

适合类脑脉冲神经网络的应用任务范式分析与展望

张铁林^{1,*}, 李澄宇², 王刚³, 张马路⁴, 余磊⁵, 徐波^{1,*}

1(中国科学院自动化研究所 北京 100190)

2(中国科学院神经所 上海 200031)

3(军事科学院军事认知与脑科学研究所 北京 100850)

4(电子科技大学 成都 611731)

5(武汉大学 武汉 430072)

摘要:类脑脉冲神经网络(SNN)由于同时具有生物合理性和计算高效性等特点,因而在生物模拟计算和人工智能应用两个方向都受到了广泛关注。本文通过对SNN发展历史的演进分析,发现这两个原本相对独立的研究方向正在朝向快速交叉融合的趋势发展。回顾历史,随着动态异步事件信息采集装置的成熟,如动态视觉相机(DVS)、动态音频传感(DAS),SNN可以有机会充分发挥其在脉冲时空编码、神经元异质性、功能环路特异性、多尺度可塑性等方面的优势,并在一些传统典型的应用任务中崭露头角,如动态视觉信号追踪、听觉信息处理、强化学习连续控制等。与这些物理世界的应用任务范式相比,生物大脑内部存在着一个特殊的生物脉冲世界,这个脉冲世界与外界物理世界互为映像且复杂度相似。展望未来,随着侵入式、高通量脑机接口设备的逐步成熟,脑内脉冲序列的在线识别和反向控制,将逐渐成为一个天然适合SNN最大化发挥其低能耗、鲁棒性、灵活性等优势的新型任务范式。类脑SNN从生物启发而来,并将最终应用到生物机制探索中去。我们相信,这类正反馈式的科研方式将极大的加速后续相关的脑科学和类脑智能研究。

关键词:脉冲神经网络;类脑智能;脑机接口;实验范式.

中图分类号: TP183 文献标识码: A 文章编号:

Research Advances and Perspectives of New Paradigms for Biology-inspired Spiking Neural Networks

ZHANG Tielin^{1,*}, LI Chengyu², WANG Gang³, ZHANG Malu⁴, YU Lei⁵, XU Bo^{1,*}

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

2 (Institute of Neuroscience, Chinese Academy of Sciences, Shanghai 200031, China)

3 (Center of Brain Sciences, Beijing Institute of Basic Medical Sciences, Beijing 100850, China)

4 (University of Electronic Science and Technology of China, Chengdu 611731, China)

5 (Wuhan University, Wuhan 430072, China)

Abstract: Spiking neural networks (SNN) are drawing extensive attention in the disciplines of computational simulation and artificial intelligence for their biological plausibility and computational efficiency. In this paper, we analyze the historical development of SNN and conclude that these two mentioned disciplines are intersecting and

收稿日期: 2022-11-10; 改回日期: 网络出版;

*通信作者: 张铁林, tielin.zhang@ia.ac.cn; 徐波, xubo@ia.ac.cn。

基金项目: 科技创新 2030 新一代人工智能项目(2020AAA0104305), 中科院先导专项 A(XDA27010000)、先导专项 B(XDB32070000)、上海市市级科技重大专项、青促会等资助。

Foundation Item: The National Key Research and Development Program of China (2020AAA0104305), the Strategic Priority Research Program of the Chinese Academy of Sciences (XDA27010000, XDB32070000), the Shanghai Municipal Science and Technology Major project, and the Youth Innovation Promotion Association CAS.

merging rapidly. Looking back on history, after the successful application of Dynamic Vision Sensors (DVS) and Dynamic Audio Sensors (DAS), SNNs have found some proper paradigms, such as continuous visual signal tracking, automatic speech recognition, and reinforcement learning of continuous controlling, which have supported their key features extensively including but not limited to, the spiking encoding, neuronal heterogeneity, specific functional circuits, and multiscale plasticity. Compared to these real-world paradigms, the brain contains a spiking version of the biology-world paradigm, which exhibits a similar complexity and is usually considered a mirror of the real world. Then looking forward to the future, with the rapid development of the invasive and parallel brain-computer-interface (BCI), the new BCI-based paradigm, including online pattern recognition and stimulus control of biological spike trains, is natural for SNN to exhibit their key advantages of energy efficiency, robustness, and flexibility. The biological brain has inspired the present study of SNNs, and the effective SNN machine-learning algorithm can further spur neuroscience discovery in the brain by applying them back to the new BCI paradigm. Such two-way interactions with positive feedback can accelerate brain science research and brain-inspired intelligence technology.

Key words: Spiking Neural Network; Brain-inspired Intelligence; Brain-Computer Interface; Experimental paradigm.

脉冲神经网络 (Spiking Neural Network, SNN) [1] 作为脑启发的新型神经网络算法之一, 自 1997 年首次提出以来, 受到了神经科学、计算机科学等多领域科研人员的广泛关注。SNN 同时兼具生物合理性和时空计算高效性, 因此可以同时在生物脑模拟和类脑智能计算上发挥优势, 同时也可以在生物智能和人工智能之间架起沟通桥梁, 加快我们理解生物认知智能的本质。经过 20 多年的发展, SNN 也在备受瞩目和期待中多次调整科研定位并逐步收敛到一些合适的应用领域: 如基于 SNN 的生物认知功能模拟被广泛的应用于计算神经科学中, 用以验证多种生物想定[2-9]; 基于 SNN 的人工智能应用也逐步的在计算精度、能耗、鲁棒性、灵活性等方面发挥出独特优势[10-13]。未来的 SNN 路在何方, 在应用场景、自身模型特点等方面应该有哪些坚持、折中和突破, 是 SNN 科研领域极为关键的本质问题。

1 类脑 SNN 的发展历史演进

SNN 是一种强调以脉冲编码和脉冲通讯为主要信息处理手段的新型人工神经网络模型, 于 1997 年被首次提出并后被广泛称为“第三代”人工神经网络[1]。自提出以来, SNN 一直在多层面 (如机制机理、学习方法等)、多评价维度 (如正确率、泛化性等) 存在着和人工神经网络 (Artificial Neural Network, ANN) 算法的评测对比。一个很直观的问题是, 生物体经过千百年的遗传进化, 为什么最终选择了 SNN 而非 ANN 的智能形式, 除了部分能耗限制以外, 还有没有其它如神经元编码、网络结构、学习方法、生存范式等根本差异导致的原因。从生物计算的视角来看, 了解这些差异和原因, 将可以极大的帮助我们评估或厘清生物智能本质。带着诸多期盼, SNN 经过了 20 多年的发展, 其典型的科研方向主要覆盖两大应用领域: 一个是以计算神经科学为主的生物计算仿真模拟, 多用于解释多层次的生物脑感知认知机制和现象; 另一个是以类脑智能计算为主的人工神经网络创新应用, 需要深入交叉计算机、生物、新器件等多学科来突破新一代人工智能软件算法和硬件基础。下面针对这两个方向展开详细介绍。

1.1 生物模拟计算方向

已发现的很多生物机制和实验现象被广泛的应用在 SNN 算法中, 用来解释和验证生物脑的智能感知、工作记忆、决策等能力, 如图 1 所示。1952 年, 较为精细的生物神经元 Hodgkin-Huxley (H-H) 放电模型被提出, 验证了 1907 年提出的漏电-积分-放电 (Leaky integrated-and-fire, LIF) 模型猜想。LIF 由于具有更简明的数学计算表达式而被更广泛的应用于后续诸多 SNN 算法模型中。1990 年左右, 随着神经形态计算概念的提出, SNN 作为以 Spike 异步事件编码的人工神经网络新形态模型, 受到了计算机软件、微电子硬件等领域的持续关注。以神经形态计算为主的类脑硬件有望突破原有的冯氏计算架构, 在存算一体、异步并行计算、极低能耗等方面发挥优势。然而, 将生物的多尺度计算能力直接复制到人工智能系统中并

不如初始预计的那样简单，2014年以生物脑计算模拟为初始目标的欧盟脑计划也因为其逐渐增加的实施难度而调整了战略方向。一些感觉较为简单的生物神经元类型、网络结构等在后续的光学和电子显微镜下展现了极其复杂的非线性变化，双光子、膜片钳等在体生物信息记录也显示网络存在长期且多类型的神经可塑性机制，包括但不限于，神经元可塑性（如动态放电阈值），突触可塑性（如脉冲时序可塑性、短时突触可塑性等），以及一些元可塑性（如多巴胺、乙酰胆碱等神经调制影响的基于可塑性的可塑性）。

自1997年SNN被提出后，不同类型的生物机制有机会可以统一被嵌入到同一个框架中，用以更方便的理解生物系统的认知能力、能量消耗等。SNN后续称为第三代人工神经网络，主要用于区分第一代的感知机（一类两层线性人工神经网络模型）和第二代的多层感知机（一类多层非线性人工神经网络模型）。相关的生物机制或相关现象在实验过程中陆续被发现。如2003年，生物突触的随机信息传递机制被数学建模并应用于SNN的突触学习[14]；2006年，电导的动态扰动过程被精确模拟并用于促进SNN学习[15]；2013年，一种特定的针对昆虫决策控制模拟的SNN网络被首次提出[16]；2014-2017年，多类功能脑区启发的SNN模型被提出，如类海马的多尺度环状SNN网络用于模拟海马的鲁棒记忆形成和提取[2, 17, 18]，6层皮层特征约束下的SNN网络用于模拟运动识别能力[19]。

2017年后，多类生物合理的SNN学习算法被开发出来，如生物启发Force学习算法[20]、多生物可塑性规则融合算法[9, 21-23]、自组织反向传播（Self-BP, SBP）学习算法[13]等。生物结构也启发了一些SNN新模型，如不同尺度Motif生物结构分布预测[24]、多类Motif基本环路结构的视听多模态融合算法[25]、基于神经网络结构搜索的SNN架构搜索[26]、基于彩票理论的生物网络结构测评[27]等。这些生物模拟计算方面的科研进展，为后续构建生物合理的人工神经网络提供了很多借鉴和启发，是迈向新一代人工智能算法中间的重要一环。

值得一提的是，随着越来越多的生物特征被加入到SNN中，SNN逐渐从生物模拟转为可以承担更多类似ANN人工智能应用的任务，如基于MNIST数据集的手写体数字识别[28]、基于TIDigits数据集的数字语音识别[29]、基于TIMIT语音数据集的说话人识别[12]、基于DvsGesture数据集的动作行为识别[13]，以及其它如强化学习应用任务等[12, 30]。由此可以预见，从生物模拟计算到人工智能应用的融合趋势已经越来越明显，一些基本关键的SNN适用性问题也即将被回答，即哪些人工智能应用任务可以最大化的发挥SNN优势，而哪些任务并不是很合适SNN，而应更聚焦在传统的ANN领域。

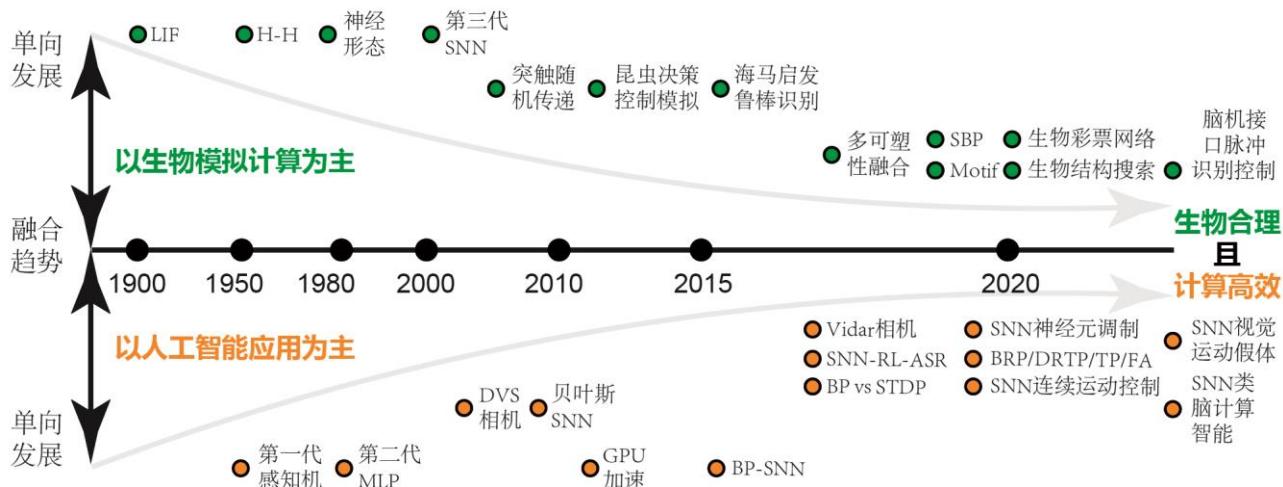


图1 SNN历史发展时间简表

1.2 人工智能应用方向

SNN和ANN的发展都极大借鉴了不同时期当时人们对生物智能的不同阶段认识。现有的SNN研究很

多是将 SNN 看作 ANN 的一种脉冲型特例，即除了脉冲节点编码以外，其他的如网络结构、学习方法、优化器等都和 ANN 的技术路线保持一致，最为极端的做法是研究如何将训练好的 ANN 直接等价转换为 SNN[31]。这些从人工智能应用视角出发来发展 SNN 的研究思路，将最大化的借鉴已有 ANN 的科研积累，如反向传播学习方法、卷积核结构算子等，并在保持 SNN 可接受的精度损失下尽可能提升能效比。在这个指导思路下，已有很多 SNN 算法被提出并广泛应用到很多特定场景[32-34]。

自 2005 年首个动态视觉相机（Dynamic Vision Sensor, DVS）被提出后[35]，SNN 作为适配模型算法之一被广泛研究。DVS 相机将动态输入差异信息编码成动态脉冲序列，可以极大的提升相机帧率并减少响应时间。随后，一些贝叶斯理论与 SNN 学习算法尝试融合，用以提升 SNN 适应性[36]。2012 年，SNN 算法首次在硬件上实现了 GPU 加速[37]。通过 BP 算法来直接优化 SNN 在 2016 年左右也迎来了高潮，不同结构但更深的 SNN 算法被接连提出并广泛应用到 ANN 曾经探索过的诸多应用领域[32, 34, 38-41]。

在这期间，BP 的生物合理性也被重新提出并经过广泛讨论[42]，一些更加生物合理的 BP 变种方法也被广泛提出，如反馈校准方法[43]（Feedback Alignment, FA）、奖赏而非误差传播方法[28]（Biologically-plausible Reward Propagation, BRP）、目标传播[44]（Target Propagation, TP）、直接随机目标传播[45]（Direct Random Target Propagation, DRTP）等方法。甚至经典的脉冲时序依赖可塑性（Spike Timing-Dependent Plasticity, STDP）也被论证和 BP 在能量函数约束下具有某种相关性[46]，对 BP 可能是某种生物合理算法这个假设增加了越来越多的佐证。然而，生物中的反向传播虽然有类似的形式，却是以自组织的形式存在且只能存在相邻层次，不支持 2 以上层级的反向传播[47-49]，因此更加合理的自组织反向传播 SBP 算法被提出并在典型的 SNN 和 ANN 网络上验证了其有效性[13]。此外，一些非梯度类的优化方法在 SNN 的学习中也发挥了重要作用，如类似多巴胺奖赏学习的信度分配方法[28, 29]、多种 STDP 的变种方法[23, 50-52]等。一些基础工具的持续开发也极大的增加了相关领域的发展，如标准化 Python 工具包[53, 54]的支持使得大规模、深度 SNN 的软硬件部署[55, 56]成为可能。

上述以计算高效性为出发点的 SNN 模型，已经不仅仅在传统如图像分类[57, 58]等方面表现良好，更在如 DVS 脉冲事件信息处理、连续动态语音识别[59]、连续动作强化学习[30, 60]等方面展示优势。更为重要的是，随着 SNN 模型在精度方面的逐渐提升，研究人员对 SNN 本身的生物特性及其可能具有的应用优势越来越重视。以人工智能应用方向出发的 SNN 研究，也逐步的朝向了生物合理且计算高效的融合方向发展。

1.3 SNN 的交叉融合发展方向

如前所述，SNN 的发展方向已经表现出较为明显的交叉融合趋势。同时满足生物合理和计算高效的應用方向主要有两个：一个是类脑计算智能，包括以高效计算研究为主的类脑芯片以及以通用智能研究为主的认知计算；另一个就是本文重点强调的基于 SNN 的脑机接口解码及调控。类脑计算智能通过深入融合 ANN 和 SNN 的综合计算优势，结合忆阻器等新材料器件，已经在典型的计算应用任务中取得了迅猛发展，如以动态视觉 DVS、动态听觉（Dynamic Audio Sensors, DAS）等感知设备为主的高效信息处理，较好的平衡了计算精度和能量消耗。与之相比，脑机接口应用环境中，侵入式、高通量、噪声强的电极阵列采集得到的脉冲序列信息，天然的适用于 SNN 网络进行信息处理，可以发挥其快速性、鲁棒性、灵活性等优势。

SNN 是由生物现象、机制等发现启发出来的类脑新模型，这类模型折返回来用于解析脑机接口中的生物信号本身，无疑将展示出极大的计算优势。一方面，类脑 SNN 模型满足多尺度生物计算合理性，因此对生物信号的处理天然具有更明确的可解释性。另一方面，已有的计算神经科学已经开展了多种脑功能的 SNN 计算模拟，如海马的学习记忆模拟、视觉感知计算模拟等，这些生物 SNN 模型具有深刻的生物合理性，如多类可塑性机制、生物拓扑结构、兴奋性异质性神经元类型等，可以作为未来生物组织的计算仿真替换。再有，在脑机接口的信号反向调控方面，类脑 SNN 网络也具有较大优势。针对连续刺激控制的神经信号流形，SNN 因为具有较为精准的时序特性而较好的应用于连续动作控制任务中，如强化学习的

Mujoco 控制等[30]。未来,对于癫痫等病人,反向的电刺激幅度、位置、时刻等的具体计算都可以通过 SNN 来实现,达成脑内活动的最优控制。一些以视觉假体和运动假体为主要脑机接口研究方向的领域,还可以结合 SNN 的模拟特色,将 SNN 直接连接到脑内的视觉 V1 或者运动皮层 M1 的部分组织,实现摄像头外设、机器臂外设等设备和脑内组织信息的直接偶联。从生物合理和计算高效的融合大趋势来看,类脑计算智能和脑机接口软硬件在某种程度上也可能会殊途同归,即脑机接口有望基于类脑计算智能的软硬件成果来发挥其关键价值。

2 类脑 SNN 的模型特色及三类传统典型应用

已有的人工智能算法大多处理静态离散信号或动态连续信号,而两者的结合(动态离散信号)却较少应用于传统视听觉感知任务,究其原因,是由于结合后的信号往往具有较明显的事件、异步计算等特性,容易造成软件算法的学习困难。随着 SNN 模型的兴起和广泛应用,传统的视听觉感知设备被更新为独特的异步动态视觉(DVS)或动态听觉(DAS)传感设备,支持特定受限环境下的智能感知任务,如高动态、高速度、低光照、低能耗下的物体识别等。以相机为例,与 DVS 的极高帧率相比,传统光学相机若想要达到类似的帧率标准,则需要耗费极大的软硬件代价,如更新原有硬件设备提升曝光频率或多通道并行处理等。异步事件信号本身具有延迟低、编码率高等独特优势,因此被认为天然适合类脑 SNN 算法。本章节将介绍 SNN 模型的基础特点,以及在视觉信息处理、听觉信号处理、强化学习运动控制等方面的应用。

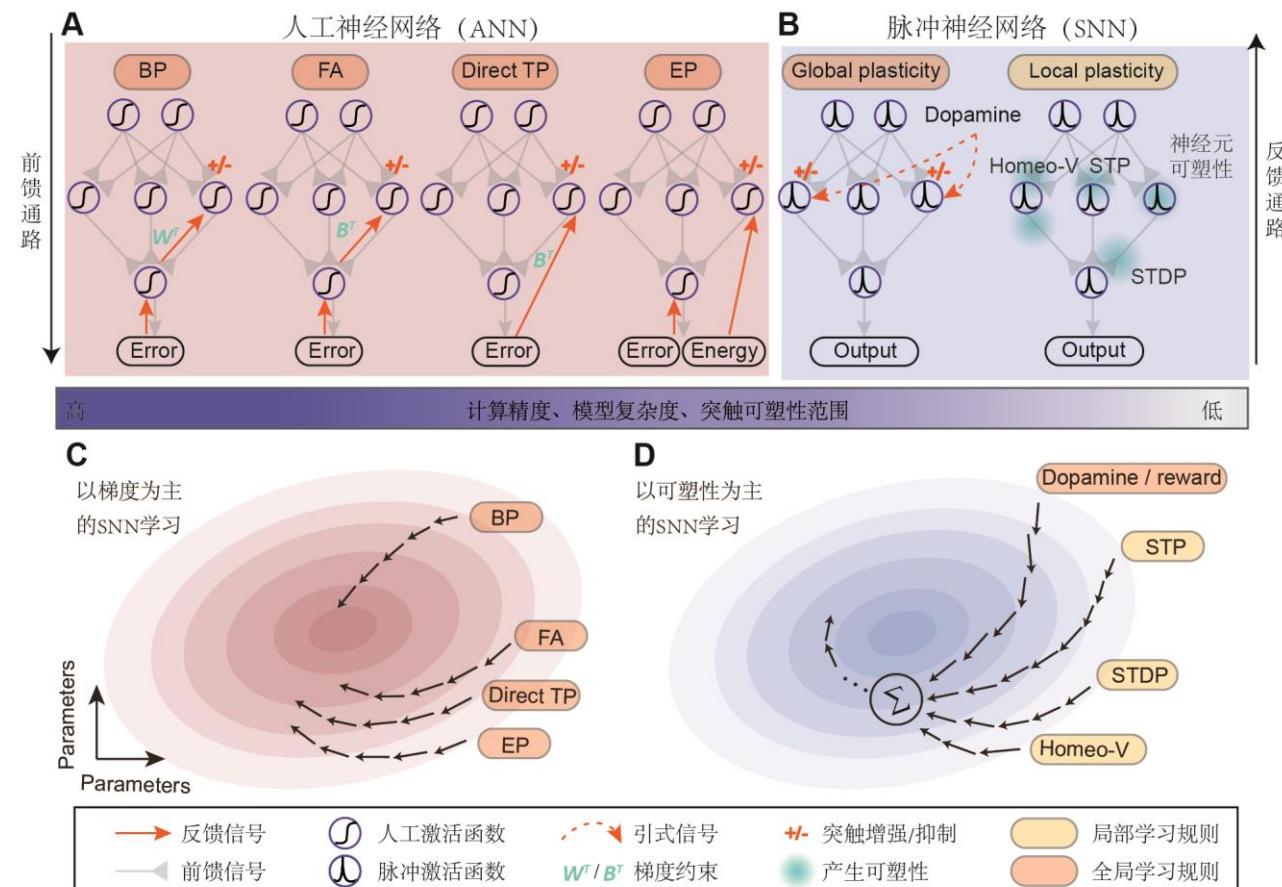


图 2 SNN 和 ANN 的关键特性比较

2.1 SNN 的模型特色及关键优势

SNN 和 ANN 的主要区别在于脉冲节点带来的算子变化以及动态学习方法差异[10]。如图 2A 所示，ANN 中往往采用基于梯度的学习方法，如 BP 反向传播方法，描述了经过层级的信息前馈后，误差随着网络的输出层再反向逐层传递到每个突触，是一种突触调制的数学最优。考虑到 BP 学习方法和生物计算相差太远，一系列朝向生物合理的梯度计算方法被提出，如反馈校准[43] (FA) 方法描述了误差梯度的反向传播过程中不需要前馈权重的约束；目标传播 (TP) [42, 61] 描述了误差或者奖惩信息可以直接作为梯度调制所有中间神经元状态；稳态调优 (EP) [62-64] 描述了局部的神经元状态可以在能量函数约束下达到局部稳态。可以发现，从 BP、FA、TP 到 EP，人工梯度的修改可以朝向越来越生物合理的方向发展。

与人工神经网络的梯度学习方法相比，生物网络往往采用生物可塑性的方法进行学习，如图 2B 所示，通过将多类、多尺度的突触可塑性机制有机组合，整体达到高效的信度分配[9, 65]。在介观尺度，生物中的多巴胺等神经递质可以对多类突触可塑性进行全局影响，引导不同脑区及环路实现不同功能。在微观尺度，突触可塑性如 STDP 描述了突触权值随神经元活动状态改变的机制，如 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 (SBP) [49, 66] 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一层的 LTP 或者 LTD 得到。除了突触可塑性，神经元可塑性涵盖了如稳态阈值 Homeo-V、自适应阈值等[8, 13, 21]。

基于 BP 的学习方法是 ANN 的主流优化方法，可以数学上保证权重更新朝向最小化全局误差方向，如图 2C 所示。与这种精确的数学优化不同，生物更多采用了模糊的多优化策略融合的方法，通过更多的自组织局部学习，将网络整体限定在局部纳什均衡状态，这种状态下全局的网络能量最小。虽然就单独的分类效果而言稍逊于人工 BP 方法，但是仍然能够收敛，如图 2D 所示，该类网络可以在算法复杂度、能量消耗、非监督自组织学习、灵活性等方面都展现出较好的生物特色[21, 22]。

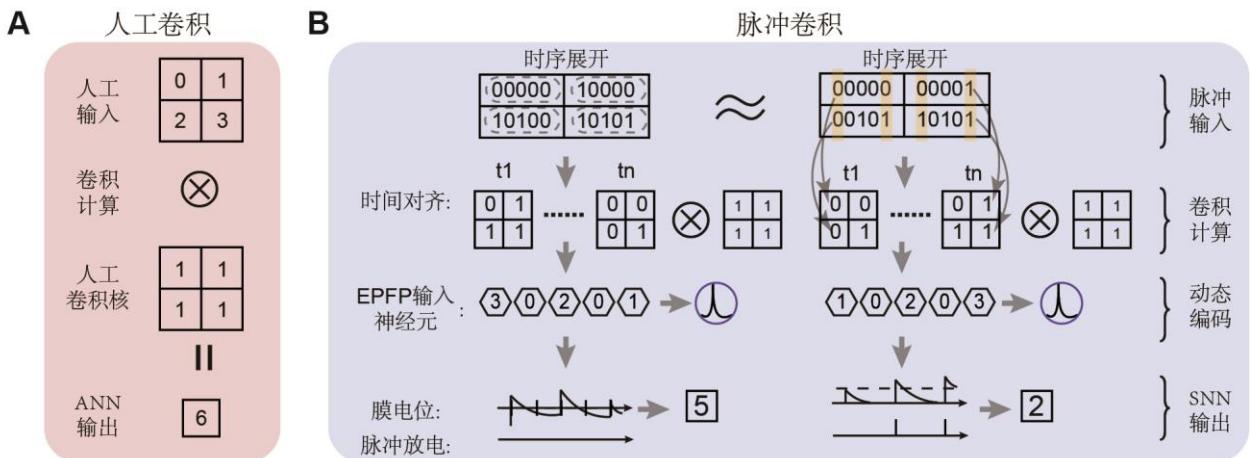


图 3 SNN 和 ANN 的卷积计算比较

此外，由于加入了富有动力学特性的脉冲神经元，以往简单的人工乘法或卷积在计算过程中相当于加入了一个额外的时间维度，带来了时序计算过程的多样性。如图 3A 所示，在人工卷积中，对一个 2×2 的输入矩阵数据（值为 0-3 均匀分布）做卷积核为 2×2 且值全为 1 的卷积操作，传统的人工卷积方法将会按照矩阵浮点乘法得出结果为 6。而在脉冲卷积中，同样的输入经过时间窗口为 5 的时间编码后，除了原本的 0 输入不变只在时间域复用 5 次以外，其他编码都有多种时序编码可能，而不同的时序编码方案会在接下来的卷积和神经元信息整合过程中发生偏差，如图 3B 所示，产生网络输出结果为 5 或 2 或其他多种可能。时序卷积的不同输出强调了时序展开过程中神经脉冲编码的重要性，这类时间信息敏感性为 SNN 在时序信息处理、连续动作控制等方面的优势打好了基础。

2.2 基于 SNN 的动态视觉信息处理

动态视觉 DVS 摄像机将连续不变的视频流视为无信息输入，只将信号的变化积累下来并通过固定或动态阈值检测出 Spike 序列对动态场景进行编码。相比传统基于帧的视觉传感器，动态视觉传感器（DVS）输出的 Spike 信息具有极低的延时和极高的动态范围，因此可以作为传统相机视觉采集的有效补充，进一步提升视觉成像质量和感知性能[67-70]。一方面，事件脉冲极低的延时使其具备对动态场景的连续感知能力，能够为视觉成像和感知任务提供有效的动态纹理变化和场景运动信息，极大缓解了传统图像处理问题中由于帧内或者帧间信息缺失导致的病态问题，如较长曝光时间导致的运动图像模糊。图 4 展示了基于动态视觉相机的图像运动模糊重建和图像插帧原理示意图，在传统图像/视频增强任务中，尤其是面向复杂动态场景下，通过引入额外的动态视觉脉冲信息能够极大的提升算法的精度[67, 69]。

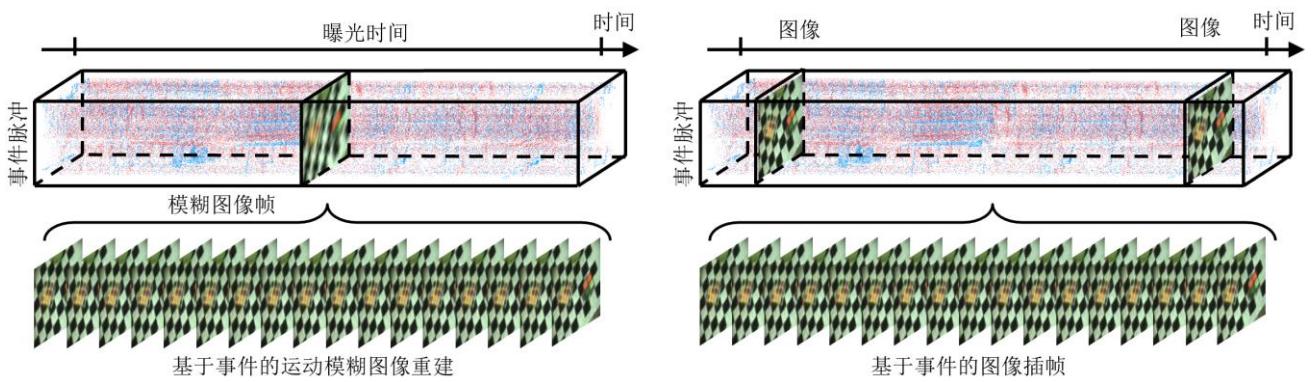


图 4 基于事件的图像运动模糊重建和图像插帧原理示意图[67, 69]

通过将动态 Spike 信息和传统相机采集的视觉信息结合起来，来提升已有相机的综合性能，另一个示例是将生物 What 和 Where 通路结合的双通路检测系统。该方法通常采用分光镜将视觉信息分成两股并输入到不同的相机感知设备上，然后分别最大化的发挥 ANN 和 SNN 的各自优势，分别用来处理自然视频数据以及脉冲视觉信息，如图 5 所示。

生物系统经过长期的遗传进化，视觉信息通过视网膜、外侧膝状体、初级视觉皮层等的公共编码后，视觉感受装置明显的进化出腹侧和背侧两个通路。其中，背侧通路着重对运动方向、空间方位等进行信息处理，因此也常被称为 Where 通路，可以通过 MT 等脑区连接运动皮层，实现快速的运动控制或躲避。由于强调快速、时序敏感等特点，因此这类信息流非常适合 SNN 模型来处理，发挥其内部脉冲事件信息的精确时间信息编码能力，实现大范围、高速度物体的快速检测。

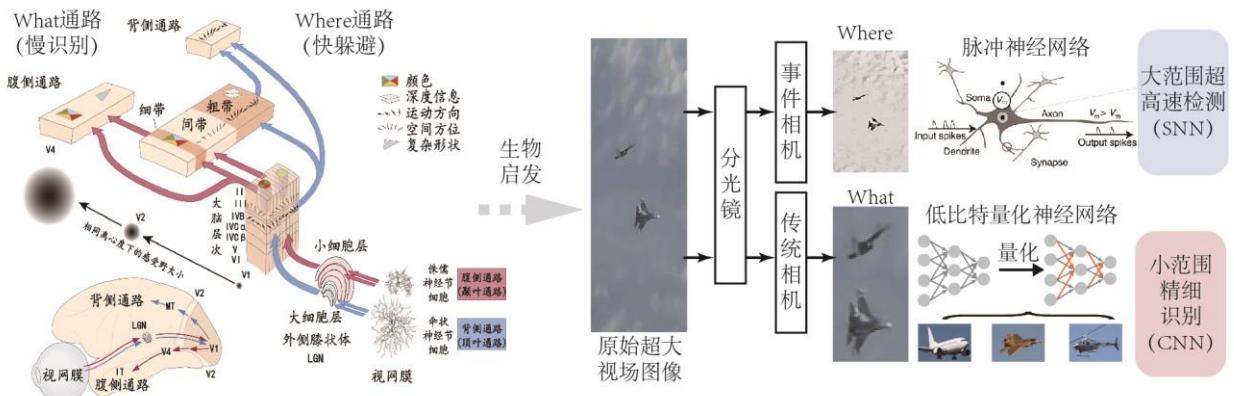


图 5 一种生物视觉双通路启发的类脑 ANN-SNN 视觉感知应用示例[71]

另一方面，视觉的腹侧通路着重对颜色、复杂形状、纹理等进行分析和识别，因此又常被称为 What 通路，如通过 IT 等脑区连接更为复杂的前额叶或海马等脑区，进行更深层次的推理和记忆提取分析。这部分的信息流更适合已有的 ANN 模型来处理，通过结合深层、卷积等模型结构，以及低比特量化、压缩、蒸馏等已有的 ANN 研究基础，可以实现小范围、精细目标的准确识别。

因此，两种相机及各自承载的软件算法各有优势，特别在两者的处理时间及精细度上有较大差异。可以先通过事件相机上的 SNN 快速检测到重要目标，然后再通过普通相机的 ANN 实现精细识别，类似于用 Where 通路来表实现快速运动位置定位，用 What 通路来实现慢速度的精确识别。类似利用 SNN 和 ANN 各自优势的工作还有很多，这里不一一列举。

2.3 基于 SNN 的听觉信号处理

典型的脉冲听觉信息处理流程，是将输入的音频原始信息编码为时间-空间频谱特征，例如梅尔谱，并对频谱做一些关键特征提取和脉冲转换[72, 73]，然后输入到后续的自动语言识别（Automatic Speech Recognition, ASR）模块。但是，基于数字滤波器或者傅里叶变换的时空频谱获取需要大量的计算，导致该编码方法难以部署在资源受限的场景中。具有低功耗优势的动态听觉 DAS[74]则可以直接模拟耳蜗，用来片上实现声源信息的模拟带通滤波，并把滤波器输出的频谱强度编码成连续的的 Spike 序列。由于 DAS 的特征提取能力有限，语音识别的效果仍有待提高。不同于上述“前端-后端”计算模式，基于一维人工或脉冲卷积的“端到端”计算模型可通过学习的方式有效提取时空特征，结合脉冲网络特有的动态时序处理能力，在听觉信号处理的应用中具有巨大的潜力，蕴含着低功耗、高性能的优势。

一种脉冲 Transformer 和动力学神经元相结合的语音识别方案[75]如图 6 所示。其中，多头注意力模块、全连接层等人工 Transformer 设计部分被保留，将脉冲神经元层加入到全连接层之间，替换原本的人工 ReLU 做非线性信息处理。然后，利用脉冲神经单元独有的丰富动力学特性，如一阶或高阶的神经元胞内的动力学编码，可以用于听觉信息处理过程中声学边界的确定[75, 76]。脉冲声学边界的准确提取可以极大的保证 ASR 识别的准确性，并帮助端对端的网络信息处理实现精准的信息分割。因此，结合脉冲声学边界和原始的语音特征可以对语音信息流进行高精度的音素或语音识别，达到相比非脉冲边界辅助的 ASR 模型更低的词错误率和更低的能量消耗[75]。

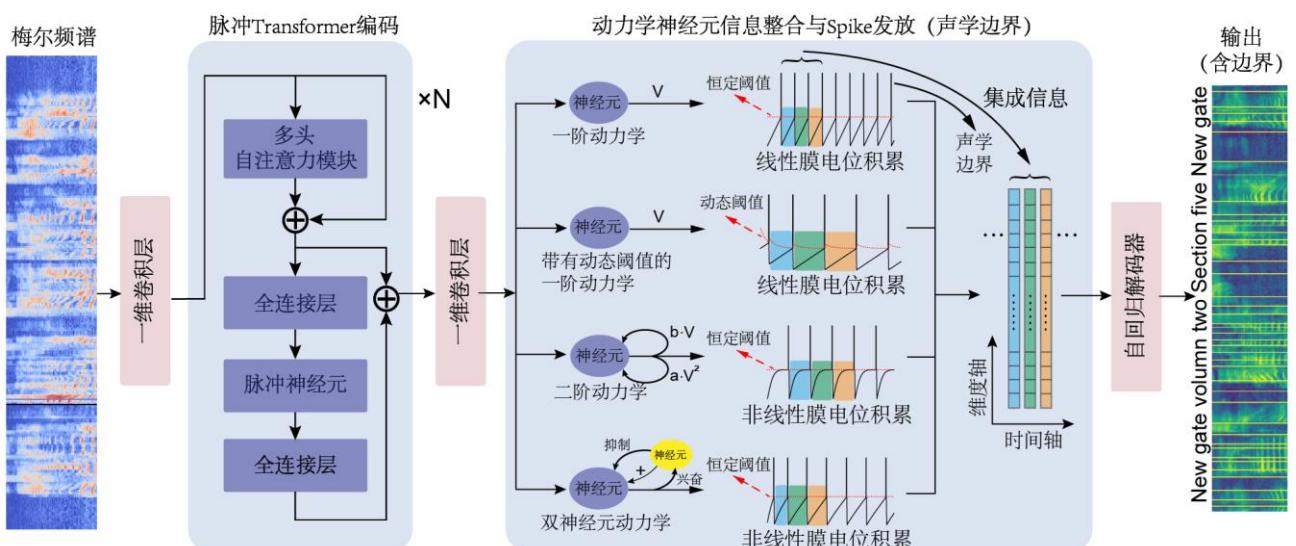


图 6 一种结合脉冲 Transformer 和多类动力学脉冲神经元的 SNN 听觉信息处理示例[75]

2.4 基于 SNN 的强化学习运动控制

SNN 具有典型的时序信息敏感性，因此对于连续动作控制类的强化学习任务天然适配[30, 77]，如 Mujoco 环境，包含不同形态的机器人或无人机等单智能体，可以针对连续的动作场景给出连续的动作输出。与之相比，雅达利 Atair 等任务并不适合采用 SNN 模型来处理。如在 Atair 中控制空间为左转、右转、前进、后退、跳等有限的几个离散动作；对环境的时序状态要求不仅不高，反而经常需要额外设置样本缓存库来随机采样，以去耦合相邻样本间的相关性；且更强调输入输出维度信息的映射和拟合能力。这些特点使得 Atair 任务环境更合适 ANN 而非 SNN 模型。

在 Mujoco 任务中，对于输入原始状态向量，每个数值代表了智能体控制关节、头朝向、转弯等的连续数值；与之类似，对于输出行为向量，每个数值代表了即将对各个关节或状态量的控制数值。这些原始状态向量和连续控制向量，都和时序历史信息高度相关。智能体通过逐步的学会协调身体各个关节，完成某项连续动作控制任务，如四腿蜘蛛学会爬行且越爬越快（Ant-v3，含 111 维感知空间，8 维连续动作空间）、四肢小狗学会跑步（HalfCheetah-v3，含 17 维感知空间，6 维连续动作空间）、人形机器人学会连续站立（Humanoid-v3，含 17 维感知空间，6 维连续动作空间）等[30]。相对简单的 Mujoco 单智能体的控制，更为复杂的如 DeepMind 的 Humanoid Football 任务，则模拟了多智能体协作控制下的复杂踢足球行为[78]。

一个典型的 Mujoco 连续动作控制强化学习应用示例如图 7 所示，SNN 可以作为典型的脉冲策略网络，接受原始的连续状态信息并输出连续动作。在这个过程中，SNN 可以最大化的发挥其时序信息处理优势。考虑到 SNN 采用事件信息进行连续计算有可能会导致计算精度的降低，可以采用神经元集群编码的方式补充部分损失。如对不同维度的原始状态进行多神经元群的状态升维编码，然后再经过脉冲序列化输入到 SNN 中。SNN 中的不同类型动力学神经元的协同编码，也可以进一步的增强 SNN 信息处理能力，最后经过群体解码输出行为动作。进一步的，在学习阶段，可以补充 ANN 为一个额外的价值评估网路，并融合传统的 TD3 或 PPO 等强化学习框架，辅助 SNN 策略网络的损失评估^[30]；在应用阶段，只保留 SNN 策略网络进行单智能体的连续动作控制，回归脉冲网络连续控制的初衷。特别的，Mujoco 的连续动作控制类任务，非常类似动物的生存任务，而采用生物合理的 SNN 网络进行信息处理且发挥优势，从某种意义上说，实现了从实验范式到模型设计的多尺度生物合理闭环。

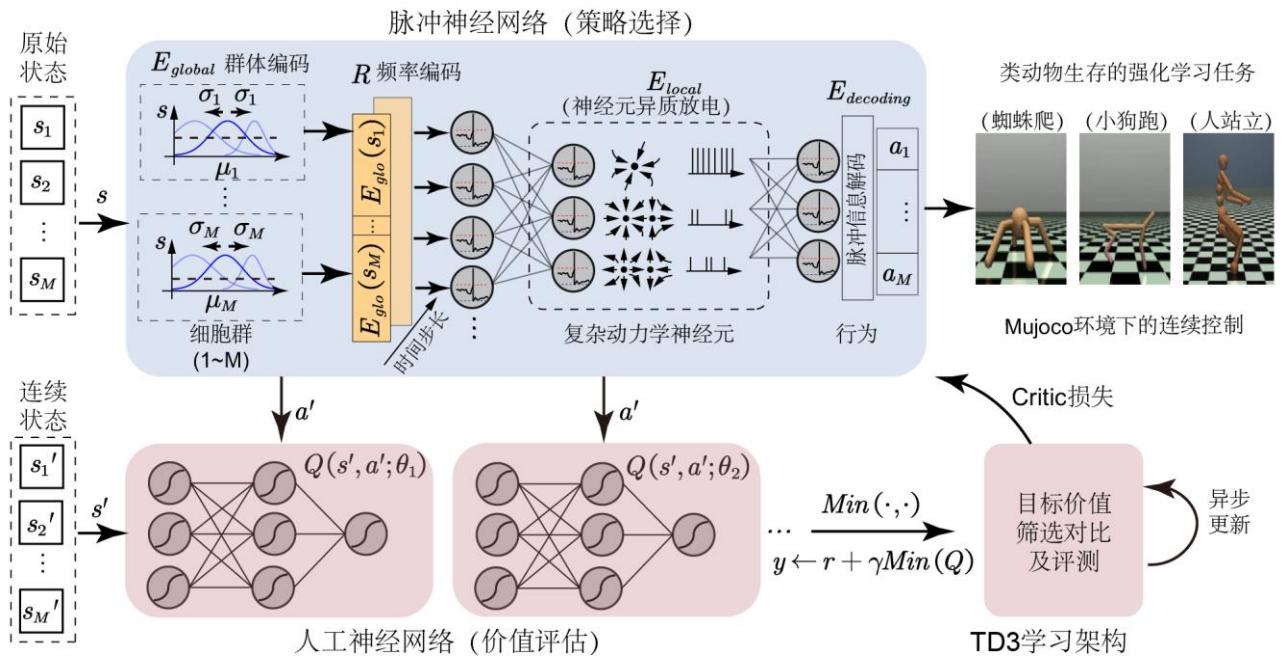


图 7 一种脉冲策略网络为主、人工评估网络为辅的强化学习连续控制应用示例^[30]

3 实验新范式：基于 SNN 的脑机接口脉冲序列识别和控制

上述的动态视觉信息处理、听觉信息处理、强化学习运动控制等传统典型实验范式，由于具有不同形式和复杂程度的时序信息，因此相对 ANN 而言更为适配 SNN 模型。然而上述经典实验范式并不完美，在信息处理过程中，需要将图片、语音频谱等连续信息预编码为脉冲序列信息，然后再输入到 SNN 模型中进行脉冲信息处理，这个过程本身包含了不小的信息损失。DVS、DAS 等脉冲编码类设备的出现，也只是将软件脉冲预编码替换为硬件预编码，并没有从根本上解决编码转化过程中的时序信息损失问题。

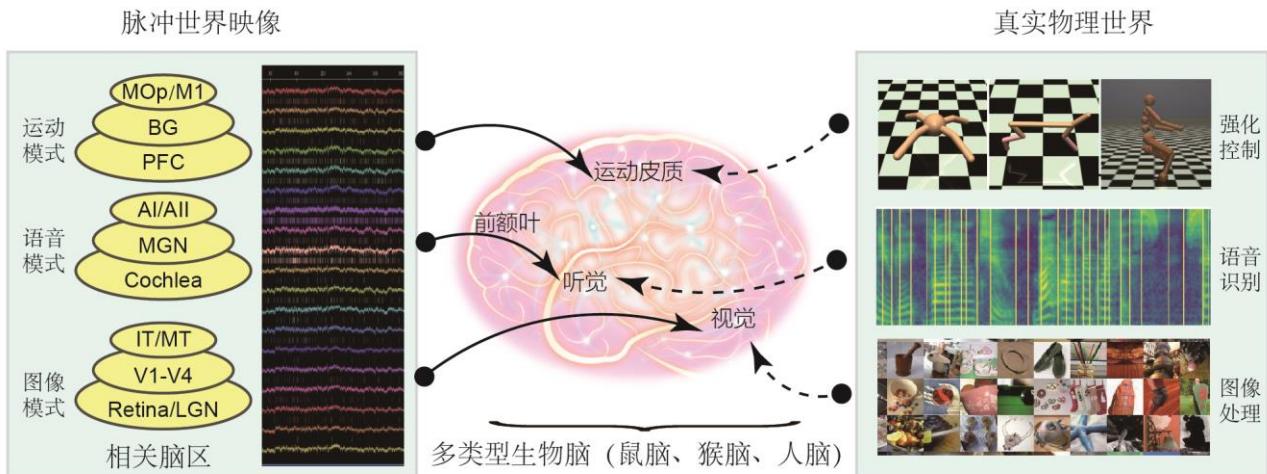


图 8 高通量侵入式脑机接口脉冲序列作为外部世界的复杂映像

有没有一类现实的应用范式，天然的具有脉冲序列特征而不需要额外的时序脉冲转码呢？答案是存在的，而且就在我们的大脑中。与上述这些物理世界的实验任务范式相比，大脑内部的神经脉冲序列，可以看作一个真实外界物理世界的脑内虚拟脉冲世界镜像。这个脉冲镜像具有和外部世界可比拟的复杂度，外界的视频、音频、连续控制等物理信息，都可以在这里找到对应的脉冲序列版本映射，如图 8 所示。随着脑机接口领域的快速发展，生物脑数据信息编解码逐步的从非侵入式模式（如 EEG、fMRI 等）转换为侵入式模式（如 NeuroPixels 等），由刚性过渡为柔性，由低通量逐步增加为高通量的同步信息记录。如 2021 年马斯克的 NeuroLink 电极覆盖了 1024 通道，支持多脑区的同步信息记录及反向调控刺激。临港实验室、中科院自动化所等也同步开展了多通道脑机接口相关的软硬件工作布局，并构建基于 SNN 的脑信息处理新型算法模型，支持多通道脉冲序列的在线解码和反向调控。

脑内的复杂动力学系统产生了大量脉冲序列来表征对外界物理世界的多模态信息感知、处理及控制。这些脉冲序列信息来源于大脑的不同计算区域，且具有不同的抽象层级。对这些脑内的分属视觉、听觉、触觉、动觉或其他躯体感知觉的脉冲序列信息进行模式识别，其需要的模型能力和处理 DVS/DAS 视音频事件信息相似，且因为大脑中存在着的大量脉冲噪声而使得信息处理更具挑战性。本章节将重点介绍基于脑机接口的 SNN 实验新范式，以及 SNN 模型本身在这类范式上的天然优势。

3.1 鼠脑延迟匹配任务范式

基于小鼠延迟配对舔水任务的脉冲工作记忆和认知决策可以作为一个典型的 SNN 新范式，如图 9A 所示。经典的小鼠基于嗅觉的延迟性配对偶联（Olfactory Delayed Paired Association, ODPA）任务范式[79]，规定了小鼠在一个较长间隔期内分别被给予两个配对（Paired）或不配对（Non-paired）的气味输入，通过间隔期内工作记忆维持的不同时长来影响小鼠的最终抉择。工作记忆维持的时间范围很广，涵盖几百毫秒

到秒或分钟、小时级别；覆盖的脑区范围也很广泛，包括感知皮层、海马、内侧前额叶等，同时涉及感知-决策通路，如嗅觉区域、视觉区域、运动区域等。工作记忆维持依赖延迟期内信息在多脑区、跨皮层和呈现不同编码模式的神经元间的流动，全脑尺度大范围神经元脉冲序列间有着明显的时相关系，契合 SNN 模型的天然优势。通过记录感知、工作记忆等高度相关的 50 个以上关键脑区及海量 Spike 信息序列，研究时序感知、记忆依赖的认知决策意义重大[80]。在任务中，工作记忆的延迟时间（Delay）被设定为 3 秒和 6 秒两种模式，以微组块（Mini-block）的形式交替出现。样本气味（Sample）时间为 1 秒，测试气味（Test）时间为 1 秒，反应时间（Response）为 1 秒。Sample 和 Test 气味不一样，并在单个试次（Trial）中进行配对组合。小鼠在配对试次的反应时间内舔水（命中，Hit），或在不配对试次中不舔水（正确拒绝，Correct Rejection），视为正确行为；小鼠在配对试次的反应时间内不舔水（错失，Miss），或在不配对试次中舔水（误报，False Alarm），视为错误行为。由于小鼠必须形成 Sample 和 Test 气味的正确配对关系，才能熟练执行 ODPA 任务实验范式，因此，小鼠直到 Test 气味出现都无法进行抉择、运动计划和预期奖赏。考虑到 Sample 气味完全不同于 Test 气味，且 Sample 和 Test 气味在试次中位置固定，试次结构清晰，在延迟期内的小鼠舔水行为几乎不发生。在这类新型 ODPA 任务实验范式下，小鼠脑将空间（气味经过群体编码）和时间（在不同区间的信息维持及 Delay 期间的工作记忆维持等）的编码整合到脉冲序列中。ODPA 任务实验范式使得小鼠对抉择、运动计划和执行、奖赏预期的编码从大规模脉冲序列中剥离开来，而 3 秒和 6 秒延迟期的实验设计又能够精确地将时间编码信号从大规模脉冲序列中识别出来。综上，ODPA 任务实验范式能极大地发挥 SNN 模型的优势，基于 SNN 的解码算法需要针对这类特异性的时空流形数据进行分类，并还原实验在给定 Sample-Delay-Response 情况下的预期结果。

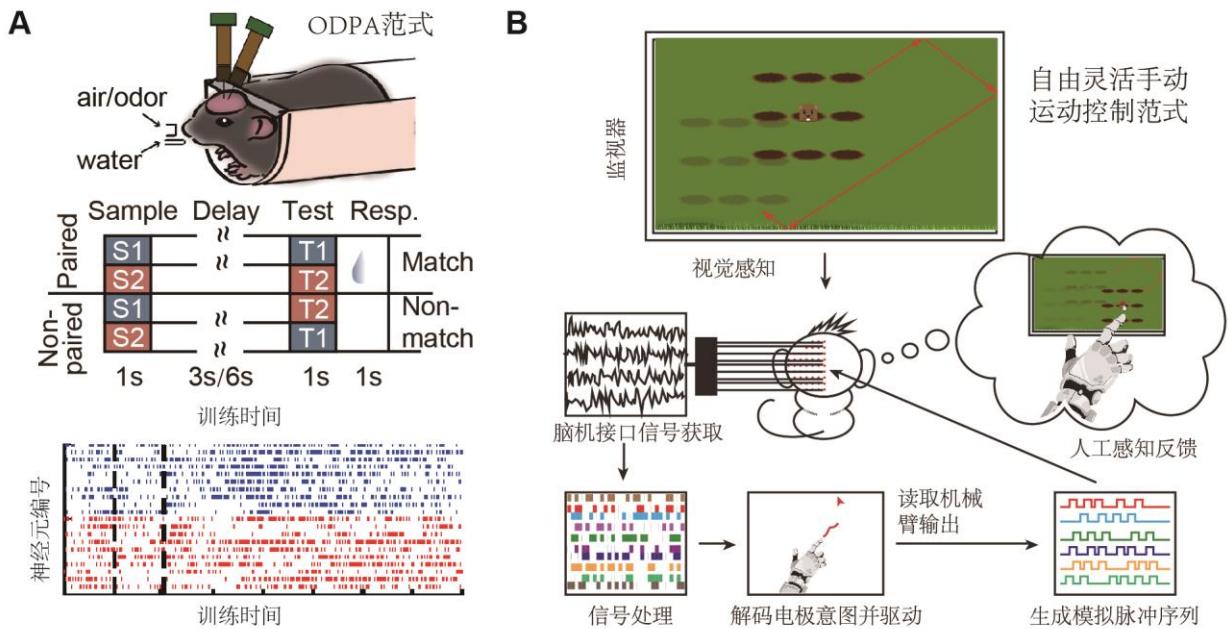


图 9 两种典型模式动物的生物实验范式示例及对应的脉冲序列数据集

3.2 猴脑自由抓取任务范式

基于猕猴自由抓取任务的脉冲连续运动控制可以作为另一个典型的 SNN 新范式，可以根据实验设计的不同稍有变化。如固定有限 Reach 点的 Center Out 任务；灵活 Reach 的自由抓取任务等。猕猴通过视觉输入刺激，决定当前形势下需要手动移动的目标，如正确则奖励，否则惩罚。该项任务将重点对运动皮层、前运动皮层、前额叶、基底神经节等相关脑区做同步电极记录，在控制的规划期、执行期等不同阶段产生复杂的脉冲序列，同时记录猕猴手部的真实运动轨迹，用以作为外设运动控制的金标准。

运动控制范式作为成熟脑机接口研究方向之一，是适于 SNN 快速测试并探索应用的极佳场景。传统

的运动控制行为范式主要以单调刻板运动为切入点进行运动学参数解码并驱动外设（如机械臂假肢）进行运动，而对自由灵活手动运动控制范式下的探索则仍较为有限，部分原因在于目前流行的线性神经解码算法在非单调刻板行为下对复杂的运动状态的估计表现不佳。为探究自由灵活手动下高效纯脑活动运动控制的实现，猕猴手动触屏运动控制行为范式如打地鼠任务被重点应用【】。如图 9B 所示，一组试验在猕猴触摸起始信号后将进入打地鼠场景，在一定的试验次数中，将有地鼠随机从 9 个地鼠洞中冒出，被试需要在一定的反应时间限内触碰地鼠所在位置，否则将被视为错失目标，进入短暂的试验间隔后将随机出现下一个地鼠，如此在一组试验中反复。由于没有限定起始与固定的终点，被试执行此行为范式时手部是自由的。为了更进一步地实现运动控制的灵活性，地鼠洞将被设置为可连续整体移动的模式，被试将利用大脑前馈式预测地鼠洞和地鼠的位置以实现准确击打。结合基于电刺激的闭环体感反馈，SNN 网络解码器有望在此类自由运动控制行为范式下取得优异表现。

3.3 人脑深部脑刺激任务范式

通过高通量的脑电数据采集，将感知、工作记忆、决策区域中的不同脉冲放电过程记录下来，我们可以通过瞬态记忆轨迹的形式展示不同 Spike 放电序列的模式特点。然后经过数据的标准化、数据对齐、简单的噪声滤波之后，就可以形成标准的 SNN 新范式数据集，以供后续的 SNN 工作记忆、识别和反向控制。与小鼠或猴子等模式动物不同，面向人类神经回路调控的脑深部脑刺激（Deep Brain Stimulation, DBS）改变了治疗和理解人类大脑疾病的方式，DBS 可以改善患有多种神经疾病患者的生活质量，如原发性震颤、帕金森病、肌张力障碍等[81]。传统 DBS 的治疗刺激参数通常依赖预设和经验值，无法动态地与患者行为、药物疗效和外部环境因素的短期变化相适应[82]。此外，对差异化的不同患者而言，非匹配的参数或者固定的刺激参数可能严重影响治疗效果，甚至产生不良反应。针对传统深部脑刺激参数时程匹配性、个体差异性等方面的局限性，业内期望基于脑电信号开发能够自适应调控的智能化深部脑刺激技术[83]。该类技术通过植入式 DBS 脉冲发生器将神经刺激与侵入性神经状态感知相结合，根据神经环路的实时状态决定刺激参数，包括刺激频率、刺激幅度和脉宽等。如通过借助 Hodgkin-Huxley 类型 SNN 网络设计基于强化学习闭环深部脑刺激方法就是一个典型的应用示例[84]，该方法基于丘脑基底神经节计算模型来调节深部脑刺激的参数，实验结果表明这种闭环控制策略可以有效地恢复丘脑功能，且减少深部脑刺激器件的能耗。由于神经状态感知的脑电信号本身就是脉冲发放的形式，加之脉冲神经网络计算的低功耗特性，预期基于 SNN 深部脑刺激智能化计算芯片及系统将会有良好的应用前景。

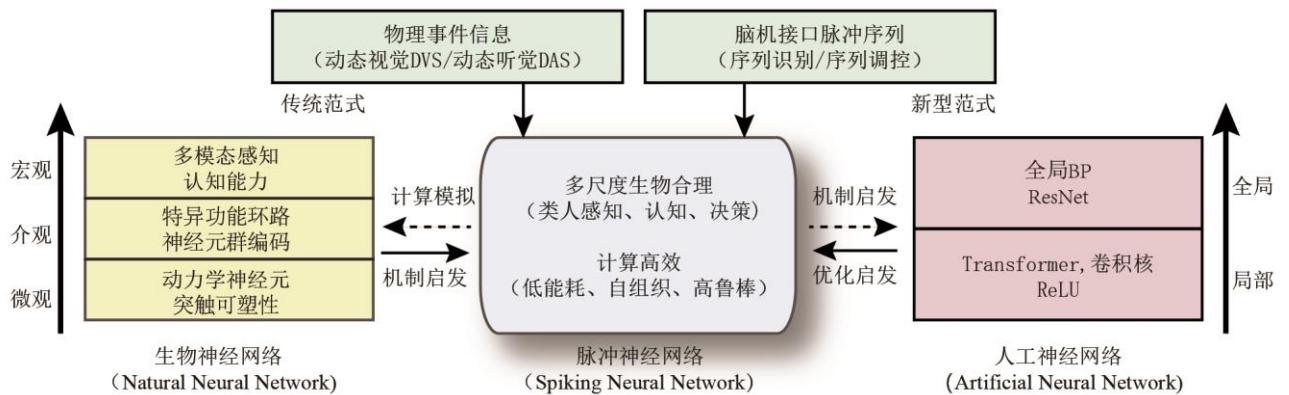


图 10 融合生物和人工网络优势的 SNN 模型天然适合动态视听觉和脑机接口两类典型范式

3.4 SNN 算法与新范式的关系

SNN 具有天然的多尺度生物合理性，如图 10 所示，在节点设计上 SNN 借鉴了生物神经元脉冲时序积

分、漏电放电等特征；在结构上相对参考了多种的生物认知环路拓扑结构，形成具有生物特色的功能特异环路；在学习方法上，也利用了很多生物合理的可塑性学习方法，如时序依赖可塑性、短时突触可塑性等。SNN 同时借鉴了很多现有的 ANN 研究进展，并引入以梯度为主的优化方法，以及卷积核、Transformer 等结构，极大的增强了 SNN 在模式识别方面的能力。SNN 本身的节点、结构、学习方法等融合设计，天然的使得 SNN 本身具有处理事件异步信息的优势。前述的 DVS 或者 DAS 等事件信息处理范式，以及脑机接口中的高通量脉冲序列处理，都是两类 SNN 的典型应用范式。随着高通量脑机接口的快速发展，逐步增多的生物实验范式记录了越来越多的生物脉冲序列数据集。这些数据集合覆盖了多种脑区、参与了多类认知功能，这些都增加了脉冲序列识别和调控的难度。我们相信，一方面，基于脑机接口的脉冲序列识别和控制，将是一类为 SNN 量身定做的新型实验范式，有望更好的发挥 SNN 时序信息处理、异步信息整合的优势。另一方面，随着生物大脑的解构，越来越多的生物编码、结构、学习方法等机制机理将被发掘出来，同时结合已有的 ANN 研究进展，将有望启发得到更多的新型类脑 SNN 模型，并在精度、性能、鲁棒性、泛化性、灵活性等多方面展示出优势。

4 总结和讨论

本文首先通过对 SNN 的应用发展和历史演进进行分析，总结 SNN 在生物模拟计算和人工智能应用两个平行应用领域的科研进展，并指出随着时间推演，两个领域正展现出逐渐交叉融合的趋势，而侵入式、高通量的脑机接口由于同时涉及脉冲序列的模拟、识别和反向控制，因此极有可能成为下一步 SNN 领域的一个新型融合范式。然后，介绍 SNN 模型本身的特色及时序、连续信息处理优势，并介绍以动态视觉、听觉、连续控制等三类经典任务范式下的特色解决方案。最后，重点介绍 SNN 在脑机接口范式下的脉冲序列识别和控制，介绍具有脉冲序列特色的工作记忆决策、运动控制等小鼠、猕猴等生物实验范式，并将脑内的复杂信息处理和脑外的经典任务做横向对比。

我们认为，针对脑内高通量复杂脉冲序列的模式识别和连续控制，将具有和脑外物理世界镜像任务（如动态视听识别、连续运动控制等）相似或更高的复杂程度，可以未来作为适合 SNN 应用的天然典型验证场景之一，最大化的发挥 SNN 在脉冲编码、节点、结构、可塑性等多尺度生物合理性方面的诸多优势，而嵌入 SNN 认知功能的神经形态器件未来也有望进一步作为脑机接口核心芯片辅助视觉或运动假体，未来可期。

参 考 文 献

1. Maass, W., *Networks of spiking neurons: The third generation of neural network models*. Neural Networks, 1997. **10**(9): p. 1659-1671.
2. Zenke, F., E.J. Agnes, and W. Gerstner, *Diverse synaptic plasticity mechanisms orchestrated to form and retrieve memories in spiking neural networks*. Nat Commun, 2015. **6**: p. 6922.
3. Liu, Y.H., et al., *Cell-type-specific neuromodulation guides synaptic credit assignment in a spiking neural network*. Proc Natl Acad Sci U S A, 2021. **118**(51).
4. Wang, W., et al., *Learning of spatiotemporal patterns in a spiking neural network with resistive switching synapses*. Sci Adv, 2018. **4**(9): p. eaat4752.
5. Duan, Q., et al., *Spiking neurons with spatiotemporal dynamics and gain modulation for monolithically integrated memristive neural networks*. Nat Commun, 2020. **11**(1): p. 3399.
6. Kumar, A., S. Rotter, and A. Aertsen, *Spiking activity propagation in neuronal networks: reconciling different perspectives on neural coding*. Nat Rev Neurosci, 2010. **11**(9): p. 615-27.
7. Gutig, R., *Spiking neurons can discover predictive features by aggregate-label learning*. Science, 2016. **351**(6277): p. aab4113.

8. 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).
9. Zeng, Y., T.L. Zhang, and B. Xu, *Improving multi-layer spiking neural networks by incorporating brain-inspired rules*. Science China-Information Sciences, 2017. **60**(5): p. 052201.
10. 张铁林 and 徐波, *脉冲神经网络研究现状及展望*. 计算机学报, 2020: p. 在线发表.
11. Yamazaki, K., et al., *Spiking Neural Networks and Their Applications: A Review*. Brain Sci, 2022. **12**(7).
12. Bellec, G., et al., *A solution to the learning dilemma for recurrent networks of spiking neurons*. Nat Commun, 2020. **11**(1): p. 3625.
13. Zhang, T., et al., *Self-backpropagation of synaptic modifications elevates the efficiency of spiking and artificial neural networks*. Sci Adv, 2021. **7**(43): p. eabh0146.
14. Seung, H.S., *Learning in spiking neural networks by reinforcement of stochastic synaptic transmission*. Neuron, 2003. **40**(6): p. 1063-1073.
15. Fiete, I. and H.S. Seung, *Gradient learning in spiking neural networks by dynamic perturbation of conductances*. Physical review letters, 2006. **97** 4: p. 048104.
16. Zhang, X., et al., *Spike-based indirect training of a spiking neural network-controlled virtual insect*. IEEE Conference on Decision and Control, 2013.
17. Zenke, F., *Memory formation and recall in recurrent spiking neural networks*. 2014, EPFL University.
18. Zhang, T., et al. *HMSNN: Hippocampus inspired Memory Spiking Neural Network*. in *The IEEE International Conference on Systems, Man, and Cybernetics*. 2016. Budapest, Hungary.
19. Zhao, B., et al., *Feedforward Categorization on AER Motion Events Using Cortex-Like Features in a Spiking Neural Network*. Ieee Transactions on Neural Networks and Learning Systems, 2015. **26**(9): p. 1963-1978.
20. Nicola, W. and C. Clopath, *Supervised learning in spiking neural networks with FORCE training*. Nat Commun, 2017. **8**(1): p. 2208.
21. Zhang, T., et al. *A Plasticity-centric Approach to Train the Non-differential Spiking Neural Networks*. in *The Thirty-Second AAAI Conference on Artificial Intelligence (AAAI)*. 2018. New Orleans, USA: AAAI.
22. Zhang, T., et al. *Brain-inspired Balanced Tuning for Spiking Neural Networks*. in *The Twenty-Seventh International Joint Conference on Artificial Intelligence*. 2018. Stockholm, Sweden: IJCAI.
23. Hao, Y., et al., *A biologically plausible supervised learning method for spiking neural networks using the symmetric STDP rule*. Neural Netw, 2020. **121**: p. 387-395.
24. Zhang, T., Y. Zeng, and B. Xu, *A computational approach towards the microscale mouse brain connectome from the mesoscale*. J Integr Neurosci, 2017. **16**(3): p. 291-306.
25. Jia, S., et al. *Motif-topology and Reward-learning improved Spiking Neural Network for Efficient Multi-sensory Integration*. in *International Conference on Acoustics, Speech and Signal Processing*. 2022. Visual Conference: IEEE.
26. Kim, Y., et al., *Neural Architecture Search for Spiking Neural Networks*. European Conference on Computer Vision (ECCV), 2022.
27. Kim, Y., et al. *Exploring Lottery Ticket Hypothesis in Spiking Neural Networks*. in *European Conference on Computer Vision (ECCV)*. 2022.
28. Zhang, T., et al., *Tuning Convolutional Spiking Neural Network With Biologically Plausible Reward Propagation*. IEEE Trans Neural Netw Learn Syst, 2021. **PP**.
29. Jia, S., et al., *Neuronal-Plasticity and Reward-Propagation Improved Recurrent Spiking Neural Networks*. Front Neurosci, 2021. **15**: p. 654786.
30. Zhang, D., et al. *Multiscale Dynamic Coding improved Spiking Actor Network for Reinforcement Learning*. in *Thirty-Sixth AAAI Conference on Artificial Intelligence*. 2022. Virtual conference.

31. Wu, Y., et al. *Direct training for spiking neural networks: Faster, larger, better*. in *The AAAI Conference on Artificial Intelligence*. 2019. Hawaii, USA: AAAI.
32. Lee, J.H., T. Delbrück, and M. Pfeiffer, *Training Deep Spiking Neural Networks Using Backpropagation*. *Front Neurosci*, 2016. **10**: p. 508.
33. Huh, D. and T.J. Sejnowski. *Gradient descent for spiking neural networks*. in *Advances in Neural Information Processing Systems*. 2018. Montreal, Canada: Curran Associates, Inc.
34. Wu, Y., et al., *Spatio-Temporal Backpropagation for Training High-Performance Spiking Neural Networks*. *Front Neurosci*, 2018. **12**: p. 331.
35. Stromatias, E., et al., *An Event-Driven Classifier for Spiking Neural Networks Fed with Synthetic or Dynamic Vision Sensor Data*. *Front Neurosci*, 2017. **11**: p. 350.
36. Bobrowski, O., R. Meir, and Y.C. Eldar, *Bayesian filtering in spiking neural networks: noise, adaptation, and multisensory integration*. *Neural Comput*, 2009. **21**(5): p. 1277-320.
37. Brette, R. and D.F. Goodman, *Simulating spiking neural networks on GPU*. *Network*, 2012. **23**(4): p. 167-82.
38. O'Connor, P. and M. Welling, *Deep spiking networks*. arXiv, 2016. [cs.NE/1602.08323](https://arxiv.org/abs/1602.08323).
39. Wu, J., et al., *Progressive Tandem Learning for Pattern Recognition with Deep Spiking Neural Networks*. Arxiv, 2020. [cs](https://arxiv.org/abs/2003.00001).
40. Lee, C., et al., *Enabling Spike-Based Backpropagation for Training Deep Neural Network Architectures*. *Front Neurosci*, 2020. **14**: p. 119.
41. Kheradpisheh, S.R. and T. Masquelier, *Temporal Backpropagation for Spiking Neural Networks with One Spike per Neuron*. *Int J Neural Syst*, 2020. **30**(6): p. 2050027.
42. Lillicrap, T.P., et al., *Backpropagation and the brain*. *Nat Rev Neurosci*, 2020. **21**(6): p. 335-346.
43. Lillicrap, T.P., et al., *Random synaptic feedback weights support error backpropagation for deep learning*. *Nat Commun*, 2016. **7**: p. 13276.
44. Meulemans, A., et al. *A Theoretical Framework for Target Propagation*. in *Advances in Neural Information Processing Systems*. 2020. Curran Associates, Inc.
45. Frenkel, C., M. Lefebvre, and D. Bol, *Learning Without Feedback: Fixed Random Learning Signals Allow for Feedforward Training of Deep Neural Networks*. *Front Neurosci*, 2021. **15**: p. 629892.
46. Mnih, A. and G. Hinton. *Learning nonlinear constraints with contrastive backpropagation*. in *Neural Networks, 2005. IJCNN'05. Proceedings. 2005 IEEE International Joint Conference on*. 2005. IEEE.
47. Kobayashi, K. and M.M. Poo, *Spike train timing-dependent associative modification of hippocampal CA3 recurrent synapses by mossy fibers*. *Neuron*, 2004. **41**(3): p. 445-54.
48. Du, J.L., et al., *Long-range retrograde spread of LTP and LTD from optic tectum to retina*. *Proc Natl Acad Sci U S A*, 2009. **106**(45): p. 18890-6.
49. Bi, G. and M. Poo, *Synaptic modification by correlated activity: Hebb's postulate revisited*. *Annu Rev Neurosci*, 2001. **24**(1): p. 139-66.
50. Zhao, D., et al., *GLSNN: A Multi-Layer Spiking Neural Network Based on Global Feedback Alignment and Local STDP Plasticity*. *Front Comput Neurosci*, 2020. **14**: p. 576841.
51. Kheradpisheh, S.R., et al., *STDP-based spiking deep convolutional neural networks for object recognition*. *Neural Netw*, 2018. **99**: p. 56-67.
52. Tavanaei, A. and A.S. Maida, *Bio-inspired spiking convolutional neural network using layer-wise sparse coding and STDP learning*. arXiv preprint arXiv:1611.03000, 2016.
53. Hazan, H., et al., *BindsNET: A Machine Learning-Oriented Spiking Neural Networks Library in Python*. *Front Neuroinform*, 2018. **12**: p. 89.
54. Mozafari, M., et al., *SpykeTorch: Efficient Simulation of Convolutional Spiking Neural Networks With at Most*

- One Spike per Neuron.* Front Neurosci, 2019. **13**: p. 625.
55. Sengupta, A., et al., *Going Deeper in Spiking Neural Networks: VGG and Residual Architectures*. Front Neurosci, 2019. **13**: p. 95.
56. Tavanaei, A., et al., *Deep learning in spiking neural networks*. Neural Netw, 2019. **111**: p. 47-63.
57. Wade, J.J., et al., *SWAT: a spiking neural network training algorithm for classification problems*. IEEE Transactions on Neural Networks, 2010. **21**(11): p. 1817-30.
58. Sporea, I. and A. Grüning, *Supervised learning in multilayer spiking neural networks*. Neural computation, 2013. **25**(2): p. 473-509.
59. Wu, J., et al., *A Spiking Neural Network Framework for Robust Sound Classification*. Front Neurosci, 2018. **12**: p. 836.
60. Yuan, M., et al., *Reinforcement Learning in Spiking Neural Networks with Stochastic and Deterministic Synapses*. Neural Comput, 2019. **31**(12): p. 2368-2389.
61. Frenkel, C., M. Lefebvre, and D. Bol, *Learning without feedback: Direct random target projection as a feedback-alignment algorithm with layerwise feedforward training*. arXiv, 2019. **stat.ML/1909.01311**.
62. Zhang, T., et al. *A Plasticity-centric Approach to Train the Non-differential Spiking Neural Networks*. in *The National Conference on Artificial Intelligence*. 2018. New Orleans, USA.
63. Zhang, T., et al. *Brain-inspired Balanced Tuning for Spiking Neural Networks*. in *The International Joint Conferences on Artificial Intelligence*. 2018. Stockholm, Sweden.
64. Scellier, B. and Y. Bengio, *Equilibrium Propagation: Bridging the Gap between Energy-Based Models and Backpropagation*. Front Comput Neurosci, 2017. **11**: p. 24.
65. Abbott, L.F., B. DePasquale, and R.M. Memmesheimer, *Building functional networks of spiking model neurons*. Nat Neurosci, 2016. **19**(3): p. 350-5.
66. Dan, Y. and M.M. Poo, *Spike timing-dependent plasticity: from synapse to perception*. Physiol Rev, 2006. **86**(3): p. 1033-48.
67. Wang, B., et al. *Event enhanced high-quality image recovery*. in *European Conference on Computer Vision*. 2020. Springer.
68. Lin, S., et al. *Autofocus for Event Cameras*. in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2022.
69. Zhang, X. and L. Yu. *Unifying Motion Deblurring and Frame Interpolation with Events*. in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2022.
70. Liao, W., et al. *Synthetic Aperture Imaging With Events and Frames*. in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2022.
71. Schwartz, J.H., T.M. Jessell, and E.R. Kandel, *Principles of neural science*. 1991: Elsevier New York.
72. Dennis, J., et al. *Temporal coding of local spectrogram features for robust sound recognition*. in *IEEE International Conference on Acoustics, Speech and Signal Processing*. 2013.
73. Gutig, R. and H. Sompolinsky, *Time-warp-invariant neuronal processing*. PLoS Biol, 2009. **7**(7): p. e1000141.
74. Liu, S.C., et al., *Asynchronous binaural spatial audition sensor with 2 x 64 x 4 channel output*. IEEE Trans Biomed Circuits Syst, 2014. **8**(4): p. 453-64.
75. Wang, Q., et al. *Complex dynamic neurons improved spiking transformer network for efficient automatic speech recognition*. in *Thirty-Seventh AAAI Conference on Artificial Intelligence (AAAI 2023)*. 2022.
76. Dong, L. and B. Xu. *CIF: Continuous Integrate-And-Fire for End-To-End Speech Recognition*. in *The international conference on acoustics, speech, and signal processing (ICASSP)*. 2020.
77. Han, X., K. Jia, and T. Zhang. *Mouse-Brain Topology improved Evolutionary Neural Network for Efficient Reinforcement Learning*. in *International Conference on Intelligence Science (ICIS 2022)*. 2022.

78. Liu, S., et al., *From motor control to team play in simulated humanoid football*. *Sci Robot*, 2022. **7**(69): p. eab0235.
79. Baddeley, A., *Working memory: theories, models, and controversies*. *Annu Rev Psychol*, 2012. **63**: p. 1-29.
80. Zhu, J., et al., *Transient Delay-Period Activity of Agranular Insular Cortex Controls Working Memory Maintenance in Learning Novel Tasks*. *Neuron*, 2020. **105**(5): p. 934-946 e5.
81. Lozano, A.M., et al., *Deep brain stimulation: current challenges and future directions*. *Nat Rev Neurol*, 2019. **15**(3): p. 148-160.
82. Krauss, J.K., et al., *Technology of deep brain stimulation: current status and future directions*. *Nat Rev Neurol*, 2021. **17**(2): p. 75-87.
83. Beudel, M. and P. Brown, *Adaptive deep brain stimulation in Parkinson's disease*. *Parkinsonism Relat Disord*, 2016. **22 Suppl 1**: p. S123-6.
84. Lu, M., et al., *Application of Reinforcement Learning to Deep Brain Stimulation in a Computational Model of Parkinson's Disease*. *IEEE Trans Neural Syst Rehabil Eng*, 2020. **28**(1): p. 339-349.