中国自动化学会通讯

COMMUNICATIONS OF CAA

第 9 期

2022 年 09 月

第43卷 总第228期

主办：中国自动化学会　http: //www.caa.org.cn　E-mail: caa@ia.ac.cn　京内资准字2020–L0052号

中国自动化学会60周年会庆

弘扬科学家精神　奋力推进中国自动化事业高水平发展 / 郑南宁 P004

在中国自动化学会 60 年会庆上的讲话 / 孙优贤 P008

铭记与传承——中国自动化学会六十周年杰出贡献奖隆重颁发 / P009

CAA 中国自动化学会

扫描二维码 关注官方微信

扫描二维码 关注官方微博

中国自动化学会通讯
Communications of CAA

主管单位 中国科学技术协会
主办单位 中国自动化学会
编辑出版 中国自动化学会办公室

主　　编 | 郑南宁　CAA 理事长、中国工程院院士、西安交通大学教授

副 主 编 | 王飞跃　CAA 监事长、中国科学院自动化研究所研究员
杨孟飞　CAA 副理事长、中国科学院院士、中国空间技术研究院研究员
陈俊龙　CAA 副理事长、欧洲科学院院士、华南理工大学教授

编　　委 | （按姓氏笔画排列）
丁进良　王　飞　王占山　王兆魁　王庆林
王　坛　邓　方　石红芳　付　俊　吕金虎
乔　非　尹　峰　刘成林　孙长生　孙长银
孙彦广　孙富春　阳春华　李乐飞　辛景民
张　楠　张　俊　陈积明　易建强　周　杰
赵千川　赵延龙　胡昌华　钟麦英　侯增广
姜　斌　祝　峰　高会军　黄　华　董海荣
韩建达　谢海江　解永春　戴琼海

刊名题字 | 宋　健
地　　址 | 北京市海淀区中关村东路 95 号
邮　　编 | 100190
电　　话 | （010）8254 4542
传　　真 | （010）6252 2248
E-mail：caa@ia.ac.cn
http：//www.caa.org.cn
印刷日期 | 2022 年 9 月 30 日
发行对象 | 中国自动化学会会员及自动化领域科技工作者

关注官方微信　　关注官方微博

本刊声明

◆ 为支持学术争鸣，本刊会登载学术观点彼此相左的不同文章。来稿是否采用并不反映本刊在学术分歧或争论中的立场。每篇文章只反映作者自身的观点，与本刊无涉。

主编的话

郑南宁

自动化是一门涉及学科较多、应用广泛的综合性科学技术，在新技术新思想的推动下，控制科学与工程学科的发展不断吸收其他学科领域的最新成果，已经成为保障和促进现代社会发展和生产力提高的核心科学技术之一。六十年来，广大自动化领域科技工作者前赴后继，创造了一个又一个奇迹，孕育了一大批重大成果，凝聚了一大批科研学者，产生了一大批科技论文，培育了一大批科技期刊，构建了一大批学术研究机构，形成了完善的教育体系。自动化已长成为一棵根基深厚、枝繁叶茂的参天大树，不断交叉融合，孕育产生了许多新兴学科，成为衡量一个国家发展水平和现代化程度的重要标志。

一甲子风云历程，六十载春华秋实。伴随自动化科学技术的发展，中国自动化学会也逐渐发展成为一流科技社团，学会各项业务实现了跨越式发展，取得了诸多辉煌的荣誉，逐步发展成为了拥有近 8 万名会员、58 个分支机构，具有国内外广泛影响力和公信力的现代科技社团。

2022 年 8 月 12 日，中国自动化学会 60 周年会庆活动在云南昆明成功召开。本期通讯聚焦中国自动化学会六十周年会庆活动，为大家分享了中国工程院院士、中国自动化学会理事长、西安交通大学教授郑南宁在活动上的工作报告，及中国工程院院士、中国自动化学会第九届理事会理事长、浙江大学教授孙优贤在论坛上的致辞，并重点介绍了中国自动化学会六十周年杰出贡献奖。

在此向贡献稿件的各位专家学者表示衷心的感谢。六十载砥砺前行，新时代催人奋进。历史启示我们，前进道路从来不是一帆风顺的，但只要有坚定的信念、坚决的行动，必将战胜一切艰难险阻，不断创造历史伟业。站在新的历史起点，中国自动化学会将团结带领广大科技工作者，瞄准世界科技前沿，坚持“四个面向”，发扬科学家精神，勠力同心，笃行不怠，奋力推进我国自动化科技事业自立自强！

[目录] CONTENTS

专题 / Column

004 弘扬科学家精神　奋力推进中国自动化事业高水平发展——中国自动化学会成立六十周年工作报告 / 郑南宁

008 在中国自动化学会 60 年会庆上的讲话（内容节选）/ 孙优贤

009 铭记与传承——中国自动化学会六十周年杰出贡献奖隆重颁发

观点 / Viewpoint

012 王耀南院士：我国智能机器人核心芯片技术发展战略研究

024 王飞跃：元宇宙如何改变一切

学术前沿 / Academic Frontier

028 具有全局速度约束的惯性 / 编码器 / 视觉 / 激光融合定位方法：IEVL-Fusion / 武东杰　仲训昱　崔晓珍　庄明溪　彭侠夫

039 一种基于功用性图的目标推抓技能自监督学习方法 / 吴培良　刘瑞军　毛秉毅　史浩洋　陈雯柏　高国伟

054 解耦表征学习综述 / 文载道　王佳蕊　王小旭　潘　泉

科普园地 / Science Park

079 “魔镜”靠什么辨识每一张脸 / 戴凤智

081 人脸识别技术全面总结：从传统方法到深度学习 /Daniel Saez Trigueros 等

学会动态 / Activities

087 第七期 CAA 会士面对面活动成功召开
088 第十期 CAA 科普大讲堂活动成功召开
089 零距离“对话”人工智能，机器人足球赛“燃翻全场”——扬子晚报苏州小记者走进同济机器人科普教育基地
091 首届新兴技术产业高端圆桌论坛在京召开

党建强会 / Party Building

092 习近平：在复兴之路上坚定前行——《复兴文库》序言
093 张玉卓：在深化系统改革中持续增强科协组织的发展活力

形势通报 / Voice

097 关于新时代进一步加强科学技术普及工作的意见

弘扬科学家精神　奋力推进中国自动化事业高水平发展

——中国自动化学会成立六十周年工作报告

文 / 中国工程院院士、中国自动化学会理事长、西安交通大学教授郑南宁

今天，我们怀着激动和喜悦的心情在这里隆重集会，热烈庆祝中国自动化学会成立 60 周年。首先，我代表中国自动化学会，向莅临此次大会的来宾表示热烈的欢迎！向关心、支持学会工作的各界同仁、自动化及相关领域广大科技工作者表示衷心的感谢！

本次大会是在我国开启全面建设社会主义现代化国家新征程、以实际行动迎接党的二十大的重要时刻召开的一次大会，具有重要的历史意义。会议的主题是：弘扬老一辈科学家精神，奋力推进自动化高水平自立自强，为把我国建设成为世界一流科技强国做出更大贡献。

1956 年，党中央发出“向科学进军”的号召，为贯彻落实科学技术十二年发展远景纲要，在周总理的亲切关怀下，在钱学森、沈尚贤、钟士模、陆元九、郎世俊等老一辈科学家的倡议下，中国自动化学会于 1961 年 11 月 27 日，宣告成立，钱学森任学会第一届理事长。

1978 年，邓小平同志提出“科学技术是第一生产力”的重要论断，中华民族迎来了“历史上最灿烂的科学春天”，中国自动化学会恢复和焕发出了新的生机，中国自动化事业得到了快速发展。

2012 年党的十八来以来，以习近平同志为核心的党中央加强了对科技事业的全面领导；中国自动化学会不忘初心，牢记使命，紧抓机遇，锐意改革，积极创新，昂首阔步迈向新的发展阶段。

六十多年以来，自动化科学与技术不断地将人类从繁重的体力劳动中解放出来，不断地拓展人类认识世界和改造世界的领域，不断地提升人类认识世界和改造世界的能力，成为衡量一个国家发展水平和现代化程度的重要标志。随着科学技术的快速发展和社会需求的日益增长，自动化已经开始并继续将人类从复杂的脑力劳动中解放出来，推动人类社会进入新的智能化时代。经过六十年的发展，中国自动化已长成为一棵根基深厚、枝繁叶茂的参天大树，孕育产生了许多新兴学科，在空天科技、深地深海前沿领域、轨道交通、生物医疗、智慧农业、社会治理等方面发挥着不可替代的作用，取得了重要突破。

第一部分：历史回顾

六十年来，中国自动化学会和中国自动化事业大体上经历了开创发展、追踪发展和加速发展三个阶段。

第一阶段：开创发展期（1961 年至 1976 年）

中国自动化学会成立之初就立足国家发展战略：主动参与国家科委关于自动化科学学科组工作；组建自动化元件及装置等五个专业委员会；创办《自动化学报》等期刊；成为国际自控联的发起成员国之一；以及举办展览会等；为百废待兴的新中国建设与发展贡献了一份力量。

第二阶段：追踪发展期（1977 年至 2012 年）

1978 年，邓小平同志在全国科学大会上做出了“科学技术

是第一生产力”的重要论断，确立了科技工作的指导思想。中国自动化学会迎来了发展的春天，1977 年 9 月学会正式恢复开展学术活动。自此，在宋健、胡启恒、杨嘉墀、陈翰馥、戴汝为、孙优贤等理事长的大力领导下，中国自动化学会已经成长为拥有 4 万余名会员、80 个团体会员、26 个专业委员会的科技社团。

1978 年，学会在太原召开第一次大型学术年会，1979 年复刊《自动化学报》、创刊《机器人》。自 1980 年起逐步增建仿真技术专委会等，全面开展学术交流、学科研究等相关工作。自此学会每年平均举办 40 余次全国性综合或专门领域的学术会议。

学会高度重视国际学术交流活动，1981 年与美国 IEEE 控制系统学会共同主办“中美控制系统学术会议”；1999 年承办国际自动控制联合会（IFAC）第 14 届世界大会等，为提升中国自动化的国际地位做出了重要贡献。

学会积极开展人才培养工作，2007 年与中国宇航学会共同设立杨嘉墀科技奖，组织 RoboCup 机器人世界杯中国赛、高校自动化大赛等自动化系列赛事。学会创办中国自动化产业世纪行活动，推动产学研用协同发展。

第三阶段：加速发展期（2013 年至今）

党的十八大以来，中国自动化学会积极响应党的号召，与时俱进全面深化改革，团结凝聚科技工作者不断促进科技创新、助力经济社会发展、深化国际科技合作，向科学技术的广度和深度进军。

在中国科协的坚强领导下，在中科院自动化所的大力支持下，中国自动化学会在近十年中实现了跨越式发展。学会个人会员数量翻番，现有个人会员近 8 万名，团体会员由 80 家增长至近 300 家，新增 27 个专业委员会、53 个科普教育基地、23 个学会服务站，参与筹建 2 个国际学术组织，荣获“全国科协系统先进集体”称号，获评世界一流科技社团评价“五星级社团”。

第二部分：近十年主要工作与改革创新成果

过去十年，是自动化领域科技工作者砥砺奋进的十年。我国自动化在基础理论、关键技术、产业应用等方面取得了重要进展和重大突破。

过去十年，是中国自动化学会锐意进取的十年。学会坚持党建引领，民主办会，全面深化学会改革，全力打造有温度的科技工作者之家，构筑多层次学术交流和科普格局，引领学科高质量发展，全面提升战略支撑力，助力科技经济深度融合，为自动化、信息与智能科学技术的繁荣发展，为建设世界科技强国做出积极贡献。

一、立根铸魂，以党建促会建，全面推进学会发展。

夯实党建之基。学会自成立以来不断增强全面从严治党的政治自觉，以党的政治建设为统领，不断加强思想建设，建立学会理事长、知名科学家讲党课常态化机制；开展“不忘初心，牢记使命”、学习贯彻党的十九届五中全会精神、喜迎建党百年等专项政治学习活动，用党的创新理论指导学会发展实践。以党的制度建设为保障，制定《中国自动化学会党委工作会议议事规则》等，不断推动学会从严治党向纵深发展，切实发挥党组织的政治引领作用和战斗堡垒作用。

弘扬科学家精神。学会于 2015 年打造“口述历史”系列访谈，深度采访“七一勋章获得者”百岁院士陆元九等与学会建设和学科发展息息相关的老一辈科学家，以科学家精神引领时代风尚。

筑牢党建强会主阵地。自 2012 年至今，学会连续 9 年积极承担中国科协党建强会计划，切实开展“科技精准扶贫”系列活动。“CAA 党员先锋队”的足迹已遍布云南、贵州、甘肃等全国 20 余个地市区，建立 2 所爱心图书馆，8 个智慧教育实验基地，广泛开展助学助教工作，普及科技新知，助力乡村振兴，作为唯

一一家全国性社会组织，入选中国社会组织扶贫 50 佳案例。

深化学会治理结构与治理机制改革。自上而下分工合作、权责明确，创新理事会五级例会制度，形成位阶有序的议事规则；规范分支机构动态管理，推进学会办事机构实体化建设，增强服务能力。

矢志不懈，戮力奋斗。学会党建工作得到了中国科协党委的充分肯定，连续 6 年荣获党建强会项目“优秀组织奖”，2018 年荣获全国学会“星级党组织”称号（八星级），并在建党百年之际被中国科协评为“2018–2020 年度中国科协党建工作先进学会”。

二、以人为本，打造有温度的科技工作者之家

学会充分发挥组织优势，以品牌凝聚人才，以服务温暖人心，以核心价值观引领人才，以信息化平台为手段，全方位、多层次、宽领域服务科技工作者，建设深受广大会员喜爱的科技工作者之家。

以品牌凝聚人才，构筑学术交流高地。搭建高端学术交流平台，打造中国自动化大会等 10 余个品牌学术会议，形成层次清晰的学术交流矩阵。

以服务温暖人心，实施会员精准服务。面向全体会员，学会设立会员服务月，每年定期开展 10 余次专属会员活动；面向女性会员，设立“女性科技工作者发展计划”项目；面向青年会员，全力打造青年菁英系列论坛、钱学森国际杰出科学家讲座等品牌活动；打造 CAA 线上云讲座系列活动；在疫情来袭之际，第一时间向疫情地区会员邮寄口罩等防疫物资，为会员提供有温度的服务。

以核心价值观引领人才，强化人才培养力度。建设科技奖励体系，实现多层次人才评价。此外，学会不断拓宽奖励举荐渠道，2015 年获得直推国家科技奖励资格，经学会推荐的 3 个项目荣获国家科技奖；依托中国科协“青年人才托举工程”，支持 38 位青年人才茁壮成长；广泛开展人才培训和评价，承担国家专业人才知识更新工程，探索工程师能力标准国际互认试点。

以信息化平台为手段，开创智慧学会新局面。以“互联网 +”集成学会优势资源，提升联通能力，建设会员服务系统、学术交流系统、期刊采编系统、奖励系统、组织管理系统和科研动态系统，与学会各项业务工作同频共振。

三、砥砺深耕，坚守学术本源，引领学科高质量发展

中国自动化学会以高端交流平台和高水平科技期刊等为抓手，汇聚国内外顶尖人才，筑牢开放合作基础，突出高端学术引领，建设支撑科技自立自强新高地。

搭建开放交流平台，构建三位一体学术会议体系。学会瞄准世界科技前沿和可持续发展目标，紧扣时代发展主题，构建以中国自动化大会为代表的“综合交叉类学术会议”、以国家机器人发展论坛、国家智能车发展论坛、中国认知计算与混合智能学术大会等为代表的“前沿高端类学术会议”。58 个分支机构面向不同的二级学科建立品牌学术会议。学会每年约召开千余场学术活动，受众人数近两千万人次，交流论文上万余篇，覆盖自动化、信息与智能科学领域的基础研究、技术开发、产业应用和教育等各个方面，有力地助推了自动化、信息与智能科学的自主创新和人才培养。

支撑引领原始创新，加快一流期刊品牌建设。学会紧跟学科发展趋势，大力培育 9 种精品学术期刊，形成一流期刊集群。编制发布高质量科技期刊分级目录，形成《中国自动化学会推荐学术期刊目录（试行）》。

深耕学科发展，积极组织撰写领域学科发展研究。学会连续四年开展“控制科学与工程学科发展研究”，编制《中国控制科学与工程学科史》《自动化学科发展路线图》和《智能控制：方法与应用》，发挥学科战略引领作用，

预判学科发展趋势，推动自动化学科快速发展。

四、精准布局，发挥智库优势，服务科技经济融合发展

中国自动化学会以国家和区域产业发展需求为牵引，把科技共同体人才势能转化为高质量发展动能，为提升国民经济发展水平提供科技支撑。

学会组建多个产业科技服务团，汇聚 200 余位专家学者，走访 50 余个城市，成立 23 家学会服务站、2 个院士工作站，形成 20 余项技术开发合作项目，为产业集群和重点企业提供定制化组合式服务。创办国家机器人发展论坛、等十余个品牌学术活动，构建供需对接信息平台、人才技术赋能平台，形成“成果库”“专家库”“需求库”以及重点技术领域专利信息库，发布《前沿科技领域成果汇编》、《区块链技术前沿热点综述》、《工业控制系统信息安全》等重点领域系列发展报告；开展团体标准制定和科技成果评价工作，完成百余项目技术成果鉴定；开展“智汇中国”平台建设，参与中国科协学术会议成果智库化项目，将学术交流成果有效转化为智库成果；前瞻性提出未来竞争优势的重点布局，为制定科技战略和规划提供依据，为自动化产业及科技社团发展建言献策，突出科技社团治理特色，为党和政府决策服务。

五、肩负使命，合力打造“科普之翼”

中国自动化学会始终肩负传播自动化、信息及智能科学领域新知识、提高全民科学素质的重要使命，积极推动自动化、信息与智能科学领域内科普传播协同化、侧重化、多样化发展。

搭建多主体参与、多样化传播的共建共享平台。组建以科研院所、媒体及企业为主体的科普工作委员会；组建“自动化与人工智能”科普百人团及 9 个科学传播团队；建立 53 家科普教育基地，织密科普工作网络。此外，学会积极参加全国科普日等活动，加强《自动化博览》等科普刊物建设，出版科普书籍；积极探索“互联网 + 科普”新模式，广泛传播领域知识。

构建培养青少年科技人才的开放高地。组织开展了 RoboCupJunior 青少年机器人世界杯中国赛、中国机器人大赛、3E 国际青少年智能与创意设计大赛、世界青少年创客奥林匹克竞赛（WYMOLY）中国赛等系列赛事，组织开展了全国高校青年“自动化与人工智能”知识普及志愿活动。

学会微博进驻科普中国潜力榜，荣获科普新媒体传播飞跃奖，连续多年荣获中国科协“全国学会科普工作优秀单位”称号。

六、开放合作，提升学会国际影响力

中国自动化学会着力构建对外开放新格局，以全球视野谋划和推动学会改革创新，不断提升学会开放合作能力。

搭建国际学术交流平台。学会成功承办 IFAC 第 14 届世界大会、第 23 届世界人工智能国际联合大会、国际智能车大会等 10 余个大型在华国际学术会议，其中学会于 1999 年承办的 IFAC 世界大会是第一次在发展中国家召开的国际自动控制界的一次盛会；世界人工智能国际联合大会是人工智能领域的顶级学术会议，被誉为人工智能界的奥林匹克，是自创办 45 年以来首次落户中国。

提升参与全球科技治理能力。学会参与筹建智能科学与技术协会（AIST）和智能产业促进协会（AAII）；与国际自动控制联合会（IFAC）、电气电子工程师学会（IEEE）、以及国际模式识别学会（IAPR）等建立互惠合作网络。推荐百余位会员当选国际学术组织 Fellow，担任国际学术组织重要领导职务，有力提升了我国自动化的国际影响力和话语权。

第三部分：“十四五”发展设想

今年是实施“十四五”规划的关键之年，中国自动化学会将

继续围绕党和国家的发展大局，以改革创新的精神推进中国特色世界一流科技社团建设；以广大科技工作者为中心，繁荣学术研究和交流，促进开放合作，涵养创新生态；以更加广阔的视野、更强有力的历史担当，团结带领广大科技工作者为中国自动化事业繁荣发展做出更大的贡献。

自动化同仁们！

岁月峥嵘，甲子荣光。广大科技工作者在我国自动化事业的发展道路上留下过辛勤的汗水，谱写过辉煌的篇章。宏图引领未来，使命呼唤担当。站在新的历史起点，中国自动化学会将团结带领广大科技工作者，瞄准世界科技前沿，坚持“四个面向”，发扬科学家精神，勠力同心，奋勇前进，为推进我国自动化事业高水平发展，为使我国真正成为世界自动化和人工智能强国做出更大的贡献！

在中国自动化学会 60 年会庆上的讲话（内容节选）

文 / 中国工程院院士、中国自动化学会第九届理事会理事长、浙江大学教授孙优贤

壮丽六十载，奋斗新时代。从一株幼苗成长为如今枝繁叶茂的参天大树，中国自动化学会在一代又一代自动化人的接续奋斗中砥砺前行，这其中饱含了无数老一辈科学家上下求索的追寻、呕心沥血的奉献；饱含了无数青年科技工作者热情昂扬的奋斗和坚定执着的前行；饱含了全国各界自动化工作人员任劳任怨的付出和勤勤恳恳的奉献。

作为中国自动化学会第九届理事会理事长，看到如今蓬勃发展的中国自动化学会，我感到非常骄傲和自豪。

尤其是这十年来，中国自动化学会在郑南宁理事长的带领下，取得了全方位的、开创性的成就，学会获得了民政部先进社会组织，连续两年蝉联了世界五星级科技社团的称号，这是全国各界自动化学人共同努力的结果。

十年来，中国自动化学会进行了深层次的、根本性的变革，包括提出的一系列新理念新思想新战略，推出的一系列重大举措，开展的一系列重大工作，办成了许多过去想办而没有办成功的大事，推动了学会和自动化事业的繁荣发展。

我们更加欣喜地看到，这十年来，中国自动化学会全面深化改革实现了重大突破，学术引领力、会员凝聚力、战略支撑力、文化传播力、国际影响力实现了跨越式发展，这让我们看到了一个更加团结、更加奋进、更加蓬勃的中国自动化学会。

铭记与传承

——中国自动化学会六十周年杰出贡献奖隆重颁发

中国自动化学会六十周年杰出贡献奖获得者

2022 年 8 月 12 日，2021 中国自动化大会暨中国自动化学会六十周年会庆活动在云南昆明召开，值此甲子华诞之际，学会特别设立“中国自动化学会六十周年杰出贡献奖”，隆重表彰 12 位在自动化学科、产业繁荣、学会建设等方面作出突出成就的老一辈科学家，传承弘扬以他们为代表的创新精神和奉献精神。

中国自动化学会理事长、中国工程院院士西安交通大学郑南宁教授为获奖者颁奖。

中国自动化学会杰出贡献奖授予仪式

CAA 六十周年杰出贡献奖（按年龄排序）

万百五

CAA 第三届理事会常务理事、第四届理事会理事

我国自动化及系统工程专家，在大工业过程递阶稳态优化控制、稳态模型辨识、大工业过程智能控制等方面取得重大成果。

胡启恒

CAA Fellow　第四、五届理事会理事长

中国工程院院士，我国模式识别与人工智能领域最早的探索者之一，推动互联网在中国发展做出了卓越贡献，成为获得全球互联网最高荣誉的首位中国人。作为学会两任理事长，对学会发展做出了突出贡献。

涂序彦

CAA 第三、五、六、七、八届理事会常务理事

我国自动控制和人工智能专家，主持研制了世界上第一个中医专家系统，在国际上首先提出“智能管理”新概念与“多级专家系统”等新方法。连续多届参与学会工作，为学会学术、期刊等发展做出了重要贡献。

王子才

CAA Fellow

中国工程院院士、我国自动控制、系统仿真专家，发展了伺服系统理论，首次研制成功分布式仿真系统，为半物理仿真系统及仿真转台研制及产业化发展作出了重大贡献。

吴　澄

CAA Fellow
第十、十一届理事会特聘顾问

中国工程院院士、我国自动控制专家，领导并参与了中国 CIMS 的研究和应用，为中国企业的技术进步和建立现代管理制度起了示范及引导作用。积极参与学会产学研工作，为提升学会服务科技经济融合能力做出了重要贡献。

熊范纶

CAA Fellow
第六、七、八届理事会常务理事

CAA 会士，国际自动控制联合会 IFAC Fellow。我国智能农业的开创者与奠基人，国际农业人工智能的开拓者之一，并为 CAA 智慧农业专委会的创建发展做出了突出贡献。

王天然

CAA Fellow
第九届理事会副理事长

中国工程院院士、我国机器人与工业自动化专家，在工业机器人关键技术攻关及推进中国机器人技术产业化方面做出了突出成绩。

席裕庚

CAA 第七、八、九届理事会副理事长，
第十、十一届理事会特聘顾问

我国自动控制专家，我国预测控制领域的开拓者，为推动预测控制在我国的传播、研究和应用做出了杰出贡献。

吴启迪

CAA 第九届理事会特聘顾问

我国智能控制专家，长期从事控制理论、控制工程和管理工程领域的教学、科研和管理工作，为国家培养了一大批自动控制领域的人才。

柴天佑

CAA Fellow
第十届理事会副理事长

中国工程院院士、我国控制理论和控制工程专家，为中国控制理论与控制工程学科的发展和中国工业自动化事业做出突出贡献。积极参与学会学科发展与研究工作，为学会学术及期刊发展做出了重要贡献。

桂卫华

CAA Fellow
第十、十一届理事会副理事长

中国工程院院士、我国自动控制专家，为中国有色金属工业的可持续发展和自动化水平的提升，以及中国大型高强度铝合金构件制备重大装备自动化技术水平跨入世界先进行列做出了重要贡献。积极参与奖励工作，为学会奖励规范化发展、提升奖励影响力做出了重要贡献。

王成红

CAA Fellow
第十、十一届理事会副理事长

作为学会副理事长分管组织管理工作，为全面深化学会改革、推动学会各项业务发展、提升学会影响力和公信力做出了重要贡献。时光承载，岁月濡染。历史长河，奔流不息。那些在自动化和中国自动化学会发展长河中做出贡献的杰出科学家，我们需要铭记；同时我们也需要传承，发扬光大“自动化人”的精神，以更加坚定的信念、更加坚决的行动，奋力推进我国自动化科技事业自立自强。

王耀南院士：我国智能机器人核心芯片技术发展战略研究

智能机器人正在引领全球新一轮的科技革命和产业变革。机器人是芯片技术研究的载体，芯片是机器人功能实现的保障。培育并推进我国智能机器人核心芯片技术及产业发展，提出可行的智能机器人自主可控专用芯片技术发展路线，对解决机器人发展的“卡脖子”问题，推动产业优化升级并实现生产力跃升，具有重要的产业价值和战略意义。

中国工程院王耀南院士研究团队在中国工程院院刊《中国工程科学》2022 年第 4 期发表《我国智能机器人核心芯片技术发展战略研究》一文。文章阐述了智能机器人核心芯片技术对于推动技术自主可控、实现经济高质量发展、满足居民美好生活需要、提升国家核心竞争力等方面的重要价值；梳理了相关政策、技术、产业等的国际进展，分析了我国发展智能机器人核心芯片的基础优势和面临的问题；以多架构路线、技术方案比对的方式，论证了我国智能机器人芯片技术发展路线，据此提出领域发展策略，形成面向 2035 的重点任务与发展路线图。文章建议，将智能机器人芯片自主可控发展上升为国家战略，明确顶层设计；设立智能机器人芯片重大科技专项，加大科研经费投入；出台激励智能机器人芯片技术研究和产业应用的政策，牵引产业链升级；落实智能机器人芯片人才培养和发展措施，推动技术及产业健康发展。

一、前言

智能机器人作为新一轮科技革命和产业革命的代表性成果，其研发与制造涉及人工智能、机械工程、控制论、材料、计算机等多学科领域，产业链覆盖面广、带动性强，是推动我国工业、农业、国防等各大行业转型升级的战略性产业，也是衡量国家科技创新实力的重要标志。随着智能机器人逐渐融入到人类的生产与生活中，其面临的环境愈发多样，从事的任务愈发复杂，高可靠、高动态、强对抗的应用需求对智能机器人的算法与算力提出了高要求，但我国在机器人所需的核心高性能芯片领域仍相对薄弱，核心部件的自主研发生产能力与国际领先水平相差较大，算力、稳定性和集成化程度等方面表现不佳。伴随着国际形势日益严峻，中美贸易摩擦升级，逆全球化趋势愈演愈烈，加强国产制造能力，掌握新兴产业主导权，实现智能

机器人芯片技术及其产业链的自主可控刻不容缓。

目前，我国智能机器人核心芯片领域的研究仍处于起步阶段，制定合理的战略规划对于其发展具有至关重要的作用。已有研究较为系统地梳理了智能机器人与芯片技术的发展现状并提出发展策略建议。相关研究围绕当前人工智能核心软硬件在技术、产业和政策的发展情况，梳理总结了我国面临的生态体系不完整、基础理论研究存在短板、创新环境不完善等问题，为其技术和产业发展提出了思路与目标。瞄准陆空协同多模态智能机器人，分析了该种机器人的发展现状，指出其缺乏系统的发展规划，没有形成全链条式的发展模式，软硬件结合度不够等问题，并给出相应发展建议。对人工智能芯片的概念、分类、发展历程进行介绍，对其产业发展现状与趋势进行调研与判别，并围绕人工智能芯片产业发展提出了建议。“先进半导体材料及辅助材料”编写组提出了半导体材料与辅助材料的体系化发展、上下游协同发展与可持续发展思路，形成了集成电路发展的相关对策建议。工业和信息化部、发展和改革委员会、科学技术部等 15 个部门联合印发了《“十四五”机器人产业发展规划》，为我国智能机器人产业提供了发展路线指引。

机器人是芯片技术研究的载体，芯片是机器人功能实现的保障，两者发展具有深刻的内在联系，这是当前研究未能深入探讨之处。为此，中国工程院及时针对智能机器人核心芯片自主可控发展的全局性和关键性问题，启动了相关研究，旨在梳理战略规划、论证技术路径、提出技术方案。本文分析了智能机器人核心芯片的重要价值与国际进展，总结我国的基础优势与面临的问题，着重论证技术发展路线并提出面向 2035 年的发展路线图，以期为国家产业政策、技术规划、技术攻关等研究提供参考。

二、智能机器人核心芯片发展的战略意义

智能机器人核心芯片是一种专门用于实现感知、控制、导航、决策、规划等机器人计算功能的高性能处理器，是机器人在复杂环境完成各类作业任务的关键。通过对智能机器人核心芯片技术发展战略的研究，能够为相关技术的研究提供思路，推动技术链、产业链的自主可控，促进经济高质量发展。

（一）推动技术自主可控的重要赛道

目前智能机器人核心芯片产业面临着严重的内忧外患。内忧在于机器人芯片产业链核心技术严重不足，国产化率很低，国内芯片封装测试初步可控，但设计与制造等高端环节自主可控率严重不足；外患在于目前大国博弈的国际形势，西方国家对我国高端设备、材料与技术进行封锁，对先进芯片实施禁运，以遏制中国的发展。因此，亟需开展智能机器人核心芯片技术方案论证，根据算法模型特点设计芯片计算架构，根据计算架构优化算法模型与编译，以实现高性能、低功耗、低延时的目标，推动“直道追赶”和“换道超车”双线并行，积极抢占集成电路技术创新竞争高地，增强智能机器人核心芯片技术链、产业链自主可控能力。

（二）实现经济高质量发展的重要支撑

智能机器人是集成众多领域技术的高端装备，是产业间技术融合和创新的产物，核心芯片技术的发展能够提升智能机器人的作业能力与适应能力，进一步释放智能机器人的需求，从而带动整条产业链的技术升级和产品结构优化，对实体经济振兴起到明显效果，进而成为经济脱虚向实的重要手段。大力发展智能机器人及其核心芯片技术能够带动制造业的全面提升，成为制造强国建设的突破口。此外，作为信息革命的代表性产业，智能机器人核心芯片产业的发展能够进一步整合大数据、云计算、物联网，

5G 通信等新兴技术，构建新型工业体系，成为推动我国经济高质量发展的“火车头”。

（三）满足人民对美好生活需要的重要保障

我国社会的主要矛盾已转化为人民日益增长的美好生活需要和不平衡不充分发展之间的矛盾。智能机器人核心芯片技术的发展能够提升智能机器人的应用范围，大大提升社会生产力，将人民从重复机械性劳动中解脱出来，创造更多更高层次与质量的工作岗位；智能机器人适应性的提升也能加大特种作业需求，使人远离危险作业任务，如何在消防、治安、搜救、排爆等工作中发挥出重要作用；智能机器人的大规模利用能够有效提升生产效率，从而减少生产过程中的消耗和污染。推动智能机器人产业的发展，能够有效节约资源、减少排放，成为建设“两型社会”的重要支撑。

（四）提升国家核心竞争力的重要载体

大力推进智能机器人核心芯片技术与产业的发展，有助于保障我国国防安全、抢占全球科技制高点，从而有效提升国家核心竞争力。目前无人化战争已逐步成为现代战争的主流，无人系统作为一类具备自主移动能力的智能机器人，其态势感知、规划决策、多机协同、运动控制等都离不开智能机器人核心芯片的计算处理能力，本项目的研究有助于推动军事智能化的发展，推动我国国防现代化进程。而机器人核心芯片作为新一轮科技革命的典型产品，是衡量国家科技创新实力的重要标志，目前我国在这个方面具有很大的发展潜力，大力发展机器人核心芯片能够快速推动我国相关高技术产业发展，提升国家核心竞争力。

三、智能机器人核心芯片的国际发展现状

（一）政策规划方面

近年来，全球性的芯片短缺给所有智能化产业都带来了严重的影响，世界各主要发达国家和地区针对芯片发展制定了一系列政策规划，围绕技术革新、接口标准、财政计划等全面布局，抢占芯片技术发展主导权。

美国 2020 年推出《2020 美国晶圆代工法案》，建议国会收紧芯片制造技术的瓶颈，以防止中国在未来几年内超越美国。随后又推出《2021 年美国创新与竞争法案》（USICA）主张对我国采取强硬的反制措施，提高美国与中国科技竞争的能力。欧盟委员会 2020 年发表了《欧洲处理器和半导体科技计划联合声明》，预计投入 1450 亿欧元助力半导体产业发展。日本 2020 年发布了“绿色增长战略”，将半导体产业作为重点发展领域。韩国 2020 年宣布，将在未来 5 年内投资 950 万美元，发展 5 nm 以下半导体光刻工艺的材料技术。

各传统芯片强国意图依靠其丰富的经验，强大的创新能力，以及雄厚的经济实力，在政策法规的引导下，凭借国家战略达成各方共识，将优势资源引导至芯片领域，从而引领新一轮科技革命，进一步加强其竞争优势。

（二）技术方面

在新一轮科技革命的浪潮中，机器人的应用场景与作业需求日益复杂，对其环境感知、决策规划、导航定位、运动控制的算法算力提出了更高的要求。目前基于通用嵌入式处理器和可编程逻辑控制器的计算系统，不能满足未来机器人的感知能力、认知能力、灵敏运动能力需求。因此，亟需研发新形势下机器人核心芯片，融合最新的人工智能算法，提升机器人智能自主能力。

在机器人智能算法方面，人工智能的赋能带来了突飞猛进式的发展：

① 人工智能提高环境感知效率。面向目标识别，提出了诸如 SSD、YOLO、R-CNN 等系列经典框架，让智能机器人可以模拟人类大脑的计算方式，依靠多层卷积神经网络大幅增强感知环境能力；

② 人工智能提升规划决策能

力。人工智能技术的迅速发展大大提升了智能机器人规划决策的自主性，面向高动态、高复杂、强对抗环境依然能够正常开展作业任务；

③ 人工智能强化多机协同能力。以“机动能量和信息互联”为基础、围绕“模型算法与数据计算”的核心，智能机器人能够实现自主作业为主，人机协同、机机协同的合作，这将成为未来智能机器人运用的主要方式。人工智能技术在互操作、自主决策、集群控制算法等方面提供了强大的技术支撑。

在智能机器人计算硬件方面，正面临摩尔定律失效的问题，并逐步朝着高能效、专用化、定制化等多元方向发展：

① 在通用人工智能芯片架构上，逐渐向类脑化和神经形态演化。2019 年清华大学发布全球首款异构融合类脑芯片——“天机”，让自行车真正实现自动行驶，登上 Nature 封面；

② 在制造工艺上，芯片制造进入原子时代。2021 年湖南大学、韩国三星高等技术研究院等在 Nature 上发表综述文章，文章讨论了二维半导体和传统三维半导体的关键材料参数，总结了推动二维晶体管极限的途径；

③ 在芯片设计上，未来人工智能（AI）自动设计或将实现。2021 年谷歌大脑团队联合斯坦福大学在 Nature 上发表一篇论文，基于 AI 的芯片设计方法进行了改进，并将其应用于 Google I/O 2021 大会上正式发布的下一代张量处理单元（TPU v4）加速器的产品中。

在机器人智能算法与芯片硬件融合方面，类脑芯片是一种具有天然高能效优势的智能算法实体化解决方案。众所周知，算法、算力与数据是人工智能技术发展的三架马车，人工智能技术的引入增强了机器人的算法效能，各类传感器为机器人引入了海量的数据，类脑芯片的出现成为了承接算法与数据的载体。智能机器人芯片信息处理单元的架构也逐渐向仿生大脑结构的方向转变，“存算一体”的类脑芯片成为了人工智能技术创新的基础，在运行一些智能算法上具有高能效优势。其底端的非易失性核心器件也正逐步取代易失性核心器件，从而更好地实现非结构化环境和复杂任务的智能计算功能。

（三）产业方面

智能机器人核心芯片技术涉及到半导体、机器人以及人工智能等多个产业。在半导体领域，加工制造设备的市场集中度较高，荷兰、美国、日本的企业垄断了全球芯片制造市场超过 9 成的份额。在芯片产业链上，国外整体上都处于强势地位，在芯片设计、制造、封测上中下三个主要环节都占据着主导地位。机器人方面，目前工业机器人巨头企业主要集中在日本、美国、德国等工业发达国家。

因此，国际上智能机器人核心芯片产业已经形成了一系列商业化平台。2017 年 11 月，英特尔中国研究院正式发布 HERO 机器人平台，是专为智能机器人（包括服务机器人、医疗机器人、自动驾驶汽车等）打造的一套低功耗、高性能、体积小的异构系统平台方案。在该方案中，中央处理器（CPU）作为控制中心，与现场可编程逻辑门阵列（FPGA）和其他专用加速器芯片搭配，能够提供优异的性能。2018 年 12 月，英伟达发布世界首款专为机器人设计的芯片 Jetson AGX Xavier。作为首款专为自主机器设计的计算机，Jetson AGX Xavier 的性能足以完成视觉测距、传感器融合、定位与建图、障碍物检测以及对新一代机器人至关重要的路线规划等任务。2020 年 6 月，美国高通推出迭代产品机器人 RB5 平台，成为高通专为机器人设计的最先进和高集成度整体解决方案，其在 RB3 基础上提供了丰富的硬件、软件和开发工具组合，助力开发者与厂商研制具有低功耗、高算力的下一代智能机器人，满足消费级、企业级、工业级以及专业服务领域的要求。

四、我国发展智能机器人核心芯片的基础优势及面临的问题

（一）基础优势

1. 我国积极营造智能机器人核心芯片发展环境

国家历来重视基础科技和高新技术产业的发展，在历次国家顶层宏观政策中，都重点突出对机器人 / 芯片等高新技术产业的支持。2021 年 3 月发布的《中华人民共和国国民经济和社会发展第十四个五年规划和 2035 年远景目标纲要》中更是提出在科技前沿领域要攻关集成电路技术，推动集成电路、机器人等产业创新发展，提升制造业核心竞争力。与此同时，国家相关部委也在专项规划、政策扶持、进出口投资、区域发展和产业配套等方面提出了一系列政策文件，为国内机器人 / 芯片产业发展培育市场和人才提供政策与资金保障。相较于其他国家，中国特色社会主义制度也能够最大限度地整合社会资源，通过宏观调控、政策规划、金融财政等手段集中力量办大事，为智能机器人核心芯片发展保驾护航。

2. 我国巨大的内需市场为智能机器人核心芯片发展提供强大动力

目前我国芯片市场规模正在扩大，芯片产值逐年增加。统计显示，在过去的五年时间中，我国芯片产业年复合增值率超过了 21%，达到了同期全球增速的近 5 倍。依据世界半导体行业协会的统计，我国市场规模实现了跨越式的快速增长，市场份额达到了 50.7%，高居全球第一。中国已经成为了全球芯片市场不可或缺的重要组成。据有关部门统计，近年来我国机器人产业体系年均复合增长率超过 15%，产业规模也已突破 1000 亿元。而集成应用的大幅拓展，使得国内制造业机器人密度早在 2019 年就已达到 187 台 / 万人，明显高于全球平均水平。在服务机器人领域，市场扩张速度更加迅猛。据相关资料显示，2013—2021 年全球服务机器人销售额年均复合增长率为 19.2%，2021 年其所占机器人市场的比重就已达 36%。巨大的内需市场是智能机器人核心芯片产业发展的最强动力。

3. 我国拥有最为完整的工业体系，具备良好的产业基础

中国是全球最大的制造业国家，工业门类齐全，拥有联合国工业分类中 39 个工业大类、191 个工业中类、525 个工业小类的完整工业体系，产值规模高居世界第一。完整的工业体系能够大大降低生产成本，提高生产效率，为智能机器人核心芯片产业的发展提供底层支撑。芯片关联产业尤其是机器人产业链水平持续提升，我国机器人产业规模得到快速增长并已初步形成较为完整的机器人产业体系，机器人行业发展水平已进入世界第一方阵，随着中国 5G、人工智能、云计算等“新基建”的快速发展，将进一步加快智能机器人核心芯片产业的发展。

4. 我国高学位的“人口红利”，形成独特的人力资源优势

我国在科学、技术、工程和数学领域（STEM）的毕业生常年高居世界首位，据《中国科技人才发展报告（2020）》显示，我国研究与试验发展人员数量快速增长，年均增速超过 7%，截至 2020 年，人数达到了 509.2 万，连续多年居世界第一。《中国集成电路产业人才白皮书（2019—2020 年版）》的统计显示，截至 2019 年年底，中国集成电路行业的直接从业人员规模达到了 51.19 万人。根据当前的发展态势以及人均产值计算，截至 2022 年年底，该行业人才需求将突破 74.45 万人。2021 年国内各大高校集成电路学院也如雨后春笋般成立，其中包括多所国家“双一流”建设高校。从中长期看，基于持续的工程师红利和世界前列的人工智能技术优势，中国有望比肩发达国家，引领未来机器人及芯片产业的发展。

5. 国内智能机器人芯片产业迈出升级新步伐

近年来，我国机器人核心芯片产业在政策支持与市场需求的带动下正快速发展。目前国内在

芯片设计、芯片制造和机器人应用等方面涌现了一批优秀企业。芯片设计领域是国内发展最成熟，技术最全面，也是和国际一流水平最接近的领域。主要有深圳市海思半导体有限公司、中科寒武纪科技股份有限公司、北京地平线机器人技术研发有限公司等芯片设计公司。在芯片制造领域我国与世界领先水平还存在较大差距，但也在这个领域站稳了脚跟，目前中芯国际集成电路制造（上海）有限公司、上海华虹（集团）有限公司和合肥晶和集成电路股份有限公司三家公司位列全球芯片制造代工企业十强。在机器人领域我国也有长足的进步，随着市场进一步扩增，政策、研发投入力度持续加大，我国机器人发展迅速走强，出现了深圳市大疆创新科技有限公司、埃夫特智能装备股份有限公司，沈阳新松机器人自动化股份有限公司等一大批领域内的优秀企业。这些公司的快速发展，展示了我国智能机器人芯片产业迈出新步伐。

（二）面临要问题

虽然我国在智能机器人核心芯片方面已经取得了显著的成效，但对比全球产业同期发展现状，为实现相关技术、产业自主可控，仍然存在着一系列问题需要克服。

1. 针对性的顶层设计缺失，战略目标不清晰

国家全局的顶层战略如“全面深化改革”“中国制造 2025”“十四五规划”均对智能机器人芯片发展具有重要意义。然而，智能机器人芯片由于与机器人技术以及芯片技术关系紧密，具有其独特的发展规律，上述国家全局战略对于智能机器人芯片领域发展难以起到精准战略指导作用。近几年，国家陆续出台多项政策支持机器人和人工智能芯片产业发展，尤其是 2009 年后政府明显加快了政策措施出台速度和力度，从顶层设计、财税金融、示范应用、人才培养等多角度发力支持机器人产业发展，政策叠加效应为我国机器人产业营造了良好的发展氛围。然而，各部委制定的机器人和人工智能产业政策与当前智能机器人以及其核心芯片的关联性不完全匹配，缺乏针对智能机器人芯片的指向性政策，难以起到整体战略的引领作用。

2. 多个技术环节自主可控率普遍较低，受制于人

国外智能机器人芯片的设计、制造、测试、生态构建等，由于发展较早，技术壁垒较高，而国内起步较晚，且严重依赖进口，关键核心环节难以实现自主可控，诸多方面技术难题亟需突破。主要问题在于平台核心支撑能力不足，缺少支撑智能机器人芯片技术跨领域、跨行业的互联互通的平台和集成开发环境；核心软硬件产业基础薄弱，对国外产品依赖度高，特别是电子设计自动化（EDA）、知识产权（IP）核、光刻机、硅晶圆、光刻胶等环节产业基础薄弱，自主可控率非常低（≤ 5%），几乎全部依赖进口；当前我国芯片设计业发展迅速但总体小而分散，仅有三家公司营收过百亿，与国际领先的高通公司、博通公司超 1000 亿元的营收差距依旧很大，存在着多而不强，大而不强，快而不优的问题，制约了智能机器人系统芯片技术的发展。

3. 高层次人才短缺严重，学科发展不平衡

随着芯片行业的持续发展，我国迫切需要一大批芯片行业领军者。但由于各种内外因素，特别是外国政府和领先的国际企业的限制。海外的高层次领军人才很少回国效力。国内高层次人才短缺严重的原因一方面是由于国内芯片产业发展时间段，经验不足，在技术创新、产品研发、制造管理等方面的产业人才缺乏；另一方面是芯片专业的人才培养需要雄厚的学术基础，开设相关专业的师资队伍不齐全，没有足够数量的高校，难以有效满足快速扩张的芯片制造企业对人才的庞大需求。

4. 各行业环节发展不均衡，核心技术储备不足

我国智能机器人芯片企业普

遍弱小而分散，产品线少，资金实力不强，未形成合力，综合竞争力远弱于国外芯片企业，并且国内产品仍然主要集中在中低端市场，很多高端芯片核心技术仍待攻关突破和创新引领。国内在智能机器人芯片 EDA 设计工具、芯片体系架构、芯片制造工艺、关键原材料以及软硬件生态等芯片产业链核心环节，尚无法脱离国外核心技术，尤其是高端芯片 EDA 设计工具与高工艺光刻机必须依赖进口，国内在打通整个智能机器人芯片产业链方面还有很长一段路要走。

五、我国智能机器人核心芯片技术发展路线论证分析

智能机器人有相对发达的“大脑”，在脑中起主要作用的是 CPU。智能机器人智能程度的提高依赖于芯片处理能力的增强，现实是我国智能机器人系统芯片，特别是处理功能芯片等关键部件存在自给率低、性能不高等突出问题。因此，提出可行的智能机器人自主可控专用芯片技术发展路线，对解决机器人发展的“卡脖子”问题，提高我国机器人的智能化和安全性具有重要的产业价值和战略意义。

（一）技术体系框架

本文从智能机器人处理功能的芯片纯设计方面着手，进行算法芯片化设计技术体系规划。该技术体系建议：从现有技术基础（科学研究和产业技术）出发，剖析机器人关键算法，澄清关键算法芯片化技术，结合特定应用领域技术，开展算法、电路、架构、系统的软硬件协同设计研究，在技术节点不占优势的前提下，通过其他层面的变革性创新实现系统性能提升，并试图找到我国智能机器人系统芯片自主可控发展的最优方案。

（二）多架构路线全面推进智能机器人核心芯片发展

算法是决定机器人功能的重要因素，如果把机器人与人类比，可以说算法相当于人类的智慧与灵魂思想。按照功能类别来分，主流机器人算法主要可分为感知算法、规划算法、控制算法等几类。未来的智能机器人发展需要先进的算法，同时应着重于芯片的能效比，因此，通过软硬件协同的算法芯片化设计是趋势，也是以差异化方式实现我国智能机器人系统芯片自主可控的必经途径。

为推动智能机器人核心芯片发展，建议采用以下几类处理技术体系模式（异构并行方式）的并行发展路线。CPU 作为计算系统（智能机器人也属于一种计算系统）的运算和控制核心，是信息处理、程序运行的最终执行单元，它是对系统内的所有硬件资源进行控制调配、执行通用运算的核心硬件单元。本文从处理角度出发，所有技术路线都包含 CPU 作为主处理器。其中，图形处理器（GPU）、FPGA 均是前期较为成熟的芯片架构，属于通用型芯片。专用集成电路（ASIC）属于为 AI 特定场景定制的芯片，可将 ASIC 分为全数字 ASIC AI 芯片和数模混合存算一体 AI 芯片。

1. 路线 1：CPU 主处理器 + GPU 协处理器

AI 算法均可以通过 CPU 实现，但 CPU 缺乏并行性，对于 AI 算法中需要大量的并行计算方式并不友好。GPU 则具备并行的处理能力，也是目前实现 AI 计算最广泛的方式。

2. 路线 2：CPU 主处理器 + FPGA 协处理器

FPGA 可设计为非冯·诺依曼架构，使得其在运算单元和存储单元间的信息交换量大幅降低，因此具有流水线处理和响应迅速的特点。

3. 路线 3：CPU 主处理器 + ASIC 协处理器

AI 算法稳定后，AI 芯片可采用 ASIC 设计方法进行全定制，使性能、功耗和面积等指标面向深度学习算法做到最优。

（1）路线3.1：CPU主处理器+全数字 ASIC AI 协处理器。AI 算法中很多的乘累加操作（MAC）可采用“类存算一体”方式进行全数字 ASIC 设计，具有更高的能效性能。

（2）路线 3.2：CPU 主处理器 + 数模混合存算一体 AI 协处理器。通用处理架构存在冯·诺依曼瓶颈，即运算与存储分离，导致大部分的能量消耗在运算单元和存储单元的通信上。成熟非易失性存储器件或新兴非易失性存储器件结合交叉阵列架构具有天然的一步实现 AI 算法中密集的 MAC 操作的特性，从而具有实现完全“存算一体”新计算范式的能力。

（三）技术路径与技术方案分析

分析智能机器人系统芯片技术路线，其实就是分析路线中协处理器运行 AI 算法的特点和他们的自主程度，智能机器人系统芯片自主可控技术路线分析如下。

1. 路线 1：CPU 主处理器 + GPU 协处理器

该路线是目前最成熟、最易于实现相对自主可控的方式，短期可通过自研算法实现相对自主可控，长期需自研芯片实现自主可控。但也应该注意存在一定的风险，因为国产 CPU 没有自主指令集系统，并不能说是完全的自主可控产品，而景嘉微电子股份有限公司作为唯一的自主 GPU 生产商，竞争风险过于集中。

CPU 和 GPU 都是通用处理器，技术成熟，国外有先发优势，国内受到严重的技术限制，国内外差距大。虽然在该技术路线上很容易被“卡脖子”，但在该技术路线上实现智能机器人芯片自主可控非常有必要：一是反哺增强 CPU 和 GPU 的自主可控能力；二是结合特定应用实现协同优化提高智能机器人芯片的安全性和智能性。这也是在现阶段基础上最现实的技术路线，针对特定应用场景，依靠自研算法提升性能，有利于 AI 算法技术的提升，以“直道追赶 + 差异化应用”方式突破封锁。

2. 路线 2：CPU 主处理器 + FPGA 协处理器

理论上，FPGA 可以实现任意 ASIC 和数字信号处理（DSP）的逻辑功能。而实际应用中，开发人员可通过 FPGA 的 EDA 软件来修改芯片，而不是替换和重新设计芯片。FPGA 的开发流程不涉及掩模和流片等步骤，使得开发周期可以缩减。在当前 AI 企业级应用中，FPGA 占据了主导地位。

FPGA 流片成本高昂，实现同样的 AI 应用，制作 FPGA 芯片的成本可能会超过 ASIC 的成本 10 倍以上。为适应下游用户复杂多样的需求和应用，FPGA 的门电路集成度往往很高，然而具体到某一应用，冗余的门电路会提升 FPGA 的功耗。在功耗敏感的领域中，这是非常致命的缺陷。而另一方面，作为 AI 算法 ASIC 芯片化的前期验证路线，FPGA 具有较短的研究周期和较低的成本。

3. 路线 3：CPU 主处理器 + ASIC 协处理器

路线 3.1 属于电路级“存算一体”路线，即用数字“类存算一体”方式实现 MAC 操作，相对于路线 3.2，该路线实现稳定性较高，但并行性和能效比要低。

路线 3.2 是器件级“存算一体”路线，即采用的固定存储器（NVM）本身具有存储和计算功能，这些器件结合 Crossbar array 架构在 MAC 操作上具有天然的优势，并且单位器件可具有多级状态，发展潜力巨大。两种 ASIC AI 芯片技术路线具有针对特定应用执行智能机器人边缘（在机器人领域，这里边缘指代近感知端）部署的潜力，简单的任务可以自行处理，提高系统效率。国外 AI 芯片尚未形成明显压倒性优势，国内起步不算晚，国外尚未完全形成技术垄断，有利于在工艺制程技术不占优势的基础上实现系统性能的超越。

总体上，在成熟度方面：路线 1> 路线 2> 路线 3.1> 路线 3.2（能效比 / 自主可控）；在潜力方面：路线 3.2> 路线 3.1> 路线 2> 路线 1（见表 1）。虽然路线 3 的成熟度相对较低，但也意味着该领域存在着更多的技术自主可控机会，在这些领域也涌现了有代表性的中国公司。建议加大力度布局前沿技术研究，实现“换道超车”。同时，在通用芯片领域受限于摩尔定律放缓，而机器学习

规模指数级增长的机遇下，紧抓高端芯片先进工艺制程关键、核心技术攻关，由“直道追赶”到“直道赶超”。全面布局，为实现智能机器人系统芯片自主可控打下坚实的基础。

六、我国智能机器人核心芯片发展思路、重点任务与战略目标

（一）基本策略

紧密围绕解决智能机器人芯片“卡脖子”难题，服务我国科技稳步快速发展的总目标，在分析总结国内外芯片产业发展态势、发展方向，调研我国在机器人芯片领域所存在的优势和不足的基础上，提出以下五个方面的发展思路。

直面困难，自力更生。当前国际形势风云变幻，国家安全和发展环境复杂多变，未来一个时期又是我国实现中华民族伟大复兴的关键期，对我国各个领域的科技支撑能力提出了更高的要求。我国智能机器人芯片发展战略首要就是在当前时代背景和国际环境下，正视我国在芯片领域面临的“卡脖子”问题。自觉践行和大力弘扬“两弹一星”精神、载人航天精神等新时代科学家精神。制定长期发展战略，做好打持久战的准备，举国家之力，打破国外对高端芯片的技术封锁，实现新时代科技新长征的最终胜利。

顶层设计，战略布局。智能机器人芯片产业的发展与机器人技术、机器人应用技术、芯片产业、芯片应用产业等诸多行业密切相关，关乎我国国防装备、工业生产、居民生活等方方面面。需真正从国家的高度对机器人芯片的发展提出纲领性、统揽性的谋划。不能将该领域的发展寄希望于外来的技术支持，寄希望于设备的进口，而是将其作为国家科技重要支柱性产业来抓。做好从基础理论研究、关键技术突破到产业应用落地的全链条总体规划，注重对国家长期发展的支持。

强调整体，重点突破。机器人芯片产业的发展是涉及面广、影响力大、关联性强、制约关系复杂的系统工程，某一环节不足很容易形成木桶效应。发展自主可控的智能机器人芯片需要重视其相关各方面的有机联系，做到整体推进。同时，系统工程需要重点突破，善于抓“牛鼻子”，找突破点，或“剥茧抽丝”，或“快刀斩乱麻”，方式方法得当，就能起到“四两拨千金”的作用。

夯实基础，扩大优势。近几十年，我国机器人、芯片等领域的技术及应用更多是规模上“量”的增长，走的是“买来主义”路线，实际的机器人芯片基本技术和工艺，高端芯片的设计研究和应用虽有进步，但跟国外先进水平还有很大差距。要实现关键技术自主可控的转变，需要充分挖掘和发挥我国所具有的集中力量办大事体制优势，继续扩大我国在市场需求、生产加工、人才储备、基础设施建设等方面的发展优势，尤其注重在全球竞争的环境中扬长避短，积极抢占新一轮科技与产业的制高点。

深耕本土，面向世界。我国拥有世界最大的智能机器人芯片既有市场和潜在市场，这成为我国芯片发展的不竭动力。我国芯片产业应该充分立足本国市场，挖掘好本国需求，发挥好本土优势，从本土市场起步才能最终走向世界。同时我国科技与社会发

表 1　技术路径特点与比较分析

路线	成熟度	潜力（能效比 / 自主可控）	协处理器芯片架构特点
1	高	低	冯 · 诺依曼架构，存算分离
2	中	中低	非冯 · 诺依曼架构，近存计算
3.1	中低	中	非冯 · 诺依曼架构，类存算一体
3.2	低	高	非冯 · 诺依曼架构，存算一体

展对机器人芯片需求迫切，也需要在借鉴欧洲、美国、日本等发达国家和地区经验的基础上，充分立足我国国情，处理好产品进口、技术引进与自主研发之间的关系，勇敢探索一条适合我国国情的机器人专用芯片发展道路。

总之，需认真总结提炼我国在机器人芯片发展过程中的经验和教训，准确把握世界发展趋势和新时代国家整体发展需求和方向，立足新时代我国基本国情，充分发挥我国在机器人芯片方面的各种优势并将之与现阶段芯片技术发展的本质规律有机结合，探索出一条具有中国特色的智能机器人芯片发展之路。

（二）重点任务与发展路线图

我国智能机器人芯片发展要准确把握全球信息技术、机器人技术、人工智能等领域发展赋予的重大机遇，站在机器人产业和芯片产业融合发展全局的角度，充分总结历史发展经验教训，瞄准未来科技发展战略制高点，以问题为牵引，以需求为导向，围绕自主可控发展中国智能机器人芯片的总目标，着力布局以下重点任务：

① 做好中国智能机器人芯片发展的顶层设计。

② 制定智能机器人芯片的发展路线。

③ 做好智能机器人芯片的产业布局。

④ 构建智能机器人芯片产业协同优化的产业结构。

⑤ 制定释放市场和人才创新活力的协同创新机制。

⑥ 明确自主可控与国际协作发展的边界。

⑦ 重点推动智能机器人芯片的应用落地。

我国智能机器人芯片发展就是以实现解决机器人专用芯片

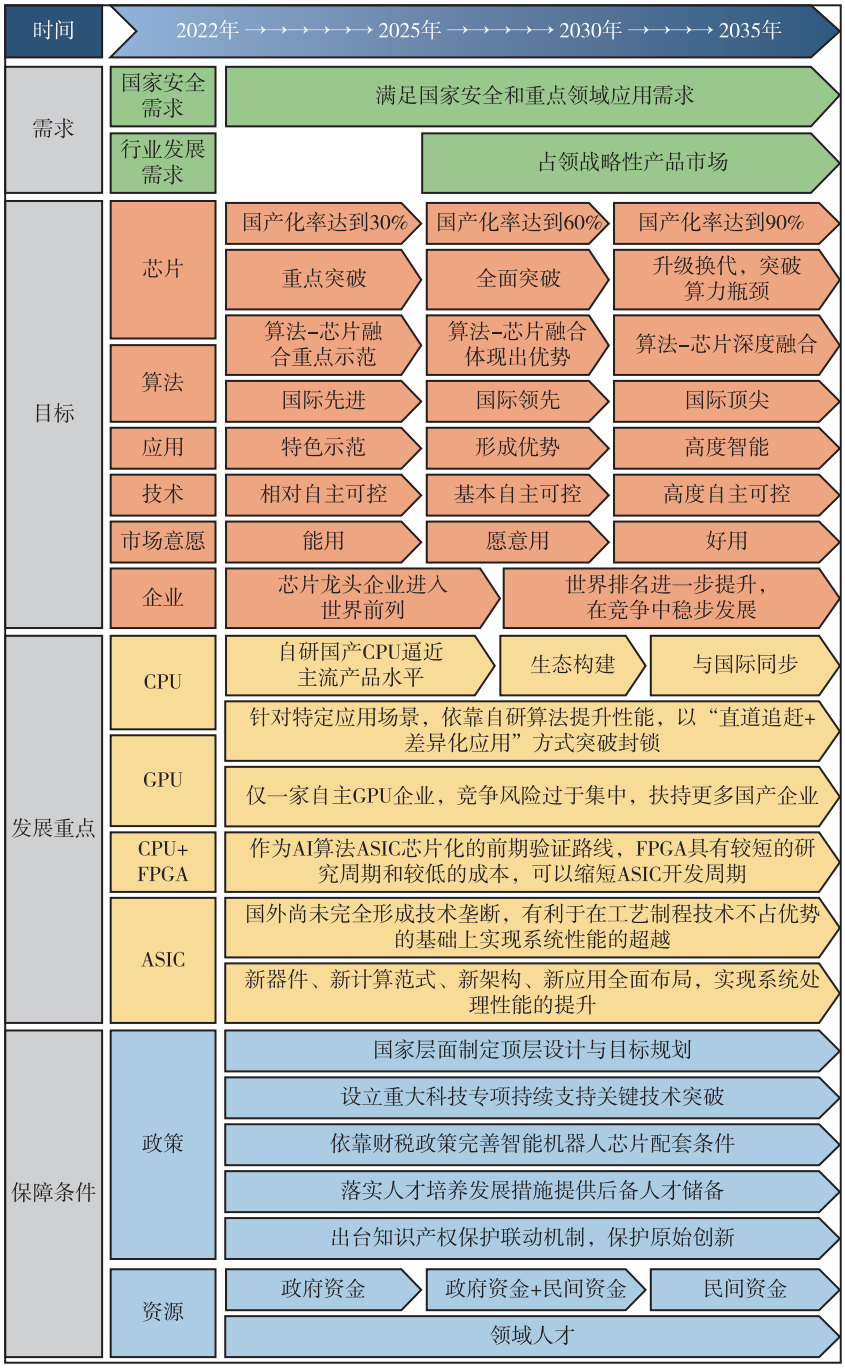

图 1　我国智能机器人核心芯片发展路线图

“卡脖子”难题、服务中国科技稳步快速发展为总目标，力争到2035年左右建设成为智能机器人芯片强国，机器人芯片产业自主、可控、完善、协同、高效，对国家经济社会发展支撑作用显著增强。我国智能机器人核心芯片发展路线图如图1所示，实现总目标可分“三步走”。

第一步，到2025年，全国上下自主可控发展机器人芯片的共识强烈，自主创新能力显著增强，掌握一批关键核心技术，优势领域竞争力进一步增强，尤其在芯片设计、中低端芯片的加工、芯片的产业化融合等领域进步明显，机器人芯片对机器人产业的提质增效作用逐步凸显。自主可控智能机器人芯片与发达国家芯片产业跟跑差距不断缩小。

第二步，到2030年，建成自主创新的机器人芯片研发体系，关键核心技术和应用达到世界领先水平，全产业链实现安全可控，在全球价值链中的地位明显提升，新型机器人芯片产业生态基本形成，低中高全覆盖的芯片设计、加工、制造、应用完整产业集群涌现，机器人芯片对机器人产业、国家经济和社会发展的支撑作用持续增强。自主可控智能机器人芯片与发达国家芯片产业并跑态势基本达成。

第三步，到2035年，形成创新引领优势，建成全球领先的机器人芯片体系，新型机器人芯片产业生态逐步完善，芯片技术、机器人技术与各个领域全面实现协调发展，芯片对经济和社会发展的支撑作用大幅提升。自主可控智能机器人芯片实现全球领跑。

七、对策建议

（一）将智能机器人芯片自主可控上升为国家战略

建议制定“智能机器人芯片自主可控发展战略”，明确智能机器人芯片的自主可控发展在国家总体战略规划中的突出地位。成立智能机器人芯片发展领导小组，负责对机器人产业和芯片产业发展的统一规划和统筹实施。组织涵盖科技、经济、能源、环境、交通、通信、城市规划等不同领域的顶级专家成立智能机器人芯片自主可控发展专家咨询委员会，为智能机器人芯片发展提供决策支撑，统筹推进机器人技术及产业、芯片技术及产业的协同发展，围绕体制机制改革、特色市场环境搭建、自主创新体系建设、智能机器人产业生态、专用智能芯片产业和集群等重点任务，制定目标清晰、方向明确、措施得力的顶层设计。

（二）设立智能机器人芯片重大科技专项

面向各大应用领域对机器人及机器人芯片的重大迫切需求，抓住机器人与芯片不断深入融合发展的重大变革机遇，设立智能机器人芯片重大科技专项，实现智能机器人芯片领域核心和关键技术全面自主可控。智能机器人芯片重大科技专项要以战略性、全局性、前瞻性、关键性技术需求为牵引，发挥国家实验室、国家工程研究中心等平台优势，重点围绕芯片基础科学及工艺的芯片设计、芯片制造、芯片封测技术，围绕智能感知、认知、交互、规划、控制、协同的机器人技术，围绕算法芯片融合的模型压缩、算法融合、新型架构设计技术，以及围绕工业机器人、服务机器人、自主无人系统、特种机器人、智慧交通系统的智能机器人芯片应用技术等为重点，为智能机器人芯片做好技术储备，促进我国机器人领域在核心理论和关键技术方面全面赶超世界先进水平。智能机器人芯片重大科技专项资金来源可从应用市场获取，主要依托机器人应用的相关产业产生的税收红利，在确保一定政府资金投入的基础上，形成多元化的投入机制。

（三）出台激励智能机器人芯片技术研究和产业应用政策

国务院印发的《新时期促进集成电路产业和软件产业高质量发展的若干政策》（2020年）强调，集成电路产业和软件产业是信息产业的核心，是引领新一轮科技革命和产业变革的关键力量。

随后，我国集成电路产业和软件产业快速发展，有力支撑了国家信息化建设，促进了国民经济和社会持续健康发展。建议在此框架内，突出“自主可控”的总体指导思想，重点强调基础研究与应用研究并重发展，出台面向智能机器人领域的芯片产业发展详细落地政策，在财税、投融资、研究开发、进出口、人才、知识产权、市场应用、国际合作等方面继续明确在机器人专用芯片领域的专项措施。由智能机器人芯片发展领导小组推进各部门、各地方尽快制定具体配套政策，加快政策落地，确保取得实效，推动我国智能机器人芯片领域实现高质量发展。

（四）落实智能机器人芯片人才培养发展措施

支撑和决定智能机器人芯片产业发展的关键在于人才。建议我国出台政策措施，重点推进“政产学研”多方协同的研发机制，不断加强芯片产业人才的培养力度、提升产业研发能力、缩小产业的技能缺口。首先，推动深层次产学研合作，促进产业人才培养。重视和加快机器人、半导体、集成电路相关学科的人才培养开发，鼓励各类研发机构、高校、科研院所与高新区企业、基地载体等各类组织开展多种形式的高层次、紧缺和骨干专业技术人才培养合作。另外，完善人才评价和激励机制，完善鼓励创新创造的分配激励机制，形成有效的正向激励，使人才能够充分发挥创新潜能。全面调动人才的积极性，发挥创新潜能与活力。再者，积极引进高端人才，完善人才集聚机制，加大对全球芯片产业高端人才的吸引力度，根据产业发展需求开展人才与企业、人才与项目对接活动，拓展全球技术研发、制造等理工科类人才流入国内芯片行业的渠道。最后，构建专业化人才服务体系，为芯片产业高层次人才的科技研发、成果转化、市场拓展等提供深层次增值服务，支持打造适合人才长期发展的良好生态，聚集人才并留住人才。

来源：中国工程院院刊

王耀南简介

王耀南，中国工程院院士，机器人技术与智能控制专家，湖南大学教授，机器人视觉感知与控制技术国家工程研究中心主任。任中国科协委员、中国图象图形学学会理事长、中国自动化学会会士、中国计算机学会会士、中国人工智能学会会士、全国智能机器人创新联盟副理事长、国家自然科学基金委员会专家咨询委员、中国自动化学会常务理事、中国人工智能学会监事、教育部科技委人工智能与区块链技术委员会委员、湖南省自动化学会理事长等。曾任湖南大学电气与信息工程学院院长、机器人学院院长、国家 863 计划智能机器人领域专家、欧盟第五框架国际合作重大项目首席科学家。

长期从事机器人感知与控制技术教学科研工作，成果获国家技术发明二等奖 1 项、国家科技进步二等奖 4 项、国际 IEEE 机器人与自动化领域“工业应用最高奖”，省部级一等奖 11 项。发表国际 IEEE 等 SCI 论文 200 余篇，出版机器人感知与智能控制等著作 15 部，获国家发明专利 90 余项，培养博士 70 余名（含 IEEE Fellow、长江、杰青等）。荣获国家百千万工程人才、德国杰出洪堡学者、全国高等学校优秀教师、全国五一劳动奖章、全国先进工作者、全国创新争先奖、全国教材建设先进个人、湖南省抗击新冠疫情先进个人等荣誉称号。

王飞跃：元宇宙如何改变一切

关于元宇宙的：现象与本质

莎士比亚曾说：一千个读者眼中就会有一千个哈姆雷特。对于“元宇宙”，一千个人的头脑里，会有“一千零一夜”的元宇宙（Metaverse）之梦。

再结合马修·鲍尔关于元宇宙的文章，就会发现，在每一个元宇宙里至少有上亿个“哈姆雷特”，他们不停地在自问：是生活在元宇宙之中，还是消失在元宇宙之外？

Tobe or not to be（inthe Metaverse）？

自从2021年Facebook创始人扎克伯格宣布其公司更名为ftetaPlatforms之后，“元宇宙”一词顿时在全世界热了起来，引发人们的热烈讨论：

这是Trickor Treat（是“猪”都会飞的风口还是割“韭菜”的时机）？Hopeor Hype（是科技新希望还是商业新忽悠）？这些问题归根结底就是：到底什么是元宇宙？元宇宙究竟意味着什么？

曾任亚马逊全球战略主管的马修·鲍尔应该是回答这些问题的最佳、最权威人士。他去年在Facebook改名之前发布的《元宇宙入门》，几乎是阅读量最高的“元宇宙”主题的文章，或许扎克伯格就是受此影响才决定变“脸”为“元”，自我革命，Allinfteta！

毫无疑问，正是马修·鲍尔的努力，才使元宇宙成为西方投资者、商界人士和政客追逐的新热点，并引发世界性热潮，成了令无数相关人士向往并希望可以借其通向新世界的“蓝海”。

因此，在“元宇宙入门”基础上完成的《元宇宙改变一切》，应该是每一位关注元宇宙人士的必读之物。

在本书中，马修·鲍尔以其一贯的风格，用翔实的素材、深入的分析，全面论述了元宇宙的现状和潜力，是目前关于这一“形而上”愿景之最“形而下”的权威著作。

在我看来，元宇宙的出现推动人类社会关注方式和信用机制的变革。而且，无论你我对其的态度是认可的“Tobe”还是否定的“Nottobe”，元宇宙都将改变一切。相信本书将有助于大家正确理解元宇宙，避免落入“黑”科技的“黑洞”，自然地融入科技发展之历史潮流，共同引导智能科技向善，推动人类社会向健康可持续的智慧社会发展。

特别令人赞赏的是，马修·鲍尔在本书中没有在众多的“哈姆雷特式”元宇宙问答或定义中选边站队，更没有对五花八门、各式各样的元宇宙愿景及其实现进行预测或“算命”，只是力求客观地描述各路“元军”的努力、希望、意义，为大家进一步的畅想提供了良好的素材与空间。至于元宇宙为何能改变世界，或借用本书英文书名The Metaverse:And How It Will Revolutionize Everything提出的问题，依然是读者自己必须面对并回答的“哈姆雷特式”问题。

本书让我遗憾之处是没有对“元宇宙”一词的英文起源进行全面而客观的梳理，特别是没有对1981年弗诺·文奇（VernorVinge）的《真名实姓》（TrueNames）和1984年威廉·吉布森（William Gibson）的《神经漫游者》（Neuromancer）催生元宇宙的作用给予充分的阐述。实际上，没有吉布森在其1982年的处女作《全息玫瑰碎片》（Burning Chrome）中提出的“赛博空间”（cyberspace）一词，并在《神

经漫游者》中发扬光大，很难想象 1992 年尼尔·斯蒂芬森（Neal Stephenson）会在《雪崩》（Snow Crash）中提出“元宇宙”一词。

此外，马修·鲍尔还有意无意地忽略了 1991 年出版的《镜像世界》（Mirror Worlds）及其作者戴维·格勒尔特（David Gelernter），以及众多和镜像世界有关的小说和影视作品。从时间上和技术上看，其实“镜像世界”才是当下人们谈论的元宇宙之真身。

无论如何，同马修·鲍尔一样，我坚信元宇宙将改变人类社会的一切，就像从农业社会到工业社会是一场产业与社会革命，元宇宙、数字孪生和平行智能等将是从工业社会到智业社会这场革命的关键科技与产业支撑及基础设施。

这些技术就是“新 IT”智能技术（Intelligent Technology），是“旧 IT”信息技术（Information Technology）和“老 IT”工业技术（Industrial Technology）的升级和升华。

“老”“旧”“新”三种 IT 技术将融汇起来，开发我们面临的波普尔的“三个世界”：物理世界，以老 IT 工业技术为主；心理世界，以旧 IT 信息技术为主；人工世界，以新 IT 智能技术为主。

这一切的本质就是：通过虚实互动一体化的元宇宙等技术，人类社会将信用度（Trust）和关注力（Attention）等人工世界的理念，转化为可大批量生产并可大规模流通的新商品，就像工业革命是以利用纺织机将心理世界的“时尚”转化为实际的新商品为起点一样，使整个人工世界成为人类发展的新边疆和提高效益的新途径。

据此，元宇宙及其支撑和衍生科技必将改变一切。

关于元宇宙的：哲学与科技

哲学上，元宇宙 ftetaverse 之“元”就是形而上学 ftetaphysics 之“元”（fteta）。元宇宙的实质就是“形而上”，其实际功能就是激发大家的想象力和创新能力。所以，不是一千个人应有一千个元宇宙，而是每个人都该有自己的“一千零一夜”之元宇宙梦。

我的元宇宙梦就是为此类理念建立相应的科学与技术及其工程支撑体系，这就是我一直倡导的平行智能与平行系统。

借用我为中国青年科技工作者所撰的另一部元宇宙专著所写之序，在此就元宇宙之哲学和科技，谈谈自己的初步想法。

“形而上者谓之道，形而下者谓之器”，这本是中国古老的哲学思想，但今日的元宇宙之“fteta”，区块链之“DAO”，还有各种智能科技新 IT 之“器”般的理念与算法，从维纳的《控制论》（Cybernetics）到吉布森的赛博空间，从人工智能（AI）到深度学习（DL），从影子系统、数字孪生到平行智能，已将这一哲学思想转化为技术要求和工程系统，如图 1 和图 2 所示。

《圣经·新约·约翰福音》开篇第一句就是“太初有道，道与神同在”。中国经典《道德经》第四十二章开首即为“道生一，一生二，二生三，三生万物”。二者之合，恰好“形而上”地刻画出未

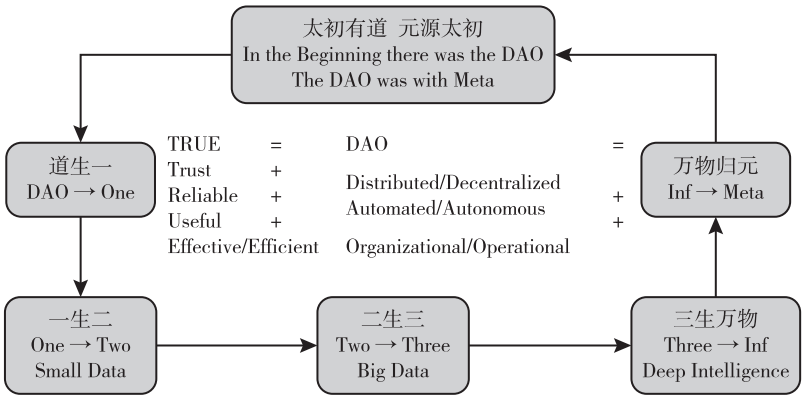

图 1　平行智能与元宇宙：迈向智慧社会的“真”（TRUE）与“道”（DAO）

资料来源：Fei-YueWang，Parallel Intelligence in Metaverses: Welcome to Hanoi! IEEEIntelligent Systems，Vol.37，No.1，pp.16-20，2022.

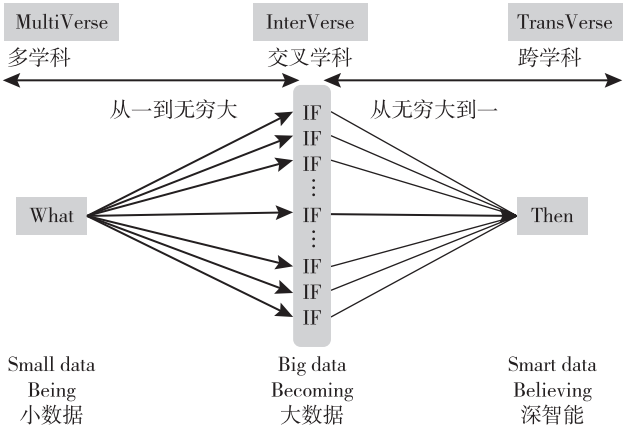

图 2　学科交叉与元宇宙：在多重元宇宙和交叉学科中实现“循环因果”和“小数据－大数据－深智能”智能科技新范式

资料来源：Fei-YueWang，The DAO to Meta Control for Meta Systems in Metaverses: The System of Parallel Control Systems for Knowledge Automation and ControlIntelligence in CPSS，IEEE/CAA Journal of Automatica Sinica，Vol.9，No.11，pp.1899-1908，2022.

来智能技术的必然流程：

• 太初有道，元源太初，是催生控制论的“循环因果论”，将区块链之“道”与元宇宙之“元”，通过“真”与“道”的理念融合起来，变成技术，特别是机器学习等“形而下”的人工智能技术，为“真”的可信 Trust、可靠 Reliable、可用 Useful、效益 Effective/Efficient，以及“道”的层次和功能（分布 / 全中心、自动 / 自主、组织 / 行动），提出具体要求；

• 道生一，就是我们必须面对的特定自然系统和问题；

• 一生二，就是我们开始解决问题时必须面对的界限和“小数据”；

• 二生三，就是我们的由经验、模型、“实验”（特别是“计算实验”）所产生的“大数据”；

• 三生万物，就是通过智能方法从大数据中提炼出来的各种具有针对性的“深智能”；

• “小数据－大数据－深智能”这一流程尽归于“元”，在“元宇宙”中必然存在其对应物，从而实现虚实合一、平行互动。由此，必然走向基于 ACP（A：人工社会；C：计算实验；P：平行执行）的平行智能方法，融机器人、区块链和智能科技为一体，变革生产资料、生产关系和生产力，进入人类社会发展的新阶段。

这一切的本质，就是试图把过去受个人认知能力的“密勒指数”（ftillerindices，5±2），以及社会认知容量的“邓巴圈”（150±50）之限而无法商品化的关注力和信用度转化为可批量化生产、可规模化流通的新型商品。这正是我们研究元宇宙的原因和动机。我们相信，如果正确的元宇宙模式成功，将革命性地变革经济商品的范畴。同时，也能够极大地扩展提高社会效益的途径，加速从工业时代到智业时代的进程。

20 世纪 80 年代初，从利用蒙特·卡罗方法（ftonte Carlo method）和高斯随机场（Gaussian Random Field）进行材料缺陷研究开始，我有幸在浙大走上了利用计算手段设计、分析、实验、验证物理系统的学术研究道路。20 世纪 90 年代初，我向美国国家航空航天局（NASA）提出将模型作为数据产生器和可视化工具的“影子系统“方法，即今天的数字孪生思想。

21 世纪初，在科学哲学家卡尔·波普尔“三个世界”理论的影响下，我在中国科学院提出“平行系统”及其平行智能，以及相应的 ACP 方法和 CPSS（Cyber-Physical-Social Systems）概念。我一直希望这些研究能够催生新的产业革命，促成智能企业和智能产品—从我们日常离不开的智能家居系统开始。为此，2000 年在上海举办的第一届中国家电科技大会上，我做了“家用‘网器’及其互联互通与产业革命”的大会报告，提出互联网将导致“第四次产业革命”，即“工业 4.0”，而 OSGi 将开启“第五次产业革命”，即“工业 5.0”。同年，我

与广东科龙电器集团、中国科学院和美国亚利桑那大学合作，成立国际研发中心和创业公司，于2000年至2001年进行云计算和物联网相关科研和系统开发，有幸发表了平行、ACP和CPSS领域的开拓性文章。这些经历，让我对数字孪生和元宇宙等有了进一步的思考与认识，相信本书的出版将更深入地推动元宇宙智能科技的发展与应用。

元宇宙在赛博空间中孕育，在《镜像世界》一书中诞生，借小说《雪崩》成名。

我的希望是，通过平行智能，元宇宙进化到钱学森的“灵境”技术，最终构成“明境、临境、灵境”三位一体的智能科技体系，即三境智能：明察其境、身临其境、智汇灵境，成为不但更有“中国味”，也更加人性化，能更好地服务于人类的向善的新科技。

来源:《元宇宙改变一切》序言

王飞跃简介

王飞跃教授，1990年获美国伦塞利尔理工学院（RPI）计算机与系统工程博士学位。1990年起在美国亚利桑那大学先后任助教授、副教授和教授，机器人与自动化实验室主任，复杂系统高等研究中心主任。曾任中国科学院自动化研究所副所长，现为中国科学院自动化研究所复杂系统管理与控制国家重点实验室主任。

王教授是智能控制、智能机器人、无人驾驶、智能交通等领域早期开拓者之一。自上世纪80年代起，师从机器人和人工智能领域开拓者G. N. Saridis和R. F. McNaughton教授，开展智能控制、机器人、人工智能和复杂系统的研究与应用工作，提出并建立了智能系统的协调结构和理论、语言动力学理论、代理控制方法、复杂系统的ACP方法等。现已完成“Advanced Studies of Flexible Robotic Manipulators: Modeling, Design, Control and Application”、“Autonomous Rock Excavation: Intelligent Control Techniques and Experimentation”、“Advanced Motion Control and Sensing for Intelligent Vehicles”、“Advances in Computational Intelligence: Theory and Applications”、《社会计算》、《智能汽车》、《智能轮胎》、《区块链理论与方法》等十多本学术专著，皆为相关领域的首部学术著作。自二十一世纪初，发起并开拓了社会计算、社会制造、平行智能、平行控制、平行管理、平行艺术、知识自动化等新的研究领域。王教授现任智能科学与技术学报、IEEE智能车汇刊（IEEE Trans. on Intelligent Vehicles）主编，指挥与控制学报名誉主编。1996创办Int'l J. of Intelligent Control and Systems和World Scientific Series on Intelligent Control and Intelligent Automation，2019年创办《智能科学与技术学报》。现任中国自动化学会监事长。2003年起先后当选IEEE、INCOSE、IFAC、ASME和AAAS等国际学术组织Fellow。2007年获国家自然科学二等奖和ACM杰出科学家称号，2014年获IEEE诺伯特·维纳奖。

具有全局速度约束的惯性 / 编码器 / 视觉 / 激光融合定位方法：IEVL-Fusion

文 / 武东杰　仲训昱　崔晓珍　庄明溪　彭侠夫

摘要：针对卫星拒止环境中移动机器人高精度定位需求，提出一种基于误差状态扩展卡尔曼滤波（ES-EKF）的激光定位子系统 / 视觉定位子系统 / 全局速度测量子系统松耦合融合定位方法，并设计了一个误差低漂移的组合定位系统。首先，根据向量加法和矩阵乘法对系统状态的误差进行最小表示，建立误差形式的卡尔曼滤波模型，以误差状态的最优估计对系统状态的估计值进行补偿。然后，针对激光和视觉定位子系统位姿不确定度未知的问题，将位姿输出依时间戳转化为位姿增量，并建立位姿增量观测模型。其次，针对组合定位系统缺少全局速度约束的问题，利用姿态航向参考系统（AHRS）和正向运动学模型构建全局速度测量子系统，并建立全局速度观测模型。最后，在街道和野外两个场景中进行测试，本文算法的相对定位误差小于 0.4%，相较于仅受局部速度约束的 EKF 和 ES-EKF 融合定位算法降低了约 40%。实验结果表明，所提出的算法有效提升了定位系统的精度。

关键词：卫星拒止；多传感器融合；位姿增量融合；全局速度约束；误差状态扩展卡尔曼滤波；轮式机器人；移动机器人定位

1　引言（Introduction）

定位是移动机器人所必须具备的一项重要功能，是实现地图构建、自主导航等功能的前提和基础[1]。全球卫星定位系统（GNSS）能够在全球范围内、24 小时地提供全局位置信息，是室外车辆所普遍使用的定位技术[2]。然而，在卫星拒止区域内，例如在室内、地下等，接收器完全接收不到卫星信号时，必须启动备用的导航系统才能完成导航任务[3-4]。

移动机器人常配备惯性测量单元（IMU）、编码器（encoder）、视觉（vision）传感器和激光雷达（LiDAR）等导航传感器。IMU 和编码器虽然成本低廉、原理简单，但定位误差会随时间和运行里程快速累积，通常用于辅助视觉或激光雷达进行定位。视觉定位系统通过对连续的两帧图像进行特征跟踪、特征匹配、位姿递推估计等一系列处理，实现对移动机器人的定位，但在高动态和光照变化明显的情况下，其误差累积会显著增大。

激光定位系统通过点云匹配实现较高精度的位姿估计，具有定位精度高、使用范围广等特点，目前已广泛应用到物流机器人与扫地机器人等低速的移动机器人上[4]。但是激光定位系统所获得的高精度是以降低输出频率为代价的。LOAM（LiDARodometry and mapping）[5] 是目前 KITTI Odometry 数据集[6] 上排名最靠前的定位算法之一，其相对定位误差可达 0.55%，输出频率却很低（在 NVIDIA Jetson TX2 处理器上测试的后端定位频率约 1.5 Hz）。为了进一步降低计算量，Shan 等[7] 基于特征分割和地面优化技术对 LOAM 算法进行改进，提出了轻量型的 LeGO-

LOAM 算法，虽然精度和稳定性均有一定的提高，但输出频率仍然偏低（在 NVIDIA Jetson TX2 处理器上测试的后端定位频率约 3Hz），这对于中、高速移动机器人导航是十分不利的。另外，由于缺乏高度方向上的全局约束，其高度方向上的平均误差约占总体定位误差的 70% 以上[7]。

面对单一传感器的不足，研究人员提出了许多基于多传感器融合技术的组合定位算法。如为了应对光照变化和高速运动时的特征丢失等问题，可将高频率的 IMU（惯性测量单元）数据融入到视觉定位系统中，以此来提高系统的鲁棒性和算法的稳定性[8-9]。其中，Qin 等[9] 设计了一个基于优化方法的相机和 IMU 紧组合定位系统 VINSFusion，在 KITTI Odometry 数据集上的测试定位精度为 1.09%，是目前较为优秀的双目视觉 / 惯性融合定位算法。为了弥补激光输出频率低和视觉高动态不稳定的缺点，Zhang 等[10] 基于优化融合方法提出了 V-LOAM 算法，单目视觉模块以 60Hz 的频率进行运动估计，激光模块以 1Hz 的频率对位姿进行地图匹配优化，实现了 0.54% 的定位精度。Kubelka 等[11] 认为 IMU/ 编码器 / 相机 / 激光雷达组合定位是实现卫星拒止环境下高精度、高可靠性导航的有效方式，并利用 EKF 算法对 IMU/ 编码器里程计 / 视觉里程计 / 激光里程计进行融合，在多种场景下实现了 1.2% 的定位精度。但是，这些研究侧重于定位系统的整体设计，编程实现复杂，且导航定位精度往往很难超过在激光雷达可用时的定位精度。

为了避免复杂的系统设计和编程实现，研究人员开始尝试另一条研究思路，即直接对现有的定位系统进行松耦合融合。为此，Moore 等[12] 在 ROS（robot operating system）环境下设计并实现了一个基于 EKF 的多传感器融合算法框架 robotlocalization，可以依照 ROS 预定义的信息格式，融合任意多个定位子系统的位置、姿态和速度等数据。当前，它已经成为 ROS 系统上非常流行、被广泛使用的一种定位算法包。但是，该算法在融合定位子系统的位姿时存在着协方差无法确定的问题：在没有卫星定位等全局信息辅助的情况下，激光或视觉定位子系统的位姿输出会随着运动范围的增大而产生误差累积，即位姿估计的不确定度关于时间是无界的 [13]。尽管回环检测能够大幅度减小累积误差，但进行复杂场景下大范围运动时，回环检测常常失效，甚至出现假阳性闭环的问题 [14]。因此，目前还缺少有效方法对激光或视觉定位子系统的协方差进行建模。

另外，在组合定位系统中，速度测量通常是在机器人坐标系中进行（即局部速度测量），而非在世界坐标系中进行（即全局速度测量）。但是，相对于全局速度融合，局部速度融合对于提升系统定位精度的意义并不大。例如 IMU/ 编码器融合定位算法[15-16] 和 IMU/ 相机 / 编码器融合定位算法[17] 都是先根据正运动学模型和编码器读数计算出局部速度，再将其融入系统的状态中。由于局部速度必须使用最新的姿态估计值将其分解为全局速度才能对位置估计产生约束，因此，这种融合方式对定位结果的影响严重依赖于姿态估计的好坏。如果能够利用 IMU 和编码器构建一个独立于系统状态的全局速度测量系统，通过卡尔曼观测更新过程直接对系统状态产生约束，便可进一步提升系统的定位精度。

针对定位子系统位姿协方差无法建模和组合定位系统缺少全局速度测量的问题，本文借助当前优秀的激光定位系统和视觉定位系统，设计一个松耦合定位算法 IEVL-Fusion，将激光、相机、编码器和 IMU 快速、高效地集成起来，实现低漂移、高频率的移动机器人定位。首先，考虑到 ES-EKF 相对于常规的 EKF 具有一些显著优点[18-19]：（1）姿态误差是小量，可用 3 维向量对其进行等价表示，有利于避免出现协方差奇异问题；（2）系统误差

在 0 附近，有利于降低系统的非线性程度，提高滤波精度；（3）系统误差为小量，意味着可忽略二次项及高阶项，使雅可比矩阵的计算变得简单、快速。因此，本文选择 ES-EKF 作为融合方法。其次，针对激光定位子系统位姿协方差无法建模的问题，将位姿依时间戳转换为位姿增量，并将位姿增量的协方差建模为时间增量的二次函数，建立了位姿增量观测模型。最后，受 AHRS 可输出全局姿态信息的启发[20]，利用 AHRS 输出的全局姿态对正向运动学模型输出的局部速度进行分解，获得对移动机器人全局速度的独立测量结果，从而获得对系统状态的全局速度约束。

本文方法的创新和贡献主要体现在：

（1）将协方差无法建模的位姿融合问题转化为协方差可建模的位姿增量融合问题，并考虑位姿增量测量输出的不均匀性，将其协方差建模为时间增量的二次函数，有效实现了激光和视觉定位子系统输出的融合；

（2）设计了一种新型的编码器信息的融合方式，即利用 IMU 姿态输出和移动机器人正向运动学模型构建全局速度测量子系统，再将全局速度测量值融合到系统状态中，有效降低组合系统的定位误差；

（3）在街道和野地 2 个场景中对本文算法进行测试和对比分析，并公开实验中所采集到的数据集，可通过扫码本文标题页的 OSID 码下载。

2 方法（Methodology）

2.1 总体框架

如图 1 所示，融合算法总体框架包括子系统和融合估计器两大部分。子系统包括激光定位子系统、视觉定位子系统、全局速度测量子系统。其中，IMU 姿态测量模块以重力方向或地磁方向作为参考，提供有绝对参考的俯仰角、滚转角等姿态信息，例如 AHRS、垂直参考单元（VRU）等。移动机器人正运动学模型以编码器输出的轮速作为输入，求解出移动机器人参考点处的线速度，经 IMU 姿态分解后可得车体在世界坐标系中的运动速度，其观测模型详见 2.4.3 节。视觉定位子系统和激光定位子系统分别以图像和激光点云（也包括 IMU 数据）为输入，可输出移动机器人的位置、姿态等信息，其观测模型详见 2.4.1 和 2.4.2 节。ES-EKF 估计器在结构上可以分为状态预测过程和状态更新过程，算法设计过程详见第 2 节。

图 2 展示了基于 ES-EKF 的融合估计器的算法流程，其中，各模块的具体处理过程请参考其对应的公式。

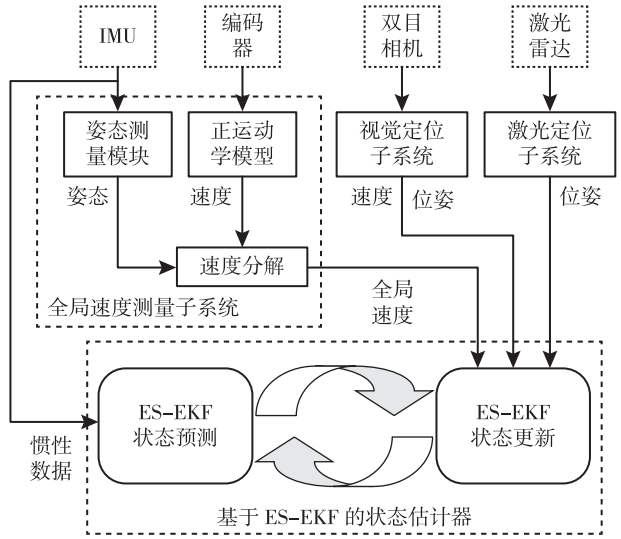

图 1　融合算法总体框架

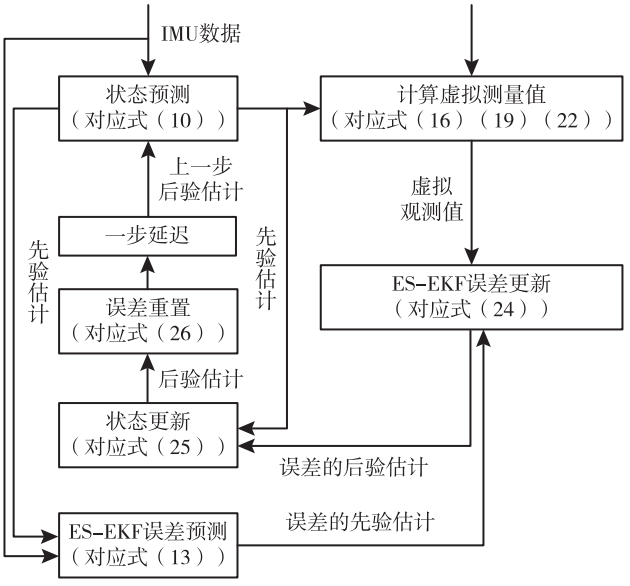

图 2　基于 ES-EKF 的状态估计器框图

2.2 姿态及其误差表示

设 $SO(3)$ 为 3 维姿态空间，姿态的矩阵表示、旋转向量表示分别记为 $\boldsymbol{R} \in SO(3)$ 和 $\boldsymbol{\theta} \in \mathbb{R}^3$，它们之间的转换关系记为

$$R = \exp(\boldsymbol{\theta}^{\wedge}),\ \boldsymbol{\theta} = (\ln R)^{\vee} \tag{1}$$

式中，$(\cdot)^{\wedge}$ 表示将向量映射为一个反对称矩阵[21]，$(\cdot)^{\wedge}$ 和 $(\cdot)^{\vee}$ 互为逆映射，即

$$\boldsymbol{\theta}^{\wedge} = \begin{bmatrix} 0 & -\theta_z & \theta_y \\ \theta_z & 0 & -\theta_x \\ -\theta_y & \theta_x & 0 \end{bmatrix},\quad (\boldsymbol{\theta}^{\wedge})^{\vee} = \boldsymbol{\theta} \tag{2}$$

2.3 系统模型与状态预测

2.3.1 状态变量定义

将系统状态 $\boldsymbol{x}$ 定义为

$$\boldsymbol{x} \triangleq [\boldsymbol{p}, \boldsymbol{v}, \boldsymbol{R}, \boldsymbol{b}_{\mathrm{a}}, \boldsymbol{b}_{\mathrm{g}}] \tag{3}$$

其中，位置 $\boldsymbol{p} \in \mathbb{R}^3$、姿态 $\boldsymbol{R} \in \mathbb{R}^3$、速度 $\boldsymbol{v} \in \mathbb{R}^3$定义在世界坐标系中，加速度计测量偏差 $\boldsymbol{b}_{\mathrm{a}} \in \mathbb{R}^3$，陀螺仪测量偏差 $\boldsymbol{b}_{\mathrm{g}} \in \mathbb{R}^3$定义在机器人坐标系中。对应的估计值记为

$$\hat{\boldsymbol{x}} \triangleq [\hat{\boldsymbol{p}}, \hat{\boldsymbol{v}}, \hat{\boldsymbol{R}}, \hat{\boldsymbol{b}}_{\mathrm{a}}, \hat{\boldsymbol{b}}_{\mathrm{g}}] \tag{4}$$

将状态估计误差$\boldsymbol{\delta}$定义为真实值与估计值的偏差：

$$\boldsymbol{\delta} \triangleq [\boldsymbol{\delta}_{\boldsymbol{p}}^{\mathrm{T}},\ \boldsymbol{\delta}_{\boldsymbol{v}}^{\mathrm{T}},\ \boldsymbol{\delta}_{\boldsymbol{\theta}}^{\mathrm{T}},\ \boldsymbol{\delta}_{\boldsymbol{b}\mathrm{a}}^{\mathrm{T}},\ \boldsymbol{\delta}_{\boldsymbol{b}\mathrm{g}}^{\mathrm{T}}]^{\mathrm{T}} \in \mathbb{R}^{15} \tag{5}$$

各误差的定义式如下：

$$\begin{cases} \boldsymbol{\delta}_{\boldsymbol{p}} \triangleq \boldsymbol{p} - \hat{\boldsymbol{p}} \\ \boldsymbol{\delta}_{\boldsymbol{v}} \triangleq \boldsymbol{v} - \hat{\boldsymbol{v}} \\ \boldsymbol{\delta}_{\boldsymbol{\theta}} \triangleq \ln(\hat{\boldsymbol{R}}^{\mathrm{T}}\boldsymbol{R})^{\vee} \\ \boldsymbol{\delta}_{\boldsymbol{b}\mathrm{a}} \triangleq \boldsymbol{b}_{\mathrm{a}} - \hat{\boldsymbol{b}}_{\mathrm{a}} \\ \boldsymbol{\delta}_{\boldsymbol{b}\mathrm{g}} \triangleq \boldsymbol{b}_{\mathrm{g}} - \hat{\boldsymbol{b}}_{\mathrm{g}} \end{cases} \tag{6}$$

2.3.2 系统的状态运动模型

IMU 的测量模型设为[19]

$$\boldsymbol{a}_{\mathrm{m}} = \boldsymbol{a} + \boldsymbol{b}_{\mathrm{a}} + \boldsymbol{n}_{\mathrm{a}} \tag{7}$$

$$\boldsymbol{\omega}_{\mathrm{m}} = \boldsymbol{\omega} + \boldsymbol{b}_{\mathrm{g}} + \boldsymbol{n}_{\mathrm{g}} \tag{8}$$

其中，$\boldsymbol{a}_{\mathrm{m}} \in \mathbb{R}^3$表示加速度计的测量输出，$\boldsymbol{a} \in \mathbb{R}^3$为加速度真值，$\boldsymbol{n}_{\mathrm{a}} \in \mathbb{R}^3$为加速度计的测量噪声；$\boldsymbol{\omega}_{\mathrm{m}} \in \mathbb{R}^3$表示陀螺仪的测量输出，$\boldsymbol{\omega} \in \mathbb{R}^3$为角速度真值，$\boldsymbol{n}_{\mathrm{g}} \in \mathbb{R}^3$为陀螺仪的测量噪声。

将测量偏差$\boldsymbol{b}_{\mathrm{a}}$和$\boldsymbol{b}_{\mathrm{g}}$建模为随机游走模型[9]，则系统的状态运动模型为

$$\begin{cases} \dot{\boldsymbol{p}} = \boldsymbol{v} \\ \dot{\boldsymbol{v}} = \boldsymbol{R}(\boldsymbol{a}_{\mathrm{m}} - \boldsymbol{b}_{\mathrm{a}} - \boldsymbol{n}_{\mathrm{a}}) + \boldsymbol{g} \\ \dot{\boldsymbol{R}} = \boldsymbol{R}(\boldsymbol{\omega}_{\mathrm{m}} - \boldsymbol{b}_{\mathrm{g}} - \boldsymbol{n}_{\mathrm{g}})^{\wedge} \\ \dot{\boldsymbol{b}}_{\mathrm{a}} = \boldsymbol{\tau}_{\boldsymbol{b}\mathrm{a}} \\ \dot{\boldsymbol{b}}_{\mathrm{g}} = \boldsymbol{\tau}_{\boldsymbol{b}\mathrm{g}} \end{cases} \tag{9}$$

式中，$\boldsymbol{g}$为重力加速度常量，$\boldsymbol{n}_{\mathrm{a}}$、$\boldsymbol{n}_{\mathrm{g}}$、$\boldsymbol{\tau}_{\boldsymbol{b}\mathrm{a}}$、$\boldsymbol{\tau}_{\boldsymbol{b}\mathrm{g}}$均建模为高斯白噪声，即$\boldsymbol{n}_{\mathrm{a}} \sim \mathcal{N}(\boldsymbol{0}, \sigma_{\mathrm{a}}^2\boldsymbol{I}_3)$，$\boldsymbol{n}_{\mathrm{g}} \sim \mathcal{N}(\boldsymbol{0}, \sigma_{\mathrm{g}}^2\boldsymbol{I}_3)$，$\boldsymbol{\tau}_{\boldsymbol{b}\mathrm{a}} \sim \mathcal{N}(\boldsymbol{0}, \sigma_{\boldsymbol{b}\mathrm{a}}^2\boldsymbol{I}_3)$，$\boldsymbol{\tau}_{\boldsymbol{b}\mathrm{g}} \sim \mathcal{N}(\boldsymbol{0}, \sigma_{\boldsymbol{b}\mathrm{g}}^2\boldsymbol{I}_3)$。

对微分方程（9）在微小时间间隔 $\Delta t \triangleq t_k - t_{k-1}$内进行数值积分，得到系统模型的差分递推形式：

$$\boldsymbol{x}_k = \boldsymbol{f}(\boldsymbol{x}_{k-1}, \boldsymbol{u}_{\mathrm{m},k-1}, \boldsymbol{w}_{\mathrm{sys},k}) \tag{10}$$

其中，控制输入定义为 $\boldsymbol{u}_{\mathrm{m},k-1} \triangleq [\boldsymbol{a}_{\mathrm{m},k-1}^{\mathrm{T}},\ \boldsymbol{\omega}_{\mathrm{m},k-1}^{\mathrm{T}}]^{\mathrm{T}}$，系统的过程噪声定义为 $\boldsymbol{w}_{\mathrm{sys},k} \triangleq [\boldsymbol{n}_{\mathrm{a}}^{\mathrm{T}}, \boldsymbol{n}_{\mathrm{g}}^{\mathrm{T}},\ \boldsymbol{\tau}_{\boldsymbol{b}\mathrm{a}}^{\mathrm{T}},\ \boldsymbol{\tau}_{\boldsymbol{b}\mathrm{g}}^{\mathrm{T}}]^{\mathrm{T}}$。

2.3.3 系统的误差运动模型

根据误差定义式（6）和系统微分方程（9），可得误差状态的微分方程[19]：

$$\dot{\boldsymbol{\delta}} = \boldsymbol{A}\boldsymbol{\delta} + \boldsymbol{B}\boldsymbol{w}_{\mathrm{sys},k} \tag{11}$$

式中，

$$\boldsymbol{A} = \begin{bmatrix} \boldsymbol{0}_3 & \boldsymbol{I}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 \\ \boldsymbol{0}_3 & \boldsymbol{0}_3 & -\hat{\boldsymbol{R}}(\boldsymbol{a}_{\mathrm{m}} - \hat{\boldsymbol{b}}_{\mathrm{a}})^{\wedge} & -\hat{\boldsymbol{R}} & \boldsymbol{0}_3 \\ \boldsymbol{0}_3 & \boldsymbol{0}_3 & -(\boldsymbol{\omega}_{\mathrm{m}} - \hat{\boldsymbol{b}}_{\mathrm{g}})^{\wedge} & \boldsymbol{0}_3 & -\boldsymbol{I}_3 \\ \boldsymbol{0}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 \\ \boldsymbol{0}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 \end{bmatrix}$$

$$\boldsymbol{B} = \begin{bmatrix} \boldsymbol{0}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 \\ -\hat{\boldsymbol{R}} & \boldsymbol{0}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 \\ \boldsymbol{0}_3 & -\boldsymbol{I}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 \\ \boldsymbol{0}_3 & \boldsymbol{0}_3 & \boldsymbol{I}_3 & \boldsymbol{0}_3 \\ \boldsymbol{0}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 & \boldsymbol{I}_3 \end{bmatrix}$$

对微分方程（11）在 Δt 上进行数值积分，可得误差状态的运动模型为[21]

$$\boldsymbol{\delta}_k = \boldsymbol{F}_{k,k-1}\boldsymbol{\delta}_{k-1} + \boldsymbol{C}_k\boldsymbol{w}_{\mathrm{sys},k} \tag{12}$$

式中，

$$\boldsymbol{F}_{k,k-1} = \mathrm{e}^{\boldsymbol{A}_{k-1}\Delta t} \approx \boldsymbol{I}_{15} + \boldsymbol{A}_{k-1}\Delta t + \frac{1}{2}(\boldsymbol{A}_{k-1}\Delta t)^2$$

$$\boldsymbol{C}_k = \begin{bmatrix} \boldsymbol{0}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 \\ \Delta t\boldsymbol{I}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 \\ \boldsymbol{0}_3 & \Delta t\boldsymbol{I}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 \\ \boldsymbol{0}_3 & \boldsymbol{0}_3 & \sqrt{\Delta t}\boldsymbol{I}_3 & \boldsymbol{0}_3 \\ \boldsymbol{0}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 & \sqrt{\Delta t}\boldsymbol{I}_3 \end{bmatrix}$$

$$\boldsymbol{w}_{\mathrm{sys},k} \sim \mathcal{N}(\boldsymbol{0}_{12\times 1}, \boldsymbol{\Sigma}_{\mathrm{sys}})$$

$$\boldsymbol{\Sigma}_{\mathrm{sys}} = \mathrm{diag}(\sigma_{\mathrm{a}}^2\boldsymbol{I}_3, \sigma_{\mathrm{g}}^2\boldsymbol{I}_3, \sigma_{\boldsymbol{b}_{\mathrm{a}}}^2\boldsymbol{I}_3, \sigma_{\boldsymbol{b}_{\mathrm{g}}}^2\boldsymbol{I}_3)$$

2.3.4 状态预测与误差预测

在上一时刻，状态、误差状态及其协方差矩阵的后验估计分别记为 $\hat{\boldsymbol{x}}_{k-1}^{+}$、$\hat{\boldsymbol{\delta}}_{k-1}^{+}$和$\boldsymbol{P}_{k-1}^{+}$；在当前时刻，状态、误差状态及其协方差矩阵的先验估计分别记为 $\hat{\boldsymbol{x}}_{k}^{-}$、$\hat{\boldsymbol{\delta}}_{k}^{-}$和$\boldsymbol{P}_{k}^{-}$；则在卡尔曼滤波框架下，可得状态和误差的预测式：

$$\begin{aligned} \hat{\boldsymbol{x}}_k^- &= \boldsymbol{f}(\hat{\boldsymbol{x}}_{k-1}^+, \boldsymbol{u}_{\mathrm{m},k-1}, \boldsymbol{0}) \\ \hat{\boldsymbol{\delta}}_k^- &= \boldsymbol{F}_{k,k-1}\hat{\boldsymbol{\delta}}_{k-1}^+ \\ \boldsymbol{P}_k^- &= \boldsymbol{F}_{k,k-1}\boldsymbol{P}_{k-1}^+\boldsymbol{F}_{k,k-1}^{\mathrm{T}} + \boldsymbol{C}_k\boldsymbol{\Sigma}_{\mathrm{sys}}\boldsymbol{C}_k^{\mathrm{T}} \end{aligned} \tag{13}$$

2.4 观测模型与状态更新

2.4.1 激光定位子系统观测模型

在总结 Kubelka[11] 和 Ma[21] 的工作基础上，进一步将位置增量 $\boldsymbol{y}_{\Delta\boldsymbol{p},k} \in \mathbb{R}^3$和姿态增量 $\boldsymbol{y}_{\delta\boldsymbol{R},k} \in SO$（3）的协方差建模为时间增量的 2 次函数，建立增量的测量模型为

$$\begin{aligned} \boldsymbol{y}_{\delta\boldsymbol{R},k} &= \hat{\boldsymbol{R}}_{k-1}^{+\mathrm{T}}\boldsymbol{R}_k\exp((\boldsymbol{w}_{\delta\boldsymbol{R},k}\Delta t)^{\wedge}) \\ \boldsymbol{y}_{\Delta\boldsymbol{p},k} &= \hat{\boldsymbol{R}}_{k-1}^{+\mathrm{T}}(\boldsymbol{p}_k - \hat{\boldsymbol{p}}_{k-1}^{+}) + \boldsymbol{w}_{\Delta\boldsymbol{p},k}\Delta t \end{aligned} \tag{14}$$

其中，$\boldsymbol{w}_{\delta\boldsymbol{R},k} \in \mathbb{R}^3$和$\boldsymbol{w}_{\Delta\boldsymbol{p},k} \in \mathbb{R}^3$分别为姿态增量测量噪声和位置增量测量噪声，这里均假设为高斯白噪声，协方差分别设为 $\sigma_{\Delta\boldsymbol{p}}^2\boldsymbol{I}_3$和 $\sigma_{\delta\boldsymbol{R}}^2\boldsymbol{I}_3$。

记激光定位子系统在时刻 t_{k-1} 和 t_k 输出的位置测量结果分别为 $\boldsymbol{p}_{\mathrm{m},k-1} \in \mathbb{R}^3$ 和 $\boldsymbol{p}_{\mathrm{m},k} \in \mathbb{R}^3$，姿态测量结果分别为 $\boldsymbol{R}_{\mathrm{m},k-1} \in SO$（3）和 $\boldsymbol{R}_{\mathrm{m},k} \in SO$（3），定义虚拟测量值 $\boldsymbol{z}_{\mathrm{pi},k} \in \mathbb{R}^6$：

$$\boldsymbol{z}_{\mathrm{pi},k} \triangleq \begin{bmatrix} \boldsymbol{R}_{\mathrm{m},k-1}^{\mathrm{T}}(\boldsymbol{p}_{\mathrm{m},k} - \boldsymbol{p}_{\mathrm{m},k-1}) - \hat{\boldsymbol{R}}_{k-1}^{+\mathrm{T}}(\hat{\boldsymbol{p}}_k^- - \hat{\boldsymbol{p}}_{k-1}^+) \\ \ln(\hat{\boldsymbol{R}}_k^{-\mathrm{T}}\hat{\boldsymbol{R}}_{k-1}^{+}\boldsymbol{R}_{\mathrm{m},k-1}^{\mathrm{T}}\boldsymbol{R}_{\mathrm{m},k})^{\vee} \end{bmatrix} \tag{15}$$

建立虚拟测量的观测模型如下：

$$\boldsymbol{z}_{\mathrm{pi},k} = \boldsymbol{H}_{\mathrm{pi},k}\boldsymbol{\delta}_k + \boldsymbol{D}_{\mathrm{pi},k}\boldsymbol{w}_{\mathrm{pi},k} \tag{16}$$

其中，

$$\boldsymbol{H}_{\mathrm{pi},k} = \begin{bmatrix} \hat{\boldsymbol{R}}_{k-1}^{+\mathrm{T}} & \boldsymbol{0}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 \\ \boldsymbol{0}_3 & \boldsymbol{0}_3 & \boldsymbol{I}_3 & \boldsymbol{0}_3 & \boldsymbol{0}_3 \end{bmatrix}$$

$$\boldsymbol{D}_{\mathrm{pi},k} = \begin{bmatrix} \Delta t\boldsymbol{I}_3 & \boldsymbol{0}_3 \\ \boldsymbol{0}_3 & \Delta t\boldsymbol{I}_3 \end{bmatrix}$$

$$\boldsymbol{w}_{\mathrm{pi},k} \sim \mathcal{N}(\boldsymbol{0}_{6\times 1}, \mathrm{diag}(\sigma_{\Delta}^2\ \boldsymbol{I}_3, \sigma_{\delta\boldsymbol{R}}^2\boldsymbol{I}_3))$$

2.4.2 视觉定位子系统观测模型

视觉定位子系统可同时输出位置、姿态及速度信息，其位姿观测模型与激光位姿观测模型完全一样，不再赘述，这里仅介绍其局部速度观测模型。

在机器人坐标系中，设时刻t_k的局部速度测量模型为

$$\boldsymbol{y}_{\mathrm{lv},k} = \boldsymbol{R}_k^{\mathrm{T}}\boldsymbol{v}_k + \boldsymbol{w}_{\mathrm{lv},k} \tag{17}$$

其中，$\boldsymbol{w}_{\mathrm{lv},k} \in \mathbb{R}^3$为局部速度测量噪声，协方差设为$\sigma_{\mathrm{lv}}^2\boldsymbol{I}_3$。

记视觉定位子系统在时刻t_k输出的局部速度测量值为$\boldsymbol{v}_{\mathrm{lv,m},k} \in \mathbb{R}^3$，参考系为机器人坐标系，定义虚拟测量值$\boldsymbol{z}_{\mathrm{lv},k} \in \mathbb{R}^3$：

$$\boldsymbol{z}_{\mathrm{lv},k} \triangleq \boldsymbol{v}_{\mathrm{lv,m},k} - \hat{\boldsymbol{R}}_k^{-\mathrm{T}}\hat{\boldsymbol{v}}_k^- \tag{18}$$

建立虚拟测量值的观测模型如下：

$$\boldsymbol{z}_{\mathrm{lv},k} = \boldsymbol{H}_{\mathrm{lv},k}\boldsymbol{\delta}_k + \boldsymbol{D}_{\mathrm{lv},k}\boldsymbol{w}_{\mathrm{lv},k} \tag{19}$$

其中，

$$\begin{aligned} &H_{\mathrm{lv},k} = [\boldsymbol{0}_3\ \ \hat{\boldsymbol{R}}_k^{-\mathrm{T}}\ \ (\hat{\boldsymbol{R}}_k^{-\mathrm{T}}\hat{\boldsymbol{v}}_k^-)^{\wedge}\ \ \boldsymbol{0}_3\ \ \boldsymbol{0}_3\ \ \boldsymbol{0}_3] \\ &\boldsymbol{D}_{\mathrm{lv},k} = \boldsymbol{I}_3 \\ &\boldsymbol{w}_{\mathrm{lv},k} \sim \mathcal{N}(\boldsymbol{0}_{3\times 1}, \sigma_{\mathrm{lv}}^2\boldsymbol{I}_3) \end{aligned}$$

2.4.3 全局速度测量子系统观测模型

在世界坐标系中，设时刻 t_k 的全局速度测量模

型为

$$\boldsymbol{y}_{\mathrm{gv},k}=\boldsymbol{v}_k+\boldsymbol{w}_{\mathrm{gv},k} \tag{20}$$

其中，$\boldsymbol{w}_{\mathrm{gv},k}\in\mathbb{R}^3$为世界坐标系内的速度测量噪声，协方差设为$\sigma_{\mathrm{gv}}^2\boldsymbol{I}_3$。

记 IMU 姿态测量模块的输出为 $\boldsymbol{C}_{\mathrm{m},k}\in SO$（3），正运动学模块利用编码器读数解算出的机器人速度为 $\boldsymbol{v}_{\mathrm{m},k}\in\mathbb{R}^3$，定义虚拟测量值 $\boldsymbol{z}_{\mathrm{gv},k}\in\mathbb{R}^3$：

$$\boldsymbol{z}_{\mathrm{gv},k}\triangleq\boldsymbol{C}_{\mathrm{m},k}\boldsymbol{v}_{\mathrm{m},k}-\hat{\boldsymbol{v}}_k^- \tag{21}$$

建立虚拟测量值的观测模型如下：

$$\boldsymbol{z}_{\mathrm{gv},k}=\boldsymbol{H}_{\mathrm{gv},k}\boldsymbol{\delta}_k+\boldsymbol{D}_{\mathrm{gv},k}\boldsymbol{w}_{\mathrm{gv},k} \tag{22}$$

其中，

$$\begin{aligned}&\boldsymbol{H}_{\mathrm{gv},k}=[\boldsymbol{0}_3\ \ \boldsymbol{I}_3\ \ \boldsymbol{0}_3\ \ \boldsymbol{0}_3\ \ \boldsymbol{0}_3\ \ \boldsymbol{0}_3]\\&\boldsymbol{D}_{\mathrm{gv},k}=\boldsymbol{I}_3\\&\boldsymbol{w}_{\mathrm{gv},k}\sim\mathcal{N}(\boldsymbol{0}_{3\times1},\sigma_{\mathrm{gv}}^2\boldsymbol{I}_3)\end{aligned}$$

2.4.4　误差更新与状态更新

为了便于表示，将观测模型统一表示为

$$\begin{aligned}&\boldsymbol{z}_k=\boldsymbol{H}_k\boldsymbol{\delta}_k+\boldsymbol{D}_k\boldsymbol{w}_{\mathrm{meas},k}\\&\boldsymbol{w}_{\mathrm{meas},k}\sim\mathcal{N}(\boldsymbol{0},\boldsymbol{\Sigma}_{\mathrm{meas},k})\end{aligned} \tag{23}$$

其中，$\boldsymbol{H}_k$、$\boldsymbol{D}_k$ 和 $\boldsymbol{\Sigma}_{\mathrm{meas},k}$ 分别表示第k时刻的观测矩阵、噪声矩阵和协方差矩阵。

在当前时刻，状态、误差状态及其协方差矩阵的后验估计分别记为 $\hat{\boldsymbol{x}}_k^+$、$\hat{\boldsymbol{\delta}}_k^+$ 和 $\boldsymbol{P}_k^+$；则在卡尔曼框架下，可得状态和误差的观测更新式：

$$\begin{aligned}&\boldsymbol{K}_k=\boldsymbol{P}_k^-\boldsymbol{H}_k^{\mathrm{T}}(\boldsymbol{H}_k\boldsymbol{P}_k^-\boldsymbol{H}_k^{\mathrm{T}}+\boldsymbol{D}_k\boldsymbol{\Sigma}_{\mathrm{meas},k}\boldsymbol{D}_k^{\mathrm{T}})^{-1}\\&\hat{\boldsymbol{\delta}}_k^+=\hat{\boldsymbol{\delta}}_k^-+\boldsymbol{K}_k(\boldsymbol{z}_k-\boldsymbol{H}_k\hat{\boldsymbol{\delta}}_k^-)\\&\boldsymbol{P}_k^+=(\boldsymbol{I}_{15}-\boldsymbol{K}_k\boldsymbol{H}_k)\boldsymbol{P}_k^-\\&\hat{\boldsymbol{x}}_k^+=\hat{\boldsymbol{x}}_k^-\boxplus\hat{\boldsymbol{\delta}}_k^+\end{aligned} \tag{24}$$

式中，运算符$\boxplus$表示利用误差后验估计值 $\hat{\boldsymbol{\delta}}_k^+$ 对状态先验估计值 $\hat{\boldsymbol{x}}_k^-$ 进行补偿，具体计算公式如下：

$$\begin{cases}\boldsymbol{p}_k^+=\boldsymbol{p}_k^-+\hat{\boldsymbol{\delta}}_{\boldsymbol{p},k}^+\\\boldsymbol{v}_k^+=\boldsymbol{v}_k^-+\hat{\boldsymbol{\delta}}_{\boldsymbol{v},k}^+\\\boldsymbol{R}_k^+=\boldsymbol{R}_k^-\exp(\hat{\boldsymbol{\delta}}_{\boldsymbol{a},k}^{+\wedge})\\\boldsymbol{b}_{\mathrm{a},k}^+=\boldsymbol{b}_{\mathrm{a},k}^-+\hat{\boldsymbol{\delta}}_{\boldsymbol{b}\mathrm{a},k}^+\\\boldsymbol{b}_{\mathrm{g},k}^+=\boldsymbol{b}_{\mathrm{g},k}^-+\hat{\boldsymbol{\delta}}_{\boldsymbol{b}\mathrm{g},k}^+\end{cases} \tag{25}$$

最后，对误差状态的后验估计值进行归零重置，为下一次滤波估计过程做准备，归零过程记为

$$\hat{\boldsymbol{\delta}}_k^+\leftarrow\boldsymbol{0}_{15\times1} \tag{26}$$

3　实验（Experiments）

3.1　实验平台搭建

硬件平台由 3 部分构成：（1）四轮独立驱动越野型移动机器人；（2）传感器集合；（3）工控机。移动机器人及其传感器配置情况如图 3 所示。

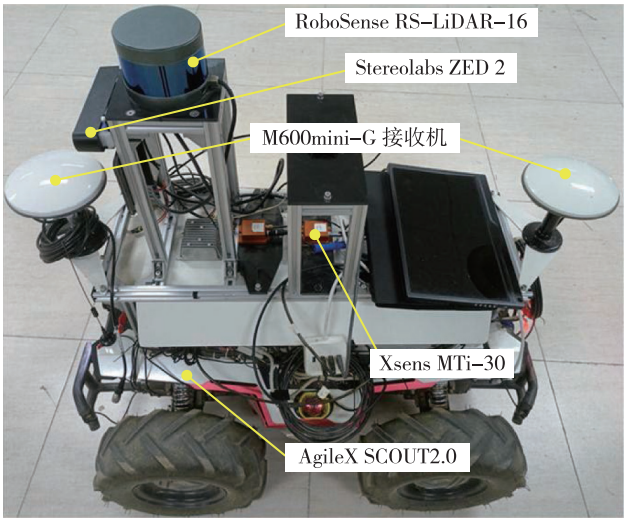

图 3　移动机器人及其传感器配置

移动机器人为 AgileX SCOUT2.0，工控机为 NVIDIA Jetson AGX Xavier，工控机通过 CAN（控制器局域网络）接口与移动机器人下位机通信，实时获取底盘的轮胎转速、线速度等运动状态信息。传感器产品包括：轮式编码器（SCOUT2.0 自带）、惯性测量单元（Xsens MTi-30）、双目视觉传感器（Stereolabs ZED 2）、激光雷达（RoboSenseRS-LiDAR-16）、RTK 接收机（司南导航 M600miniG GNSS-RTK 接收机），各传感器产品的输出参数见表 1。

表 1　各传感器产品的输出参数表

传感器 / 产品	输出数据
轮式编码器	转速（rad/s）
Xsens MTi-30	角速度（rad/s）
	比力（$m \cdot s^{-2}$）
	磁场强度（0.1mT）
	姿态角（°）
Stereolabs ZED 2	双目图像
	角速度（rad/s）
	比力（$m \cdot s^{-2}$）
RoboSense RS-LiDAR-16	点云
RTK 接收机	位置（m）
	水平精度：10mm+$D \times 10^{-6}$mm
	高度精度：20mm+$D \times 10^{-6}$mm

注：D 代表以千米计量的 RTK 接收机到基站的距离数值

整个导航系统在 ROS 环境下使用 C++ 语言编程实现，其中，激光定位子系统改编自 LeGOLOAM[7] 开源算法包，视觉定位子系统算法改编自 VINS-Fusion[9] 开源算法包。表 2 展示了系统各模块的输出频率。

表 2　系统各模块的输出频率

激光定位子系统	视觉定位子定位	全局速度测量子系统	融合估计器输出
3Hz	10Hz	20Hz	>30Hz

3.2　测试及其评估

为了充分验证本文融合定位算法的有效性，分别在街道场景和野外场景下完成定位测试，表 3 列出了各实验场景中移动机器人的基本运动情况。

表 3　各实验场景中移动机器人的基本运动情况

场景	路程 /m	时长 /s	平均速度 /（m/s）	参考源
街道	1419	1158	1.23	RTK
野外	529	619	0.85	RTK

实验中，将各传感器数据采集下来，分别进行了如下定位算法测试：（1）利用 VINS-Fusion 算法[9] 进行 IMU/ 相机融合定位；（2）利用 LeGO-LOAM 算法[7] 进行 IMU/ 激光雷达融合定位；（3）利用 robotlocalization 算法[12] 进行 IMU/ 编码器 / 相机 / 激光雷达融合定位；（4）利用本文的 IEVL-Fusion 算法进行 IMU/ 编码器 / 相机 / 激光雷达融合定位；（5）利用本文的 IEVL-Fusion-no 算法进行 IMU/ 编码器 / 相机 / 激光雷达融合定位。IEVL-Fusion-no 算法是将 IEVL-Fusion 算法中编码器全局式融合替换为局部式融合后得到的算法，其余部分均与 IEVLFusion 算法相同。各定位算法的文献来源及其所用传感器组合如表 4 所示。

图 4 展示了街道实验中相关的照片和定位曲线。街道数据采集于晚上 6 点左右，光线由明变暗，移动机器人总的行驶路程约为 1419m，高度变化约 2.5m，行驶时长约 1158s，平均速度约 1.23m/s。图 4（a）为街道所在区域的卫星地图，红色曲线为 RTK 参考轨迹，移动机器人绕着两栋教学大楼走出了一个“8”形，其中约有 1/4 的石板路，另外 3/4 为柏油路。图 4（b）为实验过程中实拍到的移动机器人和环境的照片，此时的光线昏暗，马路旁路灯已经打开。图 4（c）为各算法的 3 维轨迹估计结果，对比来看，IEVL-Fusion 算法的结果更加接近 RTK 给出的参考轨迹。图 4（d）为各算法在 X、Y、Z 分量上的定位误差关于时间的变化曲线。

图 5 展示了野外实验中相关的照片和定位曲线。野外数据采集的时间在下午 2:30 左右，移动机器人

表 4　各定位算法及其所用传感器组合

定位方案	来源	融合方法	IMU	相机	激光雷达	编码器融合方式	
						局部速度融合	全局速度融合
VINS-Fusion	文 [9]	优化	√	√			
LeGO-LOAM	文 [7]	优化	√		√		
robot-localization	文 [12]	EKF	√	√	√	√	
IEVL-Fusion-no	本文	ES-EKF	√	√	√	√	
IEVL-Fusion	本文	ES-EKF	√	√	√		√

（a）街道所在区域的卫星地图

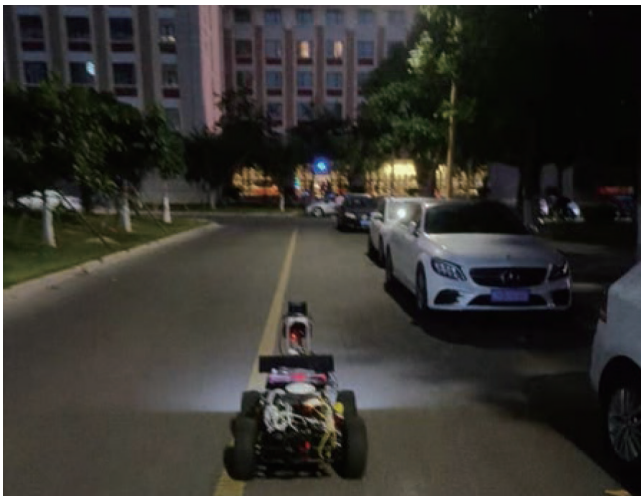

（b）移动机器人和环境的实验实拍图

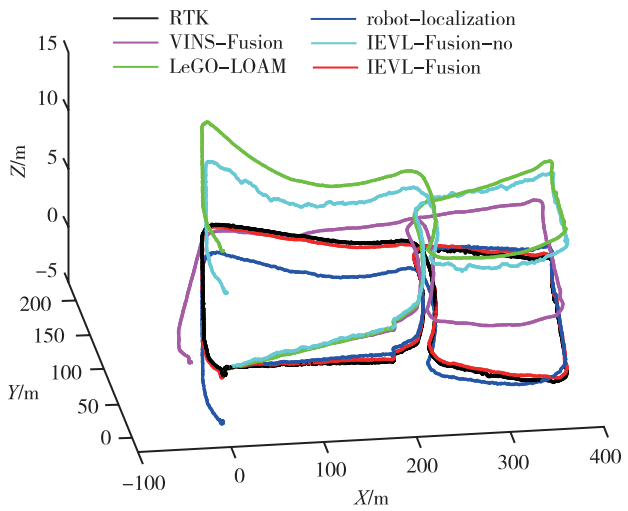

（c）各算法的 3 维轨迹估计结果

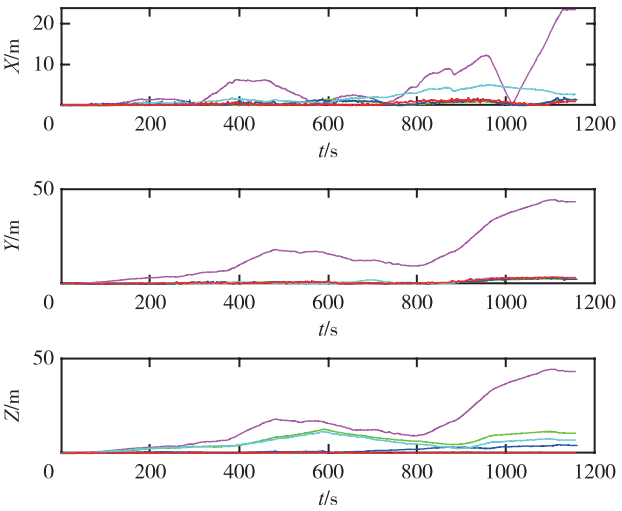

（d）各算法在各轴上的位置误差

图 4　街道实验中相关的照片和定位曲线

（a）实验所在区域的卫星地图

（b）移动机器人和环境的实验实拍图

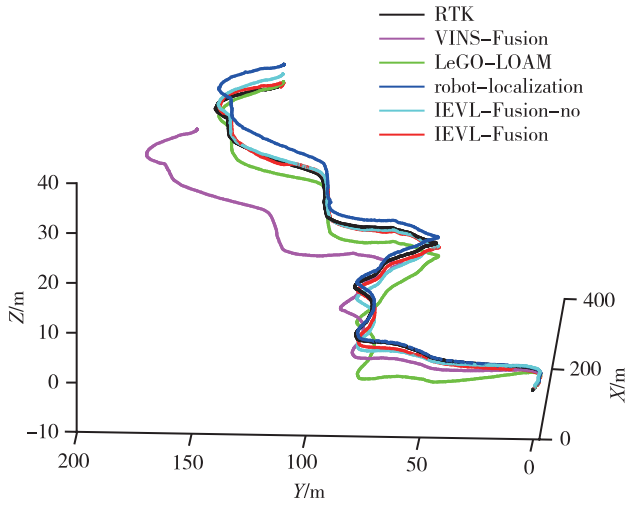

（c）各算法的 3 维轨迹估计结果

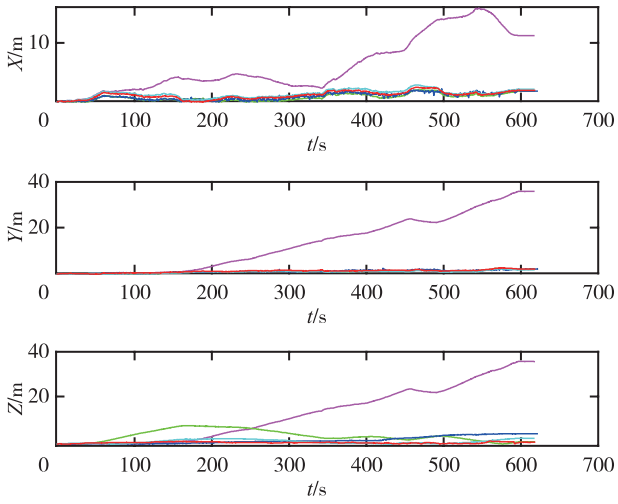

（d）各算法在各轴上的位置误差

图 5　野外实验中相关的照片和定位曲线

总的行驶路程约为 529m，高度变化约 35m，行驶时长约 619s，平均速度约 0.85m/s。图 5（a）为实验所在区域的卫星地图，红色曲线为 RTK 参考轨迹，移动机器人沿着非常崎岖的土路曲折前行，道路两旁为自然生长的植被。图 5（b）为实验过程中实拍到的移动机器人和周围环境的照片，可以看到，这样的场景在野外是普遍存在的。图 5（c）为各算法的 3 维轨迹估计结果，IEVL-Fusion-no、IEVLFusion 和 robot-localization 算法的定位轨迹均有较好的收敛。图 5（d）为各算法的 X 分量、Y 分量和 Z 分量的定位误差关于时间的变化曲线，从曲线变化很难直观看出定位效果，需要进一步定量分析。

实验过程中 RTK 接收机的数据接收正常，本文依据 RTK 定位数据对测试结果进行量化与评价。为了对定位结果进行综合评估，本文定义了 4 个量化指标：最大定位误差 ME、最大相对定位误差 MRE、平均定位误差 AE 和平均相对定位误差 ARE[11]：

$$\begin{cases} \mathrm{ME} = \max\{\|\hat{\boldsymbol{p}}_i - \boldsymbol{p}_i^{\mathrm{RTK}}\|\}_{i=1}^{N}, & \mathrm{MRE} = \dfrac{\mathrm{ME}}{D} \times 100\% \\ \mathrm{AE} = \dfrac{1}{N}\displaystyle\sum_{i=1}^{N}\|\hat{\boldsymbol{p}}_i - \boldsymbol{p}_i^{\mathrm{RTK}}\|, & \mathrm{ARE} = \dfrac{\mathrm{AE}}{D} \times 100\% \end{cases} \tag{27}$$

其中，N 表示采样点的个数，D 表示机器人运动的路程。

依据以上定义的量化指标，对各算法的 X、Y、Z 三个分量和总体（3D 位置）进行指标计算，计算结果列于表 5 中，其中加粗的字体表示对应列中的最小值。

就总体定位误差而言，IEVL-Fusion 在 ME、MRE、AE 和 ARE 四个指标上均为最好，平均相对定位误差小于总路程的 0.4%，最大相对定位误差小于 0.7%。相较于 VINS-Fusion、LeGO-OAM、robotlocalization 和 IEVL-Fusion-no 算法，IEVL-Fusion 算法的最大相对定位误差分别降低了约 90%、65%、40% 和 40%。

对比各算法在 X 和 Y 分量上的定位误差可看出，IEVL-Fusion 算法的水平定位精度和 LeGOLOAM 算法相当。但在 Z 分量上，IEVL-Fusion 算法具有最小的定位误差，且 IEVL-Fusion 算法的平均定位误差相较于 VINS-Fusion、LeGO-LOAM、robot-localization 以及 IEVL-Fusion-no 算法分

表 5　各算法在 X、Y、Z 轴上的定位误差和总体定位误差

场景	算法	X 分量 AE/m	Y 分量 AE/m	Z 分量 AE/m	总体误差（3D 位置）			
					ME/m	MRE/%	AE/m	ARE/%
街道	VINS-Fusion	4.83	15.28	2.20	49.43	3.48	16.5	1.16
	LeGO-LOAM	0.52	0.71	6.27	12.68	0.89	6.35	0.45
	robot-localization	0.74	0.94	1.75	5.79	0.41	2.25	0.16
	IEVL-Fusion-no	2.01	1.04	5.14	11.39	0.80	5.87	0.41
	IEVL-Fusion	0.49	0.95	0.28	3.57	0.25	1.21	0.10
野外	VINS-Fusion	6.26	12.99	4.61	38.33	7.25	15.61	2.95
	LeGO-LOAM	0.77	1.02	3.56	8.04	1.52	4.04	0.77
	robot-localization	1.11	1.30	2.21	5.36	1.01	2.88	0.55
	IEVL-Fusion-no	1.38	0.94	1.05	3.79	0.72	2.17	0.41
	IEVL-Fusion	1.15	1.22	0.60	3.28	0.62	1.88	0.36

别降低了 86%、83%、72% 和 42% 以上。

实际上，偏航角ψ、俯仰角θ、滚转角ϕ与旋转矩阵$\boldsymbol{R}$之间存在如下关系：

$$\boldsymbol{R}=\begin{bmatrix} * & * & * \\ * & * & * \\ -\sin\theta & \cos\theta\sin\phi & \cos\phi\cos\phi \end{bmatrix} \quad (28)$$

其中，* 表示与ψ有关的项。AHRS 输出的俯仰角和滚转角是以重力向量为参考求解到的，偏航角是以地磁为参考的。根据全局速度观测模型（21），全局速度$\boldsymbol{C}_{\mathrm{m},k}\boldsymbol{v}_{\mathrm{m},k}$的第 3 个分量是有绝对参考的竖直速度测量值，第 1 个分量和第 2 个分量易受到周围环境中电磁干扰的影响，无法提供无偏的速度测量值。这一分析与实验结果相互印证，即全局速度观测更新对于竖直方向上的误差累积具有显著的抑制作用。

4 结论与展望（Conclusion and prospect）

针对卫星拒止环境中移动机器人高精度定位的需求，提出一种基于 ES-EKF 的激光定位子系统 / 视觉定位子系统 / 全局速度测量子系统松耦合融合定位方法，设计了一个误差漂移低、输出频率高的 IMU/ 编码器 / 相机 / 激光组合定位系统，并在城镇和野外场景下进行了测试。相较于 VINSFusion、LeGO-LOAM、robot-localization 等定位算法，本文提出的方法具有更高的定位精度。本文方法的主要优势为：（1）无需对整个定位系统进行重复设计即可实现 LeGO-LOAM、VINS-Fusion 算法在组合导航中的快速集成和应用；（2）将位姿融合转化为位姿增量融合，避免了激光定位系统中位姿协方差无法建模的问题；（3）利用 IMU 和编码器分解得到机器人的全局速度测量值，对状态估计器的高度估计产生有效约束，显著提高整个系统的状态估计精度。

在实际的移动机器人导航中，除了努力提高定位系统的精度之外，还希望提升复杂环境下移动机器人的定位鲁棒性和持续性[22]。例如，遮挡、逆光等会造成视觉定位算法失效，长廊会造成激光定位算法失效[23-24]。因此，在接下来的研究中，将进一步利用多传感器融合技术赋予系统处理这些问题的能力，提升整个定位系统的定位可靠性。

来源：《机器人》

作者简介

武东杰（1990—），男，博士生。研究领域：多源融合定位与自主导航。

仲训昱（1980—），男，博士，副教授。研究领域：多源融合定位与自主导航。

崔晓珍（1997—），女，硕士生。研究领域：组合导航。

一种基于功用性图的目标推抓技能自监督学习方法

文 / 吴培良　刘瑞军　毛秉毅　史浩洋　陈雯柏　高国伟

摘要：提出了一种基于功用性图的目标推抓技能自监督学习方法。首先，给出了杂乱环境下面向目标推抓任务的机器人技能自监督学习问题描述，将工作空间中机器人推抓操作的决策过程定义为一个全新的马尔可夫决策过程（MDP），分别训练视觉机制模块与动作机制模块。其次，在视觉机制模块中融合自适应参数与分组拆分注意力模块设计了特征提取网络 RGSA-Net，可由输入网络的原始状态图像生成功用性图，为目标推抓操作提供良好的前提。然后，在动作机制模块中搭建了基于演员 – 评论家（actor-critic）框架的深度强化学习自监督训练框架 DQAC，机器人根据功用性图执行动作后利用该框架进行动作评判，更好地实现了推、抓之间的协同。最后，进行了实验对比与分析，验证了本文方法的有效性。

关键词：推抓技能学习；功用性图；自监督学习；自适应参数；拆分注意力机制

1　引言（Introduction）

近年来，机器学习方法快速发展，使得机器人可以实现对未知物体的自主抓取操作，但机器人抓取杂乱场景下的目标物体仍面临不小的挑战。一些研究在 Conell Grasping、Jacquard 等抓取数据集上通过深度学习方法进行有监督的训练以获取最优抓取框[1-4]、判定物体的抓取点或抓取姿势，进而完成机器人对物体的抓取任务，但应用大量数据集导致训练时间过长。强化学习的兴起，使得机器人可以自监督地与环境进行信息交互，进而完成所设定的任务。传统强化学习方法为机器臂抓取、机器人堆叠和整理、四足机器人行走以及机器人导航等高维度的控制问题提供了较好的解决方案。

数据驱动的方法在许多方面都取得了成功，受此鼓舞，深度神经网络也被用在杂乱场景下的物体姿态估计。机器人通过对抓取数据集训练实现了对目标物体的抓取[1-4]。Morrison 等[1]提出生成式抓取卷积神经网络（GG-CNN），对图像中每个像素的抓取质量和姿势给出得分。Redmon 等[2]使用单阶段回归法找到可抓取的矩形检测框。Levine 等[3]拟合了末端夹具的运动轨迹进而预测抓取成功的概率，并探索了多个机器人并行化训练的方法。Schmidt 等[4]提出了一种数据驱动、自下而上的学习方法，使用深度卷积神经网络（DCNN）来实现机器人对新颖对象的抓取。Mahler 等[5]使用 Dex-Net 2.0 数据集训练抓取质量卷积神经网络（GQ-CNN）模型，根据深度相机给出的 3D 点云信息，找到鲁棒性最高的吸附抓取点。Kumra 等[6]提出了一种新颖的生成式残

基金项目：国家重点研发计划（2018YFB1308300）；国家自然科学基金区域联合基金（U20A20167）；北京市自然科学基金（4202026）；河北省自然科学基金（F202103079）.

通信作者：毛秉毅，ysdxmby@163.com　收稿 / 录用 / 修回：2021-06-18/2021-08-20/2021-08-24

差网络（GR-ConvNet）模型，用于反足机器人从场景的n通道图像中生成最佳抓取点，成功完成对未知目标的抓取。Lou等[7]提出了一种基于3维像素的深度卷积神经网络（3D-CNN），可在能实现可达性感知的无限制工作空间中生成可行的6自由度机器人抓取姿态。Shao[8]等基于ResNet和U-Net[9]网络训练了一种端到端的神经网络，在不需要进行识别和姿态估计的非结构化环境中预测抓取区域。深度学习中使用的数据集大多由人工标记抓取点构成，由于存在多种抓握方式，因此标记并非易事；而且，受语义偏见的影响，实验中使用的数据量较低，这也导致机器人倾向于过拟合[10]。

基于深度强化学习算法的自监督抓取策略为实现自动化抓取提供了可能，该类方法在抓取对象形状、位姿未知的情况下，通过策略迭代与奖励值反馈进行自监督学习。Shukla等[11]将形状规则的刚性目标抓取的问题分解为位置和方向学习，提出了一种GDQN（抓取深度Q网络）深度强化学习算法，用于姿态估计，并验证了该网络的有效性，但其对于目标物体要求较高且需要部分人工标注。Kalashnikov等[12]提出了一种大规模分布式优化和深度Q学习拟合的离线策略训练方法，实现了机器人的动态操作，但其硬件要求过高导致复现较难。Sarantopoulos等[13]提出了一种模块化的强化学习方法，使用连续动作将目标对象从周围的杂波中完全分离出来。通过动作原语和特征选择，将先验知识有效地融入到学习中，提高了样本效率，一定程度上解决了训练效率低的问题。Quillen等[14]探索了一种基于视觉的机器人抓取深度强化学习算法，根据异策略（off-policy）强化学习算法评估无模型的机器人抓取任务。Hou等[15]在机器人抓取之前，通过监督学习对Q网络进行预训练，验证了该方法能够在早期阶段显著加速自监督学习，并且与工作空间中对象的稀疏性几乎无关。Deng等[16]基于DQN（深度Q网络）设计了一种结合吸盘与夹持器的新型机械手的主动探索算法，在杂波环境中完成了抓取任务。Xie等[17]提出带失败概率的贝叶斯逆强化学习（BIRLF）算法，该算法从策略最优性条件导出半空间，在贝叶斯逆强化学习（BIRL）框架下合并失败的经验并回传给机器人，适用于工作空间更复杂的环境。但其需要对规则物体进行前期人工标注，工作量较大。Johannink等[18]直接在现实世界中训练智能体，将机械臂控制难题分解为常规反馈控制方法解决的部分和用RL（强化学习）法解决的残差部分，有效地解决实际控制问题。Mohammadi等[19]在改进的DDPG（深度确定性策略梯度）基础上提出了一种在线连续深度强化学习的方法，用于完成混乱环境中的抓取任务。Ni等[20]针对边缘物体抓取，将抓取质量函数的变化与遗忘机制相结合来训练推抓动作，此外，还设置了双重体验重播，以增加边界上的搜索。文[21-22]都在DQN算法的基础上提出了新的改进，Gui等[21]提出了一种知识诱导的深度Q学习模型（KI-DQN），在采取抓取动作之前先将目标物体推向墙壁，将该问题看作马尔可夫决策过程，主动利用环境优势来抓取物体。Joshi等[22]构建双重DQN框架抓取网络来输出抓取概率，提高了抓取成功率，但其需要收集海量训练数据，还要在多个物理机器人上进行训练，大大增加了训练成本。Zhang等[23]基于DQN提出了一种堆叠抓取网络（GSN），在研究目标物体的抓取问题时进一步讨论了物体放置问题，但其仅考虑了单个物体的场景，具有一定的局限性。Zeng等[24]通过卷积神经网络预先计算每个动作的置信度Q值，然后通过环境奖励反馈进行梯度回传，通过推、抓之间的协同完成抓取任务，但其使用传统DQN算法训练动作，使得推、抓之间的协同性较差。Yang等[25]在文[24]的基础上通过语义分割得到目标掩码，并使

用二分类网络训练推、抓之间的协同，重新排列目标周围的干扰物体，实现了对目标物体的抓取，但其仍然存在抓取点定位不准确、推抓协同效率低等问题。

针对杂乱环境下面向目标物的抓取任务，本文提出一种基于功用性图检测的目标抓取技能自监督学习方法，主要贡献包括：

（1）给出了杂乱环境下面向目标抓取的问题描述，并将其表示为一个全新的马尔可夫决策过程（MDP）。其中状态信息包括 t 时刻的图像状态与特征状态，对于 2 种状态分别给出奖励函数集合。

（2）基于自适应参数调节与分组拆分注意力机制，提出一种新型特征提取网络 RGSA-Net，它可根据 RGB-D 摄像机采集到的状态得到精准推抓的功用性图（affordance map）。同时，通过自适应参数调节防止梯度弥散。

（3）基于演员 - 评论家框架的思想，在动作机制模块中设计 DQAC 算法。该算法将基于值函数与策略梯度的算法的优势结合起来，用于训练机器人推、抓之间的协同。

2 问题描述与求解框架（Problem descrip-tion and solution framework）

2.1 推动和抓取任务描述及抽象化

杂乱环境的特点是在一个场景下一些形状未知的物体呈无规律堆叠，而且目标物体被严重遮挡。因此，该环境中面向目标的抓取尤为困难。功用性图定义了某一像素的推抓置信度，颜色越深表示采取动作的置信度越高，反之置信度越低。本文研究机器人在图 1 所示的杂乱环境下面向目标的推抓问题，采用 RGB-D 相机作为机器人的外部传感器，利用功用性图判断该场景中是否存在适于抓取的位置和角度。若存在则直接抓取；若不存在，则采取若干次推动动作，增大目标物体周围的空间供机器人抓取。

本文将机器人面向目标的推抓技能学习问题定义为一个马尔可夫决策过程（MDP），该过程由七元组（S，S^{C}，A，R^{q}，R^{C}，$\boldsymbol{P}$，γ）组成。参数 S 表示图像状态集，集合中以图像的形式存储每一时刻相机所采集到的环境状态；

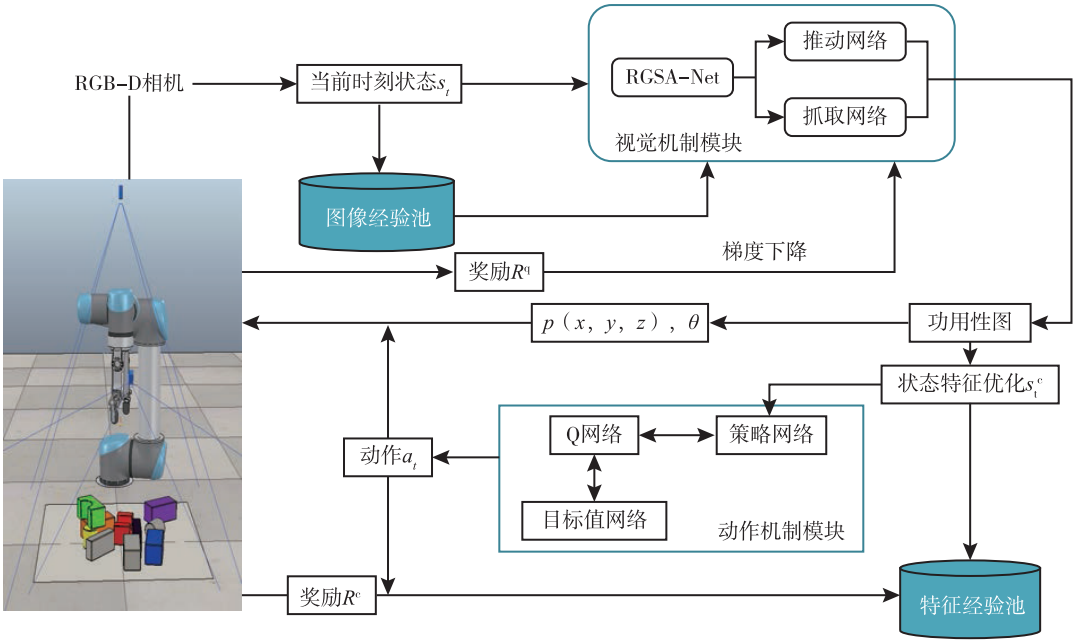

图 1　机器人目标推抓技能自监督学习系统

参数 S^C 表示特征状态集，集合中以功用性图的形式存储每一时刻状态 S 经特征提取网络处理后生成的特征状态；参数 A 为有限动作集合，包括推动与抓取动作；参数 R^q 为针对特征设计的奖励函数，集合中存储每一时刻的 Q 值以及奖励值；参数 R^C 为根据动作以及环境反馈给出的奖励函数集合；参数 $\boldsymbol{P}(s^c_{t+1} \mid s^c_t, a_t)$ 为根据当前时刻状态与动作得到的下一时刻状态的转移概率矩阵；参数 $\gamma \in (0, 1]$ 为折扣因子，用于平衡即时奖励以提高奖励期望。机器人在任意时刻 t 接收到图像状态 $\boldsymbol{s}_t$ 与特征状态 $\boldsymbol{s}^c_t$，并基于深度强化学习策略以概率 p 选择行为 a_t，进入新的状态 $\boldsymbol{s}_{t+1}$ 和 $\boldsymbol{s}^c_{t+1}$ 并得到相应的奖励 $r^q(s_t, a_t)$ 和 $r^c(s^c_t, a_t)$。

2.2 问题求解的总体框架

基于深度强化学习设计了一种目标推抓技能自监督学习方法。如图 1 所示，整个框架分为视觉机制模块和动作机制模块。首先将机器人上方的 RGB-D 相机获取的工作台图像信息作为当前时刻的状态 s_t 放到图像经验池（SRB）和视觉机制模块中。图像经验池用于打破相邻时间内图像的相关性。视觉机制模块由两部分构成，一部分是 RGSA-Net 特征提取网络，另一部分是由推抓网络构成的动作网络。该模块用于生成推抓功用性图，整合推抓操作的位置 $p(x, y, z)$ 和角度信息 $\boldsymbol{\theta}$。利用环境给出的功用性图奖励 R^c 进行随机梯度下降来训练网络参数。将功用性图作为当前时刻的特征状态 $\boldsymbol{s}^c_t$ 送入特征经验池（FRB）与动作机制模块中。特征经验池用于打破相邻时间内特征的相关性。动作机制模块将传统的演员 - 评论家框架进行拆分，将评价网络进一步分解成值网络（Q 网络）与目标值网络（Target Q 网络），用于训练机器人推、抓动作之间的协同，利用环境给出的动作奖励 R^c 更新参数。

视觉机制模块的执行流程如图 2 所示。首先在相机坐标系中将深度信息投影到 3D 点云中，创建 RGB-D 高度图，经预处理后得到状态高度图（heightmap），将其旋转 16 次后输入到特征提取网络 RGSA-Net 进行特征提取。然后将提取到的特征作为推抓动作网络的输入，分别得到推动与抓取动作的功用性图，进而求得在执行动作时所需的置信度最大的像素点与角度。最后根据手眼标定结果将相机坐标系信息转化为机器人坐标系信息，在工作空间中得到接触点位置与角度来执行动作。

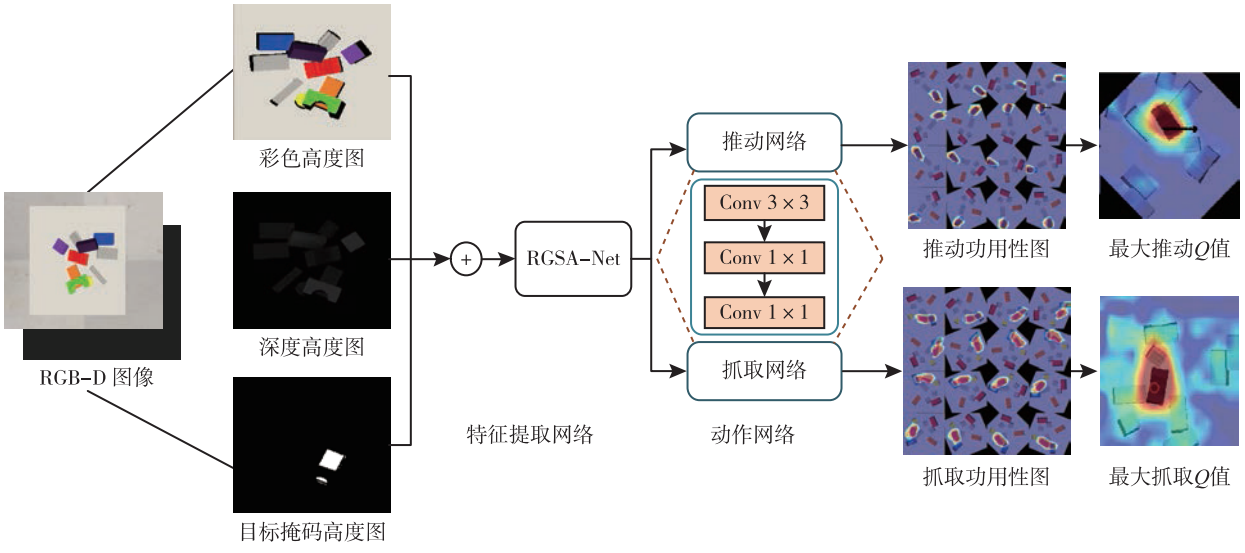

图 2　视觉机制模块执行流程

动作机制模块基于演员－评论家框架的思想，其策略网络输入为当前状态值，输出为决策动作，目标是训练最优的策略 $\pi_\theta(s^c, a)$ 以达到最高奖励，即在状态 s_t^c 下执行动作 a_t 可得到最优的参数 $J(\theta)$：

$$J(\theta)=\sum_{a\in A}\pi_\theta(s^c,a)r^c(s_t^c,a_t) \tag{1}$$

其评价网络基于值函数，负责评估动作网络的表现，并指导该网络下一阶段的输出动作，即评判动作执行的好坏，其目标函数梯度更新计算公式如下：

$$\nabla J(\theta)=\sum_{a\in A}\pi_\theta(s^c,a)\nabla_\theta \operatorname{lb}\pi_\theta(s_t^c,a)r^c(s_t^c,a_t) \tag{2}$$

3 方法（Method）

3.1 推抓功用性图特征提取网络 RGSA-Net

为了生成准确的推抓功用性图，本文在视觉机制模块中以深度残差网络（ResNet18[9]）作为主骨干，设计了一种基于分组卷积和自适应拆分注意力机制的特征提取网络 RGSA-Net。该网络将预处理后得到的 3 种高度图（彩色高度图、深度高度图、目标掩码高度图）旋转 16 次后作为输入，得到所有像素点期望 Q 值并生成推抓功用性图，采取贪婪策略选取最大的 Q 值像素点转化为动作执行位置点 $p(x, y, z)$，同时得到动作执行的角度 θ。

3.1.1 自适应参数

深度神经网络虽然在各个领域取得了很大进展，但是经常面临梯度消失或梯度弥散等问题，研究者通常使用 3 种方法解决上述问题[26]：1) 设置初始化；2) 使用 BatchNorm 或 LayerNorm 等算法实现正则化；3) 残差连接方法。而这些方法同样存在着设计痕迹过重、计算开销大等问题。对于一个深度为 L 的模型，传统残差网络第 l 层输出为

$$z^{(l)}=\mathcal{H}\left(x^{(l-1)}\right)=x^{(l-1)}+\mathcal{F}\left(x^{(l-1)}\right) \tag{3}$$

本文在残差连接前增加一个初始值为 0 的自适应参数，该参数可以使得模型更好地接收梯度信号，加快网络的收敛速度，其基本形式如下：

$$z^{(l)}=\mathcal{H}\left(x^{(l-1)}\right)=x^{(l-1)}+\alpha_i\times\mathcal{F}\left(x^{(l-1)}\right) \tag{4}$$

残差网络可以解决传统神经网络中梯度弥散的问题，但用其拟合恒等变换并不容易。恒等变换的主要目标是构造一种天然的恒等映射，即：

$$x^{(l)}=z^{(l)} \tag{5}$$

等价于令残差部分 $\mathcal{F}(x^{(l-1)})\to 0$。

对于任意 2 个层数 $l_2 > l_1$，可将式（3）递归展开：

$$x^{(l_2)}=x^{(l_1)}+\sum_{i=l_1}^{l_2-1}\alpha_i\times\mathcal{F}(x^{(i)}) \tag{6}$$

最终损失 ε 对于低层输出的梯度可展开为

$$\frac{\partial\varepsilon}{\partial x^{(l_1)}}=\frac{\partial\varepsilon}{\partial x^{(l_2)}}+\frac{\partial\varepsilon}{\partial x^{(l_2)}}\frac{\partial}{\partial x^{(l_1)}}\sum_{i=l_1}^{l_2-1}\alpha_i\times\mathcal{F}(x^{(i)}) \tag{7}$$

式中前一项表示反向传播时错误信号不经过任何中间权重矩阵变换直接传播到低层，可以很好地缓解梯度弥散问题。

自适应参数 α_i 的训练如下所示。假设深度神经网络模型输出由式 (8) 给出：

$$x_L=(1+\alpha\omega)^L x_0 \tag{8}$$

其中权重参数 ω 的训练迭代过程为

$$\omega\leftarrow\omega-\lambda L x_0(1+\alpha\omega)^{L-1}\partial C \tag{9}$$

式中 C 为损失函数，λ 为学习率。由式 (9) 可以看出：当 $\alpha=0$ 时，第 1 轮更新没有更新参数 ω。参数 α 的训练过程如下：

$$\alpha\leftarrow\alpha-\lambda L x_0\omega\partial C=-\lambda L x_0\omega\partial C,\quad \alpha=0 \tag{10}$$

从第 2 轮开始，权重参数 ω 的更新方式为

$$\lambda L x_0(1+\alpha\omega)^{L-1}\partial C=\lambda L x_0(1-\lambda L x_0\omega^2\alpha C)^{L-1}\partial C \tag{11}$$

由式 (11) 可以看出，如果损失函数 C 是合理的，当前的更新不会导致很强的梯度振荡（$\lambda L x_0\times\omega^2\alpha C\approx 0$），保证了深度神经网络模型更新时网络的稳定性。自适应参数 α_i 在 RGSA-Net 网络中的更新过程如图 3 所示。

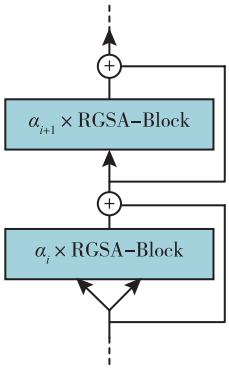

图 3　自适应参数更新过程

3.1.2 基于分组卷积的 RGSA-Block

分组卷积已经被证实可以在效能不变的情况下大大减少参数量[27]。若初始输入深度神经网络的特征向量维度为 $C_1 \times H \times W$，则将该特征在通道维度上分成 g 个基数组 $\{\boldsymbol{G}_1, \boldsymbol{G}_2, \cdots, \boldsymbol{G}_g\}$，每组特征维度为 $(C_1/g) \times H \times W$。若普通卷积对应的卷积核大小为 $K \times K \times C_1$，则分组卷积核的维度为 $K \times K \times C_1/g$。将 g 组特征在通道维度拼接后仍可得到维度为 $C_2 \times H \times W$ 的输出特征。此时深度神经网络的参数量可减少为标准卷积操作的 $1/g$，且经过不同路径卷积得到的特征图之间的耦合性较低，利用所关注的不同特征可以得到互为补充的特征图。

将 RGB-D 相机采集到的图片数据经过一种语义分割的深度全卷积神经网络结构 SegNet[28] 作预处理后，得到了彩色高度图（RGB-height）、深度高度图（depth-height）、目标掩码高度图（mask-height）。将完成特征提取后的 3 种数据在通道维度融合，得到维度为 1×5×640×640 的特征。深度强化学习框架每次训练输入网络的样本数量为 1 会导致特征归一化失败，因此本文在通道维度增加相同维度的数据并进行特征拼接。最终 RGSA-Net 网络的输入特征维度为 2×5×640×640，输出特征维度为 1×1024×20×20。

如图 4 所示，本文的 RGSA-Block 基本块先将输入特征分为 2 个候选集（K=2），每一集合又分成 2 组（G=2）进行训练，每一组特征在经过 2 个不同卷积块后馈入到拆分注意力模块进行特征融合。卷积块由卷积层、归一化层、ReLU（线性整流）激活函数依次构成，区别在于卷积核的大小分别为 3×3 和 5×5。2 个候选集的输出特征经过拼接操作后由 1×1 的卷积块进行维度调整以适应网络输入，乘上自适应参数 α_i 后与原始特征向量相加，作为最终的输出特征。

如图 5 所示，将 RGSA-Block 基本块嵌入到残差网络 ResNet-18 后得到了 RGSA-Net。

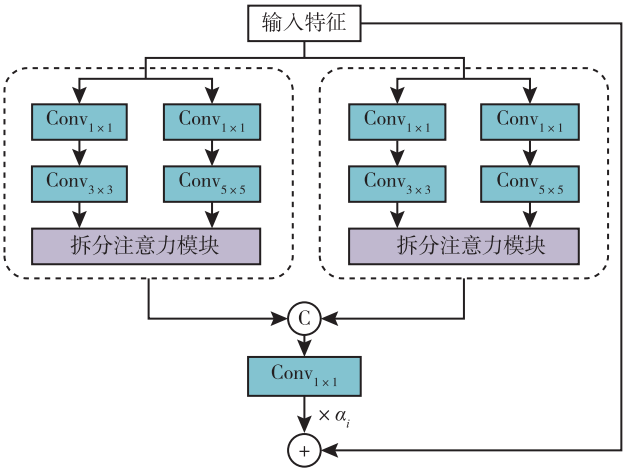

图 4　RGSA-Block 网络结构

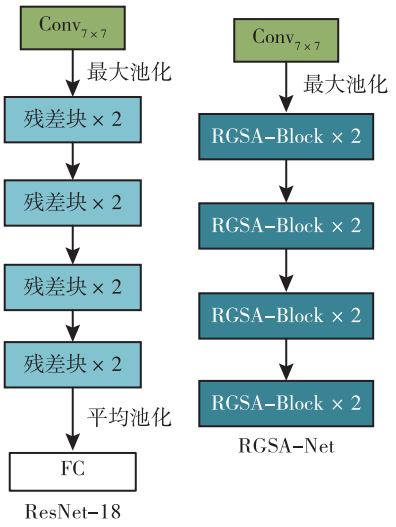

图 5　RGSA-Net 网络结构

3.1.3 基于拆分注意力机制的 Split-Attention 模块

在计算能力有限的情况下，机器人需要更加注意目标物体周围的情况[29]。使用具有注意力机制的深度神经网络，可以使机器人更快地定位目标物体，提高对目标物体的注意力程度，从而探索更多的环境状态以获得目标信息。如图 6 所示，本文采用基于通道的拆分注意力机制[29]，对于输入 RGSA-Net 网络的彩色高度图、深度高度图、目标掩码高度图 3 种状态高度图在通道方面给予不同的权重，以建模 5 个通道的重要程度。

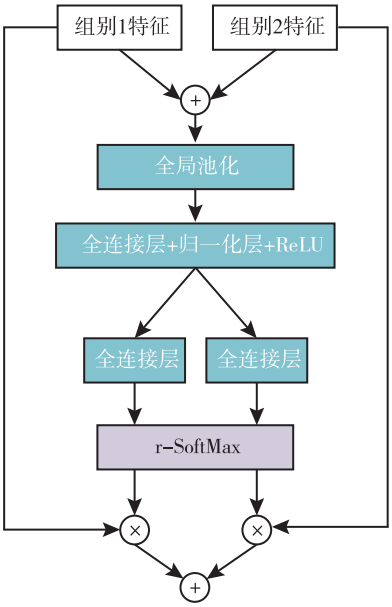

图 6 拆分注意力网络结构

图 6 中，设每个输入特征的维度为 $W\times H\times C$，其中 $C=\frac{C_1}{K}$，特征融合计算公式为

$$\hat{\boldsymbol{T}}_k=\sum_{j=r(k-1)+1}^{rk}\boldsymbol{T}_j \tag{12}$$

其中 r=2 为基数，将融合后的特征进行全局平均池化，计算公式如下：

$$\boldsymbol{s}_k^{\mathrm{c}}=\frac{1}{H\times W}\sum_{i=1}^{H}\sum_{j=1}^{W}\hat{\boldsymbol{T}}_k^{\mathrm{c}}(i,j) \tag{13}$$

至此，将得到的单图平均后的中间特征经过卷积块处理后进行通道拆分，拆分成通道数为 3、1、1 的 3 种特征后，再分别经过全连接层和 r-SoftMax 层进行特征提取，r-SoftMax 层参数计算如下：

$$a_i^k(d)=\begin{cases}\dfrac{\exp(F_i^{\mathrm{c}}(\boldsymbol{s}_k))}{\sum_{j=0}^{r}\exp(F_i^{\mathrm{c}}(\boldsymbol{s}_k))}, & r>1\\ \dfrac{1}{1+\exp(-F_i^{\mathrm{c}}(\boldsymbol{s}_k))}, & r=1\end{cases} \tag{14}$$

将经过 r-SoftMax 层处理的 3 种特征在通道维度进行特征融合，得到通道数为 5 的输出特征，并将其输入到下一个网络模块中。

3.2 面向机器人推抓技能学习的 DQAC 算法

训练面向目标物体的推、抓动作之间的协同是机器人抓取成功的关键。在保证抓取成功率的同时尽可能地减少机器人运动次数，就需要建立起良好的评估机制，充分训练推、抓之间的协同策略。

3.2.1 DQAC 算法思想

本文的动作机制模块是基于演员－评论家框架[30]设计的一种自监督学习算法 DQAC，该算法由策略网络和值网络构成。策略网络建立模型 $\boldsymbol{\pi}(\boldsymbol{s},a;\boldsymbol{\theta})$ 将动作选择策略参数化，根据状态的分布概率选择离散动作。值网络评判当前动作以迭代更新策略参数值，使得策略模型的累积回报不断增加，从而得到最优的协同动作策略。

3.2.2 DQAC 算法设计

熵是信息论中的重要概念，用于表示信息的不确定程度，熵值越大，则信息的不确定程度越大。

$$\boldsymbol{H}_{\mathrm{e}}(\boldsymbol{X})=-\sum_{1}^{n}\boldsymbol{p}(x_i)\,\mathrm{lb}\,\boldsymbol{p}(x_i) \tag{15}$$

DQAC 算法是针对离散动作空间异策略改进的强化学习算法，使用信息熵最大化随机策略来提高机器人对环境的探索能力，从而实现目标策略的优化。

$$\boldsymbol{\pi}^*=\arg\max_{\boldsymbol{\pi}}E_{(\boldsymbol{s},a)\sim\rho_{\boldsymbol{\pi}}}\left(\sum_t\boldsymbol{r}(\boldsymbol{s}_t^{\mathrm{c}},a_t)+\boldsymbol{\beta}\boldsymbol{H}_{\mathrm{e}}(\boldsymbol{\pi}(\cdot|\boldsymbol{s}_t^{\mathrm{c}}))\right) \tag{16}$$

式中，目标函数值$\boldsymbol{\pi}^*$为最优策略，$\boldsymbol{H}_e(\boldsymbol{\pi}(\boldsymbol{s}_t^c))$表示在状态为$\boldsymbol{s}_t^c$时采取不同策略得到的不同熵值。熵值越大表示机器人对环境的探索策略越随机，同时采用软更新方式进行策略迭代。

DQAC 算法的环境奖励值由功用性奖励r_g和动作奖励r_g^c两部分构成。将推动动作奖励定义为：当推动动作导致环境结构发生变化的像素值超过阈值时r_p=0.5，r_p^c=0.5；未超过阈值时r_p=0，r_p^c=−1。本文将阈值设置为 30 个像素。将抓取奖励定义为：抓取目标成功时，r_g=1，r_g^c=1；抓取目标失败时，r_g=0，r_g^c=−1。

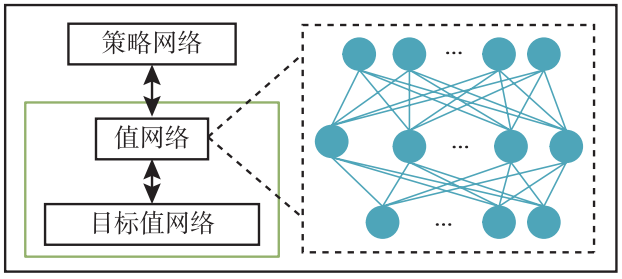

图 7　动作机制模块网络结构

如图 7 所示，动作机制模块由策略网络（actor）、值网络（critic）和目标值网络（targetcrit−ic）组成。每个网络由结构相同的多层感知机（MLP）网络构成。该网络由输入、输出及中间层构成，相邻 2 层之间的所有神经元均互相连接，而同层神经元之间无连接。

动作机制模块的作用是根据 RGSA−Net 网络提取的特征作出决策。具体的流程为：将从环境中提取的特征状态送入到策略网络中，中间经过不同神经元的前向传播直到输出层神经元。使用 SoftMax 函数计算出不同动作的概率值，使用非线性激活函数 ReLU 防止梯度消失。值网络（Q 网络）由 2 个结构相同的 MLP 网络构成，用于拟合计算某一时刻的机器人特征状态与动作决策；目标值网络（Target Q 网络）以固定周期复制 Q 网络的参数，采用软更新策略进行更新，用于预测环境中下一时刻的状态以及动作 Q 值。

考虑机器人在杂乱环境中采取推动和抓取 2 种离散动作，DQAC 算法根据特征状态$\boldsymbol{s}_t^c$对策略$\boldsymbol{\pi}$进行拟合以减小目标估计方差。由贝尔曼方程得出计算离散动作对应值函数公式：

$$\boldsymbol{V}_{\boldsymbol{\pi}}(\boldsymbol{s}) = \boldsymbol{\pi}(\boldsymbol{s}_t^c)\left(\boldsymbol{Q}(\boldsymbol{s}_t^c, a_t) - \boldsymbol{\beta}\,\mathrm{lb}\,\boldsymbol{\pi}(\boldsymbol{s}_t^c)\right) \tag{17}$$

式中，$\boldsymbol{\beta}$为温度参数，用于自适应调节值函数的奖励。

目标值网络的输出计算公式如下：

$$\boldsymbol{y}_t = \boldsymbol{r}_t^c(\boldsymbol{s}_t^c, \boldsymbol{s}_{t+1}^c; a_t) + \gamma \boldsymbol{V}_{\boldsymbol{\pi}}(\boldsymbol{s}_t^c) \tag{18}$$

该网络使用均方误差损失函数计算目标值与现实值之间的差值 δ 并进行梯度下降处理。均方误差损失函数计算公式如下：

$$\boldsymbol{\delta} = (\boldsymbol{y}_t - \boldsymbol{Q}(\boldsymbol{s}_t^c, a_t))^2 \tag{19}$$

通过减小熵值损失来减小估计值的损失方差，据此，设计了如下的温度熵损失目标函数：

$$\boldsymbol{J}(a) = \boldsymbol{\pi}_t\left((\boldsymbol{s}_t^c)^{\mathrm{T}}\right)\left[-\boldsymbol{\beta}\left(\mathrm{lb}\,\boldsymbol{\pi}_t(\boldsymbol{s}_t^c) + \boldsymbol{H}_e\right)\right] \tag{20}$$

在目标值网络中加入动作值函数期望和熵值计算来更新策略，从而对离散动作空间输出准确的概率分布以减小误差。因此，设计策略损失目标函数如下：

$$\boldsymbol{J}_{\boldsymbol{\pi}}(\phi) = E_{\boldsymbol{s}_t^c \sim D}\left[\boldsymbol{\pi}_t\left((\boldsymbol{s}_t^c)^{\mathrm{T}}\right)\left(\boldsymbol{\beta}\,\mathrm{lb}\,\boldsymbol{\pi}_\phi(\boldsymbol{s}_t^c) - \boldsymbol{Q}_{\boldsymbol{\theta}}(\boldsymbol{s}_t^c, a_t)\right)\right] \tag{21}$$

综上所述，DQAC 推抓技能自监督学习算法描述如下。

算法 1　DQAC 推抓技能学习算法

输入：当前状态 $\boldsymbol{s}$

输出：$\boldsymbol{Q}$，$\boldsymbol{\pi}^*$

1：初始化视觉网络参数 ω 和动作策略网络 $\boldsymbol{\pi}(\boldsymbol{\varphi})$，值网络 $\boldsymbol{Q}_{u_1}$，$\boldsymbol{Q}_{u_2}$，目标值网络$\overline{\boldsymbol{Q}}_{u_1}$，$\overline{\boldsymbol{Q}}_{u_2}$

2：$u_1 \leftarrow \overline{u_1}$，$u_2 \leftarrow \overline{u_2}$

3：初始化图像经验池 D 和特征经验池 D^c，定义 M

4：迭代次数 < M：

5：计算置信度 Q 值：

$$\boldsymbol{Q}_{t+1} = \boldsymbol{R}_{a_t}(\boldsymbol{s}_t, \boldsymbol{s}_{t+1}) + \gamma \max_a(\boldsymbol{s}_{t+1}, a; \boldsymbol{\omega})$$

6：根据功用性图最大 $\boldsymbol{Q}$ 值，得到机器人工作点位置 p（x，y，z）和旋转角度 $\boldsymbol{\theta}$

7：初始化特征状态信息 $\boldsymbol{s}^{\mathrm{c}}$

8：$a_{\mathrm{t}}\sim\boldsymbol{\pi}_{\phi}$（$a_{\mathrm{t}}|\boldsymbol{s}_{\mathrm{t}}^{\mathrm{c}}$）# 根据策略选择执行动作

9：选择执行动作 a_t

10：$\boldsymbol{s}_{t+1}^{\mathrm{c}}\sim p$（$s_{t+1}^{\mathrm{c}}|\ \boldsymbol{s}_t^{\mathrm{c}}$，$a_t$）# 转移概率更新下一特征状态

11：环境反馈奖励值 r，r^{c}

12：策略函数计算：

$$\boldsymbol{\pi}^{*}=\arg\max_{\boldsymbol{\pi}}E_{(\boldsymbol{s},a)\sim\rho_{\boldsymbol{\pi}}}\left(\sum_{t}R(\boldsymbol{s}_t^{\mathrm{c}},a_t)+\boldsymbol{\beta}\boldsymbol{H}_{\mathrm{e}}(\boldsymbol{\pi}(\cdot|\boldsymbol{s}_t^{\mathrm{c}}))\right)$$

13：计算损失函数，优化目标，更新网络参数

14：$\hat{\boldsymbol{\varphi}}\leftarrow\boldsymbol{\varphi}-\lambda_{\boldsymbol{\pi}}\nabla_{\phi}\boldsymbol{J}_{\boldsymbol{\pi}}(\boldsymbol{\varphi})$ # 更新策略网络参数

15：$\hat{\boldsymbol{\mu}}\leftarrow\boldsymbol{\mu}-\lambda_{Q}\nabla_{\mu}\boldsymbol{J}(\mu)$ # 更新值网络参数

16：$\hat{\boldsymbol{\beta}}\leftarrow\boldsymbol{\beta}-\lambda\nabla_{\boldsymbol{\beta}}\boldsymbol{J}(\boldsymbol{\beta})$ # 更新温度参数

17：$\hat{\boldsymbol{Q}}\leftarrow\tau\hat{\boldsymbol{Q}}+(1-\tau)\boldsymbol{Q}$ # 目标网络参数进行软更新

18：$\boldsymbol{s}_{t+1}=\boldsymbol{s}_{\mathrm{t}}$，$\boldsymbol{s}_{t+1}^{\mathrm{c}}=\boldsymbol{s}_t^{\mathrm{c}}$

19：将元组存储到图像经验池和特征经验池中

20：下一步训练，在 2 个经验池分别采样（$\boldsymbol{s}_{\mathrm{t}},\boldsymbol{s}_{t+1}$，$a$，$r$）和（$\boldsymbol{s}_t^{\mathrm{c}}$，$\boldsymbol{s}_{t+1}^{\mathrm{c}}$，a，$r^{\mathrm{c}}$）

21：直到迭代次数 > M

4 实验与结果（Experiment and results）

4.1 仿真环境搭建

为了验证机器人采用本算法抓取目标物体的性能，使用 V-REP 3.5.0[31] 动力学仿真软件模拟机器人在未知环境下对目标物体的抓取。该软件内部的运动学模块可准确地模拟真实机器人的运动轨迹，同时还具有重力等物理引擎，可模拟真实物体属性。使用 RGB-D 相机采集工作空间状态信息。该相机由被动 RGB 相机和主动深度传感器组成，除了提供 RGB 图像外还提供每个像素的深度信息，可将每个像素的深度值快速转换为点云信息用于 3D 感知。

建立了图 8 所示的仿真实验环境。建立装有 RG2 夹具的 UR5 机械臂模型，并在工作空间正上方与斜上方 45° 的位置安装 RGB-D 相机，该相机会在每次机械臂执行完动作后进行图像采集，提供完整的且大小为 640 × 480 的深度信息。

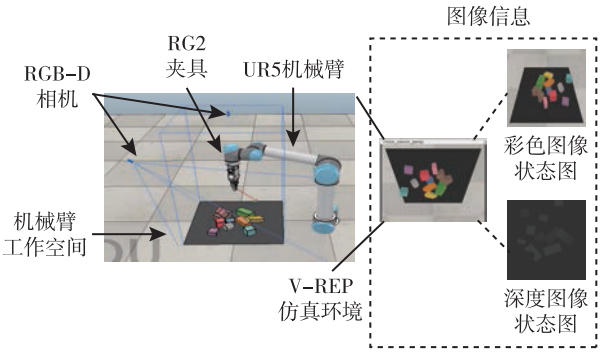

图 8 V-REP 仿真环境与图像信息

仿真硬件配置为 3.6GHz Intel Core i9-9900 k CPU 和 NVIDIA 2070S GPU，操作系统为 Ubuntu 18.04 LTS，V-REP 的版本为 3.5.0 的教育版，采用 0.4 版本的 PyTorch 框架来训练网络模型。

4.2 训练阶段

在训练阶段，待抓取的目标物体的颜色、形状及位置随机，机器人通过不断试错寻找最优策略来实现未知环境下对目标物体的成功抓取。该阶段采用特征提取网络 RGSA-Net 生成推动和抓取功用性图，采用 DQAC 框架选取最优动作，前期采用初始探索概率为 0.50 的 ε 贪婪策略进行探索，且概率随训练回合数增加而减小，并采用最大贪婪策略与动作分类策略探索推、抓动作之间的协同，自监督训练的回合数 M 取 2500。如图 1 所示，在仿真环境中杂乱放置了 m 个随机目标块和 n 个不同形状的基本块，机器人通过协调推抓动作实现对目标物体的成功抓取。

为了验证本方法的有效性，将其与其他 4 种方法在训练阶段的抓取性能进行了对比。

（1）RAND：一种不经过监督训练而采取随机像素点抓取的方法；

（2）Grasping-only[24]：一种贪婪的确定性抓取策略，它使用单个 FCN（全卷积网络）进行抓取，该网络使用二分类（来自试错）的监督。此策略下的机器人仅执行抓取动作；

（3）VPG[24]：提出面向目标的抓取任务，使用基于 DQN 的强化学习框架训练推、抓之间的协同实现目标抓取；对于给定目标物体，使用 2 个动作全卷积网络映射动作 Q 值。

（4）GIT[25]：一种深度强化学习方法，使用目标分割网络提取特征来增强机器人感知，基于 DQN 二分类器进行机器人推动与抓取训练。

4.2.1 性能展示

训练阶段执行动作次数的最大阈值设置为 30，当动作数超过阈值或整个工作区域无目标物体时，重置抓取环境开启新一轮的抓取训练，该过程中随机指定目标物块。使用不同算法对机器人进行 2500 次的训练，不同算法的耗时如表 1 所示。图 9 绘制了机器人在不同方法下的抓取成功率。

4.2.2 性能分析

从表 1 和图 9 可见，在训练过程中，RAND 算法训练耗时最短，但其面对目标抓取任务时忽略环境而采取随机策略选择动作，使得抓取成功率极低。Grasping-only 算法中加入了卷积神经网络处理视觉输入，训练耗时较 RAND 算法有所增加，但其仅采用抓取动作，忽略了杂乱环境对目标任务的影响，

表 1 不同算法 2500 次训练耗时

方法	训练耗时 /h
RAND	4.45
Grasping-only	5.58
VPG	6.33
GIT	5.72
RGSA-Net	**6.15**
DQAC	**5.84**
RGSA-Net + DQAC	**6.24**

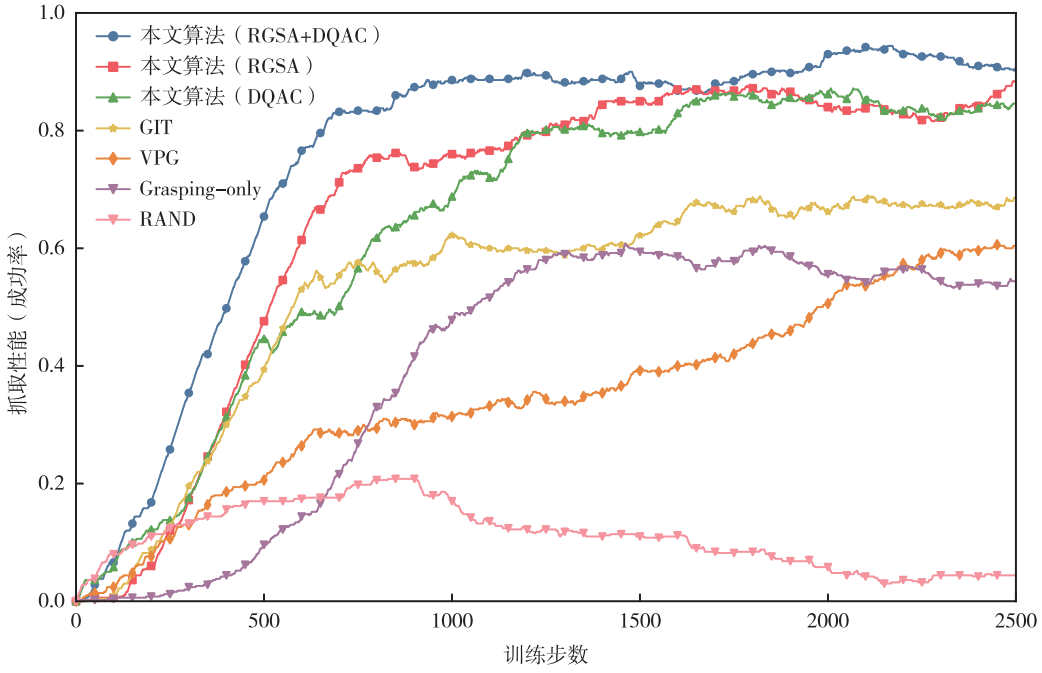

图 9 抓取成功率对比

使得其抓取成功率偏低。VPG 方法中首次将推动动作加入动作集，但其仅采用传统 DQN 进行训练，并未很好地考虑二者的协同作用，且所用网络较为繁琐导致训练耗时增加，在所有算法中耗时最长，抓取成功率在 60% 左右。GIT 算法使用简单的二分类器对动作进行拟合预测以提高动作协同效率，同时简化协同训练网络，使得训练耗时有所降低，抓取成功率在 60%~70% 之间。

本文算法在前期对视觉输入进行处理时使用了分组拆分注意力 RGSA 模块，该模块较传统残差块具有较深的网络层次，使得训练时长有所增加，但训练网络参数时融合自适应参数方法，通过加快梯度下降速度来提高网络收敛速度，最终耗时比 GIT 算法稍长。本文的 DQAC 框架在传统演员 – 评论家算法的基础上将动作网络拆分成两部分，更好地训练了推、抓之间的协同，其网络结构较为简单，耗时与 GIT 算法相差不大。但 DQAC 框架采用传统的视觉机制模块，前期对于目标定位的准确程度不足。本文将视觉机制模块与动作机制模块进行结合后，训练时长较 DQAC 框架有所增加，但其效果达到最佳，受环境干扰较小，抓取成功率在 90% 左右，总体训练性能优于其他方法。

视觉效果对比如图 10 所示，由本文算法得到的推抓功用性图能更好地定位到目标物块，推、抓中心均恰好在目标物块之上。而使用 GIT 算法产生的推抓功用性图某一区域热度较高，无法实现对目标的精准定位。这进一步验证了视觉机制模块对机器人最终抓取效果的重要作用。

4.3 测试阶段

为了检验本算法在不同实验场景中的有效性，在仿真中设置了 3 组对比实验进行测试，分别为松散放置物块情形、紧密放置物块情形和完全遮挡物块情形。

与 RAND、Grasping-only、VPG、GIT 四 种方法进行对比来验证本方法的有效性。对每个测试案例设置 30 轮实验，每轮的动作执行次数阈值设置为 n 次。若机器人在 n 次内实现对目标的抓取，则记为一轮成功的抓取案例，阈值选定与环境有关。定义抓取成功率为

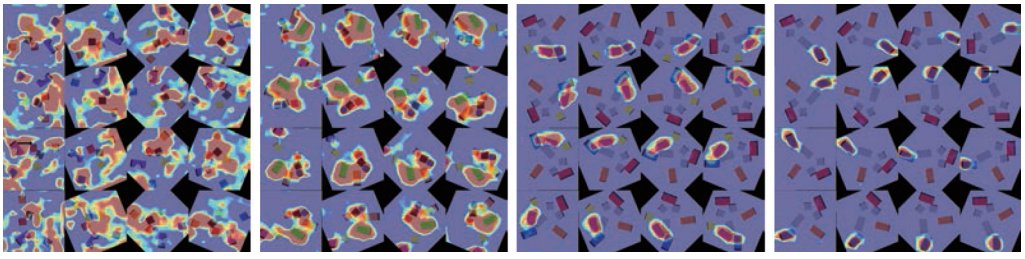

GIT 抓取　GIT 推动　RGSA 抓取　RGSA 推动

图 10　GIT 与 RGSA 算法视觉效果对比

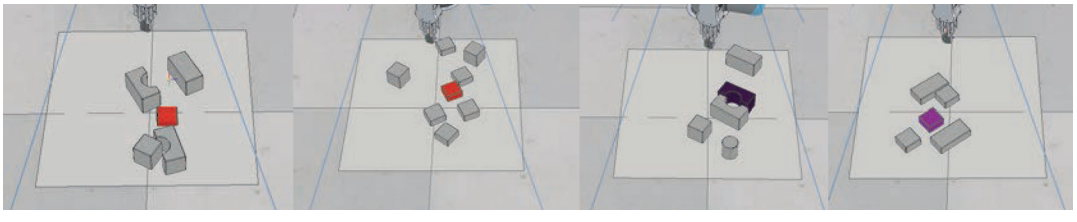

测试 0　测试 1　测试 2　测试 3

图 11　松散放置物块情形的 4 种测试案例

$$\frac{\#\text{成功抓取目标轮数}}{\#\text{实验总轮数}}$$

定义平均运动次数为

$$\frac{\sum_{1}^{n}\text{每一轮成功运动数（推动 + 抓取）}}{n\text{（重复测试实验次数）}}$$

该指标数值越小，说明实验成功率越高。

4.3.1　松散放置物块情形

由于训练过程的实验场景均是随机摆放实验场景，故本文只设置了 4 个松散放置物块情形的测试案例。如图 11 所示，每一个测试案例中设置一个带特殊颜色的目标物块，其余为干扰物块，用来模拟该算法在松散放置物块环境中的实验效果。

松散放置物块情形的 4 种测试案例较为简单，可以通过 RGB-D 相机直接获取目标物块的完整特征，无法验证推、抓技能的协同作用，故将执行动作阈值设为 1，即一次抓取就成功则计入成功案例，否则记为失败，用以检验视觉机制模块对抓取效果的影响。实验结果对比如表 2 所示。

表 2　松散放置物块案例的平均表现

方法	平均成功率 /%	平均运动次数
RAND	39.5	4.325 ± 0.41
Grasping-only	52.0	3.170 ± 0.30
VPG	72.0	3.901 ± 0.03
GIT	89.5	2.645 ± 0.15
RGSA-Net	**95.3**	**1.413 ± 0.22**
DQAC	**93.1**	**1.751 ± 0.80**
RGSA-Net + DQAC	**97.4**	**1.212 ± 0.26**

4.3.2　紧密放置物块情形

对于紧密放置物块的实验环境，设计了 8 个不同形状物块的抓取测试案例来验证训练模型的性能，各测试案例中设置一个特殊颜色的目标物块，被其他物块紧紧包围，用来模拟推、抓之间的协同训练效果。机器人通过动作集合 $a=\{a_p, a_g\}$ 执行有限次动作，其中 a_p 表示机器人面向目标执行推动动作，改变环境状态提供足够的抓取空间；a_g 表示抓取动作。推动和抓取动作总数的阈值设为 5，即推动和抓取动作在 5 次以内时，表明推抓成功。根据环境状态选择动作并得到环境的反馈训练网络参数，最终实现成功抓取。测试案例如图 12 所示。

紧密放置物块情形突出推动动作对最终抓取效果的辅助作用，即动作机制模块对抓取效果的影响。图 13 和图 14 分别展示了本方法和其他 4 种方法在 8 个测试案例中的表现，由于每个测试案例的目标场景是不同的，故本文的改进方法表现不同。表 3 展示了本文方法与其他 4 种方法的平均抓取成功率与平均运动次数对比结果。

表 3　紧密放置物块案例的平均表现

方法	平均成功率 /%	平均运动次数
RAND	17.5	4.775 ± 0.60
Grasping-only	35.0	4.325 ± 0.98
VPG	70.0	4.025 ± 0.83
GIT	87.5	3.675 ± 0.90
RGSA-Net	**90.3**	**3.575 ± 0.80**
DQAC	**90.0**	**3.506 ± 0.75**
RGSA-Net+DQAC	**91.1**	**3.436 ±0.85**

4.3.3　完全遮挡物块情形

对于完全遮挡物块的实验场景，设置了 4 种不同的测试案例。如图 15 所示，每个场景中的目标物块都是不可见的，用来模拟前期无法生成高度图时，机

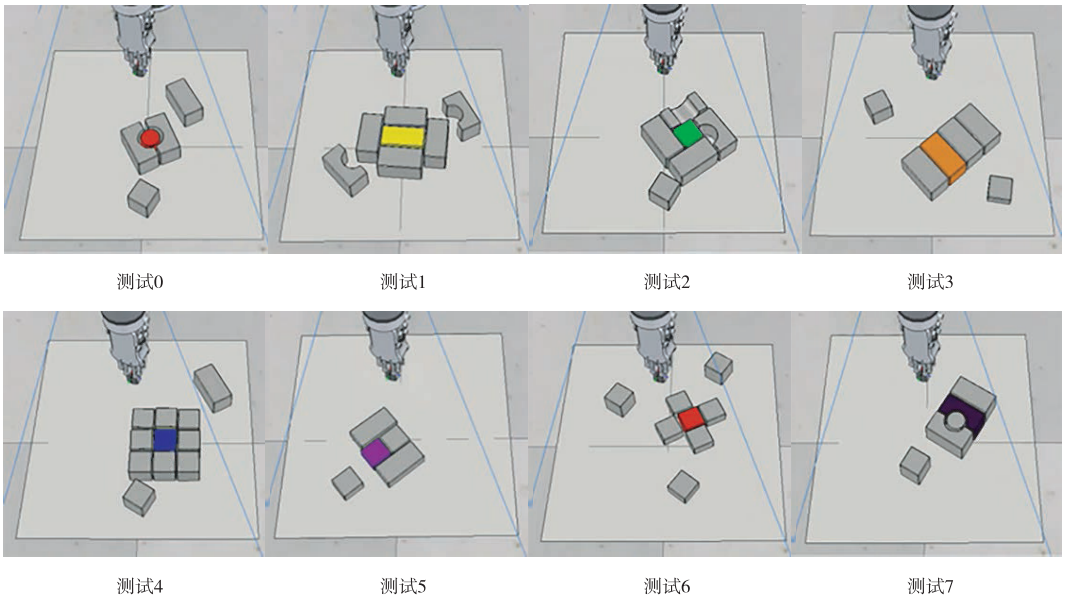

图 12　紧密放置物块情形的 8 种测试案例

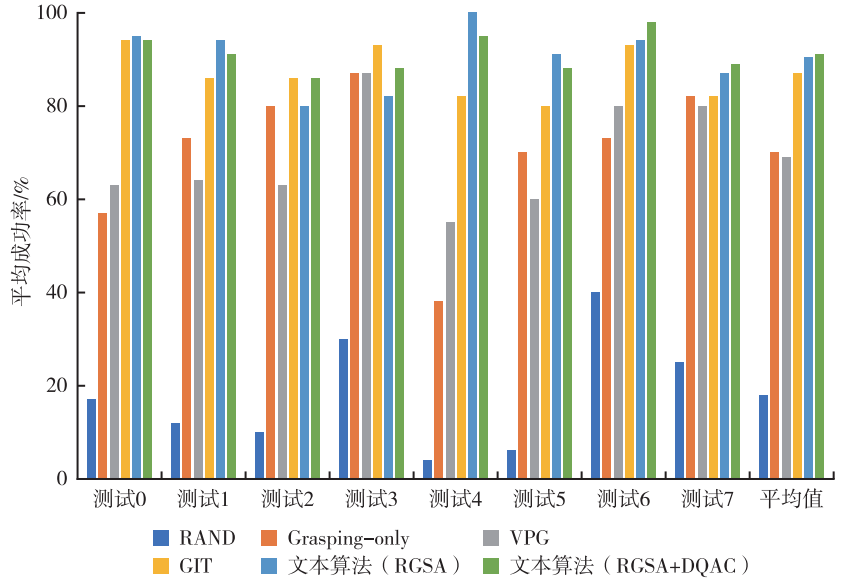

图 13　紧密放置物块案例的平均成功率

器人对于环境中目标物块的探索能力。

在该场景下，由于目标物块不可见，故本文算法在获取到当前状态的深度信息后，优先选择较高的堆叠部分使用 ε 贪婪策略进行探索，使目标物块特征显现，该场景转化成紧密放置物块情形。由于该过程为探索过程，机器人仅采用推动动作，故将推动动作阈值设置为 $n_{\text{push}}= n_{\text{clutter}}-1$，其中 n_{clutter} 表示工作空间中干扰块的数量。该过程检验了视觉机制模块与动作机制模块的协同作用效果。实验结果对比如表 4 所示。

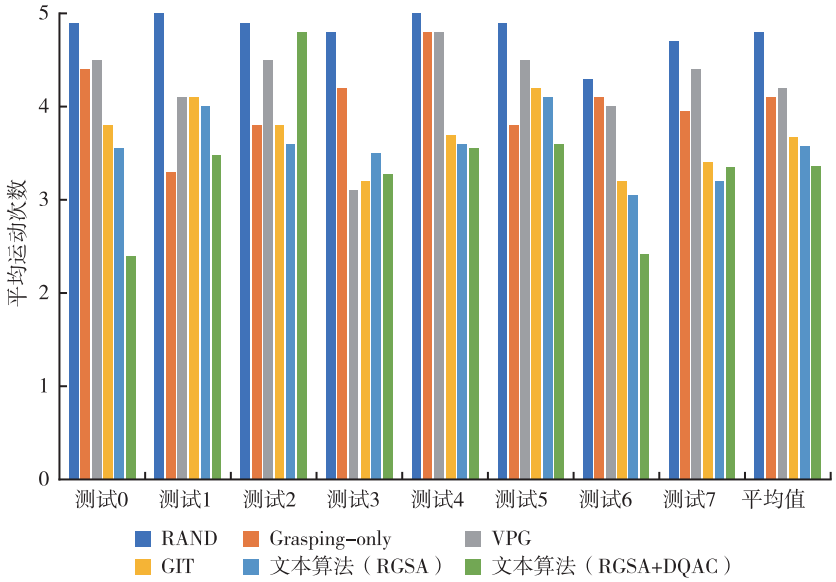

图 14　紧密放置物块案例的平均运动次数

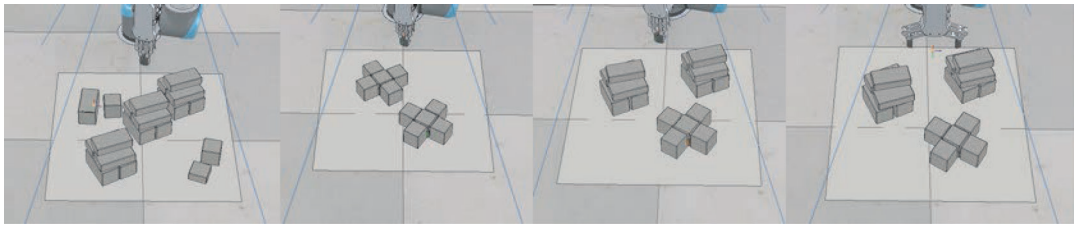

测试 0　　测试 1　　测试 2　　测试 3

图 15　完全遮挡物块情形的 4 种测试案例

表 4　完全遮挡物块案例的平均表现

方法	平均成功率 /%	平均运动次数
RAND	47.5	9.832 ± 1.14
Grasping-only	50.1	8.603 ± 0.78
VPG	78.5	7.645 ± 1.33
GIT	89.2	7.175 ± 1.28
RGSA-Net	**90.7**	**5.705 ± 1.04**
DQAC	**91.3**	**5.516 ± 1.75**
RGSA-Net+DQAC	**93.8**	**5.436 ±1.24**

4.4　结果分析

松散放置物块情形模拟了真实场景中随机放置目标物块的抓取情况，用于检验视觉机制模块对最终抓取效果的影响。由表 2 可以看出，加入 RGSA- Net 视觉机制模块后，算法以 1.41 的平均移动次数实现了 95.3% 的抓取成功率。而使用传统视觉机制的 GIT 算法仅实现了 89.5% 的抓取成功率，即使加入动作机制模块的 DQAC 算法仍无法很好地完成视觉特征提取，仅实现了 92.9% 的抓取成功率。而本文的 RGSA-Net 算法具有较好的视觉特征效果。

紧密放置物块情形模拟了真实世界中目标物块被紧紧包围的场景，此时由于没有足够的空间供机械

手完成抓取操作，故可以检验动作机制模块 DQAC 对抓取效果的影响。图 13 和图 14 是不同对比方法在 8 个紧密放置物块测试案例中的性能指标。其中，RAND 算法与 Grasping-only 算法的平均成功率在 10% ~ 35% 之间，但平均运动次数在 4.3 次以上。VPG 算法仅将推动动作引入抓取任务而未考虑二者之间的相互作用，其平均成功率为 60% ~ 75% 之间，平均运动次数为 4.0 次，进一步验证了推动动作在抓取过程中的重要性。GIT 算法基于 DQN 二分类器进一步训练推动与抓取之间的协同，平均成功率在 85% 以上，平均运动次数为 3.6 次左右。而本文采取基于演员 - 评论家框架的 DQAC 算法，以平均 3.4 次的动作实现了 91.1% 的成功率，性能优于其他基线方法。

完全遮挡物块情形模拟真实世界中目标物块完全不可见，需要机器人探索环境、寻找物块并成功抓取的场景。该过程用于检验视觉机制模块与动作机制模块的协同作用效果。由表 4 数据可得，RAND 和 Grasping-only 两种方法对抓取目标任务的效率比较低，抓取成功率均在 50% 左右。RAND 算法倾向于随机抓取目标物体而忽略了目标周围物体的密集程度，故实验效果较差。Grasping-only 算法还未引入非抓取算法的协同作用，仅采用抓取动作改变环境结构，当目标物体被完全遮挡时往往会陷入局部最优导致任务失败。VPG 算法使用基于值函数的 DQN 算法计算出的 Q 值，忽略了目标物块先验知识的影响，有较多错误的抓取动作和冗余的推动动作，故平均成功率仅为 78%，平均运动次数为 7.645。GIT 算法使用动作二分类器来协调机器人的推动与抓取动作，但在完全遮挡任务前期，高度图不完整，GIT 算法无法通过良好的视觉感知获取目标物块周围的密集程度，故平均成功率为 89.2%，平均运动次数为 7.175。本文提出的基于 RGSA-Net 和 DQAC 算法的机器人自监督学习方法，使用拆分注意力模块提高对目标物块的关注度，使用 DQAC 算法进行动作评判及反馈，增强了对杂波环境的感知能力，完成任务的平均成功率达到了 93.8%，平均运动次数为 5.436，性能达到最优。

5 结论（Conclusion）

众所周知，在服务机器人共融式宜人化进化过程中，自主认知与操作杂乱场景下的工具是其必备的技能。本文提出一种基于功用性图的目标推抓技能自监督学习方法，克服了抓取成功率低的问题，提高了机器人在复杂环境中对目标抓取技能的学习性能。

提出了基于 RGSA-Net 特征提取网络的视觉机制模块，生成了准确的推抓功用性图；提出了基于 DQAC 自监督学习方法的动作机制模块，实现了推、抓之间的协同。在训练阶段提高了抓取性能，在测试阶段提高了 3 组测试案例的抓取成功率，减少了平均移动次数，在仿真环境中设计实验验证了本文方法的有效性。接下来，将搭建实物实验环境并进一步验证本文方法的有效性。

来源：《机器人》

作者简介

吴培良（1981—），男，博士，教授。研究领域：家庭服务机器人工具认知，机器人抓取，强化学习。

刘瑞军（1996—），女，硕士生。研究领域：家庭服务机器人工具操作技能学习，强化学习。

毛秉毅（1964—），男，博士。研究领域：家庭服务机器人功用性认知。

解耦表征学习综述

文 / 文载道　王佳蕊　王小旭　潘　泉

摘　要：在大数据时代下，以高效自主隐式特征提取能力闻名的深度学习引发了新一代人工智能的热潮，然而其背后黑箱不可解释的“捷径学习”现象成为制约其进一步发展的关键性瓶颈问题 . 解耦表征学习通过探索大数据内部蕴含的物理机制和逻辑关系复杂性，从数据生成的角度解耦数据内部多层次、多尺度的潜在生成因子，促使深度网络模型学会像人类一样对数据进行自主智能感知，逐渐成为新一代基于复杂性的可解释深度学习领域内重要研究方向，具有重大的理论意义和应用价值。本文系统地综述了解耦表征学习的研究进展，对当前解耦表征学习中的关键技术及典型方法进行了分类阐述，分析并汇总了现有各类算法的适用场景并对此进行了可视化实验性能展示，最后指明了解耦表征学习今后的发展趋势以及未来值得研究的方向。

关键词：深度学习，捷径学习，潜在生成因子，智能感知，解耦表征学习

自动化系统，大到复杂的导弹制导、自动驾驶、飞行控制等运动系统，小到人脸图像识别、行人流量检测、视频跟踪监控等图像 / 视频解译系统，均在国家、国防等重大生产、生活与管理进程中起到了不可替代的作用[1]。随着人工智能技术最近几年的迅速发展，采集数据的自动、精准智能感知对整个系统的智能辨识与控制预测能力至关重要，备受研究者的广泛关注[2]。

人类作为目前最为智能的生物系统，能够通过各类生物传感器（眼睛、鼻子、耳朵等）接收周围环境的视觉、嗅觉、听觉等数据信号，并将这些数据送入大脑进行融合处理，挖掘出数据内部隐含的各类有效信息，通过持续性学习将其汇总为简单的语义属性，形成概念，建立起抽象的逻辑关联规则，最终结合自身具备的常识形成完整知识体系，实现对各类复杂环境的智能化感知[3-4]。例如，将图 1（a）中从不同视角下拍摄得到的三幅不同交通图像作为视觉数据输入到人眼中，人类便能够自主完成如下的层次化数据智能感知：

1）检测并识别出图像中不同姿态、不同风格的物体，并具有抗遮挡能力，能够毫不费力地想象还原出被遮挡物体的全貌，如图 1（b）所示；

2）能够全面有效剖析出每类物体的各个内在属性并对该类物体进行全方位想象关联。例如对于图 1（c）中的车辆而言，假设将其内在属性认知为车型、角度两类，人类便可按照这两类属性对已有图像进行相应的分组关联，并能够通过组合不同的属性值想象出并未见过的车辆图像。如此，面对存在车辆的各类未知新场景，

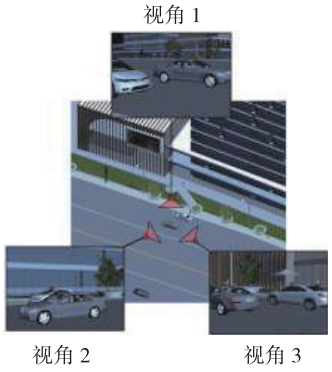

（a）多个不同视角下的同一交通场景量测数据输入

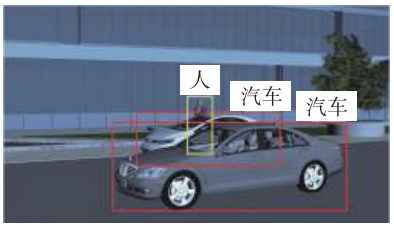

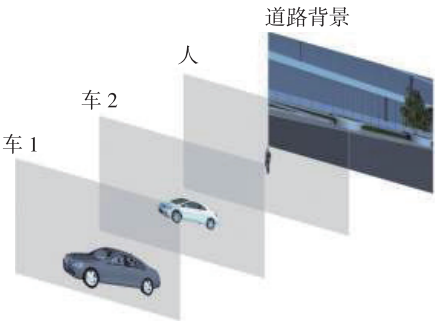

（b）自动检测识别每幅视角图像中所含物体信息，并想象还原出被遮挡物体的全貌

（c）对于车辆而言，将其内部属性解耦为车辆角度、车辆类型两类独立属性

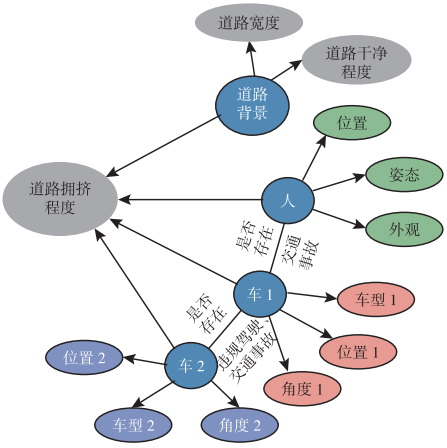

（d）构建交通场景的智能树状知识体系图

（e）人类想象泛化出发生车辆追尾碰撞现象的拥挤交通场景

图 1　人类对于交通场景量测数据的层次化智能感知示意图

人类能够不受大差异性视角或新型车辆的影响，检测并识别出各类不同的车辆，并能够精确推理出每辆车的内在属性值；

3）能够结合一些常识推理（例如两辆车相对位置过近或人躺在车辆行驶正中间的马路上时往往代表着交通事故的发生）构建出代表不同对象间交互关系的树状知识体系图，如图 1（d）所示。利用该知识体系图，人类能够通过对知识的改造重组想象泛化出各类符合因果逻辑关系的新场景，例如图 1（e）中道路拥堵状态下的交通事故新场景。该能力有助于人类对各类复杂场景进行因果知识关系梳理与认知更新，从而轻松完成类似智能知识问答等复杂图像理解任务。

为了使现有系统真正实现对数据的自主智能感知，借鉴人类这种层次化数据智能感知思想，构建从数据、信息、语义、规则再到知识的多尺度、多层次、具有可解释性的数据表征至关重要。

传统模式识别主要依据特定领域的专家经验知识进行显式的特征设计与推理，从而完成相应任务。随着误差反向传播（Backpropagation，BP）人工神经网络的提出，将传统专家知识驱动的显式特征提取方法替换为复杂数据驱动的神经网络隐式

特征提取方法逐渐引起了学术界的关注。尤其在 Hinton 等[5]提出以深度神经网络为代表的深度学习技术后，相关以深度学习为主的隐式特征提取理论开始蓬勃发展，逐渐在语音识别[6-8]、自然语言处理[9-11]、人脸识别[12-14]、目标检测[15-18]等领域取得突破性进展。截至目前，深度学习技术已被广泛应用于多种复杂非线性系统的预测任务中[19]。这类以提升特定预测任务性能指标为目的的判别式深度学习算法通过堆叠多层神经网络来构建从原始的输入数据到最终预测目标（如物体类别、位置、姿态等）的端到端非线性映射函数，使机器能够从数据中自适应地进行学习，有效缓解传统模式识别中手工设计选择显式特征的繁琐低效问题[20]。

然而现有以有监督深度网络为代表的端到端黑箱判别式学习方法是一种捷径学习（Shortcut learning）策略[21-22]，即网络学习得到的判别性隐式抽象特征往往没有朝着人类所期望的方向进行泛化。如图 2 所示，对于图 2（a）中所显示的人类所具有的泛化能力并未被网络所学到。与此相反，在图 2（b）中，网络学习得到的泛化能力又不能为人类所理解。发生这种现象的本质原因在于现有判别式网络做出决策的评判标准仅仅为了提高训练样本数据的预测准确性。在这种评判标准下，网络会自主选择一条最容易、最精准地对训练集拟合的方向进行学习，而这一方向并不一定是人类所期望网络学习的方向。如图 3 所示，网络学到得是所有决策空间中在训练集上展现出良好性能的一部分决策，在这一部分决策内，仅有一小部分决策能够泛化到服从独立同分布特性（Independent and identically distributed，i.i.d）的测试集上，即图 3 中的蓝色区域。然而人类真正期望网络做出的决策不仅能够泛化到 i.i.d 测试集上，而且能够泛化到其余该分布以外（Out-of-distribution，o.o.d）的测试集中[23]，即图 3 中的红色区域部分。现有大多数判别式网络仅旨在寻找蓝色区域内适应于 i.i.d 测试集的决策空间，难以自主学到同时适应于 o.o.d 数据集的红色区域决策空间。例如图 2（a）中，当网络学习判断图像类别是否为猫时，很容易聚焦于图像的纹理特征，而忽略整体的形状特征，这使得一幅具有猫的形状、大象纹理的图像会被网络判定为大象而不是猫；又如图 2（b）中，网

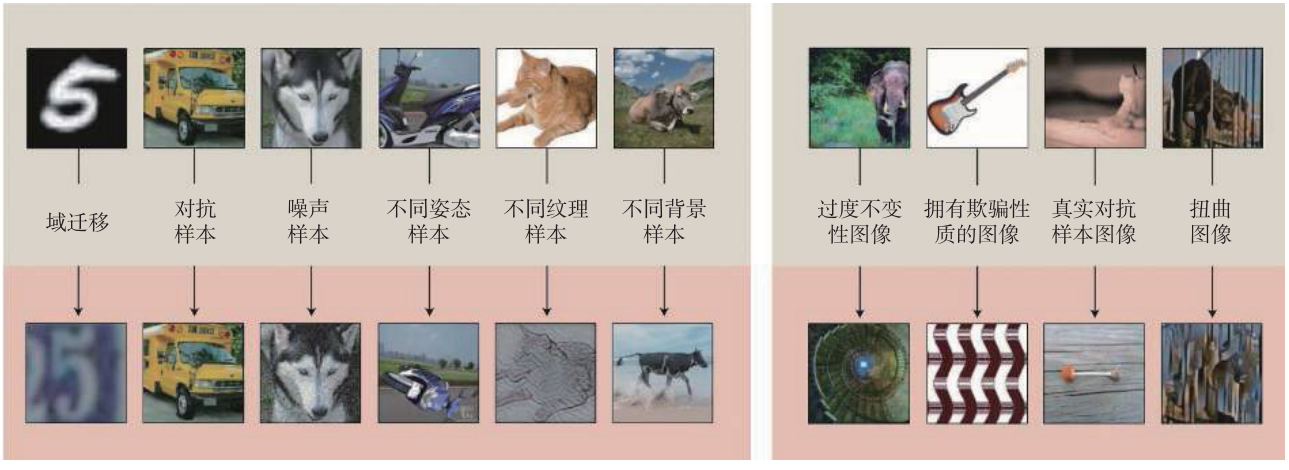

（a）对于人类而言相同类图像，但对深度网络而言属于不同类图像示例图

（b）对于人类而言完全不相同类的图像，但对深度网络而言属于相同类图像示例图

图 2　深度网络的捷径学习（Shortcut learning）现象示例图[21]

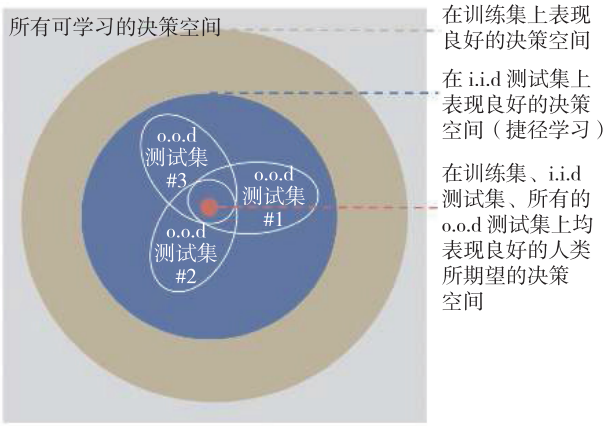

图 3 决策空间示意图[21]

络对于一把吉他类别的判断可能仅在于评判其是否具有弯曲的纹理与线段等，这使得该网络很容易将人类认为明显不是吉他的图像判定为吉他。因此现有深度网络经常因为稳定性差、可解释性弱、易受欺骗攻击等饱受诟病[24-27]。

为了缓解上述问题，对网络学习方向施加一定的归纳偏好约束，促使网络挖掘数据中所蕴含的常识推理与因果逻辑关系[28-31]，将有助于网络像人类一样学习从数据到信息到语义到规则再到知识的多尺度、多层次化数据表征。基于此，结合认知科学原理和视觉信息处理机制的解耦表征学习逐渐成为深度学习领域重要的研究方向[32-36]。解耦表征学习旨在按照人类能够理解的方式从真实数据中对具有明确物理含义的生成因子（如类别、位置、外观、纹理等）进行解耦，并给出其所对应的独立潜在表示，引起国内外大量学者的广泛关注。

鉴于解耦表征学习深刻的理论意义，所蕴含的应用价值以及可观的发展潜力，本文对解耦表征学习的研究进展进行了系统性的综述，为进一步深入研究解耦表征学习机制、开发解耦表征学习应用潜力确立了良好的基础。文中第 1 节对解耦表征学习基本概念、发展历史等进行了概述；第 2 节着重介绍了从非结构化表征先验正则角度分析解耦表征学习最初的几种典型解决思路；第 3 节则从结构化模型先验归纳偏好的角度挖掘模型架构设计对于现有解耦表征学习的启发；第 4 节结合实际数据中所蕴含的物理知识对现有解耦表征学习研究进行进一步深入探索；第 5 节则对前三节的模型算法进行对比分析论证。最后，在第 6 节指出了解耦表征学习未来的可能发展方向并对全文进行总结。

1 解耦表征学习

在表征学习中，通常将真实数据 x 建模为两部分：从先验分布 $p(z)$ 中采样得到潜在变量取值 z；从条件数据生成分布 $p(x|z)$ 中采样得到数据观测值 x[37]。该模型背后的关键性假设在于将真实数据 x 视作由一系列物理语义可解释的因素 $\{\upsilon_1, \upsilon_2 \cdots, \upsilon_n\}$ 通过复杂未知的非线性系统映射函数 $Sim(\cdot)$ 作用相互耦合产生[37-38]，即 $x=Sim(\upsilon_1, \upsilon_2 \cdots, \upsilon_n)$。例如从宏观上看，图 1（b）中的交通场景图像数据可看作由车 1、车 2、人、道路背景四个可解释的对象通过交通成像系统耦合而成，图 1（c）中的车辆数据可看作由车型、角度两个可解释的生成因子通过车辆成像系统耦合而成。从微观上看，物质均由分子、原子等微观粒子耦合而成。表征学习模型中的潜在变量 z 即为对这些物理可解释因子 $\{\upsilon_1, \upsilon_2 \cdots, \upsilon_n\}$ 的近似表征，条件似然分布 $p(x|z)$ 即为从概率角度对未知非线性系统映射函数 $Sim(\cdot)$ 的近似。在此基础上，解耦表征学习旨在学习可分离的潜在变量表示 $z=\{z_1, z_2 \cdots, z_n\}$，且 $p(z)=\prod_{k=1}^{n} p(z_k)$，使得该表示下每个潜在变量子集 z_k 能够对数据内部相对应的生成因子 υ_k 进行有效表征控制。

传统解耦表征类研究可以追溯到独立成分分析（Independent component algorithm，ICA）方法[39-40]，旨在表示量测信号是如何由多种独立成分线性叠加而成。据此构建的数学模型为：

$$x=w_1z_1+w_2z_2+\cdots+w_nz_n=Wz \quad (1)$$

其中 x 为真实量测数据；z 为服从统计独立特性

且非高斯分布的独立成分表示，可视作潜在变量，用于捕获影响线性系统输出的生成因子；W为混合转换矩阵，可近似为线性系统中将多输入生成因子线性叠加转换为量测输出数据的系统函数。

然而 ICA 一般仅适用于线性系统量测数据的解耦表征中，对于复杂非线性系统量测数据的解耦表征类研究可通过将式（1）中用于近似线性系统函数的转换矩阵 W 替换为由多层参数化深度神经网络定义的复杂非线性转换函数，如此便引申出自编码（Auto-encoders，AE）模型。在自编码模型中，由神经网络构成的编码器 h 对输入数据 x 进行编码形成潜在编码量 z，即 $z=h(x)$；另一个神经网络构成的解码器 f 则负责将这些潜在编码量 z 解码，重构出原始数据 x，即 $x=f(z)=f(h(x))$。通过最小化重构误差，自编码模型能够逐渐挖掘到对重构数据更有效的相关特征，舍弃无关特征[41]。该表征模型被 Schmidhuber[42] 于 1992 年用于非线性数据的解耦表征中，他们建立的自适应预测器通过最小化可预测性原理惩罚每个潜在编码量所包含信息被其余潜在编码量预测出的概率来完成自编码模型中潜在编码量 z 的解耦任务。

现有大多数表征学习网络都是基于 Kingma 等提出的变分自编码（Variational auto-encoders，VAE）模型[43]，该模型从极大似然的角度对真实数据进行表征建模。其中针对潜在变量 z 的推断过程，VAE 采用将真实数据输入到深度编码网络 f_ϕ 的方式进行变分近似后验推断 $q_\phi(z|x)$；针对真实数据 x 的生成过程，VAE 采用将变分推断得到的潜在变量 z 输入到深度解码网络 g_θ 来近似数据生成建模 $g_\theta(x|z)$，其中 $z\sim q_\phi(z|x)$。对于整体 VAE 模型中的网络参数 θ；ϕ 的求解优化方式采用极大对数似然思想，如式（2）所示。式中第一项为变分后验分布 $q_\phi(z|x)$ 与真实后验分布 $p(z|x)$ 间的 KL 散度（Kullback-Leibler divergence）。由于此项非负，第二项 $\mathcal{L}(\theta,\phi;x;z)$ 被称为真实数据 x 的变分下界，代替式（2）成为 VAE 模型中新的优化目标函数，如式（3）所示。式中第一项 $\ln p_\theta(x|z)$ 称为数据的条件对数似然项，反映的是潜在变量 z 对于真实数据 x 的表征能力，第二项 $\mathrm{KL}(q_\phi(z|x)\,||\,p_\theta(z))$ 常称为 KL 项，反映的是变分后验分布 $p_\phi(z|x)$ 与先验分布 $p(z)$ 间的相似性。在 VAE 模型中，由于人为选择的先验分布 $p(z)$ 通常满足独立特性，如高斯正态分布等，因此式（3）中的第二项 KL 项相当于对网络施加了一定程度的独立性约束，通过该优化函数训练出的模型具备一定的解耦性能，但实际应用过程中发现该约束能力还远不能实现对数据的有效解耦。基于此问题，目前大量学者通过在原始 VAE 中增添各类隐式或显式的归纳偏好促使网络学会数据内部各个可解释生成因子的有效解耦表征。

$$\max_{\theta,\phi}\ln p_\theta(\boldsymbol{x})=\max_{\theta,\phi}\left\{\mathrm{KL}\left(q_\phi(\boldsymbol{z}|\boldsymbol{x})\,||\,p_\theta(\boldsymbol{z}|\boldsymbol{x})\right)+\mathcal{L}(\theta,\phi;\boldsymbol{x},\boldsymbol{z})\right\} \tag{2}$$

$$\mathcal{L}(\theta,\phi;\boldsymbol{x},\boldsymbol{z})=\mathrm{E}_{q_\phi(\boldsymbol{z}|\boldsymbol{x})}\ln\frac{p_\theta(\boldsymbol{x},\boldsymbol{z})}{q_\phi(\boldsymbol{z}|\boldsymbol{x})}=\mathrm{E}_{q_\phi(\boldsymbol{z}|\boldsymbol{x})}\ln p_\theta(\boldsymbol{x}|\boldsymbol{z})-\mathrm{KL}\left(q_\phi(\boldsymbol{z}|\boldsymbol{x})\,||\,p(\boldsymbol{z})\right) \tag{3}$$

与 VAE 从贝叶斯的角度对真实数据进行生成分布建模不同，Goodfellow 等[44]于 2014 年提出生成对抗网络（Generative adversarial nets，GAN）模型，运用对抗学习思想在无需假设数据全概率生成分布模型的情况下正向模拟真实数据的生成过程。具体而言，该模型首先从人为假设的潜在先验分布 $p(z)$ 中采样，近似复杂系统内影响数据输出的各个隐含生成因子；随后将这些采样值送入用于模拟未知复杂系统函数的生成器 C 中，输出生成的数据 $G(z)$；最后采用判别器 D 对生成数据的真实性进行打分。与 VAE 不同，GAN 不直接以数据分布与模型分布的差异作为目标函数，而是采用对抗的方式，先通过判别器去学习生成数据与真实数据的差异，再引导生成器去缩小这种差异，如式（4）所示，逐渐寻找这种类似零和博弈中的纳什均衡解[45]。相较于 VAE，GAN

不用对数据的分布模型进行显式设计，避免了人为设计的复杂繁琐且赋予了网络更强大的生成数据能力。然而 GAN 缺乏有效的推理机制，只着重于数据的生成过程估计，更适用于潜在因子已知情况下系统数据的近似生成问题，而不是潜在因子的变化规律探索问题，因此 GAN 模型难以直接应用到挖掘数据内部未知潜在生成因子的解耦表征研究中。针对此，目前大量学者提出 GAN 与 VAE 相结合的思想进一步开展对于真实数据的解耦表征学习研究。

$$\min_{G}\max_{D} V(D,G)=\mathrm{E}_{\boldsymbol{x}\sim p(\boldsymbol{x})}[\ln D(\boldsymbol{x})]+\mathrm{E}_{\boldsymbol{z}\sim p_{\boldsymbol{z}}(\boldsymbol{z})}[\ln(1-D(G(\boldsymbol{z})))] \tag{4}$$

这两类生成式模型为解耦表征学习研究提供了许多新的思路。然而在模型与数据都不存在归纳偏好（Inductive bias）的情况下，网络无法自主无监督地学习出良好的解耦表征[37]。对此，大量学者针对表征变量、模型架构等提出了不同的归纳偏好设计，促使模型拥有良好的解耦表征能力。本文接下来将分别从非结构化表征先验归纳偏好、结构化模型先验归纳偏好、物理知识归纳偏好三方面对现有解耦表征学习的研究进展进行综述。

2 基于非结构化表征先验的解耦表征学习

在对真实数据进行解耦表征学习过程中，对于潜在变量 z 的归纳偏好设计形式至关重要。2016 年 ~ 2019 年，大量解耦表征学习研究通过在原有生成式模型目标函数的基础上增添各类无监督正则项归纳偏好来为潜在变量 z 施加额外的独立性元先验约束，促使网络偏向于学习满足独立统计分布特性的潜在变量表征。本节将主要从独立性先验正则归纳偏好的角度出发，对现有基于非结构化表征先验归纳偏好的解耦表征学习研究进行归纳整理分析。

对于 VAE 而言，式（3）中的第二项 KL 项通过设计满足独立特性的先验分布 $p(z)$ 能够对网络学习到的变分后验分布 $q_\phi(z|x)$ 施加一定程度的独立性约束。基于此，Higgins 等[46] 于 2017 年提出 β-VAE 模型，直接对式（3）中的 KL 项施加大于一的罚项系数 β，进而加强对近似后验分布的独立性约束，鼓励网络着重学习潜在变量 z 的可分离性。此时构成的新的优化函数如式（5）所示。

$$\mathcal{L}(\theta,\phi,\beta;\boldsymbol{x},\boldsymbol{z})=\mathrm{E}_{q_\phi(\boldsymbol{z}|\boldsymbol{x})}\ln p_\theta(\boldsymbol{x}|\boldsymbol{z})-\beta\mathrm{KL}\left(q_\phi(\boldsymbol{z}|\boldsymbol{x})\,||\,p(\boldsymbol{z})\right) \tag{5}$$

其中 $\beta\geq 1$。

然而，来自高 β 值的额外压力往往会使潜在变量所含的有效信息在经过解码器的过程中由于受约束的潜在瓶颈导致高频细节丢失，对数据的表征能力下降，难以达到数据的有效表征与解耦表征之间的最佳权衡。基于此，后续多项研究提出进一步的改进策略，期望能够在不丢失过多数据表征能力的同时尽量提升潜在变量的解耦性能。Burgess 等[47] 于 2018 年从信息瓶颈理论分析的角度认为式（5）的对于近似后验分布的约束项为第一项重构项的信息瓶颈，提出在训练过程中采用渐进策略逐渐增加潜在变量的信息容量，如式（6）所示，将有助于达成强表征能力与强解耦能力之间更好的权衡，给予潜在变量更大的表示空间。

$$\mathcal{L}(\theta,\phi,C;\boldsymbol{x},\boldsymbol{z})=\mathrm{E}_{q_\phi(\boldsymbol{z}|\boldsymbol{x})}\ln p_\theta(\boldsymbol{x}|\boldsymbol{z})-\gamma\left|\mathrm{KL}\left(q_\phi(\boldsymbol{z}|\boldsymbol{x})\,||\,p(\boldsymbol{z})\right)-C\right| \tag{6}$$

其中 C 为随着网络训练不断线性增大的超参数。

除了上述将式（3）中的第二项 KL 正则项看作一个整体进行改动以提高网络解耦表征的能力外，Makhzani 等[48] 提出对抗自编码（Adversarial autoencoders，AAE），对式（3）中的 KL 项进行更加细致化与规范化的推导，如式（7）所示。他们认为式（7）中第三项互信息项反映的是潜在变量 z 与输入数据 x 间的相关性。若惩罚该项，将有可能导致潜在变量 z 无法对输入数据 x 进行有效表征。而式中第二项有关累积后验分布与先验分布的 KL 项则是真正有助于提升解耦效能的关键项。基于此，他们采用对抗约束的方式仅惩罚式（7）中第一

项重构项与第二项 KL 项。该分解相较于 β-VAE 将式（7）中后两项看作一个整体进行惩罚，更好地达到数据解耦性能与表征性能间的平衡。Kumar 等[49]认为 AAE 在运用对抗思想的同时会面临对抗训练所存在的鞍点等问题[50]。他们提出的 DIP-VAE（Disentangledinferred prior variational auto-encoders）模型将潜在变量后验累积分布 $q_\phi(z)$ 与先验分布 $p(z)$ 均假设为高斯分布，利用矩估计思想设计了两种矩匹配项来对后验分布的协方差矩阵进行约束来促使二者分布达到一致，其设计形式如式（8）、（9）所示。该方法相对于 AAE 而言大大简化了训练过程，避免了对抗训练中所可能出现的鞍点等问题。

$$\begin{aligned}&\mathcal{L}(\theta,\phi;\boldsymbol{x},\boldsymbol{z})=\\&\mathrm{E}_{q_\phi(\boldsymbol{z}|\boldsymbol{x})}\ln p_\theta(\boldsymbol{x}|\boldsymbol{z})-\mathrm{KL}\left(q_\phi(\boldsymbol{z}|\boldsymbol{x})\,||\,p(\boldsymbol{z})\right)=\\&\mathrm{E}_{q_\phi(\boldsymbol{z}|\boldsymbol{x})}\ln p_\theta(\boldsymbol{x}|\boldsymbol{z})-\\&\mathrm{E}_{q_\phi(\boldsymbol{z}|\boldsymbol{x})}\left[\ln\left(\frac{q_\phi(\boldsymbol{z}|\boldsymbol{x})}{q(\boldsymbol{z})}\frac{q(\boldsymbol{z})}{p(\boldsymbol{z})}\right)\right]=\\&\mathrm{E}_{q_\phi(\boldsymbol{z}|\boldsymbol{x})}\ln p_\theta(\boldsymbol{x}|\boldsymbol{z})-\\&\mathrm{E}_{q_\phi(\boldsymbol{z}|\boldsymbol{x})}\left[\ln\frac{q(\boldsymbol{z})}{p(\boldsymbol{z})}+\ln\frac{q_\phi(\boldsymbol{z}|\boldsymbol{x})}{q(\boldsymbol{z})}\right]=\\&\underbrace{\mathrm{E}_{q_\phi(\boldsymbol{z}|\boldsymbol{x})}\ln p_\theta(\boldsymbol{x}|\boldsymbol{z})}_{\text{reconstruction term}}-\underbrace{\mathrm{KL}\left(q_\phi(\boldsymbol{z})\,||\,p(\boldsymbol{z})\right)}_{\text{marginal KL}}-\underbrace{I(\boldsymbol{z};\boldsymbol{x})}_{\text{mutual info}}\end{aligned}\tag{7}$$

$$\begin{aligned}&\max_{\theta,\phi}ELBO(\theta,\phi)-\lambda_{od}\sum\nolimits_{i\neq j}\left[Cov_{p(\boldsymbol{x})}\left[\mu_\phi(\boldsymbol{x})\right]\right]_{ij}^2-\\&\lambda_d\sum\nolimits_i\left(\left[Cov_{p(\boldsymbol{x})}\left[\mu_\phi(\boldsymbol{x})\right]\right]_{ii}-1\right)^2\end{aligned}\tag{8}$$

$$\begin{aligned}&\max_{\theta,\phi}ELBO(\theta,\phi)-\lambda_{od}\sum\nolimits_{i\neq j}\left[Cov_{q_\phi(\boldsymbol{z})}\left[\boldsymbol{z}\right]\right]_{ij}^2-\\&\lambda_d\sum\nolimits_i\left(\left[Cov_{q_\phi(\boldsymbol{z})}\left[\boldsymbol{z}\right]\right]_{ii}-1\right)^2\end{aligned}\tag{9}$$

然而当潜在变量先验分布 $p(z)$ 设计有偏差时，采用上述方法对后验累积分布 $q_\phi(z)$ 与先验分布 $p(z)$ 施加强一致性约束会导致数据表征学习的有效性减弱。基于此，Kim 等[51]与 Chen 等[52]先后于 2018 年提出能够直接鼓励后验累积分布 $p(z)$ 服从因式阶乘分布的惩罚项：$\mathrm{KL}(q(\boldsymbol{z})||\prod_{i=1}^{d}q(z_i))$项。其中 Kim 等[51]所提出的 Factor-VAE 直接在原始 VAE 优化函数中增加该惩罚项，如式（10）所示，用于提升模型的解耦性能。Chen 等[52]所提出的 β-TCVAE（Totalcorrelation variational auto-encoders）从理论推导角度将式（7）中第二项 KL（$q(z)||p(z)$）进一步分解，如式（11）所示。进而通过对不同项赋予不同的权重值构成新的优化函数，如式（12）所示。两种方法对于 $\mathrm{KL}(q(\boldsymbol{z})||\prod_{i=1}^{d}q(z_i))$ 项的相似性度量均采用对抗方式求解。

$$\begin{aligned}&\mathcal{L}(\theta,\phi,\gamma;\boldsymbol{x},\boldsymbol{z})=\\&\mathrm{E}_{q_\phi(\boldsymbol{z}|\boldsymbol{x})}\ln p_\theta(\boldsymbol{x}|\boldsymbol{z})-\mathrm{KL}\left(q_\phi(\boldsymbol{z}|\boldsymbol{x})\,||\,p(\boldsymbol{z})\right)-\\&\gamma\mathrm{KL}(q(\boldsymbol{z})||\prod\nolimits_{i=1}^{d}q(z_i))\end{aligned}\tag{10}$$

$$\begin{aligned}\mathrm{KL}\left(q(\boldsymbol{z})\,||\,p(\boldsymbol{z})\right)=&\mathrm{KL}(q(\boldsymbol{z})||\prod\nolimits_{i=1}^{d}q(z_i))+\\&\sum_j\mathrm{KL}(q(z_j)||p(z_j))\end{aligned}\tag{11}$$

$$\begin{aligned}&\mathcal{L}(\theta,\phi,\alpha,\beta,\gamma;\boldsymbol{x},\boldsymbol{z})=\\&\mathrm{E}_{q_\phi(\boldsymbol{z}|\boldsymbol{x})}\ln p_\theta(\boldsymbol{x}|\boldsymbol{z})-\beta\mathrm{KL}\left(q(\boldsymbol{z})\,||\prod\nolimits_{i=1}^{d}q(z_i)\right)-\\&\alpha I(\boldsymbol{z};\boldsymbol{x})-\gamma\sum_j\mathrm{KL}(q(z_j)||p(z_i))\end{aligned}\tag{12}$$

除了上述基于表征独立分布特性设计先验正则用于解耦表征学习外，还有部分学者从其余表征分布特性的角度出发对上述方法进行了进一步的补充。以下将分别从离散型潜在变量分布特性、与数据相关的潜在变量解耦特性、序列图像中潜在变量的时空一致性以及潜在变量的稀疏性四个角度进行展开描述。

用于捕捉数据内部生成因子的潜在变量除了类似位置、外观等连续型潜在变量外，还存在着类别等离散型潜在变量。这类离散型潜在变量的存在会使得深度网络在进行梯度回传时出现无法有效求微的难解问题。基于此，Dupont 等[53]提出 JointVAE，使用连续的 Concrete 分布[54]来对离散型潜在变量进行建模，并采用连续型潜在变量 z 与离散型潜在变量 c 联合分布建模 $q_\phi(z,c|x)$ 的方式，将式（6）中的目标函数扩展为式（13）形式，为涉及到离散型潜在变

量的解耦问题提供了一个很好的思路。

$$\begin{aligned}\mathcal{L}(\theta,\phi)=&\mathrm{E}_{q_\phi(\boldsymbol{z},\boldsymbol{c}|\boldsymbol{x})}\ln p_\theta(\boldsymbol{x}|\boldsymbol{z},\boldsymbol{c})-\\&\gamma\left|\mathrm{KL}\left(q_\phi(\boldsymbol{z}|\boldsymbol{x})\,||\,p(\boldsymbol{z})\right)-C_z\right|-\\&\gamma\left|\mathrm{KL}\left(q_\phi(\boldsymbol{c}|\boldsymbol{x})\,||\,p(\boldsymbol{c})\right)-C_c\right|\end{aligned}\tag{13}$$

此外，在潜在变量子集中还会存在着一些无关噪声干扰。对此，Chen 等[55]于 2016 年提出生成对抗网络的信息论扩展网络 InfoGAN（Information-maximizing generative adversarial nets）。该网络旨在将潜在变量解耦为不可压缩噪声源 z 与有效信息源 c 两部分。考虑到有效信息源 c 应该在数据生成过程中发挥主要作用，InfoGAN 提出最大化有效信息源 c 与生成数据 $G(z,c)$ 间的互信息 $I(c;G(z,c))$。该文献使用变分后后验分布 $Q(c|x)$ 来近似真实后验分布 $P(c|x)$，设计出一种可以有效优化的互信息目标下界 $\mathcal{L}(G,Q)$，将难解问题可解化。其定义如式（14）所示。将其并入 GAN 的优化目标函数中，如式（15）所示，旨在鼓励网络学习更具可解释性和有意义的表征形式。

$$\begin{aligned}&\mathcal{L}_I(G,Q)=\\&\mathrm{E}_{\boldsymbol{c}\sim P(\boldsymbol{c}),\boldsymbol{x}\sim G(\boldsymbol{z},\boldsymbol{c})}\left[\ln Q(\boldsymbol{c}|\boldsymbol{x})\right]+H(\boldsymbol{c})=\\&\mathrm{E}_{\boldsymbol{x}\sim G(\boldsymbol{z},\boldsymbol{c})}\left[\mathrm{E}_{\boldsymbol{c}'\sim P(\boldsymbol{c}|\boldsymbol{x})}\left[\ln Q(\boldsymbol{c}'|\boldsymbol{x})\right]\right]+H(\boldsymbol{c})\le\\&I(\boldsymbol{c};G(\boldsymbol{z},\boldsymbol{c}))\end{aligned}\tag{14}$$

$$\begin{aligned}\min_{G,Q}\max_{D}V_{\mathrm{InfoGAN}}(D,G,Q)=\\V(D,G)-\lambda\mathcal{L}_I(G,Q)\end{aligned}\tag{15}$$

除此之外，Kim 等[56]认为对于这些无关噪声干扰间的解耦程度并不需要额外约束，于 2019 年引入相关性指标 r 对 Factor-VAE 进行改进，提出 RFVAE（Relevance factor variational auto-encoders）。如式（16）所示，旨在使式（10）中的最后一项仅作用于对数据有用的相关潜在变量。

$$\begin{aligned}\mathcal{L}(\theta,\phi)=&\mathrm{E}_{q_\phi(\boldsymbol{z}|\boldsymbol{x})}\ln p_\theta(\boldsymbol{x}|\boldsymbol{z})+\\&\mathrm{E}_{p_d(\boldsymbol{x})}\left[\sum_{i=1}^{d}\lambda_j\mathrm{KL}(q(z_j|\boldsymbol{x})||p(z_j))\right]+\\&\gamma\mathrm{KL}(q(\boldsymbol{r}\circ\boldsymbol{z})||\prod\nolimits_i q(r_i\circ z_i))+\eta\|\boldsymbol{r}\|_1\end{aligned}\tag{16}$$

对于序列型数据而言，时空一致性是其本征重要物理特性之一，若在潜在变量分布建模时融入该特性将有助于网络学习到更符合真实物理规律的表征形式。基于此，Grathwohl 等[57]于 2016 年针对视频序列中相对静止的背景场景与随时间平缓运动的前景目标间的解耦表征问题，提出采用式（17）的形式对背景表征分布进行建模，采用式（18）的形式对前景目标表征分布进行建模。此种建模方式模拟了真实世界中背景时空不变性与前景运动目标时空平缓变化的特征，更为有效合理。

$$\begin{aligned}p(h_0)&=\mathrm{N}(0,\boldsymbol{I})\\p(h_t)&=\mathrm{N}(h_0,\sigma_t\cdot\boldsymbol{I})\end{aligned}\tag{17}$$

$$\begin{aligned}p(h_0)&=\mathrm{N}(0,\boldsymbol{I})\\p(h_t)&=\mathrm{N}(h_{t-1},\sigma_t\cdot\boldsymbol{I})\end{aligned}\tag{18}$$

除了上述提及的几个特性外，还应注意到数据内部潜在变量表征往往是具有稀疏特性的，即不是每个潜在变量都需要对数据进行表征。传统变分自编码模型对于潜在变量的先验建模大多采用高斯正态分布，难以反映其内有稀疏特性，而学生 t 分布、拉普拉斯分布等厚尾分布则可以很好地体现变量的稀疏分布特性。基于此，Kim 等[58]于 2019 年提出分层贝叶斯深度变分自编码模型，BF-VAE（Bayesfactor variational auto-encoders）。同 InfoGAN[55]一样，将潜在变量分为相关潜在变量与干扰潜在变量两类。他们认为厚尾分布更适用于相关潜在变量的分布建模，而传统高斯分布则适用于干扰潜在变量的分布建模。利用此思想，在传统高斯先验的方差上引入超先验的同时保持传统 VAE 的易学性与推理性，将 VAE 扩展为分层贝叶斯模型。

因此针对具体问题，应具体分析其背后所具备的物理分布特性，并基于此选择适用的表征分布模型，将有助于提升整体网络的解耦表征学习能力。此外，对于本节所涉及的各类先验正则化归纳偏好方法的汇总如表 1 所示。从表 1 中可看出，本节所涉及的各类算法虽然一定程度上能够实现数据的有效解耦表征，

表 1　非结构化表征先验归纳偏好方法对比

工作	正则项	优点	缺点
β-VAE [46]	$-\beta D_{KL}(q_\phi(z\|x)\|\|p(z))$	高 β 值促使网络所学到的后验分布与先验分布尽可能服从相似的独立统计特性，提升解耦性能。	高 β 值在提升解耦性能的同时会限制网络的数据表征能力，直观反映为重构性能降低，无法很好权衡二者。
Understanding disentangling in β-VAE [47]	$-\gamma\|KL(q(z\|x)\|\|p(z))-C\|$	从信息瓶颈角度分析 β-VAE，在训练过程中渐进增大潜在变量的信息容量 C，能够在一定程度上改善了网络对于数据表征能力与解耦能力间的权衡。	该设计下的潜在变量依旧缺乏明确的物理语义，且网络增加了信息容量 C 这一超参数，需要人为设计其渐进增长趋势。
Joint-VAE [53]	$-\gamma\|KL(q_\phi(z\|x)\|\|p(z))-Cz\|$ $-\gamma\|KL(q_\phi(c\|x)\|\|p(c))-Cc\|$	运用 Concrete 分布 [54] 解决离散型潜在变量的解耦问题。	潜在变量缺乏明确物理语义。
AAE [48]	$DJS[E_\phi(z)\|\|p(z)]$	利用对抗网络完成累积后验分布与先验分布间的相似性度量，使得潜在变量的表达空间更大，表达能力更强。	面临对抗网络所存在的鞍点等训练问题 [50]。
DIP-VAE [49]	$-\lambda_{od}\sum_{i\neq j}[Cou_{q\phi(z)}[z]]_{ij}^2$ $-\lambda_d\sum_i([Cou_{q\phi(z)}[z]]_{ii}-1)^2$	设计更简便的矩估计项替代 AAE [48] 中对抗网络的设计，计算更为简洁有效。	该设计仅适用于潜在变量服从高斯分布的情况且并未限制均值矩或更高阶矩，适用范围有限。
Factor-VAE [51]	$D_{JS}(q(z)\|\|\prod_{i=1}^d q(z_i))$	设计对抗网络直接鼓励累积后验分布 $q(z)$ 服从因子分布，进一步改善了网络在强表征能力与强解耦能力间的权衡。	面临对抗网络所存在的鞍点等训练问题 [50]。
RF-VAE [56]	$D_{JS}(q(r\circ z)\|\|\prod_{i=1}^d q(r_i\circ z_i))$ $-\alpha Iq(x;z)$ -	引入相关性指标 r 使得网络对于无关隐变量间的解耦程度不作约束。	相关性指标 r 也需要由网络学习得到，加深了网络训练的复杂性。
β-TCVAE [52]	$\beta KL(q(z)\|\|\prod_{i=1}^d q(z_i))$ $-\gamma\sum_j KL(q(z_i))\|\|q(z_i))$	证明了 TC 总相关项 $KL(q(z)\|\|\prod_{i=1}^d q(z_i))$ 的重要性并赋予各个正则项不同的权重值构成新的优化函数使其具有更强的表示能力。	引入更多的超参需要人为调试。

但这类算法的学习过程依旧缺乏明确的物理语义导向。这将进一步引出本文后两节基于结构化模型先验归纳偏好与基于物理知识先验归纳偏好的解耦表征学习类研究算法探讨。

3　基于结构化模型先验归纳偏好的解耦表征学习

对于第 2 节中基于非结构化表征先验的解耦表征学习方法，Montero 等 [59] 于 2021 年设计实验，调整数据集中的部分属性取值范围，分别测试了原始 VAE，β-VAE，Factor-VAE 三类方法在相应测试集上的泛化性能，发现这类单纯施加非结构化表征先验正则归纳偏好的方法对于模型学习方向的约束能力隐形且较弱，不足以支持复杂情境设计下的组合泛化性。他们认为设计模块化、结构化、融合实际物理机理的模型尤为重要。本节将从顺序深度递归网络、层

次深度梯形网络以及树形网络三个由人类认知过程所启发的高度显式结构化网络模型来对现有基于结构化模型先验归纳偏好的解耦表征学习类研究进行归纳探讨，对于融入实际物理机理的模型设计将在本文第 4 节中进行探讨。

3.1 顺序深度递归网络

目前，大多数基于深度学习进行图像理解的方法往往倾向于一次性理解整幅场景。在生成式神经网络的背景下，这通常意味着所有像素都受单次潜在分布的约束，且网络无法进行迭代自校正。然而人类进行场景感知时往往不倾向于同时处理整幅场景。相反，人类会利用连续的中心凹运动进行“主动感知”：在给定的时间内，有选择地将注意力集中在中心凹的高分辨率视觉空间中，并随着时间的推移将来自不同注视点的信息结合起来，指导未来的眼球中心凹运动序列（旋转和平移）决策，逐渐建立起整幅场景的全面表征，如图 4 所示。受到该人类感知方法的强烈驱动，许多学者逐渐发现“一次性感知”表示方法从根本上很难扩展到大图像或目标占比过小的图像场景。与此相比，通过一系列的局部瞥视或显著区域捕捉可以更好地捕获视觉结构[60-62]，这种思想可以通过使用递归神经网络执行概率迭代推理来实现，使得网络每次只关注部分图像进行处理，最终整合至整幅图像。这种顺序递归模型的明显优点是，通过将复杂数据分布映射到一系列更简单的问题中，反复生成以先前状态

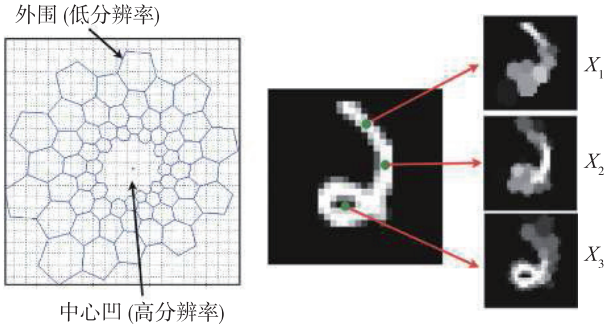

（a）视网膜瞥视示意图　（b）视网膜瞥视过程可视化示例图

图 4　人类视网膜瞥视过程图[60]

为条件的输出，简化了建模复杂数据分布的问题。然而该方法的难点在于如何选择注意机制以及如何将显著区域的位置与提取的特征相结合，如何选择递归次数等。

Larochelle 等[60] 于 2010 年首先提出一种特殊的模拟人眼中心凹特性的受限玻尔兹曼机模型，该模型在可见单元（瞥视），隐藏单元（累积特征）以及控制可见单元与隐藏单元连接的位置相关单元间建立三阶连接，学习如何在多个固定点上累积有关单个目标形状的信息。基于此思想，Mnih 等于 2014 年[61] 将注意机制问题看作是以目标为导向的智能体与视觉环境交互的顺序决策过程。他们提出基于递归神经网络的循环注意机制模型，为每次决策设计计算一个标量奖励的反馈，从而结合强化学习的训练策略，促使最终决策的总和最大化。该模型随后被 Gregor 等[62] 扩展为深度递归视觉注意模型（DRAW）用于生成图像，在 VAE 的框架下采用递归循环网络来构建编码器与解码器，每次循环通过解码器发出的修改累积迭代地构造场景，同时嵌入空间二维高斯滤波器来产生位置、缩放平滑变化的局部图像“块”充当每次迭代过程中网络所选定的注意区域。而对于如何选择迭代次数，他们将其视为人为提前设定的固定超参数。

目前该思想被广泛用于解决复杂场景多目标解耦问题。对于场景的认知，Henderson 等[63] 给出了以下定义：“场景是真实世界环境的语义连贯（通常是可命名的）视图，包含背景元素和以空间特定方式排列的多个离散对象。”基于此，许多学者将循环递归网络每次的迭代过程视为新目标的形成过程，并在每次形成新目标后通过一组特定的仿射函数将其与之前场景相复合。其中，Eslami 等[64] 于 2016 年提出的基于 VAE 的结构化图像模型 AIR（Attend-infer-repeat）引起人们的广泛关注，后续被大量引用于复杂多目标场景的解耦表征研究中。该模型可理解为基于对象的解耦表征，通过将编码推理网络构建为递归神

经网络的形式促使网络迭代学习关于场景中存在的每个对象的解耦表征。且由于该模型将对象表示为{存在概率、特有属性、坐标}三类，该模型可被用于目标检测、识别等下游推理任务中。后续被 Crawford 等[65]改进为适用于较多目标场景的检测模型 SPAIR（Spatially invariant attend-infer-repeat）。AIR 的整体架构设计如图 5 所示，通过平摊、迭代推理的方式来逐目标地实现多对象场景的理解，并结合空间仿射变换对坐标这一潜在表征施加强物理约束，有效指引了网络的学习方向。除此之外，AIR 将网络的迭代次数，即前景目标个数也视为一个隐变量，服从特定的分布，这一方法对于可变数量的前景目标检测具有更强的鲁棒性与泛化性。然而该方法只能处理简单背景下少量前景目标的检测等问题，且并未进一步考虑不同目标间的语义关联关系。

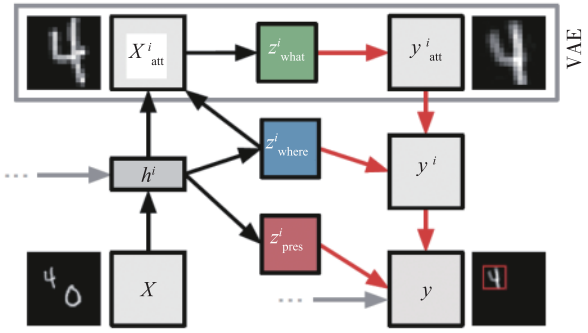

图 5　模型架构设计图[64]

为了扩展 AIR 在连续视频场景下的使用，Kosiorek 等[66]于 2018 年提出的 SQAIR（Sequential-attend-infer-repeat）将视频中所具有的时空一致性加入原始 AIR 模型中进行改进。具体而言，该模型将视频数据的生成过程分为两支路实现：传播支路（Propagation，PROP）用于负责更新（或遗忘）前一时间步中所含对象的潜在变量观测（图像），且结合关系 RNN[67]来对物体间的关系进行捕获；发现支路（Discovery，DISC）在传播支路（PROP）的基础上进一步检测是否有新对象出现。该模型能够实现简易视频数据集中的目标检测跟踪问题，为具有时序变化性的变分自编码架构设计提供了前瞻性的解决思路。此外，Massague 等[68]于 2020 年提出视频部分帧缺失情况下的解耦表征问题。他们认为人类在视频帧突然缺失或突然受到干扰的情况下自然而然地认为之前帧中的物体依旧存在，且其运动轨迹遵循之前的规律。基于此，他们在潜在空间设计中多考虑了一组代表缺失状态的潜在变量子集用于判别当前帧数据的缺失状态，若缺失，则通过在过去帧的潜在空间采样来插补近似缺失帧的潜在表征。此设计促使网络自监督地学习缺失数据的插补表征方式，一定程度上解决了视频部分帧缺失数据的解耦表征问题。

3.2　层次深度梯形网络

除了第 3.1 节中利用循环递归网络实现顺序迭代逐步处理特定任务外，考虑到现实世界中许多自然信号本身所特有的成分分层特性，本节集中于层次深度梯形网络的设计搭建，赋予深度网络不同语义特征提取过程中显式层次结构的归纳偏好，即通过组合较低层的语义特征来获得较高层的语义特征表示。例如在现实世界中，边缘的局部组合形成图案，图案组装形成零件，零件组装形成对象。

Sønderby 等[69]于 2016 年提出梯形变分自编码网络（Ladder variational auto-encoders，LVAE）。与传统 VAE 所使用的推理模型与生成模型间无交互作用的纯自底向上推理过程（如图 6（a）所示）不同，该文献提出推理与生成模型中共享自顶向下的依赖结构，如图 6（b）所示，使得模型的推理过程只用简单修正生成分布，将优化过程变得更加容易。

然而 Zhao 等[70]认为 LVAE[69]在训练到最优的情况下，仅底层潜在变量包含足够的信息用于重建数据分布，其余层则很容易被忽略。且通常用于构建层次生成模型的许多构建块不太可能帮助学习解耦特征。基于此，他们于 2017 年提出变分梯形自动编码网络（Variational ladder auto-encoders，

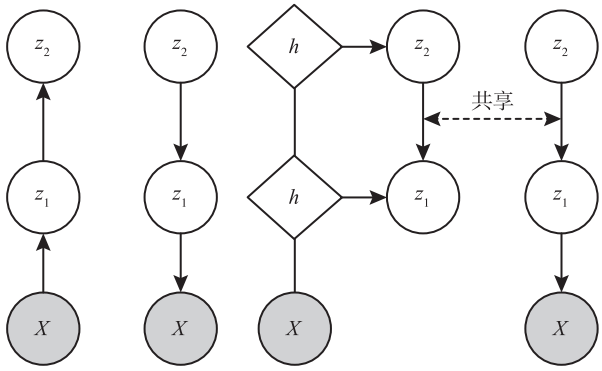

（a）VAE[43]　（b）LVAE[69]

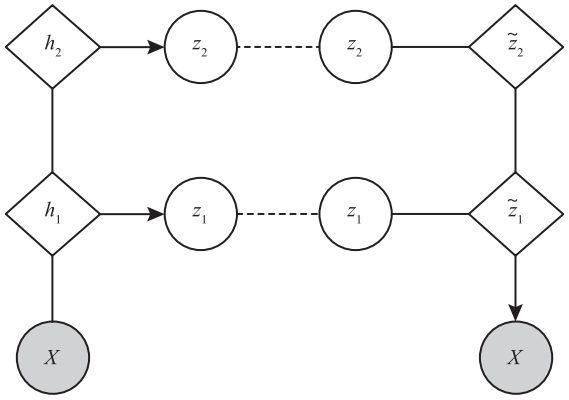

（c）VLAE[70]

图 6　深度梯形网络模型图

VLAE），通过在每一层潜在变量与图像之间映射所需的计算程度来分离图像的潜在变量子集。将不同层次的潜在变量与具有不同表达能力（深度）的网络连接起来；鼓励模型在顶部放置高层次、抽象的特征（如身份特征等），在底部放置低层次、简单的特征（如边缘特征等）。该模型设计如图 6（c）所示，其中条件生成模型 $p(x|z_1, z_2; \cdots; z_L)$ 被隐式定义为式（19）的形式。推理网络定义为式（20）的形式。这种模型设计使得越高层、越抽象的潜在表示需要越复杂的网络来捕获，在不需要特定任务规则化或先验知识的情况下，能够学习到高度可解释的、解耦的层次特征。该模型随后被 Willetts 等[71]用于促使网络在不同层解耦代表不同属性的潜在表征，从而基于该表征在各个层次实现按照不同属性区分的聚类任务，他们称其为解耦聚类。除此之外，Esmaeili 等[72]于 2019 年从多级隐变量角度出发，将潜在变量分为组间潜在变量与组内潜在变量两级来对 KL 项进行进一步分解，如式（21）、（22）所示，提出了基于 VAE 的两级分层 HFVAE（Hierarchically factorized variational auto-encoders）模型。该模型可以通过控制两级隐变量不同的权重系数来控制组间隐变量与组内隐变量的相对解耦程度，如式（23）所示。

$$\begin{aligned}\tilde{\boldsymbol{z}}_L &= f_L(\boldsymbol{z}_L)\\ \tilde{\boldsymbol{z}}_l &= f_l(\tilde{\boldsymbol{z}}_{l+1}, \boldsymbol{z}_l)\\ \boldsymbol{x} &\sim r(\boldsymbol{x}; f_0(\tilde{\boldsymbol{z}}_1))\end{aligned} \tag{19}$$

$$\begin{aligned}\boldsymbol{h}_l &= g_l(\boldsymbol{h}_{l-1})\\ \boldsymbol{z}_l &\sim \mathrm{N}(\mu_l(\boldsymbol{h}_l), \sigma_l(\boldsymbol{h}_l))\end{aligned} \tag{20}$$

其中 f_l，g_l 均为非线性神经网络映射。

$$\begin{aligned}&\mathrm{KL}(q_\phi(\boldsymbol{z})||p(\boldsymbol{z})) =\\ &\mathrm{E}_{q_\phi(\boldsymbol{z})}\left[\ln\left[\frac{q_\phi(\boldsymbol{z})}{\prod_d q_\phi(\boldsymbol{z}_d)}\circ\frac{\prod_d q_\phi(\boldsymbol{z}_d)}{\prod_d p(\boldsymbol{z}_d)}\circ\frac{\prod_d p(\boldsymbol{z}_d)}{p(\boldsymbol{z})}\right]\right] =\\ &\mathrm{E}_{q_\phi(\boldsymbol{z})}\left[\ln\frac{q_\phi(\boldsymbol{z})}{\prod_d q_\phi(\boldsymbol{z}_d)}-\ln\frac{p(\boldsymbol{z})}{\prod_d p(\boldsymbol{z}_d)}\right]+\\ &\sum\nolimits_d \mathrm{KL}(q_\phi(\boldsymbol{z}_d)||p(\boldsymbol{z}_d))\end{aligned} \tag{21}$$

其中

$$\begin{aligned}&\mathrm{KL}(q_\phi(\boldsymbol{z}_d)||p(\boldsymbol{z}_d)) =\\ &\quad\mathrm{E}_{q_\phi(\boldsymbol{z})}\left[\ln\frac{q_\phi(\boldsymbol{z}_d)}{\prod_e q_\phi(\boldsymbol{z}_{d,e})}-\ln\frac{p(\boldsymbol{z}_d)}{\prod_e p(\boldsymbol{z}_{d,e})}\right]+\\ &\quad\sum\nolimits_e \mathrm{KL}(q_\phi(\boldsymbol{z}_{d,e})||p(\boldsymbol{z}_{d,e}))\end{aligned} \tag{22}$$

$$\begin{aligned}&\mathcal{L}(\theta,\phi;\boldsymbol{x},\boldsymbol{z}) =\\ &\quad\mathrm{E}_{q_\phi(\boldsymbol{z}|\boldsymbol{x})}\ln p(\boldsymbol{x}|\boldsymbol{z})-\alpha I_{q_\phi}(\boldsymbol{x};\boldsymbol{z})-\\ &\quad\beta\mathrm{E}_{q_\phi(\boldsymbol{z})}\left[\ln\frac{q_\phi(\boldsymbol{z})}{\prod_d q_\phi(\boldsymbol{z}_d)}-\ln\frac{p(\boldsymbol{z})}{\prod_d p(\boldsymbol{z}_d)}\right]-\\ &\quad\gamma\mathrm{E}_{q_\phi(\boldsymbol{z})}\left[\ln\frac{q_\phi(\boldsymbol{z}_d)}{\prod_e q_\phi(\boldsymbol{z}_{d,e})}-\ln\frac{p(\boldsymbol{z}_d)}{\prod_e p(\boldsymbol{z}_{d,e})}\right]-\\ &\quad\sum\nolimits_e \mathrm{KL}(q_\phi(\boldsymbol{z}_{d,e})||p(\boldsymbol{z}_{d,e}))\end{aligned} \tag{23}$$

3.3 树形网络

除了第 3.2 节中所展示的层次深度梯形网络架构的设计，树形模型的结构设计更是将第 3.2 节中深度层次梯形网络与高层超潜变量间的横向连接思想相融合，如图 7 所示，构建出更符合现代神经科学在视觉皮层中观察到的横向连接现象。将此结构归纳偏好再次加入模型结构设计中，通过引入更深层的超潜变量父节点可以在达到子节点中潜在变量解耦效果的同时结合更深层父节点语义间的交互性特征，实现更科学的解耦性能。

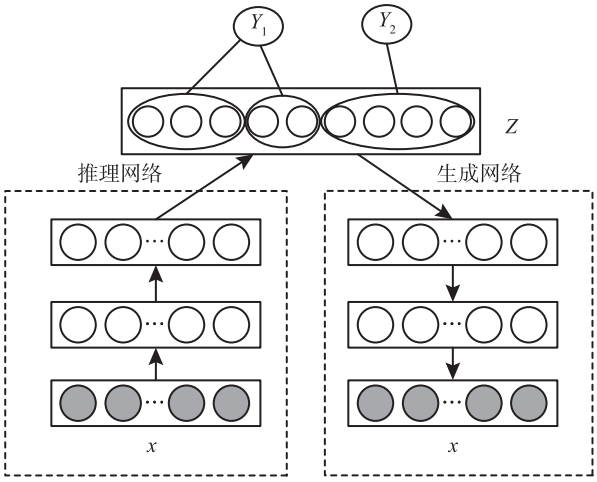

图 7　简易树形变分自编码模型示意图 [73]

George 等 [74] 于 2017 年所提出的递归皮层网络（Recursive cortical network，RCN）便搭建出一种类似人类大脑皮层处理方式的组合性树形结构网络，如图 8（d）所示。该网络将目标对象解耦为轮廓表征与外观表征，如图 8（a）所示，使模型能够识别具有明显不同外观的对象形状，在复杂场景下的文本识别中展示了出色的泛化和遮挡推理的能力。其中外观表征使用条件随机场（Conditional random field，CRF）建模来反映外观表面平滑变化的物理特性。轮廓表征的建模方式如图 8（b）所示，通过多层特征池、横向连接、组合的设计，实现高层次特征间相互独立，又同时共享底层特征彼此交互的特性。其中池化结构的设计使得顶层特征节点能够表示具有一定平移、缩放和变形不变性的对象；横向连接的设计能够实现同一层次不同组特征间的彼此交互作用，其直观展示如图 8（c）所示。该网络设计为组合式模型提供了更多的概率图模型中所涉及的高级推理与学习算法。

Li 等 [73] 于 2019 年提出潜在树形变分自编码器（Latent tree variational auto-encoders，LTVAE），其表示结构是由多个超潜变量组成的树结构，与 Willetts 等 [71] 类似旨在生成多种按照数据不同指标方式的聚类结果。该模型假设数据是通过神经网络从潜在特征生成的，而潜在特征本身被另一层次的超潜变量通过树型贝叶斯网络生成，每个超潜变量都代表着一种聚类方式。该方法能够自主选择每个超潜变量的潜在特征子集，并学习不同超潜变量间的依赖结构。

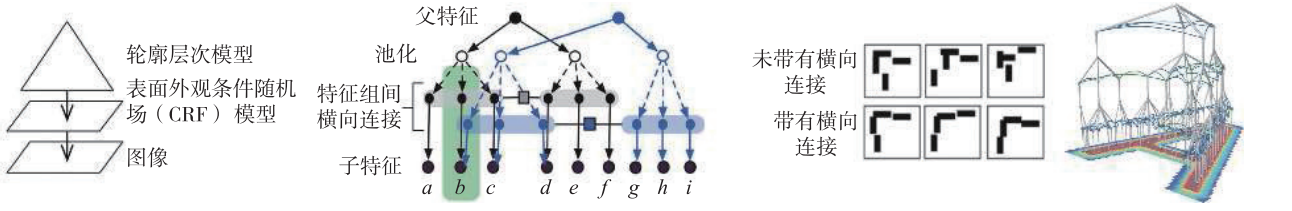

（a）轮廓表征与外观表征的层次化解耦结构示意图　（b）包含池化结构与横向连接设计的轮廓层次结构示意图　（c）带有和不带有横向连接设计在一个文字角点处的直观展示图　（d）字母“A”的四级轮廓层次网络结构图

图 8　RCN 模型示意图 [74]

4 基于物理知识归纳偏好的解耦表征学习

除了第 2 和 3 节基于非结构化与结构化先验归纳偏好的解耦表征学习研究外，在模型中融入真实数据内所蕴含的物理本征机理和复杂逻辑关系将有助于进一步发展内嵌底层逻辑与物理内涵的解耦表征学习新体系。因此本节将从输入数据间的物理关联与基于对象的场景空间组合两种物理语义理解层面着手，研究当下融入物理知识归纳偏好的解耦表征学习。

4.1 基于输入数据间物理关联的多输入解耦表征学习

第 2 和 3 节所述有关解耦表征学习的研究均默认输入数据服从独立同分布特性，然而在弱监督分组观测的情况下，组内数据间蕴含着一定的共性特征（如各种视角下的同一物体共享身份特征；同一颜色下的不同物体共享颜色特征等），如图 9 中遥感舰船图像组数据示例，此时组内数据间具有一定的相关性，该假设不再成立。因此本节旨在研究如何将组内数据间的弱监督相关性信息加入到网络归纳偏好的设计中，实现针对分组数据的相关因子与不相关因子的解耦表征学习。除此之外，本节也会涉及到成对输入图像中感兴趣因子的差异比较，这种比较与医生根据两个病人的疾病对比程度来量化他们的疾病严重程度思想类似，旨在能够对相关感兴趣因子进行更好的量化。

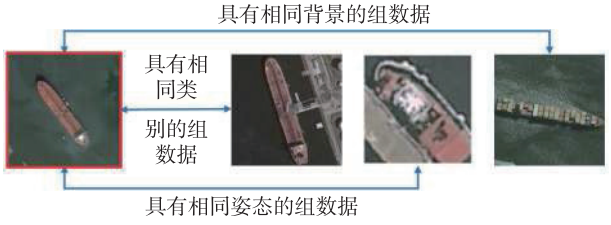

图 9 遥感舰船图像组数据示例图

针对具有部分完全相同属性的分组数据而言，大量研究学者提出通过在组内数据间共享或交换部分潜在变量的方法[75-79]，促使网络学习到代表组内数据间特定相关生成因子所对应的潜在变量，通过该举措能够从施加强结构偏好的角度有效完成组内数据相关因子与不相关因子的解耦表征学习任务。

Bouchacourt 等于 2018 年[75]提出多级变分自编码器（Multi-level variational auto-encoders，ML-VAE），在组内数据共享相关因子潜在表示 C_G 的同时，认为不相关因子的潜在表示 S_G 服从独立阶乘分布，二者共同参与图像的生成过程。其中值得注意的是，该架构构建了两组完全分离的编码网络，ϕ_c，ϕ_s 分别为这两组分离的编码网络的变分参数，对两组隐变量语义表示进行源头性的阻断隔离解耦，同时可以通过交换潜在表示生成新的类型图像对解耦表征进行可视化展示。其整体的优化函数如式（24）所示。

$$\begin{aligned}&\mathcal{L}(\boldsymbol{G};\theta,\phi_c,\phi_s)=\\&\sum_{i\in G}\mathrm{E}_{q(\boldsymbol{C}_G|\boldsymbol{X}_G;\phi_c)}\left[\mathrm{E}_{q(\boldsymbol{S}_i|\boldsymbol{X}_i;\phi_s)}\left[\ln\left(\boldsymbol{X}_i|\boldsymbol{C}_G,\boldsymbol{S}_G;\theta\right)\right]\right]-\\&\sum_{i\in G}\mathrm{KL}\left(q\left(\boldsymbol{S}_i|\boldsymbol{X}_i;\phi_s\right)||p\left(\boldsymbol{S}_i\right)\right)-\\&\mathrm{KL}\left(q\left(\boldsymbol{C}_G|\boldsymbol{X}_G;\phi_c\right)||p\left(\boldsymbol{C}_G\right)\right)\end{aligned}\tag{24}$$

与 ML-VAE 组内数据共享相关因子的表示不同，Szabó 等[77]于 2018 年提出组内图像对间通过交换不相关因子的潜在变量表示来重构出其所对应的另一幅图像，而不是原图像本身，通过这种操作达到解耦相关因子与不相关因子的目的。除此之外，他们提出对于分组数据的解耦表征学习往往存在退化映射问题，即图像的所有信息均集中在某一部分的特征表示中。为了缓解这一问题，他们引入与输入图像对均完全无关的图像，运用对抗思想再次将潜在变量进行交换来保证相关因子的潜在变量表示一定包含部分图像信息，有效避免了退化映射现象的发生。Ge 等[78]于 2021 年提出组监督学习模型 GSL（Group-supervised learning），在结合上述交换潜在变量表示进行回归匹配思想的同时融合 Cycle-GAN[80]的思想，将交换隐变量表示后的图像再次通过同样的网络将其交换回来进行与原图像间的回归匹配。该思想相较于上述方法优势在于保证上述方法性能的同时，通过再次交

换回传可以进一步施加原转换问题的逆约束，使得属性值不一样的相关因子（如都含有颜色相关属性但属性值不同的组图像）的解耦进一步明朗化。以图 9 中的遥感舰船图像组数据为例，若使用 GSL 模型，则该模型对应的网络设计如图 10 所示。

除了上述通过共享或交换潜在变量来达到相关属性与其余属性的解耦表征外，从互信息相关性角度对分组数据内潜在表示间进行相关性度量，也可以进一步对分组数据输入施加正则约束，从而促进分组数据潜在表示的挖掘与解耦。Sanchez 等[81]便于 2020 年采用局部互信息与全局互信息相结合的方式衡量图像对内相关因子潜在表示的相关性，让其值尽可能大，促使分组数据间不同数据的相同属性表示尽可能相似。同时为了达到解耦目的，运用对抗思想来使同一数据内共享表示和互斥表示间的互信息尽可能小。

将上述共享或交换隐变量表示与互相关信息的思想相结合，Esser 等[82]构建分离的姿态编码器与外观编码器，从目标姿态所对应的图像中学习姿态表示，从目标外观所对应的图像中学习外观表示，随后共同送入解码网络中生成新的图像。该网络在训练过程时与 Sanchez 等[81]类似也采用判别器约束外观表示与姿态表示间的互信息大小。Lorenz 等[83]在 Esser 等[82]的基础上，将前景目标看作由一系列部件通过一定的空间组合规律组成，每个部件都具有外观与姿态特性，除此之外他们还利用物理变换的方式人为将一幅图像扩充为姿态发生变化但外观未变的图像与外观未发生变化但姿态发生变化的图像来取代组标签信息，从而设计分离的编码网络，从外观变化的图像中学习姿态信息，从姿态变化的图像中学习外观信息。该网络设计能够在无监督条件下利用自监督思想有效实现部件间姿态与外观的解耦表征，将分组数据间的解耦表征研究思想应用到通过数据增强等有效物理转换方式的独立数据解耦表征研究中。此后这种通过物理变换构造分组数据以及姿态，外观的解耦方式还被 Liu 等[84]用于无监督部件分割的任务研究中。Dundar 等[85]则是将上述方法扩充到视频信息中随时空变化与随时空不变的信息间的解耦表征。他们认为相邻帧中除了背景信息随时间推移稳定不变外，前景纹理信

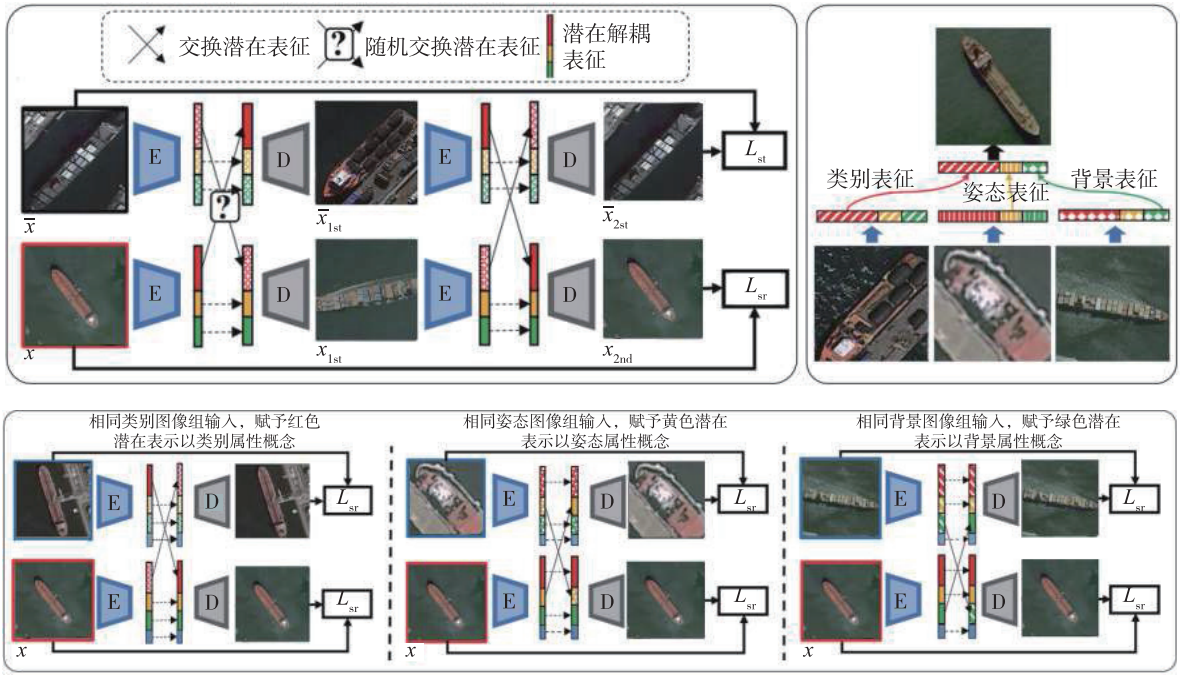

图 10　GSL 模型[78]用在遥感舰船图像组数据集中对应的网络架构示意图

息在前景目标还未消失前也同样保持不变，随时间变化的仅为前景目标的形态姿势信息。基于此，他们利用相邻帧之间前景目标姿态信息各异而外观信息与背景信息共享这一组内的弱监督信息出发，创建出一种新颖的模型架构旨在将视频帧中前景与背景分离，且前景信息中姿态信息与外观信息分离。

以上研究都是基于相同的指标属性进行分组解耦表征，然而现实数据集中大多纷杂错乱，如何综合利用按照各种不同指标的分组数据变成了一个新的挑战。Vowels 等[86]于 2020 年提出了 Gated-VAE，期望在网络训练过程中能够加入任何可用领域的先验知识，使得模型的适用性更广。他们提出一种新颖的训练方式，在梯度前向传播过程中，所有潜在空间的分区共同合并在一起，即在整个潜在空间上进行优化函数的计算；但在误差反向传播过程中，梯度将根据不同的图像对来选择特定的潜在空间分区进行传播。通过这种独特的训练方法，他们认为如果整个数据集中所需的分区与人为所划分的图像对一致，则各个分区将包含不同的因素。即使在分区内存在纠缠现象，分区间也会实现解耦，为解耦学习的研究注入了新思路。

4.2 基于对象空间组合归纳偏好的解耦表征学习

正如第 3.1 节所述，场景图像可看作由背景元素和以空间特定方式排列的多个离散对象组成，而单个对象又可以看作是由外观与形状耦合而成。因此本节注重于考虑如何将一幅复杂场景解构为多个简单对象的组合，并据此理解 / 生成这些简单对象的组合关系。

人类天生具有组合泛化的能力，如图 11 所示，对于一幅多物体复杂场景，人类可以将其解构为多个简单对象，并可以在脑海中按照空间位置重新排列组合这些对象，构成一幅新的场景图。除此之外，对于单个简单对象而言，人类也可以将其解构为具有多组共通属性与各异属性的多个简单部件。正是依靠这种组合泛化能力，人类智能才能够从一些最基础的元素出发，一步一步创造出复杂甚至无限的语义世界。从这个角度出发，越来越多的研究工作开始研究探索数据集中内在的组合性规律，旨在促使深度神经网络拥有像人类一样的组合泛化能力。

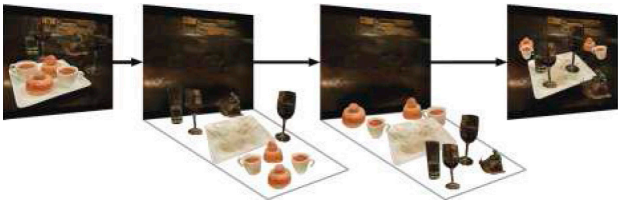

图 11　人类想象泛化能力示意图[87]

要拥有像人类一样的组合泛化能力，首先应学会对各类输入数据进行内在分组解耦，例如在解决鸡尾酒会的问题时，应对不同说话人的语音进行解耦；在自动驾驶中，应对道路上各种不同对象的类别、位置和速度进行解耦。在现实世界中，这些信息或多或少相互纠缠，隐藏在可见数据背后，本小节将着重于解耦隐藏在真实数据背后的丰富物理结构，完成不同对象不同特性的解耦表征任。

Greff 等[88]于 2016 年提出一种能够有效进行分组解耦的迭代推理框架（TAGGER）。该框架对数据输入类型不设约束，结合期望最大化（Expectation-maximum，EM）聚类算法，对数据背后的潜在分组以及每个分组所对应的潜在表示进行迭代摊销推理：给定分组的条件下推断各个组内特征；给定各个组内特征的条件下推断分组，如此迭代优化地完成对组分配以及各个组内对象表征的估计任务。然而正是由于该方法对数据类型以及网络设计不施加任何其他约束，仅能够对存在明显分组偏差的简单数据集进行解耦表征，并未泛化到各类复杂任务场景中。

对于单目标场景的组合泛化能力而言，Li 等[89]于 2020 年提出条件生成模型 MixNMatch（Mixand-match），旨在将单目标场景解耦为背景、前景目标的形状、姿态、外观四类表征。他们对于场景生成过程的理解借鉴 Singh 等[90]的 FineGAN 模型，分离为三个独立作用的阶段：背景提取阶段、父场景前景形

状提取阶段和子场景外观提取阶段。其中背景提取阶段利用控制背景图像生成的潜在变量进行背景建模。父场景前景形状提取阶段利用控制对象的轮廓（形状）的潜在变量生成前景目标的形状掩模。子场景外观提取阶段则利用控制对象外观纹理的潜在变量进行前景外观建模。三个独立的生成网络间首尾相连将每个网络生成的图像拼接耦合在一起生成最终的细粒度图像。尽管这类模型在单域数据集下能够达到很好的解耦表征性能，具有一定的联想组合泛化能力，但对于多个跨域数据集的解耦性能却不尽如人意。Ojha 等[91]认为其原因在于源域属性信息在单域数据集下并未多做考虑，导致其耦合在形状、外观等表征中。对此，他们在 FineGAN 的基础上提出一种基于可学习的物体外观特征直方图表示，从而消除跨域情况下域信息对于物体解耦表征的影响。

除了将前景目标视为一个整体解耦其姿态与外观纹理属性外，Lorenz 等[83]认为前景目标可解耦为不同部件的外观表示与姿态表示。如此则应保证原部件施加外观转换干扰时其所对应的姿态表示不应发生变化，反之亦然。他们便将这种真实世界存在的物理约束加入模型设计中，从部件外观变化的图像中学习部件姿态表示，从部件姿态变化的图像中学习部件外观表示这种强逻辑结构。但他们并未进一步考虑部件与整体间的逻辑映射关系。对于此类问题，Kosiorek 等[92]于 2019 年提出的堆栈胶囊自编码网络（Stacked capsule auto-encoders，SCAE）则巧妙运用自然语言处理领域内 Settransformer[93]思想，将部件组成整体的任意组合方式考虑进去。该模型首先将图像分割为多个部件，再将部件组合为多个连贯的整体，整个逻辑图如图 12 所示，不仅能够解决单目标场景的部件解耦问题，还能够泛化到多目标场景的目标级解耦以及每个目标多对应的多部件解耦中，为解耦问题注入了新思想。此外，Yang 等[94]认为解耦后的潜在变量在通过解码网络生成原图像的过程应服从一定的因果关系，他们提出的 CausalVAE 在网络解码过程中加入了一层用于挖掘潜在变量间因果关系的因果层，促使整个网络的生成过程更服从人类对于世界因果关系的认知过程，为构建因果结构化的解耦表征学习模型提供了重大的参考意义。

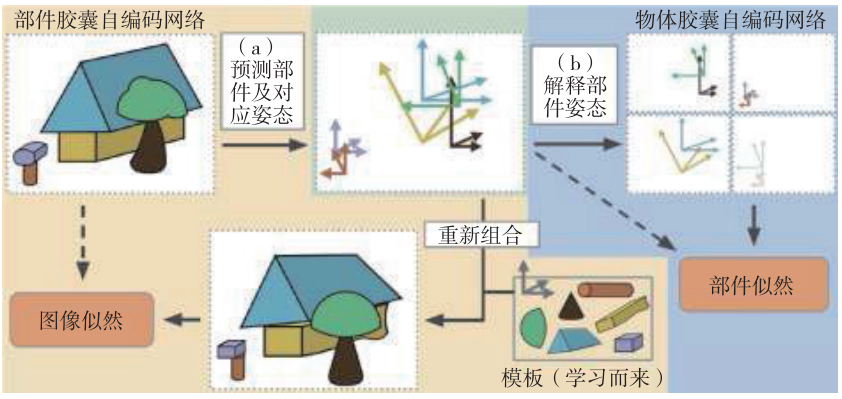

图 12　堆栈胶囊自编码网络（SCAE）模型架构图[92]

针对多目标场景的对象级解耦表征理解，除了上述的 SCAE 模型外，2019 年，Greff 等[95]提出的迭代对象分解推理网络（Iterative object decomposition inference network，IODINE）与 Bur-gess 等[96]提出多对象网络（Multi-object network，MONET）均将多目标场景图像理解为由多个物体级别的抽象块按照一定的空间映射关系组合而来。基于此假设，二者均将多目标场景图像分布视为由多个服从单高斯分布的物体级抽象块按照一定的概率组合而成的混合高斯分布。其中对于推理网络的设计，IODINE 采用迭代变分推理的方式[97]得到每个物体级抽象块所对应的潜在表征，随后利用解码网络得到每个物体级抽象块所对应的高斯分布

似然图以及空间掩码概率图。而 MONET 则使用递归空间注意力网络得到每个物体级的抽象块所对应的空间掩码概率图，随后将该概率图与原图一起输入自编码网络中得到每个物体级抽象块的高斯分布似然图。然而这两个网络仅能处理简单多目标场景，并不能解决复杂多目标场景的目标级解耦表征。

针对复杂多目标场景的解耦表征理解，Zhan 等[87] 于 2020 年提出了一种自监督的场景遮掩算法，用于学习物体间相互遮挡的空间关系。如图 13 所示，该算法从前景目标间的空间排列组合方式提出了构建有向图进行表征的新角度，通过目标间的空间逻辑树状图的构建实现了对多目标场景图像的空间想象。

除此之外，Prabhudesai 等[98] 于 2021 年提出从 3D 特征图的角度进行二维图像解耦的新思想。他们认为对于一个前景目标而言，三维本征立体结构是目标本身的内禀不变属性，据此他们提出将二维图像投影到三维空间中，在三维空间中进行对象级别的解耦更加能够符合人类对于二维图像数据的认知过程，且通过此方式不仅能够解决目标遮掩与视角大差异性问题，而且能够从任意视角想象泛化出新场景图像，为真正从三维角度看待二维图像解耦表征问题提供了良好的解决思路。

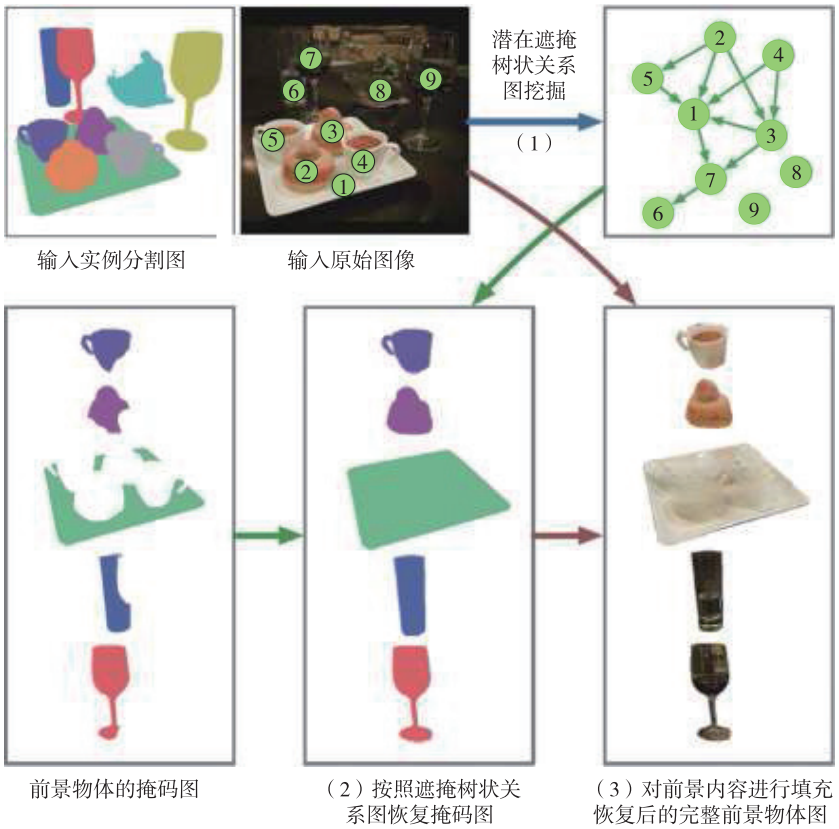

图 13　多目标场景去遮掩实现过程示意图[87]

5　模型对比分析

上文描述的有关解耦表征学习算法被归纳为三类：基于非结构化表征先验的解耦表征学习、基于结构化模型先验归纳偏好的解耦表征学习与基于物理知识归纳偏好的解耦表征学习。本节将对这三类方法进行对比分析，讨论其各自的适用范围，并选取部分模型进行实验性能的可视化展示，突出解耦表征学习对各类下游任务以及可解释性深度学习的贡献。

解耦表征学习的真正内核在于将数据内部各个具有可解释性的生成因子采用尽可能独立的潜在变量子集进行捕获表征，并不拘泥于特定的数据类型与具体的下游任务。从表 2 中可以看出，本文各类算法的适用场景以及对应的下游任务不尽相同，所选用的数据集也各有侧重。因此对于解耦表征学习而言，各类算法的评价指标并未有统一标准，应根据实际情况具体分析所需解决问题的特定数据集，从主观的角度出发设定能为人类所理解的特定评价指标。基于此，本节仅选取

几类典型算法的特定测试性能进行展示以辅助读者结合表 2 内容对解耦表征学习进一步深入思考。

首先针对第一大类基于非结构化表征先验的解耦表征算法而言，该类算法大都属于无监督学习范畴，通过在网络优化过程中对潜在表征施加独立性、稀疏性等归纳偏好，约束网络学习可分离的潜在表征。对于这些可分离表征的物理意义验证，大多文献采用控制变量重构法进行直观可视化验证，即在保持其余潜在表征不变的情况下，依次单独变换某一特定潜在表征的取值，通过分析重构图像所发生的可视化改变来对这一特定潜在表征所代表的具体物理含义进行人为分析理解，如图 14 所示。除此之外，Higgins 等[46]，Kim 等[51]，Kumar 等[49]，Chen 等[52]，Eastwood 等[130]先后提出一系列有关潜在表征解耦性能的度量方法，然而这些方法只是单纯探究潜在表征的可分离性，对其背后所捕捉的可解释性因子并未进行评判。而解耦表征学习的本质重在挖掘数据生成背后复杂耦合的物理机理，并非单纯地学习一堆未知含义但拥有独立统计特性的潜在表征集合。因此本节并未同 Locatello 等[37]一样根据这些独立性指标对该类算法进行量化对比，只是单纯列举其中典型算法 AAE[48]，Factor-VAE[51]在一些数字、人脸等简易数据集上的可视化解耦表征结果，分别如图 14、15 所示。

表 2　不同归纳偏好方法对比

归纳偏好分类		模型	简要描述	适用范围	数据集
非结构化表征先验		β-VAE[46] InfoGAN[55] 文献[47] Joint-VAE[53] AAE[48] DIP-VAE[49] Factor-VAE[51] RF-VAE[56] β-TCVAE[52]	在网络优化过程中施加表 1 中不同的先验正则项，能够促使网络学习到的潜在表征具备一定的解耦性能。但该类方法并未涉及足够的显式物理语义约束，网络不一定按照人类理解的方式进行解耦，因此该类方法一般用于规律性较强的简易数据集中。	适用于解耦表征存在显著可分离属性的简易数据集，如人脸数据集、数字数据集等。	MNIST[99]；SVHN[100]；CelebA[101]；2D Shapes[102]；3DChairs[103]；dSprites[102]；3DFaces[104]
结构化模型先验	顺序深度递归网络	DRAW[62] AIR[64] SQAIR[66]	通过构建顺序深度递归网络架构，可以在执行决策时反复结合历史状态特征，实现如简易场景下的检测、跟踪等。	适用于需要关联记忆的多次决策任务场景。	3Dscenes[64]；Multi-MNIST[64]；dSprites[102]；Moving-MNIST[66]；Omniglot[105]；PedestrianCCTV data[106]
	层次深度梯形网络	VLAE[70] 文献[71] HFVAE[72]	使用层次梯形网络模拟人类由浅入深的层次化认知过程，促使每层潜在变量代表着不同的涵义，可用作聚类等任务。	适用于简易数据集下由浅入深的属性挖掘。	MNIST[99]；CelebA[101]；SVHN[100]；dSprites[102]

续表

归纳偏好分类		模型	简要描述	适用范围	数据集
结构化模型先验	树形网络	RCN[74] LTVAE[73]	使用树形网络模拟人类高级神经元间的横向交互过程，完成底层特征解耦的同时高层特征语义交互，可用作聚类、自然场景文本识别等任务。	适用于底层特征解耦共享，高级特征耦合交互的场景任务。	CAPTCHA[107]；ICDAR-13 Robust Reading[107]；MNIST[99]；HHAR[73]；Reuters[108]；STL-10[73]
物理知识先验	分组数据的相关性	MLVAE[75] 文献[77] GSL[78] 文献[81] 文献[82] 文献[83] 文献[85] 文献[86]	通过交换、共享潜在表征、限制互信息相关性、循环回归等方式，实现分组数据相关因子的解耦表征 . 后续可单独利用有效因子表征实现分类、分割、属性迁移数据集生成等任务。	适用于分组数据的相关有效属性挖掘。	MNIST[99]；RaFD[109]；Fonts[78]；CelebA[101]；Colored-MNIST[81]；dSprites[102]；MS-Celeb-1M[110]；CUB birds[111]；ShapeNet[112]；iLab-20M[113]；3D Shapes[81]；IAM[114]；PKUvehicle id[115]；Sentinel-2[116]；Norb[117]；BBC Pose dataset[118]；NTU[119]；KTH[120]；Deep fashion[121]；Cat head[122]；Human3.6M[123]；Penn action[124]；3D cars[125]
	基于对象的物理空间组合关系	MixNMatch[89]	结合数据组件化、层次化生成过程实现单目标场景的背景、姿态、纹理、形状解耦表征。	适用于单目标场景属性迁移的数据集生成。	CUB birds[111]；Stanford dogs[126]；Stanford cars[125]
		文献[83]	考虑单目标多部件间的组合关系。	适用于人类特定部位、面部表情转换等数据生成。	Cathead[122]；Human 3.6M[123]；Penn action[124]
		SCAE[92]	提出了胶囊网络的新思想，考虑多目标、多部件间的组合关联关系。	适用于简易数据集的目标、部件挖掘。	MNIST[99]；SVHN[100]；CIFAR10
		TAGGER[88] IODINE[95] MONET[96]	考虑多目标场景的逐次单目标解耦表征方式。	适用于简易多目标场景的目标自主解译任务。	Shapes[127]；TexturedMNIST[88]；CLEVR[128]；dSprites[102]；Tetris[95]；Objects room[96]
		文献[87]	引入目标空间逻辑树状图，解耦多目标复杂场景的遮掩关系，可用于去遮挡等任务。	适用于自然复杂场景下少量目标的去遮挡任务。	KINS[129]；COCOA[112]
		文献[98]	将目标三维本体特征视为目标内禀不变属性进行挖掘，解决视角、尺度大差异问题，有望实现检测、识别、智能问答等高级场景理解任务。	适用于简易数据集的高级场景理解。	CLEVR[128]

图 14　Factor-VAE[51]算法在 3D chairs[103]以及 3D faces[104]数据集上的解耦性能展示图．每一行代表仅有左侧标注的潜在表征取值发生改变时所对应的重构图像变化

图 15　AAE[48]算法对于 MNIST[99]和 SVHN[100]数字数据集中类别与风格属性的解耦表征结果展示图．图中每一行代表风格类潜在表征保持不变的情况下，改变类别类潜在表征取值所对应的重构图像变化；每一列代表类别类潜在表征保持不变的情况下，改变风格类潜在表征取值所对应的重构图像变化

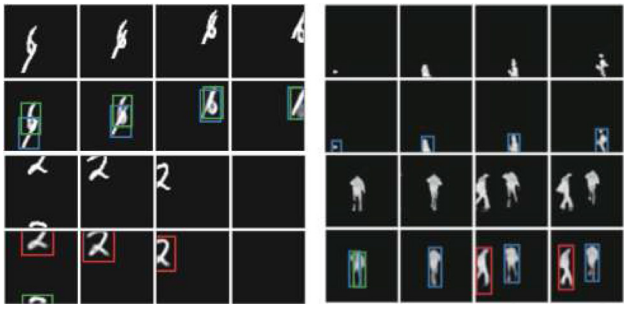

图 16　SQAIR[66]用于视频目标检测、跟踪实验结果图。其中不同颜色的标注框代表网络递归过程中所检测、跟踪到的不同目标

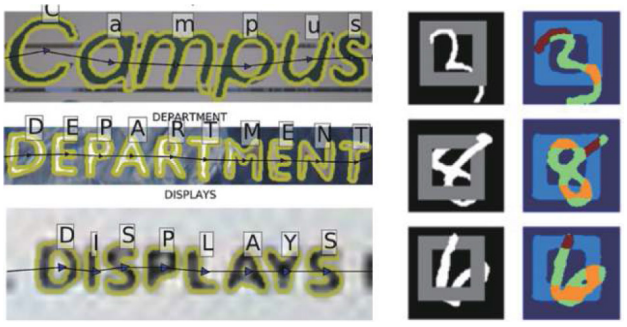

图 17　RCN[74]用于字符分割识别的实验结果展示图．其中左侧图像中黄色轮廓线为字符分割结果，右侧第一列为输入遮掩数字，第二列为网络预测的去遮掩掩码图

其次针对基于结构化模型先验归纳偏好的解耦表征学习算法而言，这类算法的独特之处在于模仿人类大脑的功能性区域构建可解释的网络架构。这类由网络架构引起的模型结构化归纳偏好能够在很大程度上调整网络学习的方式，其中顺序递归网络架构促使网络每做出一次决策的时候都会与之前学习的内容进行关联；深度梯形网络架构促使网络由浅入深地逐层挖掘数据特征；树形网络架构则会促使网络对高层高级特征进行横向语义关联。因此这类由人类大脑结构启发的网络架构设计形式不尽相同，所对应的人为任务偏好也千差万别。为了形象化展示这类算法在解耦表征以及下游任务中所展现的优秀性能，本节挑选出三类典型的模型架构代表算法 SQAIR[66]，RCN[74]，LTVAE[73]，验证解耦表征学习对于一些下游检测、识别、聚类等任务的有效性，如图 16~18 所示。

最后针对基于物理知识归纳偏好的解耦表征学习算法而言，该类算法更是将前两类算法与真实世界的物理知识相结合，进一步提高了解耦表征学习的科学性。本文将目前已有的相关类研究算法分为分组弱相关物理知识与对象空间组合关系物理知识两类，其中前者旨在利用弱监督组信息去挖掘组内数据相关性特征，这类算法的直观可视化验证主要通过属性迁移图像生成来验证相关性特征提取的好坏，对此本节以文献 GSL[78]为例，直观展示其在属性迁移图像生成中

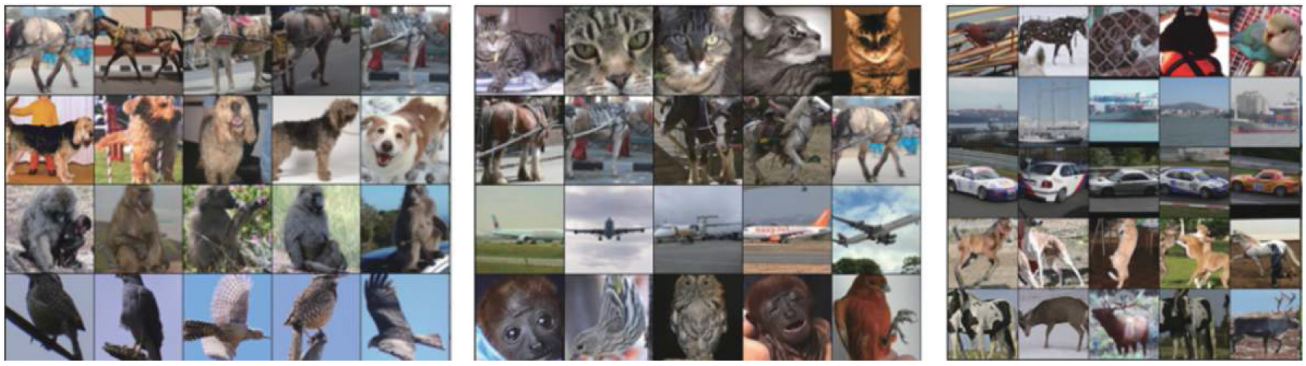

图 18　文献[73]所提算法的聚类实验结果图

图 19　GSL[78]算法所实现的图像属性迁移实验结果图

所展现出的实验性能，如图 19 所示。对于后者基于对象空间组合关系的物理知识运用而言，现有文献主要从多目标间的组合关联关系、目标内多部件间的组合关联关系两层面入手进行研究，因此本节以文献[83]为例展示目标部件间的解耦表征学习性能，如图 20 所示，以文献[87]与文献[98]为例展示多目标场景下目标关系的重组化以及需要高级语义理解

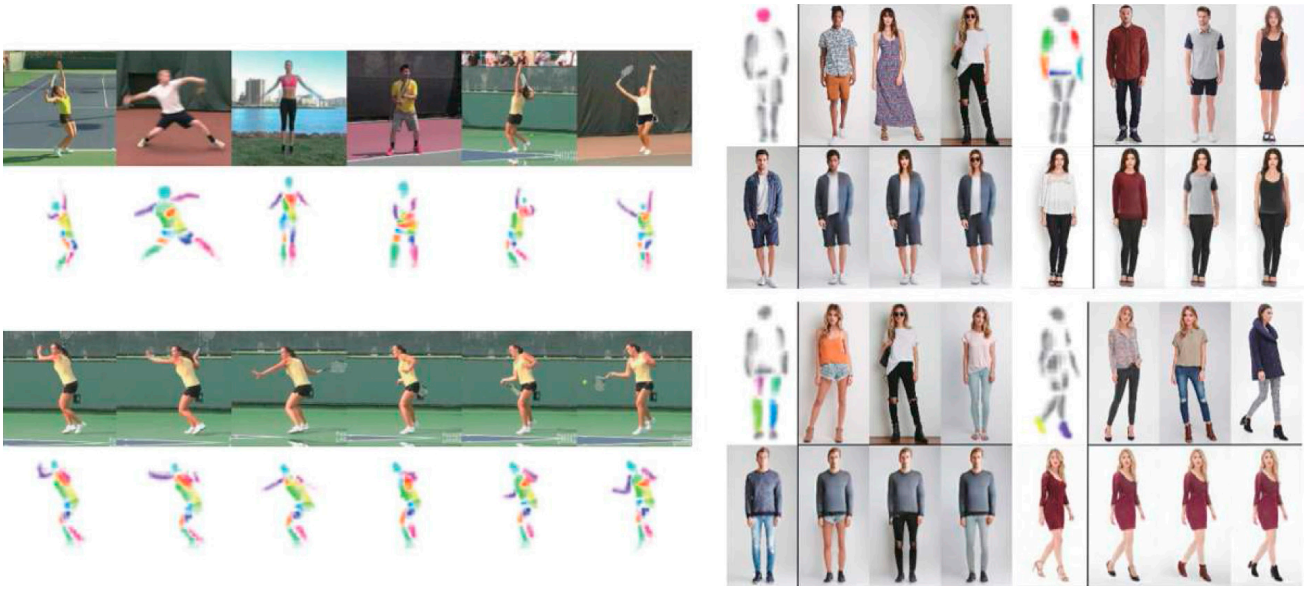

图 20　文献[83]所提算法在人类关节动作识别以及部分关节风格转换后生成图像的实验结果图

图 21　文献[87]所提算法在自然场景下按照人类偏好重组目标位置以及遮盖顺序后的实验结果图

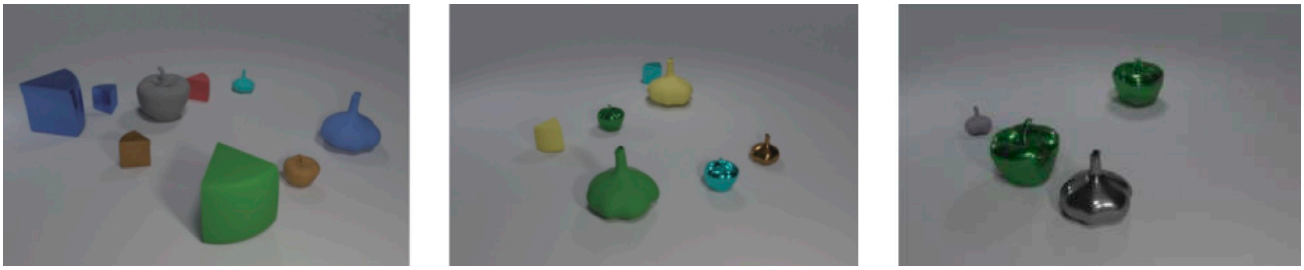

问：蓝色的亚光奶酪和在棕色金属奶酪前面的亚光奶酪大小一样吗？
答：不一样

问：图片中有多少奶酪？
答：2 个

问：图片中与小亚光物体形状相同的灰色物体是什么材质的？
答：金属

图 22　文献[98]所提方法应用在 CLEVR[128]数据集上的智能知识问答实验结果图

所支撑的智能问答任务性能，分别如图 21、22 所示。

6　研究重点和技术发展趋势

与人类相比，目前的深度学习网络大多仅对与特定任务相关的样本特征进行训练，而不考虑产生这些特征的内在物理属性，因此在面对之前未见过的纠缠图像特征时表现出较弱的概括性与泛化性。若深度网络能够学习到可概括的公共属性，即带有实际物理语义属性的解耦表征学习，将能够帮助神经网络想象各类具有不同属性的物体，将已知耦合的图像特征转换为新的耦合图像特征，例如，可以对红船和蓝车的图像进行分解和重组，合成新的红车图像等，这将更有利于深度学习对数据内在本身物理特性进行挖掘，增强对各类下游任务的迁移性与鲁棒性。解耦表征的目的便是挖掘数据中潜在的相互作用因子，并赋予其相互分离的数据表征，属于可解释性的深度表征学习范畴，能够很大程度上提高深度学习的可解释性，增强其内在逻辑性，在当今深度学习盛行的时代具有广阔的研究前景。本文将目前有关解耦表征学习的研究大致概括为三类：

1）基于非结构化表征先验的解耦表征学习，如 β-VAE，

InfoGAN，FactorVAE 等。通过将潜在变量的先验分布的独立性约束传递给后验分布，促使模型学习可分离的潜在变量表示，从而达到解耦表征的效果。然而该类方法并未考虑真实世界的复杂语义信息，赋予潜在变量明确的物理含义，导致其只能应用于手写数字体 MNIST 数据集、人脸 CelebA 数据集等简单数据集的解耦表征。

2）基于结构化模型先验归纳偏好的解耦表征学习。该类模型架构归纳偏差的设计主要基于类脑的思想构建深度层次化结构表征，各个不同深度的层次代表不同语义信息，如深度梯形网络、深度递归网络、树形网络等。这类结构化归纳偏好的设计旨在挖掘自底向上、逐层递进的数据表征，能够处理复杂场景大规模数据集以及数据流信息的解耦表征。然而这类架构若仅仅模拟人脑结构，并未赋予其更强的逻辑语义约束，便不能真正达到符合人类理解的解耦表征学习。

3）基于物理知识归纳偏好的解耦表征学习。该类解耦表征学习旨在将强先验物理语义信息与逻辑关系加入模型设计中，如多输入数据间的物理关联性、部件 – 个体间的逻辑拓扑关系，个体 – 整体间的空间物理关系等，能够同时融入上述两类归纳偏好的设计构成最终的解耦表征模型，完成数据内部语义空间的挖掘，能够处理复杂自然场景的数据。

本文对目前的解耦表征学习研究进行归纳总结后，认为该研究领域依旧面临着许多严峻的挑战，具有着广泛的研究前景。以下是对该领域技术发展趋势的展望：

1）建立世界的因果模型，以支持解释和理解，而不只是解决模式识别问题；

2）物理和心理学的直观理论基础学习，以支持和丰富所学习的知识；

3）利用组合能力学习快速获取知识，并将知识推广到新的任务和情况；

4）提出能够量化由不同模型实现的解耦程度非常重要。但是，为此设计度量标准并不容易。除了主观解释之外，尽管有大量学者提出各种指标，如分离属性可预测性[49]、互信息差异[52]、FactorVAE 度量[51]、β-VAE 度量[46]、解耦性 / 完整性 / 信息性（Disentanglement/Completeness/Informativeness，DCI）度量[130]、属性依赖关系（Attributedependency，AD）度量[131]等，但目前还没有就定量衡量解耦性能的最佳标准达成共识，这些指标中是否有任何一个能像人们通常想象的那样衡量解耦程度尚不清楚。

在当今深度学习快速发展的背景下，泛化性与可解释性成为制约其进一步突破的关键问题，受到社会各界的广泛关注。解耦表征学习旨在挖掘数据内部潜在生成因子，并利用可分离的潜在表示分别对其进行表征控制，对数据进行深入理解，揭示数据内部的生成作用机理，逐渐成为提高深度学习泛化性、可扩展性与可解释性的重要手段。本文对当前解耦表征学习研究进行了归纳总结，该研究作为一门快速发展的开放性学科领域，在内涵外延、模型理论、技术方法及实施策略方面还需要大量学者继续投入更多的研究与实践。

来源：《自动化学报》

作者简介

文载道　西北工业大学自动化学院副教授 . 主要研究方向为压缩感知与稀疏模型，认知机器学习，合成孔径雷达图像解译，多源自主目标识别 .
E-mail:wenzaidao@nwpu.edu.cn
(WEN Zai-Dao　Associate profess-or at the School of Automation, Northwestern Polytechnical University. His researchinterest covers compressed sensing and sparse model, cognitive machine learning, synthetic aperture radarimage interpretation, and multisource automatic target recognition.)

王佳蕊　西北工业大学自动化学院博士研究生 . 主要研究方向为解耦表征学习，SAR 图像处理，因果推理 .
E-mail: wangjiarui_wyy163@163.com
(WANG Jia-Rui　Ph. D. candidateat the School of Aut omation, Northwestern Polytechnical University. Her research interest covers disentangled representation learning, SAR image processing and causal reasoning.)

王小旭　西北工业大学自动化学院教授 . 主要研究方向为惯性器件与惯性导航，合成孔径雷达图像解译，协同感知 . 本文通信作者 .
E-mail: woyaofly1982@163.com
(WANG Xiao-Xu　Professor at the School of Automation, Northwestern Polytechnical University. His research interest covers inertial devices and inertial navigation, synthetic aperture radar image interpretation, cooperative sensing.Corresponding author of this paper.)

潘　泉　西北工业大学自动化学院教授 . 主要研究方向为信息融合理论及应用，目标跟踪与识别技术，光谱成像及图像处理 .
E-mail: quanpan@nwpu.edu.cn
(PAN Quan Professor at the School of Automation, Northwestern Polytechnical University. His research interest coversinformation fusion theory and application, targettracking and recognition technology, spectral imagingand image processing.)

编者按

近年来，随着人脸识别技术的规模化普及应用，从安防、支付、金融到教育、医疗和交通，“刷脸”日渐成为大众生活与工作的日常，为人们的生产与生活带来了诸多智能、安全与便捷。本期“科普园地”栏目，为大家分享的是““魔镜”靠什么辨识每一张脸”和“人脸识别技术全面总结：从传统方法到深度学习”两篇文章。

“魔镜”靠什么辨识每一张脸

文 / 戴凤智

“白雪公主”的童话故事可谓家喻户晓。故事书、动画片、电影、歌舞剧等各种形式的文艺作品都曾将这一经典童话故事展现在大众面前。故事中嫉妒心极强的王后，每天都要做的事情，就是询问她的“魔镜”：“谁是世界上最美丽的女人”。“魔镜”几十年如一日的回答让她的虚荣心得到了极大的满足，也成为她唯一想要听到的答案。随着白雪公主一天天长大，王后的极度自信终于被打破，“魔镜”竟然说出了一个不一样的答案：“白雪公主是世界上最美丽的女人”，由此展开了后面的曲折故事。

童话故事中的神奇和温馨也不全是杜撰，随着现代科技的发展，想要拥有给人脸审美打分判断的“魔镜”也不再是天方夜谭。而我们是不是会产生这样的疑问：现代技术中的“魔镜”到底是如何判断谁才是“世界上最美丽的人”呢？

为了给出正确答案，“魔镜”需要提前完成如下工作：当一个人站在“魔镜”面前时，摄像头会自动提取面部特征，如脸型、五官位置等；“魔镜”还需要知道什么是当下审美中“美丽”的标准，也就是通过哪些面部特征才能判断出美丽与否，如鼻梁高低、眼睛大小等；最重要的是，“魔镜”需要具有自主学习与思考判断的能力。这些就涉及到了近年的科技热点——人脸识别技术，它是基于人的面部特征信息进行身份识别的一种生物识别技术。不同于童话故事中的天方夜谭，现实生活中的人脸识别技术已经得到了长足发展，也是人工智能的具体应用之一。

那么，搭载了人脸识别技术的真实“魔镜”是怎样学习的？都能学到什么？能从学习中自动总结出什么知识和归纳出什么特征？又是如何利用这些知识与特征去判断“谁是世界上最美丽的人”呢？

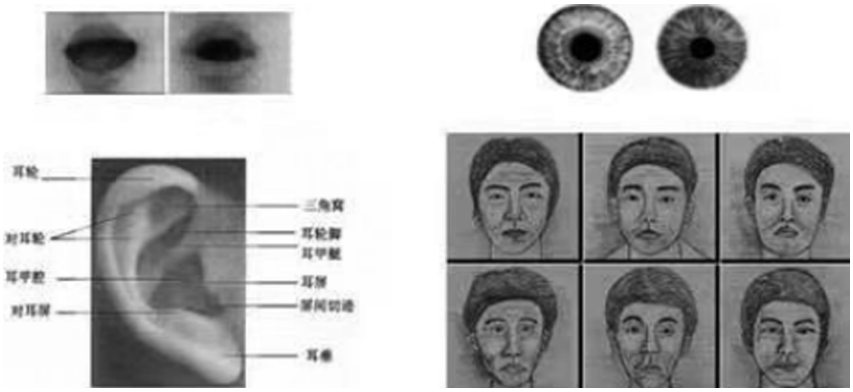

嘴型、眼中的虹膜样式、耳的特征和不同的人脸

人有眉、眼、鼻、口、耳五官，而每个人的嘴型、眼睛和虹膜的样式、耳朵的轮廓等均不尽相同，五官在面部的布局以及头部形状也各不相同。“魔镜”必须通过人脸图像的采集与预处理、人脸检测、人脸特征提取和人脸识别这五个步骤才能够给出正确的答案。这些分析处理过程需要依靠计算机视觉和机器学习技术来处理，并得出最终结果。

计算机视觉和机器学习技术，可以让计算机通过不断地观察图像来记忆各种事物。我们知道，人们即使面对模糊的甚至有一部分被遮挡的照片，也能够迅速判断出被遮挡的物体是什么。这是我们能够从过去的经验和现况中获取知识的能力，把这种能力赋予计算机就是机器的学习能力。而深度学习则是一种更先进的人工智能技术，它能够进一步将大脑的判断能力附着在计算机上。通过深度学习，计算机既可以进行识别，更可以进行预测。例如，我们把自己不同年龄段的照片输入到计算机，它就能够根据一些智能算法“预测”出你今后某时的外貌变化。

随着该技术的不断成熟，人脸识别技术在公共安全、信息安全、政府职能等领域上的应用越来越广泛，而且具有非侵扰、便捷、友好、非接触和可扩展性。人脸识别技术与人工智能算法、3D 建模与识别技术、大数据信息的结合，也将是未来发展的趋势。

当然，随着人脸识别技术的发展和应用领域的更大拓展，随之带来的信息与个人隐私泄露也引发越来越多的社会问题。历史的车轮不停转动，层出不穷的新技术、新成果的应用势必是一把双刃剑，我们在享受科技发展的红利时，更需要通过完善立法并严格执法来进行保护，才能真正造福人类。

来源:《科普时报》第 171 期第 2 版

戴凤智简介

戴凤智，本科和硕士毕业于北京理工大学自动控制系，博士毕业于日本国立大分大学。2003 年 4 月至 2009 年 3 月任教于日本国立松江工业高等专门学校电子控制系。2009 年 11 月至今，在天津科技大学电子信息与自动化学院任教。现为中国自动化学会普及工作委员会委员、天津市机器人学会理事。工作、研究领域包括自动化、人工智能、智能制造和机器人的开发。获得“中国商业联合会科学技术奖”一等奖，“天津市科学技术进步奖”二等奖，中国轻工业联合会科学技术奖”优秀奖。主编的《机器人制作轻松入门》一书获得 2017 年“中国轻工业优秀教材”二等奖，2018 年主持教改项目获得“高等教育天津市级教学成果”二等奖，译著《漫画机器学习入门》获得 2020 年“信息通信科普教育精品图书”。2018 年作为专业负责人申报机器人工程新专业并获得教育部批准（于 2019 年开始招生），以第二负责人身份获得 2019 年天津市级教学团队（智能控制与机器人设计核心课程群教学团队）。

从 2010 年开始开展科普工作，指导并带领学生团队参加各种人工智能与机器人专业竞赛和各项科普宣传活动，包括在中小学宣传科学知识并开展科学实验、在多所院校进行人工智能与机器人领域宣讲、通过各种媒体进行科普讲座（央视新闻直播间节目和天津卫视均有报道）、从 2014 年开始以平均每年一本的速度出版人工智能与机器人相关的科普图书、与天津市和平区劝业场街宁夏路社区建立长期交流合作关系为居民进行垃圾分类知识的宣讲等。

现为中国自动化学会“智向未来”自动化与人工智能科普百人团专家和“十三五”期间天津市全民科学素质工作先进个人。

人脸识别技术全面总结：从传统方法到深度学习

文 /Daniel Saez Trigueros 等

自七十年代以来，人脸识别已经成为了计算机视觉和生物识别领域被研究最多的主题之一。基于人工设计的特征和传统机器学习技术的传统方法近来已被使用非常大型的数据集训练的深度神经网络取代。在这篇论文中，我们对流行的人脸识别方法进行了全面且最新的文献总结，其中既包括传统方法（基于几何的方法、整体方法、基于特征的方法和混合方法），也有深度学习方法。

1. 引言

人脸识别是指能够识别或验证图像或视频中的主体的身份的技术。首个人脸识别算法诞生于七十年代初 [1，2]。自那以后，它们的准确度已经大幅提升，现在相比于指纹或虹膜识别 [3] 等传统上被认为更加稳健的生物识别方法，人们往往更偏爱人脸识别。让人脸识别比其它生物识别方法更受欢迎的一大不同之处是人脸识别本质上是非侵入性的。比如，指纹识别需要用户将手指按在传感器上，虹膜识别需要用户与相机靠得很近，语音识别则需要用户大声说话。相对而言，现代人脸识别系统仅需要用户处于相机的视野内（假设他们与相机的距离也合理）。这使得人脸识别成为了对用户最友好的生物识别方法。这也意味着人脸识别的潜在应用范围更广，因为它也可被部署在用户不期望与系统合作的环境中，比如监控系统中。人脸识别的其它常见应用还包括访问控制、欺诈检测、身份认证和社交媒体。

当被部署在无约束条件的环境中时，由于人脸图像在现实世界中的呈现具有高度的可变性（这类人脸图像通常被称为自然人

（a）（b）（c）（d）（e）

图 1　在自然人脸图像中找到的典型变化。（a）头部姿势，（b）年龄，（c）光照，（d）面部表情，（e）遮挡。

图 2　人脸识别的构建模块

脸（faces in-the-wild）），所以人脸识别也是最有挑战性的生物识别方法之一。人脸图像可变的地方包括头部姿势、年龄、遮挡、光照条件和人脸表情。图 1 给出了这些情况的示例。

人脸识别技术这些年已经发生了重大的变化。传统方法依赖于人工设计的特征（比如边和纹理描述量）与机器学习技术（比如主成分分析、线性判别分析或支持向量机）的组合。人工设计在无约束环境中对不同变化情况稳健的特征是很困难的，这使得过去的研究者侧重研究针对每种变化类型的专用方法，比如能应对不同年龄的方法［4，5］、能应对不同姿势的方法［6］、能应对不同光照条件的方法［7，8］等。近段时间，传统的人脸识别方法已经被基于卷积神经网络（CNN）的深度学习方法接替。深度学习方法的主要优势是它们可用非常大型的数据集进行训练，从而学习到表征这些数据的最佳特征。网络上可用的大量自然人脸图像已让研究者可收集到大规模的人脸数据集［9-15］，这些图像包含了真实世界中的各种变化情况。使用这些数据集训练的基于 CNN 的人脸识别方法已经实现了非常高的准确度，因为它们能够学到人脸图像中稳健的特征，从而能够应对在训练过程中使用的人脸图像所呈现出的真实世界变化情况。此外，深度学习方法在计算机视觉方面的不断普及也在加速人脸识别研究的发展，因为 CNN 也正被用于解决许多其它计算机视觉任务，比如目标检测和识别、分割、光学字符识别、面部表情分析、年龄估计等。

人脸识别系统通常由以下构建模块组成：

- 人脸检测。人脸检测器用于寻找图像中人脸的位置，如果有人脸，就返回包含每张人脸的边界框的坐标。如图 3a 所示。
- 人脸对齐。人脸对齐的目标是使用一组位于图像中固定位置的参考点来缩放和裁剪人脸图像。这个过程通常需要使用一个特征点检测器来寻找一组人脸特征点，在简单的 2D 对齐情况中，即为寻找最适合参考点的最佳仿射变换。图 3b 和 3c 展示了两张使用了同一组参考点对齐后的人脸图像。更复杂的 3D 对齐算法（如［16］）还能实现人脸正面化，即将人脸的姿势调整到正面向前。
- 人脸表征。在人脸表征阶段，人脸图像的像素值会被转换成紧凑且可判别的特征向量，这也被称为模板（template）。理想情况下，同一个主体的所有人脸都应该映射到相似的特征向量。
- 人脸匹配。在人脸匹配构建模块中，两个模板会进行比较，从而得到一个相似度分数，该分数给出了两者属于同一个主体的可能性。

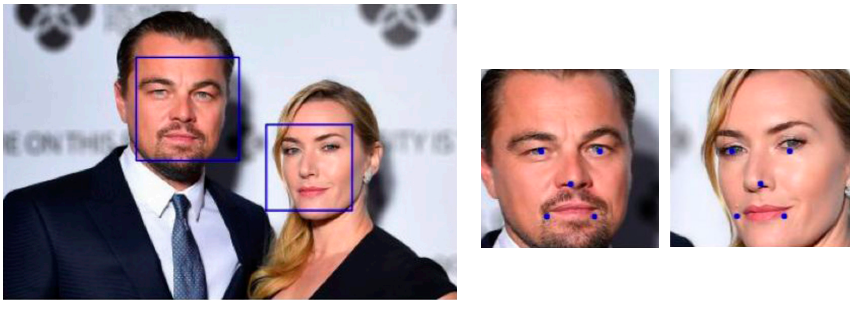

（a）　（b）　（c）

图 3　（a）人脸检测器找到的边界框。（b）和（c）：对齐后的人脸和参考点。

很多人认为人脸表征是人脸识别系统中最重要的组件，这也是本论文第二节所关注的重点。

2. 深度学习方法

卷积神经网络（CNN）是人脸识别方面最常用的一类深度学习方法。深度学习方法的主要优势是可用大量数据来训练，从而学到对训练数据中出现的变化情况稳健的人脸表征。这种方法不需要设计对不同类型的类内差异（比如光照、姿势、面部表情、年龄等）稳健的特定特征，而是可以从训练数据中学到它们。深度学习方法的主要短板是它们需要使用非常大的数据集来训练，而且这些数据集中需要包含足够的变化，从而可以泛化到未曾见过的样本上。幸运的是，一些包含自然人脸图像的大规模人脸数据集已被公开[9-15]，可被用来训练 CNN 模型。除了学习判别特征，神经网络还可以降维，并可被训练成分类器或使用度量学习方法。CNN 被认为是端到端可训练的系统，无需与任何其它特定方法结合。

用于人脸识别的 CNN 模型可以使用不同的方法来训练。其中之一是将该问题当作是一个分类问题，训练集中的每个主体都对应一个类别。训练完之后，可以通过去除分类层并将之前层的特征用作人脸表征而将该模型用于识别不存在于训练集中的主体[99]。在深度学习文献中，这些特征通常被称为瓶颈特征（bottleneck features）。 在这第一个训练阶段之后，该模型可以使用其它技术来进一步训练，以为目标应用优化瓶颈特征（比如使用联合贝叶斯[9]或使用一个不同的损失函数来微调该 CNN 模型[10]）。另一种学习人脸表征的常用方法是通过优化配对的人脸[100，101]或人脸三元组[102]之间的距离度量来直接学习瓶颈特征。

使用神经网络来做人脸识别并不是什么新思想。1997 年就有研究者为人脸检测、眼部定位和人脸识别提出了一种名为「基于概率决策的神经网络（PBDNN）」[103]的早期方法。这种人脸识别 PDBNN 被分成了每一个训练主体一个全连接子网络，以降低隐藏单元的数量和避免过拟合。研究者使用密度和边特征分别训练了两个 PBDNN，然后将它们的输出组合起来得到最终分类决定。另一种早期方法[104]则组合使用了自组织映射（SOM）和卷积神经网络。自组织映射[105]是一类以无监督方式训练的神经网络，可将输入数据映射到更低维的空间，同时也能保留输入空间的拓扑性质（即在原始空间中相近的输入在输出空间中也相近）。注意，这两种早期方法都不是以端到端的方式训练的（[103]中使用了边特征，[104]中使用了 SOM），而且提出的神经网络架构也都很浅。[100]中提出了一种端到端的人脸识别 CNN。这种方法使用了一种孪生式架构，并使用了一个对比损失函数[106]来进行训练。这个对比损失使用了一种度量学习流程，其目标是最小化对应同一主体的特征向量对之间的距离，同时最大化对应不同主体的特征向量对之间的距离。该方法中使用的 CNN 架构也很浅，且训练数据集也较小。

上面提到的方法都未能取得突破性的成果，主要原因是使用了能力不足的网络，且训练时能用的数据集也相对较小。直到这些模型得到扩展并使用大量数据[107]训练后，用于人脸识别的首个深度学习方法[99，9]才达到了当前最佳水平。尤其值得一提的是 Facebook 的 DeepFace[99]，这是最早的用于人脸识别的 CNN 方法之一，其使用了一个能力很强的模型，在 LFW 基准上实现了 97.35% 的准确度，将之前最佳表现的错误率降低了 27%。研究者使用 softmax 损失和一个包含 440 万张人脸（来自 4030 个主体）的数据集训练了一个 CNN。本论文有两个全新的贡献：（1）一个基于明确的 3D 人脸建模的高效的人脸对齐系统；（2）一个包含局部连接的层的 CNN 架构

[108，109]，这些层不同于常规的卷积层，可以从图像中的每个区域学到不同的特征。在那同时，DeepID 系统 [9] 通过在图块（patch）上训练 60 个不同的 CNN 而得到了相近的结果，这些图块包含十个区域、三种比例以及RGB或灰度通道。在测试阶段，会从每个图块提取出 160 个瓶颈特征，加上其水平翻转后的情况，可形成一个 19200 维的特征向量（160×2×60）。类似于 [99]，新提出的 CNN 架构也使用了局部连接的层。其验证结果是通过在这种由 CNN 提取出的 19200 维特征向量上训练一个联合贝叶斯分类器 [48] 得到的。训练该系统所使用的数据集包含 202599 张人脸图像，来自 10177 位名人 [9]。

对于基于 CNN 的人脸识别方法，影响准确度的因素主要有三个：训练数据、CNN 架构和损失函数。因为在大多数深度学习应用中，都需要大训练集来防止过拟合。一般而言，为分类任务训练的 CNN 的准确度会随每类的样本数量的增长而提升。这是因为当类内差异更多时，CNN 模型能够学习到更稳健的特征。但是，对于人脸识别，我们感兴趣的是提取出能够泛化到训练集中未曾出现过的主体上的特征。因此，用于人脸识别的数据集还需要包含大量主体，这样模型也能学习到更多类间差异。[110] 研究了数据集中主体的数量对人脸识别准确度的影响。在这项研究中，首先以降序形式按照每个主体的图像数量对一个大数据集进行了排序。然后，研究者通过逐渐增大主体数量而使用训练数据的不同子集训练了一个 CNN。当使用了图像数量最多的 10000 个主体进行训练时，得到的准确度是最高的。增加更多主体会降低准确度，因为每个额外主体可用的图像非常少。另一项研究 [111] 研究了更宽度的数据集更好，还是更深度的数据集更好（如果一个数据集包含更多主体，则认为它更宽；类似地，如果每个主体包含的图像更多，则认为它更深）。这项研究总结到：如果图像数量相等，则更宽的数据集能得到更好的准确度。研究者认为这是因为更宽度的数据集包含更多类间差异，因而能更好地泛化到未曾见过的主体上。表 1 展示了某些最常用于训练人脸识别 CNN 的公开数据集。

用于人脸识别的 CNN 架构从那些在 ImageNet 大规模视觉识别挑战赛（ILSVRC）上表现优异的架构上取得了很多灵感。举个例子，[11] 中使用了一个带有 16 层的 VGG 网络 [112] 版本，[10] 中则使用了一个相似但更小的网络。[102] 中探索了两种不同类型的 CNN 架构：VGG 风格的网络 [112] 和 GoogleNet 风格的网络 [113]。即使这两种网络实现了相当的准确度，但

表 1　公开的大规模人脸数据集

Dataset	Images	Subjects	Images per subject
CelebFaces+ [9]	202,599	10,177	19.9
UMDFaces [14]	367,920	8,501	43.3
CASIA-WebFace [10]	494,414	10,575	46.8
VGGFace [11]	2.6M	2,622	1,000
vGGFace2 [15]	3.31M	9,131	362.6
MegaFace [13]	4.7M	672,057	7
MS-Celeb-1M [12]	10M	100,000	100

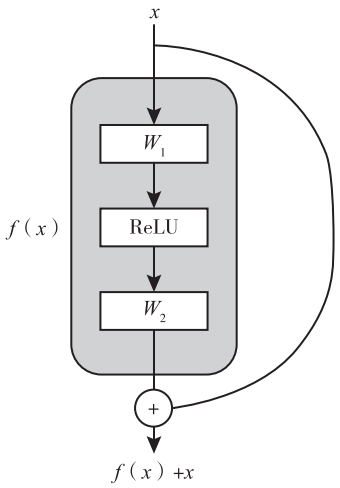

图 4 ［114］中提出的原始的残差模块

GoogleNet 风格的网络的参数数量少 20 倍。更近段时间，残差网络（ResNet）[114] 已经成为了很多目标识别任务的最受偏爱的选择，其中包括人脸识别 [115−121]。ResNet 的主要创新点是引入了一种使用捷径连接的构建模块来学习残差映射，如图 7 所示。捷径连接的使用能让研究者训练更深度的架构，因为它们有助于跨层的信息流动。[121] 对不同的 CNN 架构进行了全面的研究。在准确度、速度和模型大小之间的最佳权衡是使用带有一个残差模块（类似于 [122] 中提出的那种）的 100 层 ResNet 得到的。

选择用于训练 CNN 方法的损失函数已经成为近来人脸识别最活跃的研究领域。即使使用 softmax 损失训练的 CNN 已经非常成功 [99，9，10，123]，但也有研究者认为使用这种损失函数无法很好地泛化到训练集中未出现过的主体上。这是因为 softmax 损失有助于学习能增大类间差异的特征（以便在训练集中区别不同的类），但不一定会降低类内差异。研究者已经提出了一些能缓解这一问题的方法。优化瓶颈特征的一种简单方法是使用判别式子空间方法，比如联合贝叶斯 [48]，就像 [9，124，125，126，10，127] 中所做的那样。另一种方法是使用度量学习。比如，[100，101] 中使用了配对的对比损失来作为唯一的监督信号，[124−126] 中还结合使用了分类损失。人脸识别方面最常用的度量学习方法是三元组损失函数 [128]，最早在 [102] 中被用于人脸识别任务。三元组损失的目标是以一定余量分开正例对之间的距离和负例对之间的距离。从数学形式上讲，对于每个三元组 i，需要满足以下条件 [102]：

$$\| f(x_a)-f(x_p) \|_2^2+\alpha<\| f(x_a)-f(x_n) \|_2^2$$

其中 x_a 是锚图像，x_p 是同一主体的图像，x_n 是另一个不同主体的图像，f 是模型学习到的映射关系，α 施加在正例对和负例对距离之间的余量。在实践中，使用三元组损失训练的 CNN 的收敛速度比使用 softmax 的慢，这是因为需要大量三元组（或对比损失中的配对）才能覆盖整个训练集。尽管这个问题可以通过在训练阶段选择困难的三元组（即违反余量条件的三元组）来缓解 [102]，但常见的做法是在第一个训练阶段使用 softmax 损失训练，在第二个训练阶段使用三元组损失来对瓶颈特征进行调整 [11，129，130]。研究者们已经提出了三元组损失的一些变体。比如 [129] 中使用了点积作为相似度度量，而不是欧几里德距离；[130] 中提出了一种概率式三元组损失；[131，132] 中提出了一种修改版的三元组损失，它也能最小化正例和负例分数分布的标准差。用于学习判别特征的另一种损失函数是 [133] 中提出的中心损失（centre loss）。中心损失的目标是最小化瓶颈特征与它们对应类别的中心之间的距离。通过使用 softmax 损失和中心损失进行联合训练，结果表明 CNN 学习到的特征能够有效增大类间差异（softmax 损失）和降低类内个体差异（中心损失）。相比于对比损失和三元组损失，中心损失的优点是更高效和更容易实现，因为它不需要在训练过程中构建配对或三元组。另一种相关的度量学习方法是 [134] 中提出的范围损失（range loss），这是为改善使用不平衡数据集的训练而提出的。范围损失有两个组件。类内的损失组件是最小化同一类样本之间的 k− 最大距离，

表 2　有余量的 softmax 损失的不同变体的决策边界。注意这些决策边界针对的是二元分类案例中的类别 1

Type of softmax margin	Decision boundary
Multiplicative angular margin [116]	$\|x\|\ (\cos m\theta_1 - \cos\theta_2) = 0$
Additive cosine margin [119], [120]	$s\ (\cos\theta_1 - m - \cos\theta_2) = 0$
Additive angular margin [121]	$s\ (\cos\ (\theta_1 + m) - \cos\theta_2) = 0$

而类间的损失组件是最大化每个训练批中最近的两个类中心之间的距离。通过使用这些极端案例，范围损失为每个类都使用同样的信息，而不管每个类别中有多少样本可用。类似于中心损失，范围损失需要与 softmax 损失结合起来以避免损失降至零 [133]。

当结合不同的损失函数时，会出现一个困难，即寻找每一项之间的正确平衡。最近一段时间，已有研究者提出了几种修改 softmax 损失的方法，这样它无需与其它损失结合也能学习判别特征。一种已被证明可以增加瓶颈特征的判别能力的方法是特征归一化 [115，118]。比如，[115] 提出归一化特征以具有单位 L2 范数，[118] 提出归一化特征以具有零均值和单位方差。一个成功的方法已经在 softmax 损失中每类之间的决策边界中引入了一个余量 [135]。为了简单，我们介绍一下使用 softmax 损失进行二元分类的情况。在这种情况下，每类之间的决策边界（如果偏置为零）可由下式给定：

$$\|x\|\ (\|\boldsymbol{W}_1\|\cos\theta_1 - \|\boldsymbol{W}_2\|\cos\theta_2) = 0$$

其中 x 是特征向量，$\boldsymbol{W}_1$ 和 $\boldsymbol{W}_2$ 是对应每类的权重，θ_1 和 θ_2 是 x 分别与 $\boldsymbol{W}_1$ 和 $\boldsymbol{W}_2$ 之间的角度。通过在上式中引入一个乘法余量，这两个决策边界可以变得更加严格：

$$\|x\|\ (\|\boldsymbol{W}_1\|\cos m\theta_1 - \|\boldsymbol{W}_2\|\cos\theta_2) = 0 \text{ for class 1}$$

$$\|x\|\ (\|\boldsymbol{W}_1\|\cos\theta_1 - \|\boldsymbol{W}_2\|\cos m\theta_2) = 0 \text{ for class 2}$$

如图 8 所示，这个余量可以有效地增大类别之间的区分程度以及各自类别之内的紧凑性。根据将该余量整合进损失的方式，研究者们已经提出了多种可用方法 [116，119–121]。比如 [116] 中对权重向量进行了归一化以具有单位范数，这样使得决策边界仅取决于角度 θ_1 和 θ_2。[119，120] 中则提出了一种加性余弦余量。相比于乘法余量 [135，116]，加性余量更容易实现和优化。在这项工作中，除了归一化权重向量，特征向量也如 [115] 中一样进行了归一化和比例调整。[121] 中提出了另一种加性余量，它既有 [119，120] 那样的优点，还有更好的几何解释方式，因为这个余量是加在角度上的，而不是余弦上。表 2 总结了有余量的 softmax 损失的不同变体的决策边界。这些方法是人脸识别领域的当前最佳。

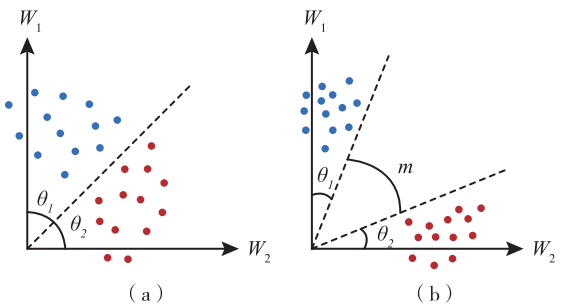

图 5　在两个类别之间的决策边界中引入一个余量 m 的效果。（a）softmax 损失，（b）有余量的 softmax 损失。

来源：机器之心

第七期 CAA 会士面对面活动成功召开

图 1　鲁仁全教授作题为“变结构无人自主系统控制理论与应用”的报告

CAA 会士面对面系列活动是中国自动化学会为学会会士量身打造的高端学术交流平台，每期活动邀请 1 位或数位学会会士进行专题报告，围绕国际科技热点，聚焦国家创新发展战略需求，前瞻学科领域发展新方向，积极发挥学术引领和科技智库作用，展现重大学术咨询研究成果，引导社会尊崇科学思想和方法，促进公众提升科学意识和素养。

第七期会士面对面讲座于 2022 年 9 月 16 日上午成功召开，中国自动化学会会士、监事，广东工业大学科研管理部部长鲁仁全教授作题为“变结构无人自主系统控制理论与应用”的报告。

无人自主载体在面对水、陆、空跨域切换时，需要面对环境与机构突变、网络拓扑剧变等复杂场景带来的姿态切换难，减振控制难，协同控制难等难题。鲁仁全教授在报告中重点围绕变结构的无人自主系统控制理论的背景、意义及关键技术问题进行了全面的介绍，同时展示了团队的多项代表性科研成果。

本次活动由 CAA 青年人才托举工程项目入选者、鹏城实验室助理研究员李轩主持，通过腾讯会议、CAA 会议小程序、CAA 官方视频号、bilibili 官方账号、学会微博官方账号、百家号及科技工作者之家全程直播，共计近 4 万人次在线观看直播。

学会秘书处　供稿

图 2　中国自动化学会会士、监事
广东工业大学科研管理部部长鲁仁全教授

图 3　CAA 青年人才托举工程项目入选者、
鹏城实验室助理研究员李轩

第十期 CAA 科普大讲堂活动成功召开

CAA 科普大讲堂活动是中国自动化学会特面向学生会员、广大科技工作者及社会公众推出科普活动，每期活动邀请 1 位或数位教授进行专题报告，充分利用全媒体矩阵，开展自动化领域科技知识普及，弘扬科学精神，增进全国高校自动化相关领域学生及社会大众对科技创新知识的了解，开拓眼界，激发对科学的热情和兴趣，提高科学素养，积极打造学会学术、科普比翼齐飞新格局。

第十期 CAA 科普大讲堂于 2022 年 9 月 20 日上午成功召开，华中科技大学教授、图像信息处理与智能控制教育部重点实验室副主任伍冬睿作题为“脑机接口：原理与应用”的报告。伍冬睿教授在报告中简要介绍了非侵入式 BCI、半侵入式 BCI、侵入式 BCI 的三种脑机接口方式及“一体两翼”的中国脑计划。他指出，脑机接口是大脑和外部设备的直接交互通道，能够研究、测绘、帮助、增强或修复人体认知或感觉运动功能。目前，国内在非侵入式脑机接口算法等方面处于国际领先地位，在半侵入式和侵入式的的脑机接口研究方面未来仍有无限可能。

本次活动由 CAA 普及工作委员会秘书长、中国科学院自动化研究所高级工程师宫晓燕主持，通过腾讯会议、CAA 会议小程序、CAA 官方视频号、bilibili 官方账号、知乎账号、学会微博官方账号及科技工作者之家全程直播，约 4.5 万人次在线观看直播。

伍冬睿，华中科技大学人工智能与自动化学院教授、博导，图像信息处理与智能控制教育部重点实验室副主任，国家海外青

图 1　华中科技大学教授、图像信息处理与智能控制教育部重点实验室副主任伍冬睿作题为“脑机接口：原理与应用”的报告

图 2　脑机接口：原理与应用

年高层次人才。主要研究方向为脑机接口、机器学习、智慧医疗等。发表论文200余篇，其中SCI 95篇（一作35篇，IEEE汇刊65篇），ESI高引9篇，谷歌学术总引用9900余次（H=51），爱思唯尔中国高被引学者。授权国际专利5项，中国发明专利13项，转让4项。两个一作算法进入Matlab Fuzzy Logic Toolbox。获4个青年科学奖（2021中国自动化学会青年科学家奖，2020 USERN Prize in Formal Sciences，2017 IEEE系统、人和控制论学会首届青年科学家奖，2014北美模糊信息处理学会首届青年科学家奖），6个杰出论文奖（2021 IEEE神经系统与康复工程汇刊最佳论文奖，2020 IEEE机电一体化与自动化会议最佳论文奖，2014 IEEE模糊系统汇刊杰出论文奖，2012 IEEE计算智能学会杰出博士论文奖，等），2019-2022连续四年世界机器人大赛--BCI脑控机器人大赛技术赛全国一等奖或特等奖，2022湖北青年五四奖章，等。现任IEEE SMC学会助理副主席、管理委员会委员和eNewsLetter主编，及3个IEEE汇刊副编。2023年起将担任IEEE模糊系统汇刊（IF=12.253）主编。

学会秘书处　供稿

零距离“对话”人工智能，机器人足球赛“燃翻全场”

——扬子晚报苏州小记者走进同济机器人科普教育基地

“抢球、射门、扑救……裁判哨音一响，场上所有的动作都要机器人自己来完成。”9月17日上午，扬子晚报苏州小记者们走进中国自动化学会科普教育基地——同济机器人科普教育基地，参观智能制造展厅，欣赏精彩的机器人足球赛，并与服务型机器人的互动，零距离感受了人工智能的魅力。

图1　扬子晚报苏州小记者们在中国自动化学会科普教育基地合影留念

当天上午9点，扬子晚报苏州小记者们在科普教育基地集结完毕。同济人工智能（苏州）研究院常务副总、同济机器人科普教育基地负责人邓若愚先生带领小记者们来到会议厅，一边播放视频一边讲解，同小记者们一起回顾了同济足球机器人在以往比赛中的精彩表现。“机器人居然会自己防守和射门！”“呀，机器人摔倒之后自己爬起来了，还那么迅速！”“这个守门员机器人的扑救太棒了！”……会议厅内，小记者们不时发出赞叹声和惊呼声，足球机器人的精彩表现，不断点燃小记者们的激情。

图 2　扬子晚报苏州小记者们观看 NAO 机器人足球赛事

图 3　同济人工智能（苏州）研究院常务副总、同济机器人科普教育基地负责人邓若愚先生为扬子晚报苏州小记者们讲解

图 4　同济人工智能（苏州）研究院常务副总、同济机器人科普教育基地负责人邓若愚先生带领扬子晚报苏州小记者们参观并讲解

随后，在同济机器人科普教育基地的志愿者们引导下，小记者们与仿真机器人进行对话与互动。“你叫什么名字？”“你唱一首生日歌吧。”“你吃午饭了吗？”小记者们迫不及待地用手或声音引导机器人，让机器人抬臂、摇头、转圈等，呈现出各种有趣的动作，引得现场一片欢声笑语。同济机器人科普教育基地志愿者方秦向小记者们介绍：“目前，机器人可以根据需求所设定的指令做事情，娱乐、家庭服务等功能均可实现，未来还可以用在监测老年人行为等领域。”

来到了小记者们最期待的环节——NAO 机器人足球赛事。随着一声哨响，足球赛正式开始，机器人在绿茵场上传球、抢球、射门、扑救……“萌感十足”。“比赛要求机器人完全自主，不允许任何形式的场外干预。一旦裁判哨音一响，场上所有的动作都要机器人自己来完成。使用的机器人都是从厂商购买，所以比拼的就是软件方面的实力。”比赛结束后，同济机器人科普教育基地志愿者徐子晗在现场耐心、细致地讲解了机器人运作的原理，让小记者们对机器人的结构、零部件等有一定的了解。

活动期间，基地负责人邓若愚先生在接受采访时表示：“同济机器人科普教育基地作为中国自动化学会科普教育基地之一，承担了对当地中小学生提供科普教育的职能，为了更好地推动科普教育、培养相应人才，今天面向扬子晚报小记者开放了这一活动，也希望小记者们能够在这次活动中喜欢上机器人技术。”

中国自动化学会科普教育基地以普及自动化、信息及智能科学领域知识、倡导科学方法、传播科学思想、弘扬科学精神为己任，充分调动社会力量开展科普工作的积极性，以青少年为重点普及对象，广泛开展形式多样、内容丰富的科普教育活动，推动自动化、信息、智能科学领域科普事业发展。截至目前，学会已建有科普教育基地 53 家。

学会秘书处　供稿

图 5　小记者们与仿真机器人进行对话与互动

图 6　扬子晚报苏州小记者们观看机器人踢足球

图 7　扬子晚报苏州小记者们与机械臂互动

首届新兴技术产业高端圆桌论坛在京召开

图 1　会议现场

2022 年 9 月 16 日下午，首届新兴技术产业高端圆桌论坛在京召开。中国科协党组书记、分管日常工作副主席、书记处第一书记张玉卓出席会议并致辞。中国质量协会党委书记、会长贾福兴，中国航天科工集团党组书记、董事长袁洁，中国工程院院士、中国矿业大学（北京）校长葛世荣，中国工程院院士、南京航空航天大学校长单忠德，中国科学院院士、中国自动化学会副理事长、中国空间技术研究院研究员杨孟飞，中国自动化学会监事长、中国科学院自动化研究所研究员王飞跃，中国自动化学会副秘书长、北京理工大学教授邓方等出席会议。中国科协党组成员、书记处书记王进展主持会议。

论坛聚焦“智能制造·数控机床”的主题，旨在促进科学家与企业家聚焦新兴技术前沿与产业需求，开展对话交流。张玉卓在致辞中指出，习近平总书记强调要健全关键核心技术攻关新型举国体制，加快突破受制于人的“卡脖子”问题。中国科协聚焦“国之大者”，创设高端对话交流平台，促进跨界融智，凝聚科学家、企业家、行业专家的智慧共识，共促高水平科技自立自强，推动高质量发展。

自动化是智能机床的核心技术，中国自动化学会将积极响应习总书记号召，贯彻落实中央和中国科协决策部署，大力支持并推动新型“智能机器操作系统 IMOS（Intelligent Machine Operations Stations/Systems）”技术的研发与应用，赋能产业创新升级，为“中国智造”迈向新高度保驾护航。

学会秘书处　供稿

图 2　中国科学院院士、中国自动化学会副理事长、中国空间技术研究院研究员杨孟飞发言

图 3　中国自动化学会监事长、中国科学院自动化研究所研究员王飞跃发言

图 4　中国自动化学会副秘书长、北京理工大学教授邓方发言

习近平：在复兴之路上坚定前行

——《复兴文库》序言

修史立典，存史启智，以文化人，这是中华民族延续几千年的一个传统。编纂《复兴文库》，是党中央批准实施的重大文化工程。在我们党带领人民迈上全面建设社会主义现代化国家新征程之际，这部典籍的出版，对于我们坚定历史自信、把握时代大势、走好中国道路，以中国式现代化推进中华民族伟大复兴具有十分重要的意义。

中华民族是世界上伟大的民族，为人类文明进步作出了不可磨灭的贡献。近代以后，中华民族遭受了前所未有的劫难。从那时起，实现中华民族伟大复兴就成为中国人民和中华民族最伟大的梦想。无数仁人志士矢志不渝、上下求索，奔走呐喊、奋起抗争。中国共产党成立后，团结带领人民前仆后继，进行艰苦卓绝的斗争，坚持马克思主义指导地位，找到了实现中华民族伟大复兴的正确道路，通过革命、建设、改革各个历史时期的不懈努力，迎来了从站起来、富起来到强起来的伟大飞跃，谱写了中华民族发展进程中最为波澜壮阔的历史篇章，中华民族伟大复兴展现出前所未有的光明前景。历史已经证明并将继续证明，在中国共产党坚强领导下，坚持科学理论指导和正确道路指引，凝聚亿万人民团结奋斗的磅礴力量，中国人民就能把中国发展进步的命运牢牢掌握在自己手中！

在实现伟大复兴的历史进程中，一代代中华民族的先进分子和优秀儿女探索、奋斗、牺牲、创造，留下了大量具有重要历史价值和时代意义的珍贵文献。编纂出版《复兴文库》大型历史文献丛书，就是要通过对近代以来重要思想文献的选编，述录先人的开拓，启迪来者的奋斗。

历史是最好的教科书，一切向前走，都不能忘记走过的路；走得再远、走到再光辉的未来，也不能忘记走过的过去。当前，世界百年未有之大变局加速演进，中华民族伟大复兴进入关键时期，我们更需要以史为鉴、察往知来。

我们要在学好党史的基础上，学好中国近代史，学好中国历史，弄清楚我们从哪里来、要到哪里去，弄清楚中国共产党人是干什么的、已经干了什么、还要干什么，弄清楚过去我们为什么能够成功、未来怎样才能继续成功。要坚定文化自信、增强文化自觉，传承革命文化、发展社会主义先进文化，推动中华优秀传统文化创造性转化、创新性发展，构筑中华民族共有精神家园。要萃取历史精华，推动理论创新，更好繁荣中国学术、发展中国理论、传播中国思想，不断推进马克思主义中国化时代化。要坚定理想信念，凝聚精神力量，在新时代更好坚持和发展中国特色社会主义，为实现中华民族伟大复兴的中国梦贡献我们这一代人的智慧和力量，创造属于我们这一代人的业绩和荣光。

来源：人民网

张玉卓：在深化系统改革中持续增强科协组织的发展活力

党的十八大以来，以习近平同志为核心的党中央高度重视群团改革发展，习近平总书记亲自谋划，对做好新时代群团工作作出一系列重要论述，深刻回答了群团事业发展的一系列方向性、根本性、战略性问题，为推进群团工作和群团改革提供了根本遵循。中国科协作为党领导下的人民团体、科技工作者的群众组织，切实发挥党和政府联系科技工作者的桥梁纽带职责，全面落实中央关于群团改革的重大部署，以不断增强科协组织的政治性、先进性、群众性为标尺，坚持问题导向，不断将科协系统改革引向深入，在加强科技工作者思想政治引领、做好联系服务工作、推动创新驱动发展、提高全民科学素质、服务党和政府科学决策等方面做了大量富有成效的工作，有力服务了党和国家工作大局。

立根铸魂，科协组织政治建设全面加强

坚定不移把厚植党执政的群众基础作为首要政治任务，把发挥桥梁纽带职责、团结引领科技工作者服务国家发展作为“最大的政治”和“重要的大局”，大力弘扬科学家精神，强化政治引领和政治吸纳，增强“四个意识”、坚定“四个自信”、做到“两个维护”。

把推动习近平新时代中国特色社会主义思想在科技界走深走实作为一切工作的“纲”和“魂”。抓好“关键少数”理论武装，在重要报刊媒体发表理论文章，深入解读习近平新时代中国特色社会主义思想和习近平总书记关于科技创新、群团发展的重要论述。建立中国科协党组成员、全国学会理事长、知名科学家讲党课常态化机制，用党的创新理论指导科协发展实践，聚焦新时代政治建设靶心设计科协系统工作格局，走好“两个维护”第一方阵。创办中国科协党校，面向科技领军人才、科协系统干部、海外科技人才开展理想信念教育、专题研修、国情调研，推动设立“全国科技工作者日”并广泛开展系列活动，强化全国创新争先奖、中国青年科技奖等激励导向，引导科技工作者奋力创新争先，持续打造没有围墙的思想引领阵地。编制并在海内外广泛传播《跟着总书记学科技》《嘱托》《佑护》等文化作品，推进思想政治引领空间深化拓展，润物无声凝心聚力，不断筑牢科技界团结奋斗的共同思想基础。

弘扬新时代科学家精神。深入贯彻习近平总书记关于科技创新重要论述，全面阐释以爱国、创新、求实、奉献、协同、育人为内核的科学家精神。全国科学道德和学风建设宣讲深入高校师生，科学家精神宣讲团、科学家精神教育基地、学风传承行动、中国科学家博物馆全方位建设科技工作者的精神家园。引领青年学子接力精神火炬，科学大师名校宣传工程深耕高校，“英才计划”“高校科学营”等机制实现科教协同育人。探索人才成长规律，老科学家学术成长资料采集工程深入挖掘 600 余位杰出科学家成长历程，展示科学家群体精神气质。“科学家精神”话题引发科技

界广泛共鸣，社会辨识度、认同感显著增强，科学家精神引领时代风尚的底色更加浓厚。

夯实科协系统党建保障，破冰学会党建难题。深入贯彻新时代党的建设总要求，推进党建与业务深度融合。成立科技社团党委，实施“党建强会”计划。截至目前，推动成立全国学会理事会党委 197 个、学会办事机构基层党组织 162 个，114 个学会探索建立分支机构党的工作小组 2151 个，初步形成学会理事会、办事机构、分支机构三层党建工作模式，完成全国学会党的组织和党的工作“两个全覆盖”。发挥政治引领作用，推动所属全国学会全面实现将习近平新时代中国特色社会主义思想、坚持党的全面领导、党的建设等载入章程。积极探索在学会理事会层面开展党建工作，旗帜鲜明加强党对学会工作的全面领导，切实发挥党组织的政治领导作用和战斗堡垒作用。

锐意创新，全面拓展“四服务”事业发展新空间

把坚持以人民为中心的发展思想贯穿科协事业发展全过程，紧扣时代主题，聚力打造科普、学术、智库“三轮驱动”服务品牌，实现科协优势资源战略重组和服务流程再造，为科技工作者创新创造、实现价值搭建广阔舞台。

坚持在联系服务科技工作者“亲”和“紧”上下功夫。发挥中国科协和全国学会、地方科协“一体两翼”组织优势系统联动，开通心理咨询服务热线，为科技工作者提供有温度的服务。推动完善奖励举荐制度，共推荐 1006 人次成为两院院士有效候选人，397 人获得中国青年科技奖、89 人获得中国青年女科学家奖。强化学会对科技人才尤其是青年人才的培养和举荐，青年人才托举工程支持 2100 余名青年科研人员成长。网上“科技工作者之家”连接 14 万基层组织，为科技工作者提供一站式服务。零距离听取科技工作者诉求呼声，建设“科情在线”调查系统，连接覆盖全国的 1254 个机构调查节点、700 余万科技工作者，形成快速调查和信息获取机制，网上联系服务、引领动员能力进一步增强。

全面提升战略支撑力，强机制、建基地、筑生态促进产学研融合。优化升级创新驱动助力工程，推出“科创中国”服务品牌，打造产学研供需对接的信息平台、技术服务与交易的运营平台、人才与技术的赋能平台。建设 65 个“科创中国”试点城市和园区，组建 482 支科技服务团，组织科技人员响应企业需求“揭榜挂帅”，为 6800 余家企业解难题、促升级。出台《中国科协科创促就业八项举措》，建立“政产学研金服用”多主体联动、形成要素汇聚涌流的创新联合体，“科创中国”咨询委员会、青年百人会、长三角助力创新联盟、国际技术交易联盟等近 200 个各类新型协同创新组织快速发展，大力营造科技经济深度融合发展的良好生态。

深入落实科学普及与科技创新同等重要的战略思想。准确把握科普内涵之变，既注重科学知识传播，更注重科学方法传授，不断强化科学精神、树立创新自信，推动科普协同化、信息化、国际化转型。接续推动《全民科学素质行动计划纲要（2006—2010—2020 年）》《全民科学素质行动规划纲要（2021—2035 年）》实施，成立中国公众科学素质促进联合体，持续开展全国科普日活动，协同化机制广聚百川势能共塑社会化动员新格局。2020 年，公民具备基本科学素质的比例达到 10.56%，全民科学素质建设迈上新台阶。扎实推动基层科普设施建设，现代科技馆体系从无到有、量质齐升，10 年来已逐步发展成为拥有 408 座全国实体科技馆、612 套流动科技馆、1251 辆科普大篷车、1112 所农村中学科技馆和中国数字科技馆“五位一体”的覆盖全国、世界独有的科普基础设施体系，线下服务公众超 8.5 亿人次。着力打造科普中国平台，面向公众提供科

学、权威、有趣、有用的科普内容，平台资源总量超 53TB，传播渠道 715 家，传播量达 416 亿人次，已成为国内最权威的科普平台和最大的科普资源库之一。面对新冠肺炎疫情大考，迅速启动应急科普机制，以“科学辟谣平台”阻击“疫情谣言”，联合中宣部等提出加强应急科普宣教工作的意见，推动形成平战结合的科普协同联动长效机制。连续举办 3 届世界公众科学素质促进大会，成立世界公众科学素质组织筹委会，打造以全球科学素质提升服务人的全面发展的开放高地。

突出科技治理特色，打造系统联动的科协智库体系。建立持续研判机制，组织引导科技工作者聚焦国家战略，积极建言献策。探索跨界研判“卡脖子”瓶颈的工作机制，持续发布重大科学问题、工程技术难题和产业技术问题。协同高校、地方和社会智库形成开放研究平台，围绕数字经济、公共卫生等重大问题，会地合作建设战略区域智库。组织能源企业和专家持续开展科技支撑“双碳”目标战略研究，提出煤化工消纳可再生能源以及原料煤不纳入能耗统计等建议。积极配合政府部门开展第三方评估，大众创业万众创新评估、全面创新改革试验评估、国家整体科技能力评估等受到广泛好评。

团结合作，开放型枢纽型平台型组织建设迈出坚实步伐

根据科技经济社会深度融合、创新主体协同发展的时代趋势，把握科技工作者思想动态、规模分布等新特点，探索新时代“三型”科技群团发展的新机制新模式。

坚持以会兴业、以业聚才、以才引才，持续打造团结引领的价值平台。打造世界科技与发展论坛、世界新能源汽车大会、世界机器人大会、世界生命科学大会、世界青年科学家峰会等国际交流平台，中国主场影响力持续提升。紧扣变革时代的发展主题，主动发起全球话题，广泛汇聚全球智慧。全国学会和地方科协推出数以万计的精品会议，机制化联系 200 多个国际组织，形成学科领域广泛交叉、产学研深度融合、思想碰撞交流的重要阵地。

强化学会改革主体地位。以治理结构和治理方式现代化为目标深化学会治理改革，加快建设世界一流学会，支持学会有序发展港澳台会员和外籍会员，探索吸纳港澳台及海外知华友华科学家在学会任职，拓展社会组织发展国际视野。一流期刊建设取得新突破。大力实施中国科技期刊卓越行动计划，一批优秀期刊跻身国际前列，44 种期刊学科排名进入国际前 5%，30 种位列学科前三，14 种跻身学科第一，5 种进入全球百强，实现零的突破。建设临床案例成果数据库，汇聚 10 万余篇病例报告向社会开放，为临床医生评价制度改革提供支撑。发布 32 个学科领域高质量科技期刊分级目录，覆盖国内外期刊 5198 种，推进中外期刊同质等效应用。集成 95 个国家（地区）、38 个语种共 1.4 万余种科技期刊构建“世界引文库”，研制期刊影响力综合评价指数，形成面向世界的自主评价体系。

党建带群建赋予基层组织新活力。推动组织与业务融通发展，集成科普、学术、智库资源协同下沉，进入基层党建平台，融入社会治理网络，增强科协组织服务发展的能力。构建省域统筹政策机制、市域构建资源中心、县域着重组织落实、各级学会协同联动的工作体系，以基层党群服务中心、新时代文明实践中心为阵地，推动建立科技志愿服务工作机制。赋能 4 万余名基层“三长”（医院院长、学校校长、农技站站长），有效延长科普服务链，拓宽科普惠民覆盖面，基层组织力不断增强。

以“互联网 +”促进组织变革。集成科协优势资源，主动融入数字化转型大局，以科技工作者为中心打造“智慧科协 2.0”一体化功能平台，做好各部门单位、地方科协、全国学会等组织、专网、独立信息系统的整合接入工作，推进审查事项、办事流程、数据交换等

方面的标准化建设。国家级科技人才库入库人数向千万量级迈进，为党和政府人才工作大局提供服务支撑。弥合不同领域、不同行业、不同部门单位、不同组织之间的断层，打破时空限制、信息分割与数据壁垒，重组整合科协各类业务，形成“一体两翼”数字化转型升级的新发展格局，提升网上群众工作能力。

发挥国际民间科技交流主渠道作用。坚持面向世界、面向未来，秉持开放、信任、合作理念引领科技工作者共同应对国际复杂变局。持续加强与港澳台科技组织的交流合作，团结服务港澳台科技工作者融入国家发展、民族复兴大局。积极参与全球科技治理，代表中国科技界加入 372 个国际科技组织，推荐中国科学家就任执委以上职务 399 人次。支持发起成立国际氢能燃料电池协会等国际科技组织。积极参加联合国与重要国际科技组织联合发起的大科学计划。积极深化科技抗疫国际合作，组织 167 个全国学会与 254 个对口国际科技组织建立信息分享机制，推动 200 多种期刊迅速向世界卫生组织提交授权书参与 COVID-19 数据库建设。积极开展“一带一路”科技人文交流合作平台建设，支持建立或筹建 30 个区域科技组织或联盟、39 个国际科技组织联合研究或培训中心、5 个国别或区域科技问题研究中心。持续实施“海智计划”，累计与 102 个海外科技团体建立合作关系，设立 138 个各类海智基地，以多种形式开展引才引智工作。

10 年来，我们深刻体会到，科协事业发展的根基在于坚持以习近平新时代中国特色社会主义思想为指引，始终保持党领导下人民团体的政治本色；活力在于始终围绕党和国家事业发展大局，以科技工作者为中心，与时俱进地确立工作重心；动力在于顺应世界科技发展大势，坚持不懈深化改革、扩大开放。面向未来，科协组织必须立足新发展阶段，贯彻新发展理念，不断提高政治判断力、政治领悟力、政治执行力，着力涵养自立自强，着力推动创新发展，着力推进协同治理，着力拓展开放融合，以更加广阔的视野、更强有力的历史担当，团结科技工作者主动融入构建新发展格局的历史进程中。

全面建设社会主义现代化国家的号角已经吹响。新征程上，科协组织要自觉把党和人民的期待和呼唤，当作科技进步和创新的时代强音，坚定主心骨、汇聚正能量、振奋精气神，以昂扬奋进的姿态最广泛地凝聚广大科技工作者，更加紧密地团结在以习近平同志为核心的党中央周围，众心向党、自立自强，向着实现第二个百年奋斗目标的宏伟蓝图不断前进，以实际行动迎接党的二十大胜利召开。

来源：学习时报

通知

关于开展 2022 年度中国自动化学会会士候选人提名填报工作的通知

为表彰对自动化、智能化和信息化科学与技术的发展做出卓越贡献或为 CAA 服务做出突出贡献的 CAA 会员，根据《中国自动化学会会士实施细则》的规定，现中国自动化学会开展 2022 年度 CAA 会士候选人提名填报工作，具体事项详见中国自动化学会官网：http://www.caa.org.cn/article/192/3054.html

关于新时代进一步加强科学技术普及工作的意见

科学技术普及（以下简称科普）是国家和社会普及科学技术知识、弘扬科学精神、传播科学思想、倡导科学方法的活动，是实现创新发展的重要基础性工作。党的十八大以来，我国科普事业蓬勃发展，公民科学素质快速提高，同时还存在对科普工作重要性认识不到位、落实科学普及与科技创新同等重要的制度安排尚不完善、高质量科普产品和服务供给不足、网络伪科普流传等问题。面对新时代新要求，为进一步加强科普工作，现提出如下意见。

一、总体要求

（一）指导思想。

以习近平新时代中国特色社会主义思想为指导，坚持把科学普及放在与科技创新同等重要的位置，强化全社会科普责任，提升科普能力和全民科学素质，推动科普全面融入经济、政治、文化、社会、生态文明建设，构建社会化协同、数字化传播、规范化建设、国际化合作的新时代科普生态，服务人的全面发展、服务创新发展、服务国家治理体系和治理能力现代化、服务推动构建人类命运共同体，为实现高水平科技自立自强、建设世界科技强国奠定坚实基础。

（二）工作要求。

坚持党的领导，把党的领导贯彻到科普工作全过程，突出科普工作政治属性，强化价值引领，践行社会主义核心价值观，大力弘扬科学精神和科学家精神。坚持服务大局，聚焦“四个面向”和高水平科技自立自强，全面提高全民科学素质，厚植创新沃土，以科普高质量发展更好服务党和国家中心工作。坚持统筹协同，树立大科普理念，推动科普工作融入经济社会发展各领域各环节，加强协同联动和资源共享，构建政府、社会、市场等协同推进的社会化科普发展格局。坚持开放合作，推动更大范围、更高水平、更加紧密的科普国际交流，共筑对话平台，增进开放互信、合作共享、文明互鉴，推进全球可持续发展，推动构建人类命运共同体。

（三）发展目标。

到 2025 年，科普服务创新发展的作用显著提升，科学普及与科技创新同等重要的制度安排基本形成，科普工作和科学素质建设体系优化完善，全社会共同参与的大科普格局加快形成，科普公共服务覆盖率和科研人员科普参与率显著提高，公民具备科学素质比例超过 15%，全社会热爱科学、崇尚创新的氛围更加浓厚。到 2035 年，公民具备科学素质比例达到 25%，科普服务高质量发展能效显著，科学文化软实力显著增强，为世界科技强国建设提供有力支撑。

二、强化全社会科普责任

（四）各级党委和政府要履行科普工作领导责任。

落实科普相关法律法规，把科普工作纳入国民经济和社会发展规划、列入重要议事日程，与科技创新协同部署推进。统筹日常科普和应急科普，深入实施全

民科学素质行动，为全社会开展科普工作创造良好环境和条件。

（五）各行业主管部门要履行科普行政管理责任。

各级科学技术行政部门要强化统筹协调，切实发挥科普工作联席会议机制作用，加强科普工作规划，强化督促检查，加强科普能力建设，按有关规定开展科普表彰奖励。各级各有关部门要加强行业领域科普工作的组织协调、服务引导、公共应急、监督考评等。

（六）各级科学技术协会要发挥科普工作主要社会力量作用。

各级科学技术协会要履行全民科学素质行动牵头职责，强化科普工作职能，加强国际科技人文交流，提供科普决策咨询服务。有关群团组织和社会组织要根据工作对象特点，在各自领域开展科普宣传教育。

（七）各类学校和科研机构要强化科普工作责任意识。

发挥学校和科研机构科教资源丰富、科研设施完善的优势，加大科普资源供给。学校要加强科学教育，不断提升师生科学素质，积极组织并支持师生开展丰富多彩的科普活动。科研机构要加强科普与科研结合，为开展科普提供必要的支持和保障。

（八）企业要履行科普社会责任。

企业要积极开展科普活动，加大科普投入，促进科普工作与科技研发、产品推广、创新创业、技能培训等有机结合，提高员工科学素质，把科普作为履行社会责任的重要内容。

（九）各类媒体要发挥传播渠道重要作用。

广播、电视、报刊、网络等各类媒体要加大科技宣传力度，主流媒体要发挥示范引领作用，增加科普内容。各类新兴媒体要强化责任意识，加强对科普作品等传播内容的科学性审核。

（十）广大科技工作者要增强科普责任感和使命感。

发挥自身优势和专长，积极参与和支持科普事业，自觉承担科普责任。注重提升科普能力，运用公众易于理解、接受和参与的方式开展科普。积极弘扬科学家精神，恪守科学道德准则，为提高全民科学素质作出表率。鼓励和支持老科技工作者积极参与科普工作。

（十一）公民要自觉提升科学素质。

公民要积极参与科普活动，主动学习、掌握、运用科技知识，自觉抵制伪科学、反科学等不良现象。

三、加强科普能力建设

（十二）强化基层科普服务。

围绕群众的教育、健康、安全等需求，深入开展科普工作，提升基层科普服务能力。依托城乡社区综合服务设施，积极动员学校、医院、科研院所、企业、社会组织等，广泛开展以科技志愿服务为重要手段的基层科普活动。建立完善跨区域科普合作和共享机制，鼓励有条件的地区开展全领域行动、全地域覆盖、全媒体传播、全民参与共享的全域科普行动。

（十三）完善科普基础设施布局。

加强科普基础设施在城市规划和建设中的宏观布局，促进全国科普基础设施均衡发展。鼓励建设具有地域、产业、学科等特色的科普基地。全面提升科技馆服务能力，推动有条件的地方因地制宜建设科技馆，支持和鼓励多元主体参与科技馆等科普基础设施建设，加强科普基础设施、科普产品及服务规范管理。充分利用公共文化体育设施开展科普宣传和科普活动。发挥重大科技基础设施、综合观测站等在科普中的重要作用。充分利用信息技术，深入推进科普信息化发展，大力发展线上科普。

（十四）加强科普作品创作。

以满足公众需求为导向，持续提升科普作品原创能力。依托现有科研、教育、文化等力量，实施科普精品工程，聚焦“四个面向”创作一批优秀科普作品，培育高水平科普创作中心。鼓励

科技工作者与文学、艺术、教育、传媒工作者等加强交流，多形式开展科普创作。运用新技术手段，丰富科普作品形态。支持科普展品研发和科幻作品创作。加大对优秀科普作品的推广力度。

（十五）提升科普活动效益。

发挥重大科技活动示范引领作用，展示国家科技创新成就，举办科普惠民活动，充分展现科技创新对推动经济社会高质量发展和满足人民群众美好生活需要的支撑作用。面向群众实际需求和经济社会发展典型问题，积极开展针对性强的高质量公益科普。

（十六）壮大科普人才队伍。

培育一支专兼结合、素质优良、覆盖广泛的科普工作队伍。优化科普人才发展政策环境，畅通科普工作者职业发展通道，增强职业认同。合理制定专职科普工作者职称评聘标准。广泛开展科普能力培训，依托高等学校、科研院所、科普场馆等加强对科普专业人才的培养和使用，推进科普智库建设。加强科普志愿服务组织和队伍建设。

（十七）推动科普产业发展。

培育壮大科普产业，促进科普与文化、旅游、体育等产业融合发展。推动科普公共服务市场化改革，引入竞争机制，鼓励兴办科普企业，加大优质科普产品和服务供给。鼓励科技领军企业加大科普投入，促进科技研发、市场推广与科普有机结合。加强科普成果知识产权保护。

（十八）加强科普交流合作。

健全国际科普交流机制，拓宽科技人文交流渠道，实施国际科学传播行动。引进国外优秀科普成果。积极加入或牵头创建国际科普组织，开展青少年国际科普交流，策划组织国际科普活动，加强重点领域科普交流，增强国际合作共识。打造区域科普合作平台，推动优质资源共建共享。

四、促进科普与科技创新协同发展

（十九）发挥科技创新对科普工作的引领作用。

大力推进科技资源科普化，加大具备条件的科技基础设施和科技创新基地向公众开放力度，因地制宜开展科普活动。组织实施各级各类科技计划（专项、基金）要合理设置科普工作任务，充分发挥社会效益。注重宣传国家科技发展重点方向和科技创新政策，引导社会形成理解和支持科技创新的正确导向，为科学研究和技术应用创造良好氛围。

（二十）发挥科普对科技成果转化的促进作用。

聚焦战略导向基础研究和前沿技术等科技创新重点领域开展针对性科普，在安全保密许可的前提下，及时向公众普及科学新发现和技术创新成果。引导社会正确认识和使用科技成果，让科技成果惠及广大人民群众。鼓励在科普中率先应用新技术，营造新技术应用良好环境。推动建设科技成果转移转化示范区、高新技术产业开发区等，搭建科技成果科普宣介平台，促进科技成果转化。

五、强化科普在终身学习体系中的作用

（二十一）强化基础教育和高等教育中的科普。

将激发青少年好奇心、想象力，增强科学兴趣和创新意识作为素质教育重要内容，把弘扬科学精神贯穿于教育全过程。建立科学家有效参与基础教育机制，充分利用校外科技资源加强科学教育。加强幼儿园和中小学科学教育师资配备和科学类教材编用，提升教师科学素质。高等学校应设立科技相关通识课程，满足不同专业、不同学习阶段学生需求，鼓励和支持学生开展创新实践活动和科普志愿服务。

（二十二）强化对领导干部和公务员的科普。

在干部教育培训中增加科普内容比重，突出科学精神、科学思想培育，加强前沿科技知识和全球科技发展趋势学习，提高领导干部和公务员科学履职能力。

（二十三）强化职业学校教育和职业技能培训中的科普。

弘扬工匠精神，提升技能素

质，培育高技能人才队伍。发挥基层农村专业技术协会、科技志愿服务等农业科技社会化服务体系作用，深入推进科技特派员制度，引导优势科普资源向农村流动，助力乡村振兴。

（二十四）强化老龄工作中的科普。

依托老年大学（学校、学习点）、社区学院（学校、学习点）、养老服务机构等，在老年人群中广泛普及卫生健康、网络通信、智能技术、安全应急等老年人关心、需要又相对缺乏的知识技能，提升老年人信息获取、识别、应用等能力。

六、营造热爱科学、崇尚创新的社会氛围

（二十五）加强科普领域舆论引导。

坚持正确政治立场，强化科普舆论阵地建设和监管。增强科普领域风险防控意识和国家安全观念，强化行业自律规范。建立科技创新领域舆论引导机制，掌握科技解释权。坚决破除封建迷信思想，打击假借科普名义进行的抹黑诋毁和思想侵蚀活动，整治网络传播中以科普名义欺骗群众、扰乱社会、影响稳定的行为。

（二十六）大力弘扬科学家精神。

继承和发扬老一代科学家优秀品质，加大对优秀科技工作者和创新团队的宣传力度，深入挖掘精神内涵，推出一批内蕴深厚、形式多样的优秀作品，引导广大科技工作者自觉践行科学家精神，引领更多青少年投身科技事业。

（二十七）加强民族地区、边疆地区、欠发达地区科普工作。

推广一批实用科普产品和服务，组织实施科技下乡进村入户等科普活动，引导优质科普资源向民族地区、边疆地区、欠发达地区流动，推动形成崇尚科学的风尚，促进铸牢中华民族共同体意识和巩固拓展脱贫攻坚成果。

七、加强制度保障

（二十八）构建多元化投入机制。

各级党委和政府要保障对科普工作的投入，将科普经费列入同级财政预算。鼓励通过购买服务、项目补贴、以奖代补等方式支持科普发展。鼓励和引导社会资金通过建设科普场馆、设立科普基金、开展科普活动等形式投入科普事业。依法制定鼓励社会力量兴办科普事业的政策措施。

（二十九）完善科普奖励激励机制。

对在科普工作中作出突出贡献的组织和个人按照国家有关规定给予表彰。完善科普工作者评价体系，在表彰奖励、人才计划实施中予以支持。鼓励相关单位把科普工作成效作为职工职称评聘、业绩考核的参考。合理核定科普场馆绩效工资总量，对工作成效明显的适当核增绩效工资总量。

（三十）强化工作保障和监督评估。

完善科普法律法规体系，推动修订《中华人民共和国科学技术普及法》，健全相关配套政策，加强政策衔接。开展科普理论和实践研究，加强科普调查统计等基础工作。加强科普规范化建设，完善科普工作标准和评估评价体系，适时开展科普督促检查。合理设置科普工作在文明城市、卫生城镇、园林城市、环保模范城市、生态文明示范区等评选体系中的比重。○

来源：新华社

中国自动化学会

中国自动化学会（Chinese Association of Automation，缩写CAA）于1961年在天津成立，是我国最早成立的国家一级学术团体之一，是中国科学技术协会的组成部分，是发展我国自动化科技事业的重要社会力量。学会现有个人会员近8万人，团体会员单位近300个，专业委员会58个，工作委员会9个，30个省、自治区、直辖市设有地方学会组织，覆盖了我国自动化科学技术领域的各个层面。

中国自动化学会在改革中求发展，不断加强群众组织力、学术引领力、社会公信力和国际影响力。近年来，中国自动化学会重点从学术交流与应用推广、组织建设与会员服务、科技评估与人才评价、课题研究与决策支撑、科学普及与继续教育等方面开拓创新，推动中国自动化科学和事业的发展和壮大，成为连接政府、产业、学术、科研、会员的重要纽带，致力于成为国内外有影响力的现代社会团体组织。

学会品牌学术活动

·中国自动化大会 ·中国认知计算与混合智能学术大会
·国家智能车发展论坛 ·国家机器人发展论坛 ·国家智能制造论坛
·青年菁英系列活动 ·智能自动化学科前沿讲习班 ·钱学森国际杰出科学奖系列讲座
·中国控制会议 ·中国过程控制会议 ·青年学术年会

学会奖励奖项

·钱学森奖 ·杨嘉墀科技奖 ·CAA科学技术奖励 ·CAA优秀博士学位论文奖
·中国自动化与人工智能创新团队奖 ·CAA高等教育教学成果奖 ·CAA青年科学家奖
·企业创新示范单位 ·杰出自动化工程师 ·小微创业示范单位 ·智慧系统创新解决方案示范单位

学会主办期刊

·中国自动化学会通讯 ·自动化学报 ·自动化学报（英文版）
·信息与控制 ·机器人 ·模式识别与人工智能 ·电气传动
·自动化博览 ·计算技术与自动化

官方微信　　官方微博

地址：北京市海淀区中关村东路95号自动化大厦
网址:http://www.caa.org.cn/
电话：010-62522472
传真：010-62522248
邮箱：caa@ia.ac.cn
邮编：100190