

联合突触权重和延迟可塑性的高效多脉冲学习算法研究

高嘉潞¹⁾ 于 强¹⁾ 唐华锦²⁾ 黄铁军³⁾

¹⁾(天津大学智能与计算学部 天津 300072)

²⁾(浙江大学计算机科学与技术学院 杭州 310027)

³⁾(北京大学计算机科学技术系 北京 100871)

摘 要 基于脉冲的信息表达被认为是大脑进行稀疏、高效信息处理的基础,但是如何高效地处理和学习离散的脉冲仍然是一个具有挑战的问题.本文受突触延迟在生物可塑性中的重要作用所启发,将突触延迟引入脉冲神经元模型中,基于以发放期望脉冲数目为目标的高效多脉冲学习算法 EML 提出了两种针对延迟的学习方法:间断和连续延迟学习,其中连续延迟学习解决了间断延迟学习中延迟调整波动大的问题.两种延迟学习方法分别与权重学习结合得到了两种联合突触权重和延迟可塑性的多脉冲学习算法,命名为 Discontinuous EML-DL 和 Continuous EML-DL.本文首先对所提出的两种算法的学习动态特性进行了初步验证;进而,探索了所提出算法在不同的初始设置下的性质,并通过区间选择任务验证了突触权重和延迟联合可塑性的有效性和必要性,实验结果展现了本文方法在高效性的基础之上有效提升于神经元学习的灵活性和选择性;最后,本文构建了基于阈值交叉编码的孤立词识别系统,并在 Ti46 和 TIDIGITS 两个语料库上进行了测试,实验结果验证了所提出的两种算法在实际任务上的可行性和有效性.本文的研究成果展现了突触权重与延迟相结合的有效性,提升了多脉冲学习算法的性能,对基于脉冲的神经形态学习与计算有一定参考意义及价值.

关键词 脉冲神经网络;多脉冲学习;突触延迟;神经形态计算

中图法分类号 TP18 **DOI号** 10.11897/SP.J.1016.2022.02065

Research on Efficient Multi-Spike Learning Algorithms Joint with Synaptic Weight and Delay Plasticity

GAO Jia-Lu¹⁾ YU Qiang¹⁾ TANG Hua-Jin²⁾ HUANG Tie-Jun³⁾

¹⁾(College of Intelligence and Computing, Tianjin University, Tianjin 300072)

²⁾(College of Computer Science and Technology, Zhejiang University, Hangzhou 310027)

³⁾(Department of Computer Science and Technology, Peking University, Beijing 100871)

Abstract Spike-based information expression is considered to be the basis for sparse and efficient information processing in the brain, but how to efficiently process and learn discrete spikes is still a challenging problem. Following a similar spike-based processing in the brain, spiking neural networks (SNNs) provide a promising candidate for a new generation of artificial neural networks that would approach the efficient performance of the brain. How to design the adjustment of synaptic weights is a major focus in many spike-based learning rules. However, other component such as synaptic delay is also found to be adaptive and important in modulating the neuronal dynamics in biological systems. How could plasticity on different component cooperate to facilitate the learning is still a problem worth exploring. Some research attempts have been made in this

收稿日期:2021-11-17;在线发布日期:2022-04-16. 本课题得到国家自然科学基金(62176179)、之江实验室开放课题(2021KC0AB03)资助. 高嘉潞,硕士研究生,主要研究方向为脉冲神经网络算法、神经编码. E-mail: gaojialu@tju.edu.cn. 于 强(通信作者),博士,副教授,主要研究方向为类脑智能计算、神经网络、人工智能、理论神经学. E-mail: yuqiang@tju.edu.cn. 唐华锦,博士,教授,主要研究领域为神经形态计算与芯片、智能机器人等. 黄铁军,博士,教授,主要研究领域为视觉信息处理(图像识别与视频编码)和类脑计算.

field over the past few decades, but these explorations are limited to algorithms based on precise-timing output spikes which are often difficult to design and even reduce the learning flexibility. In this paper, we explore the possibility to further improve the performance of the advanced multi-spike learning by integrating the delay plasticity. Inspired by the important role of synaptic delay in biological plasticity, synaptic delay is defined the time lag between the presynaptic input and the postsynaptic reception and introduced into spiking neuron model. Based on the efficient multi-spike learning algorithm EML, which aims at firing the desired number of spikes without requiring the precise timings and is capable of training neurons to complete different complex tasks more flexibly, we propose two delay learning methods: Discontinuous and Continuous delay learning, where the Continuous delay learning solves the problem of large fluctuations in delay adjustment in Discontinuous delay learning. The two delay learning methods are combined with weight learning to obtain two supervised multi-spike learning algorithms that combine synaptic weight and delay plasticity, named as Discontinuous EML-DL and Continuous EML-DL, respectively. This paper shows that the addition of synaptic delay can significantly change the neuronal response and firstly verifies the learning dynamic characteristics of the two proposed algorithms. Furthermore, the properties of our proposed algorithms are explored and analyzed through some simulation experiments under different initial settings. We also show the effectiveness and necessity of joint with synaptic weight and delay plasticity through the interval selection task. The experimental results confirm that the combination of weight and delay plasticity improves the flexibility and selectivity of learning on the basis of retaining the efficiency of the benchmark algorithm. Finally, due to the inherent spatiotemporal characteristics of SNNs, we construct a spike-based isolated word recognition system based on threshold-based crossing coding approach and tests the proposed algorithms on Ti46 and TIDIGITS corpora. The experimental results show that our proposed learning rules outperform the baselines, and verify the feasibility and effectiveness of the proposed two algorithms in real-world task. These observations in this paper demonstrate the effectiveness of the joint synaptic weight-delay plasticity which enhances the learning ability of neurons and improves the performance of multi-spike learning algorithms. The research results provide valuable references for spike-based neuromorphic learning and computing.

Keywords spiking neural network; multi-spike learning; synaptic delay; neuromorphic computing

1 引 言

受人脑在各种复杂认知任务中的功耗低、速度快等出色表现启发,越来越多的学者基于人脑的信息处理机制开展人工智能方面的研究,以期望赋予人工智能类似于人脑的信息处理和认知能力^[1]. 近几十年来,通过模拟人脑的层级结构和相互连接方式,人工神经网络(Artificial Neural Networks, ANNs)飞速发展并在很多具有挑战性的任务中获得优异的表现,例如语音识别、自然语言处理、自动驾驶等^[2]. 但是 ANNs 对大量的训练数据和计算资源的依赖阻碍了它们在一些限制性任务上的进一步发展,例如移动设备上的关键词识别任务、嵌入式应

用等. 如何平衡好性能和计算资源之间的关系逐渐成为人们在使用 ANNs 时所关注的关键问题之一^[3-4].

不同于 ANNs 使用模拟值来处理信息的方式,人脑中神经元之间使用脉冲(spikes)来传递及处理信息,这一基于脉冲的离散处理方式被认为是大脑进行稀疏、高效信息处理的基础^[5]. 受此启发,基于脉冲的神经形态学习与计算逐渐发展起来,主要包括算法模拟和硬件实现两类研究方向. 由于脉冲的离散特性和复杂动态,算法模拟与硬件实现之间存在较大鸿沟,因此针对算法与硬件之间差距大的问题,研究简单、高效、可行性高、扩展能力强的算法模拟是必要的. 脉冲神经网络(Spiking Neural Networks, SNNs)^[6-7]使用脉冲进行信息传递及处理,是基于脉冲的神经形态学习与计算研究的核心,也是算法模

拟的主要模型。SNNs 采用事件驱动的方式处理时空信息,具有计算效率高、能耗低的优点,而且有可靠的生理学证据支撑。利用 SNNs 探索生物神经网络计算机制、掌握网络动态特征、构建高效学习算法与智能应用系统近年来受到越来越多不同领域学者的关注。

学习算法是脉冲神经网络研究的核心内容之一,其通过特定方式对网络参数进行调整,以使得网络对于给定输入信息做出期望的输出响应。最初受到神经科学中的生理现象启发,文献[8]提出了 Hebbian 学习,其定义了突触权重的增加源于突触前神经元对突触后神经元重复和持续的刺激,但是没有定义突触权重的减弱如何进行,而且学习不稳定。脉冲时间依赖可塑性(Spike-Timing-Dependent Plasticity, STDP)[9]是在 Hebbian 理论的基础上结合实验观察提出的,它基于突触前、后发放脉冲的相对时间以一种无监督的方式来调整突触权重(即突触之间连接的强度),但是其对时间连续性的依赖较高,进而会降低算法整体的学习性能。

因为脉冲离散不可导的特性,经典的梯度下降算法不能直接作用于脉冲。SpikeProp 算法[10]以期望和实际输出脉冲时刻之间的均方误差作为误差函数,基于线性近似的假设应用了梯度下降方法调整权重,使得神经元能在精确时刻发放脉冲,但是网络中每个神经元只能接收和发放单个脉冲,使得 SpikeProp 算法学习性能的稳定性较差。Tempotron[11]是一种利用膜电位进行二值决策的高效学习算法,它通过调整膜电位最大值和发放阈值之间的距离训练神经元对特定模式发放单脉冲作为响应,但是其发放单脉冲的决策机制不能充分利用传入脉冲在较大时间域内所携带的信息,这限制了其学习性能。

针对单脉冲学习算法中没有充分利用输入模式时间维度信息的问题,以发放期望脉冲序列为目标的监督学习算法逐渐发展起来。其中一类学习算法训练神经元在多个固定的精确时间点发放脉冲,具有代表性的算法包括 ReSuMe[12]、SWAT[13]、PSD[14]、SpikeProp[10]和 PBSNLR[15]等算法。ReSuMe 和 SWAT 都可以看作是 STDP 的变体,前者结合 STDP 和 anti-STDP 算法[13],后者结合了 BCM 规则的滑动阈值窗口,并引入输入数据的相似度增加学习的稳定性[13]。PSD(Precise-Spike-Driven)算法[14]追踪记录输入脉冲触发的突触电流,并以此为基础进行权重调整,减小实际输出脉冲序列和期望输出脉冲序列之间的误差,训练神经元对特定脉冲模式输出期望的脉冲

序列作为响应。PBSNLR[15]则借鉴了感知机的学习方法调整突触权重,训练期望发放脉冲时间点处的膜电位超过阈值,同时让其它位置的膜电位低于阈值,从而让神经元对传入的特定模式输出期望的脉冲序列,但是其计算复杂度相对较高。整体来看,这些以发放期望脉冲序列为目标的学习算法主要存在以下问题:(1) 这些算法基于期望发放脉冲序列已知的假设,需事先将精确的时间信息传递给神经元,而生物神经系统如何构建并完成这些过程仍然是未解之谜,缺乏可靠的生物支撑;(2) 这些算法受限于时间编码,不能扩展到其它类型的编码方法中;(3) 限定在给定的精确时间点发放脉冲减少了神经元学习的灵活性。

近年来,涌现了以输出期望数目脉冲为目标的一类多脉冲学习算法[16-19]。与在精确时间点发放脉冲的学习算法不同,这类算法由神经元自主选择决定发放脉冲的位置,学习更加灵活,而且在图像识别、声音分类等实际任务中获得了出色的性能表现[20-21]。文献[16]首次应用了输出期望数目脉冲的策略,通过定义临界阈值和输出脉冲数目之间的关系构造脉冲阈值表面函数(Spike-Threshold-Surface, STS),提出了 MST(Multi-Spike Tempotron)算法调整突触权重,指导神经元发放指定数目的脉冲,但是 MST 算法中求导过程繁杂、计算复杂度较高。为了进一步简化计算和提升这类多脉冲算法的性能,研究人员提出了一些改进算法。TDP(Threshold-Driven Plasticity)[17]算法基于发放脉冲瞬间膜电位变化是关于时间的线性函数的假设,简化了求导计算,可以扩展到不同类型的神经编码中,在鲁棒性、收敛性等方面提供了较为全面的理论支撑;MPD-AL[18]将膜电位瞬时状态的选择加入学习算法中,省略了 STS 函数的构造,在性能上有进一步的提升;文献[19]利用一种简化的泄露整合发放(Leaky Integrate-and-Fire, LIF)神经元模型,进一步提出了高效的多脉冲学习算法 EML(Efficient Multi-spike Learning),相比之前的相关算法,EML 的求导更加简单、学习效率更高、可扩展性更强。

突触是学习和记忆的关键基础单元,对于网络的动态属性起到至关重要的作用。当前脉冲学习算法的研究主要集中在调整突触权重上,但是突触的其它属性对于神经元的学习同样具有直接的重要影响,例如突触延迟。突触延迟与轴突和树突长度、形状的不同以及信息的传导速度的差异有关[22],它可以延迟信息传播、平衡兴奋与抑制,进而影响神经系

统某些特定的行为功能. 有生物研究表明突触延迟在生物系统中普遍存在, 在兴奋和抑制之间的相互平衡^[23]、视觉皮层的方向选择功能^[24]、听觉通路中的声源定位和信息处理^[25]等方面都发挥了重要的作用. 进一步有研究发现突触延迟在突触可塑性中是可以调整的^[26], 因此将突触延迟引入脉冲学习算法中, 对于探索神经网络行为动态和时序信息的高效处理具有重要意义.

为了探究突触延迟在脉冲学习算法中的性质以及扩展高效的脉冲学习算法的研究, 本文以简单高效的多脉冲算法 EML 为基础, 将突触延迟引入脉冲神经元模型中, 推导出突触延迟的学习规则. 由于直接求导得到的延迟学习存在调整波动较大的问题, 本文对延迟学习的规则进行了改进, 提出了相对平稳的延迟调整方案. 基于提出的两种延迟学习方法, 本文相应提出了两种联合突触权重和延迟可塑性的多脉冲监督学习算法, 这两种学习算法都可以指导神经元发放指定数目的脉冲. 然后, 本文进一步探索和分析了所提出算法的学习动态和在不同初始条件下的学习效率, 通过区间选择任务揭示了突触权重和延迟在学习过程中相互作用的机制, 并展现了权重和延迟可塑性联合的必要性. 最后, 本文构造了基于脉冲处理的孤立词识别系统, 集编码、学习、读出为一体, 并在两个语音数据集上进行了测试, 实验结果进一步验证了联合可塑性在时空信息处理上的有效性. 本文的研究一方面揭示了突触延迟以及联合可塑性是如何改善神经元学习的机制, 另一方面为提升多脉冲学习算法的性能提供了解决方案, 扩展了脉冲神经网络的研究内容.

本文第 2 节介绍突触延迟在脉冲神经网络中的相关工作; 第 3 节详细阐述本文所提出的方法; 第 4 节是实验与分析; 最后进行总结和未来展望.

2 相关工作

因为突触延迟可以显著影响神经系统的网络动态和行为功能, 目前已有一些研究将突触延迟引入到脉冲学习算法的研究中, 初步展示了这种引入是有效的.

关于突触延迟较早的研究工作可以分为两类: 延迟选择(delay selection)和延迟移动(delay shift)^[27], 在这两种方法中突触权重和延迟只有一方进行学习调整, 另一方则保持固定. 延迟选择方法中脉冲神经元的突触由很多子连接组成, 每个子连接都额外引

入了不同恒定常数值的突触延迟, 使得突触延迟覆盖一定的范围, 只有突触权重进行学习更新. 例如文献[10]中的 SpikeProp 算法便采用了该方法, 通过权重学习增强带有合适突触延迟的连接强度, 并减弱其它不合适延迟的连接强度. 延迟移动策略中突触权重设置为常数, 突触延迟可以进行学习调整, 例如 DELTRON^[28]采用了类似 Tempotron 的架构调整突触延迟, 可以用于脉冲模式存储和分类, 作用的机制类似于重合检测器.

突触权重和延迟的协同作用对于神经元的脉冲动态响应至关重要^[29]. 近年来, 突触权重和延迟联合学习的研究逐渐涌现. DL-ReSuMe^[30]在 ReSuMe 算法的基础上引入了突触延迟, 定义了输入脉冲对于突触后膜电位贡献随时间变化的轨迹函数, 通过对轨迹函数求逆来反向调整突触延迟, 但是在学习过程中只调整一次突触延迟, 对脉冲序列精确时间信息已知的假设依赖程度较高; 文献[31]通过核函数将离散的脉冲序列映射为连续的模拟值, 从而应用经典的梯度下降算法调整突触权重和延迟; 文献[32]定义了输入脉冲触发最大膜电位时刻与输出脉冲时刻之间的距离, 以此为基础结合输出脉冲的动态和突触的类型调整突触延迟, 然后基于 ReSuMe 和 PBSNLR 算法提出了突触权重和延迟联合学习的算法 ReSuMe-DW 和 PBSNLR-DW, 与 DL-ReSuMe 相比简化了计算; 而文献[33]改进了 SpikeProp 算法只能处理单脉冲输入的不足, 将其扩展到更通用的输入和突触连接类型, 基于在精确时间点发放脉冲的策略对突触权重和延迟进行学习, 并在图像分类、坐标转化等方面进行了应用探索.

总体来说, 目前对突触权重和延迟联合学习的研究大都是基于在精确时间点发放脉冲序列的策略, 缺乏针对基于发放期望脉冲数目的多脉冲算法中突触权重和延迟联合可塑性的研究. 能否以及如何将突触延迟可塑性整合到基于发放期望脉冲数目的多脉冲算法中来进一步提高算法效率仍然是一个亟待探索的重要科学问题.

3 方 法

3.1 脉冲神经元

与传统人工神经元使用连续的模拟值不同, 脉冲神经元采用离散的脉冲作为输入输出. 经过多年的研究和发展, 研究人员目前已提出多种不同的脉冲神经元模型. 这些模型在模拟生物神经元不同的

神经动态学特征的逼近程度和计算复杂性上各有侧重,包括 Hodgkin-Huxley 模型、Izhikevich 模型、脉冲响应模型 (Spike Response Model, SRM) 和 LIF 模型等^[34],其中 LIF 和 SRM 模型由于简洁性以及可解析性而在类脑计算研究领域中广泛使用。本文以 EML 算法作为拓展研究的基准,神经元初始模型采用文献[19]中的单指数核 LIF 模型。

突触延迟在生物上一般被认为是突触前膜的内向电流峰值与通过突触后膜的内向电流起始点之间的时间间隔^[35]。考虑到突触延迟在生物上的定义,这里将突触前神经元发放脉冲到突触后神经元接收脉冲产生动态响应之间的时间间隔建模为突触延迟。那么,有 N 个传入的单指数核 LIF 神经元的突触后膜电位可以表示为

$$V(t) = \sum_{i=1}^N w_i \sum_{t_i + d_i \leq t} \kappa(t - t_i - d_i) \vartheta \sum_{t'_j \leq t} \kappa(t - t'_j) \quad (1)$$

这里, t_i 是来自第 i 个传入神经元的第 j 个脉冲的时间, w_i 和 d_i 分别表示对应的突触权重和突触延迟, ϑ 代表发放阈值, t'_j 是当前神经元输出的第 j 个脉冲的时间。 $\kappa(t) = \exp(-t/\tau)$ 是一个指数函数,用来描述输入脉冲对膜电位产生的影响,很显然 $\kappa(t)$ 随时间递减,同时考虑因果效应,规定在 $t < 0$ 的时候无响应输出。




图 1 脉冲神经元基本动态示意图

神经元不断整合输入的脉冲,当膜电位达到阈值时发放输出脉冲并复位,主要动态响应如图 1 所示。神经元接收如图 1(a) 灰色星标所示的原始脉冲模式,该模式有 10 个传入神经元(分别对应图 1(b) 中的一个连接权重),神经元在输入模式的刺激下展现出相应的动态响应;图 1(c) 显示了加入突触延迟前后神经元膜电位动态响应的变化,无突触延迟情

况下神经元对输入模式响应并对应发放出 2 个脉冲(图 1(c) 中的灰色虚线);而突触延迟的引入会延后输入的脉冲(图 1(a) 黑色圆点),使得神经元的膜电位动态也相应地发生显著改变(图 1(c) 中的黑色曲线);图 1(d) 则显示了加入突触延迟前后核函数 $\kappa(t)$ 的动态变化。

3.2 权重可塑性

本文遵循文献[16-17,19]中使用的脉冲阈值表面 STS 函数。通常情况下,神经元阈值越高,其发放的脉冲数目就越少,因而存在一个临界阈值 ϑ^* ,在该位置输出的脉冲数目从 $k-1$ 变到 k 。STS 据此定义了神经元输出脉冲数目和发放阈值之间的单调关系,如图 2 所示。




图 2 脉冲阈值表面函数示意图

每一个阈值临界值 ϑ^* 都会对应一个膜电位方程,即 $V(t^*) = v_{\max}(\vartheta^*) = \vartheta^*$,其中 $v_{\max}(\vartheta^*)$ 表示临界阈值 ϑ^* 所对应的亚阈值膜电位的最大值,并由此可以得到相应临界阈值所在时刻点 t^* 。根据因果效应,在 t^* 时刻前出现的脉冲会对膜电位产生影响,并通过多个输出脉冲进行因果关联传递。文献[15]发现这种对输出脉冲的连续依赖可以忽略不计,所以临界阈值 ϑ^* 对于第 i 个突触权重的导数可以被简化并表示为

$$\frac{\partial V(t^*)}{\partial w_i} = \sum_{t'_j + d_i \leq t^*} \kappa(t^* - t'_j - d_i) \quad (2)$$

由式(2)可以构建出对突触权重的调整算法。这里采纳了文献[17,19]中逐步调整输出脉冲数目的方法。相应的突触权重的学习算法如下所示:

$$\Delta w = \begin{cases} -\lambda \frac{d\vartheta_{n_o}^*}{dw}, & n_o > n_d \\ \lambda \frac{d\vartheta_{n_o+1}^*}{dw}, & n_o < n_d \end{cases} \quad (3)$$

其中, λ 是权重调整的学习率。从式(3)可以看出,当实际输出的脉冲数目 (n_o) 大于期望输出数目 (n_d) 时,学习算法执行长时程抑制(Long-Time Depression,

LTD),反之进行长时程增强(Long-Time Potentiation, LTP).

3.3 延迟可塑性

3.3.1 间断延迟学习(Discontinuous delay learning)

在以上权重可塑性讨论的基础上,可以从式(1)描述的神经元动态方程直接推导得到临界阈值 ϑ^* 对于突触延迟 d_i 的导数,具体的形式如下所示:

$$\frac{\partial V(t^*)}{\partial d_i} = w_i \sum_{t_i^j + d_i \leq t^*} \frac{1}{\tau} \exp\left(-\frac{t^* - t_i^j - d_i}{\tau}\right) \quad (4)$$

3.3.2 连续延迟学习(Continuous delay learning)

首先,定义延迟后输入脉冲和临界阈值所对应的时间节点 t^* 之间的距离 $\Delta t_D = t^* - t_i^j - d_i$. 则式(4)可以表示为以下形式:

$$\frac{\partial V(t^*)}{\partial d_i} = w_i \sum_{t_i^j + d_i \leq t^*} \frac{1}{\tau} \exp\left(-\frac{\Delta t_D}{\tau}\right) \quad (5)$$

可以看到,式(5)中当 Δt_D 为 0 时,延迟后的输入脉冲与输出脉冲在时间轴上重合,输入脉冲对输出位置膜电位的贡献最大,突触延迟的调整反而是最大的,意味着输入的脉冲通过学习调整会被偏移到其它位置,导致整体上突触延迟的学习波动较大,增加计算负担,进而影响整体的学习性能. 结合式(5)中延迟调整的相关性质,称式(4)和(5)对应的延迟学习方法为间断延迟学习(Discontinuous delay learning).

为了减少延迟调整中的波动,让整个延迟学习过程更平稳连续,我们对间断延迟学习进行了改进,在式(5)中突触延迟的调整项上引入距离 Δt_D 乘积因子,改进后突触延迟的调整如下所示:

$$\frac{\partial V(t^*)}{\partial d_i} = w_i \sum_{t_i^j + d_i \leq t^*} \left[\frac{1}{\tau} \exp\left(-\frac{\Delta t_D}{\tau}\right) \cdot \Delta t_D \right] \quad (6)$$

对照式(4),本文命名式(6)对应的延迟学习方法为连续延迟学习(Continuous delay learning).

两种学习算法中归一化的延迟调整幅度关于距离 Δt_D 的延迟学习曲线如图 3 所示. 从图 3 中可以




图 3 延迟学习曲线

观察到,间断延迟学习方法中距离越小延迟调整的幅度反而越大, $\Delta t_D = 0$ 处是一个突变点,易引起较大的学习波动;连续延迟学习方法则解决了距离越近延迟调整幅度越大的问题, Δt_D 为 0 时突触延迟将不会被调整,解决了延迟调整跳跃的问题.

在式(4)和(6)的基础之上可以构建关于突触延迟 $\hat{d}$ 的学习规则,如下所示:

$$\Delta \hat{d} = \begin{cases} -\lambda_{\hat{d}} \frac{d\vartheta_{n_o}^*}{d\hat{d}}, & n_o > n_d \\ \lambda_{\hat{d}} \frac{d\vartheta_{n_o+1}}{d\hat{d}}, & n_o < n_d \end{cases} \quad (7)$$

其中, $\lambda_{\hat{d}}$ 是延迟学习的学习率.

根据延迟学习算法的不同,可以分别联合权重学习得到两种新的多脉冲学习算法:根据式(3)和间断延迟学习式(4)、(7)更新突触权重和延迟的方法称为 Discontinuous EML-DL;按照式(3)和连续延迟学习式(6)、(7)联合调整突触权重和延迟的规则称之为 Continuous EML-DL.

从学习算法的公式描述中可以看到,权重学习式(2)中包含突触延迟,说明延迟会影响突触权重起作用的时刻点,进而影响对权重的调整;同理,从延迟学习式(4)、(6)可知,权重的改变也会影响突触延迟的学习. 二者相互作用,相互影响.

4 实验与分析

4.1 学习动态

学习动态的研究可以帮助我们了解学习过程中神经元内部变量的变化过程,从而对学习算法有更深入的了解. 本节的实验主要展示了本文所提出的两种算法 Discontinuous EML-DL 和 Continuous EML-DL 在学习给定的脉冲模式发放期望数目的脉冲任务中神经元的动态调整过程,主要包括神经元学习前后的膜电位变化、学习过程中突触权重和延迟的演化以及期望和实际输出脉冲数目之间的误差变化.


在该任务中,为了更好地可视化学习过程中神经元内部变量的变化,我们设定具有 50 个传入的神经元在不同算法的训练下对给定的脉冲序列发放 10 个脉冲,每个传入的脉冲序列由频率为 4 Hz 的泊松(Poisson)过程随机构建并固定. 突触权重的初始值服从均值为 0.04、标准差为 0.02 的高斯分布,突触延迟被初始化为均值 10 ms、标准差为 5 ms 的高

斯分布,权重调整的学习率被设置为 10^{-4} . 生物神经网络的突触延迟一般分布在几毫秒到几百毫秒之间且其值不可能无限增大,因而我们给突触延迟设置了 100 ms 的学习上限. 两种延迟学习的学习率设定为 10^{-4} . 神经元的时间常数 τ 设置为 20 ms.

图 4 展示了神经元在两种算法指导下的学习动态,其中,子图(1)显示了 Discontinuous EML-DL 算法的学习动态,子图(2)描述了 Continuous EML-DL 算法的学习动态,图 4(a)、(e)分别展示了在 Discontinuous EML-DL、Continuous EML-DL 指导下神经元学习前后突触后膜电位 V_m 的变化,图 4(b)、(f)展示了部分突触权重在学习过程中的演化过程,图 4(c)、(g)显示了对应的延迟的变化,图 4

(d)、(h)显示了学习过程中误差的变化情况. 从图 4 可以看到经过迭代,神经元在两种学习算法的指导下都完成了相应的发放任务,误差虽然在学习中有所振荡但是都从 10 逐渐收敛到 0,突触权重和延迟也逐渐随着学习稳定到一定值.

对比两幅子图,可以看到在相同的初始条件设置下,Continuous EML-DL 比 Discontinuous EML-DL 稍微早一些完成任务. 其中,从图 4(c)可以观察到虽然 Discontinuous EML-DL 中的突触延迟学习地很快且有一部分延迟项的值很快就达到了上限,但是部分延迟项有很明显的阶段跳跃,尤其图 4(c)中学习后半段某些延迟项的跳跃直接导致误差波动的出现,这说明 Discontinuous DL-EML 的延迟学



(1) Discontinuous EML-DL的学习动态
(b)、(c)中不同颜色曲线分别代表不同
权重和延迟在学习过程中的变化曲线)

(2) Continuous EML-DL的学习动态
(f)、(g)中不同颜色曲线分别代表不同
权重和延迟在学习过程中的变化曲线)

图 4 两种算法的学习动态

习确实存在 3.3 节中所讨论的延迟突变、调整波动大、影响整体学习性能的问题,另外 Discontinuous DL-EML 中延迟学习波动较大也增加了神经元的计算;相比之下,图 4(g)描述的 Continuous EML-DL 算法中突触延迟的整体变化比较平缓,对应误差的变化也相对稳定,这说明连续延迟学习确实改善了间断延迟学习中存在的问题,减少了突触延迟在学习过程中的波动,从而促进了整体的学习性能.进一步观测可以看到,在输入和初始状态都相同的情况下,两种算法在整体上学习的趋势有一些类似,但是因为延迟学习方法的不同,神经元内部变量的变化也有所差异,使得神经元对同一模式响应的神经动态也会不一样(如图 4(a)和(e)中的膜电位动态所示).

4.2 学习效率分析

初始设置的不同会对算法的性能评估产生一定的影响,本节进一步探究了不同初始参数对本文所提出算法学习效率的影响.

这里对一些基本设置进行说明. 神经元接受来自 400 个传入神经元的输入,其中输入的脉冲模式服从频率为 2 Hz 的泊松分布,神经元被训练对该模式输出 10 个脉冲作为响应. 权重学习的学习率被设置为 10^{-4} ,权重初始化服从均值为 0.01、标准差为 0.01 的高斯分布,延迟初始化为均值为 10 ms、标准差为 5 ms 的高斯分布. 此外,考虑到上一节中延迟学习率相同的情况下,Discontinuous EML-DL 受到延迟波动的影响,整体表现比 Continuous EML-DL 表现性能差一些,本节对两种算法的学习率进行分别设置,使得突触延迟最大调整项幅度的差异尽量减小. 这里,设置 Discontinuous DL-EML 的延迟学习率为 10^{-5} ,Continuous DL-EML 的延迟学习率为 10^{-3} .

本节的实验选择传入神经元数目 N 和期望输出脉冲数目 n_{out}^* 作为初始设置的调控参数进行研究,其中 N 在 100 到 1000 之间以 50 为间隔进行取值, $n_{out}^* \in [1, 100]$. 为了评测算法性能,本节进行了 200 次独立实验对算法的评测指标进行统计,其中包括平均迭代次数、平均 CPU 运行时间以及 Discontinuous EML-DL、Continuous EML-DL 在迭代次数上对于基准算法 EML 的相对速度. 这里,相对速度定义为对应条件下基准算法 EML 的平均迭代次数/所提出算法的平均迭代次数,数值越高表示速度越快. 所有的模拟实验都是在 Intel E5-2609v4@1.70 GHz 平台上进行的.

传入神经元数目的不同决定了学习过程中可利用资源的多少,也就是固定长度的时间窗口内脉冲的数目以及可调整参数的多少. 这里,时间窗长 T 设置为 500 ms.

图 5 展示了传入神经元数目 N 对于不同算法的影响. 由图可见,不同的算法都呈现类似的趋势:随着传入的增加,学习收敛得越快,这说明固定长度的学习窗口内突触通道资源越冗余,神经元越可以充分利用过剩的资源更加轻易地完成发放任务(图 5(a)). 从迭代次数上可以看到,Continuous EML-DL 是三种算法中表现最优的,Discontinuous EML-DL 则完成任务最慢. 从图 5(b)显示的相对速度可以观察到,Discontinuous EML-DL 的相对速度在 1 以下,也就是说相对于基准算法来讲学习速度较慢;Continuous EML-DL 算法的相对速度整体在 1 以上,说明与基准 EML 相比学习速度更快. 在 $N=100$ 时,连续算法相对性能最好,随着传入神经元的增多,相对学习速度趋于一致,这说明在突触资源受限的情况下,Continuous EML-DL 算法的优势更加明显.





图 5 不同多脉冲学习算法受不同传入神经元数目的影响

进一步分析发现随着传入神经元的增加,联合突触延迟的两种算法和基准算法这三者的差距都在不断缩小.例如在 $N=1000$ 时,三种学习算法的学习速度趋于一致.这些实验现象展示了突触权重和延迟等各种资源之间的关联性:当突触资源丰富时,神经元可调控的参数选择较多,对突触延迟的依赖较小;当资源较少时,突触延迟对学习性能的改进作用则更加明显.

期望输出脉冲的数目 n_{out}^* 决定了神经元在给定

任务情况下需要达到的输入状态,通过调整其参数选择可以帮助我们更好地观察不同算法学习效率上的差异.在该实验中为了可以较为清晰地看到不同算法之间的差异以及进一步检查学习算法在脉冲分布较为广泛的情况下的学习性能,这里设置时间窗口的长度为 1 s,传入神经元数目为 100.除了基准算法 EML 以外,这里还选取了多脉冲学习算法 TDP^[17]作为实验对照,以进行更深层次的分析.具体的实验结果如图 6 所示.




图 6 不同多脉冲学习算法随期望输出的脉冲数目 n_{out}^* 的性能评价

图 6(a)显示了平均迭代次数随期望输出脉冲数目 n_{out}^* 的变化,可以看到在期望输出的脉冲数目较小时,几种学习算法之间的差距很小,随着期望的输出越多,学习算法所需要的训练次数也逐渐增加.其中,TDP 完成任务所需要的迭代次数最少,Continuous EML-DL 次之,Discontinuous EML-DL 算法需要的迭代次数最多.而从图 6(b)可以看到,TDP 完成任务消耗的 CPU 时间反而是最多的,EML 最快完成任务,这一观察跟文献[19]中的研究保持一致,而 Discontinuous EML-DL 和 Continuous EML-DL 算法因为增加了额外需要学习的突触延迟参数,比基准算法 EML 要慢一点.重要的是,由图可见,即使神经元计算复杂度增加了,本文提出的两种算法完成任务所需要的 CPU 时间仍然要比 TDP 少,约为 TDP 所需要的 CPU 时间的十分之一,继承了基准算法 EML 运行速度快的优势.图 6(c)中的相对速度进一步放大了在迭代次数上本文提出的两种算法与基准算法之间的相对关系,可以看到 Discontinuous EML-DL 算法的相对速度均在 1 以下,这和图 5(b)中展示的实验结果一致,再次表明间断延迟学习的较大波动增加了计算,使得 Discontinuous EML-DL 的表现要比基准算法 EML

差;而 Continuous EML-DL 算法完成任务需要的迭代次数相对少一些,相对速度性能较好.图 6(c)中 Discontinuous EML-DL 的比值曲线是先下降后上升的趋势,说明刚开始 n_{out}^* 较小时间断延迟学习存在的问题确实增加了学习的负担,到后期 n_{out}^* 越大,越需要权重学习,延迟对于输出的作用被削弱. Continuous EML-DL 曲线则基本是相反的趋势:先略微下降再上升再下降,尤其是在输出脉冲数目为 100 时,Continuous EML-DL 与 EML 的学习速度持平,验证了期望输出增多时突触延迟作用被削弱的发现.

综合以上的分析,本文提出的两种算法 Discontinuous DL-EML 和 Continuous DL-EML 保留了基准算法 EML 运行速度快的优势,Continuous DL-EML 算法在不同的初始设置下所需要的迭代次数不管是比基准算法 EML 还是 Discontinuous EML-DL 算法都要少,学习效率更高. Continuous DL-EML 中合理的突触延迟可塑性在传入脉冲时空分布比较稀疏的情况下或者说在突触资源具有限制性的条件下发挥的作用更大,这样的延迟可塑性在限制性条件下可以通过影响脉冲的时间分布帮助神经元更好地整合信息,从而促进整体的学习性能.

4.3 区间选择任务

在生物中延迟项(delay line)可被用来检测运动和定位声音^[25,36],本文所提出的算法是否具备完成类似任务的特性尚不清楚.为了进一步探究延迟学习加入的意义以及学习算法中突触权重和延迟两种可塑性相互作用的内在机制,本节设计了区间选择任务.结合4.2节的实验结果,这里选择 Continuous EML-DL 算法作为本文所提出算法的代表,下面对区间选择任务的实验设置进行说明.

区间选择任务设置了一个拥有两个突触的神经元,神经元的基本结构如图7(a)所示.每个突触只有单个脉冲传入,脉冲传入的时间点分别记为 t_1 、 t_2 ,两个脉冲之间的时间差定义为 $\Delta t = t_2 - t_1$,显然这个时间差可正可负.接下来,我们构造了一系列脉冲对模式,也就是设定 Δt 取不同的值.然后,我们任意选定了一个目标区间,神经元对 Δt 在目标区间的脉冲模式发放一个脉冲,否则保持静默.在学习过程中,如果神经元输出错误的响应,突触权重和延迟将会被调整.在区间选择任务中,神经元的变量初始化如下:因为突触资源有限,所以突触权重的初始值服从均值为 0.45、标准差为 0.1 的高斯分布,突触延迟以及权重、延迟学习的学习率的初始设置和 4.2 节中关于 Continuous EML-DL 中的实验设置相同.这里,学习前后最大的膜电位值 $V_{\max}$ 被记录下来评价任务完成情况.




图7 区间选择任务示意图

图7(b)展示了初始状态、正区间选择任务、负区间选择任务中 $V_{\max}$ 随时间差 Δt 的变化情况.可以看到初始状态(无突触延迟)下 $\Delta t = 0$ 时 $V_{\max}$ 最大,

这是因为同步的两个脉冲引发的动态膜电位最大(图7(b)中的黑色曲线).在没有突触延迟的情况下, Δt 为 0 的脉冲模式总会导致最大的膜电位值 $V_{\max}$,也就是说 $V_{\max}$ 的最大值被锁定在 $\Delta t = 0$ 处,缺乏灵活性,我们称这种现象为最大值锁定问题.由于最大值锁定问题的存在,对于目标区间没有包含 $\Delta t = 0$ 的区间选择任务,神经元不可能在只有权重调整的条件下完成任务.得益于突触延迟在时间轴上的偏移作用,最大值锁定问题可以由本文所提出的结合突触延迟的算法解决.可以看到,图7(b)中蓝色和橘黄色曲线峰值的位置发生了转移,神经元在目标区间内的 $V_{\max}$ 值都超过了 1,表示不论目标区间的正负(图中阴影部分所示),神经元在 Continuous EML-DL 算法的指导下都可以成功在对应的目标区间作为输入时发放脉冲,而对于非目标区间的输入则保持静默($V_{\max}$ 值小于 1),完成了区间选择任务.类比生物神经网络对于运动估计感知的工作机制,区间的正负可代表运动的方向,例如从左到右或者从右到左,区间的长度则可以关联运动的速度(短区间表示运动速度快).图7(b)的结果表明本文提出的学习算法增强了神经元学习的灵活性和对输入脉冲模式的选择能力,也表示本文所提出的联合突触权重和延迟可塑性的学习算法可以用于并解释运动感知方面的模型与机制,训练神经元对运动的方向和速度具有特定选择性.

然而突触权重和延迟可塑性是如何具体相互协调完成区间选择任务的呢?为了探究神经元完成区间选择任务的内在机制,我们记录了学习过程中神经元内部变量的调控动态,包括选择误差、权重加和 $\sum w = w_1 + w_2$ 、延迟差 $\Delta d = d_1 - d_2$ 的变化,分别展示在图8的(a)、(b)、(c)子图中.从图8可以看到不论任务的设定是对正区间还是对负区间进行选择,随着学习的进行,神经元内部状态都逐渐趋于稳定.在数十个迭代学习后,误差从一个相对较大的初始值收敛到 0 附近;权重加和 $\sum w$ 也稳定在一定范围内,结合图7我们发现 $\sum w$ 收敛后的大小和所学习区间的长度成正比,例如图7(b)中期望学到的负区间长度为 20ms,正区间长度是 40ms,与此相对应的可以看到图8(b)中负区间的权重加和 $\sum w$ 的稳定值要比正区间的小一些,这和图7(b)中所显示的负区间任务中 $V_{\max}$ 的最大值也相应比正区间的小的现象保持一致.另外,延迟差 Δd 的符号和期望学习区间的符号保持一致.结合图7(b)和图8(c)可以推断




图 8 区间选择任务中神经元内部变量的变化

出突触延迟可以通过同时偏移传入的脉冲补偿传入脉冲之间的时间差,从而使得神经元可以完成区间选择任务。

进一步分析研究发现,考虑只有延迟学习的情况下,最大值锁定问题虽然可以通过突触延迟的偏移作用来解决,但是如何精确地设置固定突触权重的值以使得神经元在目标区间发放脉冲成为一个难题。

综合区间选择任务的实验结果和分析,突触权重决定了区间学习跨度的大小,突触延迟通过偏移输入的脉冲来补偿输入之间的时间差异。因此,权重和延迟可塑性相互作用、相互协同,增强了神经元学习的灵活性和选择性。这些现象和生理实验中所发现的神经系统的方位选择性^[24,36]、声源定位^[25]等神经机制有一定类似,进一步突出了本文所提出的学习算法的重要性。

4.4 孤立词识别

孤立词识别是时序信息处理研究中的重要任务之一,以此任务为基础我们进一步测试了所提出的两种算法在实际应用问题上的学习性能。本文选取了两个经典常用的语音数据集:Ti46 语料库^[37]中的孤立词子集和 TIDIGITS 语料库^[38]。Ti46 语料库包括来自 16 个说话人的口语样本,这里我们选取 Ti46 的数字子集和孤立词子集 Ti20 作为实验参考,其中 Ti46 的数字子集包含 0 到 9 十个类别的英文口语,标准划分包含 1595 个样本为训练集、2542 个样本为测试集;Ti20 除了包含 0 到 9 十类数字口语,还包含了其它十类英文孤立词,选其中 3186 个样本为训练集、5082 个样本为测试集。TIDIGITS 语料库包含了 0 到 9 以及 oh 的 11 个类别的孤立词样本,这些样本来自 22 个方言地区,其中,2464 个样本为训练集、2486 个样本为测试集。

为了使用脉冲神经网络对语音信号进行学习和处理,需要将语音信号转换成脉冲神经网络可以处理的脉冲形式。这里我们借鉴了多脉冲声音分类任务中的识别框架^[21],构造了可以结合本文所提出算法的孤立词识别框架,整个框架的流程如图 9(a)所示,分为三个阶段:编码、学习和读出。原始的声音文件经过编码处理变成脉冲模式,然后输入到神经元进行学习分类,最后根据输出神经元的响应读出分类结果,完成整个识别过程,下面将详细描述每个阶段的流程。

在编码阶段,输入的语音信号经过基于阈值的交叉编码前端转化为脉冲序列^[16]。在基于阈值的交叉编码前端中,指定频率通道中信号功率向上(onset)和向下(offset)的交叉点被认为是基本的声学事件,这些被提取出来并映射成相应的脉冲,用于后续的学习和处理。具体来说,输入的语音(图 9(b))首先经过傅里叶变换转换成语谱图(图 9(c)),接下来,我们用 16 个对数形式的梅尔滤波器对语谱图进行平滑处理,其中这 16 个滤波器覆盖了 360 Hz 到 8000 Hz 的人耳听力频率范围,滤波后得到的语谱图再进行归一化处理。然后,我们在 0 到 1 之间等间隔设置 15 个阈值,经过处理后得到的语谱图中每个频率通道上的信息可以看作是随时间变化、取值分布在 0 到 1 之间的曲线,当曲线向上或向下超过所设置的阈值时,我们认为对应的编码神经元就在该时间点发放一个脉冲,对应的神经元编号和时间值被记录(图 9(d))。由此,相应的语音输入信号被转换成了脉冲神经网络可以处理的脉冲模式(图 9(e))。图 10 展示了基于阈值的交叉编码示意图,可以看到编码后的脉冲模式的时空分布与语谱图中共振峰的位置基本重合,说明这里使用的编码前端可以提取到语音信号中具有区分性的特征信息。




图 9 孤立词识别框架示意图




图 10 基于阈值的交叉编码示意图

在学习阶段,编码得到的脉冲模式输入到分类层进行学习训练,每个对应的分类神经元被训练对属于自己目标类别的脉冲模式发放指定数目的脉冲,对其它类别则保持静默.在测试读出阶段,当分类神经元对自己目标类别的脉冲模式发放的脉冲数目比其它神经元对该类脉冲模式发放的多时,我们认为分类成功(图 9(f)).

除了基准算法 EML 以外,为了显示多脉冲算法的优势,这里还选取了单脉冲算法 Efficient Tempotron (ET)^[39] 作为实验对照,其中 ET 中的脉冲神经元模型与本文使用的相同.

表 1 列出了不同脉冲架构在孤立词识别任务上的性能表现,其中 Aurora 是基于 TIDIGITS 数据集加入背景噪声形成的子集,包括 500 个干净的训练样本和 500 个加噪的测试样本.根据表 1 中的实验

结果可以看出在三个数据集上,相比单脉冲算法 ET,多脉冲算法都获得了更好的结果,再次验证了多脉冲学习算法的优势,与文献[20-21]中的研究结果保持一致.进一步可以看到,本文提出的两种算法在三个数据集上获得的准确率都比基准算法 EML 高,验证了联合权重和延迟可塑性在孤立词识别任务上的可行性和有效性,说明突触延迟的加入可以改善多脉冲学习在时序信号处理任务上的性能表现.通过进一步比较发现,Continuous EML-DL 算法的表现要比 Discontinuous EML-DL 算法更好,突出了连续延迟学习的有效性以及优势.

表 1 不同脉冲架构在孤立词识别任务上的结果

模型	数据集	准确率/%
Liquid State Machine ^[40]	Ti46 的数字子集	92.30
SWAT ^[13]	Ti46 的数字子集	95.25
ET	Ti46 的数字子集	86.00
EML	Ti46 的数字子集	93.88
Discontinuous EML-DL	Ti46 的数字子集	95.72
Continuous EML-DL	Ti46 的数字子集	97.64
ET	Ti20	73.50
EML	Ti20	83.80
Discontinuous EML-DL	Ti20	89.60
Continuous EML-DL	Ti20	92.12
Spikesignature+SVM ^[41]	Aurora	91.00
Spiking CNN+HMM ^[42]	Aurora	96.00
SOM+Tempotron ^[43]	TIDIGITS	97.40
2D Convolutional SNN (BRP) ^[44]	TIDIGITS	94.86
MPD-AL with $N_d=3$ ^[18]	TIDIGITS	95.35
MPD-AL with dynamic decoding ^[18]	TIDIGITS	97.52
ReSuMe-DW ^[32]	TIDIGITS	92.45
PBSNLR-DW ^[32]	TIDIGITS	96.50
ET	TIDIGITS	78.86
EML	TIDIGITS	92.18
Discontinuous EML-DL	TIDIGITS	93.17
Continuous EML-DL	TIDIGITS	95.47

在 Ti46 的数字子集上, 和表 1 中其它架构的脉冲算法工作相比, 本文提出的两种算法 Discontinuous EML-DL 和 Continuous EML-DL 优于其它方法(SWAT^[13] 和 Liquid State Machine^[40])的性能, 达到了 95.81% 和 97.89% 的准确率, 同时我们的算法使用了更少的训练样本, 再次验证了本文提出的两种学习算法在孤立词识别任务中的优异性能。

在 TIDIGITS 数据集上, MPD-AL^[18] 采用了动态解码方法, 获得了 97.52% 的准确率; 自组织映射(SOM)的脉冲框架使用了大量的连续语音训练 SOM 的特征提取能力, 采用 Tempotron 算法分类时使用了 3950 个孤立词语音做训练和 1000 个孤立词样本做测试, 获得了 97.40% 的准确率^[43]; 多层 SNN 框架使用了二维卷积和 BRP(Biologically plausible Reward Propagation), 在 TIDIGITS 上达到了 94.86% 的准确率^[44]。综合以上的分析以及表中所列出的结果, 在 TIDIGITS 上, 在保有训练测试比为 1:1、整体框架比较简单且没有使用复杂特征提取方法的情况下, 不论是和经典的脉冲框架^[18,41,43]、联合突触权重和延迟可塑性的算法框架^[32] 抑或是和多层 SNN 网络框架^[42,44] 相比, 本文提出的两种算法获得的结果是具有竞争力的, 尤其是 Continuous EML-DL 算法获得了 95.47% 的准确率。

综上所述, 我们所提出的两种联合突触延迟的学习算法在孤立词识别任务是可行、有效且高效的。

5 总结与展望

本文受到突触延迟在生物可塑性所起到的重要作用启发, 将突触延迟引入脉冲神经元模型中, 基于高效的多脉冲学习算法 EML, 构建出间断延迟学习方法, 针对间断延迟学习中延迟调整波动大的问题, 进一步提出了连续延迟学习方法, 进而将两种延迟学习分别与权重学习结合提出了两种多脉冲学习算法 Discontinuous EML-DL 和 Continuous EML-DL。本文对所提出的两种算法进行了系统研究, 验证了连续延迟学习的优势。实验结果表明延迟可塑性的加入虽然增加了神经元的计算复杂度, 但是一定程度保留了基准 EML 学习效率高的优势。另外, Continuous EML-DL 算法与 Discontinuous EML-DL 相比, 在各方面表现更优、更高效, 尤其在传入较稀疏、突触资源受限制的情况下更能发挥其优势。区间选择任务揭示了学习算法中突触权重和延迟相互作用及协同的机制, 验证了突触权重和延迟的联合可

塑性是必要的, 实验结果表明延迟学习的加入增强了神经元在学习上的选择性和灵活性。最后本文在孤立词识别任务上对提出的算法进行了应用测试及展示, 与基准算法及其它的脉冲架构方法相比, 本文提出的算法获得了较好的结果, 初步验证了我们的算法在实际任务中的有效性和可行性。

本文通过联合突触延迟进一步提升了高效多脉冲学习算法的性能优势, 展现出了突触延迟和权重联合学习的有效性, 为基于脉冲的高效学习算法研究提供参考, 具有扩展到其它脉冲算法及神经形态计算系统上的潜力。

参 考 文 献

- [1] Zeng Yi, Liu Cheng-Lin, Tan Tie-Niu. Retrospect and outlook of brain-inspired intelligence research. *Chinese Journal of Computers*, 2016, 39(1): 212-222(in Chinese)
(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, 39(1): 212-222)
- [2] LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*, 2015, 521(7553): 436-444
- [3] Strubell E, Ganesh A, McCallum A. Energy and policy considerations for deep learning in NLP//*Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics*. Florence, Italy, 2019: 3645-3650
- [4] Alvarez R, Park H-J. End-to-end streaming keyword spotting //*Proceedings of the 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Brighton, UK, 2019: 6336-6340
- [5] Roy K, Jaiswal A, Panda P. Towards spike-based machine intelligence with neuromorphic computing. *Nature*, 2019, 575(7784): 607-617
- [6] Maass W. Networks of spiking neurons: The third generation of neural network models. *Neural Networks*, 1997, 10(9): 1659-1671
- [7] Zhang Tie-Lin, Xu Bo. Research advances and perspectives on spiking neural networks. *Chinese Journal of Computers*, 2021, 44(9): 1767-1785(in Chinese)
(张铁林, 徐波. 脉冲神经网络研究现状及展望. *计算机学报*, 2021, 44(9): 1767-1785)
- [8] Lowel S, Singer W. Selection of intrinsic horizontal connections in the visual cortex by correlated neuronal activity. *Science*, 1992, 255(5041): 209-212
- [9] Caporale N, Dan Y. Spike timing-dependent plasticity: A Hebbian learning rule. *Annual Review of Neuroscience*, 2008, 31: 25-46
- [10] 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

- [11] Gütig R, Sompolinsky H. The tempotron: A neuron that learns spike timing-based decisions. *Nature Neuroscience*, 2006, 9(3): 420-428
- [12] Ponulak F, Kasiński A. Supervised learning in spiking neural networks with ReSuMe: Sequence learning, classification, and spike shifting. *Neural Computation*, 2010, 22(2): 467-510
- [13] Wade J J, McDaid L J, Santos J A, et al. SWAT: A spiking neural network training algorithm for classification problems. *IEEE Transactions on Neural Networks*, 2010, 21(11): 1817-1830
- [14] Yu Q, Tang H, Tan K C, et al. Precise-spike-driven synaptic plasticity: Learning hetero-association of spatiotemporal spike patterns. *PLoS One*, 2013, 8(11): e78318
- [15] Xu Y, Zeng X, Zhong S. A new supervised learning algorithm for spiking neurons. *Neural Computation*, 2013, 25(6): 1472-1511
- [16] Gütig R. Spiking neurons can discover predictive features by aggregate-label learning. *Science*, 2016, 351(6277): aab4113
- [17] Yu Q, Li H, Tan K C. Spike timing or rate? Neurons learn to make decisions for both through threshold-driven plasticity. *IEEE Transactions on Cybernetics*, 2019, 49(6): 2178-2189
- [18] Zhang M, Wu J, Chua Y, et al. MPD-AL: An efficient membrane potential driven aggregate-label learning algorithm for spiking neurons//Proceedings of the AAAI Conference on Artificial Intelligence. Hawaii, USA, 2019: 1327-1334
- [19] Yu Q, Li S, Tang H, et al. Toward efficient processing and learning with spikes: New approaches for multispike learning. *IEEE Transactions on Cybernetics*, 2022, 52(3): 1364-1376
- [20] Yu Q, Song S, Ma C, et al. Temporal encoding and multi-spike learning framework for efficient recognition of visual patterns. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, Early Access
- [21] Yu Q, Yao Y, Wang L, et al. Robust environmental sound recognition with sparse key-point encoding and efficient multispike learning. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, 32(2): 625-638
- [22] Debanne D, Campanac E, Bialowas A, et al. Axon physiology. *Physiological Reviews*, 2011, 91(2): 555-602
- [23] Barral J, Reyes A D. Synaptic scaling rule preserves excitatory-inhibitory balance and salient neuronal network dynamics. *Nature Neuroscience*, 2016, 19(12): 1690-1696
- [24] Rossi L F, Harris K D, Carandini M. Spatial connectivity matches direction selectivity in visual cortex. *Nature*, 2020, 588(7839): 648-652
- [25] Butman J A, Suga N. Synaptic mechanisms shaping delay-tuned combination-sensitivity in the auditory thalamus of mustached bats. *Hearing Research*, 2016, 331: 69-82
- [26] Lin J-W, Faber D S. Modulation of synaptic delay during synaptic plasticity. *Trends in Neurosciences*, 2002, 25(9): 449-455
- [27] Paugam-Moisy H, Martinez R, Bengio S. Delay learning and polychronization for reservoir computing. *Neurocomputing*, 2008, 71(7-9): 1143-1158
- [28] Hussain S, Basu A, Wang R M, et al. Delay learning architectures for memory and classification. *Neurocomputing*, 2014, 138: 14-26
- [29] Boudkazi S, Carlier E, Ankri N, et al. Release-dependent variations in synaptic latency: A putative code for short-and long-term synaptic dynamics. *Neuron*, 2007, 56(6): 1048-1060
- [30] Taherkhani A, Belatreche A, Li Y, et al. DL-ReSuMe: A delay learning-based remote supervised method for spiking neurons. *IEEE Transactions on Neural Networks and Learning Systems*, 2015, 26(12): 3137-3149
- [31] Wang X, Lin X, Dang X. A delay learning algorithm based on spike train kernels for spiking neurons. *Frontiers in Neuroscience*, 2019, 13: 252
- [32] Zhang M, Wu J, Belatreche A, et al. Supervised learning in spiking neural networks with synaptic delay-weight plasticity. *Neurocomputing*, 2020, 409: 103-118
- [33] Hong C, Wei X, Wang J, et al. Training spiking neural networks for cognitive tasks: A versatile framework compatible with various temporal codes. *IEEE Transactions on Neural Networks and Learning Systems*, 2019, 31(4): 1285-1296
- [34] Gerstner W, Kistler W M, Naud R, et al. *Neuronal Dynamics: From Single Neurons to Networks and Models of Cognition*. UK: Cambridge University Press, 2014
- [35] Katz B, Miledi R. The measurement of synaptic delay, and the time course of acetylcholine release at the neuromuscular junction. *Proceedings of the Royal Society of London, Series B: Biological Sciences*, 1965, 161(985): 483-495
- [36] Fisher Y E, Sillescu M, Clandinin T R. Orientation selectivity sharpens motion detection in *Drosophila*. *Neuron*, 2015, 88(2): 390-402
- [37] Instruments T. TI 46-word speaker-dependent isolated word corpus (CD-ROM). Gaithersburg: NIST, 1991
- [38] Leonard R G, Doddington G. TIDIGITS speech corpus. Texas Instruments, Inc, 1993
- [39] Song S, Ma C, Sun W, et al. Efficient learning with augmented spikes: A case study with image classification. *Neural Networks*, 2021, 142: 205-212
- [40] Zhang Y, Li P, Jin Y, et al. A digital liquid state machine with biologically inspired learning and its application to speech recognition. *IEEE Transactions on Neural Networks and Learning Systems*, 2015, 26(11): 2635-2649
- [41] Tavanaei A, Maida A S. A spiking network that learns to extract spike signatures from speech signals. *Neurocomputing*, 2017, 240: 191-199
- [42] Tavanaei A, Maida A. Bio-inspired multi-layer spiking neural network extracts discriminative features from speech signals//Proceedings of the International Conference on Neural Information Processing. Guangzhou, China, 2017: 899-908

[43] Wu J, Chua Y, Zhang M, et al. A spiking neural network framework for robust sound classification. *Frontiers in Neuroscience*, 2018, 12: 836

[44] Zhang T, Jia S, Cheng X, et al. Tuning convolutional spiking

neural network with biologically plausible reward propagation. *IEEE Transactions on Neural Networks and Learning Systems*, 2021, Early Access



YU Qiang, Ph. D. , associate professor. His research interests include brain-inspired intelligence and computing,

GAO Jia-Lu, M. S. candidate. Her research interests focus on learning algorithms in spiking neural networks and neural coding.

Background

The mechanisms of cognition and solving complex problems in brain have attracted considerable attention, and spike-based temporal expression is considered as the basis of sparse and efficient information processing in brain. Inspired by this, spike-based machine intelligence has gradually developed. But there is a gap between software simulation and hardware implementation. Spiking neural networks (SNNs) are one of the potential and promising candidates for efficient processing like the brain where information is transmitted and processed with spikes. Designing efficient learning rule is a challenge for SNNs. Most existing learning algorithms are based on the adjustment of synaptic weights. However, other properties of synapses, such as synaptic delay, have been proved to play a fundamental and essential role on neuron learning. Although some studies have either explored the plasticity of synaptic delay itself or studied the joint learning with synaptic weights, most of those study are based on the strategy of firing spike trains at precise times. It is still an open question whether and how to integrate the synaptic delay plasticity into the multi-spike algorithms based on the desired number of spikes to further improve the efficiency.

A series of multi-spike learning methods have recently emerged, which can train neurons to fire a desired number of output spikes without requiring their precise timings, such as

neural networks, artificial intelligence, and theoretical neuroscience.

TANG Hua-Jin, Ph. D. , professor. His current research interests include neuromorphic computing and chips, and intelligent robot.

HUANG Tie-Jun, Ph. D. , professor. His main research interests include visual information processing and neuromorphic computing.

EML (Efficient Multi-spike Learning). This type of multi-spike learning is capable of training neurons to complete different complex tasks more flexibly, and to achieve competitive results on the real-world tasks. Based on the previous multi-spike learning algorithm EML, we integrate synaptic delay into spiking neuron model and derive the Discontinuous delay learning. The Discontinuous delay learning has the problem of large fluctuations in delay adjustment, so Continuous delay learning is proposed to solve it. Then, we combine the two delay plasticity methods with weight plasticity to propose multi-spike learning algorithms, named as Discontinuous EML-DL and Continuous EML-DL. On the basis of retaining the advantages of the original benchmark algorithm EML, our proposed learning algorithms further enhance the selectivity and flexibility of neuron learning. The simulation results show that the Continuous delay plasticity has more advantages in different initial settings. Furthermore, our proposed rules achieve higher accuracy on the isolated words recognition tasks than the baselines and are comparable with other spike-based frameworks, especially the Continuous EML-DL. Our works extend the research content of spiking neural networks and provide guidance for spike-based neuromorphic learning and computing.