

同行专家业内评价意见书编号: 20240854213

附件1

浙江工程师学院（浙江大学工程师学院） 同行专家业内评价意见书

姓名: _____ 俸朗

学号: _____ 22160269

申报工程师职称专业类别（领域）: _____ 电子信息

浙江工程师学院（浙江大学工程师学院）制

2024年03月26日

一、个人申报

（一）基本情况【围绕《浙江工程师学院（浙江大学工程师学院）工程类专业学位研究生工程师职称评审参考指标》，结合该专业类别(领域)工程师职称评审相关标准，举例说明】

1. 专业理论知识与技术技能掌握情况

我对强化学习的核心原理，包括价值函数、策略优化、以及奖励信号的设计有深刻的理解。在深入研究强化学习的同时，我特别关注多智能体强化学习（MARL）的研究进展，这是一个关注如何使多个智能体在环境中协同工作以达到共同或个别目标的领域。通过项目实践，我掌握了主要的多智能体强化学习算法，如协作与竞争环境下的策略学习、异质智能体交互、动态环境适应等，并理解了这些算法在处理复杂交互任务中的优势与局限性，对这一领域的发展动态和前沿技术有了全面的认识。此外，我还掌握了数据分析、编程（尤其是Python）、以及使用相关开发工具和框架（如TensorFlow和PyTorch）的技能，这些都为我在强化学习研究中提供了坚实的技术支撑。

2. 工程实践经历

我在浙江浙大西投脑机智能科技有限公司参与的项目，“基于强化学习的人机交互类群体协同对抗研究”，不仅是一个学术研究项目，更是一个涉及复杂工程实践的挑战。项目中，我负责群体协同算法的设计与实现，以及算法优化与调整工作。在此过程中，我不仅运用了我在强化学习方面的专业知识，还涉及到了软件工程、系统设计、以及高性能计算等多个方面。在团队合作下，我参与设计出了一种通用的多智能体强化学习算法，该算法旨在解决人类和机器智能体之间的异质性、不完全信息和动态环境等复杂问题，以促进智能体之间的高效合作。同时，我也参与对所设计的算法进行优化和调整，以提高其泛化能力和适应性。通过不断的实验和改进，确保我们的算法在不同场景下能够稳定运行，并能够与零样本队友高效合作。

3. 综合运用知识解决复杂工程问题案例

本人的一个工程问题案例是在实习期间的一个项目：“基于强化学习的人机交互类群体协同对抗研究”。该工程的目标是实现一个非常具有挑战性的目标：探索多智能体强化学习领域的群体协同算法，实现智能体之间的高效协作，并促进群体智慧的集成效果。研究的核心内容集中在设计和实现一个高度灵活和可扩展的多智能体强化学习算法框架，该框架能够适应智能体之间的异质性、处理不完全信息，以及动态变化的环境条件。这项任务不仅涉及到算法的设计和优化，还包括对算法在各种复杂场景下表现的深入评估。

为了实现这一目标，我们采用了一系列创新的技术路线。首先，我们进行了广泛的文献回顾，深入理解了强化学习理论的最新进展，并对基于价值的方法、基于策略的方法以及演员-评论家方法等不同的群体协同算法进行了深入研究。我们特别关注那些能够适应中心化、分布式或混合架构的算法，以便在不同的应用场景中找到最适合的解决方案。在算法设计方面，我们提出了一种创新的多智能体强化学习算法。该算法针对现有群体协同算法在不同网络结构和动态环境中表现出的通用性和适应性不足的问题，通过引入新的学习机制和优化策略，显著提高了算法的性能和泛化能力。我们的算法不仅在仿真环境中经过了严格测试，而且还展现了在处理不同类型智能体间的协作时的出色适应性。此外，为了增强算法的鲁棒性，我们在设计阶段特别考虑了零样本鲁棒性的重要性，这是指算法能够在遇到完全未知的情况或智能体时，仍能保持良好的性能。我们通过引入更多的异构性和不确定性处理机制，以及增加算法的随机性和探索性，大大提高了算法的适应能力

在我们的研究项目中，我们面临的巨大挑战是设计一个既能适应动态变化的环境，又能处理人机智能体之间异质性和不完全信息问题的算法。通过团队的共同努力，我们提出了一种基于强化学习的群体协同算法，该算法特别关注于智能体之间的有效合作，即使在零样本队友

的情况下也能表现出良好的适应性和泛化能力。另一个挑战性部分是设计一种能够在不同任务场景下都能稳定运行的群体协同算法。我们面临的一个具体问题是如何提高算法在与未知智能体进行交互时的适应性和鲁棒性。为了解决这一问题，我们采用了多策略学习和环境模拟技术，允许算法在虚拟环境中与各种模拟智能体交互，以此来提高其泛化能力。我们还引入了一种基于反馈的调整机制，使算法能够根据实际交互结果自我优化。通过这些技术创新，我们的算法能够更加灵活地应对各种交互场景，有效提升了人机协同效率。

(二) 取得的业绩(代表作)【限填3项, 须提交证明原件(包括发表的论文、出版的著作、专利证书、获奖证书、科技项目立项文件或合同、企业证明等)供核实, 并提供复印件一份】

1. 公开成果代表作【论文发表、专利成果、软件著作权、标准规范与行业工法制定、著作编写、科技成果获奖、学位论文等】

成果名称	成果类别 [含论文、授权专利(含发明专利申请)、软件著作权、标准、工法、著作、获奖、学位论文等]	发表时间/授权或申请时间等	刊物名称/专利授权或申请号等	本人排名/总人数	备注
Multi-Level Firing with Spiking DS-ResNet: Enabling Better and Deeper Directly-Trained Spiking Neural Networks	会议论文	2022年07月29日	International Joint Conference on Artificial Intelligence	1/5	

2. 其他代表作【主持或参与的课题研究项目、科技成果应用转化推广、企业技术难题解决方案、自主研发设计的产品或样机、技术报告、设计图纸、软课题研究报告、可行性研究报告、规划设计方案、施工或调试报告、工程实验、技术培训教材、推动行业发展中发挥的作用及取得的经济社会效益等】

(三) 在校期间课程、专业实践训练及学位论文相关情况	
课程成绩情况	按课程学分核算的平均成绩： 89 分
专业实践训练时间及考核情况(具有三年及以上工作经历的不作要求)	累计时间： 1 年（要求1年及以上） 考核成绩： 91 分（要求80分及以上）
本人承诺	
<p>个人声明：本人上述所填资料均为真实有效，如有虚假，愿承担一切责任，特此声明！</p> <p style="text-align: right;">申报人签名： 俸 朝</p>	

浙江工业大学研究生学院

攻读硕士学位研究生成绩表

学号: 22160269	姓名: 俸朗	性别: 男	学院: 工程师学院	专业: 计算机技术	学制: 2.5年						
毕业时最低应获: 24.0学分		已获得: 28.0学分		入学年月: 2021-09	毕业年月: 2024-03						
学位证书号: 1033532024602225			毕业证书号: 103351202402600451								
学习时间	课程名称	备注	学分	成绩	课程性质	学习时间	课程名称	备注	学分	成绩	课程性质
2021-2022学年秋季学期	数字化自动驾驶		2.0	93	专业选修课	2021-2022学年夏季学期	研究生英语		2.0	81	公共学位课
2021-2022学年冬季学期	计算机视觉		2.0	98	专业选修课	2021-2022学年夏季学期	物联网信息安全技术与应用基础		2.0	95	专业学位课
2021-2022学年秋季学期	中国特色社会主义理论与实践研究		2.0	91	公共学位课	2021-2022学年夏季学期	大数据与人工智能工程应用		2.0	97	专业学位课
2021-2022学年冬季学期	数据分析的概率统计基础		3.0	89	专业选修课	2021-2022学年夏季学期	移动互联网智能设备应用设计与实践		3.0	85	专业学位课
2021-2022学年秋季学期	研究生论文写作指导		1.0	92	专业学位课	2021-2022学年夏季学期	自然辩证法概论		1.0	91	公共学位课
2021-2022学年冬季学期	机器学习		3.0	96	专业选修课	2021-2022学年春季学期	工程伦理		2.0	89	公共学位课
2021-2022学年秋季学期	电子与信息工程技术管理		2.0	93	专业学位课	2022-2023学年春季学期	研究生英语基础技能		1.0	83	公共学位课

说明: 1. 研究生课程按三种方法计分: 百分制 (通过、不通过), 五级制 (优、良、中、及格、不及格)。

2. 备注中“*”表示重修课程。

学院成绩校核章: (00)

成绩校核人: 张梦依

打印日期: 2024-04-02

Multi-Level Firing with Spiking DS-ResNet: Enabling Better and Deeper Directly-Trained Spiking Neural Networks

Lang Feng¹, Qianhui Liu¹, Huajin Tang^{1,2}, De Ma¹ and Gang Pan^{1,2,*}

¹College of Computer Science and Technology, Zhejiang University, Hangzhou, China

²Zhejiang Lab, Hangzhou, China

{langfeng, qianhuiliu, htang, made, gpan}@zju.edu.cn

Abstract

Spiking neural networks (SNNs) are bio-inspired neural networks with asynchronous discrete and sparse characteristics, which have increasingly manifested their superiority in low energy consumption. Recent research is devoted to utilizing spatio-temporal information to directly train SNNs by backpropagation. However, the binary and non-differentiable properties of spike activities force directly trained SNNs to suffer from serious gradient vanishing and network degradation, which greatly limits the performance of directly trained SNNs and prevents them from going deeper. In this paper, we propose a multi-level firing (MLF) method based on the existing spatio-temporal back propagation (STBP) method, and spiking dormant-suppressed residual network (spiking DS-ResNet). MLF enables more efficient gradient propagation and the incremental expression ability of the neurons. Spiking DS-ResNet can efficiently perform identity mapping of discrete spikes, as well as provide a more suitable connection for gradient propagation in deep SNNs. With the proposed method, our model achieves superior performances on a non-neuromorphic dataset and two neuromorphic datasets with much fewer trainable parameters and demonstrates the great ability to combat the gradient vanishing and degradation problem in deep SNNs.

1 Introduction

Spiking neural networks (SNNs) are developed to realize brain-like information processing [Maass, 1997], which use asynchronous binary spike signals to transmit information and have the ability to process information in both spatial domain (SD) and temporal domain (TD). Besides, the sparsity and event-driven properties position them as potential candidates for the implementation of low energy consumption on dedicated neuromorphic hardware. As an example, the energy consumed by SNNs to transmit a spike on neuromorphic hardware is only nJ or pJ [Diehl and Cook, 2015].

*Corresponding author.

In terms of learning algorithms, existing unsupervised learning algorithms [Qi *et al.*, 2018; Liu *et al.*, 2020] are difficult to train deep SNNs. Currently, there are two main learning algorithms for deep SNNs training. One is ANN-SNN conversion learning [Sengupta *et al.*, 2019; Yan *et al.*, 2021; Hu *et al.*, 2021], which converts the pre-trained ANN model to the SNN model. Conversion learning can achieve deep SNNs training with competitive results, but it has to consume a large number of timesteps to ensure the coding resolution. Moreover, conversion learning cannot utilize the TD information, making it difficult to train neuromorphic datasets. The other is direct supervised learning [Wu *et al.*, 2018; Gu *et al.*, 2019; Liu *et al.*, 2022; Zheng *et al.*, 2021], which is the approach taken by this paper. Direct supervised learning has great potential to make full use of spatio-temporal information to train the network and can reduce the demand for timesteps. However, to achieve more efficient direct supervised learning for better and deeper directly-trained SNNs, there are still two challenging issues to overcome.

The first is gradient vanishing. Due to non-differentiable spike activities, approximate derivative [Nefcici *et al.*, 2019] has to be adopted to make the gradient available, such as rectangle function and Gaussian cumulative distribution function [Wu *et al.*, 2018]. However, it will raise a problem that the limited width of the approximate derivative causes membrane potentials of a multitude of neurons to fall into the saturation area, where the approximate derivative is zero or a tiny value. Furthermore, the sharp features that have larger values in the feature map cannot be further enhanced due to falling into the saturation area to the right of the approximate derivative caused by excessive membrane potential. This greatly limits the performance of deep SNNs, and the neurons located in this saturation area caused by excessive membrane potential are termed to be *dormant* units in this paper. In the above cases, the gradient propagation will be blocked and unstable, therefore resulting in the gradient vanishing and increasing the difficulty of training deep SNNs.

The second is network degradation, which is terribly serious in deep directly-trained SNNs, even if residual structure [He *et al.*, 2016] is adopted. Therefore, existing training methods mainly expand SNNs in width to get improved performance, resulting in a large number of trainable parameters. The above non-differentiable spike activity is one of the reasons for network degradation, and the weak spatial ex-