



类脑计算脉冲神经网络模型及其学习算法研究进展

黄泽南, 刘晓捷, 赵晨晖, 邓亚彬, 郭东辉

引用本文

黄泽南, 刘晓捷, 赵晨晖, 邓亚彬, 郭东辉类脑计算脉冲神经网络模型及其学习算法研究进展[J]. 计算机科学, 2023, 50(1): 229-242.

HUANG Zenan, LIU Xiaojie, ZHAO Chenhui, DENG Yabin, GUO Donghui. [Spiking Neural Network Model for Brain-like Computing and Progress of Its Learning Algorithm](#) [J]. Computer Science, 2023, 50(1): 229-242.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

[Similar articles recommended \(Please use Firefox or IE to view the article\)](#)

[一种基于脉冲神经网络的星体表面岩石检测算法](#)

Onboard Rock Detection Algorithm Based on Spiking Neural Network

计算机科学, 2023, 50(1): 98-104. <https://doi.org/10.11896/jsjlx.211100149>

[在线影响力最大化研究综述](#)

Survey on Online Influence Maximization

计算机科学, 2020, 47(5): 7-13. <https://doi.org/10.11896/jsjlx.200200071>

[多层前向人工神经网络图像分类算法](#)

Algorithm of Multi-layer Forward Artificial Neural Network for Image Classification

计算机科学, 2018, 45(11A): 238-243.

[术语关系自动抽取方法研究](#)

Study on Term Relation Extraction from Domain Text

计算机科学, 2010, 37(2): 189-191.

[一种基于数值积分的过程神经元网络训练算法](#)

Training Algorithm of Process Neural Networks Based on Numerical Integration

计算机科学, 2010, 37(11): 203-205.

类脑计算脉冲神经网络模型及其学习算法研究进展

黄泽南 刘晓捷 赵晨晖 邓亚彬 郭东辉

厦门大学电子科学与技术学院 福建 厦门 361005

福建省集成电路设计工程技术研究中心 福建 厦门 361005

(36120200155808@stu.xmu.edu.cn)

摘要 深度神经网络在实际应用中的局限性日益凸显,具备生物可解释性的类脑计算脉冲神经网络成为了人们研究的热点课题。应用场景的不确定性及复杂多样性给研究者提出了新的挑战,要求类似生物大脑组织具备多尺度架构的类脑计算脉冲神经网络,能够实现对多模态、不确定性信息的感知决策功能。文中主要介绍了多尺度生物合理性的类脑计算脉冲神经网络模型及其面向多模态信息表征和不确定信息感知的学习算法,并分析探讨了基于忆阻器互联的脉冲神经网络可实现多尺度架构类脑计算的两个关键技术问题,即多模态、不确定信息与脉冲时序表示一致性问题和多尺度脉冲神经网络学习算法与容错计算问题。最后,对类脑计算脉冲神经网络的研究方向进行了分析与展望。

关键词:类脑计算;脉冲神经网络;多尺度网络模型;多模态信息;不确定信息感知;决策融合;学习算法;STDP

中图法分类号 TP183

Spiking Neural Network Model for Brain-like Computing and Progress of Its Learning Algorithm

HUANG Zenan, LIU Xiaojie, ZHAO Chenhui, DENG Yabin and GUO Donghui

School of Electronic Science and Engineering, Xiamen University, Xiamen, Fujian 361005, China

IC Design R & D Engineering Center of Fujian Province, Xiamen, Fujian 361005, China

Abstract With the increasingly prominent limitations of deep neural networks in practical applications, brain-like computing spiking neural networks with biological interpretability have become the focus of research. The uncertainty and complex diversity of application scenarios pose new challenges to researchers, requiring brain-like computing spiking neural networks with multi-scale architectures similar to biological brain organizations to realize the perception and decision-making function of multi-modal and uncertain information. This paper mainly introduces the multi-scale biological rational brain-like computing spiking neural network model and its learning algorithm for multi-modal information representation and uncertainty information perception, analyzing and discussing two key technical issues that the spiking neural network based on the interconnection of memristors can realize multi-scale architecture brain-like computing, namely: the consistency problem of multi-modal and uncertain information with spike timing representation, and the computing fault-tolerant problem for the multi-scale spiking neural network with different learning algorithms. Finally, this paper analyzes and forecasts the further research direction of brain-like computing spiking neural network.

Keywords Brain-like computing, Spiking neural network, Multi-scale network model, Multi-modal information, Uncertain information perception, Decision fusion, Learning algorithm, STDP

1 引言

深度神经网络(Deep Neural Network, DNN)及其学习算法的成功应用^[1-4]被认为是促进新一轮以神经网络为核心的人工智能研究热潮的主要动力。相比传统的感知机^[5],深度神经网络在目标识别^[6-8]、物体检测^[9-11]、语义表达^[12]和自然语言处理^[13]等方面都体现出了良好的学习记忆与分类识别能力。然而,基于冯·诺伊曼架构的传统计算系统实现的深度神经网

络及其学习算法是计算密集型和存储密集型的,网络结构的层次加深意味着系统兑现所需的计算单元及数据内存也大幅增加。以ResNet-50^[14]为例,需要对2500万个网络互联突触数据进行39亿次运算操作,这种基于深层次的网络结构在空间上重复性堆叠的运算操作无疑存在着系统能耗、计算速度和数据带宽等一系列技术难题^[15]。而且,这种深度神经网络的层次性系统结构及计算模式与大脑生物神经网络相差甚远,因此,随着研究人员对以神经网络为核心的人工智能技术

到稿日期:2022-01-06 返修日期:2022-08-08

基金项目:国家自然科学基金重点项目(61836010)

This work was supported by the Key Program of National Natural Science Foundation of China(61836010).

通信作者:郭东辉(dhguo@xmu.edu.cn)

研究热情的高涨,深度神经网络及其学习算法在各种领域中的不尽如人意的表现促使人们开始探寻更具生物合理性及可解释性的类脑计算模型。

生物神经系统的研究成果^[16]表明,动物大脑是由许多简单的生物神经元组成的,生物神经元之间通过突触实现错综复杂的互联与学习记忆,并以脉冲信号的形式相互传递交换信息。为此,近年来研究人员致力于研究可实现神经元突触功能的忆阻器,开发基于忆阻器突触互联且具有生物合理性的脉冲神经网络(Spiking Neural Network, SNN)电路^[17-20],如国际商业机器公司(International Business Machines Corporation, IBM)^[21]、麻省理工学院(Massachusetts Institute of Technology, MIT)^[22]及国内外一些研究机构^[23]等相继推出了具有特定类脑计算功能的脉冲神经网络处理器芯片。然而,这些以脉冲神经网络为基础的类脑计算功能仍缺乏具有可解释性的理论支撑,还不具备通用的感知学习决策能力,在复杂的应用场景下难以实现推广应用^[24]。因此,面对愈加复杂的应用需求,如何突破脉冲神经网络类脑计算机制的可解释性瓶颈,在同一框架内构建具有多尺度生物合理性的大规模类脑神经网络模型,以满足多种学习任务兼容的要求,已成为类脑计算模型研究的重点。同时,从单个神经元的脉冲活动到以局部场势(Local Field Potentials, LFP)和皮层脑电路(Electrocorticogram, ECOG)等为体现的神经元群体活动^[25],在不同时空尺度上的神经系统活动编码行为被认为是实现通用感知决策机制的基础,也是大脑神经系统对不同模态信息的一致性处理过程的体现^[26]。同样,多模态信息的表征与融合有助于提升类脑计算系统面对复杂应用的学习决策能力,保证了学习的可靠性与抗干扰的能力^[27]。因此,类脑计算脉冲神经网络模型的机制研究还需要进一步探寻信息不确定性与脉冲序列之间的关系,了解基于忆阻器互联突触的不确定信息编码如何有效地提升类脑计算脉冲神经网络模型的鲁棒性。

本文从脉冲神经网络类脑计算模型、多模态信息融合感知技术和不确定信息类脑学习算法3个方面总结了基于突触互联的脉冲神经网络模型及类脑计算机制的研究进展和技术发展趋势,并分析了同一模型下相关学习算法在不同场景的应用前景。最后,本文归纳了类脑计算脉冲神经网络及其学习算法研究中的关键科学问题,并探讨了下一步的研究方向。

2 脉冲神经网络类脑计算模型

大脑的神经系统是由不同区域的生物神经元互联及其不同功能表现的网络组织构成^[28-29],类脑计算的人工智能研究首先需要从模拟生物神经系统结构和功能特性出发,分析生物神经网络突触互联机制及其在不同时空和多尺度下生物神经网络的功能体现。为此,本文将从生物神经系统结构与功能特性、基于突触互联的神经形态网络模型及多尺度神经网络类脑计算机制3个方面来介绍相关的研究进展。

2.1 生物神经系统结构与功能机制

自解剖学诞生以来,人们就开始对研究模拟人脑的生物神经系统产生了浓厚的兴趣^[30]。在20世纪中叶,心理学家McCulloch和数学家Pitts合作,在前人研究的基础上开创性

地提出了M-P模型^[31],并成功将其用于描述生物神经元的活动状态,这为人工神经网络的研究取得飞速发展起到了重要的促进作用^[32]。如自组织映射(Self-Organizing Map, SOM)网络^[33]、Hopfield网络^[34]、多层前馈网络^[35]等都是基于M-P神经元模型及其随后发现神经元突触可塑性的Hebb学习规则^[36]发展起来的。

但是,这些简单结构及基于突触互联的人工神经网络并没有体现生物神经系统中不同细胞、组织和器官之间通过脉冲信号实现信息交流及功能协调等现象^[37],如人脑的视、听、触觉等感官神经元将不同模式的输入信息转换为电脉冲序列,并将其传输到大脑神经系统;大脑神经元及其互联突触则是在电脉冲信号的激励下实现自主学习记忆;不同模态信息的脉冲信号输入先汇聚到各自的脑区网络,并最终融合到前额区实现决策。因此,受大脑生物神经系统的结构和活动的启发,基于神经形态突触互联的脉冲神经网络^[38]被认为是具有生物合理性的类脑计算模型,应该具备比基于简单神经元组成的深度神经网络更合理的类脑计算功能。

从生物神经系统结构的角度来看,无论是原子级的离子输运、分子级的基因组织变化,还是细胞级的神经元及其突触互连,不同尺度下生物信息的相互作用应该是大脑产生认知、学习、决策等复杂功能的具体表现^[39],这种多个时空尺度共同作用的信息特性也体现出了大脑结构的复杂性^[40]。已有的研究成果表明,涉及空间尺度判断的决策与前扣带回皮质、邻近的背内侧前额皮质和前内侧前额叶皮质等部位的神经活动有关^[41]。同样,对于不同的大脑皮层区域,其对应的时间尺度也不同。文献[42]表明,在灵长类皮层放电中存在时间尺度上的分层排序,感觉区、顶叶区和前额叶区具有自小到大的时间尺度,而不同时间尺度可以有效解释大脑学习记忆的行为机制^[43]。

2.2 基于突触互联的脉冲神经网络

几乎是在描述神经元突触可塑性及其记忆原理的Hebb学习规则被提出的同时,研究人员就发现生物神经元之间是以脉冲形式传递信息的。如Hodgkin等^[44]对乌贼的巨形轴突的研究发现,神经元细胞膜电压与3种离子运动的动态关联,神经元细胞膜电压V可以用描述脉冲动力学的微分方程式来表示:

$$\tau \frac{dV}{dt} = -(V - V_{\text{res}}) + RI \quad (1)$$

其中, $\tau = RC$ 为膜时间常数, R 为膜电阻, I 为离子输运产生的注入电流, V_{res} 为复位的膜电压。当神经元膜电位超过阈值时将发放脉冲,信息将以脉冲的形式在神经元之间传递。

在Hebb学习规则和神经元脉冲传输信息的原理的基础上,研究人员普遍认为神经元间的突触可塑性是大脑学习和信息存储的基础。神经元突触的前后变化应该与神经元间发放脉冲峰值的时间紧密相关,是一个时序非对称的Hebb学习形式。这种突触的变化作为突触前和突触后动作电位的相对时间的函数被称为脉冲时间依赖可塑性(Spike Timing Dependent Plasticity, STDP)函数^[45],如图1所示。其中, Δw 表示突触权重的变化量, t_{pre} 和 t_{post} 分别表示突触前神经元与

突触后神经元脉冲发放时间。如今基于突触互联的脉冲神经网络通过 STDP 的可塑性学习算法已经可以达到与传统深度神经网络接近的效果,表 1 列出了几种不同结构及学习算法下的神经网络^[46-51]识别 MNIST 数据的效果。

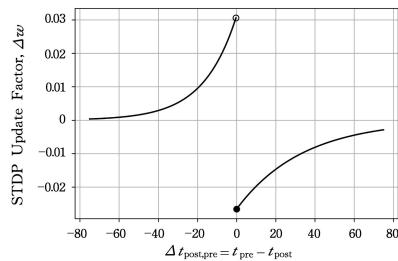


图 1 STDP 函数示意图

Fig. 1 STDP function diagram

表 1 脉冲神经网络与深度神经网络在 MNIST 数据识别上的功能效果对比

Table 1 Comparison of functional effects of spiking neural network and deep neural network in MNIST data recognition

数据集	参考文献	神经元个数(突触个数)	网络模型	输出精度/%
Mnist	文献[46]	$24416(23818 \times 10^3)$	脉冲	96.48
Mnist	文献[47]	$8400(7379 \times 10^3)$	脉冲	95.64
Mnist	文献[48]	$9000(11304 \times 10^3)$	脉冲	95.07
Mnist	文献[49]	$12800(45977 \times 10^3)$	脉冲	95.00
Kannada-MNIST	文献[50]	123003(463121)	深度	99.80
Kannada-MNIST	文献[50]	72906(269290)	深度	99.74

突触互联构成的脉冲神经网络及其 STDP 学习算法具有存算一体的可塑性及低功耗的特点,一直被认为是突破深度神经网络的局限性且最具实用价值的类脑计算模型。因此,近年来人们开始关注开发基于神经形态器件的脉冲神经网络类脑处理器芯片^[52-53],如 IBM 的 TrueNorth^[54]和英特尔的 Loihi^[55]。然而,这些类脑处理器芯片采用交叉开关矩阵(CrossBar)的全互联架构,该方式虽然易于可重构编程以实现各种逼近人类大脑互联的网络结构,但它无法发挥所有突触器件的作用,因此目前只能在特定的场景中应用。

2.3 多尺度神经网络及其类脑计算机制

在不同尺度下观测同一客观存在的事物,其呈现的结果形式是不同的,对应的信息特征也存在差异。由于大脑神经系统在不同结构层面上具有多尺度特征,特别是神经元间大规模互联的相互作用,对于系统级层面的功能描述需要考量不同尺度间的相互转换,即从微观层面上神经元细胞膜离子通道的离子输运产生相互作用将导致组织、器官等宏观层面动态行为的改变。为此,Spiliotis 等^[56]提出了一种多尺度计算框架,从描述个体神经元相互作用的微观动力学中提取系统级信息特征。图 2 给出了微观粒子(细粒度)与宏观系统(粗粒度)间相关转换的表达关系,其中 $u(x)$ 表示微观变量在微观坐标 x 集合上的分布函数,其对应的微观演化分布的低阶矩用 u_s 表示,而系统级别即粗粒度级别状态用 u_f 表示,该框架使用“Equation-Free”方案,在时间视距 T 内可以将高阶矩表示为低阶矩的快速函数。

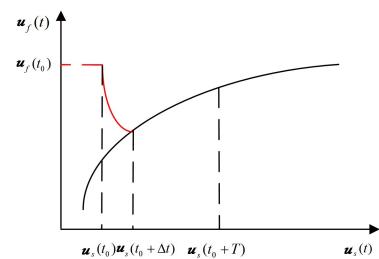


图 2 粗细粒度变换

Fig. 2 Coarse and fine-grained transformation

同样,从单个神经元的脉冲活动到大脑各区域以局部场势或心电图等信号来体现系统级神经元群体活动,大脑生物神经系统活动行为表现为在神经元活动的多个时空尺度上的信息编码^[57]。基于 M-P 神经元模型,神经元脉冲活动一般以二进制表示,在毫秒尺度上用 0 或 1 来表示在该时间节点下是否存在脉冲,而系统级种群活动是在较大时间尺度上以连续信号来表示的。对于由 C 个神经元组成的神经网络系统,假设在时刻为 t 时,每个神经元的活动可以表示为 $N_t^{1:C} = [N_t^1, \dots, N_t^C]'$, N_t^c 为第 c 个神经元在 t 时刻的状态,所有神经元的似然函数可以表示为:

$$p(N_t^{1:C} | x_t) = \prod_{c=1}^C (\lambda_c(x_t) \Delta)^{N_t^c} \exp(-\lambda_c(x_t) \Delta) \quad (2)$$

$$\lambda_c(x_t) = \exp(\beta_c + \alpha_c' x_t)$$

其中, Δ 和 x_t 分别表示时间间隔和神经元的行为状态, λ_c 是具有脉冲模型的神经元 c 在时刻 t 的激活率, α 和 β 是可学习调整的参数。考虑到系统场信号的对数功率特征是系统行为变量的线性函数,可以采用线性高斯模型^[58]来表示神经元的群体活动:

$$y_t = Q \bar{x}_t + z_t \quad (3)$$

其中, Q 是一个待学习的参数矩阵, $\bar{x}_t = [1, x_t']'$ 表示每个神经信号的频率特征, z_t 是高斯白噪声。则针对系统级神经信号特征的高斯似然函数可以表示为:

$$p(y_t | x_t) = N(Q \bar{x}_t, Z) \quad (4)$$

其中, $N(a, G)$ 表示具有平均 a 和协方差 G 的高斯分布。因此,统一的多尺度时空编码模型可以表示为:

$$p(y_t, N_t^{1:C} | x_t) = p(y_t | x_t) p(N_t^{1:C} | x_t) \quad (5)$$

基于上述多尺度结构下的时空信息编码,文献[59]开发了一种自适应学习算法的多尺度滤波器(Multiscale Filter, MSF)。该滤波器可在毫秒尺度上运行并将来自场域的信息添加到更慢的时间尺度中,场域信号可以捕获有关脉冲事件的信息,而脉冲也有助于产生场信号。

基于脉冲与场域的一致度量性,文献[60]提出了一种新的多尺度因果估计算法。如图 3 所示,考量脉冲到脉冲、场域到脉冲、场域到场域和脉冲到场域之间的因果关系,文献设计的算法可以评估脉冲场网络中的多尺度因果关系。文献[61]则设计了一种利用脉冲场活动和多尺度滤波器相结合的多尺度脉冲神经网络动力学模型,将感知信息转换为脉冲形式,并将其编码在不同时空尺度中,实现隐藏状态下的无监督学习算法。同等规模的神经网络比深度神经网络的学习算法具有更大的信息存储量和更高的收敛精度^[62]。此外,同一模型

架构下的多尺度脉冲神经网络还适用于多种学习算法^[63],如监督学习、无监督学习等,有效地迎合了不同应用的需求。

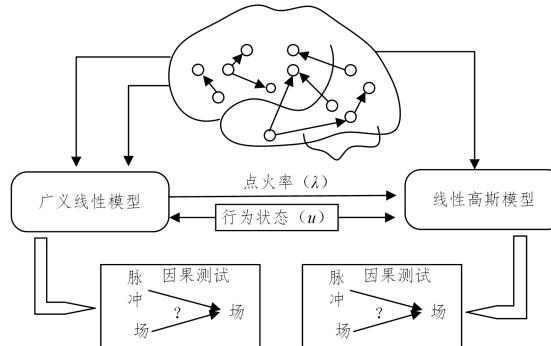


图 3 多尺度因果关系估计

Fig. 3 Multi-scale causality estimation

与传统的全连接不同,多尺度脉冲神经网络的突触在不同时空尺度之间以稀疏互联的形式存在,可以在保证网络性能的同时,有效减少神经元间的突触连接,这对将网络扩展到千亿级别的神经元电路^[64]的设计尤为关键。考虑到大脑是通过融合不同模态信息来实现最终决策的,而基于不同的模态信息,大脑的多尺度网络可实现模态间的跨域学习,因此,成熟的多尺度类脑神经网络仍需要实现对不同模态信息的感知融合,通过学习多模态信息来提高网络的泛化能力^[65]。

3 多模态信息感知决策技术

神经科学研究表明^[66],大脑在很短的时间内对来自多个感官系统的多模态信息具有整合能力^[67],特别是在人脸识别和手势识别等任务中,大脑在 150~200 ms 内能有效地对多模态刺激信息进行处理^[68]。理解这一感知学习决策过程中多模态信息与脉冲表征的一致性,有助于提升神经网络在感知任务中的表现。考虑到模态特征的异质性,以下从多模态信息表征、模态信息感知学习算法及多模态信息类脑融合决策来介绍多模态信息处理技术的研究进展。

3.1 多模态信息表征

当处于复杂、嘈杂的环境时,大脑能有效利用多种模糊的感官信息来调节和控制之后一段时间的行为决策。对这种感知决策的研究已经成为心理学和神经学的研究重点^[69]。生物从感官系统中收集信息后,不同模态的信息将以脉冲的形式传输到大脑的不同区域,并在大脑中实现对信息的融合处理。研究表明^[70],感官器官、顶叶和额叶皮质中的神经元等都参与了多模态信息的编码,然后根据积累的来自不同神经组织的脉冲信号规划了随后的运动行动。因此,针对多模态数据信息,我们需要考虑其表征问题。

多模态表征可以分为联合表征与协调表征。现有的多模态联合表征应用聚焦于图像、语音、文字这 3 个方面。其中,Xu 等^[71]在统一框架下实现了对组合语言模型、深度视觉模型和联合嵌入模型的建模,使模型在处理自然语言生成、视频检索和语言检索等应用场景中展现出了优异的性能。类似地,文献[72]使用双线性 softmax 层融合单模态深度网络的隐藏层,获得了深度网络的联合特征空间,从而实现了自动语音识别;文献[73]使用具有正交正则化的深度多模态散列来

捕获不同模态信息的复杂性,模型中加权矩阵经过正则化操作后被证明是近似正交的,该模型被应用于多模态数据的相似性搜索,有效地解决了冗余问题。

与联合表征不同,协调表征在单模态学习表征的基础上设计约束以进行协同表征。一般地,协调表征考虑不同模态间的相似性^[74],构造协调空间以实现不同模态间特征的映射,从而将协同空间中模式之间的距离最小化。文献[75]提出了一种深度视觉语义嵌入模型,该模型利用标记图像数据和未注释文本的语义信息来识别视觉对象。文献[76]使用长短期记忆人工神经网络(Long Short-Term Memory, LSTM)模型排序损失来构成协调特征空间,以实现句子和图像的协调表示。文献[77]设计了带有语义嵌入的长短期记忆模型,实现了 LSTM 和视觉语义嵌入的学习。如图 4 所示,从 3D 卷积神经网络中提取的视频特征与语义特征被输入到嵌入空间中,相关性损失 $E_r(v, s)$ 评估句子语义与视频的相关性,一致性损失 $E_c(v, W)$ 则描述 LSTM 中单词的上下文关系。通过最小化两个损失函数,该模型既充分考虑了句子中单词的连贯性,又保证了句子与视频之间的相关性。

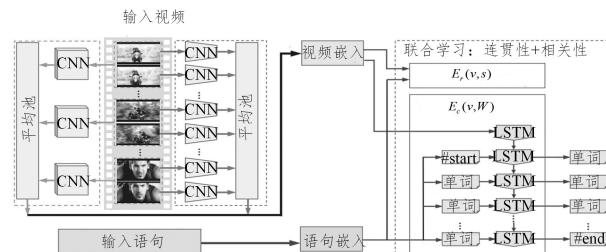


图 4 相关性协调表示模型结构图

Fig. 4 Relevance coordination representation model

上述方法针对不同模态信息采用的信息编码和相应的表征方式并不相同,这极大限制了其应用的通用性。同时,模态信息数据编码缺乏生物可解释性,无法解释大脑中的多信息融合机制。视、听、触、嗅等模态信息在实质上是被不同感知器官感知并最终编码成了脉冲信号。以视觉感知为例,在人类和许多其他哺乳动物中,当光通过角膜进入眼睛时,视网膜中的光感受细胞会对光子做出反应并产生神经信号。来自视网膜的脉冲信号通过外侧膝状体核传播到视觉皮层中。当不同感官信息传递到大脑后,神经元将考虑不同刺激强度对决策速度及准确率的影响^[78]。相关的研究表明,人类后顶叶皮层区域的神经活动反映了感觉证据的强度,协助大脑做出相应的决策活动。这些区域本身对感官刺激并不作出反应,而是整合了针对决策结果的感官证据^[79]。

直觉上,感知判断的整合效率取决于感官刺激的强度。刺激强度大意味着更高的精度和更快的响应速度,当刺激强度较弱时,决策判断的精度低且反应时间长。现代响应时间理论的起点是顺序抽样^[80],相关刺激的内部表征被认为是噪声并随时间而变化的。基于上述理论,文献[81]将反应时间和准确性作为刺激强度变化的函数,该理论的提出允许人们将精度理论扩展到响应时间,表现了脉冲信号与信息表征的一致性。来自视、听、触、嗅等感觉的不同模态信息,都可以用相似的编码方法表示为脉冲序列的形式,并最终汇入代表

顶叶和额叶皮层细胞的脉冲决策神经元以完成推理、检测等任务。其中,模态信息特征表现为不同强度、不同时序的脉冲信号,不同模态信息间的相互补充将有效提高网络的泛化能力和容错计算能力。

3.2 模态信息感知学习算法

多模态任务可以追溯到声学和视觉识别任务^[82]。自动语音识别系统依赖于声学语音信号,在噪声环境中单一模态系统的性能表现往往不尽如人意。在处理具有噪声的声音信号时,视觉信号提供有效的补充信号来提升系统的识别性能。对生物大脑的研究表明,顶叶和额叶皮层的感觉运动关联区将感官证据映射到运动动作上并不是一种刻板的反射,这种映射强烈依赖于决策者当前的行为目标。针对不同的应用环境,完全相同的感官输入可以被映射到不同的动作上,而不同的感官输入也可能导致相同的选择。

随着脉冲神经元模型的发展,对应的类脑计算模型学习算法也在逐步完善。其中,STDP 学习规则探寻了神经元发放时间与突触权重之间的关系^[83],从理论上解释了神经元连接的生物学过程。与反向传播学习规则相似,SpikeProp 算法^[84]聚焦于脉冲神经元的触发时间,通过最小化输出和期望之间的误差来实现网络的训练。ReSuMe 算法^[85]和 Tempotron 算法^[86]则依照不同膜电压变换方式实现了 SNN 的监督学习。针对不同的模态信息,对应的学习算法也应发生改变。以图像数据为例,如图 5 所示,MuST 模型^[87]在 S1 层中引入 Gabor 滤波器来描述信号的局部纹理特征,在 C1 层使用最大池操作来采样脉冲信息,并通过 STDP 方法实现对视觉信息的采样。

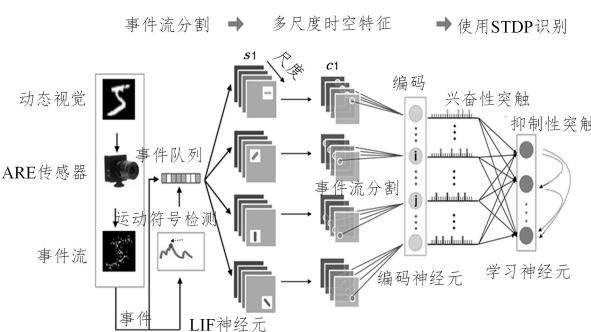


图 5 MuST 模型

Fig. 5 MuST model

除此之外,SNN 也被用于口语识别任务。SWAT^[88]算法将 Bienenstock-Cooper-Munro 学习规则与 STDP 相结合,通过 STDP 学习特定的权重分布来反映不同类语音数据的相似性与区别。如文献[89]从语音信号中提取出了脉冲特征,其中高相似度的脉冲序列属于同一类别的语音数字,低相似度的模式属于不同的类别。文献[90]将隐马尔可夫模型(Hidden Markov Model, HMM)和 SNN 相结合来处理语音信号。HMM 的观测概率用 SNN 表示,并使用 STDP 规则训练语音分类模型。

虽然单模态类脑计算模型在一定程度上能满足应用的需求,然而面对存在噪声的复杂环境,其容错计算能力难以令人满意。类脑计算的多模态网络模型成为了解决上述问题的

一条有效途径。表 2 列出了单模态类脑计算网络和多模态类脑计算网络在数字识别应用中的性能比对。

表 2 单模态与多模态脉冲神经网络性能比对

Table 2 Performance comparison of single-modal and multi-modal spiking neural networks

网络模型	层数	学习方法	模态	数据集	输出精度/%
文献[49]	2	无监督	单模态	MNIST	95.00
文献[87]	3	无监督	单模态	NMNIST	89.70
文献[88]	3	监督	单模态	TI46	95.25
文献[91]	4	监督	单模态	TIDIGITS	96.00
文献[92]	2	无监督	单模态	MNIST	93.20
文献[92]	2	无监督	单模态	TI46	96.00
文献[92]	2	无监督	多模态	MNIST 和 TI46	98.00
文献[93]	3	监督	单模态	MNIST	96.80
文献[93]	3	监督	单模态	TIDIGITS	95.80
文献[93]	3	监督	多模态	MNIST 和 TIDIGITS	98.90

从表 2 可以看出,多模态分类框架的网络性能整体上优于单模态分类框架。同时,由于跨模态连接结构的存在,多模态网络在多模态数据集中分类性能有明显的提升。为明确这一点,本文将在 3.3 节中介绍类脑计算中多模态信息融合决策的相关研究进展。

3.3 多模态信息融合决策方法

正如神经科学和机器学习领域中的时间信用分配问题(Temporal Credit Assignment, TCA),学习多感官信息需要精确处理不同感官反馈信号延迟的到达时间。在脉冲神经网络中,当预测的线索发生时,神经元通过类似感知器学习的突触学习规则^[94]来加强突触权重,然而当线索的到达时间是未知时,即在无监督条件下,单一的突触变化学习方法^[95-96]在这类应用中的性能是有限的。Gutig^[97]提出了一种聚合学习的方法,用于解决时间信用分配问题,将输出脉冲的数量与反馈信息的多少相匹配,在一个神经元中有效地模拟了大脑处理多模态信息的方法。如图 6 所示,A 中上方矩形表示 10 个不同的感官特征,即多模态信息,左侧为输入活动信息,右侧为对应的突触后膜电位变化示意图。当一个神经元经过训练后,其输出脉冲数量与反馈信息的多少将成正比关系。如图 6 中的 B 所示,每个感官信息产生的输出脉冲的数量对应于不同感官信息对突触前膜电压的贡献程度。聚合标签学习范式训练了脉冲神经元在不考虑每个脉冲精确到达时间的条件下触发脉冲的数量,解决了神经系统识别输入活动中预测延迟反馈特征的问题。

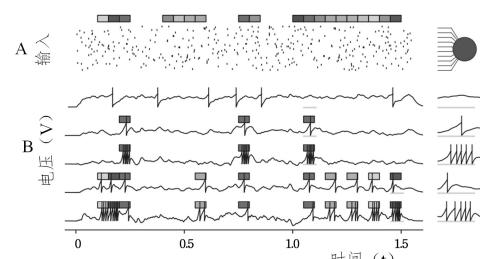


图 6 聚合标签学习方法

Fig. 6 Aggregate label learning method

在聚合标签学习的基础上,文献[98-100]基于膜电位来

估计生物放电阈值变化的关系,通过构造误差函数来学习嵌入在不相关脉冲活动中的预测线索。文献[101]将离散脉冲时间差转化为固定生物发射阈值与假设阈值之间的连续距离,引入梯度下降算法将触发阈值距离最小化以实现突触权重的学习。考虑到上述学习算法仅适用于单个神经元,文献[102]扩展了阈值驱动的神经元可塑性算法(Efficient Threshold-Driven Plasticity,ETDP)来支持多层脉冲神经网络,显著提高了学习算法的适用性。除了监督学习方法,STDP也被应用于多模态的无监督学习^[103]。

近年来,对功能性磁共振成像(Functional Magnetic Resonance Imaging,FMRI)^[104]、脑电图^[105]、扩散张量成像(Diffusion Tensor Imaging,DTI)^[106]等非侵入性脑数据收集技术的研究,为理解大脑结构和功能特性做出了巨大的贡献。不同的大脑数据抽样方法(即 FMRI,EEG 和 DTI 数据)可以提供大脑在不同时空模式下的独特认知。在一个模型中整合各个数据源中提取到的相关信息,不仅对预测模型的鲁棒性和性能至关重要,而且对理解数据中的时空关系也提供了一定的可解释性。尽管对大脑数据的机器学习研究已经较为成熟^[107-109],但由于数据源的不同时间和空间特征,脉冲神经网络中的多模态数据融合仍需要继续探索。文献[110]在 Neu-Cube^[111]的基础上整合了来自 DTI 的方向信息和 EEG/FMRI 活动数据,并定量评价了神经行为及模型利用空间、时间、方向信息的能力,极大地提高了模式识别能力。

从以上论述可以看出,多模态类脑计算算法将不同模态的信息编码为脉冲,并通过相应的类脑计算模型实现对多模态信息的整合与学习,保证了类脑计算模型在复杂环境中对外界信息的感知能力与最终决策任务的有效性。当然,单一的多模态类脑计算算法依旧存在鲁棒性与结构不确定性问题,为了满足复杂的应用需求,类脑计算模型仍需要解决泛化能力问题,即不确定性问题。

4 不确定信息类脑学习算法

机器学习(包括深度学习算法)的实现需要大量标记的数据来支撑,对标记数据的需求^[112-114]随着网络架构复杂性的提高与日俱增,特别是在复杂多变环境下^[115]。为了提高网络的鲁棒性和稳定性^[116],研究者将不确定性感知决策的思想引入类脑计算模型中。其中,偶然不确定性^[117]描述感知数据的固有噪声,认知不确定性^[118]描述模型决策中的不确定性。神经网络一般通过量化模型预测的置信度来评估对不确定信息^[119]的感知处理能力。本节从不确定信息表示方法、不确定信息的学习算法和类脑计算模型的不确定决策3个方面来介绍不确定性信息类脑学习算法的研究进展。

4.1 不确定信息表示方法

对于给定的输入 $\mathbf{X} = \{x_1, \dots, x_N\}$ 与对应的输出 $\mathbf{Y} = \{y_1, \dots, y_N\}$,通过贝叶斯回归找寻合适的参数 w 来判断输出的可能性,其后验概率表示为:

$$p(w|\mathbf{X}, \mathbf{Y}) = \frac{p(w)p(\mathbf{Y}|\mathbf{X}, w)}{p(\mathbf{Y}|\mathbf{X})} \quad (6)$$

其中, $p(w)$ 代表参数 w 的先验概率, $p(\mathbf{Y}|\mathbf{X}, w)$ 为在已知

输入 \mathbf{X} 与参数 w 的条件下网络输出 \mathbf{Y} 的概率,在分类问题中这一概率通常以 softmax 似然分布或者高斯似然分布的形式来表示。利用贝叶斯理论,我们可以通过积分来预测新输入点 x^* 的输出:

$$p(y^*|x^*, \mathbf{X}, \mathbf{Y}) = \int p(y^*|x^*, w)p(w|\mathbf{X}, \mathbf{Y})dw \quad (7)$$

然而,真实的后验概率分布复杂且难以解析,贝叶斯方法通过函数逼近的方式来调整参数。变分推理^[120]引入 Kullback-Leibler 散度(KL 散度)^[121]有效解释了复杂模型之间的平衡关系,并最终获得了表示模型不确定的概率模型。其中,KL 散度通过计算不同分布的相对熵来度量两个随机变量间的距离:

$$KL(q_\theta(w) \parallel p(w|\mathbf{X}, \mathbf{Y})) = \int q_\theta(w) \log \frac{q_\theta(w)}{p(w|\mathbf{X}, \mathbf{Y})} dw \quad (8)$$

对于数据的真实分布 p , $q_\theta(w)$ 表示数据的模型分布。最小化 KL 散度可以获得关于最优解 $q_\theta^*(w)$ 的近似预测分布:

$$\begin{aligned} p(y^*|x^*, \mathbf{X}, \mathbf{Y}) &\approx \int p(y^*|x^*, w)q_\theta^*(w)dw \\ &= q_\theta^*(y^*|x^*) \end{aligned} \quad (9)$$

基于贝叶斯推理,贝叶斯神经网络(Bayesian Neural Network,BNN)^[122]通过推断模型权重的分布方法奠定了神经网络概率模型基础。这一模型在预防过拟合、实现不确定性估计中表现出了良好的鲁棒性,同时在小数据集应用中也展现出了优异的性能。BNN 的目的是获得对应权重矩阵的分布情况,变分推理^[123]提供了一种将实际分布与近似分布间 KL 散度最小化的方法。最早的 BNN 只演示了单隐藏层的优化方法,难以满足具体应用的要求。在此基础上,Hinton 等^[124]通过对权重之间的相关性进行建模提升了网络性能,但也因为引入了权重的二次项而增加了计算的复杂度。此外,文献[125]使用蒙特卡洛估计近似期望对数似然函数^[126],突破了单隐藏层的限制,使 BNN 可以应用到更复杂的模型。深度学习的兴起带动了贝叶斯网络的发展。其中,Opper 等^[127]使用高斯近似进行贝叶斯神经网络后验逼近,进一步提升了模型性能。文献[128]使用概率反向传播在均方根误差和不确定性估计方面大大改进了变分推理模型^[129],使 BNN 在大数据应用场景中也有了用武之地。

贝叶斯深度学习给不确定性学习提供了一系列理论依据,增强了网络的鲁棒性。虽然贝叶斯神经网络在一定程度上提高了网络的泛化能力,但该网络依旧受限于深度学习的框架,由于缺乏生物可解释性,其能存储的信息量依然受到限制。因此,相应的贝叶斯类脑计算学习方法也随之出现。

4.2 不确定信息的学习算法

心理学和神经生理学证据表明,大脑使用贝叶斯原理来处理复杂的环境问题^[130-131],如认知^[132]、线索组合^[133]和决策问题^[134]。同时,大脑皮层的层状结构及分层信息处理方式的发展促使分层贝叶斯推理成为类脑计算的基础框架^[135]。生物在面对充满不确定性和模糊性的环境时,当感官器官感知到外界信息时需要具备推理隐藏状态信息的能力。因此,以结合脉冲神经网络与贝叶斯理论的学习方法来实现上述

要求,对理解人脑的感知学习过程具有重要意义。

神经元与突触构成了大脑的基本计算单元,根据突触前和突触后神经元的不同发放脉冲时间实现大脑学习决策功能^[136-137],即 STDP。贝叶斯类脑计算模型将 STDP 与 Hebbian 学习规则解释为贝叶斯推理过程,从微尺度层面阐述神经元感知计算机制。Nessler 等^[138]在赢者通吃(Winner-Take-All, WTA)电路中证明了贝叶斯计算与通过 STDP 改变的神经元活动的内在一致性。贝叶斯计算的先验概率是由神经元突触权重变换的隐形生成模型产生的。实质上,每个脉冲都可以被理解为生成概率模型后验分布的取样。如图 7(a)所示,外部输入电压由群体编码反馈到 WTA 电路中,WTA 电路中的神经元通过横向抑制竞争使用 STDP 更新输入权重。图 7(b)给出了多项式混合的生成概率模型:假设外部输入变量依赖于隐藏因素 k ,则推理任务等同于观察输入变量来获得 k 的具体参数。整个网络模型将图模型的条件概率编码为权向量,使用 STDP 对突触权重进行调整来实现功能最大化,最终实现推理任务。在此基础上,Guo 等^[139]提出了一种层次化贝叶斯电路网络,该网络实现了具有树结构的层次化贝叶斯模型的表示、推理和学习过程。

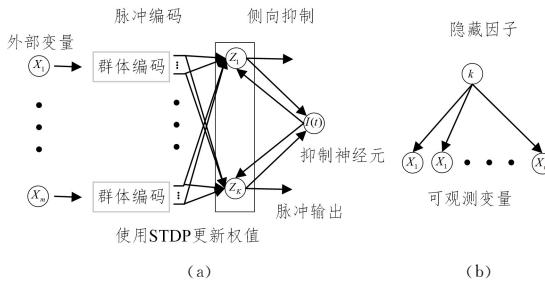


图 7 WTA 网络模型及概率解释

Fig. 7 WTA network model and probabilistic interpretation

从以上论述可以看出,针对不确定信息的学习算法以 STDP 为主,STDP 学习规则与贝叶斯推理过程具有内在一致性。使用 STDP 学习规则确定突触权重后,能否精确分析不确定信息以保证网络本身的容错计算能力就成了限制类脑计算模型发展的关键问题。

4.3 类脑计算模型的不确定决策

在类脑计算模型中,神经元放电过程可以解释为马尔可夫链蒙特卡罗算法(Markov Chain Monte Carlo, MCMC)的概率推断行为。文献[140]将循环脉冲神经网络和隐马尔可夫模型联系起来实现贝叶斯推理,在识别带有噪声的视觉刺激和检测运动刺激的运动方向上取得了巨大突破。为了解释神经科学和认知科学中大量的错综复杂的实验数据,同时考虑神经元放电活动固有的随机特征,文献[141]将脉冲神经元的随机放电活动通过 MCMC 采样解释为概率推理过程,在连续和离散的时间情况下,神经元的神经活动实现给定分布的 MCMC 采样。类似地,文献[142]以 MCMC 采样的概率推理为基础来模拟皮质微电路的精确结构和复杂神经元的树突计算功能。其实验结果表明,精确结构的神经元微电路使脉冲神经元网络能够通过其固有的随机动力学解决各种复杂的概率推理任务。文献[143]将研究层次从神经元扩展到神经

种群,把神经种群与概率分布联系在一起,通过神经种群的线性组合进行贝叶斯推理。文献[144]提出了一种两层泊松神经元递归网络,下层的感觉神经元接收来自外界的信息,高层神经元根据感官神经元产生的输入内容使用近似贝叶斯推断来学习所表示的神经元种群活动的后验分布。这一设计已被证实具有突触可塑性的神经元网络能够实现类似于蒙特卡罗方法(如粒子滤波)的贝叶斯推理形式。

贝叶斯推理模型不仅在理论上为类脑计算提供了生物合理性与生物可解释性,在类脑计算的加速与硬件实现上也有着不可忽视的影响。文献[145]将脉冲神经网络与只看一次算法(You only look once, YOLO)相结合,提出了第一个基于脉冲的对象检测模型。与较为成熟的脉冲图像分类模型^[146]相比,针对对象检测应用的脉冲神经网络具有 2 倍以上的延迟及 100 倍以上的脉冲数。因此,若要提升复杂应用类脑计算模型的性能,则需要减少时间步数和突触操作来降低网络延迟及脉冲数。文献[147]利用贝叶斯优化技术来衡量网络的延迟、突触操作数与网络精度的关系,然后通过贝叶斯推理获得脉冲神经元中最优的阈值电压来实现更快更精确的目标检测功能。表 3 列出了不同目标检测脉冲神经网络模型在 PASCALVOC 与 MSCOCO 数据上的比对。

表 3 不同 SNN 模型的目标检测精度比对

Table 3 Comparison of target detection accuracy of different SNN models

(单位:%)

Method	PASCAL VOC		MS COCO	
	500 step	5 000 step	500 step	5 000 step
文献[145]	30.78	50.81	18.23	25.30
文献[147]	46.66	54.44	21.05	25.78
文献[148]	8.36	7.91	5.25	5.29
文献[149]	29.86	30.93	16.97	16.95

可以看到,使用贝叶斯优化的脉冲神经网络模型具有最优的目标检测模型,同时其在两个数据集上的收敛速度是基准的 2 倍和 1.85 倍。除了使用贝叶斯方法确定网络中的超参数,还存在两种提升网络能效的方案:1) 使用专用类脑计算硬件(TrueNorth, Loihi)来充分利用二进制序列信号的时间稀疏性;2) 将突触权重限制在 1 和 -1 中来避免繁琐的计算。文献[150]使用贝叶斯范式将二值化突触权重与脉冲神经网络相结合,通过降低神经操作的复杂性来保证贝叶斯推理在精度和校准方面的优势。

与简单贝叶斯神经网络相比,贝叶斯类脑计算模型探寻了贝叶斯学习过程与大脑中神经元间相互作用机理的一致性过程^[151],在保证类脑计算有效性与可解释性的同时,提供了对不确定性信息的学习方法,极大地提高了类脑计算模型的泛化能力。因此,贝叶斯过程有助于理解从神经基质到认知系统的脉冲刺激处理过程,保证了多尺度神经网络的容错计算能力,提高了类脑计算模型在面对不同应用时的学习决策能力。

5 关键科学问题分析

大脑神经系统虽然是由大量的神经元互联构成,但其复杂的功能主要是通过离子、分子、神经细胞、局域突触、长程

互联等多尺度结构的相互作用体现出来的^[152]。从第3节的分析中可以看出,如何在同一个理论框架下实现从微观到宏观的多尺度类脑表示框架,并从理论上证明其稳定收敛和具有容错性仍然是亟需解决的问题。从第3节与第4节的分析可以看出,尽管贝叶斯理论推理模型及深度神经网络特征提取的分类算法可以在一定程度上描述不确定信息的特征分类或感知决策机制,但在同一模型内,基于神经元脉冲信号的不确定信息编码、传递及多模态信息整合与知识泛化等技术仍需新的理论模型来支撑。因此,基于多尺度神经网络的多模态、不确定信息感知学习算法的研究仍存在一些问题,这些问题的分析与解决是构建新一代类脑计算体系及其能否有效解决实际应用难题的关键所在。

5.1 多模态、不确定信息与脉冲时序表示一致性问题

首先,类脑计算模型需要考虑多模态、不确定信息与脉冲时序表示一致性问题。视、听、触、嗅等信息感知都是通过相应感官细胞以脉冲信号传送到大脑神经系统来实现的,而网络的学习记忆不确定性感知信息也可以通过脉冲时序在忆阻器上实现。因此,为了提升类脑计算模型的性能,必须要考虑提升忆阻器 STDP 突触变化的神经元编码、学习和记忆融合功能。

若要解决多模态、不确定信息与脉冲时序表示一致性问题,首先要研究基于最大似然估计(Maximum Likelihood Estimate, MLE)^[153]的不确定信息贝叶斯模型与神经元感知信息的时空表示方法。大脑通过不同感官细胞来认知外部的信息,已被确认是通过神经元脉冲信号来实现的,但各模态的信息由于环境、噪声等不确定因素的影响,其工作机理也没有明确的结论。由于贝叶斯理论推理模型及深度神经网络特征提取与分类算法可以在一定程度上描述不确定信息的特征分类或感知原理,因此基于脉冲神经元突触的不确定信息编码技术有望用于实现感知信息的传输和多模态信息整合。为了避免环境或噪声的影响,可以考虑引入 MLE 来分析感知信息贝叶斯模型与神经元时空表示的一致性问题。

在统计力学和数学中,玻尔兹曼分布^[154](也称为吉布斯分布、吉布斯度量)是一种概率分布或概率测度模型,表明系统将处于某个状态的概率取决于该状态的能量和温度的函数。分布形式如下:

$$p_i = \frac{1}{Q} e^{-\frac{\epsilon_i}{kT}} = \frac{e^{-\frac{\epsilon_i}{kT}}}{\sum_{j=1}^M e^{-\frac{\epsilon_j}{kT}}} \quad (10)$$

其中, p 是系统中状态的概率, ϵ 是该状态的能量, k 是玻尔兹曼常数, T 是热力学温度。分布表明,能量较低的状态始终具有较高的被占据概率。玻尔兹曼机与 hopfield 网络通过定义能量函数来实现收敛^[155]。

$$E = -(\sum_{i < j} w_{ij} s_i s_j + \sum_i \theta_i s_i) \quad (11)$$

其中, s 是神经元状态, w_{ij} 是神经元之间的连接权重, θ 是偏差。上述能量函数来自 Ising 模型^[156], 该模型由离散变量组成, 这些离散变量表示原子“自旋”的磁偶极矩, 有两种状态(+1 或 -1)。考虑到脉冲神经元的输出状态为 0 或 1, 因此脉冲神经元输出为吉布斯采样形式的时空模式信息, 可体现脉冲神经网络感知信息输入的不确定性, 根据最大似然估计

算法(见式(12))可以在数学上证明基于概率采样的脉冲神经网络突触编码输出符合贝叶斯理论推理模型, 具备自主感知能力。

$$\hat{\theta} = \arg \max_{\theta \in \Theta} \hat{L}_n(\hat{\theta}; y) \quad (12)$$

其中, L_n 是最大似然估计值, 体现了感知信息的可信度。

同一物体或概念的信息通常可能以不同模态出现, 通过 MLE 方法仅能感知相同模态信息的似然性, 无法实现不同模态的信息整合。各种模态信息经不同感官细胞的认知, 也已被确认是通过将神经元突触的脉冲信号传递给各自的大脑皮层来实现感知的。动物对视、听、触、嗅等感知的过程体现了其大脑神经系统对不同模态信息的一致性处理过程。在时空模式变换下, 不同模态或尺度传输的信息均能体现出具有相同时序特征的信息, 这就为多模态信息整合和知识泛化提供了数学建模的可能性。

为了避免不同模态信息感知的局限性, 考虑引入 Skolem 函数^[157]来实现知识泛化, 并使用广义分配原理(Generalized Distributive Law, GDL)^[158]进行信息融合, 最终仍由神经元的概率采样脉冲序列信号输出。其中, 基于 Skolem 函数的知识泛化表示如下:

$$\forall x(R(g(x)) \vee \exists y R(x, y)) \leftrightarrow \exists f \forall x(R(g(x)) \vee R(x, f(x))) \quad (13)$$

而基于广义分配原理的信息融合法则可以表示为:

$$\alpha(a, b) \stackrel{\text{def}}{=} \sum_{c \in A} f(a, c, b) \cdot \sum_{d, e \in A} g(a, d, e) \quad (14)$$

其中, $f(a, c, b)$ 和 $g(a, d, e)$ 体现为不同模态的信息表示。自主感知的信息经脉冲神经元突触实现概率采样编码输出, 这样就可以建立起多模态信息整合与知识泛化计算模型。

可见, 引入 MLE 准则来说明脉冲神经元自主感知的信息与贝叶斯理论表示多模态、不确定信息特征的一致性, 并通过 GDL 原理及 Skolem 函数来表示多模态信息融合及不确定信息的可信度, 在一定程度上能够提升多种类脑学习算法通过忆阻器实现神经元突触的学习记忆功能, 有助于解决一致性表示的关键难点问题。

5.2 多尺度神经网络的构建及容错计算问题

基于生物多尺度特性的感知、学习和决策过程充分利用了局部特征与全局特征, 有望实现全局最优决策。在确定了多尺度神经网络模型的有效性后, 为了保证网络的鲁棒性, 基于忆阻器^[159]的类脑计算模型的动力学系统在外界干扰或突触故障等情况下应该是稳定收敛的。满足上述条件后, 新一代类脑计算模型既可实现目标函数的全局优化计算, 也能体现容错计算功能。因此, 多尺度神经网络的构建及容错计算问题是另一个急需解决的关键问题。

建立具备自主感知-学习-决策协同计算能力的类脑计算模型, 首先需要研究基于非线性传输的多尺度脉冲神经网络动力学模型。如图 8 所示, 神经元间突触互联的信息传输可以采用非线性函数来表示, 体现出了具有分维自相似的网络结构^[160], 因此可以建立一个能够体现非线性传输特性的动力学模型来表示多尺度脉冲神经网络。

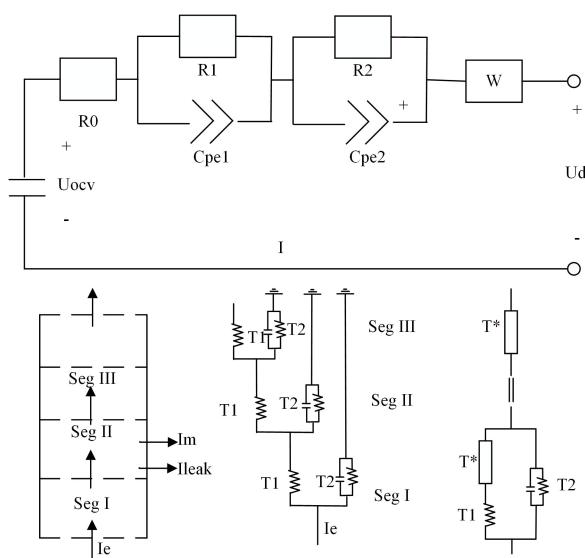


图 8 多尺度分维结构示意图

Fig. 8 Multi-scale fractal structure

在构建了多尺度脉冲神经网络系统后,还需要考虑其动力学过程中的收敛性与容错计算能力。多尺度脉冲神经网络的互联突触变化、脉冲信息的非线性传输与器件缺乏一致性的问题能否使网络系统保持收敛及稳定性也需要进行具体分析。更重要的是,系统工作时不可避免地会出现器件故障或

$$\begin{cases} \frac{dx_i(t)}{dt} = -d_i(t, r(t))x_i(t) + \sum_{j=1}^n a_{ij}(t, r(t))f_j(x_j(t)) + \sum_{j=1}^n b_{ij}(t, r(t))g_j(x_j(t-\tau_{ij}(t))) + I(t), & t \neq t_k, t > 0 \\ x_i(t) = p_{ik}(x_1(t^-), x_2(t^-), \dots, x_n(t^-)) + q_{ik}(x_1((t-\tau_{i1}(t))^-), x_2((t-\tau_{i2}(t))^-), \dots, x_n((t-\tau_{in}(t))^-)), & t = t_k, k \in N \end{cases} \quad (16)$$

综上所述,多尺度脉冲神经网络设计需要构建能描述具有分维特性的非线性传输电路,来实现脉冲神经元间忆阻器突触互联,使之具备模拟学习和记忆融合的自主感知-学习-决策协同计算功能。在此基础上,还需要考虑多尺度架构的稳定收敛及满足求解精度情况下的容错计算问题,以保证系统在外界干扰下能够正常工作,从而建立具备生物合理性和生物可解释性的多尺度脉冲神经网络计算模型。

结束语 多尺度神经网络的多模态、不确定信息、感知学习算法是保证类脑计算生物合理性与可解释性的关键,具有广泛的应用前景。在理论上将多模态、不确定信息纳入多尺度神经网络统一框架,有助于在同一框架下实现不同学习算法的集成,使其在多种应用场景下具备鲁棒性与实用性。本文主要探讨了这些模型的原理及相关应用,系统地评述了类脑计算模型的最新进展,指出了目前仍需解决的关键问题并给出了进一步探索的方向,旨在吸引更多研究者关注并深入类脑计算领域,以期该模型在理论和应用上取得突破性的进展。

参 考 文 献

- [1] SHANG J Y, YANG L H, HE K. Analyzing Latent Representation of Deep Neural Networks Based on Feature Visualization [J]. Computer Science, 2020, 47(5): 190-197.
- [2] KAMILARIS A, PRENAFETA-BOLDÚ F X. Deep learning in agriculture: A survey [J/OL]. Computers and Electronics in Agriculture, 2018, 147: 70-90. <https://www.sciencedirect.com/science/article/abs/pii/S0168169917308803>.
- [3] GOODFELLOW I, BENGIO Y, COURVILLE A, et al. Deep learning [M]. Cambridge: MIT press, 2016.
- [4] SCHMIDHUBER JÜRGEN. Deep Learning in Neural Networks: An Overview [J/OL]. Neural Networks, 2015, 61: 85-117. <https://www.sciencedirect.com/science/article/abs/pii/S0893608014002135>.
- [5] GUZE LIS C, KARAMAHMET S. Recurrent perceptron learning algorithm for completely stable cellular neural networks [C]// IEEE International Workshop on Cellular Neural Networks & Their Applications. IEEE, 2002.
- [6] PANM Y, SONG H H, ZHANG K H, et al. Learning Global Guided Progressive Feature Aggregation Lightweight Network for Salient Object Detection [J]. Computer Science, 2021, 48(6): 103-109.
- [7] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2015: 1-9.
- [8] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016: 770-778.
- [9] ZHANG P, WANG X Q, XIAO Y, et al. Real-time Binocular Depth Estimation Algorithm Based on Semantic Edge Drive [J]. Computer Science, 2021, 48(9): 216-222.
- [10] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look

外界干扰问题,因此,在保证脉冲神经网络动力学收敛及实现非线性问题全局最优求解的同时,还需要从数学的角度建模分析在满足求解精度的情况下多尺度脉冲神经网络的容错计算能力。

大脑的决策过程通常可归结为非线性规划问题的求解过程。只要能通过式(15)所示的目标函数及若干约束条件来表示决策问题,就可以利用脉冲神经网络动力学模型求得其最优解:

$$\begin{aligned} & \min f(x) \\ \text{s. t. } & g_i(x) = 0, i = 1, 2, \dots, b \\ & h_j(x) \leq 0, j = 1, 2, \dots, c \\ & x = (x_1, x_2, \dots, x_n) \in D \end{aligned} \quad (15)$$

其中, $f(x)$ 为决策任务的目标函数, x 为决策变量即可行解, D 为可行解的集合, $g_i(x)$ 为等式约束, $h_j(x)$ 为不等式约束。

多尺度脉冲神经网络的动力学模型可以表示一个带有时间延迟、随机切换的非自治系统网络模型,如式(16)所示。式(16)中, $t = t_k$ 和 $t \neq t_k$ 分别表示神经元处于激活和非激活状态的状态方程, p_{ik} 和 q_{ik} 则分别体现发出采样脉冲的情况。对于非线性的激活函数 $f_j(x_j(t))$ 和 $g_j(x_j(t))$, 可以证明该脉冲神经网络系统会稳定收敛在 a_{ij} 和 b_{ij} 的变化范围内。可见,多尺度脉冲神经网络系统在满足收敛精度要求的前提下具有一定的容错计算能力。

- once: Unified, real-time object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016:779-788.
- [11] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot-multibox detector[C]// European Conference on Computer Vision. Springer International Publishing, 2016:21-37.
- [12] SUN S Z, GUO B H, YANG X B. Embedding ConsensusAutoencoder for Cross-modal Semantic Analysis [J]. Computer Science, 2021, 48(7): 93-98.
- [13] TONG X, W B, WANG R Z, et al. Survey on Adversarial Sample of Deep Learning Towards Natural Language Processing[J]. Computer Science, 2021, 48(1): 258-267.
- [14] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016:770-778.
- [15] SZE V, CHEN Y H, YANG T J, et al. Efficient Processing of Deep Neural Networks: A Tutorial and Survey[J]. Proceedings of the IEEE, 2017, 105(12): 2295-2392.
- [16] MEAD C. Neuromorphic electronic systems[J]. Proceedings of the IEEE, 1990, 78(10): 1629-1636.
- [17] MEMMESHEIMER R M, TIMME M. Designing the Dynamics of Spiking Neural Networks[J]. Physical Review Letters, 2006, 97(18): 188101-188101.
- [18] LI P Q, YU G J, HUA X, et al. PEST: Energy-Efficient NEST Brain-Like Simulator Implemented by PYNN Cluster[J]. Journal of Frontiers of Computer Science and Technology, 2021, 15(11): 2127-2141.
- [19] KOO M, SRINIVASAN G, SHIM Y, et al. SBSNN: Stochastic-Bits Enabled Binary Spiking Neural Network with On-Chip Learning for Energy Efficient Neuromorphic Computing at the Edge[J]. IEEE Transactions on Circuits and Systems I: Regular Papers, 2020, 67(8): 2546-2555.
- [20] HUANG Z, LUO H, GUO D. Application of Locally Connected Spiking Neural Network in Image Processing[C]// 2019 IEEE 13th International Conference on Anti-counterfeiting, Security, and Identification(ASID). IEEE, 2019: 108-111.
- [21] ESSER S K, MEROLLA P, ARTHUR J V, et al. Convolutional networks for fast, energy-efficient neuromorphic computing[J]. Proceedings of the National Academy of Sciences, 2016, 113(41): 11441-11446.
- [22] YEON H, LIN P, CHOI C, et al. Alloying conducting channels for reliable neuromorphic computing [J]. Nature Nanotechnology, 2020, 15(7): 574-579.
- [23] LI X, TANG J, ZHANG Q, et al. Power-efficient neural network with artificial dendrites [J]. Nature Nanotechnology, 2020, 15(9): 776-782.
- [24] AT A, MG B, SRK C, et al. Deep learning in spiking neural networks[J]. Neural Networks, 2019, 111: 47-63.
- [25] BUZSÁKI G, COSTAS A, KOCH C, et al. The origin of extracellular fields and currents—EEG, ECeG, LFP and spikes[J]. Nature Reviews Neuroscience, 2012, 13(6): 407-420.
- [26] NAOYUKI S, RIKI M, AKIHIRO S, et al. Frequency-Dependent Cortical Interactions during Semantic Processing: An Electrocorticogram Cross-spectrum Analysis Using a Semantic Space Model[J]. Cerebral Cortex, 2021, 31(9): 4329-4339.
- [27] SUN S Z, GUO B H, YANG X B. Embedding Consensus Autoencoder for Cross-modal Semantic Analysis[J]. Computer Science, 2021, 48(7): 93-98.
- [28] LI Y, CHEN Y, WANG N, et al. Scale-aware trident networks for object detection[C]// Proceedings of the IEEE International Conference on Computer Vision. 2019: 6054-6063.
- [29] HARDCASTLE K, MAHESWARANATHAN N, GANGULI S, et al. A multiplexed, heterogeneous, and adaptive code for navigation in medial entorhinal cortex[J]. Neuron, 2017, 94(2): 375-387.
- [30] TONONI G, EDELMAN S. A Measure for Brain Complexity: Relating Functional Segregation and Integration in the Nervous System[J]. Proceedings of the National Academy of Sciences of the United States of America, 1994, 91(11): 5033-5037.
- [31] WARREN S, WALTER H. A logical calculus of the ideas imminent in nervous activity[J]. The Bulletin of Mathematical Biophysics, 1943, 5(4): 115-133.
- [32] AHMAD Z, NOOR R, ZHANG J. Multiple neural networks modeling techniques in process control: a review[J]. Asia-pacific Journal of Chemical Engineering, 2010, 4(4): 403-419.
- [33] KOHONEN T. The self-organizing map[J]. Proceedings of the IEEE, 1990, 78(9): 1464-1480.
- [34] HOPFIELD J. Neural networks and physical systems with emergent collective computational abilities[J]. Proceedings of the National Academy of Sciences, 1982, 79(8): 2554-2558.
- [35] PHANSALKAR V, SAstry P. Analysis of the back-propagation algorithm with momentum[J]. IEEE Transactions on Neural Networks, 1994, 5(3): 505-506.
- [36] HEBB D O. The organization of behavior: a neuropsychological theory[M]. Psychology Press, 1949.
- [37] DECO G, JIRSA V K, ROBINSON P A, et al. The Dynamic Brain: From Spiking Neurons to Neural Masses and Cortical Fields[J]. PLOS Computational Biology, 2008, 4(8): e1000092.
- [38] DAS A, WU Y, HUYNH K, et al. Mapping of local and global synapses on spiking neuromorphic hardware[C]// Design, Automation & Test in Europe Conference & Exhibition. IEEE, 2018: 1217-1222.
- [39] HAWRYLYCZ M J, LEIN E S, GUILLOZET-BONGAARTS A L, et al. An anatomically comprehensive atlas of the adult human brain transcriptome[J]. Nature, 2012, 489(7416): 391-399.
- [40] KOCH C, LAURENT G. Complexity and the nervous system [J]. Science, 1999, 284(5411): 96-98.
- [41] KOLLING N, O'REILLY J X. State-change decisions and dorsomedial prefrontal cortex: The importance of time[J/OL]. Current Opinion in Behavioral Sciences, 2018, 22: 152-160. <https://www.science-direct.com/science/article/pii/S2352154618300585>.
- [42] MURRAY J D, BERNACCHIA A, FREEDMAN D J, et al. A hierarchy of intrinsic timescales across primate cortex[J]. Nature Neuroscience, 2014, 17(12): 1661-1663.
- [43] HIKOSAKA O, TAKIKAWA Y, KAWAGOE R. Role of the basal ganglia in the control of purposive saccadic eye movements [J]. Physiological Reviews, 2000, 80(3): 953-978.
- [44] HODGKIN A L, HUXLEY A F. A quantitative description of

- membrane current and its application to conduction and excitation in nerve[J]. *The Journal of Physiology*, 1952, 117(4): 500.
- [45] IZHIKEVICH E M. Solving the Distal Reward Problem through Linkage of STDP and Dopamine Signaling [J]. *Bmc Neuroscience*, 2007, 8(10): 1-2.
- [46] MENG M, YANG X, XIAO S, et al. Spiking Inception Module for Multi-layer Unsupervised Spiking Neural Networks[C] // 2020 International Joint Conference on Neural Networks (IJCNN). IEEE, 2020; 1-8.
- [47] MENG M, YANG X, BI L, et al. High-parallelism Inception-like Spiking Neural Networks for Unsupervised Feature Learning [J]. arXiv: 2001.01680, 2019.
- [48] SAUNDERS D J, PATEL D, HAZAN H, et al. Locally connected spiking neural networks for unsupervised feature learning [J/OL]. *Neural Networks*, 2019, 119: 332-340. <https://www.sciencedirect.com/science/article/abs/pii/S0893608019302333>.
- [49] DIEHL P U, COOK M. Unsupervised learning of digit recognition using spike-timing-dependent plasticity[J/OL]. *Frontiers in computational neuroscience*, 2015, 9: 99. <https://www.frontiersin.org/articles/10.3389/fncom.2015.00099/full>.
- [50] BEIKMOHAMMADI A, ZAHABI N. A Hierarchical Method for Kannada-MNIST Classification Based on Convolutional Neural Networks[C] // 2021 26th International Computer Conference, Computer Society of Iran(CSICC). IEEE, 2021; 1-6.
- [51] PRABHU V U. Kannada-MNIST: A new handwritten digits dataset for the Kannada language[J]. arXiv: 1908.01242, 2019.
- [52] CARRILLO S, HARKIN J, MCDAID L J, et al. Scalable hierarchical network-on-chip architecture for spiking neural network hardware implementations [J]. *IEEE Transactions on Parallel and Distributed Systems*, 2012, 24(12): 2451-2461.
- [53] NAWROCKI R A, VOYLES R M, SHAHEEN S E. A mini review of neuromorphic architectures and implementations [J]. *IEEE Transactions on Electron Devices*, 2016, 63(10): 3819-3829.
- [54] AKOPYAN F, SAWADA J, CASSIDY A, et al. Truenorth: Design and tool flow of a 65 mw 1 million neuron programmable neurosynaptic chip [J]. *IEEE Transactions on Computer-aided Design of Integrated Circuits and Systems*, 2015, 34(10): 1537-1557.
- [55] DAVIES M, SRINIVASA N, LIN T H, et al. Loihi: A neuromorphic manycore processor with on-chip learning[J]. *IEEE Micro*, 2018, 38(1): 82-99.
- [56] SPILIOТИS K G, SIETTOS C I. Multiscale computations on neural networks: from the individual neuron interactions to the macroscopic-level analysis[J]. *International Journal of Bifurcation and Chaos*, 2010, 20(1): 121-134.
- [57] KNOPFEL T, GALLERO-SALAS Y, SONG C. Genetically encoded voltage indicators for large scale cortical imaging come of age[J]. *Current Opinion in Chemical Biology*, 2015, 100(27): 75-83.
- [58] ROWEIS S, GHAHRAMANI Z. A Unifying Review of Linear Gaussian Models[J]. *Neural Computation*, 2014, 11(2): 305-345.
- [59] HSIEH H L, WONG Y T, PESARAN B, et al. Multiscale modeling and decoding algorithms for spike-field activity[J]. *Journal of Neural Engineering*, 2018, 16(1): 16-34.
- [60] WANG C, SHANECHI M M. Estimating multiscale direct causality graphs in neural spike-field networks[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2019, 27(5): 857-866.
- [61] ABBASPOURAZAD H, HSIEH H L, SHANECHI M M. A multiscale dynamical modeling and identification framework for spike-field activity[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2019, 27(6): 1128-1138.
- [62] ROY K, JAISWAL A, PANDA P. Towards spike-based machine intelligence with neuromorphic computing [J]. *Nature*, 2019, 575(7784): 607-617.
- [63] PEI J, DENG L, SONG S, et al. Towards artificial general intelligence with hybrid Tianjic chip architecture[J]. *Nature*, 2019, 572(7767): 106-111.
- [64] SHAZEER N, MIRHOSEINI A, MAZIARZ K, et al. Outrageously large neural networks: The sparsely-gated mixture-of-experts layer[J]. arXiv: 1701.06538, 2017.
- [65] SHE X, LONG Y, MUKHOPADHYAY S. Improving robustness of reram-based spiking neural network accelerator with stochastic spike-timing-dependent-plasticity [C] // 2019 International Joint Conference on Neural Networks (IJCNN). IEEE, 2019; 1-8.
- [66] GILBERT C D, LI W. Top-down influences on visual processing [J]. *Nature Reviews Neuroscience*, 2013, 14(5): 350-363.
- [67] JAHFARI S, RIDDERINKHOF K R, SCHOLTE H S. Spatial frequency information modulates response inhibition and decision-making processes[J/OL]. *PLoS One*, 2013, 8(10): e76467. <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0076467>.
- [68] AMANO K, GODA N, NISHIDA S, et al. Estimation of the timing of human visual perception from magnetoencephalography [J]. *Journal of Neuroscience*, 2006, 26(15): 3981-3991.
- [69] HEEKEREN H R, MARRETT S, UNGERLEIDER L G. The neural systems that mediate human perceptual decision making. [J]. *Nature Reviews Neuroscience*, 2008, 9(6): 467-479.
- [70] GOLD J I, SHADLEN M N. The neural basis of decision making. [J]. *Annual Review of Neuroscience*, 2007, 30(1): 535-574.
- [71] XU R, XIONG C, CHEN W, et al. Jointly Modeling Deep Video and Compositional Text to Bridge Vision and Language in a Unified Framework[C] // AAAI. 2015.
- [72] MROUEH Y, MARCHERET E, GOEL V. Deep multimodal learning for audio-visual speech recognition[C] // 2015 IEEE International Conference on Acoustics, Speech and Signal Processing(ICASSP). IEEE, 2015: 2130-2134.
- [73] WANG D, CUI P, OU M, et al. Deep multimodal hashing with orthogonal regularization [C] // Twenty-Fourth International Joint Conference on Artificial Intelligence. 2015: 999-1002.
- [74] WESTON J, BENGIO S, USUNIER N. Large scale image annotation: learningtorank with joint word-image embeddings [J]. *Machine Learning*, 2010, 81(1): 21-35.
- [75] FROME A, CORRADO G S, SHLENS J, et al. Devise: A deep

- visual-semantic embedding model[C]// Advances in Neural Information Processing Systems. 2013;2121-2129.
- [76] KIROS R, SALAKHUTDINOV R, ZEMEL R S. Unifying visual-semantic embeddings with multimodal neural language models[J]. arXiv, 1411.2539, 2014.
- [77] PAN Y, MEI T, YAO T, et al. Jointly modeling embedding and translation to bridge video and language[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2016;4594-4602.
- [78] RESULAJ A, KIANI R, WOLPERT D M, et al. Changes of mind in decision-making[J]. Nature, 2009, 461(7261): 263-266.
- [79] TOSONI A, GALATI G, ROMANI G L, et al. Sensory-motor mechanisms in human parietal cortex underlie arbitrary visual decisions[J]. Nature Neuroscience, 2008, 11(12): 1446-1453.
- [80] BURBECK S L, LUCE R D. Evidence from auditory simple reaction times for both change and level detectors[J]. Perception & Psychophysics, 1982, 32(2): 117-133.
- [81] PALMER J, HUK A C, SHADLEN M N. The effect of stimulus strength on the speed and accuracy of a perceptual decision[J]. Journal of Vision, 2005, 5(5): 1-1.
- [82] YUHAS B P, GOLDSTEIN M H, SEJNOWSKI T J. Integration of acoustic and visual speech signals using neural networks[J]. IEEE Communications Magazine, 1989, 27(11): 65-71.
- [83] HODGKIN A L, HUXLEY A F. Propagation of electrical signals along giant nervefibres[J]. Proceedings of the Royal Society of London. Series B-Biological Sciences, 1952, 140 (899): 177-183.
- [84] SHIN H C, ROTH H R, GAO M, et al. Deep convolutional neural networks for computer-aided detection: CNN architectures, dataset characteristics and transfer learning[J]. IEEE Transactions on Medical Imaging, 2016, 35(5): 1285-1298.
- [85] LI C N, SHAO Y H, YIN W, et al. Robust and sparse linear discriminant analysis via an alternating direction method of multipliers[J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 31(3): 915-926.
- [86] HU R, CHANG S, WANG H, et al. Efficient multispike learning for spiking neural networks using probability-modulated timing method[J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 30(7): 1984-1997.
- [87] LIU Q, PAN G, RUAN H, et al. Unsupervised AER Object Recognition Based on Multiscale Spatio-Temporal Features and Spiking Neurons[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(12): 5300-5311.
- [88] 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.
- [89] TAVANAEI A, MAIDA A S. A spiking network that learns to extract spike signatures from speech signals[J]. Neurocomputing, 2017, 100(240): 191-199.
- [90] TAVANAEI A, MAIDA A S. Training a hidden Markov model with a Bayesian spiking neural network[J]. Journal of Signal Processing Systems, 2018, 90(2): 211-220.
- [91] TAVANAEI A, MAIDA A. Bio-inspired multi-layer spiking neural network extracts discriminative features from speech signals[C]// International Conference on Neural Information Processing. Cham: Springer, 2017: 899-908.
- [92] RATHI N, ROY K. Stdp-based unsupervised multimodal learning with cross-modal processing in spiking neural network[J]. IEEE Transactions on Emerging Topics in Computational Intelligence, 2018, 5(1): 143-153.
- [93] ZHANG M, LUO X, CHEN Y, et al. An efficient threshold-driven aggregate-label learning algorithm for multimodal information processing[J]. IEEE Journal of Selected Topics in Signal Processing, 2020, 14(3): 592-602.
- [94] NGIAM J, KHOSLA A, KIM M, et al. Multimodal deep learning [C]// The 28th International Conference on Machine Learning. ICML, 2011.
- [95] GURBAN M, THIRAN J P, DRUGMAN T, et al. Dynamic modality weighting for multi-streamhmms in audio-visual speech recognition[C] // Proceedings of the 10th International Conference on Multimodal Interfaces. 2008; 237-240.
- [96] EVANGELOPOULOS G, ZLATINTSI A, POTAMIANOS A, et al. Multimodal saliency and fusion for movie summarization based on aural, visual, and textual attention[J]. IEEE Transactions on Multimedia, 2013, 15(7): 1553-1568.
- [97] GUTIG R. Spiking neurons can discover predictive features by aggregate-label learning [J/OL]. Science, 2016, 351 (6277): aab4113. <https://www.science.org/doi/abs/10.1126/science.aab4113>.
- [98] ZHANG M, WU J, CHUA Y, et al. Mpd-al: an efficient membrane potential driven aggregate-label learning algorithm for spiking neurons[C] // Proceedings of the AAAI Conference on Artificial Intelligence. 2019, 33: 1327-1334.
- [99] XIAO R, YU Q, YAN R, et al. Fast and Accurate Classification with a Multi-Spike Learning Algorithm for Spiking Neurons [C] // IJCAI. 2019; 1445-1451.
- [100] GU P, XIAO R, PAN G, et al. STCA: Spatio-Temporal Credit Assignment with Delayed Feedback in Deep Spiking Neural Networks[C] // IJCAI. 2019; 1366-1372.
- [101] YU Q, LI H, TAN K C. Spike timing or rate? neurons learn to make decisions for both through threshold-driven plasticity[J]. IEEE Transactions on Cybernetics, 2018, 49(6): 2178-2189.
- [102] ZHANG M, LUO X, CHEN Y, et al. An efficient threshold-driven aggregate-label learning algorithm for multimodal information processing[J]. IEEE Journal of Selected Topics in Signal Processing, 2020, 14(3): 592-602.
- [103] RATHI N, ROY K. Stdp-based unsupervised multimodal learning with cross-modal processing in spiking neural network[J]. IEEE Transactions on Emerging Topics in Computational Intelligence, 2018, 5(1): 143-153.
- [104] DENG F, ZHU D, LV J, et al. FMRI Signal Analysis Using Empirical Mean Curve Decomposition[J]. IEEE Transactions on Biomedical Engineering, 2013, 60(1): 42-54.
- [105] CHIANG C Y, CHANG N F, CHEN T C, et al. Seizure prediction based on classification of EEG synchronization patterns with on-line retraining and post-processing scheme[C] // 2011 Annual International Conference of the IEEE Engineering in

- Medicine and Biology Society. IEEE, 2011;7564-7569.
- [106] AWATE S, SUYASH P, ZHANG H, et al. A Fuzzy, Nonparametric Segmentation Framework for DTI and MRI Analysis: With Applications to DTI-Tract Extraction[J]. IEEE Transactions on Medical Imaging, 2007, 26(11):1525-1536.
- [107] SUI J, ADALI T, YU Q, et al. A review of multivariate methods for multimodal fusion of brain imaging data[J]. Journal of neuroscience methods, 2012, 204(1):68-81.
- [108] GREICIUS M D, SUPEKAR K, MENON V, et al. Resting-state functional connectivity reflects structural connectivity in the default mode network[J]. Cerebral cortex, 2009, 19(1):72-78.
- [109] PATEL M J, ANDREESCU C, PRICE J C, et al. Machine learning approaches for integrating clinical and imaging features in late-life depression classification and response prediction[J]. International Journal of Geriatric Psychiatry, 2015, 30(10):1056-1067.
- [110] SENGUPTA N, MCNABB C B, KASABOV N, et al. Integrating space, time, and orientation in spiking neural networks: A case study on multimodal brain data modeling[J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(11):5249-5263.
- [111] KASABOV N K. NeuCube: A spiking neural network architecture for mapping, learning and understanding of spatio-temporal brain data[J/OL]. Neural Networks, 2014, 52:62-76. <https://www.sciencedirect.com/science/article/pii/S0893608014000070>.
- [112] YANG Y L, BI Z Z. Network Anomaly Detection Based on Deep Learning[J]. Computer Science, 2021, 48(11A):540-546.
- [113] QI B L, ZHONG K H, CHEN Y W. Semi-supervised Surgical Video Workflow Recognition Based on Convolution Neural Network[J]. Computer Science, 2020, 47(6A):172-175.
- [114] DEVLIN J, CHANG M W, LEE K, et al. Bert: Pre-training of deep bidirectional transformers for language understanding[J]. arXiv:1810.04805, 2018.
- [115] PROSPERI M, MIN J S, BIAN J, et al. Big data hurdles in precision medicine and precision public health[J]. BMC Medical Informatics and Decision Making, 2018, 18(1):1-15.
- [116] ZHAO C, HE S, LI L, et al. Convergence Stability of Spiking Neural Networks with Stochastic Fluctuations[C]// 2019 IEEE 13th International Conference on Anticounterfeiting, Security, and Identification(ASID). IEEE, 2019;163-167.
- [117] GAL Y, GHAHRAMANI Z. Dropout as a bayesian approximation: Representing model uncertainty in deep learning[C]// International Conference on Machine Learning. PMLR, 2016; 1050-1059.
- [118] KENDALL A, GAL Y. What uncertainties do we need in bayesian deep learning for computer vision? [C]// Advances in Neural Information Processing Systems. 2017;5574-5584.
- [119] HELMREICH R. Applied social psychology: The unfulfilled promise[J]. Personality and Social Psychology Bulletin, 1975, 1(4):548-560.
- [120] KULLBACK S. Information theory and statistics[M]. Courier Corporation, 1997.
- [121] NUZZO R. Scientific method: statistical errors[J]. Nature News, 2014, 506(7487):150.
- [122] CHAI R, TRAN Y, NAIK G R, et al. Classification of EEG based-mental fatigue using principal component analysis and Bayesian neural network[C]// 2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society(EMBC). IEEE, 2016;4654-4657.
- [123] JORDAN M I, GHAHRAMANI Z, JAAKKOLA T S, et al. An introduction to variational methods for graphical models[J]. Machine Learning, 1999, 37(2):183-233.
- [124] HINTON G E, VAN CAMP D. Keeping the neural networks simple by minimizing the description length of the weights[C]// Proceedings of the Sixth Annual Conference on Computational Learning Theory. 1993;5-13.
- [125] BARBER D, BISHOP C M. Ensemble learning in Bayesian neural networks [J]. Nato ASI Series F Computer and Systems Sciences, 1998, 168: 215-238. <http://research.microsoft.com/apps/pub-s/default.aspx?id=67172>.
- [126] GRAVES A. Practical variational inference for neural networks [C]// Proceedings of the 24th International Conference on Neural Information Processing Systems. 2011;2348-2356.
- [127] OPPER M, ARCHAMBEAU C. The variational Gaussian approximation revisited[J]. Neural Computation, 2009, 21(3): 786-792.
- [128] HERNÁNDEZ-LOBATO J M, ADAMS R. Probabilistic backpropagation for scalable learning of bayesian neural networks [C]// International Conference on Machine Learning. 2015; 1861-1869.
- [129] GRAVES A. Practical variational inference for neural networks [C]// Advances in Neural Information Processing Systems. 2011;2348-2356.
- [130] FUNAMIZU A, KUHN B, DOYA K. Neural substrate of dynamic Bayesian inference in the cerebral cortex[J]. Nature Neuroscience, 2016, 19(12):1682-1689.
- [131] ERNST M O, BANKS M S. Humans integrate visual and haptic information in a statistically optimal fashion[J]. Nature, 2002, 415(6870):429-433.
- [132] CHATER N, MANNING C D. Probabilistic models of language processing and acquisition[J]. Trends in Cognitive Sciences, 2006, 10(7):335-344.
- [133] YU Z, CHEN F, DONG J, et al. Sampling-based causal inference in cue combination and its neural implementation[J/OL]. Neurocomputing, 2016, 175: 155-165. <https://www.sciencedirect.com/science/article/abs/pii/S0925231215015040>.
- [134] BECK J M, MA W J, KIANI R, et al. Probabilistic population codes for Bayesian decision making[J]. Neuron, 2008, 60(6): 1142-1152.
- [135] LEE T S, MUMFORD D. Hierarchical Bayesian inference in the visual cortex[J]. JOSA A, 2003, 20(7):1434-1448.
- [136] DAN Y, POO M. Spike timing-dependent plasticity of neural circuits[J]. Neuron, 2004, 44(1):23-30.
- [137] FELDMAN D E. The spike-timing dependence of plasticity[J]. Neuron, 2012, 75(4):556-571.
- [138] NESSLER B, PFEIFFER M, BUESING L, et al. Bayesian computation emerges in generic cortical microcircuits through spike-

- timing-dependent plasticity [J]. PLoS Comput. Biol., 2013, 9(4):1-30.
- [139] GUO S, YU Z, DENG F, et al. Hierarchical bayesian inference and learning in spiking neural networks[J]. IEEE Transactions on Cybernetics, 2017, 49(1):133-145.
- [140] RAO R P N. Bayesian computation in recurrent neural circuits [J]. Neural Computation, 2004, 16(1):1-38.
- [141] BUESING L, BILL J, NESSLER B, et al. Neural dynamics as sampling:a model for stochastic computation in recurrent networks of spiking neurons [J]. PLoS Comput. Biol., 2011, 7(11):1-25.
- [142] PECEVSKI D, BUESING L, MAASS W. Probabilistic inference in general graphical models through sampling in stochastic networks of spiking neurons [J]. PLoS Comput. Biol., 2011, 7(12):1-25.
- [143] POUGET A, DAYAN P, ZEMEL R S. Inference and computation with population codes[J]. Annual Review of Neuroscience, 2003, 26(1):381-410.
- [144] HUANG Y, RAO R P N. Bayesian inference and online learning in poisson neuronal networks [J]. Neural Computation, 2016, 28(8):1503-1526.
- [145] KIM S, PARK S, NA B, et al. Spiking-YOLO:spiking neural network for energy-efficient object detection[C]// Proceedings of the AAAI Conference on Artificial Intelligence. 2020;11270-11277.
- [146] SENGUPTA A, YE Y, WANG R, et al. Going deeper in spiking neural networks: VGG and residual architectures[J/OL]. Frontiers in Neuroscience, 2019, 13: 95. <https://www.frontiersin.org/articles/10.3389/fnins.2019.00095/full>.
- [147] KIM S, PARK S, NA B, et al. Towards fast and accurate object detection in bio-inspired spiking neural networks through Bayesian optimization [J/OL]. IEEE Access, 2020, 9: 2633-2643. <https://ieeexplore.ieee.org/abstract/document/9306772>.
- [148] HAN B, ROY K. Deep Spiking Neural Network: Energy Efficiency Through Time based Coding[C]// European Conference on Computer Vision. Cham: Springer, 2020:388-404.
- [149] HAN B, SRINIVASAN G, ROY K. Rmp-snn:Residual membrane potential neuron for enabling deeper high-accuracy and low-latency spiking neural network[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2020;13558-13567.
- [150] JANG H, SKATCHKOVSKY N, SIMEONE O. BiSNN: Training Spiking Neural Networks with Binary Weights via Bayesian Learning[J]. arXiv, 2012, 08300, 2020.
- [151] DU C, DU C, HUANG L, et al. Reconstructing perceived images from human brain activities with Bayesian deepmultiview learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 30(8):2310-2323.
- [152] ROY K, JAISWAL A, PANDA P. Towards spike-based machine intelligence with neuromorphic computing [J]. Nature, 2019, 575(7784):607-617.
- [153] GAUVAIN J L, LEE C H. Maximum a posteriori estimation for multivariate Gaussian mixture observations of Markov chains [J]. IEEE Transactions on Speech and Audio Processing, 1994, 2(2):291-298.
- [154] MEYER S. Literatur-Berichte: Elementary principles in statistical mechanics[J]. Monatsh. Math. Phys., 1903, 14(1):A55-A59.
- [155] ZOU D X. Global Attractivity in Delayed Hopfield Neural Network Models[J]. Siam Journal on Applied Mathematics, 1998, 58(6):1878-1890.
- [156] GLAUBER R J. Time dependent Statistics of the Ising Model [J]. Journal of Mathematical Physics, 1963, 4(2):294-307.
- [157] JOHN A K, SHAH S, CHAKRABORTY S, et al. Skolem functions for factored formulas[C]// 2015 Formal Methods in Computer-Aided Design(FMCAD). IEEE, 2015:73-80.
- [158] AJI S M, MCELIECE R J. The generalized distributive law[J]. IEEE Transactions on Information Theory, 2000, 46(2):325-343.
- [159] BHARATHI M, WANG Z, GUO B, et al. Memristors: Understanding, utilization and upgradation for neuromorphic computing[J]. NANO, 2020, 15(11):2030005.
- [160] YI G S, WANG J, WEI X L, et al. Exploring how extracellular electric field modulates neuron activity through dynamical analysis of a two-compartment neuron model[J]. Journal of Computational Neuroscience, 2014, 36(3):383-399.



HUANG Zenan, born in 1993, Ph.D. His main research interests include artificial intelligence and neural network.



GUO Donghui, born in 1967, Ph.D, professor. His main research interests include computer networking, artificial intelligence, optimization computing, IC design, nano device, and BioMEMS.

(责任编辑:喻藜)