基于脉冲神经网络的智能控制研究进展

刘晓德, 郭宇飞, 黄旭辉, 马 喆[†]

(航天科工集团智能科技研究院有限公司,北京 100043)

摘要: 近些年, 具备低功耗、高鲁棒、融合时空信息等优势的脉冲神经网络(SNN)在类脑研究与智能控制的交叉领域方兴未艾. 基于脉冲神经网络架构的智能控制方法是实现与环境自主交互并且高能效完成复杂控制任务的有效途径之一. 为此, 本文首先介绍了SNN的基本要素与研究动机; 然后, 详细介绍了近年来基于脉冲神经网络智能控制的研究进展以及在机器人、无人车、无人机等领域的应用情况; 接着, 总结了一些现有的硬件平台, 用以实现SNN算法的高效能实现; 最后, 总结展望了SNN控制发展的机遇与挑战. 本文旨在梳理出SNN控制发展的技术脉络, 为其快速发展提供借鉴与思路.

关键词:脉冲神经网络;深度学习;神经网络与智能控制;神经形态计算

引用格式: 刘晓德, 郭宇飞, 黄旭辉, 等. 基于脉冲神经网络的智能控制研究进展. 控制理论与应用, 2024, 41(12): 2189-2206

DOI: 10.7641/CTA.2024.30330

Research advance in intelligent control based on spiking neural networks

LIU Xiao-de, GUO Yu-fei, HUANG Xu-hui, MA Zhe[†]

(Intelligent Science & Technology Academy of CASIC, Beijing 100043, China)

Abstract: In recent years, spiking neural networks (SNN) have garnered significant attention in the fields of braininspired learning and intelligent control due to their advantages in energy efficiency, robustness, and the ability to incorporate spatial-temporal information. In the field of brain-inspired learning and intelligent control, SNN architectures have shown promise in achieving complex control tasks with autonomous interaction with variations in the environment. This paper presents a comprehensive review of the development of intelligent control based on SNN and systematically summarizes relevant SNN control applications. Firstly, the basic concept of SNN, as well as the motivations and advantages of intelligent control based on SNN, is briefly introduced. Subsequently, the research progress of intelligent control based on SNN in recent years and its applications in fields such as robotics, unmanned vehicles, and unmanned aerial vehicles are systematically reviewed. Additionally, we summarize some hardware platforms that enable efficient implementation of SNN algorithms. Finally, the opportunities and challenges associated of SNN control are discussed. The purpose of this paper is to provide a technical framework for intelligent control based on SNN approach, and facilitate its rapid development and application.

Key words: spiking neural networks (SNN); deep learning; neural network and intelligent control; neuromorphic computing

Citation: LIU Xiaode, GUO Yufei, HUANG Xuhui, et al. Research advance in intelligent control based on spiking neural networks. *Control Theory & Applications*, 2024, 41(12): 2189 – 2206

1 引言

以神经网络为代表的人工智能深刻改变了人类社 会的发展,并越来越多地应用于机器人技术,如目标 感知^[1]、路径规划^[2-3]、智能决策^[4]和端到端控制^[5]. 研究通过构建神经网络模型来不断借鉴与发掘生物 智能^[6-7],以期逐步接近甚至超越人类的智能水平.近 些年,随着自动驾驶、无人机等智能无人系统的快速 发展,人们对系统自主控制有了更高的需求,具体表 现为^[1,8]:高维数据传感器融合和降维功能、以低延迟 和高能效处理冗余或稀疏信息、在动态复杂环境中自

收稿日期: 2023-05-17; 录用日期: 2024-02-09.

[†]通信作者. E-mail: mazhe_thu@163.com; Tel.: +86 10-88534360.

本文责任编委: 曾志刚.

国家自然科学基金项目(12202413, 12202412)资助.

Supported by the National Natural Science Foundation of China (12202413, 12202412).

主学习控制策略、对于高维控制形成稳健和通用的解 决方案、解释和预测人类的行为以及融合前面能力, 实现高级任务规划.

随着智能控制理论和人工神经网络的快速发展, 控制的精度和鲁棒性得到了很大的提升. 然而, 控制 性能的提升主要局限于受控环境中执行可编程和重 复的任务. 面对变化和不可预测的动态环境, 实现具 备上述能力的自主控制仍然面临不小挑战. 比如在 人-机协作场景中, 个体和环境状态可能会随时间和 任务发生变化, 机器人的自适应协作能力显得至关重 要^[9]; 在大多数交互式应用中, 机器人需要在短时间 内对突发环境变化做出反应. 虽然以人工神经网络为 代表的智能控制在环境适应性和鲁棒性方面表现出 色, 但该方法存在训练时间长、能耗大、响应延迟高等 缺点^[8], 在复杂环境中实现自适应控制仍面临一定困 难.

脉冲神经网络(spiking neural network, SNN)被誉为"第3代人工神经网络",以异步事件策略高效地编码数据信息,具有时空并行处理机制、异步计算、记忆和自学习能力等优势^[10].研究表明:脉冲神经网络一定程度上可以弥补经典控制理论面临的难题^[11].在硬件层面,随着芯片设计的功耗墙问题日趋严重^[12],许多研究打破传统的冯诺依曼式计算硬件架构,发展存算一体的低功耗神经形态硬件,如Loihi^[13]、天机芯^[14]等,有效提升了复杂任务下的高能效自主控制性能.

目前,只有很少系统总结基于脉冲神经网络智能 控制的英文综述论文[8,11],中文综述论文还尚未发现 有相关报道.虽然有几篇中文综述系统介绍了脉冲神 经网络研究进展[15-17],但并未侧重关注脉冲神经网络 在智能控制方面的发展与应用前景.因此,笔者认为 迫切需要对基于脉冲神经网络控制的最新文献及研 究发展进行全面总结、归纳和评述,并分析其面临的 挑战和未来发展机遇.本文聚焦近些年来基于脉冲神 经网络的智能控制模型、算法、应用研究和硬件平台 发展概况,系统梳理SNN智能控制近5年来的技术发 展,总结代表性的算法和几个主要的应用方向.本文 将SNN智能控制相关研究归纳为从理论到模型、从算 法到应用两个方向,如图1所示.然后,重点关注不同 控制算法在各个任务上的表现性能. 第2节简要介绍 脉冲神经网络控制的相关的背景与动机; 第3节详细 介绍了脉冲神经网络控制在模型算法方面的研究进 展,之后介绍了脉冲神经网络控制相关的应用(第4节) 及硬件平台(第5节)等方面的研究.最后,总结和展望 了脉冲神经网络控制的挑战及未来发展方向.本文的 主要贡献概括如下:

1) 提出一种新的SNN控制的分类方法,将现有的 SNN控制研究工作进行了系统归纳总结;

2) 比较分析了SNN控制算法的主要研究方向,重 点关注其在不同测试任务上的表现;

并展望了未来的研究方向.

3) 指出了当前SNN控制研究存在的挑战和机遇,

```
无人车自主
导航控制
    突触可塑性理论
               脉冲神经网
络主要算法
                                                机器人运动控制
模型
                           网络组成
                                      相关应用
                                                                   应用
     网络拓扑结构
                                                无人机姿态控制
                                                           仿生控制
    生物合理性与计算有效性平衡
                           基本要素
                                      硬件平台
                                                 离线学
习平台
                                                       在线学
习平台
                                                             FPGA
    神经元模型
            脉冲编码方式
    梯度消失
           模型训练开销大
                                                          突触可塑性
                                                 强化学习方法
理论
                        理论与模型训练挑战
                                      算法研究
                                                                   算法
          信息损失
                                                 PID控制方法
                                                           其他方法
                          基于脉冲神经网络的智能控制
```





2 背景与动机

基于脉冲神经网络的智能控制方法研究属于交叉 学科领域,其发展与以脉冲神经网络为代表的类脑智 能和以神经网络控制为代表的智能控制密切相关.本 节主要介绍脉冲神经网络的相关基本要素以及研究 动机.

2.1 脉冲神经网络简介

脉冲神经网络以神经元作为基本单元,借鉴大脑 神经网络结构对信息的处理机制,通过脉冲的形式传 递信号,结合脉冲序列在网络中的编码方式、突触可 塑性理论以及网络拓扑结构实现对数据的整合和处 理,通过模型训练和推理完成相应的目标识别、检测 及控制决策等任务.脉冲神经网络通常由神经元模 型、脉冲编码方式、网络拓扑结构、学习算法等要素 构成.

2.1.1 神经元模型

神经元是生物接收刺激、传导冲动和整合信息的 基础. 生理学上主要包括树突、胞体和轴突3部分. 树 突是神经元的感受区,负责接收信号并传入胞体;胞体起到中央处理器的作用,当输入电流累计使神经元 膜电位超过某个固定阈值时产生动作电位(即脉冲信 号);轴突负责将胞体处理的信息传递到其他神经元的 突触上.两个神经元之间的信息交换通过突触来实现. 根据脉冲神经元不同的动态特征,研究建立了多种神 经元模型,并且评估了不同神经元的算力实现与生物 合理性情况^[18],如图2所示.神经元模型的模拟是生 物合理性与计算效率之间的一个平衡.虽然H-H(Hodgkin-Huxley)模型能够精确描述动作电位的变化,但 在大规模神经网络层面上无法实现.脉冲神经元两种 模型(leaky intergrate and fired, LIF)和(intergrate and fired, IF)采取了不同程度的简化,在SNN的神经元模 拟中得到了广泛的应用.





2.1.2 脉冲编码方式

理解大脑的运作方式,除了依赖于近似神经元模 拟,还需要进一步解释大脑对信息的编码、加工和解 码机理. 现已发展出的编码方式主要包括频率编码 (rate coding)、时间编码(temporal coding)、群体编码 (population coding)和Bursting编码等. 频率编码主要 由神经元的脉冲发放频率来表征,更强烈的脉冲刺激 将导致更高频的脉冲发放频率.研究发现该方法在 人工神经网络(artificial neural network, ANN)转SNN 的深度学习领域具有良好效果[15]. 但该方法仅计算脉 冲数量,忽略了序列内部的时间结构,不利于信息的 高效传输.时间编码方案充分考虑了时间结构上的差 异,脉冲发放的时间序列用来编码神经元之间传递的 信息. 群体编码理论认为刺激产生的信息是由多个神 经的共同活动所表征的,群体中每个神经元都具有捕 获部分编码信号的感受野.相关研究表明它能够更好 的代表刺激^[19],特别是在基于SNN方法的高维监督学 习任务方面取得一定的突破^[20-21]. Bursting编码是基 于大脑中存在的Bursting模式,即神经元在某个时间 段内密集、快速的激发脉冲,之后进入较长时间静息 的行为. 该方法可以增加神经元间信息传递的可靠性 和选择通信的特异性^[15].

神经编码理论还在不断发展和完善,不同的控制 任务往往也需要选择合适的编码方式.从大脑的实际 生理功能来看,同一种任务中可能也存在多种信息 编码方式,相互配合为信息感知提供编码基础.目前 SNN模型大都基于单一的编码方案,存在信息损 失^[22]、单个脉冲神经元编码精度低等问题^[23].明确各 种编码方式在不同任务下的优劣,发展适合于混合编 码的SNN理论模型仍是需要研究的问题.

2.1.3 突触可塑性理论

大脑如何学习和记忆是人类一直关注的问题.古 往今来众多学者从哲学、心理学乃至神经科学角度进 行了不同的解释.其中科学领域影响最大、应用最为 广泛的是Hebb于1949年提出的突触可塑性理论.该理 论认为神经元突触之间的信息传递效率存在差异,这 种差异可以通过神经间的联系来动态调节.由此对大 脑如何学习与记忆给出如下假设: 当细胞A重复或者 持续地参与激活细胞B时, A, B细胞间的联系会加强, 反之A, B细胞间的联系会减弱. 海马体中的长时程增 强作用(long-term potentiation, LTP)和长时程抑制作 用 (long-term depression, LTD) 研究证实了相关假说, 并在鼠、猫等动物突触、神经元连接相关研究中得到 证实^[24]. 其中, 脉冲时间的突触可塑性规则(spiketiming dependent plasticity, STDP)^[25]通过引入时间尺 度成功揭示了突触间连接的强弱变化过程,进一步丰 富和发展了原先的Hebb学习规则.STDP作为自动修 改突触权重过程的一种无监督学习算法,逐步发展 出R-STDP^[26-28], sym-STDP^[29]等多种基于脉冲神经 网络的理论方法.其中,基于奖励值的R-STDP网络与 强化学习结合,在SNN控制方面得到了较为广泛的研 究.这部分将在后面第2章、第3章节详细介绍.

2.1.4 网络拓扑结构

网络拓扑结构是算法的骨架,针对不同问题往往 需要选择不同的神经网络架构.脉冲神经网络架构目 前主要沿袭了传统神经网络,可分为静态结构和动态 结构两种^[16].静态结构是指网络的神经元数量、突触 数量和各层结构不变,突触权重改变即是网络学习的 过程,包括多层全连接网络结构、循环网络结构和卷 积网络结构;动态结构是指网络中的神经元数量和连 接都可以改变,以进化脉冲神经网络为典型代表.几 种常见的神经网络如图3所示.其中,多层全连接结构 网络规模较小,训练相对容易,并且契合输出量较少 的控制任务需求,目前较多应用在基于脉冲神经网络 的智能控制当中.卷积神经网络领域发展迅速,出现 了多种里程碑式的网络结构,如Resnet^[30],VGG^[31], Denset^[32], Alexnet^[33]等,在检测、识别、跟踪等多个 任务中性能出众.基于卷积神经网络的SNN结构也大都基于经典SNN方法.目前ANN转SNN方法已经较为成熟,通过将特定网络结构转为脉冲形式,接近或者实现了同卷积 ANN 相同的性能^[34].但经过转换后SNN模型的准确度和延迟之间存在互相制约的关系^[35],限制了SNN模型训练精度的提升.





2.1.5 学习算法

根据机器学习的主流分类方法,脉冲神经网络的 学习算法可分为监督学习、无监督学习和强化学习3 大类.其发展历程如图4所示.监督学习算法研究相对 较多,常见的主要分为基于梯度下降规则、基于脉冲 卷积方法、基于突触可塑性的监督学习和脉冲神经网 络的进化算法^[36];无监督学习算法主要是基于Hebb, STDP等突触可塑性规则完成脉冲神经网络的权值及 结构调整;基于强化学习的脉冲神经网络算法将强化 学习的策略生成优势与脉冲神经网络的高能效、高鲁 棒性优势相结合.结合前面研究来看,对于优化控制, 目前大都使用强化学习和以STDP为代表的无监督学 习相结合开展模型设计;对于以PID为代表的反馈控 制,模型多基于有误差反馈的监督学习进行构建.

监督学习算法最为经典的方法之一是梯度下降与 误差反向传播算法结合^[37].借鉴这一思想,Bohte等 人^[38]首次将梯度下降法应用在多层前馈脉冲神经网 络当中,称为SpikeProp算法.后续又发展出若干基于 SpikeProp算法的改进,如考虑限制输出层神经元发放 次数^[39]、整个网络结构不限制脉冲发放个数^[40]等.随 着误差反向传播算法在深度神经网络中的广泛应用, 陆续有研究将其应用到SNN卷积网络中,围绕脉冲形 式函数不可导的问题,通过膜电势改变^[41]、近似脉冲 函数梯度^[42]、优化神经元^[43]等方式直接训练深度 SNN卷积网络.相关系统性研究见于Neftci^[44]等人 的工作.值得注意的是,基于误差反传直接训练深层 SNN存在不同程度的信息损失问题^[22],在一些数据集 测试性能上不及ANN^[15].

无监督学习算法主要借鉴前面提到的突触可塑性 理论,通过构建合适的STDP网络结构来模拟大脑的 学习与记忆功能.研究表明^[45],基于STDP构建的无监 督学习网络在一些多维数据任务上的性能要优于深 度卷积网络AlexNet.基于STDP规则的多层卷积网络 用于特征提取,并结合支持向量机进行分类器有监督 训练,在MNIST数据集上达到了准确率为98.4%的水 平^[46].

强化学习作为一种更具生物学基础的学习范式, 通过智能体与环境不断交互的方式优化生成策略,以 奖励值的形式反映算法性能及目标任务完成的优劣, 在基于脉冲神经网络的控制决策任务方面表现出巨 大的潜力[23,47-48]. 强化学习有多种分类方法, 其中最 常见的分为基于价值(value-based)的方法和基于策略 (policy-based)的方法. 基于价值的典型算法为Q-learning,将Q函数优化到最优,再根据Q函数选取最优策 略,如DQN算法、DDPG算法;基于策略算法的典型代 表是策略梯度法,通过优化函数来不断迭代策略状态 空间,如Actor-Critic 算法. Tang 等人^[23]在OpenAI Gym环境中将脉冲神经网络与多种强化学习(TD3, DDPG, SAC)方法融合, 通过训练运动反馈的奖励值 实现了对多个自由度物体的连续运动控制,并且在神 经形态芯片Loihi上表现出显著低功耗的优势;最近, Chen 等人^[49]将 SNN 与 DQN 算法融合,提出了一种 DSQN算法,通过非脉冲神经元的最大膜电压表示 Q值来训练脉冲神经网络.该算法对游戏噪声具有较强的鲁棒性,在部分Atari游戏上的性能优于人工神经

网络构建的DQN算法. 类似的结论也在研究中^[47]得到了验证.



Fig. 4 Development of spiking neural networks (left) and the main algorithms (right)

2.2 研究动机

研究表明:脉冲神经网络控制可以充分借鉴大脑 信息处理及调控机制,在速度能效、计算能力和信息 编码方面表现出强大的生物神经学基础^[21].多个研 究^[8,50]证实了脉冲神经网络在控制方面具有天然优 势.2019年11月,普渡大学的Kaushik Roy, Akhilesh Jaiswal和Priyadarshini Panda^[10]在Nature发表长文综 述,概述了神经形态计算的主要挑战以及发展前景. 2022年2月, Nature Communications发表最新综述文 章"具身神经形态智能",指出了类脑智能在科研和工 业研究方向^[51].相比依赖现有冯诺依曼硬件架构的智 能控制方法,脉冲神经网络控制能够使用相对少量的 脉冲来充分处理信息,以驱动学习和行为^[52],具有低 功耗、高鲁棒等优势^[36].

然而,基于脉冲神经网络的智能控制作为一个多 学科交叉的研究领域(包括类脑智能、控制方法、计算 机科学、系统仿真等学科),目前还没有形成较为完整 且成熟的理论体系,应用层面控制的运动自由度规模 较小^[53-54].为了能够对本领域发展有所帮助,本文系 统总结了脉冲神经网络控制研究的理论框架及研究 现状,旨在帮助读者较快构建起对脉冲神经网络控制 的完整知识体系,为进一步发展后续研究提供借鉴和 帮助.本文的研究动机主要包括两个方面.

1) 经典控制方法发展面临的挑战.

经典控制方法针对确定、可建模的实际工程任务 在控制精度、实时性和鲁棒性方面已取得显著成果. 然而,面向复杂任务场景及控制模型未知的情况,现 有控制方法仍面临诸多挑战.第一,随着自动驾驶、无 人机集群协同等控制任务越来越复杂,控制对象与环 境的强非线性及参数变化的不确定性对控制精度、实 时性等性能的影响愈发严重;第二,一些复杂控制任 务对系统的实时性、可靠性和鲁棒性等各方面都提出 了更高的要求,研究对象逐步从被控对象到控制器本 身进行转换,高维控制问题成为研究的热点与难点; 第三,复杂任务场景下的模型不确定、高度非线性等 特征,要求控制器具备实时故障诊断及部分机构失效 情况下正常完成任务的能力;第四,在特定场景下控 制单元的相对自主化、独立化对边缘计算、嵌入式设 备的能效提出了更高的要求.

2) 脉冲神经网络对智能控制领域带来的机遇.

随着摩尔定律逐步失效,功耗墙、存储墙问题日益 突出^[55],基于非冯诺依曼架构的神经形态计算芯片近 些年获得了快速发展.融合脉冲神经网络和神经形态 硬件平台的系统为智能控制发展也带来了新的增益: 一是与感知、决策深度融合.随着控制对象和任务的 复杂化,完整的闭环控制系统往往需要与目标感知、 信息融合、认知决策高度耦合^[51].脉冲神经网络与神 经形态硬件二者结合有望实现低功耗优势下的从感 知到决策控制的深度融合,形成感知、规划、决策与控 制一体化的智能体;二是对于无法搭载大型计算设备 的机器人系统,在未知环境、变化场景的自适应控制 方面有望构建低功耗、高鲁棒的控制系统.脉冲神经 元内在的时空动力学特性使得感觉运动事件的时间 模式能够比其他联结主义模型更有效地捕捉和利 用^[56].此外,脉冲神经网络相比传统神经元模型可以 更容易地映射到硬件.因为脉冲本质上是二进制事件, 非线性动力学和脉冲电路的编码可以通过脉冲时间 来提供,而非传统神经元模型中的非线性实值激活函 数.同时,脉冲神经网络适合部署到内存和电源都非 常有限的微纳米级自主机器人的控制上,更契合在微 级和纳米级平台上进行高级机器人开发^[50].

3 脉冲神经网络控制算法研究进展

基于脉冲神经网络的智能控制方法通过选择合适 的神经元、突触模型来调整和优化网络参数,通过构 建全连接、卷积等网络结构实现对特定目标任务的自 主控制.一种典型的脉冲神经网络控制框架如图5所 示.根据脉冲神经网络的算法及架构设计方式不同,可 以大致将其分为3类:第1类是将脉冲神经网络与强化 学习算法结合,借助强化学习在自主策略生成方面的 优势,构建特定场景下的智能控制模型;第2类是与经 典控制方法,如PID结合,通过比较相同任务完成的性 能,来发掘脉冲神经网络控制的潜力;第3类是结合其 他算法,如遗传算法^[57]、卡尔曼滤波^[58]、STDP^[25]等 来优化网络参数,在控制的实时性、鲁棒性方面实现 更优的性能.下面依次介绍在这3个方面的研究进展.



Fig. 5 A typical spiking neural network control framework

3.1 基于强化学习的脉冲神经网络控制模型

强化学习可以认为是一种直接自适应的最优控制 方法[59],在自然界有着广泛的生物学基础.强化学习 思想最早可追溯到行为心理学研究.其中效果律(law of effect)表明:一定情景下让动物感到舒服的行为, 就会与此情景增强联系(强化),当此情景再现时,动物 的这种行为也更易再现,反之则相反.受这种生物对 环境的适应性启发,强化学习通过不断试错的方式与 环境交互,完成从环境状态映射到个体动作的学习, 实现累计回报期望的最大化[60].强化学习建模通常用 马尔科夫决策过程 (markov decision process, MDP)来 表示,由4个基本部分构成:状态s、动作a、个体策略 π 和奖励信号r.其过程可表示为:智能体在状态st下, 根据策略 π 选择动作 a_t ,并据此从状态 s_t 转移到新的 状态s_{t+1},同时获得环境反馈的奖励r.根据奖励r获 得最优策略π*. 近些年, 研究将具有感知能力的深度 学习和具有决策能力的强化学习结合在一起,并通过 端到端的方式实现了从原始输入到结果的实时输出, 在图像分类[61]、语音识别[62]、游戏博弈[4,47]、机器人 控制[63-64]等领域取得了令人曙目的成就. 近期, 国内 陈鼎等人[65] 梳理了脉冲神经网络与强化学习相结合 的算法研究,将其分为两类:一是理解和发掘大脑中 的奖励学习机制:二是以实际控制任务的性能、功耗 为目标,探索脉冲强化学习算法在功耗、鲁棒性等方面的优势.许多研究将强化学习的决策优势与脉冲神经网络的能效优势结合,提出了许多新的理论方法和网络架构.如研究^[66-67]关注将连续时序差分学习扩展到以包含脉冲神经元的Actor-Critic强化学习网络中,实现了对连续状态和动作的表征.借助深度学习网络的优势,Patel等人^[47]将训练好的DQN算法转化为SNN,并且在若干Atari游戏性能中保持甚至超越了人类水平.图6表示一种典型的脉冲神经网络与强化学习相结合的控制框架.

结合强化学习的脉冲神经网络控制模型大致可分为两类:一是借助Gym, ROS, V-rep, Gazebo等虚拟环境,通过构建SNN与强化学习的网络架构,在仿真平台上进行模型算法及网络结构的检验;二是首先在虚拟环境中训练好模型,然后迁移到实际环境中,与传统算法对比进而验证其性能.代表性的工作如美国罗格斯大学的计算脑实验室.Tang等人^[23]将利用脉冲群体编码的优势,将深度强化学习与脉冲神经网络架构融合,用于实现高维连续运动控制.其效果在Gym中的Mujoco物体控制中得到了验证.之后,借助ROS与Gazebo联合仿真,他们将SNN的决策控制方法应用到无地图导航研究当中^[48].首先在虚拟环境中训练,然后迁移到实体环境中进行自主导航验证.通过对比

在传统硬件与神经形态硬件Loihi的功耗情况,验证了 脉冲神经网络用于连续运动控制的低功耗优势.类似, Mahadevuni等人^[27]将强化学习与脉冲神经网络结合 用以实现机器人在未知环境中导航到已知目标位置, 结果表明该方法能够显著缩短导航时间.

同时,也有许多研究关注SNN与强化学习结合在 经典Atari游戏上的表现.如Patel等人^[47]通过游戏训 练性能表明基于ReLU训练好的ANN可以在不降低性能情况下转为SNN,并且SNN中脉冲神经二值性质对遮挡攻击表现出更好的鲁棒性.同时,当输入数据有噪声和潜在的误导性时,基于SNN的DQN方法在某些游戏表现上要比基于ReLU的神经网络表现更好.表1 汇总了SNN结合强化学习及突触可塑性算法的研究进展.



Fig. 6 A control framework of combination spiking neural networks and reinforcement learning. DRL: deep reinforcement learning

3.2 结合PID控制的脉冲神经网络控制模型

脉冲神经网络应用到智能控制研究领域,一个重要的问题是其性能相比经典控制方法有无提升?或是与经典控制方法相结合,有没有新的增益?近些年,许多研究开展了脉冲神经网络与经典控制方法的深度融合.苏黎世大学相关研究团队做了许多开创性的工作.Stagsted等人^[53-54]首次在神经形态硬件上使用 PID控制,控制器的P,I和D增益作为突触权重实现,可根据芯片可塑性规则进行调整,其控制网络架构如 图7所示.该方法在神经形态芯片Loihi上得到了实现, 在单个自由度的无人机和无人车控制性能方面与传统方法相当,同时表现出显著低功耗和低延迟的优势.

研究^[68]指出,在实时传感、高维控制以及机器学 习技术的推动下,基于SNN的智能控制在能效、对扰 动的鲁棒性和对不同条件的适应等方面都优于传统 控制范式.该研究融合激光雷达数据,提出了基于PID 方法的Nengo神经形态控制模型,用以实现静态和动 态环境下的转向和避障.同样,文献[69]中的研究提 出了一种在混合信号神经形态硬件上实现的全脉冲 闭环PI控制器.控制器根据所需的速度或位置,将脉 冲频率调制(pulse frequency modulation, PFM)技术集 成到脉冲神经网络系统中,用以控制单个电机的运动, 结果达到了97.1%的控制精度与75.8 ms的平均延迟. Jimenez-Fernandez等人^[70]将控制系统融合激励和传 感器信息作为脉冲流,在FPGA上实现了基于脉冲数 据和神经网络的PID控制.

3.3 其他脉冲神经网络控制模型

由于脉冲神经网络理论还处于发展阶段,许多研 究将它与其他算法结合来研究智能控制方面的性能. Dethier等人^[71]在NEF神经形态框架下^[72],把脉冲神 经网络与卡尔曼滤波结合,将控制理论算法映射到基 于脉冲神经元的计算结构上,基于动物脑--机接口实验与标准卡尔曼滤波控制器进行对比,验证了该方法在临床资源受限条件下的应用潜力. Zhang等人^[73]提出了一种基于脉冲的间接训练方法,通过类似 STDP规则的脉冲来诱导突触权值的变化. 在没有任何先验信息的情况下实现了在障碍物密集仿真环境中的自主导航. 同样,研究^[74]基于突触可塑性规则和进化策略来训练脉冲神经网络,实现了不同运动模式的自主生成与转换. Hagras等人^[50]结合遗传算法提出了一种自适应方法,通过与真实环境的交互在线进化SNN网络权重,在少量世代内即收敛到机器人完成所需任务的解,并且与模糊控制器相比表现出更平滑的响应.

此外,也有研究关注基于SNN的非线性控制理论 方法. Perez等人^[75]采用进化算法进行监督学习,用于 优化神经网络的结构和大小,在较少神经元和连接数 的情况下实现了非线性系统控制. Qiu等人^[76]使用拓 扑进化算法来解决连续域中的非线性控制问题,与sigmoidal神经网络相比,所提出的控制模型可以更快地 发现函数解. Gilra等人^[77]提出了一种差分前馈脉冲 网络结构,通过突触可塑性规则来学习非线性电机的 逆模型,从状态轨迹推断产生轨迹的连续时间命令, 在双连杆臂测试中表现出比前馈和递归算法更低的 测试误差. 表2汇总了结合PID及其他算法的相关研 究.

4 脉冲神经网络控制的应用研究

鉴于SNN在功耗、鲁棒性方面的优势,许多研究 面向实际应用设计了基于SNN的控制器,结合模拟仿 真平台或者神经形态硬件完成试验验证.本节主要围 绕机器人运动控制、无人车自主导航控制、无人机姿 态控制和仿生控制等4个方面对已有研究进行总结, 以帮助读者加深对脉冲神经网络控制方法的理解.

Table 1 Summary of research on combination of reinforcement learning and synaptic plasticity algorithms 采用算法 作者(时间) 神经元模型 控制对象/任务 网络规模 控制输出值 性能验证 Gym环境自主 三层全连接 Loihi, Tang (2021)^[23] LIF模型 依模型而定 TX2 连续控制 网络 Turtlebot2无地图 五层全连接 Loihi, RL Tang (2020)^[48] LIF 模型 左/右轮速度 网络 自主导航 TX2 三层 四个最优 Patel (2019)^[47] IF模型 Atari游戏控制 仿真环境 SNN结构 动作估计值 Izhikevich 自主控制四 两层全连接 四个关节 iCub Bouganis (2010)^[81] 运动指令 机械臂 简化模型 自由度机械臂 网络 Izhikevich 迷宫中避障和 输入输出 Xue (2014)^[82] 左/右轮转速 FPGA 模型 及隐藏层 目标搜索 STDP 自主避障和 三层七个 Zhang (2013)^[73] LIF模型 左/右轮速度 仿真环境 导航控制 神经元结构 Izhikevich 模拟经典条件 七个神经元 乐高 Lobov (2020)^[83] 左/右轮速度 模型 反射任务 互连结构 机器人 Gym中CartPole Hasegan (2021)^[84] IF模型 三层SNN结构 左/右运动 仿真环境 平衡控制 Izhikevich 自主导航和 两层全连接 Mahadevuni (2017)^[27] 左转或右转 仿真环境 模型 避障任务 结构 Izhikevich 两自由度 三层七个 两个弯曲 Spüler (2015)^[85] 仿真环境 简化模型 手臂控制 神经元 角度 小车轨迹目标 左右两个 Bing (2018)^[86] LIF模型 两层SNN 仿真环境 RL+STDP 跟踪控制 速度 一个转弯 蛇形机器人 三层全连接 Bing (2019)^[87] LIF模型 仿真环境 目标跟踪控制 网络 半径值 IF和LIF 自主导航 三层全连接 左右角速度 Bing (2019)^[88] 仿真环境 模型 和避障控制 网络 和一个判别值 IF和LIF 避障和 三层SNN 左右距离 Liu (2021)^[89] 仿真环境 目标的角度 模型 目标跟踪 结构 移动机器人 三层前馈 向左或向 Shim (2017)^[26] LIF模型 仿真环境 导航 网络 右移动 多足机器人 四足或 仿生六足 Takase (2015)^[74] SRM模型 未提及 六足 机器人 控制 三层SNN 未知环境下 左右前后 Cao (2015)^[90] Hebbian规则 SRM模型 仿真环境 结构 四个值 目标跟踪 三层十个 Wang (2008)^[91] IF模型 机器人避障 左/右角速度 仿真环境

4.1 机器人运动控制

移动机器人通常在非结构化和动态的环境中工作, SNN信息传递的时空特性比ANN更适合用于机器人 的控制器设计^[78]. Floreano等人^[56]通过遗传算法来优 化SNN的权重和结构,用于实现基于视觉的机器人自 主控制.类似地,Alnajjar等人^[79]设计了一种基于SNN 的分层自适应控制器,在动态环境中实现了最优导航. Cyr等人^[80]基于突触可塑性和循环神经网络设计了不 同的SNN学习规则,成功实现了运动机器人的实时控 制. iCub是一种类人机器人,同时支持基于事件驱动的视觉传感器和神经形态传感器.基于这一特性,许多学者开展了融合SNN的iCub机器人控制系统的研究.Gamez等人^[97]提出了基于脉冲神经网络模拟器和 iCub类人机器人之间的接口程序iSpike,用以将机器 人的感觉信息转换为神经网络模拟器的输入,随后, 从网络中提取的输出值,然后,被解码为运动信号来 控制机器人.针对iCub的头部控制,研究通过设计神 经形态结构^[98]和闭环PID控制器^[99]来控制iCub头部 姿态.同样,文献[100]提出一种Vestibulo-Ocular Ref-

神经元

lex(vestibulo-ocular reflex, VOR)协议,采用自适应方 法实时控制环路内的脉冲小脑模型.该协议融合 iCub的头和眼睛,可以用来检查视网膜上的图像运动, 但目前仅能完成较少自由度的控制.



图 7 PID控制与脉冲神经网络结合示意图^[54]

Fig. 7 Diagram of combination of PID control and spiking neural network^[54]

主	2	什么DIDIT出始管法的研究汇片主	
衣	2	结合PID及其他异法的研先几志衣	

Table 2	Summary	of researc	h on com	bination	of PID	and other a	algorithms

采用算法	作者(时间)	神经元模型	控制对象/任务	网络规模	控制输出值	性能验证
	Perez (2018) ^[75]	Izhikevich 模型	1) 电机转矩; 2) 手臂运动	三层网络 结构	1) 期望转矩; 2) 伸举运动	仿真环境
	Batllori(2011) ^[92]	LIF模型	避障和光源 寻找任务	未提及	左右轮速度	无
遗传算法	Floreano (2001) ^[56]	SRM模型	导航和避障 任条	SNN三层全 连接网络	车轮速度 变化	Khepera 机器人
	Hagras (2004) ^[50]	SRM模型	沿既定路径 移动	两层SNN 结构	左右轮运动 速度	微型机器 人平台
	Trhan (2010) ^[93]	SRM模型	机器人自主 沿墙运动	两个局部SNN 全连接结构	左中右三个 前进控制量	乐高机器 人工具包
卡尔曼 滤波	Dethier (2011) ^[71]	LIF模型	预测手臂速度	两千个神经元 的神经网络	两个方向 速度	动物脑机 接口测试
	Shalumov (2021) ^[68]	LIF模型	车辆转向和 避障控制	未提及	速度和转向	仿真环境
	Zhao (2020) ^[69]	自适应LIF 模型	实现闭环 PI控制	三层 SNN 结构	电机控制 指令	DYNAP-SE 芯片
DID	Glatz (2019) ^[94]	自适应LIF 模型	控制车辆 转速	未提及	机器人预期 旋转速度	ROLLS芯片 和Pushbot 机器人
PID	Zaidel (2021) ^[95]	LIF模型	逆向动力学 和 PID 控制	三层SNN-PID 控制结构	机械臂六自由 度控制量	Loihi
	Stagsted (2020) ^[53-54]	类IF模型	小型无人机 单自由度控制	多层SNN-PID 控制结构	无人机单轴 旋转角度	Loihi
	Jimenez-Fernandez (2012) ^[70]	类IF模型	直流电机 转速控制	SNN-PID 控制结构	直流电机速度	AER机器人 和FPGA
	Webb (2011) ^[96]	Izhikevich 简化模型	PID控制器	未提及	电流序列拟合	SpiNNaker 平台

在机械臂控制方面,一些学者将SNN网络及神经 形态硬件融入到机械臂的四自由度^[81,101]、六自由 度^[95]控制当中,并结合FPGA和Loihi等硬件开展相关 性能验证.研究^[81]构建了一种在三维空间自主学习控 制四自由度机械臂的脉冲神经网络模型.输入层对手 臂的关节位置和末端效应器的所需空间方向进行编 码,输出层表示相应的电机命令.Gilra等人^[77]基于在 线局部学习训练包含隐藏层的脉冲异构网络,控制一 个双链臂实现期望的状态轨迹.该研究通过一种微分 前馈结构来构建非线性动力学的逆模型,以状态轨迹 作为输入来产生轨迹的时序命令,表现出比其他前馈 和递归结构更低的测试误差.Oniz等人^[102]评估了脉 冲神经网络在伺服系统上的性能.研究采用梯度算法 生成SNN控制模型,并通过有负载干扰的直流电机调 速进行了性能验证.

4.2 无人车自主导航控制

在实时传感、高维控制以及机器学习技术的推动 下,基于脉冲神经网络的智能控制在能效、对扰动的 鲁棒性和不同条件的自适应性等方面都优于传统的 控制范式^[68].朱祥维等人^[103]系统梳理了基于脉冲神 经网络实现类脑导航控制的技术路线,从鲁棒性、导 航路径、功耗等多个方面分析了类脑导航的优势.一 些研究从不同角度评估了 SNN 在无人车控制方面 的性能,如多任务自主学习和切换^[89]、自主目标跟 踪^[90]、静态^[93]和动态^[104]环境避障、基于非事件相机 数据^[105]和事件相机数据^[106]的车道保持等.为了更好 的实现端到端的自主控制,Shalumov等人^[68]将雷达 数据与 SNN 网络结合,在Nengo神经形态控制模型与 AirSim模拟器上进行集成,通过融合PID算法控制车 辆的速度和转向,提高了静态和动态环境下车辆控制 的性能.

在低功耗自主导航方面,研究将SNN与现有的路径规划算法相融合.Tang等人^[107]将同时定位与地图 创建(simultaneous localization and mapping, SLAM) 算法部署到基于SNN架构的Loihi神经形态处理器上,在保证方向定位和地图生成准确性的同时,其能耗比在 CPU上运行 GMapping 算法减少 100倍.Hwu等人^[108]基于神经形态芯片和SNN设计了一种户外路径规划算法,并在实际环境中进行了验证.Wang等人^[78]开发出了基于SNN的模块化导航控制器,无需精确的环境数学模型,在未知和非结构化环境中能够顺利完成导航任务,避免了局部极小值引起的死锁问题.

值得注意的是,目前研究大都是将SNN部署到小型无人车上实现基本的自主导航任务^[94,109],如车轮转向、避障、调谐速度等,控制自由度少,任务简单, 在应用层面与基于ANN的控制算法还存在一定差距. 虽然SNN低功耗、低延时的优势已在多个研究中得到 了证实和应用,然而,SNN理论方法尚不成熟,适配 SNN网络架构和神经形态硬件的编程框架有待进一步研究.

4.3 无人机姿态控制

无人机在计算、能耗资源有限情况下对低延迟、 快速响应有着更高的要求. Dupeyroux等人^[110]在Loihi神经形态芯片上设计了一个具有35个神经元的SNN 控制器,在保证性能前提下与GPU相比表现出更低的 功耗(约为1/75). 苏黎世大学相关研究团队也做了相 关的验证.不同地是,他们将PID控制算法融合到SNN 框架中,在嵌入式的神经形态芯片Loihi上与经典PID 控制方法进行了对比验证^[53]. Qiu等人^[111]提出了一 个包含六自由度的无人机控制方案,将SNN控制器在 3个方向的位移及3个欧拉角与经典PID控制效果进行 比较,其相对误差控制在5%以内.近些年,苏黎世大 学相关科研团队发展了一种受生物启发的视觉传感 器,即事件相机.相比传统基于帧的相机,事件相机只 记录亮度变化的像素点,具有低延迟(反应速度ms 级^[112])、低功耗(约为mW级)、高动态范围(事件相机 140 dB vs 传统相机60 dB)等优势[113]. 因特尔研究院 联合苏黎世大学在 Loihi 上开展的基于事件相机和 SNN的姿态控制研究^[114].事件传感器首先将信息传 输到神经形态处理器中,代表像素亮度变化的"0", "1"信号经由SNN处理输出转化为控制指令,取得的 控制性能与PD控制效果相当. 由此, 该研究将脉冲形 式的信息输入、处理、输出融合为一体,具备快速感知 及控制的同时保持有低功耗的优势.

4.4 仿生控制

脉冲神经网络受生物神经网络启发,通过脉冲发放的时空动力学特征来表示生物对外界的刺激,能够 任意逼近非线性函数,是目前最具生物解释性和合理 性的神经网络.基于SNN的仿生控制旨在通过对生物 运动学和动力学模拟来揭示其内在的运动调控机理. 一方面将脉冲神经网络应用到类人运动模式的研究 中,关注运动控制的生物合理性;另一方面,通过探究 更具生物合理性和可解释性的脉冲神经网络控制模 型来发掘SNN控制的优势和潜力.

在运动控制的生物合理性方面, Fernandez等人^[115]尝试通过模拟中枢神经系统的运动行为来控制手臂的位置.该研究提出了一种类似于反射弧结构的脉冲神经网络来模拟对人手臂的控制,并结合STDP学习策略,使该控制器具备自主学习能力.结果与经典的Hill肌肉模型模拟手臂的控制效果进行对比,表现出类似于人真实运动的控制效果.但该研究并未评估能效情况.类似地,为了提高机械臂驱动系统的生物合理性,研究采用SNN模拟小脑皮质功能并对部分肌肉进行建模,实现了对人工肘部^[116-117]、单关节臂

模型^[118]、三连杆臂模型^[119]弯曲、伸直的模拟,可适应手臂力学结构的未知变化,保持良好的精度.

在仿生运动策略方面, Takase等人^[74]利用Hebbian 学习规则和进化算法将生成的运动策略成功应用于 多足机器人,实现了在各种复杂地形上的行走. Kumarasinghe等人^[120]结合脑机接口和SNN方法,提出了 一种通过脑-机接口进行假肢控制的框架. 通过对运 动肌肉的协同实现了精确而稳健的假肢控制. 也有一 些学者通过模拟生物结构来探究 SNN 控制的优势. Clawson等人^[121]通过基于LIF神经元的SNN模拟蜜 蜂的飞行控制,成功实现了控制悬停、轨迹跟踪和栖 息等动作. Tang等人^[122]通过SNN模拟大脑导航系统 补偿部分或全部损失的视觉信号,实现了在未知环境 中的稳健控制. Polykretis等人^[123]利用SNN模拟人类 动眼神经系统,在Loihi神经形态芯片上部署了仿生控 制器,成功实现了类似人眼球一样的平稳追逐和扫视 运动,性能与在CPU上的控制效果相当.

综上,从仿生角度构建更具生物相似性的SNN智 能控制模型,对于认识、发展和深化脉冲神经网络的 实际应用具有重要价值,是生物智能与智能控制深度 融合的潜在途径之一.

4.5 决策控制一体化设计

感知、决策与控制的深度融合是发展高阶机器人 乃至迈向具身神经形态智能的重要途径之一[51]. 通过 融合脉冲神经网络的感知能力与强化学习的决策能 力,实现从原始数据输入到决策控制行为的端到端输 出.苏黎世联邦理工学院相关团队开发设计了基于 SNN的 SLAM 算法^[109]及 CNN 算法^[124], 成功搭建了 无人机感知与决策控制一体化的计算平台. Hwu等 人^[125]基于TrueNorth类脑芯片实现了无人车自主决 策与控制一体化测试;清华大学设计开发的天机芯混 合异构芯片能够能自主控制平衡、避障,识别语音指 令、探测前方行人[14]. 最近, 他们开发了"天机猫"机 器人搭载升级版的天机芯X(TianjicX)类脑计算芯 片[126],同时运行跨计算范式的多种智能算法,实现了 低功耗下自主规划、决策和控制机器人的优势(与 NVIDIA Jetson TX2 相比, 搭载 TianjicX 的延迟降低 了79.09倍,动态功耗降低了50.66%).美国诺贝尔生 理医学奖获得者Edelman团队提出的类脑系统"BBD" (brain-based device)一体化架构^[127],成功实现了从传 感器输入、类脑认知、决策及运动控制的全过程.

5 基于硬件平台的SNN控制实现

随着摩尔定律的失效,传统冯诺依曼式的计算硬件架构发展遭遇瓶颈.基于该架构芯片的"存储墙"和"功耗墙"问题越来越明显^[55].如何实现高性能、低

功耗的信息处理与转换成为计算硬件平台发展的重 点方向.不同于传统冯诺依曼式"存算"分离的硬件架 构,神经形态计算平台采用了从计算核、芯片到系统 的可扩展结构,通过路由网实现各模块之间的数据交 换.每个计算核由神经元和突触构成,可根据任务需 求进行网络模型及学习规则的自适应调整.该架构最 大的特点之一是每个计算核都有自己独立的存储空 间,呈现为去中心化的运行模式,具有极高的并行性 和访存效率^[15],如图8所示.研究^[53]指出:当所有的感 知、决策和运动控制都基于神经元结构集成到神经形 态硬件上时,神经形态计算系统最有效.因而,发展适 合SNN算法的神经形态硬件平台,对于SNN智能控制 应用的落地至关重要.

5.1 现有神经形态计算平台

现有的神经形态计算平台从功能上可分为离线学 习平台和在线学习平台.离线学习中SNN参数已提前 训练好,在推理过程中不支持参数实时更新.知名的 离线学习计算平台有斯坦福大学的Neurogrid^[128]、瑞 士苏黎世大学的DYNAPs^[129]、IBM 公司的TrueNorth^[130]和清华大学的Tianjic^[14].其中,Neurogrid和DY-NAPs是基于数模混合电路开发,在图像识别方面具 有一定优势^[90].然而,模拟电路本身抗干扰能力弱、 受噪声等外界影响较大,尚未见报道将其作为SNN智 能控制的计算平台.相比而言,基于全数字电路的 TrueNorth和Tianjic神经形态计算平台受到许多学者 的青睐.相关团队分别将其用在了室外六轮车的自主 导航控制^[125]以及自行车的车身平衡、自主决策及避 障等功能当中^[14],在不降低控制性能前提下,表现出 显著低功耗的优势.

在线学习神经形态计算平台同时支持训练和推理 过程中的实时更新,其存算一体的特性常用来设计以 STDP为代表的突触可塑性规则的实现. Jin等人^[131] 通过改变脉冲信号触发机制来优化STDP规则,成功 实现了STDP在神经形态硬件计算平台SpiNNaker上 的在线学习.因特尔最新发布的Loihi2芯片^[13]拥有最 多100万个神经元, 1.2亿个相互连接的突触. 单个芯 片集成了128个计算核,能够灵活实现突触权值更新、 发放阈值自适应、神经与与多核之间的连接等[15].研 究成功将其应用在无人机单自由度的PID控制^[53-54]、 多自由度运动物体的连续控制[23]及无地图自主导 航^[48]等方面,其能耗相比CPU降低1-3个数量级,表 现出低延迟、高鲁棒的特性. 特别地, 文献[132]按照 同一基准比较了Loihi和SpiNNaker这两个平台机械 臂控制的计算时间和功耗. 研究发现: SpiNNaker2在 输入维数较高时效率更高, 而Loihi在输入维数较低时 效率更高.



图 8 去中心化的脉冲神经网络路由架构 Fig. 8 Decentralized spiking neural network routing architecture

最近,中国科学院自动化研究所类脑智能研究中 心研究员曾毅团队发布了全脉冲神经网络的类脑认 知智能引擎"智脉"(brain-inspired cognitive engine, BrainCog)^[133],该平台以多尺度生物可塑性原理为基 础,支持全脉冲神经网络建模,整合了多种神经元计 算模型、可塑性法则、神经网络连接模式与编码方式, 实现了感知和学习[134]、决策[135-136]、运动控制[137]、 知识表征和推理[138]、社会认知等功能.此外,加拿大 滑铁卢大学的神经学家开发出了一个名为Nengo的神 经建模开发和仿真平台.该平台定义了基于Python的 API, 可支持 Keras 或 TensorFlow 的部署与构建, 并且 可以在CPU, GPU, FPGA和神经形态硬件上进行应用 开发. 文献[139]报道了基于Nengo 平台开发嵌入式 机器人控制系统的相关研究,包括与Mujoco交互的目 标跟踪控制系统构建和基于Loihi的片上学习机制实 现机械臂的自适应控制.该平台构建了支持多种混合 架构设计的通用硬件平台,用户能够开发神经(Nengo Loihi)或非神经(CPU, GPU)的机器学习解决方案.

5.2 基于FPGA的仿真研究

神经形态硬件计算平台开发成本高、周期长、难度大,许多学者基于FPGA开展了SNN硬件平台设计的研究.FPGA,全称field programmable gate arrays,即现场可编程逻辑门阵列,是一种可编程使用的信号处理设备,用户可通过灵活配置信息实现自定义功能,具有高集成度、高速和高可靠性等优点.同时,在FP-GA上设计好的逻辑功能和I/O端口也易于移植到芯片上,可有效提升电路板的设计效率.文献[140]综述了近些年SNN在FPGA平台上的神经元模型构建^[141]、

网络架构设计、训练算法及应用^[70,142]等方面的研究. 在机器人控制方面,通过将SNN控制算法部署映射 到FPGA平台上,研究实现了多足机器人运动模式生 成^[143]、自主避障^[144]及导航任务^[145].尽管准确率和 任务复杂度相比已有的神经形态计算平台(如Loihi) 上有一些差距^[48], FPGA良好的可移植性和可重新配 置性仍是SNN智能控制重点关注的方向^[140].

总体而言,神经形态计算硬件平台经过十余年的 发展,取得了显著的成果,它们相比传统冯诺依曼式 的计算架构表现出异步并行、低功耗、低延迟等重要 特性,带动和促进了SNN的理论研究和应用探索.如 何将现有神经形态硬件平台与各种SNN算法有效结 合,是未来SNN自主节能控制的重要方向.同时,FP-GA作为神经形态硬件模拟仿真平台会在架构设计、 模型完善、功能验证等方面发挥越来越重要的作用.

6 总结与展望

正如前文介绍,目前基于脉冲神经网络的智能控制已取得一定进展.本节对以上研究做简要总结,并 对今后可能的研究方向进行展望.

6.1 总结

脉冲神经网络控制研究融合了脑认知科学、人工 智能、计算机科学与智能控制等多个领域,未来有望 在速度、能效和算力方面构建出具备通用人工智能的 高阶智能体.本篇综述围绕脉冲神经网络控制研究与 发展,从基本概念、研究动机、算法研究、应用方向、 硬件平台等5个方面介绍了当前研究现状及未来可能 的发展方向,旨在让读者较为清晰的把握当前脉冲神 经网络控制的发展,为后续相关研究提供思路和借鉴. 本文首先简要介绍了脉冲神经网络的基本要素, 从神经元模型、脉冲编码方式、突触可塑性理论、网 络拓扑结构和学习算法等方面概述了SNN算法的基 本要素.从发展现状来看,SNN相关理论还在不断完 善.明确各种编码方式及网络架构在不同控制任务中 的优劣,发展适合于混合编码的SNN理论架构可能会 是未来发展的一个方向.

为了让读者清晰把握SNN控制的研究动机及潜在 优势,本文在第2节阐述了SNN控制相比经典控制方 法的增益,以及高阶机器人发展对SNN控制的需求. 在算法部分,将现有的脉冲神经网络控制研究划分为 3类,涵盖了SNN控制算法在监督学习(以PID控制为 代表)、无监督学习(以STDP为代表)和强化学习领域 的相关进展.在应用部分,系统总结了SNN控制在机 器人运动控制、无人车自主导航控制、无人机姿态控 制和仿生控制等4个方面的相关应用.应当指出的是, 现有的SNN控制算法在SNN网络架构设计及神经形 态芯片适配方面仍存在不小挑战, SNN网络架构的发 展目前还依赖于ANN. 在ANN的网络框架下, SNN额 外的时间维度、阈值激发特性与脉冲的稀疏性导致仿 真时间变长,加深了对显存的需求^[15],在传统CPU/ GPU上并不节能.具体到硬件层面,第5节总结了现有 的神经形态计算平台,并概述了FPGA上针对不同 SNN算法的研究.综合现有研究来看,目前大都基于 简单任务(如较少自由度的运动控制,导航中的车轮转 向、避障等)来验证模型算法的性能,对于实际复杂场 景下的SNN控制模型构建还有待深入研究.

6.2 展望

通过分析当前研究进展,本文对未来脉冲神经网 络控制的发展有以下几点分析:

1)小型化、专用化模型构建是基于脉冲神经网络的智能控制迈向实际应用的重点问题之一.脉冲神经网络低功耗、低延迟、高鲁棒等优势目前在算法和仿真层面得到了验证,然而考虑到不同任务和SNN模型构建之间的差异,鲜有仿真实验比较监督学习、无监督学习、强化学习算法这3种算法的优缺点.通过在同一任务上比较3种SNN控制算法的差异,有望提升特定任务下模型的专用化能力.同时,神经形态硬件为SNN计算提供了高效的解决方案^[15],可以在某个特定实际任务下开展专用化的SNN控制模型构建,考虑算法设计与神经形态硬件的高效适配,可有效提高SNN控制系统的实用性.

2) 当前提出的一些方法大都基于仿真环境平台和 数据集完成验证, 尽管在某些控制性能方面表现优异, 但应用到现实环境中还有不少差距.可从以下几个方 面来完善相关研究: 一是发展SNN与神经形态硬件的 适配方法, 提升SNN控制模型在神经形态芯片上的性 能; 二是关注模型的迁移性研究, 特别是从仿真环境 到现实环境的域间差异, 通过跨模态学习等方法提升 已训练好的模型在现实环境中的推理能力; 三是融合 借鉴当前智能控制和经典控制等方法, 在特定任务场 景下发掘其在精度和鲁棒性等方面的增量; 最后, 脉 冲神经网络与强化学习的融合发展, 可从生物角度进 一步理解大脑中的奖励学习机制, 不断深入对大脑学 习过程的理解, 以更好地解释动物在现实环境中的各 种复杂控制及反应.

3) SNN时空信息表征的优势有待进一步挖掘.目前SNN的低功耗、低延迟等优势已得到广泛验证, 然而时空并行处理的优势还有待深入研究. SNN相比 ANN的主要区别之一是具有时空动力学特征^[10]. 通过借鉴和发掘脉冲神经网络在时空信息方面的表征 优势, 融合部分先验知识, 可进一步提升SNN智能控制的精度和效果.

4) 脉冲神经网络与事件相机具有天然适配性^[146],结合事件相机传感器的SNN控制系统有望发挥出事件相机高时间分辨率和SNN轻量化的双重特性,增强模型对不同状态信息的处理能力和复杂环境下的抗干扰水平,进而可提升在高动态任务场景中的感知和自适应控制性能,同时也可为研究感知到运动控制一体化的类脑智能技术提供新思路与新方法.

综上,基于脉冲神经网络的智能控制研究是一个 多学科交叉任务,在未来智能机器人、智能设备、自动 驾驶、无人机等领域具有巨大的发展潜力.希望通过 本文可以让更多人了解基于脉冲神经网络的智能控 制研究现状,追求性能突破的同时,赋予模型更多应 用价值,不断逼近更高阶、更自主(如具身神经形态智 能^[51])的控制水平.

参考文献:

- PIERSON H A, GASHLER M S. Deep learning in robotics: A review of recent research. *Advanced Robotics*, 2017, 31(16): 821 835.
- [2] CADENA C, CARLONE L, CARRILLO H, et al. Past, present, and future of simultaneous localization and mapping: Toward the robustperception age. *IEEE Transactions on Robotics*, 2016, 32(6): 1309– 1332.
- [3] KARKUS P, HSU D, LEE W S. Qmdp-net: Deep learning for planning under partial observability. *Advances in Neural Information Processing Systems*. Long Beach, CA, USA: MIT Press, 2017, 30: 1 – 18.
- [4] 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.
- [5] RAUSCH V, HANSEN A, SOLOWJOW E, et al. Learning a deep neural net policy for end-to-end control of autonomous vehicles. *American Control Conference (ACC)*. Seattle, WA, USA: IEEE, 2017: 4914 – 4919.
- [6] LECUN Y, BENGIO Y, HINTON G. Deep learning. *Nature*, 2015, 521(7553): 436 – 444.

- [7] SEJNOWSKI T J. The unreasonable effectiveness of deep learning in artificial intelligence. *Proceedings of the National Academy of Sciences*, 2020, 117(48): 30033 – 30038.
- [8] BING Z, MESCHEDE C, RHRBEIN F, et al. A survey of robotics control based on learning-inspired spiking neural networks. *Frontiers in Neurorobotics*, 2018, 12(35): 1 – 22.
- [9] AJOUDANI A, ZANCHETTIN A M, IVALDI S, et al. Progress and prospects of the human-robot collaboration. *Autonomous Robots*, 2018, 42: 957 – 975.
- [10] ROY K, JAISWAL A, PANDA P. Towards spike-based machine intelligence with neuromorphic computing. *Nature*, 2019, 575(7784): 607 – 617.
- [11] DEWOLF T. Spiking neural networks take control. *Science Robotics*, 2021, 6(58): eabk3268.
- [12] ZHANG B, SHI L, SONG S. Creating more intelligent robots through brain-inspired computing. *Science Robotics*, 2016, 354(6318):4 – 9.
- [13] DAVIES M, WILD A, ORCHARD G, et al. Advancing neuromorphic computing with loihi: A survey of results and outlook. *Proceedings of the IEEE*, 2021, 109(5): 911 934.
- [14] PEI J, DENG L, SONG S, et al. Towards artificial general intelligence with hybrid tianjic chip architecture. *Nature*, 2019, 572(7767): 106 – 111.
- [15] HU Yifan, LI Guoqi, WU Yujie, et al. Spiking neural networks: A survey on recent advances and new directions. *Control and Decision*, 2021, 36(1): 1 26.
 (胡一凡, 李国齐, 吴郁杰, 等. 脉冲神经网络研究进展综述. 控制与 决策, 2021, 36(1): 1 26.)
- [16] CHENG Long, LIU Yang. Spiking neural networks: Model, learning algorithms and applications. *Control and Decision*, 2018, 33(5): 923 937.
 (程龙,刘洋.脉冲神经网络:模型,学习算法与应用.控制与决策, 2018, 33(5): 923 937.)
- [17] LIN Xianghong, WANG Xiangwen, ZHANG Ning, et al. Supervised learning algorithms for spiking neural networks: A review. *Acta Electronica Sinica*, 2015, 43(3): 577 586.
 (蔺想红, 王向文, 张宁, 等. 脉冲神经网络的监督学习算法研究综述. 电子学报, 2015, 43(3): 577 586.)
- [18] IZHIKEVICH E M. Which model to use for cortical spiking neurons? *IEEE Transactions on Neural Networks*, 2004, 15(5): 1063 – 1070.
- [19] TKAIK G, PRENTICE J S, BALASUBRAMANIAN V, et al. Optimal population coding by noisy spiking neurons. *Proceedings of the National Academy of Sciences*, 2010, 107(32): 14419 – 14424.
- [20] BELLEC G, SALAJ D, SUBRAMONEY A, et al. Long short-term memory and learning-to-learn in networks of spiking neurons. Advances in Neural Information Processing Systems, 2018, 31: 1–19.
- [21] PAN Z, WU J, ZHANG M, et al. Neural population coding for effective temporal classification. *International Joint Conference on Neural Networks (IJCNN)*. Budapest, Hungary: IEEE, 2019: 1–8.
- [22] GUO Y, CHEN Y, ZHANG L, et al. Reducing information loss for spiking neural networks. In *European Conference on Computer Vi*sion (ECCV). Tel Aviv, Israel: Springer-Verlag, 2022: 36 – 52.
- [23] TANG G, KUMAR N, YOO R, et al. Deep reinforcement learning with population-coded spiking neural network for continuous control. In *Conference on Robot Learning*. London, UK: PMLR, 2021: 2016 – 2029.
- [24] JACOB V, BRASIER D J, ERCHOVA I, et al. Spike timingdependent synaptic depression in the in vivo barrel cortex of the rat. *Journal of Neuroscience*, 2007, 27(6): 1271 – 1284.

- [25] SONG S, MILLER K D, ABBOTT L F. Competitive hebbian learning through spike-timing-dependent synaptic plasticity. *Nature Neuroscience*, 2000, 3(9): 919 – 926.
- [26] SHIM M S, LI P. Biologically inspired reinforcement learning for mobile robot collision avoidance. *International Joint Conference on Neural Networks (IJCNN)*. Alaska, USA: IEEE, 2017: 3098 – 3105.
- [27] MAHADEVUNI A, LI P. Navigating mobile robots to target in near shortest time using reinforcement learning with spiking neural networks. *International Joint Conference on Neural Networks* (*IJCNN*). Alaska, USA: IEEE, 2017: 2243 – 2250.
- [28] ZHANG Yaozhong, HU Xiaofang, ZHOU Yue, et al. A novel reinforcement learning algorithm based on multilayer memristive spiking neural network with applications. *Acta Automatica Sinica*, 2019, 45(8): 1536 1547.
 (张耀中, 胡小方, 周跃, 等. 基于多层忆阻脉冲神经网络的强化学 习及应用. 自动化学报, 2019, 45(8): 1536 1547.)
- [29] HAO Y, HUANG X, DONG M, et al. A biologically plausible supervised learning method for spiking neural networks using the symmetric stdp rule. *Neural Networks*, 2020, 121(1): 387 – 395.
- [30] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, USA: IEEE, 2016: 770 – 778.
- [31] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition. *ArXiv Preprint*, 2014, arXiv: 1409.1556.
- [32] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks. *Proceedings of the IEEE conference on computer vision and pattern recognition*. Hawaii, USA: IEEE, 2017: 4700 – 4708.
- [33] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks. *Communications* of the ACM, 2017, 60(6): 84 – 90.
- [34] GUO Y, ZHANG L, CHEN Y, et al. Real spike: Learning realvalued spikes for spiking neural networks. *Computer Vision – ECCV* 2022: *The 17th European Conference*. Tel Aviv, Israel: Springer, 2022: 52 – 68.
- [35] HOND, CHANG I J. Tcl: An ann-to-snn conversion with trainable clipping layers. In *Design Automation Conference*. San Francisco, USA: IEEE, 2021: 793 – 798.
- [36] GAVRILOV A V, PANCHENKO K O. Methods of learning for spiking neural networks. a survey. *The 13th International Scientific-Technical Conference on Actual Problems of Electronics Instrument Engineering (APEIE)*. Novosibirsk, Russia: IEEE, 2016, 2: 455 – 460.
- [37] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning representations by back-propagating errors. *Nature*, 1986, 323(6088): 533 – 536.
- [38] BOHTE S M, KOK J N, LA POUTRE H. Error-backpropagation in temporally encoded networks of spiking neurons. *Neurocomputing*, 2002, 48(1/4): 17 – 37.
- [39] GHOSH-DASTIDAR S, ADELI H. A new supervised learning algorithm for multiple spiking neural networks with application in epilepsy and seizure detection. *Neural Networks*, 2009, 22(10): 1419 – 1431.
- [40] XU Y, ZENG X, HAN L, et al. A supervised multi-spike learning algorithm based on gradient descent for spiking neural networks. *Neural Networks*, 2013, 43(3): 99 – 113.
- [41] GUO Y, TONG X, CHEN Y, et al. Recdis-snn: Rectifying membrane potential distribution for directly training spiking neural networks. Proceedings of the IEEE/CVF Conference on Computer Vi-

sion and Pattern Recognition. New Orleans, USA: IEEE, 2022: 326-335.

- [42] WU Y, DENG L, LI G, et al. Spatio-temporal backpropagation for training high-performance spiking neural networks. *Frontiers in Neuroscience*, 2018, 12: 331 – 342.
- [43] LEE C, SARWAR S S, PANDA P, et al. Enabling spike-based backpropagation for training deep neural network architectures. *Frontiers in Neuroscience*, 2020, 119(14): 1 – 22.
- [44] NEFTCIEO, MOSTAFAH, ZENKEF. Surrogate gradient learning in spiking neural networks: Bringing the power of gradient-based optimization to spiking neural networks. *IEEE Signal Processing Magazine*, 2019, 36(6): 51 – 63.
- [45] KHERADPISH S R, GANJTABESH M, MASQUELIER T. Bioinspired unsupervised learning of visual features leads to robust invariant object recognition. *Neurocomputing*, 2016, 205(3): 382 – 392.
- [46] KHERADPISHEH S R, GANJTABESH M, THORPE S J, et al. Stdp-based spiking deep convolutional neural networks for object recognition. *Neural Networks*, 2018, 99(1): 56 – 67.
- [47] PATEL D, HAZAN H, SAUNDERS D J, et al. Improved robustness of reinforcement learning policies upon conversion to spiking neuronal network platforms applied to atari breakout game. *Neural Networks*, 2019, 120(4): 108 – 115.
- [48] TANG G, KUMAR N, MICHMIZOS K P. Reinforcement colearning of deep and spiking neural networks for energy-efficient mapless navigation with neuromorphic hardware. *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. Las Vegas, USA: IEEE, 2020: 6090 – 6097.
- [49] CHEN D, PENG P, HUANG T, et al. Deep reinforcement learning with spiking q-learning. ArXiv Preprint, 2022, arXiv: 2201.09754.
- [50] HAGRAS H, POUNDS-CORNISH A, COLLEY M, et al. Evolving spiking neural network controllers for autonomous robots. In *IEEE International Conference on Robotics and Automation*. Hong Kong, China: IEEE, 2004, 5: 4620 – 4626.
- [51] BARTOLOZZI C, INDIVERI G, DONATI E. Embodied neuromorphic intelligence. *Nature Communications*, 2022, 13(1): 1024 – 1027.
- [52] WOLFE J, HOUWELING A R, BRECHT M. Sparse and powerful cortical spikes. *Current Opinion in Neurobiology*, 2010, 20(3): 306 – 312.
- [53] STAGSTED R K, VITALE A, RENNER A, et al. Event-based pid controller fully realized in neuromorphic hardware: A one dof study. *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. Las Vegas, USA: IEEE, 2020: 10939 – 10944.
- [54] STAGSTED R, VITALE A, BINZ J, et al. Towards neuromorphic control: A spiking neural network based pid controller for UAV. *Robotics: Science and Systems (RSS)*, online Conference, 2020.
- [55] ROGERS B M, KRISHNA A, BELL G B, et al. Scaling the bandwidth wall: Challenges in and avenues for cmp scaling. In Proceedings of the 36th Annual International Symposium on Computer Architecture. Texas, USA: IEEE, 2009: 371 – 382.
- [56] FLOREANO D, MATTIUSSI C. Evolution of spiking neural controllers for autonomous vision-based robots. In *Evolutionary Robotics. From Intelligent Robotics to Artificial Life: International Symposium. Tokyo, Japan*: Springer, 2001: 38 – 61.
- [57] MIRJALILI S, MIRJALILI S. Genetic algorithm. Evolutionary Algorithms and Neural Networks: Theory and Applications, 2019, 2(3): 43 – 55.
- [58] CHEN B, DANG L, ZHENG N, et al. Kalman filtering under information theoretic criteria. *Kalman Filtering Under Information Theoretic Criteria*. Cham: Springer International Publishing, 2023.

- [59] SUTTON R S, BARTO A G, WILLIAMS R J. Reinforcement learning is direct adaptive optimal control. *IEEE Control Systems Magazine*, 1992, 12(2): 19 – 22.
- [60] SUTTON R S, BARTO A G. Reinforcement Learning: An introduction. Baltimore County: MIT Press, 2018.
- [61] RUSSAKOVSKY O, DENG J, SU H, et al. Imagenet large scale visual recognition challenge. *International Journal of Computer Vision*, 2015, 115(4): 211 – 252.
- [62] GRAVES A, MOHAMED A, HINTON G. Speech recognition with deep recurrent neural networks. *IEEE International Conference* on Acoustics, Speech and Signal Processing. Vancouver, Canada: IEEE, 2013: 6645 – 6649.
- [63] LILLICRAP T P, HUNT J J, PRITZEL A, et al. Continuous control with deep reinforcement learning. *ArXiv Preprint*, 2015, arXiv: 1509.02971.
- [64] ZHANG Tielin, LI Chengyu, WANG Gang, et al. Research advances and new paradigms for biology inspired spiking neural networks. *Journal of Electronics and Information Technology*, 2023, 45(6): 1 14.
 (张铁林,李澄宇, 王刚,等. 适合类脑脉冲神经网络的应用任务范式分析与展望. 电子与信息学报, 2023, 45(6): 1 14.)
- [65] CHEN Ding, HUANG Yangru, PENG Peixi, et al. Research on spiking reinforcement learning algorithms: A survey. *Chinese Journal of Computers*, 2023, 10(46): 2132 2160.
 (陈鼎, 黄杨茹, 彭佩玺, 等. 脉冲强化学习算法研究综述. 计算机 学报, 2023, 10(46): 2132 2160.)
- [66] FRÉMAUX N, SPREKELER H, GERSTNER W. Reinforcement learning using a continuous time actor-critic framework with spiking neurons. *PLoS Computational Biology*, 2013, 9(4): e1003024.
- [67] POTJANS W, MORRISON A, DIESMANN M. A spiking neural network model of an actor-critic learning agent. *Neural computation*, 2009, 21(2): 301 – 339.
- [68] SHALUMOV A, HALALY R, TSUR E E. Lidar-driven spiking neural network for collision avoidance in autonomous driving. *Bioinspiration & Biomimetics*, 2021, 16(6): 066016.
- [69] ZHAO J, DONATI E, INDIVERI G. Neuromorphic implementation of spiking relational neural network for motor control. *The 2nd IEEE International Conference on Artificial Intelligence Circuits and Systems (AICAS)*. Hangzhou, China: IEEE, 2020: 89 – 93.
- [70] JIMENEZ-FERNANDEZ A, JIMENEZ-MORENO G, LINARES-BARRANCO A, et al. A neuro-inspired spike-based pid motor controller for multi-motor robots with low cost fpgas. *Sensors*, 2012, 12(4): 3831 – 3856.
- [71] DETHIER J, NUYUJUKIAN P, ELIASMITH C, et al. A brainmachine interface operating with a real-time spiking neural network control algorithm. *Advances in Neural Information Processing Systems*, 2011, 24(10): 1 – 12.
- [72] ELIASMITH C, ANDERSON C H. Neural Engineering: Computation, Representation, and Dynamics in Neurobiological Systems. St. Louis: MIT Press, 2003.
- [73] ZHANG X, XU Z, HENRIQUEZ C, et al. Spike-based indirect training of a spiking neural network-controlled virtual insect. *The* 52nd IEEE Conference on Decision and Control. Florence, Italy: IEEE, 2013: 6798 – 6805.
- [74] TAKASE N, BOTZHEIM J, KUBOTA N. Evolving spiking neural network for robot locomotion generation. *IEEE Congress on Evolutionary Computation (CEC)*. Sendai, Japan: IEEE, 2015: 558 – 565.
- [75] PEREZ J, CABRERA J A, CASTILLO J J, et al. Bio-inspired spiking neural network for nonlinear systems control. *Neural Networks*, 2018, 104(3): 15 – 25.

- [76] QIU H, GARRATT M, HOWARD D, et al. Evolving spiking neural networks for nonlinear control problems. *IEEE Symposium Series* on Computational Intelligence (SSCI). Paris, France: IEEE, 2018: 1367 – 1373.
- [77] GILRA A, GERSTNER W. Non-linear motor control by local learning in spiking neural networks. In *International Conference on Machine Learning*. Stockholm, Sweden: PMLR, 2018: 1773 – 1782.
- [78] WANG X, HOU Z G, LV F, et al. Mobile robots modular navigation controller using spiking neural networks. *Neurocomputing*, 2014, 134(8): 230 – 238.
- [79] ALNAJJAR F, BIN MOHD ZIN I, MURASE K. A hierarchical autonomous robot controller for learning and memory: Adaptation in a dynamic environment. *Adaptive Behavior*, 2009, 17(3): 179 – 196.
- [80] CYR A, BOUKADOUM M. Classical conditioning in different temporal constraints: An stdp learning rule for robots controlled by spiking neural networks. *Adaptive Behavior*, 2012, 20(4): 257 – 272.
- [81] BOUGANIS A, SHANAHAN M. Training a spiking neural network to control a 4-dof robotic arm based on spike timing-dependent plasticity. *The 2010 International Joint Conference on Neural Networks (IJCNN)*. Barcelona, Spain: IEEE, 2010: 1 – 8.
- [82] XUE F, WANG W, LI N, et al. Fpga implementation of selforganized spiking neural network controller for mobile robots. *Advances in Mechanical Engineering*, 2014, 6: 180620.
- [83] LOBOV S A, MIKHAYLOV A N, SHAMSHIN M, et al. Spatial properties of stdp in a self-learning spiking neural network enable controlling a mobile robot. *Frontiers in Neuroscience*, 2020, 14: 88 – 101.
- [84] HASEGAN D, DEIBLE M, EARL C, et al. Multi-timescale biological learning algorithms train spiking neuronal network motor control. *BioRxiv*, 2021: 11 – 20.
- [85] SPULER M, NAGEL S, ROSENSTIEL W. A spiking neuronal model learning a motor control task by reinforcement learning and structural synaptic plasticity. *International Joint Conference on Neural Networks (IJCNN)*. Killarney, Ireland: IEEE, 2015: 1 – 8.
- [86] BING Z, MESCHEDE C, HUANG K, et al. End to end learning of spiking neural network based on r-stdp for a lane keeping vehicle. *IEEE International Conference on Robotics and Automation* (*ICRA*). Brisbane, Australia: IEEE, 2018: 4725 – 4732.
- [87] BING Z, JIANG Z, CHENG L, et al. End to end learning of a multilayered snn based on r-stdp for a target tracking snake-like robot. *International Conference on Robotics and Automation (ICRA)*. Montreal, Canada: IEEE, 2019: 9645 – 9651.
- [88] BING Z, BAUMANN I, JIANG Z, et al. Supervised learning in snn via reward-modulated spike-timing-dependent plasticity for a target reaching vehicle. *Frontiers in Neurorobotics*, 2019, 13: 18 – 32.
- [89] LIU J, LU H, LUO Y, et al. Spiking neural network-based multi-task autonomous learning for mobile robots. *Engineering Applications of Artificial Intelligence*, 2021, 104: 104362.
- [90] CAO Z, CHENG L, ZHOU C, et al. Spiking neural network-based target tracking control for autonomous mobile robots. *Neural Computing and Applications*, 2015, 26(5): 1839 – 1847.
- [91] WANG X, HOU Z G, ZOU A, et al. A behavior controller based on spiking neural networks for mobile robots. *Neurocomputing*, 2008, 71(4/6): 655 – 666.
- [92] BATLLORI R, LARAMEE C B, LAND W, et al. Evolving spiking neural networks for robot control. *Proceedia Computer Science*, 2011, 6(1): 329 – 334.
- [93] TRHAN P. The application of spiking neural networks in autonomous robot control. *Computing and Informatics*, 2010, 29(5): 823 – 847.

- [94] GLATZ S, MARTEL J, KREISER R, et al. Adaptive motor control and learning in a spiking neural network realised on a mixed-signal neuromorphic processor. *International Conference on Robotics and Automation (ICRA)*. Montreal, Canada: IEEE, 2019: 9631 – 9637.
- [95] ZAIDEL Y, SHALUMOV A, VOLINSKI A, et al. Neuromorphic nef-based inverse kinematics and pid control. *Frontiers in Neurorobotics*, 2021, 15: 631159.
- [96] WEBB A, DAVIES S, LESTER D. Spiking neural pid controllers. Neural Information Processing: The 18th International Conference, ICONIP 2011. Shanghai, China: Springer, 2011: 259 – 267.
- [97] GAMEZ D, FIDJELAND A K, LAZDINS E. Ispike: A spiking neural interface for the icub robot. *Bioinspiration & Biomimetics*, 2012, 7(2): 025008.
- [98] KREISER R, RENNER A, LEITE V R C, et al. An on-chip spiking neural network for estimation of the head pose of the icub robot. *Frontiers in Neuroscience*, 2020, 14: 551–565.
- [99] ZHAO J, RISI N, MONFORTE M, et al. Closed-loop spiking control on a neuromorphic processor implemented on the icub. *IEEE Journal on Emerging and Selected Topics in Circuits and Systems*, 2020, 10(4): 546 – 556.
- [100] NAVEROS F, LUQUE N R, ROS E, et al. Vor adaptation on a humanoid icub robot using a spiking cerebellar model. *IEEE Transactions on Cybernetics*, 2019, 50(11): 4744 – 4757.
- [101] LINARES-BARRANCO A, PEREZ-PEA F, JIMENEZ-FERNAN-DEZ A, et al. Ed-biorob: A neuromorphic robotic arm with fpga-based infrastructure for bio-inspired spiking motor controllers. *Frontiers in Neurorobotics*, 2020, 14: 590163.
- [102] ONIZ Y, KAYNAK O, ABIYEV R. Spiking neural networks for the control of a servo system. *IEEE International Conference on Mechatronics (ICM)*. Vicenza, Italy: IEEE, 2013: 94 – 98.
- [103] ZHU Xiangwei, SHEN Dan, XIAO Kai, et al. Mechanisms, algorithms, implementation and perspectives of brain-inspired navigation. Acta Aeronautica et Astronautica Sinica, 2023, 44(19): 28569 28569.
 (朱祥维, 沈丹, 肖凯, 等. 类脑导航的机理、算法、实现与展望. 航
 - 空学报, 2023, 44(19): 28569 28569.)
- [104] DING Jianchuan, XIAO Jintong, ZHAO Kexin, et al. Spiking neural network-based navigation and obstacle avoidance algorithm for complex scenes. *Journal of Graphics*, 2023, 44(6): 1121 1129.
 (丁建川, 肖金桐, 赵可新, 等. 基于脉冲神经网络的复杂场景导航 避障算法. 图学学报, 2023, 44(6): 1121 1129.)
- [105] NICHOLS E, MCDAID L J, SIDDIQUE N H. Case study on a selforganizing spiking neural network for robot navigation. *International Journal of Neural Systems*, 2010, 20(6): 501 – 508.
- [106] KAISER J, TIECK J C V, HUBSCHNEIDER C, et al. Towards a framework for end-to-end control of a simulated vehicle with spiking neural networks. *IEEE International Conference on Simulation, Modeling, and Programming for Autonomous Robots (SIMPAR).* Hokkaido, Japan: IEEE, 2016: 127 – 134.
- [107] TANG G, SHAH A, MICHMIZOS K P. Spiking neural network on neuromorphic hardware for energy-efficient unidimensional slam. *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. Macao, China: IEEE, 2019: 4176 – 4181.
- [108] HWU T, WANG A Y, OROS N, et al. Adaptive robot path planning using a spiking neuron algorithm with axonal delays. *IEEE Transactions on Cognitive and Developmental Systems*, 2017, 10(2): 126 – 137.
- [109] KREISER R, RENNER A, SANDAMIRSKAYA Y, et al. Pose estimation and map formation with spiking neural networks: Towards neuromorphic slam. *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*. Madrid, Spain: IEEE, 2018: 2159 – 2166.

- [110] DUPEYROUX J, HAGENAARS J J, PAREDES-VALLES F, et al. Neuromorphic control for optic-flow-based landing of mavs using the loihi processor. *IEEE International Conference on Robotics and Automation (ICRA)*. Xi'an, China: IEEE, 2021: 96 – 102.
- [111] QIU H, GARRATT M, HOWARD D, et al. Evolving spiking neurocontrollers for uavs. *IEEE Symposium Series on Computational Intelligence (SSCI)*. Glasgow, UK: IEEE, 2020: 1928 – 1935.
- [112] FALANGA D, KLEBER K, SCARAMUZZA D. Dynamic obstacle avoidance for quadrotors with event cameras. *Science Robotics*, 2020, 5(40): eaaz9712.
- [113] GALLEGO G, DELBRUCK T, ORCHARD G, et al. Event-based vision: A survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 44(1): 154 – 180.
- [114] VITALE A, RENNER A, NAUER C, et al. Event-driven vision and control for uavs on a neuromorphic chip. *IEEE International Conference on Robotics and Automation (ICRA)*. Xi'an, China: IEEE, 2021: 103 – 109.
- [115] FERNANDEZ J P, VARGAS M A, GARCIA J M V, et al. A biological-like controller using improved spiking neural networks. *Neurocomputing*, 2021, 463(10): 237 – 250.
- [116] HULEA M, CARUNTU C F. Spiking neural network for controlling the artificial muscles of a humanoid robotic arm. *The 18th International Conference on System Theory, Control and Computing* (*ICSTCC*). Sinaia, Romania: IEEE, 2014: 163 – 168.
- [117] HULEA M, BURLACU A, CARUNTU C F. Robotic joint control system based on analogue spiking neural networks and sma actuators. *International Conference on Robotics and Automation (ICRA)*. Montreal, Canada: IEEE, 2019: 1148 – 1154.
- [118] HULEA M, BURLACU A, CARUNTU C F. Intelligent motion planning and control for robotic joints using bio-inspired spiking neural networks. *International Journal of Humanoid Robotics*, 2019, 16(4): 1950012.
- [119] DEWOLF T, STEWART T C, SLOTINE J J, et al. A spiking neural model of adaptive arm control. *Proceedings of the Royal Society B: Biological Sciences*, 2016, 283(1843): 20162134.
- [120] KUMARASINGHE K, OWEN M, TAYLOR D, et al. Faneurobot: A framework for robot and prosthetics control using the neucube spiking neural network architecture and finite automata theory. *The* 2018 IEEE International Conference on Robotics and Automation (ICRA). Brisbane, Australia: IEEE, 2018: 4465 – 4472.
- [121] CLAWSON T S, FERRARI S, FULLER S B, et al. Spiking neural network (snn) control of a flapping insect-scale robot. *IEEE* 55th Conference on Decision and Control (CDC). Las Vegas, USA: IEEE, 2016: 3381 – 3388.
- [122] TANG G, MICHMIZOS K P. Gridbot: An autonomous robot controlled by a spiking neural network mimicking the brain's navigational system. *Proceedings of the International Conference on Neuromorphic Systems*. Montreal, Canada: IEEE, 2018: 1 – 8.
- [123] POLYKRETIS I, TANG G, BALACHANDAR P, et al. A spiking neural network mimics the oculomotor system to control a biomimetic robotic head without learning on a neuromorphic hardware. *IEEE Transactions on Medical Robotics and Bionics*, 2022, 4(2): 520 – 529.
- [124] PALOSSI D, CONTI F, BENINI L. An open source and open hardware deep learning-powered visual navigation engine for autonomous nano-uavs. *The 15th International Conference on Distributed Computing in Sensor Systems (DCOSS)*. Coimbatore, India: IEEE, 2019: 604 – 611.
- [125] HWU T, ISBELL J, OROS N, et al. A self-driving robot using deep convolutional neural networks on neuromorphic hardware. *International Joint Conference on Neural Networks (IJCNN)*. Alaska, USA: IEEE, 2017: 635 – 641.

- [126] MA S, PEI J, ZHANG W, et al. Neuromorphic computing chip with spatiotemporal elasticity for multi-intelligent-tasking robots. *Science Robotics*, 2022, 7(67): eabk2948.
- [127] FLEISCHER J G, EDELMAN G M. Brain-based devices-an embodied approach to linking nervous system structure and function to behavior. *IEEE Robotics & Automation Magazine*, 2009, 16(3): 33 – 48.
- [128] BENJAMIN B V, GAO P, MCQUINN E, et al. Neurogrid: A mixedanalog-digital multichip system for large-scale neural simulations. *Proceedings of the IEEE*, 2014, 102(5): 699 – 716.
- [129] MORADI S, QIAO N, STEFANINI F, et al. A scalable multicore architecture with heterogeneous memory structures for dynamic neuromorphic asynchronous processors (dynaps). *IEEE Transactions* on Biomedical Circuits and Systems, 2017, 12(1): 106 – 122.
- [130] MEROLLA P A, ARTHUR J V, ALVAREZ-ICAZA R, et al. A million spiking-neuron integrated circuit with a scalable communication network and interface. *Science*, 2014, 345(6197): 668 – 673.
- [131] JIN X, RAST A, GALLUPPI F, et al. Implementing spike-timingdependent plasticity on spinnaker neuromorphic hardware. *International Joint Conference on Neural Networks (IJCNN)*. Barcelona, Spain: IEEE, 2010: 1 – 8.
- [132] YAN Y, STEWART T C, CHOO X, et al. Comparing loihi with a spinnaker 2 prototype on low-latency keyword spotting and adaptive robotic control. *Neuromorphic Computing and Engineering*, 2021, 1(1): 014002.
- [133] ZENG Y, ZHAO D, ZHAO F, et al. Braincog: A spiking neural network based brain-inspired cognitive intelligence engine for brain-inspired ai and brain simulation. *ArXiv Preprint*, 2022, arXiv: 2207.08533.
- [134] WANG Y, ZENG Y. Multisensory concept learning framework based on spiking neural networks. *Frontiers in Systems Neuroscience*, 2022, 16(6): 1–12.
- [135] ZHAO F, ZENG Y, HAN B, et al. Nature-inspired self-organizing collision avoidance for drone swarm based on reward-modulated spiking neural network. *Patterns*, 2022, 3(11): 100611.
- [136] ZHAO F, ZENG Y, XU B. A brain-inspired decision-making spiking neural network and its application in unmanned aerial vehicle. *Frontiers in Neurorobotics*, 2018, 12: 56 – 69.
- [137] ZHAO Y, ZENG Y. A brain-inspired intention prediction model and its applications to humanoid robot. *Frontiers in Neuroscience*, 2022, 16(10): 1 – 11.
- [138] FANG H, ZENG Y. A brain-inspired causal reasoning model based on spiking neural networks. *International Joint Conference on Neural Networks (IJCNN)*. Nanjing, China: IEEE, 2021: 1 – 5.
- [139] DEWOLF T, JAWORSKI P, ELIASMITH C. Nengo and low-power ai hardware for robust, embedded neurorobotics. *Frontiers in Neurorobotics*, 2020, 14: 568359.
- [140] PHAM Q T, NGUYEN T Q, HOANG P C, et al. A review of snn implementation on fpga. *International Conference on Multimedi*a Analysis and Pattern Recognition (MAPR). Virtual Conference: IEEE, 2021: 1 – 6.
- [141] RICE K L, BHUIYAN M A, TAHA T M, et al. Fpga implementation of izhikevich spiking neural networks for character recognition. *International Conference on Reconfigurable Computing and FPGAs.* Cancun, Mexico: IEEE, 2009: 451 – 456.
- [142] CAMUAS-MESA L A, LINARES-BARRANCO B, SERRANO-GOTARREDONA T. Low-power hardware implementation of snn with decision block for recognition tasks. *The 26th IEEE International Conference on Electronics, Circuits and Systems (ICECS).* Shanghai, China: IEEE, 2019: 73 – 76.

- [143] GUERRA-HERNANDEZ E I, ESPINAL A, BATRES-MENDOZA P, et al. A fpga-based neuromorphic locomotion system for multilegged robots. IEEE Access, 2017, 5(3): 8301 - 8312.
- [144] JOHNSON A P, LIU J, MILLARD A G, et al. Homeostatic fault tolerance in spiking neural networks: A dynamic hardware perspective. IEEE Transactions on Circuits and Systems I: Regular Papers, 2017, 65(2): 687 - 699.
- [145] MITCHELL J P, BRUER G, DEAN M E, et al. Neon: Neuromorphic control for autonomous robotic navigation. IEEE International Symposium on Robotics and Intelligent Sensors (IRIS). Ottawa, Canada: IEEE, 2017: 136 - 142.
- [146] SU Li, YANG Fan, WANG Xiangyu, et al. A survey of robot perception and control based on event camera. Acta Automatica Sinica, 2022, 48(8): 1869 - 1889.

(粟傈,杨帆,王向禹,等.基于事件相机的机器人感知与控制综述. 自动化学报, 2022, 48(8): 1869-1889.)

作者简介:

刘晓德 博士, 工程师, 目前研究方向为类脑智能、智能控制与决 策, E-mail: beyondlxde@163.com;

郭宇飞 博士,高级工程师,目前研究方向为先进智能计算、类脑 智能, E-mail: yfguo@pku.edu.cn;

黄旭辉 博士,研究员,目前研究方向为类脑智能、小样本机器学

习、智能控制与决策, E-mail: starxh@163.com;

马 喆 博士,研究员,目前研究方向为机器智能与模式识别、机

器视觉, E-mail: mazhe_thu@163.com.