

中图法分类号: 文献标识码: A 文章编号: 1006-8961(XXXX)XX-0001-32

论文引用格式: Yang Shuangming, Shen Jiangrong, Li Youjun, Huang Zigang, Chen Badong. Recent advances and future prospects in brain-inspired artificial intelligence research[J/O]. Journal of Image and Graphics, XXXX:1-32. DOI: 10.11834/jig.260022. (杨双鸣, 申江荣, 李尤君, 黄子罡, 陈霸东. 脑启发的人工智能研究进展与展望[J/O]. 中国图象图形学报, XXXX:1-32. DOI: 10.11834/jig.260022. ) [DOI: 10.11834/jig.260022]

## 脑启发的人工智能研究进展与展望

杨双鸣<sup>1</sup>, 申江荣<sup>2,4</sup>, 李尤君<sup>3</sup>, 黄子罡<sup>3</sup>, 陈霸东<sup>4</sup>

1. 天津大学电气自动化与信息工程学院, 天津 300072; 2. 西安交通大学电信学部, 西安 710049; 3. 西安交通大学生命学院, 生物医学信息工程教育部重点实验室, 西安 710049; 4. 人机混合增强智能全国重点实验室, 西安交通大学人工智能与机器人研究所, 西安 710049

**摘要:** 脑启发的人工智能以人类大脑的结构与功能机制为灵感, 旨在构建具备低功耗与强泛化能力的新型智能系统。当前以深度学习为核心的人工智能方法在计算资源开销、能耗、可解释性与适应性方面仍存在显著不足, 难以在复杂多变或资源受限的环境中实现持续学习与灵活推理。相比之下, 大脑展现出在并行处理、低功耗、快速泛化及自适应学习等方面的天然优势, 这为突破传统人工智能范式提供了重要启示。本文系统综述了脑启发的人工智能领域的国内外研究进展。从脑结构启发的角度, 分析了神经元模型、神经环路与神经调制机制的多层级建模方法; 从脑功能启发的角度, 探讨了感知、认知、学习、决策与控制等智能环节的算法创新路径; 从硬件系统的角度, 总结了具有近内存与存算一体架构的新型类脑计算系统的发展现状。报告进一步比较了国际与国内在理论研究、算法优化与硬件实现等方面的差异与互补优势。最后, 展望了未来脑启发的人工智能在算法-硬件协同、跨学科融合及产业化应用方面的发展趋势, 提出了推动我国在该领域实现跨越式突破的关键方向。

**关键词:** 脑启发; 类脑智能; 脑结构; 脑功能; 类脑计算系统

## Recent advances and future prospects in brain-inspired artificial intelligence research

Yang Shuangming<sup>1</sup>, Shen Jiangrong<sup>2,4</sup>, Li Youjun<sup>3</sup>, Huang Zigang<sup>3</sup>, Chen Badong<sup>4</sup>

1. School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China; 2. Faculty of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China; 3. School of Life Sciences and Technology, Key Laboratory of Biomedical Information Engineering of Ministry of Education, Xi'an Jiaotong University, Xi'an 710049, China; 4. State Key Laboratory of Human-Machine Hybrid Augmented Intelligence; Institute of Artificial Intelligence and Robotics, Xi'an Jiaotong University, Xi'an 710049, China

**Abstract:** Brain-inspired artificial intelligence (AI) seeks to emulate the structural organization, functional mechanisms, and adaptive learning principles of the human brain, with the goal of developing intelligent systems that exhibit high energy efficiency, strong generalization capability, continual learning, and robust adaptability to complex environments. Despite the remarkable success of contemporary artificial intelligence approaches dominated by deep learning, these methods remain fundamentally constrained by high computational cost, excessive energy consumption, limited interpretability, and

收稿日期: 2026-01-09; 修回日期: 2026-02-09

**基金项目:** 国家自然科学基金项目(32541016, 62376185, 62306274), 脑科学与类脑研究国家科技重大专项(编号: 2021ZD0201300) 国家自然科学基金项目(32541016, 62376185, 62306274), 脑科学与类脑研究国家科技重大专项(编号: 2021ZD0201300)

**Supported by:** National Natural Science Foundation of China (32541016, 62376185, 62306274), and Brain Science and Brain-like Intelligence Technology-National Science and Technology Major Project (Grant 2021ZD0201300) National Natural Science Foundation of China (32541016, 62376185, 62306274), and Brain Science and Brain-like Intelligence Technology-National Science and Technology Major Project (Grant 2021ZD0201300)

weak adaptability to non-stationary or resource-constrained environments. Such limitations hinder their deployment in real-world scenarios that require long-term autonomy, online learning, and efficient decision-making under uncertainty. In contrast, the human brain represents an unparalleled natural intelligent system, capable of performing perception, cognition, learning, memory, and decision-making in parallel while consuming only tens of watts of power. This exceptional efficiency arises from the synergistic interaction of neuronal dynamics, synaptic plasticity, neural circuit organization, and neuromodulatory regulation across multiple spatial and temporal scales. These characteristics provide profound inspiration for rethinking the computational paradigms, learning mechanisms, and hardware architectures underlying artificial intelligence. Consequently, brain-inspired artificial intelligence has emerged as a frontier research direction at the intersection of neuroscience, artificial intelligence, electronic engineering, and materials science, aiming to bridge the gap between biological intelligence and engineered systems. This paper presents a comprehensive review of recent advances in brain-inspired artificial intelligence from both international and domestic perspectives. From the viewpoint of brain structural inspiration, we systematically analyze multi-level modeling approaches spanning neuronal models, neural circuits, and neuromodulatory systems. The evolution of spiking neuron models and spiking neural networks (SNNs) is reviewed, with particular emphasis on the trade-offs between biological plausibility, computational efficiency, and scalability. Key mechanisms such as dendritic nonlinearity, neuronal heterogeneity, synaptic dynamics, and event-driven information processing are discussed in terms of their contributions to efficient temporal encoding, sparse computation, and robustness. Furthermore, neuromodulatory mechanisms inspired by dopamine, acetylcholine, and other neurotransmitters are examined, highlighting their roles in regulating learning rates, credit assignment, and context-dependent adaptation, and their potential to support continual learning and mitigate catastrophic forgetting in artificial systems. From the perspective of brain functional inspiration, this paper reviews algorithmic developments across core intelligent functions, including perception, attention, memory, learning, reasoning, decision-making, and control. Brain-inspired principles underlying convolutional architectures, recurrent neural networks, attention mechanisms, reinforcement learning, and meta-learning are analyzed, revealing how biological concepts such as hierarchical processing, temporal recurrence, selective attention, reward-driven learning, and multi-timescale adaptation have shaped modern artificial intelligence algorithms. Special attention is paid to recent trends toward integrating multiple cognitive functions into unified architectures, enabling closer coupling between perception, cognition, and action, and facilitating more flexible and generalizable intelligence. From the hardware and system implementation perspective, this paper summarizes the state of the art in neuromorphic computing systems designed to support brain-inspired algorithms. Emerging computing paradigms based on near-memory computing and in-memory computing architectures are reviewed, emphasizing their ability to overcome the von Neumann bottleneck and achieve significant gains in energy efficiency and parallelism. Advances in neuromorphic devices, including memristors, ferroelectric devices, electrochemical memory elements, and novel transistor structures, are discussed with respect to their capability to emulate synaptic plasticity, neuronal dynamics, and memory-computation co-location at the physical level. The importance of algorithm-hardware co-design is highlighted, as efficient deployment of brain-inspired intelligence critically depends on the co-optimization of learning rules, network architectures, device characteristics, and system-level communication mechanisms. In addition, this paper provides a systematic comparison of international and domestic research efforts in brain-inspired artificial intelligence. While international research has demonstrated strong advantages in fundamental neural modeling, large-scale neuromorphic platforms, and interdisciplinary collaboration, domestic research has made rapid progress in application-oriented system integration, independently developed neuromorphic hardware, and large-scale brain-inspired computing platforms. The complementary strengths and existing gaps between these research trajectories are analyzed, offering insights into future collaborative and competitive development strategies. Finally, future directions and challenges in brain-inspired artificial intelligence are discussed. Key trends include deeper algorithm, hardware co-design, tighter integration between neuroscience and artificial intelligence, and the development of scalable, interpretable, and energy-efficient intelligent systems for real-world applications. Emphasis is placed on advancing theoretical foundations, improving system-level robustness and adaptability, and accelerating the translation of brain-inspired technologies into industrial and societal applications. Several strategic directions are outlined to promote leapfrog advances in brain-inspired artificial intelligence, particularly in the context of China's long-term scientific and technological develop-

ment.

**Key words:** brain-inspired; neuromorphic intelligence; brain structure; brain function; neuromorphic systems

## 0 引言

近年来,人工智能(artificial intelligence, AI)技术在深度学习、强化学习及自然语言处理等领域取得了突破性进展,极大推动了计算机视觉、语音识别、自动驾驶及智能医疗等产业的发展。然而,这一以数据驱动和统计学习为核心的范式在走向高层次智能的过程中暴露出若干瓶颈(Lake等,2017)。例如传统的深度学习通常依赖大量标注数据和高算力,缺乏少样本自适应能力,并且其学习机制远离生物神经过程,难以实现持续高效学习。

相较之下,人类大脑作为自然界中最复杂的智能系统,仅以约20瓦功率便能同时完成感知、学习、记忆与决策等多层次任务,依托约860亿个神经元及其突触构成的庞大动态网络,实现高能效的并行处理、冗余补偿与快速泛化,而其学习过程则由时间顺序与化学调制等多层机制协同驱动(Azevedo等,2009)。这些特征为新一代人工智能提供了可借鉴的理论框架,因此脑启发的人工智能成为近年来人工智能领域的一个前沿研究方向(Schuman等,2022; Zheng等2025)。

脑启发的人工智能的核心思想是借鉴人脑在认知与信息处理方面的基本原理,将这些原理转化为人工系统的算法和结构。它试图通过模仿神经元放电规律、神经环路连接模式与神经调制机制,实现更贴近生物智能的信息处理方式。在结构层面,近年来脉冲神经网络(spiking neural network, SNN)的理论体系在Maass提出的框架(Maass,1997)基础上取得了显著发展。Eshraghian等人(2023)提出的替代梯度(surrogate gradient, SG)训练方法,使深度SNN具备了可端到端训练的能力,在事件驱动、低功耗和时间序列处理任务中展现出更高效率。在功能层面,近年来脑启发认知模型逐步从早期的Spaun(Eliasmith等,2012)等结构扩展到更具泛化能力的框架。Wang等人(2018)提出的“前额叶作为元学习系统”模型为任务适应和策略重构提供了新的认知解释;此外,最新研究(Mei等,2025)表明,借鉴多巴胺、乙酰胆碱等调制机制可显著提升人工网络的持

续学习能力,为构建高适应性的智能系统提供了新的思路。在硬件层面,近年来涌现了多样化的新型存储器件,主要包括忆阻器、相变存储器、铁电晶体管存储器、Mott存储器、电化学随机存取存储器,以及基于二维材料、光子、自旋等新原理的器件。这些器件为类脑计算提供了更高能效和生物仿真度的物理基础。

脑启发的人工智能推动了神经科学、计算机科学、电子学及材料科学等学科深度融合,是人工智能范式演进的重要方向。其研究涵盖模型算法、硬件系统与认知机制,并在智能机器人、自动驾驶、脑机接口与神经康复等领域展现出广阔前景。本文旨在系统梳理该领域的研究现状与发展趋势,对比分析不同技术路径在神经建模、功能模拟与硬件实现方面的特点,进而总结当前挑战与未来机遇,并提出关键发展方向与建议。

## 1 国际研究现状

当前,国际上的脑启发人工智能研究呈现出深度交叉融合的特点,学术界与产业界协同演进。美国、欧洲及日本在该领域起步较早,在基础理论、神经形态硬件及应用系统开发方面总体领先。其核心驱动力在于克服传统人工智能的高能耗、低可解释性及自适应能力有限等固有瓶颈。研究普遍致力于通过精细的神经元动力学建模、特定脑区功能机制模拟,以及与之匹配的专用神经形态芯片设计,探索算法与硬件的协同优化路径。

### 1.1 脑结构启发的人工智能

大脑结构启发的人工智能研究以理解和模拟神经元这一大脑信息处理的基本单元为核心。神经元通过突触连接形成高度复杂的网络,其并行计算、冗余容错与信息融合等特性,构成了神经形态计算的功能基础。

#### 1.1.1 神经元模型

生物神经元的结构如图1所示,其主要包括细胞体、树突和轴突,动作电位在突触间的传播会引发兴奋或抑制,从而实现并行而高效的信息处理。人工神经元利用数学函数模拟这一过程:接收输入信

号并加权求和,再由激活函数决定是否输出,最终将结果传递至下游神经元。多个人工神经元互联形成人工神经网络(artificial neural network, ANN),通过调整连接权重实现学习与适应,具备并行计算、容错性和模式识别等能力。神经元模型的发展经历了从简单数学抽象到复杂生物仿真的过程,不同类型的神经元模型在生物真实性和计算效率上各有优势。




图1 生物神经元的结构(Kandel等,2000)

Fig. 1 Structure of a biological neuron (Kandel et al, 2000)

早期的经典模型以Hodgkin和Huxley(1952)提出的Hodgkin-Huxley(HH)模型为代表,该模型通过对枪乌贼巨轴突实验数据的拟合,能够精确描述动作电位的产生与传播,是生物神经元电生理建模的理论基础。然后由于HH模型结构复杂、计算成本高,研究者随后发展了多个简化模型以提升计算可行性。1962年,Nagumo等人将HH神经元简化为FitzHugh-Nagumo神经元模型,既降低了复杂度,又保留了动作电位的关键动态特性,可以模拟基本的神经元放电活动(Nagumo等人,1962)。1985年,Chay在HH框架基础上构建了用于刻画胰腺 $\beta$ 细胞电活动特性的三变量动力学模型,展示了神经元模型从通用建模向特定细胞类型建模的拓展(Chay, 1985)。在脉冲神经网络SNN快速发展的背景下,近二十年提出的模型更多关注在生物真实性与计算效率之间取得平衡。2003年,Izhikevich模型,通过仅需四个变量即可复现多种皮层神经元的发放模式,是工程实现与动力学建模的关键桥梁(Izhikevich, 2003)。2016年,Allen Institute发布了基于大规模电生理记录构建的广义积分-发放(generalized leaky integrate-and-fire model, GLIF)模型系列(Tetter等,2018),利用对不同类型皮层神经元的实验数据拟合得到多种参数化模型,既能保留不同神经元

类型的发放特性,又具有训练和部署效率高的优点,是目前系统级神经建模的重要工具。2021年,研究者提出可学习参数的LIF神经元模型(Fang等, 2021),使膜时间常数、阈值电位等动力学变量能够作为网络参数参与端到端训练,进一步提高了SNN的适应能力与表达能力。此外,还有多种具有代表性的脉冲神经元模型,如漏电积分-发放(leaky integrate-and-fire, LIF)模型(Delorme等,1999)、多室模型(Beniaguev等,2021)与脉冲响应模型(spike response model, SRM)(Jolivet和Gerstner,2003)等模型。尽管已有多种脉冲神经元模型在生物真实性与计算效率之间取得了不同程度的平衡,但如何构建既具备较高计算可扩展性,又能更真实反映神经元动力学特性的模型,仍是推动神经元启发人工智能发展的核心问题。未来神经元模型的研究趋势将更加强调生物动力学机制、可学习参数与硬件可实现性的融合,以支撑更高效、更智能的类脑计算系统。

神经元模型不仅推动了对生物神经元电生理机制的理解,也启发了人工神经网络结构的发展。受神经元结构与工作方式的启发,国际研究界先后提出了人工神经网络ANN与脉冲神经网络SNN两类重要模型。如图2所示,图a、图b分别展示了ANN与SNN的基本单元结构。ANN通过引入隐藏层、非线性激活函数以及反向传播(backpropagation, BP)算法(Rumelhart等,1986)实现复杂的非线性映射,并在图像识别、语音识别与自然语言处理等领域取得显著成果。然而,ANN基于连续数值计算与全局梯度下降,其工作方式与生物神经系统存在差异,缺乏事件驱动特性和时间依赖的脉冲机制,因而在能耗与泛化能力方面仍存在局限。为弥补这些不足,研究者发展了更接近生物神经元工作机制的第三代神经网络—SNN(Mass,1997)。SNN以离散脉冲作为信息载体,利用时间编码执行计算,可在输入超过阈值时产生脉冲并在网络中传播。这种事件驱动的计算方式使得SNN在低功耗、高并行、高时间敏感性处理等方面具有优势(Ahmed等,2014),其在模式识别、视觉感知和机器人控制等任务中已展现出良好应用前景(黄铁军等,2022;余磊等,2025)。然而,由于脉冲信号的离散与不连续特性,传统基于梯度的反向传播算法难以直接应用于SNN。针对这一挑战,国际研究者从生物可塑性机制出发,持续探索可替代的学习方法。早期研究可追溯至Hebb

(2005)提出的Hebbian机制,其核心思想是“共同激活的神经元会增强突触连接”,这一原理为突触可塑性理论奠定了基础。随后,Caporale等人(2008)对Hebbian机制进行了系统总结,提出了脉冲时间依赖可塑性(spike-timing-dependent plasticity, STDP)理论,指出突触权重的变化取决于前后神经元脉冲发放的时间差,这一规则成为模拟生物学习的重要依据。基于这一原理,Tavanaei等人(2019)提出了BP-STDP框架,通过STDP近似反向传播过程,将生物启发的突触更新机制与监督学习相结合,显著提升了SNN的可训练性与任务适应性。随着网络深度与复杂度的增加,SNN在训练过程中面临梯度消失、计算负担过重以及时序依赖难以建模等问题,这极大限制了其在复杂任务中的性能提升。为此Dampfhofer等人(2023)构建了基于反向传播的深层SNN系统化训练框架,阐述了从ANN到SNN的模型映射机制(如图2c)及梯度近似方法,并将学习范式划分为空间编码、时空编码与单脉冲编码三类。

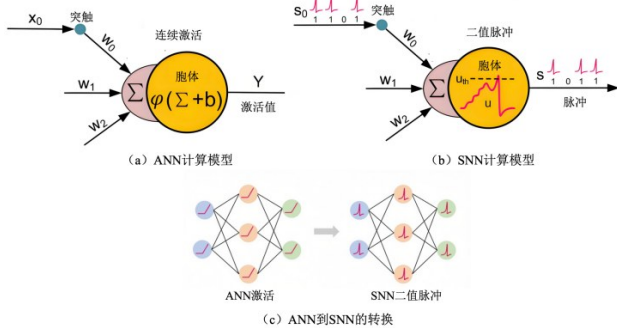


图2 ANN与SNN的计算模型及结构映射(Wu等,2024;Hu等,2024)

Fig. 2 Computational models of ANN and SNN and their structural mapping(Wu et al, 2024; Hu et al, 2024)

综合来看,现有SNN学习方法的本质上是“生物合理性”与“工程实用性”的平衡。然而,这些研究面临着共性瓶颈,如梯度计算在精度与效率上难以兼顾,深层网络的长时序依赖建模能力不足且计算负担重,以及模型因优化策略偏离生物基础而导致的可解释性与硬件部署协同性薄弱。为了突破这些瓶颈,一是推动生物启发模型与工程优化的深度融合,以提升可解释性与效率;二是发展跨模态编码与多任务适配能力,拓展其在复杂场景中的应用;三是加强算法与硬件的协同设计,构建“优化-适配-能效提升”的闭环。

### 1.1.2 神经环路启发的人工智能

现代神经科学技术的快速发展,如功能磁共振成像、脑片电生理记录、光遗传学等,使科学家能够更深入地研究神经环路的结构与功能。研究发现,大脑中不同区域的神经环路具有多样化的连接模式与功能特点(Bargmann和Marder,2013),如感觉信息处理环路、运动控制环路、学习与记忆环路、情感调节环路等。这些神经环路之间相互协作、相互制约,形成复杂的神经网络系统,共同完成大脑的高级认知功能。例如图3展示了神经环路与认知功能之间的关系。同时,对神经环路中神经元群体编码、神经信号整合与传递规律的研究不断深入,为神经环路启发人工智能的模型构建和算法优化提供了更丰富的理论资源。

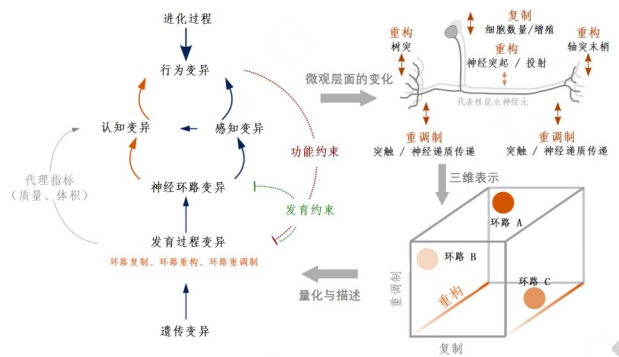


图3 神经环路与认知关系(Farnworth和Montgomery,2024)

Fig. 3 Relationship between neural circuits and cognition (Farnworth and Montgomery, 2024)

美国的BRAIN Initiative(Brain Research through Advancing Innovative Neurotechnologies)项目致力于通过推动创新的神经技术,建立更全面的大脑功能图景。该项目利用先进的神经成像技术,如功能磁共振成像和光遗传学,深入探索大脑各个细胞及其复杂神经环路在不同时间和空间维度上的相互作用(Bargmann和Newsome,2014)。BRAIN Initiative强调利用这些技术揭示大脑功能的复杂性,并推动对神经环路层次化结构和动态交互机制的深入理解。此外,DeepMind提出了“神经环路仿生强化学习框架”(Wang等,2018),模拟前额叶-基底神经节-海马系统的多层交互机制,通过循环连接实现了基于奖励的行为学习和长期记忆整合,在复杂任务(如Atari游戏与空间导航)中表现出与人类类似的泛化策略。麻省理工学院DiCarlo Lab实验室提出了性能

优化的层次神经网络模型(Yamins等,2014),用于模拟高级视觉皮层(如下颞皮层 Inferior Temporal cortex, IT 区)的神经反应。该模型在物体识别任务上的分类性能与其预测IT区神经元响应的能力高度相关,且其层次结构与大脑视觉皮层层次特征高度一致,为神经环路启发的人工智能提供了重要参考。

### 1.1.3 神经调制系统启发的人工智能

神经调制系统启发的人工智能(Vecoven等,2020)近年来逐渐成为类脑智能研究中的重要方向,其核心思想并非简单引入新的生物信号,而是通过模拟生物神经系统中调制机制,对学习过程本身进行动态、情境依赖的调控。在生物系统中,多巴胺、乙酰胆碱、去甲肾上腺素和血清素等神经调制剂并不是直接编码具体信息,而是通过调节神经元兴奋性与突触可塑性,重塑学习速率、信用分配和行为策略的更新方式,从而在复杂环境中实现高效适应与长期稳定行为。这一特性为突破传统人工神经网络“静态参数、固定学习规则”的局限提供了重要启发。

从功能层面看,不同神经调制信号在生物系统中承担着分工明确但相互协同的调控角色。例如,多巴胺信号与奖赏预测误差密切相关,是强化学习中策略更新与价值评估的关键驱动力(Lerner等,2021);乙酰胆碱主要调节注意与感知精度,在不确定环境中增强与当前任务相关的信息通道;去甲肾上腺素参与觉醒与应激调节,影响探索—利用平衡;血清素则与行为抑制和情绪调控相关(Morilak等,2005)。这类“调制—执行”分离的机制,使生物智能体能够在保持基本结构稳定的同时,根据情境快速切换学习策略和行为模式。

在人工智能模型中,引入神经调制机制的关键价值在于为学习过程增加一个可控、可解释的调节维度。一方面,调制信号可用于实现动态学习率调整和上下文感知,使智能体在稀疏奖励或非平稳环境中保持有效学习能力。例如,将多巴胺机制融入强化学习框架,有助于提升策略更新的稳定性与样本效率(Schultz,2024)。另一方面,在脉冲神经网络中,调制机制能够对神经元发放概率和突触更新强度进行全局或通道级控制,从而提高编码效率与信息保真度(霍兵强等,2023)。Maass等人(2007)指出,调制信号可作为上下文变量,显著增强SNN对复杂时间结构任务的表达能力。Shen等人(2024)

通过模拟大脑前额叶皮层神经元集群在连续学习过程中的选择性激活机制,显著提升了脉冲神经网络模型在连续学习场景的多任务学习能力。

在学习规则层面,神经调制进一步促进了学习机制由“固定突触可塑性”向“情境依赖可塑性”的转变。Frémaux等人(2013)提出的三因素学习规则,将传统的突触活动与时序依赖项扩展为“突触活动—时间关系—调制信号”三元耦合形式,使权重更新能够与奖赏或行为结果建立更直接的联系。基于资格迹的模型(Gerstner等,2018)进一步表明,突触更新可以被延迟触发,从而解决生物和工程系统中普遍存在的信用分配问题。Bellec等人(2020)提出的E-prop算法将这一思想系统化,引入调制信号调节突触可塑性的灵敏度,在连续学习场景中有效缓解了灾难性遗忘。最新研究(González-Redondo等,2025)则进一步展示了乙酰胆碱作为通道特异的可塑性门控信号,在多刺激、多动作任务中显著提升学习效率与抗干扰能力。

总体而言,神经调制机制的引入使人工神经网络不再仅依赖单一、静态的学习规则,而是具备了根据环境状态和任务需求动态调整学习策略的能力。这为构建具备持续学习、多任务适应和强泛化能力的智能系统提供了新的理论框架。然而,该方向仍面临显著挑战:生物神经调制系统涉及多种递质、多尺度动力学及跨脑区交互,现有模型难以完整刻画其核心机制;调制因子的引入也会加剧模型非线性与参数耦合,增加训练不稳定性与计算开销。此外,目前多数神经调制模型仍以经验设计为主,缺乏统一的数学形式与可验证的理论分析框架,制约了其在大规模系统中的推广应用。

### 1.2 脑功能启发的人工智能

大脑的功能启发为人工智能提供了算法层面的重要灵感,是连接神经科学机理与工程智能系统的重要桥梁。不同于神经元结构和神经环路层面的“形态仿生”主要关注计算单元及其连接方式,功能启发更强调对大脑在感知、注意、记忆、学习、推理、决策与控制等认知活动机制的抽象与模拟,关注信息在不同功能模块之间的流动、整合与调节方式。相关研究往往不直接复刻具体的生物结构,而是从功能层面提炼具有普适意义的计算原则,并将其转化为可扩展的算法框架。这些研究不仅推动了深度学习模型的演化,也为构建具备泛化、自适应与解释

能力的新型智能系统提供了理论支撑。

### 1.2.1 感知功能启发的人工智能

#### 1) 卷积神经网络(convolutional neural network, CNN)

CNN模拟视觉皮层的局部感受野与层次化特征提取机制,通过卷积核的局部连接和权值共享策略,实现从底层特征(边缘、纹理)到高层语义(物体结构、场景概念)的逐层抽象(Krizhevsky等,2012)。作为一种处理具有网格数据结构的深度学习模型,CNN已成为计算机视觉、语音识别、自然语言处理等领域的核心算法框架。

2012年,CNN在ImageNet大规模视觉识别挑战赛中取得了突破性成果,Hinton团队提出的AlexNet模型(Krizhevsky等,2012)通过深层卷积架构与ReLU激活函数,将Top-5分类错误率从26%降至15.3%,首次显著超越传统方法,标志着深度学习在计算机视觉领域的重大飞跃。随后,VGGNet(Simonyan和Zisserman,2014)、GoogLeNet(Szegedy等,2015)与ResNet(He等,2016)等深层结构通过参数共享与残差连接机制不断刷新性能纪录,其中ResNet通过残差连接解决了梯度消失问题,将网络深度拓展至152层,图像分类精度首次超过人类水平。尽管卷积神经网络在视觉任务中表现稳定,但其受限于局部感受野,在建模长程依赖和全局上下文信息方面存在一定不足,这也促使Vision Transformer通过自注意力机制在视觉领域迅速发展;然而,凭借更高的参数与计算效率、更强的归纳偏置以及在中小规模数据和资源受限场景中的鲁棒性优势,一系列改进的卷积神经网络结构仍持续推动CNN在精度与效率上的性能上界。EfficientNet(Tan和Le,2021)系列通过神经结构搜索与复合缩放策略实现了参数量、计算量与性能的协同优化,其中EfficientNetV2(Tan和Le,2021)在ImageNet上取得85.7% Top-1准确率,相比前代在训练速度上提升3-9倍,并显著减少模型规模。随后提出的ConvNeXt(Liu等,2022)通过引入更大的卷积核LayerNorm等“现代化”设计,使纯卷积网络在ImageNet-1K上达到最高87%+Top-1精度,在目标检测与语义分割任务上也与主流Transformer模型保持竞争力。其后续工作ConvNeXt V2(Woo等,2023)在此基础上结合了全卷积Masked Autoencoder预训练框架并引入Global Response Normalization(GRN)等结构,使

CNN在自监督表征学习与下游任务中的性能进一步提升。

#### 2) 循环神经网络(recurrent neural network, RNN)

大脑在处理时序信息时具有显著的短期记忆与反馈调控能力,能够根据时间上下文动态更新内部状态,实现对连续事件的理解与预测。这一机制为循环神经网络RNN的设计提供了重要启发。RNN通过隐藏层状态的递归传递来建模序列数据间的时间依赖关系,使模型能够在当前输入的基础上综合历史信息,从而实现动态过程的持续感知与预测(Graves等,2013)。

然而,随着网络深度和时间跨度的增加,RNN在训练中容易出现梯度消失或爆炸现象,限制了其对长期依赖关系的建模能力。为此,Hochreiter与Schmidhuber(1997)提出了长短时记忆网络(long short-term memory, LSTM),通过“输入门-遗忘门-输出门”结构控制信息流动,显著提升了模型对长序列依赖的学习稳定性与记忆能力。LSTM的门控机制在一定程度上模拟了大脑海马与前额叶皮层在时间记忆与信息筛选中的交互方式。尽管LSTM解决了梯度消失问题,但其结构较为复杂,计算开销较大。为此Cho等人(2014)提出了门控循环单元(gated recurrent unit, GRU)。GRU将LSTM的三个门结构压缩为“更新门”与“重置门”,并将细胞状态与隐藏状态合并为单一的隐变量,使模型在保持长期依赖建模能力的同时减少参数量与计算开销。从神经科学角度看,GRU的更新门类似于对长期记忆的保持机制,而重置门则对应于对短期信息的快速遗忘,使其在执行动态信息过滤方面呈现出与生物脑功能“快速适应-快速遗忘”现象的相似性。

RNN与LSTM的提出曾推动自然语言处理与语音识别领域取得重要突破。尽管近年来Transformer(Vaswani等,2017)架构在大多数序列建模任务中表现更为优越,并在工业界和学术界逐渐成为主流,但是RNN由于其结构紧凑、时间依赖建模自然等特点,依然在语音处理、时间序列预测、金融分析与在线流式推理等场景中保持竞争力。值得注意的是,随着研究者重新审视循环结构的潜力,基于状态空间建模与高效递归机制的新方法为RNN带来了新的发展机遇。例如,Smith等人(2022)提出的简化状态空间层能够在保持训练稳定性的同时高效捕获长

程依赖;Orvieto 等人(2023)的工作则表明经过结构与训练方式的改进,RNN 仍可在超长序列任务中达到甚至超过 Transformer 的性能。这些研究表明,循环结构并未被完全取代,而是正在与现代深度学习技术融合,未来 RNN 与 Transformer、状态空间模型等架构的结合,有望构建更高效、可扩展且适用于多场景的序列建模框架。

### 3) Transformer 模型

Transformer 模型通过自注意力机制实现对全局特征的动态权重分配,能够在不依赖循环结构的情况下捕获长距离依赖关系,从而突破了传统 RNN 在并行计算、长期记忆能力和梯度稳定性方面的局限(Vaswani 等, 2017)。该机制与人类大脑的“选择性注意”颇为相似,使模型能够在多源信息中自动聚焦关键特征并抑制冗余信号,从认知机制视角体现出高度的解释性与灵活性。

Transformer 自 2017 年提出以来,迅速成为自然语言处理领域的主流架构,并催生了 BERT、GPT、T5 等一系列具有里程碑意义的模型。BERT 通过双向编码结构显著提升了文本理解能力;T5 将多种语言任务统一为“文本到文本”框架,增强了模型泛化能力;GPT 系列则在大规模预训练与自回归生成机制的加持下,在语义生成、逻辑推理、知识问答和多模态理解方面展现出接近人类的认知水平,推动了大模型时代的到来。大规模 Transformer 模型的成功验证了“海量数据 + 大模型 + 统一架构”的范式,为通用人工智能(Artificial General Intelligence, AGI)的发展奠定了技术基础。

在视觉领域,Transformer 结构同样展现出强大的潜力。Vision Transformer(Dosovitskiy 等, 2020)首次将图像视作 patch 序列,并使用纯注意力机制取代卷积进行特征提取,在大规模数据集上取得了超越 CNN 的性能。随后,Swin Transformer(Liu 等, 2021)通过提出层次化窗口注意力结构,使 Transformer 既能扩展到高分辨率视觉任务(孙巍 等, 2025),又保持了较高的计算效率,在目标检测、语义分割与视频理解等任务中刷新了多项性能基准。近年来,Transformer 与卷积网络的结合(如 ConvNeXt V2(Woo 等, 2023)、CoAtNet(Dai 等, 2021)等)进一步证明了注意力机制与局部感受野结构的互补性。

目前类脑感知正从“单一机制仿生”迈向“多模态协同与场景涌现”。ConvNeXt、Swin Transformer

等基础视觉模型借助大规模预训练逐渐成为通用感知底座,融合卷积的局部结构、注意力的全局动态以及递归模型的时序记忆能力,其整体计算框架与功能组织方式如图 4 所示。研究重心由复刻视觉皮层或海马回路的独立功能,转向构建与认知-运动系统紧密耦合的“感知架构”,在开放环境中通过自监督学习、快速适应并主动采样,提升通用感知与自主决策能力。

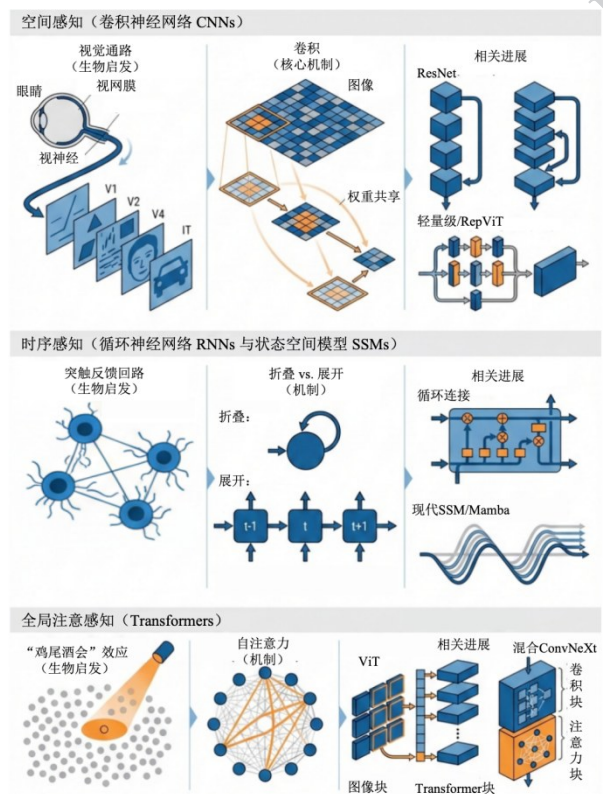


图4 感知功能启发的人工智能基础框架(He 等, 2016; Liu 等, 2022; Hochreiter 和 Schmidhuber, 1997; Smith 等, 2022; Orvieto 等, 2023; Vaswani 等, 2017; Dosovitskiy 等, 2020)

Fig. 4 Fundamental artificial intelligence framework inspired by perceptual functions (He et al, 2016; Liu et al, 2022; Hochreiter and Schmidhuber, 1997; Smith et al, 2022; Orvieto et al, 2023; Vaswani et al, 2017; Dosovitskiy et al, 2020)

## 1.2.2 认知功能启发的人工智能

### 1) 注意力模型

注意力模型受人类认知机制启发,旨在模仿大脑在复杂环境中动态聚焦关键信息的能力。其核心在于通过对输入信息进行选择性加权,将有限的计算资源集中在最具任务相关性的区域,从而提升感知与处理的效率与精度。

从神经科学视角看,视觉注意力使人类能够在

复杂场景中有选择地关注特定部分,并忽略无关背景(Rolfs等,2011),这种选择性注意是应对信息过载、在遮挡或杂乱环境下实现准确目标识别的关键。Wilterson和Graziano(2021)提出的“注意力图式”假说进一步指出,智能体可通过内部维护一种关于自身注意状态的元表征,来动态调节注意焦点,从而更高效地驱动行为。

在人工智能领域,注意力机制已被形式化为多种可计算模块。按其作用的数据维度,主要可分为通道注意力、空间注意力、时间注意力及其组合形式(如通道-空间注意力、空间-时间注意力等)。这些机制已被广泛集成于CNN、RNN及Transformer等主流模型中,显著提升了图像识别、视频理解、语音与文本建模等任务的性能与模型鲁棒性。

### 2) 记忆模型

记忆是智能行为的基础,由短期记忆、语义记忆与情景记忆等多种功能系统协同实现。神经科学研究表明,长期记忆与短期记忆在神经元结构上存在差异(Colicos和Goda,2001),语义与情景记忆由左侧额下回、前岛叶皮质等区域共同参与编码与提取(Vatansver等,2021),而短期记忆的维持依赖内侧额叶与内侧颞叶中记忆神经元的持续活动(Kamiński等,2017)。受此启发,近年来的人工智能研究发展出多种“显式记忆增强模型”,通过可检索存储或持久化表示来模拟类似于海马体-皮层系统的索引与回放机制。例如:kNN-LM(Khandelwal等,2019)通过在预测阶段对向量库执行k近邻检索,并与语言模型输出分布融合,使模型能够直接调取训练语料中的长尾知识,实现无需微调的快速记忆增强。RAG(Lewis等,2020)进一步将稠密检索模块与生成模型端到端结合,在生成过程中动态引入外部知识片段,为模型提供显式语义记忆,从而在知识密集型任务中提升事实一致性。RETRO(Borgeaud等,2022)面向更大规模知识场景,通过对万亿级语料库执行片段检索,并将检索结果作为条件输入解码器,使中等规模模型即可获得接近超大模型的知识覆盖能力。与此同时,Memorizing Transformers(Wu等,2022)在Transformer内部引入可扩展键值记忆模块,通过检索历史隐状态来建立跨文档或跨会话的长期依赖,增强了模型的上下文建模与知识持久化能力。

### 3) 推理模型

推理是大脑依据已有信息推导出新结论的高级

认知过程,主要包括归纳与演绎两种基本形式(Choi等,2018)。在多感官环境中,大脑需要判断不同通道的信号是否源于同一外部事件,这依赖于因果推理机制。神经科学研究表明,大脑皮层中存在能对多种感觉输入进行比对与整合的神经元,其活动反映了不同信号间的一致性,是决定是否进行多模态整合的基础之一(Rideaux等,2021)。从计算视角看,这一过程可描述为基于贝叶斯理论的因果推断:大脑作为一个推理系统,会同时评估刺激的特征及其可靠性,并计算不同因果结构的后验概率。

为解释其神经实现,研究者提出了基于神经群体编码的生成模型,由神经元集群的活动编码概率分布,通过模拟群体向量间的运算,为理解大脑如何通过简单的加性机制整合多路信号并实现逆向推断提供了一种几何化的计算解释(Ma等,2006;Beck等,2012)。该模型揭示出,大脑在面对复杂多变的环境时,能够通过高效的多模态信息整合与因果推理,形成稳定、统一的感知,并支撑后续的识别与决策。

这一机制为人工智能,尤其是多模态推理、鲁棒的场景理解与决策模型的设计提供了重要启发。其核心在于如何构建能够动态评估证据可靠性、进行概率性因果推断,并灵活整合多源信息的计算框架。

### 4) 遗忘模型

遗忘并非简单的记忆衰减,而是大脑主动优化信息存储的过程。其生物学基础主要包括两方面:一是通过削弱或消除特定的突触连接来调节记忆强度;二是海马体中新生神经元的持续生成与整合,会重塑现有神经环路,从而干扰或覆盖旧的记忆痕迹,使其难以被检索(Zhang等,2019)。在动态环境中,这种主动遗忘机制对于清除过时信息、提高决策的灵活性至关重要。在认知与决策中,适度的遗忘扮演着多重积极角色:它不仅能消除可能干扰当前判断的陈旧或无关信息,还能防止对过去经历过度拟合所导致的行为僵化,从而增强智能体对新情境的适应能力和新任务的学习能力(Endress和Johnson,2021)。因此,遗忘有助于降低认知负荷,是持续学习和高效决策的重要支持(吕凡等,2025)。

借鉴脑功能的遗忘机制,研究者开发了具有主动遗忘功能的人工神经网络模型(Ierusalem,2018),通过有选择地重置或减弱特定神经元间的连接权重,来模拟生物遗忘中突触效能的降低,从而为学习

新任务释放神经计算资源,最终提升模型在多任务学习中的效率与适应性。

当前,认知功能启发的人工智能研究正从“单一功能模拟”迈向“系统级整合”,如图5展示了认知功能启发的人工智能基础框架。以大规模语言模型为代表的基础模型,凭借其规模化训练形成的统一表

示,正在整合注意力、记忆乃至推理等核心认知功能。总体而言,该领域的研究重心已从复刻“认知组件”转向构建能与感知和行动闭环耦合的认知架构,旨在最终实现更强的泛化能力、自主性,并逐步逼近 AGI 的长期目标。

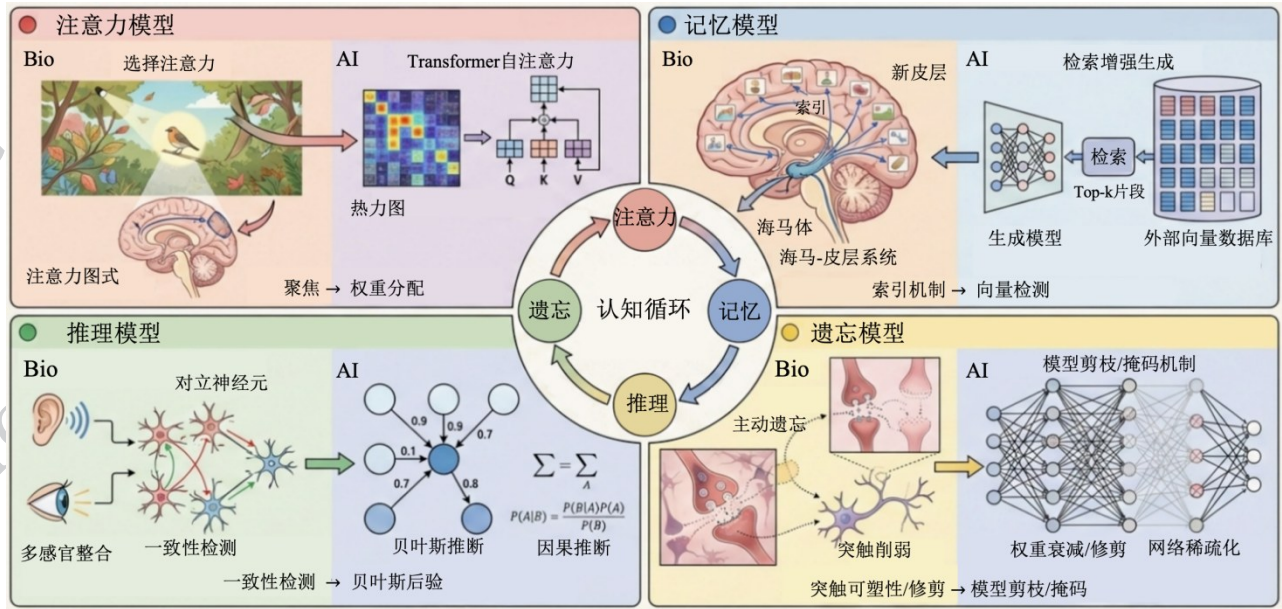


图5 认知功能启发的人工智能基础框架 (Vatansver 等, 2021; Kamiński 等, 2017; Ma 等, 2006; Endress 和 Johnson, 2021)  
Fig. 5 Fundamental artificial intelligence framework inspired by cognitive functions (Vatansver et al, 2021; Kamiński et al, 2017; Ma et al, 2006; Endress and Johnson, 2021)

### 1.2.3 学习功能启发的人工智能

全球范围内,多个大规模科研项目 and 持续的基础研究正在推动脑功能启发学习的边界。与以误差反向传播BP为核心的传统深度学习范式不同,学习功能启发的研究更加关注生物可实现性、能效约束以及持续学习能力,重点探索超越BP的学习规则以及SNN的高效训练与应用方法,其总体结构如图6所示。

#### 1) 基于生物学特性的学习规则

传统BP算法依赖全局误差信号和精确梯度传播,其计算过程需要对网络整体结构具有完全可见性,与生物神经系统中以局部突触更新为主的学习方式存在本质差异。这一差异不仅限制了模型的生物解释性,也制约了其在低功耗神经形态硬件上的部署。因此,近年来研究者广泛探索超越BP的生物启发学习规则,以期实现更高效、更可扩展的片上学习机制。

正如本文1.1.3节所述,生物神经系统中,突触

可塑性通常并非仅由突触前、后神经元的活动决定,而是受到全局调制信号(如多巴胺、乙酰胆碱等)的共同影响。该机制影响的学习规则可概括为三因子学习,即:突触更新由突触前活动、突触后活动以及调制信号三者协同决定。该规则不仅能够解释奖励驱动学习和情境依赖学习,还为强化学习和持续学习提供了生物学基础。

近年来,多项研究进一步将三因子规则与更精细的生物过程相结合,引入钙离子动力学、树突非线性整合和奖励调制机制,以提升学习规则的表达能力和稳定性。例如,Girão等人(2025)提出的基于钙信号调控的Hebbian-STDP学习规则,通过将钙浓度作为突触可塑性的内部状态变量,实现了对脉冲时间依赖可塑性的连续调节,从而显著提升了学习稳定性与鲁棒性。Khodadadi等人(2024)进一步将奖励信号与钙依赖的突触可塑性机制耦合,使模型在强非线性任务中实现高效学习,验证了三因子规则能够有效突破传统SNN的固有瓶颈。这类更接近

生物学特性的学习规则使突触更新从“固定学习过程”演化为“受情境调制的动态学习过程”,为构建具备持续学习能力、抗灾难性遗忘能力和高效特性的类脑智能系统提供了重要理论支撑。

## 2) 大规模SNN的训练与应用

在学习规则不断发展的同时,如何将这些生物启发机制推广到大规模SNN,并应用于复杂任务,是该领域面临的核心挑战之一。传统SNN由于脉冲信号的非连续性,难以直接使用梯度下降方法进行深层训练,限制了SNN在大规模任务中的应用。

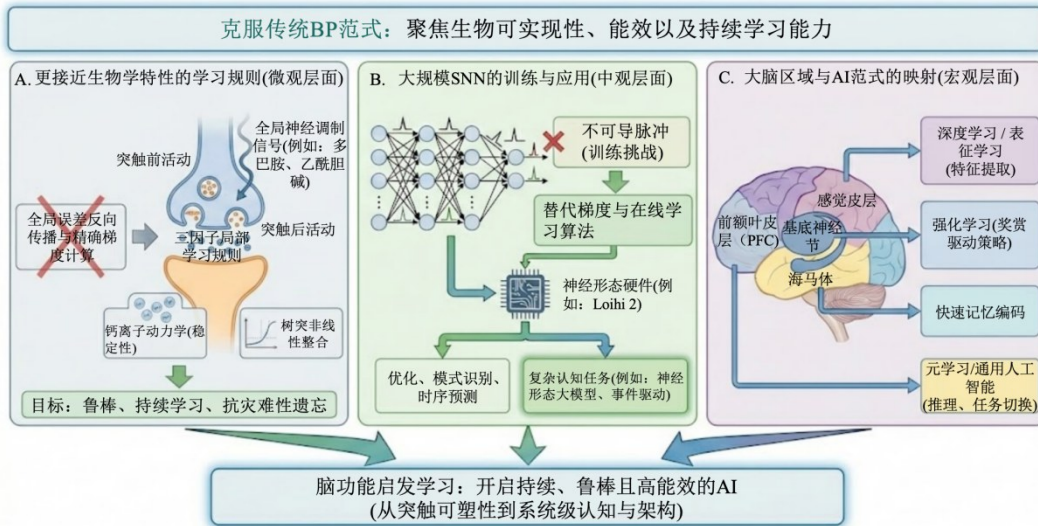


图6 学习功能启发的人工智能:从生物机制到认知架构(Girão等,2025;Khodadadi等,2024;Abreu等,2025)

Fig. 6 Learning-function-inspired artificial intelligence: from biological mechanisms to cognitive architectures (Girão et al, 2025; Khodadadi et al, 2024; Abreu et al, 2025)

近年来,随着替代梯度SG、局部学习规则与神经形态硬件的协同发展,大规模SNN的训练与部署逐步成为现实。Yang等人(2025a; 2025b)提出了面向SNN的信息瓶颈学习策略,通过信息压缩与保留间的权衡实现了泛化性、鲁棒性的提升与功耗的降低。英特尔推出的Loihi 2芯片及其后续Hala Point系统,为大规模SNN提供了可编程、低功耗、支持在线学习的硬件基础。相关研究表明,SNN在优化问题、模式识别、时序预测等任务中,能够在显著降低能耗的同时保持具有竞争力的性能(Roy等,2019; Davies等,2021; Göltz等,2021)。

更进一步,近期研究开始将SNN引入大语言模型LLM等高层认知任务,显示出类脑计算正从以感知和控制为主的应用阶段,向更复杂的推理与生成场景拓展。通过重新表述Transformer等主流模型中的注意力与前馈计算,使其能够在脉冲神经元动力学和事件驱动机制下实现等价或近似计算,从而验证生成式语言建模并非必然依赖连续值人工神经网络(刘花成等,2025)。以SpikeGPT(Zhu等,2023)和基于Loihi 2的神经形态LLM(Abreu等,2025)为

代表的研究表明,在保持基本语言建模能力的前提下,通过脉冲编码、稀疏激活、低比特精度以及无矩阵乘法的计算方式,可显著降低模型运行过程中的能耗需求,体现出类脑计算在高复杂度认知任务中的潜在优势。从更宏观的角度看,这类探索并非旨在直接替代现有大模型体系,而是揭示了一条不同于“算力与参数规模驱动”的技术路径,即通过重构计算范式与软硬件协同设计来支撑高层认知功能的实现。尽管当前SNN在生成质量、训练稳定性和大规模扩展性方面仍面临明显挑战,但已有研究结果表明,脉冲神经网络并不局限于低层感知任务,而具备向复杂推理与生成任务拓展的可行基础,为构建高效认知智能系统提供了新的研究方向。

## 3) 大脑区域与AI范式的映射

除了具体算法与硬件实现外,学习功能启发研究还关注大脑不同区域在学习中的功能分工,以及这些功能如何映射到不同的人工智能范式。神经科学研究表明,大脑并非依赖单一学习机制,而是由多个功能区域协同完成:感觉皮层负责特征提取与表征学习,基底神经节参与奖励驱动的策略选择,海马

系统支持快速记忆编码,而前额叶皮层则在任务切换、元学习和策略重构中发挥关键作用。

基于这一认识,部分研究开始系统性地分析大脑关键区域与AI学习范式之间的对应关系。Theotokis等人(2025)的研究指出,当前深度学习模型在结构上更接近感觉皮层的信息处理机制,而强化学习框架则与基底神经节的奖赏学习功能具有高度相似性;相比之下,前额叶皮层所体现的元学习和快速适应能力,仍是现有AI系统中相对薄弱的环节。这类分析为理解人工智能从“感知智能”向“认知与推理智能”演化提供了重要参照,也为未来融合多脑区功能的学习架构设计提供了重要启发。

#### 1.2.4 决策功能启发的人工智能

决策是智能系统将感知、记忆与学习结果转化为具体行为的关键环节,也是脑启发的人工智能中连接认知理解与行为执行的核心纽带。在神经系统中,决策依赖多脑区协同,主要包括:基底神经节在多巴胺调制下编码奖励预测误差(reward prediction error, RPE),驱动动作选择与策略更新;前额叶皮层负责目标导向的策略规划与价值权衡;海马系统与感觉皮层提供情境记忆与状态表征,为决策提供可用的信息结构。上述以奖赏驱动、风险评估与持续更新为特征的生物决策机制,为强化学习等计算模型提供了重要启发。

##### 1) 深度强化学习(deep reinforcement learning, Deep RL)

深度强化学习受大脑奖赏驱动学习机制启发,模拟中脑多巴胺能神经元对奖励预测误差(reward prediction error, RPE)的编码功能,将环境反馈转化为行为策略的更新信号。以深度Q网络(Deep Q-Network, DQN)为代表的价值函数逼近框架利用深度神经网络参数化动作价值函数,并引入经验回放与目标网络机制,有效抑制样本相关性及训练不稳定性。在此基础上,Double DQN、优先经验回放与竞争网络架构等改进策略被系统归纳为提升学习稳定性与样本效率的关键技术路径(Terven, 2025)。

在策略梯度方向,近端策略优化(Proximal Policy Optimization, PPO)通过限制策略更新幅度,以“小步快走”的方式提升训练稳定性。近期有理论研究进一步给出收敛率与性能边界,阐明了PPO及其变体在特定马尔科夫决策过程下的适应条件(Zhong和Zhang, 2023)。Soft Actor-Critic(SAC)以最

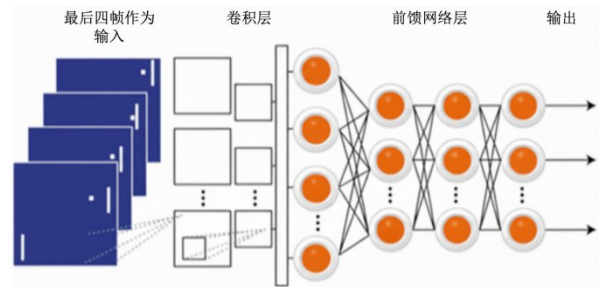


图7 DQN网络架构(Terven, 2025)

Fig. 7 Architecture of the DQN network (Terven, 2025)

大熵目标刻画“回报—探索”的权衡,在优化回报的同时鼓励策略多样性;近年还有研究将SAC推广到平均回报等设定并延续熵正则化思想,用以增强不确定环境中的持续探索与鲁棒性(Adamczyk等, 2025)。从神经计算视角看,Deep RL的价值评估与策略更新过程可对应基底神经节相关通路对行为选择的调制机制,而熵正则化与探索策略则反映了生物决策中对不确定性的内在处理方式。

##### 2) 值分布强化学习(Distributional RL)

值分布强化学习的提出,源于神经系统对奖赏不确定性与概率分布的并行编码能力。神经电生理证据表明,不同多巴胺神经元对奖赏幅度或时序的敏感度存在异质性,可在群体层面同时刻画回报分布的多个分位或矩信息,为个体实施风险评估与期望动态调整提供了计算基础。与传统方法将回报压缩为单一期望不同,分布式强化学习将回报建模为完整分布,并围绕分布表示、分布Bellman算子、分位数回归/隐式分位等路线形成了相对系统的方法(Bellemare等, 2017)。该范式使强化学习从传统的期望回报最大化框架,拓展为更贴近生物风险感知与不确定性评估机制的决策模型,在金融决策、自动驾驶安全规划等高风险场景中具有重要应用潜力。

##### 3) 元强化学习(Meta-RL)

元强化学习直接模拟了前额叶皮层(prefrontal cortex, PFC)对学习过程的调控功能,即“学会如何学习”。PFC能够在不同任务之间提取共性结构,并基于有限经验快速调整策略,这一能力是人类灵活决策和快速适应新环境的关键。Duan等人(2016)提出的RL<sup>2</sup>框架利用循环神经网络将任务经验隐式编码在网络状态中,使智能体在新任务中表现出快速适应能力;Finn等人(2017)提出的模型无关元学习(model-agnostic meta-learning, MAML)通过元学习

获得一组对任务分布敏感的模型初始参数,当面对新任务时,模型可基于该初始点,仅用少量样本和几步梯度更新即可完成高效微调,其典型的内外循环学习过程如图8所示。

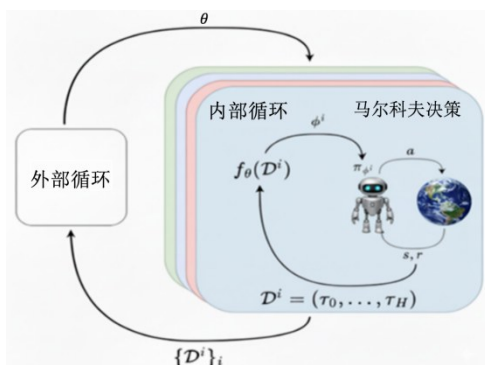


图8 元强化学习的内外循环(Beck等,2023)

Fig. 8 Inner and outer loops of meta-reinforcement learning  
(Beck et al., 2023)

从脑启发角度看,元强化学习通过在时间尺度上分离“快速任务适应”与“慢速结构更新”,在计算层面模拟了前额叶皮层对策略搜索、规则抽象和任务切换的调控机制,为构建具备终身学习能力的人工智能系统提供了重要思路。

#### 4) 多智能体决策(Multi-Agent RL)

多智能体决策受到人脑社会认知能力和合作推理机制的启发,尤其与镜像神经元系统和心智建模能力相关。人类在团队协作和博弈中,能够根据对手行为推断其意图并调整自身策略。AlphaStar通过大规模自博弈在《星际争霸II》上达到顶尖人类水平,展现了多智能体系统中复杂协同行为和长期战略规划自动涌现能力(Vinyals等,2019)。在方法层面,集中训练—分散执行(centralized training with decentralized execution, CTDE)框架通过引入集中评论家有效解决了多智能体环境中的信用分配问题,而通信学习机制则使智能体能够通过自组织协议实现信息共享与协同行为。

#### 5) 脉冲强化学习(Spiking-RL)

脉冲强化学习则基于大脑以离散脉冲形式进行事件驱动计算的基本事实,结合局部突触可塑性规则STDP进行策略更新。这类机制显著降低能耗,同时具备高并行性,适用于边缘计算与实时响应场景。Zanatta等人(2024)提出的SpikeGym框架在Isaac Gym环境中训练SNN-PPO模型,在Ant-v4任务

上性能提升达4.4倍,展示了SNN在强化学习任务中的潜力。Bellec等人(2020)提出的e-prop则通过局部梯度近似,使循环SNN可用于Actor-Critic训练。Nazari等人(2025)提出位置自注意力与协同注意力,将STDP与奖励调制结合,在多个视觉数据集上显著提升精度并加速收敛。随着片上存储扩展和事件相机等脉冲传感器普及,端到端事件驱动感知-决策链有望在无人机、脑机接口、极端边缘节点上率先落地,实现真正类脑的高时效、微瓦级自主决策。

#### 1.2.5 控制功能启发的人工智能

运动皮层作为运动控制的高级中枢,具有多模态信息整合与运动指令生成两个核心功能。在信息整合层面,它能同时处理视觉、本体感觉和前庭觉等多源感觉输入,并与前额叶的认知信号进行协同处理;在指令生成层面,负责将运动意图转化为具体的运动参数。Gentili等人(2016)开发的前额叶皮层模型建立了关节空间与任务空间的坐标转换机制,为复杂动作规划提供了计算基础;Corchado等人(2020)提出的迭代学习控制器再现了运动皮层的闭环反馈调节功能。

基底神经节(basal ganglia, BG)在运动控制中主要承担动作选择与行为调制的关键角色,其神经环路构成了一个高效的决策与筛选系统。该系统首先整合来自运动皮层的候选动作信息,随后通过纹状体—苍白球/黑质通路对动作价值进行评估,并最终经丘脑反馈至皮层以执行最优行为。以Prescott等人(2006)的工作为代表,验证了上述神经机制在工程系统中的可迁移性,表明基于BG原理的计算模型能够在多模态感知条件下实现稳定且自适应的行为选择;随后,概率决策模型(Mannella和Baldassarre,2015)和多巴胺调制机制(Prescott等,2024)的引入进一步揭示了BG在不确定环境中平衡探索与利用、调节行为阈值以及塑造长期策略偏好的功能特性。从整体上看,这类研究不仅复现了BG在生物运动控制中的核心作用,也为构建具备奖赏调制、情境依赖和自适应能力的类脑决策与控制系统提供了统一的计算框架,凸显了BG启发模型在机器人自主行为生成中的方法论价值。

小脑在运动控制中以精确性和适应性著称,其计算模型主要基于两个核心功能机制:在线误差校正和内部动力学建模。如图9展示了小脑运动学习和误差校正功能原理。这些机制分别支持不同时间

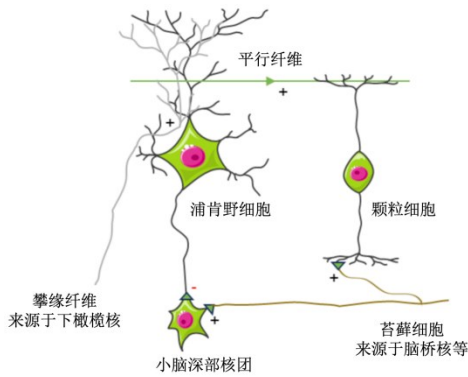


图9 小脑运动学习和误差校正功能原理示意图(Hull, 2020)

Fig. 9 Schematic diagram of motor learning and error correction mechanisms in the cerebellum (Hull, 2020)

尺度的运动适应过程:在短期适应中,小脑通过快速反馈调节实时修正运动误差;而在长期适应过程中,则通过持续学习建立精确的肢体-环境动力学模型




图10 包含RG、BC、PF和AF模块的四足机器人控制系统框架(Bhattasali等,2024)

Fig. 10 Control system framework of a quadruped robot including RG, BC, PF, and AF modules (Bhattasali et al, 2024)

尽管神经科学研究已在脑功能机制层面取得深刻认识,然而传统人工神经网络因缺乏脉冲编码、突触可塑性等基本生物神经特性,在模拟具生物合理性的运动控制方面仍面临局限。为此,研究者通过借鉴脉冲时序编码、突触可塑性及兴奋-抑制平衡等关键生物机制,构建了具备类脑学习能力的脉冲神经网络模型,以弥合上述差距(Ghosh-Dastidar和Adeli,2009)。研究表明,SNN在运动控制任务中的优势并非体现在单一算法性能提升,而在于其能够通过稀疏脉冲通信、局部可塑性和兴奋-抑制调控,实现低时延、高稳定性的闭环控制(Hagras等,2004)。在此基础上,研究重心由单一控制模块转向多脑区协同建模,通过模拟运动皮层、基底神经节、小脑等功能单元之间的分工与交互,使控制策略在精度、平滑性与环境适应性之间取得更优平衡

(Wulff等,2009)。Tolu等人(2013)改进了经典的自适应滤波器模型(Dean等,2010),引入局部加权投影回归算法(Vijayakumar等,2025)来增强长期学习能力;随后开发的预测控制框架(Tolu等,2020)在机器人手臂上实现了接近生物水平的运动跟踪精度,充分验证了小脑模型在动态环境中的适应能力。

近年来的研究还进一步揭示,单一脑区模型难以完整复现生物运动控制的复杂性。小脑、皮层和基底神经节通过功能互补形成协同控制网络(Caligiore等,2020):小脑负责构建前向模型预测动作结果,BG则通过强化学习机制评估行为价值。Bhattasali等人(2024)受脊髓神经回路启发,开发了包含节奏生成(rhythm generation, RG)、脑干命令(brainstem command, BC)、模式形成(pattern formation, PF)和传入反馈(afferent feedback, AF)模块的四足机器人控制系统,为仿生运动控制提供了新思路。

(DeWolf等,2016)。结合神经形态硬件的实验结果显示,基于SNN的控制框架在保持控制性能可比的前提下,能够显著降低系统能耗并提升控制频率,凸显了类脑计算在实时运动控制场景中的工程可行性(Amaya等,2024;Jiang等,2025)。这类研究共同指向一个清晰的发展方向:通过将生物神经机制与多脑区协同建模相结合,构建具备高效率、高精度和强自适应能力的类脑运动控制系统,正在成为推动神经启发控制方法走向实际应用的关键路径。

### 1.3 脑启发的人工智能硬件系统与芯片

随着类脑算法的不断发展,传统的冯·诺依曼计算架构在能效、带宽和并行性方面的局限性日益突出。为了实现接近生物大脑能效比的智能计算,国际研究重点转向了脑启发硬件系统的探索。该方向以神经形态计算为核心,采用事件驱动的异步电路

设计,结合脉冲神经网络的时空编码机制实现存算一体的高效信息处理,并逐步形成从仿生器件到可扩展系统的全栈式突破,旨在从硬件层面重构计算范式,实现“计算-存储-通信”一体化的智能处理。自Mead(1990)提出“神经形态工程”以来,该领域在国际上已由早期的生物仿真研究发展为兼具科学探索与工程应用的跨学科方向,推动了神经形态芯片在规模与架构上的持续演进。如图11所示,神经形态系统的规模在过去二十年呈指数级增长。从早期ADALINE的单个神经元模拟(Widrow, 1960),到

Spiking Neural Network Architecture 2(Gonzalez等, 2024)的52亿神经元集成,神经形态芯片的算力密度提升了9个数量级。目前,国际神经形态计算已进入规模化应用阶段,覆盖机器人控制、动态视觉和类脑仿真等场景,但仍面临器件精度、架构可扩展性及算法-硬件协同优化三大挑战。基于上述研究背景,以下将从三个层次展开分析:类脑材料基础、神经元与突触仿生器件以及非冯·诺依曼架构,以系统阐述脑启发的人工智能硬件系统的技术体系与演进逻辑。




图11 神经形态计算系统的演进图(Kudithipudi等,2025)

Fig. 11 Evolution of neuromorphic computing systems(Kudithipudi et al,2025)

### 1.3.1 类脑材料

类脑计算的实现首先依赖于能够模拟生物神经信号调制特性的新型材料体系。与传统硅基存储和逻辑单元不同,类脑材料需要具备非易失性、多态可调、电导连续变化与时间依赖特性,以支持突触权重调制和神经动态行为的硬件实现。近年来,复杂氧化物材料因其独特的电子关联效应和对外部刺激(如电场、温度、离子掺杂)的动态响应能力,成为神经形态计算领域的重要研究方向。以 $\text{VO}_2$ 、 $\text{NbO}_2$ 及 $\text{ReNiO}_3$ 为代表的金属-绝缘体转变材料,因其在室温附近的电阻突变特性,被广泛用于模拟生物神经元的阈值激发行为(Park等,2023)。例如, $\text{VO}_2$ 在施加阈值电压时可实现亚纳秒级的绝缘态-金属态转变,与生物神经元的动作电位动力学高度匹配(Pickett等,2013)。通过将 $\text{VO}_2$ 与电容、电阻等元件集成,研

究者已成功构建了Hodgkin-Huxley神经元模型和LIF神经元电路,展示了频率适应、不应期等生物神经元特性(Lin等,2018)。在该研究中,基于 $\text{VO}_2$ 的LIF神经元电路通过电容与电阻的协同作用,在输入电压驱动下实现了周期性的放电行为,其电流-时间曲线与电压波形精准复现了生物神经元的积分-发放特性。在突触器件方面,复杂氧化物通过离子迁移、氧空位调控或铁电极化等机制,实现了长短期可塑性和脉冲时序依赖可塑性。例如, Jerry等人(2017)提出了一种基于 $\text{Hf}_{0.5}\text{Zr}_{0.5}\text{O}_2$ 铁电薄膜的铁电场效应晶体管(ferroelectric field-effect transistor, FeFET)突触器件,能够实现超过106次循环的稳定可塑性调控,为大规模神经形态网络的实现提供了可扩展方案。此外,铁电隧道结(ferroelectric tunnel junction, FTJ)利用极化方向调控隧穿电阻,展示了

非易失性存储与模拟突触行为的兼容性(Boyn等, 2017)。这类器件的关键优势在于其“存算一体”特性,能够绕过冯·诺依曼架构的存储墙问题,显著提升能效。

除复杂氧化物外,新型低维与光电子材料的引入正为类脑器件提供更广阔的发展路径。二维材料因其原子级厚度和优异的电学特性,可实现高灵敏度、低功耗的神经突触功能。例如,基于石墨烯边缘电极的忆阻器展现出超高开关比和亚纳秒响应速度(Lee等, 2015),适用于高密度突触阵列。同时,光电子材料通过光-电协同调控,为全光神经形态计算提供了新的实现思路,例如光子张量核已实现光域矩阵乘法的并行加速(Feldmann等, 2021)。

未来,类脑材料研究需进一步深化界面工程与异质集成技术,以在性能、稳定性与制造成本间实现平衡。特别是多维复合结构在实现高速、低功耗的神经形态硬件方面展现出巨大潜力,为可扩展、可重构的智能计算平台奠定了材料基础。

### 1.3.2 神经元与突触仿生器件

传统(complementary metal oxide semiconductor, CMOS)器件作为现代集成电路的基石,在神经形态计算领域早期探索中占据重要地位,IBM的TrueNorth芯片和Intel的Loihi、Loihi 2芯片是典型代表,通过CMOS晶体管模拟神经元和突触功能,构建大规模SNN。TrueNorth芯片采用异步事件驱动的神经形态架构,能够模拟超过百万级的神经元和突触,支持高度并行的计算和低延迟响应,其功耗仅为65mW(Akopyan等, 2015),在边缘计算和嵌入式系统等低功耗场景中表现突出。与此不同,Loihi芯片系列由Intel Neuromorphic Computing Lab开发,侧重于可塑性学习与自适应调控。第一代Loihi采用动态可配置神经核设计,支持多种突触可塑性规则,可在片上实现实时自适应学习(Davies等, 2018)。在此基础上,Loihi 2进一步扩展了体系结构,采用Intel 4制程,神经核数量与神经元规模提升约10倍,支持更高精度的事件驱动矩阵运算与多时尺度突触动力学。Loihi 2还新增了可编程学习引擎和混合时序编码模块,使其能够在自然语言理解、视觉感知以及机器人控制等复杂任务中运行大规模脉冲网络。最新研究表明,基于Loihi 2实现的大型语言模型在语义推理任务中可实现约96%的能耗降低(Abreu等, 2025)。

然而,传统CMOS器件在神经形态应用中存在固有局限:其一,电压模态与生物神经元的电流模态不匹配,导致突触可塑性和非线性动力学模拟困难;其二,随着集成度提升,漏电流和开关损耗导致功耗和散热问题加剧,难以满足人脑级能效需求(Indiveri等, 2011)。

为克服上述问题,研究者尝试在CMOS工艺中引入新型器件结构与材料体系,以实现更接近生物神经机制的计算模型。例如,浮栅晶体管通过电荷存储实现突触权重虚拟模拟,其低功耗特性与非易失性存储技术兼容,可直接用于突触阵列设计(Malavena等, 2018)。铟镓锌氧化物(indium gallium zinc oxide, IGZO)晶体管因其低功耗、高透明度和低温制备优势,成为CMOS兼容神经形态器件的重要候选。此外,铁电场效应晶体管利用HfZrO薄膜的极化特性,实现低电压操作和线性电导调节,为高密度神经形态芯片提供了新方向(Kim等, 2023)。

与此同时,国际研究者也在探索突破CMOS架构限制的全新器件体系。其中,忆阻器及其衍生结构被广泛认为是神经形态计算的核心元件。基于电阻式随机存取存储器(resistive random-access memory, RRAM)的忆阻器因其结构简单、可扩展性强以及与生物突触/神经元行为的物理相似性,成为研究热点。RRAM主要通过导电细丝或均匀电阻切换机制实现阻态调控(Ielmini等, 2021)。导电细丝型RRAM通过电场调控导电细丝的形成或断开,实现高低阻态切换;而均匀电阻切换型RRAM则通过界面氧空位分布的整体调控改变阻值。例如,HfO<sub>2</sub>基于RRAM通过电场调控氧空位迁移,形成或断开导电细丝,实现高阻态和低阻态的切换(Larentis等, 2012)。

在此基础上,研究进一步发展出具备多端口与多功能特性的新型器件,如电化学RAM(electrochemical random-access memory, ECRAM)和忆阻晶体管。前者通过电化学离子迁移调节导电通道,实现高线性度和低能耗的突触权重更新;后者则结合二维材料的半导体特性与离子迁移效应,可同时调控突触权重与神经元阈值,为复杂时空信号处理提供硬件支撑。这些新型器件的出现,标志着神经形态硬件正从传统CMOS逻辑向新型物理机制驱动的计算体系演进。

### 1.3.3 非冯·诺依曼与存内计算架构

传统的冯·诺依曼架构将计算单元与存储单元分离,数据需频繁在两者之间传输,受制于“存储墙”瓶颈,导致能耗高、延迟大,难以满足类脑计算中对高并行度、低功耗和时序敏感性的要求。为突破这

一限制,非冯·诺依曼架构应运而生,其核心思想是计算与存储融合、事件驱动式并行处理和异步通信机制,在体系结构层面模拟生物神经网络的高效动态特性。如表1展示了传统的冯·诺依曼架构与非冯·诺依曼架构的对比。

表1 冯·诺依曼架构与非冯·诺依曼架构的对比

Table 1 Comparison between von Neumann architecture and non-von Neumann architecture

对比维度	冯·诺依曼架构	非冯·诺依曼架构
计算与存储关系	计算与存储分离	计算与存储一体化
数据处理方式	顺序执行(指令驱动)	事件驱动(异步并行)
能效表现	高功耗	低功耗
学习与适应性	依赖离线训练,结构固定	支持在线学习与可塑性调节
代表实现	CPU、GPU、TPU	Loihi、Tianjic、SpiNNaker、Darwin、BiCoSS

在这种架构中,计算可直接在存储阵列中完成,实现存算一体化。IMC通过电流叠加等方式在硬件阵列中执行矩阵向量乘操作,大幅降低了数据搬运能耗,从而使芯片具备更高的能效比与实时响应能力。例如,IBM的HERMES64核模拟计算芯片在14nm CMOS工艺中集成相变存储器阵列,每个阵列可执行高精度向量-矩阵运算,峰值能效达9.76TOPS/W,展示了存算一体在大规模推理中的可扩展性与稳定性(Le等,2023)。IBM的NorthPole作为新一代在IMC芯片,在系统层面实现了计算与局部存储的紧耦合。该芯片通过在每个核心中配置专用存储模块,实现完全“就地计算”,有效避免了传统总线带宽瓶颈,在图像推理任务中实现了数量级的性能与能效提升(Modha等,2023)。与此同时,FeFET阵列因具备多态可调特性,被成功用于构建多比特权重的存内计算宏单元,实现了在高密度存储条件下的高精度矩阵计算(Jerry等,2017)。

总体来看,非冯·诺依曼架构通过融合存储与计算、采用事件驱动的并行异步机制,突破了传统计算体系的瓶颈,为脑启发的人工智能硬件提供了高能效、可扩展的新范式。这一架构从物理层面体现了从“存算分离”向“存算融合”的转变,也为未来实现低功耗、自学习、智能化的神经形态系统奠定了基础。

### 1.4 脑启发的人工智能的产业应用

脑启发计算技术通过模拟生物神经系统的结构特征与信息处理机制,正在重塑人工智能产业的底

层技术范式。该技术以神经元动态、突触可塑性及分布式协同计算为核心理念,将生物智能的自适应性与能效优势引入工程系统之中。从当前研究与应用进展来看,脑启发的人工智能在神经模拟、智能感知、实时决策、能效优化等关键方向展现出显著潜力,不仅推动了算法架构的范式革新,也加速了智能制造、自动驾驶、医疗健康等领域的产业化落地(潘峰等,2021)。

在机器人领域,事件驱动型视觉传感器(如dynamic vision sensor, DVS)通过异步感知与低延迟响应,显著提升了机器人在复杂环境中的实时决策能力(Gallego等,2020)。例如,基于神经形态芯片的机器人系统已在快速运动目标追踪与避障任务中表现出优于传统视觉算法的性能(Vitale等,2021)。特斯拉“擎天柱”机器人借助神经环路级别的平衡与感知模拟,实现了实时步态调节与动态避障控制,运动规划效率提升约35%,体现了脑启发结构在高自由度控制系统中的优势。此外,神经形态计算在医疗设备中的应用逐渐成熟,如硅耳蜗植入设备通过脉冲编码技术实现高保真听觉信号处理(Chan等,2007),而神经形态假肢则通过事件驱动传感器与仿生控制算法,显著提升了触觉反馈的自然性与实时性(Osborn等,2018)。

在自动驾驶领域,神经形态系统的低功耗与实时性优势尤为突出。例如,英特尔Loihi芯片通过SNN实现了车辆周围环境的动态建模,相比传统GPU方案降低了能耗(Davies等,2021)。同时,神经

形态计算在边缘智能设备中的应用潜力巨大,例如智能手表可通过事件驱动的生物信号处理算法,实现实时健康监测(Kudithipudi等,2016)。此外,工业物联网中的分布式传感器网络借助神经形态芯片的稀疏通信特性,能够显著降低数据传输能耗,延长设备续航(Schuman等,2022)。

在金融领域,脑启发计算在金融分析和决策支持系统中展现出显著潜力。研究表明,基于脑启发学习机制的投资组合优化算法在多变量市场环境下的收益稳定性较传统深度模型提升约28%(Rundo等,2019)。此外,仿生认知决策框架被用于欺诈检测与异常识别,通过模仿大脑前额叶皮层的注意机制实现了交易模式异常的早期识别(Soltoggio等,2018)。在医疗健康领域,脑启发的人工智能正推动医疗智能从感知辅助迈向认知决策阶段。通过模拟大脑的感知—决策—反馈闭环机制,研究人员开发出多类具备自适应学习与多模态融合感知能力的智能医疗系统。研究者基于突触可塑性与时序依赖学习STDP机制开发了类脑康复接口系统(brain-machine interface, BMI),能够在患者运动意图与肌肉响应之间建立动态映射,实现实时反馈训练。

科学计算与高性能计算是另一重要应用方向。神经形态系统通过模拟生物神经网络的并行性与动态可塑性,已成功应用于复杂科学问题的求解,如蛋

白质折叠模拟与流体动力学建模(Severa等,2016)。此外,神经形态计算在航空航天领域的低功耗需求场景中展现出独特优势,例如欧洲空间局(European space agency, ESA)已将神经形态处理器部署于星载系统中,用于实时数据处理。

## 2 国内研究进展

我国脑启发的人工智能研究虽起步晚于欧美发达国家,但在国家重大科技战略引导和多学科交叉融合推动下,近年来已形成从神经机理建模、类脑算法设计到神经形态硬件与系统实现的完整技术链条。与国际研究以单点突破和算法性能为主的演进路径不同,国内研究呈现出鲜明的体系化推进特征:一方面注重模型与真实神经机制的对应关系,强调生物合理性与可解释性;另一方面面向工程落地需求,在能效、可扩展性和系统协同方面持续突破,逐步构建起具有自主知识产权的类脑计算技术体系。从研究内容看,国内学者围绕ANN与SNN的改进、神经环路与认知建模以及脑启发系统实现三个层面展开协同攻关。这种“算法—认知—硬件”多层次并行推进的研究范式(如图12所示),不仅加速了脑启发的人工智能从理论探索走向工程应用,也为我国在该领域形成长期竞争优势奠定了基础。

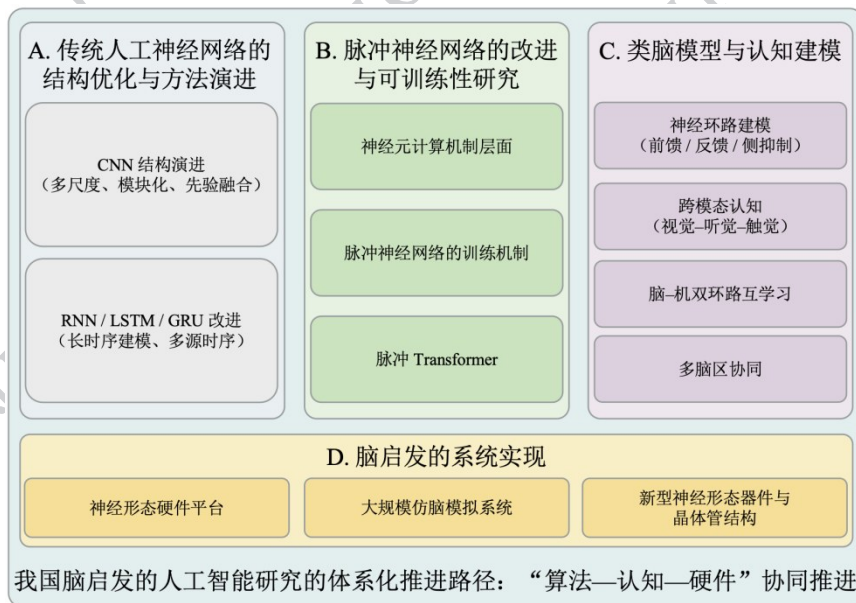


图12 我国脑启发的人工智能研究总体技术框架图

Fig. 12 Overall technical framework of brain-inspired artificial intelligence research in China

## 2.1 传统人工神经网络的结构优化与方法演进

ANN是现代人工智能的基础,其核心思想是通过模拟生物神经元的连接与计算方式,实现智能系统的感知与学习功能。国内研究在继承深度学习主流框架的同时,逐步将研究重点从单纯的性能提升,转向结构优化、生物合理性增强以及复杂场景适应能力的提升。

在前馈神经网络与卷积神经网络CNN方面,国内学者围绕模型结构演进及其在复杂数据分布和真实应用场景中的适应能力开展了系统性研究。CNN模型结构经历了从早期浅层卷积网络向深层、多分支与模块化结构的演进,其关键技术路线主要包括卷积核设计与感受野扩展、层级特征表达、多尺度特征融合以及先验知识与网络结构的协同建模等方向。相关综述工作(严春满和王铖,2021;田雨禾,2025)对CNN的结构演进脉络和核心技术路线进行了系统梳理,指出在复杂场景下引入结构先验和任务相关约束是提升模型鲁棒性与泛化能力的重要手段。在此背景下,Fang等人(2023)提出了一种针对长尾类别和标签噪声的图像分类方法,通过识别尾部类别中的噪声样本并在训练中降低其影响,有效提升了模型在不平衡和噪声数据环境下的目标识别性能。Gao等人(2021)提出的多尺度曲波散射网络(multi-scale curvelet scattering networks, MSCCNs)框架,利用曲波散射模型(curvelet scattering model, CCM)有效描述了图像特征。上述研究体现出国内在视觉任务中由单纯依赖网络深度与参数规模,逐步转向“结构设计与先验知识融合”的发展趋势,使CNN在复杂感知任务中的稳定性与泛化能力得到显著提升。

在循环神经网络RNN及其结构改进方面,国内研究者围绕序列建模能力不足、长程依赖难以捕获以及复杂时序数据适应性有限等核心问题,开展了系统而深入的研究。研究中对RNN的结构演化与技术路线进行了系统梳理,将现有模型概括为衍生RNN、组合RNN与混合RNN三大类,并指出通过引入门控机制、层次结构和跨结构融合,是缓解梯度消失、增强时序建模能力的主要发展方向(刘建伟和宋志妍,2021)。在此基础上,国内学者围绕LSTM和GRU等关键模型开展了大量改进工作,通过在网络内部结构、门控方式以及时空建模维度上的创新,有效提升了模型对长时序依赖和复杂动态模式的刻画

能力。例如,张等人(2022)提出基于残差的门控循环单元,通过引入残差连接缓解深层GRU训练中的性能退化问题,增强了对长时序依赖的建模能力。何等人(2025)采用ConvLSTM网络对InSAR地面沉降数据进行时空联合建模,有效刻画了空间相关性与时间演化特征。王等人(2021)结合互信息特征选择与改进粒子群算法优化LSTM参数,提升了多源时序数据融合场景下的预测精度与稳定性。相关研究不仅在语音识别、自然语言处理和行为识别等任务中取得了显著性能提升,也逐步推动RNN模型从单一时序建模向多尺度、多模态和高鲁棒性方向发展,体现出国内在RNN结构体系化改进方面的持续积累与深化。

## 2.2 脉冲神经网络的改进与可训练性研究

在脉冲神经网络SNN的研究中,国内学者的探索逐渐形成了一条以生物神经系计算机制为起点、以可训练性与能效优化为核心目标的演进路径。在神经元计算机制层面,研究者不仅关注脉冲编码方式本身,也开始从单神经元内部结构出发探索表达能力的提升路径。传统SNN多采用“单点积分—阈值触发”的简化神经元模型,难以刻画生物神经元中普遍存在的树突非线性整合现象。为突破这一限制,部分国内研究通过引入多间室神经元模型(Yang等,2020)或树突级非线性运算(Chen等,2022),使单个神经元具备更强的局部特征组合与非线性表达能力,在不显著增加网络规模的前提下提升了整体计算能力。与此同时,针对传统同质神经元假设的局限,相关工作(Fang等,2021;Sun等,2023)在膜时间常数、发放阈值等关键参数中引入可学习的异质性,使神经元在时间响应与脉冲发放条件上呈现差异化动态特性,从而增强了网络对复杂时序模式的建模能力与泛化性能。这类研究表明,生物多样性并非仅是建模负担,而可以被系统性地转化为计算优势。

尽管在神经元与计算机制层面不断增强模型表达能力,SNN的离散脉冲特性仍使其在学习与训练阶段面临显著挑战。围绕脉冲发放函数不可微这一核心瓶颈,国内学者从学习机制层面对SNN的可训练性展开系统探索(Yi等,2023;Ding等,2025)。现有研究大体可归纳为三类具有代表性的技术路线。第一类基于STDP学习规则(Yi等,2023;庄祖江等,2020),依托突触前后脉冲发放时序相关性实现局部

权值更新,强调生物可解释性与实现简洁性,但由于缺乏全局误差信号的有效传递,在深层网络结构和复杂任务场景中存在一定局限;第二类基于梯度优化的方法(Lian等,2023;Wu等,2018),将误差反向传播机制引入脉冲神经元的时空动力学建模中,通常借助替代梯度或可微近似缓解脉冲不可微问题,使误差信息能够沿时间与空间维度反向传播,从而支持端到端的监督学习,在性能与可扩展性方面表现突出,但也对梯度稳定性与计算效率提出了更高要求;第三类方法采用ANN-SNN转换范式(Bu等,2025),通过在连续值人工神经网络中完成模型训练并将其映射为等效的脉冲表示,从训练阶段规避不可微性约束,相关研究进一步围绕转换误差控制、脉冲发放率约束以及推理时延优化等问题展开,结合ANN-SNN知识蒸馏技术(Xu等2023),以提升转换后SNN的实用性与部署效率。总体而言,上述三类方法分别从局部可塑性机制、全局误差驱动学习以及间接构建可训练脉冲表示等不同层面,为深层脉冲神经网络的训练与优化提供了相互补充的技术路径。

随着网络深度的不断增加,单纯依赖局部替代梯度的方法逐渐暴露出梯度消散、表示冗余以及训练不稳定等问题。为应对深层结构下的表示退化现象,近期研究(Zhang等,2022;Yang和Chen,2025a;Yang等,2025b)开始引入更具全局约束性的理论视角,将信息论方法融入SNN的训练过程。通过显式建模有效信息的保留与冗余表示的压缩,这类方法在一定程度上改善了深层脉冲网络中的表示质量,为构建稳定可训练的大规模SNN提供了新的理论支撑。

在训练机制逐步成熟的基础上,研究重心进一步从局部学习规则转向网络结构层面的表达能力扩展。传统卷积或前馈式SNN在建模长程时序依赖与全局上下文关系方面存在天然局限,其计算过程更依赖局部感受野与逐层传播,这在复杂视觉理解、跨时间关联建模以及多模态任务中逐渐成为性能瓶颈。与此同时,随着SNN向深层化与规模化发展,如何在保持脉冲计算范式的同时提升全局信息交互能力,成为网络结构设计中的关键问题。在这一背景下,Transformer架构因其基于自注意力机制的全局建模能力,被视为拓展SNN表达能力的重要候选方案(徐晗等,2025;Zhao等,2022;Shen

2025a等)。然而,标准Transformer依赖连续值表示与softmax归一化操作,其计算模式与脉冲神经网络的事件驱动特性在形式上存在显著差异。针对这一不匹配问题,国内研究者(Zhou等,2022;Zhou等,2023)开始探索将自注意力机制重新表述为脉冲域中的计算过程,通过对Query、Key和Value的脉冲化表示与事件驱动点积运算,实现对全局依赖关系的建模,同时避免高能耗的连续归一化操作。通过引入脉冲自注意力机制,构建了基于Transformer框架的深层脉冲神经网络模型,使SNN首次在结构层面具备了与主流深度模型相当的全局建模能力,例如Spikformer(Zhou等,2022)、Spikingformer(Zhou等,2023)、SpikeCLIP(Lv等,2025)和SDiT(Yang等,2024b)等模型。与传统Transformer不同,这类模型通常以时间维度上的脉冲序列作为输入,通过跨时间步的注意力计算实现对时序信息的动态加权,从而更自然地融合脉冲编码与注意力机制。随着脉冲Transformer架构的逐步完善,其应用范围也从早期的静态分类任务扩展至目标检测(Yao,2024;Xu等2025;Miao等2025)、语义分割(Lv等,2025)、生成建模(Yang等,2024)连续学习(Shen等,2024)以及多模态信息处理(Shen等,2025b)。在这些应用中,脉冲自注意机制不仅显著增强了模型对复杂时序依赖关系的建模能力,也为在神经形态硬件上实现高效推理提供了结构基础。

### 2.3 类脑模型与认知建模

在神经网络模型与算法不断演进的背景下,国内类脑研究逐步形成了一条以神经环路为核心、贯通感知、认知与行为的建模主线。不同于传统人工神经网络主要关注映射关系和任务性能,真实大脑通过多层级神经环路的协同作用,实现了信息在不同模态、不同时间尺度以及不同功能层级之间的动态组织。因此,如何以神经环路为中介,理解并复现感知—认知—行为的整体过程,成为国内类脑模型与认知建模研究的共同关注点。

在这一主线中,研究首先从跨模态信息的神经环路重编码机制展开。多模态认知并非简单的信号转换,而依赖神经环路对信息时序结构与表征空间的统一组织。国内部分研究通过仿生神经环路结构,将这一机制引入工程系统中,例如通过模拟头足类动物神经-色素细胞通路(Qu等,2025),实现触觉信息向光学信号的动态编码与传递。这类工作表

明,跨模态认知的关键不在于模态本身,而在于神经环路如何保持信息结构并完成重编码,为后续认知处理提供统一表征基础。

在实现跨模态统一表征的基础上,研究进一步关注认知过程本身如何在不同学习系统之间协同形成。传统脑机接口将人脑视为信号源、机器作为被动解码器,而近年来提出的脑-机双环路互学习框架(Liu等,2025),则将生物神经环路与人工神经环路视为两个可共同演化的认知单元。通过引入具备突触可塑性的人工环路结构,机器系统能够根据生物认知状态动态调整自身参数,从而与生物环路形成正反馈闭环。这一研究思路将认知建模从“信号解码”提升为“系统协同学习”,揭示了认知并非单一系统内部的过程,而是可在多系统间协同涌现。

然而,无论是跨模态感知还是脑-机协同,其有效性都高度依赖神经环路结构本身的表达能力。基于这一认识,国内研究进一步将注意力转向神经环路结构的自主演化机制。与依赖人工先验设计固定网络结构的传统模型不同,自主演化框架通过可塑性规则驱动连接的生成与消亡,使环路结构本身成为学习过程的一部分。相关研究(Shen等,2023)表明,引入前馈、反馈与侧向抑制等多类型连接,不仅显著提升了脉冲神经网络在动态感知与大规模任务中的性能,也增强了模型在跨模态场景中的泛化能力。这一结果从认知层面说明,结构多样性是支持复杂认知与持续学习的重要条件,而非额外复杂性来源。

当神经环路在结构与功能层面具备自适应能力后,其价值最终体现在复杂行为与运动控制的整体表现上。国内在类脑运动控制领域的研究(Xing等,2022;Wang等,2024),普遍将感觉皮层、运动皮层、小脑、基底神经节及脊髓等多脑区纳入统一建模框架,通过多时间尺度的预测、反馈与调节,实现认知与行为的闭环协同。尽管具体模型形式各异,但这些研究在方法论上高度一致:高质量行为并非源于单一复杂策略,而是来自多脑区神经环路在认知与执行层面的分工协作。这类模型在复杂环境下的鲁棒性、小样本学习能力及抗干扰性能方面具有明显优势,验证了以神经环路为核心的认知-行为建模路径的有效性。

总体来看,国内类脑模型与认知建模研究已逐步完成从局部机制探索到系统级建模的过渡,形成

了一条以神经环路为纽带、贯通跨模态感知、协同认知与复杂行为控制的发展路径。尽管在环路尺度扩展、跨脑区统一建模及认知层可解释性方面仍面临挑战,但可以预见,随着神经科学实验数据、类脑硬件平台与模型方法的进一步融合,基于神经环路的整体认知建模将成为推动类脑人工智能走向通用化的重要基础。

## 2.4 脑启发的系统实现

当前,国内脑启发硬件的设计正经历从深度学习加速器向脑启发计算芯片的体系化转型。如表1展示了传统的冯·诺依曼架构与非冯·诺依曼架构的对比,前者以高性能算力与并行加速为核心目标,依托传统冯·诺依曼架构不断提升算力密度与任务吞吐率;后者则突破冯·诺依曼瓶颈,通过计算与存储的一体化设计,实现对生物神经过程的物理仿真与能效优化,更加注重结构可塑性和自适应性。在此背景下,我国科研团队积极探索神经形态计算的体系结构与新型器件实现路径,致力于构建具备事件驱动并行、低功耗、可塑性强的类脑计算系统。

### 2.4.1 神经形态硬件平台

近年来,中国在神经形态计算与类脑芯片领域取得了显著进展,涌现出一批具有自主知识产权的硬件平台。这些平台在能效、实时性和可塑性方面逐渐逼近国际先进水平,并在国内AI芯片生态中占据关键地位。

清华大学提出的“天机芯”(Tianjic)是全球首个在同一硬件平台上融合人工神经网络ANN与脉冲神经网络SNN的类脑芯片(Pei等,2019)。该芯片采用数字与模拟混合架构,支持可重构数据流,能够同时处理ANN和SNN任务,适用于图像识别、语音处理和自动驾驶等多模态任务。Tianjic的提出突破了传统类脑芯片仅能支持单一SNN架构的限制,在算法兼容性与应用通用性方面具有里程碑意义,为通用化类脑计算提供了可行路径。

浙江大学开发的“Darwin系列芯片”则聚焦于SNN的硬件实现。最新一代Darwin 3(Ma等,2024)采用新型指令集架构,支持灵活的神经元模型编程与局部学习规则设计,具备多达235万个神经元的处理规模和高密度突触连接能力,同时具备片上在线学习功能。该芯片在神经元规模、突触存储密度及推理效率等方面均处于国际领先水平,为类脑智能的硬件实现提供了坚实基础。除上述代表性平台

外, BiCoSS(Yang等, 2022)是国内近年来提出的另一类具有代表性的类脑计算系统,其核心特点在于强调算法—架构—硬件的协同设计支持。BiCoSS面向复杂认知与感知任务,体现了国内在系统级类脑计算架构方面的探索,为推动类脑智能从单一芯片向多片级联复杂系统形态演进提供了重要思路。

总体而言,这些国内神经形态硬件平台的持续发展标志着我国在类脑计算硬件自主创新能力方面的显著提升。它们不仅推动了脑启发计算技术的实际应用与产业化进程,也为构建具备高能效与自适应特性的下一代人工智能系统奠定了重要基础。

#### 2.4.2 大规模仿脑模拟系统

在硬件实现的同时,科学界也致力于通过仿真平台来模拟大脑的结构与功能。大规模脑模拟系统旨在通过计算手段重建大脑的神经网络结构,以研究其计算机制和信息处理模式。为此我国于2016年正式提出中国脑计划,该计划以“认知原理—疾病机理—类脑计算”为主线,旨在揭示人脑的认知规律、阐明脑疾病的神经机制,并推动脑启发的人工智能的发展。其研究体系涵盖从基础神经科学到工程实现的全链条内容,强调多学科交叉与多层次融合。

在上述研究框架下,国内涌现出一批面向脉冲神经网络与类脑认知建模的开源仿真平台。其中, SpikingJelly(Fang等, 2023)是近年来发展迅速、具有广泛影响力的脉冲神经网络仿真与开发框架之一。SpikingJelly由国内研究团队提出,基于PyTorch构建,借助与主流深度学习生态的兼容性,SpikingJelly已被广泛用于大规模SNN训练、事件驱动视觉处理等研究方向。中国科学院自动化研究所开发的BrainCog平台是国内脑启发认知计算领域的另一项代表性成果。该平台是一个开源脑启发认知计算框架,旨在模拟大脑的多层次认知功能(Zeng等, 2023)。BrainCog采用模块化认知架构,支持多模块灵活组合,实现从单一认知过程到复杂智能行为的多层次仿真,成为国内类脑智能系统研究的重要基础平台。此外,复旦大学建立的脑启发仿真与多模态智能平台,以大脑多模态信息处理机制为核心,融合视觉、听觉与语言等多模态信息通道,通过注意机制、记忆模块和跨模态学习算法实现语义层面的综合理解(Lu等, 2023)。

#### 2.4.3 新型神经形态器件与晶体管结构

在脑启发硬件体系中,器件层的创新是实现高

效神经形态计算的关键基础。随着非冯·诺依曼架构的不断发展,如何通过新型材料和器件实现神经形态计算的高效能和可扩展性,成为国内研究的重要方向。为此,Xiong提出了基于脉冲耦合神经网络模型(pulse coupled neural network, PCNN)的CMOS神经元电路,该电路能够模拟神经元的放电与脉冲传递特性,并在高集成度与低功耗的条件下实现脉冲神经网络的并行计算(Xiong等, 2010)。此外,国内研究者通过CMOS晶体管模拟神经元与突触功能,构建大规模脉冲神经网络SNN(Zhu等, 2023),推动了类脑硬件在能效和扩展性上的提升。

在新型晶体管结构方面,Wan团队开发的IGZO双电层晶体管(electric double layer transistor, EDLT)(Wan等, 2016)成功模拟短时程可塑性和长时程可塑性,并通过光调控实现动态滤波功能。这一成果不仅在材料设计层面突破了传统晶体管的功能限制,也为构建具备“感知—计算—记忆”一体化能力的光电神经形态器件奠定了基础。此外,国内研究者提出的一晶体管—电阻结构通过串联晶体管限制电流,显著提高了阻态可控性,并支持多级存储(Sun等, 2020)。Wang等人(2018)提出的全忆阻神经网络(fully memristive neural network, FMNN)框架通过忆阻器阵列实现突触权值存储与动态更新,在无监督学习与模式分类任务中展现出接近生物神经系统的自适应特性。该研究进一步验证了忆阻器及其网络结构在实现高密度、低功耗类脑计算系统中的潜力,为国内相关研究提供了重要的理论与技术参考。

### 3 国内外研究进展比较

脑启发的人工智能作为神经科学与人工智能深度交叉的前沿方向,其研究范式在国际范围内呈现出高度融合与系统化的发展趋势。总体来看,欧美、日本等发达国家在基础理论积累、神经形态硬件体系以及跨学科协同研究方面起步较早,已形成从神经机制建模到系统级验证的较为完整研究链条;我国虽进入该领域时间相对较晚,但在国家战略牵引和持续科研投入的推动下,逐步形成了以算法创新、自主硬件研制和应用导向为特征的发展路径,并在若干关键方向上实现了具有国际影响力的突破。

在理论与算法层面,国际研究长期围绕生物神

经元与神经环路机制展开系统建模,为人工神经网络和脉冲神经网络的发展奠定了坚实基础。从早期的Hodgkin-Huxley模型到后续的LIF、Izhikevich等简化模型,相关工作在生物合理性与计算可行性之间不断取得平衡,并逐步推动SNN在视觉感知、时序建模和自主决策等任务中的应用。基于脉冲时间依赖可塑性STDP及神经调制机制的学习框架,使得网络能够在一定程度上实现在线学习和环境自适应,为类脑智能系统提供了重要理论支撑。在此基础上,国内研究并未简单复现既有模型,而是更加注重模型表达能力与工程可扩展性的结合。相关工作从神经元参数与结构的异质性建模、树突层级非线性机制引入,到信息论约束(Yang等,2025a)、自监督学习(Yang等,2025b)和注意力机制与SNN的融合等多个层面展开探索。这类研究不仅在一定程度上提升了网络对复杂时序信息的建模能力,也增强了模型在噪声环境和跨任务场景中的鲁棒性。尤其是在Transformer结构与脉冲自注意机制结合方面的探索,反映出国内团队在吸收国际前沿思想的同时,积极推动SNN向深层化与通用化方向演进。这一趋势表明,国内在算法层面的优势正逐步从“追赶”转向“结构性创新”。

在硬件与系统层面,国际研究呈现出以神经形态芯片为核心、算法与认知功能协同推进的发展格局。美国在该领域保持整体领先,通过构建大规模神经形态计算平台,不断验证类脑计算在能效和持续学习方面的潜力。以Loihi 2和NorthPole为代表的芯片体系,体现了通过体系结构创新突破冯·诺依曼瓶颈的技术路线,其应用场景也开始从感知加速拓展至推理与认知层级。与此同时,欧洲通过跨国基础设施建设,强调脑结构数据、计算模型与临床应用之间的协同映射,推动类脑研究向神经科学与医学领域延伸。相比之下,我国在类脑硬件发展中更加强调自主可控与应用牵引。以“天机芯”为代表的类脑芯片体系,在支持ANN与SNN异构融合、实现多模态感知与控制任务方面形成了鲜明特色,展示了国内在算法—硬件协同设计方面的系统能力(Pei等,2019)。以BiCoSS(Yang等,2022)为例的大规模神经拟态计算平台的持续推进,使我国在认知级类脑计算系统方面逐步建立起工程化优势。这类平台不仅关注神经元和突触规模的扩展,更注重算法、硬件与认知任务之间的协同验证,体现了国内研究从

单点突破向系统集成演进的趋势。总体而言,尽管在工艺成熟度和生态完善程度上仍与国际先进水平存在差距,但我国在系统架构创新和应用导向设计方面已具备较强竞争力。

在应用层面,国际脑启发的人工智能研究多聚焦于自动驾驶、机器人控制和高性能感知系统等高附加值场景,强调在复杂动态环境中实现低延迟与高能效的统一。基于神经形态硬件的事件驱动视觉和控制系统,展示了类脑方法在实时性和鲁棒性方面相较传统方案的优势。国内研究则在智能驾驶、无人系统、类脑机器人和神经形态计算平台等方向形成了较为全面的布局,相关成果逐步从实验验证走向实际场景部署。通过多模态感知、层级化决策与类脑控制的融合,我国在复杂环境下的自主智能系统方面展现出良好的应用潜力,脑启发的人工智能正开始服务于智能装备与无人系统的发展需求(Qiao等,2021)。

综合比较可以看出,国际研究在脑启发的人工智能的基础理论深度、神经形态硬件成熟度以及跨学科协同机制方面仍占据整体优势,而国内研究则在算法优化路径、自主硬件体系构建以及面向应用的系统集成方面形成了鲜明特色。然而,国内在基础神经机制建模深度、先进制造工艺以及长期跨学科协同方面仍存在不足。未来发展亟需在加强神经科学、材料科学与人工智能深度融合的同时,加快类脑硬件和软件生态的完善,通过“国际合作与自主创新并重”的方式,逐步构建覆盖模型、算法、硬件与应用的全链条创新体系,从而在若干关键方向上实现由并跑向领跑的转变。

## 4 发展趋势与展望

脑启发的人工智能正处于由理论探索向系统化工程实践过渡的关键阶段,其发展趋势已不再体现为单一算法或器件的突破,而是逐步演化为算法、硬件、系统架构与认知机制的协同推进。从整体上看,该领域的核心目标正在从提升局部计算效率,转向构建具备高能效、强泛化能力、可持续学习且具备可解释性的类脑智能系统。这一转变不仅关系到人工智能计算范式的演进,也为探索通用人工智能提供了新的技术路径。

在算法层面,脉冲神经网络和神经调制机制为  
© 中国图象图形学报版权所有

突破传统深度学习在能耗、时间建模和持续学习方面的瓶颈提供了重要启发。然而,当前研究面临的主要挑战已从“是否可训练”转向“能否支撑深层结构与复杂任务”。尽管替代梯度、局部学习规则以及 ANN - SNN 转换等方法在一定程度上缓解了脉冲信号不可微带来的训练困难,但在网络规模和任务复杂度提升后,仍普遍存在梯度稳定性不足、表示冗余以及跨时间尺度信息建模能力有限等问题。此外,现有模型在感知、决策与控制等功能的统一建模方面仍显不足,往往依赖人工结构设计,难以实现对动态环境的自适应调节。未来算法研究需要更加注重神经动力学建模、时序编码机制与信息流约束之间的协同设计,在保证生物合理性的同时提升工程可扩展性和模型可解释性。

可解释性问题是当前脑启发人工智能面临的另一项关键挑战。尽管类脑模型在结构和学习机制上更接近生物神经系统,但在实际应用中,其内部动力学过程、脉冲编码方式以及神经调制信号对决策行为的影响仍缺乏清晰、可量化的解释框架。一方面,深层 SNN 与神经调制模型在时空维度上的高度非线性,使得模型行为难以通过传统权重分析或特征可视化方法进行理解;另一方面,现有评测体系更多关注任务性能与能效指标,对模型决策过程的可解释性和可靠性关注不足。未来研究需要结合神经科学理论、信息论分析与可解释人工智能方法,探索从神经元动力学、突触可塑性到系统级行为决策的多层次解释机制,从而为类脑智能在安全关键和高可靠性场景中的应用提供理论支撑。

在硬件与系统实现层面,类脑芯片和神经形态计算平台被认为是释放脑启发算法能效潜力的关键基础。事件驱动、异步并行和存算一体等架构在理论上能够显著降低能耗,但在实际部署中,其优势往往受到通信开销、资源调度复杂度以及系统规模扩展等因素的制约。随着神经元和突触规模的增加,片上与跨核通信所引入的额外能耗逐渐显现,使部分神经形态平台在复杂模型运行时的能效优势明显收敛。未来类脑硬件的发展不仅依赖新型器件性能的提升,更需要从体系结构层面推进算法-硬件协同设计,通过稀疏计算、事件压缩、分层调度以及软硬件协同映射等手段,降低系统级冗余开销,提升整体能效与可扩展性。

从系统架构与应用需求的视角来看,当前脑启

发的人工智能在复杂动态环境中,感知精度、决策时效性与系统稳定性之间仍存在明显权衡,限制了在长期自主运行场景中的应用潜力。未来的重要发展方向在于构建感知-决策-控制紧密耦合的类脑闭环系统,并引入神经调制和多时间尺度控制机制,使系统能够根据环境变化动态调整内部状态与资源分配。这一思路不仅有助于提升系统在不确定环境中的鲁棒性,也为实现持续学习与任务迁移提供了结构基础。同时,认知功能建模(如前额叶-海马系统)有望从理论参照逐步转化为系统设计层面的重要依据,推动人工智能从任务驱动向情境理解与自主决策演进。

在产业应用与生态建设方面,尽管脑启发人工智能在自动驾驶、机器人、医疗健康和边缘智能等领域已展现出显著潜力,但其规模化落地仍受到标准体系缺乏、软硬件接口不统一以及开发门槛较高等现实因素制约。目前,不同研究平台在脉冲编码方式、模型描述语言和性能评测指标上的差异,使得研究成果难以直接比较和复用,制约了技术迭代与产业转化效率。因此,在持续推进算法和硬件创新的同时,加快构建兼顾性能、能效与可解释性的评测体系和开发工具链,将成为推动脑启发的人工智能走向工程实践的重要基础条件。

总体而言,脑启发的人工智能正沿着通用化、规模化与融合化的方向加速发展,其研究重心将从单一技术突破逐步转向系统级协同创新。随着神经科学、人工智能与新型计算技术的深度交叉,脑启发的人工智能有望在低功耗智能系统、自主决策与复杂时序信息处理等方面发挥关键支撑作用,并在推动人工智能理论演进与产业升级中展现出长期而深远的影响。

**致谢:**本文由中国图象图形学学会类脑视觉专委会组织撰写,该专委会更多详情请见链接:  
<https://www.csig.org.cn/16/202111/49338.html>

## 参考文献 (References)

- Abreu S, Shrestha S B, Zhu R J and Eshraghian J. 2025. Neuromorphic principles for efficient large language models on Intel Loihi 2 [EB/OL]. [2025-02-12].  
<https://arxiv.org/abs/2503.18002>.
- Adamczyk J, Makarenko V, Tiomkin S and Kulkarni R V. 2025. Average-reward soft actor-critic [EB/OL]. [2025-08-05].

<https://arxiv.org/abs/2501.09080>.

- Ahmed F Y, Hamed H N A and Yusob B. 2014. Computing with spiking neuron networks: A review. *International Journal of Advances in Soft Computing & Its Applications*, 6(1): 21 - 41.
- Akopyan F, Sawada J, Cassidy A, Alvarez-Icaza R, Arthur J, Merolla P, et al. 2015. Truenorth: Design and tool flow of a 65 mw 1 million neuron programmable neurosynaptic chip. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 34(10): 1537-1557 [DOI: 10.1109/TCAD.2015.2474396].
- Amaya C, Eames E, Palinauskas G, Perzlyo A, Sandamirskaya Y and von Arnim A. 2024. Neuromorphic force-control in an industrial task: validating energy and latency benefits//Proceedings of the 2024 IEEE/RSJ International Conference on Intelligent Robots and Systems. Abu Dhabi: IEEE: 717-724 [DOI: 10.1109/IROS58592.2024.10802430].
- Azevedo F A C, Carvalho L R B, Grinberg L T, Farfel J M, Ferretti R E L and Leite R E P, et al. 2009. Equal numbers of neuronal and nonneuronal cells make the human brain an isometrically scaled-up primate brain. *Journal of Comparative Neurology*, 513(5): 532 - 541 [DOI: 10.1002/cne.21974].
- Bargmann C I and Marder E. 2013. From the connectome to brain function. *Nature Methods*, 10(6): 483 - 490.
- Bargmann C I and Newsome W T. 2014. The brain research through advancing innovative neurotechnologies (BRAIN) initiative and neurology. *JAMA Neurology*, 71(6): 675 - 676.
- Bartolozzi C, Indiveri G and Donati E. 2022. Embodied neuromorphic intelligence. *Nature Communications*, 13(1): 1024 [DOI: 10.1038/s41467-022-28632-7].
- Beck J M, Ma W J, Pitkow X, Latham P E and Pouget A. 2012. Not noisy, just wrong: the role of suboptimal inference in behavioral variability. *Neuron*, 74(1): 30 - 39 [DOI: 10.1016/j.neuron.2012.03.016].
- Bellec G, Scherr F, Subramoney A, Hajek E, Salaj D and Legenstein R, et al. 2020. A solution to the learning dilemma for recurrent networks of spiking neurons. *Nature Communications*, 11(1): 3625 [DOI: 10.1038/s41467-020-17236-y].
- Bellemare M G, Dabney W and Munos R. 2017. A distributional perspective on reinforcement learning//Proceedings of the 34th International Conference on Machine Learning. PMLR: 449 - 458.
- Beniaguev D, Segev I and London M. 2021. Single cortical neurons as deep artificial neural networks. *Neuron*, 109(17): 2727 - 2739.e3 [DOI: 10.1016/j.neuron.2021.07.002].
- Bhattachali N X, Pattabiraman V, Pinto L and Lindsay G W. 2024. Neural Circuit Architectural Priors for Quadruped Locomotion [EB/OL]. [2024-10-09]. <https://arxiv.org/abs/2410.07174>
- Borgeaud S, Mensch A, Hoffmann J, Cai T, Rutherford E and Millican K, et al. 2022. Improving language models by retrieving from trillions of tokens//Proceedings of the 39th International Conference on Machine Learning. PMLR: 2206 - 2240.
- Boyn S, Grollier J, Lecerf G, Xu B, Locatelli N, Fusil S, et al. 2017. Learning through ferroelectric domain dynamics in solid-state synapses. *Nature Communications*, 8(1): 14736 [DOI: 10.1038/ncomms14736].
- Bu T, Li M and Yu Z. 2025. Inference-Scale Complexity in ANN-SNN Conversion for High-Performance and Low-Power Applications. *Proceedings of the Computer Vision and Pattern Recognition Conference*: 24387 - 24397.
- Caligiore D, Pezzulo G, Baldassarre G, Bostan A C, Strick P L, Doya K, et al. 2017. Consensus paper: towards a systems-level view of cerebellar function: the interplay between cerebellum, basal ganglia, and cortex. *The Cerebellum*, 16(1): 203-229 [DOI: 10.1007/s12311-016-0763-3].
- Caporale N and Dan Y. 2008. Spike timing - dependent plasticity: a Hebbian learning rule. *Annual Review of Neuroscience*, 31(1): 25 - 46.
- Chan V, Liu S C and van Schaik A. 2007. AER EAR: A matched silicon cochlea pair with address event representation interface. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 54(1): 48-59 [DOI: 10.1109/TCSL.2006.888687].
- Chay T R. 1985. Chaos in a three-variable model of an excitable cell. *Physica D: Nonlinear Phenomena*, 16(2): 233 - 242 [DOI: 10.1016/0167-2789(85)90060-0].
- Chen Y and Liu J. 2022. Polynomial dendritic neural networks. *Neural Computing and Applications*, 34(14): 11571-11588 [DOI: 10.1007/s00521-022-07174-0].
- Cho K, Van Merriënboer B, Gulcehre C, Bahdanau D, Bougares F and Bengio Y, et al. 2014. Learning phrase representations using RNN encoder - decoder for statistical machine translation [EB/OL]. <https://arxiv.org/pdf/1406.1078.pdf>.
- Choi J H, Sim S E, Kim J, Choi D I, Oh J and Ye S, et al. 2018. Inter-regional synaptic maps among engram cells underlie memory formation. *Science*, 360(6387): 430 - 435 [DOI: 10.1126/science.aas9204].
- Cisek P, Drew T and Kalaska J F, eds. 2007. Computational neuroscience: theoretical insights into brain function. (Progress in Brain Research, 165). Amsterdam: Elsevier.
- Colicos M and Goda Y. 2001. Pictures reveal how nerve cells form connections to store short- and long-term memories in the brain. *Cell*, 107(5): 605616 [DOI: 10.1016/S0092-8674(01)00564-2].
- Corchado C, Antonietti A, Capolei M C, Casellato C and Tolu S. 2020. Integration of paired spiking cerebellar models for voluntary movement adaptation in a closed-loop neuro-robotic experiment: a simulation study//Proceedings of 2019 IEEE International Conference on Cyborg and Bionic Systems and HBP Workshop. [DOI: 10.1109/CBS46900.2019.9114412].
- Dai Z, Liu H, Le Q V, Tan M and Fu J, et al. 2021. CoAtNet: Marrying convolution and attention for all data sizes. *Advances in Neural*

- Information Processing Systems, 34: 3965 – 3977.
- Dampfhofer M, Anghel L, Mesquida T and Valentian A, et al. 2023. Backpropagation-based learning techniques for deep spiking neural networks: A survey. *IEEE Transactions on Neural Networks and Learning Systems*, 35(9): 11906 – 11921 [DOI: 10.1109/TNNLS.2023.3263008].
- Davies M, Srinivasa N, Lin T H, Chinya G, Cao Y, Choday S H, et al. 2018. Loihi: A neuromorphic manycore processor with on-chip learning. *IEEE Micro*, 38(1): 82-99 [DOI: 10.1109/MM.2018.112130359].
- Davies M, Wild A, Orchard G, Sandamirskaya Y, Fonseca Guerra G and Joshi P, et al. 2021. Advancing neuromorphic computing with Loihi: a survey of results and outlook. *Proceedings of the IEEE*, 109: 911 – 934 [DOI: 10.1109/JPROC.2021.3067593].
- Dean P, Porrill J, Ekerot C F and Jörntell H. 2010. The cerebellar microcircuit as an adaptive filter: experimental and computational evidence. *Nature Reviews Neuroscience*, 11(1): 30-43 [DOI: 10.1038/nrn2756].
- Delorme A, Gautrais J, Van Rullen R and Thorpe S J. 1999. SpikeNET: A simulator for modeling large networks of integrate-and-fire neurons. *Neurocomputing*, 26: 989 – 996 [DOI: 10.1016/S0925-2312(99)00095-8].
- DeWolf T, Stewart T C, Slotine J-J and Eliasmith C. 2016. A spiking neural model of adaptive arm control. *Proceedings of the Royal Society B: Biological Sciences*, 283(1843): 20162134 [DOI: 10.1098/rspb.2016.2134].
- Ding J, Zhang J, Huang T, Liu J K and Yu Z. 2025. Assisting Training of Deep Spiking Neural Networks With Parameter Initialization. *IEEE Transactions on Neural Networks and Learning Systems*.
- Dosovitskiy A, Beyer L, Kolesnikov A, Weissenborn D, Zhai X and Unterthiner T, et al. 2020. An image is worth 16×16 words: Transformers for image recognition at scale [EB/OL]. <https://arxiv.org/pdf/2010.11929.pdf>.
- Duan Y, Schulman J, Chen X, Bartlett P L, Sutskever I and Abbeel P. 2016. RL<sup>2</sup>: Fast reinforcement learning via slow reinforcement learning [EB/OL]. [2016-11-09]. <https://arxiv.org/abs/1611.02779>.
- Eliasmith C, Stewart T C, Choo X, Bekolay T, DeWolf T and Tang Y C, et al. 2012. A large-scale model of the functioning brain. *Science*, 338(6111): 1202 – 1205 [DOI: 10.1126/science.1225266].
- Endress A D and Johnson S P. 2021. When forgetting fosters learning: A neural network model for statistical learning. *Cognition*, 213: 104621 [DOI: 10.1016/j.cognition.2021.104621].
- Eshraghian J K, Ward M, Neftci E O, Wang X, Lenz G and Dwivedi G, et al. 2023. Training spiking neural networks using lessons from deep learning. *Proceedings of the IEEE*, 111(9): 1016 – 1054 [DOI: 10.1109/JPROC.2023.3308088].
- Fang C, Cheng L, Zhang D, Li G and Jiao L. 2023. Separating noisy samples from tail classes for long-tailed image classification with label noise. *IEEE Transactions on Neural Networks and Learning Systems* 2023, Early Access. [DOI: 10.1109/TNNLS.2023.3291695].
- Fang W, Chen Y, Ding J, Zhang X, Zhou Z and Tian Y. 2023. Spikingjelly: An open-source machine learning infrastructure platform for spike-based intelligence. *Science Advances*, 9(40): eadi1480 [DOI: 10.1126/sciadv.adi1480].
- Fang W, Yu Z, Chen Y, Ma T, Masquelier T and Tian Y. 2021. Incorporating learnable membrane time constant to enhance learning of spiking neural networks//*Proceedings of the 2021 IEEE/CVF International Conference on Computer Vision*. Montreal: IEEE: 2661-2671 [DOI: 10.1109/ICCV48922.2021.00268].
- Farnworth M S and Montgomery S H. 2024. Evolution of neural circuitry and cognition. *Biology Letters*, 20(5): 20230576 [DOI: 10.1098/rsbl.2023.0576].
- Feldmann J, Youngblood N, Karpov M, Gehring H and Pernice W. 2021. Parallel convolutional processing using an integrated photonic tensor core. *Nature*, 589(7840): 52-58 [DOI: 10.1038/s41586-020-03063-0].
- Finn C, Abbeel P and Levine S. 2017. Model-agnostic meta-learning for fast adaptation of deep networks//*Proceedings of the 34th International Conference on Machine Learning*. PMLR: 1126 – 1135.
- Frémaux N, Sprekeler H and Gerstner W. 2013. Reinforcement learning using a continuous time actor-critic framework with spiking neurons. *PLoS Computational Biology*, 9(4): e1003024 [DOI: 10.1371/journal.pcbi.1003024].
- Gallego G, Delbrück T, Orchard G, Bartolozzi C and Scaramuzza D. 2020. Event-based vision: A survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 44(1): 154-180 [DOI: 10.1109/TPAMI.2020.3008413].
- Gao J, Jiao L, Liu F, Yang S, Hou B and Liu X. 2021. Multiscale curvelet scattering network. *IEEE Transactions on Neural Networks and Learning Systems*, 34(7): 3665-3679 [DOI: 10.1109/TNNLS.2021.3118221].
- Gentili R J, Oh H, Kregling A V and Reggia J A. 2016. A cortically-inspired model for inverse kinematics computation of a humanoid finger with mechanically coupled joints. *Bioinspiration & Biomimetics*, 11(3): 036013 [DOI: 10.1088/1748-3190/11/3/036013].
- Gerstner W, Lehmann M, Liakoni V, Corneil D and Brea J. 2018. Eligibility traces and plasticity on behavioral time scales: experimental support of neohebbian three-factor learning rules. *Frontiers in Neural Circuits*, 12: 53 [DOI: 10.3389/fncir.2018.00053].
- Ghosh-Dastidar S and Adeli H. 2009. A new supervised learning algorithm for multiple spiking neural networks with application in epilepsy and seizure detection. *Neural Networks*, 22(10): 1419-1431 [DOI: 10.1016/j.neunet.2009.04.003].
- Girão W S, Risi N and Chicca E. 2025. Learning in spiking neural networks with a calcium-based Hebbian rule for spike-timing-

- dependent plasticity [EB/OL]. [2025-04-09].  
<https://arxiv.org/abs/2504.06796>.
- Göltz J, Kriener L, Baumbach A, Billandelle S, Breitwieser O F and Gibson B, et al. 2021. Fast and energy-efficient neuromorphic deep learning with first-spike times. *Nature Machine Intelligence*, 3(9): 823 - 835 [DOI:10.1038/s42256-021-00388-x].
- Gonzalez H A, Huang J, Kelber F and Furber S. 2024. SpiNNaker2: A large-scale neuromorphic system for event-based and asynchronous machine learning [EB/OL]. [2024-01-08].  
<https://arxiv.org/abs/2401.04491>
- González-Redondo Á, Garrido J A, Hellgren Kotaleski J, Grillner S and Ros E. 2025. Cholinergic modulation enables scalable action selection learning in a computational model of the striatum. *Scientific Reports*, 15(1): 34902 [DOI: 10.1038/s41598-025-18776-3].
- Graves A, Mohamed A and Hinton G. 2013. Speech recognition with deep recurrent neural networks//Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing. Vancouver: IEEE: 6645 - 6649 [DOI: 10.1109/ICASSP.2013.6638947].
- Hagras H, Pounds-Cornish A, Colley M, Callaghan V and Clarke G. 2004. Evolving spiking neural network controllers for autonomous robots//Proceedings of the 2004 IEEE International Conference on Robotics and Automation. New Orleans: IEEE: 4620-4626 [DOI: 10.1109/ROBOT.2004.1302409].
- Han Y, Deng C and Huang G B. 2023. Brain-inspired cognition and understanding for next-generation AI: Computational models, architectures and learning algorithms. *Frontiers in Neuroscience*, 17: 1169027 [DOI: 10.3389/fnins.2023.1169027].
- He K, Zhang X, Ren S and Sun J. 2016. Deep residual learning for image recognition//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE: 770 - 778 [DOI:10.1109/CVPR.2016.90].
- He Y, Yao S, Chen Y, Yan H W and Zhang L F. 2025. Spatiotemporal prediction of time-series InSAR land subsidence based on ConvLSTM neural network. *Geomatics and Information Science of Wuhan University*, 50(3): 483-496 (何毅, 姚圣, 陈毅, 闫浩文, 张立峰. 2025. ConvLSTM 神经网络的时序 InSAR 地面沉降时空预测. *武汉大学学报(信息科学版)*, 50(3): 483-496 [DOI: 10.13203/j.whugis.20220657])
- Hebb D O. 2005. *The organization of behavior: A neuropsychological theory*. Psychology Press.
- Hochreiter S and Schmidhuber J. 1997. Long short-term memory. *Neural Computation*, 9(8): 1735 - 1780 [DOI: 10.1162/neco.1997.9.8.1735].
- Hodgkin A L and Huxley A F. 1952. A quantitative description of membrane current and its application to conduction and excitation in nerve. *The Journal of Physiology*, 117(4): 500 - 544 [DOI: 10.1113/jphysiol.1952.sp004764].
- Hu Y, Zheng Q, Li G, et al. 2024. Toward large-scale spiking neural networks: A comprehensive survey and future directions [J]. *arXiv preprint arXiv:2409.02111*.
- Huang T J, Yu Z F, Li Y, Shi B X, Xiong R Q, Ma L, et al. 2022. Advances in spike vision. *Journal of Image and Graphics*, 27(6): 1823-1839 (黄铁军, 余肇飞, 李源, 施柏鑫, 熊瑞勤, 马雷, 等. 2022. 脉冲视觉研究进展. *中国图象图形学报*, 27(6): 1823-1839) [DOI: 10.11834/jig.220175]
- Hull C. 2020. Prediction signals in the cerebellum: beyond supervised motor learning. *eLife*, 9: e54073 [DOI: 10.7554/eLife.54073].
- Huo B Q, Gao Y Z and Qi X F. 2023. Spiking neural networks for brain-inspired computing. *Journal of Image and Graphics*, 28(2): 401-417 (霍兵强, 高彦钊, 祁晓峰. 2023. 面向类脑计算的脉冲神经网络研究. *中国图象图形学报*, 28(2): 401-417)
- Ielmini D, Wang Z and Liu Y. 2021. Brain-inspired computing via memory device physics. *APL Materials*, 9(5): 050702 [DOI: 10.1063/5.0047641].
- Jerusalem A. 2018. Catastrophic importance of catastrophic forgetting [EB/OL]. [2018-08-20].  
<https://arxiv.org/abs/1808.07049>.
- Indiveri G, Linares-Barranco B, Hamilton T J, van Schaik A, Etienne-Cummings R, Delbruck T, et al. 2011. Neuromorphic silicon neuron circuits. *Frontiers in Neuroscience*, 5: 73 [DOI: 10.3389/fnins.2011.00073].
- Izhikevich E M. 2003. Simple model of spiking neurons. *IEEE Transactions on Neural Networks*, 14(6): 1569 - 1572 [DOI: 10.1109/TNN.2003.820440].
- Jerry M, Chen P Y, Zhang J, Sharma P, Ni K, Yu S, et al. 2017. Ferroelectric FET analog synapse for acceleration of deep neural network training//2017 IEEE International Electron Devices Meeting (IEDM). San Francisco: IEEE: 6.2.1-6.2.4 [DOI: 10.1109/IEDM.2017.8268338].
- Jiang X, Zhang Q, Sun J, Cao J, Ma J and Xu R. 2023. Fully Spiking Neural Network for Legged Robots [EB/OL]. [2023-10-08].  
<https://arxiv.org/abs/2310.05022>
- Jolivet R, Lewis T J and Gerstner W. 2003. The spike response model: A framework to predict neuronal spike trains//Proceedings of the International Conference on Artificial Neural Networks. Berlin: Springer: 846 - 853 [DOI: 10.1007/3-540-44989-2\_101].
- Kamiński J, Sullivan S, Chung J M, Ross I B, Mamelak A N and Rutishauser U. 2017. Persistently active neurons in human medial frontal and medial temporal lobe support working memory. *Nature Neuroscience*, 20(4): 590 - 601 [DOI: 10.1038/nn.4509].
- Kandel E R, Schwartz J H, Jessell T M. 2000. *Principles of Neural Science* [M]. 4th ed. New York: McGraw-Hill
- Khandelwal U, Levy O, Jurafsky D, Zettlemoyer L and Lewis M. 2019. Generalization through memorization: Nearest neighbor language models [EB/OL]. [2019-11-01].  
<https://arxiv.org/abs/1911.00172>.

- Khodadadi Z, Trpevski D, Lindroos R, et al. 2024. Local, calcium-and reward-based synaptic learning rule that enhances dendritic nonlinearities can solve the nonlinear feature binding problem [EB/OL]. [2024-03-12]. bioRxiv: 2024.03.12.584462 [DOI: 10.1101/2024.03.12.584462].
- Kim I J, Kim M K and Lee J S. 2023. Highly-scaled and fully-integrated 3-dimensional ferroelectric transistor array for hardware implementation of neural networks. *Nature Communications*, 14 (1): 504 [DOI: 10.1038/s41467-023-36270-0].
- Krizhevsky A, Sutskever I and Hinton G E. 2012. Imagenet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, 25: 1106 - 1114.
- Kudithipudi D, Saleh Q, Merkel C, Thesing J and Wysocki B. 2016. Design and analysis of a neuromemristive reservoir computing architecture for biosignal processing. *Frontiers in Neuroscience*, 9: 502 [DOI: 10.3389/fnins.2015.00502].
- Kudithipudi D, Schuman C, Vineyard C M, Li P, Lin P and Joshi S. 2025. Neuromorphic computing at scale. *Nature*, 637(8047): 801-812 [DOI: 10.1038/s41586-024-08253-8].
- Lake B M, Ullman T D, Tenenbaum J B and Gershman S J. 2017. Building machines that learn and think like people. *Behavioral and Brain Sciences*, 40: e253 [DOI: 10.1017/S0140525X16001837].
- Larentis S, Nardi F, Balatti S, Gilmer D C and Ielmini D. 2012. Resistive switching by voltage-driven ion migration in bipolar RRAM—Part II: Modeling. *IEEE Transactions on Electron Devices*, 59(9): 2468-2475 [DOI: 10.1109/TED.2012.2202320].
- Le Gallo M, Khaddam-Aljameh R, Stanisavljevic M, Papandreou N and Eleftheriou E. 2023. A 64-core mixed-signal in-memory compute chip based on phase-change memory for deep neural network inference. *Nature Electronics*, 6(9): 680-693 [DOI: 10.1038/s41928-023-01002-5].
- Lee S, Sohn J, Jiang Z, Kim S and Williams R S. 2015. Metal oxide-resistive memory using graphene-edge electrodes. *Nature Communications*, 6(1): 8407 [DOI: 10.1038/ncomms9407].
- Lerner T N, Holloway A L and Seiler J L. 2021. Dopamine, updated: reward prediction error and beyond. *Current Opinion in Neurobiology*, 67: 123 - 130 [DOI: 10.1016/j.conb.2020.10.012].
- Lewis P, Perez E, Piktus A, Petroni F, Karpukhin V and Goyal N, et al. 2020. Retrieval-augmented generation for knowledge-intensive NLP tasks. *Advances in Neural Information Processing Systems*, 33: 9459 - 9474.
- Lian S, Shen J, Liu Q, Li C, Pan G and Wu Y. 2023. Learnable surrogate gradient for direct training spiking neural networks//Proceedings of the 32nd International Joint Conference on Artificial Intelligence (IJCAI 2023). Macao: IJCAI Organization: 3002-3010 [DOI: 10.24963/ijcai.2023/329].
- Lin J, Guha S and Ramanathan S. 2018. Vanadium dioxide circuits emulate neurological disorders. *Frontiers in Neuroscience*, 12: 856 [DOI: 10.3389/fnins.2018.00856].
- Liu F, Zhao W, Chen Y, Yu Q and Li Y. 2021. SSTDP: Supervised spike timing dependent plasticity for efficient spiking neural network training. *Frontiers in Neuroscience*, 15: 756876 [DOI: 10.3389/fnins.2021.756876].
- Liu H C, Ren W Q, Wang R and Cao X C. 2022. A super-resolution Transformer fusion network for single blurred image. *Journal of Image and Graphics*, 27(5): 1616-1631 (刘花成, 任文琦, 王蕊, 操晓春. 2022. 用于单幅模糊图像超分辨率的Transformer融合网络. *中国图象图形学报*, 27(5): 1616-1631) [DOI: 10.11834/jig.210847].
- Liu J W and Song Z Y. 2022. A survey of recurrent neural networks (刘建伟, 宋志妍. 2022. 循环神经网络研究综述). *控制与决策*, 37(11): 2753-2768 [DOI: 10.13195/j.kzyjc.2021.1241].
- Liu Z, Lin Y, Cao Y, Hu H, Wei Y and Zhang Z, et al. 2021. Swin Transformer: Hierarchical vision transformer using shifted windows//Proceedings of the IEEE/CVF International Conference on Computer Vision. Montreal; IEEE/CVF: 10012 - 10022 [DOI: 10.1109/ICCV48922.2021.00986].
- Liu Z, Mao H, Wu C Y, Feichtenhofer C, Darrell T and Xie S. 2022. A convnet for the 2020s//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE/CVF: 11976 - 11986 [DOI: 10.1109/CVPR52688.2022.01167].
- Liu Z, Mei J, Tang J, Xu M, Gao B, Wang K, et al. 2025. A memristor-based adaptive neuromorphic decoder for brain - computer interfaces. *Nature Electronics*. Advance Online Publication. [DOI: 10.1038/s41928-025-01340-2].
- Lu W, Zeng L, Du X, Zhang Y, Li Q and Wang H. 2023. Digital Twin Brain: a simulation and assimilation platform for whole human brain [EB/OL]. [2023-08-02]. <https://arxiv.org/abs/2308.01241>
- Lv C, Li T, Liu W, Zhang J and Liu Q. 2025. Spikeclip: A contrastive language-image pretrained spiking neural network. *Neural Networks*, 180: 107475 [DOI: 10.1016/j.neunet.2024.107475].
- Lyu F, Wang L, Li X, Zheng W S, Zhang Z, Zhou T, et al. 2025. Comprehensive survey of continual learning. *Journal of Image and Graphics*, 30(8): 2599-2632 (吕凡, 王亮, 李玺, 郑伟诗, 张彰, 周涛, 胡伏原. 2025. 持续学习研究进展. *中国图象图形学报*, 30(8): 2599-2632) [DOI: 10.11834/jig.240661].
- Ma D, Jin X, Sun S, Zhang Y, Li H and Wang Q. 2024. Darwin3: a large-scale neuromorphic chip with a novel ISA and on-chip learning. *National Science Review*, 11(5): nwae102 [DOI: 10.1093/nsr/nwae102].
- Ma W J, Beck J M, Latham P E and Pouget A. 2006. Bayesian inference with probabilistic population codes. *Nature Neuroscience*, 9(11): 1432 - 1438 [DOI: 10.1038/nn1790].
- Maass W and Natschläger T. 1997. Networks of spiking neurons can emulate arbitrary Hopfield nets in temporal coding. *Network: Computation in Neural Systems*, 8(4): 355 - 371.
- Maass W. 1997. Networks of spiking neurons: The third generation of

- neural network models. *Neural Networks*, 10(9): 1659 - 1671 [DOI: 10.1016/S0893-6080(97)00011-7].
- Malavena G, Spinelli A S and Compagnoni C M. 2018. Implementing spike-timing-dependent plasticity and unsupervised learning in a mainstream NOR flash memory array//2018 IEEE International Electron Devices Meeting (IEDM). San Francisco: IEEE: 2.3.1-2.3.4. [DOI: 10.1109/IEDM.2018.8614604].
- Mannella F and Baldassarre G. 2015. Selection of cortical dynamics for motor behaviour by the basal ganglia. *Biological Cybernetics*, 109(6): 575-595 [DOI: 10.1007/s00422-015-0662-6].
- Mead C. 1990. Neuromorphic electronic systems. *Proceedings of the IEEE*, 78(10): 1629-1636 [DOI: 10.1109/5.58356].
- Mei J, Rodriguez-Garcia A, Takeuchi D, Friedrich J and Dayan P, et al. 2025. Improving the adaptive and continuous learning capabilities of artificial neural networks: lessons from multi-neuromodulatory dynamics [EB/OL]. <https://arxiv.org/abs/2501.06762>
- Miao W, Shen J, Xu H, Kärkkäinen T, Xu Q, Xu Y and Cong F. 2025. Advanced SpikingYOLOX: Extending Spiking Neural Network on Object Detection with Spike-based Partial Self-Attention and 2D-Spiking Transformer. *Proceedings of the 33rd ACM International Conference on Multimedia*: 10837 - 10846.
- Modha D S, Akopyan F, Andreopoulos A, Cassidy A, Merolla P and Arthur J. 2023. Neural inference at the frontier of energy, space, and time. *Science*, 382(6668): 329-335 [DOI: 10.1126/science.adi7562].
- Morilak D A, Barrera G, Echevarria D J, Garcia A S, Hernandez A and Ma S, et al. 2005. Role of brain norepinephrine in the behavioral response to stress. *Progress in Neuro-Psychopharmacology and Biological Psychiatry*, 29(8): 1214 - 1224 [DOI: 10.1016/j.pnpb.2005.08.007].
- Nagumo J, Arimoto S and Yoshizawa S. 1962. An active pulse transmission line simulating nerve axon. *Proceedings of the IRE*, 50(10): 2061 - 2070 [DOI: 10.1109/JRPROC.1962.288235].
- Nazari S and Amiri M. 2025. An accurate and fast learning approach in the biologically spiking neural network. *Scientific Reports*, 15(1): 6585 [DOI: 10.1038/s41598-025-90113-0].
- Orvieto A, Smith S L, Gu A, Fernandez-Marqués J, Dehghani M and Hutter F, et al. 2023. Resurrecting recurrent neural networks for long sequences//*Proceedings of the International Conference on Machine Learning*. Honolulu: PMLR: 26670 - 26698.
- Osborn L E, Dragomir A, Betthausen J L, Hunt C L and Kaliki R R. 2018. Prosthesis with neuromorphic multilayered e-skin perceives touch and pain. *Science Robotics*, 3(19): eaat3818 [DOI: 10.1126/scirobotics.aat3818].
- Pan F and Bao H. 2021. Research progress of autonomous driving control technology based on reinforcement learning. *Journal of Image and Graphics*, 26(1): 28-35 (潘峰, 鲍泓. 2021. 基于强化学习的自动驾驶控制技术研究进展. *中国图象图形学报*, 26(1): 28-35) [DOI: 10.11834/jig.200428].
- Park T J, Deng S, Manna S, Wang C, Schranghamer T F, Trainor N, et al. 2023. Complex oxides for brain-inspired computing: A review. *Advanced Materials*, 35(37): 2203352 [DOI: 10.1002/adma.202203352].
- Pei J, Deng L, Song S, et al. 2019. Towards artificial general intelligence with hybrid Tianjic chip architecture. *Nature*, 572(7767): 106-111 [DOI: 10.1038/s41586-019-1424-8].
- Pickett M D, Medeiros-Ribeiro G and Williams R S. 2013. A scalable neuristor built with Mott memristors. *Nature Materials*, 12(2): 114-117 [DOI: 10.1038/nmat3510].
- Prescott T J, González F M M, Gurney K, Humphries M D and Redgrave P. 2006. A robot model of the basal ganglia: behavior and intrinsic processing. *Neural Networks*, 19(1): 31 - 61 [DOI: 10.1016/j.neunet.2005.06.049].
- Prescott T J, Montes González F M, Gurney K, Humphries M D and Redgrave P. 2024. Simulated dopamine modulation of a neurobotic model of the basal ganglia. *Biomimetics*, 9(3): 139 [DOI: 10.3390/biomimetics9030139].
- Qiao H, Chen J and Huang X. 2021. A survey of brain-inspired intelligent robots: Integration of vision, decision, motion control, and musculoskeletal systems. *IEEE Transactions on Cybernetics*, 52(10): 11267-11280 [DOI: 10.1109/TCYB.2020.3043948].
- Qu S, Yu Q, Jiang C, Liu Y, Zhang H and Wang X. 2025. Oxide semiconductor in a neuromorphic chromaticity communication loop for extreme environment exploration. *Science Advances*, 11(20): eadu3576 [DOI: 10.1126/sciadv.adu3576].
- Rideaux R, Storrs K R, Maiello G and Welchman A E. 2021. How multisensory neurons solve causal inference. *Proceedings of the National Academy of Sciences*, 118(32): e2106235118 [DOI: 10.1073/pnas.2106235118].
- Rolfs M, Jonikaitis D, Deubel H and Cavanagh P. 2011. Predictive remapping of attention across eye movements. *Nature Neuroscience*, 14(2): 252 - 256 [DOI: 10.1038/nn.2711].
- Roy K, Jaiswal A and Panda P. 2019. Towards spike-based machine intelligence with neuromorphic computing. *Nature*, 575: 607 - 617 [DOI: 10.1038/s41586-019-1677-2].
- Rumelhart D E, Hinton G E and Williams R J. 1986. Learning representations by back-propagating errors. *Nature*, 323(6088): 533 - 536.
- Rundo F, Trenta F, Di Stallo A L and Battiato S. 2019. Machine learning for quantitative finance applications: A survey. *Applied Sciences*, 9(24): 5574 [DOI: 10.3390/app9245574].
- Schultz W. 2024. A dopamine mechanism for reward maximization. *Proceedings of the National Academy of Sciences*, 121(20): e2316658121 [DOI: 10.1073/pnas.2316658121].
- Schuman C D, Kulkarni S R, Parsa M, Mitchell J P and Kay B. 2022. Opportunities for neuromorphic computing algorithms and applications. *Nature Computational Science*, 2(1): 10-19 [DOI: 10.1038/s43588-021-00184-y].

- Severa W, Parekh O, Carlson K D, James C D and Aimone J B. 2016. Spiking network algorithms for scientific computing//2016 IEEE International Conference on Rebooting Computing (ICRC). San Diego: IEEE: 1-8 [DOI: 10.1109/ICRC.2016.7738693].
- Shen G, Zhao D, Dong Y, Liu H, Wang J and Li Q. 2023. Brain-inspired neural circuit evolution for spiking neural networks. *Proceedings of the National Academy of Sciences*, 120 (39) : e2218173120 [DOI: 10.1073/pnas.2218173120].
- Shen J, Xie Y, Xu Q, Pan G, Tang H and Chen B. 2025. Spiking neural networks with temporal attention-guided adaptive fusion for imbalanced multi-modal learning. *Proceedings of the 33rd ACM International Conference on Multimedia*: 11042 - 11051.
- Shen J, Wang K, Gao W, Liu J K, Xu Q, Pan G, Chen X and Tang H. 2025. Temporal spiking generative adversarial networks for heading direction decoding. *Neural Networks*, 184: 106975.
- Shen J, Ni W, Xu Q and Tang H. 2024. Efficient spiking neural networks with sparse selective activation for continual learning. *Proceedings of the AAAI Conference on Artificial Intelligence*, 38 (1): 611 - 619.
- Simonyan K and Zisserman A. 2014. Very deep convolutional networks for large-scale image recognition [EB/OL]. [2014-09-04]. <https://arxiv.org/pdf/1409.1556.pdf>.
- Smith J T H, Warrington A and Linderman S W. 2022. Simplified state space layers for sequence modeling [EB/OL]. <https://arxiv.org/pdf/2208.04933.pdf>.
- Soltoggio A, Stanley K O and Risi S. 2018. Born to learn: the inspiration, progress, and future of evolved plastic artificial neural networks. *Neural Networks*, 108: 48-67 [DOI: 10.1016/j.neunet.2018.08.013].
- Sun H, Cai W, Yang B, Xu Q and Liu H. 2023. A synapse-threshold synergistic learning approach for spiking neural networks. *IEEE Transactions on Cognitive and Developmental Systems*, 16 (2) : 544-558 [DOI: 10.1109/TCDS.2023.3282668].
- Sun W, Wang Q Z, Chen X L, Ding C, Yan Q S, Zhang L, et al. 2025. Development of real-world image super-resolution. *Journal of Image and Graphics*, 30(6) : 1576-1592 (孙巍, 王乾宙, 陈雪凌, 丁晨, 闫庆森, 张磊, 等. 2025. 真实场景下图像超分辨率技术现状与趋势. *中国图象图形学报*, 30(6) : 1576-1592 [DOI: 10.11834/jig.240775]).
- Sun Z, Ambrosi E, Pedretti G and Ielmini D. 2020. In-memory PageRank accelerator with a cross-point array of resistive memories. *IEEE Transactions on Electron Devices*, 67(4) : 1466-1470 [DOI: 10.1109/TED.2020.2969457].
- Szegedy C, Liu W, Jia Y, Sermanet P, Reed S and Anguelov D, et al. 2015. Going deeper with convolutions//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Boston: IEEE: 1 - 9 [DOI: 10.1109/CVPR.2015.7298594].
- Tan M and Le Q. 2019. EfficientNet: rethinking model scaling for convolutional neural networks//*Proceedings of the International Conference on Machine Learning*. Long Beach: PMLR: 6105 - 6114.
- Tan M and Le Q. 2021. EfficientNetV2: smaller models and faster training//*Proceedings of the International Conference on Machine Learning*. Virtual: PMLR: 10096 - 10106.
- Tavanaei A and Maida A. 2019. BP-STDP: Approximating backpropagation using spike timing dependent plasticity. *Neurocomputing*, 330: 39 - 47.
- Teeter C, Iyer R, Menon V, Gouwens N, Feng D and Berg J, et al. 2018. Generalized leaky integrate-and-fire models classify multiple neuron types. *Nature Communications*, 9(1) : 709 [DOI: 10.1038/s41467-017-02717-4].
- Terven J. 2025. Deep reinforcement learning: a chronological overview and methods. *AI*, 6(3): 46 [DOI: 10.3390/ai6030046].
- Theotokis P. 2025. Human brain inspired artificial intelligence neural networks. *Journal of Integrative Neuroscience*, 24 (4) : 26684 [DOI: 10.31083/JIN26684].
- Tolu S, Capolei M C, Vannucci L, Lund H H and Vanegas M. 2020. A cerebellum-inspired learning approach for adaptive and anticipatory control. *International Journal of Neural Systems*, 30 (1) : 1950028 [DOI: 10.1142/S012906571950028X].
- Tolu S, Vanegas M, Garrido J A, Luque N R and Ros E. 2013. Adaptive and predictive control of a simulated robot arm. *International Journal of Neural Systems*, 23 (3) : 1350010 [DOI: 10.1142/S012906571350010X].
- Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L and Gomez A N, et al. 2017. Attention is all you need. *Advances in Neural Information Processing Systems*, 30: 5998 - 6008.
- Vatansever D, Smallwood J and Jefferies E. 2021. Varying demands for cognitive control reveals shared neural processes supporting semantic and episodic memory retrieval. *Nature Communications*, 12 (1) : 2134 [DOI: 10.1038/s41467-021-22354-7].
- Vecoven N, Ernst D, Wehenkel A and Drion G. 2020. Introducing neuromodulation in deep neural networks to learn adaptive behaviours. *PLoS One*, 15(1): e0227922.
- Vijayakumar S, D' Souza A and Schaal S. 2005. Incremental online learning in high dimensions. *Neural Computation*, 17(12) : 2602-2634 [DOI: 10.1162/089976605774320557].
- Vinyals O, Babuschkin I, Czarnecki W M, Mathieu M, Dudzik A and Chung J, et al. 2019. Grandmaster level in StarCraft II using multi-agent reinforcement learning. *Nature*, 575 (7782) : 350 - 354 [DOI: 10.1038/s41586-019-1724-z].
- Vitale A, Renner A, Nauer C, Bartolozzi C and Indiveri G. 2021. Event-driven vision and control for UAVs on a neuromorphic chip//*Proceedings of the 2021 IEEE International Conference on Robotics and Automation*. Xi'an: IEEE: 103-109 [DOI: 10.1109/ICRA48506.2021.9561006].
- Wan C J, Liu Y H, Zhu L Q, Shi Y and Wan Q. 2016. Short-term synaptic plasticity regulation in solution-gated indium - gallium - zinc-oxide electric-double-layer transistors. *ACS Applied Materials & © 中国图象图形学报版权所有*

- Interfaces, 8(15): 9762-9768 [DOI: 10.1021/acsami.6b01021].
- Wang J X, Kurth-Nelson Z, Kumaran D, Tirumala D, Soyer H and Leibo J Z, et al. 2018. Prefrontal cortex as a meta-reinforcement learning system. *Nature Neuroscience*, 21(6): 860 - 868.
- Wang L, Xu H, Shu B, Yi C and Tian Y Q. 2021. A multi-source heterogeneous data fusion method for landslide monitoring with mutual information and IPSO-LSTM neural network. *Geomatics and Information Science of Wuhan University*, 46(10): 1478-1488 (王利, 许豪, 舒宝, 义琛, 田云青. 2021. 利用互信息和IPSO-LSTM进行滑坡监测多源数据融合. *武汉大学学报(信息科学版)*, 46(10): 1478-1488) [DOI: 10.13203/j.whugis20210131]
- Wang Q, Sun Y, Lu E, Zhang H, Li J and Chen B. 2024. Brain-inspired action generation with spiking transformer diffusion policy model//*Proceedings of the International Conference on Brain Inspired Cognitive Systems*. Singapore: Springer Nature Singapore: 229-238.
- Wang Y, Xu Y, Yan R and Tang H. 2020. Deep spiking neural networks with binary weights for object recognition. *IEEE Transactions on Cognitive and Developmental Systems*, 13(3): 514-523 [DOI: 10.1109/TCDS.2020.2977321].
- Wang Z, Joshi S, Savel' Ev S, Li Y, Gao B and Ielmini D. 2018. Fully memristive neural networks for pattern classification with unsupervised learning. *Nature Electronics*, 1(2): 137-145 [DOI: 10.1038/s41928-018-0023-2].
- Widrow B. 1960. Adaptive "adaline" neuron using chemical "memistors"[R]. Stanford: ,CA:Stanford University.
- Wilterson A I and Graziano M S A. 2021. The attention schema theory in a neural network agent: Controlling visuospatial attention using a descriptive model of attention. *Proceedings of the National Academy of Sciences*, 118(33): e2102421118 [DOI: 10.1073/pnas.2102421118].
- Woo S, Debnath S, Hu R, Chen X, Liu Z and Kweon I S, et al. 2023. ConvNeXt V2: co-designing and scaling convnets with masked autoencoders//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Vancouver: IEEE/CVF: 16133 - 16142 [DOI: 10.1109/CVPR52729.2023.01548].
- Wu J, Wang Y, Li Z, et al. 2024. A review of computing with spiking neural networks. *Computers, Materials & Continua*, 78(3) [DOI: 10.32604/cmc.2024.047240]
- Wu Y, Deng L, Li G, Zhu J and Shi L. 2018. Spatio-temporal back-propagation for training high-performance spiking neural networks. *Frontiers in Neuroscience*, 12: 331 [DOI: 10.3389/fnins.2018.00331].
- Wu Y, Rabe M N, Hutchins D L and Szegedy C. 2022. Memorizing transformers [EB/OL]. [2022-03-16]. <https://arxiv.org/abs/2203.08913>.
- Wulff P, Schonewille M, Renzi M, Viltano L, Sassoè-Pognetto M, Badura A, et al. 2009. Synaptic inhibition of Purkinje cells mediates consolidation of vestibulo-cerebellar motor learning. *Nature Neuroscience*, 12(8): 1042-1049 [DOI: 10.1038/nn.2348].
- Xing D, Li J, Zhang T and Xu B. 2022. A brain-inspired approach for collision-free movement planning in the small operational space. *IEEE Transactions on Neural Networks and Learning Systems*, 33(5): 2094-2105 [DOI: 10.1109/TNNLS.2020.3034535].
- Xiong Y, Han W H, Zhao K, Wang J and Liu Z. 2010. An analog CMOS pulse coupled neural network for image segmentation//2010 10th IEEE International Conference on Solid-State and Integrated Circuit Technology. Shanghai: IEEE: 1883-1885 [DOI: 10.1109/ICSICT.2010.5667946].
- Xu H, Dong S H, Zhang J W and Zheng Y H. 2025. Transformer object tracking method integrating contextual-aware attention. *Journal of Image and Graphics*, 30(1): 212-224 (徐哈, 董仕豪, 张家伟, 郑钰辉. 2025. 融合上下文感知注意力的Transformer目标跟踪方法. *中国图象图形学报*, 30(1): 212-224) [DOI: 10.11834/jig.240084]
- Xu Q, Deng J, Shen J, Chen B, Tang H and Pan G. 2025. Hybrid Spiking Vision Transformer for Object Detection with Event Cameras. *Forty-second International Conference on Machine Learning*.
- Xu Q, Li Y, Shen J, Liu J K, Tang H and Pan G. 2023. Constructing deep spiking neural networks from artificial neural networks with knowledge distillation. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*: 7886 - 7895
- Yamins D L K, Hong H, Cadieu C F, Solomon E A, Seibert D and DiCarlo J J. 2014. Performance-optimized hierarchical models predict neural responses in higher visual cortex. *Proceedings of the National Academy of Sciences*, 111(23): 8619 - 8624.
- Yan C M and Wang C. 2021. Development and application of convolutional neural network model (严春满, 王铖. 2021. 卷积神经网络模型发展及应用). *计算机科学与探索*, 15(1): 27-46) [DOI: 10.3778/j.issn.1673-9418.2008016].
- Yang S, Chen B. 2025a. Effective Surrogate Gradient Learning With High-Order Information Bottleneck for Spike-Based Machine Intelligence [J]. *IEEE transactions on neural networks and learning systems*, 36(1): 1734-1748. [DOI: 10.1109/TNNLS.2023.3329525].
- Yang S, Deng B, Wang J, Li H, Lu M and Che Y. 2020. Scalable digital neuromorphic architecture for large-scale biophysically meaningful neural network with multi-compartment neurons. *IEEE Transactions on Neural Networks and Learning Systems*, 31(1): 148-162 [DOI: 10.1109/TNNLS.2019.2909433].
- Yang S, Linares-Barranco B, Wu Y, Chen B and Huang T. 2025b. Self-Supervised High-Order Information Bottleneck Learning of Spiking Neural Network for Robust Event-Based Optical Flow Estimation [J]. *IEEE transactions on pattern analysis and machine intelligence*, 47(4): 2280-2297. [DOI: 10.1109/TPAMI.2024.3510627]
- Yang S, Ma H, Yu C, Chen B and Huang T. 2024b. Sdit: Spiking diffusion model with transformer [EB/OL]. [2024-02-18]. <https://arxiv.org/abs/2402.11588>
- Yang S, Wang J, Hao X, Deng B, Liu C, Huang T, et al. 2022.

- BiCoSS: toward large-scale cognition brain with multigranular neuromorphic architecture. *IEEE Transactions on Neural Networks and Learning Systems*, 33 (7) : 2801-2815 [DOI: 10.1109/TNNLS.2020.3043432].
- Yao M, Hu J, Hu T, Xu B and Li Z. 2024. Spike-driven transformer v2: Meta spiking neural network architecture inspiring the design of next-generation neuromorphic chips [EB/OL]. [2024-04-05]. <https://arxiv.org/abs/2404.03663>
- Yu L, Shi B X, Wang W, Yu Z F, Guo Y F, Qiao N, et al. 2025. Neuromorphic-enabled visual enhancement: principles, methods and recent advances. *Journal of Image and Graphics*, 30(6) : 1593-1615 (余磊, 施柏鑫, 王威, 余肇飞, 郭宇飞, 乔宁, 等. 2025. 类脑赋能视觉增强: 原理、方法与前沿进展. *中国图象图形学报*), 30(6) : 1593-1615 [DOI: 10.11834/jig.240779]
- Yi Z, Lian J, Liu Q, Li C and Pan G. 2023. Learning rules in spiking neural networks: A survey. *Neurocomputing*, 531: 163-179 [DOI: 10.1016/j.neucom.2023.02.086].
- Zanatta L, Barchi F, Manoni S, Tolu S, Bartolini A and Acquaviva A. 2024. Exploring spiking neural networks for deep reinforcement learning in robotic tasks. *Scientific Reports*, 14(1) : 30648 [DOI: 10.1038/s41598-024-77779-8].
- Zeng Y, Zhao D, Zhao F, et al. 2023. BrainCog: A spiking neural network based, brain-inspired cognitive intelligence engine for brain-inspired ai and brain simulation. *Patterns*, 4(8) [DOI: 10.5281/zenodo.7955594].
- Zhang A, Niu Y, Gao Y, Li J and Li Y. 2022. Second-order information bottleneck based spiking neural networks for sEMG recognition. *Information Sciences*, 585: 543-558 [DOI: 10.1016/j.ins.2021.11.009].
- Zhang W, Wu S, Doiron B and Lee T S. 2019. A normative theory for causal inference and Bayes factor computation in neural circuits. *Advances in Neural Information Processing Systems*, 32: 3799 - 3808.
- Zhang Z H, Dong F M, Hu F, Wu Y R and Sun S F. 2022. Residual-based gated recurrent unit. *Acta Automatica Sinica*, 48(12) : 3067-3074 (张忠豪, 董方敏, 胡枫, 吴义熔, 孙水发. 2022. 基于残差的门控循环单元. *自动化学报*, 48(12) : 3067-3074) [DOI: 10.16383/j.aas.c190591]
- Zhao L, Huang Z, Ding J and Yu Z. 2022. TTFSFormer: A TTFS-based Lossless Conversion of Spiking Transformer. *Forty-second International Conference on Machine Learning*.
- Zheng Z, Wei J, Xu Y, Li C, Lu T, Guo Q, Ji X, Guo H, Wang G and Deng L. 2025. Modeling macroscopic brain dynamics with brain-inspired computing architecture. *Nature Communications*, 16(1) : 9424.
- Zhong H and Zhang T. 2023. A theoretical analysis of optimistic proximal policy optimization in linear Markov decision processes. *Advances in Neural Information Processing Systems*, 36. (NeurIPS 2023)
- Zhou C, Yu L, Zhou Z, Wang S, Li J and Pan G. 2023. Spikingformer: Spike-driven residual learning for transformer-based spiking neural network [EB/OL]. [2023-04-24]. <https://arxiv.org/abs/2304.11954>
- Zhou Z, Zhu Y, He C, Wang S, Li J and Pan G. 2022. Spikformer: When spiking neural network meets transformer [EB/OL]. [2022-09-30]. <https://arxiv.org/abs/2209.15425>
- Zhu R J, Zhao Q, Li G and Eshraghian J K. 2023. SpikeGPT: Generative pre-trained language model with spiking neural networks [EB/OL]. [2023-02-27]. <https://arxiv.org/abs/2302.13939>.
- Zhu Y, Mao H, Zhu Y, Li X, Zhang J and Wang Q. 2023. CMOS-compatible neuromorphic devices for neuromorphic perception and computing: a review. *International Journal of Extreme Manufacturing*, 5(4) : 042010 [DOI: 10.1088/2631-7990/acd6c6].
- Zhuang Z J, Fang Y, Lei J C, Wang H and Liu S. 2020. Research on spiking neural network based on STDP rules (庄祖江, 房玉, 雷建超, 等. 2020. 基于STDP规则的脉冲神经网络研究. *计算机工程*, 46(9) : 83-88+94) [DOI: 10.19678/j.issn.1000-3428.0055311].

## 作者简介

杨双鸣,男,特聘研究员,研究方向为类脑计算与具身智能。

E-mail: yangshuangming@tju.edu.cn

陈霸东,通信作者,男,教授,主要研究方向为脑机接口、类脑计算、具身智能。E-mail: chenbd@mail.xjtu.edu.cn

申江荣,女,特聘研究员,主要研究方向为类脑计算。E-mail: jrshen@zju.edu.cn

李尤君,男,副教授,主要研究方向为类脑智能和神经工程。E-mail: liyoujun1@mail.xjtu.edu.cn

黄子罡,男,教授,主要研究方向为脑科学与信号处理技术。E-mail: huangzg@xjtu.edu.cn