

基于脑电信号的脑机接口智能解码技术及临床应用

郑炜豪¹, 杜亚峰¹, 付 钰¹, 张 喆²

(1. 兰州大学信息科学与工程学院, 兰州 730000; 2. 杭州师范大学脑科学研究所, 杭州 311121)

摘 要: 脑机接口(Brain-computer interface, BCI)通过解析脑活动建立人脑与外部设备之间的信息通路, 为辅助交流、功能评估、康复训练和神经调控提供了新的技术手段。脑电图(Electroencephalography, EEG)具有无创、低成本、高时间分辨率和便于重复采集等优势, 是当前非侵入式BCI和脑健康研究中应用最广泛的信号模态之一。近年来, 人工智能推动EEG解码由经典控制指令识别逐步拓展至复杂脑状态表征、视觉与语言语义重建和实时闭环交互。本文以EEG智能解码技术的演进为主线, 梳理控制意图解码、脑状态解码、高层语义解码、通用表征学习和闭环交互等方向的代表性进展, 并进一步分析上述技术在脑卒中康复、语言和视觉功能康复、癫痫检测与预警、意识障碍评估和精神疾病辅助诊断中的应用证据。现有研究表明, EEG解码所能表征的信息层级和应用范围不断扩展, 但不同方向的临床成熟度存在明显差异: 控制意图识别、异常状态检测和闭环神经康复已积累了一定的研究基础, 视觉与语言语义解码仍主要停留在健康受试者和受控实验条件下。当前制约临床转化的关键已不仅是模型性能, 还包括跨个体和跨中心泛化、神经信息忠实性、长期稳定性、临床增量价值以及闭环安全与伦理监管。未来应以真实临床需求和患者结局为导向, 推动EEG智能解码由方法可行性验证走向稳定、可信和可评价的临床应用。

关键词: 脑机接口; 脑电信号; 智能解码; 脑状态评估; 脑健康; 临床应用

中图分类号: TP391 **文献标志码:** A

引用格式: 郑炜豪, 杜亚峰, 付钰, 等. 基于脑电信号的脑机接口智能解码技术及临床应用[J]. 数据采集与处理, 2026, 41(4): 910-945. ZHENG Weihao, DU Yafeng, FU Yu, et al. Brain-computer interface intelligent decoding technology based on EEG signal and its clinical application[J]. Journal of Data Acquisition and Processing, 2026, 41(4): 910-945.

引 言

脑机接口(Brain-computer interface, BCI)通过采集和分析脑活动, 建立不依赖外周神经与肌肉系统的信息交互通路。自Vidal于1973年提出BCI概念以来^[1], 不同类型的脑信号被用于探索人脑与外部设备之间的直接通信。本文聚焦以头皮脑电图(Electroencephalography, EEG)为信号载体的非侵入式BCI。EEG能够以毫秒级时间分辨率记录神经活动, 同时具有无创、成本相对较低、便于重复采集及床旁部署等特点, 因而成为BCI研究中应用最广泛的信号模态之一。本文所称“智能解码”, 主要指利用信号处理与人工智能方法, 从EEG活动中提取与任务相关的时空、频谱及语义信息, 并进一步识别控制意图、表征脑功能状态、恢复视觉或语言内容, 或生成用于外部设备交互和闭环反馈的控制指令。

早期EEG-BCI研究主要解决脑信号能否被稳定转换为可操作信息的问题, 并由此确立了几类具有

持续影响的任务范式。基于P300事件相关电位的拼写系统利用受试者对目标字符的选择性注意反应完成字符输出^[2],其意义在于首次将短暂的诱发EEG响应转化为可实际使用的交流通道。基于感觉运动节律的二维光标控制研究进一步表明受试者可以通过调节运动想象相关脑活动持续控制外部设备^[3],使BCI由离散选择拓展到连续交互。Wadsworth中心开发的BCI2000通用平台将EEG采集、刺激呈现、信号处理和反馈控制整合于统一框架中^[4],为不同范式和算法的复现、比较与验证提供了标准化工具。Birbaumer等^[5]针对完全锁定综合征患者开展BCI通信研究,将技术可行性进一步转化为临床问题,即对于失去常规运动输出通道的患者,脑活动本身能否成为新的交流媒介。上述研究分别从任务范式、连续控制、系统平台和临床应用4个层面奠定了EEG-BCI的发展基础。

在此后的研究中,BCI的核心问题由“能否解码”逐渐转变为“如何提高解码的稳定性、实时性和泛化能力”。共空间模式、线性判别分析和支持向量机等方法通过提取任务相关的空间、频谱和统计特征,形成了较为成熟的传统分析流程^[6];黎曼几何、自适应滤波和多尺度时频分析则试图提高模型对噪声、状态变化和跨条件差异的适应能力^[7-8]。这些方法推动了运动想象、P300和稳态视觉诱发电位等范式的性能提升,但其效果往往依赖频带选择、时间窗设定和人工特征设计,模型也通常针对单一任务或单一被试进行优化。2017年前后,以卷积神经网络(Convolutional neural network, CNN)和循环神经网络(Recurrent neural network, RNN)为代表的深度学习方法开始系统性地进入EEG解码领域^[9-10]。卷积结构能够从多通道EEG中联合学习局部时间、频谱和空间模式,循环结构则能够描述脑状态随时间变化的依赖关系。当这些结构被用于端到端特征学习后,传统依赖人工经验、串联特征提取与分类器的分析流程,开始被统一的神经网络架构所替代^[9-10]。深度学习改变了EEG编解码的基本思路:研究者不再完全依赖预先定义的生理特征,而是尝试从原始或弱预处理信号中直接学习与任务相关的潜在表征。由此,EEG编码由人工设计逐渐转向数据驱动,解码目标也由相对单一的控制指令识别扩展到注意、疲劳、认知负荷、情绪和意识等复杂脑状态。

自监督学习与基础模型的出现进一步推动了EEG编解码由任务专用模型走向通用表征。BENDR^[11]通过在连续EEG数据上开展自监督预训练,使模型能够在缺少大规模人工标签的情况下学习可迁移的时间表征,并将其应用于不同下游任务。这一工作表明,EEG模型可以先学习信号本身的结构,再针对具体问题进行调整,而不必从每个小规模数据集重新训练。BIOT^[12]将EEG与其他生理时间序列纳入统一建模框架,其关注点由单一EEG任务进一步转向不同生理信号之间可共享的表示形式。LaBraM^[13]通过更大规模的EEG数据和掩码建模策略学习通用EEG表征,体现了该领域向更大数据规模、更复杂预训练任务和跨任务迁移发展的趋势。与此同时,BCI的解码目标也开始突破固定标签和有限控制指令。DreamDiffusion^[14]将自监督EEG编码与预训练扩散模型结合,使EEG视觉解码由图像类别判断和粗粒度重建逐渐转向语义条件生成,这一方向的关键变化并不是生成图像更加逼真,而是EEG表征开始与预训练视觉语义空间建立联系。语言解码研究也经历了类似变化:早期工作主要是识别有限字符、词汇或想象语音类别,随后Transformer和大语言模型被用于句子级EEG表征和开放文本生成^[15-16]。相较于早期以运动想象和稳态视觉诱发电位控制为核心的研究范式,当前EEG解码的目标已扩展至视觉感知重建、连续语音解码、情绪识别以及认知状态评估等更高层次的脑功能解析任务。上述平台与模型的共同价值在于推动EEG-BCI从单一实验范式和任务特异算法,逐步走向可复现、可迁移和可扩展的研究体系。BCI2000通过整合EEG采集、刺激呈现、信号处理和在线反馈,为不同BCI范式的标准化实现、算法比较和系统复现提供了基础平台;BENDR、BIOT和LaBraM则代表EEG解码由单任务监督学习向自监督预训练和通用表征学习转变,使模型能够从大规模无标注或弱标注生理信号中学习跨任务共享特征。由此,EEG-BCI的发展重点不再局限于单一任务中的离线分类准确率,而是进一步转向跨任务迁移、跨人群泛化、长期稳定性和真实场景部署能力。

解码能力的扩展为BCI进入临床场景提供了新的可能。在脑卒中康复中,运动意图解码可与功能性电刺激、康复机器人或外骨骼训练结合,使患者的主动脑活动参与运动反馈过程^[17-20];在癫痫研究中,连续EEG分析被用于识别发作期和发作前状态,以支持长期监测和风险预警^[21-24];在意识障碍中,诱发电位和运动想象范式可辅助发现行为评估难以识别的残余意识^[25-26];在抑郁、焦虑等精神障碍中,研究者尝试利用EEG表征进行状态识别、患者分型和疗效评估^[27-31]。然而,技术能力的扩展并不意味着临床价值已经得到充分证明。被试内或单中心实验获得的高准确率可能无法推广到新的患者和设备;生成图像或文本的质量可能受到预训练模型先验的显著影响,而未必真实反映EEG中包含的信息;离线模型在短期实验中的有效性也不能代表其在长期闭环使用中的稳定性。BCI的评价因此需要由单纯关注算法性能,转向同时考察神经信息的条件依赖性与模型可解释性、跨个体和跨中心泛化性、长期适应能力以及对临床评估和干预决策的增量价值。基于上述问题,本文以EEG信号的智能表征编码为基础,以控制意图、脑状态和高层语义解码为核心,系统梳理BCI智能编解码技术的发展,并进一步分析其在脑卒中、癫痫、意识障碍和精神疾病等场景中的临床应用与转化挑战。本文的综述框架如图1所示。




图1 基于EEG信号的BCI智能解码技术框架

Fig.1 Framework of EEG-based intelligent decoding techniques for BCI

1 方法综述

1.1 EEG智能解码的任务范围与评价维度

从输出目标看,EEG智能解码大致覆盖3个相互衔接的信息层级。第1类是控制意图解码,利用运动想象、P300和稳态视觉诱发电位等相对明确的脑活动模式产生字符选择、方向控制或设备指令;第2类是脑状态解码,关注注意、疲劳、认知负荷、情绪、意识和病理相关异常等持续或动态状态;第3类是高层语义解码,尝试从EEG中恢复视觉类别、图像属性、词汇或句子内容。自监督学习和EEG基础模型为不同任务提供共享表征,闭环系统则将离线结果转化为反馈、训练或干预。上述任务并非线性替代,而是在信息复杂度、数据规模和应用需求不断增加的背景下逐步扩展。

不同任务需要采用不同的评价维度。控制意图解码除准确率外,还应关注信息传输率、响应延迟、在线稳定性和使用负担;脑状态解码需要考察跨被试泛化、概率校准、纵向一致性及其与行为或临床表型的对应关系;视觉和语言语义解码则必须区分类别识别、语义一致性和实例级内容恢复,并判断输出究竟依赖多少真实EEG信息。进入临床场景后,模型还应在患者级、跨设备和跨中心条件下验证,并结合假警报、功能结局、增量检出或治疗反应等任务进行特异指标评价。

1.2 文献检索与筛选方法

本文采用结构化文献检索与叙述性综合方法,检索重点覆盖2017~2026年发表的深度学习、生成式人工智能、基础模型^[32]及临床EEG解码研究;对于BCI概念、经典范式、核心网络架构和生成模型等奠基性工作,不设置发表年份限制。本文将2017年作为深度学习EEG解码研究的主要检索起点,主要基于两方面考虑:一方面,2017年前后卷积神经网络、循环神经网络和端到端学习开始较系统地应用于EEG解码,研究重点逐渐由人工特征提取与传统分类器组合,转向从原始或弱预处理EEG中自动学习时空表征;另一方面,EEGNet、Deep ConvNet等代表性结构及相关综述工作推动了深度学习在运动想象、P300、稳态视觉诱发电位和脑状态识别中的规模化应用。因此,2017年以后文献更能反映EEG解码由传统机器学习向深度学习、生成模型和基础模型演进的主要趋势。该策略旨在兼顾技术发展脉络、代表性工作和近年研究前沿。检索数据库包括Google Scholar、PubMed、IEEE Xplore和arXiv,并结合代表性综述进行补充。核心检索词包括“EEG”“electroencephalography”“brain-computer interface”“text generation”“image reconstruction”“generative AI”“clinical application”“rehabilitation”,并进一步与“stroke”“epilepsy”“disorder of consciousness”“depression”“anxiety”“motor imagery”“aphasia”等临床关键词组合检索。

纳入文献需以非侵入式EEG为主要信号,采用机器学习、深度学习或生成式模型完成分类、检测、预测、控制、视觉内容恢复或语言内容生成等任务,并提供明确的数据来源、实验设计和量化结果。对于预印本研究,本文将其作为前沿技术证据,但在讨论临床成熟度时与同行评议研究加以区分。排除标准包括以功能磁共振成像(functional Magnetic resonance imaging, fMRI)、脑磁图(Magnetoencephalography, MEG)或侵入式神经记录为主要信号模式;缺乏明确方法描述、实验结果或应用场景的研究。经过标题与摘要初筛、全文评估以及重复文献剔除后,本文最终纳入近百篇代表性研究,覆盖控制意图与脑状态解码、视觉与语言语义解码、EEG基础模型、临床应用和转化评价。

2 EEG信号基础

2.1 EEG信号特点

本文选择EEG作为核心信号模式,因为它与fMRI、MEG等技术相比,在时间精度、采集成本和临床可实施性之间形成了较为独特的平衡。常规EEG的采样率通常在250~1 000 Hz,能够记录毫秒尺度的感觉、认知和运动过程,例如视觉刺激后的早期诱发成分^[33]和语言加工中的N400效应^[34]。这一时间优势使研究者能够观察脑状态如何随刺激、任务和疾病过程动态变化,也为实时解码和闭环反馈提供了信号基础。与依赖固定场地和大型设备的功能磁共振成像或脑磁图相比,EEG更便于床旁部署、重复测量和长时间连续记录,因此更适合需要动态监测和即时反馈的BCI场景。

EEG的局限同样需要正视。头皮电位受到容积传导、参考方式和电极布局影响,空间分辨率通常低于fMRI,源定位结果也具有模型依赖性。此外,眼动、肌电、环境噪声和电极阻抗变化还会显著影响单次信号质量。不过,空间精度有限并不意味着EEG缺乏可用信息;基于高密度EEG的视觉分类研究表明,头皮EEG中仍包含可用于区分视觉内容的空间和语义信息^[35]。 δ (0.5~4 Hz)、 θ (4~7 Hz)、 α (8~

12 Hz)、 β (13~30 Hz)和 γ (30~100 Hz)等频段及其耦合关系,也能够从不同时间尺度反映觉醒、注意、记忆、运动和异常放电(图2)。例如, α 频段事件相关去同步化通常反映皮层激活水平; θ 频段活动与记忆提取和语义检索密切相关; β 和 γ 频段则更多参与感觉运动整合以及高级认知加工; δ 频段增强常见于脑损伤或意识障碍状态下的皮层功能失调^[36-37]。高时间分辨率、有限空间信息和较强临床可及性决定了EEG解码既需要针对低信噪比和个体差异设计稳健模型,也必须结合任务范式和临床问题解释其结果。




图2 EEG信号基础

Fig.2 Basics of EEG signals

2.2 EEG特征编码

EEG特征编码旨在从低信噪比、多通道和非平稳的原始EEG中提取可用于分类、生成及跨模态映射的有效表征。现有方法由早期时频与统计特征,逐步发展为时序、空间和时空联合建模,并进一步引入自监督预训练和跨模态对齐,以提高表征的稳定性和任务适应能力。早期研究多利用短时傅里叶变换、小波变换、共空间模式和通道统计量描述EEG的频谱、空间及统计特征,再将其输入分类器或浅层网络。这类方法生理含义相对明确,适合样本规模有限的闭集任务,但难以充分刻画长时间依赖和跨通道交互。随后,长短期记忆网络(Long short-term memory, LSTM)、门控循环单元(Gated recurrent unit, GRU)等循环网络被用于建模EEG随刺激呈现或认知加工变化的动态过程。Brain2Image^[38]采用LSTM将变长EEG序列压缩为固定维度表示;Singh等^[39]在此基础上引入三元组损失,以增强同类表征的紧凑性和不同类别之间的可分性。在空间编码方面,卷积网络主要提取不同通道间的局部关系。Wakita等^[40]采用一维卷积编码器估计视觉EEG的潜在分布;Mishra等^[41]则在卷积编码器中加入通道注意力,以突出对图像重建贡献较大的电极。EEGNet和Sinc-EEGNet等轻量结构通过较少参数完成时间与空间滤波,更适合小样本EEG任务^[10,42]。

图结构建模进一步将电极或脑区视为节点,以功能连接、相干性、相位锁定值或相关性定义边,从而显式描述跨区域协同活动。Khaleghi等^[43]基于EEG功能连接矩阵构建图嵌入,用于生成视觉显著性图;Song等^[44]则将图注意力与时空卷积结合,在电极拓扑关系上学习视觉相关表征。由于EEG同时具有时间序列和多通道空间分布,时空联合建模逐渐成为较常见的策略。Zeng等^[45]提出的基于扩散模型的脑电信号到图像重建框架(Diffusion model-based reconstruction from EEG to image, DM-RE2I)结合

空间卷积、时序卷积和多核残差结构;Shimizu等^[46]则通过通道级变换与时空卷积,进一步区分电极内时间演化和电极间空间交互。这类方法能够同时利用局部波形、通道关系和时间动态,但在小样本或跨被试条件下也更容易出现过拟合。

在语言任务中,CNN与RNN、LSTM或GRU的组合被用于先提取通道间空间特征,再建模EEG序列的时间变化。Biswal等^[47]将该类结构用于EEG医疗报告生成;Srivastava等^[48]则采用CNN-LSTM建模EEG的时空变化。随着Transformer的引入,上下文EEG表示逐渐成为重要方向。Wang等^[49]利用多层Transformer将词级EEG序列编码为文本生成模型可使用的上下文表示;Feng等^[50]进一步将EEG表征投影到BART(Bidirectional and auto-regressive Transformers)的序列到序列语义空间;Tao等^[51]通过跨模态码本统一EEG嵌入与文本嵌入;Liu等^[52]在句子级EEG上开展掩码预训练,并利用多视图Transformer分别建模不同脑区信号;Wang等^[53]结合词级和句级掩码,使模型同时学习局部上下文与整体语义。这些研究使EEG编码由局部时空特征提取进一步转向长程上下文和句子级表示。自监督学习和跨模态对齐进一步改变了EEG特征编码的目标。掩码建模通过遮蔽并恢复部分EEG片段,从无标注数据中学习较稳定的潜在表征。DreamDiffusion采用类似的掩码自编码策略增强EEG编码器的鲁棒性^[14]。对比学习则通过拉近匹配的EEG与图像或文本表征、分离不匹配样本,使EEG嵌入进入相应的视觉或语言语义空间。Mehmood等和Rezvani等^[54-55]采用基于InfoNCE的目标对齐EEG与图像文本语义;Feng等^[50]则在EEG编码器与文本解码器之间引入对比学习。DeWave^[15]进一步同时学习词级对齐EEG与连续句子级EEG表征,以减少语言任务对眼动边界和精确词级切分的依赖。

用于EEG信号编解码研究的代表性数据集包括Spampinato等的视觉EEG数据集^[35]、ZuCo 1.0/2.0同步EEG-眼动阅读语料库^[56-57]、THINGS-EEG大规模视觉认知数据集^[58]和KARA ONE想象语音数据集^[59]等。主要数据集信息如表1所示。

表1 各数据集汇总
Table 1 Summary of each dataset

数据集	刺激类型	通道数	刺激材料	被试数
ZuCo 1.0	文本	128	来自Stanford Sentiment Treebank和Wikipedia语料库的句子	12
ZuCo 2.0	文本	128	在ZuCo 1.0基础上扩展被试数量,刺激内容相似	18
KARA ONE	想象语音	14	20个文本刺激,包括数字、字符以及10个物体名称	23
Chisco	文本、想象语音	128	6 681个日常中文表达句子	3
ChineseEEG	文本	128	2部中文小说,字符逐个呈现,每个字符呈现350 ms,无标点符号	10
Neural Spelling	文本、手写	64	26个英文字母,使用平板触控笔书写;每个字母重复25次,共650个试次	28
OCED	图像	128	6个物体类别,每类12张图像	10
ImageNet EEG	图像	128	ImageNet子集,40个类别,每类50张图像,共2 000张	6
Texture Perception	图像	19	166张灰度自然纹理图像	15
THINGS-EEG	图像	64	22 248张图像,覆盖1 854个物体概念	50
DCAE	图像	32	200张ImageNet图像,包括猫、狗、花和熊猫等类别	26
DM-RE2L	图像	32	200张ImageNet图像,数据来自26名被试	26
Alljoined	图像	64	每名被试观看10 000张图像,来自MS-COCO数据集的80个类别	8
Low-Density EEG	图像	8	每个实验阶段600张图像,包含20个类别。每张图像呈现2 s,随机顺序呈现	9
Reconstruction				
ThoughtViz	想象物体	14	被试想象数字、字符和物体时记录EEG信号	23

总体来看,EEG 特征编码已由手工时频特征和单一时序或空间模型,逐步发展为时空联合、图结构、自监督预训练和跨模态语义对齐。不同策略并不存在统一的最优选择:小样本任务更适合轻量模型和先验明确的特征;需要描述长程上下文或脑区协同时,Transformer、时空模型和图网络更具优势;在视觉与语言语义解码中,编码器能否学习稳定 EEG 表征并与目标语义空间建立对应关系,通常比单纯增加后端生成模型复杂度更为关键。

3 EEG 智能解码技术进展

EEG 智能解码的发展并非简单表现为模型结构不断复杂化,而是体现为解码对象、训练方式和系统形态的共同变化。早期研究主要从稳定诱发的 EEG 模式中提取少量控制指令,随后逐步转向持续脑状态、复杂认知活动和高层语义内容;模型训练也由人工特征和单任务监督学习,扩展至自监督预训练、跨模态对齐和通用表征学习;实时反馈与康复设备的结合,则推动 EEG 解码由单向信息读取走向闭环交互。本节围绕这些变化梳理代表性工作,重点讨论各阶段解决的核心问题及其技术边界,而不对具体模型结构作逐层展开。EEG 智能解码的通用框架如图 3 所示,图中: Z_{brain} 表示由 EEG 特征提取器获得的脑信号潜在表征; $t_i(i=1,2,\dots,N)$ 表示文本解码过程中第 i 个输入词元; $y_i(i=1,2,\dots,N)$ 表示模型在第 i 个解码步生成的预测词元或输出结果。




图3 EEG 智能解码通用框架

Fig.3 EEG intelligent decoding general framework

3.1 基础解码模型

3.1.1 变分自编码器

VAE^[60]在自编码器中引入概率潜在空间,具体结构如图 4 所示。其编码器根据输入估计潜在分布的 μ 和方差 σ^2 ,解码器通过从该分布中采样完成图像重建;训练过程中,重建损失用于保持生成结果与目标图像的一致性,KL 散度则约束潜在分布接近先验分布,从而提高潜在空间的连续性和可采样性。由于视觉刺激诱发的 EEG 具有低信噪比、非平稳性和明显个体差异,VAE 能够以概率方式描述 EEG 表征中的




图4 变分自编码器结构示意图

Fig.4 Architecture of VAE

不确定性,适合早期小样本条件下的图像重建,但其生成结果通常较为平滑,细节与边缘表现有限。

3.1.2 生成对抗网络

GAN^[61]通过生成器与判别器之间的对抗训练学习真实图像分布,具体结构如图5所示。生成器根据随机变量生成图像,判别器判断输入来自真实数据还是生成模型,其基本目标函数为

$$\min_G \max_D E_{x \sim p_{\text{data}}} [\ln D(x)] + E_{z \sim p_z} [\ln(1 - D(G(z)))] \quad (1)$$

式中: G 和 D 分别表示生成器和判别器; x 表示从真实数据分布 $P_{\text{data}}(x)$ 中采样的真实样本; z 表示从先验分布 $P_z(z)$ 中采样的随机噪声向量; $G(z)$ 表示生成器产生的生成样本; $D(x)$ 和 $D(G(z))$ 分别表示判别器将真实样本和生成样本判断为真实数据的概率; E 表示数学期望。生成器通过最小化目标函数提高生成样本的真实性,判别器则通过最大化目标函数增强对真实样本和生成样本的区分能力。

与VAE相比,GAN通常能够生成轮廓更清晰、视觉真实感更强的图像,但训练过程容易出现梯度不稳定和模式坍塌。在EEG驱动的语义解码过程中,若EEG约束不足,生成器还可能过度依赖语义信息的分布先验,产生与输入EEG不一致的内容。为增强EEG与生成结果之间的关联,条件GAN将EEG特征作为条件信息,同时输入生成器和判别器,使生成过程由无条件采样转变为EEG条件约束,即

$$\min_G \max_D E_{x \sim p_{\text{data}}} [\ln D(x|y)] + E_{z \sim p_z} [\ln(1 - D(G(z|y)))] \quad (2)$$




图5 生成对抗网络结构示意图

Fig.5 Architecture of GAN

3.1.3 Transformer模型

Transformer^[62]通过自注意力机制建模输入序列中不同位置之间的依赖关系,具体结构如图6所示,图中 N 表示编码器层或解码器层的堆叠数量。其核心思想是利用查询、键和值之间的相似度计算注意力权重,从而动态捕获全局特征关系;多头注意力机制进一步从不同子空间提取多层次特征表示,前馈网络和残差连接则用于增强特征变换能力并稳定模型训练。与传统卷积神经网络主要关注局部邻域特征不同,Transformer能够直接建模EEG信号在不同时间片段、频段或通道之间的长程依赖关系,因此适合处理具有时空耦合特征的EEG数据。在EEG图像重建任务中,Transformer可用于提取EEG时序特征、增强跨通道信息交互,或作为EEG编码器与图像生成模型之间的特征映射模块,从而提升EEG表征与视觉语义之间的对齐能力。




图6 Transformer网络结构示意图

Fig.6 Architecture of Transformer network

3.1.4 图神经网络

GNN^[63]是一种面向图结构数据的深度学习模型,其核心思想是通过节点之间的信息传递与邻域聚合来学习结构化特征表示,具体结构如图7所示,图中 L 表示图卷积层或消息传递层的堆叠数量。对于EEG数据而言,不同电极通道可以被视为图中的节点,通道之间的空间邻近关系、功能连接关系或相关性关系则可构建为图的边。GNN通过不断聚合相邻节点的特征信息,能够刻画脑区之间的空间依赖和功能交互关系,从而弥补传统卷积网络在非欧氏结构建模方面的不足。与Transformer主要依赖自注意力机制建模全局关系不同,GNN更强调基于EEG通道拓扑结构或功能连接网络的局部-全局信息传播,因此适合处理具有脑网络特征的EEG数据。在EEG图像重建任务中,GNN可用于提取跨通道空间关系、构建脑区功能连接表征,或作为EEG编码器的一部分将多通道EEG信号映射到更具结构信息的潜在表示中,从而增强EEG表征与视觉语义特征之间的对应关系。但GNN的性能在很大程度上依赖图结构的构建方式,不同的电极连接策略、功能连接指标或邻接矩阵设定可能影响模型的表达能力与泛化效果。因此,在小样本和跨被试EEG场景下,通常需要结合自适应图学习、稀疏约束、正则化或跨被试对齐策略,以提高模型对个体差异和噪声干扰的鲁棒性。

3.1.5 扩散模型

DM^[64]通过前向加噪和反向去噪学习数据分布,具体结构如图8所示。前向过程在多个时间步中逐渐向原始图像加入高斯噪声,其单步过程为

$$q(x_t|x_{t-1}) = N\left(x_t; \sqrt{1 - \beta_t} x_{t-1}, \beta_t I\right) \quad (3)$$

式中: $q(x_t|x_{t-1})$ 表示由第 $t-1$ 步样本生成第 t 步样本的前向条件分布; t 为扩散时间步; x_{t-1} 和 x_t 分别表示加噪前后的相邻时间步样本; β_t 为第 t 步的噪声方差系数; I 为单位矩阵; $\sqrt{1 - \beta_t} x_{t-1}$ 和 $\beta_t I$ 分别为高斯分布的均值和协方差矩阵。




图7 图神经网络结构示意图
Fig.7 Architecture of GNN




图8 扩散模型结构示意图
Fig.8 Architecture of DM

反向过程则训练神经网络预测各时间步的噪声,并由随机噪声逐步恢复目标图像。潜在扩散模型 (Latent diffusion model, LDM)进一步将扩散过程由像素空间转移至预训练自编码器的低维潜在空间,在降低计算成本的同时保持较高的生成质量^[65]。

3.1.6 不同深度学习模型在EEG解码中的应用场景与局限比较

前文围绕VAE、GAN、Transformer、GNN和DM介绍了EEG智能解码中常用的基础模型。上述模型分别侧重于潜在空间建模、对抗生成、长程依赖建模、脑网络结构表示和高质量条件生成,为EEG信号从低层时空特征提取到高层语义重建提供了不同技术路径。但由于EEG信号普遍存在信噪比较低、个体差异明显、跨会话稳定性不足和样本规模有限等问题,模型性能并不单纯取决于网络结构复杂度,而更依赖于模型机制与具体任务需求之间的匹配程度。控制意图和脑状态解码通常更关注分类判别能力、实时响应和跨被试泛化;视觉与语言语义解码则更强调EEG表征与图像、文本等语义空间之间的有效对齐。因此,有必要从适配场景、主要优势和潜在局限3个方面对不同基础模型进行横向比较,如表2所示。

从任务适配角度看,VAE和GAN更早应用于视觉语义解码等生成任务,适合探索EEG表征与视觉内容之间的映射关系。其中,VAE更适合小样本和不确定性建模,但生成图像细节有限;GAN能够提升生成结果的视觉真实感,但对训练稳定性和条件约束要求更高。Transformer和GNN则更偏向

表2 EEG解码中不同深度学习模型的应用场景、优势与局限比较

Table 2 Comparison of applications, advantages, and limitations of different deep learning models in EEG decoding

模型	EEG 解码适配场景	优势	局限
VAE	小样本图像重建、潜在空间建模	可以描述不确定性,潜在空间连续	生成结果平滑,细节不足
GAN	视觉语义解码、视觉语义生成	图像清晰度和真实感较好	训练不稳定,可能模式坍塌
Transformer	长时序 EEG、文本语义、跨通道依赖	善于建模长程依赖和上下文	数据需求大,小样本易过拟合
GNN	电极拓扑、功能连接、脑网络建模	适合跨脑区协同关系	依赖图结构构建,泛化受邻接矩阵影响
Diffusion	高质量图像生成、语义条件生成	生成质量高,可结合预训练模型	计算成本高,EEG 约束可能被生成先验掩盖

EEG 表征学习。Transformer 适合处理长时间窗、多通道和上下文相关的 EEG 数据,因此在语言语义解码、脑状态识别和跨模态对齐中具有优势;GNN 能够利用电极拓扑或功能连接关系,适合描述脑区间协同活动和病理状态下的网络异常。扩散模型近年来在视觉生成任务中表现突出,但在 EEG 解码中需要特别注意生成图像是否真正受到 EEG 条件约束,而不是主要依赖预训练视觉模型的分布先验。

因此,各类模型在 EEG 解码中不存在统一最优解。小样本或实时控制任务更适合轻量化结构和明确的生理先验;视觉与语言语义解码更依赖跨模态对齐和条件约束;脑状态评估和临床辅助诊断则更关注跨被试泛化、可解释性及其与临床指标的对应关系。未来 EEG 解码模型的发展重点不应只是增加网络复杂度,而应更加关注模型机制、任务范式和临床应用需求之间的匹配。

3.2 控制意图解码

控制意图解码是非侵入式 BCI 最早形成稳定技术体系的方向。运动想象、P300 和稳态视觉诱发电位分别代表自发节律调节、事件相关诱发电位和周期视觉驱动 3 类典型范式。在运动想象任务中,用户通过想象左手、右手、双脚或舌部等肢体运动,引起感觉运动皮层 μ 节律和 β 节律的事件相关去同步化或同步化变化。早期方法主要依赖人工特征和传统分类器,常用共空间模式(Common spatial pattern, CSP)、滤波器组共空间模式(Filter bank common spatial pattern, FBCSP)、功率谱密度、快速傅里叶变换(Fast Fourier transform, FFT)、短时傅里叶变换(Short-time Fourier transform, STFT)和小波变换等方法提取空间、频域或时频特征,再结合线性判别分析(Linear discriminant analysis, LDA)、支持向量机(Support vector machine, SVM)或朴素贝叶斯分类器完成意图识别^[66-68]。P300 系统主要检测目标刺激与非目标刺激在特定时间窗内的诱发电位差异,稳态视觉诱发电位则利用频谱峰值或典型相关分析比较 EEG 与刺激频率模板之间的相关性。上述方法共同形成了预处理、特征提取和分类决策的基本流程,也奠定了在线拼写和设备控制的技术基础。

随后出现的方法并非完全取代传统流程,而是在降低人工特征依赖和提高跨条件稳定性方面形成补充。黎曼几何方法直接在多通道协方差矩阵构成的流形上分类,能够保留电极间整体关系,减少对单一频带和局部特征的依赖^[7-8]。在运动想象 EEG 解码中,深度学习方法大致经历了由浅层网络到端到端时空表征学习的发展过程。早期深度神经网络(Deep neural network, DNN)多以原始 EEG、CSP 特征或 FFT 特征作为输入,但容易受到小样本和参数冗余的影响^[69-70]。随后 CNN 成为运动想象解码中最常用的深度结构:一类模型直接处理原始 EEG 矩阵,通过时间卷积和空间卷积模拟 FBCSP 的滤波过程;另一类模型先将 EEG 转换为时频图,再利用 CNN 提取判别特征。EEGNet 是其中的代表模型,

采用时间卷积和深度可分离卷积,以较少参数学习频谱和空间模式,可用于运动想象、P300和稳态视觉诱发电位等多类任务^[9-10]。Sinc-EEGNet则将首层滤波器设计为可学习带通滤波器,使模型能够自动选择任务相关频段^[42]。

在此基础上,LSTM、CNN-LSTM、多分支CNN、GNN网络和多任务学习进一步扩展了运动想象解码的建模能力。LSTM主要用于捕获EEG序列中的时间依赖,但通常需要与CNN或CSP等空间特征提取方法结合使用。CNN-LSTM结构先提取空间或时频特征,再对时间动态进行建模;多分支CNN通过不同卷积核或不同尺度分支提取多尺度特征;GNN网络和注意力机制用于描述EEG通道之间的空间拓扑关系和关键时间片段;多任务学习则通过输入重构、域判别等辅助任务提升跨被试和跨会话鲁棒性^[71-75]。因此,运动想象解码技术的发展并不是由复杂网络简单替代经典方法,而是逐步形成了人工生理特征、协方差结构、时频表示、卷积表征、时序建模和多任务约束相结合的技术路线。

当控制意图解码由离线实验走向在线交互后,算法优劣开始受到系统环节的共同制约。字符选择和光标控制不仅要求单次分类正确,还取决于刺激周期、信息传输率、反馈延迟和连续使用稳定性。面向康复设备时,运动意图检测还需要与功能性电刺激、康复机器人或外骨骼的动作时序匹配^[76]。因此,该方向的评价重点已由离线准确率逐步转向校准负担、跨会话稳定性、实时响应以及使用者能否通过反馈持续调整脑活动。对于运动想象解码而言,除准确率、 F_1 值、AUC(Area under curve)等离线指标外,跨被试验证、跨会话泛化、模型参数量、推理速度和在线稳定性也逐渐成为衡量模型实际可用性的重要因素。

3.3 脑状态解码

当BCI的目标由设备控制扩展到脑功能评估时,解码对象也由少数离散指令转向注意、警觉、疲劳、认知负荷、情绪、意识水平和疾病相关异常等多维状态。与诱发电位或运动想象不同,这些状态往往缺少明确起止点,标签也可能来自行为表现、量表评分、主观报告或临床诊断。疲劳和警觉研究通常追踪 θ 、 α 等频段功率随时间的变化,并结合反应时、眼动或任务表现判断状态下降。例如,上海交通大学情绪脑电数据集警觉性子集(SJTU emotion EEG dataset-Vigilance, SEED-VIG)将驾驶模拟过程中的EEG/眼电图(Electrooculography, EOG)信号与单位时间内瞳孔区域眼睑闭合比例(Percentage of eyelid closure over the pupil over time, PERCLOS)眼动指标结合,用连续警觉度标签描述被试在长时间任务中的警觉下降过程,为疲劳和警觉状态的连续估计提供了代表性实验基础^[77]。认知负荷研究常利用事件相关电位、前额叶 θ 活动、 α 抑制以及任务正确率等信息刻画脑资源占用程度。情绪识别则关注额区不对称、频段功率、频段耦合和跨脑区连接,并结合效价、唤醒度或离散情绪标签进行分类。睡眠分期等任务则更依赖长时间窗中的阶段转换、节律演化或异常放电。脑状态解码的核心由此从识别单个事件转向刻画持续变化的功能过程。

早期脑状态解码主要依赖人工特征和传统机器学习方法。疲劳检测中常用 θ 、 α 、 β 频段功率、 θ/β 比值、 α/β 比值、样本熵、近似熵和功率谱密度等特征,再结合SVM、LDA、随机森林或 k 近邻算法(k -nearest neighbors, KNN)完成清醒、疲劳和警觉下降状态分类。近年来,也有研究将这一思路进一步扩展到可穿戴场景。例如,Kaveh等^[78]基于无线干电极入耳式EEG系统开展睡意监测实验,在9名被试约35 h的诱导睡意数据上,SVM分类器在已见用户和未见用户条件下分别取得93.2%和93.3%的准确率,这说明传统机器学习方法在合适的可穿戴采集条件下仍具有较强应用潜力。情绪识别中常用差分熵、功率谱密度、频带能量、额区 α 不对称和相干性等特征,并在生理信号情绪分析数据库(Database for Emotion analysis using physiological signals, DEAP)和SEED等数据集上训练传统分类器。以SEED相关研究为例,差分熵特征在三分类情绪识别中取得84.22%的平均准确率,高于差分不对称特

征(Differential asymmetry, DASM)、比值不对称特征(Rational asymmetry, RASM)和能量谱等特征,同时 γ 频段被认为与情绪状态具有更强关联^[79]。认知负荷解码则常结合ERP成分、前额叶 θ 增强、顶枕区 α 抑制和行为表现,完成低负荷与高负荷状态识别^[80-82]。这一阶段的优势是特征具有一定生理可解释性,但模型依赖人工频段选择和任务设置,跨被试、跨任务和跨场景稳定性有限。

随后深度学习逐渐被用于疲劳检测、情绪识别和认知负荷评估。CNN常用于从原始EEG、时频图或空间拓扑图中提取局部时频特征,LSTM、GRU和时间卷积网络(Temporal convolutional network, TCN)用于建模状态随时间累积变化的动态过程,CNN-LSTM和CNN-Transformer等混合结构则同时利用空间分布、频谱变化和长程时间依赖。对于疲劳检测,研究重点从单个频段功率变化扩展到多通道时频图、脑网络特征和连续监测模型。对于情绪识别,方法逐渐从单一功率特征转向深度特征、通道注意力、频段注意力和多模态融合。例如,4D-aNN将EEG表示为空间、频谱和时间联合结构,并通过空间注意力、频谱注意力和时间注意力突出情绪相关脑区、频段和时间片段,在SEED数据集上取得96.25%的分类准确率,较传统人工特征方法有明显提升^[83]。对于认知负荷评估,深度模型开始关注跨任务泛化、特征迁移和不同实验范式之间的稳定表征。基于多模态数据的实时认知负荷评估(Cognitive load assessment in realtime with multimodal data, CLARE)数据集进一步体现了这一趋势,该数据集采集24名被试在MATB-II多任务操作中的EEG、ECG、皮肤电活动(Electrodermal activity, EDA)和眼动数据,并要求被试每10 s报告一次主观认知负荷,从而使认知负荷评估从任务后量表分类转向更细粒度的实时状态估计^[84]。

图神经网络、注意力机制、迁移学习和自监督学习进一步推动脑状态解码从离线分类走向鲁棒评估。图神经网络将EEG通道或脑区视为节点,通过功能连接或空间邻接关系建模跨脑区协同活动,适合情绪、疲劳和认知负荷等涉及分布式脑网络的状态识别。例如,正则化图神经网络(Regularized GNN, RGNN)将EEG电极之间的生物拓扑关系引入图结构,并结合节点级领域对抗训练和情绪分布学习,以缓解跨被试差异和标签噪声问题,在SEED和SEED-IV数据集上取得了优于多数对比方法的结果^[85]。进一步地,双注意力机制图卷积神经网络(Dual attention mechanism graph convolutional neural network, DAMGCN)通过双注意力图卷积网络同时分析脑区和频段贡献,在SEED数据集上的被试依赖实验中取得99.42%的准确率,但在被试独立实验中准确率下降至73.21%,这说明当前深度图模型虽然能够显著提升被试内识别性能,但跨被试泛化仍是脑状态解码中的关键瓶颈^[86]。注意力机制用于突出关键通道、关键频段和关键时间片段,迁移学习和领域自适应用于缓解不同被试、不同会话和不同设备之间的分布差异,自监督学习和数据增强则用于降低对大量人工标签的依赖。由此,脑状态解码的发展表现为频段功率特征、非线性动力学特征、脑网络连接、深度时空表征和跨域鲁棒学习的逐步融合,而不是由单一模型路线完成替代。

当脑状态解码进入真实应用场景后,评价标准也不再局限于离线准确率。疲劳和警觉监测需要关注提前预警能力、误报率和连续使用稳定性;情绪识别需要关注个体差异、标签主观性和跨文化泛化;认知负荷评估需要考虑任务类型、行为表现和模型可解释性。现有EEG认知负荷深度学习综述也指出,许多研究仍停留在离线分类阶段,真正面向在线或伪在线估计、可解释建模和生成式建模的工作仍然较少^[87]。因此,脑状态解码的关键问题逐渐转向如何在低信噪比、弱标签、长时间窗和强个体差异条件下,获得稳定、可解释且可迁移的脑功能表征。

3.4 文本语义解码

语言语义解码旨在从阅读文本或想象语音过程中产生的EEG活动中恢复字符、词汇、句子及其语义内容。语言加工涉及词形识别、词汇提取、句法分析和语义整合等多个阶段,并在EEG的时间、空间

和频谱活动中留下可检测信息。已有研究表明, θ 频段活动通常与记忆提取和词汇语义加工有关, β 和 γ 频段更多参与句法组织和语义整合^[88-92];从时间进程看,约200 ms主要涉及早期词形加工,约400 ms进入语义整合阶段并出现典型的N400效应^[93]。这些研究为语言信息解码提供了神经生理依据,但相关效应在单次试验中较弱,容易受到背景噪声、个体差异和任务状态波动影响,因此需要借助时序建模和表征学习方法提取稳定的语言相关信息。

早期语言解码研究主要面向预设字符、有限词汇、短语指令或想象语音类别,方法上多采用卷积神经网络、循环神经网络及其变体。卷积网络主要用于提取EEG信号中的局部时间、频谱和通道特征,循环神经网络则通过隐状态描述EEG序列的时间依赖关系。长短期记忆网络和门控循环单元利用门控结构增强长程信息保持能力,双向循环网络进一步结合前后文信息,因而被广泛用于词级EEG表征、短序列识别和想象语音分类任务^[94-96]。Sereshkeh等^[94]基于EEG信号开展Covert speech分类实验,验证了EEG在区分不同内部语言任务中的可行性;Vorontsova等^[96]进一步利用卷积神经网络和循环神经网络对9类无声语音指令进行识别,表明CNN-RNN结构能够同时建模EEG的局部特征和时序依赖。在自然阅读场景中,ZuCo数据集^[56]同步采集EEG与眼动信号,为词级语言加工和EEG语言表征研究提供了重要数据基础。部分研究还采用音素、字母、数字或方向词等低维符号作为中介,将复杂文本生成拆分为EEG意图识别和语言转换两个过程^[97-99]。这类方法降低了直接生成自然语言的难度,验证了EEG中存在可区分的语言相关信息,但输出范围受到固定词表、预设类别和符号体系限制,本质上仍以闭集分类或序列标注为主,尚未实现真正意义上的开放词汇自然语言生成。

Transformer和预训练语言模型的引入推动语言解码由闭集识别转向开放文本生成。Wang等^[49]将EEG到文本的映射建模为类似神经机器翻译的序列生成任务,利用Transformer直接建模EEG序列不同位置之间的关系,并由BART等预训练语言模型生成语法和语义相对连贯的文本^[62,100]。与依赖逐步递归的循环网络相比,Transformer更适合捕获较长时间范围内的依赖关系和句子级上下文;预训练语言模型则利用大规模文本中学习到的词汇、句法和语义知识,提高生成文本的完整性。由此,研究目标由识别预设字符和词汇逐渐扩展为恢复开放语言内容,评价指标也由分类准确率拓展到语义一致性、表达流畅性和上下文连贯性。

开放生成框架形成后,方法改进的重点逐渐由文本解码器转向EEG表征学习和跨模态对齐。Feng等^[50]在Transformer编码器与BART解码器之间引入对比学习,以增强EEG表征和文本表征之间的一致性。Tao等^[51]提出跨模态码本,将连续EEG嵌入与离散词嵌入映射到共同空间,以缩小EEG信号与语言符号之间的模态差异。Liu等^[52]在句子级EEG上开展掩码预训练,并利用多视图Transformer建模不同脑区的信息;Wang等^[53]则融合词级和句级EEG特征,使模型同时利用局部词汇线索和整体句子语义。另有研究从个体自适应编码、层次化门控循环网络和注意力机制等方面改进模型^[101-102]。这些工作表明,预训练语言模型已经具备较强的文本生成能力,近年来的研究重点更多转向如何从低信噪比EEG中提取稳定、可迁移且具有语言意义的表征。近年来,语义空间对齐和降低眼动依赖成为语言语义解码的重要方向。与直接学习EEG到词序列的映射不同,语义对齐方法先将EEG表征投射到预训练语言模型的语义空间,再由语言模型完成文本生成。Liu等^[103]将EEG表征与冻结的Flan-T5潜在空间对齐;Lu等^[104]在中文EEG文本生成中采用MiniLM嵌入作为跨模态中介;Jiang等^[105]则采用“EEG-Letter-Text”的两阶段路径,以降低直接生成句子的难度。

总体来看,语言语义解码经历了由有限字符和词汇识别,到Transformer与预训练语言模型支持的开放文本生成,再到自监督学习、跨模态对齐、语义空间映射和去眼动化的发展过程。与视觉语义解码中生成模型由变分自编码器、生成对抗网络逐步转向扩散模型不同,语言解码在BART等预训练语言模型引入后,文本生成端的整体框架相对稳定,后续进展主要集中在EEG表征学习及EEG与语言语义

空间的对齐。其核心问题仍是如何从低信噪比、个体差异显著的 EEG 信号中提取稳定且可迁移的语言信息,并减少眼动标记和特定实验范式对模型应用范围的限制。

3.5 视觉语义解码

视觉语义解码的基础在于视觉刺激的空间位置、颜色、类别和语义属性能够以时序、空间及频谱活动的形式部分反映于头皮 EEG 中。Pfurtscheller 等^[33]发现,视觉加工过程中 α 频段事件相关去同步化具有阶段性变化,早期活动主要集中于枕叶,随后向顶叶区域扩展,提示视觉信息处理经历了由感觉分析向认知加工推进的动态过程。Lutzenberger 等^[106]观察到不同视野位置的刺激可在枕叶电极诱发差异化的 40 Hz 功率分布。频谱研究还发现,视觉感知涉及跨频段协同活动,如 θ 相位对 γ 幅度的调制可能参与视觉特征绑定和跨区域信息整合^[107];不同颜色刺激也可诱发差异化的频段与区域响应^[108]。上述证据表明,视觉相关信息分布于 EEG 的时间演化、空间拓扑和频谱活动之中,为图像分类、检索和生成提供了神经生理基础。因此,视觉语义解码需要综合利用多维 EEG 特征,而非依赖单一频段或局部电极。然而,群体平均水平上较清晰的视觉诱发效应,在单次试条件下容易受到低信噪比和个体差异的影响,这也是现有方法不断由单一特征提取转向时空联合建模、自监督表征学习和跨模态语义对齐的重要原因。

视觉语义解码中的图像生成主要借鉴通用生成模型的发展。相关研究经历了变分自编码器与生成对抗网络探索、EEG 条件约束与表征增强、预训练扩散模型引入以及语义中介生成等阶段。其演进并非单纯表现为生成器结构的更替,而是研究重点由验证 EEG 能否支持类别可辨识的图像重建,逐步转向提高 EEG 条件约束、语义一致性、视觉质量和跨被试泛化能力。Brain2Image^[38]是早期探索 EEG 图像生成的代表性框架。该方法利用 LSTM 将变长 EEG 序列转换为固定长度特征,再分别接入 VAE 和 GAN 生成图像。实验表明,VAE 能够较好地保持类别轮廓,但细节较模糊;GAN 生成结果更加锐利,却更容易出现与 EEG 条件不一致的伪影。这一结果揭示了早期方法面临的基本矛盾,即视觉真实感与条件一致性难以兼顾。Wakita 等^[40]随后将解码对象由物体类别扩展至自然纹理,进一步说明 EEG 中可能不仅包含类别信息,也保留了部分与纹理等底层视觉属性相关的可解码特征。

随着条件生成思想的发展,研究重点逐渐由生成器本身转向 EEG 表征的判别性和条件约束能力。Singh 等^[39]提出的 EEG2IMAGE 框架将 EEG 特征与类别标签共同输入生成器和判别器,并通过三元组损失增强同类 EEG 表征的聚集性和不同类别之间的可分性。Mishra 等^[41]提出的 NeuroGAN 在卷积编码器中引入通道注意力,使模型能够突出与视觉重建关系较强的 EEG 通道。Song 等^[44]进一步结合时空卷积、自注意力和图注意力,并通过对比学习对齐 EEG 嵌入与图像嵌入。由此,视觉语义解码逐渐由“采用何种生成器”转向“如何提取稳定的 EEG 视觉表征并有效约束图像生成”。

DreamDiffusion^[14]将潜在扩散模型用于 EEG 视觉解码,是该方向的重要转折。该方法首先通过掩码自编码在无标注 EEG 数据上学习潜在表征,再利用交叉注意力将 EEG 嵌入注入预训练 Stable diffusion 的去噪网络。与早期直接依靠有限 EEG-图像配对样本训练生成器不同,该框架将 EEG 表征学习与图像生成相对分离:EEG 模型主要负责提取视觉语义条件,图像结构和细节则更多由预训练扩散模型提供。Lopez 等^[109]采用 ControlNet 适配器连接 EEG 表征与冻结的潜在扩散模型,以减少可训练参数并提高小样本条件下的训练效率。这些研究推动视觉语义解码由直接像素重建逐步转向预训练生成模型支持的条件生成。

近年来,语义中介成为连接 EEG 与图像生成模型的重要路径。该类方法不再直接学习高噪声 EEG 到高维图像像素的映射,而是先将 EEG 转换为 CLIP 嵌入、文本描述或视觉属性向量等结构化语义表示,再利用预训练生成模型完成图像生成。与直接预测像素相比,语义嵌入维度较低、结构更加稳定,更符合现阶段 EEG 数据规模有限和信噪比较低的特点。Mehmood 等^[54]提出的 CatVis 采用 CLIP

文本嵌入作为语义中介,并通过对称 InfoNCE 损失对齐 EEG 表征与图像文本语义。Rezvani 等^[55]利用大语言模型生成多层次图像描述,以类别、属性和场景等不同粒度的语义信息监督 EEG 表征学习。Cheng 等^[110]进一步区分高层类别语义和颜色、形状、布局等低层视觉属性,并通过 FiLM 条件调制将不同层级信息注入扩散模型的不同阶段,使生成过程具有更细粒度的控制能力。这些工作表明,视觉语义解码正在由单一类别约束发展为多层次语义和视觉属性的联合建模。但是,语义中介方法也带来了新的问题。由于语义空间通常由文本或预训练视觉语言模型定义,EEG 信号中可能包含的某些细节信息,例如精确空间布局、细微颜色变化或物体姿态,未必能够被现有语义表示完整保留。因此,语义中介虽然降低了建模难度,但也可能形成信息瓶颈。如何评估 EEG 信号向语义映射过程中的信息损失,仍是该方向有待进一步研究的问题。

3.6 评估指标

3.6.1 控制意图解码评估指标

控制意图解码主要面向运动想象、P300、稳态视觉诱发电位(Steady-state visual evoked potential, SSVEP)等 BCI 任务,其目标是从 EEG 信号中识别用户的运动意图、目标选择或注意对象,并将其转化为可执行的控制指令。与一般分类任务相比,控制意图解码不仅关注模型对不同意图类别的识别准确性,还强调系统在实时交互中的响应速度、信息传输效率和控制稳定性。因此,单一的离线分类准确率难以完整反映系统的实际性能。表 3 汇总了该任务中常用的主要评估指标。

表 3 控制意图解码各项评估指标
Table 3 Various evaluation metrics for control intention decoding

指标	核心思想	优点	局限性
Accuracy	计算正确分类样本占总样本的比例	直观反映整体识别能力,使用广泛	类别不均衡时可能掩盖少数类别识别不足
F_1 -score	综合精确率和召回率,评价模型对不同意图类别的识别能力	适合类别不均衡任务,可综合反映误报和漏检情况	不能直接展示具体类别之间的混淆关系
Confusion matrix	展示不同控制意图之间的正确分类和误分类情况	可分析类别之间的混淆关系和错误来源	难以形成单一综合性能指标
ITR	综合类别数量、识别准确率和决策时间,衡量单位时间信息传输量	能反映 BCI 系统交互效率	对实验范式、类别数量和时间窗设置较敏感
Response time	计算 EEG 输入到系统输出控制指令之间的延迟	能评价系统实时性	不直接反映控制指令是否正确
Success rate	统计用户完成目标选择或控制任务的比例	贴近实际在线控制场景	受任务难度和实验设置影响较大
Trajectory error	衡量连续控制轨迹与目标轨迹之间的偏差	适合光标、机械臂和外骨骼等连续控制任务	不适用于离散类别选择任务

分类性能是控制意图解码中最基础的评价维度,常用指标包括准确率、 F_1 值和混淆矩阵等。准确率用于衡量模型正确识别控制意图的总体比例,适合类别分布较为均衡的任务; F_1 值综合考虑精确率和召回率,能够在类别不均衡或误判代价不同的情况下更全面地反映模型表现;混淆矩阵则可进一步展示不同意图类别之间的误判关系,例如左右手运动想象之间的混淆,或 P300 任务中目标刺激与非目标刺激之间的误判,从而帮助分析模型错误来源。

除分类指标外,信息传输率是 BCI 控制任务中的重要指标。该指标综合考虑可选择指令数量、识

别准确率和单次决策时间,能够衡量系统在单位时间内传递有效控制信息的能力。对于 P300 拼写器、SSVEP 目标选择、轮椅控制和机械臂控制等应用,仅有较高准确率并不一定代表系统具有良好实用性。如果模型响应时间过长、误触发频繁或控制过程不稳定,用户仍难以实现高效交互。因此,响应时间、任务成功率和误触发率等指标也常用于在线系统评估。

对于连续控制任务,还需要进一步关注轨迹误差和控制稳定性。轨迹误差可用于衡量光标、机械臂或外骨骼运动轨迹与目标轨迹之间的偏差;控制稳定性则反映系统在连续运行过程中是否容易受到疲劳、注意波动或信号漂移的影响。总体而言,控制意图解码的评价应从离线分类性能扩展到在线交互性能,综合考虑准确性、实时性和可控性。只有在较高识别准确率、较低响应延迟和稳定控制输出同时满足的情况下,相关模型才具备进一步应用于实际 BCI 系统的潜力。

3. 6. 2 脑状态解码评估指标

脑状态解码主要面向癫痫发作检测与预测、意识障碍评估、精神状态识别及脑卒中康复状态评估等任务。与控制意图解码不同,脑状态解码的目标并不是识别用户的即时控制指令,而是从 EEG 信号中判断个体所处的疾病状态、认知状态或风险状态。因此,该类任务的评价不仅需要考察模型的分类性能,还需要关注异常状态检出能力、误报控制能力、风险预测能力以及模型输出与临床量表或医学结局之间的一致性。表 4 汇总了该任务中常用的主要评估指标。

表 4 脑状态解码各项评估指标
Table 4 Various evaluation metrics for brain state decoding

指标	核心思想	优点	局限性
Accuracy	计算模型正确识别脑状态的总体比例	简单直观,便于不同方法比较	类别不均衡时可能高估模型性能
F_1 -score	综合精确率和召回率,评价异常状态识别效果	适合类别不均衡的脑状态分类任务	不能体现不同判定阈值下的整体性能
Sensitivity	衡量真实异常状态被正确识别的比例	适合评价异常状态检出能力,能反映漏检风险	可能忽略误报问题
Specificity	衡量正常状态被正确排除的比例	能反映误报控制能力	单独使用时不能体现异常状态检出能力
ROC-AUC	衡量不同阈值下模型区分正常与异常状态的能力	综合反映模型整体判别能力	类别极度不均衡时可能不够敏感
Prediction horizon	衡量模型在事件发生前提前预警的时间长度	适合癫痫发作预测等风险预警任务	不适用于静态脑状态分类
False alarm rate	统计模型错误报警的频率	能反映长期监测和临床预警的可接受性	受监测时长和阈值设置影响较大
Clinical correlation	分析模型输出与临床量表或功能评分之间的相关性	能评价模型的临床解释意义	受量表可靠性和样本规模影响
External validation	在独立数据集或不同中心数据上验证模型	更接近真实临床应用场景	数据获取难度较高,实验成本较大

在脑状态分类任务中,准确率和 F_1 值仍是常用基础指标。准确率能够反映模型对不同脑状态的总体分类能力,但在医学场景中,数据往往存在类别不均衡问题。例如,癫痫发作期样本通常远少于非发作期样本,意识障碍患者中的有效反应样本也可能较少,此时仅依赖准确率可能高估模型性能。因此,

灵敏度和特异性在脑状态解码中具有重要意义。灵敏度用于评价模型识别异常脑状态的能力,例如能否发现发作前状态、意识残留反应或抑郁风险状态;特异性则用于评价模型排除正常状态的能力,反映系统控制误报的水平。二者共同决定模型在临床筛查、长期监测和风险预警中的可靠性。

受试者工作特征曲线下面积(Area under the receiver operating characteristic curve, ROC-AUC)是脑状态解码中常用的综合判别指标,能够反映模型在不同阈值下区分正常状态与异常状态的整体能力。对于阳性样本较少的医学任务,还可结合精确率-召回率曲线下面积(Area under the precision-recall curve, PR-AUC)进一步评价模型对异常状态的识别效果。对于癫痫发作预测等动态风险评估任务,仅报告分类性能并不足够,还需要引入预测提前量和误报率等指标。预测提前量用于衡量模型在事件真正发生前多长时间发出预警,是评价预警系统实用性的重要指标;误报率则反映系统错误报警的频率,过高的误报会降低长期监测和临床应用中的可接受性。

对于脑卒中康复、意识障碍和精神障碍等应用,模型输出还应与临床评分或功能量表进行关联分析。例如,脑卒中康复评估可关注EEG解码结果与运动功能评分之间的相关性;意识障碍评估可分析模型预测结果与临床意识量表之间的一致性;抑郁或焦虑识别则可比较模型输出与症状量表评分之间的关系。这类指标能够进一步说明EEG解码结果是否具有临床解释意义,而不仅仅是完成统计分类。此外,由于EEG信号存在显著个体差异和采集差异,跨被试、跨中心和跨数据集验证也是脑状态解码评价中的重要环节。后续研究应同时报告分类性能、医学诊断性能、风险预测性能和泛化性能,并明确被试内、跨被试及外部验证设置,以更全面地评价脑状态解码模型的实际应用价值。

3.6.3 文本语义解码评估指标

文本解码的评价不仅要考察生成文本与参考文本在词汇层面的匹配程度,还需判断二者是否保持一致的语义,以及生成结果在字符或词汇层面存在多大偏差。由于同一语义可以通过不同词语和句式表达,词面不完全一致并不一定意味着解码错误。因此,现有评价通常从词面匹配、语义一致性和编辑误差3个层面综合衡量模型性能。表5汇总了该任务中常用的主要评估指标。

词面匹配指标主要包括BLEU、ROUGE和METEOR。BLEU通过计算生成文本与参考文本之间

表5 EEG信号生成文本各项评估指标
Table 5 Various evaluation metrics for EEG generated texts

指标	核心思想	优点	局限性
BLEU	计算生成文本与参考文本之间的词汇重合程度	计算简单,广泛使用,便于跨研究比较	对同义表达和句式变化敏感,可能低估合理改写
ROUGE	强调召回率,评估生成文本是否覆盖参考文本中的关键信息	能较好反映关键信息覆盖情况	更关注词面重合,语义理解能力有限
METEOR	在 n -gram匹配基础上加入词干还原和同义词匹配	对表达变化具有一定容忍度	对复杂语义关系建模有限
BERTScore	利用预训练BERT上下文嵌入计算Token级语义相似度	能识别同义改写,更关注语义一致性	依赖预训练语言模型能力
BLEURT	在预训练语言模型基础上进一步训练的文本质量评估指标	与人类评价一致性较高	对训练语料、模型规模和语言适配能力敏感
WER	通过插入、删除、替换操作数衡量生成文本与参考文本偏差	适合逐词精确恢复任务	对开放式生成过于严格
TER	衡量将生成文本转换为参考文本所需的最小编辑操作数	能量化文本修改成本	对合理语义改写不够宽容

的 n -gram 重合程度评价词汇一致性,ROUGE 更关注参考文本中关键信息的覆盖程度,METEOR 则通过词干还原和同义词匹配提高对表达变化的容忍度。这类指标计算简便,便于不同方法之间进行比较,但对同义改写和句式变化的识别能力有限。BERTScore 和 BLEURT 等语义指标利用预训练语言模型的上下文表征,衡量生成文本与参考文本在语义空间中的接近程度,更适合评价开放文本生成。词错误率(WER)和翻译错误率(TER)则通过统计插入、删除、替换等编辑操作,反映生成文本相对于目标文本的偏离程度,能够较直观地评价字符或词汇的精确还原水平,但可能将语义正确而措辞不同的表达判定为错误。词汇重叠度、语义相似度和错误率分别反映文本解码性能的不同方面,任何单一指标都难以证明模型完整恢复了目标语言内容。当前研究的主要问题是评价协议尚未统一,不同工作在数据集、被试内或跨被试划分、文本后处理方式及指标组合方面存在较大差异,导致结果难以直接比较。后续研究应同时报告词面匹配、语义一致性和编辑误差等指标,并明确语言模型校正或补全的具体流程;在使用预训练语言模型进行后处理时,宜分别报告处理前后的结果,以区分 EEG 解码所提供的信息与语言模型先验带来的改进。只有在数据划分、输出形式和评价流程相对一致的前提下,才能更准确地判断不同文本解码方法的实际进展。

3.6.4 视觉语义解码评估指标

视觉语义解码的评价不能只关注生成图像是否清晰,更需要判断其是否保留了原始刺激中的类别、结构和语义信息。因此,现有评价指标主要回答 3 个相互关联的问题:生成图像能否被识别为正确类别,是否在视觉结构上接近目标图像,以及是否与原始刺激保持语义一致。只有将这 3 个层面的结果结合起来,才能较为完整地评价模型的解码能力。表 6 汇总了该任务中常用的主要评估指标。

表 6 EEG 信号生成图像各项评估指标
Table 6 Various evaluation metrics for EEG generated images

指标	核心理念	优点	局限性
Top- k accuracy	将生成图像输入预训练分类器,检查正确类别是否出现在前 k 个预测类别中	直观反映类别信息	难以衡量细节一致性
IS	基于 Inception 网络预测结果,衡量生成图像清晰度与类别多样性	计算简单	对模式坍塌不敏感
FID	比较生成图像与真实图像在 Inception 特征空间中的分布距离	反映整体质量	对样本量较敏感
KID	基于核方法计算生成图像与真实图像特征分布差异	小样本更稳定	使用范围相对较少
SSIM	衡量生成图像与真实图像在亮度、对比度和结构上的相似性	突出结构保真度	与人类感知一致性有限
LPIPS	利用深度特征衡量图像感知相似性	更符合人类视觉感知	依赖预训练网络特征
CLIP score	计算生成图像与类别标签或文本描述在 CLIP 嵌入空间中的相似度	衡量语义一致性	依赖 CLIP 表征能力
Feature distance	利用 AlexNet、SwAV 等预训练模型的特征距离衡量感知相似性	比较深层语义特征	结果依赖特征提取模型
Human evaluation	由受试者判断生成图像是否与原始刺激一致或可识别	可补充自动指标不足	主观性较强

类别信息通常采用 Top- k accuracy 评价,即利用预训练分类器判断目标类别是否出现在生成图像的前 k 个预测结果中。该指标能够反映生成结果是否保留了基本类别特征,但无法评价颜色、姿态、背景和局部结构等细节。图像质量与目标相似性则常通过 Inception score、Fréchet inception distance 和

Kernel inception distance 等分布指标,以及结构相似性指数和学习感知图像块相似度等成对指标进行衡量。前一类指标侧重生成图像整体分布的真实性与多样性,后一类指标更关注生成结果与原始刺激之间的结构或感知差异。随着跨模态模型的发展,CLIP score 及基于预训练网络的特征距离也被用于衡量生成图像与类别标签、文本描述或目标图像之间的语义一致性,人工评价则可作为自动指标的补充。需要注意的是,较高的分类准确率、较低的特征距离或较好的视觉质量分别反映不同层面的性能,任何单一指标都不能证明模型完整恢复了原始视觉内容。当前研究更突出的问题是评价协议缺乏统一,不同工作在数据集、训练测试划分、被试内或跨被试设置以及指标组合上存在较大差异,导致结果难以直接比较。后续研究应在统一数据划分的基础上,同时报告类别判别、图像相似性和语义一致性指标,并明确区分被试内、跨被试及跨数据集验证,从而更准确地判断不同方法在视觉信息解码方面的实际进展。

4 EEG 智能解码技术的临床应用

为使临床应用与前述技术路径形成清晰对应,本节按照控制意图、脑状态、语言语义和视觉语义 4 类解码对象组织内容。控制意图解码主要服务于运动功能康复;脑状态解码覆盖癫痫、意识障碍以及精神疾病的检测、监测与评估;语言语义解码面向失语症康复和沟通辅助;视觉语义解码则探索残余视觉功能评估与视觉障碍辅助。为进一步比较不同脑健康应用中 EEG 深度解码方法的适用特点,本文从疾病或应用场景、主要 EEG 特征、解码任务和常用方法 4 个方面,对前述研究进行归纳总结,结果如表 7、8 所示。

表 7 脑健康应用场景中的 EEG 深度解码方法比较
Table 7 Comparison of EEG deep decoding methods in brain health applications

解码对象	疾病或应用场景	主要 EEG 特征	解码任务	常用方法
控制意图解码	卒中中运动功能障碍	μ 和 β 节律异常、ERD 减弱、运动区功能连接下降、半球间网络失衡	运动想象分类、运动意图识别、康复评估、闭环反馈	CSP、FBCSP、LDA、SVM、EEGNet、BCI-FES、康复机器人
	癫痫	棘波、尖波、棘慢复合波、高频振荡、功能连接异常、信号复杂度变化	发作检测、发作前状态识别、发作预测、预警	SVM、随机森林、CNN、CNN-LSTM、GRU、GNN、Transformer
	脑状态解码 意识障碍	δ 慢波增强、背景反应性降低、P300 异常、 α 和 θ 节律反应变化、运动想象相关 ERD 变化	意识状态评估、残余意识检测、隐匿指令跟随识别、有限辅助交流	P300、SSVEP、CCA、运动想象 BCI、CNN
	抑郁症、焦虑症等精神疾病	额叶 α 不对称、 θ 和 β 功率变化、睡眠节律异常、脑网络连接异常	患者识别、状态监测、症状评估、疗效预测	CNN、Transformer、GNN、图卷积、图注意力网络、对比学习、多模态融合
文本语义解码	失语症、闭锁综合征、严重沟通障碍	N400、P300、语言相关 θ 、 β 和 γ 活动,词汇加工和语义整合相关 EEG 变化	语言理解评估、语义识别、有限文本生成、辅助交流	CNN、RNN、Transformer、BART、T5、LLM、DeWave
视觉语义解码	视觉功能障碍、残余视觉评估、视觉辅助	VEP、SSVEP、P300、枕叶 α 和 γ 活动,视觉类别和注意相关 EEG 特征	视觉反应检测、视觉注意识别、图像类别解码、视觉辅助反馈	VEP、SSVEP、CCA、CNN、Transformer、CLIP 对齐、视觉皮层刺激

表 8 近年代表性 EEG 临床解码研究及效果比较

Table 8 Recent representative EEG clinical decoding studies and reported effects

解码对象	疾病或应用场景	代表方法	代表性效果	临床意义
控制意图 解码	脑卒中运动 功能障碍	MI-BCI+FES ^[111] 、 BCI-机器人 ^[112]	FMA-LE ^[111] 提高 6.64 分， 43.8% 达到最小临床重要 差异;BCI-FES ^[17] 上肢康复 SMD=0.50	促进主动运动训练和运 动功能恢复
	癫痫	多维 Transformer ^[113] 、 CNN-LSTM、GNN	CHB-MIT ^[114] 数据集灵敏度 98.24%，特异性 97.27%，假 警报率 0.033 次/h	支持发作预警和长期 EEG 监测
脑状态解 码	意识障碍	任务态 EEG/fMRI、P300、 运动想象 BCI	241 例无行为反应患者中 60 例检出认知运动分离，检 出率 25%	发现隐匿意识，补充行 为量表评估
	抑郁症等精神疾病	静息态 EEG 深度学习 ^[115] 、 GNN、多模态融合 ^[116]	抑郁症分类平均准确率 67.5%；SSRI ^[115] 疗效预测准 确率 79%	辅助疾病识别和个体化 治疗预测
文本语义 解码	失语症、闭锁综合 征、沟通障碍	E2T-PTR ^[53] 、 EEG2Text ^[52] 、DeWave ^[15]	BLEU-1 为 59.20%， BLEU-4 为 44.63%；部分指 标较基线提升约 5%	支持语言功能评估和有 限辅助交流
视觉语义 解码	视觉功能障碍、视 觉辅助	NICE-EEG ^[44] 、语言引导 EEG 图像识别 ^[117]	200 类零样本识别 Top-1 为 15.6%，Top-5 为 42.8%； EEG2 数据集 Top-1 为 19.7%，Top-5 为 51.5%	探索残余视觉评估和视 觉辅助

4.1 控制意图解码与运动功能康复

脑卒中后的 EEG 异常主要表现为运动相关节律减弱和半球间感觉运动网络失衡。运动执行或运动想象时,损伤侧感觉运动皮层 μ 节律和 β 节律的事件相关去同步化通常减弱,其变化程度与运动功能受损有关^[118];损伤侧与健侧半球之间的相干性下降,则可在一定程度上反映皮质脊髓通路受损及运动网络重组^[119]。跨频耦合变化也被用于评价大尺度网络调节与局部感觉运动加工之间的协调能力^[120]。这些 EEG 表型随病程发生变化,急性期常见 δ 、 θ 慢波活动增加,慢性期则更多表现为损伤侧运动区募集不足和健侧半球代偿性激活。因此,EEG 在卒中康复中的作用不仅是识别患者是否产生运动意图,还可用于评估残余运动网络功能并追踪训练过程中的神经可塑性变化。

在临床应用中,运动意图解码主要承担功能评估和闭环康复两类任务。离线分析通过量化事件相关去同步化、频段功率、功能连接和跨频耦合,评价患者运动功能及干预前后的脑网络变化;在线 BCI 则实时识别患者想象手、腕或下肢运动时产生的 EEG 模式,并驱动功能性电刺激或康复机器人,使主动运动尝试与外周感觉反馈相结合^[80]。运动想象识别可采用共空间模式结合线性判别分析或支持向量机,也可使用 EEGNet、Sinc-EEGNet 等轻量网络提取时空与频谱特征^[10,42]。但从临床角度看,模型结构并非主要评价目标,更重要的是其能否适应卒中患者病灶位置、节律峰值和残余运动能力的个体差异,并在多次训练中稳定触发及时反馈。

Biasiucci 等^[17]的随机对照研究为 BCI 辅助卒中康复提供了较有代表性的证据。该研究在检测到患者运动意图后触发上肢功能性电刺激,训练后患者 Fugl-Meyer 上肢评分得到改善,且行为获益伴随脑

网络功能连接变化,提示闭环训练可能通过反复耦合中枢运动意图与外周感觉反馈,促进感觉运动网络重组。这类研究表明,BCI的临床意义并不只是提高运动想象分类准确率,而是将患者残余运动意图转化为可重复的康复训练机会。但是,现有研究仍普遍存在样本量较小、训练剂量和随访时间不一致、对照不足及跨中心验证有限等问题。现阶段的运动意图解码更适合作为常规康复的辅助工具,未来需进一步明确适用患者、最佳训练强度和长期疗效,并验证EEG变化能否稳定对应实际运动功能恢复。

控制意图解码与运动功能康复是EEG-BCI临床转化中患者级证据相对较多的方向。早期研究主要在健康受试者中验证运动想象、P300和稳态视觉诱发电位等范式的可解码性,更多体现技术可行性;近年来,研究对象逐渐扩展至脑卒中、脊髓损伤和其他运动功能障碍患者,并与功能性电刺激、康复机器人和外骨骼训练等干预方式结合。部分研究已开始采用小样本临床试验或随机对照设计,并以运动功能评分、康复改善幅度和最小临床重要差异等指标评价效果。但现有研究仍存在样本量有限、训练方案不统一、随访时间较短和跨中心验证不足等问题,距离常规临床应用仍需进一步验证。

4.2 脑状态解码与临床评估

脑状态解码关注持续性或动态变化的神经功能状态,其临床价值不仅在于区分患者与健康人群,更在于识别常规行为观察或临床检查难以捕捉的异常变化。癫痫、意识障碍以及精神障碍分别代表3类不同需求:癫痫强调异常状态的检测和提前预警,意识障碍关注残余意识和隐匿指令反应,精神障碍则更重视持续性脑功能异常、症状异质性和治疗反应。由于3类疾病的信号表现、时间尺度和临床终点不同,EEG解码的评价也应分别围绕假警报、增量检出、纵向稳定性和临床决策价值展开。

癫痫EEG解码主要用于识别发作间期、发作前期和发作期之间的状态转换。发作间期常见棘波、尖波和棘慢复合波,部分患者在发作前还会出现高频振荡、功能连接增强和信号复杂度下降等变化^[113,121]。自动发作检测可以辅助长期EEG阅图,而发作预测则试图在临床症状出现前识别不稳定状态,为患者采取防护措施、调整用药或实施闭环刺激争取时间。Olejarczyk等^[121]利用多通道EEG中的同步和形态学特征自动识别棘慢波,并将检测结果用于评价干预前后的EEG变化,说明自动解码既可减轻人工阅图负担,也可为治疗效果提供量化依据。Hu等^[122]将功率谱、小波等人工特征与深度网络提取的表征结合,用于不同癫痫状态分类,体现了电生理特征与数据驱动方法的互补作用。对于连续监测,局部波形识别适合发作检测,连续时间窗建模更适合发作前状态分析;但临床应用的关键并非模型结构复杂程度,而是能否在长时间记录中维持较高灵敏度和较低假警报率。目前公开数据普遍存在发作样本少、类别不平衡和跨患者差异显著等问题,且相邻时间窗或同一次发作被同时用于训练和测试时容易高估性能。因此,研究除报告准确率或曲线下面积外,还需说明单位时间假警报次数、有效提前量、连续监测时长和跨患者表现,并明确预警后可采取的实际处置措施。

意识障碍患者可能因运动输出受损而无法通过行为反应表达其真实认知状态,EEG解码因而主要用于补充行为量表、发现残余意识并建立有限沟通通道。被动范式通过听觉诱发电位、患者姓名刺激、P300任务及静息态节律评估皮层反应;主动范式则要求患者按照指令进行运动想象或注意调节,以判断其是否能够理解并执行任务。无反应觉醒综合征患者通常表现为慢波活动增强和背景反应性降低,微意识状态患者则可能保留短暂的刺激反应和睡眠-觉醒节律^[123]。Cruse等^[124]对16例临床诊断为植物状态的患者开展床旁运动想象检测,发现部分缺乏外显行为反应的患者能够按照指令产生可区分的感觉运动节律变化,提示EEG可能发现行为评估遗漏的隐匿意识。P300和稳态视觉诱发电位由于训练负担较低,也被用于目标刺激识别和“是/否”选择^[125-126]。但是,被动诱发反应只能说明患者保留一定程度的信息加工,主动任务阳性才更接近有意识的指令跟随,两类证据不能等同解释。患者觉醒程度、镇静药物、视听功能和日内波动均可能造成假阴性,因此重复检测、个体化阈值及EEG相对于行为量表的增量检出率,比单次分类准确率更具有临床意义。DeWave和EEG2Text等连续EEG文本解码

方法^[15,52]目前主要在健康受试者和受控任务中验证,尚不能支持意识障碍患者的自由交流;近期更现实的方向仍是围绕疼痛、口渴、冷暖和基本照护需求建立可靠的有限选择通道。

抑郁、焦虑等精神疾病的EEG改变通常表现为持续、分布式且个体差异明显的功能异常,而非具有明确起止点的事件。研究较多关注额叶 α 不对称、 θ 和 β 功率变化、睡眠节律异常,以及默认模式、显著性和认知控制网络之间的连接失衡^[127-128]。这些指标容易受到年龄、药物、睡眠、共病和记录状态影响,单一频段或单一电极尚不足以形成稳定的个体诊断标志。近年来,EEG结合机器学习和深度学习的方法被进一步用于抑郁症识别、症状分型和治疗反应预测。Watts等^[129]对抑郁症EEG治疗反应预测研究进行机器学习荟萃分析,提示EEG模型在区分治疗反应者与非反应者方面具有一定潜力,但仍存在样本量有限、特征差异较大和外部验证不足等问题。Olbrich等^[115]进一步将EEG用于重性抑郁障碍诊断和SSRI疗效预测,说明深度学习模型能够从静息态EEG中提取与疾病状态和药物反应相关的表征。Jiao等^[116]则在EMBARC队列中整合静息态fMRI和EEG连接特征,利用图神经网络预测舍曲林和安慰剂治疗后的个体症状变化,体现了多模态脑网络建模在个体化治疗预测中的潜力。目前多数研究仍以患者一对照分类和症状相关性分析为主,但更具临床意义的方向是病程监测和治疗反应预测。Zhdanov等^[130]在CAN-BIND-1队列中利用122例抑郁症患者治疗前的静息态EEG预测艾司西酞普兰疗效,表明基线EEG可能为药物反应评估提供辅助信息。Schwartzmann等^[131]基于CAN-BIND队列分析治疗过程中EEG振荡变化与症状改善之间的关系,发现 θ 、 δ 和 α 功率的纵向变化与艾司西酞普兰或认知行为治疗后的症状改善相关,进一步说明EEG不仅可用于基线预测,也可能用于疗效监测。这类研究的价值不在于替代临床诊断,而在于识别仅凭症状量表难以区分的患者异质性,并帮助判断不同个体可能的治疗获益。相比之下,焦虑症研究目前更多集中于患者识别、症状严重程度及共病差异,能够直接预测治疗结局的前瞻性证据仍相对有限。后续研究需要在独立患者队列中检验EEG模型是否能够在量表、人口学信息和既往治疗史基础上提供增量价值,并通过纵向随访确认预测结果是否稳定。将EEG结果转化为图像或文本形式目前仍属于探索性应用,更合理的近期定位是形成可解释的结构化指标或辅助报告,而不应将生成内容理解为患者主观体验的直接恢复。

脑状态解码在3类疾病中的临床成熟度并不一致。癫痫已经形成从自动检测向连续预警发展的较明确路径,意识障碍的主要价值是提高残余意识检出率并支持有限沟通,精神障碍则正由群体分类转向个体化疗效预测。三者共同面临跨患者泛化、纵向稳定性和临床增量价值不足的问题。只有当解码结果能够稳定改变监测、评估或治疗决策时,脑状态识别才真正转化为具有临床意义的BCI应用。

脑状态解码不同任务之间的患者研究基础存在明显差异。癫痫检测已有较多真实患者EEG和公开临床数据集支持,自动发作检测已积累较多临床研究基础,但发作预测仍受个体差异、误报率要求和前瞻性验证不足的限制。意识障碍评估主要依赖P300、运动想象、稳态视觉诱发电位和任务态EEG等范式,目前多属于观察性研究或小样本床旁检测,主要用于辅助发现残余意识和隐匿指令跟随。精神疾病EEG解码则多用于抑郁、焦虑的状态识别、分型和疗效预测,证据主要来自队列研究和模型预测实验,尚不能作为独立诊断或治疗决策工具。

4.3 文本语义解码与语言功能康复

文本语义解码主要面向语言理解、语言表达和交流障碍等脑功能问题,其目标是从EEG信号中提取与词汇、句子语义或交流意图相关的神经表征,并将其转化为文本、类别标签或有限交流指令。与运动意图解码相比,语言相关EEG信号更弱,且更容易受到阅读方式、注意状态、眼动、个体语言能力和任务设计的影响。因此,文本语义解码在临床中的意义并不只是生成完整文本,而是为语言功能评估和辅助交流提供新的神经信息来源。

在语言功能康复中,文本语义解码具有两类潜在应用。第1类是语言功能评估,主要用于分析失语症、意识障碍或神经退行性疾病患者是否仍保留一定程度的词汇理解、语义加工和指令跟随能力。近年关于意识障碍语言与交流能力的综述指出,部分患者虽然缺乏稳定的外显行为反应,但仍可能在EEG或其他神经信号中表现出语言理解、语义加工或指令跟随相关反应,这提示脑信号可作为行为量表之外的补充评估信息^[132]。第2类是辅助交流,即将患者残余语言意图转化为有限文本输出、字符选择、语音输出或护理需求表达。近年来,临床辅助交流研究已经从传统EEG拼写器逐渐扩展到脑到文本和脑到语音神经假体。Willett等^[133]基于运动皮层内记录实现了尝试手写运动到文本的实时解码,在瘫痪受试者中展示了高性能脑到文本通信能力。Willett等^[134]进一步利用植入式神经接口从尝试发声相关活动中解码文本,使严重瘫痪者能够以更接近自然交流的速度表达句子。Card等^[135]在一名肌萎缩侧索硬化(Amyotrophic lateral sclerosis, ALS)严重构音障碍患者中构建快速校准的语音神经假体,报道系统可在较短训练后恢复较高水平的语音交流能力。

更进一步,语音神经假体正在从字符和文本输出走向自然语音合成。Littlejohn等^[136]通过记录言语感觉运动皮层活动,将尝试发声过程流式转换为语音输出,并利用患者发病前录音重建个体化声音。Wairagkar等^[137]在一名ALS失语患者中通过256个植入式微电极记录腹侧中央前回神经活动,实现接近即时的脑到语音合成,并结合闭环音频反馈提高交流自然性。这些研究说明,临床语言BCI的目标正在从低速字符选择扩展到更自然的语音交流。在非侵入式EEG路线中,近年研究更多集中于提高拼写器效率、降低校准成本和引入语言模型辅助。2024年以来,部分研究开始将P300拼写器与大语言模型结合,用语言模型进行词汇预测、句子补全和刺激优化,以减少按键次数、降低拼写负担并提高通信效率^[138-139]。但是,当前该技术距离临床语言康复仍有较大差距。首先,开放词汇生成结果容易受到语言模型先验影响,生成文本可能语义相近,但并不一定等同于真实脑内语言表征,因此不能直接解释为患者主观思想。其次,健康受试者在阅读任务中的EEG模式与失语症或意识障碍患者存在显著分布差异,跨人群迁移仍不稳定。此外,语言康复研究更关注患者是否恢复理解、表达和交流能力,而不仅是BLEU、ROUGE或BERTScore等文本指标。因此,未来研究需要将解码性能与临床语言量表、交流成功率、照护决策改善以及长期康复结局结合起来。现阶段,文本语义解码更适合作为语言功能评估和有限辅助交流的探索性工具,而不宜被理解为已经能够准确读取患者完整思想的临床技术。

文本语义解码目前仍主要建立在健康受试者实验基础上,常见范式包括受控阅读、想象语音和句子级EEG解码。这些研究说明EEG中存在与词汇加工、语义整合和语言意图相关的可解码信息,但向临床患者迁移仍存在明显困难。失语症、闭锁综合征和意识障碍患者可能伴随语言理解受损、注意波动、任务配合困难和脑损伤异质性,使健康受试者模型难以直接复用。现阶段,少量患者研究多集中于有限词表识别、指令跟随判断和辅助交流探索,尚缺乏大样本随机对照试验和长期应用证据,因此该方向更适合作为语言功能评估和有限辅助交流工具。

4.4 视觉语义解码与视觉功能辅助

视觉语义解码主要关注EEG信号中与视觉感知、物体识别和视觉注意相关的神经表征,其临床应用可分为视觉功能评估和视觉功能辅助两个方向。前者强调通过EEG判断患者是否保留视觉通路反应、视觉注意和高级视觉加工能力。后者则试图将外部视觉信息转化为患者可感知或可利用的神经反馈,从而帮助严重视觉障碍患者完成环境感知、目标定位和日常行动。

在视觉功能评估方面,视觉诱发电位和稳态视觉诱发电位已被广泛用于评估视觉通路完整性、残余视觉反应和视觉注意能力。对于不能稳定配合主观检查的患者,视觉诱发电位(Visual evoked potential, VEP)可以作为客观神经电生理指标,辅助判断视网膜、视神经和视觉皮层通路是否仍能对刺激产生反应。近期Clementi等^[140]在慢性意识障碍患者中分析视觉诱发电位、听觉诱发电位、体感诱发电位

和事件相关电位,发现诱发电位和事件相关电位有助于区分无反应觉醒综合征和最小意识状态,说明视觉相关EEG指标可为意识障碍患者的神经功能评估提供补充证据。同时,SSVEP和C-VEP范式也被用于视觉注意和目标选择评估。近年研究开始引入深度学习和自适应识别方法,以提高单次视觉诱发电位解码的稳定性和跨会话鲁棒性^[141]。因此,视觉语义解码在临床中的近期应用并不主要表现为生成清晰图像,而是更多用于判断视觉通路是否存在反应、患者是否能够完成视觉注意选择,以及视觉功能是否随康复或疾病进展发生变化。

在视觉功能辅助方面,BCI的作用不仅是读出视觉相关脑活动,也包括将外部图像信息输入视觉系统。对于视网膜、视神经或外周视觉通路严重受损的患者,视觉皮层刺激和视觉假体试图绕过受损通路,通过摄像头采集环境图像,再将边缘、轮廓、障碍物或目标位置转化为电刺激模式,使患者产生光点、轮廓或简化图形感知。Fernández等^[142]在一名因毒性视神经病变导致完全失明16年的受试者中植入96通道Utah微电极阵列,通过视觉皮层内微刺激诱发可辨别光幻视,受试者能够识别部分字母和物体边界,研究初步证明了慢性皮层内微刺激在人体视觉皮层中的安全性和可行性。该研究说明,视觉皮层假体已从早期概念验证进入单例人体临床探索阶段,但其输出仍以低分辨率光点和轮廓为主。

从临床角度看,视觉语义解码的评价不能仅依赖生成图像质量或分类准确率。对于视觉评估任务,更重要的是其能否提高视功能损伤定位、残余视觉识别和康复效果追踪的准确性。对于人工视觉系统,则应重点考察安全性、长期稳定性、患者主观可接受性以及是否真正改善导航、避障、物体定位、阅读能力和生活自理能力。现阶段,视觉语义解码更适合作为视觉功能评估和视觉辅助技术的前沿探索。未来若要进入稳定临床应用,还需要解决刺激编码个体化、低分辨率感知解释、长期植入安全性、跨患者泛化和真实场景有效性等问题。

视觉语义解码的临床转化仍处于较早阶段。现有研究多基于健康受试者和标准化视觉刺激,主要验证视觉诱发EEG是否能够支持类别判断和语义重建。相比之下,面向视觉障碍、意识障碍或神经损伤患者的研究仍较有限,而视觉通路损伤、注意力下降、眼动控制异常和脑网络重组等因素都会影响模型稳定性。因此,该方向目前更适合作为残余视觉反应评估、视觉注意检测和视觉辅助反馈的探索性工具,距离稳定的临床视觉辅助应用仍需真实患者队列、纵向随访和多中心验证支持。

5 BCI解码的局限与发展方向

5.1 数据异质性与跨中心泛化

跨中心泛化困难同时来自测量体系和临床人群两个层面。设备、电极布局、参考方式、采样率、滤波流程和任务范式会改变EEG的统计分布;病程、药物、年龄、共病和疾病亚型又会改变真正需要识别的神经模式。前者属于可控制和记录的技术异质性,后者则是临床问题本身的一部分。若二者在数据设计和元数据中没有被区分,模型可能把中心、设备或流程特征误认为疾病信号,也可能在过度校正时消除具有临床意义的病理差异。因此,未来的数据标准化不应被理解为所有中心必须采用完全相同的设备和处理流程,而应建立可追溯的最低信息集、统一的数据质量要求和分层验证协议。研究至少需要记录电极布局、参考方式、阻抗、采样率、伪迹处理、药物状态、疾病阶段和任务完成度,并明确区分同数据集交叉验证、跨被试测试、跨设备测试和跨中心外部验证。除报告内部性能外,还应呈现模型从内部验证到外部验证的性能衰减,以判断方法究竟学习了稳定的EEG规律,还是依赖特定中心的数据特征。多中心基础设施的建设还需要覆盖床旁、门诊和家庭环境。真实场景中的伪迹更多、任务依从性更不稳定,却能够揭示实验室数据难以呈现的设备操作、患者负担和长期运行问题。

未来研究应在统一核心数据元素的基础上保留临床异质性,并预先规定哪些差异需要校正、哪些差异应作为预测对象保留。例如,设备频响和参考方式造成的偏移应尽量控制,而疾病阶段和药物反

应可能正是模型需要识别的信息。只有将技术偏移、人口学差异和病理异质性分别建模,多中心研究才能同时提高可比性与临床代表性。

5.2 个体差异与长期适配

即使在同一疾病中,头部解剖、功能区位置、认知策略、病程和药物状态也存在明显差异。试次级随机划分会使训练集和测试集共享同一受试者的稳定特征,从而把身份信息误当作疾病或任务信号;在视觉和语言任务中,重复刺激和相邻时间窗还可能造成内容泄露。因此,临床研究应优先按照受试者、中心和时间划分数据,并报告模型在未见个体和后续随访数据上的性能,而不是只展示被试内随机划分得到的最优结果。个体化建模需要在“每位患者独立训练”和“完全统一的群体模型”之间取得平衡。群体模型能够利用较大样本学习共同结构,但可能忽略病灶位置、节律峰值和认知策略差异;患者特异模型更贴近个体,却容易受样本量不足和标签波动影响。较为可行的发展路径是先利用群体数据或预训练模型学习共享表征,再通过少量个体数据调整决策边界。适配方式还应与患者能力相匹配:意识障碍患者难以完成长时间主动任务,更依赖静息或被动诱发信号;慢性卒中患者则可能通过重复训练逐渐形成相对稳定的控制策略。

健康受试者模型向患者群体迁移是EEG智能解码临床转化中的关键瓶颈。当前视觉语义解码和文本语义解码研究多在健康受试者、标准化刺激和稳定实验条件下完成,而失语症、意识障碍、脑卒中和精神疾病患者往往存在病灶位置差异、异常节律活动、注意波动、药物影响、疲劳增加和任务依从性下降等问题。这些因素会改变EEG的时频结构、空间分布和信噪比,使健康受试者模型难以直接外推到真实患者群体。尤其在视觉和语言解码任务中,患者可能存在理解能力、注视控制、意识水平或语言加工能力受损,因此模型性能下降既可能来自算法泛化不足,也可能反映病理状态本身对任务相关神经活动的影响。未来研究应将跨人群迁移作为独立评价维度,报告健康训练到患者测试、患者少样本微调、跨中心外部验证和随访验证结果,并结合迁移学习、自监督预训练、域自适应、数据增广、多中心共享数据和联邦学习等策略,提高模型在真实患者群体中的稳定性和临床可用性。

个体差异也不是一次校准即可解决的问题。疲劳、注意、药物、电极状态和康复阶段会使同一患者的EEG分布随时间变化,未来系统需要将周期性复测、性能衰减监测和可回退的模型更新纳入长期使用流程。持续适配虽然可能减轻分布变化,但若系统直接把错误预测作为新标签,也可能放大偏差。因此,模型更新应设置明确的触发条件、稳定性检查和版本记录,并区分可以自动调整的参数与需要专业人员确认的变化。此外,持续适配是否具有临床意义,还取决于校准成本。需要长时间重复任务、频繁重新佩戴或持续人工调参的系统,即使准确率较高,也难以用于床旁和家庭环境。后续研究应同时报告校准样本量、校准时间、患者认知与体力负担、性能收益及其维持时间,使个体化解码成为可评价、可实施的临床流程。

5.3 实时解码与闭环稳定性

离线模型性能不能直接代表在线可用性。实时BCI包含采集、缓冲、预处理、推理、决策和反馈多个环节,任何环节的延迟和波动都会改变用户体验和闭环效果。因此,实时性需要根据具体用途定义:字符通信关注信息传输效率和选择节奏,癫痫预警关注有效提前量,卒中BCI结合功能性电刺激则强调运动意图与感觉反馈之间的时间耦合。后续研究应报告端到端延迟、连续运行时间、算力需求,以及丢包、伪迹和信号中断情况下的性能。

长期运行还会受到电极阻抗、导电介质干燥、位移、出汗、肌电、疲劳和注意变化的共同影响。在线自适应和重新校准可以缓解性能衰减,但模型更新本身也会引入新的不确定性。未来系统应将输入质量监测、性能报警、保守回退和版本管理作为闭环架构的一部分,并通过长时间连续实验而非短时离线

片段评价稳定性。工程指标与临床指标也需要同时报告:不仅说明模型是否正确,还要说明错误何时发生、系统能否恢复以及患者是否能够持续使用。

5.4 解码结果的可信度评价

解码结果的可信性至少包含3个层面:输出与目标信息是否一致,输出是否真正依赖当前EEG输入,以及模型所使用的时间窗、电极和频段是否符合已知神经生理过程。传统分类任务通常更关注预测正确性和特征解释,而视觉、语言生成还必须判断高质量输出究竟来自EEG条件,还是主要由类别标签、语言上下文或预训练生成模型的先验补全。预训练扩散模型和语言模型能够生成逼真的图像和流畅的文本,但表面质量本身不能证明模型恢复了个体EEG中包含的具体内容。当前评价体系的一个突出问题,是类别识别、候选检索、语义一致性、条件生成和实例级恢复经常被放在同一框架中比较。未来研究应首先明确任务边界,并采用与结论相匹配的对照实验。可以置换不同试次或不同受试者的EEG、遮蔽关键时间窗和通道、移除类别或文本条件,并比较加入真实EEG前后的增益;若输出在这些操作后基本不变,就不能将结果简单解释为“EEG驱动生成”。对于疾病分类,也应检验模型解释在不同折次、中心和预处理方案下是否稳定,避免将单一模型或单次训练得到的注意力图、显著性图或特征重要性排序直接视为可靠的神经机制证据。

可信评价还需要从单一性能指标走向多层证据。视觉和语言解码应分别报告内容恢复准确性、语义一致性和EEG条件所带来的独立增益;疾病模型则应将重要电极、频段和连接模式与独立电生理指标、症状变化或干预反应相互验证。未来的基准不仅要比较模型“生成得是否更像”,还要检验“加入EEG后是否获得了不可由其他条件替代的信息”,并报告解释的重复性和不确定性。只有当模型依据能够在不同数据划分和临床条件下重复出现,可解释性才可能真正服务于临床判断。

5.5 数据隐私与伦理

EEG数据不仅包含特定任务相关活动,还可能反映个体身份、认知状态、情绪变化及潜在病理风险,其敏感性超出一般生理信号。同一段EEG在后续分析中可能产生超出原研究目的的附加发现,而受试者在初次知情同意时未必能够预见这些用途。与此同时,静息态节律、诱发反应和脑网络特征具有一定个体稳定性,即使删除姓名等显性标识,仍可能存在重识别风险。随着EEG数据向多中心共享、可穿戴采集和居家监测扩展,仅依靠常规匿名化已难以满足保护要求。

闭环BCI还将风险由数据层面延伸至实际干预。解码误差、模型漂移或远程系统异常可能进一步影响功能性电刺激、神经反馈或康复设备的执行结果。因此,系统除保护数据机密性外,还应设置输出置信度判断、刺激参数边界、人工接管和安全回退机制,并明确算法开发者、设备提供者和临床使用者在模型更新及异常事件中的责任。对于无线设备、云端模型和居家康复,网络安全也应纳入临床风险评估,而不能仅作为一般信息技术问题处理。

脑电采集和智能解码研究的知情同意应根据研究对象的认知状态、表达能力和疾病特征进行分层管理。对于普通健康受试者,伦理重点主要在于充分告知研究目的、采集流程、数据保存期限、共享范围和二次利用方式,并说明EEG数据可能包含身份识别、情绪状态、注意波动或潜在异常活动等超出原始研究目的的信息。对于意识障碍患者,由于其可能无法自主理解研究内容或表达同意,研究应遵循最小风险原则,由法定代理人或家属在伦理委员会审查基础上进行代理同意,并根据患者意识水平变化持续评估其自主同意能力。对于失语症或脑卒中后运动障碍患者,应采用简化说明、图示材料和辅助交流工具,避免将语言或运动输出障碍误判为缺乏决策能力。对于精神疾病患者,则需关注决策能力波动、敏感标签暴露和污名化风险,限制疾病标签、疗效预测结果和可识别脑电特征的二次使用。涉及闭环反馈、神经调控或居家长期监测时,还应设置误触发处理、异常反馈记录和人工接管机制,确保

患者安全优先于算法性能。

未来治理应覆盖 EEG 采集、共享、模型训练、临床部署和长期维护的完整过程。研究阶段需明确数据用途、二次利用范围及附加发现的处理原则,并通过数据最小化、分级访问、加密存储和审计追踪降低滥用风险;临床部署则需持续监测模型性能和数据分布变化,记录算法更新及关键决策过程。由此,BCI 的伦理评价不应局限于一次性知情同意或设备上市审批,而应形成与解码能力、应用场景和闭环风险相适应的持续治理机制。

6 结束语

本文以 EEG 智能解码技术由控制意图识别向脑状态表征、高层语义恢复和闭环交互的发展为主线,梳理了人工特征、端到端学习、自监督预训练、跨模态对齐和实时反馈等代表性进展。临床应用按照 4 类解码路径重新组织:控制意图解码主要用于脑卒中运动康复,脑状态解码服务于癫痫、意识障碍以及精神疾病的检测与评估,语言语义解码开始进入失语症康复和沟通辅助,视觉语义解码则可能支持视觉功能评估与视觉障碍辅助。现有证据显示,运动意图与闭环康复的患者研究基础相对充分,脑状态解码正由横断面分类走向动态监测,失语症 BCI 仍以小样本训练为主,视觉语义解码的患者证据最为有限。未来研究应提高跨人群和跨中心可迁移性,降低个体校准负担,明确视觉与语言输出对 EEG 输入的实际依赖,并通过前瞻性患者研究验证其对运动恢复、疾病预警、语言功能和视觉辅助的真实增量价值。

参考文献:

- [1] VIDAL J J. Toward direct brain-computer communication[J]. *Annual Review of Biophysics and Bioengineering*, 1973, 2: 157-180.
- [2] 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.
- [3] WOLPAW J R, MCFARLAND D J. Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans[J]. *Proceedings of the National Academy of Sciences of the United States of America*, 2004, 101(51): 17849-17854.
- [4] SCHALK G, MCFARLAND D J, HINTERBERGER T, et al. BCI2000: A general-purpose brain-computer interface (BCI) system[J]. *IEEE Transactions on Biomedical Engineering*, 2004, 51(6): 1034-1043.
- [5] BIRBAUMER N, GHANAYIM N, HINTERBERGER T, et al. A spelling device for the paralysed[J]. *Nature*, 1999, 398 (6725): 297-298.
- [6] ANG K K, CHIN Z Y, WANG C, et al. Filter bank common spatial pattern algorithm on BCI competition IV datasets 2a and 2b[J]. *Frontiers in Neuroscience*, 2012, 6: 39.
- [7] BARACHANT A, BONNET S, CONGEDO M, et al. Multiclass brain-computer interface classification by Riemannian geometry[J]. *IEEE Transactions on Biomedical Engineering*, 2012, 59(4): 920-928.
- [8] CONGEDO M, BARACHANT A, BHATIA R. Riemannian geometry for EEG-based brain-computer interfaces: A primer and a review[J]. *Brain-Computer Interfaces*, 2017, 4(3): 155-174.
- [9] SCHIRRMUSTER R T, SPRINGENBERG J T, FIEDERER L D J, et al. Deep learning with convolutional neural networks for EEG decoding and visualization[J]. *Human Brain Mapping*, 2017, 38(11): 5391-5420.
- [10] LAWHERN V J, SOLON A J, WAYTOWICH N R, et al. EEGNet: A compact convolutional neural network for EEG-based brain-computer interfaces[J]. *Journal of Neural Engineering*, 2018, 15(5): 056013.
- [11] KOSTAS D, AROCA-OUELLETTE S, RUDZICZ F. BENDR: Using transformers and a contrastive self-supervised learning task to learn from massive amounts of EEG data[J]. *Frontiers in Human Neuroscience*, 2021, 15: 653659.
- [12] YANG C, WESTOVER M, SUN J. BIOT: Biosignal Transformer for cross-data learning in the wild[C]//*Proceedings of Advances in Neural Information Processing Systems*. New Orleans, Louisiana, USA: Neural Information Processing Systems

Foundation, Inc., 2023: 78240-78260.

- [13] JIANG W B, ZHAO L M, LU B L. Large brain model for learning generic representations with tremendous EEG data in BCI [EB/OL]. (2024-05-01). <https://arxiv.org/abs/2405.18765>.
- [14] BAI Y, WANG X, CAO Y P, et al. DreamDiffusion: Generating high-quality images from brain EEG signals[EB/OL]. (2023-06-01). <https://arxiv.org/abs/2306.16934>.
- [15] DUAN Y, ZHOU J, WANG Z, et al. DeWave: Discrete EEG waves encoding for brain dynamics to text translation[EB/OL]. (2023-09-01). <https://arxiv.org/abs/2309.14030>.
- [16] ZHOU J, DUAN Y, CHANG Y C, et al. BELT: Bootstrapping electroencephalography-to-language decoding and zero-shot sentiment classification by natural language supervision[EB/OL]. (2023-09-01). <https://arxiv.org/abs/2309.12056>.
- [17] BIASIUCCI A, LEEB R, ITURRATE I, et al. Brain-actuated functional electrical stimulation elicits lasting arm motor recovery after stroke[J]. *Nature Communications*, 2018, 9: 2421.
- [18] MANSOUR S, GILES J, ANG K K, et al. Exploring the ability of stroke survivors in using the contralesional hemisphere to control a brain-computer interface[J]. *Scientific Reports*, 2022, 12: 16223.
- [19] LIU H, WEI P, WANG H, et al. An EEG motor imagery dataset for brain computer interface in acute stroke patients[J]. *Scientific Data*, 2024, 11: 131.
- [20] ZHANG M, WU Y, JIA F, et al. Efficacy of kinesthetic motor imagery based brain computer interface combined with tDCS on upper limb function in subacute stroke[J]. *Scientific Reports*, 2025, 15: 11829.
- [21] BATISTA J, PINTO M F, TAVARES M, et al. EEG epilepsy seizure prediction: The post-processing stage as a chronology[J]. *Scientific Reports*, 2024, 14: 407.
- [22] ZHANG J, ZHENG S, CHEN W, et al. A scheme combining feature fusion and hybrid deep learning models for epileptic seizure detection and prediction[J]. *Scientific Reports*, 2024, 14: 16916.
- [23] SU J, HUANG Z, MA Y, et al. A model for epileptic EEG detection and recognition based on multi-attention mechanism and spatiotemporal[J]. *Scientific Reports*, 2025, 15: 31993.
- [24] PARTAMIAN H, JAHROMI S, CORONA L, et al. Machine learning on interictal intracranial EEG predicts surgical outcome in drug resistant epilepsy[J]. *npj Digital Medicine*, 2025, 8: 138.
- [25] DU BOIS N, KORIK A, HODGE S, et al. Advancing EEG-based assessment of consciousness and cognition in prolonged disorders of consciousness[J]. *Communications Medicine*, 2026, 6: 344.
- [26] QU S, WU X, HUANG L, et al. Diagnosis of disorders of consciousness using nonlinear feature derived EEG topographic maps via deep learning[J]. *Scientific Reports*, 2026, 16: 7417.
- [27] WAN L, CHEN Y, ZHANG Q, et al. An EEG-based digital biomarker for personalizing transcranial magnetic stimulation in major depressive disorder[J]. *npj Digital Medicine*, 2026. DOI: 10.1038/s41746-026-02603-8.
- [28] LIU R, HOU X, LIU S, et al. Predicting antidepressant response via local-global graph neural network and neuroimaging biomarkers[J]. *npj Digital Medicine*, 2025, 8: 515.
- [29] KABBARA A, ROBERT G, KHALIL M, et al. An electroencephalography connectome predictive model of major depressive disorder severity[J]. *Scientific Reports*, 2022, 12: 6816.
- [30] KAUSHIK P, YANG H, ROY P P, et al. Comparing resting state and task-based EEG using machine learning to predict vulnerability to depression in a non-clinical population[J]. *Scientific Reports*, 2023, 13: 7467.
- [31] BAGHERZADEH S, NOROUZI M R, GHASRI A, et al. Automated depression detection via cloud based EEG analysis with transfer learning and synchrosqueezed wavelet transform[J]. *Scientific Reports*, 2025, 15: 18008.
- [32] 郭霞, 李同同, 李子遇, 等. 基础模型驱动的脑机接口编解码新范式[J]. *数据采集与处理*, 2026, 41(2): 439-460.
WU Xia, LI Tongtong, LI Ziyu, et al. Foundation model-driven paradigms in brain-computer interface encoding and decoding [J]. *Journal of Data Acquisition and Processing*, 2026, 41(2): 439-460.
- [33] PFURTSCHELLER G, NEUPER C. Event-related synchronization of mu rhythm in the EEG over the cortical hand area in man[J]. *Neuroscience Letters*, 1994, 174(1): 93-96.
- [34] MARINKOVIĆ K. Spatiotemporal dynamics of word processing in the human cortex[J]. *The Neuroscientist*, 2004, 10(2): 142-152.

- [35] SPAMPINATO C, PALAZZO S, KAVASIDIS I, et al. Deep learning human mind for automated visual classification[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA: IEEE, 2017: 4503-4511.
- [36] MA X, QI Y, XU C, et al. How well do neural signatures of resting-state EEG detect consciousness? A large-scale clinical study[J]. Human Brain Mapping, 2024, 45(4): e26586.
- [37] LI H, DONG L, SU W, et al. Multiple patterns of EEG parameters and their role in the prediction of patients with prolonged disorders of consciousness[J]. Frontiers in Neuroscience, 2025, 19: 1492225.
- [38] KAVASIDIS I, PALAZZO S, SPAMPINATO C, et al. Brain2Image: Converting brain signals into images[C]//Proceedings of the 25th ACM International Conference on Multimedia. Mountain View, California, USA: ACM, 2017: 1809-1817.
- [39] SINGH P, PANDEY P, MIYAPURAM K, et al. EEG2IMAGE: Image reconstruction from EEG brain signals[C]//Proceedings of ICASSP 2023—2023 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Rhodes Island, Greece: IEEE, 2023: 1-5.
- [40] WAKITA S, ORIMA T, MOTOYOSHI I. Photorealistic reconstruction of visual texture from EEG signals[J]. Frontiers in Computational Neuroscience, 2021, 15: 754587.
- [41] MISHRA R, SHARMA K, JHA R R, et al. NeuroGAN: Image reconstruction from EEG signals via an attention-based GAN[J]. Neural Computing and Applications, 2023, 35(12): 9181-9192.
- [42] BRIA A, MARROCCO C, TORTORELLA F. Sinc-based convolutional neural networks for EEG-BCI-based motor imagery classification[M]//Pattern Recognition. ICPR International Workshops and Challenges. Cham: Springer International Publishing, 2021: 526-535.
- [43] KHALEGHI N, REZAI T Y, BEHESHTI S, et al. Visual saliency and image reconstruction from EEG signals via an effective geometric deep network-based generative adversarial network[J]. Electronics, 2022, 11(21): 3637.
- [44] SONG Y, LIU B, LI X, et al. Decoding natural images from EEG for object recognition[EB/OL]. (2023-08-01). <https://arxiv.org/abs/2308.13234>.
- [45] ZENG H, XIA N, QIAN D, et al. DM-RE2I: A framework based on diffusion model for the reconstruction from EEG to image[J]. Biomedical Signal Processing and Control, 2023, 86: 105125.
- [46] SHIMIZU H, SRINIVASAN R. Improving classification and reconstruction of imagined images from EEG signals[J]. PLOS One, 2022, 17(9): e0274847.
- [47] BISWAL S, XIAO C, WESTOVER M B, et al. EEGtotext: Learning to write medical reports from EEG recordings[C]//Proceedings of the 4th Machine Learning For Healthcare Conference. [S.l.]: PMLR, 2019.
- [48] SRIVASTAVA A. Think2Type: Thoughts to text using EEG waves[J]. International Journal of Engineering Research, 2020, V9(6): IJERTV9IS060431.
- [49] WANG Z, HENG J. Open vocabulary electroencephalography-to-text decoding and zero-shot sentiment classification[C]//Proceedings of the AAAI Conference on Artificial Intelligence. [S.l.]: AAAI, 2022.
- [50] FENG X, FENG X, QIN B, et al. Aligning semantic in brain and language: A curriculum contrastive method for electroencephalography-to-text generation[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2023, 31: 3874-3883.
- [51] TAO Y, LIANG Y, WANG L, et al. SEE: Semantically aligned EEG-to-text translation[C]//Proceedings of ICASSP 2025—2025 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Hyderabad, India: IEEE, 2025: 1-5.
- [52] LIU H, HAJIALIGOL D, ANTONY B, et al. EEG2Text: Open vocabulary EEG-to-text translation with multi-view transformer[C]//Proceedings of 2024 IEEE International Conference on Big Data (BigData). Washington, DC, USA: IEEE, 2025: 1824-1833.
- [53] WANG J, SONG Z, MA Z, et al. Enhancing EEG-to-text decoding through transferable representations from pre-trained contrastive EEG-text masked autoencoder[C]//Proceedings of the 62nd Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers). Bangkok, Thailand: Association for Computational Linguistics, 2024: 7278-7292.

- [54] MEHMOOD T, AHMAD H, SHAKEEL M H, et al. CATVis: Context-aware thought visualization[M]//Medical Image Computing and Computer Assisted Intervention—MICCAI 2025. Cham: Springer Nature Switzerland, 2025: 98-108.
- [55] REZVANI A, AKBARI A, ARANI K S, et al. Interpretable EEG-to-image generation with semantic prompts[EB/OL]. (2025-07-01). <https://arxiv.org/abs/2507.07157>.
- [56] HOLLENSTEIN N, ROTSZTEJN J, TROENDLE M, et al. ZuCo, a simultaneous EEG and eye-tracking resource for natural sentence reading[J]. *Scientific Data*, 2018, 5: 180291.
- [57] HOLLENSTEIN N, TROENDLE M, ZHANG C, et al. ZuCo 2.0: A dataset of physiological recordings during natural reading and annotation[C]//Proceedings of the Twelfth Language Resources and Evaluation Conference. Marseille, France: Association for Computational Linguistics, 2020: 138-146.
- [58] GROOTSWAGERS T, ZHOU I, ROBINSON A K, et al. Human EEG recordings for 1 854 concepts presented in rapid serial visual presentation streams[J]. *Scientific Data*, 2022, 9: 3.
- [59] ZHAO S, RUDZICZ F. Classifying phonological categories in imagined and articulated speech[C]//Proceedings of 2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). South Brisbane, QLD, Australia: IEEE, 2015: 992-996.
- [60] KINGMA D P, WELLING M. Auto-encoding variational Bayes[EB/OL]. (2013-12-01). <https://arxiv.org/abs/1312.6114>.
- [61] GOODFELLOW I, POUGET-ABADIE J, MIRZAET M et al. Generative adversarial nets[J]. *Advances in Neural Information Processing Systems*, 2014. DOI:10.3156/JSOFT.29.5_177_2.
- [62] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. *Advances in Neural Information Processing Systems*, 2017. DOI: <https://arxiv.org/abs/1706.03762>.
- [63] SCARSELLI F, GORI M, TSOI A C, et al. The graph neural network model[J]. *IEEE Transactions on Neural Networks*, 2009, 20(1): 61-80.
- [64] JONATHAN H, JAIN A, ABBEEL P. Denoising diffusion probabilistic models[J]. *Advances in Neural Information Processing Systems*, 2020, 33: 6840-6851.
- [65] ROMBACH R, BLATTMANN A, LORENZ D, et al. High-resolution image synthesis with latent diffusion models[C]//Proceedings of The IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, LA, USA: IEEE, 2021.
- [66] WANG X, LIESAPUTRA V, LIU Z, et al. An in-depth survey on deep learning-based motor imagery electroencephalogram (EEG) classification[J]. *Artificial Intelligence in Medicine*, 2024, 147: 102738.
- [67] ANG K K, CHIN Z Y, ZHANG H, et al. Filter bank common spatial pattern (FBCSP) in brain-computer interface[C]//Proceedings of 2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence). Hong Kong, China: IEEE, 2008: 2390-2397.
- [68] XU B, ZHANG L, SONG A, et al. Wavelet transform time-frequency image and convolutional network-based motor imagery EEG classification[J]. *IEEE Access*, 2019, 7: 6084-6093.
- [69] STURM I, LAPUSCHKIN S, SAMEK W, et al. Interpretable deep neural networks for single-trial EEG classification[J]. *Journal of Neuroscience Methods*, 2016, 274: 141-145.
- [70] LU N, LI T, REN X, et al. A deep learning scheme for motor imagery classification based on restricted Boltzmann machines [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2017, 25(6): 566-576.
- [71] WANG P, JIANG A, LIU X, et al. LSTM-based EEG classification in motor imagery tasks[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2018, 26(11): 2086-2095.
- [72] ZHANG D, YAO L, ZHANG X, et al. Cascade and parallel convolutional recurrent neural networks on EEG-based intention recognition for brain computer interface[C]//Proceedings of the AAAI Conference on Artificial Intelligence. [S.l.]: AAAI, 2018.
- [73] JIA Z, LIN Y, WANG J, et al. MMCNN: A multi-branch multi-scale convolutional neural network for motor imagery classification[M]//Machine Learning and Knowledge Discovery in Databases. Cham: Springer International Publishing, 2021: 736-751.

- [74] HOU Y, JIA S, LUN X, et al. Deep feature mining via the attention-based bidirectional long short term memory graph convolutional neural network for human motor imagery recognition[J]. *Frontiers in Bioengineering and Biotechnology*, 2022, 9: 706229.
- [75] LI H, ZHANG D, XIE J. MI-DABAN: A dual-attention-based adversarial network for motor imagery classification[J]. *Computers in Biology and Medicine*, 2023, 152: 106420.
- [76] PINYOL P J. Design and development of a clinical tool based on brain-computer interface (BCI) technology for motor rehabilitation[D]. Barcelona: Universitat Politècnica de Catalunya, 2025.
- [77] ZHENG W L, LU B L. A multimodal approach to estimating vigilance using EEG and forehead EOG[J]. *Journal of Neural Engineering*, 2017, 14(2): 026017.
- [78] KAVEH R, SCHWENDEMAN C, PU L, et al. Wireless ear EEG to monitor drowsiness[J]. *Nature Communications*, 2024, 15: 6520.
- [79] DUAN R N, ZHU J Y, LU B L. Differential entropy feature for EEG-based emotion classification[C]//*Proceedings of 2013 6th International IEEE/EMBS Conference on Neural Engineering (NER)*. San Diego, CA, USA: IEEE, 2014: 81-84.
- [80] BRUNNER I, LUNDQUIST C B, PEDERSEN A R, et al. Brain computer interface training with motor imagery and functional electrical stimulation for patients with severe upper limb paresis after stroke: A randomized controlled pilot trial[J]. *Journal of NeuroEngineering and Rehabilitation*, 2024, 21(1): 10.
- [81] HASSAN J, REZA S, AHMED S U, et al. EEG workload estimation and classification: A systematic review[J]. *Journal of Neural Engineering*, 2025, 22(5): 051003.
- [82] MA W, ZHENG Y, LI T, et al. A comprehensive review of deep learning in EEG-based emotion recognition: Classifications, trends, and practical implications[J]. *PeerJ Computer Science*, 2024, 10: e2065.
- [83] XIAO G, SHI M, YE M, et al. 4D attention-based neural network for EEG emotion recognition[J]. *Cognitive Neurodynamics*, 2022, 16(4): 805-818.
- [84] BHATTI A, ANGKAN P, BEHINAEIN B, et al. CLARE: Cognitive load assessment in real-time with multimodal data[J]. *IEEE Transactions on Cognitive and Developmental Systems*, 2025, 17(6): 1337-1349.
- [85] ZHONG P, WANG D, MIAO C. EEG-based emotion recognition using regularized graph neural networks[J]. *IEEE Transactions on Affective Computing*, 2022, 13(3): 1290-1301.
- [86] CHEN W, LIAO Y, DAI R, et al. EEG-based emotion recognition using graph convolutional neural network with dual attention mechanism[J]. *Frontiers in Computational Neuroscience*, 2024, 18: 1416494.
- [87] K N V, GUPTA C N. Systematic review of experimental paradigms and deep neural networks for electroencephalography-based cognitive workload detection[J]. *Progress in Biomedical Engineering*, 2024, 6(4): 042004.
- [88] BASTIAANSEN M, HAGOORT P. Oscillatory neuronal dynamics during language comprehension[M]//*Event-Related Dynamics of Brain Oscillations*. Amsterdam: Elsevier, 2006: 179-196.
- [89] BASTIAANSEN M C M, OOSTENVELD R, JENSEN O, et al. I see what you mean: Theta power increases are involved in the retrieval of lexical semantic information[J]. *Brain and Language*, 2008, 106(1): 15-28.
- [90] WEISS S, MUELLER H M, SCHACK B, et al. Increased neuronal communication accompanying sentence comprehension [J]. *International Journal of Psychophysiology*, 2005, 57(2): 129-141.
- [91] HAARMANN H I, CAMERON K A, RUCHKIN D S. Neural synchronization mediates on-line sentence processing: EEG coherence evidence from filler-gap constructions[J]. *Psychophysiology*, 2002, 39(6): 820-825.
- [92] WEISS S, MUELLER H M. "Too many betas do not spoil the broth": The role of beta brain oscillations in language processing[J]. *Frontiers in Psychology*, 2012, 3: 201.
- [93] FAHIMI HNAZAE M, KHACHATRYAN E, VAN HULLE M M. Semantic features reveal different networks during word processing: An EEG source localization study[J]. *Frontiers in Human Neuroscience*, 2018, 12: 503.
- [94] SERESHKEH A R, TROTT R, BRICOUT A, et al. Online EEG classification of covert speech for brain-computer interfacing[J]. *International Journal of Neural Systems*, 2017, 27(8): 1750033.
- [95] REZAZADEH SERESHKEH A, TROTT R, BRICOUT A, et al. EEG classification of covert speech using regularized

- neural networks[J]. *IEEE/ACM Transactions on Audio, Speech, and Language Processing*, 2017, 25(12): 2292-2300.
- [96] VORONTSOVA D, MENSHIKOV I, ZUBOV A, et al. Silent EEG-speech recognition using convolutional and recurrent neural network with 85% accuracy of 9 words classification[J]. *Sensors*, 2021, 21(20): 6744.
- [97] PANACHAKEL J T, RAMAKRISHNAN A G. Decoding covert speech from EEG—A comprehensive review[J]. *Frontiers in Neuroscience*, 2021, 15: 642251.
- [98] LAROCCO J, TAHMINA Q, LECIAN S, et al. Evaluation of an English language phoneme-based imagined speech brain computer interface with low-cost electroencephalography[J]. *Frontiers in Neuroinformatics*, 2023, 17: 1306277.
- [99] ALZHRANI S, BANJAR H, MIRZA R. Systematic review of EEG-based imagined speech classification methods[J]. *Sensors*, 2024, 24(24): 8168.
- [100] LEWIS M, LIU Y, GOYAL N, et al. BART: Denoising sequence-to-sequence pre-training for natural language generation, translation, and comprehension[C]//*Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*. [S.l.]: Association for Computational Linguistics, 2020: 7871-7880.
- [101] HAMZA A, MICUCCI D, NAPOLETANO P. Decoding EEG signals for brain-computer interfaces[M]//*Handbook on Smart Health*. London: SAGE Publications, 2025: 551-567.
- [102] CHEN Q, WANG Y, WANG F, et al. Decoding text from electroencephalography signals: A novel hierarchical gated recurrent unit with masked residual attention mechanism[J]. *Engineering Applications of Artificial Intelligence*, 2025, 139: 109615.
- [103] LIU X, SHEN D, LIU X. Learning interpretable representations leads to semantically faithful EEG-to-text generation[EB/OL]. (2025-05-01). <https://arxiv.org/abs/2505.17099>.
- [104] LU J T, CHIANG J, CHEN C S, et al. EEG2TEXT-CN: An exploratory study of open-vocabulary Chinese text-EEG alignment via large language model and contrastive learning on Chinese EEG[EB/OL]. (2025-06-01). <https://arxiv.org/abs/2506.00854>.
- [105] JIANG X, ZHOU J, DUAN Y, et al. Neural spelling: A spell-based BCI system for language neural decoding[J]. *IEEE Transactions on Biomedical Engineering*, 2026. DOI:10.1109/TBME.2026.3691322.
- [106] LUTZENBERGER W, PULVERMÜLLER F, ELBERT T, et al. Visual stimulation alters local 40 Hz responses in humans: An EEG-study[J]. *Neuroscience Letters*, 1995, 183(1/2): 39-42.
- [107] DEMIRALP T, BAYRAKTAROGLU Z, LENZ D, et al. Gamma amplitudes are coupled to theta phase in human EEG during visual perception[J]. *International Journal of Psychophysiology*, 2007, 64(1): 24-30.
- [108] KHADIR A, MAGHAREH M, SASANI GHAMSARI S, et al. Brain activity characteristics of RGB stimulus: An EEG study[J]. *Scientific Reports*, 2023, 13: 18988.
- [109] LOPEZ E, SIGILLO L, COLONNESE F, et al. Guess what I think: Streamlined EEG-to-image generation with latent diffusion models[C]//*Proceedings of ICASSP 2025—2025 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. Hyderabad, India: IEEE, 2025: 1-5.
- [110] CHENG W, TAN J, WANG L, et al. Fine-grained image generation with EEG multi-level semantics[J]. *Computer Methods and Programs in Biomedicine*, 2025, 269: 108909.
- [111] LUO X. Effects of motor imagery-based brain-computer interface-controlled electrical stimulation on lower limb function in hemiplegic patients in the acute phase of stroke: A randomized controlled study[J]. *Frontiers in Neurology*, 2024, 15: 1394424.
- [112] SHRAVAN T. A comprehensive approach utilizing functional electrical stimulation and engineered neural networks[D]. Irvine: University of California, 2026.
- [113] ZHU R, PAN W X, LIU J X, et al. Epileptic seizure prediction via multidimensional transformer and recurrent neural network fusion[J]. *Journal of Translational Medicine*, 2024, 22(1): 895.
- [114] GUTTAG J. CHB-MIT scalp EEG database, version 1.0.0[DB/OL]. (2010)[2026-06-01]. <http://10.13026/C2K01R>.
- [115] OLBRICH S, JAWORSKA N, DE LA SALLE S, et al. Deep learning using electroencephalogram (EEG) data for diagnosing and predicting SSRI response in major depressive disorder[J]. *Communications Medicine*, 2026, 6: 159.
- [116] JIAO Y, ZHAO K, WEI X, et al. Deep graph learning of multimodal brain networks defines treatment-predictive signatures in

- major depression[J]. *Molecular Psychiatry*, 2025, 30(9): 3963-3974.
- [117] SONG Y, WANG Y, HE H, et al. Recognizing natural images from EEG with language-guided contrastive learning[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2025, 36(9): 15896-15910.
- [118] JAYALAKSSHME SRINIVASAN K, PERIASAMY P, GUNASEKARAN S. Motor imagery and motor execution: A narrative review of electroencephalographic (EEG) signatures, methodological consistency, and translational applications[J]. *Cureus*, 2025. DOI: 10.7759/cureus.93011.
- [119] PIROVANO I, MASTROPIETRO A, ANTONACCI Y, et al. Resting state EEG directed functional connectivity unveils changes in motor network organization in subacute stroke patients after rehabilitation[J]. *Frontiers in Physiology*, 2022, 13: 862207.
- [120] MARK J I, RIDDLE J, GANGWANI R, et al. Cross-frequency coupling as a biomarker for early stroke recovery[J]. *Neurorehabilitation and Neural Repair*, 2024, 38(7): 506-517.
- [121] OLEJARCZYK E, SOBIESZEK A, ASSENZA G. Automatic detection of the EEG spike-wave patterns in epilepsy: Evaluation of the effects of transcranial current stimulation therapy[J]. *International Journal of Molecular Sciences*, 2024, 25(16): 9122.
- [122] HU D, CAO J, LAI X, et al. Epileptic state classification by fusing hand-crafted and deep learning EEG features[J]. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 2021, 68(4): 1542-1546.
- [123] LANDE G, BLUME C, ANNEN J. Sleep and circadian disturbance in disorders of consciousness: Current methods and the way towards clinical implementation[J]. *Seminars in Neurology*, 2022. DOI:10.1055/a-1893-2785.
- [124] CRUSE D, CHENNU S, CHATELLE C, et al. Bedside detection of awareness in the vegetative state: A cohort study[J]. *The Lancet*, 2012, 378(9809): 2088-2094.
- [125] CHEN X, WANG Y, NAKANISHI M, et al. High-speed spelling with a noninvasive brain-computer interface[J]. *Proceedings of the National Academy of Sciences of the United States of America*, 2015. DOI: 10.1073/pnas.1508080112.
- [126] NAKANISHI M, WANG Y, CHEN X, et al. Enhancing detection of SSVEPs for a high-speed brain speller using task-related component analysis[J]. *IEEE Transactions on Biomedical Engineering*, 2018, 65(1): 104-112.
- [127] BRUDER G E, STEWART J W, MCGRATH P J. Right brain, left brain in depressive disorders: Clinical and theoretical implications of behavioral, electrophysiological and neuroimaging findings[J]. *Neuroscience & Biobehavioral Reviews*, 2017, 78: 178-191.
- [128] HO T C, WALKER J C, TERESI G I, et al. Default mode and salience network alterations in suicidal and non-suicidal self-injurious thoughts and behaviors in adolescents with depression[J]. *Translational Psychiatry*, 2021, 11: 38.
- [129] WATTS D, PULICE R F, REILLY J, et al. Predicting treatment response using EEG in major depressive disorder: A machine-learning meta-analysis[J]. *Translational Psychiatry*, 2022, 12: 332.
- [130] ZHDANOV A, ATLURI S, WONG W, et al. Use of machine learning for predicting escitalopram treatment outcome from electroencephalography recordings in adult patients with depression[J]. *JAMA Network Open*, 2020, 3(1): e1918377.
- [131] SCHWARTZMANN B, CHATTERJEE R, VAGHEI Y, et al. Modulation of neural oscillations in escitalopram treatment: A Canadian biomarker integration network in depression study[J]. *Translational Psychiatry*, 2024, 14: 432.
- [132] AUBINET C, GILLET A, REGNIER A. Disorders of consciousness, language and communication following severe brain injury[J]. *Psychologica Belgica*, 2025, 65(1): 169-188.
- [133] WILLETT F R, AVANSINO D T, HOCHBERG L R, et al. High-performance brain-to-text communication via handwriting [J]. *Nature*, 2021, 593(7858): 249-254.
- [134] WILLETT F R, KUNZ E M, FAN C, et al. A high-performance speech neuroprosthesis[J]. *Nature*, 2023, 620(7976): 1031-1036.
- [135] CARD N S, WAIRAGKAR M, IACOBACCI C, et al. An accurate and rapidly calibrating speech neuroprosthesis[J]. *New England Journal of Medicine*, 2024, 391(7): 609-618.
- [136] LITTLEJOHN K T, CHO C J, LIU J R, et al. A streaming brain-to-voice neuroprosthesis to restore naturalistic communication[J]. *Nature Neuroscience*, 2025, 28(4): 902-912.
- [137] WAIRAGKAR M, CARD N S, SINGER-CLARK T, et al. An instantaneous voice-synthesis neuroprosthesis[J]. *Nature*,

2025, 644(8075): 145-152.

- [138] PARTHASARATHY N, SOETEDJO J, PANCHAVATI S, et al. Evaluation of P300 speller performance using large language models along with cross-subject training[EB/OL]. (2024-10-01). <https://arxiv.org/abs/2410.15161>.
- [139] HONG J, WANG W, NAJAFIZADEH L. ChatBCI: A P300 speller BCI leveraging large language models for improved sentence composition in realistic scenarios[EB/OL]. (2024-11-01). <https://arxiv.org/abs/2411.15395>.
- [140] CLEMENTI L, MAGNANI F G, BARBADORO F, et al. The diagnostic value of visual evoked potentials in chronic disorders of consciousness[J]. *Annals of Clinical and Translational Neurology*, 2025, 12(9): 1875-1885.
- [141] NAIR K, CECOTTI H. Deep learning architectures for code-modulated visual evoked potentials detection[EB/OL]. (2025-11-01). <https://arxiv.org/abs/2511.21940>.
- [142] BEAUCHAMP M S, OSWALT D, SUN P, et al. Dynamic stimulation of visual cortex produces form vision in sighted and blind humans[J]. *Cell*, 2020, 181(4): 774-783.e5.

作者简介:



郑炜豪(1989-),男,教授,博士生导师,研究方向:脑网络建模神经影像与人工智能, E-mail: zhengweihao@lzu.edu.cn。



杜亚峰(2004-),男,硕士研究生,研究方向:脑神经影像与人工智能, E-mail: yafengdu@foxmail.com。



付钰(1994-),男,青年研究员,博士生导师,研究方向:基于AI的神经影像去噪、重建与分割, E-mail: fuyu@lzu.edu.cn。



张喆(1987-),通信作者,男,讲师,博士研究生,研究方向:复杂系统及复杂网络,医学影像分析, E-mail: zhangz@hznu.edu.cn。

(编辑:张黄群)

Brain Computer Interface Intelligent Decoding Technology Based on EEG Signal and Its Clinical Application

ZHENG Weihao¹, DU Yafeng¹, FU Yu¹, ZHANG Zhe^{2*}

(1. School of Information Science and Engineering, Lanzhou University, Lanzhou 730000, China; 2. Institute of Brain Science, Hangzhou Normal University, Hangzhou 311121, China)

Abstract: Brain-computer interface (BCI) establishes information pathways between the human brain and external devices by analyzing brain activity, providing new technical means for assisted communication, functional assessment, rehabilitation training, and neuromodulation. Electroencephalography (EEG) is one of the most widely used signal modalities in non-invasive BCI and brain health research because of its non-invasiveness, low cost, high temporal resolution, and ease of repeated acquisition. Driven by recent advances in artificial intelligence, EEG decoding has expanded from conventional control command recognition to complex brain-state representation, visual and linguistic semantic reconstruction, and real-time closed-loop interaction; accordingly, this paper reviews representative progress in control intent decoding, brain-state decoding, high-level semantic decoding, general representation learning, and closed-loop interaction, and analyzes their applications in stroke rehabilitation, language and visual function rehabilitation, epilepsy detection and early warning, assessment of disorders of consciousness, and auxiliary diagnosis of mental disorders. Although the representational capacity and application scope of EEG decoding continue to expand, clinical maturity varies markedly across different directions: control intent recognition, abnormal-state detection, and closed-loop neurorehabilitation have accumulated a certain research foundation, whereas visual and linguistic semantic decoding remains largely limited to healthy participants and controlled experimental settings; major barriers to clinical translation include cross-individual and cross-center generalization, neural information fidelity, long-term stability, incremental clinical value, closed-loop safety, and ethical regulation. Future research should be guided by real clinical needs and patient outcomes to advance intelligent EEG decoding from methodological feasibility toward stable, reliable, and evaluable clinical applications.

Highlights:

1. This paper provides a comprehensive review of intelligent decoding technologies for electroencephalography-based brain-computer interfaces, tracing their evolution from conventional control intent recognition and brain-state assessment to language and visual semantic decoding, general representation learning, and real-time closed-loop interaction.
2. It systematically compares representative deep learning architectures, including variational autoencoders, generative adversarial networks, Transformers, graph neural networks, and diffusion models, and analyzes their applicable scenarios, technical advantages, limitations, and suitability for control, brain-state, language, and visual decoding tasks.
3. By summarizing patient-level evidence in stroke rehabilitation, epilepsy monitoring, disorders of consciousness, and psychiatric assessment, this paper distinguishes technical feasibility from clinical translation and identifies key challenges involving cross-subject generalization, neural information fidelity, long-term stability, clinical validation, safety, privacy, and ethics.

Key words: brain-computer interface (BCI); EEG signals; intelligent decoding; brain state assessment; brain health; clinical application

Foundation item: National Major Scientific Instruments and Equipments Development Project (No.62227807).

Received: 2026-06-05; **Revised:** 2026-07-10

***Corresponding author, E-mail:** zhangz@hznu.edu.cn.