

## 基于脉冲序列合成核的脉冲神经元在线监督学习算法

蔺想红, 李 丹, 王向文, 张 宁

(西北师范大学 计算机科学与工程学院, 兰州 730070)

**摘 要:** 脉冲神经网络使用时间编码的方式进行数据处理, 是进行复杂时空信息处理的有效工具。为此, 将多脉冲序列合成核引入脉冲序列处理过程, 提出一种在线监督学习算法, 采用累加和累积合成核机制进行实验学习, 并与基于单一核函数的在线 PSD 算法进行比较。实验结果表明, 该算法具有较好的学习性能, 特别在数据样本较大时优势更为突出。同时结果也表明, 通过多个核函数的组合可以获得更稳定高效的脉冲序列合成核表示。

**关键词:** 脉冲神经元; 在线学习; 多脉冲序列核; 卷积; 监督学习

**中文引用格式:** 蔺想红, 李 丹, 王向文, 等. 基于脉冲序列合成核的脉冲神经元在线监督学习算法[J]. 计算机工程, 2017, 43(12): 197-202.

**英文引用格式:** LIN Xianghong, LI Dan, WANG Xiangwen, et al. Online Supervised Learning Algorithm for Spiking Neuron Based on Spiking Sequence Composite Kernel[J]. Computer Engineering, 2017, 43(12): 197-202.

### Online Supervised Learning Algorithm for Spiking Neuron Based on Spiking Sequence Composite Kernel

LIN Xianghong, LI Dan, WANG Xiangwen, ZHANG Ning

(School of Computer Science and Engineering, Northwest Normal University, Lanzhou 730070, China)

**【Abstract】** Spiking neural network uses temporal coding for data processing, which is an effective tool for complex spatial and temporal information processing. In view of this, this paper applies multiple sequence composite kernel into the spiking sequence processing and proposes an online supervised learning algorithm. It uses accumulation and cumulative mechanisms for supervised learning and makes an experiment compared with online PSD algorithm based on single kernel. Experimental results show the better performance of the proposed algorithm. Especially in the performance of larger data sample, it can maintain this excellent performance more significantly. The results also show that the combination of multiple kernel functions can get more stable and efficient spiking sequence composite kernel representation.

**【Key words】** spiking neuron; online learning; multiple spiking sequence kernel; convolution; supervised learning

**DOI:** 10.3969/j.issn.1000-3428.2017.12.036

## 0 概述

近年来的生物学研究表明, 生物神经元之间通过脉冲序列来传递信息<sup>[1]</sup>。脉冲神经网络完全模拟生物神经元的运行方式, 拥有比传统人工神经网络更强的性能<sup>[2]</sup>, 是进行复杂时空信息处理的有效工具<sup>[3]</sup>。基于脉冲神经网络的监督学习算法<sup>[4]</sup>解决了有关复杂时空信息不连续性和非线性机制的问题。脉冲神经元以脉冲发放时间作为输入和输出, 可以更好地模拟生物神经元, 进而可以更有效地模拟人类的智能活动。

在线学习的动态性很好地应用在人工智能领域上, 其半实时处理性能加快了优化速度。在线学习较离

线学习更具有灵活性<sup>[5]</sup>, 两者的主要区别在于调整参数的时机不同。在线学习可以在整个学习过程中多次调整学习参数, 更快地优化网络, 提高学习效率, 而离线学习只能在所有样本学习完之后调整参数, 整个过程只调整了一次参数。在线学习方式训练的网络更适合时变不确定性、需要自组织调整的系统。文献[6]使用在线 Boosting 训练方法, 学习过程中只需要对训练数据进行一次学习, 实验结果表明就准确性和运行时间而言其优于批量学习。文献[7]提出一种新的在线 AdaBoost 特征选择方法, 结合高效的特征提取方法增强了实时处理性能。文献[8]采用在线增量学习方法提高了离线训练人脸检测器的检测性能。文献[9]提出基于梯度下降的脉冲神经元在线学习方法, 根据实际与期望输出脉

**基金项目:** 国家自然科学基金(61165002); 甘肃省自然科学基金(1506RJZA127); 甘肃省高等学校科研项目(2015A-013)。

**作者简介:** 蔺想红(1976—), 男, 教授、博士, 主研方向为神经网络、进化计算; 李 丹, 硕士研究生; 王向文(通信作者), 助理工程师、硕士; 张 宁, 硕士。

**收稿日期:** 2016-09-18 **修回日期:** 2016-12-16 **E-mail:** wangxw2015@nwnu.edu.cn

冲实时调整突触权值,该方法的学习效果较离线方法精度更高。

核学习方法是解决非线性模式分析问题的一种高效的方法。研究表明将多个核函数进行组合,会产生更高的学习效率。核方法是通过一个非线性映射,将样本空间映射到一个高维的 Hilbert 空间,从而使原始样本空间中的线性可分问题在高维 Hilbert 特征空间中可以进行分离。

针对核函数和所对应权系数选择困难的问题,核函数组合方法的概念被提出。多核方法学习得益于支持向量机(Support Vector Machine, SVM)等理论的发展和运用,多核学习过程中每个核函数都会保持原有的特性,同一核函数在不同情况下的应用会产生一定的差别。在学习过程中,核函数类型不一,多核学习主要面临的问题是各种核函数之间的选择和匹配。文献[10]从合成核、多尺度核、无限核3个方面对多核学习算法进行了系统的介绍。文献[11]提出了一个简单多核学习(Simple Multiple Kernel Learning, SimpleMKL)算法,并将其成功应用于人工智能学习中。文献[12]提出了一个使用批处理的多核在线学习算法,引入了一个决定学习结果稀疏程度的参数,以较低的训练时间获得最好的性能。文献[13]提出了一个多核在线分类(Online Multiple Kernel Classification, OMKC)学习算法,以在线学习方式通过选择预定义核函数的子集来学习基于核的预测函数。

在构造多核学习算法的过程中,核函数和权系数的选择是整个多核学习过程中的难点和重点。在 SVM 中,考虑到核函数的种类众多,研究者主要使用交叉验证的方法寻找最合适的核函数<sup>[14]</sup>。

在线学习算法和基于核函数的学习算法是脉冲神经网络中2个重要研究方向,然而研究者对脉冲神经网络的在线学习结合核函数学习算法的研究却较少。近年来基于核函数的脉冲神经网络在线监督学习算法逐渐形成体系,其中具有代表性的有 SPAN<sup>[15]</sup>和 PSD<sup>[16]</sup>等,但其在学习过程中多数采用单一核函数的方式将脉冲信号转化为卷积信号。

针对上述问题,本文将多核学习引入脉冲神经网络中,在学习过程中采用累加和累积2种核函数组合的脉冲神经元在线监督学习方法进行多核的构造。

## 1 脉冲序列核的合成方法

### 1.1 脉冲序列的合成核原理

得益于 SVM 等理论的快速发展和应用,核研究得到了进一步的提高,多核学习逐步成为研究者的热门研究方向。多核学习的构造方法主要有合成核方法、多尺度核方法、无限核方法等。本文中多核的构造采用的是合成核的方法。合成核的方法就是把

具有不同映射的多个核函数进行自由组合,得到每个核函数具有的特性,达到更佳的学习效率。

近年来多核学习在很多领域取得了一定的成果,生物研究表明脉冲神经元更符合生物神经元之间的信息传递。因此,本文将多核学习的机制引入到脉冲神经网络脉冲序列学习中,构造多脉冲序列核的学习算法,发挥出多个核函数特有的性能,提高学习效率。合成核方法是多核学习中一类最基本的学习方法,它是将具有不同特征的核函数进行自由组合,从而获得具有多个核函数特性的组合核,脉冲序列合成核方法过程如图1所示。

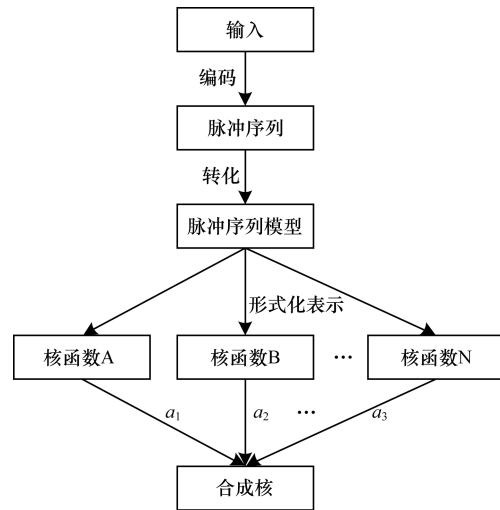


图1 脉冲序列合成核方法过程

### 1.2 多脉冲序列核的构造方法

多核模型是一类灵活性更强的基于核的学习模型。随着多核模型的快速发展和应用,研究者发现使用多个核函数代替单个核函数可以提高决策函数的可解释性,还可以得到更优的学习性能。在构造多核模型的过程中,有很多简单且成熟的方法,本文采用合成核构造方法。运用合成核方法构造多核的过程中最常用的多核学习机制就是将基本核函数进行累加(又称为凸组合),其形式如式(1)所示。

$$\kappa_{\text{sum}} = \sum_{j=1}^M \beta_j \kappa_j \quad (1)$$

其中: $\kappa_j$ 为基本核函数,本文所选的脉冲序列核为常用的核函数; $M$ 代表基本核的总个数; $\beta_j$ 为权系数, $0 \leq \beta_j \leq 1$ ,本文中取值为 $1/M$ ,并且 $\sum_{j=1}^M \beta_j = 1$ ; $\kappa_{\text{sum}}$ 是映射到 Hilbert 空间简单核的直接累加方法。采用累加法构造多核学习的方法不能保留每个基本核函数的自身性质,事实上只有多层神经元上的加法函数才能被那些核函数所超越。在学习过程中,有了这些约束条件才能发挥出更大的性能,否则在普通的神经系统科学应用过程中起不到应有的作用。在某些情况下,组合核也有可能增加超参数的数量,使得交叉验证不实用,此时可以使用经

验贝叶斯进行估值。

另一种方法为累积的形式,在多核构造的过程中将多个基本核函数进行累积,其形如式(2)所示。

$$\kappa_{\text{product}} = \left( \prod_{j=1}^M \kappa_j \right) \wedge \xi_j \quad (2)$$

其中: $\kappa_j$  为基本核函数; $M$  代表基本核的总个数; $\xi_j$  是权系数, $0 \leq \xi_j \leq 1$ , 本文取值为  $1/M$ ;  $\kappa_{\text{product}}$  是映射到 Hilbert 空间简单核的自然累积。采用累积法构造多核学习的方法可以保存每个基本核函数的普遍性,但是如果在多方面增加有效脉冲序列的维度(即在依赖脉冲序列较少或含有噪声处理的情况下),那么同一内核空间增加大小也需要脉冲序列来填满。因此,高维空间的平滑度可能就会因为内核的空间而增强,或者会有更多数据可能以指数方式被要求来公平地评价非线性函数。在多核处理问题的过程中,样本在特征空间的表示方式可以转变成基本核函数和权系数的选取问题。

## 2 基于多脉冲序列核的在线学习规则

本文采用合成核的方法构造多核学习过程,对多个核函数进行线性组合。多核学习方法早期主要应用于生物信息学领域,在 21 世纪初,Pavlidis 和 Weston 等人分析不同类型的基因组数据,在分子水平上研究了基因功能的分类问题<sup>[17-19]</sup>,其主要方法是对基本核矩阵进行组合,从而得到 DNA 异构数据的融合,由此以合成核的方法对多个核函数进行线性组合的方式逐步出现。假定  $\kappa(x, y)$  是已知核函数,本文将基本核函数的归一化形式定义为  $\hat{\kappa}(x, y)$ 。 $\kappa(x, y)$  的归一化表达式为  $\hat{\kappa}(x, y) = \sqrt{\kappa(x, x)\kappa(y, y)}$ , 在这里使用多个基本核函数的凸组合形式,因此,将式(1)和式(2)转化为多核的形式:

$$\hat{\kappa}_{\text{sum}} = \sum_{j=1}^M \beta_j \hat{\kappa}_j(x, y) \quad (3)$$

$$\hat{\kappa}_{\text{product}} = \left( \prod_{j=1}^M \hat{\kappa}_j(x, y) \right) \wedge \xi_j \quad (4)$$

对脉冲序列进行卷积运算,得出神经元突触后电位如式(5)和式(6)所示。

$$\begin{aligned} v_{i1}^\dagger(t) &= s(t) \times \hat{\kappa}_{\text{sum}}(t) \\ &= \sum_f (H(t-t^f) \times \sum_{i=1}^M \beta_i \hat{\kappa}_i(t-t^f)) \end{aligned} \quad (5)$$

$$\begin{aligned} v_{i2}^\dagger(t) &= s(t) \times \hat{\kappa}_{\text{product}}(t) \\ &= \sum_f (H(t-t^f) \times \left( \prod_{j=1}^M \hat{\kappa}_j(t-t^f) \right) \wedge \xi_j) \end{aligned} \quad (6)$$

其中: $v_{i1}^\dagger(t)$  为累加多核方法的神经元突触后电位表达式; $v_{i2}^\dagger(t)$  为累积多核方法的神经元突触后电位的表达式; $H(t)$  仍然是 Heaviside 阶跃函数。

本文使用 W-H 规则,得到多脉冲序列核的表达式,如式(7)所示。

$$\Delta \omega_i(t) = \rho v_i^\dagger(s_d(t) - s_o(t)) \quad (7)$$

其中: $v_i^\dagger(t)$  为多核组合函数; $s_d$  和  $s_o$  分别表示脉冲神经元的期望脉冲序列和实际输出的脉冲序列。

因此,可以得到基于多脉冲序列核的脉冲神经元在线学习算法的神经元突触权值修改公式为:

$$\begin{aligned} \Delta \omega_{i1}^\dagger(t) &= \rho \sum_f (H(t-t^f) \times \sum_{i=1}^M \beta_i \hat{\kappa}_i(t-t^f)) \\ &\quad \times (s_d(t) - s_o(t)) \end{aligned} \quad (8)$$

$$\begin{aligned} \Delta \omega_{i2}^\dagger(t) &= \rho \sum_f (H(t-t^f) \times \left( \prod_{j=1}^M \hat{\kappa}_j(t-t^f) \right) \wedge \xi_j) \\ &\quad \times (s_d(t) - s_o(t)) \end{aligned} \quad (9)$$

多核学习过程中需要选取合适的核函数进行组合,权值的修改也必然和核函数的组合方式有关。

## 3 模拟实验

本部分进行实验验证,通过脉冲神经元序列的学习问题综合对比分析多脉冲序列核在线学习算法的高效性。实验过程中通过改变输入突触数目、脉冲序列长度、脉冲序列发放频率进行多核学习和 PSD 学习效果的对比。本文基本的核函数选取 Laplacian、Gaussian、Alpha,多核的构造方式采用上述的累加和累积 2 种方法。

PSD (Precise-Spike-Driven) 监督学习算法是根据传统的 Widrow-Hoff 规则推导分析出来的,PSD 算法只使用了单个核函数,用来把输入的脉冲序列转换为卷积信号。无权的突触后电流形式表示如下:

$$I_{\text{PSC}}^i = \sum_{n=1}^{N_i} k(t - t_n^i) H(t - t_n^i) \quad (10)$$

其中, $k$  为双指数形式的核函数。

根据 W-H 规则推导出 PSD 算法突触权值在线学习规则为:

$$\Delta w_i(t) = \rho [s_o^d(t) - s_o^a(t)] I_{\text{PSC}}^i(t) \quad (11)$$

对式(11)进行积分,得出总的突触权值学习规则如下:

$$\begin{aligned} \Delta w_i &= \rho \left[ \sum_{m=1}^{N_o^d} \sum_{n=1}^{N_i} k(t_m^d - t_n^i) H(t_m^d - t_n^i) \right. \\ &\quad \left. - \sum_{m=1}^{N_o^a} \sum_{n=1}^{N_i} k(t_m^a - t_n^i) H(t_m^a - t_n^i) \right] \end{aligned} \quad (12)$$

本文依然采用具有直观模型表达式 SRM 的神经元模型。实验过程中脉冲响应函数的时间延迟常量  $\tau$ ,不应期函数中的延迟常量  $\tau_R$ ,激发阈值  $\vartheta$  和绝对不应期长度都保持不变,相邻神经元之间产生的突触权值范围为  $[-0.5, 0.5]$ 。Sum-STKs 代表采用累加的学习算法,Product-STKs 代表采用累积的学习算法。Sum-STKs 中权系数  $\beta_j$  和 Product-STKs 中权系数  $\xi_j$  的值为  $1/M$ ,  $M$  为基本核函数的总数。实验过程中一些基础的基准数据保持不变,有 500 个输入脉冲神经元、1 个输出神经元,单个神经元的最大发放时间长度为 200 ms,时间步长为 0.1 ms。输入脉冲序列由频率为 20 Hz 的泊松分布过程随机产

生,期望脉冲序列由频率为 50 Hz 的泊松分布过程随机产生,学习率  $\rho = 0.05$ 。在脉冲序列的单次学习过程中,最大迭代次数为 200,实验结果为每 100 次实验的平均值。

### 3.1 不同核函数的比较与分析

核函数的种类有很多,不同的核函数有不同的特性,本文在学习的过程中需要根据核函数的学习效率、学习周期等选择合适的核函数。单个核函数的学习过程本文选取 Laplacian、Gaussian 和 Alpha 函数,分别选取不同的核函数参数  $\sigma$ ,其取值为 0.5、0.8、1、2 和 3。图 2(a)为所选 3 种核函数随着核函数参数变化时的学习效率曲线。从中可以发现,3 种核函数随着核函数参数  $\sigma$  值的增大,学习效率也逐渐增大,当  $\sigma$  的值达到 1 时,Gaussian-STK 和 Alpha-STK 在线学习算法的学习效率达到最优,Laplacian-STK 在线学习算法在  $\sigma$  值为 2 时学习效率达到最优。相同核函数参数下 Laplacian-STK 在线学习算法学习效率最高。图 2(b)为所选 3 种核函数学习周期随着核函数参数的变化曲线。从中可以发现,随着核函数参数  $\sigma$  的变化,学习周期发生变化,当  $\sigma$  的值为 2 时,学习周期开始趋于稳定。在此实验过程中选取 Laplacian-STK、Gaussian-STK 和 Alpha-STK 核函数参数  $\sigma$  的基准值分别为 2、1 和 1。

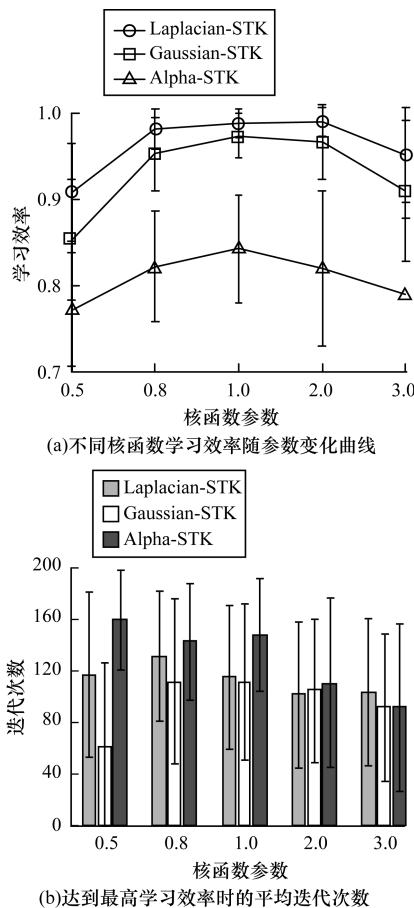


图 2 参数  $\sigma$  不同时 3 种核函数的学习情况

下面对固定  $\sigma$  时所选 3 种核函数的情况进行单独分析。图 3 为所选 3 种核函数在核函数参数  $\sigma$  分别为基准值 2、1 和 1 时的学习效率和周期,不难看出不同的核函数在相同的核函数参数下学习性能是不同的,Laplacian、Gaussian 和 Alpha 的学习效率分别为 0.989 4、0.975 0 和 0.842 8,Laplacian 具有最高的学习效率。Laplacian-STK、Gaussian-STK 和 Alpha-STK 的学习周期依次为 114、110 和 146,不同核函数之间的学习周期有一定差别。总体来说,Laplacian 函数性能最优。

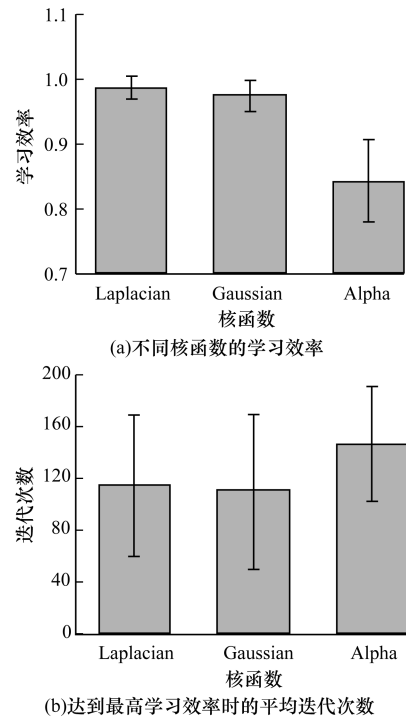
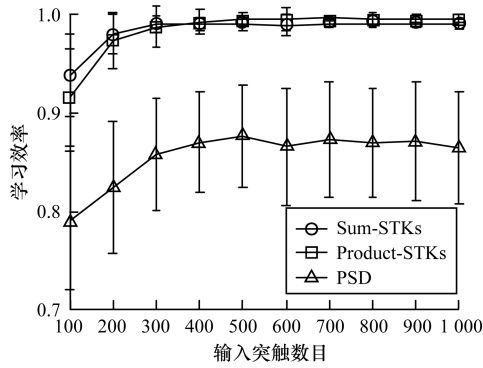



图 3 参数  $\sigma$  固定时 3 种核函数的学习情况

### 3.2 参数变化时的学习性能分析

图 4 为 2 种多脉冲序列核在线学习算法和 PSD 在线学习算法不同输入突触数目时的学习效果,其中上下的竖条表示在该输入神经元突触数目上的方差。从图 4(a)中得出随着输入突触数目的增加,3 种在线学习算法的效率逐渐增高。当突触数目较少时 Sum-STKs 在线学习算法的效率高于 Product-STKs,当突触数目增加到一定数目时 Product-STKs 在线学习算法的效率高于 Sum-STKs。整个过程中 2 种多脉冲序列核在线学习算法的效率明显高于 PSD。当输入突触数目为 400 时,Sum-STKs 的学习效率为 0.990 4,Product-STKs 的学习效率为 0.992 6,PSD 的学习效率为 0.870 4。图 4(b)为 3 种在线学习算法达到最高学习精度时的平均迭代次数对比,在整个学习过程中当输入突触数目较大时 Sum-STKs 的平均迭代次数小于 PSD 的平均迭代次数。



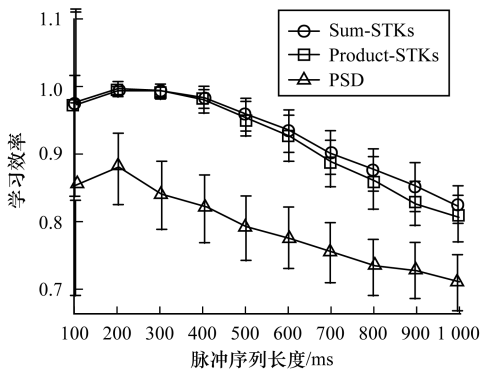
(a)输入突触数目不同的学习效率




(b)达到最高学习效率时的平均迭代次数

图 4 不同输入神经元突触数目的学习情况

图 5 为 2 种多脉冲序列核在线学习算法和 PSD 在线学习算法不同神经元脉冲序列长度时的学习效果。



(a)脉冲序列长度不同的学习效率




(b)达到最高学习效率时的平均迭代次数

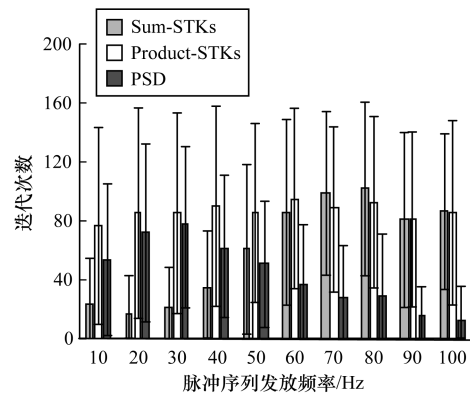
图 5 不同神经元脉冲序列长度的学习情况

从图 5 (a)可以看出,随着脉冲序列长度的增加,3 种在线学习算法的精度逐渐增高,之后开始下降。脉冲序列长度较小时 Product-STKs 在线学习算法的精度高于 Sum-STKs,当脉冲序列长度增加到一定长度时 Sum-STKs 在线学习算法的精度高于 Product-STKs。整个过程中 2 种多脉冲序列核在线学习算法的学习效率明显高于 PSD。例如,当脉冲序列的长度为 200 时,Sum-STKs 的学习效率为 0.990 4, Product-STKs 的学习效率为 0.995 6,而此时 PSD 的学习效率为 0.876 8。图 5 (b)为 3 种在线学习算法达到最高学习效率时的平均迭代次数对比,在整个学习过程中当脉冲序列长度较小时 Sum-STKs 的平均迭代次数小于 PSD 的平均迭代次数。

图 6 为 2 种多脉冲序列核在线学习算法和 PSD 在线学习算法不同脉冲序列发放频率时的学习效果。



(a)脉冲序列发放频率不同的学习效率



(b)达到最高学习效率时的平均迭代次数

图 6 脉冲序列不同发放频率的学习情况

从图 6 (a)中可以发现,随着脉冲序列发放频率的变大,学习效率急剧增高后缓慢下降最后趋于平稳。在整个学习过程中 Sum-STKs 和 Product-STKs 的学习效率一直高于 PSD。例如,当脉冲序列发放频率为 40 Hz 时,Sum-STKs 的学习效率为 0.983 3, Product-STKs 的学习效率为 0.995 1,而此时 PSD 的学习效率为 0.862 6。因此,多脉冲序列核在线学习

算法比 PSD 在线学习算法具有更高的学习效率。图 6(b) 为 3 种在线学习算法达到最高学习效率时的平均迭代次数对比,在整个学习过程中脉冲序列发放频率较小时 Sum-STKs 的平均迭代次数少于 PSD 的平均迭代次数。

#### 4 结束语

借鉴 SVM 等理论的快速发展和应用,本文使用累加和累积 2 种构造多核的机制,提出了基于多脉冲序列核的在线学习算法,并将其与 PSD 在线算法进行比较。通过改变突触输入数目、脉冲发放长度、脉冲序列发放频率的对比结果表明,多脉冲序列组合核具有较好稳定性,采用累加机制的多脉冲序列核和采用累积机制的多脉冲序列核的在线学习性能优于采用单核机制的 PSD 在线学习性能。

#### 参考文献

- [1] MABROUKEH N R, EZEIFE C I. A Taxonomy of Sequential Pattern Mining Algorithms[J]. ACM Computing Surveys, 2010, 43(1):1-41.
- [2] GHOSH-DASTIDAR S, ADELI H. Spiking Neural Networks[J]. International Journal of Neural Systems, 2009, 19(4):295-308.
- [3] KASABOV N K. NeuCube: A Spiking Neural Network Architecture for Mapping, Learning and Understanding of Spatio-Temporal Brain Data[J]. Neural Networks, 2014, 52(4):62-76.
- [4] 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.
- [5] DOLAN E, HANCOCK E, WAREING A. An Evaluation of Online Learning to Teach Practical Competencies in Undergraduate Health Science Students[J]. Internet and Higher Education, 2015, 24:21-25.
- [6] OZA N C. Online Bagging and Boosting [C]//Proceedings of 2005 IEEE International Conference on Systems, Man and Cybernetics. Washington D. C., USA: IEEE Press, 2005:2340-2345.
- [7] GRABNER H, BISCHOF H. On-line Boosting and Vision[C]//Proceedings of 2006 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2006:260-267.
- [8] HUANG C, AI H, YAMASHITA T, et al. Incremental Learning of Boosted Face Detector[C]//Proceedings of the 11th IEEE International Conference on Computer Vision. Washington D. C., USA: IEEE Press, 2007:1-8.
- [9] 徐彦. 基于梯度下降的脉冲神经元在线学习方法[J]. 计算机工程, 2015, 41(12):150-155.
- [10] 汪洪桥,孙富春,蔡艳宁,等. 多核学习方法[J]. 自动化学报, 2010, 36(8):1037-1050.
- [11] RAKOTOMAMONJY A, BACH F, CANU S, et al. SimpleMKL[J]. Journal of Machine Learning Research, 2008, 9:2491-2521.
- [12] ORABONA F, JIE L, CAPUTO B. Online-batch Strongly Convex Multi Kernel Learning [C]//Proceedings of 2010 IEEE Conference on Computer Vision and Pattern Recognition. Washington D. C., USA: IEEE Press, 2010:787-794.
- [13] HOI S C H, JIN R, ZHAO P, et al. Online Multiple Kernel Classification [J]. Machine Learning, 2013, 90(2):289-316.
- [14] LIU Y, JIANG S, LIAO S. Efficient Approximation of Cross-validation for Kernel Methods Using Bouligand Influence Function [C]//Proceedings of the 31st International Conference on Machine Learning. Beijing, China: [s. n.], 2014:324-332.
- [15] MOHEMMED A, SCHLIEBS S, MATSUDA S, et al. Training Spiking Neural Networks to Associate Spatio-Temporal Input-Output Spike Patterns [J]. Neurocomputing, 2013, 107:3-10.
- [16] YU Q, TANG H, TAN K C, et al. A Brain-inspired Spiking Neural Network Model with Temporal Encoding and Learning [J]. Neurocomputing, 2014, 138(11):3-13.
- [17] PAVLIDIS P, WESTON J, CAI J, et al. Gene Functional Classification from Heterogeneous Data [C]//Proceedings of the 5th Annual International Conference on Computational Biology. New York, USA: ACM Press, 2001:249-255.
- [18] PAVLIDIS P, WESTON J, CAI J, et al. Learning Gene Functional Classifications from Multiple Data Types [J]. Journal of Computational Biology, 2002, 9(2):401-411.
- [19] GUYON I, WESTON J, BARNHILL S, et al. Gene Selection for Cancer Classification Using Support Vector Machines [J]. Machine Learning, 2002, 46(1-3):389-422.
- [15] TAN S. An Effective Refinement Strategy for KNN Text Classifier [J]. Expert Systems with Applications, 2006, 30(2):290-298.
- [16] BRERETON R G, LLOYD G R. Support Vector Machines for Classification and Regression [J]. Analyst, 1998, 135(2):230-267.
- [17] HARRINGTON P. 机器学习实战 [M]. 李锐, 李鹏, 曲亚东, 等, 译. 北京:人民邮电出版社, 2013.
- [18] MYUNG I J. Tutorial on Maximum Likelihood Estimation [J]. Journal of Mathematical Psychology, 2003, 47(1):90-100.
- [19] 谭松波. 中文情感挖掘语料-ChnSentiCorp [EB/OL]. [2016-08-27]. <http://www.searchforum.org.cn/tansonbo/email.jsp>.
- [20] 周洋. 基于免疫网络的文本聚类算法及其应用 [D]. 西安:西安邮电学院, 2009.
- [21] SALTON B G, WONG A, YANG C. A Vector Space Model for Automatic [J]. Communications of the ACM, 1975, 18(11):613-620.

编辑 金胡考

编辑 陆燕菲

(上接第 196 页)