

《生物结构启发基本网络算子助力类脑智能研究》

张笃振¹, 程翔¹, 王岩松², 张新贺¹, 张铁林^{1*}, 杜久林^{2*}, 徐波^{1*}

1. 中国科学院自动化研究所 北京 100190

2. 中国科学院神经所 上海 200031

摘要: 类脑智能研究深入交叉脑科学和人工智能, 旨在从脑科学中汲取结构、功能、机制等方面的灵感, 用以启发人工智能软硬件研究。本文聚焦生物结构, 重点总结神经侧向交互、生物彩票网络假设、Motif 网络元结构抽提等方法, 挖掘基本网络算子并应用到类脑软件算法和硬件架构的结构设计中。未来随着多尺度和多类型生物网络组图谱的绘制, 越来越多生物结构启发的网络基本算子可以被抽提出来并持续推动类脑智能的创新发展。

关键词: 生物结构; 网络算子; 类脑智能; 人工神经网络;

中图分类号: TP183

文献标志码: A

文章编号: 2096-5036(YYYY)NN-PPPP-CC

DOI: 10.16453/j.cnki.ISSN2096-5036.YYYY.NN.XXX

0 引言

随着观测技术手段的突破, 以揭示生物智能本质为目标的脑网络组图谱研究正迎来快速发展期。从只有 302 个神经元的线虫网络, 到 10 万神经元的斑马鱼网络, 再到 7100 万神经元的小鼠脑网络, 处于生物遗传演化不同阶段的模式动物脑网络组图谱, 正在从机制、机理、功能等不同层面启发类脑智能研究, 为新算法、新网络框架、新硬件架构设计等提供丰富灵感。如图 1 所示, 本文将首先阐述三大类生物网络结构发现方法, 包括神经侧向交互分析、生物彩票网络假设以及 Motif 网络元结构提取等。然后重点介绍生物结构启发得到的多种类脑网络基本算子, 并阐述其在可解释、低能耗、鲁棒性等方面的优势。最后对生物结构启发的网络算子如何在软硬件方面助力类脑智能研究进行展望。

收稿日期: 2022-12-04;

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

基金项目: 科技创新 2030 新一代人工智能项目 (2020AAA0104305), 中科院先导专项 A

(XDA27010000)、先导专项 B (XDB32070000)、上海市市级科技重大专项、青促会等资助。

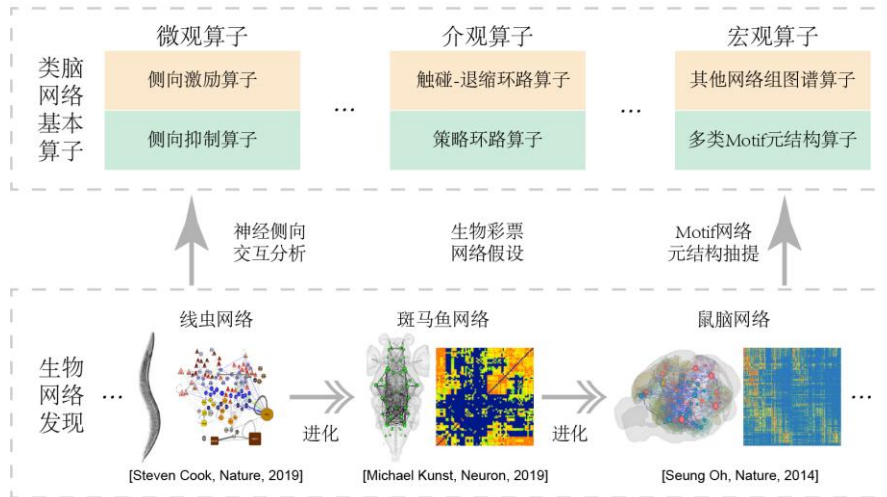


图 1 生物结构启发基本网络算子流程，含线虫^[1]、斑马鱼^[2]、鼠脑^[3]等结构。

1 神经侧向交互分析

生物神经系统中广泛存在着临近神经元间的相互抑制和相互激励。其中，侧向抑制最初为解释马赫带效应^[4]而提出，描述了在明暗变化边界上，人们会在亮处看到一条更亮的光带而在暗区看到一条更暗的线条。侧向作用最早在实验中被证实则要追溯到 H. K. Hartline 有关蜚视觉系统的研究^[5]。蜚数量众多的复眼为侧向作用提供了合适的研究对象，与此相关的工作也于 1969 年获得了诺贝尔医学或生理学奖。此后，侧向抑制更是在人、猫等多种动物的视觉、听觉、嗅觉等不同感觉系统中被证实^{[6][7][8]}。这些研究表明，侧向抑制可以整合或突出感知目标的边界，增加感觉刺激的对比度和分辨率；还可以作为一个高通滤波器去抑制低强度的背景噪声，有效支持生物高效鲁棒的感知觉能力。Wanner 则通过对斑马鱼幼鱼嗅球进行局部密集电镜重构，揭示了侧抑制机制可以实现对显著信号的衰减以及对非显著信号相对性增强，使鱼可以同时感受到更多而不是个别显著气味^{[9][10]}。与抑制作用方向相反的侧向激励作用研究则较少，但也在如嗅球等神经系统的组成部分中被发现^{[11][12]}并起到协调神经元活动的作用。

在类脑模型的设计中，有许多工作尝试构建侧向抑制/激励算子，利用其计算特性实现特定的功能。Alex Krizhevsky 于 2012 年提出的 Alexnet 中以局部响应归一化 (LRN) 为侧向抑制算子^[13]，但由于没有展现出较大的实际作用，后被批归一化 (BN) 取代。Diehl 和 Cook^[14]使用强度固定的侧向抑制算子来构建网络中的“赢者通吃”机制，帮助网络形成不同的感受野并提升认知任务性能。动态神经场^{[15][16]}同时应用侧向抑制算子的抗干扰能力和侧向激励算子的活动协调能力，描述了彼此距离很近的神经元间有一定的相互激励作用，而彼此距离较远的神经元间表现出一定的抑制作用。基于动态神经场运动物体的位置追踪算法不仅

可以克服应用场景中噪声幅度的剧烈变化,还可以长时记忆在追踪目标短暂停留或是被短暂遮挡时的目标位置。Cheng 等在 2022 年提出的 LISNN^[17]也在将侧向抑制算子引入网络的同时加入了侧向激励算子,并服务于分类识别任务。侧向作用算子被限定在网络编码信息的卷积层中,每个编码信息的神经元只会受到处于同一层领域内神经元的影响,网络算子影响的强度与方向则是通过梯度反向传播算法统一优化学习。这种侧向作用算子的引入,除了使得网络展现出更好的识别能力外,还让网络在面对噪声干扰时表现出更低性能损失。

2 生物彩票网络

2.1 彩票网络假设

人类专家通过手工设计多种基本网络算子,很好地支持了人工神经网络的广泛应用。然而,随着网络规模和复杂性的快速提升,传统的经验主义网络设计方式不能很好的解决模型泛化性、灵活性、低能耗等诸多问题。生物神经网络相对现有的深度神经网络,在执行相同任务时所需要的能耗往往要低几个数量级^[18]。如何借助生物结构知识来稀疏化深度神经网络显得尤为重要和急迫。彩票网络假设的概念应运而生,描述了对于一个随机初始化的密集连接网络,其内部存在一个稀疏连接子网络,使得独立训练的子网络可以达到超越独立训练原始网络的综合能力,且需要耗费的训练步数或训练能耗更少^{[19][20][21][22][23]}。通过遗传演化的观点也可以更直观的理解彩票网络假设。历经数代的自然演化,生物神经网络通过环境约束综合权衡能耗和性能,并最终产生一系列功能特异的稀疏子网络,这些子网络从布线经济原理的角度来看^[24],仿佛“彩票中奖”到了一个接近全局最优的结构布线图,展现出多尺度、多层面的计算优势,可以极大的启发和促进现有人工神经网络的发展。线虫脑网络组联结图谱由于结构相对简单、研究时间长,一些精细的线虫子网络结构已经通过彩票网络假设被广泛的应用于不同认知决策和控制类任务^{[25][26][27][28]}。

2.2 线虫网络结构

早在 1986 年, John G. White 等人^[24]就通过电子显微镜实现了对线虫神经联结环路的部分分析和部分重构,期待通过精细的突触神经联接图谱破解线虫结构-功能的对应关系。在此之后, Steven J. Cook 等人发现线虫的前馈-环状结构,可以表达出高达 97%的稀疏度^[1],并可以从中抽提出信息感知、整合、决策的三层模块化残差网络^[29]。这些模块化的自然设计就是一种典型的彩票网络,对神经科学和人工智能研究都具有重要的启发意义。

触碰-退缩环路 (Tap-withdrawal Circuit) 源于线虫,描述了一种贯穿感觉输入、信息整合、运动输出全过程的特殊生物结构,可以被视为一类经典的网络

算子^[30]。该算子具有详细的连接参数，可以直接用于环境感知-运动控制类的典型人工智能应用^[31]。如图 2A 所示，触碰-退缩环路包括四种感觉神经元类型，如 PVD、PLM、AVM、ALM 等，用于不同方面的前后触摸传感。同时包括五种中间神经元类型，如 AVD、PVC、AVA、AVB、DVA 等，可以通过兴奋性/抑制性突触的反复循环连接来建立复杂投射联系。环路含有两类输出神经元，分别为前向运动神经元 FWD 和后向运动神经元 REV。

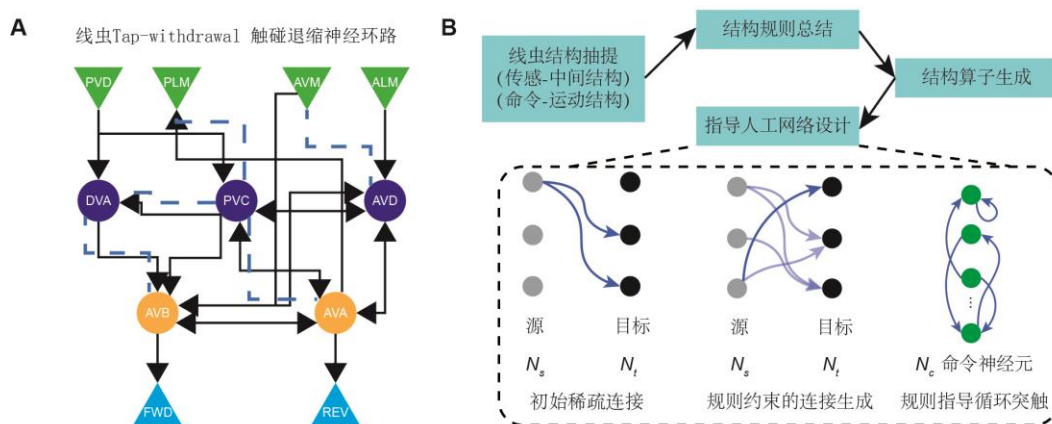


图 2 线虫彩票网络假设技术提取的网络算子：A, 线虫 Tap-withdrawal 触碰退缩环路结构^[33]；B, 线虫规则生成的新算子指导神经策略网络的结构设计^[35]。

2.3 生物彩票网络应用

生物 Tap-withdrawal 触碰退缩环路提供了一类典型的彩票网络算子，可以支持相关的连续运动控制类任务，如控制智能车巡线或导航^[32]，具有可控、可解释性、低能耗、自适应性等优势。Ramin 等人^[33]首先模拟了生物 Tap-withdrawal 环路模型，包括动力学神经元和可塑性突触，然后直接复制该环路构建强化学习框架下的人工策略网络，通过搜索优化的方式更新网络参数，可以只利用很少的神经元就能实现机器人的有效连续控制，并可以通过内部工作状态解释不同外部决策行为，网络整体表现出可观的稀疏性和运算性能。与之类似，受线虫网络结构启发的新型控制策略网络，被用于智能车的车道保持运动控制和导航任务^[35]，该网络可以直接接入摄像头采集画面，并支持端对端的网络学习，具有噪声不敏感、可解释性强的优势。

针对彩票网络算子归纳总结连接模式规则，并依据规则大量生成符合生物约束的新型网络算子，是彩票网络应用的另一种主流方式^[35]。如图 2B 所示，通过线虫图谱可以总结出感知层、中间神经层、命令层和运动层等神经元数量和连接模式，然后总结相邻层之间神经元特异性的突触连接概率，并在命令层插入循环连接并确定突触极性概率。按照该机制生成的新型网络算子，可以指导强化学习

策略网络的结构设计，并展示出稀疏性高、网络规模小(只有 19 个控制神经元和 253 个突触连接)、计算代价低等优势。特异性的中间环路连接也为算法提供了卓越的鲁棒计算能力，能处理不确定或不完整的信息输入，且保持性能不会明显下降。这类生物知识嵌入的人工神经网络，最大的优势还在于提升了网络的可解释性，可以通过网络内部投射解释复杂的外部因果关系。

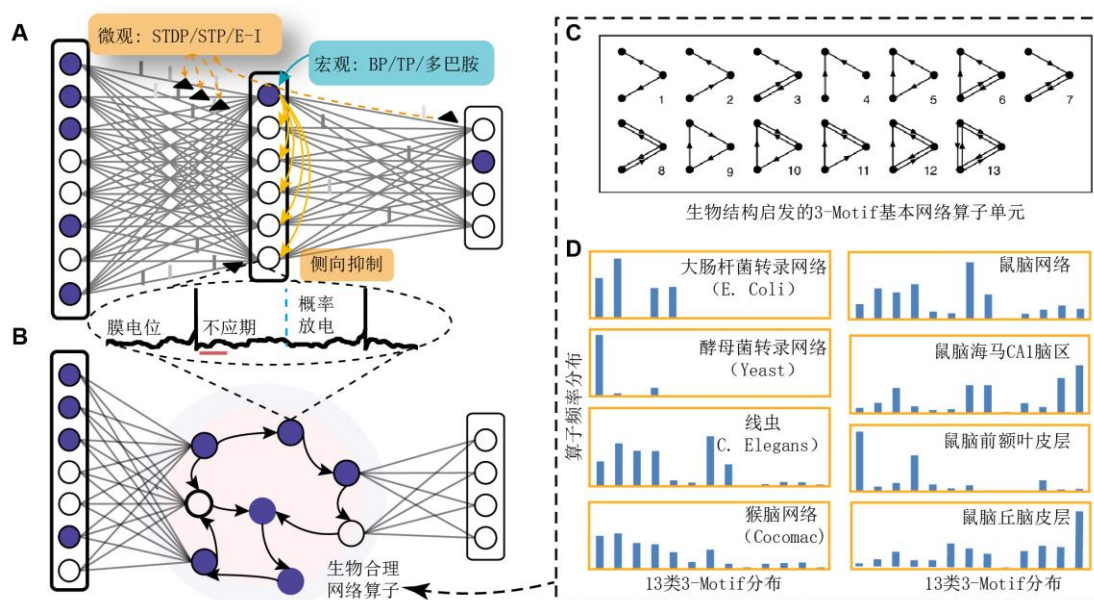


图 3 基于三点 Motif 的基本网络算子指导类脑智能网络的结构设计。

3 Motif 网络元结构抽提

如何通过生物大脑图谱抽提关键认知功能相关的基本网络算子，是高效启发类脑智能算法的关键。已有的对 Motif 最小网络结构单元的研究，提供了一种基于固定 N 节点数目 (N-Motif) 的最小网络单元统计方法。该方法将多尺度的网络拓扑关系总结为固定数目的基本 Motif 类型，由于不受网络规模的影响，现已广泛的应用于多类生物网络组学的分析中。类脑智能算法通过嵌入 N-Motif 基本结构单元，可以快速的将生物的结构先验知识特征迁移、泛化到人工神经网络中，辅助神经网络在多尺度动力学的模拟仿真方面发挥优势，并在小样本、稳定性、泛化性等方面取得突破。如图 3A, B 所示，描述了两类经典的人工神经网络模型。一类是以简单前馈结构为主的层次化神经网络模型，具有全连接前馈、卷积前馈、跨层前馈等结构特征，主要用于拟合输入-输出信息的空间映射。这类人工神经网络含有较少的动力学信息，如一些脉冲神经网络模型虽然加入了动力学的神经元节点，但是由于采用经典的积分-放电-漏电神经元模型，只在神经元级别具备较为简单的动力学特性。另一类是具有复杂环路的循环人工神经网络，主要用于对生物多尺度的动力学现象进行仿真模拟，并可以用于高阶动力学复杂系统相关

的应用任务。同样以脉冲神经网络为例，这类网络将同时具有神经元尺度和结构尺度的复杂动力学，支持的认知功能也十分丰富，因此更合适作为典型的计算模型支持 Motif 基本网络算子研究。

以三点 Motif 网络结构为例，在节点类型一致的情况下，共含有 13 大类基本网络算子(图 3C)。已有研究已经支持多类模式动物的三点 Motif 结构分布，如大肠杆菌、酵母菌、线虫、鼠脑、猴脑等(图 3D)。可以发现这些不同模式动物的 Motif 分布之间的相似性略大于异质性，符合遗传演化约束下生物结构的渐进优化特征。有趣的是，以鼠脑为例，如海马、前额叶、丘脑等特定功能脑区，其内的 Motif 结构分布相对不同模式动物脑的 Motif 分布的差异要更大。这个结果凸显了不同脑区功能细分之后，相应的网络组学也发生了根本性的变化。Motif 作为一种通用生物元结构的统计工具，可以很好的表示全脑、精细脑区等多尺度网络特征。

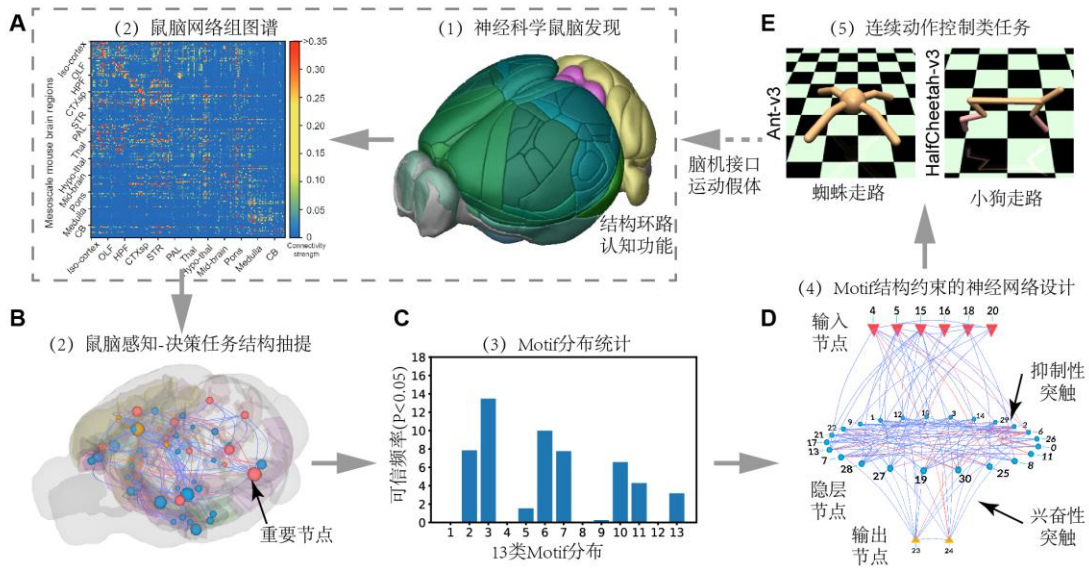


图 4 标准鼠脑结构 Motif 抽提及在富含动力学的连续控制类任务上应用示范。

一个典型的生物结构抽提及类脑模型验证流程如图 4 所示。以 Allen 脑研究院提供的小鼠脑为例^[3]，含有 213 个脑区，描述了介观尺度脑区之间的复杂连接模式(图 4A)。通过对参与特定认知功能相关脑区的投射环路进行抽提，可以总结出关键生物结构，如图 4B 所示，然后经过 Motif 的全脑及脑区内不同尺度子环路的统计分析，可以得到不同认知功能相关的关键 Motif 元结构。进一步经过和随机生成网络的对比分析，将可信度较高(P 值远小于 0.05)的 Motif 结构分布保留，作为标准 Motif 网络算子，来约束神经网络的结构设计(图 4C)。约束方法可以采用结构复制、Motif 分布一致性规约、损失函数约束等多种方式将 Motif 环路的先验知识嵌入到神经网络中(图 4D)。

这类嵌入了生物结构先验信息的神经网络将在连续控制类任务上发挥重要作用。已有的知识嵌入类模型研究发现，生物启发的信息编码、结构设计、神经元动力学等，可以在动态强化学习任务中发挥关键作用^{[36][37][38]}。考虑到这类任务和人类生存环境高度一致，如蜘蛛走路、小狗爬行等（图 4E），可以预见，嵌入复杂结构 Motif 动力学的神经网络将天然适配此类任务。此外，随着进一步高通量侵入式脑机接口的快速发展，连续动作类的机器人控制任务还可以和脑神经信号解码连接起来，一方面作为运动假体实现脑信息解码控制机械臂外设，另一方面可以通过动物生存类任务对结构需求进行反向分析，探索脑内复杂动力学功能和结构方面的特异性。此外，不同 Motif 网络算子也可以通过进一步复杂化神经元类型、可塑性模式等来实现更精细的拓扑结构分类，助力实现脑图谱启发的精细脑模拟研究。

4 讨论与展望

当前类脑智能研究已经借鉴了微观、介观、宏观等多尺度的生物神经系统结构发现，且在人工神经网络模型中一定程度上复现了脑的多种结构特征并取得了特定场景下的应用优势。然而相较于真正的生物脑智能，人工智能模型在小样本、鲁棒性、泛化性、灵活性、可解释性等多方面仍然面临挑战，需要继续通过生物结构启发的方式来寻找更多高效的基本网络算子，对软件通用算法、硬件架构设计等提供新思路。

4.1 全脑结构助力通用人工智能软件算法设计

目前，人工神经网络模型主要应用于专用人工智能领域。随着图神经网络、深度强化学习网络、深度预训练网络等多类新型算法模型的提出，一定程度上缓解了深度学习模型只能应用于特定任务的窘境。然而，研究发现，具有人类突触数量规模的深度神经网络（如深度预训练模型已达百万亿级参数），其能量消耗、通用能力等都远不如同级别的生物脑智能系统。这种功能上的单调性表明，当下人工神经网络模型还仍然有很大的结构优化空间。想要更高效地将数量日趋庞大的人工神经元组织成一个有机的网络整体并展现出通用性，需要更深入的借鉴全脑层次化、分区化的解剖结构和组织方式。

从全局出发借鉴生物脑组织结构，需要提前构建生物神经系统的“电路图纸”。这种神经线路图被称为脑结构联接组^{[39][40]}，相关工作在线虫、果蝇、斑马鱼、小鼠乃至非人灵长类和人类中都已广泛开展。在线虫中，基于体电子显微镜结构重建技术，研究者们获得了完整 302 个神经元间的连接关系，并由此启发了诸多类脑模型。可以预见，随着对更复杂结构模式动物脑图谱的深入研究，将可以从多尺度、多功能、多视角启发更多的基本网络算子。斑马鱼作为一类典型模式动物，

具有神经元数目适宜（约 10 万神经元）、活体透明、支持大规模结构-功能映射分析等优势。在斑马鱼脑图谱研究方面，Baier 等提出通过稀疏荧光标记可以建立斑马鱼的介观投射图谱^[2]，中科院脑智卓越中心的杜久林、杜旭飞团队则进一步建立了具有细胞类型遗传标记的斑马鱼全脑介观联接图谱。这一图谱包含斑马鱼全脑单神经元形态投射信息和神经元类型信息，可以支持对全脑、各脑区内、神经元群体间节点连接规律的提取，将揭示斑马鱼的神经联接规律和层级组织框架，并启发相对线虫网络更复杂的布线结构。一种高清荧光显微光学切片断层成像技术（HD-fMOST）被提出，可以将全脑光学成像从高分辨率提升到更清晰度的新标准^[41]，支持微米级别的快速鼠脑全脑信息采集，为神经元形态分类及微观网络算子抽提奠定了基础。此外，一些小鼠脑图谱^[42]、猴脑细胞类型图谱、人类脑联接图谱^[43]等也将会是深入探究生物结构机制的有力工具。一系列全脑图谱将在类脑架构和演化优化的视角下为通用人工智能模型提供网络框架设计参考。

4.2 动态基本网络算子助力终身学习

当下的人工神经网络模型在部署到实际应用场景时，往往会无法适应持续变化的工作环境。这主要是由于已经完成训练的模型很难再针对新知识进行有效的二次学习，亦即终身学习能力的缺乏。除此之外，在学习新知识的过程中，还有可能会破坏存储于连接结构中的旧知识，形成“灾难性遗忘”现象^[44]。已有的人工神经网络学习方法在训练过程中需要强制要求累积未来应用中可能遇到的“几乎所有”情形，通过严格控制训练样本的质量和数量，并经过海量样本的重复训练使得模型在训练阶段就可以习得广泛的基础知识，以缓解实际测试应用阶段的二次学习窘境。然而，由此带来的存储成本和计算代价高昂。与人工神经网络严格分离训练和测试并最终形成静态网络不同，生物的神经连接具有很强的动态可塑性，可以启发我们构建动态而非静态的基本网络算子。Vladislav Susoy 等以线虫为例，强调子网络和功能的对应关系会随着环境而变化，并存在重组与复用的现象^[27]。Daniel Witvliet 等^[28]通过对基因组相同但年龄不同线虫的神经连接进行对比，强调生物基本结构的稳定性-可塑性平衡。通过对线虫神经网络结构的自适应机制进行建模，有望赋予人工网络模型低成本、高成效的自适应学习能力，进而提升模型在动态变化场景中的实际应用价值。

4.3 基本网络算子助力类脑硬件设计

类脑硬件研究的目的是通过模仿生物编码、结构等信息处理优势，采用存算一体化的方式最终突破传统冯·诺依曼体系约束下的存储墙、能耗墙等问题。当前的类脑硬件研究主要聚焦于对微观尺度神经元信息处理模式的借鉴。虽然介观网络结构尺度的启发相对较少，许多神经科学家和类脑硬件从业人员却对这一研

究方向表现出极大兴趣。一方面，忆阻器等具有“可塑性”的电路器件在类脑硬件中逐步扩展应用，已经为进一步引入网络算子提供了适宜的研究土壤。另一方面，随着类脑硬件中神经元数量的持续增加，如何高效合理地组织起海量神经元的连接模式，使其成为复杂、灵活的层次化结构，已经逐渐成为一个极具挑战的热点研究方向。Moritz Helmstaedter^[45]强调了皮层的分层结构对类脑计算设备的启发作用，并认为类脑计算设备的研发不仅将对人工智能的发展有重大意义，还将对进一步分析、认识、理解脑的智能本质有重要作用。与之相似，Larry F. Abbott 也明确指出，现今的超级计算机在空间和能量上耗费巨大，却难以复制小鼠级别的智能水平^[46]，因此人工智能研究需要继续向神经科学学习生物组分复杂性以及平行信息处理机制，而基于连接组学的高效计算机蓝本将可以加速这一研究进程。

5 总结

本文通过介绍神经侧向交互、生物彩票网络假设、Motif 网络元结构抽提等方法，重点对线虫、斑马鱼、鼠脑等相关模式动物的脑网络组图谱分析，得到生物结构启发的基本网络算子，在可解释、低能耗、强鲁棒、高性能等方面发挥优势。随着脑科学的进一步发展以及多尺度模式动物脑联结图谱的成功绘制，未来将有更多的新型网络算子被发现并进一步的助力类脑智能研究。

参考文献

- [1] Cook S J, Jarrell T A, Brittin C A, et al. Whole-animal connectomes of both *Caenorhabditis elegans* sexes[J]. *Nature*, 2019, 571(7763): 63-71.
- [2] Kunst M, Laurell E, Mokayes N, et al. A cellular-resolution atlas of the larval zebrafish brain[J]. *Neuron*, 2019, 103(1): 21-38. e5.
- [3] Oh, S.W., et al., A mesoscale connectome of the mouse brain. *Nature*, 2014. 508(7495): p. 207-14.
- [4] Fiorentini A. Mach band phenomena[M]. *Visual psychophysics*. Springer, Berlin, Heidelberg, 1972: 188-201.
- [5] Hartline H K, Wagner H G, Ratliff F. Inhibition in the eye of *Limulus*[J]. *The Journal of general physiology*, 1956, 39(5): 651-673.
- [6] Blakemore C, Carpenter R H S, Georgeson M A. Lateral inhibition between orientation detectors in the human visual system[J]. *Nature*, 1970, 228(5266): 37-39.
- [7] Urban N N. Lateral inhibition in the olfactory bulb and in olfaction[J]. *Physiology & behavior*, 2002, 77(4-5): 607-612.
- [8] Singer W, Creutzfeldt O D. Reciprocal lateral inhibition of on-and off-center neurones in the lateral geniculate body of the cat[J]. *Experimental Brain Research*, 1970, 10(3): 311-330.
- [9] Wanner A A, Genoud C, Masudi T, et al. Dense EM-based reconstruction of the interglomerular projectome in the zebrafish olfactory bulb[J]. *Nature neuroscience*, 2016, 19(6): 816-825.

- [10] Friedrich R W, Wanner A A. Dense circuit reconstruction to understand neuronal computation: focus on zebrafish[J]. *Annual Review of Neuroscience*, 2021, 44: 275-293.
- [11] Christie J M, Westbrook G L. Lateral excitation within the olfactory bulb[J]. *Journal of Neuroscience*, 2006, 26(8): 2269-2277.
- [12] Nowotny T, Rabinovich M I, Huerta R, et al. Decoding temporal information through slow lateral excitation in the olfactory system of insects[J]. *Journal of computational neuroscience*, 2003, 15(2): 271-281.
- [13] Hinton G E, Srivastava N, Krizhevsky A, et al. Improving neural networks by preventing co-adaptation of feature detectors[J]. *arXiv preprint arXiv:1207.0580*, 2012.
- [14] Diehl P U, Cook M. Unsupervised learning of digit recognition using spike-timing-dependent plasticity[J]. *Frontiers in computational neuroscience*, 2015, 9: 99.
- [15] Nguyen H T, Nguyen T P, Vu T N, et al. Outward influence and cascade size estimation in billion-scale networks[J]. *Proceedings of the ACM on Measurement and Analysis of Computing Systems*, 2017, 1(1): 1-30.
- [16] Martel J N P, Sandamirskaya Y. A neuromorphic approach for tracking using dynamic neural fields on a programmable vision-chip[C]//*Proceedings of the 10th International Conference on Distributed Smart Camera*. 2016: 148-154.
- [17] Cheng X, Hao Y, Xu J, et al. LISNN: Improving spiking neural networks with lateral interactions for robust object recognition[C]//*IJCAI*. 2020: 1519-1525.
- [18] Cox D D, Dean T. Neural networks and neuroscience-inspired computer vision[J]. *Current Biology*, 2014, 24(18): R921-R929.
- [19] Frankle J, Carbin M. The Lottery Ticket Hypothesis: Finding Sparse, Trainable Neural Networks[C]//*International Conference on Learning Representations*. 2018.
- [20] Malach E, Yehudai G, Shalev-Schwartz S, et al. Proving the lottery ticket hypothesis: Pruning is all you need[C]//*International Conference on Machine Learning*. PMLR, 2020: 6682-6691.
- [21] Frankle J, Dziugaite G K, Roy D, et al. Linear mode connectivity and the lottery ticket hypothesis[C]//*International Conference on Machine Learning*. PMLR, 2020: 3259-3269.
- [22] Zhou H, Lan J, Liu R, et al. Deconstructing lottery tickets: Zeros, signs, and the supermask[J]. *Advances in neural information processing systems*, 2019, 32.
- [23] Wortsman M, Ramanujan V, Liu R, et al. Supermasks in superposition[J]. *Advances in Neural Information Processing Systems*, 2020, 33: 15173-15184.
- [24] White J G, Southgate E, Thomson J N, et al. The structure of the nervous system of the nematode *Caenorhabditis elegans*: the mind of a worm[J]. *Phil. Trans. R. Soc. Lond*, 1986, 314(1): 340.
- [25] Chalfie M, Sulston J E, White J G, et al. The neural circuit for touch sensitivity in *Caenorhabditis elegans*[J]. *Journal of Neuroscience*, 1985, 5(4): 956-964.
- [26] Islam M A, Wang Q, Hasani R M, et al. Probabilistic reachability analysis of the tap withdrawal circuit in *caenorhabditis elegans*[C]//*2016 IEEE International High Level Design Validation and Test Workshop (HLDVT)*. IEEE, 2016: 170-177.
- [27] Susoy V, Hung W, Witvliet D, et al. Natural sensory context drives diverse brain-wide activity during *C. elegans* mating[J]. *Cell*, 2021, 184(20): 5122-5137. e17.

- [28] Witvliet D, Mulcahy B, Mitchell J K, et al. Connectomes across development reveal principles of brain maturation[J]. *Nature*, 2021, 596(7871): 257-261.
- [29] Brittin C A, Cook S J, Hall D H, et al. A multi-scale brain map derived from whole-brain volumetric reconstructions[J]. *Nature*, 2021, 591(7848): 105-110.
- [30] Rankin C H, Beck C D O, Chiba C M. *Caenorhabditis elegans*: a new model system for the study of learning and memory[J]. *Behavioural brain research*, 1990, 37(1): 89-92.
- [31] Wicks S R, Roehrig C J, Rankin C H. A dynamic network simulation of the nematode tap withdrawal circuit: predictions concerning synaptic function using behavioral criteria[J]. *Journal of Neuroscience*, 1996, 16(12): 4017-4031.
- [32] Singh S P, Sutton R S. Reinforcement learning with replacing eligibility traces[J]. *Machine learning*, 1996, 22(1): 123-158.
- [33] Hasani R, Lechner M, Amini A, et al. A natural lottery ticket winner: Reinforcement learning with ordinary neural circuits[C]//International Conference on Machine Learning. PMLR, 2020: 4082-4093.
- [34] Hasani R M, Lechner M, Amini A, et al. Liquid time-constant recurrent neural networks as universal approximators[J]. *arXiv preprint arXiv:1811.00321*, 2018.
- [35] Lechner M, Hasani R, Amini A, et al. Neural circuit policies enabling auditable autonomy[J]. *Nature Machine Intelligence*, 2020, 2(10): 642-652.
- [36] Zhang, D., et al. Multiscale Dynamic Coding improved Spiking Actor Network for Reinforcement Learning. in *Thirty-Sixth AAAI Conference on Artificial Intelligence*. 2022. Virtual conference.
- [37] Han, X., K. Jia, and T. Zhang. Mouse-Brain Topology improved Evolutionary Neural Network for Efficient Reinforcement Learning. in *International Conference on Intelligence Science (ICIS 2022)*. 2022.
- [38] Zhang D, Zhang T, Jia S, et al. Population-coding and dynamic-neurons improved spiking actor network for reinforcement learning[J]. *arXiv preprint arXiv:2106.07854*, 2021.
- [39] Hagmann P. *From diffusion MRI to brain connectomics*[R]. EPFL, 2005.
- [40] Sporns O, Tononi G, Kötter R. The human connectome: a structural description of the human brain[J]. *PLoS computational biology*, 2005, 1(4): e42.
- [41] Zhong Q, Li A, Jin R, et al. High-definition imaging using line-illumination modulation microscopy[J]. *Nature methods*, 2021, 18(3): 309-315.
- [42] Wang Q, Ding S L, Li Y, et al. The Allen mouse brain common coordinate framework: a 3D reference atlas[J]. *Cell*, 2020, 181(4): 936-953. e20.
- [43] EC G M F C T S R, Hacker C D, Harwell J, Yacoub E, Ugurbil K, Andersson J, Beckmann CF, Jenkinson M et al[J]. A multi-modal parcellation of human cerebral cortex *Nature*, 2016, 536(7615): 171.
- [44] Parisi G I, Kemker R, Part J L, et al. Continual lifelong learning with neural networks: A review[J]. *Neural Networks*, 2019, 113: 54-71.
- [45] Bitzenhofer S H, Sieben K, Siebert K D, et al. Oscillatory activity in developing prefrontal networks results from theta-gamma-modulated synaptic inputs[J]. *Cell reports*, 2015, 11(3): 486-497.

[46] Abbott L F, Bock D D, Callaway E M, et al. The mind of a mouse[J]. Cell, 2020, 182(6): 1372-1376.