

脉冲神经网络研究现状及展望

张铁林¹⁾ 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) 被称为第三代人工神经网络, 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, 是一种局部非监督、全局弱监督的类生物网络, 具有强大的非线性计算、异步事件信息处理、自学习等能力。当前对 SNN 的研究可分为两大类: 一类以更好的理解生物系统为最终目的; 另一类以追求卓越计算性能为优化目标。本文将对当前这两大类 SNN 的研究进展及特点进行全面介绍。进一步的, 本文将从多尺度神经可塑性的角度出发, 同时借鉴生物系统的可塑性机制和当前人工神经网络的成熟优化方法, 探讨一种可能的融合优化策略。这将不仅为现有人工智能模型提高认知能力指明一种可能的优化方向, 还为反向促进生命科学中生物神经网络的研究发现提供启发。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, 而是通过脉冲神经网络的多尺度可塑性优化理论突破, 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, 使其有望获得更强的适应性、更小的能量消耗、更快的学习速度等。

关键词 脉冲神经网络; 人工神经网络; 类脑智能; 多尺度神经可塑性; 认知计算;

Research Advances and Perspectives on Spiking Neural Network

ZHANG Tie-Lin¹⁾, XU Bo^{1, 2, 3)}

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

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

³⁾ Center for Excellence in Brain Science and Intelligence Technology, CAS, Shanghai 200031, China.

Abstract Spiking Neural Network (SNN) is considered the third-generation of Artificial Neural Networks (ANNs), containing neurons with sequential dynamics, synapses with plastic stability, and circuits with specific cognitive functions. SNN is biologically-plausible, and might generally be tuned with the integration of local-scale unsupervised learning and global-scale weak supervised learning; hence, it is powerful on non-linear computation, asynchronously event-based information processing and self-learning. This paper will introduce two main classes of SNNs: one is proposed for a better understanding of the biological system; the other is constructed for efficient computation. We introduced an alternative tuning effort of SNN from the perspectives of multi-scale plasticity principles, by integrating the plasticity principles from the natural neural networks and the fine-tuning strategies from the current ANNs. These integrative principles would lead SNNs towards cognitive computation and give inspirations back to the new research findings in the natural neural networks. We think the

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)资助。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)。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。徐波 (通信作者), 男, 研究员, 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。

goal of SNN is not working as a biological version of ANN candidate, but construct a solid theoretical foundation for the next-generation artificial intelligence models with characteristics of cognitive computation by integrating breakthroughs in multi-scale plasticity principles. This effort might improve SNNs towards the more robust adaptability, smaller energy cost, and faster learning convergence.

Key words Spiking Neural Network; Artificial Neural Network; Brain-inspired Intelligence; Multi-scale Plasticity Principles; Cognitive Computation.


1 引言

随着脑科学研究和人工智能的快速发展,具有交叉学科特点的类脑智能研究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未来人工智能的发展方向,使得人工智能能够扩展、融合多种认知能力,逐步逼近类人水平的通用人工智能。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,对其结构基础、功能优化等方面的研究,将有助于我们更好的认识大脑、理解生物智能的本质并启发得到更新一代的人工智能模型。

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,是搭建脉冲神经元尺度的大规模脑模拟器并力图在下一代信息技术的类脑智能研究上获得突破。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智能特性的智能系统。2018 年,MIT 联合内部五大学院开展 Intelligence Quest

项目¹,核心研究点为机器学习算法,外延方向为通过计算机科学的见解来反向提高对生物脉冲网络功能的认识。以上这些计划的核心研究点之一就是学习和记忆的可塑性,而这也是生物脑智能中最重要的核心认知功能之一。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,大脑通过后天的再训练习得了越来越多的高级认知功能,如分类、识别、决策、记忆和联想等。正是“可塑性”使得人脑神经网络具有了强大的环境学习和再适应能力。因此,脉冲神经网络算法,将不可避免的要借鉴和学习人脑的多尺度的、多类型的可塑性认知机理及神经网络结构。

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稳步发展,一些具有里程碑意义的神经网络模型也被相继提出,如 1958 年的 Perceptron 感知机,1983 年的 Hopfield 网络,1986 年的反向传播(Backpropagation, BP)网络,1987 年的卷积神经网络(Convolutional Neural Network, CNN),1997 年的脉冲神经网络,2006 年的深度置信网络(Deep Belief Network, DBN),2012 年兴起的深度神经网络(Deep Neural Network, DNN)等。



¹ <http://news.mit.edu/2018/mit-launches-intelligence-quest-0201>

图 1 脉冲神经网络的概念定位（补充完善于[4]）

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。当前的以放电率为信息承载主体的 CNN、DNN 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特点，但是与之同样重要的还包括高动态-复杂动力学的神经元节点（时序脉冲产生）、强可塑性-稳定信息表征的突触结构（脉冲学习）、复杂功能特异性的网络环路（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、阈下膜电势累积为主体的时空编码。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成为了可能。

2 脉冲神经网络的主要优势及特点

一直以来，达到类人脑的通用智能水平是人工智能领域不懈追求的终极目标之一。SNN 网络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。




图 2 SNN 网络架构及部分多尺度可塑性。a, 层级

SNN。b, 环状类型 SNN。E, 兴奋性神经元。I, 抑制性神经元。

通过融合生物启发的、有益高效的神经信息处理机制到 SNN 中，可以探索生物系统智能运算的本质，然后通过数学模型的方式迁移泛化到更加广泛的人工智能模型中，将为得到更加智能、高效的人工智能算法提供帮助。SNN 的基本架构如图 2 所示，包括类似皮层的层级结构和类似海马的环状网络结构，网络中含有不同尺度的可塑性，用来指导网络突触权重的学习[5]。

现有的人工神经网络已经借鉴了部分的脑神经信息处理方式，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。未来，脉冲神经网络通过大规模的借鉴生物神经科学发现，将有可能在以下几个方面展现出优势：①不同神经元非线性信息处理模式的差异。生物系统中可以粗略地分为两大类神经元，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，他们对信息的非线性处理模式有很大的不同，适当比例的神经元组合建模将显著减少神经网络的能量消耗。②神经元节点对时间-空间信息的高效整合能力。单一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，可以积累很长时间内的历史输入并在放电阈值、静息电位阈值等方面产生可塑性，甚至可以单神经元通过多房室实现如工作记忆保持、信息决策、多频段信息整合及滤波等能力。③稀疏的神经信息/神经脉冲编码方式。生物神经网络采取了脉冲的方式进行信号的编码，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，大部分神经元在活动周期中都处于静息状态。这种稀疏脉冲编码的方式，将精确信息编码到了脉冲序列的时间间隔中，在降低了后期网络运算量的同时，也极大的降低了信息传递能耗。此外，脉冲序列的编码也不是一成不变的线性编码，而可以是网络根据输入信息自适应的调整上下界、放电阈值或静息电位的动态过程。④神经元中突触的位置差异性建模。生物神经元的突触位点可能发生在细胞胞体、也可能发生在远端的树突棘，两者的信息传递能效、信息迟滞时间等都有很大不同，这将极大的增加脉冲神经网络的非线性信息编码能力。⑤神经元突触的信息延迟建模。生物中的信息通过突触结构会发生信

息延迟,具体时间会根据突触的离子通道类型、受体蛋白数量的多少、距离胞体位置远近、处于几层分叉点等不同而有很大的不同,这将增强脉冲神经网络的时间动态编码能力。⑥快速的、非监督的微观神经突触可塑性调节方法。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,而是更可能由诸多的局部突触可塑性快速、直接地完成。生物系统是如何通过局部的参数调优进而实现了全局网络的优化,是值得现有的人工智能系统借鉴的,如现有的一些生物学习机制,包括赫伯学习法则(Hebb's law)[6],脉冲时序依赖的突触可塑性(Spike-Timing Dependent Plasticity, STDP)[7],短时突触可塑性(Short-Term Plasticity, STP),生物自组织反馈(Self-organized Back Propagation, SBP)[8]机制等。脉冲神经网络将依据这些机制达到更快速的网络学习。⑦介观尺度生物微环路的多时钟自组织调节。生物网络通过多神经元群体编码,对输入的不同维度的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(抗噪性)、甚至信息的启发式联想(动态稳定性)等能力带来帮助。由此,网络形成了神经元内部时钟、突触时钟、网络环路时钟的多类时钟计算过程。⑧宏观生物网络多脑区的协同能力。生物体脑区的数量众多,脑区之间的组织方法不同于脑区内部的自组织方式,具有明显的兴奋、抑制连接通路,同时可以结合多种神经反馈信息(如多巴胺奖励信号)综合实现多任务的协同,这将使得脉冲神经网络在保持脑区内部功能自稳定的基础上,同时具有快速的学习能力。

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挑战,如小样本学习效果差、待调优参数过多容易发生欠拟合、网络迭代训练次数过多又容易发生过拟合、网络迁移能力有限、DNN 的灾难性遗忘、网络对新任务的适应能力差、增量学习效果弱等;又如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,如将黄黑色条纹的图片以极高的置信度识别为校车[9]。通过生物网络结构、生物学习机制等启发,将为现有人工模型提高其认知能力指明一种可能的优化方向。考虑到现有人工神经网络所忽略的很多的生物规则可能恰恰是实现通用类人脑智能的关键,因此,在 SNN 的框架中深入研究这些生物规则,将有可能使得现有网络获得更为强大的计算能力和适应能力,最终达到与人类相比拟的智能信息感知、分析、决策能力。

3 脉冲神经网络的优化目标及定位

如何高效优化复杂的脉冲神经网络模型是近些年研究的重点,且优化方向根据最终目标的不同而稍有差别。一类是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物发现,如 STDP、STP、长时程增强(Long-Term Potentiation, LTP)、长时程抑制(Long-Term Depression, LTD)、神经元侧抑制(Lateral Inhibition)、Dale 准则(神经元突触同为正数或者同为负数)、侧抑制、兴奋-抑制神经元平衡,及其上述准则的不同变体等。通过将这些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。

图 3 搭建生物系统和人工网络的桥梁并启发新一代通用人工智能模型

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、BP 训练 ANN 后再转化为 SNN、对 SNN 的 Spike 平滑近似使其满足可微分条件等。

整体而言,如图 3 所示,脉冲神经网络可以同时借鉴生物系统的可塑性机制和当前人工网络的成熟优化方法,综合实现更加高效的类人感

知、认知、决策能力,为实现新一代的通用人工智能模型打好基础。

4 脉冲神经网络的基本信息编码

在脉冲神经网络内部,神经元接收上游神经元轴突传来的 Spike 信息(基本量纲为电势),经过树突突触后将电势信息转为电流信息,电流经

过神经元内部到达胞体, 通过电流改变胞体内外的电势差, 达到放电阈值后通过钙离子通道的打开, 生成新的 Spike 信息并通过轴突继续向下游神经元传递。

图 4 不同神经元编码示例

在脉冲神经网络外部, 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, 更为详细的编码说明请参考[10], 如包括:

- 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 20-50ms 内发生传递, 因此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[11]。
- 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, 且需要在计算的时候进行相位对齐[12]。
- ③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[13, 14]。然而, 泊松编码通过长时间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。
- ④神经元动力学特性编码。生物神经元的膜电位变化可以等效为高阶微分动力学方程, 外界的输入电流将影响动力学方程的极值数量和数值, 因此将会出现不同类型的吸引子或动态分岔, 如鞍-结分岔、Andronov-Hopf 分岔等。Izhikevich 模型提出简化的采用四个无量纲的参数组合来表征多类丰富的脉冲发放模式, 如均匀放电、强直簇状放电、梳状放电等, 可以看做是构建复杂神经动力方程的捷径[15], 部分神经元编码举例如图 4 所示。

5 以理解生物系统为目标的脉冲神经网络

网络优化进展

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 的信息转存能力[16]。Song 等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生物模型层面的解释, 如对于决策、工作记忆保持、网络周期稳定放电等, 未来将有可能在越来越多的宏观生物智能现象的解释上发挥重要作用[17]。受到大脑皮层的网络结构和功能的启发, 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算法[~]。该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。

在微观可塑性的理解方面, Diehl 采用两层 SNN 网络以及 LIF 神经元模型, 通过相邻层神经元的非监督 STDP 学习映射, 然后挑选输出层的对特定类别选择性放电的神经元作为类别标记, 在 MNIST 数据集上可以达到 95% 的测试正确率, 充分验证了 LIF 节点的信息处理能力[18]和 STDP 的可塑性学习能力[19]。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[20], SNN 网络同时加入了兴奋和抑制性突触, 最终模型得到了相比无抑制性突触的 SNN 模型更好的分类结果: 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 癌症诊断数据集中达到了 96% 的正确率。Wang 提出了一种支持小样本在线学习的 SNN 算法[21], 该网络分为时间编码层、空间时间聚类层和分类输出层三层网络结构, 使用了 STDP 和反 STDP 相结合的学习规则来调整权值, 虽然在 MNIST 数据集上只有 75% 的正确率, 但是相对其他 SNN 网络具有更快的收敛速度。Beyeler 采用了 Izhikevich 神经元模型构建 SNN 网络, 使用电导依赖的突触可塑性规则, 结合 STDP 学习规则在 MNIST 数据集上得到了约 90% 的识别正确率[22]。Resume 结合 STDP 和 anti-STDP 规则, 根据前后层神经元的放电模式调整他们之间的突触连接强度, 与传统的 STDP 的最大差异, 是通过加入了时间积分核来对历史放电模式进行积累, 并作为乘性因子来放大 STDP 的可

[~] <https://numenta.org/hierarchical-temporal-memory/>

塑性调节程度。然而此方法仍然是局部、单层的学习方法,目前主要在液体状态机的输出层权重学习部分发挥作用[23]。

在简单任务的验证方面, Wysoski 提出了一种多层的 SNN 架构来识别动态视频流中的模式[24]。其中,自适应在线学习规则和多帧意见收集算法被结合到了 SNN 算法中,并采用 LIF 模型、4 层的二维神经网络结构,以及应用 Hebb 法则学习不同的模式数据,最终在视频流的模式分类任务中取得了相对其他静态处理方法更高的正确率。Taras 提出了一种简化了的脉冲神经网络计算模型[25],采用 LIF 神经元模型、STDP 学习规则、脉冲频率编码和输入图片的感受野像素转化等方法,在线学习达到了高于传统 SNN 约 20 倍的运算速度。Yu 等构建了 SNN 网络,对语音时序信息进行了稳定编码、学习和解码[26]。

这些方法都着重依赖生物可解释的可塑性法则来优化目标功能网络,并随着优化效果的提升逐渐对生物的多类优化机制有了更深刻的认识,如 STDP 和 BP 的相关性分析[27]、泊松编码和 STDP 的关系分析[14]等。

6 以追求卓越计算性能为目标的脉冲

神经网络优化进展

针对 SNN 由于存在 Spike 而不可处处可微的问题,受到神经动力学特性的启发, SNU (Spiking Neuron Unit) 通过内部环路实现类 LIF 的工作机制,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动力学信息处理特点,如信息积累、衰减、阈值放电等[28],在 MNIST 数据集上得到 98% 的正确率。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 神经信息放电视为噪声的一种,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。训练后的网络很适合对模糊放电信息的处理,因此从侧面表现出 SNN 网络强大的时空信息整合能力[29]。另一类代理梯度的方法优化 SNN 网络,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,包括 Reset 项和 Spike 项,使得网络可以最终用近似 BP 的方式求解[30, 31],且在最终的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具有放电神经元的多类神经网络中[32-34]。

用神经元精确放电的 Spike 时刻来表征网络信息的传递,是另一种可以融合 BP 优化的有效途径。SpikeProp [35]通过限制网络中神经元的脉冲发放次数,然后通过 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 [36]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,对于不发放脉冲的状况下,网络将不会产生可学习的梯度,进而影响 SNN 的快速拟合。Tempotron [37]方法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单个神经元。

受大脑的“多脑区协同”机制启发,加拿大滑铁卢大学的科学家们实现了 NENGO 神经模拟器平台[38]。该平台包括十几个脑区,采用了统一的语义指针架构网络 (Semantic Pointer Architecture Unified Network, SPAUN) [39],包含 250 万个虚拟神经元,可执行 8 种不同的认知任务:如模仿绘图、计数器、记忆和推理等。该模型构建了前额叶皮质、基底核、丘脑等功能相关区域。在宏观尺度上,部分区域的功能与大脑中特定区域的功能保持了一致。在微观尺度上,单位运算节点与 LIF 神经元模型保持了一致。SPAUN 拥有不多的神经元数量却能够实现较为复杂的认知功能,达到了多个脑区协同来展示复杂行为的目的。然而它的缺点依旧明显,如对不同脑区的功能划分不详细、脑区特定功能是以预设目标函数方法来实现的、微观神经活动是通过自顶向下的反向函数计算拟合得到的、无法很好适应新的工作任务等等。

除此之外,将 DNN 预先训练然后转化为 SNN 也是一种高效的 SNN 实现方法[40],这些方法在 DNN 训练阶段将权值限制到 0 附近的小范围内,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,最后通过统计神经元的放电率来计算网络输出[41, 42]。脉冲耦合神经网络 [43]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提供了可能的思路[44, 45]。

7 基于多尺度生物可塑性的脉冲神经网络优化方法

网络优化方法

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。液体状态机(Liquid State Machine, LSM)是第一个明显的例子,网络由输入端、隐层状态机、输出端构成,真正参与网络特定功能(如分类[46]、预测[47]、规划[48]等)学习的权重变化只发生在输出的

权重部分。隐层状态机则是进行非监督的网络信息优化,如非线性时序计算(如 Spike 时序等)、局部稳态调节(如 STDP、STP 可塑性优化)等。第二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,在训练阶段,通过 Hebb 法则来非监督的学习输入信息(如图像)内部信息的关联,该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),并在测试阶段通过固化的权重还原输入信息(如去噪、恢复遮挡等)。以上两类 SNN 网络中的重要概念,是后续诸多 SNN 网络借鉴和发展的基础。如多层前馈 SNN 网络,如图 5 所示,大多类似于 LSM 网络,将前几层信息稳定表征和最后几层的任务相关的权重学习分开。如受限玻尔兹曼机则是基于 Hopfield 网络的延伸,将环状网络分离为输入和输出神经元,同样利用基于能量的约束方法来最优化 Sleep 过程,再通过弱监督的误差信息微调 Wake 过程,基于能量+环路结合的方式也在很多的抗噪任务中发挥了重要的作用[49]。

图 5 多尺度脉冲神经网络的优化流程

1.1 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[50, 51]。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、线粒体供能等不同限制,实现基于短时突触可塑性、长时突触可塑性等不同机理的突触信息变换;然后,信息经过“点神经元”模型的非线性变换,将连续信号转换为非连续的脉冲 Spike 信号,将可微分的突触电流信号转换为不可微分的 Spike 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、时延等诸多步骤,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[52]。

生物网络自身优化依靠的是不同尺度的生物可塑性。STDP、LTP、LTD、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。在这个过程中,神经元结构和突触结构都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,这些可塑性的变化是非

监督、自组织、和任务无关的,网络习得的是一种数据内部信息关联的稳态表征。最后根据具体任务的评测指标,加入弱监督的教师信号,使得网络习得预期的网络功能,如图 5 所示。

论文[53]采用多层卷积、STDP、信息延迟计算的方式,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,实现高效的特征分类。论文[54]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。我们之前的工作尝试将众多的非监督的微观尺度的生物可塑性学习方法,应用到能量函数优化过程中,如在论文[55]中,采用 STP 来调节突触层次的输入电势和输出电流的稳定调节,不同比例的兴奋性和抑制性神经元满足 Dale 准则并用来调节网络的整体稳定性。最后,通过弱监督的教师信号引导调节目标神经元膜电位信息,并通过 STDP 来将输出差异从膜电位变化固化到突触权值中。

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,在论文[13]中,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共 7 条规则被作为类脑的重要机制引入到 SNN 的学习中来,当引入越来越多的类脑机制后,模型的正确率会逐步提升,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。

1.2 基于介观尺度可塑性的脉冲神经网络优化

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[56]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[49]中,对海马区的三个亚区 DG、CA3 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、经过环状网络信息处理后的知识存储和提取,以及经过加权网络(CA1)后的分类功能输出。三个亚区经过分别训练后,融合后的 SNN 网络可以实现对 NAO 机器人实时观测到的带噪图片的稳定脉冲序列表征及高精度分类。论文[57]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。通过对特定样本增加好奇比率,调整其在网络训练过程中的出现比例,最终加快 SNN 网络的学习收敛过程及减少训练样本量。

1.3 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异性脑区环路建立、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,如图 5 所示。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和介观的优化法则微调。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[58]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,进而影响到如前额叶、丘脑、海马等高级脑区[59]。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。我们之前的工作中,如对 SNN 网络中加入噪声干扰,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[60],也可以是神经活动的随机扰动(如泊松噪声扰动、均匀噪声扰动等)[13]。全局背景噪声的类型、产生机制和作用还在研究中,在算法层面,一种可能的尝试是基于遗传演化算法的 SNN 优化 [61-63],逐步挖掘局部信息的扰动对全局信息的影响关系。

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[64],这些努力可以理解为由人工智能到生物机理的反向启发。如 Target Propagation (TP) [65],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,例如,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) [66] 和差异目标传播 (Difference Target Propagation, DTP) [67]突破了梯度反传矩阵和前馈矩阵必须对称的限制,提出用随机的矩阵来代替反馈过程中的梯度传递。进一步的,直接反馈校准(Direct Feedback Alignment, DFA)[68]、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)[69]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[34]也将为 SNN 的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探索方向。

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。论文[70]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,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。基于蓄水池计算网络(Reservoir Computing)或液体状态机 LSM 的研究中[71],网络将严格区分输入、隐层动力系统、输出三个部分,网络的可塑性只存在于输出层到隐层之间的权重,具有快速学习、训练代价小、时空信息融合、硬件实现容易等特点,然而相对的正确率较低、复杂性任务的表现较差。

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[72],Sporns 发现脑网络中不同区域的 Motif 分布和不同脑区的功能之间具有较为紧密的联系[73]。我们之前的工作[74]中,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,通过构建同等、类似的 Motif 分布,可以增加对原有的脑区的功能的理解及 SNN 建模实现。此外,Witter 已经通过生物解剖和数据验证,海马区的 CA3 网络是一种具有高度特异性的循环网络结构[75],CA3 的三点 Motif 统计分析结果也显示出,在 13 类 Motif 类型中的第 9、12、13 类 Motif 的分布较为突出(分别是三类循环网络的子集),这个结果和生物解剖得到的结果保持了高度一致性,为采用 Motif 指导 SNN 的网络结构构建提供部分生物基础。

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,慢慢朝向高效且具有生物合理性的方向发展。未来,随着考虑越来越多的生物约束或生物启发,SNN 中的信度分配将有效覆盖全局误差函数、网络隐层状态、局部神经节点等,走出一条多尺度的、从功能到机理融合的崭新优化道路。

8 总结及展望

脉冲神经网络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,是一种局部非监督、全局弱监督的类生物网络,因此具有强大的非线性计算、异步事件信息处理、自学习等能力。

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,可以参考不同脑区、不同功能环路的主要神经元类型,定制化的构建符合特定期望功能的脉冲神经元模型,以此来增强人工神经网络编码的有效性。同时,具有动力学优势的神经元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。

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,当人工神经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,不能像生物系统那样能够轻易的根据几个位置标记的运动轨迹抽象联想出具体的行为动作等。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设计的,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,脉冲神经网络可以同时满足生物的结构和功能约束,为进一步获得类脑的认知能力打好基础。

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。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。

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生物神经网络的研究发现, 促进生物领域未解开的对长程回路连接作用的理解、对多脑区协同方式方法的认识、对不同功能的生物网络自组织关联的假设验证等。最终, 通过 SNN 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进展, 为研发新一代人工智能计算模型贡献力量。

参 考 文 献

1. Markram and Henry, The Human Brain Project. Scientific American, 2012. 306(6): p. 50-55.
2. Helmstaedter, M., The mutual inspirations of machine learning and neuroscience. Neuron, 2015. 86(1): p. 25-28.
3. McCulloch, W.S. and W. Pitts, A Logical Calculus of the Ideas Immanent in Nervous Activity. Biol Math Biophys, 1943.
4. Sze, V., et al., Efficient Processing of Deep Neural Networks: A Tutorial and Survey. Proceedings of the IEEE, 2017. 105(12): p. 2295-2329.
5. Abbott, L.F., B. DePasquale, and R.M. Memmesheimer, Building functional networks of spiking model neurons. Nat Neurosci, 2016. 19(3): p. 350-5.
6. Hebb, D.O., The organization of behavior: a neuropsychological theory. 1949: J. Wiley; Chapman & Hall.
7. Bi, G. and M. Poo, Synaptic Modifications in Cultured Hippocampal Neurons: Dependence on Spike Timing, Synaptic Strength, and Postsynaptic Cell Type. The Journal of Neuroscience, 1998. 18(24): p. 10464-10472.
8. Dan, Y. and M.-M. Poo, Spike timing-dependent plasticity: from synapse to perception. Physiological reviews, 2006. 86(3): p. 1033-1048.
9. Nguyen, A., J. Yosinski, and J. Clune. Deep neural networks are easily fooled: High confidence predictions for unrecognizable images. in computer vision and pattern recognition. 2015.
10. 蔺想红, 王向文, 脉冲神经网络原理及应用. 科学出版社, 2018.
11. Tovee, M.J. and E.T. Rolls, Information encoding in short firing rate epochs by single neurons in the primate temporal visual cortex. Visual Cognition, 1995. 2(1): p. 35-58.
12. Hu, J., et al., A spike-timing-based integrated model for pattern recognition. Neural Computation, 2013. 25(2): p. 450-472.
13. Zeng, Y., T. Zhang, and B. Xu, Improving multi-layer spiking neural networks by incorporating brain-inspired rules. Science China Information Sciences, 2017. 60(5): p. 052201.
14. Gilson, M., T. Masquelier, and E. Hugues, STDP Allows Fast Rate-Modulated Coding with Poisson- Like Spike Trains. PLOS Computational Biology, 2011. 7(10).
15. Izhikevich, E.M., Simple model of spiking neurons. IEEE Transactions on Neural Networks, 2003. 14(6): p. 1569-1572.
16. Zenke, F., E.J. Agnes, and W. Gerstner, Diverse synaptic plasticity mechanisms orchestrated to form and retrieve memories in spiking neural networks. Nature communications, 2015. 6.
17. Song, H.F., G.R. Yang, and X.J. Wang, Training Excitatory-Inhibitory Recurrent Neural Networks for Cognitive Tasks: A Simple and Flexible Framework. PLoS Comput Biol, 2016. 12(2): p. e1004792.
18. Diehl, P.U. and M. Cook, Unsupervised learning of digit recognition using spike-timing-dependent plasticity. Frontiers in Computational Neuroscience, 2015. 9.
19. Tavanaei, A. and A. Maida, BP-STDP: Approximating backpropagation using spike timing dependent plasticity. Neurocomputing, 2019. 330: p. 39-47.
20. Wade, J., et al., SWAT: A Spiking Neural Network Training Algorithm for Classification Problems. IEEE Transactions on Neural Networks, 2010. 21(11): p. 1817-1830.
21. Wang, J., et al., An online supervised learning method for spiking neural networks with adaptive structure. Neurocomputing, 2014. 144(nov.20): p. 526-536.
22. Beyeler, M., N.D. Dutt, and J.L. Krichmar, Categorization and decision-making in a neurobiologically plausible spiking network using a STDP-like learning rule. Neural Netw, 2013. 48: p. 109-24.
23. Ponulak, F. and A. Kasinski, Supervised learning in spiking neural networks with resume: Sequence learning, classification, and spike shifting. Neural Computation, 2010. 22(2): p. 467-510.

24. Wysoski, S.G., L. Benuskova, and N. Kasabov, Fast and adaptive network of spiking neurons for multi-view visual pattern recognition. *Neurocomputing*, 2008. 71(13): p. 2563-2575.
25. Iakymchuk, T., 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): p. 4.
26. Yu, Q., et al., A spiking neural network system for robust sequence recognition. *IEEE transactions on neural networks and learning systems*, 2016. 27(3): p. 621-635.
27. Bengio, Y., et al., STDP as presynaptic activity times rate of change of postsynaptic activity approximates back-propagation. *Neural Computation*, 2017. 10.
28. Woźniak, S., et al., Deep learning incorporating biologically inspired neural dynamics and in-memory computing. *Nature Machine Intelligence*, 2020. 2(6): p. 325-336.
29. Lee, J.H., T. Delbruck, and M. Pfeiffer, Training deep spiking neural networks using backpropagation. *Frontiers in Neuroscience*, 2016. 10.
30. Zenke, F. and S. Ganguli, SuperSpike: Supervised Learning in Multilayer Spiking Neural Networks. *Neural computation*, 2018. 30(6): p. 1514-1541.
31. Shrestha, S.B. and G. Orchard, SLAYER: Spike layer error reassignment in time, in *Advances in NIPS*, S. Bengio, et al., Editors. 2018, Curran Associates, Inc. p. 1412-1421.
32. Bellec, G., et al. Long short-term memory and learning-to-learn in networks of spiking neurons. in *Advances in Neural Information Processing Systems*. 2018.
33. O'Connor, P. and M. Welling, Deep spiking networks. *arXiv preprint arXiv:1602.08323*, 2016.
34. Bellec, G., et al., Biologically inspired alternatives to backpropagation through time for learning in recurrent neural nets. *arXiv preprint arXiv:1901.09049*, 2019.
35. Bohte, S.M., J.N. Kok, and J.A. Poutre. SpikeProp: backpropagation for networks of spiking neurons. in the *European symposium on artificial neural networks*. 2000.
36. Mckennoch, S., D. Liu, and L. Bushnell. Fast Modifications of the SpikeProp Algorithm. in *international joint conference on neural network*. 2006.
37. Gutig, R. and H. Sompolinsky, The tempotron: a neuron that learns spike timing-based decisions. *Nature Neuroscience*, 2006. 9(3): p. 420-428.
38. Eliasmith, C., et al., A large-scale model of the functioning brain. *Science*, 2012. 338(6111): p. 1202-5.
39. Trevor, B., et al., Nengo: a Python tool for building large-scale functional brain models. *Front Neuroinform*, 2013.
40. Diehl, P.U., et al. Fast-classifying, high-accuracy spiking deep networks through weight and threshold balancing. in *international symposium on neural networks*. 2015.
41. Cao, Y., Y. Chen, and D. Khosla, Spiking Deep Convolutional Neural Networks for Energy-Efficient Object Recognition. *International Journal of Computer Vision*, 2015. 113(1): p. 54-66.
42. Tavanaei, A., et al., Deep learning in spiking neural networks. *Neural Networks*, 2018.
43. Wang, Z., et al., Review article: Review of pulse-coupled neural networks. *Image and Vision Computing*, 2010. 28(1): p. 5-13.
44. Marblestone, A.H., G. Wayne, and K.P. Kording, Toward an integration of deep learning and neuroscience. *Frontiers in Computational Neuroscience*, 2016. 10: p. 94.
45. Gardner, B. and A. Grüning, Supervised learning in spiking neural networks for precise temporal encoding. *PloS one*, 2016. 11(8): p. e0161335.
46. Teeter, C., et al., Generalized leaky integrate-and-fire models classify multiple neuron types. *Nature communications*, 2018. 9(1): p. 709.
47. Gütiğ, R., Spiking neurons can discover predictive features by aggregate-label learning. *Science*, 2016. 351(6277): p. aab4113.
48. Rueckert, E., et al., Recurrent spiking networks solve planning tasks. *Scientific reports*, 2016. 6: p. 21142.
49. Zhang, T., et al. HMSNN: Hippocampus inspired Memory Spiking Neural Network. in *systems, man and cybernetics*. 2016.
50. Huang, Z.J., The diversity of GABAergic neurons and neural communication elements. 2019.
51. Ecker, J.R., et al., The BRAIN initiative cell census consortium: lessons learned toward generating a comprehensive brain cell atlas. *Neuron*, 2017. 96(3): p. 542-557.
52. Brendel, W., et al., Learning to represent signals spike by spike. *PLOS Computational Biology*, 2020. 16(3).
53. Kheradpisheh, S.R., et al., STDP-based spiking deep

- convolutional neural networks for object recognition. *Neural Networks*, 2018. 99: p. 56-67.
54. Mozafari, M., et al., SpykeTorch: Efficient Simulation of Convolutional Spiking Neural Networks With at Most One Spike per Neuron. *Frontiers in Neuroscience*, 2019. 13: p. 625.
 55. Zhang, T., et al. Brain-inspired Balanced Tuning for Spiking Neural Networks. in *international joint conference on artificial intelligence*. 2018.
 56. Zhang, T., et al. A Plasticity-centric Approach to Train the Non-differential Spiking Neural Networks. in *national conference on artificial intelligence*. 2018.
 57. Shi, M., T. Zhang, and Y. Zeng, A Curiosity-Based Learning Method for Spiking Neural Networks. *Frontiers in Computational Neuroscience*, 2020. 14: p. 7.
 58. Seung, H.S., Learning in spiking neural networks by reinforcement of stochastic synaptic transmission. *Neuron*, 2003. 40(6): p. 1063-73.
 59. Zhao, F., 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): p. 296-306.
 60. Zhang, M., et al., Supervised learning in spiking neural networks with noise-threshold. *Neurocomputing*, 2017. 219: p. 333-349.
 61. Federici, D. A regenerating spiking neural network. in *international joint conference on neural network*. 2005.
 62. Shayani, H., P.J. Bentley, and A.M. Tyrrell. A Multi-cellular Developmental Representation for Evolution of Adaptive Spiking Neural Microcircuits in an FPGA. in *adaptive hardware and systems*. 2009.
 63. Zhao, F., et al. Towards a Brain-Inspired Developmental Neural Network by Adaptive Synaptic Pruning. in *international conference on neural information processing*. 2017.
 64. Huh, D. and T.J. Sejnowski. Gradient descent for spiking neural networks. in *Advances in Neural Information Processing Systems*. 2018.
 65. Bengio, Y., How Auto-Encoders Could Provide Credit Assignment in Deep Networks via Target Propagation. *Computer Science*, 2014.
 66. Lillicrap, T., et al., Random synaptic feedback weights support error backpropagation for deep learning. *Nature Communications*, 2016. 7(1): p. 13276.
 67. Lee, D., et al. Difference target propagation. in *European conference on machine learning*. 2015.
 68. Nokland, A. Direct Feedback Alignment Provides Learning in Deep Neural Networks. in *neural information processing systems*. 2016.
 69. Frenkel, C., M. Lefebvre, and D. Bol, Learning without feedback: Direct random target projection as a feedback-alignment algorithm with layerwise feedforward training. *arXiv: Machine Learning*, 2019.
 70. Scellier, B. and Y. Bengio, Equilibrium Propagation: Bridging the Gap between Energy-Based Models and Backpropagation. *Frontiers in Computational Neuroscience*, 2017. 11: p. 24-24.
 71. Tanaka, G., et al., Recent advances in physical reservoir computing: A review. *Neural Networks*, 2019. 115: p. 100-123.
 72. Mangan, S. and U. Alon, 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): p. 11980-11985.
 73. Sporns, O. and R. Kotter, Motifs in Brain Networks. *PLOS Biology*, 2004. 2(11).
 74. Zhang, T., Y. Zeng, and B. Xu, A computational approach towards the microscale mouse brain connectome from the mesoscale. *Journal of Integrative Neuroscience*, 2017. 16(3): p. 291-306.
 75. Witter, M.P., *Connectivity of the Hippocampus*. 2010: Springer New York.

Background

This paper reviewed some traditional and state-of-the-art tuning methods in the research area of Spiking Neural Network (SNN). The research of SNN covered disciplines such as biology, computational neuroscience, artificial neural network (AI), and optimization theory. SNN is biologically plausible and considered as the computationally biological effort towards the next-generation human-level AI model. We think the multi-scale plasticity principles founded in the natural neural networks may cooperate well with each other during unsupervised learning and integrate well with other tuning methods in the supervised learning of SNNs. The successful training of SNN will give us hints or inspirations for a smarter AI 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).