

中图法分类号: TP301.6 文献标识码: A 文章编号: 1006-8961(2023)02-0385-16

论文引用格式: Li Y X, Shen J R and Xu Q. 2023. A summary of image recognition-relevant multi-layer spiking neural networks learning algorithms. Journal of Image and Graphics, 28(02): 0385-0400 (李雅馨, 申江荣, 徐齐. 2023. 面向图像识别的多层脉冲神经网络学习算法综述. 中国图象图形学报, 28(02): 0385-0400) [DOI: 10.11834/jig.220452]

面向图像识别的多层脉冲神经网络学习算法综述

李雅馨^{1,2}, 申江荣³, 徐齐^{1,2*}

1. 大连理工大学人工智能学院, 大连 116024; 2. 人工智能与数字经济广东省实验室, 广州 510335;
3. 浙江大学计算机科学与技术学院, 杭州 310058

摘要: 相较于第1代和第2代神经网络, 第3代神经网络的脉冲神经网络是一种更加接近于生物神经网络的模型, 因此更具有生物可解释性和低功耗性。基于脉冲神经元模型, 脉冲神经网络可以通过脉冲信号的形式模拟生物信号在神经网络中的传播, 通过脉冲神经元的膜电位变化来发放脉冲序列, 脉冲序列通过时空联合表达不仅传递了空间信息还传递了时间信息。当前面向模式识别任务的脉冲神经网络模型性能还不及深度学习, 其中一个重要原因在于脉冲神经网络的学习方法不成熟, 深度学习中神经网络的人工神经元是基于实数形式的输出, 这使得其可以使用全局性的反向传播算法对深度神经网络的参数进行训练, 脉冲序列是二值性的离散输出, 这直接导致对脉冲神经网络的训练存在一定困难, 如何对脉冲神经网络进行高效训练是一个具有挑战的研究问题。本文首先总结了脉冲神经网络研究领域中的相关学习算法, 然后对其中主要的方法: 直接监督学习、无监督学习的算法以及 ANN2SNN 的转换算法进行分析介绍, 并对其中代表性的工作进行对比分析, 最后基于对当前主流方法的总结, 对未来更高效、更仿生的脉冲神经网络参数学习方法进行展望。

关键词: 脉冲神经网络(SNN); 学习算法; 无监督学习; 监督学习; 脉冲神经元模型; 图像识别

A summary of image recognition-relevant multi-layer spiking neural networks learning algorithms

Li Yaxin^{1,2}, Shen Jiangrong³, Xu Qi^{1,2*}

1. School of Artificial Intelligence, Dalian University of Technology, Dalian 116024, China;
2. Guangdong Artificial Intelligence and Digital Economy Laboratory, Guangzhou 510335, China;
3. College of Computer Science and Technology, Zhejiang University, Hangzhou 310058, China

Abstract: To understand the structure of human brain further, Wolfgang Mass summarizes that the structures, training methods and some other crucial parts of spiking neural networks (SNNs) systematically, which are known as the third-generation of artificial neural networks. There are hundreds of millions of neurons and synaptic structures in related to human brain, but the requirement of energy is quite small. The SNNs has its advantages of biological interpretability and lower power consumption in comparison with the first and the second generation artificial neural networks (ANNs). Its neurons

收稿日期: 2022-05-23; 修回日期: 2022-09-14; 预印本日期: 2022-09-21

* 通信作者: 徐齐 xuqi@dlut.edu.cn

基金项目: 科技创新2030—新一代人工智能重大项目(2021ZD0109803); 国家自然科学基金项目(62206037); 人工智能与数字经济广东省实验室(深圳)开放课题(GML-KF-22-11); 中央高校基本科研业务费专项资金资助项目(DUT21RC(3)091)

Supported by: National Key R&D Program of China(2021ZD0109803); National Natural Science Foundation of China(62206037); Open Research Fund from Guangdong Laboratory of Artificial Intelligence and Digital Economy (SZ) (GML-KF-22-11); the Fundamental Research Funds for the Central Universities (DUT21RC(3)091)

simulate the internal dynamics of biological neurons, and the weight-balanced simulates the construction, enhancement and inhibition rules of biological synapses. The SNN is mainly composed of such commonly-used spiking neuron models in relevant to Hodgkin Huxley (HH) model, leaky integrate-and-fire (LIF) model, and spiking response (SRM) model. The difference of ion concentration-inner and the biological neuron-outer can activate the potential of the cell membrane. To improve an action potential, channel-based ions move in and out of the neuron membrane in the neuron membrane when a neuron is stimulated. Spiking neuron model is a mathematical model that simulates the action potential process of biological neuron. A spiking neuron receives neurons-derived spiking stimulation in the upper layer. It will fire spikes to outreach a spiking train. The SNNs is focused on the transmission from spiking trains to information-targeted, which can simulate the propagation of biological signals in the biological neural network. The spiking trains can convey spatiotemporal information. However, current performance of SNNs-based pattern recognition tasks is still challenged to its immature deep learning methods. The artificial neurons of the neural network are based on the output in the form of real numbers, which makes it possible to use the global back-propagation algorithm to train the parameters of the deep neural network. But the spiking train is a sort of binary discrete output, which is still a challenging issue for SNN-based training. First, to clarify its current situation, our summary is focused on recent SNN-based learning algorithms. Then, to analyze pros and cons of popular works, the three main algorithms are introduced: 1) supervised learning, 2) unsupervised learning, and 3) ANN-SNN conversion. The unsupervised learning algorithm is mainly based on the mechanism of spike timing dependent plasticity (STDP). The biological synapses-interconnected is enhanced or inhibited according to the relative timing of the firing of presynaptic neurons and postsynaptic neurons. Unsupervised learning methods have stronger biological interpretability, which can use the local optimization method to balance the synaptic weights, but this method is challenged for its complicated and large-scale network structures. Therefore, drawing on the advantages of ANN's easy calculation, some supervised algorithms have emerged like gradient-based training method and ANN2SNN method. The gradient-based learning algorithm is mainly concerned of the training idea of back-propagation (BP), which can balance the weight in terms of the error between the output value and the target value. This challenge is to be resolved in accordance with non-differentiable nature of discrete spikes. More methods of the BP-error have been proposed like gradient surrogate method. This gradient-based training method is focused on leveraging the training advantages of ANN and SNN. The training of SNN is interpretable biologically and easy to be computed. The ANN2SNN method can be used to convert the ANN weights-trained to SNN. This method can be used to realize the continuous activation values in the ANN into spiking trains. To reduce the conversion loss of ANN and SNN, this method is fine-tuned and converted according to neuron dynamics. This training method feature is indirect that it can apply SNN to complex network structures. The method of weight transfer can avoid direct training of SNN, which can apply SNN to complicated network structures. The ANN has been widely used in the field of image recognition. To extract more image features, ANN can be mainly used for consistent functions. SNN has its features of interpretability-biological and power consumption-lower, which can show its high performance in image recognition tasks. Finally, future SNNs-bionic learning methods are predicted in terms of some popular domain methods.

Key words: spiking neural network (SNN); learning algorithm; unsupervised learning; supervised learning; spiking neuron model; image recognition

0 引言

第1个脉冲神经网络(spiking neural network, SNN)由Wolfgang Mass提出,由于其生物学上的可解释性,被誉为第3代人工神经网络。第1代神经网络是Rosenblatt于1958年提出的感知机模型,该线性模型可以用于解决简单的逻辑问题,但是难以表达更加复杂的非线性问题。第2代人工神经网络

(artificial neural network, ANN)则引入非线性的激活函数,例如Rumelhart等人(1986)提出的前馈神经网络和误差反向传播机制可以用于解决复杂问题。上述人工神经网络模型缺乏一定的生物可解释性,例如无法模仿生物神经网络的学习机制等,因此提出了更加接近于实际生物神经元的第3代人工神经网络——脉冲神经网络。SNN是基于脉冲神经元构建的网络模型,通过脉冲序列中的时间和空间信息来传递特征信息,模拟了生物神经系统中的突

触建立、增强与抑制的工作机制, SNN 将生物工作原理和数学模型结合起来, 构建兼具生物可解释性和计算高效性的神经网络模型(胡一凡等, 2021)。

ANN 在图像识别领域已有广泛应用, ANN 主要是利用连续的函数计算图像特征(黄铁军等, 2022), 近年来, 出现了很多 ANN 深度学习模型, 如 ResNet (residual network)、VGG (Visual Geometry Group) 等, 然而因为脉冲的二值性, SNN 在训练上存在不可微等问题, SNN 在一些大型复杂数据集上的性能稍逊于 ANN 模型, 但是 SNN 受实际生物视觉神经系统启发, 将图像像素编码成脉冲序列, 从脉冲序列的时空信息中提取图像特征, 在 SNN 训练时, 脉冲神经元模拟生物神经元的工作机制通过传递脉冲序列来传递信息, 更具有生物可解释性的优势, 且其因为脉冲的异步性和稀疏性(Li等, 2021), 具有高效率低耗能的优点。脉冲神经网络的学习算法主要是基于生物神经网络工作机制的原理并结合 ANN 中的一些算法思想。根据训练数据的不同以及网络结构的不同, 这里从监督学习和无监督学习的训练方法, 以及其在深度脉冲神经网络中的相关研究 3 个方面讨论 SNN 相关学习算法。

1 脉冲神经元

1.1 HH 模型

HH 模型 (Hodgkin Huxley model) 是由 Alan Hodgkin 和 Andrew Huxley 于 1952 年提出的神经元模型(Hodgkin 和 Huxley, 1952)。他们通过在乌贼的巨型轴突上进行实验, 认为膜电势的产生主要与钾离子(K^+)、钠离子(Na^+)的转运过程促使细胞内的离子浓度与细胞外液中的离子浓度之间存在差异有关, 还与一些其他的离子(如氯离子(Cl^-))通过通道形成漏电流有关, 因此 HH 模型试图刻画 3 种离子 K^+ 、 Na^+ 、 Cl^- 对于膜电位产生的作用。

如图 1 所示, HH 模型认为细胞膜可以起到存储电荷的功能, 由于细胞膜内外的离子浓度差造成了电势差, 而细胞膜上流过的电流主要由电导和离子的电势决定。 C 表示电容, E_L 、 E_K 和 E_{Na} 表示 3 种离子的平衡电势, 电阻 R 、 R_K 和 R_{Na} 表示细胞膜允许离子通过的能力即电导 g , 电导与膜电位相关, I 是外加电流。

上述离子通道有打开和关闭两种状态, 用 α 表




图 1 HH 模型 (Hodgkin 和 Huxley, 1952)

Fig. 1 Hodgkin Huxley model (Hodgkin and Huxley, 1952)

示关闭的通道打开的速率, β 表示已经打开的通道关闭的速率, n 、 m 、 h 分别表示 K^+ 、 Na^+ 、 Cl^- 离子通道打开的概率, 其更新为

$$\frac{dm}{dt} = \alpha_m(V_m)(1 - m) + \beta_m(V_m)m \quad (1)$$

$$\frac{dh}{dt} = \alpha_h(V_m)(1 - h) + \beta_h(V_m)h \quad (2)$$

$$\frac{dn}{dt} = \alpha_n(V_m)(1 - n) + \beta_n(V_m)n \quad (3)$$

式中, V_m 表示膜电位, g_{Na} 、 g_K 、 g_L 表示 3 种离子通道的电导, 则通过细胞膜的离子通道的电流之和可以表示为

$$\sum_k I_k = g_{Na} m^3 h (V_m - E_{Na}) + g_K n^4 (V_m - E_K) + g_L (V_m - E_L) \quad (4)$$

1.2 LIF 模型

LIF 模型 (leaky integrate-and-fire model) (Gerstner 等, 2014) 相比 HH 模型更加简化, 同时比传统 ANN 的神经元模型更接近于实际生物神经元的模型, 是现有 SNN 最常用的模型之一。LIF 模型将神经元的模拟电路简化为图 2 所示。

LIF 模型简化了各种不同的离子通道, 将其作




图 2 LIF 模型 (Gerstner 等, 2014)

Fig. 2 Leaky integrate-and-fire model (Gerstner et al., 2014)

为一个整体,它的基本电路只包括两个部分:一个电容 C 和驱动电流 $I(t)$ 电阻 R ,则电流 $I(t)$ 可以表示为

$$I(t) = I_R + I_C \quad (5)$$

LIF 模型中的 leaky 表示漏电电流,当电位值不超过阈值时会回到静息电位,integrate 表示积分,表示该神经元受到的所有突触前神经元的电流刺激,fire 表示发放,当电位值超过阈值就会发放一个脉冲。用 V_m 表示膜电位, E_{leak} 表示平衡电势, g_{leak} 表示电导,当 LIF 神经元接收突触前神经元脉冲,膜电位上升超过阈值就会发放一个脉冲,然后回到重置电位,则会发放其微分方程,可以表示为

$$C \frac{dV_m}{dt} = I - g_{\text{leak}}(V_m - E_{\text{leak}}) \quad (6)$$

1.3 SRM 模型

SRM 模型 (spiking response model) (Gerstner 等,2014)是由 LIF 模型推广而来,SRM 模型没有固定的发放阈值,其阈值 $\theta(t)$ 是变化的,在 SRM 模型中用 V_m 表示膜电位, V_{rest} 表示静息电位,用函数 η 来描述动作电位和动作电位之后的曲线,输入电流 $I(t)$ 用 $k(s)$ 过滤生成输入电位 h ,神经元接受突触前神经元的电流刺激,如果达到阈值,就发放脉冲序列 S ,如果发放了脉冲,阈值会增加。如图 3 所示。




图3 SRM 模型 (Gerstner 等,2014)

Fig. 3 Spiking response model (Gerstner et al., 2014)

SRM 模型的膜电位变化可以表示为

$$V_m(t) = \int_0^\infty \eta(s) S(t-s) ds + \int_0^\infty \kappa(s) I^{\text{ext}}(t-s) ds + V_{\text{rest}} \quad (7)$$

2 脉冲神经网络拓扑结构

在生物视网膜神经环路中,首先由视锥细胞和视杆细胞接受光刺激,然后由中层细胞将刺激传导至神经节细胞,神经节细胞的感受野可以感知图像特征,生物的视觉网络中会存在前馈,横向的连接,通过抑制和兴奋来控制细胞。受到生物神经网络的启发,提出了类似于神经细胞的前馈连接的多层感知机模型,后来又提出全连接、卷积和循环结构的神经网络模型,在 SNN 中也会存在这些结构,从最初的单层学习模型,后来提出适用于 SNN 的卷积核,并且也有研究循环结构的 SNN。因此,SNN 的网络

拓扑结构分为 3 种:全连接、卷积和循环结构。

神经网络结构主要由输入层、隐藏层以及输出层组成。其中全连接的网络结构每个神经元接收上一期所有神经元的加权输入,将信号进行前向传播来提取特征;卷积的网络结构利用卷积核,类似于生物视觉系统中的感受野结构,对输入特征进行卷积操作来提取特征;循环的网络结构不仅接收前一层神经元的输入,还可以接收自己上一时刻的信息作为特征。

3 脉冲神经网络的无监督学习算法

无监督学习算法受生物神经网络中突触建立、增强和抑制的工作机制启发,在生物神经系统中,传递的是脉冲序列的时空信息,根据突触前后的脉冲刺激来增强或者减弱突触连接,利用这种生物学原理可以无监督地学习 SNN 的权值。Hebbian (1949)

最早提出了突触可塑性的 Hebb 理论,即突触前神经元对突触后神经元重复持续的刺激,可以增强它们之间的突触连接强度。大多数无监督学习算法都是基于 Hebb 学习规则提出的,这种方法更具有生物可解释性。

STDP(spike-timing-dependent plasticity)规则是 Hebb 理论的扩展,Song 等人(2000)基于 STDP 规则提出了一种脉冲时序依赖的学习算法,STDP 规则根据突触前神经元和突触后神经元动作电位的相对时间来更新突触权重。如果突触前神经元发放脉冲的时刻比突触后神经元早,则称为长时程增强 LTP(long-term potentiation),突触权重应该变大;如果突触前神经元发放脉冲的时刻比突触后神经元晚,则称为长时程抑制 LTD(long-term depression),突触权重应该变小。

还有一些三脉冲的 STDP 方法,比如 Pfister 和 Gerstner (2006)的 triplet-based STDP,Shahim-Aeen 和 Karimi(2015)的 TSTDP。与一般的 STDP 不同的是,三脉冲 STDP 包括一个突触前脉冲和两个突触后脉冲。

为了将 STDP 用于图片分类任务,Diehl 和 Cook (2015)提出了将 STDP 算法用于手写数字识别,并且在 MNIST (Modified National Institute of Standard and Technology)上达到了 95% 的准确率,该方法基于 LIF 模型,建立了具有输入层和处理层的神经网络。其中处理层的兴奋性神经元以侧边抑制的方式一对一连接到抑制性神经元,抑制性神经元连接到所有的兴奋性神经元,如图 4 所示。该方法利用三脉冲 STDP 训练,因为三脉冲 STDP 不使用权重依赖进行学习。




图 4 基于 STDP 算法网络结构 (Diehl 和 Cook, 2015)

Fig.4 Network architecture based on STDP(algorithm)
(Diehl and Cook, 2015)

此前研究中的 STDP 只有单层的,为了让其有更好的性能,Kheradpisheh 等人(2018)提出了一种多层的基于 STDP 方法的 SDNN(spiking deep neural network)网络,主要用于目标识别,利用时间编码设计了一种层数更深的 SNN,包括若干个卷积层和池化层,且可以用 STDP 方法来训练,网络结构如图 5 所示,在 MNIST 上的准确率达到 98.4%。采用的是 LIF 脉冲神经元模型,每个神经元接收上一层突触前神经元的脉冲,如果达到膜电位阈值则发放脉冲,用 $w_{j,i}$ 表示第 j 个突触前神经元与第 i 个突触后神经元连接的突触权值,在每个时间步,脉冲神经元的电位可以表示为

$$V_i(t) = V_i(t-1) + \sum_j w_{j,i} S_j(t-1) \quad (8)$$

如果突触前神经元在 $t-1$ 时间步发放了脉冲,则 $S_j(t-1)$ 为 1,反之为 0。用简化的 STDP 算法更新权重

$$\Delta w_{ij} = \begin{cases} a^+ w_{ij}(1 - w_{ij}) & t_j - t_i \leq 0 \\ a^- w_{ij}(1 - w_{ij}) & t_j - t_i > 0 \end{cases} \quad (9)$$

式中, t_j , t_i 是突触前神经元 j 和突触后神经元 i 脉冲发放时刻, a^+ , a^- 表示两种情况下的学习率。

Mozafari 等人(2019)将奖励机制加入到 STDP 方法中,提出了 R-STDP 方法(reward-modulated STDP),该方法在 MNIST 上的准确率为 97.2%。设计了一个 3 层的网络结构,其结构由 Kheradpisheh 等人(2018)方法改造而来,首先输入图像用差分高斯滤波器在不同尺度卷积,然后经过编码产生脉冲序列传递到下一层,经过多个卷积层和池化层,限制神经元每个时间步长只发放一个脉冲,最后一层决策神经元可以对应每个数字类别,由最早发放脉冲的神经元或者最大电位值来分类,根据最后一层分类结果产生奖励信号调节 STDP 系数。

在 Diehl 和 Cook (2015)工作的基础上,Saunders 等人(2018)提出了 C-SNN(convolutional spiking neural networks),图像的特征可以在神经元亚群中共享,或者独立地演化以获取不同区域的不同特征。该模型以一种无监督的方式学习格点数据,小块的神元可以共享参数也可以独立学习特征。模型采用的是一种改进的 LIF 神经元模型,利用内稳态的机制平衡整个网络,包括兴奋性神经元和抑制性神经元。C-SNN 的结构如图 6 所示, k 是核大小, s 是步长,一个卷积块是一个兴奋性神经元的亚群和一




图5 SDNN 网络结构图(Kheradpisheh 等,2018)

Fig. 5 The architecture of SDNN (Kheradpisheh et al. , 2018)




图6 C-SNN 的结构 (Saunders 等,2018)

Fig. 6 The architecture of C-SNN (Saunders et al. , 2018)

个等大的抑制性神经元的亚群,输入空间的每个部分,与 STDP 可修改突触连接到兴奋性亚群的每个单个神经元,兴奋性神经元和抑制性神经元亚群一对一连接,如图 6 所示,即为提出的卷积 SNN 模型。其权值更新用的是 online STDP。

有研究表明,贝叶斯原理在人类大脑处理信息的过程中会被用到,因此,Guo 等人(2019)提出了一种赢家通吃 (winner-take-all, WTA) 策略的层次网

络,该网络基于脉冲的变分期望最大化算法。该算法有两个步骤,首先是基于脉冲的变分 E 步,将层次 WTA 动力学脉冲响应作为平均场方程优化先验概率和平均场分布之间的 KL (Kullback-Leibler) 散度;然后是基于脉冲的变分 M 步,用 STDP 规则随机收敛到下界的极大值。并且在 MNIST 数据集上达到 95% 的准确率。

Liu 等人(2020)提出了一种时间连续的模型

MPN(the McCulloch-Pitts network),用于学习脉冲序列,这个模型是基于一个局部的学习规则,定义了更新连续时间 SNN 的状态和权值的规则,并证明了给定的一对突触前和突触后神经元的权重变化的曲线与 STDP 的曲线相似,如图 7 所示。该模型更具有生物可解释性,可以学习二进制向量的序列或者脉冲的时空特征,可以稳健地学习记忆二元向量的多个时空模式,扩展了对称 Hopfield 网络的记忆静态空间模式的能力。




图 7 一对 MPN 脉冲神经元生成的曲线图(Liu 等,2020)

Fig. 7 The curves emerge from simulating an MPN on a pair of neurons (Liu et al., 2020)

受生物自组织过程的启发,Lyu 等人(2021)提出了一种在训练网络的过程中在神经元之间建立新连接的方法,利用 LIF 模型,基于电导的突触和 STDP 规则构建了一个 4 层的前馈网络,基于突触前和突触后神经元脉冲时间差,可以在隐藏层中建立新的突触连接,并利用 STDP 规则来更新突触权值,在输出层引入赢家通吃机制。

结合信息论的思想,Yang 等人(2021)提出了一种 SPA(stochastic probability adjustment)的无监督学习方法,SPA 将 SNN 的突触和神经元映射到一个概率空间中,其中一个神经元和所有连接的突触前都由一个簇表示。突触在不同簇之间的运动建模为一个类似布朗的随机过程,其中发射器的分布在不同的放电阶段是自适应的,通过随机过程的约束,减少了 SNN 的整体竞争,提高分类精度。

无监督的学习算法更加接近于实际生物性原理,利用生物神经元和突触的动力学原理进行训练,利用局部优化的方法更新突触权重,是更加类脑的方法,但是这种训练方法也存在一些缺点,无法构建深层次的复杂神经网络,因此借鉴于 ANN 易于计算的优点,出现了一些利用 ANN 反向传播的训练和

ANN 转换 SNN 等算法,这些方法融入了一些 ANN 思想,更加容易计算,也更易于训练大规模复杂结构的神经网络。

4 脉冲神经网络的监督学习算法

人在学习的过程中也存在反馈机制,这里的监督学习算法主要是利用输出值和目标值的误差来调整网络的连接权值,这种方法结合了 ANN 易于训练和 SNN 生物可解释性的优势,按照具体的训练方法将 SNN 的监督学习算法分为基于梯度下降、基于突触可塑性、基于 ANN2SNN 转换以及基于卷积的学习方法 4 种,其中 ANN2SNN 转换的学习算法属于间接训练方法。近年来,根据 SNN 的特性,也涌现出很多 SNN 的有监督学习算法,在图像识别领域得到广泛应用。

4.1 梯度下降的学习算法

SNN 的基于梯度下降的监督学习算法的主要思想与 ANN 的梯度下降优化算法类似,利用输出脉冲序列与目标脉冲序列之间的误差,优化更新突触连接的权值,该方法的主要困难是离散脉冲不可微的性质,因此根据脉冲的特性很多适用于脉冲的误差反向传播方法也陆续提出。脉冲发放的频率及时间中存在的信息,利用梯度替代法或者脉冲发放的相对时间等方法,进行误差的反向传播以更新权值。

Bohte 等人(2002)的 SpikeProp 算法是最早提出的一种经典的基于梯度的 SNN 学习算法,其思想与 ANN 的误差反向传播类似。SpikeProp 用的是 SRM 神经元模型,该算法限制每个神经元只发放一次脉冲,采用时间编码的方式,提出了一种多层的前馈 SNN 的梯度下降学习算法。根据梯度反向传播原理,假设了一个阈值函数 $x_j(t)$ 与脉冲发放的时刻 t 在其最小邻域附近存在一个线性关系来进行突触的权重更新。

Xu 等人(2013)改进了 SpikeProp 算法,由于实际上可能不只发放一个脉冲,所以该算法对每个神经元不限制只发放一个脉冲,所有层的神经元脉冲发放看做一个脉冲序列,脉冲神经元 j 的目标输出脉冲序列为 $\hat{T}_j = \{\hat{t}_j^{(1)}, \hat{t}_j^{(2)}, \dots, \hat{t}_j^{(F_j)}\}$,实际输出脉冲序列为 $T_j = \{t_j^{(1)}, t_j^{(2)}, \dots, t_j^{(F_j)}\}$,考虑实际和目标输出脉冲序列之间的误差进行梯度下降学习,则

其损失函数要考虑多个脉冲,定义为 $E = \frac{1}{2} \sum_{j=1}^{N_1} \sum_{f=1}^{F_j} (t_j^{(f)} - \hat{t}_j^{(f)})^2$ 。

Gütig 和 Sompolinsky (2006) 提出的 Tempotron 算法是一种生物可解释的有监督的突触学习规则,其认为神经元脉冲的信息不只是脉冲发放频率,而存在于脉冲序列的时空结构中。Tempotron 算法用的是 LIF 神经元模型,脉冲神经元接收突触前神经元的所有输入脉冲的加权和,如果其突触后神经元的膜电位上升超过阈值,则会发放脉冲,在二分类任务中,对于应该发放脉冲的模式而没有发放脉冲就会增强突触连接,对于应该不发放脉冲的模式而发放了脉冲则会抑制突触连接,根据这样的规则来更新突触连接的权重。

由于 Tempotron 算法的输出神经元输出的脉冲时间是任意的,不携带信息,Florian (2012) 提出了一种时间编码的算法 chronotrons, 包括有更高的存储性能的 E-learning 算法和有更高生物可解释性的 I-learning 算法,可以在发放时间上精确到亚毫秒级的脉冲序列,根据带有时间信息的脉冲序列来对不同的输入进行分类。

近年来,也涌现出各种新的误差反向传播的学习训练方法,利用误差反向传播思想,主要是根据脉冲的频率信息或者时间信息,得到权重更新的梯度进行训练。

Tempotron 算法是单层的网络结构,特征提取能力可能不够强,而 ANN 中的卷积操作有更强的特征提取能力,Xu 等人 (2018) 提出了一种结合卷积神经网络(convolutional neural network, CNN) 特征提取能力的 SNN 模型 CSNN(CNN-SNN), 可以将 CNN 的特征学习能力和 SNN 的认知能力结合起来以更好地提取特征, CNN 部分称为感知器, SNN 部分称为认知器,首先用 CNN 的卷积操作来提取输入图像的特征,然后将特征用时间编码得到时空脉冲序列,输入到 SNN 认知器中,然后利用 Tempotron 学习规则训练,最后使用赢家通吃的分类策略。这种学习方法类似于人脑的神经节细胞和复杂细胞的特征提取功能,具有更强的特征提取能力。

脉冲序列不仅携带了空间信息,还携带了时间信息,而 LIF 脉冲神经元,模型用于网络的直接训练时,由于其生物动力学的特性,难以直接训练。因而 Wu 等人 (2018) 提出了一种 STBP (spatio-temporal

backpropagation) 算法,其中提出一种可以直接迭代的 LIF 脉冲神经元模型,不仅利用了脉冲序列的时间信息 TD(temporal domain), 还利用前向传播的空间信息 SD(spatial domain) 来更新神经元的状态。空间上的误差传播类似于 DNN(deep neural network) 的从最后一层向前累积加权误差方式的误差传播;时间上的误差传播利用迭代的 LIF 模型展开,得到不同时刻的 TD 状态实现链式规则,然后根据链式法则得到梯度反向传播的更新规则。而 STBP 只能训练 2~4 层的 SNN, Wu 等人 (2019) 又提出了 NeuNorm 方法调整 LIF 神经元的选择性,缩小编码窗口,将其转化为显式迭代的方式以适用于 Pytorch 框架,可以用于稍大规模的如 8 层的网络训练。

Shrestha 和 Orchard (2018) 提出了一种基于脉冲时序的误差反向传播策略 SLAYER(spike layer error reassignment), 克服了脉冲函数不可微的问题,而该方法用的是 SRM 神经元模型, SLAYER 将采样时间 T_s 离散化,在一个周期中采样一定的样本,将脉冲的时序依赖表示到梯度,该方法用脉冲神经元状态变化的概率密度函数来表示脉冲函数的导数,以解决脉冲函数不可微的问题。由于脉冲神经元的状态取决于其输入神经元之前的状态,该方法不仅像传统方法一样反向传播了误差的信用度,还反向传播了时序的信用度,并且,用该方法训练了卷积和全连接的结构。

通过近似模拟反向传播优化全精度的梯度实现权值的算法需要很多浮点操作,而这在神经形态的电路中是不兼容的,因此 Thiele 等人 (2019) 提出了一种 SpikeGrad 反向传播训练方法。该方法将梯度离散化成脉冲事件进行反向传播,与前向传播离散化成脉冲序列一样,将误差离散化成脉冲序列从最后一层向前传播更新权重,并且证明了此方法可以实现与 ANN 等效的网络结构。

一般 SNN 的误差反向传播可以分成两种方法,一种是适合于脉冲神经网络的计算梯度的方法;另一种是根据脉冲发放的相对时间来传播误差。第 1 种方法的思想与 ANN 中的梯度下降优化算法相似,很多研究都是基于这种方法, STBP 和 SLAYER 都属于这种方法。Lee 等人 (2020) 提出了一种近似导数方法来描述 LIF 脉冲神经元模型的激活函数,类似于 ANN 中的激活函数可以使得梯度下降优化,整个

过程包括前向传播、反向传播和权值更新。前向传播的最后一层不发放脉冲,只累积膜电位,再利用链式法则分别求得最后一层和隐藏层的梯度,然后更新连接的权值。

由于实际生物在不同脑区域的神经元的膜相关参数是不同的,但是之前的研究中,SNN使用的LIF等脉冲神经元模型的膜时间常数作为超参数在整个网络中是一样的。于是Fang等人(2021)提出了一种可以在训练过程中更新膜时间常数的脉冲神经元模型PLIF(parametric leaky integrate-and-fire)模型,定义膜时间常数 $\tau = \frac{1}{k(a)} \in (1, +\infty)$,在PLIF模型的基础上提出了可以同时学习膜时间常数和突触连接权重值的SNN训练算法。将PLIF模型应用到深度SNN中,使用梯度替代法来训练突触连接权值,通过对 a 的梯度来更新膜时间常数。

由于其他的BP(back propagation)算法要利用时空信息进行反向传播,使得计算规模和模型复杂度较高,Wu等人(2021)提出了一种基于累积脉冲流的反向传播算法ASF-BP(accumulated spiking flow),ASF-BP算法的权重更新不是依赖于输出脉冲神经元的脉冲序列更新的,而是让输出神经元设置一个很高的阈值,让其不发放脉冲,而在一个时间窗口内,累积计算输出层的脉冲流,累积脉冲流是脉冲神经元在时间窗口的累积输入和输出,损失函数计算累积脉冲输出流与实际标签的误差。ASF-BP算法计算累积脉冲输出流,显著降低了计算复杂度。

在ANN的训练中有利用弱分类器集成一个强分类器的框架,这样虽然每个分类器表现未必很好,但是集成模型会有较高的准确率,因此Shen等人(2021)根据这种思路,提出一个HybirdSNN模型,将多个浅层的SNN集成为一个强分类器,通过数据驱动的贪婪优化算法来有效组合浅层的SNN,这样在能耗和性能上更有优势,提出了3种模型组合的方法:利用Tempotron规则的T-HybirdSNN、利用Mostafa算法的M-HybirdSNN和利用监督BP的C-HybirdSNN。这种框架没有固定的深度结构,更加灵活,可以适应更多样化的任务。

利用替代梯度方法会存在一定的误差,Deng等人(2022)分析了利用梯度替代直接训练产生损失的原因,并提出了TET(temporal efficient training)方法来补偿梯度下降时使用替代梯度法导致的损失,

TET不是直接优化积分电位,而是优化每个时刻的突触前输入,避免了陷入局部最优,网络也更具有鲁棒性。

第2种方法利用脉冲发放的相对时间来计算梯度,脉冲发放的时间顺序中也会隐含很多信息,Comsa等人(2020)提出了一种编码脉冲的相对时间的学习算法,并且使用有突触传递的 α 函数的SRM模型,输出层根据第1个发放脉冲的神经元来分类,其学习目标是使得脉冲发放的相对时间顺序是正确的。

Comsa等人(2020)的方法是一种延迟学习的方法,脉冲发放时间定义为膜电位的函数,脉冲的延迟或者顺序中隐含了信息,Kheradpisheh和Masquelier(2020)提出了一种使用更简单的脉冲神经元LIF模型的方法,该方法使用了一种时间编码rank-order-coding,所有神经元都只发放一个脉冲,根据脉冲发放的顺序信息来训练网络。基于这种网络提出一种新的学习方法S4NN(single-spike supervised spiking neural network),将输入数据转换成脉冲序列,用IF神经元来处理输入脉冲,根据第1个发放脉冲的神经元判断类别,然后将误差方向传播训练权重。

Zhang和Li(2021)提出脉冲时间序列的反向传播学习算法TSSL-BP(temporal spike sequence learning backpropagation),通过调整的LIF神经元前向传播脉冲序列,根据目标序列和输出序列的误差,反向传播更新权值,这种方法打破了神经元之间和神经元内的依赖,通过突触前发放脉冲的特征来捕获神经元内依赖性;它考虑每个神经元状态随时间的内部演化,捕捉同一突触前神经元在不同的脉冲时刻如何影响其突触后神经元。

两种SNN的误差反向传播的方法都存在一定的局限性,Kim等人(2020)提出一种基于激活值和基于时间的脉冲网络学习算法ANTLR(activation-and timing-based learning rule)将两种方法结合起来,可以像基于时间的方法改变脉冲时间且像基于激活值的方法移除脉冲。ANTLR用的是LIF模型,研究了基于激活值的方法和基于时间的方法之间的联系,发现当单个脉冲状态变化时两个方法是互补的。ANTLR的主要思想是将基于激活值的梯度和基于时间的梯度相加,得到一个联合梯度,并通过对二者设置系数来平衡二者的重要程度。

通过类似于 ANN 梯度下降优化的思想来训练 SNN,主要是根据脉冲神经元的动力学特性,得到对于脉冲的梯度,进而更新连接权值,其中最主要的困难在于脉冲二值性的不可微特性以及神经元复杂的动力学原理。但是近年出现很多根据神经元动力学特征求梯度进而更新权值的方法,这种方法使得 SNN 不仅具有生物学特性且易于优化计算,可以在大规模复杂网络结构中应用。

4.2 ANN2SNN 的学习算法

ANN2SNN 学习算法是一种间接的学习算法,因为直接训练 SNN 在梯度传播上存在困难,因而将梯度传播的过程转移到 ANN 上,在 ANN 的网络中训练更新权值,再将权值转移到 SNN 上进行优化,这样避免了直接在 SNN 上计算梯度,让 SNN 可以应用于一些大规模复杂神经网络。

考虑到 SNN 脉冲的二值性难以直接训练,Cao 等人(2015)提出了一种将深度人工卷积神经网络 CNN 转换为 SNN 的框架,这样可以将在 ANN 中训练好的权值转移到 SNN 中以间接地训练 SNN,其中提到 ANN 转换为 SNN 导致精度损失的 3 个主要原因:1)负数输出值在 SNN 中很难表示;2)SNN 很难表示 ANN 中的偏置项;3)需要用两层来表示 ANN 中的最大池化层而增加了计算复杂性。

Cao 等人(2015)针对这 3 个问题提出了解决办法,首先用 ReLU 激活函数避免了负值的出现;去掉了卷积层和全连接层的偏置项;用空间线性采样代替最大池化。论文中的方法包括 3 个卷积操作和线性空间采样操作,首先将 RGB 图像通过编码生成脉冲,在 SNN 中用的是 LIF 神经元模型,最后由全连接层输出计算脉冲的数量。

用 ANN 中的神经元脉冲发放频率来模拟 ANN 中的激活值是 ANN-SNN 的主要方法。近年来也有人基于此提出了各种学习方法,Rueckauer 等人(2017)提出了一种将常见的 CNN 的操作如最大池化、softmax 和批归一化等转换到 SNN 中的方法,使得可以将任意网络转换成 SNN。ANN 中常有的偏置项在 SNN 中通常难以表示,提出用一个恒定的输入电流来表示偏置项。在 ANN 中通常有批归一化层来使得特征输入保持为正态分布便于特征提取,Diehl 等人(2015)提出了两种权重归一化的方法:model-based normalization 和 data-based normalization。model-based normalization 通过计算最大的可能

激活值作为缩放因子缩放权重的值;data-based normalization 将激活值和权重的最大值作为缩放因子,在 data-based normalization 的基础上将偏置考虑进去。Cao 等人(2015)利用泊松分布来将像素值转换为脉冲,但是这种转化会损失网络的精度,因此将输入的激活值作为恒等的电流,将恒定的电荷值在每个时间步长添加到膜电位,先前的 ANN2SNN 只是用脉冲的最大输出个数来分类,没有转换 softmax 层,该文通过计算累积的膜电位来进行分类。在 Cao 等人(2015)的研究中,是用平均池化代替的最大池化层,而在该文中提出了一个门控单元让放电最大的神经元的脉冲通过来实现最大池化操作。

Sengupta 等人(2019)提出了一种 spike-norm 用于 ANN2SNN 的批归一化层方法,与 Diehl 等人(2015)的归一化方法不同,每层的权重归一化根据 spike 的输入来确定。可以将神经元的阈值设为 1,用缩放因子调整权重使得权重归一化;也可以将阈值设为最大激活值而权重不变达到阈值平衡。不仅实现了 VGG 结构网络的 ANN2SNN 转换,还扩展到残差网络结构上。

Sengupta 等人(2019)的转换方法使用的是硬重置。Han 等人(2020)研究发现,从 ANN 转换到 SNN 的精度损失大多来自于神经元的阈值硬重置,因此提出了基于软重置的 ANN-SNN 的方法 RMP(residual membrane potential)脉冲神经元,保留了脉冲神经元在发放脉冲瞬间的膜电位,RMP-SNN 通过将发放脉冲时的膜电位减去阈值,而不是重置到固定电位,使得在发放脉冲的瞬间保留了残余电位,从而减少了 ANN-SNN 转换过程中的信息损失。

为了更好地让脉冲发放速率近似 ANN 网络中的激活值,Ding 等人(2021)提出了一种 ANN2SNN 的优化算法,该算法提出一个 RNL(rate norm layer)层来代替 ANN 中的 ReLU 层,研究发现使用阈值或者权重归一化的方法需要有缩放操作,而比例因子需要人为选择,该算法的 RNL 层是一个带有可训练上限的 clip 函数,并且该算法还提出了一个拟合曲线来量化 ANN 的模拟脉冲频率和 SNN 实际脉冲频率,这减少了训练的延迟。

Deng 和 Gu(2021)提出了一种新的策略管道将阈值平衡和软重置机制结合起来的 ANN-SNN 转换方法,这种管道使得 ANN 和转换后的 SNN 之间几乎没有精度损失,从理论上分析了转换过程,总体误

差可以转换成各层的误差,修改了 ReLU 激活函数以近似 SNN 的脉冲发放频率,控制每一层的 ANN 的激活值和目标 SNN 之差,根据 Diehl 等人(2015)和 Sengupta 等人(2019)的阈值平衡机制估计每一层的最优位移值并计算总体转换误差。

为了让转换后的 SNN 的参数更加匹配 ANN 的激活值,Li 等人(2021)提出了一种 SNN 校准的方法,分析了从 ANN 转换到 SNN 的误差,并提出了分层修正误差的算法,认为转换误差通常来自两个方面:flooring 误差和 clipping 误差,提高阈值会降低 clipping 误差提高 flooring 误差。为了平衡这两种误差,用 MMSE(mean squared error)来得到合适的阈值。该方法还校准了 SNN 的参数来减少误差,包括权重和偏置项。

ANN-SNN 的方法需要较多的时间步长,但是这样会有较大的时间延迟,Bu 等人(2022)提出了一种具有低延迟的高性能算法,时间步长小于 32,通过优化初始膜电位来减少误差,发现将膜电位初始化为阈值的一半时转换误差的期望可以达到最小值。

利用神经元的脉冲频率编码来进行 ANN-SNN 的转换会有较大的时间延迟,训练收敛的时间比较长,Han 和 Roy(2020)提出了一种基于时间编码 TSC(temporal-switch-coding)的 ANN-to-SNN 的转换方法,每个输入图像的像素用两个脉冲来表示并且这两个脉冲之间的时间与像素强度成正比,这种编码方式比 TTFS(time-to-first-spike)能耗更低,每次激活最多只需要发放两个脉冲,仅在输入脉冲时跟踪突触,减少了计算成本。

ANN-SNN 的学习算法让 SNN 直接获得 ANN 中训练好的权重,而 ANN-SNN 的学习算法有较大的延迟,基于梯度的算法虽然可以直接训练,但是其训练复杂度较高,所以 Rathi 等人(2020)提出了一种混合的训练方法,首先用训练好的 ANN 的权重,作为 SNN 初始权重,然后利用基于脉冲相对时间的梯度方向传播再训练 SNN,这样减少了收敛的时间。

ANN-SNN 的学习算法可以直接把训练好的权重转移到 SNN 中,可以构建较深层的复杂网络结构,让 SNN 的训练更加容易,但是这种方法会产生较大延迟,需要较多的时间步长才可以有较好的效果。

4.3 突触可塑性的学习算法

STDP 是一种无监督的学习算法,通过突触可塑性原理来调整突触连接的权值,而相较于基于梯度的学习算法,基于突触可塑性的无监督学习算法难以扩展到深层复杂网络结构中,因而提出了结合监督学习思想的突触可塑性算法,Ponulak 和 Kasiński(2010)结合 STDP 和 anti-STDP 算法,提出了一种监督学习 ReSuMe(remote supervised method)学习算法,ReSuMe 算法根据突触前神经元和突触后神经元脉冲发放的时间来进行训练学习,类似于 Widrow-Hoff 规则,ReSuMe 算法不是基于传统的梯度的优化算法,它利用突触可塑性原理最小化目标脉冲序列和输出脉冲序列之间的误差。对于兴奋性突触,让对发放脉冲的神经元有贡献的突触增强,遵守 STDP 规则;对于抑制性突触,让阻止神经元发放脉冲的突触抑制,遵守 anti-STDP 规则。

Taherkhani 等人(2015)提出了 DL-ReSuMe(delay learning remote supervised method)算法,由于突触的延迟不是固定的,DL-ReSuMe 算法同时学习突触的权重和权值,更具有生物可解释性。在 DL-ReSuMe 的基础上又提出了 Multi-DL-ReSuMe(multiple DL-ReSuMe)算法,可以训练多个脉冲神经元的分类任务,每个神经元可以识别一个类。

Wade 等人(2010)将 BCM(Bienenstock-Cooper-Munro)和 STDP 算法结合提出了 SWAT(a synaptic weight association training algorithm)算法,SWAT 产生一个单峰权重分布,与 STDP 有关的可塑性窗口高度被调制趋于稳定。SNN 在隐藏层使用一个前馈循环拓扑结构,包括兴奋性和抑制性突触,利用 STDP 规则学习所有输出神经元的权重,再将权重映射到相对应的输出神经元。

梯度下降算法具有网络优化计算上的优点,而 STDP 规则具有生物可解释性的优点,为了将这两种优点结合起来,Tavanaei 和 Maida(2019)提出了一种基于时间突触可塑性的监督学习算法(BP-STDP),用 STDP 规则和 anti-STDP 规则的时间局部学习方法作为突触更新的规则,用教师信号选择 STDP 规则或者 anti-STDP 规则,并且可以应用到每个时间步。

Tavanaei 和 Maida(2019)的算法只利用了局部更新的规则,Liu 等人(2021)提出了一种结合 BP 全局优化规则和时间局部更新机制的 SNN 学习算法,

称为 SSTDP (supervised spike timing dependent plasticity), 前向传播时脉冲神经元接收到突触前神经元的加权膜电位, 反向传播时根据链式法则更新权值, 权值更新信息包括空间信息, 即从 STDP 的局部权值更新, 以及时间信息, 即从 BP 的全局权值更新。

将突触可塑性原理和监督学习思想结合起来, 利用 STDP 的规则来更新突触的权值, 又加入了输出和目标的误差的优化算法。这样的算法更具有生物可解释性, 且算法的训练更加容易。

4.4 脉冲序列卷积的学习算法

基于脉冲序列卷积的学习算法是利用卷积的思想, 通过引入核函数, 对离散的脉冲序列进行卷积, 进而对脉冲序列, 利用 Widrow-Hoff 规则调整突触权重进行训练。

Mohammed 等人 (2012) 提出了一种 SPAN (spike pattern association neuron) 算法, 在训练时将脉冲序列转换成模拟信号, 可以应用普通的数学操作, 用一个核函数 $\kappa(t)$ 对每个脉冲序列进行卷积, 通过这样的转换可以将 Widrow-Hoff 规则用于转换后的脉冲序列以调整突触权重

Yu 等人 (2013) 提出了 PSD (precise-spike-driven synaptic plasticity) 学习算法, 根据 Widrow-Hoff 规则, 根据输出脉冲序列和实际脉冲序列的误差来更新突触权重, 正的误差导致长时程增强, 负的误差导致长时程抑制, PSD 算法同时具有符合算数规则和生物可解释性的优点。与 SAPN 不同的是, PSD 只对输入脉冲序列进行卷积, 突触权重的调整由输出和实际脉冲的误差触发, 只取决于当前的状态。

5 深度脉冲神经网络

近年来有相关研究探索 SNN 在深度学习中的应用, 提出了很多将 SNN 用到深度学习网络架构中的方法, 将浅层的 SNN 扩展到更深层的网络中, 解决退化问题以及梯度问题, 表现出较好的性能。

Hu 等人 (2021a) 提出了一种 S-Resnet 模型 (spiking ResNet), 这是一种 ANN-SNN 的算法, 该算法的网络结构是 SNN, 深度首次超过 40 层。S-Resnet 用补偿机制减小从 ANN 到 SNN 转到导致的误差。用 IF 脉冲神经元替代 ReLU 激活函数, 将训练好的 Resnet 模型转换到 SNN, 而由于脉冲的离散二值性质, 转换的时候会产生一个误差, 误差会随着层

数的加深而逐渐累积, 为了抵消误差导致的精度下降, 提出将权重乘以一个缩放因子, 稍微增大脉冲发放率抵消误差。该算法可以用于 18, 34, 50 层的残差网络结构中, 且在大型数据集 ImageNet 上进行了测试。

Stöckl 和 Maass (2021) 提出了用两个脉冲实现的高精度分类方法, FS (few spikes) 转换是一种 ANN 转换 SNN 的方法, 可以用于 ResNet-50 结构中, 这个方法不同于频率编码的方法, 而是利用脉冲时间模式中的信息, 该文提出了一种少脉冲的神经元模型 FS 神经元模型, 其内部动力学可以用少量的脉冲模拟 ANN 神经元。

SNN 在反向传播的时候, 脉冲特征不仅体现在空间上, 还体现在时间上, 而一般的 BN (batch normalization) 算法不适用于脉冲神经元, 因此 Zheng 等人 (2021) 在 STBP 方法的基础上, 提出了 STBP-td-BN 的方法, 先前的研究中网络结构大多不超过 10 层, 该方法可以避免梯度消失或者梯度爆炸, 使得该方法可以应用到 18、34 和 50 层的残差网络中。tdBN (a threshold-dependent batch normalization) 是一种脉冲归一化的方法, 如图 8 所示, 该方法对脉冲输入沿着通道这一维度进行归一化, 不仅对空间还对时间上的脉冲进行了归一化。




图8 tdBN 的归一化方法示意图 (Zheng 等, 2021)

Fig. 8 Schematic diagram of normalization method of tdBN (Zheng et al., 2021)

将第 k 个特征图通道的 1 到 T 时间步的脉冲求均值和方差, 即 $E[\mathbf{x}_k]$, $Var[\mathbf{x}_k]$, 假设输入为 $\mathbf{x}_k = (x_k^1, x_k^2, \dots, x_k^T)$, 其输入的归一化可以表示为

$$\hat{\mathbf{x}}_k = \frac{\alpha V_{th}(\mathbf{x}_k - E[\mathbf{x}_k])}{\sqrt{Var[\mathbf{x}_k] + e}}$$

$$\mathbf{y}_k = \lambda_k \hat{\mathbf{x}}_k + \beta_k \quad (10)$$

式中, e 为阈值。

实验表明,该方法在深度的 SNN 上表现较好,且可以用于复杂数据集,如 ImageNet。

Hu 等人 (2021b) 在 TDBN 的基础上,调整了残差块的基本结构,删除了基础块之间的连接处的 LIF 神经元,将 LIF 神经元放在了残差路径的最上面,提出了 MS-ResNet (the membrane-shortcut ResNet)。这样的结构使得在恒等路径中传递是膜电位而不是脉冲流,避免了无效的残差表达式,不会有梯度爆炸或消失的问题,该方法可以用在 ResNet-104 中。

残差网络的提出解决了 ANN 深层网络训练过程中的梯度消失或爆炸的问题,因而考虑将这种结构应用到 SNN 中,但是以往的 spiking ResNet 只是简单地将 ReLU 替换成脉冲神经元,没有考虑到脉冲神经元的特性,因而并不能完全实现残差网络的恒等映射,随着网络层数的加深仍然会存在退化问题,并且存在梯度消失和梯度爆炸的现象。因此, Fang 等人 (2022) 提出了一种 SEW (spike-element-wise) ResNet 方法,这是第 1 次直接训练超过 100 层网络结构的 SNN。根据脉冲神经元的特性,改进了 SNN 学习的残差网络,将基础残差块之间的激活函数层去掉,改用逐元素操作函数 g ($g = \text{AND}/\text{IAND}/\text{ADD}$),实现了脉冲残差网络的恒等映射,解决了梯度爆炸或消失的问题。该方法可以用于 34、50、101 层的残差网络,实现了深度 SNN 的学习。

SNN 在深度学习中也涌现出许多算法,大多利用反向传播的思想或者 ANN 转换 SNN 的方法,借鉴 ANN 中的一些深层网络结构,然后根据 SNN 脉冲的时间和空间特性提出适用于 SNN 的网络结构,

而 SNN 在深层结构中也表现出不逊于 ANN 的性能。

6 总结与展望

图 9 总结了脉冲神经网络算法从出现到一些经典算法研究的进展,从最初的根据突触学习的生物性原理的单层网络,到借鉴了误差反向传播思想的直接训练和 ANN2SNN 的转换学习算法,近年来更有利用深度学习的复杂网络结构的脉冲神经网络。脉冲神经网络由于其独特的仿生特性,利用脉冲来传递信息,当膜电位超过阈值就会发放一个脉冲,这与生物细胞的动作电位类似,正是因为这种生物特性,其训练过程会有一定困难。目前的训练算法主要分为无监督学习、监督学习以及 ANN-SNN 转换的学习算法。其中,无监督学习主要利用了突触可塑性原理,这种算法生物可解释性很强,利用局部规则调整权重参数,但是这种方式无法用于复杂结构的网络模型;监督学习算法主要借鉴了人工神经网络的思想,将误差反向传播结合到脉冲神经网络的训练中,这种方法的主要困难是脉冲的不可微性,但是这种方法不仅具有生物可解释性的优点,也具有人工神经网络易于计算的优点,可以用于复杂网络结构;ANN-SNN 的转换学习算法是将在 ANN 中训练好的权值转移到 SNN 上,这种方法主要利用了 ANN 训练的优势,可以用于像 ANN 一样的复杂网络结构,但是要达到相对较高的精度,需要较长的时间步长。脉冲神经网络作为第 3 代人工神经网络,未来将是类脑智能的核心,下面是对脉冲神经网络未来发展的展望:



图 9 脉冲神经网络算法进展图

Fig. 9 Progress of spiking neural network algorithm

1) 更加仿生的学习算法。未来可能会根据实际生物神经网络中突触连接的建立以及突触的增强和减弱的规则来构建脉冲神经网络,从生物神经网络的学习规则启发脉冲神经网络的学习规则,借鉴

生物的视觉系统结构,构建更加仿生的模型。

2) 更加复杂的、大规模的网络结构。未来可能会将脉冲神经网络应用于深度学习中,在网络结构上有所创新,将人工神经网络的算法思想与生物仿

生模型结合,发挥二者的优势,构建深层次大规模的网络结构。

3)更加多样化的应用。未来类脑智能将是一个发展趋势,而更加仿生、更加高效的学习算法成为必需,探索生物脑的结构,构建更加强大的计算系统。

7 结 语

本文总结了脉冲神经网络中常用的脉冲神经元模型,概括了监督学习以及无监督学习的相关研究算法。监督学习方法主要利用反向传播的方法,通过输出层的误差来更新权值;无监督学习方法主要利用突触的生物性原理,根据脉冲发放的时序特性来更新权值。脉冲神经网络作为第3代的神经网络,由于其在生物学上的可解释性,更加近似于实际生物的神经元机制,随着研究的深入,也对脉冲神经网络的训练方法逐渐改进,其精度和性能也不断提高,为机器学习和深度学习提供一种新的范式。未来随着对人脑工作机制的探索,相信会出现更加仿生的、更加高效的脉冲神经网络学习算法,将结合数学模型计算的优势以及生物神经网络的工作原理,构建更加适合脉冲神经网络的训练方法,以在更多的实际领域得到应用。

参考文献 (References)

- Bohte S M, Kok J N and La Poutré H. 2002. Error-backpropagation in temporally encoded networks of spiking neurons. *Neurocomputing*, 48(1-4): 17-37 [DOI: 10.1016/S0925-2312(01)00658-0]
- Bu T, Ding J H, Yu Z F and Huang T J. 2022. Optimized potential initialization for low-latency spiking neural networks [EB/OL]. [2022-05-08]. <https://arxiv.org/pdf/2202.01440.pdf>
- Gao Y Q, Chen Y and Khosla D. 2015. Spiking deep convolutional neural networks for energy-efficient object recognition. *International Journal of Computer Vision*, 113(1): 54-66 [DOI: 10.1007/s11263-014-0788-3]
- Comsa I M, Potempa K, Versari L, Fischbacher T, Gesmundo A and Alakuijala J. 2020. Temporal coding in spiking neural networks with alpha synaptic function//*Proceedings of ICASSP 2020-2020 IEEE International Conference on Acoustics*. Barcelona, Spain; IEEE: 8529-8533 [DOI: 10.1109/ICASSP40776.2020.9053856]
- Deng S K and Gu S. 2021. Optimal conversion of conventional artificial neural networks to spiking neural networks [EB/OL]. [2022-05-08]. <https://arxiv.org/pdf/2103.00476.pdf>
- Deng S K, Li Y H, Zhang S H and Gu S. 2022. Temporal efficient training of spiking neural network via gradient re-weighting [EB/OL]. [2022-05-08]. <https://arxiv.org/pdf/2202.11946.pdf>
- Diehl P U and Cook M. 2015. Unsupervised learning of digit recognition using spike-timing-dependent plasticity. *Frontiers in Computational Neuroscience*, 9: #99 [DOI: 10.3389/fncom.2015.00099]
- Diehl P U, Neil D, Binas J, Cook M, Liu S C and Pfeiffer M. 2015. Fast-classifying, high-accuracy spiking deep networks through weight and threshold balancing//*Proceedings of 2015 International Joint Conference on Neural Networks (IJCNN)*. Killarney, Ireland; IEEE: 1-8 [DOI: 10.1109/IJCNN.2015.7280696]
- Ding J H, Yu Z F, Tian Y H and Huang T J. 2021. Optimal ANN-SNN conversion for fast and accurate inference in deep spiking neural networks//*Proceedings of the 30th International Joint Conference on Artificial Intelligence*. Montreal, Canada; AAAI Press: 2328-2336 [DOI: 10.24963/ijcai.2021/321]
- Fang W, Yu Z F, Chen Y Q, Huang T J, Masquelier T and Tian Y H. 2022. Deep residual learning in spiking neural networks [EB/OL]. [2022-01-22]. <https://arxiv.org/pdf/2102.04159v6.pdf>
- Fang W, Yu Z F, Chen Y Q, Masquelier T, Huang T J and Tian Y H. 2021. Incorporating learnable membrane time constant to enhance learning of spiking neural networks//*Proceedings of 2021 IEEE/CVF International Conference on Computer Vision*. Montreal, Canada; IEEE: 2641-2651 [DOI: 10.1109/ICCV48922.2021.00266]
- Florian R V. 2012. The chronotron: a neuron that learns to fire temporally precise spike patterns. *PLoS ONE*, 7(8): #e40233 [DOI: 10.1371/journal.pone.0040233]
- Gerstner W, Kistler W M, Naud R and Paninski L. 2014. *Neuronal Dynamics: from Single Neurons to Networks and Models of Cognition*. Cambridge; Cambridge University Press
- Guo S Q, Yu Z F, Deng F, Hu X L and Chen F. 2019. Hierarchical Bayesian inference and learning in spiking neural networks. *IEEE Transactions on Cybernetics*, 49(1): 133-145 [DOI: 10.1109/TCYB.2017.2768554]
- Gütig R and Sompolinsky H. 2006. The tempotron: a neuron that learns spike timing - based decisions. *Nature Neuroscience*, 9(3): 420-428 [DOI: 10.1038/nn1643]
- Han B and Roy K. 2020. Deep spiking neural network: energy efficiency through time based coding//*Proceedings of the 16th European Conference on Computer Vision*. Glasgow, UK; Springer: 388-404 [DOI: 10.1007/978-3-030-58607-2_23]
- Han B, Srinivasan G and Roy K. 2020. RMP-SNN: residual membrane potential neuron for enabling deeper high-accuracy and low-latency spiking neural network//*Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle, USA; IEEE: 13555-13564 [DOI: 10.1109/CVPR42600.2020.01357]
- Hebbian D O. 1949. *The Organization of Behavior. A Neuropsychological Theory*. New York; John Wiley & Sons

- Hodgkin A L and Huxley A F. 1952. A quantitative description of membrane current and its application to conduction and excitation in nerve. *The Journal of Physiology*, 117 (4): 500-544 [DOI: 10.1113/jphysiol.1952.sp004764]
- Hu Y F, Li G Q, Wu Y J and Deng L. 2021. Spiking neural networks; a survey on recent advances and new directions. *Control and Decision*, 36(1): 1-26 (胡一凡, 李国齐, 吴郁杰, 邓磊. 2021. 脉冲神经网络研究进展综述. *控制与决策*, 36(1): 1-26) [DOI: 10.13195/j.kzyjc.2020.1006]
- Hu Y F, Tang H J and Pan G. 2021a. Spiking deep residual networks. *IEEE Transactions on Neural Networks and Learning Systems* [DOI: 10.1109/TNNLS.2021.3119238]
- Hu Y F, Wu Y J, Deng L and Li G Q. 2021b. Advancing residual learning towards powerful deep spiking neural networks [EB/OL]. [2021-12-23]. <https://arxiv.org/pdf/2112.08954v1.pdf>
- Huang T J, Yu Z F, Li Y, Shi B X, Xiong R Q, Ma L and Wang W. 2022. Advances in spike vision. *Journal of Image and Graphics*, 27(6): 1823-1839 (黄铁军, 余肇飞, 李源, 施柏鑫, 熊瑞勤, 马雷, 王威. 2022. 脉冲视觉研究进展. *中国图象图形学报*, 2022, 27(6): 1823-1839) [DOI: DOI: 10.11834/jig.220175]
- Kheradpisheh S R, Ganjtabesh M, Thorpe S J and Masquelier T. 2018. STDP-based spiking deep convolutional neural networks for object recognition. *Neural Networks*, 99: 56-67 [DOI: 10.1016/j.neunet.2017.12.005]
- Kheradpisheh S R and Masquelier T. 2020. Temporal backpropagation for spiking neural networks with one spike per neuron. *International Journal of Neural Systems*, 30 (6): #2050027 [DOI: 10.1142/S0129065720500276]
- Kim J, Kim K and Kim J J. 2020. Unifying activation- and timing-based learning rules for spiking neural networks [EB/OL]. [2020-10-23]. <https://arxiv.org/pdf/2006.02642v2.pdf>
- Lee C, Sarwar S S, Panda P, Srinivasan G and Roy K. 2020. Enabling spike-based backpropagation for training deep neural network architectures. *Frontiers in Neuroscience*, 14: #119 [DOI: 10.3389/fnins.2020.00119]
- Li J N and Tian Y H. 2021. Recent advances in neuromorphic vision sensors; a survey. *Chinese Journal of Computers*, 44 (6): 1258-1286 (李家宁, 田永鸿. 2021. 神经形态视觉传感器的研究进展及应用综述. *计算机学报*, 44 (6): 1258-1286) [DOI: 10.11897/SP.J.1016.2021.01258]
- Li Y H, Deng S K, Dong X, Gong R H and Gu S. 2021. A free lunch from ANN; towards efficient, accurate spiking neural networks calibration [EB/OL]. [2021-06-13]. <https://arxiv.org/pdf/2106.06984.pdf>
- Liu F X, Zhao W B, Chen Y B, Wang Z W, Yang T and Jiang L. 2021. SSTDP: supervised spike timing dependent plasticity for efficient spiking neural network training. *Frontiers in Neuroscience*, 15: #756876 [DOI: 10.3389/fnins.2021.756876]
- Liu Z Z, Chotibut T, Hillar C and Lin S W. 2020. Biologically plausible sequence learning with spiking neural networks. *Proceedings of the AAAI Conference on Artificial Intelligence*, 34 (2): 1316-1323 [DOI: 10.1609/aaai.v34i02.5487]
- Lyu M Y, Shao C P, Li H Y, Li J and Sun T F. 2021. A novel spiking neural network with the learning strategy of biomimetic structure// *Proceedings of 2021 Asia-Pacific Conference on Communications Technology and Computer Science (ACCTCS)*. Shenyang, China: IEEE: 69-74 [DOI: 10.1109/ACCTCS52002.2021.00022]
- Mohammed A, Schliebs S, Matsuda S and Kasabov N. 2012. Span: spike pattern association neuron for learning spatio-temporal spike patterns. *International Journal of Neural Systems*, 22 (4): #1250012 [DOI: 10.1142/S0129065712500128]
- Mozafari M, Ganjtabesh M, Nowzari-Dalini A, Thorpe S J and Masquelier T. 2019. Bio-inspired digit recognition using reward-modulated spike-timing-dependent plasticity in deep convolutional networks. *Pattern Recognition*, 94: 87-95 [DOI: 10.1016/j.patcog.2019.05.015]
- Pfister J P and Gerstner W. 2006. Triplets of spikes in a model of spike timing-dependent plasticity. *Journal of Neuroscience*, 26 (38): 9673-9682 [DOI: 10.1523/JNEUROSCI.1425-06.2006]
- Ponulak F and Kasiński A. 2010. Supervised learning in spiking neural networks with ReSuMe: sequence learning, classification, and spike shifting. *Neural Computation*, 22 (2): 467-510 [DOI: 10.1162/neco.2009.11-08-901]
- Rathi N, Srinivasan G, Panda P and Roy K. 2020. Enabling deep spiking neural networks with hybrid conversion and spike timing dependent backpropagation [EB/OL]. [2022-05-08]. <https://arxiv.org/pdf/2005.01807.pdf>
- Rueckauer B, Lungu I A, Hu Y H, Pfeiffer M and Liu S C. 2017. Conversion of continuous-valued deep networks to efficient event-driven networks for image classification. *Frontiers in Neuroscience*, 11: #682 [DOI: 10.3389/fnins.2017.00682]
- Rumelhart D E, Hinton G E and Williams R J. 1986. Learning representations by back-propagating errors. *Nature*, 323 (6088): 533-536 [DOI: 10.1038/323533a0]
- Saunders D J, Siegelmann H T, Kozma R and Ruzinkó M. 2018. STDP learning of image patches with convolutional spiking neural networks// *Proceedings of 2018 International Joint Conference on Neural Networks (IJCNN)*. Rio de Janeiro, Brazil: IEEE: 1-7 [DOI: 10.1109/IJCNN.2018.8489684]
- Sengupta A, Ye Y T, Wang R, Liu C A and Roy K. 2019. Going deeper in spiking neural networks: VGG and residual architectures. *Frontiers in Neuroscience*, 13: #95 [DOI: 10.3389/fnins.2019.00095]
- Shahim-Aeen A and Karimi G. 2015. Triplet-based spike timing dependent plasticity (TSTDTP) modeling using VHDL-AMS. *Neurocomputing*, 149: 1440-1444 [DOI: 10.1016/j.neucom.2014.08.050]
- Shen J R, Zhao Y, Liu J K and Wang Y M. 2021. HybridSNN: combining bio-machine strengths by boosting adaptive spiking neural net-

- works. IEEE Transactions on Neural Networks and Learning Systems [DOI: 10.1109/TNNLS.2021.3131356]
- Shrestha S B and Orchard G. 2018. Slayer: spike layer error reassignment in time [EB/OL]. [2022-05-08]. <https://arxiv.org/pdf/1810.08646.pdf>
- Song S, Miller K D and Abbott L F. 2000. Competitive Hebbian learning through spike-timing-dependent synaptic plasticity. Nature Neuroscience, 3 (9): 919-926 [DOI: 10.1038/78829]
- Stöckl C and Maass W. 2021. Optimized spiking neurons can classify images with high accuracy through temporal coding with two spikes. Nature Machine Intelligence, 3 (3): 230-238 [DOI: 10.1038/s42256-021-00311-4]
- Taherkhani A, Belatreche A, Li Y H and Maguire L P. 2015. DL-ReSuMe: a delay learning-based remote supervised method for spiking neurons. IEEE transactions on neural networks and learning systems, 26 (12): 3137-3149 [DOI: 10.1109/TNNLS.2015.2404938]
- Tavanaei A and Maida A. 2019. BP-STDP: approximating backpropagation using spike timing dependent plasticity. Neurocomputing, 330: 39-47 [DOI: 10.1016/j.neucom.2018.11.014]
- Thiele J C, Bichler O and Dupret A. 2019. Spikegrad: an ANN-equivalent computation model for implementing backpropagation with spikes [EB/OL]. [2022-05-08]. <https://arxiv.org/pdf/1906.00851.pdf>
- Wade J J, McDaid L J, Santos J A and Sayers H M. 2010. SWAT: a spiking neural network training algorithm for classification problems. IEEE Transactions on Neural Networks, 21 (11): 1817-1830 [DOI: 10.1109/TNN.2010.2074212]
- Wu H, Zhang Y Y, Weng W M, Zhang Y T, Xiong Z W, Zha Z J, Sun X Y and Wu F. 2021. Training spiking neural networks with accumulated spiking flow. Proceedings of the AAAI Conference on Artificial Intelligence, 35 (12): 10320-10328 [DOI: 10.1609/aaai.v35i12.17236]
- Wu Y J, Deng L, Li G Q, Zhu J and Shi L P. 2018. Spatio-temporal backpropagation for training high-performance spiking neural networks. Frontiers in Neuroscience, 12: #331 [DOI: 10.3389/fnins.2018.00331]
- Wu Y J, Deng L, Li G Q, Zhu J, Xie Y and Shi L P. 2019. Direct training for spiking neural networks: faster, larger, better. Proceedings of the AAAI Conference on Artificial Intelligence, 33 (1): 1311-1318 [DOI: 10.1609/aaai.v33i01.33011311]
- Xu Q, Qi Y, Yu H, Shen J R, Tang H J and Pan G. 2018. CSNN: an augmented spiking based framework with perceptron-inception//Proceedings of the 27th International Joint Conference on Artificial Intelligence. Stockholm, Sweden: AAAI Press: 1646-1652 [DOI: 10.24963/ijcai.2018/228]
- Xu Y, Zeng X Q, Han L X and Yang J. 2013. A supervised multi-spike learning algorithm based on gradient descent for spiking neural networks. Neural Networks, 43: 99-113 [DOI: 10.1016/j.neunet.2013.02.003]
- Yang X Y, Meng M Y, Xiao S L and Yu Z Y. 2021. SPA: stochastic probability adjustment for system balance of unsupervised SNNs//Proceedings of the 25th International Conference on Pattern Recognition (ICPR). Milan, Italy: IEEE: 6417-6424 [DOI: 10.1109/ICPR48806.2021.9412266]
- Yu Q, Tang H J, Tan K C and Li H Z. 2013. Precise-spike-driven synaptic plasticity: learning hetero-association of spatiotemporal spike patterns. PLoS ONE, 8 (11): #e78318 [DOI: 10.1371/journal.pone.0078318]
- Zhang W R and Li P. 2021. Temporal spike sequence learning via backpropagation for deep spiking neural networks [EB/OL]. [2022-05-08]. <https://arxiv.org/pdf/2002.10085.pdf>
- Zheng H L, Wu Y J, Deng L, Hu Y F and Li G Q. 2021. Going deeper with directly-trained larger spiking neural networks. Proceedings of the AAAI Conference on Artificial Intelligence, 35 (12): 11062-11070 [DOI: 10.1609/aaai.v35i12.17320]

作者简介

李雅馨,女,硕士研究生,主要研究方向为神经形态计算、脉冲神经网络。E-mail: yaxin.li@mail.dlut.edu.cn

徐齐,通信作者,男,副教授,主要研究方向为人工智能、类脑计算、神经形态计算、神经信号编解码。

E-mail: xuqi@dlut.edu.cn

申江荣,女,助理研究员,主要研究方向为人工智能、类脑计算、神经形态计算、脉冲神经网络。

E-mail: jrshen@zju.edu.cn