



基于深度学习的脑电降噪技术及应用*

单宝莲¹⁾ 于海情^{1,2)} 黄永志^{1,2)} 孟佳圆^{1,2)} 许敏鹏^{1,2)**} 钟子平^{3)**} 明 东^{1,2)}

⁽¹⁾ 天津大学医学工程与转化医学研究院, 天津 300072; ⁽²⁾ 脑机交互与人机共融海河实验室, 天津 300072;

⁽³⁾ Swartz Center for Computational Neuroscience, University of California, San Diego, CA 92093, USA)

摘要 脑电图 (electroencephalography, EEG) 是一种无创、高时间分辨率的大脑皮层电生理活动监测技术, 被广泛应用于临床诊断、脑机接口和认知科学等研究领域。然而, 其信号幅值微弱 (通常仅在微伏级别), 极易受到眼电、心电、肌电、运动伪迹等各类噪声干扰。这些噪声不仅会掩盖真实的神经活动, 还可能引入虚假特征, 降低信号质量, 严重影响 EEG 后续分析的准确性与可靠性。基于深度学习的 EEG 降噪技术通过学习受污染 EEG 与原始 EEG 之间的非线性映射, 可实现对复杂伪迹噪声的自适应抑制与有效神经活动信息的保真重建。相比传统方法, 该技术具有非线性建模能力强、对先验假设依赖性低以及网络架构适应性强等主要优势, 有效提升 EEG 降噪性能, 并在神经工程领域展现出重要的应用潜力。为厘清深度学习 EEG 降噪技术的研究与应用进展, 本文从技术原理、基准数据集、降噪模型与评估方法 4 方面展开系统综述, 并归纳其在神经信号解析与脑机接口解码中的典型应用, 以期为该技术的深入研究与广泛应用提供方法论依据。

关键词 脑电图, 脑电降噪, 深度学习

中图分类号 R318, Q189

DOI: 10.3724/j.pibb.2026.0229

CSTR: 32369.14.pibb.20260229

脑电图 (electroencephalogram, EEG) 是通过头皮表面电极无创记录到的, 大脑皮层神经元群体同步放电所产生的生物电信号^[1]。由于其具有安全性高、便携性强和时间分辨率高的优势, 已被广泛应用于临床诊断、脑机接口 (brain-computer interface, BCI) 和认知科学等研究领域^[2-3]。

然而, EEG 信号本身存在频率范围较低 (通常为 0.5~30 Hz)、幅值微弱 (微伏级别) 以及非平稳性强的特点, 极易受到各类伪迹噪声的干扰, 例如, 眨眼或眼动引起的眼电信号 (electrooculography, EOG)、头颈部肌肉活动产生的肌电信号 (electromyography, EMG)、心脏搏动引发的心电信号 (electrocardiogram, ECG)、系统电源导致的工频干扰 (power line interference, PLI) 以及因电极相对头皮移动而产生的运动伪迹^[4-5]。这些噪声不仅会掩盖真实的神经活动, 还可能引入虚假特征, 降低 EEG 信噪比 (signal-to-noise ratio, SNR), 严重影响 EEG 后续分析的准确性与可靠性^[2]。因此, EEG 降噪技术成为了提升 EEG 信号质量的重要工具, 已受到研究人员的广泛关注。

目前, 去除 EEG 中伪迹噪声的方式主要分为两类: 一类是传统 EEG 降噪技术, 一类是基于深度学习的 EEG 降噪技术。早期研究多集中于传统方法, 包括滤波^[6]、回归^[7]、盲源分离^[8]、经验模态分解^[9]及其混合方法^[10]。滤波方法依赖于伪迹与 EEG 频域可分离的前提假设, 但多数伪迹 (如 EOG、EMG 等) 与 EEG 在频谱上存在部分或高度重叠, 容易造成有价值神经活动成分的丢失^[11]。回归方法假设污染 EEG 为原始 EEG 与加权伪迹的线性叠加, 通过从污染 EEG 中减去加权伪迹用以估计原始 EEG^[7], 该方法在 EEG 降噪中虽具有一定效果, 但依赖于高质量的伪迹参考, 在无参考条件下应用受限^[11]。盲源分离方法无需外部参考^[8, 12-13], 通过统计独立性假设将污染 EEG 分

* 国家重点研发计划 (2023YFF1203705), 国家自然科学基金 (32541010, 62406220, 82472101) 和天津市自然科学基金 (23JCYBJC01440) 资助项目。

** 通讯联系人。

许敏鹏 Tel: 022-83612122, E-mail: xmp52637@tju.edu.cn

钟子平 Tel: 022-83612123, E-mail: tpjung@ucsd.edu

收稿日期: 2026-04-29, 接受日期: 2026-06-09

解为若干独立的源信号，在信号重构阶段剔除与伪迹相关的源成分。然而，该方法要求污染 EEG 的通道数目不少于源信号数目，在单通道或少通道 EEG 降噪中适用性受限^[14]。

深度学习 EEG 降噪技术则是通过端到端学习 EEG 样本中的潜在结构与层次化表征，构建从污染 EEG 到原始 EEG 的非线性映射模型^[15]。与传统方法相比，深度学习降噪技术具备以下 3 点关键优势：第一，该技术能够自适应学习污染 EEG 与原始 EEG 之间的非线性映射关系，无需预设频域可分离性，可规避频谱重叠对降噪效果的限制，相对完整地保留 EEG 中的有效神经活动信息^[12, 16-17]；第二，深度学习将所需参考前置于训练阶段，模型部署后无需外部参考即可独立完成端到端降噪，解决了传统 EEG 降噪技术在无参考场景下的应用难题^[16]；第三，深度学习降噪技术可根据实际需求灵活设计网络结构，无论是高密度导联还是单通道条件，均能实现良好的降噪效果^[2, 18]。因此，上述优势使得深度学习 EEG 降噪技术逐渐取代传统方法，成为近 5 年 EEG 降噪领域的关键技术手段。在深度学习 EEG 降噪研究初期，由于算力条件和数据资源有限，研究者普遍采用结构浅层、架构单一的神经网络，主要针对特定伪迹进行去除^[19-20]。随着任务复杂度和模型表达能力的提升，研究逐步转向更深层次和复杂结构的深度复合网络，并结合时序建模^[21]、注意力机制^[2]与多分支融合^[18]等策略，增强对多源复合伪迹的表征能力。

在此背景下，深度学习 EEG 降噪技术的降噪性能持续提升，并在神经工程领域展现出重要的应用潜力，相关研究证实了其在神经信号解析与 BCI 解码中的应用价值，但目前尚缺乏对该领域技术与应用的系统性梳理与综述。为厘清深度学习 EEG 降噪技术的研究与应用现状，本文从技术原理、基准数据集、降噪模型和性能评估 4 个维度展开论述，归纳了该技术在静息节律、感觉诱发电位及运动相关电位等方面的典型应用，总结探讨了技术优势、现存问题及未来发展方向，旨在为深度学习脑电降噪领域的研究及应用，提供完善的理论依据与技术参考。基于深度学习的 EEG 降噪技术及应用架构如图 1 所示。

1 基于深度学习的脑电降噪技术研究

深度学习 EEG 降噪技术旨在通过数据驱动的

方式，从受伪迹噪声污染的 EEG 信号中，重构出原始的内源性神经活动成分。当前，技术研究主要采用直接恢复原始 EEG 的技术路径（图 2），该路径可分为训练建模和测试评估两步^[16]。在训练建模阶段，首先通过对伪迹噪声 A 和原始 EEG X 进行线性叠加，获得人工合成的受污染 EEG Y （公式（1）），然后以 Y 作为模型输入、 X 作为训练目标，通过反向传播逐步更新模型参数 θ ，令模型训练输出 $\hat{X}$ 逐渐接近 X ，据此得到 EEG 降噪模型 f_{EEG} （公式（2）、（3））。在测试评估阶段，将半模拟或真实数据集中获得的污染 EEG Y' 作为输入信号，送入预先训练所得的降噪模型 f_{EEG} ，预测生成降噪后的 EEG 信号 $\hat{X}'$ （公式（4）），并对此进行信号评估。此外，少数研究则是通过训练伪迹预测模型 f_{Artifact} ，预测并移除伪迹噪声 $\hat{A}$ 的方式^[18]，间接恢复原始 EEG 信号（公式（5）、（6））。

$$Y = X + A \quad (1)$$

$$\hat{X} = f_{\text{EEG}}(Y, \theta) \quad (2)$$

$$\hat{\theta} = \underset{\theta}{\operatorname{argminloss}}_{\theta}(X, \hat{X}) \quad (3)$$

$$\hat{X}' = f_{\text{EEG}}(Y', \theta) \quad (4)$$

$$\hat{A} = f_{\text{Artifact}}(Y, \theta) \quad (5)$$

$$\hat{X} = Y - \hat{A} \quad (6)$$

接下来，本文将围绕上述 EEG 降噪技术路径，对其 3 个核心组成部分（基准数据集、EEG 降噪模型和性能评估方法）进行系统综述。

1.1 基准数据集

构建深度学习 EEG 降噪技术首先需要获取模型输入，根据受污染 EEG 是否通过人工合成的方式获得，可将现有 EEG 降噪基准数据集划分为 2 类：半模拟数据集和真实数据集（表 1）。

半模拟数据集能够提供原始 EEG 作为模型训练目标，用于支持研究人员对模型的降噪性能进行定量评估^[22-27]。此类数据集主要包含两种数据：一种是在无干扰条件下采集的原始 EEG，另一种是外界实测或仿真合成的伪迹噪声。研究者通过对原始 EEG X 与各类伪迹噪声 a 进行线性叠加^[18]，获得人工模拟合成的受污染 EEG Y （公式（7））， λ 主要用于控制模拟合成信号 Y 的 SNR（公式（8））。

$$Y = X + \lambda a \quad (7)$$

$$\text{SNR} = 10 \lg \frac{\|Y\|_{\text{F}}^2}{\|\lambda a\|_{\text{F}}^2} \quad (8)$$




Fig. 1 Technique and application framework of deep learning-based EEG denoising

图1 基于深度学习的EEG降噪技术及应用架构

EEG: 脑电图 (electroencephalogram); ERP: 事件相关电位 (event-related potential); MI-BCI: 基于运动想象的脑机接口 (motor imagery based brain-computer interface); ERP-BCI: 基于事件相关电位的脑机接口 (event-related potential based brain-computer interface)。




Fig. 2 Flow chart of deep learning-based EEG denoising technique

图2 基于深度学习的EEG降噪技术路径示意图

其中, $\|\cdot\|_F$ 表示 Frobenius 范数。现有的半模拟数据集中, EEGDenoiseNet (EEGDN)^[22] 是首个专为深度学习 EEG 降噪研究所设计的金标准基准数据集, 共包含 4 514 个 EEG 片段、3 400 个 EOG 片段和 5 598 个 EMG 片段, 主要用于单道 EEG 降噪研究。对于上述伪迹, semi-simulated EEG/EOG (SSEOG)^[23] 和 semi-simulated EEG/EMG (SSEMG) 数据集^[24] 可应用于多通道 EEG 降噪研究。在抑制 ECG 和运动伪迹方面, 大部分研究采用 MIT-BIH Arrhythmia (MIT-BIH)^[25-26] 和 Physiobank Motion Artifacts (PMA) 数据集^[27], 但 MIT-BIH Arrhythmia 数据集中并不包含原始 EEG 记录, 因此, 需要结合其他半模拟数据集中的原始 EEG 信号联合使用^[28]。

真实数据集则是指在实际实验或临床环境中直接采集、受伪迹噪声污染的 EEG 数据集^[2, 29-31], 能够真实反映实际应用场景中的信号复杂性, 可用于

EEG 降噪性能的定性分析与下游任务的应用验证。然而, 由于实测 EEG 中神经活动与伪迹噪声在物理层面不可分离, 真实数据集普遍缺乏纯净的原始 EEG 作为信号参考, 因此, 研究者通常先利用半模拟数据集训练模型, 再迁移至真实数据集进行脑电降噪与定性分析^[2, 28]。在下游任务应用验证中, MNE Sample (MNE) 数据集^[29] 多用于事件相关电位 (event-related potentials, ERPs) 分类任务, 其包含单侧听觉 (左耳/右耳) 与单侧视觉 (左视野/右视野) 4 种刺激, BCI Competition IV Dataset 2b (BCI2b) 数据集^[30] 主要用于运动想象任务 (motor imagery, MI) 识别研究, BioSource (BioSR) 数据集^[2] 是真实数据集中少有的对眨眼和肌电伪迹的通道位置与发生时段进行明确标注的癫痫患者 EEG 数据, 可用于评估降噪方法在临床环境下的精确抑制能力, resting state EEG data (RSEEG) 数据集^[31] 包含 22 名被试在清醒静息状态下的脑电数据, 常用于静息态脑网络研究。

Table 1 Summary of benchmark datasets for deep learning-based EEG denoising technique

表1 深度学习EEG降噪技术的基准数据集归纳

类别	数据集	数据	导联	被试	采样率/Hz	记录时长	用途
半模拟数据集	EEGDenoiseNet ^[22]	EEG	单导	1名	256/512	4 514个2 s片段	量化单通道EEG的EOG、EMG降噪性能
		EOG	单导	1名	256	3 400个2 s片段	
		EMG	单导	1名	512	5 598个2 s片段	
	semi-simulated EEG/EOG ^[23]	EEG	19导	27名	200	54个30 s记录	量化单/多通道EEG的EOG降噪性能
		EOG					
	semi-simulated EEG/EMG ^[24]	EEG	19导	20名	500	20个10 s记录	量化单/多通道EEG的EMG降噪性能
		EMG	4导	23名	500	23个10 s记录	
真实数据集	MIT-BIH arrhythmia ^[25-26]	ECG	2导	47名	360	3 600个2 s记录	量化单/多通道EEG的ECG降噪性能
	Physiobank Motion Artifacts ^[27]	EEG	2导	6名	256	24个9 min试次	量化单通道EEG的运动伪迹降噪性能
		运动伪迹	单导	6名	256	24个9 min试次	
	MNE Sample ^[29]	EEG	60导	1名	/	/	分析ERPs特征, 验证ERPs分类性能
		EOG					
	BCI competition IV dataset 2b ^[30]	EEG	3导	9名	250	5 400个3 s试次	评估单/多通道EEG的EOG降噪效果,
		EOG				5 400个3 s试次	验证MI分类性能
	BioSource ^[2]	EEG	21导	1名	250	10 s记录	评估单/多通道EEG的EOG和EMG降噪效果
		EOG	4导			5 s记录	
		EMG	5导			4 s记录	
	resting state EEG data ^[31]	EEG	72导	22名	2 048	176 min记录	评估单/多通道EEG的EOG降噪效果
		EOG				176 min记录	

1.2 深度学习EEG降噪模型

从金标准数据集中获得 EEG 数据后, 深度学习 EEG 降噪技术主要根据伪迹噪声与干净 EEG 的

时频空特性差异, 构建适用于单通道或多通道 EEG 的降噪模型, 建立污染 EEG 到原始 EEG 之间的非线性映射, 实现对伪迹噪声的有效抑制。现有

深度学习降噪技术所采用的模型可以划分为4类: 卷积神经网络 (convolutional neural network, CNN)^[32]、自编码器 (autoencoder, AE)^[33]、生成对抗网络 (generative adversarial network, GAN)^[34] 和 Transformer^[28]。

CNN是一类在层级结构中利用卷积运算替代传统线性矩阵乘法运算的前馈神经网络^[35]。相比于传统方法, CNN可以凭借局部感知和权值共享的结构优势, 提取局部非线性特征, 实现伪迹噪声的精确分离与抑制^[22]。2020年, Sun等^[32]提出多尺度残差网络用以去除EOG、EMG、ECG伪迹, 为CNN在EEG降噪领域的研究提供了初步验证。随后, CNN方法在该领域得到了广泛应用, 首个金标准基准数据集的发布亦推动了算法性能对比与优化的热潮^[22, 36]。然而, CNN方法主要依赖局部卷积运算, 难以对信号中的全局时序依赖关系进行建模^[37]。为此, Gao等^[21]利用双分支CNN学习信号形态学特征, 并在各分支中引入长短期记忆网络 (long short-term memory, LSTM), 充分提取EEG时序依赖关系, 消融研究表明, CNN的EEG降噪性能可以得到明显提升。受此启发, Cui等^[18]结合双向门控循环单元 (bidirectional gated recurrent unit, BiGRU), 构建双分支CNN-BiGRU网络, 两分支分别用以预测原始EEG和伪迹噪声, 打破了主流深度学习降噪技术仅关注原始EEG重建却忽视伪迹噪声预测的思路局限。

AE通常由编码器和解码器两部分组成, 编码器旨在将高维含伪EEG信号压缩至低维潜在空间提取本质表征, 解码器则负责学习抑制伪迹相关成分, 将低维特征重构为高维原始EEG信号^[38]。目前使用最广泛的AE结构, 主要为稀疏AE^[19]和卷积AE^[38-40]。稀疏AE是在编码器输出的潜在特征上施加稀疏性正则化项, 针对性集中激活少数神经元, 实现对伪迹成分的结构化约束抑制^[19]。卷积AE则是利用卷积、反卷积运算, 构建具有局部感受野和空间不变性的编码-解码结构^[40]。Xing等^[38]利用委托加速将卷积AE部署至智能手机, 这是深度学习EEG降噪技术在移动端平台的首次运用。编解码器之间也可以嵌入“伪迹分离器”构筑“编码-分离-解码”变体结构, Pei等^[39]引入多尺度级联时域金字塔, 实现时频特征复用及局部-全局特征融合以提升伪迹分离能力并保留信号结构细节。

生成对抗网络通过生成器与判别器的零和博弈

实现数据优化: 生成器旨在生成逼真的原始EEG数据欺骗判别器, 判别器则试图准确区分生成信号与参考信号, 二者在对抗中协同进化^[34, 41-43]。2022年, Sawangjai等^[34]首次将GAN应用至深度学习EEG降噪领域, 构建以二维卷积为核心单元的生成器与判别器架构, 并通过均方误差与对抗损失的联合优化, 在数值精度约束与分布一致约束的双重作用下, 实现生成信号对原始EEG的高保真逼近。在此基础上, GAN降噪性能还可在模型架构与训练策略上作进一步优化。在模型架构方面, 生成器可采用CNN与Transformer并行结构, 同时捕获信号的局部与全局时序依赖^[28]; 在训练策略方面, 引入特征损失以约束生成信号在高阶特征空间与原始EEG信号趋于一致, 增强生成信号在全局拓扑结构上的特征保真性^[28]。

Transformer可视为一种特殊AE结构, 其编码-解码功能被多头自注意力机制和前馈神经网络强化: 前者通过并行注意力头建模跨时空全局依赖, 后者则通过逐位置非线性映射增强特征表达能力^[44-45]。2022年, Pu等^[46]指出Transformer通过整合多头自注意力模块中的非局部自相似性与前馈神经网络中的局部自相似性, 可以显著抑制伪迹噪声与异常值对EEG信号的干扰影响。此后, 研究者陆续将Transformer及其核心模块与其他网络结构进行优势互补, 并结合多种串并联融合策略, 开发出一系列高效的混合型EEG降噪模型^[11, 47-49]。Transformer中的多头注意力模块还可用于捕捉导联间相关性, Yin等^[11]便将其作为基本单元构筑空间注意提取器, 级联由线性层组合而成的时域特征提取器, 提升对关键时空融合特征的捕获能力, 实现了伪迹噪声与原始EEG的精准分离。在此基础上, Han等^[2]提出一种双分支并行时空神经网络, 一个分支利用Transformer逐导联提取时序依赖关系, 另一个分支则基于多通道注意权重模块跨导联提取导联间相关性, 并通过双分支时空特征融合提升多通道EEG降噪性能。

1.3 性能评估方法

在半模拟数据集或真实数据集上获得模型预测生成的EEG信号后, 需从噪声抑制和信号保真等方面综合评估深度学习方法的EEG降噪效果。目前, 研究采用的EEG降噪性能评估方法主要分为4种, 即相对均方根误差 (relative root mean squared error, RRMSE)^[18]、相关系数 (correlation coefficient, CC)^[2]、SNR^[11]和功率谱密度

(power spectral density, PSD)^[50]。

RRMSE 是评估 EEG 降噪性能的经典指标, 它反映了生成信号与参考信号之间的整体偏差, 其值越小, 表示模型输出越接近参考信号^[18]。RRMSE 可进一步分为时域相对均方根误差 (RRMSE_{temporal}) 和频域相对均方根误差 (RRMSE_{spectral}), 分别用于衡量生成信号与参考信号在时域波形和频谱结构上的差异^[39, 49] (公式 (9), (10)), 据此评估模型在时域重构精度和频域噪声抑制方面的性能。

$$RRMSE_{\text{temporal}} = \frac{\|\hat{X} - X\|_F}{\|X\|_F} \quad (9)$$

$$RRMSE_{\text{spectral}} = \frac{\|\text{Psd}(\hat{X}) - \text{Psd}(X)\|_F}{\|\text{Psd}(X)\|_F} \quad (10)$$

其中, Psd 表示信号的功率谱密度函数。

相关系数表征了生成信号与参考信号之间的线性相关程度, 其值越接近 1, 表示两者在波形形态上的相似性越高^[2, 18]。如公式 (11) 所示, 与 RRMSE 强调信号误差的绝对大小不同, 相关系数更关注信号之间的形态一致性。因此, 该指标可用于衡量模型在去除伪迹的同时, 是否保留了原始 EEG 的动态时序特征, 以此体现其在信号形态保真方面的性能^[11]。

$$CC = \frac{\text{Cov}(\hat{X}, X)}{\sigma_{\hat{X}} \sigma_X} \quad (11)$$

其中, Cov 表示协方差, σ 表示信号的标准差。

SNR 是评估生成 EEG 信号质量的关键指标, 定义为参考信号与残差信号的能量比值^[2, 11, 18], (公式 (12))。其中, 残差信号是指生成信号与参考信号之间的重构误差, 主要来源于未被完全去除的伪迹成分以及降噪过程中引入的随机噪声^[32]。值得注意的是, 公式 (8) 中的 SNR 用于衡量模拟信号的污染程度, 而公式 (12) 中的 SNR 则是为了评估降噪信号的重构质量, 其值越高, 表明有效神经成分保留越完整, 伪迹成分与随机噪声抑制越充分^[18]。与 RRMSE 和 CC 相比, SNR 从能量角度直接反映神经信号与残留干扰的相对强度^[2]。SNR 提升标志着去除伪迹后神经成分的相对能量占比提高, 客观体现了 EEG 信号质量的改善情况^[11, 18]。

$$SNR = 10 \lg \frac{\|X\|_F^2}{\|\hat{X} - X\|_F^2} \quad (12)$$

上述定量指标的计算均依赖于参考信号, 因此其应用仅限于半模拟数据集^[28]。在缺乏参考信号

的真实数据集中, 性能评估则转向功率谱定性分析方法, 核心是比较降噪前后信号的功率谱密度^[50]。该方法的有效性基于一个关键前提: 即主要伪迹具有特征性的频谱分布——EOG 伪迹能量主要集中于 10 Hz 以下的低频频段, 而 EMG 伪迹则广泛分布于高频频段^[2, 11]。因此, 一个理想的降噪模型, 其生成信号的 PSD 应在特定伪迹对应的特征频段内出现显著抑制, 同时在反映大脑核心神经活动的频段内与原始 EEG 基本一致, 以此证明其在去除伪迹的同时, 最大限度地保留了有生理意义的神经信号^[11, 24, 28, 51]。

2 基于深度学习的脑电降噪技术应用

在确保 EEG 降噪模型能够有效抑制伪迹噪声并保真重建神经信号的基础上, 为进一步验证其实际应用价值, 部分研究会进行下游任务应用验证, 据此评估降噪处理是否切实提升了 EEG 在后续任务中的分析效能。目前, 下游应用主要集中于神经信号解析和 BCI 系统解码两方面。

2.1 神经信号解析

深度学习 EEG 降噪技术通过有效分离神经活动与混杂伪迹, 实现对关键神经活动响应特征的更精准分析, 为阐明脑功能的内在机制提供更可靠的神经电生理信号支撑^[11, 39]。现有 EEG 降噪研究中, 神经信号解析主要围绕静息态 EEG^[49] 和感觉诱发 ERP^[2] 两类核心神经响应展开。

静息态 EEG 反映无外界刺激时大脑自发活动的基本状态, 可通过相位同步化分析评估脑区同步性, 并借助脑网络分析解析全脑的拓扑结构与功能耦合关系^[52-54]。Huang 等^[49] 计算了降噪前后相邻导联在特定频段内的相关系数和相位锁定值 (phase-locking value, PLV), 结果表明, 降噪后导联间的相位同步化水平得到显著提升, 平均 CC 由 0.745 增至 0.894, 平均 PLV 由 0.710 增至 0.894。为探究降噪处理是否会影响并改变静息态脑网络固有的功能连接模式, 研究进一步采用相位延迟指数 (phase-lag index, PLI), 对降噪前后清醒状态下静息态 EEG 构建的 64 导全脑网络进行对比分析, 结果显示降噪前后 PLI 矩阵高度一致, 主要功能连接基本相同^[49]。

感觉诱发 ERP 可以分为听觉诱发电位 (auditory evoked potential, AEP)、视觉诱发电位 (visual evoked potential, VEP) 和体感诱发电位^[55-56]。AEP 是大脑在处理外部听觉刺激时产生

的电位变化, 其长潜伏期响应成分如 N1 和 P2 等, 容易受到注意、记忆等高级认知因素的显著调控^[55, 57]。Yin 等^[11] 分别对降噪前后左耳听觉刺激诱发的多试次 EEG (-0.1 s~0.3 s) 进行叠加平均, 并绘制了 ERPs 脑地形图。该研究结果表明, 刺激呈现 100 ms 时前额叶区域出现的 EOG 伪迹在降噪后得到显著抑制, 而中央区的听觉诱发 N1 成分在拓扑图上则呈现得更为清晰和集中。Han 等^[2] 采用相似方法进一步证实了降噪处理对听觉诱发 N1 成分空间聚焦性的提升作用, 还发现该成分在时间分布上也变得更加清晰与平滑。此外, 研究表明, 降噪处理同样能有效增强听觉中潜伏期成分 (如 P50) 的响应幅值, 使其激活更为明显^[39]。VEP 是大脑皮层和皮层下的视觉通路受到激活时产生的电位变化, 其第一个主要的视觉 ERP 成分 P1, 主要反映初级视觉皮层的感知加工过程^[55, 57-59]。2025 年, Huang 等^[49] 研究发现, 在单侧视觉刺激呈现 100 ms 时, 降噪处理后的 EEG 在对侧枕叶区域出现更显著的早期视觉 P1 成分激活, 这表明降噪技术有助于更清晰地提取与视觉感知相关的神经响应。

2.2 BCI系统解码

深度学习 EEG 降噪技术通过提高 EEG 的 SNR, 能够有效改善任务相关神经特征的信号质量, 从而提升 BCI 系统的分类准确率、召回率、F1 分数 (F1 score) 等性能指标^[2, 11, 19]。当前, 深度学习降噪技术的 BCI 系统解码应用研究, 主要集中于运动相关电位解码^[34] 和感觉诱发 ERP 解码^[39] 两类任务。

运动相关电位解码方面, 研究大多为基于运动想象/运动执行任务 (motor imagery/execution, MI/ME) 的 BCI 系统^[19, 34]。MI/ME 过程与运动功能区具有精细的映射关系, 不同任务可令大脑产生具有不同空间模式的 EEG 响应, 主要特征包括: 表征能量变化的事件相关电位去同步/同步特征和波形变化的运动相关皮质电位特征^[60-62]。深度学习 EEG 降噪技术能够增强上述特征的可分性, 提升 MI-BCI 系统解码性能。2018 年, Yang 等^[19] 将所提稀疏 AE 降噪技术首次应用于运动想象 EEG 数据, 并提取共空间模式特征送入支持向量机中进行识别, 分类结果表明, 4 位被试的污染 EEG 经降噪处理后分类准确率均得到有效提升。沿用上述分类方法, Sawangjai 等^[34] 对降噪前后左/右手 MI 任务

下的 EEG 进行解码, 研究发现所提 EEG 降噪技术成功提升了 MI 二分类数据的识别效果, 平均分类准确率由 71.94% 升至 75.00%, 平均 F1 score 由 70.80% 升至 74.00%。除此之外, 研究还对静息态 EEG/MI 和静息态 EEG/ME 两种分类任务进行了应用验证, EEGNet 模型分类结果表明, 深度学习 EEG 降噪技术可有效提升静息态 EEG/MI 任务的分类性能, 平均分类准确率由 70.20% 增至 73.36% (跨被试) 和 73.84%, 平均 F1 score 由 68.77% 增至 72.38% (跨被试) 和 72.96%, 但对于静息态 EEG/ME 任务而言, 肢体运动所产生的相关噪声本身具备一定的判别价值, 因此深度学习降噪技术并不适用于此类任务解码性能的提升^[34]。

感觉诱发 ERP 解码方面, 研究最为广泛的是基于单侧视/听觉刺激范式的 ERP-BCI 系统^[2, 11, 39]。该系统主要通过检测 EEG 信号中的 VEP/AEP 特征输出控制指令, 其解码依据在于 VEP/AEP 特征的系统性时空差异: 空间上呈现对侧感觉皮层的优势激活模式, 时间上则体现为对侧响应所具有的更短潜伏期、更高波幅与更稳定的波形形态^[63-67]。如前所述, 深度学习 EEG 降噪技术可以改善 VEP/AEP 成分的时空特征, 有助于提升 ERP-BCI 解码性能。Han 等^[2] 采用黎曼几何方法将多通道 EEG 表征为协方差矩阵, 投影至高维黎曼流形空间提取 ERP 空间协变结构特征, 用于解码单侧左/右耳听觉与单侧左/右视野视觉刺激, 结果表明, 降噪后 ERP 四分类性能得到明显提升, 平均分类准确率由 88.57% 升至 92.05%, 平均 F1 score 由 88.56% 升至 92.13%。然而, 并非所有 EEG 降噪技术都能提升单侧 VEP/AEP 成分的解码性能, Yin 等^[11] 研究发现, 传统独立成分分析降噪技术在 EEG 降噪过程中可能会损失部分有用信息, 进而抑制单侧视/听 ERP 成分的识别效果。Pei 等^[39] 进一步验证了所提降噪模型在下游感觉诱发 ERP 解码应用中的有效性, 降噪后 6 种分类性能指标均可实现大幅提升。与此同时, 其研究结果也反映出: 不同降噪方法对 ERP 解码性能的影响各有差异, 部分深度学习 EEG 降噪技术可能因过度抑制信号或引入失真而降低 ERP-BCI 系统的分类性能^[22, 32]。

3 总结与展望

本文系统综述了深度学习在 EEG 降噪领域的

技术原理、基准数据集、降噪模型及其在半模拟与真实数据上的性能评估方法,并进一步归纳了该技术在神经信号解析与BCI系统解码中的典型应用。

根据本文调研结果可知,深度学习EEG降噪研究的核心问题在于:如何实现外源性非神经伪迹与内源性神经信号的有效分离,在抑制噪声的同时最大限度保留具有生理意义的神经活动。围绕此问题,衍生出4类方法:CNN、AE、GAN和Transformer。如表2所示,CNN虽能改善传统方法的整体性能,但其局部感受野难以建模长程时序依赖。AE通过提取信号的全局低维表征,在降噪性能上优于CNN,已应用于感觉诱发ERP的解析任务。GAN进一步拓展了EEG降噪适用性,对多种类型及混合伪迹具有较好的抑制能力,并能适应跨时段、跨被试等实际场景,已在运动相关电位解码中得到验证。而基于自注意力机制的Transformer方法,凭借高效的全局建模能力,在单通道与多通道EEG降噪任务中均展现出显著优势,并能更完整地保留任务相关的神经响应,因而被广泛应用于静息态脑网络分析、感觉诱发ERP解析及运动相关电位解码等多种下游任务。总体而言,深度学习EEG降噪技术发展趋势可概括为:在伪迹处理上,正从单一类型伪迹的处理向多类型及混合伪迹的协同抑制演进,以应对真实场景中噪声的复杂性与并发性;在建模维度上,已从单通道时域建模拓展至多通道时空联合建模,充分融合信号的时空拓扑结构与动态关联信息;在架构设计上,正经历着从单分支结构向多分支并行化、级联化框架的演变,实现更精细的信号分离与重建;在方法范式上,则体现出由单一网络模型向多网络协同与联合学习的系统转变,集成互补优势以提升EEG降噪的整体性能;在计算效率上,正从高参数量、高计算开销向轻量化、低延迟方向演进,在保证降噪性能的前提下满足实时处理与边缘部署需求。

目前,深度学习EEG降噪技术发展仍存在不足之处:技术路径方面,Cui等^[18]指出在污染EEG的SNR较高或包含简单伪迹(如PLI、EOG)时应优先预测并移除伪迹,反之则应直接恢复原始EEG,而当前研究多聚焦于恢复原始EEG信号,未能依据EEG污染类型与水平自适应选择重建目标;数据集方面,现有研究普遍依赖预先构建的半模拟数据,此类数据虽便于量化评估,却难以反映真实环境中噪声的时变、耦合、非平稳特性,而绝

大部分真实数据集均缺乏信号参考,模型训练缺乏精准监督,严重制约了模型在实际应用场景下的泛化能力;降噪模型方面,不同通道间的时空拓扑结构蕴含了区分神经源与伪迹源的可分离信息,但目前多通道EEG降噪研究较为薄弱,现有方法或采用逐导联处理数据的方式,忽视了导联间的功能连接关系,即便引入多通道建模,也鲜有研究能够考虑到脑网络结构的时序演变特性;性能评估方面,现有评价体系过度依赖仿真测度,在缺乏真实参考信号时主要借助先验知识与频谱特征,大多忽视了降噪信号在下游任务中的实际效能,导致模型优化目标与应用需求脱节;下游应用方面,现有研究多集中于典型神经信号解析与少数BCI解码任务,缺乏对高级认知过程、多样化BCI范式及临床疾病诊断等应用场景的系统验证。

未来,仍需从技术路径和应用验证方面展开深入研究。首先,EEG降噪前需明确输入信号的伪迹类型、污染程度等,据此自适应选择重建目标,以实现最优降噪路径的任务驱动式选择;其次,模型训练需纳入更大规模、更多样化的真实数据,以增强对真实噪声的适应能力,可采用自监督学习技术,如掩码重建、对比学习等方法,挖掘EEG内在特征,减少对真实标注数据的依赖;然后,设计能显式建模动态时变脑网络结构的时空神经网络,结合通道自适应加权、物理信息约束等训练策略,实现神经信号与伪迹噪声在时空维度上的精准分离;此外,在仿真指标基础上,还需引入下游任务效能测度,用于评估降噪信号相较于原始EEG,在BCI解码性能、神经响应激活程度、临床检测精度等方面是否得到显著改善,从而构建更全面、贴近实际应用的评估体系;最后,从传统的诱发响应延伸至更复杂的记忆、决策等高级认知研究,以及神经、精神疾病干预等临床诊疗场景,建立以下游任务性能为导向的评估体系,针对主动式、反应式(如稳态视觉诱发电位)、被动式(如认知负荷监测)等多种BCI范式,检验EEG降噪处理的实际应用效果。

深度学习降噪技术作为EEG信号处理领域的重要方法,其核心技术路径与应用验证体系的逐步完善,有望为高保真神经信号解析与高精度BCI系统解码提供关键技术支撑,推动脑科学研究与应用实现新高度。

Table 2 Summary of deep learning-based EEG denoising studies

表2 基于深度学习的脑电降噪技术研究归纳

类别	降噪技术	数据集	技术优势	技术劣势	主要研究结果
卷积神经网络	1D-ResCNN ^[32] (单通道)	CHBMIT	多尺度残差融合强化非线性特征表征能力	未考虑各类伪迹噪声的时域特征	性能评估: 相比传统方法, 对EOG、EMG、ECG三种伪迹的去除效果更好
	SimpleCNN ^[22] (单通道)	EEGDN	轻量级卷积结构适于提取局部时序特征	感受野小、特征融合能力有限	性能评估: 在CNN方法中, 适合处理低频眼电伪迹成分
	NovelCNN ^[36] (单通道)	EEGDN	渐进式特征扩展与时序下采样协同提升模型抗过拟合能力	仅适用于短时EEG片段, 长时序建模能力受限	性能评估: 在CNN方法中, 适合处理高频肌源性伪迹成分
	DuoCL ^[21] (单通道)	/	利用双分支CNN学习EEG形态学特征, LSTM提取时序依赖	在下游应用任务中的实际有效性并未验证	性能评估: 相较于传统单一CNN结构, CNN变体网络对EOG、EMG、ECG、运动伪迹、基线漂移5种伪迹及混合伪迹的降噪性能更高
	EEGIFNet ^[18] (单通道)	EEGDN、MITBIH、PMA	双分支分别用于预测纯净脑电和残差伪迹, 并利用融合模块进阶获得去伪脑电	在处理多种伪迹混合污染的脑电信号时, 降噪能力仍需进一步优化	性能评估: 全面有效去除EOG、EMG、ECG、运动伪迹、工频干扰共计5种生理与环境伪迹 消融实验: 针对低SNR与复杂伪迹, 应预测原始脑电; 反之, 应采用预测伪迹噪声的技术手段
自编码器	DLN ^[19] (单通道)	BCI-IV	由多个稀疏AE构成具有跨被试泛化能力	仅能处理单通道EEG中EOG伪迹	性能评估: 相较于专用于EOG伪迹去除的传统方法, 在EEG降噪效果上更具优势
	DTPNet ^[39] (单通道)	EEGDN、SSEOG、MNE	基于时序金字塔提取任意长度脑电信号的多尺度时序特征	对多通道EEG中每个导联数据独立处理, 并未考虑导联间相关性	性能评估: 适用于去除低频EOG和低频EMG伪迹, 同时保证其他频率EEG成分不失真 下游应用: 明显增强50 ms和100 ms处的关键ERPs成分, 并有效提升ERPs四分类性能
	DAE ^[38] (单通道)	SSEOG、PMA、EEGDN	首次在智能手机端实现结合软硬件协同加速、低资源消耗的移动式EEG降噪模型	未在真实数据集或可穿戴EEG数据集上验证, 适用性尚待评估	性能评估: 无需区分输入EEG是否含伪迹, 即可有效去除EOG、EMG和运动伪迹, 或精准重构原始纯净信号、失真较小 实际应用: 部署后计算速度快、功率消耗低
生成对抗网络	EEGANet ^[34] (多通道)	EEG-EA、BCI2b、MMS	采用GAN实现无需EOG参考与眨眼检测的免校准EOG去除	仅具备EOG单一类型伪迹去除功能	性能评估: 可去除水平眼动、垂直眼动、眨眼等多种EOG伪迹, 且适用于跨天、跨被试场景 下游应用: 有效提升左右手运动想象的分类性能, 但不适用于静息态与运动执行任务的区分
	GCTNet ^[28] (单通道)	EEGDN、MITBIH、SSEOG、BioSR	在GAN架构上结合CNN与Transformer并行模块, 分别捕捉局部和全局时序依赖	模型训练受限于半模拟数据, 模型迁移难以应对真实数据分布差异	性能评估: 对不同SNR水平的EOG、EMG、EOG+EMG、ECG伪迹均有较好去除效果 消融实验: 全局与局部时序依赖特征在脑电信号伪迹去除中相辅相成、缺一不可

续表2

类别	降噪技术	数据集	技术优势	技术劣势	主要研究结果
Transformer	EEGDnet ^[46] (单通道)	EEGDN	2D-Transformer 结构兼具非局部和局部自相似性功能特性	去除两种伪迹时需要分别建模, 模型通用性不足	性能评估: 适用于EOG和EMG伪迹去除, 可利用模型非局部相似性特点捕捉EEG全局动态特征, 结合局部相似性特征保留EEG细节信息
	EEGDfus ^[49] (单通道)	EEGDN、SSEOG、PMA、MNE、RSEEG	双分支融合CNN与Transformer优势, 结合条件扩散模型精细去伪, 提升条件信息控制与模型收敛性	在处理多通道脑电时, 仅能采用逐导联连接方式, 且面对不同数据, 模型泛化能力受限	性能评估: 单通道技术中降噪效果最佳 下游应用: 降噪后EEG在右枕叶区于刺激呈现100 ms处, 表现出比降噪前EEG更明显的早期视觉成分P1激活, 且静息态脑网络在降噪前后保持结构稳定, 主要功能连接基本一致
	STFNet ^[11] (多通道)	SSEOG、SSEMG、MNE、BCI2b	通过自注意力机制与多维特征提取器可显示提取EEG的时序依赖与空间相关性	训练集、测试集导联数目须一致, 且不能显式编码导联空间坐标信息	性能评估: 降噪性能显著高于单通道技术 下游应用: 降噪后, 中央区激活的N1成分空间分布更清晰集中, 且MI分类性能明显提升 推理时间: 推理效率高, 可部署移动端设备
	ASTINet ^[2] (多通道)	SSEOG、SSEMG、MNE、BioSR	利用双分支架构分别提取时域和空间信息, 模型输入并不依赖固定导联设置	模型训练受限于半模拟数据, 复杂真实噪声环境下泛化性有待提升	性能评估: EOG、EMG伪迹去除性能最高 下游应用: 有效抑制了前额叶EOG伪迹, 同步增强了听觉诱发N1成分在时空分布上的平滑性与聚焦性, 并提升了ERPs四分类性能

表中CHBMIT、EEG-EA、MMS、BCI-IV分别为数据集CHB-MIT Scalp EEG^[68]、EEG Eye Artifact^[68]、MultiModal Signal^[68]和BCI Competition IV^[30]的简称。

参 考 文 献

- [1] Xu M, He F, Jung T P, *et al.* Current challenges for the practical application of electroencephalography-based brain-computer interfaces. *Engineering*, 2021, **7**(12): 1710-1712
- [2] Han Y, Liu A, Cui H, *et al.* A flexible spatio-temporal architecture design for artifact removal in EEG with arbitrary channel-settings. *IEEE J Biomed Heal Inform*, 2025, **29**(9): 6599-6612
- [3] Phillips A R, Vakilna Y S, EPMoghaddam D, *et al.* Inferring neural sources from electroencephalography: foundations and frontiers. *J Neural Eng*, 2026, **23**(1): 011002
- [4] Chen W, Li Y, Zheng N, *et al.* DenoiseMamba: an innovative approach for EEG artifact removal leveraging mamba and CNN. *IEEE J Biomed Heal Inform*, 2025, **29**(9): 6551-6564
- [5] Guo S, Wang Y, Liu Y, *et al.* A time-frequency attention-based EEG artifact removal network by interacting and fusing artifact representation. *IEEE Sens J*, 2025, **25**(21): 40061-40071
- [6] Yedukondalu J, Sunkara K, Rejeti V K K, *et al.* Single-channel EOG artifact removal using fixed frequency EWT and GMETV filter. *Sci Rep*, 2025, **15**: 38671
- [7] Alkhoury L, Scanavini G, Louviot S, *et al.* Artifact-reference multivariate backward regression (ARMBR): a novel method for EEG blink artifact removal with minimal data requirements. *J Neural Eng*, 2025, **22**(3): 036048
- [8] Ille N, Nakao Y, Yano S, *et al.* Ongoing EEG artifact correction using blind source separation. *Clin Neurophysiol*, 2024, **158**: 149-158
- [9] Agounad S, Tarahi O, Moufassih M, *et al.* Advanced signal processing and machine/deep learning approaches on a preprocessing block for EEG artifact removal: a comprehensive review. *Circuits Syst Signal Process*, 2025, **44**(5): 3112-3160
- [10] Massar H, Stergiadis C, Nsiri B, *et al.* EMD-BSS: a hybrid methodology combining Empirical Mode Decomposition and Blind Source Separation to eliminate the ocular artifacts from EEG recordings. *Biomed Signal Process Control*, 2024, **95**: 106475
- [11] Yin J, Liu A, Wang L, *et al.* Integrating spatial and temporal features for enhanced artifact removal in multi-channel EEG recordings. *J Neural Eng*, 2024, **21**(5): 056081
- [12] Bailey N W, Hill A T, Godfrey K, *et al.* EEG is better when cleaning effectively targets artifacts. *Clin Neurophysiol*, 2025,

- 180**: 2111378
- [13] Shi W, Li Y, Cai N, *et al.* Removal of ocular and muscular artifacts from multi-channel EEG using improved spatial-frequency filtering. *IEEE J Biomed Heal Inform*, 2024, **28**(6): 3466-3477
- [14] Chen X, Liu A, Chiang J, *et al.* Removing muscle artifacts from EEG data: multichannel or single-channel techniques. *IEEE Sens J*, 2016, **16**(7): 1986-1997
- [15] Gong S, Xing K, Cichocki A, *et al.* Deep learning in EEG: advance of the last ten-year critical period. *IEEE Trans Cogn Dev Syst*, 2022, **14**(2): 348-365
- [16] Chen X, Li C, Liu A, *et al.* Toward open-world electroencephalogram decoding via deep learning: a comprehensive survey. *IEEE Signal Process Mag*, 2022, **39**(2): 117-134
- [17] 何欢, 肖晓琳, 岳璠, 等. 静息态自发脑电与任务态诱发脑电的作用关系研究. *生物医学工程学杂志*, 2025, **42**(3): 620-627
He H, Xiao X L, Yue J, *et al.* *J Biomed Eng*, 2025, **42**(3): 620-627
- [18] Cui H, Li C, Liu A, *et al.* A dual-branch interactive fusion network to remove artifacts from single-channel EEG. *IEEE Trans Instrum Meas*, 2024, **73**: 4001912
- [19] Yang B, Duan K, Fan C, *et al.* Automatic ocular artifacts removal in EEG using deep learning. *Biomed Signal Process Control*, 2018, **43**: 148-158
- [20] Nguyen H T, Musson J, Li F, *et al.* EOG artifact removal using a wavelet neural network. *Neurocomputing*, 2012, **97**: 374-389
- [21] Gao T, Chen D, Tang Y, *et al.* EEG reconstruction with a dual-scale CNN-LSTM model for deep artifact removal. *IEEE J Biomed Heal Inform*, 2023, **27**(3): 1283-1294
- [22] Zhang H, Zhao M, Wei C, *et al.* EEGdenoiseNet: a benchmark dataset for deep learning solutions of EEG denoising. *J Neural Eng*, 2021, **18**(5): 056057
- [23] Klados MA, Bamidis PD. A semi-simulated EEG/EOG dataset for the comparison of EOG artifact rejection techniques. *Data Brief*, 2016, **8**: 1004-1006
- [24] Chen X, Chen Q, Zhang Y, *et al.* A novel EEMD-CCA approach to removing muscle artifacts for pervasive EEG. *IEEE Sens J*, 2019, **19**(19): 8420-8431
- [25] Goldberger A L, Amaral L A, Glass L, *et al.* PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. *Circulation*, 2000, **101**(23): E215-E220
- [26] Moody G B, Mark R G. The impact of the MIT-BIH arrhythmia database. *IEEE Eng Med Biol Mag*, 2001, **20**(3): 45-50
- [27] Sweeney K T, Ayaz H, Ward T E, *et al.* A methodology for validating artifact removal techniques for physiological signals. *IEEE Trans Inf Technol Biomed*, 2012, **16**(5): 918-926
- [28] Yin J, Liu A, Li C, *et al.* A GAN guided parallel CNN and transformer network for EEG denoising. *IEEE J Biomed Heal Inform*, 2025, **29**(6): 3930-3941
- [29] Gramfort A. MEG and EEG data analysis with MNE-Python. *Front Neurosci*, 2013, **7**: 267
- [30] Tangermann M, Müller K R, Aertsen A, *et al.* Review of the BCI competition IV. *Front Neurosci*, 2012, **6**: 55
- [31] Jurcak V, Tsuzuki D, Dan I. 10/20, 10/10, and 10/5 systems revisited: their validity as relative head-surface-based positioning systems. *NeuroImage*, 2007, **34**(4): 1600-1611
- [32] Sun W, Su Y, Wu X, *et al.* A novel end-to-end 1D-ResCNN model to remove artifact from EEG signals. *Neurocomputing*, 2020, **404**: 108-121
- [33] Nagar S, Kumar A, Swamy M N S. Orthogonal features-based EEG signal denoising using fractionally compressed autoencoder. *Signal Process*, 2021, **188**: 108225
- [34] Sawangjai P, Trakulrangoj M, Boonnag C, *et al.* EEGANet: removal of ocular artifacts from the EEG signal using generative adversarial networks. *IEEE J Biomed Heal Inform*, 2022, **26**(10): 4913-4924
- [35] Rakhmatulin I, Dao M S, Nassibi A, *et al.* Exploring convolutional neural network architectures for EEG feature extraction. *Sensors (Basel)*, 2024, **24**(3): 877
- [36] Zhang H, Wei C, Zhao M, *et al.* A novel convolutional neural network model to remove muscle artifacts from EEG//IEEE. ICASSP 2021 - 2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Toronto, Ontario, Canada: IEEE, 2021: 1265-1269
- [37] Ma X, Chen W, Pei Z, *et al.* Attention-based convolutional neural network with multi-modal temporal information fusion for motor imagery EEG decoding. *Comput Biol Med*, 2024, **175**: 108504
- [38] Xing L, Casson A J. Deep autoencoder for real-time single-channel EEG cleaning and its smartphone implementation using TensorFlow lite with hardware/software acceleration. *IEEE Trans Biomed Eng*, 2024, **71**(11): 3111-3122
- [39] Pei Y, Xu J, Chen Q, *et al.* DTP-net: learning to reconstruct EEG signals in time-frequency domain by multi-scale feature reuse. *IEEE J Biomed Heal Inform*, 2024, **28**(5): 2662-2673
- [40] Chikkankod A V, Longo L. On the dimensionality and utility of convolutional autoencoder's latent space trained with topology-preserving spectral EEG head-maps. *MAKE*, 2022, **4**(4): 1042-1064
- [41] Goodfellow I J, Pouget-Abadie J, Mirza M, *et al.* Generative adversarial nets//Ghahramani Z, Welling M, Cortes C, *et al.* Proceedings of the 28th International Conference on Neural Information Processing Systems. Montreal, Canada: MIT Press, 2014, **2**: 2672-2680
- [42] Chakraborty T, Reddy K S U, Naik S M, *et al.* Ten years of generative adversarial nets (GANs): a survey of the state-of-the-art. *Mach Learn Sci Technol*, 2024, **5**(1): 011001
- [43] Senthilkumar S, Kumaresan P, Brindha K, *et al.* Advanced progress in optimized generative adversarial network applications across domains: a comprehensive survey. *Arch Comput Meth Eng*, 2026, **33**(1): 1467-1483
- [44] Vaswani A, Shazeer N, Parmar N, *et al.* Attention is all you need//Guyon I, Luxburg UV, Bengio S, *et al.* Proceedings of the 31st International Conference on Neural Information Processing Systems, Long Beach, CA, USA: Curran Associates, Inc, 2017: 6000-6010
- [45] Chuang C H, Chang K Y, Huang C S, *et al.* Augmenting brain-

- computer interfaces with ART: an artifact removal transformer for reconstructing multichannel EEG signals. *NeuroImage*, 2025, **310**: 121123
- [46] Pu X, Yi P, Chen K, *et al.* EEGDnet: fusing non-local and local self-similarity for EEG signal denoising with transformer. *Comput Biol Med*, 2022, **151**: 106248
- [47] N G R, Guha D, Mahadevappa M. EEG artifact removal using stacked multi-head attention transformer architecture//IEEE. 2024 46th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC). Orlando, FL, USA: IEEE, 2024: 1-6
- [48] 尹瑾, 刘爱萍, 李畅, 等. 基于并行 CNN 和 Transformer 的脑电降噪网络. 信号处理, 2023, **39**(8): 1419-1432
- Yin J, Liu AP, Li C, *et al.* *J Signal Process*, 2023, **39**(8): 1419-1432
- [49] Huang X, Li C, Liu A, *et al.* EEGDfus: a conditional diffusion model for fine-grained EEG denoising. *IEEE J Biomed Heal Inform*, 2025, **29**(4): 2557-2569
- [50] Pedroni A, Bahreini A, Langer N. Automagic: standardized preprocessing of big EEG data. *NeuroImage*, 2019, **200**: 460-473
- [51] Stalin S, Roy V, Shukla P K, *et al.* A machine learning-based big EEG data artifact detection and wavelet-based removal: an empirical approach. *Math Probl Eng*, 2021, **2021**(1): 2942808
- [52] Michel C M, Koenig T. EEG microstates as a tool for studying the temporal dynamics of whole-brain neuronal networks: a review. *Neuroimage*, 2018, **180**(Pt B): 577-593
- [53] Babiloni C, Barry R J, Başar E, *et al.* International Federation of Clinical Neurophysiology (IFCN) -EEG research workgroup: recommendations on frequency and topographic analysis of resting state EEG rhythms. Part 1: applications in clinical research studies. *Clin Neurophysiol*, 2020, **131**(1): 285-307
- [54] Lehnertz K, Bröhl T. Functional importance backbones of the brain at rest, wakefulness, and sleep. *Brain Sci*, 2025, **15**(7): 772
- [55] 许敏鹏. 脑-机接口中的事件相关电位编解码关键问题研究及应用[D]. 天津: 天津大学, 2015
- Xu M P. Research on The Key Problems of Coding and Decoding for The Event-related Potential and Its Applications in The Brain-Computer Interface[D]. Tianjin: Tianjin University, 2015
- [56] Morozova M, Yakovlev L, Syrov N, *et al.* Cortical responses to tactile imagery: a high-density EEG study of the μ -rhythm event-related desynchronization and somatosensory evoked potentials. *NeuroImage*, 2025, **319**: 121440
- [57] Luck S J, Kappenman E S. The Oxford Handbook of Event-Related Potential Components. Oxford: Oxford University Press, 2011
- [58] 肖晓琳. 基于微弱事件相关脑电特征的脑-机编解码关键技术及应用研究[D]. 天津: 天津大学, 2020
- Xiao X L. Research on Key Technologies and Applications of Brain-computer Coding and Decoding Based on Weak Event-related EEG Characteristics[D]. Tianjin: Tianjin University, 2020
- [59] Celestia G G, Brigell M G. Recommended standards for pattern electroretinograms and visual evoked potentials. *Electroencephalogr Clin Neurophysiol Suppl*, 1999, **52**: 53-67
- [60] 罗睿心, 郭思影, 李心怡, 等. 头皮表面拉普拉斯技术研究与应. 生物化学与生物物理进展, 2025, **52**(2): 425-438
- Luo R X, Guo S Y, Li X Y, *et al.* *Prog Biochem Biophys*, 2025, **52**(2): 425-438
- [61] 王坤. 脑-机接口中运动意图诱发脑电响应的关键特征强化与识别[D]. 天津: 天津大学, 2020
- Wang K. Enhancement and Recognition of Electroencephalography Features Induced by Movement Intention for Brain-computer Interfaces[D]. Tianjin: Tianjin University, 2020
- [62] Pérez-Velasco S, Marcos-Martínez D, Santamaría-Vázquez E, *et al.* Bridging motor execution and motor imagery BCI paradigms: an inter-task transfer learning approach. *Biomed Signal Process Control*, 2025, **107**: 107834
- [63] Xu M, Xiao X, Wang Y, *et al.* A brain-computer interface based on miniature-event-related potentials induced by very small lateral visual stimuli. *IEEE Trans Biomed Eng*, 2018, **65**(5): 1166-1175
- [64] Xiao X, Xu M, Jin J, *et al.* Discriminative canonical pattern matching for single-trial classification of ERP components. *IEEE Trans Biomed Eng*, 2020, **67**(8): 2266-2275
- [65] Zhou X, Xu M, Xiao X, *et al.* Detection of fixation points using a small visual landmark for brain-computer interfaces. *J Neural Eng*, 2021, **18**(4): 046098
- [66] Bleichner M G, Mirkovic B, Debener S. Identifying auditory attention with ear-EEG: cEEGrid versus high-density cap-EEG comparison. *J Neural Eng*, 2016, **13**(6): 066004
- [67] Rotaru I, Geirnaert S, Heintz N, *et al.* What are we really decoding Unveiling biases in EEG-based decoding of the spatial focus of auditory attention. *J Neural Eng*, 2024, **21**(1): 016017
- [68] Shoeb A H. Application of Machine Learning to Epileptic Seizure Onset Detection and Treatment[D]. Cambridge, USA: Harvard University-MIT Division of Health Sciences and Technology, 2009

Technique and Application of Deep Learning-based EEG Denoising*


SHAN Bao-Lian¹⁾, YU Hai-Qing^{1,2)}, HUANG Yong-Zhi^{1,2)}, MENG Jia-Yuan^{1,2)},
XU Min-Peng^{1,2)**}, JUNG Tzyy-Ping^{3)**}, MING Dong^{1,2)}

¹⁾Academy of Medical Engineering and Translational Medicine, Tianjin University, Tianjin 300072, China;

²⁾Haihe Laboratory of Brain-computer Interaction and Human-machine Integration, Tianjin 300072, China;

³⁾Swartz Center for Computational Neuroscience, University of California, San Diego, CA 92093, USA)

Graphical abstract



* This work was supported by grants from the National Key Research and Development Program of China (2023YFF1203705), The National Natural Science Foundation of China (62406220, 32541010, 82472101), and Tianjin Natural Science Foundation Project (23JCYBJC01440).

** Corresponding author.

XU Min-Peng. Tel: 86-22-83612122, E-mail: xmp52637@tju.edu.cn

JUNG Tzyy-Ping. Tel: 86-22-83612123, E-mail: tpjung@ucsd.edu

Received: April 29, 2026 Accepted: June 9, 2026

Abstract Electroencephalography (EEG) is a non-invasive neurophysiological monitoring technique. It records the electrical activity of the cerebral cortex using electrodes placed on the scalp surface. Owing to its high safety, portability, and millisecond-level temporal resolution, EEG has been widely utilized in a variety of fields, including clinical diagnosis, brain-computer interfaces (BCIs), and cognitive neuroscience research. However, due to its microvolt-level amplitude, EEG is highly susceptible to various artifacts, including electrooculographic (EOG), electrocardiographic (ECG), electromyographic (EMG), and power line interference (PLI). These artifacts can obscure genuine neural activity and introduce spurious electrophysiological features. Consequently, they may compromise EEG signal quality, thereby reducing the reliability of downstream analyses. To address this issue, numerous EEG artifact removal methods have been developed, including both traditional denoising techniques and deep learning-based approaches. Traditional EEG denoising methods have long served as the primary solutions for artifact removal. Representative approaches include filtering, regression, and blind source separation. Although these methods have demonstrated effectiveness in specific scenarios, they suffer from several inherent limitations. Filtering assumes that artifacts and EEG signals can be separated in the frequency domain, but many artifacts, such as EOG and EMG, overlap with EEG spectra, which may lead to the loss of valuable neural information. Regression methods require high-quality artifact references to estimate and subtract contaminations, limiting their effectiveness in reference-free scenarios. Blind source separation can remove artifacts without external references, but it typically requires the number of EEG channels to exceed the number of sources, restricting its application in single- or low-channel EEG recordings. Deep learning-based EEG denoising methods address these limitations effectively. First, they learn the nonlinear mapping between contaminated and clean EEG directly from data in an end-to-end manner. This approach does not rely on assumptions about spectral separability, thereby preserving neural activity more completely. Second, the reference information is incorporated during the training phase, allowing the trained model to perform artifact removal independently without external references. Third, deep learning models can be flexibly designed to accommodate various recording setups, achieving robust denoising for both high-density and single-channel EEG. Collectively, these advantages enable deep learning-based methods to overcome the main challenges of traditional approaches, providing more accurate and reliable EEG signal recovery. The superior denoising performance of deep learning-based EEG denoising methods has attracted increasing attention in EEG artifact removal research. As a result, many deep learning-based denoising methods have been developed and successfully applied in neural engineering areas. However, a systematic review of the techniques and applications in this field is still lacking. To address this gap, this paper reviews recent advances in deep learning-based EEG denoising from four perspectives: technical principle, benchmark dataset, denoising model, and evaluation method. Representative applications in neural signal analysis and BCI decoding are also summarized. Furthermore, the advantage, existing challenge, and future research direction of deep learning-based EEG denoising are discussed. This review aims to provide valuable theoretical insights and technical guidance for researchers. It is also expected to promote further advances and broader applications of deep learning-based EEG denoising techniques.

Key words electroencephalography, EEG denoising, deep learning

DOI: 10.3724/j.pibb.2026.0229

CSTR: 32369.14.pibb.20260229