

脉冲神经网络研究现状及展望

张铁林^{1),2)} 徐波^{1),2),3)}

¹⁾ (中国科学院自动化研究所 北京 100190)

²⁾ (中国科学院大学 北京 100049)

³⁾ (中国科学院脑科学与智能技术卓越创新中心 上海 200031)

摘要 脉冲神经网络 (Spiking Neural Network, SNN) 包含具有时序动力学特性的神经元节点、稳态-可塑性平衡的突触结构、功能特异性的网络环路等, 高度借鉴了生物启发的局部非监督 (如脉冲时序依赖可塑性、短时突触可塑性、局部稳态调节等)、全局弱监督 (如多巴胺奖赏学习、基于能量的函数优化等) 的生物优化方法, 因此具有强大的时空信息表征、异步事件信息处理、网络自组织学习等能力。SNN 的研究属于交叉学科, 将深入融合脑科学和计算机科学, 因此对其研究也可以主要分为两大类: 一类是以更好的理解生物系统为最终目的; 另一类是以追求卓越计算性能为优化目标。本文首先对当前这两大类 SNN 的研究进展、研究特点等进行分析, 重点介绍基于 Spike 的多类异步信息编码、基于 Motif 分布的多亚型复杂网络结构、多层时钟网络自组织计算、神经形态计算芯片的软硬结合等。同时, 介绍一种融合生物多尺度、多类型神经可塑性的高效 SNN 优化策略, 使得 SNN 中的信度分配可以从宏观尺度有效覆盖到微观尺度, 如全部的网络输出、网络隐层状态、局部的各个神经节点等, 并部分解答生物系统是如何通过局部参数的调优而实现全局网络优化的问题。这将不仅为现有有人工智能模型提高其认知能力指明一种可能的生物类优化方向, 还为反向促进生命科学中生物神经网络的可塑性研究新发现提供启发。本文认为, 脉冲神经网络的发展目标不是构建人工神经网络的生物版本替代品, 而是通过突破生物启发的多尺度可塑性优化理论, 去粗取精, 最终实现具有生物认知计算特色的新一代高效脉冲神经网络模型, 使其有望获得更快的学习速度、更小的能量消耗、更强的适应性和更好的可解释性等。

关键词 脉冲神经网络; 类脑智能; 多尺度神经可塑性; 认知计算

中图法分类号 ***** DOI号 ***

Research Advances and Perspectives on Spiking Neural Networks

ZHANG Tie-Lin^{1), 2)}, XU Bo^{1), 2), 3)}

¹⁾ (Institute of Automation, Chinese Academy of Sciences, Beijing 100190, China)

²⁾ (University of Chinese Academy of Sciences, Beijing 100049, China)

³⁾ (Center for Excellence in Brain Science and Intelligence Technology, Chinese Academy of Sciences, Shanghai 200031, China)

Abstract Spiking Neural Network (SNN) contain neurons with sequential dynamics, synapses with plastic stability, and circuits with specific cognitive functions. SNN is biologically-plausible and can be tuned by integrating local-scale unsupervised learning rules (e.g., Spike Timing-Dependent Plasticity, Short-Term

本课题得到国家自然科学基金(No. 61806195), 中国科学院战略性先导科技专项(No. XDBS01070000), 北京市科技重大专项(No. Z181100001518006)的资助。Supported by the National Natural Science Foundation of China (No. 61806195), the Strategic Priority Research Program of the Chinese Academy of Sciences (No. XDBS01070000) and the Beijing Brain Science Project (No. Z181100001518006). 张铁林, 男, 1988年生, 博士, 副研究员, CCF会员 (A2626M), 研究领域: 类脑智能, 脉冲神经网络优化, 类脑机器人, E-mail: tielin.zhang@ia.ac.cn, 联系电话: 15901091404。徐波 (通信作者), 男, 中国科学院自动化研究所, 研究员, 中科院脑科学与智能技术卓越创新中心副主任, 长期从事人工智能研究, 主要研究领域包括: 类脑智能, 类脑认知计算模型, 自然语言处理与理解, 类脑机器人, E-mail: xubo@ia.ac.cn。

Plasticity, local equilibrium adjustment of membrane potential) and global-scale weak-supervised learning rules (e.g., dopamine-based reward learning, energy-based learning). Hence, it is powerful on spatially-temporal information representation, asynchronous processing of event-based information, and self-organized learning with dynamic topologies. SNN belongs to cross-discipline research areas of brain science and computer science. Hence, the research on it can be divided into two main types. One type is designed to understand better the biological system, where detailed biologically-realistic neural models are used without further consideration of computational efficiency. The other type is constructed to pursue superior computational performance, where only limited features of SNN are retained, and some efficient but not biologically-plausible tuning methods are still used, such as different versions of backpropagation. A detailed analysis of the research advances and model characteristics of these two types of efforts is given, including the following aspects: Firstly, the multi-type information encoding at neuronal scales is given, with event-based signal processing characteristics; Secondly, the multi-scale sparseness of network structures is defined with different subtypes of network motifs; Thirdly, the self-organized computation is shown at multi-scale clocks, from micro-scale at neurons (or synapses) to macro-scale at circuits; Fourthly, some vital functional characteristics of SNN are introduced, including energy-efficient computation (with spikes and learning rules) and robust computation (e.g., anti-environmental noises); Fifthly, the integration of SNN with neuromorphic hardware is shown for efficient non-Von-Neumann computation. After that, we will introduce a biologically-plausible strategy for well-tuning SNN by integrating multi-scale and multi-type plasticity rules inspired by natural neural networks and fine-tuning processes of state-of-the-art ANNs. This strategy provides an alternative effort for the efficient credit assignment for SNN, covering the whole network neurons, from readout, locally-hidden, to input neurons. It also gives us hints on answering the critical question, i.e., how biological neural networks can handle global network-tuning problems by integrating different types of local plasticity rules. These integrative principles will give SNN a possibly right tuning direction towards efficiently cognitive computation. Simultaneously, the success of SNN will also give inspirations back to the findings of new plasticity rules in natural neural networks. We think the goal of SNN is not just working as a biological candidate of ANNs, but constructing a new generation of effective artificial-intelligence models with characteristics of biologically-plausible cognitive computation by integrating theoretical breakthroughs in biology-inspired multi-scale plasticity principles, towards the faster learning convergence, the lower energy cost, the stronger adaptability, the higher robust computation, and also the better interpretability.

Keywords Spiking Neural Network; Brain-inspired Intelligence; Plasticity Principles; Cognitive Computation

1 引言

脑科学与人工智能研究正在相互促进中迎来飞速的发展,具有交叉学科特点类脑智能研究也因此受到人们日益广泛的关注。类脑智能算法的本质,是期望从生物科学研究结果中得到结构、机制或功能等方面的启发,来完善人工智能算法或引领其未来发展的新方向,使得人工智能能够扩展、融合多种认知能力,并从多方面逐步逼近甚至超越人

类智能水平。脉冲神经网络 (Spiking Neural Network, SNN) 的研究正处于类脑智能研究的核心,通过强调高度类脑的结构基础和功能优化方法,尝试用计算的方式加速对生物智能本质的理解,为形成新一代的类人水平的人工智能模型奠定理论基础。

正如诺贝尔生理学或医学奖得主 Gerald M. Edelman 所说:“脑科学知识即将奠定新时代的科学基础,凭借脑研究的结果我们可以在疾病治疗等方面取得进展,同时建成具有仿脑功能的新机器,有

助于我们更为深入地认识和了解人类智能本质”。2013年, 欧洲的人脑计划 (Human Brain Project, HBP) 入选了欧盟委员会的未来旗舰技术框架项目^[1], 该计划的主要目标之一, 是搭建以类脑脉冲神经元为主体的大规模脑模拟器并力图在下一代类脑启发的信息技术研究上获得突破。2014年, 美国的高级情报计划署开展了由脑皮层智能网络启发的机器智能项目 (Machine Intelligence from Cortical Networks, MICrONS)^[2], 该项目的主要思路是通过采集、观察、重建和模拟大脑皮层的网络结构和脉冲信息处理机制, 以此来研发新一代的具有人类新皮层功能特性的智能系统。2018年, MIT 联合内部五大学院开展 Intelligence Quest 项目^[3], 重点研究机器学习算法, 同时外延到通过计算机科学的见解来反向提高对生物网络智能的认识。

以上这些计划的核心研究点之一就是探寻生物网络智能的本质, 如高效学习、稳定记忆、迁移泛化等。长期“优胜劣汰”使得大脑遗传进化出良好的物质和结构基础, 在这个基础上, 通过可塑性规则约束, 大脑可以后天习得越来越多的认知能力, 如分类、识别、记忆、决策等, 并以此为基础逐渐扩展到更高级别的复杂认知能力, 如启发联想、独到创新等。其中, 学习和记忆对应着生物可塑性、稳定性等机制的研究, 涵盖了从离子通道和膜电位, 到突触、环路、功能等多尺度的复杂动力学信息表征, 这些也是机器学习领域最为关注的机制之一。

自从 1943 年 McCulloch 和 Pitts 借鉴了生物神经元的运算模式, 首次提出了 MP 人工神经元模型以后^[3], 神经网络的研究开始逐步发展, 一些具有里程碑意义的神经网络模型也被相继提出, 如 1957 年的感知机 (Perceptron)^[4], 1982 年的 Hopfield 网络^[5], 1983 年的玻尔兹曼机网络^[6], 1986 年的反向传播 (Backpropagation, BP) 网络^[7], 1989 年的卷积神经网络 (可以追溯到从 Neocognitron^[8]到 Convolutional Neural Network^[9], CNN), 1997 年的脉冲神经网络^[10], 2006 年的深度置信网络 (Deep Belief Network, DBN)^[11], 2012 年兴起的深度神经网络 (Deep Neural Network, DNN)^[12]等。

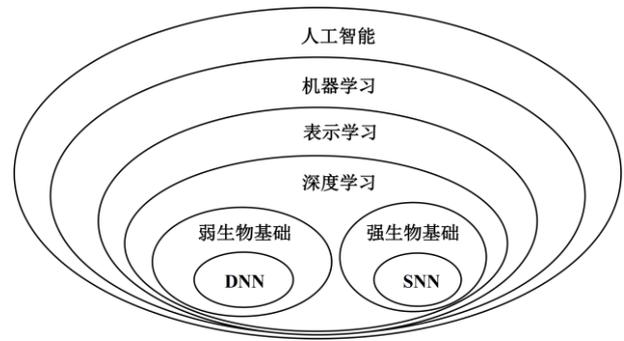


图 1 脉冲神经网络的概念定位 (补充完善于^[13])

脉冲神经网络是源于生物启发的新一代人工神经网络模型, 如图 1 所示, 属于深度学习的子集, 且具有较强的生物基础支撑。当前的以放电率为信息承载主体的 CNN 等属于非 Spike 模型。与之相比, 脉冲神经网络虽然也属于人工神经网络, 但是更加强调, 以具有精确放电时间、具有事件驱动特性的 Spike 作为信息运算的基本载体。虽然名字中着重强调了“脉冲”这一生物网络的主要外显特点, 但是与之同样重要的还包括其它内隐属性, 如具有高动态-复杂动力学的神经元节点 (时序脉冲产生)、具有强可塑性-稳定性信息表征的突触结构 (脉冲学习)、具有复杂特异性功能的网络环路 (脉冲功能表达) 等。脉冲神经网络的提出, 标志着神经网络从以放电率为主体的空间编码, 逐步过渡到以精确 Spike 放电和阈值下动力学膜电势为主体的时空混合编码。新增的时间维度, 使得更精细的生物计算模拟、更稳定鲁棒的信息表征、更高效节能的生物可塑性网络优化等成为了可能。

本文的后续章节安排如下: 第 2 章将主要阐述 SNN 网络的原理及优势, 特别对一些具有启发性的 SNN 特点等进行着重介绍; 第 3 章将主要介绍以理解生物系统为目标和以追求卓越计算性能为目标的两大类 SNN 的研究进展, 并对已有的算法性能、软硬件框架及应用等进行总结; 第 4 章将重点介绍融合多类生物可塑性的优化方法及可能的启发; 最后第 5 章将对本文工作进行总结及未来展望。

2 脉冲神经网络的原理及优势

现有的人工神经网络已经借鉴了部分的脑神经网络信息处理方式, 如非线性的神经元信息转换、权值可变的突触更新、特定层级或循环的网络结构等。

SNN 网络具备了较好的人工网络基础, 且同时考虑了更多的生物细节, 因此天然的可以作为人工

智能模型和生物神经系统的联通桥梁。未来,随着生物神经科学的进一步发展,越来越多生物启发的、有益高效的神经信息处理机制可考虑通过数学模型描述的方式,表示、论证、测试、并迁移泛化到多类人工智能模型中,为得到更智能、更高效的人工智能算法提供帮助。因此,脉冲网络通过模拟和借鉴生物系统,将在以下几个方面展现出优势。

2.1 动力学特性的神经元信息表征

生物系统中可以根据放电模式粗劣的区分神经元类型,如强直放电(Tonic Spiking)、相位放电(Phasic Spiking)、簇放电(Tonic Bursting 和 Phasic Bursting)、频率自适应放电(Spike Frequency Adaptation)、混合放电等^[14]。这些不同放电模式的神经元,可以大致的分为比例多而种类少的兴奋性(Excitatory, E)神经元,以及比例少而种类多的抑制性(Inhibitory, I)神经元。不同神经元的动力学信息编码有较大的区别,且适当比例的类型组合被发现可以显著减少神经网络的能量消耗^[15, 16]。

表 1 动力学公式表征的神经元节点

神经元节点	动力学公式
H-H 模型	$\frac{dV}{dt} = -g_{Na}(V - V_{Na}) - g_K(V - V_K) + I$
Izhikevich 模型 ^[14]	$\begin{aligned} \frac{dV}{dt} &= 0.04V^2 + 5V + 140 - u + I \\ \frac{du}{dt} &= a(bV - u) \end{aligned}$
Tempotron 模型 ^[17]	$V = U_0 \left(e^{-\frac{t-t_1}{\tau_1}} - e^{-\frac{t-t_2}{\tau_2}} \right)$

表 1 展示了几大类基本的神经元动力学节点公式,其中 H-H 模型具有最多 1 阶的膜电位吸引子;而 Izhikevich 模型采用有限个无量纲参数组合(如 a, b 等)来表征多类丰富的脉冲发放模式,是一种构建二阶神经动力学方程的有效途径^[14];类似的高阶动力学,也可以采用直接设定膜电位变化过程来实现,如类似 Tempotron 的突触后膜电位电压响应公式^[17]。

神经元的信息编码可以简单归纳为高阶微分动力学过程:突触动态接收上游神经元轴突传来的 Spike 序列(基本量纲为电势)并转为电流传到胞体(基本量纲为电流);胞体动态接收电流并最终发放异步 Spike 信号,与此同时产生不应期和电位重置。外界的输入电势或电流都将影响内部动力学

方程的极值,因此将会出现不同类型、不同数量的吸引子或动态分岔,如 1 阶稳定吸引子、鞍-结分岔、霍普夫分岔等。因此,按照不同的动力学特征(如极值数目、分叉范围等)来组织、定义不同类型的功能性神经元,将可以有效控制神经元类型数目并广泛应用到多类神经元组合的网络优化中。一些典型的神经元类型及编码如图 2 所示。

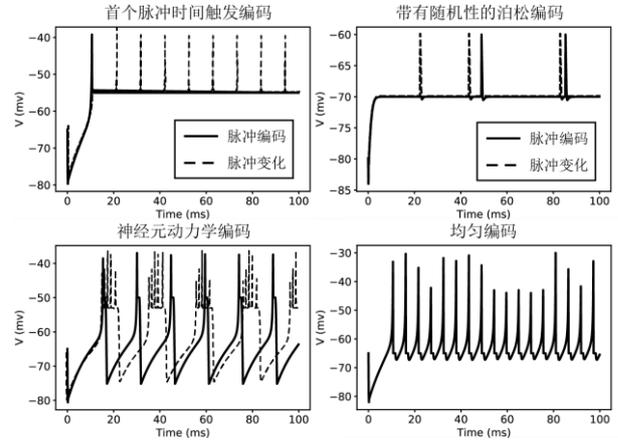


图 2 不同类型神经元的信息编码示例

2.2 动力学特性的突触可塑性机制

众多突触可塑性机制的有机组合,是生物网络实现高效信度分配的关键^[15, 18]。已有的生物研究结果表明,生物系统中不存在类似 BP 的全局误差函数调优,而是更可能由诸多局部突触可塑性快速、直接地完成。这些局部、非监督可塑性的组合是如何实现类似全局监督式的网络整体权重优化,值得下一代人工神经网络重点借鉴。

已发现的生物可塑性学习规则,基本上也都可以用多元、高阶的时空动力学方程来精确表示,且和当前主流的基于“监督误差”的 BP 类传播方法有本质差别,生物的可塑性多为“非监督自学习”方式:如在局部突触可塑性方面,赫伯学习(Hebb's law)^[19]或脉冲时序依赖可塑性(Spike Timing-Dependent Plasticity, STDP)^[20],描述了突触权值随神经元活动状态改变的机制;又如短时突触可塑性(Short-Term Plasticity, STP)描述了一种突触内部的输入-输出稳态调控机制;突触自组织传播(Self-organized Back Propagation, SBP)^[21, 22]描述了当前层的突触权重可塑性可以通过下一层权重反向传播 LTP 或者 LTD 得到;目标传播(Target Propagation, TP)^[23, 24]描述了误差或者奖惩信息可以直接作为目标信息指导所有中间神经元的状态调整;稳态调优^[25-27]描述了局部的神经元状态达到纳什均衡,网络则会表现出一种特殊的稳定状态,

有助于后期网络具体能力的学习。

脉冲神经网络很好的集成了上述的诸多可塑性学习法则, 通过将其动力学模型化, 最终有机融合来实现类似 BP 的学习效果, 且在可解释、并行计算、弱监督等方面取得突破。近期, 美国加州大学洛杉矶分校 (UCLA) 的研究团队在《科学》杂志上撰文称, 树突也可以产生复杂的电活动, 如 Spike 等, 且其数量是胞体的 10 倍以上^[28]。考虑到电活动是后续复杂认知能力的基础 (如学习、记忆、决策等), 比例高、数量大、放电多的树突结构将有可能取代胞体作为基础的神经计算单元, 同时也为人工模型中精细建模突触动力学提供了实验依据。

动力学描述的突触变化公式如表 2 所示, W 为产生突触可塑性的权重, r 为神经元的放电率, s 为发生的 Spike, i 为突触前神经元的位置, j 为突触后神经元的位置, k 为后面一层神经元的位置, 其他皆为动力学相关的参数或网络内隐状态。这些高效实时的、具有生物特色的非监督学习方式, 大部分已经被应用到图片识别^[29-34]、机器人时序动作学习^[35]等领域, 且取得了较好的应用效果。

表 2 用动力学公式表征的突触可塑性准则

可塑性规则	动力学公式
标准 STDP ^[20]	$\Delta W_{i,j} = \begin{cases} Ae^{\left(\frac{\Delta t}{\tau}\right)} & \text{if } (\Delta t < 0) \\ -Ae^{\left(\frac{\Delta t}{\tau}\right)} & \text{if } (\Delta t > 0) \end{cases}$
突触后微分 STDP ^[36]	$\Delta W_{i,j} \propto r_i^t r_j^{t+1} - r_i^t r_j^t$
突触前微分 STDP ^[32]	$\Delta W_{i,j} \propto r_i^{t+1} r_j^t - r_i^t r_j^t$
标准微分 Hebb	$\Delta W_{i,j} \propto s_i^t s_j^t$
衰减微分 Hebb	$\Delta W_{i,j} \propto s_i^t s_j^t - c$
STP ^[37]	$\begin{aligned} \Delta I &\propto -\frac{I}{\tau_i} + A_i W_{i,j} u x \delta(t - t_{sp}) \\ \Delta u &\propto -\frac{u}{\tau_u} + A_u (1 - U) \delta(t - t_{sp}) \\ \Delta x &\propto -\frac{1-x}{\tau_x} - u x \delta(t - t_{sp}) \end{aligned}$
SBP ^[20, 22]	$\Delta W_{i,j} \propto B_{LTP} \Delta W_{i,j}^+ + B_{LTD} \Delta W_{i,j}^-$
类多巴胺-资格迹的奖赏传播 ^[38]	$\begin{aligned} Z_i(s) &= \gamma Z_{i-1}(s) + \delta(s - s_{reward}) \\ \Delta W_{i,j} &\propto \delta_{TD}(t) Z_i(s) \end{aligned}$

2.3 基于 Spike 的异步信息编码

生物网络中的很多结构会对信息进行二次、多次编码, 如信息通过具有动力学信息编码的突触结构, Spike 信息会增强、衰减甚至延迟计算。这些不同的编码模式会根据突触后膜的不同离子通道

类型而发生细微差别, 这都将增强脉冲神经网络的异步时间编码能力。在神经元外部, 编码方法多用来将输入的实值信号转换为带有时间信息的 Spike 序列信息, 由于编码的目的是尽可能无损的还原输入信息, 因此基于简单均匀放电的 Spike 序列编码最为常用^[39]。除此之外还包括几大类基本信息编码, 如图 2 所示。

①首个脉冲触发时间编码。生物证据表明, 大部分脉冲信息是在刺激产生的 20ms-50ms 内发生传递, 因此这种编码着重强调第一个脉冲的出现时间, 而对其他脉冲时间忽略或做小权重整合^[40]。这种方法适用于编码刺激轮廓如边缘特征, 且每个神经元只能发放一个脉冲。

②延迟相位编码。该方法受到视网膜神经节细胞的信息处理启发, 即刺激越强, 延迟越短, 然而需要额外的相位对齐^[41]。

③脉冲序列卷积学习编码。将模拟信号转为数字信号 (适合语音、EEG 脑电等), 通过对刺激信号进行反卷积, 最小化编码和原始信息差异以实现最优编码, 典型算法包括 Bens Spiker Algorithm (BSA)^[42], Hough Spiker Algorithm (HSA)等^[43]。

④泊松信息编码。泊松 Spike 编码符合生物发现, 且在脉冲序列估计、神经网络背景噪声的模拟中被广泛采用^[15, 44]。然而, 泊松编码通过长时序列的泊松分布来对特定的精确数值进行估计, 且估计数值为泊松分布全时域的均值, 因此理论上在有限时间内无法得到精确编码。

⑤神经元动力学编码。神经元内部具有复杂的动力学特性, 膜电位本身可以是多个高阶吸引子的动态组合, 动态留存历史信息并在放电阈值、静息电位阈值等方面产生可塑性。同时, 单一的时间或者空间信息经过神经元动力学编码成统一稳定的 Spike 序列, 有助于信息的交互及融合。在空间上, 固定时间窗口内的 Spike 放电数量也可以作为量化的空间信息编码。因此, 通过对膜电位构建高阶动力学方程, 同时加入多隐变量的信息调制, 可以通过时-空融合实现复杂膜电位的动态更新^[16]。

⑥异步信息延时编码。一方面, 突触的信息传递能效、信息迟滞时间等和所处的空间位置、分叉级数、上下游突触电导等相对静态的变量高度相关; 另一方面, 延迟也与当前时刻的放电频率、放电概率动态相关。这些特点都极大的增强了脉冲神经网络的非线性信息编码能力^[45]。

⑦脉冲神经元群体编码。考虑到单个神经元具

有概率放电特性，因此生物神经元群实现了采用多神经元同时编码同一个信息，来达到稳定编码的目的，典型的例子是海马体的位置细胞、视觉区内侧

颞叶、运动皮层等部位的细胞群等。群体编码通过均匀高斯函数分配不同神经元感受野，用适量的神经元冗余实现了较高精度的信息有效编码^[46]。

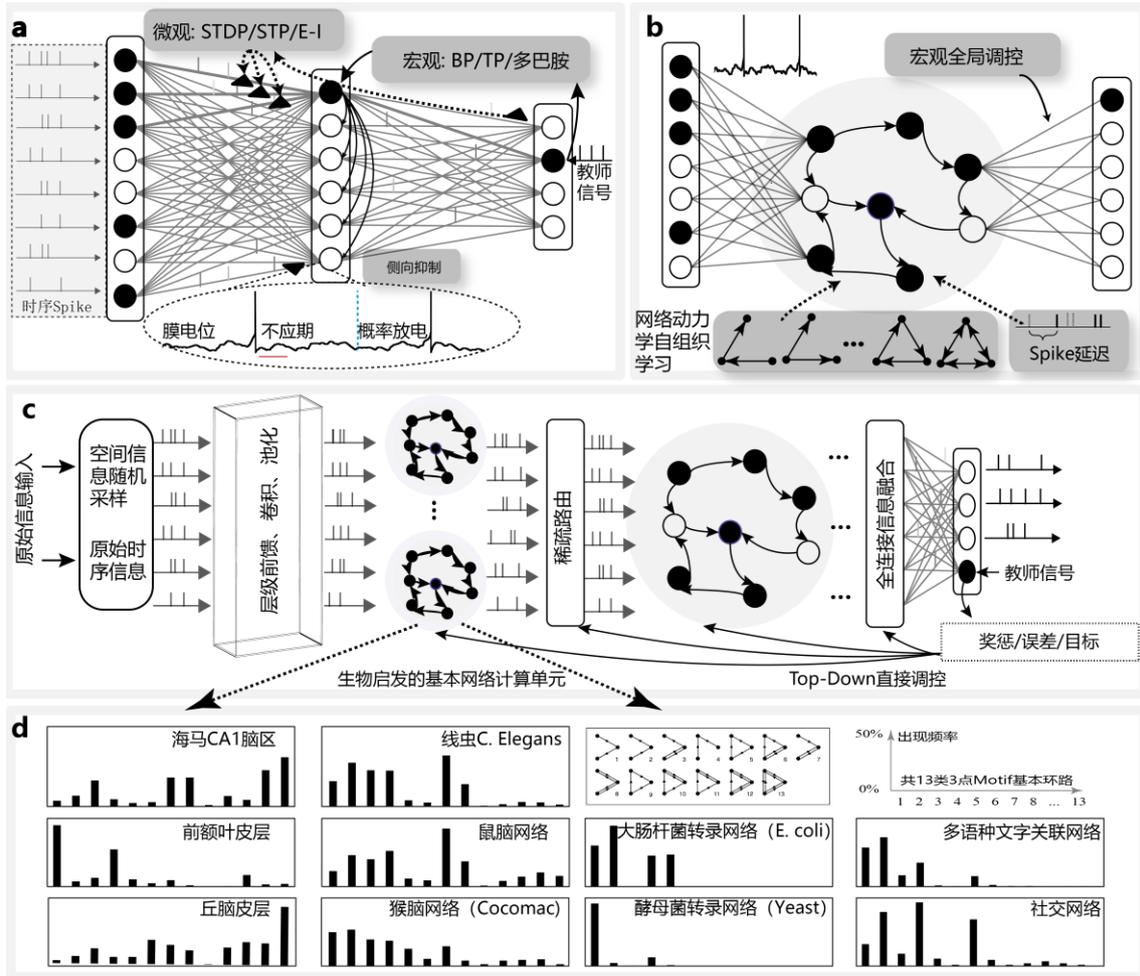


图 3 脉冲神经网络架构及部分多尺度可塑性规则。a, 层级类型 SNN。b, 环状类型 SNN。E, 兴奋性神经元。I, 抑制性神经元。STDP、SBP、STP、BP、TP 等为可选择的生物优化方法。c, 融合多尺度生物启发的脉冲神经网络结构模型，含前馈、卷积、多层循环等复杂基本单元，融合了多尺度的生物可塑性优化体系。d, 不同脑区网络（海马^[47, 48]、前额叶^[49]、丘脑^[47]）、不同物种网络（鼠脑^[47]、猴脑^[50]、大肠杆菌^[51]）、不同其它复杂非生物网络（社交系统^[52]、文字关联网络^[53]）的三元 Motif 分布，表征了不同复杂系统网络结构模式的异同，该模式与网络特定功能高度相关。

2.4 多亚型的复杂网络结构

层级结构和环状结构是大多数神经网络的两大类基础结构。如图 3a 展示了基于 SNN 的基础层级前馈结构，为三层全连接神经网络，具有积分-放电的神经元，以及不同的可塑性学习规则，如 STDP、STP 等。图 3b 则介绍了环状网络结构，同样含有类似的可塑性规则。

生物体不同尺度的脑连接结构十分复杂。目前为止，以小鼠脑为例，突触级别（含连接方向）的全脑连接图谱还未绘制完成。然而，部分脑区，如海马区、皮质柱模块等，因为和具体的智能认知功能高度关联而率先进行了多尺度的网络重构（不含

突触，微米级）和连接模式分析^[47]。

多点最小 Motif 网络可以作为基本的网络结构单元展开重点分析，该方法也是解析复杂网络系统功能的常用手段^[52]。以三点 Motif 为例，当不考虑节点类型（如不同神经元类型）时，不同基元 Motif 的组合为有限的 13 类（如图 3d 中第一行第三列子图所示）。对于完成具体复杂功能的复杂网络，在不同尺度上展现出的 Motif 分布往往具有较强的一致性和稳定性。而对于功能特异性类型网络，相互之间的 Motif 分布具有较大的差异性^[18, 52]。

如图 3d 所示，对于小鼠脑中的不同脑区，如负责短程到长程记忆转化的海马区，生物网络

经过 3 点 Motif 分布分析, 发现具有较多的环状网络结构 (如 13 类 Motif 中的第 13 类比例较高, 该类具有全连接的结构特点)。

前额叶皮层网络的 Motif 网络则展现出了更多的层级前馈信息处理模式 (如图 3d 中第 1 和第 4 类 Motif^[49], 含 470 个神经元), 因此适合的结构为层级脉冲网络结构 (如图 3a), 且常被用来实现特征提取^[48]或功能分类^[25]。

与之相比, 丘脑的网络连接模式则较为平均^[54], 这也与丘脑的全局路由机制 (同时兼顾前馈和循环的信息处理能力) 高度相关。类似的分析可以发现, 如图 3d 所示, 大肠杆菌^[51]的结构较为简单, 而社交网络^[52]、语言网络^[53]等相比之下较为复杂, 但是和生物脑结构相比, 仍然稍显简单。

因此, 通过多点 Motif 的具体分布分析, 可以较好的理解复杂的网络功能, 甚至可以分析不同物种的功能区别, 如鼠脑^[47]、猴脑^[50]等。进一步的, 通过结合优化理论方法, 还可以探究网络对于智能信息处理的优势和限制等。如文献^[52]描述了一种根据不同 Motif 的环路分布来分析网络稳定性, 以此达到理解生物网络的稳定信息表征能力。文献^[47]通过探讨鼠脑已知的 48 个脑区的内部微观 Motif 分布, 结合脑区之间的介观尺度的 Motif 网络连接分布, 提出了一个学习宏观-微观 Motif 分布规律的神经网络模型, 该模型可以较好的实现对生物未探测脑区的微环路预测 (约含有 100 多个脑区及核团), 是一种采用计算的方式来弥补生物发现不足的有效手段。此外, 基于不同的 Motif 检测算法^[55], 可以对有向-无向连接突触、单类型-多类型神经节点等实现区别性建模, 为进一步理解其网络功能提供基础理论方法支撑。

2.5 极低能耗的网络信息处理

人工网络总体的复杂性约等于节点复杂性乘以网络结构复杂性。对于深度学习网络来说, 达到某个特定总体复杂度, 当节点的复杂性较为简单 (如人工网络中的简单激活函数) 时, 网络结构复杂性需要非常复杂 (如更多的层级、神经元数目或者环状网络连接)。与之相比, 脉冲神经网络的节点适当复杂 (如含有高阶的动力学方程) 时, 对于达到同等的总体复杂性, 网络的结构复杂性可以相比深度学习网络极大下降。脉冲网络通过丰富节点的复杂性, 使得前馈 SNN 可比拟环状 DNN (时间折叠), 浅层 SNN 可比拟深层 DNN (空间折叠), 由此得到优异的网络性价比。

另一方面, 相比较人工网络的巨大能量消耗 (如 AlphaGo 耗费了 1202 块 CPU 和 176 块 GPU)^[56], 而人脑只有大约 20W 左右的能量消耗。这其中的一个主要的原因, 是生物神经网络只有当膜电位达到放电阈值才激发神经脉冲进而发生信息传递, 而大部分的生物神经元在活动周期中都处于静息状态。这种独特的信息传递方式在神经拟态器件中将发挥超低能耗运算的优势^[57]。

2.6 多时钟自组织计算

在脑区内部, 生物网络通过多神经元群体编码, 对不同维度的输入数据内部信息进行自动关联学习。如在传统的神经网络学习的 $y=f(x)$ 映射基础上, 生物网络还会增加对输入数据本身进行 $x_t \rightarrow x_{t+1}$ 的内部时间关联建模, 这种关联发生在突触上, 将对网络的稳定存储提取、甚至信息的启发式联想等能力带来帮助^[48]。

在脑区外部, 生物网络具有明显的分区分块、协同工作的特点。不同脑区之间的兴奋性和抑制性长程投射, 和各个脑区参与、协同的功能高度相关, 如丘脑脑区的信息路由机制、海马脑区的长短期记忆转换机制、基底节的多巴胺信息奖励机制等。

由此, 网络形成了突触时钟、神经元内部时钟、网络环路时钟等多尺度、独立的异步计算过程。这将使得脉冲神经网络在保持不同尺度内部独立稳定功能的基础上, 同时具有快速的迁移泛化和新知识的组织学习能力。

2.7 认知增强和抵御干扰能力

深度借鉴生物信息处理机制的另一个原因, 是现有的人工网络 (如 DNN 等) 正在逐渐面临越来越多的困难挑战, 如节点复杂性远低于网络复杂性导致网络结构复杂难以理解^[58]、待调优参数数量和任务复杂性不匹配导致欠/过拟合^[59]、单一的优化目标损失函数导致习得的网络通用性差^[60]、长程序序信息处理能力较弱且容易导致灾难性遗忘问题^[61]。

深度网络虽然对特定样本的识别正确率很高, 但是显然模型并没有真正达到对图片形成符合人类认知水平的理解, 因此容易发生啼笑皆非的测试结果, 如将黄黑色条纹的纹理图片以极高的置信度识别为校车^[62]。通过生成对抗网络形成的对抗样本很容易欺骗大多数的深度学习网络^[63], 极端情况下甚至存在不可察觉的噪声欺骗攻击^[62]、单像素改变欺骗攻击等^[64]。

脉冲神经网络在多方面展示出相对 DNN 更高

潜力的鲁棒特性。脉冲的概率信息发放、泊松信息编码、群编码等,使得信息在 SNN 中有更高的鲁棒性,不容易被随机的背景环境噪声所影响^[15, 48, 65]。SNN 中的多种可塑性学习约束,也使得网络不容易陷入极端的过拟合状况,且 SNN 本质上是一类时序动力学模型,因此常规的通过生成对抗网络的函数拟合攻击(更多的是空间拟合而非时间拟合)也更加困难。一些通过对传统的深度学习网络

中加入生物认知约束的尝试,也一定程度上提升了现有模型的防攻击能力^[66]。最近的生命科学研究也表明,兴奋性和抑制性神经元的配合可能是信息稳定表征的关键^[67],这个稳定性将高于 Poisson 放电带来的不确定性,为生物系统的稳态维持提供了更充分的生物机理解释,也对生物网络抵抗噪声干扰提供了一种可能的解释。

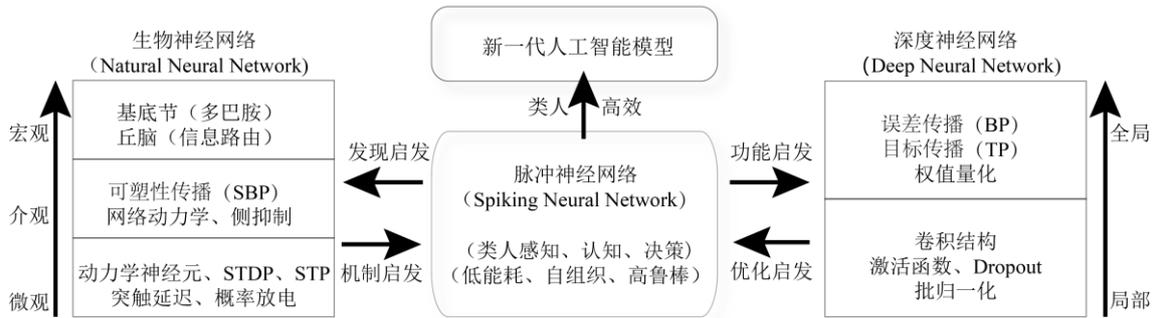


图 4 脉冲神经网络用于搭建生物和深度神经网络的桥梁并启发新一代人工智能模型

考虑到现有人工神经网络所忽略的很多生物细节可能恰恰是实现类人脑智能的关键,因此,通过生物网络结构、生物学习机制等启发,将为现有人工智能模型提高其认知能力指明一种可能的生物优化方向,最终使其具备更为强大的智能信息感知、认知、分析决策、自适应等能力。

2.8 融合已有成果体现交叉学科优势

如图 4 所示,脉冲神经网络通过同时借鉴生物系统的多尺度可塑性机制以及当前深度神经网络的成熟优化方法,将利用神经科学、计算机科学、物理科学等多学科交叉的优势,从多学科、多视角,将微观的神经元动力学、STDP、STP 等,介观的 SBP、侧抑制、网络动力学等,宏观的多巴胺奖赏学习等,与人工网络的 BP、TP、卷积、权值量化等有机融合,综合实现低能耗、自组织、高鲁棒性、高认知能力的新一代人工智能模型,并反向促进生物领域的进一步科学发现。

3 脉冲神经网络已有研究进展

如何高效优化复杂的脉冲神经网络模型是近年研究的重点,且优化方式根据优化目标的不同而有极大的差别。此外,同步支持 SNN 的计算框架和匹配硬件也取得了快速的发展,为 SNN 的优化测试和大范围应用提供了良好的基础。

3.1 以理解生物系统为目标的 SNN 优化进展

以理解生物系统为最终目标,采用的优化方法要尽可能的满足已知的生命科学发现,如脉冲时序依赖可塑性 (STDP)^[30-32, 44, 68, 69]、短时突触可塑性 (STP)^[26]、神经元侧抑制 (Lateral inhibition)^[70]、Dale 准则 (同一个神经元的突触类型相同,突触权值同为正或同为负,且不可相互转换)^[71, 72]、兴奋-抑制神经元平衡^[73, 74]、树突棘动态生长消亡^[75, 76]、生物自组织反向误差传播 (SBP)^[22, 77]、目标传播 (TP)^[78, 79],及其上述准则的不同变体等。通过将上述受生物现象启发的学习规则加入到 SNN 学习框架中来,以尝试让 SNN 具有类人认知水平的多模态信息处理能力、低能耗运算能力、鲁棒认知能力等。

在记忆认知的理解方面,Zenke 组合了多种微观神经可塑性规则,如 Hebb 规则、三相 STDP、时序异步突触后可塑性、介质调节的突触前可塑性等,通过构建循环的 SNN 网络,采用漏电-积分-放电 (Leaky-Integrated and Fire, LIF) 神经元模型进行建模,实现了多可塑性融合的学习和记忆网络,该网络可对几类简单的不同形态、轮廓的特征图片信息进行存储和记忆重现,充分展示了 SNN 的信息存取能力^[70]。

在多认知任务模拟方面,汪小京团队通过对兴奋性和抑制性神经元组建的 SNN 微环路的模拟,为多种、多尺度的认知任务进行了计算模拟,

如感知、决策、工作记忆保持、网络稳定周期放电等, 该工作将有可能在介观和宏观的生物智能现象的解释上发挥重要作用^[74]。

在大脑皮层网络模拟方面, 美国工程院院士 Jeff Hawkins 通过对大脑 6 层脑皮层的不同层间关系的生物学解剖结果分析, 构建了类脑皮层的分层时序记忆模型 (Hierarchical Temporal Memory, HTM) 算法^[75]。HTM 模型可以整合时序和多层次记忆之间的关系, 为时序数据信息抽取和模式预测提供了新的思路。最新的评测分析显示, 与长短期记忆网络 (Long Short-Term Memory, LSTM) 和门控循环单元 (Gated Recurrent Units, GRU) 相比: 在纯粹的时序预测任务下, HTM 不仅没有体现性能优势反而会消耗更多的计算时间^[80]; 然而在异常检测任务下, HTM 仍然可以有较好的能力发挥^[81, 82]。由此可以看出, 合适的结构特点与特定的功能任务匹配适应才会发挥类脑 HTM 模型的最大优势。

在以 STDP 为主的空间信息处理方面, Diehl 采用两层 SNN 网络以及 LIF 神经元模型, 相邻层神经元采用非监督 STDP 的方式进行学习映射。在训练阶段, 从输出层挑选出对特定类别输入信息选择性放电最强的部分神经元作为特定类别的标记。在测试阶段, 通过统计标记神经元数量判断输入信息类别。该方法在 MNIST 数据集上可以达到 95% 的测试正确率^[33]。该工作后续被继续优化提升为 96.7% 正确率^[29], 通过提出了一种融合多种神经可塑性和多巴胺调制的脉冲网络有监督学习算法, 可塑性包括侧向抑制、多巴胺调制、对称 STDP、突触权值归一化、动态的放电阈值等, 最后通过强制与输入标签信息关联的输出神经元高频放电, 来有效加入监督信息。论文^[31]采用多层卷积、STDP、信息延迟等计算方式, 来对不同的输入信息图像进行自组织的非监督学习, 并在习得了鲁棒特征后, 再单独加入一个独立的监督学习模块如支持向量机等, 实现高效的图像特征分类。论文^[83]提出采用 STDP 和强化学习 Reward-STDP 来组合优化基于 PyTorch 的多层 SNN, 该网络带有卷积结构, 采用分级编码方式, 在 MNIST 数据集上达到了 97.2% 的正确率。

在以 STDP 为主的时序信息处理方面, 论文

^[84]提出基于卷积结构、STDP 非监督特征学习的 SNN 进行孤立词语音识别, 基于首个脉冲发放时间编码, 将语谱图转换为脉冲序列, 具有能耗低、生物合理性强、性能优越等特点, 如在 TIDIGITS 标准数字语音数据集上分类准确率达到 97.5%。

在 Dale 准则的必要性方面, Wade 提出了一种基于 BCM (Bienenstock Cooper Munro) 和 STDP 相结合的突触权值更新方法^[85], 并结合兴奋和抑制性突触, 模型得到了相比无抑制性突触的 SNN 更好的分类结果: 如在 Iris 数据集 (包含 3 种不同类型的鸢尾花的 50 个样本) 中达到了 95% 的正确率, 且在 Wisconsin 癌症诊断数据集上达到了 96% 的正确率。

在动力学神经元性能分析方面, Beyeler 采用了更为复杂的 Izhikevich 动力学神经元模型替换了简单的 LIF 神经元, 使用电导依赖的突触可塑性以及 STDP 学习规则, 虽然在 MNIST 数据集上只得到了约 90% 的识别正确率, 但却是复杂化神经元动力学的一次有效尝试^[68]。我们自己的工作也进一步分析了不同的复杂神经元动力学对于不同的时间、空间任务的作用和联系, 并发现一些基础的神经元可以通过自组织实现更好的时-空信息处理^[86]。

对微观可塑性的规则组合也是研究的重点, 各个规则既要发挥各自作用又要避免冲突。我们之前的工作中^[15, 25, 26, 87], 神经元的动态分配、突触的生长消亡、不同类型的背景噪声、不同类型的 STDP、兴奋和抑制性神经元等多条可塑性规则被作为重要机制引入到 SNN 的学习中来, 且模型的正确率会随着规则的增多而逐步提升^[15], 展现出了 SNN 中不同机制的独特作用, 也为 SNN 的可解释性提供了帮助。除此之外, 一些传统的方法, 如 Resume 等, 因为其算法本身局限性而大多应用于较为简单的液体状态机 (Liquid State Machine, LSM) 网络^[88]中, 如实现视频流模式区分^[89]、语音编码^[79]等。

以上这些方法都着重依赖使用生物可解释的可塑性法则来优化 SNN 网络, 并在这个过程中逐步提升对生物计算方式、方法的理解和认识。更多最新脉冲神经网络的评测结果如表 3 所示, 可以发现 BP 类的优化方法会给 SNN 带来更好的性能, 然而这类努力却对揭示生物启发计算, 以及提高对 SNN 内部状态的可解释性等帮助甚微。对生物计算的理解和对传统指标最优性能的提升,

是目前脉冲网络研究的正反两面。然而在未来,随着更多的如可塑性、动力学等优化理论的突破,将有可能使两者合二为一,共同助力新一代人工智能模型的实现。

表 3 不同类型 SNN 模型在小规模标准数据集上评测结果

模型结构	监督	BP	学习规则	性能
MNIST:				
多层前馈 ^[68]	是	否	STDP-like, Spike+Rate	91.6%
二层前馈 ^[90]	否	否	STDP, Spike+Rate	93.5%
二层前馈 ^[33]	否	否	STDP, Spike	95%
三层卷积 ^[83]	是	否	奖赏 STDP, Spike	97.2%
多层前馈 ^[31]	否	否	STDP, Spike	98.4%
三层前馈 ^[26]	是	否	稳态+STDP, Spike	98.64%
三层前馈 ^[86]	是	是	Meta 神经元, Spike+Rate	98.69%
多层卷积 ^[91]	否	是	Reward+TP, Spike+Rate	99.01%
多层卷积 ^[92]	是	是	伪 BP, Spike+Rate	99.1%
多层卷积 ^[65]	是	是	循环+伪 BP, Spike+Rate	99.5%
多层卷积 ^[93]	是	是	ST-RS-BP, Spike+Rate	99.62%
Cifar-10:				
三层前馈 ^[87]	是	否	Curiosity+STDP, Spike	52.85%
一层卷积 ^[91]	否	否	Reward+TP, Spike+Rate	53.11%
深度网络 ^[94]	是	是	ANN-SNN 转换, Rate	91.55%
TIDIGITS:				
LSM ^[95]	是	是	BP, Spike	92.03%
多层卷积 ^[91]	否	否	Reward+TP, Spike+Rate	94.86%
SOM-SNN ^[96]	是	是	SOM+BP, Spike+Rate	97.40%
一层卷积 ^[84]	是	是	首脉冲+BP, Spike+Rate	97.5%

3.2 以追求卓越计算性能为目标的 SNN 进展

另一类是以追求卓越计算性能为最终目标,采用的优化方法不局限于生物约束,特别的可以采用基于 BP 的不同变体实现 SNN 的优化,如代理梯度^[97, 98], BP 训练 DNN 后转化为 SNN^[99],对 SNN 的 Spike 平滑近似使其满足可微分条件^[100-105],以及其它以 BP 为基础的近似或等价优化等。

受到神经元动力学特性的启发,脉冲神经元(Spiking Neuron Unit, SNU)通过内部环路实现类似 LIF 的动态工作机制,同时结合 BP 的优化方法,在保证多层 SNN 的有效学习的同时,尽可能的保留了生物神经节点的时序动力学信息处理特点,如非线性信息积累、膜电位无输入自动衰

减、固定阈值放电等,在 MNIST 数据集上可以达到较高的 99.5% 的正确率,同时支持音乐和弦(如巴赫)的预测^[101]。由于 SNU 支持 BP 优化,因此在更复杂网络上也取得了较广泛的应用,如 N-MNIST^[65]、动态手势动作 DVS-Gesture 分类等^[86]。

受到生物网络含噪运算的启发, Lee 构建了多层次的 SNN,并采用生物 LIF 模型建模,通过分析已有的多种生物网络中的噪声信号特性,如非均匀泊松噪声、固定频率噪声等,开创性的将现有的 LIF 神经信息放电看作噪声的一种,把原本非连续的神经膜电位信息等价为连续的神经元模型,然后采用 BP 的方式优化,同样达到了较高的分类精度^[102]。训练后的网络很适合对模糊放电信息的处理,从侧面表现出 SNN 网络强大的时空信息整合能力。类似工作还包括类脑环状网络结构启发的噪声抵抗 SNN 模型等^[15, 48, 65]。

代理梯度是另外一种有效优化 SNN 的方法,一般采用 Van-Rossum Distance 计算代价函数,在 BP 优化过程中,用连续膜电位变量替换离散 Spike 的优化推导,如将膜电位中不可微分项去掉(含 Reset 和 Spike 项),用膜电位的动态变化替换 BP 的二值状态,使得网络可以最终通过近似 BP 的方式求解^[97, 106],且基本达到在收敛速度和正确率上和标准 BP 可比较。类似的尝试也发生在环状脉冲神经网络中,文献^[104]通过融合 BPTT (Back Propagation Through Time) 和动态网络结构调整,实现了与 LSTM 网络的同等性能。

将 DNN 预先通过 BP 训练,然后转化为 SNN,也是一种高效的 SNN 实现方法^[92, 107],这些方法在 DNN 训练阶段将权值限制到 0 附近的极小范围内,使得 SNN 转化后的 LIF 信息编码可以处于激活函数的近似线性空间内(如-0.05 到 0.05 之间),转换后通过统计神经元的放电频率来计算网络输出状态,进而计算较为准确的输出误差^[103, 108]。这种方法可以利用 BP 达到较高的计算性能,但是由于多种限制使得相比于纯粹 DNN 的实验结果,性能稍弱。

遗传演化算法也是一种候选的 SNN 优化方法。通过逐步挖掘局部信息处理对全局优化的影响关系,经过剪枝、遗传、演化、适应等一系列优化步骤后,最终学习后的 SNN 在某些特定认知任务中可以展现优势^[75, 109, 110]。然而由于演化算法的随机性,以及发挥主要作用的适应函数对微

观网络权值优化方向的弱限制性, 因此在达到同样网络性能条件下, 遗传演化算法往往需要超出同类方法更多的迭代优化计算时间^[75, 111]。

脉冲耦合神经网络^[112]是 SNN 中的一类特别分支, 基本原理是将信息(如图像像素)及其周围邻域的信息同步输入到网络中, 根据这些输入信息值的大小关系输出局部整合结果, 类似于数字图像处理中的卷积滑动掩膜矩阵, 可以等价实现多种图像处理或增强效果, 如平滑、滤波、边缘增强等。这些及其他相关的有效尝试, 都为人工智能模型和生物发现的深入结合^[113]提供了可能的思路。

除此之外, 一些较为传统的方法, 如用神经元精确放电的 Spike 时刻来表征网络信息的传递, 可以看作是另一种融合 BP 优化的有效途径。SpikeProp^[114]通过限制网络中神经元的脉冲发放次数, 通过 BP 的方法根据放电时差来优化调节每层的权重数值。相似的 QuickProp^[115]等改进版本也在运算速率、非线性运算等方面展现了优势。然而, 本质上基于时域 BP 的方法使得这些 SNN 网络学习速度较慢。特别的, 对于特殊的没有脉冲发放的状况下, 网络将不会产生可学习的有效梯度, 进而拖慢了 SNN 的拟合速度。Tempotron^[17]丰富了神经元节点的信息表达, 通过计算目标和实际输出的最小化, 实现突触权值的优化, 采用了类似 BP 的方法, 但是只适用于较少的神经元数量。

3.3 SNN 的软硬件框架及应用

部分 SNN 框架被用来实现较小规模的神经元功能仿真模拟, 主要以理解生物系统为目标。Neuron^[116]和 NEST^[117]是两个常用的框架之一, 支持 Python、C++ 等多类语言接口及可视化界面等, 支持刻画较为精细的神经元活动的动力学过程, 如 LIF、H-H、Izhikevich 等点神经元, 或含有复杂结构的多房室、管道模型等。除此之外, 还支持多类突触的单独建模, 如电突触、AMPA、NMDA、GABA 等。

部分 SNN 框架可以实现特定任务的、较大规模的脉冲神经网络优化计算, 除了支持多种神经元模型, 还支持多类的突触可塑性, 如 STDP、STP 等, 因此可以针对特定数量的神经元群体进行可塑性学习。如 Aurnyn^[118]支持了信息在网络环路中的学习、记忆; Bindnet^[119]、PyNN^[120]和 Brian2^[121]等, 基于 Python 语言, 较好的支持了多

神经元组网可用于特定模式的识别任务, 包括图片分类如 MNIST、Cifar-10 等, 或语音识别如 TIMIT 等, 特别的对于异步数据集有较好的支撑能力(如 DvsGesture^[122]、DVS-Cifar10^[123]、N-MNIST^[124]等), 可以实现关联记忆、自主识别、自主学习等; GeNN^[125]基于 C++, 对软件模拟加速及能耗作了特别的优化处理。Nengo^[126]是一种支持特定函数设定下的 Spike 转换框架, 可以灵活的实现任意指定函数的 Spike 模拟, 但是对可塑性学习的支持较弱。

脉冲神经网络软件框架的快速发展, 使得对应的应用可以更快的扩展到越来越多的场景中, 特别的, 对于有限尺寸、低能耗、并行计算等有较高需求的应用场景, 如机器人芯片、高性能模拟计算、模式识别加速器、事件高速摄像机等, 已经逐步开始展示出了巨大的应用潜力。

自然杂志上发表论文称^[127], 科研人员在最基本的单个忆阻器上实现了存储和计算的融合, 可以将氧化物忆阻器的集成规模提高一个数量级, 并基于实现的 1024 个氧化物忆阻器阵列搭建原型计算系统。该系统可以使用电子突触阵列实现人脸识别, 在耶鲁大学人脸图片库(Yale Face Database)上的性能评测中, 实现了与现有 CPU 接近的识别率和泛化能力, 且保持极低的能耗。

针对神经形态芯片面临的编程挑战, 清华大学团队^[128]提出了定制化的 NEUTRAMS (Neural Network Transformation, Mapping and Simulation) 系统工具, 该工具可实现神经网络转换算法, 具有可配置的时钟驱动神经芯片模拟器。在该工具的支持下可以实现 CMOS 神经芯片的构建, 可以同时支持 SNN 和 DNN 的信息处理。类脑计算芯片“天机芯”^[129]同时支持传统的机器学习算法和新一代类脑脉冲神经网络算法, 并在自动驾驶自行车上验证了芯片的语音识别、控制追踪、自动避障等功能。

神经形态芯片 TrueNorth 含有约 54 亿个硅晶体管、4096 个内核、100 万个神经元和 2.56 亿个突触, 可以实现基于 SNN 的类脑情感计算^[130]、SNN 生态系统构建^[131]等。Neurogrid 模拟了由数十亿个突触实时连接起来的上百万个神经元, 可支持高性能计算机和类脑机器人芯片, 目前的进展包括高通量脑信息处理^[132]、脑机接口神经信息记录^[133]等。

浙江大学联合之江实验室研发的类脑计算机,

神经元数量有 1.2 亿，突触数量有 720 亿，达到了普通小鼠大脑的神经元（约 7100 万）和突触规模，典型运行功耗只需 350-500 瓦，从另一个侧面验证了神经形态器件的低能耗特性。

同期，英特尔公司展示了其最新的 Pohoiki Beach 芯片系统，模拟的神经元数量达到 800 万，突触数量达到 80 亿，并统一封装在了 Loihi 芯片中^[134]，初步在高灵敏气味感知、识别等方面发挥作用。

类脑算法和硬件的协同发展，将充分发挥各自的性能优势，在存算一体、低能耗、并行运算、小型化、多用途等方面发挥优势，特别的，也将为大规模科学模拟、复杂环境计算、实时动态建模等问题提供新的解决方案。

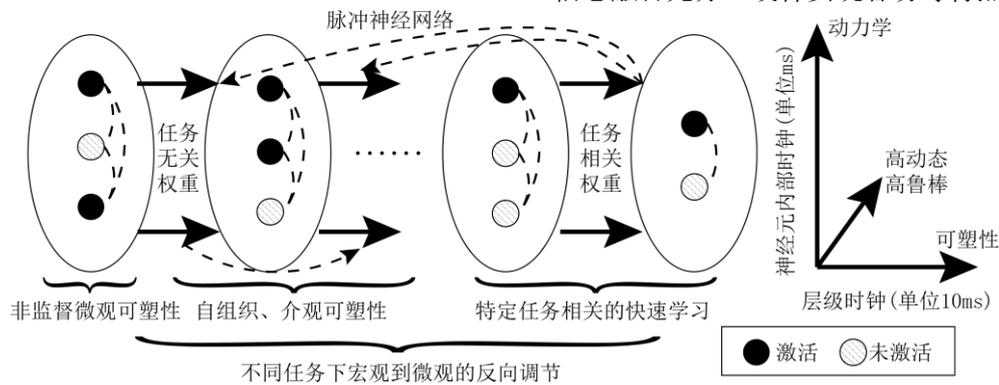


图 5 基于多尺度可塑性的脉冲神经网络多时钟示意框图

另一个值得一提的例子是离散 Hopfield 网络，该网络将所有的输入节点全连接组成环状结构。在训练阶段，通过 Hebb 法则来非监督的学习信息之间的内部关联，这个学习过程可以等效为对能量函数的最优化。能量定义为权重和其相邻神经元状态的乘积和，且会随着训练迭代而逐渐降低。在测试阶段，网络通过固化的权重还原输入信息，实现噪声去除、信息恢复等^[48, 65]。受限玻尔兹曼机可看作 Hopfield 网络的延伸，用基于能量的约束方法来最优化邻层网络权重，并在部分训练周期中与损失函数融合微调网络权重。这类特殊的基于能量而非损失函数（如网络输出和标签之间的平方误差和）的学习方式，使得网络学习可以从强监督逐步迈向更加高效和实用的半监督、弱监督等。

LSM 和 Hopfield 网络虽然是两类较为传统的人工神经网络模型，但是仍然给后续的 SNN 网络优化提供了启发，也是本章节多尺度可塑性实现的关键。如图 5 所示，多层前馈 SNN 网络的前几层主要起到稳定信息内部表征的作用，且可塑性变化和

4 多尺度可塑性的 SNN 优化方法

目前发现的生物可塑性大多是自组织、无监督的，因此在研究生物可塑性方法优化脉冲神经网络中，重点是网络信息的稳态表征、基于能量最优的网络优化、多模态时空信息融合等。在这些方面的研究可以追溯到液体状态机 (LSM)。该网络由输入端、隐层状态机和输出端构成。只有输出端的权重部分需要监督调整，来指导网络实现特定功能的学习（如分类^[135]、预测^[136]、规划^[137]等）。隐层状态机则主要进行高维度的时空信息编码，或者利用可塑性来实现非监督的部分权重优化。这样特殊的监督-非监督优化分离的模式，使得 LSM 网络具有学习速度快、训练代价小、时空信息融合充分、硬件实现容易等特点。

具体的任务目标无关；后几层的突触可塑性变化更多的和具体任务强关联^[25, 26, 48, 87]。对于不同的任务类型，存在从宏观到微观、从输出到输入的反向信息调节（如多巴胺引导、SBP 可塑性传播、目标传播等），且将在不同的时间尺度发挥作用，如神经元内部时钟、网络层级时钟等。

4.1 基于微观尺度可塑性的 SNN 优化

微观尺度的网络复杂性表现在离子通道、突触、神经元等层面^[138, 139]。首先，信息经过不同突触后膜离子通道的选择性打开和关闭，实现信息的初步变换；进一步，信息在突触层面因为囊泡释放、线粒体供能等限制，分别表现出短时突触可塑性、长时突触可塑性等不同机理的动态信息变换；然后，经过神经元胞体模型的非线性变换，将连续信号转换为非连续的、不可微分的脉冲膜电势信号。经过这些步骤，信息将至少经历门控、积分、二值化、非线性衰减、时延等步骤，使得 SNN 在微观尺度上展现出具有复杂动力学特点的信息处理能

力^[140]。

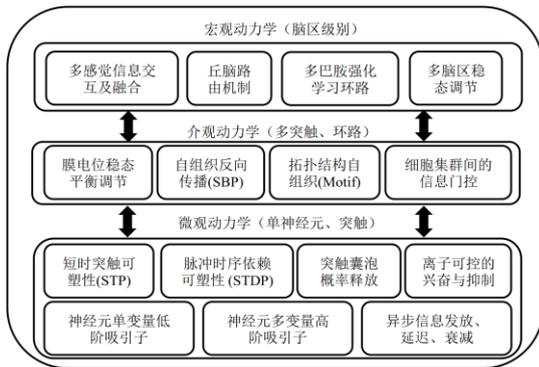


图 6 通过多尺度动力学实现的不同可塑性机制

生物网络自身优化依靠的是不同尺度的生物可塑性。STDP^[31]、STP^[26]、Reward-STDP^[83]、Dale 准则等都可以视为微观尺度可塑性，重点描述发生在单个神经元或者单个突触位点上的学习特性，这个尺度的规则在生物实验中较容易测得，因此种类数量也是最多。其他相关或不同尺度的突触可塑性学习法则如图 6 所示。神经元结构和突触结构会随着自身的放电活动情况的不同而发生微观尺度的神经可塑性变化，这些变化是非监督的，因此网络习得的是一种数据内部信息关联的稳态表征，和具体应用任务无关。

4.2 基于介观尺度可塑性的 SNN 优化

介观尺度的网络复杂性多表现在微环路级别，描述的是多个突触、多个神经元之间的相互关系，如侧抑制、自组织反向传播 (SBP)、多神经元之间的稳态控制等。

我们之前的工作对这些方面展开了部分研究，如论文^[25]中，提出了一种基于神经稳态的 SNN 学习方法，将局部的神经元输入和输出的稳态差异，扩展到全局的能量函数，最终通过优化全局能量函数最优，来实现单个节点的输入输出信息平稳。论文^[48]中，对海马区的亚区如 DG、CA3、CA1 等建模，分别构建层级、环状两个 SNN 子网络，探讨了信息经过层级信息处理后的信息降维 (DG)、经过环状网络信息处理后的知识存储和提取 (CA3)，以及经过加权网络后的分类功能输出 (CA1) 等。三个亚区经过分别训练并融合后的 SNN 网络可以实现对 NAO 机器人实时观测到的带噪声图片的稳定脉冲序列表征及高精度分类。论文^[87]中，针对 SNN 训练需要耗费大量样本的实际情况，设计出基于好奇心的 SNN 优化算法，通过加入可学习的好奇阈值，指导 SNN 网络动态的学习并区分哪些是常见而非重要的样本、哪些是重要但是数量较少的

样本，通过结合上述的稳态调控，最终达到了低能耗、快速学习的目的。

4.3 基于宏观尺度可塑性的 SNN 优化

宏观尺度的网络复杂性，表现在功能依赖的特定性脑区环路建立、多脑区结构复用、功能协同、自上至下的信度分配等。在这个尺度上，信息经过基础的微观和介观尺度的信息处理，通过组合不同的微环路，形成可以对某项具体认知任务起作用的功能性信息处理回路。图 5 给出了一种多尺度 SNN 的建模示例，其中神经元、网络的不同时钟结构是 SNN 的重要特色之一。

遗憾的是，在生物网络的全局信息信度分配方面，还没有发现类似人工网络中 BP 一样高效的全局优化方法。一种观点认为，在生物体的遗传和后期发育阶段就完成了大部分全局尺度的结构和功能优化，后期主要依靠小部分微观 (如 STDP) 和介观 (如 SBP) 的优化法则微调。另一种观点认为，类似于多巴胺的小分子可以通过强化学习^[141]环路实现对全局信息的有效调控，主要作用于基底神经节等相关脑区，通过丘脑的路由机制影响到其它脑区，如前额叶、丘脑、海马等^[142]。还有一种观点认为，生物网络中无处不在的背景“噪声”，也是宏观尺度有助于 SNN 学习的有效指导信号。如对 SNN 网络中加入“噪声”扰动，将提高 SNN 的运算性能及鲁棒性。且“噪声”的影响是全方面的，可以发生在放电阈值^[143]，也可以是神经活动的随机干扰 (如泊松噪声扰动、均匀噪声扰动等)^[15]。全局背景噪声的类型、产生的生物机制和作用还在进一步研究中。

除此之外，一些针对 BP 的变革方法，正在使得 BP 朝向更加类生物、更加节能高效的方向发展，这些努力可以理解为从人工智能到生物机理的反向启发。

如目标传播 (TP)^[98, 144]，力图逐步的减弱 BP 过程中对于各个梯度计算子部分的强限制，如必须函数处处可微分、梯度求导矩阵要和前馈矩阵对称 (Weight Transport Problem)、误差只能从网络输出层逐层反向传递到输入层等。随机反馈校准 (Feedback Alignment, FA)^[145]和差异目标传播 (Difference Target Propagation, DTP)^[146]突破了梯度反传矩阵和前馈矩阵必须要对称的限制，且可以用随机的矩阵来代替对称矩阵实现反馈过程中的直接梯度传递。进一步的，直接反馈校准 (Direct Feedback Alignment, DFA)^[147]、直接差异目标传播

(Direct Difference Target Propagation, DDTP) 和直接随机目标校准 (Direct Random Target Propagation, DRTP) [24]等, 描述了校准过程可以不用逐层反向传播, 而是输出误差可以直接通过随机矩阵传递到每个输入隐层, 有效的防止了梯度消失和梯度爆炸的问题。这些改进的 BP 优化方法 [104] 也将为 SNN 宏观尺度的可塑性优化带来新思路, 同时也为生物网络本身是否存在类似的直接目标传播给出了可能的生物探索新方向 [23]。

基于能量函数和误差函数的组合优化, 也是实现宏观尺度全局优化的有效途径。如论文 [27] 提出了网络的稳态传播模型, 通过 Sleep phase 和 Wake phase 的交替进行, 在 Sleep phase 过程中实现能量稳定传播, 在 Wake phase 过程中实现网络误差传递。通过在稳定和学习中逐步调整网络活动状态, 并最终通过类似微分 Hebb 机制来将习得的知识从网络活动中固化到突触权值中。此项工作也给了我们很大的启发, 并最终设计实现基于稳态控制的脉冲神经网络优化模型 [25]。

宏观尺度的网络优化也和网络结构高度相关, 实验结果发现, 特异性的 Motif 类型和特定的网络功能高度相关: 如 Mangan 发现前馈 Motif 的结构类型和信息抽取功能高度相关 [148]; Sporns 发现神经网络中不同区域的 Motif 分布和不同脑区的功能之间具有较为紧密的联系 [52] 等。我们之前的工作中 [47], 也描述了一种鼠脑全脑尺度的 Motif 计算方法, 该方法可以将不同的功能脑区、功能环路中的微观尺度 Motif 提取出来, 并离散化为 13 类不同的 Motif 分布, 通过构建类似的 Motif 分布, 可以增加对原有的脑区的功能的理解, 也和已有的生物网络的统计发现保持了一致 [149], 如海马网络的循环连接模式较为突出, 其对应的循环 Motif 连接模式比例较高。因此, 采用 Motif 指导 SNN 的网络结构构建, 将可以最大限度的将生物的网络特性基础迁移到人工网络中, 方便研究各类网络的异同和对生物智能计算的本质贡献。

上述这些方法从功能和结构等方面入手, 都在使得宏观尺度的脉冲网络优化思路越来越清晰, 慢慢朝向高效且生物合理的优化方向发展。未来, 随着越来越多的多尺度生物结构约束或功能启发机

制加入进来, SNN 中的信度分配将有可能有效覆盖全部网络输出、网络隐层状态、局部神经节点等, 为实现更加复杂、更加智能的新一代人工神经网络提供生物启发的优化理论支撑。

5 总结及展望

脉冲神经网络 (Spiking Neural Network, SNN) 包含具有时序动力学特性的神经元节点、稳态-可塑性平衡的突触结构、功能特异性的网络环路等, 高度借鉴了生物启发的局部非监督 (如脉冲时序依赖可塑性)、全局弱监督 (如多巴胺奖赏学习) 的生物优化方法, 具有较强的非线性时空计算、异步时序事件信息处理、自组织学习、低能耗计算等特点。

脉冲神经网络独特的信息编码模式, 将启发现有的人工神经网络逐步从以网络环路为重心, 到节点-环路并重的编码方向发展。生物神经元的膜电位编码符合动力学特性, 不同类型的神经元具有功能特异性, 因此, 也可以参考不同脑区、不同功能环路的主要神经元类型, 来定制化的构建符合特定期望功能的脉冲神经元模型, 并以此来增强人工神经网络编码的有效性。具有动力学优势的神经元将表现出相对传统神经元更大的信息容量, 可在节点内部存储更多的历史状态信息, 对研究网络的短时记忆、工作记忆等都将有极大的帮助。

另一方面, 脉冲神经网络独特的基于可塑性的优化方法, 将启发人工神经网络从单一的函数拟合逐步过渡到通用的认知计算。

现有的人工神经网络, 主要特点是“重拟合”而“轻认知”。随着神经网络的拟合能力越来越强, 人们对于模型智能水平的评价呈现了从低到高再变低的过程。当人工网络的拟合能力达到极致、甚至超过了人类单一任务的最高水平, 人工神经网络的诸多认知相关的问题便逐渐凸显: 如增量学习能力差; 鲁棒性差, 特别对噪声或者通过对抗网络学习到的对抗图片的攻击无能为力; 认知能力差, 不能自组织理解复杂背景, 不能根据抽象运动轨迹高效联想复杂行为动作等。

这些问题出现的主要原因之一, 在于人工神经网络的设计之初, 从网络结构到学习方法等都是根据单一的以性能最优为目标来学习的, 因此往往在实际应用的过程中, 展现出很多的反常识、不类人、不智能的识别结果。

通过借鉴多尺度可塑性机制, 特别是微观和介

观尺度的自组织学习, 脉冲神经网络可以同时满足生物的结构和功能约束, 并逐步在类人水平的认知能力方面取得进步。

脉冲神经网络将不会拘泥于生物计算本身, 还将从已有的深度学习、最优化理论等方面获得启发, 如高效的 BP、TP、强化学习、遗传演化等全局优化方法。在数学理论层面, 探讨生物计算和人工计算深度融合的可能, 因此, 脉冲神经网络的发展目标不是构建人工神经网络的生物版本替代品, 而是通过脉冲神经网络的优化理论突破, 为构建下一代具有认知特色的高效人工智能模型奠定理论基础, 在神经动力学、自组织学习、多模态时空信息融合、鲁棒信息表征等方面取得突破进展。另一方面, 脉冲神经网络的有效优化理论的建立, 还将反向启发生命科学中的科学发现, 如有关学习记忆的可塑性机制、长程连接的作用机制、多脑区信息协同的机制等。

参 考 文 献

- [1] Henry M. The human brain project. *Scientific American*, 2012, 306(6): 50-55.
- [2] Helmstaedter M. The mutual inspirations of machine learning and neuroscience. *Neuron*, 2015, 86(1): 25-28.
- [3] McCulloch W S, Pitts W. A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 1943, 5(4): 115-133.
- [4] Rosenblatt F. The perceptron, a perceiving and recognizing automaton project para. Cornell Aeronautical Laboratory, 1957.
- [5] Hopfield J J. Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences of the United States of America*, 1982, 79(8): 2554-2558.
- [6] Hinton G E, Sejnowski T J. Optimal perceptual inference//*Proceedings of The IEEE Conference on Computer Vision and Pattern Recognition*. Washington, D.C, USA, 1983.
- [7] Rumelhart D E, Hinton G E, Williams R J. Learning representations by back-propagating errors. *Nature*, 1986, 323(6088): 533-536.
- [8] Fukushima K. Neocognitron: A self organizing neural network model for a mechanism of pattern recognition unaffected by shift in position. *Biological Cybernetics*, 1980, 36(4): 193-202.
- [9] Lecun Y, Boser B, Denker J S, et al. Backpropagation applied to handwritten zip code recognition. *Neural Computation*, 1989, 1(4): 541-551.
- [10] Maass W. Networks of spiking neurons: The third generation of neural network models. *Neural Networks*, 1997, 10(9): 1659-1671.
- [11] Hinton G E, Osindero S, Teh Y W. A fast learning algorithm for deep belief nets. *Neural Computation*, 2006, 18(7): 1527-1554.
- [12] Krizhevsky A, Sutskever I, Hinton G E. Imagenet classification with deep convolutional neural networks. *Communications of the Acm*, 2017, 60(6): 84-90.
- [13] Sze V, Chen Y H, Yang T J, et al. Efficient processing of deep neural networks: A tutorial and survey. *Proceedings of the IEEE*, 2017, 105(12): 2295-2329.
- [14] Izhikevich E M. Simple model of spiking neurons. *IEEE Trans Neural Netw*, 2003, 14(6): 1569-1572.
- [15] Zeng Y, Zhang T L, Xu B. Improving multi-layer spiking neural networks by incorporating brain-inspired rules. *Science China-Information Sciences*, 2017, 60(5): 052201.
- [16] Izhikevich E M. Which model to use for cortical spiking neurons? *IEEE Trans Neural Netw*, 2004, 15(5): 1063-1070.
- [17] Gutig R, Sompolinsky H. The tempotron: A neuron that learns spike timing-based decisions. *Nature Neuroscience*, 2006, 9(3): 420-428.
- [18] Abbott L F, Depasquale B, Memmesheimer R M. Building functional networks of spiking model neurons. *Nature Neuroscience*, 2016, 19(3): 350-355.
- [19] Hebb D O. *The organization of behavior: A neuropsychological theory*. J. Wiley; Chapman & Hall, 1949.
- [20] Bi G Q, Poo M M. Synaptic modifications in cultured hippocampal neurons: Dependence on spike timing, synaptic strength, and postsynaptic cell type. *Journal of Neuroscience*, 1998, 18(24): 10464-10472.
- [21] Dan Y, Poo M M. Spike timing-dependent plasticity: From synapse to perception. *Physiological Reviews*, 2006, 86(3): 1033-1048.
- [22] Bi G, Poo M. Synaptic modification by correlated activity: Hebb's postulate revisited. *Annual Review of Neuroscience*, 2001, 24(1): 139-166.
- [23] Lillicrap T P, Santoro A, Marris L, et al. Backpropagation and the brain. *Nature Reviews: Neuroscience*, 2020, 21(6): 335-346.
- [24] Frenkel C, Lefebvre M, Bol D. Learning without

- feedback: Direct random target projection as a feedback-alignment algorithm with layerwise feedforward training. arXiv: Machine Learning, 2019.
- [25] Zhang T, Zeng Y, Shi M, et al. A plasticity-centric approach to train the non-differential spiking neural networks//Proceedings of The National Conference on Artificial Intelligence. New Orleans, Louisiana, USA, 2018.
- [26] Zhang T, Zeng Y, Zhao D, et al. Brain-inspired balanced tuning for spiking neural networks//Proceedings of The International Joint Conferences on Artificial Intelligence. Stockholm, Sweden, 2018.
- [27] Scellier B, Bengio Y. Equilibrium propagation: Bridging the gap between energy-based models and backpropagation. *Frontiers in Computational Neuroscience*, 2017, 11: 24.
- [28] Moore J J, Ravassard P M, Ho D, et al. Dynamics of cortical dendritic membrane potential and spikes in freely behaving rats. *Science*, 2017, 355(6331).
- [29] Hao Y, Huang X, Dong M, et al. A biologically plausible supervised learning method for spiking neural networks using the symmetric stdp rule. *Neural Networks*, 2020, 121: 387-395.
- [30] Iakymchuk T, Rosado-Munoz A, Guerrero-Martinez J F, et al. Simplified spiking neural network architecture and stdp learning algorithm applied to image classification. *Eurasip Journal on Image and Video Processing*, 2015, 2015(1): 4.
- [31] Kheradpisheh S R, Ganjtabesh M, Thorpe S J, et al. Stdp-based spiking deep convolutional neural networks for object recognition. *Neural Networks*, 2018, 99: 56-67.
- [32] Bengio Y, Mesnard T, Fischer A, et al. Stdp-compatible approximation of backpropagation in an energy-based model. *Neural Computation*, 2017, 29(3): 555-577.
- [33] Diehl P U, Cook M. Unsupervised learning of digit recognition using spike-timing-dependent plasticity. *Frontiers in Computational Neuroscience*, 2015, 9: 99.
- [34] Mozafari M, Ganjtabesh M, Nowzari-Dalini A, et al. Bio-inspired digit recognition using reward-modulated spike-timing-dependent plasticity in deep convolutional networks. *Pattern Recognition*, 2019, 94: 87-95.
- [35] Bing Z, Meschede C, Rohrbein F, et al. A survey of robotics control based on learning-inspired spiking neural networks. *Frontiers in Neurorobotics*, 2018, 12: 35.
- [36] Xie X, Seung H S. Spike-based learning rules and stabilization of persistent neural activity//Proceedings of The Annual Conference on Neural Information Processing Systems. Denver, CO, USA, 2000.
- [37] Romani S, Tsodyks M. Short-term plasticity based network model of place cells dynamics. *Hippocampus*, 2015, 25(1): 94-105.
- [38] Traub M, Butz M, Baayen R H, et al. Learning precise spike timings with eligibility traces. arXiv, 2020, abs/2006.09988.
- [39] Lin X, Wang X. Principle and application of spiking neural networks. Science Press, 2018 (In Chinese). (蔺想红, 王向文. 脉冲神经网络原理及应用. 科学出版社. 2018).
- [40] Tovee M J, Rolls E T. Information encoding in short firing rate epochs by single neurons in the primate temporal visual cortex. *Visual Cognition*, 1995, 2(1): 35-58.
- [41] Hu J, Tang H, Tan K C, et al. A spike-timing-based integrated model for pattern recognition. *Neural Computation*, 2013, 25(2): 450-472.
- [42] Schrauwen B, Van Campenhout J. Bsa, a fast and accurate spike train encoding scheme. Proceedings of the International Joint Conference on Neural Networks 2003, Vols 1-4, 2003, 4: 2825-2830.
- [43] Almomani A, Alauthman M, Alweshah M, et al. A comparative study on spiking neural network encoding schema: Implemented with cloud computing. *Cluster Computing-the Journal of Networks Software Tools and Applications*, 2019, 22(2): 419-433.
- [44] Gilson M, Masquelier T, Hugues E. Stdp allows fast rate-modulated coding with poisson-like spike trains. *PLoS Computational Biology*, 2011, 7(10): e1002231.
- [45] Stomatias E, Soto M, Serrano-Gotarredona T, et al. An event-driven classifier for spiking neural networks fed with synthetic or dynamic vision sensor data. *Frontiers in Neuroscience*, 2017, 11: 350.
- [46] Pouget A, Dayan P, Zemel R. Information processing with population codes. *Nature Reviews: Neuroscience*, 2000, 1(2): 125-132.
- [47] Zhang T, Zeng Y, Xu B. A computational approach towards the microscale mouse brain connectome from the mesoscale. *Journal of Integrative Neuroscience*, 2017, 16(3): 291-306.
- [48] Zhang T, Zeng Y, Zhao D, et al. Hmsnn: Hippocampus inspired memory spiking neural network//Proceedings of The IEEE International Conference on Systems, Man, and Cybernetics. Budapest, Hungary, 2016.
- [49] Neymotin S A, Lee H, Park E, et al. Emergence of physiological oscillation frequencies in a computer model of

- neocortex. *Frontiers in Computational Neuroscience*, 2011, 5: 19.
- [50] Shen K, Bezgin G, Hutchison R M, et al. Information processing architecture of functionally defined clusters in the macaque cortex. *Journal of Neuroscience*, 2012, 32(48): 17465-17476.
- [51] Shen-Orr S S, Milo R, Mangan S, et al. Network motifs in the transcriptional regulation network of *Escherichia coli*. *Nature Genetics*, 2002, 31(1): 64-68.
- [52] Sporns O, Kotter R. Motifs in brain networks. *PLoS Biology*, 2004, 2(11): e369.
- [53] Milo R, Itzkovitz S, Kashtan N, et al. Superfamilies of evolved and designed networks. *Science*, 2004, 303(5663): 1538-1542.
- [54] Halassa M M, Sherman S M. Thalamocortical circuit motifs: A general framework. *Neuron*, 2019, 103(5): 762-770.
- [55] Masoudi-Nejad A, Schreiber F, Kashani Z R. Building blocks of biological networks: A review on major network motif discovery algorithms. *IET Systems Biology*, 2012, 6(5): 164-174.
- [56] Silver D, Huang A, Maddison C J, et al. Mastering the game of Go with deep neural networks and tree search. *Nature*, 2016, 529(7587): 484-489.
- [57] Boybat I, Le Gallo M, Nandakumar S R, et al. Neuromorphic computing with multi-memristive synapses. *Nat Commun*, 2018, 9(1): 2514.
- [58] Chakraborty S, Tomsett R, Raghavendra R, et al. Interpretability of deep learning models: A survey of results. *The IEEE Smartworld*, 2017: 1-6.
- [59] Srivastava N, Hinton G, Krizhevsky A, et al. Dropout: A simple way to prevent neural networks from overfitting. *Journal of Machine Learning Research*, 2014, 15(1): 1929-1958.
- [60] Xu C Y, Lu C Y, Liang X D, et al. Multi-loss regularized deep neural network. *Ieee Transactions on Circuits and Systems for Video Technology*, 2016, 26(12): 2273-2283.
- [61] Kirkpatrick J, Pascanu R, Rabinowitz N, et al. Overcoming catastrophic forgetting in neural networks. *Proceedings of the National Academy of Sciences of the United States of America*, 2017, 114(13): 3521-3526.
- [62] Nguyen A, Yosinski J, Clune J. Deep neural networks are easily fooled: High confidence predictions for unrecognizable images. *Proceedings of Computer Vision and Pattern Recognition*. Boston, MA, USA, 2015.
- [63] Heaven D. Why deep-learning aIs are so easy to fool. *Nature*, 2019, 574(7777): 163-166.
- [64] Su J, Vargas D V, Sakurai K. One pixel attack for fooling deep neural networks. *IEEE Transactions on Evolutionary Computation*, 2019, 23(5): 828-841.
- [65] Cheng X, Hao Y, Xu J, et al. Lisnn: Improving spiking neural networks with lateral interactions for robust object recognition. 2020: 1519-1525.
- [66] Zhang T, Zeng Y, Xu B. Hcnn: A neural network model for combining local and global features towards human-like classification. *International Journal of Pattern Recognition and Artificial Intelligence*, 2015, 30(01): 1655004.
- [67] Deneve S, Machens C K. Efficient codes and balanced networks. *Nature Neuroscience*, 2016, 19(3): 375-382.
- [68] Beyeler M, Dutt N D, Krichmar J L. Categorization and decision-making in a neurobiologically plausible spiking network using a stdp-like learning rule. *Neural Networks*, 2013, 48: 109-124.
- [69] Tavanaei A, Maida A. Bp-stdp: Approximating backpropagation using spike timing dependent plasticity. *Neurocomputing*, 2019, 330: 39-47.
- [70] Zenke F, Agnes E J, Gerstner W. Diverse synaptic plasticity mechanisms orchestrated to form and retrieve memories in spiking neural networks. *Nature Communications*, 2015, 6: 6922.
- [71] Yang G R, Murray J D, Wang X-J. A dendritic disinhibitory circuit mechanism for pathway-specific gating. *Nature Communications*, 2016, 7.
- [72] Catsigeras E. Dale's principle is necessary for an optimal neuronal network's dynamics. *Applied Mathematics*, 2013, 04(10): 15-29.
- [73] Vogels T P, Sprekeler H, Zenke F, et al. Inhibitory plasticity balances excitation and inhibition in sensory pathways and memory networks. *Science*, 2011, 334(6062): 1569-1573.
- [74] Song H F, Yang G R, Wang X J. Training excitatory-inhibitory recurrent neural networks for cognitive tasks: A simple and flexible framework. *PLoS Computational Biology*, 2016, 12(2): e1004792.
- [75] Zhao F, Zhang T, Zeng Y, et al. Towards a brain-inspired developmental neural network by adaptive synaptic pruning. *Proceedings of The International Conference on Neural Information Processing*. Guangzhou, China, 2017.
- [76] Frankfurt M, Luine V. The evolving role of dendritic

- spines and memory: Interaction(s) with estradiol. *Hormones and Behavior*, 2015, 74: 28-36.
- [77] Whittington J C R, Bogacz R. Theories of error back-propagation in the brain. *Trends in Cognitive Sciences*, 2019, 23(3): 235-250.
- [78] Yu Q, Tang H, Tan K C, et al. Precise-spike-driven synaptic plasticity: Learning hetero-association of spatiotemporal spike patterns. *PloS One*, 2013, 8(11): e78318.
- [79] Yu Q, Yan R, Tang H, et al. A spiking neural network system for robust sequence recognition. *IEEE Trans Neural Netw Learn Syst*, 2016, 27(3): 621-635.
- [80] Struye J, Latre S. Hierarchical temporal memory and recurrent neural networks for time series prediction: An empirical validation and reduction to multilayer perceptrons. *Neurocomputing*, 2020, 396: 291-301.
- [81] Rodriguez M A, Kotagiri R, Buyya R. Detecting performance anomalies in scientific workflows using hierarchical temporal memory. *Future Generation Computer Systems-the International Journal of Escience*, 2018, 88: 624-635.
- [82] Wu J, Zeng W R, Yan F. Hierarchical temporal memory method for time-series-based anomaly detection. *Neurocomputing*, 2018, 273: 535-546.
- [83] Mozafari M, Ganjtabesh M, Nowzari-Dalini A, et al. Spyketorch: Efficient simulation of convolutional spiking neural networks with at most one spike per neuron. *Frontiers in Neuroscience*, 2019, 13: 625.
- [84] Dong M, Huang X, Xu B. Unsupervised speech recognition through spike-timing-dependent plasticity in a convolutional spiking neural network. *PloS One*, 2018, 13(11): e0204596.
- [85] Wade J J, Mcdaid L J, Santos J A, et al. Swat: A spiking neural network training algorithm for classification problems. *IEEE Trans Neural Netw*, 2010, 21(11): 1817-1830.
- [86] Xiang Cheng T Z, Shuncheng Jia and Bo Xu. Finite meta-dynamic neurons in spiking neural networks for spatio-temporal learning. *arXiv*, 2020, cs.NE: 2010.03140.
- [87] Shi M, Zhang T, Zeng Y. A curiosity-based learning method for spiking neural networks. *Frontiers in Computational Neuroscience*, 2020, 14: 7.
- [88] Ponulak F, Kasinski A. Supervised learning in spiking neural networks with resume: Sequence learning, classification, and spike shifting. *Neural Computation*, 2010, 22(2): 467-510.
- [89] Wysoski S G, Benuskova L, Kasabov N. Fast and adaptive network of spiking neurons for multi-view visual pattern recognition. *Neurocomputing*, 2008, 71(13-15): 2563-2575.
- [90] Querlioz D, Bichler O, Dollfus P, et al. Immunity to device variations in a spiking neural network with memristive nanodevices. *IEEE Transactions on Nanotechnology*, 2013, 12(3): 288-295.
- [91] Tielin Z, Shuncheng J, Xiang C, et al. Tuning convolutional spiking neural network with biologically-plausible reward propagation. *arXiv*, 2020.
- [92] Diehl P U, Neil D, Binas J, et al. Fast-classifying, high-accuracy spiking deep networks through weight and threshold balancing//*Proceedings of The International Symposium on Neural Networks*. Jeju, South Korea, 2015.
- [93] Zhang W, Li P. Spike-train level backpropagation for training deep recurrent spiking neural networks//*Proceedings of The Neural Information Processing Systems*. Vancouver Canada 2019.
- [94] Sengupta A, Ye Y, Wang R, et al. Going deeper in spiking neural networks: Vgg and residual architectures. *Frontiers in Neuroscience*, 2019, 13: 95.
- [95] Zhang Y, Li P, Jin Y, et al. A digital liquid state machine with biologically inspired learning and its application to speech recognition. *IEEE Trans Neural Netw Learn Syst*, 2015, 26(11): 2635-2649.
- [96] Wu J, Chua Y, Zhang M, et al. A spiking neural network framework for robust sound classification. *Frontiers in Neuroscience*, 2018, 12: 836.
- [97] Zenke F, Ganguli S. Superspike: Supervised learning in multilayer spiking neural networks. *Neural Computation*, 2018, 30(6): 1514-1541.
- [98] Huh D, Sejnowski T J. Gradient descent for spiking neural networks//*Proceedings of The Neural Information Processing Systems*. Montreal, Canada, 2018.
- [99] O'connor P, Welling M. Deep spiking networks. *arXiv preprint arXiv:160208323*, 2016.
- [100] Shrestha A, Fang H, Wu Q, et al. Approximating back-propagation for a biologically plausible local learning rule in spiking neural networks//*Proceedings of The International Conference on Neuromorphic Systems*. Knoxville, USA, 2019.
- [101] Woźniak S, Pantazi A, Bohnstingl T, et al. Deep learning incorporating biologically inspired neural dynamics and in-memory computing. *Nature Machine Intelligence*, 2020, 2(6): 325-336.

- [102] Lee J H, Delbruck T, Pfeiffer M. Training deep spiking neural networks using backpropagation. *Frontiers in Neuroscience*, 2016, 10.
- [103] Tavanaei A, Ghodrati M, Kheradpisheh S R, et al. Deep learning in spiking neural networks. *Neural Networks*, 2019, 111: 47-63.
- [104] Bellec L, Bonavita M C, Hourdez S, et al. Chemosynthetic ectosymbionts associated with a shallow-water marine nematode. *Scientific Reports*, 2019, 9(1): 7019.
- [105] Wu Y, Deng L, Li G, et al. Spatio-temporal backpropagation for training high-performance spiking neural networks. *Frontiers in Neuroscience*, 2018, 12.
- [106] Shrestha S B, Orchard G. Slayer: Spike layer error reassignment in time//*Proceedings of The Neural Information Processing Systems*. Montreal, Canada, 2018.
- [107] Rueckauer B, Lungu I A, Hu Y, et al. Conversion of continuous-valued deep networks to efficient event-driven networks for image classification. *Frontiers in Neuroscience*, 2017, 11: 682.
- [108] Cao Y Q, Chen Y, Khosla D. Spiking deep convolutional neural networks for energy-efficient object recognition. *International Journal of Computer Vision*, 2015, 113(1): 54-66.
- [109] Federici D. A regenerating spiking neural network//*Proceedings of The IEEE International Joint Conference on Neural Networks*. Montreal, Canada, 2005.
- [110] Shayani H, Bentley P J, Tyrrell A M. A multi-cellular developmental representation for evolution of adaptive spiking neural microcircuits in an fpga//*Proceedings of The Adaptive Hardware and Systems*. San Francisco, California, USA, 2009.
- [111] David Schaffer J. Evolving spiking neural networks: A novel growth algorithm corrects the teacher. *The IEEE Symposium on Computational Intelligence for Security and Defense Applications*, 2015: 1-8.
- [112] Wang Z, Ma Y, Cheng F, et al. Review article: Review of pulse-coupled neural networks. *Image and Vision Computing*, 2010, 28(1): 5-13.
- [113] Marblestone A H, Wayne G, Kording K P. Toward an integration of deep learning and neuroscience. *Frontiers in Computational Neuroscience*, 2016, 10: 94.
- [114] Bohte S M, Kok J N, Poutre J A. Spikeprop: Backpropagation for networks of spiking neurons//*Proceedings of The European Symposium on Artificial Neural Networks*. Bruges, Belgium, 2000.
- [115] Mckennoch S, Liu D, Bushnell L. Fast modifications of the spikeprop algorithm//*Proceedings of The IEEE International Joint Conference on Neural Network*. Vancouver, BC, Canada, 2006.
- [116] Migliore M, Cannia C, Lytton W W, et al. Parallel network simulations with neuron. *Journal of Computational Neuroscience*, 2006, 21(2): 119-129.
- [117] Plesser H E, Diesmann M, Gewaltig M-O, et al. Nest: The neural simulation tool. 2013: 1-4.
- [118] Zenke F, Gerstner W. Limits to high-speed simulations of spiking neural networks using general-purpose computers. *Frontiers in Neuroinformatics*, 2014, 8: 76.
- [119] Hazan H, Saunders D J, Khan H, et al. Bindsnet: A machine learning-oriented spiking neural networks library in python. *Frontiers in Neuroinformatics*, 2018, 12: 89.
- [120] Davison A P, Bruderle D, Eppler J, et al. Pynn: A common interface for neuronal network simulators. *Frontiers in Neuroinformatics*, 2008, 2: 11.
- [121] Stimberg M, Brette R, Goodman D F. Brian 2, an intuitive and efficient neural simulator. *Elife*, 2019, 8.
- [122] Amir A, Taba B, Berg D, et al. A low power, fully event-based gesture recognition system//*Proceedings of The IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu, HI, USA, 2017.
- [123] Li H, Liu H, Ji X, et al. Cifar10-dvs: An event-stream dataset for object classification. *Frontiers in Neuroscience*, 2017, 11: 309.
- [124] Orchard G, Jayawant A, Cohen G K, et al. Converting static image datasets to spiking neuromorphic datasets using saccades. *Frontiers in Neuroscience*, 2015, 9: 437.
- [125] Yavuz E, Turner J, Nowotny T. Genn: A code generation framework for accelerated brain simulations. *Scientific Reports*, 2016, 6: 18854.
- [126] Bekolay T, Bergstra J, Hunsberger E, et al. Nengo: A python tool for building large-scale functional brain models. *Frontiers in Neuroinformatics*, 2014, 7: 48.
- [127] Yao P, Wu H, Gao B, et al. Face classification using electronic synapses. *Nature Communications*, 2017, 8: 15199.
- [128] Ji Y, Zhang Y H, Li S C, et al. Neutrams: Neural network transformation and co-design under neuromorphic hardware constraints//*Proceedings of The Annual IEEE/ACM International Symposium on Microarchitecture*. Taipei, Taiwan, 2016.
- [129] Pei J, Deng L, Song S, et al. Towards artificial general intelligence with hybrid tianjic chip architecture. *Nature*, 2019,

- 572(7767): 106-111.
- [130] Diehl P U, Pedroni B U, Cassidy A, et al. Truehappiness: Neuromorphic emotion recognition on truenorth//Proceedings of The International Joint Conference on Neural Networks. Vancouver, BC, Canada, 2016.
- [131] Sawada J, Akopyan F, Cassidy A S, et al. Truenorth ecosystem for brain-inspired computing: Scalable systems, software, and applications//Proceedings of The International Conference for High Performance Computing, Networking, Storage and Analysis. Denver Colorado, USA, 2016.
- [132] Khodagholy D, Gelinis J N, Zhao Z, et al. Organic electronics for high-resolution electrocorticography of the human brain. *Science Advances*, 2016, 2(11): e1601027.
- [133] Wang J F, Tian H H, Fang Y. Implantable and flexible electronics for in vivo brain activity recordings. *Chinese Journal of Analytical Chemistry*, 2019, 47(10): 1549-1558.
- [134] Davies M, Srinivasa N, Lin T-H, et al. Loihi: A neuromorphic manycore processor with on-chip learning. *IEEE Micro*, 2018, 38(1): 82-99.
- [135] Teeter C, Iyer R, Menon V, et al. Generalized leaky integrate-and-fire models classify multiple neuron types. *Nature Communications*, 2018, 9(1): 709.
- [136] Gutig R. Spiking neurons can discover predictive features by aggregate-label learning. *Science*, 2016, 351(6277): aab4113.
- [137] Rueckert E, Kappel D, Tanneberg D, et al. Recurrent spiking networks solve planning tasks. *Scientific Reports*, 2016, 6: 21142.
- [138] Huang Z J, Paul A. The diversity of gabaergic neurons and neural communication elements. *Nature Reviews: Neuroscience*, 2019, 20(9): 563-572.
- [139] Ecker J R, Geschwind D H, Kriegstein A R, et al. The brain initiative cell census consortium: Lessons learned toward generating a comprehensive brain cell atlas. *Neuron*, 2017, 96(3): 542-557.
- [140] Brendel W, Bourdoukan R, Vertech P, et al. Learning to represent signals spike by spike. *PLoS Computational Biology*, 2020, 16(3): e1007692.
- [141] Seung H S. Learning in spiking neural networks by reinforcement of stochastic synaptic transmission. *Neuron*, 2003, 40(6): 1063-1073.
- [142] Zhao F F, Zeng Y, Wang G X, et al. A brain-inspired decision making model based on top-down biasing of prefrontal cortex to basal ganglia and its application in autonomous uav explorations. *Cognitive Computation*, 2018, 10(2): 296-306.
- [143] Zhang M L, Qu H, Xie X R, et al. Supervised learning in spiking, neural networks with noise-threshold. *Neurocomputing*, 2017, 219: 333-349.
- [144] Bengio Y. How auto-encoders could provide credit assignment in deep networks via target propagation. *Computer Science*, 2014.
- [145] Lillicrap T P, Cownden D, Tweed D B, et al. Random synaptic feedback weights support error backpropagation for deep learning. *Nature Communications*, 2016, 7(1): 13276.
- [146] Lee D, Zhang S, Fischer A, et al. Difference target propagation//Proceedings of The European Conference on Machine Learning. Porto, Portugal, 2015.
- [147] Nokland A. Direct feedback alignment provides learning in deep neural networks//Proceedings of The Neural Information Processing Systems. Barcelona, Spain, 2016.
- [148] Mangan S, Alon U. Structure and function of the feed-forward loop network motif. *Proceedings of the National Academy of Sciences of the United States of America*, 2003, 100(21): 11980-11985.
- [149] Witter M P. Connectivity of the hippocampus. Springer New York, 2010.



张铁林, 中国科学院自动化研究所, 副研究员。长期从事人工智能研究, 主要研究领域包括: 类脑智能, 脉冲神经网络优化, 类脑机器人。

E-mail: tielin.zhang@ia.ac.cn

联系电话: 15901091404

(ZHANG Tie-Lin, Associate Professor, Institute of Automation, Chinese Academy of Sciences. His main research interests include brain-inspired intelligence, spiking neural networks and brain-inspired robotics.)



徐波, 中国科学院自动化研究所所长, 研究员。中科院脑科学与智能技术卓越创新中心副主任。长期从事人工智能研究, 主要研究领域包括: 类脑智能, 类脑认知计算模型, 自然语言处理与理解, 类脑机器人。

E-mail: xubo@ia.ac.cn

(XU Bo, Professor, president of Institute of Automation, Chinese Academy of Sciences, and deputy director of the Center for Excellence in Brain Science and Intelligence Technology, Chinese Academy of Sciences. His main research interests include brain-inspired intelligence, brain-inspired cognitive models, natural language processing and understanding, brain-inspired robotics, etc.)

Background

This paper reviewed some traditional and state-of-the-art tuning methods in Spiking Neural Networks (SNNs). The research of SNNs covered different disciplines, including biology, computational neuroscience, Artificial Neural Networks (ANNs), and optimization theory. SNN is biologically-plausible and is considered the computationally-biological effort towards the next-generation of ANN models with brain-level intelligence. We think the multi-scale plasticity principles founded in the natural neural networks may cooperate well with each other during the unsupervised learning procedure of SNNs, and then integrate well with some state-of-the-art tuning methods from ANNs in the supervised learning procedure. The successful training of SNNs, especially with pure biologically-plausible multi-scale principles, will give us more hints and inspirations on how to design a smarter ANN model with more robust adaptability, smaller energy cost, and faster learning convergence. This research is supported by the National Natural Science Foundation of China (61806195), the Strategic Priority Research Program of the Chinese Academy of Sciences (XDBS01070000), and the Beijing Brain Science Project (Z181100001518006).