

类脑智能技术在无人系统上的应用

赵欣怡, 宗群, 张睿隆[†], 田栢苓, 张秀云, 冯聪

(天津大学 电气自动化与信息工程学院, 天津 300072)

摘要: 随着人工智能与脑科学等前沿技术的迅速发展, 无人系统智能化研究正逐渐成为当今世界强国重点关注的战略发展方向, 研究与之相关的科学问题具有前瞻性、战略性和带动性. 文章首先分析了无人系统的发展需求, 提出了面向需求的若干关键问题, 包括复杂环境与态势信息的感知与认知问题、整体效能最优的分布式任务决策问题、面向任务需求的路径实时规划问题、考虑高不确定环境的自学习控制问题、应对非预期情况的故障诊断及容错问题以及基于人机接口的人机交互问题; 随后, 系统阐述了类脑智能技术在解决这些问题上的国内外研究现状; 最后, 论述了无人系统类脑智能化发展中依然存在的问题及未来发展趋势.

关键词: 类脑智能; 无人系统; 智能自主

引用格式: 赵欣怡, 宗群, 张睿隆, 等. 类脑智能技术在无人系统上的应用. 控制理论与应用, 2019, 36(1): 1–12

DOI: 10.7641/CTA.2018.80418

Application of brain-inspired intelligence technology in unmanned vehicles

ZHAO Xin-yi, ZONG Qun, ZHANG Rui-long[†], TIAN Bai-ling,
ZHANG Xiu-yun, FENG Cong

(School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China)

Abstract: With the rapid advancement of artificial intelligence and brain science technology, intelligent unmanned vehicles is becoming the strategic development direction for world powers today, and the research of related scientific problems are forward-looking, strategic and strong in promotion. This paper first analyzes the development requirements of unmanned vehicles, based on which several requirement-oriented key problems is put forward, including the perception and cognition problem of the complex environment and situation, the distributed task decision problem subject to optimal overall effectiveness, the real-time path planning problem satisfying task requirement, the self-learning control problem under high uncertainty environment, the fault diagnosis and fault tolerance problem in response to unexpected situation and the human-machine interaction problem based on human-machine interaction equipment. Then, the current research status of brain intelligent technology in solving these problems at home and abroad is discussed. Finally, this paper summarizes the existing problems and presents the prospects in the development of intelligent unmanned vehicles.

Key words: brain-inspired intelligent; unmanned vehicles; intelligent autonomous

Citation: ZHAO Xinyi, ZONG Qun, ZHANG Ruilong, et al. Application of brain-inspired intelligence technology in unmanned vehicles. *Control Theory & Applications*, 2019, 36(1): 1–12

1 引言

近年来, 人工智能在各领域的研究成果斐然: 2011年2月, IBM的Watson问答系统在竞赛节目中打败了人类对手; 2016年12月, 谷歌Deepmind和牛津大学共同研发的唇语解读系统“LipNet”对视频人物进行唇语解读, 准确率高达93.4%; 2017年5月, 谷歌的AlphaGo战胜目前围棋世界排名第一的柯洁; 同年10月, 其

新版本AlphaGo Zero在与AlphaGo的对抗中取得了全胜的压倒性战绩……尽管人工智能在各领域的应用成果层出不穷, 但仅是从某一特定领域逼近或是超过人类的智能水平^[1].

近年来, 各国的研究学者们普遍认为高度智能化的实现需要从脑科学中受到启发, 并积极开展在类脑智能方向的研发工作^[2-3]. 2011年, 美国谷歌大脑诞

收稿日期: 2018-06-07; 录用日期: 2018-12-26.

[†]通信作者. E-mail: 839267975@qq.com; Tel.: +86 18600119153.

本文责任编辑: 裴海龙.

国家自然科学基金项目(61673294, 61773278, 61573060)资助.

Supported by the National Natural Science Foundation of China (61673294, 61773278, 61573060).

生,意图建立包括机器感知、自然语言处理、机器翻译及语音处理的互联网AI系统;2013年,美国启动脑计划,意在研究人脑成像技术、理解神经回路机理,并取得了重大突破;同年,欧盟启动脑计划,目标是建立为未来神经科学、医学和智能计算所融合的全新信息和计算技术基础;2014年2月,百度大脑诞生,到2017年已经提供了语音识别与合成、文字识别、人脸识别等数十项服务;2017年12月,阿里云提出ET大脑,阿里专家表示阿里云ET大脑将是具备多维感知、全局洞察、实时决策、持续进化等类脑认知能力的超级智能体。

人的大脑是一个通用智能系统,由千亿个神经元和数百万亿突触连接构成,具有感知、学习、推理和决策的能力。无人系统的类脑智能化是通过借鉴人脑的运行机制,使无人系统能够通过不断学习逐步进化,实现类脑感觉、认知、决策、规划和控制等功能,具有极强自适应和自学习能力,最终达到或超越人类智能水平。

2 无人系统发展需求及关键问题

无人系统在恶劣环境和危险任务领域具有独特优势,在科技、经济、社会生活等各方面发挥着日益重要的作用。根据使用区域的不同,美国将无人系统分为无人机系统、无人地面平台、无人海上系统。2011年12月,伊朗通过电子干扰阻塞美军RQ-170无人机与后方联系的通信手段,通过程序控制使其自动迫降。由此看来,无人系统存在易被对方操控的短板。此外,由于任务类型越来越广泛,任务区域不断拓展,无人系统将全面涉足于对地、对海、对空等多任务领域,在物流、应急救援等行业领域拥有巨大市场前景,这对无人系统的发展提出如下需求:

- 1) 无人系统需要“看得清”,“看得准”,“看得明白”,为自主完成任务提供技术基础。
- 2) 无人系统需要在多种任务中进行灵活有效的协调,并计算出到达任务目标的路径。
- 3) 无人系统需要在复杂环境下安全稳定的完成任务,具备应对非预期状况的能力。
- 4) 无人系统需要在人机协作的复杂场景下,与人类配合共同完成任务。

为满足上述需求,世界上以美国为首的发达国家高度重视类脑智能技术在无人系统上的应用,意在通过提高无人系统的智能化水平,使其具备自主认知、决策、规划与控制能力,从而满足上述应用需求。谷歌公司在2017年创新大会上展示了第二代人工智能专用处理器(tensor processing unit, TPU),其强大性能引起军方和军工企业高度关注。美国国防部和空军研究实验室已与谷歌探讨利用TPU增强美国无人系统的作战能力和智能化水平。我国也于2016年5月制定

《“互联网+”人工智能三年行动实施方案》,明确提出推动人工智能技术在无人系统领域的融合应用,发展无人飞行器、无人船等多种形态的无人设备。美国曾在无人机系统路线图中指出:到2025年以后,无人机将具有集群战场认知能力,实现完全自组织控制^[4]。

综上所述,随着人工智能等前沿技术迅速发展,无人系统类脑智能化的研究已逐渐成为各国关注的焦点,迫切需要开展与之相关问题的研究工作。以美国空军上校博伊德提出的观察-判断-决策-行动循环理论^[5]为指导,依据人脑的认知行为模式,提出面向应用需求的如下关键问题:

1) 复杂环境与态势信息的感知与认知问题:考虑无人系统所处环境的复杂性与多样性,如何在搭载传感器有限的情况下,对环境与态势信息进行准确感知与预判是亟待解决的关键问题之一。

2) 整体效能最优的分布式动态决策问题:综合考虑任务目标的不确定性、目标环境动态性以及单机任务有效性,如何以整体效能最优为原则进行异构无人系统分布式动态决策是亟待解决的关键问题之一。

3) 面向任务需求的路径实时规划问题:根据外界环境与潜在威胁信息,如何在机载资源有限的情况下实时规划出安全、快速的最优路径,提高指挥的高效性与无人系统的灵活性是亟待解决的关键问题之一。

4) 考虑高不确定环境的自学习控制问题:面对任务环境的高动态性与不确定性,如何利用自学习与自适应能力快速适应目标环境并完成任务是亟待解决的关键问题之一。

5) 应对非预期情况的故障诊断及容错问题:考虑无人系统在执行任务中突发故障的情况,如何将类脑智能技术与现有故障诊断与容错技术结合,提高无人系统的抗故障与自愈能力是亟待解决的关键问题之一。

6) 基于人机接口的人机交互问题:考虑现今无人系统智能性的不足,重要任务的执行离不开人的判断与决策,如何利用人机接口实现人机交互是亟待解决的关键问题之一。

3 无人系统类脑智能化研究现状

下面将分别对上述关键问题的国内外研究情况进行阐述。

3.1 复杂环境与态势信息的感知与认知问题

作为无人系统的“眼睛”,对环境感知问题的研究一直是最热门的研究领域之一,尤其近几年人工智能技术在计算机视觉领域中快速发展,许多基于人工智能的新兴算法与模型更是在无人智能系统中大放异彩。美国国防部于2017年7月批准立项的Maven项目计划使用机器学习和类脑智能技术来协助分析由无人机拍摄的海量影像资料,谷歌的TensorFlow智能系

统将作为协助完成该任务。目前,用于环境感知的类脑智能技术主要是基于深度学习中卷积神经网络框架的融合技术^[6]。卷积神经网络模型(convolutional neural networks, CNN)是一种专门用来处理图像矩阵的深度神经网络,其结构如图1所示。

2012年,美国Facebook人工智能实验室的Ross Girshick等推出了基于区域的卷积网络^[7](region-based convolutional neural networks, RCNN),将检测

速度和准确度都提升了一个层次,并于2016年进一步推出RCNN进阶版Faster-RCNN^[8],将目标检测的四个步骤(候选区域生成、特征提取、分类、边界回归)统一到一个深度学习框架里,极大地提升了运行速度,基本达到实时检测。2017年,该团队进一步提出YOLO(you only look once)^[9],直接将目标检测转化到回归上,利用一张图片得到所属类别,彻底达到了实时检测的标准。




图 1 卷积神经网络结构

Fig. 1 The structure of CNN

目前,CNN模型主要运用于无人系统的目标识别任务^[10-12]、场景分类任务^[13-15]和同步定位与地图构建(simultaneous localization and mapping, SLAM)任务^[26-30]中。针对目标识别任务,最新的研究趋势是设计一个同时具备边界回归和目标分类能力的CNN模型^[10-12]。美国德克萨斯大学Amir Ghaderi等^[16]采用无监督学习方法来训练CNN模型,该模型的优点是训练样本少,缺点是非常耗费时间和计算资源。中科院自动化所的赵冬斌等^[17]采用基于CNN的多任务学习方法解决了自动驾驶过程中的危险物体检测及距离预测问题。针对场景分类问题,目前的主要趋势是关注CNN模型中卷积层对于图像整体的表达以及图像特征学习的效率,以及全连接层对图像特征的代表能力^[14]。西班牙加泰罗尼亚开放大学的 ágata Lapedriza等^[13]指出,无人机在航拍过程中获得的图像信息也可以通过预训练的CNN模型进行特征提取。瑞士达勒莫勒人工智能研究所的 Alessandro Giusti等^[18]设计了一个10层CNN网络把Parrot AR. Dron四旋翼无人机机载摄像头获得的森林小道图像分为3类(直行、左转及右转)。澳大利亚悉尼大学的Calvin Hung等^[19]针对多旋翼无人机拍摄的航拍图像,使用了一个稀疏自编码器进行无监督学习,实现对杂草和小麦的分类。美国宾夕法尼亚大学的Steven W. Chen等^[20]采用数据驱动的方法搭建深度学习网络,对被树叶遮挡的果实进行统计计数。清华大学的付昊桓等^[21]采用Alex-net CNN结构^[22],结合滑动窗口的图像处理方法对棕榈树进行检测和计数。此外,深度学习技术在探索与救援领域中也取得了巨大的成效,如韩国城市机器人

实验室的Hangeun Kim等^[23]采用CNN算法识别出水母的种类。莫斯科航空大学的Nikolai等根据无人机获取的图像信息进行交通监控。此外,深度学习模型也用于无人机雪崩救援行动以及恐怖分子识别任务^[24-25]。深度学习方法在SLAM问题还刚刚起步,剑桥大学Alex Kendall等^[26]首先把深度学习和SLAM结合,提出了PoseNet网络对6自由度相机获得的场景进行再定位。加拿大维多利亚大学Kwang Moo Yi等^[27]提出LIFT(learned invariant feature transform)方法,通过深度学习方法对图像中的特征点进行学习与匹配。美国Magic Leap公司的Daniel DeTone等^[28]提出了一种基于深度学习的特征点的提取与匹配方法。美国加州大学伯克利分校Tinghui Zhou等^[29]采用两个CNN来估计每一帧的深度和位置。德国慕尼黑大学Keisuke Tateno等^[30]采用CNN网络估计深度以及图像语意的分割,生成一张具有语义信息的地图。

无人智能系统对态势信息的认知是根据当前时刻的环境信息对下一刻环境进行预测与评估。Boelke^[31]在第一次世界大战时首次提出态势估计概念。国防大学的朱丰等人^[32]对基于深度学习的环境态势评估进行了综述和展望,并总结了美军已启动的关于机器学习的项目,例如“深绿计划”实现“从数据到评估再到决策”的自主辅助决策系统。AlphaGo^[33]依靠深度学习的方法,建模了人类的“直觉”棋感和大局观,对当前棋局进行评估并对棋子走势进行预测。西安交通大学的李晨等^[34]提出了一种使用分层贝叶斯网络进行自适应态势评估的方法,基于模拟贝叶斯网络进行复杂环境的态势评估。美国的S. Das等^[35]采用

贝叶斯网络的节点表示各种战场概念,不仅可以对高层态势进行高效的评估,而且可以评估与特殊任务有关的情报需求.加拿大不列颠哥伦比亚大学的Famush等^[36]提出一种适合环境动态变化的态势估计系统,通过改变贝叶斯网络的参数来放慢态势变化的速度,从而得到更加准确的态势表示.

3.2 整体效能最优的分布式任务决策问题

根据协商机制不同,集群无人系统的任务决策主要分为集中式和分布式两种决策方式.美国参联会副主席指出,无人系统要做到自己对任务进行决策判断,即改变以地面站为中心的体系结构,进行以无人系统为单位的自主决策.针对异构无人系统分布式任务决策,卡耐基梅隆大学的Luo等^[37]提出了一种改进的分布式拍卖算法,投标过程中考虑通信范围内邻居机器人的收益情况,解决了异构无人系统的决策问题.韩国先进科学技术研究院的Lee等^[38]进一步针对资源受限下的多机器人任务决策问题,提出了一种基于概率的分布式拍卖算法,相比传统的分布式拍卖算法,具有更快的执行任务速度,且消耗资源更少.

由于多无人系统在完成作战任务时,不可避免地存在协作与竞争关系,因此博弈论在解决多无人系统的智能任务决策问题中存在一定的潜力.英国克兰菲尔德大学的Antonios Tsourdos等分别提出基于匿名享乐博弈^[39]与基于马尔科夫链^[40]的集群机器人智能任务分配方法,并将两种算法在收敛速度与可扩展性上进行对比,仿真实验表明基于匿名享乐博弈的智能任务分配方法收敛速度更快,而基于马尔科夫链的智能任务分配方法在集群规模的可扩展性方面更具有优势^[41].

考虑到神经网络与强化学习结合具备自主学习的能力,可以无需人工干预信号,进行终生在线学习^[42-43],其中强化学习结构示意图如图2所示.借鉴这一想法,国防科技大学的王冲等^[44]等采用强化学习算法设计了一种用于多卫星协同任务分配求解的策略,并引入约束惩罚算子和多星联合惩罚算子对效用值增益函数进行改进.巴西圣贝尔纳多-杜坎普大学的Flavio Tonidandel等^[45]针对机器人世界杯锦标赛中的球员角色分配问题提出一种基于市场机制与启发式加速强化学习的多机器人任务分配算法.西班牙马德里大学的Javier de Lope等^[46-47]分别提出了基于自动学习机的强化学习算法,基于社会昆虫劳动分工的响应阈值算法和基于蚁群优化的确定性算法,解决了多机器人自协调任务决策问题.

对于大规模的集群智能任务分配问题,伦敦大学学院的汪军认为可以借鉴生物界中的自组织机制,找到集群的内在规律^[48].美国麻省理工大学的Jonathan P. How等^[49]基于蝗虫弹性行为提出一种自主任务分配方法实现了不同任务区域的多无人机协同搜索与

救援.南京航空航天大学的甄子洋等^[50]则提出一种基于蚁群优化的新型智能自组织算法,解决了多无人机的协同搜索-攻击任务规划问题.




图2 强化学习示意图

Fig. 2 The illustration of reinforcement learning

3.3 面向任务需求的路径实时规划问题

在CVPR2016大会上,Mobileye的联合创始人及CTO Amnon Shashua发表了关于智能自动驾驶主题的演讲,指出无人车辆的驾驶策略需要考虑未来规划及其他车辆行为,并指出深度强化学习就是用来解决这一问题的技术.此外,深度强化学习方法还可以将传统路径规划算法中线上计算量转化为线下训练量,实现机载计算资源有限情况下的实时路径规划,因而近两年被研究人员应用于无人系统的路径规划问题中.

美国NASA兰利研究中心的计算机工程师Loc Tran等^[51]以携带单目前置摄像头的小型四旋翼无人机为对象提出一种基于数据集融合的深度学习方法,实现了在密集混乱环境中的自主避障.斯坦福的李飞飞团队^[52]基于谷歌Deepmind提出的多线程A3C算法^[53]在高度仿真的环境中训练机器人,使其能够通过视觉输入自主规划出到达目标点的最优路径,并在真实场景中得到验证.其优点在于将目标物体作为输入进行训练,使得训练后的神经网络泛化功能更强.韩国延世大学的Shin-Dug Kim等^[54]将Q学习算法^[55]用于室内仿真环境中的无人机规避障碍物及路径规划问题,实验表明训练后的Q学习算法在到达时间上优于A*算法.香港科技大学的Dit-Yan Yeung等^[56]将确定性策略梯度算法(deep deterministic policy gradient, DDPG)^[57]用于规划无人机的期望路径,并与PID控制器结合,利用分层结构实现目标跟踪任务,并在实际中得到验证.同样采取这一控制结构的还有英国普利茅斯大学的Riccardo Polvara等^[58],他们将深度双Q算法^[59]与PID控制器结合用于无人机的自主着陆问题中.新加坡南洋理工大学的Nursultan Imanberdiyev等^[60]将基于模型的强化学习算法——TEXPLORE^[61]用于实际环境中的无人机路径规划问题中,这一方法避免了上述免模型强化学习方法普遍存在的实际交

互成本过高的问题,同时通过引入平行线程机制解决了TEXPLORE算法存在的实时性较差的问题。

针对多无人系统的路径规划问题,麻省理工学院的Jonathan P. How等^[62]提出基于深度V学习的多机器人避障策略,使机器人能够仅通过传感器获取的邻机信息实现自主避障,快速安全地到达目标点。他们进一步考虑社交友好行为^[63],使机器人能够自主规划符合行人规则的行进路径。但上述工作均假设机器人的运动符合一定的规则,即机器人在规划自身路径时,假设邻近机器人的运行速度在 Δt 时间内保持不变。香港城市大学的潘佳等^[64]提出了一种基于策略梯度算法的多机器人避障策略,采用多场景多阶段的训练框架,使训练后的路径规划策略具有很好的泛化功能。

3.4 考虑高不确定环境的自学习控制问题

樊邦奎院士指出智能无人机的特点之一就是具备自学习能力^[65]。自学习控制器是一种无需人工干预,能够通过自主学习达到预设控制性能的控制器的^[66-68]。其具备两个特点:一是能够根据当前环境给出适当的控制量;二是能够利用控制后的结果进行自主改进^[68]。强化学习方法模拟脑的学习机制,无需人工干预信号,强调在与环境的交互过程中进行学习。它通过环境对不同控制输出的评价性反馈信号来自主修改自身的控制策略,从而实现控制量的优化,达到预期的控制性能^[69-70]。因此强化学习被称为一种自学习控制方法^[70-72]。在应对环境及模型不确定问题上具有极大优势^[69,73-74],受到谷歌、Facebook和微软等诸多AI公司的青睐。

针对无人系统的姿态控制问题,美国波士顿大学的William Koch等^[75]将深度确定性策略梯度、置信域策略优化与近端策略优化3种深度强化学习算法和传统的PID算法进行比对,实验表明在高保真的四旋翼姿态控制仿真环境中,近端策略优化算法在超调量、上升时间及跟踪误差方面优于其他3种控制算法。上海交通大学的苏志强等^[76]则研究了洋流影响下的水下滑翔机姿态控制问题,通过强化学习算法修改或估计自抗扰控制器的控制参数,有效解决了传统控制方法中调参困难的问题。针对无人系统的定点控制问题,荷兰ESA高级概念小组的Stefan Willis等^[77]提出一种基于直接策略搜索的强化学习算法实现了航天器在未知重力场的小行星上方的定点观测。美国圣何塞州立大学的Kamran Turkoglu等^[78]则将Q学习算法用到NASA SPHERES卫星集结问题中,使其从过往经验中学习未知环境下的无模型控制策略。针对无人系统的跟踪控制问题,美国伯克利及斯坦福大学的Pieter Abbeel和Andrew Ng^[79-80]提出基于学徒学习和强化学习的控制策略,即通过学习多个近似完美的机动演示实现了直升机的特技飞行。瑞士苏伊士联邦

理工学院的Jemin Hwangbo等^[81]提出一种新的Actor-critic框架下的深度强化学习算法,实现任一初始条件下无人机路径跟踪控制。清华大学的宋士吉等^[82]将优先级采样与DDPG算法相结合,实现不确定环境下的水下机器人免模型深度跟踪控制。西北工业大学的崔荣鑫等^[83]则进一步考虑六自由度的水下机器人模型,提出一种基于强化学习的自适应神经网络控制方法,实现了外界干扰、模型参数不确定及控制输入非线性影响下的轨迹跟踪控制。谷歌大脑的Aleksandra Faust等将强化学习方法用于悬挂负载系统的无人机控制问题^[84-86]中。与普通无人机运动控制问题相比,无人机悬挂负载系统对飞行过程的平稳性要求更高。

针对无人系统在未知环境下的避障问题,美国伯克利大学的Sergey Levine等^[87]提出一种基于不确定感知的深度强化学习方法,通过对碰撞概率的估计,使得机器人在面对不熟悉的未知环境中保持“警惕”,降低运行速度,减小碰撞的可能。同样为减小无人机与环境交互的试错次数,他们还提出了一种引导策略搜索算法^[88],利用从优化控制器中产生的数据进行学习,实现仿真环境下四旋翼无人机的避障控制。中科院自动化所的曾毅等^[89]提出一种基于前额叶皮层-基底核的强化学习算法实现无人机的避障控制。上海交通大学的张卫东等^[90]采用DQN算法解决水面无人艇的避障控制问题,根据障碍信息自主选择规避动作并行进至目标点。国防科技大学的牛轶峰等^[91]针对无人机的避障问题,提出一种基于CNN和卡尔曼滤波的显著性检测算法提取障碍物信息,并将Actor-critic框架与径向基神经网络结合实现无人机的连续控制输出。

文献[92-93]将强化学习算法用到无人系统的集群控制中。加拿大皇家军事学院的Shao-Ming Hung等人^[92]为模拟的真实飞行环境,在无人机4自由度模型中引入随机干扰,采用Q学习算法实现非平稳随机环境下的多无人机集群控制。美国内华达大学的Xu Hao等人^[93]进一步研究集群避碰问题,同时考虑了传感器丢包及控制器与执行器之间通信时延的问题,提出了一种基于Actor-critic强化学习算法的有限时域最优集群控制-网络协同设计方法。

此外,强化学习方法中的自适应动态规划方法在无人系统的智能控制中也起到重要的作用。美国德克萨斯大学的Frank L. Lewis团队、东北大学的柴天佑院士、张化光团队、广州工业大学的刘德荣团队、纽约大学工学院的姜钟平团队以及重庆大学的宋永端团队在这一领域取得了一系列研究成果^[94-105]。

国内外的研究学者们也采用其他方法提高无人系统的智能性。美国辛辛那提大学的Nicholas Ernest采用遗传模糊树算法设计的AI战斗系统——ALPHA^[106],在一场多人飞行模拟测试中,打败了已

退休的前美国空军上校.南开大学的方勇纯^[107]基于并发学习框架提出一种免模型的单目视觉伺服策略,在无需期望图像的情况下驱动轮式移动机器人达到预期姿态.北京理工大学的陈杰^[108]针对无人机与无人车组成的异构无人系统提出一种适用于不同协同控制策略的分类算法.北京交通大学的侯忠生^[109]建立并完善了无模型自适应控制理论,并已实际应用于清华大学无人驾驶汽车实验平台中^[110].吉林大学的陈虹^[111]提出基于学习的预测控制算法并将其应用于无人系统的最优控制问题中.北京航空航天大学的海滨^[112]将鸽群优化与滚动时域方法结合实现多无人机的编队全局重构.

3.5 应对非预期情况的故障诊断及容错问题

美国佛罗里达国际大学的 Alireza Abbaspour 等^[113]针对六自由度的 WVU YF-22 无人机模型提出一种基于卡尔曼滤波器与神经网络的在线故障诊断方法,通过网络权重参数的在线调整对系统驱动器及传感器故障进行实时监测.南京航空航天大学的陈谋等^[114]则基于径向基神经网络提出一种自适应容错控制算法,解决了驱动器故障影响下的三自由度直升机跟踪控制问题.由于深度学习能够通过多层结构对数据进行表征学习,实现未知数据的分类或预测,因此在故障诊断及预测领域有很大的应用前景^[115-116].美国 NASA 喷气推进实验室的 Kyle Hundman 等^[117]针对航天器遥测的多变量时间序列数据,采用深度长短期记忆递归神经网络实现对异常情况的高预测性能,这一算法在活性科学实验室探测器的异常报告中得到了验证.空军工程大学的倪世红等^[118]针对无人机驱动器故障建立了基于深度自动编码器的多模型故障诊断算法.山东科技大学的钟麦英等^[119]提出了一种基于混合特征模型和深度学习的无人机传感器故障诊断方法,首先采用短时傅里叶变换方法将不同传感器的故障残差信号转化对应的时频信号;然后利用卷积神经网络提取传感器故障特征,实现无人机传感器的故障诊断.南京航空航天大学的王华伟等^[120]基于深度信念网络和决策融合算法,提出了一种新型航空发动机故障融合诊断方法,先利用深度信念网络提

取性能参数中的隐藏特征,得出故障分类置信度;其后对多次故障分类结果进行决策融合,得到准确的诊断结果.北京航天测控总公司的方红正等^[121]针对航天器电源系统的故障诊断问题,建立了去躁自动编码器与反向传播算法结合的深度神经网络架构,实现了故障诊断并确定了故障类型.日本九州工业大学的 Huimin Lu 等人^[122]针对无人机电机温度检测系统,利用强化学习算法动态调整阈值温度,实现了无需人工干预下的动态状态实时温度监测.东北大学的杨光红等^[123]基于策略迭代和自适应方法研究了基于数据的故障容错问题.韩国首尔国立大学的 Donghae Kim 等^[124]则采用 Q 学习算法实现了故障情况下 F/A-18 仿真无人机从水平旋转恢复至平稳飞行状态的控制问题.

3.6 基于人机接口的人机交互问题

无人系统在人机协作的复杂场景下,需要与人类配合共同完成任务.人机交互问题作为一个热门的研究领域,主要研究如何使人与机器更加方便、智能的互动^[125].人机交互可以实现人在回路(man-in-loop)仿真,以进行人机协同系统的模拟,通过提高沉浸感来增强仿真或训练的效果.无人智能系统的研发具有实验成本高、研究周期长等缺点,利用仿真可以对前期研究的结论进行验证和评估,从而完善系统方案的设计,缩短开发周期,并且节约开发成本.2016年,美国国防高级研究计划署(defense advanced research projects agency, DARPA)提出进攻性无人机蜂群使能(offensive swarm-enabled tactics, OFFSET)项目^[126],基于增强现实、虚拟现实等游戏技术以及手势、触感和触感装置等,发展可以控制蜂群的原型系统,预期目标是实现100个无人机和无人地面车在2小时内,在4个城市街区作战.DARPA打算以游戏产业为基础,利用现有技术和开源程序库,创造真实的作战场景;并考虑与未来使用人员的交互,借助虚拟现实技术控制无人机蜂群,发展自主和自适应作战平台.因此,实现人机交互技术的主要手段是采用人机接口方式.人机交互示意图如图3所示.



图3 人机交互

Fig. 3 Human computer interaction

目前, 人机交互设备主要包括: 脑机接口技术(brain computer interface, BCI)、语音识别技术、手势控制技术以及虚拟现实技术(virtual reality, VR)。BCI是通过人的大脑直接控制无人系统执行人发出的指令, 其获得人大脑信号的主要手段之一是基于脑电图(electroencephalography, EEG)的非侵入式脑电采集手段。亚利桑那州立大学George K. Karavas等^[127]依据专注力的水平的变化对脑电波的影响进而设计出无人蜂群脑机控制系统。清华大学的高上凯、高小榕团队^[128]通过SSVEP (steady state visually evoked potentials)技术, 对26个字幕设定不同频率的闪烁, 采用典型相关分析方法进行分类识别, 实现脑机智能打字技术。他们研制的智能机器狗, 可以通过运动想象相关动作控制机器狗表演“意识流足球”^[129]。华南理工大学的李远清团队^[130]通过结合P300和SSVEP技术对轮椅进行控制, 使轮椅根据患者的指令实现前后左右的运动。天津大学明东团队研制的“神工二号”^[131]可以帮助中风患者通过想象控制机械外骨骼进行康复性训练。国防科技大学胡德文采用P300技术设计一种汉字输入界面^[132]。南开大学的段峰团队^[133]开发一种可翻译相关脑电波信号的计算机程序, 实现对汽车前进、后退、停车、锁车和开锁等操作的控制。

语音识别技术、手势控制技术以及VR技术同样也广泛的应用在有人无人系统的控制与决策领域中。DARPA的OFFSET项目致力于开发一种开放式蜂群技术体系^[134], 通过VR接口的技术, 让一个用户可以控制整个无人机群。技术人员利用HTC Vive虚拟现实设备和一对控制器与环境交互, 参与无人机集群作战的实时决策, 通过VR接口实现多种指挥功能: 如选择蜂群子集并为之分配任务, 使其移动到特定区域, 或让无人机原地盘旋; 又如使用VR环境画出待测绘区域范围, 然后选择无人机完成该任务, 最后发布语音命令测绘该区域。天津大学宗群实验室采用VR技术开发有人无人编队的沉浸式体验场景, 利用语音识别技术实现了虚拟无人机的起飞与降落, 而后利用手势控制技术实现了虚拟无人机打击目标的选取。

4 存在的问题及发展趋势

从上述论述可知, 无人系统的类脑智能化已有了初步进展与相应的研究成果, 还存在一些不够完善和尚未解决的问题, 有待进一步的研究。基于作者的理解和思考, 本文提出一些尚未解决的难点以及未来值得关注的研究方向。

1) 复杂环境与态势信息的感知与认知问题: 现有的类脑智能技术主要解决单个无人系统的环境感知及态势认知问题。考虑任务环境的复杂性与多样性, 仅仅通过单个无人系统搭载的传感器往往难以获取足够和准确的环境信息^[135]。因此, 应用多机间的信息共享与互补, 能够大大提高对外部环境的了解, 为多

无人机的任务规划和决策提供充分的依据。多无人系统的协同智能感知与认知问题实质上就是多无人系统根据任务需求, 利用搭载多层次传感器进行的多平台多源数据采集、分析、融合处理的问题^[136]。因此, 为了提高复杂环境下无人机感知环境信息的准确性和可靠性, 并且使多无人机具备态势认知能力, 利用类脑智能技术解决多无人机协同感知、态势认知问题, 将成为实现自主感知和态势认知的重要研究方向。

2) 整体效能最优的分布式动态决策问题: 目前的任务决策方法主要侧重于解决确定条件下的静态决策问题^[137-138]。在实际应用中, 由于任务环境的部分可观测性及可能存在的对抗行为, 决策时所依赖的环境信息是动态且不确定的。综合考虑任务的突发性和不确定性、无人系统之间的协作与竞争关系, 使得无人系统能够以自我为单位, 克服信息动态性与不确定性所带来的影响, 做出整体效益最优的自主类脑实时决策, 以应对任务需求发生变化的情况, 是一个挑战性的研究课题^[138]。例如, 以Deepmind和阿里巴巴认知计算实验室为首的研究学者将多智能体强化学习算法用于星际争霸等游戏任务中, 让智能体学习如何在动态环境中实现以己方最小代价造成敌方最大损伤。OpenAI提出一种多智能体确定性策略梯度算法^[139], 通过集中评判-分散执行的方式使智能体具有自主决策能力, 在动态环境中实现智能协同合作与对抗, 这对无人机的集群智能决策具有启发式作用。

3) 面向任务需求的路径实时规划问题: 现有的类脑智能路径规划算法主要针对单个无人系统, 研究如何利用有限的机载资源快速有效的规划出合理路径。然而, 从美国《无人系统综合路线图(2017-2042)》^[140]可以看出, 集群智能无人系统的发展已成为必然趋势, 其功能分布化、体系生存率高、作战成本低等优势可以有效地处理单一无人平台无法完成的任务^[141-142]。随着任务区域内无人系统数量的增多, 其路径必然会发生时空交叠, 导致碰撞情况的发生。因此, 面对可能变化的任务需求, 考虑环境中其他无人系统的当前运行状态与环境信息, 在有限计算资源的条件下迅速进行合理安全的协同路径规划是该方向的发展趋势^[62]。文献^[143]就提出一种基于长短期记忆(long short-term memory, LSTM)的深度强化学习方法, 在机器人数量增多的情况下, 无需假设邻近机器人的运行规则, 根据邻近机器人的当前运行状态进行在线避碰。

4) 考虑高不确定环境的自学习控制问题: 尽管现有的类脑智能技术能够通过学习机制应对未知的外界环境以及自身模型不确定的问题, 但是在学习过程中需要大量与环境试错交互产生的样本数据, 这会大大增加学习的成本, 限制该技术在实际操作中的应用。如果无人系统能够借鉴人脑卓越的“举一反三”能

力,利用少量高质量样本数据对原有的网络模型进行更新,从而学习任务规律,就可以快速适应突发任务与复杂多变的外界环境^[44]。近期发展起来的深度学习(deep meta learning, DML)进行了一些有意义的研究,文献[144–146]利用递归神经网络重用以往的经验,学习如何更快地完成新任务,可以给本问题的解决带来一定启发。

5) 应对非预期情况的故障诊断及容错问题: 现有基于类脑智能的故障诊断方法通过模仿人类学习大量数据自我揣摩形成判断,适用于标记数据丰富的情况,然而很多情况下,大量数据是未标记,且手动标记十分昂贵,需要耗费大量人力(例如间歇性故障)^[147–148]。因此,如何从未标记的原始数据中提取故障特征,并进行准确隔离是值得深入探讨的研究方向^[147]。例如,文献[149]提出利用无监督特征学习方法捕捉原始数据中的故障特征。此外,基于知识的故障诊断方法适用于数据不充分的系统,其依靠知识库中专家的经验知识进行诊断,诊断精度与知识库的完备性相关。笔者认为,可以考虑将深度学习方法与专家系统结合,即将专业知识整合到深度学习方法中提供成本可行的有效诊断方案^[150]。例如文献[151]就提出一种半监督学习方法,利用大量未标记的样本数据与少量基于知识标记的样本数据进行学习。

6) 基于人机接口的人机交互问题: 目前脑电信号检测方法主要采用头皮脑电检测,如果在嘈杂的环境中提取脑电信号会存在大量的干扰噪声。因此,提高脑电信号的信噪比,尽可能多的保留有用信号是未来主要的研究方向^[135]。此外,完备、便捷的人机交互方案能够使机器更快速准确地顺应人的意图。因此,通过BCI技术、语音识别技术、手势控制技术以及VR技术与无人系统相互融合与应用,即通过BCI、语音识别等多元化的人机交互的技术更加方便快捷的向无人系统发出指令或纠正无人系统的行动,使无人系统更加顺从的执行人的旨意,实现多模态人机交互也是一个值得深入研究的方向^[152–153]。

5 结束语

无人系统的类脑智能化研究是一个富于挑战性的课题。本文从无人系统发展的需求入手,分析了无人系统类脑智能化的若干关键问题,针对这些问题介绍了类脑智能技术在无人系统上的应用现状,并对尚未解决的问题进行了探讨,指出无人系统类脑智能化的进一步研究方向。在类脑智能技术与无人系统飞速发展的今天,开展无人系统类脑智能化的研究工作对推动国民经济的发展和国防力量的建设具有极为重要的意义。

参考文献:

[1] PU Muming, XU Bo, TAN Tieniu. Brain science and brain-inspired intelligence technology—an overview. *Bulletin of Chinese Academy*

of Sciences, 2016, 31(7): 725 – 736.

(蒲慕明, 徐波, 谭铁牛. 脑科学与类脑研究概述. 中国科学院院刊, 2016, 31(7): 725 – 736.)

- [2] ZENG Yi, LIU Chenglin, TAN Tieniu. Retrospect and outlook of brain-inspired intelligence research. *Chinese Journal of Computers*, 2016, 1(1): 212 – 222.
(曾毅, 刘成林, 谭铁牛. 类脑智能研究的回顾与展望. 计算机学报, 2016, 1(1): 212 – 222.)
- [3] XU Bo, LIU Chenglin, ZENG Yi. Research status and developments of brain-inspired intelligence. *Bulletin of Chinese Academy of Sciences*, 2016, 31(7): 793 – 802.
(徐波, 刘成林, 曾毅. 类脑智能研究现状与发展思考. 中国科学院院刊, 2016, 31(7): 793 – 802.)
- [4] CAMBONE A S, KRIEG J K, PACE P, et al. *Unmanned Aircraft Systems Roadmap 2005–2030*. US: Office of the Secretary of Defense. 2005.
- [5] SHU Z, JIA Q, LI X, et al. An ooda loop-based function network modeling and simulation evaluation method for combat system-of-systems. *Theory, Methodology, Tools and Applications for Modeling and Simulation of Complex Systems*. Singapore: Springer, 2016: 393 – 402.
- [6] LECUN Y, BENGIO Y, HINTON G. Deep learning. *Nature*, 2015, 521(7553): 436 – 444.
- [7] GIRSHICK R, DONAHUE J, DARREL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Columbus: IEEE, 2014: 580 – 587.
- [8] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks. *Advances in Neural Information Processing Systems 28*. Montreal: Springer, 2015: 91 – 99.
- [9] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas: IEEE, 2016: 779 – 788.
- [10] GIRSHICK R, DONAHUE J, DARREL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Boston: IEEE, 2014: 580 – 587.
- [11] LEE J, WANG J, CRANDALL D, et al. Real-time, cloud-based object detection for unmanned aerial vehicles. *IEEE International Conference on Robotic Computing*. Taichung: IEEE, 2017: 36 – 43.
- [12] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multi-box detector. *European Conference on Computer Vision*. Cham: Springer, 2016: 21 – 37.
- [13] ZHOU B, LAPEDRIZA A, XIAO J, et al. Learning deep features for scene recognition using places database. *International Conference on Neural Information Processing Systems*. Montreal: Springer, 2014: 487 – 495.
- [14] PENATTI O A B, NOGUEIRA K, SANTOS J A D. Do deep features generalize from everyday objects to remote sensing and aerial scenes domains. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Boston: IEEE, 2015: 44 – 51.
- [15] HU F, XIA G S, HU J, et al. Transferring deep convolutional neural networks for the scene classification of high-resolution remote sensing imagery. *Remote Sensing*, 2015, 7(11): 14680 – 14707.
- [16] AMIR G, VASSILIS A. Selective unsupervised feature learning with convolutional neural network (S-CNN). *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Mexico: IEEE, 2016: 2486 – 2490.
- [17] CHEN Y, ZHAO D, LV L, et al. Multi-task learning for dangerous object detection in autonomous driving. *Information Sciences*, 2018, 432(3): 559 – 571.

- [18] GIUSTI A, GUZZI J, DAN C C, et al. A machine learning approach to visual perception of forest trails for mobile robots. *IEEE Robotics and Automation Letters*, 2016, 1(2): 661 – 667.
- [19] HUNG C, ZHE X, SUKKARIEH S. Feature learning based approach for weed classification using high resolution aerial images from a digital camera mounted on a UAV. *Remote Sensing*, 2014, 6(12): 12037 – 12054.
- [20] CHEN S W, SKANDAN S S, DCUNHA S, et al. Counting apples and oranges with deep learning: a data driven approach. *IEEE Robotics & Automation Letters*, 2017, 2(2): 781 – 788.
- [21] LI W, FU H, YU L, et al. Deep learning based oil palm tree detection and counting for high-resolution remote sensing images. *Remote Sensing*, 2016, 9(1): 22 – 31.
- [22] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks. *International Conference on Neural Information Processing Systems*. Nevada: Springer, 2012: 1097 – 1105.
- [23] KIM H, KIM D, JUNG S, et al. Development of a UAV-type jellyfish monitoring system using deep learning. *International Conference on Ubiquitous Robots and Ambient Intelligence*. Xi'an: IEEE, 2015: 495 – 497.
- [24] BEJIGA M, ZEGGADA A, NOUFFIDJ A, et al. A convolutional neural network approach for assisting avalanche search and rescue operations with UAV imagery. *Remote Sensing*, 2017, 9(2): 100 – 108.
- [25] SAWARKAR A, CHAUDHARI V, CHAVAN R, et al. HMD vision-based teleoperating UGV and UAV for hostile environment using deep learning. *ArXiv Preprint*. 2016. arXiv: 1609.04147.
- [26] KENDALL A, GRIMES M, CIPOLLA R. PoseNet: a convolutional network for real-time 6-DOF camera relocalization. *IEEE International Conference on Computer Vision*. Santiago: IEEE, 2015: 2938 – 2946.
- [27] YI K M, TRULLS E, LEPETIT V, et al. LIFT: learned invariant feature transform. *European Conference on Computer Vision*. Cham: Springer, 2016: 467 – 483.
- [28] DETONE D, MALISIEWICZ T, RABINOVICH A. Toward geometric deep SLAM. *ArXiv Preprint*. 2017. arXiv:1707.07410.
- [29] ZHOU T, BROWN M, SNAVELY N, et al. Unsupervised learning of depth and ego-motion from video. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Hawaii: IEEE, 2017: 6612 – 6619.
- [30] TATENO K, TOMBARI F, LAINA I, et al. CNN-SLAM: real-time dense monocular SLAM with learned depth prediction. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Hawaii: IEEE, 2017: 6565 – 6574.
- [31] ZHAO Zonggui, XIONG Zhaohua, WANG Ke, et al. *Theory, Methodology, Tools and Applications for Modeling and Simulation of Complex Systems*. Beijing: National Defense Industry Press, 2012.
(赵宗贵, 熊朝华, 王珂, 等. 信息融合概念方法与应用. 北京: 国防工业出版社, 2012.)
- [32] ZHU Feng, HU Xiaofeng. Survey and research progress of battlefield situation assessment based on deep learning. *Military Operations and Systems Engineering*, 2016, 30(3): 22 – 27.
(朱丰, 胡晓峰. 基于深度学习的战场态势评估综述与研究展望. 军事运筹与系统工程, 2016, 30(3): 22 – 27.)
- [33] SILVER D, HUANG A, MADDISON C J, et al. Mastering the game of go with deep neural networks and tree search. *Nature*, 2016, 529(7587): 484 – 489.
- [34] LI C, CAO M, TIAN L. Situation assessment approach based on a hierarchic multi-timescale bayesian network. *International Conference on Information Science and Control Engineering*. Shanghai: IEEE, 2015: 911 – 915.
- [35] DAS S, GREY R, GONSALVES P. Situation assessment via Bayesian belief networks. *Proceedings of the Fifth International Conference on Information Fusion*. Annapolis: IEEE, 2002: 664 – 671.
- [36] MIRMOEINI F, KRISHNAMURTHY V. Reconfigurable Bayesian networks for hierarchical multi-stage situation assessment in battlespace. *Conference Record of the Thirty-Ninth Asilomar Conference on Signals*, Pacific Grove: IEEE, 2005: 104 – 108.
- [37] LUO L, CHAKRABORTY N, SYCARA K. Provably-good distributed algorithm for constrained multi-robot task assignment for grouped tasks. *IEEE Transactions on Robotics*, 2015, 31(1): 19 – 30.
- [38] LEE D H, ZAHEER S A, KIM J H. A Resource-oriented, decentralized auction algorithm for multirobot task allocation. *IEEE Transactions on Automation Science & Engineering*, 2015, 12(4): 1469 – 1481
- [39] JANG I, SHIN H S, TSOURDOS A. Anonymous hedonic game for task allocation in a large-scale multiple agent system. *ArXiv Preprint*. 2017. arXiv: 1711.06871.
- [40] JANG I, SHIN H S, TSOURDOS A, et al. An integrated decision-making framework of a heterogeneous aerial robotic swarm for cooperative tasks with minimum requirements. *Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering*, 2018, DOI: 10.1177/0954410018772622.
- [41] JANG I, SHIN H S, TSOURDOS A. A comparative study of game-theoretical and markov-chain-based approaches to division of labour in a robotic swarm. *IFAC-PapersOnLine*, 2018, 51(12): 62 – 68.
- [42] MNIH V, KAVUKCUOGLU K, SILVER D, et al. Playing atari with deep reinforcement learning. *ArXiv Preprint*. 2013. arXiv: 1312.5602.
- [43] MNIH V, KAVUKCUOGLU K, SILVER D, et al. Human-level control through deep reinforcement learning. *Nature*, 2015, 518(7540): 529 – 533.
- [44] WANG Chong. *Research on distributed cooperative mission planning of earth observation satellite based on agent*. Changsha: Military Operations and Systems Engineering, 2011.
(王冲. 基于Agent的对地观测卫星分布式协同任务规划研究. 长沙: 国防科学技术大学, 2011.)
- [45] GURZONI J A, TONIDANDEL F, BIANCHI R A C. Market-based dynamic task allocation using heuristically accelerated reinforcement learning. *Portuguese Conference on Artificial Intelligence*. Berlin: Springer, 2012: 365 – 376.
- [46] LOPE D J, MARAVALL D, QUINONEZ Y. Self-organizing techniques to improve the decentralized multi-task distribution in multi-robot systems. *Neurocomputing*, 2015, 163(9): 47 – 55.
- [47] LOPE D J, MARAVALL D, QUINONEZ Y. Response threshold models and stochastic learning automata for self-coordination of heterogeneous multi-task distribution in multi-robot systems. *Robotics and Autonomous Systems*, 2013, 61(7): 714 – 720.
- [48] 杨文. UCL计算机系教授汪军: 如何进行大规模多智能体强化学习. <https://www.leiphone.com/news/201707/5FqArxg82upR2i2.html>, 2017.
- [49] KURDI H A, ALOBOUD E, ALALWAN M, et al. Autonomous task allocation for multi-UAV systems based on the locust elastic behavior. *Applied Soft Computing*, 2018, 71(10): 110 – 126.
- [50] ZHEN Z, XING D, GAO C. Cooperative search-attack mission planning for multi-UAV based on intelligent self-organized algorithm. *Aerospace Science and Technology*, 2018, 76(5): 402 – 411.
- [51] TRAN L, CROSS C, MONTAGUE G, et al. Reinforcement learning with autonomous small unmanned aerial vehicles in cluttered environments. *AIAA Aviation Technology, Integration, and Operations Conference*. Dallas: AIAA, 2015: 2899 – 2917.

- [52] YUKE Z, ROOZBEH M, ERIC K, et al. Target-driven visual navigation in indoor scenes using deep reinforcement learning. *IEEE International Conference on Robotics and Automation*. Singapore: IEEE, 2017: 3357 – 3364.
- [53] MNIH V, BADIA A P, MIRZA M, et al. Asynchronous methods for deep reinforcement learning. *Proceedings of the International Conference on Machine Learning*. New York: IEEE, 2016: 1928 – 1937.
- [54] KIM I, SHIN S, WU J, et al. Obstacle avoidance path planning for uav using reinforcement learning under simulated environment. *IASER 3rd International Conference on Electronics, Electrical Engineering, Computer Science*. Okinawa: IEEE, 2017: 34 – 36.
- [55] CHRISTOPHER J C H W, PETER D. Q-learning. *Machine Learning*, 1992, 8(3/4): 279 – 292.
- [56] LI S, LIU T, ZHANG C, et al. Learning unmanned aerial vehicle control for autonomous target following. *ArXiv Preprint*. 2017. arXiv: 1709.08233.
- [57] TIMOTHY P L, JONATHAN J H, ALEXANDER P, et al. Continuous control with deep reinforcement learning. *ArXiv Preprint*. 2015. arXiv: 1509.02971.
- [58] POLVARA R, PATACCHIOLA M, SHARMA S, et al. Autonomous quadrotor landing using deep reinforcement learning. *ArXiv Preprint*. 2017. arXiv: 1709.03339.
- [59] VAN H H, GUEZ A, SLIVER D. Deep reinforcement learning with double Q-learning. *Proceedings of the 30th AAAI Conference on Artificial Intelligence*. Phoenix: AAAI, 2016: 1813 – 1819.
- [60] IMANBERDIYEV N, FU C, KAYACAN E, et al. Autonomous navigation of UAV by using real-time model-based reinforcement learning. *Proceedings of the 14th International Conference on Control, Automation, Robotics and Vision*. Phuket: IEEE, 2016: 1 – 6.
- [61] HESTER T, STONE P. Texplora: real-time sample-efficient reinforcement learning for robots. *Machine Learning*, 2013, 90(3): 385 – 429.
- [62] CHEN Y F, LIU M, EVERETT M, et al. Decentralized non-communicating multiagent collision avoidance with deep reinforcement learning. *IEEE International Conference on Robotics and Automation*. Singapore: IEEE, 2017: 285 – 292.
- [63] CHEN Y F, EVERETT M, LIU M, et al. Socially aware motion planning with deep reinforcement learning. *ArXiv Preprint*. 2017. arXiv: 1703.08862.
- [64] LONG P, FAN T, LIOA X, et al. Towards optimally decentralized multi-robot collision avoidance via deep reinforcement learning. *ArXiv Preprint*. 2017. arXiv: 1709.10082.
- [65] FAN Bangkui, ZHANG Ruiyu. UAV system and artificial intelligence. *Journal of Wuhan University: Information Science Edition*, 2017, 42(11): 1523 – 1529.
(樊邦奎, 张瑞雨. 无人机系统与人工智能. 武汉大学学报·信息科学版, 2017, 42(11): 1523 – 1529.)
- [66] JANG J S R. Self-learning fuzzy controllers based on temporal back-propagation. *IEEE Transactions on Neural Networks*, 1992, 3(5): 714 – 723.
- [67] NGUYEN D H, WIDROW B. Neural networks for self-learning control systems. *IEEE Control Systems Magazine*, 1990, 10(3): 18 – 23.
- [68] CHIANG C K, CHUNG H Y, LIN J J. A self-learning fuzzy logic controller using genetic algorithms with reinforcements. *IEEE Transactions on Fuzzy Systems*, 1997, 5(3): 460 – 467.
- [69] SUTTON R S, BARTO A G. *Reinforcement Learning: An Introduction*. Cambridge: MIT Press, 1998.
- [70] LIU Derong, LI Hongliang, WANG Ding. Data-based self-learning optimization control. *Journal of Automation*, 2013, 39(11): 1858 – 1870.
(刘德荣, 李宏亮, 王鼎. 基于数据的自学习优化控制: 研究进展与展望. 自动化学报, 2013, 39(11): 1858 – 1870.)
- [71] CLAEYS M, LATRE S, FAMAHEY J, et al. Design and evaluation of a self-learning HTTP adaptive video streaming client. *IEEE Communications Letters*, 2014, 18(4): 716 – 719.
- [72] WEI Q, LIU D, YANG X. Infinite horizon self-learning optimal control of nonaffine discrete-time nonlinear systems. *IEEE Transactions on Neural Networks and Learning Systems*, 2015, 26(4): 866 – 879.
- [73] RUSSELL S J, NORVIG P. *Artificial Intelligence: A Modern Approach*. Malaysia: Pearson Education Limited, 2016.
- [74] GAUDET B, LINARES R, FURFARO R. Deep reinforcement learning for six degree-of-freedom planetary powered descent and landing. *ArXiv Preprint*. 2018. arXiv: 1810.08719.
- [75] KOCH W, MANCUSO R, WEST R, et al. Reinforcement learning for UAV attitude control. *ArXiv Preprint*. 2018. arXiv: 1804.04154.
- [76] SU Z, ZHOU M, HAN F, et al. Attitude control of underwater glider combined reinforcement learning with active disturbance rejection control. *Journal of Marine Science and Technology*, 2018, DOI: 10.1007/s0077.
- [77] WILLIS S, IZZO D, HENNES D. Reinforcement learning for spacecraft maneuvering near small bodies. *AAS/AIAA Space Flight Mechanics Meeting*. Napa: AIAA, 2016: 14 – 18.
- [78] TURKOGLU K, SUN F. Reinforcement learning based continuous-time on-line spacecraft dynamics control: case study of nasa spheres spacecraft. *AIAA Guidance, Navigation, and Control Conference*. Florida: AIAA, 2018: 8 – 12.
- [79] ABBEEL P, COATES A, NG A Y. Autonomous helicopter aerobatics through apprenticeship learning. *The International Journal of Robotics Research*, 2010, 29(13): 1608 – 1639.
- [80] ABBEEL P. *Apprenticeship learning and reinforcement learning with application to robotic control*. California: Stanford University, 2008.
- [81] HWANGBO J, SA I, SIEGWART R, et al. Control of a quadrotor with reinforcement learning. *IEEE Robotics and Automation Letters*, 2017, 2(4): 2096 – 2103.
- [82] WU H, SONG S, YOU K, et al. Depth control of model-free AUVs via reinforcement learning. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2018, DOI: 10.1109/TSMC.2017.2785794.
- [83] CUI R, YANG C, LI Y, et al. Adaptive neural network control of AUVs with control input nonlinearities using reinforcement learning. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2017, 47(6): 1019 – 1029.
- [84] PALUNKO I, FAUST A, CRUZ P, et al. A reinforcement learning approach towards autonomous suspended load manipulation using aerial robots. *Proceedings of the IEEE International Conference on Robotics and Automation*. Karlsruhe: IEEE, 2013: 4881 – 4886.
- [85] FAUST A, PALUNKO I, CRUZ P, et al. Learning swing-free trajectories for UAVs with a suspended load. *Proceedings of the IEEE International Conference on Robotics and Automation*. Karlsruhe: IEEE, 2013: 4902 – 4909.
- [86] FAUST A, PALUNKO I, CRUZ P, et al. Automated aerial suspended cargo delivery through reinforcement learning. *Artificial Intelligence*, 2017, 247(7): 381 – 398.
- [87] KAHN G, VILLAFLOA A, PONG V, et al. Uncertainty-aware reinforcement learning for collision avoidance. *ArXiv Preprint*. 2017. arXiv: 1702.01182.
- [88] ZHANG T, KAHN G, LEVIN S, et al. Learning deep control policies for autonomous aerial vehicles with mpc-guided policy search. *Proceedings of the IEEE International Conference on Robotics and Automation*. Stockholm: IEEE, 2016: 528 – 535.
- [89] ZHAO F, ZENG Y, WANG G, et al. A brain-inspired decision making model based on top-down biasing of prefrontal cortex to basal ganglia and its application in autonomous UAV explorations. *Cognitive Computation*, 2018, 10(2): 296 – 306.

- [90] CHENG Y, ZHANG W. Concise deep reinforcement learning obstacle avoidance for underactuated unmanned marine vessels. *Neurocomputing*, 2018, 272(1): 63 – 73.
- [91] MA Z, WANG C, NIU Y, et al. A saliency-based reinforcement learning approach for a UAV to avoid flying obstacles. *Robotics and Autonomous Systems*, 2018, 100(2): 108 – 118.
- [92] HUNG S M, GIVIGI S N. A Q-learning approach to flocking with UAVs in a stochastic environment. *IEEE Transactions on Cybernetics*, 2017, 47(1): 186 – 197.
- [93] XU H, CARRILLO L R G. Fast reinforcement learning based distributed optimal flocking control and network co-design for uncertain networked multi-UAV system. *Proceedings of the SPIE 10195*. California: Unmanned Systems Technology XIX, 2017: 1019511-1 – 1019511-9.
- [94] KIUMARSI B, VANVOUDAKIS K G, MODARES H, et al. Optimal and autonomous control using reinforcement learning: A survey. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(6): 2042 – 2062.
- [95] KIUMARSI B, LEWIS F L. Output synchronization of heterogeneous discrete-time systems: A model-free optimal approach. *Automatica*, 2017, 84(10): 86 – 94.
- [96] LI J, MODARES H, CAHI T. Off-policy reinforcement learning for synchronization in multiagent graphical games. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28(10): 2434 – 2445.
- [97] JIANG Y, FAN J, CHAI T, et al. Tracking control for linear discrete-time networked control systems with unknown dynamics and dropout. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(6): 2042 – 2062.
- [98] JIANG H, ZHANG H, LUO Y, et al. Neural-network-based robust control schemes for nonlinear multiplayer systems with uncertainties via adaptive dynamic programming. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2018, DOI: 10.1109/TSMC.2018.2810117.
- [99] JIANG H, ZHANG H, XIAO G, et al. Data-based approximate optimal control for nonzero-sum games of multi-player systems using adaptive dynamic programming. *Neurocomputing*, 2018, 275(1): 192 – 199.
- [100] WANG D, LIU D, ZHANG Y, et al. Neural network robust tracking control with adaptive critic framework for uncertain nonlinear systems. *Neural Networks*, 2018, 97(1): 11 – 18.
- [101] LUO B, LIU D, HUANG T, et al. Multi-step heuristic dynamic programming for optimal control of nonlinear discrete-time systems. *Information Sciences*, 2017, 411(10): 66 – 83.
- [102] GAO W, HUANG M, JIANG Z, et al. Sampled-data-based adaptive optimal output-feedback control of a 2-degree-of-freedom helicopter. *IET Control Theory & Applications*, 2016, 10(12): 1440 – 1447.
- [103] GAO W N, JIANG Z P. Learning-based adaptive optimal tracking control of strict-feedback nonlinear systems. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(6): 2614 – 2624.
- [104] ZUO S, SONG Y, LEWIS F L, et al. Optimal robust output containment of unknown heterogeneous multiagent system using off-policy reinforcement learning. *IEEE Transactions on Cybernetics*, 2018, 29(6): 2042 – 2062.
- [105] SONG Y D, LEWIS F L, POLYCARPOU M, et al. Guest editorial special issue on new developments in neural network structures for signal processing, autonomous decision, and adaptive control. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28(3): 494 – 499.
- [106] WATKINS J C H C, DAYAN P. Genetic fuzzy based artificial intelligence for unmanned combat aerial vehicle control in simulated air combat missions. *Journal of Defense Management*, 2016, 6(144): 2167 – 0374.
- [107] LI B, ZHANG X, FANG Y, et al. Visual servoing of wheeled mobile robots without desired images. *IEEE Transactions on Cybernetics*, 2018, DOI: 10.1109/TCYB.2018.2828333.
- [108] CHEN J, ZHANG X, XIN B, et al. Coordination between unmanned aerial and ground vehicles: a taxonomy and optimization perspective. *IEEE Transactions on Cybernetics*, 2016, 46(4): 959 – 972.
- [109] HOU Z S, WANG Z. From model-based control to data-driven control: Survey, classification and perspective. *Information Sciences*, 2013, 235(6): 3 – 35.
- [110] TIAN Taotao, HOU Zhongsheng, LIU Shida, et al. Unmanned vehicle lateral control method based on model-free adaptive control. *Acta Automatica Sinica*, 2017, 43(11): 1931 – 1940. (田涛涛, 侯忠生, 刘世达, 等. 基于无模型自适应控制的无人驾驶汽车横向控制方法. *自动化学报*, 2017, 43(11): 1931 – 1940.)
- [111] XU X, CHEN H, LIAN C, et al. Learning-based predictive control for discrete-time nonlinear systems with stochastic disturbances. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(12): 6202 – 6213.
- [112] DOU R, DUAN H. Pigeon inspired optimization approach to model prediction control for unmanned air vehicles. *Aircraft Engineering and Aerospace Technology: An International Journal*, 2016, 88(1): 108 – 116.
- [113] ABBASPOUR A, ABOUTALEBI P, YEN K K, et al. Neural adaptive observer-based sensor and actuator fault detection in nonlinear systems: Application in UAV. *ISA Transactions*, 2017, 67(3): 317 – 329.
- [114] CHEN M, SHI P, LIM C C. Adaptive neural fault-tolerant control of a 3-DOF model helicopter system. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2016, 46(2): 260 – 270.
- [115] JIA F, LEI Y, GUO L, et al. A neural network constructed by deep learning technique and its application to intelligent fault diagnosis of machines. *Neurocomputing*, 2018, 272(1): 619 – 628.
- [116] HE M, HE D. Deep learning based approach for bearing fault diagnosis. *IEEE Transactions on Industry Applications*, 2017, 53(3): 3057 – 3065.
- [117] HUNDAM K, CONSTANTINOU V, LAPORTE C, et al. Detecting spacecraft anomalies using lstms and nonparametric dynamic thresholding. *ArXiv Preprint*. 2018, arXiv: 1802.04431.
- [118] MA J, NI S, XIE W, et al. Deep auto-encoder observer multiple-model fast aircraft actuator fault diagnosis algorithm. *International Journal of Control Automation & Systems*, 2017, 15(11): 1 – 10.
- [119] GUO D, ZHONG M, JI H, et al. A hybrid feature model and deep learning based fault diagnosis for unmanned aerial vehicle sensors. *Neurocomputing*, 2018, 319(11): 155 – 163.
- [120] CHE C, WANG H, NI X, et al. Fault fusion diagnosis of aero-engine based on deep learning. *Journal of Beijing University of Aeronautics and Astronautics*, 2018, 44(3): 621 – 628. (车畅畅, 王华伟, 倪晓梅, 等. 基于深度学习的航空发动机故障融合诊断. *北京航空航天大学学报*, 2018, 44(3): 621 – 628.)
- [121] FANG H, SHI H, DONG Y, et al. Spacecraft power system fault diagnosis based on DNN. *Prognostics and System Health Management Conference*. Harbin: IEEE, 2017: 1 – 5.
- [122] LU H, LI Y, MU S, et al. Motor anomaly detection for unmanned aerial vehicles using reinforcement learning. *IEEE Internet of Things Journal*, 2018, 5(4): 2315 – 2322.
- [123] XIE C H, YANG G H. Data-based fault-tolerant control for affine nonlinear systems with actuator faults. *ISA Transactions*, 2016, 64(9): 285 – 292.
- [124] KIM D, OH G, SEO Y, et al. Reinforcement learning-based optimal flat spin recovery for unmanned aerial vehicle. *Journal of Guidance, Control, and Dynamics*, 2016, 40(4): 1 – 8.

- [125] KARRAY F, ALEMZADEH M, SALEH J A, et al. Human-computer interaction: overview on state of the art. *International Journal on Smart Sensing and Intelligent Systems*, 2008, 1(1): 137 – 159.
- [126] 袁成. DARPA OFFSET项目最新进展. <http://www.dsti.net/Information/News/109091>, 2018.
- [127] KARAVAS G K, ARTEMIADIS P. On the effect of swarm collective behavior on human perception: towards brain-swarm interfaces.. *Proceedings of the IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems*. San Diego: IEEE, 2015: 172 – 177.
- [128] GAO S, WANG Y, GAO X, et al. Visual and auditory brain-computer interfaces. *IEEE Transactions on Biomedical Engineering*, 2014, 61(5): 1436 – 1447.
- [129] 王晓易. 清华大学: 智能机器狗表演“意识流”足球. <http://news.163.com/06/0615/07/2JL2JIMD00011229.html>, 2006.
- [130] LONG J, LI Y, WANG H, et al. A hybrid brain computer interface to control the direction and speed of a simulated or real wheelchair. *IEEE Transactions on Neural Systems & Rehabilitation Engineering*, 2012, 20(5): 720 – 729.
- [131] MING D, WANG K, HE F, et al. Study on physiological information detection and application evoked by motor imagery: Review and prospect. *Chinese Journal of Scientific Instrument*, 2014, 35(9): 1921 – 1931.
- [132] YU Y, ZHOU Z, YIN E, et al. A P300-based brain-computer interface for chinese character input. *International Journal of Human-Computer Interaction*, 2016, 32(11): 878 – 884.
- [133] LU Y, HU Y, LIU R, et al. The design of simulation vehicle system controlled by multichannel EEG based on imaginary movements. *Proceedings of the 35th Chinese Control Conference*. Chengdu: IEEE, 2016: 4976 – 4981.
- [134] KARRAY F, ALEMZADEH M, SALEH J A, et al. Human-computer interaction: overview on state of the art. *International Journal on Smart Sensing and Intelligent Systems*, 2008, 1(1): 137 – 159.
- [135] AL-KAFF A, MARTIN D, GARCIA F, et al. Survey of computer vision algorithms and applications for unmanned aerial vehicles. *Expert Systems with Applications*, 2018, 92(2): 447 – 463.
- [136] CARRIO A, SAMPERDRO C, RODRIGUEZ R A, et al. A review of deep learning methods and applications for unmanned aerial vehicles. *Journal of Sensors*, 2017, DOI: 10.1155/2017/3296874.
- [137] KIM I, MORRISON J R. Learning based framework for joint task allocation and system design in stochastic multi-UAV systems. *2018 International Conference on Unmanned Aircraft Systems*. Texas: IEEE, 2018: 324 – 334.
- [138] JIANG Y. A survey of task allocation and load balancing in distributed systems. *IEEE Transactions on Parallel and Distributed Systems*, 2016, 27(2): 585 – 599.
- [139] LOWE R, WU Y, TAMAR A, et al. Multi-agent actor-critic for mixed cooperative-competitive environments. *Advances in Neural Information Processing Systems 30*. Long Beach: Curran Associates, 2017: 6382 – 6393.
- [140] HONORABLE K M F, MARY J M. *Unmanned systems integrated roadmap FY 2011–2036*. US: Office of the Secretary of Defense, 2011.
- [141] HADAEGH F Y, CHUNG S J, MANOHARA H M. On development of 100-gram-class spacecraft for swarm applications. *IEEE Systems Journal*, 2016, 10(2): 673 – 684.
- [142] CHUNG S J, PARANJAPE A A, DAMES P, et al. A survey on aerial swarm robotics. *IEEE Transactions on Robotics*, 2018, 34(4): 837 – 855.
- [143] EVERETT M, CHEN Y F, HOW J P. Motion planning among dynamic, decision-making agents with deep reinforcement learning. *ArXiv Preprint*. 2018, arXiv: 1805.01956.
- [144] WANG J X, KURTH N Z, TIRUMALA D, et al. Learning to reinforcement learn. *ArXiv Preprint*. 2016, arXiv: 1611.05763.
- [145] DUAN Y, SCHULMAN J, CHEN X, et al. RL2: Fast reinforcement learning via slow reinforcement learning. *ArXiv Preprint*. 2016, arXiv: 1611.02779.
- [146] FINN C, ABBEEL P, LEVIN S. Model-agnostic meta-learning for fast adaptation of deep networks. *ArXiv Preprint*. 2017, arXiv: 1703.03400.
- [147] MIOTTO R, WANG F, WANG S, et al. Deep learning for healthcare: review, opportunities and challenges. *Briefings in Bioinformatics*, 2017, 18(6): 1236 – 1246.
- [148] ZHAO G, ZHANG G, GE Q, et al. Research advances in fault diagnosis and prognostic based on deep learning. *Prognostics and System Health Management Conference*. Chengdu: IEEE, 2016: 1 – 6.
- [149] LEI Y, JIA F, LIN J, et al. An intelligent fault diagnosis method using unsupervised feature learning towards mechanical big data. *IEEE Transactions on Industrial Electronics*, 2016, 63(5): 3137 – 3147.
- [150] LIU R, YANG B, ZIO E, et al. Artificial intelligence for fault diagnosis of rotating machinery: A review. *Mechanical Systems and Signal Processing*, 2018, 108(8): 33 – 47.
- [151] NIKFARJAM A, SARKER A, O'CONNOR K, et al. Pharmacovigilance from social media: mining adverse drug reaction mentions using sequence labeling with word embedding cluster features. *Journal of the American Medical Informatics Association*, 2015, 22(3): 671 – 681.
- [152] CROWLEY J. Put that there: 20 years of research on multimodal interaction. *Proceedings of the 2018 on International Conference on Multimodal Interaction*. Colorado: ACM, 2018: 4 – 4.
- [153] WANG Dangxiao, ZHENG Yilei, LI Teng, et al. Multi-modal human-machine interaction for human intelligence augmentation. *Scientia Sinica Informationis*, 2018, 48(4): 449 – 465. (王党校, 郑一磊, 李腾, 等. 面向人类智能增强的多模态人机交互. *中国科学: 信息科学*, 2018, 48(4): 449 – 465.)

作者简介:

赵欣怡 博士, 目前研究方向为智能决策与规划, E-mail: zhaoxin yizhf@163.com;

宗群 教授, 目前研究方向为飞行器建模控制与仿真、耦合复杂航天器容错控制与星群编队控制、多无人系统智能自主协同控制等, E-mail: zongqun@tju.edu.cn;

张睿隆 博士, 目前研究方向为智能控制与脑机接口, E-mail: 839267975@qq.com;

田栢苓 特聘研究员, 目前研究方向为面向安全域的RLV轨迹姿态协同、基于群体智能的集群协同控制与基于人工智能的自适应自主学习控制等, E-mail: bailing_tian@tju.edu.cn;

张秀云 博士, 目前研究方向为智能故障诊断与容错控制, E-mail: zxy_xy_11@tju.edu.cn;

冯聪 硕士, 目前研究方向为多模态人机交互, E-mail: fc2012 auto@tju.edu.cn.