



“十一五”国家重点图书出版规划项目

10000个

科学难题

10000 Selected Problems in Sciences

信息科学卷

Information Sciences

“10000个科学难题”信息科学编委会



科学出版社
www.sciencep.com

“十一五”国家重点图书出版规划项目

10000 个科学难题

10000 Selected Problems in Sciences

信息科学卷

Information Sciences

“10000 个科学难题”信息科学编委会

科学出版社

北 京

内 容 简 介

本书是《10000 个科学难题》系列丛书中的信息科学卷。为了能够尽可能全面地反映信息领域的学科全貌,编委会在以信息领域著名专家为编委会主任、副主任委员的基础上,参照了国务院学位委员会的学科结构划分原则,聘请信息领域六个一级学科的知名专家作为责任编委,据此扩展。本书的编撰工作得到了信息领域众多专家学者的大力支持。由于信息科学本身就是一门应用科学,因此,在编撰过程中围绕区分“科学难题”而非“技术难题”做了大量工作。为便于读者浏览与阅读,科普类题目放在最前面,其余则按六个一级学科分类排列。

本书可供高等院校和科研单位从事信息科学研究的工作者参考阅读。希望本书在引导广大青年学子致力于信息科学研究的同时,对从事信息科学研究的科研人员也有所帮助和启发。

图书在版编目(CIP)数据

10000 个科学难题·信息科学卷/“10000 个科学难题”信息科学编委会. —北京:科学出版社,2011

ISBN 978-7-03-031911-1

I. ①I1… II. ①I1… III. ①自然科学-普及读物 ②信息学-普及读物
IV. ①N49 ②G201-49

中国版本图书馆 CIP 数据核字(2011)第 148036 号

责任编辑:孙 芳 / 责任校对:包志虹 宋玲玲 林青梅 钟 洋
责任印制:赵 博 / 封面设计:陈 敬

科学出版社出版

北京东黄城根北街 16 号

邮政编码:100717

<http://www.sciencep.com>

双青印刷厂印刷

科学出版社发行 各地新华书店经销

*

2011 年 9 月第 一 版 开本: B5(720×1000)

2011 年 9 月第一次印刷 印张: 71 1/4

印数: 1—3 000 字数: 1 407 000

定价: 260.00 元

(如有印装质量问题,我社负责调换)

“10000 个科学难题”征集活动领导小组名单

组 长 杜占元 王伟中 李静海 孙家广
副组长 钟 掘
成 员 (以姓氏拼音为序)
韩 宇 孟宪平 王延觉 吴学梯 张先恩 张尧学
赵玉海 周德进

“10000 个科学难题”征集活动领导小组办公室名单

主 任 雷朝滋
成 员 (以姓氏拼音为序)
马晋并 吴晓东 鄢德平 朱蔚彤 朱小萍

“10000 个科学难题”征集活动专家指导委员会名单

主 任 钟 掘 赵沁平 刘燕华
副主任 李家洋 赵忠贤 孙鸿烈
委 员 (以姓氏拼音为序)
白以龙 陈洪渊 陈佳洱 程国栋 崔尔杰 冯守华 冯宗炜
符淙斌 葛墨林 郝吉明 贺福初 贺贤土 黄荣辉 金鉴明
李 灿 李培根 林国强 林其谁 刘嘉麒 马宗晋 欧阳自远
强伯勤 田中群 汪品先 王 浩 王静康 王占国 王众托
吴常信 吴良镛 夏建白 项海帆 徐建中 杨 乐 张继平
张亚平 张 泽 郑南宁 郑树森 周炳琨 周秀骥 朱作言
左铁镛

“10000 个科学难题”信息科学编委会名单

主 任 陈俊亮

副主任 姚建铨 夏建白 李衍达 冯正和 孟洛明 梅 宏
段广仁 徐可欣 王涌天

编 委 (以姓氏拼音为序)

鲍虎军	陈俊亮	陈卫标	丁耀根	段广仁	冯登国
冯正和	顾 瑛	何 力	洪 伟	侯忠生	贾英民
金 海	李醒飞	李衍达	廖桂生	刘 杰	刘 旭
刘京郊	隆克平	陆祖宏	骆清铭	梅 宏	梅 霆
孟洛明	沈作军	苏志武	孙承启	孙凝晖	谭 民
谭久彬	王 戟	王 雪	王涌天	王占山	夏建白
徐德刚	徐可欣	杨昌喜	杨德森	杨放春	姚建铨
殷勤业	袁小聪	张 健	张存林	张继峰	赵慧洁
赵正平	周傲英	周志华			

《10000 个科学难题》序

爱因斯坦曾经说过“提出一个问题往往比解决一个问题更为重要”。在许多科学家眼里，科学难题正是科学进步的阶梯。1900 年 8 月德国著名数学家希尔伯特在巴黎召开的国际数学家大会上提出了 23 个数学难题。在过去的一百多年里，希尔伯特的 23 个问题激发了众多数学家的热情，引导了数学研究的方向，对数学发展产生的影响难以估量。

其后，许多自然科学领域的科学家陆续提出了各自学科的科学难题。2000 年初，美国克雷数学研究所选定了 7 个“千禧年大奖问题”，并设立基金，推动解决这几个对数学发展具有重大意义的难题。几年前，中国科学院编辑出版了《21 世纪 100 个交叉科学难题》，在宇宙起源、物质结构、生命起源和智力起源四大探索方向上提出和整理了 100 个科学难题，吸引了不少人的关注。

科学发展的动力来自两个方面，一是社会发展的需求，另一个就是人类探索未知世界的激情。随着一个又一个科学难题的解决，科学技术不断登上新的台阶，人类社会也源源不断获得新的动力。与此同时，新的科学难题也如沐雨春笋，不断从新的土壤破土而出。一个公认的科学难题本身就是科学研究的结果，同时也是开启新未知大门的密码。


《国家中长期科学和技术发展规划纲要(2006~2020 年)》提出建设创新型国家的战略目标，加强基础研究，鼓励原始创新是必由之路。为了引导科学家们从源头上解决科学问题，激励青年才俊立志基础科学研究，教育部、科学技术部、中国科学院和国家自然科学基金委员会决定联合开展“10000 个科学难题”征集活动，系统归纳、整理和汇集目前尚未解决的科学难题。根据活动的总体安排，首先在数学、物理学和化学三个学科试行。

征集活动成立了领导小组、领导小组办公室，以及由国内著名专家组成的专家指导委员会和编辑委员会。领导小组办公室公开面向高等学校、科研院所、学术机构以及全社会征集科学难题；编辑委员会认真讨论、组织提出和撰写骨干问题，并对征集到的科学问题严格遴选；领导小组和专家指导委员会最后进行审核并出版《10000 个科学难题》系列丛书。这些难题汇集了科学家们的知识和智慧，凝聚了参与编写的科技工作者的心血，也体现了他们的学术风尚和科学责任。

开展“10000 个科学难题”征集活动首先是一次大规模的科学问题梳理工作，把尚未解决的科学难题分学科整理汇集起来，有利于加强对基础科学研究

的引导。其次，这么多科学难题呈现在人们面前，有利于激发我国科技人员，特别是广大博士、硕士研究生探索未知、摘取科学明珠的激情，而这正是我国目前基础科学研究所需要的。此外，深入浅出地宣传这些科学难题的由来和已有过的解决尝试，也是一种科学普及活动，有利于引导我国青少年从小树立献身科学、做出重大科学贡献的理想。

分学科大规模开展“10000 个科学难题”征集活动在我国还是第一次，难免存在疏漏和不足，希望广大科技工作者和社会各界继续支持这项工作，更希望我国专家学者，特别是青年科研人员持之以恒地解决这些科学难题，开启未知的大门，将这些科学明珠摘取到我国科学家手中。



2008 年 12 月

前 言

教育部、科学技术部、中国科学院、国家自然科学基金委员会等四部门于2007年联合发起了“10000个科学难题”的征集活动，其目的是通过各领域难题的提出，以提高我国学者，特别是青年学子对科学难题探索的兴趣，促进他们对科学与创新的追求。继“10000个科学难题”数学、物理学、化学卷的出版，天文学、地学与生命科学三卷即将成册之时，我们启动了“10000个科学难题”信息科学卷的征集工作，这将是我国第一次对信息科学领域的科学难题进行比较系统的梳理，我们希望本书的出版有助于激发广大青年学者对信息科学的兴趣和对解决难题的探索热情。因此，本书的出版是一项影响深远的公益事业。

为了使《10000个科学难题·信息科学卷》能够尽可能全面地反映信息科学领域的全貌，在“10000个科学难题”征集活动领导小组办公室的指导下，借鉴了数学、物理学、化学等学科的征集经验，成立了以信息领域著名专家为编委会主任、副主任委员的编委会。在组织编委会时，参照了国务院学位委员会的学科结构划分原则，聘请了信息领域六个一级学科——电子科学与技术、信息与通信工程、计算机科学与技术、控制科学与工程、仪器科学与技术和光学工程学科的知名专家作为责任编委，再按照各所属二级学科分类，根据需要聘请相关专家组成编委会。

信息科学是一门应用科学，因此，确定难题的“科学性”是我们征集工作的主要“难题”。在整个征集过程中，区分“科学难题”而非“技术难题”一直是我们讨论的热点。在撰稿专家们的积极努力下，经过编委会主任、副主任及全体编委认真负责、几上几下的讨论筛选和修改，对征集到的共821个题目、400余篇稿件进行了严肃科学的取舍。经编委会审议，最后确定录用稿件328篇，其中，科普类32篇。为便于读者浏览与阅读，我们把科普类题目放在最前面，其余则按一级学科分类排列。

信息科学是当今世界科技发展最迅速的领域之一。马可尼发明无线电、贝尔发明电话，标志着信息科技的诞生。一百多年来，信息科技的发展，不仅极大地提高了社会生产力，也引起了社会生产方式、社会交往方式乃至人们生活方式的深刻变化，社会由此从工业社会进入到了信息社会。改革开放以后，我国在信息科技领域取得了举世瞩目的成就，但在信息科技创新方面的贡献还不够多，由我国科技工作者发明或率先提出的新的原理、新的方法、重要的新思

维还相当少。在信息科学领域，我国原创性成果不足，制约了国家在信息领域科技与产业的快速发展。我国在许多信息产品的生产量上已成为世界生产大国，但离生产强国却差得较远。

科学发现的动力源于强大的社会需求，也源于人们对未知探索的兴趣与追求。我们衷心希望，《10000 个科学难题 • 信息科学卷》的出版在引发广大青年学子对信息科学产生兴趣的同时，对于想从事信息科学研究的科研工作者们也有所帮助和启发，这些科学难题的解决将是对我们编委会工作的最好回报与最高褒奖。

本书的编撰工作是在“10000 个科学难题”征集活动领导小组办公室的指导下完成的，得到了信息科学领域广大专家学者的支持，他们的无私奉献使本书的出版成为可能；同时，在整个编撰过程中，北京邮电大学科技处做了大量工作，他们的努力使编撰工作得以顺利进行；另外，科学出版社也参与了编撰工作的相关环节并给予指导。编委会对于他们的贡献表示衷心感谢！

由于整个编纂工作仅为一年，尽管在难题征集过程中我们努力避免学科领域的遗漏，但由于学术水平的限制，书中一定还存在不少缺陷和偏差，希望广大读者不吝赐教，以便再版时予以修正和提高。

信息科学编委会

2010 年 12 月

目 录

《10000 个科学难题》序

前言

科普篇

微电子的纳米时代	赵正平(3)
破译基因表达的调控密码	汪小我 李衍达 孙 啸(11)
Fermat 原理之谜	梁昌洪 陈 曦(17)
梦的重建与读脑术	尧德中 雷 旭(25)
太赫兹生物分子光谱学——生命之谜的窗口	陈晓东 刘小明(32)
水声科学与水下通信	杨德森(41)
如何持续提升计算机系统的性能?	孙凝晖 陈明宇 包云岗(51)
计算机系统如何成为可靠的系统?	宫云战 杨朝红 李晓维 韩银和(58)
自动编程:如何让计算机自动地从需求规约生成软件	王 戟(63)
电脑(计算机)能否接近人脑?	张 钹(68)
知识的自动发现	杨 强 薛贵荣(75)
自然语言处理	刘知远 马少平(82)
计算机感知	万华根(87)
如何让计算机实现人工世界?	赵沁平(95)
网络科学的基本问题	陆建华(100)
机器学习之模型选择	徐 雷(106)
操控量子世界	谈自忠 张 靖 吴热冰(111)
合作演化之谜	王 龙 陈小杰 伏 锋(117)
微型飞行器控制问题	李洪儒(120)
多相航行器的航行控制问题	关世义(128)
微纳米生物学系统状态空间建模	谈自忠 高 瑞 张明君(135)
飞行器大包线鲁棒飞行控制	易建强 仇立伟(141)
脑机接口:人类与机器的对话	李醒飞(146)
测量及仪器科学的发展和面临的科学难题	徐可欣(155)
光的七个极限问题	朱晓农(164)

空间太阳能发电站	曹良才(171)
光镊及其应用	李银妹 张晓晖(180)
全光开关研究进展	李淳飞(189)
太赫兹波	张存林 牧凯军(199)
半导体激光器面临的挑战	滕京华(211)
弱激光治疗对人体细胞生物学作用的机理和量效关系 ...	顾 瑛 陈虹霞(218)
光动力疗法的机制及量效作用规律	顾 瑛 陈虹霞(223)

专题篇

太赫兹波(光)源与探测器	曹俊诚(231)
等离子体填充微波器件	王 彬(234)
太赫兹电真空器件	鄢 扬(238)
基于过模相互作用电路的回旋放大器	刘濮鲲 杜朝海(241)
带状电子注的成形与传输	阮存军(244)
微波真空电子器件的发展	丁耀根(248)
纳米尺度场发射的理论问题	冯进军(251)
分子电子学的难题	薛增泉(253)
从医学超声成像发展看隐含信息的揭示	陈思平(256)
复合发射阴极与热-场统一发射模型	李 季(260)
自旋电子学中的自旋传输矩效应	陈培毅(263)
无缺陷硅单晶	杨德仁(267)
硅基电泵激光	杨德仁(269)
固态太赫兹源	赵正平(271)
高效率硅量子点激光器	赵新为 彭英才(274)
稀磁半导体——内禀磁性的物理机理?	张新惠(276)
IV-VI族半导体光电应用的瓶颈	吴惠桢(278)
CMOS 工艺特征尺寸的极限是什么?	陈书明 刘 尧(280)
辐射环境下的单粒子效应	陈书明 刘忠立 陈建军(283)
纳米集成电路的软错误问题	张民选(287)
量子点存储器中存取速度与保持时间的矛盾	陈坤基(290)
中间能带半导体	罗 毅 王 健(293)
多核芯片系统	杨华中(297)
集成电路的互连问题	毛军发(299)
集成电路在纳米级工艺下面临的设计挑战	李冬梅 刘力源(302)

GaN 基宽禁带半导体	王占国 (305)
半导体金刚石	王占国 (307)
ZnO 半导体材料	王占国 (310)
量子点激子太阳电池	彭英才 赵新为 (313)
多结叠层太阳电池	廖显伯 向贤碧 (316)
突破硅单结太阳电池转换效率的理论极限	王启明 左玉华 (321)
氮化物表面态——何时能探其究竟?	陈堂胜 孔月婵 (324)
固态微波器件	王晓亮 (328)
电磁黑洞	崔铁军 程 强 (332)
超级人工电磁材料	崔铁军 蒋卫祥 (334)
多层媒质的电磁并矢 Green 函数	
..... 洪 伟 周后型 宋 喆 胡 俊 郑开来 (336)	
射频电路的非线性行为描述与建模	翟建锋 周健义 洪 伟 (338)
微波毫米波功率合成	樊 勇 徐锐敏 (340)
统计电磁学	张 敏 (342)
电磁波与复杂多尺度媒质体的作用机理	盛新庆 (345)
微波的非热效应	黄卡玛 (347)
电磁辐射与散射中的近场理论	何国瑜 (349)
神经递质检测方法研究	蔡新霞 (352)
生物传感器	王雪梅 张晓璐 (354)
基于纳电子技术的 DNA 测序	刘 明 (357)
睡眠快速眼动的信息处理	孙复川 (361)
脑信号的解码	王海贤 (364)
生物系统建模及其生物鲁棒性	包家立 (367)
微生物燃料电池	顾忠泽 吴文果 (370)
单光子源	张 巍 (373)
时间的精确度量	戴一堂 徐 坤 (376)
安全方案中的单向函数	王天择 (380)
密码学中的整数分解问题	赵 岩 (382)
RSA 问题	冯登国 (384)
安全方案中的离散对数问题	张旭升 (386)
Diffie-Hellman 问题	张旭升 (389)
格约化问题	史 涛 (392)
纠错码的译码问题	张 寅 (394)

多项式分层	李振琦	(396)
偶数变元 APN 置换的存在性	林东岱	(399)
量子计算机和量子通信的出现所引发的安全协议设计问题	颜俊	(400)
弹性布尔函数的非线性度的紧上界	张卫国 肖国镇	(403)
非交互式零知识证明中的私密信息提取难题	周福才 李慧	(406)
视觉密码方案的最优化问题	刘峰	(409)
是否存在安全实用的量子公钥密码?	温巧燕	(411)
网络中的未知行为识别问题	隆克平 彭云峰	(414)
网络信息论	尹长川 罗涛 乐光新	(417)
光纤通信频谱效率的极限	喻松 顾婉仪	(420)
网络中的信息流最大化	廖建新 王敬宇	(423)
Shannon 信息论中的语义鲁棒性难题	刘健 隆克平	(425)
互联网的可测性问题	谢高岗 闵应骅 孟洛明	(428)
网络的建模方法及建模	高志鹏 邱雪松 孟洛明	(431)
网络的基本性质	邱雪松 高志鹏 孟洛明	(434)
通信网络的免疫自愈问题	隆克平 彭云峰	(436)
复杂网络中关键节点集合的确定	苏森 李勇辉 阎冬	(439)
多域协同通信机理	陆建华	(442)
空间网络科学	陆建华	(444)
非均匀采样问题	穆鹏程 殷勤业	(446)
空谱的描述与定义	穆鹏程 殷勤业	(449)
具有明确物理含义且满足边缘条件的非负时频分布的存在性	张建国 殷勤业	(452)
无线通信系统中信道容量的定义和度量	邓科 穆鹏程	(455)
图像差异感知模型	牟轩沁	(458)
能否建立多种物理场联合反演的一般理论与方法	高静怀	(461)
高性能迭代解码问题	邓科	(464)
用分段线性时不变系统逼近时变系统的条件与方法	高静怀	(467)
微波成像的稀疏表示问题	廖桂生 王伟伟	(470)
非均匀样本条件下的协方差矩阵估计问题	廖桂生 李明	(472)
语义不确定的新媒体信息量化描述问题	苏志武 曹三省	(474)
融合网络媒体服务环境中的用户行为模型方法问题	曹三省 苏志武	(477)
面向未来媒体的人机工程理论与身心服务机制	曹三省 苏志武	(479)
水下高性能声呐	杨德森	(481)

水声通信	卞红雨 杨德森(483)
处理器芯片的性能极限是多少?	范东睿(485)
超大规模并行编程	陈文光 陈 莉 冯晓兵(488)
突破冯·诺依曼结构的挑战	包云岗 陈明宇 孙凝晖(491)
计算机的存储墙	吴 松(494)
大规模分布式计算系统的建模	廖小飞(497)
海量信息存储	周 可(500)
计算系统的能耗瓶颈	喻之斌(503)
未来网络交换机理	马华东(507)
网络的自适应性	苏 森 孙 毅 谢高岗(510)
网络体系结构的优化问题	徐 恪(513)
Mu-演算模型检测复杂度	林惠民(516)
BQP 类的大小	刘 田(518)
约束求解与优化	季晓慧 刘 田 王怀氏(521)
计算复杂性若干未解决问题	李昂生 朱 洪(524)
逻辑公式可满足性问题	赵希顺 李初民(527)
Unique Games 猜想	张 鹏(530)
Tarski 指数函数问题	詹乃军(533)
DNA 计算中的检测问题	许 进(536)
三维凸多面体相交检测	朱滨海(539)
基因组间的转位距离	朱滨海(542)
非阿贝尔群上的隐子群问题	孙晓明(545)
软件性能的自动优化问题	郑纬民 陈文光 陈德颢(548)
软件可测度性及度量	徐宝文 周毓明(551)
软件质量保证承诺	
..... 赵建华 王林章 卜 磊 陈 鑫 张 天 李宣东(554)	
静态分析与形式验证	赵建华 张 健(557)
软件需求的自动获取	金 芝(560)
软件系统复杂性控制	吕 建(563)
软件模型:可表达性与可理解性	梅 宏 焦文品(566)
面向数据管理的数据模型	王 珊 陈 红(570)
数据质量可保障性	周晓方(574)
数据库管理系统体系结构面临的挑战	李建中 金澈清(577)
数据密集型计算系统的平衡性	周傲英 钱卫宁 周敏奇(580)

面向敏感数据的隐私保护	杨晓春 于 戈(583)
社会网络协同计算问题	钱铁云 彭智勇(587)
复杂知识表示与推理	
..... 刘大有 欧阳丹彤 王国胤 杨 博 王生生 漆桂林 欧阳继红(590)	
高维数据降维	乔立山 陈松灿 张道强(593)
因果推断	耿 直(596)
模式特征的抽取和表达	丁晓青(600)
数字媒体内容的理解	王蕴红(603)
自然启发的计算	焦李成 公茂果(606)
几何计算的健壮性问题	高曙明 齐建昌(609)
复杂装备和系统的高精度交互模拟分析	刘振宇(612)
从多幅照片还原立体场景;复杂三维场景重建中的对应点自动匹配问题 ...	
..... 章国锋(615)	
计算机全息图形的生成	彭群生 王章野(618)
虚拟环境与真实环境的“无缝”融合	陈小武(622)
自然高效的人机交互	王宏安 田 丰(625)
海量数据可视化分析	陈 为 屈华氏(628)
静态输出反馈下的干扰解耦	陈本美(631)
鲁棒自适应非线性控制	姜钟平(633)
大种群随机多自主体系统的自适应动态博弈	李 韬(635)
非线性控制系统分析与设计中的结构分解方法	林宗利(638)
数据驱动控制系统设计	李少远(641)
宏观经济控制问题	叶旭东(644)
目标跟踪中的数据关联问题	李晓榕(646)
基于脑电信号的人机融合控制	王行愚(650)
部分可观马尔可夫决策过程的性能优化	汪德新 曹希仁(653)
大规模网络服务集群系统节能机理的建模与控制	奚宏生 康 宇(656)
有限信息系统的辨识与适应控制	赵延龙(659)
关联系统分散控制及其应用	段志生(661)
微分平坦系统的判定	霍 伟(664)
控制器结构与控制性能之间约束关系的定量化	陈增强(667)
神经网络控制系统的优化设计	任雪梅(671)
随机系统 H_∞ 预演控制	张焕水 王宏霞(674)
滑动模态的抖振问题	李文林(677)

区间系统的鲁棒严格正实综合	郁文生 王 龙(680)
不准确量测下非完整系统控制问题	王朝立(683)
线性时变系统的渐近稳定性	张 龙 谭 峰 段广仁(686)
流体中机器人运动载体对环境力载荷的抗干扰	龚振邦 罗 均(689)
机器人的仿生自主供能	王越超 刘金国(692)
服务机器人的认知与情感	王田苗 孟 德(694)
水下仿生机器人的推进控制	谭 民 王 硕(698)
仿人机器人的双足自然行走机理与实现	黄 强 范宁军 余张国(701)
旋翼飞行机器人高机动自主飞行控制	齐俊桐 韩建达 王越超(704)
机器人视觉中的物体表达问题	胡占义(706)
高速移动机器人高精度漂移控制	刘景泰 王鸿鹏(709)
相对阶不小于 1 的 P 型迭代学习控制系统	孙明轩(712)
数据驱动自适应迭代学习控制系统的设计和分析	侯忠生(716)
自适应动态规划的结构和算法优化	刘德荣(719)
数据驱动控制理论基础问题	侯忠生(722)
学习控制系统	许建新(726)
无线网络调度策略的稳定性及分布式实现	关新平 杨 博(731)
卫星姿态系统相平面控制的稳定性分析	解永春 刘 涛(735)
复杂卫星姿态动力学建模和甚高精度姿态控制	刘一武(738)
平流层飞艇大范围变参数与多场耦合的控制	李智斌 岳宝增(740)
飞行器 PID 控制的实用稳定性	孟 斌(744)
在轨闭环参数辨识	孟 斌 黎 康(747)
飞行器的非最小相位控制问题	宗 群(750)
变体飞行器的控制问题	陆宇平(753)
欠驱动飞行器运动控制	葛 晖 杨永胜 敬忠良(756)
临近空间飞行器地磁导航与制导	蔡 洪(759)
高超声速飞行器的最优闭环制导问题	沈作军(762)
飞行器控制的操纵问题	周 军(766)
湿度测量的计量标准	王 雪 王 鹏(769)
交流量子化霍尔电阻基准的建立	王 雪 王 勇 刘 长(772)
非球面和自由曲面形状量值溯源问题	谭久彬 王伟波(775)
$\mu\text{N}/\text{nN}$ 级微小力量值溯源	齐永岳(778)
不依赖于时间基准与光速的长度自然基准及米定义	张国雄(782)
通过测定阿伏伽德罗常数定义质量自然基准	戴高良(785)

空间超高精度时空基准	张高飞 尤 政(789)
如何实现长度计量中的高精度、无导轨大尺寸测量	任大海(792)
复杂系统分形(自相似)结构与功能及行为	王 雪 张 星(795)
Mathieu 方程与谐振式传感器动态特性	樊尚春(798)
原子干涉陀螺仪中隔离重力的干涉方法	房建成(801)
延长原子自旋陀螺仪弛豫时间的方法	房建成(804)
超细光束探针的形成与传感机理	谭久彬 林 杰(807)
显微仪器信息容量极限及表征	谭久彬 刘 俭(810)
具有超宽抑制频带的光学带通滤波器形成机理与特性表征	陆振刚(813)
微位移的极限问题及表征	崔继文(816)
超短或超薄波导间光能量耦合问题及传感机理	崔继文(819)
三维超高分辨率共焦显微探测机理	谭久彬 刘 涛 刘 俭(822)
外空间极大尺度的超精密测量	谭久彬 胡鹏程(825)
分子量级精度圆、球、圆柱形状标准的形成	谭久彬 黄景志 谷 伟(828)
大尺度测量中绝对测量精度高和测量范围大之间矛盾的协调问题	 郝继贵(831)
光束直径与光束发散角的同步压缩难题	谢洪波(835)
真空中光速恒定性及影响因素研究	张国雄(837)
光在人体组织中的传播规律及观测方法	顾 瑛 赵会娟(840)
扩散光学成像中 crosstalk 的问题	蒋华北 袁 振(843)
地下电磁探测深度与分辨率的矛盾	刘长胜 林 君(847)
如何赋予机械手触觉功能?	余有龙(850)
微纳精密测量仪器中的精度控制问题	卢荣胜(853)
建立坐标测量机面向任务的测量不确定度模型与传递链函数	陈晓怀(856)
大动态范围油气勘探用地震信号传感器	李淑清 陶知非(859)
纳米三坐标测量机的精度标定	范光照(861)
衍射极限问题的突破	范光照(864)
超高分辨率光学显微镜	李奇峰(867)
中长期天气的温、湿度预测	王 鹏 王 雪(870)
量子运动测量问题	王 雪 孙欣尧(872)
超高精度、长航时、微型化惯性导航测量	冯焱颖(876)
地磁场测量高斯分析中的唯一性问题	李玉和 杨建中(880)
精密封闭内腔几何/物理特性表征与探测方法	陆振刚(883)
在体活体细胞三维实时探测与表征	谭久彬 刘 涛 刘 俭(886)

中微子质量的探测机理与表征	崔俊宁(889)
人工运动神经系统重建原理与机制	明 东(892)
能否实现人体血糖浓度的无创伤检测?	刘 蓉 徐可欣(896)
是否能依据食品的综合光学特征进行成分掺杂的快速识别?	余 辉 徐可欣(899)
经络穴位精密测量	欧阳健飞(902)
是否大多数癌症可实现血液的早期诊断?	蒋景英 王 毅(905)
微深槽三维几何量特征参数的测量方法	胡晓东(908)
肿瘤拉曼散射诊断方法学的挑战	陈 达(911)
单次曝光任意光波波形的测量	李桂芳(914)
电磁波探测地球深度的确定	朱凯光 林 君(917)
地球深部的水能直接探测吗?	王应吉 林 君(920)
欠冗余传感器网络的故障诊断	陈伟民 胡顺仁 税爱社 章 鹏(923)
光学频率的直接测量	张书练 徐春欣(926)
自由曲面光学设计理论	侯 佳(929)
真实立体感头戴式三维显示器	程德文 黄 涛 王涌天(932)
真实感空间三维显示	刘 旭(935)
光在随机介质中的传播与成像	李晓彤(938)
X 射线超衍射极限分辨成像研究	穆宝忠 王占山(942)
红外成像高分辨率与衍射极限的矛盾问题	叶振华 林 春 胡晓宁 丁瑞军 何 力(945)
远场超分辨成像	袁小聪 张斗国 明 海 匡翠方 刘 旭(949)
基于光场量子态的量子信息研究	张宽收 彭堃堃(952)
量子态的制备、操控和精密测量	张永生 郭光灿(956)
基本物理问题的量子光学检验	张永生 郭光灿(958)
弱光非线性效应	张国权 孔勇发 孙 骞 张心正 许京军(961)
新型高效红外非线性光学晶体	陶绪堂 王善朋 蒋民华(965)
新型人工电磁材料的吸波与隐身问题	何赛灵(969)
纳米表面等离子集成光子学	黄旭光(973)
表面等离子体传播的主动调控	李一岑 王 茜 袁小聪 梅 霆(975)
高灵敏度高空间分辨率表面增强拉曼散射光谱	袁小聪 苑光辉 肖晓晟 杨昌喜(978)
光学旋涡	袁小聪 张 凝 林 皎(981)
亚波长金属孔阵列光学异常透射现象的微观解释	刘海涛(985)

- 从光学衍射极限到超分辨率成像和加工 洪明辉 陈国新(989)
- 单向性高品质因子非对称光学微腔 肖云峰(996)
- 纳米光学天线 宋 勇 王涌天(999)
- 可集成的低折射率高非线性材料 张 林(1002)
- 金属在紫外-微波波段的吸收特性 兰 胜(1005)
- 太阳能电池提高光子能量利用率及转换效率的问题 董建荣(1007)
- 有机柔性发光二极管 章 勇(1010)
- Ⅲ族氮化物半导体高效发光问题 李述体(1013)
- ZnO 器件的高效电泵激子发光 宿世臣 梅 霆(1015)
- 单片光子集成的难题 梅 霆 滕京华(1018)
- 石墨烯 申泽骧 倪振华 詹 达(1022)
- 全光缓存 徐安士 肖晓晟 杨昌喜(1025)
- 无噪声的全光放大 肖晓晟(1027)
- 激光混沌通信 闫连山(1030)
- 纳米尺度集成型非线性光信号处理器件的效率问题 高士明(1032)
- 太赫兹波室温下的直接探测 张存林 苏 波(1035)
- 太赫兹脉冲波前整形 张存林 钟 华(1038)
- 基于固态增益介质能级跃迁的太赫兹波辐射机理
..... 姚建铨 徐德刚 李忠洋(1041)
- 光频段到太赫兹波频率下转换效率限制
..... 徐德刚 姚建铨 王与烨 钟 凯(1044)
- 太赫兹波大气传输统一模型 姚建铨 汪静丽 徐德刚(1046)
- 如何测量含水环境中生物样品的太赫兹频率响应 汪 力(1050)
- 基于新型人工电磁媒质的可调谐太赫兹功能器件 金飏兵(1053)
- 太赫兹表面等离子体激元 杨冬晓(1055)
- 高光子能量、高亮度阿秒级相干 X 射线源 李儒新 刘 鹏(1058)
- X 射线自由电子激光 王 东(1061)
- X 射线自由电子激光与物质作用机理 李文斌 王占山(1065)
- 激光荧光冷却 孟俊清(1068)
- 高功率中红外超连续谱激光光源 周 军 陈卫标(1071)
- 用光纤激光直接产生高功率可见光输出 楼祺洪(1075)
- 纳米尺度等离子体激光及 SPASER 宁存政(1077)
- 基于全固型光子带隙光纤的三次谐波产生的研究 栗岩锋 王清月(1081)
- 大气中超短脉冲激光的成丝 常胜江 刘伟伟(1085)

用于直接泵浦的中长波红外激光介质	程小劲(1088)
超短脉冲激光烧蚀产生的极端非平衡物质状态	张 楠 朱晓农(1091)
如何实现活体生物信息的无标记光学获取	邢 达(1094)
活体蛋白质功能的跨层次动态光学分子成像	骆清铭(1097)
神经网络回路的高分辨光学成像	曾绍群(1099)
光声显微与层析成像	汪立宏(1102)
具有大成像深度的光学无损活体生物组织医学成像	谈宜东(1106)
引力波的激光直接测量	陈卫标(1109)
无衍射光束	刘 娟 王涌天(1112)
红外与微波一体化隐身	潘建珍 陆 卫(1115)
编后记	(1118)

10000 个科学难题 · 信息科学卷

科普篇

微电子的纳米时代

The Nanoscale Era for Microelectronics

20 世纪电子学中最具魅力的革命性的发展是集成电路，其奠定了现代信息社会发展的基础。1948 年晶体管发明、1958 年集成电路的诞生都是集成电路发展史上具有里程碑意义的重大科技成果。纵观 20 世纪微技术的发展，经历了 5 个重要阶段：20 世纪初的机械，40 年代的电机，50 年代的电真空器件，60 年代的晶体管，70 年代开始至今的集成电路。集成电路的发展是以平面印刷的精细加工技术为基础，其依赖的基本器件是金属氧化物半导体场效应晶体管 (MOSFET)，如图 1 所示。




图 1 MOSFET 的结构原理图

在数字集成电路中，MOSFET 是一个开关，利用晶体管的导通和截止作为信息单元 1 和 0。在 MOSFET 中，源和漏是开关的两端，栅的控制信号通过薄的栅氧化层改变沟道中的电场，由栅来控制沟道的开与关。存在两种类型的 MOSFET：NMOS 和 PMOS，其差别在于沟道的导电载流子不同，NMOS 是电子，PMOS 是空穴，因此，开关的开启电压存在极性差别。集成电路发展的初期，一个芯片上仅集成几百个晶体管。1965 年，Moore^[1]历史性地观察发现一个规律：市场的需求（同时也是半导体工业的反应）在每一年半到两年的时间内，芯片的功能翻一番，并在 1975 年确定为集成电路中的晶体管数量每两年增加一倍，这就是集成电路发展中的“摩尔定律”。集成电路遵循按比例缩小的规律发展，不断缩小其特征尺寸（如图 2 所示），进入了微米尺度，即微电子发展阶段。1965 年 Moore 预计集成电路发展规律时，集成电路芯片上只有几百个晶体管，经过四十多年的发展，目前，集成电路芯片上已集成了上亿个晶体管，其按比例缩小发展的内在规律使得晶体管的速度更快、功耗更小。根据电流连续性方程和电荷的泊松方程可以推出沟道

电流一级近似的公式^[2]： $I_D = \frac{\mu C_{ox} w}{2L} (V_{GS} - V_{th})^2$ 。当晶体管尺寸减小，氧化层厚度减小， C_{ox} 增大，可提高沟道电流 I_D 。同时，沟道的长度 L 也减少时，会减少沟道的电阻，这些因素都使得沟道电流增大。尺寸减小的同时，引线 and 栅的电容也降低。电流的增加、电容的减小使得晶体管的开关速度加快。由于晶体管的尺寸下降， V_{GS} (栅源电压) 和 V_{th} (导通晶体管的阈值电压) 也下降，导致功耗下降。因此，按比例缩小的规律的关键是不断缩短源漏间的沟道长度，缩短载流子的输运路程，提高晶体管开关速度。同时，可大大提高芯片的集成度，降低单个晶体管的成本；但为了克服 MOSFET 的短沟道效应，增强栅电压对沟道中的载流子控制，在沟道长度缩小的同时，晶体管的沟道厚度、 SiO_2 绝缘层的厚度和电极上的电压必须等比例缩小。同时，沟道中的掺杂浓度和电荷密度要等比例提高。在宏观物理范畴中，即集成电路的特征尺寸大于等于 $0.13\mu m$ 之前，等比例缩小规律对性能提高有很大益处。微电子发展到 20 世纪末仍处在宏观物理学范畴内，人们可尽享集成电路按比例尺寸缩小发展所带来的好处。但进入 21 世纪后，当微电子的特征尺寸缩小到纳米尺度，进入介观物理学范畴时，按比例缩小发展规律遇到了新的挑战。




图 2 集成电路特征尺寸示意图^[3]

1993 年，在集成电路进入超大规模集成电路 (VLSI) 时，有微电子专家^[4]曾定义，纳米电子学是 VLSI 中集成元素的特征尺寸小于 $0.1\mu m$ 。进入 21 世纪后，微电子的特征尺寸在 2004 年进入了 90nm 节点，标志着微电子进入了纳米时代，这个尺度和半导体中电子的德布罗意波长相当。在固体电子学中，半导体中的电子也具有波粒二相性，其波动性表现为：电子的空间位置分布在动量空间中遵循概率波函数规律，其波长为 100nm 尺度，在这个尺度中，电子的量子效应将起重要作用。

按照 ITRS 2009 年的预计^[3]，微电子进入纳米时代后，按比例尺寸缩小的规律继续发展，2007 年达到 65nm，2010 年达到 45nm，2013 年达到 32nm，2016 年达到 22nm，2019 年达到 16nm，2022 年达到 11nm，2024 年达到 9nm，发展趋势是逐步走向 MOSFET 的理论极限，即从介观物理范畴到微观物理范畴。当集成电路特征尺寸低于 32nm 后，晶体管有效栅长将低于 15nm，图 3 给出了平面 MOSFET 在有效栅长低于 15nm 的结构原理图^[5]。有效栅长低于 15nm 之后，微电子将面临一系列科学难题。




图 3 32nm 平面 MOSFET 尺寸缩小的挑战^[5]

(1) 栅的漏电增加，晶体管的静态功耗增加。当有效栅长低于 15nm 后，栅控制沟道电流的隔离层——栅氮氧化层厚度已减至 $15\text{\AA}$ ^① 以下。量子力学隧道效应将显著增加栅的漏电流，这将增加晶体管的关态功耗。同时，短沟道效应要求增加沟道中的掺杂浓度，这将使得沟道中载流子的迁移率下降，影响驱动电流。

(2) 短沟道效应影响扩大。由于沟道偏短，源区和漏区的内建电势渗透到沟道深处，将会导致栅电极丧失控制沟道电势的能力。同时，在晶体管关断时，由于源漏之间的量子力学隧穿效应产生亚阈值漏电流，导致关态电流增加，增加静态功耗。

(3) 提高驱动电流，要求不断提高载流子的迁移率。在 CMOS 特征尺寸进入 65nm 后，采用应力工程的新工艺来提高载流子迁移率，45nm、32nm 及 22nm 均不断发展新的应力工程器件。N 沟道 MOSFET 采用覆盖介质膜对沟道

① $1\text{\AA}=0.1\text{nm}=10^{-10}\text{m}$ 。

中硅晶体产生应力,载流子迁移提高 20%。P 沟道 MOSFET 采用嵌入 SiGe 合金到源漏区对沟道硅晶体产生应力,载流子迁移率提高 30%。22nm 后,要采用迁移率更高的 SiGe 和 III-V 族半导体新材料。

(4) 低维晶体管的电场控制。当有效栅长进入亚纳米范围(小于 10nm)时,沟道的厚度大大减薄,体硅 MOS 的沟道变成薄膜 SOIFET。为了加强对薄膜 SOIFET 沟道中电子的静电控制(如图 4 所示),未来晶体管结构将从三维(体硅 FET)向二维(薄膜 SOIFET)发展,进而发展到一维(纳线基 FET)^[6]。在低维 FET 中,由于量子力学的原因,载流子的输出机理以弹道运输为主,为增强其运输速度,采用双重栅或环栅的新结构。





图 4 纳米尺度 MOSFET 从三维到二维及到一维的发展^[6]

(5) “后 CMOS”发展阶段中新器件的选择。当集成电路的特征尺寸进入亚纳米,CMOS 栅长只有几纳米,介质层厚度只有几个原子层时,也就进入“后 CMOS”发展阶段。有很多新的器件在发展研究,但目前都不成熟,谁将成为集成电路的主流器件尚不清楚。

微电子进入纳米时代后,发展趋势有两条科学路线:其一是继续按从上到下的方法,以 CMOS 技术为基础,不断改变栅结构,改变沟道材料,增强控制电子的能力;其二是从下到上的新思路,采用新的器件结构,走自组装的发展方法。图 5 给出未来近十年第一种方法的发展示意图。

为了解决栅漏电问题,采用叠层栅的结构,用高 K 介质代替 SiON,可减少栅的漏电,也可使等效氧化层厚度继续按比例缩小。用金属栅代替多晶硅栅,

图5 等比例缩小工艺技术的发展趋势^[3]



限制多晶硅耗尽，解决多晶硅在高 K 介质上的 V_T 钉扎问题，同时能屏蔽软光学声子效应。为了加强对沟道载流子的电场控制，从三维体 MOS 走向二维全耗尽 SOIMOS，走多重栅的一维控制。提高沟道载流子迁移率的方法目前主要是应力工程，已经经历了三代的应力工程，可延伸到 22nm。到 2016 年，可能选用电子和空穴迁移率比硅更高的锗薄层来代替应力硅。到 2019 年，可能选用更高迁移率的 III-V 族化合物半导体，如 InAs、InGaAs 代替锗的沟道。选择新的材料将有栅叠层、钝化层、硅上异质薄层生长等新的问题解决。

在从上而下方法的发展中，从系统设计的角度走功能多元化异构集成的方法，以提高系统整体的性能，即所谓“more than Moore”，如图 6 所示。对非数字功能的芯片(RF、功率控制、无源元件、传感器、生物器件等)，在系统水平上集成于封装(SIP)或芯片(SOC)。

从下而上发展的方法的新器件是微电子纳米时代中最活跃的前沿研究领域。科学家们从碳基纳电子新材料，单个电子、单个原子、单个分子，量子点中电子的自旋态，纳电子机械等新的视角，不断探索“后 CMOS”时代的科学奥秘。科学家按与 MOSFET 关联度和非相关性把新的器件分成三类：MOSFET 沟道材料的延伸，电荷基 CMOS 器件的延伸，以及非 FET、非电荷基的“后 CMOS”器件。图 7 是改变沟道材料延伸 CMOS 的示意图。在第一类器件中，有纳线 FET、碳纳米管 FET 和石墨烯纳带 FET。

纳线 FET 用半导体纳线代替平面 MOSFET 的沟道，纳线的直径仅有 0.5nm，可由硅、锗、III-V 族化合物、II-VI 族化合物等多种半导体制成。纳线

具有量子限制的性质，一维电导，可以减少短沟道效应和其他尺寸效应。现已有 12MHz 工作的纳线 CMOS 逻辑门的报道。

图 6 摩尔定律的发展趋势^[3]图7 改变沟道材料的方法延伸发展 CMOS^[3]

碳纳米管 FET 用碳纳米管代替平面 MOSFET 沟道，单壁碳纳米管直径在 $0.7\sim 2\text{nm}$ 之间，其载流子具有高的迁移率，通过三维栅控可达到最小的亚阈值斜率。目前，碳纳米管 FET 的 f_T 达到 4GHz ，比 32nm CMOS 的开关速度快近 50 倍。

石墨烯纳带 FET 用石墨烯薄膜代替平面 MOSFET 的沟道，其厚度为几个原子层，纳带宽度小于 5nm ，比碳纳米管更易光刻成形，迁移率更高，可达 $10000\text{cm}^2/(\text{V}\cdot\text{s})$ 。石墨烯纳带 FET 是 2004 年刚诞生的新器件，正在快速发展，2009 年报道其 f_T 达 50GHz 。

电荷基 CMOS 新扩展器件的功能与场效应器件不同，其包括利用带间隧穿效应的隧穿 FET、利用冲击离化效应的 I-MOS、利用磁阻效应的自旋 FET、利用量子点中单电子库仑阻塞效应的单电子器件、利用纳电子机械低功耗效应的 NEMS 开关。基于铁电电容的负栅电容 FET 如图 8 所示，用铁电介质代替 MOSFET 叠层栅的介质，可建立一个微型电压变压器，放大栅的电压，导致更低的亚阈值斜率、电压及功耗。




图 8 “后 CMOS” 新器件材料与界面^[3]

非场效应器件、非电荷基的新器件提供高性能计算，但不采用传统的冯·诺依曼计算结构，其包括铁磁逻辑器件的共自旋器件、利用铁磁线中磁畴壁在不同磁化方向的传播机理形成的运动磁畴器件、利用 MIM 电化学开关机理的原子开关、利用分子接触、分子密度功能理论和分子开关等原理形成的分

子开关器件、利用双层石墨烯构成的双层自旋场效应晶体管(其层间小电压能产生大的隧穿电导)。

众多的“后 CMOS”器件如天上的繁星闪烁着,每颗星都给科学家们打开探索之门,但哪颗星能产生,以地球上原料最充足的硅和延续了五十多年仍充满活力的 CMOS 这样的效果,成为“后 CMOS”集成电路的主流器件,我们等待着。

参 考 文 献

- [1] Moore G E. Cramming more components into integrated circuits .Electronics ,1965 ,38(8) .
- [2] Jaeger R C .Microelectronic Circuit Design .Boston :WCB/McGraw-Hill,1997 .
- [3] Allan A .ITRS roadmap ,2009 ITRS Conf . ,2009 .
- [4] Bogomolov B K .Nanoelectronics and nanotechnology-basis of information of a society . International Forum on Strategic Technologies ,2008 ;264—265 .
- [5] Kuhn K J .CMOS scaling beyond 32nm :Challenges and opportunities .Design Automation Conference ,2009 ;310—313 .
- [6] Yu B .Nanoelectronics ;Towards end of scaling beyond .Solid-State and Integrated Circuit Technology Conference ,2006 ;19—22 .

撰稿人：赵正平
中国电子科技集团公司

破译基因表达的调控密码

Deciphering the Regulatory Code of Gene Expression

人类基因组计划的标志性成果就是获得一本“生命天书”，这本天书的载体就是我们的基因组，其既简单，又复杂。简单是因为它仅由 A、T、C、G 等 4 个字母构成；复杂是因为它包含了人类生长发育的所有信息，隐含了我们生老病死的规律。人从一个受精卵分裂成多个细胞，进而在不同时间、不同位置上分化为各种类型的细胞，构成组织和器官，直到发育成一个完整的个体，这个过程受到严格的程序控制，任何差错都有可能导致严重的缺陷和疾病，而控制着这一切的遗传信息都记录在基因组 DNA 的双螺旋分子中。通常，人体中的每个细胞都含有相同的基因组 DNA，但在不同类型的细胞中，能将遗传信息表达出来的基因各不相同，从而能够让各类细胞行使不同功能。生命的信息究竟是如何组织在基因组中，如何实现对基因表达的精确控制呢？这是目前科学研究者所关注并努力探索的重大科学难题。

1. 基因组的两类信息

基因是指携带有遗传信息的 DNA 序列，基因表达是指 DNA 转录为 RNA，RNA 翻译成蛋白质的过程。基因组编码有两类主要信息：一是编码蛋白质的基因；二是引导基因在特定时空表达的调控信息。20 世纪 60 年代，科学家揭示了基因的信息编码方式，即三联体密码。基因密码最早在简单的生命体细菌中被发现，这种基本的遗传指令为所有生命所共享。基因密码的发现拉开了在分子水平上进行生命信息科学研究的序幕，启动了人类探索遗传语言奥秘的进程。基因组 DNA 序列并非是一种简单的生物分子序列，而是一种语言的表示形式，该语言以特殊的方式组织和编码生命的遗传信息，控制生物体的生长发育过程，控制生物体的性状。DNA 分子通过复杂而准确的信息复制、信息传递和信息表达，构成不同类型的细胞，形成不同的组织和器官，最终发育成为完整的生命体，一个具体的生命体是基因组信息的生动表现。从 20 世纪 90 年代以来，随着基因组学研究的不断深入，人们对基因组中信息组织结构和信息组织规律的认识也在不断深化。在人类基因组计划开始前，科学家们估计人类至少拥有十万个基因。然而基因组测序结果表明，人的基因组仅包含两万多个基因。相比之下，就连低等动物线虫的基因组也有近两万多个基因，而且大部分基因编码的蛋白质与人类基因非常相似。显然，基因的数量并不能反映生物体的复杂程度。

随着研究的深入,人们逐渐认识到在物种进化过程中,调控机制的演变起着关键性作用,越高等的生物,其基因表达的调控机制就越复杂、精细,能在特定时间和特定细胞中激活特定的基因,按照预先设定的程序进行增殖、分化和行使生理功能。在人类基因组中,蛋白质编码基因仅占基因组总长度的 1.5%,而在剩余的非编码序列中,蕴藏着调控基因表达调控的重要信息^[1],这些信息引导细胞在特定的时空执行基因指令,合成蛋白质产物。

从信息学的角度来看,蛋白质编码序列包含的信息相当于制造生命机器的“蓝图”,或者说相当于待处理和加工的合成蛋白质产物的“数据”,而非编码序列中的调控信息则相当于“程序”或“指令”,这些程序指导如何实现“蓝图”,指定如何对“数据”进行加工和处理,确定如何在不同时间和不同空间调节基因表达,控制蛋白质合成。基因组 DNA 序列好比是计算机上的一串代码,但不是储存在电子芯片上的 0、1 代码,而是储存在染色体上的四字符代码串。在计算机中,数据与程序是相对分立的,而在染色体上,它们则是相互嵌套的,也就是说,蛋白质编码信息和表达调控信息是融合在一起的。如同计算机程序对输入数据处理以后产生输出结果一样,染色体上的基因经过调控程序的解码和翻译产生蛋白质机器,从而发挥生物学功能。无论是数据还是程序,都属于信息,但它们的作用不一样,信息组织的规律也不一样。蛋白质编码基因数据的组织形式就是简单的三联体密码,是我们所熟知的,而关于基因调控指令和调控程序的组织形式我们却知之甚少。

对基因表达调控的解码是从根本上认识生命起源和人类生老病死等基本生命现象的关键。掌握了其中的规律,就有可能通过干预基因表达、控制细胞的形态和功能,实现对生命的控制和改造。例如,2006 年,日本科学家 Takahashi 等通过改变少数几个基因的表达,使已分化的成纤维细胞变成与胚胎干细胞类似的“多能干细胞”,实现了对细胞的“重编程”^[2],这对疾病治疗、器官移植与再造等具有重大意义。

2. 真核生物基因表达调控的复杂性

基因编码指令是原核生物和真核生物所共有的,然而,真核生物具有更加丰富、精细的调控指令系统,这是原核生物所不具备的。首先,真核生物具有复杂的转录调控机制,真核基因的转录受到多种转录因子的作用,它们共同控制着基因的转录过程,综合调节遗传信息从 DNA 到 RNA 的传递。其次,真核基因具有明显的结构特点,其由非连续的编码序列(外显子)所构成,这种独特的结构为真核基因调控提供了更为复杂、精细的调控方式。第三,真核生物具有细胞核和细胞器,形成了不同的功能分区,基因的转录与翻译过程被分离开来,在多个环节进行调控。另外,真核生物基因组具有复杂的染

色质结构, 基因表达受到表观调控因素影响。下面对真核基因表达的调控环节做一简要介绍。

3. 真核基因表达调控的主要环节

基因表达过程受多种因素控制, 大致分为转录调控和转录后调控两大环节。

1) 转录调控

转录是指以 DNA 为模板, 在 RNA 聚合酶催化下合成 RNA 的过程^[3]。通常, 基因的转录无法由 RNA 聚合酶独自完成, 需要依赖多种转录调控蛋白(转录因子)的协同作用(如图 1 所示)。基因的周围存在能被转录因子结合的特定 DNA 片段, 它们被称为调控序列, 是基因组调控信息的表现形式。调控序列就如同我们寄信时的邮政编码一样, 蕴含该基因在特定发育阶段、特定组织中表达的“地址”信息。当一个基因需要被转录时, 特定的转录因子会特异性地结合到调控序列上, 调节该基因的转录过程。各种转录因子的作用方式和功能不尽相同, 有的是基因转录所必需的基本调控因子, 有的则对不同基因实行差异转录; 有的会增强基因的转录效率, 而有的则抑制转录; 有的近程作用于基因, 而有的则远程作用于基因, 它们的组合效应决定了基因在该细胞中的转录速率。人类基因组包含上千种不同的转录因子, 每种转录因子可以调控成百上千个基因, 每个基因可能同时被多种转录因子调控。与此同时, 编码转录因子的基因表达过程也同样受到严格控制, 不同类型细胞中表达的转录因子存在显著差异。因此, 同样一个基因在不同细胞中可能被不同的转录因子调控, 从而导致其表达量不同。由此可见, 转录因子的调控关系非常复杂。到目前为止, 人类基因组中大部分的蛋白质编码基因已经被找到, 但对基因周围调控序列和调控规律的认识还非常有限。

基因转录过程中的另一个重要问题是各种转录因子与 RNA 聚合酶需要接近紧密包裹在染色质中的 DNA。真核细胞中的 DNA 通常以染色质的形式存在于细胞核内。染色质由蛋白质、DNA 和少量 RNA 组成, 其基本结构单元是核小体, 由组蛋白和包裹在上面的 DNA 组成。核小体经过多个层次的折叠、包裹, 形成复杂的染色质结构。在生物生长发育的过程中, 细胞核内的染色质结构会相应地发生一系列变化, 通过改变基因组 DNA 包裹的疏密程度, 改变基因组上一些特定区域的转录活性, 从而导致特定基因的表达或沉默(如图 1 所示)。这种影响基因转录活性而不涉及 DNA 序列改变的基因表达调控方式称为表观遗传调控^[4]。表观遗传调控的具体表现形式包括核小体定位、DNA 和组蛋白的化学修饰及非编码 RNA 等, 这些表观遗传因素能改变染色质的状态和结构, 从而促进或抑制转录因子与 DNA 的相互作用。例如, 核小体对不同的 DNA 序列具有不同的亲和力, 它在基因组上的定位会封闭转录因子的结合位点; DNA 和组蛋

白的不同化学修饰则会影响核小体的结构, 改变 DNA 被包裹的松紧程度; 在更宏观的层面, 细胞内的染色质会发生相互作用并形成特定的三维结构^[5], 将基因组大致划分为两个区域: 一个是活跃基因区, 另一个是不活跃基因区, 需要被表达或关闭的基因在这两个区域间移动^[6]等。




图 1 基因转录调控示意图

TF. 转录因子; TFBS. 转录因子结合序列

2) 转录后调控

基因转录后在 RNA 水平同样受到多种因素的控制。高等生物基因通常是由非连续的序列(外显子)所构成, 这种独特的结构为基因表达提供了更为复杂、精细的调控方式。在剪接过程中, 剪接调控因子根据序列特征特异性结合到前体 RNA 上, 协助或阻止剪切酶发挥作用, 从而能在不同细胞中按照不同方式处理 RNA, 形成不同的剪接结果(如图 2 所示)^[7]。通过选择性剪接(用不同的外显子组合来编码不同的蛋白质), 一个基因可以生成多个转录本, 从而编码不同的蛋白质产物。人类基因组中超过 80% 的基因可以按照不同的方式被剪接, 从而大大增加了蛋白质产物的多样性。

microRNA 抑制是另一种重要的转录后调控因素。microRNA 是一类长度约 22 个核苷酸的内源性单链非编码 RNA 分子, 它能根据核苷酸序列信息识别特定靶基因的 mRNA, 抑制该 mRNA 的翻译过程或导致其降解, 从而对靶标基因




图2 基因的选择性剪接(用同一段DNA加工产生不同的RNA)

的表达过程起到负调控的作用。目前,已知的人类 microRNA 已经近千个,科学家估计每个人类 microRNA 平均能调控数百个靶基因。与转录因子类似,不同microRNA在人体不同发育阶段和不同组织中的表达水平有显著差异,它们与转录因子调控协同作用,构成了复杂的调控网络。研究表明, microRNA 对维持不同类型细胞的形态和功能起到了重要作用。

此外,转录后调控还包括 RNA 分子的化学修饰、mRNA 分子不同的亚细胞定位等,这里不再一一赘述。

综上所述,真核基因的表达过程在多个环节、不同层次都受到严格调控,而不同层次之间的调控因素会相互影响。例如,染色质的状态和结构受特定转录因子的影响,有的转录因子可以介导 DNA 和组蛋白的化学修饰,而染色质的移动与转录因子之间的蛋白质相互作用有关^[8]。最近更有研究表明,基因的剪接受到组蛋白修饰和染色质空间分布的影响。由此可见,转录与转录后多个层面的调控因素协同作用,构成了极其复杂的调控网络,共同决定了特定基因在特定发育阶段和组织中的表达^[9]。这是一个非常精细复杂的过程,一切都按照“程序”有条不紊地进行,其稳定有序性令人惊叹!

4. 面临的挑战

近年来, DNA 深度测序和基因芯片等新技术的出现为科学家大规模测量细胞中基因表达量的高低、转录因子与调控序列的相互作用、基因的选择性剪接等创造了条件,人们能够以前所未有的速度获取更加高通量和高分辨率的数据^[10]。然而,数据本身是不产生知识的,如何有效挖掘它们、整合多层次信息、建立模型描述和解码复杂的基因表达调控过程是研究中面临的难题。从技术上,各种生物学高通量数据的含义、获取手段、存储方式、数据质量都不相同,但共同的特点是数量巨大、关系庞杂。如何对这些数据进行有效存取、比较、检索、运算等基本处理,对计算能力、存储能力和算法效率提出了挑战。在此基础上,怎样从数据中发现规律、找到联系?怎样将不同层面的数据结合起来构建描述基因表达调控的网络和系统,并对其进行解析?怎样将各种分子层面的

模式和规律与复杂的发育过程和疾病联系起来等? 这些都是我们面临的难题, 若要有效解决, 需要生命科学与信息科学等多学科的交叉研究, 从系统的角度对复杂的基因表达调控网络进行研究, 才有可能揭开其中的奥秘。

目前来看, 基因表达调控的“密码”可能十分复杂, 既涉及复杂的生物学机制, 也涉及复杂的信息编码、信息传递和信息表达过程, 需要多学科交叉去探索这样一个复杂的系统。完全解析调控信息编码则是一个长期的目标, 需要我们不懈地努力去接近这个目标。突破这一科学难题具有重大的意义, 相关的研究成果不论是在医学上, 还是在人类认识自身方面, 以及改造生物、创造新的生命都具有重要作用。

参 考 文 献

- [1] Hood L, Galas D. The digital code of DNA. *Nature*, 2003, 421(6921): 444—448.
- [2] Takahashi K, Yamanaka S. Induction of pluripotent stem cells from mouse embryonic and adult fibroblast cultures by defined factors. *Cell*, 2006, 126(4): 663—676.
- [3] Amaral P P, Dinger M E, et al. The eukaryotic genome as an RNA machine. *Science*, 2008, 319(5871): 1787—1789.
- [4] Bernstein B E, Meissner A, Lander E S. The mammalian epigenome. *Cell*, 2007, 128(4): 669—681.
- [5] Lieberman-Aiden E, et al. Comprehensive mapping of long-range interactions reveals folding principles of the human genome. *Science*, 2009, 326(5950): 289—293.
- [6] Hubner M R, Spector D L. Chromatin dynamics. *Annu. Rev. Biophys.*, 2010, 39: 471—489.
- [7] Barash Y, Calarco J A, Gao W, et al. Deciphering the splicing code. *Nature*, 2010, 465(7242): 53—59.
- [8] Barrera L O, Ren B. The transcriptional regulatory code of eukaryotic cells—insights from genome-wide analysis of chromatin organization and transcription factor binding. *Curr. Opin. Cell Biol.*, 2006, 18(3): 291—298.
- [9] Busser B W, Bulyk M L, Michelson A M. Toward a systems-level understanding of developmental regulatory networks. *Curr. Opin. Genet. Dev.*, 2008, 18(6): 521—529.
- [10] Shendure J, Ji H. Next-generation DNA sequencing. *Nature Biotechnology*, 2008, 26(10): 1135—1145.

撰稿人: 汪小我¹ 李衍达¹ 孙 啸²

1 清华大学自动化系

2 东南大学生物电子学国家重点实验室

Fermat 原理之谜

Mystery of Fermat Principle

1. Fermat 本人就是一个最大的谜

Fermat 原理的提出者——Fermat (1601~1665) 在解析几何、数论、概率论和光学等数学和物理领域给出了众多超一流的成果。Fermat 最后定理为

$$x^n + y^n = z^n (n = 3, 4, 5, \dots) \quad (1)$$

不存在整数解。直到提出问题后的 358 年 (1995 年), 才被剑桥大学的数学家 Wiles 攻克^[1]。

本文深入讨论 Fermat 在完全不同的物理光学领域, 对光行走的路线做出的巨大创新成就。1662 年, 61 岁的 Fermat 深刻认识到自然界总是以最简单的行为方式来达到其目的, 他具体表述为: “当光经过两种介质的界面时, 无论是反射还是折射, 总是能用时间最短的路径运行。” 这就是闻名于世的 Fermat 原理。

2. 自然规律的表述方式^[2]

人类要和自然和谐相处, 首要的是认识自然, 揭示自然规律。几千年来, 关于自然规律究竟如何表述? 人们经历了一个极其漫长的发展过程。图 1 给出了简要的框图。




图 1 自然规律表述的发展历程

Fermat 原理的亮点在于: 首先, 它并不具体指出光的行走路线 (也即方程), 而是给出了光运动所遵循的极值原则——按最小时间进行, 这确实是一个原创性的思想。此后, Maupertuis 的发展、Euler 的变分, 其思想均与 Fermat 一脉相承。其次, Fermat 原理是一个无坐标原理, 它根本不需要具体坐标, 所以越发显示其普遍性。

之后, 汤姆孙在静电学中也提出了导体上电荷分布的极值原则——导体上的电荷应该是这样分布的: 它使静电储能保持最小, 即汤姆孙原理, 由此开创了自然规律极值表述的一条新路 (如图 2 所示)。




图2 导体上电荷分布 $\rho(r)$ 的汤姆孙原理

大家知道，在 Fermat 原理提出之前，已经有反射定律和折射定律，即

$$\begin{cases} \theta_i = \theta_r \\ \frac{\sin \theta_i}{\sin \theta_r} = \frac{v_i}{v_r} = \frac{n_r}{n_i} \end{cases} \quad (2)$$

$$\quad (3)$$

式中， v 表示速度； n 表示折射率。如图 3 所示。

Fermat 原理给我们带来的第一个谜是：原理的表述是代数的，但结果却是几何的。

3. 极小值还是极大值

Euler 最推崇极值原则，他说：“因为宇宙的结构是最完善的，而且是最明智的上帝的创造，因此，如果在宇宙里没有某种极大或极小的法则，那就根本不会发生任何事情。”^[3]

关于宇宙究竟取极大值还是极小值，科学界几乎也是一边倒的倾向——“大自然基本是懒惰的，它总是争取最小量的路线。”所以，由 Fermat 原理发展而来的也称之为最小作用量原理。

然而，事实并非如此，让我们来研究图 4 所示的二维椭圆柱凹面镜的反射情况。




图3 光的反射定律和折射定律




图4 二维椭圆柱凹面镜上的光反射

考虑一个特例：先从 A 点 (x, y) ($x > c$, $y > 0$, $c = \sqrt{a^2 - b^2}$ 为焦距) 通过反射镜反射到 B 点，而 B 点正好在椭圆的一个焦点 C_2 上。图 4 中，长短半轴分别为 a 和 b ，

$$OC_1 = OC_2 = c = \sqrt{a^2 - b^2} \quad (4)$$

式中, a 为焦距。众所周知, 椭圆有以下两个重要性质:

(1) 两焦点(C_1, C_2)到椭圆任意一点的距离和为 $2a$ 。

(2) OC 平分 $\angle BCA$, 也即

$$\theta_1 = \theta_2 \quad (5)$$

且 OC 是椭圆 C 处的法线。

显然, $AC_1 C \rightarrow CB$ 这条光线满足入射角等于反射角, 且路径和为

$$AC + BC = AC_1 + C_1 C + CB = \sqrt{(x-c)^2 + y^2} + 2a \quad (6)$$

为了比较, 取 y 轴上 D 点, 即光线另外走 $AD \rightarrow BD$ 。注意到, $BD = C_1 D = a$ (因为 $BD + CD = 2a$ 及对称性), 则

$$AD + BD = a + \sqrt{x^2 + (y+b)^2} \quad (7)$$

再考虑三角形 $C_1 DA$ 中,

$$AC_1 + C_1 D > AD \quad (8)$$

有

$$\sqrt{(x-c)^2 + y^2} + a > \sqrt{x^2 + (y+b)^2} \quad (9)$$

或者写成

$$\sqrt{(x-c)^2 + y^2} + 2a > \sqrt{x^2 + (y+b)^2} + a \quad (10)$$

也即

$$AC + BC > AD + BD \quad (11)$$

在这种凹面镜条件下, 光走的是极大路径! 这真是石破天惊的一个结论。注意到, 文献[4]中用脚注的方式给出: “有一些例子, 如光线从凹面镜的反射, 这时光线所取的路径需要极大的时间, 这个事实为 Fermat 所知, 并由 Hamilton 明确叙述过。”

尽管一些学者认识到 Fermat 原理中最小时间原则存在问题, 但对于什么情况下出现极小值, 什么情况下出现极大值, 并没有提出思想和准则, 从而构成了 Fermat 原理之谜 2。

4. 相速 v_p 还是群速 v_g ^[5]

在 Fermat 原理的发展中, 有一个重要的关节点必须提及, 即当时从不同视角同时存在两种不同的极值原理: Fermat 原理和 Maupertuis 原理, 并且恰好一个与光速成反比, 另一个与光速成正比, 形成显著矛盾。

时代造就英雄。正是年轻的法国博士生德布罗意以极为尖锐的眼光考察了量子力学, 深刻揭示了当时存在的两种极值原理中: Fermat 原理与相速 v_p 相联系, 而 Maupertuis 原理则与群速 v_g 相关联, 从而统一了两种不同的表述方式,




图5 两种极值原理对应两种不同光速

如图5所示, n 表示相对折射率, 有

$$n = \frac{c}{v_p} \quad (12)$$

而 P 表示动量(的大小), 有

$$P = m v_g \quad (13)$$

德布罗意利用普朗克量子论(E 表示能量, h 表示普朗克常数, ν 表示辐射电磁波的频率)

$$E = h\nu \quad (14)$$

和爱因斯坦相对论(m_0 表示物体静止时的质量, m 表示物体以速度 v 运动的质

量, $\beta = \frac{v}{c}$)

$$E = mc^2 = \frac{m_0 c^2}{\sqrt{1 - \beta^2}} \quad (15)$$

导出了与普朗克能量关系完全对应的动量关系, 即

$$P = m v_g = m_0 v_g / \sqrt{1 - \beta^2} = \frac{E v_g}{c^2} = \frac{h\nu}{v_p} = \frac{h}{\lambda} \quad (16)$$

上式中应用了

$$\nu\lambda = v_p \quad (17)$$

如图6所示。



图6 量子的能量关系与动量关系

再计及

$$\nu\lambda_0 = c \quad (18)$$

$$n = \frac{c}{v_p} = \frac{\lambda_0}{\lambda} = \left(\frac{\lambda_0}{h} \right) P \quad (19)$$

计及 $\frac{\lambda_0}{h}$ 为常数, 可知

$$\oint n dS = \oint P dS = 0 \quad (20)$$

确实证明了 Fermat 原理和 Maupertuis 原理在光运动中的统一。

Fermat 原理的物理意义表示相位波射线, 对应相速 v_p , 它和能量守恒不直

接相关, 即 Fermat 原理不会破坏能量守恒或坡印亭定理。

近年来提出的双负媒质或左手材料, 简单的可以理解为负折射率 $-n$ 或负相速 $-v_p$ (在这种表示中, n 和 v_p 为正), 这时, 从空气向 $-n$ 媒质折射时, 折射线与入射线处于法线同侧, 如图 7 所示, 并给出

$$\frac{\sin \theta_i}{\sin \theta_t} = -\frac{c}{v_p} \quad (21)$$

特别当媒质 1 为 n , 而媒质 2 为 $-n$ 时, 则有

$$\frac{\sin \theta_i}{\sin \theta_t} = -1 \quad (22)$$

这种情况下, 从 A 到 B 光以群速 v_g 运动需要时间, 但若 A 、 B 处于上下对称时, 以 v_g 运动时总时间 (波相位) 为 0。于是, 可以有无数条射线从 A 到 B , 这时似乎 “光找不到北了 !”, 这又成为 Fermat 原理谜之 3 (如图 8 所示)。




图 7 负折射现象




图 8 n 与 $-n$ 介质界面, 光存在无数条可运行路径

5. 能量 E 和作用量 S ^[3,6]

从 Fermat 原理发展成为最小作用量原理过程中, Lagrange 和 Hamilton 是功不可没的。

目前, 普遍的最小作用量原理可以写为

$$\begin{cases} \delta S = \delta \int_{t_0}^{t_1} L dt = 0 \end{cases} \quad (23)$$

$$L = T - V \quad (24)$$

上式中, $\delta S = 0$ 即著名的最小作用量原理, S 表示作用量, 而 Lagrange 函数 $L = T - V$ 是能量中动能 T 与位能 V 之差。特别有意思的是, 能量 E 恰好是动能 T 与位能 V 之和, 也即

$$E = T + V \quad (25)$$

人们在了解能量 E 的同时, 对于作用量 S 总有一种说不出的陌生。Fermat 原理与相速 v_p 对应, 给了我们很大的启示(如图 9 所示)。




图 9 能量 E 和作用量 S 的物理意义

正是年轻的德布罗意深刻指出普朗克公式, 即

$$E = h\nu = h\left(\frac{v_p}{\lambda}\right) \quad (26)$$

从本质上揭示了粒子(能量 E)和波(v_p 和 λ)的有机结合。

美国的物理学奇才 Feynman 在深入探索量子力学最小作用量原理的过程中, 终于找到了量子力学独立的第三种形式——路径积分, Feynman 给出两个不同时刻 t_a 和 t_b 的波函数 ψ 的联系, 即

$$\psi(x_b, t_b) = \int K(x_b, t_b / x_a, t_a) \psi(x_a, t_a) dx_a \quad (27)$$

式中, 核函数 K 为

$$K(x_b, t_b / x_a, t_a) = \sum e^{is(b,a)/h} \quad (28)$$

这里, 要提出的 Fermat 原理谜之 4 是: 为什么能量(振幅) E 与 $T+V$ 相关, 而作用量(相位) S 中 Lagrange 量 L 与 $T-V$ 相关?

6. 电磁最小作用量原理^[7]

1977 年, Morishita 和 Kumagai 两位日本学者发表在电磁领域中的最小作用量原理^[7]具体表述为

$$S = \int_{t_0}^{t_1} L dt \quad (29)$$

式中, Lagrange 函数为

$$L = \int_r \left\{ \frac{1}{2} [\mathbf{E}(\mathbf{r}, t) \cdot \mathbf{D}(\mathbf{r}, t) - \mathbf{H}(\mathbf{r}, t) \cdot \mathbf{B}(\mathbf{r}, t)] + \mathbf{A}(\mathbf{r}, t) \cdot \mathbf{J}(\mathbf{r}, t) - \rho(\mathbf{r}, t) \cdot \varphi(\mathbf{r}, t) \right\} dV \quad (30)$$

且有关系

$$\begin{cases} \mathbf{B}(\mathbf{r}, t) = \Delta \times \mathbf{A}(\mathbf{r}, t) \\ \mathbf{E}(\mathbf{r}, t) = -\frac{\partial \mathbf{A}(\mathbf{r}, t)}{\partial t} - \Delta \varphi(\mathbf{r}, t) \\ \mathbf{D}(\mathbf{r}, t) = \epsilon \mathbf{E}(\mathbf{r}, t) \\ \mathbf{B}(\mathbf{r}, t) = \mu \mathbf{H}(\mathbf{r}, t) \end{cases} \quad (31)$$

电磁最小作用量原理具体表述为：“只需知道区域 V 内在起始时间 t_0 和结束时间 t_1 的 $\mathbf{A}$ 和 φ 之正确值，以及包围 V 的封闭表面 S 上在 $[t_0, t_1]$ 期间的 $\mathbf{A}$ 和 φ 的正确值，则在体积 V 内的 $\mathbf{A}$ 和 φ 可以根据 $\delta S=0$ 的变分原则求出，并由此定出整个区域的全部真实场。”如图 10 所示。




图 10 电磁最小作用量问题

对应的频域问题为

$$\begin{aligned} S = \int_{-\infty}^{\infty} d\omega \int_V \left\{ \frac{1}{2} [\mathbf{E}(\mathbf{r}, \omega) \cdot \mathbf{D}^*(\mathbf{r}, \omega) - \mathbf{H}(\mathbf{r}, \omega) \cdot \mathbf{B}^*(\mathbf{r}, \omega)] \right. \\ \left. + \mathbf{A}(\mathbf{r}, \omega) \cdot \mathbf{J}^*(\mathbf{r}, \omega) - \rho(\mathbf{r}, \omega) \cdot \varphi^*(\mathbf{r}, \omega) \right\} dV \end{aligned} \quad (32)$$

和

$$\begin{cases} \mathbf{B}(\mathbf{r}, \omega) = \Delta \times \mathbf{A}(\mathbf{r}, \omega) \\ \mathbf{E}(\mathbf{r}, \omega) = -j\omega \mathbf{A}(\mathbf{r}, \omega) - \Delta \varphi(\mathbf{r}, \omega) \\ \mathbf{D}(\mathbf{r}, \omega) = \epsilon \mathbf{E}(\mathbf{r}, \omega) \\ \mathbf{B}(\mathbf{r}, \omega) = \mu \mathbf{H}(\mathbf{r}, \omega) \end{cases} \quad (33)$$

文中严格证明了由 $\delta S=0$ 可导出全部 Maxwell 方程组和边界条件。换句话说，电磁最小作用量原理与 Maxwell 理论完全等价。

前面讨论也已表明，能量 E 反映振幅条件，而作用量 S 反映相位条件。于是，这里可提出难解之谜 5——相位条件可等价于运动方程，而振幅条件却无法还原为运动方程，这是为什么？

7. 作用量与广义谐振

行笔至此，我们可以从哲学上探讨这一问题。与作用量 S 密切相关的 Lagrange 量 L 所包含的是两个能量之差。深入研究，很容易发现，这两种性质不同的能量（动能 T 与位能 V ，电能 W_e 和磁能 W_m ）恰好构成一对矛盾。从这个意义上来看， L 或作用量 S 求极值正是一种广义谐振问题。

进一步从广义类比上看，极小与极大是网络的串联谐振与并联谐振，这种思想值得深究。

参 考 文 献

- [1] Singh S.费马大定理.薛密译.上海:上海译文出版社,1998.
- [2] 王福山.近代物理研究史(二).上海:复旦大学出版社,1986.
- [3] 许良.最小作用量原理与物理学发展.成都:四川教育出版社,2001.
- [4] Kline M.古今数学思想(二).上海:上海科学技术出版社,2002.
- [5] 黄席椿.论波速.北京:高等教育出版社,1985.
- [6] Taylor J C.自然规律中蕴藏的统一性.暴永宁译.北京:北京理工大学出版社,2004.
- [7] Morishita K, Kumagai N. Unified approach to the derivation of variational expression for electromagnetic fields. IEEE-MTT, 1977, 25(1); 34—40.

撰稿人: 梁昌洪 陈 曦
西安电子科技大学工程学院

梦的重建与读脑术

Dream Reconstruction and Mind Reading

神秘的梦境耐人寻味，而读懂大脑，进而重建梦境则是科学家们千方百计想要破解的难题。从 1899 年奥地利学者 Freud 发表《梦的解析》，到 1929 年德国学者 Berger 第一次记录人类脑电，再到 1990 年日本科学家 Ogawa 利用磁共振成像生成脑血流变化的图像，一个又一个理论和技术的突破，使人们一步步接近那些鲜活的梦。

一般认为，梦是人在睡眠时大脑的一部分神经细胞活动而产生的想象，通常是非自愿的。这种想象有时是散乱的图像和声音，没有任何逻辑可言；有时又是连续的场景和完整的故事，充满了独到的创意。主观的情绪伴随其中，大梦初醒，有人怀恋甜蜜幸福的美梦，也有人对恐怖的噩梦心有余悸。近年来，随着脑成像技术的不断发展，大脑里面的奥秘正一点一点地被科学家们解读。那么，我们要问，能利用脑成像技术，通过“解码”，把梦重建出来吗？要回答这个问题，就要牵涉到读脑术了。

读脑术是指用科学客观的方法将人们的思想解读出来。我们这里要特别强调“科学客观”。因为读脑术在古代常常与巫术和占卜相关，充满神秘和迷信色彩。不管是古代的希腊还是中国，都曾经把“心”当做思维器官，因而读脑术一度也被称为“读心术”（mind reading）。我们这里的读脑术并不是那个受到魔术师青睐的神秘的读脑术，它仅仅是指从神经信号中解码出感官系统的输入，以及思维和记忆。通过读脑，我们试图回答被读脑的人正在做什么，正在想什么。梦的重建，就是希望根据解码出来的结果，重建梦里的场景和声音，作为多媒体的形式保留下来。这是一个庞大的工程，在完成梦的完整拼图前，让我们先看看人们目前读脑得到的一些碎片。

1. 脑电波上的密码

德国神经精神病学家 Berger 被认为是人类脑电图的发现者。利用双线圈检流计，Berger 在他儿子头上完成了人类第一段脑电波记录。在他关于人类脑电的开创性工作之后，脑电的研究获得了较快的发展，这其中和梦最为相关的就是人们关于睡眠脑电的研究了。

戴上一个布满电极的帽子，再让受试者美美地睡上一觉，就可以开始睡眠脑电的研究了。多年的研究发现，睡眠过程中有一种非常特殊的脑电波，这

种脑电波完全不同于安静睡眠时期的脑电波，它频率快、振幅低，此时的受试者则表现出心率加快、血压升高、肌肉松弛等现象。最奇怪的是，眼球还在不停地左右摆动。1953 年，Aserinsky 和 Kleitman 第一次描述了这种脑电波的出现。根据这种脑电波和眼动的密切联系，科学家们把这一阶段的睡眠称为快速眼动睡眠，以区别安静睡眠时期的慢波睡眠。人们还发现，快速眼动睡眠和做梦是有一定联系的：当一个人进入快速眼动睡眠之后把他唤醒，他通常会报告说正在做梦；而在慢波睡眠期间把他唤醒，报告做梦的机会就少得多了。

在整个睡眠过程中，人们常常要经历多个快速眼动睡眠期。如果每次快速眼动睡眠都伴随着梦，做梦的频次可以相当得多。有研究者观察到，有的受试者常常诉说他们整夜都在做梦，而这些人恰巧是在快速眼动睡眠期间醒来的。于是，有研究者认为，诉说整夜都在做梦的人其实并不尽然，只是他们在做梦的时候醒来了，对梦记忆历历在目，因此形成了错觉。事实上，梦只进入暂时记忆，只有梦后立刻觉醒时，梦中的片断才可能进入长期记忆。有可能每个人都会在快速眼动睡眠期间做梦，只是大多数人醒来后把梦的内容忘掉了。有的忘得一干二净，便以为根本没有做梦，而有的则忘得不够彻底，尚能回忆起一些散乱的片断。重建梦境当然是要把梦里的内容都重现出来，但可能只有醒来还记得的那一部分，可以帮助我们对重建的效果进行验证。

目前，脑电已成为研究睡眠的主要工具之一，它可以方便地告诉你受试者是在慢波睡眠还是快速眼动睡眠。但要重建梦境，脑电就显得力不从心了。主要是因为大脑里的电信号在传出过程中，会经过传导率极低的颅骨，从而使信号变得模糊不清。从头皮上的记录信号很难推知脑子里什么地方发生了什么事情，这就好比我们隔着厚厚的墙壁是很难推知屋子里在说些什么一样。加之眼动、皮肤电等干扰，使得目前的脑电常常只是用来研究简单明确的心理过程，或者用来产生一些简单的指令。这里特别提到近年来兴起的脑机接口技术^[1]。脑机接口技术试图建立人脑与计算机等设备之间不依赖于语言和肢体的对外交流接口。脑机接口需要解码大脑的活动，可以认为，脑机接口技术的成功必须依赖读脑术的进步。它在解码大脑的一些初级感知觉方面做了许多有益的尝试，并取得了可喜的成果。梦的重建需要迈出的第一步是读懂大脑，这方面的工作值得借鉴。

目前，借助于头皮脑电，人们已经能成功地将脑电波翻译为光标的运行命令(如图 1 所示)，从而实现对开关、轮椅等的控制，这可以帮助那些由于生病、意外事故而丧失了全部或者部分交流能力的人。新闻媒体上有关脑机接口的新闻屡见不鲜，如 2008 年，用大脑操控电子游戏的设备被美国两家公司研发出来，并成功上市；2009 年用意念写微博则被时代杂志评为年度最佳发

明之一。



图1 利用脑电控制光标的移动

如果将电极直接植入到大脑的灰质中，神经信号的质量将极大提高，此类脑机接口被称为侵入式脑机接口。目前，它主要用于重建瘫痪病人的运动功能及盲人的视觉。在感觉运动皮层植入电极阵列来驱动假肢被称为“运动神经假体”，这方面的先驱是 Emory 大学的 Kennedy 和 Bakay。1998 年，他们在位脑干中风病人的皮层里植入了电极阵列，脑干中风使得这位病人全身瘫痪，甚至不能说话，植入后，病人学会了用脑机接口来控制电脑光标，从而实现和外界的简单交流。科学家对感觉运动皮层的解码能力已经到了相当高的水平。来自美国的科学家 Velliste 等于 2008 年在 *Nature* 上报道了他们的工作^[2]。基于植入电极，他们已经成功地训练出恒河猴通过假肢自由取食。假肢被设计成了现实场景中的形象，肩部、肘部都可以自由移动。连接在感觉运动皮层的传感器将神经的活动解码为假肢的运动指令。Velliste 一共训练了两只猴子，它们抓取食物的成功率能分别达到 61% 和 78%。让人吃惊的是，猴子甚至可以引导假肢绕过挡在它们和食物之间的障碍物，安全地将葡萄送入嘴中(如图 2 所示)。



图2 利用植入电极控制假肢的运动

侵入式脑机接口需要进行开颅手术来植入电极，在人群中大量推广存在一定的困难。其次，侵入式电极容易引发免疫反应，进而导致信号质量衰退甚至消失。

2. 功能磁共振——观察梦的显微镜？

大脑是自然界最精妙的杰作，我们目前对它的了解还极其有限。侵入式脑机接口将颅骨直接打开，可能会让大脑受到无法逆转的伤害。于是，人们发展了很多技术来间接观察大脑，如上面提到的头表脑电。CT 也是大家熟知的一种间接观察大脑的技术，常常被医生们用来诊断脑的结构性病变。它有一个重要的弊病，即需要用 X 射线穿过人体，因而有辐射的危险。

正电子发射型计算机断层显像，即 PET，是另一种临床检查影像技术，它利用人体不同组织的代谢状态不同，将标记有放射性核素的代谢物质聚集到特定组织。PET 通过高度灵敏的照相机对这一聚集进行捕捉，从而可对病变进行诊断和分析。与 CT 一样，PET 也有辐射的危害，因为它需要注射入放射性核素。

功能磁共振成像则是一种利用脑内各区域血氧含量的相对水平来进行成像的方法。大家知道，神经细胞的活动是要消耗能量的，这就使得附近区域的血流显著增加，血流的增加会使血红蛋白产生变化。因为血红蛋白包括含氧血红蛋白和去氧血红蛋白，而这两种血红蛋白对磁场有完全不同的磁性质：含氧血红蛋白是抗磁性物质，而去氧血红蛋白是顺磁性物质。血红蛋白的这一变化将使得该区域的磁共振信号发生微小改变。功能磁共振就是借助这一微小改变对全脑进行成像的。脑的动态变化像拍摄数字视频一样，被功能磁共振全部扫描下来。不用打开颅骨，功能磁共振就能对特定脑区进行准确、可靠的定位，空间分辨率达到毫米量级。作为无损和动态的探测技术，功能磁共振已日益成为观察大脑活动，进而揭示脑和思维关系的一种重要方法。

功能磁共振由于精确的定位能力和非侵入性，可能是“捕梦”的一个良好工具。梦的重建要想恢复出梦里的声音和画面，需要关注功能磁共振成像关于听觉和视觉系统的研究。

3. 重建梦境

听见别人的说话内容，并搞清楚是谁在说话，这是人脑听觉系统的一个基本功能。一直以来，人们认为闻声识人应该发生在比听觉皮层更高级的一个专门化区域。借助于新的成像技术，人们发现事情并不是想象的那样。来自荷兰的研究人员在提交给 *Science* 杂志的文章中解释了大脑闻声识人的真相^[3]，他们让受试者聆听录自三个不同说话人的三个元音的声音，应用功能磁共振成像来

监控受试者听觉皮层的活动。研究人员发现，对于听觉皮层的有些区域，无论说话人是谁，与某一元音相关的模式都是相同的。与此同时，另一些区域则对同一说话人保持相同的活动，而不管具体的语音是什么。

借助于功能磁共振成像，视觉系统的研究也得到长足的发展。2008年3月，美国加州大学伯克利分校神经学家 Gallant 宣布，他的团队采用从视觉皮层读取的信息，成功地从一组候选图片中选出一幅受试者正在看的图案^[4]。他们采用功能磁共振技术来观察受试者的视觉皮层。在试验之初，Gallant 快速地向受试者展示 1750 张图片，并同时扫描他们的大脑，这些图片中包含了许多基本元素，如马、树木、花朵和建筑等。然后利用模式识别技术，找到这些事物翻译成大脑活动的内在规律。这一过程有点像我们学习外语时的语法学习过程。当电脑学会这些语法后，Gallant 让电脑根据采集到的大脑活动进行“造句”。他设立了一个包含 120 张照片的图库，这些照片是受试者不曾见过的。随机地给受试者看其中的某张图片，然后用电脑根据采集到的大脑活动猜测出受试者看到的是哪一张，正确率竟高达 92%。相比之下，如果只是随便猜测的话，正确率只会 0.8% 而已。Gallant 小组的工作由于成功地猜测出受试者眼中所见，在 *Nature* 杂志上刚一发表，就引起国际同仁的广泛关注。

9 个月后，神经科学领域的权威杂志 *Neuron* 发表了日本神经科学家一个更有意思的工作（如图 3 所示）。来自日本电气通信基础技术研究所(ATR)的 Kamitani，领导其团队在 Gallant 工作的基础上再进一步^[5]。同样是用功能磁共振扫描视觉皮层脑区，同样是模式识别技术解码脑细胞活动，Kamitani 这次不玩猜图片游戏，而是直接从信号中重建图像。实验中，他们为受试者准备了一个包含 400 张黑白图像的图片库，每张由纵横各 10 小格共 100 格组成，格子内用黑白两色描绘出字母、方块、十字等记号。随后，他们让受试者每 12 秒看一幅图片，通过功能磁共振测定视觉皮层脑血流的变化。然后，利用模式识别技术，将图像特征和脑部活动联




图3 12月11日 *Neuron* 杂志封面

系起来，让电脑掌握这些联系中的规律。最后，受试者被要求观看新的图像，将功能磁共振的测定结果输入到电脑后，电脑就能结合之前掌握的规律将图像基本重现。令人称奇的是，研究人员向受试者展示了“neuron”（神经元）的6个字母，之后使用这种技术测量了他们的大脑活性，结果在电脑屏幕上再现了

“neuron”这 6 个字母！

显然，Kamitani 的这一研究在 Gallant 的基础上又迈进了一步。因为 Gallant 的电脑程序是从有限的图片库中猜测和选择图片，而 Kamitani 则让电脑学习了影像重建的一般规律，可识别的图片不受限制。Kamitani 介绍，尽管在做梦和想象等过程中，人脑中出现的可能是实际上并不存在的图像，但与看东西时一样，有视觉皮质在发挥作用，“读出梦里和想象中的图像已经不再遥远”。

需要强调的是，梦境中的场景其实要比 Kamitani 采用的那些黑色背景上的白色十字、方块和 X 形要复杂得多。已有研究表明，大脑里有专门负责加工面孔、工具、建筑物等复杂事物的区域，而梦中复杂的场景是这些事物的集合。有关电影欣赏过程中的脑激活的研究表明，复杂的场景将引起全脑的激活。

Hasson 是普林斯顿大学的神经科学家，2004 年，他在 *Science* 上发表文章^[6]，解密了复杂场景是如何引起全脑反应的。他让受试者躺在磁共振机器中观看电影片段，然后计算了不同受试者相同大脑区域神经活动的同步性。在没有观看电影时，不同观众的大脑活动是无关的；但如果观众在看同一部电影，而且电影够引人入胜，诱发的神经活动就会在不同观众中显示出很大的相似性。他发现，电影诱发了很多个脑区的激活，而且相同的场景刺激让大脑的视觉加工皮层、听觉加工皮层及颞叶和顶叶等区域都会显示出很高的同步性，而负责高级认知加工的额叶皮层却很少同步。另外，全脑的激活还和电影的具体内容相关，Hitchcock 的《断魂枪声》片段引起了 65% 的大脑区域的同步激活，David 的《抑制热情》片段只引起了 18% 的大脑区域的同步激活，而一段在纽约华盛顿广场公园拍摄的自然场景视频只引起了 5% 的大脑区域的同步激活。

4. 梦的重建——梦长路更长

以上研究引起神经科学界的广泛讨论。我们必须强调，人类的梦境并不是简单的声音和画面的组合。梦里既有花好月圆的风景，蝉噪鸟鸣的声响，也有故人相逢的喜悦和骨肉分离的悲伤。即使我们将重建的内容简化到像电影那样的多媒体，也会发现场景的转换会非常迅速，绝非磁共振所能提供的 1 秒一幅图像那么慢吞吞。我们目前甚至无法给出“捕梦”需要的时间尺度，丰富的内容也许就是记忆的瞬间浮现。此外，目前还不能确定，在人类做梦时，大脑处理信息的部位是否与清醒时相同。即使肯定了视听觉系统的参与，但它们参与的方式与过程还和清醒时一样吗？

梦的重建同时也面临伦理方面的问题。重建梦境就是要探测人们脑子里的下意识的想法。如果这种探测可以轻易获得，那么，人们该采取何种措施来保护隐私？如今，科学家已经能够识别大脑的简单活动模式，并解读其中的意义。

有研究开始尝试预测人们试图做的事情,甚至撒谎行为的动机,暴力和种族偏见的神经生理基础,这些都将涉及个人隐私。不少科学家已经意识到读脑可能会引发的伦理问题,他们呼吁尽快展开讨论,制定相关法律法规。

可以肯定的是,梦的重建对于我们理解大脑,进而保护大脑,具有重要的意义。梦的重建有赖于我们对大脑机制的深刻了解,它的最终意义就是要体现对人的关怀。逝去的亲人有时从梦中捎来问候,而现实的困境有时在梦中就有答案。我们希望美好的梦境能被保存下来,时时滋润我们的心田,这也许会成为人们短暂人生的另一笔财富。

借助神奇的功能磁共振技术,人们在“捕梦”的道路上已经迈出了第一步。有理由相信,新兴的脑电结合磁共振技术^[7]及双光子成像^[8]等新技术的应用,以及脑基因组计划、脑连接组计划的开展,必定会使人们读懂大脑,进而重建梦境成为现实。

参 考 文 献

- [1] 尧德中,刘铁军,雷旭,等.基于脑电的脑-机接口:关键技术和应用前景.电子科技大学学报,2009,38(5):550—554.
- [2] Velliste M,Perel S,Spalding M C,et al.Cortical control of a prosthetic arm for self-feeding. Nature,2008,453(7198):1098—1101.
- [3] Formisano E,de Martino F,Bonte M,et al.“Who” is saying “What”? Brain-based decoding of human voice and speech. Science,2008,322(5903):970—973.
- [4] Kay K N,Naselaris T,Prenger R J,et al. Identifying natural images from human brain activity. Nature,2008,452(7185):352—355.
- [5] Miyawaki Y,Uchida H,Yamashita O,et al. Visual image reconstruction from human brain activity using a combination of multiscale local image decoders. Neuron,2008,60(5):915—929.
- [6] Hasson U,Nir Y,Levy I,et al. Intersubject synchronization of cortical activity during natural vision. Science,2004,303(5664):1634—1640.
- [7] Lei X,Qiu C,Xu P,et al. A parallel framework for simultaneous EEG /fMRI analysis: Methodology and simulation. Neuroimage,2010,52(3):1123—1134.
- [8] Miller M J,Wei S H,Parker I,et al. Two-photon imaging of lymphocyte motility and antigen response in intact lymph node. Science,2002,296:1869—1873.

撰稿人:尧德中 雷旭

电子科技大学神经信息教育部重点实验室

太赫兹生物分子光谱学——生命之谜的窗口

THz Biomolecule Spectroscopy——A Window to Life Puzzle

人类裸眼的观测能力其实相当有限。我们可以看到飞禽走兽，但难以辨识单个的细菌，更不用说更小尺寸的分子了。但是，人类善于借助工具来延伸其观测能力。例如，我们早已用光学显微镜观察生物细胞，电子显微镜观察细胞内部的各种结构，X 射线成像观察各种生物分子结构^[1]。现在，我们可以用太赫兹光谱学来研究生物分子的运动，以期进一步研究生命现象，解开生命之谜。

这里，大家可能会问以下几个问题：为什么要从分子级别来研究生命现象？太赫兹光谱学是什么？它为什么能够用来研究生物分子？它又遇到了什么样的问题和挑战呢？

我们知道，到目前为止，人类还不能治愈癌症，是因为我们还不明白控制癌细胞分裂的原癌基因是如何工作的。或者换句话说，要启动原癌基因，就要有几把“生物钥匙”，但我们还没有破解这些“生物钥匙”的工作原理。基因主要是由 DNA 分子和一些蛋白质分子组成的^[2]，而这里提到的“生物钥匙”从本质上讲也应当是一些有某种功能的分子，这些都可以叫做生物分子，当然，生物分子还包括蛋白质、RNA、糖类等。这只是一个简单的例子，但却足以说明从分子级别来研究生命现象的重要性了(如图 1 所示)。

现在要回答的问题是：什么是太赫兹？用太赫兹光谱研究生物分子有什么优势？

太赫兹现在指的是频率从 $0.1 \times 10^{12} \sim 30 \times 10^{12}$ Hz 的电磁波，相应的单位为 THz，因此也就是指 $0.1 \sim 30$ THz，它处于微波与可见光之间。1 THz 对应的光子能量为 4.1 meV，相应的时间级别为 1 ps (10^{-12} s)。相对于传统的傅里叶变换红外光谱(Fourier transform infrared)、X 射线成像技术来讲，用太赫兹来研究生物分子有其独特的优势：①对分子的组成及拓扑结构的细微变化非常敏感。不同的同分异构体，空间异构体都会产生不同的吸收曲线。②无损非电离辐射。太赫兹对应的光子能量比 X 射线要低好几个数量级，它的能量不足以使分子电离。③高灵敏度。可以有效抑制远红外背景辐射噪声的干扰，辐射强度测量的信噪比和探测灵敏度远高于傅里叶变换红外光谱。④时间分辨率高。主要归因于其相应的时间级别。这几点对于实际应用都相当重要，第①点保证了太赫兹光谱技术能够检测到分子结构的变化；第②点保证了被探测物的完整性，特别是对于活的有机体而言，非电离辐射能够保证有机体的安全，这是 X 射线技术




图 1 分子运动对应的频谱范围^[3]

在太赫兹频段，生物分子的整体运动、分子间的相互作用都可以有对应的频谱。分子旋转的频谱主要在微波段，也有部分在太赫兹段，而键的振动谱线主要产生在中红外和近红外内

不可比肩的；第③点能够保证我们提取相应的频谱信号；第④点对于观测快速的构象变化是十分有利的。现在，太赫兹光谱学已经发展成为信息科学的一个新兴分支(如图 2 所示)^[4~8]。





图 2 太赫兹频段^[9]

处于微波与可见光之间，光子能量相对很低，可以对生物样品进行无损检测

但在 20 世纪 80 年代之前，因为缺乏有效的产生太赫兹波的源及探测设备，太赫兹频段一直处于没有开发的状态，因此一度称为“太赫兹间隙”。不过，自从光电导天线技术发明后，便有了稳定的辐射源和探测技术，太赫兹科学与技术及太赫兹的应用才以燎原之势发展，我们也就得以用太赫兹技术从分子级别来研究生命科学。第一台太赫兹时域光谱仪大约出现在 1988~1989 年之间^[10]。到目前为止，太赫兹时域光谱仪是应用于生物分子探测中最广泛的设备(如图 3 所示)。

现在，再来看另外一个问题，即光谱揭示了哪些与生命现象相关的过程。生物分子在参与调节生命的过程中总是会涉及其结构及状态的改变，如蛋白质分子。蛋白质分子是由氨基酸通过肽链组成的。事实上，蛋白质的分子结构要

图3 太赫兹时域光谱仪^[11]

复杂得多，它一共有4级结构：一级结构是简单的肽链；二级结构有 α 螺旋、 β 折叠和 β 转角；三级结构包括二硫键及一些非共价力作用下所形成的稳定的立体结构；四级结构是多条肽链结合最终组成蛋白质分子。由此可以看出，即使是同一个蛋白质分子，其实也是可以有多种特定的空间结构，这种特定的空间结构在生物学中叫做构象。现在，我们感兴趣的是，如果蛋白质分子的构象发生了变化，它会泄露什么信息给我们呢？打一个比较简单的比方，物体都可以有谐振频率，例如，坐火车的时候，会有一段时间感觉颠簸得最厉害，是因为车轮与铁轨连接处碰撞的频率达到或接近火车的谐振频率了，而蛋白质分子的运动泄露的就是它的谐振频率。当然，蛋白质分子的运动其实并不简单，它可以有整体的运动，如展开与合并，整体的扭动、旋转，还可以有局部的运动，如内部共价键的振动(如图4所示)。而涉及蛋白质分子整体的振动产生的谐振频率在太赫兹范围内。其他生物分子的整体运动同样会在太赫兹范围内产生谐振频率。这些谐振频率称为光谱信息，它可以通过观察分子在不同频率下的吸收特性来获得。图5所示为D-葡萄糖在不同频率下的吸收特性，可以看到，在1.4THz频率附近，D-葡萄糖显示出很强的吸收特性，即为此种分子结构的光谱信息。

在此举几个例子。同一个生命体中，每一个细胞都有一套完整的遗传信息，这主要由DNA分子携带。因此，在细胞分裂时，必须完整地将DNA分子进行复制，才能保证每个细胞中的遗传信息是一致的。DNA获得复制的能力是通过各种相关调控蛋白与DNA复制起始点顺序性结合而实现的。于是，这个过程就涉及酶(大部分的酶为蛋白质，也有的酶是RNA)的运动、构象的变化和DNA、





图4 蛋白质分子示意图

(a) 蛋白质三维结构效果图，不同形状代表不同的二级结构^[12]；(b) 蛋白质分子展开与叠起，它的状态可能与生理过程有关^[13]

图5 D-葡萄糖^[14]

RNA 分子的运动与结构的变化。因为 DNA 分子必须将双螺旋结构打开，RNA 才能将碱基对的顺序一一转录，而这个过程 RNA 本身也是要经历结构的变化；抗生素就是靠改变 DNA 的构象来阻止 DNA 转录因子转录 DNA 的信息；肌血球素中的呼吸过程要求大尺度的运动来吸收氧气分子；溶解酶素吸附在细菌细胞壁上，并在破坏细菌细胞壁时会有铰接运动。因此，我们可以看到，生命体内的每一个过程都有大量的分子在运动(如图 6 所示)。

那么，再回到开始提及的癌细胞的问题。癌细胞是通过不受控制的细胞分裂使人体的资源耗尽的，那它就必须经过遗传信息的复制，而 DNA 获得复制的能力是要相关调控蛋白参与的。我们有理由相信，某一种蛋白质应当是其中的

一把“钥匙”。如果通过观察太赫兹谱线找到了是哪一种蛋白质参与了调控，我们就找到了其中一把“钥匙”。到现在为止，我们可以将整个过程描述如下：生命体内部某种生物化学过程→生物分子运动或构象变化→产生太赫兹谱线。而实际上，我们要做的却是相反过程的工作：观察得到一系列的谱线→某种或几种生物分子运动或构象变化→生命体内特定的生物化学过程。因此，光谱就可能与生物化学过程一一对应。显然，谱线就成了观察生命现象的窗口了。这里，隐含的意义就在于我们可以阻止生物分子运动或构象变化来阻止那些危及人类生命安全的生物化学过程。正是由于这些潜在的意义，现在利用太赫兹光谱学来研究生物分子是全世界科研工作人员关注的，并积极参与的研究热点，它是一个涵盖了生物、物理、化学、信息学科的科学领域。各国科研人员已对大量的生物分子作了观察，进一步的工作还在进行之中，以期能够达到在活的有机体内探测到各种生理过程的目标。




图 6

(a) 遗传信息的转录过程，在此过程中，DNA 的双螺旋结构要打开，以便于 RNA 分子能够进行信息转录^[15]；(b) 抗生素进入病菌内部的过程，内部要有复杂的分子运动^[16]

最后，还要回答的问题是拦路虎到底在哪里？

首先，我们需要理解太赫兹波与生物分子相互作用时的基本物理机制，理解其生物机理。到目前为止，我们还不明白生命体内有多少生物化学过程，有多少生物分子。仅人体内的蛋白质就估计多于 10 万种，更何况生物化学过程其实是由多种生物分子同时参与的。正是生物化学过程的多样性、综合性，才使我们不能单纯地用实验方法来解释一切现象。否则，很可能找不到特定的生物化学过程来对应我们所得到的频谱信息。

其次，当前实验条件本身还是有局限的。尽管现在的太赫兹时域光谱仪能够工作在 $0.1\sim 4\text{THz}$ 范围内，但实际的生物分子的频谱可能会延伸到更高的频率，这实际上就要求实验设备的更宽频率范围内有较好的信噪比。即使是在 $0.1\sim 4\text{THz}$ 范围内，还存在着一些小幅度的振动模式是比较难捕捉的，但我们不能够想当然地认为这些模式不存在而将其简单地忽略不计，这种态度显然是不科学的，也是危险的，而且现有的频谱分辨率还有限，大约为 0.1cm^{-1} ，合 3GHz 。

再次，水和氢键的影响。一旦涉及活的有机体，就不得不提到水和氢键的问题，因为活的有机体内必然存在大量的水分子。水是生物分子的功能环境。人体内水的比例在 70% 左右。但水的存在产生了两个问题：一是水本身对太赫兹波具有强烈的吸收特性。到目前为止，对水的吸收峰的研究其实并没有完全弄清。所以，实验设备就必须有足够高的功率才能使太赫兹波穿透水层，到达生物分子内部。可是，水在 3THz 时的衰减系数达到 450dB/cm ，如此大的衰减的确是一个大的障碍。这也就是近年来大部分的测试都还局限于固态样品的原因。当然，也有一些实验是基于水溶液去做的，但基本上来讲，样品的厚度相当得小，只有几十微米，显然远远小于一般有机体的尺寸。打个比方，假设生物分子是海里的一群鱼，它们在海里游动，会前进、甩尾等，这些过程当然会激起波纹。我们现在感兴趣的是鱼在做什么动作，会有什么样的波纹。如果它们仅仅是在海面上游动，我们就能很清楚地看到鱼在做什么动作，同时也能看到有什么样的波纹。但问题是它们全在深海里，我们既看不到它们做什么动作，也很难看到波纹如何。另外一个问题同样相当棘手，就是氢键的影响。氢键可以在氢原子与氧原子间形成，也可以在氢原子与氮原子间形成。水分子之间本身是当然可以形成氢键的，而蛋白质分子内部本身存在大量的氨基酸残基，于是，水分子与这些残基又可以形成大量的氢键。所以，生物分子周围其实是由水形成的一个氢键网络。这些水分子对生物分子会产生什么样的作用，带来什么影响，已经有科研人员研究这些问题，但似乎并没有突破性进展。这不仅是因为形成的氢键网络太复杂，也是因为氢键本身性质就很复杂。从原理上讲，一个水分子可以与周围的水分子形成 4 个氢键，但实际过程是，某些氢键会暂时断裂，变成 3 个。那么，一个水分子到底有几个氢键？3 个，还是 4 个？但我们能不考虑这些影响吗？不能，因为前面提到，分子间的相互作用也会产生太赫兹吸收谱。再打个比方，假设我们现在有办法潜入到深海接近这群鱼了，可是这群鱼钻进了水藻丛，鱼现在在水藻丛里游动，于是水藻也跟着动。除此之外，水藻自身也有运动，那么，我们不知道鱼到底在做什么样的运动（如图 7 所示）。

最后，复杂环境下理论分析困难。光谱数据得到后，当然要进行数据处理




图7 蛋白质分子周围存在大量的水分子(蛋白质运动过程中要受到水分子的影响)^[17]

和数据分析。更重要的是数据分析，其目的就是要弄清楚每条谱线的来源。当然，我们要清楚的是，我们面临的是复杂的生物环境建模。现在，主要有两套计算机模拟方法，它们都是基于“第一原理”，也就是最基本的物理理论，然后用计算机建模进行仿真分析。

(1) 分子动力学方法。它是基于经典牛顿力学^[18]，基本思想是：每个原子受到的力是其他所有原子对它作用的合力。或者等效的，每个原子都处在其他原子所产生的势能场之中。通过势能场就能求得每个原子所受到的力。因此，分子动力学方法主要的就是建立合理的势能场，并在原子级别进行仿真计算。就像每个原子是一条鱼，生物分子就是一个鱼的群体，每条鱼都会告诉其他的鱼下一步要做什么，于是，整个鱼的群体是怎么运动的就可以知道了。

(2) 基于量子力学的基本理论。称为密度泛函理论(density functional theory)^[19]。每一个分子都有一个最低能量态，称为基态。求得了分子的基态其实就可以确定分子的结构了。有了分子的结构，就能求得它的一些运动频率。20 世纪 60 年代，Kohn 和 Hohenberg 证明了基态由分子中电子密度分布决定；Kohn 和 Sham 又证明了真正的电子密度分布使得分子整体能量最小。这种方法就有如每个原子是一个鱼家庭，每个鱼家庭有不同数量的家庭成员，就像每个原子所带电子数是不一样的。所有的家庭成员组成了一个小社会，它们是有组织的。于是，如何配置这些家庭及家庭成员，才能使整个小社会在动作时消耗的能量最少，就是这种方法关心的问题。

但问题马上来了。对于第一种方法，显然没有考虑任何量子效应，完全基

于宏观的经典力学。况且，它还要求找一个可靠的势能函数，就是说，还要知道鱼是如何通信的，就这一点而言，实际上就比较困难。现在比较常用的一种方法是基于 Lennard-Jones 势能模型。对于第二种方法，首先可以肯定的一点是，对于复杂的生物分子，基本上是不可能去求得薛定谔方程的解析解的。即使是用计算机的数值解，还存在着因为能量函数不能确定的问题。现在的做法是将能量分解成一个已知项和修正项，然后用迭代的方法修改修正项，直到能量收敛为止，而且这套方法只是针对孤立的分子进行建模，很难处理分子间的作用力，因此，前面我们提到的氢键的影响，它似乎有些力不从心，也就是说，鱼要是钻进水藻丛了，这种方法就鞭长莫及了。其实，氢键本身的复杂性对现有的方法都是一个巨大的挑战。在这种情况下，两种方法的精度有多高？现在并没有一个确定的答案。因为从实验的观测结果来看，能够观测到一些吸收峰与计算结果相吻合，但更多的是计算结果与观测结果不一致，甚至不同的计算方法得到的结果也不一致，以至于存在争议——我们是否应当相信这些方法。撇开精度不说，就现在而言，从现有的研究组的计算经历来看，计算时间也是一个问题。举个例子，用分子动力学要几个月的时间才能完成一个样本的仿真；而密度泛函在利用 4~8 个结点基于 Linux 簇计算的情况下也要好几周的时间。当然，所有这些问题的出现，从根本上讲还是来自于生物分子本身及其所处环境的复杂性，从而使得现有的理论模型过于简单，精度有限。如果再深入一点，分子动力学太宏观，密度泛函理论太微观，而生物分子应当处于两者之间。那么，是否存在一套兼顾分子动力学与密度泛函的中性理论呢？

理论上存在的困难还有：既然太赫兹波是可以探测生物分子的，那太赫兹波与生物分子是如何互动的呢？生物分子又是如何吸收能量的呢？除了以谐振形式产生吸收谱线，会不会有其他方式产生谱线呢？

实际上，我们还处于太赫兹生物分子光谱学研究的早期阶段。但对于医学界来说，显然还不可能应用这些技术。医学界与工程领域的鸿沟并不比“太赫兹间隙”本身小^[20]，要跨过这个鸿沟同样是充满挑战的。解决这些问题并不完全是工程或医学本身的事，更多的或许在于背后的科学本质并没有被我们发掘出来。还有多远的路要走，我们并不知道，而且很有可能，并不能仅仅依靠太赫兹技术就能解决所有的问题，核心的难点是：在理解生物及物理机制的基础上能将实验结果与理论分析对应起来，并准确地、唯一地确定相应的生物化学过程。

我们期待着来自信息、生物、物理等相关领域的同心协力，共同揭开这个生命之谜。

参 考 文 献

- [1] Nelson D L, Cox M M. Principles of Biochemistry. 4th ed. London: Worth Publishers Inc., 2004.
- [2] Lodish H, Berk A, Kaiser C A. Molecular Cell Biology. 6th ed. London: Worth Publishers Inc., 2007.
- [3] Ueno Y, Ajito K. Analytical terahertz spectroscopy. Analytical Sciences, 2008, 24: 185—192.
- [4] Globus T, Woolard D, Bykhovskaia M, et al. THz-frequency spectroscopic sensing of DNA and related biological material. International Journal of High Speed Electronics and Systems, 2003, 13(4): 903—936.
- [5] Markelz A G, Whitmire S E. Terahertz applications to biomolecular sensing. International Journal of High Speed Electronics and Systems, 2003, 13(4): 951—967.
- [6] Dexheimer S L. Terahertz Spectroscopy, Principle and Applications. Boca Raton: CRC, 2008.
- [7] Yamaguchi M, Miyamaru F, Yamamoto K, et al. Terahertz absorption spectra of L-, D-, and DL-alanine and their application to determination of enantiomeric composition. Applied Physics Letters, 2005, 86(5): 53903.
- [8] Korter T M, Balu R, Campbell M B, et al. Terahertz spectroscopy of solid serine and cysteine. Chemical Physics Letters, 2006, 418(1): 65—70.
- [9] http://thz.phys.rpi.edu/images/thz_gap.png.
- [10] Smith P R, Auston D H, Nuss M C. Subpicosecond photoconducting dipole antennas. IEEE J. Quantum Elec., 1988, 24(2): 255—260.
- [11] <http://images.iop.org/objects/opo/news/14/11/7/terahertzsetup.jpg>.
- [12] http://cnx.org/content/m11461/latest/protein_folding.jpg.
- [13] <http://www.biosci.ohio-state.edu/~prg/protein1.gif>.
- [14] <http://www.sinap.ac.cn/New/lnat/thzgpps.htm>.
- [15] <http://www.bio.miami.edu/~cmallery/150/gene/c7.17.7b.transcription.jpg>.
- [16] <http://textbookofbacteriology.net/themicrobialworld/ResistanceMechanisms.gif>.
- [17] <http://www.internetchemie.info/news/2007/dec07/protein-influence.html>.
- [18] Field M J. A Practical Introduction to the Simulation of Molecular Systems. 2nd ed. Cambridge: Cambridge University Press, 2007.
- [19] Sholl D S, Steckel J A. Density Functional Theory: A Practical Introduction. New York: Wiley, 2009.
- [20] Siegel P H. Terahertz technology in biology and medicine. IEEE Transactions on Microwave and Techniques, 2004, 52(10): 2438—2447.

撰稿人：陈晓东 刘小明
英国伦敦大学玛丽女王学院

水声科学与水下通信

Underwater Acoustical Science and Communication

在人们所熟知的各种能量形式中，声波在水下的传播性能最好。在含有大量的盐和复杂成分的水中，人们所熟悉的光波或是无线电波，它们的传播衰减都非常大，因而传播的距离十分有限，远远不能满足人们在海洋中的各种活动（如目标探测、水下导航、水下通信等方面）的需要。相比之下，水下声波的传播性能却好得多。例如，我们可以清晰地听到几千公里之外的几磅^① TNT 炸药水下爆炸时辐射的声信号。有人做了研究，对于几赫兹的声波，只要几瓦的声功率就可在世界的海洋中绕几圈。正是由于这些原因，使得水声技术在人类获取水下声信息的各种活动中得到了广泛的应用。随着人类把关注点越来越多的投注到海洋上，对海洋信息的需要也日益增长。水声技术的应用与发展将迎来一个新的阶段，而由此带来的对水下声信息的利用必将使人类的信息时代更为完善。

1. 水下信息获取简史

虽然水声学的迅速发展开始于第二次世界大战时的军事应用，但其起源却可以上升到 15 世纪。意大利的达·芬奇曾经记录到：“如果使船停航，将长管的一端插入水中，管的另一端放在耳旁，则能听到远方的航船。”这是人类利用水声探测水下目标的最早记载，这种方法在第一次世界大战中确实得到了采用^[1]。

1827 年，瑞士物理学家 Colladon 和法国科学家 Sturges 合作，在日内瓦湖测量了水下的声波传播速度。1840 年，焦耳发现了磁致伸缩效应，并与居里在 1880 年发现了压电效应。在此基础上，人们研制了水声压电换能器和磁致伸缩换能器，实现了水声电能和声压之间的转换，大大提升了人们研究水下声信息的各方面知识的自由度。目前为止，虽然人们可以利用多种技术研制出许多新型换能器，如薄膜换能器、磁流体换能器、稀钽换能器、光纤换能器和矢量水听器等，但压电换能器和磁致伸缩换能器仍然主导着很多的水声设备。

1912 年，倒霉的英国“泰坦尼克号”巨轮在赴美国的处女航中和冰山相遇，1500 多人丧生，这次海难的直接教训是海上航行必须有导航探测和定位设备。事件后不久，英国人 Richardson 提出水下回声定位方案。船舶通过水下声发生器向水中发射声波信号，信号遇到障碍物（如礁石、冰山、对向行驶的船舶等）

^① 1lb(磅)=0.453592kg。

目标会反射回波,接收这些回波信号可实现探测目标的目的。这是水声技术发展史上的第一个回声定位方案。

1914 年爆发的第一次世界大战促进了军用声呐技术的发展。为了对付德国人的潜艇,1916 年,法国科学家 Langevin 和俄国电气工程师 Constantin 接收到了海底回波和 200m 远处的一块钢板的回波。1917 年,Langevin 又将电子学应用到水声技术获得了成功。1918 年,他收到了来自 1500m 处潜艇的回波。这些创造性的工作把电子和信息处理技术引入到了水声技术,使水声技术进入了一个迅速发展并获得广泛应用的时代。

第二次世界大战的爆发进一步推动了水声技术的发展。电子技术的进步使水声这种微弱信号的放大、处理和显示都有了良好的技术基础。交战双方均投入大量人力、物力发展水声各领域的研究工作,取得了许多成果,各种主被动声呐、水声制导鱼雷、水声值班水雷纷纷问世。随之而来的,人们对制约水声技术发展的因素,特别是与水声环境关系的认识,则由初步到深入,不断广泛和深刻起来。

与此同时,随着人们把未来的希望更多地投入到海洋的同时,水声技术应用于海洋开发、渔业开发、海底地质测绘与勘探、石油开发、导航设备、海洋环境保护、水下机器人的视觉感知等方面的需求日益明朗与迫切。

新中国成立以来,我国的水声事业从无到有,从小到大,经过几代人的努力拼搏,目前已形成了完整的水声科研、生产和人才培养体系,取得了大量的科研成果,特别是改革开放以来,水声科学不再是闭门科学,不断扩大的国际交流缩小了与发达国家的距离。目前,我国水声技术领域的许多方面已经接近世界先进水平,有些方面已领先于世界先进水平。

2. 声呐的工作原理^[1,2]

由前已知,声呐的用途很多,不同的应用使得声呐的种类很多,它们的共同点当然都是把声波作为信息的载体,水作为传播信息的介质。由物理学知识知道,声波是一种压力波,因此,我们可以从能量的角度描述海水介质、声呐目标和声呐设备之间的关系及其具有的特性与效应。如果从信息流程出发,将声波的产生、传播与接收,或者把海水介质、目标和设备的作用综合在一起建立一个关系式,综合水声所具有的各种现象和效应及其对声呐设备的应用效果所产生的影响,这个关系式就是著名的声呐方程。

考虑一个收发合置的主动声呐,其辐射声源级为 SL,并设接收阵的指向性指数为 DI,由声源到目标的传播损失为 TL,目标强度为 TS,信号处理器的检测阈为 DT,背景干扰为环境噪声,在设备的工作带宽内,其声级为 NL。由图 1 可知,由于声传播损失,声源级为 SL 的声信号到达目标时,其声级将为

$SL - TL$ 。由于目标的强度是 TS ，由 TS 定义可知，在信号返回方向上，离目标声中心单位距离处的声级为 $SL - TL + TS$ ，此时，回声到达接收阵时的声级是 $SL - 2TL + TS$ 。 $SL - 2TL + TS$ 通常称为回声信号级。另一方面，背景噪声也作用于接收换能器，但它为接收阵接收指向性所抑制，起干扰作用的噪声级是 $NL - DI$ 。因为换能器的声轴总是指向目标的，所以，回声信号级不会被接收指向性指数压低。回声信号和噪声经换能器转换为电信号送至处理器，该电信号的信噪比(通常以分贝表示)就是

$$(SL - 2TL + TS) - (NL - DI) \quad (1)$$

这样，就可以得到如下形式的主动声纳方程：

$$SL - 2TL + TS - (NL - DI) = DT \quad (2)$$

称式(2)为声纳方程。




图1 主动声纳信号强度变化示意图

为了正确应用方程(2)，指出以下两点是有意义的：①方程(2)适用于收、发合置型声纳。对于收、发分开的声纳，声信号往返的传播损失会有不同，所以，不能简单地用 $2TL$ 来表示往返的传播损失。②方程(2)适用于背景干扰为各向同性的环境噪声情况，但对于主动声纳来说，混响也是它的背景干扰，而混响是非各向同性的，因而当混响成为主要背景干扰时，就应使用等效平面波混响级 RL 替代各向同性背景干扰 $NL - DI$ ，方程(2)变为

$$SL - 2TL + TS - RL = DT \quad (3)$$

方程(2)和方程(3)适用于主动声纳，因此称之为主动声纳方程。如果声纳以接收目标发出的声信号为主，这种声纳则称为被动声纳。在声纳方程(2)中，目标发出的噪声信号不需要往返传播，是直接由声源到接收换能器，噪声源发出的噪声不经目标反射，所以，目标强度 TS 不再出现，被动声纳的背景干扰主要是环境噪声，考虑这些因素，式(2)变为

$$SL - TL - (NL - DI) = DT \quad (4)$$

式中， SL 为目标辐射噪声的声源级；其余各参数的定义与式(2)相同。式(4)就是被动声纳的声纳方程。

声纳方程是水声科学工作者在各种水声领域探讨水声技术发展及设计预报

各种声呐设备的性能指标时常常需要遵守和分析研究的依据。

3. 声呐工作环境的特点

在了解了声呐方程和方程中各个物理量的定义后,我们对声呐工作环境已有了初步的了解。尽管一再强调海洋对电磁波的传导很差,光波在海洋中的传播与在大气中相比也是非常差的。即使在清澈的海水中,光到达水下 100m 深度时,其能量尚不到原来的 1%^[1]。所以,水下的信息传播只能依靠水下声波来实现。但是,也有相反的情况。在某些条件下,声呐信号却连短短几百米也难以接收到。著名的“下午效应”说到一个笑话:早晨工作良好的声呐,到了炎热的下午,人已经可以用肉眼观察到目标,声呐却接收不到信号。这就是说,海洋环境决定着海洋中声的传播。海洋中深度方向的声速不均匀性(声速梯度)、海洋的不均匀性、海洋信道的复杂性及海洋环境特有的各种各样的环境噪声等因素强烈地影响着海洋中声信号的传播。

1) 海水中的声速

对水声技术来讲,海水中最重要声学参数是声传播速度,它是影响海洋中声传播的最基本的物理量。在液体介质中,声速是弹性纵波,其声速可近似为: $C=1/\sqrt{\rho\beta}$, ρ 为海水密度, β 为在流体介质中的绝热压缩系数, ρ 、 β 都是温度 T 与盐度 S 和静压力 P 的函数。实际工程使用中,人们建立了一些经验公式,如文献[3]介绍:

$$C = 1449.22 + \Delta C_T + \Delta C_S + \Delta C_P + \Delta C_{STP} \quad (5)$$

式中, ΔC_T 、 ΔC_S 、 ΔC_P 、 ΔC_{STP} 分别是在一定条件下温度、盐度、静压力及综合因素对声速影响的修正值。文献[3]和[4]中还给出了适用范围和特征值表,可以从表中简便地查出水中各深度和温度、盐度、压力条件下的声速值。

图 2 给出了典型的深海和浅海的声速剖面图。图 2(a)中表示的是由温度垂直分布的“三层结构”所形成的声速剖面图^[1]。浅海的海洋声速剖面分布的影响因素更复杂,图 2(b)中给出了不同月份同一地点温度剖面的分布。

2) 海水中的声吸收

声波与光波和电磁波相比,在海洋中波传播损失小,但不是说没有衰减。与人们能够提供的声源级或者希望获取的信号相比,这种衰减仍然是令人不满意的。影响声波传播衰减的因素同样很多,主要有以下几个方面:

(1) 声传播衰减。其原因主要有声传播过程中波阵面的不断扩展引起的声强衰减,又称几何衰减。

(2) 吸收损失。通常指均匀介质中由介质黏滞、热传导及其弛豫过程引起的声强衰减。




图2 典型海水声速剖面图

(3) 散射。指海洋中的泥沙、气泡、浮游生物等悬浮粒子及各种原因导致的介质不均匀性引起的声散射和声强衰减。另外,海水界面对声波的散射也是引起衰减的一个原因。

3) 海底与海面的影响

海底结构、地形和沉积层是影响声波传播的重要原因。海底对声波的吸收、散射和反射等声学特性关系到水声设备工作性能的发挥。影响声波传播能量损失的重要因素之一是海底地形的粗糙度。海底地形粗糙度有一个很宽的谱,从几厘米到几十公里或几百公里等^[1,2,5]。

海面如镜,这是诗人的意境,无风也起浪方是大海的本性。海面波浪既呈周期性或准周期性,又呈随机性。因此,人们也常用周期、波长、波速和波高等量描述波浪的特征。通信理论中的随机过程理论普遍用在波浪研究上,如用波浪的概率分布、方差、谱和相关性来描述波浪的特征。

4) 海洋内部的不均匀性

除去上面介绍的海表面、海底的不均匀性及海水温度、盐度和声速垂直分布特性对声波传播的影响,海洋内部尚有许多其他不均匀性,如湍流、海流、内波和深海散射层等,这种不均匀性搅乱了本已不均匀和不稳定的海水介质的垂直分层性质和水平均匀性,加剧了海水中声场的起伏^[1,4]。

5) 海洋中的噪声

在目前科学技术发展状态下,我们在充分肯定声波对水介质有着最为良好的穿透性的同时,也要看到在海洋中任何海区都存在严重的噪声。海洋中的世界丰富多彩,这种噪声的性质也是多种多样的。除了认识到它的严重性之外,可以说,对海洋环境噪声的研究仍然不十分充分。一般地说,海洋中的噪声大

致可分下列几类^[4]：

(1) 动力噪声。它的产生与海浪及水和大气中的湍流有关，还与海浪拍岸的噪声、雨噪声、自然空化等有关。

(2) 冰下噪声。它的产生和冰层的形成与运动、冰层表面的不平整性与风与海流的相互作用有关。

(3) 生物噪声。它由各种海栖动物所产生。

(4) 地震噪声。它由地壳运动和火山活动及伴随这些而形成的海啸波等所引起。

(5) 工业噪声。它由人类的活动所造成，包括航运噪声及在港湾、沿岸、海底的工业装置等所发出的噪声。而随着人们海洋活动的增加，近几年这部分噪声的增加十分迅速。

图 3 给出了摘自权威文献^[4]的海洋环境噪声场的谱分布特征，分别给出了




图 3 噪声场的能谱特征

1, 2. 最高与最低的动力学噪声；3. 风平浪静时的噪声谱(根据 Kundsén)；圆圈内的数(风速级). 谱参数；4, 5. 水下噪声谱；6. 地震背景噪声谱；7. 2, 7. 10. 伪声谱；8. 火山爆发的噪声谱(平均)；9. 航运噪声谱(C 区：航线噪声谱)；10, 11. 鲈目鱼和小虾噪声谱；12. 暴雨噪声谱；13. 热噪声谱；a. 地震背景，爆炸、地震和冰块堵塞的噪声频段；b. 湍流噪声频段；c. 表面波影响的频段；d. 工业噪声频段；e. 空化噪声和雨噪声频段；f. 热噪声频段；g. 生物噪声频段

动力学、地震、工业、生物和热分子噪声的谱及它们的相互比例和各种噪声谱可能的变化范围，这是一份对水声科学工作者有重要参考价值的图表。

6) 海洋中的混响

在声呐方程中，我们已经知道，对于主动声呐来讲，还受到混响信号的干扰，而在许多情况下，混响是主要的背景干扰，是限制声呐工作性能的主要原因。混响是一种水声信号领域特殊形成的干扰，它伴随着声呐发射的信号发生而产生，主要是由于海洋中存在的大量无规散射体对入射信号产生的散射信号在某接收点的叠加而形成的，所以，它是一个随机过程^[1~5]。混响和发射信号本身的性质关系密切，而且还和传播的通道环境特性有关。海水中散射体的形式不同，所产生的混响场特性也不同。根据混响场特性，大致可以分成三类：

(1) 体积混响。散射体存在于海水本身或体积之中，如海水中的流砂粒子生物、海水本身不均匀性、大的冰山和鱼群等引起的混响。

(2) 海面混响。海面的不平整性和波浪形成的气泡层对声波的散射所形成的混响。

(3) 海底混响。海底及其附近散射体形成的混响。

图4给出了摘自文献[1]的各类混响信号的属性示意图，它们是根据水深、声源和水听器的布设对接收信号的传播时间分析计算后得出来的。




图4 水听器测得的海水混响

水深为1980m的海中，2磅炸药于244m深处爆炸后，位于其附近41m深处的水听器测得的混响，滤波通带1~2kHz

7) 海洋中声信号的传播起伏

我们简单地了解了声信号在水下传播的基本知识，可以说，海水介质对于声波的传播，不确定问题十分突出，是典型的、巨大的随机介质体系。海水中任何一点的声波传播速度不仅和深度有关，事实上也是随机变化的。当声波在海水中传播时，在不同声速断面不断发生折射的同时，不断地散射造成声波能量在空间各方向上的不断再分配。加上海水中许多其他随机因素，就形成了随

机介质中信号的散射和起伏。这种现象在许多不同领域(如大气物理、无线电物理、光学)中都有类似问题存在,只是海洋中的声信号的传播起伏更为严重而已。这种传播与起伏的简单成因可有三种:①由海水介质的随机不均匀性产生的声传播起伏;②由海面、海底的随机不平整性引起的传播起伏;③由内波等因素引起的声传播起伏。

8) 水下通信的现状与发展

通信技术的发展是现代社会的标志之一,它使人们的交流不再受地域限制,把人们希望自如地和亲朋好友、同事、领导之间既谋面而又闻声的梦想变成了现实。然而,这种局面只能维持在占地球面积仅 30% 的陆地和空间中,在占地球面积 70% 的海洋之中,人们仍然无法实现这一点。

由前已知,海洋中的信息传播情况与陆地大为不同。首先,海洋中无法采用人们熟悉的无线电或光波通信;其次,声波通信的环境与无线电波在空气中的工作环境大为不同。特别是在海洋中严重的多途干扰和海底海面反射及内波的时空变化,使得接收信号的码间干扰严重,加上海洋环境的高噪声背景、低载波频率、有限的带宽和传输条件的时-空-频的变化,使水声信道,特别是浅海水声通信成为迄今为止困难的无线通信信道^[6]。

近几十年中,人们曾大力研究过非相干通信 MFSK 调制技术及相位相干通信技术在水声中的应用,取得了一些成果与进步。2005 年开始,世界上许多科研院所采用将可用的频带分割成一系列子载波的多载波通信技术,为实现实时高速水声通信提供了新的选择。目前,正交频分复用技术(OFDM)是分载波水声通信的研究热点。表 1 是相关研究单位近几年基于 OFDM 水声通信系统的海上试验研究数据结果^[7]。

表 1 近年来多载波水声通信的最新研究成果

试验时间/ 地点/单位	基阵	通信频带	信道编码	通信距离	调制方式/ 数据率
2005. 9/ Buzzard Bay / UoC WHOI MIT	1 TX 12 RX	22~46kHz	无	2. 5km	QPSK / 22. 7Kbps
2006. 12 / Woods Hole Harbor / UoC WHOI MIT	1 TX 4 RX	21~33kHz	2/3CC	50~800m	QPSK / 9. 7Kbps
2006. 12 / Buzzard Bay / UoC WHOI MIT	1 TX 4 RX	21~33kHz	2/3CC	600~110m	QPSK / 9. 7Kbps

续表

试验时间/ 地点/单位	基阵	通信频带	信道编码	通信距离	调制方式/ 数据率
2007.6/panama /City Beach, FL/UoC UoC WHOI MIT	2,4 TX 16 RX	26~38kHz	1/2CC 1/2LDPC	500m 1000m 1500m 2000m	16QAM/ 12Kbps
2007.8/ Baltic Sea DUoT	N/A	1.5~5.1kHz	Turbo	52km	4.2bps 78bps
2007.9/ Trondheim fjord/ TUoL UoA	16 RX	1.5~4.5kHz	N/A	800m	QPSK/ 6Kbps
2007.9/ Buzzard Bay/ UoC	N/A	85~135kHz	1/2CC 1/2LDPC	180~300m	16QAM/ 50Kbps
2008.1/ Lake Washington /UoW	1 TX 4 RX	带宽 4kHz	RS	250m 500m 1000m 2000m	QPSK/ 939bps
2008.3/ Narragansett Bay UoC WHOI MIT	4 TX 12 RX	10~12.4kHz	1/2LDPC BCH(64,10)	400m	64QAM N/A
N/A/ Viapahu Lagoon/ UoCSB	N/A	N/A	(672,336) LDPC	330m	N/A
2008.4/ N/A N/A	2 TX 6 RX	75~137.5kHz	1/2 Coding	600m	64QAM 125.7Kbps

注：N/A 表示在发表的文献中没有给出；UoC：University of Connecticut；WHOI：Woods Hole Oceanographic Institution；MIT：Massachusetts Institute of Technology；DUoT：Delft University of Technology；TUoL：Technical University of Lison；UoA：University of Algarve；UoW：University of Washington；UoCSB：University of California Santa Barbara；调制方式/数据率：指试验中采用的最高阶调制方式和最大数据传输速率。

从表 1 中数据可以明显看出, 这些成果仍然远远满足不了人们在海洋中通信的需要。

自 20 世纪 90 年代开始, 人们对水下传感器网络的研究投入了极大的热忱。我国和欧美的一些研究机构均启动了多个关于水下通信网络的研究计划。当前, 各国相关领域的科学家们根据水声通信与无线电通信不同的约束条件, 正在大力研究适用于水声通信的路由协议。除了最基础的点对点通信的困难之外, 水下能源问题、水声通信的大延时、海洋环境高噪声、带宽窄、可适用的载频低和时空变化问题, 以及海水的侵蚀、腐烂、海洋生物的侵扰也是不能回避的问题。

4. 结语

在简单地了解了声呐的工作原理和工作环境特点之后, 我们已可理解了为什么在通信与信息技术高度发达的高科技时代, 人们却在海洋中通信信息获取能力方面仍面临巨大的挑战。事实上, 从第二次世界大战以来, 水声技术日益成熟发展, 科研人员对声表面声道、海底反射声、深海声道和声会聚区效应等传播方式做了认真而卓有成效的研究, 取得了丰硕的成果, 使水下声信号的探测能力有了数量级上的进步, 特别是现代信息处理技术的出现, 使声呐的性能得到了飞跃。然而, 这些先进的信息处理技术远没有达到在雷达上的运用效果, 这也使人们进一步认识到水声设备的工作环境远较雷达的工作环境更为复杂。

参 考 文 献

- [1] 刘伯胜, 雷家煜. 水声学原理. 哈尔滨: 哈尔滨船舶工程学院出版社, 1989.
- [2] Urick R J. Principles Underwater Sound for Engineerings. New York: McGraw-Hill, 1975.
- [3] 马大猷, 沈壕. 声学手册. 北京: 科学出版社, 1983.
- [4] 布列霍夫斯基 J M. 海洋声学. 北京: 科学出版社, 1983.
- [5] 汪德昭, 尚尔昌. 水声学. 北京: 科学出版社, 1981.
- [6] Stojanovic M, Presig J. Underwater acoustic communication channels: Propagation models and statistical characterization. IEEE Communications Magazine, 2009; 84—89.
- [7] 徐小卡. 基于 OFDM 的浅海高速水声通信关键技术研究[博士学位论文]. 哈尔滨: 哈尔滨工程大学, 2009.

撰稿人: 杨德森

哈尔滨工程大学水声工程学院

如何持续提升计算机系统的性能?

How to Scale Up the Performance of Computer System?

1946 年,世界上第一台电子计算机 ENIAC 诞生,它的计算能力为每秒五千次加法运算。从那以后,计算机的性能不断提高。到 2010 年 6 月,世界上计算速度最快的计算机是美国 Cray 公司设计的“美洲豹”^[1],它的实测计算能力达到 1.75 Pflops (1 Pflops = 10^{15} 次浮点运算/s)。六十多年来,计算机系统的性能提升了近 12 个数量级。

那么,人们自然会提出一个科学问题:计算机系统的性能还能不能持续提高^[2]?

在回答这个问题之前,首先要回答的问题是:人们是否还需要更高性能的计算机?这个问题的回答是肯定的,人类对计算的需求是无止境的。在微观方面,随着人类观测技术的进步,人类从自然界获取的信息量越来越多,如可观测的最小尺度从微米级延伸到单个原子的纳米级别。从宏观方面,人类研究的复杂系统的规模越来越大,如从短期的天气预报到全球的气候变化,从简单的化学反应到复杂的蛋白质生化过程。随着互联网的出现,它既为人类提供了一个数据共享的平台,同时也把对人类社会自身行为的分析纳入可计算的范围内。根据目前科学家们的预测,在很多科研领域都有直到 Y 级别(10^{24})的计算需求^[3]。

那么,计算机系统的计算能力和存储容量能否继续保持高速的增长,从今天的 P 级一直增长到 Y 级呢?下面这些关键问题需要我们去研究:计算机系统的体系结构该如何扩展?如何挖掘和表达应用的并行性?如何让应用在百万以上计算单元组成的系统上实际性能具有可扩展性?如何保证百万以上规模部件组成的整机系统的可靠性?

1. 计算机系统的扩展性

电子计算机自诞生以来,其基本结构一直是 20 世纪 40 年代提出的冯·诺依曼结构。但是,构成计算机的处理器、存储器、输入输出、指令系统、互连网络等一直在发生着变化,这种内部的组成结构被称之为系统结构。从大的方面,可以把一台计算机的系统结构分为节点内结构和节点间结构。节点是计算机系统内相对独立的一个子系统,基本上具有了一台计算机的完整功能。高性能的计算机系统一般由多个相对独立的节点通过系统级的互连网络构成一台整机。

如图 1 所示, 计算机体系结构经历了单处理器、对称多处理(SMP)、非一致性共享内存访问(NUMA)和机群多个发展阶段, 使得计算机系统的扩展性越来越好。




图 1 计算机体系结构的发展

显然, 提高计算机系统性能的问题可以分解成如何提高单个节点的计算能力和如何扩展系统中节点的规模。系统的规模首先受到能够放置一台计算机系统及其附属设备的空间的限制, 其次才是如何高效地完成并行应用, 而单个节点的计算能力当前主要受限于能耗。

首先分析一下空间对提高系统中节点的总体规模的制约。按 2010 年的技术, 最小的 1U 机架(即 1.75 英寸^①高, 19 英寸宽)计算能力最大可达 2Tflops (1T=10¹²), 而一个机柜(占地面积为 1.32m²)最多可以容纳 42 个 1U 机架。那么, 制造一台 Y 级的计算机系统需要 120 亿个机柜, 占地面积大约 1.5 万平方公里, 相当于一个北京市的土地面积。

反过来, 假如限定机房大小为整个天安门广场的大小(约 0.44km²), 那么, 需要单节点性能为 71Pflops。以排名 2010 年 6 月世界第二、中国最高性能的曙光“星云”计算机^[4]为例, 它的整机峰值性能为 2.98Pflops, 116 个机柜, 占地 600m²。那么, 至少需要将 24 个星云系统放到一个 1U 的节点内, 也就是压缩 116928 倍(24×116×42), 才可能造出这样一台计算机。

按照目前摩尔定律的发展速度, 即单节点性能每两年翻一番来估算, 需要 34 年(2¹⁷=128000 倍), 那么, 大概要持续发展到 2044 年才能出现这样的节点。所以, 单节点的计算性能能否按照这个速率扩展呢? 实际上, 按照现有的技术

^① 1in(英寸)=2.54cm。

路线,大概到 2020 年就会遇到瓶颈^[3]。

其次分析一下能耗对计算能力持续提高的制约。电子计算机内部是由电路系统组成的,电路系统在进行计算时要消耗能量。随着单芯片集成的晶体管数量的不断提高,能耗问题已经成为限制单节点性能提高的首要障碍。2010 年 6 月,高性能计算机的最高能效比为 $773.38 \text{ Mflops/W}^{[5]}$,按照这个值,1Yflops 的能耗为 $1.4 \times 10^{12} \text{ kW}$,三峡大坝一年的发电量($846.8 \times 10^8 \text{ kW}$)仅够其用 3.6 分钟!所以,必须有革命性的技术才能突破能耗的限制。

与能耗相关的是散热问题。计算机产生的热量必须及时排出才不会导致过热而损坏系统。计算机系统使用的散热技术已经逐渐从风冷转向水冷,甚至连芯片内部都需要考虑液冷散热了。高性能计算机的散热系统自身也要消耗可观的能量。

但是,如果从能耗的理论效率看,实际上可发展的空间还很大。研究表明,完成单次运算所需要的能量,系统级大概是微焦耳量级(10^{-6});而一个实际的运算电路能量消耗只为皮焦耳(10^{-12})。也就是说,绝大多数能耗不是用来完成计算,而是消耗在包括互连、控制、漏电等在内的开销上了。从这个角度看,计算机系统结构、器件的发展还有足够的空间。

那么,单个节点的计算能力的极限是多少?物理学家曾经用量子物理方法给出过估计:1kg 物质在 1s 内最多可以进行 5.4×10^{50} 次位运算^[6],即使按现代处理器 100W 功耗限制,也可以达到大约 6×10^{29} flops。

计算机是一个复杂的综合系统,除了空间、能耗的物理限制挑战外,最终计算机要有效地完成计算任务还涉及很多下面描述的其他问题。图 2 给出了科学家们对高性能计算机发展的预测^[7],随着在低功耗、并行和纳米材料等技术上的突破,在 2050 年左右会出现 1Yflops 的计算机。

2. 如何挖掘和表达应用的并行性?

并行计算是指同时使用多个计算部件来协同解决同一个应用问题。前面提到,提高高性能计算机系统性能的主要途径是并行。今天,高性能计算机系统已经达到了十万级别的并行度,相当于有十万个计算机通过协同方式同时计算求解一个问题。可以想象,未来计算机的并行规模可能达到百万甚至亿级以上。

那么,这么多计算机怎么协同运行呢?这就涉及另一个问题,如何挖掘和表达应用中的并行性,如何将自然现象中普遍存在的并行映射到计算机系统上,也就是并行编程问题。

有一类称为显式并行(explicit parallelism)的应用,可以简单地把计算任务分发给不同的计算机单独进行计算,最后汇总结果即可。一个典型的代表就是“搜寻地外文明”的 SETI@home 计划。1995 年,美国加州大学伯克利分校提出




图2 高性能计算机的发展前景

可以利用 Internet 上成千上万台计算机的闲置计算能力搜寻地外文明，并于 1999 年启动，截至到 2004 年 5 月，它吸引了 543 万用户，这些用户的电脑累计工作了 243 万年，累积进行了近 5×10^{21} 次浮点运算，至 2010 年 4 月 30 日，这一计划的后续 BOINC 项目在全世界拥有了约 557000 台活跃主机，平均提供约 5.411Pflops 的运算能力^[8]。

显式并行应用的并行编程不存在太大困难，但自然界本身是复杂而又相互关联的，大多数科学计算应用，如天气预报、流体物理、行星变化的模拟、化学过程的模拟等都需要计算单元之间不断地进行数据交换和同步。所以，如何设计可以有效地表达并行计算流程的编程模型和编程工具是一个巨大的挑战。目前，基于消息传递的执行模型是分布式并行编程的主流，基于 PRAM 模型的执行模型是共享内存系统的并行编程的主流，一些大型应用则需要两者的结合。未来计算机系统向多层次、异构化发展，现有的并行编程工具远远不能适应。

此外，还有一些研究试图更好地填补应用和计算机体系结构在并行上的语义鸿沟。一个是通过编译器进行自动并行化，这种自动挖掘出程序中的并行方法在以数组和循环为主的程序上有很多成功的例子，但对复杂流程和存在间接关联的应用上还没有很好的办法。另一个是关于更适合表述自然并行的编程方法的研究，如基于函数式的程序设计，这类语言虽然表达能力强，但与现有的计算机结构差距太大，很难有效运行这些程序。

3. 大规模并行系统的应用效率

高性能计算机系统提供了强大的计算能力,但并不意味着应用在这样的计算机上就一定能获得很高的实际性能,这就是常说的峰值计算速度和有效计算速度的差别。这里的问题是如何提高大规模并行应用的计算效率。

首先,应用程序是否有足够的并行性。为使计算机高效运行,需要应用在任何时候都有足够多的任务并发执行。例如,对很多自然现象的模拟都是一种基于时间演化的过程,需要大量的时间步,每个时间步内都需要有大量的计算,以及足够多的并行度。如果这些并行度不够,就需要扩大求解问题的规模^[4]。

其次,计算量的负载平衡也是一个难题。因为被模拟的自然界中的很多现象天然就是并行而不均衡的系统,所以,在同一时刻,每个计算单元分配的計算任务可能是不均匀的,对计算机来说,一旦出现某个局部任务处理时间过长,就会导致其他部分的计算资源因等待而空闲,整个计算机的应用效率就会降低。这个问题随着并行规模的增大而更为严重。解决这个问题需要从算法设计开始就对任务分配进行认真的评估和设计,在运行过程中还需要根据动态的情况进行恰当地调整。

最后,数据通信的开销必须得到控制。完成一个并行计算的时间包括计算时间和通信时间。计算机系统允许计算和通信操作在时间上重叠,但存在数据相关时,则不能重叠。随着系统并行规模的增大,通信的开销不可避免地也要增大,从而降低整机的效率。通信的性能首先受限于信号的传播速度,其次是系统域的互连网络的交换和控制的开销。每多经过一次交换,即所谓的“一跳”(hop),通信延迟就要增加。例如,按照单个 CPU 核 10Gflops 计算, Y 级系统将包含 10^{14} 个核,假设采用通用的胖树拓扑和 16 端口的交换机,互连这么多的计算单元的互连网络的半径将达到 20 多级。所以,系统域互连网络的研究热点包括并行、多级、大端口的结构,和自由空间的光交换等变革性的通信技术。此外,如果应用有大量的 I/O,系统的 I/O 能力和数据访问能力也必须是可扩展的。

4. 如何保证超大规模部件组成的整机系统的可靠性?

由于计算机的正常工作会受到热、电磁辐射等因素的影响,计算机系统的规模也越来越大、越来越复杂,软硬件部件很容易发生各种各样的故障。对于由大量部件组成的高性能计算机,可靠性问题会严重到无法正常地计算^[9]。

计算机系统的可靠性通常用平均无故障时间(MTBF),或者单位时间故障率来衡量。当故障率恒定时,故障率就是 MTBF 的倒数。假设每个节点的 MTBF 是 1×10^4 h,即故障率为 1×10^{-4} /次/h,那么,100 万个节点组成的计算机的故障率就要放大 100 万倍,达到 100 次/h。也就是说,每一分钟都会出故障,根

本无法完成实际应用的计算任务。所以，如何在上百万规模计算部件组成的系统中保证应用的可完成性成为一个难题。

通过预先消除不可靠的因素，如提高器件品质、减少电磁干扰等，可以提高计算机系统的可靠性，但不能完全解决问题。目前主要靠容错法，即保证系统在发生局部错误后整机仍然能够正确地运行应用。

一种常用的容错方法是多模冗余。 m 模冗余系统由 m 个 ($m=2n+1$ 为奇数) 相同的子系统和一个表决器组成，经过表决器表决后， m 个子系统中输出相同结果占多数的作为系统的输出。在 m 个子系统中，只要有 $n+1$ 个以上子系统能正常工作，系统就能正常工作，输出正确结果。航天器里的容错计算机用冗余方法能获得非常好的可靠性保证。但是，在超大规模的计算机系统中，这种冗余方法的开销非常大。假设每个节点的故障率是 1×10^{-4} 次/h，如果采用 3 模冗余，理论计算可得故障率变为 3×10^{-8} 次/h。对 100 万个节点，采用 3 模冗余故障率可以降为 0.03 次/h，大概一天半一次故障。但是，3 模冗余意味着这台计算机的资源利用率只有 33%，这对大规模系统是 unacceptable 的。

当前高性能计算机系统容错主要靠检查点方法，即分阶段地出错重做。在应用每运行一定时间之后就对应用的状态进行全局保存，一旦系统发生故障，可以恢复到最近的检查点重新执行。这种方法在系统规模较小时是可行的，但在百万规模的并行计算机中，每次保存的系统状态就变得极为庞大，要花费较多的时间和存储空间。当系统规模增大到平均无故障时间已经小于检查点周期时，系统可能会不断地进行回滚操作却无法前进到下一阶段。

必须找到新的方法来解决可靠性问题。一种可能的方法是通过算法的改进，设计出能自我容错的并行算法。另一个可能的思路是提高系统的智能自我修复的能力，即希望计算机能够具有自预测 (self-prediction)、自检测 (self-detection)、自定位 (self-location)、自隔离 (self-isolation)、自愈合 (self-healing) 的特征，能够预测即将发生故障的部件，在发生故障时，能够自己检查出错误的发生原因，根据故障的原因和严重程度进行自我修复或将发生故障的部件隔离起来，使其不影响整个计算机系统的运行。

总之，Y 级计算机是人类未来半个世纪的梦想，面对这个计算机怎么造、怎么编程、怎样保证效率、怎么保证可靠性这些困难，虽然存在很多挑战，但如果回到 60 年前看今天，可能那时候的挑战更为巨大，我们有理由对计算机系统性能的持续提高充满信心。

参 考 文 献

- [1] <http://www.top500.org>.

- [2] Gray J. What next? A dozen information-technology research goals. *Journal of the ACM*, 2003, 50(1): 41—57.
- [3] <http://www.exascale.org>.
- [4] Gustafson L. Reevaluating Amdahl's law. *Communications of the ACM*, 1988, 31(5): 532—533.
- [5] <http://www.green500.org>.
- [6] Lloyd S. Ultimate physical limits to computation. *Nature*, 2000, 406(6799): 1047—1054.
- [7] 中国科学院信息领域战略研究组. 中国至 2050 年信息科技发展路线图. 北京: 科学出版社, 2009: 89—92.
- [8] <http://boinc.berkeley.edu>.
- [9] Schroeder B, Gibson G. Understanding failures in petascale computers. *Journal of Physics: Conference Series* 78, 2007: 012022.

撰稿人: 孙凝晖 陈明宇 包云岗
中国科学院计算机系统结构重点实验室

计算机系统如何成为可靠的系统?

How a Computer to be a Reliable System?

1. 计算机系统的可靠性问题

1996 年 6 月 4 日, 欧洲航天局研制的阿丽亚娜(Ariane)5 型火箭升空 30 秒后爆炸, 这是世界航天史上的一大悲剧。阿丽亚娜 5 型火箭耗费了约万名参研人员超过 10 年(1985~1996 年)的时间, 花费了 70 亿美元, 却由于计算机系统的可靠性问题失败了。事后分析事故原因发现, 火箭采用的定位软件中用整型表示的加速度值发生溢出, 从而导致惯性导航系统失效。由于 α 粒子辐射导致系统存储单元的某一位发生数据错误, 使得我国某型航天系统失效, 损失达十多亿人民币。事后研究表明, 如果当初在系统中加进数据纠错码技术, 则完全可以避免此类错误。2003 年, 北美东北电网发生的大停电事故是由于电网控制中设置的竞争条件缺陷导致的; 而加拿大近年发生的多起癌症患者因受到过量放射性辐射而死亡的事故, 是由控制放射性治疗设备的软件错误造成的。所有这些人类悲剧都指向了计算机系统的可靠性问题。

可靠性问题是计算机系统需要解决的根本问题之一, 就是如何基于不太可靠的器件和部件构造出满足可靠性要求的整机, 以及在系统的部分部件出现故障时整机如何继续工作。通常而言, 一个系统越复杂, 它的可靠性越难保障。

计算机系统由硬件、软件和数据组成, 因此, 计算机系统的可靠性也包括了硬件的可靠性、软件的可靠性、数据存储的可靠性、在系统级如何容忍局部的错误及可靠性评估的方法。Gray 通过研究 1985 年到 1990 年期间高端容错的 Tandem 服务器的历史数据发现^[1], 硬件故障所占的比例小于 10%, 而软件故障接近 60%。硬件失效所占比例很小, 并不是说明底层的硬件组件有多可靠, 而是依靠了可靠性技术能够有效地屏蔽组件失效对上层系统的影响。然而, 由于成本的限制, 目前的数据中心系统一般不会采用昂贵的高端容错机, 而是采用软件容错方法, 即只要硬件故障可以容忍就不中断服务, 利用软件的方法管理、隔离和屏蔽硬件故障对上层应用的影响。在目前支撑互联网服务大规模负载的计算机系统中, 如 Google、Amazon 等, 广泛采用了数据副本技术、计算的划分和迁移技术、系统健康状况和完整性监视等可靠性保障方法。

经过六十多年的努力, 计算机系统的可靠性技术取得了很大的进展, 但计算机系统的可靠性设计仍然缺乏严格的科学基础, 迄今为止所提出的保证系统

可靠性的方法和理论在面对规模巨大的实际应用时仍然显得苍白无力。

2. 硬件的可靠性

校验和冗余是处理硬件故障的主要方法,如保障数据通路可靠性的 CRC(循环冗余校验码)校验法、ECC(错误检查与纠正法)校验法、保障服务器关键业务可用性的 HA(high-availability)双机和多机高可用技术、多模冗余技术。图 1 就是一个三模冗余系统的例子。




图 1

校验和冗余都是需要开销的,计算机发明六十多年来,科学家们总是努力降低保障可靠性的开销,计算机高可靠结构的设计从最初的多模组冗余,演化到双模冗余,再发展到最近的部分冗余,不断降低代价。硬件可靠性保障的重要研究问题是可靠性保障的最小代价究竟是多少?存不存在一个下限?例如,在多核和未来上千个核构成的众核系统中,由于集成电路制造工艺不可避免的硬件缺陷,可能很难保证我们得到需要的核数,需要设计 $m+n$ 个核使我们能有保障地得到 m 个核。那么,最小的 n 是多少?

3. 软件的可靠性

20 世纪 50 年代软件诞生之初,程序一般比较简单,以控制类程序和计算类程序为主,规模一般在几百至几千行源代码,容易保证正确性。随着高级语言的诞生和软件的广泛应用,软件的规模急剧增大,操作系统软件、编译软件等系统软件一般在数万行源代码以上,而且这种软件一般是计算机系统运行的核心,其正确性和可靠性的要求都比较高,传统程序开发方法和软件可靠性之间的矛盾日趋突出。70 年代诞生的软件工程技术是软件发展的里程碑,它在某种程度上缓解了这个矛盾,但没有从根本上解决问题。近二十年来,软件开发技术迅速发展,包括结构化软件开发方法、面向对象软件开发方法、基于构件的软件开发、面向服务的软件体系结构等,这些先进的技术大大提高了大型软件的开发效率和可靠性,但当软件变得日趋庞大时,缺陷和漏洞还是难以避免。

软件可靠性理论中的重要研究问题包括:如何根据发生的错误来评估软件的可靠性指标?如何检测软件中错误的方法,包括采用形式化验证来证明关键软件模块的正确性?以及如何容忍软件中的错误?

软件测试是目前发现软件中错误和提高软件可靠性的主要手段,但早在 1972 年, Dijkstra 曾说过一句名言:“软件测试只能表明错误的存在,而不能表明错误不存在。”所以,软件测试只能测试程序的一部分执行状态,而不可能对

整个软件进行彻底测试。

另一条可行的技术道路是采用形式化验证的方法来证明部分关键软件模块的正确性。形式化验证方法的关键是能够将程序性质表述出来,然后再进行验证,其中,模型检测(model checking)和逻辑推导这两种通用的形式化验证方法是计算机硬件和软件的正确性验证中常常用到的工具。模型检测的基本思想是用状态迁移系统(S)表示系统的行为,用模态逻辑公式(F)描述系统的性质。这样,“系统是否具有所期望的性质”就转化为数学问题“状态迁移系统 S 是否是公式 F 的一个模型”。对有穷状态系统,这个问题是可判定的,即可以用计算机程序在有限时间内自动确定。逻辑推理通常采用定理证明器对系统进行形式化的数学推理,该方法通常是半自动化的。形式化验证的代价比较昂贵,通常只适用于关键模块的正确性保障,目前用在硬件部件和硬件协议上比较有效,用在软件模块上效果差一些。

4. 数据存储的可靠性

数据是计算机系统的关键部分,在大规模计算机系统中都采用数据备份的方法加以保护,常用的数据存储可靠性技术包括磁盘阵列技术(RAID)和多副本技术。例如,在 Amazon 的 Dynamo 系统中^[2],数据副本数遵循 (N, R, W) 规则, N 表示副本数目,如果 R 个读取一致则认为读取成功, W 个写入正常则认为写入成功,并不要求全部 N 个都成功完成。只要 $R + W > N$,数据的最终一致性就可以得到保障。

数据存储可靠性的一个重要研究问题是如何在可用性、容错性和高效性之间进行折中。容错性需要做更多额外的工作,而更多的额外工作必将降低效率,同时,额外工作也会间接增加系统复杂度,进而影响可用性。例如,数据划分法是一种常用的数据可靠性方法,它通过把数据划分成很多小的碎片,把这些碎片分布在大量不同的机器上,对数据集的计算和操作也分发到拥有碎片的部分或全部机器上,然后由客户端把结果合并起来,因为小数据碎片的恢复比大数据更快,这种方法有助于数据恢复。例如,对用户而言,关键操作日志和难于再生的数据是绝对不能丢失的,而这些关键数据是整个数据中相对小的一部分,因此,采用有所区分的不同策略比提供一致的完美数据可用性更为有效。在搜索引擎中,Web 的副本和它对应的索引文件非常庞大,但通过重新获取数据和重生成索引文件能使它们再生,因此,就可以采用不同的可靠性策略。

5. 系统的可靠性

对于大规模复杂计算系统,系统级的可靠性设计必须考虑数据、软件、硬件等多个层面,需要考虑由海量的不可靠节点构成的系统中,如何保证整机的

可靠性。系统的可靠性研究有下面这些重要的研究问题：

(1) 大型计算系统的失效分析与故障级别评价。一个大型系统的不可靠可能来自硬件、软件、工作环境、用户负载等多个因素，需要研究它们对系统可靠性的影响，发现系统的失效模式。通过分析系统的故障类型和失效模式，可以对故障进行分级，确定对系统的服务质量的影响程度。

(2) 大型计算系统可靠性的跨层协同。可靠性在系统的不同层次间是有关联的，例如，内存的局部故障会表现在操作系统的出错上，对硬件层次的错误统计与分析能够帮助应用软件预测未来可能的失效，进而提前采取措施。因此，从芯片、系统、编程模型、支撑环境、服务应用等多个层面综合考虑，是提高系统级可靠性的一个重要研究方向。

(3) 大型计算系统的故障管理。故障管理需要解决的是故障的预测、故障的隔离、故障的诊断和故障的修复等一系列问题。例如，在互联网应用中，用户所能体验到的是服务质量和服务是否可持续，能够容忍一定时间或空间范围内的失效存在，因而有效的故障管理能够帮助获得更好的用户服务体验。目前，智能化的故障管理是一个突出的研究问题，即通过自检测、自定位、自隔离、自愈合、自预测的所谓 5S 可靠性保障技术，来提高故障管理的智能性。其目的是减少复杂的配置和人工干预，这对大规模复杂计算机系统非常重要。借助从芯片到系统级的软硬件容错机制的支持，能够根据系统的行为和症状有效地自预测、自检测，并能够自定位到故障部件。当系统发现失效的部件时，能够进行及时自隔离，并迁移相关的数据和计算。当系统中移除或添加了新的部件时，计算机系统的自愈合功能能够自动地识别损失的、替换的或者添加的节点，并自组建成一个新的功能系统。这种可靠性保障技术能够极大地提高故障管理的效率，进而提升服务的质量。

6. 系统的可靠性评估

计算机系统的可靠性评估是一个极为复杂的科学问题。目前，许多行业对计算机系统的可靠性都提出了很明确的量化要求，如电力、电信行业的可靠性要求为 99.999% (5 个 9，即 1 年 10 分钟的停机时间)，航天系统可靠性的要求为 99.9999999% (9 个 9)，达到此目标需要付出极高的代价。美国 NASA 为了保障其航天软件的可靠性目标，软件测试与可靠性保障的费用占整个软件开发费用的 90% 以上。系统可靠性评估的研究包括故障注入技术、故障的发生机理及预测技术、硬件、软件及计算机系统可靠性基础理论等。Gray 将“如何使计算机系统都能达到 99.999999% (8 个 9) 以上的可用时间并验证之”作为他提出的计算机 12 个难题中的一个科学难题^[3]。

自然界的各种生物是通过几十亿年进化形成的理想的“整机系统”，都具有

很高的“容错”和“自愈”能力。可以借鉴生物体的自愈机制，研究出更可靠的计算机系统，使计算机能够形成自容错和自恢复能力。可靠的计算机系统这一目标虽然远大，实现过程很艰难，但人类绝伦的创造力定会使人类发明出来的计算机成为可靠的系统。

参 考 文 献

- [1] Gray J. A census of tandem system availability between 1985 and 1990. IEEE Transactions on Reliability, 1990, 39(4): 409—418.
- [2] Hastorun D, Jampani M, Kakulapati G, et al. Dynamo: Amazon's highly available key-value store. ACM SIGOPS Operating Systems Review, 2007, 41(6): 205—220.
- [3] Gray J. What next? A dozen information-technology research goals. Journal of the ACM, 2003, 50(1): 41—57.

撰稿人：宫云战¹ 杨朝红¹ 李晓维² 韩银和²

1 北京邮电大学网络与交换技术国家重点实验室

2 中国科学院计算机系统结构重点实验室

自动编程：如何让计算机自动地从需求规约生成软件

Automatic Programming: Generating Software from Requirements Specification by Computers Automatically

自计算机诞生之时就有了编程活动，人们提出了许多软件或程序设计语言来开发软件。据统计，一般程序人员每天平均生产 5~50 行有效代码，每行代码要开销 100 美元，经过反复测试后，通常质量的软件中每千行代码约有 1 个错误。然而，各类计算机系统和应用中，软件数量越来越多，规模越来越大，软件中的错误数也随之增长，软件开发面临的成本高昂、质量欠佳、生产率低等问题变得越来越突出。究其原因，编程活动在很大程度上是程序人员的智力活动，往往易错且效率不高。为了提高软件生产率与质量，一个自然的想法是借鉴传统工业自动化的途径，能不能让计算机自动地从需求规约生成可靠正确的程序。其“理想”是用户只需要了解应用领域并书写简要的应用需求，自动编程系统就能产生满足需求的程序。该系统一是面向终端用户；二是通用的，没有领域差别；三是完全自动化，不需要人的帮助。上述“理想”或许难以实现。然而，对它的长期追求拉动着计算机科学，尤其是软件科学与技术的进步与发展。

“自动编程”一词几乎伴随着整个计算机科学历史的发展，它的含义随时间而不断变化，随着人们对程序和软件开发认识的深入，也有不同的认识。在计算机发展的早期阶段，人们便开始在一定范围内将编程中一些机械性的工作交给计算机去做，如汇编与编译中的机械翻译工作。1958 年 4 月，《ACM 通讯》第 1 卷第 4 期上曾列出了当时的一组称为“自动编程”的系统，大多数系统在今天看来有些是汇编器，有些是编译器（如 IBM 704 上的 Fortran 编译器，如图 1 所示）。与机器码程序设计相比，汇编器提高了程序设计自动化水平，而 Fortran 更是编程走向高级语言的显著进步。例如，1957 年的案例称，一个 47 行的 Fortran 程序经 704 上 6 分钟的编译产生了约 1000 条机器指令。著名软件工程大师 Parnas 认为，自动编程指把较高层的语言提供给程序人员作程序设计。20 世纪 60 年代，自动编程拉动了编译理论、编程语言语义、形式化方法和人工智能等领域的发展，出现了编译器的编译器（如 YACC）等一批成果。软件工程出现以后，自动编程的含义有了较大丰富和发展，也称为软件自动化^[1,2]。

一般认为，在程序人员给出程序应该“做什么”（what）后，自动编程来生成



图1 IBM 704 上的 Fortran

“如何做”(how)的代码^[3]。从狭义理解,自动编程指从高层规约描述到可执行的程序代码这一过程的自动化,起到了程序人员与设计人员的作用。从广义理解,自动编程是尽可能借助计算机系统(特别是软件开发系统)进行软件开发,包括需求描述、设计、编码、测试、确认、交付使用乃至维护、演化的全过程,即为采用自动化手段进行软件开发的方法、技术、工具和过程。这时,自动编程系统将起到系统分析员、设计人员、程序人员、测试人员和维护人员,甚至部分领域专家的作用。近五十年来,自动编程研究一直是程序设计语言和系统的圣杯^[4]。

自动编程的起点是表达需求或者规约的语言^[5],该语言处于问题空间表达与软件解空间表达之间,可以是自然语言、领域特定语言、逻辑语言和甚高级语言等。自然语言易于描述需求或规约,然而,自然语言的不严格、歧义是软件错误引入的重要来源,使得后续编程变得困难,因而自动编程需要填补从非形式需求到形式需求描述的跨越。领域特定语言是描述特定领域需求的半形式或形式的语言,易用但依赖领域知识,通用性不强。逻辑语言准确、表达能力强,但在计算上存在不可解问题,并难于为终端用户使用。甚高级语言采用一种自底向上的方式,通过添加语言设施(如抽象数据类型)扩展高级语言的表达能力,其抽象能力虽有提升,但易用性上接近高级语言。目前的主流方法是结合领域特定语言和甚高级语言的方法,设计高层次的非过程语言,并充分发挥软件复用的能力,使得编程变得容易。在数据库、Web、建模等领域,程序人员往往通过书写诸如JavaScript脚本语言和一组预建的对象上开发软件,编程代码量显著减少。例如,面向网络环境出现了将Web数据源和服务组合在一起快速形成新应用程序的Mashup技术。图2给出了一个Mashup应用图示即Google春运地图服务,以标注电子地图的形式提供了春运主要城市的天气和交通整合信息;在系统建模与仿真领域,Modelica语言有效支持了复杂系统的构件化建模。但是,如果应用问题需求与已有的程序风范

不适配的话，则效果欠佳。




图2 Mashup应用举例——Google 春运地图

正如图灵奖获得者 Gray 所指出的，解决自动编程问题需要人们重新思考和设计能支持自动编程的计算机语言，这种语言要比现有的所有语言更容易掌握、能力更强大，并能被计算机编译，同时，这种语言要能描述所有的应用需求^[4]。利用这样的语言，开发人员可以将客户的应用需求快速自动地转换为可在计算机上运行的软件。

自动编程的难度还体现在如何从对“what”的需求表达得到对“how”的实现表达，即从非算法化问题空间到算法化软件解空间的跨越，其主要途径包括过程实现、演绎综合、程序变换等。过程实现类似于传统的编译方法，在源规约与目标程序的各个成分明确且相应的转换映射也明确的前提下，用过程的方法实现自动代码生成。但是，这种方法难以在通用意义上解决从“what”到“how”的问题，需要新意义下的“编译”，近来与软件复用技术的结合有效地提升了其代码生成能力。

演绎综合方法是自动编程中程序生成的重要途径，其基本思想是将从一个给定规约综合出程序的问题看做是给出该规约可满足性问题的构造性证明，即“证明即程序”的思想。对要生成的程序，用户以某种形式语言(如谓词演算)给出它的输入、输出数据必须满足的条件。对于所有这些满足条件的输入，通过定理证明器证明存在一个满足输出条件的输出，从该证明中综合出目标程序。该方法具有通用性，但面临着很大的复杂性，在真实程序的综合

上往往由于定理证明的复杂性而变得难以实施。近年来,随着定理证明理论和工具的较快发展,以演绎构造方法为主的程序综合及其与其他方法的结合成为研究热点^[6]。

程序变换方法试图将一个甚高层语言描述的程序以一系列变换的方式转换为满足其要求的实现。其中,变换规则由模式、变换的应用条件和动作过程组成。当有一个模式实例发现后,如果变换的应用条件满足,则使用相应的动作过程来生成出对应的较低层实现。程序变换方法中的变换可分为水平变换和垂直变换,对应不同的抽象形态变换。前者是由抽象级别较高的规约或程序转换成与之功能等价的抽象级别较低的规约或程序;后者是在相同抽象级别上的规约或程序间的功能等价转换。变换规则可以看做是程序设计知识的表达,程序变换保持语义正确性。

目前,演绎综合方法和基于规则的程序变换方法等严格的程序自动生成方法均难以适应大型软件的自动编程,也难以摆脱人的参与。因此,人工智能是自动编程必需的支撑技术。合理地引入知识表达与处理、人的因素(包括经验)、学习与交互是值得自动编程深入研究的重要途径。

20 世纪 90 年代以来,软件复用成为自动编程的关键支撑技术,与特定领域相结合形成的应用生成器使得特定应用软件的生产率提升了若干数量级。典型的应用生成器有图形用户界面生成器、数据库应用生成器、Web2.0 的 Mashup 等。复用在自动编程中的成功取决于特定领域语言表达的复用风范与应用问题的吻合程度。

自动编程问题是计算机科学及其应用发展的重要牵引性难题,它桥接了软件问题空间到软件解空间之间从非形式化到形式化、非算法化到算法化的质的跨越。当前,计算机科学前沿有许多是自动编程的子问题或问题的延伸。例如,软件的 CxC 问题(correctness by construction)是自动编程中非算法化到算法化的子问题。对自动编程问题的突破必须依赖软件语言、人工智能和数理逻辑等方向上的进步。

自动编程将软件开发从专业的开发人员逐步扩展为终端用户,使软件进入更广泛的应用领域,惠及更多的用户。作为自动编程的终极理想的一步,终端用户编程被视为软件技术发展的重要目标之一。终端用户编程将传统软件开发进行的活动变为非专业开发人员可以理解和实施的活动,它主要通过配置、插件等一系列形式从已有软件生成符合新需求的软件。“终端用户编程”工具具有易用性和领域性等特点,目前,形式有可视化编程、基于示例的编程等。面向服务的软件开发以网构软件的形式为网络软件自动编程中的软件复用和终端用户编程(也称零编程)提供了新途径。

参 考 文 献

- [1] 徐家福,陈道蓄,吕建,等.软件自动化.北京:清华大学出版社,1994:1—10.
- [2] Balzer R. A 15 year perspective on automatic programming. IEEE Transactions on Software Engineering, 1985, SE-11(11):1257—1268.
- [3] Lowry M R. Automatic Programming, Encyclopedia of Computer Science. 4th Edition. New York: Wiley, 2003:119—122.
- [4] Gray J. What next? A dozen information-technology research goals. Journal of the ACM, 2003, 50(1):41—57.
- [5] Rich C, Water R C. Automatic programming: Myths and prospects. IEEE Computers, 1988: 40—51.
- [6] Srivastava S, Gulwani S, Foster J. From program verification to program synthesis. Proceedings of the 37th Annual ACM SIGPLAN-SIGACT Symposium on Principles of Programming Languages, 2010:313—326.

撰稿人：王 戟

国防科学技术大学计算机学院

电脑（计算机）能否接近人脑？

Can Computers Approach Human Brain?

1. 一个有争议的难题

“电脑能否接近人脑”的含义是“计算机能否像人脑那样具有智能”，以及“多大程度上能够达到人脑的智能”。由于大家对什么是“智能”有着不同的理解，于是对这个问题的答案就有了很大的分歧。因此，在进入问题讨论之前，先要澄清关于智能的概念。反对计算机会有智能的人大体有两类：一类属哲学家，一类属科学家。不少哲学家认为通过计算机的程序或算法不可能达到人脑的智能，其中，具有代表性的有 Dreyfus、Searle 等，他们写了很多书和文章反对人工智能的主张^[1]，其理由之一就是反对英国数学家、计算机理论的创始人图灵(Turing)提出的关于机器智能的主张。图灵于 1950 年提出一种实验，他的目的是通过这种实验来鉴别机器是否具有智能。他设计的实验测试中，有一名人类裁判员和两名被试者，而被试者分别是一个人与一台机器。裁判员可以通过键盘与屏幕(或其他通信工具)以自然语言的方式与被试者对话，两个被试者都试图将自己装扮成人以迷惑裁判员。如果通过对话，裁判员不能可靠地分辨出被试者哪一个是人、哪一个是机器，我们就可以认为“机器具有人的智能”或者说“机器能够思考”，这就是所谓的“图灵测试”(Turing test)^[2]。从图灵测试可以看出图灵对“智能”的主张，即机器如果表现出与人类相似的智能行为，就可以认为该机器具有人类的智能，而不管机器用的原理是否与人类相同。Searle 提出一个叫“中文屋子”(Chinese room)的假想试验作为对图灵主张的反驳。他的假想试验是这样的，“假设一个被关在小屋里的人只懂英文。事先我们给他一批中文的材料，包括问题、答案等，以及一套英文的规则与指令。随后我们从窗口递进一张纸条，纸条上写着以中文表示的提问。屋里的人尽管一点不懂中文，但他可以根据英文指示的步骤，将中文的提问与中文的相应答案联系起来，最后将中文的答案从窗口递出来。”可见，只要程序安排得当，完全可以让他给出正确的答案，而和懂中文的人几乎没有两样。Searle 据此认为，一台机器即便像“中文屋子”那样，表面上表现出看似智能的行为，但实际上只是根据给定的程序，一步一步笨拙地执行，对自己所做的一切毫不理解，没有任何与人脑一样的心智(mind)与意识(consciousness)，这种情况不能认为机器具有智能。可见，他们之所以反对机器具有智能，原因在于他们对“智能”的理

解与图灵针锋相对。

从科学的角度反对计算机具有智能的也有许多，其中有代表性的如数学物理学家 Penrose 等^[3]，他们反对的理由是人类意识是“非算法的”（non-algorithmic），因此，不能使用通常的确定性的计算机（图灵机）来实现。Penrose 还认为量子力学的规律在人类意识中扮演重要角色，基于普通物理规律的计算机也是无法实现的，因此，现代计算机不可能达到人脑的智能。有的反对者还利用 Gödel 不完全性定理来否定制造智能机器的可能性。因为 Gödel 定理指出“一个形式系统不可能证明其中所有的真命题”，由此可以推断作为形式系统的计算机一定也存在同样的局限性。总而言之，他们反对的理由也比较简单，既然人脑的结构与工作机理与计算机都有着本质的区别，所以，计算机不可能达到人脑的智能。

看来要解决这些争议，首先需要澄清我们这里所说的“电脑接近人脑”和“计算机具有智能”究竟是什么含义。图灵测试给出了一个检验“智能”的标准，即“如果机器能够表现出像人一样的智能行为，就可以认为该机器像人一样具有智能”，而不管这个智能行为是用什么办法实现的。这个测试巧妙地回避了关于什么是“智能”的直接定义，而且还可以回答许多科学家提出的对机器智能的质疑。因为这里讨论的是如何利用计算机来模拟（逼近）人脑的智能，而不是全面“克隆”人脑。因此，尽管计算机与人脑的结构和工作原理不相同，但利用前者来模仿后者还是有可能的，至少在某些方面是可能的。显然，我们前面提到的“中文屋子”与“图灵测试”尽管针锋相对，也只是对“智能”理解上的分歧，只是反映了不同的哲学观点，可以留给哲学家们去讨论。如果只着眼于计算机科学与技术，我们不妨采用图灵的观点，因为“图灵测试”为我们提供了一个可操作的标准，一切从事人工智能与机器智能研究的人，都可以把“使机器通过图灵测试”作为他们的奋斗目标，有了这个目标，广大研究者就有了共同的努力方向。

人类在探索“电脑接近人脑”的道路上尝试过各种办法，有的成功，有的不太成功，有的失败了，总之充满了曲折与困难，说明这是一个难题。下面，我们将简单介绍计算机模拟人脑的主要计算模型及所取得的研究进展，以此来说明利用现代计算机科技在模拟（逼近）人脑的功能上已经取得了哪些成果，遇到过哪些困难，并由此展望今后可能的发展道路。

2. 符号推理模型

1956 年，电子计算机诞生不久就出现了人工智能这一新的研究领域^[4]。那么，什么是人工智能？一种为多数人接受的观点是该领域的创始人之一 McCarthy 提出的，他的定义是“人工智能是制造智能机器的科学与工程，特别

是智能计算机程序,” 换句话说讲, 人工智能试图通过计算机程序来实现对人脑功能的模拟(逼近)。这个新领域至今依然是计算机科学中十分活跃的研究领域。人工智能包含许多研究内容, 如推理、规划、搜索、问题求解、知识表示、不确定性处理、感知、学习、群体智能等。在半个多世纪的研究探索中, 人工智能在模拟人类高级智能行为方面取得了很大的成功。人工智能的奠基人认为, 人脑是一个信息处理系统, 人脑的许多行为, 如推理、规划、决策与问题求解等, 都可以看成是信息处理过程, 他们由此推断计算机完全能够模拟此类行为。为了强化这个论断, Newell 与 Simon 提出了物理符号系统假设(physical symbol system hypothesis)。该假设认为: 物理符号系统是智能行为的必要与充分手段。有了这个假设, 自然就有以下结论, 即根据其必要性可以推出, 因大脑具有智能行为, 它一定是一个物理符号系统; 反之, 根据其充分性, 计算机既然是一个物理符号系统, 因此, 它必定具有智能行为。虽然不是所有科学家都接受这个假设, 但它的确是早期从事人工智能研究的主要指导思想, 并形成了被称为符号主义(symbolist)的学派。依据这个假设所提出的以经验与知识为基础的计算机推理模型, 以及启发式(heuristic)程序设计方法, 打破了以往编程只能依靠数学模型的限制, 极大地扩展了计算机的应用范围, 使计算机根据经验与启发式知识也可以编制出应用程序, 在模拟人类的高级智能行为上迈进一步。利用这种编程方法, 人们建造了许多针对特定领域的智能应用系统, 如各类专家系统, 取得了很大成功, 掀起 20 世纪 80 年代人工智能研究的高潮。一直到 21 世纪初, 这个趋势仍在发展中, 专家系统已广泛应用于管理、数据挖掘、医疗诊断等各个领域, 有的还获得了商业上的应用。其中一项标志性的成果是 1997 年



图 1 人-机大战

5 月 11 日, IBM 公司国际象棋程序——深蓝(Deep Blue)打败了世界冠军 Kasparov。他们之间共下了 6 盘棋, 最后计算机以二胜一负三平的战绩取得胜利(如图 1 所示)。此项胜利意义重大, 因为在人工智能诞生之初(1956 年), 它的创始人就把设计国际象棋程序在十年内打败世界冠军作为奋斗目标之一, 经过 40 年的努力, 这个目标终于实现了。虽然比

预定时间晚了许多, 但毕竟在“下国际象棋”这样堪称“高级智能的行为”上, 计算机接近甚至超过了人脑的能力。深蓝象棋程序之所以取得成功, 是因为集成了大量的人工智能研究成果, 包括推理、启发式搜索、顶尖棋手的经验与知识的运用等, 因此, 深蓝的获胜标志着人工智能在模拟人类“冷智能”(cool intelligence)(高级智能行为)上的成功。人工智能的这些成就来源于众多原创性思想, 如物理符号系统假设、有限理性(bounded rationality)原理、符号推理、基

于经验与知识的启发式编程、知识表示、不确定性知识处理等。其中,人工智能创始人 Minsky、McCarthy、Newell 与 Simon、Feigenbaum 与 Reddy 等 6 人为此做出重大的贡献,并分别获得图灵奖。

3. 统计机器学习模型

如上所述,人工智能尽管在模拟“冷智能”方面获得成功,但对于“热智能”(hot intelligence),如感知、情感等方面,符号推理模型却遇到很大的困难,进展缓慢。属于“热智能”而最具代表性的是模式识别,如图像识别、语音识别等。对于这类复杂的模式,如一幅图像进行符号描述十分困难,同时它又是一个归纳问题,存在多种不确定性与多解现象。人们虽然尝试过各种符号归纳的模型,但都只能在“玩具世界”中进行原理性的探讨,难以应用到实际问题中,与人脑的性能相比则有天壤之别。从 20 世纪 80 年代开始,机器学习理论与方法的涌现,特别是统计学习理论与方法的发展,使“热智能”的研究有了较大的进展^[5]。如何识别一个模式(如一幅人脸图像)?机器学习采取这样的学习步骤:先用一组人脸图像集(包括正例与反例)对机器进行训练,让机器根据训练图像的特征学习区分正例与反例的办法。学习之后,再用一组新的人脸图像集进行测试,如果机器能够较好地将测试图像集中的正例与反例区分开来,那就可以认为机器具备了一定的人脸识别能力(如图 2 所示)。目前,已经提出的机器学习方法有很多,研究者把这些方法应用于图像、语音、文本、视频等各种多媒体信息的处理,应用于网络数据挖掘与理解等,在不同领域均取得不同程度的进展。例如,计算机人脸识别系统的性能有了很大的改善,在一些特定的情况下,可以得到较好的性能,有些场合甚至达到实用的要求,如出入境人员检查、安全保卫等。尽管“热智能”的模拟取得一些进展,但总体来讲,与人脑的能力相比依然相差很大。



图 2 人脸识别

由此可以得到这样的结论:计算机在模拟人脑的功能上,在有些领域效果很好,如科学计算、推理、问题求解等,机器的能力可以接近甚至超过人脑的能力。但是,在另外的方面,如感知、情感等方面,却与人脑相差很远。计算机接近人脑的道路依然很漫长。

4. 基于行为的智能模型

上面介绍的围绕模拟人脑所做的研究都是以孤立的大脑为对象,特别是高

级问题求解行为,把智能看成从上而下以逻辑与知识为基础的推理行为,这是一种“整洁”(neat)的处理方法。以图灵测试的观点来看,我们主要根据“对话”(言谈)来判断机器是否具有智能,然而智能是一个非常复杂的现象。人脑的智能行为既包括“言谈”,还包括“举止”,因此,有一种批评意见认为,人脑的智能行为不是大脑的孤立现象,是大脑与周围环境交互的结果,包括环境感知和行为动作,所以,利用孤立的计算机来模拟人脑智能行为具有很大的局限性,很难达到人脑的境界。20 世纪 80 年代,美国 Brooks 教授提出一个基于行为(behavior-based)的模型,与以往的模型不同,它是从下而上以行为为基础的智能,其关键是把大脑与躯体结合起来,组成一个完整的机器人(robot)(如图 3 所示),机器人与环境有交互,一方面感知周围的环境,另一方面采取一定的行动作用于环境,形成感知-行动的循环。这种主张形成了另一种流派——“粗陋”(scruffy)的处理方法。这种流派在人工智能诞生之初,即 20 世纪 60 年代就



图 3 机器人

由 Minsky 等提出,并逐步形成。他们不主张从上到下逻辑地构建智能系统,而是从下而上地通过与环境的交互,不断学习、凑试,最后形成适当的响应。通过这个思想建立的智能系统具有很强的自主能力、对未知环境的适应能力很高、系统的鲁棒性很强等优势。将智能主体嵌入到环境之中,如果这个主体是硬件,那就是我们所说的机器人;如果是软件,那就是软(件)机器人(softbot)。基于行为的智能对智能机器人的研究有着重要的影响。如果关注的只是对人脑的模拟,我们感兴趣的应该是这个学派提出并形成的一套原理与方法,如基于行为的模型、激励学习(reinforcement learning)等,因此,它在计算机模拟人脑的研究中占有一定的地位。

5. 人工神经网络模型

人工神经网络(artificial neural networks)最初是受生物神经网络的启发而建立起的数学计算模型^[6]。它的结构与中枢神经系统有着某种相似之处,即由大量的简单处理单元(神经元)相互连接组成的网。网络整体的复杂行为取决于处理单元的参数及它们相互之间的连接强度,通过并行、整体的共同处理实现,因此,有时把这种方法称为连接主义方法(connectionist approach)。人工神经网络受到关注有其历史原因,因为反对计算机能够拥有智能的重要理由之一是计算机的结构与大脑完全不同。为此,大家希望寻找一种与大脑结构相似的计算模型,人工神经网络模型满足这个要求,所以受到关注。可是,

与大脑的神经网络系统的结构相比，目前在人工智能、认知心理学及统计学中使用的人工神经网络都是经过极大简化了的。在实际应用中，主要通过电子计算机，依靠设计合适的学习算法，通过改变神经元之间连接的强度(权值)，以产生希望的信息处理结果，如复杂的输入-输出关系、发现数据中的模式，以及联想记忆等。人工神经网络的结构与大脑神经系统结构有着某种相似之处，如平行处理、存储与处理在同一场所进行等，尽管它是一个极为简化的模型，目前还无法与大脑的智能相比，不过，由于它在结构上的明显优越性，同时能够在通用的电子计算机上加以实现，因此，在探索计算机模拟人脑的道路上仍有其独特的作用。

在人工智能研究中还有一些重要的学派，如演化算法、遗传算法、粒子群算法、蚁群算法等所谓计算智能的方法，这些研究主要借助仿生学的原理，学习与借鉴动物或动物群体的智能，对于机器智能的研究有很大的帮助与推动作用。这里就不逐一介绍了。

电脑接近人脑的道路之所以如此艰难，其原因之一就是我们对大脑的工作机制缺乏了解。脑科学、神经科学、心理学等的研究就是试图揭开大脑智能之谜，目前，这些学科研究的进展离这个目标还很远。展望未来，我们可以看到，随着科技的进步，特别是信息科技的进步，脑科学的研究方法与工具不断在改进，如测量神经元活动的探针技术、脑电图测量(EEG)、肌电扫描(EMG)及功能性磁共振成像(fMRI)等技术的发明，使我们能够从大脑的不同层面上，即单个神经元、神经网络、脑功能模块，一直到心理等层面同时进行研究。此外，20世纪80年代形成的计算神经科学(computational neuroscience)等新领域主张利用信息科学的方法来研究神经系统的工作。有了这些方法与技术，我们对大脑的认识将会不断深入。智能机器的建造离不开这些知识的积累与借鉴。历史上，人工智能的研究与认知心理学、神经科学研究有着很密切的联系，人工智能的创始人就来自各个不同的领域，如认知心理学家、数学家、计算机科学家等。我们需要发扬这种传统，加强多学科的交叉、渗透，以加快智能机器的研制。“电脑接近人脑”不仅是计算机科学的难题，也是脑科学、神经科学、认知科学、心理学及哲学等关注的课题。目前，我们离这个问题的答案虽然还很遥远，也许还需要几代人的努力。人脑是一个极为复杂的系统，要想利用计算机的计算模型来模拟它，简单的单一模型是不够的，因此，需要从不同的学科，沿不同的方向，按照不同的思路进行探索，以建立不同的模型与方法，我们已经积累了相当丰富的知识与经验，不断地将这些成果集成起来，总结经验并继续往前走，这样，我们离最终的目标将会越来越接近。“电脑接近人脑”是一个很难的课题，其中既有需要解决的科学难题，也有大量的技术与工程难题，充满了魅力，正吸引着各种不同学科的科技人员的积极参与。

参 考 文 献

- [1] Dreyfus H L .What Computers Still Can't Do ;A Critique of Artificial Reason .Cambridge : MIT Press ,1992 .
- [2] Turing A .Computing machinery and intelligence .Mind ,1950 ,59 (236) :433 —260 .
- [3] Penrose S R .The Emperor's New Mind .Oxford :Oxford University Press ,1989 .
- [4] Russell S J .人工智能——一种现代方法 .第 2 版 .姜哲 ,等译 .北京 :人民邮电出版社 ,2004 .
- [5] Mitchell T .Machine Learning .New York :McGraw-Hill ,1997 .
- [6] 杨行峻 ,郑君里 .人工神经网络 .北京 :高等教育出版社 ,1992 .

撰稿人：张 钹

清华大学计算机科学与技术系

知识的自动发现

Automatic Knowledge Discovery

知识的自动发现是一个横跨机器学习、数据挖掘、认知科学、脑科学和哲学等多学科领域。简单地说,知识的自动发现是用计算机从大量、繁杂的数据中自动地发现其隐含的、有用的并具有一定概括性的知识。例如,从各种行星轨迹的记录中自动发现开普勒定律;从超市大量的客户消费数据中获取哪些物品经常被一起购买的信息。知识的自动发现标志着人类不仅能够对自然界和人类本身有足够的理解(如牛顿定律等),而且能够重复并扩展这种发现的过程,解释知识发现的本质和机理。同时,在信息化时代,随着海量复杂数据的不断涌现,人们越来越意识到对这些数据进行知识的自动发现可能带来巨大的商机与社会价值。

知识的自动发现与人类对知识的探索是息息相关的。从亚里士多德用逻辑对知识的表达,到达·芬奇对各种物理现象的推演和形象描述,直至牛顿等对天文和物理等自然现象利用自然定律的总结,都可以认为是人类早期对知识发现所做出的努力。为了使人类能在更为广泛的领域进行知识发现,学者对知识发现的过程与原理产生了浓厚的兴趣。有学者通过研究认知科学(cognitive science)、综合语言学、心理学、神经科学、哲学和人工智能,来研究大脑如何对知识进行获取、储存、变换与传播,研究结果表明,知识发现中的一个要点是“学习提升智能”^[1]。最近,通过功能磁共振成像(fMRI)等技术,学者可以较精确地测量大脑各区域脑血流的变化及其功能结构,进而研究人的知识发现过程。

为达到同样的目标,人工智能的学者们则探讨如何利用计算机对大量数据进行高通量的积累和处理,来实现知识发现的目的。在给定计算机足够的物理数据、生物数据和商业数据的情况下,计算机能不能自动地发现牛顿定律,推出DNA的双螺旋结构并自动挖掘出有效的商业信息呢(如图1所示)?

现在,我们得到的知识、发现的成果还远远无法达到“计算机像人类科学家一样进行知识发现”这一目标,但这个目标一直是学者们努力的方向。早在20世纪70年代,Langley教授^[2]就描述了自动发现物理学定律的系统BACON。BACON算法主要是基于专家系统的生成规则对各种变量的子集进行搜索,用穷举法得到如 $F=ma$ 这样的定律。虽然只能发现一些较为规则的物理和化学定律(如开普勒定律等),并需要非常纯净的少量数据作为输入,但这些成功的实例




图1 知识发现的目标

为后来的工作提出了两个重要概念。首先，知识发现需要我们能自动地提出上层的知识模式，即“学什么”的问题。例如，在研究物理问题中，我们有大量的实验变量，如速度 v 、质量 m 、力 F 、温度 T 等，那么，我们应该找 (v, m, T) 之间的关系，还是应该找 $\left(\frac{dv}{dt}, \frac{d^2v}{dt^2}, m, F\right)$ 之间的关系呢？这涉及如何自动地进行特征构建(feature generation)的问题。同时，我们也要有一整套底层的发现模块，用来解决“怎么学”的问题。例如，如果 $F=Wma$ ， W 是一个常量，那么， W 应该是多少呢？至今，知识发现领域内的主要工作都集中在后者，即“怎么学”的问题上，如这个 W 值就可以通过回归的方法得到。

在“怎么学”的问题上，主要的工作分为分类学习(classification)、回归算法(regression)和聚类算法(clustering)等。分类学习的目标是在数据中找到主要的因素，以对一个特定的标记进行预测。例如，给定职员个人信息，可以预测职员的收入高低(如图2决策树所示)。回归算法则是对数值的预测，如预测某种气体的温度有多高。基于有标记的训练数据的学习过程叫做有监督学习，这样的知识发现任务虽然简单(预测两类，多分类或数值标记)，但在科学领域已经非常有用。例如，在生物信息学领域，人类基因组测序计划初步完成和癌症基因组计划的开展积累了大量的实验数据，机器学习成为生物信息学中的重要工具。在研究疾病，尤其是癌症的致病基因时，监督分类学习从病人和正常人的基因序列、SNPs 序列或基因表达数据出发，通过特征选择得到最能区分患者和正常人的单个基因或者多个基因，进而帮助设计新的生物学实验以验证致病基因。当知识发现的任务里没有任何监督信息时，聚类算法也可以从数据之间的相关性出发，对数据中隐含的聚类知识进行挖掘。学者同时开始研究如何在只有少量有标记数据而存在大量未标记数据的情况下进行学习的问题，也就是半监督学习问题。半监督学习试图找到未标记数据分布和学习目标之间的联系，然后利用未标记数据来辅助提高学习性能^[3]。

除了对科学定律进行自动知识发现，学者们同时对不同应用领域的知识发现进行了广泛的研究。在商业应用之中，我们也经常会碰到在大规模数据中找




图2 分类学习中的决策树模型

出不同变量之间的联系的问题。众多学者对“关联规则挖掘”(association rule mining)进行了大量研究。早期的工作包括 Agrawal 等在 1994 年提出的 Apriori 算法^[4]。Apriori 算法能够通过广度优先的搜索,发现“买‘知识发现’方面图书的人也很可能买‘数据挖掘’方面的书”这样的关联规则。此后,大批学者开展了后续研究,从时间复杂度与空间复杂度等方面优化关联规则挖掘。在互联网方面,搜索引擎成为最主要的知识发现工具。最成功的实例要数 Page 与 Brin 等在 1999 年提出的 PageRank 算法^[5]。PageRank 算法通过网页之间超链接的关系计算出网页的重要度,并在应用中获得了良好的效果,成为现在广为人知的 Google 搜索引擎的核心组成部分,每天都被全世界成千上万的用户使用。在电子商务方面,对诸多网络用户而言,互联网上的信息在极大丰富的同时,不可避免地带来了信息过载的困扰。当在售的产品经常数以亿计时,个性化推荐技术应运而生。数据挖掘根据用户买过的商品、用户经常点击的网页等信息,自动去推测会有哪些新的信息跟用户相关,此方面的研究成果已经广泛应用于商业系统,如全球最大的在线书籍销售网站 Amazon 及在线影碟租赁网站 Netflix 都使用了自动知识发现的方法从成千上万的商品中为用户挑选出他们最有可能感兴趣的那些。在社会化网络(social networks)应用方面,社会化计算(如 Web 2.0)发展迅速,数据挖掘已成为社会网挖掘的重要工具。由此也引出许多新的研究,如在社会化网络上对信息传播机制的研究、网络动态演变的研究等。继

互联网之后，物联网也逐渐流行起来。在这一背景下，传感器及传感器网成为获取人或物体行动信息的重要手段。学者们研究如何用机器学习对传感器数据建模以精确识别人或动物的行为，预测其位置和行为信息。

上面提到 Langley 的 BACON 系统提出知识发现的两个层次，其下层模块“怎么学”的问题已经有了很多的研究和应用。但是，对于上层的“学什么”的问题，至今尚未得到很好的解答。可见，对这样一种自动学习过程，需要从全局角度将不同的学习问题有机地结合起来。下面，我们将展望知识发现领域中三个重要且相互联系的热点问题。概括起来说，这三个问题是如何能够自动地进行“借鉴和类比”、“复杂问题的简约”和“产生灵感”。

首先，知识的自动发现需要计算机有联想、借鉴和类比的功能，使其能够举一反三。就这一点，我们来讨论迁移学习。在现实问题中，我们可能难以得到同种类或同分布的训练数据。此时，学者们开始尝试借用其他任务的数据或其他种类的数据辅助学习，这种学习称为迁移学习^[6]。迁移学习类似于我们人类利用象棋的思想与套路学习机器人足球(如图 3 所示)，它从很大程度上量化了人工智能早期的类比学习(learning by analogy)的目标^[7]，使得我们能够通过从其他相关领域中得到的启发，利用现代机器学习的手段来解决一个新出现的较难问题。现阶段的迁移学习研究可以分为两个方面：同构空间下的迁移学习和异构空间下的迁移学习。在同构空间下，尽管辅助训练数据和源训练数据或多或少会有些不同，但辅助训练数据中还是应该会存在一部分数据比较适合用来训练一个有效的分类模型，并且适应测试数据，这是基于实例的迁移学习的基本思想。基于特征的迁移学习的基本思想是同时考虑源数据与辅助数据，以得到一个更好的共同特征空间，通过在这个新空间表示源数据实现迁移学习。




图 3 迁移学习

在异构空间下，即非常不同的领域之间进行迁移学习，是实现借鉴和类比功能的另一个方面。在非常不同的领域之间进行迁移学习难度在于如何找到能迁

移的知识。例如，我们会问：学习绘画创作与学习音乐创作之间是否有公共知识可以迁移呢？人类可以做到这一点，因为在创作意图、情感及表达上，作为艺术的两种形式，美术与音乐有很多相通之处。而对于计算机来说，做到这一点并不容易。在已有的工作中，学者已经在文字和图像之间的转换问题上做了很好的尝试^[8]。一般来说，异构空间下的迁移学习致力于解决训练数据与测试数据分别属于两个不同特征空间的情况，其基本思想是：首先获得一个连接不同特征空间的桥梁，然后通过这个桥梁将辅助数据迁移到源数据特征空间里去，用一个统一的模型进行学习及预测。能够在更加广泛、缺少直接联系的任务间做到举一反三和触类旁通是当前知识自动发现这一方向的挑战与热点之一。

其次，知识的自动发现需要计算机能够把不同的知识联系起来，同时，把一个复杂的问题化解或简约(reduction)为几个简单的问题来解决。结合领域的背景知识把不同的学习子任务联系起来，是关系学习(relational learning)的一个主要目的。其中的一个重要手段是将逻辑引入统计学习，以达到把一个全局的学习问题分解与简化的目的。马尔可夫逻辑网(Markov logic networks, MLNs)^[9]就是这样的一个方法，它的基本思想可以通过一个例子来表达。例如，假设我们要通过网页间的联系来发现一个学校里老师和学生之间诸如“教育与被教育”之类的关系，这种关系可以通过研究大量的数据中存在的共同现象被发现与证实。例如，他们经常在同一门课的网页里出现或常在同一篇文章中为合作者，这些都可以作为他们师生关系的依据。在马尔可夫逻辑网里，这些关系可以用带权值的逻辑公式来描述。如果我们对某些人不是很确定他们有这样的关系，那么，可以赋予这个逻辑公式一个较小的权值，反之，也可以增加权值，而这些权值可以从数据中通过优化及近似等方法得到。这样，一个有权值的逻辑网络架构能够更好地表达很多仅用统计所不能表达的特征。今天，马尔可夫逻辑网已被应用于文本分析、生物信息学及机器人的动作模型学习中。

另一个新的备受关注的方向是如何把一个困难的学习问题转化为一系列相对容易或已有答案的学习问题。例如，学习一个英文句子的语法时，可以化解为一系列的子问题，如“学习第 t 个词的词意”和“学习第 t 个词和第 $t+1$ 个词之间的联系”等，我们对其中每一个子问题都已有一些可行的算法。这类问题叫做“简约学习”(machine learning reductions)^[10]。学者们现在的做法大都是把一个有结构的问题(structured learning problem)化简为许多子学习问题。

我们看到，目前的知识发现系统仅局限于建立模型、完成简单的任务，如分类等。今天的计算机还不能做到自动地发现普遍存在于宏观和微观社会中的科学定律和自然规律的程度，如从大量的物理文献、理论与实验观察里得出像爱因斯坦的 $E = mc^2$ 那样深奥的理论，其中一个很重要的原因是我们对人类知识发现过程中“灵感”的产生机理还不太了解。这是我们要提的第三个问题，也

是一个非常有趣的问题：知识发现过程中的灵感到底是从哪里来呢？

可以想象，当数据量和复杂程度达到一定规模的时候，所能发现的知识很可能会发生某种“相变”，就像水在某种温度下变成冰一样，而这种相变很可能就相当于人的灵感的产生。从计算的角度，在数据量骤增的情况下，知识发现是不是也有一个从量变到质变的过程，可以让计算机像人类一样地产生灵感呢？这种研究现在已经有了一定的可能性，其基础之一就是大规模分布式的机器学习算法。现在，这种算法的研究已经成为科研与在线工业应用的一个新的热点。从特征的角度，我们要解决的实际问题中所包含的特征数目通常非常巨大，例如，从 2010 年的知识发现大赛的数据中我们可提取多达三千万个特征，显然，这些特征是互相联系的，并且含有冗余。人类可以从大量的特征中综合、提炼出最重要的数个重点进行知识发现，并自动地产生新的特征，计算机是否也能做到这一点呢？现在，许多学者开始关注这个问题，思考如何自动地进行特征构建，如建立层次化的特征空间或深度信念网络(deep belief networks)。当前，自动地进行特征构建仍然属于知识发现领域中的薄弱环节，但渐渐成为了一个研究热点。

灵感来源于实践。过去的经验很可能为我们将来的学习问题提供答案，这就需要我们所说的终生学习。“活到老，学到老”是中国人耳熟能详的名言，我们同样希望计算机能够终生学习。当然，对于计算机而言，“终生学习”指的是永不休止的学习。现有的机器学习技术主要是针对某个特定的任务与数据集设计，一旦算法结束，学习过程也将中止，而这个任务学到的知识也不会用到以后的学习过程中。因此，为了更好地利用各种来源的数据与知识，我们希望机器学习也能终生学习。现在，这类研究已经开始，如卡内基梅隆大学的“永不终止的语言学习”(never ending language learning)系统。

知识的自动发现这一领域从探索之初至今仅五十多年的时间，但却已渗透到了生活中的方方面面。虽然当前知识的自动发现还面临诸多挑战，与人类相比仍显得十分简单，但是，考虑到人类进化、发展了二十万年才获得的当前知识与文明，假以时日，知识的自动发现一定也能有更大的发展。

致谢 感谢陈雨强、刘楠、金鸥、徐倩、胡昊等同学及朱小燕教授的讨论和校对。

参 考 文 献

- [1] 史忠植,余志华.认知科学和计算机.北京:科普出版社,1990.
- [2] Langley P.Rediscovering physics with BACON3.Proceedings of the 6th International Joint Conference on Artificial Intelligence,1979,1:505—507.

- [3] Zhu X. Semi-supervised learning literature survey. Madison: University of Wisconsin-Madison, 2006.
- [4] Agrawal R, Srikant R. Fast algorithms for mining association rules in large databases. Proceedings of the 20th International Conference on Very Large Data Bases, 1994: 487—499.
- [5] Page L, Brin S, Motwani R, et al. The page rank citation ranking: Bringing order to the web. Stanford; Stanford InfoLab, Technical Report, 1999.
- [6] Pan S J, Yang Q. A survey on transfer learning. IEEE Transactions on Knowledge and Data Engineering, 2010, 22(10): 1345—1359.
- [7] Falkenhainer B, Forbus K D, Gentner D. The structure-mapping engine. Proceedings of the American Association of Artificial Intelligence, 1986: 272—277.
- [8] Lu R, Zhang S. Automatic Generation of Computer Animation: Using AI for Movie Animation. New York: Springer, 2002.
- [9] Richardson M, Domingos P. Markov logic networks. Machine Learning, 2006, 62(1—2): 107—136.
- [10] Beygelzimer A, Langford J, Zadrozny B. Reductions in machine learning. Proceedings of International Conference on Machine Learning, 2009.

撰稿人：杨 强¹ 薛贵荣²

1 香港科技大学计算机科学与工程系

2 上海交通大学计算机科学与工程系

自然语言处理

Natural Language Processing

1. 什么是自然语言处理

简单而言,自然语言处理(natural language processing, NLP)就是用计算机来处理、理解及运用人类语言(如中文、英文等),它属于人工智能的一个分支,是计算机科学与语言学的交叉学科,因此,也常被称为计算语言学。由于自然语言是人类区别于其他动物的根本标志,没有语言,人类思维也就无从谈起,因此,自然语言处理体现了人工智能的最高任务与境界。也就是说,只有当计算机具备了处理自然语言的能力时,机器才算实现了真正的智能。

从研究内容来看,自然语言处理包括语法分析、语义分析、篇章理解等。从应用角度来看,自然语言处理具有广泛的应用前景。特别是在信息时代,自然语言处理的应用包罗万象,包括机器翻译、手写体和印刷体字符识别、语音识别和文语转换、信息检索、信息抽取和过滤、文本分类和聚类、舆情分析和观点挖掘等。而与语言处理相关的研究领域包括数据挖掘、机器学习、知识获取、知识工程、人工智能和与语言计算相关的语言学研究等。

追根溯源,自然语言处理的兴起与机器翻译这一具体任务有着密切联系。机器翻译是指利用计算机自动地将一种自然语言翻译为另外一种自然语言。例如,自动将英文“I like Beijing Tiananmen Square”翻译为“我爱北京天安门”,或反过来将“我爱北京天安门”翻译为“I like Beijing Tiananmen Square”。由于人工进行翻译需要训练有素的双语专家,翻译工作往往非常耗时耗力,更不用说当需要翻译一些专业领域文献时,还要求翻译者了解该领域的基本知识。世界上有超过几千种语言,仅联合国的工作语言就有 6 种之多。如果能够通过机器翻译准确地进行语言间的翻译,将大大提高人类沟通和了解的效率。

《圣经》里有一个故事说巴比伦人想建造一座塔直通天堂。最初,建塔的人都说着同一种语言,心意相通,齐心协力。上帝看到人类竟然敢做这种事情,就让他们的语言变得不一样。因为人们听不懂对方在讲什么,于是大家整天吵吵闹闹,无法继续建塔。后来,人们就把这座未完成的塔叫做“巴别塔”,其中,“巴别”的意思就是“分歧”(如图 1 所示)。虽然巴别塔停建了,但一个梦想却始终萦绕在人们心中:人类什么时候才能拥有相通的语言,重建巴别塔呢?而机器翻译被视为“重建巴别塔”的伟大创举。假如能够实现不同语言之间的

机器翻译，我们就可以理解世界上任何人说的话，与他们进行交流和沟通，再也不必为相互不能理解而困扰。

事实上，20 世纪 50 年代，“人工智能”被作为一个研究问题正式提出来的时候，创始人 McCarthy 就将计算机国际象棋和机器翻译作为两个标志性任务，认为只要国际象棋系统能够打败人类世界冠军、机器翻译系统达到人类翻译水平，就可以宣告人工智能的胜利。1997 年，IBM 公司的深蓝超级计算机已经能够打败国际象棋世界冠军 Kasparov。

而机器翻译到现在仍无法与人类翻译水平相提并论，从此可以看出自然语言处理有多么困难！

自然语言处理兴起于 20 世纪 50 年代的美国。当电子计算机还在“襁褓”之中时，利用计算机处理人类语言的想法就已经出现。当时，美国希望能够利用计算机将大量俄语材料自动翻译成英语，以窥探苏联科技的最新发展。研究者受到破译军事密码的启发，认为不同的语言只不过是对“同一语义”的不同编码而已，从而想当然地认为可以像破译密码一样采用译码技术“破译”这些语言。

1954 年 1 月 7 日，美国 Georgetown 大学和 IBM 公司合作，实验成功地将超过 60 句俄语自动翻译成英语。虽然当时的机器翻译系统非常简单，仅仅包含 6 个语法规则和 250 个词，但由于媒体的广泛报道，大家一致认为这是一个巨大的进步，导致美国政府备受鼓舞，加大了对自然语言处理研究的投资。实验完成者也当即自信地撰文称，在 3~5 年之内就能够完全解决从一种语言到另一种语言的自动翻译问题。他们认为只要制定好各种翻译规则，通过大量规则的堆砌就能够完美地实现语言间的自动翻译。

然而，事实是理解人类语言远比破译密码要复杂得多，研究进展非常缓慢。1966 年的一份研究报告总结发现，经过 10 年之久的研究，结果远远未能达到预期，因此，支持资金急剧下降，使自然语言处理（特别是机器翻译）的研究陷入长达 20 年的低潮。直到 20 世纪 80 年代，随着电子计算机的计算能力的飞速提高和制造成本的大幅下降，研究者又开始重新关注自然语言处理这个极富挑战的研究领域。三十年沧海桑田，此时此刻，研究者已经清楚地认识到，简单的语言规则堆砌无法实现对人类语言的真正理解。研究发现，通过对大量文本数据的自动学习和统计，能够更好地解决自然语言处理问题，包括机器翻译。这一思想被称为自然语言处理的统计学习模型，至今方兴未艾。



图 1 传说中的巴别塔

那么,自然语言处理到底存在哪些主要困难或挑战,吸引那么多研究者几十年如一日孜孜不倦地探索解决之道呢?

2. 自然语言处理的主要困难

自然语言处理的困难可以罗列出来很多,不过关键在于消除歧义问题,如词法分析、句法分析、语义分析等过程中存在的歧义问题,简称“消歧”。而正确的消歧需要大量知识,包括语言学知识(如词法、句法、语义、上下文等)和世界知识(与语言无关)。这带来自然语言处理的两个主要困难。

首先,语言中充满了大量的歧义,这主要体现在词法、句法及语义三个层次上。歧义的产生是由于自然语言所描述的对象——人类活动非常复杂,而语言的词汇和句法规则又是有限的,这就造成同一种语言形式可能具有多种含义。

例如,单词定界问题是属于词法层面的消歧任务。在口语中,词与词之间通常是连贯说出来的。在书面语中,中文等语言也没有词与词之间的边界。由于单词是承载语义的最小单元,要解决自然语言处理,单词的边界界定问题首当其冲。特别是中文文本,通常由连续的字序列组成,词与词之间缺少天然的分隔符,因此,中文信息处理比英文等西方语言多一步工序,即确定词的边界,我们称为“中文自动分词”任务。通俗地说,就是要由计算机在词与词之间自动加上分隔符,从而将中文文本切分为独立的单词。例如,句子“今天天气晴朗”带有分隔符的切分文本是“今天 | 天气 | 晴朗”。中文自动分词处于中文自然语言处理的底层,是公认的中文信息处理的第一道工序,扮演着重要的角色,主要存在新词发现和歧义切分等问题。我们注意到,正确的单词切分取决于对文本语义的正确理解,而单词切分又是理解语言的最初的一道工序。这样的一个“鸡生蛋、蛋生鸡”的问题自然成了(中文)自然语言处理的第一只拦路虎。

其他级别的语言单位也存在着各种歧义问题。例如,在短语级别上,“进口彩电”可以理解为动宾关系(从国外进口了一批彩电),也可以理解为偏正关系(从国外进口的彩电)。又如在句子级别上,“做手术的是她的父亲”可以理解为她父亲生病了需要做手术,也可以理解为她父亲是医生,帮别人做手术。总之,同样一个单词、短语或者句子有多种可能的理解,表示多种可能的语义。如果不能解决好各级语言单位的歧义问题,我们就无法正确理解语言要表达的意思。

另外一个方面,消除歧义所需要的知识在获取、表达及运用上存在困难。由于语言处理的复杂性,合适的语言处理方法和模型难以设计。

例如,上下文知识的获取问题。在试图理解一句话的时候,即使不存在歧义问题,我们也往往需要考虑上下文的影响。所谓“上下文”,指的是当前所说这句话所处的语言环境,如说话人所处的环境,或者是这句话的前几句话或者

后几句话等。假如当前这句话中存在指代词的时候，我们需要通过这句话前面的句子来推断这个指代词是指的什么。以“小明欺负小亮，因此我批评了他”为例，第二句话中的“他”是指代“小明”还是“小亮”呢？要正确理解这句话，我们就要理解上句话“小明欺负小亮”意味着“小明”做得不对，因此，第二句中的“他”应当指代的是“小明”。由于上下文对于当前句子的暗示形式是多种多样的，因此，如何考虑上下文影响问题是自然语言处理中的主要困难之一。

再如背景知识问题。正确理解人类语言还要有足够的背景知识。举一个简单的例子，在机器翻译研究的初期，人们经常举一个例子来说明机器翻译任务的艰巨性^[1]。在英语中，“The spirit is willing but the flesh is weak”的意思是“心有余而力不足”。但是，当时的某个机器翻译系统将这句英文翻译到俄语，然后再翻译回英语的时候，却变成了“The Vodka is strong but the meat is rotten”，意思是“伏特加酒是浓的，但肉却腐烂了”。从字面意义上看，“spirit”（烈性酒）与“Vodka”（伏特加）对译似无问题，而“flesh”和“meat”也都有肉的意思。那么，这两句话在意义上为什么会南辕北辙呢？关键问题就在于在翻译的过程中，机器翻译系统对于英语成语并无了解，仅仅是从字面上进行翻译，结果自然失之毫厘，差之千里。

从上面两个方面的主要困难，我们看到自然语言处理这个难题的根源就是人类语言的复杂性和语言描述的外部世界的复杂性。人类语言承担着人类表达情感、交流思想、传播知识等重要功能，因此，需要具备强大的灵活性和表达能力，而理解语言所需要的知识又是无止境的。那么，人们是如何尝试进行自然语言处理的呢？

3. 自然语言处理的发展趋势

目前，人们主要通过两种思路来进行自然语言处理：一种是基于规则的理性主义，另外一种是基于统计的经验主义。理性主义方法认为，人类语言主要是由语言规则来产生和描述的。因此，只要能够用适当的形式将人类语言规则表示出来，就能够理解人类语言，并实现语言之间的翻译等各种自然语言处理任务。而经验主义方法则认为，从语言数据中获取语言统计知识，有效建立语言的统计模型。因此，只要能够有足够多的用于统计的语言数据，就能够理解人类语言。然而，当面对现实世界充满模糊与不确定性时，这两种方法都面临着各自无法解决的问题。例如，人类语言虽然有一定的规则，但在真实使用中往往伴随大量的噪声和不规范性。理性主义方法的一大弱点就是鲁棒性差，只要与规则稍有偏离，便无法处理。而对于经验主义方法而言，又不能无限地获取语言数据进行统计学习，因此，也不能完美地理解人类语言。20 世纪 80 年代

以来的趋势就是基于语言规则的理性主义方法不断受到质疑,大规模语言数据处理成为目前和未来一段时期内自然语言处理的主要研究目标。统计学习方法越来越受到重视,自然语言处理中越来越多地使用机器自动学习的方法来获取语言知识。

迈进 21 世纪,我们已经进入了以互联网为主要标志的海量信息时代,这些海量信息大部分是以自然语言表示的。一方面,海量信息为计算机学习人类语言提供了更多素材;另一方面,也为自然语言处理提供了更加宽广的应用舞台。例如,作为自然语言处理的重要应用,搜索引擎逐渐成为人们获取信息的重要工具,涌现出以百度、Google 等为代表的搜索引擎巨头;机器翻译也从实验室走入寻常百姓家,Google、百度、有道、金山等公司均提供了基于海量网络数据的机器翻译和辅助翻译工具;基于自然语言处理的中文输入法(如搜狗、Microsoft、Google 等)成为计算机用户的必备工具;带有语音识别的计算机和手机也正大行其道,协助用户更有效地工作和学习。总之,随着互联网的普及和海量信息的涌现,自然语言处理正在人们的日常生活中起着越来越重要的作用。

然而,我们同时面临着一个严峻事实——如何有效利用海量信息,这已成为制约信息技术发展的一个全局性瓶颈问题。自然语言处理无可避免地成为信息科学技术中长期发展的一个新的战略制高点。同时,人们逐渐意识到,单纯依靠统计方法已经无法快速有效地从海量数据中学习语言知识,只有同时充分发挥基于规则的理性主义方法和基于统计的经验主义方法的各自优势,两者互相补充,才能够更好、更快地进行自然语言处理。

自然语言处理作为一个年龄尚不足一个世纪的新兴学科,正在突飞猛进的发展。自然语言处理的发展历程并不是一帆风顺,有过低谷,也有过高潮。现在,我们正面临着新的挑战 and 机遇。例如,目前网络搜索引擎基本上还停留在关键词匹配,缺乏深层次的自然语言处理和理解。语音识别、文字识别、问答系统、机器翻译等目前也只能达到很基本的水平。路漫漫其修远兮,自然语言处理作为一个高度交叉的新兴学科,不论是探究自然本质还是付诸实际应用,在将来必定会有令人期待的惊喜和异常快速的发展。

参 考 文 献

- [1] 张钊.自然语言处理的计算模型.中文信息学报,2007,21(3):3-7.

撰稿人:刘知远 马少平
清华大学计算机科学与技术系

计算机感知

Computer Perception

信息感知是人类和动物认识世界的主要源泉。如果没有感官，我们就会同外界隔绝，找不到食物，无法逃离危险。人类的感官包括“五感”，即眼(视觉)、耳(听觉)、鼻(嗅觉)、舌(味觉)、身(触觉)。人对外部世界的感知主要通过视觉、听觉、嗅觉、味觉、触觉这五感来实现。如果人不能看、听、感觉、尝或闻，就根本无法了解外面的世界。计算机感知综合采用计算机视觉、机器听觉、传感器、人工智能、多媒体、认知科学等分析文字、图像、声音、视频、触觉信息与其他传感信号，使得它们能为计算所见、所闻、所感^[1]，其最终目的是增强人类由于生理限制不可达，或在危险、恶劣等情境下的感知能力，扩展人类获取外部世界信息的通道。

1. 计算机视觉感知

视觉是人和大多数动物最为重要的感觉。视觉感知是根据进入眼睛的可见光解释信息与周围环境的能力，也称视力。包括虹膜、瞳孔、杆状细胞和锥状细胞、视网膜等在内的视觉系统与大脑相结合使人产生视觉感知的过程已成为生理学、认知科学、神经科学、分子生物学等的研究焦点。受视觉感知理论激发，计算机视觉(又称机器视觉、计算视觉)研究如何让计算机有效地感知、处理及理解来自相机或其他成像装置的图像、视频等信息，其中，计算机就像人的大脑，相机就像人的眼睛(调光的光圈就像瞳孔、玻璃镜就像晶状体一样能聚集光线，胶片就像视网膜一样遇光线会发生变化)。但值得指出的是，由于人类视觉感知的复杂性，其工作原理尚未能被人们完全认知，计算机视觉感知中的计算机虽然起着代替人脑的作用，但并无必要依人类视觉感知模式完成对视觉信息的处理。计算机视觉完全可以依据计算机系统的数字化特点来进行视觉信息的处理。

对于三维场景的计算机视觉感知的研究起源于20世纪60年代初期Roberts的先驱性工作^[2]，他比较系统地研究了从单视图中识别简单三维多面体物体的问题，他的系统能从三维场景的数字电视图像中提取出物体的线画图及其描述，随后，通过与已知物体的计算投影相比较识别出特定物体。Roberts提出的计算投影的过程亦被认为是三维计算机图形学的开创性工作之一。受当时条件的限制，Roberts的系统仅能处理有限遮挡的情形。20世纪70年代末，Marr提出的

视觉多层理论一举奠定了计算机视觉的理论基础^[3]。为了专注于视觉中特定问题的理解, Marr 的视觉多层理论在不同的抽象层分析了视觉过程, 确定了计算层、算法层和实现层三个不同的分析层次。其中, 计算层主要解决视觉系统必须克服的问题; 算法层尝试确定可用于解决这些问题的策略; 而实现层则主要尝试解释这些问题是如何依照实际的神经活动被解决的。Marr 将视觉描述为从虹膜上的二维可视阵列向作为输出的物理世界的三维描述的渐进过程, 即: ①场景的二维草图。该草图基于场景中包括边、区域等在内的基本组件进行特征提取建立。②场景的二维半草图。其中, 纹理被确认。③三维模型。其中, 场景被可视化为一个连续、三维的图。进入 20 世纪 80 年代中后期, 计算机视觉研究中引入了距离传感器, 主动视觉的研究方法受到重视, 其中, 可直接或通过移动间接获得场景的深度图。自 20 世纪 90 年代起, 以 SIFT (scale invariant feature transform) 特征为典型代表的场景底层描述得到了较为充分的研究, 进入 21 世纪, 如何从真实场景视频数据中恢复出三维几何和运动信息并进行重用受到高度关注, 包括摄像机参数、深度和光流等信息的高精度恢复及场景的结构估计等问题的部分解决, 为计算机视觉与计算机图形学、增强现实技术相结合奠定了基础。

目前, 计算机视觉感知技术已逐渐成熟, 在航空照片解释、机器人导航、汽车自动驾驶、智能人机交互等领域得到了广泛应用, 它的典型任务包括物体检测与识别、运动分析、场景重建、图像复原等。计算机视觉系统的主要功能一般有图像获取、预处理、特征提取、检测与分割, 以及其他高层处理方法(如估计物体姿态参数、将检测到的物体进行分类等)。计算机视觉研究的挑战是让计算机效仿甚至超过人眼和人脑的视觉感知能力, 从而最终扩展人类获取外部世界信息的能力。

2. 计算机听觉感知

听觉是人的另一重要感觉。当某种东西快速地来回运动, 它周围的空气也会跟着振动, 产生声波, 声波穿过空中, 进入人的耳朵, 触发人的听觉系统开始工作, 经过大脑处理, 从而听到声音。空间听觉感知研究主要包括物理、感知和神经三个领域。一个声源的声学组成包括编码于其内容的表征声源位置的关键空间信息及它所占据的空间。人的感知机制捕获声学信息并抽取与声源及环境相关的重要线索。当信号到达神经处理阶段时, 声源信息与方向信息被组合在一起。听觉神经系统提取方向信息并建立关于声音起源的位置和空间的表示^[4]。传统意义上的声学仿真是指对声音产生与传播的物理过程用计算机进行模拟或辅助处理, 如环境噪声分析等; 而计算机听觉感知主要指的是借助于计算方法研究基于听觉的场景分析问题。

一般而言, 声信号的表示模型大致分成物理建模、信号建模、感知建模三大类。与物理建模依据特定声源的发声机理、信号建模依据声信号的频率组织或时域波形不同, 感知建模基于人类听觉感知模型进行相应声信号的建模, 其中, 计算听觉场景分析(computational auditory scene analysis, CASA)中的耳蜗图及其自相关表示即是其典型代表^[5]。从本质上说, 计算机听觉感知系统即传统意义上的“机器听觉(machine listening)”系统, 其主要目的是像人一样区分混合的声源。从某种意义上说, 它以人类听觉系统的机理为基础, 因此, 不会采用多于两个麦克风捕获听觉环境, 并且由于认识到人的双耳滤波效应在声音的空间定位过程中扮演着极为重要的角色, 往往采用与头相关的传递函数(HRTF)作为声音从自由场传播至耳鼓处的变换函数。计算机听觉感知在噪声环境下鲁棒地自动语音识别、音乐唱片自动转录、助听器设计等方面有着重要应用。

3. 计算机触觉感知

触觉是最为复杂的感觉之一。人的皮肤作为一个感觉器官, 其上的感受细胞发送“触摸”的神经信号到大脑触觉区。触觉丧失会导致诸如抓持物体、使用工具, 甚至是行走等能力丧失, 因而是灾难性的。触觉感知指的是通过接触识别物体的过程, 它包含肌肉运动知觉、肤感、痛感、温感等体觉感知(somatosensory perception)及人手位置和构型的本体感受(proprioception)。与计算机视觉感知和听觉感知不同, 计算机触觉感知是用户和系统间能量与信息双向交流的过程, 因此, 必须借助于特定的接触式装置实现, 诸如 CyberGrasp 等外骨架结构[如图1(a)所示]可将接触、抓持三维虚拟物体的力准确地传递到用户手指^[6]; 而 Salisbury 等研发的 PHANTOM 个人触觉设备[如图1(b)所示]则开启了全新的计算机触觉学(computer haptics)研究^[7]。



(a) CyberGrasp 力反馈数据手套



(b) PHANTOM Premium 1.5/6DOF 触觉设备

图1 力反馈装置

计算机触觉学研究生成和再现合成的触觉刺激相关的技术及过程^[8]。现实物理世界中, 触觉感知依赖于触摸过程中所体验到的力。人能够通过接触快速准确地判别出三维物体, 这主要是由于人所采用的是探索过程。例如, 在物体外表面上移动手指, 或将整个物体握在手中^[9]。与现实世界中人通过接触物体获得触觉反馈的过程类似(如图 2 所示), 在与虚拟物体的触觉交互过程中, 诸如 PHANTOM 等桌面式机电装置与计算机的输入输出端口直接相连, 用户通过手抓笔杆或将手指插入顶针操纵触觉装置, 触觉装置中内置的传感器自动跟踪用户手部的位置与运动, 将手部运动信息传递给计算机, 通过采用适当的触觉计算模型实时计算生成反馈力数据, 并经由传动制动装置将计算所得到的反馈力传递给用户。由于具备高达 1000 至数千赫兹的刷新率, 触觉设备允许用户与虚拟物体进行触觉交互, 其所施加的外力会让用户产生与真实物体交互的幻觉。




图 2 触觉交互过程

实时计算生成反馈力并准确地传递给用户是计算机触觉学的核心研究内容, 这一过程又称触觉绘制(haptic rendering)。通常, 采用一个虚拟物体作为触觉界面的化身, 用户通过操纵触觉设备控制化身在虚拟环境中的运动, 与其他虚拟物体进行触觉交互。显然, 化身的几何表示在很大程度上取决于具体的应用及所采用的触觉设备^[10]。如图 3 所示, 一个典型的触觉绘制算法主要包括三个部分: 碰撞检测算法检测化身与虚拟物体间的碰撞, 提供关于处于位置 X 的化身与虚拟物体间出现的接触 S 的信息; 当碰撞发生时, 力响应算法计算化身与虚拟物体间的相互作用力 F_d ; 而控制算法则将按照设备最佳性能计算的理想的反馈力 F_r 反馈给用户。

近年来, 计算机触觉感知已取得较大进展, 并已在航空航天、医疗仿真、纳米材料研制、装配仿真等领域初步得到应用, 但仍存在不少迫切需要解决的难题, 如反馈力计算过程中所必需的模型间的高达 1000 Hz 的实时碰撞检测帧率




图3 触觉绘制系统结构

与日益复杂的三维模型之间的矛盾、保持可感知接触细节的模型简化方法、保持用户感觉的触觉生成方法等^[11]。

4. 计算机嗅觉感知与味觉感知

人的嗅觉是由位于鼻腔上方的嗅觉细胞产生的。许多脊椎动物，包括大多数哺乳动物和爬行动物，有两种截然不同的嗅觉系统——主嗅觉系统和副嗅觉系统。其中，主嗅觉系统检测挥发性化学品，而副嗅觉系统则检测流体相化学品，主要是弗洛蒙(pheromones)^[12]。一个人的鼻子里有500万个嗅觉细胞，但与其他动物(如狗的2亿个嗅觉细胞)相比，嗅觉极不灵敏。味觉是一种直接化学感受的形式，它指的是检测诸如食品、某些矿物质和毒素等物质味道的能力。在“五感”中，人们对味觉了解最少。人的大多数味蕾都在舌头上。在人和许多脊椎动物中，味觉与嗅觉一起在大脑的协同下形成对味道的感知。当人嚼食物时，食物分子进入嘴里的空气，并随空气进入人的咽喉部和鼻子。西方传统上认为只有4种基本味道：甜、咸、酸和苦。在东方国家，辣和鲜也被认为是基本味道。人能分辨出1万多种不同的味道，这些味道是由基本味混合而成，并掺杂了许多食物的气味。

计算机嗅觉感知，又称人工嗅觉，指的是利用传感装置等模拟人的嗅觉来检测、识别复杂气味成分，其研究涉及新型敏感材料、传感器、信号处理、计算机、模式识别等。自1964年Wilkens等基于气味分子在电极上发生氧化还原反应原理建立了第一个人工嗅觉系统(也称电子鼻)后^[13]，有关人工嗅觉的研究得到了快速发展。如图4所示，人工嗅觉系统主要包括三个部分，即传感器阵列、信号处理模块及神经网络模块。气味分子被传感器阵列吸附，产生信号，经信号处理模块的处理电路加工处理，完成信号转换与传输，进入神经网络模块进行识别，做出判断^[14]。与计算机嗅觉感知类似，计算机味觉感知又称人工味觉，而人工味觉系统也称电子舌。如图5所示，人与电子舌的味道识别机制包




图 4 计算机嗅觉感知系统

括三个相同的层次：接收层(人：味蕾；电子舌：脂质膜传感器)、电路层(人：神经传输；电子舌：传感器)、感知层(人：丘脑中的认知；电子舌：软件中的统计分析)^[15]。




图 5 电子舌概念

计算机嗅觉感知和味觉感知对于食品工业、医疗、安全、环境污染监测、化工、空气质量控制、味道和气味的数字“指纹”等有着重要意义。借助于计算机嗅觉感知和味觉感知，人们将可以轻松地胜任化学危险品的检测等高危任务。

5. 超感官知觉

超感官知觉(extra sensory perception, ESP)即人们俗称的“第六感”,是一种某些人认为存在的能力,此能力能透过正常感官之外的管道接收信息,主要包括心电感应、灵感、遥视、预知、心灵致动等超心理现象。西方心理学认为,意识通过五感等正常感官接收外界刺激,经过整理分析,最终达到认知。而潜意识则接收到更多由意识层面所遗漏的、非透过语言或逻辑推理而得到的东西。这些信息经年累月地储存在人的大脑里,且不为人所察觉。当它们浮现到意识层面、成为一种可辨认的感觉时,即形成所谓的“直觉”或“第六感”^[16]。

计算机感知技术日新月异的发展使普通人获得“第六感”超能力成为可能。2009年2月,美国麻省理工学院媒体实验室的博士生 Mistry 在 TED 论坛上演示了一个能有效支持真实世界与数据世界之间新型交互的系统——“第六感”^[17]。作为一个可穿戴的手势交互界面,“第六感”的硬件部分由一个微型投影机、一面镜子、一个摄像头及一个放置于用户口袋中的移动计算装置构成。投影机向周围的物理物体的表面投射视觉信息,使其成为交互界面;而摄像机用于识别物理物体、跟踪用户手势;软件部分主要处理摄像机捕获的视频流,采用计算机视觉技术跟踪用户指尖佩戴的视觉跟踪彩色标记(准标, fiducial)。这些准标的运动与配置被解释为不同的手势,用作交互指令。“第六感”使得信息脱离了传统的纸张和屏幕的束缚,可与现实世界无缝集成,从而变得触手可及(如图6所示)^[18]。



图6 “第六感”基本配置及应用

“第六感”这类系统正是计算机视觉感知与人机交互技术的典型应用。随着新技术的不断涌现,计算机多感觉通道感知技术的快速发展,1969年,英国摇滚乐队“谁人(Tho Who)”曾深情吟唱的“See me, touch me, feel me, ...”正日益成为现实。在不久的将来,人们有望能借助计算机多感觉通道感知的支持,

扩展自身获取外部世界信息的通道,以前所未有的多感官通道与计算机进行自然的、全方位的信息交流,增强人类由于生理限制不可达,或在危险、恶劣等情境下的感知能力与处理问题的能力。

参 考 文 献

- [1] [http://www.peterindia.net/Computer Perception.html](http://www.peterindia.net/Computer%20Perception.html).
- [2] Roberts L G. Machine perception of three-dimensional solids//Tippett J T, et al. Optical and Electro-Optical Information Processing. Cambridge: MIT Press, 1963: 159—197.
- [3] Marr D. Vision: A Computational Investigation into the Human Representation and Processing of Visual Information. Cambridge: MIT Press, 1982.
- [4] [http://www.ausim3d.com/about/Au Web_perception.html](http://www.ausim3d.com/about/Au%20Web_perception.html).
- [5] Wang D L, Brown G J. Computational Auditory Scene Analysis: Principles, Algorithms and Applications. New York: Wiley, 2006.
- [6] [http://www.cyberglove systems.com/products/cybergasp/overview](http://www.cyberglove%20systems.com/products/cybergasp/overview).
- [7] <http://www.sensable.com/products-haptic-devices.html>.
- [8] Srinivasan M A, Basdogan C. Haptics in virtual environments: Taxonomy, research status, and challenges. Computers and Graphics, 1997, 21(4): 393—404.
- [9] http://en.wikipedia.org/wiki/Haptic_perception.
- [10] Salisbury K, Conti F, Barbagli F. Haptic endering: Introductory concepts. IEEE Computer Graphics and Applications, 2004: 24—32.
- [11] Lin M C, Otaduy M A. Haptic Rendering: Foundations, Algorithms, and Applications. Wellesley: A K Peters, 2008.
- [12] <http://en.wikipedia.org/wiki/0/faction>.
- [13] 颜黄苹, 黄元庆. 人工嗅觉系统及其在临床诊断中的应用. 传感器世界, 2006, 12(9).
- [14] 王平. 人工嗅觉与人工味觉. 第2版. 北京: 科学出版社, 2007.
- [15] <http://www.pharmainfo.net/reviews/electronic-tonguea-review>.
- [16] [http://baike.baidu.com/view/1571.htm? fr=ala0_1_1](http://baike.baidu.com/view/1571.htm?fr=ala0_1_1).
- [17] http://www.ted.com/talks/pattie_maes_demos_the_sixth_sense.html.
- [18] Mistry P, Maes P. SixthSense-A wearable gestural interface//Proceedings of SIGGRAPH Asia 2009, Emerging Technologies, Yokohama, 2009.

撰稿人: 万华根

浙江大学 CAD&CG 国家重点实验室

如何让计算机实现人工世界？

How to Realize an Artificial Computer World?

让计算机实现人工世界，一直是人类追求的一个目标。虚拟现实(virtual reality, VR)就是利用计算机图形学、人机交互、计算机视觉、认知心理学、传感器、网络通信等多方面计算机技术来实现人工世界。

我们看一下虚拟故宫实例：只要戴上特制的头盔，骑上不动的自行车，从头盔显示器里就能看见形象逼真的天安门城楼。登上自行车的脚踏板，就会感到自己骑车来到了午门前的大道上，飞快地穿过午门，越过金水桥、太和门，来到太和殿广场，最后进入御花园，就好像身临其境地游完了故宫。但是，当摘下头盔时，仍然是骑在自行车上，一步也没有动。

虚拟现实要达到的目标是：利用各种计算机技术生成一定范围感觉是真实的人工世界、一个在视、听、触感等方面高度近似的数字化环境，用户借助特殊设备利用人们的自然通道与数字化环境中的对象进行自然交互，相互影响，从而产生亲临相应真实环境(假象环境)的感受和体验^[1]。例如，人们可以在虚拟战场环境中进行军事训练和演练，在虚拟人体上进行手术训练和手术规划，可乘虚拟光速航天器在虚拟太空漫游，体验相对论世界，也可以体验假想的西游记和阿凡达世界。

1929年，Link发明了一种飞行模拟器“蓝盒子”(因模拟器座舱漆成蓝色而得名)，使乘坐者实现了对飞行的一种感觉体验。可以说，这是人类采用现代技术模拟仿真物理现实的初次尝试。其后，随着控制技术的不断发展，各种仿真模拟器陆续问世。计算技术的发展和计算机的小型化推动了计算机仿真技术的发展，形成了计算机仿真科学技术学科。1965年，计算机图形学的重要奠基人Sutherland发表了一篇短文，以其敏锐的洞察力和丰富的想象力描绘了一种新的显示技术^[2]。他设想在这种显示技术支持下，观察者可以直接沉浸在计算机控制的虚拟环境之中，就如同日常生活在真实世界一样。观察者还能以自然的方式与虚拟环境中的对象进行交互，如触摸感知和控制虚拟对象等。Sutherland的文章从计算机显示和人机交互的角度提出了模拟现实的思想，推动了计算机图形图像技术的发展，并启发了头盔显示器、数据手套等新型人机交互设备的研究。1966年，美国麻省理工学院林肯实验室研制出了第一个头盔式显示器，随后又将模拟力和触觉的反馈装置加入到系统中。总体上说，20世纪60~70年代是虚拟现实思想、概念和技术的酝酿形成阶段。进入80年代，随着计算机技术，特别是个人计算机和计算机网络的发展，虚拟现实技术发展加快，这

一时期出现了几个典型的虚拟现实系统,推动了虚拟现实技术的发展。1987年, *Scientific American* 发表了报道数据手套的文章,引起了人们的关注^[3]。1989年, Lanier 提出了虚拟现实一词,很快被研究人员普遍接受,成为这一科学技术领域的专用名称。90年代以后,由于军事演练、航空航天、复杂设备研制等重要应用领域的巨大需求,虚拟现实技术进入了快速发展时期。1990年,在美国 Dallas 召开的 SIGGRAPH 会议上对虚拟现实技术进行了讨论,认为虚拟现实技术的主要研究内容是实时三维图形生成技术、多传感器交互技术和高分辨率显示技术等。这一时期用于虚拟现实系统开发的软件平台和建模语言开始在市场出现。1994年,在日内瓦召开的第一届 WWW 大会上,首次提出了 VRML,开始了相关国际标准的制定。同年, Burdea 和 Coiffet 出版了 *Virtual Reality Technology* 一书,用 3I (immersion、interaction、imagination), 即沉浸、交互和想象概括了虚拟现实的基本特征^[4]。

虚拟现实是新兴的、学科高度交叉的科学技术领域,具有大量的科学技术问题,这些问题集中在虚拟环境构造和应用过程的4个方面,即表达、感知、控制和作用,成为虚拟现实的三大科学技术问题。

第一类问题是现实世界在数字空间的表达问题,也就是虚拟现实的建模。在数字空间模拟现实世界中的对象和状态,需要通过数学、物理,以及各种数字化方法将现实世界中的对象、对象之间的关系、对象之间相互作用及动态变化所遵循的规律映射为数字空间中的各种动静态数据表示,这一过程称为建模或模型化^[5]。虚拟现实的模型是现实世界事物在数字化环境中的体现。那么,现实世界的所有事物都是可以数字化建模的吗?这个问题与我们对现实世界事物的认识程度有关,与模型的复杂性和可计算性有关,也与我们对模型逼近现实的期望程度有关。例如,我们现在对刚性物体在中观尺度上的运动可以进行精确模拟;对流体运动的建模就很困难,所建立的各种流体模型与实际流体的差距也较大;而人的思维能否建模目前还属未知。是否可以建立一套类似于可计算理论的可建模理论,以及可建模性与可计算性之间存在什么关系,这是一个值得研究的问题。与之相关的一个问题是可否对客观事物及其模型的复杂性进行度量和评价,就像计算复杂性和软件复杂性那样?

大量的事物因素复杂,难以建模,但将因素简化就可以建立较低精确度的模型。例如,海浪是难以精确建模的,但简化的概念性海浪模型是容易建立的;完全符合现实的气象模型是难以建立的,但简化的气象模型总是可以建立的。对于物体的几何模型,目前一般用网格的多少或网格稠密程度作为其复杂性的度量。对于物理模型和行为模型,有一些以计算复杂度进行衡量,但这显然是远远不够的。模型的复杂性度量方法是应该研究的问题。将事物简化以后得到的模型在多大程度上可信,在什么范围可用?进行模型可信性的度量和评价是直接影响模型应用的重要问题。对模型可信性进行评价,必然会涉及模型之间

的相似性(或差异性)度量问题,模型的可信度问题实际就是模型与相应真实对象之间的相似性问题。比较两个模型(如两张图像)的相似性程度,或者评价一个模型(图像)的失真程度对人来说并不太难,但对计算机来说是一个至今没有很好解决的问题。是否可以建立有用的相似性理论,以及如何针对不同的模型类建立相似性测度和相似性度量方法^[6]。

综上所述,可建模性、模型复杂性、模型相似性和模型可信性的评价、度量是虚拟现实建模中需要研究的几个基本理论问题。

除上述基本理论问题以外,大量要解决的是具体的建模方法与技术,这首先涉及模型数据。从来源说,模型数据大体有复制现实、数学生成和人工构造三大类。复制现实指通过二维或三维扫描仪、摄像机、运动捕获设备、录音机及各类专业数据采集设备(如CT、B超、核磁共振、卫星遥感等)或人工测量所获得的数据;数学生成指通过实验分析、物理仿真、归纳抽象等形成数学模型,如物理公式、模拟算法、公理系统等,数学模型的计算可以生成模型数据,如根据物体运动方程获得物体的位置数据;人工构造指人工或人工借助建模软件,通过想象和设计生成模型数据(如物体的三维模型、动漫、影视制作等)。实际建模过程中,常根据被模拟的现实世界对象的复杂性及模型逼真期望程度,采用多种方式相结合形成模型数据。同时,也需要研制更合适,甚至智能化的复制设备,开发更完善、自动化程度更高的建模工具。具体的虚拟现实建模方法与所要模拟的对象类有关,也与应用领域密切相关。针对所要模拟对象的不同方面,可将建模方法分为空间结构建模、基于物理的建模、行为建模和虚实融合建模等。

空间结构建模主要包括基于点云数据、网格、体素和材质光照信息的建模方法,无论是理论、方法研究,还是建模工具开发,由于其起步时间较早,因此研究较多。

物理建模在于体现对象的物理特性,使得虚拟环境中的动、静态景物更加逼真。目前,主要集中在虚拟实体的运动学和动力学特性方面。如果要进一步提高逼真度,就必须考虑虚拟实体的材料、摩擦力、弹塑性和黏稠性等物理特性。物理特性的计算模型、高效算法及有效的表现方式和方法是需要研究解决的三大问题。由于人类认识世界的无限性,因此,可以说物理特性建模是虚拟现实领域中的一个永恒的方向^[7]。

近年来,虚拟现实应用对自治对象行为的智能水平提出了越来越高的需求,行为建模成为虚拟现实研究中一个重要方面。这一领域总体上属于人工智能的研究范畴,其难度相当大,进展也较缓慢。但是,由于目前自治对象行为建模引入和借鉴人工智能研究成果的程度还比较低,因此,如果能将人工智能已有的研究成果创造性地应用于行为建模,无疑会有效提高虚拟现实自治对象行为的智能水平。

传统的虚拟环境强调虚拟场景建模和虚拟场景的表现,需要大量的建模与绘制工作,随着虚拟现实应用领域的不断扩展,人们发现一些应用完全可以依托真实环境,只将少量的真实环境中没有或需要灵活变更的景物,通过虚拟现实建模构造造成相应的虚拟景物,将其融入真实场景,既可以有效提高虚拟环境的建模效率,又可以扩展人机交互的空间和虚拟现实的应用领域。这就是目前增强现实所研究的内容,其主要问题有虚实对象三维注册、遮挡处理、虚实光照融合处理等。一个基本的理论问题是基于图像和基于图形的模型是否可以做到无缝融合,以及无缝融合的主要标志、评价指标是什么?

第二类问题是人和外部环境对虚拟环境对象的感知,也就是虚拟现实的逼真表现问题,包括视觉、听觉、触/力觉、嗅/味觉等的表现。虚拟现实表现技术是虚拟现实的重要研究内容,它将数字空间内的各种虚拟景物模型通过不同的表现方法、算法渲染在表现设备上,以沉浸方式呈现给用户。表现方法与对象模型和表现设备直接相关,而且表现设备,如透视式头盔、全息真三维显示等都在不断发展,因此,这也是一个无穷尽的问题领域。

真实感图形图像实时绘制是实现虚拟现实视觉感知的最重要手段,但真实感与实时性是一对矛盾性指标,具有一定的对偶性。例如,物体几何模型的网格数量越大,与实际物体形状的差异越小,绘制所需的时间就越长,这类似于算法复杂性中时间和空间复杂度的对偶性。若能从理论上对这种对偶关系给予证明,并找到其决定因素,就可以在应用中根据实际需求对两者进行权衡。

听觉是人类仅次于视觉的第二大感知来源。听觉表现不仅可以为视觉画面伴音,还可以补充视野之外的信息,增强虚拟环境的空间感和真实感。因此,如临其境的听觉表现技术是虚拟现实研究的重要内容。

视觉与听觉提供给人的都是非接触性感知信息。提供虚拟对象的接触性感知信息能够更直接地增强用户的真实感、沉浸感,扩大虚拟现实的应用领域。力/触觉表现就是要使用户与虚拟对象进行接触性交互时能够获得逼真的力/触觉感受。力/触觉表现需要借助力/触觉设备,并进行高效的力/触觉信息处理,主要是碰撞检测和碰撞响应。由于人的触觉灵敏,所以,力/触觉绘制至少需要 1000 Hz 的刷新频率才能给人以真实感。因此,高刷新率和快速计算成为力/触觉表现研究的一个重要方面^[8,9]。

嗅觉是人体的重要感知,如何让虚拟环境中的人感受到各种气味是虚拟现实领域研究的一个内容。嗅觉是由化学刺激产生的,这和视、听、触觉有很大不同,Kaye 指出嗅觉表现必须依靠气味间的差异,这是一个难度很大的领域,目前,许多研究只集中于气味的传播。味觉与化学物质、触觉和声音等多方面的因素有关,因此,对其进行表现的难度更大,Iwata 将其称为虚拟现实的最后战线^[10]。

第三类问题是对虚拟环境对象的控制和操作,这是虚拟现实人机交互特

性的直接体现, 主要涉及人或外部世界与虚拟环境之间互相作用的信息交换方式与人机交互设备。虚拟现实的人机交互强调人与虚拟环境之间的感知传递, 相对而言, 虚拟现实的人机交互要求更高的自然性和真实感。真三维显示、六自由度魔标、真实感触/力觉感知、三维空间方位跟踪、交互行为信息交换, 以及新概念虚拟现实人机交互机制和大量的面向领域应用的专用人机交互机制和人机交互设备问题是虚拟现实中人机交互的重要研究内容。

虚拟现实是一种人和计算机的自然界面, 能实现人机和谐的环境; 虚拟现实是一种生成人工世界的工具, 帮助人们探索自然界和社会界的奥秘。虚拟现实是一个充满活力和挑战的科学技术领域, 存在大量有待解决的问题和难题, 而且还在不断产生新的理论和关键技术问题, 这些问题的突破会导致虚拟现实技术与应用的巨大发展。

参 考 文 献

- [1] Zhao Q P. A survey on virtual reality. Science in China Series F: Information Sciences, 2009, 52(3): 348—400.
- [2] Sutherland I E. The ultimate display. Proceedings of the International Federation of Information Processing, 1965: 506—508.
- [3] Foley J D. Interfaces for advanced computing. Scientific American, 1987.
- [4] Burdea G, Coiffet P. Virtual Reality Technology. New York: Wiley, 1994.
- [5] Roush W. Second earth. Technology Review, 2007, 110(4): 38—48.
- [6] Hong J W. On similarity and duality of computation. 21st Ann. IEEE Sympo. Found. Comput. Sci., 1980: 348—359.
- [7] Michael H. Metaphysics of Virtual Reality. Oxford: Oxford University Press, 1993.
- [8] Klein D, et al. Modelling the response of a tactile array using electro-rheological fluids. Journal of Physics D: Applied Physics, 2004, 37: 794—803.
- [9] Otaduy M A, Lin M C. Introduction to haptic rendering. International Conference on Computer Graphics and Interactive Techniques, 2005: 3—33.
- [10] Iwata H, et al. Food simulator: A haptic interface for biting. Proceedings of the 2004 Virtual Reality, 2004: 51—57.

撰稿人: 赵沁平

北京航空航天大学虚拟现实技术与系统国家重点实验室

网络科学的基本问题

Fundamental Problems of Network Science

1. 概念及内涵

网络是由节点集合 $V=\{v_1, v_2, \dots, v_V\}$ 和边集合 $E=\{e_1, e_2, \dots, e_E\}$ 所组成的集合。网络节点的一个基本属性是度，它表征该节点和其他节点之间的连线(边)数量。图 1 给出了一个包含 6 个节点和 7 条边的网络拓扑结构图，各个节点的度分别为 3、2、3、2、1、3。




图 1 网络的拓扑结构

网络科学是一门涉及多个学科和领域的交叉科学，它研究物理、信息、生物、认知和社会网络中的相互连接关系，致力于发现主导网络行为的普适性规律、算法和工具，并对其进行控制^[1]。

理论物理学家 Hawking 曾预言：“21 世纪将是复杂的世纪。”从人类社会网到生物网，从计算机互联网到通信网，都呈现出复杂的拓扑结构和动态演化特性。以万维网为例，若每一个页面对应一个节点，每两个页面之间存在链接，则对应一条边，可以据此画出万维网的拓扑图，如图 2 所示，它是一个非常复杂的网络。

2. 网络科学的发展历程及代表性成果

网络科学的发展经过了规则网络理论、随机网络理论和复杂网络理论三个阶段。图 3 给出了这三种网络理论中的典型网络拓扑示意图。

1) 规则网络理论

规则网络理论的发展与图论和拓扑学的发展密切相关，创始人是瑞士大数学家 Euler，代表性人物还有英国数学家 Hamilton。规则网络理论的特点是用有




图 2 万维网的拓扑图(部分)




图 3 网络科学中的三种网络拓扑

规则的网络结构来表示真实系统各因素之间的关系，主要研究包含较少节点(通常不超过数百个)、拓扑结构较简单且不会改变、可精确求解的网络。

规则网络理论中最著名的问题是哥尼斯堡七桥问题。哥尼斯堡是东普鲁士的首都(现为俄罗斯的加里宁格勒市)，普莱格尔河横贯其中。18 世纪在这条河上建有七座桥，将河中间的两个岛和河岸连接起来，如图 4(a)所示。有人提出，能不能每座桥都经过一遍且只经过一遍，最后又回到原来的位置。这个看起来很简单却很有趣的问题吸引了大家，很多人身体力行地尝试了各种各样的走法，然而都没有成功。Euler 在 1736 年创造性地解决了这个问题，他将七桥问题抽

象化为一个图论问题，即把每一块陆地用一个点来代替，将每一座桥用连接相应的两个点的一条线来代替，从而相当于得到一个图，也就是一个网络，如图 4(b) 所示。Euler 得出结论，不可能每座桥都走一遍，最后回到原来的位置，即不可能在图中找到一条经过每条边一次且仅一次的回路，因为图中 4 个节点的度都是奇数，而问题具有肯定回答的必要条件是图中度为奇数的节点数要么是 0 要么是 2。




图 4 七桥问题及其对应网络图

2) 随机网络理论

随机网络理论最早是由匈牙利数学家 Erdős 和 Rényi 于 1959 年提出，他们在构造随机网络时采用给一个概率 p 来决定两个节点之间是否连边。该理论认为网络的连接虽然是随机的，但由此形成的网络却是高度民主的，即大部分节点连线数目大致相同，节点连线数的分布服从泊松分布。

随机网络理论中最重要的一个成果是：网络的许多重要性质都是随着网络规模的增大而突然涌现的。也就是说，对于任意给定的概率 p ，要么几乎每一个网络都具有某个性质，要么几乎每一个网络都不具备该性质。

3) 复杂网络理论

对于复杂网络和复杂系统的研究很早就开始了，Bertalanffy 和 Prigogine 等都做出了很好的工作，美国的圣塔菲研究院更是研究复杂系统的中枢^[2]。但是，引发复杂网络研究高潮直到今天的主要原因还是两项开创性工作：美国人 Watts 于 1998 年在 *Nature* 上提出的小世界网络模型^[3]和 Barabási 于 1999 年在 *Science* 上提出的无尺度网络模型^[4]。

小世界网络模型是经典的人际关系网中的“六度分离理论”的推广。“六度分离理论”来自对社会调查的推断，指在大多数人中，任意两个素不相识的人通过朋友的朋友，平均最多通过 6 个人就能够彼此认识。2003 年，Watts 领导的研究小组利用互联网在全世界范围内检验了“六度分离”假说，有 6 万多志愿者利用电子邮件参与了实验，确实不到 6 步就实现了他们的假设，从而利用互联网初步验证了小世界现象。我们在日常生活中常有这种体验，当参加一个聚会与遇到的新朋友聊天时，很快就发现：原来他认识我的某一个朋友，而我

也认识他的某一个朋友，于是大家不约而同地感叹：“这个世界真小啊！”我国唐代诗人王维的名句“海内存知己，天涯若比邻”也是这种思想的体现。后来的研究表明，除了人际关系网，科研合作网、电影演员合作网、长途电话网、引文网等都具有小世界的特性。

无尺度网络模型的基本原理是“增长”和“择优连接”，节点度的分布服从幂率分布，它反映了网络中度分布的不均匀性，只有很少数的节点与其他节点有很多的连接，成为“中心节点”，而大多数节点度很小，从而形成了网络节点度分布的马太效应：“富者越富，穷者越穷。”这个无标度特性其实是一把“双刃剑”，一方面可使网络对意外故障具有惊人的抗攻击能力；另一面对协同式攻击则很脆弱，一旦击中少数“中心节点”，就会导致整个网络崩溃。根据这个原理，我们在设计和构建一个网络时，为了避免网络因遭受攻击或意外事故导致崩溃发生，最有效的办法就是保护好网络中节点度最大和次大的少数“中心节点”。

目前，新的网络科学理论已经在艾滋病病毒传播机理、恐怖分子追捕、金融危机预防等方面得到了初步的应用^[5]，但毕竟网络科学的发展还不成熟，缺乏完整严密的理论体系，尤其是网络科学的基础数学理论——图论在处理实际网络时还不够灵活。因为图论处理的是静态网络，而实际的网络通常是动态变化的。以恐怖组织网络为例，当一个恐怖分子被抓住或被击毙时，他的位置可能会被他的某一个堂兄弟取代，而这个堂兄弟会带来与原来不同的社会联系，从而使得网络的拓扑结构发生根本性变化，目前的图论并不能处理这样的情况。于是，网络模型的规模越大，里面的噪声会越多，能从里面获取的信息就越少，分析也就会越困难。

3. 网络科学中的科学问题及其难点

除了基本的数学分析工具还需要不断完善以外，网络科学中的科学问题和研究热点主要集中在三个方面：网络测量、网络演绎和网络模拟。

在研究网络科学有关具体问题的过程中，一个前提条件是要确定“什么样的对象才能称之为节点，什么样的关系才能称之为边”。节点集的不同确定方式会从本质上影响到所形成网络的规模和密度，最终影响到随后的分析。同时，节点之间的连接通常不能简单地用“有”或“无”来表示，虽然这会使理论分析得到简化，但实际上许多形式的相互作用是间歇发生的，并且还是在不同条件下发生的。在分析的过程中，我们需要先确认所研究的相互作用是否足够稳定，或者在感兴趣的时间范围内是否可以看成是不变的常数。

1) 网络测量

19 世纪，英国著名的物理学家 Kelvin 曾说过：“当我们可以测量并且用数

字表达我们谈论的东西的时候，才算得上对此有所了解，如果我们不能测量或者是不能用数字表达所谈论的东西时，那么，我们对此的了解就是贫乏不足的。”我们要研究网络，理解和认识网络，就必须能够能够对网络进行测量，对网络的态势进行感知，获得网络行为的第一手数据。网络测量的核心是如何在网络中布设传感器、如何利用传感器获取网络状态并感知网络行为、如何从海量数据中挖掘出有价值的信息。计算机互联网中的流量统计、丢包率统计、新闻传播网中的社会舆情调查、手机短信传播网中的谣言监控都属于网络测量的重点研究内容。

网络测量通常包含三个要素：测量对象、测量环境和测量方法。测量方法应该满足三个方面的要求：一是稳健性，即被测网络的轻微变化不会使得测量方法失效；二是可重复性，即同样的网络条件下，多次测量结果应保持一致；三是准确性，即测量结果要能反映网络的真实情况。

由于复杂网络中的节点规模过于庞大，目前，对于网络测量的研究主要侧重于非实时测量，实时测量对于数据的传输能力和计算机的处理能力提出了很高的要求，一个可能的解决手段是进行分布式处理。

2) 网络演绎

网络演绎，即对复杂网络的动力学特性进行分析，包括对网络的拓扑结构、演化、涌现、突变等现象进行定量分析，以得到蕴藏在网络背后的基本规律。前面提到的无尺度网络中的幂率分布理论就是网络演绎的重要成果。对于网络动力学特性的研究，不仅需要大量的测量数据和深厚的数学知识，还涉及物理学、社会学、心理学、博弈论等学科，难度很大。

目前，在网络动力学方面的一个重要成果是利用最小作用量原理来分析网络的形成机理。几何光学告诉我们：空间两点之间光的实际路程总是光程（折射率与路程的乘积）取极值所对应的路程。换句话说，大自然总是让光走最容易走的捷径。光程就是几何光学中的作用量。对于一个网络来说，它的作用量是什么？这个作用量是不是普适的？这些问题都有待于进一步的研究来做出回答。

3) 网络模拟

网络模拟，即对复杂网络的演化进行计算机模拟，包括网络的特性建模、网络演化的动态模拟和行为预测。如果说网络测量是从微观的角度来认识网络，网络演绎是从宏观的角度来理解网络，那么，网络模拟则是从微观和宏观两个方面来帮助我们研究网络。对于人类来说，每一个人的性格特点和处事方式都是互不相同的，但从整个社会的角度来看，99%以上的人都是类似的，只有极少数人看起来很另类。通过对人类社会这个网络的模拟，可以让我们更好地理解上述现象。

网络模拟，一方面可以对网络测量的数据和对网络演绎的成果进行验证，

另一方面可以在计算机上对网络的演化过程进行提前预测,以指导人们采取有针对性的防范和应对措施。网络模拟的效果取决于模型的逼真度、节点的海量性和仿真的时效性。

4. 小结

从各种聚会到恐怖组织,从远古的细菌到现代跨国大公司,都组织成了网络,这些网络对人类社会造成了深远的影响。虽然不同网络节点的属性各不相同,但它们背后都具有一种深层次的基本秩序,并且按照一些简单而强有力的规则在运转。网络科学的研究目的就是揭示这些规则,并通过这些规则对网络的运行进行预测,并尽可能控制网络的行为。

通过对网络科学的研究,将帮助人们更好地理解最新时尚的流行特性、病毒的传播规律、生态系统的健壮性、全球经济的脆弱性,甚至可以构建未来完备的社会制度。

参 考 文 献

- [1] 曾宪钊.网络科学.北京:军事科学出版社,2006:1—15.
- [2] Waldrop M.复杂:诞生于秩序与混沌边缘的科学.陈玲译.北京:三联书店,1997.
- [3] Watts D J,Strongatz S H. Collective dynamics of “small-world” networks. Nature, 1998, (393):440—442.
- [4] Barabási A L, Aibert R. Emergence of scaling in random networks. Science, 1999, (286): 509—512.
- [5] Barabási A L. 链接网络新科学.徐彬译.长沙:湖南科学技术出版社,2007.

撰稿人: 陆建华
清华大学电子工程系

机器学习之模型选择

Model Selection for Machine Learning

机器学习致力于建立计算模型 q 以发现并描述已知数据集 X 中的规律，并用 q 进行预测推断和问题求解。 q 是一个计算程序或数学模型。 X 中数据量是有限的，可以被一个复杂度 k 足够的 q_k 及任何一个 $q \supseteq q_k$ (包含 q_k 为子集) 来完全描述。不过， X 中数据通常受到噪声干扰，即使 q_k 能完全表述 X ，也分不清所描述的有多少是规律，多少是噪声，且 k 越大，描述噪声的机会也越大。相反，一个复杂度 k 太小的 q_k ，不能充分表述 X 中规律，且 k 小则相应的描述误差(称为经验误差或风险) r_f 也越大。考虑模型簇 $q_1 \subset q_2 \subset \dots \subset q_k \subset \dots$ ，如图 1 所示，曲线 r_f 随 k 增加逐步下降至零，因此，难以由 r_f 确定合适的 k^* 。我们更感兴趣的是，将 q_k 用于 X 以外但仍反映 X 中规律的 future 数据，相应的描述误差称泛化误差或风险 r_g ，它随 k 变化有个最小点 k^* 。以图 2 为例，经验误差 r_f 在 $k=1$ 处较大，而在 $k \geq 2$ 各处都变得很小，泛化误差 r_g 在 $k=1$ 处较大，在 $k=2$ 时最小，而 $k > 2$ 又增大。模型选择之经典概念就是在模型簇 $\{q_k\}$ 中选择合适的 k^* 以致相应模型 q_{k^*} 之泛化风险最小。实际上，并没有未来数据可用，只能根据经验风险 r_f 和 q_k 的结构，在给定数据集 X 上去预测它在未来数据上的表现 r_g ，这正是模型选择的困难所在。




图 1 经验风险与泛化风险






图 2 多项式曲线拟合

在机器学习中， q_k 通常由 k 个简单单元经过简单组合形成，如图 3 所示。最常见是图中第一个例子，每个单元为一红点，表示一个类，称为聚类分析，模型选择的任务是回答有几个类。同样，此问题难以由曲线 r_f 回答，看似是一、

二类的数据集，却可以在把每个数据点都看成是一个类时出现 $r_f = 0$ ，而且，究竟是 $k=1$ 或 $k=2$ ，并非仅看似就可解决，一个数据点的去留就能影响判断（如图 3 中实心点所示）。考虑到数据的随机性，每个单元进一步可以是一个概率分布，也可以是线、面或图 3 中的其他结构。更一般地， q_k 可以表示成一个参数概率分布 $q(X|\theta_k)$ 。模型选择通常以两步法实现。首先，对每个 q_k ，基于 X 求解 θ_k ，称为参数学习，并得到图 1 中的 r_f 曲线。然后，按某准则近似估计 r_g ，并选择合适的 k^* 。这个两步法，枚举 k 并对应于每个 k 值需学习 θ_k ，计算量巨大。不仅如此，当 k 值越变越大时， θ_k 中未知参数的数目将骤增， θ_k 和 r_f 曲线的估计都将变坏，并造成 k^* 估计变坏。这两个缺点都让模型选择变得更加困难。



q_k 可以简单的是几个点、线、面、高斯分布



q_k 也可以是一个 k 维线性系统或是 k 个隐单元构成的非线性网络

图 3 简单单元经过简单组合形成的结构

下面以两个发展阶段，回顾数十年来对这些问题的主要努力：

第一阶段从 20 世纪 60 年代中到 90 年代初，以两步法实现为主，探求各种理论下的选择准则，可归纳为两个方向。方向一是寻求近似估计泛化风险 r_g ，兵分三路。一是基于数据集 X 重复取样的经验估计，要点是每次从 X 获得两个不同子集，分别用于建立模型和评估它的 r_g ，并重复多次后获得平均值，典型例子是 Stone 于 1974 年提出的交叉验证 (cross-validation, CV)^[1]，这条路计算量巨大，但做法简单，故仍有广泛应用。第二路是把 X 看成随机集，而参数估计 $\theta_k(X)$ 和相应的 $r_g(X)$ 都是随机变量，通过理论分析，近似估计 $r_g(X)$ 的期望值作为泛化风险。始于 1960 年出现的 C_p 准则，用于在平方误差 r_f 最小的线性回归分析中选择变量^[2]。随后是以 $-\ln q(X|\theta_k)$ 为 r_f 的准则 AIC (Akaike

information criterion)^[3], 用于线性自回归中的阶次分析, 它包括 C_p 为特例, 还渐近地等价于 CV ^[1]。AIC 的提出引发了对模型选择的广泛研究, 三十余年后, Akaike 获得类似诺贝尔奖的日本 Kyoto 奖。第三路则基于 Vapnik-Chervonenkis (VC) 理论, 估计任何 θ_k 下 $r_g - r_f$ 的上界^[4], 对定性分析有用, 也给局限于两类识别的支持向量机提供了理论支持, 但得到的上界通常含有未知系数, 表达式也复杂, 一般不便于实际应用。方向二不是估计泛化风险, 而是寻求对数据 X 之最短编码。最早由 Solomonoff 于 1964 年提出, 1 年后, Kolmogorov 也独立给出, 后来被称为 Kolmogorov 复杂度, 即表述 X 所要的最短计算程序^[5]。真正被用于参数学习和模型选择, 是局限在概率模型下的最短编码, 始于 MML (minimum message length)^[6], 随后有 BIC (Bayesian information criterion)^[7] 和 MDL (minimum description length)^[8]。这些研究相互影响, 有共同特点, 细节又不同。如图 4(a) 所示, MML 和早期 MDL 的思路皆是两部分编码, 即用 $q(X|\theta_k)$ 对 X 编码, 并估计 $q(\theta_k)$ 用于对 θ_k 编码, 而 MML 和 MDL 的不同点在于对 $q(\theta_k)$ 的不同考虑, 此办法也等价于基于非规范先验 $q(\theta_k)$ 的最大验后 (MAP) 估计。BIC 和后期的 MDL 则都是考虑单部分编码。如图 4(b) 所示, BIC 或 Marginal Bayes 用 $q(X|k)$ 对 X 编码。后期的 MDL 则用归一化后的 $q(X|\theta_k)$ 对 X 编码。最广泛应用的是这些研究所共同含有的主要部分。实际上, 许多应用都涉及图 4(c) 所示隐变量模型, 上述研究所致力考虑的都是消去隐变量后得到的 $q(X|\theta_k)$, 实质上如同考虑一个无隐变量模型。




图 4 最短编码与 Bayes 方法

从 20 世纪 90 年代初至今是研究发展的第二阶段。除了上述成果的应用和延伸外, 还出现了第三个方向, 即 BYY 阴阳和谐学习。考虑图 5(a) 所示的系统, 内部表示 R 不仅有参数 θ 为长期记忆, 还包括隐变量 Y 为短期记忆。阴模型从内向外描述或重建数据 X , 而阳模型作为阴模型的逆, 从外向内将观察 X 映射到 R , 这些都在阴阳和谐原理下进行。阴阳和谐指阴阳以最默契 (交换信息最小)

的方式达到最大共识。数学上通过图 5(a)中所列的和谐度 $H(p \parallel q)$ 之最大化来实现, 不仅寻求阴能很好描述 X , 而同时阳成为阴之最优逆, 并且促使 BYY 系统复杂度尽量小。另一理解是, 为了让阴能很好描述 X , 阳需从 X 向 R 输送给阴的信息为 $-H(p \parallel q)$, 它越小越好。在图 4 中, 先验 $q(\theta_k)$ 是模型选择的仅有动因, $q(Y|\theta_k)$ 则躲在 $q(X|\theta_k)$ 的积分背后, 实际上对模型选择没有帮助。而在图 5(a)中, Y 的复杂度 k_Y 是 k 的一部分; 甚至在许多应用中, 模型选择就是只选择复杂度 k_Y 。 $q(Y|\theta_k)$ 远比 $q(\theta_k)$ 容易准确获得, 且在 $H(p \parallel q)$ 中占有与 $q(\theta_k)$ 同等的地位, 可以显著地改进模型选择。




图 5 BYY 系统与最大和谐原理

第二阶段的另一方向是针对两步法实现的两个缺点(参见本文第二段内容), 寻求在参数学习中自动实现模型选择, 即所依据的学习理论或机制能够驱使某参数子集在学习趋向零, 导致多余的模型复杂度被删除^[9]。20 世纪 90 年代初提出的 RPCL 学习在竞争学习各类中心的同时能自动选择类别^[10]。90 年代中期开始的 Lasso 和基于拉普拉斯先验的 Bayes 学习, 在线性回归分析中能自动删除多余变量^[11]。通过挑选先验 $q(\theta_k)$, 图 4(a)的 MML^[6]和图 4(b)中基于 VB(variational Bayes)近似的 $q(X|k)$ ^[12], 皆在 21 世纪初用于在学习自动选择类别。在学习过程中自动实现模型选择, 也是 BYY 阴阳和谐学习的重要特点之一, 与 MML 和 VB 相比, 优点是 $q(Y|\theta_k)$ 与 $q(\theta_k)$ 具有同等地位, 有力地加强了学习中自动模型选择的能力。

虽然经过近半世纪的努力, 可以认为模型选择仍是未决难题。已有各种方法中, 没有哪一个被公认是最好的。机器学习的目的, 即学习现有的去推断未来的, 是造成困难的关键。此难题实质上涉及从哲学层面看什么是最好的学习理论。若相信现有的和未来的都遵循同一真理, 则追求估计泛化风险是有道理的, 应当致力改进基于 VC 理论的研究, 令其便于实际应用, 并建立它与最短编码和 BYY 阴阳和谐的内在联系。其实, 许多人不再信奉这一经典哲学, 转向寻

求能对数据最短编码的模型或等价地最可能产生这一数据的模型^[5,8]。值得注意的是, Solomonoff 于 1964 年提出的基本思想近年来已成为新人工智能的理论基础^[5]。基于多年研究, 笔者相信作为中华核心文化之一的阴阳和谐哲学, 是解决此难题的一个出路^[9]。

参 考 文 献

- [1] Stone M .An asymptotic equivalence of choice of model by cross-validation and Akaike's criterion .J.R.Statist.Soc.B,1977,39,44—47 .
- [2] Gorman J W ,Toman R J.Selection of variables for fitting equations to data .Technometrics , 1966,8;27—51 .
- [3] Akaike H .A new look at the statistical model identification .IEEE Trans.on Automat.Contr.,1974,19(6);714—723 .
- [4] Vapnik V .The Nature of Statistical Learning Theory .New York ;Springer,1995 .
- [5] Schmidhuber J.The new AI is general and mathematically rigorous .Journal of Frontiers of Electrical and Electronic Engineering in China,2010,5(3);347—362 .
- [6] Wallace C S,Boulton D M .An information measure for classification .Computer Journal , 1968,11(2);185—194 .
- [7] Schwarz G . Estimating the dimension of a model .Annals of Statistics,1978,6(2);461—464 .
- [8] Rissanen J .Basics of estimation .Journal of Frontiers of Electrical and Electronic Engineering in China,2010,5(3);274—280 .
- [9] Xu L .Bayesian Ying-Yang system ,best harmony learning ,and five action circling .Journal of Frontiers of Electrical and Electronic Engineering in China ,2010,5(3);281—328 .
- [10] Xu L,Krzyzak A,Oja E .Rival penalized competitive learning for clustering analysis :RBF net and curve detection .IEEE Transactions on Neural Networks ,1993,4(4);636—649 .
- [11] Williams P M .Bayesian regularization and pruning using a Laplace prior .Neural Computation,1995,7(1);117—143 .
- [12] Corduneanu A,Bishop C M . Variational Bayesian model selection for mixture distributions//Jaakkola T,Richardson T .Artificial Intelligence and Statistics 2001 .New York : Morgan Kaufmann Publishers ,2001 ;27—34 .

撰稿人：徐 雷

香港中文大学计算机科学与工程系

操控量子世界

Manipulating the Quantum World

1. 背景介绍

在漫长的历史进程中，人类经历了从畏惧自然、认识自然到征服自然的过程。近代社会以来，人们认识和改造自然的能力以惊人的速度不断突破其所能达到的极限。人们所需驾驭对象的尺度逐渐进入微纳观，甚至更小的原子分子尺度。有别于传统系统，这类系统显现出明显的量子力学特性，需要采用量子力学原理才能比较准确地描述，从而必须发展新的控制技术对其进行加工、操纵^[1,2]。

以电子技术为例，随着计算机芯片技术的发展，芯片加工尺度已经达到纳米尺度，传统的光刻加工技术已经无法满足需要。在这一尺度下，人们已经开始研究，利用扫描隧穿显微镜或原子力显微镜等纳米操作技术，对单个原子或分子进行控制和组装。在化学领域，科学家已经开始尝试抛开传统的瓶瓶罐罐，利用激光来直接“加工”分子中的化学键^[3]，从而得到采用常规化学方法无法得到的产物，它们的激光脉冲必须要短到几十到几百飞秒($1\text{fs}=10^{-15}\text{s}$)。在物理领域，利用激光冷却和光阱捕获等技术，人们已经可以囚禁单个原子分子并对其进行操纵。人们甚至已经开始尝试探讨在分子原子尺度，模拟和控制简单的生物现象，如植物的光合作用。

图1给出了上述几个操控微观系统的具体例子的示意图。图1(a)中描述了利用原子力显微镜针尖实现纳米操作，其中，三角状物体代表原子力显微镜的针尖，其尖端尺度可以达到原子量级，因此，可以通过原子力显微镜的针尖操作原子尺度的对象，从而使得加工线宽可以达到几纳米甚至更小。图1(a)中4幅小图分别演示了推动/拉动(pushing/pulling)、切割(cutting)、触探(touching)及刻印/刻蚀(indenting/lithography)等不同操作过程。图1(b)来自文献[3]，描述了通过设计激光脉冲打破分子中的化学键，从而选择性地控制化学反应产物的过程，其中，控制脉冲通过外部学习控制回路(learning loop)进行迭代优化，不断提高化学产物的产率。图1(c)描述了利用激光囚禁原子的示意图^[4]，通过在空间3个独立方向上施加的6个光束，限制原子的三维运动，从而可以将原子囚禁在固定的位置并进一步实现对原子的精确操纵和控制。




图1 微尺度系统操控

近年来,人们发现微尺度系统中的量子效应可以被巧妙利用,来实现用经典力学描述的宏观系统无法达到的强大功能,这方面最典型的代表是20世纪90年代兴起的量子信息学。基于量子叠加原理所赋予的并行性,量子计算机可在多项式时间复杂度意义下,破解世界上现在普遍使用的RSA密码体系。而基于量子纠缠的量子通信则从原理上讲具有绝对的安全性,从而可以完全解决窃听问题。但是,距离造出实用的量子信息处理器还有很长的路要走,这其中关键之一就是基于量子力学原理的操控技术。根据DiVincenzo的著名观点,任何量子计算的硬件实现方案必须解决以下5个问题:①可规模化的量子比特构造方案;②量子态的初始化;③足够长的相干保持时间,需要远大于量子门操作时间;④具有普适性的量子逻辑门的实现;⑤量子信息的提取,即量子测量问题。

显然,这些都是典型的控制问题。因此,将理论上可行的量子计算机变成真正可以用来解决问题的实用量子计算机,控制的思想和技术是其中的关键。在量子通信领域,技术上需要解决的控制问题也很多,如实现可控的特别是确定性的光子源及纠缠光源,以及克服信道传输过程中退相干引起的纠缠流失等问题。

2. 问题描述

在上述背景下,传统控制理论与量子力学原理结合形成了量子控制这门综合交叉学科^[1,2]。从控制对象来看,量子控制所处理的对象小到原子分子,大到具有一定宏观尺度的电路(如超导电路),它们的共同特点是其物理特性需要用量子力学进行描述。从控制手段来看,由于对系统的操控通常需要在低温、小尺度等极端条件下实现,而在这些极端条件下,电磁场是相对较为容易实现控制的手段之一,如通过射频磁场控制核自旋、通过激光脉冲控制原子能级跃迁

甚至控制化学反应、通过门电压和磁通控制超导回路的量子态等。

3. 历史回顾及研究现状

量子控制早期发展可以追溯到 20 世纪 80 年代,有关量子系统的控制建模、可控性^[5]、可逆性、可观性及滤波^[6]的一批基础性研究作为量子控制的发展奠定了基础。随着选键化学和量子信息的兴起,量子控制开始得到迅速发展与推广。在这一领域,早期研究主要针对简单的量子系统进行讨论。具体来说,从系统模型的角度来看,所讨论系统主要集中在封闭系统,即不考虑被研究系统与环境间的相互作用;从系统复杂度来看,主要集中在低维简单系统;从控制设计角度来看,控制思想主要来源于物理直观,而且所采用的控制基本是开环控制。这一时期一个重要的问题是对于有限维封闭量子系统可控性的讨论,这个问题和量子计算中的量子逻辑门的通用性问题是等价的。经过近十年的研究,这个问题已经基本得到了解决。

随着研究的深入,与实际系统相关的因素不断被考虑进来。首先是这一领域研究重点由封闭系统转向了与环境相互作用的开放系统。事实上,封闭系统的研究相对较简单,这是量子控制研究的基础。但在实际量子系统中,系统与环境间的相互作用往往不能忽略,因此,需要进一步考虑开放系统的控制问题,这里涉及系统与环境的相互作用的描述^[7]、控制场的噪声对控制效果的影响等重要问题。此外,从系统模型复杂度来看,由早期研究的低维简单系统转向高维系统,甚至是具有连续能级结构的复杂无穷维系统的研究,在这方面,在可控性等基础问题上,已有研究已经取得了一定的成果^[8]。但应该指出,为应对这些复杂情况,需要从传统控制论中借鉴系统性的控制设计思想,特别是从开环控制到反馈控制的转变^[2]。量子反馈控制的研究可以追溯到 20 世纪 90 年代初,量子光学方面的进展推动了量子反馈控制理论的发展。研究人员提出,测量对系统状态的破坏并不是一个瞬间变化,而是经过了一个演化过程,即提出量子弱测量的概念,这就为引入反馈控制提供了理论上的依据。在此基础上, Wiseman 等学者首先提出了基于输出反馈的马尔可夫直接反馈控制方案,在这一方案中,控制信号被限制为测量输出信号的线性函数。而后, Doherty 等学者又考虑了连续弱测量的输出信号与系统状态的关系,提出了基于状态估计 Bayes 反馈控制方案,在这一方案中,控制信号不需要再限制为测量输出信号的线性函数。到目前为止,量子反馈控制理论已经成功运用到一些具体物理问题当中,并且在实验方面也已经取得了一定的进展。但是,在这一领域还有很多基本问题有待解决,如关于一般的非线性量子反馈控制理论的描述、关于系统可观性的一般性讨论、观测器的设计、量子反馈控制的鲁棒性等。考虑到反馈控制在经典控制理论中的重要性和成功的应用,量子反馈控制近几年受到了越来越多

研究者的重视。

应该指出,迄今为止,在理论上和实验上较为成功的量子控制研究大多来源于对传统控制中较为成熟的理论和技术的平行推广。如化学反应激光控制,由于引入了最优控制理论的思想^[3],从而大大拓宽了对分子体系的控制能力,并带来了 20 世纪 90 年代末以来大批成功实验 [如图 1(b)所示]。传统时间最优控制在量子计算实现中的应用是另一个典型例子^[9],其设计结果不仅可以加速量子逻辑运算,还可以削弱环境噪声对量子信息处理的致命影响。近年来,传统随机线性系统控制中的线性二次高斯型 (linear quadratic Gaussian) 控制设计思想已被推广到线性量子系统反馈控制研究中,并发展出了 H-infinity 鲁棒控制方法^[10]。


4. 量子系统控制的主要困难

尽管量子控制领域迄今为止的大多数研究还停留在对经典控制中的标准问题及其标准解法的推广应用,但是,由于量子系统与经典系统存在物理上的本质不同,相应的控制问题很多情况下并不能简单化为标准经典控制问题,这是量子控制作为一个科学难题最典型的困难,也是其魅力所在。

首先,量子力学基本原理为量子系统的控制设计,特别是量子反馈控制的引入设置了种种限制。

图 2 描述了原子-光学系统中实现量子反馈控制的实验原理图。如图 2 所示,探测激光通过分光镜进入光腔,与光腔中的原子系综发生相互作用。通过相互作用,探测激光将携带原子系综的信息(如原子在各能级上的分布)进入测量回路,通过光电探测装置将其携带的原子信息转化为电磁信号并输入控制回路,通过场处理门级序列 (field programmable gate arrays, FPGA) 装置得到控制信号,并根据它来调节原子系综上的磁场,从而实现对原子系综的控制。这个反馈过程利用激光对原子系综的探测是量子力学意义上的测量过程,而根据基本的量子测量原理,量子测量将不可避免地随机改变系统的状态,并在系统中产生随机的量子噪声,而这种干扰是由量子力学原理本身决定的,而非测量仪器不理想造成的,这是量子系统控制与经典系统控制的本质不同之一,它为量子反馈控制的引入造成了本质上的困难。此外,量子力学中著名的海森堡测不准原理指出,一般情况下,同一系统的两个物理量(如粒子的位置和动量)不可能同时精确测量,这意味着量子测量不可能得到关于系统量子态的完全信息,因此,原则上无法实现量子系统的全状态反馈,这也为量子反馈控制设计带来了很大的困难。

另一方面,随着理论和实验研究的深入,复杂量子多体系统的控制逐渐进入人们的视野,特别是量子信息处理发展的大势所趋——量子信息网络。多体

图2 量子反馈控制^[11]

量子系统的复杂性为量子控制带来了巨大挑战。众所周知，经典多体系统的状态变量个数随子系统个数增加呈线性增长，但量子多体系统的状态变量个数随子系统个数增加呈指数增长。量子系统的这一特性是量子计算得以实现的关键，但却在利用经典计算机或经典数字处理器为量子系统设计控制时带来了指数时间复杂度的问题。这个问题与利用经典计算机模拟量子系统，即做所谓的 quantum simulation 时，会遇到指数时间复杂度的问题是一样的。可以想见，这个问题会越来越严重。

除了理论发展所遇到的困境，量子控制在走向实用化的进程中还必须解决对退相干的抑制这个瓶颈问题。退相干是指由于系统与环境相互作用导致系统量子态的相干性退化，从而使得量子态退化为经典态的物理现象。由于量子控制的目标是为了更好地利用量子效应，因此，必须能够阻止退相干过程的发生。早期的退相干抑制策略主要来源于对经典系统纠错方法的推广，即通过引入冗余量子信息资源对量子信息载体重新编码，以实现纠错和避错，它在理论上可以纠正退相干带来的误码，但其所需的冗余资源在当前技术条件下是难以让人接受的。因此，人们又提出利用主动控制的方法抑制退相干，其中，源于核磁共振中的回波技术的 BangBang 控制策略较为成功^[12]，并在实验上已经成功应用于固态系统，但这种策略在屏蔽环境噪声的同时也影响了对控制对象进行控制的能力，从而限制了其应用范围。总体而言，退相干抑制问题复杂而丰富多样，目前还远没有得到解决，未来较有希望的解决途径是引入传统控制理论中的系统思想，如基于内模原理的噪声干扰抑制方法^[7]。

操控量子世界，这个曾经有如科幻的梦想正逐渐成为现实，它在理论上的有趣性和应用上的重大意义吸引了来自物理、化学、材料和控制科学等诸多领域研究人员的关注，从而形成了一个高度交叉的学科领域，并以其独有的方式

影响着从基础物理、化学学科到纳米、材料等工程学科的发展。

参 考 文 献

- [1] D'Alessandro D. Introduction to Quantum Control and Dynamics. Boca Raton: Chapman & Hall, 2007.
- [2] Wiseman H M, Milburn G J. Quantum Measurement and Control. Cambridge: Cambridge University Press, 2009.
- [3] Rabitz H, de Vivie-Riedle R, Motzkus M, et al. Whither the future of controlling quantum phenomena. Science, 2000, 288(5467): 824—828.
- [4] <http://www.anl.gov/Media.Center/News/2004/PHY041029.html>.
- [5] Huang G, Tarn T J, Clark J W. On the controllability of quantum-mechanical systems. J. Math. Phys., 1983, 24(11): 2608—2618.
- [6] Barchielli A, Belavkin V P. Measurements continuous in time and a-posteriori states in quantum-mechanics. J. Phys. A: Math. Gen., 1991, 24(7): 1495—1514.
- [7] Ganesan N, Tarn T J. Decoherence control in open quantum systems via classical feedback. Phys. Rev. A, 2007, 75(3): 032323.
- [8] Wu R B, Tarn T J, Li C W. Smooth controllability of infinite-dimensional quantum-mechanical systems. Phys. Rev. A, 2006, 73(1): 012719.
- [9] Khaneja N, Brockett R, Glaser S J. Time optimal control in spin systems. Phys. Rev. A, 2001, 63(3): 032308.
- [10] James M R, Nurdin H I, Petersen I R. H^∞ control of linear quantum stochastic systems. IEEE Trans. on Automat. Contr., 2008, 53(8): 1787—1803.
- [11] Mabuchi H, Doherty A C. Cavity quantum electrodynamics: Coherence in context. Science, 2002, 298(5597): 1372—1377.
- [12] Viola L, Lloyd S. Dynamical suppression of decoherence in two-state quantum systems. Phys. Rev. A, 1998, 58(4): 2733—2744.

撰稿人：谈自忠 张 靖 吴热冰
清华大学信息科学与技术国家实验室

合作演化之谜

Evolution of Cooperation

合作现象在现实世界中非常普遍，如国家与国家之间的战略合作、社会生产生活中人与人之间的相互协作、动物和原始人类的联合捕猎及不同物种之间的共生联盟等^[1]。合作行为在生物进化的过程中起着极其重要的作用。从单细胞的微生物到高级哺乳动物，从社会性昆虫到人类社会，生物个体之间的合作增加了整个种群的生存机会，并使得种群得以繁衍下去。合作被认为是除了变异和自然选择之外演化的第三种基本法则^[2]。在生物进化的过程中，正是合作导致了不同层次的复杂生命组织相继出现，并最终形成了丰富多彩的复杂性世界。因此，可以说合作是生命现象与文明社会的基础。然而，依据达尔文适者生存理论，自私个体为使自己的利益最大化倾向于选择不合作，这是因为个体的合作行为虽然给种群内其他成员带来好处，但会损害自身的利益。达尔文在其著作《物种起源》中指出：没有任何一种本能是专门为了他人谋利而形成的，相反，所有的动物都欺骗和利用对方^[3]。因此，具有自私本性的个体之间为了获得更好的生存条件会相互利用和竞争，这显然不能解释现实世界中随处可见的合作行为。在这种情况下，如何解释合作行为从自私个体之间涌现并在整个种群中演化是演化生物研究中的一个核心问题。合作演化难题主要是探寻生物、社会和经济等系统中合作行为产生并维持的可能机制，其研究不仅涉及演化生物学，还涉及生态学、人类学、心理学、社会学、行为学和经济学等学科，是目前多学科交叉研究的前沿热点问题之一^[4~6]。

演化博弈论为研究合作演化难题提供了方便而有效的数学框架^[7]。囚徒困境博弈和雪堆博弈是最常用的两个合作演化模型^[8]。在囚徒困境博弈中，每个纯策略的个体都有两种选择：合作与背叛。背叛者利用合作者获得收益 T ，同时合作者获得收益 S 。当双方都合作，则都获得收益 R ，都背叛则都获得收益 P ， $T > R > P > S$ 。在单轮博弈下，无论对手采取何种策略，个体的最佳策略总是背叛。然而，在双方都采取合作策略的情况下，两者总的收益才是最大的。这一现象说明了社会两难问题的本质。而在雪堆博弈中，与囚徒困境博弈不同的只是 P 和 S 的大小顺序变了，即 $T > R > S > P$ 。此时，个体的最佳策略取决于对手的选择：当对手合作时则选择背叛；当对手背叛时则选择合作。在基于个体的博弈模型中，个体能够在与其他个体相互作用时积累经验和存储信息，并根据这些经验和信息来调整自己的行为。在这样的模型假设下，提出一些合理的机制来促进个体合作行为的自组织涌现，同时，揭示一些真实种群系统

(如生物生态系统和社会经济系统)中合作演化自下而上的内在作用机理是十分有必要也是非常有意义的,从而可以有效解决合作演化难题。20 世纪 90 年代末以来,蓬勃发展的复杂网络理论为描述种群中个体之间的博弈和竞争关系提供了方便的框架。网络上的节点代表种群中的个体,边代表个体之间的连接博弈关系。特别是近年来复杂网络上的合作演化研究引起了学术界广泛的关注,成为一个非常重要的研究方向。种群系统的演化动力学具备一般复杂系统的特征,包括非对称、非均匀、层次结构、动态演化、学习适应与反馈等,而且系统是由许多平行作用且相互影响的独立个体组成的。因此,种群系统中合作演化也可作为研究复杂系统和复杂性科学一个可行的切入点^[9]。

自 20 世纪 60 年代以来,对合作涌现和演化机制的探索研究一直广受关注,研究者相继提出了一些能够促进合作演化的有效机制,如亲缘选择、直接互惠、间接互惠、网络互惠和群体选择等^[2]。尽管合作演化难题研究已取得了诸多突破和成果,但还有许多公开难题尚未得到完全解决或者存有争论。在合作演化研究中,最重要的一类模型是迭代囚徒困境博弈。在反复博弈作用中,“针锋相对”是一种倾向于合作并会“模仿”对手在上一轮的策略,以其人之道还治其人之身:以合作报以合作,以背叛报以背叛。研究者发现这种“针锋相对”策略能促进合作,并且博弈行为实验表明它是获得最高收益实验者中广为使用的策略。与“针锋相对”对应的是另外一种“创新”策略,即“赢存输变”。如果个体当前的收益高于自己的期望值,则保持当前策略;否则,切换到另外一种策略。目前,公认“针锋相对”和“赢存输变”或他们的变种规则在促进并维持合作上最为简单有效。但是,到底在合作等社会行为演化过程中发挥主要作用的是策略模仿还是创新,或是两者综合呢?这个问题的解决对于解释人类社会文明的演化具有举足轻重的作用^[10]。众多研究表明,种群结构影响了合作演化。事实上,合作与种群结构是共同演化的,两者相互影响,互为反馈。用图论的语言描述就是动态图上的演化博弈动力学。这类问题中,种群中个体的状态配置描述必须使用高维变量,数学上严格解析难度极大,很具有挑战性。当前,解析研究结论一般是基于弱选择假设(博弈收益只是对个体适应度的小修正)。对于强选择(博弈收益很大程度上决定了个体适应度)下动态图上的合作演化研究,尚无严格解析结果,是目前的一个公开难题^[11]。总的说来,前文所述的 5 种促进合作演化的机制都导致了某种特定种群结构,使得合作者之间形成了“聚类”,即合作者相互“抱团”,他们相互作用的频率要比与背叛者之间的作用频率要高,从而可以维持合作。从这个意义上,可否提出一般模型,并结合自然选择和种群结构因素,统一合作得以演化的条件?这类工作对解决目前亲缘选择与群体选择之间的争论具有重大意义与前景。

合作是社会行为最为普遍的一种表现形式,涉及多个个体同时或交替相互作用,产生协同效应,使得种群的总体适应度得以增加。社会性是同种个体之

间合作的先决条件。但是,个体因选择群居而形成小型社团的这种社会性是怎么演化产生的?如何解释个体的社会性演化是当前演化生物理论研究中一个尚未完全解决的前沿问题。在自然演化进程中,合作导致了更高层次生命组织形式的出现,使得生命世界井然有序。演化过程使得生命系统向着复杂性和自组织性发展,即形成了高度有序的复杂性,并在这过程中熵减少了。表面上看来这违背了热力学第二定律(熵增定律)。如何理解这种达尔文自然演化与物理热力学定律之间存在的悖论,目前存有大量争论。可否建立一个最小模型重现生命体最小单元之间合作导致复杂性组织形式的涌现?建立这种简洁而有效的数学模型是解决这个难题的可行途径之一。

合作行为涌现及其演化机制的研究已成为备受人们关注的主要课题,吸引了越来越多研究者的关注。通过对这一课题的研究,可以加深人类对自然界中广泛存在的合作行为的理解,并对自组织演化、多智能体协作、经济动力学、社会及生态稳定性等方面的研究大有裨益。

参 考 文 献

- [1] 王龙,伏锋,陈小杰,等.复杂网络上的演化博弈.智能系统学报,2007,2:1—20.
- [2] Dugatkin L A.Cooperation among Animals:An Evolutionary Perspective.Oxford:Oxford University Press,1997.
- [3] Darwin C.On the Origin of Species.London:J.Murray,1859.
- [4] Doebeli M,Hauert C.Models of cooperation based on the prisoner's dilemma and the snow-drift game.Ecol.Lett.,2005,8:748—766.
- [5] Colman A M.The puzzle of cooperation.Nature,2006,440:744—745.
- [6] Nowak M A.Five rules for the evolution of cooperation.Science,2006,314:1560—1563.
- [7] Nowak M A.Evolutionary Dynamics:Exploring the Equations of Life.Cambridge:Harvard University Press,2006.
- [8] Nowak M A,Tarnita C E,Antal T.Evolutionary dynamics in structured populations.Phil.Trans.R.Soc.B,2010,365:19—30.
- [9] Pennisi E.How did cooperative behavior evolve.Science,2005,309:93.
- [10] Pennisi E.On the origin of cooperation.Science,2009,325:1196—1199.
- [11] Rendell L,et al.Why copy others? Insights from the social learning strategies tournament.Science,2010,328:208—213.

撰稿人:王 龙 陈小杰 伏 锋
北京大学工学院系统与控制研究中心

微型飞行器控制问题

The Control Problem in Micro Air Vehicles (MAVs)

1. 引言

像鸟儿那样在空中自由飞翔,是人类长期以来一直梦牵魂萦的向往。为实现这一美好的愿望,人们进行了前仆后继的探索。早在 1505 年,著名的意大利艺术大师达·芬奇就在他的研究手稿《论鸟的飞行》中,对鸟的起飞、降落、扑翼飞行、转弯、滑翔、升力和阻力的产生等进行了观察和研究,并且给出了很多合理的解释,还根据鸟的飞行设计了多种类型的飞机和降落伞,这位艺术大师在科技方面也做出了巨大贡献。

具有实际意义的突破出现在 1903 年 12 月 17 日,美国莱特兄弟制造的“飞行者”1 号飞机在北卡罗来纳州成功地进行了 12s 动力飞行,飞行距离 36.5m,由此掀开了人类航空飞行的历史篇章。6 年之后的 1909 年 9 月 21 日,中国著名飞机设计师冯如也驾驶由自己设计和制造的“冯如”1 号飞机翱翔蓝天。随后的 100 年间,大型动力飞行器不断涌现,在改变人们的时空理念的同时,也使有关科学和技术的进步插上了翅膀,一直向“更高、更快、更远”的目标攀升。2005 年 1 月 18 日,世界上最大的民用飞机空中客车 A380 诞生,机内可设 555~800 个座位,最大航程达 1.5×10^4 km。2005 年 12 月 15 日,世界上第一型第四代战机“猛禽”F/A-22 正式进入美国空军服役,战机能够以最高 1590km/h 的飞行速度进行超声速巡航,并可在 15km 以上高空执行作战任务。

在大型和高速飞行器层出不穷的同时,随着科技的不断进步,飞行器向小型和微型方向发展也成为一种重要的趋势。像鸟一样甚至更小的微型飞行器在诸多民用领域,特别是军用领域存在强烈需求,如在军事上,微型飞行器可应用于城区作战和应对恐怖威胁。微型飞行器的概念最初是 1992 年由美国科学家 Augenstein 在国防高级研究计划局(DARPA)主持在兰德公司(RAND)召开的一次关于未来军事技术的会议上提出的,当时,Augenstein 领导的一个微型飞行器研究小组正在研制像蜂鸟或昆虫一样大小的微型飞行器^[1,2]。

2. 微型飞行器的概念、发展及应用

自 20 世纪 90 年代起,随着微电子和微机电系统(MEMS)等技术的飞速发

展,飞行器设计的小型化和微型化发展成为可能。美国多家航空航天公司、大学等科研机构在美国 DARPA、NASA 和军方的资助下,最早开始了多项微型飞行器计划的研究。美国 DARPA 要求微型飞行器应具有自主飞行、携带任务载荷执行特定任务、通信及传输信息等基本特征,具体包括:①应是适合军用的系统;②能够携带全天候的近距离成像系统,分辨率应足以使操作人员分辨出发送区内的重要细节;③应具有准确确定地理位置的能力;④质量轻,坚固耐用,以便能够放在士兵的背包里携带;⑤价格低廉,甚至可以一次性使用;⑥隐蔽性好,不易被敌人发现,不应暴露使用人员的位置^[3]。

目前,对微型飞行器的基本技术指标还没有严格的界定,参考美国 DARPA 提出的要求,一般认为应满足以下条件:小于 15cm 的主尺度,35~72km/h 的最大飞行速度,100g 以下的起飞质量,10km 的航程等^[4]。在系统构成上,微型飞行器一般由高升阻比的轻质机体结构、微型任务载荷、微型高效动力系统及能源和具有导航及通信功能的微型飞行控制系统构成。对于微型化的飞行器,由于其特征尺度已远小于传统的飞行器,许多传统的飞行器设计理论和方法将不再适用,飞行器的微型化将面临诸多来自科学和技术上的挑战。

微型飞行器按飞行机理或总体布局不同,可分为固定翼式(fixed wings)、旋翼式(rotary wings)和扑翼式(flapping wings)三种^[5]。其中,固定翼和旋翼式微型飞行器的飞行原理分别与传统的固定翼飞机和直升机类似。扑翼飞行采用的是一种模仿鸟类或昆虫飞行的新型飞行原理,基于这种仿生学原理设计制造的微型飞行器又被称为“机械鸟”或“人工昆虫”。扑翼飞行与固定翼和旋翼飞行相比,优势在于它将举升、悬停和推进功能集于一个扑翼系统,可以用很小的能量进行长距离飞行,同时具有较强的机动性,因此,更适于在长时间无能源补充及远距离条件下执行任务。自然界的飞行生物无一例外地采用扑翼飞行方式,这就给了我们一个启迪,同时根据仿生学和空气动力学研究结果可以预见,在翼展小于 15cm 时,扑翼飞行比固定翼和旋翼飞行更具优势^[6]。

从概念研究阶段算起,美国对微型飞行器的研究和发展已经历了十多年的时间。紧随其后,欧盟国家、澳大利亚、俄罗斯、印度、以色列、日本、中国等也相继展开了微型飞行器及相关技术的研究。相对而言,美国和欧盟国家取得了领先优势。其中,美国比较典型的微型飞行器有 4 种,分别是 AeroVironment 公司的黑寡妇(Black Widow)、Sanders 公司的微星(MicroSTAR)、Lutronix 公司的蜂鸟(Kolibri)和加州理工学院与 AeroVironment 公司等联合研制的微型蝙蝠(Microbat),气动布局依次是两个固定翼式、旋翼式和扑翼式;欧盟比较有影响的微型飞行器有欧洲宇航防务公司(EADS)旗下的道尼尔公司(Dorniers)的 DO-MAV 和德国不伦瑞克工业大学(Technical University of Braunschweig)的 CAROLO,它们均为固定翼式气动布局,后者的目标是开发成全自主式微型飞行器。

Black Widow 是按照美国 DARPA 提出的微型飞行器技术要求而研制的一种微型飞行器,翼展为 15cm,原型机外形呈碟型,于 1996 年春完成了 9s 的飞行。1997 年 11 月,未携带有效载荷、飞行质量为 40g、采用锂电池的 Black Widow 飞行时间达到 16min。后来又经过多次优化,AeroVironment 公司开发出第一代 Black Widow。2000 年 8 月,Black Widow 携带彩色摄像机,试飞的留空时间达到 30min,最大活动半径为 1.8km,最大飞行高度约 234m,飞行质量为 80g^[7]。图 1 为 Black Widow 的原型机与第一代机。



图 1 Black Widow 的原型机(左)与第一代机(右)

MicroSTAR 的翼展为 15.24cm,起飞质量为 85g,巡航速度为 48km/h,任务范围可达 5km。微电子设备安装在机翼内,采用微电机驱动螺旋桨推进,电源由锂电池提供。机上装有质量为 5g 的差分 GPS 和惯性导航装置,具有自主导航和控制能力,可采用手持式发射器或直接手掷发射^[3]。Kolibri 的旋翼直径为 10.16cm,起飞质量为 316g,有效载荷为 100g,续航时间达 2h^[3]。图 2 为 MicroSTAR 与 Kolibri。




图 2 MicroSTAR(左)与 Kolibri(右)

Microbat 是世界上第一种手掌大小的电动扑翼机,原型机采用类似蝙蝠的机翼,以后逐步改进,更新换代,图 3 为 Microbat 的原型机和未来设想图。2002 年 8 月,新一代的 Microbat 采用高能锂离子电池作为电源,曾创下了连续

飞行 25min 的世界纪录, 图 4 为 Microbat 实际飞行试验录像中截取的图片。新一代的 Microbat 翼展约 22.86cm, 飞行质量为 14g^[7]。



图 3 Microbat 的原型机和未来设想图



图 4 Microbat 实际飞行试验录像中截取的图片

欧盟的 DO-MAV 的翼展为 42cm, 质量为 500g, 机上装有光/电摄像机进行实时视频传输, 飞行时间约 30min, 采用自动驾驶仪进行飞行控制^[8]。图 5 为 DO-MAV 及其地面站和飞行过程获取的图像。图 6 为 DO-MAV 机上的自动驾驶仪, 质量不到 25g。



图 5 DO-MAV 及其地面站和飞行过程获取的图像

德国 CAROLO 的研制目标是开发成全自主式无人飞行器。CAROLO 的名称来源于开发大学的名称 (Technical University Carolo Wilhelmina of Braunschweig)。




图 6 DO-MAV 机上的自动驾驶仪(质量不到 25g)

为实现自主飞行, CAROLO 的尺度和质量超出了一般的微型飞行器, 它的翼展为 40cm, 最大质量为 390g, 飞行时间为 40min, 航程约 45km^[9]。CAROLO 采用惯性和 GPS 组合导航, 机上配有数据链与地面站进行通信。图 7 为 CAROLO 的原型机和风洞试验图。CAROLO 家族除原型机(代号 CAROLO C40)外, 还开发了翼展更大的 CAROLO P50 和 CAROLO T140。



图 7 CAROLO 的原型机和风洞试验

与常规无人飞行器相比, 微型飞行器具有体积小、质量轻、成本低的飞行平台优势, 而且操纵方便、机动灵活、噪声小、隐蔽性好, 在众多领域中具有不可估量的应用潜力, 在军事领域的作用尤为突出。首先, 微型飞行器可用于低空或近距离的侦察和监视。载有全天候图像传感器的微型飞行器可以从 50~100m 的高度, 甚至更近的距离对目标实施侦察监视, 尤其是对卫星和军用侦察机触及不到的盲区或人员无法涉足的地区进行侦察。同时, 可以被部署到适当的位置, 作为固定而隐蔽的地面传感器实时传送侦察信息。其次, 微型飞行器能够承担通信中继、电子干扰和对地攻击等任务。虽然单架微型飞行器的干扰信号很小, 但当大量的微型飞行器接近敌方雷达天线作用区时, 可达到有效的干扰效果。如果携带高效能弹药, 则它们可用于对地攻击、破坏敌方雷达系统和通信中枢。此外, 微型飞行器还可用于目标指示、核武器和生化武器的探测等。特别地, 由于微型飞行器能够在城市建筑物群中以缓慢的速度飞行,

可飞抵甚至停留在建筑物内进行侦察,探测和查找建筑物内部的敌方人员或恐怖分子,因此,它在未来的城区战场和反恐军事行动中具有极为广阔的应用前景。

在民用领域,微型飞行器除了可用于通信中继、环境监测、灾情的监测等,还可用于交通道路监控、边境巡逻与控制、毒品禁运、农业勘测、大型牧场巡逻、城区监视、航空摄影等。

3. 微型飞行器的控制问题及解决途径

微型飞行器由于尺寸小、速度低,其飞行雷诺数 Re 远小于普通的飞行器,范围一般为 $10^2 \sim 10^5$,与自然界的鸟类及昆虫等大体相当。飞行雷诺数反映了施加在飞行器上的惯性作用力与黏滞作用力之比。在上述范围的飞行已属于低雷诺数飞行,此时,空气黏性的影响越发显著,微型飞行器受到的黏滞力相对增大,升阻比显著下降。例如,对于最小的飞行昆虫,它们在空气中的飞行就如同在蜂蜜中游泳。在这种情况下,应用常规的飞行器控制理论和方法很难保证微型飞行器在实际运行环境下稳定飞行。

微型飞行器尺度小,质量和转动惯量都比较小,抗风能力很差,因此,抗干扰和对复杂飞行环境的适应能力已成为微型飞行器实用化面临的主要问题之一。原则上讲,利用各种增稳、控制技术能实现抗干扰稳定飞行要求,但对于微型飞行器来说,由于尺寸很小,气动效率非常低,对于微型飞行器在自然风或其他干扰下的飞行稳定控制,采用偏转舵面控制、集中式或分布式扰流片控制、微喷流干扰控制和柔性翼自适应外形控制等传统控制方法难以达到目的,这是由于风速等参数变化引起的雷诺数波动可以达到 30% 以上。

与此同时,作战环境给微型飞行器的飞行控制带来了巨大挑战。例如,操作手仅经过短时培训,视线外操作,狭小区域内发射回收,微型飞行器在与自身巡航速度等量级的风沙天气下稳定工作,低高度飞行邻近障碍,在城区甚至室内作战等。微型飞行器的质量、尺寸、成本约束限制了机上计算机的能力和功耗、控制器件的数量和性能,增加了微型飞行器的运动耦合,从而也增加了飞行控制系统的设计困难^[8]。

为解决微型飞行器的控制和抗干扰稳定飞行问题,人们又开始了向自然的学习。仿生学研究中发现,许多尺度相近的鸟类和昆虫能够在强风和复杂环境下悬停或稳定飞行,主要原因是它们的翅膀及身体可根据外界条件的改变产生自适应变形,如图 8 所示。采用扑翼或柔性智能可变形体的方法是该问题的努力方向之一。

自然界中,鸟类和昆虫等动物的飞行已被人们关注了许多世纪。虽然在过去的 100 年中,航空技术取得了飞速进步,但人类发明的机械飞行依然在诸多




图8 蜂鸟悬停时的扑翼轨迹

方面远远逊色于生物的飞行，尤其是在物理尺度与飞行生物相当量级上的机械飞行。就运动速度而言，每秒钟人类最快能够跑过相当于自己身长 3~4 倍的距离，赛马约能跑过自身身长的 7 倍，而跑得最快的陆地动物印度豹则能跑过自身身长的 18 倍。对 SR-71(俗称黑鸟)这样的超声速飞机，飞行马赫数可达 3 (约每小时 2000 英里^①)，相当于每秒飞过约 32 倍的机身长度，但普通鸽子可经常以每小时 50 英里的速度飞行，这相当于每秒飞过 75 倍的自身体长。欧洲的一种八哥每秒可飞过 120 倍身长，而各种雨燕则可达到 140 倍以上。滚转速率较高的特技飞机(如 A-4)据称滚转速率可达 $720^\circ/\text{s}$ ，但家燕却可超过 $5000^\circ/\text{s}$ 。在过载方面，多数用于通用航空的飞机可以承受 4~5 倍的重力加速度，先进的军用飞机可承受 8~10 倍的重力加速度，但根据统计，许多鸟类每天上百次地经受到 10 倍以上，甚至高达 14 倍的重力加速度载荷。

要采用仿生学方法，模拟鸟类和昆虫的高稳定性和高机动性的飞行能力，则必须发展适用于微型飞行器的具有高可靠性、强适应性、高稳定性、强抗干扰能力的智能自主控制理论与方法^[4,10]；发展灵巧蒙皮、自适应结构、可变形机翼和完全柔性飞行器的变参数自适应控制理论和控制技术；微小型结构和微结构系统的集中或分布式自主协调控制；柔性飞行器构形动力学与控制；发展微自适应流动控制(MAFC)技术；进行微尺度的 MEMS 器件对于宏观尺度流动控制的机理研究及其精细实验。

生物运动仿生学为微型飞行器的飞行控制问题提供了多方面有益的启示和

^① 1mile(英里)=1.60934km。

问题解决途径,对微型飞行器的实用化发展具有重要意义。正如同许多高新技术的产生和发展首先是出于军事战略的需要,微型飞行器技术亦不例外。美国 DARPA 最初考虑此项技术正是源于军事目的,以期美国能在未来的军事行动中具有领先的高技术。由于微型化飞行器不可估量的应用潜力,因此,许多国家已经开始将微型飞行器技术列为研究的重点。

参 考 文 献

- [1] Hundley R O, Gritton E C. Future technology-driven revolutions in military operations . Documented Briefing of the RAND National Defense Research Institute ,1992 .
- [2] Hundley R O, Gritton E C. Future technology-driven revolutions in military operations : Results of a workshop .RAND Corporation Document ,1994 .
- [3] 陈国栋,贾培发,刘艳.微型飞行器的研究与发展.机器人技术与应用,2006,(02);34—44 .
- [4] 崔尔杰.生物运动仿生学与智能微型飞行器.力学与实践,2004,(02);1—8 .
- [5] 李科杰,宋萍.微小型无人系统技术在未来战争中的重要意义及发展动向.传感器世界,2004,(01);6—11 .
- [6] 侯宇,方宗德,孔建益,等.仿生扑翼飞行微机器人研究现状与关键技术.机械设计,2008,25(07);1—4 .
- [7] Keennon M T, Grasmeyer J M .Development of the Black Widow and Microbat MAVs and a vision of the future of MAV design .AIAA 2003—2901,2003 .
- [8] Arning R K, Sassen S. Flight control of micro aerial vehicles .AIAA 2004—4911,2004 .
- [9] Kordes T, Buschmann M, Winkler S, et al. Progresses in the development of the fully autonomous mav “CAROLO” .AIAA 2003—6547,2003 .
- [10] 崔尔杰.智能微型飞行器——从仿生学得到启示.科学中国人,2004,(4);26 .

撰稿人：李洪儒

中国航天科技集团公司第三研究院

多相航行器的航行控制问题

On Controlling Multi-medium Navigating Vehicle

1. 多相航行器呼之欲出

自古以来,人类就梦想,有一天能够自由自在地在地面、水上、水下、空中、太空遨游。在现代,人类已经发明了火车、汽车、飞机、导弹、鱼雷、飞艇、航天飞机、飞船、水面舰船和潜艇等。人类已经登上了月球,正在准备访问火星。不过,这些航行器一般只具有比较单一的航行性能,即只能在地面跑,或在空中飞,或在水面游,能够同时在多种介质中航行的航行器真是寥寥无几。

同时可以看到,在科学技术高度发达的今天,人类生活面临着越来越多的严重挑战。别的不说,我们来看看现代化城市中所面临的交通问题和环境问题。数以百万计的、各式各样的汽车给人们的生活带来了方便、带来了乐趣。但是,如果开着心爱的汽车到大城市宽阔的马路上去旅行一下,你就会亲自体验到什么是交通拥挤和“塞车”,什么是汽车尾气的污染,什么是车祸,什么是心急如焚……

因此,多年来,许多工程师和发明家都曾经幻想过、设计过、尝试过,希望制造出一种万能的航行器,能够根据人们出行的需要,既可以在地面上跑,又可以在天空中飞,还可以在水面上甚至在水下航行,这就是所谓的多相航行器。

对于多相航行器的需求,不仅仅来自人类日常生活方面或民用方面,更主要的,还来自军用方面,因为往往军事方面的需求,对于某些技术的发展,起着十分强烈的牵引作用。例如,要求设计一个能够上天、下海、钻地的导弹。于是,水上飞机、水陆两用坦克和装甲车、水翼船、飞行汽车、空天飞行器等就应运而生。近年来,飞行汽车的试验成功就是一个令人关注的例子。

让我们来简单回顾一下各种运动器械发展变化的过程,可以看到,关于航行的概念是在不断发展变化的。按文献[1]、[2]可知,“航”字的含义是:①船;②渡,航行。航行是指“船在水里或飞机在空中行驶”。众所周知,古代只有“船在水里行驶”,飞行是在20世纪初飞机发明以后的事。没有飞机,自然就没有“飞机在空中行驶”的问题。空间之大、之广,无边无际。站在地球上,有海、陆、空(稠密大气层)、天(太阳系内)、宇(太阳系外),相应地,

就是航海、航陆、航空、航天、航宇。不过,迄今人们并没有提出和使用过航陆这个名词。

2. 航陆概念的提出

那么,什么是航陆呢?由上所述可见,从航海到航空,中间跨越了一个很重要的环节或界面,这就是陆地,反之亦然。据说,海洋占地球表面面积的70%左右。虽然陆地面积不足地球表面的三分之一,但它却是人类的摇篮,是人类最重要的活动场所。各种地面运输工具、运输器械是人类生活的必需手段。随着技术的进步,现在已经或即将出现两相(栖)航行器、三相(栖)航行器。于是,在陆地上航行自然就是航陆,这是顺理成章的事。

其实,如果我们冷静下来想一想,有了航陆这一名词,在学术上统一描述和处理航行器(运动体)的问题时,就会感到很方便。我们知道,不管一个航行器在什么环境下航行,都服从牛顿运动定律,只是受力的状态不同而已。在建立统一形式的运动体的运动数学模型之后,就可以着重研究在不同环境下航行器的受力问题。当一个航行器从某一种相态过渡到另一种相态时,航行器的运动状态就是其新相态的初始条件。从此,航行器的受力状态也发生了变化,即变换到新相态的受力状态^[3~5]。

目前,国外已有几家公司正在研制飞行汽车^[6~8],下面给出一个实例。据文献[8],美国马萨诸塞州沃伯恩的 Terrafugia 公司于美国东部时间 2009 年 3 月 18 日宣布,已经完成了世界上第一辆飞行汽车的首次试飞(如图 1 所示)。该汽车名为“Transition(飞跃)”,机翼可折叠,翼展约为 8.3m,飞行距离可达 740km,最高时速约为 185km/h,在路面行驶时可变换成汽车模式。由于飞行汽车的翼面是可以折叠的,在地面行驶时,其翼面是多余的,需要折叠起来,以便减少空间,降低空气阻力和升力。同样,在空中飞行时,轮子是多余和有害的,应当把它收藏起来。可见,飞行汽车是一种有人驾驶的、可变形的航行器。可以预见,同飞机一样,飞行汽车的出现必然会带来一系列的空中和地面交通管制问题。

导弹飞行时也有类似的情况。一种飞航式反潜导弹的攻击示意图如图 2 所示。

3. 建立航陆力学的必要性^[4]

一般的航陆(在陆地上航行)问题是非常复杂的,其原因有二:

(1) 陆地航行器的复杂性。在陆地上航行的器械多种多样,如各种汽车、火车和其他轨道交通、坦克和装甲车、拖拉机、电车、摩托车等。汽车中又可以分为许多种类。




(a) 飞行中的汽车



(b) 地面上的汽车

图1 飞行汽车“Transition”

图2 一种飞航式反潜导弹^[9]

(2) 地面状态的复杂性。地面状态可大致分为各种道路(国道、等级公路、乡村公路或土路)、轨道交通(高速铁路、城市地铁、有轨电车、磁悬浮列车等)、无路(普通地面、草地、起伏的丘陵、山地等)。

由此可见,上述复杂性必然会带来航行器运动和控制的复杂性。

各类有人驾驶航陆器的航行问题过去都分别进行过十分详尽的研究,现有许多文献资料可供参考。对于两相航行问题,可以给出适当的、有实际意义的假设。例如,规定所航行的路(水)面状况,而不是在一般的、任意的路(水)面上航行。这样,就可以大大简化所研究的问题,同时,也可能得到具有实际意义的结果。

与飞行力学一样,建立航陆力学时,首先要明确所要研究的问题,对研究对象进行科学的抽象,在牛顿力学指导下,建立研究对象的理论模型;然后,用数学方法建立对象的数学模型;最后,通过编写计算机软件,把数学模型转

变成可以进行直接运算的计算模型(或仿真模型)。

4. 建立统一的航行力学^[4,5]

牛顿力学是建立统一的航行力学的基础。有了航陆概念以后,我们就可以在牛顿力学和维纳控制论的基础上,建立有控航行器的统一的航行力学。

如果把各种不同类型的人造运动器械(运动体)统一称为航行器,那么,就可能比较方便地利用现有的知识来描述它们的运动,建立统一形式的数学模型,为利用现代先进的计算机求解问题奠定坚实的基础。

航行器可以细分为:①航海器。各种在海洋中行驶的航行器,如各种军用和民用的水面船只、军舰、潜艇(潜航器)等。②航陆器。各种在陆地上行驶的航行器,如各种汽车、坦克、装甲车、火车、电车、拖拉机、摩托车等。③航空器。各种在大气层中飞行的航行器(飞行器),如固定翼飞机、直升机、无人航空器(UAV)、火箭、导弹、飞艇、气球等。④航天器。各种在大气层外的空间运动的航行器,如人造地球卫星、航天飞机、飞船、空间实验室、空间站、宇宙探测器等。⑤航宇器。各种在太阳系以外的空间运动的航行器。⑥两相或三相航行器。水上飞机、飞行汽车、水陆两用汽车、水翼船、跨介质航行器等。

当航行器运动于三相(海面、陆地、天空,即海陆空)时,采用统一的坐标系、统一的数学方法,建立统一形式的航行器运动的数学模型,对于问题的计算机求解具有重要的意义。

我们知道,当用矢量和矩阵来表示航行器的运动方程时,不同的力、力矩矢量往往都可以用一些分块矩阵(模块)来表示。在变换到新相态的受力状态后,可用新的模块来取代原方程中相应的模块。借助现有的软件开发技术,可以很好地解决这一问题。不同航行环境下的数学模型的最大区别仅仅在于航行器的受力状态。

总之,在建立理论模型和数学模型时,应当针对具体研究对象的具体情况进行分析。

5. 多相航行器的控制问题

多相航行器,无论是军用的还是民用的,也无论是有人驾驶的还是无人驾驶的,其显著特点是“复杂多变”,与航行器有关的各种因素都在不断地发生变化:①航行环境(陆、海、空、天、宇)在变化;②航行器的外形在变化(如助推器的分离、级间分离、翼面折叠、起落架收放等);③作用于航行器上的外力和力矩在变化;④航行器的组成及其质量、转动惯量在变化;⑤航行器的航行性能和动力学特性(如稳定性、操纵性和机动性)在变化;⑥有关控制系统的结构、参数和性能在变化等。总之,与航行器有关的一切因素都在变化。这种变化通

常分为两种情况(如图 3 所示):①渐变。航行器的参数随航行时间改变而缓慢变化。②突变。航行器的参数随航行时间或航行状态改变而突然变化。




图 3 航行器参数变化示意图

因此,为了保证这种航行器的正确航行或飞行,无论是有人驾驶的还是无人驾驶的,作用于航行器上的控制作用(包括控制力和控制力矩)必须跟随航行时间不断变化。

对于有人驾驶航行器,驾驶员应能根据不同的飞行环境和飞行要求来控制航行器,以便适应变化了的情况。为此,对有关的驾驶员需要进行充分的专业知识培训和实际操作训练。不同的是,无人驾驶航行器必须配备各种必要的航行控制系统,如自动驾驶仪或姿态稳定和控制系統、航行高度保持和控制系统、导航系统和制导系統。

一般,对于航行控制系統的要求是非常苛刻的。在各种航行环境条件下,能够保证航行器自身的安全,保证正确的姿态,能够按照预定的要求正确、可靠地航行,也就是系統必须具备自学习、自组织和自适应的特性和能力。一个航行器是否具备这种“三性”,以及“三性”的完善程度,恰好反映出该航行器控制系统智能化的完善程度。

为了实现“三性”,航行器上应当安装各种各样的传感器,以便给航行器提供各种必要的信息,如有关航行环境的信息、有关航行器上各种设备工作情况的信息、有关航行器本身运动的信息、有关控制系统工作状态的信息、有关航行器与外界联系的信息,以及其他有关航行器的信息等。同时,航行器上还需要一台性能先进的电脑,以便实现各种信息的加工、处理,以及实现各种先进的控制方法、算法。

我们知道,智能控制是自动控制理论和控制技术的最高形态或顶峰。要进一步登天,设计出完全智能化的航行器是很困难的,但随着现代控制理论和技术的发展,我们可以逐步来实现控制系统的智能化(如图 4 所示)。

导弹是一种典型的和特殊的无人驾驶的有控飞行武器,其发展历程如图 5 所示。可见,导弹的智能化发展也是循序渐进的。

通常,现代各式各样的航行器,即使是有人驾驶的航行器(如民航飞机),一般都具有某种形式的自动控制系统。同样,不少无人驾驶航行器(包括导弹),在航行当中往往需要人(操作手、驾驶员)的协助,即采用所谓“人在回路”技术,因而大大提升或改善航行器的航行能力,降低其研制成本。

智能控制与“人在回路”相结合,反映出未来多相航行器是一种开放的、



图4 自动控制的发展历程^[10]

图5 导弹的发展历程

复杂的巨系统，是一种“人工参与、人机结合”的智能化系统。

总之，根据不同用途，未来多相航行器的控制可能存在以下5种模式：
 ①全人工模式。完全依靠人(驾驶员)的控制。
 ②人工为主+自动为辅。以人工控制为主，并附加一定的自动控制装置。
 ③自动为主+人工为辅。以自动控制装置为主，并附加一定的人工干预。
 ④自动、人工并重。可以根据需要随时转换工作模式，有时用自动，有时用人工手动。
 ⑤全自动模式。完全依靠自动控制装置。

总之，多相航行器可能在陆地、水面、水下、空中和空间航行，无所不至。

在解决多相航行器的航行问题时,涉及许多学科,情况复杂,建立统一形式的航行力学可能是一件很有意义的工作。同时,由于要求多相航行器在不同的介质中航行,因而会遇到许多航行控制问题、系统设计和系统集成问题、任务规划问题、航行管制问题等。

多相航行器的显著特点是“复杂多变”,因此,解决以自学习、自组织和自适应为主要特征的智能控制问题具有特殊重要的意义。

参 考 文 献

- [1] 《古代汉语词典》编写组.古代汉语词典.北京:商务印书馆,2002.
- [2] 《现代汉语词典》编写组.现代汉语词典.北京:商务印书馆,2005.
- [3] <http://www.sciencenet.cn/htmlnews/2009/3/217483.html>.
- [4] 关世义.建立统一形式的航行力学.战术导弹技术,2010,(1).
- [5] 庄继德.汽车地面力学.北京:机械工业出版社,1981.
- [6] 谢芸.首辆飞行汽车问世.信息时报,2008-01-02.
- [7] 沈志真.“三栖汽车”畅游水陆空.中国妇女报,2008-02-13.
- [8] 关世义,张克,马洪忠.未来无人飞行器发展面临的飞行力学问题.2010年中国飞行力学学术年会论文集,2010.
- [9] 蔡自兴.智能控制——基础与应用.北京:国防工业出版社,1998.
- [10] 刘桐林.世界导弹大全(修订版).北京:军事科学出版社,1998.

撰稿人:关世义

中国航天科技集团公司第三研究院

微纳米生物学系统状态空间建模

Modeling of Micro /Nano-scale Biological Systems in the State Space

1. 问题背景

21 世纪是生命科学创新引导技术革命的时代。从工业生产中高效便捷的仿机器人的成功应用,到具有超强运算能力的 DNA 计算机概念的提出,针对生命现象的研究成果越来越多地应用于社会经济和生产生活中,对社会发展起到巨大的推动作用。生物科学的研究在 20 世纪的发展过程中,从宏观领域到微观领域的研究取得了长足的进步,而且从系统科学的角度运用信息技术对生物学研究已成为生物学研究的主流方法之一。但是,这种微观生物系统数学模型的缺乏正逐步成为阻碍该学科研究发展的瓶颈。

生物 DNA 计算是近年来根据分子生物学中心法则^[1,2]所描述的基因表达原理产生的一种新的颠覆传统的计算方式,由于其低能高效、快速并行处理信息的特点,已成为现今的一个活跃的研究领域^[3,4]。DNA 计算机已经被证明至少等价于经典的图灵机^[1,5,6]。2002 年,图灵奖获得者 Adleman 博士指出,它们使我们看到了取代电子计算机的曙光,而对它们的研究将把我们引向真正的“未来时代的计算机”。但是, DNA 计算仍然面临着这样的挑战:它缺乏一个可以应用的理论计算模型,导致 DNA 计算的执行具有高出错率。所以,一个好的数学模型将有助于理解 DNA 计算理论,也有助于利用数学工具来解决 DNA 计算问题。

生物基因理论也是当前热点的研究领域,在疾病的基因治疗、优良育种等方面都有着广泛的应用。基因、蛋白质及环境之间的交互作用共同架构了生物体系统的完整功能,利用系统的方法对生物体进行解析,综合观察实验数据来建立合适的数学模型,并利用该模型对真实生物系统的预测来验证模型的有效性,可以揭示出生命所蕴涵的奥秘。而且,基于这种有效的数学模型,对从系统科学的角度出发继续研究基因突变稳定性及诱导控制策略具有积极的推动作用。最后,这种量化模型对基于干细胞的再生医学和纳米医学是极为重要的,其被视作对人类生命具有主要潜在影响的下一次技术革命。

上述问题在生物信息学、分子生物学、基因理论等研究领域是热点问题,利用生化实验方法针对这些问题的研究成果也大量出现。但迄今为止,从国内外的相关文献来看,从系统科学的角度出发,利用基于状态空间的方法来建模

并研究上述生物学过程的做法少见报道。此处建立的这种完善的、公式化的分子生物学过程模型将为数学、系统科学、信息科学同分子生物学、生物化学、基因工程、生物微纳米工程等学科的交叉提供借鉴,为进一步研究打下良好的理论基础。

1996 年,一种简单抽象的分子计算机的数学模型被提出来,该模型的建立为深刻理解 DNA 计算理论打下基础,而且有助于利用数学工具来研究解决 DNA 计算问题^[7]。2006 年,DNA 计算的数学描述被进一步提出,该描述把基于文字表述的 DNA 计算转化成一个数值计算问题,并给出了关于 DNA 杂交完全性的相关判定命题^[8]。2009 年,承接上述的研究工作,一种全新的核酸链碱基序列的数学模型被建立起来,基于该模型,分子生物学中心法则所诠释的蛋白质合成中基因信息的传递过程得到了很好的公式化表述,而且该模型也用于 DNA 序列杂交、RNA 序列自杂交、氨基酸极性及蛋白质二级结构的相关分析^[9]。2010 年,群论模型被用于建模蛋白质合成转录过程中的一步基因突变和多肽链氨基酸内二面角,同时,离散事件动态系统模型也在 DNA 杂交过程分析中得到了应用^[10]。生物计算中另一种重要的模型是隐式马尔可夫模型(hidden Markov model, HMM)。HMM 是一种随机模型,主要用来描述蛋白家族或序域,也用于刻画核酸序列模型。1987 年,HMM 用于遗传连锁图谱的构建;1989 年,该建模方法又被用于序列分析以产生一个 HMM,基于序列谱(谱 HMM)来分析序列的构成和模型。自 20 世纪 90 年代始,HMM 被广泛应用于建模核酸序列和蛋白质,HMM 被用于建模蛋白超家族和蛋白质二级结构的预测,并得到了较以往更高的预测率。HMM 也用于生成多序列比对。实验证明,基于 HMM 的多序列分析方法等同甚至优于其他方法,如包含谱和打分矩阵的全局比对和局部比对方法。显而易见,HMM 作为有效的学习算法模型在计算分子生物学中有许多优势。但是,HMM 要求训练集合要足够大。HMM 也经常含有大量的无结构参数,受其一阶马尔可夫性质的限制,模型无法表示隐状态之间的依赖关系;而且 HMM 不擅长描述完整的生物基因信息传递过程,如分子生物学中心法则描述的蛋白质分子合成过程。

生物信息学这一崭新的研究领域也备受国内学者的关注,最近几年出现了一些颇具学术价值的研究成果。2004 年,模糊 k-最近邻算法被应用于预测蛋白质亚细胞的定位问题。2005 年,创新的基因组扫描计算方法被提出,基于序列和结构排列来检测 miRNA,该课题组又在 2008 年通过对 miRNA 超家族的刻画,研究了脊椎动物中的 miRNA 进化模型,验证了这些调控分子在进化过程中的重要性。2005 年,基于微生物细胞的综合基因调控网络被建模出来,并且在完全均匀混合的多细胞系统中细胞间通信的噪声反应得到研究;在间接耦合的多细胞系统中,细胞通信的生物学似然模型被提出来。2005 年,一种具有输入

和活性膜识别器的二分膜系统的神经膜算法被用于解决线性时间内的多维 0-1 背包问题。次年,该课题组又对神经膜系统的膜的划分进行了研究,运用膜分离的方法来得到指数工作空间,并且证明了可满足性问题和 Hamilton 路径问题在线性或多项式时间内可以通过统一的一族具有划分规则的膜系统确定可解。2006 年,文献挖掘和微阵列分析相结合的网络方法首次被提出,即 LMMA 方法,并给出该方法在血管生成中的应用。2007 年,基于蛋白质编码开放读框和翻译起始位点的统计学模型的一种新的原核基因识别算法被导出。同年,利用多细胞系统,在埃希氏大肠杆菌中普通的噪声信号传递分子穿过一束独立的基因振荡子能够引起同相同步化的论题得到了证明。2008 年,国内学者提出一个计算模型框架,将人类蛋白质间相互作用、疾病显型相似性和已知的基因显型相关性结合在一起得到基因型和显型之间的复杂关系,并开发了专业软件工具来预测和定义疾病基因的优先次序。同年,基于最优搜索理论的一种有限时间资源下的最优模体发现策略和算法实现被给出。还有学者从动力学的观点出发通过研究生物学中似然耦合的影响、多种噪声和外部刺激来阐明多类同步机制,并通过三类基因振子深刻阐明了基因振子的同步化现象。2009 年,基于基因表达数据的一套基因集合分析方法被开发出来以研究主调控因子和它们在时相变化中的调控靶。另外,国内学者还利用高密度的低聚核苷酸微阵列研究了老鼠肝脏进化过程中的基因表达和转录调控,基于研究数据,给出了肝脏进化期间针对基因表达模式、功能参数选择和转录调控的一个全面的分析。

综上所述,高集成、高智能的生物体作为典型的复杂系统越来越受到广大科研人员和工程技术人员的关注,它们所具有的生物学特征为系统科学、信息科学领域内的研究提供了大量有益的借鉴,已经被广泛深入研究的生物计算、人工神经网络、人工智能及机器人等领域的课题和成果都来自于生物科学的启示。但是,针对分子生物学中基因表达完整过程的公式化描述尚未出现,受限于这种数学模型的缺失,很难将系统科学、信息科学领域内先进的理论工具应用于生物科学中热点的研究领域,因此,不能实现真正意义上的学科交叉。

此处提到的问题从严格意义上来说是属于生物信息学的范畴,是从系统科学、控制科学的角度对微纳米量级的生物学系统进行数学建模的研究。在以往对此类问题的研究中,多数是生物化学领域的专家在实验室中经过生化实验来得到系统的文字表述的模型。随着生物信息学的兴起,越来越多的信息科学、系统科学及工程科学领域的学者和研究人员将生命体系统作为研究的对象,尝试通过信息科学和系统科学中的成熟的理论分析工具和先进的控制技术来诠释生命现象并改进生命体系统。因此,这是一项具有创新性和深远意义的研究。

2. 问题描述

在这个问题的研究中,我们希望给出一种分子生物学对象的系统状态空间表述形式,基于这种数学模型表述,就可以将目前先进的自动化理论和控制技术结合生物化学手段来实现对微观生物系统的研究。遵循由浅入深的原则,我们先将分子生物学中最简单的核酸链及其氨基酸作为数学建模的对象,建立核酸链的状态空间数学模型。但是,由于细胞核中这种核酸链模型都是以杂交螺旋结构存在的,因此,单纯的单链数学模型还不能够深刻刻画它的物理化学性质,必须将它们的化学结构也考虑进其数学模型中。例如,它们的互补碱基配对情况、氢键位置、形成“茎区”、“单链”及“环”(包括“分支环”、“发夹环”、“内环”和“凸起”)的情形,以及新陈代谢中的基因突变情况。

我们另一方面关注的系统对象是与合成蛋白质分子二级结构相关的多肽链上氨基酸内沿主脉的扭转角的数学建模问题。事实上,在生物化学实验室方法对该问题的研究中,已经将扭转角的重复值用角度描述出来,虽然这种角度描述可以很好地反映该多肽链与以后生成的蛋白质分子二级结构的关系,但这种角度描述为多肽链上每一个氨基酸内基于一个假想平面扭转得到的,每个氨基酸对应一个假想平面,这就使得没有一个统一的坐标系框架,在该框架之下可以建立某种坐标定义可以描述多肽链上所有氨基酸内扭转角的位置。这个工作使得扭转角重复值和生成蛋白质分子二级结构的对应关系更加明晰,有利于用确定性研究方法对蛋白质分子二级结构进行预测。

从上述描述中可以看出,无论是 DNA 计算,还是蛋白质二级结构预测,都离不开完备的数学理论模型。但是,目前来自生物实验手段的模型显然不能够满足生物信息学研究的需要。作为微观生物学系统,分子生物学系统具有复杂性、多样性和动态性的特点。单针对最简单的核酸单链的状态空间数学建模而言,就存在着巨大的挑战性。

图 1 所示是一个核糖核酸单链自杂交螺旋结构的示意图。RNA 链条上有大量的碱基和自杂交形成的配对碱基之间的氢键结构。若在状态空间中建立其模型,要求该模型能够反映其分子结构与空间位置,因此,如何建立该分子空间基坐标系的定义,以及如何遵循尽量简单的原则给出状态空间原点的定义,以及基于该定义的状态空间原点,给出每一个碱基、氢键所对应的位置坐标是一个困难的问题。而且,由




图 1 RNA 单链自杂交发夹状螺旋结构图示

于受到温度、压力、体内外环境等因素的影响,该 RNA 自杂交结构并不是以唯一的形式存在于状态空间中的,而是要在不同的结构之间进行动态的切换。所以,建模过程中同时需要兼顾其切换状态的空间定义及切换动态特性的描述。再者,由于核酸分子的存在性不同于一般的物理系统,其存在是通过新陈代谢来实现的。但是,在新陈代谢过程中,基因突变时有发生,因此,针对核酸链上突变部位的碱基的重新定义也是值得思考的问题。

由蛋白质分子合成的生物学过程也可以知道,通过 DNA 复制、RNA 转录及从 tRNA 到多肽链的翻译过程可以得到多肽链,而且经过状态空间中的扭曲和多条多肽链生化聚合反应,可以形成蛋白质宏分子。其中,多肽链中氨基酸内沿其主脉的扭转角重复值是决定其生成的蛋白质分子二级结构的重要因素。由于一条多肽链上的氨基酸数量成百上千,对多肽链单链的建模也将是一个重要而有意义的研究问题。设立多肽链的状态空间坐标系,给出各个氨基酸内扭转角重复值在统一框架下的描述是非常困难的事情(如图 2 所示)。




图 2 多肽链氨基酸内沿主脉扭转角图示

3. 问题的研究意义

一旦这种状态空间中的微纳米生物学系统模型建立起来,将为以后更加深刻地理解 DNA 计算、蛋白质二级结构的生成问题、DNA 计算过程中由于模型缺乏导致的计算高出错率问题的解决提供坚实的理论支持。更重要的,这种数学模型作为纳米生物科学、生物学和医学中许多前沿研究领域的数学基础,将使得量化基因治疗、个体化用药、最优受控给药及再生医学等研究迈进重要的一步。

参 考 文 献

- [1] Crick F H C .On protein synthesis .Symp .Soc .Exp .Biol .,1958 ,Ⅺ :139—163 .
- [2] Crick F H C .Central dogma of molecular biology .Nature ,1970 ,227 :561—563 .
- [3] Cox J P L .Long-term data storage in DNA .Trends in Biotechnology ,2001 ,19 :247—250 .
- [4] Mitchison G J ,Durbin R M .Tree-based maximal likelihood substitution matrices and hidden

- Markov models .J .Molecular Evolution ,1995 ,41 ;1139—1151 .
- [5] Eddy S R .Multiple alignment using hidden Markov models .ISMB ,1995 ,3 ;114—120 .
- [6] Dresselhaue M S ,Dresselhaus G ,Jorio A .Group Theory :Application to the Physics of Condensed Matter .Berlin/Heidelberg :Springer ,2008 .
- [7] Zhang M J .On constructing a molecular computer //Lipton R ,Baum E .DNA based Computers .Providence ;Amer .Math .Soc . ,1996 ;1—21 .
- [8] Zhang M J ,Cheng M X ,Tarn T J .A mathematical formulation of DNA computation .IEEE Trans .on Nanobioscience ,2006 ,5(1) ;32—40 .
- [9] Gao R ,Yu J Y ,Zhang M J ,et al .A mathematical formulation of the central dogma of molecular biology //Zhang M ,Xi N .Nanomedicine :A System Engineering Approach .Singapore ;Pan Stanford Publishing Pte .Ltd ,2009 ;81—116 .
- [10] Gao R ,Yu J Y ,Zhang M J ,et al .Systems theoretic analysis of the central dogma of molecular biology ;Some recent results .IEEE Trans .on Nanobioscience ,2010 ,9(1) ;59—70 .

撰稿人：谈自忠¹ 高 瑞² 张明君³

1 清华大学信息科学与技术国家实验室

2 山东大学控制科学与工程学院

3 美国田纳西大学纳米生物系统与生物模拟实验室

飞行器大包线鲁棒飞行控制

Robust Flight Control for Large Flight Envelope

1. 难题的来龙去脉及重要性

在 20 世纪 90 年代初, 控制科学界基本上达成了一个共识, 即控制科学的发展必须以控制工程的问题为背景, 以信息科学和数学作为主要研究手段来解决控制工程问题^[1]。“上九天揽月”一直是人类的“久有凌云志”, 然而, 生物的进化并未让人类长出飞翔的翅膀, 却让人类催生了超越翅膀的灵感: 借助飞行器实现梦想。起初, 人类只能制造出自己操纵为主、自动驾驶仪为辅的飞行器。随着人类改造自然的动力, 人类可以按照自己的意愿制造出无人飞行器(UAV)自主飞行。在 21 世纪, 人类制造出了多种用途的飞行器, 以便在飞行高度和飞行马赫数刻画的大飞行包线上实现自己的梦想, 如图 1 所示。




图 1 大包线飞行

然而, 人类在一次次认识自然、征服自然的过程中会面临着诸多的挫折, 而这些挫折往往会使人类的认识得到升华。21 世纪初, 最令人震惊的空难莫过于波兰总统卡钦斯基的专机图-154 于 2010 年 4 月 10 日在俄罗斯斯摩棱斯克的失事事件, 专机上共有 96 人, 其中, 波兰代表团高官 88 人。调查人员分析失事原因是: 在天气条件不佳的情况下, 波兰总统专机在降落时受到外物干扰, 导致飞机驾驶员对飞机失去控制。这样的空难在人类进化的漫漫长河中绝不会是句号, 但人类也认识到, 飞行器在大飞行包线中受到的气动力和气动力矩是受客观规律决定的, 无论飞行控制器如何发挥作用, 都只能遵循而不能违背这些规律。经典的刚体力学知识告诉人们, 飞行器在空间中的运动总可分解为其质

心的运动(航迹运动)和相对其质心的姿态运动。人们在设计特定功能控制器完成指定飞行任务时,要考虑这两种运动之间的相互影响,并进行有效综合。以飞行器做盘旋任务为例,如图 2 所示。空速向量与飞行器纵轴如果不能重合协调转动就会产生侧滑,而侧滑角的出现将使得飞行器受到的阻力增大,飞行品质变差,但人们只需要实现飞行器滚转角的姿态控制,就能使飞行器的航迹完成盘旋动作,盘旋的半径完全由滚转角决定。由于飞行姿态的不同会引起气动力、气动力矩等分布的差异,而考虑到诸多外在因素时,姿态角、姿态角速率等的精确测量本身在捷联惯导领域就是一项十分困难的任务,状态测量不准将直接影响到飞行控制的品质。




图 2 飞行器协调转弯受力分析

这就给航空、航天领域的研究人员提出了一个问题:如何在飞控系统面临诸多不确定性和外部干扰的情况下确保飞行器的飞行品质,实现鲁棒飞行控制?飞控系统的不确定性主要来自以下两个方面:①不可预测的系统外部扰动,如传感器高频测量噪声、飞行故障发生时的不可预测因素等;②由于飞行器气动数据不精确带来的模型建模误差、转动惯量测量误差、飞行器重心改变等内部可控因素。飞控系统的飞行品质涉及的大包线纵向静稳定性、沉浮稳定性、轨迹稳定性等多种稳定性能在多种不确定性下如何得到保证?

2. 难题解决现状

正是鉴于大包线鲁棒飞行的重大意义和广阔应用前景,美、俄和欧洲各国竞相开展相关技术的研究,取得了较大的进展。针对该问题比较认可的做法是采用内、外环的混合控制方案,如图3所示。内环的主要作用体现在消除飞行器本身的非线性耦合效应,在内环采用反馈线性化或者反演算法等机制的基础上,外环对飞行中遇到的不可抗因素进行补偿,这涉及多目标之间的折中、可控控制。现阶段,主要有以下两种应对飞行器不确定性的解决方案:




图3 内、外环的混合控制方案

飞行器模型可用如下一般非线性系统来描述:

$$\begin{aligned}\dot{x} &= f(x) + g(x)u \\ y &= h(x)\end{aligned}$$

式中, x 为飞行器状态; u 为飞行器控制输入; y 为飞行器输出。

一种方案是外环采用鲁棒控制算法来抑制不确定因素。Sadraey^[2]于2006年在无人飞行控制器的内环回路采用时标分离的方法对全包线模型进行了反馈线性化,外环采用了 H_∞ 环路成形的方法来达到期望的抑制干扰的目的。Malekzadeh^[3]于2009年提出了采用 μ 综合来克服反馈线性化带来的非最小相位和舵机幅值饱和问题,并将该方法用于非线性柔性航天飞机的姿态控制中。Paw^[4]借助于线性分式变换(LFT),在考虑参数不确定因素情况下分别设计了纵向、横侧向通道的鲁棒控制器。Marcos^[5]进一步比较了LTI、增益调度和LPV在空间载入式飞行器中的建模应用。以上这类控制策略将包线内的飞行器视为一个由标称模型和模型不确定性组成的系统族,在外环采用鲁棒控制算法,该系统族能

够满足期望的性能指标。虽然飞控系统的整体稳定性较易实现,但每个具体飞行航路点的飞行品质已大打折扣。

另一种方案是采用自适应控制算法以实时逼近诸多不确定性。Bijmens^[6]于2005年采用神经网络来补偿反馈线性化纵向直升机模型带来的误差。Sonneveldt^[7]于2007年利用反演算法设计了F-16/MATV的跟踪迎角、滚转角速率和飞行速率的控制律,采用了B样条神经网络自适应更新逼近不确定的气动力和气动力矩。Kaminer^[8]于2010年设计了无人飞行器的 L_1 自适应航迹跟踪商用自动驾驶仪。Nguyen^[9]针对部分受损飞机设计了间接自适应学习算法和回归最小二乘学习算法。自适应学习算法实施的理论基石在于神经网络和模糊算法等对未知不确定性因素的万能逼近性能,在理论上能够保证时间趋于无穷大时逼近值是趋于真值的,然而飞行器在大包线、大速域运动时,有限时间内的逼近性能将会直接影响到飞控系统的稳定性。因此,人们有必要着眼讨论有限时间稳定性和不确定性估计。

3. 难题的主要困难所在

由于各种鲁棒算法和自适应算法只能够在标称模型的摄动范围内满足飞行品质,但在大飞行包线下飞行器的气动参数变化剧烈,飞控系统的稳定性与鲁棒性均难以保证,目前的研究现状只能局部改善而不能根本解决该难题。针对该难题当前的解决策略是对飞行包线进行局部分割,包线间进行插值切换,而如何确保飞行品质和系统稳定性仍是一个没有得到很好的解决方案,具体难点如下:

难点一:当飞行器由于外部不可抗力使传感器设备受损情况下,飞行状态无法精确度量,能否用数学推导的方法构成解析余度来弥补硬件余度的欠缺?

难点二:现在自适应补偿不确定性的算法过于单一,局限于神经网络和模糊算法,而且只能针对飞行包线的小范围摄动,针对大飞行包线难以保证全局的稳定性。能否拓宽设计思路?有学者引入了扩张状态观测器来实时观测扰动。

难点三:转换设计思路,多学科融合,在内环设计的基础上,借鉴数学机械化的最新成果,能否采用多对象同时镇定的分析思路解决大飞行包线的鲁棒控制问题?由于飞行包线的不同阶段可以等效为多个不同的被控对象,完全有可能用单一控制器实现对多对象的镇定,从而实现优秀的飞行品质。

难点四:提出的算法如何与飞控工程实践结合?目前很多的研究成果,如针对F-22的前馈和反馈增益的特征结构配置和针对F-35的主控制模态的动态逆,均尚处于预研阶段,在飞控工程实践中采用的仍多是传统的增益调度控制策略。

总之,该领域的研究工作任重而道远,亟须在理论和应用中取得突破性成果。

参 考 文 献

- [1] 黄琳,段志生,杨莹.现代飞行器控制的几个科学问题.科技导报,2008,26(20):92—98.
- [2] Sadraey M,Colgren R.Robust nonlinear controller design for a complete UAV mission//AIAA Guidance,Navigation and Control Conference and Exhibit,Colorado,2006.
- [3] Malekzadeh M.Robust nonlinear tracking control design for flexible spacecraft//AIAA Guidance,Navigation and Control Conference,Chicago,2009.
- [4] Paw Y C,Balas G J.Uncertainty modeling,analysis and robust flight control design for a small UAV system//AIAA Guidance,Navigation and Control Conference and Exhibit,Hawaii,2008.
- [5] Marcos A,Bennani S.LPV modeling,analysis and design in space systems;Rationale,objectives and limitations//AIAA Guidance,Navigation and Control Conference,Chicago,2009.
- [6] Bijmens B,Chu Q P,Voorsluijs G M,et al.Adaptive feedback linearization flight control for a helicopter UAV//AIAA Guidance,Navigation and Control Conference and Exhibit,San Francisco,2005.
- [7] Sonneveldt L,Chu Q P,Mulder J A.Nonlinear flight control design using constrained adaptive backstepping.J.Guidance,Control and Dynamics,2007,30(2):322—336.
- [8] Kaminer I,Pascoal A,Xargay E,et al.Path following for unmanned aerial vehicles using L_1 adaptive augmentation of commercial autopilots.J.Guidance,Control and Dynamics,2010,33(2):550—564.
- [9] Nguyen N,Krishnakumar K,Kaneshige J,et al.Flight dynamics and hybrid adaptive control of damaged aircraft.J.Guidance,Control and Dynamics,2008,31(3):751—764.

撰稿人：易建强 仇立伟
中国科学院自动化研究所

脑机接口：人类与机器的对话

Brain-Computer Interfaces：Where Human and Machine Meet

Reeves 主演的奥斯卡获奖影片《黑客帝国》带来了人们对未来互联网技术的无限遐想；电影《阿凡达》中的 3D 效果引发了人们对电影发展的热烈讨论；DiCaprio 主演的《盗梦空间》激起了人们对梦境探索的新一轮热潮。科幻迷们对上述经典作品喜爱备至，而细心的人们就会发现这几部科幻电影中的情节都与人类的思维密切相关。网络黑客 Neo 的思维可以在虚拟网络世界生存并完成各种艰巨的任务；双腿瘫痪的前海军陆战队员 Sully 的意识可以进驻到“阿凡达”中；商业间谍 Cobb 可以潜入别人梦中，窃取他人的思想甚至植入思想。

有人会说这些科幻作品中的典型代表距离现实生活过于遥远。而实际上，在过去几十年间，科幻作品中描述的一些技术陆续成为了现实。脑机接口 (brain-computer interfaces, BCI) 技术是目前世界各领域的科学家们研究的一个热点，这项技术或许可以帮助我们当中的某些人成为上述科幻电影中的主角。

脑机接口技术形成于 20 世纪 70 年代，是一种在人脑与计算机或其他电子设备之间建立的不依靠大脑输入、输出通道 (如外周神经和肌肉组织等) 的通信与控制系统^[1]，是一种全新的人机接口方式。

联系到上述科幻电影，脑机接口就是 Neo 的思维登录虚拟网络世界的通道；也可以认为是 Sully 的意识进驻“阿凡达”的专用连接设备；通过这个接口，Cobb 就可以窃取别人潜意识中有价值的信息和秘密。当然，这些说法也许只是科幻迷们的一厢情愿，更为恰当的说法是：脑机接口技术是目前广泛应用的人机接口技术的全新方式。

人机接口是计算机系统和用户之间进行交互和信息交换的媒介，如显示屏、扬声器与麦克风等。2007 年 3 月，互联网之父 Cerf 接受中国媒体采访时谈道，目前互联网的边界就是人机接口，即音、视频是目前人们与互联网交互的主要途径。Cerf 还谈道，未来科技的发展或许可以通过植入记忆芯片与互联网相连的方式来修复人的感官功能，这里就包含了脑机接口的含义。

脑机接口与人机接口的区别在于：对于人机接口，来自计算机系统的数字化信息，首先必须转化为模拟信号，再通过光波和声波传输，被人们的感觉器官所接收并转化为神经电信号，通过外周神经组织传输到大脑；而对于脑机接口，来自计算机系统的信息不用再借助传统的大脑输入、输出通道，而直接进入人体的神经系统，从而实现真正意义上的“人机合一”。那时，互联网的边界

就是人类的大脑，我们也就初步具备了成为 Neo 式网络黑客的能力。

目前，脑机接口技术的发展还不能实现真正意义上的“人机合一”，但研究者们已经实现了人与计算机系统的直接连接，替代大脑传统的输入输出通道。由图 1 所示脑机接口系统的结构可以看出，脑机接口系统是由使用者和机器构成的一个闭环系统，除使用者外，脑机接口由以下几个部分组成^[2]：




图 1 脑机接口系统框图

(1) 信号采集模块。信号采集的功能是提取脑电信号，对其进行预处理以提高信号质量，然后转换成数字信号，提供给信号处理模块。利用现有医疗设备的无创式信号采集是当前的主要方式，如脑电图(EEG)、脑磁图(MEG)及功能核磁共振成像(fMRI)等。植入式微电极也是当前脑电信号采集的研究热点。

(2) 信号处理模块。脑机接口信号处理分为特征提取和特征转换。目前，人类还不能解读复杂的思维过程，而且大多数脑机接口并非解释自发脑电信号。因此，特征提取只是设法提取人为刺激产生的、对应特定简单思维的脑电信号的特征，再通过特征转换对大脑活动参数分类，输出外设控制信号。这部分主要通过软件算法来实现。

(3) 外设与接口部分。这部分接收信号处理模块发出的控制信号，实现对外设的操作和对使用者的反馈，主要包括控制接口、设备控制器、设备、操作环境和反馈设备。

实际上，电影《阿凡达》中 Sully 用思维控制没有自我意识的生物体“阿凡达”的过程完美地体现了脑机接口的概念和组成。Sully 作为使用者，通过“睡

眠舱”将自身思维与“阿凡达”相连接，可以认为电影中的“睡眠舱”包含了信号采集、处理及接口的功能。现实中，脑机接口的外设主要是屏幕光标、机械臂或人形机器人等。电影中给予了人们极大的想象空间，将人造生命体“阿凡达”作为外设，其感觉器官接受的信息反馈给 Sully，使其重新拥有了奔跑的感觉，由此实现了脑机接口的闭环控制。

脑机接口技术早期的研究者们通过近三十年的研究才逐渐得出了上述脑机接口的定义，并对其基本组成达成了一致意见。其实，自 1929 年 Berger 发现脑电信号 (EEG) 以来，人们就曾设想利用其来进行通信和提供控制^[1]。20 世纪 70 年代，基于生物控制理论的脑机接口技术逐渐成为人们的讨论热点，在此领域，最为成功的早期研究组织是美国加州大学洛杉矶分校 (UCLA) Vidal 博士带领下的 BCI 实验室。

Vidal 和其他几位科学家的早期研究揭示了脑机接口在通信上与传统的神经信号控制技术的区别，即脑机接口通信不依赖于肌肉组织的控制，这正是目前脑机接口快速发展的主要原因，即脑机接口具有强大的潜力，可以给严重的运动及交流障碍患者 (如肌萎缩性侧索硬化、脑干或脊髓损伤) 提供一种新型的运动和交流增强技术，以实现运动及交流功能的康复治疗，使人工智能义体的梦想进一步接近现实。其次，脑机接口技术在治疗神经疾病方面存在广阔的前景，很多与中枢神经系统有关的疾病，如小儿麻痹症、帕金森综合征、顽固性慢性疼痛和癫痫病，用传统的治疗方法无法痊愈，而神经刺激方法是一种很有潜力的疗法。再次，作为探索神经网络的有力工具，脑机接口技术为神经生理学的发展提供了可靠的实验手段，推动了神经形态工程学的发展，使神经生理理解码人脑思维过程成为可能。最后，脑机接口技术存在广阔的市场前景，具有可观的潜在经济价值。

基于上述观点，人们对脑机接口技术进行了进一步的研究^[3]。进入到 20 世纪 90 年代，国际上研究脑机接口算法并系统地解读神经信号以用于控制的包括德国 Tübingen 大学的 Wolpaw、美国 Brown 大学的 Donoghue、美国 Pittsburgh 大学的 Schwartz、加州理工学院的 Anderson、美国 Duke 大学的 Nicolelis 及 Wadsworth 中心。国内最具代表的是清华大学，研究者深入分析了稳态视觉诱发电位的特征和提取方法，设计了一种具有高传输速率的脑机接口系统，他们成功实现了由两名戴着特殊电极帽的学生用“思维”控制机器狗踢球的过程 (如图 2 所示)。

最近十年，脑机接口技术得到了较为迅速的发展，目前正受到世界范围内更多的关注。1995 年，研究脑机接口技术的团体和组织还不超过 5 个，而现在已经发展到数以百计。国外研究者主要来自美国、德国、奥地利、意大利、日本等，国内研究机构目前有清华大学、重庆大学、上海交通大学、华中科技大学、天津




图2 清华大学的脑机接口系统

大学等。在国际上，众多科技博客网站将脑机接口相关技术列为未来十大科学技术之一。在我国“十一五”期间，脑机接口技术已被列入国家科技支撑计划等重点项目。脑机接口技术国际会议已经分别于1999年、2002年、2005年和2010年举行了4次，关于脑机接口在信号处理方面的数据竞赛已经举办了多次。

根据近几届脑机接口技术国际会议报告，脑机接口技术可以分为非侵入式、部分侵入式和侵入式三类，其划分的依据是所采集生物电信号在大脑中的发生部位^[4]。非侵入式脑机接口技术通常利用头皮电极采集的 EEG 信号作为信息载体；部分侵入式脑机接口一般将传感器植入到颅腔内，但位于大脑皮层外；而侵入式脑机接口采用的电极植入技术记录大脑皮层内的神经信号（如图3所示）。




图3 脑机接口技术的分类

非侵入式脑机接口技术的研究者使用脑电图作为脑机之间的接口在人体上进行了实验,由于具有良好的时间分辨率、易用性、便携性和相对低廉的价格,这类脑机接口已得到深入研究。非侵入式脑机接口与人体通信的装置通常是一个类似泳帽的“电极帽”,透过颅骨提取的脑电信号相对微弱。因此,信号的空间分辨率不高,对噪声敏感,很难确定发出信号的大脑功能区。此外,使用者在工作之前要进行大量的、长时间的训练。这方面研究的一个典型例子是德国 Tübingen 大学 Birbaumer 于 1990 年代进行的项目,该项目利用头皮电极记录的皮层慢电位(SCP)为瘫痪病人设计了名为 Thought Translation Device (TTD) 的脑机接口设备。经过训练,瘫痪患者能够成功地用皮层慢电位偏移对字符进行分类选择。

非侵入式脑机接口的信号记录方法也可以是脑磁图及功能核磁共振成像。美国加州大学伯克利分校的研究人员通过电脑模型和功能核磁共振成像扫描仪成功地演示了“读心术”^[5]。研究人员对正在观看视频的志愿者的脑神经系统活动进行了解码,并将其观看到的内容显示在计算机屏幕上。科学家表示,这种方法可以将犯罪现场目击者看到的情况在计算机上模拟出来,以推进案件的侦破。这项研究可能也会帮助科学家在某天制造出能够解读人类梦境和控制人类思维的计算机(如图 4 所示)。



图 4 美国加州大学伯克利分校的“读心术”

部分侵入式脑机接口技术的空间分辨率优于非侵入式,但不如侵入式脑机接口,其另一优点是引发免疫反应和愈伤组织的概率较小。皮层脑电图(EECoG)的技术是部分侵入式脑机接口的主要记录方式,其基础和 EEG 相似,但其电极直接植入到大脑皮层上、硬脑膜下的区域。华盛顿大学的 Leuthardt 和 Moran 是最早在人体试验 ECoG 的研究者。根据报道,一位少年男性病人可以通过其

基于 ECoG 的脑机接口玩电子游戏。

侵入式脑机接口获取的神经信号的质量比较高，其缺点是容易引发免疫反应和愈伤组织，进而导致信号质量的衰退甚至消失。美国 Brown 大学植入式脑机接口研究成果被《探索》杂志认为是 2006 年七大技术发现中最重要的技术发现。可见，侵入式脑机接口技术的研究也逐渐成为人们关注的热点。2008 年，美国 Duke 大学神经学专家 Nicolelis 博士进行了一次实验，一只在美国北卡罗来纳州的母猴凭借其大脑的思维活动，成功地指挥一个日本京都的机器人在跑步机上行走。实验中，研究人员利用高速网络，将脑中植入多个电极的母猴的神经元活动传给远在日本京都的机器人，从而实现母猴与机器人在各自跑步机上的同步行走。通过屏幕，母猴看到机器人的脚部运动情况，并认为是自己的脚部运动。特别值得一提的是，当母猴的跑步机电源关闭后，它仍然把屏幕中机器人的脚当成了自己的一部分，它的脑电信号指挥机器人继续走了 3 分钟(如图 5 所示)。




图 5 美国 Duke 大学的“思维控制运动”

上述三种类型的脑机接口技术大多还处于实验室阶段,但目前在感官康复方面已经存在一定的应用和商品化产品。实际上,简单的接通大脑的神经修复装置已经存在于成千上万人的颅骨内。听觉障碍的患者植入人工耳蜗,把麦克风采集到的声音转化为刺激听觉神经的信号,从而产生人工听觉。

1978年,Dobelle利用大脑皮层电极植入技术,帮助一位男性盲人成功实现了光幻视。2002年,Naumann成为第一位接受Dobelle第二代皮层视觉假体植入的病人。接受植入后不久,Naumann就可以自己在研究中心附近慢速驾车行驶。2004年为止,该研究团队已经为16位失明病人植入了初级视皮层视觉假体。

Donoghue及其同事创立了Cybernetics公司,宗旨是推动实用的人类脑机接口技术的发展。2005年,Cybernetics公司获得美国FDA批准,对9位病人进行了第一期的运动皮层脑机接口临床试验。四肢瘫痪的Nagle成为了第一位用侵入式脑机接口来控制机械臂的病人,他能够通过运动意图来完成机械臂控制、电脑光标控制等任务。

经过近四十年的努力,脑机接口的研究取得了不少成果,但该领域尚处于发展的初期。对脑控假肢热火朝天的宣传掩盖了人们对神经系统工作机制认识的匮乏。事实上,人类尚未完全认识自身,更不用说极为复杂的大脑及思维意识活动。加州理工学院的神经科学家Andersen说:“我们对于高级认知活动的大脑回路几乎一无所知。”

当然,脑机接口当前遇到的最大挑战还是来自技术。在Gartner公司2009年公布的技术成熟度曲线上,脑机接口的成熟应该是十年之后的事情。因此,从人机接口到脑机接口,注定还有漫长的路要走。大多数脑机接口技术仍然处于实验室阶段,要进入到成熟的应用阶段,还需要在以下各个方面进行更加深入的探索和研究^[6]:

(1) 多学科的协作。目前,对脑机接口系统形成的一致性认识是:这是一门多学科间的研究领域,涉及临床学、工程学、神经科学、心理学等众多学科。因此,学科间的互相协作对于脑机接口的发展起着重要作用。

(2) 脑电信号的采集。从脑机接口技术发展角度分析,ECoG、大脑皮层内微电极(LFPs)等有创型传感器的潜力较大,它可以提供更精确的信号、更稳定的长期记录和临床安全性,但目前该技术实现困难、有创伤,因此,大部分的研究还处于动物实验阶段。

(3) 实现脑机接口的闭环控制。同时实现脑电波对机械的运动控制和控制结果对大脑的反馈是脑机接口研究的一个重要方面,但人体对反馈信号的读取还存在很大问题,失败的反馈可能改变使用者的精神状态,人们对脑机接口反馈的执行方式还存有争议。

(4) 提高脑机接口的通信传输效率。脑机接口技术的一个重要特征是系统的整体通信速度。目前，脑机接口系统整体信息传输率过低，通信速度慢，对于频率 100~10kHz 的神经元动作电位来说太过低下，而且误差率高，难以应用于实际中。

(5) 优化信号特征提取和转换算法。信号分析和处理是每个脑机接口系统的核心部分，特征提取和转换的常用算法有多种，其中，应用最广泛的是神经网络算法。由于受神经科学发展的限制，人们对脑电信号的理解还相当粗浅，而且不同采集方式获取的信号特征不同，因此，算法的自适应性是关键。

(6) 实时性。由于脑电信号的复杂性和非平稳性，实时处理脑电信号对信号处理模块是一个挑战。据 2006 年的统计数据，只有 13% 的脑机接口系统实现了外设的实时控制。出于应用的考虑，实现脑机接口的在线功能是很迫切的。

(7) 增强脑机接口系统的稳定性和安全性。不同个体的差异及个体生理和心理因素的改变，降低了脑机接口系统应用精度，不同个体与接口系统的相互适应性存在很大的差异，这种差异来自人体的排异等生理反应。

(8) 系统评价准则和标准化。目前，特征转换算法、使用者训练规范和其他重要的操作方面缺少统一的评价和标准化措施。在 2005 年的第三次脑机接口会议上，与会者一致认为脑机接口系统的评估和比较需要一个标准客观的评价方法。对这些方面进行标准化会大大促进脑机接口的发展。

此外，脑机接口技术也带来文化、隐私方面的挑战。出人意料的是，在美国，人工耳蜗最大的反对群体却来自聋人社区中自幼失聪的人群，他们认为人工耳蜗影响到了聋人文化。而遥远的未来，更大的挑战则来自隐私方面。当设备接收的灵敏度可以提高到近距离接收脑电波的水平，人们可以无限制地去阅读他人的思维，甚至传送到互联网上，其引发的问题将更为严重。

目前，大部分脑机接口的研究集中在运动康复领域，即用脑电信号控制人工假肢或康复机器人。通过脑机接口系统，伤残人士可以对多自由度假肢、外动力矫形器、护理机器人等运动康复辅助器械进行实时控制，帮助其进行运动功能重建和生活自理。近年来，人们提出了更多的脑机接口的发展方向，新型的电子游戏就是其中一个。当前的电子网络游戏依靠玩家对鼠标、键盘或操纵杆的操作，如果能够只靠“意识”就加入到游戏当中，一定会成为一种更具吸引力的娱乐方式。脑机接口技术在军事领域也有很大的应用前景，利用脑机接口技术可以使飞行员能够在战术决策、瞄准目标、发射武器等方面具有更快的响应速度，其潜在的应用价值还在于：人们可以通过训练动物驱动微型机器人，深入恶劣环境中去搜寻目标，完成扫雷或救援等危险工作。当然，还有人像 Cerf 那样提出了更为大胆的想法，计划把互联网和大脑中负责记忆形成的神经结构——海马直接相连来增强人类的记忆，就像《黑客帝国》里那样把直升机

驾驶手册“下载”到大脑中。

我们相信随着对上述问题的不断探索和逐渐解决,脑机接口的应用会逐步走出实验室,满足工业、医疗及普通家庭的需求,有朝一日,我们在科幻电影中所看到的技术也会为我们亲身所体验。

参 考 文 献

- [1] Wolpaw J R, Birbaumer N, Heetderks W J, et al. Brain-computer interface technology: A review of the first international meeting. *IEEE Trans. on Rehabilitation Engineering*, 2000, 8(2): 164—173.
- [2] Cincotti F, Bianchi L, Birch G, et al. BCI Meeting 2005-Workshop on technology: Hardware and software. *IEEE Trans. on Neural Systems and Rehabilitation Engineering*, 2006, 14(2): 128—131.
- [3] 杨帮华, 颜国正, 丁国清, 等. 脑机接口关键技术研究. *北京生物医学工程*, 2005, 24(2): 308—310, 315.
- [4] Wolpaw J R, Loeb G E, Allison B Z, et al. BCI Meeting 2005-Workshop on signals and recording methods. *IEEE Trans. on Neural Systems and Rehabilitation Engineering*, 2006, 14(2): 138—141.
- [5] 高楠, 卓晴, 王文渊. 一种新型的人机交互方式——脑机接口. *计算机工程*, 2005, 31(18): 1—3.
- [6] McFarland D J, Anderson C W, Muller K R, et al. BCI Meeting 2005-Workshop on BCI signal processing: Feature extraction and translation. *IEEE Trans. on Neural Systems and Rehabilitation Engineering*, 2006, 14(2): 135—138.

撰稿人: 李醒飞

天津大学精密仪器与光电子工程学院

测量及仪器科学的发展和面临的科学难题

The Development and Challenge of Measurement and Instrument

1. 测量及仪器与我们的生存、发展息息相关

测量是科学与技术，仪器是工具。测量及仪器在认识世界、改造世界、保证我们社会的安全和秩序等重要方面一直起着不可替代的作用。

社会的发展进步与测量手段的发展密切相关。在原始社会，人们学会了使用工具，随着生产的发展与交换的产生，又发明了度量衡。农耕时代，人们为了不违农时，学会了天文观测并形成了农历，同时发明了原始的天文观测仪器。人类社会经过工业革命发展到今天的信息化社会，测量及仪器科技的水平已经成为了一个国家物质文明程度的标志。

测量行为是人们实践科学思维的基础。门捷列夫 100 年前就指出，没有测量，就没有科学。因为科学本身是证实的过程，是定量分析的过程。科学探索的经过是获取数据、提出假说、验证假说以获取新知。获取数据与验证都离不开测量。

以用途、目的区分，我们也可以将测量分为两类：一类是为了认识世界，进行科学探索所作的测量，如光速的测量、重力波的测量等，这些测量与基础研究有关，是科研人员的工作；而另一类则是在我们日常生产、商贸、生活中每时每刻都在进行的测量，包括物体的测量(如位置、速度、长度等)、物态的测量(如温度、压力等)和物质的测量(如浓度等)。一般是工程技术人员和管理工作者乃至寻常百姓的日常事务。

2. 测量及仪器科学的水平决定了国家的竞争力和安全

测量及仪器科技水平决定了国家的竞争力和安全，这可以从基础理论水平、经济实力和国防实力这三个方面分析说明。

从基础理论水平的角度看，表 1 列举的是部分通过测量和观察完成的科学发现，或者是将物理法则创新地应用到测量方法或仪器中而获得诺贝尔奖的情况^[1]，这些事实说明了科学探索与测量及仪器的关系。验证科学假说必须设计出相应的测量方法，而且还必须制造出精度、性能满足要求的测量仪器或实验装置来，可见测量手段和工具的创新是认识世界、探索科学的前提。通过测量可以获得信息，信息经过提炼可得到知识，依靠知识才创造出生产的技术或生

活的智慧。一个国家的基础研究水平是其开展应用研究、开发新技术的基础，也是构成生产中的核心技术与产品的核心性能的源泉。例如，量子力学理论的确立不但提供了关于电子、原子、分子及光本身的基本知识，提供了光与物质相互作用的知识，也奠定了作为应用科学的光谱学的测量方法及光谱仪器的理论基础，也是后来激光技术、生物医学光子学及很多医疗诊断方法和仪器的理论基础。

表 1 与测量及仪器相关的诺贝尔奖

1901, Wilhelm Conrad Röntgen (德), X 射线及测量法, 物	1953, Frits Zernike(荷), 相衬显微镜, 物	1981, Arthur L. Schawlow(美), 高分辨激光及电子光谱测量法, 物
1907, Albert A. Michelson (美), 光学干涉仪, 物	1955, Polykarp Kusch (美), 射频束技术并测量电子磁矩, 物	1981, Kai M. Siegbahn (瑞典), 高分辨率电子频谱仪, 物
1908, Gabriel Lippmann (法), 彩色照相干涉测量法, 物	1958, Frederick Sanger(英), 胰岛素分子结构测量法, 化	1985, Klaus von Klitzing (德), 霍尔效应及物理常数测量, 物
1914, Theodore William Richards (美), 元素原子量精确测量, 化	1960, Donald A. Glaser (美), 气泡室测量电子轨迹, 物	1986, Ernst Ruska (德), 电子显微镜, 物
1922, Francis William Aston (英), 质谱仪, 用于发现多种同位素, 化	1960, Willard Frank Libby(美), 放射性碳同位素年代测量法, 化	1986, Heinrich Rohrer(瑞士), 扫描隧道显微镜, 物
1924, Willem Einthoven (荷), 心电图机制, 心电图测量法, 医	1962, Max Ferdinand Perutz (英), 血红蛋白结构测量术, 化	1989, Norman F. Ramsey (美), 最准确时间测量法——原子钟, 化
1927, C. T. R. Wilson (英), 云雾室测量电子轨迹方法, 物	1964, Charles H. Townes (美), 微波射器和激光器, 物	1991, Erwin Neher (德), 细胞膜上离子通道电流测量术, 医
1930, Sir Venkata Raman (印), 拉曼效应, 拉曼光谱测量法, 物	1964, Dorothy Crowfoot Hodgki (英), X 射线衍射测量分子结构, 化	1991, Richard R. Ernst (瑞士), 高分辨率核磁共振测量技术, 化
1943, Otto Stern (美), 质子磁矩测量法, 物	1967, Manfred Eigen (德), 化学反应快速测量技术, 化	1992, Georges Charpak (法), 多丝正比计数管粒子检测器, 化
1950, Cecil Powell (英), 核过程照相乳胶测量法, 物	1966, Alfred Kastler (法), 光束与射频双共振光学测量法, 物	1999, Ahmed H. Zewail (美), 测量化学键断裂和形成过程, 化
1952, Felix Bloch (美), 原子核磁力测量法, 物	1971, Dennis Gabor (英), 全息摄影测量法, 物	2003, Paul C. Lauterbur (美), 磁共振成像技术, 医
1952, Archer John Porter Martin (英), 分配色谱法测量法, 化	1979, Godfrey N. Hounsfield(美), CT 扫描测量方法, 医	2009, Willard S. Boyle (美), CCD 图像传感器, 物

其次,测量及仪器科学的水平直接反映了国家的经济实力。有专家评估,在发达国家,与测量有关的工作对于国内先进工业经济生产总值的贡献占3%~6%^[2]。以医疗仪器为例,自1901年伦琴发明X射线后,又经过后来以激光技术、微电子技术、纳米技术等为代表的几次技术革命,科技界的新成果逐渐向诊断、医疗手段集中,形成竞争激烈的医疗仪器市场。1999年的全球医疗仪器市场规模约为1590亿美元,其中,美国的需求量约占42%,欧洲的需求量约占26%,日本的需求量约占15%,而中国的需求量仅约占1%^[3]。到2007年,市场规模达到约2500亿美元,其中,美国的需求量约占40%,欧洲的需求量约占30%,日本的需求量占15%~18%,中国的需求量约占4%^[4]。可见,中国产品所占市场份额增长很快,但在世界市场总体比重还很低,人均医疗资源占有量更低,特别是中国医院所做的高端检查和治疗基本使用进口的仪器设备。例如,2008年中国图像诊断仪器需求量达到15.7亿美元,其中,美国的GE公司占25%,德国的西门子公司占23%,荷兰的飞利浦公司占19%,岛津制作所、东芝医疗、日立医疗等5家规模略小的公司共占16%,我国的迈瑞公司只占2%,其他的国内外参与者共占余下的15%^[5],这说明了测量及仪器科技方面我们国家竞争力不强。

在国防实力方面,以测量和控制技术为核心的精确打击已经改变了战争的方式和形态,运筹决策于办公室、精准打击千里之外的目标早已实现,都是以大量信息的获取和遥控仪器或系统为前提的。无论在空间定位系统中,还是在飞机、航母、导弹的演习或实战中,测量技术及精密仪器始终是眼睛,其“视力”直接反映了军队的现代化技术、装备水平,直接左右国防实力。

应该说,科学发现是人类认识世界的进展。科学发现本身对于改变人类生活方式、推动社会变化的影响应该说是难以充分认识的,但可以明确的是,创新的测量手段和仪器与科学发现是相互推动的。有了这类原始创新,才能演变出一系列的技术和产品,形成国家实力。从诺贝尔奖获奖者的地域分布可以看出,起先是出自欧洲的人多,然后是美国,近年来日本人获得诺贝尔奖的数量上升也引人注目。

先进国家认为测量和仪器科技的发展至关重要。例如,出于保持其国际竞争力领先的目的,2000年美国商务部国家标准技术研究所(NIST)在战略报告中明确提出,21世纪制造和改善人们生活质量的關鍵是测量技术,确保国家的测量基础对于维持在世界的竞争力是不可缺少的。在日本,为了实现研究开发工作稳定、高效地展开,从2002年至2010年实施了知识基础整備计划,目的在于提供包括测量基准、测量、分析、试验评价方法及相应的最先进的工具在内的世界最高水平的条件^[6]。

3. 测量的内涵及其变化

可以将测量考虑为由计量和测试两部分组成,如图 1 所示。计量的主要任务是基准的建立、遵守及传递,我国主要是由计量院负责;而测试则是对于被测量依照基准进行的比对。测量是将被测对象基于计量基准反复进行测试获得信息的过程。

有学者认为测量应包括三部分^[7],即计量的工作、信息的感知和知识的获取的工作、知识的应用的工作。知识的获取包括通过将获得的信息进行数据处理获得关于被测对象的有价值的信息。知识的应用则是将获得的知识应用到人类的文化和发展的过程。

我们要明确认识测量在学术上的地位,测量应属于科学与技术的范畴。就像物理学构成了自然科学的基础一样,测量科学是构成了所有科学基础的学问,而且是要涉及多种学科知识的交叉学科。

仪器是测量中的工具,现代仪器功能构成通常包括感知信息的传感部分、模拟信号处理部分、A/D 转换部分、数字信号处理部分等,可以用图 2 表示。




图 1 测量的内容




图 2 测量仪器系统构成

描述测量仪器主要性能的指标有:①灵敏度,表征输出与输入间的传递关系,或者说单位输入下的输出;②分辨率,表示输入值超过某一阈值后,输出开始变化;③测量范围;④精确性,包括正确度和精密度。

以事实为依据、以定量分析为基础方法的社会规范管理的进步,对测量及仪器科学不断提出更高的要求。人类认识世界的深入,各门类科学和技术的发展,也使得构成测量和工具的要素水平有可能不断提升。例如,最早的长度测量是以实物为基准的,米曾经是以地球子午线长度的四千万分之一的长度为单位、以特殊材料和形状制成的米原器上两刻线间的距离来定义的,但因为金属材料毕竟会热胀冷缩,而且其刻线也有数微米的宽度,故这种定义方法自然也就存在不确定性。所以,1960 年长度基准又基于特定元素在特定条件下放电时所发射的光波长度而被再次定义,进而在 1983 年,米被今天大家都认可的、光

在真空中 $1/299792458\text{s}$ 的时间间隔内传播的距离来定义。真空中的光速为 299792458m/s ，它可以被以非常高的精度测得，目前认为是恒定不变的，所以，这一定义方法可以获得更精确的长度基准。此例说明随着科技发展与社会进步，测量要素在不断地变化。

一般来说，实物基准大多缺乏理论或物理的根据，存在各地自行规定、逐级传递复杂、不易再现等问题，而量子基准是根据原子、电子的性质、特性定义和制造的，具有特征无个性，理论上在任何地方都容易再现的先进性。所以，各种测量从实物基准向量子基准转化是发展趋势。今天，测量上使用的多数基准都已经完成了这一转变。

4. 间接测量与物理法则

测量某一被测量时，将其与同种类的基准进行直接比较的测量为直接测量，如图 1 所示的过程。而当需要测量与目的被测量相关的几个被测量后，再将其结果通过某法则求出目的被测量的测量为间接测量。例如，欲测物理量 y ，选择与 y 相关联的物理法则，如公式(1)所示，测量与 y 不同的几个物理量 $a, b, c, \dots$ 据其结果计算得出 y 的方法。

$$y = f(a, b, c, \dots) \quad (1)$$

间接测量一般应用于基准制作困难、可测量的量受限制、相关因素不止一个等难以直接测量的场合。例如，欲测量液体中某种物质的浓度 C_i 时，通常测量入射至物质的入射光强度 I_0 和从物质透射出来的出射光强度 I ，将其代入公式(2)所示的 Lambert-Beer 法则计算得出被测浓度值 C_i ，公式中的 ϵ_i 为样品中成分 i 的摩尔吸光系数，是物质本身的固有性质， L 为光程长。所以，应用光谱方法进行物质含量的测量属于间接测量。

$$I = I_0 \exp\left(-\sum \epsilon_i C_i L\right) \quad (2)$$

与测量相伴的、不可回避的重要问题是误差。间接测量还存在着所采用的物理法则不完全适用而产生的原理测量误差。在间接测量时必须要注意的是，物理法则的成立是有条件限制的，物理现象复杂，一般与多种因素有关，而物理模型的本意是滤去次要因素影响，抽象出起支配物理现象的法则。所以，应用物理法则进行间接测量时，要特别注意该法则的成立条件是否被满足。如上述浓度测量时应用的 Lambert-Beer 法则是光通过样品的厚度 x 在测量中是不变的，不同成分的吸收效果是可线性叠加的，光在容器与空气及样品的界面的反射变化是可以忽略的等一系列假定条件下才是有效的。

除了原理性测量误差外，测量过程中也会出现误差，如产生于系统内元器件的热噪声、来源于系统外的电磁干扰等。我们无法阻止这些误差的产生，但

仍然可以使用科学的方法和技术来减少内外干扰的影响。例如,对于来源于系统内的误差,我们可以采取降低元器件的温度和信号带宽的办法使其尽量减少;而对于外部干扰,也可以采取屏蔽或者滤波的方法防止其进入系统。

由于测量与误差的伴生关系,我们对待测量结果要仔细地推敲,特别是重大科学测量工程,多数难以重复进行,而一个错误的判断往往会在时空上持续产生影响,特别是很多重大科学工程使用间接测量,要特别注意物理法则的成立条件是否被满足。

以无创伤血糖浓度的测量为例,说明间接测量的作用及误差对于测量结果的影响。实现非采血的方式测量血糖浓度是多年来医患双方的一个梦,近三十年来,多个国家的研究组织都进行了不懈的努力。起先人们考虑的是应用光谱吸收的方法,即通过间接测量光谱的强度变化来实现不抽血测量人体血糖浓度的目的。方法是通过比对入射光与穿越人体组织后出射的光,利用物质吸收的公式(2),推算出组织内的糖浓度。但几十年过去了,这一方法无明显进展,主要是因为人们还没有找到一个能够很好描述人体组织内部糖的浓度与光在穿越后变化之间稳定关系的模型或公式。如果用公式(2)来描述的话,受实际条件限制太大。光在皮肤表面的反射情况因人而异,人体组织内的各种成分的不同都会影响光的吸收,它们的叠加性将很复杂。光在人体组织中会发生散射不走直线,光程受被测者身体条件的千差万别影响而复杂多变等。另外,糖的吸收比起其他组织成分的吸收微弱,做诊断测量时的血流、脉搏、人体自身的运动等外加因素都会对测量产生影响,所以,血糖浓度的无创伤检测是一个从复杂的、千差万别的、处于生存运动状态下的被测物中提取微弱且特异性不强信号的难题。虽然在一定条件下,我们也可以看到血糖浓度的变化与光谱强度变化之间的相关关系,但还不能简单地认为是直接检测到了血糖的变化信号,因为人体中可对透射光产生影响的变量远不止血糖浓度。

5. 光在测量中的特殊地位

光作为能量的载体、人类感知外界的主要工具之一,自古以来与我们有着不可或缺的关系,其中,光作为信息载体和科研工具是人类进行测量的主要方法。我认为光与测量的联系如此紧密有如下4个原因:①眼睛是人类获取外界信息最多的器官,所谓“百闻不如一见”,即便是非可见光或非光的信息,很多也是要转化为可见光来方便接收。②光的特性决定了其传播覆盖了无论是宽广的还是细微的巨大的空间及时间,大到宇宙尺度,可接收来自远古的天体发出的光所携带的信息,小到原子尺度,即可以通过光谱的方法研究分子、原子结构内的基本粒子的性状。③光具有如下几个特殊的性质:高速性,在相当范围内测量时的时间差可忽略;空间性,与电子只能在固体和真空中传播相比,

光可在更多种介质内传播,便于布线、开关等,还可进行空间信息的同时处理;信号的多重性,光既可作为波又可作为光量子,如波长或光谱信息,可携带多重信息;多种可利用的特性,除了波长,光还具有振幅、相位、偏振、干涉性、量子性等多种特性可供测量方法的选用。④关于光的物理性质研究的不断进展,如对于光速的测量、光电效应的发现、光子概念的提出、光的波粒二象性的认识等,这些进展也直接推动了科学的发展。

6. 测量与仪器科学的前沿课题及展望

社会的发展进步总会给我们提出一些挑战现实方法的测量课题,大体可分为三类:第一类是属于测量科学本身需要发展和完善的课题,第二类是属于国内外发展大趋势中共性的前沿性测量课题,第三类则是属于在我国经济发展的现阶段独有的需集中精力解决的瓶颈性测量课题。

测量科学的发展性课题有:测量基准的进步,如测量阿伏伽德罗常数定义质量自然基准的课题;随着全球竞争的加剧,更高的生产效率、资源利用率要求我们实现动态的、在线的生产测量,以及将测量基准向现场的高精度传递;如随着测量系统或者功能元器件的微小化,我们必须面临应用常规尺度下的物理法则无法解释的、新的物理问题,随着测量系统向着多功能综合的方向发展,我们必须利用和集成更多的交叉学科的知识和技术,解决系统综合特性的评价方法等测量问题;经常要面对在被测量尺度加大的同时要求更高的绝对测量精度的测量问题,这要求我们必须在测量方法上有所创新。

前沿测量课题有:在宇宙探索领域,为了解宇宙远古时期的情况而进行的重力波测量的课题;在生命科学领域,为实现对活体细胞或者蛋白进行观测的课题;在纳米和材料领域,单分子尺度上各种物理性质的测量课题、亚原子尺寸的观察、电子波动函数的观测的课题等;在生物医学领域,血液成分的无创损伤检测、癌症的早期诊断等课题;在气象领域,如中长期天气预报的相关问题;属于影响全球环境的排放和环境变化,及其测量和评价的问题;属于防灾减灾的,如地震的中长期预测问题等。

国内需要尽快解决的测量课题有:属于经济发展需要集中力量攻关的,如国产大飞机、高速列车、大型水坝和大跨度桥梁安全的测试、测量问题;属于食品安全领域的,有困扰人们多年的食品掺杂使假的检测问题、农产品中化肥农药残留的检测问题;属于防灾减灾的,如矿难、地震、泥石流灾害后的生命信息的探测问题;属于环境保护的,有空气质量、水质,工业排放对人类健康的影响的评价及监测问题;属于医疗卫生领域的,如癌症等重症的早期检测及预报等;属于国防安全的,如独立的全球空间定位系统的构建及其精度问题,高性能的军用飞机、潜艇等测量测试;属于能源安全领域的,如油气传输管道

的自然泄露及其他安全的遥测问题。

社会的发展变化给测量提出源源不断的新课题，测量方法本身的创新需要更多地考虑与其他学科知识的交叉综合，还必须更充分地思考被测量本身在测量过程中的复杂特性及其变化。例如，生物技术与光学传感方法相结合不仅可以拓展测量领域，还能大大提高传感器的灵敏度。而利用无创伤的光学方法测量血液中的成分时，除了感兴趣的成分外，还必须关注其他血液成分变化的影响、光线在人体中的传播路径及其变化情况。除此之外，仪器科学的发展还与集成化技术、网络化技术、微米纳米技术、材料科学等的发展密切相关。

7. 提高对测量科学及仪器科学重要性的意义

我国测量与仪器科学的情况可分为研发制造与人才培养。测量的对象是大千世界，千差万别。测量科学或者仪器科学的学科发展和人才培养是对应于不同的行业背景来设置和发展的。例如，在信息科学领域中的相关学科叫“仪器科学与技术”，在综合性大学中所设仪器学科多没有相对集中的行业背景，人才知识结构是以机、光、电、算的传统知识为核心，这是因为中国刚刚才成为制造大国，它需要的主要是生产过程、技术管理和产品选型的人才，即工程师，他们能满足迄今为止的制造大国需要。

另一方面，我们必须加快测量与仪器科学的发展，加快仪器的研发制造，在满足国内市场需求的同时参与国际市场竞争。据说我国现在每年花费 6000 亿左右人民币资金从国外进口包括医疗、科学研究、生产质量管理等用的高档仪器设备，而我们几乎制造不出来高档的商用仪器。如欲改变这一现状，必须首先改变对测量与仪器科学的认识，确认其既是科学探索又是集成创新的事业。从人才培养的角度来讲，也要求从管理、使用仪器的工程师提升到有能力引进消化吸收国外先进技术的再创新研究者到具有自主研发能力的科技专家。为此，人才培养的知识结构应该从跟踪国外研发的机、光、电、算的传统结构，提升到现代测量及仪器科学所需要的知识结构，如加强物理学基础、信息的数理基础、测量与控制的科学方法、纳米技术与新材料、学科交叉和技术集成的能力等。

科学探索活动产生原始创新，测量及仪器科学是所有科学研究的基础，是各行各业创新的必要工具。今天，我们在现代仪器的核心技术、核心器件，如高性能的光电接收器、多轴高精度微纳加工母机、融合医学与机光电算等多学科交叉的高档医疗诊断设备等多方面均受制于国外，这表明了我们的基础研究、关键元器件的制造技术及技术集成能力都还薄弱，如欲满足国内市场、参与国际竞争，光是改变人才培养方向还不够，还必须在测量及仪器科学的研究方法上下工夫。我们应该考虑从测量及仪器科学发展方向上选择关键性的，甚

至国外也没有完成的科研课题组织攻关,形成研究方法、科研组织等方面的经验和创新,使我们能为人类的科技宝库做出应有的贡献。应该鼓励更多的年轻优秀人才投身于测量及仪器的科学研究事业,能够抓住测量与仪器领域新的科学问题,以扎实的知识结构做出新发现、发明,制造出具有市场竞争力的仪器和系统,而不只是满足于在某一个行业做合格的工程师。

参 考 文 献

- [1] [http://202.119.108.222/photo/index.php? cat=7](http://202.119.108.222/photo/index.php?cat=7).
- [2] Quinn T, Kovalevsky J. The development of modern metrology and its role today. Phil. Trans. R. Soc. A, 2005, 363: 2307—2327.
- [3] 国际医疗器械产业发展态势分析. 第8届全球医疗仪器会议, 2001.
- [4] Research in China. China Medical Devices Market Report, 2007.
- [5] 松尾未亜, 鶴田祐二. 中国新医療改革にともなう医療機器ビジネスの投資機会. 知的資産創造, 2010.
- [6] 文部科学省. 科学技術白書, 2004.
- [7] 荻屋公明. 計測科学—計測の社会的役割—. 産業図書, 1997.

撰稿人: 徐可欣

天津大学精密仪器与光电子工程学院

光的七个极限问题

The Seven Extremes of Light

什么是光的极限？光的七个极限问题是什么？大家知道，光作为一种电磁辐射是物质的一种特殊形态。在真空中，光的传播速度是个常量，即 299792458m/s 。爱因斯坦狭义相对论的一个基本定则告诉我们，光速是宇宙万物运动速度的上限。如果一个物体的速度达到光速，那么，它的质量或能量就会变得无限大。而光之所以不存在能量无穷大问题，是因为光没有静止质量^[1]。尽管多少年来不乏有人对光速是物质运动的最高极限速度提出质疑，但至今为止科学界的主流观点依然是：世界上的任何物体，无论大小，其运动速度都不可能超过光速。因此，我们说光速是光的第一个极限、也是最基本的极限。

当光由真空(或稀薄的气体环境)进入到一个透明的介质(如玻璃或水)当中时，其速度会发生“突变”，即从原来的真空中的光速 c 变成了 c/n 。其中， n 是介质的折射率，通常大于 1。如果光是单色的，即无须考虑色散的作用，那么，折射率是个确定值(当然需要假定温度、压力固定不变)，单色光在介质中就将始终以 c/n 的速度传播。有趣的是，光速在物质界面处(由真空到介质或反之)发生的变化是否意味着光是可以加速或减速的呢？如果答案是肯定的话，这一光的加速度(可正可负)又会是多少^①？也许，对许多人来说，这样一个问题可能不够确切。由于光速分为群速和相速，因此，更确切的表述应该是光的群速加速度和光的相速加速度分别是多少。

如果光可以加速，那么，光的加速度有极限吗？近年来，有一些科学家在研究所谓慢光(slow light)或超慢光(ultraslow light)的问题^[2~4]，即通过光与物质的相互作用(如强烈的共振吸收)来延缓光在物体中的传播速度(群速度)。据报道，最慢的光可以慢到 17m/s 的行进速度，比通常真空中的光速几乎慢了近两千万倍^[5]。对于如此奇特的科学发现，人们不禁会问，既然光

①乍看起来这不像是个难题，因为我们只要知道发生这一速度跳变所需的时间是多少，就应该能够很容易地求出光在界面处的加速度，但实际上问题却并不这么简单。也许我们可以认为界面本身是一个理论上没有厚度的面，因此，光速在界面处是跳变的，在数学上无定义或不连续。当然，在实际的物理世界里，我们很难想象或接受一个不需要任何时间就能够完成的事件。一种变化可以非常之快，但再快它还是需要一定的时间来完成的，即使这个时间可以极为短暂，但它还应该是个有限值，而不是零。

速有上限，那么，光速会有下限吗？有哪些因素决定光速有或没有下限呢？如果光速真的可以减到足够慢，如每秒毫米甚至更小的量级，这意味着我们将能用一个容器把光存储起来，需要的时候再将其释放出来使用，这无疑会是对光进行操控的理想境界。这种情况下，无论把光作为信息存储，还是把光作为能量来储备，都可能会对人类的生活和生存空间产生深刻的影响。目前，不少科学家已展望到了慢光在未来光通信和精密计量领域中的巨大应用前景。

有关光速及其变化的极限问题不过是本文所说的光的极限问题的两个最基本的例子。实际上，现代光学、光子学研究中的某些具有突出引领性的研究领域都与研究光的某些极端特性密切相关，如强光光学、超快光学、微纳光学等（在此，我们或许可以将这些研究光的极端情况的学说统称为“极限光学”）。我们知道，光具有波粒二相性，这其实也是一个一直存在争论的问题。一般来说，光的宏观描述（波）与光的微观描述（光子）之间的关联可以简单表述为：光子的密度与振幅（严格地说是振幅的平方即光的强度）相对应，而大量光子间的关联程度则反映为位相。对一束光而言，尽管在某一瞬间，它是定域在某一空间范围内的，但奇妙的是，构成光波的光子却是没有尺寸（或者说是**不定形**）的。

常识告诉我们，如果在空间中的某一点存在一个实物粒子的话，那么，同一点或位置处就不可能再有另一个粒子存在。从粒子堆积的角度来说，这意味着物质粒子（如原子、中子乃至电子）的可能最大密度（即单位体积内的粒子数）均是有限的，很容易根据粒子的大小或可以靠近的程度及最小间距求出。但对光子而言，由于光子的无定形和没有尺寸的特点^①，与实物粒子的情况大相径庭，即在空间的同一位置点上可以有许许多多多个光子同时存在，这也是光的独立传播原理和光子堆积密度不存在极限的原因所在。但是，我们要问自由空间或真空中的光子密度真的可以任意大吗？到目前为止，可以说，全世界的科学家们对这样一个问题并没有明确的答案。科学家们最多只能推测可能会存在一个最大光子密度或最大能量密度的上限，即所谓 Schwinger 极限^②。

在实验上，通过利用啁啾脉冲放大技术、空间与时间域的色散补偿技术及激光相干（或非相干）合成技术将高能量超短脉冲激光汇聚到微小的空间区域内，

① 从这一点来说，光子更像是个虚幻的粒子，它只有一份固定的能量，没有固定的物理形态（也许可以将质量定义或理解为一个复数，其实部是我们通常说的静止质量，而虚部则对应纯粹的能量。声子、表面等离子体基元（子）、光子都只有虚质量，是虚粒子，它们的存在会导致物体的有效质量增加）。

② Schwinger 极限预计当电场强度达到 10^{16} V/cm （即光强接近 10^{30} W/cm^2 ）时，如同正负电子湮灭产生光子的逆过程那样，真空态中的虚粒子对将会转变为实粒子，此时真空将会沸腾。

从而获得极高的峰值强度^[6,7]。不久前,欧洲从事强光和高能密度物理研究的科学家们提出要建一个极限光(extreme light)装置来获得 10^{26} W/cm^2 的光强(对应峰值光功率为 200PW, $1\text{PW} = 10^{15} \text{ W}$),并以此作为工具研究真空态和反物质^[8,9]。当然,在这样高的能量密度下,人们是否就能够揭开物质真空态的神秘面纱,在真正的实验开展之前还只能是未知数(关于不同量级的光子密度所对应的与物质相互作用的丰富物理内涵在参考文献[10]中有较详细的描述,此处不再赘述)。有一点可以判定的是,光子在同一空间位置上的累加,即光子密度的不断提高将会由于达到了某种新的能量耗散的阈限(伴随新产物的出现)而被钳制住。因此,探求最高光子(能量)密度的问题是一个直接涉及如何认识宇宙中物质世界基本构成的问题。

表 1 给出了光子密度 n_{photon} 和场强 E 与光强 I 的关系。其中,假定光的中心波长为 800nm,偏振态为线偏振。从表 1 中的数值可以看到,当光强为 10^{12} W/cm^2 时,光子密度已超出了一个大气压下普通气体的原子密度;当光强为 10^{16} W/cm^2 时,光子密度超出了一般固体材料的原子密度;当光强为 10^{30} W/cm^2 时,光子密度将接近中子星,即原子塌缩(电子被原子核吸附)后的中子密度。

表 1 光子密度和场强与光强的对应关系 ($\lambda=800\text{nm}$)

光 强	场 强	光子密度
$I / (\text{W/cm}^2)$	$E / (\text{V/cm})$	$n_{\text{photon}} / (1/\text{cm}^3)$
1.00×10^8	2.70×10^5	1.35×10^{16}
1.00×10^{10}	2.70×10^6	1.35×10^{18}
1.00×10^{12}	2.70×10^7	1.35×10^{20}
1.00×10^{14}	2.70×10^8	1.35×10^{22}
1.00×10^{16}	2.70×10^9	1.35×10^{24}
1.00×10^{18}	2.70×10^{10}	1.35×10^{26}
1.00×10^{20}	2.70×10^{11}	1.35×10^{28}
1.00×10^{22}	2.70×10^{12}	1.35×10^{30}
1.00×10^{24}	2.70×10^{13}	1.35×10^{32}
1.00×10^{26}	2.70×10^{14}	1.35×10^{34}
1.00×10^{28}	2.70×10^{15}	1.35×10^{36}
1.00×10^{30}	2.70×10^{16}	1.35×10^{38}

由于光强等于能量密度与光速的乘积，而能量密度又等于光子密度乘以光子能量，这意味着同样光强情况下，光子能量越高，所对应的光子密度就越低^①。举例来说，同样是 10^{26} W/cm^2 的光强，如果光子是具有 10^8 eV 的超大单光子能量的 γ 光，那么，所对应的光子密度就会变成 $10^{26} / \text{cm}^3$ ，即比处于同样光强下的近红外区的光子密度低了 10^8 量级。在此，我们可以提出“宇宙中是否存在最大单光子能量极限”的问题。如果存在，它是由什么来决定的？这个问题实际上与我们下面要提到的激光超短脉冲宽度的极限问题密切相关。

大凡接触到激光超短脉冲的人，无论是使用者还是研究者，都会为自激光发明以来人类所获得的激光脉冲的宽度从纳秒至皮秒至飞秒再至阿秒(10^{-18} s)不断的变短而感叹，同时也大都很容易产生“激光超短脉冲究竟最短能够多短，有没有极限存在”的疑问^②。目前报道的最短激光脉冲已经达到了 $80 \text{ as}^{[11]}$ 。这里，我们有必要对这个问题做一点稍微细致的分析。

图 1 是在空间某一点处的超短脉冲激光的电场分布。虚线是强度，即电场包络的平方。通常，我们所说的脉冲宽度是强度曲线的半高全宽(full width at half maxima, FWHM)。而由于光强是电场振幅包络的平方，因此，与电场的时间宽度(或电场包络的 FWHM，在图 1 中亦用双向箭头标出)相比，这一定义本身就已将实际脉冲短(或窄)的程度夸张了。此外，根据脉冲宽度的定义，我们还需清楚地认识到，对一个超短激光脉冲而言，在脉冲宽度之外依然有光信号存在，特别是根据脉冲形状的不同，光(子)可以延伸至脉冲宽度以外很远的地方。换句话说，从能量上而言，在光脉冲之外依然可以有相当大比例的光能量存在。

超短激光脉冲的另一个特点是：当其宽度非常窄时，在脉宽内仅包含了少数几个光周期(此种情况下的脉冲也称为少数周期脉冲)。由于通常脉冲宽度亦可表示为光周期乘上脉宽内所含周期的数目，因此，激光超短脉冲究竟最短能够多短的问题可以转化为“少数周期脉冲中的周期数最少可以是多少”和“最短的光周期可以有多短”这样两个问题。对于前一个问题，由于前文中提到的脉

① 在给定能量密度情况下，高能量光子所对应的密度低，低能量的光子密度高。从唯像的角度来看，这一特性等价于说高能量光子是“大光子”，而低能量光子为“小光子”。在非线性光学研究中，我们可以通过光与非线性晶体的作用(如和频或倍频技术)将两个低能(小)光子合成为一个高能(大)光子，或反之通过光参量过程将一个高能(大)光子分成两个低能(小)光子。在前一种情况下，我们说两个光子被融合了，而后一种情况下，是一个光子“破裂”了。根据能量守恒的要求，无论是光子融合还是光子破裂，其发生非线性相互作用过程的前后，光子在能量空间中的体积并没有发生变化。

② 对于这一问题，通常许多人会倾向于“没有极限”这样一个答案，因为从理论上来说，还没有发现限制脉冲宽度的理由，除非人们发现光子是有静止质量的。只要光子有静止质量，不论多小，我们将可以认为光子是有尺寸的，而只要光子是有尺寸的，就有可能存在最短光脉冲宽度的极限。




图1 空间某一点处超短脉冲激光的电场分布(实线)及相应的强度分布(虚线)

脉冲宽度 Δt 定义为强度分布的半高全宽(FWHM)，它要比光场的宽度窄些；

T 为光周期，等于光的波长除以光速

冲宽度之外仍有光周期信号存在的原因(现实中不存在绝对的方波光脉冲)，这变成了一个可能不是很有意义，或者说其本身在定义上存在某种不确定性的问题。但是，有一点对我们认识如何获得更短超短激光脉冲是很有帮助的，即当脉冲所含光周期数为一定值时，光周期越短(光的频率越高)，脉冲的宽度就越短。这实际上也正是目前从事超短脉冲激光研究的科学家们所获得的阿秒激光脉冲无一例外地都处在深紫外或软 X 射线波段的根本原因。对于后一个问题，由于光的周期等于波长除以光速，即光的频率的倒数，这个问题与前面提到的是否存在最大单光子能量极限或最高光频率是同一个问题。

对于“少数周期光脉冲中的周期数最少可以是多少”，更多研究人员进一步提出“如果脉宽小于一个周期，这样的短脉冲是否还能看作波？还能否用波动方程来描述”。这里，同时也涉及光(电磁)波理论分析中常用到的慢变波包近似(SVEA)对少数周期脉冲是否适用的问题。对此，有理论分析表明脉冲波包这样一个概念(作为描述超短光脉冲的基本理论模型)是可以扩展到单周期脉冲的^[12]。此处值得一提的是，近年来科学家们在微纳光学的框架下对于空间尺度上的亚波长结构与光相互作用特性的认识已有了长足的进展，人们已可以相当自如地对光进行亚波长尺度的约束和操控。而相比之下，对时间尺度的亚周期(即沿着光传输方向的亚波长)特性却知之甚少，还处在一种对其能否存在的疑惑之中！如果我们将光的时间和空间特性一起考虑的话，接下来无疑会提出“在四维时空中亚波长和亚周期光之间是否有关联和如何关联”的疑问。

从粒子堆积的角度出发,如果我们接受光子为某种虚粒子的假想概念(如图2所示),与最短的激光超短脉冲究竟能够多短的问题相对应的光子统计问题将是:在时间轴上,光子堆积的最大陡度是多少^①?我们可以将光子局限在亚周期的尺度内吗?在不知道单光子大小的情况下,这看起来是个相当虚幻的量子堆积问题。由于在量子力学里,能量与时间是对易量,最短光脉冲宽度将会与时间量的不确定性相关联,并由能量的不确定性来决定。也就是说,最短光脉宽的问题与最大光子密度的问题似乎要连接在一起(最终我们手中所持有的无疑还会是那把由量子力学测不准原理所确定的永远不会绝对精确的标尺)。




图2 由超短脉冲激光的光子图像所带来的疑惑:鸡蛋可以堆垒,光子可以堆积吗?
与鸡蛋垒不可能窄于一个鸡蛋的尺度相比,光子堆积的最大陡度是多少?

下面简单小结一下上述有关光的极限(或称之为极限光学,包括超快光学、超慢光光学、超强光学、超相对论光学等)中的一些有待回答的最基本的问题:

- (1) 真空光速极限是可以超越的吗?
- (2) 光可以加速/减速吗(如果可以,光的加速度有极限吗)?
- (3) 慢光的速度有没有下限?

(4) 光子的最大密度堆积极限是多少(或者说真空中光束独立传播的原理在多高的光能量密度下将不再成立)?

- (5) 宇宙中存在最大光子能量(最高电磁波频率)的极限吗?

^① 有趣的是,如果我们做一个对单个超短激光脉冲不断进行衰减(并始终保持其宽度不变)直至其达到单光子水平的想象性实验的话,那么,脉冲最短能有多短的问题就似乎转化成了最终我们能够将单个光子局域在多大的空间内的问题,而后者正是无定形的光子由定域的原子或分子发生能级跃迁所产生的逆过程。当然,即使假想单光子的定域性问题有了答案,接下来可能要回答的问题是,多光子的定域性与单光子的定域性会是怎样的关系?多光子的堆积或粘连将由多光子的哪些特性来决定,与要堆积的总光子数有关吗?

(6) 光脉冲的宽度是否可以小于一个光周期(如果可以,亚周期光会有哪些重要特性)?

(7) 单(多)光子的最小空间定域性是多少(换言之,如果我们有一个盛装光子的魔盒的话,这个魔盒最小可以有多小?其形状可以是任意的吗)?

以上关于光的七个极限问题虽然大小、清晰程度不同,有的甚至在命题上还值得进一步讨论,但对其进行认真界定和研究的意义将会是极其深远的。无论我们最终是否能够找到这些问题的答案,抑或我们需要根据新的研究成果来对其重新审视和修正,对光的这七个极限问题进行深入地思辨和实验验证,必然会帮助我们获得对光、对宇宙本质的更深刻的认识。

参 考 文 献

- [1] 罗俊.光子有静止质量吗//“10000 个科学难题”物理学编委会.10000 个科学难题·物理学卷.北京:科学出版社,2009:647—655.
- [2] http://en.wikipedia.org/wiki/Slow_light.
- [3] Ginsberg N, Garner S, Slowe C, et al. Ultra-slow light in Bose-Einstein condensates; Shocking matter and transforming light. OSA/SL 2006, 2006.
- [4] Moon S H, Park J, Oh J M, et al. Strong tunable slow and fast lights using a gain-clamped semiconductor optical amplifier. Optics Express, 2009, 17: 21222.
- [5] Vestergaard H L, Harris S E, Dutton Z, et al. Light speed reduction to 17 metres per second in an ultracold atomic gas. Nature, 1999, 397: 594—598.
- [6] Diels J, Rudolph W. Ultrashort Laser Pulse Phenomena, Fundamentals, Techniques, and Applications on a Femtosecond Time Scale. 2nd ed. New York: Academic Press, 2006.
- [7] Mourou G. Extreme light physics (ELI). Shanghai: CLEO/PR, 2009.
- [8] <http://www.extreme-light-infrastructure.eu/>.
- [9] Gerstner E D. Laser physics: Extreme light. Nature, 2007, 446: 16—18.
- [10] 李福利.超高密度光子//“10000 个科学难题”物理学编委会.10000 个科学难题·物理学卷.北京:科学出版社,2009:288—290.
- [11] Goulielmakis E, Schultze M, Hofstetter M, et al. Single-cycle nonlinear optics. Science, 2009, 320: 1614—1617.
- [12] Brabec T, Krausz F. Nonlinear optical pulse propagation in the single-cycle regime. Phys. Rev. Lett., 1997, 78: 3282—3285.

撰稿人: 朱晓农
南开大学现代光学研究所

空间太阳能发电站

Solar Power Satellite

1. 太阳能是否可以完全满足人类的能量需求

丰富的太阳辐射能是取之不尽、用之不竭、可再生、无污染、廉价、人类能够自由利用的能源。太阳以光的形式向宇宙辐射能量，功率高达 $3.75 \times 10^{23} \text{ kW}$ ，其中，只有 22 亿分之一的能量到达地球。仅这一点微不足道的比例，理论储量达每年 17000 亿吨标准煤^[1]。万物生长靠太阳，没有太阳，地球上就不可能有姿态万千的生命现象，当然也不会孕育出作为智能生物的人类。太阳给人们以光明和温暖，它带来了日夜和季节的轮回，左右着地球冷暖的变化，为地球生命提供了各种形式的能源。尽管太阳能资源开发利用的潜力非常广阔，但绝大部分在茫茫太空中白白地散失掉了。如何把损失的太阳能收集起来？如果把太阳能全部收集，是否能够满足人类对电能的需求？这已成为保护环境、节约资源、推动和保证人类社会可持续发展的重大难题之一。

20 世纪中叶，科学家已在利用太阳能方面取得了重大突破，就是能够把太阳能直接变为电能。利用太阳能的最佳方式是光伏转换，就是利用光伏效应，使太阳光照射到硅材料上产生电流直接发电。由于太阳能是未来最清洁、安全和可靠的能源，发达国家正在把太阳能的开发利用作为能源革命主要内容长期规划，目前，光伏产业正日益成为国际上继信息技术、微电子产业之后又一爆炸式发展的行业。虽然太阳能产业在蓬勃发展，但有两个根本性的问题阻碍了太阳能的发展，首先是如何全天候的利用太阳能？太阳能的利用和天气有关，如阴天和雨天的太阳能工作效率很低；其次是如何将太阳能有效地转换为电能，提高光电转换效率？当前，各国科学家都在设计新型的结构或者新型的材料来吸收太阳能，以提高太阳光能量转换成电能的效率。

2. 空间太阳能发电站科学难题的起源

人们也许会想，目前在地面已经能够将太阳能电池安装在个人住宅的屋顶上，组成家用光电池发电系统，又何必到太空中去建设太阳能发电站呢？要把丰富的太阳能转变成电能，在地球上建立大型太阳能——电能转换装置，会出现很多不利因素^[2]：①地球表面的日照受昼夜、季节、天气和气候的影响特别大，在地球上的任何一个地方，一年中只有 $1/2$ 左右的时间能获得日照，而且

日照程度又随时间和天气而改变,如云、雾、雨、雪等天气现象的出现,使工作效率大为降低;②要占用大面积的土地;③难以使大面积的定日镜跟踪太阳;④易受灰尘的污染和风、霜、雨、雪的侵蚀,还需要设计专用自动清洗设备对其进行定期清洗,不然就会影响它的转换效率;⑤太阳光穿过大气层时,一部分能量被吸收掉,没有被地面的太阳能发电站充分利用;⑥地面上有风和重力存在,使建筑超级大型太阳能电池阵或反射镜颇为困难。

由于航天技术的突飞猛进,如今人造卫星、宇宙飞船、空间站等航天器上的能源大部分是采用太阳能供电,有些是将太阳能电池贴在卫星的表面上,有些则是贴在专门供给贴太阳能电池的翼板上,这种翼板好像是卫星向左右伸出的两扇翅膀,如图 1 所示。在翼板表面上贴有数以万计的太阳能电池,将它们并联或串联起来,在太阳光的照射下,便能供给几百瓦乃至几千瓦的电力。翼板面积越大,贴的太阳能电池越多,产生的电力就越大^[1]。由于卫星的太阳能电池处于大气层外,供电不受天气的制约,于是有人提出大胆的设计,是否可以将太阳能发电站建在太空?



图 1 位于太空的空间太阳能电池帆板示意图^[3]

将太阳能从外层空间输入到地球上的设想,最早由现代航天学和火箭理论的奠基人、苏联著名科学家 Tsiolkovski 于 1912 年提出,他不但预言空间时代的到来,同时认为,火箭技术可实现从空间采集到比地面多几十亿倍的太阳能。1968 年,美国 Glaser 博士提出在地球同步轨道上建立空间太阳能发电站的方案,这一设想是建立在一个极其巨大的太阳能电池阵的基础上,由它来聚集大量的阳光,利用光电转换原理达到发电的目的,其示意图如图 2 所示,所产生的电能将以微波形式传输到地球上,然后通过天线接收经整流转变成电能,送入全国电网。Glaser 博士在 1973 年将该设想申请了美国专利,并一直致力于该领域的研究^[4]。

在宇宙空间建立太阳能发电站能合理地充分利用空间资源。太阳能发电站最好设置在赤道平面内的地球同步轨道上，位于西经 123° 和东经 57° 附近。使太阳能电池阵始终对太阳定向，并且发射天线的微波束必须指向地面的接收天线。由于处在赤道平面的同步轨道上，因此，空间太阳能发电站与地面任何地方的相对位置都保持不变。发电站上需带有少量推进剂，以便克服由太阳和月球重力作用、太阳光压和地球偏心率等因素造成的轨道漂移。不过，当空间太阳能发电站绕地球运动时，总有一部分时间被地球遮挡住阳光。但是，由于该站设置在静止轨道上，每年有 277 天是全日照，仅每年的春分、秋分前后各有 45 天时间，轨道上的发电设施才出现地球阴影（亦称星食期），最长的停电时间也只不过 75 分钟，而停电时间又是可以正确预测的，照此算来，空间太阳能发电站平均每天有 99% 的时间可向地上接收设备输电。如图 3 所示，在外层空间，太阳能的利用绝不会受到天气、尘埃、细菌和有害气体的影响，再加上日照时间长，因此，空间太阳能发电站与同一规模的地面太阳能发电站相比，接收的太阳能要高出 6~15 倍^[5]。




图2 位于太空的空间太阳能发电站示意图^[3]




图3 地面太阳能发电站与空间太阳能发电站的对比^[1]

3. 难题的研究历史

从 20 世纪 70 年代开始，美国相关的公司和政府机构开始投巨资进行研究，并对空间太阳能发电站系统进行了设计和规划。太阳能发电站的“发电机”是一块 $10\text{km} \times 5\text{km} \times 0.5\text{km}$ 的太阳电池板，板的一端连接一个直径为 1km 的微波发射天线。发电站的姿态控制系统使太阳电池板始终朝向太阳，指向机构使发射天线总是对准地面。太阳电池板产生的电流通过超导体传输线送到微波发生器，在这里转换成微波，再经过天线向地面发送，微波的工作频率选用 2.45GHz 或 5.8GHz 。太阳能发电站采用直径为 1km 的天线发射微波，波束中的功率密度分布比较合理，以提高地面接收天线的接收效率。地面接收天线是一片 $13\text{km} \times 10\text{km}$ 、占地约 1 万公顷的椭圆形地区，由无数半波偶极子天线组成。天线接收到的微波经过二极管整流变换成直流电或 50Hz 的市电。由于地面

天线的面积非常大,微波波束到达地面时的功率密度很小,波束中心大约为 $20\text{mW}/\text{cm}^2$,边缘只有 $0.1\text{mW}/\text{cm}^2$ 。

90 年代,空间太阳能方案已成为美国 NASA 研究的主要课题,他们对空间太阳能的新方案、技术和市场进行了深入的探讨后认为,空间太阳能作为下个世纪的能源仅仅是时间问题。1999 年 3 月,美国 NASA 启动空间太阳能探索研究计划(The Space Solar Power Exploratory Research and Technology Program, SERT),研究内容包括若干个专题:太阳电力生成,无线电力传输,电力管理与分配,结构、材料与控制,热材料与热管理,机器人装配、维护与服务,平台系统,地面电力系统,地面与轨道间的运输与基础设施,太空中的运输与基础设施,环境与安全问题,系统集成,应用研究,市场分析等。2007 年 10 月,美国国防部综合国际 170 多位专家的研讨意见,发表了《空间太阳能发电站作为战略安全的机遇》研究报告,该报告认为,在新的能源和航天发展形势下,虽然空间太阳能发电站的研制存在严峻的技术挑战,但从技术、需求和经济上都面临着前所未有的发展机遇,有必要制订全面的国家计划开展空间太阳能发电站的研究^[6]。

同时,日本在该领域开展了广泛而深入的研究,同样取得了较大进展。日本宇宙航空研究开发机构(Japan Aerospace Exploration Agency, JAXA)计划在太空建立大型太阳能发电站,该计划将设计并建造一套空间太阳能系统(Space Solar Power System, SSPS),希望这项计划能够帮助日本解决能源问题,并为全球气候变暖提供解决方案。该系统将包括位于地球静止轨道的大型光电池阵列和设在海上或者水库中央的地面接收天线,光电池阵列采集的太阳能将利用激光波束或微波传输到地面站。在未来几年内,日本将利用本国自主研发的火箭发射一颗用于试验微波传输的专用卫星,2020 年有望发射一套试验型在轨太阳能电池板,并在 2030 年发射定型的太阳能电池板,该系统能够产生 10 亿瓦特的电能(相当于一个中等规模的核电站)。按计划,日本的电能成本将减少到目前的 $1/6$ ^[7]。

4. 如何将电能从太空无线传输到地面?

虽然空间太阳能发电站在太空可以获得非常高的能量效率,但一个难题摆在了科学家的面前,就是如何将太空获得的电能传输到地面?空间太阳能发电站从其大的组成方面来说主要包括三个部分:太阳能发电装置、能量转换和发射装置、地面接收和转换装置。太阳能发电装置将太阳能转化成为电能;能量转换和发射装置将电能转换成微波或激光等形式(激光也可以直接通过太阳能转化),并利用天线向地面发送能束;地面接收和转换装置接收空间发射来的能束,再通过转换装置将其转换成为电能。整个过程经历了太阳能—电能—微波

(激光)—电能的能量转变过程。

将卫星太阳能发电站的电能传输到地面需要使用无线输电技术。所谓无线输电(wireless power transmission, WPT),就是用微波源或激光器把直流电转变为微波或激光,然后由天线发射出去,大功率的电磁射束通过自由空间后被接收天线收集,经微波或激光整流器后重新转变为直流电。它的实质就是用微波束或激光束来代替输电导线,通过自由空间把电能从一处输送到另一处,这种技术一旦成功,将会对消耗能源的各个行业及我们的日常生活产生巨大的影响^[8]。

人们采用电磁波来进行无线信息传输目前已经发展得非常成熟,无线电话和移动通信已经获得了广泛应用。但是,采用电磁波来进行无线能量传输还处于实验室研究阶段。如何实现无损耗的能量传输?早在100年前,著名的交流电发明家 Tesla 用工作电压 100MV、频率 150kHz 的电磁波发生器产生非定向电磁辐射,成功地点亮了两盏白炽灯,这就是最初的无线输电实验室演示,从那时起,无线输电的概念就问世了。之后,日本、俄罗斯等国的科学家一直致力于采用微波或者激光来传输能量。现在,人们通常使用的微波炉就是利用磁控管来产生和发射微波,微波携带的能量对微波炉里面的饭菜进行加热,能够在数秒内将食物煮熟。微波炉里面微波传输的距离非常短,而在空间太阳能发电中,如何实现超长距离的无线能量传输呢?这仍然是一个需要攻克科学难题。目前,研制成功的将微波能量转变为直流电的整流器包括回旋波微波整流器和半导体微波整流器。回旋波微波整流器单个器件较重,但可输出 10kW 以上的大功率和 20kV 以上的高电压,工作性能稳定,具有微波过载自我保护特性。半导体微波整流器重量轻,但单管输出的功率小(2~6W)、电压低(10~20V)、稳定性差。两者单管的整流效率相近,约为 85%。如果用于大功率整流,优先选择前者;若用于小功率输电,后者占有优势。例如,功率为 5GW 的卫星太阳能发电站,要用数目约 1×10^9 个半导体微波整流器,这将消耗大量的稀有材料,安装、连接、测试、维护也很费力,若用回旋波微波整流器,可以很好地回避这些问题。

除了微波可以传输能量,人们也在设想采用其他电磁波来无线传输能量。目前,利用激光实现空间光通信已经实现。所以有人提出,是否可以采用激光来实现空间无线能量传输?美国军方在采用激光无线能量传输方面也开展了相关的研究,如图 4 所示,他们研制了用于将激光能量转化为电能的光电池,并用于小飞机的能量供应上,通过一个激光束照射小飞机下面光伏电池板的中心位置,光伏电池将激光束携带的能量转化为电能,用于给小飞机提供飞行所需要的能量。




图4 美国研制的激光能量驱动的小飞机^[9]

在无线能量传输中,高功率的能量需要从太空传输到地球上的地面接收站,这必然会带来环境的影响。大功率定向电磁波从空间朝地面输送时对环境考虑有^[2]:①传输多大的能流密度对电离层的扰动没有影响;②采用哪一个无线电频段对日常的通信不发生干扰;③地面整流接收站选在何处对飞机等交通工具及周围的生物体(如鸟类、居民等)没有不良作用;④地球静止同步轨道上建造大面积的发电站对地面无效应及大量卫星发射产生的航天垃圾污染。

5. 太阳能发电站的发射和组建

由于空间太阳能发电站的体积庞大,特别是微波反射器,大的直径有几公里,不可能仅靠几次发射就能送入太空地球同步轨道。那么,如何将如此庞大的发电站发送到太空呢?根据目前的运载能力,需要将其打包处理,分成数十个甚至上百个有效载荷组成部分,依次送入太空,然后在太空完成组装。为了完成太空组装与维修工作,希望发展太空机器人及遥控组装技术等,只有出现不能由机器人修理的突然情况下,才需要人的参与。为了降低成本与发射次数,一方面需要发电站结构设计最优化及超轻量化,并实现组件最大的质量比功率与体积比功率,另一方面需要提高运载承载能力,发展可重复使用的运货火箭或飞船。

美国 NASA 于 1995 年开始组织来自宇航局研究中心、学术界和工业界的专家,开展了新一轮的研究论证。专家们一共分析比较了 29 种不同方案,其中一种是“太阳塔(Sun Tower)”方案。如图 5 所示,在“太阳塔”方案中,太阳电池阵不再是铺设在一整块巨大的矩形平板上,而是由数十个到数百个圆盘形发电阵组成,每个发电阵的直径为 50~100m,输出 1000kW 的功率。根据总发电量的要求配置发电阵的数目,如总发电量要求 250000kW,则配置 250 个发电阵。圆盘形发电阵沿中央缆绳两侧排列成 2 行或 4 行。如果排成 2

行,“太阳塔”发电站全长 $6.5\sim 13\text{km}$,发出的电流通过由超导材料制成的中央缆绳输送到缆绳末端的发射天线,天线直径约为 260m 。“太阳塔”发电站采用重力梯度稳定,使中央缆绳自动保持垂直于地面,保证末端的发射天线对准地面,地面接收天线的直径约为 4km 。该方案的最大特点不在于结构外形的不同,而在于它的高度模块化。整个发电站,不仅它的核心部分——太阳电池阵,其他部分也都由若干规格相同的模块化部件组成。一座发电能力为 250MW 的“太阳塔”发电站所需投资估计为 $80\text{亿}\sim 150\text{亿美元}$ 。在另一种“太阳盘(Solar Disk)”方案中,如图6所示,采用直径为 $3\sim 6\text{km}$ 的高效薄膜太阳电池阵发电,保持自旋稳定,并对太阳定向,产生的电流汇集到盘极,再传输到发射天线。天线采用直径为 1km 的相控阵天线,发电功率为 $2\sim 8\text{GW}$,用 5.8GHz 的微波向地面传输。地面接收天线直径 $5\sim 6\text{km}$,不需要地面储能系统。据估算,一座发电能力为 5GW 的“太阳盘”电站所需投资为 $300\text{亿}\sim 500\text{亿美元}$ 。




图5 “太阳塔”空间太阳能发电站构想图^[10]




图6 “太阳盘”空间太阳能发电站构想图^[10]

6. 空间太阳能发电站的应用前景

空间太阳能发电站的建设是一个跨越多行业的人类宏伟工程,发展空间太阳能发电站必将给其他领域带来很大机遇^[1]:①给能源市场,特别是电力工业带来革命性的进步与发展,国际性电力贸易概念加强。由于空间太阳能发电的定向操纵简单,将给世界电力供应带来更大的灵活性。任何地区都可以从空间电力公司购买太阳能或“太阳燃料”,而不用花很大代价进行远距离电缆架设。同时,现在电网所不能到达的地区也将方便地用上电。②给空间太阳能发电站相关基础技术行业(如微波发射、接收产品,太阳电池产品行业等)带来很大的发展机遇。一个大型空间太阳能发电站所需要的设备规模很大,就太阳电池而言,目前世界的年生产量才 100MW,对于一个 5GW 的发电站将需要 50 年生产量的积累,而对于 20 世纪中叶 200 亿千瓦的需求,将需要 20 万年的生产量。这说明现有的太阳电池生产量远远不能满足空间太阳能发电站的需求,未来太阳电池的发展前景相当广阔。其他相关基础技术行业也一样。③给包括运载在内的航天产品创造发展机遇。同时,发射业务更加繁忙,国际间空间贸易将大幅度增加。由于空间太阳能发电站庞大,根据现有运载能力,需要几十次甚至上千次分批输送到地球轨道上,这将给空间运输业带来很大的商业机遇。未来空间太阳能发电站建设时所需的运输频率将可能和现在的航空运输业相当,可见,空间太阳能发电站的大规模发展将使航天运载业大有发展前途,包括运载生产和发射业务。④给未来电动汽车、飞机等提供新能源而使其多一种发展方向。同时,利用空间太阳能发电站能源可进行深入广泛的星际探测,空间旅游业也将可能成为新的经济增长点。空间太阳能发电站不仅用于地面主要电力供应,也可作为各种飞行器和电动汽车的能量。

7. 小结

空间太阳能发电站的伟大设想从提出至今已经有近一个世纪,美国、日本、欧洲等及我国政府和相关研究机构目前都在围绕空间太阳能发电站开展可行性和初步实验研究,试图解决空间太阳能发电站的科学难题。随着人们对太阳能发电站研究的不断进展,目前亟须解决的科学和工程难题如下:

(1) 太空太阳能电池板的光电转换效率最高可以达到多少? 太阳能电池板最大尺寸可以设计成多大? 空间太阳能发电站的能量能否满足人类的全部电能需求?

(2) 如何将电能从空间无线传输到地面? 如何采用激光实现超远距离无线能量传输?

(3) 如何将太阳能发电站发射到太空? 太阳能发电站的使用寿命多长? 太阳能发电站的性价比最终如何?

参 考 文 献

- [1] <http://baike.baidu.com/view/742860.htm>.
- [2] 王秩雄,王挺,乔斌.无线输电技术与卫星太阳能电站的发展前景.空间电子技术,2006,(2): 6—12.
- [3] http://en.wikipedia.org/wiki/Space-based_solar_power.
- [4] 李国欣,徐传继,黄秉琰,等.空间太阳能电站技术的可行性研究.上海航天,1998,(2): 13—18.
- [5] 钱钱.日本计划建立大型空间太阳能电站.军民两用技术与产品,2009,(12):6.
- [6] <http://www.newenergy.org.cn/html/0091/1100924669.html>.
- [7] 廖海青.太空发电厂.经济,2008,(1):118—121.
- [8] 王秩雄,胡劲蕾,梁俊,等.无线输电技术的应用前景.空军工程大学学报(自然科学版), 2003,4(1):82—85.
- [9] http://en.wikipedia.org/wiki/Wireless_energy_transfer.
- [10] <http://www.msfc.nasa.gov/news/news/photos/1999/photos99-096.htm>.
- [11] 李国欣,徐传继.国际空间太阳能电站的发展现状.电源技术,1998,33(3):128—132.

撰稿人：曹良才

清华大学精密仪器与机械学系

光镊及其应用

Optical Tweezers and Its Applications

1. 光和光的力学效应

光是地球生命的来源之一，是信息的理想载体和传播媒质，是人类认识外部世界的工具。随着科学的发展和人类文明的进步，人们对光的认识也越来越深入。光与其他物质一样携带有能量和动量，光与物体相互作用时彼此交换能量和动量。在光的作用下，物体产生的各种现象称为光学效应。人们由日常的经验很容易认识到光携带有能量，如光照射物体时物体的温度会升高，这就是光的热学效应。但与光的能量相比，光具有动量和角动量这一性质却是人们日常经验很难体验到的。实际上，光与物质相互作用的过程中，光与物质间也交换动量，使受光照射的物体受到一个力或力矩，即产生光的力学效应。

1873 年，Maxwell 在 1616 年开普勒提出光有压力的假说一个多世纪之后，用光的电磁波理论证明了光压力的存在，并计算了光压力。单个光子的能量极其微弱(约为 $10^{-14} \mu\text{J}$)，太阳直射地球表面所受到的光压力为 10^{-5}Pa ，所以，普通光产生的力难以察觉，人们从来感觉不到太阳光的压力。普通光几乎不能引起明显的宏观效应，这对光压的实验测量极为不利。直到 1901 年，俄国科学家列别捷夫第一次在实验室中观察到了光使悬丝扭转的现象，这就是著名的光压扭秤实验。

历史上，科学家试图用光的力学效应来解释类似“彗尾”背阳的自然现象。人们也大胆的设想过，利用光的压力效应制造光帆、光子飞船、光压缩核燃料等。然而，这些具有科学根据的“设想”却在很长一段时期只是“幻想”，因为普通光的压力远不能产生这些明显的宏观力学效应。于是，光具有动量这一基本属性很少受到关注，在历来的教材中，对光具有动量可以产生力学效应这一重要特性，仅限于简略介绍开普勒提出的光有压力的论断和列别捷夫的光压扭秤实验，没有像对光具有能量或光的波动性(衍射和干涉)那样进行直观的演示实验。

1960 年，高光子密度的激光问世，对光压的研究才有了突破性进展。激光的光子密度是太阳光的亿倍，这使得光与物体相互作用过程中能够产生明显的力学效应，对光压的研究成了 20 世纪后半叶的科学主流之一，并涵盖了众多学科与技术，创造了许多科学技术的新纪录，如原子束的激光偏转、激光冷却、

光学黏胶及原子喷泉等实验技术,以及玻色-爱因斯坦凝聚方面的工作,被授予1997年和2001年度诺贝尔物理学奖。

美国科学家 Ashkin(如图1所示)在研究原子冷却的同时首先提出利用光辐射压力加速或捕获微米粒子的设想,开拓了微米亚微米层次研究光的力学效应的应用。他首先设计了一个叫做“光学瓶”的实验,用两束弱聚焦激光束相向传播,成功地捕获到了直径约为 $1\mu\text{m}$ 的介电小球,之后又设计了多种装置来操作各种粒子。经过十几年的潜心研究,




图1 Ashkin

Ashkin 于1986年成功地利用一束强会聚激光束实现了对微粒的三维捕获,这一发明被形象地称为光镊(optical tweezers)。光镊的发明是光的力学效应走向实际应用的一个重要进展,光镊捕获和操控微小粒子的能力,使它成为一种深入研究微小宏观粒子的特有手段^[1]。

2. 光镊的原理和特点




图2 光镊原理图

光镊即光学镊子,顾名思义是一种利用光物理性质实现的工具,具有挟持和操纵微小物体的功能。经验告诉我们,传统的机械镊子用来挟持物体必须使镊尖接触到物体,然后施加一定的压力于物体,物体才会被钳住。光镊则大不相同,它通过光照射物体,与物体相互作用达到“钳”的效果,然后通过移动光束来移动物体。与机械镊子相比,光镊是以一种温和的、非机械接触的方式完成挟持和操纵物体的。尤为重要的是,在以形成光镊的光为中心的一定区域内,物体一旦进入这个区域就有自动移向光束几何中心的可能,其现象犹如飞行物坠入宇宙黑洞那样,表现出光镊具有“引力”效应(也有人称之为牵引束)。已经落入阱中的粒子若没

有强有力的外界扰动,物体将不会离开光学中心,一旦粒子偏离了光学中心也会很快回复原位,所以,光镊又酷似一个陷阱。光阱造成一个势能较低的区域(阱域),即从这区域内到区域外存在一个势垒。当物体的动能不足以克服势垒时,它将继续停留在阱内(如图2所示)。

由此可见,所谓光镊,其实是比拟宏观机械镊子对光的势阱效应的一种形

象而通俗的描述。所以,当我们在研究光镊自身的物理性质时,往往采用“光学势垒”、“光捕获阱”、“光梯度力阱”或“光学势阱”等物理术语。

光在一定条件下还带有角动量,角动量包括轨道角动量和自旋角动量。在光与物体相互作用的过程中,角动量的交换使物体发生转动,这是光的力学效应的另一种表现形式,称为光致旋转。1936年,Beth用一束圆偏振光束通过由细丝悬挂着的半波片观察到半波片在光的作用下发生旋转,即说明光的角动量传递给了粒子,这是人类首次在实验上观察到光致旋转。光镊的出现也促进了光致旋转研究的发展,光镊在三维空间束缚物体,就像一根无形的“悬线”把被作用物体“悬挂”起来,物体由于没有受到机械摩擦力,因而更容易旋转。1991年,Sato利用一束旋转的高阶厄米-高斯光,首次实现了激光光阱中粒子的旋转。光镊实现粒子的转动,它使光镊对微粒在三维操作的同时又增加了一维角向的操作,拓展了光镊的功能和应用。光致旋转也是实现微机械马达的有效驱动源。人们把这种能使粒子旋转的光束形象地称为光扳手(optical spanner)。

总之,激光的发明使光的力学效应的研究和应用有了新的突破。光与物质相互作用所表现的光压、散射力、偶极力、梯度力、扭力矩等形成了一个个新兴研究领域。激光力学应用非常广泛,涉及物理、化学、材料、机械、生物和医药等领域,光镊技术已成为多学科交叉的基础。利用光的力学效应开拓学科交叉,也是21世纪跨学科研究的前沿领域。

3. 光镊技术的应用

1) 活细胞的搬运工

光镊可以灵活控制微米亚微米粒子,在保持处在生长环境中的细胞仍可以与外界沟通的情况下,对目标细胞进行非接触式的捕获与固定,或进行其他精确的操作。这种新型的单细胞操作技术是极其温和的,它克服了以往单细胞操作中细胞难以被固定和易产生机械损伤这两个致命的弱点,在生命科学研究中,几乎所有的单细胞操作中都可以用光镊替代传统的实验技术。光具有穿透性,可以穿过细胞膜深入到细胞内部操作细胞器,这也是机械镊子望尘莫及的。

一个能够抓活细胞并自如操作细胞的镊子引起了生命科学家的极大关注,人们纷纷尝试利用这个新工具研究活细胞和细胞器。对细胞进行固定、悬浮、分选、操纵,捕捉染色体、微胶囊,用于细胞融合,克服鞭毛旋转力矩和研究细胞骨架等,生命科学从此多了一个新的研究细胞的手段。

图3为用光镊捕捉一条水稻染色体(荧光标记)并将它从群体中分离。由此可以看到,光镊能够将细胞或细胞器从复杂环境中取出来,保持它的生长要求,并可以在较简单易掌握的条件下研究和观察其功能,这一直是生命科学研究个体活细胞所梦寐以求的。利用光镊捕捉并移动目标粒子的功能,将观察“对象”

人为进行“配对”并观察“配对”后的新变化,这种方法使得研究从以往只能在显微镜下“观测”上升到真正的“科学实验”。




图3 光镊捕捉一条水稻染色体(荧光标记)并将它从群体中分离^[2]


2) 直接显示微观粒子行为, 展现神秘的微观世界

自然界中,一切宏观现象都是大量个体行为的群体效应,因此,深入理解宏观自然现象就需要获取个体行为信息。光镊是个体行为研究的工具,光镊的应用都是基于对单个微粒的捕获与操控。光镊系统提供了在直接可视的条件下,测量粒子的各向异性、探索样品的局部微观性质,因此,能够直接检验已有的理论和系综统计结果,建立新理论,使得实验和理论能同步进行的研究新阶段。

分散体系是由许多粒子构成的复杂物理系统,是化学反应和生命活动最常见的与我们生活息息相关的物质,如污水、奶酪、指甲油和血液等,病毒、胶体、悬浊液和乳浊液都属液态分散体系。当粒子从分散态过渡到聚集态时,粒子所有的性质都会发生显著变化,所以,研究其胶体布朗运动行为的特征量,如扩散系数和黏滞系数,以及粒子的相互作用等性质是非常重要的。以往人们只能在宏观层面上研究分散体系的系综统计特性,有了光镊技术就可以从微观层次进行实验研究,测量个体及个体相互作用,深入理解宏观性质的微观机制^[3,4]。


例如,分散体系中的粒子由于布朗运动的随机性,人们无法预先判断碰撞在哪两个粒子间、在什么地方发生,所以,很难在实验上观察到这类运动和碰撞过程。中国科学技术大学研究人员利用在显微镜下观测光镊操控单个微粒的特点(如图4所示),设计用光镊先后捕获两个粒子,将它们局限在显微镜可以观察到的区域内,使其发生碰撞,并实时跟踪它们的碰撞聚集过程。

实验先用光镊捕获一个粒子,然后再捕获另外一个粒子[如图4(a)所示],一段时间后取消光镊将它们释放,观察两个粒子是否结合[图4(b)为分散,图4(c)为结合],通过对光镊中两个粒子体系的大量实验进行统计,得到两个粒子结合的概率。这种人为诱导粒子碰撞并测量粒子之间结合力的方法解决了由于粒子碰撞是随机而无法直接观察碰撞聚集过程这一困难,从而实现了从粒子层次研究粒子碰撞聚集过程的规律,建立了光镊中两个粒子碰撞聚集过程的物理模型。

图 4 显微镜视场直接观测光镊中两个粒子的聚集和分散^[5]

3) 皮牛力的探针

光镊操控物体实际上是光向物体施加作用力，该力的大小为 10^{-12} N，皮牛量级正是细胞大分子相互作用力的范围。光镊力的分辨能力在飞牛量级，是目前世界上测力分辨精度之最。科学家欣喜地发现了光镊这一优势，将其作为力的探针用来精确研究细胞分子等微粒间相互作用的力。作为单分子操纵技术，与原子力显微镜、磁镊、纳米孔及微流腔等相比，光镊的非侵入的力更适合于生物学研究，它使得传统热力学及统计力学无法实现的单分子水平上分子间相互作用测量成为可能(如图 5 所示)。

图 5 光镊研究驱动蛋白马达沿微管运动^[3]

科学家们已经利用光镊技术在单分子研究中取得系列成果。例如，研究单个驱动蛋白分子产生的力及单个驱动蛋白的速度与 ATP 浓度的函数关系；研

究肌动蛋白丝与单个肌球蛋白分子间的相互作用，测量了没有 ATP 水解时单个肌球蛋白分子和肌动蛋白纤维分离时所需的力。单个分子运动实验引发了对运动详细模型、ATP 水解环、单酶动力学的深入研究，科学家可以通过这种方式追踪各种单个分子的变化，研究所有的 DNA 酶，以揭示分子水平上生物体系的工作机制，回答以前经典的、大范围研究的生化方法所不可能解决的问题。

4. 光镊技术已经解决的重大科学问题

这里仅列举两项利用光镊技术在科学上产生具有划时代突破的成果。

1) 解开生命的动力源之谜

动物体内的肌肉是怎么收缩产生运动的？驱动着一切活体的运动，或者说一切生物运动的原动力是如何产生的，一直使科学家们迷惑不解。已有的宏观方法捕捉不到动力源的个体作用。因为缺乏有力的实验依据，这个问题一直没有一个令人信服的结论。现在利用光镊可以将肉眼完全不能分辨的单个肌动蛋白元和肌动纤维丝附着在只有几千分之一毫米直径的微珠上，然后在显微镜的监控下通过观察微珠的运动从而获得大分子的运动轨迹。劳兰德科学研究所的 Block 研究组把光镊对准单一的分子，观察到了驱动蛋白实际上是沿其蛋白轨道或微管按每步 8nm 的步距不连续地推进，如同孩子们过池塘时沿踏脚石迈步一样。这一实验现象终于成功地说明了我们体内的肌动蛋白元的运动情形(如图 6 所示)。正是这样一步步跳跃式的前进方式，构成了我们现在的一切运动(包括吃饭、喝水，乃至血液循环、呼吸运动)的基础。每个动力原蛋白分子就像一个看不见的幽灵一样控制着生物体千姿百态的运动，了解了这些动力原蛋白的运动方式，就知道了生命的动力来源，就可以解释生物体内各种各样的动力行为，洞察和认识生命活动的基本规律。光镊使辨认单一动力原蛋白分子的分步运动成为可能，帮助科学家解决了一直以来未能解决的难题，拉开了科学界揭示分子动力原运动本性研究的帷幕。



图 6 光镊研究驱动蛋白沿微管的运动规律^[4]

2) 挑战爱因斯坦 100 年前的科学预言




图 7 光镊测布朗粒子的瞬时速度^[6]

2010 年,《科学》杂志报道了采用光镊技术首次证明能量均分定理也适用于布朗粒子,证明了一百多年前爱因斯坦提出的预言。1827 年,英国植物学家布朗发现,气体和液体中的微观粒子由于气体与液体分子不断的无规则碰撞作用会一直处于无规则运动状态。1907 年,爱因斯坦提出了能量均分定理,指出这种微粒的动能与粒子体积和质量无关,但这个预言难

以从实验上直接证明,因为布朗运动中粒子的高速碰撞会导致其运动方向和速度不断发生变化,单个布朗粒子的瞬时速度将无法测定。现在,科学家可以采用光镊技术在空气中测定布朗粒子瞬时速度。美国德克萨斯大学的研究人员用两束激光捕获一个直径为 $3\mu\text{m}$ 的玻璃珠,并让其悬浮在空气中。通过测量激光束偏移的距离,就可以计算出玻璃珠移动的距离。根据这些测量数据,研究人员每隔 $5\mu\text{s}$ 就可获得一次玻璃珠的速度值,并直接证实了能量均分定理也适用于布朗粒子(如图 7 所示)。

5. 光镊技术的未来

二十多年来,光镊自身在不断地快速发展。光镊技术已从微米精度的操控与探测发展到了纳米精度的操控与探测,从只有单光镊系统发展成为具有多个机械手的多光镊系统,光镊已发展出一个丰富多样的光镊家族。光镊技术与现代高分辨率成像及数字图像分析相结合,形成了一种强大的实验技术平台。光镊技术也正在与其他多种技术相衔接,从深度和广度上已迈入了一个具有独立内涵和外延的新领域。目前阶段,光镊技术的发展和运用还面临着许多新的问题待我们去解决。

1) 宽场光学显微镜下纳米粒子的实时观测和操控

宽场光学显微镜一直是生命科学研究中最主要的工具之一,其非接触、无损伤的特点是生物活体细胞及生物单分子三维成像的有利条件。光镊技术可以直接操控纳米粒子,但由于光学显微镜的分辨限制,光镊只能工作在亚微米尺度。因此,在光镊系统中如何深入纳米尺度的可视观测和操控的研究,是目前宽场光学显微镜系统的一个技术瓶颈。光镊技术的再发展同样要求发展超高分辨率的成像技术,从而在分子尺度上探测生命活动的细节。因此,结合宽场光镊系统的特殊性发展,高空间分辨率与成像技术也是当务之急。

2) 全息光镊光场的有效调控

全息光镊是光镊大家族中一位具有广阔应用前景的新成员。全息光镊主要通过空间光调制器^[7]对入射光场的相位和振幅等分布进行调制,形成可同时操控多个粒子的并行光操控技术或新型分布的调制光阱,如无衍射的 Bessel 光、Airy 光等。这些新型的调制光镊技术所展现的光学微操纵技术在细胞的分子生物学机理研究、生物高分子材料的机械力学特性等研究中具有原子力显微镜、扫描隧道显微镜等其他技术无法比拟的优势。然而,全息光场需要通过与计算机等技术结合,适时动态地改变全息光阱中的光场分布。受计算机处理速度及现有算法本身的限制,动态全息的光场分布质量并不理想,这就需要发展一些实时、原位、快速的光场调控、波前校正算法。如何通过设计有效的计算机算法对光场进行实时有效的调控,消除仪器、活体组织和流动介质等对光场分辨的影响,使得新型光镊技术在实用化方面向更深层次推进将是一个值得研究的基于多学科交叉的科学难题。

3) 光镊技术的普及和仪器的实用化

简单的光镊装置包括形成光镊的光学部分、显微镜光学成像部分、样品和样品操控部分、显微成像记录及计算机与视屏显示部分。光镊技术已与多项技术结合,由于研究复杂性的增大、测量维度的增加及精度要求的提高,使得实验装备愈加庞大,操作烦琐,使用者必须经过专门的学习和训练,这无疑制约了光镊技术的应用推广。如何解决现有光镊系统对庞大的显微镜作支架的依赖,简化设备和操作;如何从根本上对硬件和软件进行改革,使对大量实验测量信息的处理更方便;如何标定统一光镊系统的技术参数,解决这些问题正是现今光镊技术的研究者肩负的重任。

4) 追踪粒子的三维运动轨迹

对纳米颗粒的轨迹进行三维追踪是很多领域的重要研究技术。若能够在液相中三维追踪纳米颗粒的运动轨迹,则可以在细胞生物学中研究物质的传输、膜转运和马达的工作循环等,在流体力学中测量速度场和流体特性,在胶体领域研究颗粒的相互作用势和自组织单分子层的形成过程。目前,追踪纳米颗粒的轨迹,一般将所研究的对象(如蛋白等颗粒)连接荧光标记分子,通过监测荧光分子实现对纳米颗粒的纳米精度追踪,这种追踪纳米颗粒的方法一般局限于二维方向,无法直接定位沿光轴方向的空间位置,而颗粒在溶液中的布朗运动实际为三维运动。因此,发展新的三维追踪纳米颗粒的方法对研究和应用具有重要意义。

6. 结束语

尽管科学实验技术日新月异,各种新方法、新思路层出不穷,但在探索微

观世界和研究生命现象领域中,光镊技术依然有巧夺天工不可替代的优势。虽然光镊的贡献已远远超出了 Ashkin 当时的预言——“将细胞器从它的正常位置移去的能力为我们打开了精确研究细胞功能的大门”,但对生命进行直接研究是人们梦寐以求的,以往的光镊应用还处在对生物的离体研究阶段,如何直接运用到活体研究中去,是光镊技术领域面临的巨大挑战。

参 考 文 献

- [1] 李银妹.光镊原理、技术和应用.合肥:中国科学技术大学出版社,1996.
- [2] Wang H W, Liu X H, Li Y M, et al. Isolation of a single rice chromosome by optical micromanipulation. *Journal of Optics A-Pure and Applied Optics*, 2004, 6: 89—93.
- [3] Ishii Y, Yanagida T. Single molecule detection in life science. *Single Mol.*, 2000, 1: 516.
- [4] Svoboda K, Schmidt C F, Schnapp B J, et al. Direct observation of kinesin stepping by optical trapping interferometry. *Nature*, 1993, 365: 721—727.
- [5] Sun Z, Xu S, Dai G, et al. A microscopic approach to studying colloidal stability. *J. Chem. Phys.*, 2003, 119: 2399—2405.
- [6] Li T, Kheifets S, Medellin D, et al. Measurement of the instantaneous velocity of a brownian particle. *Science*, 2010, 328: 1673—1675.
- [7] Ren Y X, Li M, Huang K, et al. Experimental generation of Laguerre-Gaussian beam using digital micromirror device. *Appl. Opt.*, 2010, 49: 1838—1844.

撰稿人: 李银妹¹ 张晓晖²

1 中国科学技术大学光学与光学工程系

2 中国科学院上海生命科学研究院

全光开关研究进展

Progress in All-optical Switching

1. 全光开关的意义和分类

1) 全光开关的重要性

大家知道,电学和光学都起源于18世纪的物理学,电子与光子都是基本粒子,两者皆具有波动性,同属一个电磁波大家庭。但从电子学和光子学的发展进程来看,电子学比光子学快得多,而且成熟得多。1906年,电子管的发明标志着电子学的诞生,1948年,半导体晶体管的发明标志着电子学从电子管电子学阶段跨入了半导体微电子学阶段,1960年,集成电路的诞生更促进了电子技术的大发展。今天的有线和无线电通信、网络技术、雷达遥感技术、功能强大的电子计算机技术,以及其他数字化处理的电子技术,无不建立在以弱电控制强电的器件——晶体管的基础之上。总之,有了晶体管,才有电子学今天的辉煌成就。

光学由于缺乏相干光源而发展缓慢,在电子学诞生的半个世纪以后,1960年发明了激光器,光子学才登上现代科学技术的舞台。1970年,光纤、室温半导体激光器及集成光学的发明大大促进了光纤通信的发展,光子学进入了微光子学阶段,也就是光电子学阶段。这个时期的基础器件,如半导体激光器、电光调制器和光开关都是以电控光的。信息技术的重要系统,如光通信系统、计算机系统 and 光传感系统都还是光电混合的。

激光已产生了半个世纪,至今还没有“光晶体管”或“全光开关”问世。因此,不能做到以弱光控制强光,不能进行数字光学信息处理,无法实现全光通信和全光计算机。由此可见,光子学的“光晶体管”的发明与电子学的晶体管的发明相比已经落后了100年!

目前,由于光纤通信技术的推动,电控光开关已经获得应用,这是基于电光效应、热光效应、磁光效应、声光效应、电致偏振效应(电光液晶)、电致机械效应(MEMS)等效应的光开关,它们靠电场、电压或电流控制,这类开关成本较低,工作可靠,但必须经过光电转换而效率较低,还存在开关速度较慢(毫秒至纳秒量级)及噪声较大等问题。

为了实现光通信中光信号的全光交换,以及实现光计算机中的光子芯片,必须采用直接在光域中运作的、效率高、噪声小、开关速度快(纳秒至皮秒量

级)的全光开关。

对电子来说,实现以电控电的电子开关比较容易,因为运动的电子周围会产生电磁场,直接影响其他电子的运动。而光子不带电,不能直接相互作用,只能采用非线性光学方法间接地实现以光控光。例如,为了对介质中传播的信号光实施开关运作,可以用一束外加的强光(交叉泵浦)与介质相互作用,或者用信号光本身的强光(自泵浦)与介质相互作用,使介质的光学参量发生非线性变化,如介质的吸收系数或折射率发生依赖于光功率的变化,从而改变在介质中传播的信号光的波矢、相位或偏振,最后实现对信号光的强度(振幅)或传播方向的控制。总之,全光开关是通过控制光对介质的非线性光学作用来改变被控制的信号光的各种参量的器件。

光波信号有许多参量,如功率(光强)、波长(频率)、方向、相位、偏振等。一般的光学器件只是改变光波参量的大小。例如,光放大器是改变光强大小的器件,光变频器是改变光频率的器件,这些器件都不是光开关。光开关对光参量的改变是不连续的,而是从一个状态向另一个状态突变,而且这种变化是可逆的(或可恢复性的)。此外,完成开关所耗费的时间是短暂的(纳秒至飞秒量级)。所以,光开关可以定义为使光信号的参量发生快速、可逆转换的器件。

2) 全光开关的分类

(1) 按材料的非线性机制分类。全光开关有许多不同的非线性光学机制,主要的非线性机制与相应的工作原理如表 1 所示。

表 1 全光开关的非线性机制与工作原理

非线性机制	工作原理
非线性折射	光 Kerr 效应, 自聚焦和自散焦效应, 双光子折射效应
非线性吸收	饱和与反饱和吸收, 双光子吸收, 二相色性
非线性反射	非线性界面, 两棱镜或两光栅夹非线性液体
非线性偏振	强光使液晶、手性材料等产生非线性旋光效应
非线性变频	倍频、和频、参量过程、四波混频、受激拉曼等
非线性相变	光致材料相变, 引起介质折射率或吸收系数变化
非线性光栅	单个非线性光栅, 短周期光栅对, 长周期光栅对
非线性耦合器	强光入射非对称的光耦合器引起两臂光的相位差
非线性放大器	强光使半导体光放大器饱和而改变光的相位
非线性干涉仪	强光使干涉仪部件折射率变化导致两光束相位差 π

(2) 按信号光的参量分类。相对于信号光的不同参量,有不同类型的光开关,如强度开关、波长开关、方向开关、相位开关、偏振开关等。通常,用得较多的是强度开关、方向开关和波长开关,如图1所示。强度开关是在同一输入光功率下输出光功率在“有”和“无”(或强和弱)间转换的开关,如光学双稳器件。




图1 全光开关按其光参量分类

许多光开关都存在两个以上的输出端口。方向开关是在同一输入光功率下输出光功率在不同输出端口间转换的光开关,如非线性定向耦合器。波长开关是一个波长为 λ_1 的信号光在输出端口转换为波长为 λ_2 的信号光的开关。

(3) 按光开关的功能分类。全光开关按开关的功能分类可分为普通光开关、光限制开关和光双稳开关三类,如图2所示。




图2 光开关按开关功能分类

普通光开关在开关动作之前输出光一直处于低透射功率状态 (P'_t),直到入射光强达到阈值 (P_{on}),才突然开启到高透射功率状态 (P''_t)。而光限制开关在弱光功率下,其透射光功率随入射光功率的增大而线性增大(透射率不变),当入射光功率达到一个阈值 (P_{on})时,透射光功率被限制在一个较低的光功率 (P_{ec}),透射率为零,这种开关用于防护激光损伤。普通光开关与光限制开关属于单值型开关,这两种光开关是靠改变作用于介质上光功率大小来控制开关动作。光双稳开关对应于一个入射光功率(维持功率 P_0)有两个稳定的透射光功率状态 (P'_t 和 P''_t),若要实现这两个输出状态间的转换,要靠另外两个控制光来开启和关闭开关,相当于电子学的触发开关。普通光开关抗噪声的能力较低,如果噪声处于 P_{on} 附近,容易产生开关的误导动作而工作不稳定;而对于光双稳开关,在双稳区以内的工作点,若噪声幅度远小于双稳区的宽度,工作非常稳定,不受噪声影响。三种开关的共同特点是需要通过输入泵浦光(包括交叉泵浦或自泵浦两种方式)来驱动信号光的开启或关闭。 P_{on} 是最低的开启光开关的入射光功率,简称为开关功率。

2. 典型的全光开关器件举例

1) 双稳态半导体激光器

最早的全光开关是 1964 年 Lesher 提出的一种电注入式双稳态半导体激光器^[1]，在 GaAs 器件的 P 型区内设计了两个区：光发射增益区和非线性吸收区，对相同的注入电流有两个输出光强状态，可用光脉冲导致饱和和吸收来实现双稳的开关转换，如图 3 所示。




图 3 GaAs 双稳态半导体激光器结构

2) 半导体量子阱 F-P 型双稳光开关

这是在 F-P 光学谐振腔内只含折射型被动非线性介质的光学双稳器件。1982 年，Gibbs 发明了室温运转的、GaAs 量子阱的光学双稳开关器件^[2]，如图 4 所示。




图 4 GaAs/AlGaAs 多量子阱室温运转光学双稳器件结构

这是一种基于量子阱材料的纳米光子开关器件，平均开关功率已低达

10mW 以下, 达到了实用要求, 但由于受半导体载流子复合寿命的限制, 开关时间只达到 20ns。

3) 非线性 M-Z 干涉仪型全光开关

人们研究了多种基于非线性干涉仪的全光开关^[3], 除了多光束干涉的非线性 F-P 干涉仪和非线性环共振器外, 还有双光束干涉的非线性 M-Z 干涉仪、非线性 Sagnac 干涉仪、非线性定向耦合器、非线性光纤光栅等, 其中, 最简单的是非线性 M-Z 干涉仪, 如图 5 所示。




图 5 非对称非线性 M-Z 干涉仪

若信号光从 1 端输入, 耦合器 DC₁ 将入射光等分为强度相等的两束光, 分别通过长为 L_1 和 L_2 、折射率为 n_1 和 n_2 的两直波导传输, 产生相移 ϕ_1 和 ϕ_2 , 两束光到达耦合器 DC₂ 进行干涉, 然后从 4 端或 3 端输出, 两输出光强的分配取决于两臂光干涉的相移差 $\phi = \phi_1 - \phi_2$ 。

设 $L_1 = L_2$, $n_{21} = n_2 \gg n_{22}$, 当入射功率增大, 光 Kerr 效应引起臂 I 折射率的变化正比于入射光功率, $\Delta n = n_2 \frac{P_1}{2S}$, 忽略臂 II 的折射率变化, 则相移差 $\phi = \frac{2\pi}{\lambda} \Delta n L = \frac{2\pi}{\lambda} n_2 L \frac{P_1}{2S}$ 。当 $\phi = \pi$, 则实现输出光从 4 端到 3 端的转变。此时, 相应的阈值开关功率为

$$P_{1c} = \frac{\lambda S}{n_2 L} \quad (1)$$

可以证明, 所有干涉型全光开关的阈值开关功率的公式都包含式(1)的因子。由式(1)可见, 为了降低全光开关的开关功率, 必须寻找非线性系数 n_2 大的材料, 减小波导的横截面 S , 加长非线性作用距离。如果把器件做成环形结构, 就可以在环长很小的条件下无限加长非线性作用距离。此外, 光开关的开关时间与器件的尺寸有关, 在小的器件尺寸下, 可以获得较快的开关时间。从此, 我们受到启发, 要想达到全光开关实用化的要求, 必须减小器件的尺寸, 在纳米光子学条件下有可能做出实用的全光开关来。

4) 纳米波导环共振器全光开关

在单光子的光 Kerr 效应下, 折射率的变化与泵浦光功率成正比, 但在双光子效应下, 半导体材料的折射率变化与泵浦光平均功率的平方成正比。只有在

飞秒激光的作用下,才能突显双光子效应。双光子效应不仅使材料的非线性效应加强,从而降低阈值开关功率,而且对提高开关速度有利。下面以 2004 年 Lipson 研究组发表的纳米硅波导环共振器全光开关^[4,5]为例来说明,他们的实验装置如图 6 所示。




图 6 纳米硅波导环共振器全光开关

飞秒激光作用于石英环材料,产生双光子吸收效应,因而改变载流子(电子与空穴)的浓度,导致材料的吸收系数和折射率变化。实现开关的折射率变化量仅需 10^{-3} 。在共振的情况下,折射率变化引起输出光波长发生变化,波长调谐量为 0.1nm ;从 1554.5nm 的开态转变为 1554.6nm 的关态,从而实现光开关,如图 7 所示,开关时间约 70ps 。




图 7 纳米硅波导环共振器全光开关工作原理

5) 含环共振器的 M-Z 干涉仪全光开关

1999 年,Boyd 研究组提出在石英光纤 M-Z 干涉仪的一臂上耦合一个光纤环共振器^[6],相当于把 M-Z 干涉仪的长臂无限延长,如图 8 所示。信号光在环腔中往复环行,积累非线性相移,使两臂的相移差达到 $\phi=\pi$,从而实现由端口 4→3 的开关,在环长 10m 的情况下,开关功率可以降低到毫瓦量级。

理论分析得到,不计损耗时,阈值开关功率为

$$P_c = \frac{\lambda_0 S}{n_2 l} \left(\frac{\pi}{2 F_{\max}} \right)^2 \quad (2)$$

式中, n_2 为环的非线性折射系数; S 为波导有效截面; l 为环长; $F_{\max}$ 为耦合器





图 8 在 M-Z 干涉仪一臂耦合环共振器的全光开关

DC 的反射系数 $r \rightarrow 1$ 、环的损耗率 $\alpha \rightarrow 1$ 及环共振条件下的最大环共振器的精细度，也就是光开关的阈值开关功率因环精细度的提高大大减低。

事实上，实际光开关器件中存在很大的损耗，包括光波导的吸收损耗、弯曲损耗、耦合器的插入损耗、器件之间的连接损耗等，这些损耗的存在大幅度降低环的精细度，甚至会使器件丧失开关功能。为此，2004 年，李淳飞研究组首次提出，以掺铒光纤(EDF)环代替普通光纤环，加以泵浦光，构成掺铒光纤放大器(EDFA)型的环共振器(有源环共振器)^[7]，如图 9 所示。



光与探测光入射样品的相对时间，通过一对耦合棱镜输入与输出光子晶体，输出光用光纤单色仪和计算机处理。

这种光开关的特性是：泵浦功率为 0.1 MW/cm^2 ，响应时间为 1.2 ps ，开关对比度为 80% 。这是目前阈值最低、速度最快的全光开关，此工作有待改进的是：①探测光波长需改成 1550 nm 通信波长；②有机材料的稳定性有待提高；③棱镜耦合不易实现集成化，需要改进。




图 10 光子晶体缺陷位移全光开关

3. 全光开关的困难和出路

人们从激光发明后不久就开始研究全光开关。历时半个世纪，投入了大量资金，发表了大量学术论文，但研究结果至今达不到应用的要求。实用的光开关要求满足以下三个基本指标：①要求光开关的驱动功率(泵浦功率)低到毫瓦以下，即与信号功率可以相比，过高的光功率会产生严重的发热现象，使器件工作不稳定；②要求光开关的开关时间短于皮秒以下，即要比电子开关的最高速度更快，否则不能显示光开关的优越性；③要求光开关工作在光通信波段(如 $1.55 \mu\text{m}$)，在该波长下，光吸收最小，开关器件可以实现级联运转。但是，要同时达到以上三个要求难度极大。

为什么直到今日研究不出可实用的全光开关？这是因为全光开关存在如下困难：

(1) 一般全光开关是基于材料的三阶非线性光学效应，这种效应极其微弱，需要很高的开关功率。但是，高功率激光会造成很强的热效应，致使器件工作不稳定。

(2) 很多材料的高非线性折射系数往往处于材料吸收峰的波长处，材料的高非线性可降低开关功率，却增强了材料的光吸收，使开关无法级联运转。

(3) 光开关的开关时间包括开启时间和关闭时间。开启时间取决于材料的

非线性响应时间,可以短到皮秒以下,但关闭时间一般比开启时间要长得多。例如,半导体光开关的关闭时间比开启时间慢 $3\sim 4$ 个数量级,主要因为受载流子复合寿命(约几十纳秒)的限制。因此,一般半导体光开关的开关时间很难做到比纳秒更短。

(4) 光开关器件的开关功率与开关速度之间存在着根本性的矛盾。一般而言,开关功率越低,开关速度越慢(如液晶);开关速度越快,开关功率越高(如高分子材料)。又如,为了使器件工作在光通信波段以降低光吸收,故选取石英材料做光开关,但石英的光学非线性太弱,需要高开关功率。为了降低开关功率,可采取环形共振腔结构,以便在环行中积累光学非线性。但是,开关速度却受到共振腔光子寿命的限制,一般被限制在纳秒量级。

那么,克服全光开关上述困难、解决实用化困难的可能出路是什么?

(1) 继续探索优质光开关材料,该材料必须具有高非线性、低开关功率、快响应速度、高透明度(低吸收、低散射),以及合适的工作波长。在材料的相互矛盾的性能参数中,根据应用的需要,寻找材料指标的最佳平衡点。

(2) 为了降低开关能量,采用截面积小到纳米量级的波导,使光功率密度提高,如纳米光纤、纳米平面波导或光子晶体波导。

(3) 为了降低开关功率,采用尺寸长的波导,但器件体积变大,开关时间变长。因此,建议采用微环结构,相当延长波导的长度,体积也可缩小。为了缩短腔寿命,要减小环长。

(4) 为克服载流子复合寿命的限制,缩短光开关的关闭时间,可采用超薄材料;或者采用两束脉冲光来分别控制开关的开启和关闭,做成光触发器。

(5) 为了克服开关器件的光损耗,提高阈值开关功率,可以在光开关中加入光放大器或 EDFA,不过它会给光开关的制备带来复杂性。

(6) 采用飞秒脉冲光驱动开关,可以激发材料的双光子吸收效应,与单光子的光 Kerr 效应相比,既可降低开关所需的平均功率,又可提高开关速度。

总之,全光开关的实用化是一个难以解决的问题。从现在的研究趋势看来,以飞秒激光驱动的纳米尺寸的全光开关有可能解决全光开关的实用化问题。也就是说,全光开关的实用化问题有可能在时间与空间高度集中的条件下得到解决。

参 考 文 献

- [1] Lesher G J. Analysis of a proposed bistable injection laser. Solid-State Electron., 1964, 7:707.

- [2] Gibbs H M ,Tarng S S ,Jewell J L ,et al .Room-temperature excitonic optical bistability in a GaAs/GaAlAs superlattice etalon .Applied Physics Letters ,1982 ,41 ;221—222 .
- [3] 李淳飞 .全光开关原理 .北京 :科学出版社 ,2010 .
- [4] Almeida V R ,Barrios C A ,Panepucci R R ,et al .All-optical control of light .Nature ,2004 ,431 ;1081—1084 .
- [5] Lipson M .Overcoming the limitations of microelectronics using Si nanophotonics :Solving the coupling ,modulation and switching challenges .Nanotechnology ,2004 ,15 ;622—627 .
- [6] Heebner J E ,Boyd R W .Enhanced all-optical switching by use of nonlinear fiber ring resonator .Opt .Lett .,1999 ,24 ;847—849 .
- [7] Alireza B ,Li C F .Controllable all-optical switch using an EDF-ring coupled M-Z interferometer .Photo .Tech .Lett .,2004 ,16(9) ;2102—2104 .
- [8] Hu X ,Jiang P ,Ding C ,et al .Picoseconds and low-power all-optical switching based on organic photonic band gap micro-cavity .Nature Photonics ,2008 ,2 ;185—189 .

撰稿人：李淳飞
哈尔滨工业大学物理系

太赫兹波

Terahertz Wave

太赫兹波是指频率分布在 $0.1 \sim 10\text{THz}$ ($1\text{THz} = 10^{12}\text{Hz}$) 波段内的电磁波, 其相应波长分布为 $30\mu\text{m} \sim 3\text{mm}$ 。太赫兹波处于微波和红外之间(如图 1 所示), 是宏观电子学向微观光子学过渡的波段, 覆盖了半导体、等离子体、凝聚态、有机体和生物大分子等多数物质的特征谱分布。由于 20 世纪 80 年代以前缺乏有效的太赫兹波的产生方法和探测手段, 人们对该波段电磁波的性质知之甚少。相比于较为成熟的微波和光学而言, 太赫兹波的相关研究十分滞后, 从而形成了电磁波谱研究上的“太赫兹空白”。因此, 太赫兹作为一个新的前沿交叉研究领域和新的科学研究手段, 有待人们对其进行全面深入的研究。利用该波段可以加深和拓展人类对物理学、化学、信息学、生物学和天文学等科学领域中的一些基本科学问题的认识。




图 1 电磁波谱中的太赫兹波

1THz 的光子能量为 4.14meV , 等效热力学温度为 48K , 所以, 任何温度在 48K 以上的物体都会向外辐射太赫兹波, 不过, 这些太赫兹波非常微弱且难于探测与应用。由于常温物体的温度平均为 300K , 宇宙背景辐射的温度是 2.7K , 因此, 太赫兹波广泛存在。其中, 宇宙背景辐射中有 50% 的能谱分布是在太赫兹波段, 而宇宙大爆炸所产生的光子有 98% 都是太赫兹波光子 ($0.6 \sim 7.5\text{THz}$)^[1]。

太赫兹波虽然广泛存在, 但不为人们所熟知, 再因其所具有诸多特殊特性, 使太赫兹科学技术可广泛应用于雷达、遥感、国土安全与反恐、高保密数据通信与传输、大气与环境监测、实时生物信息提取和医学诊断等领域。由此, 太赫兹科学成为近年来电磁波谱研究的热点^[2]。

与高频光波相比,太赫兹波具有如下特点:

(1) 高透性。太赫兹波对于许多非极性物质和非金属材料,如介电材料、塑料、布料和纸张等包装材料具有很高的透过性,由此可将太赫兹波应用于安检、质检等领域。另外,太赫兹波对烟雾、沙尘、阴霾等空气中悬浮物也具有好的透过性。由此,太赫兹波可应用于全天候导航、遥感等领域。

(2) 安全性。太赫兹光子能量在毫电子伏特量级,而生物体的电离阈值为 12.5eV,与 X 射线(keV)相比,太赫兹不会因为光致电离而破坏被检物质。由此,可利用太赫兹波对生物活体进行检测。

(3) 指纹谱。太赫兹波谱中包含了丰富的物理和化学信息,许多大分子的振动能级跃迁和转动能级跃迁都在太赫兹波段有分布,特别是有机分子对太赫兹有强烈的吸收和色散特性,由此可利用太赫兹波研究这些物质的结构。另外,由于太赫兹波的典型脉宽在皮秒量级,利用取样测量技术可以方便地对各种形态的材料进行高时间分辨率、高信噪比、大范围的相干测量。

与低频微波或毫米波相比,太赫兹波具有如下特点:

(1) 带宽宽。太赫兹波的频率相对于微波或毫米波的频率较高,因此,当其作为通信载体时,在单位时间内能承载的信息更多。所以,太赫兹适合于无线局域网络通信、宽带移动通信和空间通信,并且下一代无线局域网络通信的主要目标就是太赫兹通信。ITU 已经指定将 0.12THz 和 0.22THz 分别定为一代地面无线通信和卫星通信的频段。

(2) 方向性好。太赫兹波的波长相对较短,所以,它的方向性要好于微波毫米波。由于太赫兹波在大气中传输距离有限,可利用太赫兹波作为定向短距离保密通信的一种手段。

(3) 分辨率高。由于太赫兹波长短,因此,太赫兹的分辨率较高,并且有很大的景深。另外,空气中杂质对其散射损耗较小,可用于太赫兹高分辨率成像。

对太赫兹波的研究实际上始于 19 世纪末期。Kimmitt 在对 NaCl、KCl 和 CaF_2 等晶体的色散与反射光谱的测量研究过程中,首次滤波分离出了太赫兹波(6~10THz)^[3]。另外,他们发现石英封装的汞灯是一种比较好的太赫兹波源,并且到目前为止,该光源依然被广泛使用于 FTIR 之中。在这段时期,太赫兹波主要用于化学和天文学领域,这是因为太赫兹波会被大气强吸收,化学家和天文学家主要利用太赫兹波谱技术研究一些简单分子的振动和转动的光谱性质及一些热辐射的谱线研究等。

到了 20 世纪 80 年代中后期,随着新科学、新材料,特别是超快光学的发展,为太赫兹波科学的发展提供了相对合适的光源和探测技术,使得太赫兹科学技术得到了飞速的发展,太赫兹科学也随之渗透到各个研究领域之中。目前,太赫兹科学研究大体分为基础研究和应用研究两部分,如图 2 所示。




图2 太赫兹科学技术

太赫兹基础研究大致包括太赫兹波源、传输、探测及太赫兹波与物质相互作用。其中，太赫兹波的产生和探测是太赫兹基础研究的两个关键领域。

(1) 太赫兹波源。根据太赫兹波段所处的位置，通过光学下变频、电子学倍频的方法或者结合两种方法来产生太赫兹波。目前，常见的太赫兹光学产生方法有光电导、半导体表面产生、光整流、光参量和光混频等。常见的太赫兹电子源通常有真空电子源、相对论性电子源和半导体电子源。近几年又出现了等离子体产生太赫兹波的方法。其中，光学方法和等离子体方法所产生的太赫兹波通常是宽带太赫兹脉冲(光混频产生连续太赫兹波)，如图3所示，而电子学方法所产生的太赫兹波通常是窄带连续太赫兹波。




图3 宽带太赫兹脉冲

虽然上述这些方法可以产生太赫兹波，但大部分太赫兹源的一些基础科学问题仍未完全解决，如光学源的输出功率和转换效率提高、真空电子源工作频

率提高、半导体太赫兹源,尤其量子级联激光器输出功率和工作温度提高等问题。由此,也涉及了太赫兹源在工作频率、输出功率、转化效率等方面的互兼容性,这就需要人们去探索新现象、新机理和新途径来解决这些问题。

光电导机制通常使用光电导材料作为辐射天线产生瞬态电流。当光子能量大于光电导材料能隙宽度的超短激光照射到材料上时,材料内部会产生电子-空穴对。在外加偏压的作用下,这些光生载流子会沿电场方向加速运动形成一个瞬变电流,从而向外辐射太赫兹脉冲,如图 4(a)所示;半导体表面产生机制则不需外加偏压场,而是利用半导体的表面场(表面耗尽场或 Dember 电场)作用光生载流子形成瞬态电流,最终产生太赫兹波,如图 4(b)所示;光整流和光混频都是利用二阶非线性效应在非中心对称或各向异性材料中产生太赫兹波。其中,光整流利用的是 $\chi^{(2)}(0, -\omega, \omega)$ 使飞秒激光脉冲和非线性介质相互作用产生低频振荡的时变电极化场,如图 4(c)所示;而光混频则是利用 $\chi^{(2)}(\omega - \omega, \omega, -\omega)$ 使两独立的连续波在光电导体或非线性晶体中发生外差混频;太赫兹参量源是利用二阶光学参量产生和放大效应 $\chi^{(2)}(\omega - \omega, \omega, -\omega)$ 及三阶非线性拉曼效应产生太赫兹脉冲,如图 4(d)所示。




图 4 太赫兹波光学产生方法

太赫兹真空微电子源主要有行波管、返波管、速调管等,它们基于微波管的分布作用原理,利用外部调制(如外置磁场、电场等)使电子经过一些特殊结构或材料,以此改变电子的运动或传输特性,即将初始空间中均匀分布的电子注不均匀化,利用电子呈周期性群聚而产生的电流振荡产生太赫兹波,如

图 5(a)所示,这类器件具有体积小、质量轻、性能稳定等优点。基于太赫兹相对论性器件主要有奥罗管、回旋管和自由电子激光器等,它们利用相对论原理,即电子的运动速度达到或接近光速时,以强磁场改变电子的运动方向,由此产生高功率、可调谐的连续太赫兹波,如图 5(b)所示。太赫兹半导体激光器常见的有耿氏二极管、P-Ge 激光器和量子级联激光器等,其中,耿氏二极管是基于负阻效应(耿氏效应)产生太赫兹辐射的,P-Ge 激光器是利用正交磁场引起浅掺杂 P-Ge 中的空穴数翻转形成太赫兹辐射,如图 5(c)所示。而量子级联激光器则不同于传统的半导体激光器,传统半导体激光器是基于电子从导带跃迁到价带实现辐射的,辐射波长取决于半导体材料的带隙,而量子级联激光器则是根据重复周期的量子阱结构,利用子带间的跃迁实现辐射、采用耦合量子阱模块的级联而实现单电子注入的多光子输出,如图 5(d)所示。太赫兹量子级联激光器是目前唯一能够在 1THz 以下提供平均功率大于 10mW 太赫兹波的固态相干太赫兹源。到目前为止,最新的太赫兹量子级联激光器已经成功在 225K 的温度下正常工作(有外磁场的情况下),输出频率可达 3THz^[4],在没有外加磁场的情况下,太赫兹量子级联激光器已经覆盖了 1.2~5THz 的频段。




图 5 太赫兹波电子学源

等离子体产生太赫兹机制包括气体中等离子体光丝产生太赫兹波^[5]、激光尾场产生太赫兹波^[6]和表面等离子体产生太赫兹波^[7]，如图6所示。目前，气体中等离子体光丝产生太赫兹波的基本产生机制问题还没有完全确定，许多人建立了各自的模型来对这一现象进行解释，但大部分都只能部分解释该现象，仍需进一步的深入研究。激光尾场产生太赫兹波则可分为磁化均匀等离子体中Cherenkov辐射、非均匀等离子体中线性模式转换、跃迁辐射。另外，人们发现利用超短飞秒脉冲激励纳米量级的金属周期结构可产生表面等离子体，同时，该结构可将飞秒激光和表面等离子体场聚焦，以发生很强的非线性效应，在此聚焦场有足够能量将金属薄膜上的电子“轰击”出来，利用电子的振荡运动产生太赫兹脉冲。




图6 等离子体产生太赫兹波机制

(2) 太赫兹波传输。太赫兹波在自由空间中传输十分困难，这是因为大气中的水汽、 CO_2 和 O_2 等分子对太赫兹辐射有很强的吸收。另外，太赫兹波还不能被很好地控制、聚焦，使其很难有效耦合到波导等传输元件之中。目前，太赫兹波的传输通常采用准光学和波导传输两种方法。太赫兹传输问题决定着太赫兹波后期能否被成功的处理、成像、倍频、放大、滤波、环形、隔离等。虽然近年来利用准光学方法和波导方法在一定程度上实现了太赫兹的传输，但这些传输理论基本上都是借助于微波或光波传输线模型，仍然没有建立起完整的太赫兹波传输理论，太赫兹波传输器件设计所依赖的机理效应依然很模糊。

准光学方法通常利用金属抛物面、超半球硅透镜及菲涅耳透镜或波带片等二元光学器件来控制太赫兹波的传输、准直、聚焦等。太赫兹波导传输通常应

用于近场太赫兹波器件、太赫兹波互连和太赫兹波准光学腔等方面。

(3) 太赫兹波探测。由于现有太赫兹波源的功率普遍偏低(微瓦量级),所以,对太赫兹探测的灵敏度和信噪比要求都很高,由此,如何实现高灵敏度的太赫兹探测是太赫兹科学另一个需要解决的关键问题。目前,太赫兹探测大致可分为非相干探测和相干探测,但这些探测方法大多是借鉴甚至是直接利用微波或红外测量方法来实现的,消除背景噪声的影响、充分发挥太赫兹系统的作用、提高探测器的灵敏度成为太赫兹探测发展的必然方向。另外,需要通过材料研究,以及材料在太赫兹波辐射下的物理过程和噪声机制,实现逼近量子噪声极限的高灵敏探测也是太赫兹探测研究的一个重点内容。

太赫兹非相干探测一般基于光热效应和光子效应的探测,能够直接测量出太赫兹信号。光热探测器一般是将吸收的太赫兹波能量转换为探测元件的电学性质或物理性质(如温度、电阻率和自发极化强度等)的变化,这类探测器探测频带宽,使用简单,但灵敏度低,受背景温度噪声影响较大,响应速度较慢。太赫兹光子探测器一般基于所接收的太赫兹能量改变探测器内原子或分子的内部电子状态,由光伏效应实现对太赫兹信号的探测,该类太赫兹探测器具有频率选择性的特点,而且响应速度快,背景噪声小,灵敏度高,成本相对较低,结构紧凑,易集成,使用方便。

常见的太赫兹脉冲的相干探测方法有光电导取样、电光取样、外差探测及近年来发展的空气等离子探测等,如图7所示。光电导取样是光电导天线产生太赫兹的逆过程,两者的结构大体相同,只是前者没有外置偏压,取而代之的是电流计一类的装置,该方法是根据光电导天线中所产生的光电流与驱动它的太赫兹电场成正比现象,间接测量瞬时太赫兹电场,适于低频太赫兹的探测,有很好的信噪比和灵敏度,但探测带宽较窄。电光取样则是光整流的逆过程,是基于Pockels效应来得到太赫兹脉冲的相关信息,该方法适用于高频太赫兹的探测,具有探测带宽宽、信噪比高、灵敏度高、响应时间短等优点。外差探测是太赫兹波最灵敏的探测方式之一,该方法利用一个本振源提供与所测太赫兹信号频率相近且性能稳定的单频参考信号,而后太赫兹信号与参考信号在混频器中差频产生出一个中频信号,根据对该中频信号的后期处理就可得到所测太赫兹信号的相关信息。空气等离子探测是在空气中产生的逆过程,利用空气的三阶非线性性质来探测太赫兹电场^[8]。

(4) 太赫兹波与物质相互作用。在研究太赫兹波在各种物质中的传输特性,以及利用太赫兹波研究物质的性质、结构等领域中,就必须了解太赫兹波在气体、液体、固体和等离子体中的吸收特性、相移特性和色散特性等,这是太赫兹与物质相互作用的重点研究领域。另外,太赫兹波与物质的耦合及互作用机理,即在太赫兹波辐射条件下,半导体中载流子的输运、太赫兹波与金属和光




图 7 太赫兹波相干探测原理

学介质的相互作用理论，以及太赫兹波与材料结构和组分有关的相互作用物理理论和方法都需要进行深入研究。在近几年间，太赫兹波与特异性介质这种人工复合结构之间的相互作用成为研究的焦点，这种结构材料具有负折射率特性，该特性取决于其人工结构，而不是材料自身的特性，利用这种结构材料可以作为太赫兹超透镜、滤波器和相位或频率调制器^[9]。

太赫兹应用研究主要包括太赫兹光谱、太赫兹成像和太赫兹通信，通过对它们的研究，可将太赫兹科学具体应用于基础科学研究、空间、医疗、军事、安检等领域^[10]。

(1) 太赫兹光谱研究。由于太赫兹光谱中含有丰富的物理和化学信息，且大多物质在太赫兹波段都有指纹谱，所以，利用不同太赫兹光谱技术可以研究物质在太赫兹波段的性质^[11]。例如，利用太赫兹时域光谱技术对物质进行静态高时间分辨率的非接触式的相干测量；利用时间分辨的太赫兹光谱技术，通过可见光泵浦-太赫兹探测的方法可对物质的动态信息进行高信噪比的探测，由此可对它们的细微变化进行快速精确的分析和判断；利用太赫兹发射光谱技术通过分析材料所辐射出的太赫兹波波形的振幅和形状，可研究材料本身

特性。

太赫兹光谱可以用于物理学、化学、生物医学、环境科学、天文学和材料学等学科的基础研究，可对物质内部进行深入研究，不仅可以直接表征出物质在太赫兹波段的吸收系数、折射率和介电常数等物理参数，还能够提供关于物质本身的物理、化学及生物成分、波谱特性、分子、量子互作用过程等重要信息。通过研究生物分子或组织、化学物质的指纹谱，可以鉴别物质的化学成分，由此，太赫兹波可用于不同材料的识别和安全检查，以及对毒品、爆炸物、生化武器或其他违禁物品及危险品的遥感探测及预警等，如图 8 所示。在生物方面，利用太赫兹光谱技术可以表征不同的生物分子，无标记检测 DNA 和蛋白质等，以及测量分子内或分子之间的响应过程或相互作用过程等。而对于强太赫兹场在物质内部诱发的非线性动力学过程，可使人们从另一个角度重新学习和认识物理、化学和生物学。另外，宇宙中各种星系、星云和星体都会根据其特性产生或反射不同能量的太赫兹波，通过测量分析这些光谱，人们可以更好地研究宇宙、星系、星体等的起源、组成和演化过程。同理，在地球科学研究领域中，通过地球大气层所产生的太赫兹波的分析，我们可以了解大气层的组成，不同气体成分的含量与分布，进一步研究诸如温室效应和臭氧层空洞对地球的影响等。




图 8 太赫兹光谱

(2) 太赫兹成像研究。太赫兹波可以透过可见光和红外线所无法穿透的物质或材料,如塑料、陶瓷、绝热泡沫等,所以,利用不同的太赫兹成像方式可以与可见光和 X 射线等成像技术形成互补。基于太赫兹的高透性和安全性的特性,太赫兹波可透过包装材料进行安检成像。另外,太赫兹波的成像分辨率高、大景深、安全和无接触性等优点使其在材料研究、医学成像和军事成像等领域具有广泛的应用前景,如图 9 所示。




图 9 太赫兹成像

根据太赫兹波相干性质,利用太赫兹波可进行振幅和灵敏的相位成像,从而可实现在车站、机场进行安全检查,以侦测或识别毒品或爆炸物等危险和违禁品。在生物医学方面,利用太赫兹成像技术可以对生物组织进行细胞水平的成像,由此可以测量不同组织特性及其含水量的情况,从而对正常和病变组织或细胞进行鉴别诊断。太赫兹成像(或光谱)还可以用于工业领域,如食品、药品和材料的质量监控,以及产品的无损检测等。在军事方面,太赫兹雷达比微波和毫米波雷达具有更高的分辨率,更精确的定位和成像,并且它还具有穿透沙尘、烟雾的能力,由此可对隐蔽的军事目标进行侦查、识别甚至能够辅助进行精确制导。另外,根据太赫兹波的高透性、安全性,还可以利用它对航天飞机、战机和其他武器装备进行无损探伤。

(3) 太赫兹通信研究。根据太赫兹波频率相对较高,单位时间内可以承载更多的信息,太赫兹通信技术是短距离无线通信的发展方向。

现有的短程通信系统(如蓝牙和无线局域网)的带宽在未来 10 年后将不能满足人们的需求,现有载波频率只有几吉赫兹,这些系统的数据传输率被限制在 1GB/s。而在未来的 15 年之后,人们的通信系统的数据传输率会超过 10Gbps,而系统的工作频率则需在几十甚至上百吉赫兹。由此,短距离通信系统相应的载波频率则必须随之增大,即达到太赫兹频段^[12]。

太赫兹波是很好的宽带信息载体,特别适合作卫星间、星地间及局域网的宽带移动通信。太赫兹通信可以获得 10Gbps 以上的无线传输速度,这比当前的超宽带技术快几百甚至上千倍。将来利用太赫兹无线网络下载一部 DVD 电影几乎可在瞬间内迅速完成。目前,日本的 NTT 公司已经实现了太赫兹无线通信,他们在北京奥运会上利用 0.12THz 无线通信系统在 1km 的距离内实现了地面数字高清电视的实况转播,其无压缩高清信号的传输速率超过了 10Gbps,如图 10 所示。另外,与可见光和红外线相比,太赫兹波同时具有极高的方向性及较强的云雾穿透能力,有很强的抗干扰能力。由此,太赫兹通信能以极高的带宽在 2~5km 的范围内实现局部战场中的定向、高保密,甚至明码军事通信。另外,由于太赫兹可以穿透等离子体,所以,太赫兹通信可以用做地面控制中心与宇宙飞船或卫星间的通信手段,确保飞行器在飞出和进入大气层的过程中与指挥中心的联络通畅。




图 10 北京奥运会太赫兹高清电视信号传输

综上所述,太赫兹科学是科学技术发展中的重要内容,是基础科学发展的又一新的手段。虽然太赫兹科学在过去的 20 年间取得了巨大的发展,在一定程度上开展了太赫兹波的产生、传输、探测、光谱、成像和通信研究等领域的研究,但一些最基础的科学问题尚未完全解决,如太赫兹源产生太赫兹的具体机制,太赫兹源在频段、功率、效率、时域方面的互补性、系列性和兼容性的问题,新型太赫兹源的发现和新机理的探索研究、太赫兹波与物质相互作用机理,

太赫兹波完整的传输理论等都是急需解决的关键科学问题。在这些太赫兹科学问题的激励和鞭策下,我们才能更好地去研究太赫兹科学,从而使太赫兹科学将来能够更好地应用于基础科学研究、材料科学、天文学、医学和军事、国防等领域。

参 考 文 献

- [1] Siegel P H. Terahertz technology .IEEE Transactions on Microwave and Techniques ,2002 ,50(3):910—928 .
- [2] 许景周,张希成.太赫兹科学技术和应用.北京:北京大学出版社,2007.
- [3] Kimmtt M F. Restrahlen to T-rays-100 years of terahertz radiation .Journal of Biological Physics ,2003 ,29 :77—85 .
- [4] Wade A ,Fedorov G ,Smirnov D ,et al. Magnetic-field-controlled THz quantum cascade laser operating up to 225K .Nature Photonics ,2009 ,3 :41—45 .
- [5] Sprangle P ,Penano J R ,Hafizi B ,et al. Ultrashort laser pulses and electromagnetic pulse generation in air and on dielectric surfaces .Phys .Rev .E ,2004 ,69(6):1—18 .
- [6] Yoshii J ,Lai C H ,Katsouleas T .Radiation from Cerenkov Wakes in a magenetized plasma .Phys .Rev .Lett .,1997 ,79(21) .
- [7] Welsh C H ,Hunt N T ,et al. Terahertz-pulse emission through laser excitation of surface plasmons in a metal grating .Phys .Rev .Lett .,2007 ,98(2):1—4 .
- [8] Dai J M ,Xie X ,Zhang X C .Detection of broadband terahertz waves with a laser-induced plasma in gases .Phys .Rev .Lett .,2006 ,97(10):1—4 .
- [9] Chen H T ,Padilla W J ,Zide J M O ,et al. Active terahertz metamaterial devices .Nature ,2006 ,444 :597—600 .
- [10] Tonouchi M .Cutting-edge terahertz technology .Nature Photonics ,2007 ,1 :97—105 .
- [11] Ho L ,Pepper M ,Taday P .Terahertz spectroscopy signatures and fingerprints .Nature Photonics ,2008 ,2 .
- [12] Koch M .Terahertz Frequency Detection and Identification of Materials and Objects .Berlin :Springer ,2007 :325—338 .

撰稿人:张存林 牧凯军

首都师范大学太赫兹光电子学教育部重点实验室

半导体激光器面临的挑战

Challenges in Semiconductor Lasers

1. 激光的历史回顾

2010 年是激光诞生 50 周年。世界各地有很多讲座、研讨会和活动来纪念激光的诞生和缅怀那些使激光的发现、发展和应用成为可能的先驱者们的成就。让我们利用这个机会来回顾激光的发展历史并展望它的未来。世界上第一个激光是 Maiman 于 1960 年在休斯实验室展示的红宝石激光器。关于激光的原理,实际上是由当时在贝尔实验室工作的 Schawlow 和哥伦比亚大学的 Townes 首先发表在 1958 年的《物理评论》杂志里的论文“红外线 and 光学微波激光器”,他们在 1960 年共同获得了第一个激光器的专利,并且分别于 1981 年和 1964 年获得了诺贝尔物理奖(如图 1 所示)。



图 1 Schawlow 在贝尔实验室调整红宝石激光器, Garrett 在准备拍摄激光闪光

美国总统奥巴马在他的激光诞生 50 周年纪念信中写道,“仅仅 50 年前,激光还被称为‘搜索问题时发现的一个解决方案’。今天,从在 DVD 播放机上观看我们所喜欢的电影,浏览网页,到杂货店里的条码扫描,激光使我们的生活方式发生了革命性变化”^[1]。正如奥巴马所说,激光展示了基础研究的重要性,也展示了科技对社会和我们日常生活的重要影响。有意思的是,奥巴马讲话里援引的三个激光的应用例子其实都是半导体激光。DVD 播放器和条形码扫描仪使用的是 InGaP/InAlGaP 红光半导体激光器,通过光纤连接的互联网里使用的关键的光源是基于 InP 和 GaAs 的近红外半导体激光器。

2. 半导体激光器

半导体激光器是在 Maiman 的红宝石激光器出现 2 年后由霍耳于 1962 年首先展示,它是由 GaAs 材料制作,发光在 850nm 左右的近红外波段。同一年的早些时候, Holonyak Jr 展示了第一个红色可见光 GaAsP 半导体激光器。但是,由于量子效率低,阈值电流高,早期的半导体激光器必须在低温和脉冲模式下工作。只有到了 1970 年,将薄的有源区夹在两个较大能带层的异质结构的采用

才实现了室温连续波半导体激光。异质结构能将载流子有效地限制在中间的有源区，大大降低了激光器的阈值电流，提高了激光器的性能。为此贡献，Alferov 和 Kroemer 获得了 2000 年的诺贝尔物理奖(如图 2 所示)^[2]。




图 2 半导体激光器阈值电流的演化

随着晶体生长技术的不断进步，特别是金属有机化学气相沉积(MOCVD)及分子束外延(MBE)技术的发展，量子阱和量子点的采用开发极大地提高了半导体激光器的效率和性能，如较低的阈值电流、波长的灵活控制、较大的微分增益、降低的温度依赖性等。如果说没有光纤便没有互联网和信息革命，那么，我们可以说如果没有半导体激光器的进步便没有光纤通信的实现。提到光纤通信，我们也应该记住“光纤之父”，2009 年诺贝尔物理奖得主的华人科学家——高锟。

半导体激光器发展还有其他两个重要的里程碑：量子级联激光器(QCL)和基于 InGaN 材料的蓝光激光器。对于所有的传统半导体激光器，材料的带隙很大程度上决定了激光器的发光波长。例如，广泛应用于数据处理和通信上的 1.3 μm 和 1.5 μm 波长附近的近红外半导体激光器通常是由 GaAs 和 InP 基半导体晶体异质结构制作。但是，对于中红外和远红外波长范围，所谓的分子“指纹”区域，可选择材料通常是铋化物和铅盐，它们的晶体质量和可靠性都不如 InP 和 GaAs 基材料。贝尔实验室的 Faist 和 Capasso 等于 1994 年发明的量子级联激光器彻底改变了这个局势，并提供了一个全新的半导体激光器设计方法^[3]。量子级联激光器的波长完全由量子结构确定，而不是由材料带隙决定。对能级、波函数和光学矩阵元的任意控制为新器件和新结构的电学、输运和光学性质的设计提供了一个前所未有的新途径。量子级联激光器现在能够覆盖 2.9~250 μm 的波长范围(如图 3 所示)。另外一个里程碑是基于 InGaN 材料的蓝色激光二极管的发展。多年来，电流注入半导体激光器的发射波长最短只能达

到红光区域。科学家正在努力寻找有效的能发射三原色中蓝光和绿光的材料系统。20 世纪 80 年代, GaN 的发展和当时在日本日亚化学工业工作的 Nakamura 对 P 型 GaN 的掺杂研究改变了这种状态^[4]。Nakamura 的研究在 1993 年打开了高功率发光二极管(LED)通向商业化的大门。LED 正在给通用照明带来一场绿色革命,在不久的将来取代白炽灯和荧光灯,它也被应用在很多其他像汽车照明、液晶电视背光源、交通信号、户外显示等领域。1996 年, Nakamura 首次报道了用金属有机气相沉积生长的使用 InGaN 多量子阱结构的电泵浦蓝色激光二极管,该二极管在正向峰值电流 2.3A 下输出了波长在 417nm 的功率为 215mW 的蓝光。如今,基于 AlGaIn 或 InGaIn 量子阱结构的半导体激光器已可以覆盖波长从约 340nm 的紫外光到 530nm 的绿光区域。




图 3 量子级联激光器中的量子设计和能级示意图

半导体激光器是目前以市场价值计算最重要的激光源。在过去的十几年里,它们一直占据世界全部激光器市场的一半以上份额^[5]。除了以上提到的光纤通信和数据存储外,在激光印刷、材料加工、生物和医疗、安全和其他方面也有广泛应用,图 4 是两张半导体激光器的照片。随着消费电子的发展,如激光电视、手机和电脑里可能使用的迷你激光投影仪,以及世界主要电子巨头正在紧锣密鼓发展的连接家电的最后几英尺光纤通信等,半导体激光器将会在人们的日常生活中占有更加明显的位置。听起来好像半导体激光器已达到了一个几乎完美的状态,其实不然,无论从物理、材料还是结构上,半导体激光都还面临许多挑战。

3. 前沿和挑战

太赫兹波虽然在遥感、图像和光谱分析等领域有很多应用,但它仍然是最欠开发的电磁频段。没有简单的光学或电子方法能产生太赫兹射线。缺少大功率、低成本、室温、便携的太赫兹源严重制约了现代太赫兹系统的发展。




图4 5.6mm 封装的商业激光二极管和放在针上的半导体激光芯片

基于飞秒激光的时域技术是现在产生太赫兹波的最常用方法。一个连续波太赫兹源对于很多应用(如高分辨率光谱)将是非常理想的。量子级联激光器是最有希望的大功率连续波太赫兹源。现在,量子级联激光器在低温帮助下可以覆盖到低太赫兹波(约1THz)范围。目前,运转温度的世界纪录是186K(无外磁场,频率为3.9THz)^[6]。量子级联激光器可以在室温下或者热电冷却温度下延伸到较低的太赫兹波段吗?一些基本问题和限制(如声子散射和电子热激发等)使这个目标在正常情况下变得不可能。由于其内在的分立能级和更长的带间载流子弛豫时间,半导体量子点可能是太赫兹量子级联激光器一个非常有吸引力的选择。然而,除了晶体生长的挑战外,我们需要做很多基础研究以充分了解其量子动力学特性。量子点潜在的强非线性光学效应也可以被开发用来实现室温太赫兹的发射。GaN材料系统与常用的GaAs和InP相比,较大的纵向光学声子能量(约90meV)使它成为另一个潜在的候选者。世界上有几个小组正在进行GaN基量子级联激光器的研究,并有可能在不久的将来取得突破。

让我们回到较短波长的方向,绿光是成像和显示的三个基色之一。绿光半导体激光器是激光显示等所急需的。由于InGaN材料的较大缺陷密度和半导体外延生长的许多挑战,现在世界上只有非常有限的几个公司可以展示InGaN近绿色激光,波长最长可达到530nm。现在的问题或面临的挑战是:是否或何时可以看到一个基于InGaN的更长波长的激光?如黄光、红光,甚至红外光?这可能听起来像一个工程问题,但或许没有科学上的突破未必能够实现这个目标。正像在半导体激光器的发展初期,如果没有异质结构概念的引入,我们可能需要更长的时间才能发展到现在的阶段。利用InGaN量子点直接产生白光已被用在LED上。通过实现基于InGaN的更长波长的激光,或许我们甚至可以从一种半导体材料和一个芯片上实现宽带或“白色”激光?抑或通过光子晶体结构非线性效应来实现?对于频谱的更短波长方向,GaN材料也是产生紫外激光的选择。利用AlGaN/GaN量子阱结构的紫外LED已能达到210nm的发光波长。自然,我们会期待这样一个波长的紫外半导体激光,这需要更有效的P型掺杂、更小的缺陷密度和更低的光

损耗，这将是材料科学家和激光物理学家需要面对的挑战。

电子器件的尺度在不断地减小以保持对不断增加的信息处理能力的要求，并且现在已经接近了几纳米尺度。不可否认，伴随而来的是不断增加的对更快信息传输速度的要求。光所具有的大带宽和天生的并行特性使光互连具有海量数据传输能力，同时又很少受电磁干扰、焦耳热和电路阻容延迟的影响。表面等离子体可以大大降低光子器件的尺寸，使它们有可能和纳米电子器件相匹配。最新的表面等离子体的研究进展为纳米光子学和光电集成电路(OEIC)的发展带来了希望。与它们的光子器件对等的各种表面等离子结构和器件已经被展示出来，如表面等离子体耦合器、分束器、调制器、多模干涉器、表面等离子体开关等。但是，还有一个最关键也可能是最困难的问题没有解决，就是缺少一个可以在芯片上集成的纳米激光源。表面等离子体结构结合半导体增益材料可能是一个比光子纳线和光子晶体更有希望实现纳米半导体激光器的方法。光子纳线通常有一个更大的模体积，而光子晶体虽然腔可以是纳米尺度，但总体结构通常比波长要大。一种超小型表面等离子体导引的纳米激光器(二维)在2009年进行了光泵浦的激射实验(如图5所示)^[7]，它使用了置于银膜顶部由5nm绝缘层相隔的CdS纳线作为增益材料。另一个三维尺度都在亚波长的半导体激光器在2010年进行了室温光泵浦激射(如图6所示)^[8]，它使用金属介质腔限制和In-GaAsP化合物半导体增益材料。这些报道为纳米激光源提供了希望，但也提出了更多的挑战。如何实现有实际意义的电驱动的半导体纳米激光，而不是依赖于外部强激光泵浦？如何提高这种表面等离子体束缚的纳米激光源的效率？如何使它们和现有的先进微电子CMOS技术集成在一个硅平台上？现在，无论是产生表面等离子体使用的金属材料，还是增益材料都与CMOS工艺不兼容。另外，理论上什么是纳米激光器的最小极限，小到一个量子点或是一个电子波长？是否有可能使用光学结构材料中的单元细胞的共振效应来得到一个半导体纳米激光器并控制它的波长？这些都需要大量的材料科学、量子电动力学、半导体激光物理、光学等方面的基础研究和技术创新。




图5 光泵浦的激光实验

左图说明光被压缩在纳线和银表面之间5nm绝缘层，右图是扫描点镜图像




图6 优化的金属介质腔

左图是与 InP 平面制造技术兼容的激光腔设计，右图是 TE₀₁₂ 模式电场大小的截面图

上面讨论的激光器都是基于无机半导体材料。有机材料在要求低成本、大面积或者非平面表面的应用中占有优势。有机 LED 在未来的固态照明和显示里大有前途。然而，虽然光泵浦的有机半导体激光器已经在从紫外到红光的波长范围里显示了脉冲激射，电驱动的有机半导体激光器在目前甚或未来可预见的一段时间里，仍将是一个巨大的挑战。几个有关有机材料的关键问题亟待解决，如损耗、载流子寿命、能量消散率和材料寿命。最近有关有机极化子激光的报道，虽然仍然是光泵浦脉冲激射，但为未来有机半导体电泵浦激光器提供了一条潜在的希望之路^[9]。极化子是激子和光子的耦合状态，它在常温下稳定并可以发出可见光，其玻色子性质使得它不需要粒子数反转，因而有可能低阈值激射。但是，要获得一个连续运作和最后电驱动的有机半导体激光器还有很长的路要走。上面提到的所有有机材料中的关键问题都必须解决。

我们上面讨论的只是半导体激光器面临的部分挑战，还有许多其他有趣的问题和课题需要科学家与工程师来回答和研究。例如，用一个通用的物理模型描述常规激光谐振腔和随机激光；在超微移动显示和激光通信等领域极有价值的半导体激光器超准直光束和光束方向的三维操控；通过激光腔的动力学设计或使用新材料(如 Graphene 饱和吸收)来实现飞秒甚至阿秒半导体激光，如何进一步提高量子效率和通过激光器的结构设计等来实现更大功率的半导体激光器等。随着科学和技术在各个领域的不断进步和发展，相信我们提到的半导体激光器的很多挑战将会在不远的将来被克服超越，它也将会不断发展并继续光耀世界。

参 考 文 献

- [1] www.osa.org.
- [2] Alferov Z I. The double heterostructure: Concept and its applications in physics, electronics and technology. Nobel Lecture, 2000.

- [3] Faist J, et al. Quantum cascade laser. Science, 1994, 264: 553—556.
- [4] Nakamura S, et al. The Blue Laser Diod; The Complete Story. 2nd ed. Berlin: Springer, 2000.
- [5] Overton G, et al. Laser market place 2010; How wide is the chasm. Laser Focus World, 2010, 32—48.
- [6] Kumar S, et al. 186K operation of terahertz quantum-cascade lasers based on a diagonal design. Applied Physics Letters, 2009, 94: 131105.
- [7] Oulton R F, et al. Plasmon lasers at deep subwavelength scale. Nature, 2009, 461: 629—632.
- [8] Nezhad M P, et al. Room-temperature subwavelength metallo-dielectric laser. Nature Photonics, 2010, 4: 395—399.
- [9] Kéna-Cohen S, et al. Room-temperature polariton lasing in an organic single-crystal micro-cavity. Nature Photonics, 2010, 4: 371—375.

撰稿人：滕京华

新加坡材料研究与工程研究院

弱激光治疗对人体细胞生物学作用的机理和量效关系

Mechanism and Dose-Effect Relationship of Low Level Laser Therapy on Body Cell

自 1960 年 Maiman 发明了世界上第一台激光器以来,激光作为一种新颖的技术手段,以其独特的生物组织学作用特征,在临床医学各领域得到广泛应用^[1]。1967 年, Mester 首次发现了弱激光(low level laser)作用于生物组织产生生物效应的现象。弱激光是一种低功率、低能量密度的激光,其作用于生物组织时,不会造成生物组织的不可逆性损伤,但可以刺激机体产生一系列的应答反应,起到调节增强或抑制的功能,从而达到治病的目的。一般认为,弱激光所引起的组织温度升高应在一个很小的范围,不应超过 $0.1\sim 0.5^{\circ}\text{C}$,输出功率小于 500mW ,输出功率密度在 $1\sim 4\text{J}/\text{cm}^2$ 的水平。最有效的用于弱激光治疗的光谱位于红光及近红外区域。常用的光源有 He-Ne 激光(632.8nm)、半导体激光(可见光与近红外光)。另外,由于 CO_2 激光(10600nm)、Er:YAG 激光(2940nm)等可以产生明显的发热效应,也可用于加速伤口愈合的治疗^[2]。

多年来,弱激光疗法因无创、无痛、安全、简便、适应证广在临床上得到广泛应用,目前已成为临床治疗的有效手段,也是极具家庭治疗和保健应用前景的好方法。弱激光治疗 and 传统光疗有很多不同,表现为亮度高、方向性好、单色性好、相干性好的特点。但是,它又和传统物理疗法有很多相似之处,如促进血液循环、加强免疫功能等。根据治疗理论和方法不同,可将弱激光治疗分为两大类:一是用现代医学理论作为指导,用弱激光对病灶进行局部照射或神经反射区的照射,称之为激光理疗;另一类是以祖国医学中的经络理论为指导,进行辨证论治穴位照射治疗,称之为激光针灸治疗。20 世纪 80 年代后期,苏联率先采用 He-Ne 激光代替紫外线照射血液,将其应用于治疗心脑血管疾病和缺血缺氧性疾病,疗效较好。90 年代初,王铁丹等将该种疗法引入我国。随后,在我国弱激光血疗又经历了静脉内照射疗法、离体血液照射回输疗法、口咽部照射伴吸氧疗法和鼻腔内照射疗法等^[3]。

人们在应用中发现弱激光有种特殊的作用,即作用于生物体时不产生不可逆损伤,而直接由辐射产生刺激效应。例如,病灶直接照射和穴位照射能产生消炎、镇痛、血管扩张、促进创伤愈合、毛发再生、神经、骨再生等作用;照射小鼠胸腺区和脾区可增强免疫细胞活性及促进免疫分子产生。大量动物及临床研究观察到,弱激光辐照在促进溃疡愈合、刺激组织修复、增进皮瓣活力等

方面有肯定疗效,同时具有调理机体免疫功能、消炎、镇痛、促进神经、骨再生等作用。Hopkins等^[4]使用 $8\text{J}/\text{cm}^2$ 的半导体弱激光直接照射开放性创伤,发现能明显促进开放创伤的收合,缩短愈合时间;Kreisler等^[5]使用 50mW 的半导体弱激光照射刚做完牙髓手术后的牙髓,发现患者牙髓疼痛能明显减轻。Stadler等^[6]观测了使用 $0\sim 5\text{J}/\text{cm}^2$ 的 660nm 弱激光照射外周血对淋巴细胞增殖的作用,发现经弱激光照射的外周血中淋巴细胞的数量有明显增加。细胞分子水平研究发现,弱激光照射后成纤维细胞胶原蛋白的表达增加,细胞增殖及代谢的水平提高。

所有这些无法用激光的热作用、化学作用、电磁场作用和机械作用等来解释,于是,根据电刺激、超声刺激、毫针的机械刺激和艾灸的热刺激等物理因子导致的生物刺激作用原理,提出了弱激光这一物理因子也一定存在“弱激光生物刺激作用”这样一个推理性假设,用来解释动物实验和临床实践的结果。自20世纪70年代开始,国内外学者对其生物刺激作用机理进行了广泛研究,相继提出了许多假说^[7]。1972年,在Gurvich的生物场理论和SzentGyorgyi的非定域电子在生物过程中的作用及生物分子具有半导体性质的基础上,Inyushin提出了生物电场设想,该设想在当时解释了He-Ne激光的治疗作用,但不能解释可见及近红外范围内的各种激光都可以产生某些生物效应和不同波长激光具有相似的生物效应。1977年,Mester提出了偏振刺激的设想。当细胞被偏振光照射时,脂分子的极化方向被迫按偏振光的电场方向重新排列(有序分布代替随机分布),从而影响与细胞膜有关的每一个过程,如细胞代谢、免疫应答、酶反应等。但从理论上讲,弱激光的电场强度是高频交变的,类脂分子的极化取向不会固定不变,且低强度激光的电场强度远小于细胞膜的固有电场强度,能否引起膜结构的改变值得怀疑。1997年,刘承宜等提出了生物信息模型与生物信息转换模型,该理论模型中,色素、膜受体等概念是对前人观点的继承与发展,但按照该理论,对健康动物或人体来说,弱激光都不应该产生生物效应,这不符合许多文献的报道。1998年,Wilden等提出了电子辐射现象的线粒体能量传递理论模型,该理论从电子的波粒二象性出发解释激光与生物大分子的原初相互作用,其关于红光和红外光与呼吸链组分相互作用的观点与Karu等一致,但同样缺乏对波长较短的可见光与生物大分子相互作用的阐述。还有如1980年Jl-poxonnykob提出的细胞膜受体设想和1981年Tamanek提出的色素调节设想、1993年周凌云提出的孤子态G混沌态假说及1999年Chichuk等提出的自由基机制假说等,这些设想或假说都从激光与生物分子相互作用的原初过程出发,尽管它能解释许多动物实验及临床观察的结果,但可惜的是,诸多假说却是学者各自知识的演绎推理,根本不是实验观察结果的提示。真正依据细胞分子水平的研究数据的更为稀少。因此,迄今没有一种假说得到普遍认可。

针对利用激光穴位照射是否向针刺一样“得气”和激发经络中的经气也是弱激光治疗机理研究的范畴之一。国外在 20 世纪 70 年代开始了对激光穴位照射的基础研究,如 Kellner 证实了激光照射表浅深度也足以刺激到穴位内的多种神经感受器,Kroetlinger 用弱激光照射与传统银针相比,发现激光照射穴位时电位升高与针刺该穴相似。诸多研究结果表明,经络的隐形传感线基本与经络的循环线路相符合。经络和其周围非穴位皮肤相比,它们的电阻小,因而容易感受和传导电磁波。在激光照射时,穴位中的“气”受到激光能的刺激振荡放大,并沿着阻抗最小的经络传导到相应的脏腑,给予经穴一定的刺激,使穴位组织起到兴奋、代谢加强、疏通经脉调气血的作用,同时使皮肤的神经末梢冲动传递加强,从而调节和改善脏腑的功能,即所谓“气到病除”,才能获得应有的疗效。但是,由于目前人们对“经络”治疗机制尚有大量的问题亟待解决,激光针灸的机制必然仍无法准确解释。

弱激光血疗法在我国发展十几年,仍存在一定的模糊性,机制不清,针对性不强。虽然不少研究表明,弱激光血疗对多种疾病都存在辅助治疗的作用,但最近弱激光血疗法的应用出现了应用面过宽、过滥、适应证不够明确、治疗方法和治疗条件不规范等问题,主要原因在于其治病机制至今未有较好解释,因此,很多西方国家(尤其是美国)的发展受到很大限制,研究方向主要局限于微观领域的机制研究。目前,关于这方面的研究主要集中在我国和俄罗斯,而俄罗斯的研究工作也已由最初的临床研究转向机制研究。研究过程中,人们发现弱激光与血液组织相作用时可改变其流变学参数,促进机体免疫功能等。进一步研究表明,改善血液流变学的原因因为弱激光可提高红细胞的变形性和降低红细胞的聚集性,而提高机体免疫功能的原因因为弱激光可促进免疫细胞的增殖等。最近的研究已经深入到弱激光是如何引起膜结构、膜功能的变化及电荷在膜酶、膜受体和膜表面的分布变化等。为了揭示弱激光的生物刺激效应,各种假说应运而生,其中,最具影响力的是俄罗斯学者 Karu 提出的弱激光细胞效应的线粒体机制。血疗法在我国的发展道路与俄罗斯极为相似,从最初的临床上风靡一时,到后来的机制研究。所不同的是,血疗法在发展的过程中与我国的传统中医相结合,早在 1997 年就有学者采用中医辨证的思路解释弱激光血疗,但并未引起重视。近几年,刘颂豪等提出了光子中医学的概念。从中医角度来看,弱激光治疗可能存在着活血化瘀(改变血液流变学性质、使血液凝固性降低、抑制血栓形成、改善血液循环、增加大脑的血流量等)、扶正固本(人体免疫系统有双向调节作用、提高机体的抗病能力、增强人体红细胞内的 SOD 活力、提高 $\text{Na}^+2\text{K}^+2\text{ATP}$ 酶活性等)、清热解毒(清除体内自由基、降低体内中分子物质、减少其他有毒物质的堆积等)、醒脑开窍(加速神经冲动传递、活跃机体代谢过程、调节恢复功能)和引经增效(可激活药物活性、提高所用药物的

作用)等功能。

目前,关于弱激光治疗对人体细胞生物学作用机制的认识仍然是带猜测性的,这直接阻碍了人们真正掌握、有效应用弱激光技术及其在新领域中的开发应用。值得提出的是,激光医学工作在我国开展已三十余年历史,在临床应用上取得的成绩应当肯定,但同时不能不注意到,所有这些实践只是在经验指导下进行的,并无更多理论依据。这种摸索前进的工作方法,不仅会延缓激光医学中许多问题的解决,而且使激光医学应用停留在感性认识阶段,致使目前我们仍有许多问题未能明确回答。如用激光治疗疾病时有时有效,有时又无效?有时是刺激作用,有时又是抑制作用?各类弱激光发挥其生物刺激作用的最小有效剂量和照射时间到底是多少?抑制的最小剂量和照射时间是多少?特别是最佳照射参数?不同状态下生物体组织为什么对弱激光的响应不同?生物体又是如何响应弱激光刺激的即弱激光是通过何种途径引发机体细胞生物效应的系列胞内分子事件?所有这些问题都不是单凭经验和想象就很好回答的。因为它们的回答牵涉弱激光对生物大分子、细胞、组织作用的根本性研究,尤其是弱激光生物刺激作用机理的明确阐明。据此才能把感性认识提高到理论性认识,以指导弱激光诊治和防护实践。因此,大力开展激光生物刺激作用机理这一基础研究尤感迫切。

弱激光疗法的生物刺激作用是一个多种因素决定的复杂过程,激光的参数(如波长、功率、能量和激光模式等)^[8]、生物组织的性质(如密度、比热容、色素、含水量、不均匀性和层次结构等)、生物体状态^[9]及操作者的水平等对治疗效果都有很大影响。因此,由于治疗中所使用的激光参数、创伤种类及程度和操作人员方法的不同,弱激光疗法的疗效时好时无,故而对该疗法的效果也存在一些争议和怀疑。激光波长、选择脉冲激光还是连续激光、输出功率、能量密度、暴露时间、暴露频率、总的暴露天数等均与光刺激效果有关,而这些参数在各研究之间也不尽相同,激光器类型、实验条件不同使实验数据难以比较,因此,有些研究可能会得出无效结论。弱激光的应用是很广泛的,但掌握弱激光作用于人体细胞的生物学反应的机理、途径和量效关系,克服弱激光治疗中主要凭经验,缺乏理论依据的问题,仍是弱激光治疗发展的一大难题。

参 考 文 献

- [1] Mester E. The biomedical effect of laser application. *Lasers Surg. Med.*, 1985, 5: 312—339.
- [2] Capon A, Mordon S. Can thermal lasers promote skin wound healing. *American Journal of Clinical Dermatology*, 2003, 4(1): 1—12.
- [3] 唐洁媛, 郭周义, 杨熙承. 弱激光血疗法的发展及展望. *中国激光医学杂志*, 2006, 15(4):

223—227.

- [4] Hopkins J T, McLoda T A, Seegmiller J G, et al. Low-level laser therapy facilitates superficial wound healing in humans: A triple-blind, sham-controlled study. *Journal of Athletic Training*, 2004, 39(3): 223—229.
- [5] Kreisler M B, Haj H A, Noroozi N, et al. Efficacy of low level laser therapy in reducing post-operative pain after endodontic surgery—a randomized double blind clinical study. *Int. J. Oral. Maxillofac. Surg.*, 2004, 33(1): 38—41.
- [6] Stadler I, Evans R, Kolb B, et al. In vitro effects of low-level laser irradiation at 660nm on peripheral blood lymphocyte. *Lasers Surg. Med.*, 2000, 27(3): 255—261.
- [7] 李成, 李迎新. 弱激光生物刺激效应在创伤治疗中的作用. *医疗卫生装备*, 2007, 28(10): 26—28.
- [8] Nascimento P M, Pinheiro A L, Salgado M A, et al. A preliminary report on the effect of laser therapy on the healing of cutaneous surgical wounds as a consequence of an inversely proportional relationship between wavelength and intensity: Histological study in rats. *Photomed. Laser Surg.*, 2004, 22(6): 513—518.
- [9] Rabelo S B, Nicolau R A, et al. Comparison between wound healing in induced diabetic and nondiabetic rats after low-level laser therapy. *Photomed. Laser Surg.*, 2006, 24(4): 474—479.

撰稿人：顾 瑛 陈虹霞
中国人民解放军总医院

光动力疗法的机制及量效作用规律

Mechanism and Dose-Effect Relationship of Photodynamic Therapy

早在 4000 年前, 古埃及人就通过口服含光敏剂的植物后照光来治疗白癜风, 但有关光动力疗法 (photodynamic therapy, PDT) 的科学探索则始于 20 世纪初。1900 年, Raab 首先观察到生物体内的光动力疗法, 即用吡啶橙染色草履虫后, 被日光照射者死亡, 而避光者生存。当时认为光和化学致敏物质作用后产生了对生物体的毒性作用。1904 年, Tappeiner 指出, 光诱发强烈的敏化反应时必须要有分子氧的存在, 并把有分子氧参与的这种光敏化反应称为光动力作用。后来逐渐发现, 具有与光作用的化学物质至少有好几百种。1942 年, Auter 和 Figge 给大鼠注射 Hp 后, 观察到 Hp 能优先在肿瘤组织等新生组织中富集, 当用紫外光照射时肿瘤区产生橘红色荧光, 用日光照射时可以损伤肿瘤组织, 这是人类首次发现 Hp 对肿瘤组织光敏杀伤作用。1960 年, Lipson 等研制出血卟啉衍生物, 并发现它对肿瘤组织有亲和性, 且于 1966 年尝试将 HpD 作光敏剂用于治疗肿瘤患者^[1]。60 年代, 激光器的出现不仅改善了光动力治疗的效果, 也极大地激发起人们对光动力疗法的研究热情, 以至于在 70 年代末至 80 年代形成了肿瘤光动力疗法的研究高潮, 使光动力疗法成为继手术、放射治疗和化学治疗之后治疗肿瘤的又一重要手段。1974~1975 年, 美国的 Dougherty^[2] 连续报道以 HpD 为光敏剂结合红光照射, 对乳腺癌、子宫癌、基底细胞癌、鳞状上皮癌等十几种癌症进行治疗, 收到良好效果, 这些研究结果极大促进了光动力疗法的发展, Dougherty 也因此被公认为是肿瘤光动力治疗的先驱者。1993 年 4 月 16 日, 加拿大健康保护局宣布, 批准光敏素 II 作为正式临床用光敏剂, 用于治疗膀胱癌。此后, 日本、美国和欧洲也相继批准了用光动力疗法来治疗一些癌症, 如胃癌、肺癌等。至此, 光动力疗法正式确立了其在肿瘤临床治疗中的地位。

20 世纪 80 年代, Selman、Star 等最早观察到光动力疗法的微血管效应, 发现其在损伤肿瘤细胞的同时会造成微血管血流减慢、血小板聚集和管腔闭塞, 进一步研究证明, 光动力疗法可以损伤内皮细胞、封闭微血管。随后, 人们利用这一特点展开了光动力疗法选择性损伤病变血管的研究, 并取得了可喜的成果。1990 年, 顾瑛等率先探索将光动力疗法用于鲜红斑痣 (port wine stains, PWS, 一种皮肤微血管扩张畸形) 的治疗, 明显提高了治疗效果, 并可以防止疤痕形成, 为长期生活在“红胎记”阴影中的患者带来了福音。经过系统的基础

研究, 根据 HpD 的吸收代谢特点和光敏激发特性, 建立了一种全新的治疗鲜红斑痣的光动力疗法方案, 该疗法开创了光动力疗法治疗非肿瘤疾病的先河, 标志着光动力疗法进入了一个新的发展阶段。之后, 美国科学家将光动力疗法尝试用于老年黄斑变性的治疗。2000 年 4 月 13 日, 美国 FDA 正式批准苯并卟啉衍生物单酸环 A (BPD-MA, 商品名为 Verteporfin) 用于老年黄斑变性的临床治疗, 此方法是目前唯一可以在不损伤正常视网膜、不降低视力的前提下封闭新生血管的治疗手段, 打开了黄斑中心凹下脉络膜新生血管激光治疗这一长期无人敢问津的禁区。

光动力疗法原称光辐射疗法 (photoradiation therapy, PRT)、光化学疗法 (photochemical therapy, PCT), 它是利用光动力反应进行疾病诊断和治疗的一种新技术。光动力诊断在临床上通常被称为荧光诊断。光动力反应的基本过程就是生物组织中的内源性或外源性光敏物质受到相应波长光照射时, 吸收光子能量, 由基态变成激发态, 处于激发态的光敏物质很不稳定, 迅速经过物理退激或化学退激过程释放出能量而返回基态, 其物理退激过程可以产生荧光, 通过分析荧光光谱能进行疾病的诊断; 其化学退激过程可以生成大量活性氧, 其中最主要的是单线态氧, 活性氧能与多种生物大分子相互作用, 损伤细胞结构或影响细胞功能, 因而产生治疗作用。在光动力反应体系中, 物理退激与化学退激是同时存在而又相互竞争的两个反应过程。荧光诊断利用光动力反应过程中相对简单的物理过程, 而光动力治疗则是利用其相当复杂的光化学-生物学过程, 它的初级反应是光敏化反应, 次级反应大多属于生物化学反应的范畴, 随后发生的是一系列生物学反应。光动力反应主要有以下特点:

(1) 组织选择性好。组织选择效应是指光动力疗法能在光照区域内较特异地作用于靶组织、靶细胞的现象, 这是光动力疗法最突出的优点, 可以最大限度地减少重要器官的功能丧失。例如, 鲜红斑痣是一种真皮浅层毛细血管网扩张畸形, 光动力疗法在去除病变毛细血管网时可以不损伤其上的表皮层和其下的真皮深层, 因此不会遗留疤痕; 采用放疗和热疗方法治疗膀胱黏膜的多灶性肿瘤时, 由于导致肌层纤维化, 经常发生膀胱容量和顺应性降低的并发症, 但采用光动力疗法治疗可以避免这种情况。因此, 光动力疗法特别适用于重要器官的高精度治疗。

(2) 作用表浅。人体组织的光透射性较差。对大多数组织而言, 光动力疗法的有效作用深度很难超过 10mm。因此, 光动力疗法的主要临床适应证是一些靶组织为“薄层”结构的疾病, 如皮肤、黏膜的浅表肿瘤、鲜红斑痣、视网膜黄斑变性、动脉粥样硬化和牛皮癣等疾病。对于深部肿瘤或瘤体较大的肿瘤, 必须通过特殊的照射方法加以解决。

(3) 对微血管组织的损伤作用强。血管内皮细胞直接接触血流, 细胞表面积大, 对光敏剂吸收迅速, 在光动力反应中消耗的光敏剂和氧可以得到快速补充, 血液中产生的 $^1\text{O}_2$ 也可以直接损伤内皮细胞膜, 所以, 光动力疗法对微血管组织的选择性好、作用强。因此, 光动力疗法特别适用于微血管疾病的治疗, 如鲜红斑痣、视网膜黄斑变性、食道静脉曲张栓塞治疗后遗留的微血管等疾病, 同时也适用于通过破坏微血管可以实现治疗目的的疾病, 如肿瘤。

(4) 是一种局部治疗方法。光动力疗法的治疗作用仅限于光照范围内, 故只适用于病变范围局限的疾病。例如, 光动力疗法具有抗病毒作用, 但它只能用于局部病毒感染, 如乳头状瘤。

(5) 全身副反应少。由于光动力疗法是一种局部治疗方法, 无明显的全身副反应, 所以, 特别适用于一般情况差、不能耐受其他治疗方法的患者, 并且可以多次重复使用。

光敏剂在靶组织优先分布是光动力疗法产生组织选择效应的先决条件。给予光敏剂后, 靶组织内的光敏剂含量在给药后的某一段时间相对高于周围其他组织, 形成光敏剂浓度差, 此时给予适当波长和剂量的激光照射, 靶组织因光敏反应中生成的单态氧和活性氧物质多而受到严重损伤, 非靶组织因单态氧和活性氧物质生成少而损伤较轻或无损伤。Webber 等研究认为光动力疗法通过以下三种机制杀灭肿瘤细胞: 光毒作用直接杀灭, 引发凋亡, 局部血管闭塞导致的继发性细胞死亡^[3]。此外, 免疫系统也参与了光动力杀灭肿瘤细胞的过程^[4]。研究表明, 光敏剂有在增殖活跃的细胞中优先聚集的特性。新生细胞的细胞膜上表达大量的低密度脂蛋白受体 (low density lipoprotein receptor, LDLP), 肿瘤细胞具有比静止细胞更多的 LDLP, 从而使一些易附于 LDLP 上的亲脂性光敏剂在肿瘤细胞上高度聚集, 直接杀灭肿瘤细胞。而亲水性光敏剂则更多的通过白蛋白和血清蛋白的运输聚集在肿瘤的间质和血管组织, 阻塞血管, 切断肿瘤的氧和营养物质的供应, 间接起到杀伤肿瘤细胞的作用。

国内外学者在研究光动力疗法作用机制时, 都不同程度地观察了亚细胞结构的变化。光敏效应表现在细胞器水平应该是多种细胞器受损。细胞膜、线粒体、胞核、内质网、高尔基器等均可受损。可能存在受损前后顺序, 但在亚细胞水平难以明确区分^[5]。细胞在光动力疗法作用后究竟是发生凋亡还是发生坏死, 受多种因素影响, 如细胞种类、状态及光敏剂的细胞内定位。定位于线粒体的光敏剂容体导致细胞凋亡, 定位于细胞膜和溶酶体的光敏剂容易导致细胞坏死^[6]。有趣的是, 小剂量光动力疗法反而具有生物刺激作用, 可以促进细胞增殖。顾瑛等观察到应用光动力疗法处理血管平滑肌细胞, 当功率密度为 $20\text{mW}/\text{cm}^2$ 、照射时间小于 15s 时, 光动力疗法对各 HMME 浓度组平滑肌细胞

有轻度促增殖作用。光动力疗法促细胞增殖效应的光参数范围较窄，这与 Gomer 等的报道相似。如何利用光动力疗法的非致死性损伤以实现某种治疗目的也是值得探索的问题。虽已知光动力疗法的作用机制有直接杀伤靶细胞、破坏微血管和免疫反应，但由于其基础研究相对薄弱，迄今对其作用机制和途径方面还存在诸多未解问题。例如，光动力疗法杀伤靶细胞的信号通路？光动力疗法免疫反应的机理和途径？光动力疗法对全身免疫调节的影响程度、如何提高光化学反应效应及联合应用其他抗肿瘤治疗手段以提高疗效等方面，现在知之不多。

光动力反应是一个多因素相互作用的动态变化过程，研究其作用规律及量效关系涉及组织光学、光物理、光化学、药效学、药代动力学、细胞生物学等多个学科，难度很大。光动力疗法与单纯激光治疗不同，参与因素包括光、光敏剂、氧等，单个治疗剂量指标(光、光敏剂)与疗效之间没有明确的线性关系，只有在各种因素达到最佳匹配时才有最佳疗效，并不像常规化放疗那样，给予的光或光敏剂量越大效率越高。治疗时，除了对激光、光敏剂总量的把握，还要选择波长适合的激光，容易在血管中分布的光敏剂，合理的给药照光时间间隔，适宜的激光功率密度和照光时间等。许多研究都已发现，在光敏剂含量、氧含量相同的条件下，入射光功率密度超过一定水平，光动力疗法疗效反而下降，这种违背光剂量越大活性氧产量越大的现象是由于强光照射下光敏剂的光漂白和组织氧耗增加。可见，光动力疗法反应中，光、光敏剂、氧之间相互影响并不符合线性规律，其生物效应整体上是一种多因素参与的复杂非线性系统，这种多因素之间相互作用规律的复杂性是限制光动力疗法生物效应机制和量效关系深入研究的瓶颈，要促进光动力疗法在临床治疗中的应用、明确光动力疗法中各因素之间的复杂作用规律进而优化治疗参数已成为迫切需要解决的问题。然而，单凭适用于单一因素研究的传统医学研究方法很难实现这一目的，因为单因素研究方法主要靠大量重复性实验来摸索这些规律，真实规律很容易被实验对象的个体差异所掩盖，而且研究结果和理论基础之间缺乏合理而充分的衔接，这就要求我们必须采用一种动态、综合、整体、系统的方法来进行研究。

近年来，人们开始注重人体作为一个整体的系统特征，也开始采用复杂系统论的思维方式建立生物系统的数学模型，解决生物医学中有关作用机制或量效关系等基础性问题，因而生理系统的仿真与建模在生物医学研究领域已日益受到重视并且广泛开展起来。采用数学建模的方法也可以对光动力疗法生物作用中的复杂量效关系规律进行分析与控制，对研究光动力疗法基本机制及指导临床治疗都有重要意义。目前，国外已有应用数学建模的方法研究光动力疗法治疗肿瘤的报道，但具体应用还局限在两个方面：一是针对光

动力疗法中的某一现象进行机理建模研究,如对光敏剂光漂白规律、氧消耗规律的研究;二是针对治疗剂量进行的数学建模研究,如光动力疗法治疗基底细胞癌。这些研究只针对肿瘤的治疗,而且停留在对光敏剂和激光作用的机理建模阶段,还没有全面覆盖从机理到生物效应的全过程,尤其利用光动力疗法微血管效应治疗良性疾病具有不同于光动力疗法肿瘤治疗的特点,前者更强调选择性损伤,对剂量要求更精确。目前,国内顾瑛等已经就单根血管中光动力疗法光活性产物进行机理建模^[7],并取得了良好的效果。进一步将针对光动力疗法选择性微血管效应,建立血管靶组织和周围正常组织中各因素在光动力疗法中相互作用规律的机理模型,利用此模型,对不同微血管疾病(鲜红斑痣和老年性黄斑变性等)在细胞水平、动物水平和临床病人水平的各种组织模型进行仿真运算,得到活性产物随时间和空间变化的量,并在活性物质和生物效应之间建立模糊神经网络模型,形成一个完备的光动力疗法微血管效应的数学模型。

目前,由于还不能对光动力反应过程及光动力各要素之间的作用关系给出定量化的描述,临床医生只能沿用最早 HpD-PDT 的经验方案,千篇一律地处理不同的病人,影响疗效的发挥,因此,研究光动力各要素之间相互作用的规律、影响因素及量效关系,使光动力疗法的临床应用更科学化、规范化、量化仍是当前光动力疗法治疗面临的一大难题。上述模型的建立有望使该难题的解决前进一大步。

参 考 文 献

- [1] Lipson R L, Baldes E J, Olsen A M. Further evaluation of the use of hematoporphyrin derivative as an aid for detection of malignant disease. *Dis. Chest.*, 1964, 46: 676—679.
- [2] Dougherty T J, Grindey R F, Weishaupt D G, et al. Photoradiation therapy II—Hematoporphyrin and light. *JNCI*, 1975, 55: 115.
- [3] Webber J, Herman M, Kessel D, et al. Photodynamic treatment of neo-plastic lesions of the gastrointestinal tract. *Langenbecks Arch. Surg.*, 2000, 385(4): 299—304.
- [4] Oleinick N L, Evans H H. The photodynamic therapy: Cellular targets and mechanisms. *Radiat. Res.*, 1998, 150(5): 146—156.
- [5] Mori M, Kuroda T, Obana A, et al. In vitro plasma protein binding and cellular uptake of ATX-S10 (Na), a hydrophilic chlorin photosensitizer. *Jpn. J. Cancer Res.*, 2000, 91(8): 845—852.
- [6] Chen J Y, Cheung N H, Fung M C, et al. Subcellular localization of merocyanine 540 and induction of apoptosis in murine myeloid leukemia cells. *Photochem. Photobiol.*, 2000, 72: 114—120.

- [7] 顾瑛,黄乃艳,刘凡光,等.数学仿真研究光漂白对光动力治疗鲜红斑痣的影响.中国激光医学杂志,2005,14:31—34.

撰稿人: 顾 瑛 陈虹霞
中国人民解放军总医院

10000 个科学难题 · 信息科学卷

专题篇

太赫兹波(光)源与探测器

Terahertz Sources and Detectors

太赫兹(THz)波^[1~5]是指波长介于 3mm(0.1THz)和 30 μ m(10THz)之间的电磁波,也被称为 T-射线^[1]。长期以来,由于缺乏有效的太赫兹辐射的产生和检测方法,导致这一频段的电磁波未得到充分的研究和应用。

太赫兹技术^[2]的核心是太赫兹辐射源和探测器。人们用不同的方法来产生和探测太赫兹辐射,每一种方法都具有各自的特点。

太赫兹辐射源通常包括自由电子激光器、工作于太赫兹频段的气体激光器、真空电子学太赫兹源^[4]、超快激光泵浦光电导太赫兹源、太赫兹量子级联激光器^[6~8]及固体电子学和光学太赫兹源等。

自由电子激光器是通过直接加速自由电子来实现的。加速电子在有磁场作用下的周期性结构中运动,当速度与光速接近的电子束通过偏转磁铁形成的扭转磁场时,电子在洛伦兹力作用下加速运动,通过自发辐射,产生太赫兹电磁波。与其他太赫兹辐射源相比,自由电子激光器具有连续可调、频谱范围广、峰值功率和平均功率大、相干性好、光束质量和波形结构优良等优点。但是,自由电子激光器价格昂贵,设备笨重,不适合大规模的广泛应用。

气体激光器的原理是通过光泵浦(如 CO₂激光器)在气体分子的振动/转动能级之间形成粒子数反转,从而产生受激辐射,这种激光器可以在室温下工作。但是,气体激光器的激射频率依赖于所选择的气体,因此,频率不可以连续调谐。另外,这种激光器价格昂贵,体积大,消耗功率大,能量转换效率低。

回旋管是目前工作在毫米波及太赫兹频段功率最高的真空电子学器件,功率可达千瓦以上。回旋管基于电子在磁场中的回旋谐振受激辐射机理,是一种快波器件,不需要传统微波、毫米波真空电子学器件所必需的慢波系统,可实现高频、大功率输出。回旋管在远程探测、高分辨雷达和太赫兹辐射与物质非线性相互作用研究方面有重要的应用前景。

瞬时光电导产生太赫兹电磁脉冲的基本原理为:在光电导半导体材料(如 GaAs)表面淀积金属制成偶极天线电极结构,当飞秒激光照射在电极之间的光电导半导体材料时,会在其表面瞬时地(10^{-14} s 量级)产生大量自由电子-空穴对,这些光生载流子在外加电场或内建电场作用下被加速,并由于光生载流子的复合,在光电导半导体材料表面形成变化极快的光电流,从而产生向外的太赫兹电磁辐射脉冲。

2002 年,意大利和英国的研究小组研制出频率为 4.4THz、功率约为 2mW 的太赫兹量子级联激光器^[6]。太赫兹量子级联激光器的研制成功是半导体固态太赫兹辐射源发展的一个里程碑。量子级联激光器是只有电子参与的单极型激光器,电子从较高的能量状态跃迁到较低的能量状态,发射出光子,其激射波长取决于由量子限制效应决定的量子阱两个激发态之间的能量差。太赫兹量子级联激光器具有重量轻、体积小、能量转换效率高和易集成等优点。目前,太赫兹量子级联激光器最大输出功率达到 250mW,频率覆盖 1.2~5.0THz(加磁场条件下可低于 1.0THz),最高工作温度达 186K。

基于电子学的太赫兹辐射源有共振隧穿二极管、超晶格电子器件、碰撞雪崩渡越时间二极管、倍频耿氏二极管及肖特基二极管等,这类电子学振荡源体积小、结构紧凑,但它们的频率基本限制在几百吉赫兹。此外,基于光学非线性效应的差频发生器和参数振荡器等都可以产生太赫兹辐射。

对于太赫兹辐射的探测,目前主要有傅里叶变换光谱探测方法、时域光谱太赫兹探测方法、太赫兹半导体量子阱探测器、热电探测器、超导 SIS(superconductor-insulator-superconductor)混频器和热电子辐射热计(HEB)等,这些探测方法各有其特点。

傅里叶变换光谱探测方法是常用的中远红外频谱测量方法。目前,傅里叶变换光谱仪覆盖了从红外到太赫兹波段很宽的频率范围。傅里叶变换光谱仪是基于 Michelson 干涉仪研制而成的,通过连续改变干涉仪内一个镜面的位移,测量得到的干涉图样包含了光源的频谱特性。对于红外及太赫兹波段的光谱测量,光源常常采用能辐射很宽带宽电磁波的高温黑体(如白炽硅碳棒)。探测器则采用各种热辐射计。为了降低热噪声的影响,热辐射计需要在低温下工作。

时域光谱太赫兹探测系统主要由超快脉冲激光器、太赫兹发射元件、太赫兹探测和时间延迟控制系统组成。其中,太赫兹探测有两种采样方式,分别是光电导采样方式和电光采样方式。与傅里叶变换光谱探测方法相比,时域光谱太赫兹探测方法具有更好的信噪比和频率分辨率,而且还能对太赫兹电场的位相随时间变化等信息进行相干测量。因此,时域光谱太赫兹探测方法在太赫兹光谱和成像等方面具有广阔的应用前景。

太赫兹半导体量子阱探测器^[9,10]是红外量子阱探测器向太赫兹波段的延伸。Liu 等^[9]采用传统的 GaAs/AlGaAs 材料体系,率先实现了能在太赫兹波段工作的量子阱探测器,其峰值探测频率为 7THz。太赫兹半导体量子阱探测器在光谱范围的选择上有很大的灵活性,可以采用成熟的材料生长技术和器件工艺来提高器件的性能。高质量的太赫兹半导体量子阱探测器单元器件可以应用于太赫兹无线通信;太赫兹半导体量子阱探测器焦平面阵列可以应用于太赫兹实时成像和太空观测。由于大部分分子体系在太赫兹波段有丰富的特征吸收峰,而太

赫兹半导体量子阱探测器具有很好的光谱分辨能力和很快的响应速度,利用普通的连续波光源(如高压汞灯)就可以实现有毒有害物质的实时检测。

超导 SIS 混频技术是 20 世纪 80 年代初兴起的低噪声检测技术,也是目前太赫兹射电天文和大气物理研究的核心技术。SIS 探测器以光子辅助隧穿机制为理论基础,探测频率范围约为 $0.1 \sim 1.2 \text{ THz}$,需要在液氮温度下工作。热电子辐射热计则是近年来利用声子和电子散射冷却机制发展起来的一种高灵敏度探测器,其响应速度很快。与 SIS 技术相比,热电子辐射热计更适合探测频率大于 1 THz 的辐射。目前,热电子辐射热计可探测的最高频率约为 5 THz 。另外,肖特基二极管也可用于太赫兹辐射的探测。

太赫兹技术正处于一个飞速发展的阶段,正向深层次理论研究、器件研制及应用系统研发等多方面迅速发展。可以预见,太赫兹技术也将像光学和微波技术一样,给人类社会的许多方面带来巨大的影响。

参 考 文 献

- [1] Ferguson B,Zhang X C .Materials for terahertz science and technology .Nature Materials ,2002 ,1 :26—33 .
- [2] Siegel P H .Terahertz technology .IEEE Transactions on Microwave and Techniques ,2002 ,50(3):910—928 .
- [3] Cao J C .Interband impact ionization and nonlinear absorption of terahertz radiations in semiconductor heterostructures .Phys .Rev .Lett .,2003 ,91(23):1—4 .
- [4] 刘盛纲 .太赫兹科学技术的新发展 .中国基础科学 ,2006 ,8(1):7—12 .
- [5] Tonouchi M .Cutting-edge terahertz technology .Nature Photonics ,2007 ,1 :97—105 .
- [6] Köhler R,Tredicucci A,Beltram F,et al .Terahertz semiconductor-heterostructure laser .Nature ,2002 ,417:156—159 .
- [7] 曹俊诚 .太赫兹量子级联激光器研究进展 .物理 ,2006 ,35(8):632—636 .
- [8] Williams B S .Terahertz quantum-cascade lasers .Nature Photonics ,2007 ,1 :517—525 .
- [9] Liu H C ,Song C Y ,SpringThorpe A J ,et al .Terahertz quantum-well photodetector .Applied Physics Letters ,2004 ,84(20):4068 .
- [10] 曹俊诚 .太赫兹半导体探测器研究进展 .物理 ,2006 ,35(11):953 .

撰稿人:曹俊诚

中国科学院上海微系统与信息技术研究所

等离子体填充微波器件

The Plasma Filled Microwave Devices

20 世纪 90 年代以来, 随着对高功率微波器件的更高要求, 很多学者对引入等离子体填充来改善性能做了很多研究。研究表明, 填充可控数量的等离子体到微波器件中, 在多数情况下, 相比于普通的真空器件而言, 能大大改善微波管的性能。但是, 这类等离子体填充微波器件的应用与更深入的研究还存在一些尚待解决的难题。

1. 等离子体填充微波器件的优点

(1) 增大束电流容量。足够密度的背景等离子体允许微波源工作在比真空情况时高得多的束电流下, 这就可以产生更高微波输出功率。

(2) 可减小甚至取消外加磁场^[1]。少量的等离子体可以使外部磁场获得显著减小。

(3) 可提高功率和效率。分析得出, 由于等离子体填充而增强电子束聚束, 一般耦合腔行波管的效率可以提高 1/3。

(4) 模式抑制。等离子体对慢波结构的色散性有着很强的影响, 因此, 可以利用这个作用来减少或消除不需要的模式。

(5) 拓宽带宽。研究发现, 当在耦合腔行波管电子注通道填充等离子体时, 行波管的带宽增加。

2. 实验举例



图 1 L 波段螺旋线
PASOTRON 照片

1) PASOTRON^[2~4]

1996 年, 美国的休斯实验室研制成功了螺旋线结构的 PASOTRON。由于等离子体的电中和作用, 加之电子注本身的自箍缩效应^[5], 可以实现在无引导磁场下电子注在等离子体中的高质量传输。由于取消了笨重的外加磁场, 因而与常规高功率微波器件相比, 具有体积小、重量轻、单次脉冲能量大等优点, 被称为新一代电子战的理想高能微波源。L 波段 PASOTRON 照片如图 1 所示。

2) 等离子体填充耦合腔行波管

俄罗斯全俄电技术研究所 1993 年研制成功了等离子体填充的耦合腔行波管(照片如图 2 所示)^[6]。工作时,气压维持在 $10^{-6} \sim 5 \times 10^{-3} \text{ Torr}^{\text{①}}$, 等离子体密度超过了 10^{12} cm^{-3} , 整个装置放置在由螺线管产生的磁场中, 磁场强度为 $0.25 \sim 0.3 \text{ T}$ 。电子注的电压为 25 kV , 注电流为 $2 \sim 4 \text{ A}$, 相互作用效率达 40% , 带宽达 30% , 输出功率超过 30 kW , 与未填充等离子体相比, 提高了一倍, 他们用等离子体模与腔模耦合形成混合模式的理论来解释了这一现象。



图 2 等离子体耦合腔行波管照片

3. 等离子体填充器件在研究、应用方面尚待解决的难题

(1) 离子噪声。离子噪声问题是等离子体填充器件能在更多领域得到应用的最大障碍^[7]。20 世纪 50 年代, 科学家们就意识到传统微波源存在等离子体会导致离子噪声的增大和不稳定性的产生。在背景气压过高时, 由等离子体引起的“离子边频”的频率会接近载波信号的频率, 并且在带内产生寄生振荡。20 世纪末, 莫斯科电真空研究所的研究者研究了等离子体填充耦合腔行波管噪声水平和非线性特性。首先, 比较真空及气体填充工作时耦合腔行波管的交调特性, 研究发现, 如果抑制了一些低频寄生震荡, 两者的交调在相同水平。另外, 等离子体耦合腔行波管的寄生信号水平低于载波信号至少 50 dB , 可媲美真空管型。在某些应用(如雷达和通信)中, 等离子体填充器件的离子噪声仍然是一个重要的问题, 并且必须进一步研究。如要将等离子体填充器件应用于信噪比要求很高的领域, 我们还可以采用其他技术, 如反馈电路、校正电路等, 将等离子体填充器件的信噪比提到一个更高的水平。

(2) 输出功率不稳定^[7]。在普通微波管中, 等离子体的产生常常导致功率输出的不稳定及脉冲缩短效应。众所周知, 等离子体的填充会产生“离子聚焦”效应, 使得等离子体填充器件中的电子注直径相对于高真空管型更细, 正是这种效应降低了电子注的空间电荷效应, 并使得电子注能在离子通道中的无聚焦磁场传输。

① $1 \text{ Torr} = 1 \text{ mmHg} = 1.33322 \times 10^2 \text{ Pa}$ 。

在气体填充的线圈磁场聚焦或是周期永磁体聚焦管型中,离子聚焦效应会减小电子注的直径,甚至使得电子注被螺旋线或腔壁截断。由等离子体引起的电子注直径的微小改变,可以导致电子注与微波耦合效果及输出功率的显著降低。例如,在耦合腔行波管中,电子注尺寸减小 10% 将导致增益损失 3~6dB,这将直接影响管子的输出功率。俄罗斯全俄电技术研究所研究的耦合腔行波管中采用一个强磁场解决了这一难题,控制了电子注直径的减小。在不同的等离子体填充器件中,过剩的等离子体同样会导致耦合结构的截止及电子注的不稳定,这些效应会降低功率水平及脉冲宽度。

普通真空中,常常通过提高真空度和管内的洁净度来避免脉冲缩短效应及管子输出功率下降,这些办法也可以应用于等离子体填充管型。我们可以采用等离子注入系统,在微波管中直接填充入密度受控的等离子体;同时,可以忽略掉由于电子注与管内残余气体产生的等离子体,这样一来,就可以在管内形成一个可再生的、稳定的等离子体环境。

利用电子注与气体碰撞离化产生等离子体的电子注传输系统或是微波管,必须保持等离子体的动态平衡,这类等离子体高功率微波源中,等离子体由电子注与气体碰撞离化产生,在这类器件中,要想减轻脉冲缩短效应及失真效应,就必须很好地控制电子离化速率及等离子体浓度。

(3) 相对论、非相对论器件研究方法不同。根据慢波结构工作机理不同,有些微波管(如波纹波导结构)的等离子体背景是由相对论电子注电离而成,因此,研究时需要考虑粒子的相对论效应,增加了微波管的难度分析。但当等离子体密度达到某一临界时,其效率和功率大大提高,有时其性能成几倍增加,这也给很多学者在此方面进行深入研究提供了很大动力。

而对非相对论器件来说,虽然不考虑相对论效应,但由于结构、工作和等离子体至发机理的不同,其分析理论设计方法也都有不同(如 PASOTRON 和等离子体填充耦合腔行波管),这就使对不同类型的微波管需要不同理论和设计方法,需要更多学者发现并对其分门别类地分析研究。

(4) 理论分析、数值仿真。对于特定的微波管,可以通过忽略次要因素进行理论分析得到经典公式进行分析。由于微波结构和机理复杂性使得其推导公式不具有普适性,这给研究者的分析带来了难度,并且耗时巨大。同时,由于主观忽略一些因素,等离子体填充环境下也许很微小的因素可能得到相反的结果。因此,现在更多的学者偏向于结合一些等离子体仿真软件进行研究分析,如一些商业软件 ANSOFT、CST、MAGIC、KARAT、电子科技大学自主研发的 CHIPIC 等,可以考虑更多因素进行最初总体分析。但是,由于商业软件进行封装,不能给研究者更细微的优化,因此,有些情况下不能突出主要问题。而美国加州大学的开源等离子体仿真软件 XOOPIC 可以更好地提供微波器件的

设计和研究更大设计空间,但由于其软件是基于 Linux 系统的 C 语言开发,因此,给使用软件者有更高的要求。

参 考 文 献

- [1] Lin A T. Emission of plasma cyclotron wave in plasma-filled backward-wave oscillators. *Phys. Rev. Lett.*, 1990, 65(6): 717—720.
- [2] Dawson J M. Particle simulation of plasmas. *Reviews of Modern Physics*, 1983, 55(2): 403—447.
- [3] Birdsall C K. Particle-in cell charged-particle simulations, plus monte carlo collisions with neutral atoms, PIC-MCC. *IEEE Transactions on Plasma Science*, 1991, 19(2): 65—85.
- [4] Zavjlov M A, Mitin L A, Perevodchikov V I, et al. Powerful wideband amplifier based on hybrid plasma-cavity slow-wave structure. *IEEE Transactions on Plasma Science*, 1994, 22(5): 600—607.
- [5] Shkvarunets A G, Kobayashi S, Carmel Y, et al. Operation of a relativistic backward wave oscillator filled with a preionized high density radially inhomogeneous plasma. *IEEE Transactions on Plasma Science*, 1998, 26(3): 646—652.
- [6] Goebel D M, Butler J M, Schumacher R W, et al. High-power microwave source based on an unmagnetized backward-wave oscillator. *IEEE Transactions on Plasma Science*, 1994, 22(5): 547—553.
- [7] Goebel D M, Ponti E S, Feicht J R, et al. High power microwave source performance. *Proc. Intense Microwave Pulses IV*, 1996, 2843(1): 69—78.

撰稿人: 王 彬

电子科技大学物理电子学院

太赫兹电真空器件

THz Vacuum Electronic Devices

1. 简介

太赫兹波段是指频率从 100GHz 到 10THz, 介于毫米波与红外光之间的电磁波谱区域, 长期以来, 该波段缺乏有效的辐射产生和检测方法, 是电磁波谱中唯一没有获得充分研究的波段, 太赫兹辐射源是其中的薄弱环节, 目前大致可分为基于光子学的源与基于电子学的源两类^[1,2]。

光子学太赫兹辐射产生方法主要有太赫兹激光器(包括气体激光器和量子级联激光器)、飞秒激光脉冲光电导和光整流效应及光学差频等, 由于光学量子极限等因素的限制, 越向低频方向, 困难越大。电子学太赫兹辐射源包括半导体源和真空电子学太赫兹辐射源, 由于电子弛豫时间等因素的限制, 导致越向高频方向, 困难越大。目前, 固态半导体太赫兹源和光子学太赫兹源的转换效率很低, 一般小于 1%, 输出功率在微瓦至毫瓦量级。

太赫兹电真空器件的效率和输出功率是所有太赫兹源中最高的, 在雷达、远程通信、远距离成像及太赫兹电子对抗等重要军事应用中将具有广泛的应用前景。太赫兹电真空器件可分为慢波器件和快波器件两种类型, 慢波器件有行波管、返波管、绕射辐射振荡器、扩展互作用速调管等, 工作原理与微波、毫米波电真空器件相同, 这类器件体积小, 重量轻, 使用方便, 但输出功率较小。快波器件有回旋管和自由电子激光, 输出功率可达千瓦数量级, 但重量和体积较大。

2. 太赫兹电真空器件发展现状

返波管是工作频率最高的器件, 频率为 0.1~1.4THz, 功率从频率低端的几十毫瓦到高端的 1mW, 用于成像、射电天文观测和遥感(如图 1 所示)^[3]。太赫兹行波管的频率达到 0.5THz, 基于 Smith-Purcell 效应的绕射辐射器件的频率可达到 1THz, 扩展互作用速调管工作频率目前最高为 0.28THz, 脉冲功率为 30W, 进一步发展频率可达到 0.5~0.7THz(如图 2 所示)。美国加州理工学院 JPL 实验室利用微加工技术在硅片上实现微型反射速调管^[4], 称为纳米速调管, 大小仅为数十微米, 预期频率范围在 0.3~3.0THz, 输出功率大于 50mW。



图1 太赫兹返波管




图2 太赫兹扩展相互作用速调管

回旋管是目前工作在太赫兹频段功率最高的电真空器件，在国际核聚变反应堆计划(ITER)的推动下，110GHz、140GHz 和 170GHz 等频率的回旋管输出功率已达兆瓦量级，效率大于 40%。俄罗斯应用物理研究所采用 20T 脉冲磁场系统，获得了 1THz(二次谐波)、1.5kW 的太赫兹辐射(如图 3 所示)^[5]。日本福井大学研制成功 0.3~0.9THz 系列回旋管振荡器^[6]。国内电子科技大学于 2007 年研制出 0.22THz 回旋管振荡器，输出功率达到 30kW。自由电子激光的工作波长可以覆盖整个太赫兹波段，而且通过调节电子束的能量，实现输出波长连续可调。2005 年，中国工程物理研究院研制出了我国首台自由电子激光太赫兹辐射源，频率为 2.6THz。




图3 太赫兹回旋管

3. 需要解决的关键问题

(1) 改善高频系统结构。太赫兹电真空器件高频结构存在的主要问题是尺寸小、损耗大、功率容量受限、模式竞争严重。十分有必要探索新的高频结构，例如，采用光子晶体材料构成高频系统，利用带隙结构对电磁波进行控制，增大系统尺寸，提高功率容量。另一种途径是采用开放式准光系统，使本征频谱变得稀疏，保证单模工作。另外，高频系统加工精度要求很高，尤其是慢波器

件的尺寸很小,常规加工手段难以完成,需要采用 LIGA 等深刻蚀微电子加工工艺,工艺流程复杂,成本高昂,有待探索更好的加工手段。

(2) 提高阴极性能。太赫兹电真空器件的电子注密度很高,对阴极性能提出了非常苛刻的要求,需要研究更好的阴极材料和制备工艺,提高阴极电流发射密度。另外,迫切需要探索新发射机理和新型阴极,场致发射冷阴极具有很高的电流发射密度,有希望在器件中得到应用,但需进一步解决稳定性和寿命问题。

(3) 探索新注波互作用机理,发展新型器件。太赫兹处于电子学和光子学的过渡区域,因此,能够将真空电子学与光子学有机结合起来注波互作用机制将是最有效的解决办法。例如,电子注与金属表面等离子体波、仿等离子体波及亚波长孔阵列均可相互作用产生太赫兹辐射,这方面的研究有待进一步深入。

(4) 改进模拟软件,提高设计精度。太赫兹电真空器件的设计需要精确模拟技术,现有的模拟软件主要针对微波和毫米波频段,需要完善模拟软件以适应太赫兹波段的特点。

参 考 文 献

- [1] 刘盛纲.太赫兹科学技术的新发展.中国基础科学,2006,8(1):7—12.
- [2] Siegel P H.Terahertz technology .IEEE Transactions on Microwave and Techniques ,2002, 50(3):910—928.
- [3] Ives L,Kory C,et al.Development of backwardwave oscillators for terahertz applications . Proceedings of SPIE ,2003 ,(5070):71—78.
- [4] Garcia-Garcia J,Martin F,et al.Optimization of micromachined reflex klystrons for operation at terahertz frequencies . IEEE Transactions on Microwave and Techniques ,2004, 52(10):2366—2370.
- [5] Glyavin M Y,Luchinin A G,Golubiatnikov G Y . Generation of 1.5kW,1THz coherent radiation from a gyrotron with a pulsed magnetic field .Phys.Rev.Lett.,2008,100(1):015101.
- [6] Idehara T,Ogawa I,Mitsudo S.Development of frequency tunable,medium power gyrotrons (gyrotron FU series)as submillimeter wave radiation sources .IEEE Transactions on Plasma Science ,1999,27(2):340—354.

撰稿人: 鄢 扬

电子科技大学物理电子学院

基于过模相互作用电路的回旋放大器

Gyrottron Amplifiers Based on Overmoded-Interaction Circuits

回旋管电子器件基于相对论效应的电子回旋脉塞(electron cyclotron maser, ECM)原理工作,采用回旋运动的电子束与电磁波互作用,发生角向群聚,能够在毫米波到太赫兹频段产生高功率电磁波辐射,在工业、能源、医疗、国防安全等领域具有重要的应用价值^[1]。经过约半个世纪的发展,回旋管已经发展成为一个品种多样的器件家族,主要包括振荡器和放大器两类。回旋振荡器的结构示意图如图1所示。回旋放大器同时具有高功率和宽频带的优点,在高分辨率雷达、高速率通信、电子对抗等领域具有重要的发展潜力,受到广泛关注。




图1 回旋振荡器的结构示意图

回旋管有别于常规真空电子器件,在毫米波到太赫兹频段能够产生高功率电磁波辐射,其根本原因在于电子回旋脉塞互作用允许采用结构简单的过模互作用电路,系统具有较大的功率容量^[1]。回旋振荡器采用腔体作为互作用电路,注波耦合较强,能够稳定地工作在很高阶的模式上。目前,用于热核聚变等离子体加热的170GHz兆瓦级连续波回旋振荡器的典型工作模式为高阶圆柱腔体 $TE_{31,8}$ 模式^[2]。回旋放大器与回旋振荡的根本区别在于:回旋放大器的电子注回旋谐波与工作模式在偏离截止频率的宽频带范围内同步,注波耦合强度相对较弱。此外,系统互作用电路中的各次回旋谐波都可能和非工作模式同步,基于电子回旋脉塞绝对不稳定性原理诱发自激振荡,抑制工作模式正常工作。向高频高功率方向发展是真空电子器件始终不变的主题之一。当向毫米波到太赫兹方向发展时,回旋放大器会面临过小、功率容量受限制的问题。为克服该问题,回旋放大器基于过模互作用电路中的高阶模式工作是必然趋势。过模互作用电路中,模式密度高,模式竞争更加激烈,系统稳定性将进一步恶化。因此,

如何抑制基于过模相互作用电路的回旋放大器的自激振荡问题,保证系统稳定、高效地激发高功率宽频带相干电磁辐射是限制回旋放大器向毫米波到太赫兹方向发展的根本问题。

回旋放大器主要包括回旋行波管(gyrottron-traveling-wave tube, Gyro-TWT)和回旋速调管(gyroklystron)两类。回旋速调管采用腔体相互作用电路,而回旋行波管采用具有几十个波长长度的行波相互作用电路,因而具有更大的带宽优势,在高分辨率成像雷达、高速率通信系统方面具有更好的发展潜力。由于有效相互作用空间过长,回旋行波管中的竞争模式更容易获得足够强的内反馈,建立自激振荡。因此,回旋行波管的稳定性问题比回旋速调管更加严重^[1]。回旋电子注和电磁模式是电子回旋脉塞相互作用系统的两个基本元素。国际上研究的焦点之一是探索通过控制相互作用电路中电磁模式的传输特性来解决回旋放大器的系统稳定性问题。例如,在保证工作模式与电子注具有一定耦合强度的前提下,采用特定的损耗加载形式,增强竞争模式的传输衰减,稀疏电路中的模式密度,降低系统产生自激振荡的可能性^[1]。

回旋放大器经过曲折的发展,已经取得了一些重要的研究成果。在毫米波的低频端,回旋速调放大器已经成功地应用于雷达系统,而回旋行波放大器也基本达到了实用化的水平^[1,3,4]。俄罗斯的大型相控阵雷达“Ruza”系统采用两路 Ka 波段回旋速调放大器并联作为末级功率放大器,获得 1MW 的合成功率,对散射截面大于 0.01m^2 的物体探测距离达 420km,能同时跟踪 30 个目标^[3]。美国的 WARLOC 雷达系统采用了 W 波段回旋速调放大器作为末级放大器,该放大器峰值功率为 100kW,平均功率为 10kW,3dB 带宽为 700MHz,该雷达能够进行高精度的云层成像和掠海面目标跟踪^[4]。台湾国立清华大学于 1998 年首次成功证明了分布损耗加载的相互作用电路能够有效抑制系统的自激振荡^[1,5],实验报道的 Ka 波段 TE_{11} 模回旋行波管实验获得了 93kW 的峰值功率,26.5% 的效率,3dB 带宽 3GHz 和 70dB 的超高增益。此后,美国海军实验室相继开展了具有一定平均功率能力的损耗相互作用电路回旋行波管实验^[1],包括 Ka 波段 TE_{01} 模损耗介质加载的实验和 TE_{11} 模径向开槽散射损耗实验。

尽管上述研究都取得了较理想的成果,但这些实验都具有共同的特点,即采用较低阶的圆波导 TE 模式工作,且使用了大量的损耗材料抑制系统中的自激振荡。在相互作用电路中加载的大量损耗材料在抑制系统自激振荡的同时也会吸收一部分被放大的高频功率,这严重限制了系统的平均功率承受能力。若往更高的频率和功率水平发展,放大器必然基于过模电路中的高阶模式工作。如果将大量的损耗材料直接加载到过模相互作用电路中,由于电路中模式密度较高,系统的模式选择能力降低,对工作模式和竞争模式都造成较强的衰减,系统难以高效工作。所以,分布损耗材料加载技术对过模相互作用电路的适用性还有待

进一步斟酌。此外,美国麻省理工学院于2001年和2003年先后报道了140GHz的光子带隙结构回旋振荡器实验^[6]和140GHz准光共焦波导回旋行波管实验^[7],这两种实验的相互作用电路本身具有很强的模式选择能力,对提高放大器过模相互作用电路的稳定性有较高的参考价值。

解决过模相互作用电路中电子回旋脉塞相互作用的稳定性问题是回旋放大器向毫米波到太赫兹方向发展过程中必须扫除的障碍。在几十年曲折的研究发展历程中,尽管研究人员尝试过各种各样的方案,探索出一些能在一定程度上抑制系统自激振荡的方法,但稳定性问题仍然没有找到根本的解决方案,有待进一步深入探索和尝试新的方法,如调整相互作用系统的局部注波同步条件^[8]、尝试新型的回旋放大器相互作用电路结构、尝试多种稳定性方法同时使用等。总结过去几十年回旋放大器的研究发展经验,我们可以相信,在不久的将来,基于过模相互作用电路的回旋放大器一定能够在更高的频率上获得高功率宽频带的电磁辐射,推动相关领域新型电子系统装备的革新。

参 考 文 献

- [1] Chu K R. The electron cyclotron maser. Review of Modern Physics, 2004, 76(2): 489—540.
- [2] Sakamoto K, Kasugai A, Takahashi K, et al. Achievement of robust high-efficiency 1MW oscillation in the hard-self-excitation region by a 170GHz continuous-wave gyrotron. Nature Physics, 2007, 3(6): 411—414.
- [3] Tolkachev A A, Levitan B A, Solovjev G K, et al. A megawatt power millimeter-wave phased array radar. IEEE AES Systems Magazine, 2000, 15(7): 25—31.
- [4] Linde G J, Ngo M T, Danly B G, et al. WARLOC: A high-power coherent 94GHz radar. IEEE Trans. on Aerospace and Electronic Systems, 2008, 44(3): 1102—1117.
- [5] Chu K R, Chen H Y, Hung C L, et al. Ultrahigh gain gyrotron traveling wave amplifier. Phys. Rev. Lett., 1998, 81(21): 4760—4763.
- [6] Sirigiri J R, Shapiro M A, Temkin R J. High-power 140GHz quasiopitcal gyrotron traveling-wave amplifier. Phys. Rev. Lett., 2003, 90(25): 258302.
- [7] Sirigiri J R, Kreischer K E, Machuzak J, et al. Photonic-band-gap resonator gyrotron. Phys. Rev. Lett., 2001, 86(24): 5628—5631.
- [8] Du C H, Liu P K. Stabilization of the potential multi-steady-state absolute instabilities in a gyrotron traveling-wave amplifier. Physics of Plasma, 2009, 16(10): 103—107.

撰稿人: 刘濮鲲 杜朝海
中国科学院电子学研究所

带状电子注的成形与传输

The Formation and Transmission for the Sheet Electron Beam

面向新一代微波电子系统对高功率微波和毫米波真空功率源的需求,真空电子器件逐步向高频率、高功率、高效率、小型化和紧凑型等方向发展。但是,以圆柱状电子注为主要特征的传统微波真空电子器件在这些方向发展时,由于其几何尺寸与工作频率的共度性,输出功率和工作效率很难进一步提高。带状电子注正是基于突破上述技术障碍提出的,它特指这类宽高比值很大(约 ≥ 10)的薄片状截面电子束。将带状电子注应用于真空电子器件时(如图 1 所示),其主要技术特征与优势如下:




图 1 带状电子注真空电子器件示意图

(1) 带状电子注可以在一个维度上具有小尺度以与器件的工作频率相匹配(共度性),而在另一维度上根据输出功率要求选择较大的尺寸,这种变化使得带状注能够在维持较小注内空间电荷力的前提下传输强流电子注。为了比较,图 2 分别给出了应用于 W 波段峰值功率 100kW 速调管的圆柱注和带状注束流截面示意图^[1],在工作电压和电流相同且带状注宽高比为 10 的情况下,其电流密度约为圆柱注的 1/12,聚焦磁场约为圆柱注的 1/4,大大降低了阴极电流密度和空间电荷力的限制,非常适合采用周期永磁聚焦(PPM)系统,从而可大大减轻器件的体积和重量,使其具有获得长寿命和高可靠性的技术潜力。

(2) 采用带状注的器件,其高频场与电子注相互作用和能量交换工作于非轴对称过模高频结构中,大大降低了对其几何特征尺寸的依赖,使其完全适用于微波、毫米波,甚至太赫兹频段,提高了注波作用效率和功率容量,从而可获得很高的峰值和平均功率。

(3) 带状电子注可完全应用于速调管、行波管、返波管、平面自由电子激




图 2 圆柱状电子注与带状电子注截面比较示意图

光、Orotron、Clinitrons 等多种真空电子器件中，极大地丰富和拓展了带状注器件的研究与应用范围。

正是由于上述特征和技术优势，使得带状电子注真空电子器件相关技术近年来备受关注，并迅速成为领域前沿研究的热点。但是，带状电子注的成形与传输恰恰是开展这类极具潜力的微波真空电子器件研究与应用首要解决的基础科学问题和共性瓶颈技术。

带状电子注概念虽然在 1938 年由俄罗斯的 Kovalenko 提出^[2]，但其真正意义上的研究工作始于 20 世纪 90 年代，并在近几年取得了一定的进展。

在带状电子注聚焦与传输的理论研究方面，主要发展了单粒子模型理论和旁轴冷流模型理论。单粒子模型理论主要以带电粒子在电磁场中运动方程出发，假设电子注分布不随时间变化，空间电荷场和聚焦磁场都是稳态场，从而获得电子注的运动轨迹。可以利用这种理论研究了不同密度分布的带状电子注的空间电荷场分布、带状电子注在均匀磁场中传输的 Diocotron 不稳定性，以及在 Wiggler 磁场、周期会切磁场 (PCM)、偏置周期会切磁场中的稳定性传输等^[3~5]。旁轴冷流模型理论以电子运动方程、连续性方程和泊松方程为基础，假设带状电子注是稳态的层流，从而可以得到其传输的包络方程、速度变化、密度分布和空间电荷场分布等特征。可以利用这种理论研究了带状电子注在均匀磁场中传输的 Diocotron 不稳定性^[5]，以及密度分布均匀的椭圆带状电子注在均匀磁场或线性周期聚焦结构中的传输特性^[6]。

在带状电子注成形与传输技术方面，主要有美国 CPI、SLAC、UC Davis 和 Los Alamos 国家实验室及中国科学院电子学研究所分别独立开展了相关研究工作，其关键技术是解决大宽高比非轴对称带状电子注成形中的一维压缩，以及聚焦与传输过程中的稳定性问题。研究表明，带状电子注的成形可以采用两种技术途径实现：一种是利用轴对称圆形平面阴极电子枪，通过四级磁透镜将圆形电子注一维压缩成形为带状电子注^[7]；另一种技术途径是采用非轴对称椭圆柱面或矩形柱面阴极电子枪，直接利用静电聚焦一维压缩成带状电子注^[8~10]。对于带状电子注的聚焦与传输，也可以采用两种途径实现：一种是均匀场聚焦方式^[9]，易于实现电子注与磁场的匹配，但必须克服传输过程中的 Diocotron 不

稳定性,即出现上下层之间的断裂与成丝,严重破坏束流均匀性及长距离的稳定传输;另一种是采用 Wiggler、周期会切磁场等周期永磁聚焦系统^[7~10],易于实现电子注的长距离传输,且具有小型化和紧凑型的优势,但存在电子注传输的截止电压问题,且必须实现电子注与磁场的精确匹配。

基于上述带状电子注成形与传输的技术途径,美国 CPI 于 2009 年研制成功了国际上首只具有高频输出功率的 X 波段带状注速调管,其电子注工作电压为 73kV,注电流为 152A,注截面宽高比为 25:1,采用周期会切磁场聚焦方式所获得的带状电子注直流通过率仅为 63% 左右,研制出的带状注速调管获得了 2.67MW 的高频输出功率^[8]。美国 UC Davis 也于 2009 年研制出了 W 波段带状注速调管,采用周期会切磁场聚焦传输带状电子注,工作电压为 74kV,注电流为 3.6A,注截面为 0.5mm×6mm,带状注直流通过率为 92% 左右,速调管高频输出功率为 30kW^[1]。中国科学院电子学研究所于 2007 年起开展了应用于 W 波段带状注速调管的电子注成形与传输研究工作,采用了静电聚焦成形、均匀场和 Wiggler 聚焦传输带状电子注的研究工作,带状电子注工作电压为 80kV,注电流为 4A,注截面为 0.5mm×10mm,研制出的 Wiggler 聚焦与传输带状电子注直流通过率达到了 95% 以上,均匀场聚焦与传输带状电子注的直流通过率高达 98% 以上^[10]。

综上所述,带状电子注的理论和关键技术虽然取得了一定进展,但带状电子注的成形与传输仍然是真空电子器件领域面临和急需解决的科学技术难题,主要体现在:①带状电子注的动力学理论体系研究虽然先于技术而发展,但目前尚未形成自洽与完善的理论体系,更没有与带状电子注成形与传输技术研究结合起来,以对其不稳定性问题进行深入诠释。②带状电子注传输技术目前虽然在直流通过率方面取得了一定进展,如采用均匀场聚焦方案虽然可以获得很高的直流通过率,但这种方案完全是以高强度的磁场约束带状电子注聚焦,而忽略了其传输过程中 Diocotron 不稳定性、层流性,以及旋转和扭曲等重要特性,而这些特性对带状电子注与高频系统的相互作用过程至关重要;采用周期 Wiggler 或周期会切磁场聚焦方案时,由于电子注传输特性对其周期聚焦磁场非常敏感,使得两者的良好匹配很难实现,也大大制约了电子注的长距离传输。③带状电子注传输物理过程非常复杂,到目前为止,对其层流性、均匀性、旋转、扭曲、变形、振荡、边缘发散等不稳定性进行全面测试的系统尚未建立起来,因此,也无法对其传输物理过程进行实验验证。④从应用需求角度而言,真空电子器件对带状电子注的束流品质要求较高,但目前由于尚未获得满足品质要求的电子注,使得研制出的带状注器件注波相互作用效率低于 30%,也无法全面体现出这种器件的技术优势。⑤带状电子注技术向高频段发展时,尚需突破小尺寸、高精度的微机械加工,以及大尺寸平面焊接等一系列瓶颈技术。

由此可见,如何解决带状电子注成形与传输的动力学理论与技术,以获得长距离传输、高稳定性、高直流通过率和高品质的带状电子注,并将其全面应用于微波真空电子器件领域,推动其向高频率、高功率、高效率、小型化和紧凑型等方向发展,将是本研究方向近年来面临和急需解决的核心基础科学问题和共性关键技术。

参 考 文 献

- [1] Barnett L R, Shin Y M, Gamzina D, et al. Quasi-optical (QO) multi-gap output cavity w-band sheet beam klystron. Beijing: Research Report at Institute of Electronics, Chinese Academy of Sciences, 2010.
- [2] Booske J H, Brian D M, Thomas M A. Stability and confinement of nonrelativistic sheet electron beams with periodic cusped magnetic focusing. J. Appl. Phys., 1993, 73(9): 4140—4155.
- [3] Booske J H, Basten M A, et al. Periodic magnetic focusing of sheet electron beams. Physics of Plasma, 1994, 1(5): 1714—1720.
- [4] Basten M A, Booske J H. Two-plane focusing of high-charge sheet electron beams using periodically cusped magnetic fields. J. Appl. Phys., 1999, 85(9): 6313—6322.
- [5] Chen H C. The diocotron instability of a general relativistic electron beam. Phys. Fluids B, 1992, 4(6): 1412—1415.
- [6] Zhou J, Bhatt R, Chen C P. Cold-fluid theory of equilibrium and stability of a high-intensity periodically twisted ellipse-shaped charged-particle beam. Physics Review Special Topics-Accelerators and Beams, 2006, 9(3): 1—5.
- [7] Carlsten B E, Russell S J, Earley L M, et al. Technology development for a mm-wave sheet-beam traveling-wave tube. IEEE Transactions on Plasma Science, 2005, 33(1): 85—93.
- [8] Cusick M, Atkinson J, Balkcum A, et al. X-band sheet beam klystron (XSBK) // 2009 IEEE International Vacuum Electronics Conference, Rome, 2009: 296—297.
- [9] Scheitrum G, Caryotakis G, Burke A, et al. W-band sheet beam klystron research at SLAC // IEEE 2006 International Vacuum Electronics Conference, California, 2006: 481—482.
- [10] Ruan C J, Wang S Z, Xie J X, et al. Development of sheet beam electron optics system for w-band klystron // IEEE 2010 International Vacuum Electronics Conference, Monterey, 2010: 39—40.

撰稿人: 阮存军
中国科学院电子学研究所

微波真空电子器件的发展

The Development of Microwave Vacuum Electron Devices

作为产生电磁波的重要手段,微波真空电子器件的发展已有一百多年的历史。1904 年,英国 Fleming 发明了二极电子管,1906 年,美国 Forest 发明了三极电子管,20 世纪 20~40 年代发明了基于动态控制原理的磁控管、速调管和行波管,60 年代发明了基于回旋脉塞机理的回旋管,70 年代发展了基于强流电子注发生器和电子加速器的相对论微波器件与自由电子激光器。微波真空电子器件已广泛应用于雷达、电子对抗、通信和广播、粒子加速器、可控热核聚变等离子体加热装置、微波加热和材料处理系统,成为军用和民用微波电子系统的核心器件,图 1 表示微波真空电子器件的应用领域^[1]。




图 1 微波真空电子器件的应用领域

随着固态器件的发展,微波真空电子器件的发展受到了严重挑战。

微波真空电子器件是否会被固态器件替代,微波真空电子器件的发展是否已经到头了? 其答案肯定是否定的^[1,2]。衡量一门学科和一类器件是否继续发展的标准有三个: ①与其他类型器件相比,是否还有其优点; ②是否有进一步的应用需求; ③是否还有需要解决的科学技术问题。下面分别对上述问题进行分析:

(1) 微波真空电子器件的独特技术优势。高脉冲功率和平均功率是微波真空电子器件的独特技术优势,是微波固态器件无法替代的。S波段速调管的峰值功率达到200MW, X波段速调管的峰值功率达到75MW, P波段和L波段速调管的连续波功率超过1MW^[3]。回旋管振荡器在110~170GHz的频率范围内,其长脉冲和准连续波功率已达到兆瓦量级^[4]。

(2) 微波真空电子器件的应用需求。探索宇宙起源和物质结构的高能粒子加速器、深空通信和探测系统、微波武器等系统要求器件的峰值功率达到数百兆瓦至数十吉瓦;作为未来能源的可控热核聚变装置、加速器驱动洁净核能系统和空间太阳能微波电站要求器件的频率覆盖微波与毫米波段、效率为65%~75%、连续波功率达到兆瓦级;太赫兹成像、反恐装备等系统要求器件的频率覆盖毫米波和太赫兹波段、功率为瓦级至百千瓦级。上述应用只能由微波真空电子器件来实现。

(3) 微波真空电子器件发展中需要解决的科学技术问题。

微波真空电子器件在向高频率、高功率发展中面临的科学难题如下:

(1) 解决模拟微波真空电子器件内所有物理过程中遇到的科学问题^[5]。微波真空电子器件内电子注的产生、成形和聚焦,电子与高频电场的相互作用,电子和微波与器件材料的相互作用,器件的热和机械特性等物理过程的描述与模拟对于器件的性能、可靠性和寿命等有重要影响。由于微波真空电子器件内物理过程的复杂性,要实现器件全物理过程的精确模拟,其主要难点有以下几点:①器件中包含数量巨大的电子和由器件内各种残余气体产生的各种离子,模拟粒子间的相互碰撞、粒子与微波电场间的相互作用的物理过程非常复杂。②器件的高频系统、电子枪区和收集极区中存在各种高频模式,由于注-波互作用区域和高频系统在尺寸上存在巨大差异,要精确模拟电子注与各种模式的相互作用十分困难。对于大功率毫米波和太赫兹器件,这种差异更大,其物理过程的模拟将更为困难。③器件的性能还与其结构的力学和热学特性相关。由于微波真空电子器件由数十种不同材料的数百个零件组成,零件间的连接由多种焊接方法形成的上百个焊缝实现,模拟器件在工作状态的力学和热学特性也是十分困难的。

在理论上,采用全粒子、全电磁计算模拟方法可以精确描述电子注与各种高频模式的相互作用,从而预测器件的高频性能、振荡、谐波分量和噪声等特性。目前发展的粒子模拟方法和相应的计算软件,在计算模型的正确性和计算方法的有效性方面距离器件整个物理过程的精确模拟还相差很远,如果考虑器件结构和材料的力学与热学特性,其难度更大。

(2) 解决基于高次模式和大尺寸电子注的高频率、高功率器件中存在的科学问题。当微波真空电子器件向高频率、高功率方向发展时,由于受到阴极发

射电流密度、高频结构和电子注聚焦的限制,必须采用工作在高次模式的高频结构和大尺寸的电子注(多电子注和带状电子注)。

对于工作在高次模式的回旋器件和多注器件,为了实现稳定工作,需要研究电子注与多个非工作模式的相互作用,研究模式竞争的物理机理,提出抑制非工作模式振荡和降低杂谱输出的方法与技术途径。

对于采用大电子注尺寸的带状注器件,需要解决带状电子注在矩形漂移管通道中长距离传输存在的扭曲、变形和破裂等特殊科学问题。

(3) 解决毫米波和太赫兹真空器件中存在的科学问题^[6]。微波真空电子器件向亚毫米波和太赫兹频段推进时,在阴极发射能力,电子注形成和聚焦,高频系统的材料、加工和工艺,器件的热耗散等方面遇到了非常大的技术困难。基于场致发射阵列阴极、微加工和微制造技术的微真空电子器件是克服上述困难的重要技术途径,其中,需要解决的科学问题主要有:具有高发射电流密度的场致发射阴极的材料和制备工艺;微型高频结构(如带状注谐振腔、折叠波导型慢波结构)的加工、制造、焊接和测试;低高频损耗和高导热率的金属和介质材料的制备等。

综上所述,在实际应用和科学技术进步的推动下,微波真空电子器件作为产生电磁波的重要手段仍在不断发展,仍然存在很多科学技术问题需要人们去研究和解决。

参 考 文 献

- [1] Abrams R H, et al. Vacuum electronics for the 21th century. IEEE Microwave Magazine, 2001, 61—72.
- [2] Levush B, et al. Vacuum electronics: Status and trends. IEEE AES Systems Magazine, 2007: 28—34.
- [3] Caryotakis G. High-power microwavetubes: In the laboratory and on-line. IEEE Transactions on Plasma Science, 1994, 22(5): 683—691.
- [4] Thumm M. History, present status and future of gyrotrons // IVEC 2009, Rome, 2009: 37—40.
- [5] Antonsen T M, et al. Advances in modeling and simulation of vacuum electronic devices. Proceedings of the IEEE, 1999, 87(5): 804—839.
- [6] 刘盛纲. 太赫兹科学技术的新发展. 中国基础科学, 2006, 1: 7—12.

撰稿人: 丁耀根
中国科学院电子学研究所

纳米尺度场发射的理论问题

Theoretical Issue of Nano-scale Field Emission

20 世纪初, 人们就发现了场致发射现象, 并在 20 年代得到了金属表面场致发射的 Fowler-Nordheim 公式, 并在扫描电镜中得到了应用。50 年代末, 微电子工艺的发展使人们想到了利用微加工技术和薄膜技术制作低压场发射阵列阴极。斯坦福研究所的 Spindt 博士进行了长达近五十年的研究工作, 制作出了薄膜场发射阵列阴极, 阵列阴极的电流密度达到 $100\text{A}/\text{cm}^2$ 以上^[1], 并已经在 C 波段行波管中进行了试验, 在 10% 的占空比下工作了 150 小时, 电子注电流为 121mA, 射频功率在 5GHz 时为 100W, 阴极电流密度达到 $15.4\text{A}/\text{cm}^2$, 阴极工作电压在 100V 以下。理论上讲, 这种阴极具有快速启动、功耗小、电流密度大等特点, 人们试图将它应用在微波真空器件、电子束曝光系统、平板显示器件等, 但都没有完全成功, 主要问题在于: 大面积微尖阵列的均匀性、几何形状的不均匀使得大部分发射体在工作电压下对发射没有贡献, 而部分微尖则有可能存在过量发射而损坏, 并导致整个阵列的失效; 在应用过程中, 要求较高的真空度, 避免阵列阴极受到离子的轰击。除了技术上的问题之外, 由于发射体是由薄膜工艺制成的, 同时随着纳米科学的发展, 很多纳米材料也开始进行了场发射的应用研究, 这种纳米尺度表面的发射机理、表面功函数、热效应、发射稳定性的影响因素等尚未完全解决, 纳米尺度下传统的场发射 Fowler-Nordheim 理论是否有效并没有完全解决。如果这些科学问题得以解决, 将有助于理解微尖锥场发射的理论, 促进应用问题的解决。

场发射就是通过外加电压在发射体表面产生大的电场而发射电子, 都是通过降低表面势垒和材料的功函数, 以及改变发射体的物理形状(提高场增强因子)来提高场电子的发射能力。场发射理论的起源是早期 Fowler 和 Nordheim 的研究工作, 也就是一维平面发射理论, 其中假设了电子分布服从 Fermi-Dirac 分布, 发射体表面是光滑平坦的, 忽略原子尺度的不规则性、发射体表面功函数均匀分布等, 并认为表面势垒是三角形的, 考虑镜像电荷并根据量子力学计算出透射系数, 从而得到常用的关于场发射电流密度 J 和电场 E 、功函数 ϕ 之间关系的 Fowler-Nordheim 公式, 如下:

$$J = \frac{AE^2}{\phi} \exp\left(\frac{-B\phi^{3/2}\theta_{(r)}}{E}\right)$$

式中, A 和 B 为常数; $\theta_y = 0.95 - y^2$ 为 Nordheim 函数, $y = 3.79 \times 10^{-4} \frac{\sqrt{E}}{\phi}$ 。

Fowler-Nordheim 公式得到了广泛应用, 在很多应用中利用 $\lg\left(\frac{I}{V^2}\right)$ 和 $\frac{1}{V}$ 之间是否为线性关系来验证一个电子发射是否为场致发射。在 Fowler-Nordheim 公式出现后的几十年间, 科学家也对它进行了多方面的考虑, 如在接近金属表面时, 经典的镜像电荷近似电子的量子力学性质, 使得原来的近似不再适用; 开展了多体效应、势垒高度对温度和场的依赖性、化学势的影响、二次势的影响等研究工作。

由于场发射通常是利用尖端表面的强电场来产生场致电子发射, 在计算微尖端阵列发射时, 利用了“等效”尖端半径、“等效”发射面积的概念, 计算总发射电流时采用了将一维发射电流密度作为局部电场变化的函数在三维曲面上进行积分的近似方法。

研究者发现, 在发射体尖端表面, 其实有远小于曲率半径的“发射点”, 如粒子边界、原子团、纳米级突起等, 由于离子轰击、溅射过程、强电场下的迁移等原因形成, 尺寸量级在 $2 \sim 3\text{nm}$ 量级。目前的一维到三维理论研究都假设了一个特殊的结构, 如双曲面或椭圆面发射体, 集中在 Fowler-Nordheim 公式的推导和应用, 忽视了电子发射物理机制的复杂性和多样性, 如电子在体材料内部的传输、原子级发射点的量子力学处理、不同材料之间的肖特基接触等, 特别是近年来纳米材料、纳米结构在场发射领域的应用, 这些纳米结构场发射中存在的问题需要进行深入的理论和实验上的研究。

参 考 文 献

- [1] Zhu W. Vacuum Electronics. New York: Wiley, 2001: 33—98.

撰稿人: 冯进军

中国电子科技集团公司第十二研究所

分子电子学的难题

Puzzle of Molecular Electronics

20 世纪 70 年代,描述微电子小型化发展趋势的摩尔定律为人们广泛接受,引发学者考虑微电子之后的电子器件是什么?至 80 年代初,国际上研究的先驱者明确提出了分子电子学的概念,探讨分子开关、分子计算机、细胞自动化元件和生物计算机的可能。在先驱者中,法国的 Lehn 教授^[1],以其非凡的归纳、推理和想象力描述了分子器件的信号发生、处理、传输及检测等,提出了信息化学(semiochemistry)和超分子化学(supermolecular chemistry)等概念。由于他对分子电子学研究的贡献,获得了 1987 年诺贝尔化学奖,由此激起了分子电子学的研究热情,希望继续研究的成果能第二次获得诺贝尔奖。

当前在分子电子学研究中,人们多是以微电子的场效应晶体管为主要结构,将分子置于源(S)、漏(D)电极之间,作为载流子的通道,通过门(G)电极调控载流子,从而实现电信号放大^[2]。在目前的器件和电路研究中遇到难于跨越的问题主要有:①难于控制分子水平的器件组装、测量和表征,特别是目前的技术很难达到重复、批量地制备样品。多数模拟计算结果往往高于实验测量数据,差别高达量级大小。很多研究是用有序分子排列的膜代替单分子作为通道,所测得的器件特性很少能超过现今微电子的。②单分子器件具有显著的尺寸效应和量子效应。图 1 给出在 Au 电极间的有机分子结构^[3],其中的有机分子与 Au 电极接触可能是一两个原子结合,这个界面不仅存在原子结构的尺寸问题,也存在电子结构间的耦合问题,涉及多尺度和参考能级的选取问题,这使得分子器件性能对环境 and 外界参量的变化非常敏感,即分子和电极原子的任何改变,或温度、电磁场、光、应力、化学环境等的微小变化都将显著改变器件的特性。分子与电极界面结构本质上就是一个不稳定的结,所以,实验测量上难于得到重复的结果。③分子电子器件和电路难于用微电子光刻重复步进技术制造,而基于化学的自组装技术本征地存在缺陷和杂质。因此,分子器件的自检测、自纠错和自修复技术是必不可少的,但至今如何通过选定的材料和功能软件实现分子器件集成电路的功能稳定也是一个具有探讨意义的问题。④如何像人类大脑那样进行信息加工和存储?

在 20 世纪末,科学家对探索人类大脑和感官神经系统是怎样进行信息加工的产生了浓厚的兴趣。比较计算机与大脑,都是用电信号处理信息,但有基本上的不同。如在计算机中,信号是由固体中产生的电子;而在大脑中,是流体中阴阳离子扩散。其次,在计算机中,信息以光速传输;而在神经系统




图 1 在 Au 电极间的有机分子

中，信号的传输速度的典型量级是 100m/s 。这样，计算机与大脑的信号速度差 $3 \times 10^6 \sim 3 \times 10^8$ 倍。尽管如此，大脑仍有能力在几分之一秒内完成识别和分析复杂图像，但大脑的计算速度和容量的功能还是不能与现代最快和最大的计算机相比。在大脑中，计算元件是神经细胞，经过几百万年的发展，能有效地执行高度专门化的任务。在大脑中，信息的加工和存储是在过程中同时进行的，生物体从生活环境中接收、加工和存储信息，是生命的基本特征和能力。存储的一部分是来自生活经验的记忆，另一部分是非感官获取的遗传信息。在大脑中，信息加工过程被称为思考，心理学家认为思想、感觉、意志和行为是大分子交叉连接系统中的物理化学过程。思想是在语言和图像的信息联系与结合中形成的，给出体系运动的命令、行为过程的控制等。多种多样的思想演变是相当丰富的。在生物记忆中，有短期、中期和长期的区别，几分钟后将被忘记的印象可以存储在“中间”记忆中。在短期记忆中，事件会很快被忘记。在长期记忆中，信息可被固化多年甚至终生 (>120 年)，通常的感觉刺激也不能擦除。关于人类大脑的记忆功能如表 1 所示，其中，网络指神经网络。

表 1 人类大脑的记忆功能

	短期记忆	中间记忆	长期记忆
存储能力/bit	150	1500	$10^6 \sim 10^7$
注入速率/bit	15	0.5	0.05
信息保存期	几分钟	几天	一生
存储方式	网络	生物膜和网络	蛋白质和 DNA

20 世纪 80 年代，人们已经开始认真研究神经系统的计算机问题。首先考虑的是作为中心神经系统(CNS)加工信息的机理，研究在神经网络中的细胞和分子加工信息的过程。目前流行的人工神经网络模型是一个数学模型，它使

用了大量简单的但由高度相互连接的加工元件构成的网络，称为人工神经网络^[4]，图2给出三层人工神经网络结构和反向传播模型，它分为输入层、存储层和输出层。如果能用分子电子材料和器件构造人工神经网络集成电路，就有可能实现在同一单元同时进行信息加工和存储，这种记忆存储与整个电路的结构有关，有相当复杂的联系^[5]。当某些信息被忘记或受到侵害，可以通过回忆而重新记起，而且能追溯当初信息的输入过程。如在存储器中记录为10，网络记忆能告诉我们当初是经过 2×5 ，还是 $5 + 5$ 等运算后存入的。这种网络计算和存储具有极小的体积、极高的效率，在分子电子学中是有可能实现的。关于短期、中期和长期存储记忆问题，是生命特征，进而还涉及遗传信息和知识信息的加工与存储等诸多问题，那已经超出了分子电子学的研究范围。




图2 三层人工神经网络信息加工模型

参 考 文 献

- [1] Lehn J M .Supramolecular chemistry :Receptors ,catalysts ,and carriers .Science ,1985 ,227 (4689) : 849—856 .
- [2] Sablon K .Nanoelectrodes for molecular devices ; A controllable fabrication .Nanoscale Res . Lett . ,2008 ,3 :268—270 .
- [3] Reed A M .Molecular electronics ;Back under control .Nature Materials ,2004 ,3 :286—287 .
- [4] Matsumoto G .Optical switch and devices for future .IEEE Spectrum ,1988 ,25 :36—41 .
- [5] Turel O ,et al .Architectures for nanoelectronic implementation of artificial neural networks ;New results . Neurocomputing ,2005 ,64 :271—283 .

撰稿人：薛增泉
北京大学电子学系

从医学超声成像发展看隐含信息的揭示

Development of Medical Ultrasound Imaging Originated from the Discovery of Hidden Information

次声波、声波、超声波、红外、紫外、微波、X 射线等各种波动形式的载体在运动过程中会携带信息，如 X 射线射束在穿过物体时被物体中各种成分吸收而衰减，在接收端接收到的 X 射线强度信号中就隐含有物体各种成分及其不同数量的信息。

在直接检测的信号中存在隐含信息是一种普遍现象。隐含信息有许多十分重要和有用的特性，同时，这些特性是其他方法所不具有的。所以，如果能把隐含信息从直接信号中提取出来，则将为各个领域的发展作出重要的贡献。

下面以医学超声成像为例。医学成像发展已经有超过 50 年的历史，正是不断揭示超声回波内的隐含信息推动了医学超声成像的发展。当我们通过超声探头在体外向人体组织内发射超声波，人体组织内部就不断有超声回波产生，其回波又通过超声探头接收，在普通示波器上就可以观察到如图 1 所示的典型超声回波图，大量来自人体内的隐含信息存在其中。几十年以前，人们就在开始研究如何从中发现和提取有用的信息。




图 1 超声回波图

人们首先认识到，超声反射和折射所产生的组织内部各层次回波有不同的幅度变化信息，决定此幅度信息的物理基础则是人体内声特性阻抗值的差异性，利用这些信息及其变换就可以进行超声诊断。1952 年，美国 Wild 等^[1]做了先驱工作，他们应用脉冲反射式 A 型超声诊断仪(简称 A 超)分析组织结构，这是一种将检测出来的超声回波包络幅度表示为纵坐标、超声传播时间表示为横坐标

的显示方式。然而，A 超所显示的波形图只能反映某一方向的一维深度各点的回波波形信息，缺少二维解剖形态。20 世纪 60 年代末，B 型超声诊断仪(简称 B 超)被广泛研究。B 超也是以回波的幅度调制光点亮度，再加上声束平面扫描，就形成二维显示断面图，此成像方法检测的实质还是以界面的声特性阻抗差形成的幅度信息作为成像参数。

在提取幅度信息进行成像之后，人们又考虑到胎心、瓣膜、血管壁、血流等都是人体中的运动体，当超声照射到它们时会产生多普勒效应，那么，只要在体外检测出由体内运动体产生的多普勒频移信号，就可无创性地揭示出体内运动速度信息。多普勒超声诊断法主要用于心血管，以频谱显示血流动力学指标。彩色多普勒血流成像法(彩超，color doppler flow imaging, CDFI)将某个特定区域内的血流速度映射为一幅伪彩色图像，并实时显示在一幅二维 B 超图像之上。1983 年，日本 Aloka 公司首先推出血流彩色成像。我国深圳安科高科技股份有限公司于 1989 年研制和生产出中国第一台彩超^[2]。彩超以伪彩色图像显示血流动力学指标，在心脏、外周血管检查及某些肿瘤的良恶性鉴别上进一步补充和完善了 B 超的诊断。

以上两种信息的揭示都沿用了线性声学的规律。实际上，声波在介质中传播，以及在反射和散射时，都具有非线性效应，导致产生谐波，其中，二次谐波幅度最强，其他高次谐波都可忽略不计，如图 2(b)所示^[3]。揭示出人体回波中谐波信息并进行成像，尤其是利用超声造影剂的谐波成像是超声诊断技术的又一次飞跃。




图 2 微泡的声学特性图示

微泡是由气体填充，其直径远小于超声波波长而具有高散射截面，可以产生强烈的声散射，微泡在超声波作用下非对称性地膨胀和压缩，产生的谐波幅度比周围组织的高几十倍至几百倍，应用谐波成像技术可明显改善图像质量。谐波成像技术标志着超声成像开始跨入分子成像时代。此外，可将超声造影剂作为一种载体，利用超声波与微泡造影剂的相互作用及所产生的生物学效应，

实现携带药物、基因等靶向组织的转移释放,起到靶向治疗的作用。可以说,超声微泡造影剂(ultrasound contrast agent, UCA)的出现是超声医学发展史上的又一重大飞跃。

千百年来,医生们常常使用“触诊”来检测某些疾病,因为“坚硬”的组织通常是早期病变的标志。当软组织发生病变时,其组织的弹性特征会随之改变。这就启示人们应当提取与组织弹性有关的参数,以弥补医学成像模态的不足。1988年,Lerner和Parker提出有里程碑意义的“声弹性(sonoelasticity)”技术,首次将感兴趣区域表示成一幅图像,该图像显示了一个由软组织包绕的高硬度区域的检测情况。1991年,Ophir等提出了“弹性成像(elastography)”技术,采用外部压迫的方法获得应力图像,可显示病人的炎症、增生、纤维化病变^[4]。

作为一种全新的成像技术,超声弹性成像可用于肿瘤(乳腺癌、前列腺癌等)检测、热治疗监测、肾移植监测等方面,被称为继A型、B型、D型、M型之后的E型模式,具有非常重要的临床价值和广阔的应用前景。

回顾过去几十年,从超声回波中检测出幅度信息,到检测出多普勒频移信息,进而检测出谐波信息、弹性信息,可以说超声回波信号的检测历史就是一部不断发展的揭示隐含信息的历史。从B超、彩超,到谐波成像、弹性成像……应该说每一步都有一个跃进,但都没有带来根本性的突破。难点有两个:一是要突破前面所述的声特性阻抗差异成像的传统,找到新的成像参数;二是要改变超声成像除了实时无创地揭示器官解剖信息外,还要获得病变的功能信息及分子水平的信息。

长期以来,已有大量的基础研究在继续寻找各种新的成像参数,其研究前沿及可能有进一步突破的领域目前聚焦在以下几个方面:

(1) 继超声谐波信息揭示和应用后,超声非线性声学参数信息的揭示和研究一直没有停止,如医学超声衰减信息提取和应用,有可能揭示新的组织结构图像。

(2) 医学超声有关的交叉学科的发展和应用,在前述的超声谐波成像基础上进一步和分子生物学结合,发展超声分子成像;将编码通信技术和超声技术结合^[5],改变“发射脉冲进,脉冲回波出”的传统低效率的成像方式,实现信息量丰富的编码超声成像技术;将射频技术或激光技术与超声波技术进行了有效结合,改变传统超声成像“声进声出”和传统光学成像的“光进光出”,实现“光进声出”,即发射激光或射频进入人体,通过激光或射频吸收、转变成超声回波,其回波中含有吸收过程中携带的生物化学信息,如可以检测出癌变信息^[6]。

可以预见,新的超声隐含信息检测出来将会带来医学超声成像新的进步和

根本性的突破。

参 考 文 献

- [1] Wild J J, Reid J M .Application of echo-ranging techniques to the determination of the structure of biological tissues .Science ,1952 ,115 :226—230 .
- [2] 陈思平 .医学超声影像产业现状和发展 .应用声学 ,2005 ,24 (4) :201—207 .
- [3] Lindner J R .Microbubbles in medical imaging :Current applications and future directions . Nat .Rev .Drug Discov . ,2004 ,3 :527—532 .
- [4] Ophir J ,Céspedes I ,Ponnekanti H ,et al .Elastography :A quantitative method for imaging the elasticity of biological tissues .Ultrason .Imag . ,1991 ,13 :111—134 .
- [5] Jin C ,Chen S P ,Qin Z D .A new coding scheme in coded ultrasound using repetition interval staggering .Journal of Zhejiang University :Science A ,2009 ,10 (8) :1213—1216 .
- [6] 汪立宏 .光声成像的未来 .光学与光电技术 ,2009 ,7 (3) .

撰稿人：陈思平

深圳大学生物医学工程中心

复合发射阴极与热-场统一发射模型

Hybrid Cathodes and Thermal-Field Generalized Emission Model

1967 年, 苏联阴极专家 Figner 第一次研制成功了添加元素钨的储备式阴极, 因为钨元素是以钨酸盐的形式添加的, 所以, 习惯上把该型阴极称为钨酸盐阴极。在 Figner 之后几十年, 各国又逐渐研制成功了各种形式的钨酸盐阴极, 包括浸渍型钨酸盐阴极、顶层钨酸盐阴极、薄膜型钨酸盐阴极、亚微米基体含钨扩散阴极等, 这些阴极都具有一个共同点, 就是与普通的钨钨阴极相比具有非常突出的发射能力, 通过对其电子发射机理的深入研究, 发现钨酸盐阴极的电子发射特性非常特殊, 采用任何一种单一电子发射理论都难以解释其发射特性, 而采用热发射与场发射相叠加的“复合发射机制”却可以较好解释其发射特性。实际上, 在自然界中还存在很多可以采用“复合发射机制”解释的发射体。例如, 应用于正交场器件的阴极发射体, 采用的是热发射与次级电子发射的复合作用机制, 还有其他的光与热复合作用的热助光电子发射等, 这些现象说明电子发射存在共同作用的发射机制, 但共同作用的发射方式之间似乎又存在着复杂的互相作用。针对这种现象, 海军实验室的 Jensen 依据量子理论提出了所谓“统一发射理论”的方程^[1], 如下:

$$J(F, T) = \underbrace{\frac{1}{2\pi} \int_0^\infty \frac{dk}{m} T(E(k)) f(E(k)) dk}_{\text{热发射}} = \underbrace{\frac{1}{2\pi h} \int_0^\infty T(E) f(E) dE}_{\text{场发射}}$$

$$T(E) = \Theta[E - (\mu + \Phi - \sqrt{4QF})], \quad -\ln(T(E)) = \frac{b_n}{F} + \alpha_n(\mu - E)$$

$$f(E) = \frac{m}{\pi h^2} \exp[\beta(\mu - E)], \quad f(E) = \frac{m}{\pi h^2} (\mu - E)$$

该方程主要考虑了热与场的因素, 但依然无法解释钨酸盐阴极的低温高发射特性。

通常, 电子的发射方式大致有以下几种: 热电子发射、场发射、光电发射、次级电子发射及旋转极化发射等。本文主要探讨如何能够把热电子发射与场发射理论统一起来。热电子发射遵循 Richardson-Dushman 方程, 而场发射遵循 Fowler-Nordheim 方程, 两个方程的简化形式非常类似, 发射电流密度分别是以温度和场强为主要特征的函数, 其特性对比概述如表 1 所示^[2]。

表 1 场发射与热发射特性对比

热发射	场发射
Richardson-Dushman 方程 $J_{\text{RLD}}(F) = A (T[\text{K}])^2 \exp\left(-\frac{B}{T}\right)$ $\begin{cases} A = 120.17 \frac{\text{Amp}}{\text{cm}^2 \text{K}^2} \\ B = 11604.5 \text{ K}(\Phi[\text{eV}]) \end{cases}$	Fowler-Nordheim 方程 $J_{\text{FN}}(F) = a_{\text{fn}} F^2 \exp\left(-\frac{b_{\text{fn}}}{F}\right)$ $\begin{cases} a_{\text{fn}} = \left(1.5414 \times 10^{-6} \frac{\text{Amp}}{\text{eV}}\right) \frac{1}{\Phi[\text{eV}] t(y)^2} \\ b_{\text{fn}} = \left(6.8309 \times 10^7 \frac{\text{eV}}{\text{cm}}\right) (\Phi[\text{eV}])^{3/2} v(y) \end{cases}$
少量电子：具有接近 1 的发射概率	大量电子：具有很低发射概率
与温度 T 成指数关系	与温度 T 相对无关
阴极涂层材料具有低功函数特性	用作发射体的金属具有高功函数特性
阴极发射面积可以做得比较大，但发射电流密度相对较低	阴极发射电流密度可以很高，但通常发射面积很小

热电子发射的途径是获得外界热能克服势垒进入自由空间，而场发射的途径是纯粹由隧道效应引起的电子发射，但其电子发射概率非常小。事实上，热电子发射和场发射可分别看做“热-场统一发射模型”的两个特例。在这两个特例之间，当热阴极处于加速场的条件下，外部电场抑制势垒，相应地会降低阴极表面的功函数，此即为肖特基效应，故阴极发射提升的能力被定义为肖特基增强因子；而肖特基效应本身也伴随着因外加电场引起的势垒宽度变窄，即可能形成量子隧道(这个过程可称为“场助热发射”，实际上，场助热发射是与扩散阴极的非正常肖特基效应相对应的)。当电场进一步增强，形成量子隧道效应时，即转变为热场发射(这个过程也可称为“热助场发射”)，当电场强度足够强时，热发射的贡献与场发射相比微不足道时，即构成场发射，场增强因子被定义为 β 。

在场助热发射和热助场发射之间，存在热与场共同起作用的区域。工作在这个区域的阴极，特别是新型含钨扩散阴极和改进型氧化物阴极，具有复合发射机制，故称之为热-场复合发射阴极。如图 1 所示，热-场复合发射阴极比常规的热电子发射体在低温下能提供更高的发射电流密度，其工作稳定性和可靠性与场发射阴极相比又高得多^[3,4]。

目前，实际工程应用的电子源大多是通过能量转换方式获得的，如热阴极、光电阴极、次级电子发射体等。热阴极广泛应用于各种大功率真空微波管中，微波管的发展对电子源提出了越来越多的要求，如大电流密度、低工作温度、长寿命等，这就使得单一工作机理的阴极难以满足要求，迫切要求有新型的阴极诞生。类似钨酸盐阴极，具有更低温度、更大发射电流密度的新型阴极的研究方向如何确定呢？这就需要能反映各种具体热和场相互作用，并综合考虑各




图1 半导体-单原子层叠加模型

种因素的统一的电子发射模型。热-场统一发射模型必须能够定性并定量解释“场助热发射”和“热助场发射”的形成基础。

构建了统一电子发射模型，期望可以回答各种不同发射机理的复合作用机制如何互相影响，各种不同发射机制在什么情况下可以得到最佳的电子发射效果，同时，也为如何制备具有复合发射机制的新型阴极提供研究指导方向。

参 考 文 献

- [1] Jenson K L, Cahay M. A general thermal-field emission equation. IVEC/IVESC2006, 2006: 97—98.
- [2] 江剑平, 翁甲辉, 杨泮棠. 阴极电子学. 北京: 国防工业出版社, 1980.
- [3] 李季. 非正常肖特基效应的研究[硕士学位论文]. 北京: 清华大学, 2007: 40—68.
- [4] Li J, Wang H, Yu Z Q, et al. Study on Abnormal Schottky effect of thermionic cathodes. IVESC2008, 2008.

撰稿人：李 季

中国电子科技集团公司第十二研究所

自旋电子学中的自旋传输矩效应

Spin Transfer Torque Effect in Spintronics

电子的电荷和自旋都可以是信息的载体,传统电子学研究的是电荷的运动规律,而后者研究的是自旋的运动规律,是有待开发的新的信息资源,它本身形成了一门新的学科,即自旋电子学。

1. 自旋电子学发展背景及自旋传输矩的发现

自旋传输矩 (spin transfer torque, STT) 效应是由 Slonczewski 和 Berger 在 1996 年分别独立发现的与自旋相关的新的量子效应^[1,2], 具有重要的科学意义。与其相关的有巨磁阻 (giant magnetic resistance, GMR) 效应、隧道磁阻效应 (tunneling magnetic resistance, TMR)。自旋阀 (spin valve) 结构为铁磁固定层 20/隔离层 4/铁磁自由层的磁 3 组成的磁多层结构, 数字为层厚度, 以 nm 为单位, 整体如图 1 所示。当两个磁膜平行或反平行排列时, 具有不同的电阻, 平行态为低阻态, 而反平行态为高阻态, 只不过巨磁阻中间的隔离层为普通金属, 而隧道磁阻为绝缘层。电子的转移可以产生自旋流, 它是张量, 决定于电流和自旋的大小与方向, 由此推论, 在电子流为 0 时, 自旋流可以不为 0, 如携带不同自旋的电子沿相反方向运动的情况, 这样的过程几乎不消耗能量, 对节省能耗非常有用。




图 1 纳米自旋阀的基本结构

2. 自旋传输矩效应简介及其理论和技术的发展现状

自旋传输矩实际上是自旋运动产生的一类特殊物理现象。当电流通过纳米自旋阀 (nano-spin-valve, NSV) 结构时, 它会使两个铁磁膜的状态发生改变, 由平行组合变为反平行组合, 或者相反, 开关速度在纳秒范围, 此效应称为电流感应磁开关 (current-induced magnetic switching, CIMS)。传统的巨磁阻器件自由层磁化的翻转都是依赖外磁场, 而 CIMS 效应提供了用电流直接实现磁膜磁化方向翻转的新理论, 方便的纯电学操作方法具有极大的吸引力, 它已经成为新一代高速、高密度、低功耗非挥发磁存储器 (stt-RAM) 的理论基础, 目前已经

实现了 32M 位的 stt-RAM 样品^[3]，实用化的主要障碍是写电流还不够小。自旋传输矩引起的另一个重要效应是：当施加外磁场大于磁膜的矫顽场时，加以适当电流，纳米自旋阀的电阻会发生周期性变化，并由此产生微波振荡，频率在 1~200GHz 并具有很高的 Q 值，一般在 200~3000，此效应称为自旋传输矩振荡 (spin transfer torque oscillator, STO) 效应^[4]，它为信息技术的纳米微波源的应用奠定了理论基础。目前的主要瓶颈是：样品的振荡功率和效率都较低，不能满足实用的要求。

对于 CIMS 效应，目前主要使用两类处理方法：一类是宏自旋模型，它将自由层整体看做自旋，又称为单磁畴，其磁化强度大小不变，而方向可以任意旋转。这个模型的优点是直观，物理图像清楚，但不够精确。另一类是用微观的第一原理的微磁模拟方法，其特点是比较精确，定量性好，但此方法反而使物理图像变得模糊了，而且也并不完全与试验一致。最近提出的自旋对称系综模型考虑了单个自旋的微观性质，整体又形成一个系综，使用宏观处理方法，与微磁模拟的结果类似^[5]。图 2 给出了自旋矩模型的简单示意图。




图 2 Slonczewski 自旋传输矩模型示意图

纳米自旋阀还可以看做一个宏观的量子二能级系统，类似超导量子电路。原则上，用磁场或电流产生的自旋传输矩都可以对纳米自旋阀量子位实现调控，两个量子位之间可以通过磁膜间的交换作用实现耦合及纠缠，完成量子计算，这是一个全新的研究领域。与核磁共振量子计算方案相比，它具有更好的可扩展性。核磁共振的读出信号随量子位数的增加呈现指数式减弱，而纳米自旋阀不存在这类问题，而且其量子位在室温下是高度稳定的。纳米自旋阀宏自旋系统相对广义坐标方位角形成对称的双势阱，S 或 -S 态的垒可以达到 1~2eV，态在阱中的驻留时间可以达 10 年以上。两个态由于量子隧穿作用彼此关联，能

级分裂为对称态和反对称态, 能级间隔(带隙)也可以达到零点几电子伏, 它有希望在室温下正常工作, 而超导量子位需要 1K 以下的温度才能正常工作。实际上, 国外研究者已经在 2001 年提出了用宏自旋构建磁量子位的概念^[6]。图 3 简单给出了对称态和反对称态的形成过程。




图 3 宏自旋的 S 态和 -S 态组成对称和反对称态 ($|0>$ 为对称态, $|1>$ 为反对称态)

3. CIMS 和 STO 效应的物理解释

从物理上理解 CIMS 效应, 可以认为在自由磁膜的两个边界, 自旋流不等, 结果造成自由层内自旋的集聚或减少, 类似自旋泵或自旋漏。对于自旋泵, 由于自由层内磁化已经饱和, 磁化矢量保持不变; 对于自旋漏的情况, 它与 Gilbert 阻尼平衡, 当它超过最大阻尼时, 使自由层内磁化强度不断减少, 最终导致自由层磁化方向的翻转, 即发生 CIMS 效应。

对于 STO 效应的处理, 有磁化矢量进动模式和 CIMS 开关模式。单纯的进动并不改变磁化矢量的大小, 即不引起磁电阻的变化, 结果不会发生微波振荡。只有当发生横向自旋分量的注入, 在自由层内发生磁化矢量 z 分量的宏观周期性变化, 才会发生微波振荡。CIMS 开关模式是指 STO 效应引起自旋阀的两个磁膜的磁化方向交替翻转, 从而产生微波振荡。

4. 自旋传输矩问题的困难所在

纳米磁多层宏自旋系统属于内含个体数目极大的多体问题, 用量子力学方法处理具有很大难度。当有电流参与时, 系统本身又是非平衡系统, 能量不守恒, 这就更增加了难度。对于实际应用来说, 还需要解决开关电流过大、微波振荡功率小、量子态的耦合、纠缠及退相干问题。

参 考 文 献

- [1] Slonczewski J C .Current-driven excitation of magnetic multilayers .J .Magn .Magn .Mater . , 1996 ,159(1—2) :1—7 .
- [2] Berger L .Emission of spin waves by a magnetic multilayer traversed by a current .Phys . Rev .B ,1996 ,54(13) :9353—9358 .
- [3] Katine J A ,Fullerton E E .Device implications of spin-transfer torque .J .Magn .Magn . Mater . ,2008 ,320(7) :1217—1226 .
- [4] Devolder T ,Mefteh A ,Ito K ,et al .Spin transfer oscillators emitting microwave in zero applied magnetic field .J .Appl .Phys . ,2007 ,101(6) :1—5 .
- [5] Ren M ,Hu J ,Zhang L ,et al .Symmetry ensemble theory of spin wave emitting effect driven by current in nanoscale magnetic multilayer .Chinese Physics B ,2009 ,18(5) :2006—2011 .
- [6] Tejada J ,Chudnovsky E M ,et al .Magnetic qubits as hardware for quantum computers .Nanotechnology ,2001 ,12(2) :181—186 .

撰稿人：陈培毅
清华大学微电子学研究所

无缺陷硅单晶

Defect-free Single Crystal Silicon

1810 年, 瑞典的 Berzelius 将石英砂、碳和铁加热, 得到一种材料, 称为硅 (silicon), 从此开始了人类对硅材料的认识和应用, 而真正使得硅材料广为人知, 还是由于 20 世纪 50 年代硅单晶材料在微电子上成功地广泛应用^[1,2]。

目前, 高纯、高完整的 300mm 直径的直拉硅单晶是极大规模集成电路的基础材料。随着集成电路技术的发展, “纳米”线宽时代已经来临, 到 2015 年, 集成电路的特征线宽将达到 22nm。随着集成电路线宽的减小, 硅单晶的小尺寸微缺陷问题变得非常突出, 对集成电路构成了致命的影响。事实上, 当单个缺陷的尺寸达到最小特征线宽的约 1/3 时, 就将导致器件的失效。因此, 如何理解、控制和消除直拉硅单晶中纳米级微缺陷, 生长和制备无缺陷硅单晶成为一个重要的挑战^[3]。

如果硅单晶中仅仅存在平衡浓度的本征点缺陷(空位和自间隙硅原子), 没有存在杂质点缺陷及其他缺陷, 就称为“无缺陷硅单晶”。实际上, 除杂质外, 硅单晶中的缺陷主要是其本征缺陷自间隙硅原子或空位的过饱和造成。因此, 要制备和生长无缺陷硅单晶, 首先要控制其空位和自间隙硅原子点缺陷的浓度、分布、扩散和聚集, 显然, 这也是此问题的关键困难之处。进一步地, 到目前为止, 由于点缺陷尺寸太小, 在原子尺寸左右, 尚没有有效的科学仪器能够直接探测或测量其存在、浓度及分布。

因此, 人们试图建立各种理论模型来描述硅单晶中点缺陷的性质和行为, 并用相关辅助实验来验证。其中, Voronkov 理论是较为成功的一个模型^[4,5]。Voronkov 认为, 在硅熔点时, 空位和自间隙硅原子的浓度是相当的, 如果在晶体生长时的固液界面上使得自间隙硅原子和空位处于平衡状态, 在硅晶体内部没有过饱和的自间隙硅原子和空位, 则有可能生长无缺陷完美硅单晶。当晶体离开固液界面, 温度下降时, 两者快速复合, 形成和轴向温度梯度 G 成正比的浓度梯度, 因此, 导致点缺陷从界面到晶体的扩散通量, 叠加在由于晶体提升而引起的和晶体生长速度 V 相关的点缺陷对流通量上, 此时, 点缺陷主要取决于晶体的拉速 V (即晶体生长速度) 和沿晶体生长方向在固液界面处的热梯度 G 的比值 V/G 。在较大 V/G 时, 晶体中存在大量过饱和的空位; 当 V/G 较小时, 晶体中则存在大量过饱和的自间隙硅原子。也就是说, 低拉速时, 扩散速度快的自间隙硅原子呈过饱和状态, 高拉速生长晶体时, 高温溶解度大的空位是多

余的。在这之间,存在一个临界值为

$$R=V/G(r)=1.34\times 10^{-3}\text{ cm}^2/\text{K}\cdot\text{min}$$

因此,如果晶体生长时,保持 R 为上述常数,就有可能生长空位、自间隙硅原子浓度相同的无缺陷硅晶体。

事实上,即使上述理论条件成立,在实际晶体生长时,也很难制备无缺陷硅晶体。首先, G 的精确测量存在困难;其次,在高温时,硅晶体的饱和点缺陷浓度高,随着晶体生长完成后,温度下降,点缺陷的饱和浓度降低,点缺陷处于过饱和状态,而两种点缺陷的扩散系数不同,使得晶体中残留的两种点缺陷浓度会不同,高浓度的一种点缺陷(一般是空位)会聚积造成新的缺陷。

无缺陷硅单晶晶体生长理论和技术的建立,不仅能够满足今后超大规模集成电路用硅晶体材料的需求,同时,对晶体生长理论也是一个重要的贡献,意义重大,将会一直吸引着人们不断地研究。

参 考 文 献

- [1] 杨德仁.半导体硅材料//王占国,陈立泉,屠海令.中国材料工程大典:信息功能材料工程.北京:化学工业出版社,2006.
- [2] 阙端麟,陈修治.硅材料科学与技术.杭州:浙江大学出版社,2001.
- [3] Chen J H, Yang D R, Que D L. Monocrystalline silicon used for integrated circuits: Still on the way. *Frontiers of Materials Science in China*, 2008, 2: 335—344.
- [4] Voronkov V V, Falster R. Vacancy and self-interstitial concentration incorporated into growing silicon crystals. *J. Appl. Phys.*, 1999, 86: 5975—5979.
- [5] Falster R, Voronkov V V, Quast F. On the properties of the intrinsic point defects in silicon: A perspective from crystal growth and wafer processing. *Phys. Stat. Sol.*, 2000, 222: 219—223.

撰稿人: 杨德仁

浙江大学硅材料国家重点实验室

硅基电泵激光

Electrically Pumped Silicon-based Laser

1991年, Canham 通过电化学腐蚀技术^[1]在硅片上形成了多孔结构, 并在室温下观察到了光致发光(如图 1 所示)。室温下, 其量子效率可以达到 10% 以上, 从而引起了研究硅基发光的热潮, 人们期待有朝一日能够实现硅基电泵激光的突破。

众所周知, 建立在硅材料基础之上的微电子对人类社会的进步发挥了巨大的作用, 是信息产业的基本载体。但是, 随着时代的发展, 信息数据的计算、传输、储存将海量增加, 因此, 现有的微电子技术特征线宽不断降低的同时, 将遭遇特征线宽物理极限、高速运算所需解决的功耗和散热等问题, 制约着微电子的持续发展, 难以满足今后信息化社会越来越高的要求。

因此, 现有成熟的、相对低成本和可以大批量制备器件的微电子技术可以与制备高速、高频器件的光电子技术结合起来, 实现在硅集成电路工艺基础上的光电子技术(硅基光电集成)^[2], 这就成为信息产业发展的重要方向之一。

经过三十多年的努力, 硅基光电子集成的光传输、光调制、光放大和光探测等技术已经基本实现, 但是, 硅基光电子集成的光源——硅基电泵激光依然没有解决, 成为实现硅基光电子集成的关键瓶颈。

硅基电泵激光是指利用与现有硅集成电路工艺兼容的技术, 在微电子的芯片上, 室温下制备出电泵控制的一定波长的激光。硅晶体材料是一种间接带隙半导体材料, 在导带的电子向价带跃迁时, 动量需要改变, 因此, 辐射复合的发光需要声子的参与以满足动量守恒条件, 其寿命大约在毫秒数量级, 明显长于一些非辐射跃迁过程的微秒和纳秒级的复合时间。所以, 辐射复合发光的概率比非辐射复合的概率小好几个数量级。也就是说, 当电子向价带跃迁时, 多余的能量变成声子发出, 而不是变成光子。所以, 硅材料本身是很难发光的, 其理论发光效率仅在 10^{-5} , 可以说几乎不发光。因此, 实现硅基电泵激光的最




图1 不同时间阳极氧化的多孔硅室温下的光致发光 (PL 强度随波长变化)^[1]

大科学难点在于：如何在微电子工艺兼容的情况下，提高硅基光电子材料和器件辐射复合发光效率，抑制非辐射复合，从而实现室温电泵激光。

为实现硅基电泵激光，研究者探索了多种途径，其中，硅基量子点效应、硅基稀有元素掺杂、硅基晶体缺陷和硅基化合物是最主要的方法。①硅基量子点效应^[1,3]。包括多孔硅、纳米硅、纳米硅镶嵌 SiO_2 (Si_3N_4)、硅基量子阱和超晶格结构等，通过将激子的运动限制在小于电子和空穴的德布罗意波长的纳米区域内，使得载流子遇到缺陷的概率降低，非辐射复合下降，相应的辐射性复合的概率增加。同时，间接带隙可能变成发光效率高的直接带隙。②硅基稀有元素掺杂^[4]。包括铒(Er)及其化合物的掺杂，通过能量转移，实现硅基稀土的高效发光。③硅基晶体缺陷发光^[5]。包括硅晶体位错发光、氧沉淀发光及硅中嵌入直接带隙化合物沉淀(如 FeSi_2)，通过硅晶体中位错等缺陷在硅的禁带中引入可能的深能级，使载流子的复合避开声子的作用，或者降低载流子的非辐射复合，增加其和发光相关的辐射复合，以达到提高发光效率的目的。④硅基化合物发光^[6]。包括硅基 InP、GaAs、CdS、InGaAsP 等，通过键合等技术将发光效率高的直接带隙的化合物半导体集成在芯片上，以及硅基锗量子点的发光。

但是，上述技术和原理都有不同方面的弱点，并不能真正应用在硅基光电子集成上。因此，硅基电泵激光依然是需要人们挑战的难题。

参 考 文 献

- [1] Canham L T. Silicon quantum wire array fabrication by electrochemical and chemical dissolution of wafers. *Applied Physics Letters*, 1990, 57: 1046—1048.
- [2] Hirschman K D, Tsybeskov L. Silicon-based visible light-emitting devices integrated into microelectronic circuits. *Nature*, 1996, 384: 338—341.
- [3] Walson W L, Szajowski P F, Brus L E. Quantum confinement in size-selected, surface-oxidized silicon nanocrystals. *Science*, 1993, 262: 1242—1244.
- [4] Hak-Seung H. Coefficient determination related to optical gain in erbium-doped silicon-rich silicon oxide waveguide amplifier. *Applied Physics Letters*, 2002, 81: 3720—3722.
- [5] Ng W L, Lourenco M A, Gwillam R M. An efficient room-temperature silicon-based light-emitting diode. *Nature*, 2001, 410: 192—194.
- [6] Fang W, et al. Electrically pumped hybrid AlGaInAs-silicon evanescent laser. *Optics Express*, 2006, 14: 9203—9210.

撰稿人：杨德仁

浙江大学硅材料国家重点实验室

固态太赫兹源

Solid State THz Sources

太赫兹电磁波科学是 21 世纪重要的发展科学前沿，但其应用的发展受到太赫兹固态源的制约，成为科学家们要解决的难题之一。在微波毫米波到光子的电磁波谱之间，固态源的功率性能存在一个所谓“太赫兹空隙”。

传统的电子学固态源是基于半导体器件的振荡与放大。由于半导体器件中载流子的渡越时间和电抗寄生效应，固态源的输出功率随着频率升高，存在规律的功率衰减和效率降低，从微波毫米波进入太赫兹频段，输出功率降至毫瓦量级。而传统的固态光子源，即固态激光器，以半导体激光器为例，在 1eV 量级的带隙之间的电子激射跃迁，可在红外频段产生百瓦级脉冲功率。而要工作在太赫兹频段，相当于工作在与晶体振动的声子类似的能级，约毫电子伏特量级，要降至超低温状态，如图 1 所示^[1]。目前，科学家们采用两种方法不断探索在太赫兹固态源领域填补太赫兹空隙。电子学方法的上变频或光学方法的下变频(光混频)，这两种方法的转换效率很低，输出功率仅在毫瓦和微瓦量级。如何提高固态太赫兹波功率源的输出功率和效率是科学家们不断研究探索的重要方向。




图 1 固态源的功率性能^[1]

太赫兹波电子学固态源的需求来自于地基与天基的太赫兹波超外差接收机和雷达成像用固态源，要求体积小、重量轻、可靠性高、可调谐宽带的太赫兹

固态本振源。由于半导体器件在太赫兹频段直接振荡输出功率太小,20 世纪 90 年代引入 GaAs 基平面肖特基变容二极管作倍频器件,利用其非线性特征,由毫米波振荡源泵浦,在倍频电路输出端获得高次谐波分量,得到进入 300GHz 以上的功率源^[2](330GHz, 4mW 输出)。GaAs/AlGaAs 异质结变容二极管具有奇对称 $I-V$ 特性和偶对称 $C-V$ 特性,利用这种非线性特征形成的倍频电路仅产生奇数谐波分量,可提高转换效率,在 230GHz,转换效率达 22%^[3]。但是,由于其寄生参量较大,向太赫兹频率发展遇到阻碍。减少寄生参量,特别是变容二极管的结电容和衬底串联电阻,是提高器件截止频率的关键。基于 GaAs 基平面肖特基变容二极管和平衡电路的结构,采用微机械加工工艺将 GaAs 厚度减至 3 μm ,形成了将输入输出阻抗匹配、多个平面二极管、偏置隔直电容集成在一起的 GaAs 单片薄膜二极管与亚毫米波集成电路。单个 2 次、3 次倍频电路频率进入




图 2 1.9THz 平衡电路的 3 倍频芯片、波导结构(上图)及芯片阳极的局部放大图(下图)^[7]

入 1~2.5THz 频段。在 1.2THz,室温下,输出功率为 80 μW ,峰值效率为 0.9%,120K 低温输出功率为 195 μW ^[4]。120K 低温下,2.7THz 输出功率为 0.1 μW ,峰值效率为 0.002%^[5]。采用多个倍频电路级联形成的倍频链可以优化第一级功率承受力的设计、末级优化频率特性的设计,形成宽带可调谐的太赫兹功率源:1.4~1.6THz,120K,15 μW ,1.5THz 峰值功率为 40 μW ^[6];1.7~1.9THz,120K,1.5 μW ,1.746THz 峰值功率为 15 μW ^[7];1.55~1.75THz,120K,4 μW ,1.665THz 峰值功率为 100 μW ^[8]。GaAs 单片薄膜二极管与亚毫米集成电路的结构如图 2 所示。

随着半导体器件特征尺寸进入纳米尺度,各类器件的基频振荡已进入 0.3THz 量级。35nm InP HEMT 集成电路:338GHz,10mW 功率放大,330GHz 功率振荡输出 0.25mW。GaInAs/AlAs RTD 基频 831GHz,输出 1 μW ,45nm CMOS,410GHz 振荡器,输出功率 20nW。

太赫兹电子固态源未来发展要解决的科学难题如下:

(1) 发展 2~3THz 更高频率的太赫兹源,该频段对天体物理学很重要。要达到 2~3THz 频段,将要攻克亚毫米波集成电路制造的极限尺度。同时,在未来 2~3THz 空间探测实现阵列构成,将需要功率合成的方法来实现阵列接收机本振功率提高的目的。

(2) 探索新的材料提高肖特基变容二极管的功率承受能力。随着宽禁带半导体新材料的发展,毫米波 GaN MMIC 功放的泵浦功率可以在 W 波段达到几瓦,将会导致 GaAs 基变容二极管反向击穿。发展 GaN 基变容二极管,以提高击穿电压和输出功率。

(3) 发展太赫兹晶体管。理论预计 InP HBT 的发射极宽度达到 32nm,收集极宽度达到 90nm,基区厚度为 180Å 时,其 f_T 和 f_{max} 可达 1.4THz 和 2.8THz,晶体管放大器的中心频率将达 1.4THz,1.0THz 的噪声为 5.0dB。

参 考 文 献

- [1] WooLard D L, Brown E R, Pepper M, et al. Terahertz frequency sensing and imaging: A time of reckoning future applications? Proceedings of the IEEE, 2005, 93(10): 1722—1743.
- [2] Frickson N R, Smith R P, Mastin S C, et al. High efficiency MMIC frequency triplers for millimeter and submillimeter wavelengths. IEEE MTT-S Digest, 2000, 2: 1003—1006.
- [3] Krach M, Freyer J, Claassen M. An integrated ASV frequency tripler for millimeter-wave applications. Proc. 33rd Eur. Microwave Conf., 2003, 3: 1279—1281.
- [4] Maestrini A, Braston J, Pakala D, et al. Performance of a 1.2THz frequency tripler using a GaAs frameless membrane monolithic circuit. IEEE MTT-S Digest, 2001, 3: 1657—1660.
- [5] Maiwald F, Martin S, Bruston J, et al. 2.7THz waveguide tripler using monolithic membrane diodes. IEEE MTT-S Digest, 2001, 3: 1637—1640.
- [6] Chattopadhyay C, Schlecht E, Ward J, et al. An all solid-state broadband frequency multiplier chain at 1500GHz. IEEE Transactions on Microwave and Techniques, 2004, 52(5): 1538—1547.
- [7] Maestrini A, Ward J, Gill J, et al. A 1.7 to 1.9THz local oscillator source. IEEE Microw. Compon. Lett., 2004, 14(6): 253—255.
- [8] Ward J S, Chattopadhyay G, Gill J, et al. Tunable broadband frequency-multiplied terahertz sources. IEEE IRMMW-THz Digest, 2008: 1—3.

撰稿人: 赵正平
中国电子科技集团公司

高效率硅量子点激光器

High Efficiency Si-Quantum Dot Laser

作为未来硅基光电子集成电路中的光源,高效率硅基激光器的探索是其中的一个热点课题,因为它是最终能否实现全硅光电子集成的关键,但同时也是目前困扰科学家的一个棘手难题。自从 1990 年英国科学家 Canham 首次发现纳米多孔硅的可见发光以来,人们一直谋求各种硅基纳米材料的高效率发光,并在此基础上开始了硅基光电子集成电路的艰辛探索。因为一旦能够借助于成熟的硅微电子工艺实现全硅光电子集成,必将会对未来的光通信技术和计算机技术产生革命性的影响,而要真正实现这一目标,首当其冲的是要制作出高效率的硅基激光器。

早在 10 年前,人们就着手硅基纳米材料与结构受激光发射的研究。1999 年, Zhao 等^[1]采用激光烧蚀方法制备了掺铒的纳米晶硅(nc-Si:Er),并由此制作了硅基光波导器件,实验清楚地观测到了 20K 和 300K 下 $1.54\mu\text{m}$ 受激光发射的特性。2000 年, Pavesi 等^[2]采用硅离子注入加后退火处理的方法,在 SiO_2 层和高纯石英衬底中获得了晶粒尺寸约为 3nm 的镶嵌硅纳米晶粒,并在光激发条件下观测到了很高的光学增益。2004 年, Chen 等^[3]将掺硼的 SiO_2 纳米微粒向 n-Si 表面进行扩散形成了硅基纳米 P-N 结,也同样观测到了硅的受激光发射现象,如图 1 所示。2005 年,美国英特尔公司的研究人员在硅单晶芯片上,利用紧密的 SOI 波导微腔结构实现了受激拉曼散射,并研制成功了全硅连续波拉曼激光器^[4]。2006 年,美国英特尔公司和加州大学圣塔芭芭拉分校的研究小组研制成功了世界上首例混合型 Si-InP 激光器^[5],该激光器是利用 III-V 族的 InP 材料产生光,而利用硅波导结构形成谐振腔以实现光的激射输出。




图 1 硅基纳米晶粒 P-N 结的受激光发射特性

上述实验结果均证实了采用硅基纳米结构实现受激光发射的可能性。然而到目前为止,真正基于硅纳米晶粒或量子点的三维量子限制效应,乃至准直接跃迁性质的高效率激光器尚没有问世。那么,问题的根本原因在哪里呢?追根溯源,大体有以下两个方面:①难以获得具有准直接带隙的硅基低维材料,因此,不能使硅摆脱其固有的间接跃迁性质。尽管人们试图采用 Ge/Si 短周期超晶格或 β -FeSi₂ 材料获得准直接带隙结构,但终因难度太大而不得不放弃。②难以实现基于硅纳米晶粒或量子点的三维量子受限作用而实现的受激光发射。因为目前采用各种方法制备的硅纳米晶粒或量子点及 SiO₂/Si 超晶格都绕不开 nc-Si/SiO₂ 界面这个问题。一方面,在许多情形下是与氧相关的缺陷在支配着其发光特性;另一方面,界面处所存在的非辐射复合中心也直接制约着发光效率的提高。

据此我们认为,为了真正能够实现基于硅基纳米晶粒或量子点的三维量子限制效应而实现其受激光发射,如何采用优化的自组织生长工艺制备出高密度($10^{12} \sim 10^{13} / \text{cm}^2$)、小尺寸(2~3nm)、分布有序且具有高质量界面的硅基纳米结构或阵列是必须要逾越的一个障碍。因为只有小尺寸晶粒才能产生显著的量子约束效应,高密度晶粒易于提高单位面积上量子点的发光效率,有序排列的晶粒有利用实现载流子的隧穿输运,而高质界面则可以减少非辐射复合中心的数量。倘若能够制备出满足上述要求的硅基纳米结构,并在电注入或光泵浦条件下实现粒子数反转,高效率硅基激光器最终得以实现的那一天就不会离我们太远了。

参 考 文 献

- [1] Zhao X W, Komuro S, Isshiki H, et al. Fabrication and stimulated emission of Er-doped nanocrystalline Si waveguide formed on Si substrate by laser ablation. *Applied Physics Letters*, 1999, 74: 120.
- [2] Pavesi L, Hegro L D, Mzzoleni C, et al. Optical gain in silicon nanocrystals. *Nature*, 2000, 408: 440.
- [3] Chen M J, Yen J L, Li J Y, et al. Stimulated emission in a nanostructured silicon p-n junction diode using current injection. *Applied Physics Letters*, 2004, 84: 2163.
- [4] Rong H, Jones R, Liu A. A continuous-wave Raman silicon laser. *Nature*, 2005, 433: 725.
- [5] Bowers J E, Fang A W, Park H. Hybrid III-V and IV lasers and amplifiers. *European Conference on Optical Communications*, 2007.

撰稿人: 赵新为¹ 彭英才²

1 日本东京理科大学物理系

2 河北大学电子信息工程学院

稀磁半导体——内禀磁性的物理机理？

Diluted Magnetic Semiconductors——Where the Ferromagnetism comes from?

建立在半导体材料基础上的半导体晶体管和集成电路是利用电子的电荷自由度来进行海量信息处理和信息传输，信息技术中另一个不可缺少的方面，即信息存储又是建立在磁性金属多层膜结构中利用自旋自由度来进行信息的写入和读取。而同时利用电子的电荷和自旋属性及在此基础上研制新一代多功能电子器件，是近十几年来自旋电子学兴起与发展的核心目标。由于常见的半导体材料都不具有磁性，而磁性材料如 Fe、Co、Ni 等又不具有半导体的性质，因此，人们通过在半导体材料中掺入磁性离子来获得磁性。例如，在 GaAs、GaN、InAs、ZnO 等化合物半导体中掺杂引入过渡金属等磁性离子，因为磁性离子与半导体中载流子的自旋交换作用会导致这类材料的磁性。由磁性离子部分代替非磁性半导体化合物中阳离子所形成的一类新型半导体材料，称之为“稀磁半导体”（diluted magnetic semiconductors, DMS）。稀磁半导体材料同时利用电子的电荷属性和自旋属性，具有优异的磁、磁光、磁电性能。1992 年，日本科学家 Ohno 等利用低温分子束外延技术，首次成功制备了具有铁磁性的 InMnAs 材料^[1]。1996 年，Ohno 等又成功制备具有铁磁性的 GaMnAs。人们已经通过各种理论计算和实验研究对 III-V 族稀磁半导体的铁磁性起源进行了广泛的讨论，提出了几种物理模型来解释 III-V 族稀磁半导体的铁磁性，包括平均场理论、Ruderman-Kittel-Kasuya-Yosida (RKKY) 机制、双交换机制、磁极化子模型等。波兰科学家 Dietl 与 Ohno 合作对 GaMnAs 的磁性起源进行了研究^[2]。由于掺入的 +2 价磁性离子部分替代 III-V 族半导体中的 III 族阳离子同时又成为受主杂质，能提供高载流子浓度的空穴，磁性离子间以空穴作为媒介的交换相互作用会使得材料在较高温度下具有铁磁性^[2]。这一认识普遍为大家接受，并且也能解释 GaMnAs 中的大部分光、电、磁性质。但是，目前对稀磁半导体磁性的物理起源和本质还存在很大争议，亟待深入研究的挑战性物理问题主要有下面几点：

(1) 如上所述，磁性离子间以载流子为交换媒介的铁磁相互作用是稀磁半导体产生磁性的根本，但目前发现有些半导体材料即使在没有磁性离子掺杂时也会表现出明显的磁性，这主要包括一些有机纳米磁性材料及氧化物（如 ZnO）^[3]。因此，引发的問題就是稀磁半导体一定要有磁性掺杂离子吗？没有磁

性掺杂离子的半导体中产生的磁性是否具有内禀性?其物理机制是什么?

(2) 稀磁半导体的磁性与载流子和磁离子的耦合相互作用紧密相关。有两条路径可能带来载流子引起的铁磁相互作用:一是磁性 Mn 离子局域磁矩和来自价带载流子之间的相互作用,二是和来自于磁性杂质带载流子间的相互作用。尽管大家普遍认可标准的稀磁半导体 $(Ga, Mn)As$ 中磁性的起源是由 $GaAs$ 价带空穴作为媒介的交换相互作用引起的,但近年来以其磁离子杂质态中载流子为媒介的交换相互作用研究备受人们关注,并引起很大争议。最近有较多的实验与理论研究越来越支持空穴来自磁性杂质态^[4]。那么,对于这样一个大家公认的标准稀磁半导体材料,与磁离子耦合相互作用的载流子到底来自哪里?究竟是宿主的价带还是杂质带?

(3) 几乎所有金属性的 $(Ga, Mn)As$ 材料在趋于 $0K$ 时(实际温度小于 $10K$)都会有电阻随温度下降而上升约 $30\% \sim 40\%$ 的奇异现象(类似于绝缘体的电阻特性),尽管目前对此的物理机制解释为载流子的局域化行为^[5],但仍需大量理论与实验研究工作。更为引起物理学家关注的一个课题是:金属性 $(Ga, Mn)As$ 材料表现出的铁磁性虽然已经可以理解,但同时绝缘性的 $(Ga, Mn)As$ 材料也会表现出铁磁性,这一物理问题的研究目前还很匮乏。

总之,稀磁半导体材料为固态信息领域的发展带来了前所未有的契机和广阔的应用前景,同时也为我们提供了凝聚态基础物理研究的新方向和新的科学难题,推动我们进一步加深对物质的认知,从而揭示更深刻的物理规律。

参 考 文 献

- [1] Ohno H, Munekata H, Penney T, et al. Magnetotransport properties of p-type $(In, Mn)As$ diluted magnetic III-V semiconductors. *Phys. Rev. Lett.*, 1992, 68(17): 2664—2667.
- [2] Dietl T, Ohno H, Matsukura F, et al. Zener model description of ferromagnetism in Zinc-Blende magnetic semiconductors. *Science*, 2000, 287(5455): 1019—1022.
- [3] Peng H W, Xiang H J, Wei S H, et al. Origin and enhancement of hole-induced ferromagnetism in first-row d0 semiconductors. *Phys. Rev. Lett.*, 2009, 102(1): 017201—017204.
- [4] Burch K S, Shrekenhamer D B, Singley E J, et al. Impurity band conduction in a high temperature ferromagnetic semiconductor. *Phys. Rev. Lett.*, 2006, 97(8): 087208—087211.
- [5] Dietl T. Interplay between carrier localization and magnetism in diluted magnetic and ferromagnetic semiconductors. *J. Phys. Soc. Jpn.*, 2008, 77(3): 031005—031015.

撰稿人: 张新惠
中国科学院半导体研究所

IV-VI 族半导体光电应用的瓶颈

The Bottlenecks of IV-VI Group Semiconductors for Optoelectronic Applications

以 PbS、PbSe 和 PbTe 等为代表的 IV-VI 族窄带隙半导体具有一系列独特的物理特性：它们都是直接带隙半导体，带隙位于第一布里渊区的 L 点，能带结构高度对称，介电常数高，激子的玻尔半径大，而且简并重空穴带缺失使它们具有比 II-VI、III-V 族半导体低一个数量级以上的俄歇非辐射复合系数等。IV-VI 族窄带隙半导体曾在历史上发挥过重要作用，如 20 世纪 40 年代的第二次世界大战中，PbS、PbSe 红外探测器就被应用于战斗机上；到了 70 年代，美国在“导弹探测预警卫星”系统的第一代“国防支援计划”卫星上就使用了波长为 $2.7\mu\text{m}$ 、带宽约为 $0.1\mu\text{m}$ 的 PbS 探测器阵列，使用这种接近大气吸收带中心的窄光谱波段探测技术可有效抑制地球和大气背景的辐射干扰，对固体火箭发动机、导弹等尾喷焰可做出灵敏响应，起到跟踪和预警的作用；PbSe、PbTe 中，红外激光器在环境检测、医学诊断等领域的应用也已经有十多年的历史^[1]，由于其价格相对低廉，颇具竞争力。至今，IV-VI 族窄带隙半导体及其量子结构仍然是一类重要的红外光电子器件材料，在红外焦平面^[2]、红外发光器件^[3,4]等领域发挥着作用。但是，这类红外光电子器件的性能与理论预测还有比较大的差距，至今 IV-VI 族半导体红外焦平面探测器还只能在液氮 (77K) 温度下工作^[1]，电注入中红外激光器的最高工作温度也只有 223K，输出功率较低，约为 1mW ^[3,4]，因此，其应用受到较大限制。

中红外激光器和探测器的工作温度低、性能不够理想的主要原因之一是 PbS、PbSe 和 PbTe 等的热导率低，加上器件又工作中红外波段，光子能量与声子能量接近，声子散射对电子输运、光学跃迁影响显著，导致器件热噪声大。因此，如何调控该系列半导体中的声子行为是人们多年来关注的一个重要问题。

最新的研究还发现，PbS、PbSe、PbTe 等半导体量子点^[5]和体材料^[6]中具有高效的光生载流子倍增效应。当它们受到能量大于这些半导体带隙的 2.7 倍以上的一个光子照射时，会产生 2 个 (或以上) 电子-空穴对 (称为 carrier multiplication)。这一新的量子现象被认为有可能大大提高太阳电池效率 ($\geq 100\%$) 和红外探测器的灵敏度^[7]，因此，具有重大的科学意义和技术价值，受到了国际著名研究机构的关注。PbS、PbSe、PbTe 等半导体量子点的 CM 量子现象成为了国际研究的一个热点^[5~8]。PbS、PbSe、PbTe 等胶质量子点中，

光生载流子增殖效应是基于碰撞电离 (impact ionization) 的俄歇过程, 即一个光子首先激发一个动能大于半导体带隙的电子-空穴对, 接着是这对具有较大动能的光生载流子通过碰撞电离过程激发出另一对 (或多对) 电子-空穴, 碰撞电离过程还需与电子-声子散射的能量弛豫过程进行竞争, 在窄带隙半导体量子点中, 电子-声子散射能量弛豫过程受到抑制, 碰撞电离过程被大大增强, 因为量子点中的电子受到三维限制, 显著增强了电子-空穴的库仑作用, 而且量子点中的电子能级高度分立又大大降低了电子-声子散射作用, 使热电子的弛豫速率降低, 碰撞电离的俄歇过程得到加强。

但是, 胶质量子点的光生载流子增殖效应尚未在太阳电池和红外探测器中实现真正应用, 因为还有一些重要的科学问题没有解决: ①目前, 由化学合成的 PbS、PbSe、PbTe 等量子点是胶质悬浮体, 量子点的表面受到电学绝缘的配位体壳层物质的包裹^[9], 导电性差, 因此, 光生载流子从量子点中有效提取还存在困难; ②化学合成得到胶质量子点和表面剂本身往往具有较高密度的缺陷 (电荷陷阱)。上述问题使 IV-VI 族半导体胶质量子点中光生载流子有效电荷转移困难, 至今还未解决, 是一个正在研究中的重要课题。

参 考 文 献

- [1] Roller C, McCann P J, et al. Simultaneous NO and CO₂ measurement in human breath with a single IV-VI mid-infrared laser. *Opt. Lett.*, 2002, 27: 107.
- [2] Zogg H, Alchalabi K, Zimin D, et al. Two-dimensional monolithic lead chalcogenide infrared sensor arrays on silicon read-out chips and noise mechanisms. *IEEE Transactions on Electron Devices*, 2003, 50: 209.
- [3] Zhao F, Wu H Z, et al. Continuous wave optically pumped lead-salt mid-infrared quantum-well vertical-cavity surface-emitting lasers. *Applied Physics Letters*, 2003, 83: 5133.
- [4] Feit Z, McDonald M, et al. Low threshold PbEuSeTe/PbTe separate confinement buried heterostructure diode lasers. *Applied Physics Letters*, 1996, 68: 738.
- [5] Schaller R D, Agranovich V M, et al. High-efficiency carrier multiplication through direct photogeneration of multi-excitons via virtual single-exciton states. *Nature Physics*, 2005, 1(3): 189.
- [6] Pijpers J. Assessment of carrier-multiplication efficiency in bulk PbSe and PbS. *Nature Physics*, 2009, 5: 811.
- [7] Schaller R. High efficiency carrier multiplication in PbSe nanocrystals: Implications for solar energy conversion. *Phys. Rev. Lett.*, 2004, 92: 186601.

撰稿人: 吴惠楨

浙江大学物理系

CMOS 工艺特征尺寸的极限是什么？

What is the Feature Size Limit of CMOS Technology ?

1958 年，美国德州仪器公司的 Kilby 提出了集成电路的构想，主张把有源器件和无源器件同时集成到一个半导体衬底上，正是这个构想，以及一块仅由若干凌乱的电线和 5 个电子元件组成的集成电路使他获得了诺贝尔奖。然而，恐怕令他也难以想象的是，在 21 世纪的今天，单芯片上集成的晶体管数目已经超过 10 亿，晶体管的特征尺寸已达到纳米量级。英特尔公司创始人之一 Moore 提出的摩尔定律解释了这一切：单芯片上可以容纳的晶体管数目大约每隔 18 个月翻一番^[1]。几十年来，强大的市场需求与制造业技术的进步推动半导体行业不断向前发展。CMOS 工艺因具有功耗低、可集成度高等优点，在 20 世纪 70 年代末期逐步成为集成电路制造的主流工艺，其特征尺寸已从 20 世纪 50 年代初期的约 $125\mu\text{m}$ 进化到现在 28nm 以下，并且还在向更小的尺寸发展，这就引起了一个热点话题，即 CMOS 工艺特征尺寸的极限究竟是什么？为了理解这个问题，首先要对 CMOS 工艺有一个基本的了解。

CMOS 全称为互补氧化物半导体，是一种集成电路制造工艺，这种工艺能够同时在硅晶圆上制作出 PMOS 和 NMOS 晶体管，由于这两种晶体管在特性上为互补性，因此称为 CMOS 工艺(如图 1 所示)。MOS 晶体管可认为是一个开关，它有两个工作状态——导通和截止，导通时晶体管传递电流，截止时没有电流通过。PMOS 晶体管和 NMOS 晶体管的区别在于导通的条件：PMOS 晶体管在栅极电平为低时导通，在高电平时截止。而 NMOS 晶体管在栅极电平为高时导通，在低电平时截止。它们的导通条件恰好相反，这就是“互补”这个词的由来。“互补”的优点可以通过 CMOS 反相器来解释(如图 2 所示)。反相器由一个 PMOS 晶体管和一个 NMOS 晶体管组成，当输入端 In 为高电平时，PMOS 晶体管截止而 NMOS 晶体管导通，输出端 Out 为低电平。当输入端 In 为低电平时，PMOS 晶体管导通，NMOS 晶体管截止，输出端 Out 为高电平。在这两种情况下，都没有从电源到地的直接电流通路，因此，静态低功耗是 CMOS 工艺的一大优势。低功耗使得 CMOS 工艺战胜了双极型数字逻辑、PMOS 逻辑和 NMOS 逻辑，最终脱颖而出，在 20 世纪 70 年代末之后成为集成电路制造的主流工艺^[2]。

在对 CMOS 工艺及其发展历程有了初步的了解后，我们回到文章第一段中提出的问题：CMOS 工艺特征尺寸的极限是什么？这里首先要解释两个概念，




图1 CMOS工艺示意图




图2 CMOS反相器逻辑图

分别是 CMOS 工艺特征尺寸和 Scaling。通俗地讲，CMOS 工艺特征尺寸可以理解为能够实现的 MOS 晶体管的最小沟道长度。而 Scaling 可翻译为“尺寸缩放”，也就是说，MOS 晶体管的沟道长度、栅氧厚度、供电电压等工艺参数按照一定的规则缩放。在过去的几十年中，正如摩尔定律中所描述的那样，在 CMOS Scaling 理论的引导下，MOS 晶体管的特征尺寸不断缩小，芯片的集成度和性能持续增长，晶体管的成本不断下降。关注最近十几年来 CMOS 领域的发展，便可让我们对这个日新月异的行业刮目相看。在 1997 年之后，250nm 设计流程逐渐成为标准流程；1999 年前后，180nm 的设计成为主流；130nm 流程技术节点于 2001 年左右形成；2005 年前后，业界进入 65nm 设计；而 45nm 设计流程也在 2007 年付诸实施；2010 年，32nm 和 28nm 的微处理器也已逐步进入量产阶段。然而，令人们疑惑的是，CMOS 特征尺寸的缩小能否一直进行下去？如果不能，它的极限究竟是多少呢？

事实上，这是一个多少年来人们非常向往解答却又难以给出正确答案的问题。CMOS 工艺一系列成功的 Scaling 并不像我们介绍它时那么简单，它的背后隐藏着诸多挑战，这些挑战来自于物理（漏感应势垒降低效应、量子隧道穿透效应、器件特性的不一致性、短沟道效应和可制造性等）和经济（制造成本昂贵）两大方面^[3,4]。特别是 CMOS 工艺从微米级转向纳米级的时候，这些挑战逐步升级为不可逾越的障碍。在物理方面，不断增长的静态功耗和器件特性的不一致性是 CMOS Scaling 最重要的两大难题，这些问题源于 CMOS 工艺已接近量子力学和原子理论所决定的物理极限。功耗困境产生的原因包括亚阈值漏电流、漏感应势垒降低效应、量子隧道穿透等效应，这些效应会增大晶体管的漏电流，导致整个芯片的功耗急剧增加。器件特性的不一致性同样也会成为 Scaling 的噩梦。工艺参数在空间和时间上引起的偏差，以及电压和温度的变化会让芯片时序收敛变得非常困难。杂质原子数目的随机涨落与不连续的微观随机分布已经成为影响 CMOS 器件阈值电压所不容忽视的因素。光刻中的工艺邻近效应、栅线条边缘粗糙度问题都是工艺制造中非常棘手的问题，尽管光邻近校正（OPC）和分辨力增强技术（RET）都在努力减小这些效应。除此之外，一个很实际的问

题就是人们能否从如此小的 CMOS 晶体管、集成度如此高的芯片中获得利润。如果芯片的成本比它的售价还高,那么,将 CMOS Scaling 继续下去还有什么意义呢?

为解决 CMOS 工艺面临的各种困境,目前有两种主导思想:第一种是引入新材料、新工艺和研究新的器件架构来扩展 CMOS Scaling。一方面,为解决器件物理和互连技术的限制,人们开发金属栅、双栅/多栅器件、高 K 栅介质、应变沟道和高迁移率材料等技术。另一方面,在集成电路的设计与制造中,采用光电器件混合集成技术和系统芯片集成技术可以进一步提高集成电路的速度与功能(详细参见文献[3])。第二种是积极探索后硅时代的新技术,如自旋电子器件、分子电子器件、碳纳米管和纳线等,以期望有全新的替代 CMOS 工艺的技术出现^[3,5]。

根据国际半导体技术蓝图(ITRS)发布的技术预测,世界集成电路主流工艺特征尺寸将在 2020 年之后达到 10nm 以下^[6]。然而,这只是一种说法而已,谁也无法准确地预测未来。英特尔公司负责开发最尖端 CMOS 工艺技术的 Kuhn 也曾指出,半导体业界总能随着公认的工艺极限的接近找到很好的解决办法。其实,CMOS 工艺特征尺寸的极限究竟是多少并不重要,重要的是如何为这个传统的行业注入新的活力。同时,我们不能抱残守缺,一味地延续 CMOS 工艺 Scaling 的神话,努力探索可以取代 CMOS 工艺的划时代技术也是必不可少的,这一切都是为了人类生活得更好。

参 考 文 献

- [1] Moore G. Cramming more components into integrated circuits. Electronics, 1965, 38(8): 114—117.
- [2] Rabaey J M. Digital Integrated Circuits. 2nd ed. New York: Prentice Hall, 2003: 2—4.
- [3] 王占国. 硅微电子技术物理极限对策探讨. 中国科学院院刊, 2007, 22(6): 480—484.
- [4] 李志坚, 李铁夫. 浅谈后摩尔定律时期电子技术的发展. 中国集成电路, 2005, (2): 1—5.
- [5] 陈自强. 战胜 CMOS Scaling 的研究挑战半导体业发展方向. 中国集成电路, 2007, 16(1): 20—23.
- [6] Iwai H. CMOS technology after reaching the scale limit. Junction Technology, 2008: 1—2.

撰稿人: 陈书明 刘 尧

国防科学技术大学微电子与微处理器研究所

辐射环境下的单粒子效应

Single Event Effects in Radiation Environment

单粒子效应是指单个高能粒子在穿过微电子器件的灵敏区时,在其轨迹上所沉积的电荷被器件电极收集,造成存储单元存储信息翻转、电路中出现电压和电流的瞬时扰动,甚至引起器件烧毁的一种辐射效应。单粒子效应通常引发两类错误:一类称为硬错误,表现为器件的永久损伤,包括单粒子门锁(SEL)、单粒子烧毁(SEB)、单粒子栅介质击穿(SEGR)等;另一类称为软错误,表现为存储数据的随机翻转、电路节点逻辑状态的随机扰动,而器件本身没有损坏,包括单粒子翻转(SEU)、单粒子瞬态(SET)、单粒子扰动(SED)等。由于单粒子效应的复杂性及随机性,研究其产生的机理并对其进行建模和加固,以减轻它产生的危害难度较大,因而成为航天科学领域中的一项难题。

相对于单粒子硬错误而言,软错误是单粒子效应引发的主要失效模式。其中,单粒子翻转、单粒子瞬态和单粒子多位翻转(MBU)是软错误的主要来源。空间辐射环境下的单粒子效应显得尤为严重。有关资料表明,自1971年至1986年,国外发射的39颗同步卫星,由于各种原因造成的故障共1589次,其中,与单粒子效应有关的故障就有621次,占总故障的39.08%。除此之外,地面环境中的单粒子效应也在持续增加,正变得越来越严重。随着工艺尺寸的急剧缩减,大气中的“热中子”和封装材料中的 α 粒子引起的软错误率在持续增加。

第一篇预测到微电子电路将会因为地面宇宙射线而引发单粒子翻转的论文发表于1962年,13年后,Binder等第一次确认了空间环境下宇宙射线诱导的单粒子翻转^[1],随后,来自英特尔公司的学者也在地面环境下观测到了单粒子翻转的存在。70年代末,充分的证据表明,宇宙射线诱导的单粒子翻转的确是引起卫星存储子系统发生错误的重要原因。另外,除宇宙射线外,太阳质子事件及俘获在内外范·艾伦地球辐射带中的质子(如图1所示,低地轨道卫星会频繁穿过辐射带)也能够引起单粒子翻转。

20世纪80年代有少数学者开始研究单粒子瞬态。其他关于单粒子瞬态的研究出现在80年代晚期,但经常被淹没在对单粒子翻转的大量研究中。90年代晚期,人们开始重新关注单粒子瞬态,得出结论:随着集成电路器件尺寸的下降,时钟频率的增加,单粒子瞬态导致的软错误率最终将超过单粒子翻转导致的软错误率。

进入21世纪初,学者们又发现了一种新的单粒子效应,即在SRAM或者




图1 内外范·艾伦地球辐射带

DRAM 中, 粒子轰击之后电离产生的电荷在邻近节点的扩散会引起单粒子多位翻转。在掠入射的情况下, 电荷轨迹可与多个敏感区相交, 也可以引起单粒子多位翻转。

单粒子效应的研究主要围绕空间辐射环境模型、单粒子效应机理、建模和加固方法等方面展开。

空间辐射环境模型的研究对预估飞行器中器件单粒子效应的发生及危害的减轻具有重要意义。目前, 各国已广泛采用美国 NASA 发展的 AP8 及 AE8 辐射带模型, 但这两个模型的空间复杂性和精度仍有较大局限。因此, 国际标准化组织(ISO)第 14 分会正着手 AP8 及 AE8 模型的修订工作, 美国、俄罗斯、日本等均进行了各种飞行试验, 以便向新的模型提供最新观测数据^[2]。高精度的空间辐射环境模型仍然是单粒子效应的一个重要研究课题。

单粒子效应的机理问题一直都是很难完全解决的难题。几十年来, 学者们开展了大量的研究工作, 得出单粒子效应的基本物理机理是电荷收集, 而电荷收集的机理主要包括“漏斗”辅助的漂移、扩散和双极效应。然而, 对于不同器件、电路及不同的单粒子失效模式, 三种收集机理的贡献又都不尽相同, 如 PMOS 晶体管的双极效应相对于 NMOS 晶体管而言就更加严重。同时, 随着工艺的不断缩减, 离子径迹的横向分布大于器件的特征尺寸, 电荷收集的敏感区域增多, 各敏感区的有效收集因子又都各不相同, 使得电荷收集机制更加复杂。另外, 新工艺、新结构和新材料的不断引入, 又出现了一些新难题。例如, 多层金属布线中的高 Z 金属会和入射粒子发射核反应放射出次级粒子, 次级粒子的入射电离增加了单粒子效应机理分析的难度。新工艺下还出现了一些新的单粒子效应, 如轰击集成电路会导致组合电路中产生单粒子多瞬态(MSET)^[3]、单粒子瞬态抑制(SETQ)^[4]等新的单粒子效应, 这些都是近两年来才出现的新效应, 其机理都有待于进行更深入的研究。

单粒子效应的建模同样也是一大难题, 尽管学者们提出了多种单粒子脉冲的建模方法。然而, 随着器件工艺尺寸的缩减, 传统的双指数模型已不再准确。PWL 方法依赖于器件模拟或者试验数据, 且只适于单一情况; 基于插值表的模型又不利于大规模集成电路使用; 而其他一些新的解析模型在准确性上又都没有得到广泛认同。目前为止, 提出更加精确适用的解析模型依然是一个研究的重点和难点。单粒子瞬态在复杂组合电路中传播特性的分析及其软错误率的评估都受到复杂计算量的限制, 如果提出更加合理简化的单粒子瞬态模型, 将对提高软错误率的评估效率和准确性具有重要作用, 然而, 由于机理问题没能最终解决, 使得提出更加精确的解析模型变得十分困难。

单粒子效应的芯片加固在深亚微米下同样也是难题。芯片加固技术主要分为工艺加固和设计加固两个层面。首先, 器件结构及加工工艺对器件单粒子效应加固性能有重要影响, 如采用三阱工艺、增加阱的掺杂浓度及减薄外延层的厚度, 能增加结电容降低辐射电荷收集量, 从而提高 CMOS 器件抗单粒子效应的能力。采用 SOI CMOS 技术, 特别是采用全耗尽 SOI CMOS 技术, 由于其优良的隔离及同粒子相互作用的体积减小, 可以明显提高器件的抗单粒子效应水平。其次, 设计加固可以在电路版图级至体系结构级等不同层次上展开。改进电路结构具有单粒子效应加固的潜力, 如在 SRAM 存储单元的触发器中串联附加电阻, 可以延迟电荷收集而增加电路抗单粒子效应的能力。对于在一般的待工线上加工电路芯片, 在电路的设计中, 采用冗余存储单元[如 DICE (dual interlocked cell, 交叉互锁单元)]也能有效提高抗单粒子效应水平。另外, 在版图设计中调整 N/P 区间距, 调整存储节点的位置等都能够有效提高抗单粒子效应水平。在体系结构级采用针对存储器件单粒子效应的纠检错 EDAC (如奇偶校验、Hamming 码、R-S 码及卷积码等) 技术也是有效的方法。与控制器和状态机有关的单粒子效应可以采用看门狗计时器来缓减, 三模冗余(TMR)表决电路也是一个重要的措施。解决电路系统的单粒子效应问题, 最有效的方法是将器件的工艺加固、电路版图级的设计加固及体系结构级的软硬件加固结合起来综合运用, 做到既保证器件和电路在辐射环境下能正常工作, 同时又能尽量减小为提高其抗辐射能力所付出的代价。在 180nm 及更粗大工艺下, 采用以上加固方法通常能够达到适当的加固目标。目前, 国际上也出现了 150nm 工艺下可用的抗辐照加固集成电路产品。

然而, 随着器件工艺尺寸的缩减, 单粒子多位翻转和单粒子瞬态等单粒子效应逐渐成为软错误率的最主要来源(如图 2 所示)^[5], 使得以往提出的在较大器件工艺尺寸下行之有效的加固技术和分析方法, 在 90nm 以下器件工艺尺寸下都需进一步改进。首先, 单粒子瞬态变得和正常数据信号很难区分, 采用传统的时域采样门闩和 Muller_C 单元的加固方法很难有效抑制单粒子瞬态, 同时,

建立有效的测试分析系统及仿真 EDA 工具也变得更加复杂。其次,在 90nm 和 65nm 器件工艺下,单粒子多位翻转影响的范围可以超过 10 个存储位,传统的 EDAC 纠一检二技术和 DICE 等加固技术都将不再有效。目前,尚无有效的单粒子瞬态和单粒子多位翻转加固方法。




图 2 随着器件工艺的缩减,单粒子瞬态和单粒子多位翻转发生的概率增加

总之,随着工艺的不断缩减,单粒子效应机理、建模及器件与电路的加固技术都将一直是难于完全解决的科学问题,其最终解决还尚需时日。

参 考 文 献

- [1] Dodd P E, Massengill L W. Basic mechanisms and modeling of single-event upset in digital microelectronics. IEEE Trans. on Nucl. Sci., 2003, 50(3): 583—602.
- [2] Huston S L, Plitzer K A. A new model for the low altitude trapped proton environment. IEEE Trans. on Nucl. Sci., 1998, 45(3): 2972—2978.
- [3] Casey M C, Duncan A R, et al. Simulation study on the effect of multiple node charge collection on error cross-section in CMOS sequential logic. IEEE Trans. on Nucl. Sci., 2008, 55(6): 3136—3140.
- [4] Ahlbin J R, Massengill L W, et al. Single-event transient pulse quenching in advanced CMOS logic circuits. IEEE Trans. on Nucl. Sci., 2009, 56(6): 3050—3056.
- [5] Amusan A, Casey M C, et al. Laser verification of charge sharing in a 90nm bulk CMOS process. IEEE Trans. on Nucl. Sci., 2009, 56(6): 3065—3070.

撰稿人: 陈书明¹ 刘忠立² 陈建军¹

1 国防科学技术大学微电子与微处理器研究所

2 中国科学院半导体研究所

纳米集成电路的软错误问题

The Soft Error Problem of Nanometer Scale Integrated Circuits

随着微电子制造工艺的发展,集成电路特征尺寸逐渐缩小,已经进入纳米时代。在纳米集成电路中,不断降低的供电电压、越来越高的工作频率、持续减小的节点电容和高速增长的芯片复杂度使得电路对环境的影响越来越敏感。当纳米集成电路受到高能粒子及外界环境中噪声和干扰等影响时,电路节点会发生瞬时充放电,有可能破坏芯片的内部状态,使集成电路发生瞬态故障,导致执行错误或数据错误。由于这种错误具有瞬态、可恢复、发生位置和时间随机等特点,因此被称为“软错误”^[1,2]。研究表明,在纳米级工艺条件下,软错误是引起集成电路失效的主要原因^[3]。

集成电路中的软错误与电路中的节点电容、电源电压、芯片工作频率、片上器件数等参数相关。在过去的集成电路中,器件特征尺寸相对较大,电源电压较高,工作频率较低,器件集成度较小,这些特征使高能粒子或噪声干扰对电路的影响很小,软错误发生的概率几乎可以忽略。但是,当集成电路特征尺寸发展到纳米级,电路的节点电容迅速减小,芯片工作频率和器件集成度都急剧增加,而电源电压却反而降低。此时,电路受外界的干扰越来越明显,频繁发生的软错误将导致系统的运行极不稳定,严重影响了集成电路的可靠性和可用性^[4]。图1表示了纳米集成电路中存储器和逻辑电路发生软错误的示意。




图1 纳米集成电路中的软错误

软错误对集成电路中各种部件和电路的影响不同。存储类部件对软错误比较敏感,并且具有较大的面积,因此,存储器件的软错误问题也最为严重。而组合与时序逻辑由于其结构特点,存在几种屏蔽效应,一定程度上降低了软错误发生的概率^[1]。集成电路中多样的电路类型和软错误发生的随机性特点使得针对集成电路软错误的精确评估比较困难。为了尽可能对电路软错误率进行准

确评估,需要进行大量复杂的运算,耗费巨大的时间,而简化的计算在精确度上难免有所损失。在目前的研究中,大多采用电路模拟、统计故障注入、体系结构易感性分析等多种技术相结合的方法进行集成电路的软错误率估算^[5,6],兼顾运算速度和估算精度,在两方面达到较好的平衡。

为了降低集成电路中的软错误率,主要有两种方法:一是通过降低电路对软错误的敏感性或降低错误发生的可能性来减少错误率,在软错误发生之前或发生之初就将其扼杀或屏蔽,从而确保正确性;二是允许错误在电路中出现,但电路结构和设计保证在错误发生后能够检测或者改正错误,不会引起最终系统错误。前一种方法可以灵活地调整电路关键部分的软错误敏感性,可靠性收益明显,所需开销较小,但这种方法需要对电路结构进行精心设计,工作量非常大,因此,通常应用于较规整的存储电路和对软错误率影响较大的关键电路中;后一种方法主要采用冗余的方法保证集成电路的正确运行,这种设计思想简单,效果较好,因此,在高可靠集成电路设计中广泛采用,然而,冗余必然带来较大的开销,将影响集成电路的性能和成本。如何使用较低的开销设计容软错误的电路结构是当前一个热门研究方向。

纳米集成电路由于其出色的性能、强大的功能和较低的功耗,已经广泛应用于电子通信、航空航天、军事和消费电子等设备中。但随着技术的发展,纳米集成电路中的软错误问题越来越突出,可能引起系统数据误差、运行错误,甚至导致整个系统崩溃,这将造成严重后果,必须加以重视。特别对于应用于航空、航天、军事等设备中的集成电路,由于所处环境复杂,并且可靠性要求极高,软错误问题更是设计中最严峻的挑战之一,需要特别考虑。

由于纳米集成电路中的软错误问题近些年才逐渐凸显并被重视,因此,在软错误产生机理、软错误率估算、软错误缓解方法和软错误率测量等方面还存在很多难题需要解决。归纳起来,这些难题主要有以下几方面:①软错误的产生机理仍需要进一步研究。软错误的产生与辐射或噪声环境、温度、器件类型和电路结构等很多因素有关,机理非常复杂。当前,在软错误产生机理的精确描述和建模方面仍然存在很多未解决的问题。②缺乏大规模电路的软错误率分析工具。集成电路软错误率的精确评估是一件比较困难的工作,需要耗费大量的运算时间。目前,只有一些学术机构开发出内部使用的小规模电路分析工具。能够较精确地评估大规模集成电路软错误率的商用工具仍然缺乏。③还没有为解决软错误问题而提出相关规范和标准。集成电路中的软错误问题是一个新出现的问题,对于软错误的评估、缓解、保护和测量还没有出台统一的规范和标准,各个设计部门各自为政,比较混乱。如何制定合理的规范和标准是当前亟须解决的问题。④软错误缓解技术带来的开销较大。降低软错误率的技术在提高可靠性的同时,大多会引起电路性能降低、成本增加及设计周期增长等,如

何降低软错误缓解技术的开销也是目前需要重点突破的难题。⑤集成电路芯片的软错误测量比较困难。由于软错误随机、偶发、不可预测和无法再现的特点,使得实际芯片的软错误测量变得十分困难。一般使用粒子加速测试或星载测试方法,但其巨大的成本限制了该方法的使用。开发既经济又准确的软错误测量方法在目前来说仍是一个难题。

纳米集成电路中,软错误问题的研究已成为集成电路设计的活跃前沿方向,很多研究机构和设计公司都在进行该方向的研究。电子领域著名的 IBM 公司这样描述软错误问题:“集成电路中的软错误问题已经成为一个极具吸引力的交叉学科,IBM 公司投入了业界最大的一个研究组来分析和解决大型机、超级计算机和 ASIC 产品的软错误问题。”^[7]相信随着科学技术的不断发展,在全世界研究人员的共同努力下,纳米集成电路的软错误问题将逐渐不再成为问题,本文介绍的难题也会一一得到解决。

参 考 文 献

- [1] Binder D, Smith E C, Holman A B. Satellite anomalies from galactic cosmic rays. IEEE Trans. on Nucl. Sci., 1975, 22: 2675—2680.
- [2] Ziegler J F, Curtis H W, Muhlfield H P, et al. IBM experiments in soft fails in computer electronics (1978—1994). IBM Journal of Research and Development, 1996, 40(1): 3—18.
- [3] Mitra S, Seifert N, Zhang M, et al. Robust system design with built-in soft-error resilience. IEEE Computers, 2005, 38(2): 43—52.
- [4] Mukherjee S S, Emer J S, Reinhardt S K. The soft error problem; An architectural perspective. Proceedings of 11th International Symposium on High-Performance Computer Architecture, 2005: 243—247.
- [5] Mukherjee S S, Weaver C, Emer J, et al. A systematic methodology to compute the architectural vulnerability factors for a high-performance microprocessor. Proceedings of International Symposium Microarchitecture, 2003: 29—42.
- [6] Li X, Adve S V, Bose P, et al. Online estimation of architectural vulnerability factor for soft errors. Proceedings of International Symposium on Computer Architecture, 2008: 341—352.
- [7] KleinOsowski A, Cannon E H, Oldiges P, et al. Circuit design and modeling for soft errors. IBM Journal of Research and Development, 2008, 52(3): 255—263.

撰稿人: 张民选

国防科学技术大学计算机学院

量子点存储器中存取速度与保持时间的矛盾

The Contradiction between Operation Speed and Retention Time in Quantum Dot Memory Devices

半导体存储器作为数据存储的主要载体,广泛应用于数据处理、移动通信、移动多媒体等电子产品。存储器以其功能特点一般分为两大类:易失性和非易失性。易失性存储器在系统关闭或断电时会立即失去存储在内的数据信息,它需要持续的电源供应以保存数据;而非易失性存储器在系统关闭或无电源供应时仍能保持数据信息。

典型的半导体非易失性存储器是一种浮栅型的金属氧化物场效应晶体管结构,如图 1 所示,它是由 Kahng 和 Sze 在 1967 年发明的^[1],其工作原理是通过沟道和浮栅间少量电子的转移来调制栅偏压对沟道电导的控制,进而控制器件的阈值电压(V_{th}),通过器件的双稳工作状态实现存入和取出信息的功能,而沟道和浮栅间电子转移是通过隧穿绝缘层来实现的。由此可知,浮栅与衬底沟道间的绝缘层(常称为隧穿层)的性质对实现非易失性功能有关键作用。如选用 SiO_2 做隧穿层,则 Si/SiO_2 界面的势垒高度约 3.15eV。理论估算指出^[2],假设 SiO_2 层厚度如从 1nm 增厚到 10nm,电子注入(转移)效率可变化 200 倍之多,这就提供给我们一个理论依据,如选用厚的 SiO_2 隧穿层,则可实现非易失性功能,但工作速度会减慢,反之要提高存储器的工作速度,则要减薄 SiO_2 层厚度,但非易失性功能降低。理想的半导体存储器应具有数据存取速度快、功耗低、数据保持时间长等优良特性,但从上述理论模型分析可知,对该类半导体浮栅型非易失存储器结构中,存取速度与保持时间是一对固有的矛盾,也是自这类半导体存储器发明以来至今尚未解决的难题。




图 1

针对半导体浮栅存储器件面临的难题,多年来科技工作者从新的存储介质的选择、器件结构设计及数据存取原理等多个途径来解决这一难题。

IBM 公司的 Tiwari 于 1996 年首次提出纳米晶存储器的概念^[3],如图 2 所示,传统浮栅中的存储介质被分立的由绝缘氧化层包裹的纳米硅晶粒代替,其工作原理是:基于纳米晶粒的三维量子限制效应,由沟道中注入的电子将被存储在分立的纳米晶粒的量子势阱中,这种分离存储特性可以有效抵抗纵向隧穿氧化层的应力漏电(stress induced leakage current, SILC)和横向漏极诱导势垒漏电(drain induced barrier leakage, DIBL),从而改善存储器数据的保持特性。另一方面,由于纳米晶粒电荷存储位置相对固定,通过控制纳米晶空间层的有序分布就可以实现多位存储特性^[4]。理论模拟指出,如在浮栅中包含有两层尺寸不同的纳米晶粒,利用由量子尺寸效应产生的势垒高度差异,降低电子向沟道泄漏的概率,提高数据的保持能力^[5]。在理想情况下,我们可控制注入浮栅中的电子只在相邻的两层纳米晶粒之间转移,不会再泄漏到沟道中,从而达到永久保存数据的目的。此外,如采用 Si/GeSi 复合纳米晶粒材料嵌入浮栅结构中也能获得很好的效果。




图 2

根据浮栅型半导体存储器中数据的泄漏与隧穿 SiO_2 的厚度有密切关系,采用高介电常数介质层代替隧穿 SiO_2 层是提高存储器保持时间的另一个重要途径。有报道指出^[6],当选 3.0nm 的高介电常数介质层(如 HfO_2)取代 1.2nm 的 SiO_2 层,尽管厚度增加了 2.5 倍,但其电容值却增加了 60%,更重要的是,其漏电流降低了两个数量级。 HfO_2 介电常数为 25,禁带宽度为 5.68eV,基本上能满足高介电常数材料的要求,但存在晶化温度低、易形成界面过渡层等缺点。如采用多元 HfSiON 薄膜,在提高介电常数的同时,改善其热稳定性和界面稳定性^[7]。在实际应用中,必须注意高介电常数栅介质层与硅衬底间的界面态,以及电极材料的选择,防止因势垒高度的失配降低了电子的注入效率。

高性能的新型非易失性存储器是当前半导体存储器领域中的研究热点,发展异常迅速,已达到 43nm/16Gb 的技术水平,超越 CPU 和 DRAM 提前跨越 50nm 的技术节点。从器件工作原理上,正朝着量子点单电子存储的方向发展^[2]。但是,量子点中的电子能量在三个维度上都是量子化的,电子的输运及存储性质将受到量子限制效应的影响,电子的局域性和相干性也有所增强。而随着量子点尺寸的减小,库仑阻塞效应导致的电子静电势的增加又从另一方面影响了电子的存取速度和保持特性,因此,研究量子点存储器中的能级分裂、共振隧穿、量子调控等量子尺寸效应和库仑阻塞效应与存储特性的关系是当前器件物理的重要内容。

随着集成电路技术向 22nm 的技术节点迈进(2016 年前后),在这样小的器件中依靠几十个电子来存储信息,可靠性会降低。科技工作者已开始研究用阻抗的改变代替电荷的改变来存储信息,如相变存储器、阻变存储器等原型器件相继出现,但最终哪一类存储器能成为理想的非易失存储器是大家共同研究的方向^[8]。

参 考 文 献

- [1] Kahng D, Sze S M. A floating gate and its application to memory devices. Bell Systems Technical Journal, 1967, 46: 1283—1287.
- [2] Tiwari S, Wahl J A, et al. Small silicon memories: Confinement, single-electron and interface state considerations. Appl. Phys. A, 2000, 71: 403—414.
- [3] Tiwari S, Rana F, et al. A silicon nanocrystals based memory. Applied Physics Letters, 1996, 68: 1377—1379.
- [4] Lu T Z, Alexe M, et al. Multilevel charge storage in silicon nanocrystal multilayers. Applied Physics Letters, 2005, 87: 202110—202113.
- [5] Yu L W, Chen K J, et al. Modeling and simulation for the enhancement of electron storage in a stacked multilayer nanocrystalline silicon floating gate memory. J. Appl. Phys., 2007, 102: 014501—014506.
- [6] Barrett C R. The digital evolution. MRS Bulletin, 2006, 31: 906—913.
- [7] Koike M, Ino T, et al. Dielectric properties of nanocrystalline HfSiON. Phys. Rev. B, 2006, 73: 125123.
- [8] Meijer G I. Who wins the nonvolatile memory race? Science, 2008, 319: 1625—1626.

撰稿人: 陈坤基
南京大学物理系

中间能带半导体

Intermediate-band Semiconductor

太阳能是可再生能源的重要组成部分。根据能量利用方式的不同,太阳能利用可以分为光电、光热和光化学转换,其中,最吸引人的是光电转换技术,其核心器件为太阳能电池。

成本和转换效率是阻碍太阳能电池发展的主要因素。光伏效应是太阳能电池工作的物理基础。目前,太阳能电池普遍采用半导体 PN 结结构,在 PN 结中存在由 N 区指向 P 区的内建电场。当光子从空气进入半导体内部后,电子吸收能量($h\nu$)不小于半导体禁带宽度(E_g)的光子,从价带跃迁到导带,形成光生空穴-电子对。光生空穴、电子通过扩散的方式到达 PN 结边缘,在 PN 结内建电场的作用下,分别被 P 区和 N 区收集,形成光电池的正极和负极。太阳能电池的转换效率由电池光生电压和光生电流决定。光生电压受限于半导体禁带宽度 E_g 。光生电流主要受限于半导体的内量子效率、光生电子和空穴的重新复合情况。

太阳辐射能量分布在紫外到近远红的宽光谱范围。现有的半导体材料,如 Si、GaAs 等,只有单个固定 E_g 。即使在理想情况下,也只能对部分的太阳光谱能量进行光伏转换。具体来说,太阳能电池不能对 $h\nu < E_g$ 光子进行光伏转换;对 $h\nu > E_g$ 的光子,最多只能转换 E_g 部分能量,而多余部分能量($h\nu - E_g$)则被浪费(如图 1 所示),从而形成太阳能电池在理想情况下转换效率的极限。随着半导体技术的发展,传统太阳能电池的实际转换效率逐渐接近理论极限。以单晶硅太阳能电池为例,理想转换效率约 29%,目前实验室的最好水平接近 25%,十几年来没有进一步的提高。

中间能带半导体,在半导体的禁带中引入半空半满的中间能带,光生载流子不仅可以通过价带-导带的跃迁吸收能量大于禁带宽度的光子形成,而且可以通过价带-中间带、中间带-导带的跃迁吸收两个能量小于禁带宽度的光子形成(如图 2 所示)^[1]。中间能带太阳能电池,在保持太阳能电池开路电压的条件下增加光生电流,其理想转换效率可达 63.2%^[2]。目前,中间能带半导体尚处于初步研究阶段,人们尚未实现可用于高效太阳能电池的中间能带半导体。主要的科学难题包括中间能带的形成机制和中间能带半导体的相关制作技术。

现有的半导体材料,只有导带和价带及两者之间的禁带,如何在禁带中引入中间能带成为中间能带半导体研究的首要问题。根据固体理论,能带来源于




图1 影响太阳能电池效率的主要因素

- ①. 半导体表面反射；②. $h\nu < E_g$ ，不能激发电子-空穴对；③. $h\nu > E_g$ ， $h\nu - E_g$ 部分热损失；
④. 光生载流子(电子、空穴)复合；⑤. PN 结和接触电阻损耗




图2 中间能带太阳能电池基本原理

- ①. 价带→导带跃迁；②. 价带→中间带跃迁；③. 中间带→导带跃迁

电子能级在周期性势场下的分裂。对于孤立原子，电子围绕原子核运动，每个电子都具有固定的本征波函数和本征能级。当若干个原子靠近相互作用时，核外电子，尤其是外层电子的每个本征能级发生分裂，形成若干个分裂能级。当大量原子周期性排列形成晶体时，外层电子的每个本征能级形成数目巨大的分裂能级，这些能级的能量差别极小，电子的能量状态很容易在这些分裂之间相互转换，从而形成能带中的允许带(简称允带)。由于原子中各个本征能级的能量是分立的，能级之间不允许存在其他能量状态，形成能带后，如果各个允带的宽度小于原有能级之间的能量差，则形成没有本征能级的禁止带(简称禁带)。现有半导体材料的光电特性主要由导带、价带及两者之间的禁带决定，它们分别来自原子的最低未完全填充能级、最高完全填充能级及两者之间的能量间隙。

在半导体当中，可以通过掺杂在禁带中形成杂质能级。如在本征 Si 中，掺杂 P 可以在靠近 Si 导带底部的位置形成能级，掺杂 B 可以在靠近 Si 价带顶部的位置形成能级，掺杂 Cu、Ag、Au 可以在 Si 禁带中形成深能级。但是，这些能

级都不能形成中间能带，主要原因如下：①杂质原子的浓度普遍较低，原子间距较大，杂质原子之间难以形成有效的相互作用；②杂质原子随机分布，其势场不具有周期性。

根据能带理论，第一种可能形成中间能带的方法是：以传统的半导体作为宿主，如 Si、GaAs、GaP、GaN 等，由这些半导体提供导带和价带。在半导体中加入杂质原子形成中间能带，所加的杂质原子如果满足以下几个条件，则有可能形成中间能带：①杂质原子的本征能级位于宿主半导体的禁带；②杂质原子的浓度足够高，间距足够小，存在较强的相互作用；③杂质原子的位置周期性排列；④杂质原子对宿主半导体的导带和价带影响较小。

在中间能带的理论研究方面，人们采用第一性计算原理，预言了各种具有中间能带的半导体材料。一般以 III-V 族或 II-VI 族化合物作为宿主半导体，如 GaN、GaP、ZnS、ZnSe、ZnTe 等，以第四周期的过渡金属元素作为杂质原子，如 Sc、Ti、V、Cr、Mn、Fe、Co、Ni、Cu 等。如果若干个宿主化合物半导体晶胞中的某个固定位置的原子被杂质原子替代，形成所谓的超晶胞结构，则有可能产生中间能带，可能的半导体材料有 $\text{Zn}_{107}\text{CrS}_{108}$ 、 $\text{Zn}_{107}\text{CrTe}_{108}$ 、 $\text{Ga}_{32}\text{N}_{31}\text{Cr}$ 、 $\text{Ga}_{32}\text{P}_{31}\text{Sc}$ 、 $\text{Ga}_{32}\text{P}_{31}\text{V}$ 、 $\text{Ga}_{32}\text{P}_{31}\text{Cr}$ 、 $\text{Ga}_{32}\text{P}_{31}\text{Fe}$ 、 $\text{Ga}_{31}\text{P}_{32}\text{Cr}$ 等^[3~5]。

但是，以上结果存在两方面的问题：

(1) 计算结果的可信程度。即使对于晶胞结构相对简单的传统半导体材料，如 Si、GaAs、GaN 等，采用第一性原理计算得到的能带结构和实际的禁带宽度测量结果具有较大的差异，以 GaN 为例，实测的 $E_g = 3.4\text{eV}$ ，而第一性原理计算得到的 $E_g = 1.9\text{eV}$ 。对于晶胞结构更为复杂的中间能带半导体，则更难估计理论计算和实际特性的差异。

(2) 制作技术的困难。现有的半导体单晶薄膜制备技术，如分子束外延、金属有机化合物气相沉积等，基本上只能进行同族材料原子的相互替代，如在 GaAs 中用 Al 或 In 材料替代一部分 Ga 形成 GaAlAs、GaInAs 等多元化合物半导体。而第一性原理预言的超晶胞结构，杂质原子和被替代原子基本不属于同一族，外层电子结构具有较大的差异，在制作上具有较大的难度。

第二种形成中间能带的可能方法是：采用周期性的低维量子结构(如量子点)，将不同禁带宽度的半导体材料周期性排列，形成周期性分布的有限深势井和有限高势垒，对应的本征能级分裂成中间能带。目前，已从理论上预言，基于 GaSb/InAs 的相互嵌套的立方体周期性 II 型量子点具有中间能带特性^[6]，该方法的主要问题是制作技术的困难。目前制作出来的量子点基本上是随机分布的，很难保证周期性；量子点的形状很难形成保证；另外，引入量子点以后，对半导体的其他特性，如光吸收、载流子逸出等形成不利影响。

为降低制作的困难，人们采用一些相对简单的工艺来制作中间能带材料，

如离子注入等。已有人采用在Ⅲ-V族化合物中注入 N 或者在Ⅱ-VI族化合物中注入 O, 然后进行激光退火或快速热退火的方法, 合成诸如 $\text{ZnO}_x\text{Te}_{1-x}$ 、 $\text{CdO}_x\text{Te}_{1-x}$ 、 $\text{Zn}_{0.88}\text{Mn}_{0.12}\text{O}_x\text{Te}_{1-x}$ 的材料^[7]。但是, 这些材料是否具有中间能带特性、能否用于太阳能电池, 尚有待验证。另外, 采用离子注入等手段形成的杂质原子, 在宿主半导体中的分布是非周期性的, 目前尚缺乏合适的理论工具分析其能带特性。

参 考 文 献

- [1] Luque A, Mart A. Increasing the efficiency of ideal solar cells by photon induced transitions at intermediate levels. *Phys. Rev. Lett.*, 1997, 78(26): 5014—5017.
- [2] Luque A, Mart A. A metallic intermediate band high efficiency solar cell. *Progress in Photovoltaics: Research and Applications*, 2001, 9(2): 73—86.
- [3] Tablero C. Survey of intermediate band materials based on ZnS and ZnTe semiconductors. *Solar Energy Materials and Solar Cells*, 2006, 90(5): 588—596.
- [4] Tablero C. Electronic and optical analysis of high-efficiency photovoltaic materials based on a GaN semiconductor. *Solar Energy Materials and Solar Cells*, 2006, 90(12): 1734—1740.
- [5] Tablero C. Survey of intermediate band material candidates. *Solid State Communications*, 2005, 133(2): 97—101.
- [6] Cuadra L, Mart A, Luque A. Type II broken band heterostructure quantum dot to obtain a material for the intermediate band solar cell. *Physica E*, 2002, 14(1—2): 162—165.
- [7] Yu K M, Walukiewicz W, et al. Diluted II-VI oxide semiconductors with multiple band gaps. *Phys. Rev. Lett.*, 2003, 91(24): 246403.

撰稿人: 罗 毅 王 健
清华大学电子工程系

多核芯片系统

Open Problems in Multi-core System-on-Chip

增加集成电路的工作频率是提高信息系统处理能力的传统手段,以 CPU 为例,其工作频在 1969 年仅为 108kHz,1989 年增长到 50MHz,2003 年增长到 3.4GHz。在 2003 年之后,提高芯片的工作频率变得异常艰难。增加芯片的规模成为提高芯片处理能力的重要手段,多核芯片系统也因此成为半导体行业的主流!随着工艺的进步,CMOS 工艺可以很容易地从 45nm 缩小到 32nm、22nm,甚至更低,芯片上集成的晶体管数目呈指数增长。将多个处理器核集成到一个芯片上看起来是轻而易举的事情,但实际情况并非如此,因为我们不仅需要多核芯片具备处理特定应用问题所必需的速度,而且需要使其功耗最低、面积最小。经过几年的发展,16 核的 CPU 已经于 2010 年 8 月问世,面向图像处理这一特定领域的 GPU 在 2010 年初就已经包含 480 个流处理核,可以预计,未来不论是 CPU 中处理核的数目,还是 GPU 中流处理核的数目,都会进一步增长,如何充分利用芯片中如此众多的核^[1]、如何设计面向特定应用的多核系统芯片将面临一系列严峻的挑战^[2]。

多核系统芯片在应用层面面临的挑战主要是程序员无法充分利用芯片上众多的处理器核^[1],这个问题实质是程序并行化的问题。在图像处理、搜索等容易在任务级实现并行化的领域,充分利用任意数目的处理器核是容易的,而在其他更普遍的情况,并行程序设计是异常艰难的。以求解下列线性方程组为例:

$$\begin{bmatrix} \mathbf{A}_{11} & \\ & \mathbf{A}_{22} \end{bmatrix} \begin{bmatrix} \mathbf{X}_1 \\ \mathbf{X}_2 \end{bmatrix} = \begin{bmatrix} \mathbf{B}_1 \\ \mathbf{B}_2 \end{bmatrix}$$

式中, $\mathbf{A}_{11}$ 和 $\mathbf{A}_{22}$ 都是 N 阶方阵,而且是非稀疏的。如果有 2 个核,可以让这 2 个核分别求解 $\mathbf{A}_{11} \mathbf{X}_1 = \mathbf{B}_1$ 和 $\mathbf{A}_{22} \mathbf{X}_2 = \mathbf{B}_2$,可以很容易地使 2 个核的计算速度接近单核的 2 倍。但如果用 10 个核的 CPU 来求解上述方程组,则很难让计算速度接近单核的 10 倍,因为要把上述求解过程“分成 10 个计算量相当的任务,且任务划分过程的时间远远小于单一核求解方程的时间”是极为困难的。

多核系统芯片在设计方面同样面临严峻挑战^[2]。首先需要解决核间通信架构的自动综合问题。多核之间高效率地传输数据取决于核间的通信构架,在核的数目确定后,不仅需要确定什么样的通信架构、带宽和缓存容量才能满足核间通信速度的要求,而且还必须在延时、面积、功耗等之间进行折中,因而需要针对实际应用的特点,优化核间的通信拓扑结构、信道带宽和缓存容量。在

通信架构确定之后,还必须高效地处理数据交换过程的一些动态管理问题。如果采用基于网络的包交换模式实现核间的通信,路由选择和网络交换是核心问题^[3];如果采用基于传统的总线结构,总线的分配与调度则是核心问题。应用映射(application mapping)是多核系统芯片设计面临的第三个难题^[4],包括如何将特定的任务均衡、动态地分配到各个处理器核?如何将特定信息处理专用芯核映射到特定的集成电路制造工艺?这两个问题处理得不好,会严重影响多核系统芯片的效率。Marculescu 等给出了这三个挑战的形式化描述^[2]。由于它们是 NP 完全问题,计算复杂度高,实际应用中只要能利用较小的计算成本获得近似最优的解即可。可靠性是多核系统芯片设计面临的第四个难题^[5],包括如何监测芯片的功耗、温度以增加多核芯片的寿命、提高多核芯片的可靠性?特别是在出现可靠性故障后,如何让多核芯片进行功能重组并从故障中恢复?这一点对于在太空或恶劣环境运行的系统尤为重要。

多核系统芯片的发展历程尽管非常短,但它是芯片今后发展的主要方向,即使在 CMOS 工艺不能再按比例缩小的时候,依靠多核结构、增加芯片的晶体管数目将依然能够提高系统的处理能力,特别是随着云计算等的发展,任务级并行的计算需求会不断增加,用成千上万个核构成的多核芯片替换今天的千上万台服务器将不仅可以显著减小这些服务器所占用的空间,而且可以显著降低其能耗,有利于信息社会朝绿色、低碳和环保方向发展。

参 考 文 献

- [1] Patterson D. The trouble with multi-core. IEEE Spectrum, 2010, 1(7): 28—32, 52—53.
- [2] Marculescu R, Ogras U Y, Peh L S, et al. Outstanding research problems in NoC design: System, microarchitecture, and circuit perspective. IEEE Trans. on Computer-Aided Design, 2009, 28(1): 3—21.
- [3] Stolberg H J, Berekovic M, Friebe L, et al. HiBRID-SoC: A multi-core system-on-chip architecture for multimedia signal processing applications. Proc. DATE, 2003: 20008.
- [4] Hansson A, Goossens K, Bekooij M, et al. CoMPSoC: A template for composable and predictable multi-processor system on chips. ACM Trans. Design Automation of Electronic Systems, 2009, 14(1): 1—24.
- [5] Tumeo A, Regazzoni F, Palermo G, et al. A reconfigurable multiprocessor architecture for a reliable face recognition implementation. Proc. DATE, 2010: 319—322.

撰稿人: 杨华中
清华大学电子工程系

集成电路的互连问题

Interconnect Problem of Integrated Circuits

在过去很长一段时间(30年)里,集成电路的性能主要取决于晶体管。为了提高电路系统性能,集成电路工艺按照摩尔定律不断发展,晶体管的特征尺寸不断缩小,电路速度与集成度不断提高。然而,集成电路由晶体管、无源元件与互连三种基本单元组成,晶体管特征尺寸缩小的同时,互连尺寸、互连布线面积及间距也相应地按比例减小。一方面,金属(铝、铜)互连线的电阻率随互连尺寸缩小而增加,同时,大规模集成导致互连线总长度越来越长,使得金属互连线的寄生电阻、电容和电感等参数开始影响电路性能,特别是随着集成电路工艺进入超深亚微米/纳米时代(后摩尔时代)^[1],互连线对信号传输产生的延时、畸变、反射和串扰等信号完整性问题日益严重,逐渐成为影响集成电路性能的一个瓶颈因素。另一方面,随着互连尺寸缩小与电路集成规模增加,互连上流过的电流密度迅速增加,从45nm工艺开始,ITRS预测的互连工作电流密度将逐渐超出铜互连能够容载的最大电流密度,同时,金属互连的电迁移问题和热问题也开始体现,产生互连可靠性问题。互连的上述信号完整性问题与可靠性问题统称为互连问题,将使电路系统的性能降低,甚至不能正常工作,而且工艺越先进,互连问题越严重。表1给出了三种工艺下晶体管延时与互连延时的比较。可见,工艺越先进,互连延时越大,对电路性能的负面影响也越大,这与通过工艺进步提升电路性能的目标背道而驰。因此,在后摩尔时代,微电子技术面临互连问题的严峻挑战,必须加以分析和解决。

表1 三种工艺下晶体管延时与互连延时的比较

工艺	MOSFET 延时/ps	1mm 互连延时/ps
1.0 μm (Al, SiO ₂)	20	5
0.1 μm (Al, SiO ₂)	5	30
0.035 μm (Cu, 低K)	2.5	250

互连问题解决的手段包括:①对传统互连结构与电路布局布线进行优化设计;②降低集成电路中导体的电阻率(如使用铜互连代替铝互连),降低互连损耗;③层间介质采用低介电常数的材料,提高信号在互连上的传输速度,减少互连延时;④通过三维集成方式减少互连长度;⑤发展互连新技术,如射频/无线互连技术^[2,3]、碳纳米互连技术^[4]及光互连技术^[5]等。

射频互连技术利用微波传输线(微带、共面波导等)对高速信号的传输性能远优于集成电路金属互连线的性质,以电容、电感近场耦合方式收、发信号,以微波传输线传输信号的互连技术,可综合使用无线通信中的各种调制解调方式,对单根高性能微波传输线进行复用。射频互连技术具有 CMOS 工艺兼容、有效带宽大、多路 I/O 等优点,可实现 100Gbps 量级的数据传输。无线互连利用微波天线和无线通信的技术手段,以电磁波形式实现芯片之间或芯片内部信号的无线传播,具有 CMOS 工艺兼容、可重构、时钟偏差小等优点,可实现 10Gbps 量级的数据传输,已在 Sun、Sony 公司的大型计算设备中使用。图 1 给出了片上无线互连系统结构框架。碳纳米互连是利用金属性碳纳米管或石墨烯作为信号传输媒质的互连技术,用于全局互连时,损耗与延时都比铜互连小,电流密度容量也高于铜互连 1 个量级。光互连则是利用光波导或自由空间作为信号传输媒质的互连技术,理论上具有很高的数据传输率。碳纳米互连与光互连目前在工艺上还有许多关键问题需要解决。




图 1 片上无线互连系统结构框架

综上所述,随着集成电路技术的发展,互连问题越来越严重和迫切。互连问题被认为是未来纳米集成电路的关键问题之一。

参 考 文 献

- [1] Meindl J D. Beyond Moore's law: The interconnect era. IEEE Transactions on Computing in Science and Engineering, 2003, 5(2): 20—24.
- [2] Chang M F, Verbaughede I, Chien C, et al. Advanced RF/baseband interconnect schemes for inter-and intra-ULSI communications. IEEE Transactions on Electron Devices, 2005, 52(7):

1271—1285.

- [3] Lin J J, Wu H T, Su Y, et al. Communication using antennas fabricated in silicon integrated circuits. IEEE Journal of Solid-State Circuits, 2007, 42(8): 1678—1687.
- [4] Li H, Yin W Y, Banerjee K, et al. Circuit modeling and performance analysis of multi-walled carbon nanotube (MWCNT) interconnects. IEEE Transactions on Electron Devices, 2008, 55(6): 1328—1337.
- [5] Koprinsky M J. On-chip optical inter-connects. Intel Technology Journal, 2004, 8(2): 129—141.

撰稿人：毛军发
上海交通大学电子工程系

集成电路在纳米级工艺下面临的设计挑战

The Challenge of IC Design in Nanometer Scale Process

自从 1947 年第一个半导体晶体管在贝尔实验室诞生, 1958 年第一块半导体集成电路问世, 从最初的十几个晶体管, 到今天单片可集成几十亿个晶体管, 集成电路一直遵循摩尔定律在飞速发展^[1]。半个世纪以来, 集成电路作为信息技术的核心载体, 随着技术的不断进步, 逐渐渗透到人类社会的各个领域。

目前, 集成电路主流工艺(平面 CMOS 工艺)的最小加工线宽已进入纳米量级。随着工艺尺寸的不断缩减, 芯片的集成度和速度不断提高。但同时, 各种物理效应在纳米尺度下也愈加显著, 并对器件特性及电路设计产生影响^[2]。

1. 纳米级 CMOS 工艺对器件特性及电路设计的不利影响

(1) 由于集成电路的最小加工尺寸已小于光刻技术使用的深紫外线波长的一半, 光刻误差越来越明显。同时, 由于量子效应及器件周边电路的应力效应, 使 MOS 器件阈值电压、载流子迁移率的变化较大。造成器件的匹配特性恶化, 对高精度电路设计带来挑战。

(2) 随着器件尺寸的缩减, 其本征增益显著下降, 这使得高增益放大电路设计难度增加, 从而使器件的非线性特性对电路的精度造成更大影响。

(3) 随着工艺尺寸的缩减, 芯片工作电压不断降低, 但电路中的噪声并不随之减小, 严重影响了电路的动态范围。

(4) 器件阈值电压降低, 使其不易完全关断。此外, 由于纳米级器件的内部电场强度大, 隧道电流、热载流子效应增强。这些都会导致漏电问题愈加严重, 增加电路的功耗。

2. 纳米级工艺下集成电路设计需要解决的难题

随着工艺的进步, 集成电路在工作速度方面具有更大的潜力。数字电路随着电源电压的降低, 其功耗在一定程度上有所降低, 但并不乐观。因为器件阈值、工作电压的下降只是有利于动态功耗的降低, 而器件漏电更为严重, 漏电功耗几乎可以和动态功耗相比。由于 SoC 系统中数字电路规模大, 晶体管数目众多, 器件漏电引起的功耗开销相当可观, 这是数字电路需要解决的重要问题。

虽然集成电路对数字信号的处理能力越来越强大, 但由于现实世界中需要处理的是模拟信号, 因此, 完整的系统芯片不可避免地需要将数字电路与模拟

电路集成在一起。模拟电路的设计需要同时考虑电路的速度、精度和功耗。从前文的分析可知,纳米工艺下器件的匹配度、工作电压、本征增益的减小会导致电路动态范围、线性度的降低,最终导致电路的精度降低。为克服上述困难,实现高精度,就必然带来功耗的代价。因此,模拟电路在功耗和精度的折中设计方面将面临更为严峻的考验。

3. 可能的研究方向

为应对纳米工艺条件给电路设计带来的困难,需要在设计层面和工艺材料层面不断探索。

(1) 电路实现及设计方法的研究。模拟电路的设计可以利用先进工艺的速度优势弥补精度的弱势,如采取利用时间域精度换取电压域精度的方法。但是,这类电路仍未完全摆脱利用电压幅度代表信号信息这一本质约束,而且是以牺牲速度为代价的。寻求一种非电压域的方法(如采用电荷代表信号的方法)可能是未来解决高速高精度设计的另一个途径^[3,4]。利用数字电路对模拟电路的误差进行校准也是获得高精度的一种方法,目前的数字校准算法可以校准器件失配误差,补偿放大器的有限增益误差,校正非线性增益曲线,在高速高精度的模数转换电路中应用广泛^[5]。大规模数字集成电路面临的主要问题是降低功耗并获得功耗与速度的优化指标。采用多阈值设计、电源管理等技术可有效控制动态功耗和漏电功耗。新的低功耗技术,如亚阈值设计和异步设计也在研究之中。虽然亚阈值型电路能大大降低功耗,但这种电路本身还存在一些缺点,如噪声大、带宽窄、对工艺比较敏感等,因此,如何更好地利用亚阈值型电路仍然是需要解决的问题^[6]。异步逻辑电路的应用可以使功耗降低,但其面临的问题较多,理论模型也不如同步电路那样完善,逻辑综合工具、时序检查工具都较为欠缺,因此,异步逻辑电路的研究还有很大空间^[7]。

(2) 器件模型和仿真工具的研究。电路设计离不开模型和仿真工具。对于纳米级工艺,由于其物理效应的复杂性,使得原有器件模型和建模方式不再适用。目前,新工艺的物理特性的研究还非常有限,器件模型和建模方法尚不成熟,面向特殊场合应用的器件模型尚待开发,这使得依赖于工艺厂家提供的器件模型进行仿真设计的电路的可靠性面临更大的风险和挑战。因此,研究纳米级工艺的建模方法,开发新一代的器件模型及电路仿真器,使其与工艺结合更加紧密且更加高效而精确,是设计实现高性能电路所迫切需要的。

(3) 新材料、新工艺的研究。在后摩尔时代,新材料、新工艺的开发是必然的发展趋势。目前,在这方面已进行了很多研究,如应变硅材料、SOI 技术、新的互连材料、双栅器件、碳纳米管等。另外,通过在制造工艺与系统设计方面的共同研究,将光技术与电技术更好地结合,也是解决集成电路设计瓶颈的

一个可能的途径。

(4) 多样化、多功能、跨学科的研究。集成电路技术是 20 世纪人类的伟大发明。集成电路之所以迅猛发展,从根本上说,除了工艺技术的进步,还有层出不穷的应用推动。在集成电路自身发展的同时可以看到,当它与其他学科进行交叉时,也为这些学科带来新的活力。当集成电路与信息技术结合时,出现了无线通信与互联网系统,改变了人们的工作、生活和社交方式;当集成电路和影像、音响技术结合时,造就了丰富多彩的电子消费领域,改变了人们的休闲娱乐方式;当集成电路与航空航天技术结合时,开启了人类走出地球去探索更广阔的宇宙空间的梦想。目前,集成电路技术正在与生物医疗技术结合,将使人们的健康水平和生活质量得到进一步提高和改善。随着与其他学科的结合,也使集成电路技术不断面临需要解决的新问题和需要突破的新技术,如当集成电路用于航天和军事领域时,就需要研究集成电路在辐射环境下的可靠设计问题。

虽然集成电路技术的发展终将受到物理规律的制约,面临材料和结构的更新换代,但从应用角度来看,还远没有挖掘出它的巨大潜力。因此,在解决电路的精度、速度、功耗问题的同时,更需要探索新的应用领域,并研究和解决集成电路在新的应用领域中所面临的新问题。

参 考 文 献

- [1] ITRS Working Group. The International Technology Roadmap for Semiconductors. 2009.
- [2] Lewyn L L, Ytterdal T, Wulff C, et al. Analog circuits design in nanoscale CMOS technologies. Proceedings of the IEEE, 2009, 97(10): 1702—1703.
- [3] Park M, Perrott M. A 0.13 μm CMOS 78dB SNDR 87mW 20MHz BW CT $\Delta\Sigma$ ADC with VCO-based integrator and quantizer. International Solid-State Circuit Conference, 2009, 170—171.
- [4] Anthony M, Kohler E, Kurtze J, et al. A process-scalable low-power charge-domain 13-bit pipeline ADC. IEEE Symposium on VLSI Circuits, 2008, 222—223.
- [5] Siragusa E, Galton I. A digitally enhanced 1.8V 15b 50 MS/s CMOS pipelined ADC. International Solid-State Circuit Conference, 2004, 452—453.
- [6] Markovic D, Wang C C, Alarcon L P, et al. Ultralow-power design in near-threshold region. Proceedings of the IEEE, 2010, 98(2): 237—252.
- [7] Martin A J, Nystrom M. Asynchronous techniques for system-on-chip design. Proceedings of the IEEE, 2006, 94(6): 1089—1120.

撰稿人: 李冬梅 刘力源
清华大学电子工程系

GaN 基宽禁带半导体

GaN-based Wide Band Gap Semiconductors

通常把禁带宽度大于 2.3eV 的半导体材料称作宽禁带半导体材料,Ⅲ族氮化物中的 GaN 基材料(包括 GaN、AlN 和 $\text{Al}_x\text{Ga}_{1-x}\text{N}$)是典型的宽禁带半导体材料,其禁带宽度由 GaN 的 3.4eV 到 AlN 的 6.2eV 之间可调。GaN 基材料具有热导率高、电子饱和漂移速度高、热稳定性和化学稳定性好、抗辐照、耐腐蚀等优点,是理想的白光照明等光电子和高频、大功率微电子、紫外光电探测等器件的基础材料,有着广泛的应用前景,是目前材料科学领域研究的热点。

1. GaN 基材料发展简史

GaN 薄膜材料的研究起始于 20 世纪 60 年代。1969 年,Maruska 等采用氢化物气相淀积技术(HVPE)在蓝宝石衬底上制备出了 GaN 薄膜^[1];1972 年,Pankove 等用掺锌(Zn)的 GaN 做成 MIS 结构的 LED 器件,首次实现了蓝光发射^[2]。随着 GaN 的 P 型掺杂技术获得突破性进展,1994 年,Nakamura 报道了首只高亮度 GaN 基蓝光 LED^[3],在国际上掀起了Ⅲ族氮化物器件研发高潮,多种Ⅲ族氮化物器件,如蓝绿光 LED、激光器、紫外探测器和微波、毫米波器件等相继问世。然而,由于缺乏大尺寸的同质衬底材料,基于它们的微结构材料不得不在与其晶格和热失配很大的异质衬底材料(蓝宝石、SiC 或硅等)上生长,大失配导致的高缺陷密度($10^9 \sim 10^{10} / \text{cm}^2$)严重制约了 GaN 基材料质量和基于它的光电器件性能的提高。

2. GaN、AlN 基材料研究现状

采用蓝宝石衬底上的 GaN 横向外延技术和在晶格失配较小的 6H-SiC 衬底上的异质外延技术等,GaN 基外延层的缺陷密度虽有所降低,但仍难满足高功率发光器件和高频大功率微波器件与电路对材料质量愈来愈高的要求。为此,开展 GaN、AlN 体单晶制备技术研究,满足 GaN 同质外延对衬底的需求,就成为发展 GaN 基宽禁带半导体亟待解决的一个难题。目前,GaN 体单晶衬底的制备技术主要有氢化物气相外延技术(采用氢化物气相外延技术先在蓝宝石衬底上生长 GaN 薄膜,然后将其剥离作为衬底再生长 GaN 厚膜的技术)和氮高压熔融生长技术(“氨热法”)。利用上述两种技术得到的最好结果分别为 2 英寸、缺陷密度最低 $5 \times 10^5 \text{ cm}^{-2}$ 的 GaN 单晶厚膜和尺寸为 $17\text{mm} \times 17\text{mm}$ 、缺陷密度最低

为 10^3 cm^{-2} 的 GaN 体单晶, 但生长条件苛刻, 制备技术复杂, 价格极其昂贵, 很难推广应用。AlN 单晶衬底研究进展比较顺利, 2006 年, Crystal IS 公司从钨坩埚成功拉制出直径 2 英寸、位错密度小于 $10^4 / \text{cm}^2$ 的 AlN 单晶材料, 但晶体为“本征”高阻, 难以用于器件研制。

GaN、AlN 及其三元合金存在的另一个难题是 P 型杂质的有效掺杂。目前, GaN 及其合金的 P 型杂质的掺杂浓度仍徘徊在 $10^{17} / \text{cm}^3$ 左右, AlN 尚为“本征”高阻材料, 难以满足高性能器件研制的需求。

3. GaN 基材料亟待解决的难题

(1) 大尺寸、低缺陷密度的 GaN 和 AlN 单晶衬底材料制备, 变大失配异质外延为同质外延, 彻底解决大失配异质外延在外延层中引入的高密度缺陷难题。GaN 体单晶通常要在数千度高温、数万大气压的高压釜制备, 研究进展缓慢。最近, 日本科学家采用“氨热法”在制备大尺寸块体 GaN 单晶方面取得进展, 但离实用尚远。

(2) GaN 基材料的 P 型杂质的有效掺杂和 AlN 的 N 与 P 型掺杂有待突破。有报道指出, 非极性 GaN 基材料有利于 P 型杂质的掺杂, 但理论依据尚不清楚。

(3) 通过对大失配异质外延生长动力学的深入研究, 发展柔性衬底制备技术, 将大失配在异质结外延层中引入的高缺陷密度限制在柔性层或衬底中, 从而提高外延层质量, 改善器件性能, 这既是半导体材料科学家目前面临的严峻挑战, 也是取得原始创新成果的难得机遇。

上述三个难题的突破必将有力地推动 GaN 基宽禁带半导体科学和技术的快速发展和基于它的战略高技术产业的形成。

参 考 文 献

- [1] Maruska H P, Tietjen J J. The preparation and properties of vapor-deposited single-crystalline GaN. *Applied Physics Letters*, 1969, 15(10): 327—329.
- [2] Pankove J I, Miller E A, Berkeyheiser J E. GaN bluelight-emitting diodes. *Journal of Luminescence*, 1972, 5: 84—86.
- [3] Nakamura S, Mukai T, Senoh M. Candela-class high-brightness InGaN/AlGaIn double-heterostructure blue-light-emitting diodes. *Applied Physics Letters*, 1994, 64(13): 1687—1689.

撰稿人: 王占国

中国科学院半导体研究所

半导体金刚石

Semiconductor Diamond

金刚石不仅具有“宝石之王”的美称，而且还具有禁带宽度大(5.5eV)、硬度和热导率极高、耐高温、抗腐蚀、电子饱和漂移速度高、抗辐照等其他半导体材料不可比拟的优异性能，在高温、高频大功率微电子领域和深紫外光辐射与探测、强辐照高能粒子检测与监控光电子领域有着极其重要的应用前景。半导体金刚石被称为“终极半导体”，它的发展和应用极有可能带来科学技术上的重大变革。图 1 显示了在高频大功率微电子领域半导体金刚石与其他半导体材料相比具有的不可替代的优越性。




图 1 用于无线通信领域的几种主要半导体材料的输出功率与工作频率关系对比

1. 半导体金刚石制备

自从 19 世纪末石墨被发现起，人们就开始模拟自然过程，探索使石墨在特定环境下转变成金刚石的方法，直到 1955 年，美国 GE 公司宣布利用高压高温设备制造出金刚石小晶体，从而拉开了工业化生产人造金刚石的序幕。随后，人们又利用瞬态高压高温技术，成功合成了纳米级金刚石。尽管目前高压高温技术可获得尺寸 10mm 左右的单晶金刚石，但晶体质量难以控制，造价昂贵，且难以获得更大的尺寸。低压化学气相沉积(CVD)技术，特别是微波等离子体 CVD 技术的成功应用，使其成为了目前用于金刚石薄膜生长的主流技术，但这种技术仅局限于在单晶金刚石衬底上的同质外延生长，获得高晶体质量、大尺

寸的金刚石外延薄膜不易, 半导体单晶金刚石的研究进展一度受阻。21 世纪初, 微波等离子体 CVD 金刚石单晶薄膜生长速度(最高可达 $167\mu\text{m}/\text{h}$) 的突破^[1]和在单晶金刚石衬底上重复纵向、横向生长方法的实验成功, 为制备大面积单晶金刚石薄膜奠定了基础。2010 年初, 日本科学家在日本应用物理学会上称, 将同一金刚石衬底外延生长的金刚石层剥离下来, 抛光后紧密地拼接起来作为新的衬底, 可以获得 1 英寸大小的外延片。

2. 半导体金刚石掺杂

利用微波等离子体技术, 在金刚石同质外延生长过程中引入硼源, 可获得高质量 P 型金刚石薄膜。硼受主能级位于价带顶以上 0.37eV 处, 由于硼的能级较深, 金刚石中的空穴浓度不仅与受主浓度有关, 还与外界温度有关。目前, 室温下空穴浓度为 $2\times 10^{14}\text{cm}^{-3}$ (受主浓度为 10^{17}cm^{-3}) 时, (100) 面硼掺杂金刚石的空穴霍耳迁移率最好值高达 $1840\text{cm}^2\cdot\text{V}^{-1}\cdot\text{s}^{-1}$, 杂质补偿率为 0.4% 。金刚石的 N 型掺杂是目前待攻破的难题。尽管替位氮在金刚石中为施主, 但能级太深, 室温下很难获得 N 型电导。自 20 世纪 80 年代微波等离子体 CVD 用于生长金刚石以来, 人们便采用离子注入、原位掺杂等尝试在金刚石中引入替位杂质磷来获得 N 型导电, 但均未获得成功。直到 1997 年, 由于 CVD 外延工艺的改进, N 型导电的金刚石薄膜才得以实现, 随之, 首只金刚石 PN 结深紫外光发射二极管也研制成功^[2]。然而, 磷掺杂 N 型单晶金刚石外延薄膜质量很差, 电子霍耳迁移率最高值仅为 $660\text{cm}^2\cdot\text{V}^{-1}\cdot\text{s}^{-1}$, 远低于理论值。为此, 人们一直在探索 N 型金刚石的其他掺杂剂, 如有报道称碱金属锂和钠可以在金刚石中形成浅施主能级^[3], 硫在金刚石中可形成激活能为 0.37eV 的施主, 但均未得到理论和实验的进一步证实。

3. 发展半导体金刚石材料与器件要解决的难题

在半导体金刚石时代真正到来之前, 必须要解决的难题有: ①较大面积金刚石单晶薄膜的生长虽已取得进展, 但如何提高单晶薄膜的纯度、完整性和均匀性等尚无良策。另外, 大尺寸块体金刚石单晶合成一直是人们奋斗的目标, 目前仍无取得突破的迹象, 但这种追求不会停止。②N 型掺杂仍然是制约半导体金刚石发展的最重要因素, 寻求新的浅能级施主或发展新概念器件是人们面临的又一个严峻挑战。

参 考 文 献

[1] Liang Q, Chin C Y, Lai J, et al. Enhanced growth of high quality single crystal diamond by

microwave plasma assisted chemical vapor deposition at high gas pressures .Applied Physics Letters ,2009 ,94 (2) ;024103 .

- [2] Koizumi S ,Watanabe K ,Hasegawa M ,et al .Ultraviolet emission from a diamond pn junction .Science ,2001 ,292 (5523) ;1899—1901 .
- [3] Goss J P ,Briddon P R .Theoretical study of Li and Na as n-type dopants for diamond .Phys . Rev .B ,2007 ,75 (7) ;07520 .

撰稿人：王占国
中国科学院半导体研究所

ZnO 半导体材料

ZnO Semiconductor Materials

II-VI 族 ZnO 基材料(包括 ZnO、MgZnO 和 BeZnO 等)是另一类典型的宽禁带半导体材料。ZnO(禁带宽度为 3.37eV)与其他半导体材料相比,具有很高的激子结合能(60meV)、极好的抗辐照性能、低的外延生长温度及具备同质外延所需的 ZnO 单晶衬底等一些独特的优势,有望用于室温、高效激子发光器件、紫外 LED、紫外探测器、生物传感器及抗辐照太空探测器等新型光电器件的研制,受到国内外广泛的重视,是目前国际半导体材料科学研究领域的热点和前沿。

1. ZnO 材料的发展简史

20 世纪 90 年代初,II-VI 族 ZnSe 基蓝绿光器件 77K 电注入脉冲激射的实现曾掀起过对该材料体系研究的高潮,然而,由于它固有的低缺陷形成能和非化学配比导致的高点缺陷密度等致命弱点使其在与 III 族氮化物的竞争中失去了优势,目前研究进展缓慢。与此相反,随着 ZnO 材料生长技术的进步、材料质量的不断提高及其引人注目的优异光电性能,ZnO 近十多年来发展迅速,成为了 II-VI 族宽禁带半导体的主要代表。1996 年,ZnO 材料光泵紫光激射的实验结果激起了世界范围的 ZnO 基材料的研究热潮,随着 ZnO 单晶制备技术(如水热法、高压熔体法、气相输运法等)的迅速发展,特别是水热法,于 2003 年研制成功大尺寸(2~3 英寸)的 ZnO 单晶导电衬底,进一步加快了 ZnO 基材料与器件的研究步伐。然而,由于价格昂贵和难以得到,致使 ZnO 同质外延技术踏步不前。目前,虽然不少实验室声称已制备出 N 和 P 型 ZnO “单晶”薄膜,但基于大失配的异质外延技术获得的晶体质量难以保证。事实上,目前基于这种材料的器件性能与理论预测值相差甚远。发展 ZnO 同质外延技术,提高 ZnO 基单晶薄膜的质量,彻底解决 ZnO 基材料的稳定、高浓度 P 型掺杂是 ZnO 基材料和器件走向实用化前必须要解决的难题。

2. ZnO 基材料的 P 型掺杂研究现状

早期,ZnO 的 P 型掺杂主要是通过 I 族元素(Li、Na、K、Au、Ag、Cu 等)替代 Zn 位和 V 族元素(N、P、As、Sb 等)替代 O 位形成受主来实现,然而实验结果表明,这种掺杂技术难以获得 ZnO 的有效 P 型掺杂。为解决这一难题,

材料科学家提出了诸如 H 钝化 (N_O -H、 Li_N -H、 Na_Zn -H 等)、施主-受主 (Al-N 等) 和双受主共掺杂 (Li-N 等) 等技术, 目的都是为了提高 N 和 Li 等在 ZnO 中的固溶度、抑制掺入杂质的自补偿和降低受主的激活能。2005 年, Tsukazaki 等^[1] 利用 MBE 技术, 采用高低温调制生长方法制备出空穴浓度 $10^{17}/\text{cm}^3$ 的 P-ZnO : N 薄膜, 首次观察到了 ZnO PIN 二极管的室温电致发光。2006 年, 又报道了基于 ZnO/BeZnO 多量子阱结构紫外激光器原型器件^[2]。2008 年, Liu 的课题组^[3] 采用 MBE 技术, 获得了空穴浓度为 $1.7 \times 10^{18} \text{ cm}^{-3}$ 、迁移率为 $20 \text{ cm}^2 \cdot \text{V}^{-1} \cdot \text{s}^{-1}$ 的 P-ZnO : Sb 薄膜, 并研制出了 ZnMgO/ZnO 多量子阱结构的激光器原型器件, 这是迄今报道的最好结果。实验虽取得了进展, 但有关 P 型 ZnO 空穴浓度报道的数据不仅相差悬殊, 而且难以重复。

最近, Na 掺杂 ZnO 研究受到关注, 由于 Na-O 键能大, 与 N 受主相比, 激活能较低, 有可能成为 ZnO 一个稳定的 P 型掺杂剂。另一方面, 考虑到 BeO 及其 BeZnO 合金的键能强、电声子耦合较弱等特点, 或许是克服 P-ZnO 制备难题的一个选择。Yan 等的理论计算^[4] 指出, ZnO 中 IB 族元素 (如 Cu、Ag 等) 的 P 型掺杂时不发生自补偿效应, 而且在富氧条件下生长, 可以有效抑制本征施主缺陷, 如 Zn_i 、 V_o 等的形成, 并认为 IB 族元素是比较理想的掺杂剂。此外, 在提高 N 等 P 型掺杂剂在 ZnO 中的溶解度、降低受主激活能研究方面, 人们还尝试了 N 与阴离子等电子杂质 (如 ZnO : N-S、ZnO : N-Se) 的共掺技术, 虽然 P 型掺杂浓度有所提高, 但合金散射导致空穴迁移率的降低使得此种技术受到质疑。

3. ZnO 基材料与器件发展的瓶颈

制约 ZnO 基材料体系发展的主要难题有: ①获得稳定、高浓度 P 型 ZnO 的关键是如何提高 N、Li 等受主杂质在 ZnO 中的固溶度、抑制掺入杂质的自补偿和降低受主的激活能, 十多年来, 人们虽尝试了多种掺杂技术, 但进展缓慢。显然, 这一难题的解决有赖于对 ZnO 的 P 型掺杂机理的深入理解和晶体生长、掺杂技术的不断创新。②采用目前常用的大失配异质外延技术难以获得高纯、高完整和高均匀的 ZnO 基单晶薄膜, 这是制约 ZnO 基光电器件进一步发展的又一个瓶颈。ZnO 体单晶衬底虽已研制成功多年, 但由于价格昂贵, 加之晶体质量尚存问题的情况下, ZnO 的同质外延一直停止不前。提高 ZnO 单晶衬底的质量, 发展 ZnO 基材料的同质外延技术, 也许是 ZnO 基材料与器件走向实用化的一条捷径。

参 考 文 献

- [1] Tsukazaki A, Ohtomo A, Onuma T, et al. Repeated temperature modulation epitaxy for p-type doping and light-emitting diode based on ZnO. *Nature Materials*, 2005, 4: 42.

- [2] Ryu Y R, Lee T S, Lubguban J A, et al. Wide-band gap oxide alloy: BeZnO. Applied Physics Letters, 2006, 88, 052103.
- [3] Chu S, Olmedo M, Yang Z, et al. Dominant ultraviolet light emissions in packed ZnO columnar homojunction diodes. Applied Physics Letters, 2008, 93, 181106.
- [4] Yan Y F, Aljassim M M, Wei S H. Doping of ZnO by group-IB elements. Applied Physics Letters, 2006, 89, 181912.

撰稿人：王占国
中国科学院半导体研究所

量子点激子太阳电池

Quantum Dot Excitonic Solar Cells

作为一种重要的光电能量转换器件,太阳电池的研究一直受到人们的热切关注。一般而言,太阳电池可以分为两大类:一类是基于半导体 P-N 结中载流子输运过程的无机固态太阳电池,另一类则是基于有机分子材料中光电子化学过程的光电化学太阳电池。但是,不管哪类太阳电池,目前的能量转换效率都远低于其理论预测值。太阳能转换效率难以提高的主要原因有:一是对于一种具有特定带隙的光伏材料而言,只有大于此带隙的光子能量才会被吸收,而小于此带隙的光子能量却不能被吸收,由此会造成低光子能量的损失;二是在目前的太阳电池中,一个光子只能激发并产生一个电子-空穴对,即量子效率总是小于 1,这样会使高能端光子的能量不能得到充分利用,也就是说,会造成高光子能量的损失。

有两种途径可以显著改善单结太阳电池的光伏性能,从而使其能量转换效率得以大幅度提高。一种方法是拓宽光伏材料对太阳光谱能量的吸收范围,如采用多结叠层或多带隙结构。另一种方法就是从光子和电子之间的相互作用,以及声子对能量转换过程的参与入手,即通过合理而充分利用光生热载流子的输运性质提高太阳电池的转换效率。简言之,就是通过减少热载流子弛豫造成的能量损耗使光伏电池的转换效率得以增加,而这又可以通过两种技术途径实现:一种是通过增加开路电压实现,另一种则是通过增加短路电流实现。前者要求光生热载流子在变冷之前应及时从太阳电池中被收集,借以增加光生电压;后者则要求热载流子能通过碰撞电离激发产生两个或更多的电子-空穴对,即所谓的多激子产生过程(MEG)。该过程为热载流子俄歇复合的逆过程,它的物理含义不是通常的电子和空穴在复合时将多余的能量传递给另一个载流子,使其从低能态被激发到更高的能态中去,而是由两个电子-空穴对复合以产生一个具有更高能量的电子-空穴对。为了实现前者,要求光生载流子的分离和输运过程必须快于热载流子的变冷速率,而后者则要求碰撞电离过程大于热载流子的变冷速率和其他的能量弛豫过程。2002 年,美国国家可再生能源实验室 Nozik 和澳大利亚新南威尔士大学 Green 两个小组的研究同时指出,某些半导体量子点在来自于光谱末端的蓝光或高能紫外线轰击时,能释放出两个以上的电子^[1,2]。2004 年,美国新墨西哥州 Los Alamos 国家实验室的 Klimov 等首次用实验证明了上述理论是正确的,他们发现,对于有多激子产生效应的光伏材料

而言,一个入射光子可以产生两个或两个以上的电子-空穴对,其量子产额可以高达 300% 以上。




图1 量子点中的多激子产生过程

量子点激子太阳电池就是基于这种多激子产生效应设计和制作的光伏器件。理论估计,这种太阳电池的能量转换效率可高达 40% 以上,甚至可以超过 50%。量子点或纳米晶粒中之所以能够产生多激子,主要是由于这类量子微结构具有显著的能级分立特性和强三维量子限制效应,它的类 δ 函数状态密度和电子-空穴谱的分立特征,使得电子通过电子-声子作用的弛豫速率可以有效减少。同时,由于在量子点中电子-空穴库仑相互作用的增强,可以使多激子产生的逆俄歇过程大大增加。这种由碰撞电离制约的逆俄歇过程所描述的物理含义是:当量子点吸收一个能量大于或等于 $2E_g$ 的光子时,所产生的高

能量激子通过能量转移过程而弛豫到带边,其结果是导致一个吸收的光子形成两个或两个以上的激子,这样,就会使太阳光谱中的高光子能量转变成光电转换所需要的能量,而不会导致能量损耗,这是多激子产生的最本质体现。图 1 示出了一个发生在典型量子点中的碰撞电离多激子产生过程。

近年,人们已对发生在各种量子点和纳米晶粒中的多激子产生效应进行了诸多富有成效的研究。实验指出,属于 IV-VI 族的纳米 PbSe 晶粒(nc-PbSe)、纳米 PbS 晶粒(nc-PbS)及纳米 PbTe 晶粒(nc-PbTe)均具有良好的多激子产生能力,这主要是因为它们具有较窄的带隙,易于满足 $h\nu \geq 2E_g$ 或 $3E_g$ 的要求,其带隙能量分别为 0.29eV、0.42eV 和 0.30eV。Klimov 等^[3]首次研究了发生在晶粒尺寸为 4~6nm 的 nc-PbSe 中的多激子产生过程。据报道,当泵浦光子能量为 nc-PbSe 带隙能量的 3 倍时,便可以产生两个或两个以上的激子。2006 年,该小组又报道了更加鼓舞人心的实验结果,他们发现,当用高能紫外线轰击 PbSe 和 PbS 量子点时,每个吸收光子可以产生 7 个激子。与此同时,Nozik 等的研究团队也展开了对 PbSe、PbS、PbTe 量子点中多激子产生的实验研究,结果发现,当入射光子的能量为量子点带隙能量的 4 倍时,将会有有一个光子产生 3 个激子,相当于获得了 300% 的量子产额。

最近,量子点激子太阳电池的研究取得了突破性进展。2009 年,美国康奈尔大学的 Choi 等^[4]率先研发成功了 nc-PbSe 激子太阳电池,在 1sun 太阳光照射下,其功率转换效率为 3.4%。虽然这一转换效率还相对较低,但它向世人展示

出,量子点激子太阳电池研究的热潮即将到来。为了能够实现具有真正意义上的实用化量子点激子太阳电池,无论在理论上还是在技术上,尚有大量的工作需要尝试和探索,主要包括以下几个方面:①选择适宜的量子点材料。为了实现基于多激子产生效应的量子点太阳电池,应选用体材料禁带宽度相对较窄的PbSe、PbS和PbTe等。因为要在一定光照度下产生多个电子-空穴对,需要入射光子能量至少为量子点带隙能量的2~3倍,而在这种材料中比较容易引发多激子产生过程。②制备有序的量子点阵列。为了有效改善量子点激子太阳电池的光伏特性,排列有序的量子点及其阵列的形成至关重要。目前,人们多采用胶体化学方法形成这种纳米晶粒。③调整量子点界面的性质。在量子点激子太阳电池结构中存在着大量界面组织,为了能够实现高效率的多激子产生过程,最大限度地加快界面之间的载流子输运过程和最大限度地降低载流子在界面同缺陷态的复合过程,无缺陷的高质量界面的形成则是关系到能否大幅度提高太阳电池转换效率的重要因素。

参 考 文 献

- [1] Nozik A J. Quantum dots solar cells. *Physica E*, 2002, 14: 115.
- [2] Trupke T, Green M A, Würfel P J. Improving solar cell efficiencies by down-conversion of high-energy photons. *J. Appl. Phys.*, 2002, 92: 1668.
- [3] Schaller R D, Klimov V I. High efficiency carrier multiplication in PbSe nanocrystals, implications for solar energy conversion. *Phys. Rev. Lett.*, 2004, 93: 186601.
- [4] Choi J, Lim Y F, Oh M, et al. PbSe nanocrystal excitonic solar cells. *Nano Lett.*, 2009, 9: 3749.

撰稿人: 彭英才¹ 赵新为²

1 河北大学电子信息工程学院

2 日本东京理科大学物理系

多结叠层太阳能电池

Multi-junction Tandem Solar Cells

对于单能隙半导体材料构成的太阳能电池,存在一个极限效率,计入电池表面热辐射和光吸收之间的细致平衡,此极限效率为 32.8% (Shockley-Queisser 极限效率)。进一步提高太阳能电池效率最现实的途径是构成多结叠层聚光电池。将多个子电池按其带隙宽度的大小从上至下叠合起来,分谱段吸收阳光,从而与太阳光谱更好匹配。理论上,考虑到电池表面的热辐射和光吸收之间的细致平衡,无限多结叠层电池的极限效率在一倍太阳光强下为 65.4%,在最大聚光(约 46200 倍)下达 85.0%^[1]。

聚光可利用相对便宜的光学系统,成百上千倍地提高入射太阳光强,相应提高电池的输出功率。这样,不仅可以降低光伏发电系统的成本,还可以提高电池的效率。因为在一定光强范围,电池的短路电流与光强呈正比,而开路电压随光强呈对数式增长。

单片两端叠层电池是一种串联电路,它的电压是各子电池的电压之和,而其电流与流经各子电池的电流相等。所以,为了获得高效叠层电池,首先需要合理设计各子电池的带隙宽度和厚度,使它们在最大功率点附近的电流相等。同时,高效叠层电池应当由晶格完美的外延薄膜材料构成,不同带隙宽度的子电池材料之间应当是晶格匹配的,这就限制了子电池材料的可选范围。在获得最佳电流匹配的同时又能获得最佳晶格匹配的机会是很小的,往往需要容忍一定程度的晶格失配,并将晶格失配的影响控制在缓变层内,这是外延工艺面临的课题。

近年来,在美国国家可再生能源实验室工作的基础上,以直接带隙 III-V 族材料为主体的三结叠层聚光太阳能电池取得了重要进展,单片两端 GaInP/GaInAs/Ge 三结叠层电池效率已达 40% 以上。

1. 晶格匹配外延 GaInP/Ga(In)As/Ge 三结叠层聚光电池

2007 年,美国 Spectrolab 公司研制的晶格匹配三结叠层 $\text{Ga}_{0.5}\text{In}_{0.5}\text{P}/\text{Ga}_{0.98}\text{In}_{0.02}\text{As}/\text{Ge}$ (1.86eV/1.39eV/0.67eV) 聚光电池效率达到 40.1% ($135\times\text{AM}1.5\text{D}$, $13.5\text{W}/\text{cm}^2$, 25°C)^[2]。2009 年,该公司通过改进电池工艺,减小电池正面栅极遮光面积,将这种聚光电池效率提高到 41.6% (0.3174cm^2 , $346\times\text{AM}1.5\text{D}$)^[3]。图 1 示出了美国可再生能源实验室测量的这种三结叠层电池的光照 $I-V$ 特性曲线和光伏参数。




图1 美国 Spectrolab 公司研制的晶格匹配三结叠层电池的光照 $I-V$ 特性曲线

2. 晶格失配外延 GaInP/GaInAs/Ge 三结叠层聚光电池

晶格匹配 GaInP/GaInAs/Ge 三结叠层电池中, Ge 子电池的电流密度过大, 未得到充分利用。为了改进叠层电池的电流匹配, 需要适当提高上、中子电池材料的 In 含量, 降低其带隙宽度, 增加电流密度。

2007 年, 美国 Spectrolab 公司发展了一种晶格失配外延技术, 制备出 $\text{Ga}_{0.44}\text{In}_{0.56}\text{P}/\text{Ga}_{0.92}\text{In}_{0.08}\text{As}/\text{Ge}(1.80\text{eV}/1.29\text{eV}/0.67\text{eV})$ 三结叠层电池。其中, $\text{Ga}_{0.44}\text{In}_{0.56}\text{P}/\text{Ga}_{0.92}\text{In}_{0.08}\text{As}$ 子电池材料之间是晶格匹配的, 但其晶格常数比 Ge 大 0.5%。他们在 Ge 与 $\text{Ga}_{0.92}\text{In}_{0.08}\text{As}$ 之间用缓变层使晶格失配得到弛豫, 将失配位错控制在缓变层内, 这样构成的晶格失配三结叠层电池聚光效率达 40.7% ($240\times\text{AM}1.5\text{D}$, $24.0\text{W}/\text{cm}^2$, 25°C)^[2]。

2009 年, 德国 Fraunhofer 太阳能研究所报道, 他们研制的晶格失配 $\text{Ga}_{0.35}\text{In}_{0.65}\text{P}/\text{Ga}_{0.83}\text{In}_{0.17}\text{As}/\text{Ge}(1.67\text{eV}/1.18\text{eV}/0.67\text{eV})$ 三结叠层电池, 在 $454\times\text{AM}1.5\text{D}$ 光强下效率达到 41.1%^[4]。 $\text{Ga}_{0.35}\text{In}_{0.65}\text{P}$ 与 $\text{Ga}_{0.83}\text{In}_{0.17}\text{As}$ 层之间是晶格匹配的, 而 Ge 和 $\text{Ga}_{0.83}\text{In}_{0.17}\text{As}$ 层之间晶格失配达 1.2%, 需要生长缓变层使晶格常数从 Ge 的 $5.658\text{\AA}$ 缓变到 $\text{Ga}_{0.83}\text{In}_{0.17}\text{As}$ 的 $5.723\text{\AA}$, 并在缓变层上生长高 In 组分 $\text{Ga}_{0.77}\text{In}_{0.23}\text{As}$ 薄层, 使其上生长的外延层晶格得到完全充分的弛豫,

以免残留的结构应力在电池有源层中形成位错。

3. GaInAs 为底电池材料的三结叠层聚光电池

如果用窄带隙 GaInAs ($0.9 \sim 1.0\text{eV}$)取代 Ge(0.67eV)作为底电池材料,可进一步提高三结叠层电池的开路电压和改善电流匹配。为此,美国可再生能源实验室发展了一种反向外延生长工艺。在 GaAs 衬底上首先生长晶格匹配的 $\text{Ga}_{0.51}\text{In}_{0.49}\text{P}$ (1.83eV)顶电池,然后经缓变层过渡,外延生长晶格失配的 $\text{Ga}_{0.96}\text{In}_{0.04}\text{As}$ (1.34eV)中电池,最后经缓变层过渡,生长晶格失配度达 2.6% 的 $\text{Ga}_{0.63}\text{In}_{0.37}\text{As}$ (0.89eV)底电池。将电池背面蒸镀金电极后键合到支撑硅片上,剥离 GaAs 衬底,完成正面栅电极和减反射层。测量结果表明,这种反向生长 GaInP/GaInAs/GaInAs 电池,在 326 倍太阳光强下效率为 40.8% [5]。

2010 年,美国 Spire 公司在 IEEE PVSC-35 会议上报道,他们发展了一种双面外延生长 GaInP/GaAs/GaInAs 电池技术,无需将 GaAs 衬底剥离,只需在生长 GaInAs 电池后将 GaAs 衬底表面反转,以生长 GaAs/GaInP 电池,他们所生长的 $\text{Ga}_{0.51}\text{In}_{0.49}\text{P}/\text{GaAs}/\text{Ga}_{0.65}\text{In}_{0.35}\text{As}$ 三结叠层电池聚光效率达到 41.4% (0.3093cm^2 , 光强 $334.3\text{kW}/\text{m}^2$) [6]。

在同一届光伏会议上,日本夏普公司报道,他们用反向外延生长技术,通过改善晶格失配外延 GaInAs 层的质量,所研制的高效 GaInP(1.88eV)/GaAs(1.42eV)/GaInAs(0.97eV)三结叠层电池,在 1 个太阳光强下效率达到 35.8% ,并且指出,这种三结叠层电池的聚光效率将可望达到 45% [7]。

4. 三结叠层聚光电池的极限效率

作为单片集成两端器件,这种三结叠层聚光电池的效率究竟能达到多高?四结、五结甚至六结叠层电池是否有更高的效率?

1996 年, Marti 等指出,考虑到光的吸收和热辐射之间的细致平衡,三结和四结叠层电池极限效率分别为 67.0% 和 71.0% [2]。2003 年, Araki 等在计入太阳光谱的日变化和年变化后得出,三结、四结和五结叠层电池的年平均效率分别为 47.3% 、 49.3% 和 50.5% ,而多于五结以后,年平均效率不再增加 [8]。2009 年, King 等对以 Ge 为底电池的 III-V 族多结叠层电池的效率进行了更实际的模拟计算,指出除考虑细致平衡外,再考虑直接带隙材料的辐射复合损失,最佳化串联电阻和栅电极遮光损失,在 500 倍太阳光强下三结和四结叠层电池极限分别为 47.5% 和 48.5% [3]。可以说,这就是以 Ge 为底电池的三结和四结叠层电池可望实现的效率目标。迄今为止,已有一些关于四结、五结和六结叠层电池的实验报道,但都没有取得比三结叠层电池更好的结果。

5. 硅衬底 II-VI 族三结叠层聚光电池

前面介绍的基本上是在 Ge 衬底上生长的 III-V 族叠层电池。Ge 衬底价格贵, 易碎, 密度大, 尺寸小, 供应有限。能否采用硅衬底呢? 硅衬底便宜, 结实, 密度小, 尺寸大, 来源丰富。然而, 硅上生长 III-V 族电池失配大, 位错密度大, 效率低, 经过多年研究, 进展不大。

2010 年, Xu 等指出, 模拟计算表明 II-VI 族/硅叠层电池的效率, 无论是两结或三结结构, 还是在 1 倍或 500 倍太阳光强下, 都要明显高于 III-V 族/Ge 叠层电池的效率^[9]。由于 II-VI 族材料更具离子性, 对于晶格失配引起的缺陷不那么敏感, 所以, 预期 II-VI 族/硅叠层太阳电池可能大有前途。

6. 结语

III-V 族三结叠层聚光电池的效率已达 41%, 在不远的将来可望达到 45% ~ 50%。关键是完善晶格失配外延工艺, 以获得最佳电流匹配, 同时优化器件工艺, 减小栅极遮光面积和串联电阻损失, 还需要发展高质量、低成本聚光系统, 解决好散热和太阳跟踪问题。高效 II-VI 族三结叠层聚光电池是一个新的发展方向, 其前景有待实验的检验。

参 考 文 献

- [1] Marti A, Arafijo G L. Limiting efficiencies for photovoltaic energy conversion in multigap systems. *Solar Energy Materials and Solar Cells*, 1996, 43: 203—222.
- [2] King R R, Law D C, Edmondson K M, et al. 40% efficient metamorphic GaInP/GaInAs/Ge multijunction solar cells. *Applied Physics Letters*, 2007, 90: 183516.
- [3] King R R, Boca A, Hong W, et al. Band-gap-engineered architectures for high-efficiency multijunction concentrator solar cells // 24th European Photovoltaic Solar Energy Conference, Hamburg, 2009: 55—61.
- [4] Guter W, Schöne J, Philipps S P, et al. Current-matched triple-junction solar cell reaching 41.1% conversion efficiency under concentrated sunlight. *Applied Physics Letters*, 2009, 94: 223504.
- [5] Geisz J F, Friedman D J, Ward J S, et al. 40.8% efficient inverted triple-junction solar cell with two independently metamorphic junctions. *Applied Physics Letters*, 2008, 93: 123505.
- [6] Wojteczuk S, Chiu P, Zhang X B, et al. InGaP/GaAs/InGaAs 41% concentrator cells using bi-facial epigrowth. *IEEE PVSC-35*, 2010.
- [7] Takamoto T, Agui T, Yoshida A, et al. World's highest efficiency triple-junction solar cells fabricated by inverted layers transfer process. *IEEE PVSC-35*, 2010.

- [8] Araki K ,Yamaguchi M ,Kondo M ,et al .Which is the best number of junctions for solar cells under ever-changing terrestrial spectrum? 3rd World Conference on PV Energy Conversion , 2003 ;307 .
- [9] Xu D ,Biegala T ,Carmody M ,et al .Proposed monolithic triple-junction solar cell structures with the potential for ultrahigh efficiencies using II -VI alloys and silicon substrates .Applied Physics Letters ,2010 ,96 :73508 .

撰稿人：廖显伯 向贤碧
中国科学院半导体研究所

突破硅单结太阳能电池转换效率的理论极限

Beyond the Theoretical Limit of Single Junction of Si Solar Cell Photovoltaic Conversion Efficiency

随着化石能源面临的枯竭及碳排放对大气的污染,寻求取之不尽的新能源是当今社会最重大的关注课题。硅由于地球蕴藏量丰富(达 27%),材料与器件制作工艺成熟,硅基太阳能光伏电池已成为新能源发展的主流。

太阳光照到地面的辐射谱覆盖了紫外到红外(300~2600nm)宽光谱范围。硅材料的带隙为 1.1eV,吸收谱带边为 1.1 μm 。然而,由于硅对短波(小于 500nm)光的吸收系数很大,发生在很浅的硅表面层内,而光激发电子、空穴能量远高于硅的带底,是一类过热载流子,它在皮秒时间内通过与晶格振动交换能量,以释热的形态落到了带底,即便如此,这些回到准平衡态的光生载流子也将被表面态的非辐射复合形态俘获消耗,对光伏电池没有贡献。因而,对硅光伏电池的太阳光有效响应带是在 450~1060nm 之内。

根据 1961 年 Shockley 和 Queisser 在理想条件下(即不计体内和表面非辐射复合,只考虑体内辐射复合)理论计算得出硅光伏电池的极限效率为 31%^[1],这就是说对紫外波段和红外波段各有 30% 的太阳光辐射能量未能被充分利用。近半个世纪以来,经过材料和器件工作者的努力,实验室单晶硅光伏电池的最高水平达到 25%^[2],规模化产业水平已接近 20%,而多晶硅薄膜也接近 17%,在世界范围内以此开始建设规模化太阳能光伏电站。然而,就此效率水平而言,并网电价仍高于化石发电三倍以上。如若能降低至 1 元/度水平,就完全能够替代面临枯竭的化石能源发电。除了材料工艺成本外,关键就是如何突破硅材料自身的本征极限,把光电转换效率提高到 40% 的水平之上。

十多年来,世界各国科学家与工程家们做过了大量的探索与努力,提出了诸多创新方案,代表性的主要是不同带隙子电池串联方案,如下:①非晶硅(带隙为 1.7eV)与单晶硅(1.1eV)串联;②Si/a-Si_{1-x}Ge_x/a-Si_{1-y}Ge_y 三带子电池串联;③nc-Si/SiO₂ SL/Si 二带子电池串联;④利用硅材料中深能级中间子带的接力吸收对太阳光红外辐射谱的响应等。

除了中间带接力吸收的运用可兼容在同一个硅光伏电池之内,上述多结电池虽在理想条件下有可能使光电转换理论效率高达 70%,但实验效果至今相差甚远,远未达到单结硅电池 25% 的效率水平,其难点主要是光电流有效输运和电流匹配问题的制约。串联类电池都存在一个反向结输运,只能靠隧道结输

运来解决。然而,隧道输运要求反向结必须高掺杂到 $10^{19}/\text{cm}^3$ 以上,这就可能在有源区材料中引入诸多非辐射复合中心,使输运效率降低。再者,多结电池中为避免器件内部电荷积累,需要对子电池优化设计,使各子电池短路电流优化匹配(即相等),它只能以开路电流最小的子电池为基准,于是就降低了其他子电池转换效率内在潜力的发挥。

多结电池的工艺复杂性大为增加,使电池成本提升。由此可见,在 21 世纪的未来岁月中,“突破单结硅光伏电池的效率极限”是一项意义重大的关键性课题,需要从物理、化学及相关交叉学科的角度取得开拓性创新突破。

突破的思路大致如下:

(1) 红外波段响应的突破。深能级中间带的运用^[3,4]是一项重要的优选途径。中间带的引入可以作为一个接力站,从价带中电子吸收一个红外光子,跃迁到中间带,而中间带的电子可以同时吸收另一波长的光子跃迁到导带,在硅体内形成载流子,经内部分离开的自由电子、空穴参与硅中光生电流的输运。为了获得高的运作效率,要求掺杂浓度要接近 Mott 极限(即大约 $10^{19}/\text{cm}^3$),同时要求杂质带中电子迁移率远低于硅中的电子迁移率,不致使开路电压降落,中间带电子空穴的发射率远大于俘获率,避免硅中非平衡载流子寿命的缩短,这就需要研究选择具体的杂质元素,并运用非平衡掺杂的方法,甚至可以共掺多种适宜的深能级杂质,形成针对不同红外波长的多个接力站,以达到更有效全面提高中间带对太阳辐射光红外波段响应的有效性。另外,在硅电池的背面涂覆一层有效的红外光上转换材料,把红外光转换为可见光,并反射回到电池内部,被电池有源区硅再吸收,也能够适度提高电池对红外波段的响应度,但这属于非线性光学效应,需要高亮度的红外光激发,只适宜对聚光型电池的应用。

(2) 近紫外波段有效响应度的提高是依靠把短波(直至紫外)光,在被硅材料吸收前转变为较长波的可见光,这就避免了硅光伏电池中“热化”和表面复合过程对太阳辐射光的无用消耗。至少能有相当权重的短波光经下转换后,在远离表面处被硅吸收,其所产生的光生载流子参与了对短路电池的贡献。波长下转换^[5]的途径可以运用对宽带隙材料中掺入在可见光区高效率的发光中心来实现,甚至可掺入二类发光中心,通过有效的交叉弛豫,实现对紫外光能量的剪裁,从而得到在硅可适宜吸收的波段中获得二对光生载流子参与短路电流的贡献。也可以考虑利用适宜的纳米金属膜中等离子极化元 SPP 效应来实现。关键是要保证有足够高的下转换效率,哪怕有 10% 也是重要贡献,但要有根本性改观至少要达到 30% 以上。

现在的单晶硅单结光伏电池实验水平,其最高转换效率已达 25%。如果长波段和短波段响应能得到突破,就算其效果仅 25%,在能量转换效率总体上将

再有 15% 的贡献,从而使硅单结电池效率达到 40%,大大超过了 31% 的理论极限,无疑对硅光伏电池的发展,乃至取之不尽、洁净新能源产生的开拓,将具有历史性里程碑式的贡献。

参 考 文 献

- [1] Shockley W,Queisser H J.Detailed balance limit of efficiency fo p-n junction solar cells .J . Appl.Phys .,1961,32(3):510—519 .
- [2] Green M A .The path to 25 percent silicon solar cell efficiency :History of silicon cell evolution . Progress in Photovoltaics ;Research and Applications ,2009,17(3):183—189 .
- [3] Luque A ,Martí A .Increasing the efficiency of ideal solar cells by photon induced transitions at intermediate levels .Phys .Rev .Lett .,1997,78(26):5014—5017 .
- [4] Antolin E,Martí A,Olea J,et al .Lifetime recovery in ultrahighly titanium-doped silicon for the implementation of an intermediate band material . Applied Physics Letters , 2009 , 94(4):042115 .
- [5] Trupke T,Green M A ,Würfel P.Improving solar cell efficiencies by down-conversion of high-energy photons .J .Appl .Phys .,2002,92(3):1668 .

撰稿人：王启明 左玉华
中国科学院半导体研究所

氮化物表面态——何时能探其究竟？

Surface State of Nitrides——What's the Real Face?

GaN 材料作为第三代宽禁带半导体材料的代表，具有高饱和电子漂移速率、高热导率、高击穿场强、热稳定性好等优异的材料特性，是发展微波功率器件的优选材料。

近年来，基于 AlGaIn/GaN 异质结的 GaN 高电子迁移率晶体管(HEMT)的研究飞速发展，但在器件研制过程中，许多基础的材料和器件机理问题仍不是十分清楚，其中，最为神秘的则是 GaN 表面态问题。

一方面，与硅单质半导体不同，GaN 化合物半导体及其合金体系由多种元素构成，其表面悬挂键、缺陷及杂质状态更为复杂；另一方面，与其他化合物半导体不同，纤锌矿结构 GaN 是一种极性半导体，由于其晶格缺乏中心反演对称性，在材料表面会产生极化电荷，从而进一步增加了材料表面的复杂性。

1. 表面态与二维电子气来源

众所周知，AlGaIn/GaN 异质结构具有强极化效应及大导带偏移，使其即使在未掺杂的情况下也可获得高达 10^{13} cm^{-2} 面密度的二维电子气(2DEG)，研制的 GaN HEMT 的输出功率密度比同类 GaAs 器件提高了一个量级。由于异质结中没有使用调制掺杂，如此一来，高密度电子气的来源就成为备受关注的问题。

要弄清二维电子气的来源问题，首先需对 AlGaIn/GaN 异质结构进行分析。电子只可能有以下三个来源：AlGaIn 势垒层、GaN 缓冲层和表面态。为了保证异质结构中 GaN 一侧量子阱的形成，即对电子有限制作用从而形成二维电子气，GaN 缓冲层中的电荷应该为负。假定电子来源于 GaN 层，那么，电子向沟道的迁移将在 GaN 层中留下正电荷，能带弯曲使电子从阱中溢出，于是，可以判定二维电子气不可能来源于 GaN 缓冲层。又因为 AlGaIn 势垒层为非故意掺杂，所以，电子也不可能大量来源于 AlGaIn 势垒层，因此，二维电子气很可能来自于 AlGaIn 势垒层表面态。

关于表面态对二维电子气的贡献，有许多报道从理论和实验两方面来证明。Ibbetson 等通过对 AlGaIn/GaN 异质结构中电荷分布进行静电学分析，提出表面态是二维电子气的实际来源^[1]。如图 1 所示，假定类施主的表面态位于 AlGaIn 带隙中较深的位置，当 AlGaIn 势垒层厚度较薄时，表面态全部被占据，没有二维电子气形成[如图 1(a)所示]；随着 AlGaIn 层厚度增加，由极化场导致表面态

能级相对于 Fermi 能级升高[如图 1(b)所示],一旦 Fermi 能级与表面态能级一致,表面态电子发射,并聚集在 AlGaIn/GaN 界面形成二维电子气。当 AlGaIn 厚度继续增加,表面态能级被清空,二维电子气密度趋于饱和,接近异质界面处正极化电荷面密度。表面态理论不仅解释了二维电子气的来源问题,同时也给出二维电子气面密度随 AlGaIn 势垒层的依赖关系[如图 1(c)所示]。




图 1 AlGaIn/GaN 异质结构表面态与二维电子气形成

Koley 等用扫描 Kelvin 探针显微镜的方法研究了 AlGaIn/GaN 异质结构表面势,也得出了二维电子气来源于表面态这一结论^[2]。

2. 表面态与电流崩塌现象

电流崩塌(current collapse)现象是影响 GaN 高频功率特性的最主要因素。电流崩塌是指 GaN 器件在射频工作条件下,其输出电流摆幅相对于直流条件下明显降低的现象。目前,对于该现象的解释大多也与表面态相关,其中,最为典型的是“虚栅”模型^[3],即器件工作时,沟道中电子被强电场加速成为高能热电子,溢出到沟道阱以外,被表面态或缓冲层陷阱所捕获,被捕获的电子会在栅极附近形成一个具有负电性的“虚栅”(如图 2 所示),对二维电子气起耗尽作用。

在电流崩塌现象获得较好解释的同时,人们也进一步对表面态的本质进行了研究,发现 GaN 表面存在大量的 N 空位,其构成了施主型表面态的主要来源,能级位置在导带底下方 0.37eV 左右。另外,在材料生长和器件工艺过程中,不可避免引入的氧杂质也是表面态的来源之一。

为了抑制电流崩塌现象,最重要的是降低材料表面的表面态密度,为此,




图 2 电流崩塌现象及“虚栅”模型示意图

人们从材料和工艺角度开发了一系列改变表面状态的方法，如 SiN 钝化工艺、表面等离子体处理工艺及 GaN 帽层等。

电流崩塌现象作为长期以来影响 GaN 功率器件输出性能的一大难题，已经在近年来得到了较好的解决，但从物理角度讲，大家对该现象的认识仍不深入，理论研究工作仍很薄弱，钝化等表面处理工艺与表面态之间的作用机理及电流崩塌过程中电子的来源问题仍有待进一步深入研究。

3. 表面态与器件可靠性

目前，影响 GaN HEMT 大规模应用的主要原因是器件仍缺乏坚实的可靠性。GaN HEMT 的可靠性主要指在器件工作过程中漏极电流和射频输出功率的退化。研究表明，栅漏电是器件性能退化的主要原因，其中诸多机理解释也与表面态相关^[4]。

如图 3 所示，在高电压工作时，栅极电子通过量子隧穿到达材料表面并以表面陷阱为跳跃中心沿表面运动形成栅漏电的主要机制。另外一种可能是电子穿过 AlGaN 势垒层到达二维电子气沟道，这种情况仅在较为极端的工作条件下




图 3 栅极漏电及可能的电流途径

有势垒层缺陷形成时才较为明显。理论模拟表明, 在高电压大信号工作条件下, 栅极靠漏侧处的电场强度可达到 $6\text{MV}/\text{cm}$, 沟道内部的电场强度峰值也达到了 $2\text{MV}/\text{cm}$ 以上, 足以导致电子隧穿。

研究发现, 栅漏电流对肖特基势垒接触和材料表面, 特别是栅极漏侧的表面态密度及电场强度非常敏感, 据此, 研究人员开发了许多工艺来改变表面状态, 从而达到大大降低栅漏电流的目的, 如生长 GaN 帽层、利用在特定水溶液中对 GaN 表面进行阳极氧化及 CF_4 等离子体表面处理工艺等。除了表面处理工艺的改进, 通过器件结构的优化设计也进一步提高了器件可靠性, 然而, 目前对器件性能退化的物理过程的描述仍不完善, 要完全弄清性能退化行为与失效物理机制之间的联系还需要研究人员的不懈努力。

综上所述, GaN 表面态虽然给 GaN 器件研制带来一系列问题, 但人们仍通过大量的实验研究找出相应的解决方法, 甚至加以利用。如实验中发现 SiN 钝化以后沟道阱中的电子气密度会增加, XPS 和 $C-V$ 测试发现钝化后异质结表面势垒降低了 1V。钝化为何能降低势垒高度目前还不清楚, 但这开辟了一条用表面处理来剪裁沟道阱能带、优化场效应晶体管性能的新途径。总之, GaN 表面态问题作为 GaN 材料和器件的一大难点, 如能有朝一日完全掌握其产生与变化机理并为我所用, 必将实现 GaN 材料应用的跨越式发展。

参 考 文 献

- [1] Ibbetson J P, Fini P T, Ness K D, et al. Polarization effects, surface states, and source of electrons in AlGaIn/GaN heterostructure field effect transistors. *Applied Physics Letters*, 2000, 77(2): 250—252.
- [2] Koley G, Spencer M G. Surface potential measurements on GaN and AlGaIn/GaN heterostructures by scanning Kelvin probe microscopy. *J. Appl. Phys.*, 2001, 90(1): 337—344.
- [3] Vetury R, Zhang N Q, Keller S, et al. The impact of surface states on the DC and RF characteristics of AlGaIn/GaN HFETs. *IEEE Transactions on Electron Devices*, 2001, 48(3): 560—566.
- [4] Hasegawa H, Inagaki T, Ootomo S, et al. Mechanisms of current collapse and gate leakage currents in AlGaIn/GaN heterostructure field effect transistors. *J. Vac. Sci. Technol. B*, 2003, 21(4): 1844—1855.

撰稿人: 陈堂胜 孔月婵

中国电子科技集团公司第五十五研究所

固态微波器件

Solid State Microwave Devices

从 20 世纪中期固态二端器件和硅基双极晶体管发明至今, 固态微波器件已经走过了 60 多个年头。随着器件工艺的不断进步和新材料、新结构的不断涌现, 固态微波器件正朝着更高频率、更大输出功率、更高效率、更大带宽、更快速度等方向发展。目前的研究领域主要包括传统材料的新工艺、新结构、新应用和新型材料及器件两个方面。传统材料主要指技术相对成熟的硅、GaAs 和 InP 材料。新型材料包括以 GaN、SiC 为代表的宽禁带材料和以锑基化合物半导体材料为代表的窄禁带半导体材料^[1,2]。

1947 年, 贝尔实验室的 Bardeen 和 Brattain 发明了点接触晶体管, 拉开了固态微波器件研究的序幕。1949 年, Shockley 发表了关于 P-N 结双极晶体管 (BJT) 的经典论文, 同年制成了 P-N 结锗晶体管, 晶体管的发明成为“20 世纪最重要的发明”。1958 年, 第一块固态集成电路在美国德州仪器公司诞生, 成功地实现了把电子器件集成在一块半导体材料上的构想, “为现代信息技术奠定了基础”, 从此集成电路取代了分立电路, 开创了电子技术历史的新纪元, “改变了世界”。固态集成电路问世以后, 一直奇迹般地遵循着英特尔创始人之一——Moore 提出的“集成电路上可容纳的晶体管数目, 约每隔 18 个月便会增加一倍, 性能也将提升一倍”的定律发展, 这种奇妙而又夸张的发展速度使得我们生活中电子产品的性能越来越强大, 体积越来越小。1947 年, 贝尔实验室制造的第一个固态晶体管可握在手中, 而 60 年后, 2007 年, 英特尔用 45nm 工艺制造的晶体管仅在一根人类头发的宽度上就能摆放 2000 多个。

固态器件特征尺寸的不断减小是微电子技术的发展趋势。2004 年, 90nm CMOS 器件量产标志着人类开始进入纳米制造时代。固态器件的特征尺寸进入到纳米领域后, 一系列的问题接踵而来^[3]。首先, MOS 器件的沟道长度不断减小, 器件的短沟道效应愈加明显; 其次, 器件的纵横向尺寸缩小, 而电源电压不能以同样比例缩小, 所以, 器件栅介质和沟道内的电场不断增强, 引起强场效应; 再次, 器件尺寸缩小到 100nm 以下时, 要维持足够的栅控能力就必须进一步减小栅氧化层的厚度(等比例缩小), 这将导致电子在氧化层中的隧穿概率增加, 栅漏电流增大。实际上, 在 0.13 μm 节点, 栅极漏电已经开始成为人们担心的问题, 从 90nm 阶段开始, SiO₂ 栅介质厚度达到 1.2nm, 已经非常接近它的物理极限厚度。这一系列问题是否预示着

摩尔定律的神话将被打破？固态微波器件的发展将会达到极限而停止吗？虽然这个问题一次次因为新材料、新结构、新工艺的发明或采用而被解决，但它又一次次随着器件特征尺寸的进一步减小而被重新提出。目前，固态微波器件领域发展的新方向有以下几个方面。

1. 高速 SiGe/Si 异质结器件

利用 SiGe 形成异质结构器件的想法早在 20 世纪 60 年代就已经出现，但由于材料研制工艺的限制，直到 1987 年 IBM 的研究人员才研制出第一支 SiGe 异质结双极晶体管(HBT)，1989 年才真正研制成功具有理想异质结特性的 HBT。SiGe 器件的异质结构突破了传统硅的某些极限，器件在高频和噪声等方面的性能远优于硅，而且 SiGe 器件的成本与硅相近，工艺又与硅工艺兼容，因此，成为当前半导体主流技术之一。

SiGe 微波器件的挑战主要来自于材料制备和温度稳定性两方面。硅与锗的晶格常数相差 4% 以上，所以，在硅上进行高质量、无缺陷 SiGe 材料的外延比较困难，外延层的厚度、组分和应变状态都需要严格控制。SiGe 器件的温度特性也是它面临的一个问题，高温使应变 SiGe 发生弛豫，这样，不仅禁带宽度变大，异质结构的禁带不连续性降低，器件性能受到影响，而且材料的弛豫会在异质结构中形成穿透位错，穿透位错成为杂质扩散的通道，使发射极和集电极短路。

2. 基于 GaAs 和 InP 材料的固态微波器件

GaAs 和 InP 是继硅材料之后发展起来的第二代半导体材料。与硅器件相比，基于 GaAs 材料的器件和电路损耗小、噪声低、频带宽、输出功率大，是微波、毫米波通信和军用相控阵雷达等应用领域的理想器件。虽然 GaAs 的市场不断受到 SiGe、Si RFCMOS 和 GaN 等技术的挑战，但它在性能、价格、技术成熟度等方面的综合优势仍然使其当之无愧地成为目前固态微波器件的主流技术。InP 是继 GaAs 技术之后发展起来的面向更高频率微波器件的技术，是目前半导体技术中少数可用于 W 波段及更高频率器件和电路的技术。一般认为，W 波段是 GaAs 基器件的极限，而更高频段则是 InP 的天下。

GaAs 和 InP 基器件和电路，目前存在的问题主要是超高频、超强场下载流子的输运规律问题。GaAs、InP 基器件在超高频毫米波领域具有非常诱人的应用前景，但随着频率的增加，器件的特征尺寸逐渐减小到纳米尺度，强场效应、量子效应、短沟道效应的影响日趋严重，沟道载流子随着这些效应的变化规律及对器件性能的影响目前还未被完全认知；另一方面，超高频、超强场器件和电路的热效应、信号耦合等问题也是亟须解决的问题。

3. 宽禁带 GaN 基微电子材料和器件

宽禁带 GaN 基半导体材料具有宽直接带隙、高临界击穿电场、抗辐照、强极化、易于形成异质结构等特点,是非常理想的新一代高频、大功率微电子材料。基于 GaN 基材料研制的 HEMT,频率和效率高,输出功率大,体积小,重量轻,在军用和民用领域均具有重要应用潜力。日本、美国等纷纷投入巨额资金开展研究,目前已经实现了部分产品在部分领域的实用化。但是,GaN 基微电子材料和器件的基础问题研究进展滞后于应用开发研究进展,此领域仍有诸多“具有 GaN 特色”的重大物理问题并没有先于或随着产品进入市场而解决,如材料中杂质和缺陷的种类、产生和运动规律、界面态和表面态的性质、极化效应与材料和器件可靠性的关系等。

GaN 基材料的极化系数较大,因此,即使是非故意掺杂的异质结构材料(如 AlGaIn/GaN),也能仅凭极化效应在异质结界面处形成数量级为 10^{13} cm^{-2} 的二维电子气。但是,极化效应对 GaN 基材料来说是一把双刃剑。一方面,极化效应诱导形成的高密度二维电子气有利于提高功率器件的输出功率;另一方面,压电极化效应的大小会随着外加电场的变化而变化(逆压电效应),这给材料和器件的可靠性带来了影响。

因目前极难得到高质量的高纯半绝缘 GaN 同质衬底,因此,只能在晶格和热膨胀系数不匹配的异质衬底上用金属有机化学气相沉积(MOCVD)或分子束外延。通过异质结构设计产生量子限制效应、应变效应、极化效应和局域化效应等,可实现异质结构材料和器件的能带剪裁和性能调控。例如,在传统的 AlGaIn/GaN HEMT 材料中引入 2~3 个原子层厚的 AlN 插入层,就能更好地限制沟道二维电子气,并降低势垒层对沟道电子的合金散射,提高沟道电子的输运特性。再如新型 InAlIn/GaN HEMT 结构,能够通过调节 In 和 Al 的比例实现晶格完全匹配生长,因此,可以将材料的压电极化效应降为零,消除其对材料和器件可靠性的影响。但同样,这些“具有 GaN 特色”的效应也有不利的地方,应力场中的原子运动和结合机制比较复杂,大失配异质材料的外延过程会伴随着缺陷的形成,而缺陷又会在热场、应力场等的多重作用下增值、运动,缺陷的输运又反过来影响异质外延过程和异质结构材料的极化和应变,多方面的作用与反作用过程使这种材料体系变得既复杂、又神秘,并且充满了不断吸引人去探究、揭示的魅力。

4. 铋基化合物半导体材料和器件

铋基化合物半导体主要指以 Ga、In、Al 等Ⅲ族元素与 Sb、As 等Ⅴ族元素化合形成的二元、三元和四元化合物半导体材料^[4,5],具有最高的电子迁移

率和饱和电子速度,带隙很小,十分适合研制超高速、低功耗、微波毫米波器件和电路。20世纪50年代,窄禁带半导体曾受到科学界的广泛关注,但后来人们认为它的热稳定性太差不适合微波应用,因此被冷落了近半个世纪。后来随着材料技术的发展,在GaAs和InP衬底上成功研制出AlSb/InAs异质结构材料,窄禁带半导体又因其很多独特的性质受到科学家们的青睐,目前已经在基于锑基化合物半导体HEMT和HBT电路方面取得了突破,S、X、Ka、W波段的放大器已经实现。

锑基化合物半导体技术面临的问题首先是高质量、低缺陷密度材料的制备问题。锑基化合物的晶格常数在 $6.1\text{\AA}$ 左右,很难得到晶格匹配的衬底材料,因此,微波器件材料一般也是生长在晶格不匹配的异质衬底上,同其他化合物半导体材料一样面临应力、缺陷和位错的问题。另一方面,窄禁带半导体技术还面临一系列与材料本身特性有关的问题,如禁带宽度小带来的导带与价带的相互影响问题、热稳定性问题、载流子的输运规律问题等,这些问题在相当长一段时间内将是我们不得不面对并急需解决的问题。

固态微波器件的出现改变了我们生活的世界,把人类文明带进了现代电子时代,使人与人之间的距离越来越近,整个地球成为一个“地球村”。器件特征尺寸的减小把我们带进了纳米时代,使我们可以控制的尺寸越来越小,甚至可以控制单原子的排列。掺杂工程、应变工程、能带工程、极化工程等一系列随着新材料、新结构、新工艺的出现而被引进固态微波器件和电路领域的新理论,促成了今天微电子百花齐放、日新月异的局面。

参 考 文 献

- [1] Colantonio P, Giannini F, Limiti E. High Efficiency RF and Microwave Solid State Power Amplifiers. New York: Wiley, 2009: 1—42.
- [2] 郑新. 三代半导体功率器件的特点与应用分析. 现代雷达, 2008, 30(7): 10—17.
- [3] 肖德元, 陈国庆. 半导体器件发展历程及其展望. 固体电子学研究进展, 2006, 26(4): 510—515.
- [4] 赵正平. 固态微波器件与电路的新进展. 中国电子科学研究院学报, 2009, (4): 329—335.
- [5] Bennett B R, Magno R, Boos B, et al. Antimonide-based compound semiconductors for electronic devices: A review. Solid-State Electron., 2005, 49: 1875—1895.

撰稿人: 王晓亮
中国科学院半导体研究所

电 磁 黑 洞


Electromagnetic Black Hole

广义相对论中的黑洞是引力场很强的区域,以致任何接近的物体或光都难以逃出^[1]。类似热力学中的理想黑体,黑洞只有一个单向表面,它吸收所有的光或粒子而没有任何反射,因此,没有物体能从黑洞里逃逸出来。在广义相对论中,物质的能动量密度导致的弯曲时空结构决定了周围物体运动或光的传播方向,这种现象类似于光或者电磁波在弯曲空间或非均匀新型人工电磁材料中的传播。事实上,经典力学和光学之间确实存在这样的对应关系,力学中决定粒子运动的最小作用量原理对应于光学中决定光传播的 Fermat 原理。

光学和力学的这种对应使得非均匀介质中光或电磁波的传播理论可以对应于引力场中的粒子或光的轨迹,从而通过观察电磁波在非均匀新型人工电磁材料介质的传播并进行仿真计算来模拟粒子在极端引力场中的运动^[2,3]。因此,研究这种所谓的电磁黑洞或者光学黑洞,即可研究某些天文现象。在最近的一篇理论工作中,美国学者提出了基于新型人工电磁材料的光学黑洞概念,数值模拟结果显示这种黑洞能在任意方向和较宽的频带范围以较高的效率吸收光波^[4]。之后,我们在微波频段首次用实验演示验证了电磁黑洞,如图 1(a)所示^[5]。这种黑洞材料由非谐振和谐振结构的新型人工电磁材料组成,能够螺旋式地吸收全向电磁波[如图 1(b)所示],并且利用新型人工电磁材料局域性地控制电磁场,使电磁黑洞几乎没有反射。结果表明,在微波段,电磁黑洞的吸收率能够达到 99%。因此,或可用于模拟天体黑洞的性质(其强大引力造成时空弯曲导致任何邻近物体和电磁波都被螺旋式地卷入)。



(a)



(b)

图 1 人工电磁黑洞(a)及其对电磁波螺旋式地吸收(b)

然而,目前的电磁黑洞只能模拟真实黑洞的部分特性,与真正意义上的黑洞还有较大差距。因此,如何应用新型人工电磁材料模拟真实黑洞的全部特性是一个世界性难题。在黑洞的视界内,黑洞的引力非常强大,甚至连光线也无法逃脱,因此,其内部光线不可逆。现在的电磁黑洞内核由一个损耗很大的电磁材料构成,尽管将入射其中的电磁波几乎完全吸收,但其各向同性的性态使电磁波还是可逆的(尽管返回的光线非常少)。所以,模拟真实黑洞还有一系列的问题亟待解决。如何利用人工电磁材料来模拟视界?如何验证黑洞的霍金辐射?如何模拟黑洞内部强大的吸引力?通过未来进一步的理论分析和基于新型人工电磁材料的实验设计^[6],加深对电磁黑洞的理解和认识,从而开创一个新的研究领域。

参 考 文 献

- [1] Kox A J, et al. The Collected Papers of Albert Einstein. Princeton: Princeton University Press, 1997.
- [2] Pendry J B, Schurig D, Smith D R. Controlling electromagnetic fields. Science, 2006, 312: 1780—1782.
- [3] Genov D A, Zhang S, Zhang X. Mimicking celestial mechanics in metamaterials. Nature Physics, 2009, 5: 687.
- [4] Narimanov E E, Kildishev A V. Optical black hole: Broadband omnidirectional light absorber. Applied Physics Letters, 2009, 95: 041106.
- [5] Cheng Q, Cui T J, Jiang W X, et al. An omnidirectional electromagnetic absorber made of metamaterials. New J. Phys., 2010, 12: 063006.
- [6] Cui T J, Smith D R, Liu R. Metamaterials—Theory, Design, and Applications. New York: Springer, 2009.

撰稿人: 崔铁军 程 强
东南大学毫米波国家重点实验室

超级人工电磁材料

Metamaterials

超级人工电磁材料(metamaterials)亦称超材料、特异材料、新型人工电磁材料(早期亦被称为左手材料或左手媒质),它是一种周期/非周期人造结构^[1,2]。当结构单元尺寸远小于波长(通常为十分之一波长)时,其宏观电磁响应与材料相似,因此,可用等效媒质描述^[3],其性质不仅取决于人造结构的组成材料,而且与结构单元的形状、结构的空排布密切相关。与自然材料或其他复合材料相比,超级人工电磁材料可具有特殊性质。通过在关键物理尺度上的结构有序设计,可以突破某些表现自然规律的限制,从而获得超出自然界固有的普通性质的超常材料功能。我们知道,任何一种材料对电磁波都会有特定的响应,其中,对电场的响应可以用介电常数来表征,对磁场的响应可以用磁导率来表征。绝大部分自然界存在的材料对电场的响应为相对介电常数 $\epsilon > 1$ 的一些离散值,而对磁场的响应为相对磁导率 $\mu = 1$ (少数磁性材料除外)。通过人工电磁材料可以实现更加丰富和广泛的介电常数值和磁导率值,达到许多自然材料不能达到的值域空间,甚至可以控制材料在空间的非均匀分布,从而实现许多常规材料无法实现的性质和功能。

光学变换(或称变换光学)^[4]为应用超级人工电磁材料控制电磁波奠定了理论基础。因此,超级人工电磁材料在科学中的意义和工程中的潜在应用受到人们越来越多的重视。在远小于电磁辐射波长的尺度上,通过改变微结构单元的特征结构和尺寸,人工电磁材料与电磁波发生相互作用,可以控制和改变电磁波的传播和分布,实现普通材料不能实现的完全电磁隐身^[5~7]、模拟电磁黑洞^[8]等新奇现象。同时,在与电磁辐射相关的应用领域,人工电磁材料也将带来广阔的前景。例如,作为介质材料,人工电磁材料可以用于无线通信、车载雷达、机载天线等;利用负折射的性质,人工电磁材料可以在光学显微镜、核磁共振成像、数据存储和光刻技术等方面发挥作用;在太赫兹频段,人工电磁材料有望用于无损检测、医疗成像、术中成像和机场安检等。

目前,超级人工电磁材料的理论、设计和应用研究已经成为物理学、电磁学和材料学的研究热点。在美国,各大基金组织(如 NSF、DARPA、MURI 等)纷纷投巨资支持这种新型人工电磁材料的研究,期望在这一领域占据领先地位。在欧洲,新型人工电磁材料的发展被列入第七期欧盟科技框架计划,该计划是当今世界上最大的官方科技计划之一,瞄准了未来科技的发展方向。同样,在

日本、韩国、新加坡、中国等国家,政府也投入了大量的人力和物力来组织相应的研究和开发。工业界非常重视这种新型材料潜在的应用和巨大的市场前景,波音、丰田、Sony、LG 等大型跨国公司纷纷参与了相关的研究计划。新型电磁材料的发展必将引起材料科学的一场革命,并同时带动一系列相关学科和产业的快速发展。

虽然各国科研工作者对超级人工电磁材料展开了广泛而深入的研究,但这一领域还有很多问题亟待解决:①超越变换光学的调控电磁波理论;②极端媒质参数(介电常数/磁导率为负、为零、或者很大)超级人工电磁材料的设计与实现,各向异性超级人工电磁材料的设计与实现,可调控超级人工电磁材料的设计与实现;③太赫兹波和光波段超级人工电磁材料的设计与实现;④宽频带和低损耗超级人工电磁材料的研制,实现现有材料不可替代的新奇应用。

参 考 文 献

- [1] Veselago V G .The electrodynamics of substances with simultaneously negative values of permittivity and permeability .Sov .Phys .Usp .,1968,3 :509 .
- [2] Pendry J B, Holden A J, Robbins D J, et al .Magnetism from conductors and enhanced non-linear phenomena .IEEE Transactions on Microwave and Techniques ,1999,47 :2075 .
- [3] Cui T J, Smith D R .Metamaterials-Theory ,Design ,and Applications .New York :Springer ,2009 .
- [4] Pendry J B, Schurig D, Smith D R .Controlling electromagnetic fields .Science ,2006,312 :1780 .
- [5] Schurig D, et al .Metamaterial electromagnetic cloak at microwave frequencies .Science ,2006,314 :977 .
- [6] Liu R, Ji C, Mock J J, et al .Experimental verification of a broadband ground-plane cloak .Science ,2009,323 :366 .
- [7] Ma H F, Cui T J .Three-dimensional broadband ground-plane cloak made of dielectrics .Nature Communications ,2010,1 .
- [8] Cheng Q, Cui T J, Jiang W X, et al .An omnidirectional electromagnetic absorber made of metamaterials .New J .Phys .,2010,12 :063006 .

撰稿人: 崔铁军 蒋卫祥
东南大学毫米波国家重点实验室

多层媒质的电磁并矢 Green 函数

The Electromagnetic Dyadic Green's Function for General Multilayered Media

Green 函数的概念源于英国数学家 Green，他在 1830 年首次引入 Green 函数来求解服从初值或边界条件的非齐次微分方程。此后，借助 Green 函数来求解服从边界条件的微分方程或积分方程便成为一种常用的方法。Green 函数实际上是一个线性系统对一个“点源”激励的响应函数。物理学中也大量使用 Green 函数，尤其在量子场论、统计场论和电磁学中。由于电磁场为矢量场，相应的 Green 函数一般为并矢形式，又称为电磁并矢 Green 函数，它在基于电磁场积分方程的分析方法中占有极其重要的地位。

随着现代微波毫米波集成电路的快速发展，人们越来越注重对多层电路的严格、精确建模与快速仿真。多层电路可以建模为多层媒质结构，实际上，大气层探测、地球物理勘探、遥感等问题也可建模为多层媒质结构^[1]。基于混合位的电场积分方程法特别适合于分析多层媒质结构的电磁问题。由于 Green 函数的核心作用，该方法只需要对多层媒质结构中的导体表面进行离散，即采用一组适当的局域基函数来展开导体表面的未知电流，进而将积分方程通过适当的测试步骤转化为线性代数方程组，这种方法称为矩量法或加权余量法。在求解线性代数方程组后，就可获得导体表面的电流分布，进而可导出其他相关电磁参量。仅对多层媒质结构中导体表面进行离散就意味着代数方程组的阶数相对较低，从而计算量较小，但前提是必须能够精确、快速地计算多层媒质的电磁并矢 Green 函数。

利用多层媒质结构的几何特征，通过傅里叶变换可以得到闭式谱域 Green 函数，进而借助傅里叶-贝塞尔变换可以表示出空域 Green 函数^[1]，这个表达式通常称为 Sommerfeld 积分，积分核是 Bessel 或 Hankel 函数。谱域 Green 函数的极点和支点的奇异性及 Bessel 或 Hankel 函数的高振荡性导致 Sommerfeld 积分的数值计算非常耗时。当场-源距离很大时，可以采用最陡下降路径积分法快速计算，其核心思想是在复平面上选取一条变形的积分路径，使无穷积分快速收敛^[1]。在理论上，最陡下降路径积分法也可用于场-源距离较小的情形，但此时必须考虑谱域 Green 函数在“漏波极点”处的留数对积分的贡献。1988 年，Fang 等提出了离散复镜像方法，为谱域 Green 函数反演到空域的快速半数值方法奠定了基础^[2]。离散复镜像方法实际上是针对电磁并矢 Green 函数水平分布

的一个快速算法,并且它还涉及谱域 Green 函数在“表面波极点”处的留数。谱域 Green 函数在复平面上模式极点的定位是一项比较困难的工作,但它对于谱域 Green 函数到空域的精确反演确是非常重要的,尤其是对多层媒质结构层数较多和层间距离较大的情形。二十多年来,学术界对多层媒质电磁并矢 Green 函数的研究取得了许多成果。1995 年,广义矩阵束方法被应用于复镜像部分的拟合。1996 年, Aksun 提出了两级复镜像方法。1997 年, Michalsky 等基于传输线 Green 函数模型系统推导了一般多层媒质 Green 函数,并研究了相应的混合位电场积分方程^[3]。2006 年, Kourkoulos 等提出以球面波函数混合柱面波函数的矢量拟合方法。2007 年, Wu 等提出一种快速全模式极点定位算法,次年发展到多层形式。2008 年, Yuan 等提出一种同时考虑空域水平分布和垂直分布的二维离散复镜像方法。2009 年,作者提出一种针对三层媒质结构精确定位全部模式极点的数学同轮变换算法^[4]。2010 年,基于逐步频率扰动的精确定位漏波极点的算法和基于逐步损耗扰动的精确定位表面波极点的算法被提出^[5]。

到目前为止,针对多层媒质电磁并矢 Green 函数水平分布的快速算法已经达到可以实际应用的程度,但具有通用性的能够同时精确计算水平分布和垂直分布的 Green 函数快速算法还很不成熟,有待学术界继续深入研究。

参 考 文 献

- [1] Chew W C. Waves and Fields in Inhomogeneous Media. New York: Van Nostrand, 1990.
- [2] Fang D G, Yang J J, Delisle G Y. Discrete image theory for horizontal electric dipoles in a multilayered medium above a conducting ground plane. IEE Proc. H, 1988, 135(5): 297—303.
- [3] Michalsky K A, Mosig J R. Multilayered media Greens functions in integral equation formulations. IEEE Transactions on Microwave and Techniques, 1997, 45: 508—519.
- [4] Hu J, Zhou H X, Song Z, et al. Locating all the modes of Green's function for a three-layered medium based on the path tracking algorithm. IEEE Trans. on Antennas Propagat., 2009, 57(8): 2315—2322.
- [5] Song Z, Zhou H X, Hu J, et al. Accurate evaluation of Green's functions in a layered medium by SDP-FLAM. Science in China Series F: Information Sciences, 2009, 52(5): 867—875.

撰稿人: 洪 伟 周后型 宋 喆 胡 俊 郑开来
东南大学毫米波国家重点实验室

射频电路的非线性行为描述与建模

Nonlinear Behavioral Characterization and Modeling of Radio Frequency Circuits

射频电路是无线通信、雷达、制导、射电天文、遥感等系统中的关键部件,通常可以分为线性射频电路和非线性射频电路。线性射频电路主要用于改变信号的幅度,而非线性射频电路主要用于信号的产生和频率的变换。实际上,线性射频电路也或多或少存在一定的非线性效应。射频电路非线性现象的精确行为描述与建模对射频电路的设计有重要的意义,是目前微波领域的研究难题与热点之一。

射频电路的非线性现象主要包括谐波特性、组合频率特性、互调特性、杂散特性、记忆效应等^[1,2]。射频电路常用的非线性行为描述与分析方法有幂级数法^[1]、负载牵引、时域分析方法^[2]、谐波平衡法^[2]、Volterra 级数法^[3]、神经网络方法^[4,5]、X 参数法^[6]等。

幂级数法比较简单,容易计算和分析,适用于无记忆的弱非线性电路。

负载牵引是指通过改变输出端负载,测量被测射频电路参数和特性的方法。

时域分析方法需要求解射频非线性电路的时域微分方程组,因而对电路的规模有限制,否则要做大量的矩阵运算,而且在时域中很难分析微波电路的分立元件。时域分析方法需要选择合适的仿真算法才能得到准确的结果。

谐波平衡法和 Volterra 级数法都是频域分析方法。谐波平衡法主要用于分析大信号激励的强非线性电路,如功率放大器、混频器、倍频器、振荡器等,可仿真非线性电路中的噪声、增益压缩、谐波失真、振荡器的相位噪声、功率放大器的互调失真和效率等。Volterra 级数法是对泰勒级数法的扩展,主要用于小信号激励的弱非线性电路,相当于有记忆的泰勒级数法,是分析弱非线性射频电路的常用方法。Volterra 级数法的参数会随着阶数和记忆长度的增大而急剧增加,因而会导致参数多、计算量大、收敛慢。

神经网络是模拟大脑基本特性而提出的,是对生物神经网络的抽象和简化。神经网络能逼近任意连续的非线性函数,且具有灵活的学习方式,已经成为非线性建模的研究热点。近年来,在射频非线性电路的行为描述和建模方面,神经网络方法已经得到了广泛应用。

X 参数法是由 Agilent 公司提出的,可以较全面地描述射频器件或电路

的线性和非线性特性。X 参数的建立基础和 S 参数一样，都是基于对电路端口入射波和反射波的描述。但是，与 S 参数相比，X 参数增加了端口组合频率上的入射波和反射波信息。利用 X 参数可以对器件的非线性特性建模，这样，就可以对射频电路非线性参数进行分析，如功率放大器的交调特性和邻道泄漏比 (ACLR) 等。

虽然射频电路非线性行为描述和建模的方法很多，但都有一定的局限性，往往要综合考虑计算精度、复杂度和算法稳定性等。对于有记忆的非线性射频电路，在不同的激励信号下，通常会呈现出不同的动态非线性特性。因此，描述射频电路的模型会更加复杂。

在非线性射频电路中，如振荡器、混频器、倍频器等，非线性模型能够帮助设计者合理使用电路的非线性。在线性射频电路中，非线性模型能够帮助设计者减少各种非线性失真，如功率放大器线性化技术^[7]等。

虽然关于射频电路非线性行为描述与建模已有几十年的历史，而且已积累了丰富的研究成果，但还远没有实现对射频电路非线性特性的全面、快速和精确定量表达。根据射频电路非线性行为的物理机理及实验测量，系统地建立其精确且自适应的非线性行为模型是该科学问题的重要发展方向。

参 考 文 献

- [1] Vuolevi J H K, Rahkonen T. Distortion in RF Power Amplifiers. Boston: Artech House, 2003.
- [2] Maas S A. Nonlinear Microwave and RF Circuits. 2nd ed. Norwood: Artech House, 2003.
- [3] Zhu A, Pedro J C, Brazil T J. Dynamic deviation reduction based Volterra behavioral modeling of RF power amplifiers. IEEE Trans. on Microw. Theory Tech., 2006, 54(12): 4323—4332.
- [4] Xu J, Yagoub M C E, Ding R, et al. Neural-based dynamic modeling of nonlinear microwave circuits. IEEE Trans. on Microw. Theory Tech., 2002, 50(12): 2769—2780.
- [5] Zhai J, Zhou J, Zhang L, et al. Behavioral modeling of power amplifiers with dynamic fuzzy neural networks. IEEE Microwave and Wireless Components Letters, 2010, 20(9): 528—530.
- [6] Vye D. Fundamentally changing nonlinear microwave design. Microwave Journal, 2010, 53(3): 22—38.
- [7] Kenington P B. High Linearity RF Amplifier Design. Boston: Artech House, 2000.

撰稿人：翟建锋 周健义 洪 伟
东南大学毫米波国家重点实验室

微波毫米波功率合成

Microwave and Millimeter-wave Power Combining

在雷达、通信、测控、对抗等电子系统中,经常会有功率合成问题。通过功率合成,可以提高电子系统发射功率,增大其探测和作用距离。从功率合成基本构架来说,主要有以下几类合成方法:芯片级合成、电路级合成、空间功率合成。在实际应用系统中,高功率获取往往是采用多种合成技术组合完成,即由芯片级合成得到单器件输出能力提升,并由电路级合成实现单个高功率单元,最后组合这样多个高功率单元,使之通过特定的空间传播,从而合成得到更大的发射功率,或在特定方向和特定距离处形成高能量密度的电磁波束。

与真空电子器件相比^[1],在微波毫米波高功率应用系统中的微波毫米波固态功率合成技术主要具有利用固态半导体器件^[2]的优势。

在芯片级合成中,采用同一半导体工艺完成多芯合成,实现单器件输出能力的倍增。目前,限制单器件合成输出功率的主要因素有合成电路损耗、多热源散热及电磁兼容问题。在提高单器件输出能力方面,从半导体材料、工艺本身入手,寻求新器件、新方法,特别是高耐压半导体材料(如 GaN)的应用是芯片级合成的新趋势。对于较低功率的芯片级合成,采用常规集成电路结构的合成网络,如 wilkinson 功率分配/合成器及其级联网络,在少于 8 个合成支路情况下,可以在 20% 的频带内实现大于 70% 的合成效率。而对于高功率芯片级合成,低损耗的合成网络是关键。如何实现低损耗、宽带、高效率的合成网络是这类研究面临的主要问题。

在电路级合成中^[3],结合多种电路工艺,如单片集成电路、混合集成电路及三维集成电路工艺,实现多器件功率合成,提高输出功率。随着工作频率的不断提高,一方面,传输线损耗增大,另一方面,传统的两路并行及其级联形式的功率合成网络的损耗也增大,使得微波毫米波功率合成效率的提高成为研究重点。因此,这类研究主要面临的是新型低损耗传输线、高效多路并行功率合成网络及多个高功率固态器件的集成方法问题。

准光空间功率合成^[4]面临的最为严峻的挑战是多个高功率固态器件高密度工作条件下的热传导问题。自由空间功率合成^[5]由于受物理机理和传输线最大功率容量限制,单器件或电路无法承受过高的峰值功率,而选择在自由空间中实现高功率叠加。空间功率合成涉及多方面的研究,如高功率微波源研究、高功率天线设计、天线布阵对合成效率影响、具有一定带宽的高能电磁脉冲在大

气中传播的机理及影响等。高功率微波天线辐射技术决定着能否将微波有效辐射出去。与传统天线不同,应用于高功率微波天线需避免空气击穿现象。空间功率合成阵列中,单元个数、天线单元特性决定了能否在目标处实现期望的功率密度,这需要控制阵列方向图的性能、形状,以调整能量在空间的分布,如抑制栅瓣的出现、增加目标所在空间固定立体角内的功率比例、调整主瓣宽度等。改变相位可以实现主波束的任意指向,而调整阵元位置则可以改变方向图的特性。为在合适的时间与地点实现多个源的功率叠加,需要精确控制各个源的相位。

功率合成技术是突破太赫兹频段^[6]较高功率获取的有效途径之一。对于更短工作波长,低损耗传输媒介及相应合成网络将是这类研究首要解决的难题,多支路同相位关系保障是这类研究面临的关键。

参 考 文 献

- [1] Levush B, Abe D K, Calame J P, et al. Vacuum electronics; Status and trends-2007. IEEE Radar Conference, 2007; 971—976.
- [2] Haddad G I, Trew R J. Microwave solid-state active devices. IEEE Transactions on Microwave and Techniques, 2002, 50(3): 760—779.
- [3] Epp L W, Hoppe D J, Abdur R, et al. A high-power Ka-band (31~36GHz) solid-state amplifier based on low-loss corporate waveguide combining. IEEE Transactions on Microwave and Techniques, 2008, 56(8): 1899—1908.
- [4] DeLisio M P, York R A. Quasi-optical and spatial power combining. IEEE Transactions on Microwave and Techniques, 2002, 50(3): 929—936.
- [5] Jia P, Chen L Y, Alexanian A, et al. Broad-band high-power amplifier using spatial power-combining technique. IEEE Transactions on Microwave and Techniques, 2003, 51(12): 2469—2475.
- [6] Moussessian A, Wanke M C, Li Y, et al. A terahertz grid frequency doubler. IEEE Transactions on Microwave and Techniques, 1998, 46(12): 1976—1981.

撰稿人: 樊 勇 徐锐敏
电子科技大学电子工程学院

统计电磁学

Statistic Electromagnetics

经典电动力学是一个基于实验结论的宏观电磁理论。统计力学^[1]给出了在分子层面上粒子运动概率的统计描述。量子电动力学^[2]则对波长与经典原子半径相比拟时光子与电子能级间的微观定量关系给出描述。物质在分子层面运动所引起的电磁统计波动尚未被目前的宏观和微观理论所涉及,这一随机运动是宏观电磁不确定性的根源所在。这些分子层面上的运动已经无法采用经典电磁叠加原理来描述,犹如电子围绕原子核旋转而并不因同步辐射而最终耗尽能量落到原子核上这一通过经典电动力学所得出的悖论而最终引入了划时代的、全新的理论——量子力学理论^[3]所替代一样,我们需要一个新的理论——统计电磁学。

实验表明,当频率不断提高(波长不断减小)时,物质所表现出来的宏观电磁特性具有明显的不确定性,无论是源(随机源)还是场(测量观测仪器),均具有这种不确定性。当然,我们总是试图先假设观测仪器是“绝对”准确稳定的,则剩下来的就是我们真正需要研究的源的不确定性。与量子电动力学不同之处在于,这里研究的是“全局”量子化的统计平均特性,而不是量子电动力学的“点”特性。

既然是“全局”特性,就表明它不但与物质的属性相关,而且还与其分布和形态相关,这就使得统计电磁学具有多样、多重和复杂性。需要给予简化的平面波光子加上统计运动的属性,这将是一条研究的思路。

以下是一个宏观观察事实:通过 Maxwell 方程组可以精确地描述单一强信噪比电磁辐射传播问题,电磁场呈现为良好的确定性问题。理论上讲,所有宏观电磁场问题均可以采用经典 Maxwell 方程组来描述和求解,但对于包含有线缆线束、细小搭接机箱和各类有源器件下的空间,任意一点、任意时刻的电磁场值及其频谱的研究似乎已经无法采用确定的 Maxwell 方程来求解,一门需要探讨的统计电磁学正在孕育而生。无论是场源还是结构,均采用统计的概念来描述,空间场点的电磁场也是统计意义下的值。

实验室中,对于厘米以下频段可以精确地测定电磁场分布,随着频率不断提高,在毫米到亚毫米波段,对电磁场的测定开始显现出明显的不确定性。例如,同样的实验室条件下,不同时间测试的结果是不一致的。测量仪器本身也具有不确定度,对精确测量趋于其极限,这一点又从另一个侧面证实了海森堡

测不准原理($\Delta x \cdot \Delta p \geq h$)。可以想象,当电磁波波长不断减小,且与结构中微小的拓扑尺寸相比拟,同时又将不断接近金属表面电子逸出能量(1eV 量级,它对应着 241.5THz 或 $1.24\mu\text{m}$ 波长),此时,宏观电磁场表现出明显的统计特性。

经典 Maxwell 方程建立的是一个确定性场源关系,即在确定性源的激励下通过确定性媒介在确定性时刻和确定性场点处所建立的电磁场。在现实复杂的电磁设备中,多频段、多场源、结构材料的不确定性和媒介分布多样性,均使得精确测量某一个特定场点的时域和频域特性变得不稳定。换言之,该点处的场值,无论是时域还是频域,均呈现出一定的不确定性。难道是经典 Maxwell 方程有问题了吗?它不再适用于复杂电磁环境下精确求解电磁问题了吗?答案是:它没有错,但它只能精确描述简单确定的电磁问题,而对于现实复杂电磁环境,由于包含了大量的统计稳定但时变杂散的源及媒介的因素,所以,需要对 Maxwell 方程引入统计的概念,使其解在统计意义下收敛和成立。这一点犹如牛顿定律没有错,只是在物体运动速度接近光速时它不再精确,而必须代之以爱因斯坦狭义相对论理论。

在微观世界中,各类(不)带电粒子或离子时刻在相互作用着,世界本身就是充满着运动、随机和不确定性的。而在宏观世界中,这些微观中的不确定性却由于其稳定的统计特性,而显现出确定性的稳定属性,如牛顿定律和经典电磁学。经典电磁学中的场源具有微观杂散运动的统计稳定性。大量场源具有统计特性。

在微观世界中,动量与所能观察的空间精度间满足测不准原理。在牛顿的宏观力学中,人们并未遇到物体的动量和位置无法精确测量的问题,这是因为宏观物体的动量很大,即便在极高的测量精度下,该物体的位置也能极为精确地确定。例如,一个质量为 10g 的子弹,其出膛速度为 10km/s,倘若我们采用的测速仪器精度高达 1/10000,则根据测不准原理,能够确定某一瞬时子弹的位置精度可达 $6.626 \times 10^{-32}\text{m}$,这个值远远超过当今所有测量仪器的精度,所以,人们感觉不到这一测不准原理的存在。同样的,倘若试图观察一个电子的位置,已知电子质量为 $9.11 \times 10^{-31}\text{kg}$,运动速度和测速精度仍分别为 10km/s 和 1/10000,此时,将无法精确知道此电子在某一瞬时的位置,而只知道它在直径为 0.727mm 的球体里。

类比到现实物理空间中,我们也发现所要讨论的频率越高,或场点与源点间距离越大时,该场点处的电磁场就越不确定,尤其是在大量场源同时作用时,这一不确定性就更大。诚然,当我们对场源和媒介的认识达到确定性时,且测量仪器的精度和稳定度进一步提高时,此时的场值将变得具有可测性,但永远无法 100% 精确测准。

我们首先要对场源进行统计描述,包含强度、分布、时变关系。同样的,

还要对场源通过的媒介进行统计描述,包含有效介质填充系数、欧姆损耗、介质损耗的统计模型建立。

任何物理理论均有着其实际现象作为背景和支撑。统计电磁学来源于对实践中大量电磁设备在统计稳定工作下进行测试的结果,该结果表明,每次进行测试的值均有所不同。倘若我们认为测量仪器是准确且稳定的(这也基本上是事实),则不稳定的电磁场强测量值表明了设备呈现出的不确定性。是设备自身源的不稳定?还是测量环境的不稳定?应当说,两者兼而有之。而大量的测试结果又表明,这些测量值具有很好的统计稳定性,这就是统计电磁学的基础。随着人们对电磁学的不断认识,统计电磁学将会不断充实发展,将成为经典确定性电磁学的良好补充。

目前,对统计电磁学的研究仍处于初步认识阶段,尚未见到系统的理论研究成果,其难度在于它介于微观量子电动力学与宏观电磁理论之间,需要物理学、电子学及大量实验结果的支撑。

参 考 文 献

- [1] 张启仁.统计力学.北京:科学出版社,2004.
- [2] 费曼 R P.量子电动力学讲义.张邦固译.北京:科学出版社,1985.
- [3] 朗道·栗弗席兹.量子力学(非相对论理论).北京:高等教育出版社,2008.

撰稿人:张 敏

北京理工大学信息与电子学院

电磁波与复杂多尺度媒质体的作用机理

Interaction Mechanism of Electromagnetic Wave and Multi-scale Objects of Complex Materials

认知电磁波与复杂多尺度媒质体的作用机理是发展现代信息技术的核心基础之一。隐身飞行器就是利用电磁波与媒质的作用机理,通过外形设计和材料涂敷,达到飞行器隐身的目的。智能雷达就是利用电磁波与目标的作用特征,通过设计雷达体制和算法来识别目标。电磁兼容就是解决电子系统或平台中的各个设备在电磁波作用下能协同工作。

电磁波遵循一组 Maxwell 方程。原则上说,电磁波与复杂多尺度媒质体的作用机理可以通过求解这组方程得知。为此,人们发展了一系列方法,如分离变量法、高频近似法等解析方法,但只能解决电磁波与一些简单特殊媒质体的作用问题。随着计算机的发展,一些数值方法,如矩量法、有限元方法、时域有限差分法相继发展起来,成为研究电磁波与复杂媒质体作用机理的重要工具,推进了人们对电磁波与媒质体作用机理的认识。基于这些方法和高性能计算平台的快速精确算法不断涌现,如并行快速多极子算法^[1,2]、并行高阶合元极算法^[3,4]更是进一步拓展了人们对电磁波与媒质体作用机理的认识。计算科学已成为探索自然规律的重要工具^[5]。

近年来,人们发现在一些特殊结构材料中,电磁波表现出一些有趣的性质^[6,7]。但是,对于电磁波与复杂多尺度媒质体作用机理的认识还远远不够。这里,“复杂多尺度媒质体”指由多种尺寸、形状、结构、材料复合构成的系统,如飞行器系统。“复杂”主要指系统的组成成分、结构、形状复杂,如带有内壁涂层的飞机进气道、结构型吸波材料涂敷的隐身飞行器、一系列特殊单元组成的天线阵列、由微结构构成的特性独特的超材料等。“多尺度”指系统既有尺寸远大于电波长,在几百个波长以上,甚至上千个波长的电大部分,又有尺寸小于1个波长的电小部分。战斗机在 X 波段、装甲车在 K 波段、舰船在 L 波段,它们的主体部分的电尺寸都超过 1000 个波长,而其上所布置的天线单元的电尺寸则小于 1 个波长。此类问题之所以认识不够,主要是因为目前还没有发展出解决这类问题的有效方法,或者说在解决这类问题时还有难以绕过的瓶颈。以往方法解决这类问题失效的原因有:①电磁波与复杂多尺度媒质体的作用极其复杂,要准确模拟其作用规律,计算方法必须足够准确;②电磁波与复杂多尺度媒质体的复杂相互作用导致各种计算瓶颈,如在用有限元方法计算电磁波与

复杂多尺度媒质体作用时,因为是多尺度媒质体,模拟未知数往往达千万,甚至过亿,若用直接稀疏矩阵求解是不可能的;若用迭代法求解,则因为有限元矩阵条件数很差而难以收敛。

正因为没有发展出高效的求解电磁波与复杂多尺度媒质体相互作用的方法,也就无法通过大量求解电磁波与复杂多尺度媒质体的相互作用问题,从结果中总结出电磁波与复杂多尺度媒质体的具体作用机理。这样,迫切需要解决的具体问题很多,如电磁波在电大深腔中的传播规律、机载天线阵列的散射机理、天线罩与天线的作用机理、电大涂敷目标的散射机理等。因此,发展出高效精确求解电磁波与复杂多尺度媒质体相互作用的方法,总结出各种电磁波与复杂多尺度媒质体的具体作用机理,对发展各种先进信息技术具有极其重要的意义。

参 考 文 献

- [1] Velampambil S, Chew W C, Song J. 10 million unknowns: Is it that big? IEEE Antennas Propagat. Mag., 2003, 45: 43—58.
- [2] Pan X M, Sheng X Q. A sophisticated parallel MLFMA for scattering by extremely large targets. IEEE Antennas Propagat. Mag., 2008, 50(3): 129—138.
- [3] Jin J M, Liu J, Lou Z, et al. A fully high-order finite-element simulation of scattering by deep cavities. IEEE Trans. on Antennas Propagat., 2003, 51: 2420—2429.
- [4] Peng Z, Sheng X Q. A flexible and efficient higher-order FE-BI-MLFMA for scattering by a large body with deep cavities. IEEE Trans. on Antennas Propagat., 2008, 56(7): 2031—2042.
- [5] President's Information Technology Advisory Committee. Computational Science: Ensuring American's Competitiveness. 2005.
- [6] Pendry J B, Schurig D, Smith D R. Controlling electromagnetic fields. Science, 2006, 312: 1780—1782.
- [7] Schurig D, Mock J J, Justice B J, et al. Metamaterial electromagnetic cloak at microwave frequencies. Science, 2006, 314: 977—980.

撰稿人: 盛新庆

北京理工大学信息与电子学院

微波的非热效应

The Non-thermal Effect of Microwave

微波对生物个体和化学反应的非热效应是指在微波作用下某些特殊的效应不能用温度的变化和特殊的温度分布去解释^[1,2]，如微波的低温催化效应。微波的特殊效应与非热效应有本质的区别。

目前，具有争议的长期使用手机是否会致癌的问题实际上是微波对生物体是否存在非热效应的反映。由于生物体固有的个体差异导致很多实验不能重复，以至于许多癌症机构的研究结论相互矛盾，但最近世界卫生组织宣称手机的确有致癌的可能性^[3]。

与弱电磁辐射对生物个体的非热效应不同，微波催化中的微波功率较高，系统往往伴随有显著的温度升高。要区别效应是否是由温度上升引起的非常困难。不管是生物个体还是化学反应，微波非热效应的分子机理是一样的。是否存在微波的非热效应？这一问题一直没有定论，在目前学术界存在很大争议。一些理论科学家反对存在微波的非热效应，同时也有很多实验科学家坚持认为存在非热效应。

从化学平衡的观点来看，反对者认为根据 Wien 第二效应，需要大约 10^7 V/m 的电场强度作用下才可以使化学反应的平衡常数有明显的改变，所以，在通常情况下，弱电磁场不能使化学平衡发生移动。而支持非热效应者则认为，仅仅根据 Wien 第二效应的估计是不准确的。在微波作用下，化学反应中由于反应物不断减少，和生成物的逐渐增加，使得系统等效的介电系数与反应物和生成物的浓度和微波场强相关，其极化强度的变化已经不再和电场强度存在简单的线性关系。此外，还通过实验观察到在一定条件下，微波腔中气-液界面的场强可以达到很高的数值。因此，仅靠场强大小就认定是否存在化学平衡移动是片面的^[4]。

从微波对化学反应系统自组织行为的影响上看，一个远离平衡的开放化学体系是具有发生自组织过程能力的，这种系统通过不断与外界交换物质和能量，就可能从原有的混乱无序状态转变为一种在时间上、空间上或功能上的有序状态，平时只能作为噪声或者是干扰的弱电磁场就可能对系统产生重大影响。

然而，这些都仅仅是从宏观的角度去研究微波的非热效应。在微观方面，微波作为非电离辐射，其光量子的能量相对化学键键能来说是非常低的。以 2.45GHz 微波来说，其光量子能量大约是 10^{-5} eV，最弱的氢键键能在 0.04 ~

0.44eV 之间。所以,对于微波辐射来说,不可能破坏任何化学键。但美国学者的最新研究表明,当微波光子数目足够多时,也会对化学键产生影响^[5]。另一种观点则认为,微波辐射可以对氢键产生作用,它通过扭曲的方式使氢键的空间构象发生变化,从而影响化学反应的进程和生物个体的发育^[6,7]。

研究表明,通常情况下,微波的非热效应相对于热效应是非常微弱的,仅占 1%,如何从热效应中检测出非热效应是一项复杂且困难的任务。就目前的研究现状和进展程度估计,在未来的 5 年内,将有希望在微波非热效应的分子机理研究上获得突破。但是,这样的微观层次上的变化会引起化学反应什么样的宏观效应,以及生物个体什么样的病理变化却可能需要 20 年或者更长的时间去研究。

参 考 文 献

- [1] Adam D. Microwave chemistry :Out of the kitchen .Nature,2003,421:571—572.
- [2] Pomerai D, Daniells C, David H, et al. Non-thermal heat-shock response to microwaves . Nature,2000,405:417—418.
- [3] World Health Organization .IARC classifies radiofrequency electromagnetic fields as possibly carcinogenic to humans .International Agency for Research on Cancer,2011.
- [4] 黄卡玛,杨晓庆.微波加快化学反应中非热效应研究的新进展.自然科学进展,2006,16(3):273—279.
- [5] Volkow N D, Tomasi D, et al. Effects of cell phone radiofrequency signal exposure on brain glucose metabolism .JAMA,2011,305(8):808—813.
- [6] Yang L J, Huang K M. Electric conductivity in electrolyte solution under external electromagnetic field by nonequilibrium molecular dynamics simulation .J. Phys. Chem. B,2010,114:8449—8452.
- [7] Huang K M, Yang X Q, Hua W, et al. Experimental evidence of a microwave non-thermal effect in electrolyte aqueous solutions .New J. Chem.,2009,33:1486—1489.

撰稿人:黄卡玛
四川大学电子信息学院

电磁辐射与散射中的近场理论

Near Field Theory on EM Radiation and Scattering Problem

1. 难题的来龙去脉及重要性

天线辐射场在距离上被分成三个不同区域。

(1) 凋落(evanescent)区。指离开辐射或散射口径几个波长 λ 的区域,其中,占主要成分的场是不产生电磁波辐射的感应场,且随离开口面的距离 R 的衰减极快。

(2) 近场(fresnel)区。指凋落区与远场区之间的区域。

(3) 远场(fraunhofer)区。指随离开口面 D 的距离 $R > 2D^2/\lambda$,其中的场绝大部分是辐射场,场振幅近似按 $1/R$ 规律衰减。

天线大多数应用在远场区域。因此,天线方向性图被默认为天线的远场响应,而且天线的远场响应是与距离无关的、描述天线的确定特性。由此定义了天线的增益、效率、波束宽度等概念。在理论上,证明天线口面场的傅里叶变换为远场方向性图。这些概念得到广泛应用。

根据电磁理论的唯一性定理,由完整的近场信息可以准确地预测辐射的远场响应,因此,近场响应更具一般性。但是,近场区域天线辐射场的研究较少,近场分布与口面场的关系、近场分布与远场响应的关系都有待深入研究。

目标散射特性同样可以被分成三个区域。广泛使用目标雷达散射面积(RCS)的概念和定义为散射的远场响应。

近场研究有重要的工程应用价值。如天线和散射测量,不可能在真正的远场条件下完成,并且有重要的测量误差。如果建立了近场响应与远场响应之间的理论公式,就可以在存在近场因素时对测量结构进行误差评估和修正,也可以用近场测量代替价格昂贵的远场测量。另外,导弹末制导、天线罩研究、近场光学等也有赖于近场研究。

显而易见,近场研究的难度远高于远场,致使近场完整理论框架至今没有建立。

2. 难题解决现状

近年来,近场理论研究的发展受到重视,也取得了很大进步。

1978年,美国Paris教授针对三维场得到了天线从远场估计近场的积分

公式^[1]。

1981 年, 美国国家标准局的 Kerns 得到从远场估计近场的三维积分公式和卷积公式^[2]。

电磁辐射的近场问题在天线测量工程需求的牵引下研究得较为深入, 也发展出了多种测量技术, 包括近场平面、柱面、球面和无相测量等^[3,4]。然而, 对于由口径到近场的辐射问题, 近场菲涅耳积分和分数阶傅里叶变换计算精度不高, 物理光学积分又不能满足大型紧缩场天线优化设计的计算需求。近场散射问题的研究相对更为薄弱, 尤其是满足工程需求的电磁散射的近远场之间的相互转换问题。

1989 年, 美国 Cown 教授采用近似的耦合积分方程, 得到从目标远场 RCS 估计近场的三维积分公式和卷积公式^[5]。

1994 年, 美国 Birtcher 和 Balanis 教授在物理光学假设和小角度近似的条件下, 在柱面波将这个结果推广到由近场响应预测远场 RCS 的近似公式^[6]。

1995 年, 我国科技人员在天线和 RCS 的研究中也开始对近场理论进行了独立研究, 主要进展是得到了近场与远场响应之间的两类链条关系式^[7,8], 并且在近场远场变换中, 根据卷积关系中变换域的定义, 对严格变换所需的双站信息进行了界定, 而且对忽略双站信息时进行变换的条件做了初步论证^[9]。

从 1978 年至今, 辐射口面近场研究的历史有 30 年。从 1989 年至今, 散射问题近场研究的历史有 20 年。应该说, 辐射和散射的远场研究还是一个比较年轻的领域。

3. 难题的清晰提法及必要的说明

辐射与散射近场理论的完整框架应该包括: ①非近轴前提下, 复杂辐射口面场分布和近场分布的解析表达式。②复杂辐射口面近场分布规律性描述, 即揭示近场与口面尺寸、频率和距离的关系等。依球面波、柱面波和平面波、远场响应与距离的关系可用 $(1/R)$ 、 $(1/R)^{0.5}$ 或 $(1/R)^0$ 表示。近场响应则与距离、频率和口面尺寸存在更为复杂的关系, 但可用简洁的相似规律加以描述。③辐射与散射近场响应与远场响应的各种关系式及由远场预测近场的唯一性问题和算法。④在以上研究基础上抽象出更完整的近场理论框架。

4. 难题的主要困难

(1) 辐射口面近场的物理机理、口径衍射和边缘绕射现象; 近场随口径形状、尺寸、频率和距离的变化规律; 如何实现近场的快速计算。

(2) 在通信系统(或称天线系统)和雷达系统系统(或称散射系统)中, 近场响应一般特征及它与远场响应的区别。

(3) 辐射和散射的近场响应与其远场响应之间的变换关系, 这种变换关系如何分类。如何根据近场预测远场, 辐射近远场变换与散射的近远场变换的异同。

(4) 只利用单站散射信息进行散射的近远场变换, 有什么条件, 如何进行误差评估。

以上问题涉及近场理论的核心内容, 又是工程应用非常关心的问题, 难以得到解答。正是由于天线和目标近场响应存在的复杂性和不确定性, 使得近场问题增添了某种“神秘”色彩。

未知领域研究具有重要的科学意义, 正如在频域的太赫兹空白一样, 在空域, 近场研究相当薄弱和零散, 因此, 近年来同样引起了许多科学家的关注。

参 考 文 献

- [1] Paris D T, Leach W M, Joy E B. Basic theory of probe-compensated near-field measurements. IEEE Trans. on Antennas Propagat., 1978, 26(3): 373—379.
- [2] Kerns D M. Plane-Wave Scattering-Matrix Theory of Antennas and Antenna-Antenna Interactions. Washington D C: US Gov. Printing Office, 1981.
- [3] Rahmat-Samii Y, Seyyed-Farhad R. The art and engineering of modern antenna near-field measurements. 2009 MTT-S International Microwave & Optoelectronics Conference, 2009: 344—349.
- [4] Seyyed-Farhad R, Rahmat-Samii Y. Resilience to probe-positioning errors in planar phaseless near-field measurements. IEEE Trans. on Antennas Propagat., 2010, 58(8): 2632—2640.
- [5] Cown B J, Ryan C E. Near field scattering measurements for determining complex target RCS. IEEE Trans. on Antennas Propagat., 1989, 37(5): 576—585.
- [6] Birtcher C R, Balanis A, Vokurka V J. RCS measurements, transformations and comparisons under cylinder and plane wave illumination. IEEE Trans. on Antennas Propagat., 1994, 42(3): 329—334.
- [7] 何国瑜, 等. 分析 RCS 测量误差的反演法. 环境与目标特性研究, 1998, (2): 16—23.
- [8] 何国瑜, 陈海波, 苗俊刚, 等. 近场散射与远场 RCS 的链条关系式. 微波学报, 2006, 22(4): 1—4.
- [9] 何国瑜, 等. 电磁散射的计算与测量. 北京: 北京航空航天大学出版社, 2006.

撰稿人: 何国瑜

北京航空航天大学电子信息工程学院

神经递质检测方法研究

The Detection of Neurotransmitter

大脑是一个复杂的组织系统,包括数十亿个神经元和多种感官信息传递机制,通过密切协调才能控制人或动物的思维和行为^[1,2]。脑神经细胞的信息传递由脉冲放电和神经递质共同完成,作为脑科学研究的第一步,即脑神经电信号的采集,微电极技术的应用及电子放大技术的发展使得 20 世纪的神经科学获得了长足的进步,然而对神经递质信号检测的研究,却因神经递质信号错综复杂且其在脑等组织中的含量极低(nmol/L 或 pmol/L 量级),使传统的电极不能满足科研和临床检测需求,成为研究难点而未深入开展。

神经递质是作用于神经元上的受体后导致离子通道开放从而产生兴奋或抑制的化学物质,多为一些小分子化合物,目前已经明确的有:乙酰胆碱;单胺类,包括肾上腺素、去甲肾上腺素、多巴胺、5-羟色胺;氨基酸类,包括谷氨酸、天冬氨酸、 γ -氨基丁酸、甘氨酸等。这些神经递质通过传递各种信息而实现调节机体生理功能的作用,由于其直接影响人体的行为和活动,参与体内的循环和调控,并与多种功能性疾病(如精神分裂症、抑郁症等)和病变(如帕金森氏综合征等)息息相关,例如,谷氨酸是与中风有关的神经递质,大脑缺血缺氧后,谷氨酸过度释放,对神经元造成毒性损害作用;多巴胺与帕金森症、抑郁症有关,其浓度受精神因素影响,传递亢奋和欢愉的信息;此外,多巴胺为拟肾上腺素药,具有兴奋心脏、增加肾血流量的功能,可用于失血性、心源性及感染性休克,因此,研究神经递质的电子传递机理,建立灵敏、可靠的检测方法,在体、实时地定量测定微量的神经递质及其代谢产物,无论是在生理功能研究方面,还是在神经疾病的预防、诊断和治疗方面都有重要意义^[3~6]。

面向脑神经疾病和脑科学研究的神经递质含量变化检测需求,基于微纳制造技术,开展微电极阵列脑神经信息检测研究^[7~10],将为脑科学研究提供一种新型的脑信息获取工具,可对多个脑神经元神经递质信息进行高灵敏度同步记录,并为脑功能疾病诊断提供神经元群体活动更多和更可靠的数据。神经递质检测技术是一项多学科交叉的研究课题,涉及信息、生物医学、化学等众多的学科背景。其主要研究内容如下:开展基于微纳制造技术的电极阵列与脑神经信息检测微系统研究,获取神经递质的浓度信息,由于脑中浓度过低,对它的检测要求使得电极的制备同样向微型化、阵列化(更高的灵敏度、更快的响应速度、更少的样品体积、更小的组织损伤)发展。对电极阵列的空间分布、生物兼

容性等进行设计、优化；在微电极阵列表面进行纳米材料制备、修饰技术研究，优化微电极的电学特性；开展相关检测系统的微型化研究，突破抗干扰技术、微弱神经信号可编程放大、高速数据采集等关键技术；进行微电极阵列神经信号测试性能研究，探究神经电信号传导与神经递质含量的相互作用关系，揭示其与某些疾病的潜在关联，进行脑组织切片和动物在体实验及演示验证，探索神经元群体间的信号传导机制及外部电刺激对神经元放电的影响，为神经损伤修复机制研究提供信息。

参 考 文 献

- [1] 孙久荣.脑科学导论.北京:北京大学出版社,2001:1—10.
- [2] 陈惟昌,邱红霞,王自强.脑科学进展的跨世纪回顾与展望.世界科技研究与发展,2001,22(6):24—28.
- [3] 彭建德,冯立中.皇冠上的明珠——走进脑科学研究.中国医药指南,2003,1.
- [4] 冯峰.脑科学时代迎面走来.世界科技研究与发展,1999,21(6):82—83.
- [5] 梁培基,陈爱华.神经元活动的多电极同步记录及神经信息处理.北京:北京工业大学出版社,2003:60—85.
- [6] 杨庆华,叶宪曾,陶家,等.二茂铁单竣基衍生物/Nafion修饰电极对多巴胺的电化学催化研究.北京大学学报(自然科学版),1999,35(6):738—744.
- [7] Sandison M E, Anicet N, Glidle A, et al. Optimization of the geometry and porosity of micro-electrode arrays for sensor design. Analytical Chemistry, 2002, 74: 5717—5725.
- [8] Suzuki H. Advances in the microfabrication of electrochemical sensors and systems. Electroanal, 2000, 12(9): 703—713.
- [9] Arrigan D W M. Nanoelectrodes, nanoelectrode arrays and their applications. Analyst, 2004, 129: 1157—1165.
- [10] Sandison M E, Cooper J M. Nanofabrication of electrode arrays by electron-beam and nanoimprint lithographies. Lab Chip, 2006: 1020—1025.

撰稿人：蔡新霞
中国科学院电子学研究所

生物传感器

Biosensor

生物传感器(biosensor)是对生物物质敏感并将其浓度等参数转换为光电信号进行检测的仪器,它是由固定化的生物敏感材料作识别元件(包括酶、抗体、抗原、微生物、细胞、组织、核酸等生物活性物质)与适当的理化换能器(如氧电极、光敏管、场效应晶体管、压电晶体等)及信号放大装置构成的分析工具或检测系统。生物传感器具有接收器与转换器的功能(如图1所示)。根据生物传感器中分子识别元件(即敏感元件)可将其分为五类:酶传感器、微生物传感器、细胞传感器、组织传感器和免疫传感器等^[1]。显而易见,所应用的敏感材料可以是相关生物活性物质,如生物酶、细胞或微生物个体、动植物组织、抗原和抗体等。



图1 生物传感器原理示意图

由于生物酶等相关生物活性物质的分子结构具有选择性识别功能,只对特定反应起催化活化作用,因此,生物传感器具有非常高的选择性。目前,已发展了第二代生物传感器(如微生物、免疫、酶免疫和细胞生物传感器),并已研制和开发了第三代生物传感器,如将系统生物技术和电子技术结合起来的场效应生物传感器等。随着人类基因组研究的深入和微纳米技术的普及与成熟,纳米生物传感器、生物芯片及微全分析系统(TAS)等新器件、新系统的出现把生物传感器的研究推进到一个崭新的发展阶段^[2]。

但是,目前成熟的商品化生物传感器还很少,且大多数处于小批试生产阶段,仅有少数品种已计划大规模生产。今后一段时间里,生物传感器的研究工作将主要围绕生物活性强、选择性好和灵敏度高的生物传感元件设计,进一步提高信号检测器与信号转换器的使用寿命及生物响应的稳定性,实现生物传感器的微型化、自动化、便携式和快速高效分析。

(1) 提高灵敏度。生物传感器技术的不断进步,必然要求不断提高产品的灵敏度、稳定性和使用寿命。在灵敏度的提高方面,可以寻求借助多种性能优异的纳米结构和材料^[3]。当物质的结构单元小到纳米数量级时,会产生特异的表面效应、小尺寸效应、宏观量子隧道效应和量子尺寸效应,因而使纳米结构材料展现出许多特有的光学、力学、热学、光催化、光电效应等方面的性质。功能纳米材料的介入为生物传感器的发展提供了无穷的想象空间,具有纳米结构的功能材料可以广泛地应用于敏感分子的固定、信号的检测和放大等。与传统的传感器件相比,基于纳米结构材料的新型生物传感器具有超高灵敏度与选择性,同时,传感器的响应速度也会得到大幅度的提高,并且可以实现高通量的实时在线检测分析。由于纳米材料的尺寸与性质有很大的关联,因此,在用纳米结构材料来构筑具有优良性能的传感界面时,纳米材料的尺寸要均匀并保持一致,这对功能纳米材料的设计合成提出了更高的要求。另外,通过信号放大手段,将收集到的微弱信号放大,则有利于人们的观察和传感器灵敏度的进一步提高。

(2) 多功能化。未来的生物传感器将进一步涉及医疗保健、疾病诊断、食品检测、环境监测、发酵工业等各个领域。目前,生物传感器研究中的重要内容之一就是研究能代替生物视觉、嗅觉、味觉、听觉和触觉等感觉器官的生物传感器,这就是仿生传感器,也称为以生物系统为模型的生物传感器。仿生传感器是一种采用新的检测原理和方法的新型传感器,它采用固定化的细胞、酶或者其他生物活性物质与换能器相配合组成传感器,这种传感器是近年来生物医学和电子学、工程学相互渗透而发展起来的一种新型的信息技术。在仿生传感器中,比较常用的是生物体模拟的传感器。目前,虽然已经成功发展了许多仿生传感器,但仿生传感器的稳定性、再现性和可批量生产性明显不足。因此,以后除继续开发出新系列的仿生传感器和完善现有的系列之外,生物活性膜的固定化技术和仿生传感器的固态化值得进一步研究^[4]。在不久的将来,模拟生物体功能的嗅觉、味觉、听觉、触觉等仿生传感器将出现,并有可能超过人类五官的能力,完善目前机器人的视觉、味觉、触觉和对目的物进行操作的能力。

(3) 人性化。生物传感器在国民经济中的临床诊断、工业控制、食品和药物分析(包括生物药物研究开发)、环境保护及生物技术发展等方面都有广泛应用前景。随着微加工技术和纳米技术的进步,生物传感器将不断微型化,各种便携式生物传感器的出现使人们在家中进行疾病诊断、在市场上直接检测食品等成为可能^[5]。另外,在检测方式上,生物传感器还将应用于尿液、血液、唾液等各种体液的同步检测。例如,利用新型纳米材料(如 SiO_2 等)结合尿液干化学检查技术,可测定尿液中某些特定成分。但是,尿液检测技术并不成熟,针对某一种疾病选择何种成分来进行测量及对测量结果的处理放大等均是要亟待

解决的问题。唾液、体液检测也存在同样的难题。

(4) 可编程化和阵列化。针对传感器的输出特性,找到对应于它的算法,利用算法对传感器进行控制,就实现了可编程化。可编程的生物传感器作为多功能的诊断治疗工具可方便地应用于疾病的诊断和治疗(包括癌症、心脏病和艾滋病病毒等)。其中,算法编程是难点,不同的生物传感器算法也不同。而阵列化则是使多个生物传感器按照一定的排列顺序形成一个阵列,通过观察它与被测物反应后所呈现的不同的阵列组合变化来检测疾病^[6]。阵列元素的选择及结果的分析(建立数据库)均是需要解决的问题。

未来的生物传感器必定与计算机紧密结合,自动采集数据、处理数据,更科学、准确地提供结果,实现采样、进样、结果一条龙,形成检测的自动化系统。同时,芯片技术将愈加进入传感器,实现检测系统的集成化、一体化。

生物传感器技术的不断进步必然要求不断降低产品成本,提高检测特异性、灵敏度、稳定性和寿命,这些特性的改善也会加速生物传感器市场化、商品化的进程。在不久的将来,生物传感器会给人们的生活带来巨大的变化,它具有广阔的应用前景,必将在市场上大放异彩。

参 考 文 献

- [1] Karyakin A A .Biosensors .Sensors for Environment ,Health and Security ,2009 ;255—265 .
- [2] Lv X Y ,Bao X ,Huang Y ,et al .Mechanisms of cytotoxicity of nickel ions based on gene expression profiles .Biomaterials ,2009 ,30(2) ;141—148 .
- [3] Skottrup P D .Analytical biochemistry .Small Biomolecular Scaffolds for Improved Biosensor Performance ,2010 ,406(1) ;1—7 .
- [4] Sardarly N A ,Nagiev T M .Physicochemical peculiarities of iron porphyrin-containing electrodes in catalase-and peroxidase-type biomimetic sensors .Chemistry and Materials Science ,2009 ,83(8) ;1400—1404 .
- [5] Herron P M ,Gage D J ,Cardon Z G .Micro-scale water potential gradients visualized in soil around plant root tips using microbiosensors .Plant ,Cell & Environment ,2010 ,33(2) ;199—210 .
- [6] Densmore A ,Vachon M ,Xu D X ,et al .Silicon photonic wire biosensor array for multiplexed real-time and label-free molecular detection .Opt .Lett . ,2009 ,34(23) ;3598—3600 .

撰稿人:王雪梅 张晓璐

东南大学生物电子学国家重点实验室

基于纳电子技术的 DNA 测序

Nanopore-based DNA Sequencing

1. 个人基因组测序：开启个性化医疗的时代

近年来，随着分子水平上的生命科学与技术的迅速发展，如何实现快速、廉价的基因测序，以及相应的基因药物开发，成为现代生命科学研究的一个热点问题。

现代遗传生物学认为，基因是 DNA 分子上具有遗传效应的特定核苷酸序列的总称，是具有遗传效应的 DNA 分子片段。基因位于染色体上，并在染色体上呈线性排列。基因不仅可以通过复制把遗传信息传递给下一代，还可以使遗传信息得到表达。不同人种之间头发、肤色等的不同正是基因差异所致。

我们现在知道，人体有 22 对常染色体，1 对性染色体，总共包含了 30 亿个 DNA 碱基对，编码约 6 万~8 万个蛋白质，这些编码区只占到 2% 的基因组(剩下的 98% 的功能都不知道)。另外，有些染色体比起其他有更高的基因密度。

理解遗传学因子是如何对人类疾病起作用的探索进展非常迅速。1985 年，美国科学家提出人类基因组计划，目标是为 30 亿个碱基对构成的人类基因组精确测序，弄清楚每种基因制造的蛋白质及其作用，从而最终破译人类遗传信息。经过十几年的不懈努力，科学家已经绘制出人类基因组的物理图谱，基因组的编码基因起着里程碑的指导意义。物理图谱已为完成草图顺序提供了卓有成效的框架结构，并直接辅助鉴别大约 100 个疾病基因。

研究人员发现，大部分疾病可以在基因中发现病因。基因通过其对蛋白质合成的指导，决定我们吸收食物，从身体中排除毒物和应对感染的效率。第一类与遗传有关的疾病有四千多种，通过基因由父亲或母亲遗传获得。第二类疾病是常见病，如心脏病、糖尿病、多种癌症等，它们是多种基因和多种环境因素相互作用的结果。

如果能够实现个人基因组的快速、廉价测序，势必将在现代医药领域掀起一场革命性变革。届时，人类将有能力根据每个人的基因序列，开发所谓的个人化(individualized)药物，来实现与基因相关疾病的预防和有效治疗。因此，如何实现个人基因组的快速、廉价测序，是一个有着重大应用意义的课题。

2. 基于纳电子技术的 DNA 测序：原理

当下，微纳电子加工技术进入到纳米精度，而这正是 DNA 分子的直径尺度。于是，人们很自然地想到，有无可能利用纳电子技术实现 DNA 的检测？

美国科学家提出基于纳电子技术的 DNA 测序构想，他们设计了如下装置（如图 1 所示）^[1,2]。




图 1

(a) 一个单链 DNA 在纵向电场的驱动下，游动通过一个纳米孔的示意图，其中， E_x 是驱动 DNA 通过纳米孔的纵向电场， D_z 是纳米孔的直径；(b) 利用分子动力学模拟软件，在 van de Waals 绘景中做出的器件图，其中，纳米孔是氮化硅-金电极-氮化硅的三明治结构，中间的金电极用于测量 DNA 通过时的横向隧穿电流，两端的绝缘氮化硅材料用于把金电极跟水溶液隔离开来，游动在纳米孔中的是单链 DNA 分子，红白相间的小颗粒是水分子，间杂其中的是氯离子和钾离子。整个测序必须在常温下的溶液环境中完成

这一电学测序原理是利用核苷酸上不同碱基的电子结构不同。我们知道，一个核苷酸是由一个碱基和一个骨架组成，通过骨架把各个核苷酸连接起来。从结构上看，4 种核苷酸的骨架是一样的，它们的区别表现在碱基上。如图 2 所示，不同的碱基对应的电子结构不同，那么，相应的电学特性也就不同。

DNA 分子是带电的大分子，在纵向电场的驱动下，将游动通过纳米孔。在此期间，同时测量纳米孔里横向的隧穿电流，如前所述，不同核苷酸的碱基电子结构不同，由此导致的横向电学特性也不同，据此可以判断出正在通过的是哪一种核苷酸。这一原始方案提出后，引起了学术界和工业界的极大兴趣，IBM 等世界顶级高科技公司都开始投入人力、财力研究这一测序方案。





图 2 4 种碱基的分子模型图
(白色是氢原子, 蓝色是碳原子, 红色是氧原子)

3. 基于纳电子技术的 DNA 测序: 困难和挑战

这一方案虽然很有吸引力, 但无论是定量的理论计算、预测, 还是实际的实验实现, 都面临非常多的困难。

实验方面, DNA 测序对纳米孔的孔径和厚度都有严格要求。如图 3 所示, 实际的纳米孔, 必须是绝缘层-电极-绝缘层的三明治结构。中间的电极用于测量横向隧穿电流, 两边的绝缘层用于隔断水溶液(整个实验必须在水溶液里完成)。



(a) 剖面图

(b) 侧视图

图 3 绝缘层-电极-绝缘层三明治结构的纳米孔

首先, 纳米孔的孔径必须足够小: 第一, 要小到在每一时刻只能容下一个核苷酸通过。考虑到 DNA 分子很容易在溶液环境中扭曲、转动, 如果纳米孔大了, 可能同时通过的不止一个核苷酸, 而是多个核苷酸。这种情况下, 测得的电学特性就是两个并排的核苷酸叠加效果了, 而这就违背了我们测序的要求。第二, 要小到横向隧穿电流可测。由简单的物理分析可知, 隧穿电流跟接触的距离是指数衰减的。这意味着核苷酸分子跟电极的距离增大一点, 相应的测序分析的横向隧穿电流将指数下降。形象地说, DNA 分子必须是几乎卡着通过纳米孔的, DNA 分子才能与横向电极足够近, 接触足够好, 才能有大到可测量的横向隧穿电流。

其次, 纳米孔的厚度也必须足够小。可以想见, 假如纳米孔的厚度比较大, 极有可能同时有两个或两个以上的核苷酸在纳米孔里, 以串联的方式同时与电

极有接触,这种情况下,测出的电学特性将是同一个 DNA 链上多个核苷酸电学特性的叠加效果,而非单个核苷酸的。

最后,作为电极的金属,它本身的特性也会导致相关的问题。这样一种多层纳米孔结构,在实际制备中,电极需要采取淀积、刻蚀等多步工艺,才能制成纳米孔的形状。然而,金属本身有一定的延展性,这意味着在刻蚀出纳米孔的时候,被刻蚀掉的金属极有可能被黏附在电极上,甚至引起短路,这些非理想效应都将引起纳米孔特性的偏差。

可以看到,以上要求对当前的加工技术和原理提出了巨大挑战。

以上提到的是技术方面的困难,还有基本原理方面的困难。DNA 分子的结构并不是刚性的,在溶液环境中,很容易发生扭曲、转动等,这意味着构成核苷酸的各个原子会发生相对位移。由此导致电子结构发生涨落,从而导致不同核苷酸的电学特性发生重叠、模糊,导致区分度降低,大大增加了测序的难度。针对这一难题,已经有一些改进的方案被提出来。例如,在横向电极上附加上官能团分子,以期与 DNA 形成氢键,由此增加测序过程中 DNA 分子结构的稳定性^[3];再如,利用微分电导来测序,以实现更好的单碱基检测^[4];还有利用单层石墨做横向电极,以达到单碱基的分辨率^[5]。

总的来说,利用纳电子技术做 DNA 测序,既有着成本低廉、测序迅速等诱人前景,也面临着具体实现上的一系列重大难题,而这些困难对年轻的科技工作者们,既是挑战,也是机遇。

参 考 文 献

- [1] Zwolak M, et al. Electronic signature of DNA nucleotides via transverse transport. *Nano Lett.*, 2005, 5: 421.
- [2] Lagerqvist J, et al. Fast DNA sequencing via transverse electronic transport. *Nano Lett.*, 2006, 6: 779.
- [3] He H, et al. Functionalized nanopore-embedded electrodes for rapid DNA sequencing. *J. Phys. Chem. C*, 2008, 112: 3456.
- [4] He Y, et al. Differential conductance as a promising approach for rapid DNA sequencing with nanopore-embedded electrodes. *Applied Physics Letters*, 2010, 97: 043701.
- [5] Postma H W C. Rapid sequencing of individual DNA molecules in graphene nanogaps. *Nano Lett.*, 2010, 10: 420.

撰稿人: 刘 明
中国科学院微电子研究所

睡眠快速眼动的信息处理

Information Processing during Sleep Rapid Eye Movement

1. 睡眠快速眼动简介

健康人在正常睡眠期间会间歇地出现一种快速急剧的眼球运动,称为快速眼动(rapid eye movement, REM),每晚约出现 3~4 次,一次持续期为几分至 50 分钟,累计共约 2 小时左右,在时间上与“梦”同步发生,且在 REM 时期脑血供应量明显增加。这一方面提示了在睡眠期间人脑并非处于静止休息状态,而是周期地进行着高强度的神经信息处理活动;另一方面也揭示“梦”并非睡眠中的偶发现象,而是一种正常睡眠过程中必然的生理现象^[1]。

Aserinsky 和 Kleitman 首次以详尽的实验记录报道了睡眠中快速 REM 眼动现象的规律及与梦的关系,突破了以往凭主诉回忆、或用“自我”、“本我”之类主观心理分析对梦睡眠的猜测,研究结果于 1953 年首次发表在 *Science* 后,就吸引了大量研究者的兴趣,该文发表 50 周年的 2003 年, *J. Neuropsychiatry Clin. Neurosci.* 还全文重刊了原文^[1],说明它在梦睡眠研究中的重要作用,也表明睡眠 REM 至今在多种交叉学科中受到关注,急待深入研究。

2. 睡眠 REM 的“反向学习机制”假设

人在正常睡眠中皆发生间歇性 REM,并与梦同步,这种 REM 在脑信息处理中究竟起何作用?这吸引了 DNA 基因发现者 Crick 及其同事用大脑神经网络的“反向学习机制(reverse learning mechanism)”假设来解释其脑信息处理^[2],他们认为大脑皮层如 Hopfield 人工神经网络中描述的平行处理式联想记忆网络,能对一组模式样本输入通过学习改变权重系数来更新神经元的突触连接,然后在新信息模式输入时,网络由突触权重求和运算再经非线性激励函数后,自动导致 Hamming 距离最近的神经元激活状态,也即得到联想结果(也称作“吸引子”, attractor)。Crick 假设,大脑的成长或生活经验的学习过程所塑造的神经元突触联结都难免会有联结错误,形成错误的寄生吸引子模式(parasitic attractor modes),它们会导致脑产生奇异联想(bizarre association),或顽固地产生同一联想状态的强迫观念(obsession),或因不当反馈信号使在无输入信息下造成幻觉(hallucination),REM 活动正是脑在睡眠中以“反向学习”来消除这些产生寄生模式的神经突触联结错误。趁大脑处于与外界的输入输出皆被阻

断的睡眠状态下,从脑桥-膝状体-枕叶发出 PGO 波(ponto-geniculo-occipital wave)随机信号来励神经网络系统,产生 REM,同时促成梦境中各种非现实的幻觉出现,使其中错误寄生模式都被激发出来,再经“反向学习”在神经突触联结中校正消除。Crick 认为这种“反向学习机制”虽然目前还不易用实验来验证,但比其他的假设都更合理。

3. 对“反向学习机制”的质疑及其他机制探讨

(1)“反向学习机制”假设本身还存在一些疑问。例如,幼婴儿每天睡眠中的 REM 眼动时间累计多达 8 小时以上,为青年期每晚 REM 眼动期(约两小时)的 4 倍,如何解释婴儿脑部神经网络联结的错误比成年时大如此之多?尤其是幼婴视知觉经历很少甚至尚未睁眼,其大脑如何界定正常经验知觉与视幻觉?虽然脑研究也报道了人类发育过程从胎儿直到青春期,都是大脑皮层神经突触密度逐步减少,但那是由基因控制的发育过程,连先天盲人都如此,更不易用反向学习机制解释。还有,实验表明,某些神经抑制药物能完全阻止发生 REM 睡眠,但不出现“反向学习”未能执行可能出现精神异常。因此,该理论并未能满意解决睡眠 REM 机制问题。

(2)脑内记忆信息转换假设。实验证明,仅剥夺受试者的 REM 睡眠,保留其他时段睡眠不受影响,则受试者第二天精神正常,但学习能力受到很大损害^[3],表明 REM 睡眠对人的记忆功能有很大作用。故 Newman 等提出人的 REM 睡眠相当于计算机在运算后清除无用信息保持记忆能力^[4],但这受到 Crick 等的反对,认为计算机不同于脑神经网络的平行计算而加以否定。其实,从控制论观点来比较大脑与计算机记忆还是有借鉴意义的。睡眠 REM 眼动实验揭示了梦境当时仅进入短时记忆,当时觉醒后马上回忆,梦才能进入长期记忆不遗忘,睡眠 REM 眼动可能正是参与了记忆信息转换。当然,这还得由实验研究来检验。

(3)“睡眠 REM 眼动”与“梦”需区分。至今,不少有关文献提及睡眠 REM 眼动总是与“做梦”等同起来,实际上,两者的关系正需进一步的实验研究来阐明的问题。因为至今所有的实验结果都仅仅只表明睡眠 REM 与出现梦境在时间上有很强的相关性(也有文献报道了有少量的非 REM 期间“梦”的事例),究竟这两者之间是因果关系,或仅是伴随关系?但绝不是全同关系。“梦”是人在睡眠中没有感觉输入信号刺激下发生的无意识(也称半意识)特殊状态的精神(mental)或心智(mind)现象;睡眠 REM 是眼球在脑部有关核团控制下进行的具体的器官运动;人在清醒状态下的眼动是视觉信息诱发的随意或非随意地眼球运动,以实现有效地采集和处理视觉信息,清醒状态下人的眼动有微小幅度的注视眼动(fixation)、改变注视点位置的 saccade 眼动、跟踪运动目标的 smooth pursuit 眼动等三种基本形式,正常人每天不自觉地进行着数十万次的眼动,直至入睡才基本停止;但在睡

眠中既无视觉信息输入,也无大脑皮层的清醒意识活动,REM 眼动是如何诱发出来的?它是白天的眼动经历有关的回放(replay)?还是梦境中的幻视觉景象所引发的眼动?在脑内信息处理中起何作用?深入研究睡眠 REM 眼动信息处理机制不仅有其理论意义,而且将对老年痴呆症及精神分裂症(皆与 REM 睡眠有密切关联)等神经及精神疾病的诊治有重大价值,对仿生计算机设计创新也具有借鉴意义。

4. 睡眠 REM 眼动研究方法难点

(1) 基于动物模型的困难。很多文章是基于大鼠等动物实验,用来推测人睡眠 REM 控制模型,其结果值得商榷。低等哺乳动物与人差异很大,即使与人类最接近的类人猿黑猩猩的脑结构及思维方式与人还有很大差别,未有实验证明它们睡眠模式与人完全一样,更未证实有和人一样“做梦”的心智现象。只有对志愿者进行实验研究才能获得准确结论。

(2) fMRI(functional magnetic resonance imaging, 功能磁共振成像)脑成像设备研究睡眠 REM 与清醒状态下不同,必须实验上有根本创新。

(3) 探讨睡眠 REM 过程中眼动位置与梦境的关系,不能套用普通交流脑电记录眼动信号,必须采用低漂移直流宽带眼动记录设备。

总之,睡眠 REM 信息处理机制研究,是涉及探索人在睡眠中的“意识”或“心智”问题,会受到“占梦”、“盗梦”等影视商业宣传的干扰,或被 Freud 理论中无法实验证伪的非科学思路的误导,必须可实验证伪性原则下^[5]进行严谨研究,才可能揭开睡眠 REM 眼动脑信息处理机制。

参 考 文 献

- [1] Aserinsky E, Kleitman N. Regularly occurring periods of eye motility, and concomitant phenomena, during sleep. *Science*, 1953, 118: 273—274.
- [2] Crick F, Mitchison G. The function of dream sleep. *Nature*, 1983, 304(7): 111—114.
- [3] Yoo S, et al. A deficit in the ability to form new human memories without sleep. *Nature Neuroscience*, 2007, 10(3): 385—392.
- [4] Newman E A, Evans C R. Human dream processing as analogous to computer program clearance. *Nature*, 1965, 206(5): 534—535.
- [5] Popper K R. *Conjectures and Refutations: The Growth of Scientific Knowledge*. London: Loutledge, 2002.

撰稿人: 孙复川

中国科学院上海生命科学研究院

脑信号的解码

Decoding of Brain Signals

大脑的重量只有约 1.4kg，但却包含了 1000 多亿个神经元，是宇宙中已知的最复杂、最精密的组织。大脑是人体的器官之一，但却充满神秘与奥妙，人类一直渴望能了解大脑，能对大脑信号进行破译，推测人的意图或想法，从而用于康复医疗，如帮助瘫痪患者通过思维控制假肢、电话按键、键盘打字，对有精神缺陷的患者进行早期鉴别和干预；用于辅助控制，如在医疗手术、航空驾驶过程中无法或来不及用常规肢体控制的装置，或控制机器人；用于监控，如监控士兵、战斗机飞行员的战斗意志；用于科学教育，如鉴别社会情绪能力退缩或学习困难儿童、评测课堂教学效果；还可用于选拔各类人才，如对政府而言，需要考虑选拔的人是否忠诚等。

我们面对的主要科学问题为分析神经活动的模式和机理，提取认知或情感信息，对大脑信号进行解码，推测人的意图想法或情感。目前，所用的两个主要手段为脑电 (electroencephalogram, EEG) 和功能磁共振成像 (functional magnetic resonance imaging, fMRI)。

1929 年，德国科学家 Berger 首次记录到人类 EEG 信号，这是一种脑认知成像方法，被誉为“窥测脑高级功能的窗口”。自 EEG 信号问世以来，人们就希望能通过对 EEG 信号的处理来解读大脑的相关活动，实现“脑机接口 (brain-computer interface, BCI)”^[1]。1973 年，美国科学家 Vidal 首次尝试了通过对 EEG 信号的处理来控制光标穿越二维迷宫。自 20 世纪 90 年代以来，EEG 信号的处理和分类已如火如荼地在世界范围内展开，吸引了上百个科研单位及军方，各种信号处理与机器学习的方法被运用、发展^[2]。基于诱发 EEG 信号的处理 [如 P300、视觉诱发电位 (visual-evoked potentials)]，在实验室阶段已有初步的应用，但诱发 EEG 需要特定设备对使用者进行材料刺激，而自发 EEG 的应用更接近自然、实际。目前，自发 EEG 大都集中在运动想象 (motor imagery, MI) 的研究，自发 EEG 的信噪比更低，这使得信号的解码比较困难。通常，对 EEG 信号进行空间滤波，其中，广泛使用且功能强大首推共同空间模式 (common spatial patterns, CSP) 及其变种，CSP 已被成功运用到柏林 BCI 系统中^[3]。目前，大部分 EEG 信号的解码只是针对两类 MI 任务，多类 EEG 信号只有零星的初步探索。如何进行自发 EEG 的多类、单次实验分析，实现连续、稳健、准确地思维状态的判断还是一个挑战性的科学问题。根本原因在于无创伤性头皮

测量的 EEG 信号极其微弱,它是一族神经细胞放电经头颅折射后的信号总和,是个复杂的非线性系统。所以,发展恰当的信号处理方法、揭示脑电活动模式尤为重要。

另一种解码脑信号的手段是基于血氧水平依赖(blood oxygen level dependent, BOLD)对照机制的 fMRI,利用 BOLD-fMRI 进行脑信号解码是近几年才发展起来的,研究的基本流程如图 1 所示。Haxby 等发现了人脸及猫、五种人造物体、无意义图片在大脑皮层中都对应一个特定的反应模式(response pattern)^[4],Cox 和 Savoy 进一步用多元统计模式识别方法对各种物体类别视觉表示的反应模式进行分类^[5],更艰难的解码是方向(orientation)刺激,这是因为方向列(orientation column)的大小比当前 fMRI 可获得体素(voxel)的大小小得多,方向刺激解码(甚至可在方向刺激前放置一个遮挡使得刺激不可见)的初步成功则归功于多元模式的使用^[6,7],近年来的研究还包括位置的解码^[8]。2008 年,Kay 等的研究则把图像的解码本质地推进了一步,他们建立了基于量化接收域模型(quantitative receptive-field models)的自然图像视觉刺激和 fMRI 早期视觉区域活动的关系^[9],此外,他们推测能否仅仅从脑活动信号重构出受试者所看到的图像。目前的实验室研究离实际场景还有很大的距离,如材料刺激持续时间通常为几秒甚至达到 20s,这远大于人类视觉感受物体的时间,选择的材料刺激差异较大,而且通常为块(block)设计范式,刺激间有很长的时间间隔。如何在快速、事件相关、微弱刺激条件下(接近自然环境)解码刺激信号(甚至重构视觉刺激)仍是需要解决的问题。这一方面涉及从神经科学、心理学、生物医学方面探究相关的神经科学原理,另一方面又依赖于方法的发展,如获得更高分辨率的信号、发展更艰深的信息处理方法。此外,脑信号的解码也不限于视觉刺激,如研究者们考虑了在赌博决策中如何基于脑信号及上次的选择结果推测下次的决策^[10],这些问题才刚刚开始研究。国际上一些顶级大学、科研单位相继开展这方面的研究。对脑信号解码的研究必将深化人类对自身的认识、对人类的生活方式产生广泛深远的影响。




图 1 基于 fMRI 的脑解码示意

参 考 文 献

- [1] Wolpaw J R, Birbaumer N, McFarland D J, et al. Brain-computer interfaces for communication and control. *Clin. Neurophysiol.*, 2002, 113: 767—791.
- [2] Bashashati A, Fatourehchi M, Ward R K, et al. A survey of signal processing algorithms in brain-computer interfaces based on electrical brain signals. *J. Neural Eng.*, 2007, 4: 32—57.
- [3] Blankertz B, Tomioka R, Lemm S, et al. Optimizing spatial filters for robust EEG single-trial analysis. *IEEE Signal Process Mag.*, 2008, 25: 41—56.
- [4] Haxby J V, et al. Distributed and overlapping representations of faces and objects in ventral temporal cortex. *Science*, 2001, 293: 2425—2430.
- [5] Cox D D, Savoy R L. Functional magnetic resonance imaging (fMRI) “brain reading”: Detecting and classifying distributed patterns of fMRI activity in human visual cortex. *Neuroimage*, 2003, 19: 261—270.
- [6] Kamitani Y, Tong F. Decoding the visual and subjective contents of the human brain. *Nature Neuroscience*, 2005, 8: 679—685.
- [7] Haynes J D, Rees G. Predicting the orientation of invisible stimuli from activity in human primary visual cortex. *Nature Neuroscience*, 2005, 8: 686—691.
- [8] Thirion B, et al. Inverse retinotopy: Inferring the visual content of images from brain activation patterns. *Neuroimage*, 2006, 33: 1104—1116.
- [9] Kay K N, Naselaris T, Prenger R J, et al. Identifying natural images from human brain activity. *Nature*, 2008, 452: 352—356.
- [10] Hampton A N, O’Doherty J P. Decoding the neural substrates of reward-related decision making with functional MRI. *PNAS*, 2007, 104: 1377—1382.

撰稿人：王海贤

东南大学学习科学研究中心

生物系统建模及其生物鲁棒性

Modeling of Living Systems and Biological Robustness

生物系统是一种由多组分、多层次、多尺度组成的高度复杂的巨系统，它具有输入和输出变量多、系统规模大、调控机制复杂等特点，并且许多变量或参数不能在体检测，仅仅用实验的手段和方法很难揭示生物系统的本质和规律。因此，建立生物系统模型有助于阐明生物系统中组分之间的复杂关系，获得各种变量或参数的定量变化规律，揭示生物系统与环境、生物体维生与发育、生物变异与突变等自然规律。不仅如此，通过生物系统模型及仿真可以预测生物系统变量或参数的控制结果，从而对医疗计划制定、药物发现与开发、环境评价与保护等重大科学问题的解决具有重要意义。

早期生物系统建模的主要目的是生物特性的发现，运用的手段是数学物理理论，以数学模型和物理模型为多。早在 17 世纪，由于不能在活体下进行解剖，人们一直没有发现循环系统。1628 年，英国医生 Harvey 用归纳法安排一系列物理实验证明心脏各个阶段的活动，用数学证据比较了静脉和肺动脉容量与其他血管容量，用力学原理得出动脉内的搏动是由于血柱冲击弹性血管壁的结果^[1]。Harvey 对血循环的发现开启了近代生理学之门。比较著名的生物系统模型有描述细胞动作电位的 H-H 方程、描述药物动力学特性的模型等。

生物系统模型对维纳创立控制论起到至关重要的作用。美国数学家维纳在《控制论》导言的第一句话就肯定了本书是与生理学家 Rosenblüeth 共同研究的成果，他提出的反馈控制系统与生理学中的反射弧十分相似，并受脊髓痨神经疾病的启发揭示了系统振荡的控制机理^[2]。1932 年，美国生理学家 Cannon 提出了“稳态”(homeostasis)这一生理学概念，维纳和 Rosenblüeth 共同研究认为负反馈是保持稳态的基本条件^[2]。

20 世纪 80 年代开始，生物系统建模成为生物系统仿真的主要工具。美国迈阿密大学首次通过运用 Harvey 人体模型实现人体功能的再现，改造了包括触诊、听诊和心电图等许多方面的心脏检查。与此同时，欧洲许多公司也在开发各种模拟器和急救设备等控制创伤反应的技术，如复苏训练人体模型、便携式呼吸机、除颤器等。1986 年，美国国立卫生研究院(NIH)虚拟人体计划(Virtual Human Project)用 CT、磁共振和冻干切片等对人尸进行 1mm 断层切片，将这些数字化图像数据提供医学和工业作参考^[3]。90 年代末，日本和美国都开展了虚拟细胞(virtual cell)的研究，运用信息技术，通过数学计算和分析，对细胞结

构和功能进行分析、整合和应用,以再现和仿真细胞的生命现象^[4]。

近年来,生物系统的实体建模正在兴起。许多医学实验是不允许直接在人体上进行的,动物实验就成为临床前试验的必要环节。实验动物模型是一种具有模拟人体生理、病理过程的实体模型,它按照特定目标设计、运用基因敲除技术来改变动物的遗传特性,具有先天性疾病。2010年,哈佛大学的 Ingber 等利用血管细胞制成一个机械泵和调节阀连接,模拟人体肺部呼吸活动的“芯片肺”。这种“芯片肺”是运用电路技术制造出的一个微芯片,可以精确地模拟大鼠肺脏的很多功能,如肺部吸入纳米粒子后作出的反应等,其意义在于加速新药开发的进程。目前,哈佛的研究人员正在研发其他的“芯片器官”,如肠、心脏和肾等,以在药物测试和毒理测试中彻底摒弃动物实验^[5]。

生物系统建模蕴含着理想化、抽象化、简单化三层含义。在建立模型时并不苛求与原型的等同性,可以将实际条件理想化,具体事物抽象化,复杂系统简单化以满足解决问题的需要。然而,生物系统建模的关键问题是需要实验或临床数据基础上,建立能够充分反映生物系统特性和特征的数学模型、物理模型和实体模型。了解和掌握生物系统特性是生物系统建模的前提。

生物鲁棒性是生物系统整体特性中的一种,它指生物系统在受到外部扰动或内部参数摄动等不确定因素干扰时,系统仍保持其结构和功能稳定的一种性质。生物鲁棒性的两个基本问题是生物系统维持条件(即稳定性)和抵抗外源扰动或参数摄动的能力(即系统品质)。




图1 生物系统的状态稳定与状态转移

稳定性是指系统结构、状态、行为的恒定,是系统的一种维持机制。稳定鲁棒性是指系统对外界环境或系统本身变化所保持状态稳定能力的特性,它通过两种方式来体现:①在遭受外界干扰或内部参数摄动时,系统状态返回当前吸引子,这个吸引子可以是稳定的(点吸引子),也可以是振荡的(周期吸引子),如图1状态1。②在有刺激作用时,系统状态(状态1)转向另一个新吸引子(状态2)

过程的稳定,使系统在对抗干扰时保持其行为的连贯性^[6]。品质鲁棒性是指系统在受到外界环境或系统本身变化时,用来衡量系统各种性能指标的鲁棒性能,如干扰抑制、响应性、最优性等。

生物鲁棒性揭示了外界扰动对生物系统影响的限值问题。当扰动足够小时,系统状态不改变,系统是稳定的;当扰动足够大时,系统状态改变,系统是渐进稳定或不稳定。研究生物鲁棒性对疾病治疗和疾病预防是非常有意义的。例1:在图1中设状态1为疾病状态,状态2为健康状态,给药为扰动,我们需要

给予一定剂量的药物使人体系统状态以最快的速度、最少的用药量从状态 1 转移到状态 2, 并且还不可逆, 这就需要研究该个体人的稳定鲁棒性和品质鲁棒性。例 2: 状态设置同例 1, 但扰动为电磁场, 当环境电磁场达到足够量时, 人体系统的状态可能从状态 2 转移到状态 1, 这就引起电磁场致病。为了防止这种情况发生, 又不限制电磁场的有益利用, 需要研究人体对电磁场的稳定鲁棒性和品质鲁棒性, 从而建立有利于人体健康和电磁利用的电磁场限值标准。

生物鲁棒性有以下科学问题: ①模型问题, 需要建立以实验或临床数据为基础的数学模型; ②状态问题, 包括状态变量、状态域、状态转移、状态稳定性等一系列问题; ③限值问题, 外界扰动对生物系统状态转移的极值量及其限值的模糊性; ④性能问题, 生物系统状态转移过程中过渡时间、超调量、扰动强度等指标的变化; ⑤评价问题, 用什么样的指标定量评价生物鲁棒性; ⑥机制问题, 生物鲁棒性的作用机制是什么?

总之, 生物系统建模和生物鲁棒性在医疗、药学、环保、农业等诸多领域的运用具有广阔前景。

参 考 文 献

- [1] 卡斯蒂廖尼. 医学史(上册). 程之范译. 桂林: 广西师范大学出版社, 2003: 443—448.
- [2] 维纳. 控制论(或关于在动物和机器中控制和通信的科学). 北京: 北京大学出版社, 2007: 13—30, 83—96.
- [3] Kunkler K. The role of medical simulation: An overview. *Int. J. Med. Robotics Comput. Assist. Surg.*, 2006, 2: 203—210.
- [4] 孙冬泳, 汤健, 尚彤, 等. 虚拟细胞——人工生命的模型. *中华医学杂志*, 2001, 81(21): 2431—2433.
- [5] Huh D, Matthews B D, Mammoto A, et al. Reconstituting organ-level lung functions on a chip. *Science*, 2010, 328(5986): 1662—1668.
- [6] Kitano H. Towards a theory of biological robustness. *Mol. Sys. Biol.*, 2007, 3: 137.

撰稿人: 包家立
浙江大学医学部

微生物燃料电池

Microbial Fuel Cells

微生物燃料电池 (microbial fuel cells, MFCs) 是一种利用产电微生物将有机物直接转换成电能的装置, 其中的产电微生物是一类具有胞外电子传递功能的细菌。与传统的燃料电池相比, 微生物燃料电池具有原料来源广泛、价格低廉、清洁环保等优点。

图 1 是一种典型的双室微生物燃料电池的示意图, 它主要由阳极、阴极和交换膜构成。微生物在阳极室代谢有机物产生电子并传递给阳极, 电子通过外接电路传递至阴极后将电子释放给阴极室中的氧化剂, 微生物和阳极之间通过电子中介体、纳米导线(菌毛)、细菌表面氧化还原蛋白(细胞色素)三种方式进行电子传递^[1,2]。




图 1 一种典型的双室微生物燃料电池示意图

微生物产电现象是 1911 年由英国植物学家 Potter 首次发现。1999 年, 无介体电子转移的发现使微生物燃料电池的研究获得了重大进展。根据用途的不同, 微生物燃料电池可以分为废水处理微生物燃料电池、环境修复微生物燃料电池、沉积物微生物燃料电池、产氢微生物燃料电池等。其中, 废水处理微生物燃料电池、环境修复微生物燃料电池和沉积物微生物燃料电池利用废水和环境中的

有机物来产生电能；而产氢微生物燃料电池运行时需在微生物燃料电池的阳极外加电压使阴极产生氢气。微生物燃料电池在环境保护、可再生能源、物联网传感节点供电、全自主型机器人等许多领域都有着十分广泛的应用^[3~5]。

目前，国内外关于微生物燃料电池的研究尚处于起步阶段，较低的输出功率仍然是阻碍其应用的瓶颈。影响微生物燃料电池输出功率的因素有很多，其中，微生物燃料电池材料、微生物燃料电池构型及产电微生物是主要影响因素。

(1) 微生物燃料电池材料。微生物燃料电池材料包括阳极材料、交换膜和阴极材料。阳极材料研究的主要目的是提高电极的比表面积、催化活性及电子的转换效率。微生物燃料电池的阳极材料一般为石墨、碳纸和碳布。在最近的研究中，一些多孔材料、贵金属材料及导电高分子材料电极也被应用于微生物燃料电池中。微生物燃料电池中常用的交换膜有阳离子交换膜和阴离子交换膜。交换膜可用于分隔阳极室和阴极室中的液体，并且阻止阴极室的氧气传递至阳极室，从而提高库仑效率，但交换膜的使用也提高了微生物燃料电池的成本，增大了微生物燃料电池的内阻，且交换膜易被污染和堵塞。因此，在研究如何降低交换膜成本，提高交换膜性能的同时，开发无交换膜微生物燃料电池也是一个重要的研究方向。所有用做阳极的材料均可用做阴极。为了提高催化效率，阴极材料往往还需要负载铂等催化剂。最近，利用细菌催化阴极的还原反应成为微生物燃料电池的一个新的研究方向。

(2) 微生物燃料电池构型。微生物燃料电池构型不仅要求装置具有低内阻、高功率、高库仑效率，同时还要求其经济实用、易于放大。目前，微生物燃料电池的构型主要有双室微生物燃料电池、单室微生物燃料电池和管式微生物燃料电池。

(3) 产电微生物。2002年，Park和Zeikus通过在微生物燃料电池中使用混合微生物群落而不用纯培养的微生物，使微生物燃料电池的发电量提高大约6倍。2009年，Lovley通过基因工程手段改造后的*Geobacter*被美国《时代》杂志评为“50项最佳发明”之一，其发电效率是普通*Geobacter*的8倍。这两项发现说明筛选合适的微生物及构建合适的微生物群落是提高微生物燃料电池效率的重要手段。

微生物燃料电池是多学科交叉研究的产物。随着相关学科的发展和融合，微生物燃料电池面临新的发展机遇和挑战。主要研究包括：①电极的改进。制备纳米结构三维电极材料，使之具备高比表面及优良的导电性能、催化性能和生物相容性，从而提高微生物燃料电池的输出功率。②交换膜的改进。进一步开发底物和气体渗透性低、内阻小、成本低新型离子交换膜。③微生物燃料电池构型的改进。进一步优化微生物燃料电池反应器的结构，降低微生物燃料电池内阻和造价，提高微生物燃料电池输出功率、库仑效率及COD去除率，并

最终放大应用于实际。④产电微生物的研究。深入研究电子从胞内传递到胞外和微生物种群之间电子传递的机理、微生物和电极相互作用、微生物种群之间相互作用及微生物电化学进化的机理。⑤混合菌微生物燃料电池的研究。未来不仅要从自然界高效快速筛选高活性产电微生物,同时还要发挥高活性产电菌种群之间的协同作用,采用混合菌微生物燃料电池,提高微生物燃料电池的产电效率,并研究其中微生物群落和代谢途径的变化。⑥分子水平上的研究。从基因水平上对菌种进行改造,使益于产电的基因或蛋白过表达,同时抑制阻碍产电的基因或蛋白表达,从而构建新一代基因工程产电菌微生物燃料电池。

总之,在环境和能源备受关注的今天,开发清洁、可再生新能源已成为世界各国政府的国家战略。微生物燃料电池作为一种新型绿色能源,必将受到越来越多的关注。

参 考 文 献

- [1] Lovley D R. Bug juice: Harvesting electricity with microorganisms. *Nat. Rev. Microbiol.*, 2006, 4(7): 497—508.
- [2] Reguera G, McCarthy K D, Mehta T, et al. Extracellular electron transfer via microbial nanowires. *Nature*, 2005, 435(7045): 1098—1101.
- [3] Lovley D R. The microbe electric: Conversion of organic matter to electricity. *Curr. Opin. Biotech.*, 2008, 19(6): 564—571.
- [4] Reimers C E, Tender L M, Fertig S, et al. Harvesting energy from the marine sediment-water interface. *Environ. Sci. Technol.*, 2001, 35: 192—195.
- [5] Logan B E. *Microbial Fuel Cells*. New York: Wiley, 2008.

撰稿人: 顾忠泽 吴文果
东南大学生物电子学国家重点实验室

单光子源

Single Photon Sources

光子的概念体现了光波粒二相性中粒子性的一面。自 20 世纪初这一概念被提出以来,人们对它的内涵进行了深入的探索,伴随而来的则是新科学问题不断涌现,揭示出光子概念的深刻性。迄今为止,光子的属性仍是物理学研究中一个迷人的基本问题。另一方面,随着对光子认识的深入,人们开始关注光作为粒子的潜在应用。光子是一种静止质量为零的玻色子,它不易与外界耦合的特征使得它便于保持自身的量子状态;另一方面,光子的经典对应是电磁波(光波)。人们对电磁波(光波)的产生、调制、传输、处理、接收等物理功能已经积累了丰富的技术和经验。因此,作为不可替代的量子信息载体,光子特别适合作为“flying qubit”实现量子信息的传递,在量子密钥分配、量子远程传态和量子密集编码等量子信息应用中已经得到实验上的论证。

在量子信息应用中,实现单光子产生的功能器件是单光子源。理想的单光子源应能够在给定时隙内高质量地产生单个光子[如图 1(a)所示]。目前,在量子光学和量子通信实验中,常采用衰减的相干光脉冲作为单光子产生手段,光脉冲的宽度决定了单光子出现的时间范围。然而,相干光脉冲光子数分布规律满足泊松分布,存在一定的多光子概率。若要减小光脉冲中多光子概率,就必须将每脉冲平均光子数水平降得很低($1\% \sim 10\%$),使得脉冲序列中有大量空脉冲出现[如图 1(b)所示]。图 1(c)是平均光子数为 0.1 时脉冲中的光子数分布,可见,衰减的相干光脉冲无法兼顾低空脉冲率和低多光子概率的要求。




图 1 利用衰减相干光脉冲产生单光子

近年来,人们在实现高性能单光子源方面不断努力,提出并论证了若干方案,这些方案从原理上大体可分为基于单发射中心的单光子源和基于关联双光子发射的可预报单光子源。

基于单发射中心的单光子源如图 2 所示,将单个发射中心激励到激发态,通过它的自发辐射发射出单光子。它具有实现单光子按需(on-demand)发射的功能,在量子信息中有重要应用价值。此类单光子源的性能强烈依赖单发射中心特性,要求它具有较窄的自发辐射线宽和很低的非辐射复合。目前,已利用多种材料和物理系统实现了此类单光子源的原理论证,包括单个原子或分子的共振荧光发射^[1]、置于高精密光学微腔内的冷原子单光子发射^[2]和金刚石中的替位氮-空位(N-V)色心的光泵发光^[3]等。近年来,面向量子信息功能器件集成化发展的趋势,基于半导体量子点的全固态单光子源引起人们的关注。已有利用 InAs/GaAs、InGaAs/GaAs、InP/GaInP 和 CdSe/ZnSe 等多种量子点实现光泵单光子发射的实验报道^[4]。另一方面,利用光子微结构或光学微腔增强单发射中心的自发辐射率和发射光子的收集效率也是进一步提升单光子源性能的重要手段。已报道的用于单光子发射的光学微腔包括微柱、微盘和光子晶体微腔等。




图 2 基于单发射中心的单光子源

基于关联双光子发射的可预报单光子源如图 3 所示,它通过探测关联双光子中的一个光子为另一个光子的到达提供触发信号,可在保证低多光子概率的前提下大大降低空脉冲概率。非线性光学晶体中的二阶非线性光学参量下转换是产生关联双光子的常用手段,一般工作在 800nm 波段,基于此的可预报单光子源被广泛应用在量子光学实验中。近年来,在光纤基量子保密通信发展的推动下,利用光学晶体和周期极化光学晶体波导中的参量下转换实现光纤通信波段(1550nm)的可预报单光子源取得很大进展^[5]。同时,利用光纤和硅纳线中自发的四波混频效应产生关联双光子的工作也引起普遍关注^[6,7],以此为基础的可预报单光子源可以充分利用现代光纤通信的成熟技术,是发展实用化单光子源的另一重要途径。




图3 基于关联双光子发射的可预报单光子源

总体而言,单光子源研究处于量子信息、介观物理和光电材料的学科交叉点。目前,这一领域正处于多种方案并存、相互竞争发展的阶段。可以预见,这一研究的突破性进展必将极大地推动量子信息技术的发展,并将人们对光子的认识提升到一个新的高度。

参 考 文 献

- [1] Kimble H J, Dagenais M, Mandel L. Photon anti-bunching in resonance fluorescence. *Phys. Rev. Lett.*, 1977, 39: 691—695.
- [2] McKeever J, Boca A, Boozer A D, et al. Deterministic generation of single photons from one atom trapped in a cavity. *Science*, 2004, 303: 1992—1994.
- [3] Kurtsiefer C, Mayer S, Zarda P, et al. Stable solid-state source of single photons. *Phys. Rev. Lett.*, 2000, 85: 290.
- [4] Zwiller V, Aichele T, Benson O. Quantum optics with single quantum dot devices. *New J. Phys.*, 2004, 6: 96.
- [5] U'Ren A B, Silberhorn C, Banaszek K, et al. Efficient conditional preparation of high-fidelity single photon states for fiber-optic quantum networks. *Phys. Rev. Lett.*, 2004, 93(9): 093601.
- [6] Li X, Voss P, Sharping J E, et al. Optical-fiber source of polarization-entangled photons in the 1550nm telecom band. *Phys. Rev. Lett.*, 2005, 94: 053601.
- [7] Sharping J E, Lee K F, Foster M A, et al. Generation of correlated photons in nanoscale silicon waveguides. *Optics Express*, 2006, 14(25): 12388.

撰稿人: 张 巍
清华大学电子工程系

时间的精确度量

Time Metrology


子在川上曰，逝者如斯夫，不舍昼夜。时间，从文明的开端就走进了人类的生活，几千年来一直是宗教、哲学、物理学和文学的主题。时间是什么？如何定义它？多年来，科学家们一直在思考和深入研究这个问题，特别是 2005 年诺贝尔物理学奖的获得者美国科学家 Hall 和德国科学家 Hansch 的获奖工作^[1,2]，它将人类对时间的测量提高到了一个前所未有的高度。

“日出而作，日落而息。”“时间”源自于我们对日常生活中事件发生次序的认知，时间的度量来源于对两个过程的比较：如两件事同时开始，但一件事结束了另一件事还在进行，我们就说另一件事所需的时间更长。因而我们可以通过可测量的事件来定义时间，再将所有的过程都和一个统一的“标准过程”做对比。在人类早期的农耕时代，人们自然会采用最自然的计时单位——太阳日，即以连续两次经过同一地点的天顶之间的时间间隔作为一“天”，这恐怕也是最早的时间单位了。而且，或许从那时起，人们就开始意识到，时间的度量必须依赖于一个稳定的、可重复的周期性过程，再加上一个计数器和分数器，用于度量持续过程长于及短于这个周期性过程的事件。

标准过程的选择直接决定了人们对时间测量的精度。这有两层含义：第一，标准过程应当不随时间的演化而改变，这就是为什么长久以来人们一直使用天文学来定义时间，虽然我们直到近代才发现天体的运动周期也是在缓慢变化的。一直到 1967 年，国际上才改天文时为原子时标准：1s 定义为铯 133 原子基态的两个超精细能阶间跃迁对应辐射的 9192631770 个周期的持续时间。基于铯 133 的微波振荡器能够输出周期非常稳定的微波，其频率（周期的倒数，也就是微波在 1s 内振荡的次数）的稳定性能达到 10^{-14} ，再利用一个计数器，就可以累计时间。

Hansch 在诺贝尔奖演说词中讲到：“测量什么都不如测量频率。”因为如果频率已知了，时间的测量就是简单的数振荡的个数，这个过程不会有任何的噪声。而针对小于标准过程的度量依赖于分数，就会有误差。所以，现在人们普遍的观点是，标准过程的选择应该周期越小越好，这就是第二层含义。原子时的振荡频率在微波波段，按照上面两个标准，下面的发展就是更高频率的光子时了。因此，当代人们对时间精确度量的问题实际上包含以下两个课题：①更高频率的光学频率标准；②光子振荡的计数。

而实际上，自从原子钟问世以来，人们的研究思路也是沿着上面两个问题进行的。随着精密光谱学的发展，人们很快通过捕获离子或者原子的技术实现了 10^{-18} 精度的光子频率控制，远超过原子时的精度。例如，氢原子 1S 和 2S 两个能级之间跃迁辐射的自然线宽只有 1.3 Hz。图 1(a) 展现了基于光频率标准的光原子钟较基于微波频标的原子钟的优越性。



(a) 光频率标准精度的发展和微波频标的对比

(b) 人类计时方法和相应精度的演进

图 1

然而，光子振荡计数却走了一条艰辛的道路。因为铯微波振荡的频率只有 10^{10} 左右，可以用电子技术来实现计数过程。但是，光频却在 10^{15} 甚至以上，电子技术望尘莫及。唯一的思路就是分频，将光子频率标准和微波频率联系起来，如微波频率是光频的某一分频。方法就是从可以计数的微波频率开始，通过谐波倍频的方式(非线性过程)一步步提高振荡频率，一直到光子频率标准。从微波频率和光子频率之间的巨大差异可以想象，这个“频率链”的建立是多么的复杂，从来没有一条链能够连续工作甚至几分钟。

频率链的问题在 20 世纪 90 年代以让人非常惊讶的简单方式解决了。美国科学家 Hall 和德国科学家 Hansch 分别提出了光频梳的概念。一个光频梳由一组光子频率组成，这些光频率的间隔在微波频率量级，而且间隔非常精确地相等。光频梳的另一个特点是它的频谱宽带至少有一个倍频程，也就是说，它能够同时包含 f 和 $2f$ 范围的光子频率。让人们觉得漂亮的是，这两个光子频率能够通过微波频率联系起来——根据光频梳的特点，它们之间的间隔是某一微波频率

间隔的整数倍，又能通过光子频率联系起来——通过某些控制，其中一个是一个光子频率的两倍。这样，光频梳成功地把微波频率和光子频率联系起来，从而达到分频计数的目的。

在光频梳中，每条光频的大小为 $f_n = nf_{\text{rep}} + f_0$ ；如果通过非线性倍频的方式得到 $2f_n$ ，再将倍频的光和光频梳内频率为 $2f_n$ 的光拍频，就得到如上式所示的频率值 f_0 ，该数值是光频梳和参考梳(以零为起点，间隔同为 f_{rep} 的频梳)的偏差。这样，我们就把光频 f_n 和微波频率 f_{rep} 联系起来了。

光频梳的概念实际上可以追溯到 1978 年，当年斯坦福大学的研究人员首次在实验室中得到了 500GHz 的频率间隔相等的光谱。光频梳从产生开始就被认定是测量光频率的尺子。然而，一直到 1998 年光频梳才实现了对光绝对频率的首次测量，并以此为基础在 2004 年实现了不确定度在 10^{-19} 的光原子钟。为什么图 2 所描述的简单的想法，却费了如此长的时间得到实现的呢？这是由于如果要想实现绝对频率测量，光频梳的载体——窄脉冲光源必须具有严格可控的波包速度(也就是群速度)和光的相速度。然而，这个工作在当时是难以想象的，因为超短脉冲光源的水平在当时只具有皮秒量级，其中包含了无数多个光振荡周期(相位)，两者的控制手法中间间隔了很大的沟壑。直到超短脉冲技术发展到了飞秒(10^{-12})以至阿秒(10^{-15})量级的时候，这个问题才得到解决，即图 2(右)所示的途径。这个途径看似简单，却离不开两个具体技术的发展。一是钛蓝宝石激光器，即基于 Kerr 透镜效应的被动锁模技术(1991 年)，该技术提供了高功率、能够窄至几飞秒的光脉冲，而且非常稳定；另一个技术则是飞秒光脉冲的超连续谱展宽技术，即通过非线性介质使得输入光谱的谱宽得到极大的展宽。各种非线性介质的研究在其中起了决定性的推动作用，最值得一提的就是光子晶体光纤(1995 年)，如图 2(左下)所示。和一般只擅长于导光的普通光纤相比，光子晶体光纤通过其截面上的按照一定规律排列的小孔，实现对光色散的控制，并且能够将光集中到更小面积的纤芯中以极大地提高光强。这两者共同作用，使非线性增强并沿着人们预想的途径对光脉冲进行作用，产生相干的超宽带光谱，对应的将光脉冲的宽度从皮秒推进到阿秒这个领域。

可见，看似简单的想法却需要其他领域长时间的理论和技术手段的积累。光子钟的发展正朝着更高频率的光子技术发展，现在极紫外及 X 射线的光谱学和光频梳技术已经是国际研究的热点，直接推动光原子钟发展的超快光学、阿秒光学也是当前物理学的热门领域。

时间精确度量对物理学最基本的问题到普通人的生活都有重要意义。全球定位系统(GPS)就是在铯原子时的基础上发展起来的，而光子时的发展会使得 GPS 的定位精度进一步提高。现在大家普遍接受的观点是，在国际单位的 7 个基本物理量里面，时间的测量精度是最高的，其他物理量的测量都尽量转化为对




图 2

(左上)实验中观察到的光频梳，在光栅的作用下各个频率的光在空间上依次排列展开；

(左下)光子晶体光纤示意图；(右)基于光频梳的光绝对频率测量或者光频分频

时间的测量。例如，国际上对长度的定义就是基于时间：1m 等于 $1/299792458s$ 的时间间隔内光在真空中行程的长度。时间的精确度量对基本的物理理论也有重要的意义。当前，宇宙学的发展正处于新理论的验证期，很多物理假设和模型都有待更精确的实验测量来确认，如通常人们认为不变的物理常数是否随时间在缓慢变化？

人类对于时间的精确测量走过了一条漫长的道路，从古代的沙漏、近代的钟摆，到现代的石英钟、原子钟，甚至光钟，时间的有效数字的长度越来越长，而相应的我们对自然的理解也越来越深。可以这样说，人类测量时间的有效数字长度本身就是我们对物理理解深度的一把标尺。

参考文献

- [1] Hansch T W .Nobel lecture ;Passion for precision .Reviews of Modern Physics ,2006 ,78(4): 1297—1309 .
- [2] Hall J L .Nobel lecture ;Defining and measuring optical frequencies .Reviews of Modern Physics ,2006 ,78(4):1279—1295 .

撰稿人：戴一堂 徐 坤

北京邮电大学信息光子学与光通信教育部重点实验室

安全方案中的单向函数

The Existence of One-way Functions in Security Schemes

在安全加密方案中,一方面,合法用户利用其所拥有的私密信息,能够容易地解密出消息(即明文),敌手(没有这些私密消息)则不能有效地解密密文(在多项式时间内)。而另一方面,一个非确定性图灵机能够快速地解密密文(如通过猜测秘密信息)。因此,安全加密方案的存在性就意味着有这样一种工作(如“破译”加密方案),这种工作可以由非确定性多项式时间的机器来完成而不能由确定性(甚至是随机)多项式时间的机器来完成。换言之,安全加密方案的存在性的一个必要条件就是 NP 不包含在 BPP 内(因此, $P \neq NP$)^[1,2]。

尽管 $P \neq NP$ 对现代密码学而言是一个必要条件,但却非充分条件。假设破译某个加密方案是 NP 完全的,那么, $P \neq NP$ 就意味着该加密方案在最坏情况下是难以攻破的,但却不能排斥该加密方案在绝大多数情况下是容易攻破的可能性^[2]。事实上,我们可以构造出这样的“加密方案”:攻破该方案是 NP 完全的,而且存在一个有效的破解算法使其成功的概率超过 99%。因此,最坏情况下求解的难度并不适合作为安全性的度量。安全性要求的是在大多数情况下的困难性,或者至少“平均情况下的困难性”。因此,安全加密方案的存在性的一个必要条件是在 NP 中存在一个语言,(求解或判定)该语言的平均难度是困难的。我们还不清楚, $P \neq NP$ 是否就意味着 NP 中该类语言的存在性^[1]。

只考虑在平均情况下计算困难的问题的存在性依然是不够的,为了利用这类平均计算困难的问题,我们必须能够生成困难实例及一些辅助信息,在这些辅助信息的帮助下,可以快速地求解该实例。因此,安全加密方案的存在意味着存在一个有效的方法(即概率多项式时间的算法),利用该方法能够生成实例及其相应的辅助信息,满足:①将该辅助信息作为输入,容易求解该实例;②如果不知道该辅助信息,求解这些实例在通常情况下是困难的。

单向函数就反映了第一个要求。

问题描述:直观地说,单向函数是这样一类函数 $f(x)$:给定变量的值 x ,计算 $y=f(x)$ 是容易的(一般是指在多项式时间内可以计算出);但给定函数值 y ,在一般情况下,计算 x 使得 $y=f(x)$ 是困难的(不能在多项式时间内计算出)。单向函数的存在性问题的指:在假定计算复杂性假设“ $NP \setminus BPP \neq \emptyset$ ”成立的情况下,单向函数是否一定存在。一些问题被猜测是单向函数,如整数分解、离散对数、随机线性码解码、子集和问题等^[3]。

单向函数的存在性是现代密码学的基石，密码学中的伪随机数生成器、伪随机置换、公钥密码算法等几乎所有的密码学基础构件都和单向函数的存在性息息相关。很显然，单向函数的存在意味着计算复杂性假设“ $NP \setminus BPP \neq \emptyset$ ”成立(因此， $P \neq NP$)，但到目前为止，人们还不知道“ $NP \setminus BPP \neq \emptyset$ ”是否意味着单向函数的存在性^[1]。这个问题和计算复杂性问题的平均难度有关，任何关于“ $NP \setminus BPP \neq \emptyset$ ”隐含某种形式的平均难度及后者隐含单向函数存在性的研究结果都是令人振奋的。

参 考 文 献

- [1] Goldreich O, Foundations O F C. Foundations of Cryptography :Basic Tools .Cambridge: Cambridge University Press ,2001 .
- [2] Papadimitriou C H .Computational Complexity .New York ;Wiley ,2003 .
- [3] Katz J ,Lindell Y .Introduction to Modern Cryptography .New York ;Chapman & Hall/ CRC ,2008 .

撰稿人：王天择
中国科学院软件研究所

密码学中的整数分解问题

Integer Factorization Problem in Cryptography

整数分解问题在代数学、密码学和计算复杂性等领域中都有着重要意义,而且整数分解问题的困难性假设则是许多现代密码算法安全性的基础。如果能够找到解决整数分解问题的快速方法,那么,现有的几个重要的密码系统将会被攻破,包括 RSA 公钥密码算法和 Blum-Blum-Shub 随机数生成器等。

一般形式的整数分解问题是数学上的难题,至今人们还没有找到多项式时间算法来解决这个问题,但相对应的素数的判定问题是容易的,因为计算实例和解的最大公因子的算法就是一个解答检验器。整数分解问题和素性检测问题是密切联系在一起的^[1]。要分解一个整数,首先需要判断这个整数是否是素数。判断素数的问题称为素性检测。由于素性检测问题存在有效的随机算法,可以在多项式时间内解决,因此,我们所指的整数分解主要是针对合数的分解,这个问题实例的概率分布尚不清楚^[2]。

大整数分解问题:给定一个正整数 n , 将 n 分解成素因子的乘积 $n = p_1^{e_1} p_2^{e_2} \cdots p_k^{e_k}$, 其中, $p_1 < p_2 < \cdots < p_k$, 且 p_i 是素数, $e_i \geq 1$ 是自然数。根据算术基本定理^[3], 这样的分解结果是唯一的。

在密码学中, 整数 n 通常被选取 $p \cdot q$ 或 $p^2 \cdot q$ 的形式, 其中, p 、 q 是大小相近的、随机产生的素数, 因为这些是对现行的分解算法最困难的一些实例。

这个问题的研究已经有了很长的历史。现代分解整数的算法主要分为两大类: 第一类算法侧重于快速寻找 n 的较小的素因子, 其运行时间依赖被分解整数本身的未知因子的大小、类型等, 这些算法包括试除法、欧几里得算法、 $p \pm 1$ 方法^[4]、Pollard ρ 方法^[5]、Fermat 分解方法、平方型分解算法^[6]、椭圆曲线分解算法及特殊数域筛法等; 第二类分解整数的算法中不考虑素因子的长度, 其运行时间仅仅依赖要分解的整数的长度, 所以, 当对很大的整数进行分解时, 花费的代价相对比较大, 这些算法大部分基于平方同余方法^[7], 包括连分数方法、二次筛法和数域筛法等。目前, 公认的最有效因子分解算法有二次筛法、数域筛法和椭圆曲线分解算法。现在已知最好的整数分解算法比指数时间算法要快, 比多项式时间算法要慢, 是所谓的亚指数时间算法。

19 世纪 60 年代, 当时的最好算法需要的时间是 $O(n^c)$ 。后来, Morrison 和 Brillhart 引入连分数的方法, 把分解时间降低到 $O(\exp((\sqrt{2} + o(1)) \sqrt{\ln n \ln \ln n}))$ 。随着数学、计算机科学、密码学和通信方面的发展, 大整数分解的算法也在不

断改进,可以分解的大整数的记录也在不断地被刷新。

对于普通的计算机,现在最好的整数分解算法是一般数域筛法(GNFS)。1989年,Lenstra和Manasse利用二次筛法且通过把计算分配给成百个工作站的办法分解了一个116位的十进制整数。1990年,Lenstra等利用数域筛法把 $2^{512}-1$ 分解成三个素数,这三个素数分别是7位、49位和99位十进制数。1994年4月,Atking等使用二次筛法分解了一个129位的十进制整数。1999年的2月和7月,在RSA数字安全公司开展的RSA合数分解竞赛中,参赛者使用数域筛法,分解了一个130位的十进制数和一个155位的十进制数。而特殊数域筛法的记录是日本人2004年4月创造的,他们成功分解了 $2^{821}+2^{411}+1$,这是一个248位的十进制数。最近的一个分解一般形式的整数的纪录是由德国国家信息技术安全机构保持的,利用一般数域筛法,他们在2005年5月9日成功分解了一个663位二进制(200位十进制)的一般形式的整数。目前,普遍相信分解一个1024位的大整数是可能的,只是在没有特殊硬件支持的情况下,代价是非常巨大的。

不过,对于量子计算机而言,整数分解问题有其特殊的量子算法来予以解决。早在1994年,Shor发现了一个只使用 $O(\log n)$ 个量子比特、 $O((\log n)^3)$ 次量子运算来分解一个整数 n 的量子计算机算法^[8]。如果实用的量子计算机被制造出来,那么,大整数分解问题在多项式时间内就将得以解决。

参 考 文 献

- [1] France M M, Tenenbaum G. 素数论. 姚家燕译. 北京: 清华大学出版社, 2007.
- [2] Riesel H. Prime Numbers and Computer Methods for Factorization. Boston: Birkhäuser, 1985.
- [3] 裴定一, 祝跃飞. 算法数论. 北京: 科学出版社, 2002.
- [4] von Zur Gathen J, Gerhard J. Modern Computer Algebra. Cambridge: Cambridge University Press, 2002.
- [5] Brent R P. An improved Monte Carlo factorization algorithm. BIT Numerical Mathematics, 1980, 20(2): 176—194.
- [6] Gower J E, Wagstaff S S. Square form factorization. Mathematics of Computation, 2008, 77(261): 551—588.
- [7] Dixon J D. Asymptotically fast factorization of integers. Mathematics of Computation, 1981, 36(153): 255—260.
- [8] Singh S. 密码故事. 朱晓蓬, 林金钟译. 海口: 海南出版社, 2001.

撰稿人: 赵 岩
中国科学院软件研究所

RSA 问题

RSA Problem

RSA 问题：给定一个长为 l 的合数 n ，一个和 $\varphi(n)$ 互素的整数 e ，以及 $y \in \mathbf{Z}_n^*$ （由所有模 n 的可逆元组成的集合），求解 $x \in \mathbf{Z}_n^*$ 使得 $y = x^e$ 。

RSA 问题的参数主要有两个：一个是整数 n 的长度 l ，另一个是指数 e 的大小。像整数分解问题一样，实例的概率分布还不清楚。唯一知道的解决 RSA 问题的方法是求解 n 的整数分解问题。假设 RSA 问题是难处理的，称为 RSA 假设。RSA 问题相应的判定问题是容易的，因为判定 x^e 是否等于 y 的算法就是一个解答检验器。

在 RSA 问题中，如果取消 e 和 $\varphi(n)$ 互素的要求，对于给定的长为 l 的合数 n 和 $y \in \mathbf{Z}_n^*$ ，求解 $x \in \mathbf{Z}_n^*$ 和 $e > 1$ 使得 $y = x^e$ 的问题称为柔性 RSA 问题。假设柔性 RSA 问题是难处理的，称为强 RSA 假设^[1]。

当前，最著名、应用最广泛的公钥系统 RSA 是由麻省理工学院的 Rivest、Shamir、Adelman 于 1979 年提出来的，它的安全性就是基于 RSA 问题的困难性（事实上，RSA 问题的命名也是由此而来）^[1,2]。RSA 算法的安全性依赖于分解大整数的困难性。如果密码分析者能从用户的公钥 n 在多项式时间内求出 p 和 q ，那么，RSA 算法将是不安全的。因此，RSA 需采用足够大的整数。

RSA 体制的提出使得人们更加关注整数分解问题，促进了整数分解算法的发展。19 世纪 60 年代，当时的最好算法需要的时间是 $O(n^2)$ 。后来，Morrison 和 Brillhart 引入连分数的方法，把分解时间降低到 $O(\exp((\sqrt{2} + o(1)) \sqrt{\ln n \ln \ln n}))$ 。现代的分解决整数的算法主要分为两大类：第一类算法侧重于快速寻找 n 的较小的素因子，这些算法包括试除法、Pollard ρ 方法、 $p \pm 1$ 方法及椭圆曲线分解算法；第二类分解整数的算法中不考虑素因子的长度，所以，当对很大的整数进行分解时，花费的代价相对比较大，这些算法包括连分数方法、数域筛法和二次筛法^[3,4]。

目前，最有效因子分解算法有二次筛法、数域筛法和椭圆曲线分解算法。1989 年，Lenstra 和 Manasse 利用二次筛法且通过把计算分配给成百个工作站的办法分解了一个 116 位的十进制整数。1994 年 4 月，Atking 等使用二次筛法分解了一个称作 RSA-129 的 129 位的十进制整数。1990 年，Lenstra 等利用数域筛法把 $2^{2^9} + 1$ 分解成三个素数，这三个素数分别是 7 位、49 位和 99 位十进制数。1999 年的 2 月和 7 月，在 RSA 数字安全公司开展的 RSA 合数分解比赛中，

参赛者使用数域筛方法，分解了 RSA-130 和 RSA-155。最新的记录是 2005 年 5 月和 11 月，德国科学家分解了 663 比特的整数 RSA-200 和 640 比特的 RSA-640。

参 考 文 献

- [1] 裴定一,祝跃飞.算法数论.北京:科学出版社,2002.
- [2] 冯登国,裴定一.密码学导引.北京:科学出版社,1999.
- [3] Boneh D,Venkatesan R.Breaking RSA may not be equivalent to factoring .Eurocrypt'98,1998.
- [4] Rivest R,Kaliski B.RSA problem//van Tilborg H C A .Encyclopedia of Cryptography and Security .New York :Springer,2005.

撰稿人：冯登国
中国科学院软件研究所

安全方案中的离散对数问题

The Discrete Logarithm Problem in Security Schemes

离散对数问题是具有较长历史的数论问题, 原始的定义是在有限域的乘法群 $\mathbf{Z}_p^*$ 上给出的, 其中, p 是素数。由于 $\mathbf{Z}_p^*$ 是循环群, 令 α 是本原元, 对于给定的元素 $\beta \in \mathbf{Z}_p^*$, 有唯一的表示 $\beta = \alpha^a$, a 称为 β 相对于基底 α 的离散对数。最初, 离散对数问题只用来进行一些有限域中的计算, 并且和大整数分解问题一样被人们忽视, 但是, 后来大整数分解问题被数学家高斯等关注。直到 20 世纪, 随着计算能力的提高, 越来越多的算法层面的问题被提出, 此时, 离散对数问题才受到人们的关注。离散对数问题第一次在密码学中发挥重要作用是 1950 年移位寄存序列的出现, 用来检测移位寄存序列的特殊状态。但是, 离散对数问题真正被广泛关注, 还是由于 Diffie-Hellman 协议的提出, 并且直到作为密码协议中的一大类公钥密码算法的 ElGamal 算法被提出, 离散对数问题作为 ElGamal 算法基于的计算难题, 才成为著名的密码学问题之一^[1]。

ElGamal 算法: 设 p 是一个素数且离散对数问题在 $\mathbf{Z}_p$ 上是难处理的, $\alpha \in \mathbf{Z}_p^*$ 是一个本原元。 $P = \mathbf{Z}_p^*$, $C = \mathbf{Z}_p^* \times \mathbf{Z}_p^*$, $K = \{(p, \alpha, a, \beta) \mid \beta \equiv \alpha^a \pmod{p}\}$ 。值 p , α 和 β 是公开的, a 是保密的。

对 $K = (p, \alpha, a, \beta)$ 和一个秘密地随机选择的数 $k \in \mathbf{Z}_{p-1}$, 对于消息明文 x , 定义加密算法 $E_k(x, k) = (y_1, y_2)$, 其中, $y_1 = \alpha^k \pmod{p}$, $y_2 = x\beta^k \pmod{p}$ 。对于密文 $y_1, y_2 \in \mathbf{Z}_p^*$, 则定义解密算法 $D_k(y_1, y_2) = y_2 (y_1^a)^{-1} \pmod{p}$ 。

随着对离散对数问题的深入研究, 发现事实上其与整数分解问题有着紧密的关系。如果能够解决离散对数问题, 那么, 也就能解决整数分解问题, 但逆命题的正确性还未得到证明。实际上, 如果 p 是一个素数, 那么, 求解 $\mathbf{F}_p$ 上离散对数问题的复杂性相当于对同样大小的一个整数 n (n 是两个大致等长的素数的乘积) 进行因子分解的复杂性, 目前, 比较好的渐近时间估计值为 $e^{(1.923 + o(1))(\ln(p))^{(1/3)}(\ln(\ln(p)))^{(2/3)}}$ 。

广义离散对数问题: 设 G 是一个 n 阶循环群, α 是 G 的生成元。对于给定的元素 $\beta \in G$, 存在唯一的整数 $0 \leq x \leq n-1$, 使得 $\alpha^x = \beta$, 求解 β 相对于基底 α 的离散对数 x , 记为 $\log_\alpha \beta$ 。

广义离散对数问题可以有不同的表现形式, 即关于循环群 G 的选取方法有很多。除了原始离散对数问题中选取的有限域乘法群 $\mathbf{Z}_p^*$ 外, 还可选取有限域上椭圆曲线有理点群、有限域上超椭圆曲线的 Jacobi、虚二次域的理想类群等的循

环子群。有限域上的离散对数问题被研究的最透彻,应用的也最早。但是,随着椭圆曲线离散对数问题的提出,并且理论和计算逐渐趋于完善,在密码学中已取代了原始的离散对数问题。

下面是在密码学中常用的4种循环群:①小特征的有限域的乘法群 $G = F_p^{*n}$, 其中, p 为小素数,一般取 $p=2, 3$, 且 n 是大整数;②大特征的有限域的乘法群 $G = F_p^{*n}$, 其中, p 为大素数,且 n 是小整数,通常取 $n=1$;③特征2的有限域上椭圆曲线有理点群 $E(F_2^n)$ 的大素数阶循环子群,其中, n 是大整数;④特征 p 的有限域上椭圆曲线有理点群 $E(F_p)$ 的大素数阶循环子群,其中, p 是大素数。

离散对数问题的困难性和群的表述形式是密切相关的。对于循环群1和2,一般认为,若仔细选择 p , 则该问题是困难的,目前还没有多项式时间算法。对于循环群3和4,当避免所选取的椭圆曲线是异常的时,则问题是困难的,没有多项式时间算法。特别的,当所选取的椭圆曲线不是超奇异或嵌入次数不是很小时,即排除了利用 MOV 或 FR 约化攻击的可能,此时甚至没有亚指数时间算法。由于被排除的椭圆曲线只是一少部分,而可使用的椭圆曲线非常多,因此,人们普遍相信椭圆曲线离散对数问题要比有限域中离散对数问题更困难^[2]。

现在,已知的计算离散对数问题的算法主要分为以下三类^[3,4]:

第一类是对任意群都适用的一般性算法,如穷举搜索算法、Shanks 的大步小步算法和 Pollard ρ 方法。穷举搜索算法是指通过连续计算 $\alpha, \alpha^2, \dots$ 直到 β 出现为止。这种计算方法需要进行 $O(n)$ 次乘法运算,其中, n 是 α 的阶,因此,当 n 比较大时,效率很低。Shanks 算法是一种时间-空间折中的穷举搜索算法,其运行时间和存储空间均为 $O(\sqrt{n})$ 。Pollard ρ 方法是一个随机化算法,其期望运行时间和 Shanks 算法相同,但其存储空间是一个可以忽略的量。利用 Pollard ρ 方法的随机化思想,之后又出现了更为有效的带随机步的 Pollard ρ 方法^[5]、并行的 Pollard ρ 方法^[6]等。但是, $O(\sqrt{n})$ 被认为是目前一般性算法的平均复杂度。

第二类也是适用于任何群的一般性算法,如果群的阶只有较小的素因子,则这类算法对于计算这些群上的离散对数尤其有效,如 Pohlig-Hellman 算法。Pohlig-Hellman 算法是利用群 G 的阶数 n 的素因子分解来计算离散对数的。设给定的分解式为 $n = P_1^{e_1} P_2^{e_2} \cdots P_k^{e_k}$, 其中, P_i 两两互素, $e_i \geq 1$, 则这种算法需要进行 $\sum_{i=1}^k e_i (\lg n + \sqrt{P_i})$ 次乘法运算。对于求解离散对数问题的一般性方法, Shoup^[7] 证明了如果 p 是群 G 的阶的最大素因子,则求解 G 中离散对数问题的一般性方法至少要用 $O(\sqrt{p})$ 个群操作。

第三类算法则是只对有些群适用的特殊算法,例如,指数演算算法是最早

的求解有限域上离散对数问题的亚指数时间算法。指数演算需要选取 G 的一个因子基 B , 通过预计算找到因子基中的各个元素的对数, 然后利用因子基中元素对数知识计算期望的元素 β 的离散对数。该算法在预计算阶段的时间复杂度是 $O(e^{1+O(1)\sqrt{\ln p \ln \ln p}})$, 找到单个的离散对数的时间复杂度为 $O(e^{1/2+O(1)\sqrt{\ln p \ln \ln p}})$ 。目前, 数域筛法^[8]是大特征有限域中的循环群(2)上求解离散对数问题的最快算法, 并且时间复杂度是 $O(e^{1.923+O(1)(\ln p)^{1/3} \ln^{2/3} \ln p})$ 。而函数域筛法^[9]是小特征有限域中的循环群(1)上求解离散对数问题的最快算法, 并且时间复杂度是 $O(e^{1.526+O(1)(\ln p)^{1/3} \ln^{2/3} \ln p})$ 。

最后, 对于椭圆曲线上离散对数问题^[2], 当椭圆曲线或有限域选取的很特殊时, 会有一些较快的算法。目前, 求解一般的椭圆曲线上离散对数问题较快的算法仍是 Pollard ρ 和 Pollard λ 方法。对于元素个数为 n 的循环群, 它们的计算复杂性分别是 $\sqrt{\pi n/2}$ 和 $2\sqrt{n}$, 而实际中常使用它们带随机步的并行版本。

参 考 文 献

- [1] Schneier B. 应用密码学. 吴世忠, 等译. 北京: 机械工业出版社, 2000.
- [2] Koblitz A H, Koblitz N, Menezes A. Elliptic curve cryptography: The serpentine course of a paradigm shift. Journal of Number Theory, 2009.
- [3] McCurley K S. The discrete logarithm problem. Cryptography and Computational Number Theory, Proceedings of Symposia in Applied Mathematics, 1990, 42: 49—74.
- [4] Odlyzko A. Discrete logarithms: The past and the future. Designs, Codes and Cryptography, 2000, 19(2—3): 129—145.
- [5] Teske E. Speeding Up Pollard's Rho Method for Computing Discrete Logarithms. New York: Springer, 1998: 541—554.
- [6] van Oorschot P C, Wiener M J. Parallel collision search with cryptanalytic applications. Journal of Cryptology, 1999, 12: 1—28.
- [7] Shoup V. Lower bounds for discrete logarithms and related problems. Advances in Cryptology—EUROCRYPT'97, 1997, 1233: 256—266.
- [8] Gordon D M. Discrete logarithms in $GF(p)$ using the number field sieve. SIAM Journal on Discrete Mathematics, 1993, 6: 124—138.
- [9] Adleman L M, Huang M A. Function field sieve method for discrete logarithms over finite fields. Information and Computation, 1999, 151: 5—16.

撰稿人: 张旭升
中国科学院软件研究所

Diffie-Hellman 问题

Diffie-Hellman Problem

1976 年, Diffie 和 Hellman 联合发表了一篇论文^[1], 第一次提出了公钥密码学的思想, 这篇论文被认为是密码学的一次革命, 这两位科学家被誉为现代密码学的奠基人。虽然这篇经典的论文没有给出一个公钥密码方案, 但它首创性地提出了第一个带有公钥性质的密钥交换协议, 即 Diffie-Hellman 协议。基本思想为: 当 Alice 和 Bob 想在不安全的信道上通信时, 需要生成一个秘密的公共密钥, 因此, 他们在循环群 $G = \langle g \rangle$ 中, 首先选取两个数 $S_A, S_B \in [0, |G|-1]$, 再分别计算 $g^{S_A}, g^{S_B} \in G$, 并且在不安全信道上交换 g^{S_A} 和 g^{S_B} , 从而 Alice 和 Bob 可以分别计算出 $a_{AB} = g^{S_A S_B}$ 和 $a_{BA} = g^{S_B S_A}$, 由于 $a_{AB} = a_{BA}$, 则 Alice 和 Bob 共享了公共密钥。后来, 人们进一步证明了当群 G 的阶至少含有一个大素因子时, 按某种一致分布随机地选取 S_A, S_B , 则公共密钥 a_{AB} 也近似地满足某种一致分布。循环群有很多取法, 如有限域乘法群、有限域上椭圆曲线有理点群、有限域上超椭圆曲线的 Jacobi、虚二次域的理想类群等的循环子群。

上述 Diffie-Hellman 协议基于的数学问题就是 Diffie-Hellman 问题, 简单地讲, 即是在已知 g^{S_A} 和 g^{S_B} 但未知 S_A, S_B 的情况下, 如何有效地计算出 $g^{S_A S_B}$ 。显然, Diffie-Hellman 问题的难度不会超过离散对数问题, 其中, 离散对数问题即是在循环群 G 中已知 $a = g^S \in G$, 如何有效地计算出 S 。所以, Diffie-Hellman 问题可以归约到离散对数问题。对于 Diffie-Hellman 问题和离散对数问题的一般算法, 即已知群元素有唯一表示, 但不利用任何表示的性质的算法。Shoup 在文献[2]中证明了这两种问题的一般算法复杂度都是 $\Theta(\sqrt{p})$, 其中, p 是群阶 n 的最大的素因子。后来, Maurer 和 Wolf 在文献[3]中证明了存在离散对数问题到 Diffie-Hellman 问题的一个多项式时间的一般归约, 当且仅当群阶 n 的所有重素因子的大小为 $(\log n)^{O(1)}$ 。

由于 Diffie-Hellman 问题或离散对数问题的困难性都依赖于循环群 G 中最大素数阶子群上问题的困难性, 所以, 后面我们都将局限在素数阶的循环群上考虑问题。

一般地, Diffie-Hellman 问题可分为计算性 Diffie-Hellman 问题 (CDH 问题) 和判断性 Diffie-Hellman 问题 (DDH 问题)。事实上, 前面讨论的就是计算性 Diffie-Hellman 问题。

计算性 Diffie-Hellman 问题: 令 G 是 q 阶循环群, 其中, q 为大素数, g 是

群 G 的生成元, 已知 g , 对于随机选取的群中元素 g^x 和 g^y , $x, y \in \mathbf{Z}_q$ 为随机选取的指数, 计算 g^{xy} 。一个可解决计算性 Diffie-Hellman 问题的算法是指以 g 、 g^x 、 g^y 为输入, 以一个不可忽略的概率输出 g^{xy} 的概率多项式时间图灵机。

等价问题如下: ①平方计算性 Diffie-Hellman 问题(SCDH 问题)。已知 g , 随机选取 g^x , 计算 g^{x^2} 。②求逆计算性 Diffie-Hellman 问题(InvCDH 问题)。已知 g , 随机选取 g^x , 计算 $g^{x^{-1}}$ 。③可除计算性 Diffie-Hellman 问题(DCDH 问题)。已知 g , 随机选取 g^x 和 g^y , 计算 $g^{y/x}$ 。

文献[4]证明了上述三个变形的计算性 Diffie-Hellman 问题都与原计算性 Diffie-Hellman 问题等价, 即原计算性 Diffie-Hellman 问题可以通过多项式时间算法约化到任意一个变形的计算性 Diffie-Hellman 问题, 同时, 每个变形的计算性 Diffie-Hellman 问题也可以通过多项式时间算法约化到原计算性 Diffie-Hellman 问题, 简记为: $\text{CDH} \Leftrightarrow \text{SCDH} \Leftrightarrow \text{InvCDH} \Leftrightarrow \text{DCDH}$ 。

判断性 Diffie-Hellman 问题: 令 G 是 q 阶循环群, 其中, q 为大素数, g 是群 G 的生成元, 区分如下两种情况: 情况 1, 随机选取四元组 g, g^x, g^y, g^{xy} , 其中, $x, y \in \mathbf{Z}_q$ 为随机选取的指数; 情况 2, 随机选取四元组 g, g^x, g^y, g^r , 其中, $x, y, r \in \mathbf{Z}_q$ 为随机选取的指数。可解决判断性 Diffie-Hellman 问题的算法是指一个有效区分上述两种情况的多项式时间统计检验。一种等价的问题描述是: 对于随机选取的 g^x, g^y, g^r , 其中, $x, y, r \in \mathbf{Z}_q$, 判断是否 $xy=r$ 。

等价问题如下: ①平方判断性 Diffie-Hellman 问题(SDDH 问题)。已知 g , 随机选取 g^x 和 g^r , 判断 $r=x^2$ 。②求逆判断性 Diffie-Hellman 问题(InvDDH 问题)。已知 g , 随机选取 g^x 和 g^r , 判断 $r=x^{-1}$ 。③可除判断性 Diffie-Hellman 问题(DDDH 问题)。已知 g , 随机选取 g^x, g^y, g^r , 判断 $r=y/x$ 。

文献[4]中证明了: $\text{InvDDH} \Leftrightarrow \text{SDDH} \Leftarrow \text{DDH} \Leftrightarrow \text{DDDH}$ 。

在应用中, 密码格式的安全性要归约到 Diffie-Hellman 问题的困难性, 所以, 提出了 Diffie-Hellman 问题的困难性假设, 即对于一般群不存在可解决 Diffie-Hellman 问题的算法。对于有限域乘法群的素数阶子群上的计算性 Diffie-Hellman 问题和判断性 Diffie-Hellman 问题的困难性假设都是被普遍认可的, 但椭圆曲线的素数阶有理点群上的判断性 Diffie-Hellman 问题却是容易的, 尽管认为其上的计算性 Diffie-Hellman 问题要比有限域乘法群上的计算性 Diffie-Hellman 问题困难。因此, 判断性 Diffie-Hellman 问题困难性假设是为保证密码算法安全性的较强的假设。类似地, 文献[3]中给出判断性 Diffie-Hellman 问题的一般算法复杂度是 $\Omega(\sqrt{q})$ 。当群阶为 n 时, q 则是 n 最小的素因子, 并且从判断性 Diffie-Hellman 问题到计算性 Diffie-Hellman 问题的一般归约的复杂度是 $\Omega(\sqrt{p})$, p 是群阶 n 的最大的素因子。

随着 Pairing-Based 密码系统的提出和应用, 基于双线性对计算性 Diffie-Hellman 的双线性 Diffie-Hellman 问题(BDH 问题)也被提出了, 参见文献[5]。但双线性 Diffie-Hellman 问题也可归约到计算性 Diffie-Hellman 问题, 或者说双线性 Diffie-Hellman 问题的难度不超过计算性 Diffie-Hellman 问题。

计算性 Diffie-Hellman 问题、判断性 Diffie-Hellman 问题、双线性 Diffie-Hellman 问题的困难性假设都不能完全实用有效地保证 Diffie-Hellman 协议等的安全性。例如, 在无法计算计算性 Diffie-Hellman 问题的情况下, 仍然有可能计算出公共密钥的一部分重要的比特位, 使得通信不安全, 具体的关于 Diffie-Hellman 问题比特位的复杂度分析参见文献[6]。为了能够给出密码格式的可证明安全性及新的密码格式, 后来又分别提出了 Gap-Diffie-Hellman 问题和 Twin-Diffie-Hellman 问题, 以及相应的困难性假设, 参见文献[7]、[8]。

参 考 文 献

- [1] Diffie W, Hellman M E. New directions in cryptography. IEEE Transactions on Information Theory, 1976, 22(6): 644—654.
- [2] Shoup V. Lower bounds for discrete logarithms and related problems. Advances in Cryptology—EUROCRYPT'97, 1997: 256—266.
- [3] Maurer U M, Wolf S. The relationship between breaking the Diffie-Hellman protocol and computing discrete logarithms. SIAM Journal on Computing, 1999, 28(5): 1689—1721.
- [4] Bao F, Deng R H, Zhu H F. Variations of Diffie-Hellman problem. ICICS 2003, 2003: 301—312.
- [5] Galbraith S D, Hopkins H J, Shparlinski I E. Secure bilinear Diffie-Hellman bits. ACISP 2004, 2004: 370—378.
- [6] Blake I F, Garefalakis T. On the complexity of the discrete logarithm and Diffie-Hellman problems. Journal of Complexity, 2004, 20: 148—170.
- [7] Okamoto T, Pointcheval D. The gap problems: A new class of problems for the security of cryptographic schemes. PKC 2001, 2001: 104—118.
- [8] Cash D, Kiltz E, Shoup V. The Twin-Diffie-Hellman problem and applications. Journal of Cryptology, 2009, 22: 470—504.

撰稿人: 张旭升
中国科学院软件研究所

格约化问题

Lattice Reduction Problem

格约化的出现可以追溯到 18、19 世纪 Lagrange 和高斯关于二次型的约化研究。现代，格在计算数论、计算代数，特别是在公钥密码学上又得到了诸多重要应用，格约化问题被人们重新重视起来。20 世纪 80 年代，基于格约化技巧，Lenstra 找到一个非多项式时间的整数规划算法，Lovász 受其启发，又发展得到了一种求格的约化基的多项式时间算法，最后形成了著名的“LLL”算法^[1]。

格是实数域 $\mathbf{R}$ 上 n 维向量空间的一个离散加法子群^[1]。具体地说，一个格 L 由 $\mathbf{R}^n$ 中一组线性无关的向量的所有整系数线性组合所构成，即

$$L = \left\{ \sum_{i=1}^d n_i \mathbf{b}_i : n_1, \dots, n_d \in \mathbf{Z} \right\}$$

式中， $\{\mathbf{b}_1, \dots, \mathbf{b}_d\}$ 是 $\mathbf{R}^n$ 的一组线性无关的向量。这样一组向量称为格 L 的一组基。一个格有多个基，所有的基都包含有相同个数的向量，这个相同的个数称为格 L 的维数。当维数大于或等于 2 时，格有无限多个基。在解决格上相应问题时，即使在同一算法下，选择不同的基，所需的计算量也可能会相差很大。所以，我们希望能从这些不同的基中找到满足一定条件的基，使得采用这样的基有利于相应问题的解决，选择这组基的过程就称为格约化。一般地，格约化的目的是要找到格的一组尽可能短的、几乎正交的基。

关于格，有两个有名的问题^[2]：一个称作最短向量问题(SVP)，另一个称为最近向量问题(CVP)。用 $\|\cdot\|$ 表示 $\mathbf{R}^n$ 中欧几里得范数，则这两个问题的表述如下。

最短向量问题(SVP)：给定格 L 的任意一组基，寻找一个 L 中的最短向量，即非零向量 $\mathbf{x} \in L$ ，使得 $\|\mathbf{x}\|$ 最小。带有因子 k 的近似 SVP 是指寻找一个非零向量 $\mathbf{y} \in L$ 使得 $\|\mathbf{y}\| \leq k \|\mathbf{x}\|$ ，其中， $k \geq 1$ 是一个与格维数 n 有关的参数， $\mathbf{x}$ 是一个最短向量。

最近向量问题(CVP)：给定格 L 的任意一组基和一个目标向量 $\mathbf{t} \in \mathbf{R}^n$ ，寻找一个离 $\mathbf{t}$ 最近的格向量，即向量 $\mathbf{x} \in L$ ，使得 $\|\mathbf{x} - \mathbf{t}\|$ 相对所有格向量来说最小。带有因子 k 的近似 CVP 是指寻找一个非 $\mathbf{t}$ 向量 $\mathbf{y} \in L$ 使得 $\|\mathbf{y} - \mathbf{t}\| \leq k \|\mathbf{x} - \mathbf{t}\|$ ，其中， $k \geq 1$ 是一个与格维数 n 有关的参数， $\mathbf{x}$ 是一个离 $\mathbf{t}$ 最近向量。

显然，当 k 等于 1 时，近似 SVP 就是 SVP，近似 CVP 就是 CVP。格约化是研究这两个著名问题的重要工具。

在格约化问题中,有两个参数:一个是格的维数,另一个是向量的长度,其中,格的维数决定了格约化问题的难度。随着格的维数的增加,问题的复杂度也会增加。CVP 和带有拟多项式因子 $2^{\log(1-\epsilon_n)}$ 的近似 CVP 都是 NP-hard 的,而 SVP 和带有常数因子的近似 SVP 在随机归约下也都是 NP-hard 的。

针对近似 SVP,有两个重要的关于复杂性的公开问题。

猜想,对任意固定的 $\delta \geq 0$, $k = n^\delta$,即使是在量子算法下,带参数 k 的近似 SVP 也是难的,即不存在多项式时间算法,这正是激发大家研究格基密码学的出发点。

对 $k = n^\delta$ ($\delta > 0$),如令 $\delta = 2$,带参数 k 的近似 SVP 是不是至少和整数分解问题一样难?如果是,则格基密码学将比 RSA 更安全。

CVP 看起来比 SVP 要难,而事实上,SVP 也可能不比 CVP 更容易。给了一个解答带有因子 $f(n)$ 的 CVP 的预言机,我们可以在多项式时间内求解带有同样因子 $f(n)$ 的近似 SVP。相应地,Kannan 证明了利用任何一个求解非递减函数因子 $f(d)$ 的近似 SVP 的算法,都可求解带有因子 $n^{3/2} f(n)^2$ 的近似 CVP。但是,SVP 和 CVP 的 NP 困难性是有局限的,Goldreich 和 Goldwasser 证明了带有因子 $\sqrt{n/\log n}$ 的近似 SVP 和 CVP 不是 NP-hard 的,除非有关复杂性理论中的多项式时间层次结构坍塌,而这是非常不可能的。

目前,求解 SVP 最好的算法是 AKS 筛法,这是一个概率算法,时间复杂度为 $2^{O(n)}$,而求解 CVP 的最好算法则是 Kannan 的超指数算法,时间复杂度为 $2^{O(n \log n)}$ 。对于近似问题,最好的算法是结合了 AKS 算法的 Schnorr 的 BKZ 算法,这是一个亚指数的算法,近似因子为 $2^{O(n(\log \log n)^2 / \log n)}$ [3]。

参 考 文 献

- [1] Nguyen P Q, Stern J. Lattice reduction in cryptology: An update. Algorithmic Number Theory, 2000.
- [2] Wan D Q. Lattices and code. Lecture Script in Morningside Center of Mathematics. Beijing: Chinese Academy of Science, 2009.
- [3] Yu W C. Lattice reduction theory and its application to cipher design [PhD Dissertation]. Chengdu: Southwest Jiaotong University, 2005.

撰稿人: 史 涛
中国科学院软件研究所

纠错码的译码问题

Problem on Decoding of Error-correcting Code

纠错码是指在传输过程中发生错误后能在收端自行发现或纠正的码。Shannon^[1]在信道编码定理指出：在一定条件下，只要码的长度充分大，一定存在一种编码、译码方法，使得错误译码的概率充分小。自这一理论发表以来，人们经过持续不懈的努力已找到很多很好的纠错码，可以满足许多实用要求，如 Hamming 码和 BCH 码。1970 年，Goppa 提出了一种线性分组码的构造方法，原则上可以达到 Gilbert 限，实现了理论上预期的目标。

纠错码能够检错或纠错，主要是靠码字之间较大的差别，这可用码字之间的 Hamming 距离 $d(x, y)$ 来衡量，它定义为码字 x 与 y 之间的对应位取不同值的码元个数。一种纠错码的最小距离 d 定义为该码中任两个码字之间距离的最小值。一种码要能发现 e 个错误，它的最小距离 d 应不小于 $e+1$ 。若要能纠正 t 个错误，则 d 应不小于 $2t+1$ 。一个码字中非零码元的个数称为此码字的 Hamming 重量。一种码中非零码字的重量的最小值称为该码的最小重量。对线性码来说，一种码的最小重量与其最小距离在数值上是相等的。从代数角度上说，构造线性码就是从 n 维线性空间中选择一个 k 维线性子空间，并且使得该子空间内各非零码字的重量尽可能大。任意线性码的译码问题是编码理论中的公开问题之一。

译码问题：给定有限域 F_q 上的一个长为 n 的 k 维线性码 C ，一个到 C 的 Hamming 距离至多为 t 的字 $y \in F_q^n$ 。所谓译码问题，是指求解 $x \in C$ ，使得 $d(x, y)$ 最小，其中， $d(x, y)$ 表示 x 和 y 之间的 Hamming 距离。

译码问题的参数包括码长 n 、维数 k 及需要纠正的错误个数 t ，该问题在最坏情况的难度已知，是一个 NP-hard 问题。尽管在实际中，所有的实例都是困难的，但对该问题的平均复杂性还不清楚。

常常用来设计密码系统的编码有二元 Goppa 码和 Reed-Solomon 码，这两种码的译码问题都已被证明是 NP 完全的^[2~4]。有意思的是，最近人们还给出了 Reed-Solomon 码的译码和有限域上离散对数之间的关系^[5]。针对复杂度可用于密码算法的译码问题，目前已知的最快算法是 Canteaut 和 Chabaud 给出的^[6]，复杂性为

$$\exp\left(\left(\ln \frac{n}{n-k}\right) \frac{n-k}{\log^2 n} (1+o(1))\right)$$

参 考 文 献

- [1] Shannon C E .A mathematical theory of communication .Bell Systems Technical Journal ,1948 .
- [2] Berlekamp E R ,McEliece R J ,van Tilborg H C .On the inherent intractability of certain coding problems .IEEE Transactions on Information Theory ,1978 ,24 (3) .
- [3] Finiasz M .Nouvelles constructions utilisant des codes correcteurs d'erreurs en cryptographie clef publique .Th'ese de doctorat ,Ecole Polytechnique ,2004 .
- [4] <http://www.eccc.uni-trier.de/report/2004/040/> .
- [5] Cheng Q ,Wan D Q .On the list and bounded distance decodibility of Reed-Solomon codes .FOCS 2004-45th Annual IEEE Symposium on Foundations of Computer Science ,2004 .
- [6] Canteaut A ,Chabaud F .A new algorithm for finding minimum-weight words in a linear code :Application to McEliece's cryptosystem and to narrow-sense BCH codes of length 511 .IEEE Transactions on Information Theory ,1998 ,44 (1) :367 —378 .

撰稿人：张 寅
中国科学院软件研究所

多项式分层

Polynomial Hierarchy

在介绍多项式分层之前，我们有必要先介绍一下计算复杂性理论中两个重要的语言类： P 和 NP ，复杂类 P 包含所有那些可以由一个确定型图灵机在多项式表达的的时间内可以解决的判定问题，而 NP 语言类则是可以由非确定型图灵机在多项式时间内可以求解的判定问题。简单地说， P 问题就是那些能够在计算机上多项式时间内求解的问题，而 NP 问题则是那些在普通计算机上能够在给定正确信息下多项式时间可验证的判定性问题，很显然， P 是属于 NP 的，然而， NP 是否属于 P ，也就是 $P=?NP$ 是到目前为止还没有证明的一个公开问题。

很多计算复杂性的研究者都相信 $P\neq NP$ 的，关于这个问题的详细描述，可以参看文献[1]。人们之所以提出 NP 问题，是因为大多数遇到的自然的难解问题最终发现都是 NP 问题， NP 问题类非常丰富，存在于数学、优化、人工智能、生物、物理、经济、工业等各个领域。如果能解决 P 和 NP 两个问题类之间的关系，则对于这些困难问题的研究会有很大帮助。

$P=?NP$ 的问题在密码学和信息安全领域扮演着重要角色，如果 $P=NP$ ，那么，现行的很多加密算法将会是不安全的，因为这些算法的核心都是基于 NP 问题的困难性，如果 $P=NP$ 成立，将意味着存在确定的多项式时间算法可以解决这些困难问题，则基于该问题的加密算法将是不安全的。例如，RSA 公钥加密体系的核心算法的安全性基于大数分解问题，也就是说，如何将一个正整数 n 分解成若干素数的乘积，这是一个 NP -hard 问题，如果 $P=NP$ 成立，将存在有效的算法可以分解正整数 n ，则就很容易根据密文求得私有密钥，从而解密出明文。

如果存在有效的可以分解的大整数 n 的方法，但这不足以证明 $P=NP$ 命题的成立，为了深入研究 $P=?NP$ 的问题，我们引入了 NP 完全问题的概念。 NP 完全问题是 NP 问题的一个子类。一个语言 $L\in NP$ 完全，如果 $L\in NP$ 且所有 NP 中的问题都可以在多项式时间内转化为 L ，可以认为 NP 完全问题是 NP 类中最难的问题。由定义不难看出，如果任何一个 NP 完全问题属于 P ，就有 $P=NP$ 命题成立。因此，如果 $P\neq NP$ ，则任何一个 NP 完全问题都不在 P 中。Garey 和 Johnson 在他们的书中列出了数百种 NP 完全问题^[2]。

下面介绍多项式层次结构 (polynomial hierarchy) 的概念。多项式层次结构是一个基于 P 、 NP 和 co - NP 上的计算复杂类的层次结构，这个结构建立在 Or -

cle 图灵机模型下,是资源受限的,同数学逻辑中算术层次结构(arithmetical hierarchy)^[3]和分析层次结构(analytical hierarchy)^[4]具有同样地位。

多项式层次结构可以归纳定义如下:

$$\Delta_0^P = \Sigma_0^P = \Pi_0^P = P$$

$$\Delta_{i+1}^P = P^{\Sigma_i^P}, \quad \Sigma_{i+1}^P = NP^{\Sigma_i^P}, \quad \Pi_{i+1}^P = co\Sigma_{i+1}^P, \quad i \geq 0$$

$$PH = \bigcup_{k \geq 0} \Sigma_k^P$$

由定义,很显然有 $\Delta^P = P^{\Sigma_0^P} = P^P = P$, $\Sigma_i^P = NP^{\Sigma_{i-1}^P} = NP^P = NP$ 和 $\Pi_i^P = co\Sigma_i^P = co-NP$ 。注意: M^N 表示图灵机 M 在执行过程中,以图灵机 N 作为 Oracle 来询问。用图形来表示多项式层次结构如图 1 所示。

多项式层次结构有三个很重要的定理。

(1) 对每个 $i \geq 0$, 有 $\Sigma_i^P \cup \Pi_i^P \subseteq \Delta_{i+1}^P \subseteq \Sigma_{i+1}^P \cap \Pi_{i+1}^P$ 。

(2) $PH \subseteq PSPACE$ 。

(3) 每一个 Δ_i^P 、 Σ_i^P 、 Π_i^P 和 PH , 都是 $\leq_m^P$ 封闭的。多项式层级结构中的 Δ_i^P 层级在 $\leq_r^P$ 归约下也是封闭的^[5]。

如果存在 $k \geq 0$, 使得 $\Sigma_i^P = \Sigma_{i+1}^P$ 或 $\Sigma_i^P = \Pi_i^P$ 成立, 那么, 多项式层次结构将坍塌到 k 层, 即对任意的 $i > k$, 有 $\Sigma_i^P = \Sigma_k^P$ 。特别的, 假如 $P = NP$ 成立, 则多项式层次结构将完全坍塌到 P 。根据上面的定理(2)我们知道, PH 是包含在 $PSPACE$ 当中的, 但现在仍然不知道 $PH = PSPACE$ 是否成立。

如果多项式层次结构中存在完全问题, 那么, 层数就是有限的, 因为存在 $PSPACE$ 完全问题, 如果 $PH = PSPACE$, 则多项式层次结构一定会坍塌, 因为一个 $PSPACE$ 完全问题在 $PH = PSPACE$ 时, 对于某个 $k > 0$ 而言, 将会是一个 Σ_k^P 完全问题。多项式层次结构中的每一个复杂类包含 $\leq_m^P$ 完全问题(即可以在多项式时间多对一归约的问题)。除此之外, 每一个复杂类在 $\leq_m^P$ 归约下是封闭的(即对于任意一个层次结构中的复杂类 C , 以及语言 $L \in C$, 如果 $A \leq_m^P L$, 则 $A \in C$ 成立)。上面的两个事实合起来说明: 如果 K_i 是语言类 Σ_i^P 的完全问题, 则有 $\Sigma_{i+1}^P = (\Sigma_i^P)^{K_i}$ 和 $\Pi_{i+1}^P = (\Pi_i^P)^{K_i^C}$ 成立。例如, $\Sigma^P = NP^{SAT}$ 。换言之, 如果一个语言的定义是基于某个复杂类 C 中的 Oracle, 则我们可以认为这个语言的定义是基于复杂类 C 中的完全问题。

上面的公开问题到目前为止还没有很好的解决办法, 实际中, 有很多多项式层次结构中的问题, 如 Σ_1^P 中的电路最小化问题, 以及 Σ_1^P 中的完全问题 QBF_k 或




图 1 多项式层次结构

者 QSAT^[6]。

参 考 文 献

- [1] Gasarch W .The $P=?$ NP poll .SIGACT News ,2002,33(2):34—47 .
- [2] Garey M R ,Johnson D S .Computers and Intractability :A Guide to the Theory of NP-Completeness .Srancisco ;W H Freeman ,1979 .
- [3] Japaridze G .The logic of the arithmetical hierarchy .Annals of Pure and Applied Logic 66 ,1994 ;89—112 .
- [4] Rogers H .Theory of Recursive Functions and Effective Computability .New York ;McGraw-Hill ,1967 .
- [5] Rothe J .Complexity theory and cryptology .ACM Computing Classification ,1998 .
- [6] Meyer A R ,Stockmeyer L J .The equivalence problem for regular expressions with squaring requires exponential space .Proceedings of the 13th IEEE Symposium on Switching and Automata Theory ,1972 ;125—129 .

撰稿人：李振琦
中国科学院软件研究所

偶数变元 APN 置换的存在性

The Existence of APN Permutations on Even Number of Variables

现代分组密码的研究始于 20 世纪 70 年代中期, 至今已有三十余年历史, 这期间, 人们在这一研究领域已经取得了丰硕的研究成果。分组密码是一个密钥控制下的变换, 该变换将固定长度的明文分组映射为相同长度的密文分组。现代分组密码大都是迭代型分组密码, 其核心是轮变换。轮变换一般包括非线性组件(S 盒)和扩散组件。迭代型分组密码的安全性主要依赖于轮变换的安全强度, 尤其是 S 盒的安全强度。为了抵抗差分分析和线性分析等已知的密码分析, S 盒必须满足高非线性度、高代数次数、良好差分特性^[1]等一系列准则。

由于具有高非线性度、极好的差分特性等良好密码学性质, APN (almost perfect nonlinear)^[2]置换常被用于 S 盒构造。设 n 是一正整数, F_2^n 为二元域 F_2 上的 n 次扩域。设映射 $\varphi: F_2^n \rightarrow F_2^n$ 为置换。如果对任意非零 $\alpha, \beta \in F_2^n$, 方程 $\varphi(x+\alpha) + \varphi(x) = \beta$ 在有限域 F_2^n 上至多存在两个解, 则称 φ 是一个 APN 置换。当 n 为大于等于 3 的奇数时, 目前已经发现许多 APN 置换。当 $n=4$ 时, 已经证明不存在 APN 置换; 当 $n=6$ 时, 在 CCZ 等价意义下仅找到一个 APN 置换^[3]。然而, 当 n 为大于等于 8 的偶数时, 是否存在 APN 置换还是一个公开难

题。文献[4]证明了当 n 为偶数时, 如果 $\varphi(x) = \sum_{i=0}^{2^n-1} a_i x^i (a_i \in F_2^{n/2})$, 则 φ 不是 APN 置换。

参 考 文 献

- [1] Nyberg K. Differentially uniform mappings for cryptography. EUROCRYPT'93, 1994, 765: 55—64.
- [2] Beth T, Ding C. On almost perfect nonlinear permutations. EUROCRYPT'93, 1994, 765: 65—76.
- [3] Browning K A, Dillon J F, McQuistan M T, et al. An APN permutation in dimension six // The 9th Conference on Finite Fields and Applications FQ9, Dublin, 2009.
- [4] Hou X. Affinity of permutations of F_2^n . Discrete Appl. Math., 2006, 154(2): 313—325.

撰稿人: 林东岱
中国科学院软件研究所

量子计算机和量子通信的出现所引发的安全协议设计问题

The Design of Security Protocol Problem Arising from the Possible Emergence of Quantum Computer and Quantum Communication in Near Future

在进入 21 世纪十余年后的今天，电子计算机已经广泛深入到我们的日常生活中，给我们的学习、工作和生活带来了无尽的便利。我们平常都希望计算速度能更快些，这样，能够节省我们更多宝贵的时间。然而，事与愿违的是，有一些计算问题，如中国邮路问题，是几乎不可能（由著名的 $P \neq NP$ 猜想所导致）找到有效快速的算法的，我们把这一类问题称为计算困难问题。诚然，计算困难问题的存在看起来对我们是一个坏消息——我们当然希望计算机能够又快又好地解决所有问题，但出乎常人所意料的，计算困难性也能够给我们的生活带来意想不到的好处——安全性。

下面，举一个有趣的例子，这个例子将展示利用计算困难性我们能做些什么有趣的事情。这个例子是由著名的华人理论计算机科学家、图灵奖得主姚期智先生在 20 世纪 80 年代的一篇学术论文中提出的^[1]。姚先生提了这样一个“百万富翁”问题：两个百万富翁碰在一起，想攀比富贵，一个简单的办法就是，他们各自拿出自己的银行存折摆在桌面上，看看谁的存款多。可是，这样一来便会泄漏他们各自的存款数目，他们谁都不想让对方知道自己有多少钱。请问：这两个百万富翁有办法知道他们谁的钱更多，但同时又不泄漏他们各自的存款数目吗？粗略一想，这怎么可能办到呢？不把存款的数目摆到桌面上，怎么比较？不比较怎么知道谁的存款多？但是，姚先生却在文章中出人意料地给出了一个解决方案。这个方案就是我们这篇短文所要引出的安全协议设计问题的一个例子。通俗地说，安全协议设计问题就是设计一个协议（一组规则，用来指导一个通信和计算的过程），使得一组计算个体能够基于自身的输入（在“百万富翁”问题中，为两个富翁各自的银行存款数），共同地计算一个函数值（在“百万富翁”问题中，这个函数为“比大小”函数。例如，当第一个富翁更富有时，令该函数值为 0；反之，为 1），而且同时确保各计算体自身的输入（看作一个私人秘密）在整个过程中不会泄漏出去。姚先生给出的这个协议正是建立在存在计算困难问题的基础上的。由于这个协议本身很复杂，我们不可能在这篇短文中给出。

因此，存在计算困难问题这个事实，既有坏处，也有好处——这是一对矛盾。我们已经很好地利用了这对矛盾的两个方面，服务了我们的社会。下面我们

们将来看看,随着在不久的将来,量子计算机、量子通信技术的出现,会给现有的计算困难问题、给我们的计算理论、密码学带来什么影响?我们将面临哪些新的问题?又会有哪些新的契机?

如我们前面所提到的,当前很多安全协议都是基于存在计算困难问题的。其中,两个最重要的计算困难问题就是“素数分解”和“离散对数”,这两个问题都是密码学中单向函数的具体实例。所谓单向函数,通俗地说,是指朝一个方向计算容易,而朝反方向计算却很困难的函数。如素数分解问题,计算几个数的乘积很容易,但反之,计算一个数的素因子分解却很难。1994年,一个科学上的突破是,计算机科学家 Shor 发现,用量子计算机能够快速地计算“素数分解”和“离散对数”问题。因此,量子计算机的出现,使我们的计算能力得到增强的同时,又把一个严峻的问题摆在我们面前。我们在过去几十年所设计出来的安全协议在量子计算机的攻击面前还安全吗?显然,并不是所有协议的安全性都能够保持的。比如说 RSA 协议就不能,因为它是基于“素数分解”问题的困难性的。尽管如此,还是有一些协议,如很多“零知识”协议,被证明了即使是出现了量子计算机,它本身还是可能安全的——前提是如果存在抵抗量子计算机攻击的单向函数的话^[2]。因此,量子计算机的出现打破了原有计算问题难易的界限,让我们必须重新界定计算困难问题,重新审视已有的安全协议。

更令人兴奋的是,我们注意到,量子技术的出现本身是一把双刃剑,它在给现有的安全协议带来威胁的同时,也提供了设计新的安全协议的契机。我们想问,能否利用量子技术,设计量子安全协议,来抵抗量子计算机的攻击呢?这正是我们常用的“以彼之道,还施彼身”之术。在量子安全协议设计这方面,当前的研究才刚刚起步,结果也很少。其中,成功的例子有计算机科学家们已经设计出了量子密钥分配协议^[3];也有一些负面的例子,如我们已经证明了不存在信息论意义上安全的量子承诺方案。量子安全协议设计方面结果较少的另一个原因在于这个问题本身比较“难”——它难在量子原理比较“怪异”,证明起来更加复杂。特别地,其中有两个量子性质,让科学家在设计量子协议时往往感到无所适从。第一个性质是“information cause disturbance”,通俗地说,就是我们若想从一个量子状态中获得一些信息,便会破坏原来的量子状态。第二个性质是不可克隆性(non-cloning),说的是我们不能像拷贝经典信息一样拷贝一个量子状态,得到多个备份。正是这两个奇特的量子性质,让我们的工作变得既困难又有趣,充满着无穷的魅力。

综上所述,随着在不久的将来量子计算机和量子通信技术的出现,我们现有的密码学安全协议将面临重大的挑战。对于当代和未来的计算机科学家,他们所要面临的紧迫而困难的任务,同时也是时代赋予他们的历史使命,就是一

方面检查现有的协议在量子攻击下是否安全，而另一方面设计全新的量子安全协议，为我们未来的信息生活提供一个安全可靠的保障。

参 考 文 献

- [1] Yao A C C. Protocols for secure computation. Proc. 23rd IEEE Symposium on Foundations of Computer Science (FOCS), 1982; 160—164.
- [2] Watrous J. Zero-knowledge against quantum attacks. SIAM Journal on Computing, 2009, 39(1); 25—58.
- [3] Nielsen M A, Chuang I L. Quantum Computation and Quantum Information. Cambridge: Cambridge University Press, 2000.

撰稿人：颜 俊
中国科学院软件研究所

弹性布尔函数的非线性度的紧上界

The Tight Upper Bound of the Nonlinearity of Resilient Boolean Functions

布尔函数在对称密码系统(尤其是流密码系统)的设计中扮演着重要角色。随着密码分析技术的飞速发展,各种对称密码系统正遭受着越来越多的攻击,如何设计同时满足多个密码学指标的布尔函数成为困扰密码学界的难题。

非线性度和弹性是用于对称密码系统的布尔函数最重要的两个密码学指标,它们彼此之间存在着相互制约关系,不可能同时达到最优。弹性函数的非线性度的紧上界是目前悬而未解的公开难题。

Rothaus^[1]于1976年证明了在 n 为偶数时, n 元布尔函数的非线性度最优是 $2^{n-1} - 2^{n/2-1}$,称这类函数为Bent函数。遗憾的是,Bent函数不是平衡的,更不是弹性函数,这限制了其在密码学中的直接应用。在之后的几十年里,密码学者们花费了大量精力寻找密码性质良好的高非线性度布尔函数。

我们把平衡函数看做弹性函数的一个特殊情形。Seberry等^[2]曾给出具有偶数个变元的 n 元平衡布尔函数非线性度的一个上界 $2^{n-1} - 2^{n/2-1} - 2$,但至今没人证明这个界是紧的。 $n \geq 8$ 时,这个界是否能达到至今还不知道。8元(10元)平衡布尔函数的非线性度能否达到118(494)是目前受到关注的公开问题^[3]。当 n 为奇数且 $n \leq 7$ 时,布尔函数的最大非线性度是 $2^{n-1} - 2^{(n-1)/2}$,并且可以是平衡的;当 n 为奇数且 $n \geq 9$ 时, n 元平衡布尔函数的最大非线性度还不知道。

关于偶数个变元的高非线性度平衡布尔函数的一般构造方法,目前最好的结果由Seberry^[2]和Dobbertin^[4]分别独立给出,十几年过去了,这个问题没有大的突破。如何构造非线性度严格大于 $2^{n-1} - 2^{(n-1)/2}$ 的奇数个变元的非Patterson-Wiedemann^[5]型平衡布尔函数也是目前颇受关注的问题。

关于弹性布尔函数最大非线性度上界的研究,近十年来最重要的结论是Sarkar和Maitra给出的所谓布尔函数的Walsh谱值重量整除定理^[6]。由这个定理,不难得到弹性布尔函数非线性度 N_f 的上界,称为Sarkar-Maitra界。

在文献[7]中,Sarkar和Maitra证明了对任意正整数 t ,都存在偶数 n ,可以构造出非线性度严格大于 $2^n - 2^{n/2}$ 、代数次数达到Siegenthaler界的 n 元 t 阶弹性函数,并指出对任意偶数 $n \geq 12$,达到最大代数次数 $n-2$ 的 n 元1阶弹性布尔函数的非线性度可以达到

$$2^{n-1} - 2^{n/2-1} - 2^{n/2-2} - 2^{n/4-2} - 4$$

Maitra和Pasalic^[8]改进了这个结果,他们利用发现的(8,1,6,116)函数构造

出变元个数是偶数 $n \geq 10$ 、达到最大代数次数 $n-2$ 的 1 阶弹性布尔函数, 其非线性度可以达到

$$2^{n-1} - 2^{n/2-1} - 2^{n/2-2} - 4$$

为了得到具有非线性度严格大于 $2^{n-1} - 2^{n/2} - 2^{n/2-2}$ 的 n 元 t 阶弹性布尔函数 (n 为偶数), Maitra 和 Pasalic^[9] 采用的途径是毗连 $2^{n/2} - 2^k$ 个不同的 $n/2$ 元线性 t 阶弹性布尔函数和一个 $n/2+k$ 元的高非线性度弹性布尔函数。在 $n \geq 8t+6$ 时, 他们构造出非线性度是 $2^{n-1} - 2^{n/2-1} - 2^{n/2-3} - 2^{n/4-2}$ 的 n 元 t 阶弹性布尔函数。

在文献[10]中, Zhang 和 Xiao 借助“不相交谱函数集合”, 给出一种在 $n \geq 12$ 为偶数情形下, 构造几乎最优弹性函数的方法。给定任意正整数 t , 总可以在 n 大于某个值 n_0 时构造出几乎最优 t 阶弹性函数(随着 t 增大, t/n_0 趋近 $1/4$), 得到一大批前人未知的几乎最优弹性函数。尤其值得一提的是, 在 $t/n \ll 1/4$ 时, 构造的函数非线性度非常接近 Bent 函数。文献[10]中认为, Sarkar-Maitra 界是可以改进的, 猜想在 $m < \lfloor n/4 \rfloor$ 时,

$$N_f \leq 2^{n-1} - 2^{n/2-1} - 2^{\lfloor n/4 \rfloor + m-1}$$

有关概念定义:

设 f 是 n 元布尔函数, $L_n = \{\varphi_\alpha + \varepsilon \mid \alpha \in F_2^n, \varepsilon \in F_2\}$ 表示所有仿射布尔函数所构成的集合。称非负整数

$$N_f = \min_{l(x) \in L_n} d_H(f(x), l(x))$$

为布尔函数 f 的非线性度。

设 $f(x) \in B_n$, $x_1, x_2, \dots, x_n$ 是 F_2 上独立的、均匀分布的随机变量, 如果对任意的 $(a_1, a_2, \dots, a_m) \in F_2^m$ ($m \leq n$) 和 $b \in F_2$, 都有

$$P(f=b, x_{i_1}=a_1, x_{i_2}=a_2, \dots, x_{i_m}=a_m) = \frac{1}{2^m} P(f=b)$$

则称 f 与变元 $x_{i_1}, x_{i_2}, \dots, x_{i_m}$ 统计无关。如果 f 与 $x_1, x_2, \dots, x_n$ 中任意 m 个变元都统计无关, 则称 f 是 m 阶相关免疫的(correlation immune)。

平衡的(真值表中 0, 1 个数相同) m 阶相关免疫函数称为 m 阶弹性函数, 平衡的但没有相关免疫性的布尔函数可以看作 0 阶弹性函数。

参 考 文 献

- [1] Rothaus O S. On ‘bent’ functions. Journal of Combinatorial Theory, 1976, 20: 300—305.
- [2] Seberry J, Zhang X M, Zheng Y. Nonlinearity and propagation characteristics of balanced Boolean functions. Information and Computation, 1995, 119: 1—13.
- [3] Sarkar P, Maitra S. Construction of nonlinear resilient Boolean functions using small affine functions. IEEE Transactions on Information Theory, 2004, 50(9): 2185—2193.

- [4] Dobbertin H. Constructions of bent functions and balanced Boolean functions with high nonlinearity. *Fast Software Encryption*, 1994, 1008; 61—74.
- [5] Patterson N J, Wiedemann D H. The covering radius of the $(2^{15}, 16)$ Reed-Muller code is at least 16276. *IEEE Transactions on Information Theory*, 1983, 29; 354—356.
- [6] Sarkar P, Maitra S. Nonlinearity bounds and constructions of resilient Boolean functions. *CRYPTO 2000*, 2000, 1880; 515—532.
- [7] Sarkar P, Maitra S. Construction of nonlinear Boolean functions with important cryptographic properties. *Advances in Cryptology-EUROCRYPT 2000*, 2000, 1807; 485—506.
- [8] Maitra S, Pasalic E. Further constructions of resilient Boolean functions with very high nonlinearity. *IEEE Transactions on Information Theory*, 2006, 52(5); 2269—2270.
- [9] Maitra S, Pasalic E. A Maiorana-McFarland type construction for resilient Boolean functions on variables (n even) with nonlinearity $> 2^{n-1} - 2^{n/2} + 2^{n/2-2}$. *Discrete Appl. Math.*, 2006, 154; 357—369.
- [10] Zhang W G, Xiao G Z. Constructions of almost optimal resilient Boolean functions on large even number of variables. *IEEE Transactions on Information Theory*, 2009, 55(12); 5822—5831.

撰稿人：张卫国 肖国镇

西安电子科技大学 ISN 国家重点实验室

非交互式零知识证明中的私密信息提取难题

Secret Information Extraction Problem in Non-interactive Zero Knowledge Proofs

随着非交互式零知识(NIZK)证明理论的发展,许多研究人员开始使用NIZK理论来完成数字签名方案的构造和安全性证明。因为在交互式的协议中,零知识证明一般都需要交互,尽管交互次数很少,这就意味着示证者和验证者都必须同时在线。若在零知识证明中做到无需交互,即使用“单向”通信方式,则有很多优点,使得示证者可以在不揭示自己真实身份的情况下,证明自己拥有某一私密信息,并且示证者和验证者之间不需交互,这在很大程度上降低了系统存储和通信的代价。但在某些情况下,需要能够打开该用户的证明过程,得到其身份信息,即进行私密信息提取。

Blum 等于 1988 年首次提出了 NIZK 证明的概念,并在 1991 年构建了可计算的 NIZK 证明系统^[1]。此后的研究表明,NIZK 证明可以应用于所有的 NP 问题,不过当时 NIZK 证明的效率非常低。Groth 和 Sahai 于 2006 年构建了第一个统计的 NIZK 论据系统^[2],同年他们又构造了适用于所有 NP 语言的非交互式 Zaps^[3],其安全性依赖于判定性线性假设,实现了非交互式证据的不可区分性,保证了系统完备性。2007 年,Boyen、Waters 等探索如何直接用双线性群来构建一个有效的 NIZK 证明^[4,5]。Groth 在 2006 年提出了基于双线性配对的通用的基于素数阶群的 NIZK 证明系统^[6],该证明满足标准模型下定义的强安全性。2007 年,Groth 和 Sahai 提出了非交互式的高效 GS 证明系统^[7],其首先建立了高效的证据不可区分性(WI)证明系统,然后说明怎样将 WI 证明系统转换为零知识证明系统,并给出了基于 SDA、DLIN、SXDH 假设难题的实例。

在 GS 系统中,当产生纠纷时,需要验证者利用提取算法从证明中提取出示证者的私有身份信息。当前的研究情况是:验证者只能判断这些承诺值是否满足配对等式,并不能直接找出满足等式的承诺对象。若已知构建承诺时使用的随机数,则可以将私密信息从中提取,但在通常情况下,构建承诺使用的随机数只有用户知道,并且该随机数实时变化,若其他人要打开承诺,就必须每次都传送随机数,但如此操作需要额外的通信和计算代价,并不可行。因此,寻找有效方式打开承诺并取出承诺对象,即解决私密信息提取是很必要的问题。

该难题可以进行如下概括：选择 $\{a_q\}_{q=1,\dots,Q} \in G_1$, $\{b_q\}_{q=1,\dots,Q} \in G_2$, 并且 $\{\alpha_{q,m}\}_{q=1,\dots,Q,m=1,\dots,M} \in Z_p$, $\{\beta_{q,n}\}_{q=1,\dots,Q,n=1,\dots,N} \in Z_p$, 利用上述值, 承诺 $\{C_m = a_q \prod_{m=1}^M x_m^{\alpha_{q,m}}\}_{m=1,\dots,M}$ 可将 $\{x_m\}_{m=1,\dots,M} \in G_1$ 进行隐藏, $\{D_n = b_q \prod_{n=1}^N y_n^{\beta_{q,n}}\}_{n=1,\dots,N}$ 可将 $\{y_n\}_{n=1,\dots,N} \in G_2$ 进行隐藏。若想证明满足双线性配对等式

$$\prod_{q=1}^Q e\left(a_q \prod_{m=1}^M x_m^{\alpha_{q,m}}, b_q \prod_{n=1}^N y_n^{\beta_{q,n}}\right) = t \quad (1)$$

解的存在很容易, 但要从中提取出解 $\{x_m\}_{m=1,\dots,M}$ 和 $\{y_n\}_{n=1,\dots,N}$ 是一件很困难的事。此难题的存在主要是因为 NP 完全问题的困难性, 即问题求解难于问题验证。

NIZK 证明系统已成为密码体制中的一个重要工具, 它比 ZK 证明具有更强的安全性。因为除了完整性、正确性及零知识性以外, NIZK 证明系统还具有证据不可区分性和可提取性。NIZK 作为重要的密码学原型已被广泛应用在组签名、环签名、代理签名等签名方案中。例如, 在不希望公开验证签名的应用中, NIZK 可以作为“不可否认签名”的一种高效实现; 在电子投票系统中, 为其提供“无收据的电子投票”; 同样, NIZK 也可以用在离线的电子现金交易系统中, 使得银行可以认证离线用户电子现金的合法性; 匿名认证中, NIZK 允许用户不泄露自己的身份并示证自己拥有一项服务的合法证书。但在这些应用中, 都需要存在高效的方法可以从证明中提取真实用户的私有身份信息, 以便仲裁机构解决纠纷, NIZK 的这种可提取性才能保证交易的安全性, 因此, 关于 NIZK 证明中私密信息的提取具有重要的研究价值。

参考文献

- [1] Blum M, de Santis A, Micali S, et al. Non-interactive zero-knowledge. SIAM Journal on Computing, 1991, 20: 1084—1118.
- [2] Groth J, Ostrovsky R, Sahai A. Perfect non-interactive zero-knowledge for NP. Proceedings of EUROCRYPT'06, 2006: 339—358.
- [3] Groth J, Ostrovsky R, Sahai A. Non-interactive zaps and new techniques for NIZK. Proceedings of CRYPTO'06, 2006: 97—111.
- [4] Boyen X, Waters B. Compact group signatures without random oracles. Proceedings of EUROCRYPT'06, 2006: 427—444.
- [5] Boyen X, Waters B. Full-domain subgroup hiding and constant-size group signatures. Proceedings of PKC'07, 2007: 1—15.
- [6] Groth J. Simulation-sound NIZK proofs for a practical language and constant size group signatures. Proceedings of ASIACRYPT'06, 2006: 444—459.

- [7] Groth J, Sahai A. Efficient non-interactive proof systems for bilinear groups. 2007. <http://eprint.iacr.org/>.

撰稿人：周福才 李 慧
东北大学信息科学与工程学院

视觉密码方案的最优化问题

On the Optimization of Visual Cryptography Schemes

视觉密码方案是针对图片的秘密共享方案。经视觉密码方案加密后，一幅秘密图片被加密成若干个分享图片，将这些分享图片分别分配给不同的参与者之后，只有预先指定的参与者合作才能解密出秘密图片，其他人则不能得到除秘密图片尺寸之外的任何信息。视觉密码方案在解密时，只需要将分享图片叠加即可通过人的眼睛直接解密^[1]，如图1所示的彩色视觉密码方案中^[2]，将分享图片(d)和(e)印到透明的幻灯胶片上，然后叠放到一起，直接用眼睛就可以看到图片(f)中的影像。由于解密过程不需要参与者掌握任何密码学知识，也不依赖计算设备，因此，视觉密码方案会在一些特殊的场景中有很重要、也很有意思的应用。




图1

评价视觉密码方案最重要的两个指标是像素扩张和对比度，其中，像素扩张用来反映所解密的秘密图片尺寸与原秘密图片尺寸的倍数[如图1中(d)相对于(a)的尺寸扩张]，而对比度则用来反映所解密的秘密图片的图像质量(这里，我们考虑最简单的情况，即在黑白视觉密码方案中，此时对比度反映的是所解密的图片中黑白两种像素的差别)。对一个视觉密码方案来说，像素扩张的值越小

越好(携带更方便),而对比度的值越大越好(解密图片更清晰),这两个参数是互相影响的。通常,具有较小像素扩张的视觉密码方案,其对比度之值也较小;而具有较大对比度的视觉密码方案,其像素扩张也较大。视觉密码方案的最优化问题的就是要理清两者的关系,即对于一般的存取结构来说^[3],求解视觉密码方案最小的像素扩张之值,最大的对比度之值,以及最小像素扩张条件下最大的对比度之值和最大对比度条件下最小的像素扩张之值,并构造出具体的视觉密码方案。

目前,在视觉密码方案的最优化问题上已经有一些相关的研究结果,如意大利的 Blundo 教授给出了几类特殊门限存取结构下的对比度的最优化构造^[4,5],意大利的 Cimato 教授考虑了门限存取结构下彩色视觉密码方案对比度的最优化构造^[6],德国的 Hofmeister 和 Krause 教授对门限存取结构下的视觉密码方案的对比度最优值进行了计算^[7,8]。

从目前的研究情况来看,缺少针对一般存取结构的最优化方案和探讨像素扩张与对比度关系的研究结果,而这正是视觉密码最优化问题的困难所在。

参 考 文 献

- [1] Naor M, Shamir A. Visual cryptography. EUROCRYPT'94, 1995, 1—12.
- [2] Liu F, Wu C K, Lin X J. Color visual cryptography schemes. IET Information Security, 2008, 2(4): 151—165.
- [3] Ateniese G, Blundo C, de Santis A, et al. Visual cryptography for general access structures. Information and Computation, 1996, 129: 86—106.
- [4] Blundo C, de Santis A, Stinson D R. On the contrast in visual cryptography schemes. Journal of Cryptology, 1999, 12(4): 261—289.
- [5] Blundo C, D'Arco P, de Santis A, et al. Contrast optimal threshold visual cryptography schemes. SIAM Journal on Discrete Mathematics, 2003, 16(2): 224—261.
- [6] Cimato S, de Prisco R, de Santis A. Optimal colored threshold visual cryptography schemes. Designs, Codes and Cryptography, 2005, 35: 311—335.
- [7] Krause M, Simon H U. Determining the optimal contrast for secret sharing schemes in visual cryptography. Combinatorics, Probability & Computing, 2003, 12(3): 285—299.
- [8] Hofmeister T, Krause M, Simon H U. Contrast-optimal k out of n secret sharing schemes in visual cryptography. Theoretical Computer Science, 2000, 240(2): 471—485.

撰稿人: 刘 峰
中国科学院软件研究所

是否存在安全实用的量子公钥密码?

Does Secure and Practical Quantum Public-key Cryptosystem Exist?

现行密码体制可以分为对称密码和非对称密码两类。对称密码中,通信双方需要先通过密钥交换过程来秘密共享一串相同的密钥,然后用此密钥对所传递的消息进行加密和解密。非对称密码即公钥密码^[1],每个用户都有一对密钥:公钥和私钥,用其中一个密钥加密的消息,可以用另一个密钥来解密。由于公钥是公开的,通信双方无需事先交换密钥就可以进行保密通信。若以公钥作为加密密钥,私钥作为解密密钥,则可实现多个用户加密的信息只能由一个用户解密;反之,以用户私钥作为加密密钥,公钥作为解密密钥,则可实现一个用户加密的消息可以被多个用户解读。前者可用于数据加密(如解决对称密码体制中的密钥交换问题),后者可用于数字签名。相对于对称密码来说,公钥密码灵活易用,能解决多种密码学应用问题,在安全技术领域起着不可替代的作用。

公钥和私钥作为一对分别用于加密和解密的密钥,它们之间必然有一定的关联,但出于安全性考虑,公钥密码中要求人们不能从公钥推出私钥,这一点通常是由一些数学难题来保证的,如大数因子分解、离散对数问题等。也就是说,要想从公钥推出私钥,就必须面对这些数学难题的求解。因此,这些难题的复杂性就决定了公钥密码系统的安全性。实践证明,基于以上数学难题的公钥密码体制对人们现有的计算能力来说是可靠的。然而,随着量子计算的发展,Shor在20世纪90年代提出了大数因子分解的多项式时间求解算法^[2]。目前,对于有限Abel群上的隐含子群问题都已经找到了多项式级的量子算法,因此,基于大数因子分解和离散对数等问题的公钥密码体制在量子计算环境下将不安全。

此后,科学家一直在积极地寻找可以抵抗量子计算攻击的公钥密码算法。目前,格难题在经典环境下和量子环境下都还没有找到高效的解决方法,因此,设计基于格难题的安全密码系统可能能够抵抗量子计算的攻击,但由于已知的量子算法还很有限,能够抵抗现有量子算法还远远不能保证能够对抗量子计算。因此,继续寻找经典难题的方法似乎还不能从根本上解决这一问题。

在对传统密码带来严重威胁的同时,量子力学也为密码学带来了新思路。我们知道,量子不可克隆原理和测不准原理使通信双方可以发现信息传输中存在的窃听,进而保证了密钥分配过程的无条件安全性。量子密钥分配的提出解

决了公钥密码的一个重要应用问题,即密钥分配问题,但在密钥管理及签名等其他应用场合中寻找现行公钥密码的替代品,仍然是一个亟待解决的重要问题。一种理想的解决方案就是像量子密钥分配那样,利用量子力学特性设计安全的量子公钥密码算法^[3]。量子公钥密码算法要求其安全性基于量子物理基本原理,而不是基于计算难题,它既可以加解密经典信息,又可以加解密量子信息。根据公钥量子态的特点,量子公钥密码中可能会有以下三种不同的情况:

(1) 公钥和私钥是量子纠缠态。这种情况下,如果多个用户利用公钥加密信息,则要求解密者拥有多份私钥进行解密,即用户有多个公、私钥对且每对公、私钥一一对应,这并不符合公钥密码中只有一个私钥的特点,往往会大大降低公钥密码的实用性^[4,5]。

(2) 公钥是未知量子态(这里,“未知”和“已知”均针对发布公钥的权威机构而言)。量子不可克隆定理告诉我们,未知量子态不能被精确复制,从而不能实现多个用户利用该公钥量子态对信息进行加密。同时,未知量子态的不可区分性表明我们不能对未知量子态进行认证^[6],这样,就无法确认公钥量子态在传输中是否被篡改。因此,量子力学特性本身对以未知量子态做公钥的假设形成了诸多障碍。

(3) 公钥是已知量子态^[3]。根据量子信息理论,每发布一份公钥则会泄露有关私钥的部分信息。随着公钥发布份数 N 的增加,私钥被泄露的信息则越来越多^[5,7],甚至当 N 足够大,就可以近似确定该公钥量子态,从而将量子公钥转换为经典密钥,这时,量子公钥系统的安全性也将降低为计算安全性。因此,在这种情况下,确定公钥量子态发布的份数是保证量子公钥安全性和高效性的关键。目前,关于该问题还没有确定的结果和证明。另外,即便公钥量子态是已知的,其认证过程也相当复杂和困难^[6],目前还没有很好的解决方案。

看起来,量子物理特性也为设计安全量子公钥密码带来了一定的困难。如何解决这些困难,设计出既像量子密钥分配那样无条件安全,又像经典公钥密码那样灵活实用的量子公钥密码体制,仍需要人们去深入地研究。

参 考 文 献

- [1] Diffie W, Hellman M. New directions in cryptography. IEEE Transactions on Information Theory, 1976, 22: 644—654.
- [2] Shor P W. Algorithms for quantum computation: Discrete logarithms and factoring. Proceedings of the 35th Annual Symposium on the Foundations of Computer Science, 1994: 124—134.
- [3] Nikolopoulos G M. Applications of single-qubit rotations in quantum public-key cryptography. Phys. Rev. A, 2008, 77: 032348.

- [4] Koshiba T. Security notions for quantum public-key cryptography. IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences, 2007, J90A (5): 367—375.
- [5] Gao F, Wen Q Y, Qin S J, et al. Quantum asymmetric cryptography with symmetric keys. Science in China Series G: Physics, Mechanics & Astronomy, 2009, 52(12): 1925—1931.
- [6] Barnum H, Crépeau C, Gottesman D, et al. Authentication of quantum messages // Proceedings of the 43th Annual IEEE Symposium on Foundations of Computer Science, Vancouver, 2002: 449—458.
- [7] <http://arxiv.org/pdf/quant-ph/0105032v2>.

撰稿人：温巧燕

北京邮电大学网络技术研究院

网络中的未知行为识别问题

On Unknown Behavior Detection in the Networks

1. 难题的来龙去脉及重要性

当前的互联网系统日益复杂,对非法网络行为的感知和识别仍缺乏有效的手段。人体免疫系统能够在没有任何先验知识的情况下,有效地识别并清除病毒、细菌等潜在威胁,保护人体免受侵害。通过研究免疫系统入侵检测机理,可能提炼出适用于解决当前网络安全领域的快速有效地识别未知威胁问题的有效方法和途径。近年来,国内外开展了一系列的相关研究,但仍未找到能够像生物免疫系统那样准确区分未知入侵行为的有效科学方法依据。

2. 难题解决的现状及主要困难所在

1) 自我非我识别理论方面

传统的免疫学认为免疫系统是通过区分自我和非我并清除有害自我的方式来实现人体保护的功能。早在 1994 年,美国新墨西哥大学的 Forrest 研究小组就认为计算机安全也可以通过识别自我与非我来实现^[1],并提出了基于自我非我识别理论的计算机免疫学概念。其中,自我表示授权用户、合法程序和数据等,而非我则表示未授权的用户、非法程序和数据等。

IBM 研究中心的 Kephart 等将自我非我识别的思想应用到杀毒软件的设计中,并在已有的杀毒软件模型的基础上,设计了一种“饵”程序来捕获病毒样本和收集病毒特征^[2]。系统需要利用事先保存的病毒特征进行模糊匹配或检测关键数据或文件的完整性来发现病毒。为了降低虚警率,当一个可疑的病毒被检测到时,系统将诱导其感染“饵”程序由此确定是否是病毒,但至今仍未见有具体的测试结果。

大量的相关研究是基于阴性选择理论的。阴性选择过程是 T 淋巴细胞从产生到成熟需要经历的甄选过程。阴性选择算法是对这一过程的抽象,被广泛用于生成具有检测能力的探测器,淘汰不合格和与自我匹配的探测器^[3]。这种方法可以检测到未知的攻击,但由于不能将新的合法业务分离,使得在测试过程中的虚警率很高。为了降低虚警率,在判定一个未知模式是否正常时,也有考虑增加如共同刺激信号、激活阈值等附加信息以限定攻击的条件^[4]。另外,为了提高检测的准确率,多种启发式算法,如神经网络、遗传算法、数据挖掘等

也被用于自我集合的构建^[5,6]。

自我非我识别被大多数科学家所接受并开展了广泛的研究探讨,但这种方法存在先天不足。首先,自我和非我都是模糊的概念,不同的应用场景、不同的权限自我和非我都有所不同,因而难以作统一的量化定义。其次,静态的定义难以适应动态的网络环境,新的攻击或新的业务容易导致漏检或虚警。最后,自我非我理论本身不能很好地解释免疫学自身问题。

2) 危险理论研究方面

2003年,Aickelin等提出了危险理论模型^[7],是自我非我理论的补充。与前者截然不同,危险理论不再以自我非我的识别作为安全与否的判别标准,而是用危险信号来触发免疫响应,其典型的成果是 Greensmith 根据树枝状细胞的功能设计出树枝状细胞算法^[8]和 Twycross 根据 Toll 受体的模型提出了 Toll 样受体算法(Toll like receptor algorithm, TLRA)^[9],极大地完善了危险理论。虽然危险理论能够很好地解释免疫学中的问题,但针对信号的量化分析一直是危险理论应用的瓶颈。

总之,现有的相关研究活动尝试用生物免疫学的典型理论模型来模拟通信网络的入侵识别过程。但在免疫学中,免疫系统的病原体识别机制仍然存在争议。免疫系统是从内容(如病毒特征)上进行识别,还是从行为(如异常行为)上进行识别?是通过特征匹配的方式实现,还是通过软计算的方式实现?这些问题目前都不得而知。一方面,需要进一步发展免疫学以揭开免疫识别原理的庐山真面目;另一方面,将免疫机制用于解决网络安全问题还需要建立合理的数学模型,尤其量化分析是突出的难点。

参 考 文 献

- [1] Forrest S, et al. Self-nonsel self discrimination in a computer. Proceedings of the 1994 IEEE Symposium on Security and Privacy, 1994, 202: 16—18.
- [2] Kephart J O. A biologically inspired immune system for computers // Brooks R A, Maes R. Artificial Life IV: Proceedings of the Fourth International Workshop on the Synthesis and Simulation of Living Systems. Boston: MIT Press, 1994: 130—139.
- [3] Ayara M, Timmis J, Lemos R D, et al. Negative selection: How to generate detectors. Proceedings of 1st International Conference on Artificial Immune Systems (ICARIS), 2002: 89—98.
- [4] Hofmeyr S, Forrest S. Immunity by design: An artificial immune system // Genetic Evolutionary Computation Conf., San Francisco, 1999: 1289—1296.
- [5] Gonzalez F, Dasgupta D, Kozma R. Combining negative selection and classification techniques for anomaly detection. Evolutionary Computation, 2002, 1(1): 705—710.

- [6] Watkins A, Timmis J, Boggess L. Artificial immune recognition system (AIRS): An immune-inspired supervised learning algorithm. Genetic Programming and Evolvable Machines, 2004, 5(3): 291—317.
- [7] Aickelin U, Bentley P, Cayzer S, et al. Danger theory: The link between AIS and IDS. Proceedings of the 2nd International Conference on Artificial Immune Systems (ICARIS2003), 2003: 147—155.
- [8] Greensmith J. The dendritic cell algorithm [PhD Dissertation]. Nottingham: University of Nottingham, 2007.
- [9] Twycross J. Integrated innate and adaptive artificial immune systems applied to process anomaly detection [PhD Dissertation]. Nottingham: University of Nottingham, 2007.

撰稿人: 隆克平 彭云峰

电子科技大学光互联网及移动信息网络研究中心

网络信息论

Network Information Theory


现代通信(信息传输)系统都是建立在 Shannon 信息论基础上的。Shannon 信息论的核心内容之一是信道容量的度量。信道容量定义了在一定差错概率任意小情况下传输信道所能支持的最大可达信息传输速率。Shannon 的信道容量及其有噪信道上的编码理论是现代信息传输系统的理论基础。基于 Shannon 理论发展起来的一些新技术,如多天线(MIMO)技术、Turbo 编码和 LDPC 编码技术等,已经成为现代无线通信中的核心传输技术。但是,Shannon 在 1948 年创建信息论^[1]时,通信环境还比较简单,主要是电话电报通信,通信的数字化还没有实现,所以,Shannon 理论针对的是纯高斯信道、单用户(点到点系统)。通信发展至今日,已是一个包括多种通信方式、多种业务、涉及几乎所有人的巨系统。现代通信是通过网络来完成的。网络路由通过物理信道来实现,不同信道利用不同的电磁波频段,传输条件差别极大,它们的统计模型远不能仅用简单的高斯噪声(AWGN)所能代表。此外,信道带宽受限引起的传输信号线性失真所造成的符号间干扰(ISI)也是影响通信可靠性和有效性的重要因素。网络环境中,多个用户之间既是通信伙伴又互相影响,这对现代通信系统的建立也都有重要影响。因此,建立符合现代通信实际的信息论(容量理论、基本编码定理等)将使我们对现代通信有更新、更深刻的认识,从而推进通信技术向更高的水平发展。

在由多个通信节点所组成的通信网络中,人们需要回答的一个基本问题是:在任意可能进行通信的成对节点之间能同时实现的最大信息传输速率是多少。例如,在一般的通信网络中,如果允许任意的一对网络节点之间都可以进行通信,由 N 个节点组成的通信网络中将可能存在 $N \times (N-1)$ 个通信节点对,这些可能的通信节点之间最大可达信息传输速率所定义的区域称为通信网络的 Shannon 容量域。正如在点到点的通信链路上,Shannon 信道容量公式定义了实际可实现的物理通信系统不可逾越的传输速率限,该公式激发通信理论工作者研发新的通信技术以逼近该理论极限。对于通信网络,人们也期望获得其 Shannon 容量域,了解其理论极限,并研发新的理论和技术(如各种基于网络的编码技术、交换和路由技术等),以使得实际通信网络的信息传输能力逼近该极限。


目前,对于一般通信网络,我们还不能从理论上回答其 Shannon 容量域。

但是, 经过信息理论工作者半个多世纪以来不懈的探索, 人们已经对某些特殊配置的通信网络和信道条件取得进展。

(1) 多址接入信道。如图 1(a)所示, 该信道是由多个发送机和一个接收机



(a) 多址接入信道



(b) 广播信道


图 1 容量已知的简单网络

组成的信道, 常见的例子, 如卫星地球站和卫星之间组成的上行(地球站至卫星)通信信道, 以及蜂窝通信系统中移动用户至基站之间的通信信道。对于存在 AWGN 噪声的时不变多址接入信道^[2], 以及发送机和接收机理想获知信道状态信息的时变平坦衰落多址接入信


道^[3], 其 Shannon 信道容量域已经可以求得。

(2) 广播信道。如图 1(b)所示, 该信道是由一个发送机和多个接收机组成的信道。常见的例子, 如卫星通信中卫星至地球站之间的通信信道、蜂窝通信系统中基站至移动用户之间的信道。与多址接入信道类似, 对于存在 AWGN 噪声的时不变广播信道^[2], 以及发送机和接收机能够理想获知信道状态信息的时变平坦衰落广播信道^[3], 我们也可以从理论上计算其 Shannon 信道容量域。

由于节点间信号互动的复杂性, 即便对于非常简单的时候不变高斯噪声网络模型[如图2(a)所示的3节点中继信道和图2(b)所示的干扰信道], 我们仍不能求得其 Shannon 容量域, 更不用说存在成千上万个节点的复杂通信网络, 其困难之处在于经典的 Shannon 信息论是建立在基于无穷维空间上求得单尺度最优解的基础之上, 对于多节点的网络环境, 数学优化异常困难。对于图2中给出的简单网络, 目前已知的最好结果是: Gamal 和 Cover 在文献[4]中给出了一个3节点中继信道 Shannon 容量的上界, Han 和 Kobayashi 利用叠加编码(superposition coding)给出了干扰信道的可达速率域^[5]。最近, 美国加州大学伯克利分校的 Tse 等提出了一种“确定信道模型”, 并用此模型给出了一般高斯中继信道的可达速率^[6]。



(a) 3 节点中继信道



(b) 4 节点干扰信道

图 2 Shannon 容量域未知的简单网络

另一项近期的研究进展是: 美国伊利诺伊大学 Kumar 等证明^[7], 在多跳无线通信网络中, 任意一对通信节点之间的信息传输速率与网络中通信节点数量 n

之间的渐近关系是 $\theta(\sqrt{n/\log n})$, 该关系称为无线通信网络吞吐量的“伸缩律”, 该“伸缩率”实际上仅仅定义了 Shannon 信道容量域中的一个点, 即通信网络中 $n \times (n-1)$ 种可能的信息速率组合中所有通信节点对之间速率均相等的那一点。

综上所述, 目前人们对于通信网络 Shannon 容量域的研究已经取得部分进展, 但离问题的真正解决还有很远的距离。另外一个值得人们思考的问题是^[8]: Shannon 的信道容量定义来源于点对点的通信传输链路, 该定义没有考虑通信网络中的队列稳定性、计算复杂度、包传输时延等一系列实际参数, 而这些实际参数对于通信网络的性能至关重要, 从这一角度考虑, 在未来人们是否应该为通信网络定义包含信息传输速率和网络其他性能指标相结合的更全面的容量度量, 这一问题也将是网络信息论需要进一步回答的问题。

参 考 文 献

- [1] Shannon C E. A mathematical theory of communication. Bell Systems Technical Journal, 1948, 27: 379—423, 623—656.
- [2] Cover T M, Thomas J A. Elements of Information Theory. New York: Wiley, 2006.
- [3] Goldsmith A. Wireless Communications. Cambridge: Cambridge University Press, 2005.
- [4] Cover T M, Gamal A E. Capacity theorems for the relay channels. IEEE Transactions on Information Theory, 1979, 25(5): 572—584.
- [5] Han T, Kobayashi K. A new achievable rate region for the interference channel. IEEE Transactions on Information Theory, 1981, 27(1): 49—60.
- [6] Avestimehr A S, Diggavi S N, Tse D. Wireless network information flow: A deterministic approach. IEEE Transactions on Information Theory, 2009.
- [7] Gupta P, Kumar P R. The capacity of wireless networks. IEEE Transactions on Information Theory, 2000, 46(2): 388—404.
- [8] http://www.stanford.edu/~adlakha/ITMANET/ITMANET_Publications/goldsmith_commagsub.pdf.

撰稿人: 尹长川 罗 涛 乐光新
北京邮电大学信息与通信工程学院

光纤通信频谱效率的极限

Maximum of Frequency Efficiency of Optical Fiber Communication Systems

频谱效率是所传输的信息量与所占用的频谱空间之比。比值越高, 频率的利用效率越高。Shannon 在 1948 年率先提出了通信信道传输信息容量极限的问题, 给出在具有一定频带宽度 B 的加性高斯白噪声信道上, 单位时间内可能传输的信息量极限数值 C 与信号噪声功率比之间的关系为

$$C = B \log_2 \left(1 + \frac{S}{N} \right) \quad (1)$$

式(1)只是考虑在加性高斯白噪声信道中进行 PCM 编码的情况下计算了频谱效率的极限, 而实际上, 频谱效率与调制格式、信道特征等多个因素相关。

相对于电缆通信, 光纤信道有其自身的特点。除了收发光端机的电高斯噪声、光散粒噪声和信道中光放大器的放大自发辐射(ASE)噪声外, 随着光纤传

输距离的增加和传输容量的提高, 光纤非线性效应、色散造成的影响也不可忽略。比如说, 色散会造成码间干扰, 非线性会造成信道间的串扰, 这些都会降低系统的频谱效率。图 1 显示了光纤非线性效应中的四波混频(FWM)和交叉相位调制(XPM)效应对频谱效率的限制^[1], 可以看到, 由于 FWM 和 XPM 效应, 频谱效率实际上会随着信噪比的提高而下降。




图 1 光纤非线性效应对频谱效率的限制

采用传统的 OOK 调制格式的光纤通信系统的频谱效率一般在 1bps/Hz 以下。近年来, 通过采用各种新型调制格式来提高频谱效率, 同时增强对非线性光学效应和色散的容纳能力成为光通信领域的一个研究热点。不同调制格式所能达到的频谱效率如图 2 所示^[2]。

在光纤通信领域, 提高频谱效率有如下三种途径^[1~5]:

- (1) 采用高阶调制格式, 如 M -PSK 和 M -QAM 等新型调制格式。
- (2) 缩小波分复用信道之间的间隔或者采用光-正交频分复用调制方式。
- (3) 采用偏振复用(PDM)技术。




图2 不同调制格式所能达到的频谱效率

以上三种技术的结合可以大大提高频谱效率。例如,2010年,Gnauck等通过采用16-QAM调制格式和偏振复用^[4],实现了频谱效率为6.2bps/Hz的长距离传输,系统复用了10个信道,每个信道的传输速率为112Gbps,信道间隔为16.7GHz。截止到2010年为止,光纤通信报道的最高频谱效率的实验为10bps/Hz,所采用的调制格式为128-QAM^[4]。

若可以忽略光纤信道的非线性效应、色散和噪声等,对于采用偏振复用技术和M-QAM调制格式的相干光OFDM通信系统,其频谱效率可以采用下式来估计^[2]:

$$SE=2\log_2 M\times\frac{B}{\Delta f}\times\frac{1}{1+\epsilon} \quad (2)$$

式中,M是调制格式的阶数,如M=4,16,32,64,256等;B表示数据的速率; Δf 是波分复用系统的频率间隔; ϵ 是系统中前向纠错和循环前缀等部分的开销占整个传输速率的比率。

因此,如何建立光纤通信系统完整的Shannon理论模型,预测光纤通信系统的信息容量极限,探求达到此极限的条件,进而指导光纤通信系统进一步提高频谱效率是亟须解决的关键科学理论问题。

解决难题的一个主要困难在于光纤信道建模的复杂性。光纤非线性效应的建模本身是一个非常复杂的问题,色散(含色度色散与偏振模色散)与非线性效应的相互作用进一步加大了信道建模的复杂性,而激光器、光放大器和探测器噪声的统计特性也更为复杂,随机性更强。因此,发现光纤非线性、色散与多种噪声对频谱效率的作用规律,找出光纤通信频谱效率的极限是非常困难的。

解决难题的另一困难在于光通信器件性能的限制,比如说,高阶调制格式

的产生难题, M -QAM 调制的 M 究竟能达到多大? 高速偏振模色散补偿的难题和有源器件噪声降低的难题等, 这些也是值得研究的问题。

在有关光纤通信频谱效率的报道中, 较多研究是集中在如何提高光域的频谱效率, 很少见到光纤通信频谱效率极限问题的有关报道。从难题的原因所在可以知道, 难题的解决可以从理论建模与器件两方面着手: 一方面, 可以根据实验与仿真数据, 获得感性认识和特定场景下的规律, 为全面解决问题做准备, 或通过简化次要因素, 抓住主要矛盾的方法来推进理论研究工作; 另一方面, 通过优先发展全光高阶调制格式产生技术、传输损伤数字信号补偿技术、低相位噪声激光器、低噪声全光放大技术、高速数字信号载波恢复技术及高速 OFDM 技术, 降低光纤非线性效应、偏振模色散和噪声的影响, 提高系统的频谱效率。

参 考 文 献

- [1] Kahn J M, Ho K P. Spectral efficiency limits and modulation/detection techniques for DWDM systems. IEEE Journal of Selected Topics in Quantum Electronics, 2004, 10(2).
- [2] Takahashi H. Coherent OFDM transmission with high spectral efficiency. ECOC 2009, 2009.
- [3] Jansen S L, et al. Long-haul transmission of 16×52.5 Gbits/s polarization-division-multiplexed OFDM enabled by MIMO processing. Journal of Optical Networking, 2008, 7(2): 173–182.
- [4] Gnauck A H, et al. 16-QAM on a 50GHz grid over 1200km of fiber // Proc. OFC 2010, San Diego, 2010.
- [5] Nakazawa M. Challenges to FDM-QAM coherent transmission with ultrahigh spectral efficiency. ECOC'08, 2008.

撰稿人: 喻 松 顾婉仪

北京邮电大学信息光子学与光通信研究院

网络中的信息流最大化

Maximizing Information Flows in Networks

1956年,信息论的创立者 Shannon 在其经典论文 A note on the maximum flow through a network^[1]中指出,根据图论的最大流-最小割定理,通信端到端的最大信息流容量由网络有向图模型的最小割决定(如图1所示)。然而,当今通信网络中的信息流距离实现 Shannon 所提出的最大信息流容量上限还相去甚远。因此,有必要对现有网络的信息编码、路由、传输等通信模式加以改进或重新设计,对信息流进行合理的多路径调度,最大化从信源到信宿节点的流量速率,使得达到信息流容量的理论上限成为可能。




图1 网络信息流最大流问题

简单的最大流问题可以通过线性规划理论加以解决,倘若考虑更为复杂的网络参数和限制条件,势必需要融合信息论、运筹学、博弈论、图论、控制论等跨领域的理论。近年来,采用基于效用函数的优化设计成为研究网络优化问题的一个重要研究方向。自从1998年 Kelly 等提出非线性、凸的效用函数^[2]来度量网络中节点的性能以来,网络效用最大化(network utility maximization, NUM)^[3]的思想被广泛应用到网络资源分配、流量控制等研究领域。NUM方法借鉴经济学模型和博弈理论中消费者接受服务所获收益的效用思想,定义网络节点对于网络服务的满意程度为效用,最为典型的效用函数为节点的传输速率。NUM问题通常采用对偶分解的方法将求解全局最优的任务转化为可以在每个节点上执行的分布式算法,协调节点间传输速率以达到全网效用最大化。在分配网络资源时,可采用跨层^[4]的方式进行,约束条件包括公平性、价格成本及供求关系的博弈论模型^[5]等。此外,还需要考虑路径多样性^[6],实现网络各部分的负载均衡,以保证网络整体的健壮性和普适性。

为了获得单信源组播网络的最大流限,科学家们还提出了一个新的研究领域——网络编码理论(network coding theory)。2000年, Ahlswede 等发表了论文 Network information flow^[7],证明了在单信源组播网络中,网络编码是可以逼近网络信息流容量理论上限的有效方法,它的核心思想是在信源将原始的 m 个信息流编为一组并编码成 $n(n \geq m)$ 个大小相等的新信息流,在中继节点对隶

属同组的编码信息流进行任意不加冗余的编码(如随机线性变换等)并转发,在信宿将收到的编码信息流进行解码操作恢复出原始信息流。2003年,Li等给出了线性网络编码^[8]的构造方法,并且指出了对于一般的组播网络,采用线性网络编码可以达到组播容量的上限。区别于传统网络通信的存储转发机制传输数据,网络编码在提高组播数据传输的吞吐率、简化调度策略、平衡链路负载、增强信息安全性等方面体现了巨大的优势。

信息流最大化的理论和应用探索一直以来都是网络信息理论领域最受瞩目的科学难题之一,吸引着众多网络通信领域的专家学者投身其中,推动了最大流问题的研究进展。但在大规模复杂的网络环境下,如何达到或接近信息流容量的理论上限依然是有待解决且颇具挑战性的疑难问题,有关这一难题的研究还将持续至少二三十年。特别是由网络编码技术所引发的对传统网络路由交换体系的颠覆,必将启发科学家对网络信息流最大化研究更深刻的认识和更巧妙的解决方案。

参 考 文 献

- [1] Elias P, Feinstein A, Shannon C E. A note on the maximum flow through a network. IRE Trans. on Info. Theory, 1956; 117—119.
- [2] Kelly F P, Maulloo A K, Tan D K H. Rate control for communication networks: Shadow prices, proportional fairness and stability. J. Operational Research Soc., 1998, 49 (3): 237—252.
- [3] Low S H, Lapsley D E. Optimization flow control i: Basic algorithm and convergence. IEEE/ACM Transactions on Networking, 1999, 7 (6): 861—874.
- [4] Wang J, Li L, Low S H, et al. Cross-layer optimization in TCP/IP networks. IEEE/ACM Transactions on Networking, 2005, 13 (3): 582—595.
- [5] Yaiche H, Mazumdar R R, Rosenberg C. A game theoretic framework for bandwidth allocation and pricing in broadband networks. IEEE/ACM Transactions on Networking, 2000, 8 (5): 667—678.
- [6] Lin X, Shroff N B. Utility maximization for communication networks with multipath routing. IEEE Trans. on Automat. Contr., 2006, 51 (5): 766—778.
- [7] Ahlswede R, Cai N, Li S Y R, et al. Network information flow. IEEE Transactions on Information Theory, 2000, 46 (4): 1204—1216.
- [8] Li S Y R, Yeung R W, Cai N. Linear network coding. IEEE Transactions on Information Theory, 2003, 49 (2): 371.

撰稿人: 廖建新 王敬宇

北京邮电大学网络与交换技术国家重点实验室

Shannon 信息论中的语义鲁棒性难题

A Problem on Semantic Robust in Shannon Information Theory

1. 难题的来龙去脉及重要性

1948 年, 美国数学家 Shannon 发表了《通信的数学理论》一文, 给出了信息传输的一系列重要成果, 建立了比较完整而系统的信息理论体系, 这就是 Shannon 信息论。在 Shannon 信息论中, 首要解决的问题是信息如何定义。从本体论上定义的信息概念是广义的概念, 即任何事物的运动状态及其变化方式都可以理解为信息。从这个意义上讲, 信息是客观存在的, 与认知主体是否感知到没有任何关系。从认识论角度上定义信息概念, 与本体论的主要不同是, 它指认知主体能够感受到的事物的状态及其变化, 即认知主体不能感知的状态及其变化不叫信息。因此, 前者所描述的信息是广义信息论的范畴, 后者所描述的范围要窄一些, 但内涵更丰富。因此, 在认识论层次研究信息时, 一般要同时考虑形式、含义和效用三个因素。在认识论层次研究信息时, 把只考虑到形式因素的部分称为语法信息, 把只考虑到含义因素的部分称为语义信息, 把只考虑到效用因素的部分称为语用信息。目前, Shannon 信息论中主要研究语法信息, 对语义信息和语用信息, 特别是针对可靠语义信息表达, 即语义鲁棒性的研究还未有定论。目前, 仍未找到从数学上对其进行定量描述的有效方法。

2. 难题解决现状及主要困难所在

当前的相关研究主要集中在使用数学来表述形式, 而用语言来表述相应的语义内容。由于 Shannon 信息论存在不足, 研究人员在 Shannon 信息论创立不久, 就开始对它进行研究并试图将 Shannon 信息论推广到更一般的领域。

Weaver^[1]提出了包含语法信息、语义信息和语用信息的广义通信模型, 但他没有使用数学公式来对所提出的理论进行证明。为了解决语义信息问题, Carnap 等^[2]提出了使用逻辑概率代替随机概率的方法, 并用 Shannon 信息熵来度量语义信息, 该方法要求可选择语句必须是互不相容的, 语句的真假必须是严格分明的, 以及语句的使用必须是正确无误的。20 世纪 50 年代, Kullback^[3]提出了公式(1), 它把 $P^*(x_i)$ 看做是主观预测的可能性测度。

$$I_X = \sum_i P^*(x_i) \log \frac{P^*(x_i)}{P(x_i)} \quad (1)$$

如果先验概率 $P_1(x_i)$ 和 $P_2(x_i)$ 不同, 则不同的先验概率 $P_1(x_i)$ 和 $P_2(x_i)$ 带入公式(1)中, 其差值可表示为^[4]

$$I'_X = \sum_i P^*(x_i) \log \frac{P_2(x_i)}{P_1(x_i)} \quad (2)$$

20 世纪 70 年代, 针对 Shannon 信息论中熵的表达, de Luca 和 Termini 基于模糊集合论, 提出了模糊熵的概念^[5]。模糊熵定义为

$$H_f = -\frac{1}{N} \sum_i [\mu_i \log \mu_i + (1 - \mu_i) \log (1 - \mu_i)] \quad (3)$$

式中, μ_i 是 x_i 在模糊集上的隶属度。当 μ_i 恒等于 1/2 时, 模糊熵 H_f 达到最大值, 此时的模糊信息量为

$$I_f = 1 - H_f \quad (4)$$

这一理论试图通过改进的 Shannon 信息熵——模糊熵, 来对语义信息进行全新的度量, 但它只适用于两个互补的模糊集的情况。

20 世纪 80 年代, Aczel 和 Forte 在 Generalized entropies and the maximum entropy principle 一文中提出了广义熵的概念^[6]。

$$H = \sum_i P(x_i) \log P^*(x_i) \quad (5)$$

并证明了当 $P^*(x_i) = P(x_i)$ 时, 广义熵 H 达到最大值, 即为 Shannon 熵。

基于前期的发展, 当前语义鲁棒性的研究主要集中到: 针对语义信息和 Shannon 信息论定义的信息, 建立一套统一的信息表达理论^[7], 特别是, 针对通信系统的协议栈结构, 研究语义信息在发送端和接收端的实际性能^[7]。

因此, 如何建立与 Shannon 信息论相统一的可靠语义信息表达是本科学难题最重要的方面。以 Shannon 信息论为基础的通信系统, 其任务是将信源产生的信息尽可能无失真地复制到系统的信宿端。在此传输过程中, 通信系统并未对信息的语义作任何处理和判断, 只要通信系统的信宿端把信源端发出的消息从形式上复制出来, 就认为已经实现了它的语义内容。在此过程中, 语义信息的鲁棒性问题尤为重要。首先, 鲁棒性问题在 Shannon 信息论中是通过信源编码和信道编码来解决的, 即如果传输中存在噪声干扰, 通过信源编码和信道编码仍然能让接收端尽可能无失真地得到信源信息。另外, 鲁棒性问题通过上下文信息的相关性来实现, 即通过语义信息的相关性来对噪声干扰产生的信息失真进行纠正。因此, 在通信系统中, 鲁棒性是不可缺少的, 如何将基于语义的鲁棒性引入到 Shannon 信息论中是当前研究的科学难题。

参 考 文 献

- [1] Weaver W. 通讯的数学理论的新发展//庞元正,李建华.系统论控制论信息论经典文献选编.北京:求实出版社,1989;612—636.
- [2] Bar-Hillel Y, Carnap R. An outline of a theory of semantic information. Boston: MIT, 1952.
- [3] Kullback S. Information and Statistics. New York: Wiley, 1959.
- [4] Theil H. Economics and Information Theory. Amsterdam: North-Holland, 1967.
- [5] de Luca A, Termini S. A definition of nonprobabilistic entropy in the setting of fuzzy sets. Infor. Contr., 1972, 20: 201—312.
- [6] Aczel J, Forte B. Generalized entropies and the maximum entropy principle. Maximum Entropy and Bayesian Entropy and Bayesian Methods in Applied Statistics: Proceedings of the Fourth Maximum Entropy Workshop, 1986: 95—100.
- [7] Rodoplu V, Vadvalkar S S. Challenges and directions for semantic communication. International Conference on Semantic Computing, 2007: 290—294.

撰稿人: 刘 健 隆克平

电子科技大学光互联网及移动信息网络研究中心

互联网的可测性问题

The Problem in Measurable Internet

互联网是一个大跨度、分布式、永恒动态的大型复杂系统，是全世界信息传递与处理平台，已经成为国民经济的基础。所谓大跨度，是指网络面向全世界，甚至整个三维空间。所谓分布式，是指不可能有一个集中协调管理。所谓永恒动态，是指不存在稳定时刻，始终在变化，当 $t \rightarrow \infty$ 时，不存在收敛的状态。随着网络技术与信息化进程的推进，政治、经济、军事乃至日常生活越来越依赖网络。网络的应用也极大地推动着网络技术的创新。网络体系结构、协议、设备、业务与用户行为相关作用，共同决定网络状态与应用服务质量，建设可管可控的互联网基础设施，需要实时测量网络、业务与用户行为，建立行为模型并理解相关作用机理。因此，网络测量是未来网络体系结构设计与协议研究的前提，也是网络系统建设、业务创新与优化、网络运营管理的基础。然而，IP 网的设计思想是协议简洁、易于扩展，网络体系结构本身不提供任何测量机制，根本没有考虑可测性需求。所以，网络可测性需要统计地、动态地、局部地来定义。

网络可测性问题包括两个基本问题：网络是否可以全面测量和网络是否可以深入测量。全面测量是指测量空间范围涵盖尽可能的大，甚至涵盖整个互联网系统。深入测量指提供涵盖网络资源、流量、业务等各种特征的多维度、多粒度测量指标。互联网作为人类建造的规模最大的信息系统，各个局部系统通过 TCP/IP 协议栈实现互连，并相互作用共同决定整个网络系统的状态。例如，2009 年 5 月 19 日的影音风暴 DNS 域名解析故障导致 15 省网络瘫痪；2007 年 6 月 29 日 iPhone 推出后，AT&T 公司网内的数据流量 3 年内激增了 5000%，AT&T 的网络多次出现拥塞或是局部瘫痪的情况。另一方面，互联网的各个指标是相互影响的。例如，某个业务流的 QoS 指标由网络数据包处理能力、QoS 策略、并发业务流等决定，诊断与定位网络问题，需要综合分析各个指标，但网络系统并没有提供这些指标的测量机制，而且网络带宽增加与业务动态发展使得指标定义与指标获取愈加困难，尤其是面对服务、面向数据等未来网络体系结构的发展与应用，将对测量指标、实时性等提出新的难题。因此，全面、深入的测量是互联网科学运维管理与规划优化的基础，也是网络测量面临的重要挑战。

自互联网诞生以来，人们就开始互联网测量研究，测量研究包括数据平面

(如性能^[1]、流量^[2]、数据资源分布^[3]等)与控制平面(如路由^[4]、拓扑^[5]等)的测量,目前在测量基础理论、实现技术、分析模型化、测量标准与测量平台方面都取得了大量的成果。例如,IETF成立了IPPM(IP Performance Metrics)工作组^[6],定义了连通性(connectivity)、单向延迟(one-way delay)、双向延迟(round-trip delay)、延迟抖动(delay variation)等一系列互联网数据传输的质量、性能与可靠性指标,建议了相关的测量方法。以NIMI(National Internet Measurement Infrastructure)为代表的网络测量系统的研发、部署为互联网测量提供了直接的手段^[7]。在此基础上,人们开始网络分析与模型化的研究。例如,1994年,Leland等首先发现了以太网流量的自相似特征^[8],该论文被评为网络与通信领域50年最佳论文。

物联网、P2P计算、云计算、移动互联网及未来网络体系等的发展给互联网测量带来巨大的挑战^[9]。美国国家自然科学基金委员会在GENI(Global Environment for Network Innovations)研究计划中指出,网络测量与分析是当前网络研究最重要的挑战与机会,是迫切需要解决的基础性科学问题^[10]。

为了解决网络全面、深入测量的问题,需要设计支持测量的未来网络体系结构与协议,需要研究分布式协同测量理论与机制,需要提出多维自适应高速网络测量方法,并分析建立网络的核心特征和模型。相关研究内容包括以下几个方面:

(1) 测量基础理论与分布式协同测量体系机构。被测量对象的界定与测量意义,测量指标定义与灵活扩展,支持普适测量的未来网络体系结构,可伸缩分布式测量体系结构,大规模协同测量理论与策略,海量测量数据传输与存储,测量数据授权与应用。

(2) 多维、多粒度网络测量实现技术。快速数据包深度处理方法,高效精确测量算法,业务感知理论与方法,网络/业务/用户自适应关联测量机制,网络测量协议与存储。

(3) 分析与模型化基础理论。网络资源、数据、业务特征与行为模型,网络、流量与业务性能的相互影响机制与关联分析,大规模仿真与实际网络实验验证方法,基于测量模型的未来网络体系结构性能评价。

参 考 文 献

- [1] Paxson V. Measurements and analysis of end-to-end Internet dynamics [PhD Dissertation]. Berkeley: University of California, 1997.
- [2] Karagiannis T, Papagiannaki K, Faloutsos M. BLINC: Multilevel traffic classification in the dark. ACM SIGCOMM 2005, 2005.

- [3] Cha M , Kwak H , Rodriguez P , et al . Everybody tubes : Analyzing the world-largest user generated content video system . ACM SIGCOMM IMC 2007 , 2007 .
- [4] Paxson V . End-to-end routing behavior in the Internet . IEEE/ACM Transactions on Networking , 1997 , 5 (5) : 601 — 615 .
- [5] Ni J , Xie H Y , Tatikonda S . et al . Efficient and dynamic routing topology inference from end-to-end measurements . IEEE/ACM Transactions on Networking , 2010 , 18 (1) : 123 — 135 .
- [6] <http://datatracker.ietf.org/wg/ippm/charter/> .
- [7] <http://www.caida.org/research/performance/measinfra/> .
- [8] Leland W , et al . On the self-similar nature of ethernet traffic (Extended Version) . IEEE/ACM Transactions on Networking , 1994 , 2 (1) : 1 — 15 .
- [9] Arlitt M , Williamson C . The extensive challenges of Internet application measurement . IEEE Network , 2007 , 21 (3) : 41 — 46 .
- [10] <http://groups.geni.net/geni/attachment/wiki/OldGPGDesignDocuments/GDD-06-28.pdf> .

撰稿人：谢高岗¹ 闵应骅¹ 孟洛明²

1 中国科学院计算技术研究所

2 北京邮电大学网络与交换技术国家重点实验室

网络的建模方法及建模

The Model and Modeling of Network

随着网络体系及其服务应用的发展,研究人员意识到原有的网络基础理论,特别是在网络建模方法和基础网络模型方面存在着一定的不足^[1]。现有的网络建模方法多采用直觉刻画的方式对网络的不同特性分别进行建模,缺乏精准的数学定义、统一的表述方式及丰富的语义信息,其构建的网络模型无法满足对网络行为细致刻画和对网络业务准确测量的需求,更无法精确地预测网络行为,从而给管理和控制网络带来了技术上的困难^[2]。为保证未来融合、泛在网络环境下的业务应用,综合现有网络建模方法和网络模型的理论知识,从网络测量、管理、控制等技术角度出发,提出适用于融合和泛在网络的、支持对网络行为感知/预测/控制的网络建模方法,并基于该方法,构建一个普适的、基于精准数学表达的、富语义的网络模型,成为当前和未来一段时期内网络研究领域的重大课题。

19 世纪 70~80 年代, Cerf 等提出的 TCP/IP 协议和 ISO 提出的开放式系统互连(OSI)参考模型采用了分层的思想,对计算机网络进行建模。特别是 OSI 参考模型,将计算机网络自下而上划分为物理层、数据链路层、网络层、传输层、会话层、表示层和应用层等 7 个层次,成为经典的计算机网络模型,对后续的网络建模思路和方法影响很大。ITU 在 OSI 参考模型分层建模思路的基础上提出了“分层与分割”的建模方法,在传输、交换等通信网信息建模方面进行了应用。第三代移动通信伙伴计划(3GPP)针对第三代移动通信网络中的语音、数据、增值业务,从抽样业务能力角度进行统一建模,形成 IP 多媒体子系统(IMS)等参考模型。互联网工程任务组(IETF)从解决互联网实际技术问题角度出发,构建了互联网不同特性的若干模型,如针对互联网服务质量(QoS)保障的集成服务(Int-Serv)模型、差分服务(Diff-Serv)模型和多协议标签交换(MPLS)模型等;在简单管理协议(SNMP)框架下,提出各类网络设备、服务和协议的管理信息库(MIB)等。分布式管理任务组(DMTF)针对企业计算机网络管理信息建模的问题,提出了基于 Web 的企业管理(WBEM)建模方法,并构建了通用信息模型(CIM)。电信管理论坛(TMF)采用了自顶向下和商务驱动的建模思路,描绘了增强电信运营图(eTOM),并针对通信网及其运营企业的管理构建了共享信息/数据(SID)模型。

以上网络模型均在某些特定领域(如网络规划建设、网络通信控制等)起着

重要的指导作用,但仍然存在以下多方面的问题:多是对网络部分特性(如网络流量、QoS 等特性)建模,缺乏对网络全面特性的完整描述;对网络行为多为定性判断,缺少定量分析,如可基于模型判断网络是否故障,但难以直接基于模型实现故障定位和根原因分析;可以对网络历史行为数据进行部分获取,但不全面,更无法对未来网络行为预测,特别是精确预测。

造成目前网络建模和网络模型存在缺陷的原因是多方面的,其中,网络复杂性和业务需求复杂性是比较重要的因素。网络复杂性表现在网络(特别是复杂网络)的结构非线性、拓扑动态性、资源自组织性、节点和协议的异构性等诸多复杂特性上;业务需求复杂性表现在网络业务的使用者存在复杂的社会化特征,以及基于此的业务复杂性需求,这些业务复杂性需求会导致网络行为及相关数据成为时空函数。网络复杂性与业务需求复杂性的结合会促使网络行为产生一定的变化,如使得网络行为具有仿生学、统计力学等特性^[3],从而给网络建模带来更大的难度。

在学术界,已经有部分学者就如何对网络进行精确建模的问题展开了研究,其研究方向和研究方法值得借鉴。综合来说,可以围绕以下几个层面对网络建模方法及其模型进行探索:

(1) 异构融合网络的统一建模方法及模型。针对异构网络的融合化趋势,提出融合网络的统一建模理论和方法,并构建统一模型,如面向连接的网络和面向无连接的网络的统一建模方法及融合模型^[4]。

(2) 富语义的网络多特性建模方法及模型。针对网络的多方面特性,研究能够将多特性综合在一个模型中的建模方法,从而实现网络多特性的内在关联。目前,已经有部分学者将人工智能领域中的本体概念^[5]纳入网络建模研究中,希望通过本体理论,提出一种富语义的网络建模方法,能够对网络多方面特性进行综合描述,解决网络的动态性和扩展性问题^[6,7]。

(3) 与其他学科结合进行网络建模和行为分析。结合网络复杂性和业务需求复杂性,基于仿生学、生态学、社会学、统计力学、量子理论等若干已有学科中相关理论,对网络行为进行建模和分析。目前,此方面的研究成果已经非常多,如文献[8],但也正因如此,给网络带来了更多的特性,对这些特性的选择和综合也成为研究人员需要进一步考虑的问题。

参 考 文 献

[1] Clark D, Shenker S, Falk A, et al. GENI research plan. GENI Design Document, 2007.

[2] <http://www.cs.cmu.edu/~4D/>.

[3] Boccaletti S, Latora V, Moreno Y, et al. Complex networks: Structure and dynamics. Physics

- Reports-Review Section of Physics Letters ,2006 ,424 (4—5) :175—308 .
- [4] Smith E .Comparison of traffic engineering techniques in connectionless and connection-oriented networks .Journal of the Communications Network ,2007 ,6 (2) :45—54 .
- [5] Gruber T R .A translation approach to portable ontology specifications .Knowledge Acquisition ,1993 ,5 (2) :199—220 .
- [6] Kim J ,Jeong D ,Baik D K .Ontology-based semantic recommendation system in home network environment .IEEE Transactions on Consumer Electronics ,2009 ,55 (3) :1178—1184 .
- [7] Rahman M A ,Pakstas A ,Wang F Z .Towards communications network modelling ontology for designers and researchers .Intelligent Engineering Systems ,2006 .
- [8] <http://www.biomedcentral.com/1471-2105/5/24/> .

撰稿人：高志鹏 邱雪松 孟洛明
北京邮电大学网络与交换技术国家重点实验室

网络的基本性质

The Character of Network

20 世纪 90 年代以来, 由于计算机、通信和其他高科技等科学技术的迅猛发展, 人们比以往任何时候更容易快捷地获取所需的各种信息和资源, 促使人类加速跨进了网络信息时代, 人类生活和科学研究因此发生了巨大的历史性变化, 网络对全球经济与社会的发展与进步起着十分巨大的推动作用。如同道路、电力、水等一样, 网络已成为当前信息社会的重要基础设施之一, 并逐步向经济、军事、科技与教育等多个领域渗透, 成为信息时代生活中不可或缺的一部分, 并发挥着主导的作用。与此同时, 各领域的科学家积极合作和充分利用人类已有的科学知识和高科技的成果, 试图从理论和实证上深入探索网络的“庐山真面目”, 推进各种复杂网络的广泛应用。但是, 目前对网络的规律尚未完全揭开, 进一步探索网络科学问题, 不仅具有理论意义, 而且具有巨大的应用潜力, 有助于人类解决面临的一些重要问题。认识一个事物的基本性质, 是一类科学问题解决涉及的基本问题, 随着网络的发展, 网络表现出的大规模、非线性、动态性、复杂约束等特征为认识和揭示网络的基本性质带来了极大的困难。

网络的基本性质主要包括网络模型和网络行为等。用网络模型来描述系统的历史由来已久, 可以追溯到 1736 年 Euler 的七桥问题, 甚至更早。两个匈牙利著名的数学家 Erdos 和 Renyi 在 20 世纪 60 年代建立了著名的随机图理论^[1], 对于网络科学理论研究的影响长达近四十年之久。1998 年, Watts 和 Strogatz 在 *Nature* 上提出了“小世界”(small world)网络模型^[2], 阐述了系统涌现出短的平均最短路径的原因。1 年以后, Barabási 和 Albert 在 *Science* 上提出了“无尺度”网络模型^[3], 揭示了复杂网络的“无尺度”特性及其形成机理。在网络模型方面, 科学界迄今已经积累了一些有价值的理论模型, 开展了许多实际网络的研究。多年来, 网络流量特性的研究一直使用 Erlang 模型, 即在泊松过程的影响之下, 包的到达过程是无记忆的, 包的到达间隔服从指数分布。但是, 由于网络规模不断扩大, 业务类型不断增加, 异构性特点越来越突出, 传统的基于泊松过程的网络行为数学模型已不能反映实际的网络行为。1993 年, Leland 等揭示了网络流量的尺度特性^[4]。近年来, 国内外的有关研究大都是通过对大量业务数据进行分析研究, 提炼出反映网络某些真实特性的新的数学模型, 如自相似(self-similarity)、长相关(long-range dependence, LRD)、重尾分布(heavy-tailed)、分形(fraction)及多重分形(multifractal)等模型。

进入 21 世纪以来,国际上有关的重大科学计划^[5]都将认识和揭示网络的基本性质,特别是网络行为作为主要的研究内容,但都没有取得实质性的进展,该科学问题的难点在于传统和经典的通信网理论和研究方法已不足以刻画目前网络的特性。随着网络规模的扩大、承载业务的多元化和服务质量要求的提高,以及影响网络正常运行的因素的增多,尤其是面临的非正常因素具有很强的多样性、随机性、隐蔽性和传染性等特点,网络的基本性质的相关科学问题还需要进一步进行探索。例如,如何为 Internet 等复杂网络构造可用于指导网络设计和建设的模型;如何全面认识网络运行的动态变化规律;如何认识网络在故障状态下的行为和网络在遭受安全攻击时的行为;如何描述网络的可管理性及其管控模型等。

虽然小世界网络和无尺度网络比较准确地把握了现实世界中网络的基本特性,但它们仍然存在一定的局限性,需要在微观层面更深入研究复杂网络的拓扑结构、演化规律和网络行为。在网络行为方面,由于现代网络信息传输的高突发性和随机性,至今尚未发现令人满意的能全面反映网络状态和行为的理论和模型。因此,迫切需要对现有的网络进行新的思考和研究,探索新一代网络行为学,这些新的理论和方法必须突破传统理论的限制,能够处理在规模和复杂性发生数量级变化的网络信息交换问题,适应超大规模超高速信息网络的需要,满足更及时、更方便的服务需求,为未来网络的建设和管理提供理论基础和技术支撑。

参 考 文 献

- [1] Erdos P, Renyi A. On the evolution of random graphs. Publ. Math. Inst. Hung. Acad. Sci., 1960, 5: 17—61.
- [2] Watts D J, Strogatz S H. Collective dynamics of small-world networks. Nature, 1998, 393: 440—442.
- [3] Barabási A L, Albert R. Emergence of scaling in random networks. Science, 1999, 286: 509—512.
- [4] Leland W, Taqqu M, Willinger W, et al. On the selfsimilar nature of ethernet traffic. Proc. ACM SIGCOMM '93, 1993: 183—193.
- [5] <http://www.geni.net/>.

撰稿人: 邱雪松 高志鹏 孟洛明
北京邮电大学网络与交换技术国家重点实验室

通信网络的免疫自愈问题

Immune Self-healing Issues for Communication Networks

1. 难题的来龙去脉及重要性

当前,互联网等通信网络已渗透到人类社会的各个领域。通信网在推动人类社会进步和发展的同时,也伴随有因自然灾害、人为破坏、网络黑客、网络病毒等对互联网基础设施的损害及应用软件系统攻击等诸多的负面影响和社会危害。传统的故障恢复方法及被动的网络攻防技术已无法胜任,需要借助多学科交叉探索网络智能自主自愈的网络安全容错技术方法。

基于生物学的方法(如蚁群智能)已经被证实并已用于解决信息系统中的广泛的问题。生物免疫系统具有耐受、大规模并行分布处理、自组织、自学习、自适应、免疫记忆和鲁棒性等优秀的系统性能,其系统环境与日益复杂和多元化的通信网络系统具有诸多相似性,免疫系统的这类优良功能可望用于通信网系统。因此,十多年来,人们从未停止尝试将生物免疫系统的自愈恢复、自学习、自组织优良性能用于通信网络的容错安全设计和研究。但是,因问题涉及的学科跨度较大,尚未有大力度的、有效的、跨学科的研究组织实施,缺乏对免疫系统的免疫可计算机理、通信网的可免疫机理的交叉深入探究,至今仍未突破局部单点问题方面的简单模拟和概念化探讨的瓶颈。

2. 难题解决现状及主要困难所在

当前的相关研究主要集中在通信网领域模拟生态系统生物免疫系统的自组织特性以用于特定网络场景的寻路、网络资源搜索、网络入侵检测等方面。

(1) 基于生态系统、生物免疫系统自组织特性的鲁棒寻路方面。许多社会性生物群体(如蚁群、蜂群等)表现出了惊人的自组织性、鲁棒性,如原有路径被破坏后,蚁群能迅速重新发现从蚁巢到食物源的最佳路径。受此启发,20 世纪 90 年代,意大利学者 Dorigo 等通过模拟蚁群觅食行为提出了一种基于种群的模拟进化算法——蚁群优化算法(ACO)^[1]。由于蚁群优化算法寻路机制对网络的变化有较强的自愈鲁棒性,近年有学者尝试将其用于分组交换网络系统及无线网络领域^[2]。当前,在通信网领域的相关探讨还仅限于实验室的理论分析和仿真模拟,而且由于蚁群算法在构造解的过程中利用了随机选择策略,导致进

化速度变慢,影响算法的收敛性,尚无法适应要求较快收敛速度的网络实际。因此,当前的难点是如何提高蚁群优化算法路由算法的收敛速度,并有效应用到通信网络系统中。

(2) 基于免疫学中趋向性的路由代理搜索方面。在免疫学中,“趋向性(taxis)”指白细胞在其生活环境中会先天性地朝某些化学物质浓度高的地方作定向运动的现象^[3]。datataxis 是由 Lee 等创造出来的一个词^[4],用来描述路由代理向数据密度高的地方运动。Lee 等将 datataxis 看做城域网中路由载体代理,用于车载 ad hoc 网络(VANETs)。显然,这种数据只储存于特殊的分散移动载体群组中。根据 Lee 等的仿真,证明 datataxis 模型比两个随机游走模型更有效,datataxis 模型对于协议参数的改变具有鲁棒性,但相关研究还仅限于理论模型分析和特殊理想网络场景的简单仿真,用于真实网络尚有很多具体问题有待发现和研究解决。

(3) 基于人工免疫的入侵检测和网络免疫抗体实施方面。20 世纪 90 年代,Forrest 等首先提出了用阴性选择的方法来模拟人体免疫系统中病毒检测的问题,并提出了第一个网络入侵检测系统 NIDS^[5],阴性选择将所有数据分成两类——“自我”和“非我”,然后将接收到的数据和自我的特征码进行匹配,如果吻合,则认为是安全的,否则认为是恶意的。为了改进“自我”和“非我”的二义性识别的困难,Aickelin 等又将免疫学中的危险理论引入到入侵检测中^[6]。危险理论中不再存在自我和非我的概念,而是通过危险信号的强弱进行评价,但该方面的工作仍未突破阴性选择存在误判率和虚警率高,以及危险理论涉及模糊判别实现困难。

参 考 文 献

- [1] Dorigo M, Maniezzo V, Colomi A. Positive feedback as a search strategy. Milano: Politecnico di Milano, 1991.
- [2] Di Caro G, Ducatelle F, Gambardella L M. AntHocNet: An ant-based hybrid routing algorithm for mobile ad hoc networks. PPSN VIII, 2004, 461—470.
- [3] Adler J, Tso W W. Decision-making in bacteria: Chemotactic response of escherichia coli to conflicting stimuli. Science, 1974, 184(4143): 1292—1294.
- [4] Lee U, Magistretti E, Gerla M, et al. Bio-inspired multi-agent data harvesting in a proactive urban monitoring environment. Ad Hoc Networks, 2009, 7(4): 725—741.
- [5] Hofmeyr S, Forrest S. Immunity by design: An artificial immune system. Proc. Genetic and Evolutionary Computation Conference (GECCO), 1999, 2: 1289—1296.
- [6] Aickelin U, Cayzer S. The danger theory and its application to artificial immune systems.

Proc. 1st International Conference on Artificial Immune Systems (ICARIS 2002), 2002 :
141—148 .

撰稿人：隆克平 彭云峰
电子科技大学光互联网及移动信息网络研究中心

复杂网络中关键节点集合的确定

Finding the Key Node Group in Complex Networks

1. 背景介绍

自然界中,大量复杂的系统(生态系统、人类社会系统等)都可以用复杂网络的模型加以描述。模型中的节点表示真实系统中的个体,边表示个体之间的联系。因而,对复杂网络的研究对于我们深入认识自然界的规律有着十分重要的作用。近年来,针对复杂网络理论的研究越来越多,如复杂网络的统计描述、网络演化模型、网络动力学等,其中,复杂网络中关键节点集合确定问题是研究者颇为关注的一个问题。

在我们的日常生活中有许多这样的问题,例如,目前许多城市为了维护社会治安,需要在一些重点地区部署监视器,那么,如何挑选安装位置使监视范围最大?在社会群体中也有类似问题,例如,在一个恐怖组织的网络中,如何确定该组织中的一些关键人物并对其进行打击,从而彻底摧毁整个网络?这些问题都与关键节点集合确定密切相关。

2. 问题描述

关键节点集合确定问题实质上是一个与组合优化相关的问题,它可以描述为:复杂网络中,在资金、网络拓扑、通信模式、时间等约束条件下,如何挑选有限个节点构成一个集合,使该集合在网络中所产生的作用最大化。

由于复杂网络中节点数目众多,并且每个节点的作用、所连接的邻居节点均不同,因而要评判每个节点的重要程度、挑选一些节点构成一个集合并确保该集合是最优解,是一个计算量十分巨大的工作,甚至是在现有条件下很难完成的任务。

3. 必要说明

在研究关键节点集合确定问题的过程中,首先应该确定如何评判单个节点的重要性。已提出的度量单个节点重要性的方法主要包括节点的度(degree)、接近度(closeness)、介数(betweenness)、特征向量(eigenvector)和累计提名(cumulated nomination)等^[1]。其中,基于介数的评判方法是目前应用较为广泛的一种方案。介数最早是 Freeman^[2]于1977年在研究社会网络时提出的用于衡

量个体社会地位的参数。节点的介数是网络中所有最短路径之中经过该节点的数量。节点的介数值越高,这个节点的影响力就越大。随着网络规模越来越大,计算网络中节点的介数运算量迅速增大,研究人员针对此种情况,提出了一些快速计算介数的方法^[3]。

随着对单个节点重要性评判的相关研究逐步深入,人们发现,单纯依据单个节点的重要性程度从高到低挑选一些节点构成集合,并不能保证所构成集合就是网络中最重要的集合。因而,研究人员对关键节点集合确定问题进行了深化,指出欲解决此问题需像单个节点重要性评判那样,找出判定节点集合重要性的方法,然后再依据此方法逐步挑选节点构成一个集合。

1999年, Everett^[4]首次针对集合的重要性计算方法进行了深入研究,他利用计算单个节点重要性的方法(如度、接近度、介数和流介数等方法)来计算集合的重要性。其中,使用度判断集合重要性的方法简单方便,但该方法导致内聚性强的集合重要性低,与外界联系多的集合重要性高,难以反映现实情况;使用接近度的评价方法主要计算集合到集合外各个节点的最短距离之和,计算结果越小,说明集合越重要,这种方法仅从集合自身出发来判断其重要性,所得结果不够准确;使用介数判断集合重要性的方法比较全面准确,但在大规模网络中,其计算量巨大,效率十分低下,导致人们经常不得不舍弃此方法。Everett的贡献主要在于提出了计算单个集合重要性的可能方法,给相关研究开拓了思路。

在随后的研究中,由于使用介数判断集合重要性所得结果比较准确,研究者纷纷提出了一些改进方案,以降低计算量,提高其实用性。其中, Puzis 的研究较为引人注目^[5,6]。Puzis 指出,两个相距较近的高介数节点同时加到集合中,对集合的介数贡献不大;在复杂网络中找出一个大小为 k 的集合,并使其介数最大化是一个 NP 完全的组合优化问题。Puzis 提出了一个快速计算集合介数的方法^[6],虽然该方法对集合的介数计算有了一定改进,但在复杂网络中快速找出一个介数最大的集合目前仍然十分困难。

综上所述,在多种约束条件下,以有限的时间在大规模网络中找到一个最优的关键节点集合还是一个需要继续深入研究的问题,效率和准确性是必须着重关注的指标,两者之间需要取得合理平衡。

4. 相关扩展

Borgatti^[7]指出现有的判定集合重要性的方法在以下两个场合无法适用:当需要删掉一些节点,使剩余网络内聚性最低时;当在一定传播跳数限制下,挑选一些节点作为传播起点,在有限跳数内向尽可能多的节点传播信息时。因而, Borgatti 分别定义了这两个场合下的节点集合重要性评判标准,并指出可使用现

有的一些优化算法挑选合适节点构成所需要的集合,但其提出的节点挑选方法只是简单地利用了贪婪算法,虽然在一定程度上缩短了计算时间,却无法得到最优解。

从 Borgatti 的研究中可以看出,目前提出的集合重要性判定方法存在一定的局限性,在某些场合无法满足要求,需要我们根据实际需要进行改进。

参 考 文 献

- [1] 赫南,李德毅,淦文燕,等.复杂网络中重要性节点发掘综述.计算机科学,2007,34(12): 1—5,17.
- [2] Freeman L C. A set of measures of centrality based upon betweenness. Sociometry, 1977, 40: 35—41.
- [3] Brandes U. A faster algorithm for betweenness centrality. Journal of Mathematical Sociology, 2001, 25(2): 163—177.
- [4] Everett M, Borgatti S. The centrality of groups and classes. Journal of Mathematical Sociology, 1999, 23: 181—202.
- [5] Puzis R, Elovici Y, Dolev S. Finding the most prominent group in complex networks. Ai Communications, 2007, 20(4): 287—296.
- [6] Puzis R, Elovici Y, Dolev S. Fast algorithm for successive computation of group betweenness centrality. Phys. Rev. E, 2007, 76(5): 056709.
- [7] Borgatti S. Identifying sets of key players in a social network. Computational & Mathematical Organization Theory, 2006, 12(1): 21—34.

撰稿人: 苏 森 李勇辉 阎 冬
北京邮电大学网络技术研究院

多域协同通信机理

Fundamental Theory of Multi-domain Cooperation Communication

以移动通信、无线局域网等为代表的无线网络已成为世界各国重要的高新技术支柱产业^[1]。近年来,泛在物联网成为全球热点,被视为战略性新兴产业的代表。然而,已有的和即将推出的系统在无线资源综合优化利用等方面存在局限性,仍然不能很好地解决有限的频谱资源与迅速增长的业务需求的矛盾,由此产生的无线通信瓶颈问题日益突出^[2]。

出现这些问题的根源在于这些系统面向增长的业务需求进行多业务宽带化技术演进时往往受到“边界效应”的制约。“边界效应”源于经济学的概念,意指单一品种投资的后期收益空间越来越小,趋于饱和^[3]。与之类似,传统的无线通信体系主要基于资源独立优化使用模式,在此基础上演进和发展的技术具有局部优化的特征,进一步提升频谱资源利用率往往受到各种“边界效应”的制约。另一方面,传统的资源共享技术往往针对单一的业务进行资源调度,当各种多媒体业务出现并逐步成为主导业务时,宽带无线资源共享调度优化成为数学上经典的“背包问题”,它是一种难解问题(intractable problem),在有限时间内得不到最优解,因而构成了一种时间约束的“边界效应”,使得宽带无线通信如何在保障服务质量的前提下提高多用户多业务系统容量面临越来越大的技术挑战。

为满足不断增长的业务需求,解决无线通信瓶颈问题,就需要突破这些“边界效应”,从根本上提高无线频谱资源利用的有效性。多域协同无线通信理论探索无线通信的基础理论,从体系架构入手,创建新型的无线通信体系框架,通过合理地利用空间、频率、时间、信号、功率、终端、网络等资源,最大限度提高频谱效率和资源共享系统容量,通过研究基于多域协同的无线通信高效传输方法及多用户资源共享优化机理,在此基础上构建未来宽带无线通信基础理论与技术新体系。

多域协同是指空间、频率、时间、信号、功率、终端、网络等多种资源域的协同利用。多域协同通信的主要特征如下:

(1) 无线通信的体系框架由基于单一资源独立使用模式向多种资源综合使用模式发展,支持多用户多媒体业务,并适应各种新型业务需求。

(2) 通过多域协同,将传统的多个一维优化问题扩展为多维联合优化问题,充分挖掘协同潜力,突破“边界效应”的制约,从根本上提高频谱效率。

(3) 充分考虑终端和信道构成的特性,通过多域协同,有效分解多用户高效共享资源时的难解问题,从根本上提高系统容量。

当前,资源域协同的概念正陆续渗透到无线通信的新技术研究中,一些新技术闪亮登场。例如,空时频编码探索了空间、时间、频率三域协同,取得了有意义的理论成果;MIMO-OFDM 融合了多天线和 OFDM 抗多径能力,成为无线环境下提高频谱效率的有效手段^[4];2000 年,Gupta 和 Kumar 针对 Shannon 信息论在讨论信道容量时只考虑了功率、带宽的关系,且大都只适用于单用户应用环境等局限,突破传统 Shannon 信息论的理论框架^[5],提出网络传输容量的概念和一种评价和描述无线网络传输能力极限的理论框架,从而使无线网络在多资源域融合环境下的容量分析受到学术界和工业界的广泛关注。目前,多用户网络信息理论成为研究热点,为面向多用户多业务的资源调度与优化配置指明了方向。

多域协同通信中的主要难点在于用户行为的特征及其网络的影响,如多域协同的效增机理,即通过多域资源的协同实现“ $1+1>2$ ”的系统效能增益,具体表现在无线通信系统中为频谱效率的倍增方法和网络容量的大幅度提高技术。另一方面,多域协同的有效性评价理论也是研究的难题。

参 考 文 献

- [1] 张晓强.中国高技术产业发展年鉴(2008).北京:北京理工大学出版社,2008.
- [2] ITU-R.Requirements related to technical system performance for IMT-advanced radio interface(s).2008.
- [3] Mankiw N G.经济学原理(第三版).梁小民译.北京:机械工业出版社,2003.
- [4] Yang H W.A road to future broadband wireless access ;MIMO-OFDM-based air interface . IEEE Communications Magazine ,2005 ,43(1) :53—60 .
- [5] Gupta P,Kumar P.The capacity of wireless networks .IEEE Transactions on Information Theory ,2000 ,46(2) :388—404 .

撰稿人:陆建华
清华大学电子工程系

空间网络科学

Space Networks Science

21 世纪,人类正面临着全球环境和社会可持续发展的巨大挑战。一方面,人类受到不断变化的地球系统的严峻挑战;另一方面,人类活动正以前所未有的速度影响着地球系统,并正从多种尺度(局部的、区域的、全球的)改变和开发利用地球的物理、化学、生物环境。这些基本地球过程和环境的研究依赖于长期持续的科学数据和空间信息获取、传输和处理,空间网络可以实现大规模数据的实时获取,成为对地观测和系统认识地球的主要手段,尤其是涉及国家安全、具有国家重大急需的高时效性空间信息的获取和应用,必须依赖于空间网络的支持。与此同时,空间网络技术已广泛应用于国民经济和社会发展的各个方面,如经济、社会、人口、资源、环境等。空间网络技术正在孕育一系列具有广阔市场前景的新兴产业,其发展水平直接关系到国家的综合国力和国防安全。

作为未来网络的重要组成部分,空间网络支持航天航空飞行器的全网络连接和信息交互,组成空间互联网,并与地面网络构成天地互连的一体化复杂网络。空间高动态飞行器(如飞机、卫星、飞船、深空探测器等)网络节点的引入,给空间网络的设计带来了全新的挑战。主要表现在:①高动态节点导致网络拓扑的快速变化,给网络体系架构和路由交换带来挑战,地面互联网架构和路由协议不适应空间网络环境;②多层次异构异质特性带来网络互连和融合的困难,现有地面网络技术不支持一体化空间网络;③种类复杂的空间网络业务呈现多源、多维、异质特征,包括通信、遥感、遥测、控制等,其信息速率和 QoS 要求差异大,现有地面网络技术不适应这类业务的传输。因此,空间网络是未来网络研究中的重要方向之一。

空间网络科学是为了探索空间复杂网络的一般规律,综合运用数学、系统科学、复杂科学和空间科学等理论与方法进行空间多维信息获取、传输、存储、处理、分发与应用的科学^[1],它是信息科学当前的重要研究内容之一,主要包括空间网络的特征分析、建模、动力学特性和时空一致性处理等基础研究,以及系统科学和复杂科学相关的研究。与空间网络科学相关的空间信息网络工程是依据空间网络的信息流传输与处理机制来解决工程技术和国民经济重要领域的困难问题,如智能交通、精准农业、服务科学等。

空间网络科学的发展将对空间新型平台设计、空天地一体化网络设计和宇

宙起源探索等具有重大意义；空间信息网络工程一方面有望突破传统平台技术发展的系统局限性，从网络化、系统化的角度设计空间网络，另一方面可以构建新型信息服务体系，为国民经济的可持续增长提供技术基础。

美国和西欧国家非常重视空间网络的研究和建设。美国相继发射、研发了空间侦察监视星座系统、空间通信保障星座系统、GPS 导航定位系统、红外导弹预警卫星星座系统、TDRSS 跟踪与数据中继卫星系统、空间气象保障系统、对地观测系统、海洋监测系统及“天基雷达”系统等。俄罗斯发展了自己的预警天基网、“多功能卫星声信和远程地球监视系统”计划等。欧洲提出了伽利略卫星导航系统、下一代空间网计划等。2004 年，美国编制了美国集成对地观测系统 (IEOS) 的战略计划。2004 年，欧共体也通过了全球环境与安全监测 (GMES) 执行计划。

空间网络科学的主要研究内容包括空间网络的几何性质与拓扑结构、空间网络形成机制、空间网络拓扑的演化规律、空间网络信息流的动力学特征(高动态拓扑结构特征导致信息流量特性)、网络的结构稳定性、空间网络的体系框架与信息传输瓶颈的时空结构演化规律、空间网络的时空一致性和同步理论、空间网络的认知协同理论和服务发现理论、空间动态自组织网络配置理论和方法 and 空间网络动态聚合与重构的理论和方法、时空约束下的多系统控制网络理论等^[2]。

参 考 文 献

- [1] 曾宪钊.网络科学.北京:军事科学出版社,2006:1—15.
- [2] Barabási A L.链接网络新科学.徐彬译.长沙:湖南科学技术出版社,2007.

撰稿人：陆建华
清华大学电子工程系

非均匀采样问题

The Problem of Non-uniform Sampling

众所周知, 基于时域均匀采样的奈奎斯特采样定理是联系连续时间信号与离散时间信号的桥梁, 更是数字信号处理的理论基础^[1,2]。奈奎斯特采样定理叙述如下。

采样定理: 设 $x(t)$ 是一个带限信号, 在 $|\omega| > \omega_M$ 时, $X(j\omega) = 0$ 。如果 $\omega_s > 2\omega_M$, 其中, $\omega_s = 2\pi/T$, 那么, $x(t)$ 就唯一地由其样本 $x(nT)$ ($n = 0, \pm 1, \pm 2, \dots$) 所确定。

上述定理中, ω_M 是信号的上限频率, ω_s 是采样频率, 就带限实信号的时域均匀采样而言, 奈奎斯特采样定理告诉我们, 只要采样频率大于信号最高频率的两倍, 就可以防止频谱混叠, 从而可以通过信号的采样重建原信号。信号重建公式如下:

$$x_r(t) = \sum_{n=-\infty}^{+\infty} x(nT) \frac{\omega_s T \sin(\omega(t-nT)/2)}{\omega_s(t-nT)/2} = \sum_{n=-\infty}^{+\infty} x(nT) \frac{\omega_s T}{2\pi} \operatorname{sinc}\left(\frac{\omega T(t-nT)}{2\pi}\right) \quad (1)$$

式中, $\operatorname{sinc}(x) = \frac{\sin(\pi x)}{\pi x}$ 。

图 1 给出了根据公式(1)从离散时间信号到连续时间信号的重建过程示意图, 其中, 实线表示的连续时间信号是通过使用 sinc 函数对各采样点进行理想带限内插得到的连续信号。需要指出的是, 奈奎斯特采样定理仅仅给出了通过均匀采样重建连续时间信号的一个充分条件, 但它并不是必要条件, 也就是说, 在某些情况下, 即使不满足奈奎斯特采样定理, 仍然可以重建信号。此外, 奈奎斯特采样定理也并不适用于非均匀采样的情况。

随着阵列天线在雷达和通信领域的广泛应用, 使用多天线对空间中传播的信号进行空域快拍(snapshot)以得到阵列信号, 进而对阵列信号进行波束形成^[3]或波达方向估计^[4]的阵列信号处理技术越来越引起人们的高度重视^[5]。空域快拍对应时域的采样, 相应地, 时域采样的频谱也就对应空域快拍的空谱。因此, 与频谱的混叠问题类似, 空谱也存在混叠的问题。空谱的混叠一般是指阵列方向图中栅瓣出现, 在空域快拍过程中避免栅瓣出现与时域采样中避免频谱混叠有着同等的重要性。

由于时域采样一般都是均匀采样, 与之对应的空域快拍也就是均匀线阵快

拍。图 2 给出了在 9 元均匀线阵中使用等加权进行空域快拍的阵列方向图。可以看出,当阵元间距不超过信号波长的一半时,可见区内就只有一个主瓣而不会出现额外的栅瓣;随着阵元间距的增大,栅瓣将会进入可见区。因此,在使用均匀线阵时,避免栅瓣出现的一个充分条件是要求阵元间距不超过信号波长的一半,这与时域的奈奎斯特采样定理是类似的。




图 1 利用 sinc 函数重建连续信号




图 2 等加权 9 元均匀线阵方向图

然而,实际中的天线阵列大多不能保证是线阵,更不能保证是均匀线阵,而共形天线阵列的使用则更是在空域的非均匀采样,此时,阵列需要满足什么样的条件才能保证不出现空谱混叠就成为一个关键问题。文献[5]中引入 co-array 的概念来分析任意阵列的空谱混叠问题,co-array 函数可以看做是阵列激励的空域相关函数,离散 co-array 函数定义如下:

$$c(\mathbf{x}) = \sum_{(m,n) \in \vartheta(\mathbf{x})} w_m w_n^* \quad (2)$$

式中, m 和 n 分别代表阵列中任意两个阵元,它们在空间的位置分别为 $\mathbf{x}_m$ 和 $\mathbf{x}_n$; w_m 和 w_n 分别代表用来激励它们的加权系数; $\vartheta(\mathbf{x})$ 则表示由所有满足 $\mathbf{x} = \mathbf{x}_m - \mathbf{x}_n$ 的二元组 (m, n) 构成的集合。

离散 co-array 函数 $c(\mathbf{x})$ 一般只在空间中若干个离散网格点上取非零值,这些网格点在空间的排布即构成该阵列的 co-array。一般认为,空谱混叠与否不是依赖于阵列中阵元间的最小间距,而是跟 co-array 中网格点之间的最小间距有着密切的关系。对于线阵来说,其 co-array 仍然是线阵,但最小间距一般与原始线阵并不相同;而对于非线阵来说,其 co-array 将变得非常复杂,最小间距也与原始阵列大不相同。尽管可以使用 co-array 分析空谱混叠,然而不幸的是,如果我们想直接从 co-array 出发设计不出现混叠的阵列,其结果往往是很难找到与之对应的真实阵列。因此,当想要使用任意阵列进行空域非均匀采样时,该阵列需要满足什么样的条件才能保证不出现空谱混叠仍然是一个难

题。随着阵列天线应用范围的不断扩展及阵列形式的进一步复杂化,研究空域非均匀采样问题对阵列信号处理意义重大,这也是该领域急需解决的一个科学难题。

参 考 文 献

- [1] Oppenheim A V, Willsky A S, Nawab S H. 信号与系统. 第二版. 刘树棠译. 西安: 西安交通大学出版社, 1998.
- [2] Madisetti V K, Williams D B. Digital Signal Processing Handbook. Boca Raton: CRC, 1998.
- [3] Veen B D V, Buckley K M. Beamforming: A versatile approach to spatial filtering. IEEE Signal Process Mag., 1988, 5(2): 4—24.
- [4] Krim H, Viberg M. Two decades of array signal processing research: The parametric approach. IEEE Signal Process Mag., 1996, 13(4): 67—94.
- [5] Johnson D H, Dudgeon D E. Array Signal Processing: Concepts and Techniques. Englewood Cliffs: P T R Prentice Hall, 1993.

撰稿人: 穆鹏程 殷勤业
西安交通大学电子与信息工程学院

空谱的描述与定义

Description and Definition of Spatial Spectrum

信号的谱指的是信号能量(一般用幅度或功率表示)的分布,如信号幅度在时域上的分布构成时谱^[1],在频域上的分布构成频谱^[1],而对信号进行联合时频分析还可以形成时频谱^[2]。时谱和频谱都是一维谱,而时频谱则是一种二维联合谱,这三种谱相互联系,都可以从某个侧面描述信号的不同属性。除此之外,无线电波和声波等无线信号在大气和水下传播时还会形成信号能量在空间的分布,无线信号与有线信号最本质的区别就在于对空间的使用。无线信号能量在空间的分布即为空谱。

充分利用信号的空谱信息在无线通信、雷达和声呐等方面有着非常重要的意义^[3,4]。举例来说,蜂窝移动通信通过划分小区来实现对任意形状的大范围服务地区的覆盖,这种对空间区域的划分就是利用空谱的一种表现形式。图1给出了一种小区划分示意图,其中包括A~G共7种使用不同频谱的小区。由于各小区均使用小功率发射机,根据无线电波信号在空间传播时的衰减特性,距离足够远的小区之间可以使用相同的频谱而基本不会造成相互干扰。可以说,蜂窝移动通信系统就是通过利用空谱实现了对频谱的复用,这也是其能够取得成功的关键。除此之外,在阵列信号处理中进行波达方向估计^[5]时所涉及的空谱主要指的是来波能量在空间不同方向上的分布情况,而波束形成^[6]则是把信号能量集中到所关心的方向上,相当于形成特定的空谱。这两种情况下的空谱都是考虑信号能量在空间不同方向(或角度)上的分布情况,因此,都可以看做是方向谱(或角度谱)。




图1 蜂窝系统的小区划分

无线通信的快速普及和发展使得频谱资源越来越紧张,除了上述蜂窝系统中通过小区划分的方式利用空谱之外,基于多天线的智能天线系统和多输入多输出系统可以通过波束形成和空域分集技术提高频谱的利用率,其本质上也是在利用空谱解决无线通信中频谱资源紧张的问题。为了更好地解决该问题,近年来还兴起了认知无线电技术^[7],其中,感知用户通过感知系统中授权用户对频谱的使用情况来选择可用频谱资源,以达到充分利用有限的频谱资源的目的。

事实上,由于认知无线电中感知用户需要感知的主要是其对授权用户是否造成影响,这往往并不等同于授权用户是否对感知用户有影响,因此,不能仅仅通过频谱感知来判断,而应该对时、频、空谱进行联合感知,尤其是要对空谱的使用情况进行感知。




图2 认知无线电谱感知示意图

以图2为例,基站(BS)与授权用户(PU)之间进行通信,BS使用多天线波束形成对PU定向发射频率为 f_1 的信号,同时,BS的多天线波束形成还可以定向接收来自PU的频率为 f_2 的信号。PU使用单个全向天线进行收发,作为感知用户的CS和CD也均使用单个全向天线收发。由于CS和CD可以通过接收到的信号感知到PU在使用频率 f_2 发射信号,因此,按照一般频谱感知的原则就不应当使用该频率,这个结论其实是不对的。事实上,使用 f_2 并不会对PU和BS之间的通信造成影响,这是因为BS只定向接收来自PU的频率为 f_2 的信号,对其他方向的频率为 f_2 的信号

并不关心,而PU处在发射状态,CS使用 f_2 更加不会对其造成影响。相反,由于CS和CD均感知不到频率为 f_1 的信号的存在(BS只对PU做定向发射),因此,按照一般频谱感知的原则,CS就可以使用该频率发射信号,而一旦使用 f_1 ,CS发射的信号就可能会对PU造成干扰,这显然是不允许的。由此可见,认知无线电中谱感知的关键是合理有效地利用空谱,最终实现对时、频、空谱的联合感知,这是目前认知无线电技术最大的困难所在。

要想合理有效地利用空谱,首先应该解决空谱的准确描述和定义问题,而实际上,该问题到目前为止尚未得到很好解决。事实上,无论是蜂窝通信中的空间区域还是阵列信号处理中的方向谱,它们都只是从某一个侧面对空谱进行描述。认知无线电需要同时考虑空间区域和传播方向,再加上无线信号在空间传播时的多径效应,这就需要一个能够综合各个方面来对空谱进行准确描述的定义。除了以上提到的三维空间位置和波的传播方向之外,电磁波的不同极化方向也反映了信号在空域上的不同特性,因此,也应该反映在空谱的定义中。与时谱和频谱这两种一维边缘谱相比,确定空谱的维数其本身就不是一件容易的事情,在这种情况下,想要全面、准确地描述和定义空谱就更是一个难题,攻克这一科学难题对无线通信及雷达、声呐等领域的进一步发展有着非常重要的意义。

参 考 文 献

- [1] Oppenheim A V, Willsky A S, Nawab S H. 信号与系统. 第二版. 刘树棠译. 西安: 西安交通大学出版社, 1998.
- [2] Cohen L. Time-frequency distributions-a review. Proceedings of the IEEE, 1989, 77(7): 941—981.
- [3] Johnson D H, Dudgeon D E. Array Signal Processing: Concepts and Techniques. Englewood Cliffs: P T R Prentice Hall, 1993.
- [4] Tse D, Viswanath P. Fundamentals of Wireless Communication. 北京: 人民邮电出版社, 2009.
- [5] Krim H, Viberg M. Two decades of array signal processing research: The parametric approach. IEEE Signal Process Mag., 1996, 13(4): 67—94.
- [6] Veen B D V, Buckley K M. Beamforming: A versatile approach to spatial filtering. IEEE Signal Process Mag., 1988, 5(2): 4—24.
- [7] Bruce F. Cognitive Radio Technology. 2nd ed. Boston: Academic Press/Elsevier, 2009.

撰稿人: 穆鹏程 殷勤业
西安交通大学电子与信息工程学院

具有明确物理含义且满足边缘条件的非负时频分布的存在性

Existence of Positive Time-Frequency Distribution Satisfying Marginal Conditions with Physical Meaning

时域信号是时间的函数，记为 $s(t)$ ，对其进行傅里叶变换可以得到信号的频域表示 $S(\omega)$ ^[1]。根据经典的傅里叶分析，信号在时刻 t 的瞬时谱密度为 $|s(t)|^2$ ，而在频率 ω 上的谱密度为 $|S(\omega)|^2$ ，两者分别对时间、频率积分即信号的总能量。

$$\int_{-\infty}^{\infty} |s(t)|^2 dt = \frac{1}{2\pi} \int_{-\infty}^{\infty} |S(\omega)|^2 d\omega \quad (1)$$

客观上，信号的能量分布与时间和频率两个变量有关，因此，应该是二维分布。而经典的傅里叶分析方法，要么仅从时域观察信号，要么仅从频域观察信号，相当于仅观察了信号的一维边缘分布。如果希望知道信号的频率分量随时间的变化情况，就需要在时间和频率上对信号进行联合分析^[2]。例如，图 1 的左上子图即为四段跳频信号的一种时频分布，它清楚地描述了信号的频率分量随时间的变化情况。图 1 中的下子图是信号的时域波形，右子图是传统的功率谱。联合时频分析的基本思想就是设计一个时间和频率的联合函数(分布)，使其能同时在时间和频率上描述信号的能量(或强度)分布，称之为信号的时频分布、时频谱或时变谱。通常，用 $P(t, \omega)$ 表示信号的密度函数，那么，它应该满足什么样的条件呢？




图 1 四段跳频信号的时频谱

首先,从概念上讲,作为一个二维联合分布密度函数,它应符合边缘条件^[2,3],即有

$$\int_{-\infty}^{\infty} P(t, \omega) dt = |S(\omega)|^2 \quad (2)$$

$$\frac{1}{2\pi} \int_{-\infty}^{\infty} P(t, \omega) d\omega = |s(t)|^2 \quad (3)$$

通常称式(2)为频率边缘条件,即在某特定频率上对时间的积分应该等于该频率上的能量密度。类似地,称式(3)为时间边缘条件。为方便分析,通常会对信号的能量归一化,因此,若以上两个边缘条件成立,则

$$\frac{1}{2\pi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} P(t, \omega) d\omega dt = 1 \quad (4)$$

一定成立。

其次,按照传统的能量和分布密度的概念,它还应该是非负的,即 $P(t, \omega) \geq 0$ 。

最后,也是最为重要的,时频分布应该具有明确的物理含义,即能准确地反映信号频率分量随时间的变化情况,这是联合时频分析的主要目标,也是最难保证的性质。

Wigner 首先发现了满足边缘条件的分布函数。Wigner 分布(Wigner-Ville distribution, WVD)对信号时变特性的描述比许多已有的时频表达都要好,它具有许多对信号分析来说有用的性质,如时间和频率边缘条件、瞬时频率性质与群时延性质等。然而,交叉项的存在使得 Wigner 分布不满足非负条件,这与传统的能量概念是相悖的。Cohen 类将所有的双线性时频分布归纳成统一的形式,通过选择或设计适当的核函数,就可以得到所需的时频分布。但是,正如 Wigner 证明的那样,这种通过双线性变换得到的时频分布不能同时满足边缘条件和非负条件。

如果不考虑具体的物理含义,而仅从数学角度看,满足边缘条件的非负时频分布显然是存在的。例如,

$$P(t, \omega) = \frac{|s(t)|^2}{\|s(t)\|^2} |S(\omega)|^2, \quad \|s(t)\|^2 = \int_{-\infty}^{\infty} |s(t)|^2 dt \quad (5)$$

既满足边缘条件,又是非负的。遗憾的是,类似式(5)这样的分布并不能真实地反映信号的局部性质,因此,对时频分析来说是没有任何意义的。

实际上,由边缘分布确定联合分布是欠定问题。因此,给定边缘分布,可以找到无穷多种对应的联合分布。Cohen 与 Posch 在文献[4]中给出了满足边缘条件的非负时频分布在数学上应该满足的条件,被称为 Cohen-Posch 理论。起源于统计学的 Copula 理论给出了从边缘分布确定联合分布的理论方法。文献[5]建立了 Cohen-Posch 理论与 Copula 理论之间的联系,证明了两者在数学形

式上是等价的。基于上述理论,对任意信号都可以找到无穷多种非负时频分布,许多学者也做了大量的研究工作。然而,迄今为止,基于以上数学理论提出的非负时频分布都不具有明确的物理含义,不能准确地反映信号的时变性质。

该问题的主要难点在于:时间与频率这两个物理量是通过傅里叶变换紧密联系在一起的。傅里叶理论告诉我们,要观察一个信号是否包含某个频率分量,需要在整个时间轴上观测,即要从无穷远的过去一直观察到无穷远的将来。而时频分析的主要目的是观察信号的局部变化,这就需要对信号加上时间窗(在二次表达中对应为核函数)进行观察。显然,两者的出发点存在着根本的不同,要同时考虑这两个方面存在的主要困难是:给目标信号加窗会影响到对信号所含频率分量的分析。

传统的能量非负的概念直接导出了上面的非负条件。实际上,非负条件是否必要也是一个非常值得探讨的问题,但目前学术界的研究重点仍然是非负时频分布的存在性。

综上,能反映信号时变特性(具有明确物理含义)的满足边缘条件的非负时频分布(谱)的存在性至今仍然是一个科学难题,该问题的研究不仅对信号处理意义重大,而且也是物理学研究的基本内容。

参 考 文 献

- [1] Oppenheim A V, Willsky A S, Nawab S H. 信号与系统. 刘树棠译. 西安: 西安交通大学出版社, 1998.
- [2] Qian S, Chen D P. Joint Time-Frequency Analysis. New York: Prentice Hall, 1996.
- [3] Cohen L. Time-frequency distributions-a review. Proceeding of the IEEE, 1989, 77(7): 941—981.
- [4] Cohen L, Posch T E. Positive time-frequency distribution functions. IEEE Trans. on ASSP, 1985, 33(1): 31—38.
- [5] Davy M, Doucet A. Copulas: A new insight into positive time-frequency distributions. IEEE Signal Processing Letters, 2003, 10(7): 215—218.

撰稿人: 张建国 殷勤业
西安交通大学电子与信息工程学院

无线通信系统中信道容量的定义和度量

Definition and Measurement of the Channel Capacity in the Wireless Communication System

Shannon 信息论^[1]给出了一般意义上的信道容量的定义,即信道使用一次平均所能够传递的最大信息量,它对现代数字通信系统具有非常重要的理论指导意义。对于离散无记忆信道而言,目前已经有了大量的工具和方法来计算其信道容量。对于连续无记忆信道,也有 Shannon 公式可以完成加性高斯白噪声信道容量的计算。Shannon 公式比较适合有线通信系统,然而它却难以用于计算现实通信系统中的复杂无线信道的容量。这是因为:①在无线信道中,影响信道的因素非常多,远远超过有线信道的情况,如信号在传输过程中会经历复杂的频率选择性衰落和时间选择性衰落;接收机在接收时除了噪声,还有来自别的用户的干扰。值得注意的是,干扰与噪声不同,它有可能对接收是有益的。简单机械地照搬有线系统模型无助于描述无线信道。②现实的无线信道一般具有多径效应,多径效应意味着信道中存在着记忆。无线信道一般是有记忆的,这个问题本质上与空间谱的性质和特点有关。另一方面,无线通信的迅速发展又需要人们掌握实际系统的容量,以便为搭建现实通信系统提供理论指导。

目前,人们已经知道,无线通信系统的信道容量至少与以下因素有关^[2]:信噪比、接收天线数、发射天线数、位于同一小区的用户数及调制与编解码方式。可以看出,与信道容量有关的因素太多,这是导致描述它的数学模型迟迟没有出现的原因。

此外,人们对无线通信系统信道容量的认识也是一个不断深化的过程。例如,初期人们认为乘性信道的容量不会超过加性信道,现在人们已经知道,如果接收端准确地已知信道信息,乘性信道的容量可以超过加性信道^[2]。又如,人们长期认为,同一小区中别的用户的干扰对本用户接收是有害的,然而,后来的研究表明,多用户也可以带来分集增益,如果接收算法合适,同一小区中用户越多,信道容量越大。

与这一问题紧密相关还有一个无线信道的建模问题,它也是一个难题。虽然现在已经有了大量的模型,包括理论仿真使用的 Rayleigh 衰落模型、Rice 衰落模型、LTE 使用的 SCME 信道模型^[3]等,但这些模型都是统计模型,也就是说,要确定这些模型的参数,需要大量的观测值才能得到一个统计估计值。在

实际使用时,无线信道建模过程相当繁琐,以至于几乎没有运营商会真的采用它来对自己的网络进行优化。

图 1 和图 2 分别给出了原始的 Shannon 公式适用的简单信道及现实通信系统中的无线信道。可以看出,即使在单发单收这种简单的无线通信模式下,现实的无线通信系统也不可避免地存在着多径,图 1 中的简单模型实在难以描述。




图 1 原始的 Shannon 公式所描述的信道容量




图 2 现实的复杂无线通信环境

目前,人们在无线信道容量问题上已经取得了一些进展。对于无记忆的系统而言,单发单收的加性信道、乘性信道包括快衰落信道慢衰落信道,基于某些空间复用或空时编码的多发多收这些系统的信道容量都已经有了相当成熟的模型和结论。目前,人们正在研究类似于有中继和协作时的信道容量^[4]等问题。

但是,多天线多发多收系统的信道容量问题并没有完全解决,如图 3 所示。假设各天线均为全向天线,各天线上的噪声在频率和空间上均为白色(“频白”和“空白”、“双白”)。发射端(天线 1)发出的信号经过两路反射后在右边接收端(天线 2)同相叠加,使得接收信号功率得到增强,而左边接收端(天线 3)的接收信号由于没有叠加效果,因此不会增强。在“双白”的前提下可以认为左右两接收端的噪声功率是一致的,则右边的接收端可以达到更高的信道容量。从某种角度来看,造成这种差异的原因正是由于两个接收端对空间谱的利用效率不同,或者在一定程度上可以看做是利用了无线信道的多径传输特点。更一般地说,无线信道的多径特点会造成通信双方之间的信道从加性信道(平衰落信道)变为乘性信道(频率选择性衰落信道)。因此,从空间谱角度研究这个问题也是

一种思路。




图3 无线信道容量示意图

正是因为目前的无线信道容量还没有成熟的理论，所以，现在的移动通信系统只能把无线信道的建模当成是一个工程问题。现在不论是 GSM 系统，还是 CDMA 系统，要决定需要在什么地方新增加基站，基站的功率是否足够，应当怎样优化各个基站的分布等这些问题主要是靠实测和经验，还没有合适的数学模型可以帮助人们处理这些问题。

研究这一问题有一个基本困难在于：Shannon 信息论不擅长描述连续（模拟）系统。对于连续信源，Shannon 信息论中所给出的平均信息量是一个无穷大，这就限制了它合理地描述现实的无线通信系统。

总之，实际通信系统的信道容量是一个很重要的物理量和指标，然而，已有的科学理论却很难描述和度量它，这使得这一问题自然地成为了一个科学难题。

参 考 文 献


- [1] Shannon C E. Communication in the presence of noise. Proceedings of the IRE, 1949, 37:10—21.
- [2] Tse D, Viswanath P. Fundamentals of Wireless Communication. Cambridge: Cambridge University Press, 2005.
- [3] <http://www.tkk.fi/Units/Radio/scm/>.
- [4] Sendonaris A, Erkip E, Aazhang B. User cooperation diversity-Part 1: System description. IEEE Trans. on Com., 2003, 51:1927—1938.

撰稿人：邓 科 穆鹏程
西安交通大学电子与信息工程学院

图像差异感知模型

Perceptual Image Difference

图像信号差异的计算准则一直以来以 MSE (均方根误差) 或其对应指标 PNSR (峰值信噪比) 为主, 广泛地应用于各种图像处理、分析、分割、识别和重建等领域, 构成了图像相关领域的几乎所有科学问题的基础。但是, 该准则与人类视觉感知机制不匹配, 导致无法得到有效的应用^[1]。一方面, 它难以充分表达视觉感知差异, 具有不完备性, 如图 1 所示。相对于原始参考图像图 1 (a), 图 1 (b)~(f) 分别为对参考图像进行特定处理后的图像, 每一个处理后图像相对于参考图像的 MSE 基本上等于 225, 但各自的主观差异却非常明显。另一方面, 我们已经知道, 人类视觉观察图像差异主要依赖对图像结构改变的感知, 这种感知在一定意义上可以通过互相关函数表达^[2], 但该计算模式比 MSE 对信号的约束相对要弱。因此, MSE 计算准则实际上增加了问题难度, 人们因而期望研究更加准确的图像差异计算准则。



(a) 原始图像, MSE=0




(b) 对比度增强, MSE=225




(c) 电平偏移, MSE=225



(d) JPEG 压缩, MSE=215



(e) 高斯模糊, MSE=225



(f) 加椒盐噪声, MSE=225

图 1 几乎相同 MSE 的约束下, 运用几种典型图像处理方法获得的原始图像(a)的处理效果

注: 该图来源于: http://www.cns.nyu.edu/~zwang/files/research/quality_index/demo.html

从牛顿和 Young 关于光学原理的研究、Von Helmholtz 的生理光学, 以及

近代和现代关于视觉神经系统的实验和研究等,到现代 Marr 等学者创立的视觉计算理论,人们逐渐用一种可计算的模型描述人类视觉的认知过程,这种可计算模型将视觉系统纳入人类现有的逻辑知识体系中描述和发展,并通过计算机技术具体实现,从而获得可能的实用技术。

自 Barlow 以来,人们逐渐认识到,生物视觉系统在长期的进化中对自然场景逐渐适应,演化成为对自然图像提取基本元素,并在此基础上表象所见场景的生物视觉行为模式,而基本元素具有高度的统计独立性,能够完备地表达图像的全部信息^[3]。视觉神经系统生理物理学方面的研究及视觉计算理论的相关研究充分证实了这一点。首先,视觉皮层细胞对自然图像的响应特性被证明是稀疏表达(sparse representation)和统计独立的^[4],其次,Olshausen 等在他们那篇著名文章里成功地完成了对自然图像的字典训练和稀疏表达^[5],并且有趣的是,训练出用于表达自然图像的字典与初级视觉皮层简单细胞的响应行为高度一致,可以用 Gabor 函数表达。从视觉神经生理物理系统的研究角度来讲,人们已经初步了解了从视网络到大脑皮层的视觉神经信号的传递过程,构建了比较完整的初级视觉模型及部分中级视觉模型。在这个过程中,从节细胞(GC)和外侧膝状体细胞(LGN)的圆对称感受野(零交叉滤波器),到初级视觉皮层的具有空间频率、方向和尺度的简单细胞输出,以及后继的非线性和抑制机制(divisive normalization transformation, DNT),说明了视觉神经系统以冗余的方式处理图像特征,并且稀疏地和独立地表达图像特征。

根据人类视觉系统的知识推理图像差异模型是研究者一直追寻的目标,现有的主要研究对象包括图像质量评估(image quality assessment, IQA)和视觉观察者模型(human observer model, HO model)。

图像质量评估研究的主要动机是估计图像经过处理、压缩、传输等环节后的主观感知质量。人们最初的想法是根据视觉神经系统知识自下而上地构建计算方法,典型的方法有 VSNR 模型^[6]和后继的 MAD 模型,但由于目前 HVS 的知识并不充分,因而无法取得完全理想的结果。另外的一些研究者尝试采用自上而下的研究方法,在一些合理假设的基础上直接建模,也取得了一定的进展,典型的方法有基于结构相似性的 SSIM 模型^[2]和基于互信息的 VIF 模型^[7]。

视觉观察者模型的主要研究动机是评估确定已知背景(background known exactly, BKE),或者统计已知背景(background known statistically, BKS)中的确定信号的视觉检测能力,实际上属于关于局部图像差异感知的研究。该方面的研究最早见于评估电视设备质量的 ROSE 模型^[8],现代信号处理技术的引入使得我们能够在统计学意义上研究视觉观察者的行为,在医学图像质量评估中得到了充分的应用,典型的成果有非预白化滤波器^[9]和基于线性分类器的 Hotelling 模型^[10],这些模型都纳入了 HVS 的知识,逐渐接近基于背景和信号统计独立地检测的理想观察者模型。

尽管人们已经在以上方面进行了大量的研究工作,但距离建立一个具有视觉神经系统结构支持的通用图像差异感知模型,还有大量的研究工作需要进行。

首先,人们关于图像质量评估和视觉观察者模型等两方面的研究目前是相对独立的,没有互相融合以获得更多的进展。其次,虽然已有大量的理论和实验研究结果揭示了初级视觉神经系统的自下而上的结构和机制,但更多的自上而下的机制尚不清楚。在这样的背景下,如何正确地引入视觉神经系统模型到图像差异研究中是一件困难的事情,妨碍了建立有明确 HVS 模型背景的图像差异感知理论。

近年来,自然图像统计模型和压缩感知框架下稀疏编码理论的发展,为构建符合 Barlow 定律和视觉神经系统响应信号特征的计算模型提供了新的理论框架,也为最终建立通用的图像差异感知模型提供了新的基础。

参 考 文 献

- [1] Wang Z, Bovik A C. Mean squared error: Love it or leave it? IEEE Signal Process Mag., 2009; 98—117.
- [2] Wang Z, Bovik A C, Sheikh H R, et al. Image quality assessment: From error measurement to structural similarity. IEEE Trans. on Image Process, 2004, 13(4): 600—612.
- [3] Barlow H B. Understanding natural vision // Braddick O J, Sleigh A C. Physical and Biological Processing of Images. Berlin: Springer, 1983: 2—14.
- [4] Field D J. Relations between the statistics of natural images and the response properties of cortical cells. J. Opt. Soc. Am. A, 1987, 4(12): 2379—2394.
- [5] Olshausen B A, Field D J. Emergence of simple-cell receptive field properties by learning a sparse code for natural images. Nature, 1996, 381: 607—609.
- [6] Chandler D M, Hemami S S. VSNR: A wavelet-based visual signal-to-noise ratio for natural images. IEEE Trans. on Image Process, 2007, 16(9): 2284—2298.
- [7] Sheikh H R, Bovik A C. Image information and visual quality. IEEE Trans. on Image Process, 2006, 15(2): 430—444.
- [8] Burgess A E. The rose model. J. Opt. Soc. Am. A, 1999, 16(3).
- [9] Burgess A E. Statistically defined backgrounds: Performance of a modified nonprewhitening matched filter model. J. Opt. Soc. Am. A, 1994, 11: 1237—1242.
- [10] Barrett H H, Yao J, Rolland J P, et al. Model observers for assessment of image quality. Proc. Nat. Acad. Sci., 1993: 9758—9765.

撰稿人: 牟轩沁

西安交通大学电子与信息工程学院

能否建立多种物理场联合反演的一般理论与方法

Can We Find a General Theory and Methods for the Joint Inversion Where the Information from Different Types of Physical Field

1. 背景介绍

反问题的主要目标是确定介质或激发源的物性参数及几何参数等。在解决实际问题时,由单一物理场的观测数据构成的反问题常常存在多解性,限制了反演的精度及分辨率。在很多实际问题中,对同一研究对象,我们可用不同性质的源激发波,这些波分别与介质作用后被接收,得到具有不同性质的观察数据。例如,要研究地下介质中油气储层的空间展布及含油气的情况,我们可以在地表激发地震波,地震波经地下介质反射或散射后,被布置在地表的接收器接收,得到数据集合(称为数据集1)。也可以在地表附近激发电磁波,波经地下介质反射或散射后在地表被接收,得到另一个数据集合(称为数据集2)。还可以把激发源及接收器都放在介质中得到其他数据集。激发源也可以是其他类型。仅用单一的数据集反演,反演的精度及分辨率等可能不能满足实际问题的要求。若把两个数据集(或更多个数据集)构成一个整体(新的数据集),构造恰当的目标函数进行反演(这种反演方法称为联合反演),反演的精度及分辨率会有明显提高。因此,联合反演受到学术界及工业界的重视,是一个十分活跃的研究领域。

2. 问题的历史回顾及现状分析、难点所在

关于联合反演的理论与方法,国内外学者开展了大量的研究工作,在一定条件下提出了一些有效方法,并在实际应用中取得了很好的结果。例如,Misiek、Liebig等^[1]提出了地电和地面地震资料的联合反演方法;Vermeesch、Morgan等^[2]提出了旅行时和重力数据的三维联合反演方法;Mello等^[3]提出地震、岩石物理和盆地模拟的联合反演方法;曹丹平、印兴耀等^[4]提出反射地震资料、井间资料及垂直地震剖面资料的联合反演方法;Drahos^[5]给出了地球物理联合反演中目标函数的确定方法等。这些方法可大致分为三类:方法1,不同类型的数据集独立反演,但反演时用到其他数据集反演的结果;方法2,以一个数据集为反演对象,把其他数据集通过某种映射转换为待反演数据集同类的数据;方法3,多个数据集构成整体,进行联合反演。我们重点考察方法3。

关于方法 3, Drahos 给出了很好的概括, 叙述如下: 联合反演中待优化求解的目标函数是由代表每个参与反演的数据集的目标函数共同产生的。通常的策略是: ①考虑到不同的数据集中测量数据、相应的正演中生成的数据大小及量纲可能不同, 对它们做归一化处理; ②对每一个数据集构造反问题的目标函数; ③把所有目标函数进行加权求和, 得到联合反演的目标函数。该方法的联合反演目标函数中, 每个数据集对应的目标函数的加权系数代表了它对总的反演结果的贡献大小。在每个数据集中, 测量量的误差服从正态分布的情况下, Drahos 给出了上述加权因子的确定方法。在一般情况下, 加权因子需根据多次试验来确定, 缺乏统一客观的方法。

需要指出, 上述方法中有一个条件, 所有数据集中待反演的模型参数向量是相同的。

3. 问题描述

上述方法的条件在实际中可能不满足, 举例如下:

大量的实际问题中, 我们获得的关于研究对象的不同物理量的观测值, 物理性质、测量尺度等差别很大, 与这些物理量对应的介质几何和物理参数可能不同。例如, 在油气勘探中, 我们希望研究地下介质中油气的空间展布, 这时地球介质是我们的研究对象。在地表上观察到的反射地震资料是地下介质对地震波的响应, 电磁测井得到的数据是地下介质对电磁波的响应。地震波的波阻抗界面与电磁波的阻抗界面可能不同, 因此, 反演时它们各自构造的反问题模型参数可能是不同的。

测量量的误差由于测量仪器的带宽有限可能不服从正态分布。

问题: 多种地球物理场联合反演时信息如何融合? 能否建立多种物理场联合反演的一般理论与方法?

上述问题对推动反问题的研究有十分重要的意义, 是需要解决的科学难题。

4. 难题的主要相关扩展问题

联合反演的核心问题之一是目标函数的构造。上述不同类型的物理场得到的观测数据, 针对研究问题的目标, 如何进行智能型的处理, 进行信息融合, 建立新的反演理论与方法, 是需要研究的问题。

参 考 文 献

- [1] Misiek R, Liebig A, Gyulai A, et al. A joint inversion algorithm to process geoelectric and surface wave seismic data. Part II: Applications. *Geophysical Prospecting*, 1997, 45: 65—85.

- [2] Vermeesch P M ,Morgan J V ,Christeson G L ,et al. Three-dimensional joint inversion of travelttime and gravity data across the Chicxulub impact crater . Journal of Geophysical Research ,2009 ,114 :02105 .
- [3] Mello U T ,Levin S A ,et al. Assisted seismic matching :Joint inversion of seismic ,rock physics and basin modeling .Seg Expanded Abstracts ,2007 .
- [4] 曹丹平 ,印兴耀 ,张繁昌 ,等 .多尺度地震资料联合反演方法研究 .地球物理学报 ,2009 ,52(4) :1059—1067 .
- [5] Drahos D .Determining the objective function for geophysical joint inversion .Geophysical Transactions ,2008 ,45(3) :105—121 .

撰稿人：高静怀

西安交通大学电子与信息工程学院

高性能迭代解码问题

The Problem of High Performance Iterative Decoding

信道编解码理论一直是通信研究中的热点问题。近年来,这个领域的主要发展就是发现了多种迭代解码方法,如 Turbo 码^[1]、LDPC 码^[2]等。迭代解码方法可以使信道传输速率逼近信道容量。然而,关于迭代解码的性能分析一直未能取得太多的进展。现在,人们依然不能定量地描述迭代解码算法的性能,甚至不能给出收敛速度和误码率的公式。有趣的是,第一种迭代解码方法——Turbo 码的发现是一个偶然,它不是在严格数学推导下或者基于某些物理概念而发明的。后来,人们尝试使用 Tanner 图^[3]来解释部分迭代解码算法的性能,并且取得了一些进展,但完整严格的数学工具和推导过程依旧没有出现。如果能在迭代解码算法的定量分析方面有所突破,那么,就可以从理论上得出更好的解码方法,而不用像现在这样,不得不靠尝试才能得到好的编解码算法。

从编码发展历史来看,数学上的归纳与分析总落后于新型编码的发现。从 20 世纪 50 年代信道编解码理论出现以来,编码总共经过了三次历史性的发展,分别是 1950 年 Hamming 提出了 Hamming 码,1967 年 Viterbi 提出了卷积码的最大似然解码算法,1993 年 Turbo 码的发现。从它们各自的性能分析来看,Hamming 提出 Hamming 码时就给出了详细的性能分析,他所用的数学手段是近世代数^[4]的理论,Viterbi 只是提出了一种卷积码解码的快速算法,这种算法大大促进了卷积码的实用化,但并没有给出卷积码的性能分析。实际上,卷积码的性能分析还是基于分组码性能分析的理论,使用卷积编码后码字间的 Hamming 距离来衡量。

以 Turbo 码为代表的迭代解码大大提高了信道编解码的性能,它在目前人们能够可接受的条件下几乎可以无限逼近 Shannon 界。然而,凡事有利有弊,到了以 Turbo 码为代表的迭代解码时代,原有的用于分组码和卷积码这种基于码字 Hamming 距离为基础的衡量也不存在了。具体的解释如下:解码过程如图 1 所示^[5],待解码符号如同水流一般在两个解码器之间来回流动,这也就是为什么称为 Turbo 码的原因(Turbo 本意为涡轮机)。很难说现在码字的性能只与码字间的距离有关了。从直观上来看,影响性能的除了两个解码器以外,交织器是影响性能的重要因素,仿真结果也证实了这一点。但是,目前尚无合适的数学模型来给交织器影响性能这一现象建模。




图 1 Turbo 解码器原理示意图

没有性能分析理论会带来很多问题，举例来说，正是因为 Hamming 在提出分组码时有详细的数学模型和理论分析，所以，后来的研究人员提出了各种各样的分组码，包括分组码的一大子类——循环码，它包括许许多多构造出的线性分组码，如 BCH 码、Reed-Solomon 码、Kappa 码等。而卷积码在这方面就逊色得多，卷积码没有像分组码这样成熟的数学模型和理论分析，这就导致目前构造卷积码的主要途径是通过计算机搜索。这一现象到迭代解码时就更加严重，卷积码还可以通过计算机搜索，判断性能只要比较卷积码的生成码字之间的距离即可。而迭代解码的性能不仅与码字距离相关，还与交织器的选择有关。交织器一般都比较长，典型的长度成千上万，使用计算机穷举搜索相当费时。还有一个对迭代解码不利的因素是迭代解码的码字一般都较长，导致判断码字性能所耗费的计算机资源相当可观。

目前，人们在这一问题上已经有了一些探索，其中以使用 Tanner 图^[3]对 LDPC 码的性能解释最为理想。LDPC 码采用迭代解码算法也可以逼近信道容量。Tanner 图是一种二部图，如图 2 所示，一半表示码字的各个位(比特节点)，另一半表示码字各个位的关系(约束节点)。通过对 LDPC 码解码过程采用 Tanner 图描述，人们已经发现如果需要构造性能良好的 LDPC 编码，那么，Tanner 图上最好不要出现环，尤其是比较短环(环上结点数比较少)会造成性能的急剧下降。




图 2 Tanner 图

Tanner 图实际上是试图将 Turbo 码中的交织器模型化，这是因为 Turbo 码中的交织器起的作用是使两个分量编码器尽可能无关，在 LDPC 码里，这是由生成矩阵的行和列约束来实现的。可能正是因为 LDPC 码有了良好的数学工具，

所以,它能够克服原始 Turbo 码解码过程中的平台效应(就是说随着信噪比的增加, Turbo 码的迭代解码器性能不再提高了)。

虽然 Tanner 图帮助人们解释了 LDPC 码的性能,但这方面需要完成的工作还有很多。LDPC 码的编码和解码比原始的 Turbo 码要复杂一些,如果需要达到同样的性能, LDPC 码的码字长度要超过 Turbo 码,这就限制了它的实用性。而其他的迭代解码器的性能还没有找到合适的数学模型和分析方法。另一方面,使用 Tanner 图只能定性地描述解码的过程,定量的分析结果至今尚未出现,这仍是以后信道编码领域需要攻克的难题。

造成这一现象的本质原因是人们的数学工具太有限了,目前在抽象代数领域,非线性空间一直没有合适的数学工具,而迭代解码器的解码过程恰好在线性空间中进行。另外,人们对迭代解码的深层物理机制也不了解。所以,造成这一难题也就不足为奇了。

参 考 文 献

- [1] Berrou C, Glavieux A. Near optimum error correcting coding and decoding: Turbo-codes. IEEE Trans. on Com., 1996, 44: 1261—1271.
- [2] MacKay D J C, Neal R M. Near Shannon limit performance of low density parity check codes. Electronics Letters, 1996, 32: 1645—1646.
- [3] Kschischang F R, Frey B J, Loeliger H. Factor graphs and the sum-product algorithm. IEEE Transactions on Information Theory, 1998, 47: 498—519.
- [4] 朱平天, 李伯滨, 邹园. 近世代数. 北京: 科学出版社, 2009.
- [5] 沈连丰, 叶芝慧. 信息论与编码. 北京: 科学出版社, 2004.

撰稿人: 邓 科

西安交通大学电子与信息工程学院

用分段线性时不变系统逼近时变系统的条件与方法

The Condition and Method of Approximating a Time-variant System with Piecewise Linear Time-invariant Systems

1. 背景介绍

线性时不变系统的性质及分析方法是我們很熟悉的。然而,实际研究对象往往是时变系统。时变系统的参数估计与处理具有重要的理论意义和实用价值。例如,把地球看成层状黏弹性介质,考虑平面波垂直入射,忽略多次反射波,地表上激发一个子波,把入射在所有深度的波阻抗界面上的子波集合看成一个系统,所有波阻抗界面上的反射系数集合(即反射系数序列)看成该系统的输入,地表上接收到的记录看成系统的输出,该系统就是一个时变系统,若不考虑噪声,该系统可用下式描述:

$$s(t) = \int_{-\infty}^{\infty} w(\tau, t-\tau) r(\tau) d\tau \quad (1)$$

式中, $s(t)$ 表示输出的地震记录; $r(\tau)$ 表示反射系数序列; $w(\tau, t-\tau)$ 表示入射到 τ 时刻对应的波阻抗界面上的子波。在已知某些先验信息的情况下,由 $s(t)$ 出发,利用式(1)求反射系数序列,这是地震资料处理中需要解决的关键问题之一。

2. 研究现状、历史回顾及难点所在

在式(1)中,由于介质是黏弹性介质,入射在不同深度处波阻抗界面上的子波是不同的,直接从式(1)出发求取反射系数序列是很困难的。为此,人们提出了对式(1)的一些近似表示,进而给出了估计地震子波与反射系数序列的方法。下面举出两个有代表性的近似方法。

方法1: 根据实际问题的特点,人为地把非平稳地震记录 $s(t)$ 划分为若干段,每一段地震记录近似认为是平稳的,即满足褶积模型,对每一段记录分别用通常褶积模型中使用的方法来处理,从而得到反射系数序列与地震子波^[1,2]。

方法2: Margrave 等给出的方法^[3,4]。考虑黏弹性介质,品质因子 Q 不依赖于频率,波阻抗界面上形成的反射系数序列服从白噪声假设,则 Q 值引起的效应可用如下公式来模拟:

$$s_Q(t) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \alpha_Q(\tau, f) r(\tau) e^{2\pi i f(t-\tau)} d\tau df \quad (2)$$

式中,

$$\alpha_Q(\tau, f) = e^{-\pi f \tau / Q + i H(\pi f \tau / Q)} \quad (3)$$

为单频平面波的传播算子, $i = \sqrt{-1}$ 。若地表激发的地震子波在频率域表达式为 $\hat{w}(f)$, 则非平稳地震记录道在频率域可表示为

$$\hat{s}(f) = \hat{w}(f) \int_{-\infty}^{\infty} \alpha_Q(\tau, f) r(\tau) e^{-2\pi i f \tau} d\tau \quad (4)$$

对式(4)两边做 Gabor 变换, 并利用渐进展开, 可得到

$$V_g s(\tau, f) \approx \hat{w}(f) \alpha_Q(\tau, f) V_g r(\tau, f) \quad (5)$$

式中, V_g 表示以 g 为窗函数的短时傅里叶变换, 其定义为

$$V_g f(\tau, f) = \int_{-\infty}^{\infty} f(u) \bar{g}(u - \tau) e^{-2\pi i f u} du \quad (6)$$

这里, $\bar{g}$ 表示对 g 取复共轭。基于式(5), 他们给出了在时频域估计子波和反射系数序列的方法。

上述方法 1 中把非平稳地震记录划分为分段平稳序列的标准是人为选择的, 这在实际中不能保证划分的合理性及逼近精度; 方法 2 所用的假设不一定满足实际情况。

3. 问题的描述

问题可表述为: ①当时变系统的输入及系统函数满足哪些条件时, 该系统可用分段线性时不变系统逼近? 或可表述为时变系统输出的非平稳时间序列在何种条件下可用分段平稳时间序列来逼近? ②如何实现有效分段? 能否对精度进行估计?

4. 难题的主要相关扩展问题

(1) 如果已知构成时变系统的入射在每个波阻抗界面上的子波的傅里叶振幅谱随频率缓变, 而反射系数序列的傅里叶振幅谱随频率快变, 能否从非平稳时间序列中把子波的振幅影响校正掉?

(2) 若地表处(对应于时变系统初始时刻)子波已知, 该信息对把非平稳序列划分为逐段平稳序列有何帮助?

(3) 利用分段得到的逐段平稳序列能否近似估计介质中地层 Q 值?

参 考 文 献

- [1] van der Baan M. Time-varying wavelet estimation and deconvolution by kurtosis maximization. *Geophysics*, 2008, 73(2): 11–18.

- [2] Yilmaz O .Seismic Data Processing .Tulsa ;Society of Exploration Geophysicists ,2007 .
- [3] Margrave G F ,Lamoureux M P .Gabor deconvolution .Calgary ;CREWES Research Report ,2001 .
- [4] Margrave G F ,Gibson P C ,Grossman J P .The Gabor transform ,pseudodifferential operators ,and seismic deconvolution .Integrated Computer-Aided Engineering ,2005 ,12 (1) :43 —55 .

撰稿人：高静怀

西安交通大学电子与信息工程学院

微波成像的稀疏表示问题

The Problem of Sparse Expression for Microwave Imaging

随着雷达成像分辨率要求越来越高,高分辨、超高分辨微波成像需要发射大带宽信号及获得大多普勒带宽,仅数据量超大之困难,就给目前的微波成像系统带来严峻挑战。近年来,稀疏信号处理理论获得了重大突破,Candes 和 Tao 等学者给出了将稀疏线性回归等价转化为优化问题的充分条件(RIP 条件)^[1,2],Donoho 首次提出压缩感知的概念^[3],为信号稀疏采样条件下的准确重建提供了重要理论依据;美国 Rice 大学提出了信号稀疏采样的实现方法^[4],并已经成功研制出稀疏采样光学相机。该理论体系下,特定信号的稀疏性表示是稀疏信号能够准确重建的前提。例如,对某港口停泊的船只进行稀疏微波成像,由于水面反射系数强度远远小于船只的反射系数强度,因此,该观测区域反射系数可以看成是稀疏的,满足稀疏重建的条件,成像结果如图 1、图 2 所示。




图 1 方位向稀疏采样条件下的
稀疏微波成像




图 2 满足奈奎斯特采样条件下的
传统 RD 成像

目前,有相关文献对某地面区域在小波域进行稀疏表示,但稀疏成像效果不够理想^[5]。由于观测区域的多样性,观测区域的稀疏性表示也是多样的。复杂区域条件下,如城市、山区地带的反射系数稀疏化表示相当困难,主要因为观测区域的多样性与复杂性导致观测区域稀疏表示的多样性与复杂性。目前,

尚未提出一种有效的理论与方法能够针对不同观测区域寻求其稀疏化表示。

因此,建立一套完整有效的理论体系,以指导寻求不同复杂观测区域的稀疏化表示,是一个具有重要研究意义的科学难题。

参 考 文 献

- [1] Candes E, Romberg L, Tao T. Robust uncertainty principles: Exact signal reconstruction from highly incomplete frequency information. IEEE Transactions on Information Theory, 2004.
- [2] Candes E, Tao T. Near optimal signal recovery from random projections: Universal encoding strategies? IEEE Transactions on Information Theory, 2006, 52(12): 5406—5424.
- [3] Donoho D L. Compressed sensing. IEEE Transactions on Information Theory, 2006, 52: 1289—1306.
- [4] Kirolos S, Laska J, Wakin M, et al. Analog-to-information conversion via random demodulation. Proc. IEEE Dallas Circuits Syst. Workshop (DCAS), 2006: 71—74.
- [5] Bhattacharya S, Blumensath T, Mulgrew B, et al. Fast encoding of synthetic aperture radar raw data using compressed sensing. IEEE Workshop on Statistical Signal Processing, 2007.

撰稿人: 廖桂生 王伟伟

西安电子科技大学雷达信号处理国家重点实验室

非均匀样本条件下的协方差矩阵估计问题

Covariance Matrix Estimation by Nonhomogeneous Samples

雷达在接收目标信号的同时,由于杂波和干扰等信号环境的多变性,采用自适应处理技术抑制不需要的噪声提高信噪比是常用方法。其中,自适应处理的关键环节是利用雷达接收的样本数据估计杂波干扰噪声协方差矩阵。从 RMB 准则^[1]可知,在雷达接收信号服从独立同分布条件下,当样本数目大于自适应处理权系数(自由度)两倍时,自适应处理的信噪比损失与最优处理相比不超过 3dB。但实际应用中,雷达接收信号数据样本存在不是独立同分布的情况,这种情况下,协方差矩阵如何估计长期以来是一个没有解决的问题,在统计估计理论上也是一个难题。

双站机载雷达的发射机和接收机将安装在不同的载机平台上,相对于普通的单站机载雷达,其具有获取信息丰富、作用距离远、安全性高、抗干扰能力强和抗截获性能好等突出优点。但双站机载雷达接收的雷达回波信号在空时两维功率谱上存在严重的随距离变化的多普勒扩展现象,也称为杂波距离依赖性。

运动平台雷达抑制地物杂波的最先进的信号处理方法是空时两维自适应处理(STAP)^[2]。STAP 方法性能的优劣取决于对干扰杂波噪声的协方差矩阵估计的准确性。对于雷达回波信号,通常认为地杂波是随距离近似平稳的,即认为不同距离单元对应杂波的空时谱分布相同,这样,就能从距离上获得足够独立同分布样本进行协方差矩阵估计,这样的假设对于机载正侧面阵雷达情况是成立的(如图 1 所示)。但对于机载非正侧面阵雷达与双站机载雷达,其接收的回波空时两维功率谱存在严重的距离扩展现象。在这种情况下,不同距离门的杂波空时分布不同,呈现出严重的非均匀特性,分布不再满足独立同分布条件,从而无法通过雷达接收的距离门回波数据准确估计杂波干扰噪声协方差矩阵,使得空时自适应处理不能有效的抑制地杂波(如图 2 所示)。

如何利用非均匀的杂波样本进行协方差矩阵准确估计是雷达自适应处理方法中一个核心的关键问题。一方面,人们试图找出一种方法将非均匀样本转换成均匀样本。例如,针对杂波距离依赖性的补偿。补偿的核心是找到一个线性变换矩阵,使不同距离单元的杂波样本经过该矩阵变换后能够变成独立同分布的样本,从而能够在距离上获得足够的均匀样本进行杂波协方差矩阵估计。已有的补偿方法主要有多普勒搬移法(DW)^[3]、角度多普勒补偿法(ADC)^[4]、自适应角度多普勒补偿法(A²DC)^[5]、空时插值方法^[6]及基于配准的补偿方法^[7]。但




图1 单基正侧面阵雷达杂波功率谱




图2 双基地雷达杂波功率谱

是, 这些补偿方法仍不能将所有距离单元的非均匀样本变换为严格理论意义上的均匀样本。因此, 一个公开的科学难题是: 是否存在一个线性变换将不同空时分布的所有距离单元数据一致变换为具有相同空时分布的数据样本?

另一方面, 从统计估计理论方面来看, 也存在一个公开的科学难题: 是否可以直接通过非均匀样本实现协方差矩阵的准确估计?

参考文献

- [1] Reed I S, Mallett J D, Brennan L E. Rapid convergence rate in adaptive arrays. IEEE Trans. on Aerospace and Electronic Systems, 1974, 10(6): 853—863.
- [2] Brenna L E, Reed I S. Theory of adaptive radar. IEEE Trans. on Aerospace and Electronic Systems, 1973, 9(2): 237—252.
- [3] Kreyenkamp O, Klemm R. Doppler compensation in forwardlooking STAP radar. Proc. Inst. Elect. Eng.—Radar Sonar Navig., 2001, 148(5): 253—258.
- [4] Himed B, Zhang Y, Hajjari A. STAP with angle-Doppler compensation for bistatic airborne radars. Processing of 2002 IEEE Radar Conf., 2002: 311—317.
- [5] Himed B, Zhang Y, Hajjari A. Adaptive cancellation method for geometry-induced non stationary bistatic clutter environments. IEEE Trans. on Aerospace and Electronic Systems, 2007, 43(2): 651—672.
- [6] Varadarajan V, Krolík J L. Joint space-time interpolation for distorted linear and bistatic array geometries. IEEE Transactions on Signal Processing, 2006, 54(3): 848—860.
- [7] Lapiere F D, Ries P, Verly J G. Foundation for mitigating range dependence in radar space-time adaptive processing. IET Radar Sonar Navigation, 2009, 3(1): 18—29.

撰稿人: 廖桂生 李 明

西安电子科技大学雷达信号处理国家重点实验室

语义不确定的新媒体信息量化描述问题

Quantification of Semantic-uncertain Information in New Media

1. 难题的来龙去脉及重要性

信息度量是信息科学中的一个重要的基础性问题。由于在现实世界中,信息对应于对本身具有不确定性的事物的状态和运动的描述,信息的“量”与所依附事件的复杂度与不确定性存在必然关系。因此,信息的量化描述,即信息度量,就构成了信息传播与处理领域内的一项关键问题。信息度量的设想最早由 Hartley 提出^[1],而真正具有奠基意义的则是 Shannon 在其所创立的信息论中^[2]所给出的、以消息事件概率为基础的信息度量方法。设消息所代表的事件出现的概率为 $P(x)$,则该消息所含的信息量 I 为

$$I = -\log_a P(x) \quad (1)$$

当 a 取 2 时, I 的单位为 bit。设信源由 n 个符号组成,各个符号 x_i 出现的概率为 $P(x_i)$,则每一符号的平均信息量(信源的熵)为

$$H = -\sum_{i=1}^n P(x_i) \log_2 P(x_i) \quad (2)$$

式中, H 的单位为 bit/符号。当各符号等概率时,信源熵达到最大值 $H_{\max} = \log_2 n$ 。

20 世纪末以来,随着数字信息技术和信息网络技术的迅速发展,各类新媒体系统逐渐成为承载信息传播与服务功能的主要平台。根据目前领域内的共识^[3],新媒体是指数字技术为基础的、具有开放性、对等性和交互性的信息传播系统;而广义的新媒体则是指人类社会的发展进程中各类与信息传播相关的新兴科学技术所产生的信息传播方式和途径。

在新媒体环境下,信息所承载的语义,即信息在特定信息传播语境中的具体内涵,较之传统的通信系统而言,具有明显的复杂性和动态性。而新媒体所产生的复杂网络结构中的海量信息交换,也为信息语义带来了更大程度的不确定性。尽管式(1)和式(2)所确立的信息度量方法对于新媒体环境下的消息个体还是有意义的,但新媒体消息语义的不确定性使得对于传统信息度量方法的扩展成为必然。新媒体环境下的信息量化描述应当是以语义的不确定性的描述和处理为基础的。

不确定性信息处理是现代信息技术中的一项关键共性问题。在新媒体环境

下,媒体服务内容、网络动态性、智能服务决策等各个层面的不确定性存在彼此的关联与相互影响,使得这一领域内的信息描述与处理较之传统的信息系统而言,具有更为突出的系统复杂性。目前,国际、国内针对媒体语义不确定性建模与处理机制的研究获得了广泛关注,在传统的模糊集和粗糙集理论基础上衍生出了以混合高斯模型为代表的媒体内容语义描述机制。但是,如何有效地结合媒体内容、服务结构、网络 and 智能服务决策等层面的不确定性描述问题,提出更为综合而有效的不确定性信息描述模型与处理机制,目前仍然是一项亟待解决的问题。

2. 难题解决的现状

Zadeh 创立的模糊数学理论^[4]是不确定性信息处理的重要基础,而其所提出的高斯钟形模糊模型则在近年来针对媒体语义的不确定性描述中呈现出显著的优势。除 Bordogna^[5]等通过语义的心理认知实验建立基于高斯分布的语义描述模型之外,以下各项研究共同完成了高斯模糊模型在语义描述问题上的确立。

Li 和 Wei^[6]推证了高斯隶属度函数对于自适应的语义决策的有效性,以及模糊语义决策规则的权重和匹配精确度之间的折中关系,并且以均方误差为匹配精确度的度量指标,对 Mackey Glass 和 Box Jenkins 等标准数据集进行了实验验证,实验结果表明了以高斯模型为基础的模糊语义描述的有效性。

Pieczynski 等^[7,8]对比研究了不同模糊模型(三角、钟形分段平方和高斯)在多维非线性过程描述中的特性,并针对高斯隶属度模型进行了参数可配置的建模研究。根据文献[7]中的归纳,确定模糊模型的过程往往是专家决策或基于有限实验的主观决策的过程。文献[8]验证了高斯隶属度模型对于系统进化算法的有利性。

3. 难题的描述与说明

语义不确定的新媒体信息量化描述问题,就其本质而言可以概括为:为适应开放式网络环境下复杂媒体信息自身所具有的语义不确定特征,在传统的信息度量理论与方法基础上,需要研究和建立有效的不确定信息描述结构,确定复杂媒体内容环境下的信息度量方法。具体地,需要建立适合各类语义特征和语义关系的模糊描述模型,并构建相应的基于信息内容特征的模糊匹配算法,进而在语义不确定情形下的信源熵度量方式也能确立。

4. 难题的主要困难所在

该难题的解决所面临的主要两个难点是:其一,模糊模型的参数化策略是决定这一新型信息度量方法有效性的重要因素,需要在数学上发现符合新媒体

内容信息特征和人类感知特点的参数化模型；其二，新媒体是一个不断发展的领域，其技术形态和应用模式的不断演进将会引发其信息特征的相应变化，进而给信息度量等基础问题带来不容忽视的挑战。

参 考 文 献

- [1] Hartley R V L. Transmission of information. Bell Systems Technical Journal, 1928, 7(3): 535—563.
- [2] Shannon C E. A mathematical theory of communication. Bell Systems Technical Journal, 1948, 27: 379—423.
- [3] <http://zh.wikipedia.org/zh-cn/%E6%96%B0%E5%AA%92%E9%AB%94>.
- [4] Zadeh L A. Fuzzy sets. Infor. Contr., 1965, 8: 338—353.
- [5] Bordogna G, Carrara P, Pasi G. Extending Boolean information retrieval: A fuzzy model based on linguistic variables // Proc. of the IEEE Intl. Conference on Fuzzy Systems, San Diego, 1990: 769—776.
- [6] Li Y, Wei M Y. Meaning and precision of adaptive fuzzy systems with Gaussian-type membership functions. Fuzzy Sets and Systems, 2002, 127(1): 85—97.
- [7] Pieczynski A, Obuchowicz A. Application of the general Gaussian membership function for the fuzzy model parameters tuning. LNAI 3070, 2004: 350—355.
- [8] Pieczynski A. Fuzzy modeling of multidimensional non-linear process-influence of membership function shape // Proc. 8th East West Zittau Fuzzy Colloquium, Zittau, 2000: 125—133.

撰稿人：苏志武 曹三省
中国传媒大学

融合网络媒体服务环境中的用户行为模型方法问题

User Behavior Modeling within the Context of Converged Network Media Services

1. 难题的来龙去脉及重要性

用户行为模型是对信息系统的服务能力进行分析和研究的重要基础。只有建立起一个完善的用户行为模型,才能够对用户在系统中的行为模式进行有效的感知和预测,进而为用户提供其所需的信息服务,提升系统的服务效率。

在融合网络环境下,大量以媒体内容复杂性和深层交互性为特征的媒体服务将能够得以普遍开展,这一融合网络媒体服务环境将成为未来信息社会的主要服务支撑体系,是未来所有自然智能体(用户)和所有人工智能体(设备)实现服务互连的信息基础设施。

在融合网络媒体服务环境下,一方面,由于服务形态产生了融合与发展,用户行为变得更加复杂而丰富,具有突出的语义复杂性、瞬态与时变性及环境相关性^[1,2];另一方面,用户自身的特征也涉及用户的背景知识、技能与经验、信息需求、在特定领域内拥有的知识、认知能力和情感状态等多方面因素^[3,4],这都会进一步提升用户行为模式的复杂性。

2. 难题解决的现状

当前开展的用户行为模式研究仍然是依托于传统网络在实现了技术演进后的单一网络环境(如宽带化的移动通信网络、双向化的有线电视网络等)而开展的,特别是在互联网用户行为模型、通信网络用户行为模型和数字电视用户行为模型等方面的研究取得了较为显著的进展。这些工作虽然是依托于尚未融合的网络而开展的,但它们所涉及的服务模式已经出现了趋同性和融合趋势,因此,这些工作对于本难题的解决是具有重要的积极意义的。

例如,在互联网用户行为模型研究中,一些重要进展包括:Spink 和 Saracevic 提出了信息提取的分层交互模型,该模型包含用户和计算机两个成分,用户领域包含的要素有情境、情感、认知和请求,计算机领域包括的要素有界面、工程、加工和容量^[5]。Wang 等提出了一个多维信息模型,该模型包含用户、界面和网络空间等三个在搜索过程中相互作用的成分,并认为可将用户与网络的交互活动视为由界面所驱动的互动与沟通过程^[6]。

3. 难题的描述与说明

在下一代融合网络中,用户行为模型由于涉及物理异构的网络、不同尺度的终端、多种多样的服务形态,因此,其建模变得十分复杂。在融合网络环境下,用户行为模型应能支持复杂交互信息描述,支持业务的富内容特性,并能够具有时变性和瞬态性,以适应越来越复杂、灵活而多变的用户行为。对以上模型的构建将是支撑未来融合网络服务有效性的一个关键问题。

4. 难题的主要困难所在

该难题的解决所面临的主要难点包括:①时变性和瞬态性用户行为模型的数学基础;②用户个人经验建模中的语义信息处理机制的构建;③用户行为模型在复杂网络服务环境下的验证和优化。

参 考 文 献

- [1] Ji J Z, Liu C N, Sha Z Q, et al. Personalized recommendation based on a multilevel customer model. *International Journal of Pattern Recognition and Artificial Intelligence*, 2005, 19(7): 895—916.
- [2] 王越. 基于信息的几个相关问题研究. *微计算机信息*, 2007, 23(2): 291—292.
- [3] Hsieh-Yeei I. Research on Web search behavior. *Library and Information Science Research*, 2001, 23(2): 167—185.
- [4] 朱明泉, 等. 互联网信息搜索用户行为模型的探索性研究. *浙江大学学报*, 2006, 33(4): 475—480.
- [5] Spink A, Saracevic T. Human-computer interaction in information retrieval: Nature and manifestations of feedback. *Interacting with Computers*, 1998, 10(3): 249—267.
- [6] Wang P, William B H, Carol T. Users' interaction with World Wide Web resources: An exploratory study using a holistic approach. *Information Processing and Management*, 2000, 36(2): 229—251.

撰稿人: 曹三省 苏志武
中国传媒大学

面向未来媒体的人机工程理论与身心服务机制

Ergonomics and the Psycho-physical Service Mechanism for Future Media

1. 难题的来龙去脉及重要性

近年来, 各类新媒体系统在数字技术的推动下已经获得广泛应用, 媒体服务的有效性正在获得越来越广泛的关注, 如何建立符合用户身心需求的、有效的媒体服务体系, 已经成为信息科学技术领域内一项关键问题。

当前的人机交互理论与技术是以人对计算机和信息系统的操作请求处理为基础的, 用户在交互体系中处于相对主导地位。自1965年 Murrell 提出人机系统理论以来^[1], 人与信息系统间的关系就是以用户操作和系统响应为基础的。但是, 未来媒体服务的复杂性使得用户的交互主导难以成立, 因为在数字媒体的海量服务内容面前, 用户往往是无所适从的, 其所需要的服务内容有时难以准确描述(具体体现为: 一般用户即便在能够提供个性化服务的平台上, 也很难有效地利用搜索关键词等交互信息结构对自己的需求进行准确描述, 从而也很难访问自己真正需要的个性化服务内容), 而有时用户自身提出的服务需求对其身心也是不利的(如互联网的发展引起网络沉迷等社会问题, 即是这种用户直观需求与潜在身心效应不匹配的问题的具体体现)。因此, 智能化的未来媒体应当能够感知和处理用户的身心需求, 并能够在新型的、主动与被动有机融合的交互模态下, 基于对用户身心需求的感知和相应的智能决策, 为用户提供有利于其身心状态良性可持续发展的媒体服务。对这一问题的解决, 将涉及人机系统理论和服务科学理论的整体创新。

2. 难题解决现状

对支持以人为中心的服务有效性的新型人机系统理论的研究, 已经获得了长期以来的普遍关注。1983年, Anderson 提出了通过人类认知建模来支持智能人机交互的基本理论体系^[2]; Abowd 等进而提出了将人、系统与交互界面进行集中建模的人机交互统一模型理论^[3], 进而在近年来形成了人机一体化智能系统的理论体系^[4]; Wilson 将人机系统的服务有效性研究延伸到了以网络新媒体为基础的虚拟环境领域内, 引领了面向未来信息媒体环境的人机工程理论研究^[5]。

当前, 对媒体人机系统的研究在一定程度上集中于对媒体信息服务机制的

信息结构基础的建立,特别地,更多研究集中于对用户身心状态的感知。用户状态感知是智能信息科学中的一个关键领域。通过对用户的心理和生理状态进行有效地识别与分析处理,结合信息系统的智能决策功能,将能够为用户提供其真正需要的信息服务。

3. 难题的描述与说明

面向未来媒体的人机交互理论和身心服务机制问题可概括如下:针对以数字技术为基础的新型信息传播环境,须通过对生物特征识别、语义分析处理、沉浸媒体等理论与方法的交叉融合创新,确立以服务于人的身心状态的人机系统,克服传统人机工程理论中的用户主导片面性等问题,进而建立媒体服务平台用户状态感知的理论框架,为未来信息社会环境下的媒体服务机制提供关键支撑。

4. 难题的主要困难所在

该难题的解决所面临的主要难点在于:①用户身心状态具有十分突出的动态性和不确定性,特别是对用户情绪状态的感知与同步目前尚需突破。②当前,生物特征识别和相应的信息处理方法与途径还不具备充分的可靠性,用户身心状态的有效感知将在一定程度上依赖于该领域的进一步突破与进展。③在用户身心状态感知的基础上,还需要进一步研究媒体服务系统中的智能决策机制,实现用户身心状态和服务内容的有效匹配。

参 考 文 献

- [1] Murrell H. Ergonomics; Man in His Working Environment. London: Chapman & Hall, 1965.
- [2] Anderson J R. The Architecture of Cognition. Cambridge: Harvard University Press, 1983.
- [3] Abowd G D, Beale R. Users, systems and interfaces: A unifying framework for interaction. Proc. HCI'91: People and Computers VI, 1991: 73—87.
- [4] 杨灿军, 陈鹰, 路甬祥. 人机一体化智能系统理论及应用研究探索. 机械工程学报, 2000, 36(6): 42—47.
- [5] Wilson J R. Virtual environments and ergonomics: Needs and opportunities. Ergonomics, 1997, 40(10): 1057—1077.

撰稿人: 曹三省 苏志武
中国传媒大学

水下高性能声呐

High-performance Sonar

声呐是英文“sonar”的译音,由 sound navigation 和 ranging 三个英文单词的字头构成,意思是声导航与测距^[1]。声呐大规模的出现与使用始于第二次世界大战,今天的声呐含义早已超出原来的内容。可以说,声呐是人们利用水下声波对水中的物体类型与物体存在的姿态和具体位置进行识别的设备和方法。随着科学技术的发展和人们海洋活动日益的频繁,使得声呐的含义更加广泛。不失一般性,凡是利用水下声波作为传播载体以达到某种目的的设备和方法都可称为声呐。人们习惯上更愿意把声呐作为具体的设备,所以产生了探测、识别、报警与警戒、通信、导航、制导、值班、水声对抗、计程与地形地貌测量等各种不同用途的专用声呐。

然而,海洋中无时无刻不存在着各种机理产生的各种声音,这种不利于声呐工作的声音就是噪声^[2]。海洋中大量存在的噪声使得声呐信号的信噪比降低,信号传播路径越远,工作频带越宽,信噪比降低的就越厉害。根据声呐方程的描述,信噪比的降低直接影响对目标的探测距离。同时,水下声波传输速度低($C=1500\text{m/s}$),声速梯度不稳定,声波波长长,传输过程中受水环境和水下信道影响大,特别是对于主动声呐,水下特有的混响信号常常使得信号产生严重的畸变。目前,主动声呐的声功率已达到了一个很高的水平,而且仍然难以探测到 50km 以外的目标,而更为复杂的被动声呐都存在严重的操作是否方便的问题^[3]。这些因素使得声呐的性能和对目标的探测能力尚未满足人们的要求^[4]。

因此,如何获得远距离和超远距离的宽频带微弱信号,且具有高分辨力的声呐设备,需要在水声信息科学的基础上综合物理学、海洋学、材料科学等多门科学知识,这是人类在国防建设和开发利用海洋资源等领域必须解决的问题。

参 考 文 献

- [1] 田坦,刘国枝,孙大军.声呐技术.哈尔滨:哈尔滨工程大学出版社,1999.
- [2] Ross D.水下噪声学.水下声原理翻译组译.北京:海洋出版社,1983.
- [3] Waite A D.实用声呐工程.王德石,等译.北京:电子工业出版社,2004.

[4] 伯迪克 W S.水声系统分析.方良嗣,阎福旺,等译.北京:海洋出版社,1992.

撰稿人: 杨德森

哈尔滨工程大学水声工程学院

水声通信

Underwater Acoustic Communication

水声通信技术在传统上多用于军事领域,用来解决诸如水雷遥控、潜艇之间、母船与潜艇或其他水下作战平台之间传输战场信息的问题。随着人类资源考察和开发的脚步从陆上延伸到海洋,水声通信技术也越来越多地被应用到海洋环境考察、资源开发等民用领域,利用水声信道和水声通信系统传送各种信息的需求大为增加,如遥测数据、水下机器人和海上石油平台的遥控指令、水下无缆电话、海底勘探数据、水下电视图像、环境系统中的污染监测数据、水文站的采集数据等,这使得人们对水声通信系统性能的要求凸现。

由于传输信息量的要求,高速率水声数据传输成为水下通信技术的前沿热点研究课题之一^[1,2],而浅海高速水声通信则被认为更是困难重重,其面临最困难的问题就是多途干扰和由于海洋表面反射、内波等引起的快速时变。多途引起接收信号的幅度衰落、互多途引起接收信号的码间干扰,加上海洋环境的高噪声背景、低载波频率、极为有限的带宽及传输条件的时间-空间-频率变化特性,使水声信道,特别是浅海水声信道成为迄今为止最困难的无线通信信道^[2]。

20世纪90年代至今,带宽利用率较高的相位相干通信系统日趋成熟,这就使得相移键控调制方式逐渐占据高速水声通信的主导地位。由于采用相位相干单载波通信及其相关的自适应均衡等方式,水声通信系统的通信距离与通信速率的乘积从 $0.5\text{km} \cdot \text{Kbit}$ 提高到浅海 $40\text{km} \cdot \text{Kbit}$ ^[3]。随着通信速率的提高,符号持续时间变短,码间干扰可持续几十甚至上百个符号,导致均衡器采用更多的抽头,尽管开展了均衡器简化的研究工作,如稀疏均衡等^[4,5],但其高复杂度仍然是提高速率的主要障碍^[6]。

多载波通信将可用的频带分割为一系列的子载波,从而增加了码元的持续时间,并且可以用简单的频域均衡来代替复杂的时域均衡器,为实现实时高速水声通信提供了一种可行的选择。OFDM技术是目前多载波水声通信的研究热点。由于各个子载波间是正交的,因此,OFDM技术没有子载波间干扰。所以,与传统的调制方式相比,OFDM技术具有极高的频带利用效率。水声通信的带宽比无线电通信要小得多,因此,频带资源显得更加珍贵。从2005年开始,欧美的多个科研院所开展了大规模的基于OFDM的水声通信技术研究。

OFDM技术在水声通信中需要进一步研究的问题有:抗多普勒技术;如何将迭代译码和信道估计与补偿进行统一处理以进一步提高其性能;各种复杂的信道

编码技术如何通过修改后更好地适应水声信道；如何利用浅海信道的稀疏特性提高系统的性能；如何在多途时延扩展超长的水声信道中应用 OFDM 等。

水声通信网的研究除了包含所有点对点通信的难点之外，还包括以下难点^[7,8]：①有限的电池供电。水下节点设备利用电池供电，而且电池通常不能再充电。②水下声信道的传输延时长而且多变(声波的传播速率仅为 1500m/s)，这不仅降低了网络传输效率，并可能引起“后申请、先到达”的问题。③由于侵蚀、腐烂等原因，水声传感器容易失效。④多节点发射信号的串扰问题等。

围绕这些问题，目前各国学者的研究热点主要有：①路由协议。网络层协议的一部分，负责确定所收到的分组应转发的链路。水声信道具有与无线电信道不同的约束条件，根据水声信道的特点，设计水声通信网络的路由协议已成为水声网络设计的关键。②信道接入协议。水声信道是一个十分复杂的多径传输的信道。③环境噪声高，带宽窄，可适用的载波频率低，传输的时延大而且多变，使得研究有效的信道接入协议克服这些不利因素显得非常必要。④能量消耗。除研究开发新型电池能源之外，研究如何减少设备的耗电量，提高电池的使用时间，是网络设计中的另一个研究热点。

参 考 文 献

- [1] Stojanovic M .Recent advances in high-speed underwater acoustic communication .IEEE J. Oceanic .Eng .,1996 ,21(2):125—136 .
- [2] Stojanovic M ,Presig J .Underwater acoustic communication channels :Propagation models and statistical characterization .IEEE Communications Magazine ,2009 ;84—89 .
- [3] Kilfoyle D B ,Baggeroer A B .The state of the art in underwater acoustic telemetry .Oceanic .Eng .,2000 ,25(1) :4—27 .
- [4] Aycla G ,Coudeville J M .TIVA :A long range ,high baud rate image/data acoustic transmission system fro underwater applications //Proc .Underwater Defence Technol .Conf .,Paris ,1991 .
- [5] Stojanovic M .Efficient processing of acoustic signals for high rate information transmission over sparse underwater channels .Elsevier Journal on Physical Communication ,2008 ;146—161 .
- [6] Li B ,Zhou S ,Stojanovic M ,et al .Pilot-tone based ZP-OFDM demodulation for an underwater acoustic channel .OCEANS 2006 ,2006 :1—5 .
- [7] 徐小卡 .基于 OFDM 的浅海高速水声通信关键技术研究[博士学位论文].哈尔滨 :哈尔滨工程大学 ,2009 .
- [8] 孙桂枝 .水声通信网络路由协议研究[博士学位论文].哈尔滨 :哈尔滨工程大学 ,2006 .

撰稿人：卞红雨 杨德森
哈尔滨工程大学水声工程学院

处理器芯片的性能极限是多少？

What is the Performance Limit of a CPU Chip?

从 1971 年第一颗微处理器 Intel 4004 问世以来^[1]，40 年间，处理器芯片集成的晶体管数目从 2300 个发展到今天的数十亿个，处理器频率从不到 1MHz 发展到今天最高接近 5GHz^[2]，处理器的性能提高了数十万倍，如图 1 所示。我们不禁要问，微处理器芯片的性能还会持续增长下去吗？




图 1 处理器芯片性能增长示意图

一直以来，微处理器性能的提升主要受到应用需求和半导体集成电路技术这两个因素的影响。人们对计算速度永无止境的需求是微处理器性能不断增长的牵引力，而半导体集成电路技术的进步则是微处理器性能不断增长的技术支撑。

在过去的几十年中，半导体集成电路技术的发展一直符合经验规律——摩尔定律，即随着半导体工艺尺寸的不断缩小，微处理器芯片单位面积可集成的晶体管数目约每 18 个月翻一番。在过去很长时间里，当芯片内集成的晶体管数量每增加一倍，芯片性能也增加约一倍，处理器性能的增长趋势也符合摩尔定律。因而，摩尔定律也常被用于指代处理器性能的增长趋势。进入超深亚微米半导体工艺后，摩尔定律有所放缓，但晶体管资源还将持续增加。根据 ITRS 组织 2009 年度报告^[3]的预测，随着半导体工艺尺寸的缩小，处理器芯片单位面积可集成的晶体管数目在 2024 年前仍呈每 2~3 年翻一番的增长趋势。

有关处理器性能的科学问题是：处理器芯片的性能极限是多少？即如果摩尔定律持续有效，处理器芯片内单位面积可集成的晶体管数目越来越多，如何

将这些增加的晶体管资源转换为处理器性能的提升？芯片上晶体管尺寸不可能无限制地缩小下去，这就意味着，总有一天芯片单位面积上可集成的元件数量会达到极限，那么，摩尔定律将在什么时候失效？在其失效后，处理器芯片将如何提升性能？

2004 年以前，工业界主要采用提高处理器时钟频率和越来越激进的超标量技术持续地提高处理器的性能，其优点在于利用硬件自动挖掘串行程序中的指令级并行性。随着处理器性能的提高，应用程序在不被更改的情况下依然能够得到加速，因而在市场上获得了极大的成功。然而，超标量处理器的设计方法导致处理器性能功耗比和晶体管效率越来越差，直至不可接受，这势必促成处理器体系结构设计思路的转变。

为了在芯片功耗的约束下利用增加的晶体管资源来提高处理器性能，芯片架构设计师们改变设计思路，采用性能功耗比和性能面积比更高的挖掘线程级并行性和数据级并行性的方法来提高处理器性能。由于挖掘线程级并行性更具通用性，促成了处理器架构从单核到多核的转变。多核处理器在处理器核数较少的时候继续延续了摩尔定律带来的性能的好处。但是，以超标量处理器核为基本单元的多核处理器对芯片的性能功耗比和晶体管效率的改善依然有限，功耗依然是芯片未来发展的障碍^[4]。理论上更好的一种方式是采用简单处理器核替代超标量处理器核来构成片上大规模并行处理结构。但是，简单处理器核牺牲了单线程性能，Amdahl 定律指出，并程序的加速比最终取决于程序中没有并行化的串行执行部分。因此，少量复杂处理器核加上大量简单处理器核的异构化众核结构将是未来的发展趋势^[5]。

在并行处理器结构时代，处理器芯片单位面积可集成的晶体管数目的增长带动了处理器核数目的增长，从而带动了运算速度的增长。然而，这种方法并不是万能的，它至少面临三项巨大的科学技术挑战：首先，处理器的运算速度虽然增长，但向处理器核供应数据的能力由于受到数据传输带宽和延迟等问题的制约却没有相匹配地增长，甚至会恶化，高速信号总线和纳米光互连等技术的进步将有助于缓解数据传输带宽的问题，数据传输延迟需要程序算法和软硬件系统协同设计进行延迟避免或者延迟容忍；其次，并行编程一直是使用并行系统的难点，并行时代的软件生产率和质量将会是一个严重的问题，很多研究人员认为除了编程方法的进步外，还需要从计算机初期教育着手解决编程困难问题；最后，如何保证由数十亿甚至上百亿个元器件组成的处理器的正确性，这依赖于集成电路验证、测试、诊断和容错技术的进步。

摩尔定律得以延续主要依赖于集成电路特征尺寸的缩小。从经济的角度看，特征尺寸越小意味着生产工艺越精细，生产线越昂贵。45nm 芯片加工厂的投资额约为 35 亿美元，当特征尺寸缩小到 10nm 时，投资额将猛增至 100 亿美元左右。高昂的费用需要越来越庞大的市场来分摊开销，这将使得越来越多的厂商

退出了芯片制造行业。因此,未来10年中,集成电路特征尺寸可能会由于非技术原因延缓缩小,晶体管集成密度会发生缓慢变化。然而,人们仍然可以利用日渐成熟的三维堆叠技术突破传统的二维平面制造工艺,在三维空间上堆积更多的晶体管,来延续摩尔定律^[6]。

根据 ITRS 组织预测,到2022年,硅工艺集成电路的特征尺寸将达到10nm^[3],这与硅中电子的相干长度接近,建立在玻耳兹曼方程和统计力学基础之上的微电子理论将不再适用。为了迎接纳米尺度带来的挑战,近年来,基于量子力学效应的纳米半导体技术成为国际研究热点。2009年,英特尔公司十分自信地宣布将在2022年左右实现4nm的制造工艺。由此看来,量子力学效应也许并不会带来摩尔定律的终结,用晶体管数量增长换取处理器性能提升的方法还可持续一段时间。

碳化硅和石墨烯等新型半导体材料是现行硅基半导体材料的绝佳替代品,能在高温、高频、大功率场合下应用。IBM 的研究人员使用与现行的硅器件制造技术相兼容的加工技术制成的石墨烯晶体管截止频率达到了100GHz^[7]。未来这些新技术的成熟势必掀起新一轮的处理器体系结构的革命。

摩尔定律不仅仅是一个关于半导体集成电路技术和处理器性能的经验规律,还是一个人类用创造力和信念所坚守的规律。在微处理器发展的历史中,摩尔定律虽然多次出现停滞,但却一直得以延续,相信在未来,人类还会发明新的技术,让追求计算速度的脚步持续走下去。

参 考 文 献

- [1] http://en.wikipedia.org/wiki/Intel_4004.
- [2] <http://en.wikipedia.org/wiki/POWER6>.
- [3] Semiconductor Industry Association .International Technology Roadmap for Semiconductors .2009 .
- [4] Borkar S .Thousand core chips :A technology perspective .Proceedings of the 44th Annual Design Automation Conference ,2007 :746—749 .
- [5] Hill M D ,Marty M R .Amdahl's law in the multicore era .IEEE Computers ,2008 ,41 (7) :33—38 .
- [6] Xie Y ,Cong J ,Sapatnekar S .Three-Dimensional Integrated Circuit Design :EDA ,Design and Microarchitectures .New York :Springer ,2010 .
- [7] Lin Y M ,Dimitrakopoulos C ,et al .100GHz transistors from wafer-scale epitaxial graphene .Science ,2010 ,327 :662 .

撰稿人:范东睿

中国科学院计算技术研究所

超大规模并行编程

Very Large Scale Parallel Programming

科学计算、工程仿真、数据处理等应用都需要更快的计算机系统，近三十年间，全球最快的计算机的性能以每 10 年大致 1000 倍的速度增长。由于功耗与散热的制约，集成电路工艺的发展虽然能继续在硅片上集成更多的晶体管，但已难以进一步提高处理器主频，因此，提高单处理器核的性能已经遇到瓶颈。目前，提高计算机系统性能的主要途径是并行计算。预计在 2018~2020 年间出现的 Exascale 计算机(每秒百万万亿次浮点运算)将达到 10 万~100 万处理器核的并行度。从图 1 可以看出过去 12 年计算机系统的性能与并行度之间的关系。




图 1 历年 top1 高性能计算机性能与处理器数目变化图

因此，未来长期存在的科学问题是：如何在这样的超大规模并行系统上进行有效地编程？即针对具有不同负载特征的应用问题，采用什么样的计算模型、并行算法、并行编程方法、并行语言，能有效地将应用映射到这样超大规模的并行计算系统上；在体系结构趋向于异构、存储层次加深、存储结构暴露的情况下，如何有效地在程序员、编程语言、编程环境和运行时系统之间进行功能划分，以充分发挥出计算系统的效率。

近年来，许多团队都在研究上述问题，如 Patterson 教授领导的团队在他们发布的关于并行计算的著名报告 Berkeley view 中就相关问题进行了较为全面的阐述^[1]；Princeton 大学的 August 领导的 Liberty 研究组探讨了程序员、编译系

统、运行时保证机制等如何多方协作对程序进行深度的并行优化^[2]。2009 年初启动的国际合作计划 International Exascale Software Project (IESP)也是面向这个科学问题,力图找到能在 2018~2020 年有效利用 Exascale 级平台的计算能力的编程方法^[3]。

从国际上目前的研究进展来看,以下几个重要的研究问题可能取得突破:

(1) 新计算模型的研究。计算模型是编程模型的基础,传统的 CSP (communicating sequential processes) 计算模型具有高可扩展性,但没有考虑通信延迟等问题,已经不能适用于由多核、众核处理器形成的超大规模并行计算系统,需要对现有计算模型进行扩展,或者提出新的计算模型,以支持 Exascale 级的计算。

(2) 高维并行算法的研究。超大规模并行计算系统是一个多层次的并行系统,而很多应用本身也体现出了层次并行的特征,高维并行算法的研究就成为一个重要的研究课题。此外,为了使算法获得更好的可扩展性,需要从并行度、延迟和负载平衡等多个因素研究如何提高算法的可扩展性。美国伊利诺伊大学香槟分校的并行编程实验室关于这个问题进行了多方面的探讨^[4]。

(3) 新的并行编程方法。并行程序设计方法需要考虑并行性描述与识别、数据局部性描述及负载均衡等问题。并行编程模型的基本问题是:哪些信息应由并行程序开发者提供?哪些应由编译器自动发现?哪些应由操作系统和运行时系统负责解决?新的并行编程方法需要在传统的控制语义上扩展并行性模式、粒度的多样性,发掘出比以前多几个数量级的并行度;还需要对分布的资源进行管理,尤其是局部性的管理,在执行单元的有效利用和数据/计算的亲和性之间进行某种权衡,表达更复杂数据结构的分布;此外,由于存在很多关键应用,还需要找到对遗产代码的支持方法。另一种思路是开发面向领域的并行编程模型,如 Google 提出的面向数据中心的 Map-Reduce 并行编程模型^[5]。

(4) 新的并行编程语言。有了并行编程方法还需要用户易接受的并行编程语言来实现,并行编程语言经历了向量化语言、共享存储语言 (OpenMP, PGAS)、消息传递语言 (MPI) 三个阶段。针对高性能计算系统的应用实际性能差和可编程性差的问题,2002 年 4 月,美国 DARPA 提出的高生产率计算系统 (High Productivity Computing System) 研究计划,提出了 X10^[6]、Chapel^[7]等适合大规模并行的编程语言和相关的开发工具。这些新的并行编程语言在异步的全局地址空间特征、高层的并行抽象、多种并行性的支持等方面取得了进展,但由于过于庞大、开发周期长等原因,目前距离实用化还有比较远的距离。

(5) 在运行时系统方面也存在新的问题。由于处理器核的数量巨大,应用负载行为的动态性增加,如动态负载平衡、线程调度、存储资源分配等,需要运行时系统提供更多的性能优化手段,而基于动态图的应用,数据驱动的执行

模式也需要更多的运行时支持。新需求包括线程间同步、线程调度、存储层次的管理,实现高级的同步语义,利用复杂的消息机制,管理主动式的全局地址空间等。

如何在应用程序中发掘足够的并行度,并将应用程序有效地映射到超大规模并行计算系统上是一个巨大的挑战,也是计算机系统的性能持续提升必须攻克科学难题。

参 考 文 献

- [1] http://view.eecs.berkeley.edu/wiki/Main_Page.
- [2] <http://liberty.princeton.edu/>.
- [3] Dongarra J, Beckman P, Aerts P, et al. The international exascale software project: A call to cooperative action by the global high performance community. *International Journal of High Performance Computer Applications*, 2009, 23(4): 309—322.
- [4] <http://charm.cs.uiuc.edu/>.
- [5] Dean J, Ghemawat S. MapReduce: Simplified data processing on large clusters. *OSDI 2004*, 2004: 137—150.
- [6] Ebcioğlu K, Saraswat V, Sarkar V. X10: Programming for hierarchical parallelism and non-uniform data access. *OOPSLA 2004*, 2004.
- [7] Chamberlain B L, Callahan D, Zima H P. Parallel programmability and the chapel language. *International Journal of High Performance Computer Applications*, 2007, 21(3): 291—312.

撰稿人: 陈文光¹ 陈 莉² 冯晓兵²

1 清华大学计算机科学与技术系

2 中国科学院计算技术研究所

突破冯·诺依曼结构的挑战

Challenge to Break Through Von Neumann Architecture

Eckert 和 Mauchly 在研制人类历史上第一台电子计算机 ENIAC 时发现存储程序的必要性，1944 年，他们决定在要研制的下一台计算机 EDVAC 中采用“存储程序”的结构设计，即将程序与数据存放在同一个存储设备上。1945 年，冯·诺依曼在其报告 First draft of a report on the EDVAC 中将上述结构总结为“冯·诺依曼结构”^[1]。因此，冯·诺依曼结构与存储程序的概念基本上是等价的，指使用中央处理器进行计算，以及一个存储结构(即内存)存储指令与数据。

存储程序是冯·诺依曼结构的主要思想。此外，冯·诺依曼结构具有以下几个特点(如图 1 所示)^[2]：

- (1) 包含有 5 个部件，即运算逻辑单元、控制单元、内存、输入设备、输出设备。
- (2) 内存只存放有限位数的整数数字。
- (3) 程序也用数字编码，并与数据一起存放在内存中。
- (4) 顺序执行，一次执行一条指令。
- (5) 执行过程可能需要从内存和输入/输出设备传输少量数据。




图 1

一般而言，满足以上几个特点的计算机都被称为“冯·诺依曼计算机”。

半个多世纪以来，冯·诺依曼结构占据着计算机的主导地位。随着计算机的应用越来越广泛，计算机解决的问题规模越来越大，对计算机性能的要求也不断提高，冯·诺依曼结构反而成为制约计算机性能进一步发展的瓶颈，主要表现在以下几个方面：

(1) 程序执行是一维顺序的。程序指令线性存放在存储器中，通过指令计数器访问相应的地址。一个指令计数器对应一个程序执行指令流，由于指令计数器一般都是按顺序线性递增，程序执行过程也是一维顺序的，这限制了程序指令中所存在的并行性。数据流结构出现的动机正是希望通过突破这个限制来增加程序执行中的并行性。

(2) 存储器的地址是一维线性的，且不包含语义信息。首先，冯·诺依曼

结构中的存储器是由一维线性排列的存储单位组成,对其访问只能通过一维线性地址,而程序员使用的高级语言中的数据结构往往是多维的,这使得冯·诺依曼机中需要大量的地址运算将多维的数据结构地址转为一维的存储器地址。其次,冯·诺依曼结构存储器存放的只是有限位的整数数字,不包含对象物体、类型、关联等语义信息。但计算机的应用越来越广泛,已不仅仅是限于数字运算,计算机处理的对象包含丰富的信息,如文字、图像、音频等。因此,冯·诺依曼结构中,存储器中的数据与计算机处理的对象之间存在“语义鸿沟”。

(3) 数据传输通路是瓶颈。1977年,图灵奖得主 Backus 在其图灵奖演说中提到,处理器与内存分离,这导致两者之间的数据通路成为瓶颈,即所谓的“冯·诺依曼瓶颈”^[3]。由于处理器与内存发展速度的不一致,冯·诺依曼瓶颈最终造成了令计算机科学家最头疼的“内存墙问题”。事实上,冯·诺依曼瓶颈不仅仅存在于处理器与内存之间,还包括 I/O 与处理器、存储器之间。冯·诺依曼瓶颈已经成为制约计算机性能发展最主要的因素之一。

(4) 程序可被修改引起的安全问题。安全已经成为计算机领域的一个重要的问题,而这个问题也是由于冯·诺依曼结构引起的。冯·诺依曼结构中程序与数据一起存储,这导致程序可以像数据那样被任意修改,从而引起安全问题。

虽然冯·诺依曼结构存在诸多局限性,但同时也降低了计算机设计与实现的复杂度,从而推动计算机性能飞速发展。计算机发展历史上出现过一些非冯·诺依曼结构,都因为设计复杂、应用开发困难等多种因素而未能流行。20世纪80年代,日本曾雄心勃勃地提出研制面向人工智能的第五代机,目标是研制一台采用逻辑编程语言的大规模并行计算机,达到每秒能运行 100M~1G 次逻辑推理运算(logical inference per second, LIPS),而当时采用冯·诺依曼结构的工作站每秒只能做 100K 次逻辑推理运算。但是,日本的第五代机计划失败了,其主要原因是采用冯·诺依曼结构的计算机的性能发展非常快,很快就达到了日本第五代机的目标,导致日本研制的第五代机没有任何商业优势,最终仍然被冯·诺依曼机淘汰。

科学家一直在努力寻找突破冯·诺依曼结构的新计算机结构。一些改良性尝试包括:①程序存储用其他的格式表示,或者与数据分开存储,如哈佛结构;②采用并行结构,包括单指令流内的并行调度和多指令流。一些突破性的尝试包括:①采用不同的执行控制模式,如数据流、神经网络等;②内存存放的不仅仅是数字,而是包含类型等语义信息,如 LISP 机和 Prolog 机;③将处理器和存储器结合起来,如 processor in memory。

真正突破冯·诺依曼结构可能还需要革命性的技术,如量子计算、生物计算、分子计算、光计算等^[4]。量子计算机的基本单位是具有量子效应的量子位(qubit),每个量子位能同时表示“0”与“1”的叠加。与传统晶体管相比,量

子计算机的计算能力随规模呈指数级增长。生物计算机是利用 DNA 等生物分子上存储的控制生命过程的“程序”来进行计算，其特点是具有巨大的并行处理能力。分子计算机利用具有精密结构的有机高分子来作为核心器件，这种分子器件具有更多的逻辑状态和外联端口，可以模拟人脑神经元的工作原理。光学计算机用光子而不是电子来携带信息，除了可具有更快的计算和通信速度外，还可以利用特殊的光学特性(如相干、衍射等)实现高度的空间并行计算和存储。但是，这些技术目前还停留在实验室的阶段，真正实用化仍有待基本原理和技术取得重大进展。突破冯·诺依曼结构成了当今计算机系统结构研究者的最大的心结。

参 考 文 献

- [1] http://en.wikipedia.org/wiki/Von_Neumann_architecture.
- [2] Von Neumann J. First draft of a report on the EDVAC. IEEE Annals of the History of Computing Archive, 1993, 15(4): 27—75.
- [3] Backus J. Can programming be liberated from the von neumann style: A functional style and its algebra of programs. Communications of the ACM, 1978, 21(8): 613—641.
- [4] 李国杰. 世纪电脑. 北京: 科学技术文献出版社, 1999: 69—140.

撰稿人：包云岗 陈明宇 孙凝晖
中国科学院计算技术研究所

计算机的存储墙

The Memory Wall in Computers

在现有计算机的冯·诺依曼体系结构中，处理器是负责加工和运算数据的部件，存储器是负责存储数据的部件。在程序运行过程中，数据不断地在处理器和存储器之间传送。由于芯片引脚数目的限制和设计工艺的不同，存储器供应数据的速度比处理器处理数据的速度慢很多，处理器和存储器之间的速度差异使得处理器总是在等待要处理的数据，数据处理受到存储器性能的制约，难以发挥处理器的高性能，这就是计算机“存储墙”问题(memory wall)^[1]。图 1 显示了多个基准程序在一个带有二级缓存(16KB 的 L1 和 1MB 的 L2)的处理器上执行每条指令平均需要的时钟周期数^[2]。从图 1 可以发现，随着处理器时钟频率的增加，每条指令需要的时钟周期数却在增加，数据处理的效率并没有因为处理器性能的提升而得到相应程度的改善。




图 1 多个基准程序在不同时钟频率的处理器下执行每条指令需要的平均时钟周期数^[2]

自从半导体工业界分为微处理器和存储器两大阵营后，处理器和存储器的差距不断扩大(20 世纪 80 年代以来，处理器性能的年增长速度曾一度超过 50%，而存储器性能的年增长速度平均只有 7%^[3])。从图 2 可以看出近三十年来处理器和存储器性能差异的变化趋势，这种趋势必然会加剧它们之间的矛盾，存储器访问成为提高系统性能的最大障碍之一，“存储墙”问题日益突出。




图2 处理器和存储器的性能增长速度比较(以1980年的数据为基准)^[3]

解决存储墙问题的关键是改善和提高存储器的性能，缩短处理器和存储器之间的性能差距。实际上，存储器性能由两个因素所决定：存储器访问带宽和存储器访问延迟。

存储器访问带宽是指单位时间内传输的数据量，其大小涉及 I/O 速度、接入端口宽度及存储器可用的接入端口数量等因素。由于芯片引脚数量的限制及在高时钟频率运行宽并行总线的内在复杂性，传统的提高存储器时钟频率或者增加芯片引脚数目等方法已经接近其物理极限。近年来，研究人员提出了光互连技术，通过在存储控制器和存储模块间形成一个光学通道，能提供比传统的电线通路高得多的带宽。而三维封装技术在二维技术的基础上实现了芯片的高密度组装，从而大大改善了存储器的性能。

存储器访问延迟是指访问存储器中数据需要的时钟周期数。减少存储器访问延迟的常见方法是采用多级存储层次结构和延迟隐藏技术。对存储系统增加多级缓存，这样，小的、高速的存储设备能以低延迟服务于处理器。高速缓存也利用程序的局部性原理来减少上下文转换次数，从而能大幅度缩短对存储器的平均访问延迟。编译优化技术通过程序变换的软件方法提高程序的局部性，也是缓解存储墙问题的有效手段。

延迟隐藏技术包括预取、正确的代码调度、多线程技术及同时多线程技术等。传统的预取技术使用探索法来识别访址模式并预测将来装入指令可能请求的内存地址，通过将数据从内存预取到缓存，减少缓存缺失的次数。软件流水是一种重要的指令调度技术，它通过重叠地执行不同的循环体并结合一些存储优化技术来实现隐藏存储延迟。多线程技术则利用其并行性来隐藏长的缓存缺失延迟。而同时多线程技术综合硬件多线程技术和超标量处理器技术来支持多个独立线程的并发执行，从而更好地利用现代处理器体系结构提供的资源。

数据压缩是一种通过软件方式来间接地增加有效存储带宽同时减少数据访问延迟的方法。压缩后的数据不仅占用更少的存储空间,而且其传输也只需花费更少的时钟周期数。数据压缩技术可以增加片上缓存容量,减少片外存储访问的次数;也可以增加有效的片外存储带宽,加速数据在片外多级存储层次之间的传输;还可以增加有效的内存容量,减少对磁盘的访问。虽然压缩技术会额外增加一些压缩、解压等开销,但当前计算资源相对便宜的技术趋势会使得压缩将吸引更多研究人员的关注。

尽管上述这些技术能够对减少平均访存时间有所帮助,但仍然不能从根本上解决存储墙问题。存储墙问题仍然是影响处理器性能发挥的瓶颈问题之一,也制约着处理器性能的进一步提升^[4]。集成电路技术的进步促进了处理器微体系结构的发展,单芯片多处理器(chip multi-core processors, CMP)已成为新一代微处理器结构的主流。但是,由于受芯片尺寸大小、片上缓存和引脚数目的限制,芯片上核数目的增多将减少每个核可使用的缓存大小和总线带宽,从而加剧了存储墙问题。尽管研究人员已经提出三维封装、光互连及相变内存(phase change memory)^[5]等新型器件技术,在一定程度上可以缓解存储墙问题,但由于存储墙问题既与现有计算机的冯·诺依曼体系结构密切相关,同时也与处理器和存储器的制造工艺密切相关,到目前为止,存储墙问题依然没有解决,它仍然是计算机系统结构领域的关键科学难题。

参 考 文 献

- [1] Wulf W A, McKee S A. Hitting the memory wall: Implications of the obvious. SIGARCH Comput. Archit. News, 1995, 23(1): 20—24.
- [2] Jacob P, Zia A, Erdogan O, et al. Mitigating memory wall effects in high-clock-rate and multicore CMOS 3D processor memory stacks. Proceedings of the IEEE, 2009, 97(1): 108—122.
- [3] Hennessy J L, Patterson D A. Computer Architecture: A Quantitative Approach. 4th ed. San Francisco: Morgan Kaufmann Publishers, 2007.
- [4] <http://download.intel.com/technology/computing/archinnov/platform2015/download/RMS.pdf>.
- [5] Zhou P, Zhao B, Yang J, et al. A durable and energy efficient main memory using phase change memory technology. Proc. of the 36th Annual International Symposium on Computer Architecture (ISCA 09), 2009.

撰稿人: 吴 松

华中科技大学计算机科学与技术学院

大规模分布式计算系统的建模

Modeling of Large-scale Distributed Computing System

大规模分布式计算系统^[1]一直是学术界研究与工业界实践紧密结合的典范领域。按照荷兰阿姆斯特丹 Vrije 大学著名学者 Tanenbaum 教授的定义：“分布式系统是这样的系统，它运行在不具有共享内存的多台机器上，但在用户的眼里却像是一台计算机。”具体的，分布式计算系统是指通过计算机网络，由地理分布的若干个独立自治的计算单元相互连接而成大型计算环境，通过交互与同步实现一个共同的任务目标。为了保证所构建的分布式计算系统具有较好的服务质量、资源利用效率及扩展性，人们往往需要首先构造一个模拟系统，以评估所设计的关键机制与算法的表现。在分布式计算系统所管理的节点数量较少、所服务的用户规模不大时，建模工作可以较为顺利的开展。但是，很不幸，分布式计算系统的规模日益增大。例如，全球著名的 Facebook 建立了由分布在互联网上的 10000 余台计算机组成的大规模分布式系统，以此支撑为超过数以亿计的大规模用户构建起了社会交往新途径；Google 通过分布在全球多个超大型数据中心的数十万台服务器建立了大规模的分布式系统，以此为基础构建起了高效、快速的网络查询、信息服务等大规模互联网服务。因此，随着这些分布式系统所管理的计算节点规模从数十个扩展到数千、数万乃至数十万个，用户规模迈向百万、千万级别，这就为其建模带来了前所未有的困难。全系统组织结构的动态变化影响测量准确性，庞大的资源规模与服务规模影响了测量数据的完整性，异构性与管理非集中性增加了测量的难度，这就是“大规模分布式计算系统的建模”难题。

对分布式计算系统的建模并不是一个新问题。伴随着分布式计算系统的出现，建模被引入研究人员视野，是为了判断分布式计算系统中较为复杂的功能、算法是否会正常执行。但是，随着规模不断增大，分布式计算系统还面临着更为复杂的新问题^[2]。如何更加有效地组织分布式环境中的大规模节点；如何在动态、自主的模式下保证服务的稳定性；如何动态规划分布式环境中数据自主、高效的传输机制；如何为不同角色的实体设计高效的通信协议等。总体上，都需要回答如下问题：如何能够保证通过大量能力异构、地理分布的计算节点构建起的分布式计算系统具有正确、可靠、稳定、高效的服务能力？这些难题都需要对由大规模节点组成的分布式系统的创建、演化的规律取得足够深入的认识。因此，如何对大规模分布式系统进行建模，以期表达接近真实环境的节点、

数据及网络路径间的复杂关系具有重要意义。建模分析逐渐成为分布式计算系统性能优化的重要手段。

作为分布式计算系统建模的最重要一环,如何描述并认识分布式系统中的节点及节点间的相互关系,即网络拓扑结构的属性、规则及演化趋势,是最核心、最重要的挑战,也是一个传统经典的科学难题。分布式计算系统的网络拓扑与传统图论中的网络拓扑并无显著区别。最初,科学家们认为可用规则结构表示,如二维平面上的欧几里得格网或最近邻环网。到了 20 世纪 50 年代, Erdős 等^[3]建立了 ER 随机网络的基本模型:两个节点之间是否相连根据概率决定,它具有较小的聚集系数(表示节点在网络中的聚集程度)和平均距离;节点度(表示节点与其他节点的连接数)服从泊松分布。在很长的一段时间内,随机网络被很多科学家认为是描述真实分布式系统最适宜的网络模型。近年来,科学家们发现大量的分布式计算系统的节点网络既不是规则网络,也不是随机网络,而是具有与前两者皆不同的统计特征网络。1998 年, Watts 和 Strogatz 在 *Nature* 杂志上发表文章^[4],引入小世界网络模型,以描述从完全规则网络到完全随机网络的转变。小世界网络既有与规则网络类似的聚类特性,又具有与随机网络类似的较小的平均路径长度,表示一个大规模的复杂网络中任意两点的平均直径不超过 6 跳。紧接着,1999 年, Barabási 和 Albert 在 *Science* 上发表文章指出^[5],许多分布式计算系统的节点网络中连接度分布具有幂律形式,表示大量节点的度虽然很小,但具有这些特征的节点数目很大。六度空间原理(小世界模型的口语化)与长尾理论(幂律和 Pareto 分布特征的一个口语化表达)对大规模分布式计算系统的部分特性进行了深入刻画,如今被广泛应用于系统设计与优化之中。

但是,随着互联网的快速发展,大规模分布式计算系统表现出了许多新的特点:规模 and 用户数量不断动态增长,具有演化特性;系统中,资源节点与用户节点界限不断模糊,形成一个相互协作的整体。例如,近年来涌现出的基于对等计算模式(也称为 P2P 计算)的大规模在线流媒体服务系统,如 PPLive、PPStream 等,可同时为数以百万、千万的网络用户提供媒体服务。其中,每个节点既是资源提供者,也是服务获取者。这些新特征使得分布式计算系统的建模日益复杂,仅通过现有的小世界模型和幂律理论难以完全真实地刻画大规模分布式计算系统所具有的动态、演化、自治及融合特性。

对大规模分布式计算系统进行建模与分析,将面对多方面的挑战。首先,需要从理论上深入探索大规模分布式计算系统网络拓扑的数学描述模型,建立精确的理论框架;其次,需要探索从随机方法、确定性方法,到混合方法,从而模拟构造符合实际特征的多样性网络拓扑,以保证所模拟的网络拓扑的准确性;同时,随着大规模用户成为分布式计算系统中接受服务并影响服务提供性

能的重要角色。因此,需要引入社会学原理及其相关规则描述,将自主用户的行为分析引入进来,以加强模拟演化的真实性。解决上述问题将会极大推动分布式计算系统建模的准确性,为优化系统资源配置与设计提供重要依据。

总体上看,大规模分布式计算系统的建模所存在的上述重要挑战来源于两个难题:一方面,建模与分析需要以现有的分析与理解对未来的演化与发展做出预期和判断,存在较大的认识鸿沟难题;另一方面,以人为中心的服务具有极大的动态性和自主性,如何在建立稳定模型的同时,充分考虑人的活动及意愿的变化是一个难题^[6]。如能突破上述瓶颈,解决好其所面临的技术挑战,将对未来所需要部署的、应用于各个领域的大规模分布式计算系统提供基础性的支撑,为它们的设计、部署提供科学的、全面的理解与指导。

参 考 文 献

- [1] Mullender S J. Distributed Systems. New York: ACM Press, 1989.
- [2] 张宇, 张宏莉, 方滨兴. Internet 拓扑建模综述. 软件学报, 2004, 15(08): 1220—1226.
- [3] Erdős P, Renyi A. On random graphs. Publications Mathematicae, 1959, 6: 290—297.
- [4] Watts D J, Strogatz S H. Collective dynamics of “small-world” networks. Nature, 1998, 393: 440—442.
- [5] Barabási A L, Albert R. Emergence of scaling in random networks. Science, 1999, 286: 509—512.
- [6] Fujimoto R M, Perumalla K, Park A, et al. Large-scale network simulation—How big? How fast. Proceedings of the Symposium on Modeling, Analysis and Simulation of Computer Telecommunication Systems, 2003: 116—123.

撰稿人: 廖小飞

华中科技大学计算机科学与技术学院

海量信息存储

Mass Information Storage

1945 年, Bush 提出一种“扩展存储器(memory-extender)”设想, 以实现海量信息存储, 他将这种机器命名为 Memex, 就是“memory extender”这两个单词词首的组合, 意思是“记忆的延伸”^[1]。1999 年, 图灵奖获得者 Gray 在获奖演讲中提出 12 个研究目标, 其中, 第 6、7 个分别是 Personal Memex 和 World Memex, Personal Memex 记录一个人所看到和听到的一切并能够快速检索, World Memex 建立一个能够回答任意问题的系统^[2]。这些设想和目标的共同点是如何记录现实世界所发生的一切, 并在将来能够回溯。

实现海量信息存储的难度主要表现在量和质两方面。Gray 曾指出, 每 18 个月新增存储量等于有史以来存储量之和。数据的快速增长要求存储系统具有与之相匹配的容量, 而在短时间内能够快速找到想要的数据则要求系统具有很高的性能与很好的搜索模式。全球最大的社区网 Facebook 活跃用户数在 2009 年底已高达 3.5 亿, 超过美国的人口数, 仅这些用户的图片文件就有 300 亿左右; 网络社区 QZone 在 2009 年的活跃用户超过 2 亿, 2010 年 3 月同时在线人数达到 1 亿, 日上传照片超过 1 亿, 日点击量超过 100 亿, 这意味着每一秒钟就有不少于 12 万个文件请求; 2010 年 2 月, Twitter 每天处理的消息发布量达到 5000 万条; 2009 年初, 视频网站 Youtube 浏览人数达到 1 亿, 1 月份用户浏览了 148 亿个视频(平均长度 4 分钟), 年底增长到每天 10 亿个。2006 年, Google 的节点数量达到 45 万, 其搜索的网页、图片等内容的容量达到数十 PB, 每天提供数亿次的网页搜索服务。Google 正在开发 Google File System 2(GFS2), GFS2 将管理高达 $10^6 \sim 10^7$ 台机器, 10^{13} 个目录, 10^{18} 字节数据。面对当前如此丰富而庞大的存储需求, 存储技术往往需要通过某一方面的优化才能达到其中某一个指标。

海量信息的快速增长对数据存储系统提出的挑战主要表现在以下几个方面: ①复杂环境要求存储智能化。在开放存储环境下, 存储面临的用户需求存在开放、动态变化特征, 存储系统必须能够智能地适应不同用户需求。②存储系统的性能需求急剧提高。存储系统面临用户数量急剧增加, 同时在线访问存储系统的用户数可能达到上亿, 存储系统需提供更高的并行访问能力, 才能保证服务质量。③存储系统安全可靠性的新的挑战。存储设备的损坏比处理器和网络损坏带来的后果严重得多, 保证数据在有故障, 甚至发生灾难时也不丢失, 并

保证服务 7×24 的正常进行,就对数据的可用性和存取安全性提出了更高的要求。④大规模存储管理的挑战。由于存储容量的不断扩展,各式各样的存储设备和不断扩大的存储系统规模使得管理越来越复杂,以致管理成本超过软硬件的购买成本,这种现象已成为存储界一个令人头痛的问题。随着存储系统自身复杂性的不断提高,不同类型存储资源体现出越来越显著的差异性,应用无法根据资源的特性使用存储,存储也难以结合应用的需要发挥特长。⑤存储系统绿色节能需求。大规模存储系统的能耗问题是一个必须面对的问题,Google 在俄勒冈州的数据中心建在河边通过水力发电解决供电问题,因此,从节约成本及节能减碳需求看,必定要考虑减少能耗的方法,即在保障服务质量的前提下,构建低能耗存储系统提供服务。⑥数据长期保存的需求。数据长期保存不仅要求数据永不丢失,还要保证将来能够识别这些数据。

长期以来,人们对各种存储新技术和新方法进行了有效的探索和深入研究。一方面,从纸带到磁带、从磁盘到光盘到 CMOS、从铁磁体到硫化物到铁电薄膜乃至电子自旋极化^[3],甚至于细菌天然 DNA 和量子……在广泛的需求推动和基础学科的支持下,越来越多的材料和物理、化学原理被应用于创造新的存储介质,而新颖的技术也给存储带来了越来越丰富的特性,更为存储系统的构建带来了许多新的思路和可能性。另一方面,存储系统在体系结构方面发生了很大的变化,且不断延续,从最初的单盘和 RAID 的 DAS 结构^[4,5],发展到后来的 NAS、SAN、P2P 及网络化面向对象的存储结构及 IP SAN,网络化存储已经成为主流。海量数据的高速增长促进了大量数据中心的建设和数据密集型应用的发展,PB 级及以上规模的存储系统成为发展趋势,这些庞大的存储系统对存储 I/O 性能、可扩展性、高可用与可靠性、安全、能耗控制管理及综合效能等提出了巨大的挑战,推动着存储技术正以前所未有的速度迅速发展。早期的存储设备仅支持简单的点对点的连接方式,总线的出现显著地扩充了存储系统的扩展能力,而交换式的架构则进一步改善了性能,新的高速互连网络技术(如 InfiniBand 等)已逐渐成为高性能计算环境中搭建存储系统的可选网络互连方式。当前的存储系统已经从一个个“孤岛”变成四通八达的“都市”,设计、调度、管理的难度可想而知。

如何综合运用突破性的技术,探索和提出前瞻性的架构,将现有的存储资源有效组织起来以实现海量信息存储,并且满足多方面的用户需求,是一个具有重要科学意义的命题。

参 考 文 献

[1] Bush V. As we may think. The Atlantic Monthly, 1945; 101—108.

- [2] Gray J. What next? A dozen information-technology research goals. Jim Gray's Turing Lecture, 1999.
- [3] Kryder M. Data storage in 2000-Trends in data storage technologies. IEEE Trans. on Magnetics, 1989, 25(6).
- [4] Gibson G A. Tutorial on storage technology: RAID and beyond. ACM SIGMOD Record, 1995, 24(2): 471.
- [5] Patterson D A, Gibson G, Katz R H. A case for redundant arrays of inexpensive disks (RAID)//Proceedings of the 1988 ACM SIGMOD International Conference on Management of Data, Chicago, 1988: 109—116.

撰稿人：周 可
华中科技大学光电国家实验室

计算系统的能耗瓶颈

The Energy Bottleneck of Computing Systems

人们对计算性能的追求永无止境。从 1982 年到现在,处理器的性能提高了 3500 倍^[1]。便携式计算机和其最初的产品相比,运行速度提高了 5000 多倍^[2]。然而,计算系统性能的增长也伴随着功耗的急剧增长。1999 年,英特尔公司曾经指出,处理器的功耗密度接近核反应堆的功耗密度已经为期不远了^[3]。另一方面,随着计算设备的日益普及,大型数据中心的不断增多,计算系统能耗已达惊人的地步。据 Microsoft 的报告,美国大约 6000 个数据中心 2006 年的总耗电量高达 610 亿千瓦时,约 45 亿美元^[4]。

影响计算系统能耗的因素很多,主要包括计算系统硬件的功耗、性能、能量传输效率、冷却系统的效率、供电电源的效率、可靠性设计和软件算法的效率等。其中,硬件的功耗、性能和软件算法与完成计算任务直接相关,其引起的能耗称为直接能耗;而能量传输、冷却系统等其他因素所引起的能耗不直接完成计算任务,我们称之为间接能耗。

1. 直接能耗

直接能耗可以用下式进行描述:

$$E = P \times t \quad (1)$$

式中, E 表示系统能耗; P 表示系统功耗; t 表示运行一个任务所需的时间。同样的算法条件下,硬件性能越高,运行时间越短,反之亦然。现实是:随着性能的提升,硬件功耗急剧上升。如果功耗的增加速度超过了性能提升的速度(t 缩短的速度),则由式(1)可知,计算系统的能耗仍会增长。处理器的功耗分为两个部分:动态功耗和静态功耗。动态功耗主要有两个来源:电容充放电和短路电流。由电容充放电引起的功耗可用下式^[5]计算:

$$P_{\text{dynamic}} \sim aCV^2f \quad (2)$$

式中, V 表示供电电压; f 表示主频; C 表示电容容量; a 表示活动因子(状态变化的晶体管数占总晶体管数的比例)。从式(2)的分析可以看出,通过提升主频和增加单位面积晶体管数目来提高性能的方法都会增加硬件功耗。若同时使用上述两种方法,则功耗增加更快。短路电流引起的功耗只占总功耗的 10% ~ 15%,但目前尚无有效的办法降低这部分功耗^[5]。

静态功耗是由漏电流引起的功耗。晶体管就像一个水坝,无论多么结实,

总会有漏水现象发生。因此,电路即使不工作,也会消耗电能。根据摩尔定律,晶体管的工艺尺寸越来越小,目前已经达到 30nm 以下。工艺尺寸的减小使晶体管中的氧化绝缘层变薄,导致晶体管的漏电流呈平方增加。因此,处理器的静态功耗也在急剧上升。

目前,已有许多有关低功耗的研究,根据公式(2),人们可以有 4 种方法来降低系统功耗:降低电容容量、降低活动因子、降低主频和降低供电电压。降低电容容量和主频必然降低系统的性能,导致相同算法条件下完成任务的时间加长。所以,这两种方式不一定能降低系统的能耗,为降低电路的活动因子,人们发明了时钟门控技术(clock gating),它通过禁用处于空闲状态的功能单元的时钟信号来降低活动因子,从而减少功耗。目前,它是一种有效的降低功耗的方法。通过公式(2)可知,降低供电电压可使功耗按平方关系减小。但是,供电电压降低会引起门电路时延加大,需要同时降低主频才能保证计算系统正常工作。巧合的是,供电电压和主频同时降低(dynamic voltage scaling, DVS^[6])使系统功耗呈三次方降低。因此,DVS 技术得到了处理器厂商的使用。然而,DVS 技术和应用程序的特点有关,而且主频降低会降低机器性能。因此,它降低的能耗非常有限。

虽然时钟门控技术和 DVS 能在一定程度上降低功耗,但随着工艺尺寸的缩小,这些技术的作用越来越小。根据 ITRS 的报告,在纳米尺寸工艺下(即 100nm 以内),静态功耗越来越占主导地位。然而,降低数字电路的静态功耗十分困难,因为除了电路、体系结构、操作系统、编译器和应用程序设计以外,更重要的是要发明新的电子材料以革命性地降低漏电流功耗。目前,已有了旨在降低漏电流的新型电子材料研究,但还远未成熟。高 K 介质材料就是一个典型的例子,它虽然可以有效降低漏电流,却牺牲了晶体管的稳定性。

另外,处理器追求通用也严重影响了硬件功耗。为适应各种应用程序,芯片内的缓存部分所占的面积很大(晶体管数目众多)。因此,这部分功耗也很高。所以,把单个处理器核的频率降下来,根据不同领域的需求,把片内的缓存降下来是降低功耗的途径之一,但根据领域定制处理器的成本会很高。

2. 间接能耗

间接能耗虽然不直接参与计算,但它是必需的。然而,相当大部分的间接能耗被浪费了。因此,如何减少能量浪费是一个严峻的挑战。

首先,电力传输存在电能损失。Amazon 的杰出工程师 Hamilton 指出,电力从电厂传输到数据中心,8% 的电能被损失掉了。为避免这些损失,Google 和雅虎甚至将他们的数据中心建到了电厂附近^[7]。但是,广大的计算系统用户不可能都到电厂附近去使用计算系统,如何减少电力传输损失是一个重大挑战。

其次,冷却系统也成了瓶颈。目前,主流的冷却技术是风冷。然而,处理器功耗上升带来的热量增加正在超出风冷散热的极限^[8]。如果温度过高,不仅使系统工作不稳定,而且会使功耗急剧上升。人们已经开始寻求其他的冷却技术,如水冷、油冷等,但这些技术的成本和耗电量也很高。另一方面,由于缺乏精确的散热模型,计算系统中的冷却系统配置还远未优化,导致许多能量浪费。

第三,供电系统通常都存在低效的问题。目前,计算机电源的效率(输出功率/输入功率)平均只有 60%~70% 左右。所以,电源系统在工作的过程中平均至少浪费了 30%~40% 的能量。为减少供电电源的能耗损失,人们建立了 80plus 标准,敦促电源生产商生产高效率的计算机电源^[9],但挑战是高效率电源的生产成本很高。

最后,在芯片工艺尺寸越来越小、计算系统越来越复杂的情况下,可靠性成了一个关键问题。目前,为了保证系统的可靠性,通常采用的方法是硬件和软件冗余,但由于这些方法增加了系统的晶体管数量和延长了运行时间,从而导致了系统能耗的增加。如何既增加系统的可靠性,又不增加能耗,是一个极具挑战性的问题。

计算系统的能耗瓶颈已经引起了世界各国的重视,成为电路设计和计算机系统结构领域非常活跃的研究方向,但解决该问题不应只有计算机领域的努力,它还涉及众多的学科领域,如电子、机械、材料等,其研究会持续 10~15 年甚至更长的时间。

参 考 文 献

- [1] 郭贺铨.信息技术面向 2010 年代的发展.中国计算机学会通讯,2010,6(1):17—24.
- [2] Garrett M.Powering down.Communications of the ACM,2008,51(9):43—46.
- [3] Pollack F.New microarchitecture challenges in the coming generations of CMOS process technologies.Keynote of International Symposium on Micro-Architecture,1999.
- [4] Kurp P.Green computing-Are you ready for a personal energy meter? Communications of the ACM,2008,51(10):11—13.
- [5] Venkatachalam V,Franz M.Power reduction techniques for microprocessor systems.ACM Computing Surveys,2005,37(3):195—237.
- [6] Wang W,Mishra P.Leakage-aware energy minimization using dynamic voltage scaling and cache reconfiguration in real-time systems.Proceedings of 23rd International Conference on VLSI Design,2010:357—362.
- [7] Hamilton J.Where does the power go in high-scale data centers.Proceedings of SIGMET-RICS2009,2009.

- [8] Huang W ,Stan M ,Gurunurthi S ,et al .Interaction of scaling trends in processor architecture and cooling .Proceedings of the 26th Semi-Therm Symposium ,2010 .
- [9] <http://www.80plus.org> .

撰稿人：喻之斌

华中科技大学计算机科学与技术学院

未来网络交换机理

Future Internet Switching Mechanism

我们知道,已存在的网络交换主要有电路交换和分组交换模式。电路交换在收发两端之间建立了一条固定的信息通路,在通信过程中,不论是否发送信息,该通路均被该呼叫所独占。分组交换不对呼叫分配固定通路,而是将信息划分成数据包的形式按存储-转发方式进行传输,不同呼叫复用信息通路,从而提高了网络传输的效率。互联网是把计算机与计算机互连起来,这首先需要建立全局的地址体系,解决网络中机器的全局唯一的地址标识问题。在网络交换模式方面,目前,互联网采用的IP协议是一种分组交换,其网络层使用的地址标识符称为IP地址。传统的IPv4协议版本中使用32位的二进制地址,理论上共有 2^{32} 个地址,即大约43亿个地址。但是,随着越来越多的计算机接入互联网,IPv4定义的有限地址空间将被耗尽。因此,通过IPv6重新定义来扩大地址空间。IPv6采用128位地址长度,理论上共有 2^{128} 个地址,即大约 3.4×10^{38} 个。也就是说,IPv6在每平方米地球表面上提供的地址数多达 6.67×10^{23} 个,形象地说,可以给每个沙子分配一个独立的IP地址。除解决了地址短缺问题以外,IPv6还考虑了在IPv4中解决不好的端到端IP连接、安全性、多播、移动性等问题,但这是以更复杂的IP协议为代价来实现的。

物联网是目前的研究热点,其基本出发点是将机机互连扩展到物物互连。既然IPv6具备了充分的地址空间,实现物联网是否就不存在问题了?实际上,相较于互联网,物联网面临的物物互连更加广泛,更为复杂,要求更高。传统IP协议对网络传输存在着较多基本假设^[1,2],如网络节点标识符与定位符绑定、收发节点间必须存在持续的端到端的路由等,而物联网整合了各种设备化的普通物理对象和计算机(均简称网元),这些海量网元呈现显著的异质性,表现在计算能力强弱差异、行为特性动静不同、互连协议多种、连接状态多样等方面。传统的、基于绑定的、连接状态稳定的、强状态的“存储-转发”模式的IP路由方法在很多情形不再有效,传统的IP编址模型和寻址体系也难以适应动态的网络环境。所以,针对这些被称之为“挑战网络”的新的网络形态^[2],近年来,国际上开始探索新的网络数据交换机理、网络路由和传输方法,如DTN路由^[3]、机会路由、弱状态路由^[4]、基于位置的路由、基于事件的路由等,也在同时研究支持地址裂变、地址聚合、地址休眠的新型动态编址模型及主机标识和定位符分离的编址寻址架构,为区分它们与IP技术的差别,统称为非IP技

术。在未来网络中,将运行的是融合 IP 和非 IP 的协议,我们将其支撑技术称为后 IP 技术。

在未来网络中,为了突破 TCP/IP 的局限性,实现机机之间、物物之间、机物之间的泛在连接,我们必须解决两个关键科学问题:一是非 IP 数据交换机理,二是非 IP 与 IP 的融合机理。这两个科学问题的解决对后 IP 技术的形成十分关键。

所谓非 IP 数据交换机理,就是不同于 IP 的数据交换方法。传统的互联网协议对连网设备要求较高,计算和通信能力强、依赖的环境稳定、设备之间常连接强状态路由;在未来的物联网中,除了这些能力较强的设备以外,还需要连接很多能力较弱的网元(各种无线传感节点、RFID),常是多跳自组织,易受恶劣环境影响,时断时续,呈统计性弱状态连接,其数据交换不能直接沿用互联网协议实现。因此,我们需要研究新的非 IP 数据交换机理。

未来网络应该是继承现有 IP 交换并兼容非 IP 交换的网络,关于非 IP 与 IP 的融合机理,我们必须回答的一些基本问题是:网络节点标识符与定位符分离后如何建立它们的映射机理?如何设计屏蔽网元能力差异的寻址架构?如何建立适应不同网络环境的通用的标准后 IP 路由选择协议体系?如何针对当今信息社会对 IP 网络的依赖性实现从 IP 网络到后 IP 网络的平滑过渡?解决这些问题必须超越传统的 IP 网络的局限性,创建新的网络互连模式。

IP 网络具有网络设备计算和能力强、位置与地址绑定、节点之间连接状态稳定等约束条件,目前,很多新型的网络,如无线传感器网络、移动车载网络、体载网络、星际网络、战术通信网、水下传感网络等,它们作为未来物联网中的重要组成部分,呈现非 IP 网络的特点:在路径和链路上具有高延迟、低数据率,可能不存在稳定的端到端的连接,节点移动性强,节点系统资源有限、寿命有限, TCP/IP 性能恶化,传统路由协议无法正常运行^[5]。目前,有一些工作围绕解决上述问题展开,提出了一些新型的网络数据转移模式,例如,容迟网络概念是解决这类问题的一种尝试,其主要目标是支持具有间歇性连通、延迟大、错误率高等通信特征的网络互连,利用“存储-携带-转发”模式取代 IP 的“存储-转发”模式。已经提出的主要路由方式包括基础设施辅助路由、机会路由、基于先验知识的路由、基于模型的路由、基于编码的路由等。这些理想模型与系统协议设计之间存在差距、路由的随机性造成了协议性能评价的困难、缺乏确定性和大规模应用的困难。本质上说,目前我们对这些新的网络的模型和规律缺乏透彻的认识,从而为正确地建立相关的理论和技术体系找到合理的理论依据。

未来网络数据交换机理对未来网络体系架构、信息处理、服务提供等将产生重要影响,是下一代网络面临的基本问题,也是实现物联网的基础。目前,

还没有研究出一套从根本上解决这个难题的方法。如何发明出一种对未来网络实用有效的交换机理是一个考验人类智慧的命题。

参 考 文 献

- [1] Bush R M D .Some internet architectural guidelines and philosophy .IETF RFC3429 ,2002 .
- [2] Fall K .A message-switched architecture for challenged Internets .Berkeley ;Intel Research ,2002 .
- [3] Fall K .A delay-tolerant network architecture for challenged Internets .Proc .of the ACM SIGCOMM2003 ,2003 ;27—34 .
- [4] Acer U G ,Kalyanaraman S ,Abouzeid A .Weak state routing for large scale dynamic networks .Proc .of the ACM MobiCom07 ,2007 ;290—301 .
- [5] Farrell S ,Cahill V ,et al .When TCP breaks delay-and disruption-tolerant networking .Internet Computing ,2006 ,10(4) ;72—78 .

撰稿人：马华东
北京邮电大学计算机学院

网络的自适应性

Self-adaptation in Network

现有的互联网网络体系结构和协议形成于 20 世纪 70 年代。网络建设最初主要用于军事目的,强调连通性和可靠性,它主要是基于这样的指导思想:网络必须经受得住故障的考验而维持正常的工作,一旦发生战争,当网络的某一部分因遭受攻击而失去工作能力时,网络的其他部分应能维持正常的通信工作。

20 世纪 90 年代,互联网迈入商业化时代,在通信、信息检索等领域发挥了重要作用。全世界的学术团体、公司企业及个人用户纷纷加入,互联网已成为一种基本的交流和通信工具。

进入 21 世纪,互联网进入第三个蓬勃发展时期,各种新型服务不断涌现,如大规模流媒体服务、即时通信服务和云计算服务等。与此同时,传输通信技术也呈现多样化,包括光纤通信技术、卫星通信技术和移动通信技术等。而互联网在其设计之初考虑的因素相对有限,在动态性、灵活性等方面存在诸多不足,无法对网络资源实现动态管理,从而无法对新出现的网络服务提供有效的支持。此外,较之早期的互联网,当前网络的网络规模要大很多,网络环境要复杂很多,而现有的网络体系结构无法有效地感知网络环境的变化并做出适应性的调整,因而也无法对上层的各种网络服务动态地提供优化支持。

目前,互联网的发展现状是体系结构和协议相对固定,而上层承载的网络服务和底层的传输通信技术却不断地发生变化,相对稳定的网络体系结构和协议越来越无法动态地适应新的网络服务和传输通信技术^[1,2]。如何化解两者之间的矛盾就是网络的自适应性技术要解决的问题。网络的自适应性技术的目标是:未来网络应满足用户的个性化服务需求并适应多种多样的信息传输技术,其必须根据网络用户、业务、底层通信技术等多重因素,自适应地实现网络资源的动态管理,自适应地改进网络体系结构和协议^[3],从而保证用户的网络服务质量。

美国 NSF 于 2005 年开始启动两大下一代互联网研究计划——“未来互联网设计(Future Internet Design, FIND)”和“全球网络创新环境(Global Environment for Network Innovations, GENI)”。在这两项重大计划中,网络的自适应性都是重要的研究内容。

FIND 计划的目的是设计一个全新的、满足未来 15 年社会需求的网络,侧重于未来互联网体系框架、设计原则和运行机制的研究,该项目最大的特点在

于对网络体系结构各个方面的研究和设计都尽量做到不受到以往研究思维的影响和束缚,即“clean slate process”,强调网络的体系结构需要动态适应环境的变化并实现自动调整。

GENI 计划的目标是构建一个全新的、安全的、能够连接所有设备的互联网。GENI 计划所设计的未来互联网的特征包括支持多种技术融合、普适计算及网络虚拟化,其所计划设计的未来互联网将具有以下特征:值得社会信任,激发科学和工程革命,支持新技术融合,支持普适计算,成为物理世界和虚拟世界的桥梁,以及支持革命性服务和应用。GENI 计划强调对服务和应用的强大支持,这就需要下层的网络体系结构及其协议具有很好的自适应性、灵活性和可扩展性。

Overlay 技术可以看做是实现网络自适应的一种途径,主要用于实现受互联网体系结构限制难以很好支持的一些功能,如组播、QoS、安全 VPN 等。为了更好地适应新一代网络的需求达到网络的自适应性目标,必须将 Overlay 技术与资源虚拟化技术、网络感知技术及可编程性技术等其他关键技术有效结合起来。

实践证明,目前,互联网的体系结构具有很好的可扩展性,但这种体系结构的可扩展性仅仅局限在网络互连互通方面^[4],在支持新的服务方面则表现出越来越多的局限性。例如,很难对组播进行支持,也很难支持大量主机都处于不断移动状态的情形。这些问题出现的主要原因都是由于尽力而为的服务模型只考虑了互连互通的扩展性目标,而没有考虑互连网络在服务等其他方面的可扩展性问题。目前的网络体系结构在地址空间、寻址和路由方式、服务类型等方面都很难进一步扩展。作为一个大复杂系统,网络体系结构与协议缺乏根据服务实现自适应调节与进化的机制。新一代互连网络的复杂性(规模更大、结构更复杂、异构性更强)及用户和服务提供者对服务需求的复杂性和多样性(服务的互操作性、提供速度、可用性、可扩展性、可管理性和服务质量、服务的智能化和个性化等)使得人们急需如何构建大规模互连网络服务的理论指导。

网络的自适应性技术被看做上述问题的可行解决方案,它分为两个层面:①网络资源自适应控制^[5];②网络体系结构与协议的自适应进化^[6]。

网络的自适应性问题涉及的技术难点比较多,目前,研究人员仅是对其中的某些难点进行了初步探索,系统完整地解决网络的自适应性问题还需要一个长期的过程。当前已有的解决思路如下:

(1) 满足网络资源自适应控制理论。未来网络面临巨大的变革和发展机遇,在网络组织形式、接入方式及底层技术等方面面临多种变化。正由多种独立网络向融合的异构无线网络演进;由单一的接入技术发展为多种接入技术并存的局面;由静态接入发展为泛在的、对移动性具备内生支持的接入方式。为适应未来网络的新变化和新需求,建立网络、业务与用户行为模型,研究网络资源

的自适应控制理论具有重要意义。研究面向未来移动网络的资源自适应控制模型,综合考虑未知和随机因素,描述被控对象数学模型的结构和参数,结合动态自适应控制,不断地在线辨识系统模型,并进行决策和调整,结合反馈控制逐步完善模型,使得自适应性指标达到最优或近似最优。

(2) 满足服务发展的网络体系结构与协议自进化机理。多种网络的集成整合必然导致下一代网络环境的多样性和差异性,为满足不同组网技术、不同应用服务和不同运营环境等需求,新一代网络体系结构必须具有能进行动态适应性调整的自进化特性。借鉴动态网络体系结构、主动网等思想,研究未来网络体系结构与协议的自进化机理,根据网络设备、服务业务、网络资源、用户规模等变化,自适应地进行调节和重配置。此外,拟借助可编程网的思路提取自进化网络体系结构和协议模型,并试图从理论上证明其随着网络规模和服务发展而智能调整的可行性和完备性。

与网络的自适应性问题相关的技术难点有很多,仅举例介绍其中几个重要的技术和理论。网络感知理论是指网络能够收集周围网络环境的信息并进行学习,进而对网络进行动态地调整和重构,通过融合异构网络和联合资源管理以最大化地提高网络整体性能。资源虚拟化技术的思想是通过对网络底层的抽象以屏蔽物理网络的实现细节,将网络的控制管理与数据平面的转发交换进行有效分离,虚拟化可以提高网络的故障冗余和网络服务能力。

参 考 文 献

- [1] <http://www.geni.net/>.
- [2] <http://www.cra.org/ccn/netse.php>.
- [3] <http://cordis.europa.eu/fp7/ict/fire/>.
- [4] <http://ieeexplore.ieee.org/stamp/stamp.jsp?arnumber=05226199>.
- [5] McKeown N, Anderson T, Balakrishnan H, et al. OpenFlow: Enabling innovation in campus networks. ACM SIGCOMM Computer Communication Review, 2008, 38(2): 69—74.
- [6] Kleinrock L. History of the internet and its flexible future. IEEE Wireless Communications, 2008, 15(1): 8—18.

撰稿人: 苏 森¹ 孙 毅² 谢高岗²

1 北京邮电大学网络与交换技术国家重点实验室

2 中国科学院计算技术研究所

网络体系结构的优化问题

Problem on Network Architecture Optimization

1. 背景介绍

网络体系结构是计算机网络的总体设计思想，用于指导计算机通信机制的设计和通信协议的实现。当前广泛使用的互联网网络体系结构和协议形成于 20 世纪 70 年代，为便于抽象和模块化，使用分层的思想。然而，随着互联网的发展，各种新型的网络应用日益增多，需要设计新的协议支持网络的多点传输能力，保证网络的服务质量(QoS)，增强安全性，导致现有 TCP/IP 协议栈日益庞大，分层体系结构在动态性和灵活性方面的局限也逐渐显现，如网络资源动态分配效率较低、可管理性较差、网络应用服务间的公平性问题突出等。

20 世纪末，Kelly 等首次将最优化理论和控制理论引入网络体系结构的分析中^[1]，其关键思想是：将互联网本身看作优化器，将已有的各种拥塞控制算法看作一个动力系统^[1]或优化算法^[2]，通过系统的平衡点求解相应的优化问题。这样，可以在统一的构架下同时讨论工程上关心的系统的稳定性和经济上关心的稳定状态速率分配的公平性和有效性^[3]。受到这一思想的启发，目前最优化理论被广泛应用于前向工程(forward-engineering)，即用最优化理论作为指导，优化网络体系结构的设计^[4,5]。网络体系结构的优化问题可以定义为：在给定评价指标和约束条件的前提下，使用最优化等数学理论建立网络体系结构的性能模型，并进行求解，从而得到该评价指标下最优的体系结构设计参考方案。

2. 问题描述

令通信网络有 L 条链路和 S 个源(如端用户)，其中，每条链路 l 的容量为 c_l ，每个源使用一条由若干条链路组成的路径，记路由矩阵为 $\mathbf{R}$ ，每个源 s 的传输速率为 x_s 。那么，基本的网络效用最大化(network utility maximization, NUM)模型^[1]可以描述为

$$\begin{aligned} & \underset{\mathbf{x}}{\text{maximize}} && \sum_{s=1}^S U_s(x_s) \\ & \text{subject to} && \mathbf{R}\mathbf{x} \leq \mathbf{c} \end{aligned}$$

式中，变量 $\mathbf{x} \in \mathbf{R}^S$ ； U_s 是源 s 的效用函数，要求光滑、递增、凹，且仅依赖于本地速率，它体现了用户的弹性需求。广义 NUM 模型为

$$\begin{aligned}
& \underset{\mathbf{x} \geq 0}{\text{maximize}} && \sum_s U_s(x_s) + \sum_j V_j(w_j) \\
& \text{subject to} && \mathbf{R}\mathbf{x} \leq c(w, \mathbf{P}_e) \\
& && \mathbf{x} \in \mathcal{S}_1(\mathbf{P}_e), \mathbf{x} \in \mathcal{S}_2(\mathbf{F}) \text{ or } \in \Pi \\
& && \mathbf{R} \in \mathfrak{R}, \mathbf{F} \in \Xi, w \in \Gamma
\end{aligned}$$

式中, $\mathbf{x}$ 同上; w_j 表示网络单元 j 处的物理资源; 效用函数 U_s 和 V_j 是单调增函数。这里, 链路容量 c 是物理层资源 w 和理想解码差错率 $\mathbf{P}_e$ 的函数, 约束集 $\mathcal{S}_1(\mathbf{P}_e)$ 体现了用信道解码的可靠性和其他类似 AQR 的逐跳差错控制机制间的相互作用来限制速率; 速率还有可能受约束于媒体接入控制的成功概率 $\mathcal{S}_2(\mathbf{F})$, 其中, $\mathbf{F}$ 是连接矩阵]或者可调度性约束集 Π , Γ 、 Ξ 、 $\mathfrak{R}$ 分别表示物理资源分配机制的可选集合、可能的调度集合或者基于竞争的媒体接入集合、单径或者多径路由集合。该模型给跨层网络设计提供了统一平台, 并可以将协议栈的设计看作优化分解, 从而用分解理论理解体系结构和协议栈的设计^[5]。应强调的是, “分层优化分解” 不是对现有协议栈进行特定跨层设计的系统综述, 而是一种思想, 将网络看作优化器; 是一种语言, 允许研究者定量地对各种网络体系结构进行比较; 是一套方法, 促进我们系统地进行模块化和分布式网络体系结构设计。

最优化模型的建立包括目标函数和约束集两部分。通常根据网络体系结构设计所服务主体的不同目标函数可分为两类: 一是端用户效用函数之和, 效用函数的变量主要包括速率、可靠性、延迟、抖动等; 一是网络运营商的成本函数, 其变量主要包括网络拥塞状况、能量效率、网络生命周期等。约束集通常包含两类约束: 一类是通信基础设施所限定的物理、技术及经济方面的约束条件; 另一类是满足用户需求的硬性或者灵活的服务质量约束。

给定一个具体的最优化模型, 通常容易得到集中式的解, 但这并不是我们期望的结果。为了能应用于网络环境, 我们需要得到分布式的求解算法, 这就需要对复杂的原问题进行分解, 得到一系列较为简单的子问题。现有分解技术可分为两类: 原分解和对偶分解。前者直接基于原问题进行分解, 可理解为原问题掌握了现有的全部网络资源, 通过分解将资源分配给每一个子问题; 后者是基于原问题的 Lagrange 对偶进行分解, 可理解为原问题拥有最优的网络资源定价策略, 每一个子问题根据资源的价格决定将要使用的资源数量。

3. 研究难点

近年来, 大量研究工作集中在网络体系结构的优化方向, 也取得了很多进展, 但仍有一系列开放性问题需要进一步研究和探索, 主要包括以下几个方面:

(1) 非凸性。一般认为优化问题难与易的分界线是凸性。但是, 通常情况下, 由实际问题建模得到的最优化问题并不能保证凸性, 给求解带来了巨大的

困难^[5]。其非凸性主要体现为 4 种形式：①非凸目标函数，如 S 型效用，它广泛存在于包括语音应用在内的各种应用中，很多实际模型都会使用该类效用；②非凸约束集，如 SIR 的下界；③整数约束，如路径路由协议中的约束；④随变量数目呈指数增长的凸约束集。

(2) 分解方法。前面提到对同一最优化问题会有不同的分解方法，从而得到差异化的、分布式的解决方案，对应于不同的网络体系结构^[6]。因此，给定一组需求(如收敛速率、计算量分布的对称性及消息传递数量)的前提下，如何系统地探究备选分解方法，以及备选的网络体系结构，仍然是一个开放性问题。

(3) 延迟稳定性。最优化问题经分解可得到一组迭代算法，其收敛速度和稳定性通常是相互矛盾的，即收敛速度越快，达到均衡值前的震荡就越强烈。对于某些用户的资源分配(如窗口大小)，若某时刻的瞬时值降到阈值以下，则可能导致连接断开，那么，均衡值便没有任何意义了。因此，在存在网络延迟的情况下，如何处理迭代算法的收敛速度与稳定性之间的关系仍是研究的难点问题。

(4) 随机性。已有的众多研究大都使用了一种确定的流流(fluid-flow)模型，弱化了网络的不确定性。然而，网络传输环境并不是恒定不变的，如网络拥塞状况、网络拓扑变化等，导致通信网络具有随机性的特点。因此，需要将网络的随机性嵌入到网络效用最大化模型中，这也是目前研究热度最高的问题。

参 考 文 献

- [1] Kelly F, Maulloo A, Tan D. Rate control in communication networks: Shadow prices, proportional fairness and stability. J. Operational Research Soc., 1998, 49: 237—252.
- [2] Low S H, Lapsley D E. Optimization flow control. I: Basic algorithm and convergence. IEEE/ACM Transactions on Networking, 1999, 7(6): 861—874.
- [3] Low S H. A duality model of TCP and queue management algorithms. IEEE/ACM Transactions on Networking, 2003, 11(4): 525—536.
- [4] Xie D X, Jin C, Low S H, et al. Fast TCP: Motivation, architecture, algorithms, performance. IEEE/ACM Transactions on Networking, 2006, 14(6): 1246—1259.
- [5] Chiang M, Low S H, Calderbank A R, et al. Layering as optimization decomposition: A mathematical theory of network architectures. Proceedings of the IEEE, 2007, 95(1): 255—312.
- [6] Palomar D, Chiang M. Alternative decompositions for distributed maximization of network utility: Framework and applications. IEEE Trans. on Automat. Contr., 2007, 52(12): 2254—2269.

撰稿人：徐 恪

清华大学计算机科学与技术系

Mu-演算模型检测复杂度

The Complexity of Mu-Calculus Model Checking

模型检测^[1]的基本思想是用状态迁移系统(S)表示并发系统的行为,用模态/时序公式(F)描述系统的性质。这样,“系统 S 是否具有所期望的性质 F ”就转化为数学问题“ S 是否是 F 的模型”。对于有穷状态系统,这个问题是算法可判定的。

模型检测中最常用的逻辑有 CTL(计算树逻辑)、LTL(线性时序逻辑)和命题 Mu-演算^[2]。其中,表示能力最强的是命题 Mu-演算。命题 Mu-演算非常简洁,其表示能力主要来自于最大与最小不动点的任意交错嵌套。CTL 和 LTL 分别对应于 Mu-演算的不同子集,并且相应的子集具有和 CTL、LTL 相同复杂度的模型检测算法。

给定状态迁移系统 S 和 S 中的一个指定状态 n (称为 S 的初始状态),以及 Mu-演算公式 F ,判定 n 是否满足 F ? 这就是 Mu-演算模型检测问题。已经知道, Mu-演算模型检测问题属于 $NP \cap co-NP$ ^[1,3,4]。迄今为止,所有已经公开发表的 Mu-演算模型检测算法的复杂度都与公式 F 的交错深度成指数增长,这里,交错深度是指 F 中相互依赖的最大与最小不动点算子的嵌套层数。Mu-演算是否存在多项式时间的模型检测算法? 尽管过去 30 年中理论计算机科学家为此付出了大量努力,这个问题至今仍然是尚未解决的悬案。

和 Mu-演算模型检测密切相关的一个问题是奇偶博弈(parity game)的求解。奇偶博弈是一种双人博弈,有两个对手,不妨称为奇先生与偶女士,在一个(有穷)有向图(称为博弈图)上对弈。博弈图上的每个结点都标有两个属性:权重和类型。权重是从 0 开始的连续自然数,类型是 $\square$ 或 $\diamond$ 之一。奇偶博弈只用一枚棋子。对弈的过程就是将这枚棋子从图上的一个结点沿从该结点出发的一条边移向下一个结点。如果当前结点的类型是 $\square$,则由奇先生走这步棋,否则,由偶女士走。棋子所经过的边组成了图上的一条路径。从给定结点 n 开始的一局棋,就是棋子从 n 开始经过的极大路径 p 。如果 p 是有穷路径,那么, p 的终止结点上负责走棋的弈手就输了这局棋,其对手则赢了这局棋。如果 p 是无穷路径,那么,判定输赢的方法是:如果在 p 出现无穷多次的结点中权重最大的结点的权重是奇数,则奇先生赢,否则,偶女士赢。如果奇先生有一个策略,能够赢从 n 开始的每一局棋,则称 n 是奇先生的取胜位置;对称的,如果偶女士有一个策略,能够赢从 n 开始的每一局棋,则称 n 是偶女士的取胜位置。已经

知道奇偶博弈是确定性的,即博弈图上的每一个结点或者是奇先生的取胜位置,或者是偶女士的取胜位置。奇偶博弈的求解问题就是判定图上任意结点是谁的取胜位置。与 Mu-演算模型检测问题类似,奇偶博弈的求解问题也是属于 $NP \cap co-NP$,并且迄今为止所有已经公开发表的奇偶博弈的求解算法都与最大权重成指数增长。

事实上,给定状态迁移系统 S 和 Mu-演算公式 F ,可以构造一个博弈图 G , G 的大小与 S 的大小和 F 的长度的乘积成线性, G 的每个结点对应于 S 中的一个状态和 F 的一个子公式; S 的初始状态 n 满足 F 当且仅当 G 中对应于 n 和 F 的结点是奇先生的取胜位置。在这个意义下, Mu-演算模型检测问题和奇偶博弈的求解问题是等价的^[5]。

和 Mu-演算模型检测等价的另一个问题是交错树自动机的字问题,即判定一个无穷树是否为一个交错树自动机所接收^[5,6]。因此, Mu-演算模型检测、奇偶博弈求解、交错树自动机接收字这三个来自不同领域的问题可以看做是同一个问题的三种不同表现形式,这也是 Mu-演算模型检测问题会引起不同背景的研究者如此广泛关注的原因。

参 考 文 献

- [1] Clarke E, Grumberg O, Peled D. Model Checking. Cambridge: MIT Press, 1999.
- [2] Dexter K. Results on the propositional μ -calculus. Theoretical Computer Science, 1983, 27(3): 333—354.
- [3] Emerson A. Model checking and the Mu-calculus. Descriptive Complexity and Finite Models: American Mathematical Society, 1997: 185—214.
- [4] Bradfield J, Stirling C. Modal Mu-calculi // Blackburn P, van Benthem J. The Handbook of Modal Logic. New York: Elsevier, 2006.
- [5] Grädel E, Thomas W, Wilke T. Automata, Logics, and Infinite Games. Berlin: Springer, 2003.
- [6] Emerson A, Jutla C. Tree automata, Mu-calculus and determinacy. IEEE Proc. Foundations of Computer Science, 1991: 368—377.

撰稿人: 林惠民
中国科学院软件研究所

BQP 类的大小

The Power of the Class BQP

如今, 计算机科学的理论基础还是 20 世纪 30 年代之后逐步确立的丘奇-图灵论题, 该论题认为任何合理的计算装置在计算能力上都等同于经典图灵机^[1]。在第二次世界大战之后, 直到今日的实践上, 支配整个计算机科学技术和产业发展的却是摩尔定律, 该定律认为在价格不变的前提下, 集成电路上可容纳的晶体管数目每隔大约 18 个月增加一倍, 性能也提升一倍。随着时间的不断推移, 在目前的技术条件下, 最迟到 2020 年, 摩尔定律将达到物理上的极限而难以为继。近年来, 人们开始探索各种新型的计算模型, 量子计算机就是其中之一。Deutsch 在 1985 年正式提出量子图灵机, 证明其与经典图灵机在计算能力上是等价的^[2]。著名计算机科学家 Yao 在 1993 年提出了量子电路, 证明其与量子图灵机是等价的^[3]。从可计算性的角度来看, 量子计算机依然遵守丘奇-图灵论题, 即量子计算机与经典图灵机的能力是一样的, 在不计模拟效率的前提下, 两者可以互相模拟。但是, 从计算复杂度的角度来看, 若考虑模拟的效率, 则量子计算机有可能比经典计算机更强。量子力学内在的随机性使量子计算机天然就能有效地模拟经典概率图灵机(有效是指多项式时间)。反之, 经典图灵机似乎不能有效地模拟量子计算机。大物理学家 Feynman 在考虑用经典计算机模拟量子物理过程的时候就遇到了计算复杂度为指数增长的困难, 因而最早提出了量子计算机的设想^[4]。Shor 在 1994 年发现了大数因子分解的多项式时间量子算法^[1,5], 到目前为止, 该问题在经典计算机上还只有指数时间算法。由于因子分解问题在经典计算机保密通信中的重要作用, Shor 的结果激起了全世界对量子计算机和量子计算复杂度理论的研究热潮。

为了研究量子计算机的计算能力大小, Bernstein 和 Vazirani 在 1993 年把量子计算机在现实条件下能有效解决的判定问题类定义为 BQP 类(现实条件是指允许小的错误概率)^[1,6], BQP 意指“有界错误概率量子多项式时间”。具体地说, 设 L 是表示某个判定问题的一个语言, 则 L 属于 BQP 类, 当且仅当存在一台多项式时间量子图灵机 M , 使得 M 以至多 $1/3$ 的错误概率来接受 L 。换句话说, 对于任意的输入 x , M 都运行在输入长度 $|x|$ 的多项式时间内, 并且满足: 若 x 属于 L , 则 M 接受 x 的概率大于等于 $2/3$; 若 x 不属于 L , 则 M 拒绝 x 的概率大于等于 $2/3$ 。

从技术上来说, BQP 类只表示判定问题类(即只需回答“是”或“否”的问

题型), 相应的搜索问题类(即需要输出多个比特作为答案的问题类)应当叫做 FBQP(function BQP)^[7], 但通常也不加区分都笼统地称为 BQP 类。例如, Shor 的结果就可通俗地说成是因子分解问题属于 BQP 类。于是, 理解量子计算机的能力大小的问题就成了比较 BQP 类与其他相关经典复杂度类(如下面将要提到的 BPP 类和 NP 类等)之间包含关系的问题^[1], 这就是所谓的 BQP 类的大小问题。

人们非常关心的一个问题是: 量子计算机能否有效地解决 NP 完全问题? 这个问题等价于 NP 类是否包含于 BQP 类的问题。NP 意指“非确定型多项式时间”, 代表了一大类在实践中非常有用的判定问题, 这类问题的输入在有解的情况下, 解的长度不会超过输入长度的多项式, 并且解的正确性可以在输入长度的多项式时间内进行验证^[1,8]。NP 完全问题是这类问题中最难的一类, 只要有一个 NP 完全问题能被经典图灵机有效地解决(即属于多项式时间复杂度类 P 类^[1,8]), 则所有 NP 类问题都能有效地解决(即 $NP = P$)^[1,8]。Bernstein 等在 1993 年构造了一个外部信息源(Oracle), 相对于这个外部信息源, 在相对化计算^[1,8]的意义下, NP 不包含于 BQP^[9], 这个结果作为来自计算复杂度理论的一个证据, 表明量子计算机也许不能有效解决 NP 完全问题。

增强的丘奇-图灵论题(extended CTT)认为任何合理的计算装置在现实条件下能够有效地解决的问题类是 BPP 类, BPP 意指“有界错误概率随机多项式时间”。在 BQP 类的定义中, 把量子图灵机换成经典概率图灵机就得到 BPP 类的定义^[1]。量子计算机可以有效模拟经典概率图灵机的事实就可以表示为 $BPP \subseteq BQP$ ^[1], 这个包含关系是否为真包含的问题, 就等价于量子计算机是否比经典概率图灵机更强的问题, 或者说增强的丘奇-图灵论题是否正确的问题。由于 BPP 类包含于 PH 类^[1], 因此, 一个相关的问题是: BQP 类包含于 PH 类吗? 这里, PH 类表示多项式时间层次类, 是对于 NP 类的一种自然推广^[1,8]。最近, Aaronson 构造了一个外部信息源, 使得在相对化的意义下, 搜索问题版本的 BQP 不包含于 PH(从技术上来说, 就是 FBQP 不包含于 FPH)^[7], 这可视为量子计算机比经典计算机能力更强的一个证据。

到目前为止, 已知的关于 BQP 的上下界可以用经典复杂度类表示为^[10]

$$P \subseteq BPP \subseteq BQP \subseteq AWPP \subseteq PP \subseteq PSPACE \subseteq EXP$$

式中, AWPP 和 PP 分别是两个计数复杂度类^[1]; PSPACE 和 EXP 分别是多项式空间复杂度类^[1,8]和指数时间复杂度类^[1,8]。这说明量子计算机比经典计算机至多有指数倍时间的加速。

在大规模可扩展量子计算机成为现实之前, 对 BQP 类的研究是否有成为镜中花水中月或空中楼阁的危险? 事实并不如此。对于 BQP 类的研究, 除了有助于理解量子计算机的能力大小之外, 还有更加基本的科学意义。Shor 的因子分

解算法表明,下列三种可能性中至少有一种是真的:①增强的丘奇-图灵论题不正确,即 BPP 类不等于 BQP 类;②量子力学的基本原理是错的;③经典计算机能有效解决大数因子分解问题,即因子分解问题属于 BPP 类。无论哪一种可能性为真,都将是对我们今天拥有的对这个世界的知识的重大补充和修正。

参 考 文 献

- [1] Aroara S, Barak B. Computational Complexity: A Modern Approach. Cambridge: Cambridge University Press, 2009.
- [2] Deutsch D. Quantum theory, the Church-Turing principle and the universal quantum computer. Proc. R. Soc. London Ser. A, 1985, 400(1818): 97—117.
- [3] Yao A C. Quantum circuit complexity. Proc. 34th FOCS, 1993, 352—361.
- [4] Feynman R. Simulating physics with computers. Inter. J. Theoret. Phys., 1982, 21(6,7): 467—488.
- [5] Shor P W. Polynomial-time algorithms for prime factorization and discrete logarithms on a quantum computer. SIAM Journal on Computing, 1997, 26(5): 1484—1509.
- [6] Bernstein E, Vazirani U. Quantum complexity theory. SIAM Journal on Computing, 1997, 26(5): 1411—1473.
- [7] Aaronson S. BQP and the polynomial hierarchy. Proc. 42nd STOC, 2010: 141—150.
- [8] Garey M R, Johnson D S. Computer and Intractability: A Guide to the Theory of NP-Completeness. San Francisco: W H Freeman, 1979.
- [9] Bennett C, Bernstein E, Brassard G, et al. Strengths and weaknesses of quantum computation. SIAM Journal on Computing, 1997, 26(5): 1510—1523.
- [10] Fortnow L, Rogers J. Complexity limitations on quantum computation. J. Comput. Syst. Sci., 1999, 59(2): 240—252.

撰稿人: 刘 田

北京大学信息科学技术学院

约束求解与优化

Constraint Solving and Optimization

如何为有数千名教师和数万名学生的学校安排课表？地铁公司如何在某班列车临时取消或司机意外缺勤的情况下重新安排地铁运营？如何为无线网络分配频率以避免邻近节点之间的干扰？如何为保证软件的正确性而生成有代表性的测试用例？诸如此类的问题都依赖于约束求解与优化技术。约束问题的求解研究始于 20 世纪 60 年代的交互图形(interactive graphics)及 70 年代的场景标记(scene labeling)。交互图形的目的是允许用户在计算机的显示屏上绘制和处理各种几何图形，它发展了约束求解技术中的局部推演及约束编译技术。场景标记试图用二维的线条描绘三维的物体，它的成果在于产生了各种一致性算法。这些早期研究在 1977 年由 Mackworth 统一到约束满足问题的框架下^[1]。约束求解的早期工作还包括麻省理工学院的电路分析与综合，他们的工作开创了设计能够求解通用约束问题的语言的研究。Gallaire 及 Jaffar 分别在 1985 年及 1987 年发现的逻辑程序设计(logic programming)实质上也是一种特殊的约束求解问题。近年来，随着约束求解技术的不断发展，以及软件测试及软件规约的正确性验证等应用的需要^[2]，混合约束问题的研究也开始发展起来，并已成为当今约束求解领域的研究热点之一。

形式化地讲，约束问题由三个要素组成：变量的集合 V ，变量的域 D 及约束的集合 C 。变量 $V_i \in V$ 只能在它的域 D_i 中取值；约束 $C_i \in C$ 描述了部分或全部变量取值之间必须满足的关系。求解约束问题就是在各变量的域中找到一个值使得所有约束都被满足^[3]。对于约束优化问题，则还有一个依赖于变量取值的目标函数 f ，求解时要在满足所有约束的前提下，让目标函数 f 的值达到最大或最小^[4]。根据约束问题中变量域 D 的不同，约束问题可以分为布尔约束问题、有限约束问题及混合约束问题等。布尔约束问题中的各变量只能在 0 或 1 上取值，其约束是一组命题逻辑公式；有限约束问题中的变量只能在有限的域上取值；混合约束问题中的变量可以在多个域上取值，具有最强的表达能力，但求解也最为困难。一个重要且具有挑战性的研究方向是如何将实际应用建模为合适的约束问题以高效求解。

约束求解的主要方法包括以回溯为代表的完全算法和以局部搜索为代表的完全算法。完全算法在求解过程中通常会使用一致性检查^[3]、失败学习^[3]和对称消除^[3]等技术以加快求解速度，而不完全算法则以损失解的完全性为代价

提高求解效率^[3]。如何针对具体的约束问题选择合适的算法及其相关技术或者结合多个算法进行求解是另一个具有挑战性的问题。运筹学领域的优化问题与约束优化问题在形式上具有相似性,两者之间的求解技术可以相互借鉴^[5]。求解整数规划问题的隐枚举法是约束求解技术在优化问题上的成功应用^[5],而线性规划在约束求解领域也已被广泛应用^[5]。如何结合各自领域的先进技术高效求解优化或约束问题是又一个重要的研究方向。

约束问题从计算复杂度的角度来看属于 NP 完全问题,因此,约束问题的变量个数及各变量域的大小是决定其求解速度的关键因素。一个重要的研究方向是寻找约束问题的可多项式时间求解的子类,并在此基础上得到约束问题的复杂度分类定理,如二分定理。这个方向目前有两个途径:一个是考虑各约束本身的性质,如泛代数方法^[1],另一个是考虑变量之间的相互约束关系,即结构分解方法^[3]。研究约束问题计算复杂度的另一个重要方向是对难解性的理解和刻画。在实践中,人们广泛采用随机产生的约束问题在可满足性相变区域的实例来构造难解的算法测试用例,如 Xu 和 Li 提出的具有精确相变现象的随机约束问题模型 RB^[6],以该模型为基础所构造的算法测试用例已应用于包括约束求解算法竞赛在内的多个国际算法竞赛。在理论上,约束问题可满足性相变与难解性之间的确切关联仍然是一个重要的科学问题^[3]。

随着网络技术的迅速发展,分布式约束问题也成为一個十分重要的研究领域。分布式约束问题将变量和约束分布到一组被称为智能体的个体之中,每个智能体仅控制一部分变量,只了解与这些变量相关的约束,这些智能体将分别为其所控制的变量赋值,通过智能体的消息协议和行为准则设计来保证所有约束均被满足,或者所违反约束的代价和最小(即约束优化)。此类问题的已有算法可以分为异步和同步两大类。前者允许各个智能体异步、并行地做出决策,无需互相等待,如实现分布式约束满足的异步回溯算法^[7];后者则要求智能体的决策和消息发送遵从某种顺序,如从经典剪枝搜索算法中衍生出来的同步分枝/定界算法^[8]。分布式约束问题可对分布式系统中非集中式任务分配、协同决策等许多真实问题建模^[3],因此,近年来被广泛关注。

参 考 文 献

- [1] Mackworth A K. Consistency in networks of relations. *Artificial Intelligence*, 1977, 8: 99—118.
- [2] Zhang J, Wang X. A constraint solver and its application to path feasibility analysis. *International Journal of Software Engineering and Knowledge Engineering*, 2001, 11(2): 139—156.
- [3] Rossi F, van Beek P, Walsh T. *Handbook of Constraint Programming*. New York: Elsevier, 2006.
- [4] Tsang E. *Foundations of Constraint Satisfaction*. London: Academic Press, 1993.

- [5] Hooker J N .Logic ,optimization and constraint programming .INFORMS Journal on Computing , 2002 ,14(4) ;295—321 .
- [6] Xu K ,Li W .Exact phase transitions in random constraint satisfaction problems .Journal of Artificial Intelligence Research ,2000 ,12 ;93—103 .
- [7] Yokoo M ,Durfee E H ,Ishida T ,et al .The distributed constraint satisfaction problem ;Formalization and algorithms .IEEE Transactions on Knowledge and Data Engineering ,1998 , 10(5) ;673—685 .
- [8] Hirayama K ,Yokoo M .Distributed partial constraint satisfaction problem .Proceedings of International Conference on Principles and Practice of Constraint Programming ,1997 ;222—236 .

撰稿人：季晓慧¹ 刘 田² 王怀民³

1 中国地质大学（北京）信息工程学院

2 北京大学信息科学技术学院

3 国防科学技术大学计算机学院

计算复杂性若干未解决问题

Some Open Problems in Computational Complexity

1. 背景介绍

Hartmanis 和 Stearns^[1]定义了时间和空间复杂性的概念,给出了计算复杂性的度量,从而开创了计算复杂性这门学科。

令 $\Sigma = \{0, 1\}$, 我们称一个集合 $A \subseteq \Sigma^*$ 为一个语言, 这里, Σ^* 是一切 0, 1 串, 即有穷序列组成的集合。定义 P、NP 和 PSPACE 分别是确定型多项式时间、非确定型多项式时间和多项式空间图灵机所判定的语言的全体组成的集合。定义 Logspace 为一切确定型 log 空间图灵机判定的语言组成的集合, 这里的图灵机有三个带子: 一个只读的输入带, 一个只写的输出带, 一个可读写的工作带。根据定义有

$$\text{Logspace} \subseteq P \subseteq \text{NP} \subseteq \text{PSPACE}$$

Hartmanis、Lewis 和 Stearns^[2]证明了 $\text{Logspace} \neq \text{PSPACE}$ 。Cook^[3]找到了第一个 NP 完全的语言, 即可满足的布尔表达式全体, Karp^[4]证明了一些自然的组合计算问题是 NP 完全的。Berman、Hartmanis^[5]证明了目前已知的 NP 完全性问题是多项式时间同构的。Rabin^[6]证明了存在多项式时间随机化算法来判定一个自然数是否素数, 自此以后, 随机性在算法实践中成为一个普遍现象。BPP 和 RL 分别定义为多项式时间和 log 空间随机化算法所判定的语言组成的集合。

在计算复杂性概念里, 归约 $\leq_m^P$ 是一个十分重要的概念, $A \leq_m^P B$ 表示集合或者语言 A 经过多项式时间规约到语言或者集合 B , 意指存在一个多项式时间可以计算的函数 f , 使得 $x \in A$ 当且仅当 $f(x) \in B$, 它有时被称为 Karp 规约。 $A \leq_m^{\text{Logspace}} B$ 则表示其规约函数 f 仅仅是多项式空间可以计算的, 显然, 如果 $A \leq_m^{\text{Logspace}} B$, 则一定有 $A \leq_m^P B$ 。但反之, $A \leq_m^P B$ 能不能推出 $A \leq_m^{\text{Logspace}} B$? 属于未决问题之一。

2. 问题描述

问题 1: (1) 是否 $\text{Logspace} \neq P$?

(2) 是否 $P \neq \text{PSPACE}$? 是否 $\text{NP} \neq \text{PSPACE}$?

(3) 是否 $P \neq \text{NP}$?

问题 2：下列命题是否成立：

(1) 如果 $P \neq PSPACE$ ，那么，一切在归约 $\leq_m^P$ 下 $PSPACE$ 完全的语言多项式时间同构；

(2) 如果 $P \neq NP$ ，那么，一切在 $\leq_m^P$ 归约下的 NP 完全语言多项式时间同构；

(3) 如果 $Logspace \neq P$ ，那么，一切在 $\leq_m^{Logspace}$ 归约下的 P 完全语言 $\log$ 空间同构。这里， $\leq_m^P$ 和 $\leq_m^{Logspace}$ 分别表示多项式时间和 $\log$ 空间多一归约。

问题 3：(1) 是否 $\leq_m^P$ 和 $\leq_r^P$ 在 NP 以下相同？

(2) 是否 $\leq_m^P$ 和 $\leq_r^P$ 在 $PSPACE$ 之下相同？

这里， $\leq_r^P$ 表示多项式时间图灵归约，它有时被称为 Cook 归约。

问题 4：(1) 是否 $P=BPP$ ？

(2) 是否 $RL=Logspace$ ？

3. 问题说明与科学意义

问题 1 的(1)、(2)和(3)分别是计算复杂性中关于并行与顺序、时间和空间、确定和非确定三个基本矛盾的问题，其中，(3)是一个著名的问题，它最早隐含地出现在 1956 年 Gödel 给冯·诺依曼的一封信中。(1)和(2)是由 Hartmanis、Lewis 和 Stearns^[2]结果自然引出的问题。我们明确提出这些问题是想强调它们的意义。问题 2 是基于 Berman、Hartmanis^[5]的论文提出的，目的是强调刻画完全性概念的科学意义。问题 3 是关于 Karp^[4]和 Cook^[3]两种归约的关系问题，我们发现，它们之间有一个一致性和非一致性的关系问题。问题 4(1)是自 1980 年代以来研究最多的问题之一，然而问题仍未解决。我们这里明确提出问题 4(2)是考察随机性在更强模型下的作用。显然，随机性对 NP 和 $PSPACE$ 不起作用，我们希望找到随机性起作用的最强计算模型。

所有问题都是计算复杂性中基本而且自然的问题，但多数并没有在文献中明确提出。我们明确提出这些问题是因为认识到这些问题不仅有科学意义，而且有哲学意义。然而，计算复杂性当前的方法或思路似乎对任何一个以上问题都不足以解决。大量的研究已经表明，问题 1 不能有一个简单对角线方法的证明，因为所有(1)、(2)、(3)的证明都有一个相对化障碍。因此，对 $Logspace$ 、 P 、 NP 和 $PSPACE$ 的新的、已避免相对化障碍的刻画都是十分有意义的。Shamir^[7]证明了 $IP = PSPACE$ ，Arora、Lund、Motwani 等^[8]证明了 $NP = PCP(O(\log n), O(1))$ ，这两个结果均自然地排除了相对化障碍，而且它们除了在复杂性中的意义， NP 的 PCP 刻画还指出了近似算法的理论极限，即有些组合优化问题，好的近似算法本身都是 NP -hard 的。问题 2 和 3 与问题 1 有某些联系，但却是不同的问题，是关于归约的问题，一直以来没有实质性的好结果。

问题 4(1) 的研究最早是开始于 Yao^[9] 的 XOR 引理, 它给出了一种困难性放大的方法, 后来引导出降或去随机性方向的研究。在所有以上 4 个问题中, 问题 4(1) 的部分结果或相关结果是最多的, 但它仍是一个困难的未解决问题。我们相信解决这里的任何一个问题都需要新的算法思想和新的数学原理。

参 考 文 献

- [1] Hartmanis J, Stearns R. On the computational complexity of algorithms. Trans. Amer. Math. Soc., 1965, 177: 285—306.
- [2] Hartmanis J, Lewis II P, Stearns R. Hierarchies of memory-limited computations. Proceedings of the 6th Annual IEEE Symposium on Switching Circuit Theory and Logic Design, 1965, 179—190.
- [3] Cook S. The complexity of theorem proving procedures. Proceedings of the 3rd IEEE Symp. on Foundations of Computer Science, 1971, 151—158.
- [4] Karp R M. Reducibility among combinatorial problems // Thatcher J W, Miller R E. Complexity of Computer Computations. New York: Plenum Press, 1972, 85—103.
- [5] Berman L, Hartmanis J. Isomorphism and density of NP and other complete sets. SIAM Journal on Computing, 1977, 6, 305—322.
- [6] Rabin M. Probabilistic algorithm for testing primality. Journal of Number Theory, 1980, 12: 128—138.
- [7] Shamir A. $IP=PSPACE$. Journal of the Association for Computing Machinery, 1992, 39(4): 869—877.
- [8] Arora S, Lund C, Motwani R, et al. Proof verification and intractability of approximation problems. Journal of the ACM, 1998, 45, 501—555.
- [9] Yao A C. Theory and application of trapdoor functions. Proceedings of the 23rd IEEE Symp. on Foundations of Computer Science, 1982, 80—91.

撰稿人: 李昂生¹ 朱 洪²

1 中国科学院软件研究所

2 华东师范大学软件学院

逻辑公式可满足性问题

The Satisfiability Problem for Logical Formulas

可满足性问题是判定一个给定的逻辑公式是否可满足的问题(即公式在某个数学结构中在适当的解释下可否为真)。早在两千多年前,亚里士多德就通过可满足性来证明某些逻辑推理不是有效的。17 世纪,德国数学家莱布尼茨梦想让计算机进行人类的思维活动,为此他认为首先应该把人类的思维活动还原为符号演算。19 世纪,英国数学家布尔把推理看成是代数运算,提出了布尔代数。布尔用 x, y, z 等符号表示取值为 0 或 1 的变元(称作布尔变元,亦称命题变元),以代表一个一个的命题。命题逻辑公式是由命题变元和逻辑连接词 $\neg$ (否定)、 $\wedge$ (合取)、 $\vee$ (析取)、 $\rightarrow$ (蕴涵)及括号按照一定规则组成的表达式。命题逻辑可看作零阶逻辑的形式系统。19 世纪,德国逻辑学家 Frege 为了研究数学基础,提出了一阶逻辑的形式系统。关于形式系统的重要概念有可推导性与协调性。如果对任意公式 B ,由公式集合 $\{A_1, \dots, A_n\}$ 不可同时推出 B 与 $\neg B$,则称 $\{A_1, \dots, A_n\}$ 是协调的。协调性是一个语法概念,它所对应的语义概念则是可满足性。1900 年, Hilbert 在国际数学家大会提出了当时的 23 个世界难题,其中,包括可判定问题:是否存在一个算法,对于任意两个一阶逻辑公式 A 和 B ,它能判定是否可由 A 推出 B 。丘奇和图灵在 20 世纪 30 年代独立证明了这样的算法是不存在的。从而,谓词逻辑公式的可满足问题是不可判定的。然而,命题逻辑公式的可满足性是可判定的,并且 Herbrand 定理表明,谓词逻辑公式的可满足性也可转化为(可能无穷多个)命题逻辑公式的可满足性。这些正面成果使人们看到,命题逻辑公式的可满足问题可让计算机帮助人类进行推理。

因此,逻辑公式可满足性问题通常是指命题逻辑公式的可满足性问题,简称 SAT 问题。早在 1957 年, Newell 和 Simon 就用 SAT 算法证明 Russel 和 Whitehead 的《数学原理》中的定理。1960 年, Davis 等用 SAT 程序来研究 Hilbert 第 10 问题,提出了 DP 算法。1965 年, Robinson 提出了消解算法。1971 年, Cook 首次证明了 SAT 问题是 NP 完全的^[1]。从而研究 SAT 问题是探索著名的“P=NP?”难题的重要途径。从 1990 年代开始, SAT 问题广泛应用于计算机科学,如自动推理、规划、硬件设计、程序验证等。因此,关于 SAT 问题的算法研究是计算机科学的核心课题^[2~4]。

对于一个命题公式 A ,一旦我们对其中的每个命题变元赋以某一真值(通常用 1 表示“真”,而用 0 表示“假”),那么, A 在该赋值下就有唯一的真值。例

如, 当 x 取 0, y 取 1 时, $x \vee \neg y$ 的值为 0; 而当 x 和 y 都取 1 时, $x \wedge \neg y$ 的值为 0。SAT 问题即是: 对任意给定的 A , 是否存在对 A 中变元的赋值, 使得 A 在该赋值下的真值为 1? SAT 问题是第一个被证明是 NP 完全的问题 (Cook 定理)。对于任意命题变元 x , 我们称 x 和 $\neg x$ 为文字。形如 $(L_1 \vee \cdots \vee L_n)$ 的公式称作子句, 其中, 每个 L_i 是文字。而形如 $C_1 \wedge \cdots \wedge C_m$ 的公式称作合取范式 (CNF), 其中, 每个 C_i 为子句。根据命题逻辑中的推理规则可知, 任何一个命题公式都可等价地转换为一个 CNF 公式。然而, 保等价性的转换需要指数空间。Tseitin 证明, 可以在多项式时间把命题公式转化为有同样可满足性的合取范式。因此, 限制到 CNF 公式的 SAT 问题 (CNF-SAT) 仍是 NP 完全的。设 $k \geq 1$ 为整数, 如果一个 CNF 公式中的每个子句中仅有 k 个文字, 则称该公式为 k CNF 公式。当 $k \geq 3$ 时, 关于 k CNF 公式的 SAT 问题 (k SAT 问题) 仍是 NP 完全的, 但 SAT 问题限制到 2CNF 公式上是线性时间可解的。

评估 SAT 算法的一种方法是: 在计算机上实现该算法, 即开发相应的 SAT Solver, 使用其试图解决命题公式实例的可满足性, 并分析运行速度。目前的 SAT Solver 在实际应用中取得了很大成功。评估 SAT 算法的另一种方法是最坏情况下复杂性分析。对于 k SAT 算法, 都存在常数 $1 < a \leq 2$, 它在最坏情况下复杂性不超过 $O(a^n)$ 。自然, 人们希望找到使得常数 a 尽可能小的算法。日本学者 Iwama 和 Tamaki 得出了目前最好的结论: 当 $k=3$ 时, $a=1.324$, 即存在 3SAT 算法, 它的复杂性上界为 $O(1.324^n)$ 。目前已有的完全 SAT 算法在最坏情况下都需要指数时间。也就是说, 多项式时间的 SAT 算法都不能保证给出正确答案, 这样的算法称作不完全算法。概率分析方法即是估算这样的算法在给定的概率分布下给出正确答案的概率。总之, 不管采用哪种分析方法, 研究能够提高 SAT 算法效率的技术都属于 SAT 问题研究课题。国际上每年主办一次 SAT 算法的竞赛, 以比较 SAT 算法在 9 类 SAT 问题上的性能, 设 9 枚金牌, 9 枚银牌, 9 枚铜牌, 吸引了大批青年研究者参加, 并极大推动了 SAT 问题的研究。

最大可满足问题 (MAX-SAT) 是 SAT 问题的一种最优化形式的扩展, 它要求计算出 CNF 公式中可同时被某一赋值满足的子句的最大数目。把 MAX-SAT 限制到 k CNF 公式的问题记作 MAX- k SAT。MAX-SAT 特别在组合优化上有广泛的应用, 国际上每年也主办一次 MAX-SAT 算法的竞赛。不可满足问题 (UNSAT) 和重言式的判定问题 (TAUT) 是 co-NP 完全的。判定 UNSAT 或 TAUT 的方法也称作证明系统。证明复杂性也是 SAT 问题的研究课题。SAT 问题的另一个扩展是极小不可满足 (MU) 问题。一个 CNF 公式是极小不可满足的, 如果该公式不可满足, 但它的每一真子公式都可满足。目前, 关于 MU 公式的结构研究几乎是空白。唯一可满足性问题 (UNIQUE-SAT) 是判定一个公式是否恰有一个满足它的赋值的问题。UNIQUE-SAT 是 D^P 问题, 但至今也不知它是否是

D^P 完全的。 D^P 是所有可表示为两个 NP 问题的差的可判定问题的类。还有, $\#SAT$ 代表计算一个公式有多少个满足它的赋值的问题。

随着计算机科学的发展,人们发现布尔公式不足以或者不便于表示某些应用问题,如一些硬件检测问题不但需要命题逻辑的推理能力,还必须同时解决一些简单的算术用于寄存器的校验。在这样的背景下,把布尔可满足性与特定背景理论的约束进行有效结合求解的理论应运而生,即模可满足理论(satisfiability modulo theory, SMT)。简单地说,模可满足问题的实例是将布尔公式与背景理论的约束通过逻辑联结词组合而得到的。

SAT 问题的另外一个扩展是伪布尔可满足问题。一个伪布尔约束形如: $a_0 L_0 + \dots + a_n L_n \geq b$, 其中, a_i, b 为正整数, L_i 为 x_i 或 $\neg x_i$, 而 x_i 是取值 0 或者 1 的布尔变元。一个伪布尔实例是有穷个伪布尔约束的合取。自然地,伪布尔可满足性(pseudo Boolean satisfiability, PBS)问题定义为:任给一个伪布尔实例,问是否存在对其变元的赋值,使得其中所有伪布尔约束都被满足?伪布尔可满足性之所以得到计算机科学家的关注,一个重要的原因是它可以很方便地表示两类经典布尔约束:子句与基数约束。

在计算机科学中,很多问题借助于量词可以得到更紧致而简洁的表示。量化布尔公式(QBF)是通过对布尔(命题)公式中的布尔变元使用存在量词或全称量词而得到的。QSAT 问题就是判定量化布尔公式是否可满足的问题。QSAT 是计算复杂类 PSPACE 的代表。

参 考 文 献

- [1] Cook S. The complexity of theorem-proving procedures. STOC'71, 1971: 151—158.
- [2] Biere A, Heule M, van Maaren H, et al. Handbook of Satisfiability. Netherland: IOS Press, 2009: 1—965.
- [3] Kleine Büning H, Lettmann T. Propositional Logic: Deduction and Algorithm. Cambridge: Cambridge University Press, 1999: 1—420.
- [4] 张健. 逻辑公式的可满足性判定方法——方法、工具及应用. 北京: 科学出版社, 2000: 1—172.

撰稿人: 赵希顺¹ 李初民²

1 中山大学逻辑与认知研究所

2 华中科技大学计算机科学与技术学院

Unique Games 猜想

Unique Games Conjecture

Unique Games 问题是如下定义的一个约束满足问题 (constraint satisfaction problem, CSP)。给定有向图 $G(V, E)$, 图上的顶点代表变量, 边代表约束。以 $[N]$ 表示集合 $\{1, 2, \dots, N\}$, $[N]$ 中的每个元素是一个标签。边 e 上的约束是一个双射函数 $\pi_e: [N] \rightarrow [N]$ 。一个标签赋值 $L: V \rightarrow [N]$ 对图上的每一个顶点分配集合 $[N]$ 中的一个标签。称标签赋值 L 满足边 $e = (v, w)$, 若 $\pi_e(L(v)) = L(w)$ 。记 U 为 Unique Games 问题的一个实例, $\text{OPT}(U)$ 为在所有标签赋值上可以满足的边的数目与图的边数之比的最大值, 即 $\text{OPT}(U) = \max_{L: V \rightarrow [N]} \{ |\{e \in E \mid L \text{ 满足 } e\}| / |E| \}$ 。Unique Games 问题的目标是寻找一个最优 (即满足的边的数目与图的边数之比为 $\text{OPT}(U)$) 的标签赋值。

Unique Games 猜想 (简称为 UGC)^[1]: 对任意小的常数 $\epsilon, \delta > 0$, 存在一个常数 $N = N(\epsilon, \delta)$, 使得对给定的 Unique Games 实例 $U = (G(V, E), [N], \{\pi_e \mid e \in E\})$, 区分如下两种情形是 NP-hard 的: ① 情形 YES: $\text{OPT}(U) \geq 1 - \epsilon$; ② 情形 NO: $\text{OPT}(U) \leq \delta$ 。

PCP (probabilistically checkable proofs, 概率可验证证明) 定理^[2,3] 表明, 对于 3SAT 问题, 存在一个常数 α^* , 对任给 3SAT 问题实例 ϕ , 可在多项式时间内将其归约到 3SAT 问题的另一个实例 ψ , 使得: ① 若 ϕ 是可满足的, 则 ψ 也是可满足的; ② 若 ϕ 是不可满足的, 则 ψ 可满足的子句数目与其所有子句数目之比的最大值 $\leq \alpha^*$, 在此, 该最大值取在 3SAT 实例 ψ 的所有真假赋值上, 这表明将 MAX 3SAT 问题近似到 α^* 以内是 NP-hard 的。自从 PCP 定理被提出以后, 人们证明了大量的不可近似性结果。其中, 有许多不可近似性结果的证明是通过从一个称为 2-Prover-1-Round Game 问题^[4] 开始的保持差距的归约完成的。

2-Prover-1-Round Game 问题是如下定义的一个约束满足问题。给定二分图 $G(V, W, E)$, 图上的顶点代表变量, 边代表约束。 $[M]$ 和 $[N]$ 是两个标签集合 ($M \geq N$)。边 e 上的约束是一个满射 $\pi_e: [M] \rightarrow [N]$ 。称一个标签赋值 $L: V \rightarrow [M], L: W \rightarrow [N]$ 满足边 $e = (v, w)$ 上的约束, 若 $\pi_e(L(v)) = L(w)$ 。记 I 为 2-Prover-1-Round Game 问题的一个实例。类似地, $\text{OPT}(I)$ 表示在所有标签赋值上可以满足的边的数目与图的边数之比的最大值。2-Prover-1-Round Game 问题的目标是寻找一个最优的标签赋值。

一方面, 使用 PCP 定理证明了许多问题的最优的近似难度结果 (指近似难度

结果与问题已知的最好近似比恰好匹配), 如 MAX 3SAT 问题、团问题等。另一方面, 对于另外的许多问题, 如顶点覆盖问题、MAX CUT 问题等, 使用 PCP 定理证明的近似难度结果与问题已知最好近似比之间仍存在一定差距。Khot 猜测, 造成这种差距的原因可能是因为 2-Prover-1-Round Game 实例中边上的映射 π 是一个多一映射。若将 π 改成一—映射, 则可能会证明到更强的近似难度结果。于是, Khot^[1] 提出了 Unique Games 问题。Unique 是指映射 π 是一—映射[给定边 $e=(v, w)$ 的顶点 v 的标签 $L(v)$, 可由 π 唯一确定顶点 w 的标签 $L(w)=\pi(L(v))$; 反之, 给定顶点 w 的标签 $L(w)$, 也可由 π 唯一确定顶点 v 的标签 $L(v)=\pi^{-1}(L(w))$]。

可由 PCP 定理和 Raz 的并行重复定理^[5] 证明区分 2-Prover-1-Round Game 问题实例的 $\text{OPT}(I)=1$ 和 $\text{OPT}(I)\leq\delta$ 两种情形是 NP-hard 的, 在此 δ 是任意小的常数。对于 Unique Games 问题而言, 由于存在一个简单的多项式时间算法^[6] 判断其实例 U 是否有 $\text{OPT}(U)=1$, 因此, 感兴趣的是区分该问题实例的 $\text{OPT}(U)\geq 1-\epsilon$ 和 $\text{OPT}(U)\leq\delta$ 两种情形, 这正是 Unique Games 猜想, Khot 猜测作这种区分也是 NP-hard 的。

Unique Games 猜想提出之后, 出现了关于该猜想的大量研究工作, 这些工作可分为两类: 一类是基于 Unique Games 猜想假设证明的 NP-hard 问题的近似难度结果, 一类是对 Unique Games 问题及其各种限制版本给出的求解算法。在第一类工作中, 著名的结果包括 MAX CUT 问题的不可近似性结果、顶点覆盖问题的不可近似性结果、CSP 问题的不可近似性结果等。基于 Unique Games 猜想假设, 文献[7]证明了对任给小的常数 $\epsilon>0$, 将 MAX CUT 问题近似到 $\alpha_w+\epsilon$ 以内是 NP-hard 的, 其中, $\alpha_w=0.878\cdots$ 为 Goemans-Williamson 算法给出的 MAX CUT 问题的已知最好近似比, 从而确切刻画了 MAX CUT 问题的近似阈值。而此前 MAX CUT 问题的不可近似性结果为 $16/17+\epsilon$ (基于 $P\neq\text{NP}$ 假设)。类似地, 基于 Unique Games 猜想假设, Khot 和 Regev 证明了对任给小的常数 $\epsilon>0$, 将顶点覆盖问题近似到 $2-\epsilon$ 以内是 NP-hard 的, 这与顶点覆盖问题的已知最好近似比 2 匹配, 而此前顶点覆盖问题已知最好的不可近似性结果为 1.36 (基于 $P\neq\text{NP}$ 假设)。以及一个令人惊奇的结果: Raghavendra^[8] 证明了在 Unique Games 猜想假设之下, 任何 CSP 问题不可能在多项式时间内近似到 $\alpha+\epsilon$ 以内, 其中, α 为 CSP 问题的一个自然的半正定规划松弛的 Integrality Gap。

在第二类工作中, Arora 和 Khot 等证明了当 Unique Games 问题中给定的图是一个 Expander 时, 有多项式时间算法区分 Unique Games 中所提出的两种情形(对某一类 δ)。Arora、Barak 和 Steurer^[9] 证明了当运行时间为亚指数时间时, Unique Games 中所提出的两种情形(对某一类 δ)是可以区分的。其他工作不再一一列举, 但这些工作都没有证伪 Unique Games 猜想。当然, Unique

Games 猜想到目前为止也没有被证明。Khot 本人^[6]的一种观点是: Unique Games 猜想中所提出的问题应该是“难”的,虽然不一定是 NP-hard 的。另外,仅有很少的问题,其有亚指数时间算法,但被认为没有多项式时间算法,这样的两个著名的例子为因数分解问题和图同构问题,文献[9]的工作表明 Unique Games 猜想中的问题也是这样的一个问题。

Unique Games 猜想是计算复杂性领域和不可近似性领域中的一个重要的未解决问题。人们普遍相信,今后无论 Unique Games 猜想被证明或者证伪,在这个过程中都将催生新的方法技术和理论结果。

参 考 文 献

- [1] Khot S. On the power of unique 2-prover 1-round games. Proceedings of the 34th ACM Symposium on Theory of Computing (STOC), 2002, 767—775.
- [2] Arora S, Safra S. Probabilistic checking of proofs: A new characterization of NP. Journal of the ACM, 1998, 45(1): 70—122.
- [3] Arora S, Lund C, Motwani R, et al. Proof verification and the hardness of approximation problems. Journal of the ACM, 1998, 45(3): 501—555.
- [4] Cai J Y, Condon A, Lipton R. PSPACE is provable by two provers in one round. J. Comput. Syst. Sci., 1994, 48(1): 183—193.
- [5] Raz R. A parallel repetition theorem. SIAM Journal on Computing, 1998, 27(3): 763—803.
- [6] Khot S. On the unique games conjecture. Manuscript, 2010.
- [7] Khot S, Kindler G, Mossel E, et al. Optimal inapproximability results for max cut and other 2-variable CSPs? Proceedings of the 45th Symposium on Foundation of Computer Science (FOCS), 2004: 146—154.
- [8] Raghavendra P. Optimal algorithms and inapproximability results for every CSP? Proceedings of the 40th Annual ACM Symposium on Theory of Computing (STOC), 2008: 245—254.
- [9] Arora S, Barak B, Steurer D. Subexponential algorithms for unique games and related problems. FOCS, 2010.

撰稿人: 张 鹏

山东大学计算机科学与技术学院

Tarski 指数函数问题

Tarski's Exponential Function Problem

20 世纪 30 年代, Tarski 利用一阶量词消去方法证明仅含多项式表达式的实数域理论是可判定的, 从而得出初等代数、几何的判定性^[1]。Tarski 进一步提出在上述理论中允许指数函数后所得实数理论是否可判定问题, 即“Tarski 指数函数问题”, 是模型论中迄今尚未解决的一个重要开问题^[2]。

随着科学的快速发展, 这个开问题的求解已经不再是模型论本身的问题, 其与许多学科的发展紧密相关, 特别是计算机科学和控制理论, 甚至数学学科中的其他分支。例如, 计算机科学中许多重要验证问题都可以归结到带指数函数实数理论的判定问题, 如线性混成系统可达集的计算、程序的不变量生成等; 控制理论中许多控制系统的设计问题也归结为带指数函数实数理论的判定问题; 数学学科中超越数理论也与这个问题相关。因此, 带指数函数实数理论判定性问题的解决不仅能够促进数学的发展, 同时也能够促进其他学科的发展, 特别是计算机科学和控制理论, 具有重大的理论意义和实际价值。

为了描述这个问题, 我们首先定义一个能够描述带指数函数的实数域性质的逻辑语言。设 $\{x_1, x_2, \dots, x_n, \dots\}$ 为可数变量集合, 1, 0 为两个常量, + 为加法符号, - 为减法符号, $\times$ 为乘法符号, $\exp$ 为指数函数符号, = 和 $<$ 为两个二元关系, $\$$ 为存在量词, 那么, 我们定义一个语言 $L_{\exp} = (+, -, \times, \exp, =, <, 1, 0)$ 如下:

$L_{\exp}$ 项是由下面规则产生的最小集合: 变量是项; 常量是项; 如果 t_1 和 t_2 是项, 则 $t_1 + t_2$, $t_1 - t_2$ 和 $t_1 \times t_2$ 是项; 如果 t 是项, 则 $\exp(t)$ 是项。

$L_{\exp}$ 公式是由下面规则产生的最小集合: 如果 t_1 和 t_2 是项, 则 $t_1 = t_2$ 和 $t_1 < t_2$ 是公式; 如果 ϕ 是公式, 则 $\neg\phi$, $\$x.\phi$ 是公式; 如果 ϕ_1 和 ϕ_2 是公式, 则 $\phi_1 \wedge \phi_2$ 和 $\phi_1 \vee \phi_2$ 是公式。

对于给定的公式, 其中, 在量词约束范围内出现的变量称为约束变量, 否则, 称为自由变量。不含自由变量的公式称为句子。

$\mathbf{R}$ 为带序的实数域, 则 $\mathbf{R}_{\exp} = (\mathbf{R}, +, -, \times, \exp, =, <, 1, 0)$ 是 $L_{\exp}$ 的一个结构。 $L_{\exp}$ 可以在 $\mathbf{R}_{\exp}$ 上给出一般意义上的解释。我们用 $\text{TH}(\mathbf{R}_{\exp})$ 表示带指数函数的实数理论, 即所有在 $\mathbf{R}_{\exp}$ 解释下为真的 $L_{\exp}$ 公式。那么, “Tarski 指数函数问题” 就是问 $\text{TH}(\mathbf{R}_{\exp})$ 是否可判定。换言之, 就是能否有一个能行的方法, 对于任意给定的一个 $L_{\exp}$ 句子 ϕ , 在有穷步内判定 $\text{TH}(\mathbf{R}_{\exp}) \models \phi$ 。

自从 Tarski 提出该问题以来,因为具有重大理论和实际意义,吸引了许多数学家、计算机科学家和控制论专家的关注,已经取得许多重要进展。首先, van den Dries 在1982年通过反例证明 $\text{TH}(\mathbf{R}_{\text{exp}})$ 不具有量词消去性质,即存在一个带量词的 $\mathbf{L}_{\text{exp}}$ 公式,它不等价于任何不带量词的 $\mathbf{L}_{\text{exp}}$ 公式^[3],这表明不能像 Tarski 在给出初等代数几何可判定性时使用量词消去方法来解决这个问题。其次, Wilkie 于1996年在文献[4]中证明 $\text{TH}(\mathbf{R}_{\text{exp}})$ 具有模型完备性。再次, Macintyre 和 Wilkie 在1995年给出了这个问题的一个有条件解决^[5],即证明如果实数域上的 Schanuel 猜想为真,那么, Tarski 指数函数猜想是可判定的。Weispfenning 等于2008年给出 $\text{TH}(\mathbf{R}_{\text{exp}})$ 的一个子集的判定算法^[6],即 $\mathbf{L}_{\text{exp}}$ 中具有前束型范式且仅最外层约束变量可以出现在指数函数中的句子集合。

但是,这个问题仍旧没有彻底解决。主要困难在于:首先,过去解决这类问题比较有效的方法——量词消去技术已经不再有效;其次,可以借助的超指数理论也有许多问题尚未解决,特别是 Schanuel 猜想被认为在最近一百年内不可能解决。

Tarski 指数函数问题可以归结为能否找到一个能行算法确定任意给定整系数 n 元指数多项式在 $\mathbf{R}^n$ 是否有解。Macintyre 和 Wilkie 于1995年证明^[6] Schanuel 猜想可以保证这个算法的存在。复数域上的 Schanuel 猜想^[7] 论述如下:给定任意 n 个复数 $z_1, \dots, z_n$, 使得它们在有理数域 $\mathbf{Q}$ 上线性独立,那么,有理数域 $\mathbf{Q}$ 的扩域 $\mathbf{Q}(z_1, \dots, z_n, \exp(z_1), \dots, \exp(z_n))$ 的超指数次数至少为 n 。

Macintyre 和 Wilkie 同时证明实数域上 Schanuel 猜想足以证明 Tarski 指数函数问题,但弱化的实数域上 Schanuel 猜想不是 Tarski 指数函数问题的必要条件,这意味着即使实数域上 Schanuel 猜想不成立也不能得出 Tarski 指数函数问题是不可判定的结论。然而,如果我们能够证明 Tarski 指数函数问题是不可判定的,根据 Macintyre 和 Wilkie 的结论,就可以证明 Schanuel 猜想是不成立的。

参 考 文 献

- [1] Tarski A. A Decision Method for Elementary Algebra and Geometry. Berkeley: Univ. California Press, 1951.
- [2] Kuhlmann S. Model Theory of the Real Exponential Function. Berlin: Springer, 2001.
- [3] van den Dries L. Remarks on Tarski's problem concerning $(\mathbb{R}, +, \cdot, \exp)$. Logic Colloquium '82, 1984: 97–121.
- [4] Wilkie A. Model completeness results for expansions of the ordered field of real numbers by restricted Pfaffian functions and the exponential function. J. Amer. Math. Soc., 1996, 9: 4.

-
- [5] Macintyre A, Wilkie A. On the decidability of the real exponential field. CLSI, 1995.
 - [6] Achatz M, McCallum S, Weispfenning V. Deciding polynomial exponential problems. Proc. ISSAC'08, 2008; 115—221.
 - [7] Lange S. Introduction to Transcendental Numbers. New York: Addison-Wesley, 1966; 30—31.

撰稿人：詹乃军
中国科学院软件研究所

DNA 计算中的检测问题

Detection Problem in DNA Computing

DNA 计算是一种基于生化反应机理的新型计算模式,与基于图灵机思想的电子计算机原理毫不相同,其研究至今只有 16 年的历史,但发展迅速。从 DNA 计算解决问题规模的能力来看,1994 年,仅能处理 7 个顶点有向图中的计算问题(美国)^[1];8 年之后,研制出可达 104 万次的搜索能力的 DNA 计算机(美国),这个问题虽然电子计算机用不到 1s 的时间可以解决,但人类自身已经没法计算^[2]。

在 DNA 计算中,由于所面对的问题大多都是困难的 NP 完全问题,而目前所设计的大多数 DNA 计算模型是随着问题规模的最大而导致所需要的 DNA 分子的指数级的增加!这就相当于将算法的复杂度问题转化为所需 DNA 分子量的复杂度,也就是转化成问题解空间的复杂性问题。如何从数量众多的 DNA 分子中检测到目的 DNA 分子片段,并保证其在计算过程中和最后的检测中的高度精确性,就是 DNA 计算中所面临的一个难题^[3]。

目前,DNA 计算常见的检测技术包括 PCR 技术、测序技术等。虽然这些技术能够满足一些计算问题,但目前都还存在不精确性且耗时较长等不足,影响 DNA 计算的通用性和计算速度。寻找发现新的检测技术用于建立通用型 DNA 计算模型乃至建立通用型 DNA 计算机的研制^[4]。

解的检测问题,即如何在纳米尺度上利用现有 IT 技术快速准确地检测出海量的 DNA 序列,是 DNA 计算机中亟待解决的技术问题。解的检测是 DNA 计算的最后步骤,也是 DNA 计算机研制中的最核心技术。如何快速地将问题的解,即代表问题解的 DNA 分子检测出来,使得纳米级的 DNA 分子在宏观世界可见是当前研究的困难点。如何快速地利用 IT 技术,将代表问题解的 DNA 分子转换成电信号或光信号,是 DNA 计算机走向实用化的关键。该步骤需要高效地提取代表问题解的 DNA 分子,使得纳米级的 DNA 分子在宏观世界可见。检测问题是指将参与 DNA 计算的某种 DNA 分子通过有限次操作,将生物信号直接转化成光电信号等,使得这种 DNA 分子被全部或依照某种概率快速检测出来。在该问题中,包含了精确性和快速性两个方面。

在 DNA 计算机的研究中,为了尽可能大地减少参与的试管数量,需要解决如下困难问题:在一个试管中含有大量的 DNA 分子,需要对这些长度为 n 的 DNA 序列,将其中包含在某段,如第 i 到第 j ($j > i$) 段,具有相同 DNA 序列全

部提炼出来。这个问题一旦解决，则 DNA 计算机可实用，并在求解 NP 完全问题上超越电子计算机。

同时，检测系统是 DNA 计算机模型中一个重要的组成部分，通过运算系统后的 DNA 分子将在此系统中被检测，而得到待求解问题的解。其中，DNA 计算系统结构图如图 1 所示，而检测系统示意图则如图 2 所示。




图 1 DNA 计算系统结构图

从图 1 和图 2 中不难看出，检测系统除了独立地作为 DNA 计算机组成系统的一个子系统外，还穿插在 DNA 计算机的核心系统——运算子系统中，需要与 DNA 计算的反应器——生化反应池相连接。也就是说，对于 DNA 计算机中的检测，除了要对最终的计算结果进行检测以外，还需要对中间计算结果进行检测，此时，它不但参与了 DNA 计算的运算过程，同时也对 DNA 计算的运算过程起到了监测作用，这就需要在 DNA 计算机的研究中，除了发展生物技术、纳米技术及光电检测等先进的检测技术之外，还要研究各个系统与检测系统的接口技术。

我国学者曾利用优化思想，对待解问题进行合理分解，使得部分不满足问题的中间计算结果先被删除后，再进行组合。采用这样的方法不但可以避免 DNA 计算初始解空间的爆炸问题，同时也使得后续的检测过程更加精准。虽然这个方法可以增加 DNA 计算中待求解问题的规模，也可以进行一些精确检测，但仍然没有达到对 DNA 计算的计算过程进行实时精确检测的目的。




图2 DNA 计算检测系统示意图

我们期望纳米技术、分子信标、原子力显微镜技术及光镊技术引入 DNA 计算，提出了 5 种检测方案：基于纳米颗粒的光学特性的研究方案、根据纳米颗粒的高电子密度特性的研究方案、利用生物传感器进行检测的研究方案、利用分子信标进行检测的研究方案及综合检测手段的研究方案，这些方法都将为 DNA 计算研究提供新的、快速准确的检测技术。

参 考 文 献

- [1] Adleman L. Molecular computation of solution to combinatorial problems. Science, 1994, 66(11):1021—1024.
- [2] Braich R S, Chelyapov N, Johnson C, et al. Solution of a 20-variable 3-SAT problem on a DNA computer. Science, 2002, 296:499—502.
- [3] Schmidt K A, Henekel C V, Rozenberg G, et al. DNA computing using single-molecule hybridization detection. Nucleic Acids Research, 2004, 32(17):4962—4968.
- [4] Henekel C V, Rozenberg G, Spaink H. Application of mismatch detection methods in DNA computing. Natural Computing, 2006, 5(2):151—163.

撰稿人：许 进

北京大学信息科学技术学院

三维凸多面体相交检测

Intersection Detection of 3D Convex Polyhedra

三维凸多面体相交检测是三维计算几何中的一个非常基本的问题,这个问题在机器人自动碰撞检测、路径设计等应用中都有实际应用,其同一般的凸多面体相交计算有联系但不完全等价。

给定两个(或多个)三维凸多面体 P 和 Q , 我们可以对它们分别进行预处理。在判定 P, Q 是否相交时, 只需要在返回肯定回答时给定一个相交点作为见证点。如果 P, Q 不相交, 则只需要返回否定回答。由于在有些应用中凸多面体的顶点数可能很大, 因此, 我们希望预处理的存储空间是线性的。最理想的情况是只用线性的预处理空间而保证相交检测时间为 $O(\log |P| + \log |Q|)$, 这里, $|P|, |Q|$ 分别是 P, Q 的顶点数。

1980 年, 耶鲁大学的 Chazelle 和 Dobkin 在 STOC'80 上以 Detection is easier than computation 为题, 拉开三维凸多面体相交检测研究的序幕^[1]。此后几年是计算几何领域的黄金时代, 也发表了一系列结果, 但跟最理想的结果都有一定差距。1985 年, 普林斯顿大学的 Dobkin 和加拿大英属哥伦比亚大学的 Kirkpatrick 将原用于二维点定位的层次结构应用到三维凸多面体相交检测上, 取得了飞跃性的成果^[2]。在线性处理空间下, 他们的方法能获得 $O((\log |P|) \times (\log |Q|))$ 的检测时间。当 $|P|, |Q| \leq n$ 时, 该检测时间为 $O(\log^2 n)$ (为方便叙述, 假定 P, Q 的顶点数相同)。

除了检测时间上的改进, Dobkin 和 Kirkpatrick 的方法在 P, Q 不相交时可以返回 P 和 Q 之间(沿任意方向)的最短距离。注意, 这个距离不一定由 P, Q 上的顶点决定。1986 年, 纽约大学的 Cole 用一个不同的方法得出线性预处理下的判定 P 和 Q 是否相交的 $O(\log^2 n)$ 检测时间^[3]。1992 年出现了基于层次结构的第三个运算时间相同的算法, 该算法最早于 1992 年在 CCCG'92 上公布, 正式发表于 1997 年^[4]。1992 年后, 该问题的研究没有任何进展。

因为 Dobkin 和 Kirkpatrick 的方法在计算几何上还有其他重要应用, 因此, 我们稍微详细地描述一下这个方法。

给定一个含 n 个顶点的平面直线图 G , 根据 Euler 公式, G 最多含 $3n-6$ 条边(G 的顶点平均度数小于 6)。根据抽屉原则, G 中至少一半顶点的顶点度数小于 12。这样一来, 如果我们考虑所有顶点度数最多为 11 的顶点集合 A , 每 12 个这样的顶点中至少有一个不和 A 中顶点相邻, 把这些顶点形成的集合

称作 I , 很显然, $|I| \geq n/24$ 。现在从 G 中删去 I 获得 G_1 (并对相应的非三角形面进行三角化), $|G_1| \leq 23n/24$ 。同理, 从 G_1 中获得 G_2 , 从 G_2 中获得 G_3 这个过程可以一直重复到 G_k , 满足 $|G_k| = O(1)$, 也就是说, G_k 只有常数个顶点。

如果将 G 写作 G_0 , 那么, $G_0, G_1, G_2, \dots, G_k$ 就是对 G 的预处理的数据结构。当然, 在应用这个结构时, 需要将它们的顺序倒过来, 也就是 $G_k, G_{k-1}, G_{k-2}, \dots, G_1, G_0 (= G)$, 这个层次数据结构的大小为

$$n + (23/24)n + (23/24)^2 n + \dots + O(1) = O(n)$$

上述思路可以很简单地应用到凸多面体 P 上 (注意, P 的表面正好是一个平面图), 我们将对应的层次数据结构表示为 $P_k, P_{k-1}, P_{k-2}, \dots, P_1, P_0 (= P)$ 。在判定 P, Q 是否相交时, 我们从 P_k, Q_k 开始, 如果它们相交 (这可在常数时间内判定, 因两者都只含常数个顶点), 马上返回肯定的答案并返回 P_k, Q_k 的一个相交点作为见证点。如果它们不相交, 则需要考虑 P_k, Q_{k-1} 间的相交情况。在基于层次结构的第三个判定 P, Q 是否相交的算法中, 首先利用层次结构及 P 的凸特性计算 P 和一条线段 e 之间的垂直距离 (或返回 P 和 e 相交的见证点), 这可在 $O(\log n)$ 时间内完成。由于 P 的凸特性, P 和 e 不相交时, 它们之间的垂直距离是个分段线性的凸函数。该算法需要在 Dobkin 和 Kirkpatrick 的层次结构上做些相应的调整。

定义 $d(P_i, Q_j)$ 为 P_i 和 Q_j 间的最短垂直距离, 然后该算法从已知 $d(P_i, Q_j)$ 到计算出 $d(P_{i-1}, Q_j)$ (或者汇报 P_{i-1} 和 Q_j 相交并返回一个见证点) 需要 $O(\log n)$ 运算时间, 从已知 $d(P_k, Q_k)$ 到计算出 $d(P_0, Q_0)$ 则需要 $O(\log n)$ 步。所以, 总的运行时间是 $O(\log^2 n)$ 。

如何改进这个问题的算法运算时间? 这个问题已有近二十年没有任何进展, 在三维计算几何中, 这是一个很大的悬而未解的问题, 该问题的难度可能有几种可能: ①问题的下界可能是 $\Omega(\log^2 n)$, 但证明这样的下界以前没有先例; ②层次结构存储的信息可能还不够, 需要设计不同的数据结构; ③层次结构存储的信息可能足够, 但算法运行时没有应用到足够的凸特性。如何最终解决这个问题有待于相关年轻科技工作者的进一步努力。

参 考 文 献

- [1] Chazelle B, Dobkin D. Detection is easier than computation. Proceedings of STOC '80, 1980: 146—153.
- [2] Dobkin D, Kirkpatrick D. A linear time algorithm for determining the separation of convex polyhedra. J. of Algorithms, 1985, 6(4): 381—392.

-
- [3] Cole R. Searching and sorting similar lists .J.of Algorithms ,1986 ,7(3);202—220 .
 - [4] Zhu B. Computing the shortest watchtower of a polyhedral terrain in $O(n \log n)$ time .Computational Geometry :Theory and Applications ,1997 ,8(4);181—193 .

撰稿人：朱滨海

美国蒙大拿州立大学计算机系

基因组间的转位距离

The Transposition Distance between Genomes

自 1990 年开始,由于测序技术的飞速发展,对各种生物(包括人类)的全基因组测序成为可能。在获取各种生物的基因组之后,探求它们之间的进化及遗传关系则成为计算生物学中一个重要但棘手的问题。在数学上,一般采用距离来表示两个基因组之间进化意义上的远近。

经过多年的努力,人们已经知道如何计算基因组间的翻转、易位距离,然而,对于转位距离计算问题却进展缓慢。事实上,人们对这个问题的难度都知之甚少。对这个问题的研究涉及计算机科学、图论及组合数学等多个学科,目前仍是计算生物学中非常热门的一个分支。

我们将一个基因组表示成 1 到 n 的排列 $P = \langle p_1, p_2, \dots, p_n \rangle$, 其中, 每个 p_i 表示一个基因。基因组的一个转位操作表示为选取 P 中任意连续的一段, 如 $\langle p_i, p_{i+1}, \dots, p_j, p_{j+1}, \dots, p_k \rangle$, 在其中某个位置 j 打断后交换两个子串, 也就是从 $\langle p_i, p_{i+1}, \dots, p_j, p_{j+1}, \dots, p_k \rangle$ 变成 $\langle p_{j+1}, p_{j+2}, \dots, p_k, p_i, p_{i+1}, \dots, p_j \rangle$ 。对于两个基因组 P, Q 来说, 其转位距离就是将 P 变换成 Q 的最少的转位操作数目; 对于一个基因组 P , 也可以定义转位距离, 即将 P 变换为原始排列 $I = \langle 1, 2, \dots, n-1, n \rangle$ 的最少的转位操作数目。

1992 年, 加拿大蒙特利尔大学的 Sankoff 研究小组首次采用计算方法精确比较基因组间的距离^[1]。在这之前, 生物学家们一般都是比较基因序列, 或者用手工方法估计简单的基因组之间的距离^[2]。这个研究直接催生了计算基因组学(computational genomics)这个分支; 在此之后, 人们提出了多种距离来衡量基因组间进化意义上的远近, 如翻转、易位等。进入 21 世纪后, 一系列关于非完美基因组距离的研究也有了飞跃性的发展(非完美基因组指的是有缺损或冗余基因的基因组)。

1995 年, 南加州大学的 Bafna 和 Pevzner 在 SODA '95 上发表了关于基因组转位距离计算的第一篇论文, 该文章后正式发表于 1998 年^[3], 文章的主要结果是一个近似比为 1.5 的多项式近似算法。在此之后, 虽然也有一些相关的证明该距离性质的研究, 然而, 计算两个基因组间的转位距离的复杂性仍悬而未解。这个问题是 NP 完全的还是多项式可解的? 即使在计算生物学界, 也没有一个统一的共识。这个问题的复杂性十多年来一直没有任何进展, 可以说, 这是整个计算生物学中最大的悬而未解的问题之一。

与转位距离研究差不多同时开始的其他一些基因组距离计算则取得了长足的进展。我们在这里简单地叙述一下,希望能对读者有所帮助。

跟转位距离关系很相似的翻转距离,在不考虑基因序列的方向时(即限制 p_i 是无符号整数),是 NP 完全的^[4],并且存在近似比为 1.375 的近似算法^[5],最近,相应的参数化算法(FPT algorithm)也已被解决^[6]。而当考虑基因序列的方向时,即 p_i 是有符号整数,该问题是多项式可解的^[7]。上述算法所发展的技术在后续的基因组距离计算中产生了很大的影响。

和转位距离相似的另一种距离是易位距离,这个问题的进展和翻转距离类似。在不考虑基因序列的方向时,问题是多项式可解的^[8];而允许 p_i 是有符号整数时,该问题是 NP 完全的^[9],并且存在近似比为 1.5 的近似算法^[10]及相应的参数化算法^[6]。

转位距离计算是 NP 完全的,还是多项式可解的? 这个问题已有十多年没有任何进展,其难点在于:①在将该问题转换成相应的图论问题时,我们还没有能够找到合适的图表示方案,这和计算翻转及易位距离的情况不太相同;②由于上述的表示原因,在试图证明其 NP 完全性时找不到很合适的 NP 完全问题进行归约。总的来说,人们对这个问题的理解还不够,需要年轻科技工作者的进一步研究。

参 考 文 献

- [1] Sankoff D, Leduc G, Antoine N, et al. Gene order comparisons for phylogenetic inference: Evolution of the mitochondrial genome. *Proc. Nat. Acad. Sci.*, 1992, 89: 6575—6579.
- [2] Palmer J, Herbon L. Plant mitochondrial DNA evolves rapidly in structure, but slowly in sequence. *J. Molecular Evolution*, 1988, 27: 87—97.
- [3] Bafna V, Pevzner P. Sorting by transpositions. *SIAM Journal on Computing*, 1998, 11(2): 224—240.
- [4] Caprara A. Sorting permutations by reversals and Eulerian cycle decompositions. *SIAM Journal on Discrete Mathematics*, 1999, 12(1): 91—110.
- [5] Berman P, Hannenhalli S, Karpinski M. 1.375-approximation for sorting by reversals. *Proceedings of ESA'02*, 2002: 200—210.
- [6] <http://www.eccc.uni-trier.de/report/2010/005/>.
- [7] Hannenhalli S, Pevzner P. Transforming cabbage into turnip: Polynomial time algorithm for sorting signed permutations by reversals. *Journal of the ACM*, 1999, 46(1): 1—27.
- [8] Hannenhalli S. Polynomial-time algorithm for computing translocation distance between genomes. *Discrete Appl. Math.*, 1996, 71(1—3): 137—151.
- [9] Zhu D, Wang L. On the complexity of unsigned translocation distance. *Theoretical Computer*

Science, 2006, 352(1-3): 322-328.

- [10] Cui Y, Wang L, Zhu D, et al. A $(1.5 + \epsilon)$ approximation algorithm for unsigned translocation distance. IEEE/ACM Trans. on Computational Biology and Bioinformatics, 2008, 5(1): 56-66.

撰稿人：朱滨海
美国蒙大拿州立大学计算机系

非阿贝尔群上的隐子群问题

Non-Abelian Hidden Subgroup Problem

自从量子计算的设想由物理学家 Feynman^[1]于 1982 年提出以后,在过去的 30 年间,关于量子计算的研究蓬勃发展起来,一些具有里程碑意义的工作包括 Deutsch^[2]、Bernstein 和 Vazirani^[3]、Yao^[4]、Deutsch 和 Jozsa^[5]等。量子计算最重要的突破出现在 1994 年,Shor^[6]提出了一个大整数分解问题(将一个合数表示成它的素因子的乘积)的多项式时间的量子算法。在经典的计算机上,整数分解问题至今未有任何有效的算法,而它又是公钥密码体系 RSA 的基础,因此,Shor 算法的提出立即在理论界引起了轰动。另一重要的量子算法是 Grover^[7]在 1996 年提出的量子搜索算法,能够将经典计算机上需要 $O(N)$ 时间解决的数组查找问题在量子计算机上用 $O(\sqrt{N})$ 的时间解决。近十几年间,学者们一直致力于寻找除大数分解等以外的其他重要问题,能够在量子计算机上获得有效的解决,但不存在任何有效的经典算法。其中,一个最受学者们关注的备选问题是图同构问题。图同构问题本身是计算复杂性领域中非常重要的一个未解问题,关于它的经典算法的研究已经进行了三十多年,但至今仍未有任何有效的经典算法。图同构问题是我们所要介绍的非阿贝尔群上的隐子群问题(hidden subgroup problem, HSP)的一个特例,对此问题的量子算法研究也已经进行了十多年,但仍未有突破。

隐子群问题最一般性的描述如下:已知黑盒函数 $f: G \rightarrow X$ 将群 G 映射到集合 X ,并且满足:存在 G 的某个子群 $K \leq G$,使得任给 $g, h \in G, f(g) = f(h)$ 当且仅当 $g \in hK$,也就是说,函数 f 在 K 的任一陪集上值都相同,而在 K 的不同陪集上值不同。问题的目标是设计出一个有效的(即多项式时间)量子算法来确定子群 K 。这里所谓黑盒函数是指我们唯一可以访问函数 f 的方式是选取群元素 $g \in G$,并查询 $f(g) = ?$ 除此之外,我们不可以对函数 f 进行其他操作。

当 G 是阿贝尔群时,此问题称为阿贝尔群上的隐子群问题,很多非常著名的的问题,如大整数分解问题等都属于此类,我们会做进一步介绍。对于阿贝尔群上的隐子群问题,借助量子傅里叶变换可以给出一个多项式时间的量子算法^[8]。当 G 是非阿贝尔群时,此问题称为非阿贝尔群上的隐子群问题。其中,最重要的一个例子即图的自同构问题,至今对这一问题未有任何多项式时间的量子算法。

大整数分解问题 输入:正整数 N ;输出: N 的素因子分解 $N=p_1^{a_1} p_2^{a_2} \cdots p_s^{a_s}$ 。例如, $105=3 \times 5 \times 7$ 。大整数分解问题可以很容易地规约到求解如下问题。

求阶问题 输入:正整数 a, N , 满足 $\gcd(a, N)=1$;输出:最小的正整数 r , 使得 $a^r \equiv 1 \pmod{N}$ 。 r 被称为 a 关于 N 的阶。例如, $2^{12} \equiv 1 \pmod{105}$, 即 2 关于 105 的阶是 12。如果取 $G=Z$, 并考虑映射 $f: x \mapsto a^x \pmod{N}$, 由阶的定义很容易看出由函数 f 所定义的隐子群问题中的隐子群 $K=rZ$, 因此, 计算 a 的阶 r 等价于找出隐子群 K 。

图同构问题 输入:图 G_1, G_2 ;输出:如果两者同构, 则输出置换 $\Gamma \in S_n$, 使得 $\Gamma(G_1)=G_2$, 否则, 输出 G_1, G_2 不同构。

目前, 关于图同构问题最好的经典算法的复杂性为 $2^{O(\sqrt{N \log N})}$ [9]。图同构问题可以规约到如下图的自同构问题。

图自同构问题 输入:图 G ;输出: G 的自同构群 $\text{Aut}(G)=\{\Gamma \in S_n \mid \Gamma(G)=G\}$ 的一个生成元集合。如果取群 S_n , 并考虑映射 $f: \pi \mapsto \pi(G)$, 容易看出, 确定图 G 的自同构群 $\text{Aut}(G)$ 等价于找出 f 的隐子群 K 。

带前提的问题: 所要寻找的量子算法只需在满足前提(存在着隐子群 K)的输入上有效即可, 在不满足前提的输入上可以给出任意输出, 算法本身不需要识别输入是否满足前提。这是当前量子算法的一个重要特点, 即往往只在带有前提的问题上才比经典算法更为有效。

参 考 文 献

- [1] Feynman R. Simulating physics with computers. Inter. J. Theoret. Phys., 1982, 21(6,7): 467—488.
- [2] Deutsch D. Quantum theory, the Church-Turing principle and the universal quantum computer. Proc. R. Soc. London Ser. A, 1985, 400: 97—117.
- [3] Bernstein E, Vazirani U. Quantum complexity theory. SIAM Journal on Computing, 1997, 26(5): 1411—1473.
- [4] Yao A. Quantum circuit complexity. Proceedings of the 34th Symposium on the Foundations of Computer Science, 1993: 352—361.
- [5] Deutsch D, Jozsa R. Rapid solutions of problems by quantum computation. Proc. R. Soc. London Ser. A, 1992, 439: 553—558.
- [6] Shor P W. Algorithms for quantum computation: Discrete logarithm and factoring. Proceedings of the 35th Annual Symposium on Foundations of Computer Science, 1994: 124—134.
- [7] Grover L. A fast quantum mechanical algorithm for database search. Proceedings of the 28th Annual ACM Symposium on the Theory of Computing, 1996: 212—219.

-
- [8] Mosca M .Quantum computer algorithms [PhD Dissertation].Oxford ;University of Oxford ,1999 .
 - [9] Luks E M .Isomorphism of graphs of bounded valence can be tested in polynomial time .J . Comput .Syst .Sci . ,1982 ,25 :42 —65 .

撰稿人：孙晓明

清华大学理论计算机科学研究中心

软件性能的自动优化问题

Automatic Tuning of Software Performance

软件性能的自动优化具有重要的应用意义。一般来说,软件性能自动优化可以分为两类:静态优化与动态优化。

静态优化一般通过编译器完成,即不需要执行程序,仅依赖对程序源代码的分析进行性能优化。一些典型的静态优化措施有强度削减(strength reduction)、冗余消除(redundancy elimination)、针对 Cache 进行的数据局部性优化及自动向量化、自动并行化等。虽然软件静态优化可以取得很好的效果,但也有许多缺陷。例如,对程序中复杂的控制流和数据流很难做到精确分析,复杂的内存别名问题使得编译器只能做保守估计,从而丧失潜在的优化机会。

动态优化技术通过程序执行中收集的信息及对程序运行环境的感知,自动进行程序变换、选择算法或参数,可以达到优化程序性能的目标。动态优化的优点是运行时可以拥有许多静态分析时无法确定的信息,并可对执行环境自适应;缺点是获取程序运行信息及在运行时进行优化决策可能会引入性能开销。动态优化技术按优化决策和程序变换的时间不同,可分为在线动态优化技术和离线动态优化技术两类。在线动态优化技术的代表是即时编译技术(just-in-time compilation, JIT),如 Java 语言或脚本语言的 JIT 编译器,在程序实际运行的同时完成优化决策与程序变换;离线动态优化技术的代表是自动调整技术(auto-tuning),主要通过在参考平台上进行试运行来获取信息并调整程序中的可调整优化参数,一旦调整完成,在同一平台上的程序代码就固定下来,不再被继续优化。

本文所指的软件性能的自动优化问题主要指软件性能的动态优化问题,包括以下几个方面:

(1) 软件的哪些部分可以并值得调整?优化软件性能必须找到程序中执行时间较长的程序段,并找出对性能可能产生重大影响的因素进行调整。例如, JIT 技术可以对多次执行的代码进行更加激进的优化;对于线性代数运算库,其优化的重点在于循环展开的参数选取,因此,一些可自动调优的数学库,如 ATLAS^[1,2]就将循环展开参数设为可调整的变量。

(2) 如何感知软件的动态行为特征及预测未来执行的趋势?根据软件自动调优方法不同,运行时所需收集的信息也不同。简单的运行时信息包括程序段的运行时间或执行次数及系统的配置信息等。某些动态优化可能使用比较复杂

的运行时信息,如用程序硬件计数器收集的 Cache 缺失率、分支预测成功率等。此外,观测到的软件动态行为特征是已发生过的行为,而性能优化要针对未来的执行行为,如何预测程序未来执行的趋势是一个难题。

(3) 动态优化中的高效能优化算法。优化算法需要根据运行时收集的信息通过启发式方法确定需要调整的程序算法或参数,达到优化程序性能的目的。离线动态优化算法大多采用迭代搜索的方法,即在调整了程序算法或参数后,重复“执行—收集数据—调整软件”这样的过程多次。在线动态优化则对优化算法的高效能提出了很高的要求。因此,一些在静态优化或离线动态优化中可以使用的算法在在线动态优化中并不能直接使用,否则,会引入过大的运行时开销以至于抵消优化所带来的性能提高,甚至可能引起性能下降。

离线动态优化技术最早是针对科学计算程序提出的一种方法,美国 Argonne 国家实验室是该领域的先驱,他们针对科学计算中广泛应用的线性代数运算库 (LAPACK) 提出了一套基于程序自动优化的解决方案 ATLAS^[1,2]。在这个方案中,程序员只需要在所应用的系统上运行 ATLAS 训练程序,系统就能根据底层硬件的特征,生成适合该平台的高效线性代数运算库,这个工作完全自动地为系统量身定做高性能计算平台,在高性能计算领域得到了广泛应用。

随着多核技术的普及,越来越多的应用得以运用到并行计算带来的便利。然而,并行程序如何高效运行却是一个很难解决的问题。美国加州大学伯克利分校针对各领域内著名的几项并行应用提出了若干个并行程序的基本组成算法,其中,不仅包括了传统科学计算领域所处理的矩阵代数算法,更包括了稀疏矩阵运算、快速傅里叶变换等算法,他们通过软件离线自动优化技术将这些程序的特性进行归纳总结,并取得了优异的性能^[3]。

近年来,众核处理器和图形加速器开始普及,并逐渐成为研究的热点。众核处理器能带来无与伦比的加速比,但其程序却很难编写,而最为困难的是将程序进行优化,使其能充分发挥众核的威力。针对这个现状,伊利诺伊大学的 IMPACT 组提出了采用自动程序优化的方法,自动挖掘程序的性能优化空间^[4]。这个问题的难点在于:由于众核处理器的优化空间非常庞大,要在有限时间内挖掘出所有可能的组合是一个 NP 完全问题。该研究组经过细致的观察,提出了优化空间剪枝技术,有效地减少了优化迭代的次数。在这个研究之后,在众核处理器上自动优化的工作如雨后春笋。各种常用的数学库、图形库都通过自动优化在众核处理器上取得了令人瞩目的加速比^[5,6]。然而,关于离线自动优化的问题远没有完全解决。很多研究还在关注于如何获得合理的性能预测模型,以及更有效地对搜索空间进行裁剪。

离线动态优化技术主要适用于科学计算程序,其特点是循环时间占整个程序执行时间的绝大部分,可调整的部分主要集中于循环展开参数等,或一些运

行时参数如并行线程数等。对于非科学计算程序,如 Java 程序及近年来广泛流行的动态语言(如 JavaScript、Python、Perl 等),以 JIT 为代表的在线动态优化技术是主要的优化方式。JIT 技术的主要难点在于平衡优化算法的开销与效果,以及运行时程序特征信息的低成本获取。硬件计数器通过采样方式可以获得较为精确的信息,同时引入的开销较小,适用于动态优化技术,是一种比较有前景的运行时信息获取方法。

此外,并行计算与多核技术给在线优化提出了新的问题,如如何利用运行时信息优化将并行进程映射到处理器核上,如何利用动态调度的方法缓解并行程序负载不均衡对性能的影响等,这些都是值得研究的课题。

参 考 文 献

- [1] Whaley R C, Petitet A. Automated empirical optimization of software and the ATLAS project. *Parallel Computing*, 2001, (1-2): 3-35.
- [2] Demmel J, Dongarra J, Eijkhout V, et al. Self-adapting linear algebra algorithms and software. *Proceedings of the IEEE*, 2005, (2): 293-312.
- [3] Williams S W. Auto-tuning performance on multicore computers [PhD Dissertation]. Berkeley: University of California, 2008.
- [4] Ryoo S, Rodrigues C I, Stone S S, et al. Program optimization space pruning for a multithreaded GPU. *Proceedings of the 6th International Symposium on Code Generation and Optimization*, 2008, (1): 195-204.
- [5] Nukada A, Matsuoka S. Auto-tuning 3-D FFT library for CUDA GPUs. *Proceedings of the Conference on High Performance Computing Networking Storage and Analysis*, 2009, (1): 1-10.
- [6] Choi J W, Singh A, et al. Model-driven autotuning of sparse matrix-vector multiply on GPUs. *Proceedings of the 15th ACM SIGPLAN Annual Symposium on Principles and Practice of Parallel Programming*, 2010, (1): 115-126.

撰稿人: 郑纬民 陈文光 陈德颢
清华大学计算机科学与技术系

软件可测度性及度量

Software Measurement and Metrics

软件度量对于软件生命周期中的定量管理与决策具有十分重要的作用，它是理解、评价、预测、控制和改进软件系统质量的一种重要手段。在四十多年的发展历程中，学术界的研究人员已经提出了许多度量元。其中，典型的度量元包括常规的代码行数、McCabe 的圈复杂性和 Halstead 软件科学法中的长度和容量等度量^[1,2]。20 世纪 90 年代，随着面向对象技术的逐步流行，人们提出了与内聚性、耦合性和继承特性相关的面向对象度量^[3,4]。在度量元的基础上，人们开发了许多定量的度量模型，以支持软件生命期中的定量管理和决策。70 年代，人们在代码行数等度量元的基础上开发了许多回归模型，用于预测代码中的缺陷数目^[5]。80 年代初期，Boehm 等开发了著名的 COCOMO 模型，用于估算开发工作量和进度^[6]。90 年代，Boehm 等针对面向对象程序提出了 COCOMO II 模型^[7]。近期，随着机器学习方法的兴起和流行，人们又提出了许多基于机器学习的质量预测模型^[8]。尽管学术界已经提出了大量的度量元和度量模型，然而，绝大多数并没有被工业界真正使用^[5]。实际上，工业界当前主要使用的仍然是那些 60 年代后期提出来的代码行数、缺陷数目和人月工作量等非常容易理解和收集的简单度量元和在此基础上的回归度量模型^[5]。如何在实际的软件开发活动中真正地应用好软件度量，以有效支持软件生命周期中的定量管理与决策已成为一个非常重要的问题。

在实际的软件开发活动中，人们经常遇到开发进度和成本估算不准确、开发的软件质量不高和开发生产率提高的速度跟不上迅速增长的软件需求等问题。为了解决这些问题，人们必须能够更有效地进行软件管理。软件度量是对软件开发资源、过程及其产品进行数据定义、收集及分析的持续性定量化过程，能够支持软件开发过程中的预测、评价和决策活动，从而有助于进行风险分析并减少风险^[9,10]。

如表 1 所示，资源、过程和产品的属性有内部和外部之分，内部属性通常可以直接度量，外部属性一般很难直接度量。根据文献^[10]，基于度量元的预测模型可以划分为 4 类：①第一类利用早期产品的内部属性预测后期产品的内部属性，如用规约的规模、模块化等度量信息预测代码的规模和结构化程度等；②第二类利用早期过程/资源的属性来预测后期过程/资源的属性，如用设计审查中发现的缺陷数目来预测实现的成本；③第三类利用产品的内部属性来预测

过程属性，如用结构化程度来预测进行维护所需要耗费的时间；④第四类利用早期的过程信息预测后期产品的属性，如用运行期间的失效度量来预测产品的可靠性。

表 1 软件度量活动分类

实体	属性	
	内部	外部
资源		
团队	规模、结构化程度……	生产率、质量……
软件	价格、规模……	易用性、可靠性……
硬件	价格、速度、存储器大小……	可靠性……
……		
过程		
构造规约	时间、工作量、需求变更数目……	质量、成本、稳定性……
详细设计	时间、工作量、检测到的规约故障数……	成本、成本-效益比……
测试活动	时间、工作量、检测到的代码故障数……	成本、成本-效益比、稳定性……
……		
产品		
规约	规模、模块化、功能、语法正确性……	易理解性、易维护性……
设计	规模、模块化、耦合性、内聚性……	质量、易维护性……
代码	规模、模块化、耦合性、内聚性……	可靠性、易用性、易维护性……
……		

为此，我们必须首先定义合理的度量元来量化内部属性，然后利用合适的建模技术建立度量模型。在理想情况下，度量元应该具有能够精确定义、客观性强、收集成本低和预测能力强等特点，度量模型应能有效地捕获自变量和因变量之间的复杂关系。然而，现有的度量元预测能力不强，现有的度量模型难以同时有效处理定性和定量的度量元，难以建模真正的因果关系，难以表达估算/预测结果的不确定性，因此，难以支持软件开发活动中的风险分析并减少风险。如何开发预测能力强的度量元及有效的度量模型，支持软件生命周期中多种预测、评价和决策活动是当前急需解决的一个难题。

软件度量的主要目标是为了能够在软件开发活动中进行各种各样的有效预测，从而支持风险分析并减少风险。然而，时至今日，人们对软件的许多特性认识仍然不够深入，因此，也很难开发出准确刻画软件属性的度量元。在许多研究工作中，经常会出现同一个度量元被用来刻画不同软件属性的情况。在真实的软件开发活动中，我们需要基于度量的预测模型能够处理多种多样的度量信息、建模真正的因果关系、刻画估算/预测结果的不确定性和处理不完备的度量信息等问题。然而，传统的基于度量的预测模型使用统计回归建模技术，对所使用度量的标度及所建模的关系都存在一定的限制和约束。近年来，一些研

究人员尝试利用机器学习方法建立预测模型,特别是 Fenton 等提出利用 Bayes 网络建立预测模型^[5]。但总体上,这些技术是否能够真正解决软件生命周期中多种预测、评价和决策活动,仍然有待进一步的研究和评价。

工业界迫切需要知道在工业级规模和复杂程度的软件系统中度量元的各种特性,如度量元的基准值和阈值等,以便帮助开发和维护人员识别、监控和改进有问题的模块。然而,当前的实验验证集中在一小部分度量元上,对绝大部分度量元只进行了理论分析而没有进行实验验证。特别地,大多数实验验证研究只使用了少量的软件系统,甚至是由学生开发的系统,其规模和复杂性与工业界实际的软件规模和复杂性相距甚远。因此,这些研究所得出的结论是否具有代表性也值得商榷。更进一步,许多结论都是在单个实验上得出的,没有后续的实验来检验这些结论的通用性,这些问题使得软件度量在学术界的研究和工业界的应用之间产生了一个相当大的鸿沟,急需在将来的工作中解决。

参 考 文 献

- [1] McCabe T J. A complexity measure. IEEE Transactions on Software Engineering, 1976, 2(4):308—320.
- [2] Halstead M. Elements of Software Science. New York:Elsevier, 1977:1—127.
- [3] Briand L C, Daly J W, Wüst J. A unified framework for cohesion measurement in object-oriented systems. Empirical Software Engineering, 1998, 3(1):65—117.
- [4] Briand L C, Daly J W, Wüst J. A unified framework for coupling measurement in object-oriented systems. IEEE Transactions on Software Engineering, 1999, 25(1):91—121.
- [5] Fenton N E, Neil M. Software metrics: Success, failures and new directions. Journal of Systems and Software, 1999, 47(2—3):149—157.
- [6] Boehm B W. Software Engineering Economics. New Jersey:Prentice Hall, 1981:57—164.
- [7] Boehm B W, Abts C, Brown A W, et al. Software Cost Estimation with COCOMO II. New Jersey:Prentice Hall, 2000:12—82.
- [8] Menzies T, Greenwald J, Frank A. Data mining static code attributes to learn defect predictors. IEEE Transactions on Software Engineering, 2007, 33(1):2—13.
- [9] Purao S, Vaishnavi V. Product metrics for object-oriented systems. ACM Computing Surveys, 2003, 35(2):191—221.
- [10] Fenton N E, Pfleeger S L. Software Metrics: A Rigorous & Practical Approach. 2nd ed. Boston:PWS Publishing Company, 1997:3—72.

撰稿人: 徐宝文 周毓明
南京大学计算机科学与技术系

软件质量保证承诺

Software Quality Warranty

计算机软件产品已经和其他工业产品一样深入渗透到现代社会生活的各个方面,因此,其质量也就越来越重要,但其与普通工业产品不同之处在于:软件产品目前几乎不能提供明确的质量保证书。普通工业产品通常都有质量保证书,声明产品满足某些行业标准,并且生产厂商会对产品的质量问题的质量问题的责任,如包退包换或者赔偿部分损失等,但目前绝大部分软件产品的用户协议中都带有这样或类似的免责声明:软件生产商不对软件使用过程中产生的任何损失负责。目前,人们已经习惯于在使用软件产品时接受这种不公平的协议,主要归因于:①软件是人类思维的复杂产物,软件质量保证技术目前远不如其他工业产品的质量保证技术成熟,软件质量保证成本难以承受等诸多方面;②计算机系统中软件总是和硬件及其他软件协同工作,当系统出现问题时,人们很难界定究竟是软件的原因还是硬件的原因。

如果仅从用户的角度来看,软件的质量是指软件能够在何种程度上满足:①明确描述的功能和效率需求;②虽未明确描述,但规范的软件都应该满足的需求,如软件不会死机、崩溃等。

为了评估软件的质量,人们建立了各种软件质量评估模型。但是,这些模型通常使用一些间接量(如代码行数、代码复杂度、文档是否完整等)来判断软件的质量。依靠这些间接量不可能准确推断软件的质量。从某种意义上来说,软件产品的质量决定于开发过程中使用的能够直接检测评价软件质量的技术。在普通工业产品的生产过程中,人们可以通过一些装置和手段客观地检测原材料和中间产品是否满足相应的标准(如杂质含量等),从而保证最终产品的质量,但软件开发过程中的质量保障手段很难做到这一点。

在一个计算机系统中,软件产品和硬件及其他软件紧密协同,完成相应工作。软件产品不能正确运行的原因可能是其中包含错误,也有可能是硬件或其他软件失效导致这个软件产品给出错误的结果。人们获得软件质量保证承诺的前提是有适当的技术来确定问题的源头。因此,我们的问题是:各种软件质量检验技术能够在何种程度上保证软件的质量?这些技术应该发展到什么程度,软件产品才可以和普通工业产品一样拥有质量保证书?人们如何确定问题来自于软件自身并要求软件生产商承担相应的责任?

有关软件质量保证承诺的问题也可以这样描述:

(1) 软件质量保证承诺应该包含哪些内容?

(2) 假设软件产品(或其中间产品)P 的需求规范是 S, 我们使用某种技术/工具/方法来检测 P 是否满足 S。根据检测结果, 能否精确判断 P 的质量? 将来是否会出现一种检测技术/方法使软件生产商可以/愿意给出软件的质量保证承诺?

(3) 当用户在计算机系统中使用软件产品时出现问题, 人们怎么能够断定问题的根源是该产品中的错误, 而不是其他子系统或硬件中的错误。

软件质量保证承诺书显然应该包含对软件功能的承诺, 除此之外, 还应该包括一些其他度量, 如平均无故障时间、平均反应时间、最坏反应时间等。因为软件产品的多样性, 对所有软件产品采用同样的标准显然是不可行的。人们需要为不同类型的软件制定不同的标准, 规定软件质量保证承诺中必须包含的内容。只有这样, 质检机构才能够据此检验软件的质量, 而用户也能够根据这个承诺书作出相应的决定。

在软件质量保证技术方面, 当前能够直接检测软件质量的技术主要可以分成三大类: 软件测试、软件静态分析和形式化验证。

(1) 软件测试^[1]是最常用的软件质量检测技术, 它通过设定输入数据, 实际运行软件, 分析输出结果, 判断软件是否满足需求。但是, 软件测试只能发现错误, 不能保证软件中不包含错误。虽然人们定义了很多测试充分度标准来保证软件测试能够检出足够多的错误, 但测试充分度并不能够直接保证软件满足需求。当前的研究主要集中在降低测试成本和提高测试效能方面, 包括测试数据的生成、测试执行的自动化等。另一种使用测试来评估软件质量的方法是在测试中模拟软件的实际使用情况, 并通过对测试数据结果的分析, 以随机过程理论来推算软件的可靠性^[2]。但是, 这个方法只适用于特定类型的软件系统, 而且测试费用很高。

(2) 软件静态分析技术是在不运行程序的情况下, 通过对源代码的分析来确定软件可能包含哪些潜在的错误(如死锁、内存泄漏等)。这类分析技术能够发现某些类型的错误, 帮助开发人员提高软件的质量。但是, 静态分析技术对于判断软件质量的作用并不大。

(3) 形式化验证方法试图通过数学理论来保证软件的正确性, 分成两大类: 模型检验技术和定理证明技术。模型检验技术^[3]对软件系统模型的状态空间进行穷尽遍历, 确定模型是否满足特定性质。模型检验技术给出的结论是确定性的, 即模型检验可以明确判定系统模型满足某个性质的。因此, 模型检验技术可以有效提高人们对软件质量的信心。但是, 模型检验技术有两个缺点: ①被检验的是系统的抽象模型, 不是软件系统本身, 这影响了模型检验结果的有效性; ②当系统模型的规模增大时, 模型检验过程所需要的 CPU 时间和内存空间爆炸性增长。在模型检验技术方面, 人们的研究主要集中于抽象模型的抽取技术及降低时间/空间需求的技术。定理证明技术的主要思想是使用逻辑公式来描述程

序需要满足的需求,并通过公理系统来验证代码是否满足这个需求。一阶逻辑公式可以描述很多功能性需求,同时证明过程可以明确地判断代码满足需求。最早对于代码验证技术的研究来自于 Floyd^[4]和 Hoare^[5]。但是,这些理论不能处理很多程序结构,如指针、过程调用、多态等,且自动化程度低,这使得代码的形式化验证技术主要是在研究人员中使用。

软件质量保证的另外一个思路是综合运用上述各种技术,把它们的检测结果作为指标,和成熟软件的相应指标进行比较,从而确定软件的相对质量,但这种方法尚需进一步研究,主要需要解决的问题包括各种指标的设定和适应性、质量比较过程的客观性,以及这些指标能够在多大程度上保证软件的质量。

综上可知,现在没有普遍适用、费用适当的技术来确定性地保证软件的质量。只有当人们发明了这样的技术之后,软件产品才可能带有质量保证承诺书。

我们还需要能够明确界定计算机系统产生错误的原因,以便人们能够依据承诺书来要求软件生产商承担责任。解决这个问题有两个思路:①类似于飞机黑匣子的方式,在系统运行时记录系统运行的关键数据,并以此为基础来判断问题原因;②通过错误重现的方式来确定问题的原因。第一种方式会大大加重计算机的负载,影响系统效率,且导致系统的设计更加复杂。因为计算机系统的复杂性和错误出现的偶然性,错误很难被重现,因此,第二种方法也不能够完善地解决问题。

上面的讨论仅仅涉及软件质量保证承诺的技术层面。实际上,软件产品是否能够带有质量保证书还涉及社会、法律、经济等层面,但这些超出了本文讨论范围,不在此讨论。

参 考 文 献

- [1] Myers G J, Badgett T, Thomas T M, et al. The Art of Software Testing. 2nd ed. New Jersey: Wiley, 2004.
- [2] Musa J. Software Reliability Engineering. New York: Osborne/McGraw-Hill, 1998.
- [3] Clarke E, Grumberg O, Peled D A. Model Checking. London: MIT Press, 1999.
- [4] Floyd R W. Assigning meanings to programs. Proceedings of the American Mathematical Society Symposia on Applied Mathematics, 1967, 19: 19—31.
- [5] Hoare C A R. An axiomatic basis for computer programming. Communications of the ACM, 1969, 12(10): 576—580, 583.

撰稿人: 赵建华 王林章 卜 磊 陈 鑫 张 天 李宣东
南京大学计算机科学与技术系

静态分析与形式验证

Static Analysis and Formal Verification

程序员写好一个程序后，我们需要了解这个程序是否具有我们期待的性质（或者不具有某些坏的性质，如空指针引用、整数溢出等）。因此，计算机科学中一类很重要的问题是：给定一个程序，判断它是否具有某种性质。

对绝大多数程序员来说，通常采用测试方法，在一定程度上判断程序的性质。人们可以设定一些测试数据，动态地执行程序，检查程序中是否包含错误。但是，测试只能发现错误，不能够证明程序没有错误；而且，由于程序的输入空间通常都很大，动态测试只能检查程序在少数情况下的行为。要想提高发现错误的概率，需要运行程序很多次，并且要有好的测试用例集。

1. 形式验证

在理想情况，我们应该严格地、形式化地证明程序的正确性，就像证明数学定理一样。我们可以定义程序设计语言的形式语义（即精确定义每个语句的效用），并推理/计算出整个程序的语义，以验证程序的正确性。事实上，在计算机科学发展初期，计算机界的先驱图灵自己就曾证明过一个程序的正确性^[1]。此后，多位图灵奖获得者的主要贡献都与形式验证相关。

为了描述程序的性质，人们往往使用一阶谓词逻辑、高阶逻辑和递归函数等数学手段。要判断一个程序是否满足这些性质，人们需要使用一定的推理技巧来进行判断。对于一个完成某种计算过程的程序，我们可以使用前/后置条件来描述这个程序的规约（即程序必须实现的功能），即如果当前状态满足前置条件时执行这段程序，在程序执行完毕时程序状态应该满足其后置条件。人们通常通过推导的方式来判断程序是否满足这个规约。一个经典的推理系统是 Hoare 逻辑^[2]。虽然这种推理过程能够完全、准确地判断软件是否满足其规约，但过程通常过于复杂，很少在实际的软件开发中被使用。

目前，基于逻辑推理的形式验证，其自动化程度还不高，但也有一些如证明检查器这样的辅助工具，在这些工具的支持下，具有足够训练的科研人员也能对一些比较复杂的软件系统或关键模块（如操作系统内核）进行一定程度的验证^[3]。

如何建立易于使用、强大并且高效的推理系统是人们一直在追求的目标。

2. 静态分析

对于大多数程序来说,严格证明其正确性的推理过程非常复杂,无法自动完成,即使手工完成也非常费时费力。另一种途径是:建立程序设计语言的抽象语义(即各个语句在某个方面的作用),进行一定的近似推理,自动得到整个程序的抽象语义,并进一步判断这个程序是否具有某些特定性质。这就是程序的静态分析。

对于本文一开始提到的一般形式的问题,可以进行各种具体化。程序可以是各种各样的,性质也可以是各种各样的。人们关心的是,对于什么类型的性质,我们可以对给定程序进行高效分析,确定它是否具备一些我们关心的性质。

就性质而言,我们可以描述程序的好的性质,如终止性(程序的任何执行都是有限的)、功能正确性,也可以描述它的不好的性质,如作为除数的某个表达式在程序执行过程中可能为 0。程序的性质既可以是一般性的、通用的性质(如终止性、指针不悬空),也可以是与该程序所处的应用环境特别相关的(如人的年龄不能为负数,也不能大于 200)。

我们可以对程序加以一定的限制。例如,假定每个变量都在有限范围内取值,从而得到有限状态程序(这里说的“状态”是所有变量的一种可能的取值)。另一种特殊情形是只考察程序的一条路径。

从理论上讲,很多形式验证问题是不可判定的。例如,在一般情况下,程序终止性问题就是个不可判定的问题。但是,通过对程序行为进行自动地抽象、近似,还是能静态地获取该程序的一些相关性质。常见的静态分析手段包括以下几种:

(1) 指针别名分析与指针指向分析。所谓指针别名现象,是指程序的两个指针指向同一块内存区域。现在,人们可以通过软件工具高效地判断两个指针是否可能存在别名现象。指针别名分析的结果可以被用于编译器的优化、程序理解、程序并行化等方面,也是其他很多静态分析的基础。因此,人们总是设法尽可能地区分不存在别名现象的指针。同时,为了能处理大规模的程序,人们还希望能尽量降低分析算法的复杂度。例如,Steensgaard 算法^[4]就是一种高效率的指针分析算法,但分析结果的精确性和分析效率之间存在矛盾。很多研究者试图以各种方式高效地获得可接受的分析精度。

(2) 空指针引用/悬空指针引用分析。所谓空指针引用,是指程序试图通过一个 null 指针来访问内存,而悬空指针引用是指程序试图访问一个指向已释放内存区域的指针。这两种情况都会导致程序得出错误的结果,甚至引起系统崩溃。同样,人们不可能自动分析出所有的错误引用,但通过对程序的数据流和控制流的分析,我们仍然可以发现一些这样的引用,帮助程序员改正错误。

(3) 形态分析。即分析程序中动态创建、相互连接的数据结构的形状特性^[5]，它是一种更加精确的指针指向分析，通过更加灵活的方式来确定指针所指向的对象，可以被用于内存泄露、内存块的多次释放等异常情况的检测。

(4) 可执行路径分析。即分析程序的某条路径是否可能被执行。我们可以通过符号执行方法，分析这条路径上各个变量取值的变化情况，得到一组约束条件，并通过求解这些约束条件来判断这条路径是否可能被执行。

除上述问题之外，还有很多其他问题。例如，判断程序中的数组下标表达式是否可能越界，在此就不一一赘述了，可参看文献[6]。

从理论上讲，很多分析和验证问题在最一般情况下都是不可判定的。因此，很多静态分析方法先对被分析的软件行为进行抽象，研究其特定性质。但是，抽象模型的建立过程可能会引入偏差，导致检验结果不准确，这种偏差有两种可能：静态分析工具不能确定某些程序实际上具有的某个性质；静态分析工具报告程序可能包含某个错误，而程序实际上是正确的。后一种情况被称为假报警^[7]。这两种情况都影响了静态分析工具的进一步应用。如何尽量提高程序静态分析结果的精度，同时控制分析算法的复杂度，是静态分析研究的一个重要目标。

参 考 文 献

- [1] Morris F L, Jones C B. An early program proof by alan turing. IEEE Annals of the History of Computing, 1984, 6(2): 139—143.
- [2] Hoare C A R. An axiomatic basis for computer programming. Communications of the ACM, 1969, 12(10): 576—580.
- [3] Klein G, et al. SeL4: Formal verification of an operating-system kernel. Communications of the ACM, 2010, 53(6): 107—115.
- [4] Steensgaard B. Points-to analysis in almost linear time. ACM Symposium on Principles of Programming Languages (POPL), 1996: 32—41.
- [5] Wilhelm R, Sagiv M, Reps T W. Shape analysis, compiler construction. Springer Lecture Notes in Computer Science, 2000, 1781: 1—17.
- [6] 梅宏, 王千祥, 张路, 等. 软件分析技术进展. 计算机学报, 2009: 1697—1710.
- [7] Zitser M, Lippmann R, Leek T. Testing static analysis tools using exploitable buffer overflows from open source code. ACM SIGSOFT International Symposium on Foundations of Software Engineering (FSE), 2004: 97—106.

撰稿人：赵建华¹ 张 健²

1 南京大学计算机科学与技术系

2 中国科学院软件研究所

软件需求的自动获取

Automatic Software Requirements Acquisition

软件需求是软件系统必不可少的属性,它是标识待开发软件系统能力、特征和质量因素的陈述。是否能正确地获取到对软件的需求,是软件开发的关键,是使所开发出来的软件对客户或用户有价值的保证^[1,2]。

获取到正确的软件需求本身是一个困难的任务,所获得并表达出来的需求描述既要完整准确,又要具有一定的灵活性。一方面,完整准确的软件需求将作为所有后续软件开发活动(包括系统设计、开发、测试、实现和运行等)的基线^[3]。另一方面,软件需求要表达真实的客户需要,以保证开发出来的软件系统对客户有价值,而大部分情况下,现实的需求固有地是动态的。特别地,Internet 环境促使许多新型软件开发和应用模式(如面向服务的计算、软件即服务等)诞生,这些新型计算模式中,软件系统不再仅仅是为固定的用户开发,还需要面向具有不同价值目标的用户群体。软件需求具有多目标性、不确定性和不一致性,而且还隐含地存在包括可用性、可靠性、隐私性、安全性等可信性质的要求,这些功能的和非功能的、显式的和隐式的要求,在不同用户群体中和不同应用场景下都可能具有不同的含义,表现为对软件能力期望的动态变化性、不可预知性和固有的不一致性。这基本上是传统的依赖系统分析员手工需求获取方式无法解决的。

Internet 的出现使计算机软件操作环境从静态封闭走向动态开放,软件系统呈现出一种柔性、多目标、连续反应式的新系统形态。对这类软件系统的需求同时也具有动态性、时变性、不一致性、不确定性和灵活性,这些性质要求能够准确地捕获到用户对软件的真实需求,有时甚至需要能预测用户潜在的需求,因而给软件需求获取方式带来极大的挑战,软件需求获取需要智能化和自动化的手段,这是软件需求自动获取问题提出的背景。

Internet 环境下的软件需求自动获取问题可以从以下三个方面来解析:

(1) 基于应用场景的显式/隐式软件需求的自动发现、自动建模和分析,以及自动规约和验证。这涉及软件需求自动获取的一次完整过程,需要能够快速、自动地从特定应用场景中发现出对软件能力的期望,并通过分析、建模、规约、验证等手段,准确并正确地表达出与这个应用场景相适应的软件需求。

(2) 软件需求随用户群体的变化、应用场景的迁移等演化。这涉及满足软件需求的时变性要求,涉及当用户群体及其价值取向发生变化时,或者应

用场景发生迁移的时候,软件需求实时动态调整,以及重建模和重规约等。

(3)来自不同用户群体的软件需求的融合和基于价值取向的需求不一致性处理。这涉及软件需求的多目标性,即当不同用户群体对软件能力有不同期望时,如何综合这些不同来源的期望,解决其中可能存在的术语不一致、抽象层次不一致、表达粒度不一致等;还涉及当这些不同期望之间存在冲突的时候,如何根据用户群体的优先价值取向进行冲突消解等。

除了一些经典的纯手工获取(如头脑风暴法、面谈法、问卷法、组开发方法等)方法^[4]外,需求工程界提出了一些需求工程方法,如面向目标的方法^[5]、基于主体和意图的方法^[6]、问题框架方法^[7]等,这些方法分别提出了各自的软件需求获取理念和原则,提出了与其理念一致的需求表达元模型,同时,根据各自的理念和需求表达元模型,开发了相应的需求获取过程。这些工作针对什么是软件需求、什么是期望的软件能力等根本性问题进行了探索,使得需求获取及需求建模和分析有了概念层次上的依据。同时,它们还提供了可遵循的过程和相应的支撑工具,使需求获取有可能从纯手工的完全依赖系统分析员经验的方式,进入到可采用计算机辅助进行的工程化或自动化方式。但是,这些工作主要关注封闭式软件系统的需求获取,基本没有考虑 Internet 环境下开放式软件系统的性质。

为提供支持软件需求获取自动化的技术手段及其理论支撑,有如下几个可能的切入点:①在理论层面,需要从软件作为现实系统的部分观点出发,研究什么是软件能力,软件可能具有什么样的能力,软件能解决现实世界的什么问题,是否可表达可规约的问题模式等;②在技术层面,研究软件能力的描述,以及能力分解和组合方法,研究结合用户价值取向的冲突检测和处理方法,以及应用场景驱动的能力演化方法等;③在实现层面,进行深层次的领域建模和领域工程^[8],针对特定领域的并结合现实世界应用场景,研究并开发多层次、可共享并有一定规模的软件能力本体,支持软件需求的重用。

当然,如何识别和确定软件需求不仅是软件开发的问题,其中的许多问题,如需求的边界、需求的不一致性和冲突消解等,与人的因素和社会文化密切相关,需求获取中人的参与是不可缺少的,特别是针对复杂软件系统,要实现需求自动获取几乎是不可能的,任何自动的方法和技术都只是需求获取过程中的辅助手段。

参考文献

- [1] Kotonya G, Sommerville I. Requirements Engineering: Processes and Techniques. New York: Wiley, 1998.

- [2] Loucopoulos P, Karakostas V. System Requirements Engineering. New York: McGraw-Hill, 1995.
- [3] Robertson S, Robertson J. Mastering the Requirements Process. New York: Addison-Wesley, 1999.
- [4] Laplante P A. Requirements Engineering for Software and Systems. Redmond: CRC, 2009.
- [5] van Lamsweerde A. Requirements Engineering: From System Goals to UML Models to Software Specifications. New York: Wiley, 2009.
- [6] Chung L, Nixon B A, Yu E, et al. Non-Functional Requirements in Software Engineering. New York: Kluwer Academic Publishers, 2000.
- [7] Jackson M. Problem Frames Approach: Analyzing and Structuring Software Development Problems. New York: Addison-Wesley, 2001.
- [8] Lu R, Jin Z. Domain Modeling based Software Engineering: A Formal Approach. New York: Kluwer Academic Publishers, 2000.

撰稿人: 金 芝

北京大学信息科学技术学院

软件系统复杂性控制

Conquer System Complexity of Software

软件复杂性一直是制约软件高效与正确开发、运行的重要因素之一，控制软件复杂性是驱动软件方法学与技术体系不断向前发展的主要动力之一。20 世纪 70 年代兴起的结构化方法学与技术体系就是由于计算机基础能力快速发展和软件复杂性失控而导致人们对基础的程序设计方法和语言的科学思考和具体实践而产生的；20 世纪 80 年代兴起而至今仍为主流的面向对象方法学与技术体系则是在结构化方法学与技术体系的基础上，进一步利用和发展了从宏观角度控制软件复杂性的手段，如关注分离、信息隐蔽、模块化等，提出了与问题结构具有良好对应关系的对象式程序模型的概念与支撑机制^[1,2]。然而，从 Internet 平台和开放应用的角度，面向对象方法学与技术体系主要是针对集中可控环境而言的；而在 Internet 开放、动态、多变环境下，影响软件开发的主要因素已经发生了重要的变化，基础平台已经从单个或多个可控计算机向开放的 Internet 平台发展，其主要作用已经从“计算为主”逐步向“通信连接为主”的方面转变；设计方式已经开始从“面向个体程序员”向“群体化和服务化方式”过渡；问题空间已经从确定环境下单个问题求解到开放环境下的群体问题求解，开始向非确定环境下如何为大量最终用户提供优质服务的方面发展，从而推动了面向 Internet 软件方法学与技术体系的研究与探索。

所谓软件复杂性，是指由于软件规模不断变大和其所处外部环境的非确定性而导致构成软件系统的各个组成部分之间的交互异常复杂，使得软件系统难以理解、构造、维护，进而阻碍软件开发效率的提高和软件质量的保障。控制软件复杂性主要就是通过各种度量手段加深对复杂性的理解，通过各种开发方法来辅助软件系统的构造与维护，通过各种测试与验证手段来保障软件系统的质量。在 Internet 时代，软件复杂性又有了新的表现形式与特征，对软件方法学与技术体系提出了更为严峻的挑战。软件复杂性的主要表现为：①规模复杂性。程序代码长，成百上千万行程序代码的软件屡见不鲜。②交互复杂性。程序由大量的组件所构成，且各个组件之间的交互关系复杂，通常会产生涌现行为。③演化复杂性。开始在静态演化性的基础上考虑如何以动态演化性来适应基础平台和用户需求的变化。④平台复杂性。软件开发、部署和运行平台开始从封闭、静态、可控逐步走向开放、动态、多变。⑤保障复杂性。希望能够在正确性、可靠性、安全性、可生存性、时效性、可维性等各种需求基础上权衡主观

与客观、绝对与相对、静态与演化、计算与社会等诸多因素,为软件系统提供适合与综合的可信保障。⑥形态复杂性。复杂软件系统通常表现为大型系统和超大规模系统等,从更为广泛的角度,软件还会在嵌入式系统、混成系统、信息物理融合系统中起到关键作用。⑦应用复杂性。随着支撑软件开发与运行平台的发展,软件需要在普适计算、网格计算、云计算等各种各样的应用模式下发挥作用。上述各种因素的综合作用已经形成了所谓的复杂性障碍,控制软件系统复杂性已经成为推动信息技术进一步广泛应用的大挑战问题之一^[3]。

控制软件系统复杂性的主要环节是在从数据复杂性、数据流复杂性、数据存取复杂性、判定复杂性和分支复杂性等多个角度对软件复杂性加以理解与度量的基础上,将对复杂性的控制体现在软件构造、运行支撑和演化机制等方面。近年来,国外学者提出了诸如全球泛在计算机、资源开放联盟、软件主体、自治式程序设计等新概念与新机制,体现了“基本理念开放化、软件实体主体化、软件协调分离化、运行机制自适应、开发方法群体化、外部环境显式化、质量保障可信化、系统管理自治化”的发展趋势,从而为理解和控制软件复杂性提供了新的视角与途径^[4~6]。控制复杂性的主要研究内容涉及大规模复杂系统的设计与演化机理、大规模复杂系统的编排与控制方法、大规模复杂系统的检测与评价技术、复杂自治式系统的基本机理、复杂自治式系统的体系结构、复杂自治式系统的联盟机理、涌现行为的理解与控制、多主体系统中学习机制、多主体系统的协同机制、面向复杂系统的计算模型程序设计语言等。我国学者提出了网构化软件方法学与技术体系的途径来解决 Internet 时代所面临的软件复杂性问题,他们首先系统分析了 Internet 平台和各种新型应用模式与系统的特征,抽象提炼出一种新的软件系统形态,即网构软件的概念。在网构软件意义下,软件系统以主体性、协同性、反应性、演化性和多态性而呈现出一种柔性、多目标、连续反应式的新系统形态。以网构化软件形态作为目标导向,他们进一步提出了网构化软件范型的基本框架。以此框架为指导,按照开放协同模型 c 环境驱动模型 c 智能可信模型三个步骤来系统探讨如何从软件结构模型与方法学的角度来控制软件复杂性的问题。其中,开放协同模型是基础,它将突破经典封闭可控模型的限制,使得软件在结构上能够适应 Internet 开放环境对各类资源的多模式协同与动态可演化的要求。环境驱动模型就是在开放协同模型的基础上,探讨外部环境的特征及其各种变化模式,建立环境模型的框架结构,在此基础上,以反应式服务计算为突破点,建立开放协同模型与环境模型的交互计算模式和自适应演化模式,从而形成环境驱动模型。更进一步,智能可信计算模型就是在环境驱动模型的基础上,将可信计算框架和机器学习技术等引入,解决开放环境下软件的可信性与个性化等方面的问题,从而最终形成一个具体可用的网构化软件模型,以及与之配套的原理、方法、技术、系统和示范应用。

参 考 文 献

- [1] Dahl O J, Nygaard K. SIMULA-An algol-based simulation language. Communications of the ACM, 1966, 9(9): 671—678.
- [2] Goldberg A, Robson D. Smalltalk-80: The Language and Implementation. Boston: Addison-Wesley, 1983.
- [3] Computing Research Association. Grand research challenges in information systems. 2003.
- [4] Milner R. Theories for the global ubiquitous computer // Walukiewicz I. Proc. of the FOSSACS'04. Berlin: Springer, 2004: 5—11.
- [5] Jennings N R. An agent-based approach for building complex software systems. Communications of the ACM, 2001, 44(4): 35—41.
- [6] Raz O, Shaw M. An approach to preserving sufficient correctness in open resource coalitions. Proc. of the 10th International Workshop on Software Specification and Design, 2000: 159—170.

撰稿人：吕 建

南京大学计算机科学与技术系

软件模型：可表达性与可理解性

Software Model: Expressiveness and Understandability

让计算机为人类提供更多更好的服务一直是计算技术不断发展的原动力。从第一台真正意义上的计算机诞生以来，计算技术所基于的理论模型(图灵机)和实现模型(冯·诺依曼体系结构)并未发生本质性变化，计算机硬件系统发展的主线是计算能力(速度和精度)的不断提升。正是计算机软件技术的不断发展，使得计算技术被广泛应用于不同的行业领域，渗透到人类生活的方方面面，并影响和改变了人类社会。基础系统软件(如操作系统、高级程序设计语言及其编译器、中间件、软件开发工具和平台等)使计算机硬件的能力得到了充分发挥，极大增加了计算系统的使用灵活性和领域适用性，简化了应用软件的开发。

软件技术研究的核心内容是软件的本质、特征与模型，即软件的基本元素、体系结构、交互协议、行为模式、效率机制和质量保障机制等，基本途径是逐




图1 计算机系统层次

层的虚拟化技术和系统优化技术，如操作系统可视为构架在硬件资源上的软件虚拟机，为更高效地管理和使用硬件资源的计算能力提供友好的人机交互界面。高级语言及其编译器提供了另一层虚拟机，使得应用软件的开发可以在一台高级语言计算机上进行。而中间件、应用软件等均可视为架构在下层资源上的一层虚拟机，为充分发挥资源的计算能力提供高效的资源管理和更自然的人机界面。正是软件构成了不同“虚拟机”层次(如图1所示)。

开发计算机软件的目的是为了解决现实世界中的问题，满足人们的应用需求。计算机软件本质上可以看成是现实世界中的问题及其求解方案在计算机上的符号表示。如何将现实世界表示为人和计算机都能够理解的符号系统是计算机软件领域最核心的问题之一，此即软件模型及其建模问题。

软件模型是将现实世界问题空间映射到计算机世界解空间的“桥梁”。一方面，软件模型是现实世界的抽象表示；另一方面，它又是现实世界问题及其求解方案在计算机上实现(即计算机软件)的抽象规约。软件模型规定了软件的构成元素及其交互关系，现实世界的性质通过构成元素之间的交互反映出来。

考察一个软件模型主要是针对两个基本性质：可表达性和可理解性。可表达性是指软件模型能否准确、全面地表示问题空间。由于问题空间的固有复杂

性，很难对问题空间进行准确、全面地建模，只能是一个尽可能好的抽象。可理解性则指模型既便于人理解，也便于被计算机系统理解（即模型的软件实现能够被计算机系统执行）。由于计算机系统能力的有限性，反过来也会影响模型的表达能力。软件模型需要在这两个基本性质间保持平衡。过于复杂的模型既难于理解，也难于实现；而易于实现的模型，其表达能力必然有限。

长期以来，软件模型的发展一直是计算机软件技术发展的主线^[1,2]。尽可能提高软件开发的效率和质量，追求更具表达能力、更符合人类思维模式、易构造的软件模型是软件技术发展的重要驱动力。回顾过去，软件模型的发展主要是源自高级程序设计语言和软件范型的发展^[3~5]。软件范型是从软件工程师（程序员）视角看到的软件模型及其构造原理，是软件技术体系的核心。随着计算机应用复杂度的不断提高，主流软件实体的发展经历了指令、语句、函数/过程、模块、抽象数据类型/对象、构件、服务等粒度和层次，实体间的交互方式也在相应改变，如图2所示。主流的软件范型也经历了无结构、结构化、面向对象、基于构件、面向服务等。此外，也有不少试图摆脱传统冯·诺依曼体系结构的软件范型研究，如函数式、逻辑式、数据驱动式等。传统的结构化软件范型是基于过程抽象，体现为面向功能的软件模型，构成元素是功能模块（函数或过程集合），功能模块之间通过函数或过程调用集成在一起形成软件系统，其重点在于反映现实世界的功能性。面向对象范型是基于数据抽象，构成元素是对象，对象之间通过关联（如继承、集聚等）和消息传递相互联系在一起，其重点在于反映现实世界的结构性和功能性。




图2 软件模型的演化

软件范型的演变反映了计算机软件技术发展的基本趋势：一是支持高效率和高质量的软件开发，包括对复杂问题空间的建模和对复杂性的控制，对软件共性的凝练和复用，对开发过程的自动或半自动支持，对软件产品质量的保障和评估等；二是支持高效能、高可靠和易管理的软件运行，包括计算机系统计算能力的充分发挥，应用软件运行的安全可靠保障，软件运行时的易管理、易配置和自适应，软件的在线维护和演化等。

软件模型应该具有更强的、符合人类自然思维模式的表达复杂问题空间的表达能力,更好地帮助人们构造具有演化性的计算机软件系统。同时,还必须能充分而又恰到好处地运用计算机系统(包括运行在计算机硬件上的基础系统软件)的能力,保证软件模型可被计算机系统正确地理解并高效地转化为正确的软件实现。有三个密切相关的因素影响软件模型的发展,即问题空间的基本特征、执行软件的计算机系统、人的思维模式,而如何有效控制复杂性是软件模型面临的核心问题之一。高级语言的发展提供了控制计算机硬件平台复杂性的方法,结构化软件方法的发展提供了控制程序开发过程和执行过程复杂性的手段,面向对象方法则提供了控制系统需求易变所导致复杂性的途径。当前,面向对象技术仍能占据程序设计方法的主流,正是由于它较好地综合考虑了这三个因素。

随着计算技术应用越来越广泛,各类应用软件系统越来越复杂,人们越来越关心软件系统是否更好地解决了现实世界中的问题,为人们提供可信的服务。软件模型如何以简洁明了的方式表示除功能性和结构性之外的质量属性(如可靠性、可用性、安全性、高性能、适应性等),而这些表示又能被计算机系统所理解并能方便快捷地转换成计算机软件的实现,是软件研究者面临的新挑战。

同时,互联网及其上应用的快速发展与普及,使计算机软件所面临的环境开始从静态封闭逐步走向开放、动态和多变,软件实体的自包含性、功能独立性 & 环境适应性需求不断增强,软件实体之间的交互方式呈现多样化。开放网络环境下的软件系统需要呈现很多新的特征^[6,7],这要求软件模型具有更强的表达能力,既能表达软件实体的局部自主性,又能表达软件系统的全局稳定性、全局目标可控性及目标实现过程的协同性。另一方面,计算系统不再局限于一台计算机,而是开放的网络环境被视为一台全局性的虚拟计算机,软件模型不仅仅可被一台计算机所理解,还需被开放环境下的虚拟计算系统所理解。软件系统的性质越来越具有动态性,甚至其功能性和结构性也不再是一成不变。在一定意义下,软件模型及其实现仅是对现实世界的静态表示,如何用静态的表示手段来刻画现实问题空间的动态性质是颇具挑战性的难题。

参 考 文 献

- [1] Gil J, Kent S. Three dimensional software modeling. Proc. ICSE, 1998: 105—114.
- [2] France R, Rumpe B. Model-driven development of complex software: A research roadmap. Future of Software Engineering, 2007.
- [3] Warboys B. The software paradigm. ICL Technical Journal, 1995, 10(1): 71—79.
- [4] Pratt T W, Zelkowitz M V. Programming Languages: Design and Implementation. 4th ed. Englewood Cliffs: Prentice Hall, 2001.

- [5] Kaisler S H .Software Paradigms .New York :Wiley ,2005 .
- [6] Zambonelli F ,van Dyke Parunak H .Towards a paradigm change in computer science and software engineering : A synthesis . The Knowledge Engineering Review , 2003 , 18(4): 329—342 .
- [7] 梅宏 ,刘譞哲 .互联网时代的软件技术 :现状与趋势 .科学通报 ,2010 ,55(13):1214—1220 .

撰稿人：梅 宏 焦文品
北京大学信息科学技术学院

面向数据管理的数据模型

Data Models for Data Management

计算机要管理数据和处理数据,首先要对数据建模。因此,数据模型的研究与实现,过去、现在和将来一直是数据管理及相关领域一个重要而困难的科学问题。

数据模型的重要性在于:现实世界的的数据必须按某种数据模型组织、描述,才能被计算机所理解,进而被计算机有效地加以储存、管理和处理。因此,数据建模是计算机系统,包括计算机平台系统(操作系统、数据库管理系统等)、计算机信息系统首先要研究和解决的问题^[1]。

数据的多样性、复杂性和应用的差异性,以及计算机系统的层次性和复杂性,决定了数据模型的多样性、复杂性和差异性。如何对数据建模,如何根据数据的属性、数据的语义及应用的需求建立科学的、合适的数据模型是问题的难点所在。

数据模型研究的是如何对现实世界进行抽象,并建立科学的、合适的数据模型。数据模型的科学性应该体现在两个方面:①所提出的数据模型应该能够正确地抽象和概括出研究(问题)域内现实世界对象的基本属性、基本特征和对象之间的相互关系,能够正确定义对象上的操作,能够正确描述对象之间的语义约束。②数据模型应该易于被人们所理解,并且易于在计算机上有效地实现,同时还要支持数据上的各类应用。

关于第①个方面,对应了数据模型的3个主要组成部分:①数据模型的数据结构,是研究域内对象及对象间联系的数据结构描述;②数据模型上的数据操作,是对(表示对象及对象间联系的)数据的操作;③数据模型的约束条件,是对象及对象间联系的完整性约束。

关于第②个方面,根据面向对象的不同,数据模型可分两大类:一类是面向应用的,这类数据模型描述用户和模型设计者都能理解的信息结构,强调其表达能力和易理解性;另一类是面向计算机系统的,如面向数据库管理系统,用以刻画对象在系统中的表示和存储形式,这类模型不仅强调其表达能力,而且要考虑在软硬件技术条件下有效的实现,同时还要支持数据上的各类应用和服务。

对于现实世界的同一类对象、同一类数据,人们可以从不同的侧面,利用不同的数学理论和方法,建立不同类型的数据模型。因此,需要进一步研究不

同数据模型的差异性,即各自的特点、优缺点、相互的等价性、可否转换性等问题。

五十多年前,计算机的应用领域开始从科学与工程计算扩展到数据管理和数据处理领域。由于文件系统具有分散管理、数据冗余度大、维护困难等弱点,各国计算机学术界和工业界纷纷开始研究和探索新的数据管理和建模技术,其成果是出现了一种全新的、高效的数据管理技术——数据库技术。

数据库系统中最早实现的数据模型是层次模型和网状模型^[2]。层次模型以树形结构表示各类实体及其间的联系。层次数据库管理系统采用层次模型作为数据的组织方式,典型代表是 IBM 公司的 IMS (Information Management System) 数据库管理系统。IMS 为保证阿波罗飞船 1969 年顺利登月做出了贡献。

几乎同时, Bachman 在 GE 公司主持设计与实现了网状模型的数据库管理系统 IDS (Integrated Data System), 它以网状结构表示各类实体及其间的联系。Bachman 也被公认为“网状数据库之父”, 并因此于 1973 年获得了图灵奖。

1970 年, IBM 圣约瑟研究实验室的高级研究员 Codd 在 *Communications of the ACM* 上发表论文, 为数据库系统提出了一种崭新的模型, 即关系数据模型^[3]。关系数据模型以二维表结构来表示各类实体及其间的联系。由于关系数据模型简单明了, 有坚实的数学基础, 一经提出立即引起学术界和产业界的广泛重视和响应, 1981 年的图灵奖授予了这位“关系数据库之父”。ACM 在 1983 年把这篇论文列为从 1958 年以来的四分之一世纪中具有里程碑式意义的最重要的 25 篇研究论文之一。

随着数据库应用领域的扩展, 数据对象的多样化, 传统的关系数据模型开始暴露出许多弱点, 如对复杂对象(如文本、时间、空间、声音、图像和视频)的表示能力较差, 语义表达能力较弱, 缺乏灵活丰富的建模能力。为此, 人们提出并发展了许多新的数据模型, 这些尝试是沿着多个方向进行的, 而且一直没有停止^[4]。

(1) 对传统的关系模型(1NF)进行扩充, 引入函数构造器, 使它能表达比较复杂的数据类型, 增强其结构建模能力, 这样的数据模型称为复杂数据模型, 按照它们进行扩充的侧重点, 复杂数据模型可分为两种: 一种偏重于结构的扩充, 如嵌套关系模型(NF²); 另一种侧重于语义的扩充, 如美国加州大学伯克利分校的 POSTGRES 系统, 它支持关系之间的继承, 也支持在关系上定义函数和运算符。

(2) 提出新的数据模型, 增加全新的数据构造器和数据处理原语, 以表达复杂的结构和丰富的语义。这类模型中比较有代表性的是函数数据模型(FDM)、语义数据模型(SDM)、RM/T 模型及 E-R 模型等, 常常统称它们为语义数据模型。它们的特点是引入丰富的语义关联(如 ISA、ISP), 能更自然、恰当地表达

客观世界中实体间的联系。此外,由于拥有比较丰富的结构构造器(如 TUPLE、LIST、SET 等),它们也具有了很强的结构表达能力。由于语义数据模型比较复杂,在程序设计语言和技术方面没有相应的支持,因此,它们都没有在数据库管理系统实现方面有重大的突破,只是作为数据库设计中概念建模的一种工具(如 E-R 模型)。

(3) 将上述语义数据模型和面向对象程序设计方法结合起来,提出了面向对象的数据模型。面向对象的数据模型吸收了面向对象程序设计方法学的核心概念和基本思想,用面向对象的观点来描述现实世界对象的逻辑组织、对象间限制和联系等。把关系数据模型与面向对象数据模型结合,又产生了对象关系数据模型,它保持了关系数据库系统的非过程化数据存取方式和数据独立性,继承了关系数据库系统已有的技术,支持原有的数据管理,同时又能支持面向对象的数据模型和对象管理。

(4) XML 数据模型。随着互联网的迅速发展,Web 上各种半结构化、非结构化数据源已经成为重要的信息来源,XML 数据是一种特殊的半结构化数据,是一种面向内容的、自描述的数据。目前,XML 已成为网上数据交换的标准和数据库界的研究热点。人们研究和提出了多种 XML 数据模型,但还没有公认的、统一的 XML 数据模型。W3C 已经提出的有 XML Information Set、Xpath1.0 Data Model、DOM Model 和 XML Query Data Model 等。

(5) 非结构化数据模型。企业和组织机构的数据可以划分为三大类。除能够用数据或统一结构加以表示的结构化数据、XML 等半结构化数据外,还有一类数据无法用数字或统一的结构表示,如文本、图像、声音等,称之为非结构化数据。非结构化数据管理比结构化和半结构化数据管理更复杂,其数据量也更大。如何突破关系数据模型中结构定义不易改变的限制,并支持复杂的数据操作,是非结构化数据模型亟待解决的理论和技术难题。目前,非结构化数据模型还处于研究阶段,尚无公认的、统一的非结构化数据模型。

由于数据采集越来越容易,数据来源越来越广泛,数据呈现了多源异构、结构复杂、海量膨胀、鱼目混杂、良莠不分等特征。加上软硬件系统快速发展,计算模式和应用环境服务化,给数据建模和数据模型的研究带来了新的挑战。另一方面,数据管理的应用不断扩展,从数据(事务)处理 OLTP 领域扩展到数据分析 OLAP、智能信息检索、Web 搜索等领域,为数据建模和数据模型的研究开辟了新的、更广阔的平台。面向分析的多维数据模型、不确定数据的概率数据模型、流数据模型等新型数据模型不断涌现。数据模型的研究需要和人工智能、数理统计、概率论等学科中的理论方法交叉融合,更需要多学科专家的群体智慧和合作探索。

参 考 文 献

- [1] Date C J. An Introduction to Database Systems .8th ed .New York :Addison-Wesley ,2003 .
- [2] 王珊,萨师煊.数据库系统概论.第四版.北京:高等教育出版社,2006.
- [3] Codd E F. A relational model of data for large shared data banks .Communications of the ACM ,1970 ,13(6) :377—387 .
- [4] 刘惟一.数据模型.北京:科学出版社,2001.

撰稿人：王 珊 陈 红
中国人民大学信息学院

数据质量可保障性

Data Quality Assurance

数据质量泛指数据是否正确、准确、完整、一致、及时和可信。一般来讲,数据质量不是一个绝对的概念,而是相对于应用而言的。如果一批数据能满足一些应用的要求,那么,这些数据对这些应用来说就是高质量的。同一批数据对某些应用可能是高质量的,同时对另一些应用可能是低质量的。数据库系统对数据质量保证的有效支持是以海量、动态、分布、异构和整合为特征的现代数据管理的一大挑战。

众所周知,关系数据库系统是我们这个信息社会数据管理的核心软件。为了简化数据库设计,提供高效的数据库查询处理和保证数据库的正确性,这个四十多年前提出的关系数据库理论有一个基本假设,即“封闭世界”假设。在这个假设下,所有数据属性和数据库所要支持的典型应用在数据库设计时都是已知的,而且数据库里描述的信息都是正确的,而不在数据库里的信息(对于数据库的设计和使用者的而言)都是不正确的。基于这一假设及商用数据库管理系统高效可靠的实现,数据质量保证对于数据库管理系统并不是一个问题,数据质量保证可以简单地归结到对数据录入的质量控制。互联网和 Web 的发展把我们带入了一个数据社会。随着人们可利用的数据来源及数据量的不断增加,各种来源不同、质量参差不齐的数据被加工后用于各种新的应用。“封闭世界”的假设已不再成立。数据整合往往导致数据质量的下降,即使对原来高质量的数据也是如此。如何将数据库管理系统、数据整合和数据质量管理三者紧密地结合成一个通用、灵活、高效的现代数据管理系统是“信息爆炸”时代给数据库和信息系统研究领域带来的一个难题^[1]。

管理信息系统领域在 20 世纪 90 年代中期对数据质量保障的研究,特别是在数据质量的定性分析方面进行了大量工作,把数据质量的概念用准确性、一致性、完整性、时效性、可用性及可信性来描述,并把对数据质量有影响的上百个因素归结成内在因素、应用环境、数据表述和数据存取四大类^[2]。解决数据质量问题必须从组织机构、体系结构和计算方法三个方面入手。从组织机构上来说,一个机构必须确立数据质量管理的目标,并制定人员、职责、过程、政策和标准等方面的策略。体系结构方面的考虑包括选择适当的系统和产品来支持和实现一个组织机构制定的数据质量管理过程、标准和策略,包括系统层面上的元数据管理、数据质量回溯与追踪、常见数据错误侦测与纠正、数据抽取

转换与加载、数据质量度量方法等。计算方法方面的主要问题是对数据质量保证提供有效的计算工具和技术,用以进行数据分析、数据纠错与验证、数据连接及数据约束条件监控。

支持数据质量的计算工具和算法是数据库领域对数据质量的研究重点,着眼于在组织机构和体系结构解决方案之外寻找对大规模数据中提高和保证数据质量的有效方法。数据质量在近年来已成为数据库研究的一个重要领域,包括以下4个主要方面:

(1) 数据连接。数据连接的目的是在大量数据中找到关于现实世界中同一实体的信息,这里,同一实体可以是同一个客户、公司、地址、蛋白质或蛋白质相互作用关系等。数据连接对发现关联及互补信息、消除数据冗余、确保统计正确性都极为重要。由于数据来源不同及数据质量方面的问题(如拼写错误、非标准缩写、地域性和时间性变化等),这些关于同一实体的信息并无统一而标准的标识符。例如,两个名字写法相同不能表示这两个人就是同一个人(可能是重名);同样,两个名字不同也不能表示两个记录属于不同的人(可能名字记录有错)。数据连接研究有着悠久的历史,提出了大量适用于不同情况的记录相似性度量函数(从传统的基于发音相似度和字符串相似度的方法,到现今基于统计相似度、语言模型和模糊匹配的方法)。对给定的一组数据,如何选择适当的相似性函数,以及在上百万记录中快速找到最相似的记录组是一个非常困难的问题。

(2) 数据约束。关系数据库成功的原因之一是对数据约束条件的有效支持。用户可以在数据库关系层上定义诸如函数依赖、主键和副键的各种数据约束条件,而数据库系统则可以确保数据库中的数据满足这些约束条件,从而保证数据正确性。换言之,数据约束条件是关系数据库中对数据正确性这一数据质量重要指标的支持。现代数据管理的特征之一是大量数据都不再由数据库系统管理,来源不同的数据也不可以由统一的关系模式来描述。在新的环境下,数据约束条件应该如何表述?如何高效地保证这些相对复杂的数据约束条件?

(3) 数据溯源。提供对数据来源及处理步骤有效方便的查询支持可以帮助用户理解数据和结果的可信度。如果假定数据库中的数据及处理步骤都是完全正确和完全可信的,数据溯源这一功能并不重要(大部分关系数据库产品不支持这一功能)。在科学应用和其他基于大规模数据整合的应用中,数据来源复杂,处理步骤涉及非标准过程及外部服务,这个功能便变得极为重要了。数据溯源研究大致分为数据级溯源和过程级溯源,基本方法包括基于标记的方法和基于逆过程的方法。这一研究总体上处于起步阶段,如何有效地支持大规模数据和复杂过程下的灵活通用的数据溯源仍然是一个开放课题。

(4) 数据非确定性。传统的关系数据库不考虑数据非确定性。在很多情况

下,这实际上是对现实生活中数据的理想化简化。比如说,在一个记录交通事故的数据库中,目击证人看到的肇事车辆的颜色可能是不确定的,因此,对颜色的记录应该有多个值,而且不同颜色可能有不同的确定度。把数据非确定性引入数据库系统是一件在理论研究和工程上都极具挑战性的任务。从数据模型到查询语言,从索引方法到查询优化,几乎数据库系统的每一个方面都必须重新考虑。

以上 4 个方面是相互关联、密不可分的。新的数据约束条件及有效支持对非过程性的支持数据质量有积极意义,但必须能支持对数据源及合法操作步骤的定义和对非确定性描述。数据连接中的记录相似性必然带来数据非确定性,所以,数据连接和数据非确定性这两部分是不可分割的。而在非不确定性数据管理的环境中,数据溯源是用户对查询结果可信性进行判断的必要支持。同时必须指出的是,现有数据库系统不能有效地支持这 4 个方面的任一方面。已有数据质量的研究工作大多是独立于数据库系统的专门化方法,难以集成到现有数据库系统中。

参 考 文 献

- [1] 周晓方.数据质量:现代数据库与信息系统研究的一个核心问题.中国计算机协会通讯, 2009,5(2):49—51.
- [2] Wand Y,Wang R Y.Anchoring data quality dimensions in ontological foundations .CACM , 1996,39(11):86—95.

撰写人:周晓方

澳大利亚昆士兰大学信息技术与电气工程系

数据库管理系统体系结构面临的挑战

The Challenges of Database Management System's Architecture

自数据库管理系统(DBMS)诞生之日起,其体系结构就随着应用需求发展、硬件技术革新而不断演化。ANSI-SPARC工作组于1975年总结了当时的数据库体系结构,提出了三级体系结构:外模式、模式和内模式^[1]。外模式面向终端用户,模式是数据的逻辑描述,内模式则是数据在外部存储器上的组织形式。在外模式-模式、模式-内模式之间还留有相应接口进行管理。在此后的几十年中,三级体系结构得到广泛认可。从物理配置角度来看,鉴于所有数据管理任务均在同一主机上执行,传统的三级体系结构也可视为集中式结构。随着应用需求发展与计算机硬件革新,三级体系结构也扩展到其他计算机系统之中,衍生出分布式数据库体系结构和并行数据库体系结构。分布式数据库系统基于分布式计算机系统,数据存储在多个计算机系统中,各计算机系统之间通过网络媒介进行通信;并行数据库系统基于并行计算机系统,充分利用了并行系统的多处理器和多磁盘特性来提升数据管理能力^[2]。

数据库管理系统的体系结构无法摆脱应用需求演变与计算机硬件发展两大因素。应用需求是体系结构的目标,而硬件发展成果则是体系结构的基础。体系结构的沿革无不与这两个因素息息相关、循环不已——当应用发展时,现行体系结构显得滞后,人们开始探讨搭建新体系结构的必要性与可行性;硬件发展成果被有效融合到新体系结构之中;新体系结构能满足应用需求。而近期在应用需求、硬件技术等方面的巨大变化促使人们不得不认真思考一个问题,即传统的数据库体系结构是否仍将有效?是否有必要构建新一代体系结构?

时至今日,现代应用所表现出的与传统应用截然不同的特性使得现有数据库管理系统无法满足应用需求,这些应用包括Web搜索、自然语言处理、社会网络分析等,主要特点可归纳为规模大、类型多、不一致。规模大是指数据规模极为宏大,通常可达到PB级别($1\text{PB}=10^{15}$ 字节),远超现有数据库管理系统的管理极限。类型多是指数据类型多样,包括关系型、XML、文本、视频、音频等,无法用单一模型统一表示。不一致是指位于不同数据源(甚至位于同一数据源)的数据之间由于多种复杂原因而具有不一致性。此外,现代应用比传统应用更重视能耗问题,力图降低能耗开销^[3]。

硬件发展成果强烈地冲击了现有数据库管理系统的体系结构。多核处理器日益流行,由于包含多个核芯片,其运算能力显著增强。据保守估计,10年内

多核处理器内置的核芯片数目将超过 100 个。其他数据管理芯片还包括图形处理器、可编程逻辑器件等。内存容量快速增大、成本降低,单个系统的内存容量已可达到 TB 级别($1\text{TB}=10^{12}$ 字节),在未来一二十年内甚至可达到 100TB 甚至 PB 级别。非易失性存储技术取得革命性突破,尽管磁盘是过去相当长时间内唯一的大规模非易失性随机存取设备,但近来闪存、固态硬盘(SSD)等不断发展,成本降低且容量增大。

目前,国内外一些科研单位已经针对这个难题展开科研工作。例如,出现了面向新硬件的查询优化与存储算法;提出了针对海量稀疏数据的管理方法(如 BigTable 等);涌现了针对各种数据形态的管理系统,包括数据流管理系统、时空数据库系统、移动数据库系统等^[4]。但是,这些工作仍处于前期探索阶段,问题远未完整解决,究其原因,主要有以下三个:

首先,如何解决优化目标迁移问题。系统体系结构的沿革主要体现在性能和成本两个方面,即降低成本、改进性能。因此,当优化目标改变时,体系结构必须调整。传统数据库管理系统重视数据吞吐量,而随着“能源危机”在未来数十年内逐步加深,能耗将成为一项重要甚至是首要的因素。降低能耗并不局限于采用节能器件,而是涉及整个体系结构方方面面的优化。

其次,如何满足高可扩展性和数据融合。尽管并行数据库系统和分布式数据库系统能够通过采用更多硬件资源来增强数据管理能力,但这并不意味着处理能力总会随着硬件资源增加而无限提升。恰恰相反,数据管理的复杂度也会随着硬件资源增多而同步攀升,最终导致无法有效管理 PB 级(或更高级)数据库。新体系结构要求具备更强的可扩展性,具体表现为:数据管理能力随着硬件资源的增加而提升,而数据管理复杂度仍维持在一个较低水平。此外,新体系结构也应具备较强的数据融合能力,在同一平台上管理多形态数据及不准确数据。

最后,如何有效融合硬件发展成果。硬件技术的发展对体系结构产生深远的影响,这包括两方面内容:一方面,部分硬件发展成果产生了“质变”效应,迫使体系结构必须调整以应对。例如,多核处理器不单是“更快”的处理器,还具有显著的并行计算能力;闪存、固态硬盘也不单是“更快”的磁盘,还引入了“擦写”操作。另一方面,硬件发展成果的“量变”也会为体系结构带来新问题。例如,大容量内存彰显了主存算法的重要性;存储墙现象进一步凸显;缓存级别增加、容量扩大,亟须升级缓存调度算法等。

数据库管理系统的体系结构问题是数据库领域的核心问题之一。应用需求与硬件发展共同推动构建新一代数据库体系结构。此外,构建新一代数据库管理系统还需要与其他领域交叉融合,汇集多方智慧。例如,融入高可信计算技术,以拥有更好的安全性;重视数据即服务,以服务的形式向客户发布数据。

一言以蔽之，新一代体系结构应具有注重能效、能管理大数据、多数据形态融合、面向服务、高可信性等特点。

参 考 文 献

- [1] ANSI/X3/SPARC Study Group on Data Base Management Systems .Interim report .FDT , ACM SIGMOD bulletin ,1975 ,7(2) ;1—140 .
- [2] Silberschatz A ,Korth H F ,Sudarshan S .Database System Concepts .5th ed .New York : McGraw-Hill ,2005 ;783—807 .
- [3] Agrawal R ,Ailamaki A ,et al .The claremont report on database research .Communications of the ACM ,2009 ,52(6) ;56—65 .
- [4] Hellerstein J M ,Stonebraker M ,Hamilton J .Architecture of a database system .Foundations and Trends in Databases ,2007 ,1(2) ;141—259 .

撰稿人：李建中¹ 金澈清²

1 哈尔滨工业大学计算机科学与技术学院

2 华东师范大学软件学院

数据密集型计算系统的平衡性

Balance of Data-intensive Computing Systems

20 世纪 70 年代, IBM System R 系统和美国加州大学伯克利分校 Ingres 系统的研制成功, 证明了关系数据库系统在基础理论和实现效率上的优越性。随后的 80 年代, 由此模型衍生出的 IBM DB2、Sybase SQL Server、Oracle Database、INFORMIX-SQL 等以联机事务处理 (on-line transaction processing, OLTP) 为主的数据库管理系统的蓬勃发展, 使数据库系统得到了充分商业化。90 年代, Inmon 提出的整合历史数据, 通过联机分析处理 (on-line analytical processing, OLAP)、数据挖掘等方法实现商业规划、决策支持等商业智能服务的数据仓库系统, 为数据库系统的应用开辟了崭新的篇章, 并推动了文字管理、数据流处理等技术的发展。然而这一几近四十年历史、一体适用的数据库系统架构在当今的应用面前显得步履蹒跚, 逐渐显现出高成本、难兼容等问题^[1]。

另一方面, 待处理数据规模的爆炸性增长, 逐渐超越出了数据库的处理能力。在过去的 50 年间, 大多数学科产生了计算分支 (如计算生物学、计算物理学), 并引入了信息管理技术, 管理来自两方面按摩尔定律增长的海量数据: ①新科学仪器产生的海量数据; ②仿真实验产生的海量数据。与之相似, 商业事务处理数据也因信息收集、信息传输技术的发展成指数级增长。据 IDC 统计, 2009 年各行业产生的数据总量超过 48.6 万 PB。

从硬件方面看, 过去的 40 年里, 计算机各组件间发展很不平衡, 存储设备逐渐无法满足数据密集处理的需求。据表 1, 40 年间磁盘的寻址时间仅由 50ms 降为 5ms, 带宽也仅提高了 150 倍, 远落后于其他组件的发展速度。Gray 称磁盘 (随机寻址) 的作用已经逐步退化为与磁带 (顺序寻址) 相当^[2]。固态硬盘 (solid-state drive, SSD) 是一种新兴的数据存储设备, 与硬盘相比具有 200 倍于硬盘的随机访问速度, 且具有功耗低、体积小、噪声轻等优点, 被认为是硬盘的替代品, 但其数据访问方式不同于硬盘, 数据访问的效率、容错性、稳定性还有待提高。

本项科学难题的问题为: 针对各类应用中包括 OLTP 和 OLAP 在内的数据密集计算需求, 构建可扩展、满足 Amdahl 平衡定律的数据管理、数据处理和信息服务系统。

表 1 计算机各组件的发展状况

	磁盘容量	磁盘寻址时间	磁盘带宽	单个 CPU	网络带宽
1970 年	20MB	50ms	1MB/s	740kHz	2.94Mbps
2009 年	2TB	5ms	150MB/s	3.8GHz×8(核)	100Gbps
性能提高倍数	100000 倍	10 倍	150 倍	5135×8(核)	34013 倍

Amdahl 平衡系统定律 一个系统的位数据 (bit) 的访问效率应与指令执行效率相当^[3]。

然而，数据的爆炸式增长，计算机各组件间发展的失衡 (如处理器速度增长远大于硬盘访问速度的增长)，在数据获取、数据存储、数据处理、系统管理方式、服务方式等方面给构建平衡的数据密集型计算系统和应用带来了巨大的挑战。符合 Amdahl 定律的系统配置如表 2 所示。同时，该平衡系统的高可扩展性、高性能、自动并行性、自动管理性、易编程性、高容错性等成为亟须解决的主要问题。

线性可扩展：提高系统管理能力，使系统性能的提高与硬件的增加呈线性关系。

数据布局：通过有效布局，实现数据的就近访问，增进系统平衡^[4]。

自动并行：根据系统的数据处理 workflow，实现任务的自动并行执行。

表 2 符合 Amdahl 定律的数据密集计算系统

OPS	RAM	磁盘 IO/(B/s)	磁盘数/(100MB/s/disk)	磁盘容量	磁盘数/(1TB/disk)
Tera	TB	10 ¹¹	1000	10 ¹⁴	100
Peta	PB	10 ¹⁴	1000000	10 ¹⁸	100000
Exa	EB	10 ¹⁷	1000000000	10 ²⁰	100000000

在构建平衡系统方面，已有很多尝试。

(1) 并行数据库系统。并行数据库系统可进一步分为共享内存系统、共享磁盘系统及无共享系统。共享内存系统 (如 XPRS、DBS3、Volcano 等) 通过多个对称结构的处理器共享内存及一组硬盘实现，可扩展性较差。共享磁盘系统 (如 IBM 的 IMS/VS 系统、Oracle 系统) 采用多个独立处理器 (拥有独立内存) 共享一组磁盘 (典型连接有 SAN、NAS 等) 实现，可扩展性有限。无共享系统中各处理器都有独立的内存及磁盘，数据通过水平分割方式分散存储在各个磁盘上，可扩展性稍高。当前，所能见到最大尺度的该类系统是能够支持 512 个节点的 DB2 Extended Enterprise Edition。由此，上述系统无法满足数据密集型计算的需求。

(2) 低耦合无共享云计算系统。Google 提出了 MapReduce 框架，其数据由

Google File System (GFS) 维护(当前该框架已由雅虎公司的 Hadoop 项目实现开源)。许多公司基于这一框架开发出了多个变种,如 Nokia 的 Disco、Facebook 的 Cassandra 等。MapReduce 框架提供了用户实现数据并行计算的一个接口,用户只需关注其中 Map 和 Reduce 两个函数,进而大大简化了并行处理的复杂度。由此,Google 提供了一个编程的高度抽象模型,使用户从复杂的资源(CPU、存储)管理中解放出来。相反地,Amazon 提供的 AWS(包括 EC2、S3、SQS、CloudFront、RDS、VPC 等)则是在另一个极端,用户能够如同使用本地计算机(自行管理硬件、软件)一样使用该项服务,这类系统为数据密集型计算提供了新思路。

系统平衡是数据密集型计算的基础问题,而当前最大的瓶颈在于数据访问。在硬件系统无法达到平衡的情况下,需要通过改善数据存储模式来解决不平衡性。数据按列存储模式是一个可能有效的选择,还应考虑数据生命周期的影响。

参 考 文 献

- [1] Stonebraker M, Cetintemel U. One size fits all: An idea whose time has come and gone. Proc. ICDE, 2005, 2: 11.
- [2] Gray J. A conversation with Jim Gray. Queue Storage, 2003, 3(1): 20—25.
- [3] Bell G, Gray J, Szalay A. Petascale computational system. IEEE Computers, 2005, 39(1): 110—112.
- [4] Gray J. Distributed computing economics. ACM Queue, 2008, 6(3): 63—68.

撰稿人: 周傲英 钱卫宁 周敏奇
华东师范大学软件学院

面向敏感数据的隐私保护

Privacy Protection for Sensitive Data

对来自同一机构中不同部门或个人的数据实行集中统一的管理,是建立数据库系统的出发点,而数据安全和数据所涉及的隐私保护是需要解决的重要问题之一。传统的数据库系统中提供了各种技术手段,能较好地解决封闭应用环境下数据的安全和隐私保护问题。随着 Web 技术和应用的普及,服务计算正在成为主要的计算模式,而 Web 服务中很大比例上是基于数据处理的。通过将传统的数据管理理念和服务计算体系结构相结合,将数据管理功能(包括存储、处理、分析)作为 Web 服务提供出来作为公共服务是一个发展趋势。新的数据管理服务模式对于服务计算和数据管理都提出新的挑战,在分布式体系结构、多租户数据库、数据服务外包等新的环境和应用中,数据安全和隐私保护是需要重新解决的重要问题。

Web 技术的发展为信息共享提供了广泛的空间,不同组织与机构为达到合作或交易等目的,需要进行一定程度和范围的信息共享。例如,连锁超市的销售记录,便于企业对顾客的购买行为进行综合分析从而制定营销策略;医学研究机构利用医院共享的医疗记录对流行病的发展趋势、各种疾病的发展等进行分析;信用卡公司使用银行共享的储户信息为各种用户制定不同级别的信用额度或贷款规则。

以上共享的信息在一定程度上涉及个人的私密信息,例如,销售记录反映出消费者的个人购买兴趣,医疗记录反映了患者的身体状况,银行记录透露了储户的财产信息。因此,在共享信息的同时,需要考虑如何有效地保护这些涉及个人私密的敏感数据。目前,已提出多种面向信息共享的敏感数据保护技术,通常从安全性、可行性和实用性三个方面对不同的敏感数据保护方法进行评估。

(1) 安全性。敏感数据保护方法需要保证敏感数据不泄露。保证敏感数据零泄露(0-leakage)是不现实的。通常情况下,安全性是相对于数据提供者对敏感数据泄露的容忍程度而言的。不同的数据提供者对敏感数据的泄露程度有不同的要求,即对安全性的要求程度不同。

(2) 可行性。敏感数据保护方法不会影响数据的共享程度。当共享的信息可能造成敏感提供泄露时,需要减少共享的信息量,被减少的共享信息量称为“信息损失”。信息损失涉及数据源提供的信息,基于源信息采用数据挖掘、逻

辑推演等方法得到的数据分布、数据间的相关性等。敏感数据保护方法的可行性体现在多大程度地保证共享数据的源信息和抽象信息的安全性。

(3) 实用性。敏感数据保护方法可以快速地对共享数据进行处理。通过尽量少的的时间获得符合安全性的共享数据是敏感数据保护方法所追求的目标之一。

如何保证敏感数据保护方法的高安全性、高可行性和高实用性是数据管理领域的重要科学难题。针对不同的数据访问方式,采用的敏感数据保护方法是不同的,主要有以下三种方式:

第一种数据访问方式是 C/S 结构,即服务器(数据提供者)拥有数据和对数据的执行权力,客户(数据使用者)可以提交不同的查询给服务器。该方法包括传统的统计数据库技术、基于视图的访问控制技术、多级数据库访问控制技术^[1]和由此衍生出的 Hippocratic 数据库^[2]等。典型的基于视图的访问控制技术包括最小化信息共享技术^[3]、基于概率的方法^[4]、基于谎言(lie)和拒绝(deny)的方法^[5],以及 K-匿名化验证技术^[6]。

第二种数据访问方式是以数据库作为服务的方法,允许一个客户将自己拥有的数据存放在不被其信任的服务器上,涉及的主要问题是允许其他客户可得到服务器的查询结果,但不允许他们知道服务器中确切的数据^[7]。

第三种数据访问方式是依赖于数据的方法。主要研究如何最大化发布信息而不泄露敏感数据。服务器(数据提供者)一旦将数据发布给客户,就不再拥有对数据的任何控制能力,也无法控制客户对数据的访问方式。目前,主要的研究包括依赖于数据的访问授权方法^[8]、支持数据挖掘的隐私保护技术^[8]、K-匿名化处理技术^[6]、基于数据发布的推演控制技术^[9]。

表 1 对不同敏感数据保护方法在数据的敏感级别、安全性、可行性和实用性方面进行了对比分析。

表 1 不同敏感数据保护方法对比

		隐私保护数据挖掘		推演控制		K-匿名化
		数据扰乱	隐私关联规则挖掘	基于 XML 文档	基于关系模型	
敏感级别	源信息敏感	*	*	*	*	*
	抽象信息敏感		*			
安全性		基本保持	零泄露	零泄露	零泄露	1/K 概率
可行性	源信息 信息损失	*	*	*	*	
	抽象信息损失		*		*	
	无信息损失					
	依赖于 应用需求					*

续表

		隐私保护数据挖掘		推演控制		K-匿名化
		数据扰乱	隐私关联规则挖掘	基于 XML 文档	基于关系模型	
实用性	较好	*	*	*	*	
	依赖于应用需求					*

虽然已经提出一些敏感数据保护方法，但数据安全性与隐私保护问题仍然面临巨大的挑战，有很多问题亟待研究和解决。

(1) 安全性方面存在的问题是如何建立一种完善的安全检测体系，并对处理后的共享数据的安全性进行评估，还没有一种通用的方法可以确保数据使用者运用任何方法都不能推导出敏感信息。

(2) 可行性方面欠缺一种合适的评估体系，即应该如何测量敏感数据保护方法对可行性的影响。当前，不同方法具有不同的可行性评估准则。处理后的共享数据虽然在某种情况下比较好，但对于其他情况不一定很好，需要对共享数据的可行性进行比较完整的评估。在保护敏感信息的同时，必然会导致可行性的下降，如何在安全性和可行性之间进行权衡同样需要进一步研究。

(3) 实用性方面，当前的敏感数据保护方法可以较快地对共享数据进行处理，但尚未达到实时处理数据的程度，如对流数据的处理。因此，需要研究高性能的、实用的敏感数据保护方法，提高数据处理能力。

参 考 文 献

[1] Qian X,Lunt T F.A semantic framework of the multilevel secure relational model .IEEE Transactions on Knowledge and Data Engineering ,1997 ,9(2) ;292—301 .

[2] Agrawal R,Kiernan J,Srikant R ,et al.Hippocratic databases //Proceedings of 28th International Conference on Very Large Data Bases ,Hong Kong ,2002 ;143—154 .

[3] Agrawal R,Evfimievski A V ,Srikant R.Information sharing across private databases // Proceedings of the 2003 ACM SIGMOD International Conference on Management of Data , San Diego ,2003 ;86—97 .

[4] Miklau C,Suciu D.Controlling access to published data using cryptography //Proceedings of 29th International Conference on Very Large Data Bases ,Berlin ,2003 ;898—909 .

[5] Biskup J,Bonatti P.Controlled query evaluation for known policies by combining lying and refusal .Foundations of Information and Knowledge Systems ,2003 ;49—66 .

[6] Sweeney L .Achieving k-anonymity privacy protection using generalization and suppression . International Journal on Uncertainty ,Fuzziness and Knowledge-based Systems ,2002 ,10(5) ;

571—588 .

- [7] Hacigumus H ,Iyer B R ,Li C ,et al .Executing SQL over encrypted data in the database service provider model//Proceedings of the 2002 ACM SIGMOD International Conference on Management of Data ,Madison ,2002 ;216—227 .
- [8] Agrawal R ,Srikant R .Privacy-preserving data mining .ACM SIGMOD Record ,2000 ,29(1): 439—450 .
- [9] Yang X ,Li C .Secure XML publishing without information leakage in the presence of data inference//Proceedings of the Thirtieth International Conference on Very Large Data Bases , Toronto ,2004 ;96—107 .

撰稿人：杨晓春 于 戈
东北大学信息科学与工程学院

社会网络协同计算问题

Collaborative Computing Problem in Social Networks

古希腊哲学家亚里士多德曾经有一个著名的论断“Man is by nature a political animal”，意即人本质上是社会性的存在，需要不断地与他人产生交互，这种个体及个体之间的社会交互形成了社会网络^[1]。

社会网络是社会学研究的重要对象之一，迄今已有大量的方法和理论被提出。传统社会网络研究通常以实证分析为手段，需耗费大量资源进行调查以获取真实数据，这种数据收集的困难导致研究工作局限于少量的、以百或千计的数据规模上，阻碍了模型的正确性验证和理论的深入发展。近年来，Internet 特别是 Web2.0 的普及，互联网上博客、维基百科、Fliker 等站点大量涌现，将网络变成了一个巨大的虚拟社会，人们的交互活动正以前所未有的广度和深度被及时地记录和存储。例如，Facebook 记录了人们如何与他人联系并成为朋友的过程，维基百科记录了人们开展创造性合作的过程。在这些大型网站的后台服务器上，每分钟都记载了以百万计的数据。这种技术的进步和数据的易得性为社会网络分析提供了很好的背景平台，使得以计算技术研究社会网络问题成为可能^[2]。

Web 环境下的社会网络改变了个人的工作生活方式，给国家安全、社会导向、网络经济、信息服务模式等都带来了难以估量的影响和冲击。虚拟的网络生态和真实的社会结构趋同、互动关联，研究社会网络中的协同计算问题，服务于人类的社会经济活动，并用其提升人类活动的效益和水平，研究成果具有重大的社会意义和商业价值。

在线交互数据是人类真实行为的有效折射，社会网络研究的一个根本问题就是：如何从计算视角分析和建模社会过程，以帮助成员获得更好的互动和协同？该问题包括三个方面：①网络成员的社会关系计算；②信息在网络中的广泛共享；③网络成员的分工合作。

网络成员的社会关系计算主要用于发现一组具有共同兴趣爱好的成员，这些成员的集合构成社区，它是社会网络的基本组成单位，也是协同工作的基础。构成社区的成员具有某种程度的认识，其联系往往较为频繁。社会关系的计算通常是指对给定的社会网络，将其划分为若干个社区，使得同一社区内成员的联系比不同社区间成员的联系更为密集。

网络中的信息(思想或新技术)处于不断的运动之中，信息的快速流通和广

泛共享有助于更新成员的知识结构,提高他们的工作效能。信息传播行为分析主要考察结构因素对传播的影响,以期通过结构改造对传播起良性引导作用。也就是给定一个社会网络和附加在某节点上的信息源,该信息到达网络其他节点的过程如何被结构因素所影响,这里的结构因素包括信息源自身的状态、网络的同态、闭包、密度、度分布、强弱连接等。

社会网络催生了新的协同计算模式,对人员进行合理配置,使他们协同工作,有利于提高生产力和经济效益。也就是给定一个任务,如何从已知的社会网络中选择一个节点子集,使目标函数最优。这里的目标函数可以有多种形式,包括推荐效果、协同工作的效率等。

社区发现的常用方法包括聚类、图形分割、模块度划分等,这些方法大多基于节点-节点的单一关系实现。Web 环境下,社会网络中主体间的联系趋向多维,如朋友之间可能共存于联系人网络,却出现在不同的消息订阅网络。综合内容和结构信息实现网络划分是最近的研究热点,但对不同划分算法如何融合仍无定论,其中的难点在于虚拟社区的划分缺乏衡量标准和验证手段。因此,这种融合属于无指导的学习,难以提高其质量。

信息传播的经典模型包含线性阈值和级联传播两类。经典模型对传播问题仅考虑局部邻居影响,但实际上传播过程还受到全局结构因素的影响。Liben-Nowell 和 Kleinberg 通过对网络字母链的研究发现,由于受到聚簇系数的影响,其传播沿着深而窄的树状结构进行扩散^[3]。社会心理学的“三角闭包”理论提示,当两个主体有共同朋友时,此两者很容易成为朋友,这种现象也已经在大型在线社会网络中被观察到。在具有复杂连接关系的社会网络中,分析信息传播过程的困难主要在于传播是多因素综合作用的结果,精确建模这一过程需对各种结构要素进行评估选择和有效综合。

人员配置在过去经常被当做整数规划问题处理,模拟退火、分支界定、遗传算法是解决这类问题的常用技术,此类算法完全忽视了成员的社会属性,但现实世界中的个体总是存在于社会关系之中,个体间的关系将影响其功能需求的实现。例如,由朋友组成的团队工作效率将高于一组互有敌意的人。最近,Lappas 等学者研究了内嵌于社会网络的成员合作问题,并证明了对给定任务,交流代价最小的子集选择是 NP-hard 的^[4]。该问题的困难在于由于无法找到最优解,只能采用各种启发式方法求目标函数的近似解,因此,其效果难以保证。

这是一个社会网络和计算技术合一的时代。社会网络跨越了地理的限制,在互联网上蓬勃发展,带来大量的科学问题。本文所述仅是冰山一角,对其的研究仍在不断深入之中。例如,在分析网络成员节点时可能会涉及敏感信息,如何保护用户隐私是必须考虑的问题。在线社会网络更新频繁,动态社区发现和网络演化特征刻画也是需要重点研究的对象。在信息传播过程中,如何利用

结构信息使影响力最大化是问题的一个侧面，与之对应的另一侧面是如何改善网络结构，使其有利于引导信息的理性传播。最后，效能的提高是一个复杂的人文社会问题，如何将传统社会学理论通过计算的途径表达出来并合理运用仍然有大量的工作需要完成。

参 考 文 献

- [1] Travers J, Milgram S. An experimental study of the small world problem. *Sociometry*, 1969, 32(4): 425—443.
- [2] Kleinberg J. The convergence of social and technological networks. *Communications of the ACM*, 2008, 51(11): 66—72.
- [3] Liben-Nowell D, Kleinberg J. Tracing information flow on a global scale using Internet chain-letter data. *Proc. Nat. Acad. Sci.*, 2008, 105(12): 4633—4638.
- [4] Lappas T, Liu K, Terzi E. Finding a team of experts in social networks. *Proceedings of SIGKDD*, 2009: 467—475.

撰稿人：钱铁云 彭智勇
武汉大学计算机学院

复杂知识表示与推理

Complex Knowledge Representation and Reasoning

知识表示与推理是人工智能最基本的研究问题。

早期的人工智能研究,知识表示与推理间接融入问题求解程序中。1958年,McCarthy 提出了第一个基于逻辑的知识表示与推理系统。60年代中期,知识表示与推理成为人工智能的一个重要子域,70年代得到快速发展。1975年,Min-sky 提出框架知识表示,与语义网络、一阶谓词逻辑和产生式系统等一起成为经典知识表示与推理方法。人工智能的头十年人们着重研究一般问题求解策略,但 Feigenbaum 却发现一般性知识不足以使智能系统解决现实复杂问题,与领域专门知识的结合是必要的。1965年,他研制了第一个专家系统。1977年,他率先倡导知识工程,并在使其成为人工智能领域影响最大分支的过程中发挥了重要作用^[1]。至1990年,专家(或知识)系统一直是研究热点。

20世纪70年代末开始,不确定性知识处理成为研究热点,提出了确定性理论、证据理论和 Bayes 网等不确定性推理方法;90年代,以知识规范化和共享为目标的本体研究受到广泛关注,出现多种本体描述语言,构建了许多领域本体。

21世纪,随着计算机及相关技术的迅猛发展,处理复杂问题的知识在来源、种类和数量等方面均发生了质的变化,展现了不确定、多粒度、不协调、时空、多源、异构、大规模和动态等复杂特性,被称为复杂知识。

复杂知识表示与推理已成为人工智能的严峻挑战之一。复杂知识特性研究可追溯到20世纪70年代,出现了一致性维护、信息粒度、信息融合和本体等概念。经过四十多年的发展,逐渐形成了以多粒度计算、复杂系统信念修正、复杂时空知识处理、多源异构知识融合、多知识表示与推理、描述逻辑及其扩展、大规模本体推理和动态环境下智能规划等为核心的复杂知识表示与推理子域。世纪之交,我国人工智能学者倡导了以复杂知识处理为核心的“非规范知识”基本理论、核心技术研究。

本文将以处理复杂知识的重要理论、方法为主线,力图勾勒出复杂知识表示与推理之主要难题的来龙去脉、研究现状和难点所在。

针对多粒度特性,1979年,Zadeh 提出信息粒度概念^[2],将信息粒度引入知识处理,逐渐形成知识粒度概念。知识粒度越小(大),知识表达就越精细(粗糙),时、空开销随之增大(降低)。人类既能选择合适粒度处理问题,又能在不同粒度的世界间灵活跳转。粗糙集^[3]、词计算和商空间是多粒度知识计算的主

要基础理论。近年来,粒近似空间、粒逻辑、覆盖粒计算、模糊商空间、词计算语言动力学和多粒度智能计算模型等方面发展较快,并成功用于图像处理、数据挖掘、智能控制和生物信息处理等领域。多粒度知识建模的主要难题有:多理论融合的多粒度计算模型;适合问题空间的知识粒度选择;动态多粒度知识表达与推理;知识不确定性、模糊性和多粒性的关系等。其关键难点在于不确定性知识处理中合适知识粒度的选择,不同粒度知识的关联、转换与融合。

复杂时空知识表示与推理旨在为复杂时空任务提供基于知识的高效和鲁棒性求解方法,它不仅是计算机、认知、地理信息等学科的前沿理论课题,而且在工农业、交通、军事等领域都有十分重要的应用价值。时空知识表示与推理研究始于1983年提出的基于区间代数的时态推理。1992年,区域连接演算被提出,随后定性空间推理成为重要研究内容。2000年以来,复杂时空知识表示与推理研究逐渐展开^[4]。针对单一、简单时空关系的约束满足推理和时空结合逻辑已是难处理的,而复杂时空知识表示与推理需要处理多维空间、复杂对象、多类关系、复杂时空结合、多粒度及不确定性等,更增加了挑战性,目前,兼顾表达能力和推理效率成为其主要难点^[5]。复杂时空数据具有海量、多源异构、多粒度、动态、分布和不确定等特性,时空推理与知识发现深度结合是复杂时空数据挖掘的难点。

在动态环境下进行智能规划是复杂知识表示与推理的重要内容之一^[6]。从人工智能早期的智能规划研究开始,直至1995年以“图规划”系列方法为代表的又一次研究高峰,都属于经典规划范畴。经典规划的问题定义中有一系列假设约束,这些假设在厘清问题的同时也限制了问题的表达能力。近十年来,出现了诸多放松这些约束的新规划问题,其研究比经典规划更贴近现实,如不确定或概率条件下的动作推理,规划目标和动作带有时态约束^[4]等。这些因动态环境下进行动作推理而出现的新问题也给知识表示与推理带来了挑战,其根本难点在于知识表达能力与求解效率间的冲突。

外部不一致操作导致复杂知识的不协调性,信念修正旨在维护知识的一致性。1985年,建立的信念修正理论AGM是基于逻辑的信念修正的奠基性工作,后续研究大多是在AGM框架下,通过补充、完善现有公设集来解决新出现的不一致性。例如,20世纪90年代提出的信念更新和迭代信念修正公设;2000年后提出的动态信念修正和多Agent信念修正等公设。信念修正对于复杂知识管理至关重要,已应用于语义Web、生物医疗等多个领域。尽管以AGM为代表的方法已成为信念修正研究的主流,但其秉承的合理公设前提未必适合所有逻辑。如何针对特定逻辑特征给出信念修正的合理公设集,仍是一个理论难题。此外,逻辑推理的效率问题仍使信念修正停留在理论研究阶段,无法胜任大规模知识的信念修正任务^[4]。

复杂智能系统常常要处理多源、异构信息、知识。融合方法通过对多源信息/知识的自动探测、关联、估计和组合来提高问题求解性能^[7]。从军用多传感器系统,到网络分布式系统、无线传感器网络,信息/知识融合都是核心问题,其中,不一致信息/知识融合是非常困难的。20 世纪 90 年代以来,基于逻辑的知识融合研究取得了许多成果,但这些工作却基本上是基于单一知识表示的,不能有效处理多源、异构的复杂知识。Minsky 从 20 世纪 90 年代一直积极倡导的多知识表示与多推理方法的结合有望解决这一问题,但如何在复杂系统中针对不同类型问题选择合适的知识表示与推理方法并进行深度结合是一个理论难题^[8]。

复杂知识表示与推理涉及很多方面,但这里只选择了信息领域中近期有望取得突破的重要难题。复杂知识表示与推理已成为人工智能的前沿研究方向之一,其研究工作的突破性进展必将大大深化人类对知识和智能的认识。

参 考 文 献

- [1] Russell S J, Norvig P. Artificial Intelligence: A Modern Approach. 3rd ed. Upper Saddle River: Prentice Hall, 2009.
- [2] Zadeh L A. Fuzzy Sets and Information Granulation Advances in Fuzzy Set Theory and Applications. Amsterdam: North-Holland, 1979: 3—18.
- [3] Pawlak Z. Rough Sets: Theoretical Aspects of Reasoning about Data. Dordrecht/Boston/London: Kluwer Academic Publishers, 1991.
- [4] Harmelen F V, Lifschitz V, Porter B. Handbook of Knowledge Representation. Amsterdam: Elsevier, 2008: 551—596, 841—868.
- [5] Aiello M, Pratt-Hartmann I, et al. Handbook of Spatial Logics. Dordrecht: Springer, 2007.
- [6] Ghallab M, Nau D, Traverso P. Automated Planning Theory and Practice. New York: Morgan Kaufmann Publishers, 2004.
- [7] Klein L A. Sensor and Data Fusion: A Tool for Information Assessment and Decision Making. Washington: SPIE Press, 2004.
- [8] Minsky M. The Emotion Machine: Commonsense Thinking, Artificial Intelligence, and the Future of the Human Mind. New York: Simon & Schuster Ltd., 2007.

撰稿人: 刘大有¹ 欧阳丹彤¹ 王国胤² 杨 博¹ 王生生¹
漆桂林³ 欧阳继红¹

1 吉林大学计算机科学与技术学院

2 重庆邮电大学计算机科学与技术学院

3 东南大学计算机科学与工程学院

高维数据降维

Dimensionality Reduction for High-dimensional Data

实际问题的驱动及数据获取技术的发展使得高维数据不断涌现。处理和分析高维数据是模式识别、机器学习和数据挖掘等智能信息处理领域的核心研究内容之一。典型应用包括文本分类、目标识别、图像检索、视频监控、基因阵列分析等,涉及的数据动辄上千维甚至更高。

直接对高维数据进行诸如分类、聚类或概率密度估计等学习任务不仅要付出巨大的计算和存储代价,更严重的是可能招致所谓的“维数灾难(curse of dimensionality)”^[1]——试图让一个算法保持同等的学习或估计精度,所需数据量应随维数呈指数级增长。

降维是克服维数灾难的重要途径,一般分特征选择和特征提取两类技术。前者试图从原始高维特征(变量或属性)中按某种准则(目前主要分滤波、封装和嵌入三种策略^[2])选择一组特征子集;而后者旨在寻求某个映射将原始高维数据变换至某个低维空间以达成保持数据某些特定性质的目的。事实上,特征选择可理解为特征提取的特殊形式^[3]。鉴于此,本文仅关注特征提取,并狭义地视其为“降维”。数据之所以能降维,归咎于其外在呈现的高维性通常并未真实地反映其内在维数,后者往往较低且富含数据的整体信息。一个极端例子是高维数据的每个分量彼此相等,如图 1(左)所示,数据分布在三维空间的一直线上,而直线的内在维数为 1;另一例子是数据位于高维空间中的低维(弯曲)流形(manifold),如图 1(中)所示,数据分布在三维空间的 S 形曲面上,而该曲面的内在维数为 2。




图 1 数据分布示例(注意其内在维数)

最经典的降维方法当属主成分分析(principal component analysis, PCA)^[4],

由 Pearson 于 1901 年提出, Hotelling 于 1933 年奠定其数学基础。PCA 为线性算法, 目标是使降维(或投影)后数据分散程度尽可能大, 如图 1(左)中数据走向即为最优 PCA 投影方向。与 PCA 密切联系的一类降维算法是多维尺度变换(multidimensional scaling, MDS)^[5], 源于心理测量领域, 可追溯至 1938 年。MDS 寻找能最大程度地保持原数据间相似性的低维空间。若相似性由 Euler 距离度量, 则易证 MDS 与 PCA 等价。经多年研究, MDS 已发展成一族降维算法的集合, 并成为构建很多现代(非线性)降维算法的基础, 如 2000 年提出的 ISO-MAP 是采用测地距离的 MDS, 能较好地“展开”如图 1(中)所示的非线性流形。1936 年, Fisher 提出的线性判别分析(linear discriminant analysis, LDA)是另一经典算法。与 PCA 不同, LDA 针对类别属性数据, 实现投影后同类数据尽量紧凑、异类数据尽量分离。事实上, 几十年来, 已有众多降维方法被相继提出, 著名的有典型相关分析、投影追踪、自组织特征映射、核 PCA、局部线性嵌入等^[6]。参照文献[3], 降维的研究现状大致可归结为以下几方面:

(1) 非线性降维。旨在揭示数据内在的非线性结构, 如图 1(中)的弯曲流形结构。典型算法包括现有线性算法的核化版(如核 PCA)、流形学习(如 ISO-MAP)和深度网络降维方法^[7]等。

(2) 张量化降维。针对矩阵(如图像)及张量(如视频序列)模式进行的降维, 其思想可追溯至 20 世纪 60~70 年代的多重线性或多模数据分析, 近年因模式识别领域一系列二维(2 重线性)算法(如 2DPCA)的出现而重新受到关注。

(3) 局部化降维。利用数据的局部几何特性进行的降维, 典型算法包括部分流形学习算法(如拉普拉斯特征映射)及其线性化版本(如局部保持投影)等。

(4) 半监督降维。面向部分有类别标记但大量无类别标记数据的降维方法, 主要针对人工标注类别信息困难的现实问题。

尽管已有众多降维方法问世并取得了显著进展, 但降维问题至今仍未从本质上得以解决。现有降维算法的成功往往建立在数据内在维数足够低且样本足够多的前提之上。然而, 现实问题远非如此, 如人脸图像空间的内在维数估计有近百维^[8]。事实上, 根据文献[6], “当问题的内在维数超过 5 时, 很多非线性降维方法就要谨慎使用。”因为高的内在维数势必加剧“小样本问题”的发生, 造成样本分布极度稀疏, 进而导致现有降维技术面临诸多挑战: ①内在维数如何估计? 如图 1(右)所示的数据, 很难确定其内在维数是 1 还是 2。②学习模型的参数如何选择? 例如, 局部型降维算法中常涉及的近邻数、核参数等, 目前尚无确定其最优值的可靠理论依据。③学习算法的性能如何评价? 一种合理的评价准则应视具体任务而定, 但现有降维算法多数跟后续学习过程(如分类)相分离, 而性能却又用分类精度来衡量。上述诸问题看似独立, 但多由高的内在维数引起, 这似乎又回到了“维数灾难”这一源头问题。

正如文献[6]所指出,降维的主要动机是避免维数灾难,而许多降维方法自身却受维数灾难的困扰,这是模式识别和机器学习领域经常遇到的“悖论”之一。难道“维数灾难”本质上无法克服?NO!事实上,我们的大脑时时刻刻都在跟高维数据打着交道,能极其快速地从长年积累的庞大人脸“库”中辨认出某个人^[8],而在如此短时间内完成整个“搜索”过程,如果没有一个紧致的表示是难以想象的。人脑究竟是如何进行维数约简的?难道人脑中存在一组“美妙的基(或词典)”,能对所处的现实世界进行最简洁或最稀疏的表示?如果答案是肯定的,那么理由似乎应是:人脑中这组“基”包含了必要的历史先验(知识),并且这些先验正以惊人的速度膨胀着,因为此时此刻正在成为历史,而未来将告诉我们如何克服“维数灾难”这一终极挑战。

参 考 文 献

- [1] Bellman R E. Adaptive Control Processes .Princeton ;Princeton University Press ,1961 .
- [2] Guyon I, Elisseeff A .An introduction to variable and feature selection .Journal of Machine Learning Research ,2003 ,3 :1157—1182 .
- [3] 张道强,陈松灿.高维数据降维方法.中国计算机学会通讯,2009,5(8):15—22.
- [4] Carreira-Perpinan M A .A review of dimension reduction techniques .Sheffield ;University of Sheffield Technical Report ,1997 .
- [5] Borg I, Groenen P .Modern Multidimensional Scaling ;Theory and Applications .New York : Springer ,1997 .
- [6] Lee J A ,Verleysen M .Nonlinear Dimensionality Reduction .New York ;Springer ,2007 .
- [7] Hinton G E ,Salakhutdinov R R .Reducing the dimensionality of data with neural networks . Science ,2006 ,313(5786) :504—507 .
- [8] Meytlis M ,Sirovich L .On the dimensionality of face space .IEEE Transactions on Pattern Analysis and Machine Intelligence ,2007 ,29(7) :1262—1267 .

撰稿人: 乔立山^{1,2} 陈松灿¹ 张道强¹

1 南京航空航天大学信息科学与技术学院

2 聊城大学数学科学学院

因果推断

Causal Inference

一个现象的出现总是伴随着另一个现象的出现,改变其中之一是否会导致另一个跟着变化?其答案取决于这两个现象之间仅有相关关系?还是有因果关系?自古以来,关于因果关系的研究一直吸引着人们去思考。在科学研究中,人们通过观察和实验发现自然规律、探索现象之间的因果关系是各种科学研究的最终目标。爱因斯坦认为,“西方科学是建立在以因果律为基础的形式逻辑之上”。自 1888 年 Galton 提出相关系数的概念以来,“涉及因果推断的问题自始就缠住了统计学的脚后跟”^[1],1911 年, Pearson 提出用列联表分析因果关系,1921 年, Wright 提出路径分析模型,1934 年, Neyman 提出潜在结果模型,1935 年, Fisher 提出随机化试验方法,1974 年, Rubin 关于观察性研究提出虚拟事实模型, Pearl^[2]和 Spirtes 等^[3]提出因果网络图模型,图 1 给出了一个设想的关于肺癌的因果网络^[4]。Freedman^[5]介绍了从相关关系研究到因果关系研究的发展过程。从观察获得的数据中发现多因素之间的因果关系是统计学和人工智能领域长期关注的科学难题。




图 1 关于肺癌的因果网络

Yule-Simpson 悖论描述了一种与人们常识相悖的现象,一种药品对男性和女性都有效,但对人类无效。无因果关系的两个因素 A 和 B 可能会有相关关系,这个相关关系是由于其他因素 C 对它们共同影响所造成的,因素 C 称为混杂因素。混杂因素也可能使原本有因果关系的两个因素变得互不相关。例如,设想有一种治疗某种病危患者的特效药,而且所有患者都服用了这种药,那么,

会观察到服药的患者与不服药的正常人有相同的寿命,即服药与寿命不相关。判断是否存在混杂因素是因果推断的关键问题^[6]。采用随机化试验,即给每个患者随机地分配治疗或处理方案,可以排除混杂因素。随机化试验是因果推断的最可靠方法,但随机化试验需事先确定哪个因素是原因,其目的是推断原因对结果的作用,而且在很多研究中不允许进行随机化试验。但是,根据观察性研究进行因果推断需要某种用数据不可证伪的假定^[1]。通常,假定观察了足够多的变量,以致包含了所有的混杂因素。在观察性研究中,首先确定观测变量的集合,然后从中选择混杂因素是因果推断的两个关键步骤。当存在未知的或不可观测的混杂因素时,可以选择一个与原因变量相关但不受混杂因素影响的变量,称为工具变量,来消除混杂偏倚,而根据先验知识很难确保不受混杂因素影响。因此,确定和选择工具变量是另一个具有挑战性的研究课题。

在科学研究中,常探究原因影响结果的因果机制,原因 A 对结果 B 的直接作用有多大,而原因 A 通过中间因素 C 对结果 B 的间接作用有多大。给定中间因素 C 取相同值的条件下,根据 A 对 B 的作用来评价直接作用的方法可能会导致错误的结论。例如,给定接受新治疗与接受对照治疗的患者的中间因素血压 C 取相同值的病人并不是同一类病人,不具有可比性。为了保证可比性,Frangakis 和 Rubin 提出主分层方法,根据每个人的潜在中间因素(接受新治疗的血压和接受对照治疗的血压)将总体分层。但是,同一个人只接受一种治疗,因此,只能观测到一个血压,而不能两者兼得,导致主分层方法遇到了新的困难。

在科学研究中,人们常试图利用一个近期的或容易得到的中间指标来替代远期的或难以得到的终点指标。确定替代指标方法有基于条件独立性、主分层和因果图的准则。但是,采用这些准则可能会出现因素 A 对因素 B 有正作用,且因素 B 对因素 C 也有正作用,而因素 A 对因素 C 有负作用的现象,称为替代指标悖论或中间因素悖论^[7]。近年来,很多专家对替代指标方法进行了争议。抑制心律失常能降低发生心脏骤停的可能性,曾将抑制心律失常作为评价治疗猝死药物的替代指标。美国批准了几种能有效抑制心律失常的药品,但经过长期追踪研究发现,这些药品不但没有降低心脏骤停的可能性,反而增加了可能性,这就是美国 20 世纪 80 年代发生的历史上最严重的药品灾难事件。在科学研究中,采用将一个复杂系统分解为各部分之组合的还原论方法和采用替代指标的方法的合理性都有待于从因果推断的角度进行审视。

基于相关关系的预测仅适用于学习样本和未来样本是同分布的情况。外部干预可能会改变变量之间的相关性和总体的分布。基于因果机制的预测方法建立因果模型,对未来外部干预的结果进行预测。基于因果关系的方法可以预测制止公鸡打鸣不会阻挡日出,因此,它比基于相关关系的预测方法更具有普适性。对于历史数据中未曾经验过的干预进行预测是一个具有挑战性的问题^[4,8]。

目前,多因素之间因果关系研究主要采用 Bayes 网络模型。因果 Bayes 网络已经被广泛应用于多学科的研究中。在生物信息学研究中,使用小样本数据构建数千个基因的调控网络,这种高维小样本数据的网络结构学习同时具有计算复杂性和统计效率问题。基于 Bayes 网络的因果推断注重从数据中挖掘因果关系,而仅仅从观察数据是否能发现因果关系的问题仍存在争论。根据观察数据和试验数据学习构建因果网络是一个具有挑战性的研究问题^[2~4,9]。

100 年前发现了相关关系的数学描述,推动了人类对自然科学和人文社会奥秘的认知能力。20 世纪计算机的出现使得人们的计算能力得到了飞跃,大大增强了数据分析的能力。当今,计算机网络和生物芯片等技术的出现,使得人们获得数据的手段更加丰富。尽管从数据中挖掘相关关系的方法研究发展迅速,但分析挖掘因果关系的方法还非常贫乏。“在过去的一个世纪中,许多发现被推迟是由于缺少描述因果的数学语言。”^[2]目前,在科学研究中妨碍人们认知自然科学和人文社会奥秘的一个最大障碍也许是缺乏从数据中认知因果关系的方法。人们在认知因果方法上的进步将提升人类更深层次地认知自然科学和人文社会奥秘的能力。因果推断领域向统计学、机器学习和人工智能提出了各种具有挑战性的重要研究问题,其中包括基于观察数据评价因果作用的方法,探究直接作用和间接作用等因果机制的方法,基于因果模型对外部干预进行预测的方法,从高维数据、混合类型数据、多源数据、时间序列数据、不完全数据及含隐变量等复杂数据中挖掘因果关系和因果网络的方法等。

参 考 文 献

- [1] Holland P W .Statistics and causal inference .J .Am .Statist .Ass .,1986 ,81 :945—970 .
- [2] Pearl J .Causality :Models ,Reasoning ,and Inference .2nd ed .Cambridge :Cambridge University Press ,2009 .
- [3] Spirtes P ,Glymour C ,Scheines R .Causation ,Prediction ,and Search .2nd ed .New York :MIT Press ,2000 .
- [4] Guyon I ,Aliferis C ,Cooper G ,et al .Causation and prediction challenge .Proc .J .Mach .Learn Res .,2008 ,3 .
- [5] Freedman D .From association to causation ;Some remarks on the history of statistics .Statistical Science ,1999 ,14 :243—258 .
- [6] Greenland S ,Robins J M ,Pearl J .Confounding ,and collapsibility in causal inference .Statistical Science ,1999 ,14 :29—46 .
- [7] Ju C ,Geng Z .Criteria for surrogate endpoints based on causal distributions .J .R .Statist . Soc .B ,2010 ,72 :129—142 .
- [8] Heckman J J .Econometric causality .Internat .Statist .Review ,2008 ,76 :1—27 .

[9] <http://jmlr.csail.mit.edu/papers/topic/causality.html>.

撰稿人：耿 直
北京大学数学科学学院

模式特征的抽取和表达

Extraction and Representation of Pattern Features

对客观事物的辨认和识别是人类智能的基础，因此，能够实现计算机辨识的模式识别成为计算机智能信息处理的核心问题之一。

人类如何实现辨认和识别，一直是人们苦苦探索的，也是众多学科，如生物、心理、神经等学科在不断研究的问题。同时，人们期望计算机能如人一样，实现或部分实现人脑的智能，计算机科学为此做出了巨大的努力。但是，由于大脑和计算机在物理上的巨大差异，利用计算机模拟大脑智能的模式识别和人工智能，实质上大大有别于大脑的智能，其研究也具有极大的创新和挑战。计算机技术和信号与信息处理技术的发展推动计算机智能研究取得重要的进展。从 20 世纪至今，最重要的是在模式识别的进展上，如已经产业化应用的文字识别、人脸识别、工业自动化检测等就是具体的体现。

模式识别研究始于 20 世纪 20 年代，它是根据对事物的观测，对事物的存在或性状加以辨认和识别。模式识别包括两个基本步骤：首先从对事物的观测中抽取对于事物辨识的依据，即模式的特征；第二步则是依据抽取的模式特征对模式的类别或性状进行学习和分类判决。获得理想的最优判决结果一直是模式识别研究追求的目标。20 世纪以来，提出了多种模式识别的方法，如结构模式识别、统计模式识别、神经网络和句法模式识别方法等，而不同方法的根本差异在于不同模式的特征抽取和表达方法。理论和实践证明，特征抽取对于模式的分类判决起着决定性的作用。

模式特征抽取和表达源自模式样本的原始观测，样本的原始观测是大量的图像、声音、文字、电磁等信号。如何从复杂的、极大数据量的模式样本观测中获取和表达模式分类和识别的模式特征，特别是抽取和表达那些对模式分类密切相关的鉴别特征成为模式识别成功的关键和核心问题。

随着模式识别研究的深入，模式特征抽取和表达经历了一个发展过程。开始，人们往往容易从直观分析的方法抽取特征。例如，汉字由笔画构成，汉字笔画的抽取和表达成为汉字识别初期的特征抽取和表达。继之，研究全局/局部、高层/低层等不同层次的特征抽取。进而，从观测数据中抽取能获得高识别性能的鉴别特征成为研究重点。研究结果表明，对于汉字、人脸、指纹、虹膜等目标观测的纹理图像包含有充分的模式分类信息，基于随机图像观测的统计特征模式描述可以获得高的识别性能。从而，各种随机的高维矢量的统计特征

抽取和选择得到人们的关注,随机图像观测的各种变换特征也得到广泛的应用。例如,汉字图像的方向线素特征、人脸图像的分布 Gabor 变换特征^[1]、指纹的特征点特征等。在此基础上,还不断发展出各种图像特征,如 Haar 特征^[2]、梯度直方图 HOG 特征、尺度不变 SIFT 特征及最大稳定区 MSER 特征等,这些高维纹理特征的抽取和表达也成为包括人脸、虹膜、车辆、军事目标等大量图像目标识别的重要基础特征。

模式特征抽取和表达也决定了模式识别的基本方法。例如,汉字的笔画结构特征抽取和笔画序列表达决定了其笔画结构识别方法;而模式样本的随机矢量表达和抽取的统计特征则采用统计模式识别的方法进行学习和分类判决^[3]。正是由于统计模式识别方法对于模式巨大变化的包容和强有力的数据处理能力得到大量成功应用,也促使高维矢量的统计模式特征抽取和表达在更大范围得以推广。

模式特征的抽取最终决定着模式识别的性能,因为由信息论分析可知,在最优 Bayes 分类条件下,模式识别错误率的上限是由特征 F 与类别 E 的后验熵 $H(E|F)/2$ 所确定^[4],因此,抽取与模式类别密切相关的模式特征成为模式识别成功的决定因素。

从复杂的、极大数据量的目标观测(如图像的像素)中抽取有效维数压缩的鉴别特征,避免学习样本不足引起的“维数危机”,就成为保证模式识别成功的关键。人类具有极其强大的从复杂事物中抽取低维相关鉴别特征的能力,如从人脸图像人们可以容易地获得其方位、表情及性别、年龄等信息,但计算机却难以实现。在计算机处理中,人们提出了许多维数压缩鉴别特征提取的算法,有线性的,如最大信号能量的主成分分析方法(PCA)、最大鉴别能力线性鉴别分析方法(LDA)等;有非线性的方法,如基于核函数的非线性鉴别分析方法(KLDA)等;特别是 2000 年提出的流形学习(manifold learning)算法^[5],是为获得类似人感知的模式低维特征能力的一种尝试。

线性鉴别分析是以类间方差最大和类内方差最小的优化准则,从高维特征空间中抽取最优投影分量的特征压缩方法,在模式识别的实践中取得大量成功应用,不仅提高了模式识别的性能,而且也使许多难以实现的模式识别问题得以解决,如字体、笔迹、性别、种族、表情的识别等。但是,传统线性鉴别分析方法对特征高斯同分布的要求限制了其应用,因此,异方差线性鉴别分析(HLDA)、非高斯分布的鉴别分析、非线性鉴别方法及近邻鉴别分析的研究等也成为当前研究的重点。

面对模式识别的深入发展和各种复杂模式识别的应用要求,模式特征抽取和表达的探索还将持续进行。

参 考 文 献

- [1] Porat M ,Zeevi Y Y .The generalized Gabor scheme of image representation in biological and machine vision .IEEE Trans .on PAMI,1988,10(4):452—468 .
- [2] Viola P ,Jones M .Rapid object detection using a boosted cascade of simple features .Proc . IEEE Conference on Computer Vision Pattern Recognition ,2001 .
- [3] Fukunaga K .Introduction to Statistical Pattern Recognition .2nd ed .New York ;Academic Press ,1990 .
- [4] Devijver P A .On a new class of bound on Bayes risk in multiple-pothesis pattern recognition . IEEE Computers ,1974 ,C-23(1):70—80 .
- [5] Seung H S ,Lee D D .The manifold way of perception .Science ,2000 ,290 :2268 .

撰稿人：丁晓青
清华大学电子工程系

数字媒体内容的理解

Digital Media Content Understanding

数字媒体是指以二进制数的形式获取、记录、处理、传播的信息载体,这些载体包括数字化的文字、图形、图像、声音、视频影像和动画等感觉媒体,以及存储、传输、显示逻辑媒体的实物媒体^[1]。数字媒体现在已经越来越多地渗透进我们的生活,如图片、电影、电视、动画等随处可见,已成为人们工作和生活的重要组织部分。随着信息化的不断推进,数字媒体的内容更加丰富,种类更为多样,视听觉效果更为逼真,丰富了人们的文化生活,并在公共安全、医疗卫生等领域发挥着不可替代的作用。

顾名思义,数字媒体理解是指利用数字化手段对数字形式的媒体进行分析,具体地说,就是利用计算机对数字媒体进行分析与理解,给出对数字媒体的描述。研究人员没有停止过利用计算机进行数字媒体理解的努力,模式识别技术、图像处理技术、计算机视觉技术等的发展无一不与媒体理解的发展相关。目前的研究现状是:近四十年来,模式识别、视觉分析等方面与数字媒体理解的进展互为促进,尤其是对数字媒体底层特征的提取和识别为数字媒体的进一步理解打下了坚实的基础,在图像识别、声音识别、视频处理与分析方面取得了持续的成果,拥有了视频摘要、图像语义表示、音频分析等方面的初步结果,部分成果已获得一些应用。但是,由于数字媒体本身的复杂性等原因,期望通过计算机对其进行智能分析并像人一样给出对媒体内容的理解还是一个难题。

举例来说,对于图1所示的图片,人可以直观地给予这幅图片自己的理解,如“一个女孩在看海”,那么,如果我们将这幅图片输入计算机,计算机能否一样对图像进行分析并给出类似的语义信息呢?更为复杂的情形,如果我们输入一部电影(如《泰坦尼克号》)到计算机中,计算机能否像人一样给出“这是一部爱情片”或者“这是一部悲剧”的评价呢?这些问题都属于数字媒体内容理解的范畴。

事实上,科学技术发展到今天,数字媒体内容的理解始终没有得到很好的解决,这成为计算机科学和认知科学中公认的难题,其主要难点如下:

(1) 媒体理解的语义鸿沟问题。科学家试图从人对媒体进行认知的机理出发,使计算机能够模拟人的认知机理,对数字媒体内容进行正确的理解,并且将理解的结果用语义(语言)表示出来,但是,语义的表达与数字媒体本身蕴涵的意义之间有非常大的鸿沟。认知科学家们通过大量的动物实验,发现动物

的视觉认知具有非常明显的层次性与整体性的特点，即动物的媒体认知是从底层到高层分层进行的，同时又存在从高层到底层的交互，但这些层与层之间的交互却很难通过计算机来建立数学模型。举例来说，对于如图 2 所示的图片，计算机可以非常轻松地获取其底层特征，如颜色、大小、形状等，但如何从图片中识别出一位老人和一位小孩对于计算机来说就相对困难一些；而更进一步，让计算机知道图片中的人在干什么，什么样的心情就是难上加难了。



图 1



图 2

(2) 媒体理解的多样性问题。媒体存在着显著的多样性特点。对于同的一段媒体，由于不同的人阅历、立场的差异，对媒体内容的理解往往会仁者见仁、智者见智。例如，对于同样的一部电影，不同的人会给出不同的评价和感受。而另一方面，各种各样千差万别的媒体类型却有可能给出同样的内容理解。对于计算机而言，考虑这种多样性非常困难。

(3) 媒体理解的有效计算问题。随着信息化的不断推进，数字媒体的规模更大，种类更多。数据量巨大且结构各异的媒体数据的处理往往涉及复杂的计算过程，需要较大的计算开销。然而在很多应用中，媒体计算又往往需要满足实时性的要求。在数字媒体内容理解的实际应用中，所要考虑的不仅是算法，更要考虑效率，必须解决媒体的有效计算问题。

数字媒体理解的研究内容是如何利用计算机实现对于媒体的内容理解，进而将理解的结果用于所有与多媒体技术相关的领域中，具体包括视频摘要、图像语义表示、音频分析、媒体认知模型研究、媒体信息处理等方面。

数字媒体内容的理解已经成为计算机科学、认知科学等学科的热门研究方向。在近几年中，数字媒体内容理解的理论和方法都取得了长足的进步，在很多特定的领域和场景下得到了成功的应用，认知科学和计算机科学分别从自身角度对于媒体理解建立了相应的理论流派^[2~8]。但是，总的来说，如何基于计算机进行数字媒体内容的正确理解这一问题尚未得到全面解决。随着计算机科学、

认知科学、语言学、应用数学等相关学科的日益发展和向纵深交叉的趋势,我们相信,在不久的将来,数字媒体内容理解一定能够得到更好的解决,并给我们的日常生活带来巨大的影响。

参 考 文 献

- [1] <http://baike.baidu.com/view/237696.htm>.
- [2] Zhuo Y, Zhou T G, Rao H Y, et al. Contributions of the visual ventral pathway to long-range apparent motion. *Science*, 2003, 299(5605): 417—420.
- [3] Li W, Piech V, Gilbert C D. Learning to link visual contours. *Neuron*, 2008, 57(3): 442—451.
- [4] Lay J A, Ling G. Semantic retrieval of multimedia by concept languages: Treating semantic concepts like words. *IEEE Signal Process Mag.*, 2006, 23(2): 115—123.
- [5] Kang F, Jin R, Sukthankar R. Correlated label propagation with application to multi-label learning. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition (CVPR)*, 2006: 1719—1726.
- [6] Luo J B, Hanjalic A, Tian Q, et al. Integration of context and content for multimedia management: An introduction to the special issue. *IEEE Transactions on Multimedia*, 2009, 11(2): 193—195.
- [7] Huang T S, Dagli C K, Rajaram S, et al. Active learning for interactive multimedia retrieval. *Proceedings of the IEEE*, 2008, 96(4): 648—667.
- [8] Tsao D Y, Livingstone M S. Mechanisms of face perception. *Annual Review of Neuroscience*, 2008, 31: 411—437.

撰稿人: 王蕴红

北京航空航天大学计算机学院

自然启发的计算

Nature-inspired Computation

作为人类历史上最复杂、最困难的学科之一，人工智能的发展道路崎岖。随着认知科学与人工智能的发展，探索自然界生物的认知机理、实现具有认知机理的计算智能理论与方法成为人工智能的前沿课题。模仿自然界的智能行为成为令机器显现智能的新途径^[1]。

近年来，人工智能研究者习惯将受自然现象启发而发展起来的智能算法统称为自然启发的计算(nature-inspired computation)，它以自然界中生物体的功能、特点和作用机理为基础，研究其中所蕴涵的丰富的信息处理机制，构造相应的计算模型，设计相应的算法并应用于各个领域。自然启发的计算不但是人工智能研究的新热点，也是人工智能发展思路的新思考，更是方法论转变的新成果，其代表性成果包括人工神经网络^[2]、进化计算^[3]、模糊理论^[4]、粗糙集^[5]、人工免疫系统^[6]等。自然启发的计算方法能够解决很多传统计算方法难以解决的复杂问题，在大规模复杂优化问题求解、数据挖掘与知识发现、模式识别、智能控制、计算机网络安全等领域具有很好的应用前景。

人类很早就开始思索自身智能，也有模拟智能的愿望。“人工智能”在 1956 年被正式提出前后，其研究主要集中在探索智能及智能模拟的普适理论。传统的人工智能错误地预设了真实世界的复杂性，认为人工智能存在最基本的像物理学那样简洁的普适理论^[7]。但是，现实世界因果关系密布，成功地认识它主要不是依靠模型，而是借助于协调感知系统和相关行为的变化来达到的。在其他学科，尤其是生物技术的促进下，人工智能研究随后进入智能模拟的个性设计阶段，这一阶段的人工智能研究不仅在方法上，而且在思想上呈现出多样性，形成了不同的学派，发展了大量实用方法，是人工智能最具特色的发展阶段。

事实上，基于不同的观点和角度，生命现象和生物的智能行为一直为人工智能研究者所关注，不论是结构模拟的人工神经网络，还是着眼于生物进化微观机理和宏观行为的进化计算，或是功能模拟的模糊理论，都有仿生的痕迹。20 世纪 40 年代初，神经解剖学、神经生理学、心理学及人脑神经元的电生理的研究等都取得了丰硕成果。在此基础上，神经生物学家、心理学家 McCulloch 与青年数学家 Pitts 合作，从人脑信息处理观点出发，采用数理模型的方法研究了脑细胞的动作、结构及其生物神经元的一些基本生理特性，提出了第一个神经元模型，从而开创了人工神经网络的研究。人工神经网络通过模仿生物神经

网络的行为特征,依靠系统的复杂程度,通过调整内部大量节点之间相互连接的关系,从而达到处理信息的目的。人工神经网络经历了 40~50 年代的首次繁荣、60~70 年代的一度低潮、80 年代的再次复苏,如今已经成为一门理论日渐成熟、应用也在逐步广泛与深入的学科。20 世纪 60 年代,美国的 Holland 教授提出了系统本身和外部环境相互协调的遗传算法,并于 1968 年提出模式理论, Holland 教授也被视作遗传算法的创始人。几乎在同一时段的 1965 年,德国学者 Rechenberg 等提出了进化策略的方法,美国学者 Fogel 提出了进化规划。遗传算法、进化策略和进化规划的提出开启了进化计算的研究。进化算法模拟由个体组成的群体的学习过程,其中,每个个体表示给定问题搜索空间的一点。这一类算法从选定的初始解群体出发,通过不断迭代的进化过程逐步改进当前解群体。在进化过程中,算法在一组解上采用类似于自然选择和有性繁殖的方式,在继承原有优良基因的基础上,生成具有更好性能指标的下一代解的群体。粒子群优化算法作为一种新的进化计算技术,最早由 Kenney 与 Eberhart 于 1985 年提出,它源于对鸟群捕食行为的模拟,也是一种基于迭代的优化工具。根据蚂蚁“寻找食物”的群体行为,意大利学者 Dorigo 等于 1991 年提出了蚁群算法的基本模型。蚁群算法的基本思想是模仿蚂蚁依赖信息素进行通信而显示出的社会行为。近几年,研究人员习惯将粒子群优化算法和蚁群算法等模拟自然界群体智能行为的算法合称为群智能(swarm intelligence)。与遗传算法被提出的同时,1965 年,美国加州大学 Zadeh 教授创立了模糊集合理论,基于模糊集合理论,随后发展出了模糊逻辑、模糊推理和模糊控制等方面的内容。20 世纪 80 年代末、90 年代初,美国麻省理工学院的 Brooks 提出了人类本身就是以数十亿计的生物分子组成的复杂机器的观点,并提出了轰动一时的无表征智能理论,该理论突破了传统人工智能“感知-建模-计划-行动”框架,采取基于行为模拟的结构,其原理为控制论及“感知-行动”型控制系统,基于这一结构, Brooks 成功研制了六足机器人 Genghis^[1]。1994 年 6 月, IEEE 在美国 Orlando 召开了一次国际计算智能会议(IEEE World Congress on Computational Intelligence),首次将有关人工神经网络、模糊逻辑和进化计算方面的内容放在一起交流讨论,并将原来的 IEEE 神经网络学会(IEEE Neural Networks Society)更名为 IEEE 计算智能学会(IEEE Computational Intelligence Society)。此后, IEEE 计算智能学会分别于 1998 年、2002 年、2006 年、2008 年和 2010 年召开了五次国际计算智能会议。

然而,模拟自然的计算在基础理论 and 应用方面仍然存在诸多瓶颈难题。一方面,已有的自然启发的计算模型依然缺少严格的理论支撑,对自然启发的计算方法理论分析的研究迫在眉睫。当前,有关自然启发的计算理论方面的工作是非常有限的,然而,完善的理论分析是模型工程应用的可靠保障。通过理论分析研究,我们往往可以获得更多有用的知识,将对算法的设计有重要的指导

作用。例如,目前在遗传算法、粒子群优化算法、蚁群算法等智能优化算法的研究中,对于种群的自聚性、搜索过程的收敛性、偏离性、欺骗性及其收敛时间的估计等的研究仍然缺乏严格的理论指导。因此,对于自然启发的计算方法的理论分析是研究人员面临的巨大挑战之一。另一方面,面对信息技术领域对海量信息挖掘与高效优化大规模 NP-hard 问题的需求,已有的自然启发的计算方法在实时性和自适应性方面仍然需要进一步提高。例如,人工神经网络的学习与泛化能力在某些场合下还不能令人满意,表现在网络构造困难、适应能力较差等。对于某一具体问题,神经网络的设计是极其复杂的工作,至今仍没有系统的规律可以遵循。这样,不仅使得设计工作的效率很低,而且还不能保证设计出的网络结构和权值等参数是最优的,从而造成资源的大量浪费和网络的性能低下,这种状况也限制了神经网络的应用与发展。20 世纪 90 年代后期,以进化计算为代表的计算智能在国际上掀起了 NP-hard 优化计算的热潮,但已有基于达尔文进化机理的进化计算范式更多地强调了进化个体(或子系统)之间的竞争性,缺乏其协同机理的深入分析和利用,因而存在早熟、收敛速度慢、难以求解复杂与多目标问题的全局最优解等问题,使人们对进化计算的效率和潜力产生怀疑,影响了其研究的深入,严重地限制了其应用的推广。

总之,经过几十年的研究与实践,人工智能研究者开始认识到,要想仿效或逐步接近人类百万年进化而达到的高级智能行为,无论是传统智能,还是单一的自然启发的计算方法,都是无法完成的,仍然需要认知科学和计算机科学领域的研究人员付出更加艰辛的劳动。

参 考 文 献

- [1] Brooks R. New approaches to robotics. Science, 1991, 253: 1227—1232.
- [2] Minsky M, Papert S. Perceptions. Cambridge: MIT Press, 1969.
- [3] Holland J. Adaptive of Natural and Artificial Systems: An Introductory Analysis with Application to Biology, Control, and Artificial Intelligence. 2nd ed. Cambridge: MIT Press, 1992.
- [4] Zadeh L. Fuzzy logic. IEEE Computers, 1988, 21(4): 83—93.
- [5] Pawlak Z. Rough Sets: Theoretical Aspects of Reasoning about Data. Norwell: Kluwer Academic Publishers, 1992.
- [6] de Castro L, Timmis J. Artificial Immune Systems: A New Computational Intelligence Approach. Berlin: Springer, 2002.
- [7] Kirsh D. Foundation of AI: The big issues. Artificial Intelligence, 1991, 47(1/3): 3—30.

撰稿人: 焦李成 公茂果
西安电子科技大学工程学院

几何计算的健壮性问题

Robustness of Geometric Computations

采用计算机进行几何计算(简称几何计算)极大地提高了人类处理复杂几何模型的能力和效率,并为计算机辅助设计与制造、有限元分析、计算机图形学等诸多数字化技术的产生和发展奠定了基础,使得大规模复杂产品的设计、制造与仿真成为可能。同时,使用过涉及几何计算的软件系统的用户又往往对这类系统的不可靠很无奈。使用这类系统,用户可能在进行了很多步操作后因计算失败而不得不再从头开始,也可能用户操作成功但结果错误,从而导致更严重后果。究其原因,几何计算的健壮性问题,即在进行复杂几何计算时总无法完全避免失败或出错,直接导致了涉及几何计算的软件系统的不可靠。

解决几何计算健壮性问题的难点在于如何在计算机浮点计算精度下准确判别在实数计算下所存在的相互关联的几何关系。对于这一难题,近二十多年来国内外开展了深入研究,代表性方法有容差计算方法、区间计算算法、精确计算方法等。

几何计算健壮性问题的来源根本上归结于计算误差与数据误差这两个基本因素。计算误差来自数值计算中的浮点数运算。在几何计算中,几何元素之间的各种逻辑关系判断(如点/线/面的重合、相交、相切等关系的判断)都建立在相关的数值计算上。由于浮点数运算的不精确,使得几何元素之间各种逻辑关系的判断变得不可靠,进而导致几何计算结果的不可靠。

图1所示为六面体和四面体的求交计算实例^[1]。四面体上的边 E 与六面体上的面 F_1 和面 F_2 相交,由于边与面的夹角不同,浮点计算中的交点计算在精度上有差异,如图2所示。这里,由于 E 与 F_1 的夹角较大,求交计算结果比较精确,计算出的交点 A 位于面 F_1 的内部,而由于 E 与 F_2 的夹角很小,导致求交计算结果误差大,使得计算出的交点 B 落在了面 F_2 的边界上。这样的几何计算结果产生了逻辑上的不一致,即直线段 E 和平面 F_1 相交了两次(一次在内部,一次在边界上),将直接导致体与体之间的拼合操作失败。

在连续的几何计算中,上次计算的输出将成为下次计算的输入,于是,计算误差转换为数据误差,而且数据误差会随着几何运算的叠加而积累。一个复杂的几何造型系统往往包括成百上千个几何计算函数,并且这些函数相互关联,因此,仅仅提高单个几何计算函数的运算精度是不够的,无法保证整个几何造型系统的健壮性。




图1 四面体与六面体求交计算




图2 逻辑不一致的交点

对于几何计算健壮性的研究开始于 20 世纪 80 年代，主要在实体造型领域和计算几何领域展开。精确计算方法是计算健壮性研究中的一种有代表性的方法^[2]，其基本思想是用精确的整数运算、有理数运算或者代数运算方法来替代实数浮点运算，以保证计算结果的完全精确，该方法的缺陷是原始输入的坐标值局限在整数、有理数或者代数表示范围，导致很多工程计算无法使用现有的精确计算方法。容差计算方法^[3]在实体造型中被广泛应用于提高几何计算的健壮性，该方法通过对几何模型中的点、线、面等边界元素采用容差表示，基于边界元素的容差表示进行几何元素之间的逻辑关系判断，并在每一次几何计算后对边界元素的容差表示进行动态更新，以维持模型中几何数据与拓扑结构的一致性，进而保证几何操作的健壮性。其缺点在于容差计算方法缺乏完善的理论基础支持，难以找到有效设定和更新边界元素容差范围的准则，目前主要基于经验进行边界元素容差范围的设定和更新，通过大量的测试来逐渐完善相关准则。区间实体模型及区间计算算法^[4]是另一种提高几何计算健壮性的方法，该方法将几何模型中的点、线、面离散为一系列的立方体来表示，并采用区间运算来替代浮点计算进行几何元素之间的逻辑关系判断，能够在曲线曲面求交计算中保证所存在的解不被丢失，但过大的区间设置也会使不相交的情况被误判为相交，另外，运算的低效问题也需要解决。

值得指出的是，虽然上述方法都可以在一定程度上提高几何计算的健壮性，但距离完全解决几何计算健壮这一难题还十分遥远。

几何模型互换性问题是几何计算健壮性问题的进一步扩展^[5]。几何模型互换性问题是指出一个在原始几何造型系统中具有几何拓扑有效性的几何模型，交换到其他几何造型系统后可能会因为系统的几何容差设定不同或几何关系判别方法不同，无法通过对方的有效性检测而变成无效几何模型的问题。在几何计算健壮性问题中，更多的是解决计算精度，而在几何模型互换中，需要解决如何对模型数据精度建立格式化数学模型。当前，解决此问题的实用方法是通过

对接收到的几何模型进行几何修补操作来重构有效的几何模型, 理论上的研究还处于起步阶段^[6]。

参 考 文 献

- [1] Hoffmann C M .Robustness in geometric computations .Journal of Computing and Information Science in Engineering ,2001 ,1(2):105—204 .
- [2] Yap C .Towards exact geometric computation .Computational Geometry :Theory and Applications ,1997 ,7(1—2):3—23 .
- [3] Sakkalis T ,Shen G ,Patrikalakis N M .Topological and geometric properties of interval solid models .Graphical Models ,2001 ,63(3):163—175 .
- [4] Jackson D J .Boundary representation modelling with local tolerancing //Proceedings of the 3rd ACM Symposium on Solid Modeling and Applications ,Salt Lake City ,1995 :247—253 .
- [5] Qi J ,Shapiro V .Geometric interoperability with epsilon solidity .Journal of Computing and Information Science in Engineering ,2006 ,6(3):213—220 .
- [6] Qi J ,Shapiro V . ϵ -topological formulation of tolerant solid modeling .IEEE Trans .on Computer-Aided Design ,2006 ,38(4):366—377 .

撰稿人: 高曙明¹ 齐建昌²

1 浙江大学 CAD&CG 国家重点实验室

2 东南大学机械工程学院

复杂装备和系统的高精度交互模拟分析

High-precision and Interactive Simulation and Analysis of Complex Equipment and System

模拟仿真是继理论建模、实验验证后工程科学的三大手段之一^[1,2]。通过模拟仿真,设计者可以在虚拟环境中探索复杂装备和系统的各种可能设计方案,直观形象地对复杂装备和系统的设计、制造、作业、维修及回收全生命周期进行设计优化、功能验证、性能分析与可制造性评估,有效减少复杂装备和系统的实物样机试制次数,降低开发成本,缩短开发周期,从而显著提高企业的产品自主开发能力。

近年来,模拟仿真技术已在众多复杂装备和系统的设计制造中获得成功应用。美国波音 777 飞机、法国空客 A380 飞机、美国海军下一代航母 CVN 21、美国 NASA 载人太空探索飞船、德国西门子高速列车等复杂装备和系统的设计开发中,模拟仿真均作为提升设计能力的关键技术,成功解决了这些复杂装备和系统在设计、装配、制造与维护等关键环节的参数优化、功能验证与性能分析问题。例如,美国波音公司在波音 777 飞机研发中全面采用模拟分析技术,修正了 2500 处设计干涉问题,降低了 94% 的研制费用,研制周期降低 50%,装配时出现问题减少了 50%~80%,最终产品一次接装成功;美国海军下一代航母 CVN 21 是第一艘完全在虚拟环境中设计的航母,设计者在虚拟环境中完成航母的系统布局设计与装配模拟分析,如在哪里放置管道,如何在上层甲板安装之前建造下层甲板,如何实现航母上舰载机调运与设备作业流程仿真等。

复杂装备和系统模拟仿真中,模拟分析结果与实际装备和系统的相似程度(即逼真度)是人们最关注的问题。理想的模拟分析应该能够以一种可测量或可感知的方式精确预测或再现真实世界对象或者假想的对象、特征、环境或某种标准的状态和行为^[3,4]。因此,在复杂装备和系统模拟分析中,如何构建几何、物理、行为、感知等方面具有与物理原型相媲美的计算机仿真模型^[5],使得仿真模型能够正确地代表真实装备和系统;如何在机理、功能、性能、特性各个方面逼近实际装备和系统,使得模拟分析系统产生的输出结果能够和真实装备和系统一致;如何实现高度真实的交互感知与行为反馈,使得设计者能够直观自如地对仿真模型与仿真结果进行交互可视分析,是复杂装备和系统模拟分析技术需要解决的关键科学难题。

高精度是保证复杂装备和系统模拟分析逼真度的关键。由于复杂装备和系

统的几何、物理与过程模型高度复杂,模拟分析建模与求解过程中不可避免存在近似、不确定性和误差等影响模拟分析精度的因素:①模型近似与等价。为了减少复杂装备和系统模拟分析的复杂性,往往需要采用物理意义、作用效果或物理规律相同或相似的模型对设计参数与模型进行替代与简约,从而突出主要矛盾。模型近似与等价在有利于准确把握复杂装备和系统全局性质,将模拟分析问题化难为易的同时,也影响了模拟仿真的精度。②模型与参数不确定性。由于人们对复杂装备和系统物理规律认知的不确定性,导致模拟分析中模型参数选择、阻尼选取、载荷确定、边界条件确定等方面具有随机性和不确定性,影响了模拟分析的精度。③模拟分析求解误差。复杂模拟分析中,大规模方程系统数值求解存在误差,这些因素的存在使得目前的复杂装备和系统的模拟分析尚难以实现很高精度的建模与求解。

实时交互是发挥复杂装备和系统模拟分析优越性的重要手段。与传统的数值模拟分析相比,基于虚拟现实交互的模拟分析有效扩展了人们对计算机数字信息空间的感知通道,为复杂装备和系统设计与分析提供了全新的可视化、可感知化的方法和手段,但也对模拟分析系统提出了更高的要求。视觉上,要求每秒生成和显示 30 帧图形画面,否则将会产生视觉不连续和跳动感;触觉上,要实现拟实的力感觉,避免力觉振荡,必须以 1000 帧/s 的速度计算和更新接触力;同时,对于用户的交互操作,系统应立即做出反应并计算生成复杂装备和系统相应的行为、特性和场景,其时间延迟应小于 0.1s,这些要求对现有的计算资源提出了严重的挑战。

实现复杂装备数字样机高精度模拟仿真科学难题的突破,需要在以下三方面的基础理论研究方面取得突破:

(1) 多场多性能耦合的复杂装备和系统高精度建模理论。复杂装备和系统往往是多学科(机械、电子、控制)关联、多场(流场、电场、磁场)耦合、多技术单元(机、电、液、气、控)综合的复杂系统。目前的复杂装备和系统模拟分析主要侧重于单领域单学科的建模与分析,人为割裂了多领域多场耦合的作用机制,难以建立多领域性能分析数据的关联。提高复杂装备和系统模拟分析的精度,需要研究通过机械、电子、控制多学科协同模拟仿真,实现复杂装备刚柔多体耦合分析、多场耦合分析、多相多态耦合分析、多介质耦合分析与多尺度耦合分析,从而更精确模拟复杂装备和系统的功能与性能,减少因孤立分析对象而引起的边界条件、载荷等的不确定性。

(2) 大规模模拟分析数学模型的实时高精度求解方法。复杂装备和系统模拟分析建立的数学模型中,微分方程、状态方程、参数方程等往往耦合在一起,方程系统的规模动辄达到数十万级别,对计算机软硬件系统的求解能力提出了很大的挑战。为了改善复杂装备模拟仿真分析中大规模方程系统的收敛性、精度、实时性、速度等方面的计算指标,需要对模拟分析建立的大规模数学模型

进行约化、解耦及求解误差精度控制。同时, GPU 计算、并行计算技术也为复杂装备和系统模拟分析中实时高精度求解技术提供了新的途径。

(3) 复杂装备和系统模拟仿真的等效性与相似性分析理论。几何、力学和性能的等效性原理与相似性原理是复杂装备和系统建模与模拟分析的重要基本原理。提高复杂装备和系统模拟精度的重要途径之一是建立与实际状态等效的有效分析模型。要解决模拟仿真中的几何、力学、性能、参数的等效性分析问题, 需要研究解决模拟分析中相似性与差异性的度量与计算、复杂装备和系统等效原理与条件、复杂装备和系统等效模型的物理参数辨识、复杂装备和系统等效模型的参数敏感性分析、复杂装备和系统等效性的试验验证等问题。

复杂装备和系统的高精度交互模拟分析未来的发展趋势包括以下几个方面:

(1) 复杂装备和系统的半实物模拟分析。复杂装备与系统中往往存在一些机构、部件或机组的机理与特性非常复杂(如实现飞行器空间交会对接所需的空间对接机构), 用数学模型描述非常困难, 为了实现这类系统的高精度模拟分析, 可以把部分仿真模型用实物代替进行实时模拟, 这种模拟分析又称为硬件在环的仿真。半实物模拟分析比单纯的数值模拟分析精度更高、更接近实际、逼真性更好, 但实时要求更高, 同时, 实物模型与仿真模型的非线性强耦合也是半实物模拟分析需要解决的问题。

(2) 复杂装备和系统的全生命周期模拟分析。模拟分析的应用范围从产品关键设计阶段扩展到包括设计、制造、装配、使用与维护产品全生命周期集成。例如, 德国西门子公司在高速列车研发中启用全面数字样机流程链, 设计的各个阶段包括从概念设计到开发、生产准备、制造、装配、服务, 直到保养, 都在虚拟环境中进行高速列车的高精度模拟分析, 这一技术的使用将西门子研发生产高速列车的平均时间从三年降低到两年半, 平均年产列车达到了 450 列。

参 考 文 献

- [1] Raymond L.Orbach,advancing scientific discovery through transformational science .IBM Center for The Business of Government .2008 .
- [2] 肖田元.仿真是基于模型的实验吗? ——从定义的演变看仿真的内涵发展.系统仿真学报, 2009,21(22):7368—7371 .
- [3] 王子才.仿真科学的发展及形成.系统仿真学报,2005,17(6):1279—1281 .
- [4] Spur G,Krause F L.虚拟产品开发技术.宁汝新,等译.北京:机械工业出版社,2000 .
- [5] 谭建荣,刘振宇.数字样机:关键技术与产品应用.北京:机械工业出版社,2007 .

撰稿人: 刘振宇

浙江大学 CAD&CG 国家重点实验室

从多幅照片还原立体场景：复杂三维场景重建中的对应点自动匹配问题

Stereo Reconstruction from Multiple Photos : Automatic Point Matching for 3D Reconstruction of Complex Scenes

从实际拍摄的图像或视频序列中自动、高精度地构建出场景的三维模型是计算机视觉领域的基本问题，在视觉信息处理中具有广泛的应用与需求，该问题的解决将使人们可以便捷地获取实际场景的三维信息，为空间导航定位、虚实场景融合、数字立体视频合成等技术的发展奠定了基础。

基于图像/视频的三维重建的理论基础是多视图几何原理^[1]，目前已经比较成熟。经过二十余年的发展，已有许多有效的重建方法，但重建的稳定性一直阻碍着这些方法的深度应用，尤其对实际复杂场景，这些方法无论在计算稳定性还是处理规模和计算效率等方面都存在不同程度的问题，其核心问题在于计算机系统难以准确地将分布在不同视图上、而又来自空间同一点的特征点自动辨识出来，即对应点自动匹配问题(automatic point matching)。尽管近年来文献中所报道的一些方法^[2~5]在一定程度上提高了匹配的精度和稳定性，但离一般场景自动准确的三维重建要求仍有较大距离。

假设场景静止，根据多视图几何原理^[1]，我们可以从多幅不同位置下拍摄的图像中恢复出摄像机的内外参数和场景的三维信息。通常的技术路线分为两个步骤：①首先，在各张图像上抽取一些稀疏的特征点并进行匹配，然后根据这些二维的对应点求解出各张图像的摄像机参数，并恢复出这些特征点的三维位置。②在已知摄像机参数的条件下，通过立体匹配进一步得到稠密的匹配点，从而恢复出场景的稠密三维信息。其中，第一个步骤称为运动推断结构(structure from motion)，第二个步骤称为立体匹配(stereo matching)。

仅考虑两幅图像的立体匹配又称为双视图立体匹配^[6]。双视图立体匹配相对比较简单，其恢复深度的原理跟人类通过左右两只眼睛立体地观察现实世界类似。如图1所示，左视图上的点 x_l 与右视图上的点 x_r 对应场景中的同一个空间点，但两者在不同视图上的投影位置存在偏差(即 $d = x_l - x_r$)，这个偏差称为视差。鉴于视差跟深度成反比，立体匹配方法据此就可计算出图像的深度信息。但是，双视图立体匹配方法有其固有的缺陷，容易受噪声影响，尤其难以处理遮挡(一旦左右视图上的某个区域被遮挡，就无从匹配)情形，这一缺陷可通过引入更多的视图予以克服。近来的研究进展表明，多视图立体匹配方法^[2~5]由于

可以利用多视图上的有效信息,在处理噪声和遮挡问题方面具有明显的优势,可以得到更好的三维重建结果。因此,基于多视图的三维重建目前更为大家所常用。




图1 双视图立体匹配

基于双/多视图的三维重建,其核心问题在于如何解决对应点的准确匹配。虽然原理上目前已经研究得比较清楚,但由于实际情况的复杂性,由视频或多幅图像自动地重建出现实三维场景仍存在诸多问题。现实场景可能存在遮挡、光照变化、镜面反射和高光等,部分区域可能缺乏特征,而且实际拍摄的图像或视频又不可避免地存在畸变、噪声、曝光差异及白平衡等问题,这些诸多因素给准确的三维重建带来了极大的困难。针对这些问题,研究者们陆续地提出了各种解决方案。例如,用分割方法来改善无特征区域的匹配问题^[7];采用鲁棒函数、可见性判断并结合全局优化来减轻噪声和遮挡的影响^[8];将颜色空间转换到色度对数颜色空间,采用迭代的方法进行深度估计和颜色一致性校正,以解决存在曝光差异的立体图像的匹配问题^[9]。然而,这些解决方法往往是一把双刃剑,虽然它们能带来一定程度的改善,但同时也会引入一些新的问题(如因分割不准确可能带来深度估计的误差)。另外,这些方法往往仅适用于较为理想的情况(如漫射场景等),而难以鲁棒地处理各种复杂情况,尤其对于存在明显局部光照变化的场景,目前尚缺乏有效的方法。

更进一步,如何将不同视角下的深度图像或三维点云数据融合生成完整的三维几何模型,则是另一个开放性的研究课题。因为恢复的深度或三维点云数据不可避免地存在噪声,甚至还有错误,这给几何拓扑的判断和几何表面的生成带来了很大的挑战,尤其对于大规模的场景,实现完整的三维模型自动重建仍是一个公认的难题,有待于进一步研究解决。

上述重建方法本质上是一种由低层的局部特征恢复场景的全局几何过程,由于实际场景的高度复杂性,要实现全自动、无先验知识的通用三维重建尚存在诸多困难,特别是对于植物、树木、建筑物等复杂对象,由上述方法来实现准确的自动重建近乎不可能。一种可行的解决方法是引入一些先验性的知识或

规则来合成这类物体的三维模型，这些高层全局的信息可有效减少重建中的不确定性，从而提高三维重建的鲁棒性。可以说，低层局部特征匹配和高层全局语义的有机结合将是实现由视频和多角度图像自动重建三维场景的重要途径。

参 考 文 献

- [1] Hartley R,Zisserman A .Multiple View Geometry in Computer Vision .2nd ed .Cambridge : Cambridge University Press ,2004 .
- [2] Seitz S M ,Curless B ,Diebel J ,et al .A comparison and evaluation of multi-view stereo reconstruction algorithms .Proc .IEEE Conference on Computer Vision and Pattern Recognition , 2006 ,(1) ;519—528 .
- [3] Furukawa Y ,Ponce J .Accurate camera calibration from multi-view stereo and bundle adjustment .International Journal of Computer Vision ,2009 ,84(3) ;257—268 .
- [4] Zhang G F ,Jia J Y ,Wong T T ,et al .Consistent depth maps recovery from a video sequence . IEEE Transactions on Pattern Analysis and Machine Intelligence ,2009 ,31(6) ;974—988 .
- [5] Furukawa Y ,Ponce J .Accurate ,dense ,and robust multiview stereopsis .IEEE Transactions on Pattern Analysis and Machine Intelligence ,2010 ,32(8) ;1362—1376 .
- [6] Scharstein D ,Szeliski R .A taxonomy and evaluation of dense two-frame stereo correspondence algorithms .International Journal of Computer Vision ,2002 ,47(1/2/3) ;7—42 .
- [7] Tao H ,Sawhney H S ,Kumar R .A global matching framework for stereo computation . Proc .IEEE International Conference on Computer Vision ,2001 ;532—539 .
- [8] Sun J ,Li Y ,Kang S B .Symmetric stereo matching for occlusion handling .Proc .IEEE Conference on Computer Vision and Pattern Recognition ,2005 ,(2) ;399—406 .
- [9] Heo Y S ,Lee K M ,Lee S U .Simultaneous color consistency and depth map estimation for radiometrically varying stereo images .Proc .IEEE International Conference on Computer Vision ,2009 ;1771—1778 .

撰稿人：章国锋

浙江大学 CAD&CG 国家重点实验室

计算机全息图形的生成

Generation of Computer Hologram

物体之所以可见,是由于可见光波投射到物体表面后,经过表面的反射和折射,射入人眼后的结果。正是由于表面对不同波长的光的反射属性各异,人类才能识别物体的形状和表面颜色。但实际上,可见光只是一种波长介于 $400\sim 700\text{nm}$ (10^{-9}m) 之间人眼所能感知到的一段电磁波。在电磁波谱中,可见光仅占极为狭窄的一段(如图 1 所示),而大量不可见的其他波段的电磁波信息则不能直接为人眼所感知。若能有效地开发这些波段(如红外线、毫米波、紫外线、X 射线、 γ 射线)及声波等图形成像技术,并将其成像信息加以有效合成,必将大大增强人类认识世界的能力。




图 1 电磁波谱图

所谓计算机全息图形,即融合了多波段、多渠道信息、较为全面体现物体特性的计算机合成图形。相比基于单一波段或渠道信息生成的计算机图形,该全息图形将能向人类提供更为全面的物体和场景信息。

目前,已开发出红外夜视技术、超声波扫描、X 射线 CT 扫描、核磁共振(MRT)扫描、正电子发射断层(PET)扫描、雷达成像等多种技术,这些波段的成像各有优势,对于同一场景的物体,具有在时空上的相关性及信息上的互补性。例如,对人眼来说,可见光成像具有丰富的细节和敏锐的色感,但它在恶劣的气候下对大气的穿透能力较差,在夜间的成像能力较差;而红外光成像正好相反,它在云层及浓烟滚滚等恶劣条件下的穿透成像能力相当强,在夜间由于不同景物之间存在着温度差,因此,所成的图像仍能显示景物的轮廓,但其

成像的分辨率则较低^[1]；雷达(毫米波)是迄今为止最为有效的远程电子探测设备^[2]，合成孔径雷达(SAR)成像具有更强的穿透性和全天候成像的能力，但雷达图像缺乏足够的细节。若能对这些多光谱波段的信息进行适当地合成，则可消除因大气衰减、衣物阻挡等引起的图像模糊和消失，从而获得清晰度增强的目标图像，提高了对目标的探测和识别能力。

从历史上看，人们已认识到采用不同波段成像探测技术及其信息合成可为人类带来意想不到的难题解决方案。例如，目前的飞行物隐形技术主要针对毫米波雷达，它通过对飞行物外形巧妙的几何设计及在机体上面涂一种能产生等离子体的涂料，使发射来的雷达波大部分被散射或吸收掉，从而达到减少雷达波反射的目的。目前，一架隐形战斗机的雷达截面只有一只小鸟大小，从而实现隐形，但这类隐形技术主要对毫米波量级的雷达有效，而对波长更长的分米波(或米波)雷达则基本不起作用。因此，苏联坚持研究开发的米波雷达可探测到毫米波雷达所不能探测到的敌方“隐形”飞行物，成为美国“隐形”飞机的克星。科索沃战争期间，前南斯拉夫就是用老旧的俄制米波雷达多批次连续扫描在美隐形战机 F117 弹仓开启的一瞬间将其捕获，并用老式的 SA7 导弹将其击落。

人类在夜间的视力大大减弱，但由于红外光独特的温差成像机制，使得即使是漆黑的夜里，其红外成像仪仍可较清晰地探测出目标轮廓的成像。为了在夜里“看得像白天一样清楚”，20 世纪末，美国麻省理工学院林肯实验室的研究人员实现了红外和可见光探测器双波段夜视图像的实时彩色融合，使得合成的目标图像既有可见微光图像较为明锐的色感细节，又有红外图像明显的物体温差轮廓，并进而开发出综合可见光、短小红外、中红外和长波红外 4 种传感图像在内的实时融合的夜视系统，其合成的图像反映出目标的多种光谱特性信息，可应用于夜间侦察及目标搜索等^[3]。

在医学诊断中，CT 及 MRT 成像对于反映精细的解剖结构具有明显的优势，但对于肿瘤部位的早期诊断则不够灵敏；而 PET 成像对显示早期功能代谢异常的病灶诊断很灵敏，特别适合在复杂的解剖结构中发现肿瘤及定位早期的癫痫病灶，但其成像的精细度不是很高。因此，若能将 CT 及 MRT 成像与 PET 成像进行完美地合成，则合成的图形既能灵敏有效地定位早期肿瘤的病灶，又能显示身体内部精细的解剖结构，这对于医生的准确治疗诊断将有很大的帮助。

目前的计算机图形真实感生成技术^[4]主要针对可见光波段，其成像光照模型主要是根据可见光波段的反射、折射和透射规律建立起来的；而对于上述其他波段的成像规律则鲜有深入的研究。其他波段的成像规律与可见光成像相比，各有其不同的特点。例如，红外线的自身辐射温差成像及对烟雾颗粒

的散射透过特性；X 射线及波长更短的 γ 射线对硬物的强穿透性；不同雷达波长对物体尺寸的反射、散射成像特性及波长大小对材料涂层厚度的吸引特性影响等。

对于计算机全息图形的生成，目前主要存在以下亟待研究解决的问题：

(1) 面向非可见波段电磁波信号的计算机成像模型的建立。各电磁波段及其他成像手段(如超声波等)的成像各有其规律特性，可根据各自特性，并考虑目前计算机图形学中卓有成效的可见光成像模型，分别具体建立起各自对应的成像模型。

(2) 不同波段成像的有效图形合成。要生成能反映不同波段光谱特性的合成图形，必须提出有效的融合模型^[5]。

(3) 统一的计算机全息图形生成模型的建立。在已建立的各波段的光谱成像模型基础上，研究其共性，提出并建立起统一的计算机全息图形生成的理论及模型，从而使得该模型适用于全波段，这样，可大大提高物体的计算机全息图形的建模效率，并能通过改变特性参数，可以方便地根据不同需求快速生成不同的物体场景的计算机全息图形。

以上着重考虑了不同波段的电磁波在物体表面的反射、透射及相关信息的融合和可视化。为了全方位地集成多领域、多渠道、可见或不可见的各种信息，应进一步开展多源、多模态信息的整合及可视化。例如，在遥感地图上根据敌我双方战术演练的态势进行动态战场合成；基于城市地图上一段时间的手机通信量分布(通过通信部门)分析产业的分布、人群的流动等。另一方面，可开展基于用户关注度的场景信息的表达式显示上。例如，在旅游地图上选择性地显示出某一区域的旅馆、商场及景点的分布情况；而在决策层面上，可对各种信息进行提炼、归纳、推理，动态显示决策者所关注高层信息，而舍去较低层次的信息细节，从而对重要的决策提供可视化的支持。

参 考 文 献

- [1] Wang Z Y, Peng Q S, Lu Y Q, et al. A global infrared image synthesis model for large-scale complex urban scene. *International Journal of Infrared and Millimeter Waves*, 2001, 22(8): 1193—1208.
- [2] Zhao X H, Qu L. Analysis of radar countermeasures against stealth technology. *Modern Radar*, 2007, 29(3): 17—18.
- [3] Fay D A, Waxman A M, Aguilar M, et al. Fusion of multi-sensor imagery for night vision: Color visualization, target learning and search // *Proc. of 3rd International Conference on Information Fusion*, Paris, 2000.
- [4] 彭群生, 鲍虎军, 金小刚. 计算机真实感图形的算法基础. 北京: 科学出版社, 1999.

-
- [5] 韩崇昭,朱洪艳,段战胜.多源信息融合.北京:清华大学出版社,2006.

撰稿人: 彭群生 王章野
浙江大学 CAD&CG 国家重点实验室

虚拟环境与真实环境的“无缝”融合

The Seamless Combination of Virtual and Real Environments

以计算机和传感器为核心的相关科学技术飞速发展与交叉融合,不断促进虚拟环境与真实环境的有机融合,虚实融合的“无缝性”或者“一致性”问题已经成为涉及多学科多领域的科学技术难题,其中,主要有虚拟环境与真实环境的一致性描述和构建是否能够充分表达各种类型的虚实对象及其特性,虚拟环境与真实环境的信息交互与有效作用是否能够遵循客观规律并且使虚实对象相互理解,虚拟环境与真实环境的无缝化融合效果表现是否能够为用户提供逼真感知和精准认知。

人类在探索自然、认识自然、模拟自然、改造自然过程中创造、发展和利用虚拟现实科学技术,将真实世界的多维信息映射到可计算的数字空间,使用户能够在虚拟环境中操作各种虚拟对象、突破物理空间和时间的限制、建立接近于真实世界的虚拟场景;也可以将计算机生成的虚拟场景和虚拟作用反馈到真实世界,使用户能够获得虚拟环境产生的各种逼真感知,获得亲临等同真实环境的沉浸感^[1,2]。

传统的虚拟环境强调虚拟场景建模和虚拟场景表现,经常利用三维几何模型生成虚拟场景,但在真实数据采集、几何模型构建、场景逼真表现等方面存在相对难以克服的问题,也难以证明“真实世界的所有事物都是可以几何模型化或者数字化建模”。另一方面,飞速发展的传感器科学技术已经越来越多地运用于许多行业和领域,能够直观、快速、准确地描绘丰富多彩的真实世界,以可见光相机为例,人们已经越来越习惯于利用图像和视频记录工作和生活的真实环境。所以,以计算机和传感器为核心的相关科学技术不断促进虚拟环境与真实环境的有机融合。

Milgram 教授是早期从事虚实融合研究的学者之一,他根据人机环境中真实世界与计算机生成信息之间的比例关系,提出了虚拟环境与真实环境的关系图谱^[3],描述了混合现实、增强现实、增强虚拟的基本概念及相互之间的关系。许多科研工作者围绕“虚实融合”开展理论、技术和系统研究,并且逐渐认为,虚实融合的“无缝性”或者“一致性”问题是其中的共性化、基础性科学技术难题,是影响虚实融合场景逼真性、准确性及其应用前景的最重要因素。

以用户视觉感知与虚实融合视景为例,用户经常较容易地分辨出“有缝”虚实融合视景的虚拟景物与真实景物,而对于较理想的“无缝”虚实融合视景,

用户一般很难仅凭视觉感知分辨出虚实景物及其特征。类似地,对于虚拟环境与真实环境的理想“无缝”融合效果,用户难以通过视觉、听觉、触觉、力觉等感知通道分辨出虚与实。

虚实融合的“无缝性”问题主要涉及信息描述与表达、信息交互与理解、信息表现与认知三个方面。

(1) 虚拟环境与真实环境的一致性描述和构建是否能够充分表达各种类型的虚实对象及其特性。虚拟环境与真实环境经常特征迥异,可能源于不同的物理空间、隶属不同的信息空间,需要研究虚拟环境与真实环境的一致性描述和构建方法,以充分表达各种类型的虚实对象及其特性,如可描述性和可计算性、特性维度和维度组合、信息精度和精度耦合。

(2) 虚拟环境与真实环境的信息交互与有效作用是否能够遵循客观规律并且使虚实对象相互理解。虚拟环境与真实环境之间的信息理解是虚实无缝融合的必要条件,需要立足于客观规律,探索虚拟环境与真实环境之间的内在联系,寻找两者之间的有效交互方式与作用原理,为虚实对象相互理解提供理论依据和技术支撑。

(3) 虚拟环境与真实环境的无缝化融合效果表现是否能够提供逼真感知和精准认知。如何度量和评价虚实融合的无缝化程度及效果一直是困扰人们的难点问题,需要从用户感官特点和认知规律出发,不断完善虚实融合的评价体系及其标准,改进虚实融合的无缝指标度量方式方法,在此基础上,不断提升虚拟环境与真实环境的无缝化融合效果表现方法和技术。

虚实融合的无缝问题研究涉及认知心理学、传感器、信号处理、计算机图形学、图像处理、计算机视觉、视频处理、人机交互、人工智能、高性能计算等领域或方向,需要多学科、多领域、多方向的研究人员共同开展多层面的探索和研究。例如,光是人们获取视觉感知的必要条件,光照模型或者光场数据是生成逼真视景的必要因素,虚拟环境与真实环境的虚实光照效果无缝融合必须建立在虚拟环境光照模型、真实环境光场表示、虚实光照信息交互等基础之上。基于计算机图形学的虚拟环境光照模型^[4]主要依托多边形面片组成的三维几何模型,根据真实世界客观存在的光照物理规律,利用参数化的计算模型,近似描述真实世界的光场信息,近似模拟入射光场与几何模型之间的光照作用。基于视频图像的真实环境光场分析与表示^[5],可以利用高速视频采集系统,在变光照条件下采集全空域全时域的动态真实对象光场数据,需要发现并构建大规模光场数据的基本表示单元集,形成基于光场基元的视频场景光照效果生成理论体系,从而再现、迁移、生成基于视频图像的真实环境光照效果^[6]。虚拟环境与真实环境的虚实光照效果无缝融合,可以利用基于视频图像的真实环境光场分析与表示结果,确定基于计算机图形学的虚拟环境光照模型,使得虚拟

环境的光照效果接近于真实环境^[7]。广义上而言,也可以利用场景风格一致化处理^[8],对真实环境的视频图像及其光照效果进行风格转化,以接近虚拟环境的光照效果风格。所以,虚实融合的无缝问题是一个典型的学科交叉、领域交叉、方向交叉的难点问题。

虚实无缝融合问题目前已经成为研究热点,人们虽然很难在短时间内彻底攻克这个难题,但可以围绕该问题,从多个方面开展新理论、新算法、新技术和新技术研究。以用户视觉感知与虚实融合视景为例,人们正在开展虚实对象的基本描述单元及其一致性处理、虚实对象的一致知识表达及其理解机制、支持高精度融合的虚实对象三维注册、虚拟环境与真实环境之间的虚实光照融合、支持用户准确交互操作的虚实空间一致感知、基于用户视觉感知的虚实无缝融合度量与评价体系等方面的研究工作。

希望通过多学科、多领域的各界同仁共同努力,逐步解决虚实融合在信息描述与表达、信息交互与理解、信息表现与认知方面的无缝问题或一致性问题。

参 考 文 献

- [1] 汪成为,等.灵境(虚拟现实)技术的理论、实现及应用.北京:清华大学出版社,1997.
- [2] Zhao Q P.A survey on virtual reality .Science in China Series F ;Information Sciences ,2009 ,52(3):348—400 .
- [3] Milgram P,Kishino F.A taxonomy of mixed reality visual displays .IEICE Trans .on Information Systems ,1994 ,E77-D(12):1321—1329 .
- [4] Phong B.Illumination for computer generated pictures .Communications of the ACM ,1975 ,18(6):311—317 .
- [5] Debevec P,Hawkins T,Tchou C,et al.Acquiring the reflectance field of a human face .ACM SIGGRAPH ,2000 .
- [6] Peers P,Tamura N,Matusik W ,et al.Post-production facial performance relighting using reflectance transfer .ACM SIGGRAPH ,2007 .
- [7] Lalonde J F,Efros A A,Narasimhan S G.Estimating natural illumination from a single outdoor image .International Conference on Computer Vision (ICCV) ,2009 .
- [8] Lischinski D,Farbmán Z,Uyttendaele M ,et al.Interactive local adjustment of tonal values .ACM SIGGRAPH ,2006 .

撰稿人:陈小武

北京航空航天大学虚拟现实技术与系统国家重点实验室

自然高效的人机交互

Natural and Efficient Human Computer Interaction

人机交互主要研究交互式计算系统的设计、评估与实现。随着计算机应用的普及和软硬件技术的进步,人机交互技术在社会、经济和国家安全等领域中扮演着越来越重要的角色,“以人为本”、“人机和谐”、自然高效的人机交互问题正越来越受到人们的重视。

人机交互和计算机的发展是相辅相成的。一方面,计算机速度的提高使人性化的交互成为可能;另一方面,人机交互的发展推动着信息技术的大众化应用。事实上,正是人机交互技术的进步(如 GUI)造就了辉煌的个人计算机时代(20 世纪 80~90 年代)。鼠标、图形界面的使用大大提高了交互效率,促进了个人电脑的普及。近年来,计算设备的处理速度和存储容量都得到大幅提高,各种传感器网络逐步普及,互联网的带宽成倍增加,信息技术飞速发展并逐步融入到人们的日常生活中。此时,人机交互已逐步成为制约计算技术发展的主要瓶颈^[1],自然高效的人机交互问题日益成为学术界和工业界面临的重要挑战。

计算机处理速度和性能的迅猛发展使得用户界面成为制约计算技术发展的主要瓶颈,如何实现自然高效的人机交互、提高用户利用计算资源的生产力是信息技术面临的重要问题。例如,在指挥控制、日常办公、医疗保健等许多重要领域,由于用户对象、应用环境、交互信息等方面的特点,在信息输入输出及处理方式等方面对人机交互提出了新的需求。人机交互是否自然高效直接关系到这类应用系统效能的发挥与应用普及。

自然高效的人机交互力图在自然交互场景中通过自然交互方式实现高效人机交互。在自然交互场景中,人们可以在日常生活和工作的各个领域随时随地与计算环境进行交互。在自然交互方式下,人们可以通过手势、言语、笔迹等单个通道的自然方式进行输入,甚至是非主动方式(如生理、脑电信号等),也可以是融合多个通道信息的人机交互。自然人机交互带来了传统人机界面的彻底改变。在自然人机交互中,没有了计算机和用户的明确界线。计算机将作为多个智能化的计算设备融入到用户和环境中,它们采集用户和环境的交互信息,通过多通道信息融合和用户意图理解,智能化地执行交互任务^[2,3]。

自然人机交互的核心科学问题是对人、机、环境相互作用的理解和建模问题。如何理解人的外部行为和内在心理、生理状态?如何描述和建模人、计算和环境之间的关系和相互作用?只有在上述问题解决后,才能从根本上实现自然人机交

互。自然高效的人机交互需要涉及计算机科学、认知心理学、人机工效学、人工智能等多个学科领域知识,需要分析用户日常生活和工作情景,扩展人和计算机的感知认知处理和交互能力。目前,人机交互领域的研究者已经针对这些问题展开了相关研究,取得了一些阶段性的成果,如普适计算、移动交互、增强现实等方面的研究可以帮助用户搭建符合日常工作生活环境的自然交互场景,笔式、语音、视觉等多通道人机交互技术可以帮助用户通过自然的方式同计算环境进行交流,但就解决自然人机交互的核心科学问题角度,目前的工作才刚刚开始。需要利用分布式认知^[4]等理论,研究用户对多通道信息的感知、处理模式和呈现方式^[5];分析用户心理特征和交互行为,研究多个感觉和效应通道行为的复杂组合问题及并发性问题;通过定量性能参数的测定,支撑和量化用户模型中的参数。与此同时,需要分析自然人机交互中的交互特征,研究交互信息的词法、语法和语义处理方式,研究认知空间、计算空间和物理空间相互的融合和协作问题,建立基于感知输入、动作输出和应用计算之上的自然人机交互模型。

目前,世界各国都将人机交互作为研究重点。1999年,美国总统顾问委员会报告中将“人机交互和信息处理”列为21世纪信息技术基础研究的4个主要方面之一;2007年,美国NSF在信息与智能系统(IIS)中列出的三个核心技术领域之一是以人为本的计算,其具体主题包含多媒体和多通道界面、智能界面和用户建模、信息可视化,以及高效的以计算机为媒介的人人交互模型等^[6];2007年,欧盟第七框架项目中也包含了自然人机交互的内容。目前,一些著名的研究机构,如美国加州大学伯克利分校、卡内基梅隆大学、斯坦福大学、麻省理工学院、华盛顿大学、Microsoft、IBM、英特尔、Nokia、飞利浦等大学和著名公司的研究机构逐渐将研究重点转移到自然人机交互的研究上,分别面向特定领域作了许多有益的尝试,已经有一些重要的研究成果产生,ACM SIGCHI、ACM UIST、ACM IUI等著名的人机交互会议都将相关的研究内容作为会议的一个重要议题。我国中长期科技发展规划已将人机交互列为前沿技术和基础研究的重要内容,2009年9月出版的《中国至2050年信息科技发展路线图》也将人机交互列为重要发展内容^[7]。人机交互越来越受到国内学术机构和工业界的广泛重视。

目前,关于自然高效的人机交互方面的研究刚刚起步,并没有建立起相应的理论和技术体系,缺乏模型和评估框架的有效支持。虽然有一些针对特定领域的应用,但在如何建立自然人机交互模型、用户模型等关键理论研究,如何有效地感知和融合来自用户身体和环境的多个通道的信息,如何理解用户的交互意图等关键方法研究未有关键性的突破。

本问题未来若干年的研究热点将集中在针对自然人机交互的基础理论和关键技术方面进行突破,主要包括针对自然人机交互的模型和评估框架;对人外部行为、内部特征的理解和建模,环境的感知和建模;基于手写、语音、视觉、脑电等

生物信号的感知界面关键技术等。相关的扩展问题主要包括分布式认知理论、用户生理、心理和情感状态建模等。

参 考 文 献

- [1] Dertouzos M .The Unfinished Revolution ;Human-Centered Computers and What They Can Do for Us .New York ;HarperBusiness ,2001 .
- [2] Canny J .The future of human-computer interaction .ACM Queue ,2006 ,4 (6) :24—32 .
- [3] Harper R ,Rodden T ,Rogers Y ,et al .Being human ;Human-computer interaction in the year 2020 .Microsoft Research ,2008 .
- [4] Hollan J ,Hutchins E ,Kirsh D .Distributed cognition ;Toward a new foundation for human-computer interaction research .ACM Transactions on Computer-Human Interaction ,2000 ,7 (2) :174—196 .
- [5] Oviatt S ,Darrell T ,Flickner M .Multimodal interfaces that flex ,adapt ,and persist .Communications of the ACM ,2004 ,47 (1) :30—33 .
- [6] <http://www.nsf.gov/div/index.jsp?div=IIS> .
- [7] 中国科学院信息领域战略研究组 .中国至 2050 年信息科技发展路线图 .北京 :科学出版社 ,2009 .

撰稿人：王宏安 田 丰
中国科学院软件研究所

海量数据可视化分析

Massive Data Visual Analysis

2010 年,世界新增信息总量为 988 艾字节,且这个数量以每年至少 30% 的比率增长。这些信息来自:保存在服务器和个人电脑上以亿为单位的结构化或非结构化的文本数据(如新闻、博客、论坛、网页);科研机构、政府机关和企业的运行过程中累积的大量分散存储的医学、生物、气象、商业和地质数据库(如科学计算模拟数据);个人和社会团体在网络、社会、生活中生成的大量局部关系数据库(如社交网络、通话记录);各类影像获取设备(如视频监控系统、卫星)实时产生的流媒质数据;在线收集自然环境和社会生活中的传感器数据(如手机、GPS 定位、温度、光照、热度)。海量数据带来的挑战不仅在于它们分散、大尺度、动态和异构,还在于它们可能是模糊的、未确定的、谬误的、互相矛盾的^[1]。

为海量数据创造有效方法和系统以揭示有效信息的难点在于数据量的庞大和数据的高维度^[2]。自 20 世纪 80 年代兴起的可视化技术是一门利用人眼的感知能力对数据进行交互的可视表达以增强认知的学科^[3]。人眼是一个高带宽、巨量并行的感知处理器,具有很强的模式识别能力,对可视符号的感知速度比对纯粹的数字或文本快数个数量级^[4],且绝大多数是下意识的。将人的感知和认知能力融入数据挖掘的过程,可形成信息交互的循环通道,有效提高现有数据分析方法的效率,且特别适用于海量数据的分析困境:不知道数据中蕴含的模式;搜索空间过大;模式过于模糊;参数很难设置。海量数据可视化分析旨在从海量、动态、模糊甚至错误的数据中挖掘有用的信息,检测可能的事件,发现无法预测的时间,做出及时的、可防御的、易理解的评估,为推理决策提供可视化、分析和交互的工具。

可视化分析与科学计算可视化和信息可视化的侧重点不同。科学计算可视化产生于 20 世纪 80 年代,当时的研究重点是带有空间坐标和几何信息的医学影像数据、三维空间信息测量数据、流体计算模拟数据等。由于数据的规模通常超过图形硬件的处理能力,如何快速地呈现数据中包含的几何、拓扑和形状特征是研究的热点。随着图形硬件和可视化算法的迅猛发展,数据的显示得到了较好的解决。20 世纪 90 年代中期,非结构化、非几何的抽象数据(如金融交易、社交网络、文本数据)的大量涌现,促生了信息可视化的热潮。信息可视化的核心问题主要有高维数据的可视化、数据间各种抽象关系的可视化、用户的敏捷

交互可视化有效性的评断等。其中,针对数据的大尺度如何减少视觉混淆对有用信息的干扰一直是研究的关注点。进入 21 世纪,现有的可视化技术已难以应对海量、高维、多源和动态数据的分析需求。2005 年,美国 NSF 联合美国 NIH 召集了一个新的专题小组,讨论可视化研究的现状和面临的挑战,并于 2006 年出版了一个专题报告^[2]描述大规模数据可视化所面临的挑战。与此同时,2004 年,美国国土安全部为了应对恐怖袭击,成立了国家可视分析中心(NVAC)。可视分析迅速成为可视化领域的研究热点之一。NVAC 于 2005 年出版的名为 *Illuminating the Path: The Research and Development Agenda for Visual Analytics* 一书^[1]强调,可视分析着重于对一个问题的全面解决,其核心是采用可视化和用户交互方法,辅助用户从大尺度、复杂、矛盾甚至不完整的数据中快速挖掘有用信息以便做出有效决策。

海量数据的可视化分析与智能信息处理技术的侧重点不同,需要在信息可视化的基础上研究新的理论模型、新的可视化方法和新的用户交互手段,探索新的利于可视化的海量数据抽取和抽象方法。从可视化流程的三个环节上看,海量数据可视化分析面临的主要挑战包括信息、视觉、显示、用户和软件系统的可扩充性^[1]。其中,视觉可扩充性是指可视化表达和可视化工具有效显示海量数据的能力。信息可扩充性是从海量数据流中抽取相关信息的能力。软件可扩充性是指软件容纳变尺寸数据集的能力。

(1) 数据表示与变换。数据可视化分析的基础是数据表示和变换。为了允许有效的可视化、分析和记录,输入数据必须从原始状态变换到一种便于计算机处理的结构化的数据表示形式。通常,这些结构存在于数据本身,需要研究有效的数据提炼或简化方法以最大程度地保持信息和知识的内涵及相应的上下文。构建海量数据的有效表示的主要挑战在于表示方法的可伸缩性和扩展性,以便忠实地保持数据的内容。此外,将不同类型、不同来源的信息合成到一个统一的表示,使得数据分析和处理者能及时聚焦于数据的本质也是难题之一。

(2) 数据的可视显示。将数据以一种直观、容易理解和操纵的方式呈现给用户,需要将数据表达转换为可视表示并呈现给用户。由于大量的数据采集是以流的形式实时获取,针对静态数据发展起来的可视化显示方法不能直接拓展到动态数据,这不仅要求相邻时间段所产生的可视化结果有一定的连续性,还要求可视化方法达到高效以便给出实时反馈。海量数据可视化分析不仅需要研究新的软件算法,还需要更强大的计算平台(如分布式计算或云计算)和显示平台(如 1 亿像素显示器或大屏幕拼接)。

(3) 用户交互。交互是海量数据可视化分析中通过可视的手段辅助分析决策的直接推动力。有关人机交互的探索已经持续很长时间,但智能的适用于海量数据可视化的交互技术,如任务导向的、基于假设的方法还是一个未解难题,

其核心挑战是新型的可支持用户分析决策的交互方法。这些交互方法涵盖底层的交互方式与硬件、复杂的交互理念与流程,更需要克服不同类型的显示环境和不同任务带来的可扩充性难点。

海量数据的可视化分析是一个涉及数据挖掘、人机交互、计算机图形学等的交叉学科。如何将这些学科的相关知识有机地结合到一起,开发高度集成的可视分析系统是未来一个重大的研究课题,它在国民经济和国防安全的各个领域都会引申出重大应用难题,如天气预报、数字城市、金融安全、社会网络等。

参 考 文 献

- [1] Thomas J J, Cook K A. Illuminating the Path: The Research and Development Agenda for Visual Analytics. Seattle: National Visualization and Analytics Center, 2005.
- [2] http://dash.harvard.edu/bitstream/handle/1/4138744/Johnson_NIH-NSF.pdf?sequence=1.
- [3] Hansen C D, Johnson C R. The Visualization Handbook. New York: Academic Press, 2004.
- [4] Tufte E. Envisioning Information. New York: Graphics Press, 1990.

撰稿人: 陈 为¹ 屈华民²

1 浙江大学 CAD&CG 国家重点实验室

2 香港科技大学计算机学院

静态输出反馈下的干扰解耦

Disturbance Decoupling Problem with Static Output Feedback

1. 问题的描述

考虑一般的线性系统

$$\Sigma: \begin{cases} \dot{\mathbf{x}} = \mathbf{A}\mathbf{x} + \mathbf{B}\mathbf{u} + \mathbf{E}\mathbf{w} \\ \mathbf{y} = \mathbf{C}_1\mathbf{x} + \mathbf{D}_{11}\mathbf{u} + \mathbf{D}_{12}\mathbf{w} \\ \mathbf{z} = \mathbf{C}_2\mathbf{x} + \mathbf{D}_{21}\mathbf{u} + \mathbf{D}_{22}\mathbf{w} \end{cases} \quad (1)$$

式中, $\mathbf{x}$ 是状态变量; $\mathbf{u}$ 是控制输入变量; $\mathbf{w}$ 是外部干扰输入; $\mathbf{y}$ 是测量输出变量; $\mathbf{z}$ 是系统的被控输出。不失一般性, 我们假设 $\mathbf{D}_{11} = 0$, 并用 Σ_p 和 Σ_q 分别表示由矩阵四元组 $(\mathbf{A}, \mathbf{B}, \mathbf{C}_2, \mathbf{D}_2)$ 和 $(\mathbf{A}, \mathbf{B}, \mathbf{C}_1, \mathbf{D}_1)$ 所表征的子系统。

所谓静态输出反馈下的干扰解耦问题, 就是寻找一个静态测量反馈控制律

$$\mathbf{u} = \mathbf{K}\mathbf{y} \quad (2)$$

当它用来控制系统(1)时, 所得到的从干扰输入 $\mathbf{w}$ 到被控输出 $\mathbf{z}$ 的闭环传递函数恒等于零, 即

$$(\mathbf{C}_2 + \mathbf{D}_2 \mathbf{K} \mathbf{C}_1) (s\mathbf{I} - \mathbf{A} - \mathbf{B} \mathbf{K} \mathbf{C}_1)^{-1} (\mathbf{E} + \mathbf{B} \mathbf{K} \mathbf{D}_{12}) + \mathbf{D}_{22} + \mathbf{D}_2 \mathbf{K} \mathbf{D}_{12} \equiv 0 \quad (3)$$

如果要求闭环系统是稳定的, 也就是要求 $\mathbf{A} + \mathbf{B} \mathbf{K} \mathbf{C}_1$ 的特征值都在左半复平面上, 所对应的问题则称之为内部稳定静态输出反馈下的干扰解耦。

2. 问题的研究动机和历史

干扰解耦问题在过去四十多年里已经被广泛研究过, 这项研究实际上推动了系统理论几何方法的发展, 它也在一系列控制问题的研究中, 如分散控制、无交互控制、模型参考跟踪控制、 H_2 优化控制和 H_∞ 控制等, 发挥了重要作用。干扰解耦问题可以归结为寻找一个静态的或动态的补偿控制器, 使得从干扰输入到被控输出的闭环传递函数在所有频率上都等于零, 也就是干扰输入对控制输出没有任何影响。

状态反馈下的干扰解耦问题已经由 Basile 和 Marro^[1] 及 Wonham 和 Morse^[2] 解决, 动态测量反馈下的干扰解耦问题已经由 Akashi 和 Imai^[3] 及 Schumacher^[4] 解决。最后, 状态反馈和内部稳定下的干扰解耦问题、动态测量反馈和内部稳定下的干扰解耦问题分别由 Morse 和 Wonham^[5]、Wonham 和 Morse^[2]、Imai 和 Akashi^[6]、Willems 和 Commault^[7] 解决。尽管如此, 对于一般系统的静态输出反馈下的干扰解耦问题, 无论是否要求内部稳定都还未被完整地解决。

3. 已有结果

对于给定系统(1), 当其子系统 Σ_P 是左可逆时, 无稳定性要求的静态输出反馈下的干扰解耦问题已经被文献[8]完整解决了。同时, 文献[8]的结果还可以用来解决当子系统 Σ_Q 是右可逆的情况。在这两种情况下, 我们都可以显式地得到所有的解, 并且可以用所得到的解来解决内部稳定静态输出反馈下的干扰解耦问题。近来, 文献[9]将结果扩展到其他更广的系统中去。利用一些线性系统的结构分解技术, 文献[9]提出一系列步骤将原问题转化为降阶系统的等价问题, 这些降阶系统的动态阶数一般比原系统要小很多, 如果这些降阶系统中从控制输入到被控输出及从干扰输入到测量输出的相应子系统分别是左和(或)右可逆的, 原系统的静态输出反馈下的干扰解耦问题则可用文献[8]中的结果来完整地解决。

然而, 对于更一般的系统, 到目前为止, 静态输出反馈下的干扰解耦问题尚未有完美的答案。

参 考 文 献

- [1] Basile G, Marro G. Controlled and conditioned invariant subspaces in linear system theory. *Journal of Optimization Theory and Applications*, 1968, 3: 306—315.
- [2] Wonham W M, Morse A S. Decoupling and pole assignment in linear multivariable systems: A geometric approach. *SIAM Journal on Control and Optimization*, 1970, 8: 1—18.
- [3] Akashi H, Imai H. Disturbance localization and output deadbeat control through an observer in discrete-time linear multivariable systems. *IEEE Trans. on Automat. Contr.*, 1979, 24: 621—627.
- [4] Schumacher J M. Compensator synthesis using (C, A, B) pairs. *IEEE Trans. on Automat. Contr.*, 1980, 25: 1133—1138.
- [5] Morse S, Wonham W M. Decoupling and pole assignment by dynamic compensation. *SIAM Journal on Control and Optimization*, 1970, 8: 317—337.
- [6] Imai H, Akashi H. Disturbance localization and pole shifting by dynamic compensation. *IEEE Trans. on Automat. Contr.*, 1981, 26: 226—235.
- [7] Willems J C, Commault C. Disturbance decoupling by measurement feedback with stability or pole-placement. *SIAM Journal on Control and Optimization*, 1981, 19: 490—504.
- [8] Chen B M. Solvability conditions for disturbance decoupling problems with static measurement feedback. *International Journal of Control*, 1997, 68: 51—60.
- [9] Chen B M, Mareels I M Y, Zheng Y, et al. Solutions to disturbance decoupling problem with constant measurement feedback for linear systems. *Automatica*, 2000, 36: 1717—1724.

撰稿人: 陈本美

新加坡国立大学电子与计算机工程系

鲁棒自适应非线性控制

Robust and Adaptive Nonlinear Control

反馈可以说是大自然中一切生命赖以生存和延续的基础。控制理论主要探讨的是如何利用反馈去改变物理系统的特性,如强迫系统的输出去跟踪给定的信号。20世纪40年代,为满足军事工业的需求,人们提出了一系列新颖的控制系统分析和设计方法,极大地推动了现代控制理论的发展。当然,运用控制论去解决生物和医学中的难题或解释自然界中的现象及理解其背后的反馈机制,也一直是人们所关心的研究问题。

频域法和时域法是控制理论中非常重要的两个工具,在线性系统中得到广泛应用。但是,当被控对象带有不确定的参数或具有非线性特征时,频域法的运用遇到一个本质性瓶颈。为此,人们转向时域法,经过深入理论研究,得到许多有关线性系统的鲁棒自适应算法^[1]。非线性系统的控制也因为微分几何理论的引入而获得令人鼓舞的进展^[2],几何非线性控制可以说是20世纪80年代控制界的一个研究亮点。

一般来说,几何非线性控制理论要求非线性动力学特性精确知道。这一假定是不现实的,因为实际工程和生物系统的精确模型很难得到。为此,自1990年起,考虑到几何非线性控制的约束,人们开始转向分析法,研究如何设计控制器,特别针对具有参数和未知非线性的非线性系统^[3,4]。当系统具有动态不确定性时,非线性控制器的构造问题变得更具挑战性^[5]。目前,一个尚未解决的问题是:对一个具一般形式参数化非线性系统,可镇定性是否等价于自适应镇定。用状态方程表示,考虑以下参数化系统:

$$\dot{x} = f(x, \theta) + g(x, \theta)u$$

式中, x 是被控系统的状态变量; u 是被控系统的输入变量(或控制变量); θ 是系统的参数(可以是一个或多个)。假定对每个给定参数 θ , 系统有一个与 θ 有关的反馈控制器 $u = \alpha(x, \theta)$, 使得闭环系统在原点渐近稳定。当参数未知时, 一个重要且有意义的问题是: 在何种情况下, 系统拥有一个(与 θ 无关的)自适应控制器, 同样使得闭环系统的状态 x 收敛到原点? 如果状态变量 x 不能精确测量而仅能测量被控系统的输出变量 $y = h(x)$, 上述问题可叙述成: 输出镇定性是否等价于自适应输出镇定? 与此相关但本质上不同的问题是探讨自适应反馈的最大能力, 这方面的重要研究起源于文献[6]。

上述问题的难点在于以下几个方面:

(1) 参数的辨识本质上是非线性观测器问题, 如何解决该问题还没有一个系统的、行之有效的方法。

(2) 即使解决了(1)中的参数辨识问题, 控制器的设计也非一个显而易见的问题, 根本原因在于对非线性控制系统, “可分性原理”一般不成立。

目前, 这方面有成效的研究结果大都局限于一类带三角(“下三角”或“上三角”)结构的非线性系统。研究表明, 对这些系统, 可镇定性导出自适应镇定。

表面上看, 这是一个纯学术问题。但是, 人们发现许多实际工程和生物系统不但具有不确定参数, 而且不满足目前许多非线性控制算法要求的条件。对带三角结构非线性系统的研究产生了有别于线性控制理论的新的工具, 即积分器后推法和积分器前推法。可以预见的是, 要更好地解决上述问题, 我们需要超越常见的线性思维和现有的非线性控制理论, 提出新的非线性控制技术和工具。

参 考 文 献

- [1] Ioannou P A, Sun J. Robust Adaptive Control. New York: Prentice Hall, 1996.
- [2] Isidori A. Nonlinear Control Systems. 3rd ed. London: Springer, 1995.
- [3] Kokotovic P, Arcak M. Constructive nonlinear control: A historical perspective. Automatica, 2001, 37: 637—662.
- [4] Krstic M, Kanellakopoulos I, Kokotovic P. Nonlinear and Adaptive Control Design. New York: Wiley, 1995.
- [5] Jiang Z P, Praly L. Design of robust adaptive controllers for nonlinear systems with dynamic uncertainties. Automatica, 1998, 34: 825—840.
- [6] Guo L. Exploring the maximum capability of adaptive feedback. Int. J. Adaptive Control and Signal Processing, 2002, 16: 341—354.

撰稿人: 姜钟平
纽约大学理工学院

大种群随机多自主体系统的自适应动态博弈

Adaptive Dynamic Games of Large Population Stochastic Multi-agent Systems

对多个体动态博弈的研究在控制理论界有着悠久的历史^[1]。近年来,动态博弈理论在网络控制和多自主体系统的研究中迸发了新的活力。对于分布式多自主体系统,一般地讲,并不存在中央控制站,且每个自主体的感知和通信能力是十分有限的,因此,其控制设计通常要求是分散式的。在分散控制的框架下,每个自主体(子系统)的控制输入只能利用本地信息,在某些情形下,还可以利用其感知和通信范围内其他自主体的信息。近些年来,Huang、Caines 和 Malhame 等针对一类个体和种群存在交互作用的多自主体系统的随机博弈做了开创性的工作^[2],这类系统的个体数通常十分巨大,每个个体不但受到随机噪声的影响,而且和其他个体通过种群的平均状态相耦合,随着系统中个体数的增加,可以看做是每个个体和系统的平均场(mean field)交互作用。此外,系统中的每个个体还有其自身的指标(效用函数),不同的个体通过动态博弈以优化各自的指标,这类系统在生物聚集^[3]、经济和社会网络^[4]、无线通信网络和 Internet^[5]等领域有着广泛的应用背景,最近,在耦合震荡子领域又发现了这类系统的新应用^[6]。对这类系统进行分散控制的一个本质性难点在于:虽然个体通过种群平均状态耦合,但种群平均状态对每个个体而言是未知的,不能用于其自身控制设计。为克服这一难点,Huang、Caines 和 Malhame 提出了 Nash 必然等价原则的设计思想。首先用一个确定性新信号构造对种群平均状态的估计,然后利用该估计代替种群平均状态设计分散控制律。这种思想非常类似于自适应控制中的必然等价原则。首先估计未知参数,然后利用参数的估计代替真实参数设计适应控制律。在文献[2]的基础上,文献[7]、[8]提出了概率意义下渐近 Nash 均衡的概念,为设计基于随机指标的分散控制律提供了必要的工具。目前,对这类系统的研究已经延伸到非线性模型^[9]。

现有的对这类系统的研究大都假设自主体的动力学模型是精确已知的,在实际系统中,由于环境中的各种不确定因素,自主体的动力学中不可避免地会出现参数不确定性或未建模动态。一般而言,未知参数可以分为两类:一类是未知局部参数,包含了个体的局部环境信息;另一类是未知全局参数,由所有的自主体共享。虽然存在参数不确定性,但每个自主体都具有学习能力,可以根据量测数据逐步完善环境模型,边学习边控制以消除不确定性。通过在线辨

识器或学习机, 每个个体利用对未知参数的估计设计各自的控制器以优化其指标, 从而使整个系统呈现为一幅大种群分散自适应博弈的动态图景。例如, 每个个体的动力学方程为

$$\mathbf{x}_i(t+1) = \mathbf{A}\mathbf{x}_i(t) + \mathbf{B}\mathbf{u}_i(t) + \Lambda \frac{1}{N} \sum_{j=1}^N \mathbf{x}_j(t) + \omega_i(t), \quad i = 1, 2, \dots, N$$

式中, $\mathbf{x}_i$ 是第 i 个自主体的状态; $\mathbf{u}$ 是第 i 个自主体的控制输入; ω_i 是随机噪声; $\mathbf{A}$ 、 $\mathbf{B}$ 、 Λ 是未知参数矩阵, 其中, $\mathbf{A}$ 和 $\mathbf{B}$ 是局部参数, Λ 是全局参数; $N^{-1} \sum_{j=1}^N \mathbf{x}_j(t)$ 是种群平均状态。注意, 这里其他个体的状态对于第 i 个自体是未知的, 不能用于 $\mathbf{u}$ 的设计。每个个体待优化的指标为

$$J_i = \limsup_{n \rightarrow \infty} \frac{1}{n} \sum_{t=0}^n \left\| \mathbf{x}_i(t+1) - \Phi \left(t, \frac{1}{N} \sum_{j=1}^N \mathbf{x}_j(t) \right) \right\|^2, \quad i = 1, 2, \dots, N$$

式中, Φ 是某种可测函数。在这类自适应博弈中, 实际上存在两个估计过程: 一个是对未知种群平均状态的估计过程; 另一个是对未知参数的辨识过程。由于自主体的动力学方程中存在未知参数(全局参数 Λ)和未知状态(种群平均状态)的乘积, 如果采用传统的辨识方法, 回归向量中将出现种群平均状态, 而我们知道种群平均状态不能用来构造每个个体的辨识器。如果采用种群平均状态的估计代替种群平均状态构造辨识器, 将导致两个估计过程的非线性耦合, 再加上分散式信息架构, 使得这类自适应博弈系统与传统的单个体自适应控制^[10]有着本质的区别。对这类自适应博弈系统, 有许多基本问题有待研究, 包括分散估计器、分散辨识器和分布式控制器的设计问题及闭环系统分析问题。具体地, 能否保证闭环系统的稳定性, 如果可以, 能否保证闭环系统自主体的状态上界与个体数 N 无关; 能否保证对种群平均状态的估计在某种度量意义下的一致性, 能否给出误差收敛速度; 能否保证分散辨识的一致性, 能否给出误差收敛速度; 能否保证分散式控制律在 Nash 均衡意义下的渐近最优性并给出不同个体的指标随个体数增加收敛到最优的速度。这些问题在现有的适应控制和大系统分散控制的框架下都没有现成的答案。

参 考 文 献

- [1] Basar T, Olsder G J. Dynamic Noncooperative Game Theory. London: Academic Press, 1982.
- [2] Huang M, Caines P E, Malhame R P. Large-population cost-coupled LQG problems with nonuniform agents: Individual-mass behavior and decentralized ϵ -Nash equilibria. IEEE Trans. on Automat. Contr., 2007, 52(9): 1560—1571.
- [3] McNamara J M, Houston A I, Collins E J. Optimality models in behavior biology. SIAM Review, 2001, 43(3): 413—466.

- [4] Breban R, Vardavas R, Blower S. Mean field analysis of an inductive reasoning game: Application to influenza vaccination. *Phys. Rev. E*, 2007, 76: 031127.
- [5] Huang M, Caines P E, Malhame R P. Uplink power adjustment in wireless communication systems: A stochastic control analysis. *IEEE Trans. on Automat. Contr.*, 2004, 49(10): 1693—1708.
- [6] https://netfiles.uiuc.edu/meyn/www/spm_files/Papers_pdf/OptimizationOfSynchrony_V12.pdf.
- [7] Li T, Zhang J F. Decentralized tracking-type games for multi-agent systems with coupled ARX models: Asymptotic Nash equilibria. *Automatica*, 2008, 44(3): 713—725.
- [8] Li T, Zhang J F. Asymptotically optimal decentralized control for large population stochastic multi-agent systems. *IEEE Trans. on Automat. Contr.*, 2008, 53(7): 1643—1660.
- [9] Huang M, Malhame R P, Caines P E. Large population stochastic dynamic games: Closed-loop McKean-Vlasov systems and the Nash certainty equivalence principle. *Communications in Information and Systems*, 2006, 6(3): 221—251.
- [10] Chen H F, Guo L. *Identification and Stochastic Adaptive Control*. Boston: Birkhauser, 1991.

撰稿人: 李 韬

中国科学院数学与系统科学研究院

非线性控制系统分析与设计中的结构分解方法

The Structural Decomposition Approach to the Analysis and Design of Nonlinear Control Systems

1. 背景介绍

考虑仿射非线性系统

$$\begin{cases} \dot{\mathbf{x}} = \mathbf{f}(\mathbf{x}) + \mathbf{g}(\mathbf{x})\mathbf{u}, \mathbf{x} \in \mathbf{R}^n, \mathbf{u} \in \mathbf{R}^m \\ \mathbf{y} = \mathbf{h}(\mathbf{x}), \mathbf{y} \in \mathbf{R}^p \end{cases} \quad (1)$$

式中, $\mathbf{x}$, $\mathbf{u}$ 和 $\mathbf{y}$ 分别为系统的状态、输入和输出; $\mathbf{f}: \mathbf{R}^n \rightarrow \mathbf{R}^n$, $\mathbf{g}: \mathbf{R}^n \rightarrow \mathbf{R}^{n \times m}$ 和 $\mathbf{h}: \mathbf{R}^n \rightarrow \mathbf{R}^p$ 为光滑的向量或矩阵函数, 并满足 $\mathbf{f}(0) = 0$ 和 $\mathbf{h}(0) = 0$ 。非线性系统(1)的许多分析和设计方法都是由相应的线性系统理论中的方法启发而得出的^[1,2]。这不仅是因为线性系统是非线性系统的一个特殊形式, 也因为非线性系统可以由一个或多个线性系统来描述或近似(如线性微分包含或 Jacobi 线性化)。更重要的是, 非线性控制系统研究中的很多问题的描述也来源于线性控制理论。

我们先来回顾一下线性系统控制中的一些重要方法。作为非线性系统(1)的一个特例的线性系统可以用以下方程来描述:

$$\begin{cases} \dot{\mathbf{x}} = \mathbf{A}\mathbf{x} + \mathbf{B}\mathbf{u}, \mathbf{x} \in \mathbf{R}^n, \mathbf{u} \in \mathbf{R}^m \\ \mathbf{y} = \mathbf{C}\mathbf{x}, \mathbf{y} \in \mathbf{R}^p \end{cases} \quad (2)$$

式中, $\mathbf{A} \in \mathbf{R}^{n \times n}$, $\mathbf{B} \in \mathbf{R}^{n \times m}$ 和 $\mathbf{C} \in \mathbf{R}^{p \times n}$ 为常数矩阵。

对于线性系统(2)的研究可以在频域中用古典控制理论方法来进行^[3], 也可以在时域中直接进行。现代(线性)控制理论就是在时域中开展起来的。在时域中进行线性系统的分析与控制设计时, 可以采用不同的办法。一种办法是将要解决的问题化成一个或多个线性矩阵不等式(LMI)或者 Riccati 方程(ARE)来解决(见文献[4])。另一种办法是通过巧妙地选取坐标系, 将系统分解成各种各样的子系统。这些子系统自身简单、相互之间的关联清晰明了, 让我们能够深入地理解反馈控制是如何在整体系统中产生作用的, 从而构造出满足设计指标的反馈律, 这方面的工作可参见文献[5]、[6]。我们在这里重点讨论将线性系统理论中的结构分解方法推广到非线性系统方面的研究工作。

根据文献[5]、[6], 对于线性系统(2), 可以构造一套新的坐标系, 如下:

$$\bar{\mathbf{x}} = \Gamma_s \mathbf{x}, \quad \bar{\mathbf{y}} = \Gamma_o \mathbf{y}, \quad \bar{\mathbf{u}} = \Gamma_i \mathbf{u}$$

$$\bar{\mathbf{x}} = \begin{bmatrix} \mathbf{x}_a \\ \mathbf{x}_b \\ \mathbf{x}_c \\ \mathbf{x}_d \end{bmatrix}, \quad \mathbf{x}_d = \begin{bmatrix} \mathbf{x}_{d,1} \\ \mathbf{x}_{d,2} \\ \dots \\ \mathbf{x}_{d,m_d} \end{bmatrix}, \quad \mathbf{x}_{d,i} = \begin{bmatrix} x_{d,i,1} \\ x_{d,i,2} \\ \dots \\ x_{d,i,q_i} \end{bmatrix}$$

$$\bar{\mathbf{y}} = \begin{bmatrix} \mathbf{y}_d \\ \mathbf{y}_b \end{bmatrix}, \quad \mathbf{y}_d = \begin{bmatrix} y_{d,1} \\ y_{d,2} \\ \dots \\ y_{d,m_d} \end{bmatrix} = \begin{bmatrix} x_{d,1,1} \\ x_{d,2,1} \\ \dots \\ x_{d,m_d,1} \end{bmatrix}, \quad \bar{\mathbf{u}} = \begin{bmatrix} \mathbf{u}_d \\ \mathbf{u}_c \end{bmatrix}, \quad \mathbf{u}_d = \begin{bmatrix} u_{d,1} \\ u_{d,2} \\ \dots \\ u_{d,m_d} \end{bmatrix}$$

将其分解为以下许多子系统:

$$\left\{ \begin{array}{l} \dot{\mathbf{x}}_a = \mathbf{A}_{aa} \mathbf{x}_a + \mathbf{L}_{ab} \mathbf{y}_b + \mathbf{L}_{ad} \mathbf{y}_d \\ \dot{\mathbf{x}}_b = \mathbf{A}_{bb} \mathbf{x}_b + \mathbf{L}_{bd} \mathbf{y}_d, \mathbf{y}_b = \mathbf{C}_b \mathbf{x}_b \\ \dot{\mathbf{x}}_c = \mathbf{E}_{ca} \mathbf{x}_a + \mathbf{E}_{cb} \mathbf{x}_b + \mathbf{A}_{cc} \mathbf{x}_c + \mathbf{L}_{cd} \mathbf{y}_d + \mathbf{B}_c \mathbf{u}_c \\ \text{对于每个 } i=1, 2, \dots, m_d \\ \dot{x}_{d,i,1} = x_{d,i,2} + \mathbf{L}_{d,i,1} \mathbf{y}_d, y_{d,i} = x_{d,i,1} \\ \dot{x}_{d,i,2} = x_{d,i,3} + \mathbf{L}_{d,i,2} \mathbf{y}_d \\ \dots \\ \dot{x}_{d,i,q_i} = \mathbf{A}_{d,i,a} \mathbf{x}_a + \mathbf{A}_{d,i,c} \mathbf{x}_c + \mathbf{A}_{d,i,b} \mathbf{x}_b + \mathbf{A}_{d,i,d} \mathbf{x}_d + u_{d,i} \end{array} \right. \quad (3)$$

式中, $\mathbf{x}_a$ 子系统描述系统的零动态, 代表系统的有限零点结构; $\mathbf{x}_b$ 子系统描述系统的右可逆性; $\mathbf{x}_c$ 子系统描述系统的左可逆性; $\mathbf{x}_d$ 子系统由 m_d 串积分器组成, 每串积分器的长度代表系统的无穷零点结构。有关这些子系统的更细致的结构特性可在文献[5]、[6]中找到。利用这些结构特性, 线性控制系统中的许多问题都可以得到解决。

2. 问题的描述

线性系统的结果分解方法在 20 世纪 80 年代后期开始被逐渐地推广到非线性系统研究中来^[7]。这方面的早期工作集中在单输入单输出系统。例如, 一个单输入单输出的系统(1)在一定的条件下, 可以通过坐标换分解成以下的标准型:

$$\left\{ \begin{array}{l} \dot{\eta} = \mathbf{f}_0(\eta, \xi) \\ \dot{\xi}_i = \xi_{i+1} \\ \dot{\xi}_r = \mathbf{f}_q(\eta, \xi_1, \xi_2, \dots, \xi_r) + \mathbf{g}_r(\eta, \xi_1, \xi_2, \dots, \xi_r)u \end{array} \right. \quad (4)$$

这个标准型退化到线性系统时就是系统(3)的一个特例, 基于这个标准型, 很多非线性问题得到了很好解决。

之后, 人们作了很多努力, 将标准型(4)推广到可逆的多输入多输出非线性系统^[7,8]。系统的可逆性意味着同等数目的输入和输出。另外, 正如文献[9]最

近指出的那样,这些结果中有的对系统要求的条件过于苛刻,连线性系统都不一定能满足,有的则不是真正意义上对线性系统结果的推广。在线性系统结构分解(3)的启发下,在现有多变量非线性系统标准型^[7,8]的基础上,文献[9]提出了一个新的非线性系统结构分解方法。这个方法适用一般的、不一定有同等数目的输入输出的非线性系统。更重要的是,当非线性系统退化到线性系统时,所得到的标准型对应于线性系统的结构分解(3)。初步结果显示,这个新的标准型可以有效地用于解决一些控制问题。例如,在这个标准型下,可以实现新的 Backstepping 设计程序,从而增多了 Backstepping 设计可镇定的系统^[10]。

我们期待也相信文献[9]提出的多变量非线性系统的结构分解方法将会像线性系统结构分解方法^[8,9]一样被成功地用于解决一系列控制问题。我们期待着更多的控制理论工作者参加这方面的工作。

参 考 文 献

- [1] 郭雷,程代展,冯德兴.控制理论导论——从基础概念到研究前沿.北京:科学出版社,2005.
- [2] Khalil H K. Nonlinear Systems. 3rd ed. Upper Saddle River: Prentice Hall, 2002.
- [3] Rosenbrock H H. State Space and Multivariable Theory. London: Nelson, 1970.
- [4] Zhou K, Doyle J C, Glover K. Robust and Nonlinear Control. Upper Saddle River: Prentice Hall, 1996.
- [5] Sannut P, Saberi A. A special coordinate basis of multivariable linear systems-finite and infinite zero structure, squaring down and decoupling. International Journal of Control, 1987, 45: 1655—1704.
- [6] Chen B M, Lin Z, Shamash A. Linear Systems Theory: A Structural Decomposition Approach. Boston: Birkhauser, 2004.
- [7] Isidori A. Nonlinear Control Systems. 3rd ed. Berlin: Springer, 1995.
- [8] Schwartz B, Isidori A, Tarn T J. Global normal forms for MIMO nonlinear systems, with application to stabilization and disturbance attenuation. Mathematics of Control, Signals and Systems, 1999, 12: 121—142.
- [9] Liu X, Lin Z. On normal forms of nonlinear systems affine in control. IEEE Trans. on Automat. Contr., 2011, 56: 239—253.
- [10] Liu X, Lin Z. On semi-global stabilization of minimum phase nonlinear systems without vector relative degrees // Proceedings of the 2009 American Control Conference, St. Louis, 2009: 802—807.

撰稿人: 林宗利

美国弗吉尼亚大学电机与计算机工程系

数据驱动控制系统设计

Data-driven Control Systems Design

控制依赖于信息，这是控制论的基本观点^[1]。在经典的单回路系统结构和PID控制策略下，系统信息的获取主要是通过系统的反馈，即系统设定值与实际输出值的差值作为系统控制量计算的主要依据。当然，如果系统的扰动信息已知，还有前馈控制，这一模式下系统的控制几乎不需要系统的模型^[2]。

随着系统复杂性的增加，控制方法也越来越丰富，与前述的仅根据误差进行调节相比，很多控制方法是依赖系统数学模型的，从控制器的设计到闭环性能的分析，如自适应控制、鲁棒控制、预测控制等。早在1989年韩京清教授就发出过感叹，控制理论——模型论还是控制论^[3]？这里所谓的模型，都是通过对系统加入激励信号，利用系统的输入/输出数据进行辨识得到的，其数学模型的结构形式是以输入-输出映射为目的，并不代表实际物理系统的结构形式，其模型中的参数也不代表物理系统的“真参数”^[4]。这一模式可以称为数据驱动的基于模型的控制器的设计，与近年来兴起的数据驱动控制器的设计有着很大的不同^[5]。

按照文献[6]中对数据驱动控制器设计给出的定义：数据驱动控制器就是利用被控系统的实时测量数据，不直接利用系统参数或非参数模型进行设计，不断改善系统性能的综合设计。其两个主要特征是：一是其控制器的设计完全是基于系统的输入/输出数据，没有中间的参数模型辨识，这与以往有着很大的不同；二是强调其设计的目的是为了系统性能的不断改善，这与以往的控制器的设计要求是一样的。

从动态系统行为变化的实质来看，影响系统输出的决定因素是操纵变量，即系统的控制量，现在回过头来看系统建模与控制器的设计过程，输入量对输出量作用的灵敏度都是通过系统模型进行反映的，如果建模的精度不高，系统输入/输出之间的变化关系就不能得到描述，因而控制系统的灵敏度取决于系统模型的灵敏度，也就是系统模型的阶次和可变参数的自由度，而在一般情况下，两者的自由度是有限的，因而也就限制了系统动态变化过程中输入-输出数据关系的直接反映。

数据驱动控制的出发点和归宿都是数据，其思想是利用受控对象的在线和离线数据，实现系统的预报、评价、调度、监控、诊断、决策和优化等各种期望。从以往发展起来的控制理论的提出、形成到应用的过程来看，控制领域的

特征之一是强调所要研究问题的理论和数学描述,即从实际控制系统的应用需求提炼其科学问题进行定量描述,针对系统设计与分析问题形成严谨的体系,最终这些理论结果在实际系统中不断得到验证和完善,对应这样一条发展过程来看,数据驱动控制理论和方法还远未成熟,下述两个方面的研究仍有很多尚未解决的问题:

(1) 数据驱动的子空间辨识与预测控制。子空间方法作为一种新型辨识方法,直接基于一段时间滚动窗口的输入输出数据,不需要任何模型结构与系统阶次等先验知识,可以直接得到预测输出形式的子空间预估器模型。辨识中以多步预测误差的最小化为目标,而且由于子空间方法在辨识中利用了线性代数工具,与传统的辨识方法(如预测误差方法)相比,不需要非线性的迭代及搜索过程。因此,子空间预估器模型不仅具备了预测控制对模型的要求,而且包含了适于用作预测模型的特点。在已有的研究中,也考虑将子空间辨识与预测控制滚动优化相结合,实现对于多变量系统的预测控制,即子空间预测控制。在设计过程中,如何激励系统得到数据,并在闭环情况下利用系统数据进行多步输出预测、滚动优化和实现反馈校正仍具有很多的挑战。

(2) 数据驱动的去伪控制器设计与系统性能分析。去伪控制器的实质是利用系统输入/输出数据库中的时间窗内的“片状数据”,也就是与当前工况最为匹配的一段数据,从候选的控制器集合中选择使系统性能指标最优的控制器,以作为当前控制器,该方法实质上属于一类切换控制方法,是一种无模型的自适应控制方法,不需要任何形式的被控对象,数学模型能有效地剔除伪控制器,表现出较好的瞬态响应。初始控制器候选集合可根据被控过程的一些先验知识(如模型),用现有的、比较成熟的方法进行离线设计。候选模型的设计及其根据系统的实时数据进行优化切换,以保证系统性能不断改善及其在不断切换的情况下至少保证闭环系统的稳定性仍有许多问题需要解决。

数据驱动控制器的设计思想和策略对于复杂系统的控制无疑是很有吸引力的,虽然数据驱动的系统分析与控制方法的研究还仅处于萌芽阶段,但已得到了国内外控制理论界的高度重视,并针对多种领域的应用需求开展了一系列的研究工作,取得了很多成果。

参 考 文 献

- [1] Wiener N. Cybernetics: Or Control and Communication in the Animal and the Machine. New York: Wiley, 1948.
- [2] Mayr O. The Origins of Feedback Control. Cambridge: MIT Press, 1970.
- [3] 韩京清. 控制理论——模型论还是控制论. 系统科学与数学, 1989, 9(4): 328—335.

- [4] Goodwin G C, Payne R I. Dynamic Identification: Experiment Design and Data Analysis. New York: Academic Press, 1977.
- [5] 侯忠生, 许建新. 数据驱动控制理论及方法的回顾和展望. 自动化学报, 2009, 35(6): 650—667.
- [6] van Helvoort J J M. Unfalsified control: Data-driven control design for performance improvement [PhD Dissertation]. Eindhoven: Eindhoven University of Technology, 2007.

撰稿人：李少远
上海交通大学自动化系

宏观经济控制问题

Problem of Macroeconomic Cybernetics

经济系统是一个复杂的大系统,对其运用控制论方法进行调节、优化的思想可以追溯到波兰经济学家 Lange^[1]。我国著名科学家钱学森、宋健等也提出过应用控制论方法于经济系统的设想^[2,3]。鉴于经济系统的复杂性及作为经济主体的是人而不是机械,对经济系统进行事无巨细地完全控制似乎并不可行。较为切合实际的方法是利用市场这一无形之手进行分散控制,而政府利用有形之手进行宏观调控。宏观经济控制是应用控制论的方法设计宏观经济政策,主要包括货币政策和财政政策。货币政策是政府通过改变存贷款利率、银行准备金率或公开市场操作来调控货币供给,而财政政策是政府通过改变政府购买总量(更为精细的,改变政府购买总量在各行业的分布)或税收总水平(更为精细的,改变税收总水平在各行业的分布)来影响总需求。控制的目标是使宏观经济平稳较快增长,同时维持通货膨胀和失业率的较低水平,另外,还要兼顾眼前增长和长远增长。就经济的长远发展而言,生产率的提高(主要包括科学技术水平的提高和作为科学技术创造者的人的各种素质的提高)及环境(包括自然环境和人文环境)的保护和改善至关重要。

宏观经济控制问题的重要性不言而喻。著名经济学家 Lucas 曾指出,“一个较不富裕的国家应该采取什么政策来加快经济增长并加入到发达国家的行列,一个富裕的国家怎样才能维持它的高生活水平,这些宏观经济中最重要的问题对人的影响简直令人吃惊”^[4]。

目前,我国的经济实力显著增强,政府外汇储备和支付能力不断提升,但经济控制论对政府经济政策制订的影响仍相当有限。

宏观经济控制问题困难的原因主要包括以下几个方面:

(1) 宏观经济模型的不准确。经济系统是一个复杂的大系统,即便是考虑集中的宏观量的模型,不确定性也不可避免。对于同一问题可以有多个模型描述,在许多情况下结果并不一致,而在一些情况下甚至相反。一个重要的原因是对经济系统中众多正反馈效应(乘数效应)强度认识的分歧上^[5,6]。

(2) 世界经济的一体化。随着世界经济一体化进程的加快,各国间的贸易、经济联系不断加强。别国经济发生重大问题可能会对本国经济(甚至是较长一段时间的经济发展目标)产生重大影响。然而,由于对别国经济较为完整的数据的获取更为困难,对别国经济较为准确的模型的建立也更为困难。

(3) 大的时滞。货币政策主要通过改变利率水平来影响支出,但企业和家庭大多提前确定其支出计划。研究表明,在做出货币政策变动的6个月内,这种变动对总需求的影响很小^[4]。而财政政策从酝酿、制订到实施也需要一个较长的过程。通常,克服较大时滞的有效方法是提前预测,但由于模型的不准确性导致预测也是不准确的。

(4) 监测数据的不准确。各种宏观指标的监测(统计)数据常常含有较大的不准确性。控制论中最重要的概念是反馈,由于监测数据的不准确,控制的效果也会大打折扣。

尽管如此,目前控制论中已发展出一些方法,无论是应对模型的不准确(可以是确定性系统的框架,也可以是随机系统的框架)、大的时滞,还是观测中的不确定性。例如,对存在较大控制时滞和较大不确定性的系统,按照控制论的方法,不宜采用高增益的反馈控制,以避免系统出现大的振荡,正如我国的古语“治大国如烹小鲜”,不宜过多翻炒。也正是由于宏观政策对经济控制的不完全性,当美国发生次贷危机可能造成资本回流和外需显著下降时,我国政府的宏观经济政策是快速加大政府投入,以维持现有经济中的各种关系(一旦经济这个复杂系统中的关系发生大面积断裂,其恢复的成本是巨大的)。

随着经济理论、计量经济技术和控制理论的不断融合,宏观经济控制的进一步发展是可以预期的。好的宏观经济控制专家可以对政府提供好的政策建议,不仅是定性的而且应是定量的,在一些情况下,也应能指出,两全其美的政策并不存在,在实现一些政策目标的同时,对另一些宏观指标作何种程度的牺牲不可避免。

参 考 文 献

- [1] Lange O. 经济控制论导论. 杨小凯,等译. 北京: 中国社会科学出版社, 1981.
- [2] 钱学森, 宋健. 工程控制论. 北京: 科学出版社, 1980.
- [3] 钱学森. 创建系统科学. 上海: 上海交通大学出版社, 2007.
- [4] Mankiw N G. 经济学原理: 宏观经济学分册. 梁小民译. 北京: 北京大学出版社, 2006.
- [5] Romer D. 高级宏观经济学. 王根蓓译. 上海: 上海财经大学出版社, 2009.
- [6] Ljungqvist L, Sargent T J. 递归宏观经济理论. 杨斌,等译. 北京: 中国人民大学出版社, 2010.

撰稿人: 叶旭东
浙江大学电气工程学院

目标跟踪中的数据关联问题

The Data Association Problem in Target Tracking

1. 背景介绍

简言之,目标跟踪就是用观测或量测数据估计运动物体(即目标)的状态,其困难主要在于量测数据和目标的运动具有各种不确定性,它的主要理论基础是估计与滤波理论及决策理论。在控制界,目标跟踪一般被认为是随机系统理论的重要应用领域之一。在信息融合领域,它被广泛认为是其核心组成部分之一。

显而易见,目标跟踪有很强的军事应用背景,其中,目标可以是各种空中、地面、水面及水下运动物体,因而近半个世纪以来它得到了广泛而深入的研究。近年来,目标跟踪的其他应用(包括民用和科技应用)也已起步,前景十分可观。然而,尽管目标跟踪的研究硕果累累,但仍有不少难题,其中,数据关联问题就是一个至关重要的老大难问题。

2. 问题描述

数据关联问题是指在目标跟踪中确定目标、量测及航迹^①之间对应关系的问题,其核心是所谓量测源的不确定性问题,即观测来自哪个源?例如,由于杂波干扰、不完备检测、量测死角及电子对抗等因素,量测并不一定源自目标;由于传感器的分辨率有限,一个量测可能有多个来源,其中,任意一个源既可能是目标,也可能是非目标。另一方面,由于多径效应等因素,一个目标又可能会产生多个量测。给定不同时刻的量测,如何形成航迹是量测与量测的关联问题。给定多个量测和航迹,量测与航迹的关联指的是:哪些量测对应于哪条航迹?给定多个传感器所得的航迹,航迹与航迹的关联旨在确定哪些航迹对应于同一个目标。

数据关联问题被普遍认为是目标跟踪的标志性问题,是其独特性之根源所在,是目标跟踪与其他类估计与滤波的分水岭,是目标跟踪的首要问题。一旦该问题得到解决,目标跟踪即退化为传统的状态估计。然而,由于现实的复杂性和测量系统及传感技术内在的不确定性,数据关联问题一般难以精确解决,

^① 在目标跟踪中,目标的状态轨迹或位置量测序列被称为航迹。

甚至可以说,数据关联问题是无法完全彻底解决的。

3. 发展历史及已有方法

数据关联问题及其在目标跟踪中的至关重要性,由 Sittler 首先明确指出并加以描述和研究^[1]，“数据关联”这一术语也由他率先使用。在单目标背景下,该问题的一个过于简化但被广泛应用数十年的早期解法立足于一种“快捷而草率”的硬决策,即把最近邻(即离预测值最近的量测)作为来自目标的量测,由此即得最近邻滤波。也可用最强邻(即信号最强的量测)代替最近邻,得到最强邻滤波。这些滤波均有扩展形式,相应的理论分析由 Singer 和 Sea 开创,迄今最彻底的工作是文献[2]的工作。

Bar-Shalom 的概率数据关联滤波(probabilistic data association filter, PDAF)提供了一种明显优越的解决方法,它把后验期望量测(即波门^①内所有量测的概率加权和,并非某单一测量)作为卡尔曼滤波所需的量测,因而具有软决策特性,这是目标跟踪研究中影响深远的一个重要里程碑,它草创于 1973 年^[3],完成于 1975 年^[4]。然而,其误差协方差计算公式有误,这一微妙的错误波及了所有有着相似问题的跟踪器,并持续了二十多年直到 1998 年^[2]才被更正。另一方面,一个目标可能出现、持续存在或者消失,与此相应的三项工作是航迹起始、航迹更新与航迹终止。PDAF 仅适用于单目标的航迹更新,但它有多种推广和扩展,其中,最著名的是适用于多目标航迹更新的联合概率数据关联滤波(JPDAF)。JPDAF 的原始文献为文献[5],对其最为详尽的阐述见文献[6]。另一值得注意的扩展方向是航迹起始和终止^[7,8]。

对于多目标数据关联问题,多假设跟踪(multiple-hypothesis tracking, MHT)功能强大且广泛适用,它在两个本质方面有别于 JPDAF: ①MHT 的关联是面向量测的,其关键在于考虑量测来自本目标、它目标或其他源的概率,而 JPDAF 是面向目标的,它考虑目标的量测是一个给定量测的概率。②在 MHT 中,数据关联的假设是针对一个时间段的,而 JPDAF 是针对当前时刻的。因此,JPDAF 仅适用于航迹更新,而 MHT 除此之外还有进行航迹起始、确认和终止等决策的内在机制。MHT 是目标跟踪领域的又一重要里程碑,文献[9]是其滥觞,文献[10]对之进行了广泛而深入的阐述。对于假设,如果不加以管理,其个数将随时间呈指数增长,其优劣排序则要求大量计算。MHT 与 JPDAF 的另一显著不同是:MHT 确定最可能为真的假设并在此基础上估计目标状态,而 JPDAF 并不涉及这种硬决策。与 JPDAF 类似,概率多假设跟踪(probabilistic

① 一个目标航迹的波门是观测空间的子域,源于该目标的量测以极大的概率落入其中,因此,落在波门外的量测可认为不源于该目标,相应的虚假数据关联进而由此得以剔除。

MHT, PMHT)^[11]将量测质心用于基于 EM 算法的状态平滑中,该质心是以量测与某个目标关联概率为权值的所有量测的加权和。

数据关联问题研究的又一个里程碑是将其建模为分配问题,这是约束优化的一个重要子类,数学规划对之有深入研究。考虑观测列表 M 和源列表 S ,其中, S 是老目标(与现有航迹对应)、新目标(无对应的现有航迹)和无关源(杂波、虚警等)的集合, M 包括所有观测和一个虚构观测,该虚构观测代表老目标的所有漏观测。实际上,每个观测都可能来自一个或多个老目标、新目标或无关源,每个目标也都可能产生零个、一个或多个观测。运输问题是描述这一数据关联问题更一般的数学模型,分配问题是其特例。两个列表之间的每一元素对的关联都可赋予相应的代价(如负对数似然比)。在分配问题模型中,每个实际观测只有一个来源,每个目标也至多只能产生一个实际观测,在此约束下,极小化元素对的关联代价之和的分配即是问题的解。两维分配问题只涉及 S 和 M ,而更一般的 m 维分配问题则还要考虑以往 $m-2$ 个时刻观测的 $m-2$ 个列表。最优分配是一种硬决策,它的计算复杂度可能发生组合爆炸,但已经开发了一些有效的次优算法,详见综述文献[12]。

近年来,还提出了解决数据关联问题的一些其他方法,但意义并不显著,在此不赘述。

4. 展望

目标跟踪旨在用观测来估计目标状态,因此,目标与观测之间的关系至关重要。解决数据关联问题,即消除目标与观测之间对应关系的不确定性,长期以来一直被认为是目标跟踪的关键,这也是现有跟踪理论与技术的基础。然而事实上,这一不确定性的消除对于目标跟踪虽然极为有益但并非必需。作者认为,在许多情况下,回避目标跟踪问题更为妥当,因为数据关联问题往往比量测源不确定时的状态估计问题更具挑战性。这一建议遵从一个一般原则:一个问题的解决不应依赖于一个更难的子问题的解决。在不少情况下,回避数据关联问题不仅应该,而且可行。例如,可在集合的层面上考虑目标跟踪,因而不需考虑目标集合与量测集合彼此的元素之间的对应关系;也可将目标跟踪建模成不完全数据的估计问题,其中,关联信息为丢失的数据,这将给 EM 算法提供大有可为的广阔天地。

常将目标跟踪分解为两部分,并想当然地按两步进行:先关联数据,后估计状态。其实在很多情况下,联合关联与估计或许更好。上述 PMHT 即为一例,它统一估计目标状态和数据关联概率。另一例是文献[13]所提出的联合航迹融合法,它统筹解决航迹与航迹的关联问题及航迹与航迹的融合问题。在此之前,首先解决航迹关联问题被认为是势在必行、理所当然。

参考文献

- [1] Sittler R W .An optimal data association problem in surveillance theory .IEEE Transactions on Military Electronics ,1964 ,8 ;125—139 .
- [2] Li X R .Tracking in clutter with strongest neighbor measurements—Part I ;Theoretical analysis .IEEE Trans .on Automat .Contr . ,1998 ,43(11) ;1560—1578 .
- [3] Bar-Shalom Y ,Tse E .Tracking in a cluttered environment with probabilistic data association //Proc .4th Symp .Nonlinear Estimation ,San Diego ,1973 .
- [4] Bar-Shalom Y ,Tse E .Tracking in a cluttered environment with probabilistic data association .Automatica ,1975 ,11 ;451—460 .
- [5] Fortmann T E ,Bar-Shalom Y ,Scheffe M .Sonar tracking of multiple targets using joint probabilistic data association .IEEE J .Oceanic Eng . ,1983 ,8 ;173—184 .
- [6] Bar-Shalom Y ,Li X R .Multitarget-Multisensor Tracking .Storrs ;YBS Publishing ,1995 .
- [7] Musicki D ,Evans R ,Stankovic S .Integrated probabilistic data association .IEEE Trans .on Automat .Contr . ,1994 ,39(6) ;1237—1241 .
- [8] Li N ,Li X R .Target perceivability and its applications .IEEE Transactions on Signal Processing ,2001 ,49(11) ;2588—2604 .
- [9] Reid D B .An algorithm for tracking multiple targets .IEEE Trans .on Automat .Contr . ,1979 ,24 ;843—854 .
- [10] Blackman S S ,Popoli R .Design and Analysis of Modern Tracking Systems .Boston ;Artech House ,1999 .
- [11] Streit R L ,Luginbuhl T E .A probabilistic multi-hypothesis tracking algorithm without enumeration and pruning //Proc .6th Joint Service Data Fusion Symposium ,Laurel ,1993 ;1015—1024 .
- [12] Pattipati K R ,Popp R L ,Kirubarajan T .Survey of assignment techniques for multitarget tracking //Bar-Shalom Y ,Blair W D .Multitarget-Multisensor Tracking ;Applications and Advances .Boston ;Artech House ,2000 ;77—159 .
- [13] Li X R .Optimal Bayes joint decision and estimation //Proc .2007 International Conf .Information Fusion ,Québec City ,2007 ;1—8 .

撰稿人：李晓榕

美国新奥尔良大学电气工程系

基于脑电信号的人机融合控制

Human-Computer Integration Control Based on EEG Signal

1. 问题描述

近年来,一种基于人脑电(electroencephalogram, EEG)信号的控制系统正在兴起,其发展速度非常迅速。与传统控制系统不同,这种控制系统直接以脑电信号为基础,通过脑机接口(brain-computer interface, BCI)来实现控制。这种以脑为中心、基于脑电信号的人机融合控制系统称之为脑控系统。“脑控”涉及认知神经科学、计算机科学、控制科学、心理学等多个学科,是一个新兴的多学科交叉的前沿科研方向,引起了人们广泛的研究兴趣。这类控制系统的结构示意图如图 1 所示。




图 1 脑控系统的结构示意图

脑控系统的研究主要包含三个方面:一是人脑思维或意念与脑电信号的关系。研究在自发或外界诱发的条件下,不同的思维或意念所对应的脑电信号模式;二是 BCI 系统的设计与构建。BCI 是一种脑与计算机的接口技术,利用这种接口,脑可以不通过神经和肌肉来向外界传递信息,而是通过脑部生物电信号传递信息;三是根据不同的目的和任务,设计和构建相应的基于 BCI 的控制系统和装置。

2. 研究的难点与说明

基于脑电信号的人机融合控制的研究初衷缘于医疗康复领域的需求,如肢体损伤或肌萎缩性(脊髓)侧索硬化患者康复的需要,这些运动机能丧失的患者可望利用这项控制技术,通过自身的脑电信号来操作轮椅或机器人,以辅助完成某些基本的运动功能^[1]。从控制科学的角度看,大脑是人体所有运动、语言机能的控制中心,以外部神经为媒介向身体发出指令。研究发现,即使外部神经和肢体因损伤而失去作用,但大脑的功能还是正常的,大脑发出指令信息可以通过脑电信号表征出来。研究还发现,在做不同思维任务时,或者在外界不同的刺激诱发下,脑电信号会呈现出各种有规律的模式。BCI 技术随着这一发现而产生,即将不同思维模式或者不同诱发形式下产生的不同脑电模式的特性转换为控制命令传递到外部设备,构建人脑与外界交流的新的通道。目前,脑控系统主要应用在假肢控制、鼠标控制、上网操作控制、轮椅控制、虚拟世界导航和中文输入系统^[2]等。

目前,这类控制系统的研究仍然处于初级阶段,面临着许多困难,其中,既有科学上的难题,也有应用中的关键技术难点。

基于脑电信号的人机融合控制本质上是一种基于思维或意念的控制,其基本的科学依据是:人在进行不同自发的或在外界刺激诱发下的思维或意念时,脑电信号会呈现出对应的各种有规律的模式。因此,发现和识别这种具有思维特征的脑电信号模式是这项研究的基本出发点和立足点。目前,人们已经发现和使用 SCP、P300 电位、SSVEP 和 MI 等脑电信号来构建 BCI。但是,由于人脑思维和脑电信号的复杂性,至今所使用的这类脑电信号模式都存在一些不足之处,如识别精度不高、速度较低、控制命令单一、脑信号产生不稳定和适应性差等缺陷。在实时在线处理中,脑信号特征不仅随着时间发生变化,还会因人而异。此外,训练样本和测试数据潜在分布不一致,导致根据训练样本得到的分类器不能很好地作用于测试数据,产生“协变平移(covariate shift)”现象,因此,如何设计在线自适应分类器是一个非常重要的理论研究工作。在研究有效的特征提取方法时,熵、傅里叶变换、小波变换、独立分量分析、盲信号分离、张量分析等方法均被使用,但远未完善。面向实时处理的特征提取方法既要计算速度快,又要使得提取的特征充分反映研究探讨的精神思维活动,就需要发展更加先进的信号处理和特征提取算法。

在 BCI 的研究进程中,人们正在试图解决这些问题。例如,利用高效的模式识别和机器学习算法提高脑电信号的识别速度和精度,再加上传感器的技术发展,脑电信号提取质量得到很大提高,进一步提高了识别速度和准确率。但这种精度和速度并不稳定,并且会因人而异,所以,离广泛应用还存在着距离。

近年来,一种面向 BCI 的自适应分类器被提出,试图运用机器学习的办法解决测试数据与训练数据分布不一致时的分类问题^[3]。Brunner 等提出了一种新的 BCI 系统,叫做“Hybrid-BCI”,这种 BCI 能融合不同的脑电信号,其目的是为了提高准确率、稳定性、信息传输率及避免部分使用者因某种脑电信号不明显或者缺失而不能使用 BCI 系统的情况。这种 BCI 的适应性得到了提高^[4],但这种系统只能融合特定的脑电信号,还没找到灵活融合各种脑电信号的有效方法。此外,在实际的脑控系统中,为了避免在非任务状态下产生任务命令,BCI 系统开关,也称脑开关,是不可缺少的。但由于人的思维难以控制,也不能完全避免在非任务状态下产生这些思维。因此,如何针对不同的目的和对象,找到一个保险的开关信号,也是脑控系统实际应用的一个难题^[5]。

从控制系统的设计和构建角度看,控制设备的智能化研究也许能够弥补脑控系统的某些不足,即使得控制目标具有一定的智能,通过少量的命令输入,理解使用者的需求,提高系统的整体性能,也将是脑控系统研究的一条新的途径。

脑控系统的研究已经取得了很多成果,也正在逐渐向实际应用迈进,但要使这类系统从实验室走进实际生活,造福人类,还有许多工作要做。从科学意义上讲,脑控系统的研究正在走向“思维控制”,进而实现“心想事成”的梦想。

参 考 文 献

- [1] Wickelgren I. Tapping the mind. Science, 2003, 299: 496—499.
- [2] Jin J, Allison B Z, Brunner C, et al. P300 chinese input system based on Bayesian LDA. Biomedical Engineering, 2010, 55: 5—18.
- [3] Li Y, Kambara H, Koike Y, et al. Application of covariate shift adaptation techniques in brain computer interfaces. IEEE Transactions on Biomedical Engineering, 2010, 57: 1318—1324.
- [4] Brunner C, Allison B Z, Krusienski D J, et al. Improved signal processing approaches in an offline simulation of a hybrid brain-computer interface. Neurosci. Meth., 2010, 188: 165—173.
- [5] Müller-Putz G, Kaiser V, Solis-Escalante T, et al. Fast set-up asynchronous brain switch based on detection of foot motor imagery in one-channel EEG. Medical & Biological Engineering & Computing, 2010, 48: 229—233.

撰稿人: 王行愚

华东理工大学信息科学与工程学院

部分可观马尔可夫决策过程的性能优化

Performance Optimization of Partially Observable Markov Decision Processes

1. 背景介绍

Howard 于 1960 年首次提出马尔可夫决策过程(MDP), 经过 50 年的发展, 其应用已经扩展到当前社会生活中的众多热门领域^[1], 如金融工程、网络通信、库存管理、设备维修、资源分配、交通运输等。在 MDP 模型中, 我们寻求一个最优策略, 使得当系统在该策略下运行时, 能使某种给定目标达到最优。寻求 MDP 模型最佳策略的问题, 理论上可以通过动态规划^[2]或近年提出的直接比较法^[3]求解。

然而, 对于很多实际问题, 特别是高维问题, 其状态空间通常非常之大, 以至我们用上述方法来实际求解时, 计算量很可能大到我们无法承受^[4], 这就是所谓的“维数灾”问题。解决“维数灾”问题的方法包括近似动态规划方法、强化学习方法及近年提出的基于事件的优化方法^[3,5]。基于事件的优化方法的基本理论依据之一是: 对于大多数系统, 其事件空间远远小于其状态空间(即事件数远少于状态数)。

关于 MDP 模型的另外一个问题在于: 在 MDP 模型中, 我们假设在任何时刻, 系统的真实状态都可以被“精确”地观测到。但实际应用中, 某些具体问题可能并不满足这一假设。即我们并不能直接观察到这类系统在当前时刻的真实状态, 我们所能观察到的只是系统当前时刻的一个输出, 该输出是系统当前状态的某个随机函数, 这类问题被称为“不完美状态信息问题”。例如, 一个普通的中小投资者可能并不能真实地看到一家公司的股票内在价值, 他所能看到的是附加了一些随机波动的这个内在价值的某个函数——股票价格。另一个实际应用是设备维修问题。工厂中的机器在任何时刻其内部结构都可能处于“正常”或者“异常”两个状态, 若不检查机器, 则这个状态不可见。我们所能观测到的信息来源于一些可见的系统输出, 如产品质量、机器声响等。可供我们选择的行动包括: ①什么都不做, 让设备继续生产产品; ②检查该设备以获得关于该设备是否异常的真实状态, 但检查设备需要耗费一定的经济效益; ③维修或者更换设备, 但该行动需要耗费更多的经济效益。如何决定在某一时刻是否检查设备或者是否维修更换设备以期得到最佳收益的问题便是一个部分可观

马尔可夫过程的性能优化问题。

2. 问题描述

一个 POMDP 系统由一个六元组 $(S, A, \mathbf{P}, f, O, \mu)$ 来表示^[6,7], 其中, S 为状态空间, A 为行动空间, $\mathbf{P}$ 为概率转移矩阵, f 为报酬函数, O 为观察空间, μ 为观察函数。假设在时刻 t , 系统状态 $X_t = x \in S$, 则基于观察函数 $\mu(dy|x)$, 系统会产生一个输出 $Y_t \in O$ 。基于在时刻 t 已有信息(包括输出历史及行动历史), 我们可以选择一个行动 $u = \alpha \in A$ 并施加该行动到系统中, 则依照概率转移矩阵 $\mathbf{P}_\alpha(dz|x)$, 系统将跳转至下一个状态, 与此同时, 我们获得报酬 $f(x; \omega)$ 。考虑长期平均收益准则为

$$\eta^u(x) = \lim_{T \rightarrow \infty} \frac{1}{T} \left\{ \sum_{t=0}^{T-1} f(X_t, u_t) \mid X_0 = x \right\}$$

则我们希望解决的问题是如何选取最优的策略 u 使得上式取得最大值。

3. 必要说明

如前所述, 在 MDP 模型中, 策略仅仅只是当前状态的一个函数。而对于 POMDP 模型而言, 由于当前状态不可观测, 在时刻 t , 我们拥有的信息只有系统的输出历史和我们在 t 时刻以前已经采取的行动历史。在最一般的情况下, 一个 POMDP 系统的策略是关于整个系统输出历史和行动历史的一个函数。对于无限时长的 POMDP 系统, 记录其输出历史和行动历史显然是不可行的, 这正是 POMDP 性能优化问题至今没有被彻底解决的原因之一。

通过研究 POMDP 问题, 有学者发现一个 POMDP 性能优化问题和一个基于此 POMDP 构造的标准 MDP 性能优化问题有相同的最优策略, 这个构造的 MDP 被称为置信 MDP, 这为 POMDP 问题的解决提供了一个方向。然而, 两个方面的困难阻碍了置信 MDP 问题的求解: ①求解置信 MDP 的复杂度随系统输出空间大小(可直观地理解为不同输出的个数)的增加而呈指数增长; ②求解置信 MDP 的复杂度和我们所考虑的优化时段的长度亦呈指数关系。对连续状态空间且优化时段为无限长的系统, 求解置信 MDP 更是难上加难。

除了一些特殊的系统, 当前并没有任何方法可以精确地求解一个 POMDP 问题的全局最优策略。可行的求解 POMDP 性能优化问题目前主要有两个方向: ①用近似的方法求解置信 MDP 的性能优化问题, 如极大似然状态近似等。②在一个子空间中求解最佳策略。POMDP 性能优化问题的策略本应是整个系统输出历史和行动历史的函数(全空间 Ω), 但由于记录该历史需要无穷多的存储器, 所以, 我们寻求在一个较小的策略空间(子空间 Ω)中寻找一个最优策略, 通过选取具有良好性质的子空间, 我们可以在子空间中找到一个最佳解, 这个方向

的例子有短视策略、有限记忆策略等。

4. 相关扩展

值得注意的是,基于事件的优化方法或者可以为解决 POMDP 这一难题提供更多的思路。简略而言,使用一个变量,记为内部状态去记录关于系统输出历史和行动历史的某些统计特性。我们发现,采用基于事件的优化方法,我们可以在以系统内部状态为决策变量的策略空间(如图 1 中的 Ω)中找到一个局部最优策略。更进一步,我们发现:①如果内部状态满足某个特定条件,则可以证明在整个策略空间 Ω 中的最优策略存在于子空间 Ω_1 中,即子空间中的最优策略同时也是全空间的最优策略;②通过选择不同的内部状态,我们可以在计算量和策略精度上找到一个合适的折中算法。目前,这一方向还有待更多学者的进一步研究。




图 1 全局最优与局部最优

参考文献

- [1] Howard R A .Dynamic Programming and Markov Processes .New York :Wiley ,1960 .
- [2] Bertsekas D .Dynamic Programming and Stochastic Control .New York :Academic Press , 1976 .
- [3] Cao X R .Stochastic Learning and Optimization—A Sensitivity-based Approach .New York : Springer ,2007 .
- [4] Paradimitriou C H ,Tsitsiklis J N .The complexity of markov decision processes .Mathematics of Operations Research ,1987 ,12 :441—450 .
- [5] Cao X R .Basic ideas for event-based optimization of markov systems .Discrete Event Dynamic Systems :Theory and Applications ,2005 ,15 :169—197 .
- [6] Monahan G E .A survey of partially observable markov decision processes :Theory ,models , and algorithms .Management Science ,1982 ,28 :1—16 .
- [7] Sondik E J .The optimal control of partially observable markov processes over the infinite-horizon ;Discounted costs .Operations Research ,1978 ,26 (2) :282—304 .

撰稿人:汪德新¹ 曹希仁²

1 香港科技大学工程学院

2 上海交通大学安泰经济与管理学院

大规模网络服务集群系统节能机理的建模与控制

Modeling and Control of Power Management for Large Scale Network Service Cluster Systems

1. 背景介绍

随着信息服务业的迅速发展及普及,网络数据中心和服务器集群的规模与日俱增,为了满足用户 QoS 需求,通常采用满负载运营的设计方案,因此,所引发的能耗问题日益凸显。据 Cartnet 公司的统计数据显示,维持全球服务器集群运行所消耗的能源在 2007 年已占到全球信息和通信产业能耗的四分之一。美国环境保护总署 (Environmental Protection Agency, EPA) 的统计数据表明,到 2012 年,美国数据中心和服务器的能耗将达到 1000 亿千瓦时,至少耗费成本 74 亿美元。如何有效利用能源,降低不必要的能耗已成为一项迫切需要解决的关键问题。随着我国经济的不断发展,能源问题日益凸显,发展低碳经济、节能减排成为整个社会的共识。我国“十一五”规划纲要提出,“十一五”期间,单位国内生产总值能耗降低 20% 左右,主要污染物排放总量减少 10%。为实现该目标,各行各业都积极采取节能减排措施。我国在信息技术领域,网络服务业的发展规模和增长速度大大超越世界其他国家,特别在当前传统能源短缺、新的能源生成和供应体系尚未建立的情况下,如何有效降低能耗,实现绿色计算,有效支撑国家节能减排的目标已经引起了广泛关注。今后的信息网络服务将要求满足一定的 QoS,同时大幅度降低整个运行系统的功耗、提高资源的利用率、提供可靠的服务成为当前网络服务节能控制领域中的热点和难点。

2. 准备工作

大规模网络服务系统通常按照系统的满负载情况进行设计和配置,但系统处于满负载情况通常较少,大量资源处于闲置的状态。我们从系统和应用层面出发,利用业务平台的业务特性,拟采用超时策略来驱动服务资源的休眠/唤醒切换节能机制。超时策略作为一种工业标准在实际系统中被广泛采用,其基本原理是:当服务资源的持续空闲时间大于设定的时间间隔(超时阈值)后,切换到休眠状态来节省能耗。由于切换同样需要付出能耗代价,并出现切换延时,从而降低 QoS,因此,必须根据实际情况对阈值的选择进行优化。当系统进行能量级切换时,如果被调整的资源上存在正在服务的用户,将会影响用户体验

质量。系统可采用无缝迁移的方式,将用户从被调整资源上迁移到其他资源上,整个调整过程中无需用户参与,也不会影响服务的流畅性,保证 QoS,使得能量级切换能够顺利执行。在保证 QoS 的前提下,根据负载量的变化,将系统中闲置的资源进行“休眠”,自适应地调整系统的服务能力,降低系统的能量消耗,实现服务系统的性能/能耗比最大化。

3. 问题描述

在网络服务系统的研究领域,由于服务特性不同,可能采用不同的节能优化方法,但却表现出相似的随机动态特性,即系统不同的负载量对应不同的能量运行层级。我们通过给定的时间和空间中分布的可测动态信息元素的获取、分析和融合,获得对用户访问模式和负载量的智能感知,它们可以用一个时间序列来描述,每个时间序列定义为一个事件集,通过对时间序列的预测可以获得对未来事件发生的预测。将事件序列分为两类:一类为外部事件类,它生成一系列控制决策驱动系统在不同能量级之间的切换;另一类为内部事件类,在给定的能量层级中,它生成一系列控制决策驱动系统在确保 QoS 性能的状态中运行。控制者可以通过一系列基于外部事件的控制策略驾驭系统在不同的能量层级之间进行切换。由此可以建立下述一个统一的确保 QoS 的节能控制框架。

假定系统具有 K 个能量级,在一系列外部随机事件 $\pi: \{e_{ij}, i \in S_a, j \in S_b\}$ 生成的控制策略的驱动下,在不同能量级之间进行切换。在每一个能量级下,系统可以用一个半马尔可夫过程来描述, K 个能量级对应于 K 个具有不同状态空间和演化规律的半马尔可夫过程 $SMP_k: \{S_k, Q_k(t), r_k, R_k\}, k=1, 2, \dots, K$ 。内部事件 $\pi: \{e_{ij}, i, j \in S_k\}$ 生成一系列控制策略驱动状态过程的演化,这样,构成一个半马尔可夫切换空间控制过程,如下:

$$\{X_t, t \geq 0, (SMP_k, k=1, 2, \dots, K), D, E, \eta\} \quad (1)$$

式中, $SMP_k: \{S_k, Q_k(t), r_k, R_k\} (k=1, 2, \dots, K)$ 为 K 个具有不同状态空间的半马尔可夫报酬过程; S_k 为 SMP_k 的状态空间,称其中的元素为内部状态; $Q_k(t) = [Q_k(i, j, t)] (i, j \in S_k)$ 为 SMP_k 的半马尔可夫核,描述在此空间过程中内部状态的演化规律; r_k 和 R_k 分别为代价函数和报酬函数。

切换控制行动 $d_{kl} (k \in S_k, l \in S_l)$ 表示从第 k 个能量级至第 l 个能量级的切换,行动集合 $D = \{d_{kl}, k \in S_k, l \in S_l\}$ 。

得到上述统一的确保 QoS 的节能控制框架后,我们可以在此框架下研究模型在实际不同网络服务系统中的应用与调节问题、算法的求解与优化、算法收敛性问题。

4. 必要说明

信息技术领域中,大规模服务器集群系统通常在系统层级上进行能耗控制。

美国 Rutgers 大学的 The Systems Design and Evaluation 实验室提出了一种基于集群动态配置的节能算法,称为 LC 方法^[1],他们采用控制理论中的 PID 控制器来预测和评估当前负载下对资源的需求,但论文并没有阐述和论证 PID 控制器的合理性及科学性,只是简单的应用。文献[2]~[4]使用了相同的思想来研究节能机制。上述算法都只是停留在启发式调节的层面上。

本问题面对大规模网络服务集群系统为了确保 QoS 通常按照系统的满负载运行配置资源这一现状,需要根据用户访问模式和业务负载量,采用超时策略驱动服务资源的休眠/唤醒,自适应调整系统的能量层级。难点在于:在此节能机制上超时阈值的优化配置,在建立一种基于事件驱动的半马尔可夫控制过程中,如何通过事件的分类,从状态空间上将系统分为两个层级,并应用递阶协同控制方法以实现系统性能/耗能最优化目标,以及将上述理论应用到实际系统,以探索大规模网络服务系统形成自配置、自恢复、自优化的节能技术的控制策略方案。

参 考 文 献

- [1] Pinheiro E, Bianchini R, Carrera E, et al. Dynamic cluster reconfiguration for power and performance//Benini L, Kandemir M, Ramanujam J. Compilers and Operating Systems for Low Power. New York: Kluwer Academic Publishers, 2003.
- [2] Chase J, Anderson D, Thacker P, et al. Managing energy and server resources in hosting centers. Proceedings of the 18th Symposium on Operating Systems Principles, 2001: 103—116.
- [3] Rajamani K, Lefurgy C. On evaluating request-distribution schemes for saving energy in server clusters. Proceedings of the IEEE International Symposium on Performance Analysis of Systems and Software, 2003: 111—122.
- [4] Niyato D, Chaisiri S, Sung L B. Optimal power management for server farm to support green computing. Proceedings of the IEEE/ACM International Symposium on Cluster Computing and the Grid, 2009: 84—91.

撰稿人: 奚宏生 康 宇
中国科学技术大学信息科学技术学院

有限信息系统的辨识与适应控制

Identification and Adaptive Control of Systems with Limited Information

从1948年Wiener出版了著名的 *Cybernetics: Or Control and Communication in the Animal and the Machine* 一书以来^[1], 控制论的思想已经渗透到了几乎所有的自然和社会科学领域, 逐步形成了一些经典的方法和技术, 如最小二乘法、极大似然估计等系统辨识方法, 卡尔曼滤波、Bayes 滤波等状态估计方法, 以及自校正调节等控制方法, 这些经典方法的产生极大地提高了人类的生产和生活水平。值得注意的是, 这些经典方法都是以系统的可用数据(如输入、状态、输出)的精确已知(或带有一定统计特性的测量噪声)为前提, 通过对数据做代数运算完成系统的辨识和控制。

然而, 随着现代技术的发展和信息化程度的不断加深, 实际中涌现出了一类新的系统, 如神经元系统、集成电路、无线传感网络等, 这类系统每次关于输出的数据中含有的信息量非常有限, 只知道系统输出属于某个给定的集合中, 而不知道输出的精确值。利用这类数据, 无法将系统输出提取出来做代数运算, 这就失去了经典方法的适用前提。盲目套用经典方法势必会影响系统辨识和控制的效果, 甚至会产生重大事故。要研究有限信息系统, 必须从新的角度出发, 针对其数据可用信息少和高度非线性特点, 提出针对性的方法辨识系统参数, 估计系统状态甚至施加控制来改善系统性能。

近年来, 有限信息系统的研究受到了国内外学者的广泛关注。对于一些固定集情形, 文献[2]~[4]提出了基于有界噪声的确定性框架和基于随机噪声的随机框架的参数辨识方法, 对确定性情形给出了参数最优解耦和相应的最优输入的设计方法、参数估计算法及时间复杂性估计等; 对随机情形, 利用周期输入和系统噪声的统计特性构造性地给出了辨识算法, 证明了算法的强一致收敛性和渐近最优性。文献[5]考虑了闭环情况下的信号估计问题, 利用输入设计将状态的初始值估计出来, 进而解决了闭环情况下的状态估计问题。

对于可变集情形, 需一边估计系统参数一边根据参数估计值设计可变集, 如量化系统。文献[6]研究了量化系统的辨识问题, 为得到所提的算法收敛性需假设参数估计与集值(量化值)是独立的, 这显然是不合理甚至是错误的。文献[7]提出了量化系统的最优滤波和最优量化方法, 该方法需要假设量化值服从正态分布, 其本质仍然是假设参数估计与量化值的独立性。实际上, 参数估计与量化值的相关性恰恰是量化系统的特点和研究量化系统辨识的难点。

特别值得指出的是,对于有限信息系统,无论是固定集还是可变集情形,如何做到适应控制方面都是非常有意义的工作。对固定集情形,为实现适应控制,就必须突破已有辨识方法对输入是周期的等苛刻约束,这是因为在适应控制中输入是根据控制目标来调整的,很难保证周期性。对可变集情形,反馈控制下的量化值和参数估计值的相关性将更为明显。此时,有限信息系统的在线辨识和适应控制的研究也更加困难。因此,在这类系统的辨识与适应控制方面,存在这许多亟待解决的科学问题,包括如何在持续激励甚至衰减激励下构造辨识算法?如何在不回避设参数估计与量化值相关性的前提下构造出在线递推算法,给出算法的收敛性、最优性、鲁棒性等严谨的理论分析和证明?如何提出合理的控制指标?如何设计出最优的适应控制器?这些问题的解决不仅可以丰富、完善控制理论的内容,而且还可以更好地了解和控制实际中广泛存在的有限信息系统。

参 考 文 献

- [1] Wiener N .Cybernetics ;Or Control and Communication in the Animal and the Machine .New York ;Wiley ,1948 .
- [2] Wang L Y ,Zhang J F ,Yin G .System identification using binary sensors .IEEE Trans .on Automat .Contr . ,2003 ,48 :1892—1907 .
- [3] Casini M ,Garulli A ,Vicino A .Time complexity and input design in worst-case identification using binary sensors//Proceedings of 46th IEEE Conference on Decision and Control ,New Orleans ,2007 :5528—5533 .
- [4] Zhao Y L ,Zhang J F ,Wang L Y ,et al .Identification of hammerstein systems with quantized observations .SIAM Journal on Control and Optimization ,2010 .
- [5] Li C Y ,Wang L Y ,Yin G ,et al .Irregular sampling ,active observability ,and convergence rates of state observers for systems with binary-valued observations//Proceedings of 48th IEEE CDC ,Shanghai ,2009 :8506—8511 .
- [6] Eweda E .Convergence analysis of an adaptive filter equipped with the sign-sign algorithm . IEEE Trans .on Automat .Contr . ,1995 ,40(10) :1807—1811 .
- [7] You K ,Xie L ,Sun S ,et al .Multiple-level quantized innovation Kalman filter .Proc .17th IF-AC World Congress ,2008 .

撰稿人：赵延龙

中国科学院数学与系统科学研究院

关联系统分散控制及其应用

Decentralized Control of Interconnected Systems and Its Applications

1. 背景介绍

大系统理论由于其在经济系统、电力系统、生物系统、乃至社会系统等方面明确的工程意义,从20世纪70年代至今已有四十多年的研究历史,期间吸引了大批的研究学者,出现了一些有效的理论方法,如对角或向量 Lyapunov 函数方法、 M 矩阵方法、大系统分解集结理论等^[1,2]。但是,在分散状态反馈下,大系统的分散可镇定性问题一直未得到有效的充分必要条件。分散反馈控制的意义在于各子系统只使用自己的信息进行控制,各子系统的信息不需要互相传递,其优点在于控制器简单、设计参数少、易于实施。但是,由于这类控制器带有对角块结构约束,使得控制器设计十分困难,很难得到有效的镇定控制器存在性条件。该问题本质上类同于静态输出反馈控制问题,难于在线性框架下解决。大系统可以看做是多个子系统经过关联组合后生成的复杂系统,如果针对简单的由两个或者三个子系统生成的关联系统,给出一些分散可镇定条件,以及关联项作用分析方面的结果,那么,对于大系统分散镇定问题是非常有借鉴意义的。随着科学技术的不断发展,通过关联组合提高系统品质的需求也越来越多,在关联系统研究方面给出关联作用的判定及分散控制方法以改善系统稳定性或品质是非常有意义的。

2. 问题描述

由两个子系统生成的线性关联系统可以描述为

$$\begin{cases} \dot{\mathbf{x}}_1 = \mathbf{A}_1 \mathbf{x}_1 + \mathbf{A}_{12} \mathbf{x}_2 + \mathbf{B}_1 \mathbf{u} \\ \dot{\mathbf{x}}_2 = \mathbf{A}_2 \mathbf{x}_2 + \mathbf{A}_{21} \mathbf{x}_1 + \mathbf{B}_2 \mathbf{u} \end{cases} \quad (1)$$

其中,控制律为 $\mathbf{u} = \mathbf{K}_1 \mathbf{x}_1$, $\mathbf{u} = \mathbf{K}_2 \mathbf{x}_2$, 闭环系统状态矩阵为

$$\mathbf{A}_{cl} = \begin{bmatrix} \mathbf{A}_1 + \mathbf{B}_1 \mathbf{K}_1 & \mathbf{A}_{12} \\ \mathbf{A}_{21} & \mathbf{A}_2 + \mathbf{B}_2 \mathbf{K}_2 \end{bmatrix}$$

以上即是大系统理论中典型的分散控制问题,两个子系统分别只反馈自己的信息,在控制器设计时两个子系统的信息无交互。如果设计 $\mathbf{u} = \mathbf{K}_1 \mathbf{x}_1 + \mathbf{K}_{12} \mathbf{x}_2$, $\mathbf{u} = \mathbf{K}_2 \mathbf{x}_2 + \mathbf{K}_{21} \mathbf{x}_1$, 则是传统的集中控制问题,控制器比较容易设计。在大系统理论基本框架建立起来后,上面系统很容易用对角块 Lyapunov 函数方法给出一

些基于线性矩阵不等式描述的分散可镇定充分条件。但是,对于充分必要条件,以及关联项 A_{12} 与 A_{21} 对 A_{cl} 的稳定性所能起到的作用方面一直未有较好的进展。

3. 必要说明

对于大系统(或关联系统)分散镇定问题,最初有的学者认为只要各子系统分别可控,可以设计分散控制器将各子系统的极点配置到左半平面向无穷远处,而大系统的关联项未发生改变,直观上认为这时大系统一定稳定。但是,很快有反例说明这样的大系统不但不一定稳定,而且存在固定的特征值,无论怎样设计分散控制器都不能改变这样的特征值。这类特征值被称为分散固定模,是一般系统不可控或不可观模态在分散控制问题中的推广^[3]。进一步的研究结果显示,在一些特殊关联结构下,要使整个关联系统稳定,必须有部分子系统不稳定^[4]。这正像国家经济高速发展的情况下,经常伴随着小企业的破产。一个稳定的大系统很容易分解出不稳定的子系统,那么,大系统镇定过程中也无需要求每个子系统稳定。这类研究充分显示了关联项在大系统稳定性中的作用,以及这类问题的复杂性。利用传统的对角块 Lyapunov 函数方法,只是在子系统稳定的条件下寻求大系统的稳定条件,那么,关联项相当于不确定项,不管有无关联大系统均稳定。这类结果从可靠性与鲁棒性来看是令人满意的,而且一大类系统可以符合这样的条件。例如,传统的飞行器对三通道(俯仰、偏航、滚转)进行单独控制,设计好控制器后应用参数拉偏等方法来适应整个系统,这在本质上也是一个分散控制问题,而且将耦合项当作了不确定性。但另一方面,有的实际系统并不能保证这类前提条件,而且从有效利用关联使得大系统能发挥更好的效益来看,明显是不足的。大系统分散控制过程中,如何有效利用关联改善大系统稳定性或提高品质一直是大系统控制中的难题。

4. 进一步的发展

进入 21 世纪以来,复杂网络系统的研究得到了充分发展^[5,6]。将复杂网络节点视为一个动态系统,则复杂网络是一个典型的大系统。复杂网络中一个典型问题是控制几个节点即可以使整个网络稳定或同步(即节点运动趋于一致),这类问题被称为牵制控制问题,实际上类似于大系统分散控制。如果复杂网络每个节点动力学都相同,内关联函数也相同,则复杂网络就是一个非常简单的大系统^[4,7],类似于传统大系统领域的相似大系统。复杂网络中,另一种控制方式是改变网络的拓扑结构,即增加或减少连接边或优化连接边,这相当于改变大系统的关联部分,怎样的连接方式易于复杂网络稳定或同步也是一个非常有趣的问题。经典大系统理论与复杂网络中的一些新提法相结合有可能促进学科的新发展。

经过近半个世纪的发展,关联系统理论中的一些基本问题,如分散可镇定性、关联项对稳定性或品质的作用及可解耦性等,还未得到有效解决。随着各门学科的新发展,如数学、计算机、复杂网络等,相继会出现一些新的问题,如控制几个子系统即可镇定整个关联系统,给定连接边数,怎样连接最有利于关联系统(或复杂网络)稳定(或同步)等。利用新学科理论和新计算技术,对关联系统中的一些控制问题给出有效的算法,或针对一些特殊问题给出有意义的条件,将会不断促进学科的新发展,拓展新的研究领域,而且将会为应用领域提供有效的借鉴,如高超声速飞行器多通道协调控制、多运动体编队控制等课题。现代高超声速飞行器作高机动飞行存在强烈的多通道耦合因素,传统的解耦控制方法是否有效,能否充分利用耦合项给出有效的协调控制方法,什么情况下可以解耦,什么情况下不可以解耦,这些都是非常值得研究的课题^[8~10]。

参 考 文 献

- [1] Siljak D D. Decentralized Control of Complex Systems. New York: Academic Press, 1991.
- [2] 高为炳, 霍伟. 大系统的稳定性、分散控制及动态递阶控制. 北京: 北京航空航天大学出版社, 1994.
- [3] Davison E G, Ozguner E. Characterization of decentrally fixed modes for interconnected systems. Automatica, 1983, (19): 182—196.
- [4] Duan Z S, Wang J Z, Chen G R, et al. Stability analysis and decentralized control of a class of complex dynamical networks. Automatica, 2008, (44): 1028—1035.
- [5] 汪小帆, 李翔, 陈关荣. 复杂网络: 理论与应用. 北京: 清华大学出版社, 2006.
- [6] 郭雷, 许晓鸣. 复杂网络. 上海: 科技教育出版社, 2006.
- [7] Yang G H, Zhang S Y. Decentralized control of a class of large-scale systems with symmetrically interconnected subsystems. IEEE Trans. on Automat. Contr., 1996, (41): 710—713.
- [8] 黄琳, 段志生, 杨莹. 现代飞行器控制的几个科学问题//中国控制会议, 昆明, 2008: 6—12.
- [9] 段广仁, 王好谦, 张焕水. 滑切换控制律的参数化设计及其在倾斜转弯导弹中的应用. 航天控制, 2005, 23(2): 41—46.
- [10] 郑建华, 杨涤. 鲁棒控制理论在倾斜转弯导弹中的应用. 北京: 国防工业出版社, 2001.

撰稿人: 段志生
北京大学工学院

微分平坦系统的判定

Determination of Differential Flat Systems

微分平坦系统(differential flat system)是 Fliess 等在 20 世纪 90 年代用微分代数方法研究非线性控制系统反馈线性化时引入的概念^[1,2]。粗略地说,如果能找到与系统输入个数相同的一组输出,使得系统的所有变量(系统的状态和输入)都能由这组输出以不含其积分的形式确定,则称该系统是微分平坦的。这一概念可用以下更精确的数学语言描述。对于非线性控制系统

$$\dot{\mathbf{x}} = \mathbf{f}(\mathbf{x}, \mathbf{u}) \quad (1)$$

式中, $\mathbf{x} \in X \subset \mathbf{R}^n$ 和 $\mathbf{u} \in U \subset \mathbf{R}^m$ 分别为系统的状态和输入向量; $\mathbf{f}$ 是开子集 $X \times U$ 上的光滑向量场。如果能找到由 $\mathbf{x}$ 和 $\mathbf{u}$ 及 $\mathbf{u}$ 的有限阶导数表示的解析向量函数

$$\mathbf{y} = \xi(\mathbf{x}, \mathbf{u}, \dot{\mathbf{u}}, \dots, \mathbf{u}^{(\gamma)}) \in \mathbf{R}^m \quad (2)$$

使得状态 $\mathbf{x}$ 和输入 $\mathbf{u}$ 都可用 $\mathbf{y}$ 及其有限阶导数的实解析函数表出, 即

$$\begin{cases} \mathbf{x} = \eta(\mathbf{y}, \dot{\mathbf{y}}, \dots, \mathbf{y}^{(\alpha)}) \\ \mathbf{u} = \zeta(\mathbf{y}, \dot{\mathbf{y}}, \dots, \mathbf{y}^{(\alpha+1)}) \end{cases} \quad (3)$$

$$\quad (4)$$

这里, γ 和 α 均为非负整数, 则称上述非线性控制系统为微分平坦系统(简称平坦系统), $\mathbf{y}$ 为该系统的平坦输出。当平坦输入 $\mathbf{y} = \xi(\mathbf{x})$ 仅为 $\mathbf{x}$ 的函数时, 称系统是 0-平坦的; 否则, 称系统是 $\gamma+1$ -平坦的。

微分平坦性可以视为非线性控制系统和线性控制系统能控标准型间的等价性问题。事实上, 很容易看出, 若定义 $\mathbf{z} = [\mathbf{y}^T, \dot{\mathbf{y}}^T, \dots, \mathbf{y}^{(\alpha+1)T}]^T$, $\mathbf{v} = \mathbf{y}^{(\alpha+1)}$, 则由式(3)和式(4)确定的 $\mathbf{x} = \eta(\mathbf{z})$ 和 $\mathbf{u} = \zeta(\mathbf{z}, \mathbf{v})$ 分别为将非线性控制系统(1)化为线性控制系统 Brunovsky 能控标准型的状态和输入变换, 这表明非线性控制系统(1)的解可以用能控线性控制系统解的函数表示; 反之, 由式(2)知, 能控线性控制系统的解也可用非线性控制系统(1)解的函数表示。这一性质称为这两系统间的绝对等价性^[3]。利用绝对等价性的概念可以证明, 非线性控制系统(1)是微分平坦系统等价于它是可动态反馈线性化的, 这表明能控的线性控制系统都是微分平坦系统, 微分平坦系统是能控线性控制系统的一种重要推广。利用系统等价的概念, 还可将微分平坦系统的概念推广到用时滞微分方程和偏微分方程描述的控制系統, 使这一概念可用于时滞控制系统和分布参数控制系统研究。

可以证明, 许多实际工程系统都是微分平坦系统^[4,5], 如机械臂、移动机器人及拖车、水下机器人、某些空间机器人和卫星、垂直起降飞机、气垫船、汽车、自行车、起重机、柔性结构、飞行导航系统、感应电机、DC-DC 和 DC-AC

变换器、某些化学反应和热工过程等。

微分平坦性是非线性控制系统的重要结构性质。利用这一性质,可方便有效地解决很多复杂非线性系统的控制设计问题^[4,5]。因平坦系统的状态由平坦输出及其导数决定,在进行其轨迹规划时,可将平坦输出参数化后,利用边界和约束条件很方便地规划出平坦输出轨迹,进而确定系统的状态轨迹。这样,不仅在轨迹规划时可避免涉及复杂的系统动态方程,且可立即由式(4)得到实现该规划轨迹所需的开环控制。平坦系统的轨迹跟踪控制,可利用式(2)由期望状态轨迹得到期望平坦输入轨迹,只要能控制平坦输出跟踪期望轨迹,即可保证系统跟踪期望状态轨迹。由于平坦输出与控制输入的维数相同,减小了跟踪控制设计的难度。平坦系统的镇定问题,可以先将平坦输入作为“虚拟输入”,再用 backstepping 方法设计出镇定控制律;还可在镇定控制时利用平坦输入规划系统轨迹,将镇定问题转化为轨迹跟踪问题进行设计,以减少控制量的大小。可以说,系统的平坦输出“浓缩”了系统的动态特性,通过控制平坦输出可以更方便地达到控制整个系统的目的。

尽管系统的微分平坦性为控制系统设计提供了很大方便,但迄今尚未找到如何判定一个非线性控制系统是平坦系统并确定其平坦输出的一般方法^[6],其困难在于:由上所述可知,只有两种途径可确定一个非线性控制是否是平坦系统。一是找出系统的平坦输出,但目前还不知道平坦输出的存在性与系统方程形式有任何明确的一般关系,就如同在研究系统稳定性时不知道 Lyapunov 函数的存在性与系统方程间的关系一样,因此,无法通过这种途径找出判断平坦系统的一般方法;二是通过判断系统是否可动态反馈线性化来判断它是否是平坦系统,遗憾的是,现在对一般非线性系统可动态反馈线性化的条件还知之甚少,其主要困难是无法确定动态反馈控制器的阶数。目前,仅利用外微分系统方法对某些特殊系统得到一些结论,主要包括以下几点:

(1) 可静态反馈线性化的系统是平坦系统。由此可知,系统可静态反馈线性化的条件是判断系统平坦性的充分条件。又因单输入系统可静态反馈线性化等价于可动态反馈线性化,故单输入控制系统可静态反馈线性化的条件是判断其平坦性的充要条件。

(2) 若输入维数比状态维数少 1 的仿射非线性控制系统

$$\dot{x} = f(x) + g(x)u; \quad x \in X \subset \mathbf{R}^n, u \in U \subset \mathbf{R}^{n-1}$$

是能控的(更精确地说,是对几乎所有 $x \in X \subset \mathbf{R}^n$ 都是强能接近的),则它是 0-平坦系统。最近,这一结果被进一步推广到更广泛的系统^[7]。

(3) 二输入无漂移系统

$$\dot{x} = g_1(x)u + g_2(x)w$$

是平坦系统的充要条件是： E_k 的通秩为 $k(k=0, \dots, n-2)$ ，其中， $E_0 \triangleq \text{span}\{g^1, g^2\}$ ， $E_{k+1} \triangleq \text{span}\{E_k, [E_k, E_k]\}$ ， $[\cdot, \cdot]$ 为李括号^[8]。

(4) 若状态为 n 维，输入为 $n-2$ 维的无漂移系统

$$\dot{\mathbf{x}} = \sum_{i=1}^{n-2} g_i(\mathbf{x}) u_i; \quad \mathbf{x} \in X \subset \mathbf{R}^n$$

是能控的(对几乎所有 $\mathbf{x} \in X \subset \mathbf{R}^n$ 都是强能接近的)，则它是平坦系统；且当 n 为奇数时是 0-平坦系统，当 n 为偶数时是 1-平坦系统^[9]。

目前得到的这些确定微分平坦系统的判据还远远不能满足实际应用的需要，通过进一步深入研究获得更多的微分平坦系统判据及确定平坦输出的方法是非线性控制系统研究中有重要理论意义和应用价值的课题。

参 考 文 献

- [1] Fliess M, Levine J, et al. On differentially flat nonlinear systems // Proceedings of the IFAC Symposium on Nonlinear Control Systems Design, Bordeaux, 1992; 408—412.
- [2] Fliess M, Levine J, et al. Flatness and defect of nonlinear systems: Introduction theory and examples. International Journal of Control, 1995, 61(6): 1327—1361.
- [3] van Nieuwstadt M, Rathinam M, et al. Differential flatness and absolute equivalence of nonlinear control systems. SIAM Journal on Control and Optimization, 1998, 36(4): 1225—1239.
- [4] Martin P, Murry R M, et al. Flat systems // Proceedings of 1997 European Control Conference, Brussels, 1997; 211—264.
- [5] Sira-Ramirez H, Agrawal S K. Differentially Flat Systems. New York: Marcel Dekker Inc., 2004.
- [6] Fliess M, Levine J, et al. Some open question related to flat nonlinear systems // Blondel V D, Sontag E, et al. Open Problems in Mathematical systems and Control Theory. London: Springer, 1999; 99—103.
- [7] Bououdien S, Boutat D, et al. A geometrical characterization of a class of 0-flat affine dynamical systems // Proc. of American Control Conference, St. Louis, 2009; 3989—3994.
- [8] Martin P, Rouchon P. Feedback linearization and driftless systems. Mathematics of Control, Signals and Systems, 1994, 7(3): 235—254.
- [9] Martin P, Rouchon P. Any (controllable) driftless system with m inputs and $m+2$ states is flat // Proc. of the 34th IEEE Conf. on Decision and Control, New Orleans, 1995; 2886—2891.

撰稿人：霍 伟

北京航空航天大学自动化科学与电气工程学院

控制器结构与控制性能之间约束关系的量化

Quantitative Research on Constraint Relations between Controller Structure and Performance

1. 背景介绍

随着社会的不断进步,人们也对控制提出了越来越高的要求。为了满足不断提高的要求,以及传统控制方法往往难以满足要求的实际情况,许多现代控制方法被提出,但如果回到基础问题:一个控制器的极限性能能达到怎样?目前还没有很好地解决。控制性能指标怎样制定才是合理可行的?这个问题困扰着工程技术人员,面对着众多的控制方法也难以确定何种更为有效。控制性能指标如何以合理的方式提出才能符合实际,不仅具有很强的应用指导价值,而且具有深度揭示控制机理的理论意义。

2. 问题描述

考虑线性定常系统

$$P(s) = \frac{y(s)}{u(s)} = \frac{B(s)}{A(s)} \quad (1)$$

式中, y 为被控输出; u 为被控输出; 线性定常多项式 $A(s)$ 和 $B(s)$ 满足 $\deg B(s) < \deg A(s)$ 。

传统的 PID 控制器采用下列形式:

$$C(s) = k_p + \frac{k_i}{s} + k_d d(y) \quad (2)$$

这里的 $d(y)$ 可以采取传统的误差微分形式,对于一些输出微分可直接测量的系统,比如说飞行控制中采用速率陀螺直接得到姿态角速率信息的情形,就一般不采用误差微分,而是直接将测量角速率作为阻尼信号等。实际应用中,技术人员还是更多地使用简单的 PID 控制器。因此,对于这些结构确定的控制器,控制性能是否可达一直是困扰理论和工程界的一个难题。

控制性能的描述一般分为时域和频域两个方面。时域指标主要是指输出信号是否和指令信号贴近,平稳而快速是最理想的,也是一对矛盾的指标,从定量的角度可以描述成 ISE、ITSE 或者 ITAE 等指标,都是比较形象的。时域指标主要对应于动态品质。另一方面,控制器还必须具有一定的适应对象变化的

能力,这个往往用略微抽象的频域指标来描述,如幅值裕度和相位裕度等,也就是鲁棒性。动态性能和鲁棒性是一对制约性指标。

控制器反馈的能力到底能实现以上怎样的指标?这个问题在最近十几年来吸引了许多控制理论学者的关注,也成为控制领域一个基础性的问题。只有知道了对于一个对象,反馈控制器能够达到怎样的性能极限,才能使得控制设计更有针对性,避免盲目性。郭雷等针对控制中最根本的稳定性镇定问题,给出了这方面比较有价值的研究成果^[1]。对于如下被控系统:

$$y_{t+1} = f(y_t) + u + w_{t+1} \quad (3)$$

式中,非线性函数 $f(\cdot): \mathbf{R}^1 \rightarrow \mathbf{R}^1$ 完全未知,而 $\{w_t\}$ 是未知但有界噪声,满足

$$|w_t| < w \quad (4)$$

定义 f 的伪范数为

$$\|f\| := \lim_{\alpha \rightarrow \infty} \sup_{(x,y) \in \mathbf{R}^2} \frac{|f(x) - f(y)|}{|x - y| + \alpha} \quad (5)$$

泛函空间为

$$F(L) := \{f \in F; \|f\| \leq L\} \quad (6)$$

则当 $L < \frac{3}{2} + \sqrt{2}$ 时,存在反馈控制律 $h(\cdot)$,使得对于任意的 $f \in F(L)$ 闭环可镇定;反之,不存在这样的反馈控制律 $h(\cdot)$ 。这是一个有趣同时具有比较明确几何直观含义的结论,十分有助于理解反馈的能力,具有很强的科学价值。

如何将具有美感的科学性与实际工程联系起来,更有针对性地研究常见控制结构所能达到的性能,就摆在了我们面前,这涉及更高一个层次的控制性能问题。目前,这方面的工作基本上都是围绕线性被控对象和使用线性控制器的情形。一些学者进行了比较系统的研究,得到了很有价值的结论。对于最小相位系统,使用线性控制器可以实现对于指令信号的完全精确跟踪,对于非最小相位系统,给出了跟踪能力可以实现的性能边界,这个边界与不稳定零点的个数和位置相关。一般来说,用下列 ISE 指标还描述暂态响应误差特性:

$$J(r) = \int_0^\infty \|r(t) - y(t)\|^2 dt = \int_0^\infty \|e(t)\|^2 dt \quad (7)$$

式中, $r(t)$ 是参考指令。跟踪性能的极限用下式表示:

$$J_{\text{opt}}(r) = \inf_K J(r) \quad (8)$$

式中, K 是所有的线性镇定控制器集合。对于阶跃响应情形,这个极限为^[2]

$$J_{\text{opt}} = 2 \sum_{i=1}^m \frac{1}{z_i} \quad (9)$$

式中, z_i 是对象(1)的不稳定零点。对于跟踪正弦信号的情形,这个极限为^[2]

$$J_{\text{opt}} = 2 \sum_{i=1}^m \left(\frac{1}{z_i - j\omega} + \frac{1}{z_i + j\omega} \right) \quad (10)$$

式中, ω 为正弦信号频率。对于具有多个频率成分的情形, 文献[3]给出了类似的更为复杂的形式。上述结果所采用的控制器是一个与对象阶次相当的控制器, 对于比较高阶的对象, 实现起来具有一定难度, 仅具有理论价值。

同样, 在稳定裕度领域, 也有类似的工作。对于稳定裕度, 相位裕度往往具有更重要的意义, 不仅直接牵涉更常规的不确定性鲁棒问题, 而且还与动态性能直接相关。Doyle 等^[4]研究得到, 当对象是开环稳定并且是最小相位的时候, 可以通过线性控制器实现 π 的相位裕度, 而对于不稳定或者非最小相位系统, 则可以通过一个系统逼近来实现与右半平面零、极点相关的一个性能函数。

$$\theta_{\text{up}} = \begin{cases} \pi, & \text{对象(1)稳定或者最小相位} \\ 2\arcsin \frac{1}{\gamma_{\text{inf}}}, & \text{其他情形} \end{cases} \quad (11)$$

这里, $\gamma_{\text{inf}} := \inf \|T\|$, T 是补灵敏度函数, 也就是

$$T = \frac{PC}{1+PC} \quad (12)$$

Dorato 等^[5]针对逼近实现中可能出现的复系数问题进行了改进, 但以上结论都是在不限定控制器阶次和结构的情况下得到的。Ho 等^[6]对 $\arctan$ 函数进行近似, 对于一些低阶典型特征对象, 得到了 PI 类型控制器的稳定裕度可行区域, 但推广到更复杂一些的控制结构还比较困难。

对于实际应用而言, 由于受到种种条件的限制, 控制器的阶次一般都不会太高, 一阶或者二阶而已, 如何针对阶数和结构已知的控制器得到控制性能所能达到的极限, 是一个很具有挑战性的课题, 特别是如何得到有价值的解析结果, 或者简化的数值近似结果, 这样的结果无疑具有很重要的理论与实际价值。

参 考 文 献

- [1] Xie L L, Guo L. How much uncertainty can be dealt with feedback? IEEE Trans. on Automat. Contr., 2000, 45(12): 2203—2217.
- [2] Qiu L, Davison E J. Performance limitations of nonminimum phase systems in the servo-mechanism problem. Automatica, 1993, 29: 337—349.
- [3] Su W Z, Qiu L, Chen J. Fundamental performance limitations in tracking sinusoidal signals. IEEE Trans. on Automat. Contr., 2003, 48(8): 1371—1380.
- [4] Doyle J C, Francis B A, Tannenbaum A R. Feedback Control Theory. New York: Mcmillan, 1992: 192—193.
- [5] Dorato P, Famularo D, Abdallah C T. Analytic phase margin design. IEEE Trans. on Auto-

mat.Contr.,1999,44(10):1894—1900.

- [6] Ho W K, Hang C C, Cao L S. Tuning of PID controllers based on gain and phase margin specifications. Automatica, 1995, 31: 497—502.

撰稿人：陈增强

南开大学信息技术科学学院

神经网络控制系统的优化设计

Optimization Design of Neural Network Control Systems

20 世纪 40 年代起,随着神经解剖学、神经生理学及对脑细胞神经元电生理过程等的研究取得突破性进展,提出了由多个简单处理单元彼此按某种方式相互连接而成且具有一定信息处理功能的人工神经网络。从本质和结构上看,人工神经网络是对人脑结构、组成、工作原理及实现功能等进行简化、抽象和模拟而建立的信息处理模型。作为交叉学科,神经网络的研究从 1943 年心理学家 McCulloch 和数学家 Pitts 提出 M-P 模型^[1]开始,经历了启蒙时期(20 世纪 40~60 年代)、低潮时期(20 世纪 70 年代)、复兴时期(20 世纪 80~90 年代)和发展时期(20 世纪 90 年代中后期起)。

神经网络由于自身具有非线性特性和很强的学习、容错、并行处理和联想记忆能力,因此,被广泛用于处理非线性、动态未知或不确定的复杂系统辨识与控制。在非线性系统辨识中,经常遇到的共性问题是对某个系统可采集到大量输入、输出数据,但对其内部蕴藏的规律很难用数学方程来描述。神经网络则可以从输入输出数据中通过学习逼近系统输入、输出之间映射关系,即对于任意定义在紧集 $\mathbf{Z} \in \Omega \subset \mathbf{R}^n$ 上的连续实函数 $Q(\mathbf{Z})$ 和任意给定 $\epsilon \geq 0$, 存在含有一个隐层的神经网络(若神经网络为三层前馈网络),使得

$$\sup_{\mathbf{Z} \in \Omega} \|Q(\mathbf{Z}) - \mathbf{W}^{*T} \Phi(\mathbf{V}^{*T} \mathbf{Z})\| < \epsilon \quad (1)$$

式中, $\Phi(\mathbf{V}^{*T} \mathbf{Z}) = [\Phi_1(\mathbf{V}^{*T} \mathbf{Z}), \dots, \Phi_L(\mathbf{V}^{*T} \mathbf{Z})]^T \in \mathbf{R}^L$ 为神经网络基函数向量; $\mathbf{Z} \in \mathbf{R}^n$ 为神经网络输入; $\epsilon \in \mathbf{R}$ 为网络有界固有逼近误差; $\mathbf{W}^* \in \mathbf{R}^L$ 和 $\mathbf{V}^* \in \mathbf{R}^{n \times L}$ 为有界的神经网络理想权值。为了实现神经网络对不确定性未知非线性系统的辨识和控制,需要对神经网络控制系统进行优化设计,从神经网络结构、权值学习规则、神经网络固有逼近误差补偿等多方面进行综合考虑。近年来,这些方面已取得了较多的研究成果,极大地促进了神经网络在非线性系统控制中的应用。但由于神经网络本身结构的特殊性,在非线性神经网络辨识和控制系统优化设计方面,目前依然存在着一些亟待解决的问题,可归纳如下:

(1) 神经网络结构优化设计问题。神经网络逼近非线性函数的性能好坏通常取决于网络类型选择与网络结构设计的成功与否。目前,神经网络具有多种模型结构,如多层前馈神经网络、径向基函数神经网络、高次神经网络等。虽然已经证明,这些神经网络均能在紧集上逼近连续函数,但在什么情况下该采用哪种网络结构?需要多少个隐含层?每个隐含层需要多少个节点等基本问题

还没有明确答案,即神经网络模型选择和设计尚无系统性的指导理论,缺乏一套完善可循的设计方法,且不能从理论上进行定性和定量的分析设计。目前,大多采用试凑法来选择网络模型,然后根据设计者的经验选择隐含层数和节点个数,并在实验中修正直至达到一个满意结果为止。虽然有人给出了一些节点个数选择方法和经验公式,如针对网络节点个数提出了构造法、删除法等,但这些规则和经验给出的结果未必是最优选择和设计,且在增加和删除网络节点过程中如何分析系统的瞬态和稳态性能依然是一个需要解决的问题。

(2) 神经网络权值学习算法设计问题。BP 算法是神经网络权值学习中应用最广的方法,但该算法基于梯度最速下降法,易陷入局部极小值点、收敛速度慢等问题。近年来,以 Narendra^[2]、Polycarpou^[3]、Lewis^[4]、Ge^[5]等为代表的控制专家将自适应技术与神经网络学习相结合,通过 Lyapunov 定理进行分析,给出了基于自适应技术的神经网络权值在线学习算法(如 σ -modification 算法、e-modification 算法、Deadzone-modification 算法、Projection 算法等),保证了系统闭环误差和神经网络权值误差的一致最终有界性(uniformly ultimately bounded, UUB)。现有的研究结果大多不能保证系统误差收敛到零点,也不能保证在线调节的神经网络权值收敛到理想值,而只能证明权值收敛到理想值的邻域内。虽然 Farrell^[6]、Wang^[7]等学者在神经网络控制系统误差收敛分析方面进行了一些探索,但神经网络权值学习算法的优化设计和收敛问题依然没有得到完整的解决,成为目前神经网络领域研究的难点。

(3) 神经网络固有逼近误差补偿问题。在非线性系统辨识和控制中,常运用神经网络逼近非线性连续函数,但无论采用何种网络结构、何种权值学习算法,这种近似本身存在固有的未知逼近误差。普遍认为,该逼近误差无法从神经网络自身得到克服和解决,这也给控制系统分析带来了困难。因此,目前在含有神经网络的辨识和控制系统中只能保证系统误差和权值误差一致最终收敛到零点邻域内,而不能证明误差渐进收敛到零点。虽然有一些学者在控制器或者辨识器设计中引入滑模鲁棒项用于补偿神经网络的逼近误差^[8],但这些方法都需要神经网络的逼近误差上界已知,而且滑模项的引入也会给系统控制量中加入非光滑的动态,甚至产生抖动现象。因此,神经网络固有逼近误差的有效补偿依然是控制领域研究的难点之一。

(4) 神经网络控制系统瞬时性能定量分析和优化问题。目前,应用神经网络的辨识和控制系统中,其权值学习朝着使辨识或控制误差减小的方向进行调节。但由于神经网络权值调节需要一定的学习时间,故初始阶段瞬时性能可能无法满足系统需求。目前给出的神经网络控制系统稳定性结果大多也都是定性分析,如稳定、渐进稳定等定性的结论,而非定量的分析与评判,特别是神经网络初始权值、学习参数及基函数选取对控制系统性能和网络训练时间的影响,

目前并没有统一的研究结果,因此,需要找到一种优化策略选择神经网络初始权值和学习参数,同时保证控制系统的稳态和瞬态性能。虽然Rovithakis等^[9]给出了一种定量的神经网络控制系统瞬态和稳态性能分析方法,但尚未形成完善的体系,需要进一步研究。

由于神经网络自身融合了多学科、多门类的知识,人类对其探索依然停留在从结构上模拟人脑组织结构,并运用某些机制实现部分特殊功能的阶段,而对其有形的外在结构、背后的内在机理和本质尚无完整全面的认识。因此,需要来自不同学科的科研工作者,特别是控制领域的研究人员从系统论的角度出发,提出更加完善的神经网络控制系统优化设计思想,研究其定性定量的分析方法,真正实现从人工神经网络到“人脑”神经网络的过渡。

参 考 文 献

- [1] McCulloch W S, Pitts W .A logical calculus of the ideas immanent in nervous activity .Bulletin of Mathematical Biophysics ,1943 ,5 :115—133 .
- [2] Narendra K ,Parthasarathy K .Identification and control of dynamical systems using neural networks .IEEE Transactions on Neural Networks ,1990 ,1(1) :4—27 .
- [3] Polycarpou M M ,Mears M J .Stable adaptive tracking of uncertain systems using nonlinearly parameterized on-line approximators .International Journal of Control ,1998 ,70(3) :363—384 .
- [4] Lewis F L ,Jagannathan S ,Yeildirek A .Neural Network Control of Robot Manipulators and Nonlinear Systems .London :Taylor & Francis ,1999 .
- [5] Ge S S ,Lee T H ,Harris C .Adaptive Neural Network Control of Robotic Manipulators .Singapore :World Scientific ,1998 .
- [6] Farrell J .Persistence of excitation conditions in passive learning control .Automatica ,1997 ,33(4) :699—703 .
- [7] Wang C ,Hill D J .Learning from neural control .IEEE Transactions on Neural Networks ,2006 ,17(1) :130—146 .
- [8] Patre P M ,MacKunis W ,Kaiser K ,et al .Asymptotic tracking for uncertain dynamic systems via a multilayer neural network feedforward and RISE feedback control structure .IEEE Trans .on Automat .Contr .,2008 ,53(9) :2180—2185 .
- [9] Bechlioulis C P ,Rovithakis G A .Adaptive control with guaranteed transient and steady state tracking error bounds for strict feedback systems .Automatica ,2009 ,45 :532—538 .

撰稿人：任雪梅
北京理工大学自动化学院

随机系统 H_∞ 预演控制

Stochastic H_∞ Preview Control

1. 背景介绍

预演控制问题是研究如何利用提前获取的参考信息或扰动信息来设计控制器以改进追踪性能或更好地抑制扰动对系统造成影响的控制问题,该问题的研究具有广泛的实际应用背景,如无人驾驶飞行器、车辆、舰艇等控制系统的设计^[1,2]。

预演控制问题的研究可追溯到 20 世纪 60 年代^[2]。最初的研究主要针对确定性系统二次最优预演控制,20 世纪 70 年代,随着 Tomizuka^[3]博士课题的完成及其对连续时间最优预演控制问题的探讨,确定性系统最优预演控制理论取得了重要进展。2006 年,预演窗口宽度与最优性能之间显式表达关系的建立^[4]标志着最优预演控制问题基本得以解决。与二次最优预演控制相比较, H_∞ 预演控制复杂性表现在如何得到控制器的充要条件。确定系统 H_∞ 预演控制曾被列为 *Open Problems in Mathematical Systems and Control Theory*^[5] 的 53 个公开问题之一,而随机系统 H_∞ 预演控制是一个更具挑战性的难题。

2. 问题描述

为方便叙述,首先引入以下符号: $\|f\|_{L_2[a,b]} \doteq \left[\int_a^b f(t)' f(t) dt \right]^{1/2}$, $a, b \in \mathbf{R}$, $\mathbf{R}$ 为实数集, f' 表示 f 的转置。此外,我们还假设本文涉及的所有矩阵运算都相容。

H_∞ 预演控制问题研究当扰动信息可提前获取时,如何利用其设计控制器以保证该扰动对系统输出的影响被限制在给定的范围内。

由于已有的关于 H_∞ 问题的频域描述^[5]无法应用于相应的有限时间域、时变系统、随机系统等情况(因时变系统、有限时间域及随机系统不存在传递函数),下面将从时域的角度来刻画问题。

随机系统 H_∞ 预演控制。考虑系统

$$\begin{aligned} d\mathbf{x}(t) &= [\mathbf{A}\mathbf{x}(t) + \mathbf{B}\mathbf{u}(t) + \mathbf{C}\mathbf{w}(t-h)]dt + [\mathbf{A}_0\mathbf{x}(t) + \mathbf{B}_0\mathbf{u}(t)]d\mathbf{W} \\ \mathbf{z}(t) &= \mathbf{D}_0\mathbf{x}(t) + \mathbf{D}_1\mathbf{u}(t) \end{aligned} \quad (1)$$

对于给定的 $\gamma > 0$, 寻找全息控制器

$$u(t) = F(x(t), w(s) | t-h \leq s \leq t) \quad (2)$$

使得

$$\frac{E \| z \|_{L_2[a,b]}}{E \| w \|_{L_2[a,b-h]}} < \gamma \quad (3)$$

式中, x 、 w 、 u 、 z 分别代表系统状态、外部扰动输入、控制输入和待调节信号; h 是非负实数, 称为预演窗口宽度; W 为 Brownian 运动; E 是数学期望。

注意: 当 a, b 有界时, 问题是有限时间域的; 当 b 趋于无穷时, 问题是无限时间域的。

3. 必要说明

经过多年的研究, H_∞ 预演控制及固定滞后平滑问题陆续取得了以下进展。

2005 年, 文献[6]提出新息重组分析方法和时滞系统控制与估计对偶性理论, 完善解决多通道时滞系统的最优二次 LQR 问题, 进而将结果推广到确定系统 H_∞ 预演控制和 H_∞ 平滑估计[7]。

2005 年, Tadmor 从对策论的角度研究了确定性系统的 H_∞ 预演控制问题[8], 以一对代数 Riccati 方程解的性质, 刻画了该问题可解的充要条件, 并根据对偶性原理, 直接给出了 H_∞ 固定滞后平滑器及其存在的充要条件。

2006 年, Kojima[9]基于 Prichard-Salamon 系统, 使用算子理论, 给出了确定性系统 H_∞ 预演控制问题可解的充要条件。

尽管随机系统广泛地存在于自然界中, 能更真实地刻画系统的动态特性, 但由于随机不确定性的存在, 即便是基本的随机系统的极大值原理[10]和 LQR 控制问题, 其研究也经过了长时间的探索。因而迄今为止, 尚未看到随机系统成熟的时滞优化控制理论。不难想象, 解决随机 H_∞ 预演控制问题就更困难了。

随机 H_∞ 预演控制问题的研究与相应的确定性问题研究有本质区别, 其复杂性主要源于两方面: 预演(属于时滞问题的范畴)和随机不确定性。基于目前随机理论的发展及研究思想, 解决该问题最可能的途径是: 尽量将相应的确定性系统的思路平行但非平凡地推广到随机系统。

尽管如此, 以上提到的各类方法在推广过程中都遇到了不同程度的障碍。

文献[6]、[7]中, 标准的卡尔曼滤波与 LQR 控制问题之间的对偶关系是问题得以解决的关键。但对于随机系统, 这种对偶关系却并不成立。因此, 文献[6]、[7]的新息分析技术结合对偶性方法目前还无法推广到随机系统。

Tadmor[8]提到的思路主要在于正倒向常微分方程的解耦求解及非齐次方程的齐次化。考虑到随机正倒向方程解的适应性, 非齐次方程的齐次化非常困难, 这严重影响了整个思路的推广。

Kojima[9]解决问题的思想主要依赖于抽象无时滞系统 H_∞ 控制问题的可解性

与对应的 Hamilton 矩阵的稳定子空间之间的关系, 这种关系本质上是 H_∞ 控制问题与一个 H_∞ 型 Riccati 方程的解之间的关系, 它本该对应于随机系统 H_∞ 控制问题与一个广义 Riccati 方程解之间的关系, 而广义 Riccati 方程的解与相应 Hamilton 矩阵的稳定子空间之间不存在类似的关系。基于上述考虑, 该思路的推广也遇到了严重的障碍。

综上可知, 随机 H_∞ 预演控制问题的研究非常复杂, 它的解决任重道远, 有待于随机系统的许多基本问题的解决。

参 考 文 献

- [1] Silvestre C, Cunha R. A bottom-following preview controller for autonomous underwater vehicles. Proceedings of the 45th IEEE Conference on Decision & Control, 2006; 715—720.
- [2] Bender E K. Optimum linear preview control with application to vehicle suspensions. ASME J. Basic Engineering, 1968, 90(2): 213—221.
- [3] Tomizuka M. The optimal finite preview problem and its application to man-machine systems [PhD Dissertation]. Cambridge: Massachusetts Institute of Technology, 1973.
- [4] Moelja A A, Meinsma G. H_2 control of preview systems. Automatica, 2006, 42(6): 945—952.
- [5] Blondel V. Open Problems in Mathematical Systems and Control Theory. Berlin: Springer, 1999.
- [6] Zhang H S, Duan G, Xie L. Linear quadratic regulation for linear time-varying systems with multiple input delays. Part II: Continuous-time case // Proc. of 5th International Conference on Control and Automation, Budapest, 2005, 2: 954—959.
- [7] Zhang H S, Xie L. Control and Estimation for the Systems with Input/Output Delays. Berlin: Springer, 2007.
- [8] Tadmor G, Mirkin L. H_∞ control and estimation with preview—Part I: Matrix ARE solutions in continuous time. IEEE Trans. on Automat. Contr., 2005, 50(1): 19—28.
- [9] Kojima A, Ishijima S. Formulas on preview and delayed. IEEE Trans. on Automat. Contr., 2006, 51(12): 1920—1937.
- [10] Peng S. A general stochastic maximum principle for optimal control problems. SIAM Journal on Control and Optimization, 1999, 28: 966—979.

撰稿人: 张焕水¹ 王宏霞²

1 山东大学控制科学与工程学院

2 哈尔滨工业大学深圳研究生院

滑动模态的抖振问题

Chattering Problem in Sliding Mode Control

变结构控制是 20 世纪 50 年代末由苏联学者 Emel'yanov、Utkin^[1]等提出来的。60 年代末,人们发现滑动模态对系统参数的变化和外部扰动具有完全的自适应性^[2],这种特性引起了控制界的极大关注,吸引了国际上众多学者展开了对变结构控制的研究。特别是 20 世纪 80 年代以来,随着计算机、大功率电子切换器件、机器人及电机等技术的迅速发展,变结构控制的理论和应用研究进入了一个新的阶段,其所研究的对象已涉及非线性系统、离散系统、时滞系统、随机系统^[3]等众多复杂系统,同时,许多其他先进控制技术(如自适应控制、模糊控制、神经网络控制等)也被综合应用到变结构控制系统的设计中。然而,变结构控制本质上是一种不连续控制,不断变化的开关特性引起的高频抖振不仅影响了控制的精确性,增加能量消耗,而且会激发系统中建模时未考虑的高频部分,使系统的性能下降甚至完全破坏。抖振是制约变结构控制广泛应用的突出障碍,削弱或消除抖动是变结构控制在实际应用中要着重解决的首要问题。

1. 抖振产生的主要原因

从理论上说,对于一个理想的变结构控制系统(即假设“结构”切换的过程无时间和空间滞后,系统状态测量精确无误,控制量也不受限制),则滑动模态应是降维的光滑运动,不应当有抖振。但是,当具体实现变结构系统时,理想的开关特性 $u = u(x)\text{sgns}(x)$ 是不可能实现的,时间延迟和空间滞后是不可避免的,时间上的延迟和空间上的滞后使得滑动模态呈现抖动形式,这种现象称为抖振。

2. 削弱与消除抖振的几种常用方法

国内外针对滑动模态削弱和消除抖振的研究很多,目前,代表性的方法主要有趋近律法^[4]、边界层法^[5]、模糊控制法。另外,还有滤波方法、扇形区域法、降低切换增益方法、 H_∞ 优化设计方法等其他一些削弱与消除抖振的方法。

(1) 趋近律法(连续系统)。高为炳先生 1989 年提出下面趋近律^[4]:

① 指数趋近律: $\dot{s} = -ks - \epsilon \text{sgns}$, $k > 0$, $\epsilon > 0$ 。

② 幂次趋近律: $\dot{s} = -\beta s^\alpha$, $\beta > 0$, $0 < \alpha < 1$ 。

这两个趋近律和高先生后来针对离散变结构控制提出的趋近律^[6]从全新的

角度揭示了变结构控制的运动机理,较好解决了多变量系统变结构控制器的设计问题。指数趋近律有很直观的解释。适当增大参数 k , 减小参数 ϵ , 既可以减小抖振, 又可以保证快速到达切换面, 这是目前应用最广和最为成熟的削弱抖振的方法。变结构控制理论的创始人之一 Utkin 教授将这个方法誉为“高为炳方法”, 称其是“现代变结构控制理论的根本功绩”。

(2) 边界层法。Slotine 等^[5]在滑动模态控制的设计中引入了“边界层”的概念, 在边界层 $S_\Delta (S_\Delta = \{x; |s(x)| \leq \Delta\})$ 以外采用正常的变结构控制, 在边界层 S_Δ 内用饱和函数或 Sigmoid 连续函数来代替符号函数 sgns 。边界层厚度 Δ 越小, 控制效果越好, 但同时又会使控制增益变大, 抖振增强; 反之, 边界层厚度越大, 抖振越小, 但这又会失去变结构控制的优点。为了既能抑制抖振又能获得好的控制效果, 边界层厚度应自适应调整。

(3) 模糊控制法。利用模糊控制的柔化作用和模糊规则的适当设计可有效降低滑模控制的抖振。国内也有不少学者从事这方面的研究, 但模糊控制的设计尚缺乏系统性, 模糊规则及隶属函数完全凭经验进行; 另外, 若要提高精度则必然增加量化级数, 从而导致模糊规则和模糊推理复杂难以实时控制, 这对复杂系统的控制增加了难度。

与连续系统相比, 离散系统滑动模态到达问题和抖振抑制问题要更为复杂。1995 年, 高为炳先生给出了准滑动模态的严格定义, 指出了离散系统滑模到达条件应具有 6 个特点^[4,6], 并提出一个离散系统滑模指数趋近律:

$$s(k+1) = (1-qT)s(k) - \epsilon T \text{sgns}(k)$$

式中, $\epsilon > 0, q > 0, 1-qT > 0, T$ 是采样周期。这是目前应用最广泛的离散滑模到达条件, 适当选取趋近律中的 ϵ 和 q , 既可以减小抖振, 又可以保证系统的快速性。不过, 该趋近律无法保证系统运动最终趋于原点, 它有可能在原点附近形成一个极限环。2008 年, 文献[7]提出了一个新的离散滑模到达条件, 如图 1 所示, 这个条件的特点在于: 在 δ -带外, 状态 $x(k)$ 以指数速率单调趋于 δ -带, $x(k)$ 一旦进入 δ -带, 将步步穿越切换面, 且穿越振幅以指数衰减到零, 较好地解决了离散滑模抖振的削弱问题。




图 1

弱问题。

3. 目前存在的问题

国内外削弱抖振的方法很多, 但基本上都是对确定系统有效, 对不确定系统目前还没有找到抑制抖振的有效方法。

目前,不管是趋近律法、边界层法或是模糊控制方法,都是假设不确定性有界 $\|\omega\| \leq k$ 或满足线性有界条件 $\|\omega\| \leq \eta \|x\|$, 通过加大切换增益来抵消不确定性的影响,实现切换面的到达。例如,

$$\dot{s} = \eta(x) + \omega + u$$

式中, ω 是系统的不确定性。为了克服 ω 的影响,需按最坏的情况设计切换增益,取

$$u = -\eta(x) - ks - (\rho + \epsilon) \operatorname{sgn}s$$

式中, ρ 要大于 $|\omega|$ 的可能的最大值(当 ω 的界未知时, ρ 要取的很大)。代入上式得

$$\frac{d|s|}{dt} \leq -k|s| - (\rho + \epsilon) + \omega$$

特别, $\omega < 0$ 时, $\frac{d|s|}{dt} \leq -k|s| - (\rho + \epsilon + |\omega|)$, 这样,穿越切换面 $s=0$ 的速度就会很大,从而产生剧烈的抖振。

克服按最坏情况设计切换增益的消极对策是削弱抖振的关键。文献[8]提出了一个用动态补偿器补偿不确定项 ω 的方法,该动态补偿器的状态可以对不确定性渐近估计,然后用补偿器状态和估计的 $\hat{\omega}$ 设计控制器,解决了不确定系统抖振的削减问题。

参 考 文 献

- [1] Utkin V I. Variable structure systems with sliding modes. IEEE Trans. on Automat. Contr., 1977, 22(2).
- [2] Drazenovic B. The invariance conditions in variable structure systems. Automatic, 1969, 5: 287—295.
- [3] 郑锋,程勉,高为炳. 随机系统的变结构控制. 控制与决策, 1992, 7(1): 7—12.
- [4] 高为炳. 变结构控制的理论及设计方法. 北京: 科学出版社, 1998.
- [5] Slotine J J, Sastry S S. Tracking control of nonlinear systems using sliding surfaces with application to robot manipulator. International Journal of Control, 1983, 38(2): 465—492.
- [6] Gao W B, Wang Y F, Homaifa A. Discrete-time variable structure control systems. IEEE Transactions on Industrial Electronics, 1995, 42(2): 117—122.
- [7] 李文林. 多输入离散时滞系统的保性能变结构控制. 系统仿真学报, 2008, 20(18): 4932—4936.
- [8] Li W L, Chen X Q. Projective synchronization of chua's chaotic system with dead-zone in the control input. Commun. Nonlinear Sci. Numer. Simulat., 2009, 14: 3100—3107.

撰稿人: 李文林

河南师范大学数学与信息科学学院

区间系统的鲁棒严格正实综合

Robust Strictly Positive Real Synthesis for Interval Systems

传递函数的严格正实性(strictly positive realness, SPR)是系统的一种重要性能,在绝对稳定性与超稳定性理论、二次优化控制及自适应系统理论等领域中起着十分重要的作用。因实际系统中总存在有不确定性,研究系统的鲁棒严格正实性尤为有意义。20 世纪 90 年代以来,受鲁棒稳定性分析中参数化方法的刺激,系统鲁棒严格正实性的研究得到了广泛的关注和发展。

早期得到的多数结果是属于鲁棒严格正实分析的,系统鲁棒严格正实分析方面的最好结果是由文献[1]、[2]几乎同时独立得到的“八顶点检验定理”。

对鲁棒严格正实综合问题,通过正实引理,可以给出传递函数的基于矩阵不等式的正实性条件^[3],但用该方法进行鲁棒严格正实综合时,需引进较多的变元,得到的矩阵不等式的阶次较高,并且所得条件是用矩阵不等式的可解性来表述的,而这一点在理论上未有完整的结果。

首先给出相关的定义、记号及基本问题的描述。由于严格正实性源于控制理论的多个领域,不同的文献采用了稍有不同的定义^[3]。本文采用如下定义。

$\mathbf{R}$ 表示实数域,记 P^n 为 n 阶实系数多项式集合, $H^n \subset P^n$ 是 n 阶实系数 Hurwitz 稳定多项式(仅具负实部的根)集合。在下述定义中, $b(s) \in P^n$, $a(s) \in P^n$, $p(s) = b(s)/a(s)$ 是有理函数。

定义 1 $p(s)$ 称为是严格正实的,记为 $p(s) \in \text{SPR}$,是指 $b(s) \in P^n$, $a(s) \in H^n$ 且对 $\forall \omega \in \mathbf{R}$, $\text{Re}[p(j\omega)] > 0$ 。

定义 2 一个多项式集合 F 称为是鲁棒稳定的,是指集合 F 中的每一个元均是 Hurwitz 稳定多项式。

鲁棒严格正实综合问题的基本提法如下。

鲁棒严格正实综合基本问题 给定一个 n 阶多项式集 F ,是否存在、如何找出一个(固定的)多项式 $b(s)$,使对 $\forall a(s) \in F$ 有 $b(s)/a(s)$ 是严格正实的?

从严格正实性的定义容易知道,多项式集 F 的鲁棒稳定性是存在一个(固定的)多项式 $b(s)$,使对 $\forall a(s) \in F$, $b(s)/a(s)$ 严格正实的必要条件。另外,考虑如下问题。

鲁棒严格正实域刻画问题 给定 $a(s) \in H^n$,如何找出所有的 $b(s)$,使 $p(s) = \frac{b(s)}{a(s)} \in \text{SPR}$?

该问题对鲁棒严格正实的分析与综合是有意义的。特别, 给出 $b(s)$ 的基于 $a(s)$ 的系数的显式表达条件是文献[4]提出的一个问题。

传递函数严格正实性的判定, 本质上可以化为多项式实根的判定问题。古典 Sturm 组方法虽然也可用于判定多项式实根的分布, 但其对文字(符号)系数的多项式建立判别系统是没有效率的^[5]。

1996 年, 由杨路等建立的多项式完全判别系统可以给出一组由多项式系数构成的显式表达式来判定多项式根的状况^[5]。文献[6]借此给出了传递函数鲁棒严格正实域的描述, 从而理论上完整解决了上面的鲁棒严格正实域刻画问题。

对于鲁棒严格正实综合问题, 当所给定的多项式集合是稳定的多项式线段集、或稳定的区间多项式集、或稳定的凸多面体多项式集时, 由于这些集合在鲁棒稳定性理论中具有的特殊重要性及严格正实性本身的特点, 受到了研究者的充分重视。这方面已有结果总结如下。

当 F 的元具有相同的偶次(或奇次)项时, 这样的多项式 $b(s)$ 是存在的^[3,4,7], 这一结果最先由 Hollot 等^[7]于 1989 年针对区间多项式集而得到, 1990 年又被推广至更为一般的结果, 与文献[7]完全相同的结果于 1997 年又被 Patel 和 Datta 重新得到^[8]。

当 F 为低阶的 ($n \leq 3$) 稳定的区间多项式集时^[3,4,7], 这样的多项式 $b(s)$ 是存在的。应该提到的是, Anderson 等^[9]于 1990 年利用线性规划的方法, 给出了使上述问题存在解的一组条件[即文献[9]中的式(58)~式(60)], 并认为, 对任给的 4 次区间多项式集, 该组条件总是可以满足的, 因而认为, 上述问题对 4 次区间多项式集也就完全解决了。但是, 1993 年, Betser 和 Zeheb 举出反例说明, 文献[9]中给出的仅是一个充分性的条件。当时, 即使对于 4 次稳定的区间多项式集, 究竟是否存在一个多项式, 使其与该多项式集合配置成严格正实的有理函数族? 一方面, 理论上不能正面证明这一结论, 另一方面, 也从未发现有反例说明结论不成立, 因而成为鲁棒严格正实综合领域著名的公开问题^[3,4,7,9]。后来, 文献[10]利用针对稳定多项式线段鲁棒严格正实综合的技巧, 给出了 4 次区间稳定多项式集鲁棒严格正实综合正面肯定的答案。

上述结果表明, 任意阶多项式线段或低阶 ($n \leq 4$) 区间多项式的鲁棒稳定性, 是实现其鲁棒严格正实综合的充分必要条件, 换句话说, 鲁棒稳定性与鲁棒严格正实可综合性在某些情况下是等价的, 这是具有深刻科学内涵的结论。

上述所有这些结果均是针对连续时间系统而言的, 这些结果可以直接推广到离散时间系统、甚至 D-SPR 的情形^[3]。

此外, 一些存在结果表明多项式线段和区间多项式鲁棒严格正实综合与凸多面体多项式集的鲁棒严格正实综合具有内在的本质不同。因此, 对高阶区间

多项式集的鲁棒严格正实综合就尤为重要。如下区间系统的鲁棒严格正实综合问题仍是理论上尚未解决的具有挑战性的公开问题^[3,4,7,9]。

区间系统的鲁棒严格正实综合问题 对于阶次大于 4 的稳定的区间多项式集, 究竟是否存在一个多项式, 使其与该多项式集合配置成严格正实的有理函数族? 或者大于 4 阶的区间多项式集的鲁棒稳定性是否也是其可鲁棒严格正实综合的充分必要条件?

从计算的大量数值例子来看, 给定稳定的区间多项式集, 这样的多项式都可以找到, 尚未发现反例, 因此, 我们推测该问题可能会有正面肯定的答案。

参 考 文 献

- [1] Chapellat H, Dahleh M, Bhattacharyya S P. On robust nonlinear stability of interval control systems. *IEEE Trans. on Automat. Contr.*, 1991, AC-36: 59—69.
- [2] 王龙, 黄琳. 区间有理函数严格正实性的有限检验. *科学通报*, 1991, 36: 262—264.
- [3] 郁文生. 系统鲁棒严格正实综合与鲁棒稳定性分析[博士学位论文]. 北京: 北京大学, 1998.
- [4] Huang L, Hollot C V, Xu Z L. Robust analysis of strictly positive real function set. *Preprints of Proceedings of the Second Japan-China Joint Symposium on Systems Control Theory and its Applications*, 1990: 210—220.
- [5] 杨路, 张景中, 侯晓荣. 非线性代数方程组与机器证明(非线性科学丛书). 上海: 上海科学教育出版社, 1996.
- [6] Wang L, Yu W S. Complete characterization of strictly positive real regions and robust strictly positive real synthesis method. *Science in China Series E: Technological Sciences*, 2000, 43: 97—112.
- [7] Hollot C V, Huang L, Xu Z L. Designing strictly positive real transfer function families: A necessary and sufficient condition for low degree and structured families // *Proceedings of Mathematical Theory of Network and Systems*, Boston, 1989: 215—227.
- [8] Patel V V, Datta K B. Classification of units in H_∞ and an alternative proof of Kharitonov's theorem. *IEEE Trans. on Circuits Syst.*; Part I, 1997, CAS-44: 454—458.
- [9] Anderson B D O, Dasgupta S, Khargonekar P, et al. Robust strict positive realness: Characterization and construction. *IEEE Trans. on Circuits Syst.*, 1990, CAS-37: 869—876.
- [10] Yu W S, Wang L. Anderson's claim on fourth-order SPR synthesis is true. *IEEE Trans. on Circuits Syst.*; Part I, 2001, CAS-48: 506—509.

撰稿人: 郁文生¹ 王 龙²

1 华东师范大学软件学院

2 北京大学工学院

不精确量测下非完整系统控制问题

Control of Nonholonomic Systems with Measurement Uncertainty

关于非完整约束问题的研究可以追溯到 170 年前的经典力学中。随着自主控制的快速发展和对系统性能要求的提高,迫切需要在系统中考虑这种非完整约束下的控制问题(如轮式移动机器人、空间机器人、水下机器人、关节机器人等),这类控制问题理论上的挑战来自于 1983 年 Brockett^[1]的一篇论文,在这篇文章中,他证明了这类系统不能用光滑的纯状态反馈使其镇定,这种区别于传统反馈控制方式(如 PID 控制、光滑纯状态反馈控制等)的结论在当时引起了控制理论界的极大兴趣,取得了许多有价值的研究成果^[2,3]。然而,当这种理论应用于实际时,目标和输出或状态需要量测,而量测就会产生测不准的问题,如何从控制的角度考虑这类系统在测不准情形下的控制问题是非常有意义的^[4]。

非完整控制系统经历了二十多年理论快速的发展之后,初步尝试将这种理论应用到实际中去的时候,发现基于那些常见的模型,或者理论研究的结果要求满足的条件常常是不满足的。例如,在文献[5]中,讨论了如下系统的自适应镇定问题:

$$\begin{cases} \dot{x}_1 = u + \phi^T(x_1)\theta \\ \dot{x}_i = u x_{i+1} + \phi_i^T(u, x_1, \bar{x}_i)\theta, 2 \leq i \leq n, n \geq 2 \\ \dot{x}_n = u + \phi_n^T(u, x_1, x) \theta \end{cases} \quad (1)$$

式中, $[x_1, x^T]^T \triangleq [x_1, x_2, \dots, x_n]^T \in \mathbf{R}^T$ 是系统状态; $\bar{x}_i \triangleq [x_2, \dots, x_i]^T \in \mathbf{R}^{i+1}$; u 和 w 是系统控制输入; $\phi(x_1) \in \mathbf{R}^l$ 和 $\phi_i(u, x_1, \bar{x}_i) \in \mathbf{R}^l (1 \leq i \leq n)$ 是关于 x_1 、 u 和 $\bar{x}_i$ 的光滑未知非线性函数向量; $\theta \in \mathbf{R}^l$ 是未知有界常值参数向量。在 $\phi_i(u, x_1, \bar{x}_i)$ 满足某种关于 x_i 的线性关系的前提下讨论了系统(1)的状态反馈和输出反馈的自适应镇定问题。实际上,系统(1)本身满足所谓的三角结构。文献[4]尽管讨论的模型有差异,问题或许不同,但结论几乎无一例外要求满足这种类似的三角形结构,而且 $\phi(u, x_1, \bar{x}_i)$ 与第二个输入 w 无关。

视觉传感器对于非结构环境下目标及其状态的检测直观方便且有效,但视觉信息的使用需要对视觉系统的内外参数进行校调,而校调需要大量的时间而且在某种情形下是不可能的^[6]。因此,考虑不校准视觉参数意义下的控制问题十分重要。考虑单目固定视觉下某种非完整移动机器人的模型^[7]

$$\begin{pmatrix} \dot{x}_m \\ \dot{y}_m \\ \dot{\theta} \end{pmatrix} = \begin{pmatrix} v\alpha \cos(\theta - \theta_0) \\ v\alpha \sin(\theta - \theta_0) \\ \omega \end{pmatrix} \quad (2)$$

式中, (x_m, y_m) 表示图像坐标; θ 为机器人行进方向与 X 轴方向的夹角; α 、 α 为正的常值, 且依赖于特征点的深度、焦距及沿 u 和 v 轴方向上的像素比例因子; θ_0 为角度常数。容易证明, 系统(2)仍然是非完整控制系统。 v 、 ω 分别为机器人车体行进方向上的速度和绕质心转动的角速度。

与通常的非完整机器人的镇定模型不同的是, 这里增加了三个参数 α 、 α 和 θ_0 。如果这三个参数都是已知的, 那么, 它的镇定问题与通常的非完整系统的镇定和跟踪问题一样, 有许多解法(见参考文献[8])。然而, 当 α 、 α 和 θ_0 未知时, 也可以用一些状态变换和输入变换化为类似的标准型, 即

$$\begin{pmatrix} \dot{x}_1 \\ \dot{x}_2 \\ \dot{x}_3 \end{pmatrix} = \begin{pmatrix} u \\ u x_3 + u_2 (\alpha \cos x_1 \cos(x_1 - \theta_0) + \alpha \sin x_1 \sin(x_1 - \theta_0)) \\ -u x_2 + u_2 (-\alpha \sin x_1 \cos(x_1 - \theta_0) + \alpha \cos x_1 \sin(x_1 - \theta_0)) \end{pmatrix} \quad (3)$$

这里, (x_1, x_2, x_3) 和 (u, u_2) 分别表示新的状态和控制输入, 它与通常的非完整链式系统有很大的区别, 如第二个方程中第二项含有 u_2 。实际上, 其他对象中也存在着不满足三角形结构的情形。综合其他非完整问题, 一般说来, 比较切合实际的是从理论上考虑如下的非完整运动学系统

$$\begin{cases} \dot{x}_1 = d_1(t)u + \phi^T(x_1, \beta) \\ \dot{x}_i = d_i(t)u_{i+1} + \phi^T(u, u, x_1, x_2, \dots, x_n, \beta), 2 \leq i < n, n \geq 2 \\ \dot{x}_n = d_n(t)u + \phi_n^T(u, u, x_1, x_2, \dots, x_n, \beta) \end{cases} \quad (4)$$

$$y = [x_1, x_2]^T \quad (5)$$

的状态或输出反馈的镇定或跟踪问题, 条件是 $d_i(t) (i=1, \dots, n)$ 为有正的常值上下界的不确定时变参数, 系统不满足三角形结构, $\beta = [\beta_1, \beta_2, \dots, \beta_m]$ 为未知常值参数。

系统(4)和(5)镇定的困难在于 u 和 u_2 的耦合及 $\phi(u, u_2, x_1, x_2, \dots, x_n)$ 的非三角形结构。尽管这种形式看起来较为复杂, 但由于其未知参数具有明确的物理意义, 可以根据实际系统类的不同情况做出适当的假设, 如 α 、 α 有正的上下界, θ_0 可以假定在某一个象限或者某一个不太小的范围内等, 而且依据具体情形的某种特殊结构, 这些特殊结构有助于控制器的设计。目前, 只是就一些特殊情形得到了解决方案^[7], 一般情形下的求解还是个开问题。

这是将理论应用于实际的过程中产生的新的理论问题, 对它们的研究不仅可以推动非线性控制理论的发展, 而且也可以更好地为平面运动载体、空间和水下运动载体的控制提供更好的指导。

参 考 文 献

- [1] Brockett R W .Asymptotic stability and feedback stabilization //Brockett R W ,Milman R S ,
Sussmann H J .Differential Geometric Control Theory .Boston ;Birfiauuser ,1983 ;181—191 .
- [2] Kolmanovsky I ,McClamroch N H .Developments in nonholonomic control problems .IEEE
Control Systems Magazine ,1995 ,(6) ;21—36 .
- [3] Oriolo G .An iterative learning controller for nonholonomic mobile robots .International
Journal of Robotics Research ,1998 ,17(9) ;954—970 .
- [4] Jiang Z P .Robust exponential regulation of nonholonomic systems with uncertainties .Auto-
matica ,2000 ,36(2) ;189—209 .
- [5] Ge S S ,Wang Z P ,Lee T H .Adaptive stabilization of uncertain nonholonomic systems by
state and output feedback .Automatica ,2003 ,39 ;1451—1460 .
- [6] Wang H S ,Liu Y H ,Zhou D X .Dynamic visual tracking for manipulators using an uncali-
brated fixed camera .IEEE Transactions on Robotics ,2007 ,23(3) ;610—617 .
- [7] Wang C L ,Mei Y C ,Liang Z Y ,et al .Dynamic feedback tracking control of non-holonomic
mobile robots with unknown camera parameters .Transactions of the Institute of Measure-
ment and Control ,2010 ,32(2) ;155—169 .
- [8] Sordalen O J ,Egeland O .Exponential stabilization of nonholonomic chained systems .IEEE
Trans .on Automat .Contr .,1995 ,40(1) ;35—49 .

撰稿人：王朝立

上海理工大学光电信息与计算机工程学院

线性时变系统的渐近稳定性

The Asymptotic Stability of Linear Time-varying System

众所周知,稳定性是一个控制系统能够正常工作的必要条件。线性定常系统的稳定性早已得到了彻底的解决。然而,“定常系统”毕竟是一种理想状态,绝对的“定常”是不存在的。在实际生产与控制过程中,由于工作条件的变化、元器件的老化、运行时间的推移、正常磨损等不同原因,许多被控对象的参数都会以某种可预测或不可预测的方式发生着变化。另一方面,由于许多系统的工作过程中涉及许多参数的大范围变化,如导弹和飞机等随着飞行高度和速度的变化等,都带来了系统的时变特性。时变系统是普遍存在的。然而,关于时变系统,即使是时变线性系统的稳定性问题,至今还远没有解决。

1. 问题描述

考虑线性时变系统

$$\dot{\mathbf{x}}(t) = \mathbf{A}(t)\mathbf{x}(t)$$

式中, $\mathbf{x}(t) \in \mathbf{R}^n$; 系统矩阵 $\mathbf{A}(t) \in \mathbf{R}^{n \times n}$ 。该系统的渐近稳定性问题,即是分析在什么条件下,对于 $\forall \mathbf{x}(0) \in \mathbf{R}^n$, 当 $t \rightarrow \infty$ 时,该系统的解收敛到原点,即 $\mathbf{x}(t) \rightarrow 0$?

尽管上述问题的描述很简单,但问题本身却是很难的。目前给出的充要条件,如基于状态转移矩阵的充要条件,大多只具有理论意义,不便于应用^[1]。现有的一些方便应用的研究成果大都是针对某些特殊的线性时变系统给出判定系统渐近稳定的充分条件。

2. 线性时变系统稳定性的特殊性

众所周知,当 $\mathbf{A}(t) = \mathbf{A}$ 为定常时,只要系统的特征值,即矩阵 $\mathbf{A}$ 的特征值均具有负实部,则该系统便是稳定的。但是,对于时变的情形,下述事实说明问题远非如此简单。

事实 1: 矩阵

$$\mathbf{A}(t) = \begin{bmatrix} 1 - 4\cos^2 2t & 2 + 2\sin 4t \\ -2 + 2\sin 4t & 1 - 4\sin^2 2t \end{bmatrix}$$

具有两个相同的定常特征值: -1 , 但该矩阵所对应的系统却是不稳定的^[1]。

事实 2: 矩阵

$$\mathbf{A}(t) = \begin{bmatrix} -2+4\cos t & \cos t \\ \sin t & -2+4\cos t \end{bmatrix}$$

的两个特征值实部之和为

$$\operatorname{Re} \lambda_1 + \operatorname{Re} \lambda_2 = -4 + 8 \cos t$$

因而, 该矩阵的特征值会经常跑到复平面的右半平面, 但该矩阵所对应的系统却是稳定的。

事实 3: 矩阵

$$\mathbf{A}_1(t) = \operatorname{diag}\{-1+2\cos t, -1-2\cos t\}$$

和

$$\mathbf{A}_2(t) = \operatorname{diag}\{-1+\max(2\cos t, -2\cos t), -1-\max(2\cos t, -2\cos t)\}$$

在任意时刻 t 均具有相同的特征值集合 $\Gamma = \{-1 \pm 2\cos t\}$, 但系统 $\dot{\mathbf{x}}(t) = \mathbf{A}_1(t)\mathbf{x}(t)$ 是一致渐近稳定的, 系统 $\dot{\mathbf{x}}(t) = \mathbf{A}_2(t)\mathbf{x}(t)$ 却是不稳定的。

上述这些事实说明, 时变线性系统的稳定性不仅仅依赖于系统特征值的变化, 而且还依赖于相应的特征向量。

3. 现有结果

设 $\phi(t, t_0, \mathbf{x}_0)$ 为微分方程 $\dot{\mathbf{x}}(t) = \mathbf{A}(t)\mathbf{x}(t)$ 在初始条件 $\mathbf{x}_0$ 、 t_0 下的解, Wazewski 给出如下结果:

$$\|\phi(t, t_0, \mathbf{x}_0)\| \leq \|\mathbf{x}_0\| e^{r(t, t_0)}$$

式中,

$$r(t, t_0) = \frac{1}{2} \int_{t_0}^t \lambda_{\max}(\sigma) d\sigma$$

这里, $\lambda_{\max}(\sigma)$ 是矩阵 $\mathbf{A}(\sigma) + \mathbf{A}^T(\sigma)$ 的最大特征值。由此得出系统稳定的一个充分条件是^[2]

$$r(t, t_0) = \frac{1}{2} \int_{t_0}^t \lambda_{\max}(\sigma) d\sigma < 0$$

前述系统矩阵为 $\mathbf{A}_1(t)$ 的时变系统是稳定的, 但显然它不满足 Wazewski 给出的充分条件。关于这方面的研究, 人们一方面致力于给出保守性较小的稳定性判据, 另一方面, 着眼于对于某些特殊时变系统的研究。

一个快时变系统

$$\dot{\mathbf{x}}(t) = \mathbf{A}(\alpha t)\mathbf{x}(t)$$

式中, α 足够大。此外, $\mathbf{A}(t)$ 及它的一阶、二阶导数都是连续和有界的。当系统矩阵 $\mathbf{A}(t)$ 是以 T 为周期的周期函数时, 该系统的平均系统矩阵定义为

$$\bar{\mathbf{A}} = \frac{1}{T} \int_0^T \mathbf{A}(t) dt$$

如果这个系统的平均系统

$$\dot{\bar{\mathbf{x}}}(t) = \bar{\mathbf{A}} \bar{\mathbf{x}}(t)$$

是指数稳定的, 则此系统也是稳定的^[2~4]。

对于充分大的 α , 考虑如下以 T 为周期的慢时变周期系统:

$$\dot{\mathbf{x}}(t) = \mathbf{A}\left(\frac{t}{\alpha}\right) \mathbf{x}(t)$$

其指数稳定的充分条件是具有最大实部的瞬时特征值 $\lambda_{\max}(t)$ 的平均值小于零, 即

$$\frac{1}{T} \int_0^T \lambda_{\max}(t) dt < 0$$

除上述周期系统外, 文献[5]~[7]还考虑了下述一类特殊的系统:

$$\dot{\mathbf{x}}(t) = -f(t) \mathbf{m}(t) \mathbf{m}^T(t) \mathbf{x}(t)$$

式中, $\mathbf{m}: \mathbf{R} \rightarrow \mathbf{R}^n$ 且 $f: \mathbf{R} \rightarrow \mathbf{R}$, 并建立了系统稳定的充分条件。

参 考 文 献

- [1] 段广仁. 线性系统理论. 第2版. 哈尔滨: 哈尔滨工业大学出版社, 2004.
- [2] Levin A Y. Absolute nonoscillatory stability and related questions. St. Petersburg Math. J., 1993, 4(1): 149—161.
- [3] Brockett R W. Finite Dimensional Linear Systems. New York: Wiley, 1970: 206—207.
- [4] Willems J L. Stability Theory of Dynamical Systems. New York: Nelson, 1970: 117—119.
- [5] Aeyels D, Peuteman J. On exponential stability of non-linear time-variant differential equations. Automatica, 1999, 35: 1091—1100.
- [6] Aeyels D, Peuteman J. New asymptotic stability criterion for non-linear time-variant differential equations. IEEE Trans. on Automat. Contr., 1998, 43: 968—971.
- [7] Solo V. On the stability of slowly time-varying linear systems. Mathematics of Control, Signals and Systems, 1994, 7: 331—350.

撰稿人: 张 龙 谭 峰 段广仁
哈尔滨工业大学航天学院

流体中机器人运动载体对环境力载荷的抗干扰

Adaptive Stabilized Control of Mobile Robot in Disturbance Environment

1. 背景介绍

包括飞行机器人(小型无人机)和 underwater 机器人(潜水器)在内的机器人运动载体在流体中作业时,要求保持姿态、位置和运动状态的相对稳定,以便快速高效地完成有关测量、监测、监视和机械手动动作等作业。飞行机器人滞空悬停时,会遇到时变气流或风场对其姿态的扰动,在浅水域工作的水下机器人与深水域相比,会受到更复杂的浪涌干扰,出现更严重的横荡、垂荡、横摇、纵摇、位置漂移和定深定向偏差等问题。解决流体中机器人运动载体对环境力载荷的抗干扰控制问题是移动机器人面对的共性问题之一。

2. 研究现状

机器人运动载体抗流体扰动的核心问题是如何施加控制力来抵消各种不确定外扰作用的影响。在众多的抗扰动控制理论中,主要有三种原理:第一种是苏联学者在 20 世纪 40 年代提出的绝对不变性原理,其核心思想是:想克服外扰动影响,就要测量外扰动,控制器同时含有反馈稳定和抑制外扰动两通道;第二种是加拿大学者在 20 世纪 70 年代提出的内模原理,其核心思想是:想克服外扰动影响,就要建立外扰动模型,抗扰动控制器要包含这个外扰动模型;第三种是由我国学者韩京清于 20 世纪末提出的,其核心思想是:把作用于被控对象的所有不确定因素作用都归结为未知扰动,用对象的输入输出数据对它进行估计并给予补偿,本质上不需要直接测量外扰动作用和外扰动规律^[1]。

以上三种方法大多用于流体对载体的小扰动,而气流和水流对机器人运动载体的扰动属于大扰动,特别是波浪、涌流对水下机器人产生的扰动更为复杂。强耦合和高度非线性的动力学特点使准确建模十分困难,环境力载荷的大扰动严重影响水下机器人的控制性能。国内外进行了很多抗涌流研究,典型的有: Riedel^[2]采用滑模变结构控制方法对 AUV 在浅水域运行中的姿态控制进行了控制仿真,文献[3]、[4]采用非线性反馈控制对 AUV 在浅水域中运行的跟踪控制和姿态保持控制进行了仿真研究, Haghi^[5]采用自适应反馈控制对 AUV 在海流干扰下的位置和姿态控制的仿真研究, Zanolli 和 Conte^[6]采用 PID 模糊控制对水下机器人在干扰情况下的定深和姿态控制进行了仿真研究,国内研究的方法大

多属于变结构控制^[7]、改进 PID 控制^[8]和鲁棒控制^[9,10]方面的。

3. 问题描述

机器人运动载体对环境力载荷扰动主动适应控制的关键科学问题是如何有效感知和预测真实的环境参数。由于复杂流场的空气动力学、水动力学难以准确分析、计算复杂及扰动无规律性导致的无法准确建立扰动过程噪声和观测噪声的统计模型等原因,环境力载荷扰动参数的计算和预测成为制约机器人抗扰动控制的难点。如何建立包含环境力载荷扰动、机器人本体能力、动态动力学在内的实时模型是机器人抗扰动理论研究的一个科学问题,这个科学问题包括扰动信息的描述问题、基于扰动信息的动态优化融合与估计问题、扰动信息与状态的联合估计问题。

空气中和水下环境参数属于自然环境参数,采用分形原理可以逼真地实现自然环境的拟合。分形的基本特征是具有标度不变性。分形提供了描述自然形态的几何学方法,可以从少量数据出发,对复杂的自然景物进行逼真的模拟,也就是说,采用分形原理,可以在少量、部分传感数据的基础上,通过分形迭代迅速预测整体环境参数,为机器人运动载体对环境的主动适应提供超前控制参考量,然后配合机器人运动载体自身的被动误差补偿控制机制,有可能会为环境力载荷扰动的抗干扰的实现提供一种新的途径。

另外,从自然界中的鱼类的抗涌流和鸟类的抗风控制机理中寻找机器人运动载体对环境干扰的仿生稳定控制,有可能是一种有效的途径。

参 考 文 献

- [1] 韩京清.自抗扰控制技术.前沿科学,2007,1(1):24—31.
- [2] Riedel J S, Healey A J. Shallow water station keeping of AUVs using multi-sensor fusion for wave disturbance prediction and compensation. Oceans Conference Record (IEEE), 1998, 2: 1064—1068.
- [3] Liu S Y, Wang D W, Poh E K. Nonlinear adaptive observer design for tracking control of AUVs in wave disturbance condition. OCEANS 2006, 2007: 1—8.
- [4] Liu S Y, Wang D W, Poh E K, et al. Nonlinear output feedback controller design for tracking control of ODIN in wave disturbance condition. Proceedings of MTS/IEEE OCEANS, 2005, 17—23: 1803—1810.
- [5] Haghi P, Naraghi M, Vanini S A S. Adaptive position and attitude tracking of an AUV in the presence of ocean current disturbances. 16th IEEE International Conference on Control Applications Part of IEEE Multi-conference on Systems and Control, 2007, 1: 741—746.
- [6] Zanolli S M, Conte G. Remotely operated vehicle depth control. Control Engineering Practice,

2003,11:453—459.

- [7] 朱计华.水下机器人近水面运动的变结构控制技术研究[硕士学位论文].哈尔滨:哈尔滨工程大学,2007.
- [8] 王智学,边信黔,王奎民,等.近壁面水动力干扰下的 AUV 运动控制研究.船舶工程,2006,28(5):63—66.
- [9] 华克强,王秀娟.水下机器人姿态保性能鲁棒控制物理仿真研究.船海工程,2009,38(3):32—35.
- [10] 华克强,赵世伟.水下机器人姿态角 LQR-鲁棒方差控制实验研究.舰船科学技术,2009,31(2):49—70.

撰稿人: 龚振邦 罗 均
上海大学精密机械研究所

机器人的仿生自主供能

Bio-inspired Energy Autonomy for Robot

1. 背景介绍

动物和植物经过 45 亿年优胜劣汰、适者生存的进化,使它们能适应环境的变化,从而得到生存和发展,其结构与功能已达到近乎完美的程度。自古以来,自然界就是人类各种技术思想、工程原理及重大发明的源泉。1960 年,美国科学家 Steel 经过长期的观察研究,创立了仿生学。生物体的精巧结构、运动原理、组成材料、群居智能和行为方式等已经成各领域学者有意模仿的对象^[1,2]。生物凭借其独特的本领在各种恶劣环境中生存繁衍,科学家们向生物学习,创造出了众多高性能的仿生机器人,仿生学在机器人学中的应用推动了机器人环境适应能力的发展。仿生机器人是近年来迅速崛起和飞速发展的研究领域,而且已成为机械、信息、材料、生命、力学、物理等学科交叉研究的前沿热点之一。

2. 问题描述

随着机器人的不断应用,需要越来越多的能工作在野外、极地、海底的自主远程作业机器人,这些机器人都面临着一个共同的问题,就是难以匹配合适的能源动力。传统的充电供能方式中,蓄电池体积重量大、功率密度低、电池容量有限、充电时间长、使用寿命短等缺点极大地限制了自主机器人和远程遥控操作机器人的应用。近年来,燃料电池由于其工作温度低、功率密度较高引起关注,但对燃料电池驱动的自主机器人系统来说,不仅要求对燃料电池及辅助动力单元(氢气、空气流量等)进行控制,还需要对电机传动系统、机器人本体、故障诊断(安全性)等进行控制;由于控制参数的增加,使整个系统变得更加复杂。此外,科研人员不断探索无线供能方式,但也存在传输距离短和效率低的缺点。自主供能是机器人研究的难点之一。

地球上,能量的来源分为三类:①来自地球外部天体的能源(主要是太阳能),除直接辐射外,并为风能、水能、生物能和矿物能源等的产生提供基础;②地球本身蕴藏的能量,如原子核能、地热能等;③地球和其他天体相互作用而产生的能量,如潮汐能^[3]。其中,生物质能最为广泛。生物质是太阳能最主要的吸收器和储存器。生物质能的载体是有机物,所以,这种能源是以实物的形式存在的,而且它分布最广,不受天气和自然条件的限制,只要有生命的地

方即有生物质存在。太阳能照射到地球后,一部分转化为热能;一部分被植物吸收,转化为生物质能。由于转化为热能的太阳能能量密度很低,不容易收集,只有少量能被人类所利用,其他大部分存于大气和地球中的其他物质中;生物质通过光合作用,能够把太阳能富集起来,储存在有机物中。这些能量可以是远程自主机器人所需能源的源泉和基础。

此外,自然界的生物具有几乎完美的能量密度和功率密度。生物的能量转换效率最高达100%,肌肉把化学能转变为机械能的效率也接近50%,这远远超过目前各种机器人系统^[4,5]。因此,要缩短能量转换过程,提高能量转换效率,建立易于维护的代谢系统,就必须重新回到生物原型,研究模仿生物电器官、生物发光、肌肉直接把化学能转换成机械能的能量转换过程^[6,7]。

对于远程作业的机器人系统,仿生自主供能非常重要,以下三个方面尚待进行深入思考:一是如何模仿生物直接高效获取太阳能(包括光能和热能);二是如何像生物一样具有从环境获取自然界生物质能源的能力;三是如何像生物一样具有高效的能量转换效率。

参 考 文 献

- [1] Dickinson M H, Farley C T, Full R J, et al. How animals move: An integrative view. *Science*, 2000, 288(5463): 100—106.
- [2] Gray J. *How Animals Move*. Cambridge: Cambridge University Press, 1953.
- [3] Mustafa B, Gunhan A. Biomass energy in the world, use of biomass and potential trends. *Energy Sources, Part A: Recovery, Utilization and Environmental Effects*, 2005, 27(10): 931—940.
- [4] Ieropoulos I, Greenman J, Melhuish C. Imitating metabolism: Energy autonomy in biologically inspired robots // *Proceedings of the Second International Symposium on Imitation in Animals and Artifacts*, Aberystwyth, 2003: 1941—1944.
- [5] Mei Y, Lu Y H, Hu Y C, et al. Deployment strategy for mobile robots with energy and timing constraints // *Proc. of the IEEE International Conference on Robotics and Automation*, Barcelona, 2005: 2816—2821.
- [6] Ieropoulos I, Greenman J, Melhuish C. Artificial metabolism: Towards true energetic autonomy in artificial life. *ECAL 2003*, 2003: 792—799.
- [7] Ngo T D, Raposo H, Schioler H. Multiagent robotics: Toward energy autonomy. *Artificial Life and Robotics*, 2008, 12(1—2): 47—52.

撰稿人: 王越超 刘金国
中国科学院沈阳自动化研究所

服务机器人的认知与情感

Cognition and Emotion of Service Robots

1. 为什么要让机器人具备认知能力与情感能力?

日本、西欧等发达国家和地区因人口负增长及老龄人口的不断增多,面临劳动力不足与老年人缺乏照顾的问题,对于服务机器人的需求越来越迫切。而随着技术水平的不断提高和硬件成本的不断降低,服务机器人距离普通大众的生活也的确越来越近。Microsoft 前总裁比尔盖茨预言未来服务机器人将像 PC 一样进入千家万户^[1]。

服务机器人不知疲倦、任劳任怨,是人类理想的仆人和助手。随着服务机器人和人类的关系越来越亲近,人类不仅希望机器人能完成任务,还希望机器人能更加聪明,如会思考 and 智能识别^[2]、能和人进行基于情感的交互等^[3,4]。人是通过语言、表情和手势来进行交流,习惯用语音或手势安排任务或发出命令。但是,现在的机器人多数都是程序化、冷冰冰的金属机构,自主学习与认知环境的能力缺乏或非常有限。当前的机器人通过学习只能识别有限的语音命令和手势,尚不能像人一样识别语音或手势命令。此外,人都是有情感的,机器人如果不能及时地理解人的表情或情感变化,有时候会做出不合时宜的事情^[5]。与缺乏情感能力的机器人接触,也不能真正慰藉老年人的情感需要。能自主地认知环境、学习知识、识别人的语音、表情和手势,根据人的情感需要决定自己的行为,这是服务机器人能与人形成和谐融洽关系的必要条件。

2. 怎样让机器人具备认知能力与情感能力?

为了提升服务机器人的认知能力,给服务机器人加入人工情感,科学家和工程师付出了不懈的努力,并取得一些初步的成果。

在视觉认知方面,20 世纪 60 年代,Roberts 利用视觉让机器人识别周边的积木,开始了机器人认知环境能力的研究。70 年代末,麻省理工学院的 Marr 提出了计算机视觉的 Marr 框架理论,促进了计算机视觉技术的研究^[6]。80 年代中期,又发展出主动视觉理论、选择性注意视觉理论等新的理论和方法。目前的计算机视觉在视觉定位、运动分析、目标识别等方面已经取得显著的成效,并已广泛应用于机器人的自主导航、伺服控制及生物特征检测识别(如人脸识别、指纹识别、虹膜识别等)等领域;但计算机视觉在自然环境识别、性别识别、表

情识别等方面及识别后的理解方面距离人类期望的水平仍有相当大的差距。

在语音理解方面,也存在同样的问题。目前,许多研究单位都研制出可以与人类对话的机器人,如卡内基梅隆大学研制的机器人接待员 Valerie、中国科学技术大学研制的机器人“可佳”,都具有通过语音对话的能力。东京理科大学开发的机器人接待员可以理解 300 多个单词,能有 700 多种回答。但是,机器人词汇和回答方式有限,与人类用自然的语言交流相比仍有很大差距。除此之外,人类的语言交流中包含着丰富的情感,能体现出说话人的情绪,但机器人还缺乏在对话中对情感进行理解和对情绪进行识别的能力。日本已经开展相关的研究,如人类机器人财团新开发的情感机器人名叫“小 IF”,语言表达能力和 5 岁的小孩差不多,这个机器人非常敏感,可从对方的声音中发现感情的微妙变化^[5]。

服务机器人的情感能力可以分为情感的判别与表达。情感的判别是通过人的表情、语音、或手势等来识别人的情绪及其变化,也可以说属于机器人认知的范畴。在情感表达方面,科学家已研制出各种表达情绪的机器人。东京电子通信大学的研究人员开发出了一种能表达简单情感的机器狗,这种机器狗的前肢、耳朵和嘴巴都可以用来表达情感,如高兴、愤怒和吃惊等,总共可以表达出 8 种不同的感情。Sony 公司的电子宠物狗 AIBO 能感知主人的行为,从而利用面部表情、语调和身体姿态模拟出宠物的行为等。“小 IF”机器人不仅可从对方的声音中发现感情的微妙变化,还能通过自己表情的变化在对话时表达喜怒哀乐。

但是,目前机器人对人的情感的判别及产生相应行为的过程还是很简单的。行为与情感是个复杂的相互作用过程,如何根据人类的情(感)绪来决定自己的行为、自己什么样的行为能改变人的情绪,这对于服务机器人也仍然是个难题。针对此,美国麻省理工学院实验室的 Picard 教授提出情感计算(affective computing)的概念,研究“来源于情感或能够对情感施加影响的计算”^[7]。情感计算隶属于人工情感(artificial emotion),人工情感是使机器能够产生类人情感并与人类自然和谐地进行人机交互的研究领域^[8]。中国北京科技大学的王志良教授则进一步提出人工心理(artificial psychology)的概念,从心理学广义层次上研究情感、情绪与认知、动机与情绪的人工机器实现问题^[9~11]。

最近,英国启动了一项耗资 230 万欧元的研究机器人情感的大型跨国科研项目,来自欧洲 6 个国家的 25 位机器人专家、发展心理学家和神经学专家参与了该项目,这项研究主要是制造可以用适当方式同人进行社会和感情交流的机器人,研究人员将制造一系列可以在和人的互动交流过程中接收感官信号,并能根据人的反应调节自己行为的机器人。

3. 机器人具备认知能力与情感能力的后果会是什么?

尽管在服务机器人的认知与情感方面,科学家已经做了很多工作,但仍然是很初步的。当前的机器人在知识存储、记忆检索、逻辑推理、数字计算等方面的能力已远远超过人类,但在真正的抽象思维、感性认识、认知与学习、情感理解与表达方面仍远逊于人类。例如,尽管深蓝可以战胜世界国际象棋冠军卡斯帕洛夫,但它的学习和认知能力仍不及一个三岁的婴儿。

当前,许多科学家认为服务机器人认知与情感能力有限,与目前电脑的计算水平和存储水平有限相关,但真正的问题其实是人类对认知学习与情感情绪的机理和模型仍不清楚,而人类自身认知学习与情感情绪的机理和模型仍是一个谜^[12]。

除此之外,假使将来某一天机器人真的能具备和人一样的认知学习与情感能力,机器人将会具备独立的思维和意识能力,那人和机器人如何相处?是否会引发新的社会伦理问题^[13,14],机器人是否还能遵循阿西莫夫的机器人三定律?机器人是否隶属于人类?当机器人与人类发生冲突时,人类还能否控制机器人?

如何在遵循阿西莫夫机器人三定律前提下,提高服务机器人的认知能力与情感能力,使之能更好地服务于人类并与人和谐相处,这是未来人类发展服务机器人需要思考的问题。

参 考 文 献

- [1] Gates B. A robot in every home. *Scientific American*, 2006.
- [2] Turing A M. Computing machinery and intelligence. *Mind*, 1950, (59): 433—460.
- [3] Sloman A, Croucher M. Why robots will have emotion. *Proceedings IJCAI*, 1981.
- [4] Itoh C, Kato S, Itoh H. Mood-transition-based emotion generation model for the robot's personality // *Proceedings of the 2009 IEEE International Conference on Systems, Man, and Cybernetics*, San Antonio, 2009: 2878—2883.
- [5] 晓阳. 真的能赋予机器人情感吗. *科学 24 小时*, 2009, (11): 10—12.
- [6] Marr D. 视觉计算理论. 姚国正, 等译. 北京: 科学出版社, 1988.
- [7] Picard R W. *Affective Computing*. Cambridge: MIT Press, 1997.
- [8] Tu X Y. Artificial emotion // 10th Annual CAAI, Guangzhou, 2000.
- [9] Wang Z L, Xie L. Artificial psychology—An attainable scientific research on the human brain // *IPMM '99*, Honolulu, 1999.
- [10] 王志良. 人工心理. 北京: 机械工业出版社, 2007.
- [11] 王志良. 人工情感. 北京: 机械工业出版社, 2009.

-
- [12] 仇德辉.情感机器人发展的理论障碍.2009.<http://blog.gmw.cn/u/8402/archives/2009/60445.html>.
- [13] 仇德辉.情感机器人的社会影响.2009.<http://www.Chinavalue.net/Group/Topic/26333/>.
- [14] 仇德辉.数理情感学.长沙:湖南人民出版社,2001.

撰稿人:王田苗¹ 孟 颀²

1 北京航空航天大学机器人研究所

2 北京航空航天大学图像处理中心

水下仿生机器人的推进控制

Propulsion Control for Underwater Biomimetic Robots

1. 背景介绍

机器人的研究源于自然界对人类的启发和人类对自然界的模仿。而鱼类, 作为水中运动的佼佼者, 为水下航行器、水下仿生机器人的研究提供了完美的原型参考。据有关资料记载, 箭鱼的时速能够达到 110km/h, 跳鱼可以跳出水面 5m 以上, 而飞鱼能以 40km/h 的速度跃出水面, 在风力适当时, 可以在离水面数米的空中滑翔 200m 之远。鱼类高效率的运动方式很早就受到了研究人员的重视。英国学者 Gray 在对海豚的研究中发现, 海豚游动时, 其肌肉能够提供的功率只有克服阻力所需功率估计值的 1/7。由此, Gray 在 1936 年从能量守恒的角度向流体力学的研究人员提出了一个悖论^[1]: 海豚的游动效率远远超出了 100%。而正是这一悖论激发了众多学者对于鱼类运动研究的兴趣。在这一研究领域, Lighthill 引入“细长体理论”对鱼类运动进行了分析和建模^[2]; Wu 提出了“二维波动板”方法对鱼类运动的水动力学特性进行分析; 童秉纲和程建宇提出了解析方法和数值计算方法相结合的“三维波动板”理论对鱼类运动过程进行分析。这些理论研究工作极大地促进了仿生流体力学的研究, 为仿生推进机制的理论分析奠定了基础。同时, 作为一种重要的研究手段, 通过设计基于仿生推进的实验装置来进行实验研究和数据分析也随之发展起来, 并为水下仿生机器人的设计和研制奠定了基础。

2. 研究现状

1994 年, 美国麻省理工学院 Triantafyllou 教授领导的研究组成功研制了世界上第一条仿生机器金枪鱼, 并通过这一实验平台展示了仿生机器金枪鱼通过涡流控制实现推进的实验, 测量了模仿鱼类运动时的推进力^[3]。日本大阪大学 Kato 教授领导的研究组深入研究了鱼类胸鳍的波动运动, 研制开发了仿生机器黑鲈^[4]。英国 Heriot-Watt 大学 Sfakiotakis 教授对鱼类的结构、运动的模式、仿生机器鱼的模型与控制方法等进行了归纳和总结, 明确了水下仿生推进的不同类型, 为后续研究工作奠定了基础^[5]。美国加州理工学院的 Murray 和 Burdick 教授深入研究了仿生机器鱼的推进机理、非线性控制问题。美国东北大学 Ayer 教授采用形状记忆合金为驱动器研制开发了仿生鳗鲡和仿生机器龙虾。在这些

研究工作基础上,美国西北大学的 Colgate 教授着重于类鱼游动运动的机理和控制问题进行了归纳和总结,在建模、欠驱动、可控性等方面进行了较深入的论述^[6]。北京航空航天大学研制开发了 SPC 系列鱼型水下机器人系统,并开展了长航时巡游、环境参数检测等实验研究。中国科学院自动化研究所开发设计了尾鳍推进和长鳍推进的两类仿生水下机器人,设计了定深控制、倒游、侧向游动等控制算法。哈尔滨工程大学、国防科学技术大学、中国科学技术大学等研究单位也设计了长鳍推进型或尾鳍推进型机器人系统。这些研究作为新型仿鱼推进的水下机器人研制开发奠定了理论和技术基础,但研制开发的仿鱼游动系统与真实的鱼类相比,在游动速度、游动效率等方面还存在很大的差距。这些差距的形成有多方面的原因,如游动运动机理不完善、减阻外形设计和减阻材料需要改进、驱动装置功耗等。其中,仿鱼推进控制是关键的问题之一。

3. 问题描述

水下仿生机器人推进控制的核心问题是如何控制仿生机器人的推进机构运动在水中产生有助于推进的漩涡。鱼类运动的推进力主要依靠鱼鳍的波动运动或摆动运动,其水动力学分析困难、计算复杂。目前的主要控制方法是依据运动学的分析,设计游动步态,模拟鱼类身体和鳍的运动,但这类方法多为开环控制,只关注仿生机器人的形体变化,缺少水下复杂流场变化的实时反馈和对推进力的估计。因此,如何控制鱼体和鱼鳍的运动使其避免外部复杂流场变化的影响,乃至充分利用外部流场的变化,从而提高仿生水下机器人的推力、机动性和效率,这仍是一个困难问题。不同刚性或柔性材料的鱼鳍与水的相互作用存在的差异与变化、水下流场变化信息的实时检测与反馈、仿生鱼体和鱼鳍所受的约束、系统建模及模型简化、控制器设计与优化、控制性能指标等,这些都是水下仿生机器人推进控制必须考虑和克服的困难。

通过深入研究水下仿生机器人推进控制问题将促进仿生水动力学理论的验证与发展,理清鱼类适应复杂流场环境的内在控制机制,形成仿生推进控制的非线性建模和控制方法,研制出满足水下仿生机器人系统节能、高效、灵活机动、低噪声等性能要求的先进控制系统。因此,从提高推进效率、增强机动性、节能降耗等方面来看,水下仿生机器人推进控制的研究具有重要的理论价值和良好的应用前景。目前,国内外很多研究机构已经设计出不同类型的水下仿生机器人,并在推进控制方面有较好的初步研究工作。所以,通过进一步深入开展工作,不仅可以加深人类对鱼类高效运动方式的理解,而且可以为新型高效率、高机动性、长航时的水下运载器研制奠定基础。

参 考 文 献

- [1] Gray J. Studies in animal locomotion. VI. The propulsive powers of the dolphin. J. Exp. Biol., 1936, 13: 192—199.
- [2] Lighthill M J. Note on the swimming of slender fish. J. Fluid Mech., 1960, 9: 305—317.
- [3] Triantafyllou M S, Triantafyllou G S. An efficient swimming machine. Scientific American, 1995, 272: 64—70.
- [4] Kato N, Furushima M. Pectoral fin model for maneuver of underwater vehicles // AUV'96 (IEEE), Monterey, 1996.
- [5] Sfakiotakis M, Lane D M, Davies J B C. Review of fish swimming modes for aquatic locomotion. IEEE J. Oceanic Eng., 1999, 24(2): 237—252.
- [6] Colgate J E, Lynch K M. Mechanics and control of swimming: A review. IEEE J. Oceanic Eng., 2004, 29(3): 660—673.

撰稿人：谭 民 王 硕
中国科学院自动化研究所

仿人机器人的双足自然行走机理与实现

Principle and Realization of Biped Natural Walking for Humanoid Robots

1. 背景介绍

在科幻小说、影视作品及人们对机器人的想象中,拥有“与人一样思考、一样行动、能为人类服务”的仿人机器人一直是人类的梦想。仿人机器人具有与人类相似的外形,具有双足行走能力,能适应人类生活的环境,可使用人类所用的工具而无需进行任何改造,也更容易被人类从心理上接受。随着技术的发展,仿人机器人必将进入人类的家庭、办公室等日常生活环境,成为人类的好帮手。

2. 研究现状

让仿人机器人具备人类自然行走的能力,一直是仿人机器人领域的科学难题。围绕这一难题,国内外学者已展开了近半个世纪的研究和探索^[1]。虽然实现了仿人机器人在已知不变环境下的稳定行走,但与人类自然行走相差甚远。例如,不能适应复杂多变的环境,能量利用效率极低,步态不够自然协调等。要实现仿人机器人的自然行走,不仅要从生物学、医学的角度充分认识人类行走的机理,以便从中得到借鉴,而且还要从工程的角度来实现双足自然行走。

人类从四肢行走演变成双足直立行走是经过上千万年进化的结果。行走是人类的本能,是人类与生俱来的非条件反射。人体生命科学研究表明,双足行走不仅解放了双手,而且还比四肢行走能够节约 75% 的能量。人类进化的奥秘揭示,双足自然行走不需要大脑的刻意控制,而本能地通过脊髓产生运动模式,内耳前庭部分的半规管和小脑保持平衡,克服复杂多变的地面环境,使人类能够在自然环境中更好地生存^[2~4]。双足仿人机器人的行走研究已有近五十多年的历史,但相比人类自然行走的漫长的进化历程,是非常短暂的。20 世纪 70 年代,以日本早稻田大学加藤一郎教授为首的研究组成功研制了世界上首个双足仿人机器人 WABOT-1,实现了速度极慢的静态步行^[5]。之后,由于未能突破机构及传感控制等关键技术,仿人机器人的研究进入了严冬期。直到 1996 年,日本本田公司向世人首次展示秘密研制 10 年之久的仿人机器人 P2,仿人机器人研究才迈上了一个新的台阶,P2 不仅具备了与人相似的外形特征,而且能够完成转弯、前进、后退、侧行等动作^[6]。随后,我国也开展了仿人机器人的研究工

作,北京理工大学研制出可模仿人类舞刀和打太极拳等活动的“汇童”系列仿人机器人,并从人类行走的反射式控制得到启发,提出了仿人机器人的传感反射控制原理^[7,8]。日本学者认识到人类骨盆结构对行走有着重要的影响,通过改造机器人的结构及改进新的控制算法,实现直腿行走^[9],克服了屈膝行走耗费大量能量的缺点^[10]。

3. 问题描述

目前,尽管国内外研究者已实现了仿人机器人的双足行走和上肢的简单运动,但与人类自然行走相比,机器人的双足行走仍显得非常“稚嫩”和“蹒跚”,对地面的适应能力很差,还远达不到人类自然行走的步态,更谈不上优美步态了。仿人机器人的自然行走之所以未能取得根本性突破,原因主要有两个方面:其一,尽管人类对自身行走机理有一定的研究,但并未真正揭示出其内在奥秘,因而难以为研究者提供本质的借鉴;其二,仿人机器人涉及众多学科,依赖于多学科知识和技术的协调发展,但个别学科的滞后导致了木桶的短板效应。

长期以来,人们在追求仿人机器人从“形”似到“行”似的过程中,主要是从外部使机器人“效仿”,“模拟”人类的自然行走,但更应该从探索人类行走的自然规律出发,从内部使仿人机器人的行走更加协调顺畅,也就是从“使然”行走逐步逼近自然行走。仿人机器人自然行走的机理与实现这一科学难题的解决不仅将开启仿人机器人研究和应用的新纪元,同时,对揭示人类的运动规律也具有重要理论意义。

参 考 文 献

- [1] Vukobratovic M, Juricic D. Contributions to the synthesis of biped gait. IEEE Transactions on Biomedical Engineering, 1969, 16: 1—6.
- [2] Okamoto T, Kumamoto M. Electromyographic study of the learning process of walking in infants. Electromyography, 1972, 12: 149—158.
- [3] Grillner S, Halbertsma J, Nilsson J, et al. The adaptation to speed in human locomotion. Brain Research, 1979, 165: 177—182.
- [4] Yang J F, Gorassini M. Spinal and brain control of human walking: Implications for retraining of walking. Neuroscientist, 2006, 12: 379—389.
- [5] Lim H O, Takanishi A. Biped walking robots created at Waseda University: WL and WABI-AN family. Phil. Trans. R. Soc. A, 2007, (365): 49—64.
- [6] Hirose M, Ogawa K. Honda humanoid robots development. Phil. Trans. R. Soc. A, 2007, (365): 11—19.

- [7] Huang Q, Yokoi Y, Kajita S, et al. Planning walking patterns for a biped robot. IEEE Trans. on Robot. Autom., 2001, 17(3): 280—289.
- [8] Huang Q, Nakamura Y. Sensory reflex control for humanoid walking. IEEE Transactions on Robotics, 2005, 21(5): 977—984.
- [9] Kondo H, Ogura Y, Shimomura K, et al. Emulation of human walking by biped humanoid robot with heel-contact and toe-off motion. Journal of Robotics and Mechatronics, 2008, 20(5): 739—749.
- [10] Collins S, Ruina A, Tedrake R, et al. Efficient bipedal robots based on passive-dynamic walkers. Science, 2005, 307(5712): 1082—1085.

撰稿人：黄 强 范宁军 余张国
北京理工大学智能机器人研究所

旋翼飞行机器人高机动自主飞行控制

High Maneuvering Autonomous Flight Control on Flying-robot with Rotary Wing

1. 背景介绍

旋翼飞行机器人,又可称为无人直升机,是一种利用发动机带动螺旋桨旋转而产生的升力完成飞行任务的无人飞行器。与固定翼无人机相比,其具有能垂直起降、空中悬停和起飞场地要求低等特点。旋翼飞行机器人的潜在用途极为广泛。在军用方面,可进行侦察、监视、目标截获、诱饵、攻击、通信中继等;在民用方面,在航拍、大气监测、交通监控、资源勘探、电力巡检、森林防火、农业等方面具有广泛的应用前景。然而,旋翼飞行机器人是一种稳定性差、不易控制的飞行器,具有多变量、非线性耦合、柔性结构等多种动力学特性。因此,目前旋翼飞行机器人高机动自主飞行控制问题仍没有完全解决。

2. 研究现状

20 世纪 90 年代中期,对旋翼飞行机器人自主控制研究十分活跃,美国、欧洲、日本许多科研机构和企业,如卡内基梅隆大学^[1]、麻省理工学院^[2]、瑞典工业技术研究所、雅马哈公司等均搭建了具有高机动性能的旋翼飞行机器人平台,研究基于动力学模型的先进控制方法,实现悬停状态下的系统镇定及低速飞行中的航迹跟踪控制。进入 21 世纪,随着旋翼飞行机器人基本控制问题的解决,具有多飞行模态的高机动自主飞行控制成为新的研究热点,此项研究主要关注现有控制方法无法应对的旋翼飞行机器人在速度、加速度及姿态发生突变时所产生的动力学问题。虽然目前已实现了具有一定机动能力的自主飞行控制,但往往是针对特定的任务及环境,对未知扰动及飞行任务的更变并不适合。至今仍然没有出现飞行控制能力超越有人驾驶直升机的旋翼飞行机器人,科学家和工程师们仍在努力提升旋翼飞行机器人高机动飞行任务的自主飞行能力。

3. 问题描述

要解决面向高机动飞行任务的旋翼飞行机器人自主控制问题,关键要突破旋翼飞行机器人多模态动力学模型辨识、内部与外部扰动估计及具有强鲁棒性的跟踪控制等问题。在动力学模型辨识方面^[3~5],目前主要是针对特定飞行模态,如前飞、悬停等进行模型拟合得到相应的数学模型,而对于上述高机动飞

行中的模态跃迁,无法进行动力学描述和参数估计,致使控制器的设计上受到很大限制;在扰动估计方面^[6],由于旋翼飞行机器人的本体机械结构、载荷质量及环境中的气流、温度变化、地效等都会造成其动力学参考模型的严重失配,控制效果受到极大影响;在自主控制器设计方面^[7~10],由于受到上述两者的限制,在飞行环境、飞行任务和飞行模态发生较大变化时,往往导致控制器内环控制不稳定,直接影响旋翼飞行机器人姿态、速度跟踪及稳定性。因此,要实现高机动飞行任务的自主控制,必须解决上述科学问题。

高机动飞行任务的自主控制能力是旋翼飞行机器人发展的目标和方向,具有较高的理论研究和实际应用价值。

参 考 文 献

- [1] Amidi O, Kanade T, Miller R. Vision-based autonomous helicopter research at Carnegie Mellon Robotics Institute. Proceedings of Heli Japan '98, 1998.
- [2] Atkins S, Hall W, DeBietto D, et al. The MIT / Draper Laboratory autonomous helicopter. Cambridge: Massachusetts Institute of Technology, 1995.
- [3] Padfield G D. Helicopter Flight Dynamics: The Theory and Application of Flying Qualities and Simulation Modeling. Washington: AIAA Education Series, 1996.
- [4] Tischler M B, Cauffman M G. Frequency-response method for rotorcraft system identification: Flight application to BO-105 coupled rotor/fuselage dynamics. Journal of the American Helicopter Society, 1992, 37(3): 3—17.
- [5] Tomashofski C A, Tischler M B. Flight test identification of SH-2G dynamics in support of digital flight control system development // American Helicopter Society 55th Annual Forum Proceedings, Montreal, 1999: 1141—1167.
- [6] Voorsluijs M, Mulder A. Parameter-dependent robust control for a rotorcraft UAV // AIAA Guidance, Navigation, and Control Conference and Exhibit, San Francisco, 2005.
- [7] Abbeel P, Ng A Y. Apprenticeship learning via inverse reinforcement learning. Proc. ICML, 2004.
- [8] Saif A, Harris N M. Tracking and maneuver regulation control for nonlinear nonminimum phase systems: Application to flight control. IEEE Transactions on Control System Technology, 2002, 10(6): 780—792.
- [9] Abbeel P, Coates A, Hunter T, et al. Autonomous autorotation of an RC helicopter. International Symposium on Robotics, 2008.
- [10] Abbeel P, Coates A, Quigley M, et al. An application of reinforcement learning to aerobatic helicopter flight. Advances in Neural Information Processing Systems, 2007, 19: 1—8.

撰稿人: 齐俊桐 韩建达 王越超
中国科学院沈阳自动化研究所

机器人视觉中的物体表达问题

Object Representation for Robot Vision

1. 物体表达的必要性和重要性

机器人能像人一样识别物体,是机器人视觉(robot vision)专家的梦想和追求。要想识别物体,不论是人还是机器人,仅仅看到是不够的,还需要知道物体的表达方式。表达是一个与认知科学密切联系的词汇,英文是 representation。通俗地讲,物体表达问题就是指物体在大脑(对人类)或计算机内(对机器人)是如何对物体进行表示的问题。

物体表达是物体识别的主要步骤。对机器人而言,不同的表达(主要指不同的数学模型),直接决定着对物体识别的能力和可靠性。这主要是因为一个物体从不同的方向看,对应的图像是不同的,有时甚至差别很大。人们希望物体表达方式尽量与观察物体的视角无关,这也是为什么要研究有效表达的原因。目前,机器人很难处理同一物体在不同视角下的物体识别问题。然而,我们人类在识别物体时似乎对这种视角变化很不敏感。所以,研究人类视觉表达方式是解决机器人视觉中物体表达的有效途径,至少具有重要的参考作用。

2. 两种主要的物体表达方式

尽管文献中对物体有大量不同的数学描述方式,如显著特征描述、不变量描述、弹性模型等,但这些模型可以说仅仅是针对某些特定物体在特定环境下的一些表达形式,还上升不到通用的物体表达方式的层次。就目前的文献看,物体表达方式主要由两种模型:一种称为三维形状模型,一种称为二维图像模型。

(1) Marr 的三维模型。三维形状模型是 20 世纪 80 年代由麻省理工学院已故教授 Marr 提出的。基本思想是:物体在大脑中的表达是物体的三维几何形状。因为物体的三维几何形状与视角无关,所以,人类对物体的表达是与视角无关的表达。Marr 三维物体表达模型的提出宣告了计算机视觉这门学科的诞生。Marr 的物体表达方式主要在他 1982 年出版的 *Vision: A Computational Investigation into the Human Representation and Processing of Visual Information* 一书中进行了详细介绍^[1],至今仍具有重要的影响。Marr 的三维模型,文献中也称之为三维重建理论。Marr 理论认为,人们首先从看到的二维图像中提取一些

诸如点、线、区域等简单基元,然后通过双目立体视觉、运动视觉等视觉模块将这些简单基元的深度进行复原,最后对物体的整体几何形状给出一个简单表达。Marr 的这种三维表达方式在实践中遇到了很大的困难,并导致一些计算机视觉研究人员的批评和争论^[2]。Marr 三维表达最主要的困难是计算机很难可靠地从二维图像来复原物体在成像过程中所丢失的三维深度信息。后来,人们又提出分层重建等理论来克服深度恢复过程的不鲁棒性问题^[3,4]。

(2) 二维图像模型。心理学实验发现,尽管人们识别物体时,从侧面图像识别与从正面图像识别所需的时间差别不大(人们自身很难觉察到),但还是有差别的,这就从某种程度上说明,人类对物体的表达“不纯粹”是三维表达。如果是三维表达的话,从正面图像与侧面图像识别物体时所需的时间应该完全一样。近年来,人们又提出了基于图像的表达方式^[5~7],这种表达方式认为,人类对物体的表达不是物体的三维几何形状,而是该物体在不同视点下的一组图像。在这种模型下,物体的识别过程就成为输入图像与大脑中对该物体存储的一组图像的匹配过程,这种模型数学上的依据是所谓的子空间方法。也就是说,同一个物体,虽然从理论上来说可以投影成无数不同的图像,但在允许一定小误差的情况下,任何一幅图像都可以通过数量有限的一组基图像的线性组合得到,所以,大脑仅仅存储这组基图像就可以了。基于图像的模型还很不成熟。一个明显的问题是:大脑皮层负责物体识别的区域有大量仅仅对深度信息敏感的神经元,这些深度信息如果不对物体识别起作用,在人类长期进化的过程中,这些细胞应该早已退化不再起作用。

3. 展望

物体表达问题是一个复杂的问题。不论是三维模型,还是二维图像模型,也许人们都在“瞎子摸象”。文献[8]猜测物体的表达模型可能是二维和三维的混合模型。也就是说,人类在识别物体时,先利用二维图像识别,当二维图像仍不足以区分物体时,此时需要加入三维信息进行区分。总之,物体表达是一个重要的问题,但也是至今仍没有很好解决的一个复杂问题,随着脑成像手段的不断进步,在不远的将来,人们可望对这个问题有更加深入的认识。

参 考 文 献

- [1] Marr D. Vision: A Computational Investigation into the Human Representation and Processing of Visual Information. New York: W H Freeman, 1982.
- [2] Tarr M J, Black M J. A computational and evolutionary perspective on the role of representation in vision. CVGIP: Image Understanding, 1994, 60(1): 65—73.

- [3] Faugeras O D. Three-Dimensional Computer Vision: A Geometric Viewpoint. New York: MIT Press, 1993.
- [4] Hartley R, Zisserman A. Multiple View Geometry in Computer Vision. Cambridge: Cambridge University Press, 2000.
- [5] Riesenhuber M, Poggio T. Models of object recognition. Nature Neuroscience, 2000, 3: 1199—1204.
- [6] Tarr M J, Williams P, Hayward W G, et al. Three-dimensional object recognition is view-point dependent. Nature Neuroscience, 1998, 1(4): 275—277.
- [7] Poggio T, Bizzi E. Generalization in vision and motor control. Nature, 2004, 431(14): 768—774.
- [8] Orban G A, Jansen P, Vogels R. Extracting 3D structure from disparity. Trends in Neuroscience, 2006, 29(8): 466—473.

撰稿人：胡占义
中国科学院自动化研究所

高速移动机器人高精度漂移控制

Challenge of Precise Drift Control for High Speed Mobile Robots

“移动性”是机器人能够走下生产线、走进人类生活各个方面的关键因素之一^[1]。对更高机动性和灵活性的不断追求是移动机器人技术发展的原动力。地面移动机器人在机构上通常借鉴和模仿人类、动物、车辆等的形态。人的极限奔跑速度能达到 36km/h，非洲猎豹的奔跑速度能达到 110km/h，量产轮式车辆的最快速度能达到 300~400km/h。相较于人和动物的腿足式结构，轮式结构机构简单、稳定性好、易于提升速度。

迄今为止，高速下的自主运动控制仍然是制约着移动机器人技术发展的瓶颈之一^[2]。1966 年，斯坦福机器人研究中心研制出了世界上第一台轮式自主移动机器人 Shakey^[3]。之后的几十年间，机器人技术在感知、理解、推理、路径规划等方面都取得了长足的进步。近几年来，以 Spirit 号为代表的火星探测车已在星际探索方面发挥着无可替代的巨大作用^[4]。这些研究成果为移动机器人成为真正的“智能机器”奠定了坚实的基础。然而，由于多方面的原因，如传感器数据的采样频率和可靠性、可用于控制器的实时动力学模型、复杂多变的路况等，使得移动机器人始终难以高速、高精度地自主运动与作业。

目前，在公路汽车赛中，赛车手可以利用漂移动作来快速过弯，提高车辆的机动性。而在一般的场合下，使车辆处于漂移失稳这种状态是非常危险的，普通驾驶员很难做出及时正确的判断以便车体回复到平稳状态，因此，一般的高档民用汽车利用刹车防抱死系统 ABS、电子制动力分配 EBD、驱动防滑系统 ASR 和电子稳定程序 ESP 等技术来抑制漂移，从而保证车体行驶转弯过程中的平稳性，避免出现侧滑甚至侧翻的现象，提高人们驾车的安全性。

赋予移动机器人“赛车手”的素质，利用主动的“高精度漂移”控制，充分发挥移动机器人的机动性能，可以实现高速下的快速过弯等特技动作。因此，研究“高精度漂移控制”技术，使得高速漂移过弯可控，在理论上可以最大限度地发挥出高速移动机器人的机动性能^[5]。

图 1 所示为移动机器人漂移特技运动的原理图。从图中可以看出，当移动机器人以高速进入弯道时，如果双轮差速保持在平稳运动界限内，将会偏离跑道，违反任务目标的空间约束；当双轮差速进一步增大，移动机器人将会发生侧滑，侧滑会使机器人处于非平稳状态，如果不进行进一步的控制，将会以螺旋方式偏离跑道；只有在发生侧滑并且侧滑到车头方向指向期望方向时，通过

对双侧车轮转速进行控制使得运动方向收敛到期望方向，才能满足跑道的空间约束。




图1 移动机器人漂移特技运动

高速移动机器人高精度漂移控制的核心问题是如何对各个车轮进行独立控制，使得机器人漂移过程中的状态可测可控，其中的科学难点在于以下几个方面：

(1) 深入分析漂移运动机理，找到机器人进入和退出漂移状态的条件，建立基于车体打滑量的漂移运动学模型。

(2) 对移动机器人漂移过程中的动力学进行精确建模，模型中涉及轮地相互作用，需要对各车轮与地面相互作用进行实时的测量^[6,7]。

(3) 目前，对移动机器人自身位姿估计时可以采用一系列的传感器，如车轮码盘、惯性测量单元(IMU)、卫星定位单元(GPS)、高速摄像机、激光传感器等。在高速情况下，传感器的采样频率、多传感器信息融合算法复杂度等都会制约机器人控制的实时性和精确度，影响移动机器人准确定位定姿^[8]。

在缺乏精确的机器人运动学、动力学模型的情况下，基于传感器的测量和估计值、设计和在线优化智能控制方法可以逐步实现高精度漂移控制的目的^[9]。

从追求移动机器人更高机动性和灵活性的目的出发，对高速移动机器人高精度漂移控制问题的研究具有良好的理论价值和应用前景。

参 考 文 献

- [1] Siciliano B, Khatib O. Springer Handbook of Robotics :Part E. Berlin :Springer ,2008 .
- [2] Golda D ,Iagnemma K ,Dubowsky S .Probabilistic modeling and analysis of high-speed rough-terrain mobile robots .IEEE International Conference on Robotics and Automation ,2004 :914—

919 .

- [3] Nilsson N J. A mobile automation an application of artificial intelligence techniques //Proceedings of the 1st International Joint Conference on Artificial Intelligence ,Las Vegas ,1969 : 509—520 .
- [4] Baumgartner E. Motion planning technologies for planetary rovers and manipulators //Proceedings of International Workshop on Motion Planning in Virtual Environments ,Toulouse , 2005 .
- [5] Atsushi K ,Ryo U ,Ishihara T ,et al. Development of a high speed vision system for mobile robots .International Conference on Intelligent Robots and Systems ,2006 :1372—1377 .
- [6] Ward C C ,Iagnemma K. Classification-based wheel slip detection and detector fusion for outdoor mobile robots .IEEE International Conference on Robotics and Automation ,2007 : 2730—2735 .
- [7] Yu W ,Jr O ,et al. Analysis and experimental verification for dynamic modeling of a skid-steered wheeled vehicle .IEEE Transactions on Robotics ,2010 ,26(2) :340—353 .
- [8] Ohno K ,Tsubouchi T ,Shigematsu B ,et al. Outdoor navigation of a mobile robot between buildings based on DGPS and odometry data fusion .IEEE International Conference on Robotics and Automation ,2003 :1978—1984 .
- [9] Yi J ,Wang H ,Zhang J ,et al. Kinematic modeling and analysis of skid-steered robots with applications to low-cost inertial-measurement-unit-based motion estimation .IEEE Transactions on Robotics ,2009 ,25 :1087—1097 .

撰稿人：刘景泰 王鸿鹏

南开大学机器人与信息自动化研究所

相对阶不小于 1 的 P 型迭代学习控制系统

P-type Iterative Learning Control Systems with Relative Degree Not Less Than One

1. 背景介绍

1984 年, 日本学者 Arimoto 及其合作者提出迭代学习控制^[1], 它的学习过程类似于体育运动员经过反复练习、获得理想技术动作的训练过程, 它为有限作业区间上重复运行的受控对象提供了一种完全控制技术, 即实现整个作业区间上的零误差跟踪。与基于 Lyapunov 方法的控制系统分析不同, 迭代学习控制系统的性能分析采用压缩映射方法, 获得的收敛性条件十分宽松。它允许较大的模型失配, 甚至不经由建模, 在线尝试也可确定学习增益。通常, 建模精度严重制约着控制性能, 许多控制方法着力处理系统中存在的各种不确定性; 而在工程实现时, 未建模特性的影响却令人头疼。控制器的实现复杂性是人们关注的另一问题。控制器需要的信息越少越好, 如只是跟踪误差信号。否则, 实现难度增加, 系统成本也会随之提高。迭代学习控制是针对工业机器人控制系统提出的。控制器设计不需要建立受控对象完整动力学特性的数学模型, 只要求输入输出映射关系关于控制的导数的信息, 但不要求精确已知。因此, 迭代学习控制适于具有非线性和时变性的多变量耦合复杂动态系统。学习律仅要求跟踪误差数据, 算法在线计算量小, 适合快速运动对象。迭代学习控制在粗(无)模型下实现完全跟踪性能, 给出了解决建模精度与控制精度这对矛盾的一条途径。虽然迭代学习控制技术只适于重复地完成同一作业任务的受控对象, 但其工业应用背景却十分广泛, 除工业机器人外, 还有装配生产线、电力电子、直线电机、注塑机、半导体晶片加工及间歇化工过程等。

在开始每一次作业前, 迭代学习控制要求系统进行初始定位。由于实际系统重复定位精度的限制, 初始定位操作不可避免地存在误差。像反馈控制一样, 迭代学习控制在实际应用时应考虑各种系统不确定性的影响。不同的是, 后者还需考虑初始定位误差的影响。因为迭代学习控制的重复作业特点, 人们格外关注这种系统在重复作业时能否安全可靠运行, 存在各种系统不确定性及初始定位误差情形下的控制性能是怎样的。特别地, 相对阶不小于 1 的 P 型迭代学习控制系统的鲁棒性问题一直困扰着这一研究领域。

2. 问题描述

P 型连续迭代学习控制系统是指下述采用 P 型学习律的、重复作业下的连续动态系统:

$$\mathbf{x}_i(t) = \mathbf{f}(\mathbf{x}_i(t), t) + \mathbf{B}(\mathbf{x}_i(t), t)\mathbf{u}(t) + \boldsymbol{\eta}_i(t) \quad (1)$$

$$\mathbf{y}_i(t) = \mathbf{g}(\mathbf{x}_i(t), t) + \boldsymbol{\xi}_i(t) \quad (2)$$

$$\mathbf{u}_{i+1}(t) = \mathbf{u}(t) + \mathbf{L}\mathbf{e}_i(t) \quad (3)$$

式中, $t \in [0, T]$; $i=0, 1, 2, \dots$ 是迭代次数; $\mathbf{x}_i(t) \in \mathbf{R}^n$ 、 $\mathbf{u}(t) \in \mathbf{R}^r$ 和 $\mathbf{y}_i(t) \in \mathbf{R}^m$ 分别是系统的状态、控制和输出; $\boldsymbol{\eta}_i(t) \in \mathbf{R}^n$ 和 $\boldsymbol{\xi}_i(t) \in \mathbf{R}^m$ 分别表示系统动态不确定特性和量测噪声; $\mathbf{e}_i(t) = \mathbf{y}_d(t) - \mathbf{y}_i(t)$ 为跟踪误差; $\mathbf{y}_d(t)$ 为给定的期望轨迹; $\mathbf{L} \in \mathbf{R}^{r \times m}$ 是学习增益; $\mathbf{f}(\cdot, \cdot)$ 、 $\mathbf{B}(\cdot, \cdot)$ 、 $\mathbf{g}(\cdot, \cdot)$ 为具有相应维数的非线性函数。考虑 P 型学习律(3)在 $t=0$ 时刻的取值, 通过迭代可得

$$\mathbf{u}(0) = \mathbf{u}(0) + \mathbf{L} \sum_{j=0}^{i-1} \mathbf{e}_j(0) \quad (4)$$

系统(1)、(2)的初始条件是不受控制的。由式(4)知, 不受控制的初始定位误差决定了由式(3)产生的控制信号在初始时刻的取值, 主要表现在以下方面:

(1) 若 $\mathbf{e}_i(0)=0$, 则 $\mathbf{u}(0)=\mathbf{u}(0)$ 。通过学习律(3)产生的 $\mathbf{u}(0)$ 被钳制为 $\mathbf{u}(0)$ 。当 $\mathbf{u}(0)$ 与期望控制的初始值不同时, $\mathbf{u}(0)$ 也不等于期望控制的初始值。

(2) 在实际中, 人们不易做到使初始定位误差关于 i 一致为零, 这样, 非零初始定位误差会导致控制信号的初始值不准确, 累加项 $\sum_{j=0}^{i-1} \mathbf{e}_j(0)$ 意味着初始定位误差对 $\mathbf{u}(0)$ 的影响会不断累加。

(3) 由于系统(1)、(2)关于初值的连续依赖性, 初始定位误差的累加对控制信号初始值的影响会沿时间轴传播, 严重时可能导致迭代学习过程发散。

3. 已有结果

任意但有界的初始定位误差会导致 P 型学习算法发散是由文献[2]在讨论 D 型学习算法的鲁棒性时发现的。在 P 型学习算法中引入遗忘因子的做法可增强其关于初始定位误差、系统动态不确定性及量测噪声的鲁棒性, 使得跟踪误差收敛到原点的邻域内, 邻域半径正比于这些不确定量的界^[3]。但是, 即使这些界为零, 非零遗忘因子学习算法的收敛性仍不能得以保证。人们不得已设置遗忘因子为零, 以保证收敛性, 但含零遗忘因子的学习算法又失去了鲁棒性。在

文献[4]、[5]报道的针对这种带遗忘因子的 P 型学习律的分析中,假设条件难以检验、甚至苛刻,以上所述工作均是针对相对阶为 1 的连续系统。预期学习能有效解决 P 型学习算法的鲁棒性问题,可证明任意相对阶系统的鲁棒性,但理论上也不能保证零误差收敛性^[6,7]。应该进一步指出的是,对于动态方程中具有输入输出直接传输项的连续系统,或具任意相对阶的离散(或采样)迭代学习控制系统,其鲁棒性分析是直接的。

尽管一个迭代学习控制系统具有鲁棒性,但各种干扰不消除时,理论上仍不能保证收敛性。在已发表的文献中,许多研究者关注学习算法的鲁棒收敛性问题:对于某种特定形式的干扰,即使不消除,收敛性仍能得以保证。例如,对于存在任意但固定的初始定位误差的情形,通过引入初始修正作用,D 型学习律可实现预先指定区间上的完全跟踪^[8]。考虑 P 型迭代学习控制系统,使其在任意但有界的初始条件下鲁棒收敛也是值得研究的课题。

迭代学习控制的提出原本来自于工业机器人系统,它从诞生就烙印着鲜明的应用背景和诱人的控制品质。随着其基础研究的深入和完善,相信人们在高速、高精度控制场合越来越乐于采用这种不需要精确模型(或无模型)的精确控制技术。如 PID 是一种常用的反馈控制策略一样,迭代学习控制可望成为实际工程中切实可行的、顶用的前馈控制策略。

参 考 文 献

- [1] Arimoto S, Kawamura S, Miyazaki F. Bettering operation of robots by learning. *Journal of Robotic Systems*, 1984, 1(2): 123—140.
- [2] Heinzinger G, Fenwick D, Paden B, et al. Robust learning control // *Proceedings of the 28th IEEE Conference on Decision and Control*, Tampa, 1989, 436—440.
- [3] Arimoto S, Naniwa T, Suzuki H. Robustness of P-type learning control with a forgetting factor for robotic motions // *Proceedings of the 29th IEEE Conference on Decision and Control*, Honolulu, 1990, 2640—2645.
- [4] Saab S S. On the P-type learning control. *IEEE Trans. on Automat. Contr.*, 1994, 39(11): 2298—2302.
- [5] Chien C J, Liu J S. A P-type iterative learning controller for robust output tracking of nonlinear time-varying systems. *International Journal of Control*, 1996, 64(2): 319—334.
- [6] Wang D. On D-type and P-type ILC designs and anticipatory approach. *International Journal of Control*, 2000, 73(10): 890—901.
- [7] Sun M, Wang D. Anticipatory iterative learning control for nonlinear systems with arbitrary relative degree. *IEEE Trans. on Automat. Contr.*, 2001, 46(5): 783—788.

-
- [8] Sun M, Wang D. Iterative learning control with initial rectifying action. Automatica, 2002, 38(7): 1177—1182.

撰稿人：孙明轩

浙江工业大学信息工程学院

数据驱动自适应迭代学习控制系统的设计和分析

Design and Analysis of Data-driven Adaptive Iterative Learning Control

1. 背景介绍

迭代学习控制(iterative learning control, ILC)是1984年由Arimoto等^[1]提出,目前已经发展成为一门比较成熟的控制理论与方法,并得到成功应用。ILC利用系统在有限时间区间上的重复性,应用前一次或几次迭代控制信号和误差信息来更新当前迭代的控制输入信号以提高系统性能,实现系统在有限时间区间上的完全跟踪。ILC可处理具有重复性的非线性、时变或动力学模型未知系统的控制问题。ILC是一种典型的数据驱动控制方法或无模型控制方法^[2],因此具有重要的实际应用价值。

2. 问题描述

ILC要求系统具有严格可重复性(包括模型、初始条件、跟踪任务)和满足全局Lipschitz连续两个条件。然而,许多实际问题很难满足第一个条件,从而限制了ILC在实际中的更广泛应用。因此,围绕如何放宽或去除严格重复条件的研究已经做了很多工作,如针对初始条件问题^[3]、高阶内模迭代学习^[4]等。文献[5]提出了“lifting operation”和“沿迭代轴的 w 变换”的概念,也为处理这类系统的控制问题提供了一个很好的框架。

众所周知,自适应控制是解决参数不确定性和参考轨迹变化问题的一个有效和有力的理论工具,将自适应控制理论和方法引入到ILC中也是解决非严格重复系统的ILC问题的一个有前途的研究方向,在这方面,也有了一系列前期工作。将ILC和自适应控制结合,目前的主要工作有两类:学习控制律增益可随迭代次数变化的增益自适应ILC,如文献[6],但结果很少;另一类就是系统参数随迭代变化基于迭代轴参数估计值求出控制输入量的参数自适应ILC(控制器本身的设计是基于模型来设计的),如文献[7]。引入自适应控制,其目的就是要解决ILC的严格重复性的要求,包括严格重复的初始条件、期望轨迹及系统参数随迭代次数变化等问题。这样做的好处除了上述两点之外,从方法论上讲,还可以丰富ILC的分析手段和方法。然而,这些分析和设计手段不能简单地移植到ILC理论的分析 and 设计中,原因之一就是:ILC本质上是二维系统,

时间轴上的自适应控制推广到二维上来的时候可能会有本质上的困难。

另外,由于增益自适应 ILC 中仅通过增益自适应律很难捕获全部的沿迭代轴方向系统非严格重复的动力学行为,如模型参数或期望轨迹沿迭代轴变化等。参数自适应 ILC 方案中的控制器包含系统的动力学模型,控制器参数是沿迭代轴更新的,而不是控制输入本身沿迭代轴迭代更新,用另外的话说就是,其控制器的设计依赖已知的模型来设计,从而需要其沿迭代轴的参数估计器给出系统的真值才能保证其跟踪收敛性,从而带来严重的鲁棒性问题。理论上讲,一般情况下,ILC 沿迭代轴方向很难满足持续激励条件,因此,沿迭代轴的参数估计器不可能给出系统真值的准确值,从而导致依靠系统模型结构设计的 ILC 律就不可能给出很好的控制品质。进一步,已存在的自适应 ILC 方法,由于其控制器的设计依赖于模型的动力学行为,而 ILC 的一个最吸引人的优点,即无模型的数据驱动的本质已经丢失了,就好比将洗澡水与孩子一起被倒掉了。因此,研究数据驱动的自适应 ILC 系统的设计,并分析其稳定性和收敛性,即能保持其无模型数据驱动的本质,同时,还要期望分享已存在的 AILC 方法的优点,是一项极具理论挑战性的难题。

3. 实际背景

“数据驱动的自适应 ILC”问题的提出不仅仅来源于理论上的动机,同时也是来源于交通系统中所遇到的实际问题。

快速路交通流控制系统是基于宏观交通流模型来设计的。宏观交通流模型是 1971 年由 Payne 给出的,后来又经过 Papageorgiou 等多人的改进,已被研究和实践证明能够很好地描述高速公路稳态交通流的各种现象^[8]。城市快速路交通流系统具有按天、周的重复性,因此,我们可以应用 ILC 方法设计出入口匝道交通信号控制系统^[9,10]。然而,理论上讲,交通流系统的行为不可能具备严格的重复性,如果将不同天、周作为 ILC 的一次迭代的话,会很容易发现交通流的动力学中的参数或者期望轨迹(密度、流量、速度)会随天、周的变化而变化。

提炼到理论层面就是:

(1) 模型结构完全可重复,模型参数随迭代慢变化。这里的参数慢变化不同于传统非线性系统中的参数慢时变,而是沿迭代轴的慢变,是迭代依赖的,我们并不关心其在时间轴上是快时变、慢时变,还是时不变的。

(2) 期望轨迹随迭代轴变化是慢变化的。

轨道交通系统也是如此。众所周知,列车(客车、火车、地铁)等的运行,在正常情况下,都是严格按照列车运行图及时刻表,在同样的轨道区间、同样的运行时间区间重复运行的,所承运的货物或人员等都是基本一样的。因此,理论上讲,我们可以将原型的 ILC 理论和方法应用到列车运行控制系统上,然

而,实际上,列车尽管在同一时间区间段内、在同一条轨道区间上重复地运行,但不可能非常严格地重复。比如说,列车的荷载或载客量等可能随每一次运行的变化而变化;轨道的运行的摩擦力也可能与每一次运行的天气温度等的变化而有不同;对高速列车来临的时代,列车速度越来越高,列车运行的风阻也将与每次运行的具体风速的不同而不同。

4. 结论

针对一般或者特殊的非线性离散时间系统,研究在有限时间区间上非严格重复系统的数据驱动的自适应 ILC 问题,并分析其稳定性和收敛性,具有重要的理论意义,同时也有广阔的应用前景。

参 考 文 献

- [1] Arimoto S, Kawamura S, Miyazaki F. Bettering operation of robots by learning. *Journal of Robotic Systems*, 1984, 1(2): 123—140.
- [2] 侯忠生, Xu J X. 数据驱动控制理论及方法的回顾和展望. *自动化学报*, 2009, 35(6): 650—667.
- [3] Xu J X, Yan R. On initial conditions in iterative learning control. *IEEE Trans. on Automat. Contr.*, 2005, 50(9): 1349—1354.
- [4] Yin C K, Xu J X, Hou Z S. Iterative learning control design with high-order internal model for nonlinear systems. *48th IEEE Conference on Decision and Control*, 2009: 434—439.
- [5] Moore K L, Chen Y Q, Ahn H S. Iterative learning control: A tutorial and big picture view. *IEEE CDC*, 2006.
- [6] Owens D H, Munde G S. Universal adaptive iterative learning control // *37th IEEE Conference on Decision & Control*, Tampa, 1998.
- [7] Chi R H, Hou Z S, Xu J X. Adaptive ILC for a class of discrete-time systems with iteration-varying trajectory and random initial condition. *Automatica*, 2008, 44: 2207—2213.
- [8] Papageorgiou M, Kotsialos A. Freeway ramp metering: An overview. *IEEE Transactions on Intelligent Transportation Systems*, 2002, 3(4): 271—281.
- [9] Hou Z S, Xu J X, Zhong H W. Freeway traffic control using iterative learning control based ramp metering and speed signaling. *IEEE Trans. on Vehicular Technology*, 2007, 56(2): 1—12.
- [10] Hou Z S, Xu J X, Yan J W. An iterative learning approach for density control of freeway traffic flow via ramp metering. *Transportation Research, Part C*, 2008, 16: 71—97.

撰稿人: 侯忠生

北京交通大学电子信息工程学院

自适应动态规划的结构和算法优化

The Optimization of Structures and Algorithms of Adaptive Dynamic Programming

1. 背景介绍

动态规划(dynamic programming)是求解控制(或决策)过程最优化的数学方法。20 世纪 50 年代初,美国数学家 Bellman 等在研究多阶段控制过程的优化问题时,创立了解决这类过程优化问题的新方法——动态规划,1957 年出版了他的名著 *Dynamic Programming*^[1],这是该领域的第一本著作。动态规划方法与 Pontryagin 最大值原理和卡尔曼滤波理论被称为是现代控制理论中的三个里程碑。动态规划的核心是 Bellman 最优性原理,其原理可以叙述如下:一个多级控制问题的最优控制具有这样的性质,当把其中任何一级及其状态作为初始级和初始状态时,则不管初始状态是什么,达到这个初始状态的控制是什么,余下的控制对此初态必定构成最优控制。这个原理可以归纳为一个基本的递推公式,把多阶段过程转化为一系列单阶段问题,从而使得问题简单化。

2. 问题描述

我们设 N 级控制性能指标 J 取如下形式:

$$J_k(x_k) = \sum_{i=k}^{k+N-1} U(x_i, u_i) \quad (1)$$

式中, x_k 为系统状态变量; u_k 为控制变量; U 是由某级状态变量和控制变量决定的效用函数。需要寻找控制序列 $u_k, u_{k+1}, \dots, u_{k+N-1}$ 使 $J_k(x_k)$ 取得极小 $J_k^*(x_k)$ 。最优性原理可以表示为如下动态规划方程:

$$\begin{aligned} J_k^*(x_k) &= \min_{u_k, u_{k+1}, \dots, u_{k+N-1}} \{ U(x_k, u_k) + U(x_{k+1}, u_{k+1}) + \dots + U(x_{k+N-1}, u_{k+N-1}) \} \\ &= \min_{u_k} \{ U(x_k, u_k) + \min_{u_{k+1}, \dots, u_{k+N-1}} \{ U(x_{k+1}, u_{k+1}) + \dots + U(x_{k+N-1}, u_{k+N-1}) \} \} \\ &= \min_{u_k} \{ U(x_k, u_k) + \min_{u_{k+1}} \{ U(x_{k+1}, u_{k+1}) + \dots + \min_{u_{k+N-1}} \{ U(x_{k+N-1}, u_{k+N-1}) \} \} \} \end{aligned} \quad (2)$$

由上式可见,动态规划的最优化过程是从最里面的括号开始向外扩展的,即寻找最优控制的次序是从末端开始,到始端为止,逆向递推,逐个求解,其求解次序为 $u_{k+N-1}^*, u_{k+N-2}^*, \dots, u_{k+1}^*, u_k^*$,这种方法导致了一个很明显的问题:我

们要找到一个最优控制序列并从中获取最优控制,同时这个最优控制序列会给出一个最优性能指标,然而在控制序列结束之前,我们却得不到整个序列产生的性能指标函数值。因此,为了得到最优控制序列,我们不得不记录每一步运算的控制策略和性能指标函数值一直到控制序列结束。因此,随着 x_k 和 u_k 的维数增加,动态规划方法显露出了一个明显的弱点:计算量和存储量有惊人的增长。例如,对于一个 n 维 x 和 r 维 u 的控制系统,设离散时间段数为 N , x_k 和 u_k 的幅值离散化段数分别为 p 和 q ,用上述方法,要求存储量为 $2p^n$ 个单元,计算量为 Np^nq^r 。如果 $N=1$, $p=q=20$, $n=6$, $r=2$,则应存储的字数为 128000000,假定一次求值需要 $10\mu\text{s}$,则整个方法执行时间需要大约 3 天时间。这种情况就是著名的“维数灾”问题,它极大限制了动态规划方法的直接应用。

3. 必要说明

为了解决“维数灾”问题, Werbos 在 1977 年首次提出了自适应动态规划(adaptive dynamic programming, ADP)方法^[2],其思想是利用函数近似结构,逼近动态规划方程中的性能指标函数和控制策略以满足最优性原理,从而获得最优控制和最优性能指标函数,其结构可以用图 1 描述。




图 1 自适应动态规划方法

自适应动态规划方法的结构主要由三部分组成:动态系统、执行模块和评判模块。其中,动态系统为被控对象,执行模块用来近似最优控制策略,评判模块用来近似最优性能指标函数。后两者的组合相当于一个智能体,控制/执行作用于动态系统(或者被控对象)后,通过动态系统产生的状态共同影响评判模块,评判模块产生奖励/惩罚信息再来影响执行模块。执行模块和评判模块利用函数近似结构实现对最优性能指标函数和最优控制策略的逼近。评判模块参数的更新基于动态规划最优原理进行,这样不仅可以减少前向计算时间,而且可

以在线响应未知系统的动态变化,对每一部分的参数进行自动调整。执行模块是在评判模块的基础之上进行,也就是必须使得评判模块的输出达到极小。因此,自适应动态规划方法是一种典型的智能化方法。

自适应动态规划方法创始人 Werbos 采用了 BP 神经网络实现这种方法。Werbos 将评判模块和执行模块都用神经网络代替,利用神经网络的强大逼近功能分别逼近最优性能指标函数和最优控制策略。这样,自适应动态规划方法就得以实现并获得了很好的控制效果,因而,这种自适应动态规划实现方法得到了广泛应用。有些研究者采用多项式方法逼近最优性能指标函数和最优控制策略,如微分动态规划、Galerkin 近似法等,这些方法在系统平衡点或运行点附近具有很好的控制效果,可当控制状态远离平衡点时,控制效果就不理想了。目前我们还没有找到一种“完美”的近似结构可以真正逼近最优性能指标函数和控制策略。

针对不同类型的系统,找到最行之有效的学习方法获得最优的控制结果是自适应动态规划方法下一步努力的方向^[3~8]。

参 考 文 献

- [1] Bellman R E. Dynamic Programming. Princeton; Princeton University Press, 1957.
- [2] Werbos P J. Advanced forecasting methods for global crisis warning and models of intelligence. General Systems Yearbook, 1977; 25—38.
- [3] Werbos P J. A menu of designs for reinforcement learning over time // Miller W T, Sutton R S, Werbos P J. Neural Networks for Control. Cambridge; MIT Press, 1991.
- [4] Werbos P J. Approximate dynamic programming for real-time control and neural modeling // White D A, Sofge D A. Handbook of Intelligent Control: Neural, Fuzzy, and Adaptive Approaches. New York; Van Nostrand Reinhold, 1992.
- [5] Al-Tamimi A, Lewis F L, Abu-Khalaf M. Discrete-time nonlinear HJB solution using approximate dynamic programming: Convergence proof. IEEE Transactions on Systems, Man, and Cybernetics-Part B: Cybernetics, 2008, (4): 943—949.
- [6] Wang F Y, Zhang H, Liu D. Adaptive dynamic programming: An introduction. IEEE Computational Intelligence Magazine, 2009, (2): 39—47.
- [7] Lewis F L, Vrabie D. Reinforcement learning and adaptive dynamic programming for feed-back control. IEEE Circuits and Systems Magazine, 2009, (3): 40—58.
- [8] Powell W B. Approximate Dynamic Programming: Solving the Curses of Dimensionality. New York; Wiley, 2007.

撰稿人: 刘德荣
中国科学院自动化研究所

数据驱动控制理论基础问题

Fundamental Issues in Data-driven Control Theory

1. 引言

数据驱动控制的研究还仅处于萌芽阶段, 但已得到了国内外控制理论界的高度重视。美国 Minnesota 大学的 Institute for Mathematics and its Applications (IMA) 在 2002 年专门召开了一个为期三天的学术研讨会, 会议的名称为 “IMA Hot Topics Workshop: Data-Driven Control and Optimization”。2008 年 11 月, 国家自然科学基金委员会于北京专门召开了 “基于数据的控制、决策、调度与诊断” 学术研讨会。2010 年, 国家自然科学基金委员会信息学部项目申请指南中为此设立了 “重点项目群”。2011 年底, IEEE 神经网络汇刊、INFORMATION SCIENCE 等著名刊物将出版该方向的专辑。

2. 背景和问题描述

控制系统设计包括受控对象和控制器两部分。受控对象有 4 种: 有准确的模型; 有模型, 但模型不准确, 不确定性较大; 有模型, 但模型太复杂, 阶数太高, 非线性太强; 很难建立模型或无模型。控制器设计分为基于模型的设计、基于数据或无模型的设计。因此, 4 种有意义的可能控制系统设计方案有: 第一, 基于模型的控制器设计; 第二, 既可以考虑基于模型的控制器设计, 也可考虑基于数据或无模型的方法来设计; 第三, 由于模型太复杂, 阶数太高, 非线性太强, 很难分析和设计, 因此, 需要考虑模型简约或者控制器降阶设计, 或进行基于数据或无模型控制方法; 第四, 对象没有模型, 或者很难建立模型, 因此, 控制这类系统时, 仅能进行基于数据或无模型控制方法。后三类是数据驱动控制方法需要研究的重要对象。

数据驱动控制的定义是: “控制器设计不包含受控过程数学模型信息, 仅利用受控系统的在线和离线 I/O 数据来设计控制器, 并在一定的假设下, 有收敛性、稳定性保障和鲁棒性结论的控制理论与方法。” 或者简单地讲, 就是直接从数据到控制器设计的控制理论和方法。

从理论方面来讲, 第一, 基于模型的控制理论和方法不可避免 “未建模动态” 和 “鲁棒性” 这对孪生的问题, 没有模型现代控制理论又无能为力, 建模又面临着 “未建模动态” 和 “鲁棒性” 问题, 从而形成了一个无可避免的 “怪

圈”。这对“孪生”问题使得基于模型的控制理论和方法在实际中的应用变成了“不安全的控制器”^[1]。第二，数学模型的复杂结构决定了控制器的复杂结构，高阶的复杂非线性系统模型势必导致高阶复杂的非线性控制器，控制器的简化和降阶问题、鲁棒性问题变成了不可逾越设计问题。第三，复杂和高深的数学知识和专业技能的需求使得控制工程师在设计和维护时，尤其是在控制复杂系统时，显得力不从心和缺乏自信，理论和实际之间的距离越来越大，制约了控制理论的健康发展。

从应用角度看，实际中的很多问题，如化工过程、生产过程系统等，多数要求低成本能满足决策者控制指标的自动化系统和装置，建立系统全局的数学模型需要很多专家及高水平研究人员，成本高。另外，对某些实际系统，由于受到各种干扰，建立系统全局的数学模型不太可能，即使建立起模型也不是很准确，因此，基于模型的控制理论和方法在解决实际问题时就显得苍白无力。

从控制理论发展的历史角度来看，控制理论的历史是从简单的不需要数学模型的调节装置、PID 控制，发展到经典的基于传递函数模型的经典控制理论、基于受控系统状态空间模型的现代控制理论，以及现在的为了摆脱对受控系统数学模型依赖的数据驱动控制理论，最后再发展到智能控制理论，整个过程是螺旋式的发展历程。基于数据驱动控制理论与方法能够从数据直接设计控制器，从而符合控制理论的发展的螺旋式发展趋势。另外，从控制理论完整性的角度上看，现有的控制理论和方法可分为三类方法：其一，需要已知数学模型才能设计控制器的控制理论和方法，如航天控制技术、最优控制方法、线性和非线性控制方法、大系统控制协调和分解方法、极点配置方法等；其二，需要已知部分数学模型信息就能设计控制器的控制理论和方法，如鲁棒控制、滑膜变结构控制、自适应控制、模糊控制、专家控制、神经网络控制、智能控制等；第三，仅知道受控系统的 I/O 数据就能设计控制器的控制理论与方法，如 PID 控制、迭代学习控制、其他数据驱动控制方法等。数据驱动控制理论和方法的建立符合控制理论体系完整性的要求。

3. 已有方法

目前，从文献上看，主要有以下几类典型的数据驱动控制方法：

(1) 基于在线数据的数据驱动控制方法，它们是基于 SPSA 的无模型控制方法^[2]、无模型自适应控制(MFAC)^[3]、去伪控制(UC)^[4]。

(2) 基于离线数据的数据驱动控制方法，它们是 PID 控制方法^[5]、IFT^[6]、VRFT^[7]。

(3) 基于在线和离线数据结合的数据驱动控制方法，它们是迭代学习控制方法^[8]、基于近似动态规划(ADP)的 Q-Learning 算法^[9]等。

4. 基础问题

数据驱动控制是解决受控对象虽然有模型,但模型太复杂、阶数太高、非线性太强及受控对象没有模型这两种典型情况下的控制问题的方法,同时也是复杂系统控制问题的一种解决途径。数据驱动控制就是要直接应用受控系统闭环的输入输出量测数据,直接设计控制器,同时还要分析控制系统的稳定性、收敛性和鲁棒性,因此,存在如下一些基础的共性难点问题:

(1) 如何利用已有的在线或离线数据,给出具有良好性质的、在目标函数未知情况下的梯度计算或估计问题,本质上也是研究数据驱动的优化问题及收敛性。

(2) 在受控系统的数学模型未知的情况下,数据驱动控制系统设计典型的稳定性分析手段和方法。

(3) 数据驱动控制控制理论和方法的统一框架体系的建立。

(4) 数据驱动控制方法与基于模型的现代控制理论与方法之间的关系。

以上难题的解决无论对数据驱动控制理论的发展,还是对数据驱动控制方法在实际系统中的应用,都将会起到巨大的推动作用。

参 考 文 献

- [1] Anderson B D O, Dehghani A. Challenges of adaptive control—past, permanent and future. *Annual Reviews in Control*, 2008, 32: 123—135.
- [2] Spall J C, Cristion J A. Model-free control of nonlinear stochastic systems with discrete-time measurements. *IEEE Trans. on Automat. Contr.*, 1998, 43(9): 1198—1210.
- [3] 侯忠生. 非参数模型及其自适应控制理论. 北京: 科学出版社, 1999.
- [4] Safonov M G, Tsao T C. The Unfalsified Control Concept; A Direct Path from Experiment to Controller. *Feedback Control, Nonlinear Systems and Complexity*. Berlin: Springer, 1995: 196—214.
- [5] Ziegler J G, Nichols N B. Optimum settings for automatic controllers. *Transactions of the ASME*, 1942, 64: 759—768.
- [6] Hjalmarsson H, Gunnarsson S, Gevers M. A convergent iterative restricted complexity control design scheme // *Proceedings of the 33rd IEEE Conference on Decision and Control*, Orlando, 1994: 1735—1740.
- [7] Guardabassi G O, Savaresi S M. Virtual reference direct design method: An off-line approach to data-based control system design. *IEEE Trans. on Automat. Contr.*, 2000, 45(5): 954—959.
- [8] Arimoto S, Kawamura S, Miyazaki F. Bettering operation of robots by learning. *Journal of*

Robotic Systems, 1984, 1(2): 123—140.

- [9] Lee J M, Lee J H. Approximate dynamic programming-based approaches for input-output data-driven control of nonlinear processes. Automatica, 2005, 41(7): 1281—1288.

撰稿人：侯忠生

北京交通大学电子信息工程学院

学习控制系统

Learning Control Systems

四十多年前,傅京孙先生发表了他的原创性文章 Learning control systems: Review and outlook^[1]。为纪念这位学术领域内杰出的先驱,该文于 1986 年在 IEEE 的另一个学报再次出版。傅京孙先生在该文中回顾了 5 种学习控制方法:①基于模式识别的可训练控制器;②强化学习控制系统;③Bayes 估计;④随机逼近;⑤随机自动机模型。

在这么早的年代,能够从如此宽广的范围内定义学习控制系统确实令我们惊讶。傅京孙先生定义的学习控制系统的设计方法为:通过系统运行过程估计未知信息,然后基于被估计的信息设计最优控制器。这一四十多年前提出的设想与近年来对学习控制的理解不谋而合。

然而,四十多年来,学习控制的发展未能像几类主流控制方法那样取得显著成果,如线性二次型规划、自适应控制、模型预测控制、滑模控制及 H_∞ 控制等。学习控制发展缓慢的根本原因是值得讨论的,探索新的方法会推动学习控制的发展并带来突破。

根据文献[1],学习控制需要估计未知的信息。从系统控制的角度来讲,未知信息可被简要分为两类:过程模型的不确定性和外部环境的扰动,并且可以被进一步分为确定性的和随机性的。文献[1]中的 5 种学习控制方案主要针对随机的情况,这远比确定性的控制问题难度大且更富有挑战性,因为确定性问题研究的是确定的模型和确定性的未知信息。相比之下,过去四十多年间提出的许多先进控制方法针对的都是确定性控制问题。卡尔曼滤波器以处理随机因素而著称,尽管它针对的控制问题仅限于模型已知的线性系统,且随机因素仅限于均值为零、方差已知的白噪声。而文献[1]中的估计问题针对的是概率分布和密度函数已知的随机因素,学习过程在函数或函数空间中执行,而不是在实数空间中,这说明了随机控制问题的难度所在,也是傅京孙先生提出的学习控制方法发展缓慢的一个重要原因。

1. 确定性学习控制

相比于随机系统学习的缓慢发展,确定性学习控制成为系统控制的一种新方法。目前,两种确定性学习控制被广泛研究:迭代学习控制(ILC)和重复控制(RC)。ILC 和 RC 的基本思路是引入一个学习机制,当控制任务重复时,通过

学习来提高控制系统的性能,这类似人类的技能学习,如我们经过反复练习射击后可精确击中目标。

1984年,文献[2]提出它的学习机制是直接学习控制信号,而不是估计系统模型或环境扰动的未知信息,其学习律是

$$u_{i+1}(t) = u_i(t) + \gamma e_i(t) \quad (1)$$

式中, i 为迭代次数; t 为定义在一个有限区间 $[0, T]$ 上的时间因子; u 为控制信号; γ 为学习增益; $e_i(t)$ 为误差修正项。当控制任务重复执行时,ILC算法不断地在区间 $[0, T]$ 上更新控制信号,直到误差 $e_i(t)$ 消失,此时有 $u_{i+1}(t) = u_i(t)$,即实现了控制任务的控制信号被复制了。

当控制任务周期的运行时,重复学习^[3]以一种循环的方式更新控制信号,即

$$u(t) = u(t-T) + \gamma e(t) \quad (2)$$

式中, T 为控制任务的周期。与ILC相似,当误差 $e(t)$ 消失时, $u(t) = u(t-T)$,实现了控制任务的控制信号被复制了。

过去的二十多年,确定性学习控制得到了飞速发展,取得了显著成果,包括理论方面^[4]和应用方面^[5]。为进一步推动未来学习控制的研究,我们需要从系统控制的角度弄清楚两个基本问题:学习控制系统可以学到什么?执行一个学习控制过程需要什么?

2. 不变性原理

第一个基本问题的关键在于不变性原理,即确定性学习控制系统的可学习量在某一个拓扑下是不变的,这个量可能为空间的一个坐标,时间域的一个变量,频域内的一个相位图,几何空间的一个距离,特征空间的一个属性,函数空间的一个度量,或多个域和空间中的一个综合指标。从系统控制的角度来看,这个量可能为参考信号、环境扰动或过程模型不确定性等。

可学习量的不变性可以通过适当的映射或转化得到,如延迟一个和多个周期后周期信号可以视为时间不变,旋转机器转了 360° 以后回到原来的位置。有时,为了揭示潜在的不变性并辨识出不变量,这个映射是动态的,如混沌轨道可对应系统模型的时不变参数或初始状态值,此时,学习着眼于这些不变的未知量。

不变性原理与内模原理联系密切,后者指出参考信号和外部扰动均可以被一个固定的内模产生^[6]。于是,学习控制的目标为在控制环内建立内模。当内模结构已知而某些时不变参数未知时,学习的目标是估计这些未知参数。当内模结构未知但具有重复性特点时,ILC和RC可直接学习出一个合适的信号发生器(内模),产生任意形式的重复或周期信号。

最近提出了高阶内模的概念^[7]，参考信号在时域和迭代域上均不重复。对于线性离散时间系统，高阶内模 ILC 可以采用类似于离散时间系统 Z 变换的方法进行分析和设计。

与不变性原理相关的一些问题还有待解决。尽管确定性学习和不变性原理有着内在的联系，并在多种场合下得到研究，但讨论多停留在概念层次而非定量理论分析。高阶内模给出了学习控制处理非重复因素的一种方法，但许多问题有待解决，如多参数不确定性、控制输入系数不确定性、串级系统、基于状态估计的输出反馈、基函数已知但参数未知的高阶内模、基函数和参数仅部分已知的高阶内模，以及推广到离散时间非线性系统等。

3. 梯度信息

第二个基本问题的关键在于梯度信息。在许多学习方法中，包括神经元学习和迭代学习，系统的 Jacobi 矩阵或梯度信息起着重要的作用，即在更新控制输入时为学习机构提供了最大的下降方向。学习算法的收敛特性仅由梯度信息决定，如 ILC，知道了输入输出梯度信息的上下界就足够了。

当缺少过程模型信息导致梯度信息不可用时，一个解决办法是通过数据驱动算法计算梯度，如数值逼近法或插值法。另一方法是在学习率(1)或(2)中随机产生增益 γ ，这意味着梯度方向的随机估计^[8]。只要多次试行，学习按概率收敛，唯有学习效率会因梯度先验知识的缺失而降低。

一般而言，对于不同的学习控制问题，梯度信息是变化的，有时对于简单的线性过程也可能产生高度非线性的梯度信息，如瞬态性能与反馈增益间的梯度信息，此时，数据驱动算法是一种有力的解决工具。

4. 学习的多样性

有意思的是，文献[9]提出了一种针对随机过程的类似卡尔曼滤波的学习算法。当学习控制方法和随机系统控制方法已经变得更体系化，并成为处理含有未知信息的系统控制问题的强有力手段，学习算法^[9]的提出是必然的结果。从这个角度来看，文献[1]中的学习控制系统方案在那个时代提出的有些过早。

如前所述，即使对于某些确定性的学习控制任务，都需要利用随机算法寻找正确的梯度方向。确定性的学习控制(如 ILC 和 RC)都是模仿人的技能学习过程，实现驱动控制。从人的智能的角度讲，如何从知识中进行学习并应用于控制任务的协调和计划编制同样重要。知识学习与知识工程、知识表述和知识获取有着密切的联系。最近，强化学习被应用于机器人协调与控制^[10]。然而，系统控制和知识学习的整合有待进一步研究。

5. 系统控制中的机器学习

回顾文献[1]提出的5种学习控制方法,我们可以感受到计算机科学的强力影响。事实上,模式分类、强化学习、Bayes学习、随机逼近和自动机被认为是典型的机器学习和机器智能。过去四十多年,计算机科学的科研团体,而非系统控制团体,对这些方向进行了广泛深入的研究。

系统控制不同于机器学习的一个主要方面在于它要求闭环稳定性,这限制了机器学习方法与控制系统的直接结合。直到今天,最成功的结合当属神经网络控制和自适应神经网络控制。然而,当隐含层神经元权重需要由学习机构来调整时,仍然会遇到闭环稳定性的问题,因为这些权重相对于系统的状态和输出是非线性的。

大多数机器学习方法都是离线并且是有监督的学习,而学习控制方法期望在线工作并且是无监督的学习。随着微处理器技术的发展,计算能力不再是在线学习的瓶颈。因此,成熟的机器学习方法可以应用于闭环控制中,并产生出诸如文献[1]提出的5种学习控制方法。

控制器的设计和整定可以跟一个特征空间联系起来,特征选择可以定义在时域、频域、统计域或混合域内。特征选择过程中,信息冗余可以简化或消除,原始数据中的不准确数据也可被去除。通过搜索计算特征空间与控制行为空间的梯度信息,无监督的学习可以在线运行以提高控制性能。

值得说明的是,ILC算法是在两次不同的迭代过程之间离线更新控制信号,因此,可以采用高级的机器学习方法。一般来讲,机器学习方法可以辅助离线设计和控制器的整定。不同于学习控制方法,在过去的四十多年里,机器学习是计算机科学与工程中最活跃和发展最快的领域之一,而且绝大多数都是数据驱动方法。机器学习和系统控制的结合将为学习控制的进化或革命性的发展开辟一条新路。

参 考 文 献

- [1] Fu K S. Learning control systems: Review and outlook. IEEE Trans. on Automat. Contr., 1970, 15(2): 210—221.
- [2] Arimoto S, Kawamura H, et al. Bettering operation of robots by learning. Journal of Robotic Systems, 1984, 1(2): 123—140.
- [3] Hara S, Yamamoto Y, et al. Repetitive control system: A new type servo system for periodic exogenous signals. IEEE Trans. on Automat. Contr., 1988, 33(7): 659—668.
- [4] Xu J X, Tan Y. Linear and nonlinear iterative learning control. Lecture Notes in Control and

Information Sciences ,2003 .

- [5] Xu J X ,Panda S K ,et al .Real-Time Iterative Learning Control ;Design and Applications . Berlin ;Springer ,2009 .
- [6] Francis B A ,Wonham W M .The internal model principle of control theory .Automatica , 1976 ,12(5) ;457—465 .
- [7] Moore K L ,Chen Y Q ,et al .Iterative learning control ;A tutorial and big picture view . Proceedings of 45th IEEE Conference and Decision and Control ,2006 ;2352—2357 .
- [8] Spall J C .Introduction to Stochastic Search and Optimization .New York ;Wiley ,2003 .
- [9] Saab S S .On a discrete-time stochastic learning control algorithm .IEEE Trans .on Automat . Contr . ,2001 ,46(6) ;877—887 .
- [10] Wang Y ,de Silva C W .A machine-learning approach to multi-robot coordination .Engineering Applications of Artificial Intelligence ,2008 ,21(3) ;470—484 .

撰稿人：许建新

新加坡国立大学电气与计算机系

无线网络调度策略的稳定性及分布式实现

Stable Scheduling for Wireless Networks and Its Distributed Implementation

1. 背景介绍

本文所要阐述的问题原型为相互关联的排队系统的镇定问题,在过去 40 年受到广泛关注^[1]。排队的关联性由可同时允许服务的队列的子集描述。所谓排队的镇定问题,是指在系统有随机外部服务请求到达时如何设计调度策略,在最大化系统服务能力的同时保证系统内所有队列长度均值的有界。为了更清晰地阐述问题,我们以无线网络的调度问题为例。由于无线设备使用共享频谱进行通信,单个无线设备的行为将影响到整个网络的整体性能。如何设计行之有效的调度算法是保证整个无线网络通信性能的关键所在。

2. 问题描述

下面以图 1 为例介绍本文的科学问题。在 $[t, t+1]$ 期间有总共 $A_i(t)$ ($i \in \{1, 2, 3\}$) 的数据到达相应的发送端 S_i , 请求通过无线网络传给相应的接收端 R_i 。其中, 每个发送端产生新数据的平均期望速率为

$$\lim_{t \rightarrow \infty} \frac{1}{t} \sum_{i=0}^{t-1} E\{A_i(t)\} = X_i$$




图 1 无线网络调度问题示例

S.发送端; R.接收端; X_i .到达速率; C_i .服务速率; Q_i .队列长度

由于发送端使用共享的无线传输介质,位于 S_i 干扰域内的 R_i 在接收数据时将受到 S_i 的干扰。例如, S_1 与 S_2 因干扰关系产生关联,而 S_1 (或 S_3) 不对 R_3

(或 R_i) 的传输造成干扰, 所以, S_i 与 S_j 不具有关联性。为保证每一次传输是可靠的, 有必要合理安排相互干扰的发送端的传输时刻, 而未被安排传输的数据将被置于相应缓冲区等待下一次调度机会。相应缓冲区内队列 Q_i 变化用下式描述:

$$Q_i(t+1) = \max\{Q_i(t) - \mu_i I_{\{\sigma_i=1\}}, 0\} + A_i(t) \quad (1)$$

如果链路 i 被调度允许传输, $\mu_i(t)$ 为当前时刻链路 i (由 S_i 到 R_i) 的服务速率, 具体数值依赖时变信道状态, 否则, $\mu_i(t) = 0$, 其均值期望为

$$\lim_{t \rightarrow \infty} \frac{1}{t} \sum_{\tau=0}^{t-1} E\{\mu_i(\tau)\} = C_i$$

如果 $\sigma_i = 1$, 则指示函数 $I_{\{\sigma_i=1\}} = 1$, 否则, $I_{\{\sigma_i=1\}} = 0$, 其中的调度策略 $\sigma = [\sigma_i]$ 除了要合理安排相互干扰链路的传输时隙以避免冲突, 还要镇定系统缓冲区内的队列。

定义 1^[2] 一类排队系统 $\{Q_i(t)\}$ 如满足下式, 被称作具有强稳定性 (strong stability)。

$$\limsup_{t \rightarrow \infty} \frac{1}{t} \sum_{i=1}^{\tau-1} E\{Q_i(\tau)\} < \infty \quad (2)$$

针对无线网络这类排队系统设计调度算法, 同时保证系统稳定与资源有效利用, 其难点在于: ①实际网络系统中, $[X_i]$ 与 $[C_i]$ 无法精确已知, 因此, 保证排队系统强稳定的充分和必要条件^[2]无法直接验证; ②满足镇定队列、资源有效利用的调度算法必须是简单的、分布式的、无记忆的策略。

3. 调度算法

与图 1 相关的调度算法的寻找等价于求解一类组合优化问题, 即

$$\begin{aligned} & \max_{\sigma} \sum_i Q_i(t) \mu_i(t) \\ \text{subject to} & \begin{cases} \sigma_i \in \{0, 1\}, & \forall i \\ \sigma_i \sigma_j = 0, & i \text{ 干扰 } j \end{cases} \end{aligned} \quad (3)$$

这一问题被称作权重最大化的匹配问题 (MWM)。现有结果证明, 基于 MWM 问题的调度可以同时镇定网络队列, 实现资源的有效利用^[2,3]。MWM 问题对应于在一个有限集合中寻找一个互不相关的子集, 使其中元素能够最大化 $\sum_i Q_i(t) \mu_i(t)$, 该问题被证明是 NP 完全的^[2,3], 求解过程具有指数复杂度, 这进一步加深了设计分布式调度算法的难度。

目前, 研究结果主要围绕提出简单而又行之有效的分布式次优解, 来逼近问题 (3) 的集中式解。其中, 贪婪极大调度 (greedy maximal scheduling) 就是这样一类调度算法^[4]。然而, 其实现过程需要不具备通信关系的节点间交换 $Q_i(t) \mu_i(t)$ 信

息以寻找具有最大乘积的链路,给算法实现带来额外开销。

有别于确定性调度算法,随机接入方式是另一类可以分布式逼近问题(3)的解的一类算法。最近,人们发现节点接入概率可以基于局部队列信息自适应调整,同时达到镇定队列、降低冲突的目的^[5]。这类算法,网络节点接入概率取决于局部队列长度,而节点接入概率影响链路服务速率,从而影响队列动态演变,这种相互作用致使其成为一个关联系统,其网络镇定问题归结为寻找合适的 Lyapunov 函数刻画该关联系统的稳定性。目前,结果大多集中在假设式(1)中的 μ (链路物理带宽,受信道状态影响)为常值。在时变链路速率情况下的基于队列的随机接入算法及其稳定性还未被人们解决。

4. 未来研究方向

(1) 基于队列的随机接入方式是分布式调度算法的发展趋势之一。如何设计快速或者有限时间内收敛算法是这类问题值得研究的一个未来方向。

(2) 无线网络服务速率 $\mu(t)$ 受时变信道状态影响,目前结果假设信道状态实时可知^[2],而实际信道状态的获取依赖从接收端到发送端的反馈,这一过程存在时延,且反馈信道是不可靠的,基于滞后、非精确信道状态信息的分布式调度是另一个可能的研究方向。

(3) 在某些应用场合,如工业现场,不仅仅要求调度算法的收敛性,更强调实时性和可靠性。如式(1)的队列增长仅由外部数据的随机到达引起,忽略了信道的不可靠导致数据接收失败进而产生的重传数据,而重传数据同样会引起队列增长。一方面,数据重传可以提高可靠性,同时增加队列长度,进一步增加的队列可以提高被调度的概率;另一方面,增加的队列却引起额外的排队时延。因此,考虑重传的分布式调度是值得探讨的一个科学问题。

参 考 文 献

- [1] Rajagopalan S, Shah D, Shin J. Network adiabatic theorem: An efficient randomized protocol for contention resolution // Proceedings of ACM Sigmetrics/Performance, Seattle, 2009: 133—144.
- [2] Georgiadis L, Neely M J, Tassiulas L. Resource allocation and cross-layer control in wireless networks. Foundations and Trends in Networking, 2006, 1(1): 1—144.
- [3] Tassiulas L, Ephremides A. Stability properties of constrained queueing systems and scheduling policies for maximum throughput in multihop radio network. IEEE Trans. on Automat. Contr., 1992, (37): 1936—1949.
- [4] Wu X, Srikant R, Perkins J R. Scheduling efficiency of distributed greedy scheduling algorithms in wireless networks. IEEE Transactions on Mobile Computing, 2007, 6(6): 595—

605 .

- [5] Chen M ,Liew S ,Shao Z ,et al .Markov approximation for combinatorial network optimization//Proceedings of Infocom ,San Diego ,2010:1—9 .

撰稿人：关新平 杨 博
上海交通大学自动化系

卫星姿态系统相平面控制的稳定性分析

Stability Analysis of Phase Plane Control for Satellite Attitude Systems

1. 概述

相平面法是一种求解一阶和二阶常微分方程的图解法^[1]。

相平面控制方法是：将被控对象输出偏差及其变化率组成的相平面分成不同的区域，根据不同区域相轨迹的运动特点设计不同的控制律以实现控制目标。分区不同、控制律不同，对应的相平面控制方法也不同。

由于相平面控制对控制对象要求不严格，鲁棒性好，抗干扰能力强，因此，在工业控制及航天器姿态控制中有很广泛的应用。

尽管在工程实际当中已有很多应用，但由于相平面控制是非线性控制，利用相平面控制的控制系统稳定性分析问题却一直是控制领域的一个难题。如果能够解决该问题，则对工业控制，特别是航天器的控制具有重要的理论意义。

2. 相平面控制

二阶非线性系统的运动可描述为

$$\ddot{x}(t) = f(\dot{x}(t), x(t)) \quad (1)$$

以 $\dot{x}$ 为纵轴， x 为横轴，构成一个平面称之为相平面。系统运动时， $\dot{x}(t)$ 、 $x(t)$ 以 t 为参变量在相平面上描述出的轨迹称为相轨迹^[2]。

下面以航天器小推力姿态控制^[3]为例，对相平面控制方法的设计思路进行介绍。

对于对地三轴稳定的卫星，以俯仰姿态为例，对象模型可近似表述为

$$I_y \ddot{\theta} = L_{cy} + L_{dy} \quad (2)$$

式中， I_y 为俯仰轴转动惯量； L_{cy} 为俯仰轴控制力矩； L_{dy} 为俯仰轴干扰力矩。

施加比例加微分控制，可以得到以下闭环控制系统，如图 1 所示。

姿态稳定控制问题描述为：对任意给定的初始状态 $\theta(t_0)$ 和 $\dot{\theta}(t_0)$ ，选择适当的控制力矩，使得 θ 和 $\dot{\theta}$ 趋于零。

当推力器推力为常值并无时延，不考虑测量误差和干扰力矩时，可以得到如下相轨迹^[3]，如图 2 所示。




图1 带施密特触发器的单轴喷气姿态稳定控制系统框图




图2 带有施密特触发器的比例加微分姿态控制系统相轨迹

显然，相轨迹最终会收敛到极限环 $HIJK$ ，极限环内不施加控制，称为死区，极限环的形状表征了控制精度。

工程上，通过直接设计与图2类似的开关线，可将相平面分成不同的区域，对于不同的区域，根据相轨迹的特点分档设计控制量的大小，进而得到相应的相平面控制规律。

3. 相平面控制的稳定性分析

相平面法只能用来分析一维二阶系统在初始条件下或在一些特殊的外作用下的运动。在对非线性对象进行相平面分析时，可以根据相曲线的奇点(即平衡点)附近的曲线走向判定平衡点的稳定性。另外，极限环是非线性系统的特有性质，表征着即使系统不受外扰，也会呈现等幅震荡运动，从极限环的曲线走向可以判定极限环的稳定性。基于相平面分析的控制器设计本质上就是通过设计控制器，使得系统的相曲线在可能的初始条件下趋向稳定奇点或稳定极限环。可见，在利用相平面分析进行控制器设计的同时，就已经对系统的稳定性进行了分析。

如果是三阶系统，相应的要用三个变量 x 、 $\dot{x}$ 和 $\ddot{x}$ 才能完全描述系统的运

动,此时,相轨迹就必须描绘在 x 、 $\dot{x}$ 和 $\ddot{x}$ 所组成的三维空间中。因此,确定相空间的相轨迹比相平面的相轨迹要复杂和困难得多,而三阶以上系统的相轨迹就更不可能给出形象的描述。因而,要利用相平面法对高阶系统进行分析是非常困难的。

实际系统多为多维系统,利用相平面分析进行控制器设计时,需要首先对系统进行状态解耦简化。例如,航天器姿态控制中,就在小角度情况下对三轴的姿态运动进行近似解耦以方便处理。虽然针对解耦系统所设计的控制系统可以是稳定的,但实际系统却可能由于状态间的耦合作用而不稳定。另外,相平面控制是典型的非线性控制,不论系统是线性还是非线性,整个闭环系统都呈现非线性。所以,对相平面控制系统进行稳定性分析是非常必要的,同时也是非常困难的。目前,相平面控制在包括航天器姿态控制在内的实际工程中被广泛应用,但有关相平面控制系统稳定性分析还没有提出具有普遍意义的分析方法,通常只能根据具体系统,利用描述函数法^[4]及 Lyapunov 第二法^[5]等常用的非线性系统稳定性分析手段进行试探分析。

参 考 文 献

- [1] 蒋大明,戴胜华.自动控制原理.北京:北方交通大学出版社,2003:249—257.
- [2] 吴麒.自动控制原理.下册.北京:清华大学出版社,1992:272.
- [3] 屠善澄.卫星姿态动力学与控制.北京:宇航出版社,2001:426—434.
- [4] 胡寿松.自动控制原理.第3版.北京:国防工业出版社,1994:428—437.
- [5] 郑大钟.线性系统理论.北京:清华大学出版社,2003:224—228.

撰稿人:解永春 刘 涛

中国空间技术研究院北京控制工程研究所

复杂卫星姿态动力学建模和甚高精度姿态控制

Attitude Dynamics Modelling and Ultra-high Precise Control for Spacecraft

目前,世界上先进的光学成像卫星需要达到非常高的控制水平,从1990年发射的哈勃太空望远镜的指标可见一斑:控制系统指向精度为 $0.01''$,姿态稳定度在长达数小时的时间范围内镜像稳定在焦面的误差不超过 $0.007''$ ^[1]。这类卫星是典型的复杂卫星,承载着大型载荷、大面积帆板、大量液体燃料和多个运动部件。随着甚高精度性能指标的提出,原来忽略的因素、可以回避的因素现在凸现出来。低精度卫星可以忽略的一些物理运动特性,如高速旋转部件引起的抖动、帆板和天线等挠性部件的细微振动、充液晃动、姿态控制基准与有效载荷基准的相对形变,现在必须考虑;低精度卫星可以简化的控制对象特性,如燃料消耗、多体运动、部件电性能变化、未建模动态等导致的变结构变参数不确定特性,多体动力学、驱动间隙回滞、摩擦等非线性特性,现在必须全面考虑。卫星甚高精度的指标要求对姿态控制提出了新的问题和挑战,从哈勃太空望远镜在轨问题的研究状况^[1]和新型先进卫星的研究情况来看^[2,3],航天发达国家尚未系统解决且正在致力于解决复杂卫星甚高精度姿态控制问题。

复杂卫星甚高精度姿态控制问题的主要难点是:一是考虑复杂卫星结构参数变化与诸多不确定因素的强适应控制;二是削弱结构振动、抖动的分布式控制。这些都是卫星甚高精度控制必须解决而目前尚无系统解决方法的问题,也是卫星控制领域甚至控制学科的基础性科学问题。

在甚高精度姿态控制的理论和方法研究上,美国处于领先地位,一些主要研究机构和大学均在积极拓展这方面的研究成果^[4,5]。哈勃太空望远镜的补救过程耗资巨大,促使美国投入了新一轮的甚高精度姿态控制的研究,如在轨辨识试验、分布式控制与自适应控制试验、高频抖动机理和控制理论研究等,使得美国NASA积累并掌握了先进控制理论和方法在解决实际工程问题、达到甚高精度控制方面的大量知识。目前,美国正在研制哈勃太空望远镜的后继星(JWST),采用可展开光学系统,应用分布式振动传感器,借助主动振动控制,预期将成像分辨率提高一个数量级。

要解决复杂卫星甚高精度姿态控制问题需要具体研究以下问题:

(1) 甚高精度分布式姿态测量。复杂卫星的甚高精度姿态测量受到姿态敏感器的现状水平和卫星结构形变等因素的制约,需要探索提高姿态敏感器部件

精度的机理、新的姿态测量途径和信息处理方法。

(2) 变结构变参数不确定系统的强适应控制。强适应控制应能有效克服结构参数变化与不确定性,提高控制系统对外部环境、本体结构变化的适应能力^[6]。强适应控制主要包括控制建模与控制律设计问题:①控制建模要实时建立反映实际系统特征且能降低控制器复杂程度的模型,从而适应甚高精度、甚高稳定度的实时控制要求;②强适应控制需要采用智能自适应控制方法以有效克服结构参数变化与不确定性,实现系统稳态性能和动态响应要求,提高复杂卫星的快速机动能力与指向控制精度。

(3) 非线性振动及控制。复杂卫星运行过程中存在着由挠性结构热冲击、间隙、不平稳引起的非线性振动和充液晃动动力学呈现的强非线性特性。要研究振动主动控制方法,包括高阶系统的低阶鲁棒控制器设计、结构振动与内部运动体耦合控制系统的稳定性和鲁棒性分析等。

(4) 多目标分布式协调控制。卫星高频抖动与本体振动、传播与控制呈分散和分布式的特点,分布参数理论和分布式控制有别于传统的卫星集中参数控制,是甚高精度控制需要研究的一个基础问题。此外,控制系统必须考虑星体指向控制、不同分布的高频振动源的消振、挠性振动的抑制等多目标协调控制。

参 考 文 献

- [1] Bukley A P. Hubble space telescope pointing control system design improvement study results. J. Guidance, Control and Dynamics, 1995, 18(2).
- [2] Damilano P. Pleiades high resolution satellite: A solution for military and civilian needs in metric-class optical observation. 15th Annual/USU Conference on Small Satellites, 2001.
- [3] Somov Y I, Butyrin S A, et al. Ultra-precision attitude control of a large low-orbital space telescope. Control Engineering Practice, 1999, (7): 1127—1142.
- [4] Leitner J, Beck J, Bell K. Advanced guidance, navigation, and control for remote sensing. AIAA, 1997.
- [5] Agrawal B. Jitter control for imaging spacecraft. IEL-5158266, 2009.
- [6] 吴宏鑫, 胡军, 解永春. 基于特征模型的智能自适应控制. 北京: 中国科学技术出版社, 2009.

撰稿人: 刘一武

中国空间技术研究院北京控制工程研究所

平流层飞艇大范围变参数与多场耦合的控制^①

Control of Stratosphere Airship with Wide Range Variable Parameters and Coupling of Multiphysics

1. 背景介绍

迄今为止,所有实用的飞艇都还只能在几千米以下的低空作短暂的飞行。能否让飞艇飞得更高和更久呢? Khoury 与 Gillett^[1]明确地提出了平流层太阳能飞艇的基本概念(如图 1 所示)。




图 1 平流层太阳能飞艇示意图

实际上,平流层基本气候条件相对平稳,非常利于飞艇悬停^[2],它可以对卫星和飞机的功能进行延伸和补充,显著地提升现有航空航天格局。正是由于其诱人的潜在应用前景,人们竞相开展平流层飞艇的开发^[3,4]。

2. 问题描述

在把平流层飞艇潜在应用的美好憧憬变成客观现实之前,有两个重要的问题必须解决:第一,如何才能上得去、回得来?第二,如何确保在平流层留空期间为有效载荷高性能工作提供满意的航迹、平稳的姿态和精准的指向?这给控制科学与技术领域带来一系列难题。

与卫星、飞机等不同,平流层飞艇在本质上为浮空器,它是靠浮力来平衡重力的。经验数据表明,在平流层底部海拔 20km 高度和顶部 50km 高度的大气密度、单位体积所产生的浮力都分别是海平面的 1/14 和 1/1189^[5],因此,平流

^① 国家自然科学基金资助项目(11072028)。

层飞艇上升/下降阶段的质量变化程度将比卫星、飞机和潜艇提高 1~3 个数量级。

同时,平流层飞艇的巨型蒙皮为柔性结构,外部大气绕流场作用下会引起蒙皮结构弹性变形,从地面到平流层的飞行环境中,风场的变化将进一步加剧流固耦合的程度。飞行高度和日夜温差的改变导致环境温度变化对艇体产生外部热辐射,加之内部热对流^[6],直接影响内部气体的密度、压力和飞艇质量发生变化。

因此,平流层飞艇给控制科学与技术带来的新问题可以归结为:①质量惯量参数大范围变化所带来的控制难题;②温度场、风场、流场等多物理场与结构之间的高度耦合所带来的控制难题。

文献[7]针对平流层飞艇给出矩阵形式的非线性耦合动力学模型,即

$$\begin{bmatrix} m \underline{E} & -m \underline{P}_c^\times \\ m \underline{P}_c^\times & \underline{I} \end{bmatrix} \begin{bmatrix} \dot{\underline{Y}} \\ \dot{\underline{\omega}} \end{bmatrix} + \begin{bmatrix} m(\underline{\omega}^\times \dot{\underline{Y}} + \underline{\omega}^\times \underline{\omega}^\times \underline{P}_c) \\ \underline{\omega}^\times \underline{I} \underline{\omega} + m \underline{P}_c^\times \underline{\omega}^\times \underline{V} \end{bmatrix} = \begin{bmatrix} \underline{F}^b \\ \underline{T}^b \end{bmatrix} \quad (1)$$

式中,等号左边 m , $\underline{I}$ 分别为飞艇的质量和相对质心的惯量矩阵; $\underline{P}_c$ 为质心在飞艇体积中心坐标系 $\mathcal{E}^b$ 的位置向量列阵; $\underline{V}$, $\underline{\omega}$ 为航迹速度和角速度在 $\mathcal{E}^b$ 的向量列阵;上标“ $\times$ ”为列阵相应的叉乘矩阵;等号右边 $\underline{F}^b$, $\underline{T}^b$ 综合了重力、浮力、推力、外部流体动力的黏性项和惯性项所产生的力与力矩作用。

运动学方程组为

$$\begin{cases} \dot{\underline{P}} = (\underline{R}^{br})^{-1} \underline{V} \\ \dot{\underline{A}} = \underline{S} \underline{\omega} \end{cases} \quad (2)$$

式中, $\underline{P}$ 为飞艇体积中心相对地面参考系 $\mathcal{E}^r$ 的位置在系 $\mathcal{E}^b$ 的向量列阵; $\underline{A} = [\phi \ 0 \ \Psi]^\top$ 表示系 $\mathcal{E}^{br}$ 相对系 $\mathcal{E}^r$ 的姿态列阵; $\underline{R}^{br}$ 为从系 $\mathcal{E}^r$ 到系 $\mathcal{E}^b$ 的坐标变换矩阵; $\underline{S}$ 为角速度变换矩阵。

将式(1)、式(2)合并可以得到非线性矩阵方程为

$$\dot{\underline{X}} = f(\underline{X}, \underline{U})^\top \quad (3)$$

式中, $\underline{X}$ 为由航迹、Euler 姿态角、航迹速度、角速度构成的 12 维状态向量列阵; $\underline{U}$ 为控制输入向量列阵。

然而,上述模型将质量和惯量矩阵当做常量及常量矩阵,并将巨型柔性飞艇简化为刚体,忽略了弹性变形,也没有考虑温度场、风场、流场等多物理场同结构之间的高度耦合。

3. 必要说明

尝试进一步考虑内部气体介质的流动与传热传质, 假设控制体(每个内部气囊)内气体介质存在对流, 则可得到关于压力 p , 温度 T , 密度 ρ , 速度势 $U=ui+vj+wk$ 共 6 个未知数的 6 个方程。需要将这些方程同式(3)联立求解, 研究多物理场高度耦合和质量惯量参数大范围变化对系统动态特性的影响, 确定不确定性的特征与程度, 探讨适当的控制理论和方法, 以实现相应的控制目标。

4. 相关扩展

内部气囊气体工质的排出或吸收, 其目的不仅是进行上升/下降阶段高度控制, 同时, 也是控制飞艇内部压力适当大于外部大气压力以保持艇体的气动外形, 但又不至于太大以免将蒙皮撑破; 而在质量传递过程中, 外界温度变化将使飞艇发生热量传递, 导致参数变化情况更加复杂, 这种大范围变参数特点是如何影响飞艇上升/下降的高度变化、艇体内部温度变化^[7]和艇内外压差变化的?

放飞和返回过程, 平流层飞艇必须穿越环境条件恶劣的对流层, 风场干扰给上升/下降控制造成巨大的挑战^[5]。海拔 3~13km 是飞机频繁穿梭的空域, 需要规避不同拥挤程度的交通障碍。更有甚者, 大范围变密度绕流场与巨型飞艇结构变形之间存在复杂的动态耦合作用^[6], 如何根据耦合影响的动力学机理分析制订出合理的操纵策略, 以实现高度与温度、压差协调控制的目标?

对返回控制, 需要引起更大关注的问题是: 与放飞控制可以把飞艇上升到平流层期望高度的大范围适当位置不同, 返回控制还必须控制到固定的目标位置(一般为艇库广场), 给控制带来新的难题。

对于平流层留空期间的控制^[8]难点在于: 尽管平流层环境相对平稳, 仍有低速脉动风场的干扰影响; 同时, 太阳照射角度变化和日夜温差对飞艇的位置运动造成一定影响, 初步研究表明, 日夜温差可以引起平流层飞艇驻空高度上下变化 2km。因此, 如何进行艇体航迹控制以满足期望的定点和机动目标要求, 乃是留空期间控制的第一个基本问题。其次, 留空期间, 平流层飞艇具有数十吨的重量和几十万立方米以上量级的体积, 带有显著的大惯性特点, 与许多其他运动体相比明显存在干扰影响大、控制作用小的问题, 如何将其控制到平稳的姿态和精准的指向, 是留空期间控制另一个必须攻克科学难题。

参 考 文 献

- [1] Khoury G A, Gillett J D. Airship Technology. Cambridge: Cambridge University Press,

1999.

- [2] Toshitaka T, Takashi A. Effects of meteorological condition the operation of a stratospheric platform // The 3rd Stratospheric Platform System Workshop, Tokyo, 2001.
- [3] Nayler A. Airship activity and development world-wide-2003. AIAA, 2003.
- [4] Colozza A, Dolce J L. High altitude long endurance airships for coastal surveillance. NASA-TM-2005-213427, 2005.
- [5] 中华人民共和国国家军用标准. 北半球标准大气(−2~80公里). 国防科学技术工业委员会, 1987.
- [6] Bessert N, Frederich O. Nonlinear airship aero-elasticity. Journal of Fluid and Structures, 2005, 21: 731—742.
- [7] Henze M, Weigand B, Jens V W. Natural convection inside airship. AIAA, 2006.
- [8] Schmidt D K. Dynamic modeling of control and station-keeping guidance of a large high altitude near space airship. AIAA, 2006.

撰稿人：李智斌¹ 岳宝增²

1 中国空间技术研究院北京控制工程研究所

2 北京理工大学宇航学院

飞行器 PID 控制的实用稳定性

Practical Stability of Flight Vehicles with PID Controller

1. 背景介绍

PID 控制器自产生以来,一直是工业生产过程中应用最广,也是最成熟的控制器。PID 控制是指误差反馈律^[1]

$$u = k_1 e + k_2 \dot{e} + k_3 \int_0^t e(\tau) d\tau, \quad e = y_0 - y \quad (1)$$

式中, y_0 和 y 分别表示设定值和系统的输出; $k_i (i=1,2,3)$ 为待设计参数。尽管在控制领域,各种新型控制器不断涌现,但 PID 控制器还是以其结构简单、易实现、鲁棒性强等优点处于主导地位,广泛应用于冶金、化工、电力、轻工、机械和航空航天领域中。目前,世界上在用的闭环控制系统中超过 97% 都包含有 PID(PI)控制回路^[1]。最近 10 年, PID 控制器重新受到控制理论学界的关注^[2~4]。国际著名控制理论学者 Astrom 对 PID 控制的未来加以展望,认为 PID 控制在未来的控制工程中仍将扮演重要的角色,同时也将成为更为复杂控制器的基本单元^[2]。

2. 问题描述

Lyapunov 稳定性已被广大学者所接受,并得到了很好的研究。但是,在许多实际系统中,常常是虽然系统并不渐近稳定,可系统的振动对于所要求的性能指标而言仍然是可接受的。为了处理这种情形, LaSalle 和 Lefschetz 在文献 [5] 中引入了实用稳定性的概念。考虑未受扰动的系统及其相应的结构扰动系统^[6]

$$\begin{cases} \frac{dx}{dt} = f(t, x), & f(t, 0) \equiv 0, f \in C[I \times \mathbf{R}^n, \mathbf{R}^n] \\ \frac{dy}{dt} = f(t, y) + p(t, y), & p \in C[I \times \mathbf{R}^n, \mathbf{R}^n] \end{cases} \quad (2)$$

(3)

式中, $I \stackrel{\text{def}}{=} [0, +\infty]$, $C[I \times \mathbf{R}^n, \mathbf{R}^n]$ 表示定义在 $[I \times \mathbf{R}^n, \mathbf{R}^n]$ 上的连续函数。任意给定正数 $\delta > 0$ 及两个集合 Q 与 Q_0 , 其中, Q 是含原点的有界闭集, Q_0 是 Q 的子集, 对于 $\forall y_0 \in Q_0$, $t_0 \geq 0$ 和 $\forall p(t, y) \in P \stackrel{\text{def}}{=} \{p(t, y), \|p(t, y)\| < \delta\}$, 如果式(3)

的解 $y(t, t_0, y_0) \in Q(t \geq t_0)$, 则称式(3)的零解关于 δ, Q, Q_0 为实用稳定的。Lakshmikantham 等在文献[7]中通过实例证明了实用稳定性能更好地适用于现实世界中的具体问题。相对于经典的 Lyapunov 稳定性理论, 实用稳定性概念不仅能够定性地而且能够定量地刻画系统行为, 具有较强的实用性。

基于上述, 本文所提问题可以描述如下: 针对带有挠性附件和液体晃动的飞行器动力学模型, 在式(1)的控制下, 闭环系统的实用稳定性问题。

由于实际被控对象的复杂性, 一般来说, 其稳定性是通过大量数学仿真来验证的。在理论上, 对于 PID 控制的稳定性和暂态性能的研究均是基于二阶系统的^[8]。但是, 实际系统要复杂得多。例如, 飞行器动力学是高阶系统; 充液挠性航天器属于偏微分系统; 参数调节控制属于切换控制的研究范畴等。因此, 在 PID 控制下复杂被控对象的闭环性能的理论证明一直是困扰我们的一个难题。特别是, 迄今为止飞行器 PID 控制的实用稳定性研究未见有结果发表, 对该问题的深入研究和解决将对控制理论和控制工程产生深远的影响, 并且具有现实的科学意义。

3. 相关扩展

自适应 PID 是 PID 控制的重要分支之一, 其稳定性研究也得到了很大关注, 但现有理论结果主要是针对二阶动力学模型给出的。那么, 针对高阶系统, 在自适应 PID 控制下, 系统的实用稳定性问题也是值得探讨的一个问题。实际中, 系统的控制是由计算机控制来实现的。因此, 在 PID 控制下, 采样控制系统的实用稳定性问题是一个更为接近实际而重要的问题, 该问题未见有文献发表。

参 考 文 献

- [1] 黄友锐, 曲立国. PID 控制器参数整定与实现. 北京: 科学出版社, 2009.
- [2] Astrom K J, Hagglund T. The future of PID control. Control Engineering Practice, 2001, 9(11): 1163—1175.
- [3] Soylemez M T, Munro N, Baki H. Fast calculation of stabilizing PID controllers. Automatica, 2003, 39(1): 121—126.
- [4] Bajcinca N. Design of robust PID controller using decoupling at singular frequencies. Automatica, 2006, 42(11): 1943—1949.
- [5] LaSalle J P, Lefschetz S. Stability by Liapunov's Direct Method with Applications. New York: Academic Press, 1961.
- [6] 廖晓昕. 动力系统的稳定性理论和应用. 北京: 国防工业出版社, 2000.
- [7] Lakshmikantham V, Leela S, Martynyuk A A. Practical Stability of Nonlinear Systems.

Singapore:World Scientific,1990.

- [8] Poulin E,Pomerleau A,Desbiens A,et al.Development and evaluation of an auto-tuning and Adaptive PID controller .Automatica,1996,32(1):71—82.

撰稿人：孟 斌

中国空间技术研究院北京控制工程研究所

在轨闭环参数辨识

On-orbit Closed-loop Parameter Identification

1. 背景介绍

高分辨率对地观测卫星对姿态与轨道控制精度有极高的要求。随着 21 世纪卫星应用的商业化和军事化趋势进一步加强,常需要卫星快速、自主、精确地完成空间捕获、释放、交会和对接等各种复杂任务。卫星在执行任务受到结构不对称性、燃料晃动、内部的部件运动等条件的限制,从而给系统带来严重的不确定性与非线性,这就使得高精度姿态/轨道控制技术成为卫星能够顺利完成指定任务的重要技术保障。鲁棒自适应控制是实现上述控制目标的有效控制手段之一,而在轨参数辨识是其中非常重要的一个环节。

2. 问题描述

在轨辨识是指利用在轨飞行数据建立系统数学模型的过程。这里,系统数学模型既包括航天器动力学的数学模型,也包括反映敏感器与执行机构输入输出特性的数学模型。在轨飞行数据一般指卫星控制系统有关的测量数据,包括执行机构的输出(系统输入)数据和敏感器的输出(系统输出)数据。

本文所提出的问题可如下描述:针对带有挠性附件和液体晃动的非线性复杂航天器动力学的闭环辨识问题。

3. 航天器在轨辨识

航天器在轨辨识有两个研究方向:控制模型辨识和模态参数辨识^[1~3]。在轨辨识是系统辨识在飞行器上的一个具体应用。一方面,它应当遵循系统辨识一般步骤;另一方面,它具有其他系统辨识所没有的一些特殊困难。

(1) 输入设计。执行机构激振问题。在轨辨识通常只能利用飞行器本身已有控制系统的执行机构产生激励信号。执行机构一般包括姿态控制和轨道控制用推力器和反作用飞轮,而激励信号一般采用正弦扫描、随机激振信号或者某些固定脉冲信号。上述执行机构和激振信号对于在轨辨识而言一般不是最佳设计,因为它们不能激励所有振动模态。

(2) 输出设计。敏感器测量噪声问题。在轨辨识通常只能利用星载系统配置的观测敏感器产生输出信号。陀螺、红外地平仪、太阳敏感器和星敏感器是

姿态测量的重要敏感器,相应输出信号一般包括姿态角和姿态角速率,这里,角速率可以利用(速率积分)陀螺的输出直接给出,而姿态角一般可以通过红外地平仪、太阳敏感器(或星敏感器)和姿态确定算法给出。陀螺的输出一般具有快速更新周期,红外地平仪、太阳敏感器和星敏感器的输出一般更新速率较慢。通常,利用光学姿态敏感器的姿态输出校正(慢速校正)陀螺漂移,而利用陀螺输出积分补齐采样点上的姿态角。这样,姿态角速率和姿态角都能以较快采样周期给出。此外,加速度计也是卫星上可以有效利用的敏感器,在加速度输出信息中包括了许多高阶振型的模态信息。与执行机构配置类似,上述敏感器的配置对于辨识而言一般也不是最佳的。此外,敏感器的测量噪声也是制约在轨辨识的一个重要因素。

(3) 输入输出数据的小样本问题。在轨辨识的输入输出数据的产生有两种途径:其一,利用在轨主动激励。这时,执行机构产生专门用于在轨辨识的激励信号,相应地测量卫星动力学的输入输出数据。这种情形要特别注意卫星姿态不能够失去基准,否则,卫星上的敏感器(如红外地平仪)可能失效、卫星动力学可能失去稳定性(某些模态被过度激励引发整星强烈共振)。因此,主动激励一般只能持续较短时间。换言之,用于在轨辨识的测量数据很短,输入输出数据的样本是小样本。其二,利用卫星正常飞行的输入输出数据。这时,卫星通常的稳态输出一般只能包括外部干扰和系统某些不稳定模态的信息,系统在轨辨识的输入输出数据尽管可以是长期的,但对于在轨辨识系统动力学(精确确定某些挠性模态)而言,系统的输入输出数据不是完备的。因此,可以利用卫星正常操作的某些输入输出数据作为在轨辨识的样本,如卫星帆板展开、卫星飞轮卸载、静止轨道卫星的轨道保持等,但这些数据通常只能持续几分钟或十几分钟。因此,在轨辨识的样本是小样本。

4. 必要说明

高性能复杂卫星的复杂性主要体现在两方面:复杂卫星动力学本身是一个维数甚高(理论上有无穷维)的多体系统;卫星运行环境诱导的干扰对卫星动力学有时有着不可忽略的影响。因此,复杂卫星动力学的在轨辨识应当充分考虑其动力学复杂性问题。开环辨识算法相对较为丰富和完善,在轨辨识也主要在开环状态下进行。但开环条件(切断控制器)下的在轨辨识需要注意输入信号的大小,并设定安全控制监控机制,以保证辨识过程中卫星姿态保持在一定范围;而且在某些情况下,如开环不稳定的系统,或者控制回路无法切断的情形,不能进行开环辨识。为此,在轨辨识更希望在闭环条件下进行。但闭环辨识的困难在于:由于反馈回路的存在,系统噪声和测量噪声(白噪声或有色噪声)与输入输出信号可能是相关的,因而噪声的影响难以消除。因此,许多在开环下可

以成功应用的辨识算法,在闭环下不再适用;并且当今在轨参数辨识问题都是在一定假设下进行研究的,较实用还有一定距离^[4,5]。因此,针对带有挠性附件和液体晃动的非线性复杂航天器动力学的闭环辨识问题有待进一步研究,该问题的深入和解决将对控制理论和控制工程产生深远的影响,并且具有现实的科学意义。

参 考 文 献

- [1] Juang J N .Applied System Identification .New York ;Prentice Hall ,1994 .
- [2] Cohen L .Time-Frequency Analysis ;Theory and Applications .New York ;Prentice Hall ,1995 .
- [3] Ljung L .System Identification ;Theory for the User .New York ;Prentice Hall ,1999 .
- [4] Ma O ,Dang H .On-orbit identification of inertia properties of spacecraft using a robotic arm .J.Guidance,Control and Dynamics ,2008 ,31(6) :1761—1771 .
- [5] Lane S A ,Lacy S L ,Babuska V ,et al .Correlation and error metrics for plant identification of on-orbit space structure .Journal of Spacecraft and Rockets ,2007 ,44(3) :710—721 .

撰稿人：孟 斌 黎 康

中国空间技术研究院北京控制工程研究所

飞行器的非最小相位控制问题

The Non-minimum Phase Control Problem of Aircraft

1. 背景介绍

无论是在工业过程控制中,还是在导弹、飞机乃至具有更高飞行速度的航空航天飞行器控制中,都存在着一种严重影响控制效果的因素——非最小相位问题。例如,在锅炉汽包水位控制系统中,为了使锅炉内水位升高,往往采用加入冷水的方法,但在开始阶段,由于冷水的加入改变了热水的特性,导致汽包水位并没有上升,反而下降,表现出与期望控制目标相悖的特性,这就是非最小相位作用的结果。再比如,在航空航天发展中,随着空战对导弹的机动能力要求的进一步提高,大攻角机动控制成为必然。然而,在大攻角状态下的不确定气动力效应将引起更严重的非线性和耦合,并导致非最小相位问题的产生,使得传统控制方法难以满足快速稳定的控制效果,而近年来出现的高级控制方法也由于该类问题的出现,而无法直接用于大机动控制的实现。

2. 问题描述

那么,什么是非最小相位问题?作为控制系统中的一类特殊控制问题,非最小相位存在于各类线性系统和非线性系统中。首先,对于线性系统而言,当传递函数极点或零点的实部小于或等于零时,则称该系统为最小相位系统。反之,如果系统的开环传递函数中存在具有正实部的零极点或纯滞后环节(纯滞后环节的近似表达形式等价于具有正实部的零点),则称系统是非最小相位系统。在具有相同幅频特性的系统中,最小相位系统的相角变化范围势必小于非最小相位系统,于是,最小相位和非最小相位由此而得名。对于非线性系统而言,零动态是区分最小相位和非最小相位的一个重要概念。非线性系统的零动态是指系统输出为零的情况下,系统存在内动态的动态特性。如果零动态是稳定的,就是最小相位系统,否则是非最小相位系统。由于线性系统是非线性系统的特例,所以,非线性系统非最小相位的定义同样适合于线性系统,即“零点在左半平面”和“零动态稳定”是等价的。非最小相位问题的存在对于控制系统而言是非常棘手的,它将严重影响控制系统的稳定性、稳态性能和动态性能,给控制器设计带来了极大的困难,特别是在飞行器这类控制难度大、控制性能要求高的场合中,非最小相位的控制更是成为一个难题。

3. 必要说明

在飞行器控制中,通常要求能准确跟踪飞行高度和飞行速度的控制指令,但由于飞行器自身结构的特殊性和大气气流的不确定性,在飞行器升降舵与气动力之间往往存在着不能忽略的耦合关系,即两者之间具有交互的影响作用,导致无法通过控制舵面偏转来保证飞行器的俯仰角等姿态变量的稳定变化,这就使得飞行器控制问题呈现出非最小相位的特性,即在研究输出量与控制量之间的控制作用时,找到俯仰角和俯仰角速率等状态量的变化规律并对其施加控制作用非常困难,使其成为不稳定零动态。此外,对于新型飞行器而言,由于高速飞行、材料发热,同时,飞行器机体的超燃冲压发动机置于机体下腹部,飞行器前体下壁和后体分别成为发动机气流压缩段和膨胀段,致使机体两端流道产生附加气动力,造成飞行器产生一定的弹性变形,加剧了飞行器气动力变化和控制舵面偏转之间的耦合,从而产生弹性形变下的不稳定零动态特性。

在飞行器线性控制中,不稳定零点会限制航迹角回路的带宽,极大影响了控制系统的动态性能。而在非线性控制设计中,不稳定零动态会给方法的设计带来困难,如标准的动态逆方法难以直接应用于非最小相位系统,严重阻碍了稳定控制的实现。此外,对于飞行器中不稳定的零动态,无法直接利用控制量对其进行有效抑制。例如,在具有非最小相位的飞行器速度和高度跟踪控制问题中,由于俯仰角和俯仰角速率为不稳定零动态,则在实现了速度和高度的跟踪控制的前提下,飞行器的俯仰角和俯仰角速率仍有可能没有达到稳定。虽然从控制理论诞生之日起到今天,控制理论能够在一定程度上解决非线性、强耦合、不确定和快时变等典型问题,但针对非最小相位问题,却缺乏有效的解决方法和理论。尽管在经典控制的线性系统根轨迹设计中包含了对非最小相位问题的探讨,并经历了在现代控制理论基础上对于非线性零动态的进一步发展,但直到智能控制理论和更新控制方法的出现,都没有能够有效解决非最小相位问题。因此,无论是在近代还是在当前,非最小相位的存在都给控制系统设计带来了极大的难度,成为飞行器控制系统中最具挑战性的研究课题之一。

目前,针对飞行器非最小相位控制问题,已有国内外众多学者开展了大量工作,并取得了一定的研究成果。文献[1]采用了修正的动态逆方法,在闭环传递函数中保留右半面的零点,避免直接对消右半面零点所带来的潜在问题。文献[2]采用近似反馈线性化方法,人为改变了航迹角和升降舵偏转之间的相对阶,消除了零动态。文献[3]、[4]增加了鸭翼作为控制输入,消除了升降舵与升力之间耦合所引起的非最小相位。文献[5]通过非线性反馈变换的方式,将飞行器运动方程转化为反馈和反馈-前馈形式的子系统,来克服不稳定零动态。然而,无论是哪种解决方法,虽然在一定程度上处理非最小相位问题,但要么忽

略飞行器部分特性,要么是严重影响了系统其他功能(如鸭翼的引入影响了热防护系统),这些方法尚不能完全有效解决该问题。

4. 研究意义

近年来,国内外众多的飞行器研究机构都投入了大量的人力物力开展该问题的研究工作。从工程实践的角度分析,将保证飞行器的稳定跟踪控制性能,提高控制系统跟踪的快速性和跟踪精度;从科学理论的角度分析,对该问题的研究将进一步丰富处理非最小相位问题的相关理论,推动控制理论的进一步发展,加深对解决非最小相位这类科学问题的认识。

参 考 文 献

- [1] Oppenheimer M W ,Doman D B .Control of an unstable ,nonminimum phase hypersonic vehicle model//2006 IEEE Aerospace Conference ,Big Sky ,2006 .
- [2] Parker J T ,Serrani A ,Yurkovich S ,et al .Control-oriented modeling of an air-breathing hypersonic vehicle .J .Guidance ,Control and Dynamics ,2007 ,30(3) :856—869 .
- [3] Fiorentini L ,Serrani A ,Bolender M A ,et al .Nonlinear control of a hypersonic vehicle with structural flexibility //Proceedings of the 47th IEEE Conference on Decision and Control ,Cancun ,2008 :578—583 .
- [4] Fiorentini L ,Serrani A ,Bolender M A ,et al .Nonlinear robust adaptive control of flexible air-breathing hypersonic vehicles .J .Guidance ,Control and Dynamics ,2009 ,32(2) :402—417 .
- [5] Fiorentini L ,Serrani A ,Bolender M A ,et al .Nonlinear control of non-minimum phase hypersonic vehicle models //2009 American Control Conference Hyatt Regency Riverfront ,St . Louis ,2009 :10—12 .

撰稿人:宗 群

天津大学电气与自动化工程学院

变体飞行器的控制问题

Control Problems of Morphing Aircraft

1. 背景介绍

1903 年以来,人们不断探索与追求,制造出了各类实用的现代飞行器,为人类社会的发展进步做出了巨大贡献。然而,与自然界的鸟类等飞行生物的飞行方式相比,现代飞行器仍显得原始和简单。鸟类在飞行中能自如地改变翅膀的形状,以实现机动控制或在不同的飞行条件下获得最优的飞行性能。而现代飞行器普遍采用了固定的气动布局,无法在多种飞行条件下都达到优化的气动性能。从仿生学的角度,人们提出了一种能根据飞行器的机动控制要求或者飞行环境和任务的变化,而自适应地改变外形的“变体飞行器”。变体飞行器能够满足大范围多任务飞行的要求,并能节省能耗;用连续、光滑变形的变形机构代替传统的离散操纵面,能提高隐身性能。

近年来,变体飞行器的研究得到了各国的重视^[1~3],出现了日益趋热的新局面。1995 年,美国 DARPA 启动了智能机翼项目;1996 年,美国 NASA 开始了主动气动弹性翼项目。欧洲的主动气动弹性飞行器结构(3AS)研究项目在 A340 验证机上应用了主动吸气技术、自适应鼓包、柔性后缘技术等自适应机翼控制技术。2003 年,美国 DARPA 开展了变体飞行器结构(MAS)项目,目标是研究比以往更大尺度的变形方法,实现变体飞行器的多任务飞行。美国 NASA 制订的“21 世纪航空发展展望”中已对变体飞行器有过具体的设想,并期望在 2030 年左右将其变为现实。我国国家自然科学基金等国家级基金项目都专门将变体飞行器的相关研究列为资助对象。此外,国内外许多大学和研究机构也进行了大量的变体飞行器研究工作。

与传统的固定外形的飞行器相比,变体飞行器最大的特殊之处在于它具有变形机构。在控制学科方面,变形机构的分布式驱动特性及变形引起的飞行器模型的不确定性和非线性等都引出了许多具有挑战性的研究课题。

2. 问题描述

变体飞行器的控制系统具有两个层次:第一层可称为变形控制系统,对变体飞行器的变形机构进行控制,即实现变形控制;第二层可称为飞行控制系统,控制整个飞行器的飞行状态,即实现飞行控制。

首先讨论变体飞行器的变形控制问题。大部分变形机构是由大数量的分布式驱动单元组成的,安装了分布式的传感器、驱动器和控制器。一类分布式驱动结构的非线性动力学模型为

$$\dot{\mathbf{x}}_i = \mathbf{f}_i(\mathbf{x}_i, \mathbf{x}_{i-1}, \mathbf{x}_{i+1}) + \mathbf{g}_i(\mathbf{x}_i) \mathbf{u}_i + \lambda_i(\mathbf{x}_i) \omega_i \quad (1)$$

式中, $\mathbf{x}_i$ 为驱动结构的状态向量; $\mathbf{f}_i(\cdot)$ 、 $\mathbf{g}_i(\cdot)$ 与 $\lambda_i(\cdot)$ 为非线性函数向量; ω_i 为外界扰动。这类变形结构是一个非线性关联系统。

变形控制层需要使得全体驱动单元协同动作,以完成复杂的、光滑连续的外形变化。需要研究分布式驱动的机械变形机构或者分布参数的智能变形结构的动力学建模与协调控制问题。

变形机构在装备分布式驱动器和传感器后,留给布线的空间十分有限,一个可行的方案是采用总线网络连接变体飞行器的分布式元件,这给控制系统带来了共享信道的分布式系统的协调控制问题。

对中尺度和小尺度变形而言,如改变机翼弯度,空气动力载荷会使变形结构产生显著的气动弹性变形。变形结构会做较大位移的运动,这会引入空气动力学效应和结构动力学双方面的非线性。需要解决非线性气动弹性与主动变形耦合系统的控制问题。

接着讨论变体飞行器的飞行控制问题。变体飞行器使用了较大尺度变化的变形结构,这给飞行控制系统的设计提出了一系列难题。大尺度变形的变体飞行器具有多刚体系统的特点。中尺度和小尺度变形的变体飞行器具有柔性体的特点。多体系统建模得到的数学模型较复杂,需要研究其简化的、高精度的近似模型,以方便控制器的设计。

飞行器结构的动态变形会引起非定常流场,而且大尺度的变形会使得飞行器重心和气动力的发生较大变化,这些都增加了飞行器动力学模型的不确定性、非线性及参数的时变特性。文献[4]给出了一类变体飞行器动力学的一般方程,如下:

$$\dot{\mathbf{x}} = \mathbf{f}(\mathbf{x}, \mathbf{u}, \xi) \quad (2)$$

式中, $\mathbf{x}$ 为变体飞行器的运动学变量; $\mathbf{u}$ 为控制输入; ξ 为与飞行器外形有关的变量。可见,飞行器形状改变对动力学方程有直接影响。

需要针对这些问题,研究变体飞行器的飞行稳定性和设计飞行控制律。若使用变形结构替代传统舵面对飞行器进行操控,需要建立一个形状控制-飞行控制一体化的飞控系统。

3. 必要说明

目前,大多数研究工作集中在变体飞行器布局优化和驱动装置设计方面,控制方面的研究较少。在变形控制的研究中,大多数是围绕静态变形进行的;

为数不多的动态形状控制^[5]都没有考虑分布式的驱动结构之间的协调控制问题和网络通信特性。

在变体飞行器飞行控制方面的研究中,许多是针对集中式驱动的大尺寸变形方式展开的,基于线性化后的模型进行分析和设计控制器^[6];还有一些研究是针对分布式驱动的变形方式展开的,通常对分布式驱动器的协作方式都做了很大的简化^[7]。这些研究都没有采用真实体现变体飞行器的时变特性、非线性和不确定性的数学模型,并以此为基础设计飞行控制算法。最近,文献[4]研究了大尺度变形的变体飞行器的过渡过程的稳定性问题,在一定的假设条件下将变体飞行器过渡过程的非线性时变方程(2)转化为线性变参数方程,基于慢变系统的理论给出了保证过渡过程稳定的变形速率限制条件。

变体飞行器是当前国际航空航天界的前沿和热点研究内容,我国在这方面的研究也开始起步。变体飞行器的变形控制与飞行控制技术的发展推动着飞行器家族的新成员——变体飞行器早日翱翔天空,也将大大促进分布式协调控制与飞行控制理论的研究。

参 考 文 献

- [1] Jayanth A K, Kudva J N. Morphing aircraft concepts, classifications and challenges. Smart Structures and Materials 2004; Proceedings of SPIE, 2004; 213—224.
- [2] Armando R R. Morphing aircraft technology survey. AIAA, 2007.
- [3] Adam M W, Ephraim G. Optimization of perching maneuvers through vehicle morphing. J. Guidance, Control and Dynamics, 2008, 31(4): 815—823.
- [4] Thomas M S, David A N, Jae-Sung B, et al. Analysis of transition stability for morphing aircraft. J. Guidance, Control and Dynamics, 2009, 32(6): 1947—1953.
- [5] Hubbard J E. Dynamic shape control of a morphing airfoil using spatially distributed transducers. J. Guidance, Control and Dynamics, 2006, 29(3): 612—616.
- [6] Mujahid A, Rick L. Control and simulation of a multi-role morphing micro air vehicle. AIAA, 2005.
- [7] Manoranjan M, John L J. Robust control of redundantly actuated dynamical systems. AIAA, 2006.

撰稿人: 陆宇平

南京航空航天大学航天学院

欠驱动飞行器运动控制

The Motion Control of Underactuated Aircraft

欠驱动机械系统是指由控制输入向量张成空间的维数小于位形空间维数的系统^[1]，而位形空间的维数与系统控制输入维数相同的系统称为全驱动机械系统。简而言之，欠驱动机械系统是指系统的控制输入少于系统自由度的系统，大家都较为熟悉的倒立摆就是一个典型的欠驱动机械系统。欠驱动机械系统所具有的特性是可以由较少的控制输入确定其在比控制输入维数大的位形空间中的运动。欠驱动机械系统广泛存在于机器人、空间飞行器、海洋运动体和地面车辆等机械系统控制问题中，可以毫不夸张地说，现实世界中所存在的大部分机械系统都是欠驱动机械系统。对欠驱动飞行器系统的控制问题已经成为目前飞行器控制领域的热点和难点。

对于常规的固定翼飞行器来说，其推进装置的主要配置为螺旋桨式发动机或者喷气式发动机和控制舵面，没有任何其他推进装置。飞行器通常具有的气动控制舵面能够提供俯仰、偏航、横滚三个通道的控制力矩，这三个通道是完全可控的。同时，发动机提供了轴向运动控制力，但只能前进不能后退。不过，垂向、侧向运动无法直接控制，原因是由于垂向和侧向运动需要通过升力和侧向力来控制，而舵面总的来说无法直接产生升力和侧向力，只能通过舵面产生控制力矩，进而改变攻角和侧滑角，从而改变升力和侧向力，因此，这两个自由度是不可控的。这样，在飞行器空间运动的6个自由度中，只有4个自由度是直接可控的，而垂向及侧向运动是不可控的。一个生动的例子就是如果飞机要90°转弯，即改变航向，那么，在空间中的轨迹投影在水平面一定是一个圆弧，它永远不可能按照直角来转弯，但如果这个飞行器是全驱动的，理论上就可以实现直角转弯。另外，在拦截过程中，某些导弹上安装的姿控喷管就是为了提供直接升力、直接侧向力控制来提高导弹的机动性。因此，在飞行器的轨迹优化问题的研究中，需要考虑到飞行器的欠驱动因素。

对于欠驱动飞行器控制的研究，首先面临的一个较为困难的理论问题就是系统的可控性问题^[2]，如果我们希望飞行器按照一条事先规划好的轨迹飞行，但考虑到飞行器的欠驱动因素时，首先应该证明飞行器有能力沿着这样一条轨迹飞行，这就是为什么飞行器控制中有一个最小转弯半径的指标，本质上就是由于系统的欠驱动特性，使得小于最小转弯半径的飞行轨迹飞行器是无法实现的。上述问题在非线性控制中等效的提法是^[3]：对于控制系统，给定初始状态

和终止状态,确定合适的系统输入,在有限的时间内将系统从初始状态驱动到终止状态。但是,目前并没有一个较为通用的算法保证任何一个非完整系统精确地到达一个所给定的目标点。仅有的结果是一些近似的方法,但仅能保证到达目标点的临域。对于一般的控制系统而言,线性系统的可控性在理论上已经得到了很好的解决,人们能够给出明确的可控性判据,但对于非线性系统而言,其可控性问题还远没有解决。欠驱动飞行器系统本质上是非线性系统,如果将模型在设定点线性化后进行可控性分析,即使线性化后的模型可控,原非线性系统的可控性是无法得到保证的,很可能得到一个不可控的非线性系统。目前,有关欠驱动飞行器的可控性研究还主要集中在其水平面运动的仿射非线性系统模型,而可控性判定的理论基础及分析框架主要是基于非线性系统理论中的小时间局部可控性的充分条件。一些学者尝试使用低阶的李括号检验系统是否可控^[4],并探寻系统对称性、低阶李括号和系统的能控性之间的一般性关系且取得了一些成果,但距离解决欠驱动机械系统的可控性这一难题还有很大的差距。

对于欠驱动飞行器的控制器设计来说,其主要的难点在于直接可控部分的自由度(沿体纵轴向的平动,绕体轴系三个轴的俯仰、偏航、横滚三个转动自由度)和欠驱动部分的自由度(升降运动、侧向运动)互相之间是非线性耦合的,所设计的控制器必须同时能够对于系统所有的自由度具有较好的控制性能。同时,由于线性化后得到的系统常常是不可控的,不能用线性系统理论实现欠驱动飞行器的控制,并且由于不满足非线性系统理论中著名的 Brockett 条件,因此,不存在光滑时不变静态状态反馈使得水平面运动的欠驱动飞行器镇定在平衡点上,于是,以研究光滑状态反馈为主的现代非线性控制方法也不能直接应用于解决欠驱动飞行器的镇定控制问题。由于上述原因,人们转向通过下面两种方法实现对欠驱动飞行器的控制^[5,6]:①通过采用动态时变反馈对欠驱动机械系统进行控制,这种方法的优点是在理论上较为严密,但控制器设计较为复杂;②通过采用非连续反馈对欠驱动飞行器进行控制,其优点是控制器设计较为简单,容易得到指数收敛速率,但不足之处在于该控制律非连续且不宜工程实现。

正如前文所述,欠驱动飞行器系统的控制问题已经成为目前飞行器控制领域的热点和难点,由于其使用的理论方法较为抽象,涉及泛函、微分几何、微分代数、李群等数学工具,但对其研究不仅有很高的实际工程价值,更有助于揭示非线性系统的本质特性,对于非线性控制理论的发展有着重要的理论意义。

参 考 文 献

- [1] Sepulchre R, Kokotovic P. Constructive Nonlinear Control. Berlin: Springer, 1997.
- [2] Sussmann H J. A general theorem on local controllability. SIAM Journal on Control and

Optimization, 1987, 25(1):158—194.

- [3] Sontag E D, Sussmann H J. Time-optimal control of manipulators // IEEE International Conference on Robotics and Automation, San Francisco, 1986; 1692—1697.
- [4] Morgansen K A. Nonholonomic control based on approximate inversion // Proceedings of the American Control Conference, San Diego, 1999; 3515—3519.
- [5] Marsden J E, Ratiu T S. Introduction to Mechanics and Symmetry; A Basic Exposition of Classical Mechanical Systems. Berlin; Springer, 1999.
- [6] Reyhanoglu M, Cho S, McClamroch N H. Discontinuous feedback control of a special class of underactuated mechanical systems. International Journal of Robust and Nonlinear Control, 2000, 10(4):265—281.

撰稿人：葛 晖 杨永胜 敬忠良
上海交通大学航空航天学院

临近空间飞行器地磁导航与制导

Geomagnetic Navigation and Guidance for Near Space Vehicle

1. 临近空间

临近空间又可称为空间过渡区,包括大气平流层区域、中间大气层区域和部分电离层区域。根据国际航空联合会(FAI)的定义,临近空间的范围确定为23~100km,而美国空军参谋长 Jumper 将军、国防部航天负责人 Teets 和空军航天司令部司令 Lord 将军曾共同商定,将临近空间范围定为20~300km。基于多种考虑,目前大多数专家倾向于把临近空间范围定义为20~100km,将20km作为临近空间的最低界限,主要是因为它必须在国际民航组织(ICAO)控制的空域18.3km之上;而将临近空间的最高界限定为100km,主要是依据FAI的定义,并考虑到已有国际空域主权的协议和惯例^[1]。

目前,世界上绝大多数的作战飞机和地空导弹都无法到达20km这一高度,因此,临近空间便成了相对独立的“真空”层,从而给临近空间飞行器提供了相对安全的工作环境。随着美军2005年2月“施里弗-3”空间战模拟演习过程中首次将临近空间纳入作战视野以来,临近空间这一领域已引起世界各国关注并成为近期研究的热点^[2]。

2. 临近空间飞行器导航与制导

临近空间飞行器是指主要在临近空间区域内飞行并完成特定任务的飞行器,一般分为低速临近空间飞行器和高速临近空间飞行器。低速临近空间飞行器飞行高度低、速度慢(亚音速)、滞空时间长(续航力强)、信息获取处理能力强,主要用于探测、侦察、情报收集、通信等,包括平流层飞艇、高空气球和太阳能飞行器等;高速临近空间飞行器飞行高度高、速度快(数倍音速)、打击范围广、攻击能力强,具备全球快速到达和廉价天地往返能力,可用于天地往返运输和空间在轨服务,还可用于摧毁敌方空间系统、拦截弹道导弹和对地进行精确打击,包括高空侦察机、高超声速飞行器、亚轨道飞行器等。

目前,在各类飞行器导航与制导系统中,惯性导航系统(inertial navigation system, INS)被广泛采用。INS工作时不需要任何外来信息,也不向外辐射任何信息,仅靠系统本身就能在全天候条件下,任何介质环境里自主、隐蔽地进行连续的三维空间定位和三维空间定向,提供反映飞行器完整运动状态的完整

信息。但是,INS 系统的导航误差随时间而积累,难以满足长时间独立工作的任务要求。为了限制这种误差累积,必须引入外界导航信息,如卫星导航、无线电导航和数据库参考导航信息等。与 GPS 导航、无线电导航方式相比,数据库参考导航利用的是已有天文、地理数据库包含的参考导航信息,因此,能够保持导航系统的自主性。地形匹配、地磁导航等都属于数据库参考导航。由于在平原、海洋等地形信息不丰富或根本无地面信息可利用的地区,无法通过地形匹配实现精确导航,因此,利用地磁信息实现导航与制导对某些飞行器显得尤为重要。

20 世纪 60 年代中期,美国 E-Systems 公司就开始了地对磁导航制导技术的研究,设计了基于地磁异常场等值线匹配的 MAGCOM (Magnetic Contour Matching) 系统,当时最大的瓶颈是地磁数据的获得,经过美国海军的努力,70 年代他们利用 Lockheed-P3 卫星得到了实验区域的地磁异常数据,并对该系统进行了离线实验。20 世纪 80 年代初,瑞典 Lund 学院对船只的地磁导航进行了实验验证,实验中将地磁强度的测量数据与地磁图进行人工比对,确定船只的位置,同时根据距离已知的两个磁传感器的输出时差确定船只的速度。随后的 20 年里,GPS 技术取得的巨大进展暂时掩盖了地磁匹配导航的优势,使得地磁匹配导航研究停滞不前,并未获得深入的发展。最近几年,GPS 技术暴露出各种弱点,学者们开始寻找新的导航替代方法,地磁匹配导航就成了考虑中的替代方法之一^[3,4]。

随着地磁理论的不完善及敏感器、微处理器和导航算法的日趋成熟,地磁导航技术获得了快速发展,并以其隐蔽性好、成本低和精度适中等优点成为当前导航研究领域的一个热点。地磁场是地球的基本物理场,地球近地空间内任意一点都具有磁场信息,其强度和方向随着经、纬度和高度不同而不同,具有丰富的特征量信息。随着空间技术的飞速发展,地磁学与测绘学、空间物理学的交叉与综合不断加强,其在导航定位、战场电磁信息对抗等领域展现了巨大的应用潜力,尤其是地磁导航及其与惯性系统组成的复合导航与制导,具有全自主、无辐射、全天时、全天候、全地域的优良特征。当前,地磁导航系统已成功应用于近地卫星姿态控制、磁力矩器卸载、运载体航向与位置导航,并呈现出与惯性导航和卫星导航组合应用的发展趋势,成为推动现代新军事变革的重要技术力量^[5,6]。

3. 临近空间飞行器地磁信息运用技术

临近空间飞行器导航与制导的自主性,无论是从战略还是从战术层面上来考虑,无疑都是十分重要的。地磁导航与制导和惯性导航与制导组合使用、互为补充,有望构建理想的、较为完善的临近空间飞行器导航与制导方案。对临

近空间飞行器地磁信息运用技术进行深入研究,必须首先开展临近空间地磁特性,特别是在电离层区域的地磁特性的研究,包括分析太阳和地磁活动指数的周期性、电离层与太阳活动及地磁活动的联系,电离层对临近空间地磁场的影响等。对临近空间地磁场特性有了深入了解后,继而可以开展临近空间飞行器地磁导航与制导的研究,主要存在以下几个科学问题:复杂磁干扰环境下地磁场如何测量?如何建立临近空间地磁场模型?高速临近空间飞行器导航与制导系统如何突破“黑障”影响?采用什么样的地磁导航定位算法才能满足临近空间飞行器高精度快速定位的要求?针对地磁制导的特点,如何进行航迹规划?

地磁信息运用技术是研究地球物理特征应用功能的一个重要方向,自从1989年美国康奈尔大学的 Psiaki 等率先提出利用地磁场确定卫星轨道的概念以来,地磁信息运用技术开始成为飞行器导航、控制与制导领域的一个新的研究方向,众多大型国际实验室也都投入人力和物力继续开展此方向的研究。随着空间安全战略地位的日益凸显,临近空间飞行器地磁信息运用技术已成为一项亟待解决的关键技术。

参 考 文 献

- [1] Stephens H. Near-space. Air Force Magazine, 2005, 88(7): 31.
- [2] 原野. 近太空领域发展的背景与动因. 国际太空, 2006, 7: 24—28.
- [3] 周军, 葛致磊, 施桂国, 等. 地磁导航发展与关键技术. 宇航学报, 2008, 29(5): 1467—1472.
- [4] 徐文耀. 地球电磁现象物理学. 合肥: 中国科学技术大学出版社, 2009: 216—282.
- [5] Goldenberg F. Geomagnetic navigation beyond the magnetic compass // IEEE/ION Position, Location and Navigation Symposium, San Diego, 2006: 684—694.
- [6] Psiaki M L. Autonomous low-earth-orbit determination from magnetometer and sun sensor data. J. Guidance, Control and Dynamics, 1999, 22(2): 296—304.

撰稿人: 蔡 洪

国防科学技术大学航天与材料工程学院

高超声速飞行器的最优闭环制导问题

Optimized Closed-loop Guidance of Hypersonic Flight Vehicles

1. 高超声速飞行器的发展背景

高超声速飞行器一般指速度高于 5 倍声速的飞行器。在航空航天发展历史上, 首先实现高超声速飞行的是远程弹道导弹和运载火箭, 他们在上升段经历一段助推加速的过程后, 在几十公里高度的稀薄大气中达到高超声速, 并继续加速上升直至穿出大气层。在远程弹道导弹和返回式航天器再入大气层时, 也会经历高超声速的飞行过程。这两种典型的大气内高超声速飞行过程一般持续时间和飞行距离有限, 飞行轨迹和制导任务相对简单。随着航空航天领域的发展, 大气层内长时间高超声速飞行成为未来发展方向。这种飞行器可以是无动力的远程高超声速滑翔飞行器, 也可以是采用火箭动力或者吸气式发动机的巡航飞行器^[1,2]。

2. 闭环制导问题

闭环制导是指飞行过程中根据当前状态和任务生成的、引导飞行器到达目标的飞行轨迹控制指令。传统跨大气层飞行器在稠密大气内飞行时通常采用开环制导体制, 这种体制一般具有两种形式, 一般根据时间等自变量从预先设计的制导数据表中插值得到制导指令, 或采用跟踪预先设计好的飞行轨迹的反馈控制方式得到制导指令^[3]。近年来, 伴随着可重复使用再入飞行器和高超声速飞行器的研究进展^[4], 基于轨迹优化的闭环制导问题被认为是决定此类飞行器能否实现其飞行方式和应用价值、尚未解决的关键问题。

高超声速飞行器与常规飞行器的最大不同之处在于其飞行环境的不确定性和对飞行器自身在高速飞行条件下力学特性预测的不准确性^[5]。以 X-43A 为代表的吸气式高超声速飞行器^[6]所采用的超声速燃烧冲压发动机性能同马赫数、高度等飞行状态密切相关, 且发动机性能余量较小, 为了获得足够的动压和发动机进气流量, 这类飞行器必须始终在较稠密的大气层内飞行, 而飞行器气动性能在高超声速条件下存在许多难以预测的特性。因此, 大气内高超声速飞行闭环制导方式将是必然的选择, 其制导系统必须具有自主、实时生成飞行轨迹和控制系统可以实现的制导指令的能力。具体而言, 制导系统不但需要给控制系统提供实时、完整的未来飞行轨迹信息, 而且当控制律是基于预先规划的飞

行轨迹信息时, 要求必须能够根据飞行器的当前状态和飞行任务, 在线实时更新轨迹设计, 给出新的制导指令。由于闭环制导是基于对未来飞行轨迹的预测结果给出当前的轨迹控制指令, 而实际飞行过程中, 飞行器模型和大气环境条件都存在各种难以准确预测的不确定因素。因此, 如何实现实际飞行轨迹的最优化成为闭环制导的终极目标, 这一目标只可能逼近, 不可能实现。

3. 数学描述

飞行器状态方程为

$$\dot{\mathbf{x}} = \mathbf{f}(\mathbf{x}(t), \mathbf{u}(t), t), \quad \mathbf{x} \in \mathbf{R}^n, \mathbf{u} \in \mathbf{R}^m$$

式中, $\mathbf{x} = \begin{bmatrix} \mathbf{r} \\ \mathbf{V} \end{bmatrix}$, $\mathbf{r}$ 代表飞行器的三维位置矢量, $\mathbf{V}$ 代表三维速度矢量; $\mathbf{u}$ 代表控制输入, 包括攻角、滚转角等姿态控制和发动机油门指令等。

定义当前 t_0 时刻状态为 $\mathbf{x}_0$, 飞行轨迹需满足终端状态约束条件为

$$\psi(\mathbf{x}_f, t_f) = 0, \quad \psi \in \mathbf{R}^p, p \leq n$$

求解以下最优控制问题:

$$\min_{\mathbf{u} \in U} J = \phi(\mathbf{x}_f, \mathbf{x}_f) + \int_{t_0}^{t_f} L(\mathbf{x}, \mathbf{u}, t) dt, \quad J \in \mathbf{R}$$

得到最优控制

$$\mathbf{u}^*(t, \mathbf{x}_0), \quad t \in [t_0, t_f]$$

上式中, 轨迹性能优化指标由两部分组成, $\phi(\mathbf{x}_f, \mathbf{x}_f)$ 同终端状态有关, 而 $L(\mathbf{x}, \mathbf{u}, t)$ 代表同飞行过程相关。在当前时刻 t_0 , 制导指令取为

$$\mathbf{u}(t_0) = \mathbf{u}^*(t_0, \mathbf{x}_0)$$

对以后每一个制导时刻, 都重复上述制导指令生成过程, 因此, 实际上形成闭环制导律

$$\mathbf{u}(t) = \mathbf{u}^*(t, \mathbf{x})$$

注意到, 此闭环制导反馈机制中虽然包含当前状态, 但同一般控制系统反馈机制不同的是, 需要根据从当前状态到终端条件的最优飞行轨迹来确定当前制导指令。这一闭环制导方式存在两个理论上尚未解决的问题: 一是如何保证在一个制导指令周期内快速生成从当前时刻到终端条件的最优轨迹; 二是如何从理论上证明这种闭环反馈系统的稳定性。

4. 相关研究状况

在线轨迹优化是前述闭环制导问题的核心。由于高超声速飞行器的高速特

点和复杂动力学耦合特点^[6],为保持系统稳定性和制导精度,一般要求制导指令更新周期时间小于1s。由于轨迹优化问题本身是一个多约束条件下的多输入多输出非线性系统的最优控制问题,如何实现这一时间要求且保证得到收敛解的可靠性成为轨迹优化应用于闭环制导的最大难题。此类问题的最初理论基础为20世纪60年代前后成熟的动态规划方法和Pontryagin极小值原理^[7]。

由于计算最优轨迹问题的极大难度,目前尚不存在无需经验调试就可以得到可靠收敛结果的最优轨迹问题通用算法,主流研究方向是通过数值方法将连续时间的最优控制问题离散化,转换为近似的、具有一定精度的优化问题^[3,8]。目前,同高超声速飞行器轨迹优化和闭环制导相关的研究成果大部分是20世纪90年代前后围绕美国空天飞机概念和大气内高超声速滑翔飞行器获得的^[9]。包括基于真空解,逐渐引入大气因素的轨迹迭代收敛方法^[8]和基于两点边值问题微分方程的光滑条件,求解两点边值问题二阶近似解的有限差分方法^[3]。这些研究方向所关注的主要难题在于如何提高最优轨迹的解算速度和迭代收敛的可靠性,而对闭环制导体制的稳定性证明均通过大量的数值仿真来完成,难以获得如同线性系统稳定性理论或非线性系统Lyapunov稳定性理论那样的证明。

参 考 文 献

- [1] Dennis R J, Tony L, Jay M. American X-vehicles: An inventory, X-1 to X-50. National Aeronautics and Space Administration, Office of External Relations, 2003.
- [2] Bahm C, Baumann E, Martin J, et al. The X-43A hyper-X Mach 7 flight 2 guidance, navigation, and control overview and flight test results. AIAA/CIRA 13th International Space Planes and Hypersonic Systems and Technology, 2005.
- [3] Lu P, Sun H, Tsai B. Closed-loop endo-atmospheric ascent guidance. J. Guidance, Control and Dynamics, 2003, 26(2): 283—294.
- [4] Hanson J M. Advanced guidance and control project for reusable launch vehicles. AIAA Guidance, Navigation and Control Conference and Exhibit, 2000: 1—10.
- [5] 中华人民共和国国家军用标准. 中国参考大气(地面~80公里). GJB5601—2006.
- [6] Mirmirani M, Wu C, Clark A, et al. Modeling for control of a generic airbreathing hypersonic vehicle//AIAA Guidance, Navigation and Control Conference and Exhibit, San Francisco, 2005.
- [7] Bryson A E. Dynamic Optimization. New York: Addison-Wesley, 1999: 178.
- [8] Calise A J, Melamed N. Design and evaluation of three dimensional optimal ascent guidance algorithm. J. Guidance, Control and Dynamics, 1998, 21(6): 867—875.

- [9] Vinh N X, Lu P. Necessary conditions for maximax problems with application to aeroglide of hypervelocity vehicles. *Acta Astronautica*, 1987, 13(6/7): 413—420.

撰稿人：沈作军

中国航天科技集团公司第三研究院

飞行器控制的操纵问题

Maneuverability Problem of Aircraft Control

自古以来,能够摆脱大地的束缚,像鸟儿一样翱翔蓝天,就是人类的梦想。随着第二次工业革命期间蒸汽机的出现,以及随后各项发电机、电动机的发明和不断创新,人们借助一种被称为飞行器的人造机器的力量,不仅实现了飞翔于天空的梦想,而且开启了探索广阔宇宙的大门。现有的飞行器种类繁多,功能各异,与人们的生产生活和科学研究密不可分。如果按照飞行空域进行分类,可大致分为两大类^[1]:一类是大气层外(100km 以上空域)飞行器,通常称为航天器,如卫星、飞船、航天飞机、空间站、月球探测器、宇宙探测器等;另一类是大气层内(地面至 100km 空域)飞行器,如飞机、飞艇、热气球、部分导弹、高超声速飞行器等。

飞行器的飞行不外乎飞行器质心的运动和飞行器绕质心的转动,即姿态运动。所谓飞行器的飞行控制,就是通过操纵飞行器使之获得适当的力和力矩来实现所需的质心运动和姿态运动。用来操纵飞行器的物理机构统称为执行机构。飞行器的控制方式和执行机构类型取决于它的飞行环境,如大气层外飞行环境和大气层内飞行环境。操纵不同飞行环境中飞行器的执行机构是截然不同的。

大气层内飞行环境下^[2,3],飞行器相对大气运动时会受到空气作用力,即气动力,气动力的大小不仅与飞行器的飞行状态(如飞行姿态和飞行速度)紧密相关,而且也随大气密度的增减而显著增减。由于大气密度随高度的增加而递减,所以,同一个飞行器以同一飞行状态在低空飞行时,其所受的气动力将远远大于在高空中所受的气动力。飞行器所受气动力的作用点被称为压心。压心一般与飞行器质心不重合,从而能够同时对飞行器产生力和力矩,前者使飞行器的飞行轨迹发生变化,后者使飞行器的姿态发生改变。因此,飞行器在大气层内飞行时,如何改变飞行器所受的气动力和力矩,从而控制飞行器的飞行轨迹和姿态按照要求变化,实质上就是飞行器的操纵问题。大气层内飞行器的操纵就是借助气动力来完成的,实现操纵的执行机构统称为操纵面,根据安装位置和功能的不同,又分为舵、副翼等。操纵面通过改变其相对飞行器的位置来调整操纵面上所产生的气动力,进而相对于飞行器质心产生操纵力矩,实现对飞行器的控制。驱动舵和副翼偏转的机构通常被称为舵机。

随着大气层内飞行器飞行速度、高度和飞行控制精度要求越来越高,飞行器操纵所需的操纵力也越来越大,产生操纵力的快速性要求也越来越高。但与

此同时,飞行高度的增加却恰恰使得操纵面能够产生的气动力越来越小,产生气动力的速度也越来越慢。这一矛盾成为目前飞行器控制的操纵问题中的难题。解决这一难题的方法:一是不断提高操纵面舵机的功率,所以,大功率、长寿命、高精度的舵机技术是目前飞行器控制中的一个关键技术;另一方法是放弃利用操纵面气动力来控制飞行器,采用小型火箭发动机直接产生飞行器控制所需的操纵力和力矩,这一方式被称为直接力控制^[4],其执行机构就是小型火箭发动机。目前,高空高速飞行器的控制常常采用这一操纵方式。

大气层外飞行环境下^[5,6],由于大气几乎不存在,因此,在大气层内依靠气动力来操纵飞行器的方式不再适用,必须直接施加给飞行器控制力和控制力矩。所以,大气层外航天器的执行机构主要有两种模式,分别依据动量守恒和动量矩守恒原理。第一种依据动量守恒原理,执行机构是安装在航天器上的推力器,推力器通过向航天器外部空间喷射工质,产生作用于航天器的反作用推力,该力的大小正比于单位时间喷射工质的质量和工质的速度。当推力器所产生的推力通过航天器质心时,能够实现对航天器质心运动的控制;当作用力不通过航天器质心时,能够产生对质心的力矩以实现航天器姿态的控制。第二种执行机构是安装在航天器上转速可变的高速旋转轮体,一般称之为飞轮。当飞轮相对于航天器旋转的速度大小和方向发生变化时,依据动量矩守恒原理,其作用效果相当于对航天器施加了一个反作用力矩,可用于对航天器姿态的控制。飞轮执行机构只能产生力矩,所以,只能实现航天器的姿态控制,不能进行质心控制。

飞轮执行机构通常消耗的是电能,可由航天器携带的太阳能电池不断补充,从而可以长时间工作甚至达到20年之久。但对于推力器执行机构而言,由于其消耗的工质全部是在航天器发射时由地面携带的,总量有限且不可再生,消耗完毕则意味着控制失效。所以,如何在满足推力需求的情况下,尽可能少地消耗工质成为航天器执行机构中的一个关键问题。

解决的方法之一是不断提高工质喷射速度,从而减少工质的单位时间喷射质量。电推进^[7]就是将工质电离成离子,以极高的速度喷射出去,一方面能够有效减少工质消耗,另一方面,电离工质所需电能又可以得到补充。欧洲发射的月球探测器 Smart-2^[8]就成功运用了电推进技术,完成奔月飞行。另一种解决方法是从飞行环境中获得力,来控制航天器的运动,而无须消耗工质,如利用太阳光压^[7]。日本研制并已成功升空的太阳帆飞船“伊卡洛斯”^[9],就是在飞船上设置很大的太阳帆,利用光子撞击在巨大帆面上所产生的力,可使飞船最终加速到每小时24万公里的速度,这个速度比当今以火箭助推的最快航天器还快4~6倍。

此外,还可以利用外星引力、地球磁场等,相信在不远的未来,科技的进

步一定能够让飞行器为人类插上翅膀,更自由地飞向辽远的地方。

参 考 文 献

- [1] 昂海松,等.航空航天概论.北京:科学出版社,2008:1—20.
- [2] Etkin B.大气飞行动力学.何植岱,等译.北京:科学出版社,1979:199—521.
- [3] 余超志,等.导弹概论.北京:北京工业学院出版社,1986:70—81.
- [4] 杨军,等.现代导弹制导控制系统设计.北京:航空工业出版社,2005:149—155.
- [5] 周军.航天器控制原理.西安:西北工业大学出版社,2001:59—143.
- [6] 黄圳圭.航天器姿态动力学.长沙:国防科技大学出版社,1997:4,103—211.
- [7] 褚桂柏,等.月球探测器技术.北京:中国科学技术出版社,2007:290—299.
- [8] <http://sci.esa.int/science-e/www/object/index.cfm?fobjectid=31714>.
- [9] <http://news.cctv.com/world/20100314/103132.shtml>.

撰稿人:周 军
西北工业大学航天学院

湿度测量的计量标准

Humidity Measurement Standards

湿度用于表示水蒸气在空气或其他气体中的含量,被定义为“物象状态的量”,可采用质量混合比、相对湿度、露点温度、霜点温度等方式表达。湿度测量与人们的生产与生活息息相关,随着科学技术的进步,湿度测量在航天航空、农业生产、工业现场、仓储等领域显现出不可或缺的重要作用^[1~7]。

湿度测量的发展起步较早,最初出现了天平式验湿器、虎克湿度计、南怀仁湿度计等湿度检测器具。进入18世纪,先后出现了利用冷凝现象的露点湿度计、干湿球湿度计、毛发湿度计等。20世纪初叶,电湿度计的出现成为湿度测量史上的一个阶段性标志。进入21世纪,光学型、波谱型湿度计也先后取得了重大突破和发展^[8,9]。但是,目前为止,不同的湿度测量原理能达到的测量范围和准确度等级差别很大,亟须建立国际公认的湿度测量的计量标准,建立湿度标准实验室。

在建立湿度测量的计量标准过程中,不可避免地要遇到两个方面的科学问题:一是湿度标准的建立;二是湿度量值的准确传递。

在湿度标准建立方面,由于现存的湿度表示方法和单位相当繁杂,同时,因为湿度这个量用实物来体现比较困难,因此,迄今为止,国际上关于湿度及其单位还没有统一的定义,从而也就无法根据定义来复现这个单位^[10]。目前,国际上的两大湿度标准分别由英国国家物理实验室和美国标准与技术研究院建立^[10~12],但仍不具有普遍的权威性,主要是因为湿度测量本身的难度,其中,湿度测量的温度依赖性是一个关键问题。湿度测量总是和温度联系在一起,特别是相对湿度的测量,微小的温度变化可能会带来较大的相对湿度差异。例如,在20℃时50%的相对湿度,1℃的温度变化可以引入±3%的相对湿度误差。90%相对湿度时,0.2℃的变化可能带来±1%的相对湿度误差^[10,13]。湿度对温度的依赖性不仅要求精确的温度采集,同时也强调测试环境的温度稳定性,由于空气的导热性能差,也导致测量空间内温度不可能达到完全均衡,由此也带来较大的测量误差。同时,湿度测量也面临着大尺度的动态测量区间。湿度的测量范围可以跨越 10^9 的数量级,从极高纯气体仅含几个ppb^①的水蒸气浓度,到大气压下的纯饱和水蒸气^[14]。例如,10%~90%的相对湿度在-40~70℃之间,湿度环境从 10^4 ppb到 2×10^8 ppb

① ppb 为十亿分之一,即 $\times 10^{-9}$ 。

区间^[13]。近年来，对湿度测量的要求向更高和更低两个方向发展，尤其是对痕量水的测量，都给湿度测量的计量标准提出了更大的挑战。

在湿度量值的准确传递方面，为保证测量值的统一和一致，必须有一系列不同精确度等级的、能够产生标准湿度源的装置和能够进行湿度绝对测定的方法构成湿度量值传递网，逐级将标准湿度的单位和量值传递到湿度测量仪器中。目前，通常的方法是以重量湿度计(如图 1 所示)和动态湿度发生器组成计量基准器具；以精密露点湿度计、标准干湿表、双压湿度发生器、双温湿度发生器、渗透湿度发生器构建一级计量标准；以静态湿度发生器、通风干湿表、精密露点湿度计、动态湿度发生器、渗透湿度发生器构建二级计量标准；由上述标准量器向工作计量器具传递湿度量值^[15,16]，简单的湿度标准流程如图 2 所示。然而，水不仅以汽、液、固三种形态自然存在，有时又多相共存。受气压、温度影响，在临界状态相，会出现多相之间随机转换的现象，而且还存在诸如过冷水等特殊状态相的问题。这些现象在上述湿度量值的传递方法中，不可避免地产生了较大的误差，需要创建新的、完整严密的科学计量系统。




图 1 重量湿度计的典型测量装置^[7]




图 2 湿度标准流程图^[16]

参 考 文 献

- [1] 杨健,张玉存,宋志刚.湿度测量体制历史和现状分析及建议.气象水文海洋仪器,2009,26(2):17—23.
- [2] 李晓韬,齐明.湿度测量细分解.企业标准化,2005,(7):29—30.
- [3] Chen H W, Wu R J, Chan K H, et al. The application of CNT/Nafion composite material to low humidity sensing measurement. Sensors and Actuators B: Chemical, 2005, 104(1): 80—84.
- [4] Yeo T L, Sun T, Grattan K T V. Fibre-optic sensor technologies for humidity and moisture measurement. Sensors and Actuators A: Physical, 2008, 144(2): 280—295.
- [5] Hassanzadeh A, Lindquist R G, Borghei A. Relative humidity measurement using capacitive sensors. IEEE Southeastcon, 2008: 396—398.
- [6] Pirrotta S, Guglielmino E. Optical psychrometer for relative humidity measurement in non-conventional environments. Proceedings of SPIE, 2007.
- [7] 中华人民共和国工业与信息产业部.湿度测量方法. GB11605—89.
- [8] World Meteorological Organization. Guide to meteorological instruments and methods of observation. Preliminary 7th ed. Switzerland: World Meteorological Organization, 2006, 4: 1—27.
- [9] 李占元,杨菊.湿度测量史话.中国计量,2004,1:45—47.
- [10] 范金鹏.湿度计量标准的现状和挑战.中国计量测试学会温度计量专业委员会 2005 年年会论文集,2005:12—42.
- [11] 封海兵.关于湿度测量技术的探讨.计量与测试技术,2007,34(7):56—57.
- [12] Hudoklin D, Bojkovski J, Nielsen J, et al. Design and validation of a new primary standard for calibration of the top-end humidity sensors. Measurement, 2008, 41(9): 950—959.
- [13] Schellenberg R. The trouble with humidity: The hidden challenge of RH calibration. Cal. Lab. Magazine, 2002: 40—42.
- [14] 易洪.湿度测量的新进展及发展趋势.中国计量,2007,2:9—11.
- [15] 国家标准物质研究中心.湿度计量器具检定系统. JJG2046—90.
- [16] 王朝晖,李志达,张巍,等.湿度测量及校准方法.计测技术,2006,26(B09):96—101.

撰稿人:王 雪 王 鹏
清华大学精密仪器与机械学系

交流量子化霍尔电阻基准的建立

Study on AC Measurement of the Quantized Hall Resistance

人们为了用数量表达客观世界的特性,需要进行测量。测量过程实质上是一种比较的过程。因此,测量过程需要溯源到统一的标准,即计量标准。准确度等级最高的计量标准则被称为计量基准。电测量在现代测量科学中占据着重要地位,如在国防领域,电测量精度决定了现代化武器的打击准确度,而在工业领域,电能在工业生产中占绝对主导地位。因此,准确的电测量对于节约能源、合理制定国家政策具有重要作用。电阻测量和电压测量是电测量中最重要

的两个环节。

在电压测量方面,量子化电压标准的出现使经典的电压标准准确度由 10^{-7} 提高至 10^{-13} 量级。约瑟夫森效应是英国剑桥大学博士生约瑟夫森于 1962 年发现的一种物理现象^[1]。高洁院士于 1985 年完成了“以超导约瑟夫森效应保持和监督国家电压基准”,以量子效应为基础首次测定了我国国家伏特基准对国际法定伏特基准的偏离值,最先在我国研制成功双结串联 10mV 约瑟夫森器件^[2]。在电阻测量方面,国际计量委员会在早期采用电阻实物基准,而实物基准的缺点在于它们是一些具体的宏观实物。由于一些不易控制的物理和化学过程的影响,实物基准所保存的量值会缓慢变化,如果只从改善材料稳定性和制作工艺等方向努力,已很难大幅度提高实物基准的准确度。1988 年,国际计量委员会建议,自 1990 年 1 月 1 日起,在世界范围内启用量子化霍尔电阻自然基准代替原来已沿用几十年的电阻实物基准。量子化霍尔电阻自然基准的理论基础在于“量子化霍尔效应”,该效应是德国科学家 von Klitzing 于 1980 年发现的一种与电磁计量标准密切相关的新物理现象。




图 1 强磁场与霍尔电压

量子化霍尔效应的基本原理如下:半导体界面电子层中的电子不能离开半导体界面,但在界面上的二维空间中可以自由运动,所以被称为“二维电子气”。如图 1 所示,当外界加一个垂直于界面的强磁场时,二维电子气中的电子形成的电流就会产生霍尔电压。

另一方面,强磁场中的电子在界面上进行圆周运动,相应的运动能级称为“朗道能级”。二维电子气中的电子在充满了某一个朗道能级时,霍尔电压的曲

线上会出现平台。霍尔电压与磁场强度之间的曲线不再是直线,而成为出现一系列台阶的曲线。与此同时,电流方向的电压降变为0,成为这一方向的超电流^[1],台阶处的霍尔电阻即为

$$R_H = \frac{V_H}{I} = \frac{h}{e^2 i}, \quad i = 1, 2, 3, \dots \quad (1)$$

由上式可知,出现量子化霍尔效应时,霍尔电阻只取决于一个基本物理常数除以一个正整数,因此,也可以利用量子化霍尔效应建立一种准确性极高的量子电阻标准。

基于量子化霍尔效应,各国的标准化组织纷纷建立了直流量子化霍尔电阻基准。直流量子化霍尔电阻基准即在量子化霍尔电阻样品通以直流电流后,根据量子化霍尔效应建立的电阻基准。1995年,由 Delahaye 等^[3]对国际计量局(Bureau International des Poids et Mesures, BIPM)和法国国家计量局中央电工研究所(Laboratoire Central des Industries Electriques, LCIE)的直流量子化霍尔基准系统进行比较验证,证明了这些系统所建立的量子电阻标准准确度在某些情况下可达 10^{-9} 。2003年,中国计量科学研究院的张钟华院士带领其团队将我国的量子化霍尔电阻基准的不确定度降低到 2.4×10^{-10} ,从而使我国电阻基准的准确度提高了2000多倍。2008年1月1日,“量子化霍尔电阻基准”作为国家电阻标准正式启动,标志着我国电学计量基准已跃居国际领先水平,为高精度测量提供了技术基础,也为提高我国产品质量提供了支撑手段^[4]。直流量子化霍尔电阻基准的成功促进了交流量子化霍尔电阻基准的研究进展。交流量子化霍尔电阻基准基于交流量子化霍尔效应,即把量子化霍尔样品通以交流电流,并假设式(1)中所定义的量子化霍尔效应在交流状态仍然成立,由此可以获得交流电阻的标准量值。如在对交流电阻进行量测时仍采用直流量子化霍尔电阻基准,则需要补偿直流和交流之间的差异,从而降低测量准确度^[5]。而采用交流量子化霍尔电阻基准有利于进一步提高交流电阻量值的复现性水平,提高测量准确性,使交流电阻和直流电阻的测量基准保持一致。

但事实上,交流量子化霍尔效应与直流量子化霍尔效应间存在差异。量子化霍尔电阻样品通以交流电流时,样品内的电磁场分布非常复杂,并存在两个电流奇点。奇点处的寄生电感和寄生电容非常大,引起的交/直流转换差很难确定。当电流频率达到10kHz,电流达到几十微安时,交流量子化霍尔电阻阻值不仅取决于电流大小,也受电流频率影响^[6]。在这种情况下,当交流量子化霍尔电阻阻值较大时,即使作用于其上的电流较小,由寄生电感和寄生电容产生的电容电流也将形成很大的电压降,从而降低了测量准确度^[7]。实验数据表明,当工作频率从0Hz(直流)逐步升高到1kHz时,量子化霍尔电阻值的不确定度达到 10^{-6} 量级。为解决以上问题,研究人员提出通过补偿减小寄生电感和寄生电

容的影响。Delahaye 等^[8]提出可以通过增加一个同步的外部门电压进行补偿,并推导了相应的经验公式以根据具体环境参数推算外部门电压值。Schurr 等^[9]提出在已知纵向电阻的频率依赖性和电流依赖性的前提下,通过对比霍尔电阻变化率和纵向电阻变化率对交流量子化霍尔电阻进行补偿,从而使交流量子化霍尔电阻测量系统偏差的电流依赖性和频率依赖性接近于零,并与交流量子化霍尔电阻阻值相关。经实验验证,采用第二种方法补偿后,交流量子化霍尔电阻阻值的测量不确定度可以降低到 10^{-8} 量级。

虽然近几年交流量子化霍尔电阻基准的研究已取得了一定研究进展,交流量子化霍尔电阻基准的精度和复现性已经超过或达到其他交流电阻基准,但与直流量子化霍尔电阻基准相比还存在较大差距。如何进一步降低交流量子化霍尔电阻基准的测量不确定度成为量子计量科学研究领域的重要问题。

参 考 文 献

- [1] 张钟华.量子计量基准概况及研究进展.中国测试,2009,35(1):1—8.
- [2] <http://www.cae.cn/swordcms/html/images/member.htm?585>.
- [3] Delahaye F,Witt T J,Piquemal F,et al.Comparison of quantum Hall effect resistance standards of the BNM/LCIE and the BIPM.IEEE Transactions on Instrumentation and Measurement,1995,44(2):258—261.
- [4] 周娜.让世界向中国计量学靠拢.中国科技奖励,2008,7:26—29.
- [5] Delahaye F.DC and AC quantum Hall measurements.Digest of Conference on Precision Electromagnetic Measurements,1994:107.
- [6] Schurr J,Melcher J,von Campenhausen A,et al.Loss phenomena in the AC quantum Hall effect.IEEE Transactions on Instrumentation and Measurement,2001,50(2):214—217.
- [7] Ahlers F,Jeanneret B,Melcher J,et al.Compendium for precise ac measurements of the quantized Hall resistance.Digest of Precision Electromagnetic Measurements,2008:492—493.
- [8] Delahaye F,Kibble B P,Zarka A.Controlling ac losses in quantum Hall effect devices.Metrologia,2000,37:659—670.
- [9] Schurr J,Ahlers F J,Hein G,et al.AC longitudinal and contact resistance measurements of quantum Hall devices.Metrologia,2006,43:163—173.

撰稿人:王 雪 王 勇 刘 长
清华大学精密仪器与机械学系

非球面和自由曲面形状量值溯源问题

Traceability of Aspheric Surface and Free Surface

在形状测量中,通常要先建立测量参考基准面,该基准面往往由实物表面或表面运动形成,然后通过被测表面与基准比较测量,获得被测面的偏差,如图1所示。而最理想的参考基准面是自然基准面。形状测量的精度在很大程度上取决于参考基准的形状精度。因此,如何生成一个理想的非球面作为测量参考基准,或生成一个原理误差可分离或修正的测量参考基准,是实现非球面和自由曲面试件形状高精度检测和量值溯源的关键问题。




图1 非球面测量原理图

目前,非球面和自由曲面试件的测量都是以平面或球面实物标准器作为测量参考基准的。而实物标准器的精度往往是有限的,并且标准器的复制和量值的传递过程较为复杂,且必然存在制造误差和传递误差。

以目前的加工水平,平面标准器的平面度可以达到 $\lambda/50 \sim \lambda/100$ ^[1]。采用三平面互检和奇偶函数法可以实现平面的绝对检测,并分离作为测量参考基准的平面标准器的形状误差。另外,1893年,Rayleigh提出了使用液体平面作为测量参考基准的方法,这种测量方法假设静止液面与地球的曲率半径一致,即6371km。因此,相对于理想平面的偏差可以通过计算得到,并从测试结果中除去,所以,可以实现测量参考基准形状误差的分离,从而获得很高的测量精度。采用该方法,Powell和Goulet在1998年对一个240mm口径的光学表面进行测量,其测量精度达到 $\lambda/100$ ^[2]。Vannoni等于2005年利用液体平面作为绝对平面标准实现绝对测量,口径为90mm的平面测量不确定度可达7nm(PV)^[3]。用这样的液体表面作为参考基准面是很理想的,但液体平面易受震动、空气扰动、温度变化等干扰;同时,使用液面作为干涉参考基准平面时,被测光学平面必须水平夹持,这样,由于万有引力作用引起的被测平面下垂也会引入一定误差,因此,难以在科学实验中达到理想精度。

目前,标准球面的形状误差可以优于 $\lambda/20$ 。为进一步提高测量精度,人们采用Jenson于1973年提出的三位置法绝对检测球面的方法进行绝对测量,其测

量精度 PV 值可优于 $\lambda/50$, RMS 值可达到 $\lambda/300$ ^[4]。另外,还采用光纤点衍射的方法生成球面波前。理论计算表明,如果小孔直径是 $4\mu\text{m}$,衍射波前在数值孔径 $\text{NA}=0.1$ 时,对理想球面的偏差小于 $\lambda/10000$ ^[5]。

以标准平面或球面作为测量参考基准,进行非球面和自由曲面试件的测量,只是一种间接的比较测量。为保证检验结果的准确性和有效性,对所有的测量值,原则上应溯源到国家计量标准。因此,要想实现非球面的绝对检测,首先需要生成一个理想的非球面作为测量参考基准,并作为量值溯源的标准器。理想非球面和自由曲面生成机理的突破是制约非球面和自由曲面形状量值溯源的关键难题。传统的非球面波前是通过补偿法在平面或球面干涉系统中引入附加光学元件得到的。计算全息法(CGH)的发展为非球面波前的生成提供了一个新的途径,如图2所示。计算全息法的最大特点是:理论上,只需要知道被测面的数学模型,就可以产生任意形状的波面。因此,可以采用计算全息产生所需的任意“标准非球面或自由曲面”。1994年,亚利桑那大学采用曲面计算全息法,实现380mm和840mm口径凸非球面镜检测^[6]。采用计算全息法生成“标准非球面或自由曲面”的形状精度仍然受限于其线宽、加工误差、装调误差等^[7~9]。




图2 计算全息生成非球面波前原理图^[10]

由此可见,制约非球面和自由曲面形状量值溯源的关键问题是理想非球面和自由曲面试件测量参考基准面的生成。测量参考基准面是非球面和自由曲面试件检测和量值溯源的基础,决定了测量精度和量值溯源的正确性和有效性。因此,要实现非球面和自由曲面形状的量值溯源,必须解决如下问题:①理想非球面和自由曲面生成机理的研究;②理想非球面和自由曲面能够在自然环境下很容易地生成,如液体平面那样。

只有解决上述问题,才能真正实现非球面和自由曲面试件的形状的高精度量值溯源。

参 考 文 献

- [1] 殷纯永.现代干涉测量技术.天津:天津大学出版社,1999:250.
- [2] Powell I, Goulet E. Absolute figure measurements with a liquid-flat reference. *Appl. Opt.*, 1998, (37): 2579—2588.
- [3] Vannoni M, Molesini G. Validation of absolute planarity reference plates with a liquid mirror. *Metrologia*, 2005, 42: 389—393.
- [4] Jensen A E. Absolute calibration method for Twyman-Green wavefront testing interferometers. *J. Opt. Soc. Am.*, 1973, 63: 1313.
- [5] 吴朔, 沙定国, 林家明, 等. 光纤点衍射干涉仪测量凹球面面形. 中国仪器仪表学会第九届青年学术会议论文集, 2007: 238—241.
- [6] Burge J H, Anderson D S, Ketelson D A, et al. Null test optics for the MMT and magellan 6.5-m f/1.25 primary mirrors. *Proceedings of SPIE*, 1994, 2199: 658—665.
- [7] Truax B E. Absolute interferometric testing of spherical surfaces. *Proceedings of SPIE*, 1991, 1400: 61—68.
- [8] Evans C J, Parks R E. Absolute testing of spherical optics. *OSA Technical Digest*, 1994: 185—187.
- [9] Burge J H. Efficient testing of off-axis aspheres with test plates and computer-generated holograms. *Proceedings of SPIE*, 1999, 3782: 348—357.
- [10] Poleshchuk A G, Nasyrov R K, Asfour J M. Combined computer-generated hologram for testing steep aspheric surfaces. *Optics Express*, 2009, 17(7): 5420—5425.

撰稿人: 谭久彬 王伟波

哈尔滨工业大学超精密光电仪器工程研究所

$\mu\text{N}/\text{nN}$ 级微小力量值溯源

Traceable Force Metrology System at $\mu\text{N}/\text{nN}$ Degree

在国际单位制 SI 中，力是一个依据牛顿第二定律的导出量。由于同一地区的重力加速度 g 为常数，所以，小力值的最高基准可由标准砝码的质量和经过精确测量的当地重力加速度组合而成。目前，符合 OIML (国际法定度量衡组织) 最小的标准砝码为 1mg ，约等于 $10\mu\text{N}$ 。 1mg 以下的质量标准，材料、制作加工工艺、量值复现方法等方面都有极高的特殊要求，并且微小质量标准的不确定度已与其名义值相当甚至更大。因此，为了复现 μN 以下微小力值，一方面需要研制更小的标准原器砝码并研究其量值溯源方法，减小砝码测量的不确定度；另一方面就是研究新的力值复现方法，提高微纳力值计量的准确度。

图 1 为未来微纳力值溯源体系框图。图中的微纳力值标准装置既可以采用电学方法复现微纳力值，又可以与采用砝码复现的力值进行比对(校验)。通过力学量、电量、几何量的精确测量实现微纳力值的 SI 溯源。具有特殊结构和较




图 1 未来微纳力值溯源体系框图


高计量性能的微悬臂梁或微纳力值传感器, 经过微纳力值标准装置的校准后, 可以作为传递标准校准原子力显微镜、仪器压痕仪或其他微纳力学测试仪器, 进而实现新材料、生物、微电子、制造、航空航天等各个应用领域中微纳力值的测量实现了 SI 溯源。

近年来以美国标准与技术研究院为代表的一些国外著名计量研究机构, 如德国国家物理技术研究院 (PTB)、韩国国家标准与科学研究院 (KRISS) 等制定了中长期发展规划, 主要目标是建立可溯源至 SI 单位的 μN 以下的力值基标准装置。

图 2 所示为美国标准与技术研究院研发的静电力天平 (EFB), 采用同轴圆柱式电容器产生已知大小和方向静电力, 这种静电力天平既可以将静电力与静重砝码复现的力值进行相互校核, 又可以校准各种微力传感器^[1]。NIST 的静电力天平基本上实现了 $10^{-8} \sim 10^{-4} \text{ N}$ 范围内的力值测量, 通过将静电力与标称值为 1mg、10mg、20mg 的标准砝码产生的自重力相比较, 包含所有已知修正因素在内其相对误差处于 10^{-4} 量级^[2]。



(a) 真空系统外观图



(b) 静电力天平

图 2 美国标准与技术研究院的静电力天平

德国 PTB 精密工程处的 nN 力值计量工作组提出了一种如图 3 所示的基于静电力原理的铝盘摆装置, 测量的力值小于 10^{-5} N , 力值分辨力为 10^{-12} N , 在 10^{-10} N 力值时, 相对不确定度达到 0.8%^[3,4]。

韩国 KRISS 采用如图 4 所示的基于电磁力天平 (量程 5g, 分辨率 $0.1 \mu\text{g}$) 的原子力显微镜悬臂梁校准系统 (nN 力值校准器, NFC) 可以校准的原子力显微镜悬臂梁的刚度和灵敏度, 测量结果的相对标准不确定度优于 0.5%^[5,6]。




图3 德国 PTB 的纳牛力值标准装置




图4 韩国 KRISS 的原子力显微镜悬臂梁校准系统

通过以上分析可以看出,目前,以美国标准与技术研究院为代表的一些著名研究机构已经开始了这方面的工作,采用了不同的溯源方法,并且取得了一定程度的进展,但其研究成果还并没有得到世界的公认,因此,在世界范围内建立统一的 $\mu\text{N}/\text{nN}$ 级微小力值溯源体系仍然是一个尚未解决的科学难题,在研究过程中有可能出现一些没有预料到的问题或未知因素:①在微观领域,物质的特性与宏观世界是不一样的,尽管装置是宏观的,但当进行微纳力值 SI 溯源时,仍有可能遇到一些与宏观条件下的现象和规律不同的情况发生;②温湿度、气压气流、振动、电磁干扰等环境因素将直接对微纳力值测量的准确度造成影响。

参考文献

- [1] Leach R, et al. Recent advances in traceable nanoscale dimension and force metrology in the UK. *Measurement Science and Technology*, 2006, 17(3): 467—476.
- [2] Pratt J R, Smith D T, Newell D B, et al. Progress towards systeme international d'unités traceable force metrology for nanomechanics. *J. Mater. Res.*, 2004, 19(1): 366—379.
- [3] Nesterov V. Facility and methods for the measurement of micro and nano forces in the range below 10^{-5} N with a resolution of 10^{-12} N (development concept). *Measurement Science and Technology*, 2007, 18(2): 360—366.
- [4] Nesterov V. A nanonewton force facility and a novel method for measurements of the air and vacuum permittivity at zero frequencies. *Measurement Science and Technology*, 2009, 20(8): 1—6.
- [5] Kim M S, Choi J H, Park Y K, et al. Atomic force micro scope cantilever calibration device for quantified force metrology at micro-or nano-scale regime: The nano force calibrator (NFC). *Metrologia*, 2006, 43(5): 389—395.

-
- [6] Choi I M ,Kim M S ,Woo S Y ,et al .Parallelism error analysis and compensation for micro-force measurement .Measurement Science and Technology ,2004 ,15 (1) :237—243 .

撰稿人：齐永岳

天津大学精密仪器与光电子工程学院

不依赖于时间基准与光速的长度自然基准及米定义

The Natural Length Standard and Definition of Meter Independent from the Time Standard and Light Speed

我们生活在三维空间中，长度是一个基本物理量。从住房到出行，从穿衣到购物，都要知道物体的大小、距离的长短，都要用长度对它们进行表征。在生活、生产、科学研究和商业中，长度都是一个接触最多、最基本的物理量。

量是物体属性的表征，量分为基本量与导出量^[1,2]。在量制中，那些被认为是彼此独立的量称为基本量，而另一些为基本量的函数所定义的量称为导出量。例如，长度是人们生活、生产中接触最频繁、最直接、最容易直观理解的一个物理量；时间是人们时刻经历的另一个物理量，它们都是基本量。有了这两个基本量，就可以根据物体从一点移动到另一点走过的距离（路径长度）和所花费的时间获得另一个物理量——物体的运动速度，速度就是一个导出量。

为了对事物的属性进行评定，又需要确定量的单位。单位的准确定义、精确计量对于生产发展、商业贸易、科学进步、解决纠纷、法制公正都有至关重要的意义。

早在 3700 年前，中国已经为建立长度单位做出了重要贡献。从我国的出土文物中发现，商代已经有按手的长度制作的带刻度的象牙尺，长约 15.8cm。在英国更是以脚(foot)作为长度计量单位的名称。显然，按照人体的一部分确定长度单位，缺乏客观性。

1799 年，法国确定以经过巴黎的地球子午线的四千万分之一作为长度单位，定名为“米”，并按实际计量结果，用材料性能稳定的铂铱合金制作了米原器，存放在巴黎国际计量局。以实物基准作为米原器，对于量值统一起了重要作用，是计量科学一大进步。然而，总会有一些物理、化学等因素，使制成的米原器量值发生变化。此外，这种以实物为基准的米定义不便于量值传递，需要制作一系列副本，逐级传递，以减小由于频繁使用可能引起的实物基准量值的变化。再次，万一由于天灾或战争，米原器丢失或损坏，更会造成量值上的混乱。

量值统一的基本要求就是有一个客观、稳定、可复现的自然基准。可复现性就是只要遵守一定的条件，就能够在世界各地复制出体现同样量值的物体或现象。

1927 年、1960 年国际计量大会分别通过了以波长为 643.84696nm 的镉红线和以氪 86 的 $2p_{10}$ 和 $5d_5$ 之间跃迁所对应的辐射为基础的米定义。科技的发展，使这两种谱线都已不能满足要求，1983 年第 17 届国际计量大会上通过了米是光

在真空中于 $1/299792458\text{s}$ 时间间隔内所经路径的长度的定义，这是计量科学又一历史性的重大进步^[3,4]。

从国际上着手建立统一的量制开始，一直将长度作为一个基本量。1875年，国际上一些发达国家签订了米制公约，就将长度作为一个最基本的物理量。从米制公约的名称可以看到，长度单位“米”是一个基本单位。1954年，第十届国际计量大会确定长度、质量、时间、电流、温度、发光强度6个基本物理量，1974年，第十四届国际计量大会又增加物质的量为基本量。1959年，我国国务院发布了“关于统一计量制度的命令”，确定米制为我国的基本计量制度，确定长度是一个基本量^[5,6]。

然而，按照1983年第17届国际计量大会上通过的米的定义是“光在真空中于 $1/299792458\text{s}$ 时间间隔内所经路径的长度”，这一定义有以下不足：

(1) 根据这一定义，长度实际上已经不再是基本物理量，而是由时间和速度导出的物理量，这与客观存在不符。

(2) 这一定义是建立在光在真空中的速度不受任何因素影响，是恒定不变的基础上的^[7]。而光的真空速度恒定不变只是一种假设，没有充分理论和实验根据。充其量说，只是在目前科技水平下，难以觉察其变化而已。实际上，光速是受一系列因素影响的。目前的米定义以光在真空中所经路径为限制，排除了介质的影响，但不能排除外部环境对它的影响。美国标准与技术研究院正在进行重力波对光速影响的研究，要求测量不确定度优于 1×10^{-17} 。除了重力场以外，还存在许多其他场，如电磁场、辐射场，也难以证明它们对光速没有影响。

(3) 目前，以光在真空中在 $1/299792458\text{s}$ 内走过的路程来定义长度单位米的主要原因是测量时间可以测得很准。以什么量能够测得准来确定哪个量是基本物理量，是不科学的。基本物理量应该是客观存在的，而不是由测量手段、测量方法确定的。

(4) 不便于传递，长度单位“米”还是需要通过一些特定的谱线的波长进行传递，以与实物的尺寸或运动的距离进行比较。

应当相信能够从自然界找到直接体现、定义长度单位的物质、现象与方法。为此，需要开展一系列基本物理的研究，发展基本计量手段与技术的研究。本课题的研究将会带来对客观物质世界许多基本问题更深入的理解，也会促进科学技术与生产，特别是物理学与计量科学的巨大发展。

本课题的主要研究目标是建立一种不依赖于时间基准与光速的长度自然基准，并确定米的新定义，它具有单一性、稳定性、可再现性。主要研究内容包括以下几点：

(1) 进行物质或现象构成的基础理论研究，寻找一种能够提供可再现的、

稳定的单一长度参数的物质或现象,这种长度参数可以是晶格参数、波长等。单一性意味着这种物质的各个晶格之间的距离间隔都是高度一致的;或者谱线的宽度非常小,波线具有良好的单色性。稳定性意味着它受各种外界因素的影响非常小,长时间保持恒定。再现性指可以在世界各地按一定条件复现所需要的物质或现象,复现所定义的长度单位。

(2) 进行影响选定的基准物质或现象长度的因素,以及控制、减小这些因素影响的方法研究。

(3) 开展新的计量技术的研究,研究测试所选择基准物质或现象的长度参数及其单一性、稳定性的方法。

(4) 研究新的长度基准比对、传递的方法。

本研究包括一系列基础研究与众多的技术难点,它涉及物质精细结构或现象的形成与排列等基础物理的研究,涉及物质存在的介质及周围环境对物质的精细结构或现象形成与排列的基础理论研究。随着对量子物理的深入研究及激光科技的发展,已经制成了一系列波长单一性与稳定性达到 10^{-15} 的激光器,一些晶体的晶格常数单一性与稳定性也已达 $10^{-8} \sim 10^{-9}$,但必须对影响其波长与晶格常数稳定性的因素进行更深入的研究。新定义的长度单位必须在包括其单一性、稳定性、再现精度,以及使用的方便性,便于比对与传递等方面比现有定义更加优越。

除了上述基础理论研究外,还需要从技术上开展一系列精确计量测试技术的研究。因为没有相应的计量技术,就无法开展对影响物体或现象量值的因素深入研究,无法提出进一步提高量值稳定性的途径,也无法确定所研究量值的单一性与稳定性。

参 考 文 献

- [1] 鲁绍曾.现代计量学概论.北京:中国计量出版社,1987.
- [2] 《计量单位》手册翻译组.ISO 标准手册:计量单位(1979).北京:技术标准出版社,1981.
- [3] Petley B W.Physical Constants and the SI.London:NPL News,1987.
- [4] Documents concerning the new definition of the meter.Metrologia,1984,19:163—177.
- [5] 中华人民共和国国家标准 GB3100~3102-82.量和单位.北京:中国标准出版社,1984.
- [6] 国家计量局法规处.中华人民共和国计量法文件资料汇编.北京:计量出版社,1985.
- [7] Einstein A.Zur elektrodynamik bewegter Körper.Annalen der Physik,1905,17:891—921.

撰稿人:张国雄

天津大学精密仪器与光电子工程学院

通过测定阿伏伽德罗常数定义质量自然基准

Redefinition of SI Base Unit for Mass by Determining the Avogadro Constant

全球化是当前社会生产的主要特征。计量技术是实现全球化经济和生产活动的前提和保障。计量基准是实现计量的基石,它赋予计量结果明确一致的物理含义。高精度计量基准的定义、复现和传递是提高整个国家计量水平的基础和关键。

计量基准的定义随着科技的进步不断完善。最早的计量基准通常通过实物定义。然而,实物基准存在稳定性差、不易保存、使用不便、易被污染损坏等缺点。目前除“千克”外,其他计量基准都已通过自然常数定义。自然基准所复现的量值不受时间、地点、材料、样品尺寸、温度等各种因素的影响,具有很高的复现性和稳定性。以自然基准取代实物基准,是计量科学发展的必然趋势。“千克”是目前唯一基于实物——国际千克原器定义的国际基本单位^[1]。在过去的一百多年中,大量测量数据表明,国际千克原器的质量变化了约 5×10^{-8} kg。通过自然常数定义质量基准是当前国际计量界的迫切需要。

目前,科学家们提出了基于普朗克常数 h 或阿伏伽德罗常数 N_A 重新定义千克的设想^[2]。阿伏伽德罗常数起源于 1811 年阿伏伽德罗为解释原子反应现象时所提出的假设:“在相同的温度和压力下,等体积的任何气体都含有相同的分子个数。”1909 年, Perrin 提出了阿伏伽德罗常数的概念:“ N_A 是一个普适常数,它描述了 1 mol 物质中所包含微粒的个数。” N_A 与千克之间的关系为

$$M = N_A m_a$$

式中, M 为物质的摩尔质量; m_a 为物质的原子质量。 N_A 把宏观和微观世界联系起来。采用 N_A 重新定义千克可描述为:“1 kg 等于处于基态的碳 12 原子静止质量的 $N_A / 0.012$ 倍。”^[2]

阿伏伽德罗常数定义质量基准的原理可以粗略地类比于我国古代的“黍尺”。我国古代将黑黍百粒横排构成的长度称为一“黍尺”,黑黍一千二百粒所装的容器为一黄钟之命,重半两。这两者都是通过对“微小”颗粒计数来实现定义。值得一提的是,我国古代的度量衡在当时是非常先进的。例如,载于《汉书·律历志》的黄钟柜黍定度量衡的方法,将长度的单位定义基于律管黄钟。由于黄钟长度的变化将导致音调的变化,黄钟柜黍法就和声学原理结合起来,曾领先于西方很多个世纪,这一历史也说明了计量技术和社会发展水平的

关联性。

阿伏伽德罗常数定义质量基准的想法很直观,人们通过“数”原子个数即可获得质量基准。但是,困难是阿伏伽德罗常数太巨大了,根据 CODATA 数据库 2006 年的纪录,阿伏伽德罗常数为

$$N_A = 602214179(30) \times 10^{23} \text{ mol}^{-1}$$

也就是说,人们必须计数约 60 兆亿亿个碳原子才能得到 12g 碳。显然,要高效而精确地复现这一定义,必须有更好的方法。科学家目前提出了采用 X 射线晶体密度摩尔质量法(X-ray crystal density molar mass, XRCDMM)^[3]测定 N_A 常数,这一想法的基本思路是:以高纯度单晶²⁸Si 为材料,经精密加工制成质量约 1kg、直径约 94mm 的硅球,采用 X 射线和光学组合干涉仪测量硅晶格常数 a ,再通过测定该硅球的体积和质量确定其密度 ρ ,最终计算得出 1mol 质量 M 中硅原子的个数,即 N_A 值为

$$N_A = 8MV/(ma^3)$$

式中,常数 8 表示单位晶胞内的硅原子个数; V 为硅球体积; m 为硅球质量。展开讲,用 XRCDMM 法测定 N_A 常数包括以下重要环节:高纯度单晶²⁸Si 材料的制备及缺陷分析,超高精度硅球的加工,摩尔质量测定,晶格常数测定,体积测定,表面氧化层膜厚测定,硅球质量测定等。XRCDMM 法的技术路线及其部分装置的照片如图 1 所示。

XRCDMM 法的原理初看起来很简单,它之所以成为国际公认的计量难题之一,是由于极高的测量精度目标:约 2×10^{-8} 的相对不确定度。由于 N_A 是通过测量 a 、 M 、 V 、 m 等参数间接计算得到的,根据测量不确定度理论可知,要实现上述合成精度目标,各参数的测量相对不确定度如 $u(M)$ 、 $u(V)$ 和 $u(m)$ 应优于 2×10^{-8} , $u(a)$ 应优于 7×10^{-9} 。要实现这一研究目标,必须在深入分析相关测量方法的物理机理和关键影响因素的基础上,研制、改进和应用各种测量设备,探索各种测量方法,并在建立恰当物理模型的基础上进行数据分析,最终对各项误差进行综合评估。当前, N_A 值的测量相对不确定度已达 4.6×10^{-8} ^[3],但要实现设定目标,需克服各个环节的诸多计量难题。限于篇幅,本文仅以晶格常数和硅球体积的测定为例。硅晶格常数的测定由 X 射线和光学组合干涉仪实现^[4]。为了实现高精度测量,需要对光学干涉仪的光源进行高精度稳频(如采用碘吸收法稳频或光频梳技术),研制具有亚纳米精度且测量范围可大至 50mm 的干涉系统。目前,晶格常数的测量精度可优于 1×10^{-8} 。硅球体积可通过测量直径和球形偏差间接测定。直径的测量通常采用光学平面或者球面 Fizeau 干涉仪^[5]。和平面干涉仪相比,球面干涉仪的测量光波面为球面,因此,可获取更多的直径及其球形偏差测量数据,从而获得更高的测量精度。研究难点包括:①高精度稳频光源;②高性能光学器件和仪器的研制;③实现的温度测量和控




图1 XRCDMM 法的技术路线及其部分装置的照片(来源:德国 PTB)

制至 $\pm 2\text{mK}$ 以减小材料热膨胀的影响;④干涉仪信号解调技术;⑤CCD 传感器信噪比的提高等。此外,还需补偿由于硅表面氧化层相位延迟所导致的测量系统误差。目前,采用球面干涉仪可达到的直径测量精度约为 1×10^{-8} ,这一精度指标可类比为测量北京和上海之间距离并得到约1cm的测量精度。

参 考 文 献

- [1] Davis R. The SI unit of mass. *Metrologia*, 2003, 40: 299—305.
- [2] Becker P, de Bievre P, Fuji K, et al. Considerations on future redefinitions of the kilogram, the mole and of other units. *Metrologia*, 2007, 44: 1—14.
- [3] Becker P, Bettin H, Danzebrink H U, et al. Determination of the Avogadro constant via the silicon route. *Metrologia*, 2003, 40: 271—287.
- [4] Martin J, Kuetgens U, Stuempel J, et al. The silicon lattice parameter—an invariant quantity of nature? *Metrologia*, 1998, 35: 811—817.
- [5] Nicolaus R A, Geckeler R D. Improving the measurement of the diameter of Si spheres. *IEEE Transactions on Instrumentation and Measurement*, 2007, 56: 517—522.

撰稿人：戴高良
德国联邦物理技术研究所

空间超高精度时空基准

Ultra-high Precision Space-Time Reference System in Space

时间和空间是物质存在的基本形式,时间表征了物质运动的连续性,空间表征了物质运动的广泛性,因此,我们在描述物体运动的时候必然要引入时间基准和空间基准的概念。

1. 时间基准^[1,2]

时间基准研究包含定义时间系统,建立和维持时间参考框架。时间系统是基础,规定了时刻的参考标准和时间间隔的尺度标准。时间参考框架是时间系统的具体实现,通过守时、授时和时间频率测量技术,实现和维持某一区域或全球范围内时间的统一。时间基准必须建立在某个频率基准的基础上,一般选择某个周期性运动作为时间计量的频率标准,同时要求这个周期性运动必须是均匀的和连续的。

人类有史以来第一次给出明确的时间计量国际标准是在 19 世纪末。1896 年,在巴黎举行的国际性学术会议上,给出了“平太阳日”的严格定义,并规定平太阳日的 $1/86400$ 为 1 平太阳秒,格林尼治子午圈下中天时为时刻 0 时整,这就是以地球自转周期为基准的世界时(UT)。1956 年,在 UT 中引入了极移修正 $\Delta\lambda$ 和自转速度的季节性修正 ΔT_s ,由此而得到世界时 $UT1 = UT + \Delta\lambda$ 和 $UT2 = UT1 + \Delta T_s$ 。由于地球自转轴摆动和自转速度不均匀,虽然进行了部分修正,世界时系统的日长精度仍只能到 10^{-8} 。1960 年,第十一届国际计量大会上正式批准了以地球绕太阳公转周期为基础的历书时(ET),定义“秒”为 1900 年 1 月 0 日历书时 12 小时起算的回归年的 $1/31556952.9747$ 。历书时在理论上是均匀的,但实际技术实现上比较困难,需要长年连续观测月亮或其他行星数据,因此,实际精度比理论精度低得多,只在 1960~1967 年间被采用。由于物质内部原子跃迁所辐射和吸收的电磁波频率具有极高的稳定性和复现性,使人们寻求高精度时间频率基准的研究从天文学领域转向了量子无线电物理学领域。1967 年,第十三届国际计量大会首次利用原子时来定义“秒”,即“在零磁场中 Cs 原子(133)基态的两超精细能级间的跃迁频率的 9192631770 个周期所持续的时间”。原子时是目前世界上精度最高的时间频率基准,原子频标的准确度已经达到 10^{-15} 。世界上,原子时系统主要包括国际原子时(TAI)、协调世界时(UTC)及各卫星导航系统时。

原子时通过原子钟来守时和授时,因此,原子钟振荡器频率的准确度和稳定度便决定了原子时的精度。原子频标的稳定度与下式有关:

$$\sigma_y \propto \frac{\Delta\nu}{\nu_0} \cdot \frac{1}{S/N}$$

理想的原子频标应该具有极高的跃迁频率 ν_0 、无限窄的共振谱线宽度 $\Delta\nu$ 。目前,原子钟的量子跃迁频率在微波波段(约 10^{-10} Hz),研究更高的光频波段($10^{14} \sim 10^{15}$ Hz)的原子光钟将是未来重要的发展方向。为进一步提高原子钟的精度,有大量研究工作要做,突破因热噪声引起的激光线宽限制、克服原子数起伏引起的噪声、克服因背景辐射而引起的频率漂移等技术都需要进一步研究。发展超高准确度和稳定度、微型化甚至芯片化的原子钟是今后原子频率基准研究的重点和难点。建立全球时间参考框架,进行跨国家、跨洲的原子钟连接和频率对比研究,也是今后面临的重要挑战。

2. 空间基准

空间基准研究包含定义空间参考坐标系,建立和维持参考坐标框架。参考框架由一组参考点的坐标(及其随时间的变化)构成。参考系包含了为定义、建立和维持参考坐标框架所需的理论概念,通常包括一组相关的模式、过程和方法,涉及观测过程的描述、运动方程、信号传播方程和有关参数及常数^[3]。

空间坐标参考系统可以分为两大类:一类是坐标轴相对于宇宙遥远天体固定不动的天球坐标系,具体实现即天球参考框架;另一类是坐标轴随地球在空间一同旋转的地球坐标系,具体实现即地球参考框架。参考框架的建立,须明确采用何种基本原理,然后用所选用的原理描述由物理实体组成的体系,进而通过观测导出物理实体的位置坐标及其时间变率。由于建立参考架的方式不同,导致了参考框架的多样性。ICRS 和 ITRS 分别是 IERS(国际地球自转与参考系统该服务)最新规范的国际天球参考系统和国际地球参考系统,其具体实现分别是国际天球参考框架 ICRF 和国际地体参考框架 ITRF, IERS 的地球定向参数 EOP 提供了 ICRF 和 ITRF 的永久性连接^[4,5]。

天球参考框架最初是基于地面上的光学观测得到的,1879 年和 1883 年分别产生了天文星表 FC(基本星表)的北天和南天部分,位置精度约 0.5as。在随后的一个世纪左右的时间里,这一参考架得到不断改进,从“FC”至“FK5”的系列星表,位置精度从 0.5as 提高到 21mas。20 世纪 70 年代开始,随着甚长基线干涉测量技术(VLBI)的发展,能以亚毫弧秒甚至更高的精度得到河外射电源的位置,以此观测数据为基础,20 世纪 90 年代产生了包含 608 个射电源的射电星表,后又增补为 667 颗,被 ICRF 采纳,其源位置精度和残余旋转分别为 0.25mas 和 0.02mas/yr。另外,欧洲航天局于 1997 年发表了依巴谷星表,它的

坐标架在历元 J1991.25 与河外源实现的参考架对准的不确定度是 $\pm 0.6\text{mas}$ (1σ), 残余旋转速率是 $\pm 0.25\text{mas/yr}$, 成为 ICRS 在光学波段的主要实现。在地球参考坐标框架方面, 从 1988 年开始, IERS 相继发布了 ITRF88~2005 一系列参考框架标准。美国国防部于 20 世纪 80 年代中期建立了 WGS84, 并且不断对其进行精化处理。欧盟建立了高精度、稳定的伽利略参考框架 GTRF。俄罗斯建立了 GLONASS 导航卫星的参考框架 PZ90。此外, 许多国家和地区也都建立了自己的大地坐标系统^[3,5,6]。

空间参考框架精度的提高有赖于建立参考架的物理和数学模型的完善、物理常数精度的提高、观测源的选择和观测水平的提高等, 这需要在理论和技术上长期的努力改进。

超高精度时空基准的建立、维持和精化研究, 需要深入分析已有时空基准的定义和维持技术, 研究综合多种现代空间技术、天文观测和大地测量手段, 完善数据综合和分析方法, 探索建立和维持天地空一体化的时空基准方法, 其理论的深入研究和技术的进一步突破对现代科学研究和工程技术都具有重要意义。

参 考 文 献

- [1] Audoin C, Guinot B. The Measurement of Time: Time, Frequency and the Atomic Clock. Cambridge: Cambridge University Press, 2001.
- [2] 翟造成, 张为群, 蔡勇, 等. 原子钟基本原理与时频测量技术. 上海: 上海科学技术文献出版社, 2009.
- [3] 潘炼德. 最新规范的参考系及有关问题. 陕西天文台台刊, 2002, 25(2): 131—140.
- [4] Altamimi Z, Sillard P, Boucher C. ITRF2000: A new release of the International Terrestrial Reference Frame for earth science applications. Journal of Geophysical Research, 2002, 107(B10): 2214.
- [5] 龚健雅. 对地观测数据处理与分析研究进展. 武汉: 武汉大学出版社, 2007.
- [6] 魏娜, 施闯. 地球参考框架的实现和维持. 大地测量与地球动力学, 2009, 29(2): 135—139.

撰稿人: 张高飞 尤 政
清华大学精密仪器与机械学系

如何实现长度计量中的高精度、无导轨大尺寸测量

How to Make High-precision and No-guide Measurement in Large Scale Metrology

1. 为什么要进行高精度、无导轨大尺寸测量

从被测对象的尺度范围上分类,空间尺度测量大致可分为小尺寸测量、大尺寸测量和距离测量三类,本质上都是与更高一级别的基准进行比对。一般来讲,大尺寸测量主要指 500mm 至几百米范围内物体或距离的测量。从理论上讲,现有的小尺寸精密测量原理在大尺寸测量中均可以采用,但对大尺寸测量来说,螺旋测微仪、工具显微镜等难以使用,而制造测量范围 10m 及 10m 以上的三坐标测量机不仅困难,而且会极其昂贵。以传统激光干涉仪为典型代表的高精度测量方法需要长度至少等于被测长度的精密导轨,随着测量距离的增长,不仅导轨加工难度不断加大、价格昂贵,而且自身的检测也是一个难以解决的问题,且在很多现场检测的情况下,这样的导轨根本无法架设^[1]。

2. 基于合成波长的光学干涉测量

目前,高精度的长度计量主要是利用激光波长作为基准进行比对。根据干涉计量的基本原理,其基本表达式为: $L = (N + n)\lambda/2$, 其中, λ 为测量激光的波长, L 为被测长度, N 和 n 为所包含的整数级次和小数级次。根据数学分析,若 L 的已知初始值的测量误差小于所用波长的 $1/4$, 上述整数级次唯一确定,则只要测量出小数级次 n , 即可精确地测量出长度 L 。基于以上基本原理, 1977 年, Tilford^[2] 提出了一套完整的利用多波长尾数决定未知被测长度的分长度的分析方法, 其主要思想是波长链的形成和逐级精化。随着近年来激光器技术的发展, 这一思想得到了真正应用。目前常采用的是一种所谓的合成波长的方法, 主要通过利用两种波长的激光及一定的光路设计来构成用于绝对距离测量的干涉仪。由理论分析, 如果两激光的波长分别为 λ_1 和 λ_2 , 则合成波长 $\lambda_c = \frac{\lambda_1 \lambda_2}{\lambda_1 - \lambda_2}$ 。可见, 当这两列不同波长的激光波长相差很小时, 其合成波长 λ_c 将远大于其中任何一个波长。于是, 其可确定距离 $\lambda_c/2$ 也大大提高。

基于以上思想, 法国的 Bourdet 和美国的 Beholz 使用 CO₂ 激光器先后在 13m 测量范围达到 70 μ m 的测量精度和在 10m 范围上得到 0.03 μ m 的测量精度,

英国国家物理实验室的 Lewis 采用三波长组合及阶梯干涉计量技术在 1.5m 上得到 30nm 的测量精度^[3,4]。我国浙江大学和清华大学等从数据处理等角度开展研究,实现了纳米级的大尺寸测量^[5]。图 1 所示为根据以上基本原理的拍波干涉仪,其中,在光电接收器 1 上得到的是调幅信号,其空间周期为上述合成波长 λ 。




图 1 拍波干涉仪原理示意图

为在更大测量范围内实现更高精度的测量,上述方法中还有许多问题需要解决,主要包括谱线分布适中、具有更好合成波长性能的激光器的研究、位相测量精度的提高、频率稳定性的改善等。另外,从以上原理出发,参考显微镜的发展历史,我们不难想到,利用更短波长的激光器可以实现更高精度的测量,如 X 射线等激光器在以上大尺寸测量方法中的应用是值得深入思考的问题。

3. 基于激光视觉的测量方法

除上述基于激光干涉的测量方法外,另一个值得一提的是基于激光视觉的测量方法。在这种方法中,对目标点的测量是通过摄像机和结构光源组成的视觉检测单元进行的。点光源或线光源发出的光束照射到被测目标上,其图像由摄像系统采集并通过后续计算处理得出被测点在摄像机坐标系中的坐标。为了实现绝对坐标的测量,还需要将这个摄像机坐标系下的坐标统一到一个全局坐标系下。为此,可采用高精度经纬仪、激光跟踪仪等进行系统标定。如在激光跟踪仪标定过程中,视觉传感器和激光跟踪仪同时测量三个以上的目标点,即可求解出传感器坐标到全局坐标的旋转矩阵和平移向量。当完成对所有传感器的标定后,就可以方便地利用以上系统进行测量了^[6]。图 2 为激光视觉测量的原理示意。容易看到,虽然这种方法精度略低,但具有很高的检测效率,所以,也得到了有效的应用。




图2 激光视觉测量原理示意图

4. 无导轨大尺寸测量的其他影响因素及讨论

大尺寸测量的环境条件相对较差，空气扰动、环境振动温度、湿度等均会对测量结果造成影响。另外，由于大尺寸测量的实施往往难以在理想的计量实验室中进行，相应测量基准和现场溯源成为非常重要也更加困难的问题。

另外，除上面方法外，还有经纬仪测量系统、室内 GPS 方法等，尽管测量精度上也不能达到光学干涉测量的精度，但在量程范围、适用性、测量速度和便捷性方面具有优势，也是值得进一步研究的方法。

参 考 文 献

- [1] 张福民, 曲兴华, 等. 现场大尺寸测量量值溯源. 天津大学学报, 2008, 41(10): 1167—1171.
- [2] Tilford C R. Analytical procedure for determining lengths from fractional fringes. Appl. Opt., 1977, 16(70): 1857—1860.
- [3] Qi B, Tausz A, et al. High-resolution, large dynamic range fiber length measurement based on a frequency-shifted asymmetric Sagnac interferometer. Opt. Lett., 2005, 30(24): 3287—3289.
- [4] 王林, 赵洪志, 等. 大尺寸绝对距离测量的现状及发展. 光学技术, 1997, 2: 47—52.
- [5] Chen B Y, Yan L P, et al. Development of a laser synthetic wavelength interferometer for large displacement measurement with nanometer accuracy. Optics Express, 2010, 18(3): 3000—3010.
- [6] 任永杰, 郝继贵, 等. 机器人柔性视觉检测系统现场标定技术. 机器人, 2009, 31(1): 82—87.

撰稿人：任大海

清华大学精密仪器与机械学系

复杂系统分形(自相似)结构与功能及行为

Research on Fractal Structure of Complicated System and Its Performance and Behavior

复杂性科学是以非线性数学为基础,以现实问题为背景,包括物理、化学、生物、经济、社会等各方面的新兴交叉领域一个总的称呼,它是研究复杂系统中各组成部分之间非线性相互作用的特征、机理、规律及其复杂性,揭示系统的演化、混沌、涌现、自组织、自适应、自相似等机理及其内在规律的一门新兴的交叉学科,是 21 世纪的一门具有重大理论及实际意义并亟待开展研究的崭新科学^[1]。

作为复杂性科学研究内容的复杂系统,至今尚没有统一的定义。但是,复杂系统有以下几个共同特点^[1,2]:①大量的作用者或单元组成,它们之间存在强烈的耦合作用,表现为各元素之间相互作用、相互影响,形成复杂的关系网;②系统是开放的,与外部环境之间不断地进行物质、能量、信息方面的交换,保持系统远离平衡态;③在环境和单元相互作用下,系统能自组织、自加强、自协调、自适应,并根据各种信息调整规则,涌现出以前从未有过的新规则,表现出更高层次、更加复杂、更加协调职能的有序性;④复杂系统的行为既不是完全确定的,也不是完全随机的,相互作用开始,将有微小变化,但不同的微小变化可导致重大差异的结局。

复杂系统涵盖极广,生物系统、生态系统、环境系统、经济系统、管理系统、社会系统、工程系统等都属于复杂系统,对人类生存、科学发展、社会进步影响深远,意义重大。

正是由于复杂系统如此重要,故而此课题一经提出,立即引起了科学界的广泛关注。早在 20 世纪 80 年代,我国战略科学家钱学森教授就以其深刻的洞察力,预见到复杂系统的意义及发展,组织领导了复杂系统的研讨班,开始研究复杂系统,他提出了“开放的复杂巨系统”^[2]的概念,并于 1992 年对复杂系统的研究方法提出“从定性到定量的综合集成研讨厅体系”的设想,把人的思维、思维的成果、人的经验、知识、智慧及各种情报、资料、信息统统集成起来,从多方面的定性认识上升到定量认识。

复杂系统几乎涉及所有学科,非常复杂,开展研究难度大,既要分析系统的组成单元,又要对单元之间复杂的相互作用规律进行探讨,最后还需进行总体整合研究。复杂系统根本没有定量的数学模型,需要从不同的学科、不同的

侧面,用不同的方法和工具,进行多方面的交叉研究^[2]。

复杂性科学的研究方法不同于传统科学的研究,它是近代以来科学方法论的又一场革命,将为我们提供全新的了解大自然奥秘的新手段^[2]。我国学者首先提出用分形理论、自相似结构来研究复杂系统,具有独创性与领先性^[3]。

分形理论^[4,5]是研究自然界自相似几何图形的一种理论,该理论用自相似性来刻画这些复杂现象,认为自然界中复杂事物(仅指几何意义上的)局部与整体之间存在某种相似性,且有一定形成规律,认知事物时总能把复杂事物分解为若干简单的要素来研究,弥补了包括欧氏几何和微分几何等传统几何在刻画非规则形状时所固有的缺陷,很好地满足了人类在科学技术不断进步的条件下更深刻地了解和反映真实客观世界的迫切需求。

受到此分形理论的启发,复杂系统可通过其分形(自相似)结构与功能行为来研究。自相似结构是复杂系统演化形成的、实际存在的且具有广泛代表性的结构。基于自相似结构,可以采用与系统总体相似的降维简化子系统对系统总体进行研究,分析其功能及行为,以小见大,由点及面,得到复杂系统总体特性,可以有效减少研究复杂度。

对于测量与仪器学科而言,复杂系统的分形是至关重要的。如在工业控制领域中,由于复杂环境干扰因素多,规模庞大,数学模型复杂,大规模工业系统十分复杂,对此类复杂系统的控制是建立在信息获取,亦即是测量学科的基础之上的。对于这一类复杂系统的测量问题,就需要将该复杂系统进行分形,演化成可测量的、简单的子测量系统。在生物医疗领域,医疗仪器面向的分析对象是较工业系统更加复杂,且至今尚存有许多未知机理的生命系统——人体。对于人体这一复杂系统的研究,通过利用相似子模型进行系统的简化是一个研究发展的必然趋势。

现阶段,复杂系统自相似结构与功能行为研究主要取得了如下成果^[3,6]:
①从较广泛的研究中得到了一种体现对称、相似结构与控制问题间内在联系的普遍规律,即对称相似结果可导致控制系统在多个方面对多个问题的一系列简化;
②研究了一些新型的对称结构系统,如循环对称、旋转对称、反对称等,提出新的相似性概念,如商相似、可控相似、状态相似等;
③全息相似、全息控制的发展,用具有整体系统的全部信息的低阶系统,来寻求对整体系统的控制规律;
④利用自相似结构对复杂系统的仿真在复杂适应系统、大系统、人工生命、神经网络等方面取得了长足的进步与丰硕的成果。

虽然现阶段复杂系统自相似结构研究取得了许多成果,但尚有大量问题亟待继续深入与扩展,新的问题不断涌现^[3]。首先,没有从复杂系统中分形出合适的、能够充分反映整体复杂系统性质的、降维简化的自相似结构的理论方法,分形时更多的是依靠研究者经验,对不同复杂系统的分形建模造成很大困扰;

其次,采用自相似结构化简复杂系统与原系统间存在一定偏差,如何将该偏差控制在允许范围内是实现复杂系统自相似结构的基础;再者,不同子系统间的协调控制是一个亟待解决的难题。由于复杂系统由许多子系统构成,各子系统通过相互协作完成复杂控制任务。因此,应在子系统协调控制的前提下实现复杂系统分析(自相似)结构。同时,随着复杂系统应用的扩展,不同系统间的交叉理论也有待进一步研究。另外,现阶段复杂系统自相似结构的研究主要集中在相对简单的复杂系统上,对于复杂度很高的系统的研究还处于起步阶段,尚待深入研究与探索。

复杂系统的自相似结构及功能及行为的研究是一个有丰富内容及发展前景的课题^[3]。

参 考 文 献

- [1] 蔡世民.复杂系统的若干动力学问题研究[博士学位论文].合肥:中国科学技术大学,2009:1—22.
- [2] 张嗣瀛.复杂系统与复杂性科学简介.青岛大学学报(工程技术版),2001,16(4):25—28.
- [3] 李喜先.21世纪100个交叉科学难题.北京:科学出版社,2005:219—225.
- [4] 程锦.复杂系统的分形图形生成方法及其在非线性动力学可视化动力学中的应用研究[博士学位论文].杭州:浙江大学,2005:1—20.
- [5] 萧蕴诗,汪镭.基于分形思想的复杂系统建模实例研究.控制与决策,2001,16(1):100—103.
- [6] 徐庚保,曾莲芝.复杂系统及其仿真研究.计算机仿真,2008,25(11):1—5,20.

撰稿人:王 雪 张 星
清华大学精密仪器与机械学系

Mathieu 方程与谐振式传感器动态特性

Analytical Solution Problem for the Dynamic Characteristics of Resonant Sensors

现代信息技术的三大基础技术就是信息的获取、传输和处理,即传感器技术、通信技术和计算机技术。传感器技术的发展程度,影响、决定着人类认识世界的程度与能力,人类认识到的客观世界就是能够利用各种各类的传感器技术测量到的范围与程度。因此,传感器技术在现代信息技术乃至对人类文明的发展过程中起着举足轻重的作用。

传感器的核心是能够直接感受或响应被测量的敏感元件。传感器依据其敏感元件的工作机理可分为应变式、压阻式、电容式、热电式、压电式、谐振式等。其中,谐振式传感器基于机械谐振原理,以谐振元件作为敏感元件感受被测量。由于该类传感器自身为周期信号输出(准数字输出),只用简单的数字电路即可转换为易与微处理器接口的数字信号。同时,由于谐振敏感元件的重复性、分辨力和稳定性等非常优良,可实现高精度的谐振式传感器。因此,谐振式传感器是一类非常重要的传感器,已成为当今人们研究的热点^[1,2]。

目前,已经实用化的谐振式传感器包括谐振筒压力传感器、谐振膜压力传感器、谐振弦压力传感器、谐振式硅微机械压力传感器、谐振式硅微机械加速度传感器、石英振梁式压力传感器及谐振式科氏质量流量传感器等,在石油石化、大气测量、航空机载、测试计量等发挥了重要作用^[1]。图 1 为北京航空航天大学与太原航空仪表有限公司联合研制的谐振筒压力传感器,该传感器对气体压力测量的精度优于万分之 1.5,保证了飞机大气参数测量的精度,使飞机飞



图 1 高精度谐振筒压力传感器

行高度的测量精度达到万分之五,同时在地面测试、气象参数测量中得到了广泛应用,该传感器具有完全的主知识产权^[2]。

常规的谐振式传感器实现测量的过程相当于改变了谐振敏感元件的等效刚度与(或)等效质量,在静态(或缓变)测量过程中,谐振敏感元件的等效刚度与(或)等效质量的变化是缓慢的,其特性可以用一个二阶常微分方程来描述。而在实际测量过程中,如谐振筒压力传感器、谐振式 MEMS 陀螺、谐振式加速度传感器等,被测量快速变化,即工作于动态测量中^[3~6]。例如,飞行器进行大机动飞行时,气压高度的实时测量非常重要,就要求谐振筒压力传感器具有非常好的动态特性。因此,对谐振式传感器动态特性的研究非常重要。

例如,以梁为谐振敏感元件的动态特性的微分方程可描述为

$$\frac{\partial^2}{\partial x^2} \left(EJ \frac{\partial^2 w}{\partial x^2} \right) - N(t) \frac{\partial^2 w}{\partial x^2} + \rho A \frac{\partial^2 w}{\partial t^2} = 0 \quad (1)$$

式中, $N(t) = \varepsilon \cos(\omega_f t)$ 相当于作用于梁谐振敏感元件的是轴向力,为一交变量,其角频率 ω_f 是主谐振系统——弹簧质量块谐振系统的谐振角频率。事实上,式(1)描述的方程与经典的 Mathieu 方程具有很强的映射关系,归一化的 Mathieu 方程可描述为^[3,7,8]

$$\frac{d^2 x}{dt^2} + [K - 2\alpha \cos(2t)]x = 0 \quad (2)$$

式中,刚度 K 表示常值刚度或缓变的准常值刚度,对应于常规谐振式传感器的静态测量过程; $2\alpha \cos(2t)$ 为交变刚度,对应于常规谐振式传感器处于简谐的动态测量过程。

另一方面,近年来发展起来的一类直接输出频率的 MEMS 谐振陀螺的测量原理(静态测量中)也可以由式(2)的 Mathieu 方程描述。

综上,通过改变谐振敏感元件的等效刚度与(或)等效质量的常规谐振式传感器的动态特性或直接输出频率的 MEMS 谐振陀螺的测量原理遵守 Mathieu 方程所描述的特性。由于 Mathieu 方程的数学模型属于变参数常微分方程,所以,它所描述的物理现象也称为“参数激励振动系统”。Mathieu 方程解析解的突破可以直接应用于频率输出的谐振式传感器敏感元件的优化设计,进而为提高谐振式传感器的性能奠定坚实的理论基础。

Mathieu 方程只是在 20 世纪 50 年代国外出版的一本学术著作中进行了介绍,而具体解如何实现没有相关阐述。国内到目前为止还没有发现相关报道。由于该类微分方程在结构参数上具有周期函数组成部分,目前既没有找到实现其解析的方法,又不能直接用通常的非线性微分方程的近似求解来研究。现在,只能采用 Matlab 等大型计算机软件,通过拼凑的办法,一点一点提高其精度。同时,也找不到相关的理论依据。而实际对该类传感器的设计也是通过经验和试

凑的方法来实现的。如果根据实际工程应用背景,紧密结合谐振式传感器的工作机理,开展基础或应用基础研究,该理论能够取得一定突破,取得高精度的近似解,这将对谐振式传感器敏感元件的精确设计,进而提高谐振式传感器整体性能,产生重要影响。

参 考 文 献

- [1] Doebelin E O. Measurement Systems Application and Design. New York: McGraw-Hill, 2004.
- [2] 中国科学技术协会. 2006—2007 仪器科学与技术学科发展报告. 北京: 中国科学技术出版社, 2007.
- [3] Zhuang H H, Fan S C, Guo Z S, et al. Dynamic characteristics analysis of vibrating cylinder pressure transducers (VCPT). Sensors and Actuators A: Physical, 2010, 157(2): 219—227.
- [4] Shkel A M, Acar C, Painter C. Two types of micromachined vibratory gyroscopes. IEEE Sensors, 2005, 531—536.
- [5] Seshia A A, Howe R T, Montague S. An integrated microelectromechanical resonant output gyroscope//Proceedings of the 15th IEEE MEMS Conference, Las Vegas, 2002, 722—727.
- [6] Gallacher B J, Burdett J S. Dynamic analysis of a microelectromechanical systems resonant gyroscope excited using combination parametric resonance. Journal of Mechanical Engineering Science, 2006, 220, 1463—1479.
- [7] McLachlan N W. Theory and Application of Mathieu Function. Oxford: Oxford University Press, 1964.
- [8] DeMartini B E. Chaos for a microelectromechanical oscillator governed by the nonlinear mathieu equation. Journal of Microelectromechanical System, 2007, 16(6): 237—245.

撰稿人: 樊尚春

北京航空航天大学仪器科学与光电工程学院

原子干涉陀螺仪中隔离重力的干涉方法

Interferometry Method for Atomic Interferometer Gyroscope to Isolate Gravity

随着现代物理的快速发展,量子力学、原子操控、现代光学等领域的飞速进步,尤其是从20世纪90年代末至今,冷原子(1997年、2001年诺贝尔物理学奖)、原子光学(2005年诺贝尔物理学奖)等关键物理基础理论和技术的突破,以原子作为敏感介质的元器件得到了空前的关注。

原子和光子一样,具有波粒二象性,利用其波动的Sagnac效应,可以实现与光学陀螺仪类似的原子干涉陀螺仪,其敏感角速度的原理如图1(左)所示,原子团通过在起点分束、在终点汇合,形成一个闭环回路,当有角速度存在时,在终点汇合处会产生相位差,该相位差的大小即反映了角速度的大小。原子干涉陀螺仪的实现原理如图1(右)所示,对于入射的原子团,采用对射的激光分别对该原子团进行分束、反射,原子团在这些激光的作用下构成原子运动的闭环回路,最后利用激光对原子的干涉信号进行读取,并以此敏感角速度。理论分析表明,原子干涉陀螺仪的灵敏度比光学陀螺仪高出 10^{10} 倍以上^[1],主要是由于原子的质量远大于光子的相对运动质量,对角速度更加敏感。




图1 原子干涉陀螺仪的工作原理

目前,国际上有多家研究机构开展了原子干涉陀螺仪的研究工作。美国斯坦福大学于1997年在国际上首次实现了原子干涉陀螺仪的原理验证^[2],获得了 $1.1 \times 10^{-6} \text{ } ^\circ/\text{s}/\sqrt{\text{Hz}}$ 的短时灵敏度,2006年实现了原子干涉陀螺仪 $6 \times 10^{-5} \text{ } ^\circ/\text{h}$ 的漂移性能^[3]。值得注意的是,实现这些性能的原子干涉陀螺仪只能敏感重力方向的角速度,且采用热原子进行干涉。由于热原子运动速度快,需要的干涉

体积大,在几个立方米的量级。2006年,法国巴黎天文台在国际上首次实现了冷原子干涉陀螺仪的原理验证,该陀螺仪在重力方向的短时灵敏度为 $1.2 \times 10^{-4}^\circ/\text{s}/\sqrt{\text{Hz}}$,水平方向的短时灵敏度为 $1.2 \times 10^{-3}^\circ/\text{s}/\sqrt{\text{Hz}}$,但至今未能得到陀螺仪的长期稳定性指标^[4]。2008年,针对原子干涉陀螺仪小型化的国防应用需求,斯坦福大学实现了 $2.3 \times 10^{-3}^\circ/\sqrt{\text{h}}$ 随机游走的冷原子干涉陀螺仪,体积在 1m^3 以内,代表了目前国际上冷原子干涉陀螺仪的最高漂移性能。

近年来,原子干涉陀螺仪在欧美等发达国家得到了广泛重视,是由于其对进一步提高战略武器的惯性导航精度具有重要意义。当前装备的战略级陀螺仪主要有三浮陀螺仪与静电陀螺仪,从20世纪80年代以后,国外三浮陀螺仪与静电陀螺仪的性能基本上接近了这些陀螺仪的发展极限,极大制约了核潜艇等战略武器作战能力的提高;从90年代末开始,国外将研究重点转向了原子干涉陀螺仪,以期大幅提高战略武器的导航制导精度,从而提高武器系统的战略威慑力。因此,原子干涉陀螺仪代表了未来超高精度战略级陀螺仪的发展方向,它的成功研制与应用将具有重要的国防意义。

将原子干涉陀螺仪应用于惯性导航系统中,需要装备三个原子干涉陀螺仪构成正交的三个敏感方向进行载体的姿态测量。因此,原子干涉陀螺仪不仅需要测量重力方向的角速度,而且需要测量水平方向的角速度。但是,由于原子具有质量,原子干涉也能敏感加速度,当有重力存在时,采用传统的原子干涉方法得到的原子干涉相位差主要包含角速度项、重力加速度项、角速度与重力加速度的叉乘项。由于重力加速度相对较大,当需要分辨微弱的角速度时,干涉信号中的角速度项十分微弱,重力加速度项、角速度与重力加速度的叉乘项较强,使得系统的信噪比差。虽然传统的三脉冲对射差分干涉方法^[3]、四脉冲干涉方法^[4]可以克服重力加速项,但角速度与重力加速度的叉乘项无法被克服。对于敏感水平方向角速度的原子干涉陀螺仪,由于重力加速度并没有从干涉信号中扣除,而保持重力加速度的恒定十分困难,使得目前仅仅能够实现敏感重力方向角速度的高精度原子干涉陀螺仪,而敏感水平方向角速度的原子干涉陀螺仪比前者的精度至少低1个量级,如前述法国巴黎天文台所实现的原子干涉陀螺仪。因此,为实现原子干涉陀螺仪在惯性导航系统中的应用,必须研究新的原子干涉方法。

原子导引应用于原子干涉陀螺仪是近几年发展起来的一种新的原子干涉方法。原子导引利用磁场或光场形成的势场将原子悬浮以克服重力的影响,在此基础上对原子进行分束、反射等操控,可以提高原子干涉陀螺仪的水平方向测量精度。不仅如此,通过导引原子往复运动增加围成的干涉回路面积,不仅能够提高原子干涉陀螺仪的灵敏度,而且能够减少其敏感体积。哈佛大学面向原

子干涉陀螺仪的工程应用,与 Draper 实验室合作,在国际上率先开展了基于原子导引的原子干涉陀螺仪研究,并采用磁场对原子进行导引,于 2007 年实现了世界上首台基于原子导引的原子干涉陀螺仪,能够分辨 10 倍的地球自转角速度^[5]。2009 年,斯坦福大学也开始了基于原子导引的原子干涉陀螺仪研究,拟采用光晶格对原子进行导引。

重力加速度会对原子干涉产生重要影响,其他干扰加速度同样也会影响原子干涉陀螺仪的综合性能。相比光学陀螺仪,原子干涉陀螺仪在具有超高精度的同时,也具有加速度严重耦合的缺点。因此,面向原子干涉陀螺仪在惯性导航系统中的应用,必须研究隔离重力影响的原子干涉新方法,并扩展到克服干扰加速度的影响,从而发挥原子干涉陀螺仪超高精度的优势。国外在该方面已经开展了原子导引等方法的尝试,并取得了初步的进展。相信随着新的原子干涉方法不断涌现,将为实现更高精度、更小体积、更加可靠的原子干涉陀螺仪提供理论支持,原子干涉陀螺仪的工程应用也会越来越近。

参 考 文 献

- [1] Clauser J F. Ultra-high sensitivity accelerometers and gyroscopes using neutral atom matter-wave interferometry. *Physica B*, 1988, 151: 262—272.
- [2] Gustavson T L, Bouyer P, Kasevich M A. Precision rotation measurements with an atom interferometer gyroscope. *Phys. Rev. Lett.*, 1997, 78: 2046—2049.
- [3] Durfee D S, Shaham Y K, Kasevich M A. Long-term stability of an area reversible atom-interferometer sagnac gyroscope. *Phys. Rev. Lett.*, 2006, 97: 240801.
- [4] Canuel B, Leduc F, Holleville D, et al. Six-axis inertial sensor using cold-atom interferometry. *Phys. Rev. Lett.*, 2006, 97: 010402.
- [5] Wu S, Su E, Prentiss M. Demonstration of an area-enclosing guided-atom interferometer for rotation sensing. *Phys. Rev. Lett.*, 2007, 99: 173201.

撰稿人: 房建成

北京航空航天大学仪器科学与光电工程学院

延长原子自旋陀螺仪弛豫时间的方法

The Method of Increasing the Relaxation Time for Atomic Spin Gyroscope

近几十年来,随着对原子自旋认识的不断深入,由于原子自旋带来的超精细能级结构及能级跃迁量子化等特点,以原子自旋为敏感介质的元器件已经得到了广泛的应用。利用原子的超精细结构,研制的原子钟成为目前世界上精度最高的时间计量标准;利用原子自旋所具有的核磁共振现象,研制的核磁共振分析仪成为了现代医学等领域重要的工具;利用原子能级跃迁的量子化特性,研制的激光器成为了现代光学发展的里程碑;而原子自旋陀螺仪是原子自旋元器件的又一朵奇葩。

从 20 世纪 60 年代开始,欧美等发达国家利用核自旋磁矩测量角速度,研制出原子自旋陀螺仪(当时采用过核磁共振的手段进行检测,也称为核磁共振陀螺仪,但逐渐被光学检测手段替代)^[1],其工作原理如图 1 所示。核自旋磁矩在惯性空间中具有定轴性,当存在磁场时,核自旋磁矩绕外磁场进行拉莫尔进动。利用固连在载体的激光检测核自旋磁矩的进动频率,当载体旋转时,核自旋磁矩在惯性空间中仍然保持其原有的拉莫尔进动频率,但检测激光测量到的核自旋磁矩进动频率是拉莫尔进动频率与载体旋转角速率的叠加。由于核自旋磁矩的进动频率大小与磁场和原子核的种类相关,当磁场和原子核确定后可理论计算得到,从而可以在检测激光得到的进动频率中计算载体的旋转角速率。




图 1 基于核自旋的原子自旋陀螺仪工作原理

用磁矩替代机械转子,避免了传统转子陀螺仪中转子摩擦等影响,使得原子自旋陀螺仪没有活动部件,具有分辨率高、耐冲击、抗振动等突出特点,成为当时各国竞相研制的热点,但磁矩这种“转子”也有“摩擦”的微观现象。由于在自然状态下,原子系统呈杂乱无章的玻耳兹曼平衡状态,当偏离上述状态时,原子系统会自发地向该状态恢复,恢复的快慢即为弛豫时间。因此,核自旋磁矩的定轴性受核自旋弛豫时间影响,弛豫时间越长,类比于转子摩擦越小,核自旋磁矩的定轴性越好,能分辨的角速度越小。采用低温方式能够减少核自旋之间碰撞带来的定轴性破坏,从而延长核自旋的弛豫时间,但由于核自旋的数量少,信噪比低,另外,角速度的准确测量需要精确地控制磁场,从而实现在检测激光测得的频率中,有效分离由于磁场导致的拉莫尔进动频率,这也成为分辨率进一步提高的瓶颈。因此,受限于弛豫时间短、信噪比低、磁场稳定难等因素,基于核自旋的原子自旋陀螺仪当时仅实现了导航级的精度,与同期发展的光学陀螺仪相比,很多单位逐渐放弃了基于核自旋的原子自旋陀螺仪的研究。

2005年,普林斯顿大学偶然发现了一种新型的原子自旋陀螺仪^[2,3],利用 $\Phi 25\text{mm}$ 球体的敏感体积实现了 $2 \times 10^{-3}^\circ/\sqrt{\text{h}}$ 随机游走、 $4 \times 10^{-2}^\circ/\text{h}$ 漂移,但仍未达到该敏感体积下 $5 \times 10^{-6}^\circ/\text{h}$ 的理论可实现性能。理论分析表明,采用 $\Phi 125\text{mm}$ 球体的敏感体积可实现 $5 \times 10^{-8}^\circ/\text{h}$ 漂移,采用 $\Phi 5\text{mm}$ 球体的敏感体积可实现 $5 \times 10^{-4}^\circ/\text{h}$ 漂移,使得该陀螺仪具有突出的高精度、小型化优点,其原理如图2所示。电子自旋磁矩在惯性空间中具有定轴性,为避免电子自旋磁矩在外界磁场作用下的拉莫尔进动,采用另一种原子的核自旋磁矩自动跟踪和补偿外界磁场的变化,从而隔离磁场对电子自旋磁矩的影响。当载体转动时,电子自旋磁矩定轴保持在其原来的方向,检测激光随载体转动,其与电子自旋磁矩的夹角反映了角速度的大小。另一方面,通过核自旋磁矩与电子自旋磁矩的相互作用,可以增强在同样角速度下检测激光对电子自旋磁矩检测的灵敏度,从而提高系统的分辨率。

上述原子自旋陀螺仪不需要精确地控制磁场,而由核自旋磁矩进行自动跟踪补偿,从而保持电子自旋磁矩的定轴不受外界磁场影响。另外,该陀螺仪利用了2002年普林斯顿大学实现的一种原子自旋 Spin-Exchange Relaxation-Free (SERF)态^[3,4],该原子态不仅具有原子密度高的特点,提高了系统的信噪比,而且电子自旋的弛豫时间在同等原子密度条件下,相比普通态有3个量级地提高,使得弛豫时间长和信噪比高兼得。因此,基于电子自旋的原子自旋陀螺仪,从机理上克服了以前原子自旋陀螺仪几十年发展中遇到的瓶颈,展现了原子自旋陀螺仪强大的生命力。

若用字母“R”代表基于电子自旋的原子自旋陀螺仪与基于核自旋的原子自旋陀螺仪的理论精度之比,从物理常数看,电子自旋磁矩比核自旋磁矩高4个




图2 基于电子自旋的原子自旋陀螺仪工作原理

量级以上,使得 R 为 10^4 。但也应该看到, SERF 态下的电子自旋弛豫时间虽然相比普通态大有提高,但仍然仅在几十毫秒量级,相比核自旋弛豫时间的几十秒量级仍然较低,弛豫时间的 3 个量级下降,导致 R 有 1.5 个量级的下降。因此,综合考虑磁矩与弛豫时间,从目前实现的两类原子自旋陀螺仪来看, R 为 $10^{2.5}$,表明基于电子自旋的原子自旋陀螺仪在理论精度上具有优势。由于磁矩是物理常数,由原子的种类决定,难以改变,但如何延长电子自旋的弛豫时间仍有较大空间,需要新方法、新机理的发现。因此,类似于转子陀螺仪的支撑从液浮、气浮、三浮到静电的发展历程,弛豫时间的延长仍会将原子自旋陀螺仪的精度带入新的发展阶段,超高精度的原子自旋陀螺仪将成为现实。

参 考 文 献

- [1] Woodman K F, Franks P W, Richards M D. The nuclear magnetic resonance gyroscope: A review. Navigation, 1987, 40: 366—384.
- [2] Kornack T W, Ghosh R K, Romalis M V. Nuclear spin gyroscope based on an atomic co-magnetometer. Phys. Rev. Lett., 2005, 95: 230801.
- [3] Stoner R, Walsworth R. Collisions give sense of direction. Nature Physics, 2006, 2: 17—18.
- [4] Allred J C, Lyman R N, Kornack T W, et al. High-sensitivity atomic magnetometer unaffected by spin-exchange relaxation. Phys. Rev. Lett., 2002, 89: 130801.

撰稿人: 房建成

北京航空航天大学仪器科学与光电工程学院

超细光束探针的形成与传感机理

Forming and Sensoring of Ultrafine Beam Probe

近年来,生物体细胞内部结构及半导体表面微/纳结构的研究成为广泛关注的热点。在常用的共焦显微、扫描近场光学显微技术中,测量精度与光学探针的特性密切相关,因此,光学探针,尤其是超细光束探针的形成和传感受到广泛的关注。为了提高表面微/纳结构测量分辨力和光学存储量、减少光刻线宽、提高成像分辨率、降低系统复杂性,要求光学探针具有一定的长度。

传统的光学探针通过如图 1(a)所示的透镜或者透镜组对光聚焦获得。根据 Rayleigh 判据,若采用数值孔径一定的聚焦光学元件或系统所获得的光束直径受衍射极限限制,探针的横向尺寸与纵向尺寸同步变化,光束愈细,其衍射现象愈严重,不利于细光束的传播。常见的实例是压缩高斯光束的发散角,但这必须对光束进行扩束。由于光传播是衍射过程,光束经过一定的距离后,必将逐渐发散开来,光束宽度和发散角符合量子力学的不确定关系。根据爱因斯坦的波粒二象性原理,若能够把若干光子排列成线状来传播,能否真正实现超细光束。因此,目前面临的关键问题就是光束探针如何同时满足如下两个条件:①长距离范围内不发散的光束探针;②光束探针的横向尺寸要足够小。由此引出一个值得思考的问题是:考虑到光子自旋,光束探针的极限是否存在?在宏观尺度上能否获得无限细的光学探针。根据爱因斯坦的理论,光具有波粒二象性,若能抑制其波动性,有望降低在传播过程中的衍射,进而获得长程细光束探针。然而,粒子性占据主导的超细光学探针与被作用样品相互作用的物理机制该如何描述,以及这种超细光束如何检测,经典的电磁理论能否描述该光学探针与被测物的相互作用也成为一个问题。




图 1 通过聚焦方式获得光学探针

为了获得长程细光束探针,近年来的研究表现在:①无衍射光束。1987年,Durnin指出光束在传播方向的振幅分布为零阶 Bessel 函数时,能在任意范围内无衍射传播^[2]。②负折射材料压缩光束横向尺寸。由于倏逝波的存在,传统的聚焦光学系统不可能突破衍射极限聚焦。早期,波前编码技术、振幅和相位滤波技术都曾被用来获得突破衍射极限聚焦。1968年,苏联科学家 Veselago 提出了负折射率的概念^[3],在此基础上,英国科学家 Pendry 提出用负折射材料制作完美透镜能够实现点源成点像,且现象可借助于金属微结构激发表面等离子来实现^[4~6],由此开辟了获得超细光束探针的新时代。③利用偏振态压缩光束。德国科学家 Dorn 利用径向偏振光场对光斑进行压缩,其研究结果表明,径向偏振较线性偏振的光斑尺寸降低了至少 0.1λ ^[7]。很显然,偏振态控制在获得超细光束探针方面具有很好的优势。有研究者还结合偏振控制和二元光学相位对高斯光束的波前相位进行控制,实现光斑压缩和焦深扩展,并取得了一个重要进展,即光束的半高宽度为 0.43λ ,无衍射光束的长度即焦深为 4λ ^[8]。然而,上述方法并没有同时解决横向压缩和长度扩展。

由于微加工技术的发展,还可采用如图 1(b)所示光子晶体聚焦、整形或者利用光子晶体激光器也能得到细光束探针^[9,10]。由于具有周期调制金属微结构能实现光束超分辨率聚焦,因此,结合微加工、激光及表面等离子激发的研究,是否有望引入半导体微结构,而直接抑制光激发时的波动性,保留光的粒子性,抛开传统折射透镜而直接实现超细长程光束探针?

鉴于超细光束探针的横向尺寸很小,而现有探测器的探测单元在微米量级,因此,如何对其进行检测同样是一个值得关注的问题。如果超细光束探针表现出量子性,现有检测手段的有效性也是值得思考和探索的问题。

总之,对超细光束探针的研究分裂成为大尺度无衍射光束和光束横向尺寸压缩两方面。大量的研究表明两者不可调和。一方面要对传统透镜聚焦并滤波的方法加以深入研究,另一方面应研究结合光子晶体和表面等离子直接激发粒子性为主导的超细光束。用现有的研究方法实现超细长程光束探针是否具有局限,是否应该考虑光的量子性,超细长光束的存在性及其极限,都是该光束探针形成与传感研究中机理必须思考的问题。

参 考 文 献

- [1] Moreno E, Garcia-Vidal F J, Martin-Moreno L. Enhanced transmission and beaming of light via photonic crystal surface modes. *Phys. Rev. B*, 2004, 69(12): 121402.
- [2] Durnin J, Miceli J J, Eberly J H. Diffraction-free beams. *Phys. Rev. Lett.*, 1987, 58(15): 1499—1501.

- [3] Veselago V G .The electrodynamics of substances with simultaneously negative values of ϵ and μ .
Sov .Phys .Usp . ,1968 ,10(4) ;509—514 .
- [4] Pendry J B .Negative refraction makes a perfect lens .Phys .Rev .Lett . ,2000 ,85(18) ;3966—3969 .
- [5] Valentine J ,Zhang J ,Zentgraf T ,et al .Three-dimensional optical metamaterial with a negative refractive index .Nature ,2008 ,455(7211) ;376—380 .
- [6] Smith D R .How to build a superlens .Science ,2005 ,308 ;502—503 .
- [7] Dorn R ,Quabis S ,Leuchs G .Sharper focus for a radially polarized light beam .Phys .Rev .
Lett . ,2003 ,91(23) ;1—4 .
- [8] Wang H ,Shi L ,Lukyanchuk B ,et al .Creation of a needle of longitudinally polarized light in
vacuum using binary optics .Nature Photonics ,2008 ,2(8) ;501—505 .
- [9] Tang D H ,Chen L X ,Ding W Q .Efficient beaming from photonic crystal waveguides via
self-collimation effect .Applied Physics Letters ,2006 ,89(13) ;131120 .
- [10] Painter O ,Lee R K ,Scherer A ,et al .Two-dimensional photonic band-gap defect mode
laser .Science ,1999 ,284(5421) ;1819—1821 .

撰稿人：谭久彬 林 杰

哈尔滨工业大学超精密光电仪器工程研究所

显微仪器信息容量极限及表征

Perfect Description for Capability of Microscopy Instruments




图1 扫描隧道显微镜观测到的碳纳米管原子结构^[3]

现代显微科学仪器可以将原子的排列结构扩大 100 亿倍，从而使人得以对微观世界的物质进行立体性的观测和摄影^[1]，人们不仅能够观测到原子的大小，甚至可以观测到原子的内部运动^[2]，图 1 为扫描隧道显微镜观测到的碳纳米管原子结构。当然，人们期待借助显微仪器可以无限分辨或记录物体细节信息，然而，科学测量仪器的分辨本领真的可以被无限提高吗？这一问题可以通过探求测量仪器信息容量极限表征寻求答案。

对显微仪器而言，系统有限带宽信息容量是其提高测量能力的根本约束。如果一台显微仪器的信息容量是可以无限扩展的，那么，其分辨能力就是可以无限提高的。所谓显微仪器信息容量极限表征，是指完整揭示测量信息的存在、探测形式及其传递规律，并由此揭示显微仪器提高分辨能力的技术本质与性能极限，指引人们探索 and 发现新原理显微仪器。

普通光学照相机是人们所熟知的一种光学仪器，它通过记录光强度信息实现物体成像，然而，实际景物是三维立体的，为什么普通相机获得的图像却是平面的呢？人们认识到，物体光强度仅记录了物体的明暗信息，而光相位则载有物体的深度信息。1960 年，激光发明之后，科学家们利用激光的高相干性发明了全息照相技术，实现了三维物体信息记录与再现。全息照相技术的本质是通过同时使用光强和光相位信息实现物体信号表征，从而扩展了仪器系统的信息容量。全息照相与测量技术的发展体现了仪器信息容量扩展与极限表征的研究意义。

纵观仪器科学发展进程，显微仪器信息容量极限的表征问题始终是仪器科学家们所关注的重要问题。以光电成像测量仪器为例，科学家们希望通过系统信息容量极限的表征研究，实现仪器测量极限能力评价，并探寻提高仪器测量分辨率的技术途径与方法。1928 年，Hartley 将系统信息容量描述为 $N = \log_2 m$ ，

其中, N 表示信息容量, m 表示可能的信息状态总数^[4]。1948 年, Shannon 将信息容量的概念引入时域通信系统, 给出了著名的 Shannon 定理, 并将系统信息容量表示为 $N=2TB_T+1$, T 为信号周期, B_T 为通道带宽, “1” 表示直流分量^[5]。1955 年, Felgett 和 Linfoot 忽略直流分量, 给出二维成像系统的信息容量表达式 $N=2B_xL_xB_yL_y\log_2[(s+n)/n]$, 其中, s 、 n 分别表示信号平均功率和噪声功率, $B_{x,y}$ 为 x 、 y 方向的空间带宽, $L_{x,y}$ 为 x 、 y 方向的空间带宽^[6]。随着成像仪器信息带宽极限与完美表征问题的不断探索, Lukosz 和 Cox 等分别在 1966 年和 1986 年进一步给出信息容量的新表达式^[7,8]。2003 年, Sheppard 和 Larkin 针对 Cartesian 坐标系给出了三维空间信息的信息容量表达式 $N=3(2B_xL_x+1)(2B_yL_y+1)(2B_zL_z+1)(2TB_T+1)\log_2[(s+n)/n]$, 这一表达式被用于描述三维显微测量仪器的测量能力^[9]。

然而, 尽管上述研究成功解决了某些给定测量原理下系统信息容量的评价问题, 但随着人类科学活动不断推进, 仪器科学家们进一步认识到系统测量信息存在形式及传递规律的复杂性, 如光电探测系统信息传递能力并不局限于系统传递函数所描述的通带宽度, 待测信号的电场、磁场强度及其偏振态变化与调制方式变化均可实现系统信息传递能力扩展^[10], 这些研究进展显然已经超出了人们对系统信息传递能力的传统认知。显微仪器测量极限与表征问题研究将推动超衍射极限光学显微测量科学和超衍射极限光写入技术领域发展。

参 考 文 献

- [1] <http://www.eol.cn/20011129/3012305.shtml>.
- [2] <http://www.eol.cn/20010101/21033.shtml>.
- [3] Odom T W, Huang J L, Kim P, et al. Atomic structure and electronic properties of single-walled carbon nanotubes. *Nature*, 1998, 391: 62—64.
- [4] Hartley R V L. Transmission of information. *Bell Systems Technical Journal*, 1928, 535—563.
- [5] Shannon C E. A mathematical theory of communication. *Bell Systems Technical Journal*, 1948, 27: 379—423.
- [6] Felgett P B, Linfoot E H. On the assessment of optical images. *Proc. R. Soc. London Ser. A*, 1955, 247: 369—407.
- [7] Lukosz W. Optical system with resolving powers exceeding the classical limit. *J. Opt. Soc. Am. A*, 1966, 56(11): 1463—1472.
- [8] Cox I J, Sheppard C J R. Information capacity and resolution in an optical system. *J. Opt. Soc. Am. A*, 1986, 3: 1152—1158.
- [9] Sheppard C J R, Larkin K G. Information capacity and resolution in three dimensional imaging. *Optik*, 2003, 113(12): 548—550.

- [10] Andrews M R, Mitra P P, et al. Tripling the capacity of wireless communications using electromagnetic polarization. *Nature*, 2001, 409: 316—318.

撰稿人：谭久彬 刘 俭

哈尔滨工业大学超精密光电仪器工程研究所

具有超宽抑制频带的光学带通滤波器 形成机理与特性表征

The Formation Mechanism and Characterization of Optical Band-pass Filter with Ultra-wide Suppression Band

房屋是人类的安居之所,而窗户则使房屋更适合居住,并增加了新的功能。在建筑学上,窗户是指墙或屋顶上建造的洞口,用以使光线或空气进入室内,因而通光和使空气流通是窗户最基本的功能。诗人孟郊《织妇辞》中“筋力日已疲,不息窗下机”正是说明窗户的这一功能。窗户另外还具有信息通道的功能,诗人杜甫《绝句》中“窗含西岭千秋雪,门泊东吴万里船”形象地反映了窗户的信息通道功能,“西岭千秋雪”本是房屋外的景物信息,却通过窗户使室内的诗人可以看见。正是因为窗的这些功能,窗的概念也不仅仅限于房屋,如飞机的炫窗、汽车的车窗等。在仪器科学领域,测量信息的通道入口也称之为窗。

从信息的角度看,窗户是允许有益信息传递的一种媒介或屏障。然而,随着居住场所的特殊需要和科学技术的发展,越来越要求窗户具有阻断其他信息传递的功能。例如,普通办公和居住场所的窗户,只要能够传递有益信息(光线或景物信息)即可,对除此之外的其他信息并不关心;但在一些特殊的场合,如一些重要行政、军事、商业、科研等办公场所,要求窗户在具有透光性的同时,还能够有效屏蔽无线电和微波等波段,以防止这些场所电脑等电子设备工作时的电磁辐射传播出去,造成重要信息的“泄露”,这就需要窗户同时具有屏蔽光学波段以外其他电磁波段的滤波功能。在测量与仪器科学领域,尤其是以某种频率电磁波为测量信息载体的测量仪器,随着电磁环境的日益复杂和对仪器测量精度要求的不断提高,也要求这类仪器的窗户,即测量信息的入口具有滤波功能,保留有益电磁信息,抑制其他电磁信息。

近年来,随着人们对各个波段电磁波认识的不断深化和应用领域的拓展,无线电波、微波、红外线、可见光、紫外光等多个波段的电磁波都已经直接用于测量或者作为测量信息的载体。而且,空间电磁环境也日益复杂,除了自然界各种电磁辐射外,人们常用的各种电子设备、光学仪器、生产生活中产生的各种电磁辐射都增加到空间环境中,这就意味着,在测量环境中既有人需要利用的电磁波段,也包含其他可能对测量产生干扰的电磁波段。因此,对于以某波段电磁波为信息载体的测量而言,就需要进行相应的滤波处理,除保留需

要传递信息的电磁波段外,尽可能地将其他电磁波段滤除,尤其是要滤除对接收设备和其他电子设备产生干扰的电磁波段。例如,在以激光为载波的光学测量中,需要滤除激光波长以外光学波段能量对激光接收器的影响,同时,也需要滤除无线电波等波段对光学仪器中电子器件产生的干扰(如图 1 所示)。




图 1 理想测量仪器窗口的滤波特性

光学测量是最重要的一类测量,是目前人们认识和感知宏观、微观世界最重要的手段之一。随着光学传感和光学仪器科学研究的快速发展,追求测量精度或分辨力的提高及有用信息的选择便成为一个趋势,而为了满足这一趋势,在光学仪器中增加光学滤波器显得日益重要^[1~5]。然而,与电子滤波中带外能量被吸收损耗相比,目前应用的各种光学滤波器带外能量的抑制以反射为主,吸收部分较少,而且抑制的带宽较窄。例如,带通光子晶体滤波器仅可以实现通带两侧较窄范围内的光波的抑制,抑制能带以外的电磁波能量能够穿透滤波器,进而可能对测量直接产生影响,而滤波器反射的能量回到空间环境中,可能对传感器造成其他干扰和危害。因而,研制具有带内全透、带外全吸收的理想光学带通滤波器具有重要的科学意义和应用前景。

研制理想的超宽抑制频带光学带通滤波器是十分困难的。仅从电磁波吸收角度考虑,目前虽然已经研发出相对比较成熟的电磁波吸收材料^[6~8],但对雷达波的吸收波段宽度和吸收能力上仍不十分理想。例如,通常吸波材料对雷达波的吸收波段一般仅为一个或几个雷达波段,带宽为几个到几十个 GHz,极少有超宽波段雷达吸波能力(如从无线电波到远红外的宽波段);吸波材料的吸收能力一般从几 dB 到几十 dB,且吸波能力在吸收波段内一般呈不均衡分布;雷达波被吸波材料吸收后,多转为红外辐射发射出去,又有可能成为新的干扰源,特别是对于光学仪器和光学测量而言,在一定光学波段内全透光且能吸收宽频雷达波的材料目前尚未研发成功。目前,光学波段的透光高通滤波器或抗电磁干扰滤波器所采用的方式仍是频率选择表面技术^[9],对低频干扰采用的是反射抑制方式,而非吸收。

要形成理想的超宽抑制频带光学带通滤波器,或者以其他频率为通带的测

量窗口带通滤波器,其核心问题是保证测量需要的光学波段或其他频率电磁波在通带内具有高通透性的同时,如何对带外较宽波段的电磁波能量进行“完全捕获”而避免其反射,进而用一定的手段或方式将其“损耗或存储”,其“损耗或存储”又不产生新的对测量有危害的电磁干扰,该问题的解决也许要依赖新型材料和智能材料的发展。

参 考 文 献

- [1] 林洪榕,迟晓玲,李利军.光滤波器:结构、原理与特性.激光与光电子学进展,2001,11: 31—37.
- [2] 欧阳征标,刘海山,李景镇.光子晶体超窄带滤波器.光子学报,2002,31(2):281—284.
- [3] 梁冠全,韩鹏,汪河洲.空间与频率双性能的薄膜光学滤波器.物理学报,2004,53(7): 2197—2200.
- [4] Jeong J W, Jung I W, Jung H J, et al. Multifunctional tunable optical filter using MEMS spatial light modulator. Journal of Microelectromechanical System, 2010, 19(3): 610—618.
- [5] 吴国锋.几种新型可调谐窄带光滤波器.光子技术,2006,(2):64—68.
- [6] 谢俊磊,杜仕国,施冬梅.新型雷达吸波材料研究进展.飞航导弹,2008,(7):58—61.
- [7] Costa F, Monorchio A, Manara G. Analysis and design of ultra thin electromagnetic absorbers comprising resistively loaded high impedance surfaces. IEEE Trans. on Antennas Propagat., 2010, 58(5): 1551—1558.
- [8] Babinec P, Jirsak O. Microwave absorbing nonwoven textile from electrospun magnetically responsive nanofibers. Optoelectronics and Advanced Materials-Rapid Communications, 2008, 2(8): 474—477.
- [9] Kärkkäinen M K, Ikonen P M T. Finite-difference time-domain modeling of frequency selective surfaces using impedance sheet conditions. IEEE Trans. on Antennas Propagat., 2005, 53(9): 2928—2937.

撰稿人:陆振刚

哈尔滨工业大学超精密光电仪器工程研究所

微位移的极限问题及表征

Limitation and Description of Micro-displacement

人类在认识世界与改造世界的过程中，对微位移的产生一直是永恒的追求目标。如人类在改造世界的过程中需要对物质原子进行重组，以形成新的物质；在原子重组的过程中需要产生比原子量级更高精度的微位移，微位移产生的量值将直接决定新物质形成的种类与特性；又如在几何空间超精密测量领域中，为了提高位移或尺度测量精度，达到高的测量分辨率，需要实现对器件的调整、调焦等过程，这些调整、调焦过程要求实现微位移的产生，对微位移的要求已达到亚纳米量级。微位移的产生是通过物体的宏观运动产生的，物体的宏观位移要求组成物体的所有微观粒子均进行位置改变，物体的微观粒子结构如图 1 所示。




图 1 密排六方晶体钢球模型与密排六方晶胞模型

目前，对微位移的产生可以通过不同的原理实现，不同的原理可产生的最小位移值不同。磁致伸缩驱动器利用焦耳效应(即铁磁体在外磁场中磁化时，其长度及体积均发生变化的现象)进行驱动，其最小产生的位移可达纳米量级；压电陶瓷驱动器利用压电效应(即在缺少对称中心的晶态物质中，由电极化强度产生与电场强度呈线性关系的机械变形的现象)进行驱动，其分辨率可优于 0.1nm 。对微位移的检测主要采用现代量子力学理论实现的扫描隧道显微镜，以及随后相继出现的原子力显微镜，直接在原子的尺度上进行探测，已实现深亚纳米的位移分辨率。利用隧道电流或原子力的相互作用直接在原子的尺度上进行探测，但原子也是有一定尺寸的，当要求获得比原子的尺度更小的位移时，便出现了新的问题。

测量是在我们日常生活所在的宏观世界里进行的，所熟悉的物体(如灰尘颗

粒、飞机、行星等)的运动都可以用牛顿定律精确地描述,按照这些经典定律,物体的运动轨迹在原理上可以实现任意精度的测量,它们运动的任何不确定性都归咎于测量装置的不精密;另一方面,在原子及亚原子颗粒层面,如氢原子和电子的微观世界里,量子物理的盖然论定律处于支配地位^[1]。测量精度的提高要求产生极小的位移,位移的产生通过物体之间的相对运动,当要求相对位移量低于分子/原子尺寸一个甚至几个数量级时,物体的运动将不符合宏观描述的运动规律,如何描述物体的微小位移,探索微位移产生的极限及如何表征微位移的极限成为测量领域亟待解决的问题之一,对超精密测量科学的发展具有重要意义。

自从量子机制建立以来,人们已认识到位置的重复测量精度有一个原理性的限制,这是海森堡测不准原理的结果。海森堡测不准原理限制了同时测量一个物体的位置和速度时的精确度^[2]。海森堡测不准原理给出了同时获取物体位置 Δx 和动量 Δp 的极限: $\Delta x \cdot \Delta p \geq \frac{\hbar}{2}$, 其中, $2\pi\hbar$ 为普朗克常数。对于一个质量为 m 、振动角频率为 ω 的简谐振荡器,测不准原理给出了同时精确测量两者的极限,称为标准量子极限^[3,4]: $\Delta x_{\text{SQL}} = \sqrt{\frac{\hbar}{2m\omega}}$ 。存在量子极限的原因是: 当一个线性探测器进行位移测量时,探测器不只是探测和放大进入的信号,同时也会有一个反作用作用在所研究的对象上,从而,不仅测不准原理显现出来,也使物体达到的微位移显示出来。

但测不准原理要求相关的物理量必须存在高限与低限^[5],而在普朗克常数的定义中是存在假设的,即相互作用中体系间相互交换的能量不可小于 h ; 常数 c 的定义也是质量不等于零的物体速度的极限值是光速 c ,宏观世界中不存在质量为零的物体。在物理学的发展过程中,经验告诉我们,如果有 A 、 B 两个物理量,它们本是相关的,当我们还不知道这种相关的定律而各自给它们以任意独立单位时,就会出现一个度量常数,而实验迟早会发现这个常数。经典力学的 M. K. S. 单位制既然有三个独立单位,那么,它应该有两个度量常数。光速 c 是常数的发现说明它是时间与长度间的度量常数,那么,另一个度量常数是什么呢? 广义相对论(度规场论)认为引力常数 G 是这个度量常数,而微观的量子场论(量子规范场论)则认为作用量子普朗克常数 h 。这些常数的确定直接决定了产生位移的大小,如何描述这一常数便成为学者们争论的问题之一,同时,对微位移的产生极限成为学者研究的科学问题之一。

目前,已有实验观察到纳机械振荡器的振动位置测量的量子极限,这是由海森堡测不准原理所决定的。但海森堡原理所限制的是同时精确地获取物体的位置和动量,强调的是同时,如果在前后两次测量中只是为了精确地获取物体

的位置从而得到物体的位移量，而并不关心物体动量的变化，这时，前后两次位置之差所能够得到的最小位移量是否仍然存在一个极限值呢？这个问题可能包括两个部分：一是物体自身的最小位移量是否存在极限；二是对于该位移量，最小可敏感的程度是否存在极限。对于该问题的研究可以提高人类认识世界和改造世界的能力，促进新型物质的产生，推动对位移敏感机理的研究，促使新技术或新理论的出现，从而对微位移的发生与敏感程度的提高具有重要意义。

参 考 文 献

- [1] Blencowe M .Nanomechanical quantum limits .Science,2004 ,304 :56—57 .
- [2] LaHaye M D ,Buu O ,Camarote B ,et al .Approaching the quantum limit of a nanomechanical resonator .Science,2004 ,304 :74—77 .
- [3] Knobel R G ,Cleland A N .Nanometre-scale displacement sensing using a single electron transistor .Nature,2003 ,424 (17) :291—293 .
- [4] Teufel J D ,Donner T ,Castellanos-Beltran M A ,et al .Nanomechanical motion measured with an imprecision below that at the standard quantum limit .Nature,2009 ,4 :820—823 .
- [5] 何国柱 .物理量的极限原理和循环宇宙 .中国科学 G 辑 :物理学、力学、天文学,2007 ,37(6) :753—759 .

撰稿人：崔继文

哈尔滨工业大学超精密光电仪器工程研究所

超短或超薄波导间光能量耦合问题及传感机理

Energy Coupling and Sensing Mechanism between Ultra-short or Ultra-thin Waveguides

激光与光纤科学的发展为测量学研究提供了高相干度照明光源和新的光波传导介质,对仪器科学与技术的研究起到至关重要的推动作用。利用光在不同波导之间的相互作用引发的传感原理可以应用于不同领域,而基于波导间耦合机理的传感器件具有重要地位,如通过一束光来控制另一束光的全光开关传感装置对于实现最高速度的信号处理至关重要^[1],其光调制耦合形式如图1所示。利用波导间耦合已研制的一些性能优异的硅光学元件^[2~6]均是利用直线型或环形波导之间光能量的耦合来工作;又如利用光波导之间的耦合,通过检测入射端耦合到出射端波导的光信号变化实现对被测量值的传感,其主要利用了不同波导间的耦合特性。




图1 光调制器耦合形式

随着半导体技术和光学技术的发展,在未来各种应用领域中,利用光能量在波导之间的耦合制作的传感器件有着广泛应用,如有毒环境、易污染环境、超精密/超小/超大环境等。光能量在波导之间的耦合机理是否由某种目前人们所没有认识到的理论所支撑这一问题是目前学者尚没有解决的问题。若能够解决光能量在波导间的耦合机理问题,对于分析波导中光能量的耦合关系及不同波导间的耦合方式,如直线型波导间、环状波导间、超薄型波导间等,实现不同领域的高性能传感具有极其重要的指导意义,使得极高性能的光学元件制作与应用及利用光波导耦合实现完美传感成为可能。波导间光能量的耦合输入与

输出对于光学元件的应用、传感等领域具有重要意义。超短或超薄波导间的耦合机理问题及传感机理问题便成为学者必须面对的新的科学难题。

目前,研究较多的是采用倏逝波耦合理论分析波导间能量的传递与交换。倏逝波是全反射过程中满足 Maxwell 电磁场边值关系所必然存在的。依据倏逝波机理,光在一个波导中的光功率在传输过程中会逐渐转移到另一波导中去,把功率从一个波导全部转移到另一波导后再回到第一个波导时的传播距离为耦合长度。当一个波导处于另一波导的倏逝场中时,两者组成一个复合波导结构,两波导中的模场分布都会发生变化,倏逝场越强,则相互影响越强,模场变化越显著。沿复合波导传播的不同位置处,能量在两波导间发生不同的功率分配,类似于“拍”现象,但总能量守恒。复合波导间的耦合过程总的来说是由两波导的模式场间干涉造成的。能量交换的拍现象的产生是由于两个基模场间的干涉或差拍所致,功率的转移仅仅依赖于基模间的传播常数的差值。在目前采用的环形谐振腔与直波导的耦合形式中,环形谐振腔与直波导之间的距离都在波长范围以内,认为光能量能够通过倏逝波的形式从一个光波导耦合到另一光波导中。从能量的角度来看,通过控制环形谐振腔的折射率,在直波导的出射端可以达到非常高的消光比,即可以实现非常高的光能量耦合效率,但这是倏逝波理论所不能够解释的。倏逝波均匀地分布在以波导为中心的立体空间中,而环形谐振腔与直波导在一个平面内放置,并且两者之间相距约 $1/4$ 波长,通过倏逝波耦合的光能量无法达到较高的耦合效率。

目前的研究中主要采用的是一种环形谐振腔与一根或两根直波导间隔一定距离进行耦合的形式,这种结构已经被证明具有优异的性能,然而实际中,波导及波导间的形式多种多样,如超薄波导间等形式。对波导之间的耦合机理并没有得到完善的解释。波导是一种用来约束或引导传输电磁波的结构,电磁波在波导中的传播受到波导内壁的限制和反射,尤其是对于不同超薄波导间的传输。从理论上讲,入射光波在波导内壁满足全反射条件才能够在波导中稳定地传输,但光波导中传输的光能量是如何从一个光波导耦合到另一光波导中,即波导间的光能量耦合机理问题,尤其是对超短或超薄波导间的耦合机理问题,仍是一个学者们没有解决的科学问题,如何利用这一耦合机理问题进行完美传感机理研究也是学者们必须面对的科学问题。

参 考 文 献

- [1] Waldow M, Plotzing T, Gottheil M, et al. 25ps all-optical switching in oxygen implanted silicon-on-insulator microring resonator. Optics Express, 2008, 16(11): 7693—7702.
- [2] Dong P, Preble S F, Lipson M. All-optical compact silicon comb switch. Optics Express,

2007,15(15):9600—9605.

- [3] Lee B G, Biberman A, Dong P, et al. All-optical comb switch for multiwavelength message routing in silicon photonic networks. IEEE Photonics Technology Letters, 2008, 20(10): 767—769.
- [4] Xu D X, Delage A, McKinnon R, et al. Archimedean spiral cavity ring resonators in silicon as ultra-compact optical comb filters. Optics Express, 2010, 18(3): 1937—1945.
- [5] Lee B G, Biberman A, Sherwood-Droz N, et al. High-speed 2×2 switch for multiwavelength silicon-photonic networks-on-chip. Journal of Lightwave Technology, 2009, 27(14): 2900—2907.
- [6] Xu Q, Manipatruni S, Schmidt B, et al. 12.5Gbit/s carrier-injection-based silicon microring silicon modulators. Optics Express, 2007, 15(2): 430—436.

撰稿人：崔继文

哈尔滨工业大学超精密光电仪器工程研究所

三维超高分辨率共焦显微探测机理

Three-dimensional Sensing Mechanism of Ultrahigh Resolution Confocal Microscopy

世界上第一台光学显微镜于 16 世纪末由荷兰眼镜制造商詹森父子发明,从此一个崭新的微观世界向人类敞开了大门,显微镜的发明有力地推动了人类认识自然的进程。显微镜种类繁多,共焦显微镜是其中的一种,由美国哈佛大学 Minsky 于 20 世纪 50 年代中后期发明,并于 1961 年获得美国发明专利权^[1]。共焦显微探测原理的核心是采用点照明和点探测,并引入逐点扫描,具有高成像分辨率和独特的轴向光学层析能力^[2],图 1 所示是普通宽场显微成像和共焦显微层析成像原理的比较^[3]。共焦显微技术已演变发展成为现代光学成像与测量领域的一个重要分支^[4],如可实现对生物细胞内部结构的透视立体观测,以及对集成电路微结构进行三维层析测量等。共焦显微仪器已广泛应用于细胞生物学、病理学、眼科学、神经科学、材料科学、纳米科学、精密工程、矿物学、考古学等众多领域。




图 1 普通宽场显微成像(a)和共焦显微层析成像(b)原理比较^[3]

英国牛津大学的 Sheppard 和 Wilson 在 20 世纪 70 年代后期至 80 年代初期建立了共焦显微理论体系^[2],完整阐述了共焦显微探测和传感的基本原理,揭示了共焦显微仪器克服厚样品光学传输信息混叠、实现三维层析观测的本质,并证明在理想共焦点照明和点探测条件下,共焦显微仪器的横向分辨率是普通

宽场显微仪器横向分辨率的 1.4 倍。20 世纪 90 年代上半期, 澳大利亚悉尼大学的 Gu 以三维传递函数为主线全面、系统阐述了各种典型共焦显微模式的本质特性, 丰富和完善了共焦显微理论^[5]。

众所周知, 普通光学显微仪器能够分辨物体的最小细节为照明波长的一半, 这就是著名的 Abbe 衍射分辨率极限, 不管光学系统制作多么完善, 在根本上都受这一客观物理规律的约束^[6]。共焦显微仪器的成像分辨率虽然优于普通宽场显微镜, 但其分辨本领依然受限于衍射分辨率极限, 在可见光波段, 共焦显微仪器的横向最佳成像分辨率约为 180nm, 而轴向最佳成像分辨率约为 500nm^[6]。共焦显微仪器面临两大主要问题: 首先是三维成像分辨率的不对称性, 由于共焦扫描点扩散函数沿轴向呈现长扁椭圆状, 使得共焦显微仪器的横向分辨能力远高于轴向分辨能力, 这意味着共焦显微仪器对生物样品内部进行三维检测时, 在横向要比轴向能分辨更多细节; 其次是衍射受限造成亚微米量级低成像分辨率特性, 共焦显微仪器的横向分辨率在原理上要优于普通宽场显微镜, 但受针孔有限尺度、光学系统像差等因素的影响, 造成其实际成像分辨率的提高并不显著, 衍射效应依然是决定共焦显微仪器三维低分辨率的主要原因, 图 2(a)在原理上展示了共焦显微仪器三维成像分辨率^[7]。此外, 对于工业检测共焦显微仪器, 还存在成像分辨率和深度分辨率失衡问题, 利用干涉共焦显微技术、差动共焦显微技术等可以使共焦显微测量仪器在沿轴深度方向对单扫描点表面高度进行纳米甚至亚纳米量级的精密测量, 而横向分辨率依然在百纳米甚至数百纳米以上, 前者比后者高两个数量级以上。共焦显微仪器的低成像分辨率, 在生物领域, 限制了其对活体细胞内部蛋白质、DNA 分子等纳米尺度细微结构的观测, 甚至对 HIV 病毒(约 100nm 尺度)等的探测都是困难的; 在表面测量领域, 其对数十纳米典型线宽的微结构无法提供三维高分辨率测量。因而, 如何使共焦显微仪器在具有独特的光学层析能力的同时, 实现数十纳米甚至数纳米三维超高分辨率探测成为生物研究和仪器测量领域面临的难题!

超高分辨率共焦显微探测机理的突破, 与超分辨光学显微成像的研究密切相关。突破 Abbe 衍射分辨率极限的物理约束, 长期以来成为科学家关注和研究的热点和难点问题, 这一研究在 20 世纪末至 21 世纪初的近二十年内, 涌现出了多种新颖的解决方案^[6]。例如, 德国 Hell 为了提高生物荧光共焦显微镜的轴向分辨率, 提出了 4Pi 共焦荧光显微技术^[7], 该技术采用双物镜照明来增大显微物镜的有效孔径, 结合干涉原理, 使生物荧光共焦显微的轴向分辨率达到了百纳米量级, 在亚微米分辨率量级上实现了轴向和横向分辨率的匹配, 如图 2(b)所示^[7], 4Pi 共焦显微技术有效地提高了生物共焦检测的轴向分辨率, 是共焦显微高分辨率成像取得的重要突破。扫描共焦电子显微镜的出现^[8], 为三维超高分辨率共焦显微探测机理的研究提供了新的途径。




图 2 共焦(a)与 4Pi 共焦(b)三维分辨率比较^[7]

共焦显微仪器在光学显微发展史上占据着重要的地位，其独特的光学层析能力和高成像分辨率特性使共焦显微镜成为 20 世纪光学显微领域最重大的进展之一，探索具有数十纳米甚至数纳米量级超高分辨率共焦显微传感机理，在生物医学、细胞分子学、材料科学、纳米科学和仪器测量等众多学科领域都具有重大的科学价值！

参 考 文 献

- [1] Minsky M .Microscopy apparatus ;Unite States Patent ,3013467 .1961-10-19 .
- [2] Wilson T ,Sheppard C .Theory and Practice of Scanning Optical Microscopy .New York : Academic Press ,1984 :37—78 .
- [3] Schuldt A .Seeing the wood for the trees .Nature Milestones ,2009 .
- [4] White J G ,Amos W B .Confocal microscopy comes of age .Nature ,1987 ,328 :183—184 .
- [5] Gu M .Principles of Three-dimensional Imaging in Confocal Microscopes .New York :World Scientific ,1996 :47—310 .
- [6] Heintzmann R ,Ficz G .Breaking the resolution limit in light microscopy .Briefings in Functional Genomics and Proteomics ,2006 ,5 (4) :289—301 .
- [7] Hell S W .Far-field optical nanoscopy .Science ,2007 ,316 :1153—1158 .
- [8] Wang P ,Behan G ,Takeguchi M ,et al .Nanoscale energy-filtered scanning confocal electron microscopy using a double-aberration-corrected transmission electron microscope .Phys .Rev . Let . ,2010 ,104 (20) :200801 .

撰稿人：谭久彬 刘 涛 刘 俭
哈尔滨工业大学超精密光电仪器工程研究所

外空间极大尺度的超精密测量

Ultra-precision Measurement Method for Ultra-large Space Dimension in Outer Space

近年来,随着小卫星编队飞行、空间虚拟探测及引力波探测等大科学工程的相继实施,人类信息探索领域同时向以外太空为代表的这一极大尺度空间不断拓展,并力图在极大空间尺度里更加精确地感知、操纵相关信息和物质。作为人类感官探测能力的有效延伸和重要补充之一,测量技术也被要求同时在极大尺寸上向着超精密方向不断迈进^[1~3]。尽管目前极大尺寸上的测量精度需求并不完全满足一般超精密概念中的深亚微米特征,但从整个量程范围内来看,其相对测量精度要求高达 10^{-8} 乃至 10^{-10} 以上,而潜在的相对测量精度需求则更是高达惊人的 10^{-18} ,已超过现有超精密测量手段所能达到的极限测量精度^[4,5]。

目前,对外空间尺度进行超精密测量的重大潜在需求主要包括航天装备间相对移动位置和空间姿态的精确测量,如图 1 所示的小卫星编队飞行过程中各小卫星的间距从几百米到几十千米,而其距离测量精度要求达到亚毫米量级,相对测量精度高达 10^{-9} ,否则,将直接影响分布式小卫星雷达的三维测高、空间分辨力及慢速运动目标速度检测的精度,甚至导致无法执行对地观测任务。此外,在大科学工程(如引力波探测)研究中,要求在数十万米乃至数百万千米的范围内探测到亚纳米级的探测臂长变化,其相对测量精度高达 10^{-18} ,这完全突破了现有超精密测量方法的精度表征边界。




图 1 在小卫星编队飞行中卫星间的基线长度测量至关重要

然而,一方面人们对空间探索范围的加大和探测精度需求的加强,将要求测量方法可同时兼顾超长测量范围、超精密测量准确度需求,另一方面,这种极限

测量的测量特性表征将大大区别于现有大尺寸高精度测量方法，如激光干涉测距、差分 GPS 测距、脉冲激光测距等^[2,4]，其对测量科学的发展提出了严峻挑战。首先，在如此超大量程范围进行高精度测量，就必须要求采用具有更高相对精度的空间尺度自然基准作为测量基准，否则，将无法同时满足超大量程、超精密测量需求；其次，在超远程传输中，测量信号载体的能量将不可避免地产生急剧衰减，信噪比和测量精度也随之下降。此外，在空间飞行与探索中，编队小卫星或人造引力波观测站之间的相对运动速度高达几十米每秒到几百米每秒，因此，空间尺度的高精度测量必将是速度极快、效率极高的强实时测量过程。

围绕外空间测量中的极大尺度空间和超精密这一极限测量背景，以美国 NASA、德国宇航中心为代表的研究机构分别从测量基准、测量系统拓扑结构等方面进行了一些前期研究。考虑到超大尺度空间中的高精度测量对相对测量精度的需求高达 10^{-8} 甚至 10^{-10} 以上，在全球定位系统 GPS 中，利用相对准确度优于 10^{-11} 的铷原子时钟或铯原子时钟产生频率基准，而在汉诺威引力波观测站 GEO600 中，则采用真空波长准确度高达 10^{-11} 的稳频激光作为测量基准，近年来新研究的飞秒光梳、光钟等科学装置将可能为极大尺度空间的高精度测量提供相对精度优于 $10^{-14} \sim 10^{-18}$ 的测量基准。然而，由于非线性误差、测量噪声等不利因素的存在，目前上述测量系统的相对测量精度很难超越 10^{-10} 。

鉴于极大尺度空间中存在信号载体能量衰减，因此，测量系统拓扑结构研究是极大尺度空间、超精密测量中的另一个挑战。目前，超大尺寸空间测量中主要采用无线电波和激光作为测量信号载体，其中，无线电波由于波长较大的缘故，其测量分辨力和测量精度难以超越亚毫米，同时波束发散性强，在极大尺度空间中传输时，其在有效探测口径内的能量衰减严重；与无线电波相比，激光波长更短，发散性更小，理论上具有更小的能量衰减和更大的可测范围，但由于激光衍射发散本质特性和往返衰减过程，使得测量设备收到的激光能量随测程增加而呈 4 次方急剧衰减，无法完成有效测量。为解决这一问题，国际上成立了双向激光测距研究小组，拟通过双向激光传输机制来降低信号能量衰减，提高测量范围；而美国 NASA 和德国宇航中心等更是提出了如图 2 所示的 LISA 计划，该计划设想在分别相距 500 万公里的 3 颗航天器之间，将利用 3 次单程激光传输来降低激光能量衰减，完成极大尺度空间的超精密测量任务。

通过测量基准、测量系统的拓扑结构的初步研究，人们已经迈出了极大尺度超精密测量研究的第一步。然而，极大尺度空间超精密测量的探测机理与特性表征已大大超出现有超精密测量方法的范畴，当前阶段对下一代外空间超精密测量的研究主要集中在方法的科学性讨论与地面等效模拟验证阶段。随着研究的深入，在外空间的实际测量应用中将出现更多的科学难题。在下一步研究中，需在测量信息载体双向传输、时间频率基准-空间尺度基准有机转化、外空




图2 LISA 计划中的激光干涉系统拓扑结构图

间尺度测量手段的校准等方面进行理论基础和应用技术的开拓^[2], 实现测量距离、精度和动态特性等测量特性的有机统一, 提供外空间极大尺度信息获取手段, 积极推进人类向海洋、天空和宇宙探索的进程。

参 考 文 献

- [1] 庄松林,肖中汉.我国仪器仪表与测量控制科技的发展.自动化仪表,2009,30(5):1—6.
- [2] Gorham P,Folkner W,Blackwood G.Enabling concepts for a dual spacecraft formation-flying optical interferometer for NASA's ST3 mission.ASP Conference Series,Optical and IR Interferometry from Ground and Space,1999,112—117.
- [3] The LIGO Scientific Collaboration,The Virgo Collaboration.An upper limit on the stochastic gravitational-wave background of cosmological origin.Nature,2009,460:990—994.
- [4] Kroes R, Montenbruck O,Bertiger W,et al.GRACE baseline determination using GPS.GPS Solutions,2005,9:21—31.
- [5] Degnan J.Simulating interplanetary transponder and laser communications experiments via dual station ranging to SLR satellites //15th International Workshop on Laser Ranging, Canberra,2006,80.

撰稿人: 谭久彬 胡鹏程

哈尔滨工业大学超精密光电仪器工程研究所

分子量级精度圆、球、圆柱形状标准的形成

The Manufacturing, Measurement and Expression of Circle, Sphere and Cylinder Standards with Molecular Precision

在形状测量中,离不开各种形状标准器来进行量值传递及溯源,如在基本几何要素圆度、球度、圆柱度的测量中就需要有相应圆、球、圆柱的测量的参考标准,即圆、球、圆柱标准器。

圆、球和圆柱形状是几何形状中最基本的形状要素,因此,提高其测量精度对牵动几何形状测量水平的提升具有重要意义。传统的圆、球、圆柱形状标准器是采用金属、陶瓷或石英玻璃等制造材料,通过精密/超精密加工工艺获得,其圆度最高的也不过是十数纳米级,圆柱标准器的圆柱度则在微米量级^[1,2]。

圆、球、圆柱形状标准器是以物质宏观表现形式存在(实物标准),从微观上看,它们是由一个个原子或分子组成,这就激发了测量科学家的一个向往,即如何在分子量级上将圆、球、圆柱形状标准做到极限——分子量级的圆、球、圆柱形状标准。

期待中的分子量级形状标准器可采用纳米加工制作方法,通过原子和分子的搬迁、去除、增添和排列重组手段形成^[3]。在各种材料中,单晶硅拥有完整的点阵结构晶体及各向异性,它硬度高、脆性大,在室温下没有延展性,是分子量级精度圆、球、圆柱形状标准器的理想材料,其单体结构如图 1 所示。采用单晶硅排列来制作分子量级精度圆、球、圆柱形状标准,除晶体本身的缺陷外,如点缺陷、位错、层错和微缺陷^[4,5],缺陷量级约在 10^{-10} m,其制作精度至少可提高一个数量级(圆柱度标准器的精度提高的更多,约 2~3 个数量级),则可使量值传递及溯源误差减小 1~3 个数量级。

以单晶硅为材料的圆度标准器、球度标准器和圆柱度标准器(如图 2~图 4 所示)的形成、探测与表征存在如下难题:




图 1 单晶硅晶体结构图^[6]




图 2 分子量级圆度标准器圆度示意图




图3 分子量级球度标准器球度示意图





图4 分子量级圆柱度标准器圆柱度示意图

(1) 标准器的制备形成机理。

为实现分子量级的圆、球、圆柱形状标准器的制备,可采用扫描探针原子操纵加工技术来对标准器表面原子、分子进行搬运、去除、增添和排列重组。

① 原子和分子的搬运。1990年,美国 Eigler 等在低温和超真空环境下,用 STM 将镍表面吸附的 Xe(氙)原子逐一搬运,最终以 35 个 Xe 原子排成“IBM”三个字母,每个字母高 5nm, Xe 原子间最短距离约为 1nm,如图 5 所示^[7]。

图5 原子排列成 IBM^[8]

② 原子的去除。1993年,日本的 Aono 发表在室温条件下用 STM 加脉冲电压从 Si(111)-7×7 表面去除硅原子,机理为场蒸发。无论正负脉冲均能去除单个硅原子,表明硅原子可以成为正离子,也可以成为负离子而被电场蒸发^[9]。

中国科学院北京真空物理实验室使用 STM,加大直流偏压,在 Si(111)-7×7 表面去除硅原子,获得原子级平直沟槽,沟宽 2.33nm。1996年,中国科学院物理研究所纳米物理与器件实验室庞世谨等在 Si(111)-7×7 表面利用 STM 针尖加电脉冲移走硅原子,形成沟槽,写出“中国”字样^[10]。

这些都为实现分子量级的圆、球、圆柱形状标准器的制备提供了基础,但上述工作都是在几个原子上进行的,以一个 Φ50mm 的球形标准器为例,其表面

积约为 7850mm^2 , 表面排列的硅原子个数量级在 10^{12} , 对这些硅原子进行搬运、去除、增添和排列重组等操作, 工作量是巨大的。

(2) 分子量级圆、球、圆柱标准器的测量与表征。

在非接触测量中, 如光学测量, 作用光斑的尺度与形状滤波特性的关系需要讨论, 在接触测量的过程中, 存在接触变形。重力作用下, 各标准器存在重力变形, 在球度测量中还存在夹持变形, 这些都将对标准器形状和测量结果产生影响, 采用表层显微力学探针检测法可得到试件表层的弹性变形、塑性变形、蠕变等多种信息, 该技术为计算标准器与传感器和测量参考基准间的关系提供了基础。但是, 如何确定分子量级圆、球、圆柱标准器在形成时因点缺陷、位错、层错和微缺陷等微观误差与测量时形状标准器宏观误差之间的对应关系都是科学家们要解决的问题。

参 考 文 献

- [1] Donaldson R. A simple method for separating spindle error from test ball roundness error. *Annals of the CIRP*, 1976, 21(1): 125—126.
- [2] Horikawa O, Maruyama N, Shimada M. A low cost, high accuracy roundness measuring system. *Precision Engineering*, 2001, 25(3): 200—205.
- [3] Wang Y, Herron N. Nanometer-sized semiconductor clusters—materials synthesis, quantum size effects, and photophysical properties. *J. Phys. Chem.*, 1991, 95(2): 525—532.
- [4] Zhou M, et al. Brittle-Ductile Transition in Diamond Cutting of Silicon Single Crystals. London: Taylor & Francis, 2001: 447—460.
- [5] Bhushan B, Li X. Micro-mechanical and tribological characterization of doped single-crystal silicon and poly-silicon film for micro-electromechanical systems. *J. Mater. Res.*, 1997, 1: 54—63.
- [6] <http://www.xinkexue.com/wiki-doc-docid-4661.html>.
- [7] Eigler D M, Schweizer E K. Positioning single atoms with a scanning tunnelling microscope. *Nature*, 1990, 05(344): 524—526.
- [8] <http://wiki.ujelly.org/index.php?doc-view-10575>.
- [9] Uchida H, Huang D H, Grey F, et al. Site-specific measurement of adatom binding energy differences by atom extraction with the STM. *Phys. Rev. Lett.*, 1993, 70: 2040—2043.
- [10] 庞世谨, 刘宁. 原子操纵的进展. *电子显微学报*, 1996, 15(2): 99—108.

撰稿人: 谭久彬 黄景志 谷 伟
哈尔滨工业大学超精密光电仪器工程研究所

大尺度测量中绝对测量精度高和测量范围大之间矛盾的协调问题

Conflict between High Absolute Accuracy and Large Range in Large Scale Measurement

测量领域内一直存在着绝对精度高和测量范围大之间的基本矛盾,即对于某一测量仪器设备,如果测量的绝对精度高,则其测量范围受到限制;相反,如果测量的范围大,则其测量精度亦受到限制。

图1说明了绝对测量精度与测量范围之间的矛盾。蚂蚁和大象分别用自己的脚步来测量距离,假设蚂蚁每一步的长度是1mm,而大象每一步的长度是1m。那么,所测得的长度等于走过的步数乘以相应的步长。因为蚂蚁的步长只有1mm,可以达到毫米级的测量精度,测量精度较高,但如果要测量一段很长距离,就需要走很多步,且每步的均匀性和行走路线的直线性都要严格保证,这是很困难的;对于大象,情况相反,因为其步长为1m,少量的步数就可以轻易测量较长的距离,只是每一步都比较大,只能实现1m的较低测量精度。图中的蚂蚁和大象可以看作两种不同的测量仪器,测量精度高的仪器测量范围比较小,而测量范围大的仪器测量精度不高。事实上,每种测量仪器设备都有其自身的测量范围与绝对精度,两者相互制约。这种制约关系是测量领域内存在的共性问题,只是在常规尺度测量中,涉及的测量范围较小,绝对测量精度问题不太突出。

随着大型装备制造技术的快速发展,大尺度条件下的精密测量技术已经成为基础支撑技术之一。大尺度测量是指几十米至几百米范围内物体的空间位置、尺寸、形状、运动轨迹等的测量,由于测量范围的显著增大,绝对精度与测量范围之间的矛盾显得非常突出。

表1列举了几种测量仪器及其性能指标,可以看出,不论是不同种类的测量仪器,还是相同种类不同型号的仪器,绝对测量精度都是随着测量范围的增大而呈显著下降趋势。目前,尚无一种理想的测量仪器及方法能协调好绝对精度高和测量范围大之间的矛盾,尤其是在上百米的测量,这些仪器的绝对测量精度都不高。如何解决大尺度测量中高绝对精度与大测量范围之间的矛盾,在绝对精度与测量范围之间找到一种平衡来满足实际应用的需要,是当前理论研究和工程应用所面临的挑战。




图 1 用大象和蚂蚁步长测量距离的比较

表 1 几种测量仪器与方法^[1]

测量仪器	精度	测量范围
三坐标测量机(Leitz PMM—C Infinity)	0.5 μm	1.2m
三坐标测量机(Leitz PMM—G 40.30)	5.1 μm	7m
激光跟踪仪(Leica AT901)	10 μm	80m
数字经纬仪(Leica TM5100A)	5 $\mu\text{m}/\text{m}$	100m
全站仪(Leica TDRA 6000)	0.25mm	100m

注：仅列举一些常见型号的仪器。

绝对精度高与测量范围大之间的矛盾有其深层次原因。首先，对于一般的测量仪器设备，其动态范围是有限的，动态范围是指所能测得的最大信号与最小信号之比，最大信号代表测量范围，最小信号代表分辨力，而分辨力直接决定测量精度。图 2 给出了两个测长仪器的示值，左边的以 cm 为单位，最小刻度值为 0.2cm，最大测量范围为 6cm；右边的以 m 为单位，最小刻度值为 0.2m，最大测量范围为 6m。虽然两者的测量精度和测量范围不同，但量程(测量范围)与最小刻度值(分辨力)之间的比值是相等的，也就是它们的动态范围是相等的。对于动态范围一定的系统，其测量范围与测量精度的比值也是一定的，测量范围越大，绝对精度越低，测量范围越小，绝对精度越高。




图2 两个测长仪器示数的比较

其次，如图3所示，测量的一般过程可抽象理解为：传感器感受被测对象（如长度量），输出特征信号，经过信号变换、处理等一系列过程，给出测量结果。在信号传输过程中，测量信号本身经过一次或多次滤波变换，会造成一定损失，丢失高频细节，致使信号的动态范围下降而受到限制。




图3 测量信号的传输

协调大尺度测量中绝对精度与测量范围之间的矛盾，或者缓解实际工程应用中出现的矛盾，可以考虑下述途径：

(1) 探索新的测量原理方法，缩短或优化测量信号传输路径，减少或改善测量信号传感、处理变换路径上的信息损失，增加系统带宽，提高动态范围，提高相对测量精度。

(2) 针对具体的应用背景，在不影响目标需求的前提下，采用分量程方法，合理划分量程空间，处理好测量精度与测量范围之间的关系。

在大尺度测量领域，由于技术手段和理论的限制，现有测量方法和仪器设备在动态范围、传输信息损失等方面已经很难有较大突破，必须寻找新的方法和仪器以满足实际应用的需要。目前，一种基于飞秒频率梳和相干检测原理的快速、高精度、大尺度测量方法^[2]获得了人们的高度重视，该方法将激光干涉法(测量精度低，测量范围小)与飞行时间法(测量精度低，测量范围大)测距通过某种方式结合起来，大大改善了测量信息(长度)在传感变换过程中的损失，理论上可以同时具备很高的测量精度(可达5nm)及很大的测量范围(几十千米)优势，是一种非常有学术研究价值和工程应用前景的测量新方法。

协调大尺度测量中绝对精度高和测量范围大之间的矛盾是一个具有重要科学价值的难题，对推动国民经济的发展也有重大意义，虽然大尺度测量的工程

应用发展很快,但在基础原理层面上还面临着很多问题和挑战,需要广大科技工作者坚持不懈地努力。

参 考 文 献

- [1] 叶声华,郝继贵.大空间坐标尺寸测量研究的现状与发展.计量学报,2008,29(4):1—6.
- [2] Coddington I,Swann W C,Nenadovic L.Rapid and precise absolute distance measurements at long range.Nature Photonics,2009,3(6):351—356.

撰稿人:郝继贵

天津大学精密仪器与光电子工程学院

光束直径与光束发散角的同步压缩难题

How to Compress Its Diameter and Divergence Angle of a Light Beam at the Same Time

光是信息的载体,也是能量的载体,始终以光速在传播。携带信息和能量的一束光,压缩它的直径,则能量更为集中;压缩它的发散角,则在传播较远的距离后仍然能保证其信息和能量不会散开。有许多应用场合,人们期望能同时压缩光束的直径与发散角,但目前还没有找到有效的方法。

这是因为光在介质中传播,以及通过介质的分界面发生反射、折射或衍射时,必然遵从电磁理论所决定的各种规律,这些规律是人们设计各种光学系统的重要依据。其中,拉格朗日-赫姆霍兹不变量(简称拉赫不变量)是几何光学推导出的一条重要定理,在光学设计过程中具有重要的指导作用,也给出了传统光学无法突破的局限^[1]。图1给出了光学成像系统拉赫不变量示意图。




图1 光学成像系统拉赫不变量示意图

如图1所示,若折射率为 n 的物空间,有一直径为 $2y$ 、发散角为 $2u$ 的光源,经过光学系统成像变换后,其像的直径为 $2y'$,发散角为 $2u'$,则具有如下不变量:

$$J = ny \tan u = n' y' \tan u' \quad (1)$$

该式表明,如果减小光束的直径,则其发散角一定增大;如果减小光束的发散角,则其直径一定增大。我们无法同时压缩光束的直径和发散角。

在非成像系统中,如果采用与成像系统类似的光学元件,将具有同样的规律;如果出现非均匀的介质、非光滑的表面(如漫反射器件、漫透射器件等),则会让变换后的乘积变得更大。

激光之所以能同时在信息领域和能量领域带来革命,是因为相对普通光而言,除了具有单色性外,它的光束直径更小,光束发散角也更小,在传播较远的距离后仍然能保持信息和能量的集中性,因而在诸多领域得到广泛应用^[2]。

然而,激光(高斯光束)和普通光一样,也受拉赫不变量的限制。高斯光束的远场发散角与其束腰直径之间具有如下关系:

$$\theta = \lambda / \pi \omega \quad (2)$$

该式与式(1)一样,禁止了高斯光束直径与发散角的同步压缩,这严重制约了其在激光引爆核聚变等尖端领域的实用化。

相比于激光,普通光是更为常见的信息或能量来源。例如,设图1左边为有一定大小和一定发散角的光源,右边为较细的照明光纤束,则变换后的光束发散角极可能大于光纤的数值孔径角,从而造成能量损失;又如在成像领域,光学设计的难度及物镜的复杂程度和价格主要受孔径和视场(有限远时对应图1中的 $2u$ 和 $2y$,无穷远时则为光圈 $F^\# = f'/D$ 和视场角 2ω)两个因素的制约^[3]。如果能突破传统光学的限制,找到新的结构或材料同时压缩孔径和视场,则光学设计的难度能大大降低,物镜结构也会大大简化。

由此可见,如果能找到新的光子控制技术,发现或发明特殊的材料和结构,同时压缩普通光或激光的光束直径与发散角,一定会在成像、照明、通信、太阳能开发、激光武器等领域带来新的革命。

目前,利用物空间和像空间的折射率差异来实现孔径和视场的同步压缩已有应用,如显微物镜中的浸液物距,把待观察物体浸泡在某种折射率 n 较大的液体中,由式(1)可知,可利用 u 角更大的光线,从而获得更好的照明和更高的分辨率,同时, u' 角较小降低物镜的设计难度^[4]。但在物和像处于同一介质中时,还没有很好的解决方案。

参 考 文 献

- [1] 郁道银,谈恒英.工程光学.北京:机械工业出版社,2005.
- [2] 周炳琨,高以智,陈家骅.激光原理.北京:国防工业出版社,1995.
- [3] 王之江.光学设计理论基础.北京:科学出版社,1965.
- [4] 袁旭沧.光学设计.北京:科学出版社,1983.

撰稿人: 谢洪波

天津大学精密仪器与光电子工程学院

真空中光速恒定性及影响因素研究

A Study on the Constancy of Light Speed in Vacuum and the Factors Influencing the Light Speed

真空中的光速(下面简称光速)在物理学理论和计量学中都有十分重要的意义。1905年,爱因斯坦提出了相对性原理和光速不变原理,光速的恒定不变性是狭义相对论的重要支柱之一,许多重要基本物理常数与它密切相关。爱因斯坦还认为,没有任何物体或波的运动速度会超过光速^[1]。

但是,光速恒定不变只是一种学说,没有充分理论和实验证明,充其量说,只是在目前科技水平下,难以觉察其变化而已。实际上,光速是受一系列因素影响的,以真空中光速为限制,排除了介质的影响,但不能排除外部环境对它的影响。美国标准与技术研究院正在进行重力波对光速影响的研究,要求测量不确定度优于 1×10^{-17} 。除了重力场以外,还存在许多其他场,如电磁场、辐射场,也难以证明它们对光速没有影响。再次,什么是光,也缺乏确切的定义。根据目前的科学认识,光是一种电磁波,不同波段的电磁波在真空中的速度也会不同。光在宇宙空间与在地球上的传播速度是否相同,也难以确定。

无可置疑,爱因斯坦对物理学和整个科学的发展做出了伟大贡献,但他与其他伟大的科学家一样,不能终结科学的发展,不能说凡是爱因斯坦说过的都是正确和完美无缺的。

需要从理论与实验两个方面对光速恒定不变性的适用性、适用度,以及哪些因素影响光速、影响程度进行研究,这是物理学的一个基本问题,也是计量学的一个基本问题。本课题的研究必将大大加深对光、基本物理、宇宙空间的认识,有可能导致整个基本物理体系的改变,其意义将不亚于狭义与广义相对论的建立,也会带来计量学及计量技术革命性的变化。

17世纪以前,天文学家和物理学家都认为光是以无限速度飞行的,他们认为宇宙中各个恒星的光都是瞬时到达地球的^[2]。

1600年前后,伽利略进行了测量光速的实验,虽然实验十分粗糙,但开创了测量光速的先河。三百多年来,人们试探了利用间接测量、计量光行进的距離和时间、计量光波的频率与真空波长三类方法,进行了各种测量光速的实验。

1849年,法国物理学家 Fizeau 首次在实验室做了光速计量,通过计量光行进的距離和时间,测得光速为 312000 km/s 。以后, Michelson 等不断进行改进,得出的光速最佳值为 $c = 299792.6 \pm 0.25 \text{ km} \cdot \text{s}^{-1}$, 相对不确定度为 8×10^{-7} ,

这是利用计量光行进的距离和时间测得的最好结果。

1952 年,英国的 Froome 开始用计量频率与真空波长的方法测量光速,得到 $c=299792.5\pm0.10\text{km}\cdot\text{s}^{-1}$ 。随着激光稳频和测频技术的发展,光速计量技术产生了飞跃。经过各国科学家的不懈努力,1973 年,国际米定义咨询委员会正式推荐的光速值为 $c=299792458\pm1.2\text{m}\cdot\text{s}^{-1}$, 不确定度为 4×10^{-9} 。

1983 年,第 17 届国际计量大会上通过了“米是光在真空中于 $1/299792458\text{s}$ 时间间隔内所经路径的长度”的定义。在这个米的新定义中,光速是作为等于 $299792458\text{m}\cdot\text{s}^{-1}$ 的定义值确定下来,不再具有不确定度^[3,4]。然而,第 17 届国际计量大会的决议并没有给出光速为什么恒定不变的依据。各国科学家仍在研究光速恒定性的适用范围及其可能发生的微小变化。美国标准与技术研究院已投入 500 亿美元巨资进行重力波对光速影响的研究。国际基本物理常数咨询委员会多次对基本物理常数值进行调整,也说明它们是受多种因素影响的^[5]。

本课题的主要研究目标是研究光速恒定性的适用度及影响光速变化的主要因素和影响程度。主要研究内容包括以下几个方面:

(1) 对光的性质(波动性、粒子性等)进行深入的基础理论研究,研究光的传播机理^[6,7]。

(2) 从光的性质及其传播机理出发,从理论上研究影响光速的内部因素(如波段、形成机理等)与外部因素(如各种场的作用),建立其影响程度的理论模型。

(3) 研究宇宙空间光的传播机理与影响光速的特殊因素。

(4) 开展新的光速计量技术的研究,包括基本机理的研究,有可能需要突破现有的间接测量、计量光行进的距离和时间、计量光波的频率与真空波长三类方法。

(5) 进行各种内部与外部因素对光速影响、影响程度及影响模型的研究。

本项目包含一系列基本科学问题的研究,具有很多技术难点,它首先涉及时空观的基本哲学理论问题,同时涉及光的基本物理实质的基础物理研究,以及光的传播基本理论的研究。

除了以上基本哲学问题与基础理论研究外,还需要进行光的传播介质及外部环境对光速影响的基本物理研究,以及涉及时间、长度单位新定义的研究。

光不仅在地球上传播,而且在宇宙空间传播。光在宇宙空间传播的机理与规律是否与在地球上相同、有哪些区别、有哪些影响光速的特殊因素,怎样影响等,这些都是本课题需要研究的问题,同时也是难点。通过对宇宙空间光的传播的研究,必将促进人们对宇宙空间的认识。

实践是检验真理的唯一标准,为了进行真空中光速恒定性及影响因素的研究,必须发展一系列精确计量测试技术,包括时间计量、长度计量、频率计量,

以及各种可能产生影响的因素的计量,而对于它们的精度要求非常高。例如,美国标准与技术研究院正在进行重力波对光速影响的研究,就提出了测量不确定度优于 1×10^{-17} 的要求。为了实现这一要求需要发展一系列新技术,包括新的测量原理、仪器,环境保障、信息处理技术等。

参 考 文 献

- [1] 鲁绍曾.现代计量学概论.北京:中国计量出版社,1987.
- [2] Petley B W. Physical Constants and the SI. London: NPL News, 1987.
- [3] Documents concerning the new definition of the meter. Metrologia, 1984, 19: 163—177.
- [4] Einstein A. Zur elektrodynamik bewegter Körper. Annalen der Physik, 1905, 17: 891—921.
- [5] Taylor B N, Cohen E R. The 1986 adjustment of the fundamental physics constants. Beijing: CODATA Bulletin, 1983.
- [6] Born M, Wolf E. Principles of Optics. 7th ed. Cambridge: Cambridge University Press, 1999.
- [7] 廖延彪.光学原理与应用.北京:电子工业出版社, 2006.

撰稿人: 张国雄

天津大学精密仪器与光电子工程学院

光在人体组织中的传播规律及观测方法

The Law of Light Transportation and Distribution in Human Tissue

随着激光在人类疾病的诊断和治疗中应用日益广泛,已发展出独特的临床新学科——激光医学,其临床应用已涉及人体各组织和器官。国外学者早在1989年就提出生物组织的“黑匣子模型”,将激光辐射馈入作为“黑匣子”的一种输入,将医学上的结果视为输出,通过研究激光在人体组织中的传输与分布规律及观测,尽可能精确地获得影响医学结果的各项参数。因此,该研究已成为激光医学重要的基础性问题,在激光医学诊疗中有着重要的应用。其主要应用有三个:一是发展任意组织内光子分布特性的准确快速的定量方法,预测诸如光动力治疗等应用中的内部光子密度分布和所需光剂量;二是发展精确模型作为评价其他特定应用模型的“金标准”;三是发展快速有效的算法和准确测量方法,为实现疾病的定量光谱或光学成像诊断打下基础(如图1所示)。



图1 研究光在人体组织中的传播规律的临床意义

光在介质中传播时,会发生光的吸收、反射、折射、散射、衍射及干涉等物理过程。人们对于一些物理过程的规律都有了公认的描述,如光的吸收遵循 Beer-Lambert 定律,对散射的描述有 Rayleigh 散射、Mie 散射、Tyndall 散射、拉曼散射、布里渊散射、Compton 散射等。通常,将同时存在吸收和散射的介质称为混浊介质,人的身体内除了眼睛和脑脊髓液是近似无散射之外,其余组织均为混浊介质,因此,激光在人体组织中的传输与分布规律可以抽象为研究光在浑浊介质中的传播。

研究光在人体中的传播规律及观测方法包含三方面的内容,即描述光在人体组织中传播的理论模型、光传播规律的观测方法和人体组织光学参数的测量方法^[1,2]。

历史上,处理光在随机混浊介质中的多次散射效应有两种不同的方法:解析理论和输运理论。解析理论从基本的 Maxwell 波动方程出发,引入粒子的吸收和散射特性,并获得相关统计量,如方差和相关函数等的微分-积分方程。由于该理论原则上考虑了光波的多次散射、衍射和干涉效应,因此,它在数学上是严格的,但在实际应用中,该理论不可能得到完全包括这些效应的通用解,产生有用解的各种模型(如 Twersky 理论、图解法及 Dyson 和 Bethe-Salpater 方程等)都是近似的,只适用于一定的参数范围。输运理论又被称为辐射传输理论,由 Schuster 于 1903 年首创,它直接讨论能量通过包含粒子的介质时的输运问题,该理论的研究方法比较直接,但缺乏解析理论所具有的数学严谨性,并且尽管其在描述单粒子吸收和散射特性时考虑了衍射和干涉效应,但就输运理论本身而言,并不包括波动效应。当忽略光的波动性时,混浊介质中光传播过程的精确建模即等价为一个全时域辐射传输方程的求解问题,而该方程的解析解在通常情况下是不存在的,折中方案包括采用基于统计技术(蒙特卡罗或随机行走)的解及基于简化过程的近似解^[3],如漫射方程、Kubeka-Munk 理论,加倍法及近年来发展的辐射传输离散坐标法和高阶近似法等。由于采用了太多的假设,扩散方程只适合于满足漫射近似条件下的介质,且目前只在少数几种形状的不均匀介质下有解析解^[4]。蒙特卡罗模型虽然可模拟任意几何形状、边界条件和不均匀的介质的光传播行为,但计算量巨大,且结果强烈地依赖于统计量的大小。

目前,观测光在不均匀复杂混浊介质中的传播规律并无直接的实验手段,大多采用间接方法通过外部平均测量推测光子的传输规律。例如,用超快时间分辨技术和相干光层析成像技术,通过测量光在介质内传播时间的分布和功率衰减程度,了解光在介质内受到吸收或散射的情况。再如,采用连续波测量方式,使用具有恒定强度的点光源或细准直光束注入介质,检测出射光强度信息,得到组织光学参数。还如,采用频域测量方式使用高频调制光入射生物组织,光子密度波以一定的相速度和振幅衰减系数在生物组织中传播,通过测量出射漫射光计算组织对光的吸收和散射程度。

虽然多种生物组织在可见光到近红外范围内的光学参数值已经通过各种测量技术获得,但这些测量通常是在离体情况下进行的,这种测量方式不可避免地存在离体组织样品在制作过程中的变化,而致测量数据不可靠,而且即使是离体的组织,至今也没有得到完整的数据。因此,如何从光在组织中传输理论出发,设计出组织光学特性的测量技术,了解激光在人体组织中的传输与分布规律,建立人体组织光学参数数据库,是掌握激光与人体组织相互作用规律的重要基础。

参 考 文 献

- [1] Vo-Dinh T. Biomedical Photonics Handbook. New York: CRC, 2003.
- [2] Ishimaru A. Wave Propagation and Scattering in Random Media. London: Academic Press, 1978.
- [3] Wang L, Jacques S L, Zheng L. MCML-Monte Carlo modeling of light transport in multi-layered tissues. Computer Methods and Programs in Biomedicine, 1995, 47: 131—146.
- [4] Martelli F, Bianco S D, Ismaelli A, et al. Light Propagation through Biological Tissue. Washington: SPIE Press, 2010.

撰稿人：顾 瑛¹ 赵会娟²

1 中国人民解放军总医院

2 天津大学精密仪器与光电子工程学院

扩散光学成像中 crosstalk 的问题


The Crosstalk Issue in Diffuse Optical Tomography

扩散光学成像(diffuse optical tomography, DOT)作为新近出现的一种功能成像技术,现已成为生物医学领域的热点和前沿课题之一。DOT 的成像原理主要基于血红蛋白对近红外光的吸收和细胞等粒子对光的散射,该法可通过测量吸收光谱来计算血液中的氧含量和血的体积,进而反映组织的血管活动及代谢变化,也可通过光的散射谱确定细胞等粒子的大小和密度。


现在, DOT 面临的最大的技术挑战是如何减少重建过程中光的吸收系数和散射系数的 crosstalk 问题。众所周知, DOT 反问题没有精确的唯一解, DOT 解的不适定性严重影响重建图像性能和质量。Arridge 证实只有时域或频域的 DOT 模型且当组织的折射系数确定时才能克服光学参数的 crosstalk^[1], 而连续光(CW)测量不能克服 crosstalk。然而,事实是从重建的光学像来看,时域和频域的测量均不能完全克服 crosstalk, 反而 CW 测量在使用某些技术后能有效减小 crosstalk。特别是 Xu 和 Barbour 等研究工作证实反问题解的存在性和唯一性^[2,3], 不仅依赖测量数据的类型,更依赖测量数据的质量和重建算法的性能,这说明数学理论对 DOT 中的 crosstalk 证明是不完备的,并且仅仅从数学理论上解释该问题也是不全面的。

首先,对于 DOT,为什么说基于时域的测量模型往往能给出较好的重建精度,特别是对于动态大脑或者神经病理成像?要从理论上阐明这个问题,我们不能仅仅在数学层面上使用解的存在性和唯一性来证明之,还要从基于模型的扩散光学重建理论谈起,该理论认为任何定量的影像的重建依赖前向模型的精度、逆向算法及测量数据的性能。时域的重建使用的是相对精确的数学模型,能较好地描述光子在生物组织中的传播与扩散,并且测量数据比较全面。而频域的重建实际上往往要扔掉某些频段的数据, CW 测量系统更是进一步扔掉相位数据,只保留幅度测量数据。所以,当同时重建光学吸收系数 $\mu_a(r)$ 和散射系数 μ'_s 时,理论已经证实 CW 测量在丢掉一种数据测量类型(相位数据)后不能有效克服 crosstalk 问题^[1],也就是说,不能同时捕获两类参数在组织内部的分布。但是,由于时域的定量成像计算量大,硬件测量系统昂贵,许多研究者乐于使用频域的测量系统^[4]。可更简单、更实用、更便宜的成像系统为 CW,并且经验和事实是:频域的测量不能完全克服 crosstalk, CW 测量在实施某些条件后,如归一化技术^[2,3],能有效减小 crosstalk。下面的仿真和临床测试结果证实了这一点


(如图 1 所示)。



(a) 重建体积存在不同的吸收和散射各向异性分布(对比度均为 3 : 1)



(b) 重建结果使用 CW 测量和归一化、正则化重建方法



(c) 重建结果使用频域的测量和正则化重建方法

图 1

所以, 基于非线性模型的多参数重建问题, 通过适当的调整反问题解空间, 能有效减少多参数 crosstalk, 因而测量数据类型及相应的光学重建模型可能是减少多参数 crosstalk 的必要条件, 但不是充分条件。调整反问题解空间的策略之一是增加测量数据。例如, Corlu 的研究工作证实通过优化的多波段 CW 光测量^[5], 能有效减小多参数 crosstalk, 并能得到最小二乘意义上的唯一单解(如图 2 所示)。另外, 通过使用归一化算法也能有效调整解空间。例如, Xu 和 Barbour 的研究证实通过使用归一化参数可以增加结构^[2,3], 功能或者测量的已知信息(如图 3 所示)能有效减小基于 CW 测量的多参数 crosstalk^[6]。当然, 通过使用约束优化算法, 也能有效减少频域或 CW 测量的多参数 crosstalk。




图2 同时重建的含氧血红蛋白、不含氧血红蛋白和水的浓度分布使用不同波段的 CW 测量
第1列为血氧参数和水的真实分布,第2,3,4列为相应重建的参数分布使用不同的测量波段;
第1行为含氧血红蛋白,第2行为不含氧血红蛋白,第3行为水




图3 同时重建的手指关节的光学散射系数(a)和吸收系数
(b)使用单波 CW 测量和 X 射线结构信息(c)

依作者和其他研究组的经验,要攻克这一难题,重点要侧重逆向问题。因为反问题受影响的因素最多包括测量数据类型、信噪比、多寡和反问题算法的性能及已知的结构和功能信息,而反问题算法的性能又依赖于优化方法的性能、归一化和正则化方法的功能及矩阵理论的稳定性,并且统计方法也是要考虑的重要方向之一。总之,关于如何克服或者减小 DOT 的多参数 crosstalk 问题,仍然是困扰数学家、物理学家和工程师的多年的难题,严格的数学证明和物理说明仍然是十分必要和紧迫的。希望这一难题能在这几年内迅速攻克,为生物医学光学的广泛应用提供坚实的数学基础。同时这一问题的克服,也为超声、电磁、微波成像的多参数重建提供坚实的数理基础。

参 考 文 献

- [1] Arriaga S R, Lionheart W. Nonuniqueness in diffusion-based optical tomography. *Opt. Lett.*, 1998, 23: 882—884.
- [2] Xu Y, Gu X, Khan T, et al. Absorption and scattering images of heterogeneous scattering media can be simultaneously reconstructed by use of dc data. *Appl. Opt.*, 2002, 41: 5427—5437.
- [3] Pei Y, Graber H L, Barbour R L. Normalized-constraint algorithm for minimizing inter-parameter crosstalk in DC optical tomography. *Optics Express*, 2001, 9: 97—109.
- [4] McBride J T O, Pogue B W, Jiang S, et al. Initial studies of in vivo absorbing and scattering heterogeneity in near-infrared tomographic breast imaging. *Opt. Lett.*, 2001, 26: 822—824.
- [5] Corlu A, Durduran T, Choe R, et al. Uniqueness and wavelength optimization in continuous-wave multispectral diffuse optical tomography. *Opt. Lett.*, 2003, 28: 2339.
- [6] Yuan Z, Zhang Q, Sobel E, et al. Tomographic X-ray guided three-dimensional diffuse optical tomography of osteoarthritis in the finger joints. *J. Biomed. Opt.*, 2008, 13: 044006-1—044006-10.

撰稿人：蒋华北 袁 振
美国佛罗里达大学生物医学工程系

地下电磁探测深度与分辨率的矛盾

The Conflict between Investigation Depth and Resolving Power in Underground Electromagnetic Detection

自从 20 世纪初,电磁场被用于大地构造研究和地下目标体探测以来,地下电磁探测已拥有较为悠久的历史。该方法利用地表电磁场与地下介质电性分布之间的关联性,根据仪器记录的电磁场数据,推断地下电性分布,判断具有某种电性特征的目标体是否存在,并反演其电性参数、几何形态和空间位置等信息。当前,该方法已得到广泛应用,在资源勘查、地下水调查、工程环境勘察、地质构造研究、地质灾害预测和治理等领域发挥着重要作用。但该方法对深部目标的分辨能力仍较差^[1],难以满足社会发展和地学研究的需求。

地下电磁探测根据发射源和观测方式的不同,可分为天然源、人工源、时间域和频率域电磁法。尽管如此,其工作原理本质上都是相同的^[2]。发射源产生的电磁场(称为一次场或激励场)在地下自由扩散,电磁能量主要分布在发射源附近有限的空间范围内^[3~5],该空间范围的大小取决于发射源尺度、功率、电磁场频率和大地电阻率等因素。在一次场的激励下,该空间内的导电介质中会感生电流,从而产生二次电磁场(简称二次场)。二次场叠加在一次场中,使空间电磁场的分布出现扰动。不同的电性分布,扰动不同,因此,扰动记载着地下介质信息。

目标体引起的电磁扰动的大小主要取决于目标体与围岩介质的电性差异、目标体尺度、该处一次场大小及观测点与目标体之间的距离。前两者体现电磁探测的分辨率,一般,目标体尺度(位于一次场范围内)越小,电磁扰动越小;目标体与围岩的电性差异越小,电磁扰动也越小^[6]。后两者直接受目标体埋深制约,埋深越大,目标位置一次场越小,且其与观测点距离越远,致使观测点处电磁扰动越小。这表明,深部大尺度、大电性差异目标体才能引起与浅部小尺度、小电性差异目标体同等强度的电磁扰动,深部探测分辨率降低。这就是地下电磁探测中探测深度与分辨率之间的矛盾,如图 1 所示(由于具体数值与地电环境和发射源等因素有关,这里仅为示意图)。克服该矛盾需要解决两个问题:一是能够测量深部小尺度、小电性差异目标体引起的电磁扰动;二是能够在浅部强干扰背景下提取深部扰动信息。




图1 地下电磁探测示意图

在目标体尺度、埋深、电性及围岩环境不可变的情况下，为了观测到深部较小尺度和较小电性差异目标体引起的电磁扰动，必须增大目标体所在区域的一次场能量。但随着深度的增加，一次场分布在更广的空间范围，而且在传播过程中，因导电介质的吸收而快速衰减，这使得深部单位体积的一次场能量急剧减小。当前，加大深部一次场能量的做法是降低电磁场频率或增大发射功率，前者利用低频电磁场在导电介质中吸收少这一特点来减小一次场在往深部传播过程中的能量损耗，后者通过增加一次场总能量来提高深部单位体积内的一次场能量，但受实际条件(电源、器件性能、工作环境等)限制，发射功率的增加幅度是有限的。降低电磁场频率确实可以使电磁场传播到地球更深部，目前已经可以利用天然低频电磁场对地幔进行探测^[7]。不过，由于低频电磁场在深部单位体积内的一次场能量仍然较弱，且波长较长，目前降低频率的措施也只能是分辨大尺度的地下目标。

此外，提高接收系统灵敏度和动态范围，以及降低仪器系统本底噪声和压制环境电磁噪声也是当前人们常用的措施。这使得仪器系统能够观测到更加微弱的目标信号，从而分辨深部较小尺度和较小电性差异的目标体；但受当前科技水平的限制，这些措施存在瓶颈，只能起到部分改善作用。

由于降低频率、增大功率和增加接收系统对弱信号的检测能力均无法改变浅部一次场能量强于深部一次场能量这一事实，在同等条件下，浅部介质对观测点电磁场的贡献大于深部介质，这意味着浅部介质所引起的电磁扰动(地质噪声)容易淹没来自深部目标体的电磁扰动(信号)。针对这一现象，目前采取的措施有大偏移距观测、多频测量或时域测量。其中，大偏移距观测通过拉大观测点与发射源附近一次场较强区域介质的距离来减小其扰动影响；多频测量则是利用高频穿透深度小而低频穿透深度大这一特点，通过数据处理突出深部介质

的贡献;时域测量则是在晚延时测量电磁场的瞬态响应,此时发射源处于关闭状态,电磁扰动主要来自深部介质。但是,采取这些措施后仍然只能分辨深部较大尺度和较大电性差异的目标体。

是否可以找到一种新的地下电磁探测方法,使一次场在地下目标区聚焦,然后通过控制聚焦方向和距离对地下进行高分辨电磁探测呢?这样,不仅可以加大对深部目标体的激励,而且同时可以减弱非目标区的二次场干扰,解决当前电磁探测存在的深度与分辨率问题。

参 考 文 献

- [1] Spies B R. Depth of investigation in electromagnetic sounding methods. *Geophysics*, 1989, 54(7): 872—888.
- [2] Nabighian M N. 勘查地球物理电磁法(第一卷). 北京:地质出版社, 1992: 120—298.
- [3] Nabighian M N. Quasi-static transient response of a conducting half-space—An approximate representation. *Geophysics*, 1979, 44(10): 1700—1705.
- [4] Reid J E, Macnae J C. Comments on the electromagnetic “smoke ring” concept. *Geophysics*, 1998, 63(6): 1908—1913.
- [5] Wang T. The electromagnetic smoke ring in a transversely isotropic medium. *Geophysics*, 2002, 67(6): 1779—1789.
- [6] Kaufman A A. The influence of currents induced in the host rock on electromagnetic response of a spheroid directly beneath a loop. *Geophysics*, 1981, 46(8): 1121—1136.
- [7] 李立. 中国大陆地壳上地幔电性特征. *地球物理学报*, 1996, 39: 130—140.

撰稿人: 刘长胜 林 君
吉林大学仪器科学与电气工程学院

如何赋予机械手触觉功能？

Solution on How to Make a Robotic Hand with a Sensing Function

机器人不仅已被大量用于生产线中的零件装配、焊接等工序，还被用于太空作业和深海探测。在一些危险环境和恶劣条件下，它被用来排险(如排雷等)或其他操作。随着我国迈入老龄化社会，服务机器人还将大量进入家庭，用于侍候老人、照顾小孩、打理家务等。大多情况下，人们利用的主要是机器人手的功能。

传统的机械手由于缺少感知，拿鸡蛋时会出现握破鸡蛋或握力不够而致滑脱现象。如果手中植有“神经”，让其拥有触觉，则它可实时感知握力的大小、承重的多少及温度的高低。经学习(或称“认知”)过程，可为下一步动作提供决策。结合反馈控制并配合关节驱动技术，使得肘关节和腕关节都能自主活动。这样，一只知冷暖、拿捏有分寸，甚至具备一定的自决后续动作能力的手，称其为智能手。

智能手既有人手对环境状态的快速反应和分析判断能力，又有机器高速、高精度、高效率、抗恶劣环境的能力。智能手的成功研制将是仿生学的重大进展，并为工业技术的进步、航天科技的发展提供重要的技术支撑。同时，也只有智能化了的机械手才是人类真正的帮手！它将人类从复杂、繁重、恶劣的工作环境中解脱出来，并使人手的功能得以延伸。




图1 能拿住鸡蛋的机械手

如何获得人造神经，是机械手智能化首先要解决的问题。发展分布式传感技术，让手能感知受何种作用、作用的大小及分布情况，赋予其“触觉”功能，相关报道主要集中在：①利用压电材料层(piezoelectric layer)作为蒙皮^①的灵巧结构^[1,2]。考虑压电材料缺乏柔性，其众多的连接导线也会影响结构的机械性能，感测结果还会受环境电磁场影响，其实用性有限。②基于形状记忆材料(如聚合物^[3]或合金^[4]等)的具有自愈能力的智能结构，它不适于对载荷进行定量感知，何况与真人皮肤相差甚远。③利用柔性聚合物(flexible polymer)受压时产生的量子通道合成(quantum tunnelling composite)现象，制成有压触感的机械手(如图1所示)^[5]，虽在

① 蒙皮指人造皮肤。

向真手逼近的道上向前又迈出了一步,但它仍受环境电磁场干扰,且无法鉴别压力以外的其他作用。

光纤传感器可用来对物理量进行分布式传感,传感结果不受电磁场和潮湿环境的影响,易置入其他结构而不影响其机械性能。光纤光栅传感器拥有普通光纤传感器的全部优点,它采用通信网络的信号处理技术,利于以无线方式与互联网连接,便于遥控,它对应变和温度非常敏感,具备分布式或准分布式传感能力,是触觉系统的理想选择。已有用于手指压力感测的尝试^[6],但还不具备实时监测功能,也未进行智能化方面的探索。

感知的目的是为后续动作提供依据。新“手”的学习过程也是数据库的建立过程,结合专家系统,对动作与否做出判断;而动作的执行则由计算机控制下的伺服机构完成^[7],也有利用模型跟踪,结合自适应控制技术,引入反馈控制器实现对手的差动同步控制^[8]。

存在的技术难点有以下几点:

(1) 由于机械手的尺寸在厘米量级,普通光纤传感器虽可进行连续分布式传感,现有技术还无法在这样的尺寸范围内对待测量精确定位,而光纤光栅传感器目前还未彻底攻克连续分布式传感的技术难题。

(2) 针对小尺寸物体,解决单一物理量的分布式传感技术难题后,还将面临多物理量同时监测的问题,否则,怎知冷暖、掌握拿捏分寸?因此,在光纤光栅及其网络化传感的基础上,有必要发展多功能传感技术。

(3) 对于全部手指及手掌等部位的多个传感元所获得的传感信息,还存在数据融合等方面的问题。借助虚拟仪器对信号进行处理,建立适当的数学模型,提取关键信息供决策使用。

(4) 选用硅橡胶等柔性材料作为机械手的蒙皮,将传感系统埋置其中,可有效保护光纤和光栅,但光纤与柔性材料间存在滑脱现象,造成感知结果与真实值间的偏差,出现错觉,因此,有必要探索埋置的方法和工艺。

(5) 埋有人造神经的新“手”,控制程序本身并不懂得拿捏的分寸,需根据实际操作中获得的感知信息,通过设置,规范其后续动作,该学习过程对机械手来说可能会因手而异。

若作为机器人的一部分,机械手的触觉信息应反馈给“大脑”,机械手的行为应服从“脑”的统一指挥。

随着科学技术的不断进步,机械手向人手功能的逼近在不断进行。高度智能化了的机械手将会为人类的明天书写美好的篇章。

参 考 文 献

[1] Hurlebaus S, Gaul L. Smart layer for damage diagnostics. J. Intelligent Material Systems and

- Structures,2004,15(9—10):729—736.
- [2] Cheng J Q,Wu X X,et al.Development of a smart composite pipe joint integrated with piezoelectric layers under tensile loading.International J.Solids and Structures,2006,43(17):5370—5385.
- [3] Hu J L,Ding X M,et al.Shape memory polymers and their applications to smart textile products.J.Donghua Univ.,2002,19(3):89—93.
- [4] Hu Z L.Meso-mechanical analysis of shape memory alloy reinforced smart structure with damage.Acta Mechanica Solida Sinica.,2006,19(3):189—195.
- [5] <http://www.shadowrobot.com/hand/overview.shtml>.
- [6] Park Y L,Chau K,et al.Force sensing robot fingers using embedded fiber Bragg grating sensors and shape deposition manufacturing.Proc.of the 2007 IEEE International Conference on Robotics and Automation,2007,1—10:1510—1516.
- [7] 申屠南英,高潮,等.基于微机测控技术的智能伺服操作系统.重庆大学学报,2003,26(9):73—76.
- [8] 王纪森,钟丹华.基于 MRAC 的电液伺服作动器同步控制.控制工程,2006,13(5):506—508.

撰稿人：余有龙

合肥工业大学仪器科学与光电工程学院

微纳精密测量仪器中的精度控制问题

Precision Control Problems of Micro /Nano Precision Measurement Instruments

精度理论是精密测量仪器领域的重要基础理论,是研究精密测量仪器在测量时误差产生的原因,进而提高精密测量仪器测量精度的方法,它是指导合理设计精密测量仪器、减小误差、提高精度的重要工具。影响精密测量仪器精度的误差可分为伪静态误差和动态误差,这两类误差可以粗略地进一步划分为几何误差、运动误差、变形误差等^[1]。要提高精密测量仪器的测量精度,在仪器设计时要充分了解这些误差源对精度的影响程度,掌握减小误差的方法,合理地设计出精度最优的结构,把误差控制在允许的范围内,保证测量精度达到设计指标的要求。

近几十年来,为了满足精密制造与组装产业的需求,精密测量仪器的测量精度正在向微纳米尺度发展,涌现出了大批高精度精密测量仪器,使精密测量仪器的精度理论发生了新的变化,有些在传统精密测量仪器中对精度的影响处于次要因素,在微纳精密测量仪器中已经无法忽视,使仪器的精度设计遇到了新的挑战。

(1) 精度设计原则问题。在精密测量仪器结构设计时,为了提高仪器测量精度,常常需要遵循一些设计原则,如著名的 Abbe 原则、Bryan 原则、运动学设计(kinematic design)原则等^[2]。Abbe 原则要求被测量位移应该布置在测量基准元件沿运动方向的延长线上,否则产生 Abbe 误差。遵守 Abbe 原则虽可消除 Abbe 误差,但会使精密测量仪器的结构增大。鉴于这个原因,目前许多测量仪器,由于受到结构上的限制,都不能遵从 Abbe 原则^[3],但若不遵守 Abbe 原则,又难以减小误差,尤其在微纳米精密测量仪器中,这对矛盾显得更为突出。例如,设测量线与基准线之间有 1mm 的偏离量,测量时,如果它们之间有 1" 的偏转,将产生大约 5nm 的 Abbe 误差,如果偏离量为 10mm,就会产生 50nm 的 Abbe 误差。因此,在微纳米精密测量仪器(如纳米三坐标)设计中,如何遵循 Abbe 原则,研究满足 Abbe 原则的结构设计方法显得非常重要。

为了克服 Abbe 原则的不足,Bryan 后来将 Abbe 原则作了推广,Bryan 原则要求位移测量系统的工作点的路程同被测位移作用点的路程应该位于同一条直线上,如果不能满足时,必须使传送位移的导轨没有角运动,或者必须能够测量出角运动,补偿 Abbe 偏离。Bryan 同 Abbe 原则不同的地方在于提出了误

差补偿与修正的思想,该原则认为,如果 Abbe 原则不能满足,但可以采取补偿或修正误差,也认为该仪器设计满足 Abbe 原则,这就给人们提出了一个新的课题:在微纳米精密测量仪器设计中,如何实现误差补偿与修正?

另外,还有运动学设计原则,又称准确约束原则,它要求按照机构的运动方式施加约束数,为了避免过约束带来的应力变形,一个平面最多为三个约束,一个直线最多为两个约束。满足运动约束虽然具有许多优点,不过纯粹的运动约束原则一般难以实现,有时需要采用半约束原则^[4]。运动学设计原则存在一些理想的假设,如要求机构为刚体、约束为点接触等,但在微纳米精密测量仪器中,针对微纳米尺度的特点,如何实现这些准确约束,需要进一步研究。

(2) 变形误差控制问题。精密测量仪器中的变形误差包括温度变化造成的热误差、各种力引起的变形误差等。热误差是结构零部件之间由于温度变化发生热伸缩变形造成的位移误差,产生热误差的热源通常来自轴承、齿轮和液压油、驱动和离合、泵和电机、导轨、切削力及外部热源等^[5]。为了减小热误差,目前的一个主要手段是采取控温技术,如把环境工作温度控制在 0.1°C 范围内;第二种方法是对热误差进行建模,采取误差补偿与修正方法^[6,7],予以消减。这些是目前国内外研究得最多的减小热误差的两种方法,但控温技术成本很高,热误差建模修正有时由于热误差的不确定性难以实现。因此,在有些场合,需要采取热配合方法予以补偿^[8]。热配合误差补偿方法是研究零部件之间热配合特性、变形规律与温度变化之间的关系,通过合理结构设计使得配合部件之间的热变形相互抵消,保持配合特性的稳定。例如,孔和轴的配合运动副在高速运动情况下会产生热量,在孔和轴热胀冷缩量不同的情况下,使得配合间隙发生改变,产生热误差。如果能够通过热配合设计,合理地设计孔和轴的结构形式,使孔和轴的热变形量相同,配合间隙保持不变,就会补偿热误差。但是,如何设计这种理想的运动副,目前还有许多理论问题需要研究,如孔和轴的热变形规律问题、孔在外部结构形式的约束下的变形规律等。

(3) 误差实时补偿与修正问题。误差补偿与修正是目前提高微纳米精密测量仪器精度的一个非常重要的措施,但补偿与修正是有区别的。误差补偿是采取各种结构和方法,使它们之间可能产生的误差相互抵消和削弱,或者引入新的误差,以减小其他误差的影响。误差修正是通过建立误差的模型,掌握误差的变化规律,通过计算的方法予以修正^[9,10]。误差修正技术目前在微纳米精密测量仪器中被广泛使用,但如何对微纳米精密测量仪器的误差进行建模,还有许多建模理论问题有待进一步研究。另外,还有一个重要的问题是:误差修正是建立在仪器结构具有良好的稳定性和误差具有良好的复现性基础上的,但目前人们对于如何设计高度稳定性的精密测量仪器还没有形成一套完整的设计理论。

参 考 文 献

- [1] Ramesh E, Mannan M A, Poo A N. Error compensation in machine tools-A review .Part I: Geometric, cutting-force induced and fixture-dependent errors . International Journal of Machine Tools & Manufacture ,2000 ,40 :1235—1256 .
- [2] Schellekens P, Rosielle N, Vermeulen H ,et al. Design for precision :Current status and trends .Annals of the CIRP ,1998 ,47 :557—585 .
- [3] Fan K C ,Liu C L ,Wu P T ,et al. The structure design of a micro-precision CMM with Abbé principle .Proceedings of the 35th International MATADOR Conference ,2007 :297—300 .
- [4] Hale L C .Principles and techniques for designing precision machines [PhD Dissertation] .Livermore :Lawrence Livermore National Laboratory ,1999 .
- [5] Ramesh E, Mannan M A, Poo A N. Error compensation in machine tools-A review .Part II: Thermal errors .International Journal of Machine Tools & Manufacture ,2000 ,40 :1257—1284 .
- [6] Ramesh E, Mannan M A, Poo A N. Thermal error measurement and modeling in machine tools .Part I: Influence of varying operating conditions . International Journal of Machine Tools & Manufacture ,2003 ,43 :391—404 .
- [7] Ramesh E, Mannan M A, Poo A N ,et al. Thermal error measurement and modeling in machine tools .Part II :Hybrid Bayesian network-support vector machine model .International Journal of Machine Tools & Manufacture ,2003 ,43 :405—419 .
- [8] 费业态,李桂华,卢荣胜,等.机械热变形理论及应用.北京:国防工业出版社,2009.
- [9] Rahman M. Modeling and measurement of multi-axis machine tools to improve positioning accuracy in a software way [PhD Dissertation] .Oulu :University of Oulu ,2004 .
- [10] Schwenke H ,Knapp W ,Haitjema H ,et al. Geometric error measurement and compensation of machines-an update .CIRP Annals-Manufacturing Technology ,2008 ,57 :660—675 .

撰稿人：卢荣胜

合肥工业大学仪器科学与光电工程学院

建立坐标测量机面向任务的测量不确定度 模型与传递链函数

Establishing the Task-oriented Uncertainty Model and Transport Chain Function for CMM

测量不确定度是评价测量结果质量的重要指标。由 ISO 等 7 个国际组织制订并颁布实施的《国际测量不确定度表示指南》(简称为 GUM)定义:“测量不确定度表征合理地赋予被测量值的分散性,是测量结果含有的一个参数。”没有不确定度的测量结果是不完整的、没有意义的、不具有实用价值的。

产品几何量技术规范(geometrical product specifications and verification, GPS)是一套关于产品几何参数的完整技术标准体系,为几何产品的设计、制造及检验提供了技术规范。新一代 GPS 标准体系利用不确定度的传递关系,将标准与计量联系起来,将不确定度评定与几何产品的设计规范、生产制造和检验认证贯穿于整个生产过程,成为设计人员、制造人员和计量测试人员之间的共同依据的准则。完善不确定度评定规范及工程应用技术是当前新一代 GPS 标准应用研究的重点之一。

三坐标测量机(简称为 CMM)是一种集机械、光学、电子、数控技术和计算机技术为一体的大型高精度、高效率、万能性测量仪器,主要用于产品尺寸、形状、位置等几何参数的测量,是现代工业检测、质量控制和制造技术中不可缺少的重要测量设备,广泛应用于机械工业、电子工业、航空航天、国防军工等领域。

现有 CMM 在应用时通常得到的只是被测参数的估计值,不能给出相应的测量不确定度。现代先进制造技术的发展对 CMM 不断提出新的更高的要求,测量结果的不确定度越来越受到测量机用户的关心和重视,准确方便地评定面向任务的测量不确定度是当前 CMM 应用中亟待解决的难题。

要准确给出 CMM 被测参数的测量不确定度并非易事。一方面是因为引起被测参数不确定度的来源非常复杂,它不仅与测量机本身的精度有关,还与采样策略、被测工件、环境条件及数据处理方法等一系列因素有关;另一方面,不确定度评定需要大量关于不确定度方面的专业知识和丰富的评定经验,这对于一般坐标测量机的操作人员来说,无疑具有相当大的难度。即使是专业计量人员在评定测量机面向任务的不确定度时,也会因为不同的人具备不同程度的

知识、经验和设想而给出不同的不确定度表述。因此,被测参数的不确定度评定成为制约 CMM 合理应用的瓶颈,国内外学者及研究机构对此给予了高度重视。

国际标准化“坐标测量机”工作组 ISO/TC 213/WG10 围绕“坐标测量机”标准化工作,建立了 ISO10360 系列标准和 ISO/TS 15530 系列标准。国外许多著名的研究机构投入大量的资金和力量进行坐标测量机测量不确定度评定的相关研究。意大利国家计量所(IMG C)提出了专家坐标测量机方案^[1];德国 PTB 提出模块化设计思想,旨在研究开发 CMM 面向对象的测量不确定度评定软件^[2];美国研究人员基于 GUM 的因子实验设计(DOE)方法,分析 CMM 面向任务时各种因素及相关性所引起的测量不确定度^[3];英国学者研究了 CMM 测量工件时的环境条件和测量策略等因素对测量不确定度的影响^[4];波兰学者基于 GPS 分析了 CMM 面向任务时的测量不确定度来源及评定方法^[5]。

国外对 CMM 面向任务的测量不确定度研究开展得较早,研究工作比较深入,并有部分成果的应用。国内针对测量机自身的精度研究较多,而关于测量机面向任务的不确定度评定方面的研究目前处于起步阶段,研究问题比较单一,还未展开全面、系统、深入的研究。随着 GUM 和 GPS 的颁布实施,产品检验、实验室认可、国际贸易等都要求出具符合规范的不确定度报告。市场经济的全球化使得愈来愈多 CMM 的生产企业和用户努力追求与 ISO 保持一致,迫切需要科学方便地评定坐标测量机面向任务的不确定度。

研究符合 GPS 标准体系和 GUM 基本原则的 CMM 面向任务的测量不确定度的评定方法,开发具有我国自主知识产权的坐标测量机面向任务的不确定度评定软件(UES)与专家系统,实现测量机在线或离线进行测量结果的不确定度评定,并给出符合 GPS 和 GUM 的不确定度报告,这对提升坐标测量机的应用价值、促进我国先进制造技术与社会经济发展,具有重要的现实意义和科学价值。

建立测量不确定度模型与传递链函数是进行坐标测量机面向任务不确定度评定的关键,也是当前亟待解决的科学难题。其困难在于:面向任务的不确定度评定非常复杂,不仅与测量任务及坐标测量机的精度有关,还与所采取的测量策略(被测件放置的位置、方向、测头和探针的选择、测点数及分布,数据处理方法等)、操作状态(测量人员、瞄准方式、运动速度等)、环境条件(温度、湿度、振动等)、测量对象(表面粗糙度、形状误差、污染、夹持等)多种因素有关。正确分析各种因素对不同任务的测量不确定度影响,并用数学模型科学描述,建立模块化的传递链函数,是实现面向任务不确定度评定的基础。

该难题的解决将有助于以下研究工作的开展:

(1) 应用计算机模拟和专家判断进行测量不确定度评定。利用蒙特卡罗模拟法将复杂的测量过程分解成模块化处理,简单而准确地进行不确定度评定。

对于某些不能用测量数据描述的不确定度来源,采用基于 Bayes 统计的专家判断,依据专家的经验 and 历史测量数据进行当前测量的不确定度评定。

(2) 开发坐标测量机面向任务的测量不确定度评定软件。依据 GPS 标准体系和 GUM 基本原则,在全面考虑测量策略、环境条件、操作状态等多种因素的情况下,研究坐标测量机面向任务的不确定度评定软件的设计与编制,实现坐标测量机面向任务的不确定度评定。用户可以方便地在线或离线获取测量不确定度报告,将使用者对测量不确定度评定的影响降为最小。

(3) 为几何产品的设计、制造、测试及应用提供共同依据的准则。基于 GPS 规范与 GUM 原则,将标准、计量与制造紧密结合,使不确定度评定与产品公差设计、检验认证、合格判定等贯穿于产品制造的全过程,为几何产品的设计、制造、测试及应用提供共同依据的准则。

参 考 文 献

- [1] Balsamo A, Di Ciommo M, Mugno R, et al. Evaluation of CMM uncertainty through Monte Carlo simulations. *Annals of the CIRP*, 1999, 48(1): 425—428.
- [2] Schwenke H, Siebert B R L, Waldele F, et al. Assessment of uncertainties in dimensional metrology by Monte Carlo simulation: Proposal of a modular and visual software. *Annals of the CIRP*, 2000, 49(1): 395—398.
- [3] Feng C X J, Saal A L, Salsbury J G, et al. Design and analysis of experiments in CMM measurement uncertainty study. *Precision Engineering*, 2007, 31: 94—101.
- [4] Lobato H, Ferri C, Faraway J, et al. Uncertainty due to experimental conditions in co-ordinate measuring machines. *Proc. IMechE Part B: J. Engineering Manufacture*, 2009, 223: 499—509.
- [5] Jakubiec W. Estimation of uncertainty of coordinate measurements according to the B method. *Measurement Technology and Intelligent Instruments IX*, 2009, 2: 113—117.

撰稿人: 陈晓怀

合肥工业大学仪器科学与光电工程学院

大动态范围油气勘探用地震信号传感器

High Dynamic Range Seismic Sensor for Oil & Gas Industrial

中国经济的发展对能源的依赖也已经越来越明显了,当前,能源的安全已经上升到国家安全的高度,因此,寻找后备油气资源成为中国乃至全球越来越紧迫的工作。

随着油气勘探的不断深化,勘探目的层从浅层向深层转移;勘探对象从构造性油气藏勘探向隐蔽性油气藏勘探转移;勘探区域从东部向西部新区、新盆地转移;勘探目标区地表地下条件从简单区向复杂区转移^[1]。从传统能源(油气、煤)转向非传统能源(页岩气、煤层气、水合物、油页岩等)领域,这些新的技术发展趋势都要求地震勘探技术的精度有更大的提高,对地下微弱反射信息的检测更灵敏,地震波信息检测更充分。因此,只有发展接收到精度更高、成本能够为大规模应用所接受的地震信号传感器,才能从根本上解决复杂区油气检测与识别,提高油气藏勘探开发的成功率,最大限度地满足未来国家经济社会发展对能源的需求^[2,3]。

未来油气勘探面临的勘探条件越来越复杂,勘探难度越来越大,勘探目标越来越隐蔽,勘探对象主要集中在大面积低丰度岩性油气藏、复杂山地山前高陡构造区油气藏、高成熟区的小断块油气藏、台盆区碳酸盐岩油气藏、复杂岩性体油气藏、非传统能源等6个重点勘探领域,这些重点勘探领域对地震勘探技术具有强烈的依赖和需求,但目前的地震勘探技术还不能够准确发现与落实圈闭及储层^[4,5],难点在于:①目的层埋深及展布边界的确定;②岩性及裂缝识别;③薄互层的分辨;④油气识别。与这4个难点相关联的是反射地震勘探过程中的地震波信号激发、振动信号采集、数据处理及解释,其中的首要问题是如何得到高信噪比、高保真、高分辨率的原始地震信号^[6]。

本问题是:如何设计并制造出满足下述产品指标的地震信号传感器:①频带范围内:0~800Hz;②动态检测:≥110dB;③参数精度:≤1%。

地震波采集记录系统的动态范围已经从早期的60dB左右发展到目前采用基于DS数据流转换技术的A/D芯(套)片,其动态范围已经超过120dB,而高精度常规地震传感器动态范围则只有70~75dB。尽管一些基于MEMS技术的数字传感器动态范围可以达到110dB,但价格远远超过了应用能够接受的水平。因此,震动信号检测已经成为制约基于反射地震检测油气技术的技术瓶颈。

为解决复杂区油气检测与识别^[6~8],目前,全球相关的研究课题主要致力

于:①拓展地震信号的波场(全波场);②提高地震信号的频宽;③增加下传地震信号的能量;④改善接收信号的信噪比;⑤降低传感器的成本。

提高地震信号传感器的研究主要集中在:①提高传统线圈式电磁传感器的努力(75~80dB);②采用 MEMS 技术的电容式传感器(90~110dB);③采用光栅及干涉技术的传感器(100~120dB);④经济性。

除传统能源勘探外,非传统能源由于地质目标往往埋藏较浅、对储集层薄互层的分辨力(垂向分辨率 $<1\text{m}$)要求更高,勘探活动更需要高精度、大动态、宽频响应的地震信号传感器,并且地震数据采集密度(面元 $<5\text{m}\times 5\text{m}$)要远大于目前传统能源勘探的数据密度(面元通常为 $25\text{m}\times 25\text{m}$),数据采集使用的传感器数量更多,经济性就显得尤为关键。

参 考 文 献

- [1] Sheriff R E. Encyclopedic Dictionary of Applied Geophysics .4th ed .Houston ;The Society of Exploration Geophysicists ,2002 .
- [2] 熊翥 .关于发展“开发地震技术”的几点认识 .石油物探局聘高级技术专家文集 ,2002 .
- [3] Sun S ,Castagna J P ,Siegfried R W .Examples of enhanced spectral processing in direct hydrocarbon detection .72nd Annual Meeting ,Society of Exploration Geophysicists ,2002 : 457—460 .
- [4] Pinnegar C R ,Mansinha L .The S2 transform with windows of arbitrary and varying shape . Geophysics ,2003 ,68(1) :381—385 .
- [5] Stockwell R G ,Mansinha L ,Lowe R P .Localization of the complex spectrum ;The stransform .IEEE Transactions on Signal Processing ,1996 ,44(4) :998—1001 .
- [6] Goloshubin G M ,Korneev V A .Seismic low frequency effects from fluid saturated reservoir . 70th Annual Meeting ,Society of Exploration Geophysicists ,2000 :1671—1674 .
- [7] Castagna J P ,Sun S ,Siegfried R W .Instantaneous spectral analysis ;Detection of low frequency shadows associated with hydrocarbons .The Leading Edge ,2003 ,22(2) :120—127 .
- [8] 陈学华 ,贺振华 ,黄德济 ,等 .时频域油气储层低频阴影检测 .地球物理学报 ,2009 ,52(1) : 215—221 .

撰稿人:李淑清¹ 陶知非²

1 天津科技大学电子信息与自动化学院

2 中国石油集团东方地球物理勘探有限责任公司

纳米三坐标测量机的精度标定

Accuracy Calibration of Nano-coordinate Measuring Machines

纳米技术所涵盖的尺寸范围从 100nm 到 0.1nm^[1]。在 10nm 以下(或称深纳米),大多为科学领域的前沿研究,如原子排列、分子结构探索、细胞组织研究等;而在 100nm 至 10nm 之间(或称微纳米),有广大的纳米工程技术可探索空间,如 IC 步进电机、碳纳米管、高密度资料存储、光通信组件、MEMS 组件、激光光刻、电子束加工等。一般而言,科学家们所称的纳米测量技术仍局限于使用纳米级扫描探针显微镜(SPM)实现的深纳米一维测量,而目前迅速发展的微器件的几何特征尺寸多集中于介观范围(数毫米至数微米),精度参数多为微纳米数量级(数微米至 10nm),如微齿轮、微透镜、光开关、光纤等。对于这些微小的测量对象,现有商业三坐标测量机体积庞大,同时还存在以下缺点:①各轴定位及综合精度均只能达到微米量级,满足不了纳米测量的精度要求;②测量范围过大,难以实现纳米量级的分辨率;③探头直径最小为 0.3mm,无法用于微型器件的测量;④测量力过大,对纳米测量会造成许多不确定的误差因素。

因此,近一二十年来,精度达纳米级且体积微型化的三维测量系统的研制受到世界各国的重视,大多列入世界级或国家级重点大学和研究机构的研究项目,得到充足的研究经费资助。例如:①美国标准与技术研究院的分子测量机(molecular measuring machine)^[2](未完成);②英国国家物理实验室所承担的小型三维测量机开发(small CMM)及微探头开发(探头已销售)^[3];③德国 PTB 开发的接触式光纤(CCD 作为传感组件)探头系统以对微型器件的测量^[4](技术转让给 Werth 公司上市);④日本东京大学 Takamasu 教授开发的 nano-CMM^[5](已结束,转为校正方法研究);⑤荷兰 Eindhoven 大学的高精度 3D-CMM 及微探头开发^[6](已成立 Xpress 公司上市);⑥德国 Ilmenau 大学 Jaeger 教授所研制的 nanomeasuring machine^[7](已成立 SIOS 公司上市),中国合肥工业大学在国家自然科学基金委员会资助下于 2002 年起开始研制纳米三坐标测量机(nano-CMM),经过 8 年来的努力,近年来成果也受到国际上的重视^[8]。到目前为止,国际上对此类仪器尚未有统一的名称,有称之为微型三坐标测量机(micro-CMM,依机台尺寸)或微纳三坐标测量机(micro/nano-CMM,依待测件尺寸),也有称之为纳米三坐标测量机(依最小分辨率),本文所指的纳米三坐标测量机系涵盖所有类似名称。

纳米三坐标测量机泛指所有测量精度能达到纳米尺度(100nm 至 0.1nm)范围

内的微型三坐标测量机，其准确度的标定需要有溯源性的校正方法，但目前没有任何国际标准可采用，也还未有一种国际上公认的方法。虽然在长度计量溯源体系上稳频激光干涉仪是国际所公认的最高精度仪器，但使用激光干涉仪来标定精度已遇到许多问题：第一，激光干涉仪本身在空气中的不稳定性已在数十纳米；第二，纳米三坐标测量机是要放在一小型恒温恒湿的环境腔中才能达到预期精度，但一般激光干涉仪的体积太大，不易装置于温湿控箱中；第三，如果仿照大型三坐标测量机的精度标定国际规范 (ISO/IEC 17025) 来执行，采用激光干涉仪做空间精度标定时需要测量 4 个对角线的定位精度，在更换激光的 4 个光轴时必须打开温湿控箱，再关上时需等待很长时间以便让温度稳定，然后才可执行下一动作，非常耗时；第四，无法执行探头触发位置的重复性标定。一台纳米三坐标测量机的完整标定方法须包含测头的标定 (含接触与非接触式)、测量机本体的标定 (含一维至三维的移动精度及测量精度)。如何提出有效、准确及快速的完整精度标定方法是国际上正在讨论的问题，是需挑战的难题。

依照日本东京大学 Takamasu 教授的研究，纳米三坐标测量机是应用在传统三坐标测量机和 SPM 之间的微纳测试系统，而不像 SPM 仅用在极限纳米测量领域。SPM 虽然可达纵向 0.1nm 的分辨率，但其纵向测量范围只有数微米，且其横向位移仍是靠数十微米行程的压电平台来驱动待测工件。纳米三坐标测量机的横向位移可达 20~50mm，纵向位移可达数毫米，分辨率可达 1nm。由于机台加工精度的限制，各国发展中的纳米三坐标测量机都只能标定空间不确定度 (50~100nm)，很少看到有谁敢宣称空间精度的，这是目前纳米三坐标测量机迫切解决的瓶颈问题。

如前所述，目前尚没有国际标准规范可循，但依据在 ISMTII2009 国际会议中所讨论的“微纳三坐标测量机关键技术”圆桌会议结论中所述^[9]，出席人员一致认为采用空间标准件来校正的方法应是可行的，故必须先设计合理的空间标准件的几何形状及尺寸，再研究校正测量精度的规程。图 1 给出了几个可行的空间标准件设计构想，分别可做一维测量、宽度及高度测量、二维测量等精度的校正，三维测量需要有不同的位置不同高度的几何形状，目前尚无腹案，还需要在国际合作的交流中取得共识再做定案。




图 1 构想中为校正测量精度所设计的空间标准件

参 考 文 献

- [1] McKewon P A .Nanotechnology //4th ICMT ,Hsinchu,1998 .
- [2] <http://www.nist.gov/>.
- [3] Peggs G N ,Lewis A ,Leach R K .Measuring in three dimensions at the mesoscopic level .
Proceedings of the ASPE Winter Topical Meeting-Machines and Processes for Micro-Scale
and Meso-Scale Fabrication ,Metrology and Assembly ,2003 ;53—57 .
- [4] <http://www.ptb.de> .
- [5] Takamasu K ,Hiraki M ,Enami K ,et al .Development of nano-CMM and parallel-CMM :
CMM in the 21th century .International Dimensional Metrology Workshop ,1999 .
- [6] Vermeulen M ,Rossiell P ,Schellekesn P .Design of a high precision 3D-coordinate measur-
ing machine .Annals of the CIRP ,1998 ;447—150 .
- [7] Jaeger G ,Manske E ,et al .Nanopositioning and measuring technique .Proc .of the 7th Inter-
national Symposium on Laser Metrology ,1997 .
- [8] Fan K C ,Fei Y T ,Yu X F ,et al .Development of a low cost micro-CMM for 3D micro/nano
measurements .Measurement Science and Technology ,2006 ,17 ;524—532 .
- [9] Fan K C .Technologies for micro/nano-CMM development .ISMTII 2009 ,2009 .

撰稿人：范光照
台湾大学工学院

衍射极限问题的突破

The Breakthrough of Diffraction Limit Problem

随着科技的发展,微小尺寸量测的重要性与日俱增,如何达到纳米等级的横向分辨,已是纳米测量技术的一个重要课题。在半导体产业中,目前部分芯片制造商已达到数十纳米等级线宽的制造水平,对线宽测量范围与精度之要求亦不断提升;在微机电系统中,涉及了微纳米与纳米等级的加工与测量,同样需要纳米级线宽的测量技术;在生技产业与研究中,许多生化上的反应都是发生在细胞膜和周围环境的接口,一套适合的观测设备,使研究人员直接观察其行为与传输过程,有助于生技产业之发展。

在测量方法中,目前的半导体与面板产业曝光及微纳加工的 CD (critical dimension) 线宽都仍仰赖破坏性的扫描电子显微镜 (SEM) 来测量。尽管扫描近场光学显微镜 (scanning near-field optical microscopy, SNOM) 已可突破了衍射极限 (diffraction limit)^[1], 但和工件距离太近 (10nm), 易受碰撞。许多利用远场的光学显微系统进行量测时,虽然在纵向光轴方向已达到数纳米的分辨率,但由于衍射极限的影响,最多只能达到半个光学波长左右的横向分辨率。原因在于当来自物体上的光通过成像系统,将产生衍射现象,无法在焦平面上汇聚成一清晰光点,如图 1 所示,其光点大小与光学系统之数值孔径 (NA)、光源波长有关。

光是一种电磁波,在三维空间中,任一平面上的光波复振幅分布可由各种不同方向的平面波依不同的振幅与相位差迭合而成,相当于一时域信号可分解成不同振幅与相位差的弦波。因此,若将待测物上某一点视为点光源,其发出的球面波可视为无数平面波的总和,在进入光学系统后,由于透镜之作用,能将不同方向的平面波在焦平面上再汇聚成一点。透镜具有一定的孔径大小,只有通过此一有限孔径大小的平面波才能再度汇聚成一光点,超过孔径的平面波将阻挡而无法通过,故实际上透镜的转移函数前需再加上一光瞳函数。因此,最后在成像面上的复振幅分布将少了部分的平面波,无法呈现待测面上的分布情形。透镜之孔镜多为圆形,其绕射结果的强度分布为 Airy 绕射图案 (如图 2 所示)。其中,第一个零点的半径为

$$\Delta r_0 = 1.22 \frac{\lambda z}{l} \quad (1)$$

式中, λ 为光波长; l 为孔径直径; z 为孔径至成像面之距离,相当于 $0.61\lambda/\text{NA}$ 。



图1 衍射极限光盘重合示意图



图2 Airy disc 示意图

由以上叙述可知,传统由透镜组成的光学系统相当于滤波器,部分空间频率的光波无法通过,最后在成像面所得到的光强分布是由待测物发出不同振幅与频率的平面波信号,经光学系统的滤波作用后所得到的失真现象^[2]。

观察式(1),提高数值孔径与应用较短的波长皆有其极限。在20世纪末,纳米科技开启了近场光学的研究,不再测量平常所见的反射光,而是测量存在于物体表面1个波长以内的衰减波,强度随距离急速衰减,其存在可由电磁波理论进行探讨。由于测量的非反射光,不会有衍射图案产生,而有较高之分辨率,但需要较精密之定位仪器与设备,且部分传感器孔径极小,量测大范围时相当耗时。故光学衍射问题的突破被 *Nature* 子刊——*Nature Method* 评选为2008年度最具影响力的技术之一。如能突破此瓶颈,未来甚至有可能在线非破坏性地测量出纳米线宽。

必须在光点通过阶高过程中,寻找一适当阈值,判断阶高断面位置,以提高边缘检测的横向分辨率。

在突破衍射极限上,可大致分成新型光学仪器与光学信号之解析两类方法。在新型仪器上已形成几种趋势:①线缘激发光原理,如全内部反射式荧光显微术(total internal reflection fluorescence, TIRF),其主要是应用结合近场驻波和荧光分布修补算法,具有高频率调变在横向且波峰到波峰的距离约为半个波长。被照明的对象边缘会散射出荧光且其分布被放大,透过远场光学影像可以被侦测出来,据东京大学 Takamasu 教授团队的研究,横向分辨率可达80nm左右^[3]。其他类似的有STED(stimulated emission depletion microscopy),横向分辨率可达40nm左右^[4]。②散射光场原理(scatterfield microscopy)^[5~8],由密集纳米数组线条或纳米矩阵孔洞所散射出的电磁波震荡光场强度来测量纳米线宽,此现象称之为超震荡,可达50nm左右。③结构光栅照明原理(3D structured illumination microscopy),利用一结构光栅产生三维衍射图像,其聚焦面和待测件的影像合成一空间编码信息以提高横向分辨率^[9,10],约可达100nm左右。光

学信号的解析方法有：①使用神经网络进行边缘检测，然后对确定的边缘进行线性拟合计算线宽^[11]；②利用跨焦调变将已知成像系统的点散布函数(point spread function, PSF)进行最大可能性估计的运算，将损失的高频成分重建回来而大幅提高横向解析率达 80nm^[12,13]。

参 考 文 献

- [1] Durig U, Pohl D W, Rohner F. Near-field optical-scanning microscopy. J. Appl. Phys., 1986, 59:3318—3327.
- [2] Goodman J W. Introduction to Fourier Optics. New York: McGraw-Hill, 1996.
- [3] Takahashi S, et al. Analysis of lateral resolution improvement for fluorescence microscopy using standing evanescent light. Proc. of ISMTH, 2007.
- [4] Hell S W, Wichmann J. Breaking the diffraction resolution limit by stimulated emission: Stimulated emission depletion fluorescence microscopy. Opt. Lett., 1994, 19:780—782.
- [5] Silver R M, et al. Scatterfield microscopy for extending the limits of image-based optical metrology. Appl. Opt., 2007, 46(20):4248—4257.
- [6] Silver R M, et al. Angle resolved optical metrology. Proceedings of SPIE, 2008:6922.
- [7] Shyu D M, Ku Y S, Hsu W T. Angle-resolved scatterfield microscope for linewidth measurement. Proceedings of SPIE, 2009:7272.
- [8] Huang F M, Chen Y F, et al. Optical super-resolution through super-oscillations. IPO Publishing Opt. A: Pure Appl. Opt., 2007, 9:S285—S288.
- [9] Gustafsson M G, et al. Three-dimensional resolution doubling in wide-field fluorescence microscopy by structured illumination. Biophysics, 2008, 94:4957—4970.
- [10] Shao L, et al. IS: Widefield light microscopy with 100nm-scale resolution in three dimensions. Biophysics, 2008, 94:4971—4983.
- [11] Aghajan H K, Schaper C D. Pattern recognition algorithms for linewidth measurement. Proceedings of SPIE-The International Society for Optical Engineering, 1992, 1673:83—96.
- [12] Ku Y S, Liu A S, Smith N. Through-focus technique for nanoscale grating pitch and linewidth analysis. Optics Express, 2005, 13:6699—6708.
- [13] Attota R, Germer T A, Silver R. Through-focus scanning-optical-microscope imaging method for nanoscale dimension analysis. Opt. Lett., 2008, 33(17).

撰稿人：范光照
台湾大学工学院

超高分辨率光学显微镜

Super-resolution Optical Microscopy

最早的光学显微镜出现于 17 世纪初,是人类历史上最伟大的发明之一。显微镜揭示了一个全新的微观世界,包括无数奇妙的微生物、各种各样的细胞及其错综复杂的内部结构等。伴随着显微镜方法的不断改进,显微镜一直是生物学家们从事科学研究、探寻生命奥秘的有力工具,并直接促成了细胞生物学及其相关学科的突破性发展。现代医学为了更加准确地阐述生命活动的机理和重大疾病的发病原理,以及提供实时快速的检测及诊断,更是离不开超高分辨的光学显微镜。

但是,在过去的几个世纪里,光学显微镜的空间分辨率却一直受限于衍射极限。可见光由于其波动特性会发生衍射,导致光束不能无限聚焦。在 $400\sim 760\text{nm}$ 的可见光波段内, 200nm 就是显微镜的理论分辨率(如图 1 所示)。而随着生命科学的迅猛发展,研究已深入到单细胞、亚细胞和单分子这样的层次,显微镜的空间分辨率已经成为其中最为关键的核心问题。




图 1 普通光学显微镜的分辨率

病毒是怎样感染细胞的? 细胞是如何感受外界刺激? 蛋白质是怎样组装和运作的? 要了解这些,科学家需要深入到细胞内部,看清楚 $2\sim 20\text{nm}$ 尺度的目标物体。尽管近场扫描光学显微镜(near-field scanning optical microscopy, NSOM)^[1]突破了衍射极限,不再受到光波的限制,分辨率可以达到纳米级别,但它只适用于表面二维高分辨率测量,不能直接观测细胞内部。

最近,基于近期物理学家带来的方法原理的革新和现代测量技术的发展,远场光学显微镜得到了革命性的进展,分辨率提高到纳米尺度(如图 2 所示),其中,主要包括受激发射减损显微镜(stimulated emission depletion microscopy, STED)^[2]、饱和结构照明光学显微镜(saturated structured illumination microscopy, SSIM)^[3]、基于单分子定位方法的光敏定位显微镜(photo activated localization microscopy, PALM)^[4]和随机光学重建显微镜(stochastic optical reconstruction microscopy, STORM)^[5],这些方法使得光学显微镜得以突破光波衍射极限的限制,直接在单分子水平上对生物细胞内部进行细微的观察研究。

2009 年年初，*Nature* 子刊——*Nature Method* 评选出的年度最具影响力的生物方法突破就是超高分辨的光学显微镜。




图 2 超高分辨显微成像技术

(a) 各种超高分辨显微技术原理示意图；(b) 传统显微成像；(c) 超高分辨显微成像

2000 年，德国哥廷根马普生物物理化学研究所的 Hell 利用 STED 显微原理，率先将远场光学显微镜的分辨率提高到 100nm。STED 原理是通过两束激光，减少荧光光点的衍射面积。第一束激光用于激发荧光分子，第二束激光将激发光斑焦点外围的荧光猝灭，只有焦点中心能检测到荧光，显微镜的分辨尺度由激发光斑的大小缩小到焦点中心的大小。原则上，提高第二束激光的光强，荧光光斑的大小可以趋近于 0，也就是说，显微镜分辨率不再受光的衍射限制。实际操作中，STED 显微镜的分辨率可以达到 30nm 左右。STED 显微镜的优点是可以快速观察活细胞内实时变化的过程，目前已经可以达到视频速度，这是其他超高分辨的光学成像无法达到的。但是，它的缺陷也很明显，光路复杂，设备昂贵，对系统的稳定性要求很高。另外，只能选用特定的染料，并使用高强度的第二束激光，也限制了它的应用范围。

2005 年，美国加州大学旧金山分校的 Gustafsson 发展了 SSIM 方法，成功得到了分辨率达到 50nm 的图像。SSIM 是一种干涉成像方法，将多束激光照射

到样品上,由相互衍射得到一系列的低分辨 moire 条纹成像,然后经计算机处理和重建,从中提取样本高分辨率的信息。SSIM 是一种宽视野荧光显微镜,可以大范围快速地扫描样品,而且搭建简单,不需要特殊的荧光标记。可惜,SSIM 最大的缺点是它的分辨率要低于其他的超分辨率成像方法。

2006 年,美国霍华德·休斯医学研究所的 Betzig 提出了 PALM 方法。同年,哈佛大学的庄小威发布了 STORM 方法,这两种方法原理相似,需要采集多张原始图像,在每一张原始图像中,只有部分分立的荧光分子能被观察并成像,最后将这些原始图片叠加、重合在一起就得到了分子水平的高分辨率图像。其中, PALM 方法使用外源表达的蛋白质作为荧光探针, STORM 方法用标记内源蛋白质的染料分子作为荧光探针。因为使用单分子进行精确定位, PALM 和 STORM 方法是迄今分辨率最好的光学显微镜,能达到 20nm 以下,由于采集时间较长,它们都还不太适合于活细胞的实时成像。

短短几年,生物学家已经借助各种超高分辨率光学显微镜,正在不断改变我们对细胞内部结构及运作的认识,研究领域从动态及静态的细胞组织结构、细胞膜的不均一性问题到动态蛋白组装。随着各种荧光探针和标识技术的发展和出现,现有的超高分辨率光学显微成像技术将大幅改善。现在,超高分辨率光学显微成像的研究热点大致有三个方向:第一,进一步提高空间分辨率,将分辨率从现有的几十纳米推进到几纳米;其次,缩短采集时间,能实时观测活细胞;最后,开展多色超高分辨率光学显微成像,实现同时探测多个目标分子。

参 考 文 献

- [1] de Lange F, Cambi A, Huijbens R, et al. Cell biology beyond the diffraction limit: Near-field scanning optical microscopy. *J. Cell Sci.*, 2001, 114: 4153—4160.
- [2] Klar T A, Jakobs S, Dyba M, et al. Fluorescence microscopy with diffraction resolution limit broken by stimulated emission. *Proc. Nat. Acad. Sci.*, 2000, 97(15): 8206—8210.
- [3] Gustafsson M G. Nonlinear structured-illumination microscopy: Wide-field fluorescence imaging with theoretically unlimited resolution. *Proc. Nat. Acad. Sci.*, 2005, 102: 13081—13086.
- [4] Betzig E, Patterson G H, Sougrat R, et al. Imaging intracellular fluorescent proteins at nanometer resolution. *Science*, 2006, 313: 1642—1645.
- [5] Rust M J, Bates J, Zhuang X. Sub-diffraction-limit imaging by stochastic optical reconstruction microscopy (STORM). *Nature Methods*, 2006, 3: 793—796.

撰稿人: 李奇峰

天津大学精密仪器与光电子工程学院

中长期天气的温、湿度预测

Medium/Long Range Temperature and Humidity Prediction

温度、湿度是重要的气象要素，早在几千年前，人们已经能够根据气候特点进行耕种、建筑，并且出现了专门从事气象工作的专职人员，但那时人类对天气的观测尚处于感性认识和经验积累阶段。进入工业革命阶段，先后出现了一些气象观测仪器，为中长期天气的温、湿度预测奠定了坚实的基础。1904 年，Bjerkne 首次提出基于温、湿度预测的数值天气预报理论。1922 年，Richardson 对这种理论进行了首次尝试实践。20 世纪以来，气象学进入快速发展时期。1954 年，基于中长期温、湿度预测的数值天气预报业务首先在瑞典得以实现，并陆续在各国开展应用，日益成为当代天气预报的主要方式。

基于中长期温、湿度预测的数值天气预报是以大气运动的动力学和热力学为基础，应用巨型高速计算机进行数值求解控制大气运动的方程组，尝试对天气进行客观、定量的预测^[1]。一般把时效为 3~10 天的预报称为中期预报，时效为 10 天以上的预报称为长期预报。我国业已建立了完善的数值预报系统。目前，国际上主要的数值天气预报模式包括欧盟的 ECMWF 全球谱模式 T511L60、日本的远东区域模式 ASM、美国的全球谱模式 T170L42、英国统一模式 UM、德国的全球模式 GME、我国的全球与区域同化预报系统 GRAPES^[2]。随着数值天气预报技术水平的不断提高，预报周期至少是每 10 年增加 1 天。

但是，上述基于中长期温、湿度预测的数值天气预报模式仍然存在着一些尚未解决的关键科学问题，导致中、长期天气预报仍然存在着较大的误差，亟须科学工作者们共同努力，实现突破。

首先，较远空间和时间距离的任何微小的变化都会对数值天气预报精度产生不可忽视的影响，也就是人们常说的“蝴蝶效应”。因此，需要创建全球气象监测数据同步系统，实现气象数据的全球共享。虽然国际上已经在尝试建立地面常规观测、雷达观测、气象卫星遥感探测等多方法、多角度、多层次的立体化数据结构，并构建了具有卫星通信和地面公共通信相结合的气象信息网络系统^[3]，各国气象中心也可以从全球电信系统获取相应气象信息^[4~6]，但远未实现气象数据的全球同步共享，而且就全球气象观测而言，目前仍有相当多的资料空白区域，特别是在南半球洋面上的气象数据十分匮乏。

其次，中长期天气的数值预报是一个初值问题，其准确率与初始状态的准确程度密切相关。在目前全球观测站点分布极不均匀的情况下，如何将资料转变为

规则网点上的完整模式初值是完成精确预报的基础和成功的关键^[4]。目前,正在尝试使用的方法包括逐步订正法、最优统计差值法、三维和四维变分同化方法^[7~9],其中,四维变分同化取得了一定的突破,但仍然没有达到令人满意的程度^[10]。

最后,数值天气预报从来都是对高性能计算机需求最大的主要领域之一。早在 Richardson 的时代,人们就已经注意到数值预报的计算量靠人力是无法完成的。世界上第一台电子计算机“MANIAC”(狂人)也因为能够成功完成数值天气预报而轰动一时。可以说,计算机的性能长期以来都是制约气象数值模拟和预测的“瓶颈”因素。近年来,大规模并行计算机技术的发展为数值模拟和预报的发展提供了极好机遇。但是,因为不仅涉及了机器的计算能力、算法的连续运行稳定性,还要综合超大规模数据库同步、全球气象观测点建立统一标准等问题^[11]。无论是早期的专家系统、神经网络算法,还是后来的云计算平台,如何应用它们进行准确的中长期数值天气预测,始终是科学领域的一个重要难题。

参 考 文 献

- [1] 陈德辉,薛纪善.数值天气预报业务模式现状与展望.气象学报,2004,62(5):623—633.
- [2] 冯国柱.中期数值天气预报发展综述.广东气象,1998,1:39—41.
- [3] 郑国光.气象部门改革开放三十周年纪念文集.北京:气象出版社,2008.
- [4] 章国材,矫海燕,李延香.现代天气预报技术和方法.北京:气象出版社,2007.
- [5] Bevis M, Businger S, Herring T, et al. GPS meteorology-Remote sensing of atmospheric water vapor using the global positioning system. Journal of Geophysical Research, 1992, 97(D14):15787—15801.
- [6] Kelly G. Satellite observations for global modelling. Advances in Space Research, 1992, 12(7):263—275.
- [7] Courtier P, Andersson E, Heckley W, et al. The ECMWF implementation of three-dimensional variational assimilation (3D-Var). I: Formulation. Quarterly Journal of the Royal Meteorological Society, 2006, 124(550):1783—1807.
- [8] Daescu D N. On the sensitivity equations of four-dimensional variational (4D-Var) data assimilation. Mon. Wea. Rev., 2008, 136:3050—3065.
- [9] Fang F, Pain C C, Navon I M, et al. A POD reduced-order 4D-var adaptive mesh ocean modelling approach. International Journal for Numerical Methods in Fluids, 2009, 60(7):709—732.
- [10] 薛纪善,陈德辉.数值预报系统 GRAPES 的科学设计与应用.北京:科学出版社,2008.
- [11] 伏圣信.神威机上集合数值天气预报系统功能概述.应用气象学报,2002,13(02):228—231.

撰稿人:王 鹏 王 雪
清华大学精密仪器与机械学系

量子运动测量问题

The Question of Measurement in Quantum Motion

量子力学是基础物理研究的重要组成部分，量子理论的建立被认为是 20 世纪世界的伟大里程碑。量子力学基础理论的发展促进了原子能、激光和半导体等重大技术的发明，并使人们对微观世界的运动规律有了基本正确的、革命性的理解^[1]。近年来，量子力学与信息、能源、生化等学科的结合越来越广泛和深入，产生了许多重要的交叉研究领域，量子理论已在 21 世纪科技发展中具有不可替代的重要作用。但是，量子力学理论仍是不完善的物理学理论，自量子力学建立以来，关于量子理论的一些基本问题的争论从未停止过^[2]，特别是量子运动测量问题，至今仍未能得到很好的解决。

量子运动测量问题的产生、定义与发展引起了 20 世纪初基础物理学界广泛的研究与争论。1900 年，普朗克在分析黑体辐射实验中首次引入了量子的概念，并成功用光量子的观念解释了光电效应；1926 年，薛定谔提出了波动方程，发表了量子波动力学，描述了微观粒子状态随时间变化的规律；1927 年，海森堡提出了“测不准原理”，指出微观粒子的某些物理量无法同时确定，测量一对共轭量的误差乘积大于 $h/4\pi$ (h 是普朗克常数)；1930 年，玻尔提出了量子力学的哥本哈根诠释，对量子测量问题进行诠释。

在微观世界中，测量本身会干扰测量结果(如图 1 所示)。量子运动的测量过程会引起量子状态的不可逆改变，亦即产生量子的坍缩现象。与经典力学测量不同，当使用测量仪器对某一被测量子运动系统进行测量时，被测仪器将会被纳入量子力学框架，测量仪器与被测量子运动系统之间会产生相互作用，被测系统将会发生坍缩，量子原有的波函数描述会被约化到其中一个分支，亦即从一个具有多种可能运动状态的概率分布退化为类似于经典运动测量的单一状态，发生了信息丢失。量子运动测量中的波包坍缩源于物质运动的双重属性：波动性与粒子性。在同一次测量实验中，微观粒子的两个属性是相互排斥的^[3]。

近年来的研究表明，在某些条件下，测量仪器对被测量子系统产生的破坏是可逆的。1995 年，Pritchard 研究小组进行了激光介入钠原子干涉的相干性破坏实验^[4]。实验中，钠原子流在干涉仪中沿两条路径发生干涉，用激光干扰照射其中一条钠原子流路径，干涉条纹消失；将两条钠原子流的路径改为 $1/4$ 激光波长的整数倍后，屏幕上重新出现了钠原子干涉条纹。该激光干扰钠原子干

涉实验说明, 钠原子的相关性在与激光光子的“纠缠”中保存了下来, 在某些特定条件下, 被破坏的量子相关性能够得到恢复。针对量子运动测量中的波包坍缩问题, 弱测量理论是一种有效的解决途径^[6]。对量子运动进行弱测量, 波包坍缩只会被部分的触发。美国加州大学圣芭芭拉分校的 Nadav 研究小组的研究表明, 在超导状态下量子运动状态的弱测量引起的波包坍缩是可以被恢复的^[7] (如图 2 所示)。但是, 在非弱测量条件下的去坍缩问题仍然无法解决。





图 1 Giedke 小组的介观自旋集测量结果^[5]

每次测量将会对量子运动状态引入干扰, 使得量子运动状态发生坍缩






图2 Nadav 小组的量子运动测量去坍缩研究成果

图中通过状态断层扫描将量子状态表示在了 Bloch 球面上, 第一排为部分坍缩后量子状态, 第二排为去坍缩后量子状态

研究量子运动测量问题首先要讨论的基本问题就是量子测量的定域性问题。量子测量的定域性问题主要涉及量子力学的完备性, 是否遵循定域性准则, 以及量子测量过程中是否存在隐参数等。量子测量的定域性问题最早起源于爱因斯坦与玻尔等关于 EPR 佯谬的争论。爱因斯坦等提出的 EPR 佯谬中指出, 双粒子飞行系统中由测量所引发的波包坍缩是满足动量守恒的, 并针对该现象指出量子力学的描述是不完备的, 或不具备定域性。玻尔则提出双粒子飞行系统的两个子系统是不能互不相干的。贝尔则针对此问题提出了贝尔不等式, 引入隐藏数描述相互关联的两个子系统。自 20 世纪 70 年代起, 各国研究者先后完成了十余次量子测量实验, 期望能够从中找出支持量子定域性问题上上述某一结论的实验依据。但遗憾的是, 实验所得到的结论是不统一的, 这也直接导致由 EPR 佯谬引发的量子测量定域性问题变得愈发尖锐^[2]。

量子世界里存在不确定性, 根据海森堡不确定原理可知, 粒子在某一时刻的位置与动量是不能同时准确给出的。对粒子的位置进行一次精确测量, 会影响到粒子动量的精确性, 位置测量的越精确, 它的动量就会越不精确, 反之亦然。对粒子实现测量会影响其他特性, 量子内部存在模糊性。因此, 关于量子的行为通常用概率来表示, 例如, 一个粒子在某一时刻、某一位置出现的概率是多大。概率是不确定性的表现, 一般指某个事件发生的可能性。在量子力学中, 一个力学量的哪个值能被测量到原则上是无法预测的, 这种概率是事物的内禀属性^[8]。

测不准原理是量子力学中的基本定理之一, 反映的是量子运动测量中的同时性问题。许多重要的物理现象(如粒子的隧道效应等)均是由粒子的测不准原理引起的。量子系统中, 测不准关系本质上是由微观粒子的波粒二重性所导致。在测不准原理的基础上, 如何通过概率统计的方法对量子运动进行预测测量对于现代科学技术的发展具有重要意义。

量子微观世界充满着各种未知。在采用测量的手段认知量子运动的过程中,面临着量子运动测量的定域性确定、波包坍缩及测量同时性等问题,这些尚未解决的难题使得人类对量子世界的认知是不完备的。量子运动测量问题是基础物理测量中的基本问题,也是近百年来最富有挑战性的难题之一。

参 考 文 献

- [1] 孙昌璞.量子力学若干基本问题研究的新进展.物理,2001,30(5):310—316,321.
- [2] 何祚庥.谈谈量子力学测量问题.物理,1993,22(7):419—430.
- [3] Omnes R.The Interpretation of Quantum Mechanics.New Jersey:Princeton University Press,1994.
- [4] Yam P.Bringing Schrödinger's cat to life.Scientific American,1997.
- [5] Giedke G,Taylor J,et al.Quantum measurement of a mesoscopic spin ensemble.Phys.Rev.A,2006,74(3):32316—32324.
- [6] Jordan A,Korotkov A.Uncollapsing the wave function.Coherence and Quantum Optics IX,2008:191.
- [7] Nadav K,Matthew N,et al.Reversal of the weak measurement of a quantum state in a superconducting phase qubit.Phys.Rev.Lett.,2008,101:200401.
- [8] 王鹏,李建平.信号测不准原理的量子诠释.电子科技大学学报,2008,37(1):14—16,42.

撰稿人:王 雪 孙欣尧
清华大学精密仪器与机械学系

超高精度、长航时、微型化惯性导航测量

Ultra-high Precision ,Long-endurance ,Miniaturized Inertial Navigation Measurement

导航技术的发展直接推动了人类文明的进步,提高了人类探索未知世界的能力。从美国凤凰号火星探测器飞越茫茫太空成功着陆火星到我国神舟七号载人飞船顺利返回地球,“导航”均在其间扮演了极其重要的角色。导航就是利用各种方法使航行体到达指定地点,是一个通过与已知位置或者图谱相比较确定航行者的位置,从而控制其在不同位置间移动的过程。导航对航行体运动的控制作用就如同人体中枢神经对肢体的控制作用。人类在生产和生活实践中发明了导航方法,从早期的根据夜空中的北斗七星和利用“司南”、罗盘等装置确定方位,到现代的惯性导航、卫星导航、天文导航及无线电导航,不一而足。惯性导航是现代导航技术中最重要的一种,被广泛用于车辆、飞机、空间飞行器、战术/战略导弹、潜艇和船舶,同时,也在大地测量、资源勘测、海洋探测、铁路、隧道,甚至机器人、摄像机和儿童玩具中广泛应用^[1~4]。

惯性导航系统至少包括一台计算机和一个由加速度计、陀螺或者其他运动传感器组成的模块。陀螺在惯性导航系统中测量系统相对惯性参考系的角速度。系统在惯性参考系中的最初方向作为输入的初始条件,当前方向通过积分角速度来获得。加速度计在惯性导航系统中测量系统相对惯性参考系的线加速度,但测量方向只能是相对载体移动方向,因为加速度计被固定在系统上并随系统一起转动,并不知道自己的方向。同时具有加速度计和陀螺可以通过跟踪系统当前相对于运动载体的角速度和线加速度,确定其在惯性参考系中的线加速度。依据动力学方程,以初始速度作初始条件,对惯性加速度进行积分可获得系统的惯性速度,以初始位置作初始条件再次积分可以获得系统的惯性位置。图 1 是惯性导航的一个简单的概念示意图。

由上所述,惯性导航系统是由其他来源(操作人员、GPS 卫星等)提供初始位置和速度,然后通过积分运动传感器的信息来计算当前的位置和速度。一旦系统初始的经/纬度确定,就可以依据多轴线加速度和角速度信息,连续并精确计算出当前的经/纬度。优点是:一旦初始位置确定,就不要求外界信息,不受恶劣气象条件影响,也不会被敌探测或者阻断。缺点是:导航的精度会受到积分漂移的影响。加速度和角速度测量的小误差通过积分会累积成更大的速度误差,进一步会转变成更大的位置误差。因为新的位置是从以前计算的位置和加

速度与速度测量值计算出来的,这些误差是累积的,累积速率与从输入初始位置到当前测量间的时间大约成正比。测量时间越长,累积误差越大,对应的导航精度就越差。因此,当惯性导航系统精度不够高时,其测量位置就必须通过其他导航系统定期纠正,或者一般用于辅助其他导航系统来获得比使用单一系统更高的精度。惯性导航系统和卫星导航系统通过数字滤波系统混合使用是常用的方式。当惯性导航系统的精度足够高时,就可以在足够长时间内使累积误差保持在允许的范围内,这样,系统不与外界通信,仅依靠载体自身传感器和数据处理器就能长时间获得精确的位置信息。这种超高精度长航时的自主导航能力是目前导航技术发展所迫切需求的。

目前,一个导航级的高精度惯性导航系统的位置不确定度一般小于 0.6 海里/h,陀螺偏移 $<0.01^{\circ}/\text{h}$,加速度计偏移 $<50\mu g^{[5]}$ 。当其与卫星导航系统混合使用时,则可以达到 $<5\text{m}/\text{h}$ 的位置不确定度。要实现超高精度的惯性导航系统,使之定位精度接近惯性/卫星混合导航定位精度($<5\text{m}/\text{h}$),要求实现超高精度的加速度计和陀螺,如偏移要达到 $1\text{ng}/\text{h}$ 量级的加速度计和 $10\mu\text{deg}/\text{h}$ 量级的陀螺。另一方面,惯性导航系统的导航精度也与地球参数的精度密切相关。高精度的惯性导航系统须用参考椭球来提供地球形状和重力的参数。由于地壳密度不均匀、地形变化等因素,地球各点的参数实际值与参考椭球求得的计算值之间往往有差异,这种现象称为重力异常。要获得超高精度的惯性导航测量,须通过高精度重力或者重力梯度仪对重力场进行实时测量,解决重力异常问题。总之,高精度惯性导航问题的解决需要足够精度的加速度、角速度和重力测量方法的实现和有效组合,也需要我们对惯性机理的更深层次的理解。

另一方面,惯性导航系统的成本和复杂性对其适用的环境附加了诸多约束,其体积和功耗限制了其应用领域的扩展。惯性导航系统的微型化则一方面可以降低功耗与成本,更重要的是可以大大扩展其应用范围,如将惯性导航系统用到炮弹、机器人、人和动物的运动捕获上等。近年,微米纳米技术的发展大大促进了微型惯性器件的研发,微型加速度计和陀螺被广泛应用到汽车、摄像机、手机、炮弹等传统惯性器件无法应用的场合,大大提高了这些装置的性能。例如,美国苹果公司最新推出的 iPad 和 iPhone 都安装了微型加速度计和陀螺(如图 2 所示)。但是,要实现微型化的惯性导航,则需要微型惯性器件的性能获得大幅度的提高。而解决这一问题,或者要寻找新的高精度测量加速度、角速度和重力的原理或实现方法,或者要对当前的惯性导航技术进行大幅度改进,这是一个复杂的科学与工程难题。

突破当前技术限制,解决兼具超高精度、长航时和微型化的惯性导航测量问题,将使我们人类认识未知世界的能力大大提高,很多科幻电影中出现的场

景将成为现实，如能够在深海、太空和天空中自由遨游的高级机器人和飞行器
等，将成为现实。




图1 惯性导航示意图



图2 美国苹果公司 iPhone4 中的微型陀螺芯片

现代惯性导航方法已经有很长的研究历史。17 世纪，牛顿研究了高速旋转刚体的力学问题，奠定了惯性导航的理论基础；1852 年，傅科将这种刚体称为陀螺并制成供姿态测量用的陀螺仪；Anschutz 于 1906 年制成自转轴能指向固定方向的陀螺方向仪，于 1907 年在方向仪上增加摆性制成陀螺罗盘。1923 年，舒拉发表“舒拉摆”理论，解决了在运动载体上建立垂线的问题，使加速度计的误差不致引起惯性导航系统误差的发散，为工程上实现惯性导航提供了理论依据。这些工作是惯性导航系统的先导^[1,3,4]。1942 年，德国在 V-2 火箭上首先应用了惯性导航原理。1954 年，惯性导航系统在飞机上试飞成功。1958 年，鲟鱼号潜艇依靠惯性导航在北极冰下航行 21 天，证明了惯性导航不但可以在火箭、飞机上使用，也可以在船舶、潜艇、车辆上使用。虽然过去几十年里，各种导航系统不断升级和发展，但惯性导航系统仍然是很多航天飞机、空间探索导航和武器系统的核心系统。

惯性导航系统按照其在载体上的安装方式，可分为平台式惯性导航系统和捷联式惯性导航系统。目前，已经发展出挠性惯导、光纤惯导、激光惯导、微固态惯性仪表等多种方式。激光陀螺在高精度的应用领域中一直占据着主导地位。成本较低的光纤惯导和微机械惯导精度近年提高很快，是未来技术发展的方向之一。基于原子干涉的超高精度惯性技术及重力测量技术也是未来重要的发展方向。

我国从 1956 年开始研制惯性导航系统，自 1970 年以来，在多次发射的人造地球卫星和火箭，以及各种飞机上都采用了本国研制的惯性导航系统，但总体水平上与国外发达国家仍有较大差距^[6]。

参 考 文 献

- [1] Woodman O J. An introduction to inertial navigation .UCAM-CL-TR-696 ,2007 .
- [2] Barbour N ,Schmidt G .Inertial sensor technology trends .IEEE Sensors ,2001 ,1 (4) ;332—339 .
- [3] 朱家海 .惯性导航 .北京 : 国防工业出版社 ,2008 .
- [4] 秦永元 .惯性导航 .北京 : 科学出版社 ,2006 .
- [5] 张炎华 ,王立端 ,战兴群 ,等 .惯性导航技术的新进展及发展趋势 .中国造船 ,2008 ,49 : 134—144 .
- [6] 中国科学技术协会 .惯性技术学科发展报告 .北京 : 中国科学技术出版社 ,2010 .

撰稿人：冯焱颖

清华大学精密仪器与机械学系

地磁场测量高斯分析中的唯一性问题

Uniqueness in the Gaussian Analysis of Geomagnetic Field Measurement

地球具有磁场,人类很早以前就发现了地磁场并加以利用。公元前 250 年,中国人就已发现天然磁石的吸铁性和指极性,并用天然磁石磨成指向装置,而地磁学历史可追溯到公元 1000 年左右磁罗盘在中国的发现。近代,自然科学许多学科的发展都是从研究地球开始。地磁场的理论概念是英国人 Gilbert 对磁铁和磁场进行系统研究后于 1546 年发现,并在《论磁性、磁体和巨大地磁体》著作中最早提出了“地球是一个巨大磁石”假说。1839 年,数学家高斯在著作《地磁力的绝对强度》中,从地磁成因于地球内部这一假设出发,创立了描绘地磁场的球谐分析方法,奠定了地磁学理论基础,从此地磁场研究纳入数理分析轨道。为纪念高斯这一功绩,人们通常把地磁场球谐分析称作“高斯分析”^[1]。地磁测量不仅是一门基础科学,也是“数字地球”框架之一,对寻找地下资源,探讨预报灾性天气、大地震发生和火山爆发等自然灾害,发射人造卫星、宇宙飞船和发展程导弹、远洋潜艇、空间通信、遥感遥测等有着重要现实意义。

高斯分析中的唯一性问题是地磁学基础研究中的热门课题之一。20 世纪 70 年代以来,许多科学家研究了在定国际地磁参考场(IGRF)中所用资料不同时的唯一性问题。1968 年,Backus 率先提出唯一性问题^[2],认为差一常数的两个势函数都满足拉普拉斯方程,并指出采用标量资料时的解不唯一。Langle 指出,原则上由于地表资料点数有限,无法完全已知地表场,以至球谐系数不能唯一确定,高于 14 阶的基本场(major field)系数还不能定。Lowers 等讨论了仅给出球面上部分场的信息时的拉普拉斯势函数的唯一性问题。Hulot 讨论了用角度资料(I, D)得出的偶极子磁场的唯一性问题。Alberto 利用量子力学中的角动量矩和 Clebsch-Gordan 系数方法对只有闭合地表面上地磁场标量信息研究^[3]。

地磁场是矢量场,地磁场势函数 U 满足拉普拉斯方程: $\nabla^2 U = 0$, 其通解为^[4]

$$U(r, \theta, \lambda) = a \sum_{n=1}^{\infty} \sum_{m=0}^n \left\{ \left[\left(\frac{a}{r} \right)^{n+1} (g_n^m \cos(m\lambda) + h_n^m \sin(m\lambda)) \right] \right\}$$

$$+ \left(\frac{r}{a} \right)^n [j_n^m \cos(m\lambda) + k_n^m(t) \sin(m\lambda)] P_n^m \cos \theta \}$$

上式称为地磁场磁位的高斯级数表达式, 其中, g_n^m 、 h_n^m 、 j_n^m 、 k_n^m 为高斯系数, g_n^m 和 h_n^m 为内源场系数, j_n^m 、 k_n^m 为外源场系数。任何一个高斯系数都是独立求出的, 在求解中, 各阶高斯系数无依赖关系, 但在即使仅存在内源场情形下也必须给出整个地球表面的 U 值或垂直分量 Z 值才能唯一确定整个自由空间的磁场解。仅已知地球表面有限个离散测点的场值, 或者仅已知地球表面局部区域的场值, 或者仅已知整个地球表面的总强度 F 值都不能唯一确定磁场解, 即不能唯一确定全部高斯系数。

从纯数学角度来看, 确定高斯系数 g_n^m 和 h_n^m 有三种做法: 一是满足第一类边界条件, 即 Dirichlet 问题, 要求地磁场势函数在全部边界的值已知; 二是满足第二类边界条件, 即 Neumann 问题, 要求地磁场势函数在全部边界的法向导数为已知; 三是满足第三类边界条件(混合边界条件), 即 Robin 问题, 要求地磁场势函数在部分边界的值已知并且在剩余边界处势函数的法向导数已知。但是, 在地磁场的高斯分析中, 一般只能获得地表附近闭合曲面(单个边界)的地磁场强度的切向分量及其垂直分量, 显然无法满足上述三种边界条件。如果能够从数学上找到第四类边界条件, 能够证明地磁场高斯分析的唯一性, 则可在丰富偏微分方程研究体系的同时巩固地球物理研究中的理论基础。

关于唯一性问题, 至今仍然还无法从根本上作出合理、完善的解决。实际分析中, 人们总是寻求在一定误差范围内的近似解, 利用一个只包含有限高斯系数的被截断的球谐级数来近似表征整个自由空间的场, 因此, 实际地磁高斯分析可归结为用最小二乘法解只包含有限个待定高斯系数的代数方程^[5]。目前, 地磁学家在高斯分析基础上, 忽略占地磁场极小分量的外源场, 每 5 年给出 1 个 IGRF。

根据地磁场研究范围, 地磁场模型分为全球和局部地区两类, 高斯分析是全球地磁分析的主要理论方法^[6]。地磁场高斯分析对推动“地磁场起源”这一地球物理学中基本问题研究深入起到重要作用。关于地核场起源假说中, 1919 年, 拉莫尔提出的“自激发电机说”是解释地核场起源最为合理的一种学说, 但并未获得一致认同; 近年来, 又有“大洋环流诱导说”等一些新的假说出现。地磁场测量分析涉及地球起源、演化及其内部物理状态等诸多问题, 同时局部区域的地磁分析及其唯一性问题还需进一步深入研究。随着计算手段和理论方法的进步, 测量载体形式多样化, 地磁数据源越来越多, 地磁测量分析方法有待进一步创新与优化, 借助先进的数据处理技术, 提供更精确的动态结果及更合理的物理解释。

参 考 文 献

- [1] 傅承义,陈运泰,祁贵仲.地球物理学基础.北京:科学出版社,1985:109—116.
- [2] Backus G E. Application of a non-linear boundary-value problem for Laplace's equation to gravity and geomagnetic intensity surveys. *Quart. J. Mech. Applied Math.*, XXI, 1968:195—221.
- [3] Alberto P, Oliveira O, et al. On the non-uniqueness of main geomagnetic field determined by surface intensity measurements: The Backus problem. *Geophys. J. Int.*, 2004, 159:548—554.
- [4] 王宣文.在地磁学与地球重力学中的球谐分析.地球物理学进展, 2005, 20(1):211—213.
- [5] Wu W J. Uniqueness of spherical harmonic analysis in geomagnetism and an interpretation of the Backus effect. *Chinese Science Bulletin*, 1985, 30(10):1368—1274.
- [6] 吴文京.关于地磁球谐分析方法应用于局部地区的问题.科学通报, 1984, 16(11): 999—1003.

撰稿人: 李玉和 杨建中
清华大学精密仪器与机械学系

精密封闭内腔几何/物理特性表征与探测方法

Geometry/Physical Characterization of Precision Closed Cavity and Its Detection Method

具有精密封闭内腔的器件是一类特殊而重要的器件,有着重要的应用场合。因而,对这类器件精密封闭内腔内尺寸和形貌进行精密测量具有重要的应用价值。例如,超导陀螺的球形转子和壳体构成的球形内腔就是一个典型的封闭内腔^[1,2]。超导陀螺的球形腔要求具有理想球体的形状特征,才能保证超导陀螺的指向精度,因而必须对超导陀螺安装完毕后的球形腔进行精密的形貌测量(如图1所示)。




图1 超导陀螺的精密球形腔

对于封闭内腔的精密探测,就是对其几何/物理特性进行表征,这包括封闭内腔在结构中的相对坐标位置、姿态、三维结构尺寸、内表面形状与微观形貌等信息。能否准确地表征封闭内腔几何特征,则依赖于能否对这些几何/物理特征进行精密测量。鉴于此,就如同对三维常规物体外几何特征所做的精密测量一样,需要对封闭内腔内几何特征进行三维精密测量。

目前,对于常规物体的外形几何特征的高精度测量典型仪器有多种选择,如测长度尺寸的双频激光干涉仪、测形状的激光平面干涉仪和测量表面微观形貌的原子力显微镜、扫描隧道显微镜和纳米测量机等。原子力显微镜、扫描隧道显微镜可以实现亚纳米精度的测量,纳米测量机也已经可以在一定测量范围内实现纳米精度的测量^[3]。通过光学外部扫描的方式也可以使常规物体或者器件的外几何特征的测量达到较高的精度,而且常规物体外几何特征的测量精度还在不断提高之中。

然而,由于封闭内腔的封闭性,使得常规的接触式测量方法和光学外部扫描方法都无能为力。也就是说,上述用于常规物体外几何特征测量的高精度仪器和方法都不能用于封闭内腔的内几何特征的测量。对封闭内腔,只能根据其结构和材料特点,寻求相应的光学透射式测量法,或者射线、电/磁感应类等非接触测量方法。目前,可用于封闭内腔的探测方法大致分为两大类:一类是工业中应用最广泛的射线检测法、超声波检测法、磁粉检测法等^[4,5];另一类是光学断层扫描法^[6~8]。

射线检测法是利用射线透过物体时会发生吸收和散射这一特性,通过测量材料和结构中因内腔存在而影响射线的吸收和散射来实现探测内腔的几何特征。射线检测法最典型的是计算机断层成像技术,已经有很成熟的产品和应用。

超声波检测法目前用得最多的是脉冲反射法,用纵波或者横波把超声波射入被测结构的一面,然后在同一面接收从内腔处反射回来的回波,通过接收和处理回波实现内腔探测。

磁粉检测法是根据铁磁性材料被磁化后,其内部产生很强的磁感应强度,磁力线增大几百倍到几千倍,器件结构中的内腔会使磁力线分布发生明显改变,如果这时在器件表面上撒上磁粉,磁粉会形成与内腔形状相近的磁粉堆积。

光学断层扫描法是把光波当做信息的载体,通过测量生物组织的背散射光强度和相位获取内部的显微结构信息进行层析成像,一般用于医疗领域,经改进后也可以用于由光波能够部分穿透的材料构成的封闭内腔的几何形貌探测。

目前,这些方法在工业产品无损探伤、海关和机场的安检、医疗诊断等领域具有广泛应用。总体而言,尽管这些方法和技术可用于封闭内腔几何特征探测,但通常只能粗略地测量封闭内腔的大致位置和形状。采用工业计算机断层成像技术和光学断层扫描技术虽能够对封闭内腔的几何特征进行一定精度的测量,但受制于探测原理的限制、射线散射的影响、光学波长分辨力的影响、成像器件分辨能力的影响、三维图像重建算法等原因^[9~11],精度还远远不能和常规物体外几何尺寸的三维精密测量相比,更无法满足像超导陀螺的精密球形腔这类精密内腔尺度的测量要求。如果期望封闭内腔几何特征的测量精度达到常规物体外几何特征的测量精度,那么,这给测量科学提出了难题和巨大挑战。

精密封闭内腔几何特征的精密探测难点主要在于两个方面:首先是内腔几何特征的无失真传感问题,即用恰当的信息载体,能够穿透腔壁,将封闭内腔的几何特征信息完整或者足够精度地传感到封闭腔体外部。该问题的解决一方面可以改进现有的射线、超声等探测方法,克服存在的射线散射、信息丢失和混叠等问题,以不断提高其传感信息的完整性和减小传感误差。另一方面,也是更为重要的,是探索 and 发现新的传感原理,实现内腔几何特征无失真地向外部传感。第二个难点是对传感出来的信息进行有效接收和三维重建,并达到精密量级。

参 考 文 献

- [1] 汤继强,赵琳,罗俊燕.球形腔内超导陀螺转子的支承特性分析.弹箭与制导学报,2004,24(4):136—151.
- [2] 汤继强,孙枫,赵玉新,等.超导陀螺转子的磁悬浮特性分析.哈尔滨工程大学学报,2005,

- 26(4):432—466.
- [3] 郭彤,傅星,陈津平,等.利用纳米测量机实现大范围的计量型原子力显微镜.计量学报, 2005,26(1):1—4.
- [4] 李保磊,傅健,魏东波,等.工业计算机断层成像系统转台旋转中心的确定.航空动力学报, 2009,24:1544—1548.
- [5] 魏国亮,赵振宇,徐胜航,等.工业常用无损探伤原理及特点分析.机械工程师,2008,3: 152—153.
- [6] 李赳韬,钱志余,王惠南.近红外光断层成像的理论和研究进展.生物医学工程学杂志, 2008,25:208—211.
- [7] 张伟,何荣.光学相干断层成像技术在医学中的应用.中国中西医结合影像学杂志,2008,6: 55—57.
- [8] 贾甲,冯音琦.宽场光学相干断层成像技术的研究进展.激光与光电子学进展,2009, 46(11):80—86.
- [9] Bronnikov A V.Theory of quantitative phase-contrast computed tomography.JOSA A, 2002,19(3):472—480.
- [10] Gureyev T E,Nesterets Y I,Pavlov K M,et al.Computed tomography with linear shift-invariant optical systems.JOSA A,2007,24(8):2230—2241.
- [11] Wang Y,Wang R K.High-resolution computed tomography of refractive index distribution by transillumination low-coherence interferometry.Opt.Lett.,2010,35(1):91—93.

撰稿人：陆振刚

哈尔滨工业大学超精密光电仪器工程研究所

在体活体细胞三维实时探测与表征

Three-dimensional Real-time Detection and Characterization of Live Cells in Vivo

英国物理学家 Hooke 于 1665 年在用他制作的复式显微镜观察一块软木组织时发现了排列整齐的蜂窝状结构,随之将其组成单元命名为“细胞”(cell),从此,人类在认识生命活动和解释生命现象的历史进程中翻开了新的一页。现代医学研究发现,一些重大疾病的产生与细胞的变异紧密相关,如癌症起源于人体内正常细胞的变异,突变细胞需经数代最终形成癌细胞,癌症已成为危害人类健康最大的杀手之一,据世界卫生组织统计,2004 年全球约 740 万人死于癌症,预测在 2030 年死亡人数将达到 1200 万。若能在细胞变异早期发现并施予治疗,则癌症的治愈概率能够大幅提高,因此,现代医学迫切需要对细胞,特别是在体活体细胞的三维实时探测仪器,以期在细胞分子水平研究癌症等重大疾病的发病机理,为医学诊断和防治提供重要科学依据。

在体活体细胞的三维实时探测与表征是指在不改变活体细胞真实生理环境的前提下,在亚细胞及分子层面,实现对细胞表层及其内部细胞器、蛋白质、DNA 等物质进行三维立体实时解析成像与特定组分的表征。开展在体活体细胞三维实时探测与表征的研究目的是在亚微米甚至纳米级分辨率水平下探测细胞表层和胞内物质在真实在体条件下的结构特征、生理机能、生命演变特性等,这对探究医学病理、生命机理等都具有重要的科学价值和现实意义。

长期以来,不论是从事细胞分子学、生命科学,还是从事生物医学、显微仪器研究的科学家,都对活体细胞的三维立体探测和表征问题开展了大量的研究,发明了多种精密复杂的生物显微仪器,用来研究生物分子、细胞、组织等不同尺度生物样品的结构和生命特征,这些研究推动了生物医学、生命科学和细胞分子学等领域的快速发展。在生物成像和探测领域,荧光显微技术是最典型的生物探测手段,而从 20 世纪 80 年代中期开始,当共焦显微镜与生物荧光显微技术完美结合后,荧光共焦显微镜就成了众多生物领域应用最为广泛的仪器之一^[1,2]。

目前,对离体活体细胞的数十纳米高分辨率探测已经实现^[3],图 1 是神经元细胞的荧光共焦和超分辨 STED(受激辐射损耗)显微成像细节比较^[4]。然而,由于细胞具有短暂的生命周期,并且在体细胞与离体细胞的生物检测环境存在根本差异,因此,生物学家更希望对活体细胞在真实生理环境下进行在体活体细胞的生命现象及演变特性的实时立体探测。




图1 神经元细胞的荧光共焦(左)和 STED 超分辨(右)观测细节比较^[4]

在当前生物仪器技术水平下,对在体活体细胞在微米级成像分辨率、特定机体部位数百微米表层深度范围内的三维实时探测,依赖共焦微内窥镜得以初步实现^[5]。传统的医学内窥镜与共焦显微镜的结合,使共焦微内窥镜具有了深度层析能力,利用光纤束制成微型光纤探头进行生物探测的共焦微内窥镜在医学成像、病理诊断等领域得到了成功应用,图2所示是共焦微内窥镜进行在体活体组织观测^[5]。尽管如此,共焦内窥镜仍远不能满足对在体活体细胞三维实时探测与表征的需求,仅就分辨率而言,共焦内窥镜仅有微米级的分辨本领,无法对在体活体细胞在亚细胞甚至分子水平进行有效观测,因为细胞内部各种大分子尺寸一般在数纳米至数十纳米之间,而人体DNA双螺旋分子直径更是小到2nm左右。

共焦显微仪器以其特有的非接触传感机理及深度层析特性为在体组织和活体细胞的三维实时探测与表征提供了初步的解决思路,但要形成真正意义上的在体活体细胞三维实时测量仪器仍存在诸多亟待克服的科学问题:

- (1) 如何在不破坏或不影响生命体征的情况下,提高对机体组织的探测深度(目前的探测深度仍局限在约几百微米的表层)?
- (2) 如何提高在体活体细胞探测的三维分辨率(达到数十纳米或数纳米)?
- (3) 如何避免在探测过程中活体细胞本身受到机体生命活动的干扰?
- (4) 如何使在体活体细胞的成像与探测不依赖于荧光分子标记?

综上,对活体细胞在真实在体生理环境下进行三维实时探测与表征,有助于完整掌握活体细胞的在体生命特征,如遗传物质DNA双螺旋分子的演变,对探索生命奥秘、弄清重大疾病诱发机理和早期防治都有着重大的科学价值与现

实意义！对在体活体细胞的三维实时探测与表征的研究，必将在生物医学、生命科学和细胞分子学等众多领域产生深远的影响。




图2 共焦微内窥镜用于在体活体组织观测^[5]

参 考 文 献

- [1] Stephens D J, Allan V J. Light microscopy techniques for live cell imaging. Science, 2003, 300: 82—86.
- [2] Pawley J B. Handbook of Biological Confocal Microscopy. 3rd ed. Berlin: Springer, 2006: 381—403.
- [3] Pinaud F, Dahan M. Zooming into live cells. Science, 2008, 320: 187—188.
- [4] Hell S W. Super-resolution microscopy: Breaking the limits. Nature Methods, 2009, 6 (1): 15—18.
- [5] Llewellyn M E, Barretto R P J, Delp S L, et al. Minimally invasive high-speed imaging of sarcomere contractile dynamics in mice and humans. Nature, 2008, 454: 784—788.

撰稿人：谭久彬 刘 涛 刘 俭
哈尔滨工业大学超精密光电仪器工程研究所

中微子质量的探测机理与表征

Detection Principle and Expression of the Mass of Neutrino

毛泽东从“一尺之捶，日取其半，万世不竭”的哲学观点出发，认为物质是无限可分的，自然界具有更深的统一。波士顿大学的学者、诺贝尔奖得主 Glashow 把人类逐层研究物质结构的历程形象地比作剥洋葱，并提议将构成基本粒子下一个层次的物质组分命名为“毛粒子”。

20 世纪 50~60 年代，日本学者坂田提出了基本粒子结构的“坂田模型”，中国学者朱洪元等提出了“层子模型”，美国学者 Gell-Mann 对“坂田模型”进行改造，提出了“夸克模型”。其中，以“夸克模型”为基础的基本粒子标准模型(如图 1 所示)得到了迅速发展，并成功地经受住了大量的实验检验^[1]，但该模型对质量起源等基本问题未能给出解释，正在不断地经受人们的质疑、修正与完善。“夸克模型”的一个重要基本假设就是：所有中微子的质量均为零。此外，在宇宙起源、宇宙标准模型的研究过程中，科学家发现宇宙中存在大量的暗物质，暗物质占据宇宙 90% 的质量，但无法直接观测或探测，其基本组成是




图 1 基本粒子尺度与夸克模型

有静止质量的中性粒子,“夸克模型”的 62 种基本粒子中,可能是热暗物质粒子的只有中微子和反中微子,但前提是中微子的静止质量不为零。

因此,中微子质量的探测机理与表征成为研究物质基本组成及相互作用、宇宙起源与标准模型中的一个重要环节与关键依据,该研究如能取得进展,将是一个里程碑式的突破,它一方面说明基本粒子标准模型需要完善,另一方面如果三种类型中微子的静止质量和为几电子伏特,将是宇宙热暗物质的重要候选者。

目前研究发现,自然界中存在的中微子有三种,分别是电子中微子 ν_e 、 μ 中微子 ν_μ 、 τ 中微子 ν_τ 。许多研究表明,不同中微子在飞行中能够互相转换,称为中微子混合或中微子振荡,它是探测中微子质量最灵敏的方法之一。目前,对中微子质量探测机理及其表征的研究主要从中微子振荡着手。

在中微子源方面,自然中微子源主要包括太阳、银河系内及距离银河系较近的超新星爆发产生的中微子。太阳核聚变会释放出中微子,20 世纪 60 年代初,美国的 Davis 建造了一个大型太阳中微子探测器,放在南达科他州的地下矿井中。实验探测到的太阳中微子通量相对理论预言值丢失了三分之二,称为太阳中微子丢失之谜,它是中微子可能存在质量与振荡的重要实验证据。此外,超新星爆发也会产生中微子,1987 年 2 月 24 日,与银河系相邻的大麦哲伦云中的 SN 1987A 超新星产生爆发,被日本神冈等研究机构的科学家在实验中记录到。大麦哲伦云距离银河系 15 光年,依宇宙尺度来看,已近在咫尺了,它基本处于研究人员可捕捉到中微子的极限距离上。核反应堆是较理想的人工中微子源,用反应堆研究中微子振荡关键参数是目前的一个研究热点,国际上曾先后提出 8 个反应堆中微子实验方案,经过激烈的竞争与合并,目前仍积极推进的有中国的大亚湾实验和法国的 Double Chooz 实验。

在中微子质量探测机理方面,由于中微子是宇宙间的“隐身人”,其几乎不与任何物质发生作用,可自由穿过地球,对中微子进行捕捉已十分困难,自 1930 年奥地利物理学家泡利提出中微子假说起,经过了近二十年的时间,人们才第一次捕捉到中微子。目前,研究人员一般利用粒子衰变中的能量与动量守恒定律,通过测量衰变产物的能量与动量来推算难以捕捉到的中微子的质量,但目前各种实验还难以精确确定中微子的质量,只能得到中微子质量的上限值^[2~4]。随着实验技术的发展,实验探测到的中微子质量的上限值在不断下降,但距离人们根据宇宙暗物质估算出来的中微子质量之和还差若干个数量级^[5,6]。经过近几十年的研究,人们已经能够进行中微子的产生与捕捉,中微子存在质量与振荡已基本得到确认;但利用中微子振荡实验只能间接测量不同中微子的质量差,还无法知道中微子的绝对质量。到目前为止,人们还没能构想出能够准确地直接测量中微子静止质量的实验方法。要想获得中微子质量的精确值,

还需要测量与仪器等学科的研究人员几十年甚至上百年的努力。

中微子质量探测与表征的难点在于：①在探测机理方面，由于中微子只参与非常微弱的弱相互作用，具有最强的穿透力，穿越地球直径那么厚的物质，在 100 亿个中微子中只有一个会与物质发生反应，因此，捕获中微子极为困难，要求探测器具有庞大的规模。②在中微子质量的表征方面，中微子静止质量之和估计仅有几电子伏特，由实验测出中微子静止质量的准确数值十分困难，目前只能给出中微子质量的上限，尚不能给出确定的结果，同时质量的起源及其表征目前还是困扰科学家们的未解之谜。③中微子实现需要消除宇宙射线、周围物质辐射等产生的背景干扰，探测器需要装在无辐射的山洞、地下矿井及水下等环境中，对环境、建筑材料要求苛刻，需要大规模的投入与国际协作。

由于中微子质量对于人类研究微观世界与宏观宇宙的重大意义，1988 年、1995 年及 2002 年的诺贝尔物理学奖均授予了与中微子相关的研究。中微子质量的探测机理与表征还需要测量与仪器等学科的研究人员的不懈努力，对该重大基础科学问题的研究仍然是一个需长期努力探索的重要科学难题。

参 考 文 献

- [1] 雨燕.费米实验室粒子物理实验项目及成就.国外科技动态,2005,(3):14—20.
- [2] Ni G. Superluminal paradox and neutrino.陕西师范大学学报(自然科学版),2002,30(4): 1—6.
- [3] 庆承瑞,何祚庥,梁东麒,等.对电子中微子质量为虚数的质疑.高能物理与核物理,1995, 19(1):27—33.
- [4] Particle Data Group. Review of particle physics. European Physics Journal C: Particles and Fields, 2000, 15: 350.
- [5] 何景棠.中微子振荡实验——超出标准模型的实验检验.物理,2001,30(2):74—80.
- [6] 王较过.中微子振荡与中微子的静止质量.物理,2000,29(11):682—685.

撰稿人：崔俊宁

哈尔滨工业大学电气工程及自动化学院

人工运动神经系统重建原理与机制

Artificial Motor Neural System Reorganization Principle and Mechanism

近年来,脊髓损伤发病率呈显著上升趋势。据有关统计,每年仅美国脊髓损伤事故的发生率约每百万人 28~55 例,新增病例达一万之多,全世界每年新增病例则在数十万以上^[1]。我国人口众多,正处经济高速发展、各类交通工伤事故频发时期,据不完全估计,每年新增脊髓损伤病例不在少数。另外,作为地震灾后三大后遗症之首,突发性重大灾难造成的脊髓损伤群体人数也十分瞩目。

由于脊髓主管脑部与人体其他部分(尤其是肢体)的信息传递,其损伤将直接导致创面以下的神经系统障碍,造成对应肢体部分的瘫痪,加之其再生能力相当微弱,临床治疗手段十分有限,因而,此类疾病会给个人及家庭带来极大负担,成为日益沉重的社会问题。可以说,脊髓损伤患者已被公认为“一个亟须关注和照顾的特殊社会群体”^[1]。

鉴于目前对损伤的脊髓尚无有效的组织再生康复方法,神经工程与人工智能领域的科学家们已开始尝试利用脑机接口技术在大脑与功能性电刺激假体重建的周边运动神经间再造一条新的人工物理信道(如图 1 所示),希望将人脑主观运动意识信息直接导出,用以自主地控制肢体运动状态^[2]。日前,奥地利格拉茨工业大学已在一位登山事故所造成的脊髓损伤截瘫患者身上成功重建了部分上肢人工运动神经系统,初步尝试了其可行性^[3]。但是,要形成完备外置的中枢-肢体运动神经系统还是一件极具挑战性的长期工作,尚有许多原理与机制上的科学难题亟待克服和解决。

人工运动神经系统重建过程中,最核心的科学问题包括以下两部分:

(1) 人工运动神经系统的物理信道^①机制问题。人体内的运动神经系统是源于对肢体运动模式的神经控制。自从 Sherrington 开始研究脊髓的反射活动以来,人们对运动系统的基本组织和工作原理的认识不断深入^[4]。现已证实,运动的控制是多等级的。最低级的控制中枢在脊髓,最高级的控制中枢在大脑皮层,中间还有不同等级的中枢参与,这就决定了人工运动神经系统需要针对不

① 物理信道指由基本电磁元件等物理实体构成的神经信息传输通道。




图1 脊髓损伤下肢人工运动神经系统重建示意图

同等级的中枢构建不同的功能假体^①，通过合理可靠的外置物理信道机制，实现这些人体高级控制中枢到低级控制中枢的规划、联系、调整等诸多复杂功能。另外，运动系统的基本成分主要包括运动单位和监视肌肉动态的受纳器^②两部分。肌肉中，两种监视其活动的受纳器分别为肌梭^③和腱梭^④。理想的人工运动神经系统重建必须准确理解两种受纳器的电生理信息感受、编码和传递机制，进而再造出人工受纳器，或整合残存受纳器与中枢神经系统相连。

(2) 体内残存神经系统与体外人工神经系统的竞争融合等功能可塑性问题。中枢程序化运动模式，在一般的动物和人类的活动中，一定会受来自周缘或高级中枢(特别是大脑皮层)的信号节制。同时，也可能有皮层下达的命令来决定其他的运动反应。因此，体外人工神经系统的存在一般不应影响到体内残余神经系统的正常中枢程序化控制的运动功能，但仍需保证有同样的信号节制作用。受周缘反馈传入控制的运动可分为两类，即闭路控制和开路控制。所谓程序的闭路控制系统，都不是孤立和绝对的。周缘的反馈信号和来自高级中枢的信号

① 功能假体指可帮助恢复神经功能的电子元件或装置。

② 受纳器指人体内专门感受肌体内、外环境变化的特殊组织结构或装置。

③ 肌梭指当肌肉受到牵伸，利用变形激活感觉神经元，将冲动传至脊髓并激活运动神经元，引起肌肉收缩的受纳器。

④ 腱梭又称高尔基腱器(Golgi tendon organ)，指可感受肌张力，并通过神经传来控制和调节肌肉群运动的受纳器。

都能节制和调整这些系统的工作。此外,实验证明,某些动作的开路反射模式在成年人中还可以通过特殊的训练向反方向改造,这也意味着,体外人工神经系统与体内残存神经系统之间将会存在通过外部反馈信号来竞争、融合、改造等这一类的功能可塑性问题,功能可塑性问题决定了人工神经系统的进化程度。

通过人脑与自体其他部分的外在联系实现人工运动神经系统的重建一直都是人类千百年以来的梦想。解释人工运动神经系统重建原理与机制问题的难点在于以下几方面:

(1) 生物神经系统的复杂性。生物体内的神经系统是人类迄今发现的最复杂系统之一,系统各单元之间的联系广泛而紧密,构成一个庞大网络,具有多层次、多功能的结构。虽然现在人们对生物神经系统已经有了很多了解,但其复杂性使得没有任何一种单独的方法可以用来研究人工运动神经系统重建功能组织和实现的所有方面。

(2) 生物神经系统的代偿性。生物体内的神经系统是一个有机整体,部分神经被损伤或破坏后有可能由邻近区域或类似功能的神经代行其机能,某些低位水平结构的神经甚至具有专门的后备功能和潜在能力,可代行高位水平的损伤神经机能,这些活体的代偿功能在人工运动神经系统重建时较难融入。

(3) 生物神经系统的进化性。生物体内的神经系统是动态的,它不断处于发展变化之中,在发展过程中能够不断地学习并对其层次结构与功能结构进行重组及完善。生物体内的神经系统又是开放的,与人体环境有密切的联系,能与人体环境相互作用,并能不断向更好的适应人体环境的方向发展变化,这些都会给人工运动神经系统重建带来新的难题。

(1) 人工运动神经系统如何向兼具感觉、运动等完备功能的人工神经系统扩展。

(2) 如何通过新材料技术、新机电技术、新信息技术等的交叉融入,设计功能更为强大的神经假体终端。

(3) 如何通过人工运动神经系统的控制,不仅建立起大脑与自体的外在联系,而且实现外物与自体的有效融合,真正达到“机械也是人体一部分”的理想目标。

参 考 文 献

- [1] Pfurtscheller G, Müller G R, Pfurtscheller J, et al. 'Thought'-control of functional electrical stimulation to restore hand grasp in a patient with tetraplegia. *Neurosci. Lett.*, 2003, 351(1):33—36.
- [2] Giszter S F. Spinal cord injury: Present and future therapeutic devices and prostheses.

Neurotherapeutics, 2008, 5(1):147—162.

- [3] Sakas D E, Panourias I G, Simpson B A, et al. An introduction to operative neuromodulation and functional neuroprosthetics, the new frontiers of clinical neuroscience and biotechnology. Acta Neurochir. Suppl., 2007, 97(1):3—10.
- [4] Paul C, Bellotti M, Jezernik S, et al. Development of a human neuro-musculo-skeletal model for investigation of spinal cord injury. Biol. Cybern., 2005, 93(3):153—170.

撰稿人：明 东

天津大学精密仪器与光电子工程学院

能否实现人体血糖浓度的无创伤检测？

Can it Succeed in the Non-invasive Sensing of Human Blood Glucose Concentration?

糖尿病是一种由于体内胰岛素相对不足或胰岛素抵抗而导致的糖、蛋白质、脂肪代谢紊乱的慢性疾病。截止 2009 年，全球的患者达到了 2.85 亿，且发病率正逐年提高，糖尿病及其并发症已成为严重的公共卫生问题^[1]，但至今还没有彻底根治的医学手段，世界卫生组织推荐患者对血糖浓度进行自我监测，及时调整用药。

目前，普通患者通常采用一种小型的快速血糖仪，并利用采血针从指尖取少量的血，再由血糖仪上的一次性试纸条吸入血样后短时间内显示结果。快速血糖仪虽然携带方便、操作简便，但它获得的每一个结果都需要针刺采血，是一种有创的方法，给患者带来了生理疼痛和心理恐惧，而且频繁测量就意味着频繁针刺取血，患者很难坚持，也就难以实现医生希望的对血糖的精确掌握。因此，找到一种无创伤的血糖浓度测量方法，对于减轻患者痛苦、改善用药方式有非常重要的现实意义，同时也是糖尿病患者期待已久的一个梦想。




图 1 光学无创血糖浓度检测示意图

早在 20 世纪 70 年代，德国的 Kaiser 就开始尝试用光学方法进行人体成分检测，标志着人体成分测量开始从生化试剂法向纯光学无试剂方法迈进，其中，人体血氧饱和度的无创检测已成功实现。到目前为止，无创血糖检测技术已经尝试了多种方法，包括阻抗法、微波法、代谢热、光学方法等^[2]。

图 1 所示为光学无创血糖浓度检测方法的示意图。光经皮肤表面进入人体组织，传播一定路径后再经皮肤表面出射时就携带了组织内部的信息。我们可以选择接收漫反射光或漫透射光，可用来检测糖浓度的光信息包括相位、强度、频率、偏振角等，相关的技术手段包括近红外光谱法、旋光法、光声光谱法、光学相干成像法等。

一般来说，直接测量是指被测量同标准仪器或器件直接比较得出测量值，但血糖包含在人体血液中，不能与任何标准器件进行比较，因此，从测量学的

角度来讲,任何一种无创检测方法都属于间接测量,都是经过皮肤获得血糖的信息,进而实现血糖的测量。我们一般假定血液或组织中的葡萄糖浓度改变会引起某一个变量变化,再通过一定的手段检测该变化的变量 S_m ,从而反推葡萄糖的浓度 C_{glu} 。从数学的角度可表达为

$$C_{glu} = f(S_m) + \text{factor}^* \quad (1)$$

式中, S_m 表示用于检测的物理信号,它是血液中所有成分、体温、测量条件等的函数; factor^* 表示其他影响因素。

因此,间接测量的前提是血糖浓度与测量信号之间存在一定函数关系。例如,阻抗法就是基于葡萄糖浓度与其吸收的特定频率的电磁波的特征值相关^[3];旋光法通过测定入射偏振光经过人眼前房后的偏振角来对血糖浓度进行定量^[4];而近红外光谱法主要是基于光经过人体组织后,漫反射或漫透射光强的变化与葡萄糖浓度相关,Maruo 等利用 1100~1800nm 的近红外光入射到人体前臂后的漫反射光的信息反推血糖浓度^[5]。

以上的这些无创检测方法,从理论上来说,都是可行的,但 5mg/dL 的检测精度却至今未能实现,原因是多方面的,包括体内葡萄糖含量低、水的强干扰、人体组织的复杂性等,但是,每一种测量方法都只关注了一种关系,公式(1)的条件实际可能不满足。例如,阻抗法中,体液中的其他非离子可溶物也吸收电磁波;而近红外光谱法中,血液里的其他成分同样存在吸收。Khalil 在 1999 年和 2004 年分别对无创血糖检测的研究现状和遇到的问题进行了综述^[6,7],天津大学的研究小组在 2007 年也探讨了无创血糖检测现状和可能的突破机遇。但人体是一个复杂的生物体,且变化因素众多,是否存在稳定的间接测量公式或卓有成效的方法消除 factor^* 对测量精度的影响,这方面的工作暂时还没有人开展。因此,公式(1)的条件不满足应该是人体血糖浓度的无创检测不成功的真正原因。

如果间接测量的前提成立且其他因素的影响能通过数学的方法消除,则血糖浓度的无创伤检测就是可以实现的,我们就需要在提高硬件检测精度的同时,更多地探讨如何从方法论的角度实现对微弱血糖信息的获取。此外,我们还可以从其他角度探讨提高检测精度,如从生化的角度,当血糖浓度变化时,人体是否存在更容易检测的化学成分?从工程的角度,是否可以通过测量更多的物理参数来降低血糖浓度检测的难度(包括精确测量体温进行修正)等?因此,人体血糖浓度能否实现真正的无创伤检测,我们还需要进一步的突破。

参 考 文 献

- [1] Halban P A, Ferrannini E, Nerup J. Diabetes research investment in the European Union. *Nature Medicine*, 2006, 12: 70-72.

- [2] Bai C, Graham T L, Arnold M A. Assessing and advancing technology for the noninvasive measurement of clinical glucose. *Analytical Letters*, 2008, 41: 2773—2793.
- [3] Wang J, Carmon K S, Luck L A, et al. Electrochemical impedance biosensor for glucose detection utilizing a periplasmic E. coli receptor protein. *Electrochemical and Solid-State Letters*, 2005, 8: 61—64.
- [4] Rawer R, Stork W, Kreiner C F. Non-invasive polarimetric measurement of glucose concentration in the anterior chamber of the eye. *Graefe's Archive for Clinical and Experimental Ophthalmology*, 2004, 242(12): 1017—1023.
- [5] Maruo K, Oota T, Tsurugi M, et al. New methodology to obtain a calibration model for noninvasive near-infrared blood glucose monitoring. *Applied Spectroscopy*, 2006, 60: 441—449.
- [6] Khalil O S. Spectroscopic and clinical aspects of noninvasive glucose measurements. *Clinical Chemistry*, 1999, 45(2): 165—177.
- [7] Khalil O S. Non-invasive glucose measurement technologies: An update from 1999 to the dawn of the new millennium. *Diabetes Technology & Therapeutics*, 2004, 6(5): 660—697.

撰稿人：刘 蓉 徐可欣

天津大学精密仪器与光电子工程学院

是否能依据食品的综合光学特征进行成分掺杂的快速识别?

Can We Rapidly Identify the Food Adulteration Based on the General Optical Characteristics?

食品安全关系国计民生,社会效益和经济效益不言而喻。深入分析食品安全事件^[1]可以发现两个层面的问题:一是掺杂已知特定物,如饲料中掺杂瘦肉精等,一旦引起人们的注意,可以实施强迫性地检测,监控特定物含量超标与否;另一种是混入的特定物未知或尚未引起人们的注意,也就难以对其实施定性检测,更谈不上对含量进行监控,往往只有在已经造成了较大面积的损害之后,才能引起了较大的社会关注,如为冒充高品质牛奶而向奶中掺入高氮含量物质(不一定非是三聚氰胺)等。所以,迫切需要一种能判断食品中是否含有标签成分以外的未知掺杂物的方法,该方法也是“十一五”发展纲要中需要重点攻关的“在线快速真伪检测技术”^[2]的核心。如果判定有异物存在,下一步则可以让产品的生产厂家说清原因。所以,这种方法的定位和意义是针对不同食品进行快速筛选,需要的关键技术是要实现快速判断和对于不同种类食品的广泛适用性。相对于其他方法,基于光学特征的检测方法属于非接触测量,具有不污染样品、测量结果重复性好等优点,是食品安全领域研究热点^[3]。

任何物质都有自己独有的光学特征(如指纹光谱),被检测的食品中应该含有的主要成分是固定的,它们的光学性质(如吸收光谱位置及叠加的情况)是已知的,而混入的其他成分的光学特征一定与应有光学特征或者其叠加的光学特征不同。对于成分简单的食品,如白酒,应该只含有乙醇、水。如图1所示,正常白酒样品的吸收光谱在 $4000\sim 5000\text{cm}^{-1}$ 波段范围内只应该在 4253cm^{-1} 、 4339cm^{-1} 、 4408cm^{-1} 处具有明显的乙醇吸收峰,除此之外,还出现其他明显的谱峰就说明一定有未知异物掺杂。

因此,我们可以根据食品的标签信息,构建出被测物应有的光学特性,理论上只要确实掺杂了化学药品并达到一定量,化学药品的特征信息就有可能在已知物质的背景信息中突显出来。于是,就有可能通过适当的数学、化学计量学、统计学等处理,将这种特征信息表征出来,达到掺杂判别的目的^[4]。对于复杂食品,由于成分众多,光学特性各异,仅凭吸收光谱信息并不足以实现掺杂判别,往往还需组织光学参数、折射率、偏振角等表征表面特性的综合光学

特征才能反映样品中包含的化学键、基团大小及分子量等信息^[5]，从而本质上判定样品中是否存在未知非标签成分掺杂(如图2所示)。




图1 基于透射光谱的白酒掺杂快速识别思路




图2 针对未知异物掺杂的光学综合检测方案

虽然该方法有明确的物理基础,然而,由于食品成分的多样性和光谱数据的复杂性,针对未知异物掺杂的检测相当困难,即使是白酒、牛奶等这类相对简单的样品,也未见有“判断未知异物掺杂”的成熟解决方案及相关研究报道,就目前而言,主要还处于探索阶段,研究内容集中在以下两个方面:

(1) 是否可测? 由于现实生活中食品都属于混合物,虽然每种标签成分自身的光学性质具有特征性,但随着浓度波动、种类增多、温度及压力等条件的变化,如何模拟计算食品样本应有的综合光学特性? 该特性是否仍然能具有“指纹特征”? 外界干扰与物质成分的本质区别导致的光学特征波动是否可区分?

可区分条件下的定量关系如何?应从理论上研究基于综合光学特征进行掺杂识别的可行性及方法论。

(2) 如何因“物”制宜,从方法论角度研究基于目标被测物光学特性的掺杂识别方案?被测物种类繁多,光学特征差别千变万化,对于白酒等简单样品可能仅用透射光谱即可实现甲醇含量超标判定,而牛奶等散射样品则至少要考虑其散射特征才能实现定性判断。因此,如何根据被测物的光学特性(包括各种标签成分光谱、组织光学参数、折射率信息和表征表面特性的光学参数等)设计最佳的光学参数特征集?通过实验或模拟计算能否得到光学特征参比基准值?如何定量描述异物掺杂判别精度与光学特征向量的内在关系,从而建立异物掺杂判别方法论?总之,如何因“物”制宜,为不同光学特性的食品设计特定的掺杂判定方案提供方法论指导,是工程应用的前提。

上述问题难度大,内容广,涉及的学科领域繁杂,它们的解决既会对物理、光谱、计算数学等学科的发展起到重大的推动作用,又对廉价、快速、原位检测新型仪器设计开发产生深远影响,社会效益、经济效益巨大。

参 考 文 献

- [1] 第十一届全国人民代表大会常务委员会.中华人民共和国食品安全法.2009-02-28.
- [2] 国家发展改革委,科技部,农业部.全国食品工业“十一五”发展纲要.2006-10-19.
- [3] 陆峰,吴玉田,柴逸峰.食品(药品)安全时代的分子光谱法.生命科学仪器,2007,5(11): 6—10.
- [4] 林涛,于海燕,应义斌.可见/近红外光谱技术在液态食品检测中的应用研究.光谱学与光谱分析,2008,28(2):285—290.
- [5] 张燕,马文宏,阎磊,等.原子吸收光谱法在婴幼儿食品检测中的应用.食品研究与开发,2007,28(6):187—189.

撰稿人: 余 辉 徐可欣
天津大学精密仪器与光电子工程学院

经络穴位精密测量

Precision Measurement of Meridians and Acupoints

经络穴位到底是什么? 尽管作为一种生命现象客观存在, 并临床应用了几千年, 但至今仍是像金字塔一样的世界未解之谜。经络穴位精密测量运用现代精密测量理论与技术, 重点研究经络穴位的精细形貌及时空特性, 借助现代测量技术手段“看到”经络穴位, 为经络穴位科学研究及临床试验提供符合中医思路和西医理论的研究方法、实验手段及测量仪器。

经络穴位精密测量主要研究以下两个方面的关键科学与技术问题: ①经络穴位的精确定位测量; ②经络穴位的精细形貌及时空特性测量。

传统中医学认为经络是运行气血的路线, 分布在人体全身, 而穴位则是经络之节点, 是经络之气输注出入之所, 是疾病的反应点和治疗的刺激点。现代医学研究也发现和证实, 刺激某些穴位确实能产生一定的医学效果^[7]。自 20 世纪 50 年代起, 世界各国都纷纷大力开展经络穴位的研究。目前, 普遍采用电、声、光、核、气等多种理化方法研究经络穴位, 虽然发现某些经络穴位处的电阻、温度、发光、声传导及微量元素含量等与其他非经络穴位处有差异, 但测量结果与皮肤结构、人体组织及测量条件等有密切关系, 且部分研究结果甚至相互矛盾^[8~11]。

基于传统中医学体系的经络穴位研究, 主要通过肉眼观察和手指触摸, 测量经络穴位的形貌信息; 而基于现代西医学体系的经络穴位研究, 则是通过仪器, 测量经络穴位的理化信息, 而对其形貌信息注意不够。经络穴位的形貌是其重要的体表映射形式, 但它是一点还是一区域? 这个区域有多大? 它的精细结构和时空特性如何? 对于这些经络穴位科学研究和临床应用中的关键理论问题, 至今仍然没有得到足够重视和深入研究。

单凭人类自身的感官功能(如视觉及触觉)不能直接感知(测量)经络穴位的电阻、温度、声传导及微量元素含量等理化参数, 但可以感知经络穴位的形貌特征(形貌、位置、变形及振动等), 只是各人的敏感度有所不同。也许正是由于这种自身感知能力的差异, 导致人们对经络穴位认知的奇异性和神秘感。

传统中医理论主要以体表几何形貌为基础, 确定经络穴位的位置。无论经络穴位的生理结构和医学功能如何, 都具有其特定的形貌和时空特性, 它们是变化、相对、相关、有序及可测的。经络穴位的精细形貌及时空特性(形貌、位置、变形及振动等)是中医诊疗的重要信息源。几千年来, 不论是传统中医典

籍,还是现代医学标准,都基于经络穴位的几何特征确定相应穴位,但经络穴位的形貌、位置、变形及振动等精细参数,却只能根据医生个人经验确定,并没有科学的测量方法和检验标准。

应用现代精密测量理论和方法,精确测量经络穴位的形貌、位置、变形及振动等精细形貌及时空特性,并加以科学诠释,是经络穴位本质研究及临床应用的关键,它不但有助于中医基础理论的完善和发展,也许还能揭示经络穴位的古老秘密,并找到发现和应用经络穴位的新途径。

传统穴位定位(取穴)主要依赖医生的临床经验,以非仪器化的人为感官测量为主,缺乏客观量化标准及精密测量手段,定位结果不准确,更难以测量其精细形貌和时空特性。取穴因人、因时、因地而异,导致取穴不具有严格的科学意义,正所谓“得之于手而应于心,口不能言,有数存焉于其间”。临床试验研究表明,不同的人,甚至同一个人,用相同方法,对相同穴位取穴,得到的取穴点都不相同。取穴点分布区域面积达 12cm^2 。甚至不同穴位取穴点区域产生相互重合现象^[11~13],如穴位 PC5、PC6、LU8、HT4 的取穴点区域重合达 30% 以上。此非彼,何以异?在经络穴位研究中,因取穴不准确,导致同一穴位取穴不完全相同,不同穴位取穴交叉重合,此穴非彼穴,因果关系模糊,其相关研究的科学性受到影响和质疑。

准确获得穴位的位置,精确测量经络穴位的形貌、变形及振动等精细形貌和空间特性,一直是经络穴位研究及应用的瓶颈之一,是中医诊疗与临床应用中亟待解决的科学难题,经络穴位精密测量是解决这一问题的关键技术基础。

工欲善其事,必先利其器。基于经络穴位精密测量的创新性研究框架、评价方法和规范化体系,研究经络穴位的精细形貌及空间特征的精密测量方法,为经络穴位的科学研究及临床试验提供测量理论、方法和仪器,是解决中医针灸学信息化、客观化、规范化、标准化、科学化及国际化问题的关键科学途径和技术手段。

若能用精密仪器精确测量经络穴位的几何形状、精确位置、微小震动和动态变形,进而研究经络穴位的时空关联性、系统性、特异性及循经感传性,为随机对照试验提供严格的技术手段和规范,并能绘制出与传统明堂图相符合的“数字明堂图”,甚至能按照中医理论的预测,在特定经络穴位处发现其时空“奇点”,就能为经络穴位的存在及实质研究提供有力的科学证据和研究手段,经络穴位的研究及临床应用将会“利剑在手,如虎添翼”。

参 考 文 献

- [1] Goldman N, et al. Adenosine A1 receptors mediate local anti-nociceptive effects of acupuncture

- ture. *Nature Neuroscience*, 2001, 2562.
- [2] Liu P, et al. Combining spatial and temporal information to explore function-guide action of acupuncture using fMRI. *Journal of Magnetic Resonance Imaging*, 2009, 30(1):41—46.
- [3] Dorsher P T, et al. Trigger points and classical acupuncture points. *German Journal of Acupuncture and Related Techniques*, 2009, 3:15—23.
- [4] Lee H, Ernst E. Acupuncture analgesia during surgery: A systematic review. *Pain*, 2005, 114:511—517.
- [5] Kaptchuk T J. Acupuncture: Theory, efficacy, and practice. *Annals of Internal Medicine*, 2002, 136:374—383.
- [6] Streitberger K, Kleinhenz J. Introducing a placebo needle into acupuncture research. *The Lancet*, 1998, 352:364—365.
- [7] Cho Z H, Chung S C, et al. New findings of the correlation between acupoints and corresponding brain cortices using functional MRI. *Proceedings of the National Academy of Sciences*, 1998, 95:2670—2673.
- [8] Kramer S, et al. Characteristics of electrical skin resistance at acupuncture points in healthy humans. *The Journal of Alternative and Complementary Medicine*, 2009, 15(5):495—500.
- [9] Lee Y, et al. Heterogeneity of skin oxygen density distribution: Relation to location of acupuncture points. *The Journal of Acupuncture Meridian Study*, 2009, 2(4):269—272.
- [10] Colbert A P, et al. A multichannel system for continuous measurements of skin resistance and capacitance at acupuncture points. *The Journal of Acupuncture Meridian Study*, 2009, 2(4):259—268.
- [11] Ahn A C, et al. Electrical properties of acupuncture points and meridians: A systematic review. *Bioelectromagnetics*, 2008, 29:245—256.
- [12] Yin C S, et al. Evaluation of the cun measurement system of acupuncture point location. *The American J. of Chinese Medicine*, 2005, 33(5):729—735.
- [13] Aird M, Coyle M, et al. Study of the comparative accuracy of two methods of locating acupuncture points. *Acupuncture Medicine*, 2000, 18(1):15—21.

撰稿人：欧阳健飞

天津大学精密仪器与光电子工程学院

是否大多数癌症可实现血液的早期诊断?

Can Serosanguineous Examination Early Diagnose almost all Cancers?

恶性肿瘤，即癌症，已经逐渐成为威胁人类生命的头号杀手，几乎每个人闻之色变。目前，癌症的种类具有全身性的特点，更是让人避之唯恐不及。临床上，早期发现、早期诊断与早期治疗是非常关键的。而实际上，人们通常是在身体出现症状时才去就医，医生需要通过各种各样的电子设备及生化方法进行检测，待查到癌症病灶，往往已为时太晚，有的肿瘤可能发生了转移，多数患者已丧失最佳治疗时机。因此，癌症的发生及发展经常是与生命赛跑，如果能越早确诊，对于制定有效治疗方案、提高患者存活率和生活质量均具有重要意义。

血液，仿佛身体的晴雨表，多种疾病均能通过血液检查而确诊，方便快捷，如有否感染、是否怀孕、是否贫血等。那么，可以大胆设想：如果通过血液检查就能在很早期确诊身患某种癌症，那将为人类生命创造更多奇迹。事实上，这方面的工作已经有很多积累，但到目前为止，血液检查仅仅作为癌症诊断一种辅助检查手段，结果可提示某种类型肿瘤可能存在，在特异性及敏感性方面均无法做到癌症早期的精确确诊。例如，自 20 世纪 80 年代至今，肿瘤标志物 (tumor marker, TM) 检测项目不断增加并应用于临床，目前已成为肿瘤患者的一种重要的检查指标。TM 是血液中某种化学物质，不同的 TM，一般由不同类型肿瘤产生。例如，乳腺、肺及胃肠道肿瘤产生一种称作癌胚抗原的蛋白质 (CEA)；而甲胎蛋白 (AFP) 可作为原发性肝细胞癌、生殖腺胚胎性肿瘤等的辅助诊断指标。但是，由于肿瘤发生发展的原因极其复杂，没有一种肿瘤是单一类型的，故至今尚无一种“理想”的 TM，其特异性和敏感性均能达到 100%，从而使 TM 用于癌症早期检查受到限制。同时，因为绝大多数 TM 无器官特异性，TM 不能对肿瘤定位，仅可作为辅助诊断，且需注意排除假阴性和假阳性的可能。有研究表明^[1,2]，多肿瘤标志物液态芯片定量检测技术由于多项指标联合检测，能明显提高少数几种恶性肿瘤 (如肺癌、肝癌、胃癌等) 诊断的敏感性，但该技术本身尚存在很多缺陷，目前检测仅以定性为主，很难做到定量，因此，很难被普遍应用于临床。

当前，越来越多的学者开始关注循环肿瘤细胞 (circulating tumor cells, CTCs) 方面的研究。美国加州大学洛杉矶分校的研究人员研发出的新型纳米柱

硅片^[3]，可如捕蝇纸一样，捕捉血液中的 CTCs，帮助医生快速有效地进行癌症的检测和诊断，进行预后判断，并提高治疗监测的有效性。CTCs 检测的原理是侦测各种肿瘤的上皮细胞异常增生并早期剥落、自溶、凋亡在血液中的癌细胞，当癌细胞经由血液出现微转移的现象时，即可通过抽取外周血来检测出血液中癌细胞是否带有 mRNA 核核酸分子标记的情形，借由这些核酸分子标记可以知道癌症是从何种器官而来，如大肠、直肠、乳房等。大量研究已经证实，CTCs 检测有助于乳腺癌^[4]早期诊断、复发转移监控、判断预后及指导术后辅助治疗等。但是，CTCs 的临床应用也存在诸多问题。目前，多用上皮特异抗原来代替肿瘤细胞特异抗原，如何进一步探索寻找更合适的肿瘤细胞标记需要研究人员付出更多努力。目前，CTCs 研究多集中在 CTCs 数量分析上，有研究者开始关注 CTCs 本身的差别，如 CTCs 表面的蛋白表达或其基因突变与临床的关系。

对于癌基因的研究目前尚存争议，持保留态度的研究者认为癌变是一个多阶段的过程，不能简单看做是一个癌基因激活的结果，尤其是在正常细胞中，癌基因也并不是完全不表达的。相反，乐观人士认为癌基因的分离成功将有助于阐明癌变的机理，进而有望在肿瘤研究中产生重要突破。英国科学家领导的研究小组^[5,6]首次成功绘制出了肺癌和皮肤癌的基因图谱，这一具有“变革意义”的突破有望改变人们对癌症的诊断和治疗方法，如通过验血能得出每位病人的癌症基因图表，进而能找出导致病人患癌的原因并为每位患者量身定制治疗方案，这项研究的成果及预期很是鼓舞人心，希望在未来有限时间内有更大的突破。

最新一项研究报告肺癌早期检测技术出现重大突破^[7]。科学家通过研究几百个英国、美国和加拿大的刚刚确诊肺癌且未经任何治疗的病例，希望找出人体免疫系统对肺癌形成时发出的首个分子信号如何反应。结果发现，肺癌会让细胞产生少量抗原，从而激活免疫系统，产生大量自身抗体，通过追踪这一变化，研究人员希望找出不同抗原与不同癌症间关系，并研究只需 10mL 血液就可以预测癌症的新方法，这种方法将仅通过一个简单的测试就可以准确辨认由抗原引发的自身抗体以及它所代表的癌症，预期可以帮助诊断 90% 以上的实体肿瘤，这一方法的实现将能更早期诊断癌症，并采取及时有效的治疗，提高病患存活率，真正成为人类战胜癌症的福音。

综上所述，通过血液检查实现癌症早期诊断似乎指日可待，解决此问题的前提是必须找到血液中类似 TM 的物质或者某种特异性基因变异，其具有很强的特异性及敏感性，从而针对某种癌症能够进行早期准确诊断。

参 考 文 献

- [1] Sun Z, Fu X, Zhang L, et al. A protein chip system for parallel analysis of multi-tumor markers and its application in cancer detection. *Anticancer Res.*, 2004, 24(2C):1159—1165.
- [2] Chen H, Jiang C M, Yu C, et al. Protein chips and nanomaterials for application in tumor marker immunoassays. *Biosensors and Bioelectronics*, 2009, 24(12):3399—3411.
- [3] Wang S T. Three-dimensional nanostructured substrates toward efficient capture of circulating tumor cells. *Angewandte Chemie International Edition*, 2009, 48:8970—8973.
- [4] Nakamura S, Yagata H, Ohno S, et al. Multi-center study evaluating circulating tumor cells as a surrogate for response to treatment and overall survival in metastatic breast cancer. *Breast Cancer*, 2009.
- [5] Pleasance E D, Stephens P J, O'Meara S, et al. A small-cell lung cancer genome with complex signatures of tobacco exposure. *Nature*, 2009, 463:184—190.
- [6] Pleasance E D, Cheetham R K, et al. A comprehensive catalogue of somatic mutations from a human cancer genome. *Nature*, 2009.
- [7] Peek L, Lam S, Healey G, et al. Use of serum autoantibodies to identify early-stage lung cancer. *J. Clin. Oncol.*, 2010, 28:7.

撰稿人：蒋景英¹ 王 毅²

1 天津大学精密仪器与光电子工程学院

2 天津医院

微深槽三维几何量特征参数的测量方法

Measurement Method for 3D Geometric Parameters of Deep Trench Micro-structures

在微电子和微机电系统(MEMS)制造领域,高深宽比微深槽结构的制作工艺具有非常广泛的应用^[1]。例如,动态随机存取存储器(DRAM)大多数都是基于微深槽电容结构完成存储功能的,随着存储密度的逐渐提高,平面的特征尺寸也随之减少,目前,其宽度已小于60nm,依据电容特性实现存储要求深槽结构的深宽比在50:1左右,这样槽的深度在3 μm 左右。三维集成电路(3D-IC)是微电子的重要发展方向,多层电路结构的电学互连是其实现的必要条件。为了实现多层结构的电学互连,首先要求在互连点制作出微深槽结构,然后将导电材料沉积到深槽形成纵向互连线,该深槽结构的宽度与集成电路的线宽相当,这样,其深宽比随着集成路线宽的减少也在不断提高。MEMS的典型加工技术有体硅加工技术和表面牺牲层技术,高深宽比刻蚀工艺具有非常重要的地位,虽然MEMS器件的特征尺寸一般在微米量级,与微电子器件的特征尺寸相比要高两三个数量级,但对结构的深宽比要求更高,目前已出现了深宽比超过100:1的微深槽结构。MEMS器件包括两大类:MEMS传感器、MEMS执行器。很多MEMS传感器是依据外界物理量改变两个微极板结构的电容来实施传感功能的。高深宽比微深槽制作工艺能够在有限的平面空间内制作出具有较大电容的微极板结构,从而可大大提高传感器的灵敏度。很多MEMS执行器是依据静电力来进行驱动的,微极板面积的增大将能提高微执行器的驱动力。综上所述,随着微加工技术的发展,微深槽的宽度已小于100nm,深宽比一般为10:1~100:1,而且为了实现相应的功能,微深槽横截面的几何形状已经不仅仅是简单的矩形,越来越多的复杂截面形状的微深槽结构被设计和制作出来,材料也越来越多样化,这更加给测量方法的研究工作带来新的难题和挑战。

高深宽比微深槽结构的典型特征是其高度远大于宽度,而且这种微深槽结构经常是以阵列的形式来实现应用的,相互的间隔与其宽度相当。微深槽的三维几何量特征参数包括尺寸、形状、位置和表面粗糙度,对其所构成的器件的性能和可靠性具有直接的影响。

传统的微结构几何量特征参数测量方法主要有扫描电子显微镜、原子力显微镜、接触式探针轮廓仪、光学探针轮廓仪和光学显微干涉轮廓仪等。扫描电子显微镜是利用聚焦电子束在被测对象表面进行扫描时激发的二次电子或背散

射电子来获得,不能得到被测对象纵深方向的信息,属于二维测量,因此,只能得到微深槽结构开口的几何尺寸。原子力显微镜是利用一根微悬臂梁探针在样品表面进行扫描,依据微悬臂梁的偏转情况来获得样品的表面形貌。微悬臂梁针尖的形状一般为金字塔形,针尖顶端的曲率半径一般为 5nm 至数十纳米,高度是 $10\sim 20\mu\text{m}$,锥角为 $20^\circ\sim 30^\circ$,因此,这类微探针无法进入到高深宽比的微深槽内实施几何量参数的测量。目前,有两种新型的微悬臂梁探针:一种是在金字塔形探针的针尖位置再生长出一个高纵横比的探针,纵横比约为 10:1,针尖的曲率半径小于 10nm,高度约为 $4\mu\text{m}$,锥角减少到 2° 左右,依然不能进入到上述提到的高深宽比微深槽内部实施几何量参数的测量;另一种是在金字塔形探针针尖的位置上固定一段碳纳米管,单壁碳纳米管的直径一般为 $1\sim 5\text{nm}$,长度可达到数百纳米甚至数十微米,仅从探针尺寸上来看,这种探针是可以进入到微深槽内实施测量的,但由于如此长的碳纳米管具有很小的弹性系数,因此,也无法用于测量高深宽比的微深槽结构^[2]。另外,即使原子力显微镜的探针能够进入到微深槽内部实施测量,也只能测量槽底表面的几何量参数,无法测量得到侧壁的几何量参数。为了获得微结构侧壁的几何量参数,可以将微悬臂梁探针的针尖弯曲或在微悬臂梁下端再固定一根悬臂梁探针^[3]。以上两种方式都是使针尖指向侧壁,这类改进的微探针是可以对侧壁的几何量参数实施测量,但对于高深宽比的微深槽结构,这类微探针无法进入到其内部实施测量。接触式探针轮廓仪的测量原理与原子力显微镜类似,而且探针的尺寸更大,同样无法进入到微深槽结构中实施测量。光学探针轮廓仪和光学显微干涉轮廓仪测量表面形貌存在一个光在被测样品表面反射的过程,在应用于高深宽比的微深槽时存在两个问题:一是微深槽的宽度较小,光无法进入到其内部并有效反射回来;二是光在微深槽的侧壁可能会被多次反射而造成虚假的光反射信号。最后,除了上述传统的微结构几何量特征参数测量方法外,研究者也提出了一种基于模型的红外光谱法^[4],在该方法中,微深槽结构等效为多层薄膜堆栈结构的理论光学模型,通过对测得的光谱与微深槽结构的理论光谱进行拟合来估计出深度和宽度,该方法一方面要求被测样品对红外光是可透过的,另一方面可测量的几何量参数只限于宽度和深度,而且其准确性难以得到保证。

目前,只能采用解剖法来获得微深槽结构三维几何量特征参数^[5],即将微深槽结构切开,然后用传统的微结构几何量特征参数测量法测量出剖面的几何量参数,这些参数来源于局部的剖面,不能反映出微深槽的三维几何量特征参数,且属于破坏性测量,而如何无损获得高深宽比微深槽结构的三维几何量特征参数是亟待解决的科学难题。

参 考 文 献

- [1] Aimi M F, Rao M P, MacDonald N C, et al. High-aspect-ratio bulk micromachining of titanium. *Nature Materials*, 2004, 3(2): 103—105.
- [2] Caballero D, Villanueva G, Plaza J A, et al. Sharp high-aspect-ratio AFM tips fabricated by a combination of deep reactive ion etching and focused ion beam techniques. *Journal of Nanoscience and Nanotechnology*, 2010, 10(1): 497—501.
- [3] Dai G L, Wolff H, Weimann T, et al. Nanoscale surface measurements at sidewalls of nano- and micro-structures. *Measurement Science and Technology*, 2007, 18(2): 334—341.
- [4] Maznev A A, Mazurenko A, Durán C, et al. Measuring trench structures for microelectronics with model-based infrared reflectometry. *Characterization and Metrology for Nanoelectronics*; 2007 International Conference on Frontiers of Characterization and Metrology, 2007, 931: 74—78.
- [5] Lee C H, Jiang K, Davies G J. Sidewall roughness characterization and comparison between silicon and SU-8 microcomponents. *Materials Characterization*, 2007, 58(7): 603—609.

撰稿人：胡晓东

天津大学精密仪器与光电子工程学院

肿瘤拉曼散射诊断方法学的挑战

The Challenges of Raman Scattering Methodology for the Diagnosis of Cancer

肿瘤的诊断是全社会高度关注的研究领域,已成为生命分析化学新的成长点^[1]。常规肿瘤诊断往往依赖于病理学家对人体活体组织检测的主观诊断,在取样过程中,病人需忍受较大的痛苦。诊断结果依赖于人体组织取样的准确性,从而导致癌症诊断的可靠性低,且多为中晚期,治疗困难。因此,人们开始尝试使用一些新型仪器方法,如质谱、色谱、毛细管电泳、核磁共振、红外吸收光谱等,对人体组织或体液(如血液、尿液、汗液、唾液等)进行检测,试图寻找癌症相关的标志物,以求对一些癌症病人做出客观、准确的早期诊断,并减轻病人的痛苦。目前的仪器诊断方法尚存在一些不足,由于质谱、色谱、毛细管电泳是体外检测方法,费时、费力、费用高且操作复杂、对样品要求苛刻,难以满足实际临床需要。核磁共振虽可以对人体进行活体无损检测,但所检测出的肿瘤多为中晚期,临床治疗较为困难;红外吸收光谱在人体体液环境下受水分的强烈干扰,导致其功能大大受限。因此,发展原位、无损、抗干扰能力强的时空高分辨活体肿瘤早期诊断技术显得尤为必要^[2]。拉曼散射光谱的特点可有效满足这些要求,大量的研究表明,拉曼光谱与不同肿瘤之间存在着显著对应关系,肿瘤拉曼散射诊断方法学研究已成为一个极具挑战性的前沿热门课题^[3]。

肿瘤的发生是机体正常组织和细胞在多因素、多基因作用下经过多途径发生转化,失去原有的生长分化调节而异常增生的结果^[4]。组织和细胞发生癌变总是从构成它们的分子开始,癌变过程中,各种生物分子的构型、构象及各成分的构成比例发生变化。然而,由于早期癌变细胞数量极少,其特征变异往往掩盖在人体复杂多变的其他生理活动中,提取相关的癌变信息犹如大海捞针一般困难^[5]。目前,肿瘤拉曼诊断方法学尚处于机理探索阶段,多方面的因素制约了肿瘤拉曼诊断方法学在临床医学上的进一步运用。由于人体组织癌变机理尚未明确,对癌症的早期与中晚期的界限较为模糊,尚无法对各种癌症的早期特征标记物提供一个准确的定义;由于人体组织的新陈代谢及不均匀性,其拉曼散射光谱具有明显的时变性和空间不确定性;由于人体个体的差异,不同个体的同一组织的拉曼光谱也存在着显著差异;由于采样规模的限制,所收集的人体样本代表性还存在不足;由于拉曼光谱每次采样

区域有限,导致拉曼成像速度慢。此外,拉曼散射光谱还存在强度低、谱带复杂、荧光背景干扰严重等问题。因此,如何从复杂、多变的人体环境中快速提取与肿瘤相关的拉曼信息,识别相关的小分子肿瘤标志物,并构建预测模型应用于其他个体的肿瘤早期诊断,是肿瘤拉曼散射诊断方法学研究的核心内容,也是生物组织光谱学领域研究的重点、难点和热点。

尽管肿瘤拉曼散射诊断方法学的概念已经提出十多年,但尚未有成熟的临床运用,相关的科学研究正在兴起,且大部分集中在概念阶段,至今尚未有确切的理论模型。如何建立满足临床医学运用的肿瘤拉曼光谱模型是肿瘤拉曼散射诊断方法学的关键所在。这主要需要解决以下几个问题:首先是明确癌症产生机理,从而确定若干种早期癌症的小分子标志物,并了解其拉曼光谱特征;其次是提高现有拉曼光谱仪的综合性能,结合各种最新技术,如纳米技术、光纤传感技术、光电一体化技术及分析技术等,使检测设备能敏锐且快速地捕捉小分子肿瘤标志物的弱信号,这其中应重点发展具有表面增强拉曼活性的人体无损检测技术;再次是如何结合信息学处理技术,去伪存真,从复杂、多变的人体组织拉曼图像中准确提取小分子肿瘤标志物的弱信号,实现拉曼诊断方法学与生物医学的基础关联;最后,确保所采集人体样本的代表性,结合最新智能建模技术,以保证光谱模型的稳健性,使其能准确预测未知样本。上述问题难度大、内容多、涉及的学科众多,它们的解决不仅有利于人类早日克服癌症这一顽疾,更能推动仪器工程技术的长足发展。

肿瘤拉曼散射诊断方法学是一个充满挑战的理论和应用研究课题,无论从科学意义、社会意义、应用价值,还是待解决的迫切性方面都是极其突出的。拉曼散射诊断仪及其附属设备研发成为各国竞相发展的前沿课题,相关研究方兴未艾。肿瘤拉曼散射诊断方法学的深入研究必将深化人类对重大疾病早期诊断的更深刻认识,同时也极大地推动仪器科学的发展。

参 考 文 献

- [1] Tran C, Ouk S, Clegg N J, et al. Development of a second-generation antiandrogen for treatment of advanced prostate cancer. *Science*, 2009, 324(5928): 787—790.
- [2] Haka A S, Volynskaya Z, Gardecki J A, et al. In vivo margin assessment during partial mastectomy breast surgery using Raman spectroscopy. *Cancer Res.*, 2006, 66(6): 3317—3322.
- [3] Keren S, Zavaleta C, Cheng Z, et al. Noninvasive molecular imaging of small living subjects using Raman spectroscopy. *Proc. Nat. Acad. Sci.*, 2008, 105(15): 5844—5849.
- [4] Klein C A, Stoecklein N H. Lessons from an aggressive cancer: Evolutionary dynamics in

esophageal carcinoma .Cancer Res .,2009,69(13);5285—5288 .

- [5] Rosen J M ,Jordan C T .The increasing complexity of the cancer stem cell paradigm .Science , 2009,324(5935);1670—1673 .

撰稿人：陈 达

天津大学精密仪器与光电子工程学院

单次曝光任意光波波形测量

Single-shot Arbitrary Optical Waveform Measurement

对基础科学和实际应用来说,全方位地标定光的电场(即测量其振幅和相位)是非常重要的。

对于超短脉冲的测量,可以采用频率分辨光学门技术和光谱相位干涉术(SPIDER)来直接重构超短脉冲的电场^[1,2]。频率分辨光学门技术属于一系列超短脉冲标定技术之一,这些标定技术都含有一个光学取样门,如二次倍频自相关光学取样门和偏振光学取样门,并且通过对光谱的测量来重新构造出光脉冲的电场结构。测量得到的光谱可以用下式表示:

$$I_{\text{FROG}}(\omega, \tau) = \left| \int_{-\infty}^{\infty} E_{\text{sig}}(t, \tau) e^{i\omega t} dt \right|^2$$

信号函数 $E_{\text{sig}}(t, \tau)$ 形式与取样门方法有关。表 1 汇总了常用的取样门方法。

表 1

光学取样门方法	方法简介	信号函数形式 $E_{\text{sig}}(t, \tau)$
偏振光学取样门	在一块非线性光学介质中,用一个高强度的取样门光脉冲操纵并旋转另一个探测脉冲的偏振方向,在不同的延迟时刻测量光脉冲的透射光谱	$E_{\text{sig}}(t, \tau) = E(t) E(t - \tau) ^2$
二次倍频自相关光学取样门	在非线性光学介质中,被延迟的脉冲串与原有的脉冲串相互作用产生倍频光,在不同的延迟时刻测量倍频光光谱	$E_{\text{sig}}(t, \tau) = E(t) \cdot E(t - \tau)$
自衍射光学取样门	两路延时的脉冲串以一个角度在一块薄的非线性光学介质中相互作用,形成透射光栅,使得探测脉冲产生衍射,在不同的延迟时刻离轴测量探测脉冲光谱	$E_{\text{sig}}(t, \tau) = E^2(t) \cdot E^*(t - \tau)$

这样测量得到的光谱包含频率和时间坐标轴上光脉冲强度信息,采用迭代算法可以重新恢复这个光脉冲的全部电场^[2]。

可以直接重构电场的频率相位干涉术是对脉冲串的两个不同形式之间的干涉进行测量,即测量被频移的脉冲串与被延时的脉冲串之间的干涉。两组脉冲串叠加的总电场表示为

$$E_{\text{tot}}(t) = \Re a(t)e^{-i\omega_c t} + a(t-\tau)e^{-i(\omega_c+\Omega)(t-\tau)}$$

该电场的功率谱为

$$|A(\omega)|^2 = |A(\omega)|^2 + |A(\omega-\Omega)|^2 + |A(\omega)||A(\omega-\Omega)| \\ \times \cos[(\omega+\omega)\tau + \phi(\omega) - \phi(\omega-\Omega)]$$

从上式可以看出,一对脉冲的功率谱呈现为正弦条纹。可以通过快速逆傅里叶变换得到功率谱的相位并滤掉功率谱中在 $t=0$ 和 $t=\tau$ 时产生的项,则信号的傅里叶变换的相位就等于 $(\omega+\omega)\tau + \phi(\omega) - \phi(\omega-\Omega)$,其中,线性项可以用数值方法去除。

这两种方法大都应用于低占空比脉冲,因为它们的光谱变化缓慢,有相对较低的时间带宽积。但在自然界中,科学实验中和实际系统中存在更复杂的波形。例如,通过频梳中的脉冲串整形得到的波形可以有 100% 占空比,即整形后的波形覆盖频梳在时间域中的整个重复周期。

一些基于互相关频域分辨光学取样门技术对任意光脉冲波形进行标定时,需要完成一系列连续测量,限制了测量速度^[3],而其他的方法,如双象限光谱干涉术需要非线性光学和/或阵列光探测器^[4]。在互相关频域分辨光学取样门技术(XFROG),测量过程中,用一个基准脉冲取样探测脉冲,通过和频或差频过程产生光谱信号,并进行测量分析,这个方法适用于分析弱脉冲信号或频域中的脉冲,特别是在没有光谱仪或高灵敏度探测器的时候可以使用这种方法。对于差频过程,由基准脉冲取样的信号可以表示为

$$E_{\text{sig}}(t, \tau) \propto E_{\text{test}}(t)E_{\text{ref}}^*(t-\tau)$$

该信号的中心频率为 $\omega_{\text{sig}} = \omega_{\text{test}} - \omega_{\text{ref}}$ 。

双象限于光谱干涉术是一种线性技术,它是对被延时的电场之间的干涉进行测量。在经典光谱干涉术中,只有一个象限的相位可以被恢复重现,而在双象限于光谱干涉术中,用一个 1/4 波片在两个不同的偏振光之间产生一个 90° 的延迟,可以测量两个象限的干涉图。

两个被测的干涉图表示为

$$|E_{\text{ref}}(\omega) + E_{\text{sig}}(\omega)|^2 = |E_{\text{ref}}(\omega)|^2 + |E_{\text{sig}}(\omega)|^2 + 2\Re\{E_{\text{ref}}(\omega)E_{\text{sig}}^*(\omega)\}$$

和

$$|E_{\text{ref}}(\omega) - E_{\text{sig}}(\omega)|^2 = |E_{\text{ref}}(\omega)|^2 + |E_{\text{sig}}(\omega)|^2 + 2\Re\{E_{\text{ref}}(\omega)E_{\text{sig}}^*(\omega)\}$$

若已知 $E_{\text{ref}}(\omega)$,并独立测量 $|E_{\text{ref}}(\omega)|^2$ 和 $|E_{\text{sig}}(\omega)|^2$,则这个 $E_{\text{sig}}(\omega)$ 的复杂形式就可以求解出来。

最近,一个采用已知基准频梳的电场互相关(EFXC)技术已经被证实可以用来测量另一个未知的来自第二个光梳的信号场^[5]。电场互相关技术与光谱相干术一样,是一种线性技术并且需要一个已知的基准脉冲或波形。如果一个超短脉冲被用来作为基准,那么,它就可以被看成是一个激励函数,该信号的振荡

部分的包络是时间延迟的函数,可以精确地给出信号场的振幅。一般地,两个场的相关函数就是包络函数,即

$$\langle P_{\text{out}} \rangle(\tau) = \frac{1}{2} \langle P_{\text{ref}} \rangle + \frac{1}{2} \langle P_{\text{sig}} \rangle + \frac{1}{2} [e^{i\omega_c \tau} \langle a_{\text{sig}}(t) a_{\text{ref}}^*(t - \tau) \rangle + c.c.]$$

当基准脉冲是 δ 函数时,上述表达式可以简化为

$$\langle P_{\text{out}} \rangle(\tau) = \frac{1}{2} \langle P_{\text{ref}} \rangle + \frac{1}{2} \langle P_{\text{sig}} \rangle + \mathcal{R} \{ a_{\text{sig}}(\tau) e^{i\omega_c \tau} \}$$

这个方法类似于最近新出现的相干多波外差光谱实验,在这个实验中,用一对稳定的光梳来快速测量气体样本的吸收谱和相位谱^[6],这个方法采用的也是线性光学取样^[7]。

当然,来自自然界的大部分任意波形,经过高非线性介质的高功率光场和 Tbps 比特的光通信信号是不能由频梳脉冲整形技术得到的。目前,单次曝光任意波形测量技术和设备还不存在,正在期待新的发明和革新手段。

参 考 文 献

- [1] Trebino R, Kane D J. Using phase retrieval to measure the intensity and phase of ultrashort pulses: Frequency-resolved optical gating. J. Opt. Soc. Am. A, 1993, 10: 1101—1111.
- [2] Iaconis C, Walmsley I A. Spectral phase interferometry for direct electric-field reconstruction of ultrashort optical pulses. Opt. Lett., 1998, 23: 792—794.
- [3] Scott R P, Fontaine N K, Cao J, et al. High-fidelity line-by-line optical waveform generation and complete characterization using FROG. Optics Express, 2007, 15: 9977—9988.
- [4] Supradeepa V R, Leaird D E, Weiner A M. Optical arbitrary waveform characterization via dual-quadrature spectral interferometry. Optics Express, 2009, 17: 25—33.
- [5] Ferdous F, Leaird D E, Huang C B, et al. Dual-comb electric-field cross-correlation technique for optical arbitrary waveform characterization. Opt. Lett., 2009, 34: 3875—3877.
- [6] Coddington I, Swann W C, Newbury N R. Coherent multiheterodyne spectroscopy using stabilized optical frequency combs. Phys. Rev. Lett., 2008, 100: 013902.
- [7] Kim I, Kim C, Li G F. Requirements for the sampling source in coherent linear sampling. Optics Express, 2004, 12: 2723—2730.

撰稿人: 李桂芳

美国中佛罗里达大学光学与光子学学院

电磁波探测地球深度的确定

Determination of Electromagnetic Investigation Depth into the Earth

我们人类脚下的地球内部构造到底是怎样的？人类通过怎样的方式能认知地球深部呢？人们常说，上天容易，入地难。目前，世界最深的钻井是 12km，而地球的半径是 6371km，因此，钻探这种直接方式无法有效地进行地球深部探测。由于地球内部构造存在电性、介电性、磁性差异，因而可以利用电磁波探查地球，从而确定地球深部结构，不仅能够进行深部资源探查，而且能通过对地球深部地质结构、断裂带活动规律、新构造运动规律、热液流动状况等的认知，为地震、海啸、火山喷发等灾害性地质活动预警提供重要的技术支撑。那么，电磁波到底能探测地球多深呢？能穿透地球吗？

电磁波探测地球深度受电磁探测系统发射电流强度、功率及发射频率、脉宽、接收机的数据采集分辨率、环境噪声、地质噪声、仪器电子噪声、数据处理方法等诸多因素的影响，本问题主要涉及如何确定地球探测深度，而不是如何提高探测深度的问题。

电磁波探测地球是指通过发射机向大地发射电流或发射磁场，通过分析接收点前端传感器接收到的磁场或电场，确定地下介质的电、磁等分布特性。通常，可以从测量方法上分为时间域与频率域电磁探测，从发射源上又可分为磁性源与电性源，以及主动源(人工源)与被动源(天然源)。时间域电磁探测[如图 1(a)所示]通常以间歇式双极性方波、梯形波、半正弦波的发射电流通过发射线圈向地下发射磁场(磁性源)或通过发射电极向地下发射电场(电性源)，地下异常体内部激发感应电流，该感应电流在接收线圈处产生二次场，在发射电流间歇期间测量地下异常体产生的二次场，通过分析衰减的二次场得出地下的电性信息。根据发射和接收装置，时间域电磁探测还可分为中心回线方式、重叠回线方式、偶极-偶极方式等。频率域电磁探测[如图 1(b)所示]发射电流为单频或多频的正弦波，在接收处测量该频率分量的幅度与相位(或实分量与虚分量)，从而获得二次场信息。大地电磁法、音频大地电磁法及可控源音频大地电磁探测涉及的频段较低，探测深度较深，其中，前两者是被动源探测，场源为天然电磁场。

在频率域电磁探测中，定义了当电磁波振幅衰减为 $1/e$ 的传播距离为趋肤深度 $\delta = \left(\frac{2}{\omega \mu \sigma} \right)^{\frac{1}{2}} = 503 \left(\frac{1}{f \sigma} \right)^{\frac{1}{2}}$ ，其中， f 、 ω 分别为电磁波的频率、角频率， μ 、 σ




图 1 电磁法勘探原理示意图

Tx .发射线圈；Rx .接收线圈；实线 .一次场；虚线 .二次场

分别为大地的磁导率、电导率。可见，在同一大地参数条件下，电磁波的频率越低，探测深度越大。时间域电磁探测，定义了场强达到最大值的深度为穿透深度 $Z = \left(\frac{2t}{\mu\sigma} \right)^{\frac{1}{2}}$ ，其中， t 为断电后的采样时间。因此，有效数据的采样时间越晚，探测深度越大。那么，用频率域的趋肤深度和时间域的穿透深度来确定电磁波探测地球的深度是否准确呢？回答是否定的。

采用电磁波探测地球，由于趋肤效应的存在，必然存在一个探测深度的极限，但由频率域的趋肤深度和时间域的穿透深度来确定电磁波探测地球深度是不准确的，因其采用均匀半空间模型及视电导率近似计算。

Spies^[1]详细讨论了层状介质模型探测深度的计算，并得出最大有效探测深度为趋肤深度的 1.5 倍，该方法后来成为计算一维模型下最大有效探测深度的标准方法。Huang^[2]在 Spies 方法的基础上进行了一定程度的改进，但其应用对象依然是层状介质，等效电导率的概念决定了该方法无法推广到二维、三维模型；王卫平^[3]、朱凯光等^[4]分别讨论了时间域、频率域电磁探测装置参数，如回线边长、偶极距等与探测深度的关系；Yan 等^[5]采用有限差分算法，基于二维大地模型研究了小发射线圈的探测深度问题，但实际大地模型应该是三维的，并存在各向异性等问题。因此，如何准确确定电磁波探测地球的深度成为一个亟待解决的科学难题。

从电磁波的传播与反射理论，要探测地下一定深度的异常体，“场”需要时间 t_1 到达该异常体然后反射或扩散经时间 t_2 回到地面，也就是需要 $t_1 + t_2$ 的时间将地下异常体产生的二次场传播与反射到接收线圈内，大地是色散的导电媒质，电磁波在其中的传播速度为 $v = \sqrt{\frac{2\omega}{\mu_0\sigma}}$ ，多频电磁波在大地中传播速度不

同,以不同的时间到达接收线圈,其时间差反映了距离差。电磁波传播速度很快,不同频率电磁波传播的时间差很小(纳秒级),如何测量并利用电磁波传播的时间差,确定地球探测深度也是一个有待解决的科学难题。

参 考 文 献

- [1] Spies B R. Depth of investigation in electromagnetic sounding methods .Geophysics ,1989 ,54(7);872—888 .
- [2] Huang H .Depth of investigation for small broadband electromagnetic sensors .Geophysics ,2005 ,70(6);135—142 .
- [3] 王卫平 .直升机 TEM 系统关键技术指标与探测深度分析 .地球学报 ,2005 ,26(1);93—97 .
- [4] 朱凯光,林君,刘长胜,等 .频率域航空电磁法一维正演与探测深度 .地球物理学进展 ,2008 ,23(6);1943—1946 .
- [5] Yan S,Chen M S,Shi X X .Transient electromagnetic sounding using a 5m square loop .Exploration Geophysics ,2009 ,40 ;193—196 .

撰稿人：朱凯光 林 君
吉林大学仪器科学与电气工程学院

地球深部的水能直接探测吗？

Is It Possible to Detect Groundwater Directly in the Deep Earth?

按照广义地壳流体的定义，地球内部的水以地下 10km 左右作为界面可分为大气成因水和深成水^[1]。前者指地表深度 10km 以内，主要来自大气降水，多为液态水。后者则主要指分布在地下十几千米至几十千米的深部，由地质作用生成^[2]。

研究表明，地壳深部的水主要是以羟基的形式存在于含水岩石中，或者以流体形式存在于俯冲板块范围内。目前能够进行的超深钻探仅能达到 12km，到更深部采样是不可能的。因此，在研究地球深部水时，基本采用地球物理探测、地球化学分析和高温高压实验的手段只能够给出深层水的含量上限，地球深部水的真正含量还是不很清楚^[3]。于是，就需要利用大地电磁、电磁测深及地震观测等地球物理方法来获得地壳深层水的分布信息，实现对地球深部水的间接探测^[4]。由 Ringwood 建立的原始地幔岩矿物模型^[5]和 Anderson 建立的榴辉岩矿物模型^[6]可以看出，目前人类对几十千米以下地壳中水的赋存情况仍处于猜想状态，尚需要地球动力学、地震学及高压地球物理学进行进一步的综合验证。

有证据表明，地球内部的水含量是地球表面水含量的数倍^[2]，但由于埋藏于地球深部的水处于高温高压的状态，而很难对其进行钻探开采。因此，如何对大气降水构成的液态地下水进行快速高效的探测，即为本难题所指的地下水探测范畴。

地质、物探、钻探是寻找地下水的常用手段。钻探方法最直接，但成本最高，工作效率最低；地质方法和物探方法是多解和间接的。目前，寻找地下水的工作还是先用地质方法。根据已有的地质资料，大致勾勒出可能的含水地带，然后用电法测量这些地带地层的电阻率，找出低电阻率的地层，即认为有可能是含水层。含水层一般是低电阻率，但低电阻率不一定就是含水层。泥层也可以形成与含水层相似的低电阻率。所以，电法不能直接确定地下水的存在。

核磁共振是一个基于原子核特性的物理现象，系指具有核子顺磁性的物质选择性地吸收电磁能量的过程。在稳定地磁场的作用下，地下水中的氢核磁矩像陀螺一样绕地磁场方向旋进，如图 1 所示，




图 1 质子磁矩在磁场作用下的旋进运动

旋进频率称为拉莫尔频率,用 f_0 表示。用人工方法,向地下供入频率为当地拉莫尔频率 f_0 的交变电磁场,激发地下水中氢核形成宏观磁矩 M_0 ,使其产生核磁共振,而在地磁场中产生旋进运动,进动频率为 f_0 。停止激发后,用线圈拾取 M_0 进动产生的核磁共振信号,即可计算出地下水的赋存状态。

目前的工作方法是在地面上用电缆铺设一个圆形或方形的线圈,短时间内在其中供以频率为 f_0 的正弦波电流,如图 2(a)所示。停止供电后,检测地下水在这个线圈中感应出的核磁共振信号,如图 2(b)所示。




图 2 核磁共振激发和接收到的信号

核磁共振信号的数学模型为

$$E(t, q) = E_0(q) \exp(-t/T_2^*) \cos(\omega_0 t + \phi_0)$$

式中, T_2^* 为描述感应信号衰减时间的平均弛豫时间; ϕ_0 为与地层的导电性有关的初始相位; $E_0(q)$ 与含水量有关:

$$E_0(q) = \frac{3\mu\omega M_0 S \Delta Z}{2Z_0} U(p)$$

式中, μ 为均匀半空间的磁导率; M_0 为单位体积内的磁矩; S 为接收天线所包围的面积; ΔZ 为含水层厚度; Z_0 为含水层顶板深度; $U(p)$ 是一个与地层电导率有关的函数。由 E_0 、 ϕ_0 、 T_2^* 和激发电流脉冲矩 q 等参数,即可计算出地下水的深度、含水率、含水层孔隙度等信息。

由以上公式可知,水层越深,水量越小,信号越微弱。目前,在地面线圈两端可以检测到纳伏级信号,可以探测最大深度为 150m 的层状地下水。显然,这只是地下水中很小的一部分。如果要探测更深的水,则需要更大的线圈、更强的激发电流、更高的接收灵敏度。核磁共振探测地下水所用频率为 1~3kHz,而这个频率范围内集中了音频和其他电磁波,它们都对探测造成干扰,使测量信噪比很低。

深部地下水能否被高精度探测是一个亟待解决的科学难题,解决这个难题对于缓解人类缺水地区饮水困难、预测灾害水源等问题具有重要的现实意义。

解决该难题的主要困难有两个方面:一是探测设备的抗干扰性能有限,用于数据处理的反演方法并不十分有效;二是探测深层的地下水需要在几十毫秒内发射数千安培甚至更强的电流,而且还要在数毫秒内关断。如果能在这两个方面取得突破,那么,探测深部地层的水是有可能的。

针对上述问题,Legchenko 等^[7]对记录的数据进行了工频谐波干扰去除方法的研究,数据处理时采用了区块对消法、正弦对消法和陷波法,但这些方法都是数字滤波法,都是在数据采集之后进行的,而在数据采集之前,干扰信号是有用信号的数百倍甚至数千倍。如果能在数据采集前大幅度提高信噪比,再加上有效的数字滤波,则有可能提取出深部的水信号。

核磁共振探测地下水的方法是目前最直接、最有效的方法,这种方法的缺点是被测量的信号太微弱。是否有更好的物理探测方法能解决地球深部水的直接探测问题?期待着答案。

参 考 文 献

- [1] National Research Council. The Role of Fluids in Crustal Processes. Washington: National Academy Press, 1990: 3—23, 114.
- [2] Bell D R, Rossman G. Water in earth's mantle: The role of nominally anhydrous minerals. Science, 1992, 255: 1391—1397.
- [3] 王多君, 易丽. 地球深部的水. 中国科学院研究生院学报, 2009: 721—730.
- [4] Baba K, Chave A D, Evans R L, et al. Mantle dynamics beneath the East Pacific Rise at 17 μ s: Insights from the mantle electromagnetic and tomography (MELT) experiments. Journal of Geophysical Research, 2006, 111.
- [5] Ringwood A E. Composition and Petrology of the Earth's Mantle. New York: McGraw-Hill, 1975.
- [6] Anderson D L, Bass J D. Mineralogy and composition of the upper mantle. Geophys. Res. Lett., 1984, 11: 637—640.
- [7] Legchenko A, Valla P. Removal of power-line harmonics from proton magnetic resonance measurements. Journal of Applied Geophysics, 2003, 53 (2/3): 103—120.

撰稿人: 王应吉 林 君
吉林大学仪器科学与电气工程学院

欠冗余传感器网络的故障诊断

Diagnostics of Deficient Sensor Networks

在苏联切尔诺贝利核电站爆炸、中国重庆綦江彩虹桥垮塌等重大灾难性事故后,世界各国都将确保重点设施/设备运行安全性提升到了国家安全、社会稳定的高度。把传感器嵌入到大坝、桥梁、隧道、铁路、电网、供水系统、油气管道等各种重大基础设施中,构成结构安全传感器网络,已成为保障基础设施安全的必然发展趋势^[1]。而且随着社会的进步、技术的发展,需要了解与掌握的结构状态信息、需要监测的结构参量、所采用的传感器数量也越来越多。例如,长江三峡工程总共采用各类传感器近 10 万只,仅在大坝上就用了 60 多种、1 万多只传感器^[2],构成了目前最大规模的结构安全传感器网络。为了提高传感器网络的可靠性,构成网络的传感器数量 M_s 必须多于待测参数 M ,且 M_s 比 M 多 k 个(即 $M_s = M + k$),在硬件上形成冗余工作状态。但在工程实践中,由于受经费、空间、工艺等诸多限制,导致构成网络的传感器数量 M_s 比待测参数 M 还要少 j 个(即 $M_s = M - j$),从而成为欠冗余的工作状态,使得系统只能监测部分主要参量,放弃多数次要参量。重大工程设施/装备状态监测的传感器网络更是典型的欠冗余系统,有的传感器数量 M_s 甚至只有待测参数 M 的几成,系统处于极度的信息匮乏状态,每只传感器的输出都极为珍贵,传感器故障的后果比普通传感器网络系统严重得多。

由于桥梁、大坝、电站等大型设施/装备是以水泥、钢铁等为基本材料,其寿命长达数十、甚至上百;而传感器网络则是以微电子元件为核心,其寿命与被测对象存在巨大差异,且长期的恶劣使用环境还会加速传感器老化、加速其性能衰退,因此,传感器输出信号的失真与变异不可避免。此外,电磁干扰、电源波动与冲击等干扰、地震、强风等环境影响、维修、误操作等人为因素也都会引起传感器输出信号的失真与变异。而待测对象渐变性的蜕变,以及在超负荷、意外事故、人为破坏等非自然条件下的突发性损伤、故障,也会导致传感器输出的变异信息。传感器故障与被测对象故障这两类数据失真与变异完全交织在一起,使本身就十分复杂的传感器数据失真与变异的甄别、辨识更加复杂、困难,因此,对欠冗余传感器网络的故障诊断必须采用与常规硬件冗余完全不同的技术路线。

如果把欠冗余传感器网络诊断问题与线性方程组求解问题进行类比,将 M_s 、 M 分别视作线性方程组中的方程数与未知数,则根据线性代数原理可知,

只有当 $M_s = M$ 时, 方程组才有唯一解; 若方程数 M_s 少于未知数 M (即 $M_s = M - j$), 就成为欠冗余方程组, 必须再添加 n 个线性无关的方程, 使 $n = j$ (即 $M_s = M$), 才能求解出这 M 个未知数。如果 n 的数量足够大、使得 $n = k + j$, 就可以使其由欠冗余方程组变为过冗余方程组。因此, 解决欠冗余传感器网络的故障诊断, 其关键就是从 M_s 个传感器的输出中再找到 $n = k + j$ 个包含待测参量的关系式, 从而构成 $M'_s = M_s + n \gg M$ 的软冗余条件, 而这就必须以被测对象为基础、以传感器输出数据为对象, 通过对传感器输出数据与被测对象内在的联系、外在的表现形式进行全面分析, 挖掘出 $n = k + j$ 个测量关系式, 才可能满足数据失真与变异的甄别、识别的条件, 实现传感器网络的故障诊断。

从系统的整体角度看, 同一被测对象不同参量的表征虽然不一样, 但它们相互之间往往存在一定的内在联系, 且都与其整体状态关联, 因此, 这样的传感器网络中, 每个传感器节点的输出信息都在一定程度上隐含了周围关联点的信息及整体信息, 这个关联性就是一种信息冗余, 是在欠冗余传感器网络故障诊断中可资利用的宝贵信息, 故可基于被测对象的物理机制, 利用现代传感器网络具有的互连、互通、互操作及自诊断特性, 挖掘出 $n = k + j$ 个新的测量关系式, 诊断传感器网络中的部件及节点故障^[3]。

由于重大设施使用寿命长, 性能蜕化与衰变过程十分缓慢, 因此, 对数据采集的速度、实时性要求极低; 而现代传感器网络高速、实时、动态的数据采集能力, 对于长期、断续、静态的数据采集而言具有极大的能力冗余, 从而能获得时间上的数据冗余; 而当时间冗余数据达到一定程度、其他相关条件又满足时, 就可能采用各种信号处理的方法, 挖掘出 n 个新的测量关系式。例如, 采用统计分析, 获取信号变化阈值及多变量间的相关性特征; 采用信号处理模型, 提取系统输出变量测量样本信号的幅域、时域、频域、功率谱、自回归滑移平均模型参数及奇异点等参数特征; 利用神经网络, 基于历史数据构建神经网络观测器、神经网络辨识器或神经网络预测器模型, 将模型输出与系统实际输出比较得到残差冗余信息; 采用定性趋势分析, 获取定性诊断信息等^[4]。

因此, 欠冗余传感器网络的故障诊断, 必须充分了解被测对象与传感器硬件, 通过时间统计与关联分析, 从时间序列、环境、位置、结构、类别上对传感器数据进行关联分析来挖掘出传感器网络中存在的各种关联特性, 从而以“软”冗余信息补偿传感器网络硬件的“欠”冗余信息, 实现欠冗余数据的传感器网络的故障诊断。为此, 需要将传感器置于对象、结构、空间、时间等的相关体系中进行研究, 针对监测对象在工作条件下的物理机制, 建立对象模型; 研究冗余监测数据的时间统计、关联分析的方法, 建立关联模型; 提取传感器数据之间的相关性特征, 建立特征空间; 研究目标函数及检测阈值的设置, 建立决策空间; 研究故障分类或推理法则, 建立故障类别空间; 研究故障辨识及

定量估计的参数阵,建立阈值空间^[5,6]。由于欠冗余传感器网络的故障诊断可有效降低系统的误漏报警,相对延长传感器系统的总体寿命,因此,越来越受到业界关注,成为仪器学科的一个前沿科学问题,并将广泛应用于土木、机械、电力、国防、航天、通信等领域。

参 考 文 献

- [1] 欧进萍.重大工程结构智能传感网络与健康监测系统的研究与应用.中国科学基金,2005,19(1):8—12.
- [2] 李天智,张英.三峡左岸电站机组状态监测故障诊断系统分析.水电自动化与大坝监测,2007,31(2):29—31.
- [3] 胡顺仁,陈伟民,章鹏.桥梁监测系统多传感器测点之间的关联分析.土木工程学报,2009,42(3):81—86.
- [4] Shui A S,Chen W M,Zhang P,et al.Review of fault diagnosis in control systems.2009 Chinese Control and Decision Conference,2009;5324—5329.
- [5] 鲍文,于达仁,王伟,等.基于关联规则的火电厂传感器故障检测.中国电机工程学报,2003,23(12):170—174.
- [6] Cho C W,Choi Y H.Concurrent diagnosis of clustered sensor networks.5th International IFIP-TC6 Networking Conference,2006;1267—1272.

撰稿人: 陈伟民 胡顺仁 税爱社 章 鹏
重庆大学光电工程学院

光学频率的直接测量

Direct Measurement of Optical Frequency

光学频率的直接测量是我们的愿景。

光是电磁波。电磁波的频率是它的电场(或磁场)在单位时间(1s)内振动的次数。光的频率很高,如 He-Ne 激光 632.8nm 波长的频率是 4.7×10^{14} Hz,即在 632.8nm 波长光的通路上任一点,电场每秒要正弦振动 470 万亿次。

人的眼睛是人类自备的光频率探测器,可以感测出光的波长(频率),感测的波长范围是我们所说的可见光(400~730nm)。眼睛的波长分辨率不高,以眼睛能分辨为依据的有标准名称的颜色共 138 种,如爱丽丝蓝、珊瑚红等^[1]。有资料认为,最好的油漆工人可以识别 1000 种颜色,在 7 色中(红橙黄绿青蓝紫)的每一种分辨出 140 多种,平均波长分辨率约 0.33nm,频率分辨率约 350GHz。真遗憾,350GHz 的范围很大,说明我们的眼睛本事不够,远远不能分辨 1Hz 的频率改变所带来的颜色差别。

为了得到光的更多信息,人们研究出了一系列的光电探测器,把光的电场波动转化为电压或电流并加以记录,包括光的功率、光的波动、光的脉冲;但至今不能对光的频率进行直接测量。

光频的直接测量是指对各种光源发射的光波的频率不经接力的、直接的测量。以可见光为例,要对 400~730nm 波段的电磁振动频率直接测量,就是直接测出范围为 $7.5 \times 10^{14} \sim 4 \times 10^{14}$ Hz 的光电场波动,此光波动的频率是目前用作频率标准的铯原子钟跃迁频率 9192631770Hz 的 50000 倍左右,远远高于一般电子仪器所能感知的电振动的速度^[2]。直接、准确地把它测量出来,是学界的难题。

对这个难题的研究在国内外都引起了广泛的关注,这是因为光学频率的直接测量有巨大的科学和应用价值。

测量物体的运动速度,多为多普勒测速原理。离开我们而去的物体,我们看到光的频率减小(多普勒红移);反之,向我们走来的物体,我们看到其光频增加(蓝移)。发光、反射光是一切物体的本能。光频的移动大小代表着大到天体、小到精子的物体移动速度。因为不能直接测量光的频率及改变,普遍使用复杂的差动方法测量频率移动的大小。所谓差动,就是把光源发出的光分为“本振光”和“测量光”。“测量光”射向被测物再返回和“本振光”混合,“测量光”和“本振光”的频率差(又称为波拍)代表被测物的速度。对于相当多的

场合,这种差动测量频率的方法是不可能使用的。例如,我们不能指望地球上的光源发出的光到达遥远的星球被反射回地球后还有足够的能量供“差动”,也就不能由这种差动获得遥远星球的运动速度。但是,如果我们可以直接测量出遥远星球上某一元素自身发出的一条光谱的频率,并和一个已知速度的天体的同一原子的同一光谱频率比较,测量天体运动速度的精度就能极大提高。借此,测量近距目标的系统也可大大简化。

如果可以直接测量光的频率,除了上面说到的由多普勒红移进行天体速度测量外,还能测量宇宙学红移(由于宇宙空间自身的膨胀所造成的),并由此红移测量天体间的距离,其精确度可以大大提高。

光学频率的直接测量还意味着测量“时间”精度的提高。时间和频率互为倒数:时间 $\times$ 频率 $=1$,这就是时间和频率的物理联系。频率的单位是 $1/\text{s}$ 。如电磁波频率已知,某事件发生,数出事件持续过程中电磁波振动过的周期数 N 就知道事件持续的时间。因此,频率测量精度的提高可以帮助我们更精确地认识千变万化的物质世界,提高我们创造新的美好世界的技术水平。

经过几十年的努力,现今的测量频率的技术已有重大进步,但还远不是直接测量。

光频率的测量最初是建立在光频链混频的方案上的,它是指以铯原子 Cs133 基态两个超精细能级之间跃迁频率 9192631770Hz 为参考基准,借助于若干中间光源发出的光的频率,通过逐级谐波混频,对激光频率进行绝对测量的一种方法^[3]。铯原子发出的光频率 9192631770Hz (属微波段)定义为频率标准(时间基准)。1967年,第13届计量大会上,定义“秒是铯原子 Cs133 基态的两个超精细能级之间跃迁所对应的辐射的 9192631770 个周期的持续时间”。为了光的频率测量的精确性,把光频率和铯原子频率基准连接起来比较。由于 Cs133 辐射的微波频率与光频率相差5个数量级或更多,直接从微波信号得到 10^5 的高次谐波是不可能的,因此,在测量中利用若干过渡激光器建立起一系列频率综合链。1983年,国际计量委员会推荐13条真空波长组成这样一个频率综合链。在测量光的频率时,将被测光的频率与这13条光频进行阶梯式的链接比较,直到与铯原子 Cs133 辐射的 9192631770Hz 相衔接。由于测量系统相当复杂,实现起来时很困难,因此,世界上只有少数国家的实验室建立了这样的测量系统,而且一条光频链只能测量一个激光频率,也即测一些孤立的频率,因此,光频链的测量在电子学中称“点”频测量^[4]。

到了1999年,人们发明了以飞秒激光为基础的光频梳,由一个飞秒激光器输出一个光频梳代替光频链。“光频梳”一词形象地描述了一系列等间隔频率。所谓光频梳,就是把一个频率看成一个头发梳的齿,多个频率即是一把梳。光频梳的发明使测量光频的技术前进了一大步。飞秒光梳技术是1999年由德国

Max-Planck 量子光学研究所的 Hänsch 教授领导的科研组提出的,他们采用锁模飞秒脉冲激光技术与光子晶体光纤技术研制了“飞秒激光-微结构光纤光学梳状频率综合装置”,其频率覆盖范围为 $500\sim 1100\text{nm}$,把光学频率梳与铯原子微波频标连接起来即可实现对光频率的测量。传统的谐波光频链的体积通常有几间实验室之大,而光频梳的体积就小多了,一个 $1.2\times 1.0\text{m}^2$ 的光学平台即可容纳。采用光频梳,实现了从红外到可见光区域的所有光学频率的逐级绝对测量,频率不确定度进入 10^{-15} 量级,这确实是科学上的一项巨大进步。

但是,从另一个角度看,从光频链到光频梳,基本的思路并没有太大改变,都利用 Cs133 辐射的 9192631770Hz 作为光频标,并由一系列频率过渡到光频测量,改变的仅是产生频率链的方法和稳定激光频率的方法。

铯原子频标再加上光频梳等构成一个整体,其复杂的程度和昂贵的造价决定了它只能安装在国家计量单位。我们的愿景是实现光学频率的直接测量。如能如愿,上述的“光频梳”不再仅是目前的基本功能,作为频率标准,它将有更大的用武之地,产生从小到大的光拍频,应用于方方面面。如能如愿,光频率这个无比巨大的信息源的潜力会得以更充分开发,对光通信、光电子学、光谱学及多种实际应用产生巨大的推动作用。

可惜的是,直到今天,光频率的直接测量仍是困扰科学界的难题,它的难点在于制造出能把光振动转化为电振动(电压或电流)的探测器,以及如此高频的电信号的传输和周期计数。为此,探测器、计数元件的材料及电容、电感、电阻的尺寸效应等大量的科学技术问题都有待研究。

总而言之,光学频率的直接测量是今天的难题,其实现需要众多的基础条件,是理论物理学者、工程科学家、实验科学家、工程师的共同任务。相信在人们的努力下,终有一天,我们的愿景能成为现实。

参 考 文 献

- [1] <http://www.chinaw3c.org/index.htm>.
- [2] 陈徐宗.光的量子相干性与光频率的超精密测量.物理,2006,35(3):207—212.
- [3] 于建国,等.光频测量的发展.宇航计测技术,2003,23(5):56—60.
- [4] 沈乃澂,等.光频标和光频测量研究的历史、现状和未来.量子电子学报,2004,4(2):139—148.

撰稿人: 张书练 徐春欣
清华大学精密仪器与机械学系

自由曲面光学设计理论

Theory for Freeform Surface Design

1. 背景介绍

传统的光学设计都是在已有初始面型结构的基础上,设计者根据提出的设计要求设置一个系统评价函数,并且通过光线追迹的方法,不断地借助评价函数来优化系统的几何结构,确定所有光学表面的最终面型^[1]。这个时候的面型基本上都是旋转对称的球面或者简单的非球面。经典的初级像差理论指出,光学系统的各种初级像差值均可以表示成孔径和视场的级数形式,一般都是随着孔径和视场的增大,像差增大越来越厉害,成像质量越来越差,这对我们现在应用的很多光学系统是很致命的限制^[2]。或许有人会问:有没有更加直接的光学设计的方法呢?能不能不通过一个初始结构的不断优化这种间接的方法来得到面型,而是通过我们对光束的需要来直接计算出满足我们应用需要的面型结构呢^[1]?或者说能不能设计出一个光学系统,能够将平面的图像无畸变地成在任意形状的物体表面呢?如果上述问题都能得到肯定的回答,那么,我们就有可能找到能够改变经典像差理论对像差由孔径和视场所决定的定势描述。幸运的是,自由曲面光学系统有潜力解决这些问题。

2. 问题描述

自由曲面光学透镜是相对于球面和简单的非球面而言,其具有更大的面型自由度,能够更好地矫正各种像差和畸变,也就是说,一片自由曲面有可能替代多片普通球面透镜,这样,在大大降低光学系统复杂程度的同时,又不会降低其成像质量^[3]。自由曲面光学设计还有着其独特的优点,那就是方法直接,人们根据自己的需要直接计算得出面型的结构,省去了很多烦琐的优化过程。自由曲面的这些优点使其越来越广泛地被关注和研究。

目前,自由曲面的应用主要集中在照明领域,用来实现均匀照明和特定形状的照明,这方面的研究已经取得了一定的成果。但是,自由曲面在成像方面的研究和应用很少,其原因成为成像应用中对光线的控制比照明应用中相对困难。但我们不能否定在成像领域自由曲面存在着可行性和巨大潜力。

光学成像的过程实际上是一个实现从物空间到像空间的空间变换过程^[4]。光学系统充当了变换系统的角色,传统的光学设计是已知物空间和变换系统来

求解像空间。现在,很多光学设计是针对一定的物空间特性,并且已知对像空间的成像要求来求解所需要的光学变换系统。现有的光学设计软件都是默认这个变换系统由球面和非球面组成,但由这些球面和非球面组成的未必是最佳的光学变换系统,如果我们放宽选择条件,把更加复杂的面型甚至是自由曲面考虑进来可能得到真正的最佳变换系统。

在成像系统里,物空间的点和像空间的点必须满足一一对应关系,传统的光学系统都能只实现平面到平面的指定倍率的成像,如果要打破这种等倍率的成像关系,将物面上的点成到像面上我们希望的任意位置上,这个当然是常规的光学成像系统所不能做到的了。我们知道,这个物点与像点的一一对应关系,在光学系统中就相当于知道了入射光线和它对应的出射光线的方向和路径。假设有这样一个曲面,物面上从任意物点发出的一条光线,经过它的折射或者反射后都能从我们指定的位置和方向出射,那么,就实现了我们前面所讲的解决任意形状图像之间的光学变换的问题。而对这个曲面,我们需要确定的是光线入射它每一点的位置和该点的法线方向,显然,这样的曲面不可能是我们平常讨论的普通球面或者非球面,而是由不能用公式表达的一些离散的点组成,根据在各点的位置和法线方向来形成曲面,叫做自由曲面。从数学上看,上述方法是可行的,并且自由曲面的设计最根本的还是遵循光学里面最基本的定律——光的折射与反射定律^[5]。虽然通常情况下,经过上述方法设计出来的单片自由曲面可能不能完全按照我们的需求来控制一束光线,但适当地添加一些其他的球面镜或者非球面镜后,结合起来使用,这些自由曲面就能发挥其他透镜所不能匹及的某些独特作用^[1]。

遗憾的是,到目前为止,由于自由曲面面型的复杂性,适合传统球面和非球面的像差理论现在已经不适用了,不仅如此,原有的基于塞德函数评价像质的体系现在也不适用了,而自由曲面的光学设计和应用还没有形成自己完整的理论和体系,也没有很好的成像质量的评价方法。因此,对待自由曲面,现在我们还不能像球面和非球面系统设计那样有很强大的计算和优化工具,也没有相应的好的评价体系,这是限制自由曲面应用的一个最重要的原因。

3. 必要说明

这里说的自由曲面区别于普通球面和非球面,一般不能用精确的表达式来表示或者说是需要很复杂的式子来表示的曲面,即它的表达式里有很多个参量,根据像差理论,这些参量都可以参与像差平衡,能够平衡多种像差,所以,一片自由曲面透镜理论上可以实现好几片球面或者非球面透镜的成像质量。

4. 相关扩展

以上只是自由曲面光学设计的最基本的原理说明和理论上的可行性分析,自由曲面的研究在过去的几十年里越来越热门起来,很多新方法的思想被提出来,它已经成为光学设计领域里一个重要的分支。

在实际的应用中,自由曲面的光学成像系统设计尚无普适的设计理论与完整的设计方法,更无强大的设计软件、工具及完善的评价体系,并且由于自由曲面的复杂性与多样性,经典的像差分析理论和像质评价体系都已经不适用了,探讨与研究适合它本身的理论和体系还有艰巨的研究和工作,这些都构成了深入探讨和解决的自由曲面设计的难题。

但毋庸置疑的是,自由曲面在成像系统里具有巨大的优越性,并且现在自由曲面在光学领域受到了越来越多的关注,很多光学设计领域的专家都投入了很多研究,我们相信,如果这方面的理论和评价体系能够像球面和非球面那样成熟和完善起来的话,对于光学设计和光学成像无疑是一个艳阳天。

参 考 文 献

- [1] Hicks R A .Direct methods for freeform surface design .Proceedings of SPIE ,2007 .
- [2] 李晓彤,岑兆丰.几何光学·像差·光学设计.杭州:浙江大学出版社,2003.
- [3] 孙旭涛.应用自由曲面的超薄投影显示系统理论和实验研究[硕士学位论文].杭州:浙江大学,2008.
- [4] 郁道银,谈恒英.工程光学.北京:机械工业出版社,1999.
- [5] 丁毅.自由曲面光学器件的设计及其在照明系统中的应用[博士学位论文].杭州:浙江大学,2009.

撰稿人: 侯 佳

浙江大学光电信息工程学系

真实立体感头戴式三维显示器

Natural Viewing 3D Head-mounted Display

16 世纪之前,人们就已经注意到,人是因为双眼看到物体的不同部位而产生立体感,著名画家达·芬奇对此做出了详尽的阐述。但直到 19 世纪,才正式开始了立体视觉理论的研究。1838 年, Wheatstone 根据“三维物体对人两只眼睛产生不同的透视投影”发明了第一副三维立体眼镜,通过它将两幅平面图像分别投影到人的左右眼,使人眼最终看到三维图像。Brewster 于 1844 年通过实验验证这一现象是由于人眼存在视差而产生的,其中,1985 年, Wade 教授对 Brewster 的实验进行了深入的研究和总结^[1],拉开了现代三维显示的序幕。随后,许多著名的科学家,如德国科学家 Helmholtz 等对立体视觉进行了深入研究。

目前,三维显示技术得到了蓬勃的发展,2009 年,《阿凡达》的热映进一步标志着立体显示时代的来临。立体显示技术也正在从三维电影向三维电视普及。大部分立体显示器仍旧采用视差原理,即生成两幅存在视差的二维图像并分别投影到观看者的左右眼,经由大脑融合成具有深度信息的三维影像。其中,应用最为成功的便是眼镜式三维显示技术。根据分离左右眼视差图的技术方法,它可分为液晶开关眼镜、偏振光眼镜、红绿/蓝眼镜、明暗眼镜和头盔显示器。

然而,双目视差只是产生真实立体视觉的生理要素之一,双目的调节和会聚及一定的视场角(身临其境)则是产生真实立体视觉的其他必要要素。无疑,视差型立体显示技术很好地解决了视差图像的生成和投影问题,却无法有效改变人眼的调节,即人眼到屏幕的距离。两眼为了看清视差图,需要一直聚焦在固定的显示屏幕上,而人双眼的会聚点则跟随重构的三维物体的远近而改变。当感知的三维物体不在显示屏上时,就会引发会聚和调节之间不相匹配,这既违背了立体视觉原理,又不符合人眼的生理习惯,可能导致视觉失真。同时,由于人眼及人体生理是非常敏感的,任何违反人眼立体视觉原理的重现都会引发人眼及身体的不适。长期使用容易引发视疲劳、眩晕感等不良反应严重影响人体健康,从而影像了立体显示技术的推广应用。

会聚与调节不匹配这一问题随着立体显示器的大量推广使用而变得愈发明显和重要,得到了科研人员的广泛关注和重视,也是今后立体显示技术必须解决的难题。那么,怎样才能有效解决立体显示中的调节与会聚相互匹配问题,

实现符合立体视觉原理的三维显示技术,从而满足健康舒适的观看需求?为此,科研人员做了大量努力。如果显示屏幕与再现的三维物体一起在空间移动就能够很好解决以上问题。科研人员提出了三维影像真实存在于三维空间中的真三维显示技术,该技术能够提供所有的深度暗示和位置信息,这类显示主要有全息型、体积静止型和体积扫掠型真三维显示等^[2],但它们面临超高分辨率显示器件、合适的显示介质及动态实时显示时的海量数据处理等诸多困难,其重现的三维影像尺寸、分辨率、色阶等受到很大限制,并且系统复杂笨重。科研人员也提出了深度融合型三维显示技术,其中,包括多平面式三维显示器^[3],它的缺点在于各屏幕间对准困难,只有在显示器正前方观赏时,立体效果较好,显示图像的大小和三维物体的深度范围也受到了限制,这些方法可以完全解决会聚与调节不协调的问题,但都存在其他的缺陷或重大困难,短期内难以应用推广。

在利用头戴式立体显示器观看三维影像过程中,除头盔显示器以外的显示器均无法改变眼睛与屏幕的距离,它们与显示屏是相互独立的。那么,能否实现具有真实立体视觉的头戴式立体显示器呢?头盔显示器是通过光学透镜将微显示器上的图像放大数倍至人眼,对透镜的光焦距做适当改动就能改变虚拟屏幕的位置。因此,解决头盔显示器中人眼调节与会聚不协调问题的关键就是发展多焦面显示技术,其原理与多平面式三维显示技术类似。通过某些技术手段生成若干焦面,不同焦面上的场景通过亮度调制(如亮度与三维物体到该面板距离的倒数的平方成正比)、色彩搭配渲染和相互遮挡关系相互融合,使合成景象所处屏幕位于若干焦面之间,形成屏幕可移动的立体三维图像,也就可以有效地改变人眼的调焦距离,产生具有真实感的立体视觉,原理如图1所示。由于头盔显示器各焦面生成的是虚拟屏幕,因此,其尺寸和呈现的景深范围都可以远比其他真实视觉的立体显示器大。如何在头盔显示系统中有效快速地生成多个焦面呢^[4]?

目前,科研人员主要提出了以下几种方法:通过分光镜引入多光路形成多焦面^[5];通过液体透镜改变系统光焦距,采用分时复用的方式实现多焦面^[6];双折射材料透镜和液晶调制器组合使用,光线通过它们并可在寻常光和非常光方向有两个不同的焦面,如果使用 N 个双折射材料透镜和液晶调制器,就可以实现 2^N 个焦面^[7]。目前,光学元器件的刷新频率可能是该项技术的一个瓶颈。虽然头盔显示技术得到了40年的发展,其色彩、亮度、体积重量、视场角都得到了空前的提高,然而,具有真实立体感的头盔显示技术要走出实验室、进入人们日常生活尚需时日,那么,如何实现系统小型轻量化和提高舒适程度将是此类立体显示器必须面对的一个难题。

具有真实感的三维立体显示技术,因其可以再现物体原貌,给人以身临其




图1 多平面/焦面立体显示技术

境的视觉享受，是人类追求完美视觉效果 of 的终极梦想，能否完全实现真实立体感的三维显示器？它们又能在何时像彩色电视替代黑白电视一样取代彩色电视现今的地位并且风靡全球？今后具有真实立体视觉的头盔型立体显示器能否像其他立体显示器一样普及呢？

参 考 文 献

- [1] Wade N J, Ono O. The stereoscopic views of Wheatstone and Brewster. *Psychological Res.*, 1985, 47: 125—133.
- [2] 黄涛. 三维显示中的关键技术研究[博士学位论文]. 北京: 北京理工大学, 2009.
- [3] Takada H, Suyama S, Date M, et al. A compact depth-fused 3D display using a stack of two LCDs. *The Journal of The Institute of Image Information and Television Engineers*, 2004.
- [4] 王涌天, 程德文. 头盔显示技术的发展趋势. *中国计算机学会通讯*, 2010.
- [5] Hoffman D M, Girshick A R, Akeley K, et al. Vergence-accommodation conflicts hinder visual performance and cause visual fatigue. *Journal of Vision*, 2008, 8(3): 1—30, 33.
- [6] Liu S, Hua H. Time-multiplexed dual-focal plane head-mounted display with a liquid lens. *Opt. Lett.*, 2009, 34(11): 1642—1644.
- [7] Love G D, Hoffman D M, Hands P J W, et al. High-speed switchable lens enables the development of a volumetric stereoscopic display. *Optics Express*, 2009, 17: 15716—15725.

撰稿人：程德文 黄涛 王涌天
北京理工大学光电学院

真实感空间三维显示

The Real Three Dimensional Display

人类是天生的空间思维者,实现真实三维显示一直是人们孜孜以求的目标。目前,主要的三维显示技术有视差型体视三维显示、全息三维显示及体空间三维显示等。

视差型体视三维显示是当前最为普及的立体显示技术,它通过特定分离方式使左、右视图分别为人们的左、右眼观察,利用双眼的视觉融像产生立体感知。视差型立体显示分成两大类:一类人们需要借助于特殊眼镜(或其他器具)才能获得立体感知,主要有互补色、时序和偏振三种方式;另一类是裸眼,即可观察的自动体视三维显示技术——自体视三维显示。随着平板显示技术的发展,出现了基于平板显示器 LCD、PDP 等与光学视差生成元件相结合的自体视立体显示器^[1]。另外,将 LCD 与可控线状 LED 照明技术相结合实现人眼跟踪的体视显示,也是当前视差立体显示的主要方向。应该指出的是,视差型三维显示依靠双眼的视觉融像而产生立体感知,虽然能给观看者一种深度空间虚拟立体感,但它仅提供分立的视区和有限个数的视点,不是空间真实的三维显示,而且非自然的深度感的三维显示对这种靠大脑融像产生的立体显示而言都会导致观看者在长时间观看时出现头痛、恶心等反应。

全息三维与体空间三维显示就是两种接近真实空间的三维显示技术。全息三维显示中,再现像光波保留了原来物光波的全部振幅和位相信息,再现像与原物有着完全相同的三维光学特性。但是,全息三维显示需要一个高分辨的信息存储媒介(高分辨率的空间光调制器),尤其是动态显示时需要动态高分辨的空间光调制器。就目前而言,空间三维显示信息量之大,对空间光调制器、计算机的处理速度、存储容量和传输带宽的要求之高,都是目前软、硬件技术所无法实现的。但是,人们还在不断地研究与探索新的存储介质。2008 年, Tay 等^[2]在 *Nature* 上发表的聚合物光折变薄膜可以实现秒级的全息记录与回放,使得动态全息显示成为可能。体三维显示是在一定的空间区域媒介内再现各空间体素的信息,使得周围的观看者都可以从不同的侧面看到该区域内空间分布的三维景物^[3~6]。但是,在视觉特性上无法提供空间三维显示所需要的空间遮拦效应,使得体三维显示仅能显示透明的三维物体^[7]。

自然界中的景物都是具有空间三维形状与分布的。因此,最理想的显示就是如何在空间真实的再现三维景物,即所谓的真实空间三维显示,这是一种能

够在一个真正具有宽度、高度和深度的真实三维空间内进行图像信息再现的技术,能够使众多观看者以其习惯的观看方式同时观看到空间三维景象 360°的各个侧面,不仅能自动满足几乎所有的生理和心理深度暗示,还可多人、多角度、同时、裸眼观察,无需任何助视仪器,符合人类在视觉观察及深度感知方面的自然生理习惯。

空间三维显示最大的困难在于三维海量数据的获取、处理、传输及再现,尤其是光学的再现技术。

从显示的信息量上看真正的空间三维显示,要比目前的高分辨二维平面显示高出 10^5 量级的数据量。这首先就给我们提出一个难题,如何快速(至少是视频的速度)处理这样大的数据信息,这是目前的计算机与通信技术还不能完成的,因此,需要发展新的海量数据的高速处理方法。其次,什么样的显示介质能够包容如此大量光学信息,而且还必须高速地再现、刷新,这对新型可控发光或电光调制材料提出极高的要求,需要研究发展新的光电功能材料;第三,将显示三维场景的各个侧面的图像准确地成像到相应的方位而且具有空间遮拦等真实感效应,显示的媒介必须具有对不同方位、不同方向光线的控制能力,这样的空间显示媒介如何实现,至少经典的光学理论难以实现。再者,海量数据的处理又催生一个新的技术,如何应用人的视觉机制,尽可能地简化、压缩空间三维显示的数据量,需要研究全新的空间数据简化与压缩方法。最后,如何快速获取大场景的空间三维数据(如未来的空间三维摄像机),能够实时获取空间场景的全方位的三维景象,以便为未来的三维显示提供信息来源,这也是一个当前的难题。

空间三维显示技术还处于初步的研究与发展阶段,大量的工作等待进行,如三维显示空间的像素表征、空间三维图像的畸变矫正技术^[8]、全彩色视频动态空间三维显示的实现、空间三维显示的数据获取技术、压缩与编解码技术等都等待着我们的努力,特别是快速可控光源技术、光束方向性可控屏幕技术^[9]等都对光电子技术与光学技术提出了极高的要求与挑战。

作为一种新型的三维再现技术,空间三维显示技术的研究将为医疗成像、科研教育、国防安全和广告资讯等领域提供一种全新的显示手段,甚至为未来真三维电视提供最佳显示技术,是一种即将为人类广泛应用的新技术与新工具。可以预见,空间三维显示将是最早实现大空间尺度真三维显示的基本技术,并将为社会支柱产业的显示产业提供新的活力与新空间。

参 考 文 献

- [1] Benzie P. A survey of 3DTV displays: Techniques and technologies. IEEE Transactions on

- Circuits and Systems for Video Tech., 2007, (17): 1647—1658.
- [2] Tay S, Blanche P A, et al. An updatable holographic three-dimensional display. Nature, 2008, (451): 694—698.
- [3] Downing E A, Hesselink L, Ralston J, et al. A three-color, solid-state, three-dimensional display. Science, 1996, 30(273): 1185—1189.
- [4] Bahr D, Langhans K, Gerken M, et al. FELIX: A volumetric 3D laser display. Proceedings of SPIE, 1996, (2650): 265—273.
- [5] Favalora G E, Napoli J, Hall D M, et al. 100 million-voxel volumetric display. Proceedings of SPIE, 2002, (4712): 300—312.
- [6] Kimura H, Uchiyama T, Yoshikawa H. Laser produced 3D display in the air. Proc. ACM SIGGRAPH'06, 2006: 20.
- [7] Jones A, et al. Rendering for an interactive 360-light field display. ACM SIGGRAPH Conference, 2007.
- [8] Xie X Y, Liu X, et al. The investigation of data voxelization for a three-dimensional volumetric display system. Journal of Optics A—Pure and Applied Optics, 2009, (11): 045707.
- [9] 刘旭, 李海峰, 刘向东, 等. 实现全视场空间三维显示的屏幕装置: 中国, Wo/2009/127089. 2009-10-22.

撰稿人: 刘 旭

浙江大学光电信息工程学系

光在随机介质中的传播与成像

Light Propagation and Imaging in Random Medium

1. 背景

当光在各向同性均匀介质中传播时,遵循直线传播定律,当光传播到两种介质的光滑界面时,遵循折射定律和反射定律。那么,当光在折射率随机变化的介质中或到达随机起伏的界面时将怎样传播?这个问题就是光在随机介质中传播的问题。例如,高速飞行器上的成像探测系统、水下成像系统、高能激光传输系统、空间对地观测、激光大气通信与对潜通信等都遇到光在随机介质中传播或成像方面的问题。

在这些重要的工程应用中,光要通过大气湍流、水流等介质传输并成像,这些介质不能再看成是各向同性均匀介质,光作为电磁波与介质之间存在相互作用,介质的光学参数在时间和空间上都有变化,这就使探测器获得的光信号或像发生失真,严重影响信号质量与探测精度。图 1 表示平面电磁波通过随机介质传播产生了波面的畸变,影响了成像质量。因此,研究光在随机介质中的传播与成像对于信号或图像的复原是非常重要的。




图 1 平面电磁波通过随机介质传播对成像的影响

2. 问题

随机介质是在时间和空间上特性随机变化的介质^[1]。当考虑光的传播时,与光传播有关的特性,如介电常数或折射率、面形等在时间和空间上随机变化

即为随机介质。例如,大气中有雨、雾等,水中有气泡和悬浮颗粒,这些都是离散的随机介质,它们主要引起光的散射;当飞行器在大气层中高速飞行时,引起周围大气的密度场和温度场在时间和空间上发生变化,从而导致光学折射率场的变化,影响光的传播路径,这属于连续的随机介质;随机起伏的表面使光到达该表面后传播方向发生不同的变化,如起伏的地面、海面等,这也属于随机介质。

高速飞行器在大气层中飞行时,由于气动加热在飞行器头部将产生高温,形成湍流流场,造成气体密度和密度梯度的变化。当来自目标的光线通过湍流流场时,飞行器上的光学系统将接收到畸变的目标图像,导致视线误差、图像抖动和模糊^[2],影响成像探测精度,这种效应属于气动光学效应中的气动光传输效应。

在激光大气通信技术中,由于太阳辐射和各种气象因素所产生的大气温度的微小随机变化所导致的大气风速的随机变化,导致了大气折射率的随机变化,会造成经大气湍流传输的光束的抖动、强度起伏,以及光束扩展和像点抖动等现象^[3],严重影响空间光通信的稳定性和可靠性。高能激光在大气中传输时,传输路径上的空气被加热,使气体介质的密度和折射率发生变化^[4],还可能产生非线性效应,严重影响了激光束的传输与使用效能。

在空间对地观测领域,成像光的传输也同样受到大气湍流的影响。

传统的水下远距离通信方式受到设备庞大、信号衰减严重、命令传输速率低等因素限制,1963年,人们发现海水对蓝绿激光的衰减比其他波段的衰减要小得多,于是开展了激光水下探测与通信的研究^[5]。由于海水的光学特性随着温度、压强、盐度而变化^[6],特别是吸收、散射特性与水中粒子密切相关,水流的影响使这些特性又具有非均匀性和流动性,光在水中传播时也受到这些因素的影响,光经波动的海面会改变路径,同时产生反射杂波,降低了信噪比或图像的质量^[7]。此外,大量混浊水区域的光学成像问题也是人们关注的热点研究范围。

3. 历史回顾与现状分析

气动光学的概念最早由美国科学家 Leapmann 提出,气动光学效应的研究可以追溯到 20 世纪 50 年代初。20 世纪 70 年代以后,研究者通过光谱分析和大量的风洞试验,将研究领域扩大到探索湍流对不同波长的光传播的影响^[8],从 20 世纪 80 年代起,系统地开展了气动光学效应关键技术的研究,包括气动光学效应的机理研究、气动光学效应测试技术与仿真,如阿诺德空军基地所做的实验包括窗口、流场、应力和热效应单一因素和多因素影响下的情况^[9]。此类问题的难点在于复杂且时变的流场物理场的分析及其向折射率场的转换,兼顾大信

息量与计算速度的光学计算、图像特征提取及校正等课题,需要由计算流体力学和光学研究人员共同解决,包括理论和极端条件下的实验等方面,有些还涉及气体组分的化学变化。

激光经湍流或加热气体的传输问题包括自聚焦、内光路热效应对远场特性的影响、大气湍流效应的具体测试与仿真等。计算流体力学的方法及其基本方程和统计方法也在这里得到了应用。

在水下光传输与成像方面,以激光水下探测较具有综合性和代表性。这是伴随着 20 世纪 60 年代中后期蓝绿激光器的发展而受到关注的,目前,美国、澳大利亚等国的水下激光扫描仪等已经商品化。水下光的传播除了受到水流折射率随机变化的影响外,主要还受到水下散射光的影响。抑制散射光的方法有同步扫描技术、距离选通技术和偏振成像技术,并需进行图像处理。利用目标反射光和散射光偏振特性的不同采用偏振成像技术也可提高信噪比。目前,研究人员公认对激光水下传输的模拟应包括成像光和非成像光传输的多路径全过程,但模拟时常采用各种简化的模型,如采用蒙特卡罗方法研究被水中粒子随机散射的概率模型。此外,对脉冲激光传输的研究需要涉及时域分析。海浪对光也具有随机的作用,而且还会产生散射回波,加拿大学者已证明了海杂波的混沌特性^[10]。

对于信息链路中有随机介质的成像系统,MTF 和 PSF 仍是公认的像质评价指标。斯坦尼斯航天中心与加拿大国防研发中心合作,在受控光学环境下获取标准鉴别率板的水下激光图像,指出总 MTF 为成像系统 MTF 与水介质 MTF 的乘积^[11],这与气动光学和激光大气传输的研究一致。

4. 问题及难点

光在随机介质中的传播与成像问题所涉及的难点包括随机介质物理与光学特性的描述、光在随机介质中传输的计算方法、随机介质及其时变性对成像的影响特性与图像的校正、极端条件下的实验验证等,属于典型的多学科交叉问题。

关于随机介质物理与光学特性的描述方法,已经提出的有随机相位屏法^[12]和网格方法^[13]等;随机介质中光传输计算方法有矢量微分与积分方法、采用蒙特卡罗方法的脉动场光传输计算方法、高折射率梯度和激波层的简化算法等,另外,人们也在积极探索利用各种光学非线性技术提高光波在随机介质中的规律性行为在成像技术中的应用。同时,随机介质成像技术中,各种主动式技术也成为研究热点,随机介质成像的退化特征及自适应校正等研究也正取得不断进展。光在随机介质中的传播与成像涉及的相关数学问题有复变函数分析方法、小波分析方法、混沌及时间序列分析方法等;所涉及的化学问题有非平衡态等

极端条件下气体的化学变化等;还涉及很多的数理模型、大规模计算方法和数据结构问题,可以扩展到多种学科,并在光学上极大促进如统计光学、自适应光学、非线性光学及检测光学技术等的发展。

参 考 文 献

- [1] http://www.sciencenet.cn/m/user_content.aspx?id=297156.
- [2] 殷兴良.高速飞行器气动光学传输效应的工程计算方法.中国工程科学,2006,8(11):74—79.
- [3] 张文涛,朱保华.大气湍流对激光信号传输影响的研究.电子科技大学学报,2007,36(4):784—787.
- [4] 刘顺发,金钢,柳建,等.激光通道传输热特性对远场光束质量的影响.强激光与粒子束,2004,16(6):703—706.
- [5] 李哲,邓甲昊,周卫平.水下激光探测技术及其进展.舰船电子工程,2008,(12):8—11,48.
- [6] Шифрин К С.Введение в оптику океана.Гидрометеоиздат,1983.
- [7] 徐啟阳,杨坤涛,王新兵,等.蓝绿激光雷达海洋探测.北京:国防工业出版社,2002.
- [8] 韩志平,殷兴良.高超音速导弹气动光学效应研究方法综述.现代防御技术,2003,31(3):13—18,36.
- [9] Plemmons D,Feather B.Aero-optics effects testing in AEDC wind tunnels.AIAA,2004.
- [10] Simon H,Sadasivan P.Chaotic dynamics of sea clutter:An experimental study.IEE Conference Publication,1997,(449):75—79.
- [11] Hou W,Weidemann A D,Gray D J,et al.Imagery-derived modulation transfer function and its applications for underwater imaging.Proceedings of SPIE,2007,6696:669622.
- [12] Trolinger J,Weber D.An aero-optical test and diagnostics simulation technique.AIAA,2002.
- [13] Deng S T,Li X T,Cen Z F,et al.Simulation of the inhomogeneous medium with a self-adapting grid.Appl.Opt.,2007,46(16):3102—3106.

撰稿人:李晓彤

浙江大学光电信息工程学系

X 射线超衍射极限分辨成像研究

Ultra-diffraction Resolution Imaging in X-ray Range

1. 背景介绍

X 射线是现代分析学的重要工具,广泛应用于先进材料与生物等领域的微纳结构、元素分布、化学键状态等研究。几乎所有的硬 X 射线分析实验都需要尽量高的空间分辨率和信噪比,因此,科学家们一直努力获得更小尺度的 X 射线聚焦光斑和更高分辨率的成像。近年来,随着同步辐射光源与精密光学制造技术的发展,实验上已经突破了 10nm 的 X 射线聚焦焦斑的限制,这样的焦斑尺寸接近了其衍射极限。如何进一步缩小焦斑尺寸甚至突破衍射极限,是摆在科学家们面前的一道难题,这样的研究对于精细结构分析将具有空前的意义。

根据光与物质相互作用的机理,硬 X 射线微聚焦可以分为反射、衍射和折射三种方式。硬 X 射线反射式微聚焦采用掠入射反射光学结构,光学元件为旋转二次曲面反射镜,反射面为多层膜或单层金属的全反射表面,这种系统的分辨率主要受限于反射面的面形误差。日本科学家提出了一种适应式的反射聚焦系统,在反射聚焦光学元件前增加一块可变形的掠入射反射镜,以校正光学元件面形缺陷所导致的波像差,用 20keV 同步辐射光实现了 7nm 的焦斑^[1]。反射式聚焦元件还有毛细管、波导等形式,目前都突破了百纳米的焦斑尺寸。例如,对 20keV 同步辐射光,毛细管聚焦元件最小获得了 50nm 的焦斑,X 射线波导最小获得了 25nm 的焦斑^[2]。最常用的衍射式聚焦元件是菲涅耳波带片,其焦斑尺寸与最外环宽度有关,目前所制作的最小外环宽度可以达到 15nm,得到了约 20nm 的焦斑尺寸和小于 20nm 的空间成像分辨率图像^[3,4]。在 X 射线能段,受波带片宽高比的限制,很难制作出外环宽度小于 1nm 的波带片,因此,波带片聚焦很难获得低于纳米的焦斑。多层膜劳厄透镜是一种新型的 X 射线衍射聚焦元件,它采用沉积的方式制作周期厚度变化的多层膜,用其侧面断层作为衍射光学元件,在最佳角度下根据劳厄公式实现聚焦,目前,最小的焦斑尺寸已可达到 15nm^[5],其理论极限有望达到几纳米,甚至 1nm。此外,还存在反射式波带片聚焦元件,波带片的带状结构制作在掠入射全反射表面上,目前,该种波带片最小可以实现 15nm 的焦斑。X 射线折射元件也称为复合折射透镜,通过多个凹面镜叠加的方式放大折射元件的聚焦能力。复合折射透镜的材料通常是铝或者铍,透镜为抛物面形,透镜个数为上百个或者几百个。复合折射透镜有多

种形式,如平面抛物透镜、气泡透镜、梳齿形透镜等。复合折射透镜对材料具有较大的吸收,因此,只有在更高强度的第三代同步辐射上才能表现出较好的性能。目前,硬 X 射线复合折射透镜最小可以达到 50nm 的聚焦斑,其理论极限可以达到 5nm 以下^[6,7]。

综上所述,X 射线微聚焦与成像已经达到十几纳米甚至几纳米的水平。无论在反射、折射还是衍射方式聚焦和成像研究领域,人们都在追求逐步实现更高分辨率的成像和更小聚焦斑点的愿望,这是人们一直要达到的目标。

2. 问题描述

如何实现纳米甚至是亚纳米 X 射线超衍射极限的聚焦和成像,如何从反射、衍射、折射及其他方式来研究实现 X 射线超衍射极限聚焦和成像的物理机制和规律,提出发展 X 射线超衍射聚焦与成像的新思路。

3. 必要说明

(1) 为了获得 X 射线超衍射分辨成像与聚焦,需要找到相应的思路和方法。目前,受超精细加工水平的限制,传统方法的 X 射线成像与聚焦还没有达到衍射极限,人们还没有提出 X 射线超分辨率成像和聚焦的概念,如何实现更是没有任何方案。

(2) X 射线是否存在可能实现 X 射线超分辨率成像与聚焦,目前未有物理阐述。

(3) 为了获得 X 射线超衍射分辨率成像与聚焦,需要借鉴目前在可见光波段发展起来的超衍射分辨率方法。可见光波段超分辨率成像与聚焦方法是迅速发展的研究领域,新的概念、研究思路和研究成果不断涌现,那些能拓展到 X 射线超分辨率成像与聚焦还没有任何描述。

4. 相关扩展

当前,广泛用于先进分析研究的 X 射线辐射主要来自于大型的科学设施——同步辐射装置或 X 射线自由电子激光器,因而难以得到广泛应用。目前,关于 X 射线精细聚焦和成像的方法都是采用同步辐射实现的。如何能在采用常规 X 射线光源时也能得到极高亮度的、具有纳米量级的微聚焦 X 射线也是人们需要解决的难题。

参 考 文 献

- [1] Mimura H, Handa S, Kimura T, et al. Breaking the 10nm barrier in hard-X-ray focusing.

Nature Physics, 2010, 6:122—125.

- [2] Salditt T, Kruger S P, Fuhse C, et al. High-transmission planar X-ray waveguides. Phys. Rev. Lett., 2008, 100:184801.
- [3] Chao W, Harteneck B D, Liddle J A, et al. Soft X-ray microscopy at a spatial resolution better than 15nm. Nature, 2005, 435:1210—1213.
- [4] Rehbein S, Heim S, Guttman P, et al. Ultrahigh-resolution soft-X-ray microscopy with zone plates in high orders of diffraction. Phys. Rev. Lett., 2009, 103:110801.
- [5] Kang H C, Maser J, Stephenson G B, et al. Nanometer linear focusing of hard X rays by a multilayer laue lens. Phys. Rev. Lett., 2006, 96:127401.
- [6] Schroer C G, Lengeler B. Focusing hard X rays to nanometer dimensions by adiabatically focusing lense. Phys. Rev. Lett., 2005, 94:054802.
- [7] Evans-Lutterodt K, Stein A, Ablett J M, et al. Using compound kinoform hard-X-ray lenses to exceed the critical angle limit. Phys. Rev. Lett., 2007, 99:134801.

撰稿人：穆宝忠 王占山
同济大学物理系

红外成像高分辨率与衍射极限的矛盾问题

Contradictory Problem between Infrared Imaging High Resolution and Diffraction Limit

1. 科学问题的起源

红外探测成像具有作用距离远、抗干扰性好、穿透烟尘雾霾能力强、可全天候、全天时工作等优点，在军用和民用领域都得到了极为广泛的应用^[1,2]。红外焦平面阵列是一种集光、机、电等尖端技术于一体的红外光电探测器^[1~3]，可探测目标的红外辐射，并具有通过光电转换、电信号处理等手段将目标物体的温度分布图像转换成视频图像的功能^[1~3]。在经历第二代凝视红外焦平面探测器的充分发展和实用化后，红外焦平面探测器在以美国、法国为首的红外探测技术先进国家已进入了以大面阵、小型化和多色化等为特征的第三代红外焦平面探测器的快速发展阶段。图 1 是红外焦平面探测器的剖面结构和工作原理图。




图 1 单色、双色和多色红外焦平面探测器的剖面结构与工作原理图

为满足高级红外系统高分辨率探测的应用需求，红外探测器的像元被迫不断缩小。但是，当像元尺寸缩小到接近甚至小于 Airy 斑半径时，红外成像系统都将会遇到一个非常关键的科学问题，即很难进一步通过缩小小像元尺寸来提高红外探测的分辨率。

2. 国内外的研究现状

目前,红外成像系统的高分辨率探测要求与衍射极限之间的矛盾问题还没有得到足够的重视,这是由于在像元尺寸小于光学衍射 Airy 斑半径 r_{Airy} 时,红外探测器自身探测分辨率性能还严重受到探测像元之间的电学串音和小像元响应率低的限制。针对上述的技术问题,许多国家,尤其是美国等西方军事发达国家,都花费大量的人力、物力和财力进行此方面的研究与开发,并相继得到明显的进步。

目前,报道的 1024×1024 规模的中波红外焦平面像元尺寸已经达到 $15 \mu\text{m}$,而红外焦平面探测系统应用的光学衍射 Airy 斑半径 r_{Airy} 满足下列公式: $r_{\text{Airy}} = \frac{1.22\lambda f}{D} = 1.22\lambda \left(\frac{f}{\#} \right)$, 其中, λ 是探测的红外光波长, $\frac{f}{\#}$ 是光学系统光圈 F 数。

取 $\lambda = 5 \mu\text{m}$ 和 $\frac{f}{\#} = 3$, 可计算得到 $r_{\text{Airy}} = 18 \mu\text{m}$ 。由此可见,红外焦平面的像元尺寸已经接近、小于红外成像系统的衍射分辨极限了。并且,随着小像元尺寸的红外焦平面探测器的技术进步,亟须解决红外成像系统的高分辨率探测要求与衍射极限之间的矛盾问题。

3. 难题的解决思路

红外成像系统的高分辨率探测要求与衍射极限之间的矛盾问题是由红外成像的光学系统特点决定的。在微电子加工领域,遵循摩尔定律的集成电路特征线宽的不断缩小都是由光刻技术的进步推动的。目前,在深亚微米集成电路加工的光刻技术中,光刻机的曝光光学系统普遍采用了高介电常数材料浸没的透镜组合,这可以将光刻的衍射极限尺寸缩小 n 倍(n 为浸没材料折射率)。

基于类似的思路,我们提出了在红外焦平面探测器的前视光场处集成新结构,以缓解红外成像系统的高分辨率探测要求与衍射极限之间的矛盾,这项研究得到了国家自然科学基金(60706012)项目的支持。图 2 是我们目前提出的新构形红外焦平面探测器的剖面结构示意图。浸没式微凸镜列阵的红外焦平面探测器,不仅具有微凸镜列阵型红外焦平面探测器抑制高密度像元之间的电学、光学串音,以及提高探测的响应率的优点^[4,5],而且在红外焦平面探测器原位集成了红外镜面窗口后,还能缓解红外成像的分辨率受衍射极限的严重限制^[6],这与原位集成的红外镜面窗口将微凸镜列阵完全浸没有关。由于原位集成的红外镜面窗口将原本受微凸镜列阵与前视光场直接耦合的衍射极限,变成在原位集成的红外镜面窗口的介质内进行间接耦合,从而能进一步减小受衍射极限限制的微凸镜列阵型红外焦平面光敏元尺寸。




图2 原位集成浸没式微凸镜列阵的红外焦平面探测器的剖面结构示意图和工作原理图

例如,当红外镜面窗口的折射率为 $n_{\text{红外镜面窗口}}$ 时,红外探测器受衍射极限限制的像元尺寸可缩小为没有集成红外镜面窗口的红外探测器像元几何尺寸的 $1/n_{\text{红外镜面窗口}}$,即红外成像的分辨率可以提高 $n_{\text{红外镜面窗口}}$ 倍,这对缓解红外成像的高分辨率要求与衍射极限限制之间的矛盾问题而言显得尤为重要。

4. 解决难题的瓶颈技术

为获得浸没式微凸镜列阵的红外焦平面探测器,以缓解红外成像的高分辨率要求与衍射极限限制之间的矛盾问题,需要解决如下一些关键技术:

首先,红外探测器新构形结构的优化设计。根据红外探测器膜系材料的特性,理论研究红外光波函数在介质镜面窗口、衬底微镜、光敏感吸收区及其界面的光传输机理,创新地建立探测芯片与光场耦合的光传输模型,确定合适的红外镜面窗口的材料,并设计与红外探测器兼容的微镜列阵和红外镜面窗口的优化结构。

其次,红外探测器正反双面的高精度对准和光刻。为使微镜列阵真正起到预期设计的效果,必须确保红外探测芯片的各个像元中轴线与选增透微透镜的中轴线重合,而且与像元尺寸一致,这给在紫外、可见光都不透明的红外探测器正反双面的高精度对准和光刻提出了新的挑战。

再次,在红外探测器光耦合界面进行会聚微镜列阵的原位集成加工技术。为通过微机械加工的刻蚀技术获得优化结构的微透镜列阵,必须解决组合刻蚀工艺的掩膜,以及等离子体刻蚀角度和样品旋转速率的工艺参数优化等相关

难题。

最后,在微镜列阵上制作红外镜面窗口的加工技术,该技术目前还没有清晰的实现方法。

参 考 文 献

- [1] Rogalski A, Antoszewski J, Faraone L. Third-generation infrared photodetector arrays. J. Appl. Phys., 2009, 105(09).
- [2] Rogalski A. Infrared detectors; Status and trends. Progress in Quantum Electronics, 2004, 27: 59—210.
- [3] Bratt P R, Johnson S M, Rhiger D R, et al. Historical perspectives on HgCdTe material and device development at raytheon vision systems. Proceedings of SPIE, 2009, 7298: 72982.
- [4] 叶振华, 陆伟, 黄建, 等. 一种原位集成浸没式微凸镜列阵的红外焦平面探测器: 中国, 201010182364.8. 2010-11-24.
- [5] 叶振华, 周文洪, 廖清君, 等. 带有增透会聚微镜的红外焦平面探测器及微镜制备方法: 中国, 200610118053.9. 2007-04-18.
- [6] 叶振华, 周文洪, 胡晓宁, 等. 背向集成微透镜红外焦平面探测器及微透镜的制备方法: 中国 200610117106.5. 2007-03-21.

撰稿人: 叶振华 林 春 胡晓宁 丁瑞军 何 力
中国科学院上海技术物理研究所

远场超分辨成像

Far-field Super-resolution Imaging

光经过圆形口径后成像，并不会汇聚成绝对的点，而是形成明暗相间、距离不等的同心圆光斑，其中，中央斑最大，集中了 84% 的能量，可以看作衍射扩散的主要部分，被称为 Airy 斑，如图 1 左上角所示。由于每个物点的像就是一个弥散斑，两个弥散斑靠近后就不易被区分，因而限制了光学系统的分辨率，光斑半径越大，分辨率越低，这个限制是物理光学的限制，是光的衍射造成的，一般称之为光学 Rayleigh 衍射极限。Rayleigh 判据的定义是：如果两个相邻点形成的 Airy 斑的角距离小于一个 Airy 斑角距离时，这两个点无法分辨，图 1 所示为形象表述光学上可分辨、勉强分辨及无法分辨的两个物点的成像光斑^[1]。对于常规光学显微物镜，其分辨率定义为 $R=0.61/(\lambda NA)$ ， λ 为入射光波长，NA 为物镜的数值孔径。




图 1 光学衍射极限

所谓超分辨成像，就是实现超越显微系统分辨率的成像技术。目前，常用的实现超分辨的手段为利用超分辨的光学虚拟探针逐点扫描方式成像，如近场扫描光学显微镜 (near-field scanning optical microscopy, NSOM)^[2]，它利用亚波长尺度的光纤探针逐点扫描被测样品，通过所得的二维矩阵数据构造出样品光学像，由于所用的探针为超分辨尺度，且探针位于被测物体的近场区域，因而可以获得物体倏逝场的信息，实现超分辨成像。对于这种近场扫描成像方式，

存在两个问题：①探针必须位于被测物体的近场区域，因此，它是一种近场成像方式。探针和样品表面之间的近场距离控制对整个系统稳定性要求较高。

②逐点扫描的方法不可避免地存在成像区域小、成像速度慢的缺陷。

德国马克斯-普朗克学会生物物理化学研究所所长 Hell 提出的受激发射损耗显微技术(stimulated emission depletion, STED)克服了 NSOM 近场成像的缺陷,是一种远场成像技术,它无需精确控制样品与光学虚拟探针之间的距离。其基本原理如图 2 所示,紫色代表的是激发激光,绿色代表的是用来受激发射损耗的激光,两束激光经过时间空间调制后同时照射在样本上。激发光使荧光物质发光的同时,STED 激光发射一束紧挨着的、环形的、波长较长的激光将激发光斑中大部分的荧光物质通过光学非线性作用被强行回到基态抑制其发荧光,从而减少荧光发射光斑面积。激发光光斑经 STED 激光的调制后大大减少了发射荧光分子的光斑大小(蓝色),并且随着 STED 激光光强的增加,能发射荧光光斑越小,其半高全宽可以达到衍射极限以下,分辨率不再受光的衍射所限制,从而打破衍射极限^[3]。




图 2 STED 打破光学衍射极限原理示意图

目前,STED 的分辨率可以达到 15nm,远远小于常规共聚焦光学显微镜的 200nm 分辨率极限。STED 技术所带来的里程碑式的超分辨效果无疑给单分子探测等应用带来了更广阔的发展机遇。虽然 STED 克服了 NSOM 近场成像的缺陷,但它本身也存在如下 5 个方面的不足:①光路复杂,设备昂贵,对系统的稳定性要求很高;②被测样品必须做荧光标记;③采用的也是逐点扫描成像方式;④理论上,无限的分辨率事实上是有限的,因为在追求高分辨的同时也增大了荧光漂白,从而降低成像质量;⑤为了达到 STED 效果,STED 激光的光强密度要比激发光高出 1000~10000 倍,甚至更高,而如此高的光强对大部分生物样品是一个致命的损伤。因此,STED 并不能如传统光学显微镜一样,物体无需

做任何标记即可一次宽场成像。

发展无标记、远场超分辨、宽场成像技术的一个充满希望的媒质是表面等离子体(surface plasmons, SPs),它是近年来纳米光子学中的热点研究对象^[4]。SPs 具有表面增强、近场局域及短波长三个基本物理特性。SPs 的表面增强效应可以提高物体的非线性响应,通过诸如双光子成像的方式提高分辨率,亦有可能利用局域场增强效应激发被测物体的自身荧光,实现无标记成像。SPs 的近场局域特性揭示它必定含有物体更精细的结构信息,因此,通过捕捉它可以得到超分辨率的物体结构信息,实现超分辨成像。从显微镜的分辨率公式可以看到,提高分辨率的一个手段是利用短波,而 SPs 恰好具有短波特性和局域特性,因此,利用 SPs 这个媒质,而不是常规的传播波,或荧光物质,有望实现超分辨无标记宽场成像。但是,如何在同一系统中充分利用 SPs 这三个基本优点,发展无标记、普遍适用的远场超分辨宽场成像技术则是当前显微成像研究必须解决的难题。

参 考 文 献

- [1] Harris T D, Grober R D, Trautman J K, et al. Super-resolution imaging spectroscopy. *Applied Spectroscopy*, 1994, 48(1): 14A—21A.
- [2] Betzig E, Trautman J K, Harris T D, et al. Breaking the diffraction barrier: Optical microscopy on a nanometric scale. *Science*, 1991, 22: 1468—1470.
- [3] Hell S W, Wichmann J. Breaking the diffraction resolution limit by stimulated emission: STIMULATED-emission-depletion fluorescence microscopy. *Opt. Lett.*, 1994, 19(11): 780—782.
- [4] Barnes W L, Dereux A, Ebbesen T W. Surface plasmon subwavelength optics. *Nature*, 2003, 424: 824—830.

撰稿人: 袁小聪¹ 张斗国² 明 海² 匡翠方³ 刘 旭³

1 南开大学现代光学研究所

2 中国科学技术大学物理系

3 浙江大学光电信息工程学系

基于光场量子态的量子信息研究

Investigation of Quantum Information Based on Quantum States of Light Field

1. 背景介绍

量子信息科学是量子物理与信息科学交叉融合而迅速发展起来的新兴前沿学科, 由于它可以提供在原理上绝对安全的量子通信和巨大的量子计算并行处理能力, 致使各国政府和科技界展开这一前沿领域的研究与探索。量子光学是现代物理学中重要的基础学科之一, 光和原子(分子)组成系统在物理上易于控制, 因此, 光作为量子信息载体, 原子用于量子信息存储, 光与原子之间量子态的传递(量子接口)就成为目前被广泛研究的对象。连续变量量子通信具有独特的技术优越性, 利用量子光学的成熟技术可以高效率地完成量子通信的全过程, 同时亦能为量子通信提供大频带宽度。在物理上, 连续变量纠缠态光场具有“无条件性”特点, 即探测到纠缠具有确定性。特别值得注意的是, 除量子比特之外, 量子连续变量已经作为发展量子通信和信息处理的一种新颖的工具出现, 它利用量子化光场正交位相振幅分量代替标准量子比特概念, 这种代替在某些特定方面具有可能超越建立在量子比特之上信息处理的潜力。量子纠缠是量子信息的重要资源, 量子纠缠态光场的产生、控制、传输和测量在量子信息和量子计算的发展中扮演了十分重要的角色, 虽然经过了近二十年努力并取得了很好进展, 但对实现量子通信和量子计算机这一目的来讲, 还有许多重要物理和技术问题亟待研究和解决。

2. 问题描述

目前, 连续变量量子信息科学领域关心的问题是: 如何从实验上构建稳定、可扩展、易操控的量子信息处理物理系统, 获得新的核心技术及探索量子态光场和原子、分子的相互作用可能产生的量子信息处理的新思想和新方法。

(1) 光场压缩态、纠缠态制备是研究连续变量量子信息的重要基础, 随着量子信息远程传送、量子信息网络化及量子计算机发展的迫切需求, 人们需要从源头入手, 研究并提高非经典光场的压缩度、纠缠度及光源的稳定度, 使其达到实用化的水平, 同时, 要扩展其波段以达到和原子吸收线及光通信波段相

匹配。

(2) 在量子网络中, 必须要将在局域地产生的量子纠缠分配到空间分离的各用户处, 在此过程中, 量子系统必然要经由噪声通道传输, 传输损耗和相散是不可避免的。这些因素将破坏量子纠缠, 导致量子纠缠度随传输距离的增加而很快降低。如果不采取措施, 远距离量子通信就不可能实现, 因此, 重新恢复甚至提高因损耗而降低的纠缠, 即进行纠缠纯化就成为一个必须解决的关键问题。当然, 仅仅利用纠缠纯化并不能完全解决长距离量子通信的问题, 进一步解决这一问题还需要建立光与原子间的量子接口, 实现量子中继。在量子中继中, 首先将信道划分为若干个短区间, 然后借助光场将每个小区间两端的原子制备到纠缠态; 借助量子存储, 所有原子纠缠态得以存储和保持; 利用纠缠交换最终把处于长距离两端, 即信息发送端和接收端的两个原子纠缠起来, 从而完成纠缠态在超长距离上的分发。

3. 必要说明

光场压缩态、纠缠态制备是研究连续变量量子信息的重要基础。美国 Kimble 实验室在获得光场压缩态的基础上, 于 1992 年利用压缩真空态获得 EPR 纠缠光束, 其纠缠度为 3.6dB ^[1]。随着量子信息远程传送、量子信息网络化及量子计算机发展的迫切需求, 人们开始从源头入手, 研究并提高压缩光源的压缩度。最近, 德国 Vahlbruch 等利用 $\text{MgO}:\text{LiNbO}_3$ 晶体构成整块光学参量振荡器(OPO)获得波长为 $1.06\mu\text{m}$ 、压缩度为 10dB 的单模压缩态光场^[2]。

山西大学光电研究所于 1997 年利用 540nm 全固态连续单频激光泵浦 KTP 晶体构成的半整块腔得到 3.7dB 双模真空压缩态光场。最近, 在同样装置上获得 6dB 纠缠度的纠缠光束^[3]。目前, 国内外的关注都集中在如何得到稳定的高纠缠度的光源及与原子吸收波段和光通信波段相匹配的可用多色纠缠源, 对于连续变量的 $1.5\mu\text{m}$ 和 795nm 可调谐“双色”纠缠源制备还处于起步阶段, 山西大学量子光学与光量子器件国家重点实验室进行了 $1.5\mu\text{m}$ 量子纠缠源的探索研究^[4]。在国内, 大多数单位从事理论方面研究工作, 而实验工作主要集中在分离变量的纠缠源研究和用上。

目前, 实现连续变量量子通信的最大困难是量子系统在传输过程中的退纠缠, 如何克服这个困难, 各国科学家提出了不少理论方案, 用以实现量子纠缠纯化。在连续变量领域, 2000 年, Duan 等提出连续变量纠缠纯化的理论和实验方案^[5], 2005 年, 德国 Andersen 等实验实现了相干态纯化^[6]。2002 年, 捷克 Fiurasek 等指出, 如果是对一个非高斯态进行操作, 即使只有高斯操作也可以完成纠缠态的量子纯化, 并在此基础上提出一个简易可行的实验方案。基于这一理论方案, 德国 Hage 和 Dong 等分别从实验实现了连续变量量子纠缠态的纠

纠缠纯化,但在他们的实验中,都是首先完成对所有光束的测量,然后通过后续选择来检测是否达到纠缠纯化的目的^[7],因此,他们纯化后的输出态不能应用于后续实验中。在纠缠纯化这个概念被提出后,国内有不少研究组从事纠缠纯化的理论和实验研究,但多数是在分离变量领域进行的。

长距离量子通信不仅要求纠缠态光场的纯化,而且要求实现光场与原子的量子态传递(接口),通过光与原子量子接口实现光场量子信息在原子中的存储,进而完成量子中继。实现量子接口,光与原子必须具备强耦合作用。由于光子传播速度快,与原子的作用时间短,因此,在通常条件下很难实现强耦合。近年来,EIT 光减速技术为量子信息存储提供了有效工具。2004 年,丹麦 Polzik 研究组使用热原子作 EIT 介质,演示了一个相干态光场连续变量的量子存储实验^[8]。2008 年,日本 Honda 等在冷原子中通过 EIT 动力学过程进行了真空压缩态光场的存储与释放实验,恢复的信号压缩度仅为输入信号的 1.6%^[9]。山西大学利用腔内 EIT 介质实现了光学信号存储,并利用 EIT 强色散效应实现了光减速、光量子信号的存储与双通道释放^[10]。与分离变量量子存储相比,连续变量的量子接口研究相对落后,其中,许多问题(如长寿命存储、任意偏振方向的光场存储)的研究有待深入发展。

参 考 文 献

- [1] Ou Z Y, Pereira S F, Kimble H J, et al. Realization of the Einstein-Podolsky-Rosen paradox for continuous variable. *Phys. Rev. Lett.*, 1992, 68: 3663.
- [2] Vahlbruch H, et al. Observation of squeezed light with 10dB quantum-noise reduction. *Phys. Rev. Lett.*, 2008, 100: 033602.
- [3] Wang Y, Shen H, Jin X L, et al. Experimental generation of 6dB continuous variable entanglement from a nondegenerate optical parametric amplifier. *Optics Express*, 2010, 18: 6149.
- [4] Feng J X, Tian X T, Li Y M, et al. Generation of a squeezed vacuum at a telecommunication wavelength with periodically poled LiNbO₃. *Applied Physics Letters*, 2008, 92: 221102.
- [5] Duan L M, Giedke G, Cirac J I, et al. Entanglement purification of gaussian continuous variable quantum states. *Phys. Rev. Lett.*, 2000, 84: 4002.
- [6] Andersen U L, Filip R, Fiurášek J, et al. Experimental purification of coherent states. *Phys. Rev. A*, 2005, 72: 060301.
- [7] Dong R, et al. Experimental entanglement distillation of macroscopic quantum states. *Nature Physics*, 2008, 4: 919.
- [8] Julsgaard B, Sherson J, Cirac J I, et al. Experimental demonstration of quantum memory for light. *Nature*, 2004, 432: 482.
- [9] Honda K, Akamatsu D, Arikawa M, et al. Storage and retrieval of a squeezed vacuum. *Phys.*

Rev .Lett .,2008 ,100 ;093601 .

- [10] Chang H ,Wu H B ,Xie C D ,et al .Controlled shift of optical bistability hysteresis curve and storage of optical signals in a four-level atomic system .Phys .Rev .Lett .,2004 ,93 ;213901 .

撰稿人：张宽收 彭堃堉

山西大学量子光学与光量子器件国家重点实验室

量子态的制备、操控和精密测量

Preparation, Controlling and Measurement of Quantum States

利用非线性过程和光与原子相互作用可以产生各种形式的量子纠缠,已发展为研究光场量子特性和执行量子信息处理的一种有效工具。非经典光场态,如光场压缩态和纠缠态,展示了光场和原子的量子特性,已被应用于量子测量^[1]与量子信息处理系统。这方面的问题主要包括:①空间纠缠^[2]和量子成像。量子成像是量子光学最近几年发展起来的,其在光学图像的低噪声处理、物理极限精度的精密测量等方面有重要的意义。量子成像主要研究高阶横模非经典光场实现突破经典光源量子噪声设定的成像精度极限,即亚散粒噪声图像,实现光学图像放大,这方面需要发展高阶横模压缩器和多横模压缩器。②多光子态的量子效应。在多光子态中研究高阶相干性,构造复杂结构的量子纠缠。使用多光子态进行超越量子标准量子极限的测量问题,亚量子噪声测量、光子数可分辨的探测、量子传感、量子印刷、各种量子态在精密测量中的应用。

光与物质相互作用一直是量子光学中重要的研究内容。探索受限光子-原子相互作用,利用其相互作用操控原子,实现原子量子态的制备、测量、控制和应用是重要的前沿科学问题^[3],也是在微观和介观层次上完全控制原子运动状态,进而实现量子信息处理、发展相关的量子控制手段和关键量子器件的重要物理基础。腔量子电动力学(CQED)是研究原子-光场相互作用最基本的物理系统,主要研究并控制受限在特定空间的光场与物质相互作用的量子现象。

量子光学研究的光与物质相互作用中过程,过去主要是基于光与稀薄原子气体或单个原子相互作用的系统,这是因为在这些系统里原子的量子性非常显著。近年来,随着加工与实验技术的发展,越来越多的光与物质相互作用系统需要用量子光学方法研究,而且这些研究不断揭示出一些新奇有趣的现象,主要有以下方向:①固态量子系统与光的相互作用。在特殊加工或极端条件下的固体系统中可以出现像原子一样具有分立能级的量子体系,如量子点、超导约瑟夫森结、纳米振子等,这些体系与光相互作用时可以获得许多新的相干物理现象甚至宏观量子现象。通过光场可以操纵这些体系的状态,并实现一些相干物理现象,如 Rabi 振荡、EIT 现象。②固体微腔^[4]中光与原子强耦合相互作用的获取。光学微腔具有高品质因子和低模式体积等优点,提高了局域光场密度,大大增加了光场与原子、量子点等物质之间的相互作用强度,已经成功用于激光的产生和量子信息操作中,同时又能在各种量子 and 经典测量中。微腔有很多

实现方式,如镜面腔、固体微球腔、固体微盘腔、微芯圆环腔、光子晶体腔等。其中,固体微球腔和微盘腔是很有特色的发展方向。在这个相互作用体系中,获取强耦合是其中关键的研究目标。③metamaterial 中光与物质相互作用的量子现象研究。随着加工技术的发展,各种人工设计结构不仅在几何结构上(如光子晶体)^[5]或介质选取上(如表面等离子体激元)^[6]单独设计,而且可以把几何结构与介质的电磁性质综合裁剪设计出更为复杂的人工材料,这些材料为光与物质相互作用提供了更为奇特的环境,从而为发现更多的物理现象提供了实验平台。

如何在实验上实现这些可控的相干相互作用,进而构造可用的量子器件并能够完成量子态的制备、操控和测量成为一个很重要的物理问题。

参 考 文 献

- [1] Clerk A A ,Devoret M H ,Girvin S M ,et al .Introduction to quantum noise ,measurement , and amplification .Reviews of Modern Physics ,2010 ,82 ;1155 .
- [2] Sensarn S ,Yin G Y , Harris S E . Observation of nonlocal modulation with entangled photons .Phys .Rev .Lett . ,2009 ,103 ;163601 .
- [3] Cronin A D ,Schmiedmayer J ,Pritchard D E .Optics and interferometry with atoms and molecules .Reviews of Modern Physics ,2009 ,81 ;1051 .
- [4] Blais A ,Gambetta J M .Filling a cavity with photons ,and watching them leave .Physics , 2008 ,1 ;39 .
- [5] Istrate E ,Sargent E H .Photonic crystal heterostructures and interfaces .Reviews of Modern Physics ,2006 ,78 ;455 .
- [6] Marklund M ,Shukla P K .Nonlinear collective effects in photon-photon and photon-plasma interactions .Reviews of Modern Physics ,2006 ,78 ;591 .

撰稿人：张永生 郭光灿

中国科学技术大学量子信息重点实验室

基本物理问题的量子光学检验

Test of Fundamental Physical Problems with Quantum Optical Methods

量子光学系统由于具有非常好的相干性、可控性,并且具有非常好的测量手段,可以作为许多重要基础物理问题的检验平台。测量问题始终是量子力学的基本问题之一。用量子光学方法研究包括量子测量问题在内的若干基本问题是非常有效的方法。在过去几十年中,人们已经取得了辉煌的成绩,包括贝尔不等式、CHSH 不等式、GHZ 态、腔 QED 中的退相干测量及量子纠缠导致的波函数塌缩、量子非破坏测量等,人们已经用若干量子光学实验验证了一些量子非定域、量子纠缠等量子力学现象,用量子光学手段检验量子物理的若干基本问题依然是量子光学的重要研究方面。量子测量问题与量子计量密切相关,这方面的发展可望在亚标准量子噪声测量、高分辨空间和时间成像、超灵敏探测等方面获得实际应用。这方面的研究包括以下几个方面:

(1) 量子力学基本问题的检验。量子力学对物理实在的描述是否完备,是否存在可能的隐变量理论?目前,这些问题在实验上的裁决最好的实验平台就是量子光学系统。量子光学方法曾经对局域隐变量理论(如贝尔不等式)^[1]、环境无关隐变量理论给予了实验验证,对于其他一些隐变量问题、非局域性问题等量子力学基础问题还有可能给出更多的实验结果。量子测量的基本问题,对量子纠缠、量子非局域、量子非破坏测量、量子 Zeno 和反 Zeno 效应等,这些检验有望大范围从光子拓展到有质量的物质粒子甚至介观物质上。

(2) 物理学基础问题的检验^[2]。量子光学系统良好的相干性和可控性为一些基础物理问题提供了实验平台,如基于 EIT 现象的慢光(停光)系统模拟黑洞视界现象;超冷原子捕获技术进行基本粒子永电矩的测量,对标准模型进行检验。

(3) 针对凝聚态体系的量子模拟。凝聚态体系由于物理系统的复杂性,许多理论模型问题无法求解,而且很难在实际物理系统中直接观察模型的机制。量子光学系统良好的可控性可以提供这些模型的实验模拟,检验其有效性。模拟体系如光晶格体系中的超冷原子体系^[3]、多腔 CQED 等。

(4) 真空引起的各种可观察效应。Casimir 效应^[4]、Unruh 效应、Lamb 移动等,这些效应在一些新的环境下的新效应。

实际量子系统都不可能是完全封闭的系统,总是要与周围的环境相互作用,

甚至周围的环境是真空态,环境对研究系统的影响也是始终存在的。所以,研究开放体系的问题对量子光学体系的研究有重要的意义,而且由于量子光学体系具有很好的可控性和许多有效的测量手段,可以在量子光学体系里细致地研究开放体系的具体演化过程。

(1) 相干性消失过程的研究和对消相干过程的抑制^[5]。环境对量子系统的影响直接导致量子系统的相干性被破坏,如何有效地刻画、计算这一过程和在量子光学系统里观察这一过程并检验理论模型的有效性是其中的核心任务。通过消相干过程的研究寻找抑制消相干的方法。

(2) 量子与经典的界限的探索。量子力学与经典物理的描述往往大相径庭,这就需要解决以下两个问题:这两个迥然不同的物理描述如何过渡并衔接起来?量子行为与经典行为的界限在哪里?

(3) 量子测量与消相干过程关系的研究^[6]。量子力学中存在么正演化和测量两个截然不同的过程,一个是可逆的保持相干性的,另一个是不可逆的破坏相干性的。量子测量中,如何通过外部观察者影响系统,量子测量与消相干过程如何建立联系,如何通过量子光学过程观察这一联系是这项研究的目标。研究非标准冯·诺依曼测量中测量与消相干过程的关系。

(4) 光场相干操纵量子系统的有效性研究^[7]。经典光场作为高效的相干源可以通过 Rabi 振荡等技术实现对量子系统(如原子内态)的相干操纵,但光场毕竟是一个量子体系,在与系统相互作用时会与系统纠缠起来,从而影响系统的相干性(如崩坍-复原现象),这种影响到底有多大,光场在什么情况下可以作为经典相干光源有效的操纵量子体系。在其他一些量子光学过程中,光场的经典与量子界限如何划分,都是值得研究的课题。

参 考 文 献

- [1] Reid M D, Drummond P D, Bowen W P, et al. The Einstein-Podolsky-Rosen paradox: From concepts to applications. *Reviews of Modern Physics*, 2008, 81: 1727.
- [2] Bradley R, Clarke J, Kinion D, et al. Microwave cavity searches for dark-matter axions. *Reviews of Modern Physics*, 2003, 75: 777.
- [3] Bloch I, Dalibard J, Zwierger W. Many-body physics with ultracold gases. *Reviews of Modern Physics*, 2008, 80: 885.
- [4] Klimchitskaya G L, Mohideen U, Mostepanenko V M. The Casimir force between real materials: Experiment and theory. *Reviews of Modern Physics*, 2009, 81: 1828.
- [5] Jacquot P, Petitjean C. Decoherence, entanglement and irreversibility in quantum dynamical systems with few degrees of freedom. *Advances in Physics*, 2009, 58: 67.
- [6] Jacobs K, Steck D A. A straightforward introduction to continuous quantum measurement.

Contemporary Physics ,2006 ,47 ;279 .

- [7] Lambropoulos P ,Nikolopoulos G M ,Nielsen T R ,et al.Fundamental quantum optics in structured reservoirs .Rep .Prog .Phys .,2000 ,63 ;455 .

撰稿人：张永生 郭光灿

中国科学技术大学量子信息重点实验室

弱光非线性效应

Nonlinear Optics at Weak Light

1. 背景介绍

传统意义下,介质的非线性光学效应主要是在强光作用下才显示出来的,随着激光技术的发展,强光非线性光学研究获得了极大的成功^[1,2]。然而,正如人们对物质世界的认识向着宏观和微观两个极端方向发展,对光学非线性效应的认识也正向着强光和弱光两个方向发展并不断深入。事实上,很多材料体系,如光折变材料体系、量子相干体系、纳微结构体系及生物光子学材料等,在毫瓦量级甚至于在单光子的水平上就可以显现出非常强的光学非线性效应。新型弱光非线性材料、效应、光调控原理和技术的发展,不仅使得人们需要重新审视光与物质相互作用的机理和方式,而且其在光的局域、光控光及光子学功能器件的微型集成化等方面的应用与发展,对于信息、能源和国家安全等方面具有重要的现实意义。

2. 问题描述

众所周知,强光非线性只有在光场的电场强度与原子的束缚内电场相当或者更强的条件下才会显著地表现出来。在此条件下,光场将引起介质中原子电子云的畸变,从而改变介质的折射、吸收及极化强度等光学性质,介质光学性质的改变反过来又影响和改变在其中传播的光波的偏振、强度及频率等光场性质。激光光源的高度相干性和高光强特性为强光非线性光学的研究和发展铺平了道路,因此,强光非线性光学的发展总是和激光技术的发展紧密相连的。随着对光与介质相互作用认识的不断深入,人们发现,诸如量子输运、量子相干、慢光及光场局域增强等效应,这些以光波和介质的光学性质的改变为特征的非线性相互作用,即使在毫瓦量级甚至于在单光子水平的弱光条件下也可以产生。弱光非线性效应的发现使得光学非线性不再是激光的专利效应,在适当条件下,低强度非相干光也可以产生强的光学非线性效应,从而大大丰富了非线性光学的内涵和范畴。

强光非线性光学已经建立了较完善的统一理论体系,无论是经典描述还是量子描述^[1,2]。然而,到目前为止,对于弱光非线性效应的各种产生机制,人们尚未建立统一的理论体系对之进行定量描述,这在一定程度上阻碍了弱光非线性

性光学的快速发展。

3. 必要说明

在 20 世纪 60 年代激光发明之后不久, Franken 及其合作者在石英晶体中观测到倍频效应, 宣告了具有现代意义的非线性光学的诞生^[3]。几乎是在同一时期, 以光折变效应为典型代表的弱光非线性效应在贝尔实验室中被观测到^[4]。然而, 在其后相当长的时间内, 弱光非线性效应的发展相对来说比较缓慢。直到 20 世纪 90 年代, 基于量子相干效应的电磁感应透明、慢光和光场局域增强等一系列效应的提出, 以及宏观量子相干体系和介观关联周期结构体系的成功制备, 为弱光非线性光学的快速发展奠定了基础。

1999 年, 哈佛大学 Hau 领导的研究小组利用电磁感应透明效应在超冷钠原子气体中将光速降低到 17m/s ^[5], 这是人类第一次将光的传播群速降到可与自行车的行进速度相比。此后不久, 人们利用量子相干效应将光脉冲完全停顿下来并存储在介质中, 在一段时间之后, 又可以将存储的光脉冲信息读取出来, 实现了光脉冲的存储和复现。最近, 基于单光子或者少光子的二维光学图像存储亦已经见诸报端^[6,7]。

由于慢光与介质之间的相互作用大大增强, 从而为实现弱光甚至单光子水平的光学非线性创造了条件, 目前, 已经在慢光机制下观测到了原子体系非线性效应成百万倍的增强^[5,8]。群速可控的慢光技术也使光脉冲与其他固体元激发之间的匹配耦合成为可能, 为研究光与固体元激发之间的非线性耦合和相互作用开创了新的篇章。由于慢光在光缓存、光延迟线、光存储、光开关及高灵敏度光探测等方面的潜在应用价值, 各种光速调控技术, 尤其是在固体介质中的慢光技术得到了迅猛的发展^[9~12]。

激光技术对于非线性光学发展的促进作用及两者之间的密切联系, 使得人们早已形成了只有激光才能激发介质光学非线性的传统认识, 然而, 非相干光的非线性光学效应的发现打破了激光在非线性光学研究中的垄断地位。在 20 世纪 90 年代后期, *Nature* 和 *Science* 先后分别报道了利用光折变非线性实现时空非相干的白光非线性“自陷”效应, 即白光空间光孤子的传输, 开启了非相干光的光学非线性效应的研究^[13,14]。非相干光的非线性效应的一个成功应用典范是利用部分相干光的非线性效应可以制备出稳定的介观关联周期结构体系——光子学晶格体系, 从而为研究光在离散体系中的传播性质提供了一个极佳的实验平台^[15,16], 该体系不仅在光控光和光信息处理等方面有潜在的应用前景, 而且在理解自然界中其他离散体系, 如生物分子链和玻色-爱因斯坦凝聚体中的周期光学势阱中的波传播规律具有重要启发意义。2007 年, 以色列科学家 Segev 领导的研究组在光子学晶格体系中可控地引入了适度的晶格无序, 首次明确地

在该体系中观测到光场(可见光波段)的横向 Anderson 局域效应^[17]。

毋庸置疑,这些具有里程碑性质的代表性成就充分说明了弱光非线性光学已经逐步形成独具特色的研究领域,具有极高的实际应用价值,并进入快速发展阶段。同时,我们也应该注意到,弱光非线性效应的产生机制多种多样,虽然各自存在相应的理论进行定量描述,但人们尚未形成能够定量描述所有弱光非线性效应的统一理论体系,在一定程度上也说明我们对于弱光非线性效应的认识仍然处于初级阶段,这无疑会对新型弱光非线性材料的研发,新型弱光非线性机制和效应的发现和调控,以及弱光非线性效应应用领域的拓展产生消极的影响。

4. 相关扩展

弱光非线性效应具有低功耗和高灵敏度的特点,因此,在微型集成化光子学器件的应用方面独具优势。然而,也正是由于其在弱光条件下工作,一般情况下,其响应速度相对来说不够快。随着高 Q 值微腔、波导等纳微结构材料体系的制备技术的发展,结合光场局域增强效应和慢光非线性增强效应,其响应速度应当可以得到大幅提高。新型弱光非线性材料、机制、效应及器件应用的发展,必将进一步丰富弱光非线性光学的内容。

参 考 文 献

- [1] Shen Y R. The Principle of Nonlinear Optics. New York: Wiley, 1984.
- [2] Sutherland R L. Handbook of Nonlinear Optics. 2nd ed. New York: Marcel Dekker, Inc., 2003.
- [3] Franken P A, et al. Generation of optical harmonics. Phys. Rev. Lett., 1961, 7: 118—119.
- [4] Ashkin A, et al. Optically-induced refractive index inhomogeneities in LiNbO_3 and LiTaO_3 . Applied Physics Letters, 1961, 9: 72—74.
- [5] Hau L V, et al. Light speed reduction to 17 metres per second in an ultracold atomic gas. Nature, 1999, 397: 594—598.
- [6] Liu C, et al. Observation of coherent optical information storage in an atomic medium using halted light pulses. Nature, 2001, 409: 490—493.
- [7] Camacho R M, et al. All-optical delay of images using slow light. Phys. Rev. Lett., 2007, 98: 043902.
- [8] Fleischhauer M, et al. Electromagnetically induced transparency: Optics in coherent media. Reviews of Modern Physics, 2005, 77: 633—673.
- [9] Krauss T F. Why do we need slow light? Nature Photonics, 2008, 2: 448—450.
- [10] Boyd R W, Gauthier D J. Controlling the velocity of light pulses. Science, 2009, 326: 1074—1077.

- [11] Bigelow M S, et al. Superluminal and slow light propagation in a room-temperature solid. *Science*, 2003, 301: 200—202.
- [12] Zhang G, et al. Phase-coupling-induced ultraslow light propagation in solids at room temperature. *Phys. Rev. Lett.*, 2004, 93: 133903.
- [13] Mitchell M, Segev M. Self-trapping of incoherent white light. *Nature*, 1997, 387: 880—883.
- [14] Chen Z, et al. Self-trapping of dark incoherent light beams. *Science*, 1998, 280: 889—892.
- [15] Fleischer J W, et al. Observation of two-dimensional discrete solitons in optically induced nonlinear photonic lattices. *Nature*, 2003, 422: 147—150.
- [16] Christodoulides D N, et al. Discretizing light behaviour in linear and nonlinear waveguide lattices. *Nature*, 2003, 424: 817—823.
- [17] Schwartz T, et al. Transport and Anderson localization in disordered two-dimensional photonic lattices. *Nature*, 2007, 446: 52—55.

撰稿人：张国权 孔勇发 孙 骞 张心正 许京军
南开大学物理科学学院

新型高效红外非线性光学晶体

Novel and Highly Efficient Infrared Nonlinear Optical Crystals

1. 背景介绍

根据红外辐射在地球大气层中传输特性的不同,可将红外波段划分为近红外($0.75\sim 3\mu\text{m}$)、中红外($3\sim 6\mu\text{m}$)、远红外($6\sim 20\mu\text{m}$)、极远红外($20\sim 1000\mu\text{m}$)。另外,由于大气对红外辐射的吸收,只留下三个重要的“窗口区”,即 $1\sim 3\mu\text{m}$ 、 $3\sim 5\mu\text{m}$ 和 $8\sim 12\mu\text{m}$,因而在军事应用上,又分别将这三个波段称为近红外、中红外和远红外。红外技术在军事上具有非常重要的应用,如激光制导、激光定向红外干扰、激光通信、红外遥感、红外热像仪、红外测距、激光瞄准等。红外技术在工业、医学和科学研究等许多方面也广为使用,如热源探测、医用热像仪、温度测量与过程控制、红外光谱分析、生物、医药、红外加热干燥、红外遥感等。中远红外相干光源对于红外技术的发展和具有非常重要的意义,目前,获得红外光源的途径主要有^[1~3]:①通过非线性光学晶体对长波红外激光进行倍频或三倍频(如 CO_2 激光倍频);②采用光学参量振荡技术(OPO)通过频率下转换技术将短波红外调谐到中波红外;③直接辐射中波红外的半导体激光器,如以 AlGaAsSb 、 InGaAsSb 、 $\text{InAs}/(\text{In})\text{GaSb}$ 等锑化物半导体材料直接制作的中红外波段的半导体激光器、量子级联激光器(QCL);④固体激光器泵浦稀土离子掺杂的低声子能量玻璃光纤、晶体及过渡金属离子掺杂的II-VI族半导体材料的中红外激光晶体(如 $\text{Er}:\text{YAG}$ 、 $\text{Tm}:\text{YAG}$ 、 $\text{Tm},\text{Ho}:\text{YLF}$,以及 $\text{Cr}:\text{ZnSe}$ 、 $\text{Fe}:\text{ZnSe}$)产生红外激光等。目前,常用的手段是通过红外非线性光学晶体进行频率变换(包括倍频及光参量振荡技术等)。因此,探索和研究新型高效的红外非线性光学晶体就显得尤为重要。

2. 必要说明

红外非线性光学晶体主要包括两大类:黄铜矿结构的 ABC_2 ($\text{A}=\text{Cu},\text{Ag}$; $\text{B}=\text{Al},\text{Ga},\text{In}$; $\text{C}=\text{S},\text{Se},\text{Te}$)和纤锌矿结构的 ABC_2 ($\text{A}=\text{Li}$; $\text{B}=\text{Al},\text{Ga},\text{In}$; $\text{C}=\text{S},\text{Se},\text{Te}$),主要有 AgGaS_2 、 AgGaSe_2 、 ZnGeP_2 等,它们都属于黄铜矿结构,缺点是:热膨胀的各向异性大,热导率较低,晶体长大困难;虽然具有较大的非线性光学系数,但由于能隙较窄,从而导致此类在近红外波段具有较强的线性吸收和双光子吸收,并伴随产生强烈的热效应,这就限制了此类不能使用高

能、短波长($1\mu\text{m}$ 以下)的激光泵浦。 ZnGeP_2 晶体非线性光学系数大(72pm/V), 但它在近红外区存在的残余吸收使得其必须采用波长大于 $2\mu\text{m}$ 的激光进行泵浦, 而 $2\mu\text{m}$ 的激光光源较难获得, 这就使 ZnGeP_2 晶体的应用受到了较大的限制; AgGaS_2 、 AgGaSe_2 晶体虽然吸收小, 但同样存在热膨胀的各向异性, 低的声子能量导致其热导率较小, 限制了其在连续激光方面的应用^[4~6]。纤锌矿结构的含锂非线性光学晶体 LiInS_2 , 具有优良的热学性能和非线性光学性质, 其带隙较大($E_g=3.61\text{eV}$), 因而, LiInS_2 晶体具有较高的激光损伤阈值, 该类晶体是一类很有前途的红外非线性光学晶体。近年来, 俄罗斯、法国、德国、丹麦、立陶宛等国家的科学家系统地研究了 LiInS_2 和 LiInSe_2 系列晶体的生长及性能^[7]。山东大学晶体材料国家重点实验室在国内率先开展了 LiInS_2 系列红外非线性光学晶体的研究, 采用垂直布里奇曼法生长了尺寸达到 $\Phi 12\text{mm} \times 40\text{mm}$ 的高质量 LiInS_2 晶体, 晶体照片如图 1 所示。



图 1 山东大学晶体材料国家重点实验室生长的 LiInS_2 晶体

3. 问题描述

探索优秀的、高激光损伤阈值的红外非线性光学晶体, 用于实现可调谐的中远红外激光输出仍然面临着巨大的挑战。对于现有的红外非线性光学晶体, 由于晶体生长工艺不成熟, 晶体缺陷较多导致晶体质量不高, 因此, 从宏观和微观角度深入研究红外晶体中的缺陷, 弄清楚缺陷的成因、缺陷种类及分布, 进而优化晶体生长工艺或退火工艺来减少或消除晶体缺陷, 是获得高质量红外晶体行之有效的途径。红外晶体研究首先遇到的困难是在多晶原料合成阶段, 由于原料在高温下具有较高的蒸气压, 高温下对所用坩埚的耐腐蚀性能和耐压强度都有非常高的要求。另外, 晶体生长阶段, 由于生长设备的限制, 生长过程难以实时监控, 无法方便地控制晶体生长过程中的参数。要

解决晶体生长过程实时控制的难题,需要研制先进的晶体生长设备,采用精确控制坩埚下降和旋转的机电控制系统及精确的温度控制系统,并且采用炉膛内多点实时测温。晶体生长过程中,存在蒸气压大导致石英坩埚爆炸、由于分解导致组分偏离化学计量比,以及固液界面难以控制等因素,因而难以获得高光学质量的晶体。

目前,大多数红外晶体属于黄铜矿结构,虽然此类材料具有较大的非线性系数和较宽的透过波段,但其带隙较小,因而晶体的激光损伤阈值较低,从而限制了此类材料在高能激光泵浦方面的应用。材料的二阶非线性系数一般随带隙的增大而减小,另一方面,晶体的激光损伤阈值随半导体材料带隙的增大而增加,因此,非线性效应与激光损伤阈值之间存在矛盾。所以,如何获得非线性系数大、透过波段宽、激光损伤阈值高的优秀红外非线性光学晶体是一个还未解决的科学难题。

4. 相关扩展

总之,高效红外非线性光学晶体要求透过波段宽,非线性系数大,激光损伤阈值高。解决的途径有两个:一是通过优化晶体生长技术与后处理工艺,提高现有红外晶体的性能;另一途径是在综合考虑晶体结构与性能之间关系的基础上,开展新型高效红外非线性光学晶体的探索研究,以期获得光学质量好、激光损伤阈值高、非线性效应大的优秀红外晶体,从而实现高功率、宽调谐范围的中远红外激光输出。

参 考 文 献

- [1] Ebrahim-Zadeh M, Sorokina I T. Mid-Infrared Coherent Sources and Applications. New York: Springer, 2008.
- [2] Schweizer T, Samson B N, Moore R C, et al. Rare-earth-doped chalcogenide glass laser. Electronics Letters, 1997, 33(5): 414—415.
- [3] Stoll K, Zondyd J J, Acef O. Fourth-harmonic generation of a continuous-wave CO₂ laser by use of an AgGaSe₂/ZnGeP₂ doubly resonant device. Opt. Lett., 1997, 22: 1302—1304.
- [4] Lee D, Kaing T, Zondy J J. An all-diode-laser-based, dual-cavity AgGaS₂ cw difference-frequency source for the 9–11 μm range. Appl. Phys. B, 1998, 67: 363—367.
- [5] Douillet A, Zondy J J. Low-threshold, self-frequency-stabilized AgGaS₂ continuous-wave subharmonic optical parametric oscillator. Opt. Lett., 1998, 23: 259.
- [6] Douillet A, Zondy J J, Yelissev A, et al. Stability and frequency tuning of thermally loaded continuous-wave AgGaS₂ optical parametric oscillators. J. Opt. Soc. Am. B, 1999, 16: 1481—1498.

- [7] Fossier S, et al. Optical, vibrational, thermal, electrical, damage and phase-matching properties of lithium thioindate. J. Opt. Soc. Am. B, 2004, 21: 1981.

撰稿人：陶绪堂 王善朋 蒋民华
山东大学晶体材料国家重点实验室

新型人工电磁材料的吸波与隐身问题

Absorption and Invisibility with Metamaterials

1. 背景介绍

各频段电磁波(包括可见光)的完美吸收有着重要的应用价值,如传统意义上的隐身也是通过吸波来实现的。一般,自然界普通材料的介电常数有较大的实部,磁导率通常是实数1,因而与自由空间存在明显的阻抗不匹配,这导致在两者的界面上存在一定的反射。所以,利用普通材料很难有效实现对电磁波的吸收与隐身。基于人造单元结构的新型人工电磁材料具有许多自然界物质不具有的性质,可以用来实现接近完美的吸波和隐身。完美隐身不同于基于吸波的传统隐身技术,能使物体对任意入射波不仅没有反射,透射也能恢复到就像物体不存在时一样。

2. 问题描述

2008年,人们提出了新型人工电磁材料的一个崭新应用,即用于完美吸收电磁波^[1]。通过合理地设计新型人工吸波材料的单元结构,可以使得等效介电常数和磁导率在一定频率上不但实部可以相等,虚部也可以完全相同,从而使阻抗跟自由空间的阻抗完全匹配,让入射波几乎能无反射地被具有损耗的新型人工电磁材料完全吸收掉。然而,吸波作为新型人工电磁介质的一个崭新的具有广泛应用前景的研究方向,国际上对此的研究到目前为止还是很初步的,有待我们深入研究。新型人工电磁介质的吸波机理至今还没有一个比较完整、系统的阐述。吸波新型人工电磁介质的设计离实际应用仍有一定差距。在实际的器件中,一般都会对吸收材料有特殊要求,如太阳能电池、红外探测要求宽带、广角、极化不敏感吸波。因此,需要对吸波新型人工电磁介质进行优化设计,满足实际需要。虽然已有这方面的一些努力,但还是很不够的。新型人工电磁材料的吸波特点使得其在许多领域中具有重要的应用价值,在军事领域的运用前景已经引起了国际上的广泛关注。通过在表面黏附一层新型人工吸波材料,可以有效减小飞机和舰艇对于雷达的反射,防止其被探测到。作为隐身应用,完美吸波只能降低物体对电磁波的反射,在物体后方却形成了阴影,很容易被双站雷达侦测到,而不能实现真正的隐身。2006年,英国帝国理工学院Pendry教授提出基于变换光学理论的新型人工电磁材料完美隐身结构^[2],可以引导电

磁波绕过隐身区域并恢复到入射到自由空间的传播方向和相位,理论上使物体对电磁波完全没有散射,从而实现真正的隐身。但是,隐身结构对材料有苛刻的参数要求,非均匀各向异性且还会存在零甚至无穷大这样的奇异值,实验实现方面还有很多问题有待解决。

3. 必要说明

完美吸波理论得到了一系列实验上的证实,由分裂环共振器(电耦合)阵列和金属线(磁耦合)阵列构成的新型人工电磁材料可以在 11.5GHz 的一层结构单元吸收率已大于 88%。之后,人们设计、测试了新型电磁材料在太赫兹波段的吸波能力,单层结构单元在频率 1.3THz 处的吸收率为 0.7^[3]。通过进一步优化设计,他们又实现了在频率 1.6THz 处高达 97% 的吸收率^[4],新型电磁材料的层厚度仅为 16 μm 。由于很薄,该新型人工电磁材料能弯曲包裹物体。吸波新型人工电磁材料在太阳能收集利用、红外探测等方面的应用前景推动着它向更高频段的发展。最近,人们设计了一个可在红外波段吸波的由金构成的新型人工电磁材料,数值模拟表明,在较大的角度范围内,他们所设计的吸波材料的吸收率几乎为百分之百^[5]。用新型人工电磁材料吸波有一个很大的优点,它是通过设计单元结构来实现等效的介电常数和磁导率的,而不是依赖材料的特性的,这样,只需合理地调整单元结构和尺寸就可以在各种不同的频段实现完美的吸波。同时,相对之前提出的吸波结构,新型人工电磁介质并不需要局限于四分之一波长的厚度,它可以在厚度远小于波长情况下实现完美的吸收。

基于变换光学的完美隐身主要分两种:全空间封闭隐身结构^[1]和半空间地毯隐身^[6]。前者基于奇异坐标变换,物质参数存在奇异性,即使使用新型人工电磁材料也很难实现大带宽的完美隐身,光频段隐身更是困难;二维简化模型可以一定程度上降低物质参数的复杂性,进而用新型人工电磁材料实现,微波和可见光频段都已经有了实验验证^[7,8];但是,三维全空间隐身目前还没有实验实现。地毯隐身只能实现半空间隐身,但它基于非奇异坐标变换,物质参数没有奇异性,更易于实现且物理原理上也不存在带宽限制,目前已经有二维甚至近似的三维实验验证^[9,10];但是,当前隐身结构可以隐藏物体相对于整体结构的大小仍然很小,距离实际应用还有一定距离。

4. 相关扩展

新型人工吸波材料容易集成到传统的器件中,可用于波长选择的太赫兹和红外探测,如热辐射仪、热成像、非破坏性检测等。由于新型人工电磁介质的结构单元可以做得很小,达到波长的几十分之一,从而可以有效改善传统探测

器的分辨率。再加上结构单元的厚度可很薄,这非常有利于小型化器件。同时,它在热辐射仪方面的运用可以很大提高目前热辐射仪的带宽。特别指出,吸波新型人工电磁介质在太赫兹应用方面将有广阔应用前景。太赫兹科学近年来发展非常迅速,但由于自然材料在这个频段的响应不足,目前有效操纵太赫兹波的光学器件还很缺少。新型人工电磁材料在这个频段提供了强吸波的响应能力,弥补了自然材料在这个方面的不足,另外,它的小尺寸和设计的灵活性则突出了其在太赫兹波接收与辐射方面的价值。另外,除了直接用以吸波外,用新型人工电磁介质调控热辐射是同样令人感兴趣的研究方向。

完美隐身的提出引起光学、电磁波领域的极大兴趣,除了上述基于变换光学的隐身机制之外,人们还提出了很多其他的隐身机制,各自有着不同的特点。基于保角变换的隐身结构可以只需要各向同性的折射率分布就能实现几何光学近似下的隐身^[11];等离子壳层的共振特性可以将已知物体的散射抵消,从而实现总散射为零^[12];互补介质可以实现对外部物体的隐身^[13];对特定入射探测波最近人们还提出有源隐身,可以形成一个电磁场为零的区域,从而对放在其中的物体不会产生散射^[14]。作为对隐身的扩展,人们还进一步提出了幻觉光学^[15],不仅能够隐藏目标,还能产生一个虚幻物体的散射特征,从而迷惑观察者。

参 考 文 献

- [1] Landy N I, Sajuyigbe S, Mock J J, et al. Perfect metamaterial absorber. *Phys. Rev. Lett.*, 2008, 100: 207402.
- [2] Pendry J B, Schurig D, Smith D R. Controlling electromagnetic fields. *Science*, 2006, 312: 5781.
- [3] Tao H, Landy N I, Bingham C M, et al. A metamaterial absorber for the terahertz regime: Design, fabrication and characterization. *Optics Express*, 2008, 16: 7181.
- [4] Tao H, Bingham C M, Strikwerda A C, et al. Highly flexible wide angle of incidence terahertz metamaterial absorber: Design, fabrication, and characterization. *Phys. Rev. B*, 2008, 78: 241103.
- [5] Avitzour Y, Urzhumov Y A, Shvets G. Wide-angle infrared absorber based on a negative-index plasmonic metamaterial. *Phys. Rev. B*, 2009, 79: 045131.
- [6] Li J, Pendry J B. Hiding under the carpet: A new strategy for cloaking. *Phys. Rev. Lett.*, 2008, 101: 203901.
- [7] Schurig D, Mock J J, Justice B J, et al. Metamaterial electromagnetic cloak at microwave frequencies. *Science*, 2006, 314(5801): 977.
- [8] Semouchkina E, Werner D H, Semouchkin G B, et al. An infrared invisibility cloak composed

- of glass .Applied Physics Letters ,2010 ,96 :233503 .
- [9] Liu R ,Ji C ,Mock J J ,et al .Broadband ground-plane cloak .Science ,2009 ,323(5912):366 .
- [10] Ergin T ,Stenger N ,Brenner P ,et al . Three-dimensional invisibility cloak at optical wavelengths .Science ,2010 ,328 :337—339 .
- [11] Leonhardt U .Optical conformal mapping .Science ,2006 ,312(5781):1777 .
- [12] Alù A ,Engheta N .Plasmonic and metamaterial cloaking :Physical mechanisms and potentials .Journal of Optics A—Pure and Applied Optics ,2008 ,10(9):093002 .
- [13] Lai Y ,Chen H ,Zhang Z ,et al .Complementary media invisibility cloak that cloaks objects at a distance outside the cloaking shell .Phys .Rev .Lett . ,2009 ,102(9):093901 .
- [14] Vasquez F G ,Milton G W ,Onofrei D .Active exterior cloaking for the 2D Laplace and Helmholtz equations .Phys .Rev .Lett . ,2009 ,103(7):073901 .
- [15] Lai Y ,Ng J ,Chen H ,et al .Illusion optics :The optical transformation of an object into another object .Phys .Rev .Lett . ,2009 ,102(25):253902 .

撰稿人：何赛灵

浙江大学光电信息工程学系

纳米表面等离子集成光子学

Nano-scale Surface Plasmonic Integrated Photonics

近几年来,电子集成线路(IC)的尺寸按照摩尔定律预期的迅速减少,其单元器件已在实验室里实现了数十纳米量级的突破。由于受到电子固有的荷电性、带宽、热耗和热电串扰等物理限制,电子 IC 的尺寸与集成度几乎到达了其理论极限值,因而难以进一步突破。

与此相反地,光子 IC 在理论上完全不受这些因素的制约,并具有极高的带宽和响应速度、高抗扰性等电子 IC 无法比拟的优异性能。但是,作为基本组成元素的光波导,其横向尺寸至今仍被限制在光波长量级而不能发挥其潜力,光子 IC 单元器件因而停留在数十至数千波长的尺度范围。为了突破这一波长极限,大幅度减少光子 IC 的尺寸,研制集成度更高、功能更强的光子 IC 或平面集成器件,研究人员先后提出了高折射率差介质波导和光子晶体波导。由于光子晶体缺陷态波导的边界需要多周期的光子晶体结构对光场干涉相消而形成禁带限制作用,这两类光波导实质上仍没能摆脱物理光学的波长极限制约。因此,如何获得真正突破波长极限的新型光波导、波长选择与复用及可调等功能平面光子器件,是实现纳米光电和全光集成的成败关键所在,因而成为目前迅速发展的纳米光子学领域的一大研究热点。

1998 年, Ebbesen 小组在 *Nature* 上发表了亚波长金属小孔阵列结构透射增强的纳米聚焦现象^[1], 2002 年, 又在 *Science* 上发表了利用准周期金属微结构控制出射光束质量实验^[2], 此后, 有关金属微结构表面等离子激元的激发及传输等现象的研究引起了人们的极大兴趣, 先后提出了基于金属纳线或金属纳米颗粒阵列的表面等离子体波导^[3], 但在可见光波段, 传播距离仅几百纳米。多个研究小组已在理论和实验证明, 金属/介质/金属(MDM)波导结构在可见区和近红外具有极强的亚波长电磁场局域能力和较低的传输损耗, 揭示了亚波长 MDM 波导具有良好的直角弯曲和 T 型分支的光传输特性^[4,5], 在金属异质结构上实现布拉格反射^[6,7]。最近, 还提出了新型纳米级滤波和波分复用结构^[8], 适用于高密度的集成。此外, 还研究了普通微米波导和纳米等离子波导之间的高效耦合。可见, 已有的理论和实验工作主要集中在等离子激元波导的场局域效应、传导特性和简单线性行为, 所讨论的器件均为完全被动不可调, 还未研究电压、磁场或光场等因素的影响及其可控制性问题。此外, 已有的波长选择器件主要是周期性结构, 作用区数微米长, 电控或光控功耗很高。因此, 研究和探讨如何通过外部物理量实现对表面等离子激元的可控制性, 并把器件尺寸限制在纳米

范围以实现高效功能化,是目前亟须解决的科学难题。

所谓的表面等离子极化激元(surface plasmon polaritons, SPPs),是一种局域在金属表面的由自由电子与光子相互作用形成的混合激发态。表面等离子激元金属波导的突出特点之一就是具有将电磁场能量聚集在纳米尺度范围的能力,打破光学器件波长极限的限制,被认为是最有希望的纳米集成光学器件的有效载体,在纳米集成光学与器件方面有极大的应用潜力。

表面等离子激元研究已在纳米金属小孔阵列透射增强、近场光学成像和光波传输等领域取得了很大进展,但在光信息处理,尤其是光电可控性、光开关及逻辑功能等方面的研究进展仍十分有限,远不能满足纳米光子 IC 应用的要求。深入开展纳米表面等离子集成光学研究,解决目前国际上表面等离子激元器件的可控性和功能化科学和技术难题,研制新型纳米等离子激元光开关等光通信关键功能器件,对于促进纳米集成光学理论和纳米光子学科的发展有很大的推动作用,因而具有十分重大的研究价值和应用价值。

参 考 文 献

- [1] Ebbesen T W, Lezec H J, et al. Extraordinary optical transmission through sub-wavelength hole arrays. *Nature*, 1998, 391(6668): 667—669.
- [2] Lezec H J, Degiron A, et al. Beaming light from a subwavelength aperture. *Science*, 2002, 107: 1895.
- [3] Maier S A, Kik P G, Atwater H A, et al. Local detection of electromagnetic energy transport below the diffraction limit in nanoparticle plasmon waveguides. *Nature Materials*, 2003, 2(4): 229—232.
- [4] Veronis G, Fan S. Bends and splitters in metal-dielectric-metal subwavelength plasmonic waveguides. *Applied Physics Letters*, 2005, 87(13): 1—3.
- [5] Lee T, Gray S. Subwavelength light bending by metal slit structures. *Optics Express*, 2005, 13(24): 9652—9659.
- [6] Wang B, Wang G. Plasmon Bragg reflectors and nanocavities on flat metallic surfaces. *Applied Physics Letters*, 2005, 87(1): 1—3.
- [7] Hosseini A, Nejati H, Massoud Y. Modeling and design methodology for metal-insulator-metal plasmonic Bragg reflectors. *Optics Express*, 2008, 16(3): 1475—1480.
- [8] Lin X S, Huang X G. Tooth-shaped plasmonic waveguide filters with nanometric sizes. *Opt. Lett.*, 2008, 33(23): 2874—2879.

撰稿人: 黄旭光

华南师范大学信息光电子科技学院

表面等离子体传播的主动调控

Active Manipulation for Surface Plasma Polaritons Propagation

早在 1902 年, Wood 首次提出在金属衍射光栅上观察到了异常的光谱局部缺失现象^[1], 这种现象超出了 20 世纪以前人们对衍射光栅光谱的认知, 随后被验证, 这个能量流失是由光波在金属光栅表面耦合成为表面等离子体(surface plasmon polaritons, SPPs)造成的, 这就是关于表面等离子体最早的记载。虽然在之后很长的时间里这种特殊电磁波的物理机制一直在被研究和阐明, 但直到近半个世纪, 纳米加工技术的迅速发展才真正使表面等离子体的应用成为现实。

表面等离子体是由金属内自由电子的密度波与空间电磁波相互谐振耦合形成的一种表面波, 沿金属和介质界面传播, 并在与界面垂直方向电磁场呈指数衰减, 其场强分布深度与波长量级相同。不同于传统的导波光学, 表面等离子体的近场特性使其可以突破衍射极限, 在亚波长的空间尺度上传播, 这一特性为高密度光子互连提供了新的思路。尺度与工艺的一致性更加使表面等离子体在纳米领域将光子学与电子学紧密结合成为可能, 对未来发展新型光子器件和光子集成回路有着重要意义^[2]。在表面等离子体波导逐渐被认识后, 如何有效地在波导中动态调节和控制表面等离子体, 实现信号的加载及传播, 成为设计表面等离子体主动器件的关键, 基于表面等离子体的光源、开关、调制器和放大器等一系列有源组件都将依赖于这项技术的发展和成熟。

然而, 表面等离子体的传播因伴随金属吸收而衰减, 其沿金属界面传播长度仅局限于几十到几百微米的范围, 并且表面等离子体器件对制备工艺的要求较高, 金属平面或者阵列结构的缺陷都会使表面等离子体产生不必要的辐射损耗。为了提高调控效率, 就需要在优化器件制造工艺的基础上, 合理设计器件结构以降低表面等离子体沿金属表面的传播损耗。金属/介质/金属平板波导、沟道型波导、光子带隙结构都曾被设计用于传导表面等离子体, 这些结构能够进一步调节电磁场在界面附近的束缚状态, 通过降低金属层中的有效能量分布来降低传播中的吸收损耗。有源材料, 如量子阱、纳线、量子点和有机发光染料通过光激发或者电激发改变材料特性(如折射率或吸收率)或者产生增益, 在界面临近区域与表面等离子体激元耦合达到对其调控的效果。

对表面等离子体的调制可以通过介质材料的电吸收、电光、磁光和热光效应来实现。近年来, 基于磁光、热光及光学非线性材料的调制器相继被报道, 而面向光电转换的电学调制也取得了很大的进展。2008 年, Dicken 利用钛酸钡

的电光效应和电畴翻转在碳酸钡和银的界面上实现了电压调制^[3]。2009 年, Cai 提出了兼容 CMOS 工艺的表面等离子体电光调制器的构想, 其理论工作频率大于 100GHz, 调制深度大于 3dB, 仅需要约 1V 调制电压^[4]。相比于电压调制, 表面等离子体在电注入下的激发及放大技术面临更大的困难, 因此, 发展相对缓慢。虽然关于激发表面等离子体的有机发光二极管^[5]和金属/介质/金属电注入表面等离子体光源^[6]的报道先后发表, 但对于需要材料增益支持的表面等离子体的放大和激射, 目前仍然需要光泵浦的条件下才得以实现^[7,8]。因为材料增益需要的载流子数量翻转需要较大电流注入密度, 而表面等离子体的本质限制了有源区与电磁场只能局限在很小的空间里, 这对电学接触及器件散热提出了很高的要求。如何在表面等离子光路中引入具有小体积、高信噪比和低插入损耗的放大器件, 解决信号的载波激发和中继放大将是影响密集集成光路发展的重要因素。

作为一个新兴且尚在发展的研究领域, 表面等离子体为全光量子通信和光电交叉系统提供了具有广阔应用前景的平台。为了获得可密集集成的表面等离子体主动器件, 尚有许多科学问题有待进一步探索。

(1) 进一步认识表面等离子体在波导中的激发和传输过程, 研究传输损耗的控制及表面等离子体增益放大, 以实现表面等离子体的导波长程传输。基于电磁场相干特性, 设计表面等离子体的干涉仪和全光开关。优化光波与表面等离子体间的耦合效率及表面等离子体器件间的内互连效率, 降低表面等离子体器件的插入损耗。

(2) 如何在金属纳米结构上引入对表面等离子体的有源调控。光子晶体和其他许多超材料结构已经被证明具有天然材料所没有的特性, 如光子带隙和负折射率, 可被用于在表面等离子体回路中实现微腔、波导、反射、聚焦和分束。改变超材料中的电光、铁电和压电材料的材料特性, 将直接调节超材料结构的光学特性, 实现动态调控光学组件。

(3) 如何利用表面等离子在界面的近场局域性对增强物质与电磁场的耦合效应与相互作用, 为非线性效应研究和实现双稳态光学开关提供很好的平台, 并利用表面等离子体在共振频率附近的高态密度实现高质量的纳米激光光源。对高增益、高非线性材料和表面等离子体结合的研究将成为表面等离子体主动器件研究至关重要的一部分, 同时也为基于表面等离子体的单光子光源和单光子开关奠定基础。

参 考 文 献

- [1] Wood R W .On a remarkable case of uneven distribution of light in a diffraction grating

- spectrum .Proc.Phys.Soc.London,1902,18(1):269—275.
- [2] Ozbay E.Plasmonics:Merging photonics and electronics at nanoscale dimensions .Science, 2006,311:189—193.
- [3] Dicken M J,et al.Electrooptic modulation in thin film barium titanate plasmonic interferometers . Nano Lett.,2008,8(11):4048—4052.
- [4] Cai W,et al.Compact,high-speed and power-efficient electrooptic plasmonic modulators . Nano Lett.,2009,9(12):4403—4411.
- [5] Koller M D,et al.Organic plasmon-emitting diode .Nature,2008,2:684—687.
- [6] Walters R J,et al.A silicon-based electrical source of surface plasmon polaritons .Nature Materials,2009,9:21—25.
- [7] de Leon I,Berini P.Amplification of long-range surface plasmons by a dipolar gain medium . Nature Photonics,2010,4:382—387.
- [8] Oulton R F,et al.Plasmon lasers at deep subwavelength scale .Nature,2009,461:629—632.

撰稿人：李一岑¹ 王 茜¹ 袁小聪² 梅 霆³

1 新加坡南洋理工大学纳米光子学实验室

2 南开大学现代光学研究所

3 华南师范大学光电子材料与技术研究所

高灵敏度 高空间分辨率 表面增强拉曼散射光谱

High-sensitivity and High-resolution Surface Enhanced Raman Scattering

单分子识别及其结构变化的实时监测一直以来是化学家的梦想，因为它们可以直观反映生化相互作用的动力学过程，而由于平均效应这一过程在多个分子的聚集体结构中无法进行研究。另外，通过单分子计数实现分子的高通量、选择性探测和微量物质的量化代表着化学分析和痕迹追踪的终极目标。单分子研究已成为化学、物理、生命科学和纳米科技领域快速增长的研究课题。目前，光谱方法被认为是探测和研究单分子的有力工具。物质分子在不同条件下吸收或发射的光谱的波长、强度、偏振态等情况和该物质的结构特征有着固有的关系，因此，可以通过光谱方法来分析、识别生化样品。光谱传感技术的一般实现方法是：激励光作用于被测分子(或标记在目标分子上的指示分子)产生新的光谱信号，该光谱信号携带了被测分子的特征信息，从而实现了生化检测。通常，分子水平检测微量物质的手段是荧光标记法，它通过抗原抗体结合的原理来定量分析待测对象是否存在及其量化指标。但是，由于荧光信号光谱较宽($400\sim 800\text{nm}$)^[1]，难以实现分子的特征识别。同时，由于标记物通常会影生物分子的功能，而且通过标记物的间接测量容易影响检测精确度，其结果也不易长期保存，并且存在因光漂白(photobleaching)导致的荧光猝灭问题，因此，该方法在应用上存在局限性和缺陷。

拉曼散射是一种光子入射到分子上发生的非弹性散射，其频率改变量和分子的固有振动能级相对应。拉曼光谱宽度很窄，通常在 $10\sim 20\text{cm}^{-1}$ 范围内。如此窄的谱宽使得即使两个化学结构类似的分子的拉曼光谱也不会发生交叠，从而可以被检测区分出来，实现分子特异性的表征和“指纹”识别。尽管拉曼光谱技术具有较高的探测准确度，不过，由于通常拉曼散射截面($10^{-30}\sim 10^{-25}\text{cm}^2$)和荧光散射截面(约 10^{-16}cm^2)相比非常小，使得分子水平的微弱拉曼信号淹没在较强的荧光信号里面，灵敏度较低，难以实现单分子探测。Stokes 光子的数量可以作为评估拉曼散射截面和激发光强度的指标。假设某个拉曼峰的散射截面为 10^{-29}cm^2 ，激发光功率为 $100\text{mW}/\mu\text{m}^2$ ，每秒钟单分子只能散射约 10^{-4} 个光子，这意味着需要等待超过一个小时的时间，单分子才能发出一个 Stokes 光子。

近年来，迅速发展起来的表面增强拉曼散射(surface enhanced Raman scat-

tering, SERS)光谱技术可以解决这一问题,它弥补了拉曼光谱灵敏度低的不足^[2],是目前可以同时实现单分子探测和化学结构识别的唯一光谱学方法,已逐渐成为探测界面特性和分子之间相互作用、表征分子吸附行为和分子结构非常有效的现代测试分析工具,在生命科学、药物研究、医疗诊断、环境监测、食品安全、军事科学等与人民身体健康和国家安全息息相关的领域中有着广泛的应用前景。SERS是指分子吸附到某些金属纳米结构基底的表面时,分子的拉曼信号显著增强的现象。1974年,Fleischmann等首次发现了SERS现象^[3],在其后的三十多年中,该技术持续引起科学界的广泛关注。已有文献中提及的SERS形成机理主要分为两大类:电磁增强模型和化学增强模型。前者认为SERS起源于金属表面局域电场的增强,通过选择合适的工作波长、偏振态和粗糙的金属微纳结构,可以激发金属微纳结构中的局域表面等离子体(其激发效率和入射光波长与偏振态密切相关),并在特定位置形成电场显著增强的“热点”;后者则认为SERS与分子的极化率变化改变有关,它们对SERS产生的相对贡献随体系的不同而不同^[4]。在可见光波段的金银颗粒或其聚合物中,SERS场增强因子可以达到 $10^{14} \sim 10^{15}$ 的量级^[5~7],和传统的拉曼光谱技术相比,其大幅度提高了拉曼信号。另外,在饱和条件下,单位时间内SERS发射的光子数是荧光光子数的100~1000倍,这是因为这一数目和分子激发态寿命成反比,而分子的振动弛豫时间(和SERS光子数相关)比电子的弛豫时间(和荧光光子数相关)短得多。为了产生显著的拉曼信号,要求金属微纳结构的尺寸在合适的范围内(通常在5~100nm)。如果金属纳米颗粒太小,金属的有效电导率描述不再成立,基于体描述的表面等离子体激元的概念也不再适用,此时需要考虑量子尺寸效应。金属微纳结构的尺寸上限由激发光波长决定,因为SERS信号的强度由电偶极跃迁概率决定。如果金属微纳结构太大,无法激发电偶极等离子体,而代之以非辐射的高阶多偶极子模式,对SERS信号没有贡献。

前述SERS技术的诸多优点使得它可以作为分子的识别探针,用于直观观测活体细胞之间的相互作用和能量输运过程。但是,由于通常都是在远场探测拉曼信号,导致使用SERS技术对生化样品进行成像时,横向空间分辨率仍然受到传统光学衍射极限的限制。已报道的利用若丹明6G分子的拉曼信号对周期性金颗粒阵列结构成像的空间分辨率只有 0.658λ ^[8]。因此,发展高空间分辨率,乃至突破传统光学衍射极限的,能探测和识别活体细胞中单个分子之间相互作用的光学成像技术显得尤为重要。作为一种实时在线、活体的非接触分析手段,拉曼成像技术在高通量检测和识别生物单分子方面有着重要的应用前景。在优化入射光波长、偏振态和金属微纳结构,提高电场增强因子的基础上,发展集生物化学和生物医学样品无标记、高灵敏度分子水平浓度检测的拉曼光谱成像

技术,同时兼顾纳米尺度空间分辨率是一个值得学者深入研究的课题。

参 考 文 献

- [1] Kneipp K, Moskovits M, et al. Surface-Enhanced Raman Scattering: Physics and Applications. Berlin: Springer, 2006: 103, 261—278.
- [2] 闫贺. 基于光子晶体光纤的表面增强拉曼探针的实验研究[博士学位论文]. 北京: 清华大学, 2009.
- [3] Fleischmann M, Hendra P J, et al. Raman spectra of pyridine absorbed at a silver electrode. Chemical Physics Letters, 1974, 26(2): 163—166.
- [4] Kneipp K. Surface-enhanced Raman scattering. Physics Today, 2007, 60(11): 40—47.
- [5] Kneipp K, Wang Y, et al. Single molecule detection using surface-enhanced Raman scattering. Phys. Rev. Lett., 1997, 78(9): 1667—1670.
- [6] Nie S, Emory S R. Probing single molecules and single nanoparticles by surface-enhanced Raman scattering. Science, 1997, 275(5303): 1102—1106.
- [7] Le R E C, Blackie E, et al. Surface enhanced Raman scattering enhancement factors: A comprehensive study. J. Phys. Chem. C, 2007, 111(37): 13794—13803.
- [8] Beermann J, Novikov S M, et al. Surface-enhanced Raman imaging of fractal shaped periodic metal nanostructures. J. Opt. Soc. Am. B, 2009, 26(12): 2370—2376.

撰稿人: 袁小聪¹ 苑光辉² 肖晓晟³ 杨昌喜³

1 南开大学现代光学研究所

2 新加坡南洋理工大学电机与电子工程学院

3 清华大学精密仪器与机械学系

光学旋涡

Optical Vortices

1931年, Dirac在 *Proc.R.Soc.London Ser.A* 上发表了一篇题为 Quantised singularities in the electromagnetic field 的文章, 第一次讨论了电磁场中的相位奇点问题^[1]。1974年, 伴随着 Nye 和 Berry 发表了他们对相位奇点在光学领域中的研究成果^[2], 学术界兴起了一股研究光学旋涡的热潮。随着研究的不断深入, 30年来, 光学旋涡基于其独特的螺旋相位和轨道角动量等特性, 吸引了许多不同领域研究者的极大兴趣。光学旋涡的生成, 通常是采用螺旋相位结构(如螺旋相位片和计算全息图)作用于激光器外部对平面波或高斯波进行调制, 从而产生光学旋涡。光学旋涡的螺旋相位概念甚至被利用来设计新型的滤光器作为天文学上观测太阳系外行星的有效工具。光学旋涡的轨道角动量特性可应用于光镊系统中, 针对难以被普通激光束捕获的某些材料的微粒, 光学旋涡的环形光强分布却能够将这些微粒固定在激光束中心光强的暗处。进一步研究表明, 光学旋涡中的光子轨道角动量可以传递给被捕获的微粒, 进而驱使这些微粒围绕光学旋涡的中心旋转。除了施加光学作用力之外, 正交的光子轨道角动量状态还可以产生高维的量子纠缠及作为信息的载体用于光通信中。

在光学图像处理方面, 光学旋涡的螺旋相位结构具有两项较为突出的特性, 第一项是螺旋干涉(spiral interference)技术^[3], 这项技术通过将螺旋相位片放置在光学系统的傅里叶平面进行相位滤波, 之后再与参考光束进行干涉, 干涉所产生的螺旋状条纹可用于检测相位差大于 2π 的透明样本(强相为体)。产生螺旋干涉条纹的机制是: 检测样本相位变化在傅里叶平面会生成空间频率较高的信号, 这些高频信号经由螺旋相位片滤波之后, 与参考光束相干, 从而生成随样本相位特征变化的干涉条纹。螺旋干涉技术的优势在于能够通过螺旋干涉条纹的旋转方向来精确判断样本的相位变化方向, 并且能够通过单幅干涉图中的螺旋干涉条纹来精确复原所检测样本的相位结构(如图1所示)。空心螺旋相位片作为螺旋干涉技术的一项改进, 利用光学系统中傅里叶平面的零级衍射作为参考光, 实现了自我参考的螺旋干涉, 有效避免了环境噪声的干扰, 并且能够将结构微型化。然而, 这项技术受到实验样本特征及其他参数的限制, 如果样本不透明, 或有双折射性质, 或是由于高曲率显微镜造成波前和偏振畸变, 则常规螺旋干涉技术不具有适应性, 需要对特殊样本和器材进行定制和校准。那么,

如何提高螺旋干涉的检测精度呢？由于螺旋干涉仍然受到传统光学干涉理论限制，若需要提高检测精度，只有采用波长较短的激光，这样，在干涉图中就能够减小条纹间距，进而获得更多的条纹数，提高相位复原的精度。但是，由于某些样本(如活体细胞)对照明波长有选择性，因此，理论上的检测精度难以实现。




图1 直径为 $15\mu\text{m}$ 的聚苯乙烯微粒的显微图片(a)、螺旋干涉图(b)和相位复原图(c)

理论家们还发现，用于产生光学旋涡的螺旋相位结构在径向具有 π 相位差，因而能够在径向进行一维 Hilbert 变换。一维 Hilbert 变换通常被应用于信号处理技术中来实现对信号的增强，径向 Hilbert 变换可视为一维 Hilbert 变换的延伸，那么，螺旋相位片能否作为 Hilbert 变换装置来实现光学图像处理呢？由此引出了光学旋涡在图像处理方面的第二项特性：利用螺旋相位结构进行光学的径向 Hilbert 变换来实现对图像的边缘增强^[4]。此项特性能够对弱相位样本的成像进行边缘增强，进而弥补螺旋干涉技术仅能应用于强相位体的不足。拓扑指数为 1 的螺旋相位结构在径向具有对称的 π 相位差，在空间滤波技术中可用作二维的径向 Hilbert 变换，从而对图像进行同性的边缘增强。同时，当螺旋相位片的拓扑指数为小于 1 的分数时，能够进行分数型 Hilbert 变换，达到径向不同性的边缘增强。当选择不同的分数值或者旋转相位片的方向时，都可对样本的特定方向进行有选择性的边缘增强。然而，常规螺旋相位片所进行的光学 Hilbert 变换会在边缘增强的图像中临近样本边缘处产生大量噪声，影响对比度和分辨率。通过增加额外的调制模式，例如，拉盖尔-高斯(Laguerre-Gauss)调制^[5]和巴特沃思(Butterworth)调制对常规螺旋相位片进行优化，可以有效降低噪声，提高对比度和分辨率(如图 2 所示)。这项技术可通过在显微镜系统光路中的傅里叶面直接加入螺旋相位片来实现对普通显微镜的升级^[6]，从而进行各种不同类型的光学图像处理工作。

随着光学旋涡各种应用的增加和逐渐深入，对光学旋涡自身的性质和特点都提出了要求。那么，如何检测和衡量光学旋涡的特征，特别是与拓扑指数相关的数据呢？研究人员们发现，含有螺旋相位的光栅结构除了能够被用于生成





图 2

光学旋涡以外,还能够实现对光学旋涡的探测和分析^[7]。当这种旋涡光栅的某个衍射级次刚好具有和入射光学旋涡自身相反的螺旋相位时,该衍射级次上的波前相位则会相互抵消。例如,拓扑指数为 $+1$ 的光学旋涡在通过旋涡光栅之后,在 -1 次衍射级上,光束的波前螺旋相位将会被旋涡光栅抵消。经由透镜聚焦之后,在傅里叶平面会形成平面波的衍射光斑,通过观测光斑特征即可实现对光学旋涡的检测(如图3所示)。这种旋涡光栅不仅可以应用于拓扑指数为整数的光学旋涡的检测,对拓扑指数为分数的光学旋涡也同样适用。分数拓扑指数可由傅里叶级数展开为若干整数指数的叠加,而相邻两个整数部分相叠加至少可以涵盖分数指数90%的光强信息。通过检测相邻的两个衍射级上光斑的中心光强分布,能够实现对分数光学旋涡的探测。然而,这种探测功能在检测精度上仍然具有一定的局限性,由于实验条件等限制,检测精度仅能够精确到小数点后一位,不同光学旋涡之间更加细微的相位差异很难被检测出来。那么,是否能够通过其他途径对光学旋涡进行高精度的探测?这也为光学旋涡的探测和分析提供了一个新的研究方向。

图3 利用旋涡光栅探测光学旋涡(拓扑指数为 $-4, -2, 0, +2, +4$)的实验结果^[7]

由于光学旋涡的优秀特性和广泛的应用前景,国际上各种科研院所都投入大量资源对光学旋涡进行研究,期待其对包括生物、量子物理、通信、天文在内的各种领域提供新型的实验方法和研究工具。

参 考 文 献

- [1] Dirac P A M .Quantised singularities in the electromagnetic field .Proc .R .Soc .London Ser . A ,1931 ,133 :60—72 .
- [2] Nye J F ,Berry M V .Dislocations in wave trains .Proc .R .Soc .London Ser .A ,1974 ,336 (1605) :165—190 .
- [3] Fürhapter S ,Jesacher A ,Beraet S ,et al .Spiral interferometry .Opt .Lett . ,2005 ,30 :1953—1955 .
- [4] Davis J A ,McNamara D E ,Cottrell D M ,et al .Image processing with the radial Hilbert transform :Theory and experiments .Opt .Lett . ,2000 ,25 :99—101 .
- [5] Guo C S ,Han Y J ,Xu J B ,et al .Radial Hilbert transform with Laguerre-Gaussian spatial filters .Opt .Lett . ,2006 ,31(10) :1394—1396 .
- [6] Maurer C ,Jesacher A ,Fürhapter S ,et al .Upgrading a microscope with a spiral phase plate . Journal of Microscopy ,2008 ,230(1) :134—142 .
- [7] Moreno I ,Davis J A ,Pascoguin B M L ,et al .Vortex sensing diffraction gratings .Opt .Lett . , 2009 ,34(19) :2927—2929 .

撰稿人:袁小聪¹ 张凝² 林皎²

1 南开大学现代光学研究所

2 新加坡南洋理工大学电机与电子工程学院

亚波长金属孔阵列光学异常透射现象的微观解释

Microscopic Interpretation of the Extraordinary Optical Transmission through Sub-wavelength Metallic Hole Arrays

光本质上是一种电磁波,满足一般波动现象的干涉、衍射等性质,因此,对光波实现操控的尺度在物理上受到波动现象衍射极限的限制,难以在小于波长(亚波长)的尺度上实现对光波的操控。例如,可见光波长在亚微米量级,常规显微成像技术的最高分辨率即受到衍射极限的限制,其最高分辨率大致是波长量级。随着现代微纳米加工技术的进步,如电子束曝光、离子束刻蚀等,使得各种形式的尺寸在微纳米量级的结构已经能够实现,相应地,研究光波在尺寸接近甚至小于波长的微纳米结构中的特性,并实现亚波长尺度下光的操控,日益成为人们关注的焦点。

1998年,光学异常透射(extraordinary optical transmission, EOT)现象在*Nature*期刊上被Ebbesen等首次报道^[1],该现象发生于贵金属(如金、银)薄膜上制作的周期排布的亚波长二维孔阵列[如图1(d)所示],表现为在某些特定波长的照明下,光透过孔阵列的比例高于孔面积所占的比例(如图2所示)。利用该现象,可以将光波有效地局限于具有亚波长尺寸的孔内区域,突破了衍射极限的限制,实现了亚波长尺度上对光波的操控,在亚波长光刻、化学传感、光电探测等领域有重要应用。

为了有效设计各种基于光学异常透射的器件,需要从物理上明确发生光学异常透射的机制,该现象之所以被称为光学异常透射,一方面是由于光透过孔阵列的比例高于孔面积所占的比例,这和传统的光波标量衍射理论预言的结果不一致,另一方面,从严格的光波矢量衍射理论出发,可以计算得到光透过单个导体孔的透过率,结果发现,该数值要比光通过孔阵列的透过率低若干个数量级。同时,发生异常透射的金属孔内场呈指数衰减,这也难以解释为什么孔阵列有很高的透过率。对于光学异常透射现象的物理解释,已经成为目前国际研究的热点问题,其意义不仅在于理解光学异常透射现象本身,更重要的是有助于理解光波和微纳米金属结构相互作用的普遍机理,用以指导相关器件的设计。后者已经发展为微纳米光学的一个新的分支——金属表面等离子体微纳米光学,研究利用金属表面等离子体波(surface plasmon polariton, SPP)实现微纳米尺度上对光波的操控。这里的金属表面等离子体波是广泛存在于亚波长金属结构中的一种表面波,由自由电子和电磁场的周期性振荡形成,能够在金属表面传播几十个波长的距离。后面我们将看到,对异常透射的解释和此类金属表

面等离子体波是紧密联系的。

为了明确发生光学异常透射现象的物理机制,各国学者陆续提出了若干解释。其中一类解释基于传统的模式展开方法^[2],从宏观唯象的角度解释发生异常透射的原因,此类解释将金属孔阵列作为空气-孔阵列-空气三层结构处理,各层中的场用相应的一组电磁场模式展开,由此分析透射电磁场发生增强的机制。结果表明,当发生透射增强时,金属孔阵列上下两个表面上会相应地激发出两个表面准周期模式,该表面准周期模式具有很强的电磁场分量,由此使得透射电磁场发生增强。

虽然上述解释在一定程度上深化了人们对异常透射的认识,但并没有从根本上明确发生异常透射的原因,特别是此类解释中出现的表面准周期模式,其形成的物理原因、导致透射场增强的具体过程等并不清楚。由于此类宏观唯象解释的局限性,人们试图从微观动力学的角度更深入地解释异常透射。其中一种观点在首次发现异常透射现象时就已经提出^[1],该观点认为,当入射光波照明金属孔阵列时,会在金属表面上激励出金属表面等离子体波,该波与金属孔径中的场相互作用导致透射场增强。然而,该观点仅限于定性的水平,缺乏定量数据的支持,并且对于金属表面等离子体波与金属孔径中的场如何相互作用以增强透射场,缺乏具体的认识。此后,出现了其他解释,其中比较有代表性的一类解释借鉴了原子物理中的 Fano 模型^[3],引入连续态和离散共振态的概念,认为获得增强的透射场来自两部分贡献:一部分来自入射波直接透过孔径的透射场,对应连续态;另一部分来自金属表面激发的表面波的共振增强,对应离散共振态。基于该物理分析,此类 Fano 模型能够精确给出发生异常透射的谱线形状,但不足在于不能够明确其中表面波的来源和物理本质,并且模型中使用的参数只能通过曲线拟合得到,并不能由模型本身给出。除此之外,还有一种微观解释采用“复合倏逝波”(composite diffracted evanescent wave, CDEW)的概念^[4],认为光波照明金属孔阵列后,会在金属表面激发出复合倏逝波,这种复合倏逝波由孔径散射场中的倏逝波分量组成,沿金属表面传播,通过这些复合倏逝波与孔径中场的相互作用,实现透射场增强。然而,此类复合倏逝波模型在理论上存在问题,该模型中的复合倏逝波是基于光波的标量衍射理论提出的,与光波的偏振状态无关,这与光学异常透射现象是矛盾的,后者只在特定的光波偏振态下才能发生。

为了从微观动力学的层面上明确发生光学异常透射的物理机制,本文作者和法国 Lalanne 教授在 2008 年提出了解释光学异常透射的一项微观理论^[5],该理论建立了光学异常透射的一个金属表面等离子体模型。如图 1 所示,对于发生光学异常透射的二维金属孔阵列[如图 1(d)所示],首先将其分解为一维孔链的周期性组合,如图 1(a)~(c)所示,考虑一维孔链发生的基本散射过程,对于金属表面波只考虑金属表面等离子体,然后将这些基本散射过程加以综合,获




图1 综合考虑一维孔链的基本散射过程建立光学异常透射的金属表面等离子模型^[5]
(a)~(c)中的入射波(黑色箭头)依次为金属表面等离子体波、孔链基模、入射平面波

得描述光学异常透射的一组解析表达式。如图2所示,该模型能够给出异常透射谱的主要特征,包括谱线形状、发生透射增强的波长 λ 的数值等,从而定量给出了金属表面等离子体波对异常透射的贡献,调和了之前关于表面等离子波在异常透射中所起作用的争论。通过分析模型方程发现,当孔阵列中各孔链激励的表面等离子波在金属表面发生相长干涉时,会在金属表面形成很强的表面等离子波分布,从而增强透射场,这样,就明确了金属表面等离子体波形成光学异常透射的微观动力学过程,并且为之前提出的表面准周期模式、Fano模型中的离散共振态等提供了物理解释。然而,图2的结果同时也表明,金属表面等离子模型预言的峰值透过率要低于实际的峰值透过率。进一步的研究表明^[5],随着波长由可见光逐渐增大到中红外甚至更长波段(如太赫兹或微波波段),光学异常透射现象仍然广泛存在,但金属表面等离子模型预言的峰值透过率和实际透过率的比值将迅速降低,模型误差迅速增大,特别地,在太赫兹或微波波段,金属接近理想导体,金属表面等离子体模型预言的峰值透过率为0。




图2

虚线为光学异常透射的透射谱,实线为金属表面等离子体模型预言的结果,其中,孔面积占总面积的8%, T 为不同照明波长 λ 对应的透过率, a 为孔阵列周期, θ 为入射角^[5]

由此可知,我们对于光学异常透射现象的认识还远没有结束。通过分析亚波长一维孔链激励的金属表面波成分,发现其中除了金属表面等离子体波之外,

还存在另外一种表面波成分,其沿金属表面的传播特性在孔链附近类似于自由空间中线源激励的柱面波,不同之处在于该表面波成分仅存在于金属表面附近区域,因此称为准柱面波。由此推断,金属表面等离子体模型存在误差的原因是忽略了这样一种准柱面波成分。

因此,如何全面考虑金属表面波的所有成分对光学异常透射的贡献,从而彻底明确发生光学异常透射的物理机制,是一个需要深入研究的科学问题,这个问题的困难之处在于:全面考虑金属表面波的所有成分对异常透射的贡献要远比只考虑金属表面等离子体波的贡献复杂。例如,此时不仅要考虑金属表面等离子体波在孔阵列表面的散射,还要考虑准柱面波的散射,以及金属表面等离子体波与准柱面波之间的相互转化。同时,准柱面波的物理性质远比金属表面等离子体波复杂,后者属于单一的电磁场模式,其传播和衰减规律比较简单,已经获得了充分的研究,而对于前者的研究才刚刚开始。初步的研究结果表明,和金属表面等离子体波类似,这种准柱面波也只能在特定的光波偏振态下才能存在,不同的是,这种准柱面波并非单一的电磁场模式,其沿金属表面的传播在不同的距离范围内呈现出不同的复杂特性,这些都预示着对于准柱面波的研究,已有的结果将提供有益的借鉴,但同时也将是一项困难的工作,还有待开展大量深入细致的研究。

我们期待着能彻底解决光学异常透射现象的微观解释问题,从而不仅为光学异常透射现象走向实际应用铺平道路,而且将从本质上深化我们对光波与亚波长结构相互作用的认识,最终实现在亚波长尺度下对光波的操控。

参 考 文 献

- [1] Ebbesen T W, Lezec H J, Ghaemi H F, et al. Extraordinary optical transmission through sub-wavelength hole arrays. *Nature*, 1998, 391: 667—669.
- [2] Martin-Moreno L, García-Vidal F J, Lezec H J, et al. Theory of extraordinary optical transmission through subwavelength hole arrays. *Phys. Rev. Lett.*, 2001, 86(6): 1114—1117.
- [3] Genet C, van Exter M P, Woerdman J P. Fano-type interpretation of red shifts and red tails in hole array transmission spectra. *Opt. Commun.*, 2003, 225: 331—336.
- [4] Gay G, Alloschery O, de Lesegno B V, et al. The optical response of nanostructured surfaces and the composite diffracted evanescent wave model. *Nature Physics*, 2006, 2: 262—267.
- [5] Liu H T, Lalanne P. Microscopic theory of the extraordinary optical transmission. *Nature*, 2008, 452: 728—731.

撰稿人: 刘海涛
南开大学现代光学研究所

从光学衍射极限到超分辨率成像和加工

From Optical Diffraction Limit to Super-resolution Imaging and Processing

光学是一门历史悠久的学科,直到今天,仍然对人们的生活发挥巨大的影响。作为光学的一个分支,光学成像和加工技术在最近几十年的发展是最令人瞩目的,它不仅让人们光学产生新的认识,而且还推动了微电子、生物医药、通信和纳米技术的发展。本文回顾了光学成像和加工的最新进展,着重探讨各种突破衍射极限的技术,并进一步阐述光学加工在微纳米制造上的应用。

1. 衍射极限

我们知道,当物体或小孔的尺寸接近或者小于光波长的时候,光会通过散射继续传播而产生衍射现象^[1]。如果两个很小的物点靠得很近,由于衍射的原因,像点就会重叠而不容易区分。Abbe 提出,显微成像系统的分辨率 r 可以用下面的公式表示:

$$r = \frac{\lambda}{\sin(\alpha/2)} \quad (1)$$

式中, λ 是入射光波长; α 是物镜的孔径角。Rayleigh 引入数值孔径的概念,分辨率可以表示为

$$r = k_1 \frac{\lambda}{NA} \quad (2)$$

式中, k_1 因子是系统决定的系数,通常情况下其大小为 0.61,在微电子领域先进的光刻系统中,其大小一般为 0.4 或更小; NA 是物镜的数值孔径。随着科技向微观世界的发展,光学成像和加工不断趋近衍射极限,又不断突破它,并且引出新的极限。以下内容对微电子领域光学成像(光刻)和科研领域的微纳米加工作简要回顾。超分辨率成像带来的不仅是技术上的突破,还有一系列的科学挑战。

2. 超分辨率成像

最近几十年,微电子技术按照摩尔定律飞速发展,元器件尺寸越来越小,对光刻系统的分辨率要求就越来越高。根据公式(2),缩短波长是非常直接的提高分辨率的办法。光刻光源的波长已从汞灯的 436nm 和 365nm,逐渐推进到深

紫外准分子激光的 248nm 和 193nm。目前, 13.5nm 的超紫外(EUV)光刻系统的研发工作正在如火如荼地进行。此外, 增大物镜的数值孔径可以得到更小的聚焦光斑, 从而进一步提高系统分辨率。然而, 当集成电路的特征尺寸缩小到入射光波长量级的时候, 光学成像已经难以保证从物(掩模)到像(光刻胶)严格地按照比例对应。为了解决这个问题, 光学邻近校正、相移掩模和离轴照明技术逐渐被开发出来^[2]。随着技术节点进一步缩小, 浸入式光刻技术被广泛采用。用浸入技术提高分辨率的想法是 Abbe 首次提出来的, 并且在显微领域一直沿用至今。如果干式光刻的分辨率为 r , 则浸入式光刻的分辨率可以提高到 r/n , 其中, n 是浸入液体的折射率。使用 193nm 光源的水浸入式光刻, 微电路的尺寸可以缩小到 45nm 节点。而当前最成熟的浸入式光刻工艺通常使用水作为浸入液, 45nm 的线宽已经逼近其极限。如需进一步缩小线宽使其达到 32nm 技术节点, 一个直接的办法是使用具有更高折射率 n 的浸入液, 另外一种方法是用两次曝光成形技术来增强对比度。在超紫外光刻工艺完全成熟以前, 193nm 波长的浸入式光刻技术将作为主要的技术手段, 将线宽向下扩展到 22nm 节点。用数学模拟光刻过程以帮助提高分辨率的做法更加得到重视。

超紫外光刻技术使用极短波长(13.5nm)光源曝光, 从理论上来说, 从 22nm 一直到 11nm 的技术节点的处理都不会有衍射的影响。因为超紫外光在空气和其他材料上有非常强的吸收, 光刻处理需要特制的掩膜和光学元件, 并且需要在真空中进行曝光^[3]。对于超紫外光刻来说, 稳定的高功率超紫外光源、相应的掩膜制造和修复、高分辨率的光刻胶及低制造成本都是很大的挑战。由于超紫外光有非常高的光子能量(92eV), 与光刻胶的相互作用的物理、化学机制必然和深紫外光有所不同, 这个作用过程决定最终的分辨率。深入研究超紫外光与物质(光刻胶、掩膜等)的作用机制, 也会对分辨率的提高产生影响。成像技术将更好与数学工具结合, 在理论上预测曝光效果, 这能进一步有助于提高分辨率和生产线的产率。

3. 超分辨率加工

随着光学微纳米加工在最近几年快速发展, 一些超分辨率加工办法被陆续开发出来。

1) 光学近场微加工

(1) 微球辅助近场加工。

① 微球的近场增强效应。在做激光清洗实验的过程中, 玻璃微球常用来模拟表面污染物。研究人员意外发现, 激光照射后, 微球存在的地方能产生纳米尺寸的突起或凹坑。理论模拟表明, 入射光和散射光在微球和衬底之间的空间近场耦合, 光强能够增大数十倍。因此, 采用这一技术可以利用较低的能量密

度照射微球(大大低于衬底材料的激光加工所需能量密度阈值),从而在衬底表面形成纳米图案,如图1所示,图案的分辨率则由微球的大小、入射光波长和入射角度决定^[4]。使用248nm准分子激光作光源照射140nm的介质微球,可以生成30nm的图案。进一步的研究显示,连续改变入射光的入射角可以在衬底上刻出连续的线条,制造出预先设计的任意图案,分辨率可以达到80nm^[5]。此外,在激光加工的同时,还可以引入化学蚀刻,从而在更多材料上制作复杂的图案^[6],这是一种并行的纳米加工方法,可以一次曝光产生数以百万计的图案。




图1 利用微球的近场增强效应生成不同的图案^[5]

② 微球辅助激光直接刻写。近场增强加工的时候,通常微球是附着在衬底的表面。把微球从衬底分开一定距离,近场增强效应会随着距离增大而迅速减弱。如果适当地控制好微球和衬底之间的距离,可以在衬底表面保持足够的能量密度,在激光照射的同时移动微球,就可以生成预先设计好的图案。研究结果表明,生成的线宽可以控制在半波长以下。图2显示的是普林斯顿大学的研究人员使用微球辅助激光直接刻写画出的纳米级校徽,他们已成功利用355nm的激光光源刻写出102nm宽的线条^[7]。




图2 微球辅助激光直接刻写的普林斯顿大学校徽(大图标尺2μm,小图1μm)^[7]

(2) 扫描近场光学显微镜辅助激光加工。

扫描近场光学显微镜是高分辨率的表征工具，同时也可以用来做高分辨率的光刻和纳米加工。在做光刻的时候，其光纤探针前端的开口对生成的光阻图案的分辨率有决定作用。以波长 400nm 的飞秒激光作光源，可以在光刻胶上生成 20nm 的线条(如图 3 所示)^[8]。



图 3 扫描近场光学显微镜辅助激光加工的纳线(线宽 20nm)

(3) 扫描探针显微镜辅助激光加工。

扫描探针显微镜本身可以作为接触式微纳米加工的工具，但针尖的污染是很大问题。如果引入激光，控制好针尖和样品的距离，就会在针尖附近产生近场增强效应，在非接触的情况就可以实时制造出侧向分辨率为 10nm 的图案^[8]。图 4 是扫描探针显微镜辅助激光加工生成的纳米字符和纳线。




图 4 扫描探针显微镜辅助激光加工的原子力显微图像

2) 飞秒多光子吸收

飞秒激光的脉冲持续时间极短，可以实现非常高的瞬时功率，在聚焦到微

小区域的情况下，可以使被照射材料同时吸收多个光子，形成多光子吸收，这是一种非线性光学效应。多光子吸收的截面和有效作用体积都比单光子吸收小很多，从而使其相应的空间分辨率得到提高。激光加工普遍采用的是双光子吸收，其光斑的有效作用范围远低于激光波长，可以轻松突破衍射极限。使用波长 780nm 的飞秒激光，日本研究人员已制造出分辨率为 120nm 的微雕刻牛(如图 5 所示)^[9]。

3) 微透镜阵列加工

这种表面纳米图案化技术类似微球辅助近场加工，根据使用的微透镜大小和密度，以及曝光的脉冲方式，可以同时产生复杂的预设图案。由于是非接触式的加工方式，微透镜阵列加工有更大的灵活性，也解决了微球辅助近场加工带来的镜头无法重复使用和污染等问题。图 6 显示的是利用波长为 248nm 的激光光源在光刻胶上曝出 80nm 的点阵列^[10]。




图 5 用双光子吸收技术制作的纳米牛栩栩如生^[9]




图 6 用微透镜阵列制作出的纳米点阵列^[10]

4) 激光干涉光刻

激光干涉光刻技术使用光敏聚合材料记录激光干涉图案。两束激光相干的时候，光强产生周期分布，在光敏聚合材料上产生正弦变化的周期性驻波图案，它是制造大周期性、准周期性和空间相干结构的简单方法。使用适当的曝光光源和聚合材料，利用激光干涉光刻技术可以制作出特征尺寸为 100nm 的结构^[8]。

5) 等离子激元光刻

等离子激元在传播过程中透过亚波长尺寸孔会产生透射增强现象，与此同时，透射的电磁波出现很强的角度限制形成光聚束效应。利用等离子激元进行光刻，特征尺寸就不受衍射极限的限制，这些特性被用来制作光学超透镜。研

究显示,银超透镜的分辨率可以达到照明光波长的六分之一,如果使用 365nm 的激光光源,就可以产生 60nm 的线宽^[8]。

4. 结论

本文介绍了超分辨率成像和加工的一些最新进展。光刻工艺即将进入 22nm 技术节点,除了成熟的 193nm 浸入式光刻配合两次曝光成形技术之外,超紫外光刻成为最热门的光学手段之一。一些突破衍射极限的加工技术,如近场微纳米加工、飞秒多光子吸收、微透镜阵列、激光干涉光刻技术和等离子激光光刻等,被提出或重新得到关注。随着光学成像和加工不断发展,以及突破分辨率极限的记录不断刷新,也带来一系列科学难题:光学分辨率极限是多少?超紫外光与物质的作用有什么样的新物理、化学机制?多光子吸收能不能进一步缩小光斑的有效作用范围,从而提高分辨率?等离子激光光刻的超透镜材料或者结构能不能得到发展以使用更短波长的光源,从而提高分辨率?这些问题的解决有助于光学成像和加工的分辨率的进一步提高。这些微纳米加工技术给现有的超分辨率加工技术,如电子束、X 射线和质子束光刻技术,提供了高产率和低成本的纳米图案制造的选备方案,同时,这些新技术在光存储和光子晶体研究等方面也有很大的应用前景。

参 考 文 献

- [1] 母国光,战元龄.光学.第 2 版.北京:高等教育出版社,2009.
- [2] Wong A K K. Resolution Enhancement Techniques in Optical Lithography. Bellingham, Wash; SPIE Publications, 2001.
- [3] Wagner C, Harned N. EUV lithography; Lithography gets extreme. Nature Photonics, 2010, 4: 24—26.
- [4] Wang Z B, Hong M H, Luk'yanchuk B S, et al. Angle effect in laser nanopatterning with particle-mask. J. Appl. Phys., 2004, 96(11): 6845—6850.
- [5] Guo W, Wang Z B, Li L, et al. Near-field laser parallel nanofabrication of arbitrary-shaped patterns. Applied Physics Letters, 2007, 90(24): 243101—243103.
- [6] Guo W, Wang Z B, Li L, et al. Chemical-assisted laser parallel nanostructuring of silicon in optical near fields. Nanotechnology, 2008, 19(45): 455302.
- [7] McLeod E, Arnold C B. Subwavelength direct-write nanopatterning using optically trapped microspheres. Nature Nanotech., 2008, 3: 413—417.
- [8] Chong T C, Hong M H, Shi L P. Laser precision engineering: From microfabrication to nanoprocessing. Laser & Photonics Rev., 2010, 4(1): 123—143.
- [9] Kawata S, Sun H B, Tanaka T, et al. Finer features for functional microdevices. Nature,

2001,412:697—698.

- [10] Lim C S, Hong M H, Lin Y, et al. Microlens arrays fabrication by laser interference lithography for super-resolution surface nanopatterning. *Applied Physics Letters*, 2006, 89 (19): 191125—191127.

撰稿人：洪明辉 陈国新
新加坡国立大学电气和计算机工程系

单向性高品质因子非对称光学微腔

High- Q Unidirectional Asymmetric Microresonator

在经典力学中,一个粒子的运动行为完全由牛顿方程描述,即一旦知道某个时刻该粒子的位置和动量,就可以确定性地获得该粒子在未来任一时刻的运动状态。一般情况下,虽然粒子的状态演化是由运动方程确定性给出,但运动方程往往不可积,很难得到解析解,任一时刻的运动状态不得不依靠数值计算。人们甚至发现,对于某些系统的数学方程,相差很小的初始值会导致以后非常大的偏差,也即在庞加莱相图上产生混沌。我们常称这类遵从牛顿力学的确定性混沌为经典混沌。随着量子力学的产生,混沌的研究拓展到量子混沌,它与经典混沌“性格”迥异,有着千差万别^[1]。由量子力学基本原理可知,占有相空间有限体积的系统不可能有混沌运动,只有具有连续谱的系统才有可能出现混沌运动。也就是说,只有无限系统、可作经典近似或准经典近似的系统才可能有混沌运动。经典混沌运动是不稳定的,量子混沌运动则是稳定的,它只是系统不可积性的表现。研究混沌的一个极好的体系是台球系统(billard)。随着现代半导体微纳加工技术的发展,人们已经可以制造出光学台球系统,也即非对称光学微腔(asymmetric resonant cavity),为混沌研究提供了极佳的实验平台^[2,3]。

非对称光学微腔不但有着强烈的混沌理论研究背景,还展现出了广泛的应用前景。例如,与非对称光学微腔对应的是一类支持高品质因子(Q)回音壁模式(whispering gallery mode)的旋转对称光学微腔。基于回音壁模式的光学微腔已经逐步成为微纳光子学研究的主要实验平台之一,被应用于窄带滤波器、超低阈值微型激光器、高灵敏生化传感器和腔量子电动力学研究等。然而,回音壁模式微腔的应用一般需要在纳米尺度上精确地调节并控制光学微腔和外部耦合器件之间的距离,极大地增加了器件的操控复杂度,从而在一定程度上限制了回音壁模式光学微腔的实际应用。为此,人们开始研究其他更为简单有效的方法耦合腔内的模式,最有效的方法之一是打破回音壁模式微腔的旋转对称性,即研究非对称光学微腔^[3]。

非对称光学微腔的研究可以追溯到 20 世纪 90 年代,最早有关非对称微腔研究是在 1993 年,Levi 在实验中制备了变形的圆盘腔,得到了方向性出射的低阈值的激光^[4]。接着,Mekis 在掺有增益介质的自由下落的液滴中观察到了方向性发射的激光^[5]。对人们来说,这在当时是一个很新奇的现象:在变形的腔中,

不仅有很好的方向,而且有很高的 Q 值。利用这一特性,研究人员利用半导体材料实现了高功率的方向性出射的量子级联激光器^[6]。近年来,这种非对称的微腔引起了研究人员的广泛关注,将实验扩展到了不同的形状和不同材料的光学微腔中,制备了跑道形、四极形、螺旋形及半圆半四极形的微腔,均实现了高 Q 和高方向性的发射。

与实验同步,非对称光学腔的理论研究也取得了很多进展。腔中的电磁场模式可以通过求解电磁场的Maxwell方程得到,但由于其边界的非对称性,无法解析求解,这也是不可积系统的一个特点,只能通过数值计算求解方程组来得到本征模式。目前的计算机的能力也很难求解三维的微腔,故一般将问题简化为二维。虽然实际实验体系(微球腔、微盘腔)都是三维的系统,但我们研究的模式主要分布在一个特定平面附近,故该简化的模型能够较好地与实验符合。目前,边界元方法被常用来求解二维Helmholtz方程,且该方法能够比较精确地求解高 Q 的模式^[7]。

为了得到清晰的物理图像,Nockel等将量子混沌研究中的光线动力学工具引入到光学微腔中^[8]。当腔尺寸远大于波长时,我们可以近似地用光线来描述光场的传播。腔内部的光线运动可方便地在二维相空间中由一对参数 $(\phi, \sin\chi)$ 描述,其中, ϕ 与 χ 分别为入射在边界上的光线的入射点极坐标角度和入射角。随着时间的推演,我们可以得到一系列点,从而在简单的台球模型中(不考虑耗散的光线反射,即封闭的边界)研究腔中的光线轨迹,即庞加莱相图。庞加莱相图分布着三类结构:KAM曲线、岛结构和混沌,分别对应于准周期运动、周期运动和无规则运动,并且光线不会从一个结构运动到另一个结构。区别于传统量子混沌台球模型的是:非对称光学微腔具有有限的折射率,光线不可能永远囚禁在腔内。光线介质腔边界上的反射可能存在光出射机制:隧穿与折射。

尽管非对称腔的研究在理论和实验上已经取得很多重要的进展,其腔模的品质因子和发射(即泄漏)方向性一直没能同时得到改善。正如前面提到的,若腔的变形度较小,则 Q 值高,但为多发性发射,而增大腔的变形度则降低了 Q 值,但能抑制发射点的反向发射。如何设计并在芯片上制备出高品质因子非对称光学微腔,得到真正单方向性发射是非对称光学微腔未来的发展趋势。高 Q 值单方向发射的非对称光学微腔能够更好地应用于高效可控单光子光源研制、低阈值微型激光器、生化传感器等交叉学科研究。

参 考 文 献

- [1] Stöckmann H J. Quantum Chaos: An Introduction. Cambridge, Cambridge University Press, 1999.

- [2] Vahala K J. Microcavities. Singapore: World Scientific, 2004.
- [3] Xiao Y F, Zou C L, Li Y, et al. Asymmetric resonant cavities and their applications in optics and photonics: A review. *Frontiers of Optoelectronics in China*, 2010, 3(2): 109—124.
- [4] Levi A F J, Slusher R E, McCall S L, et al. Directional light coupling from microdisk lasers. *Applied Physics Letters*, 1993, 62(6): 561—563.
- [5] Mekis A, Nockel J U, Chen G, et al. Ray chaos and Q spoiling in lasing droplets. *Phys. Rev. Lett.*, 1995, 75(14): 2682—2685.
- [6] Gmachl C, Capasso F, Narimanov E E, et al. High-power directional emission from microlasers with chaotic resonators. *Science*, 1998, 280(5369): 1556—1564.
- [7] Zou C L, Yang Y, Xiao Y F, et al. Accurately calculating high quality factor of whispering-gallery modes with boundary element method. *J. Opt. Soc. Am. B*, 2009, 26(11): 2050—2053.
- [8] Nockel J U, Stone A D. Ray and wave chaos in asymmetric resonant optical cavities. *Nature*, 1997, 385: 45.

撰稿人：肖云峰
北京大学物理学院

纳米光学天线

Nanometer Optical Antennas

传统天线将微波或射频波信号由自由空间耦合放大或直接将信号发射至自由空间传输,是人类直接控制电子实现信号传输与接收的重要装置。近年来,随着信息传输容量的增大,传统的电子器件在传输速率、容量及带宽方面已不能满足现代通信的需求。另一方面,由于光子速率比电子快上千倍,在容量、带宽及并行处理等方面具有电子无法比拟的优势,使得全光网络成为未来高速、大容量通信的发展趋势。然而,受衍射极限的限制,常规器件无法实现纳米级的光学聚焦,使目前基于光子操控的全光通信网络仅是人类的一种奢望。

人类真的不可能突破衍射极限实现纳米量级的光学聚焦吗?

2003年,斯坦福大学的Crozier小组发现微米尺度的金属薄膜条阵列对 $10.6\mu\text{m}$ 激光具有很强的聚束和增强效应,非常类似于微波天线的性质,故将其命名为光学天线^[1],这一发现使人类迎来了实现纳米级光学聚焦的曙光。随后,2005年,Hecht小组在*Science*上报道了一种尺寸更小的金偶极光学天线,其共振波长位于可见光波段,实现了纳米量级的光学聚焦^[2]。2006年,哈佛大学的研究者在830nm激光二极管上制作了两个长为130nm、宽为50nm、间隔为30nm的金偶极天线,并成功将光束聚焦至30nm。当人们欣喜地看到这些进展时,一个严峻的问题摆在了我们面前:这种纳米光学天线的机理是什么?

针对这一问题,研究者们提出了多种解释。一种主流的解释为:光在天线的亚波长小孔表面发生衍射和散射,产生倏逝场。倏逝场的一部分基于隧道效应穿透到小孔的另一面并被散射,形成传播场,与透射场和衍射场干涉叠加。由于表面倏逝场携带了所有高频分量,衍射和透射场携带了所有低频分量,因而实现超衍射极限聚焦,并使总能量传输效率得到了提高。另一种主流的解释为:光入射到光学天线上,当动量匹配时,激发了强烈的自由电子集体振荡,即表面等离子体激元共振(SPP),其在一定条件下重新激发形成巨大的场增强。其他的解释还包括F-P腔共振、波导共振等。上述观点虽然部分解释了纳米天线的机理,但却无法得到与实验结果完全吻合的结果,且无法解释一些特殊的现象(如光学天线透射峰随小孔直径增大而产生红移的现象^[3])。那么,纳米光学天线真正的工作机理是什么?如何才能全面、正确地解释其超强的光收集现象?

当人们抛开纳米光学天线工作机理问题的困扰,试图对其进行结构设计时,

另一重要问题又浮现出来：光学天线的微纳结构与其光学特性的关系是什么？尽管已有的研究表明，金属微纳结构、负折射材料结构、变形光学结构等均可在光波段实现纳米级的光学聚焦，但同时人们发现，光学天线的共振条件会随天线结构的改变而改变^[4]。例如，对于三角形天线，其共振波长与天线间隙及入射光的偏振状态相关；在梯形对称振子天线中，通过减小振子长度可使共振波长蓝移，且其增强因子也随之变小。那么，纳米天线的结构与其共振波长、增强因子等之间有着什么样的联系？光学天线微纳结构与其光学特性之间的关系究竟是什么？

在研究者们被纳米光学天线的难题困扰的同时，也被它所展现出的诱人前景深深吸引。事实上，当我们仅把纳米光学天线归结为一种通信器件时，它却悄然在超衍射极限成像、纳米光刻、量子单光子源、高效太阳能电池等领域为我们展现出其迷人的另一面。Hecht 小组在原子力显微镜探针端面上制作了长度约为一个波长的蝴蝶结形光学天线，并基于该天线发现了量子发射增强现象，其理论预测分辨率与为其反馈间隙（约为 50nm）；Sundaramurthy、Schuck 等在硅衬底上集成了蝴蝶结形金偶极天线阵列（单个天线尺寸为 $80 \pm 5\text{nm}$ ，间隔为 16~40nm，覆盖 75nm 光刻胶）。通过 800nm、27mJ 光照射，在光刻胶上获得了约 30nm 的特征长度^[5]；van Hulst 小组将长为 80nm 的铝制单偶天线接近一个发光分子，通过改变光与天线的耦合方式，使分子发出的光被重新导向 90° ^[6]，为形成基于光学天线的量子单光子源奠定了基础；美国能源部爱达荷州国家实验室、Micro Continuum 公司、Missouri 大学正在合作研究用于太阳能面板的纳米光学天线，此类天线可工作于红外谱段，其对日光的吸收效率有望接近 80%。

随着人类对未知领域的不断探索，目前已能够对半导体或金属材料中的电子进行自如地操控。现在，当我们转而试图对现有材料中的光子进行操控时，纳米光学天线的相关问题成为人类通向这一目标必须逾越的障碍。那么，人类能否最终解决这些难题，进而引发一次新的科技革命？让我们拭目以待。

参 考 文 献

- [1] Crozier K B, Sundaramurthy A, Kino G S, et al. Optical antennas: Resonators for local field enhancement. *J. Appl. Phys.*, 2003, 94(7): 4632—4642.
- [2] Muhlshlegel P, Eisler H J, Martin O J F, et al. Resonant optical antennas. *Science*, 2005, 308(5728): 1607—1609.
- [3] Ebbesen T W, Lezec H J, Ghaemi H F, et al. Extraordinary optical transmission through subwavelength hole arrays. *Nature*, 1998, 391(6668): 667—669.

- [4] Fromm D P, Sundaramurthy A, Schuck P J, et al. Gap dependent optical coupling of single “bowtie” nanoantennas resonant in the visible. *Nano Lett.*, 2004, 4(5):957-961.
- [5] Sundaramurthy A, Schuck P J, Conley N R, et al. Toward nanometer scale optical photolithography: Utilizing the near-field of bowtie optical nanoantennas. *Nano Lett.*, 2006, 6(3):355-360.
- [6] Taminiau T H, Stefani F D, Segerink F B, et al. Optical antennas direct single-molecule emission. *Nature*, 2008, 454(7214):251-255.

撰稿人：宋 勇 王涌天
北京理工大学光电学院

可集成的低折射率高非线性材料

Integrated Photonic Materials with Low Refractive Index and Strong Nonlinearity

硅作为一种不可或缺的材料,在过去的几十年里已经为集成电路工业的发展和信息革命提供了强有力的支撑。硅在电子学里的成功已经展示了其不可辩驳的控制电子的能力。近年来,硅光子学也成为研究热点,这主要是由于硅在近红外波段具有很低的本征损耗、很高的折射率和很强的 Kerr 和拉曼非线性^[1~3]。现有的电子工业的基础设施可以为硅光子器件的加工降低成本。更重要的是,硅光子学的发展为建立 CMOS 兼容的大规模光电集成系统铺平了道路,由此,人们可以把电子在计算方面的优势和光子在通信方面的优势整合起来,从而实现更大容量的高速信息处理系统^[3]。

一般来讲,光通信和光信号处理代表了两类不同的器件和子系统,尽管有些情况下不太容易严格地区分它们。在光通信中,光的子系统包括了信号的产生、检测、放大、滤波及光路中各种有害效应的监测和补偿^[4]。光信号处理则具有更丰富的内涵^[5],即使是与通信有关的部分也包含了诸如脉冲整形、数据路由和光逻辑等方面。我们注意到,相当多的光信号处理功能是通过光学非线性效应实现的。

在硅波导中,光学非线性得到了极大的增强,这来自于两方面的贡献:首先是材料中的 Kerr 和拉曼非线性系数比光纤增加了 100~1000 倍;其次是高的芯区和包层折射率对比使模式场面积减小 100~1000 倍,因此,总的非线性增大了约 5 个量级。各种非线性效应,如自相位调制、交叉相位调制、参量光波混频、双光子吸收和拉曼效应已经得到实验的验证。但是,一个值得注意的问题是:集成的硅光波导通常只有厘米量级的长度,而用于非线性相互作用的光纤可以达到公里量级的长度,换句话说,硅波导中的光相互作用距离减小了约 5 个量级。因此,使用普通的硅波导并不能有效地提高非线性转化效率或者降低对泵浦功率的要求。

从另一方面讲,硅波导的高折射率对比产生了很强的波导色散,这意味着很小的波导尺寸的变化即可使色散发生很大改变。通常,这被认为是硅波导在色散调谐方面的优势。但是,事实上,强的波导色散带来了两个负面效果:第一,色散随波长快速变化,色散曲线的平坦度很差,而且通常只有一个色散零点;第二,如果模式面积减小,这个色散零点往往偏离感兴趣的波长范围,移

向了更短的波长,从而有害的双光子吸收作用更显著了。

这些问题严重限制了硅波导在光信号处理领域的应用。因为一个信号处理子系统往往是很多个单一功能器件级联得到的。类比于电信号处理,一个单一的逻辑门或者加减法单元无法实现真正意义上的信号处理。光学器件如果不能有效地降低功耗和提高信号质量,就不能真正提供高端的信号处理功能。

一种被称为沟道波导或者槽状波导的新型硅波导带来了新的突破^[6]。当沟槽的材料具有低折射率并且尺寸在几十纳米范围内的时候,与沟槽表面正交的偏振光会在表面上增强,这种增强来自于高的折射率对比。大部分光将被限制在这样的纳米尺度的沟槽中,光波的模式面积可以因此减小 10 倍以上。硅提供了高折射率和高非线性,如果沟槽的材料也具有高非线性,那总的非线性系数可以被极大地增强。简而言之,找到低折射率、高非线性的光学材料对于光学材料和器件研究具有重要意义。

但是,从非线性材料的研究中,人们认识到,低折射率并且高非线性的光学材料并不容易得到。早在 1964 年,Miller 得出结论,光的三阶非线性强度和线性折射率相关。材料的三阶电极化率随着线性折射率的增加而增加^[7]。

$$\chi^{(3)} = \left(\frac{n^2 - 1}{4\pi} \right)^4 \times 10^{-10}$$

这样的关系大体上适用于很多近年来广泛研究的新型非线性光学材料^[8,9]。然而,这种非线性系数的规律是否对自然界中所有的光学材料都适用尚不是非常清楚。能否找到人工合成的新型光学材料来突破这样的材料特性的限制也是悬而未决的问题。如果存在更好的新型材料,它和硅材料是否具有兼容性仍是值得研究的。此外,是否能针对这样的新材料找到可行的光刻和刻蚀方法从而实现高集成度的光信号处理系统则构成了新的研究课题。

总之,材料科学的创新可能成为新的光学工程和技术革命的先导,同时,对现有的工程和产业领域的发展方向及技术瓶颈的深入了解也为材料科学研究提供了新的目标和方向。除了低损耗的要求外,低折射率和高非线性光学材料的出现可能成为发展高速率、大容量、低功耗的光信息处理系统的基础。

参 考 文 献

- [1] Pavesi L, Lockwood D J. Silicon Photonics. Berlin; Springer, 2004.
- [2] Reed G T. Silicon Photonics: The State of the Art. New York; Wiley, 2008.
- [3] Pavesi L, Guillot G. Optical Interconnects: The Silicon Approach. Berlin; Springer, 2006.
- [4] Kaminow I P, Li T, Willner A E. Optical Fiber Telecommunications. 5th ed. New York; Elsevier, 2008.
- [5] Ishikawa H. Ultrafast All-Optical Signal Processing Devices. New York; Wiley, 2008.

- [6] Almeida V R, Xu Q F, Barrios C A, et al. Guiding and confining light in void nanostructure. *Opt. Lett.*, 2004, 29: 1209—1211.
- [7] Miller R C. Optical second harmonic generation in piezoelectric crystals. *Applied Physics Letters*, 1964, 5: 17—19.
- [8] Monro T M, Ebendorff-Heidepriem H. Progress in microstructured optical fibers. *Annu. Rev. Mater. Res.*, 2006, 36: 467—495.
- [9] Price J H V, Monro T M, Ebendorff-Heidepriem H, et al. Mid-IR supercontinuum generation from nonsilica microstructured optical fibers. *IEEE Journal of Selected Topics in Quantum Electronics*, 2007, 13: 738—750.

撰稿人：张 林

美国南加州大学电子工程系

金属在紫外-微波波段的吸收特性

Absorption Properties of Metals in the Wavelength Region from UV to Microwave

金属及其合金由于其独特的机械、化学及电学特性应用非常广泛。然而,从紫外到微波,金属都是优良的反射体,吸收特性较差。如果能够改善金属在超宽频带(紫外-微波)内的吸收特性,使其从高反射材料转变为高吸收材料,则这种吸波金属材料具有非常广阔的应用前景,如太赫兹隐形技术、天文(太赫兹)光谱探测、传感器、通信带宽的拓展、印刻加工及新型验证码图案的制作等^[1]。

早在1930年,Pfund就发现了有良好吸收特性的“黑色金属”(因在可见光波段内吸收较强,反射较弱,故看上去呈“黑色”;若只吸收某些波长范围的可见光,则呈“彩色金属”),这种黑色金属是通过在密封的容器内利用钨丝加热金属样品,蒸发沉积在衬底上形成的金属薄膜^[2]。在随后的几十年内,科研工作者采用类似的方法系统地研究了各种金属及合金的沉积膜,发现孔状金属薄膜的吸收增强特性受到容器内气体介质种类、压强、加热温度等因素的影响。此外,在空气中,这种薄膜的吸收增强特性不稳定,有老化现象。采用这种方法增强金属的吸收特性有一定的局限性,如需要衬底^[3]。

自从1960年世界上第一台激光器出现之后,激光就成为金属加工的利器,包括切割、焊接、钻孔、打标、去除表面缺陷及快速成型等。而飞秒脉冲激光由于脉冲持续时间极短,可以在较低能量条件下获得极高的峰值功率,最高可达拍瓦量级(10^{15} W),聚焦功率密度可达 $10^{20} \sim 10^{22}$ W/cm²。因此,通过聚焦飞秒激光可将能量集中在有限的空间区域内,实现对金属的精细微加工。相对于连续光、纳秒及皮秒脉冲激光,飞秒脉冲激光在金属微加工中避免了等离子体屏蔽和金属热扩散等问题,加工区域几乎没有熔融区,没有重铸层,不产生微裂纹,避免了热熔化的存在,实现了相对意义上的“冷”加工,大大减弱和消除了传统加工中热效应带来的诸多负面影响,具有很高的精度和重复性。此外,加工区域可以小于聚焦尺寸,突破光的衍射极限,具有很高的空间分辨率。

为了寻求更加简便和快捷的制备吸波金属材料的方法,Vorobyev等利用飞秒脉冲激光对金属表面进行微加工^[4],选用接近烧蚀阈值的功率密度,在光斑区域形成纳米结构分布。随着作用脉冲数目的增多,在光斑中央区域逐渐形成亚波长的表面覆盖金属纳米粒子的周期结构,即激光诱导的周期表面结构(NC-

LIPSS), 也称周期光栅结构, 这种结构可以在很大程度上改变金属材料的吸收性质。尽管对于这种结构形成的物理机制仍然存在不同的解释, 不过可以肯定的是, 表面等离子体激元对吸收增强起到了至关重要的作用。另一方面, 若结合三维微位移平台或振镜实现光栅扫描的加工形式, 可以形成微米级(几个到几百微米)周期光栅结构, 周期可以通过微位移平台步进尺寸或者振镜偏转角度来确定。Vorobyev 等采用这种方法加工出的“黑色铝”在 $250\text{nm} \sim 2.5\mu\text{m}$ 范围内的反射率近似为 0。

很明显, 除了周围环境, 飞秒脉冲激光的参数对微加工结果具有非常显著的影响, 这些参数包括单个脉冲能量、脉冲重复率、作用脉冲个数、波长、脉冲持续宽度、激光扫描速率、偏振特性及激光入射角等。这些参数对改善金属吸收增强效应存在哪些具体的影响? 如何将吸收范围进一步拓展至太赫兹及微波波段? 如何选择性地实现某一特殊波段的吸收增强? 根据基尔霍夫定律, 好的吸收体同样是好的发射体, 那么, 在获得(紫外-微波)吸波金属材料后, 能否将其转为超宽频带且具有平坦光谱响应的光源^[5]? 这无疑也是新型光源的一个突破点。诱导激光的偏振特性决定了光栅结构的取向, 假设这种吸波金属可以作为新型光源, 它是否具有对应的偏振特性呢? 所有这些问题都是今后应该努力研究的方向, 具有很大的挑战性。

参 考 文 献

- [1] Dusser B, Sagan Z, Soder H, et al. Controlled nanostructures formation by ultra fast laser pulses for color marking. *Optics Express*, 2009, 18(3): 2913—2924.
- [2] Pfund A H. Bismuth black and its applications. *Rev. Sci. Instrum.*, 1930, 1: 397—399.
- [3] Advena D J, Bly V T, Cox J T. Deposition and characterization of far-infrared absorbing gold black films. *Appl. Opt.*, 1993, 32(7): 1136—1144.
- [4] Vorobyev A Y, Guo C L. Colorizing metals with femtosecond laser pulses. *Applied Physics Letters*, 2008, 92(4): 041914.
- [5] Vorobyev A Y, Makin V S, Guo C L. Brighter light sources from black metal: Significant increase in emission efficiency of incandescent light sources. *Phys. Rev. Lett.*, 2009, 102(23): 24301.

撰稿人: 兰 胜

华南师范大学信息光电子科技学院

太阳能电池提高光子能量利用率及转换效率的问题

Increasing the Conversion Efficiency of a Solar Cell

自从太阳能电池出现以来,提高光电转换效率一直是太阳能电池领域研究的重要课题之一。高效半导体太阳能电池的研究从基本的科学问题上来说,是如何充分吸收太阳光谱中的每个光子产生电子-空穴对,然后将电子和空穴对有效地分离产生电流,并尽量将每个光子携带的能量转换为电能,对目前的半导体高效太阳能电池,前者的效率即量子效率已超过 90%^[1,2],没有多少潜力,而后者仍有很大的提高空间。当半导体吸收能量大于其带隙的光子将电子从价带激发到导带后,多余的能量 ΔE 将以热能的形式传递给半导体材料而不能转换成电能,对电池的转换效率没有贡献,如图 1 所示。而且,对半导体太阳电池,即使吸收能量和带隙相同的光子,转换成的电能也比光子的能量小约 400meV,如对于 GaAs 太阳电池,其室温下的带隙宽度为 E_g 为 1.42eV,而不论光子的能量比带隙能量高多少, GaAs 吸收一个光子产生的电能最多约为 1.0eV,损失至少 420meV。




图 1 半导体中光吸收及光电转换过程

对于半导体单结太阳电池,由于受半导体带隙大小的限制,只能吸收能量大于或等于其禁带宽度的光子,存在吸收长波限,即不能吸收和利用能量低于其带隙宽度的波段的太阳光。为了吸收尽可能多的太阳光子,选用带隙较小的半导体材料可以覆盖太阳光谱的更多部分,但高能量的光子由于和带隙的能量差更大而导致损失更多的能量,所以,提高单结太阳电池的转换效率需要在吸收光子的数量和光子能量利用率之间取得一个平衡,这也是单结太阳电池受到其带隙的限制而转换效率不会太高的原因。为了既能充分吸收太阳光谱中的每个光子,又尽可能利用每个光子的能量,科学家们提出了一些试图提高转换效率的新概念:①多结电池^[2]。多结结构中的每一结分别吸收不同能量段的光子,

这样,可以提高每个能量段的光子能量的利用率,但对于每结电池,一个光子产生的电能比其吸收带隙小约 400meV ,即每个光子至少损失约 400meV 的能量,中低能段的光子能量利用率更低,如吸收能量为 0.67eV 的光子的太阳电池的光子能量利用率低于 35% 。②多激子产生。多激子产生是为了减少高能光子由于热迟豫而损失的能量 ΔE 提出的概念,如图 2 所示,如果光子的能量大于半导体带隙的两倍,吸收光子后产生的电子可以将多余的能量 ΔE 转移给另外一个电子并使其激发到导带中,产生另一个导电电子^[3,4]。这样,一个电子可产生两个或更多个电子,从而减少高能光子由于和半导体带隙的能量失配导致的热损耗。虽然量子效率可以大于 100% (分内外量子效率,内量子效率为材料吸收光子后产生的电子-空穴对数与吸收的光子数的百分比,外量子效率为吸收光子后产生的电子-空穴对数与照射到电池表面的光子数的百分比),但每个光子将损失两个或多个 400meV 的能量,虽然量子效率获得大幅度提高,最终的光电能量转换效率不会有明显的提升。③中间带吸收。为了提高光子能量利用率来提高太阳电池的转换效率,科学家们提出了中间带吸收的思路。在半导体禁带中产生一个中间带,通过光子的级联吸收^[5,6],两个光子产生一对电子-空穴,如图 3 所示,两个光子共损失约 400meV 。如果半导体带隙中有两个或多个中间带,这样,三个或更多的光子总共损失 400meV 的能量,提高了每个光子的能量利用率。在光子级联吸收过程中,要求吸收光子在每个子带上产生的电子有足够长的寿命以保证随后再吸收光子使电子向更高的能级跃迁,实现能量的累加,另外,还要求该子能级以下的能级有电子占据,之上的能级有空态,实现光子的级联吸收。光子的级联吸收(中间带吸收)具有几个光子总共损失 400meV 的能量从而提高光子能量的利用率及电池的效率高优势。然而,制备满足要求的中间带吸收材料就技术而言极具挑战性,基于其他概念的新型太阳电池,如有机和无机材料的复合材料可能会在效率上取得较大的突破。




图 2 半导体中多激子产生过程




图3 半导体中间带光子级联吸收过程

参 考 文 献

- [1] King R R, Law D C, Edmondson K M, et al. 40% efficient metamorphic GaInP/GaInAs/Ge multijunction solar cells. *Applied Physics Letters*, 2007, 90(18): 1—3.
- [2] Guter W, Schöne J, Philipps S P, et al. Current-matched triple-junction solar cell reaching 41.1% conversion efficiency under concentrated sunlight. *Applied Physics Letters*, 2009, 94(122): 1—3.
- [3] Luque A, Martí A, Nozik A Z. Solar cell based on quantum dots: Multiple exciton generation and intermediate bands. *MRE Bulletin*, 2007, 32(236): 240.
- [4] Kim S J, Kim W J, Sahoo Y, et al. Multiple exciton generation and electrical extraction from a PbSe quantum dot photoconductor. *Applied Physics Letters*, 2008, 92(3): 1—3.
- [5] Luque A, Martí A. Increasing the efficiency of ideal solar cells by photon induced transitions at intermediate levels. *Phys. Rev. Lett.*, 1997, 78(26): 5014—5017.
- [6] Wei G D, Forrest S R. Intermediate-band solar cells employing quantum dots embedded in an energy fence barrier. *Nano Lett.*, 2007, 7(1): 218—222.

撰稿人：董建荣

中国科学院苏州纳米技术与纳米仿生研究所

有机柔性发光二极管

Organic Flexible Light Emitting Diode

在当今信息时代,多媒体网络飞速发展,如果没有赖以获取信息的各种显示器,我们就像失去了双眼。从小到零点几英寸的手表盘到数十英寸的计算机或液晶显示屏,直至上百平方米的超大显示屏,人们从这些显示屏上获取信息,并利用这些信息了解、改造人类社会和自然界。但是,您能想象有天将电视屏幕折叠起来收入囊中,或将手机像纸一样卷起来装入口袋?近年来,随着有机柔性发光二极管技术的迅速发展,已经让这些梦想逐渐成为现实。

目前,有机发光二极管(OLED)的研制一般是以刚性玻璃为衬底,在其表面生长ITO透明导电薄膜作为阳极,然后将有机小分子或聚合物发光材料和载流子传输材料用真空热蒸镀或溶液旋涂等方法在ITO表面依次制备空穴注入/传输层、发光层和电子注入/传输层,最后热蒸镀低功函数的金属薄膜作为OLED的阴极^[1,2]。这类器件虽然有优良的发光性能,但由于是以玻璃为衬底,其抗震动、抗冲击能力都比较弱,发光二极管也相对较重,携带不方便,因此,其应用受到一定限制。

作为全固态化的电致发光器件,OLED最大的优点是能够实现柔性显示。1992年,Gustafsson和曹镛等发明了基于PET为衬底、导电聚合物PANI/CAS为阳极的柔性聚合物材料的OLED,器件的外量子效率达到了1%,启亮电压约为2~3V^[3]。1997年,Gu等也发明了柔性小分子材料的OLED,发现小分子的有机半导体材料也有优异的机械性能,在连续弯曲后,其发光性能没有明显衰减^[4]。在柔性OLED研究方面,国内起步较晚。2004年,清华大学邱勇教授课题组和北京维信诺科技有限公司共同开发了国内第一款点阵式有机柔性显示屏,与刚性OLED相比,这种柔性OLED具有耐冲击、抗震能力更强、重量轻、体积小、携带方便、成本低廉等特点,因而日益成为国际显示行业的研究热点之一。此外,柔性OLED显示屏批量生产后可望进入电子纸市场。

柔性OLED显示器经过近二十年的发展取得了一些进展,最近,Sony公司开发出了一款4.1英寸、能360度卷曲的全彩色柔性OLED显示屏,卷返1000次后,显示效果仍不受影响。但是,柔性OLED的发光效率和寿命与刚性OLED显示器相比还有很大差距,产业化生产还有许多问题需要解决,主要表现在电极材料及有机层的附着性能、柔性衬底的气密性、封装与驱动技术等。其中,柔性衬底材料对OLED性能影响尤为重要,它不仅要有足够的柔性,同

时还要能有效隔绝湿气和氧气的的能力,此外,还必须有一定的强度保证其实际应用的要求。目前,广泛采用金属薄膜为柔性 OLED 的衬底材料,虽然金属薄膜能承受高温,但其表面粗糙度高,并且不透光,因此,基于金属薄膜为衬底的柔性 OLED 需采用顶发射结构,这就需要设计和开发高平整度与高反射率的阳极材料及高透光率和有效电子注入的阴极材料,这对相关材料科学来说是一大挑战。另一种柔性衬底材料是柔性聚合物衬底材料(如 PET、聚酰亚胺等),这类衬底材料具有易制备、质量轻、柔韧性好等优点,但这些材料对水和氧的阻挡能力极差。Charton 等通过在柔性聚合物衬底上分别溅射 Al_2O_3 层和有机-无机交替多层膜能够有效地阻隔氧气和水汽对柔性 OLED 性能的影响,所制备的器件在亮度和刚性衬底器件十分接近^[5]。柔性聚合物衬底所能承受的最高温小于 200°C ,所以,在塑料衬底上很难生长高透光率、低电阻率的 ITO 薄膜,更严重的是,低温 ITO 常与聚合物衬底之间的附着力不好,在弯曲时容易开裂,从而导致柔性 OLED 失效^[6]。有报道指出,在低温沉积 ITO 薄膜过程中通入水或氢气可以获得性能良好的 ITO 透明导电薄膜,此外,ITO/Ag/ITO 等多层膜结构的阳极能进一步改善有机柔性 OLED 的发光性能^[7],但对相关物理机制还不清楚。最近,研究发现,石墨烯具有较高的透光率和电子迁移率及优异的机械韧性,是一种很有潜力的柔性衬底材料,可大面积的制备石墨烯对材料科学来说困难非常大。近年来,人们对柔性 OLED 的发光材料、电极材料及封装技术等方面的研究逐渐增多,如 Hale 等通过在有机发光层中掺杂金属纳米粒子能有效提高有机半导体材料的稳定性^[8],Huang 等开发出一类水/醇溶的共轭聚芴电解质能实现空气稳定的金属阴极的有效电子注入^[9]。但是,对柔性 OLED 在弯曲后光电性能的变化,特别有机半导体材料在弯曲状态下的物理化学性能变化的了解甚少,这严重制约着柔性 OLED 的发展。

总之,与刚性 OLED 相比,柔性 OLED 的研究进展比较缓慢,离产业化还有一定距离,主要问题是柔性衬底材料、有机发光材料及有机/无机层的附着性能、柔性衬底的气密性、封装与驱动技术等,它涉及有机、无机、物理化学、微电子学、凝聚态物理等多门学科。可以预计,随着材料设计、器件物理、封装技术和有源驱动技术等方面的不断进步,有机柔性 OLED 显示将得到进一步的发展,在未来的显示领域将起着不可替代的作用。

参 考 文 献

- [1] Tang C W, VanSlyke S A. Organic electroluminescent diodes. *Applied Physics Letters*, 1987, 51: 913—915.
- [2] Burroughes J H, Bradley D D C, Brown A R, et al. Light-emitting diodes based on conjugated

- polymers .Nature ,1990 ,347 :539—541 .
- [3] Gustafsson G ,Cao Y ,Treacy G M ,et al .Flexible light-emitting diodes made from soluble conducting polymers .Nature ,1992 ,357 :477—479 .
- [4] Gu G ,Burrows P E ,Venkatesh S ,et al .Vacuum deposited nonpolymeric flexible organic light-emitting devices .Opt .Lett . ,1997 ,22 :172—174 .
- [5] Charton C ,Schiller N ,Fahland M ,et al .Development of high barrier films on flexible polymer substrates .Thin Solid Films ,2006 ,502 :99—103 .
- [6] Zhao J Q ,Xie S J ,Han S G ,et al .A bilayer organic light-emitting diode using flexible ITO anode .Phys .Stat .Sol .(A) ,2001 ,184 :233—238 .
- [7] Choi K H ,Kim J Y ,Lee Y S ,et al .ITO/Ag/ITO multilayer films for the application of a very low resistance transparent electrode .Thin Solid Films ,1999 ,341 :152—155 .
- [8] Hale G D ,Jackson J B ,Shmakova O E ,et al .Enhancing the active lifetime of luminescent semiconducting polymers via doping with metal nanoshells .Applied Physics Letters ,2001 ,78 :1502—1504 .
- [9] Huang F ,Hou L T ,Wu H B ,et al .High-efficiency ,environment-friendly electroluminescent polymers with stable high work function metal as a cathode :Green-and yellow-emitting conjugated polyfluorene polyelectrolytes and their neutral precursors .Journal of the American Chemical Society ,2004 ,126 :9645—9653 .

撰稿人：章 勇

华南师范大学光电子材料与技术研究所

Ⅲ族氮化物半导体高效发光问题

The Improvement of the Luminescence Efficiency of Ⅲ-Nitrides

Ⅲ族氮化物半导体主要是指 InN、GaN、AlN 及其三元或四元化合物, 如 InGaN、AlGaIn、AlInGaIn 等。Ⅲ族氮化物半导体作为一种新的光电功能材料, 以其宽直接带隙、高稳定性、高热导率、高硬度等优良性质吸引了众多研究者的注意。通过调节Ⅲ族氮化物半导体材料的组分, 其禁带宽度可从 InN 的 0.7eV 到 AlN 的 6.2eV 连续变化, 发光波长可从 200nm (AlN) 到 1.77 μ m (InN) 连续调节, 覆盖了紫外、可见光、红外波段, 可广泛应用于显示指示、固态照明、太阳能电池、固体激光器、紫外探测器及各种微电子器件等领域。

Ⅲ族氮化物半导体材料的商业应用研究开始于 1970 年, 其能够激发蓝光的独特性质从一开始就吸引了研究人员的极大兴趣。但长期以来, 由于没有合适的单晶衬底材料、位错密度大、N 型本底载流子浓度太高(一般大于 $10^{18}/\text{cm}^3$)和 P 型掺杂无法实现等问题, GaN 基材料发展曾十分缓慢。直到 20 世纪 80 年代末, 采用缓冲层生长技术和 P-GaN 高温退火技术, GaN 材料制备工艺才取得突破性进展, GaN 的质量大大提高, 并能稳定获得较高空穴浓度的 P-GaN。1991 年, 日本 Akasaki 等^[1]和 Nakamura 等^[2]率先研制出了 GaN 蓝色发光二极管(LED)。此后, 在世界范围内掀起了研究 GaN 的热潮, 世界上数百家公司和研究机构都投入巨资加入到 GaN 基材料研究和器件开发热潮中, 各国也争相制定了相应的发展计划。此后, 氮化物材料生长和器件制备不断取得进展。继日亚公司 1994 年高亮度蓝光 LED 产业化之后, 1998 年, APA 光学公司推出了世界上第一个商品化的 GaN 基 UV 探测器系列。1999 年, 日亚公司又首次推出商品化的 InGaIn 基蓝紫色激光器, 其输出功率为 5mW, 室温寿命达 10000 小时^[3]。目前, 国际上蓝、绿、白光和紫色 LED 已实现规模化生产, 蓝紫色激光器已经实现了批量生产, 性能优异的 GaN 基电子器件也已可制备。特别引人关注的是, 如果氮化物半导体白光 LED 的发光效率能大大超过日光灯, 且成本进一步下降, 将可能逐步取代传统的照明光源, 在普通照明领域广泛应用, 市场潜力巨大。

随着研究的不断深入, Ⅲ族氮化物研究也从初期的 GaN 发展壮大成 Ga-In-Al-N 多元应用共同发展的局面, 器件研究也由初期的 LED 和蓝紫光激光器扩展到紫外和红外波段。要制备高性能的发光器件, 关键是要提升Ⅲ族氮化物半导体的发光效率, 这是Ⅲ族氮化物半导体研究面临的主要问题。这一问题主要有由于Ⅲ族氮化物半导体材料本身存在很强的极化电场、晶体质量不高和器件结

构设计不合理等因素,导致电子的空穴辐射复合(能量以光的形式释放)效率不高,严重影响了材料和器件的发光效率。另外,Ⅲ族氮化物器件在较大电流情况下,有较严重的载流子泄漏问题,也影响了器件的发光效率。针对这个问题,近几年已有很多研究者用一些方法来提高发光效率。例如,生长非极性的材料减少极化电场对发光效率的影响^[4],侧向外延生长技术进一步提高材料晶体质量^[5],通过改进器件结构来减弱提高电子和空穴的复合概率^[6,7]等,取得了一些效果。但是,Ⅲ族氮化物半导体材料和器件的发光效率还有很大潜力,有待提升。对于可见光短波波段氮化物半导体器件(紫光、蓝光、绿光),由于可制备出较高质量的材料,今后的研究重点应该集中在优化器件结构、提升器件发光效率方面。对于可见光长波波段(黄光、红光)、红外波段和紫外波段器件,首先需要对 InN 和高 In 组分氮化物(可见光长波波段和红外波段)、AlN 和高 Al 组分氮化物(紫外波段)的材料制备和性能进行深入研究,进一步提升材料的晶体质量,获得高效率发光的材料。另外,还要不断优化器件结构,提升器件发光效率和整体性能。

参 考 文 献

- [1] Akasaki I, Amano H, Kito M, et al. Photoluminescence of Mg-doped p-type GaN and electroluminescence of GaN p-n junction LED. *Journal of Luminescence*, 1991, 48/49: 666.
- [2] Nakamura S, Senoh M, Mukai T. Highly p-typed Mg-doped GaN films grown with GaN buffer layers. *Jpn. J. Appl. Phys.*, 1991, 30: 1708.
- [3] <http://www.la.mesh.ne.jp/nichia/index-e.html>.
- [4] Chen C Q, Gaevski M E, Sun W H, et al. GaN homoepitaxy on freestanding (1-100) oriented GaN substrates. *Applied Physics Letters*, 2002, 81: 3194.
- [5] Yu H, Lee L K, Jung T, et al. Photoluminescence study of semipolar {1011} InGaN/GaN multiple quantum wells grown by selective area epitaxy. *Applied Physics Letters*, 2007, 90: 141906.
- [6] Otsuji N, Fujiwara K, Sheu J K. Electroluminescence efficiency of blue InGaN/GaN quantum-well diodes with and without an n-InGaN electron reservoir layer. *J. Appl. Phys.*, 2006, 100: 113105.
- [7] Okamoto K, Ohta H, Chichibu S F, et al. Continuous-wave operation of m-plane InGaN multiple quantum well laser diodes. *Jpn. J. Appl. Phys.*, 2007, 46: L187.

撰稿人: 李述体

华南师范大学光电子材料与技术研究所

ZnO 器件的高效电泵激子发光

Electroluminescence Exciton Emission of ZnO Devices

短波长半导体发光和激光器件对于提高光通信的带宽、光信息的记录密度和提取速度有重要意义,一直是国内外人们关注的研究热点,是信息显示、绿色照明等领域革命性发展的基础,因此,几年前兴起的 GaN 蓝光材料很快引起了人们的关注。但是,这种材料也具有其自身的局限性,就是室温下激子束缚能低(21meV)、实现激射阈值较高等弱点。人们发现,具有与 GaN 类似的晶体结构与物理性质的 ZnO 具有很高的激子束缚能(60meV)^[1],发射波长更短,因而,理论上会在室温下获得高效的紫外激子发光和激光。而且,ZnO 的生长温度比 GaN 的生长温度几乎低一半,这就在很大程度上避免了因高温生长而导致的薄膜与衬底间的原子互扩散,而这种互扩散常在薄膜与衬底的界面形成一个薄的高掺杂 N 型简并层,能够极大地影响整个膜层的电学输运性质;而紫外波段激光在海底探测、紫外通信和光存储等方面其性能将有数量级的提高。此外,ZnO 又是高熔点(1975℃)的氧化物,具有很高的热稳定性和化学稳定性。另外,ZnO 原材料资源丰富,价格便宜,对环境无毒无害,制备方法简单,具有潜在的巨大商用价值。

但是,就目前的工作来看,关于 ZnO 的研究主要都聚集于 ZnO 的同质发光二极管(LED)和 ZnO 的 P 型掺杂方面。2005 年,针对 P 型 ZnO 材料,东北大学材料研究所的 Kawasaki 小组^[2]得到了蓝色的电致发光,他们将位于 440nm 的发光谱归于施主到受主的受激复合,这一结果激起人们对 ZnO 基结型器件实用化的信心。中国科学院长春光学精密机械与物理研究所在国际上首次在蓝宝石衬底上获得 ZnO 同质 P-N 的电致发光^[3]。韩国的 Lim 等^[4]在 2006 年的 *Advanced Materials* 又报道了采用磁控溅射的方法制备 ZnO 同质 P-N 结,他们的电致发光结果显示除了位于 380nm 附近的紫外发光外,在可见部分仍然有很强的发光。Ryu 等^[5]报道了来自于 ZnO/BeZnO 量子阱结构器件的光泵和电泵激射。

虽然目前已经有大量的关于 P 型 ZnO 掺杂的理论和实验报道,也实现了 ZnO 同质 LED 的电致激子发光,但其发光还比较弱,距离真正实用化还有很大距离。存在的主要问题是:首先,主要是因为制作高性能的器件始终依赖于高质量的材料,虽然已经实现 ZnO 薄膜的 P 型掺杂,但其载流子浓度和迁移率等参数距离实用化的需要还有一定差距。同时,P 型掺杂窗口很小,因此,如何扩

大 P 型 ZnO 的生长窗口, 如何获得低电阻、稳定、可重复的 P 型 ZnO 仍然需要进一步研究探索。P 型 ZnO 获得比较困难, 主要是由于 ZnO 材料中存在大量施主型本征缺陷, 包括氧空位 (V_o)、间隙氧 (O_i)、反位氧 (O_{Zn})、间隙锌 (Zn_i)、反位锌 (Zn_o)、锌空位 (V_{Zn}) 等^[6~8], 在 ZnO 的本征点缺陷中, O_i 和 V_{Zn} 是浅受主, 而 V_o 、 Zn_i 、 Zn_o 是施主型缺陷, ZnO 中各种本征缺陷, V_o 和 Zn_i 无论在富 Zn 和富氧条件下的形成能都很低, 较之 V_{Zn} 和 O_i 更容易在 ZnO 中存在。另外, 非故意掺杂的 H 在 ZnO 中很容易形成浅施主 (30 meV), 这些施主的存在能够补偿 P 型浅受主, 也就是所谓的自补偿效应。所以, 要想获得低阻的 P 型 ZnO, 就必须克服自身的自补偿效应, 掺入受主型杂质以实现 N 型向 P 型的转变。目前, 针对 ZnO 的 P 型掺杂已经展开了大量研究, 对于掺杂剂在 ZnO 中的稳定性也一直是困扰 P 型 ZnO 的主要问题。其次, ZnO 载流子的输运特性直接影响到其复合速率和光激发的速率, 对 ZnO 及其掺杂材料的载流子输运特性的研究将关系到实用型器件的实现。目前, 所报道的 P 型 ZnO 薄膜都存在共同的难题, 就是室温下空穴的迁移率都集中在 $1\text{cm}^2/\text{Vs}$ 左右, 这极大地阻碍了 ZnO 发光器件的进展, 在 P 型 ZnO 中, 离化杂质散射、压电散射、声学形势势散射、极化光学声子散射等都会影响空穴迁移率, 但目前关于 P 型 ZnO 迁移率低的原因还没有给出明确的解释。另外, ZnO 基器件结构和工艺上仍存在问题。

ZnO 高效的电泵激子发光的实现将带动发光器件界的革命。通过进一步改进材料生长和制作工艺, 就一定能制作出高效的 ZnO 电泵激子发光和激光器件。

参 考 文 献

- [1] Tang Z K, Wong G K L, Yu P M, et al. Room-temperature ultraviolet laser emission from self-assembled ZnO microcrystallite thin films. *Applied Physics Letters*, 1998, 72: 3270—3272.
- [2] Tsukazaki A, Ohtomo A, Onuma T, et al. Repeated temperature modulation epitaxy for p-type doping and light-emitting diode based on ZnO. *Nature Materials*, 2005, 4: 42—46.
- [3] Jiao S J, Zhang Z Z, Lu Y M, et al. ZnO p-n junction light-emitting diodes fabricated on sapphire substrates. *Applied Physics Letters*, 2006, 88: 031911—031913.
- [4] Lim J H, Kang C K, Kim K K, et al. UV electroluminescence emission from ZnO light-emitting diodes grown by high-temperature radiofrequency sputtering. *Advanced Materials*, 2006, 18: 2720—2724.
- [5] Ryu Y R, Lee T S, Lubguban J A, et al. Next generation of oxide photonic devices: ZnO-based ultraviolet light emitting diodes. *Applied Physics Letters*, 2006, 88: 241108—241110.
- [6] Kohan F, Ceder G, Morgan D, et al. First-principles study of native point defects in ZnO. *Phys. Rev. B*, 2000, 61: 15019.

-
- [7] Zhang S B, Wei S H, Zunger A. Intrinsic n-type versus p-type doping asymmetry and the defect physics of ZnO. *Phys. Rev. B*, 2001, 63: 075205—075211.
- [8] Kohan A F, Leder G, Morgan D. First-principles study of native point defects in ZnO. *Phys. Rev. B*, 2000, 61: 15019—15027.

撰稿人：宿世臣 梅 霆

华南师范大学光电子材料与技术研究所

单片光子集成的难题

Challenge in Monolithic Photonic Integration

激光器早在 1960 年问世, 到 1969 年, 电子集成芯片已能实现 10^3 个晶体管, 由此为了提高性能和降低成本, 在芯片上集成具有各种功能的光子器件是很自然的。在这一年, 贝尔实验室的 Miller 首次正式提出了这样的构想, 并随后形成了光子集成电路 (photonic integrated circuits, PIC) 的概念^[1,2]。在半个多世纪的进程里, 电子集成芯片遵循摩尔定律, 已实现 10^9 个晶体管, 而 PIC 的发展却相当滞后, 到 2005 年实现首次商业化应用, 才达到 10^2 个器件, 这显示了光子集成芯片的发展面临巨大的挑战。主要困难在于以下两点:

其一, 集成多种光子器件, 包括主动器件和被动器件, 是将光发射、放大、调制、开关、传输等各种功能集成在一块芯片上。然而, 不同器件对材料性质有不同要求, 如何在同一片芯片上满足这些要求?

其二, 光子器件尺寸取决于光波长, 远大于电子集成芯片中的电子尺度, 如何突破光波长限制, 减小器件的尺寸?




图 1 多种光子器件单片集成及激光器、电吸收调制器和波导的吸收带示意图

单片集成主动和被动器件, 需要使用有源材料, 并满足器件不同的带隙能要求, 如图 1 所示。从材料特性来讲, 首选当是 III-V 化合物半导体材料, 如 InP 衬底上使用外延生长制作 InGaAsP 系量子阱(或量子点)材料。器件集成的方法有端面对接再生长法 (butt-joint re-growth method)、选区生长法 (selective area growth, SAG)、量子阱互混 (quantum well intermixing, QWI) 等^[3]。

PIC 目前是在硅和 III-V 平台上并行发展的, 但未来微处理器对高容量、低功耗的芯片内和芯片外光互连的需求可能会打破这个平衡。CMOS 集成电子学的成功大大地激励了大学和工业界的硅光子学的研究, 目标在于将电子和光子功能集成在一个芯片上并且可在任何一家 CMOS 晶圆厂制造^[4,5]。

硅基 PIC 的主要难题在于制造主动器件。硅缺乏 LiNbO₃ 和 InP 所具有的优越的线性电光效应, 使其很难实现同样水平的调制器。然而, 通过 PN 结载流子改变折射率这一现象, 用谐振环结构和 M-Z 干涉计配置还是能实现调制器, 后

者已达到 30Gbps 的调制^[6]。除了缺乏线性电光效应,硅是间接带隙半导体,这意味着它不能够提供激光增益,而 $1.1\mu\text{m}$ 的带边使它不适合做 $1.3\mu\text{m}$ 和 $1.5\mu\text{m}$ 通信波段的光电二极管。不过,硅外延生长硅锗合金已是一些 CMOS 晶圆厂的标准工艺,集成 SiGe 探测器已被人们展示^[4]。

因此,单片硅光子学剩下最后一个障碍——光发射器。虽然有争议认为可用片外的激光源通过光栅耦合器和硅基 PIC 耦合,然而,这毕竟和减少器件耦合及封装成本这一 PIC 的宗旨相悖。可能的解决方案包括 III-V 化合物半导体和硅的杂化集成与异质集成。杂化集成可以实现激光器和硅基光电子的各自最优化,但不利于大规模集成。异质集成是将 III-V 化合物半导体异质外延生长在硅基上或是通过晶圆键合的办法将 III-V 化合物半导体薄膜结合在硅基上。异质集成可以利用硅芯片的大尺寸来降低成本,同时利用化合物半导体的高发光效率实现激光源,甚至利用化合物半导体的高电子迁移率来实现高速电子器件。例如, GaAs 的电子迁移率约是硅的 8 倍,而 InSb 约是硅的 50 倍。英特尔在异质集成方面做了大量工作,已展示了连续波运转和 40GHz 调制的硅基上的 InP 激光器。但是,两种材料的不同晶格尺寸和热学特性所带来的界面缺陷、器件可靠性、与 CMOS 的工艺匹配性等问题,还需要大量的研究工作。

光子集成技术发展中的另一个重要问题是如何减小尺寸。应用集成技术只有支持不断降低器件尺寸和制造成本,才能支撑摩尔定律^[7]所描述的芯片功能的生长(如图 2 所示)。如果光子学要在信息和通信技术市场发挥重大作用,必须遵循这样的动力机制,否则,将输于它的微电子竞争对手。初期减少器件尺寸的方案主要是采用具有高横向折射率对比的深蚀刻波导,这允许应用小波导宽度和小弯曲半径,而要进一步减小器件尺寸则要采用光子纳米线和光子晶体。这些技术使我们能够接近的光子约束的基本极限:对单缺陷微腔来说大约是半个波长(200nm)。要实现完整的三维约束,需要第三维的结构制作,这是非常困难的。一种替代性方案,即所谓二维半方案,是使用具有纵向高折射率对比度的膜层,以接近基本极限,而不苛求于蚀刻技术。

随着晶体管的尺寸越来越小,电子互连遇到了电磁干扰、焦耳发热及 RC 延迟问题,光互连提供大带宽和并行特性,更有潜力传送更多的信息,是人们预期的解决方案。尺寸在波长级别的光子器件无法和尺寸在纳米级别的晶体管相匹配,这阻滞光子集成及光电集成的进一步发展。如何进一步缩小光子器件,突破光波长尺度限制便成为核心问题。

由于表面等离子极元(surface plasmonic polariton, SPP)被强烈地约束在金属和介质界面并且沿着界面传播,平面金属介质结构起着波导结构的作用,提供了一个将光子器件缩微到纳米尺度的方案^[9]。非对称波导结构和金属-介质-金属隙状(slot waveguide)波导结构让更多的电磁场能量在介质中传播,缓解了

SPP 结构的金属损耗问题, 可以展示几十微米的传播距离, 650nm 的红光可以被约束在只有 3nm 厚、55nm 宽的结构里。SPP 的发展给光子集成带来了能真正和电子集成尺度相匹配的机遇。图 3 描述了电子和光子在尺度和速度上的应用范围。




图 2 集成光学的摩尔定律^[8]




图 3 光子和电子技术的优势及它们的速度及尺寸^[10]

正如集成常规光子器件一样, 实现主动器件对集成 SPP 结构器件来说依然是一个关键问题, 尤其由于金属损耗问题, 实现对 SPP 的有源增益更加重要。最近有报道展示, 用在银膜上的硫化铬(CdS)纳线作为增益材料的杂化 SPP 波导结构光泵浦表面等离子激光 (SPASER)^[11], 但目前尚未真正实现电泵浦增益, 而且多种器件集成问题也未进入研究阶段, 所以, 真正能实现 SPP 器件集成为期尚为遥远。

综上所述, 多种器件集成和器件小型化是单片光子集成的主要难题。InP 体系的材料能提供增益, 优势在于集成多种器件, 但没有高折射率对比的材

料搭配,不利于设计小型器件。硅体系提供高折射率对比的材料搭配(如 Si/SiO₂),给设计小型器件带来许多便利,同时,完善的 CMOS 微电子工艺也给 PIC 提供了现成的加工平台,但由于缺乏有源材料,在实现主动器件,尤其是光发射器上,存在天然的不足。采用 SPP 结构有效地实现了光子器件的纳米尺度的缩微,但实现主动器件及其集成依然是个难题,这有待今后在纳米光子学、材料科学及纳米加工技术上的发展。解决方案需要电磁场和材料科学上的基础研究和大量的工程创新,希望不久的将来我们在计算机中真正地见到光子集成线路。

参 考 文 献

- [1] Miller S E. Integrated optics: An introduction. Bell Systems Technical Journal, 1969, 48:2059.
- [2] Kaminow I P. Optical integrated circuits: A personal perspective. Journal of Lightwave Technology, 2008, 26:994—1004.
- [3] vander Tol J J G M, Oei Y S, et al. InP-based photonic circuits: Comparison of monolithic integration techniques. Progress in Quantum Electronics, 2010, 34:135—172.
- [4] Soref R. The past, present, and future of silicon photonics. IEEE Journal of Selected Topic in Quantum Electronics, 2006, 12:1678—1687.
- [5] Liang D, Bowers J E. Photonic integration: Si or InP substrates? Electronics Letters, 2009, 45:578—581.
- [6] Liu A S, Liao L, Rubin D, et al. High-speed optical modulation based on carrier depletion in a silicon waveguide. Optics Express, 2007, 15:660—668.
- [7] Thylen L. A Moore's law for photonics. Proceedings of International Symposium on Biophotonics, Nanophotonics and Metamaterials, Metamaterials, 2006, 4134792:256—263.
- [8] Smit M, Oei S, Karouta F, et al. Photonic integrated circuits: Where are the limits? OSA 2005 Integrated Photonics Research and Applications (IPRA'05) Technical Digest, 2005.
- [9] Maier S A. Plasmonics: Fundamentals and Applications. New York: Springer, 2007.
- [10] Brongersma M L, Kik P G, et al. Surface Plasmon Nanophotonics. Dordrecht: Springer, 2007.
- [11] Oulton R F, Sorger V J, Zentgraf T, et al. Plasmon lasers at deep subwavelength scale. Nature, 2009, 461:629—632.

撰稿人: 梅 霆¹ 滕京华²

1 华南师范大学光电子材料与技术研究所

2 新加坡材料研究与工程研究院

石 墨 烯

Graphene

石墨烯(graphene)是由碳原子构成的二维晶体,它的命名来自英文的graphite(石墨)+-ene(烯类结尾),也有人使用“单层石墨”作为其称呼。在石墨烯中,碳原子以 sp^2 杂化并排列成蜂窝状六角平面结构。石墨烯是其他碳材料同素异形体的基本构成单元。例如,将石墨烯堆积可以形成三维的石墨(graphite),石墨烯也可以卷成一维的碳纳米管,它甚至可以包裹成零维的富勒烯(fullerene)。2004年,曼彻斯特大学Geim教授领导的研究小组最先发现了石墨烯^[1]。在发现石墨烯之前,物理学家普遍认为热力学涨落不允许任何二维晶体在非绝对零度下稳定存在。因此,石墨烯的发现及其室温下稳定的存在立即震撼了凝聚态物理界。目前认为,单层石墨烯能在实验中被制备出来,有可能归结于其在纳米级别上的微观扭曲^[2]。由于石墨烯平面内的碳原子结合力很强,很难被破坏,所以,它具有很好的结构稳定性、热稳定性及化学稳定性。实验表明,石墨烯是现在世界上已知的最为牢固、韧性最好的材料^[2]。更为特殊的是,电子在石墨烯里遵守相对论量子力学,有效质量接近于零,可以被近似认为是以光子的形式存在(速度是光速的 $1/300$)。伴随着石墨烯的发现,一系列奇特的物理现象也相继被发现,如异常的整数量子霍尔效应(且在常温下能观测到),在其他材料中从未观察到的分数量子霍尔效应,由物理学精细结构常数所决定的石墨烯的吸收率及光导等^[3]。

基于石墨烯的弹道输运晶体管吸引了科学及工业界的广泛兴趣。实验结果显示,石墨烯具有超高的载流子迁移率,目前报道的常温下的迁移率已经超过了 $20000\text{cm}^2 \cdot \text{V}^{-1} \cdot \text{s}^{-1}$,比硅器件的迁移率高了整整一个数量级。更引人注目的是,石墨烯的载流子迁移率还有极大的提升空间,如在悬空的石墨烯中,迁移率还能再提高将近一个数量级。基于石墨烯的纳米电子器件被认为在未来极有可能替代硅材料电子器件。IBM的研究小组已经成功研制成了频率约为 100GHz 的石墨烯场效应晶体管^[4]。在未来石墨烯的电性研究上,首要的目标就是进一步提高石墨烯的迁移率,突破现有极限,使它能拥有更突出的性能。要实现这一目的,首先就需要了解限制迁移率的因素,如本身缺陷的影响、衬底的影响(应力、声子散射、带电介质散射)、表面吸附的杂质的影响等,这些都需要一系列的理论猜想和实验结果去印证,而如何克服或排除这些因素,也将是以后石墨烯研究的重点和难点。

虽然石墨烯具有超高的载流子迁移率,但在纳米半导体器件的研究与应用中,一个重大的缺陷必须被克服:石墨烯没有电子带隙,这一缺陷使得石墨烯在逻辑电路器件中不能拥有很好的开关特性。近年来,科学家们不断地从理论及实验中尝试解决这个难题,如将石墨烯切割成纳米尺度的石墨烯带,利用一维量子限域效应来调控能带结构;又比如在石墨烯表面吸附分子(如原子氢),来破坏石墨烯的 sp^2 结构^[5];还有在双层或多层石墨烯表面加垂直电场,改变上下层碳原子的势能^[6];又或者通过衬底的影响,使石墨烯中相邻碳原子的能量不对称。以上方法使石墨烯拥有了或大或小的带隙及较高的开关特性。但是,经过能带结构改性后,石墨烯本身的特性,如超高的载流子迁移率也大部分丧失了,这可能归结于改性后的石墨烯有效电子质量增加^[7]。所以,未来在石墨烯的能带改性及其本身特性的保留上还需要进行更多的研究工作。

石墨烯的另一个重要研究方向是在光电领域。实验结果显示,石墨烯的光学吸收是由物理学精细结构常数(α)决定的,虽然石墨烯只有单个原子层的厚度,但它却能吸收约 2.3% 的光(可见光范围内)^[3]。同时,石墨烯独特的线性能带结构决定了其在远红外($6\mu\text{m}$)到紫外(300nm)光区域都有相同或相近的吸收系数,再加上它极高的载流子迁移率,这就使得石墨烯非常适合应用于高灵敏度的光电器件中,如光电探测器。研究人员近期已经实现了基于石墨烯的光电探测器,实验得到的光学响应频率达到了 40GHz ,并推测理论上能达到 500GHz 的极高响应频率^[8]。同时,石墨烯光电探测器在通信波段($1.55\mu\text{m}$)的光学响应度已经达到了 6.1mA/W ^[9]。这一系列结果都说明了石墨烯在光电领域有非常好的应用前景,特别是在远红外和紫外区间的光电探测及光通信设备上。当然,进一步提高石墨烯光电探测器的光学响应度及降低探测器的暗电流是以后研究中的挑战。在光子的激发下,材料中会产生与光子能量相同的电子-空穴对,而后电子与空穴分离并相应地产生电流。但是,石墨烯中的电子与空穴分离的时间极短,马上就会复合,导致产生的有效电流很小。目前的方法是利用特制的内加电场来分离电子-空穴对^[10]。寻找更有效的方法来分离电子-空穴对,或延长电子与空穴单独存在的时间是未来研究的重点。如何降低石墨烯光电探测器中的暗电流,则可以考虑通过用垂直电场打开多层石墨烯能带等手段来实现。

如何制备大面积的石墨烯是实现其大规模研究及今后广泛应用的基础,而满足大面积的同时保证高质量更是一个巨大的挑战。研究者们先后发展了数种制备石墨烯的方法,如撕胶带剥离法、加热碳化硅法、氧化石墨分离并还原法及直接在化学试剂中分散法,以上提到的方法各有其利弊。最近,研究者们又发现了在镍或铜等过渡金属表面化学气像沉积法并转移的方法可以制备大面积的石墨烯^[10],此方法被认为是目前最有效的生长大规模、高质量且可转移的石墨烯连续薄膜的方法。高透光率及高导电性,使得石墨烯薄膜必将广泛用于太

太阳能电池、液晶平板、超电容器等器件中。在石墨烯的制备方法上,科学家们仍在不断摸索,以获得更高质量、更连续且均匀的石墨烯薄膜。

石墨烯从发现至今才短短数年,但在科学研究及工业应用方面的发展却可以用一日千里来形容。毋庸置疑,今后石墨烯方向的基础和应用研究必将更迅速、更具有挑战性,也将为凝聚态物理学的发展和工业发展做出更为重大的贡献。上述提出的几个关键难题的解决,如进一步提高电子迁移率、石墨烯能带的改性、进一步提高光电响应度、制备大规模高质量石墨烯薄膜等,将会把石墨烯的研究与应用推到一个更深、更广的高度!

参 考 文 献

- [1] Novoselov K S, Geim A K, et al. Electric field effect in atomically thin carbon films. *Science*, 2004, 306: 666—669.
- [2] Geim A K, Novoselov K S. The rise of graphene. *Nature Materials*, 2007, 6: 183—191.
- [3] Nair R R, et al. Fine structure constant defines visual transparency of graphene. *Science*, 2008, 320: 1308.
- [4] Lin Y M, et al. 100GHz transistors from wafer scale epitaxial graphene. *Science*, 2010, 327: 5966.
- [5] Elias D C, et al. Control of graphene's properties by reversible hydrogenation: Evidence for graphane. *Science*, 2009, 323: 610.
- [6] Castro E V, et al. Biased bilayer graphene: Semiconductor with a gap tunable by the electric field effect. *Phys. Rev. Lett.*, 2007, 99: 216802.
- [7] Liu L, et al. Band gap engineering of graphene: A density functional theory study. *Applied Physics Letters*, 2009, 95: 252104.
- [8] Xia F N, et al. Ultrafast graphene photodetector. *Nature Nano*, 2009, 4: 839.
- [9] Mueller T, et al. Graphene photodetectors for high-speed optical communications. *Nature Photonics*, 2010, 4: 297.
- [10] Li X S, et al. Large-area synthesis of high-quality and uniform graphene films on copper foils. *Science*, 2009, 324: 1312.

撰稿人: 申泽骧 倪振华 詹 达
新加坡南洋理工大学数学物理学院

全光缓存

All Optical Random Access Memory

1. 背景介绍

通信与信息系统工程中涉及的大多是技术问题,但也有一些非常难的科学问题,如复杂系统中的光网络、光缓存(optical random access memory, ORAM)等。光缓存是全光信息系统的一项关键技术,在光网络中的分组交换、光计算机中都要使用。在没有光缓存时,不能实现光的比特交换,光分组交换和光计算机(指全部在光域处理,不经过光-电-光转换)都无法真正实现。光随机存储的研究涉及基础科学问题。由于光子的静止质量为0,能否将光信号(光子)静止束缚在一个固定的、小的光随机存储器中?如果能实现光随机存储,将会给光通信的发展带来重大突破,不亚于高锟教授对光纤通信的贡献,此外,对光计算机等其他全光信息系统也有很大的帮助。

2. 问题描述

能否实现理想的全光随机存储器?能否将光子任意束缚甚至使其彻底静止?由于光子静止质量为0,最大可能性就是光以光子环流形式束缚在一个很小空间内。此外,为了能应用于实际的光信息系统中,能不能在普通条件下(常温、常压等)、一个较小空间内实现宽带光的任意随机存储,并且光信息得到很好的保存(不发生畸变)?

3. 必要说明

如何将光信号进行暂时存储,可以从光信号的传输时间公式 $t=L/v$ 中看出,其中, L 和 v 分别表示传输介质的长度和介质中光信号的传播速度。可见,为使光信号的到达时间延迟(或提前)有两种方法^[1]: 其一是改变传输介质的长度,如光的可变延迟线;其二是调节光信号的速度,将光信号传输速度降下来,也即“慢光”。“慢光”效应的研究近年来吸引了国内外学者的注意。1990年, Harris 等提出了利用电磁诱导透明(electromagnetically induced transparency, EIT)技术实现慢光^[2]。1999年, Hau 等在超冷钠原子气中基于 EIT 将光速成功减慢到 17m/s ^[3],但其实验条件苛刻,离应用甚远。2003年, Bigelow 等在室温下的紫翠玉晶体中基于相干粒子振荡技术将光速减慢到 91m/s ^[4],同年,在红宝石晶体中将光速减慢到 57.5m/s 。人们还提出了利用共振光学滤波法^[5]、半导体

光放大器^[6]等实现慢光。

此外,利用光纤非线性效应实现光脉冲延迟的技术也受到人们的关注,因为其可以与光纤通信很好的兼容。从 2005 年 Song 等提出利用光纤的受激布里渊散射效应实现慢光^[7]开始,人们提出了利用光纤中的受激拉曼散射效应、光纤参量放大、结合波长转换和色散等慢光技术。

2010 年 1 月 24 日, *Nature Photonics* 杂志上发表了在硅芯片上实现超低功耗超小型超快电泵浦全光存储器技术的研究成果^[8]。利用直径只有 $7.5\mu\text{m}$ 的 InP 层微磁碟激光器,让产生的光线在硅波导中顺时针或者逆时针传输,同时利用超短脉冲在这两种模式间转换,这种存储技术实现的全光存储器(AOFF)所需的偏置电流为 3.5mA ,触发脉冲能量仅为 1.8fJ ,触发时间为 60ps 。

但是,上述研究还只能将光的速度慢下来,或在一个有限区域内循环。由于光子的静止质量为 0,因此,不能将光信号(光子)静止束缚在一个随机存储器中。可以想象的是,它可能会以类似磁偶极子的形式存在,但如何并以什么样的形式实现随机存储,这些难题还需要人们进一步深入探讨。

参 考 文 献

- [1] 尹经禅.基于光纤非线性效应的慢光研究[博士学位论文].北京:清华大学,2009.
- [2] Harris S E,Field J E,Imamoglu A.Nonlinear optical processes using electromagnetically induced transparency .Phys .Rev .Lett .,1990,64(10):1107 .
- [3] Hau L V,Harris S E,Dutton Z,et al.Light speed reduction to 17 metres per second in an ultracold atomic gas .Nature,1999,397(6720):594—598 .
- [4] Bigelow M S,Lepeshkin N N,Boyd R W .Superluminal and slow light propagation in a room-temperature solid .Science,2003,301(5630):200—202 .
- [5] Vlasov Y A,O'Boyle M ,Hamann H F,et al.Active control of slow light on a chip with photonic crystal waveguides .Nature,2005,438(7064):65—69 .
- [6] Pesala B,Chen Z Y,Uskov A V ,et al.Experimental demonstration of slow and superluminal light in semiconductor optical amplifiers .Optics Express ,2006,14(26):12968—12975 .
- [7] Song K Y,Herraez M G,Thevenaz L.Observation of pulse delaying and advancement in optical fibers using stimulated Brillouin scattering .Optics Express ,2005,13(1):82—88 .
- [8] Liu L,Kumar R,Huybrechts K,et al.An ultra-small,low-power,all-optical flip-flop memory on a silicon chip .Nature Photonics ,2010,4:182—187 .

撰稿人:徐安士¹ 肖晓晟² 杨昌喜²

1 北京大学信息科学技术学院

2 清华大学精密仪器与机械学系

无噪声的全光放大

Noise-free All-optical Amplification

1. 背景介绍

在光信息系统中,介质的传输损耗及耦合、分束等操作将降低光信号的功率,从而使得光信号淹没在噪声中无法检测。将光信号进行直接放大的全光放大技术能够克服电放大器的“电子瓶颈”限制,从而大大提高整个信息系统的容量和速度。而在全光放大过程中,将会不可避免地有自发辐射等噪声混入信号中,因此,所有的光放大器在对光信号进行放大的同时都会使引入噪声,从而使得放大信号的信噪比(信号与噪声的功率之比)下降。为了衡量光放大器引入噪声的多少,一般用噪声指数来描述,其计算为输入光的信噪比除以放大输出光的信噪比。

对于一般的光放大器而言,其噪声指数等于 2 倍的自发辐射因子(或称之为粒子数反转因子)。由于放大器的自发辐射因子大于 1,因此,一般的光放大器噪声指数超过 2,也即使得放大信号的信噪比降低 3dB 以上^[1],这个数值(3dB)常称为光放大器的量子极限噪声。

放大器噪声对信息系统是根本的限制因素之一。对较复杂的光信息系统(如长距离的光通信系统),光放大器的噪声指数应尽可能地小。此外,如果将功率较低的光信号放大较大倍数,此时,放大器噪声的影响会相当严重。因此,能否得到噪声指数尽可能小(甚至趋于 0dB)的全光放大器对光信息系统有着重要的研究价值。

2. 问题描述

能否得到无噪声的全光放大?所谓无噪声,是指该放大器的噪声指数为 0dB,放大过程不引入任何新的噪声,从而使得被放大的光信号的信噪比保持不变。如何尽量消除放大过程中的各种噪声源(如自发辐射噪声、自发拉曼散射噪声)?更进一步,如何得到实际可用的无噪声全光放大(如具有一定带宽等)?

3. 必要说明

全光放大技术在光通信的发展史上扮演了举足轻重的角色。早期,光通信系统受制于电中继放大器的成本和“电子瓶颈”,发展较慢。直到 1987 年,英

国南安普顿大学和美国 AT&T 贝尔实验室对一种全光宽带的放大器——掺铒光纤放大器(EDFA)的研究取得突破性进展,使全光通信距离延长至几千公里,并大大降低了系统成本,被誉为光通信发展的一个“里程碑”。如今,全光放大技术还包括半导体光放大器、光纤布里渊放大器、光纤拉曼放大器、光纤参量放大器等。尽管现在的 EDFA 的噪声指数做到很小,但其多能级泵浦的增益原理决定了其自发辐射因子大于 1,从而无法超越量子极限噪声^[1]。

20 世纪 90 年代,人们发现基于非线性四波混频的相位敏感放大技术能得到低于 3dB 噪声指数的光放大器^[2,3]。所谓相位敏感放大器,顾名思义,就是该器件对具有不同入射相位的信号有着不同的放大效果。比如说,相位敏感放大器能够放大初始相位为 θ 的信号,同时,衰减初始相位为 $\theta + \pi/2$ 的信号。然而,该技术都基于晶体或非线性光纤中的简并(或部分简并)参量过程(如四波混频等,一个具体的示例如图 1 所示),而简并参量过程的原理限制了该放大技术的应用,如增益带宽很窄,难以在宽带的光信息系统中得到应用;即使最近有人提出了宽带的相位敏感放大技术^[4],也由于原理限制等原因,难以在实际系统中应用。而且,在基于光纤的相位敏感放大过程中将会引入自发拉曼辐射噪声,如何降低该噪声源亦是一个难题。此外,如何克服泵浦的功率和相位的抖动、保持光纤的色散和偏振等引入的噪声?因此,能否解决这些难题,得到能够实际应用于光信息系统的、噪声指数低于 3dB 甚至是趋于 0dB 的全光放大器还需要人们的深入研究。




图 1 基于简并四波混频的相位敏感放大的一个示例

泵浦与信号之间的角频率需满足关系: $\omega_1 + \omega_2 = 2\omega_3$

4. 相关扩展

无噪声全光放大技术如果能够实现,将不仅仅应用于复杂的光信息系统用于减小噪声,该技术还可应用于量子激光雷达、相干通信、光相位噪声、太赫兹兹波的产生等^[5]。

基于非线性四波混频等参量过程的全光放大技术能够得到较低噪声指数的道理与利用四波混频实现“压缩态”从而减小量子噪声类似。压缩态是指电磁场特殊态的产生,四波混频能将一对电磁场共轭量之一的量子噪声降到量子噪声水平以下,即突破量子极限。“压缩态”现象在光信息传输、精密测量、量子

态制备及控制等方面具有重要的应用^[6]。

参 考 文 献

- [1] Agrawal G P.非线性光纤光学原理及应用.贾东方,余震虹,等译.北京:电子工业出版社,2002.
- [2] Ou Z, Pereira S, Kimble H. Quantum noise reduction in optical amplification. *Phys. Rev. Lett.*, 1993, 70: 3239—3242.
- [3] Imajuku W, Takada A, Yamabayashi Y. Low-noise amplification under the 3dB noise figure in high-gain phase-sensitive fibre amplifier. *Electronics Letters*, 1999, 35: 1954—1955.
- [4] Tang R, et al. In-line phase-sensitive amplification of multichannel CW signals based on frequency nondegenerate four-wave-mixing in fiber. *Optics Express*, 2008, 16: 9046—9053.
- [5] Kumar P, Grigoryan V, Vasilyev M. Noise-free amplification: Towards quantum laser Radar. 14th Coherent Laser Radar Conference, 2007.
- [6] 叶晨光. 压缩态光场的实验研究以及相位敏感光学参量放大器中类 EIT 现象的实现[博士学位论文]. 太原: 山西大学, 2009.

撰稿人: 肖晓晟

清华大学精密仪器与机械学系

激光混沌通信

Laser Chaotic Communication

1. 背景介绍

混沌是自然界中最普遍的一种现象之一,已经在气象学、生物医学、经济学、电子信息处理及通信等与人类生活紧密相关的多个领域得到广泛应用。自1990年Pecora和Carroll提出两个混沌系统的同步以来,以类噪声混沌信号作为载波的混沌通信因其能从物理层增强通信的保密性,逐渐成为现代保密通信研究的一大热点,其中,以激光混沌通信备受世人瞩目。激光混沌通信可以很容易地得到高复杂度、宽带、高保密性的混沌光载波^[1]。关于激光混沌通信的研究,已从最初的固体激光器^[2]逐渐转向半导体激光器^[3,4],其基本原理为:信息在发端通过混沌掩蔽、混沌键控或混沌调制等方式被调制到混沌载波中,在接收端则采用相应的解调方法从同步混沌信号中解出信息^[5]。2005年,以雅典大学为首的9个国际研究组在雅典的商用光纤网上做实验,在将数字信号传输了120km以后成功解出混沌信号,而且误码率完全满足现代通信要求^[6],该实验证实了激光混沌通信的现实可操作性。

2. 问题描述

激光混沌通信的研究存在几个重要的难题,归结到底,关键问题就是如何在提高安全性(保密性)的同时提高可行性——高效可靠、安全可行的激光混沌通信系统。

除了与其他混沌系统的共性技术,如随机数发生器以外,激光混沌通信的一个关键技术是混沌同步技术。目前,激光混沌同步主要基于注入-锁定和系统对称性原理。注入-锁定混沌同步主要应用于单向通信,其参数失配鲁棒性好、易于操作,但安全性不够高,用一个类似的激光器(与收发端激光器存在参数失配)也有可能破译出信息^[7]。基于对称操作原理的混沌同步主要应用于双向通信,其信息安全性得到了很大增强,而且还可以应用于公用信道编码^[8],但由于对收发端激光器的对称性要求严格,其实际应用受到一定限制。另外,基于复杂半导体激光器结构的混沌同步通信是完善混沌通信及实现网络混沌通信的一种重要手段。有学者提出了波分复用双信道通信方案,用于实现多个发端激光器向一个收端激光器发送信息;也有学者利用垂直腔面发射激光器的偏振同步特性实现双信道通信等,但在实用性方面都尚缺乏考验。

3. 必要说明

目前,我国在混沌通信方面的研究在国际上也具有一定的特色,但主要集中在理论研究和有限的实验研究方面,其中,以西南交通大学、华中科技大学、北京邮电大学、西南大学、太原理工大学等学校的研究比较有特色,在国际高层次杂志上发表了许多文章。对于这一科学难题,有必要集中相关单位的力量共同努力,取得理论、实验及实用研究的突破。

4. 相关扩展

此外,激光混沌通信的应用还有很多需要进一步研究,如半导体激光器混沌通信系统对码元的要求、光纤链路中各种非线性效应对系统通信质量的影响、混沌通信系统的安全性方面(如随机性、抗攻击性)等。

参 考 文 献

- [1] Lang R, Kobayashi K. External optical feedback effects on semiconductor injection laser properties. *IEEE J. Quantum Elec.*, 1980, 16(3): 347—355.
- [2] van Wiggeren G D, Roy R. Communication with chaotic lasers. *Science*, 1998, 279: 1198—1200.
- [3] Lin F Y, Tsai M C. Chaotic communication in radio-over-fiber transmission based on optoelectronic feedback semiconductor lasers. *Optics Express*, 2007, 15(2): 302—311.
- [4] Vicente R, Mirasso C R, Fischer I. Simultaneous bidirectional message transmission in a chaos-based communication scheme. *Opt. Lett.*, 2007, 32(4): 403—405.
- [5] Kanakidis D, Argyris A, Syvridis D. Performance characterization of high-bit-rate optical chaotic communication systems in a back-to-back configuration. *Journal of Lightwave Technology*, 2003, 21(3): 750—758.
- [6] Argyris A, Syvridis D, Larger L, et al. Chaos-based communications at high bit rates using commercial fibre-optic links. *Nature*, 2005, 437(17): 343—346.
- [7] Li X F, Pan W, Luo B, et al. Mismatch robustness and security of chaotic optical communications based on injection-locking chaos synchronization. *IEEE J. Quantum Elec.*, 2006, 42(9): 953—960.
- [8] Klein E, Mislovaty R, Kanter I, et al. Public-channel cryptography using chaos synchronization. *Phys. Rev. E*, 2005, 2: 016204.

撰稿人: 闫连山

西南交通大学信息科学与技术学院

纳米尺度集成型非线性光信号处理器件的效率问题

The Efficiency of Nano-scale Integrated Nonlinear Optical Signal Processing Components

随着半导体工艺的不断进步,集成化已经成为未来光通信系统的发展趋势,特别是基于同一基底的片上整体集成是发展的最终目标。在光通信系统中,波长转换器、逻辑门、参量放大器、再生器等基于非线性光学效应的信号处理器件对保证系统的正常功能具有十分重要的作用^[1],这类器件具有高速、全光、码型格式透明等优点。研制高性能的非线性信号处理器件需要良好的非线性光学介质。近年来,绝缘体上硅(silicon-on-insulator, SOI)材料和工艺的迅速发展使得高集成度光波导的研制成为可能,以各种硅光子器件的设计与制作为主体的硅光子学正在成为重要的研究方向^[2]。SOI 是一种在绝缘衬底上形成一层单晶硅薄膜,或是具有“顶层单晶硅-绝缘氧化埋层-硅衬底”三层结构的材料。SOI 材料不但与 CMOS 集成工艺兼容,便于进行光子集成,而且可制作大截面尺寸的 SOI 光波导以降低同光纤的耦合损耗。另外,SOI 材料可实现制造器件的薄膜材料与衬底材料的完全隔离,减轻了衬底对器件的影响,工作性能大大提高。

硅波导的集成性能不仅由于成熟的工艺可以保证亚波长量级的波导尺寸,还由于硅和空气之间很大的折射率差可以保证硅波导对光的强约束能力,即使较弱的激光束也能获得很高的光功率密度。目前,硅波导中的光功率密度已达到传统单模光纤的 1000 倍以上^[3]。另外,硅材料具有较大的三阶非线性系数,因而硅基集成波导在非线性应用方面显示出巨大潜力。硅集成波导中的非线性效应已经陆续被人们发现。在过去的几年中,利用这些非线性效应的硅基光学器件已经被报道,如光放大器、激光器、光调制器、光开关、波长转换器等。

但是,和光纤等传统的非线性介质相比,基于硅波导的信号处理器件仍存在效率较低的问题,原因主要有以下几方面:①硅波导器件的非线性作用长度一般较短;②波导器件的耦合效率不高,波导截面尺寸越小,耦合效率的问题越突出;③硅材料的双光子吸收和由此引起的自由载流子吸收。双光子吸收和自由载流子吸收的强弱直接由材料的带隙和光子的频率所决定,硅材料的带隙和 $1.5\mu\text{m}$ 传统通信波段的光子频率恰好吻合,对于硅波导内的光波会造成强烈的吸收,而且双光子吸收系数正比于光强,自由载流子吸收系数正比于光强的

平方,通过提高入射泵浦光功率的方法对硅基非线性信号处理器件效率的提高帮助也十分有限^[4]。

目前,效率问题普遍存在于硅基信号处理器件之中,要想提高效率,就必须克服硅材料双光子吸收和自由载流子吸收的影响。为此,人们已经进行了一些探索。例如,通过在波导两侧制作电极施加电压的方法缩短自由载流子的有效寿命,从而减小自由载流子吸收损耗。利用这一方法,现在已经成功实现了连续光的硅基激光器^[5]和波长转换器^[6]。另外,在提高波导耦合效率方面也进行了一些工作,通过设计特殊的模式匹配结构可以有效提高光纤和硅波导之间的耦合效率^[7]。

硅波导中的非线性损耗源于硅材料的双光子吸收,而双光子吸收的强弱和硅的带隙及光子的频率密切相关。目前,已有研究工作证实硅材料的带隙可以通过掺杂的方法加以调整^[8],这是否会成为提高硅基非线性器件效率的有效方式?另外,根据硅材料的带隙推算,2 μm 以上的光子在硅材料中的双光子吸收效应将会明显减弱甚至可以忽略不计。目前,光通信的主要波段在 1.5 μm ,是否有可能将通信波段的主体向中红外波段转移?这些问题还需要将来不断地探索。

硅基非线性信号处理器件凭借良好的集成性能成为未来光通信系统的重要选择,有关效率问题的科学探索和技术进步将会成为实用化进程中的一个关键问题,对于集成型光通信系统的发展具有十分重要的意义。

参 考 文 献

- [1] Agrawal G P. Applications of Nonlinear Fiber Optics. 2nd ed. San Diego: Academic Press, 2008; 349—396.
- [2] Reed G T, Knights A P. Silicon Photonics: An Introduction. New York: Wiley, 2004; 57—110.
- [3] Fukuda H, Yamada K, Shoji T, et al. Four-wave mixing in silicon wire waveguides. Optics Express, 2005, 13(12): 4629—4637.
- [4] Liang T K, Tsang H K. Role of free carriers from two-photon absorption in Raman amplification in silicon-on-insulator waveguides. Applied Physics Letters, 2004, 84(15): 2745—2747.
- [5] Rong H, Jones R, Liu A, et al. A continuous-wave Raman silicon laser. Nature, 2005, 433(7027): 725—728.
- [6] Kuo Y H, Rong H, Sih V, et al. Demonstration of wavelength conversion at 40 Gb/s data rate in silicon waveguides. Optics Express, 2006, 14(24): 11721—11726.
- [7] Choudhury A N M M, Stanczyk T R, Richardson D, et al. Method of improving light coupling efficiency between optical fibers and silicon waveguides. IEEE Photonics Technology

Letters, 2005, 17(9): 1881—1883.

- [8] Liu J, Sun X, Kimerling L C, et al. Direct-gap optical gain of Ge on Si at room temperature. Opt. Lett., 2009, 34(11): 1738—1740.

撰稿人：高士明

浙江大学光电信息工程学系

太赫兹波室温下的直接探测

THz Direct Detection at Room Temperature

太赫兹波是指频率在 $0.1 \sim 10 \text{ THz}$ (波长为 $3000 \sim 30 \mu\text{m}$) 范围内的电磁波, 该波段位于毫米波和红外线之间。目前, 国际上对太赫兹辐射已达成了如下共识, 即太赫兹是一种新的、有很多独特优点的辐射源, 太赫兹科学技术是一个非常重要的交叉前沿领域, 为科技创新和国民经济的发展提供了一个非常诱人的机遇。

太赫兹探测是太赫兹研究领域一项关键科学技术问题, 是太赫兹科学技术进入应用领域的关键环节^[1]。由于目前太赫兹辐射源的功率普遍都较低, 因此, 发展高灵敏度、高信噪比的太赫兹探测方法尤为重要。太赫兹室温探测器是决定太赫兹波投入到实际应用的决定性条件之一。目前, 能在室温条件下进行太赫兹探测的大多是间接探测方式, 如光电探测、光电导探测和电子混频探测, 这些探测器的结构比较复杂, 限制因素较多。室温下, 太赫兹直接探测器也只有少部分热探测器(热释电)、气动探测器(高莱探测器)和一些光电探测器(场效应晶体管), 它们的响应带宽和探测灵敏度不太理想, 所以, 发展室温下理想的太赫兹直接探测器及阵列探测器十分必要。另外, 由于目前的太赫兹室温直接探测器多为单点探测器, 在成像应用中, 它们的探测速率很低, 不能满足实际应用需求, 所以, 亟须发展室温下太赫兹阵列探测器, 以此进行实时快速成像。而与阵列探测器相关的制作原理及方法的研究(包括单点探测器)、信号的获取及处理等是亟待解决的科学难题。

为了实现在室温下对太赫兹波的快速探测, 很多研究者将目光投向微悬臂梁阵列探测器, 由于它具有阵列式结构的特点, 从而摆脱了单点探测的束缚, 达到了快速探测的要求, 同时它也满足室温探测的条件, 但它仅仅适用于对红外波段的探测。2008年, 比利时的 Hastanin 等^[2]提出了利用表面等离子体共振技术检测悬臂梁弯曲的方法, 由于表面等离子体共振^[3]技术的灵敏度更高, 所以, 能够检测到悬臂梁的轻微弯曲。起初, 它们是利用该方法检测附着在悬臂梁上的分子, 具体的原理是: 事先在悬臂梁上涂有某种化学物质, 该物质可吸附相应的气体分子, 当气体分子附着在悬臂梁上后, 悬臂梁将弯曲, 随后通过表面等离子体共振传感器检测出气体分子的浓度。检测原理如图1所示。

随后, Hastanin 等^[4]又提出了将该方法应用在远红外和太赫兹方面的检测,




图1 利用表面等离子体共振方法检测悬臂梁弯曲

原理是：当太赫兹辐射到用两种热膨胀系数不同材料制作的悬臂梁时，悬臂梁将产生弯曲，进而利用表面等离子体共振传感器探测太赫兹。但是，他们仅仅给出了仿真数据，并没有进行实质研究。要实现在室温下对太赫兹的快速探测，将微悬臂梁阵列和表面等离子共振 (SPR) 传感器相结合是最佳的选择。表面等离子共振是：当光线由光密媒质 (折射率为 n_1) 照射到光疏媒质 (折射率为 n_2 ，并且 $n_1 > n_2$) 时，在入射角大于某个特定角度时，会发生全反射现象。如果在两种媒质的界面间存在一层合适厚度 (约为几十纳米) 的金属膜，在发生全反射的条件下，入射光线的倏逝波的 P 偏振分量将穿透导电金属层，并与金属层中的自由电子相互作用，激发出沿金属导体表面传播的表面等离子体波^[5]，适当改变入射光角度或者波长。当入射光波矢在媒质界面方向上的投影 k_x 与表面等离子体波的固有传波波矢 k_{sp} 满足 $k_x = k_{sp}$ 时，倏逝波与表面等离子波发生共振，入射光的大部分能量被表面等离子波吸收，使得发射光能量急剧下降，从而出现共振吸收峰，由于发生了入射光的能量吸收，这种全反射形式也被称为衰减全反射。

将微悬臂梁阵列和表面等离子共振相结合实现在室温下对太赫兹的快速探测，主要困难有以下几点：

- (1) 微悬臂梁阵列上吸收材料与太赫兹的相互作用机理，使吸收达到极值。
- (2) 微悬臂梁阵列所需的热膨胀系数差异较大的双材料的选择^[6]。
- (3) 发生表面等离子共振的条件，选择金膜的最佳厚度，微悬臂梁阵列与金膜间的最佳距离。
- (4) 微悬臂梁阵列与微棱镜阵列的耦合关系。
- (5) 发生表面等离子共振后的发射光的强弱与悬臂梁的弯曲程度之间的关系。

由于太赫兹波段处于红外和微波之间，它既不完全适用于光学理论来处理，

也不完全适合微波的理论来研究,从而就形成了科学家们通常所说的“太赫兹空隙”^[7],对其进行实质性的研究开始于20世纪80年代中期,对太赫兹进行探测的技术还非常不完善。把微悬臂梁阵列和表面等离子共振相结合实现在室温下对太赫兹的快速探测必将在太赫兹成像领域和安检领域发挥巨大作用。

参 考 文 献

- [1] Gunter G, Anappara A A, Hees J, et al. Sub-cycle switch-on of ultrastrong light-matter interaction. *Nature*, 2009, 458: 178—181.
- [2] Hastanin J, Renotte Y, Fleury-Frenette K, et al. A far infrared/terahertz micromechanical sensor based on surface plasmons resonance. *Proceedings of SPIE*, 2008, 71131C: 1—9.
- [3] Otto A. Exaction of nonradiative surface plasma waves in silver by the method of frustrated total reflection. *ZPhys.*, 1968, 216(4): 398—410.
- [4] Hastanin J, Renotte Y, Fleury-Frenette K, et al. A gas micromechanical sensor based on surface plasmons resonance. *Proceedings of SPIE*, 2008, 711609: 1—122.
- [5] Kretschmann E. The determination of the optical constants of metals by excitation of surface plasmons. *ZPhys.*, 1971, 241(4): 313—324.
- [6] Yang Z, Mao M Y, et al. Optomechanical uncooled infrared imaging system: Design, micro-fabrication, and performance. *J. of MEMS*, 2002, 11(2): 136.
- [7] Tonouchi M. Cutting-edge terahertz technology. *Nature Photonics*, 2007, 1: 97—105.

撰稿人: 张存林 苏 波
首都师范大学物理系

太赫兹脉冲波前整形

THz Pulse Shaping

太赫兹频率脉冲光谱成像技术已经在近些年被人们认识到了它在工业无损探伤、公共安全和国防领域的巨大发展潜力^[1]。太赫兹脉冲能够穿透多种日常材料,如皮革、纸张、木头、塑料、陶瓷等。由于它的光子能量远远小于 X 射线,因此,不像 X 射线那样会对生物体造成损伤。目前为止,没有发现太赫兹射线对人体的危害。太赫兹脉冲具有几十甚至 100THz 的宽广的频谱范围,覆盖了很多重要化合物的转动和振动能级。已经发现的具有太赫兹指纹的化合物有爆炸物、毒品、氨基酸等^[2,3]。由于太赫兹脉冲的这些独具特色的性质,使得这种技术具有了发展成为新一代具有识别功能的无损探伤和成像装置的潜力。近些年来,国内外很多新的太赫兹领域的研究工作都是围绕着怎样提高成像分辨率、成像速度和识别效率来开展的。本文所关注的科学问题是如何对光致空气等离子体产生的太赫兹光源的脉冲波前进行整形,从而实现大尺度、远距离太赫兹脉冲二维光谱成像。

太赫兹二维脉冲光谱成像一直是国内外关注的热点,因为这种成像方法摒弃了以前传统的点扫描方式,把大口径的太赫兹光束直接照在靶物体上并且进行收集^[4]。这种做法极大缩短了成像时间,是今后比较具有实际应用价值的大规模、远距离成像的发展模式。但是,这种方法遇到的一个重要问题就是:由于光束面积大(直径大于 10cm),而且收集之后每个像素点的脉冲又携带着靶物体的重要特征,因此,每个像素点脉冲的强度、信噪比,还有位相要保持高度的完美。如果在传播过程中,光束的局部相位或者强度被调制了,那么,最终将极大影响成像结果。因此,一般来说,这种成像方式对太赫兹光源的质量要求极高。

近些年发现的四波混频光致空气等离子体产生太赫兹脉冲给太赫兹成像领域提供了新的、强大的太赫兹源的产生方式^[5],这种方式产生的太赫兹脉冲调制是以前光整流方式的 2~4 倍,而且光谱很宽,在 10THz 内都有很好的信噪比。并且空气作为介质允许将光脉冲传播到远处再产生太赫兹,避免了水蒸气对太赫兹的吸收,为将来的远距离探测提供了可能。但是,这种方法产生的太赫兹波前非常不完整。由于空气中的光致等离子体形状都为沿传播方向的长纺锤形,因此,等离子体各个部分相互干涉导致了产生出的太赫兹脉冲光斑具有位相和强度两方面的调制^[6]。虽然这种光源频谱宽、信噪比高,但如果波前的

不完整性使其在实际成像工作中的应用将受到极大限制。因此,太赫兹脉冲的波前整形是目前太赫兹成像领域一个非常具有实际意义的工作。

脉冲整形在可见光和红外领域已经发展了很多年,但在太赫兹领域仍然是一个空白。现有的脉冲波前整形方法主要有三种:液晶脉冲整形、声光晶体脉冲整形和微变形反射镜脉冲整形^[7]。这三种方法各有特点。例如,液晶脉冲整形器可以对脉冲的强度和位相同时进行调整,但由于像素的离散性,会造成波前存在整形死角。声光晶体脉冲整形器的像素颗粒可以做得非常小,但效率很低。而微变形反射镜虽然没有整形死角,但只能对位相进行调整,无法对强度进行整形。太赫兹脉冲波长较长,因此,分辨率相对红外和可见光要低很多,对像素颗粒大小的要求也就相应要低。另外,光致空气等离子产生的太赫兹波前是条纹状的,具有很强的规律性,因此,通过微蚀刻技术制造出满足太赫兹波长的脉冲整形装置应该是可行的。但是,由于光谱成像,尤其是反射式光谱成像对位相精度和信噪比的极其严格的要求,因此,如果想进行光谱识别工作的话,这种外加波前整形器的方法还是具有一定难度和挑战的。

太赫兹脉冲整形技术的实现对太赫兹脉冲光谱成像具有非常重要的意义。事实上,无论对光致等离子体产生的太赫兹脉冲,还是光整流、光导天线,或者其他方式产生的太赫兹脉冲,通过波前整形的方法,都可以对脉冲光源进行修饰,使得成像质量大大提高。另外,波前整形理论上说可以将波前修饰出任何形状,这给我们提供了另一个可以发展的空间:可以通过整形器将太赫兹波前修饰出非高斯形,或者进行一定调制,使得太赫兹波前具有另外的性质。例如,通过调制的太赫兹波前可以被用来进行二维编码数据传输,或者调制后的波前模式可能会有利于在某种特定情况下传播,如沿着钢丝,或者在光导纤维内。这些可能的发展方向一经实现,都将迅速地具有现实广阔的应用前景。

参 考 文 献

- [1] Hu B B, Nuss M C. Imaging with terahertz waves. *Opt. Lett.*, 1995, 20: 1716.
- [2] Grischkowsky D, Keiding S, Exter M, et al. Far-infrared time-domain spectroscopy with terahertz beams of dielectrics and semiconductors. *J. Opt. Soc. Am. B*, 1990, 7: 2006.
- [3] Zhong H, Sanchez A R, Zhang X C. Identification and classification of chemicals using terahertz reflective spectroscopic focal plane imaging system. *Optics Express*, 2006, 14: 9130—9141.
- [4] Cook D J, Hochstrasser R M. Intense terahertz pulses by four-wave rectification in air. *Opt. Lett.*, 2000, 25: 1210.
- [5] Wu Q, Hewitt T D, Zhang X C. Two-dimensional electro-optic imaging of THz beams. *Applied Physics Letters*, 1996, 69: 1026.
- [6] Zhong H, Karpowicz N, Zhang X C. Terahertz emission profile from laser-induced air plasma.

Applied Physics Letters ,2006 ,88 ;261103 .

[7] <http://www.physics.gatech.edu/frog/UFOBook/13-Ultrafast-Pulse-Shaping-Vaughan.pdf> .

撰稿人：张存林 钟 华
首都师范大学物理系

基于固态增益介质能级跃迁的太赫兹波辐射机理

The Mechanism of Terahertz Radiation Based on Energy Transition in the Solid Gain Medium

太赫兹波是指频率在 $0.1 \sim 10 \text{ THz}$ ($1 \text{ THz} = 10^{12} \text{ Hz}$) 之间的电磁辐射, 介于毫米波与远红外光之间。由于太赫兹波的频谱很宽, 覆盖了各种凝聚态物质和生物大分子转动和集体振动频率, 各种物质在太赫兹波波段的发射、反射和透射光谱中包含了丰富的物理和化学信息, 因此, 太赫兹波在医学成像、材料检测、环境监测、天文学、分子光谱、生命科学等研究领域均有重大的科学研究价值和广阔的应用前景^[1~3]。目前, 限制太赫兹波技术发展的主要瓶颈是缺乏高效、稳定、小型化、室温工作的相干太赫兹辐射源。基于光学方法产生太赫兹辐射源的技术通常集中在传统的非线性光学领域, 如参量振荡和差频技术, 但都存在着转换效率低、系统复杂等技术问题^[4,5]。基于固态增益介质中原子最大相干能级共振拍频是产生高效太赫兹波辐射的新方法。最初, 利用原子最大相干产生太赫兹波是利用气体作为介质的。2005 年, Kalugin 等^[6]提出在原子或分子气体中利用相干散射来产生强脉冲太赫兹波辐射, 其原理是利用泵浦光激发原子或分子气体, 使其相应能级原子之间达到最大相干共振加强辐射出太赫兹波, 太赫兹波的脉冲能量可以达到微焦量级。之后, 此原理被应用到固态介质。2006 年, Kuznetsova 等^[7]提出利用红宝石介质中² E 能级的两个分裂能级上的相干原子共振拍频产生太赫兹波辐射。理论计算表明, 室温下可以得到纳焦量级的相干太赫兹波输出, 低温下 ($1.8 \sim 4.2 \text{ K}$) 可以得到毫焦量级的太赫兹波输出。

1. 问题描述

下面以红宝石晶体为例说明固态增益介质能级共振跃迁拍频产生太赫兹波辐射的机理。在红宝石晶体中, 存在着从基态能级向高能级跃迁的 R_1 线和 R_2 线, R_1 线和 R_2 线间的频率差为 29 cm^{-1} , 处于太赫兹波段。 R_1 线和 R_2 线联系着的三个能级 $|a\rangle$ 、 $|b\rangle$ 、 $|c\rangle$ 构成 V 型能级结构。根据原子跃迁选择定则, $|a\rangle$ 能级不能同时向两个相邻能级 $|b\rangle$ 、 $|c\rangle$ 跃迁, 但由于红宝石晶体本身的晶体场对 Cr^{3+} 离子的晶体场施加影响, 使得 R_1 线和 R_2 线跃迁成为可能。拉比频率为 Ω 、 Ω 的两个相干光场把原子从共同的基态 $|a\rangle$ 激发到相应的高能级 $|b\rangle$ 、 $|c\rangle$, 由于原子在 $|b\rangle$ 、 $|c\rangle$ 能级间的电偶极矩不为零, 所以, $|b\rangle$ 、 $|c\rangle$ 能级间的相干原子




图1 红宝石 V 型三能级结构示意图

就会共振拍频辐射出太赫兹波。通过解系统的密度矩阵方程,可以得到输出太赫兹波的表达式,太赫兹波输出能量与红宝石晶体的工作温度、晶体中 Cr^{3+} 离子的浓度、晶体长度、原子在能级间的相干程度、泵浦光拉比频率的大小有关(如图1所示)。

固态增益介质能级共振跃迁拍频产生太赫兹波辐射在理论上已经被证明了,但还存在一些难点需要突破。

固态增益介质中,退相干效应很严重,退相干时间比集居数衰减时间短很多,所以,严重影响太赫兹波的转化效率。只有在极低的温度下,退相干时间和集居数衰减时间才具有可比性,但超低温工作系统的实用性会受到很大影响,所以,如何使室温下固态增益介质退相干时间变长成为一个亟须解决的理论问题。

2. 必要说明

固态增益介质能级共振跃迁拍频产生太赫兹波辐射的机理与气体介质中能级共振拍频产生太赫兹波辐射的机理是不同的。在气体介质中,比较多的是利用双 Δ 系统或 Δ -V 四能级系统^[8]。由于气体介质是均匀的,受到原子跃迁选择定则的限制,公共基态能级上的原子不能直接跃迁到可以共振拍频产生太赫兹波的相邻能级,基态能级上的原子要通过受激拉曼绝热通道技术跃迁到上能级,然后再与下能级上的原子共振拍频产生太赫兹波,这个过程与固态介质中能级共振跃迁拍频产生太赫兹波辐射的机理有明显不同。

3. 相关扩展

此原理也可以应用于很多稀土离子、过渡金属离子,如 $\text{Cr}^{3+} : \text{BeAl}_2\text{O}_4$ 、 $\text{Pr}^{3+} : \text{LaF}_3$ 、 $\text{Nd}^{3+} : \text{YAG}$ 、 $\text{Nd}^{3+} : \text{YVO}_4$ 、 $\text{Er} : \text{YLiF}_4$ 等。稀土离子、过渡金属离子的能级被基质的晶体场影响,自旋轨道分裂为几个子能级,相应子能级之间的间隔为几十到几百个波数,处于太赫兹范围内。利用两束相干泵浦光将共同的基态能级上的原子激发到高能级,高能级上的相干原子就会共振拍频产生太赫兹波。对 $\text{Cr}^{3+} : \text{BeAl}_2\text{O}_4$ (紫翠玉)来说,相应能级间 R 线的间隔为 41cm^{-1} ,对应着 1.23THz ,室温下,它的吸收截面要比红宝石大 10 倍,基于此,在相同的条件下,利用紫翠玉可以获得能量更高的太赫兹波,有效提高非线性转换频率。

参考文献

- [1] Siegel P H. Terahertz technology .IEEE Transactions on Microwave and Techniques ,2002 ,

- 50(3):910—928.
- [2] Ferguson B, 张希成. 太赫兹科学与技术研究回顾. 物理, 2003, (32): 287—293.
- [3] Shikata J, Kawase K, Karino K, et al. Tunable terahertz-wave parametric oscillators using LiNbO_3 and $\text{MgO}:\text{LiNbO}_3$ crystals. IEEE Transactions on Microwave and Techniques, 2000, 48(4): 653—661.
- [4] Ikari T, Zhang X B, Minamide H. THz wave parametric oscillator with a surface emitted configuration. Optics Express, 2006, 14(4): 1604—2485.
- [5] Edwards T, Walsh D, Spurr M, et al. Compact source of continuously and widely tunable terahertz radiation. Optics Express, 2006, 14(4): 1582—1589.
- [6] Kalugin N G, Rostovtsev Y V, Scully M O. Generation of intense short pulses of THz radiation via coherent scattering in atomic and molecular gases. Proceedings of SPIE, 2005, 6120(2): 1—4.
- [7] Kuznetsova E, Rostovtsev Y, Kalugin N G. Generation of coherent terahertz pulses in ruby at room temperature. Phys. Rev. A, 2006, 74(2): 1—10.
- [8] Kalugin N G, Rostovtsev Y V. Efficient generation of short terahertz pulses via stimulated Raman adiabatic passage. Opt. Lett., 2006, 31(7): 969—971.

撰稿人: 姚建铨 徐德刚 李忠洋
天津大学精密仪器与光电子工程学院

光频段到太赫兹波频率下转换效率限制

The Conversion Efficiency Limitation from Optical Frequency to Terahertz Frequency

太赫兹波是指频率在 $0.1 \sim 10 \text{ THz}$ 范围内的电磁波 ($1 \text{ THz} = 10^{12} \text{ Hz}$), 其波段位于电磁波谱中毫米波和远红外光之间 ($30 \mu\text{m} \sim 3 \text{ mm}$, 所以亦有文献称其为亚毫米波), 是光子学技术与电子学技术、宏观与微观的过渡区域, 成为当前新兴的重点发展科学技术之一。太赫兹辐射源是太赫兹技术发展的关键技术之一, 根据太赫兹波所处的电磁波谱中的位置, 其辐射可以利用光学技术和电子学技术两种方法来产生。光学方法, 就是将光学频段向太赫兹波频段的频率下转换技术。光学方法产生的太赫兹辐射源可以覆盖整个太赫兹波谱频段, 具有室温运转、频率可调谐及小型化等优点, 但由于光频波段的频率远远大于太赫兹波的频率[如由近红外激光(约 $1 \mu\text{m}$)产生太赫兹波(约 1 THz 或 $300 \mu\text{m}$)], 导致光学太赫兹辐射源输出平均功率在毫瓦、微瓦, 甚至纳瓦量级, 转换效率非常低(小于 10^{-4} 量级)。因此, 如何突破光频段到太赫兹波频率下能量转换效率限制, 提高输出功率, 成为当前太赫兹科学技术中亟待解决的问题。

基于非线性光学频率下转换技术获得太赫兹辐射是光学产生太赫兹辐射的重要方法之一^[1,2], 其中, 非线性差频、光学整流及光学参量振荡效应是主要的非线性光学方法^[3,4], 其基本原理是利用介质的二阶或三阶非线性光学效应, 将高频率的相干光波降频到低频率的太赫兹波, 实现能量转换。以非线性差频产生太赫兹辐射源为例, 将两个频率相近的相干光波 ω 和 ω ($\omega > \omega$) 入射非线性晶体中, 通过二阶非线性效应进行光参量差频过程, 获得太赫兹辐射波 ($\omega - \omega = \omega_r$)。从量子转化角度来看, 这个非线性过程是一个光波光子 ω 产生了一个太赫兹光子 ω_r , 理论上可以实现 100% 转换效率, 但光波的光子能量 $h\omega$ 比太赫兹波光子能量 $h\omega_r$ 高 2~3 个数量级, 其能量转换效率 $h\omega_r/h\omega$ 很低, 理论上可以实现千分之几的效率极限, 实际中考虑到介质的吸收后, 转换效率就非常低了, 这就大大限制了光学方法产生太赫兹波辐射源的输出功率。

针对光学方法产生太赫兹辐射源功率输出低的现状, 目前, 相关领域的学者们做了大量的工作: 一方面探索新型的非线性晶体材料^[5], 提高非线性晶体的非线性系数; 另一方面在减少介质对太赫兹的吸收损耗方面做了很多技术突破^[6], 但这些都没有突破光波到太赫兹波光子能量转换的限制。要想突破这种光子能量转换限制, 必须从提高光子的转换效率方面考虑, 如一个光学光子可

以产生若干太赫兹光子,使光子转换效率实现数量级的突破,这样,就大大弥补了光子能量转换效率的限制。美国斯坦福大学 Fejer 课题组利用周期反转 GaAs 材料探索了级联差频实现光子转换效率成倍提高的机理^[7],但光波波段到太赫兹的光子转换效率实现数量级突破还需要在非线性理论上进行突破和探索,目前还没有人报道!

总之,光学方法产生太赫兹辐射因能够产生整个太赫兹波谱的辐射源,在太赫兹科学技术中具有重要的应用潜力,高转换效率的光学太赫兹辐射源目前尚处于探索研究阶段,现有的光学方法和光学理论还需要进一步发展。新型的太赫兹波段的光学晶体材料也在探索当中。

参 考 文 献

- [1] 孙博,姚建铨.基于光学方法的太赫兹辐射源.中国激光,2006,33(10):1349—1359.
- [2] Siegel P H. Terahertz technology. IEEE Transactions on Microwave and Techniques, 2002, 50(3):910—928.
- [3] Shikata J, Kawase K, Ito K. The generation and linewidth control of terahertz waves by parametric processes. Electron. Comm. in Japan, 2003, 86(5):52—63.
- [4] Ding Y J, Shi W. Widely tunable monochromatic THz sources based on phase-matched difference-frequency generation in nonlinear-optical crystals: A novel approach. Laser Physics, 2006, 16(4):562—570.
- [5] Belkin M A, Capasso F, et al. Terahertz quantum-cascade-laser source based on intracavity difference-frequency generation. Nature Photonics, 2007, 1:288—292.
- [6] Kawase K, Shikata J, Ito H. Terahertz wave parametric source. Journal of Physics D: Applied Physics, 2001, 34:R1—R14.
- [7] Schaar J E, Vodopyanov K L, Kuo P S, et al. Terahertz sources based on intracavity parametric down-conversion in quasi-phase-matched gallium arsenide. IEEE Journal of Selected Topics in Quantum Electronics, 2008, 14(2):354—362.

撰稿人: 徐德刚 姚建铨 王与焱 钟 凯
天津大学精密仪器与光电子工程学院

太赫兹波大气传输统一模型

Unified Model of Terahertz Radiation Atmospheric Propagation

太赫兹辐射大气传输特性的研究对太赫兹波在空间通信、大气科学、遥感检测、军事保密等领域的应用和发展具有十分重要的意义。太赫兹的空间应用,如太赫兹遥感、大气科学、太赫兹雷达、太赫兹通信等,是太赫兹应用领域的重要组成部分,但由于这些方面依赖于太赫兹辐射在大气中的传输,而目前国内对太赫兹在大气中的传输特性的研究还很不完善,使得此类应用的研究进展缓慢。如果能够精确地知道不同条件下太赫兹频段大气透过率窗口的位置和宽度,能够为太赫兹辐射的空间应用奠定坚实基础,具有重要的研究意义和实用价值,这里所涉及的不同条件包括不同大气高度、温度、压强、不同季节、不同环境(如陆地、沙漠、海洋等)、不同路径(如水平路径、倾斜路径、垂直路径等)等各种可能会影响太赫兹辐射大气传输特性的因素。如何建立一个统一的太赫兹辐射传输模型是一个科学难题。

研究太赫兹辐射在大气中的传输特性,其原理和实质就是研究太赫兹辐射与大气的相互作用过程。太赫兹单色辐射在大气中传输时,要经历衰减和增强两类过程。

(1) 太赫兹辐射在大气中的基本衰减过程。吸收和散射是太赫兹波在大气中传输时经历的两种基本衰减过程。在某些模型中^[1],将大气对太赫兹辐射的吸收分为两类:第一类是被空气中的水汽吸收,它由光谱参数描述,包括吸收谱线的中心频率、振幅强度和压力致宽系数等。大气中常见的气体分子的光谱参数可以在已有的数据库,如 JPL^[2]、GEISA Database^[3]、HITRAN^[4]等中查找,目前最常用的是 HITRAN 数据库。第二类吸收是“连续吸收”,也称为过剩吸收,它不能由水汽吸收线所描述,在很宽的电磁波频率范围内均可观测到(从微波到红外)。散射在所有波长上都出现。位于太赫兹波传播路径上的粒子通过这种过程由入射波里连续地提取能量,并将此能量向各个方向重新辐射出去。

(2) 太赫兹辐射在大气中的基本增强过程。由于大气和太赫兹辐射是相互作用的,太赫兹辐射在大气中传输时,也会经历增强过程,这主要是由散射和热辐射引起的,这两种机制的相对重要性因波长的不同而不同。

太赫兹辐射大气传输研究的核心问题是建立合理的大气传输模型,需要考虑各种因素对大气传输特性的影响,借鉴多种建模思想、算法和近似处理技巧,

具有一定难度。目前,可用于研究太赫兹辐射的大气传输模型有多种,如MPM(atmospheric millimeter-wave propagation model)模型^[5]、ATM(atmospheric transmission at microwaves)模型^[6]、Moliere(V5)(microwave observation line estimation and retrieval, Version 5)模型^[7]、SARTre(spherical atmospheric radiative transfer model)模型^[8]和AMATERASU(model for atmospheric terahertz radiation analysis and simulation)模型^[9]等。上述模型中,除去日本国家信息和通信技术研究(NICT)提出的AMATERASU是一个专门针对太赫兹频段建模的模型外,其他模型只是部分覆盖了太赫兹频段。

AMATERASU模型研究可用于大气遥感、通信系统和预测太赫兹热大气辐射对地球能量收支平衡影响的各个太赫兹频段,它在继承Moliere和SARTre的基础上改进而来,已经完成的改进工作有:①对太赫兹在非散射和水平均匀大气的传输建模。这一步的建模主要基于Moliere,还需做的工作有考虑水平非均匀的大气建模。②在AMATERASU模型中增加云的情况。此时,需要考虑云和大气微粒的影响,所以,采用带有散射的辐射传输计算。这一步的建模主要继承SARTre模型。目前,AMATERASU模型存在的最大问题是所继承的Moliere和SARTre模型中某些模块之间的相互兼容。

通过对适用于研究太赫兹频段大气辐射传输特性的各个模型的分析 and 比较,我们发现,建立太赫兹辐射大气传输的合理、通用性强的统一模型非常困难。一方面,如果建模时能充分考虑各种影响太赫兹辐射大气传输特性的因素,那么,模型的适用范围广、精确性高,问题是计算复杂度太高;另一方面,如果在建模时进行合理近似,虽然能够提高模型运行效率,但模型仅能满足某些特殊条件,适用范围窄,灵活性差。建议尝试采用模块化思想,把每种因素的影响做成一个模块,针对不同情况,调用不同模块,并注意各个模块间的兼容性。

要建立统一的太赫兹辐射传输模型是一个科学难题,涉及众多学科,如分子光谱学、电磁波学、辐射传输学、大气化学、大气遥感物理学及气象学等,各个学科间存在一定交叉,有待研究和开发。

与建立相关统一模型所对应的相关扩展问题有以下几点:

(1) 光谱参数精确性的改进。现有数据库中的光谱参数,仅有部分数据是通过实测得到,大部分数据是依据模型计算而来,其精确性有待考证。而目前对太赫兹波段某些光谱参数进行实测非常困难,由于缺乏相关的太赫兹功能器件和实测条件,使得很多实测数据均为空白。要想提高建模的精确性,尚需在太赫兹仪器设备的研发和改进、光谱参数测量等方面做更多努力。

(2) 目前仍然无法完全解决产生连续吸收的物理机制问题。其中,对太赫兹辐射影响较大的是水汽连续吸收,迄今为止,对水汽连续吸收提出过三种理

论解释：远翼吸收、碰撞诱导吸收及双水分子吸收。相应的处理方法有：CKD 连续吸收经验方法，M&T 连续吸收理论方法，MT-CKD 连续吸收理论；半经验处理方法等。毫无疑问，水汽连续吸收来源于水分子之间的相互作用，但如何描述这些相互作用并把它们模式化，仍然是一个有待解决的问题。尽管在这方面已经开展了大量研究，对太赫兹频段的水汽连续吸收的实验室测量和理论计算也有相关报道^[10,11]，但结果仍然不令人满意。

(3) 散射粒子尺度和时空的多变性给实际计算仿真带来的困难。在散射过程中，大气中造成太赫兹波散射的粒子主要有气溶胶(指悬浮在气体中的小粒子构成的多分散系)和水汽凝结物(云、雨、雪等)，其中，气溶胶由于在大气中的尺度和时空变化很大，其辐射效应成为仿真计算中的难题。

参 考 文 献

- [1] Kasai Y, Seta T. Atmospheric propagation model of terahertz-wave. *Journal of the National Institute of Information and Communications Technology*, 2008, 55(1): 73—77.
- [2] JPL database, <http://spec.jpl.nasa.gov/>.
- [3] Hess M, Koepke P, Schult I. Optical properties of aerosols and clouds: The software package OPAC. *Bull. Am. Met. Soc.*, 1998, 79: 831—844.
- [4] Rothman L S, Gordon I E, Barbe A, et al. The HITRAN 2008 molecular spectroscopic database. *J. Quant. Spectrosc. & Radiat. Transfer*, 2009, 110: 533—572.
- [5] Liebe H J. MPM-An atmospheric millimeter-wave propagation model. *International Journal of Infrared and Millimeter Waves*, 1989, 10(6): 631—650.
- [6] Pardo J R, Cernicharo J, Serabyn E. Atmospheric transmission at microwaves (ATM): An improved model for millimeter/submillimeter applications. *IEEE Trans. on Antennas Propagat.*, 2001, 49(12): 1683—1694.
- [7] Urban J, Baron P, Lautié N, et al. Moliere(v5): A versatile forward-and inversion model for the millimeter and sub-millimeter wavelength range. *J. Quant. Spectrosc. & Radiat. Transfer*, 2004, 83: 529—554.
- [8] Mendrok J. The SARTre model for radiative transfer in spherical atmospheres and its application to the derivation of cirrus cloud properties [PhD Dissertation]. Berlin: Freie Universität Berlin, 2006: 1—109.
- [9] Baron P, Mendrok J, Kasai Y, et al. AMATERASU: Model for atmospheric terahertz radiation analysis and simulation. *Journal of the National Institute of Information and Communications Technology*, 2008, 55(1): 109—120.
- [10] Podobedov V B, Plusquellic D F, Siegrist K M, et al. Laboratory measurements for the water vapor continuum and theoretical calculations for the water vapor foreign continuum in the terahertz spectral region. *AIP Conf. Proc.*, 2009, 1100(1): 151—154.

- [11] Podobedov V B, Plusquellic D F, Siegrist K E, et al. New measurements of the water vapor continuum in the region from 0.3 to 2.7 THz. J. Quant. Spectrosc. & Radiat. Transfer, 2008, 109: 458—467.

撰稿人：姚建铨¹ 汪静丽² 徐德刚¹

1 天津大学精密仪器与光电子工程学院

2 南京邮电大学光电工程学院

如何测量含水环境中生物样品的太赫兹频率响应

How to Measure Terahertz Frequency Responses of Bio-materials in Environments with Water

在所有的生物体中,生物分子对环境变化和外来物做出反应时发生的结构改变是一个极其重要的过程。例如,在视觉过程、植物光合作用效率随外界光线强弱的分子调控过程,以及药物-靶分子的反应过程中,都伴随着生物分子的结构变化。目前,比较成熟的光谱分析技术通常采用可见光和近、中红外光,在多数情况下,对应的分子光谱响应主要来自于分子的电子态和比较局域的振动激发态(如和特定分子键相关的中红外“指纹谱”),而探测涉及更多原子的、发生在较大尺度内的分子结构变化(如构型、构象改变等),这些现有的实验测量技术可以得到的信息通常是非直接的,对于相应变化动态过程的观察更是缺少有效和可靠的技术手段。而生物分子在太赫兹频率存在着直接和其大尺度结构紧密关联的特征响应,这里,分子内的质量分布和电荷分布决定这种集体振动的共振频率,与此关联的量子化能量在毫电子伏量级。所以,利用太赫兹光谱技术对生物和医学中的一些问题进行研究,存在重要的物理基础和独特的应用价值^[1]。

自从 20 世纪 90 年代有关太赫兹辐射的研究开始兴起以来,利用太赫兹光谱技术对生物分子进行分析就是一个非常受重视的研究领域,并开展了大量有关生物分子太赫兹频率响应的理论计算和生物体系的太赫兹时域光谱测量及成像等实验工作。例如,对 DNA、蛋白和其他生物分子开展的太赫兹时域光谱测量和分析,对生物组织的各种成像等,所研究的对象多为冻干粉样品和固态薄膜样品,这些研究成果初步证明了太赫兹光谱技术对生物分子和样品进行分析和功能性成像的独特能力^[2,3]。

现在已经知道,很多生物大分子在单体自由状态下存在和结构有关的太赫兹频率特征响应,但这些分子在生物体内通常都存在于含水的环境中,它们与水分子之间可以形成氢键和其他结构,维持着某种动态的准平衡状态,并在这个基础上保持其生物活性。对于分析和测量这种情况下生物分子的太赫兹频率响应,存在两个基本问题:①理论计算方面。环境中,水分子的存在导致附加的相互作用会修饰生物分子的结构,改变原有的质量和电荷分布,这使得基于自由单分子模型得到的太赫兹频率响应只是一个粗略的近似,而精确计入生物分子周边水分子的影响则是相当困难的问题。②实验探测方面。水对太赫兹辐

射的强烈吸收(吸收系数 $>200/\text{cm}$)使通常的透射测量变得非常困难,即使采用强太赫兹源和薄样品,测量的灵敏度和动态范围都很低;而反射测量在实验安排和数据提取方面也存在一些困难,得到的数据精度不高。这使得现有的太赫兹光谱探测技术很难对近生理条件下生物分子(如缓冲液中的分离样品)进行有效探测和光谱分析,因而很多研究只能对冻干粉等无水状态的样品进行实验测量,由此得到的结果是否和含水条件下相同,完全不能确定。这一现状极大地阻碍了太赫兹光谱分析技术在生物和医学领域的应用。

关于含水环境中生物样品的太赫兹光谱测量问题,一个直接的思路是利用高功率可调谐太赫兹光源,使足够强的透射信号能够穿过样品,保持足够的测量信噪比和动态范围。目前,可利用的高功率太赫兹光源有同步辐射、太赫兹自由电子激光器、P掺杂的锗太赫兹激光器、连续波气体太赫兹激光器、量子级联太赫兹激光器和利用强飞秒激光脉冲电离气体产生的宽带太赫兹源等。但是,它们都很难同时满足易用性、高功率和宽调谐范围的要求。尽管如此,有关生物分子和水环境的相互作用研究近期还是取得了一些重要的进展。例如,利用调谐范围有限的高功率P型掺杂锗太赫兹激光器和差分测量技术可以对 $100\mu\text{m}$ 厚度的水溶液样品进行有效的太赫兹光谱分析,在不同蛋白结构的水合过程及其机理研究中,发现蛋白的二级结构细节和溶剂化过程密切相关,首次在试验上直接观察到蛋白与周边水分子的长程动力学相互作用对生物分子水合过程的重要影响^[4,5]。

另一个可能的解决思路是放弃对材料样品溶液的透射测量,采用表面和界面波探测技术。例如,在光频波段,利用金属镀膜棱镜耦合的表面等离子体共振过程对金属-电介质界面样品介电性质变化的高度敏感性,已经产生了实用的商业测量仪器,在生物和医学研究中测量含水缓冲液中和生物分子结构相关的介电响应,包括分子反应等问题中,发挥了重要和难以替代的作用。在太赫兹频率,此类技术还未见报道,原因可能是可利用的光源有限和实验安排的相对困难。遵循这一思路,近年蓬勃发展的电磁特异材料也有可能用于解决含水生物样品光谱响应测量问题^[6]。这里,关键的问题是寻找和发现合适的器件和测量方法,一方面能够得到包含样品介电性质的、足够灵敏的测量信号;另一方面,发展有效并可靠地提取缓冲液中生物样品光谱响应参数的算法。

对于溶剂中的生物分子光谱响应分析,在获得体系的电磁响应数据以后,如何得到表征这个体系中所研究的生物分子样品的参数,存在一定的自由度。例如,在含水缓冲液中的生物分子,是否把它周围的壳层水分子包含在内作为一个系统来描述,是一个可以选择的问题。

参 考 文 献

- [1] Sherwin M S, Schmuttenmaer C A, Bucksbaum P H. Opportunities in THz science. Arlington: Report of DOE-NSF-NIH Workshop, 2004.
- [2] Zeitler J A, Taday P F, Newnham D A, et al. Terahertz pulsed spectroscopy and imaging in the pharmaceutical setting—a review. J. Pharmacy and Pharmacology, 2007, 59: 209—223.
- [3] Pickwell E, Wallace V P. Topic review: Biomedical application of terahertz technology. Journal of Physics D: Applied Physics, 2006, 39: 301—310.
- [4] Ebbinghaus S, Kim S J, Heyden M, et al. Protein sequence- and pH-dependent hydration probed by terahertz spectroscopy. Journal of the American Chemical Society, 2008, 130: 2374—2375.
- [5] Born B, Haenith M. Terahertz dance of proteins and sugars with water. International Journal of Infrared and Millimeter Waves, 2009, 30: 1245—1254.
- [6] Sun Y M, Xia X X, Feng H, et al. Modulated terahertz response of split ring resonators by nanometer thick liquid layers. Applied Physics Letters, 2008, 92: 221101.

撰稿人：汪 力
中国科学院物理研究所

基于新型人工电磁媒质的可调谐太赫兹功能器件

Tunable Terahertz Function Devices with Metamaterials

太赫兹功能器件,如开关、调制器、可调谐的滤波器等是太赫兹电子和通信系统中的关键器件^[1]。但是,目前所得到的原型器件离我们的实际要求还相差较远,主要原因是太赫兹波在电磁波谱中介于远红外和微波之间,在远红外和微波波段中,常用的材料、设计方法和一些制备技术都不符合太赫兹波段的要求。

新型人工电磁媒质由尺寸远小于波长的人工结构单元充当“原子”构成^[2],通过设计不同的结构单元,新型人工电磁媒质理论上能够实现几乎任意的电磁参数(如负值、近零及非常大),因此,极大地拓展了天然电磁介质的特性参数范围,可用来制备多种太赫兹器件。

最近几年,人们利用这个概念制备了许多太赫兹功能器件。通过在周期性谐振单元中加入半导体结^[3],利用电压调节半导体结的电容,改变谐振单元的频率,实现对器件功能的电调谐;或者利用氧化钒薄膜的介电常数随温度变化的原理^[4],利用热效应实现对谐振频率的调谐,或者利用大功率飞秒激光照射到周期结构中的半导体部分^[5],改变谐振单元的电容,形成光调谐,但这些调谐都存在较大的问题,如对于电调谐的方法,虽然具有速度快的优点,但制备工艺复杂,对于热调谐其调谐速度慢,而光调谐的方法需要功率很大的飞秒激光,所以,现在缺少一种方便和快速的调谐。因此,寻找满足这样条件的调谐方法是太赫兹新型人工电磁媒质研究的一个难点问题。

参 考 文 献

- [1] Tonouchi M. Cutting-edge terahertz technology. *Nature Photonics*, 2007, 1: 97—105.
- [2] Lapine M, Tretyakov S. Contemporary notes on metamaterials. *IET Microw. Antennas Propag.*, 2007, 1(1): 3—11.
- [3] Chen H T, Padilla W J, Zide J M O, et al. Active terahertz metamaterial devices. *Nature Photonics*, 2006, 444: 597—600.
- [4] Driscoll T, Hyun-Tak K, Byung-Gyu C, et al. Memory metamaterials. *Science*, 2009, 325: 1518—1521.

- [5] Padilla W J, Taylor A J. Dynamical electric and magnetic metamaterial response at terahertz frequencies. *Phys. Rev. Lett.*, 2006, 96(10):107401.

撰稿人：金飏兵
南京大学电子科学与工程学院

太赫兹表面等离子体激元

Terahertz Surface Plasmon Polaritons

太赫兹辐射是 $0.1 \sim 10\text{THz}$ 的电磁辐射 ($1\text{THz} = 10^{12}\text{Hz}$, 对应波长为 0.3mm), 波长介于毫米波与远红外之间, 有重要的学术研究价值, 在国民经济和国防建设领域有着重要的应用前景。

随着纳米技术和纳米电子技术的快速发展, 表面等离子体激元学在近年来成为一个新兴的研究方向^[1]。表面等离子体激元学主要研究表面等离子激元 (surface plasmon polaritons, SPPs) 的产生、传输和探测。目前, 表面等离子体激元在光学、材料科学、生物学、纳米电子学和纳米光子学等研究领域都已经获得了一定的成功^[2,3]。国内外对表面等离子体激元的研究进行了一些有意义的理论与实验研究, 但对太赫兹波段的研究和应用仍比较缺乏。

表面等离子体激元是当电磁波入射到金属(或介质)表面, 光子和自由电子发生相互作用, 在界面处产生的表面电磁波振荡^[4], 其电场强度在金属表面上最大, 随着垂直于金属表面的距离增大而呈指数衰减。表面等离子体激元不但可以把电磁波约束在亚波长尺寸范围内, 突破衍射极限, 而且还具有超强的增强效应。金属材质、亚波长结构及金属表面介质都会对表面等离子体激元产生影响, 同时, 表面等离子体激元还具有二维空间传播的特性, 这些都易于对其进行操控。

太赫兹波段的表面等离子体激元是一个会对太赫兹科学技术领域产生深刻影响的问题。利用表面等离子体激元的亚波长约束、超强透射效应和高灵敏性等特性, 有望实现太赫兹近场成像、高灵敏度传感及太赫兹系统器件的高度集成等。对于太赫兹表面等离子体激元这一难题的研究具有重要的理论研究意义和实际应用价值, 通过设计不同结构的样品, 可以实现太赫兹波段的传输、探测、选频、滤波等功能, 从而研制各种相关的功能器件, 为太赫兹科学技术领域的研究建立重要的基础。

微电子机械系统 (micro-electro-mechanical-system, MEMS) 可以形成各种传感器、执行器的小型(微型)集成系统, 太赫兹亚波长的尺度与微机械加工工艺能够很好地匹配。太赫兹波段的表面等离子体激元功能器件与微电子机械系统相结合, 利用微机械加工工艺制作电、光、太赫兹, 以及声、机械、化学等综合功能高度集成的小型(微型)系统, 对于未来科学研究、工程应用、日常生活等方面具有重要的作用。

由于大多数金属在太赫兹频率下的复介电常数很大,可以近似为理想导体,表面等离子体激元与外界电磁波很难耦合,导致纯金属表面对表面等离子体激元的约束较差。通过在金属表面构造周期分布的小孔,小孔的尺寸和周期都小于波长,可以促进金属内外部电磁波的耦合,增强透射效应^[5,6]。根据太赫兹波与不同金属亚波长阵列相互作用产生的等离子体波特性,可以设计应用于太赫兹波段的小体积有源滤波器、调制器、波导等功能器件。金属表面结构决定滤波器的中心频率和谱宽,而且由于表面等离子体激元的超强透射效应,可以实现中心频率的功率放大。金属亚波长阵列可以对特定频率点进行放大,而对其他频率段进行滤波,通过改变金属亚波长阵列的周期和孔的形状来实现特定频段的放大作用。金属表面介质同样会影响表面等离子体激元的传播特性,当把半导体薄层设置在金属表面(或者把金属镀在半导体薄层上)时,外加电压(电场)或泵浦光可以改变半导体的载流子浓度和迁移率,从而改变透射波中心频率点的位置和幅值,通过对电压或泵浦光的调制,就可以对入射到金属表面的太赫兹波进行调制。虽然纯金属表面对表面等离子体激元的约束很差,但在金属表面沿一维方向刻蚀周期性凹槽,可以使表面等离子体激元波沿其一维方向传播,其特性同样由表面结构,即周期、凹槽形状和深度所决定。把太赫兹波耦合到金属表面,形成表面等离子体激元沿金属表面传播,表面等离子体激元在出射端耦合出来,还原成太赫兹波,这样,金属亚波长阵列作为波导可以实现太赫兹波沿特定方向的低损耗传播。然而,表面等离子体激元在太赫兹波段的应用仍不明朗,其难度在于:构成用于激发表面等离子体激元结构的材料,尤其是金属在太赫兹波段的特性并不清楚,理论分析不易。另外,表面等离子体波的耦合、波导和探测结构的设计仍有困难。

参 考 文 献

- [1] Dragoman M, Dragoman D. Plasmonics: Applications to nanoscale terahertz and optical devices. *Progress in Quantum Electronics*, 2008, 32(1): 1—41.
- [2] Sauvan C, Billaudeau C, Collin S, et al. Surface plasmon coupling on metallic film perforated by two-dimensional rectangular hole array. *Applied Physics Letters*, 2008, 92(1): 011125.
- [3] Mrejen M, Israel A, Taha H, et al. Near-field characterization of extraordinary optical transmission in sub-wavelength aperture arrays. *Optics Express*, 2007, 15(15): 9129—9138.
- [4] Pitarke J M, Silkin V M, Chulkov E V, et al. Theory of surface plasmons and surface-plasmon polaritons. *Reports on Progress in Physics*, 2007, 70(1): 1—87.
- [5] Pendry J B, Martin-Moreno L, Garcia-Vidal F J. Mimicking surface plasmons with structured surfaces. *Science*, 2004, 305: 847—848.

-
- [6] Hibbins A P, Evans B R, Sambles J R. Experimental verification of designer surface plasmons. *Science*, 2005, 308: 670—672.

撰稿人：杨冬晓
浙江大学信息与电子工程学系

高光子能量、高亮度阿秒级相干 X 射线源

High Photon Energy and Intense Attosecond X-ray Light Sources

1. 背景介绍

超强、超快激光场和原子的非线性相互作用可以产生延伸至 X 射线波段的高次谐波,经相干叠加即产生阿秒脉冲或阿秒脉冲链,为人们研究原子、分子等微观世界的运动变化提供了前所未有的精确时间尺度,开创了阿秒物理学和阿秒化学研究的新时代^[1,2]。目前,实验室中可以产生和测量宽度仅有 80as 的单个脉冲^[3]。利用单个阿秒脉冲,原子在强激光场作用下的俄歇衰减、隧道电离等电子波包的超快运动过程都首次得到了探测,获得了百阿秒量级时间分辨的动力学信息^[4]。

超强、超快激光场作用下,分子同样产生高次谐波相干辐射。利用分子产生高次谐波的过程,对分子动力学的观测也突破了飞秒时限,得到了前所未有的原子级空间和时间分辨率。利用从取向氮分子的高次谐波角度分布结合层析成像的原理重构得到了最高占据分子轨道(HOMO)的空间成像^[5]。由于电子波包经强激光场加速在不同的时间(一个光周期之内)回转复合产生不同阶次的高次谐波,利用谐波强度的对比已经获得了氢分子以 100as 时间分辨的原子核振动的超快信息^[6]。

除了用于探索物质在原子分子级的微观和超快物理过程,高次谐波还是一种全新的具有高度相干性的超快 X 射线源,在实验室中即可实现,因而易于操作和使用,利用其高度的空间相干性和低发散角等优异的光学特性,可以进行空间分辨率高达几十纳米的静态和动态微结构衍射成像研究^[7]。当产生的高次谐波波长达到 2.3~4.5nm(约 540~275eV)范围时,就到了水分子不发生吸收的“水窗”波段,可以对生物体进行活体细胞的全息成像,在生命科学研究中有重要的应用^[8]。

因此,超强、超短激光场作用下,阿秒级相干 X 射线产生正在成为一种全新的前沿科学技术,在原子、分子、生物和材料体系的超微观超快物理学研究、检测加工上具有巨大的优势和应用前景。高次谐波相干辐射源已成功应用于微观材料的高分辨率衍射成像。

但是,高次谐波主要产生于波长较长的软 X 射线波段(小于 100eV),而且所产生的 X 射线辐射的产率较低(单脉冲能量最高为微焦耳级),而在硬 X 射线

区域的产率更低,甚至不到纳焦耳水平,限制了这一高技术领域的广泛应用和推广,因此,台式化 X 射线激光器的研究和应用尚处于刚起步阶段,高光子能量、高亮度和高光学性能的阿秒级相干 X 射线辐射的产生及其和物质相互作用研究亟待发展。

2. 问题描述

如何实现高光子能量、高亮度和高光学性能的阿秒级相干 X 射线源。如何从高次谐波产率增强、相位匹配和偏振态控制三个方向来研究通过高次谐波产生相干 X 射线的物理机制和规律,提出发展获得高能量、高亮度和偏振态可控的应用级相干 X 射线辐射的新思路。

3. 必要说明

(1) 为了获得高光子能量的高次谐波,利用中红外波段的强激光场作为驱动光场。高次谐波光谱的高能端能量同驱动光的波长的平方成正比,但其产率又和波长的 5.5 次方成反比。目前,利用红外波段驱动光场产生的高次谐波已经达到了水窗波段,但脉冲能量仅达到可供检测的水平^[9]。

(2) 为了获得高亮度的阿秒级相干 X 射线辐射,高次谐波光谱必须同相位地相干叠加(相位匹配)。研究中,通过平衡激光场、原子和等离子体造成的色散可以实现完全的相位匹配,但在较高的光子能量范围($>130\text{eV}$),场强造成的失配量大,只能通过空间调制的准相位匹配方法对谐波产率进行优化,目前,实验上获得的高次谐波产率仍然较低(通常转换效率可达到 10^{-6}),限制了其更广泛的应用。

(3) 对高次谐波相干辐射的偏振态的研究相当有限,有人通过采用双色激光场组合方案,预测可以获得圆偏振态的高次谐波辐射,此外,通过强激光场和取向 CO_2 分子的相互作用,椭圆偏振态的高次谐波也被实验中发现,但未有物理解释^[10]。

4. 相关扩展

当前,广泛用于生物分子衍射成像研究的 X 射线辐射主要来自于大型的科学设施——同步辐射装置或 X 射线自由电子激光器,因而难以得到广泛应用。台式 X 射线激光器的概念已被美国科学家提出,并在实验上实现了较高空间分辨率(70nm)的衍射成像,由于具有高度相干性,它的应用将可以把医用的 X 射线成像的分辨率提高 3 个数量级。但是,如上所述,台式 X 射线激光器的发展和应用受限于超强超快激光场中高次谐波产生的光子能量和产率。

参 考 文 献

- [1] Krausz F, Ivanov M. Attosecond physics. *Reviews of Modern Physics*, 2009, 81:163.
- [2] Brabec T, Krausz F. Intense few-cycle laser fields; *Frontiers of nonlinear optics*. *Reviews of Modern Physics*, 2000, 72:547.
- [3] Goulielmakis E, et al. Single-cycle nonlinear optics. *Science*, 2008, 320:1614.
- [4] Uiberacker M, et al. Attosecond real-time observation of electron tunneling in atoms. *Nature*, 2007, 446:627.
- [5] Itatani J, et al. Tomographic imaging of molecular orbitals. *Nature*, 2004, 432:867.
- [6] Baker S, et al. Probing proton dynamics in molecules on an attosecond time scale. *Science*, 2006, 312:424.
- [7] Sandberg R L, et al. Lensless diffractive imaging using tabletop coherent high-harmonic soft-X-ray beams. *Phys. Rev. Lett.*, 2007, 99:098103.
- [8] Gibson E A, et al. Coherent soft X-ray generation in the water window with quasi-phase matching. *Science*, 2003, 302:95.
- [9] Tate J, et al. Scaling of wave-packet dynamics in an intense midinfrared field. *Phys. Rev. Lett.*, 2007, 98:013901.
- [10] Zhou X, et al. Elliptically polarized high-order harmonic emission from molecules in linearly polarized laser field. *Phys. Rev. Lett.*, 2009, 102:073902.

撰稿人：李儒新 刘 鹏

中国科学院上海光学精密机械研究所

X 射线自由电子激光

X-ray Free Electron Laser

1. 背景介绍

1895 年,德国科学家伦琴发现了 X 射线,1901 年,他因为这项伟大的发现成为世界上第一个荣获诺贝尔奖物理奖的人。从那时以来,由于 X 射线无可比拟的广泛用途,人们对先进 X 射线光源的追求从来没有停止过。到 21 世纪初,品质最好的 X 射线源是自 20 世纪 50 年代发展起来的基于高能电子束流的同步辐射光源,但是,同步辐射发出的 X 射线仍有弱点。首先,它不是相干光源,其次,它的脉冲长度还不够短(一般在 $1\sim 10\text{mm}$ 之间)等。激光是 20 世纪一项伟大的发明,它具有极好的相干性,脉冲长度可以容易地做到微米($1\mu\text{m}$ 相当于 3fs)量级,甚至更短,不过,普通激光的波长范围受到了工作原理和工作介质的限制,很难达到 X 射线的范围。人们一直在想,要是有一种光源能够兼备激光和同步辐射的优点就好了^[1]。

1971 年,美国斯坦福大学的 Madey 提出了用电子束流作为介质的激光。所谓自由电子激光(free electron laser, FEL)^[2],即期望利用电子束流的灵活性产生高品质的激光,并很快于 1976 年在红外波段验证了这个原理。很快,各国纷纷开始建造自由电子激光装置,竞相朝着更短波长的激光进发,其中,80~90 年代逐渐形成了高增益。但是,直到 2005 年,才由德国汉堡的自由电子激光装置(FLASH)将波长推进到了软 X 射线区域,最短可以达到 6.5nm ,这其中的问题首先在于自由电子激光对于电子束流的品质有着很高的要求,如电子束流必须具有极小的发射度和能散度,同时又要要在一个很短的束团内集聚足够的电子数量等。

2. 问题描述

划时代的突破发生在 2009 年 4 月,美国斯坦福直线加速器中心(Stanford Linear Accelerator Center, SLAC)耗费 4 亿美元建造的直线相干光源(linear coherent light source, LCLS)^[3]顺利地产生了波长为 $1.5\text{\AA}$ (当于 0.15nm)的硬 X 射线激光,峰值功率在 10GW 以上,峰值亮度比同步辐射光源高十个数量级(如图 1 所示)。LCLS 和 FLASH 产生的自由电子激光都是基于叫做自放大自发辐射(self-amplified spontaneous radiation, SASE)的工作原理,它利用高能电子束

团通过精密的扭摆磁铁(自由电子激光用的一般称为 undulator, 即波荡器)进行放大, 在放大的过程中, 由于束流-磁场-辐射数者之间的相互作用, 电子逐渐形成与辐射波长相当的微小群聚, 然后进入所谓的指数增长区, 增益可达 100 万倍。但是, 这种工作原理有一个缺陷, 由于是由电子束团自身的噪声开始放大, 产生的激光具有良好的横向相干性, 但并不具备时间相干性。另一方面, LCLS 的重复频率还不够高, 为 120Hz, 与最先进的同步辐射光源的上百兆赫兹相比还有较大的差距, 平均亮度的优势就远没有峰值亮度那么明显了。因此, 现在的难题就归结为如何才能产生全相干的, 既有极高峰值亮度又有很强平均功率的 X 射线自由电子激光。




图1 世界第一台硬 X 射线激光——美国斯坦福大学的 LCLS

3. 必要说明

从原理上说, 产生全相干的自由电子激光是可能的, 最直接的办法就是先用普通激光(具有全相干性)作为种子, 与电子束流相互作用, 利用激光自身的电磁场将电子束流调制成具有激光波长特征的细微结构, 然后将其送入波荡器进行放大。问题是: 普通激光的波长一般较长, 为了获得比种子更短的波长, 人们提出了放大种子激光调制的电子束团中的高次谐波成分, 标准的工作原理, 如高增益谐波产生 (high gain harmonic generation, HGHG)^[4] 可以一次产生 5 倍频左右的高亮度激光, 最新提出的回声原理 (echo-enabled harmonic generation, EEHG)^[5] 有可能一次产生几十倍频的高亮度激光。如果需要, 可以利用这一级的激光输出(不放大到饱和)作为下一级的种子, 调制电子束团然后放大, 直到产生很短波长的 X 射线激光。这种工作原理的问题

在于：从普通激光擅长的波长(几百纳米)到硬 X 射线(如 0.1nm)有几千倍的差距，由于信噪比的放大大致正比于倍频数的平方，作为原始种子的激光品质再好，经过如此倍频后信噪比的水平也已经比较差了。为了解决这个难题，科学家们积极寻求较短波长的激光作为种子，其中，比较有希望的解决方案是采用高次谐波产生(high harmonic generation, HHG)方法，即使用较强的激光与气体相互作用产生较短波长的激光，如几纳米到几十纳米，用这样的种子信噪比就可以改进 2~4 个数量级，最终输出的硬 X 射线自由电子激光可以具有相当好的相干特性。目前，在短波长上，HHG 主要的问题是转换效率还很低(百万分之一量级)。

提高自由电子激光的平均功率主要是技术和费用的限制，常温结构的加速器(直线加速器)由于壁电阻较大，功率消耗高，重复频率较低，采用超导加速结构则可以极大地提高重复频率。近年来，迅速发展的能量回收直线加速器(energy recovery linac, ERL)技术更是其中的佼佼者，具有电子束平均功率高和节能环保的特点，其主要原理为：将使用过的电子束以减速相位重新注入主加速器，把电子束的动能转换为微波场的能量，用于加速来自注入器的后续电子束团，电子束被减速后再进入垃圾靶。由于高能电子束的能量被再次利用，大大降低了对微波源的功率要求，可以在能承受的输入功率下产生高平均功率的电子束；同时，进入垃圾靶的电子束能量大大降低，有效减少了辐射水平。

综上所述，实现 X 射线波段的全相干、高功率自由电子激光仍然是一个困难的问题，需要在分别加速器技术和激光技术方面有所突破并有机地融合为一个整体，才有可能建成新一代的 X 射线激光光源。

4. 相关扩展

(1) 高亮度、高能量电子加速器技术，包括超低发射度、高重复频率电子枪，高梯度、高重复频率超导加速结构，超小周期超导波荡器技术等。

(2) 新自由电子激光工作原理，包括基于 SASE 和 HGHG 等的各种改进型原理，以及新自由电子激光原理。

(3) 用于自由电子激光种子的短波长阿秒激光技术。

(4) 基于谐振腔原理的 X 射线自由电子激光。

(5) 基于 ERL 技术的先进同步辐射光源、高亮度粒子对撞机和大功率激光武器。

参 考 文 献

- [1] Scientific needs for future X-ray sources in the U.S. SLAC-R-910, LBNL-1090E, 2008.

- [2] Madey J M J . Stimulated emission of bremsstrahlung in a periodic magnetic field . J . Appl . Phys . , 1971 , 42 : 1906 .
- [3] <http://ssrl.slac.stanford.edu/lcls/cdr/> .
- [4] Yu L H . High-gain harmonic-generation free-electron laser . Science , 2000 , 289 : 932 .
- [5] Stupakov G . Using the beam-echo effect for generation of short-wavelength radiation . Phys . Rev . Lett . , 2009 , 102 : 074801 .

撰稿人：王 东

中国科学院上海应用物理研究所

X 射线自由电子激光与物质作用机理

Mechanisms of Interaction between X-ray Free Electron Laser and Materials

光与物质相互作用研究是人类探索自然界的重要手段和方法之一。利用光子探针研究物质的基本单元——原子分子的结构和功能,促进了人们对于微观世界基本规律的认识不断深入。X 射线是原子尺度空间分辨条件下研究物质结构的理想探针,1953 年, Watson 和 Crick 用 X 射线衍射方法成功测量了 DNA 双螺旋结构,成为 20 世纪最伟大的科学发现之一。同步辐射光源的出现进一步为人类提供了更高亮度的 X 射线源,为各学科的发展发挥了重要作用。20 世纪 60 年代,激光技术的出现和发展开启了超强激光场与原子分子相互作用机制的研究,并揭示了许多新奇的现象。强场电离机制的研究促进了超短脉冲激光的出现,使得人们可以在更快时间尺度上(飞秒甚至阿秒)研究光与原子、分子相互作用的动力学过程。

随着研究的不断深入,人类对于微观世界的认识正经历着从结构研究向功能研究变革之中。人们希望在超快时间分辨条件下(飞秒量级)对物质结构的解析达到原子尺度的空间分辨能力,如实现单个生物大分子的结构及动态功能研究。然而,目前高次谐波方法产生的激光波长虽然达到了极紫外/软 X 射线波段,但还不能实现原子尺度的空间分辨。虽然同步辐射光源可以提供波长亚纳米量级的 X 射线研究分子静态结构信息,但同步辐射光源的 X 射线脉冲时间宽度较大(约 30ps),不能用来探测光与物质作用中的超快过程。由此可见,传统的光学激光和同步辐射光源已经不能满足人们同时在原子尺度空间分辨及飞秒量级时间分辨条件下探索微观世界的需求。X 射线自由电子激光(X-ray free electron laser, XFEL)拥有了同步辐射光源和激光的各自优点,为在原子尺度空间分辨及飞秒时间分辨条件下的前沿科学研究提供了前所未有的新型光源。与第三代同步辐射光源相比,基于电子直线加速器的高增益 XFEL 峰值亮度要高约 10 个数量级;辐射脉冲宽度约几十飞秒(将来可能达到 1fs);波长从软 X 射线到硬 X 射线连续可调;以及辐射完全相干等优点^[1,2]。正是由于 XFEL 具有高峰值亮度、超短脉冲宽度、相干性等特点,其与物质的基本构成单元——原子分子的相互作用将会揭示出许多新的物理现象,特别是在强场条件下的 X 射线非线性光学、超快 X 射线分子电离解离动力学等机理研究将是未来十几年里研究的热点之一。

XFEL 经过聚焦可以在实验室条件下创造出超强激光场(如 XFEL 单脉冲能量 $100\mu\text{J}$, 脉宽 30fs , 聚焦到 $5\mu\text{m}$, 光强达到 $1.7\times 10^{16}\text{ W/cm}^2$), 在自然界中, 这些极端物理条件只存在于恒星内部或核爆中心区。原子分子与此超强 X 射线激光场的作用产生了全新的研究领域——X 射线非线性光学, 此研究对于人类探索自然界具有重要意义^[3]。与传统激光作用于原子分子机制不同, 超短波长的 XFEL 电离原子内壳层电子的截面将远大于价壳层电离, 所以, XFEL 将主要从原子内壳层电离电子^[4]。与此同时, 在强激光电场的作用下, X 射线电离原子可以实现内壳层阈上电离(above-threshold ionization, ATI)现象, 即多个 X 射线光子单电离原子内壳层电子^[5]。由于 XFEL 还具有超快脉冲特征, 可以实现多个 X 射线光子电离原子内壳层多个电子, 从而产生物质奇异态——“中空”原子^[2,6]。X 射线非线性多光子电离原子内壳层电子的过程总是伴随着俄歇和 X 射线荧光退激发竞争过程。与通常原子的俄歇过程不同, “中空”原子退激发可能会产生特殊的“超伴线”俄歇电子, 其能量将高于内壳层单空穴原子退激发产生的俄歇电子能量; 并且内壳层具有多个空位的“中空”原子会通过多次级联俄歇退激发过程而产生极高电荷态母体离子。此高电荷态离子处于极高激发态, 其退激发过程中的能量储备和转换方式还是一个未知科学领域。开展高电荷态母体离子产生及其退激发机制的研究, 对于探索未来更先进的 X 射线激光产生机制具有重要的意义。与其他 X 光源相比, XFEL 的另一个重要特性是它的相干性。众所周知, 极紫外/软 X 射线波段高次谐波激光就是利用相干的红外激光与气态原子相互作用而产生的。设想利用相干的 X 射线光源替代红外激光并与原子、分子相互作用, 将会有有什么新奇的光学现象发生? 由于强场红外激光可以扭曲原子价壳层电子的运动, 从而导致场电离原子现象的发生。相干的 X 射线激光具有比红外激光高约 1000 倍的振荡频率, 因此, XFEL 的相干性在原子强场电离机制的作用将是一个有待回答的问题。

分子的光电离解离涉及了电子波包在分子势能面上的动态演化过程, 化学家们一直期待在原子尺度空间分辨条件下对分子键的形成、断裂和转换过程实现飞秒时间分辨成像研究。Zewail 教授成功利用了飞秒光学激光研究分子动力学过程, 开创了飞秒化学研究新领域并于 1999 年获得诺贝尔化学奖。虽然光学激光可以在飞秒时间分辨条件下研究超快的分子动力学, 但受激光波长的限制, 只能研究原子价壳层电子而达不到原子尺度空间分辨能力。XFEL 具有超短波长(10^{-10} m)和飞秒量级的脉冲宽度, 适合于分子光电离解离动态过程的快速成像研究。利用飞秒红外激光(或 X 射线激光)作为泵浦光激发(或电离)分子, X 射线激光作为探测光在高空间分辨条件下测量分子光电离后的解离动力学过程。通过精确调整泵浦光和探测光的延迟时间, 人们可以实现时间分辨条件下分子键的断裂、转换过程进行动态成像分析。分子动力学的探测可以使用时间分辨

X 射线衍射成像或时间分辨光电子衍射方法直接测量原子之间的距离,从而获得与时间相关的化学键信息。XFEL 与分子相互作用会产生光电子、俄歇电子及母体离子碎裂后产生的碎片离子,通过符合测量光电子/俄歇电子和碎片离子,人们可以获得全部的光电子和碎片离子三维空间动量分布信息,即分子反应动力学的全部动态信息^[7]。这些研究为将来从飞秒时间尺度及原子空间尺度揭示复杂蛋白质大分子或病毒结构提供了可能。

利用 XFEL 单光子脉冲实现生物蛋白质大分子的三维结构重建是未来 XFEL 在生命科学领域的重要应用之一,然而,极高亮度的单个 XFEL 光脉冲可能会造成生物大分子的损伤和破坏,使其结构测量难以实现^[8]。到目前为止,人们还不清楚如此高强度的 X 射线与物质相互作用的机制是什么? X 射线非线性光电离和场电离在其中所占的角色是什么? XFEL 的相干性是否会改变损伤的特征? 开展 XFEL 与原子、分子的作用原理研究为寻找这些问题的答案提供了一把钥匙。有理由相信, XFEL 将会对自然科学的发展带来深远的影响,将引领人们进入全新的微观世界研究领域。

参 考 文 献

- [1] Ackermann W, Asova G, Ayvazyan V, et al. Operation of a free-electron laser from the extreme ultraviolet to the water window. *Nature Photonics*, 2007, 1(6):336—342.
- [2] Arthur J, et al. Linac coherent light source (LCLS). Menlo Park; Stanford Linear Accelerator Center, 2002.
- [3] Sorokin A A, Bobashev S V, Feigl T, et al. Photoelectric effect at ultrahigh intensities. *Phys. Rev. Lett.*, 2007, 99(21):1—4.
- [4] Meyer M, Cubaynes D, Richardson V, et al. Two-photon excitation and relaxation of the 3d-4d resonance in atomic Kr. *Phys. Rev. Lett.*, 2010, 104(21):1—4.
- [5] Richardson V, Costello J T, Cubaynes D. Two-photon inner-shell ionization in the extreme ultraviolet. *Phys. Rev. Lett.*, 2010, 105(1):1—4.
- [6] Young L, Kanter E P, Krassig B, et al. Femtosecond electronic response of atoms to ultra-intense X-rays. *Nature*, 2010, 466(7302):56—61.
- [7] Jiang Y H, Rudenko A, Pérez-Torres J F, et al. Investigating two-photon double ionization of D₂ by XUV-Pump XUV-Probe experiments. *Phys. Rev. A*, 2010, 81(5):1—4.
- [8] Barty A, Boutet S, Bogan M J, et al. Ultrafast single-shot diffraction imaging of nanoscale dynamics. *Nature Photonics*, 2008, 2(7):415—419.

撰稿人: 李文斌 王占山

同济大学物理系

激光荧光冷却

Laser Induced Luminescence Cooling

1. 背景介绍

激光与物质相互作用，多数情况下会使物质温度升高。例如，激光焊接与切割、激光眼科治疗等，均利用了聚焦激光使物体迅速发热的原理。然而，在特定的情况下，激光也能够使物体的温度降低，就是所谓的激光制冷。激光制冷与传统的制冷方式截然不同。传统的制冷方式通过热传导将热量从物质内部传导到表面，再通过热交换等方式将热量带走；而激光制冷则通过激光与物质的相互作用，使激光吸收物质内部的热声子，转变为能量更高的荧光光子从物质内部射出，从而使物质的温度直接降低。这种制冷方式的制冷媒介为激光，制冷位置为激光通过的位置，是一种直接制冷方式，而不是其他制冷方式采用的传导方式，因而不会在物质内部产生温度梯度，这对很多应用至关重要。同时，由于制冷媒介为激光，因而可以实现远距离非接触式制冷。这些不同于传统制冷方式的特点使得激光制冷成为近年来研究的热点。

2. 激光荧光制冷原理

激光荧光冷却的基本出发点如下。光入射到透明介质中会发生三种散射过程：Rayleigh 散射、Stokes 散射和反 Stokes 散射。Rayleigh 散射由于出射与入射频率相等，因此，既不吸热也不制热；Stokes 散射由于出射光子能量小于入射光子，因此，产生一个热声子，起到制热效果；反 Stokes 散射出射光子能量大于入射光子，吸收一个热声子，起到制冷效果，因而激光荧光冷却也称为反 Stokes 荧光冷却。

以掺 Yb 离子的玻璃为例，反 Stokes 荧光制冷循环过程如图 1 所示。泵浦光(入射激光)将 Yb 离子从基态能级顶部激发到激发态能级的底部，破坏了能级布居，于是，离子吸收声子并通过热弛豫重新达到热平衡；然后离子发生弛豫跃迁，产生反 Stokes 荧光光子，回到基态较低的能级，再吸收声子达到热平衡。在一个循环过程中，通过吸收两个热声子达到热平衡，从而使离子的热振动降低，达到制冷的效果。




图1 反 Stokes 荧光制冷循环过程

3. 激光荧光制冷研究历史及国内外研究现状

利用反 Stokes 效应实现激光制冷的设想早在 1929 年就由 Pringsheim 提出, 但直到 1946 年才由 Landau 等从理论上证明了其可行性。实验上, 直到 1981 年才由 Djeu 等以 CO_2 激光对 CO_2 及 CO_2 和 Xe 的混合气体首次实现了反 Stokes 荧光制冷^[1]。以固体材料为荧光媒介的实验在 1995 年由美国 Los Alamos 国家实验室的 Epstein 等首次成功地在掺 Yb 离子的 ZBLAN 玻璃上获得实际可测量的激光制冷效应, 实现了 0.3K 的温降, 其制冷效率达 2%, 是以往观察到的气态激光制冷效率的 104 倍^[2]。

从第一次在固体材料中实现反 Stokes 荧光制冷后, 科学家们相继在掺不同稀土离子的多种材料中均实现了反 Stokes 荧光制冷, 包括在 $\text{Tm}:\text{YBF}$ 晶体中实现 3.2K 的温降^[3], 以 1.8W 波长为 1030nm 的激光照射 Yb:YAG 获得 8.9K 的温降, 以及在 $\text{Er}:\text{KPB}_2\text{Cl}_5$ 中实现 0.7K 的温降等。其中, 1999 年低温物理学家 Finkeppen 利用掺杂蓝宝石激光器激发半导体量子阱材料的空穴激子, 实现能量 10eV 的空穴激子反 Stokes 荧光发射, 使样品温度由 77K 下降到 7K, 同时给出不同温度下制冷效率与制冷温度的关系。这是目前反 Stokes 荧光制冷获得的最低温度。

在国内, 对荧光制冷的研究仅仅处于起步阶段, 多为理论研究, 尚未有实验报道^[4]。

4. 影响激光反 Stokes 荧光制冷效果的因素

从反 Stokes 荧光制冷的原理看, 上能级与下能级的间隙越小, 则制冷效率就越高。但实际上, 当上能级与下能级的间隙变小时, 无辐射跃迁的概率就大大增加, 而无辐射跃迁的结果是释放热声子而使温度升高。因此, 在能级间隙并不是越小越好。

此外, 要实现上能级或者下能级内 (Stark) 布居数的快速平衡, 能级分裂的间隙应当越小越好。要实现反 Stokes 荧光制冷, Stark 能级的间隙应当为 K 级。

除能级的因素外,介质内部的荧光再吸收也会降低制冷效率,反 Stokes 荧光遇到反射界面返回介质内部,以及外界环境的热辐射对荧光介质的影响等都会对制冷效果产生影响。

5. 激光荧光制冷的相关扩展

目前,制约高功率固体激光器发展的主要瓶颈就是制冷问题,传统的制冷方式会造成激光介质内部温度梯度分布,从而产生应力双折射降低激光光束质量,严重时会造成激光介质炸裂。而激光荧光制冷是一种全新的直接制冷方式,不存在由于热传导而导致的温度梯度。根据反 Stokes 荧光制冷的原理,科学家提出了无内热激光器的概念。使激光增益介质内产生的热量和激光反 Stokes 荧光的制冷量达到平衡,从而有望突破制约固体激光器发展的瓶颈^[5]。

由于激光荧光制冷可以实现远距离无接触制冷,因此,将其应用于空间领域可以对伴星或小卫星等资源有限的空间飞行器的关键部件实施远距离非接触式制冷。在空间领域,对于关键部件多采用斯特林制冷机进行冷却,再将热量通过辐冷板辐射到冷空间中。为达到足够的制冷效果,辐冷板要有足够的表面积,通常都比较大。而激光制冷由于通过反 Stokes 荧光将热量带走,因此,其体积可以很小;并且与斯特林制冷机相比,激光制冷具有无运动部件、低电磁辐射、无振动、可靠性高等优点,使其在空间领域具有非常诱人的应用前景。

参 考 文 献

- [1] Djeu N, Whitney W T. Laser cooling by spontaneous anti-Stokes scattering. *Phys. Rev. Lett.*, 1981, 46: 236.
- [2] Epstein R I, Buchwald M I, Edwards B C, et al. Observation of laser-induced fluorescent cooling of a solid. *Nature*, 1995, 377(6549): 500—503.
- [3] Patterson W, et al. Anti-Stokes luminescence cooling of Tm^{3+} doped BaY_2F_8 . *Optics Express*, 2008, 16: 1704—1710.
- [4] 孙海生, 印建平. 固体材料反斯托克斯荧光制冷的理论研究及其最新进展. *物理学进展*, 2007, 26: 43—67.
- [5] Bowman S R. Laser without internal heat generation. *IEEE J. Quantum Elec.*, 1999, 35: 115—122.

撰稿人: 孟俊清

中国科学院上海光学精密机械研究所

高功率中红外超连续谱激光光源

High-power Mid-infrared Supercontinuum Source

1. 背景介绍

超连续谱(supercontinuum, SC)是高强度激光通过非线性材料时,经过一系列非线性效应与线性色散的共同作用,使得出射光中产生许多新的频率成分,从而使频谱得到极大展宽的一种现象^[1]。这种光谱展宽效应通常是伴随着脉冲激光在强非线性介质(如光纤)中传输时而产生的,新近发展的光子晶体光纤(photonic crystal fibers, PCF)因其具有较高的非线性和可控的群速度色散特性,比常规光纤更容易产生超连续谱,是实现超连续谱输出的理想介质。超连续谱光源一方面像白炽灯一样,具有很宽的发射光谱,时间相干性低;另一方面,又同激光一样,具有极高的亮度,空间相干性高,是一种真正具有“白炽灯的光谱宽度、激光的亮度”的特殊光源,又被称为“激光彩虹(laser rainbow)”。作为一种新型光源,在超高速光纤通信、光学相干成像、材料光谱学、环境测量、激光光谱学、生物医学及军事科研等均有着重要的应用价值。

超连续谱的研究最早可追溯到20世纪70年代。1970年,Alfano和Shapiro利用倍频锁模钹玻璃皮秒激光脉冲泵浦BK7光学玻璃,首次获得了400~700nm的超连续谱谱,最初的研究主要是集中在对超连续谱形成机理的解释上^[1]。由于光纤波导的长度可以灵活控制,且需泵浦光功率低,20世纪70年代中期,随着低损耗单模光纤的研发成功,使得利用光纤中的非线性效应产生超连续谱成为可能。1978年,首次观察到了光纤中的超连续谱现象,吸引了人们的注意。1989年,Islam等首次在光纤中获得宽带的孤子脉冲^[2],并对光纤负色散区超连续谱的形成进行了较为系统的研究,随后,随着人们对超连续谱理论研究的深入和光纤制备技术的提高,在色散位移光纤、色散平坦光纤和锥形光纤中均获得了超连续谱输出。

光子晶体光纤是基于光子晶体技术发展起来的下一代传输光纤。光子晶体光纤的横截面由非常微小的孔阵列组成,这种特殊的结构使光子晶体光纤具有了不同于常规光纤的一系列优异特性,给光波导技术带来了革命性变革^[3]。光子晶体光纤的“无限”单模特性、可控的色散特性和极强的非线性效应,被广泛应用于产生超连续谱的研究。2000年,Ranka等报道了利用790nm超短脉冲

注入 75cm 长的光子晶体光纤后,首次观察到 400~1600nm 的超连续谱的实验结果^[4]。随后,以飞秒、皮秒、纳秒和连续激光为泵浦源,在光子晶体光纤中均产生了很宽的超连续谱^[4~7]。

另一方面,对于高效稳定超连续谱的泵浦源,随着稀土掺杂光纤激光器及光纤放大器的发展,以超快光纤激光器代替体积庞大的超快钛宝石激光器或固体激光器,通过光纤熔接来连接泵浦光和光子晶体光纤,实现超连续谱光源的全光纤化结构,可以使系统具有更小的体积和更高的稳定性,吸引了科研和产业界的极大兴趣。目前,采用高功率超快光纤激光器和非线性光子晶体光纤结合技术的超连续谱光纤光源已有产品,并可以覆盖从低于 400nm(有报道可以到 380nm)到接近 2400nm 的广泛波段,其功率谱密度(单位波长间隔的激光功率)达到几毫瓦每纳米,并具有衍射极限输出。

2. 问题描述

超连续谱产生的关键是合适的泵浦光源和高非线性光纤,目前以超短脉冲激光为泵浦源的光谱在 0.4~2.4 μm 的超连续谱光源已有报道,且已可商品化。然而对于脉冲激光泵浦的超连续谱光源,由于注入泵浦光的平均功率受到光纤端面破坏、激光自聚焦破坏等的限制,使得超连续谱的输出平均功率难以提高。

最近,英国帝国大学采用连续波光纤激光器作为泵浦源,以具有双零色散波长的光子晶体光纤作为非线性介质,实现了 29W 的超连续谱激光输出,波长范围为 1.07~1.67 μm ^[8]。这种高功率连续波激光泵浦的超连续谱光源在高功率输出方面具有非常大的优势。所设计的这种具有“波长裁剪”功能的双零色散波长光子晶体光纤,可将超连续谱的输出波长范围进行有效控制,从而使得在所关心波段的高功率超连续谱光源成为可能。

在深入研究连续激光泵浦产生超连续谱物理机理的基础上,以 2 μm 波段的掺铥光纤激光器作为泵浦源,以新型的具有双零色散波长中红外光子晶体光纤为非线性介质,将是产生全光纤化、高光束质量、高功率中红外超连续谱的一种有效途径。

3. 必要说明

光子晶体光纤超连续谱的产生机理非常复杂,包括如自相位调制、交叉相位调制、受激拉曼散射及四波混频等。超连续谱的产生除与泵浦波长有关外,还与泵浦脉冲及光纤参数具有密切的关系,泵浦光脉冲的峰值功率、波长及脉宽对超连续谱的产生有重要的影响。只有泵浦脉冲功率大于超连续谱的阈值泵浦功率,才能观察到显著的光谱展宽现象。

光子晶体光纤中超连续谱的产生涉及一系列极其复杂的非线性光学过程,即使在目前可见光到 $2\mu\text{m}$ 的常规超连续谱波段,理论解释也不是很完美。对于高功率的中红外超连续谱的内在机理更是处于探索阶段,需要从基本物理机理、新型泵浦光源、高损伤阈值中红外材料及光纤制备等多方面开展创新性的研究工作。

4. 相关扩展

在高功率超连续谱方面,连续波光纤激光器泵浦新型光子晶体光纤产生超连续谱的方案在高功率输出方面大有潜力,且可望实现结构的全光纤化。基于掺铥光纤激光和中红外光子晶体光纤的 $2\sim 5\mu\text{m}$ 超宽带中红外高功率超连续光源是非常值得关注的研究方向^[9]。国际上,以 $1.5\mu\text{m}$ 光纤激光为泵浦源,以单模石英光纤和 ZBLAN 玻璃光纤为非线性介质,已有 10.5W 的超连续谱($0.8\sim 4\mu\text{m}$)的结果报道。

在该领域,有一系列重要的创新工作亟须开展,包括光子晶体光纤对连续波激光的光谱展宽和频率变换的物理机理,新型双零色散波长光子晶体光纤的设计理论,中红外(如 ZBLAN 或硫化物)光纤材料及光子晶体光纤制备中的基本物理问题,提高 ZBLAN 氟化物或硫化物光纤的强度和激光损伤阈值的方法和途径,中红外超连续谱产生中的模式变化特性,中红外玻璃光子晶体光纤的科学制备、石英光纤和玻璃光纤的低损耗熔接等。

参 考 文 献

- [1] Alfano R R. The Supercontinuum Laser Source. New York: Springer, 1989.
- [2] Islam M N, Sucha G, Barjoseph I, et al. Broad bandwidths from frequency-shift solitons in fibers. Opt. Lett., 1989, (14): 370—372.
- [3] Dudley J M, Taylor J R. Ten years of nonlinear optics in photonic crystal fibre. Nature Photonics, 2009, 3: 85.
- [4] Ranka J K, et al. Visible continuum generation in air-silica microstructure optical fibers with anomalous dispersion at 800nm . Opt. Lett., 2000, 25(1): 25.
- [5] Dudley J M, et al. Supercontinuum generation in air-silica microstructure fibers with nanosecond and femtosecond pulse pumping. J. Opt. Soc. Am. B, 2002, 19(4): 765.
- [6] Wadsworth W J, et al. Supercontinuum generation in photonic crystal fibers and optical fiber tapers: A novel light source. J. Opt. Soc. Am. B, 2002, 19(9): 2148.
- [7] Cumberland B A, et al. Toward visible cw-pumped supercontinuum. Opt. Lett., 2008, 33(18): 2122.
- [8] Cumberland B A, Travers J C, Popov S V, et al. 29W high power CW supercontinuum

source .Optics Express ,2008 ,16 ;5954 .

- [9] Price J H V ,et al .Mid-IR supercontinuum generation from nonsilica microstructured optical fibers .IEEE Journal of Selected Topics in Quantum Electronics ,2007 ,13(3) :738 .

撰稿人：周 军 陈卫标
中国科学院上海光学精密机械研究所

用光纤激光直接产生高功率可见光输出

High Power Visible Light Output Directly with Fiber Laser Technique

在人类历史上,新光源的出现曾经有过三次给人类文明带来革命性变革。第一次是电光源的出现,使人类战胜了黑暗,能够在黑夜中和白天一样活动;第二次是X光光源的出现,它把我们的视野扩展到肉眼看不到的物体内部和微观领域,在医疗、工业中得到广泛的应用;第三次是激光光源的出现,它具有波长单一性、方向准直性、相位相干性的特点,激光的高亮度使它在工业、通信、国防、医疗、科学研究和艺术等广泛的领域发挥十分重要的作用。目前,激光已进入千家万户的日常生活中,我们在家中听的是激光唱片的优美乐曲,看的是激光碟片的影像资料,在商场购物时,出纳员用的是激光条形码扫描器^[1]。从1960年第一台红宝石激光器出现以来^[2],激光已走过五十多个年头。高功率激光已成为工业加工、彩色显示等方面的重要工具。

第一台固体激光器是用一根细小的红宝石棒,用环绕在它周围的螺旋形氙灯做泵浦源,由于棒状材料在高功率情况下会出现无法回避的热透镜效应、热应变和热致双折射现象,产生的激光光束质量(光束的发散角)随功率的增大而急剧变差。为此,科学家们不断地寻求解决激光棒热量不易散发的问题。从几何学的角度分析,一个体积相同的介质,它的散热特性和表面积大小有关,表面积愈大,散热特性愈好。为此,相应出现了薄片激光器和光纤激光器。其中,光纤的表面积比圆棒大几个数量级,具有很好的散热特性。

光纤也是20世纪的一大发明。光在光纤中的全反射传输现象很早已经发现,早期的光纤由于损耗较大(约1000dB/km),除了医疗器件中成像元件外,很难在长距离下使用,20世纪70年代,光纤的损耗下降到0.1dB/km。这一进展带动了光纤通信革命性的变化。高锟因在有关光在纤维中的传输以用于光学通信方面取得了突破性进展而分享了2009年度诺贝尔物理学奖。

其实,1964年,世界上第一代玻璃激光器就是光纤激光器,但由于高功率室温半导体激光器和特种光纤拉制技术的限制,直到20世纪80年代中后期,光纤激光器才真正发展起来^[3]。1987年,英国南安普顿大学及美国贝尔实验室实验证明了掺铒光纤放大器(EDFA)的可行性,它采用980nm的半导体激光光泵掺铒单模光纤对光信号实现放大,现在,这种EDFA已经成为光纤通信系统中不可缺少的重要器件。

为了提高光纤激光的功率和泵浦转换效率,1988年提出光泵由包层进入的

设想。初期的设计是圆形的内包层,但由于圆形内包层完美的对称性,泵浦吸收效率不高,直到20世纪90年代初矩形内包层的出现,使激光转换效率提高到50%,输出功率达5W。1999年,Dominic等用4个45W的半导体激光器从两端泵浦获得了110W的单模连续激光输出^[4]。进入21世纪以来,随着高功率半导体激光器(包括其整形技术)和双包层光纤制作工艺的发展,单根双包层光纤激光器或放大器的输出功率逐步提高。目前,采用大模场直接的双包层掺镱光纤,以振荡器方式工作,单模连续输出功率已突破几千瓦;采用光纤级联放大的方式,已实现了万瓦的单模连续输出。

光泵光纤激光器本质上是一个波长转换器,波长短的泵浦光激励掺杂离子转换成较长波长的相干光辐射。例如,最常见的掺镱石英玻璃光纤激光器,泵浦波长经常采用975nm和915nm的半导体激光,产生波长为1080nm附近激光。

目前,经常采用的离子有Yb、Er、Nd和Tm等,可产生激光的波长大部分在1~2 μ m近红外波段。虽然采用双光子吸收方法(由两个泵浦光子产生一个激光光子)可以产生波长较短的可见光,但双光子吸收转换的效率很低,很难获得很高功率的激光输出。

若还是通过非线性频率转换方法将光纤激光注入耦合到与之匹配的非线性晶体中,通过频率转换获得可见光输出,则仍然不是光纤化的,因此,直接获得可见光波段的高功率光纤激光器是目前尚未解决的难题。从激光发展的历史我们可以看到,每前进一步,都有创新。以光纤激光为例,它包括新型激光材料、单模光纤、半导体激光泵浦、双包层光纤、光子晶体光纤和光纤光栅等创新研究。因此,要解决可见光高功率激光这一难题,更要有创新的理念和新型的材料。

参 考 文 献

- [1] 冼鼎昌.神奇的光-同步辐射.长沙:湖南教育出版社,1994:20—21.
- [2] Maiman T H. Stimulated optical radiation in ruby. *Nature*, 1960, 187: 493—494.
- [3] 楼祺洪.高功率光纤激光器及其应用.合肥:中国科学技术大学出版社,2010:73—99.
- [4] Dominic V, MacCormack S, Waarts R, et al. 110W fibre laser. *Electronics Letters*, 1999, 35: 1158—1160.

撰稿人:楼祺洪

中国科学院上海光学精密机械研究所

纳米尺度等离子体激光及 SPASER

Plasmon-polariton Nanolasers and SPASER

1. 背景介绍

微电子领域的日趋微型化和纳米科学在电子领域的日渐成熟,导致了人们对纳米尺度上光子技术类似需求。同时,基于微电子的现代计算机技术及基于光子的通信技术在不久的将来都会遇到不同程度、不同层次的发展瓶颈,而光电集成可提供一种未来将计算和通信统一的平台,可能从根本上突破这些瓶颈。目前,实现这一统一的过程中还有很多的基础科学和制作技术方面的问题需要解决,其中,重要的问题之一便是光子器件和电子器件在尺寸大小上的不匹配及与此相关的集成程度的巨大差别。虽然从微观角度看来,电子和光子都是波动物理的粒子呈现,相关的器件尺寸都受到相应波长的限制,但由于近红外和可见光的波长比通常半导体中电子的德布罗意波长比光的波长大很多,通常的光电器件要比电子器件大很多。近年来,纳米光电子学研究的一个重要前沿便是回答下述问题:光电子器件到底能做多小?有没有一个最终的物理极限?这种极限是物理原理上的,还是制作技术上的?对这些问题的探讨,正在导致一个基本的共识,即从根本上解决这个电子和光子的“波长差别”的方法,就是利用光子和金属电子在纳米尺度上的相互作用,将光子场分布限制在远小于光波长的尺度之内,这种纳米光子学的代表及顶峰便是基于纳米尺度上等离子体的激光和高强度近场的产生(或 SPASER)。半导体纳米结构和金属的集成,不仅提供了理解这些基本物理过程的平台,也同时提供了未来光电集成、通信和计算集成的物质载体。虽然这一领域近几年取得了很大的进展^[1~8],但问题并没有得到根本的解决,要从根本上解决问题,需要基本物理过程的理解、纳米加工及制作技术方面的突破。

2. 问题描述

光子或光电子器件通常的尺寸不能小于光在介质中的半波长 $\lambda/2n$ (n 为介质等效折射率),即所谓的半波极限,这是因为光波需在器件中形成驻波,我们称此为第一尺度极限^[1]。对于通常的半导体和可见到近红外段的波长,第一极限大约是 100~200nm。对于增益器件(如激光等),器件的尺寸还受到最小增益介质长度的限制,也就是说,光波在增益介质中必须传播足够距离以平衡激光器

中的各种损耗,即所谓第二极限^[1]。根据各种半导体激光器设计的不同,第二极限可以从几微米到上百微米。第二极限的大小取决于很多因素,主要有激光腔的好坏、材料的增益及所谓的限制因子,而限制因子又取决于能量在腔中的传播速度。传播速度越慢,所要求的增益介质越短,即第二极限越小。近年来,在研究各种机制以减小上述两个极限的过程中,越来越清楚地意识到,利用金属表面等离子体(surface plasmon polariton, SPP)的集体激发可以同时降低上述两个极限尺度。SPP 是金属表面电子的集体元激发,这种元激发的特点是:它能将电磁波能量限制在表面附近几纳米范围之内,这种表面波的等效折射率非常高,所以,等效波长非常短,称为波长压缩效应,能在极大程度上减小上述第一极限。同时,这个模式相应的能量传播速度非常慢,特别是在共振频率附近^[4],所以能在很大程度上减小第二极限。另一个等效的表述方式便是增大了的限制因子^[5],这种表面波的限制因子比通常光模式增加了几个数量级,是 SPP 波的一个出乎意料的结果。所有这些结果说明, SPP 能够使得尺寸很小的光电器件在原理上成为可能。但是, SPP 同时存在一个致命的弱点,便是金属中的损耗,这种损耗在 SPP 共振频率附近增加了几个数量级^[1]。最近的研究表明,由于限制因子增加引起的模式增益和 SPP 共振引起的损耗属于同一量级^[5],所以原则上,金属的损耗可以通过增加了的模式增益(限制因子)来平衡^[4~6],从而使总体的正增益和激射过程变为可能,但总的前提是增益介质必须具有相当高的材料增益。

3. 最新进展及尚待解决之难题

基于上述原理,近年来基于金属中等离子体激发和增益介质结合的理论 and 实验取得了许多重要进展^[1~8]。虽然金属腔激光器在远离 SPP 共振情况下已经被成功用于中红外和远红外,但近 SPP 共振的近红外和可见光波段鲜有报道。2007 年,文献[6]第一次系统研究了同心圆柱形核壳结构各种 SPP 模式的模式损耗和增益,特别是在红外截断和 SPP 共振附近的行为,指出了近 SPP 共振附近激射的可能性。与此独立,荷兰的 Hill 等^[2]很快在实验上实现了这种核壳结构的激射,这个实验的重要性在于它是第一个在近红外波段实现的金属腔纳米激光。但是,关于金属在这个激光器中的作用尚有讨论的余地,因为在这种尺度上,单纯的半导体圆柱(没有金属)原则上也可以实现激光。为了澄清金属的作用, Hill 和美国亚利桑那州立大学 Ning 研究组合作^[3],对原来的设计做了许多改进,一是用银替代了金,二是以长方形截面的柱体代替了原来的圆柱体(如图 1 所示),以研究单一方向(如厚度)尺寸的最小极限,该研究组实现的最小激光的半导体核是一个 6 μm 长、1 μm 高、90nm 厚的立方体。显然,如果没有银腔的限制,这样一个半导体薄膜是不会使任何一个模式激射的。这个工作的另一

个非常重要的方面是该器件的光学厚度不到 400nm, 而所产生的激光波长在 1400nm, 也就是说, 该激光的光学厚度小于半波长, 这个实验意义在于它首次证明小于半波长的激光是可能的。与此同时, 其他研究小组, 如加州大学伯克利分校的张翔研究组、Norfolk 州立大学和 Purdue 大学的研究组, 以及加州大学圣地亚哥分校组也相继发表了他们关于亚波长尺寸的激光实验工作, 美国 *Science* 杂志最近




图1 第一个小于半波长激光器的示意图^[3]

就所有这些工作做了专题介绍^[7]。目前, 上述各个研究组, 以及美国很多其他组都在这些工作的基础上, 积极地展开合作和竞争, 这些研究的目的是实现在所有三维方向小于波长尺寸且能够在电注入和室温条件下连续运转的激光, 而目前所有上述研究组的实验都没有完全达到上述要求。除文献[2]、[3]的实验外, 所有其他组的实验都是在光注入下进行的。虽然实现这一目标原则上是可能的, 但也有物理上和实际制作上的困难。其中, 基本的问题之一便是, 当所有方向的尺寸都小于波长后, 有没有一个增益介质能够提供足够大的增益, 特别是当频率接近于 SPP 的共振频率时。另一个挑战, 便是如何将这样的光源耦合到其他器件或波导中, 因为当一个激光器的三维尺寸都小于波长时, 它便相当于一个点光源, 向所有方向发射。而这个领域最终的目的是要证明 SPASER^[8] 的可能性。SPASER 是 SPP 激光的一个极限情况, 区别在于: 在 SPASER 中, 没有光子与增益介质直接作用, 而只是等离子体和增益介质的直接作用, 所直接产生的是相干电子的集体振荡, 而光只是这种振荡不可避免的后果, 就像电流在天线中震荡发射微波一样。由于这种等离子体集体振荡的衰减很大, 可以想象, 要能像受激发射那样放大等离子体的难度很高。能够证明, 实现 SPASER 的一个直接实验证据便是探测高度相干的电子的集体振荡, 到目前为止, 还没有实验直接观察到这样高度相干的电子振荡。单凭探测所发出的光子的性质显然不能够充分证明 SPASER 的运转, 而电致激发的 SPASER 的研究尚未见报道。可想而知, 尚待解决的问题还有很多。

综上所述, 基于等离子体集体振荡的纳米尺度的激光和 SPASER 不仅向我们提出了纳米制作技术上的一个严重挑战, 它还从根本上改变我们对光和物质的相互作用、激光物理过程及基本概念的理解。有关方面的研究不仅对根本解决光和电的集成, 和与此直接相关的计算及通信有革命性的影响, 还将对单分子检测、生物及化学探测, 甚至医学诊断及治疗等产生深远影响。

参 考 文 献

- [1] Ning C Z. Semiconductor nanolasers. *Phys. Stat. Sol.*, 2010, B247: 774—788.
- [2] Hill M T, Oei Y S, Smalbrugge B, et al. Lasing in metallic-coated nanocavities. *Nature Photonics*, 2007, 1: 589—594.
- [3] Hill M T, Marell M, Leong E, et al. Lasing in metal-insulator-metal sub-wavelength plasmonic waveguides. *Optics Express*, 2009, 17: 11107—11112.
- [4] Li D B, Ning C Z. Giant modal gain, amplified surface plasmon polariton propagation, and slowing down of energy velocity in a metal-semiconductor metal structure. *Phys. Rev. B*, 2009, B80: 153304—153308.
- [5] Li D B, Ning C Z. Peculiar features of confinement factors in a metal-semiconductor waveguide. *Applied Physics Letters*, 2010, 96: 181109—181111.
- [6] Maslov A V, Ning C Z. Size reduction of a semiconductor nanowire laser using metal coating. *Proceedings of SPIE*, 2007, 6468: 1—7.
- [7] Service R F. Ever-smaller lasers pave the way for data highways made of light. *Science*, 2010, 328: 810—811.
- [8] Bergman D J, Stockman M I. Surface plasmon amplification by stimulated emission of radiation: Quantum generation of coherent surface plasmons in nanosystems. *Phys. Rev. Lett.*, 2003, (90): 1—4.

撰稿人：宁存政

美国亚利桑那州立大学电机、计算机及能源工程学院

基于全固型光子带隙光纤的三次谐波产生的研究

Third Harmonic Generation in All-solid Photonic Bandgap Fibers

1. 背景介绍

常用激光器的输出通常为单一频率的激光。随着科技的发展, 各行各业对激光器的需求大大增加, 对激光器的输出波长提出了更高要求, 如要求输出波长向红外和紫外扩展、输出波长要连续可调谐等。

通过非线性频率变换可以获得普通激光器达不到的输出波长。特别的是, 从红外波段光源(如 Nd:YAG、Nd:YLF 和 Nd:YVO₄ 固体激光器等)经三次倍频产生的三次谐波经常被用作 350nm 波段附近的紫外光源。紫外光源具有荧光效应、生物效应、光化学效应和光电效应等, 在工业、农业、国防和医疗等领域有着重要的应用。

非线性光学晶体(如 BBO 等)常用于谐波的产生。为了产生三次谐波, 一般采用两个过程。首先, 通过非线性晶体产生基波的二次谐波, 然后通过另一块晶体将产生的二次谐波与剩余的基波进行和频, 从而产生三次谐波。由于需要使用两块晶体及大量诸如反射镜和透镜等光学元件, 使得整个系统既复杂又昂贵。此外, 长时间保持所有光学元件的准直也是很关键的。激光引起的损坏也是一个问题, 尤其是对暴露在高强度紫外光下的器件而言。

理论上, 应用在所有介质中都存在的三阶非线性效应直接产生三次谐波是可能的。然而, 由于光学材料的三阶非线性极化率较低, 实现基波和三次谐波的相位匹配难度较大, 直接的三次谐波产生是不实用的。

光纤激光器的迅猛发展和光纤技术的进步使得利用光纤中的三阶非线性效应直接产生三次谐波成为可能。尽管光纤的三阶非线性系数较低, 但光纤的作用长度可以很长, 同样, 理论上也可以实现高效率的三次谐波转换。此外, 全光纤的频率变换系统简单, 不需要复杂的准直元件, 可以实现小型化。

2. 问题描述

普通熔石英光纤中, 直接产生三次谐波的难点是实现基波与谐波间的相位匹配。相位匹配要求基波与谐波的模式折射率相等, 这在一对基模间是不能实现的。原因有二: ①熔石英的材料折射率决定了谐波处的材料折射率更大; ②谐波基模在光纤中束缚得更好。材料特性和波导作用导致谐波基模的折射率

比基波基模的折射率大。

Grubsky 等通过理论分析^[1], 论证了在拉锥光纤中实现谐波转换的可能性, 并通过模拟计算求得了最适宜实现三次谐波转换的谐波所在的高阶模式和相应的光纤直径。高阶模式存在截止, 而且在大的光纤直径下, 模式折射率接近纤芯材料的折射率(进而高于基波的模式折射率), 因此, 在合适的纤芯直径下总能与基波基模实现相位匹配。理论计算模式间的交叠积分表明^[1], 效率最高的谐波转换是 $\text{HE}_{11}(\omega)$ 模 $\rightarrow$ $\text{HE}_{12}(3\omega)$ 模。在此基础上, 实验中^[2]实现了由基波向三次谐波的转换。但是, 实验中谐波转换效率很低, 且谐波所处的高阶模式 $\text{HE}_{12}(3\omega)$ 模的模场分布特点使得其不适合应用。实验中, 观察到很强的二次谐波产生, 其原因尚不明确。最近, Bétourné 等^[3]讨论了利用全固光子带隙光纤中间隙孔引发全内反射与光子带隙效应共存的特性来实现基波基模与谐波基模间转换的可能性。


3. 必要说明

全固光子带隙光纤是利用光子带隙效应实现光传导的一种光子晶体光纤^[4]。光子晶体光纤是由周期微结构构成包层的一种光纤, 常见形式为熔石英中分布有周期排布的空气孔。全固光子带隙光纤的周期微结构则是高折射率的介质材料, 通常为掺杂的熔石英。周期结构可以产生光子带隙(如图 1 中编号为 1~3 的三个带隙), 这种光纤利用带隙效应能够在低折射率纤芯中实现光的传导。如果纤芯材料的折射率低于包层的有效折射率时, 光子晶体光纤可以用类似于传统光纤的全内反射实现光的传导^[4](图 1 中的 MTIR)。

研究发现^[5], 全固光子带隙光纤拉制过程中没有塌陷的间隙空气孔(图 1 中的小圆环所示)对其传输特性有着重要的影响, 使得带隙的下边界加深, 同时使得较长波长处的包层有效折射率低于纤芯材料的折射率, 因此, 全内反射效应可以实现。

如图 1 所示, 长波长处的全内反射传导的基模(叉号)比短波长处光子带隙传导的基模(三角形)的有效折射率要高, 因此, 如果基波基模与谐波基模的有效折射率之差可以抵消材料色散之差, 那么, 就可以实现一对基模间的相位匹配^[3]。三次谐波的效率有望提高, 而且谐波基模模式特性很好, 便于应用。

尽管文献[3]讨论了如何调节如图 1 所示的全固光子带隙光纤的结构参数来实现一定波长的基波与三次谐波的相位匹配, 但其报道的参数表明, 由上一部分所述的波导效应引起的基波基模和三次谐波基模间的有效折射率之差刚刚可以抵消常用的光纤激光器的波长 1064nm 处的材料色散之差, 而且间隙孔的尺寸很小(百纳米量级), 因此, 实现此特殊光纤的拉制难度极大。

图 1^[3]

4. 相关扩展

上述利用带有间隙孔的全固光子带隙光纤实现基波与三次谐波相位匹配的方案对间隙孔尺寸要求苛刻,因此,光纤拉制难度很大。但是,全固光子带隙光纤结构可灵活设计,参数调节范围很大,实现三次谐波转换可供探讨的其他方案包括以下几点:

(1) 利用无间隙孔的高折射率纤芯全固光子带隙光纤实现 $HE_{11}(\omega)$ 模 $\rightarrow$ $HE_{12}(3\omega)$ 模间的转换。基波 $HE_{11}(\omega)$ 模由全内反射传导,而谐波 $HE_{12}(3\omega)$ 模由带隙效应传导。全固光子带隙光纤的尺度可以很大,这有可能克服相位匹配条件对拉锥光纤纤芯尺寸过于敏感而带来的光纤拉制难题。不利之处仍为 $HE_{12}(3\omega)$ 模的模场分布不利于应用。

(2) 设计晶格结构新颖的全固光子带隙光纤实现 $HE_{11}(\omega)$ 模 $\rightarrow$ $HE_{11}(3\omega)$ 模间的转换。难度仍然是要克服材料的固有色散。

参考文献

- [1] Grubsky V, Savchenko A. Glass micro-fibers for efficient third harmonic generation. *Optics Express*, 2005, 13(18): 6798—6806.
- [2] Grubsky V, Feinberg J. Phase-matched third-harmonic UV generation using low-order modes in a glass micro-fiber. *Opt. Commun.*, 2007, 274(2): 447—450.
- [3] Bétourné A, Quiquempois Y, Bouwmans G, et al. Design of a photonic crystal fiber for phase-matched frequency doubling or tripling. *Optics Express*, 2008, 16(18): 14255—14262.
- [4] Russell P S J. Photonic-crystal fibers. *Journal of Lightwave Technology*, 2006, 24(12): 4729—4749.
- [5] Perrin M, Quiquempois Y, Bouwmans G, et al. Coexistence of total internal reflexion and

bandgap modes in solid core photonic bandgap fibre with interstitial air holes .Optics Express ,2007 ,15 (21) :13783—13795 .

撰稿人：栗岩锋 王清月
天津大学精密仪器与光电子工程学院

大气中超短脉冲激光的成丝

Ultra-short Pulse Laser Filamentation in Atmosphere

1. 背景介绍

超短脉冲激光在大气中传播时会出现一种独特的物理现象,即在光的传输方向上形成一个丝状的高光功率密度区域和一个狭长的等离子通道,我们把这种现象称之为“成丝”(filamentation)现象^[1,2]。超短脉冲激光成丝现象源于光学 Kerr 效应所引起的自聚焦过程,当自聚焦区域的光功率密度足以电离介质中的分子或原子时,所产生的等离子体的散焦效应将阻止光束在空间上的进一步聚焦。由于非线性自聚焦和等离子体散焦过程两者之间的动态平衡,光脉冲被钳制在一定的幅度内,形成一个稳定的连续谱分布的脉冲光场,也即我们称之为丝状的光场。“成丝”现象在很多领域有着广泛的应用前景,重要的应用包括大气污染检测、太赫兹辐射源、雷电控制及激光天线等。目前,超短脉冲激光技术在这些应用领域的发展尚需要解决成丝非线性光学中一些重要的科学问题。

2. 问题描述

(1) 成丝过程中指纹谱产生的原子分子发光动力学机理及鲁棒性问题。由于“丝”状脉冲光场的峰值强度较高,大气中的所有气体分子会被电离甚至解离,其中的生化污染气体在非线性电离和解离过程中被激发产生具有分子光谱特性的光谱——非线性荧光光谱,所释放的特征荧光光谱可以采用雷达遥感技术进行探测。由于不同分子的非线性荧光光谱具有不同的光谱特性,因此,这些光谱可以作为分子指纹模式加以识别,从而得到大气中污染气体的成分和浓度。但在大气环境中,指纹荧光受到发光局部微环境(如分子间碰撞)和宏观环境(如荧光的再吸收和散射)的影响,而使发光谱受到调制,特别是成丝过程中的激光脉冲具有脉宽窄(短至少数周期)和光谱宽(横跨紫外、可见、红外,甚至太赫兹波段)的特点。超快激光成丝过程中,指纹谱产生的原子分子发光动力学机理及鲁棒性都是该技术应用必须解决的关键问题。

(2) 超短脉冲激光成丝诱导指纹荧光光谱的有效识别问题。复杂光谱中提取清晰指纹谱特征及利用这些特征进行定量分析是超快激光成丝现象应用于大气污染实时监测时需要解决的技术问题。由于大气中的污染气体种类多、含量

较低,采用传统的光谱定量分析方法分析上述荧光光谱存在很大难度,解决这一问题的唯一方法是研究和探索新型的光谱分析技术。把荧光光谱定性分析与神经网络定量分析有机地结合起来是解决该问题潜在的有效方法。

3. 必要说明

利用飞秒激光与大气组分相互作用所产生的超快激光成丝现象对大气进行遥感探测的概念最先由 Teramobile 研究小组于 2003 年率先在世界上提出^[3]。近期,加拿大 Laval 大学的科研小组已经成功地在几十米远的距离上实现了气体杂质、生化样品浮质和固体金属等多种样品的远程检测^[4],并且在这一距离上的杂质探测灵敏度可达到几个 ppm 量级^[5]。最近,日本电力工业中央研究院也成功地利用成丝探测到了空气气溶胶中所含的微量杂质^[6]。不仅如此,Laval 大学的研究人员还发现成丝过程中所辐射的荧光光谱和普通光致等离子光谱有着本质的区别——它没有传统理论所预期的由自由电子和离子复合过程中的韧致辐射所导致的等离子体超连续谱,这就是所谓的清晰荧光光谱^[7]。这一现象为成丝在大气污染监测应用中的强大分辨能力提供了物理基础。

4. 相关扩展

在深入认识超快激光成丝现象中激光传输非线性动力学过程和清晰的指纹谱产生的光和分子原子相互作用的分子动力学过程的基础上,根据应用需要对激光成丝非线性动力学过程进行有效地相干控制是超快激光雷达技术基础研究的必然要求。

参 考 文 献

- [1] Talebpour A, Abdel-Fattah M, Chin S L. Focusing limits of intense ultrafast laser pulses in a high pressure gas: Road to new spectroscopic source. *Opt. Commun.*, 2000, 183: 479—484.
- [2] Aközbek N, Scalora M, Bowden C M, et al. White-light continuum generation and filamentation during the propagation of ultra-short laser pulses in air. *Opt. Commun.*, 2001, 191 (3-6): 353—362.
- [3] Kasparian J, Rodriguez M, Méjean G, et al. White-light filaments for atmospheric analysis. *Science*, 2003, 301 (5629): 61—64.
- [4] Xu H L, Liu W, Chin S L. Remote time-resolved filament-induced breakdown spectroscopy of biological materials. *Opt. Lett.*, 2006, 31: 1540—1542.
- [5] Liu W, Xu H L, Méjean G, et al. Efficient non-gated remote filament-induced breakdown spectroscopy of metallic sample. *Spectrochimica Acta Part B: Atomic Spectroscopy*, 2007, 62(1): 76—81.

-
- [6] Fujii T ,Goto N ,Miki M ,et al .Lidar measurement of constituents of microparticles in air by laser-induced breakdown spectroscopy using femtosecond terawatt laser pulses .Opt .Lett ., 2006 ,31 ;3456—3458 .
- [7] Gravel J F ,Luo Q ,Boudreau D ,et al .Sensing of halocarbons using femtosecond laser-induced fluorescence .Anal .Chem . ,2004 ,76 ;4799—4805 .

撰稿人：常胜江 刘伟伟
南开大学信息技术科学学院

用于直接泵浦的中长波红外激光介质

Mid-infrared Laser Crystal Materials for Directly Pumped Solid Laser

1. 背景介绍

中红外激光($2\sim 5\mu\text{m}$)在军事、民用及科研上均有重要的应用前景。在军事上,中红外激光是新一代光电制导和光电对抗的主要工作波段之一,利用中红外波段激光干扰,对抗侦察卫星不仅灵敏度高、杀伤阈值小,而且所需功率小、便于装载。在民用和科研方面,中红外波段既存在水的强吸收峰($2.4\mu\text{m}$ 附近),又存在水汽窗口($3.8\mu\text{m}$ 附近),因而中红外激光可用于高灵敏度的水汽检测,由此发展出高精度的测风、风暴预警雷达等技术,可应用于天气预报和全球气候监测^[1]。此外,结合生物细胞 80% 以上由水构成的特点和水对中红外激光的吸收特性,中红外激光可以被广泛地应用于生物检测和医疗手术中,如在牙科和眼科手术中,人们已经使用 $3\mu\text{m}$ 波长的中红外激光来提高医疗的安全性和手术的准确性(如图 1 所示)。



图 1 军用中红外干扰系统和医用中红外牙科系统

目前,得到中红外激光输出的主要途径有:①基于固体激光器和非线性频率转换(OPO)的技术。这是目前获得中红外激光输出的最常用技术方案,采用这种技术的中红外激光器系统具有宽调谐、可靠性好等优点,但激光器转换效率较低且受限于非线性晶体的损伤阈值,难以获得高功率的激光输出。②基于 CO_2 气体激光器的频率上转换技术和倍频技术。此技术路线可以获得高平均输出

功率、高光束质量的激光输出,但 CO_2 气体激光器体积庞大、维护复杂且不能获得高峰值功率。③半导体激光器。目前的研究热点是量子级联激光器,但在功率提升和光束质量方面碰到很大问题。

与传统上获得中红外激光的气体激光器、液体激光器和固体激光器+OPO等技术路线相比,通过固体激光器直接获得中红外激光输出具有电光转换效率高、激光器结构紧凑等优点,是最有发展前途的技术路线之一,该技术路线最亟须解决的就是高质量的中红外激光材料问题。

2. 问题描述

能够获得优异的中红外激光输出的激光晶体必须具备以下几个条件^[2]:

(1) 晶体必须具备良好的光学特性,在所需的中红外波段具有高的透过率,且折射率变化小,因为折射率变化会导致光在晶体内不均匀传播,产生质量差的光束。

(2) 晶体的晶格能够接收掺杂离子,其局部的晶体场必须具有对称性和感应中红外波段光谱特性所必需的强度,而掺杂离子必须有适合于产生中红外激光输出的能级结构且离子的辐射寿命长。

(3) 晶体本身具有良好的机械和热性能、高的热传导系数和抗损伤阈值,有利于获得高功率、高光束质量的激光输出。

3. 必要说明

目前,利用激光晶体直接获得中红外激光输出领域的研究热点主要集中在目前研究较多的基于掺铬(Cr)、铁(Fe)的 II-VI 族半导体的激光器和基于掺镨(Dy)、镨(Pr)的氟化物晶体。美国 LLNL 国家实验室、AFRL 实验室和 CTI 公司等都开展了过渡金属离子掺杂的 II-VI 族半导体材料的研制及其中红外可调谐激光器研究^[3~5],他们采用改进的物理气相输运(PVT)工艺制备出高质量的 $\text{Cr}^{2+}:\text{ZnSe}$ 晶体,采用 $\text{Tm}:\text{YAP}$ 激光泵浦 $\text{Cr}^{2+}:\text{ZnSe}$ 晶体,实现了 $2.0\sim 3.1\mu\text{m}$ 的可调谐激光输出,最大输出功率达 20W,斜率效率达到 65%。使用 $2.92\mu\text{m}$ 的激光泵浦 $\text{Fe}^{2+}:\text{ZnSe}$ 晶体,在室温下已获得了 $3.9\sim 4.8\mu\text{m}$ 的可调谐激光输出。美国海军实验室 2007 年 2 月份报道了调谐宽度到 1000nm、输出功率大于 2W 的实用型 $\text{Cr}^{2+}:\text{ZnSe}$ 激光器,该激光器将被用于测风雷达的演示中。国内目前受限于晶体生长技术,相关的报道还比较少。

4. 相关扩展

激光技术是一个系统工程,除了作为核心技术的激光晶体材料以外,与晶体材料相配套的中红外薄膜技术及高效的泵浦源技术也是获得高性能中红外激

光输出的关键技术。

参 考 文 献

- [1] Koechner W. 固体激光工程. 孙文, 江泽文, 程国祥译. 北京: 科学出版社, 2002: 23—74.
- [2] Urata Y, Kozeki T, Kudo A, et al. Characterization of thulium and holmium-doped YAG ceramic laser materials. Proceedings of SPIE, 2006, 6409: 1—8.
- [3] Sorokina I T. Cr^{2+} -doped II-VI materials for lasers and nonlinear optics. Optical Materials, 2004, 26: 395—412.
- [4] Sorokin E, Sorokina I T, Lieto A D, et al. Tunable diode-pumped continuous-wave single crystal and ceramic Cr^{2+} :ZnSe lasers. CLEO/Pacific Rim, 2001: 26—27.
- [5] Sorokin E, Sorokina I T, Lieto A D, et al. Mode-locked ceramic Cr^{2+} :ZnSe laser. OSA/ASSP, 2003, 83: 227.

撰稿人: 程小劲

中国科学院上海光学精密机械研究所

超短脉冲激光烧蚀产生的极端非平衡物质状态

Extreme Non-equilibrium Material State Generated
by Ultrashort Pulse Laser Ablation

超短激光脉冲是指脉冲宽度在皮秒(10^{-12} s)、飞秒(10^{-15} s)量级的激光脉冲。除了脉冲持续时间极短之外,超短激光脉冲还具有高峰值功率、宽光谱及可实现高脉冲重复频率等特点。当具有吉瓦(10^9 W)、太瓦(10^{12} W)甚至拍瓦(10^{15} W)峰值功率的超短激光脉冲烧蚀液体或固体材料时,烧蚀区内的物质由于在极短的脉冲持续时间内吸收了大量的光能,热平衡在短时间内来不及形成,因此,进入了一种极端不平衡的热力学状态。由于初期在烧蚀区域内形成极大的温度和应力梯度,在稍后的热力学状态弛豫过程中,被烧蚀物质将经历一系列瞬态热力学极端不平衡状态,这些极端的物质热力学不平衡状态是很难通过其他实验手段产生的,因为其他的实验手段实现不了如此高功率的超快加热过程。

对烧蚀过程中产生的处于极端非平衡状态的物质的研究具有重大的科学意义。从热力学角度来说,热力学最核心的问题之一就是弄清物质在一定的温度和压力条件下,在热力学相图中所处的位置及在温度、压力变化的情况下,物质状态的变化在相图上描出的路径。虽然目前利用热力学相关理论,结合分子动力学方法(这是最流行或者说是最传统的方法),通过计算可以近似得出包括极端非平衡状态下的物质热力学过程在内的物质状态变化过程,但要对极端非平衡物质状态有准确的认识,还需要在实验中观察到这些热力学状态来确定理论计算得出的各种热力学路径中哪些是最符合实际的。另外,从对超快激光烧蚀理论的研究角度来讲,对烧蚀过程中物质经历的瞬态极端不平衡状态的认识,就意味着对大部分超快烧蚀机制的准确把握,将极大推动目前处于百家争鸣状态的超快激光烧蚀理论的发展。

此外,对烧蚀过程中产生的极端非平衡物质状态的研究也具有重要的实际应用价值。通过对烧蚀过程中产生的瞬态极端非平衡物质状态的研究,可以帮助我们更好地控制烧蚀产物的生成和超短脉冲激光微纳加工的效果。例如,在超短激光脉冲烧蚀石墨制备富勒烯、碳纳米管甚至石墨烯时,如果我们了解了烧蚀过程中物质所经历的极端不平衡状态,就可以更加准确地通过改变烧蚀激光参数和烧蚀环境条件来控制各种产物的生成。

世界各国的研究人员对于这一问题的研究已经超过了 20 年,做了大量的理论和实验工作。Martynyuk、Kelly、Miotello^[1]、Vidal^[2]、Xu、Lewis、Meunier^[3]及 Zhigilei^[4]等的研究工作建立了多种超短脉冲激光烧蚀的理论模型; Sokolowski-Tinten^[5]、Mao^[6]、Kaplan、Lenner、Palmer、Zewail^[7]、Bulgakova 及我们的研究组^[8]所作的实验工作使人们对超短脉冲烧蚀过程中产生的物质瞬间非平衡状态有了不少的了解。但是,由于两个目前难以克服的困难的存在,使得对这一问题的研究还处于初级阶段。第一个困难是烧蚀产生的处于非平衡状态的物质通常局限于很小的尺度内,一般是微米量级;第二个困难是这些物质的非平衡状态的持续时间极端,一般是纳秒,甚至皮秒、飞秒量级。目前的探测手段使得我们无法直接测量这些非平衡物质状态的温度、压力及密度等热力学参数,也就无法准确确定被烧蚀物质所经历的热力学过程。即时使用大能量的激光脉冲,在保证激光流量、峰值功率不变的情况下,将烧蚀区域扩大到宏观尺度,如毫米、甚至厘米量级,但第二个困难仍旧无法克服,不存在如此快速的温度、压力和密度探测器能够响应这种超快的热力学过程。

科学就是在不断解决问题中获得发展和进步的。目前看来无法解决的问题,可能在将来得到很好的解决,对超短激光脉冲烧蚀过程中产生的处于极端非平衡状态的物质的研究也是如此。只要在这一问题上付出持续的努力,对于这一问题的研究应当会有所突破的。

参 考 文 献

- [1] Miotello A, Kelly R. Critical assessment of thermal models for laser sputtering at high fluences. *Applied Physics Letters*, 1995, 67(24): 3535—3537.
- [2] Vidal F, Johnston T W, Laville S, et al. Critical-point phase separation in laser ablation of conductors. *Phys. Rev. Lett.*, 2001, 86(12): 2573—2576.
- [3] Lorazo P, Lewis L J, Meunier M. Short-pulse laser ablation of solids: From phase explosion to fragmentation. *Phys. Rev. Lett.*, 2003, 91(22): 225502.
- [4] Leveugle E, Ivanov D S, Zhigilei L V. Photomechanical spallation of molecular and metal targets: Molecular dynamics study. *Appl. Phys. A*, 2004, 79(7): 1643—1655.
- [5] Sokolowski-Tinten K, Bialkowski J, Cavalleri A, et al. Transient states of matter during short pulse laser ablation. *Phys. Rev. Lett.*, 1998, 81(1): 224—227.
- [6] Mao S S, Mao X, Greif R, et al. Initiation of an early-stage plasma during picosecond laser ablation of solids. *Applied Physics Letters*, 2000, 77(16): 2464—2466.
- [7] Carbone F, Baum P, Rudolf P, Zewail A H. Structural preablation dynamics of graphite observed by ultrafast electron crystallography. *Phys. Rev. Lett.*, 2008, 100(3): 035501.

-
- [8] Zhang N,Zhu X,Yang J,et al.Time-resolved shadowgraphs of material ejection in intense femtosecond laser ablation of aluminum .Phys.Rev.Lett.,2007,99(16):167602.

撰稿人：张楠 朱晓农
南开大学现代光学研究所

如何实现活体生物信息的无标记光学获取

How to Capture Life Information by Label-free Optical Technique

1. 背景介绍

20 世纪中叶以来,人们通过应用 X 射线衍射仪解析了 DNA 的双螺旋结构并发现 DNA 内切酶,生命科学从此进入分子生物学时代。2000 年,科学家首次破译了人类基因组图谱,生命科学研究步入了后基因组时代。现代生命科学研究主要集中在细胞和分子层面探索生命最小基本单元的功能、生命现象和疾病发生发展的分子机理,尤其针对新发病毒性传染病的研究,如甲型 H1N1 流感病毒,亟须建立一套快速诊断和信息获取方法。光子作为信息载体,适应生命科学这一发展趋势,有望为细胞和分子水平获取信息提供新的原理、方法和技术支持。光学信息获取已成为光子学与现代生命科学前沿交叉的关键技术科学。

光学信息获取作为研究分子和细胞生命现象的主要手段,具有无损、高灵敏、高分辨率、实时动态等优势。但长期以来,由于光学手段不具备生物选择性,通常需要通过抗原-抗体结合的原理选取具有高选择性和高特异性结合能力的标记物和染料分子协助识别生物对象。但随着生命科学研究涉及的生物种类与日俱增,能够供测量使用的抗原-抗体和信号标记物的种类出现短缺,而且还有假阳性结合,加之染料对生命活性的危害、染料的光漂白、染色样品不易长期保存等问题显得尤为突出,因此,传统的基于信号标记物的光学信息获取方法越来越不适应生命科学的发展趋势和需求。

2. 问题描述

当前,如何实现活体生物信息的无标记、高特异性光学获取已经成为生物光子学领域的一大难题。上述问题既是光学手段本身尚未克服的应用基础研究难点,也是光学与生命科学交叉领域的研究热点。解决该问题,关键需要探索生物体对新光学效应的特异性响应机理,建立生命光学信息获取中能够突破标记物和染色两大外界因素的细胞、亚细胞器和分子的传感、光谱、成像、操纵测量的新机制和新方法。

3. 必要说明

生命科学研究从无标记时代(传统光学显微镜)发展到了标记(荧光标记技

术)时代,再从蓬勃发展的标记时代跨入无标记时代,看上去像是一个轮回,却是一个地道的回归,蕴含着新的令人振奋的科学内涵。为什么我们如此兴致勃勃地拥抱这样一个回归?对于所有做科学研究的人而言,为了从我们所需要研究的体系中获取有价值的信息,通常需要人为地引入一个干扰(如荧光标记)。尽管这种人为引入干扰的作用可以被预见或者测量,但我们永远不可否认的就是——它们的确对我们研究的体系施加了影响。于是我们很好奇,若可以尽可能地减小这种干扰甚至消除,我们观测到的结果是否是现有条件下观测结果的完全重现,这个问题表现在生命科学信息的光学检测上就是无标记光学检测。标记光学检测可有效解决光学标记中染料对生命活性的危害、染料的光漂白、染色样品不易长期保存等问题。

4. 相关扩展

活体生物信息的无标记光学获取实际面临三大具体难题。

(1) 如何将获取的光学信息与基于分子结构的生物特异性直接关联起来,实现生物信息的无染色、高特异性光学获取?目前,生物体的成像特征量主要是依靠染料分子或量子点等受激发光物质与光学显微术结合来实现的。利用激光的高光谱选择特性,深入研究入射激光能量在非均匀生物组织中的传输、相互作用及能量转换机理,发展反映病变组织结构和功能的新型光声成像理论,实现在体微生命环境下高特异性识别和高分辨率成像;有望摆脱染料和荧光实现显微成像,是生物光学显微术的一个具有战略意义的理论和技术创新^[1~4]。

(2) 如何通过光场增强手段,实现生物信息的无标记、高灵敏度的光学获取?利用金属微结构光谱增强、光学微腔光场增强,通过设计优化光场与金属纳米结构作用增强机制,实现超高灵敏度表面增强拉曼光谱技术检测,可有效获取生物样品的特异性光学信息,是对目前通常研究的光学传感信息获取的重大理论创新和技术突破,为光学信息获取向无标记、高灵敏度发展提供了新方向^[5,6]。

(3) 如何通过提高光学微操纵能力,实现生物信息的高选择性光学获取?利用阵列光镊分选技术,实现基于细胞自身折射率的分选和检测,可望实现新型细胞信息获取与疾病早期诊断^[7,8]。

因此,上述关键科学难题的解决,将有望突破光学信息获取手段的瓶颈,推动生命科学在分子和细胞水平向无标记、无染色的测量体系迈进,开创细胞、亚细胞器和分子的传感、光谱、成像、操纵测量的新机制和新方法,为研究活性生命现象提供新的技术支持;对于人口健康、生活质量及其整个社会发展都有及其重大的意义。

参 考 文 献

- [1] Wang L. Multiscale photoacoustic microscopy and computed tomography. *Nature Photonics*, 2009, 3: 412—417.
- [2] Wang X, et al. Noninvasive laser-induced photoacoustic tomography for structural and functional imaging of the brain in vivo. *Nature Biotechnology*, 2003, 21: 803—806.
- [3] Yang D, et al. Integrative prototype B-scan photoacoustic tomography system based on a novel hybridized scanning head. *Applied Physics Letters*, 2006, 88(174101): 1—3.
- [4] Lao Y, et al. Noninvasive photoacoustic imaging of the developing vasculature during early tumor growth. *Phys. Med. Biol.*, 2008, 53: 4203—4212.
- [5] Kneipp K, et al. Field ultrasensitive chemical analysis by Raman spectroscopy. *Chem. Rev.*, 1999, 99: 2957—2975.
- [6] Nie S M, et al. Probing single molecules and single nanoparticles by surface-enhanced Raman scattering. *Science*, 1997, 275: 1102—1106.
- [7] Paterson L, et al. Controlled rotation of optically trapped microscopic particles. *Science*, 2001, 292: 912—914.
- [8] MacDonald M P, et al. Creation and manipulation of three-dimensional optically trapped structures. *Science*, 2002, 296: 1101—1103.

撰稿人：邢 达

华南师范大学激光生命科学教育部重点实验室

活体蛋白质功能的跨层次动态光学分子成像

In Vivo Visualization of Dynamic Protein Function with Multiscale Optical Molecular Imaging Techniques

蛋白质是生命活动的载体和功能执行者，蛋白质科学的持续创新正成为解决人口健康重大问题的突破口之一。由于生物活动的复杂性，对目标蛋白质的移除或加入，其特定功能可能由其他蛋白代偿而不被发现。换言之，无论是体外分离纯化的蛋白质，还是体外培养的细胞或细胞网络，都不可能真实地模拟生物活体内的精细组成结构和生理或病理环境^[1]。因此，体外研究所获得的大量蛋白质功能信息亟待在活体内的确证。如何全面准确地描述蛋白质功能及其调控规律是蛋白质科学研究中极富挑战的难题^[2]。

近年来，光学分子成像技术在活体蛋白质功能研究中展示了巨大的潜力，成为解决上述难题的极具前景的研究手段之一^[3]。其中，超分辨光学成像已经可以实现高达 30~50 nm 的空间分辨率，为活细胞内蛋白质功能及其调控规律的研究提供前所未有的工具^[4]。飞秒激光多光子激发扫描显微成像已能在活体亚细胞水平监测蛋白质分子事件^[5,6]，而光声层析成像则有望突破高分辨光学成像的深度“硬极限”^[7]。虽然原理上光学分子成像可用于活体蛋白质功能的动态研究，然而，活体内蛋白质分子相互作用构成的复杂调控网络、细胞所处微环境的动态变化及从分子—细胞—组织—器官—整体多个层次的功能信息描述，都对光学分子成像提出了更高要求^[8,9]。

为了将光学分子成像技术应用于活体蛋白质功能的跨层次动态研究，需要成像系统能够在活体内高时空分辨地同步获取多分子事件的光学信息，并高效提取、鉴别与表征为相应的生物分子信息；需要成像系统能够跨层次、多尺度地获取蛋白质分子的动态信息，并整合蛋白质的多源信息，实现蛋白质功能的精细描述。因此，活体内蛋白质功能的光学表征和跨层次信息整合是需要解决的关键科学问题。

现有的研究手段尚难以满足活体蛋白质功能的跨层次动态研究需要，亟待技术和方法的突破。在活体内蛋白质功能的光学表征方面，需要：①解决蛋白质光学标记探针的对比度和光稳定性问题，以及活体内多分子同步光学标记的特异性和准确性等问题；②研究活体内成像对比度产生和信号放大机理，建立活体蛋白质功能与相应光学探针的物理信息之间的原理性联系，将活体内的蛋白质功能信息转化为光学可测量的物理信息；③发展和完善光学成像基础理论，

突破性解决光学成像的深度与成像分辨率之间的矛盾, 成像视场范围与成像速度之间的矛盾, 实现活体内多蛋白质分子事件的快速并行检测及跨层次多尺度快速获取。在活体内蛋白质功能的跨层次信息整合方面, 需要利用分子—细胞—组织—整体等不同层次的结构与功能信息, 特别是多种分子事件相互作用的时空变化信息, 建立跨层次的系统生物学模型, 突破不同层次之间信息的关联、耦合与相互作用, 揭示活体内蛋白质功能及其调控规律。

参 考 文 献

- [1] Verveer P J, Bastiaens P I H. Quantitative microscopy and systems biology: Seeing the whole picture. *Histochemistry and Cell Biology*, 2008, 130: 833—843.
- [2] Megason S G, Fraser S E. Imaging in systems biology. *Cell*, 2007, 130: 784—795.
- [3] Ntziachristos V, Ripoll J, Wang L H V, et al. Looking and listening to light: The evolution of whole-body photonic imaging. *Nature Biotechnology*, 2005, 23: 313—320.
- [4] Huang B, Bates M, Zhuang X W. Super-resolution fluorescence microscopy. *Annual Review of Biochemistry*, 2009, 78: 993—1016.
- [5] Zipfel W R, Williams R M, Webb W W. Nonlinear magic: Multiphoton microscopy in the biosciences. *Nature Biotechnology*, 2003, 21: 1368—1376.
- [6] Wilt B A, Burns L D, Ho E T W, et al. Advances in light microscopy for neuroscience. *Annual Review of Neuroscience*, 2009, 32: 435—506.
- [7] Wang L V. Multiscale photoacoustic microscopy and computed tomography. *Nature Photonics*, 2009, 3: 503—509.
- [8] Walter T, Shattuck D W, Baldock R, et al. Visualization of image data from cells to organisms. *Nature Methods*, 2010, 7: S26—S41.
- [9] O'Donoghue S I, Gavin A C, Gehlenborg N, et al. Visualizing biological data—now and in the future. *Nature Methods*, 2010, 7: S2—S4.

撰稿人: 骆清铭

华中科技大学武汉光电国家实验室 (筹)

神经网络回路的高分辨光学成像

Microscopic Imaging the Neural Networks with High Spatio-temporal Resolution

1. 背景介绍

大脑功能都依赖于由众多神经元形成的神经网络和回路^[1,2]。目前,对大脑功能的研究集中在生化、分子、细胞及组织水平上,而对回路层次的研究却受到制约。共聚焦显微镜和膜片钳技术为单细胞水平的神经功能研究提供了有力的手段,对组织水平的脑功能研究,则可以利用正电子发射断层成像(PET)和功能磁共振成像(fMRI)等技术。但是,对神经回路神经元集群中所发生的并行分布式信息加工与处理过程,则缺乏行之有效的实验手段。例如,大脑中感觉系统的功能单元在几十到几百微米尺度上(嗅球的嗅小结、触觉的胡须桶、视觉的柱结构等),还没有相应的研究方法可以同时观察到神经元群体的快速活动模式,这已构成了当前脑与智能研究中所面临的最严峻、最急迫的挑战。研究神经元群体的信息加工与处理过程亟须发展新的神经成像技术与仪器。一方面,能够确立神经元的网络定位,即能够确认所记录细胞的精确位置、形态、类别及相互关系;另一方面,能够记录神经元网络中快速编码信息的传递。

2. 问题描述

神经回路信息处理机制的研究,目前面临的突出问题是缺少能在活体环境中实时动态高时空分辨观测神经功能的研究手段。常用于神经回路研究的电生理记录技术,如膜片钳技术和微电极阵列芯片技术等,可获得部分细胞神经电信号,但有一定损伤性,且不能确认细胞之间的相互关系,因此,揭示网络内部的信息编码过程还有困难^[3,4]。光学显微成像为高空间分辨神经功能成像提供了有力的方法^[5,6],特别是飞秒激光双光子显微成像是活体动物以亚细胞分辨进行成像的重大进展。1990年以来,飞秒激光技术的发展使得双光子显微成像技术在生命、化学、物理等多个学科领域获得广泛应用,其高穿透深度、高空间分辨能力和低光毒性使很多以前不可能进行的科学观测成为事实,为多个学科领域带来了突破性的进展。事实上,飞秒激光双光子显微成像既能分辨细胞类型,又能记录功能信号,因此,极有潜力用于神经元群体活动模式的成像^[7],其主要不足是采用机械扫描,成像速度较慢。过低的时间分辨率不能满足探测

毫秒量级快速变化的荧光信号的需求。

3. 必要说明

发展新的光学成像原理与技术, 在提高成像的时间分辨率的同时不牺牲信噪比, 则可有效解决神经回路功能监测问题。针对传统的飞秒激光机械扫描在速率、稳定性、精度等方面的不足, 发展三维无惯性控制与扫描的技术^[8,9], 则可有效提高扫描速度、稳定性与精度, 进而追踪神经回路中快速功能信号的传递^[10]。

4. 相关扩展

利用创新的光学成像原理与技术有可能解决活体高分辨神经回路功能信号监测问题。事实上, 这一难题的解决将广泛地推进生命科学的研究。一方面, 可用于神经网络基本活动过程的监测, 了解神经信息处理的机制, 为探索记忆的形成、认知活动等高级功能提供方法; 另一方面, 也为探索疾病发病机制、药物作用机理提供了基本手段。

参 考 文 献

- [1] Stosiek C, Garaschuk O, Holthoff K, et al. In vivo two-photon calcium imaging of neuronal networks. *Proc. Nat. Acad. Sci.*, 2003, 100: 7319—7324.
- [2] Peterlin Z A, Kozloski J, Mao B Q, et al. Optical probing of neuronal circuits with calcium-indicators. *Proc. Nat. Acad. Sci.*, 2000, 97: 3619—3624.
- [3] Sinha S R, Saggau P. Imaging of 4-AP-induced, GABA(A)-dependent spontaneous synchronized activity mediated by the hippocampal interneuron network. *J. Neurophysiol.*, 2001, 86: 381—391.
- [4] Li X, Zhou W, Liu M, et al. Synchronized spontaneous spikes on multi-electrode array show development of cultured neuronal network. *Conf. Proc. IEEE. Eng. Med. Biol. Soc.*, 2005, 2: 2134—2137.
- [5] Yuste R. Fluorescence microscopy today. *Nature Methods*, 2005, 2: 902—904.
- [6] Cahalan M D, Parker I, Wei S H, et al. Two-photon tissue imaging: Seeing the immune system in a fresh light. *Nat. Rev. Immunol.*, 2002, 2: 872—880.
- [7] Helmchen F, Denk W. Deep tissue two-photon microscopy. *Nature Methods*, 2005, 2: 932—940.
- [8] Zeng S Q, Lv X, Zhan C, et al. Simultaneous compensation for spatial and temporal dispersion of acousto-optical deflectors for two-dimensional scanning with a single prism. *Opt. Lett.*, 2006, 31: 1091—1093.
- [9] Salomé R, Kremer Y, Dieudonné S, et al. Ultrafast random-access scanning in two-photon

microscopy using acousto-optic deflectors. *Journal of Neuroscience Methods*, 2006, 154: 161—174.

- [10] Reddy G D, Kelleher K, Fink R, et al. Three-dimensional random access multiphoton microscopy for functional imaging of neuronal activity. *Nature Neuroscience*, 2008, 11: 713—720.

撰稿人：曾绍群

华中科技大学武汉光电国家实验室（筹）

光声显微与层析成像

Photoacoustic Microscopy and Computed Tomography

1. 背景介绍

光声层析成像可能是生物医学成像中发展最快的一项技术,这是由于它能够在超过光学传输平均自由程(皮肤中约 1mm)的时候利用多种光学衬比实现在体高分辨成像。现存的高分辨光学成像技术,如双光子和共聚焦显微镜,已经对生物医学产生了重大的影响,但它们无法达到如此的成像深度。光声层析成像间接地将组织的透明度改善了 100~1000 倍,从而能够在深层组织中实现高分辨的功能与分子成像。此外,光声层析成像有潜力实现同一种衬比源在体的从亚细胞器水平到器官水平的多尺度成像,这在多尺度系统生物学研究中有重要的应用^[1]。

2. 问题描述

光声层析成像被定义为基于光声效应的对一种物质的层析或者三维成像技术,而没有任何深度分辨率的平面成像技术或一维深度分辨的成像不属于层析成像。在发生光声现象时,光被物质吸收并转化为热,接着由于热弹效应会产生超声波^[2]。光声层析成像,一种混合了光学成像和超声成像的技术,将丰富的光学衬比与高的超声分辨率融合到一起,它能够在体实现高散射生物组织前所未有的深度中高分辨的结构功能和分子成像。结构成像无法区分组织是否是活的,而功能成像则可以通过测量生理参数(如血流血氧)来区分。此外,分子成像能够探测到标记物来识别肿瘤细胞或者探测基因表达产物来跟踪基因活动。

简单来说,在光声层析成像中,光进入物质中而产生超声。为了高效地产生超声,短脉冲激光是常用的激发源。光声声压强度由吸收的光能量决定,同时,也取决于组织的热和机械性质。由于无论是弹道光光子还是散射的光子,都会被吸收产生热从而产生光声信号,因此,光声层析成像能够在扩散光区域成像。光声成像的原理是通过在组织外部不同位置测量光声信号到达的时间,从而测量光声源的位置。

光声层析成像有两种主要的模式。一种是聚焦式的扫描光声层析成像,如暗场共焦光声显微成像^[3],它是使用聚焦式的超声探头进行机械扫描成像。在

每个扫描点,聚焦的超声能够产生横向的分辨率,而不同的超声信号到达时间可以提供纵向分辨率。另一种是光声计算层析成像,一个非聚焦的超声探头阵列被用来同时探测光声信号。它可以获得高达 50 Hz 的成像速度,然而它需要一种重建算法来重建出层析图像。早期的重建算法是基于假设每个超声探头在一个平面而非一个球面同时接收到光声源的信号,这在实际中很难满足。稍后,不同的研究小组发展了不同的精确重建算法。近年来,在平面、圆柱面、球面三种探测结构下,一种精确的闭式重建算法被提出^[4]。有趣的是,第一种模式中的聚焦式超声探头可以被认为是一种模拟计算方式来近似实现第二种方式中的重建算法。尽管探头聚焦的方式不会出现离散化误差,聚焦的位置却不能够如光声计算层析成像中那么容易调整。结果,除非使用基于虚拟探测器的合成孔径算法,否则,只有在聚焦区域才能达到最佳分辨率。

光声层析成像对于光学吸收极端敏感。光声激发时,会将很小的光学吸收系数的改变相应地转化到超声信号的改变中。同样的道理,光声层析成像对于 Grueneisen 系数,从吸收的光能转化为压力的系数,也同样敏感,所以, Grueneisen 系数也能够提供成像的对比度。事实上, Grueneisen 系数随着平衡温度上升而上升(在水中 5% /K),这使得光声层析成像能够用来监测热疗,灵敏度达到 0.16°C。

每毫开尔文的组织中的光致温升会产生约 800 Pa 的初始压力,达到典型的超声换能器的灵敏度量级。由于温升导致的转换压力与两个参数有关,体积膨胀系数和压缩系数,幸运的是,这两个参数都使得光声层析成像在对于组织安全的温升范围内是可行的。

3. 必要说明

在 1880 年 Bell 首次报道光声效应后 100 年^[2], Bowen 展望了使用电离辐射(高能电子、X 射线光子、中子和其他带电粒子)或非电离辐射(无线电波、微波、超声)来激发从而成像^[5],他展示了使用无线电波激发的一维深度分辨成像,但没有提到使用光学激发的可能性。10 年后,初步实现了激光诱导的光声深度分辨成像,它几乎没有横向分辨率(6 mm)^[6]。为使层析的或者三维的成像能够同时达到较高的轴向和横向分辨率,发展了基于近似重建算法的光声层析成像。此外,也实现了基于聚焦的超声探测的光声层析成像。在 2003 年报道了一种在体的功能光声层析成像,它激发了整个光声层析成像领域,并导致了这一领域的研究随后快速增长^[7]。在 2005 年发展了三维光声显微成像技术,它能达到极高的空间分辨率^[3,8~10]。

高分辨的光学显微成像面临着两个根本的挑战:衍射和散射。衍射限制了空间分辨率,而散射限制了成像深度,光学显微成像的分辨率现在已经得到改

进,近年来突破了衍射极限,光声层析成像则突破了扩散的限制。

尽管由于组织的散射会导致光的扩散,通过一个小实验:在黑暗中电筒的光能够穿透手掌,可以证明散射的光子依然能够穿透生物组织。尽管电筒的光是宽带的,但只有红色的光能够大多透过。与 X 射线光子不同,光学的光子透过组织后不会产生骨头的清晰投影,这种现象在生物光子学领域是广为人知的。由于血红蛋白这种生物组织中主要的色团在绿光和蓝光区域有高的吸收系数,因此,红光在被吸收前比更短波长的光传播得更远。此外,组织中的成分(如细胞核、线粒体)的强散射使得任何投影变得模糊。事实上,一个红光的光子可能在被吸收前经历了成百上千次散射。发生相同的各向同性散射的平均距离的倒数被称为传播平均自由程,它在可见光和近红外光谱区域是在 1mm 量级,在传播平均自由程附近光子的传播由弹道区域进入扩散区域。由于在扩散区域无法有效地进行光学聚焦,因此,传播平均自由程被认为是高分辨光学成像的深度软极限。在超过软极限的范围,没有一种纯光学成像能够达到高空间分辨率。尽管散射本身不会导致光子减少,散射导致的曲折的光子前进路径极大增加了光子被吸收的概率。即使是扩散的光子,也很少能达到 50~70mm 的成像深度,这被认为是光学成像的硬极限。

光声层析成像克服了软极限的限制,在深层组织中实现高分辨率成像,超声的散射系数在组织中比相应的光学散射系数的低 2~3 个量级。因此,光声层析成像能够通过探测由于吸收散射光子产生的超声波实现高的空间分辨率。在多数情况下,超声探测系统的中心频率和带宽主要决定着空间分辨率,中心频率和带宽越高,分辨率越高,同时,超声成像的深度会降低,这种尺度可变性使得多尺度成像称为可能。

4. 相关扩展

光声层析成像领域近年来已经产生了显著的蓬勃发展的势头。自从 2003 年以来光声层析成像领域的科研论文以每三年翻一番的速度增长。光声层析成像预计会在生物学和药学研究中找到广泛的应用领域。按照作者的观点,如下的在体应用会有显著的前景并且会在不久的将来取得丰硕的成果:黑色素瘤监测、血管内导管成像、内窥成像、同时的功能和分子成像、报告基因成像、前哨淋巴结成像、乳房成像和多尺度成像^[1]。

参 考 文 献

- [1] Wang L V. Multiscale photoacoustic microscopy and computed tomography. *Nature Photonics*, 2009, 3: 503—509.

- [2] Bell A G .On the production and reproduction of sound by light .Am .J .Sci . ,1880 ,20(118): 305—324 .
- [3] Maslov K ,Stoica G ,et al .In vivo dark-field reflection-mode photoacoustic microscopy .Opt . Lett . ,2005 ,30(6) :625—627 .
- [4] Xu M H ,Wang L H V .Universal back-projection algorithm for photoacoustic computed tomography .Phys .Rev .E ,2005 ,71(1) :016706 .
- [5] Bowen T .Radiation-induced thermoacoustic imaging :United States ,4385634 .1983-05-31 .
- [6] Kruger R A ,Liu P Y .Photoacoustic ultrasound-pulse production and detection in 0.5-percent liposyn .Med .Phys . ,1994 ,21(7) :1179—1184 .
- [7] Wang X D ,Pang Y J ,et al .Noninvasive laser-induced photoacoustic tomography for structural and functional in vivo imaging of the brain .Nature Biotechnology ,2003 ,21(7) :803—806 .
- [8] Zhang H F ,Maslov K ,et al .Functional photoacoustic microscopy for high-resolution and noninvasive in vivo imaging .Nature Biotechnology ,2006 ,24(7) :848—851 .
- [9] Zhang H F ,Maslov K ,et al .In vivo imaging of subcutaneous structures using functional photoacoustic microscopy .Nat .Protoc . ,2007 ,2(4) :797—804 .
- [10] Li M L ,Oh J T ,et al .Simultaneous molecular and hypoxia imaging of brain tumors in vivo using spectroscopic photoacoustic tomography .Proceedings of the IEEE ,2008 ,96(3) : 481—489 .

撰稿人：汪立宏

美国华盛顿大学生物医学工程系

具有大成像深度的光学无损活体生物组织医学成像

Non-destructive Optical Imaging for In Vivo Tissues with Large Detection Depth

1. 背景介绍

生物医学成像,最早可以追溯到 1895 年伦琴发现 X 射线。随后的一二十年中,相继出现了许多对放射成像作出贡献的技术,如增强屏、层析成像技术、旋转阳极管等。20 世纪 70 年代中期,计算机层析成像术引入,该方法是在待测物体周围旋转小型 X 射线源,由检测器阵列测定 X 射线透射量后进行数字化,再利用计算机通过特定的算法(CT 算法)处理取得的数据,并重建断层图像。现在发展较为成熟的层析成像技术主要有三种:计算机层析成像(computed tomography)、超声成像(ultrasonic imaging)和磁共振成像(nuclear magnetic resonance),这三种技术各有其优缺点,CT 技术的成像范围大,但具有潜在的放射性危害。虽然诊断用 X 射线的剂量在这些年来减少了许多,但仍有不少资料表明存在着较小的损害效应,可能增加人体感染一些疾病,如癌、白血病及白内障的概率^[1]。超声成像虽然是无损检测,但分辨率低,对比度差,难以检测到早期病变。而磁共振成像的分辨率虽然较前两者高些,但其造价昂贵,操作复杂。总之,上述方法还不能完全满足科学研究与临床诊断对实时、非侵入性及高分辨率成像的要求(这三种层析图像的分辨率在 $100\mu\text{m}\sim 1\text{mm}$)。

2. 问题描述

无损活体生物组织医学成像技术,即在不损伤活的生物组织的前提下,实现对待测组织内部微结构的三维重构。光学无损活体生物组织医学成像,即利用光与生物组织的相互作用,如反射、散射、吸收、荧光等现象,来提取组织中的相关信息,从而产生基于它们的各种成像方法,重构生物组织内部微结构的图像。其中,分辨率和成像深度是两个极其重要的指标。

目前的光学成像技术,分辨率比 CT 高 2 个数量级左右,但成像深度远不如 CT。因此,如何在现有的高分率基础上,设计基于新原理的光学成像方法,或者发现新的光和生物组织的作用过程,从而极大地增加光学成像的深度至几十甚至上百毫米,是一个亟待解决的难题。

3. 必要说明

利用光与生物组织的相互作用进行成像,一直备受青睐,这是由于光学成像具有对组织干扰小,灵敏度高,信息丰富(可多参数联合测量,这些参数包括结构、频谱、偏振、量子效应和寿命等),可达亚细胞层次分辨率水平,适于离体或活体实时成像,便于与其他技术(如超声)结合使用,以及具备直接治疗的潜能等优点。光与组织的相互作用机制非常丰富,有反射、散射、吸收、荧光等,这些光学现象均可用于提取组织中的相关信息,从而产生基于它们的各种成像方法,使得光学方法成为生物组织成像里研究最为活跃、发展最为迅速的领域。

扩散(漫射)光层析技术(diffuse optical tomography, DOT)是一种新型光学成像技术,它利用组织体在近红外具有的低吸收、高散射的特性,探测重要生理相关的组织光学参数分布。研究还表明,散射系数也在一定程度上反映组织体结构的变化。因此,通过对光学参数的测量,基于扩散光测量的无创或微创检测可以获得人体的生理和病理信息,该方法具有连续实时性、完全无损、高时间分辨率和合理的空间分辨率等特性,可用于组织和血氧水平的可视化实时探测^[1,2]。

光学投影层析成像(optical projection tomography, OPT)技术是一种CT技术和显微技术相结合、能对荧光和非荧光物质进行三维成像的新技术^[3]。根据不同角度下各个断层的投影,经计算机重建得到样品各个断层图像,进而得出整个样品的三维结构^[4]。OPT具有比核磁共振更高的分辨率,可达微米量级;又具有比共焦显微成像更大的成像深度,能够对厚度达十几毫米的样品进行成像。该方法的不足在于需要对样品进行透明处理。

光学显微成像时,分辨率受限于衍射极限,采用高倍物镜来提高分辨率时又存在景深较小的问题,这一矛盾随着激光共焦扫描显微镜(laser confocal scanning microscopy, LCSM)的出现而得以解决。LCSM采用共轭焦点技术,使光源、被照物和探测器处在彼此对应的共轭位置,光源经物镜在样品表面锐聚焦成衍射极限的斑点,其反射光或透射光再次通过物镜或聚光镜在空间滤波器的共焦针孔平面成像^[5,6]。由靠近像面位置的探测器接受光信号。由于光照和探测都限制在样品的一个点,通过对视野内所有的点逐个扫描即能获得样品的整个图像。因而,与传统的显微镜相比,LCSM提高了成像的分辨率,其成像深度在毫米量级。

光学相干层析成像技术^[7](optical coherence tomography, OCT)将低相干干涉仪和外差探测技术结合在一起,利用宽带光源的短程相干特性,以非接触、无损伤方式,对活体生物组织实施断层结构成像,是生物医学成像向非侵入、

高分辨率发展的一个重大突破。OCT 技术的分辨率可达微米量级,成像深度一般在几毫米^[8]。

总的来说,光学成像技术具有高分辨、无损伤等优点,在生物学、医学临床诊断等领域有着广泛的应用。但是,目前的光学成像技术,成像的深度远比 CT、核磁共振等小,一般在几毫米量级。如何改进现有方法或者发明基于新原理的光学成像技术,突破传统光学成像毫米量级的探测深度限制,使之能达到几十毫米甚至上百毫米,对于光学成像的实际临床应用具有重要意义。

4. 相关扩展

在成像技术中,还有一个重要因素,即成像速度。对于活体生物组织(如视网膜)成像,这一点尤其重要。成像时间越短,成像速度越快,才能在最大程度上保证整个生物样品不受环境的影响,以及避免自身活体运动的干扰。传统的很多逐点扫描式光学成像技术,往往需要几个或十几个小时。现在,快速频域 OCT、光谱 OCT 能够一次对整个纵深断面成像,成像时间极大地缩短^[9]。而对于具有大成像深度的光学成像技术,成像速度更会是一个挑战。因此随着成像深度的增加,信号衰减增大,为保证图像质量,需要更多的信号处理过程,这就必然会增加成像的时间,这是需要引起注意的一个方面。

参 考 文 献

- [1] Arridge S R. Optical tomography in medical imaging. *Inverse Problems*, 1999, 15(2): 41—93.
- [2] 关堂兵,赵会娟,郁道银. 扩散光层析技术及其应用. *现代仪器*, 2006, 3: 1—3.
- [3] Sharpe J, Ahlgren U, Perry P, et al. Optical projection tomography as a tool for 3D microscopy and gene expression studies. *Science*, 2002, 296: 541—545.
- [4] 周红仙,王毅. 基于光学投影层析的三维显微成像系统. *佛山科学技术学院学报*, 2005, 23(4): 10—13.
- [5] Wilson T. *Confocal Microscopy*. London: Academic Press, 1990: 1—64.
- [6] 于彦华,邢达. 激光共焦扫描显微镜及其在生物医学中的应用. *激光杂志*, 1999, 20(6): 990614.
- [7] Huang D, et al. Optical coherence tomography. *Science*, 1991, 254.
- [8] 杨亚良. 全场光学相干层析成像研究[博士学位论文]. 杭州: 浙江大学, 2008.
- [9] Wojtkowski M. High-speed optical coherence tomography: Basics and applications. *Appl. Opt.*, 2010, 49: 30—61.

撰稿人: 谈宜东

清华大学精密仪器与机械学系

引力波的激光直接测量

Gravitational Wave Direct Detection by Laser

1. 背景介绍

引力波由爱因斯坦在广义相对论中提出，是物体加速运动时给宇宙时空带来的扰动。通常，引力波强度很弱，但可穿透任何物体，直接探测引力波极为困难，只有非常大的天体才会发出较强的引力波，如超新星爆发或两个黑洞相撞时。到目前为止，人类还未实现引力波的直接测量，对引力波的直接测量不仅可以进一步验证广义相对论的正确性，而且将为人类展现出一幅全新的物质世界图景，同时极大推动对宇宙诞生和时空本质的理解。

2. 问题描述

引力波携带能量使物体产生某种振荡，检测到这些振荡，就能检测到引力波。引力波会造成地面上各处相对距离的变动，但这些变动的数量级小于 10^{-21} ，非常微弱。激光干涉法是测量微小距离变化的最佳手段之一，具有高的测量灵敏度，当引力波经过数公里或更长臂长的干涉仪时，干涉仪的臂长发生微小的改变，从而引起干涉条纹变化。引力波以光速传播，如相隔几千公里的两个激光干涉仪观测站均检测到相关的干涉条纹变化，就能直接证明有引力波穿过激光干涉仪，最终实现引力波测量。图 1 为采用 Michelson 激光干涉仪测量引力波的基本原理组成图，干涉仪两臂长相等，无引力波信号时，探测器方是暗场。当引力波作用干涉仪时，干涉仪两臂长随引力波的频率而变化。干涉臂移动量在探测器一方产生的光强变化量取决于干涉臂的光程，干涉臂越长，由引力波引起的光束相移就越大，探测器的光强变化也就越大。因此，引力波探测激光干涉仪需要长达几公里的干涉臂，并在两臂中使用 F-P 腔增加光束往返光程，加长引力波与光的作用时间，以提高引力波的探测灵敏度。

3. 必要说明

虽然科学家一直在努力探寻宇宙中的引力波，但至今都未实现引力波的直接测量。与此同时，科学家选定观测双星脉冲星的轨道周期变化来间接证实引力波。1974 年，美国天文物理学家泰勒等采用射电仪器的观测手段，发现双星体系(PSR1913+16)轨道周期变慢，其变化数值与按照广义相对论计算理论结果




图1 激光干涉仪测量引力波原理图 (Mp、Ms 为循环镜, BS 为分光镜)

相符,间接证实了引力波的存在。但是,直接测量引力波的方法研究一直在进行,采用激光干涉仪的测量方法被认为是最佳直接测量手段之一^[1]。1994年,美国启动了地面 LIGO 计划^[2],建造了两套臂长均为 4km 的激光干涉仪,它是目前全世界最大的、灵敏度最高的引力波激光干涉探测装置,从 2003 年开始收集数据,在 2009 年的观测实验中实现 100Hz 频率,距离变化探测灵敏度 3×10^{-22} ,从而更精确的锁定了引力波探测范围^[3]。20 世纪末,欧洲和日本分别建立了 EURO 和 LCGT 地面引力波激光干涉测量装置,臂长均为 3km。提高探测灵敏度是激光干涉法测量引力波的关键,探测灵敏度与激光传播距离成正比,为了测量非常微弱的引力波信号,需要进一步增加干涉臂长,同时降低各种噪声干扰源,以实现更低频的引力波测量。21 世纪初,美国和欧洲合作并提出星载激光干涉仪计划 LISA,利用太空的超远距离对引力波进行探测,计划将三对观测仪送入太空,让它们组成超远距离的等边三角形,相邻两对观测仪之间的距离为 500 万公里,让它们在地球后面以 20° 的夹角一起绕太阳运行,三对观测仪之间用激光测量距离,高灵敏的激光能测出一个原子直径大小的位移,由于它们所占的地域比地球上大得多,因此,可以探测到更多的引力波源,灵敏度也更高^[4]。

4. 相关扩展

为了实现引力波的激光直接测量,需要突破高频率和强度稳定的单频相干激光源、抗环境干扰稳定的激光干涉臂、空间超远距离高精度测距等关键技术,实现相对距离变化的探测灵敏度优于 10^{-24} ,最终直接测量引力波。

参 考 文 献

- [1] Abramovici A, Althouse W E, et al. LIGO: The laser interferometer gravitational-wave observatory. Science, 1992, 256: 325—333.
- [2] Rüdiger A. Laser-interferometric gravitational wave detection-on earth and in the heavens. Nuclear Physics B, 1996, 48: 96—100.
- [3] Abbottl B P, Abbottl R, Adhikaril R. LIGO: The laser interferometer gravitational-wave observatory. Rep. Prog. Phys., 2009, 72: 076901.
- [4] Rüdiger A, et al. Gravitational wave detection by laser interferometry-on earth and in space. Space Missions for Fundamental Physics, 2001: 1331—1341.

撰稿人：陈卫标

中国科学院上海光学精密机械研究所

无衍射光束


Diffraction-free Beams

“衍射”现象在光学领域最早由意大利物理学家格里马第首先观察并提出。胡克、牛顿等试图揭示其产生的机理；Huygens、菲涅耳等用数学公式对衍射进行了系统的研究，基尔霍夫等对衍射理论进行完善。时至今日，衍射被认为是光波的本性。


光传播时遇到障碍物发生绕射的现象被称作衍射。当一束准直单色光束在自由空间传播一定距离后，就会出现衍射扩散，且光束越细，衍射扩散越明显。光的衍射对很多实际应用是非常不利的，如激光枪、激光加工、激光准直、激光通信、激光精密测量等领域。于是，人类开始探寻在传播过程中不发生衍射扩散的光束，并形象地称之为“无衍射光束”。

众所周知，光波是一种电磁波，它在自由空间中传播时遵从波动方程。平面波是波动方程最常见的一种解^[1]，在无界的自由空间中传播时，不会发生衍射而使波面畸变，沿传播方向上任何一处的垂直平面上，光强分布都是相同的，这就是最一般的无衍射光束。从理论上来说，满足 Maxwell 自由空间波动方程的解且在自由空间传输保持波形不变的光束均是无衍射光束，如零阶 Bessel 光束、Airy 光束和 Mathieu 光束等。

理论上存在的无衍射光束是否能够实现？为了实现“无衍射光束”，科学家做了许多努力。1983 年，Brittingham^[2]首次从数学上推导出一簇新的 Maxwell 自由空间波动方程的解，它在自由空间中以光速保持聚焦状态无衍射传播，这些解对应的波具有无限能量，理论上是客观存在但无法实际实现。1985 年，Ziolkowski^[3]从自由空间波动方程推出新的精确波包络解，但在光学实验中遇到了困难。1987 年，Durnin^[4]等提出了自由空间标量波动方程零阶 Bessel 函数形式的解，并以实验粗略证明了此解对应的波具有无衍射特性，这种不随传播距离而变化的光束就是(零级)Bessel 光束，简称 Bessel 光束[如图 1(a)所示]。无衍射 Bessel 光束是波动方程在无界空间中的一个特解，是有限域衍射积分方程的一个近似解。1979 年，Berry 和 Balazs 在量子力学的背景下^[5]，理论上推出薛定谔方程具有无衍射的 Airy 波包的解，该波包具有自由加速的特性。2007 年，Siviloglou 和 Christodoulides 首次观察到了 Airy 激光束的实验结果^[6,7][如图 1(b)所示]，验证了 Airy 激光束具有不同寻常的特点，能保持长距离无衍射传播，并具有自由加速的特性，传播过程中具有自愈的特性。除此之外，最近提出的另一类无衍射光束——Mathieu 光束也



(a) 零级 Bessel 无衍射光束



(b) Airy 无衍射光束

图 1

是科技工作者关注的热点^[8]。

理想的无衍射光束是非平方可积的, 即携带无限大能量。实际光学系统的有限孔径使光束在光学实现中必须截断, 光束能量是有限的, 那么, 有限能量的光束是否能够保持无衍射的特性? 目前, 科学家们试图用多种实验方法获得有限束宽, 即携带有限能量的近似无衍射光束(称为赝无衍射光束)。试图在有限束宽一定距离内获得无衍射光束, 并逐渐延长无衍射光束的作用距离。但是, 究竟能够在多长的距离上获得无衍射光束, 是否可以把这个距离延长到无限远处?

一方面, 衍射是光的本性, 另一方面, 人类企图获得无衍射光束, 在无界的空间里理论上存在无衍射光束。但是, 在现实的空间如何实现无衍射光束, 使之能够为人类所利用, 是目前光学及其相关应用领域一个难解之题。

正如人类希望获得无衍射光束一样, 人类克服衍射的另一个意义在于: 衍射影响高分辨光刻和成像, 科技工作者尽力打破衍射极限获得超分辨的成像,

如果打破了现有的衍射极限,光是否有衍射极限?能否实现没有衍射影响的物体净光学成像?

无衍射光束或者无衍射成像是否是人类无法实现的、一厢情愿的追求和梦想?

参 考 文 献

- [1] Born M, Wolf E. Principles of Optics. 7th ed. New York: Pergamon, 1999.
- [2] Brittingham J N. Focus wave modes in homogeneous Maxwell equations: Transverse electric mode. J. Appl. Phys., 1983, 54: 1179—1189.
- [3] Ziolkowski R W. Exact solutions of the wave equation with complex source locations. J. Math. Phys., 1985, 26: 861—863.
- [4] Durnin J, Miceli J J Jr, Eberly J H. Diffraction-free beams. Phys. Rev. Lett., 1987, 58: 1499—1501.
- [5] Berry M V, Balazs N L. Nonspreading wave packets. Am. J. Phys., 1979, 47: 264—267.
- [6] Broky J, Siviloglou G, Dogariu A, et al. Observation of accelerating airy beams. Frontiers in Optics, OSA Technical Digest (CD) (Optical Society of America, 2007), 2007.
- [7] Siviloglou G, Christodoulides A. Accelerating finite energy airy beams. Opt. Lett., 2007, 32: 979—981.
- [8] Bandres M A, Gutierrez-Vega J C, Chfvez-Cerda S. Parabolic nondiffracting optical wave fields. Opt. Lett., 2004, 29: 44—46.

撰稿人: 刘 娟 王涌天
北京理工大学光电学院

红外与微波一体化隐身

Integrated Invisibility of the Infrared and Microwave Wavebands

所谓隐形技术,是改变己方武器装备等目标的各种可探测信息特征,从而降低目标被对方探测系统发现概率的各种技术的统称。利用各种侦察技术获取的目标信息,其物理实质都可看成波。根据工作波段,侦察技术可以分为雷达波侦察、红外侦察、激光侦察等。雷达波侦察及激光侦察分别是从事侦察发射雷达波和激光来实现的,通过分析由目标反射回来的雷达波或激光的特性,判断目标的类型、距离、方位、速度等。因此,这两种侦察技术称为有源侦察。红外侦察技术不需从事侦察点发射红外光波,而是直接接收由目标辐射出的红外波进行侦察,因此,这种侦察技术称为无源侦察。

在雷达波段实现隐身的一个重要方式就是利用铁氧体、铁磁体材料的强吸收来降低武器装备的散射回波,降低被敌方侦测的概率。国外设计定型的产品包括美国的 286E 和 Eccsorb-FGM 型微波吸收材料、英国的 Eccsorb300 型微波吸收材料,在 3cm 和 2cm 波段范围内,雷达波吸收材料厚度在 2mm 以下,面密度在 $5.5\text{kg}/\text{m}^2$ 以下,散射回波小于 -10dB 的吸收带宽可达 $4\sim 7\text{GHz}$,专利报道的水平达 10GHz 。国外报道了纳米多层膜雷达波吸收材料的研究,法国科学家最近研制成功的一种宽带微波吸收涂层,由 CoNi 纳米材料与绝缘层构成,在 $0.1\sim 18\text{GHz}$ 内磁导率的实部(μ')和虚部(μ'')均大于 6,在 $50\text{MHz}\sim 50\text{GHz}$ 内都有一定的吸收性能,据称是目前较好的吸收剂之一,但没有检索到后续装备报道。

随着现代侦察探测技术的飞速发展和精确制导技术的不断完善,战场变得日益“透明”,对隐身技术革新甚至创新的需求迫在眉睫。性能可控的超材料表现出了传统材料无法比拟的输运性能^[1],其显著的特点体现在高透明、高吸收、和无绕射隐形等方面,在军事侦测和隐身技术中都大有用武之地。

红外探测是一种无源探测,是直接接收目标辐射的红外波,或者说是探测目标与背景的红外辐射差异^[2,3]。红外隐形技术就是抑制目标本身产生的红外辐射和制造假目标进行红外干扰,就是为了实现红外无源隐形技术和红外有源干扰技术。一是通过降低和改变目标的红外辐射特征,即采用屏蔽和冷却方法降低目标辐射的红外能量,使敌方探测器难以跟踪,如目标敷以高温隔热材料、飞机遮挡高温尾喷口、降低排气温度等就是基于降低温度,达到隐形的目的。二是红外有源干扰,是有意识地利用红外装置发射红外辐射,人为地施放干扰。美国红外干扰技术发展很快,在战斗机上安装了红外干扰装置,依赖从飞机上

发射诱饵弹进行红外干扰。一些慢速飞行的低空飞机则装有红外干扰器,使其能逼真地模拟飞机发动机喷管和尾焰的红外辐射特征,从而吸引红外制导导弹。苏联的红外干扰技术也取得了很大的成就,已研制出红外诱惑系统,能读出敌方红外传感器信号,对敌方进行欺骗和干扰。因此,新的、更好的隐形技术在国家安全对抗的战略优势起到决定性的作用。

随着侦测技术的飞速发展,对高性能的宽频隐身材料也提出了更高的要求^[4,5]。等离子体是广泛存在于自然界中的一种电中性的电离气体,具有数密度近似相等的自由电子和正离子构成,其产生和运动受电磁场力的作用与支配、对电磁波的传播有很大影响;在国家安全的防御体系建设上起着重要的作用,当雷达波频率低于等离子体频率时,雷达波被全反射,等离子体能以电磁波反射体的形式对雷达进行电子干扰,即通过雷达波往返传播途径弯曲,雷达显示屏上出现的是攻击武器的虚像,而不是真实位置;当雷达频率高于等离子体频率时,雷达波进入等离子体波吸收,从而使雷达接受到目标信号大为减弱^[6~8]。

微波隐身以吸收微波来减少反射率;红外隐身以降低物体表面辐射率、降低物体温度来减少辐射能量,但由于吸收小,则导致对微波吸收能力弱。例如,抛光金属为红外最佳隐身材料,而为微波最佳探测材料^[9]。因此,要实现红外与微波一体化隐身需寻求新隐身方式、新功能材料或新结构材料^[10]。难点在于:同时满足对微波吸收大;对红外吸收小的微波、红外一体化隐身材料,因此,已经成为国际上关注的核心问题。

参 考 文 献

- [1] Schurig D, Mock J J, Justice B J, et al. Metamaterial electromagnetic cloak at microwave frequencies. *Science*, 2006, 314: 977.
- [2] Luebbers R, Hunsberger F P, Kunz K, et al. Piecewise linear recursive convolution FDTD method for magnetized plasmas. *IEEE Trans. on Electromagn. Compat.*, 1990, 32: 222.
- [3] Sullivan D M. Frequency-dependent FDTD methods using Z transforms. *IEEE Trans. on Antennas Propagat.*, 1992, 40: 1223.
- [4] Lee J Y, Myung N H. Multiband characteristics of two fractal antennas. *Microw. Optical Tech. Lett.*, 1999, 23: 245.
- [5] Berenger J R. A perfectly matched layer for the absorption of electromagnetic waves. *Comput. Phys.*, 1994, 114: 185.
- [6] Zhao Y, Belov P A, Hao Y. An elementary proof of the geometrical dependence of the Sagnac effect. *Journal of Optics A—Pure and Applied Optics*, 2007, 9: 468.
- [7] Zhao Y, Hao Y. Finite-difference time-domain study of guided modes in nano-plasmonic

- waveguides .IEEE Trans .on Antennas Propagat . ,2007 ,55 ;3070 .
- [8] Cummer S A ,Popa B I ,Schurig D ,et al .Full-wave simulations of electromagnetic cloaking structures .Phys .Rev .E ,2006 ,74 ;036621 .
- [9] Cai W ,Chettiar U K ,Kildishev A V ,et al .A round-up of recent papers in the field of photonics published by the physical sciences division of the nature publishing group .Nature Photonics ,2007 ,1 ;224 .
- [10] Leonhardt U .Optical conformal mapping .Science ,2006 ,312 ;1777 .

撰稿人：潘建珍 陆 卫
中国科学院上海技术物理研究所

编 后 记

《10000 个科学难题》系列丛书是教育部、科学技术部、中国科学院和国家自然科学基金委员会四部门联合发起的“10000 个科学难题”征集活动的重要成果,是我国相关学科领域知名科学家集体智慧的结晶。征集的难题包括各学科尚未解决的科学问题,特别是学科优先发展问题、前沿问题和国际研究热点问题,也包括在学术上未获得广泛共识、存在一定争议的问题。这次征集的农学、医学、信息科学领域的难题,正如专家们所总结的“一些征集到的难题在相当程度上代表了我国相关学科的一些主要领域的前沿水平”。当然,由于种种原因很难做到在所有研究方向都如此,这是需要今后改进和大家见谅的。

“10000 个科学难题”征集活动是由四部门联合组织在国家层面开展的一个公益性项目,这是一项涉及我国教育界、科技界众多专家学者,为我国教育和科学技术发展、创新型国家建设,特别是科技文化建设添砖加瓦,功在当代、利在千秋、规模宏大、意义深远的工作。数理化难题的圆满成功,天文学、地球科学和生物学领域难题的顺利出版,这六卷书获得的专家好评和社会认同,为农学、医学和信息科学三卷书的撰写提供了宝贵经验。

征集活动开展以来,我们得到了教育部、科学技术部、中国科学院、国家自然科学基金委员会有关领导的大力支持,教育部原副部长赵沁平亲自倡导了这一活动,教育部科学技术司、科学技术部科研条件财务司、中国科学院院士工作局、国家自然科学基金委员会计划局、教育部科学技术委员会秘书处、中国农业大学、浙江大学和北京邮电大学为本次征集活动的顺利开展提供了有力的组织和条件保障。由于此活动工程浩大,线长面广,人员众多,篇幅所限,书中只出现了一部分领导、专家和同志们的名单,还有许多提出了难题但这次未被收录的专家没有提及,还有很多同志默默无闻地做了大量艰苦细致的工作,如教育部科学技术委员会秘书处彭倚天、彭树立、刘超,中国农学大学龚元石、李红军、凌遥、郑艳萍,北京林业大学田振坤,扬州大学房东升,中国水产科学研究院黄海水产研究所刘志鸿,湖南农业大学谭太龙,华中农业大学伍新玲,浙江大学陈昆松、项品辉、章成伟、程术希、蒋国平、曹红翠、杜维波、章益民、吴健,清华大学吴晓爱、孙玉娜,中华预防医学会田传胜,天津中医药大学康立源、薛晓娟,北京邮电大学杨放春、刘杰、李冬梅,北京大学郝丹,哈尔滨工业大学刘明岩及科学出版社王海光、沈红芬、孙芳等,总之,系列丛书的顺利出版是参加这项工作的所有同志共同努力的成果。在此,我们一并深表感谢!

《10000 个科学难题》丛书农、医、信息科学编委会

2011 年 3 月