

# 一种脉冲神经元监督学习的直接计算方法

陈国军<sup>1</sup>, 蔺想红<sup>2</sup>, 王国恩<sup>1</sup>, 王向文<sup>2</sup>

(1. 武汉大学城市设计学院, 湖北武汉 430072; 2. 西北师范大学计算机科学与工程学院, 甘肃兰州 730070)

**摘要:** 精确脉冲定时作为一种神经元信息编码方式更具生物可解释性, 使用精确脉冲定时编码的脉冲神经元具有更为强大的时空信号处理能力. 脉冲神经元监督学习是神经计算的重要方面, 目的是使神经元对给定输入脉冲在期望时刻发放脉冲. 通过分析输入脉冲序列、期望输出脉冲序列与实际输出脉冲序列的关系, 发现已有脉冲神经元监督学习算法的脉冲选择与计算较为复杂, 致使不能达到理想学习效果. 通过去除影响整体学习效果的多余脉冲计算, 构建用于脉冲神经元突触权值调整的双脉冲单元, 提出了一种适用于脉冲神经元监督学习的直接计算方法. 该方法基于输入脉冲, 使用期望输出脉冲与实际输出脉冲的时序关系, 直接计算突触权值的调整量; 每个输入脉冲在每次迭代中最多计算一次, 有效减少了脉冲计算次数. 实验结果表明, 直接计算方法作为脉冲神经元监督学习的一般性脉冲计算优化策略, 可以大幅提高已有算法的学习准确率.

**关键词:** 监督学习; 脉冲神经元; 脉冲神经网络; 脉冲序列; 直接计算

**中图分类号:** TP183      **文献标识码:** A      **文章编号:** 0372-2112 (2021)02-0331-07

**电子学报 URL:** <http://www.ejournal.org.cn>      **DOI:** 10.12263/DZXB.20190350

## A Direct Computation Method of Supervised Learning for Spiking Neurons

CHEN Guo-jun<sup>1</sup>, LIN Xiang-hong<sup>2</sup>, WANG Guo-en<sup>1</sup>, WANG Xiang-wen<sup>2</sup>

(1. School of Urban Design, Wuhan University, Wuhan, Hubei 430072, China;

2. Computer Science and Engineering, Northwest Normal University, Lanzhou, Gansu 730070, China)

**Abstract:** The purpose of supervised learning for spiking neurons is to emit spikes at desired times. By analyzing the relationship between desired output spike train, actual output spike train, and input spike trains, we argue that the spike selection and calculation of existing algorithms are much complex. By removing the repetitive spike computations which have a negative effect on the overall learning performance, we construct a unit of pair-spike and propose a direct computation method of supervised learning algorithms for spiking neurons. Based on input spikes and the relationship between desired output spike train and actual output spike train, the proposed method utilizes every useful input spike selected only once to directly adjust the synaptic weights, which truly reduces the computational cost. Experimental results show that the direct computation method, as a general optimization strategy of supervised learning for spiking neurons, can effectively improve the learning performance of existing algorithms.

**Key words:** supervised learning; spiking neuron; spiking neural networks; spike train; direct computation

## 1 引言

传统人工神经网络 (Artificial Neural Networks, ANNs) 中, 模拟神经元仅使用以时间区间 (interval) 为单位的频率编码, 输出给定区间的模拟量<sup>[1]</sup>. 然而, 相关研究表明真实生物神经元的信号编码不仅基于脉冲的刺激频率, 更与脉冲的刺激时间密切相关; 相关实验

也证明神经计算中基于脉冲刺激时间的精确定时编码比脉冲频率编码更为有效<sup>[2,3]</sup>. 脉冲神经元 (Spiking Neuron, SNs) 使用脉冲精确定时编码, 将接收到的输入信号以脉冲序列的形式进行传递、处理, 更具生物真实性<sup>[4,5]</sup>. 相较于前两代神经网络而言, 由 SNs 组成的脉冲神经网络 (Spiking Neural Networks, SNNs) 作为第三代神经网络具有更为强大的高维非线性计算能力<sup>[6-9]</sup>, 在

复杂时空信号处理方面的表现尤为出色<sup>[10,11]</sup>.

SNs 的学习算法根据有无监督分为监督学习算法和无监督学习算法. 监督学习算法整体上分为梯度下降、突触可塑性和脉冲序列卷积三种类型<sup>[9,12]</sup>. 梯度下降算法使用梯度值和反向传播方法获得脉冲神经元关联程度用以调节权值,使实际输出序列与期望输出序列的偏差值逐渐减小. 这类算法主要包括 SpikeProp 及其衍生算法<sup>[13-15]</sup>;突触可塑性算法基于 Hebb 提出的突触可塑性 (synaptic plasticity) 规则,将脉冲时间依赖可塑性 (Spike-Timing-Dependent Plasticity, STDP) 机制用于脉冲序列学习<sup>[16,17]</sup>,代表性算法包括突触权值关联训练 (Synaptic Weight Association Training, SWAT)<sup>[18]</sup>、远程监督方法 (Remote Supervised Method, ReSuMe) 及衍生方法<sup>[19-21]</sup>;脉冲序列卷积算法通过卷积核将离散的脉冲时间序列转化为连续形式,运用一般性数学算子计算权值调整量<sup>[9,12]</sup>,线性代数法<sup>[22]</sup>、脉冲模式关联神经元 (Spike Pattern Association Neuron, SPAN)<sup>[23]</sup>、精准脉冲驱动 (Precise-Spike-Driven, PSD)<sup>[24]</sup>、脉冲序列核学习规则 (Spike Train Kernel Learning Rule, STKLR) 及衍生算法<sup>[25-28]</sup> 均属于这类算法. 除以上三类外,脉冲监督学习还有基于感知器、膜电势等其他具有不同特性的学习算法<sup>[29-31]</sup>.

脉冲神经元突触后脉冲序列的发放时间与输入脉冲序列和突触权值相关. 由于输入脉冲序列在学习过程中固定不变,脉冲监督学习通过调节突触权值调整脉冲发放时间. 输入脉冲、实际输出脉冲和期望输出脉冲组成了调整权值的脉冲集合,集合中脉冲的选择与计算是脉冲监督学习的重要研究方面. 本文通过分析脉冲序列关系,发现已有算法的多余脉冲计算;基于脉冲序列的生成机制,去除影响学习效果的多余脉冲计算,提取原有方法的有效计算部分,得到实际计算所需的双脉冲单元,将其构造为一种脉冲神经元监督学习通用的脉冲直接计算方法 (Direct Computation Method, DCM).

## 2 监督学习的直接计算方法

### 2.1 脉冲神经元的监督学习结构

如图 1 所示,脉冲神经元的学习结构含有编码层、输入层、输出层和监督层四个部分,通过调节输入层与输出层之间的突触权值进行监督学习<sup>[19-21,23-29]</sup>. 这种学习结构可描述为:(1)通过线性或泊松 (Poisson) 等编码方法,将神经信息在编码层编码为脉冲序列;(2)编码层生成的脉冲序列通过输入层神经元进入神经元突触部分,每个输入层单元对应一个输入脉冲序列;(3)输入脉冲序列经突触变换后进入输出层累积,激发输出单元发放实际脉冲序列;(4)比较监督层生成的期望

脉冲序列与实际输出序列,如不相等,结果用于调节突触权值.

脉冲序列  $s = \{t^f \in \Gamma: f = 1, 2, \dots, F\}$  表示由脉冲神经元在时间区间  $\Gamma = [0, T]$  内发放的脉冲时间有序序列,其数学表达式表示为:

$$s(t) = \sum_{f=1}^F \delta(t - t^f) \quad (1)$$

其中,  $t^f$  表示第  $f$  个脉冲的发放时间,  $F$  代表模拟区间的脉冲数量;  $\delta(t - t^f)$  是 Dirac delta 函数,当  $t - t^f$  为 0 时,  $\delta(t - t^f)$  等于 1,当  $t - t^f$  不为 0 时,  $\delta(t - t^f)$  等于 0. 对于图 1 所示的学习结构,定义  $s_i$  为第  $i$  条输入脉冲序列,  $s_a$  为实际输出脉冲序列,  $s_d$  为期望输出脉冲序列.




图1 脉冲神经元的学习结构

### 2.2 双脉冲单元的选取计算

脉冲神经元监督学习中,突触权值的调整依赖于输入脉冲序列、实际输出脉冲序列和期望脉冲序列的相对时序关系<sup>[25,26]</sup>. 应用 Widrow-Hoff 规则,第  $i$  个突触在  $t$  时刻的权值调整量  $\Delta w_i(t)$  可表示为:

$$\Delta w_i(t) = \eta s_i(t) [s_a(t) - s_d(t)] \quad (2)$$

其中,  $\eta$  表示学习率,  $s_i(t)$  表示第  $i$  个输入脉冲序列,  $s_a(t)$  表示实际输出序列,  $s_d(t)$  表示期望输出序列.

设  $t_i^f, t_a^g, t_d^h$  分别表示为第  $i$  个输入脉冲序列上第  $f$  个脉冲的发放时间、第  $g$  个输出脉冲的期望发放时间、第  $h$  个实际输出脉冲的发放时间. 由式(2)可知,神经元第  $i$  个突触权值  $w_i$  在  $t_a^g$  时刻增大,在  $t_d^h$  时刻减小. 根据  $t_i^f, t_a^g, t_d^h$  的时序关系,突触权值  $w_i$  的更新规则可表示为:

$$\Delta w_i(t_i^f) = \begin{cases} \sum_g \phi(t_a^g - t_i^f), & t_i^f < t_a^g \\ - \sum_h \phi(t_d^h - t_i^f), & t_i^f < t_d^h \end{cases} \quad (3)$$

其中,  $\phi(\bullet)$  表示突触权值更新函数. 式(3)使用的脉冲选择方法为原有方法,在本文中称为多脉冲法 (multi-spike). 多脉冲法的实例示意图如图 2 所示,  $t_a^1$  之前的输入脉冲用于在  $t_a^1$  时刻减小  $w_i$ ,  $t_d^1$  之前的输入脉冲用于在  $t_d^1$  时刻增大  $w_i$ . 由式(3)可以看出,对于任意一个输入脉冲  $t_i^f$ ,其对应的权值更新值为:

$$\Delta w_i(t_i^f) = \sum_g \phi(t_a^g - t_i^f) - \sum_h \phi(t_a^h - t_i^f) \quad (4)$$

图2实例中,  $t_a^1$  位于  $t_d^1$  之前,  $w_i$  应该增大; 然而, 使用多脉冲法, 位于  $t_a^1$  之后  $t_d^1$  之前的输入脉冲  $t_i^3$  和  $t_i^4$  参与一次计算用于  $t_a^1$  时刻减小  $w_i$ , 而  $t_a^1$  之前的输入脉冲  $t_i^1$  和  $t_i^2$  却参与了两次计算, 一次用于  $t_d^1$  时刻增大  $w_i$ , 另一次用于  $t_a^1$  时刻减小  $w_i$ . 基于脉冲神经元的脉冲生成机制可知,  $t_i^1$  和  $t_i^2$  时刻发放的输入脉冲足以在  $t_a^1$  时刻生成实际输出脉冲, 而无法获知假如  $t_a^1$  时刻不生成实际输出脉冲时基于  $t_i^1, t_i^2, t_i^3$  和  $t_i^4$  时刻的输入脉冲在  $t_d^1$  时刻的实际输入脉冲生成情况, 故可能存在  $t_d^1$  时刻的权值增加量小于  $t_a^1$  时刻的权值增加量, 导致调节错误.




图2 原有脉冲选择与计算方法示意图

基于脉冲神经元的脉冲生成机制同样可知,  $t_i^1$  和  $t_i^2$  时刻发放的输入脉冲足以使得神经元在  $t_a^1$  时刻发放实际输出脉冲; 而后,  $t_i^3$  和  $t_i^4$  时刻发放的输入脉冲难以使得神经元在期望时刻  $t_d^1$  发放实际输出脉冲. 因此, 应当首先使用  $t_i^1$  和  $t_i^2$  在  $t_a^1$  时刻减小  $w_i$ , 然后只使用  $t_i^3$  和  $t_i^4$  在  $t_d^1$  时刻增大  $w_i$ ; 而多脉冲法使用了与  $t_d^1$  不相关  $t_i^1$  和  $t_i^2$  在  $t_d^1$  时刻增大  $w_i$ , 产生了多余的脉冲计算, 改变了基于  $t_i^1$  和  $t_i^2$  的实际作用在  $t_a^1$  时刻完成的权值调节.

此外, 设  $t_a^g$  和  $t_a^h$  分别为  $t_i^f$  后的第一个期望输出脉冲与实际输出脉冲. 通过式(2)可以看出, 对于单脉冲而言, 当获得一个  $t_i^f$  的  $t_a^g$  和  $t_a^h$  后, 此  $t_i^f$  对权值的调整功能是确定的. 当  $t_a^h$  在  $t_a^g$  之前时,  $t_i^f$  到  $t_a^h$  的距离小于到  $t_a^g$  的距离, 权值减小; 当  $t_a^h$  在  $t_a^g$  之后时,  $t_i^f$  到  $t_a^h$  的距离大于到  $t_a^g$  的距离, 权值增大. 因此, 在所用输入脉冲数量相同的前提下, 如果  $t_i^f$  后的第一个输出脉冲为期望输出脉冲, 权值增大; 如果第一个输出脉冲为实际输出脉冲, 权值减小.

基于以上分析, 选择每个输入脉冲后的第一个输出脉冲作为这个输入脉冲的相关脉冲, 这两个脉冲组合为一个双脉冲单元. 这种双脉冲单元的脉冲选择方法称为双脉冲法(pair-spike). 使用双脉冲法, 构造了基于输入脉冲  $t_i^f$  的脉冲监督学习直接计算方法 DCM: 在每一次学习迭代过程中, 每一个输入脉冲基于其后第一个输出脉冲的类型(实际输出脉冲或期望输出脉冲)最多被选择一次, 直接用于突触权值调节量的计算. 使用 DCM 的式(4)转化为:

$$\Delta w_i(t_i^f) = \phi(t_{\min} - t_i^f) (t_a^h - t_a^g) / |t_a^g - t_a^h| \quad (5)$$

其中,  $(t_a^h - t_a^g) / |t_a^h - t_a^g|$  用于获得  $t_a^h$  和  $t_a^g$  中更靠近  $t_i^f$  的

脉冲时间(二者最小值), 控制权值增减. 将每个  $t_i^f$  的  $t_a^g$  和  $t_a^h$  均初始设置为正无穷, 式(5)可转化为:

$$\Delta w_i(t_i^f) = \begin{cases} \phi(t_{\min} - t_i^f) (t_a^h - t_a^g) / |t_a^g - t_a^h|, & t_a^g \neq t_a^h \\ 0, & t_a^g = t_a^h \end{cases} \quad (6)$$

以图3为例, 使用 DCM 时, 图中位于  $t_a^1$  前的输入脉冲用于增大  $w_i$ , 位于  $t_a^1$  之后  $t_d^1$  之前的输入脉冲用于减小  $w_i$ . 使用 DCM, 每次学习迭代中的实际计算次数取决于输入脉冲的数量和最后一个输出脉冲的发放时间. 对于每个  $s_i(t)$  而言, 基于 DCM 的学习算法在每次迭代中的脉冲实际计算次数等于最后一个输出脉冲前输入脉冲的数量.




图3 脉冲选择与直接计算方法DCM示意图

### 2.3 基于 DCM 的脉冲神经元监督学习算法

为了验证 DCM 的有效性, 选择突触可塑性算法 ReSuMe 和脉冲序列卷积算法 SPAN 作为实例与 DCM 结合进行脉冲序列学习. 为便于区分原有算法与结合 DCM 的优化算法, 在原有算法名称前加“D-”表示结合 DCM 的优化算法. 采用原有方法, 考虑所有输入脉冲, 使用 ReSuMe 的  $w_i$  调整量为:

$$\Delta w_i^{\text{ReSuMe}} = \eta \cdot A^+ \begin{bmatrix} \sum_g (a_R + \sum_{t_i^f < t_a^g} e^{-\frac{t_a^g - t_i^f}{\tau^+}}) \\ - \sum_h (a_R + \sum_{t_i^f < t_a^h} e^{-\frac{t_a^h - t_i^f}{\tau^+}}) \end{bmatrix} \quad (7)$$

其中,  $\eta$  为学习率(learning rate, LR), 用于控制学习的速度;  $a_R$  为加速学习的参数, 设为 0.001;  $A^+$  是振幅, 设为 1. 学习窗口的时间常数  $\tau^+$  设为 7ms<sup>[19]</sup>. 使用 DCM 与 ReSuMe 结合的学习算法 D-ReSuMe 对  $w_i$  的调整量为:

$$\Delta w_i^{\text{D-ReSuMe}} = \eta \cdot A^+ \sum_f \left[ a_R + \frac{(t_a^h - t_a^g) e^{-\frac{t_{\min} - t_i^f}{\tau^+}}}{|t_a^g - t_a^h|} \right] \quad (8)$$

基于  $\alpha$  核的 SPAN 对  $w_i$  的调整量为:

$$\Delta w_i^{\text{SPAN}} = \eta \left( \frac{e}{2} \right)^2 \begin{bmatrix} \sum_g \sum_f (|t_a^g - t_i^f| + \tau) e^{-\frac{|t_a^g - t_i^f|}{\tau}} \\ - \sum_h \sum_f (|t_a^h - t_i^f| + \tau) e^{-\frac{|t_a^h - t_i^f|}{\tau}} \end{bmatrix} \quad (9)$$

其中,学习窗口时间常数  $\tau$  设为  $7\text{ms}$ <sup>[23]</sup>. SPAN 与 DCM 结合的学习算法 D-SPAN 对  $w_i$  的调整量为:

$$\Delta w_i^{\text{D-SPAN}} = \eta \left( \frac{e}{2} \right)^2 \sum_f \left[ \frac{(t_{\min} - t_i^f + \tau) e^{-\frac{t_{\min} - t_i^f}{\tau}}}{(t_a^h - t_d^g) / |t_d^g - t_a^h|} \right] \quad (10)$$

### 3 实验模拟

#### 3.1 神经元模型及相似性度量

脉冲响应模型(Spike Response Model, SRM)可以表达神经元的内部状态,便于学习算法的转换,更具生物可塑性<sup>[4]</sup>. 因此,本文选择 SRM 作为实验的基本 SNs. SRM 的内部状态  $u(t)$  表示为:

$$u(t) = \rho(t - \hat{t}^f) + \sum_{i=1}^N \sum_{f=1}^{F_i} w_i \varepsilon(t - t_i^f) \quad (11)$$

其中,  $\hat{t}^f$  表示当前最后一个输出脉冲的发放时间,  $N$  为输入脉冲序列的数量,  $F_i$  为第  $i$  个输入脉冲序列上的脉冲数量. 由输入脉冲累加得到的 PSP 可以通过脉冲响应函数表示为:

$$\varepsilon(t) = \begin{cases} \frac{t}{\tau} e^{-\frac{t}{\tau}}, & \text{if } t \geq 0 \\ 0, & \text{if } t < 0 \end{cases} \quad (12)$$

其中,  $\tau^-$  是突触后膜电势的时间延迟常数. 在神经元内部状态的表达式(13)中,  $\rho(t - \hat{t}^f)$  描述了相对不应期(Relative Refractory Period, RRP)的状态变化,  $\rho(t - \hat{t}^f)$  的函数表达式为:

$$\rho(t) = \begin{cases} -2v e^{-\frac{t}{\tau_r}}, & \text{if } t \geq 0 \\ 0, & \text{if } t < 0 \end{cases} \quad (13)$$

其中,  $\tau_r$  是一个影响衰减函数形状的时间延迟常数,  $v$  为神经元膜电势的脉冲发放阈值. 实验中,  $\tau^-$  设为  $7\text{ms}$ ,  $\tau_r$  设为  $80\text{ms}$ ,  $v$  设为 1. 由于实验使用具有离散运行时间的计算机编程模拟神经网络,因而脉冲神经元模型处于离散进化模式,实验的离散精度设置为  $0.1\text{ms}$ <sup>[7]</sup>.

学习效果度量方面,使用一种相关性度量单位  $C$  测量期望输出脉冲序列与实际输出脉冲序列之间的差异<sup>[32]</sup>.  $C$  的计算公式为:

$$C = \frac{\mathbf{v}_a \cdot \mathbf{v}_d}{|\mathbf{v}_a| |\mathbf{v}_d|} \quad (14)$$

其中,  $\mathbf{v}_a$  和  $\mathbf{v}_d$  分别表示经高斯低通变换后的实际输出脉冲序列向量与期望输出脉冲序列向量,  $\mathbf{v}_a \cdot \mathbf{v}_d$  表示  $\mathbf{v}_a$  和  $\mathbf{v}_d$  的内积,  $|\mathbf{v}_a|$  和  $|\mathbf{v}_d|$  则各自对应两个向量的模,  $C$  等于 1 表示完全学习. 每组实验重复 30 次.

#### 3.2 变时长的脉冲序列学习比较实验

本部分包含两组变时长的比较实验. 第一组实验

中,输入层发放 400 个脉冲序列,监督层发放 1 个期望脉冲序列,所有序列均为 20Hz 的 Poisson 脉冲序列,400 个初始突触权值在  $(0, 0.2)$  随机分布;脉冲序列的时长从 200ms 开始,每次增加 200ms 直至 1000ms;200ms 时的最大迭代次数为 1000 次,时长每增加 200ms,最大迭代次数增加 500 次. 表 1 统计了本组实验中不同学习算法的实验参数和表现结果,包括学习率  $LR$ 、最大  $C$  的平均值  $M_c$  (四舍五入保留小数点后三位) 和达到最大  $C$  所用的平均学习迭代次数  $M_e$  (四舍五入保留整数).

表 1 第一组变时长脉冲序列学习的比较实验结果

算法	ReSuMe	SPAN	D-ReSuMe	D-SPAN	
200ms	$LR$	0.018	0.0009	0.0135	0.0005
	$M_c$	0.988	0.976	0.993	0.990
	$M_e$	102	196	165	220
400ms	$LR$	0.0107	0.0005	0.0102	0.0004
	$M_c$	0.985	0.975	0.993	0.989
	$M_e$	655	646	591	717
600ms	$LR$	0.0074	0.0004	0.0075	0.00035
	$M_c$	0.953	0.931	0.987	0.980
	$M_e$	756	960	739	937
800ms	$LR$	0.006	0.0003	0.006	0.00026
	$M_c$	0.941	0.953	0.987	0.980
	$M_e$	750	849	916	1058
1000ms	$LR$	0.005	0.00025	0.0045	0.00022
	$M_c$	0.884	0.900	0.980	0.976
	$M_e$	997	1382	1257	1352

由表 1 可见,所有算法的  $M_c$  均随脉冲时长的增加而逐渐减小,但优化算法相较原有算法在任意脉冲时长时均有更高的  $M_c$ . 例如,脉冲时长为 800ms 时 D-ReSuMe 的  $M_c$  比 ReSuMe 的  $M_c$  高 0.046. 随着脉冲时长的增加,优化算法对  $M_c$  的提高程度越来越大. 如表 1 中 SPAN 和 D-SPAN 在脉冲时长为 200ms 时的  $M_c$  差值为 0.014,而当脉冲时长增加到 1000ms 时  $M_c$  差值增大到了 0.076. 原有算法中的 ReSuMe 优于 SPAN,在三个时长时具有更高  $M_c$ ;优化算法中的 D-ReSuMe 同样优于 D-SPAN,在所有时长时均具有更高  $M_c$ . 这表明,在脉冲序列频率相同而时长改变时,DCM 没有改变算法之间的学习比较结果. 需要指出的是, D-SPAN 与 D-ReSuMe 的学习准确率差值相较原有算法有所减小. 学习效率方面,相较原有算法而言,使用 DCM 的学习迭代次数略有增加.

第二组实验中,期望脉冲序列的发放频率增加到 100Hz,其他设置不变. 实验结果如表 2 所示,  $M_c$  相较第一组实验整体大幅减小. 随脉冲时长增加,所有算法的

$M_c$ 均逐渐减小;但优化算法相较原有算法在任意脉冲时长时仍具有更高  $M_c$ ,且两者差距越来越大.例如,D-ReSuMe 和 ReSuMe 在脉冲时长为 200ms 时的  $M_c$  差值为 0.042,而当脉冲时长增至 800ms 时差值增大到了 0.14.虽然在脉冲序列频率不同而时长改变时 DCM 同样没有改变原有算法的  $M_c$  的相对比较结果,但是 D-SPAN 与 D-ReSuMe 之间的  $M_c$  差值大幅减小,D-SPAN 在脉冲时长为 600ms 和 1000ms 时的  $M_c$  甚至超过了 D-ReSuMe.学习效率方面,ReSuMe 在任意脉冲时长时均具有最小  $M_E$ ,优化算法所需迭代次数整体较多.

表 2 第二组变时长脉冲序列学习的比较实验结果

算法		ReSuMe	SPAN	D-ReSuMe	D-SPAN
200ms	LR	0.057	0.004	0.04	0.0022
	$M_c$	0.918	0.868	0.960	0.954
	$M_E$	451	602	550	546
400ms	LR	0.035	0.0025	0.022	0.0015
	$M_c$	0.783	0.744	0.903	0.854
	$M_E$	541	892	789	859
600ms	LR	0.024	0.002	0.017	0.001
	$M_c$	0.702	0.657	0.817	0.825
	$M_E$	640	864	734	948
800ms	LR	0.021	0.0013	0.013	0.0007
	$M_c$	0.629	0.607	0.769	0.765
	$M_E$	719	1118	741	992
1000ms	LR	0.015	0.001	0.011	0.0006
	$M_c$	0.582	0.564	0.725	0.735
	$M_E$	951	1240	892	1408

### 3.3 变频率的脉冲序列学习比较实验

本部分包含两组变频率比较实验.第一组实验的脉冲序列时长为 400ms,所有脉冲序列的频率从 20Hz 开始每次增加 20Hz 直至 100Hz;最大迭代次数从频率 20Hz 时的 1500 开始,每增加 20Hz 最大学习迭代次数增加 500;其他设置不变.表 3 展示了这组变频率脉冲序列学习的比较实验结果.

由表 3 可知,所有算法的  $M_c$  均随脉冲频率的增加而减小,如 D-SPAN 的  $M_c$  从 20Hz 时的 0.989 减小到 100Hz 时的 0.874.对于每个脉冲频率,优化算法相较各自原有算法均具有更高的学习准确率.随着脉冲频率的增加,优化算法与原有算法的  $M_c$  差值越来越大.例如,ReSuMe 和 D-ReSuMe 在 20Hz 时的  $M_c$  差值为 0.007,而当脉冲时长增加到 100Hz 时, $M_c$  差值增大到了 0.092.脉冲序列时长相同而频率变化时,DCM 同样没有改变算法之间  $M_c$  的相对结果.原有算法中 ReSuMe 优于 SPAN;优化算法中 D-ReSuMe 同样优于 D-SPAN.

D-SPAN 与 D-ReSuMe 之间的  $M_c$  差值相较原有算法大幅减小,最大时不超过 0.02.学习效率方面,优化算法相较原有算法使用了更多的学习迭代次数.

表 3 第一组变频率脉冲序列学习的比较实验结果

算法		ReSuMe	SPAN	D-ReSuMe	D-SPAN
20Hz	LR	0.0107	0.0005	0.0102	0.0004
	$M_c$	0.985	0.975	0.993	0.989
	$M_E$	655	646	591	717
40Hz	LR	0.0039	0.00023	0.0035	0.00017
	$M_c$	0.943	0.900	0.981	0.975
	$M_E$	954	911	912	1097
60Hz	LR	0.0028	0.00014	0.0022	0.00009
	$M_c$	0.888	0.801	0.955	0.953
	$M_E$	1155	1524	1373	1430
80Hz	LR	0.0018	0.00013	0.0015	0.00007
	$M_c$	0.853	0.785	0.938	0.923
	$M_E$	1495	1865	1613	1810
100Hz	LR	0.0014	0.00011	0.0012	0.00006
	$M_c$	0.800	0.741	0.892	0.874
	$M_E$	1745	1793	1490	1881

第二组实验中,输入层发放脉冲序列的频率从 20Hz 开始每次增加 20Hz 直至 100Hz,监督层的发放频率为 100Hz,学习的最大迭代次数设为 3000 次,实验结果见表 4.

表 4 第二组变频率脉冲序列学习的比较实验结果

算法		ReSuMe	SPAN	D-ReSuMe	D-SPAN
20Hz	LR	0.035	0.0025	0.0022	0.0015
	$M_c$	0.791	0.745	0.903	0.894
	$M_E$	689	992	917	959
40Hz	LR	0.008	0.0006	0.006	0.0004
	$M_c$	0.800	0.752	0.903	0.902
	$M_E$	972	1623	1131	1482
60Hz	LR	0.0046	0.00026	0.0024	0.00016
	$M_c$	0.802	0.756	0.906	0.892
	$M_E$	1225	1556	1332	1496
80Hz	LR	0.0026	0.00015	0.0015	0.00009
	$M_c$	0.806	0.749	0.902	0.899
	$M_E$	1374	1751	1426	1833
100Hz	LR	0.0014	0.00011	0.0012	0.00006
	$M_c$	0.800	0.741	0.892	0.874
	$M_E$	1745	1793	1490	1881

由表 4 可知,随脉冲频率的增加,所有学习算法的

$M_c$ 均无太大变化. 例如, SPAN 的  $M_c$  在 20Hz 时为 0.745, 频率增加到 100Hz 时仍为 0.741. DCM 对两种算法均有明显优化作用, 如 40Hz 时 D-SPAN 的  $M_c$  比 SPAN 的  $M_c$  高 0.15, 60Hz 时 D-ReSuMe 的  $M_c$  比 ReSuMe 的  $M_c$  高 0.104. DCM 在脉冲时长相同而输入频率变化时同样没有改变算法学习准确率的比较结果. 但是, D-SPAN 与 D-ReSuMe 之间的学习精度已相差无几, 最大时仅为 0.018.

#### 4 结论与展望

本文基于双脉冲单元构建的 DCM 不局限于某类特定学习算法, 经变时长和变频率实验证明能够有效提高已有算法的学习效果, 在长时程和高频率脉冲序列学习时尤为明显. 基于原有算法的各自特点, 不同算法学习效果的提高程度差异较大. 例如, 结合 DCM 的 SPAN 极大提升了学习能力, 接近优化算法 D-ReSuMe 的学习效果. 然而, 结合 DCM 的脉冲神经元监督学习算法仍然存有不足之处. 例如, 虽然结合 DCM 的算法在每次迭代中的计算量相较原有方法大幅减少, 并且在获得相同  $M_c$  时所用  $M_e$  较少; 但是, 在具有相同最大学习迭代次数时, 优化算法相较原有算法具有较大的  $M_e$ . 因此, 如何在结合 DCM 的同时提高学习效率将是下一步的研究方向.

#### 参考文献

- [1] DENG L, WU Y, HU X, et al. Rethinking the performance comparison between SNNs and ANNs neural networks [J]. *Neural Networks*, 2020, 121: 294 – 307.
- [2] BOHTE S M. The evidence for neural information processing with precise spike-times: a survey [J]. *Natural Computing*, 2004, 3(2): 195 – 206.
- [3] BUTTSD A, WENG C, JIN J, et al. Temporal precision in the neural code and the timescales of natural vision [J]. *Nature*, 2007, 449(7158): 92 – 95.
- [4] GERSTNER W, KISTLER W M, et al. *Spiking Neuron Models: Single Neurons, Populations, Plasticity* [M]. Cambridge University Press, 2002.
- [5] GUTIG R. Spiking neurons can discover predictive features by aggregate-label learning [J]. *Science*, 2016, 351(6277): 4113 – 4113.
- [6] MAASS W. Networks of spiking neurons: The third generation of neural network models [J]. *Neural Networks*, 1997, 10(9): 1659 – 1671.
- [7] 蔺想红, 王向文. 脉冲神经网络原理及应用 [M]. 北京: 科学出版社, 2018.  
LIN Xiang-hong, WANG Xiang-wen. *Theory and Application of Spiking Neural Networks* [M], Beijing: The Science Publishing Company, 2018. (in Chinese)
- [8] TAVANAIE A, BELATRECHE A, LI Y, et al. A review of learning in biologically plausible spiking neural networks [J]. *Neural Networks*, 2020, 122: 253 – 272.
- [9] WANG X, LIN X, DANG X. Supervised learning in spiking neural networks: A review of algorithms and evaluations [J]. *Neural Networks*, 2020, 125: 258 – 280.
- [10] KASABOV N, DOBORJEH M G, DOBORJEH Z G. Mapping, learning, visualization, classification, and understanding of fMRI data in the NeuCube evolving spatiotemporal data machine of spiking neural networks [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28(4): 887 – 899.
- [11] MORRO A, et al. A stochastic spiking neural network for virtual screening [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(4): 1371 – 1375.
- [12] 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 [J]. *电子学报*, 2015, 43(3): 577 – 586.  
LIN Xiang-hong, WANG Xiang-wen, ZHANG Ning, et al. Supervised learning algorithms for spiking neural networks: A review [J]. *Acta Electronica Sinica*, 2015, 43(3): 577 – 586. (in Chinese)
- [13] BOHTE S M, KOK J N, POUTRÉ H L. Error-backpropagation in temporally encoded networks of spiking neurons [J]. *Neurocomputing*, 2002, 48(1–4): 17 – 37.
- [14] GHOSH D S, ADELI H. A new supervised learning algorithm for multiple spiking neural networks with application in epilepsy and seizure detection [J]. *Neural Networks*, 2009, 22(10): 1419 – 1431.
- [15] XU Y, ZENG X, HAN L, et al. A supervised multi-spike learning algorithm based on gradient descent for spiking neural networks [J]. *Neural Networks*, 2013, 43: 99 – 113.
- [16] HEBB D O. *The Organization of Behavior: A Neuropsychological Theory* [M]. John Wiley, Chapman & Hall, 2013.
- [17] CAPORALE N, DAN Y. Spike timing-dependent plasticity: A Hebbian learning rule [J]. *Annual Review of Neuroscience*, 2008, 31(1): 25 – 46.
- [18] WADE J J, MCDAID L J, SANTOS J A, et al. SWAT: A spiking neural network training algorithm for classification problems [J]. *IEEE Transactions on Neural Networks*, 2010, 21(11): 1817 – 1830.
- [19] PONULAK F, KASINŃSKI A. Supervised learning in spiking neural networks with ReSuMe: Sequence learning, classification, and spike shifting [J]. *Neural Computation*, 2010, 22(22): 467 – 510.
- [20] TAHERKHANI A, BELATRECHE A, et al. DL-ReSuMe: A delay learning-based remote supervised method for spiking neurons [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2015, 26(12): 3137 – 3149.

- [21] LIN X, CHEN G, WANG X, et al. An improved supervised learning algorithm using triplet-based spike-timing-dependent plasticity [A]. Proceedings of the 12th International Conference on Intelligent Computing [C]. Cham, Switzerland; Springer International Publishing, 2016. 44 – 53.
- [22] CARNELLA, RICHARDSON D. Linear algebra for times series of spikes [A]. Proceedings of the 13th European Symposium on Artificial Neural Networks [C]. Evere, Belgium; Dside, 2005. 363 – 368.
- [23] MOHEMMED A, SCHLIEBS S, et al. Span: Spike pattern association neuron for learning spatio-temporal spike patterns [J]. International Journal of Neural Systems, 2012, 22(4): 786 – 803.
- [24] YU Q, TANG H, et al. Precise-spike-driven synaptic plasticity: Learning hetero-association of spatiotemporal spike patterns [J]. Plos One, 2013, 8(11): e78318.
- [25] 蔺想红, 王向文, 党小超. 基于脉冲序列核的脉冲神经元监督学习算法 [J]. 电子学报, 2016, 44(12): 2877 – 2886.  
LIN Xiang-hong, WANG Xiang-wen, DANG Xiao-chao. A new supervised learning algorithm for spiking neurons based on spike train kernels [J]. Acta Electronica Sinica, 2016, 44(12): 2877 – 2886. (in Chinese)
- [26] WANG X, LIN X, et al. Supervised learning algorithm using for spiking neurons based on nonlinear inner products of spike trains [A]. Proceedings of the 12th International Conference on Intelligent Computing [C]. Cham, Switzerland; Springer International Publishing, 2016. 95 – 104.
- [27] LIN X, WANG X, HAO Z. Supervised learning in multi-layer spiking neural networks with inner products of spike trains [J]. Neurocomputing, 2017, 237: 59 – 70.
- [28] WANG X, LIN X, et al. A delay learning algorithm based on spike train kernels for spiking neurons [J]. Frontiers in Neuroence, 2010, 252(13): 1 – 16.
- [29] XU Y, ZENG X, ZHONG S. A new supervised learning algorithm for spiking neurons [J]. Neural Computation, 2013, 25(6): 1472 – 1511.
- [30] XIE X, QU H, YI Z, et al. Efficient training of supervised spiking neural network via accurate synaptic-efficiency adjustment method [J]. IEEE Transactions on Neural Networks and Learning Systems, 2017, 28(6): 1411 – 1424.
- [31] ZHANG M, QU H, BELATRECHE A, et al. A highly effective and robust membrane potential-driven supervised learning method for spiking neurons [J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(1): 123 – 137.
- [32] SCHREIBER S, FELLOUS J M, WHITMER D, et al. A new correlation-based measure of spike timing reliability [J]. Neurocomputing, 2003, 52 – 54: 925 – 931.

### 作者简介



陈国军 男, 1991 年 7 月出生, 山东德州人. 2016 年毕业于西北师范大学计算机科学与工程学院, 获软件工程硕士学位. 现为武汉大学城市设计学院博士生. 研究方向为神经网络、智慧城市与城市规划.  
E-mail: guojunchen@whu.edu.cn



蔺想红 男, 1976 年 1 月出生, 甘肃天水人. 2009 年获哈尔滨工业大学计算机应用技术专业博士学位. 现任西北师范大学计算机科学与工程学院教授, 硕士生导师. 研究方向为神经网络、深度学习、智能软件.  
E-mail: linxh@nwnu.edu.cn



王国恩 (通信作者) 男, 1965 年 3 月出生, 湖北红安人. 2006 年获同济大学博士学位. 现任武汉大学城市设计学院教授, 博士生导师. 研究方向为城乡规划、智慧城市与人工智能.  
E-mail: 150251932@qq.com



王向文 男, 1991 年 3 月出生, 甘肃天水人. 2015 年毕业于西北师范大学, 获得硕士学位. 现任西北师范大学计算机科学与工程学院教师. 研究方向为神经网络、机器学习与生物信息学.  
E-mail: wangxiangwen2@163.com