

脑网络与脑-机接口

李煜 邹宛彤 陈勋 刘爱萍

中国科学技术大学信息科学技术学院 合肥 230027

摘要 脑机接口 (Brain Computer Interface, BCI) 通过在脑与外部设备间建立直接的通信通道, 为探索神经机制、监测大脑状态及实现中枢神经系统功能的修复与增强提供了关键技术支持。传统BCI研究主要依赖从局部脑区提取的活动特征, 在解码的准确性与稳定性方面仍面临挑战。鉴于高级认知与行为源于大规模神经元集群间的动态交互而非孤立脑区活动, BCI研究日益关注解析脑网络的整体拓扑特性, 为突破其性能瓶颈带来了新机遇。为全面阐述脑网络分析对BCI技术的赋能价值并提供领域参考, 本综述系统梳理了其在BCI领域的核心应用与前沿进展。首先, 在机制理解层面, 揭示BCI学习与调控过程涉及大规模脑网络动态重组的神经可塑性, 而非仅局限于局部活动变化; 其次, 在状态解码层面, 既可提供先验知识以指导与优化解码模型设计, 也可作为表征整体拓扑结构的新颖特征, 显著提升解码性能; 随后, 在神经调控方面, 为BCI干预提供了更精准的靶点选择依据和效果评估指标, 促进了其在神经精神疾病诊疗中的应用效能。最后, 本文总结了当前脑网络BCI研究所面临的挑战, 包括虚假连接的辨识、个性化脑网络建模、解码性能瓶颈及实时计算需求, 并对未来方向进行了展望, 以推动该领域的发展。

关键词 脑-机接口; 脑网络; 神经可塑性; 解码; 神经调控

Brain Network and Brain-Computer Interface

Li Yu, Zou Wan-tong, Chen Xun, Liu Ai-ping

School of Information Science and Technology, University of Science and Technology of China, Hefei 230027, Anhui Province, China

Abstract: Brain Computer Interface (BCI) establishes a direct communication pathway between the brain and external devices, offering critical technological support for exploring neural mechanisms, monitoring brain states, and enabling restoration and enhancement of central nervous system functions. Traditional BCIs have largely relied on signal features extracted from localised brain activities and continue to face challenges in terms of decoding accuracy and stability. Given that higher-order cognition and behaviour emerge from dynamic interactions among large-scale neuronal ensembles—rather than isolated regional activity—BCI is increasingly focusing on analysing the global topological properties of brain networks. This shift presents new opportunities for overcoming performance bottlenecks. To comprehensively elucidate how brain network analysis can promote the development of BCIs and to provide field references, this review systematically surveyed the core applications and recent progress of brain network analysis in BCI. First, from a mechanistic perspective, brain network analysis reveals that BCI learning and modulation involve neuroplasticity characterised by large-scale network reorganisation, extending beyond mere changes in local activity. Second, for state decoding, brain network analysis can serve as either a priori knowledge to guide and optimise decoding models or as novel features to characterise the overall topological structure, thereby significantly enhancing performance. Third, in neuromodulation, brain network analysis provides a basis for more precise target selection and more comprehensive outcome assessment for BCI-based interventions, facilitating their therapeutic efficacy in neuropsychiatric disorders. Finally, this review summarises the current challenges in brain network-based BCI—including identification of spurious connections, individualised network modelling, decoding performance bottlenecks, and real-time computational demands—and offers an outlook on future directions to promote the development of this field.

Keywords: Brain-Computer Interface; Brain Network; Neuroplasticity; Decoding; Neuromodulation

引言

脑机接口 (Brain-Computer Interface, BCI) 是一项旨在变

*[基金项目] 国家重点研发计划项目 (2024YFE0201600); 国家自然科学基金项目 (W2432042, 62301344, 82272070)。

革人机交互方式的前沿科学技术，其核心是绕过外周神经与肌肉组织，直接在脑与外部设备之间建立信息交互通道^[1]。典型的BCI构成一个闭环控制系统：首先通过记录设备（如脑电图）捕捉大脑信号，经过预处理与特征提取后，由解码器将其转换为控制指令以驱动外部设备（如假肢或光标）；随后，外部设备的执行结果通过视觉等形式反馈给用户，激励其调节自身脑活动，从而形成闭环^[2]。这一技术不仅为探究大脑工作原理提供了独特工具，还有望监测大脑状态，并对中枢神经系统功能进行替代、修复、补充乃至增强^[3]，例如为脊髓损伤等重度运动障碍患者恢复沟通与运动能力。

BCI的早期探索始于20世纪70年代，Vidal首次尝试利用头皮脑电（Electroencephalogram, EEG）实现人脑与计算机的直接交互^[4]。随后，Farwell和Donchin引入对稀有刺激产生标志性电生理反应的P300电位为重度运动障碍患者开辟了交流的新途径^[5]。此外，其他范式如基于用户主动想象特定任务的运动想象（Motor Imagery, MI）以及利用外部视觉刺激诱发大脑特定响应的稳态视觉诱发电位（Steady-State Visual Evoked Potential, SSVEP）等，也成功应用于肌萎缩侧索硬化症患者的运动控制和视觉打字等场景^[6]。因此，BCI历来被视作神经康复与辅助技术的重要分支。然而，随着技术的演进，其应用边界正在迅速扩展，从单一的控制任务延伸到对复杂脑状态的监测与交互。无论是用于测谎的“脑指纹”技术、认知负荷与情绪状态的评估，还是在虚拟现实构建沉浸式神经交互，都充分彰显了BCI在人机交互、神经工效学及健康监护等领域的广阔前景^[7]。

尽管BCI的应用前景广泛，其性能尤其是解码的准确性与稳定性仍是制约其发展的核心瓶颈。传统BCI研究多从局部视角出发，仅关注少数脑区或电极的活动特征（如信号幅值、特定频段功率）。然而，这种聚焦于局部特征的方法，虽在特定任务中表现尚可，却极大地简化了大脑的复杂运作机制^[8]。事实上，高级认知与行为并非源于孤立的脑区，而是产生于大规模神经元集群间的动态交互。大脑在组织上遵循两大原则：功能分离（各区域功能特化）与功能整合（通过宏观网络连接），这两者是理解脑结构和功能的基础^[9]。因此，BCI研究日益关注解析大脑的整体拓扑结构，即脑网络（Brain Network）。脑网络将大脑概念化为一个由代表功能单元的“节点”与代表节点间信息流动的“边”构成的复杂系统。通过分析在执行任务时动态重组的功能连接，可以获得比局部特征更丰富、更稳定的信息^[10]，这为BCI提供了新的研究视角。

本文调研了脑网络在BCI方面的研究进展，使用关键

词“brain-computer interface” AND (“brain network” OR “brain connectivity”)在Web of Science、PubMed、Scopus和IEEE Xplore四个数据库中进行检索。如图1所示，近年来，将脑网络应用于BCI的文献呈快速增长趋势，凸显了该方向的研究潜力。鉴于此，本综述旨在系统梳理和概述脑网络在BCI领域中的应用，重点阐述其在网络构建方法、脑机制探索、脑状态解码与神经调控等方面的最新进展、核心挑战与未来展望。




图1 2025年8月前脑网络-BCI论文发表数量

Figure.1 Number of Brain Network-BCI Papers Published by August 2025

1 网络的构建和特征提取

脑网络的构建始于对两个基本要素的定义：节点（Nodes）与边（Edges）。节点的定义通常取决于所采用的神经成像技术。对于功能磁共振成像（functional Magnetic Resonance Imaging, fMRI）等基于体素的技术，通常依据脑图谱或聚类/分解算法将大脑划分为多个感兴趣区域，每个感兴趣区域视作一个节点。对于EEG等基于传感器的技术，每个传感器则常被直接定义为一个节点，以保留原始电极的空间拓扑信息^[8]。边的定义量化了节点间的连接关系，主要分为功能连接（Functional Connectivity）和效应连接（Effective Connectivity）。功能连接描述不同脑区活动信号在时间上的统计依赖性，其本质上是无向的。最常见的功能连接度量是皮尔逊相关系数，它量化了两个时间序列的线性相关程度：

$$PCC_{ij} = \frac{cov(x_i, x_j)}{\sigma_i \sigma_j} \quad (1)$$

其中，为两个信号的协方差，和分别为它们的标准差。此外，功能连接的测量方法还包括基于时域的偏相关、似然同步；基于信息论的互信息；以及基于频域的锁相值等^[11]。

与此相对，效应连接旨在揭示一个脑区对另一个脑区施加的因果性影响，因此是有向的。其计算方法可分为两类：一类

是模型驱动的方法，依赖于关于大脑结构和功能的先验假设，如结构方程模型和动态因果模型。例如，结构方程模型通过线性方程组来描述网络中各节点时间序列间的因果关系：

$$X_i = \sum_{j=1}^n A_{ij}X_j + \varepsilon_i \quad (2)$$

其中， A_{ij} 表示从节点 j 到节点 i 的效应连接强度。另一类是数据驱动的方法，它们从数据中推断因果关系，主要包括格兰杰因果、转移熵和部分有向相干性等^[11]。

由于大脑是一个动态非平稳系统，其功能网络会随时间演化。为捕捉这种时变特性，研究者常采用动态连接分析。最常用的方法是滑动窗口技术：将长时间序列分割为若干重叠的短片段，在每个时间窗口内计算一次连接矩阵，从而得到一系列随时间变化的脑网络状态。

在脑网络构建完成后，可从中提取丰富的特征用于下游任务。除直接使用连接强度作为特征外，更深入的分析则应用图论来量化网络的高阶拓扑属性。这些拓扑指标可分为局部和全局两个层次。

局部指标衡量单个节点在网络中的作用和重要性。例如，度（degree）描述了与一个节点直接相连的边的和，反映其连接广度：

$$k(i) = \sum_{j=1}^N A_{ij} \quad (3)$$

其他局部指标还包括介数中心性等。

全局指标从整体上描述网络的整合与分离特性以及信息传

输效率。例如，聚类系数（Clustering Coefficient）衡量了网络中节点的邻居之间相互连接的紧密程度：

$$C = \frac{1}{N} \sum_{i=1}^N \frac{2l_i}{k_i(k_i - 1)} \quad (4)$$

其中 l_i 是节点的邻居之间的连接数，是节点的度。其他重要的全局指标还包括全局效率和小世界属性等^[8, 12]。

2 脑网络在BCI中的应用

脑网络在BCI中的应用主要体现在三个相互关联且逐层递进的方面（图2）：首先，通过分析BCI任务中大脑网络的重塑过程，从全局视角揭示BCI诱导的脑网络可塑性神经机制；其次，基于对机制的理解，开发以功能连接和网络拓扑属性为核心的新型解码范式，这些多变量、高阶特征能够更鲁棒、更精准地表征用户意图，提升BCI性能；最终，脑网络为BCI神经反馈与干预确定精准的调控靶点，并通过引导用户主动调节特定网络的状态，促进神经功能的修复与增强。下面将围绕这三个核心方面机制探索、状态解码与神经调控系统阐述脑网络如何为BCI技术赋能。

BCI训练的生理学基础是神经可塑性。在这一过程中，用户通过反复尝试与实时反馈，逐步学会主动、稳定地产生可被BCI系统识别的特定脑活动模式。脑网络研究为此提供了新的全局视角，揭示BCI学习并非仅涉及孤立脑区的活动改变，而是涉及多个大规模脑网络动态重组与协同优化的复杂过程。

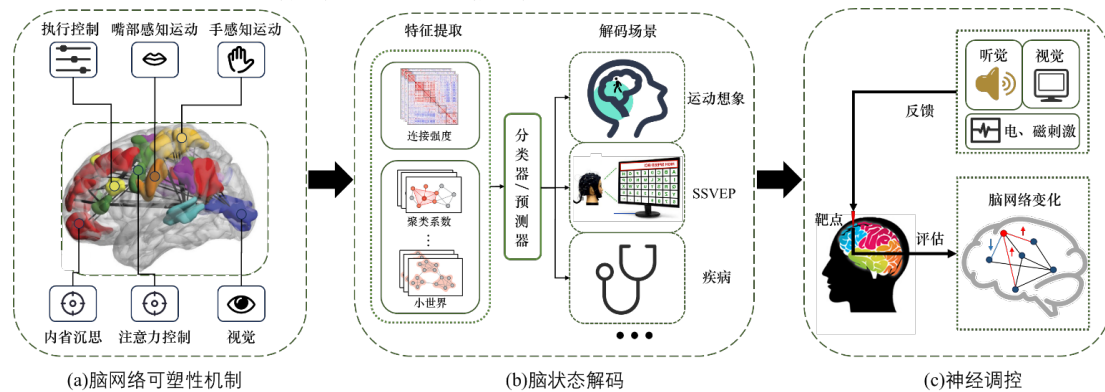


图2 脑网络在脑-机接口中的应用

Figure.2 Application of Brain Networks in Brain-Computer Interfaces

2.1 理解BCI中脑网络的可塑性机制

BCI训练的生理学基础是神经可塑性。在这一过程中，用

户通过反复尝试与实时反馈，逐步学会主动、稳定地产生可被BCI系统识别的特定脑活动模式。脑网络研究为此提供了新的

全局视角,揭示BCI学习并非仅涉及孤立脑区的活动改变,而是涉及多个大规模脑网络动态重组与协同优化的复杂过程。

运动BCI(如典型的MI)是运动功能恢复的经典范式。执行MI任务时,大脑多个区域被激活并通过复杂交互协调想象中的运动。这种神经协同作用表现为脑电信号(尤其是mu/beta节律)的同步振荡,其功能连接模式的改变不仅局限于感觉运动皮层,还涉及前运动区、辅助运动区及前额叶皮层等区域^[2,8,13]。这种网络层面的变化体现在两个时间尺度上:任务执行中的短期动态调整和技能学习中的长期功能重塑。短期内,大脑网络经历快速的功能重组:与实际运动时辅助运动区作为核心枢纽不同,MI的核心枢纽常转移至前运动区,以整合感觉运动与空间规划信息^[14];同时,网络拓扑在任务准备阶段呈现高效率结构,在执行阶段则转为对特定连接的强化^[15]。从长期来看,成功的BCI运动技能习得伴随着大脑网络的系统性演化:初期学习高度依赖额顶叶等认知控制网络,而随着技能趋于自动化,这些控制网络的参与度降低,感觉运动网络则形成更稳定、自主的功能模块^[16]。进一步研究表明,个体在额叶、前辅助运动区和后顶叶皮层等区域的网络灵活性越高,其学习速率也越快^[17]。因此,运动学习是认知与运动网络间动态协同与高效重组的过程。

与运动BCI类似,认知BCI对大脑可塑性的利用也日益聚焦于网络层面。其理论基础正从关注传统的局部病变修复,转向将系统性的大规模脑网络失调作为核心干预目标。大量证据表明,脑卒中后认知障碍或语言障碍的核心病理,与远端脑区的功能连接减弱、特定脑网络紊乱及白质纤维束结构完整性破坏密切相关^[18-20],而基于脑网络连接模式的变化已能准确预测认知表现^[18]。认知BCI通常通过实时解码大脑活动并提供神经反馈,引导患者主动调节特定脑网络活动,从而增强有效连接。这一机制已在多个认知领域得到验证:卒中后执行功能障碍与认知控制网络、显着性网络和默认模式网络的结构/功能异常相关^[20];记忆功能改善与脑连接密度相关^[18];注意力则由包含额叶与顶叶等区域的分布式网络控制^[21]。此外,连接组学指标不仅是康复靶点,也是有效的生物标志物,能预测BCI用户效能^[22],为精准认知评估与个性化干预开辟了新路径。

除运动与认知领域外,脑网络也为探索情绪和神经精神疾病的BCI干预机制提供了新视角^[23-25]。例如,在抑郁症中,前额叶皮层、杏仁核和海马体等关键节点的功能连接异常已被广泛报道。当BCI与重复经颅磁刺激或深部脑刺激等神经调控技术结合时,可针对性调节这些异常网络,为管理抑郁症患者情

绪状态提供更精准、有效的干预策略^[23]。这些多样化的应用共同凸显:BCI诱导的神经可塑性日益被视为一种网络现象。因此,探索其动态演化规律对提升BCI效能至关重要。

2.2 基于脑网络的BCI解码

将脑网络融入BCI解码是近年来重要趋势。脑网络在其中主要发挥双重作用:一是作为先验知识指导并优化解码模型;二是作为直接输入特征驱动分类器。

2.2.1 脑网络作为先验知识引导解码

(1) 指导特征与通道筛选:脑网络分析能预先识别与特定任务最相关的脑区或通道,降低冗余信息与伪迹干扰。先前研究通过构建基于皮尔逊相关或格兰杰因果的脑网络,筛选出与感觉运动任务紧密关联的通道进行特征提取。结合支持向量机或K近邻等分类器,在运动想象任务中取得了超过90%的分类准确率^[26-27]。同样,基于fMRI的个体识别研究表明,静息态下的默认模式网络具有最高的个体化辨识度,提示其可作为筛选个体化生物标志物的优先目标^[28]。

(2) 作为先验结构嵌入模型:脑网络的拓扑结构可作为结构化先验嵌入机器学习模型(尤其是深度学习模型),约束模型学习以更好地捕捉大脑空间信息流^[29]。Jia等提出的多视图时空图卷积网络,通过融合功能连接与物理距离构建大脑图结构,有效捕捉了用于睡眠分期的丰富时空特征^[30]。类似地,其他研究通过构建区分长/短程连接的脑网络探索复杂拓扑特征^[31],或融合多种连接度量(如皮尔逊相关系数、互信息等)构建更鲁棒的图结构,提升了情绪分类精度^[32]。

2.2.2 脑网络作为解码器输入特征

(1) 基于功能连接强度的解码:特定脑区间的连接强度变化可直接区分不同脑状态。研究表明,通过捕捉 α 波段额顶叶网络功能连接的显著降低,可有效区分左右脚运动准备任务,分类准确率达73.73%^[33]。然而,脑网络特征的优势并非绝对。一项MI解码对比研究发现,尽管锁相值在多种连接特征中表现最优,其解码性能并未显著超越传统单通道特征^[34],这表明网络特征的有效性依赖于具体的特征选择与应用场景。

(2) 基于动态与高阶网络特征的解码:鉴于大脑网络的高度动态性,捕捉其时变特性是提升解码速度与精度的前沿方向。近期研究通过识别功能连接保持稳定的微小时间段(数百毫秒),构建这些微状态下的动态功能连接图作为特征,再利用长短期记忆网络分类,仅需500毫秒数据即可实现高达85.32%的运动任务分类准确率^[35]。同时,解码特征正从连接强度发展至更复杂的高阶网络拓扑特征。2025年,Su等利用张量

分解等技术从增强的协方差网络中提取高阶特征,实现对MI—EEG信号的高效分类^[36]。后续研究引入交叉张量耦合分解等方法,通过融合协方差、锁相值、互信息等多模态网络,有效提取任务间共享和判别特征,使分类准确率平均提升17.43%^[13]。高阶特征应用不仅限于MI任务:在情绪识别领域,研究者通过计算功能网络的聚类系数和特征向量中心性等拓扑指标,并与眼动等多模态信息融合,在多个公开数据集上取得优异识别性能^[37]。

综上,脑网络为BCI解码提供了丰富的信息维度。无论是作为先验知识指导模型优化,还是作为直接特征输入分类器,脑网络均展现出提升解码精度、速度和可解释性的巨大潜力。

2.3 基于脑网络的BCI调控

BCI调控旨在通过神经反馈或结合外部物理刺激,主动调节大脑神经活动、诱导神经可塑性,以改善认知与运动功能或缓解疾病症状。其有效性高度依赖于对大脑活动的精准干预和评估。鉴于神经与精神疾病源于脑网络连接改变而非孤立脑区异常^[38],BCI调控范式日益关注于网络的调控,并体现在两个核心环节:靶点选择与效果评估。

2.3.1 基于脑网络的调控靶点选择

(1) 识别疾病相关的核心网络与枢纽

脑网络分析能精准识别与疾病相关的异常功能环路,为调控提供明确靶点。神经影像学荟萃分析发现,由背侧前扣带皮层和岛叶构成的凸显网络是多种精神疾病共同的功能失调核心,成为极具潜力的跨疾病通用调控靶点^[39]。针对特定疾病,如抑郁症,其异常活动则集中于前额叶皮层、杏仁核、海马体等构成的情感环路^[23]。更进一步,刺激的临床疗效与刺激部位同特定网络的连接模式密切相关。例如,治疗焦虑症最有效的经颅磁刺激靶点,往往与背内侧前额叶皮层存在强功能连接^[40]。

(2) 迈向多靶点网络协同刺激

精准定位目标网络后,调控策略正从传统单点刺激演进为更高效的多靶点协同干预,旨在通过同时或序贯干预网络中多个关键节点,协同重塑整个环路功能状态^[41]。例如,Dagan等证实,通过多通道经颅直流电刺激同时优化初级运动皮层和左侧背外侧前额叶皮层活动,其改善效果显著优于单点刺激^[42]。该策略也应用于意识障碍干预:研究者利用静息态fMRI构建的脑网络图谱,通过多通道刺激尝试重新激活严重脑损伤患者的关键意识网络(如额顶叶网络)^[43]。这些研究共同表明,协同刺激是网络化BCI调控的重要发展方向。

2.3.2 基于脑网络的调控效果评估

(1) 量化调控下的网络动态变化

脑网络指标为实时追踪和量化大脑对调控的响应提供了新角度,揭示BCI作用机制并指导反馈策略优化。例如,一项运动BCI研究发现,运动准备伴随着 α 波段额顶叶网络功能连接的显著降低。研究者据此设计神经反馈范式并在中风患者中验证,指出该网络的连接强度可作为评估神经损伤程度及康复效果的指标^[33]。在任务态fMRI研究中,网络分析也能量化调控对神经效率的影响。研究发现,对老年受试者左侧额下回施加阳极经颅直流电刺激,不仅提升其单词检索表现,还减少了任务相关的代偿性过度激活,表明单次刺激可暂时逆转与衰老相关的网络功能失调^[39]。

(2) 作为预测疗效的生物标志物

脑网络分析的价值还在于其对治疗效果的预测能力。调控前的基线网络特征能有效预测个体对干预的反应。一项针对慢性卒中患者的研究发现,仅基线状态下特定脑网络(α 波段)连接更强的患者,才对阳极经颅直流电刺激表现出更强的大脑反应性^[44]。这表明基线大脑网络连接可作为生物标志物,用于筛选特定调控方案的潜在受益人群,是实现个性化BCI调控的重要一步。

3 挑战与展望

尽管前景广阔,将脑网络分析从理论研究推向可靠的BCI应用,仍面临从理论认知到技术实现的多重挑战。首先,在理论认知层面,关键挑战在于如何从复杂的网络动态中辨别真实神经信号与虚假噪声。BCI任务中观察到的许多功能连接变化,可能并非源于目标认知过程,而是由技术伪影(如EEG的容积传导效应)或生理活动(如头动、眼动)导致的虚假连接^[8,11]。其次,在方法学层面,准确性、个性化和实时性构成三大技术瓶颈。脑网络解码准确性常表现出不稳定的任务依赖性,在运动想象等经典任务中并未显著超越传统特征^[34]。同时,当前脑网络建模常忽略个体间与人群间差异^[9],难以构建精准的个性化脑网络。最后,高维网络特征的高计算负荷构成严峻的实时性障碍,严重制约了其在毫秒级闭环系统中的部署^[45]。

面对上述挑战,未来的研究应在以下几个方面重点突破。

(1) 机制探索:发展能有效抑制虚假连接的先进方法。

这不仅包括深化源空间连接分析^[8]和采用更鲁棒的降噪算法^[46],还需设计严谨的对照实验与统计模型,分离与特定意图相关的网络信号。在此基础上,研究需向微观层面深入,探究宏

观网络变化与底层神经元活动、突触可塑性之间的联系，确认网络重塑是真实的神经可塑性体现。

(2) 技术创新：需从准确性、个性化与实时性三个维度协同突破。提升准确性要求开发更智能的脑网络解码框架，使其能根据不同任务场景自适应选择最优特征，并研发更先进的解码模型；同时，探索多模态融合策略，将全局网络信息与局部时频特征相结合，以全面提升解码精度。实现个性化则依赖于发展基于个体数据的精准网络建模技术，并利用迁移学习等方法，从少量校准数据快速构建稳定、可靠的个性化脑网络模型。突破实时性瓶颈的关键在于加速研发轻量化、高效率的计算框架，例如通过算法优化、硬件加速或模型蒸馏技术^[35]，以满足闭环BCI系统对毫秒级响应的严苛要求。

(3) 系统融合：未来BCI系统将深度融合人工智能。一方面，利用高效的图神经网络等模型，实现对动态网络特征的快

参考文献：

- [1] WOLPAW J R. Brain - computer interfaces[M]//Handbook of Clinical Neurology. Elsevier, 2013: 67-74.
- [2] BRUSINI L, STIVAL F, SETTI F, et al. A systematic review on motor-imagery brain-connectivity-based computer interfaces[J]. IEEE Transactions on Human-Machine Systems, 2021, 51(6): 725-733.
- [3] HE F, WANG C H, WANG K, et al. 通用脑—机接口软件平台发展现状 [J]. Chinese Journal of Biomedical Engineering, 2024, 43(5): 609-619.
- [4] VIDAL J J. Toward direct brain-computer communication[J]. Annual Review of Biophysics and Bioengineering, 1973, 2(1): 157-180.
- [5] FARWELL L A, DONCHIN E. Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials[J]. Electroencephalography and Clinical Neurophysiology, 1988, 70(6): 510-523.
- [6] LAZAROU I, NIKOLOPOULOS S, PETRANTONAKIS P C, et al. EEG-based brain - computer interfaces for communication and rehabilitation of people with motor impairment: a novel approach of the 21st century[J]. Frontiers in Human Neuroscience, 2018, 12: 14.
- [7] SAHA S, MAMUN K A, AHMED K, et al. Progress in brain computer interface: Challenges and opportunities[J]. Frontiers in Systems Neuroscience, 2021, 15: 578875.
- [8] GONZALEZ-ASTUDILLO J, CATTAL T, BASSIGNANA G, et al. Network-based brain - computer interfaces: principles and applications[J]. Journal of Neural Engineering, 2021, 18(1): 011001.
- [9] BIJSTERBOSCH J, HARRISON S J, JBABDI S, et al. Challenges

速、端到端解码。另一方面，结合强化学习等策略，构建能自主学习、动态调整的自适应BCI系统。最终目标是实现一个能实时感知网络状态、理解用户意图并适应个体差异的智能闭环BCI系统。

4 总结

本文系统回顾了脑网络在BCI领域的应用进展。脑网络为BCI技术带来了新的研究视角，在机制理解、状态解码与神经调控等核心环节实现显著提升，增强了BCI的性能与应用潜力。尽管面临理论认知、方法学及工程化等多重挑战，其仍然是BCI发展的重要研究方向。通过深化机制理解、驱动技术创新与促进临床转化，脑网络赋能的BCI有望在神经康复、脑功能增强等领域取得突破性进展。

and future directions for representations of functional brain organization[J]. Nature Neuroscience, 2020, 23(12): 1484-1495.

[10] HRAMOV A E, FROLOV N S, MAKSIMENKO V A, et al. Functional networks of the brain: from connectivity restoration to dynamic integration[J]. Physics-Uspekhi, 2021, 64(6): 584.

[11] CAO J, ZHAO Y, SHAN X, et al. Brain functional and effective connectivity based on electroencephalography recordings: A review[J]. Human Brain Mapping, 2022, 43(2): 860-879.

[12] RUBINOV M, SPORNS O. Complex network measures of brain connectivity: uses and interpretations[J]. NeuroImage, 2010, 52(3): 1059-1069.

[13] XIE J, SU H, YANG Z, et al. A novel method for motor imagery electroencephalogram classification: cross tensor coupling decomposition based on diverse modality brain functional networks[J]. Biomedical Signal Processing and Control, 2025, 110: 108295.

[14] XU L, ZHANG H, HUI M, et al. Motor execution and motor imagery: a comparison of functional connectivity patterns based on graph theory[J]. Neuroscience, 2014, 261: 184-194.

[15] DE VICO FALLANI F, ASTOLFI L, CINCOTTI F, et al. Cortical network dynamics during foot movements[J]. Neuroinformatics, 2008, 6(1): 23-34.

[16] BASSETT D S, YANG M, WYMBS N F, GRAFTON S T. Learning-induced autonomy of sensorimotor systems[J]. Nature Neuroscience, 2015, 18(5): 744-751.

[17] BASSETT D S, WYMBS N F, PORTER M A, et al. Dynamic reconfiguration of human brain networks during learning[J].

Proceedings of the National Academy of Sciences, 2011, 108(18): 7641–7646.

[18] SUN X, LI M, LI Q, et al. Poststroke cognitive impairment research progress on application of brain - computer interface[J]. BioMed Research International, 2022, 2022: 9935192.

[19] DIJKHUIZEN R M. Imaging neuronal loss and recovery in compromised but viable brain tissue[J]. Brain, 2013, 136(6): 1689–1691.

[20] JAYWANT A, DELPONTE L, KANELLOPOULOS D, et al. The structural and functional neuroanatomy of post-stroke depression and executive dysfunction: a review of neuroimaging findings and implications for treatment[J]. Journal of Geriatric Psychiatry and Neurology, 2022, 35(1): 3–11.

[21] FLOWERS H L, SILVER F L, FANG J, et al. The incidence, co-occurrence, and predictors of dysphagia, dysarthria, and aphasia after first-ever acute ischemic stroke[J]. Journal of Communication Disorders, 2013, 46(3): 238–248.

[22] ZHANG T, LIU T, LI F, et al. Structural and functional correlates of motor imagery BCI performance: Insights from the patterns of fronto-parietal attention network[J]. NeuroImage, 2016, 134: 475–485.

[23] ZHANG M, YANG Y, ZHAO Y, et al. The application of integrating electroencephalograph-based emotion recognition technology into brain - computer interface systems for the treatment of depression: a narrative review[J]. Advanced Technology in Neuroscience, 2024, 1(2): 188–200.

[24] RUIZ S, BUYUKTURKOGLU K, RANA M, et al. Real-time fMRI brain computer interfaces: self-regulation of single brain regions to networks[J]. Biological Psychology, 2014, 95: 4–20.

[25] WU D, LU B-L, HU B, ZENG Z. Affective brain - computer interfaces (aBCIs): A tutorial[J]. Proceedings of the IEEE, 2023, 111(10): 1314–1332.

[26] VARSEHI H, FIROOZABADI S M P. An EEG channel selection method for motor imagery based brain - computer interface and neurofeedback using Granger causality[J]. Neural Networks, 2021, 133: 193–206.

[27] DHIMAN R. Electroencephalogram channel selection based on Pearson correlation coefficient for motor imagery-brain-computer interface[J]. Measurement: Sensors, 2023, 25: 100616.

[28] LI Y, LIU A, FU X, et al. Atlas-guided parcellation: Individualized functionally-homogenous parcellation in cerebral cortex[J]. Computers in Biology and Medicine, 2022, 150: 106078.

[29] XIONG H, YAN Y, CHEN Y, LIU J. Graph convolution network-based EEG signal analysis: a review[J]. Medical & Biological Engineering & Computing, 2025, 63(6): 1609–1625.

[30] JIA Z, LIN Y, WANG J, et al. Multi-view spatial-temporal graph convolutional networks with domain generalization for sleep stage classification[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2021, 29: 1977–1986.

[31] QIU X, WANG S, WANG R, et al. A multi-head residual connection GCN for EEG emotion recognition[J]. Computers in Biology and Medicine, 2023, 163: 107126.

[32] TIAN W, LI M, JU X, LIU Y. Applying multiple functional connectivity features in GCN for EEG-based human identification[J]. Brain Sciences, 2022, 12(8): 1072.

[33] PHANG C-R, CHEN C-H, CHENG Y-Y, et al. Frontoparietal dysconnection in covert bipedal activity for enhancing the performance of the motor preparation-based brain - computer interface[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2022, 31: 139–149.

[34] DELAVARI F, SANTANIELLO S. Role of scalp EEG brain connectivity in motor imagery decoding for BCI applications[C]//2024 46th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). IEEE, 2024.

[35] SHAMSI F, HADDAD A, NAJAFIZADEH L. Early classification of motor tasks using dynamic functional connectivity graphs from EEG[J]. Journal of Neural Engineering, 2021, 18(1): 016015.

[36] SU H, XIE J, YANG Z, et al. Efficient motor imagery electroencephalogram classification via cross tensor coupling decomposition based on augmented covariance networks[J]. Neurocomputing, 2025, 634: 129911.

[37] WU X, ZHENG W-L, LI Z, LU B-L. Investigating EEG-based functional connectivity patterns for multimodal emotion recognition[J]. Journal of Neural Engineering, 2022, 19(1): 016012.

[38] SALE M V, MATTINGLEY J B, ZALESKY A, COCCHI L. Imaging human brain networks to improve the clinical efficacy of non-invasive brain stimulation[J]. Neuroscience & Biobehavioral Reviews, 2015, 57: 187–198.

[39] TO W T, DE RIDDER D, HART J R, VANNESTE S. Changing brain networks through non-invasive neuromodulation[J]. Frontiers in Human Neuroscience, 2018, 12: 128.

[40] SIDDIQI S H, KHOSRAVANI S, ROLSTON J D, FOX M D. The future of brain circuit-targeted therapeutics[J]. Neuropsychopharmacology, 2024, 49(1): 179–188.

- [41] RUFFINI G, WENDLING F, SANCHEZ-TODO R, SANTARNECCHI E. Targeting brain networks with multichannel transcranial current stimulation (tCS)[J]. *Current Opinion in Biomedical Engineering*, 2018, 8: 70–77.
- [42] DAGAN M, HERMAN T, HARRISON R, et al. Multitarget transcranial direct current stimulation for freezing of gait in Parkinson's disease[J]. *Movement Disorders*, 2018, 33(4): 642–646.
- [43] THIBAUT A, MARTENS G, LAUREYS S. Multichannel tDCS of the frontoparietal network in patients with disorders of consciousness: A double blind sham controlled randomized clinical trial[J]. *Brain Stimulation*, 2017, 10(4): e40.
- [44] HORDACRE B, MOEZZI B, RIDDING M C. Neuroplasticity and network connectivity of the motor cortex following stroke: A transcranial direct current stimulation study[J]. *Human Brain Mapping*, 2018, 39(8): 3326–3339.
- [45] RODRIGUES P G, FILHO C A S, ATTUX R, et al. Space-time recurrences for functional connectivity evaluation and feature extraction in motor imagery brain-computer interfaces[J]. *Medical & Biological Engineering & Computing*, 2019, 57(8): 1709–1725.
- [46] CHEN X, LI C, LIU A, et al. Toward open-world electroencephalogram decoding via deep learning: A comprehensive survey[J]. *IEEE Signal Processing Magazine*, 2022, 39(2): 117–134.