

基于多分支特征生成对抗网络的脑电信号去噪方法

缪佳伶¹, 何倬利^{1,2}, 王德清³, 颜佳泉^{1*}, 陈海兰⁴, 冯慧斌¹

(1. 闽江学院计算机与大数据学院, 数字福建智能化生产物联网实验室, 福建 福州 350108; 2. 福州大学计算机与大数据学院, 福建 福州 350108; 3. 厦门大学信息学院, 福建 厦门 361102; 4. 集美大学理学院, 福建 厦门 361021)

摘要: [目的] 针对单分支深度学习模型在脑电 (electroencephalography, EEG) 信号去噪的应用中存在特征提取能力不足、细节信息丢失、易受对抗样本攻击等问题, 提出一种基于多分支特征生成对抗网络 (multi-level feature generation adversarial network, MFGAN), 以提升对 EEG 信号的去噪性能。[方法] 构建多分支生成器: 分别采用卷积神经网络 (convolution neural network, CNN) 提取浅层特征, 利用基于 Transformer 的编码器获取上下文关联特征, 加深 CNN 结构以捕获深层复杂细节特征; 设计基于注意力机制的特征自筛选融合模块 (feature self-filtering fusion module, FSFM), 采用并行结构结合自注意力机制和通道注意力机制提炼优化特征融合, 剔除噪声成分。采用生成对抗的方式训练参数, 提升生成质量和抗攻击能力。[结果] 在 EEGdenoisenet 和 MIT-BIH arrhythmia 数据集上的定性和定量实验表明: 在多种单一伪影或混合伪影干扰下, MFGAN 的相关系数、信噪比、相对均方根误差均表现最优, 且能有效减少波形失真和峰值溢出。[结论] MFGAN 通过多分支特征提取与注意力机制融合, 显著提升了 EEG 去噪效果, 为 EEG 信号处理提供了可靠方法, 适用于复杂噪声环境。

关键词: 脑电信号; 伪影消除; 生成对抗网络; 多分支生成器; 注意力机制

中图分类号: TP 911.7

文献标志码: A

文章编号: 0438-0479(2025)06-0992-13

An EEG denoising method based on multi-level feature generation adversarial network

MIAO Jialing¹, HE Zhuoli^{1,2}, WANG Deqing³, YAN Jiaquan^{1*},
CHEN Hailan⁴, FENG Huibin¹

(1. Fujian Provincial Key Laboratory of Information Processing and Intelligent Control, School of Computer and Big Data, Minjiang University, Fuzhou 350108, China; 2. College of Computer and Data Science, Fuzhou University, Fuzhou 350108, China; 3. School of Informatics, Xiamen University, Xiamen 361102, China; 4. School of Science, Jimei University, Xiamen 361021, China)

Abstract: [Objective] Electroencephalography (EEG) is a widely used method for detecting brain electrical activities. It offers advantages of non-invasiveness, high temporal resolution, and cost-effectiveness. Nevertheless, EEG signals are susceptible to being affected by physiological artifacts during the recording process due to their low amplitude, which may mislead the data analysis and seriously affect the interpretation of results. Currently, most deep learning methods for EEG denoising typically employ a single-level structure, thereby suffering from limited feature representation and loss of signal details. [Methods] To tackle this issue, we proposed a multi-level feature generation adversarial network (MFGAN) for EEG denoising. To begin with, we construct a multi-level

收稿日期: 2024-11-02 录用日期: 2025-09-03

基金项目: 福建省发树慈善基金会资助研究专项 (MFK23006); 闽江学院科教联合专项 (MJKJ24006); 福建省自然科学基金面上项目 (2023J01807); 福建省自然科学基金引导性项目 (2021H0054); 集美大学科研启动基金 (ZQ2021028); 福建省工业引导性(重点)项目 (2023H0001)

* 通信作者: yanjiaquan@mju.edu.cn

引文格式: 缪佳伶, 何倬利, 王德清, 等. 基于多分支特征生成对抗网络的脑电信号去噪方法[J]. 厦门大学学报(自然科学版), 2025, 64(6): 992-1004.

Citation: MIAO J L, HE Z L, WANG D Q, et al. An EEG denoising method based on multi-level feature generation adversarial network[J]. J Xiamen Univ Nat Sci, 2025, 64(6): 992-1004. (in Chinese)



generator with the following steps: At the first level, we utilize the convolution neural network (CNN) to learn the shallow features of the target signal. At the second level, we use a Transformer-based encoder to obtain the contextual features from the EEG signal. At the third level, we deepen the CNN structure to acquire the deep detailed features of the signal. Furthermore, a feature self-filtering fusion module (FSFM) based on the attention mechanism is designed in the generator for extracting the multi-level features. FSFM applies a self-attention mechanism to filter feature information after channel interaction and a channel attention mechanism to capture feature information of each channel. These two mechanisms run parallel to each other, effectively fusing the aforementioned feature information and eliminating noise components. [Results] This method was qualitatively and quantitatively validated using the EEGdenoisenet and MIT-BIH arrhythmia datasets, with the aim to evaluate the denoising performance of MFGAN on electrooculography (EOG), electromyography (EMG), electrocardiography (ECG) and hybrid artifacts (EMG and EOG) in EEG signals. A systematic evaluation was conducted using three performance indicators, including correlation coefficient (CC), signal-to-noise ratio (SNR), and relative root mean square error (RRMSE). In qualitative experiments, we compared the denoising effects of different methods under ECG and EOG noise conditions. Results indicate that MFGAN can greatly reduce peak overflow and waveform distortion, thereby producing samples that more closely resemble pure EEG signals. In quantitative experiments, the proposed method outperformed the previous optimal method across three evaluation metrics. Specifically, in the EMG single noise environment, the proposed method led to a 0.99% increase in CC, a 4.26% increase in SNR, and a 6.72% decrease in RRMSE compared to the suboptimal model. Besides, compared to the suboptimal model the CC increased by 2.1%, the SNR increased by 6.49%, and the RRMSE decreased by 8.69% in the hybrid dual-noise environment. To gain a better intuitive understanding of the differences in denoising effects between different methods, we also visualized the quantitative results that highlight the superiority and potential of MFGAN in EEG denoising. [Conclusion] The proposed model is based on the generative adversarial network (GAN) structure, which integrates CNN, Transformer, and advanced CNN to sensitively capture shallow details of the signal, understand contextual dependencies and enhance the level of feature extraction to reveal the hidden deep patterns. In addition, introducing attention mechanisms to optimize the feature fusion further promotes the denoising performance. Experimental results show that MFGAN outperforms current mainstream denoising techniques and excels in diverse noisy environments. Consequently, this study not only offers an effective solution to the problem of inadequate feature extraction in conventional single-level architectures, but also presents a dependable data processing approach for neuroscience research.

Keywords: electroencephalography; artifact elimination; generation adversarial network; multi-level generator; attention mechanism

脑电图(electroencephalography, EEG)是人脑神经活动的生理电信号放大后的图形信号,通过在头皮上放置导电电极来测得^[1]. 目前,EEG在临床诊断^[2]、神经科学^[3]、脑机接口技术^[4]以及心理健康和神经反馈^[5-6]等领域得到广泛应用. 然而,由于EEG信号的振幅较低,在实际采集过程中极易受到眼电(electrooculography, EOG)、心电(electrocardiography, ECG)或肌电(electromyography, EMG)等生理伪影干扰,直接影响脑疾病自动诊断的性能. 因此,构建有效的生理伪影消除方法对EEG应用具有至关重要的意义.

传统的信号降噪方法可归纳为信号分解、滤波处理、数据降维以及混合方法四类. 基于信号分解的EEG伪影去除方法将受污染的目标信号分解为一组固有模态函数(intrinsic mode function, IMF),选取与目标信号相关的IMF分量进行重构实现伪影干扰消除,如变分模态分解(variational mode decomposition, VMD)^[7]、集成经验模态分解(ensemble empirical mode decomposition, EEMD)^[8]和互补EEMD^[9]. 滤波处理方法根据信号和噪声的频率特性,通过设计滤波器来

抑制噪声,包括非递归型滤波器^[10]、维纳滤波^[11]以及卡尔曼滤波^[12]等. 基于数据降维的EEG伪影抑制方法将高维数据向低维映射,在舍弃冗余特征的同时,保持低维空间中目标信号特征,以达到去噪目的,如主成分分析^[13]和独立成分分析(independent component analysis, ICA)^[14]等. 此外,研究人员提出基于混合的方法来实现更高效的EEG去噪效果,包括FastICA-VMD^[15]、EMD-ICA^[16]和EMD-CCA^[17]等. 然而,上述方法只适用于某些特定的EEG去噪任务,并且无法避免参数的人工设定问题,严重影响去噪性能. 此外,随着数据量和算法复杂度的爆炸式增长,已难以满足当前的EEG信号处理需求.

与传统方法相比,深度学习方法能够脱离人为干预,从海量数据中学习所需的特征信息,在EEG信号的特征学习方面逐渐显示出优势. 具体来说,信号分解方法存在特征混叠问题^[18-19];由于ECG、EOG和EMG伪影与EEG信号存在频域上的混叠^[20-22],基于滤波器的EEG去噪方法无法消除目标信号的带内伪影干扰;数据降维方法则依赖于特定的数学假设^[23]. 深

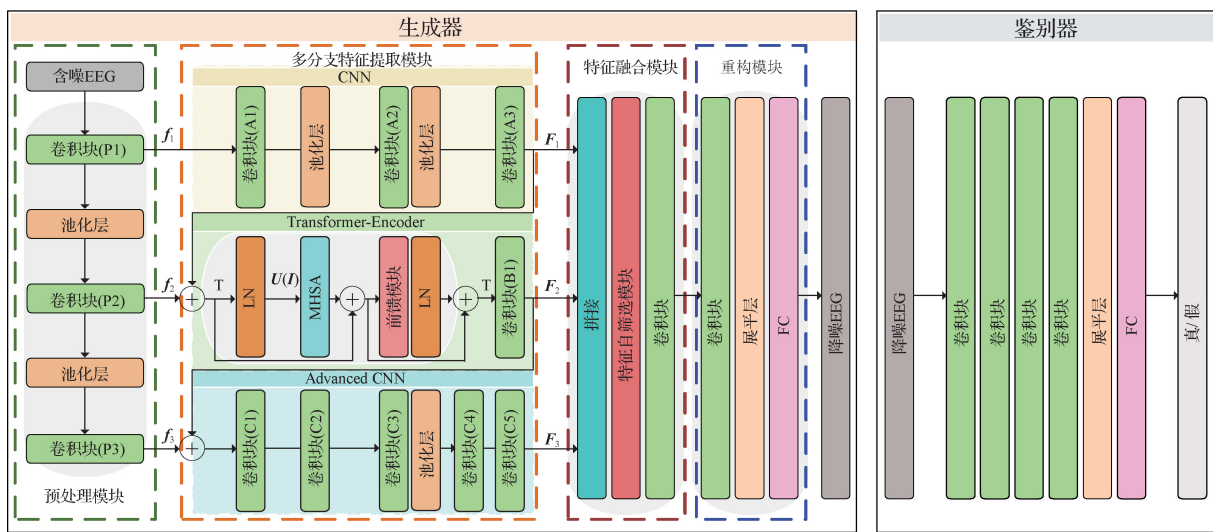
度学习方法的优势在于其能够通过多层次的非线性变换,自动提取 EEG 信号中的高阶特征,如 Mahmud 等^[24]提出一种多层多分辨率的空间池化网络,用于信号重建,从而避免传统方法依赖人工设计特征的局限性,显著提升了特征提取的效率.此外,随着深度学习技术的不断发展,越来越多的创新模型被应用于 EEG 信号处理领域. Pu 等^[25]引入 Transformer 结构,借助自注意力机制和前馈模块,分别分析 EEG 信号的非局部与局部自相似性达到噪声抑制效果. Chuang 等^[26]开发一种基于 U-Net 的伪影去除模型. Nagar 等^[27]研发一种结合卷积神经网络(convolution neural network, CNN)和自编码器的 EEG 降噪模型. Zhang 等^[28]为深度学习驱动的脑电信号去噪研究设计了一个公开数据和 4 个深度神经网络基准模型,包括全连接网络(fully-connected neural network, FCNN)、简单 CNN、复杂 CNN 以及循环神经网络.为解决 EMG 伪影去除任务中的过拟合问题, Zhang 等^[29]提出一种新型的 CNN 模型,采用逐渐上升的特征维度和时间序列下采样策略来优化模型性能.但是,上述方法容易受到对抗样本的攻击,样本扰动可能会欺骗模型,导致去噪性能急剧下降^[30-31].

为了解决这个问题,生成对抗网络(generative adversarial networks, GAN)^[32]通过生成器与鉴别器之间的对抗训练,不仅能够应对对抗样本攻击问题,还有利于增强生成样本的质量. An 等^[33]提出一种基于 GAN 的多通道脑电信号 EEG 去噪方法. Dong 等^[34]设计一种基于 Wasserstein GAN 的深度学习框架,可以在短时间内对大量原始脑电数据进行去噪处

理. Gulrajani 等^[35]提出一种基于梯度惩罚的 Wasserstein 生成对抗网络(WGAN-GP)的 EEG 降噪算法.然而,大多数 GAN 模型的生成器采用单分支网络结构,仅考虑到脑电信号在时间维度上的动态演变规律,忽略了深层特征挖掘和不同脑区之间的关联特征;另外,在多噪声源的去噪任务中,单一尺度的特征学习难以有效地区分出目标信号和噪声干扰.针对上述问题,本文提出一种多分支特征生成对抗网络(multi-level feature generation adversarial network, MFGAN). MFGAN 采用多分支特征提取的生成器,分别获取脑电信号的浅层特征、关联特征和深层特征.为了避免特征拼接引起的特征集维度过高,本文设计一个基于注意力机制的特征自筛选融合模块(feature self-filtering fusion module, FFSM),对每个通道进行信息筛选和重建,以实现有效的特征融合.

1 本文方法

MFGAN 模型如图 1 所示,该网络由多分支生成器和鉴别器组成.多分支生成器包括预处理模块、多分支特征提取模块、特征融合模块和重构模块.首先,预处理模块对含噪声的 EEG 信号进行升维操作,增强其特征表达能力;其次,将高维特征送入多分支特征提取模块进一步提取多级特征.接着,通过特征融合模块对多级特征进行筛选和重建,以剔除无关特征的干扰.最后,重构模块将特征映射回原始维度,生成降噪后的 EEG 信号.鉴别器堆叠多个卷积块,逐层学习复杂特征,并与生成器进行对抗性训练,不断优化



LN:层归一化;MHSA:多头自注意力;FC:全链接.

图 1 MFGAN 的网络结构

Fig. 1 The network structure of MFGAN

生成的样本,以获得纯净信号。

1.1 多分支生成器

1.1.1 预处理模块

预处理模块通过逐层提取 EEG 信号的特征信息,确保后续多分支特征提取模块的每个分支能够获取不同层次的特征信息,针对特定特征进行深入挖掘。具体地,预处理模块由 3 个卷积块和 2 个平均池化层构成。其中,卷积块 P1~P3 各包含 2 个卷积核为 1×3 的卷积层、一个批归一化(batch normalization, BN)层和一个连续可微指数线性单元(CELU)激活层;2 个平均池化层的池化核为 2,步长为 2。卷积块 P1~P3 提取的特征 f_1 、 f_2 和 f_3 分别作为三个分支特征提取模块的输入。平均池化层用于平滑特征图,在保留关键特征的同时压缩信息,降低模型计算量。

1.1.2 多分支特征提取模块

多分支特征提取模块由 CNN、Transformer-Encoder 和 Advanced CNN 3 个分支组成。CNN 分支用于捕获信号浅层特征 F_1 ;Transformer-Encoder 分支利用注意力机制提取信号中的上下文关联特征 F_2 ;Advanced CNN 分支提取信号的复杂深层特征 F_3 。

CNN 分支由 3 个卷积块和 2 个平均池化层组成。每个卷积块包含 4 个 1×3 的卷积层、1 个 BN 层和 1 个带池漏的修正线性单元(LeakyReLU)激活层。由表 1 可看出,该分支通过逐渐增加卷积层的输出通道数,

表 1 生成器的部分体系结构

Tab. 1 Partial architecture of the generator

模块	卷积块	卷积层数	卷积核	步长	输出尺寸
预处理模块	P1	2	1×3	1	$128 \times 32 \times 256$
	P2	2	1×3	1	$128 \times 256 \times 128$
	P3	2	1×3	1	$128 \times 256 \times 64$
CNN	A1	4	1×3	1	$128 \times 64 \times 256$
	A2	4	1×3	1	$128 \times 128 \times 128$
	A3	4	1×3	1	$128 \times 256 \times 64$
Advanced CNN	TE	B1	1×3	2	$128 \times 256 \times 96$
	C1	3	1×3	1	$128 \times 512 \times 160$
	C2	3	1×3	1	$128 \times 1\ 024 \times 160$
	C3	3	1×3	1	$128 \times 1\ 024 \times 160$
	C4	3	1×3	1	$128 \times 512 \times 80$
C5	3	1×3	1	$128 \times 256 \times 80$	

注:表中 P1~P3 层的输出对应 $f_1 \sim f_3$;A3、B1、C5 层的输出对应 $F_1 \sim F_3$;TE 为 Transformer-Encoder。

来增加特征的维度和表达能力。平均池化层用于缩减特征图,旨在保留主要特征的同时,提取更抽象的特征。利用卷积层和池化层的层层叠加的结构,捕获信号的边缘特征和细微局部特征。

Transformer-Encoder 由 MHSA 模块、前馈网络以及卷积块 B1 组成^[36]。MHSA 通过将输入序列投影到多个子空间,并在每个子空间内独立计算注意力分数,从而构建输入序列中不同位置的依赖关系,并捕捉输入信号的上下文信息。对于第 h 个注意力头,特征图 U 计算得到的查询向量 Q_h ,键向量 K_h 和值向量 V_h 分别为:

$$Q_h = UW_h^Q, K_h = UW_h^K, V_h = UW_h^V, \quad (1)$$

式中: U 为 I 经过 LN 后的特征, I 由 f_2 与 F_1 拼接后经过 T 转置操作得到, U 作为输入使得 MHSA 考虑到不同层次特征之间的交互; W_h^Q, W_h^K, W_h^V 是线性映射的参数矩阵; $h = 1, 2, 3, \dots, H$, 表示第 h 个注意力头, H 表示注意力头的数量,本文设置为 8。MHSA 的计算式为:

$$\text{Attention}(Q_h, K_h, V_h) = \text{Softmax}\left(\frac{Q_h K_h^T}{\sqrt{d_K}}\right) V_h, \quad (2)$$

$$h_h = \text{Attention}(Q_h, K_h, V_h), \quad (3)$$

式中, $\sqrt{d_K}$ 是缩放因子,用于防止点积值过大导致 softmax 函数的梯度消失。MHSA 的最终输出结果由各子空间的输出拼接得到,并通过投影矩阵 W^O 变换回原始维度:

$$\text{MultiHead}(U) = \text{concat}(h_1, h_2, \dots, h_H) W^O. \quad (4)$$

前馈神经网络由两个 FC 层和激活函数 Swish 组成,旨在对关联特征进行非线性变换和映射,从而进一步增强模型的表达能力。

相对于 CNN 分支,Advanced CNN 分支采用 5 个堆叠的卷积块,每个卷积块含 3 个卷积核为 1×3 ,步长为 1 的卷积层。随着网络深度的增加,Advanced CNN 能捕捉和学习到更深层次的特征信息,对输入信号进行更精细的处理和分析。此外,该层将特征 f_3 与 F_2 融合作为输入,整合不同层次的特征信息,构建更加丰富的特征表示,增强了模型处理复杂任务的能力。

1.1.3 特征自筛选融合模块

文献[37]指出,EEG 信号在不同采样通道间存在部分相同信息,这种特性可用于优化特征提取过程。然而,现有研究工作在处理这种通道间信息时,往往没有充分考虑和利用这种重叠特性。基于此,本文设计了一个特征自筛选融合模块。如图 2 所示,该模块由通道自交互模块、通道注意力模块以及卷积块组成。其中,通道自交互模块用于筛选通道间的特征信

息,而通道注意力模块则用于提炼每个独立通道的特征信息.两个模块并行工作,充分利用3个分支的互补特征,实现全面的特征筛选与融合. B, C, D 分别为输入特征的样本数、通道数以及特征维度.




图2 特征自筛选模块的内部结构

Fig. 2 The internal structure of the feature self-screening module

通道自交互模块的工作原理如图3所示.首先,根据通道数将每个通道的输入特征图划分为与输入窗口等长的子块.随后,将不同通道相同位置的子块重排并拼接到新的通道中,从而打破原有通道间的固定结构,实现通道间的信息交互.接着,自注意力机制通过动态地分配权重,筛选全局信息,实现对关键特征的强化和冗余信息的抑制.最终,经过权重分配的子块将被映射回初始通道位置,生成通道自交互模块的输出.通道自交互过程定义为

$$\text{reshape}(\text{SelfAttention}(\text{reshape}(\mathbf{u}, \omega)), \omega), \quad (5)$$

式中, $\omega = D/C$, 为窗口大小; $\mathbf{u} \in \mathbb{R}^{B \times C \times D}$, reshape 为对特征的重排与拼接,两次重排和拼接会将重塑后的子块还原回初始位置.




图3 通道自交互模块的工作原理

Fig. 3 Working principle of channel self-interaction module

通道注意力机制计算每个通道的注意力权重,并根据贡献程度调整特征表示,使得模型能够更有效地利用各通道的信息,提高对输入数据的表征能力.通道注意力机制与通道自交互模块的结合,可实现通道间与通道内的信息交互和全局特征捕捉,实现两种注

意力机制的优势互补.

1.1.4 重构模块

重构模块由卷积块、展平层和 FC 层组成,用于将特征重构回与原始信号相同的维度.卷积块包含 2 个卷积层,卷积核大小为 1×3 ,步长为 1.展平层将卷积层输出的三维特征张量展平为二维特征张量,而全连接层则整合这些特征,并把输出映射回原始输入维度,得到生成器的最终输出.

1.2 鉴别器

鉴别器由 4 个卷积块、1 个展平层和 1 个 FC 层组成.每个卷积块包含两个卷积层,步长为 2,输出通道数分别为 $\{64, 128, 256, 512\}$.除此之外,这些卷积块内部其余的参数设置、激活函数的选择均与生成器中的多分支特征提取器保持一致,旨在确保二者在特征表示上达到一定程度的相似性.卷积层的输出经过展平层进行降维,转换为一维特征向量,随后输入全连接层进行二分类,识别输入样本与真实样本之间的差异,推动生成器不断改进其生成质量.

1.3 损失函数

本文使用的生成器和鉴别器的损失函数均在最小二乘 GAN(LSGAN)^[38]的基础上改进.

1.3.1 生成器损失函数

生成器损失 L_G 由均方误差(mean square error, MSE)损失 L_{mse} 、特征损失 L_{fea} 和对抗损失 L_{adv} 组成:

$$L_G = L_{mse} + \alpha L_{fea} + \beta L_{adv}, \quad (6)$$

式中 α 和 β 分别是特征损失和对抗损失的权重系数.本文将 α 设置为 0.5, β 设置为 0.05.

MSE 损失函数是脑电去噪领域中较为常用的一个损失函数.其计算过程如下:

$$L_{mse} = E_{(\mathbf{x}, \mathbf{z}) \sim p(\mathbf{x}, \mathbf{z})} [\|\mathbf{x} - G(\mathbf{z})\|_F^2], \quad (7)$$

式中, \mathbf{x} 为真实干净的 EEG 数据, \mathbf{z} 为随机噪声, G 为生成器.式(7)表示 (\mathbf{x}, \mathbf{z}) 服从联合概率分布 $p(\mathbf{x}, \mathbf{z})$, 求生成数据与真实数据之间的 Frobenius 范数平均误差.

特征损失通过约束真实样本和生成样本的高层特征来获得更高质量的结果:

$$L_{fea} = E_{(\mathbf{x}, \mathbf{z}) \sim p(\mathbf{x}, \mathbf{z})} \left[\frac{1}{A} \sum_{i=1}^A \frac{1}{S_i} \|\mathbf{F}_D^i G(\mathbf{x}) - \mathbf{F}_D^i G(\mathbf{z})\|_1 \right], \quad (8)$$

其中, A 表示卷积层的总数, S_i 表示第 i 层特征图的大小, \mathbf{F}_D^i 表示鉴别器中第 i 层卷积层提取的特征图.

对抗损失定义如下, D 表示鉴别器:

$$L_{adv} = \frac{1}{2} E_{\mathbf{z} \sim p_z(\mathbf{z})} [(D(G(\mathbf{z})) - 1)^2]. \quad (9)$$

1.3.2 鉴别器损失函数

本文鉴别器损失结合了文献[35]中的梯度惩罚,让鉴别器尽可能拉开真假样本的分数差,使得梯度范数保持相对稳定.其表达式如下:

$$L_D = \frac{1}{2} E_{x \sim p_{\text{data}}(x)} [(D(x) - 1)^2] + \frac{1}{2} E_{z \sim p_z(z)} [D(G(z))] + \lambda E_{z \sim p_z(z)} [(\|\nabla_{G(z)} D(G(z))\|_2 - 1)^2], \quad (10)$$

式中最后一项为梯度惩罚,表示在真实样本和生成样本分布连线上的随机插值取样. λ 为超参数,本文设为 0.5.

2 实 验

2.1 数据集

为验证所提出方法的有效性与泛化性,本文在多个开源数据集上进行对比实验,包括 EEGdenoisenet 数据集[28]和 MIT-BIH arrhythmia 数据集[39].

EEGdenoisenet 由 4 514 个纯净 EEG 片段、3 400 个 EOG 片段和 5 598 个 EMG 片段组成.所有信号均以 256 Hz 的采样率采集,每个片段的持续时间为 2 s.这一数据集的特性在于,它允许研究者将噪声信号与真实的纯净 EEG 信号进行合成,从而更真实地模拟实际场景.

MIT-BIH arrhythmia 数据集采集自贝斯以色列医院的住院患者与门诊患者,包含采样率为 360 Hz 的 ECG 片段.为了与 EEGDenoisenet 数据集兼容并生成可靠的半模拟数据,将 MIT-BIH arrhythmia 数据集降采样至统一的 256 Hz,得到 3 600 个 ECG 片段.对于半模拟数据,本文设计了一个调幅系数 c ,用于调整噪声数据的振幅,确保与 EEG 数据混合时,能达到最佳匹配效果.数据生成过程表示如下:

$$c = \frac{\text{MSE}(x_t)}{R_{\text{SN-A}} \cdot \text{MSE}(z_t)}, \quad (11)$$

$$y_t = x_t + c \cdot z_t, \quad (12)$$

其中: $R_{\text{SN-A}}$ 是目标信噪比,本文设置为 $[-4, 4]$,单位为 dB; z_t 是噪声, x_t 是干净的 EEG 片段, y_t 是所需的半模拟数据; $t \in [1, T]$, 为信号的采样点.通过式(12)可合成不同类型的半模拟数据,包括 EOG、ECG、EMG、混合双噪声 (EMG + EOG) 以及混合三噪声 (EMG + EOG + ECG) 污染的 EEG 信号.

2.2 评价指标

本文使用以下 3 种评价指标来评估模型的去噪

效果:相关系数 (correlation coefficient, CC)、信噪比 (signal to noise ratio, SNR) 和相对均方根误差 (relative root mean squared error, RRMSE). CC 用于度量两个变量间的线性关系程度,值越高表示去噪后的 EEG 和干净的 EEG 相关性越高,定义如下:

$$\text{CC} = \frac{\text{cov}(\mathbf{x}, \mathbf{Y})}{\sqrt{\text{var}[\mathbf{x}] \text{var}[\mathbf{Y}]}, \quad (13)$$

其中, \mathbf{x} 和 \mathbf{Y} 分别是干净的 EEG 和去噪后的 EEG, cov 表示计算协方差, var 表示计算方差. RRMSE 衡量了预测值与真实值之间的差异,计算式如下:

$$\text{RRMSE} = \frac{\text{RMSE}(\mathbf{Y} - \mathbf{x})}{\text{RMSE}(\mathbf{x})}, \quad (14)$$

式中 RMSE 为均方根误差,具体表示如下:

$$\text{RMSE}(\mathbf{Y}, \mathbf{x}) = \sqrt{\frac{1}{T} \sum_{t=0}^{T-1} (Y_t - x_t)^2}, \quad (15)$$

式中 t 为采样点,越低的 RRMSE 表示差异越小,模型的预测准确性越好. $R_{\text{SN-A}}$ 是指接收到的信号的强度与噪声强度的比值,计算式如下:

$$R_{\text{SN-A}} = 10 \log_{10} \frac{\sum_{t=0}^{T-1} x_t^2}{\sum_{t=0}^{T-1} (Y_t - x_t)^2}, \quad (16)$$

$R_{\text{SN-A}}$ 越高,表明信号受噪声污染的程度越低,反之,则信号受噪声干扰越显著.

2.3 实验细节

本实验基于 Pytorch 搭建神经网络框架,实验环境设置如表 2 所示.为保障实验的可重复性,代码运行过程中设置固定的随机种子.生成器和鉴别器都使用 Adam 优化器,学习率设置为 0.000 1,其中,生成器的动量参数分别为 0.5 和 0.9, epsilon 参数为 10^{-8} .此外,数据处理严格遵循十折交叉验证的原则,将两个数据集按照 9 : 1 划分训练集和测试集,再从训练集中随机选取 10% 的数据作为验证集.批处理大小设置为 128, EOG 和 ECG 噪声环境下的训练周期是 50, EMG 和两种混合噪声环境下的训练周期是 200.

表 2 实验环境配置

Tab. 2 Experimental environment setting

实验环境	具体配置
CPU	12th Gen Intel Core i9-12900K
GPU	NVIDIA GeForce RTX 4090
Python	Python 3.9
深度学习框架	Pytorch

2.4 实验结果与分析

为验证 MFGAN 模型的可行性与有效性,本文与最新的去噪模型 FCNN^[28]、NovelCNN^[29]、ResCNN^[40]、SimpleCNN^[28]、DuoCL^[41]进行实验对比.在本次实验中,为保证 GAN 模型的结构完整性,将对模型作为生成器,共同使用本文所提出的鉴别器.

FCNN 是一个具有四个隐藏层的 FC 网络,引入 dropout 正则化减少过拟合现象;NovelCNN 通过逐层递增的特征维度和时间序列下采样结构,有效的去除了 EEG 数据中的伪影;ResCNN 是一种结合残差学习与卷积神经网络的 EEG 去噪模型,通过多尺度

的残差块增强模型非线性表达能力;SimpleCNN 利用一维卷积层提取局部时序特征,结构简单且高效;DuoCL 集成双尺度 CNN 和长短期记忆模型,在 3 个阶段对原始 EEG 进行深度伪影去除.

2.4.1 定性比较

模型在 EEGdenoisenet 和 MIT-BIH arrhythmia 数据集上的定性比较结果如图 4 和 5 所示.

在 ECG 噪声环境下,EEG 带噪信号与纯净信号的波形存在明显偏差.经过本文方法与对比方法所得的去噪信号与纯净信号虽在细节处有所出入,但两者整体基本保持一致,尤其是本文所提方法 MFGAN 整

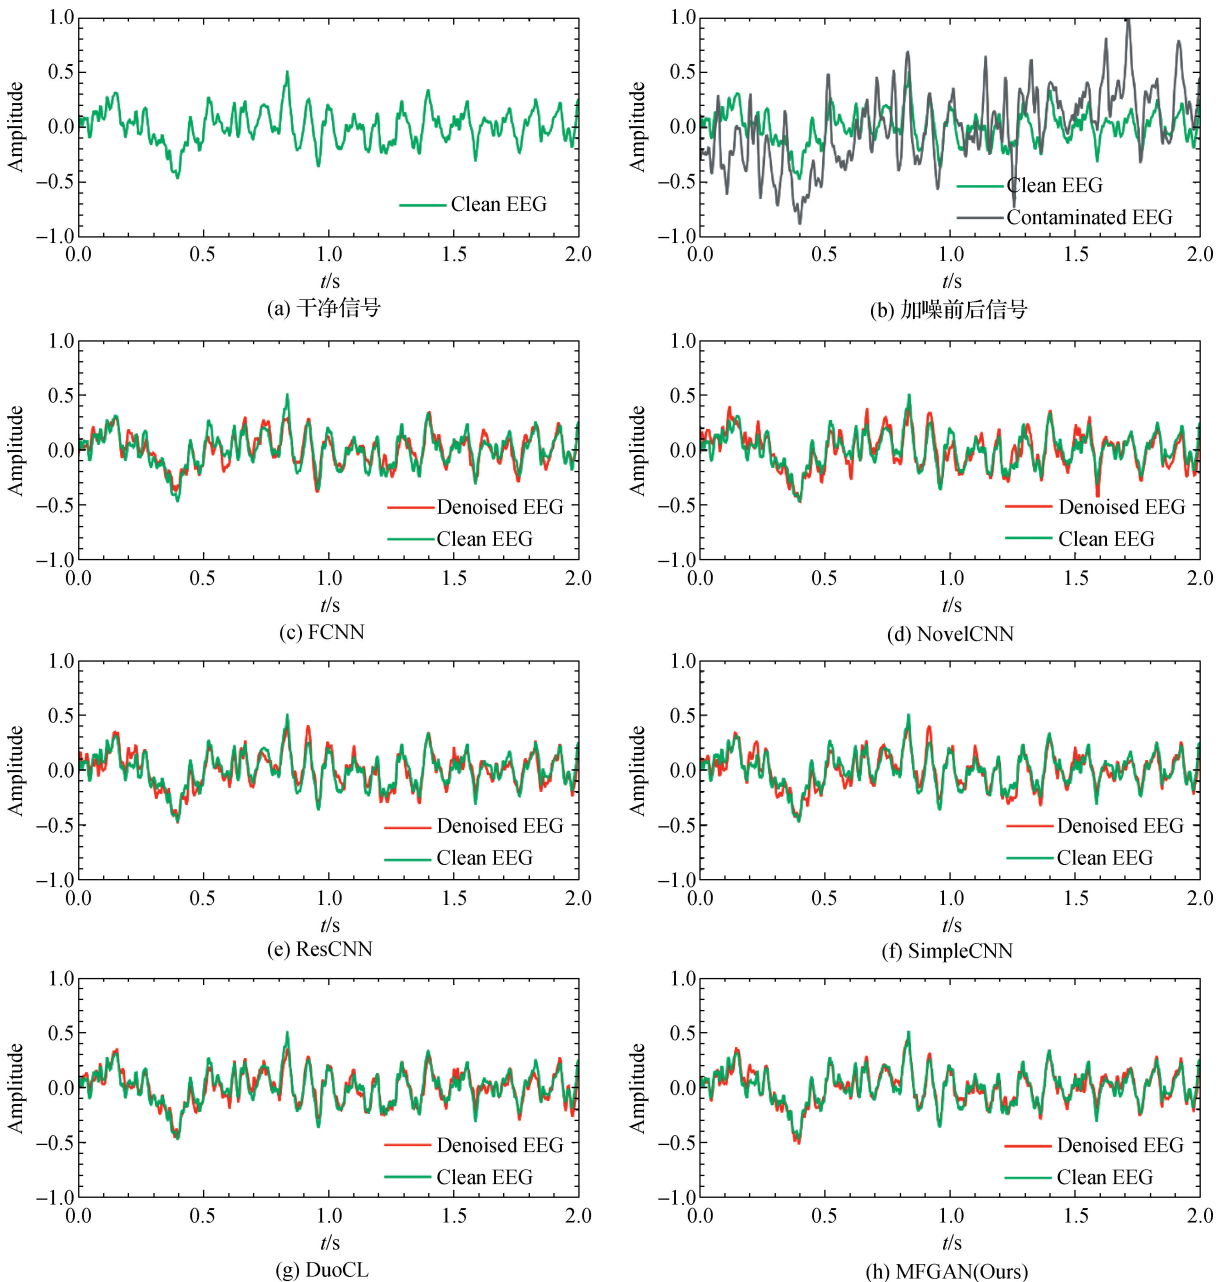


图 4 ECG 噪声环境下,不同方法在 EEGdenoisenet 数据集上的去噪效果对比

Fig. 4 Comparison of denoising effects of different methods in ECG noise environment on EEGdenoisenet dataset

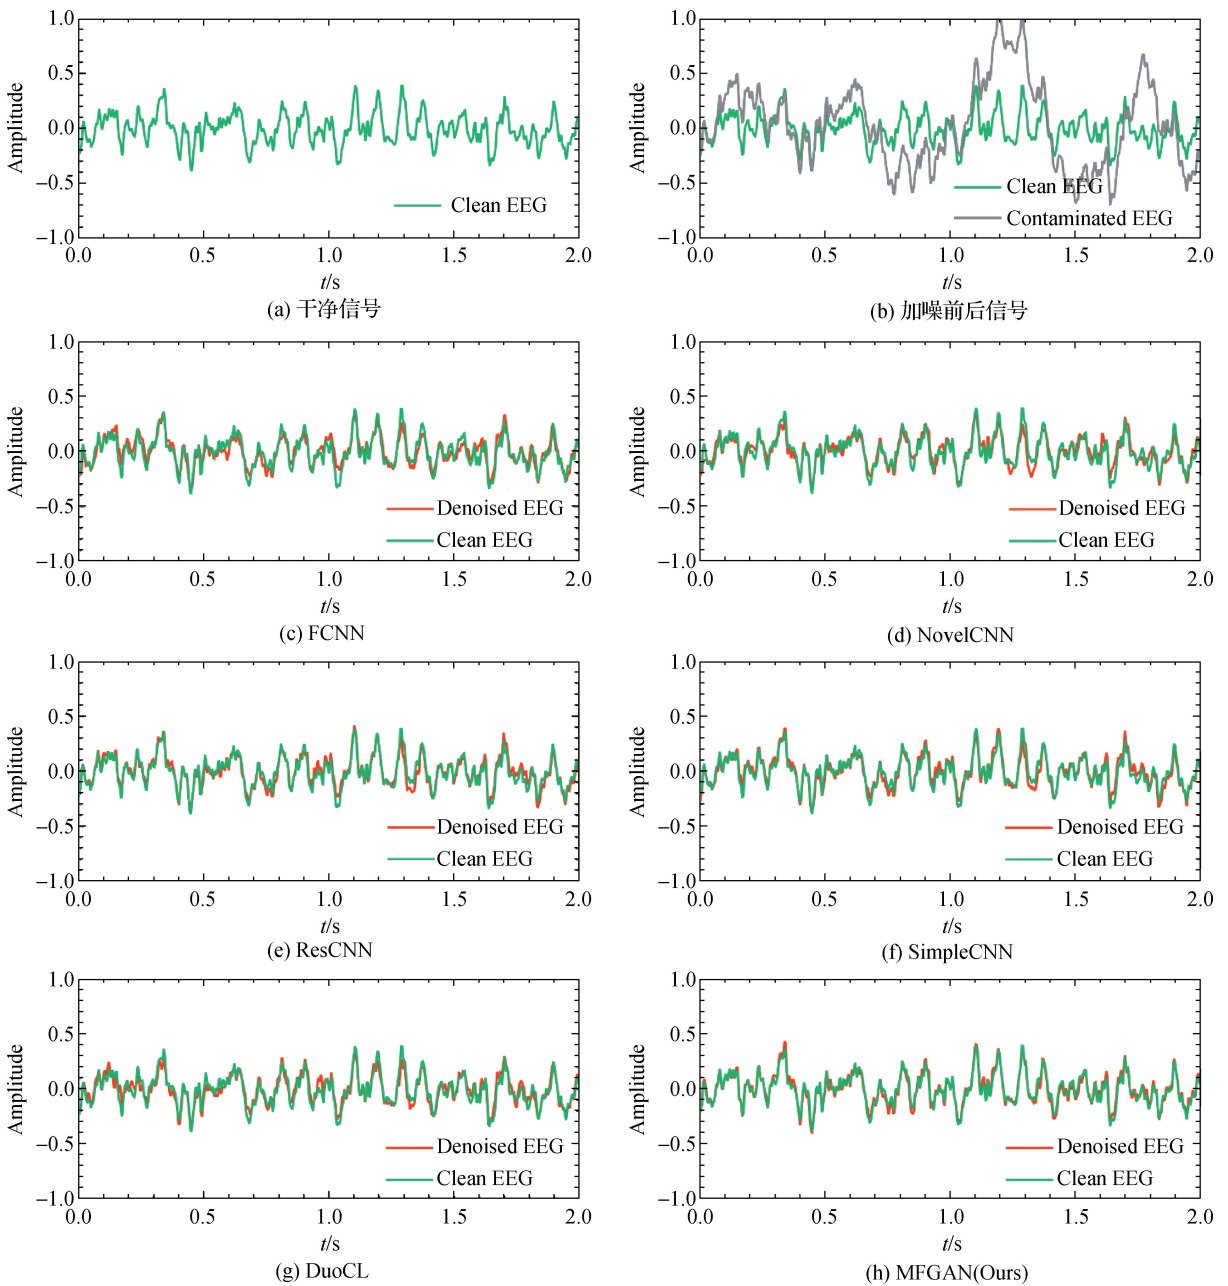


图 5 EOG 噪声环境下,不同方法在 MIT-BIH arrhythmia 数据集上的去噪效果对比

Fig. 5 Comparison of denoising effects of different methods in EOG noise environment on MIT-BIH arrhythmia dataset

体上更逼近目标信号,细节处峰值溢出和波形偏差较小,能够生成与纯净 EEG 信号更相似的样本.

在 EOG 环境下,MFGAN 与对比方法均能较好地实现信号去噪,本文方法 MFGAN 除了在个别位置存在细微的峰值溢出,几乎和干净信号重叠.为了更加直观地给出本文方法与对比方法的性能比较,下文给出本文方法与对比方法的定量对比结果.

2.4.2 定量比较

定量比较结果如表 3 所示,最佳结果以粗体显示.在 EOG、ECG 噪声的干扰下,ResCNN 和所提出

的 MFGAN 分别获得次优与最优的去噪效果.具体而言,MFGAN 相比 ResCNN 的 EOG、ECG 去噪,在 3 个关键指标上均有显著提升:平均 CC 分别提高了 0.82%、2.40%,平均 SNR 分别提高了 14.58%、19.15%,平均 RRMSE 分别降低了 11.86%、20.83%,表明所提出方法在滤除 EOG 和 ECG 噪声具有更加优异的性能.

在 EMG 噪声去除任务中,次优结果由 NovelCNN 和 DuoCL 获得,其中 NovelCNN 的 CC 指标较 DuoCL 略高,而 DuoCL 在 SNR 和 RRMSE 指标上优于

表 3 EEGdenoisenet 和 MIT-BIH arrhythmia 数据集上降噪信号和干净信号之间的 SNR、CC、RRMSE 指标(平均值±标准差)

Tab. 3 SNR, CC, RRMSE metrics (mean±standard) between denoised and clean signals on the EEGdenoisenet and MIT-BIH arrhythmia datasets

噪声类型	模型	CC	SNR/dB	RRMSE
EOG	FCNN	0.892 1±0.004 4	8.468 1±0.169 6	0.413 5±0.007 3
	NovelCNN	0.875 7±0.011 5	9.354 2±0.411 2	0.405 8±0.018 1
	SimpleCNN	0.940 0±0.003 5	11.553 3±0.251 3	0.301 1±0.008 2
	ResCNN	0.942 7±0.003 7	11.861 8±0.250 4	0.291 8±0.007 9
	DuoCL	0.915 6±0.007 9	11.077 5±0.631 3	0.334 2±0.018 6
	MFGAN(Ours)	0.950 4±0.004 1	13.590 8±0.309 1	0.257 2±0.011 2
ECG	FCNN	0.877 0±0.006 1	7.547 8±0.207 7	0.452 7±0.010 3
	NovelCNN	0.914 3±0.006 3	9.765 3±0.311 8	0.368 0±0.011 9
	SimpleCNN	0.937 8±0.003 2	10.580 1±0.279 0	0.325 9±0.009 6
	ResCNN	0.940 0±0.002 8	10.800 5±0.191 4	0.319 1±0.007 2
	DuoCL	0.930 6±0.004 1	10.549 1±0.282 1	0.330 8±0.010 0
	MFGAN(Ours)	0.962 6±0.001 7	12.868 9±0.157 8	0.252 6±0.005 8
EMG	FCNN	0.908 6±0.004 6	9.203 3±0.206 0	0.384 1±0.008 9
	NovelCNN	0.927 3±0.004 9	10.920 4±0.230 0	0.335 3±0.009 8
	SimpleCNN	0.891 9±0.003 2	7.603 5±0.157 0	0.438 6±0.007 2
	ResCNN	0.902 8±0.003 1	8.254 8±0.160 4	0.411 1±0.006 9
	DuoCL	0.922 6±0.004 9	11.254 6±0.211 6	0.324 6±0.008 9
	MFGAN(Ours)	0.936 5±0.003 5	11.733 3±0.265 0	0.302 8±0.008 4
EMG+EOG	FCNN	0.895 9±0.004 8	8.957 9±0.165 3	0.400 1±0.007 5
	NovelCNN	0.897 6±0.009 1	9.995 0±0.318 3	0.382 9±0.015 2
	SimpleCNN	0.886 1±0.003 6	7.379 9±0.162 9	0.448 5±0.007 8
	ResCNN	0.903 1±0.003 9	8.528 0±0.176 4	0.402 2±0.007 8
	DuoCL	0.907 0±0.007 4	10.803 1±0.245 7	0.347 6±0.010 5
	MFGAN(Ours)	0.926 1±0.004 8	11.503 7±0.258 0	0.317 4±0.009 0
EMG+ECG+EOG	FCNN	0.872 9±0.006 5	7.909 0±0.189 0	0.445 4±0.009 2
	NovelCNN	0.898 5±0.201 8	9.695 9±0.006 7	0.385 9±0.009 2
	SimpleCNN	0.858 1±0.003 8	6.254 1±0.143 3	0.506 2±0.007 4
	ResCNN	0.872 5±0.002 5	6.895 2±0.089 8	0.473 4±0.004 5
	DuoCL	0.901 0±0.006 8	10.133 9±0.278 6	0.366 1±0.010 6
	MFGAN(Ours)	0.922 3±0.004 3	11.055 7±0.264 0	0.329 9±0.008 6

NovelCNN; MFGAN 仍取得了最优的去噪效果. MFGAN 在平均 CC 上较 NovelCNN 提升了 0.99%, 较 DuoCL 的平均 SNR 提高了 4.26%, 平均 RRMSE 降低了 6.72%.

相对于单噪声环境, 混合噪声让实验环境变得更复杂, 各指标值都呈现出一定的下降趋势, 但仍能观

察到 MFGAN 的去噪效果优于其他方法. 具体来说, 混合双噪声去噪任务中, MFGAN 相对于次优模型 DuoCL, 平均 CC 和平均 SNR 分别提升 2.10% 和 6.49%, 平均 RRMSE 降低 8.69%. 而在更高任务复杂度的三种噪声干扰下, MFGAN 依旧保持最高水平, 以信噪比为例, MFGAN 相比次优模型提升了 9.10%.

为了更加直观地了解不同方法去噪效果的差异,将定量结果可视化.图 6 展示了不同信噪比下的 CC、SNR、RRMSE 指标的直观对比图.结果显示,MFGAN 在不同信噪比下的去噪效果均优于其他方法.在 EEGDenoisetnet 数据集的 3 种噪声环境(EMG、EOG、EMG + EOG)

下,除 NovelCNN 之外,其他方法都呈现出趋优走向;相比之下,MFGAN 在 CC、SNR 和 RRMSE 指标上均明显优于其他方法.在 MIT-BIH arrhythmia 数据集的 ECG 噪声干扰下,MFGAN 去噪后的三种指标都与之前最优的方法拉开了明显的差距.

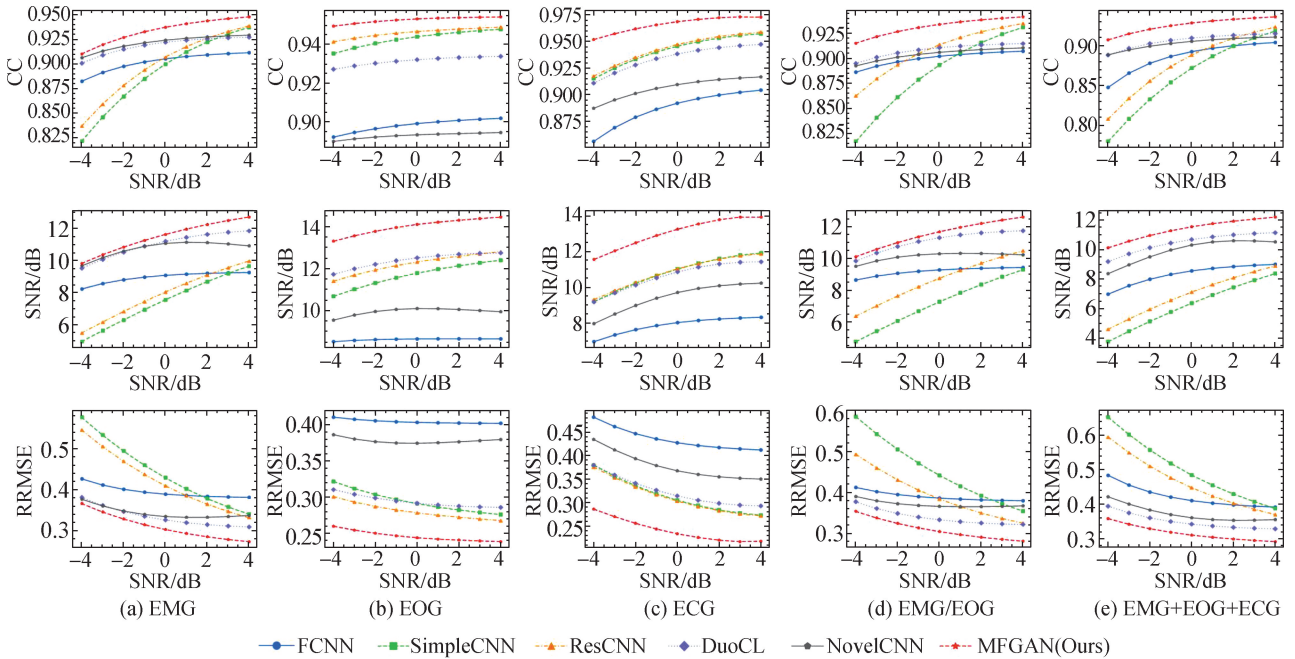


图 6 不同信噪比下的评估指标对比

Fig. 6 Comparison of evaluation indicators under different signal-to-noise ratios

此外,本研究针对 EOG 干扰场景下的消融实验评估了 FSFM 和多分支特征提取器的结构设计对去噪性能的影响.其中,FSFM 结构的消融实验设置了 4 种对比方案:Ⅰ)无 FSFM 结构;Ⅱ)仅含通道自交互分支;Ⅲ)仅含通道注意力分支;Ⅳ)完整 FSFM 结构.由表 4 可知,Ⅱ对网络性能提升明显优于Ⅲ.Ⅳ通过融合通道自交互和通道注意力分支的特征表示,在去噪任务中取得了最优性能.

多分支特征提取器的消融实验中设置了 4 种对比方案:Ⅴ)无 CNN 分支;Ⅵ)无 Transformer-Encoder 分

支;Ⅶ)无 AdvancedCNN 分支;Ⅷ)完整 3 分支结构.表 5 显示,三个分支的消融均对模型性能有消极作用,其中,Ⅶ的性能降幅明显大于Ⅴ和Ⅵ,而Ⅷ实现了最优的去噪性能.结果表明,双分支 FSFM 和三分支特征提取器均展现出多分支的特征互补优势,能够协同提升生成器的特征表达能力.

表 5 EOG 噪声干扰下的多分支结构的消融实验结果 (平均值±标准差)

Tab. 5 Experimental results of multi-level structure under EOG noise interference (mean±standard)

表 4 EOG 噪声干扰下的 FSFM 消融实验结果(平均值±标准差)

Tab. 4 Experimental results of FSFM ablation under EOG noise interference (mean±standard)

实验	RRMSE/ 10^{-3}	CC/ 10^{-3}	SNR/dB
Ⅰ	269.5±9.3	938.5±3.7	13.215 9±0.296 2
Ⅱ	257.5±10.2	950.2±4.4	13.505 3±0.337 2
Ⅲ	264.7±9.2	947.6±4.1	13.238 4±0.310 6
Ⅳ	257.2±11.2	950.4±4.1	13.590 8±0.309 1

实验	RRMSE/ 10^{-3}	CC/ 10^{-3}	SNR/dB
Ⅴ	261.5±9.8	947.2±4.8	13.540 2±0.319 2
Ⅵ	278.1±9.9	940.0±5.0	12.992 1±0.284 3
Ⅶ	267.7±8.6	948.8±4.5	12.975 5±0.303 9
Ⅷ	257.2±11.2	950.4±4.1	13.590 8±0.309 1

2.4.3 参数选择

网络主要涉及的参数包括生成器损失中的特征

损失权重系数 α 和对抗损失权重系数 β 、鉴别器损失中的梯度惩罚系数 λ 、通道自交互模块中的 dropout 值

以及卷积核大小. 为了确定最佳参数, 提出了几种 EOG 伪影下的探索性实验, 具体实验结果如表 6.

表 6 超参数对去噪性能的影响
Tab. 6 Influence of hyperparameters on denoising performance

超参数	大小	CC	SNR/dB	RRMSE
β ($\alpha = 0$)	0	0.942 9±0.005 1	13.346 1±0.302 8	0.269 3±0.009 5
	0.05	0.947 2±0.005 0	13.590 2±0.289 8	0.260 3±0.010 7
	0.10	0.946 4±0.004 8	13.324 8±0.284 0	0.263 8±0.009 8
	0.25	0.908 3±0.020 7	8.341 5±1.519 7	0.404 2±0.057 0
	0.5	0.912 7±0.039 0	8.602 5±1.736 9	0.393 3±0.083 7
α ($\beta = 0.05$)	0	0.947 2±0.005 0	13.590 2±0.289 8	0.260 3±0.010 7
	0.05	0.946 1±0.004 6	13.079 8±0.358 5	0.267 6±0.010 9
	0.10	0.944 8±0.004 2	12.921 8±0.399 2	0.271 9±0.010 9
	0.25	0.949 6±0.004 4	13.511 1±0.298 7	0.258 2±0.009 3
	0.5	0.950 4±0.004 1	13.590 8±0.309 1	0.257 2±0.011 2
λ	0	0.941 1±0.003 3	13.573 0±0.328 0	0.259 0±0.008 5
	0.25	0.947 9±0.004 0	13.331 8±0.278 5	0.263 1±0.008 9
	0.50	0.950 4±0.004 1	13.590 8±0.309 1	0.257 2±0.011 2
	0.75	0.947 6±0.003 9	13.475 2±0.270 8	0.262 0±0.009 0
	1.00	0.949 7±0.004 2	13.551 0±0.292 3	0.257 8±0.009 5
dropout	0	0.950 1±0.004 2	13.513 2±0.344 5	0.257 7±0.010 5
	0.25	0.950 1±0.004 1	13.463 8±0.302 1	0.258 5±0.008 7
	0.50	0.950 4±0.004 1	13.590 8±0.309 1	0.257 2±0.011 2
	0.75	0.949 5±0.004 9	13.549 6±0.420 6	0.259 1±0.013 7
	1.00	0.950 2±0.004 3	13.489 0±0.310 2	0.258 7±0.008 2
卷积核	3	0.950 4±0.004 1	13.590 8±0.309 1	0.257 2±0.011 2
	5	0.942 2±0.003 9	13.504 5±0.298 4	0.260 7±0.009 0
	7	0.949 2±0.003 7	13.428 3±0.275 4	0.264 5±0.007 7

实验首先设置 α 为 0 挑选最优的 β , 接着固定 β 进一步优化获得 α . 当 α 设置为 0.5, β 设置为 0.05 时网络效果达到最佳. 在上述基础上, 设置了 λ 和 dropout 率在 $[0, 1]$ 范围内, 步长为 0.25 的实验, 最终二者都确定为 0.5. 卷积核尺寸则在常用的 3、5 和 7 之间进行了研究. 实验发现, 较小的卷积核 3 获得了最小的 RRMSE, 最大的 CC 和 SNR.

2.4.4 推理时间分析

考虑到计算成本是模型可行性的重要因素, 在 ECG 噪声去除任务的评估阶段评估了模型的推理时间. 实验采用 5 次预热推理以缓解初始化误差, 随后

统计稳定的平均推理时间, 结果如图 7 所示. 尽管所提出的 MFGAN 在推理速度上低于对比模型, 但 MFGAN 能够保持高输出信噪比, 完成每秒超 1 000 个 EEG 片段, 充分满足临床 EEG 分析对实时性和精度的双重需求.

3 结 论

本文针对脑电信号易受多种噪声干扰的问题, 提出了 MFGAN, 该网络通过 3 个特征提取分支分别提取脑电信号的浅层特征、关联特征和深层特征. 此外,

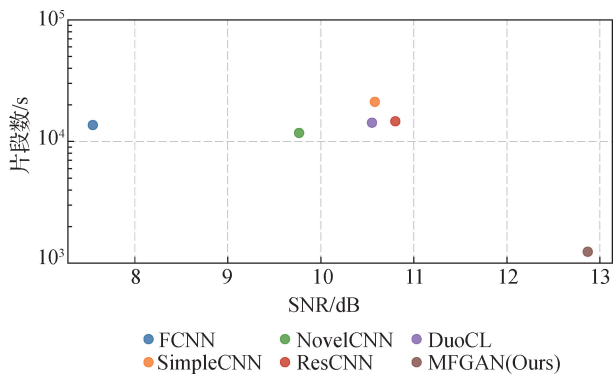


图 7 2 s EEG 片段中 ECG 伪影去除的平均推理速度
Fig. 7 Average inference speed of ECG artifact removal
in 2 s EEG segments

本文引入注意力机制,设计了一个特征自筛选融合模块,以更好地融合各分支提取的特征信息,从而提升去噪效果.本文在 EEGdenoisenet 和 MIT-BIH arrhythmia 数据集所生成的半模拟数据上,同其他方法在 CC、SNR 及 RRMSE 上进行了评估.实验表明,MFGAN 在 5 种噪声背景下均展现出卓越的去噪能力.在定性评估方面,MFGAN 能够有效滤除噪声成分,还原出更为纯净、准确的 EEG 信号;在定量分析中,其去噪效果也显著优于其他对比方法,获得了最高的信噪比、相似度和最低的误差,为脑科学研究提供了一种较为可靠的数据处理手段.综上所述,本方法在多种 EEG 噪声去除任务下,相较于其他方法具有显著优势,但仍需不断研究和完善,以更好地应对复杂多变的噪声环境.

参考文献:

- [1] CASSON A J. Wearable EEG and beyond[J]. Biomedical Engineering Letters, 2019, 9(1): 53-71.
- [2] 谭婷,钱志平,杨建工,等.动态脑电图诊断精神运动性癫痫的临床分析[J].世界复合医学, 2022, 8(12): 112-114, 118.
- [3] ZHANG H, ZHOU Q Q, CHEN H, et al. The applied principles of EEG analysis methods in neuroscience and clinical neurology[J]. Military Medical Research, 2023, 10(1): 67.
- [4] PHADIKAR S, SINHA N, GHOSH R. Unsupervised feature extraction with autoencoders for EEG based multiclass motor imagery BCI[J]. Expert Systems with Applications, 2023, 213: 118901.
- [5] 赵建强,周昌乐.短期禅修效果的脑电图多尺度排列熵分析[J].厦门大学学报(自然科学版), 2016, 55(3): 420-425.
- [6] 徐昊,黄敏,周昌乐.用于冥想神经反馈系统的脑电图数

据挖掘研究[J].厦门大学学报(自然科学版), 2018, 57(2): 258-264.

- [7] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. IEEE Transactions on Signal Processing, 2014, 62(3): 531-544.
- [8] WU Z, HUANG N E. Ensemble empirical mode decomposition: a noise-assisted data analysis method [J]. Advances in Adaptive Data Analysis, 2009, 1(1): 1-41.
- [9] YE H J R, SHIEH J S, HUANG N E. Complementary ensemble empirical mode decomposition: a novel noise enhanced data analysis method [J]. Advances in Adaptive Data Analysis, 2010, 2(2): 135-156.
- [10] DONOHO D L, JOHNSTONE I M. Ideal spatial adaptation by wavelet shrinkage [J]. Biometrika, 1994, 81(3): 425-455.
- [11] WIENER N. Response of a non-linear device to noise [M]. Massachusetts: Massachusetts Institute of Technology, 1942.
- [12] KALMAN R E. A new approach to linear filtering and prediction problems [J]. Journal of Basic Engineering, 1960, 82(1): 35-45.
- [13] PEARSON K. Principal components analysis [J]. The London, Edinburgh, and Dublin Philosophical Magazine and Journal of Science, 1901, 6(2): 559.
- [14] COMON P. Independent component analysis, a new concept? [J]. Signal Processing, 1994, 36(3): 287-314.
- [15] 李忠高,蔡艳平,王涛,等.基于 FastICA-VMD 的多通道脑电信号眼电伪迹自动去除方法 [J]. 计算机应用, 2023, 43(增 2): 312.
- [16] WANG G, TENG C L, LI K, et al. The removal of EOG artifacts from EEG signals using independent component analysis and multivariate empirical mode decomposition [J]. IEEE Journal of Biomedical and Health Informatics, 2016, 20(5): 1301-1308.
- [17] CHEN X, XU X Y, LIU A P, et al. The use of multivariate EMD and CCA for denoising muscle artifacts from few-channel EEG recordings [J]. IEEE Transactions on Instrumentation and Measurement, 2018, 67(2): 359-370.
- [18] 胡锐,乔加飞,李永华,等.基于 WOA-VMD-SSA-LSTM 的中长期风电预测 [J]. 太阳能学报, 2024, 45(9): 549-556.
- [19] DAI Y Y, DUAN F, FENG F, et al. A fast approach to removing muscle artifacts for EEG with signal serialization based ensemble empirical mode decomposition [J]. Entropy, 2021, 23(9): 1170.
- [20] ISSA M F, TUBOLY G, KOZMANN G, et al. Automatic ECG artefact removal from EEG signals [J].

- Measurement Science Review, 2019, 19(3):101-108.
- [21] LI Y C, WANG P T, VAIDYA M P, et al. Electromyogram (EMG) removal by adding sources of EMG (ERASE): a novel ICA-based algorithm for removing myoelectric artifacts from EEG [J]. *Frontiers in Neuroscience*, 2021, 14:597941.
- [22] YANG B H, DUAN K W, FAN C C, et al. Automatic ocular artifacts removal in EEG using deep learning[J]. *Biomedical Signal Processing and Control*, 2018, 43:148-158.
- [23] TANG Y B, CHEN D, LI X L. Dimensionality reduction methods for brain imaging data analysis [J]. *ACM Computing Surveys*, 2022, 54(4):1-36.
- [24] MAHMUD S, HOSSAIN M S, CHOWDHURY M E, et al. MLMRS-Net: electroencephalography (EEG) motion artifacts removal using a multi-layer multi-resolution spatially pooled 1D signal reconstruction network[J]. *Neural Computing and Applications*, 2023, 35(11):8371-8388.
- [25] PU X R, YI P, CHEN K C, et al. EEGDnet: fusing non-local and local self-similarity for EEG signal denoising with transformer [J]. *Computers in Biology and Medicine*, 2022, 151:106248.
- [26] CHUANG C H, CHANG K Y, HUANG C S, et al. ICU-Net: a U-net-based denoising autoencoder using mixtures of independent components for automatic EEG artifact removal[J]. *NeuroImage*, 2022, 263:119586.
- [27] NAGAR S, KUMAR A. Orthogonal features based EEG signals denoising using fractional and compressed one-dimensional CNN autoencoder[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2022, 30:2474-2485.
- [28] ZHANG H M, ZHAO M Q, WEI C, et al. EEGdenoiseNet: a benchmark dataset for deep learning solutions of EEG denoising [J]. *Journal of Neural Engineering*, 2021, 18(5):056057.
- [29] ZHANG H, WEI C, ZHAO M, et al. A novel convolutional neural network model to remove muscle artifacts from EEG[C]// *International Conference on Acoustics, Speech and Signal Processing*. Piscataway: IEEE, 2021: 1265-1269.
- [30] LIU Z H, MENG L B, ZHANG X, et al. Universal adversarial perturbations for CNN classifiers in EEG-based BCIs[J]. *Journal of Neural Engineering*, 2021, 18(4):0460a0464.
- [31] ZHANG X, WU D R. On the vulnerability of CNN classifiers in EEG-based BCIs[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2019, 27(5):814-825.
- [32] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets[J]. *Advances in Neural Information Processing Systems*, 2014, 63(11):139-144.
- [33] AN Y, LAM H K, LING S H. Auto-denoising for EEG signals using generative adversarial network [J]. *Sensors*, 2022, 22(5):1750.
- [34] DONG Y Z, TANG X, LI Q G, et al. An approach for EEG denoising based on wasserstein generative adversarial network[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2023, 31:3524-3534.
- [35] GULRAJANI I, AHMED F, ARJOVSKY M, et al. Improved training of wasserstein gans [C]// *International Conference on Neural Information Processing Systems*. New York: ACM, 2017:5769-5779.
- [36] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]// *International Conference on Neural Information Processing Systems*. New York: ACM, 2017:6000-6010.
- [37] SATYANARAYANA J V, RAMAKRISHNAN A G. Compressed EEG acquisition with limited channels using estimated signal correlation [EB/OL]. [2024-11-01]. <https://doi.org/10.48550/arxiv.1407.1285>.
- [38] MAO X D, LI Q, XIE H R, et al. Least squares generative adversarial networks[C]// *International Conference on Computer Vision*. Piscataway: IEEE, 2017:2813-2821.
- [39] MOODY G B, MARK R G. The impact of the MIT-BIH arrhythmia database[J]. *IEEE Engineering in Medicine and Biology Magazine*, 2001, 20(3):45-50.
- [40] SUN W T, SU Y P, WU X, et al. A novel end-to-end 1D-ResCNN model to remove artifact from EEG signals[J]. *Neurocomputing*, 2020, 404:108-121.
- [41] GAO T F, CHEN D, TANG Y B, et al. EEG reconstruction with a dual-scale CNN-LSTM model for deep artifact removal [J]. *IEEE Journal of Biomedical and Health Informatics*, 2023, 27(3):1283-1294.

(责任编辑:任滢滢)