



基于数据增强、黏菌算法与坐标注意力机制的 癫痫发作亚型分类方法

许逸钰^{a,b}, 周涛^a, 邹玉涛^{a,b}, 姜楠^{a,b}, 蒋路茸^{a,b}, 曹天傲^{a,b}

(浙江理工大学, a. 信息科学与工程学院(网络空间安全学院); b. 肾虚瘀证研究与转化重点实验室, 杭州 310018)

摘要: 癫痫发作亚型的精准分类对诊疗有重要意义, 但目前仍存在类别分布不均衡、特征冗余度较高等关键问题, 为此设计了一种基于去噪扩散概率模型(Denoising diffusion probabilistic model, DDPM)、黏菌算法(Slime mold algorithm, SMA)与坐标注意力(Coordinate attention, CA)机制的深度学习方法。首先, 利用 DDPM 生成高保真少数类脑电样本, 以缓解原始数据的分布不平衡问题。其次, 使用 SMA 算法对特征进行自适应筛选降维, 降低特征冗余并增强关键特征的表达。再次, 建立融合 CA 机制的双向长短期记忆网络(Bi-directional long short-term memory, BiLSTM), 以提高多通道脑电信号的时空依赖建模能力。最后, 采用 TUSZ 数据集, 对原始脑电信号实施预处理及样本划分, 并根据 DDPM 数据增强、SMA 筛选特征、CA-BiLSTM 模型训练以及性能评估等 4 个方面展开实验。实验结果表明, 该方法在 6 类癫痫发作亚型分类任务上获得了 96.54% 的平均准确率与 0.9687 的平均 F1 分数, 在模型稳定性和鲁棒性方面优于常见方法。该方法能够在复杂临床脑电数据条件下提升癫痫发作亚型分类的性能, 为临床精准诊断与个性化治疗提供一定的技术支持。

关键词: 癫痫发作亚型分类; 去噪扩散概率模型; 黏菌算法; 坐标注意力机制; 脑电图

中图分类号: TP391

文献标志码: A

文章编号: 1673-3851(2026)05-0315-09

引文格式: 许逸钰, 周涛, 邹玉涛, 等. 基于数据增强、黏菌算法与坐标注意力机制的癫痫发作亚型分类方法[J]. 浙江理工大学学报(自然科学), 2026, 55(3): 315-323.

Reference Format: XU Yiyu, ZHOU Tao, ZOU Yutao, et al. Epilepsy seizure subtype classification based on data augmentation, slime mold algorithm, and coordinate attention mechanism[J]. Journal of Zhejiang Sci-Tech University, 2026, 55(3): 315-323.

Epilepsy seizure subtype classification based on data augmentation, slime mold algorithm, and coordinate attention mechanism

XU Yiyu^{a,b}, ZHOU Tao^a, ZOU Yutao^{a,b}, JIANG Nan^{a,b}, JIANG Lurong^{a,b}, CAO Tianao^{a,b}

(a. School of Information Science and Engineering (School of Cyber Science and Technology);

b. Key Laboratory for Research and Translation of Kidney Deficiency-Stasis-Turbidity Disease, Zhejiang Sci-Tech University, Hangzhou 310018, China)

Abstract: The precise classification of epilepsy subtypes has significant implications for diagnosis and treatment. However, key challenges persist, including imbalanced category distributions and high feature redundancy. To address these challenges, this paper proposes a deep learning method that integrates the denoising diffusion probabilistic model (DDPM), the slime mold algorithm (SMA), and the coordinate attention (CA) mechanism. First, DDPM generates high-fidelity EEG samples for minority classes to mitigate the distribution imbalance in the original data. Second, the SMA algorithm is applied for adaptive feature selection and dimension reduction, which reduces redundancy while improving the representation of

收稿日期: 2025-12-13 网络出版日期: 2026-03-05

基金项目: 浙江省自然科学基金青年基金项目(25222260-D); 浙江省教育厅一般科研项目(Y202457174)

作者简介: 许逸钰(2000—), 男, 江苏苏州人, 硕士研究生, 主要从事脑电信号方面的研究。

通信作者: 蒋路茸, E-mail: jianglurong@zstu.edu.cn

key features. Third, the CA-enhanced bidirectional long short-term memory network (BiLSTM) is introduced to improve the modeling of the spatiotemporal dependence of multichannel EEG signals. Finally, the TUSZ dataset is used for EEG signal preprocessing and sample segmentation. The experiments are conducted along four aspects: DDPM data augmentation, SMA feature selection, CA-BiLSTM model training, and performance evaluation. The results of the experiment show an average accuracy of 96.54% and an average F1 score of 0.9687 for six epilepsy subtype classification tasks, surpassing comparative methods in terms of model stability and robustness. This approach improves the classification performance of epilepsy subtypes under complex clinical EEG conditions and provides technical support for accurate clinical diagnosis and personalized treatment.

Key words: epilepsy subtype classification; DDPM; SMA; coordinate attention mechanism; EEG

0 引言

癫痫是世界上第三大慢性神经系统疾病,全球约 7000 万人受到癫痫的影响。脑电图 (Electroencephalogram, EEG) 作为目前临床上用来诊断癫痫的重要辅助工具之一,通过捕捉、分析病变时出现的异常放电活动来辅助医师进行临床诊断^[1],已经得到了广泛应用^[2]。在实际应用中,因脑电信号本身的非平稳性、特异性等特点,以及不同癫痫发作亚型在波形上存在细微且复杂的重叠,正确区分癫痫发作亚型存在一定困难。准确识别癫痫发作亚型对临床治疗有着重要意义,例如局灶性发作类型的癫痫通常用卡马西平药物进行控制,全面性发作类型的癫痫一般使用丙戊酸钠药物进行控制。错误的发作亚型分类则会引起漏诊或误诊,使患者不能及时得到正确治疗,甚至会因用药不当而加重病情^[3-4]。面对大量的长程 EEG 监测数据以及专业医师资源匮乏的现状,利用人工智能技术实现癫痫发作亚型自动分类迫在眉睫。

随着近年来深度学习技术与信号处理技术的发展,癫痫发作亚型分类研究已经取得了长足进步。现有多数方法基于先验经验与人工划分进行特征提取与模型构建,并依托传统机器学习模型实现发作亚型分类。此类方法在特定实验条件下可取得较好的分类效果,但存在易过拟合、对训练数据依赖性较强等局限。近年来的研究逐渐转向基于深度学习的建模方法,例如:Fraiwan 等^[5]基于双向长短期记忆网络 (Bi-directional long short-term memory, BiLSTM) 实现了端到端学习特征,不需要人为干预;Feng 等^[6]设计了多流网络,通过整合时域、空间域及频域多维特征信息来提高分类效果,Cao 等^[7]在该基础上提出了 TSA3-D 网络,用双流机制将时频、空频两部分特征信息进行结合,以增强模型对复杂 EEG 模式的分类性能,但多通道 EEG 信号依然

具有高维性,模型在分类过程中不可避免地会引入大量冗余信息。部分研究采用了相关系数法进行特征选择^[8],但这种特征选择方法只针对线性相关特征,无法准确挖掘特征之间的非线性关联,易忽视有用信息。同时癫痫亚型数据分布不平衡问题也是导致模型不能很好地在临床上泛化的另一个重要原因^[9-10]。部分研究人员将生成对抗网络 (Generative adversarial networks, GANs) 用于扩充少数类样本,但其固有的模式崩塌^[11-12]与训练不稳定等问题限制了生成样本的多样性与真实性,使得生成的样本缺乏代表性。去噪扩散概率模型 (Denoising diffusion probabilistic model, DDPM) 得益于其基于逐步噪声注入与反向去噪重建机制的概率生成框架,拥有更稳定的训练过程,能够产生更多样化、覆盖面更广的样本^[13-14],已广泛应用于故障诊断^[15]、医学图像^[16]、自然语言处理^[17]等领域,但在癫痫 EEG 信号数据增强这一方向上的应用研究仍处于早期探索阶段。

针对目前癫痫发作亚型分类中存在的数据集类别不平衡、特征冗余等问题,本文提出了一种将 DDPM、黏菌算法 (Slime mold algorithm, SMA) 和坐标注意力 (Coordinate attention, CA) 机制相结合的深度学习方法。首先用 DDPM 生成少数类的高质量脑电样本,改善数据集中的数据分布问题;然后利用 SMA 自适应筛选出重要的关键特征;最后基于 CA 机制构建 BiLSTM 网络,增强时空依赖建模能力,提升在复杂临床脑电环境下的癫痫发作亚型分类性能。本文提出的方法在一定程度上改善了脑电数据不平衡与特征冗余问题,可为癫痫发作亚型的正确诊断提供辅助参考。

1 研究方法

本文基于天普大学医院脑电图 (TUH-EEG) 数据集,提出了一个包括数据增强、特征选择与时空建

模的系统性研究方法,整体方法流程如图 1 所示。首先,对原始 EEG 信号进行去噪、滤波处理,然后分成时间长度为 4 s 的不重叠片段。其次,利用 DDPM 对少数类样本进行高保真增强,弥补数据分布的不平衡,提取时域、频域及通道相关性等方面的特征;并通过 SMA 算法模拟智能觅食行为,自适

应选择最优特征子集,减少冗余并突出重要的判别信息。最后,把优化后的特征输入融合 CA 机制的 BiLSTM 网络,用 CA 机制进行空间加权,强化通道空间位置信息的表征能力,再用 BiLSTM 捕捉多通道信号的时空依赖性,完成 6 类癫痫发作亚型的自动分类。

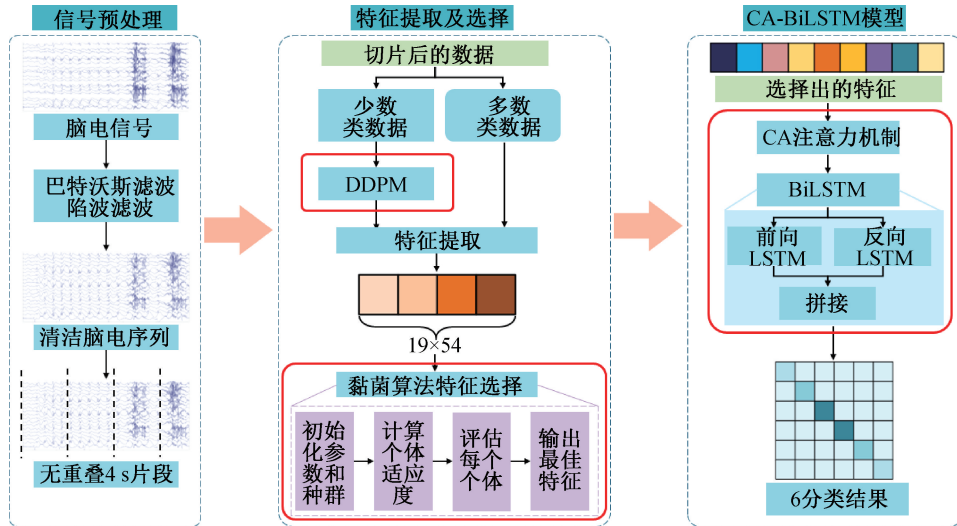


图 1 癫痫发作亚型分类方法整体示意图

1.1 数据集

本文基于 TUSZ (Temple University Hospital Seizure Corpus) 数据集^[18]的多通道头皮 EEG (采样率 256 Hz, 遵循 10-20 系统) 进行癫痫发作亚型分析。数据清洗过程中,排除样本稀缺的 TNSZ 和 MYSZ 发作亚型,并剔除多亚型发作的混合发作患者以及发作时长短于 4 s 的脑电片段样本。TNSZ 与 MYSZ 亚型在 TUSZ 数据集中不仅样本数量极少,且在患者层面存在明显的分布失衡。其中:MYSZ 亚型仅有两次发作记录,且均来源于同一名患者,其脑电信号在个

体层面表现出明显的特异性;TNSZ 亚型样本同样仅来源于 3 位患者,难以满足模型对发作亚型的判别特征进行稳定建模的要求;多亚型混合发作样本在临床标注上存在较大的模糊性。为避免因样本极度稀缺和标签噪声而引入不稳定因素,本文在当前研究阶段对上述样本进行了去除,以保证实验结果的可靠性和可解释性。最终共纳入 278 名受试者的 1292 份 EEG 记录文件,涵盖 SPSZ、CPSZ、FNSZ、GNSZ、ABSZ 和 TCSZ 等 6 类发作亚型,所有发作片段经医师标注。癫痫发作亚型及其统计信息见表 1。

表 1 本文纳入的 TUSZ 癫痫发作亚型及其统计信息

癫痫发作亚型	亚型描述	发作次数/次	持续时间/s
ABSZ	脑电图观察到无异常放电,患者意识丧失数秒	97	831
CPSZ	昏迷期间部分癫痫发作,仅根据临床症状确定类型	344	28427
FNSZ	局灶性癫痫发作且无法确定类型	1938	115697
GNSZ	全身性癫痫发作,不能进一步划分	1074	86760
TCSZ	起初身体僵硬,后抽搐	40	2744
SPSZ	意识清醒时局灶性癫痫发作,仅根据临床症状确定类型	47	1748

1.2 预处理

EEG 采集因时间跨度长且缺乏统一规范,导致数据缺乏标准化,本文通过预处理提升数据质量。首先,应用 0.5 ~ 70.0 Hz 巴特沃斯带通滤波去除噪声,保留关键频率,并采用 60.0 Hz 陷波滤波器抑制工频干扰;其次,将所有非 256.0 Hz 采样率的信

号统一重采样至 256.0 Hz,获得采样率为 256.0 Hz、频段为 0.5 ~ 70.0 Hz 的清洁脑电序列;最后,在导联处理方面,通过对单极导联的筛选与重排构建了 18 个标准双极差分通道,整合 EKG 形成 19 通道配置。对预处理后的发作信号进行无重叠 4 s 片段划分,并根据亚型发作时长加权随机抽取 40000

个片段,各亚型的片段数量见表2。从表2可看出,样本量显著不平衡,最多发作亚型数量约是最少发作亚型的140倍。

表2 本文中6类癫痫发作亚型的EEG片段数量分布

癫痫发作亚型	ABSZ	CPSZ	FNSZ	GNSZ	SPSZ	TCSZ
片段数量/段	141	4814	19592	14692	296	465

1.3 数据增强

DDPM作为概率驱动式的生成式模型,通过随

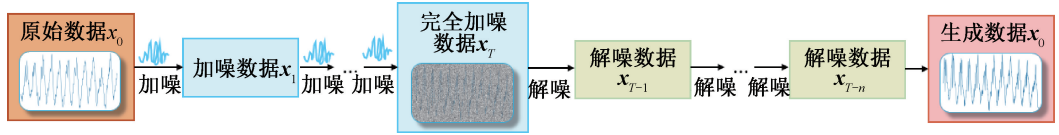


图2 DDPM实现流程示意图

模型在正向扩散过程中将原始EEG信号逐步加入高斯噪声,使原始信号不断衰变为纯噪声。在正向扩散期间,先假设原始信号属于某一分布,然后通过引入一定的扰动将其推向远离真实分布的位置,直至达到最后一个时刻所对应的高斯噪声分布。假设原始数据服从分布 $x_0 \sim q(x_0)$,使用 x_1, x_2, \dots, x_T (T 为总时间步数)表示其加噪后的隐变量序列。将整个扩散过程看作马尔可夫过程,则有如下条件概率分布:

$$q(x_t | x_{t-1}) = \mathcal{N}(x_t; \sqrt{1 - \beta_t} x_{t-1}, \beta_t \mathbf{I}),$$

其中: x_t 表示当前第 t 个时间步的数据; x_{t-1} 表示上一时间步 $t-1$ 的数据; \mathcal{N} 表示高斯分布; $\beta_t \in (0, 1)$ 用以控制噪声添加速率,且随时间 t 增加而单调增加; $\sqrt{1 - \beta_t}$ 是控制输入数据变化幅度的缩减系数; \mathbf{I} 是单位矩阵, $\beta_t \mathbf{I}$ 是 t 时间步的噪声协方差矩阵,表示噪声真实值遵从的分布。给定已知的上一时间步 x_{t-1} , $q(x_t | x_{t-1})$ 表示从上一时间步 x_{t-1} 生成当前时间步数据 x_t 的概率分布,以此描述从一个时间步向后序的时间步逐步产生新数据的过程。

使用重参数化方法可以由原始数据 x_0 直接推断出任意时刻 t 的加噪结果:

$$x_t = \sqrt{\alpha_t} x_0 + \sqrt{1 - \alpha_t} \epsilon, \epsilon \sim \mathcal{N}(0, \mathbf{I}),$$

其中: $\alpha_t = \prod_{s=1}^t (1 - \beta_s)$ 表示累积信号保留系数。随着 t 由小变大至 T 后, α_t 逐渐趋近于0,因此 x_T 会淘汰原始信号中绝大部分有价值的信息,最终几乎全部退化为服从 $\mathcal{N}(0, \mathbf{I})$ 的纯噪声。

在逆向重建过程中,模型通过神经网络从初始噪声 $x_T \sim \mathcal{N}(0, \mathbf{I})$ 逐步去噪,恢复原始数据 x_0 ,即参数化逆向分布如下所示:

机扩充过程将数据从有序状态转化为无序的噪声状态,并使用神经网络将这部分噪声数据重新还原为接近原有序状态的数据^[19]。在正向扩散过程中,模型不断向原始数据中加入高斯噪声,使其逐渐改变为近似噪声的分布;而在逆向重建过程中采用神经网络来学习消除噪声,从噪声数据出发逐步生成符合原始数据分布的样本。整个DDPM模型主要分为正向扩散和逆向重建两个过程,具体的实现流程如图2所示。

$p_\theta(x_{t-1} | x_t) = \mathcal{N}(x_{t-1}; \mu_\theta(x_t, t), \Sigma_\theta(x_t, t))$,其中:把 $\mu_\theta(x_t, t)$ 作为网络学习得到的均值项,并根据它来指导逆向还原; $\Sigma_\theta(x_t, t)$ 是第 t 时间步的噪声协方差矩阵,可以基于预定的噪声调度 β_t 而设定或者由模型学习得到。

本文使用平均绝对误差(MAE)为训练目标来准确估计每一个步骤的噪声:

$$L_{\text{MAE}} = \mathbb{E}_{x_0, \epsilon, t} \left[\frac{1}{N} \sum_{i=1}^N |\epsilon^{(i)} - \epsilon_\theta^{(i)}(x_t, t)| \right],$$

其中: L_{MAE} 表示平均绝对误差,用于衡量噪声预测的偏差大小; ϵ 是正向扩散时实际添加的噪声; $x_t = \sqrt{\alpha_t} x_0 + \sqrt{1 - \alpha_t} \epsilon$ 表示时间步 t 的加噪状态; $\epsilon_\theta(x_t, t)$ 是模型在 t 时刻对噪声的预测结果; N 代表了信号的维度; i 表示索引值。通过使模型尽可能地减小损失函数 L_{MAE} ,可以使得模型不断地提升噪声预测能力,使模型能够进行逆向去噪以及样本重构工作。

1.4 特征提取

脑电信号在时域上的动态变化和在频域中的能量分布都蕴含着大量的病理信息,在EEG片段上分别从时域、频域两个维度提取出共16维特征,目的是尽可能提取各类癫痫发作亚型特有的模式,为后续分类模型提供有区分度的特征。

时域特征主要是指3类Hjorth参数,即活动性、移动性和复杂性。活动性表示总能量水平;移动性反映尖波上升的特点;复杂性表示瞬态变化模式。同时还要计算时域上的零交叉率和非线性能量,其中零交叉率可用来表示高频振荡情况,非线性能量用来表示突发性的放电。

关于频域特征,本文采用Mel频率倒谱系数

(Mel-frequency cepstral coefficients, MFCC)的标准差以及方差,描述频谱包络整体波动特性的特征;通过功率谱密度(Power spectral density, PSD)提取峰值频率、偏度和峰度,描述频段能量分布的集中情况以及形态特征;运用强度加权平均频率和强度加权带宽,评价频谱能量的中心位置和频谱的离散程度;根据计算得到的功率谱密度谱相关系数,描述癫痫脑电节律的周期稳定性和宽频带激活特点。

在通道间相关性分析部分,本文分别基于时域的电尔逊相关系数和基于快速傅里叶变换的频域相关系数,构建了两个通道相关矩阵,即时域相关矩阵和频域相关矩阵。通过计算所有通道对之间的电尔逊相关系数得到时域相关矩阵;对每个通道信号进行快速傅里叶变换,再根据幅度谱的相关性来获取频域相关矩阵。对两类相关矩阵开展分析,可挖掘大脑网络的关联特征,揭示脑区间的协同工作模式,进而明晰其相互作用的程度与方式。任意两个通道 a 、 b 之间的相关系数计算公式为:

$$C_{a,b} = \frac{\sum_{n=1}^N (x_a(n) - \bar{x}_a)(x_b(n) - \bar{x}_b)}{\sqrt{\sum_{n=1}^N (x_a(n) - \bar{x}_a)^2 \sum_{n=1}^N (x_b(n) - \bar{x}_b)^2}}$$

其中: a 、 b 分别表示两个不同的脑电通道编号, $a \neq b$; \bar{x}_a 表示通道 a 的序列均值,在时域中为时间序列均值,在频域中是幅度谱均值。

本文从每个切片中提取时域特征、频域特征、时域相关矩阵特征及频域相关矩阵特征,并进行融合。融合后的特征维度为 54,每个切片生成的数据是维度为 19×54 的特征矩阵。

1.5 基于改进黏菌算法的特征选择

为降低 EEG 信号中的冗余成分并降低特征维度,提高癫痫发作亚型分类任务的性能,本文采用 SMA 算法进行降维操作。SMA 算法基于黏菌在寻找食物过程中表现出的觅食行为,利用自组织模式,通过振荡行为调优以及网络组件思想完成特征子集的选择与更新。SMA 算法流程如图 3 所示。同时,为了更好地适用于 EEG 数据的降维问题,本文使用了二进制编码的方式进行优化,每个个体代表一个特征子集选择方式,其中:编码值为 1 表示保留相应的特征,编码值为 0 则表示舍弃掉这个特征。设置参数如下:种群规模为 15,最大迭代次数为 10 次,目标特征数为 27。考虑分类准确率和特征数量这两个关键指标,在 SMA 算法中构建适应度函数 S ,计算公式为:

$$S = (1 - A_v) + \lambda \cdot \frac{|M_s - M_t|}{D}$$

其中: A_v 是特征子集在验证集上的分类准确率, M_s 是当前选择的特征数, M_t 是目标特征数, λ 是惩罚系数并设为 0.1, D 为原始特征总数。

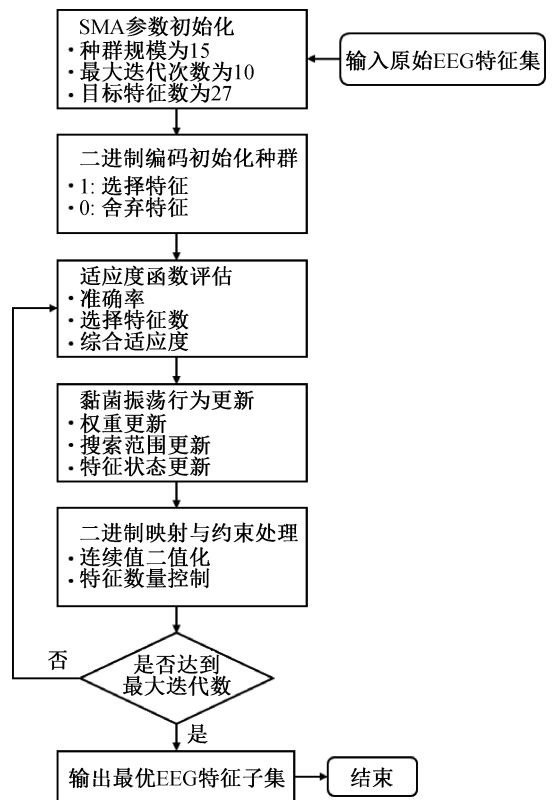


图 3 SMA 算法的流程示意图

SMA 算法通过快速训练 BiLSTM 分类器 3 个周期来获取验证集准确率,在不大幅度降低可靠性的前提下,可以大幅缩短训练时间并节约计算资源。在位置更新过程中利用混合策略平衡探索与开发计算量:以 70% 的概率进行探索,围绕当前的最优个体进行动态变异而扩大搜索范围;以 30% 的概率进行开发,采用交叉以及随机变异的方法生成新的候选解。设置了可行性约束条件,每个特征子集至少包含 1 个特征,并且将特征数量控制在目标特征数量的合理范围内,以此保证搜索到的子集有效。通过上述优化过程,SMA 算法能够筛选具有较好的癫痫发作亚型分类能力的特征子集。降维后的特征子集能够有效改善模型的泛化能力,并为后续 BiLSTM 分类器提供更优质的输入特征。

1.6 坐标注意力机制

为增强模型对不同脑电通道和特征维度之间依赖关系的建模能力,本文在 BiLSTM 之前引入了 CA 机制。不同于传统的注意力机制只关注通道或

空间信息,CA 通过在 2 个不同方向上进行一维特征编码把空间位置信息引入通道注意力的建模过程,从而在保留精确位置信息的同时实现远距离依赖的捕获。输入的多通道 EEG 特征张量 $\mathbf{X} \in \mathbf{R}^{B \times 19 \times F}$ 会先被重塑成伪图像的格式 $\mathbf{X}_{CA} \in \mathbf{R}^{B \times F \times 19 \times 1}$,其中: \mathbf{R} 表示实数域, B 为批次大小, F 为通道数。把 19 个脑电通道看作是空间高度 H ,其余特征维度就是宽度 W 。CA 沿通道 H 轴方向和特征 W 轴方向做两个独立的一维自适应平均池化,在两个方向上聚合信息得到对应的编码向量。这两个向量拼在一起,输入一个共享的 1×1 卷积去融合信息,并经过批标准化和轻量级 h_{Swish} 激活。 h_{Swish} 定义为:

$$h_{\text{Swish}}(x) = x \cdot h_{\text{Sigmoid}}(x),$$

其中: $h_{\text{Sigmoid}}(x) = \frac{\text{ReLU6}(x+3)}{6}$ 是对标准 Sigmoid 的分段线性近似函数。该激活函数在零点附近保持非零梯度,可以防止信息在融合过程中被过度抑制,同时保持平滑的非线性;在大负值和大正值区间分别抑制或者线性保留输入信息,既考虑了计算效率又考虑了表达能力。

特征融合后的输出会沿着 H 轴和 W 轴被拆分成两个独立的张量 f_h 和 f_w 。这两个张量再分别经过各自的 1×1 卷积和 Sigmoid 激活函数,得到沿通道方向的注意力权重 z_h 和沿特征方向的注意力权重 z_w 。原始特征 \mathbf{X}_{CA} 用两个权重的乘积 $\mathbf{X}_{\text{att}} = \mathbf{X}_{CA} \odot z_h \odot z_w$ 来加权增强。这一双向注意力机制可以自适应地调整某个通道上某特征的重要性,提高了 BiLSTM 对多通道 EEG 信号的判断力和模型的性能。

2 结果及分析

2.1 评价指标

在分类任务的性能评估中使用的一种基本手段就是混淆矩阵(Confusion matrix, CM),可以清楚直观地反映分类结果的情况。根据 CM 可以计算出 5 个重要指标:准确率(Accuracy)、平衡准确率(Balanced accuracy)、精确率(Precision)、召回率(Recall)和 F1 分数(F1-score)。混淆矩阵记为 $\mathbf{G} \in \mathbf{R}^{6 \times 6}$,各评价指标的计算公式如下所示:

$$A = \frac{\sum_{j=1}^6 G_{jj}}{\sum_{j=1}^6 \sum_{k=1}^6 G_{jk}},$$

$$A_B = \frac{1}{6} \sum_{j=1}^6 \frac{G_{jj}}{\sum_{k=1}^6 G_{jk}},$$

$$P = \frac{1}{6} \sum_{k=1}^6 \frac{G_{kk}}{\sum_{j=1}^6 G_{jk}},$$

$$R = \frac{G_{jj}}{\sum_{k=1}^6 G_{jk}},$$

$$S_{F1} = \frac{2 \times P \times R}{P + R},$$

其中: G_{jk} 表示真实类别为 j 且模型分类为 k 的样本数, A 表示总体准确率, A_B 表示平衡准确率, P 表示宏平均准确率, R 表示召回率, S_{F1} 表示 F1 分数。

2.2 实验结果

本文对提出的癫痫发作亚型分类算法的性能做了系统的评价。实验中使用 TUSZ 数据集和 DDPM 生成的增强样本一起进行训练,所有的 EEG 信号都在预处理阶段被切分为 4 s 长度的片段。按照 70%、10%、20% 的比例将数据集分为训练集、验证集和测试集,使用分层抽样的方法保证各癫痫发作亚型样本分布的均衡性。模型评估阶段用准确率、平衡准确率、精确率、召回率以及 F1 分数作为主要性能指标。训练参数设置如下:训练轮数为 50 轮,批次为 96 次,优化器选择 Adam,学习率设为 0.001。

为了保证模型性能的稳定并减小随机初始化所造成的偶然性影响,所有的实验都重复进行 10 次,取平均值作为最终的性能指标值。每轮实验均通过随机生成的种子对数据集进行重新划分,在不加载任何预训练权重的情况下,用随机方式对模型参数进行初始化。同模型训练时采用随机小批量采样,进一步增加训练过程中的随机性,每轮结果及其平均值如表 3 所示。由表 3 可知,提出的模型在各项指标下都表现出较强的分类性能,平均整体准确率为 96.54%,平衡准确率为 96.71%,比整体准确率略高。该结果说明模型不是只依靠样本量较大的 FNSZ 或者 GNSZ 亚型来提高准确率,同时在少数类样本上也表现出较好的分类能力。这表明 DDPM 数据增强策略对数据分布偏差起到了缓解作用,一定程度上减少了传统深度学习模型在不平衡数据上的多数类偏见现象。在 10 轮重复实验中准确率的波动范围为 95.90%~97.07%,F1 分数始终大于 0.96。较小的性能波动说明模型对训练集的划分具有较强的鲁棒性,稳定性较好。

表 3 10 次随机重复实验的性能指标值

序号	准确率/ %	平衡 准确率/%	精确率/ %	召回率/ %	F1 分数
1	95.90	96.28	96.83	96.28	0.9655
2	96.33	96.31	95.98	96.31	0.9613
3	96.33	95.76	96.41	95.76	0.9607
4	97.07	97.36	97.41	97.36	0.9738
5	96.09	96.17	97.39	96.17	0.9677
6	96.59	97.00	96.59	97.00	0.9679
7	96.76	96.83	97.46	96.83	0.9714
8	96.52	96.57	97.18	96.57	0.9686
9	96.97	97.18	97.56	97.18	0.9737
10	96.96	97.67	97.56	97.67	0.9761
平均值	96.54	96.71	97.04	96.71	0.9687

2.3 消融实验

为了分析所提出的模型中 DDPM 生成数据、SMA 算法和 CA 机制对分类性能的贡献,本文设计了 3 组消融对比实验,并将不同模型变体的统计结果汇总在图 4 中。模型 1 去除了 DDPM 数据增强的模块,仅保留 SMA+CA-BiLSTM 结构,并与完整模型对比以检验数据增强的有效性;在模型 2 中,探索 SMA 特征选择的影响;在模型 3 中,去掉了 CA 机制,只保留 BiLSTM 主干结构,考察模型结构的影响。图 4 展示的分类性能都是基于 10 轮相互独立的重复实验,同时给出了相应的平均值,方便比较不同的模型变体在性能指标上的差别。表 4 给出了各个模块的定量对比结果,每一项指标都是以 10 轮独立实验的平均值作为最终值。




图 4 消融实验中不同模型的性能箱型图

由图 4 和表 4 可以看出:模型 1 在去除了 DDPM 数据增强后,少数类样本上的准确率明显降低,进一步影响整个平衡准确率,表明 DDPM 生成的样本对解决类别不平衡问题起到了作用;模型 2

在去掉 SMA 算法后,各项指标都出现了下降,表明特征选择对于提高模型分类性能与鲁棒性很有必要;模型 3 去掉 CA 机制,只保留 BiLSTM 主干来分析模型结构的影响,分类精度以及 F1 分数都出现了一定程度的下降,这是由于 CA 机制能使模型更好地获取空间信息,有助于提升分类精度。

表 4 消融实验的模型性能

模型	准确率/ %	平衡 准确率/%	精确率/ %	召回率/ %	F1 分数
模型 1	91.86	91.35	92.40	92.05	0.9223
模型 2	94.04	93.91	94.18	93.91	0.9400
模型 3	95.30	95.46	95.88	95.46	0.9563
本文模型	96.54	96.71	97.04	96.71	0.9687

2.4 性能对比与讨论

为了进一步验证所提方法在癫痫发作亚型分类任务上的有效性及竞争力,本文将其与现有模型进行了系统对比,对比模型包括机器学习、深度学习及 EEG 信号分析领域的代表性模型。模型 1 基于多类特定频段公共空间模式和惩罚集成模型对 6 类癫痫发作亚型进行分类。模型 2 所提出的 DV-SeizureNet 基于双视图学习框架实现 4 类癫痫发作亚型分类。模型 3 基于离散小波变换和 LSTM 对 4 类癫痫发作亚型进行分类。模型 4 提出基于双树复小波变换和 LightGBM 的多类别癫痫发作亚型分类系统。模型 5 提出的基于多级小波分解提取时频特征的端到端三维卷积多频段分类模型。模型 6 提出了一种基于二维脑网络特征选择的癫痫发作亚型分类算法。模型 7 提出的可变权重卷积神经网络模型,其中可变权重卷积神经网络模型作为核心分类器。模型 8 提出的基于迭代门控图卷积神经网络的癫痫发作亚型分类模型,使用门控图神经网络作为核心分类器。模型 9 提出了一种基于注意力机制的端到端 3D 卷积多波段癫痫发作类型分类模型。

所有实验都使用 TUSZ 数据集,各模型性能如表 5 所示。从表 5 的客观指标可以看出,本文提出的模型在保证较高准确率的情况下,召回率和 F1 分数的表现也较好,说明模型在正确分类样本方面更具鲁棒性和稳定性。

为了对 DDPM 生成样本的质量做出客观评价,本文选取了 Jensen-Shannon 散度 (Jensen-Shannon divergence, JSD)、最大均值差异 (Maximum mean discrepancy, MMD) 和 KID (Kernel inception distance) 这 3 个指标来进行量化分析。上述指标从保真度与多样性两个方面出发,用生成样本与真实

样本的分布一致性来衡量生成数据的有效性。相关的实验结果如表 6 所示。从表 6 可知 DDPM 生成的样本与原始数据在分布特性上具有较高的相似度,既较好地保留了关键病理信息,又合理地增加了数据多样性。

表 5 不同癫痫发作亚型分类模型的性能指标值

模型	准确率/%	精确率/%	召回率/%	F1 分数
模型 1 ^[20]	96.14	97.24	96.36	0.9679
模型 2 ^[21]	91.40	91.20	85.30	0.8250
模型 3 ^[22]	95.92		95.92	0.9599
模型 4 ^[23]	96.50		96.00	0.9604
模型 5 ^[24]	92.69			0.9274
模型 6 ^[25]	96.60	96.61	96.60	0.9659
模型 7 ^[26]	95.00			0.9400
模型 8 ^[27]			91.8	0.9150
模型 9 ^[28]	94.47			0.9438
本文模型	96.54	97.04	96.71	0.9687

表 6 生成数据的可靠性验证指标

方法	JSD	MMD	KID
DDPM	0.0036	0.1889	0.0425
GAN	0.0068	0.3669	0.0714

在 DDPM 的生成策略下,JSD 与 MMD 指标相比 GAN 进一步降低,表明 DDPM 生成信号与真实信号的分布差异进一步缩小。这一现象表明,DDPM 生成的脑电信号能够更准确地复现真实信号的频谱特征与时域波形结构,而不是缺少生理意义的随机扰动。同时较低的 KID 指标数值进一步证实了生成样本具有较好的多样性表现。

相比 GAN 在训练时容易出现的模式崩塌问题,DDPM 能够覆盖的样本特征空间要更广泛,为本文提出方法在极度不平衡数据集上实现高分类精度奠定了技术基础。表 6 中所采用的 GAN 模型属于脑电数据增强领域里常用的典型生成模型,设置该 GAN 模型的目的仅为比较不同的生成机制在分布建模能力上的差别,并非对所有先进的生成模型进行覆盖。在本文研究的癫痫发作亚型数据极度类别不平衡的场景下,DDPM 在生成过程中更稳定,分布覆盖性更好,为后续分类模型提供了更优质的训练数据。

扩散模型的数据增强效果好坏,和原始数据的样本量以及跨患者分布的多样性相关。对于 TNSZ 与 MYSZ 这两类患者数量极少、患者样本高度集中的稀缺亚型,本文也同样计算了这 2 类亚型的生成质量指标,结果汇总于表 7。从表 7 可以看出:这两类亚型的 JSD、MMD 与 KID 值都大于其他亚型的

值,表明在样本量不充分的时候,生成分布很难稳定、可靠地逼近真实分布特性。因此,本文在现阶段研究中剔除了相关的亚型样本,降低了因不可靠生成造成的分布偏移和标签干扰风险,并防止标签噪声对分类结果造成干扰。

表 7 TNSZ 与 MYSZ 的生成数据可靠性

癫痫发作亚型	JSD	MMD	KID
ABSZ	0.0036	0.1889	0.0425
TNSZ	0.0154	0.5749	0.2371
MYSZ	0.0412	0.6891	0.5183

SMA 算法采用自适应更新的方法,可以对搜索过程进行动态的调整,实现了全局探索和局部开发之间的有效平衡,提高了关键特征的选择效率。消融结果表明,当去掉 SMA 后模型整体出现性能下降,表明该算法能够降低冗余并突出关键特征。CA 机制在两个互相垂直的方向上对通道信息与空间信息进行编码,在一定程度上提升了模型对癫痫发作局灶性及其传播模式的捕捉能力。当模型去掉 CA 机制的时候,模型对空间信息的捕捉能力变弱。由此可知 SMA 与 CA 之间相互配合,SMA 通过减少输入特征的冗余来改进输入特征子集,CA 增强深度特征的表达并且加权空间结构,共同提升了模型的鲁棒性和分类精度。

3 结 语

针对癫痫发作亚型分类过程中出现数据不平衡、EEG 特征冗余和难以捕捉到微弱特征信息等问题,本文构建了一种将 DDPM 模型数据增强、SMA 算法特征筛选与 CA 机制融合的深度学习方法。DDPM 的高保真生成有效缓解了数据不平衡问题,提高了稀有癫痫发作亚型的识别精度。SMA 算法起到了降维淘汰 EEG 特征的作用;而 CA 通过正交方向的空间编码加强了对时间和空间信息的捕捉能力。该方法弥补了传统分类模型在高复杂临床数据中的表现不足。本文模型为数据不平衡以及特征冗余问题的处理提供了新的解决思路,还可以为癫痫个体化治疗方案的制定提供高精度、强鲁棒性的辅助支持。

本文在标准数据集上取得了理想的分类效果,并对癫痫发作亚型分类方法的数据增强、特征筛选与注意力建模等多个环节进行了改进,但本文仅选取了一种具有代表性的技术方案来验证,其适用性和最优性还需进一步研究。同时可以进一步研究模型的算法效率以及实际应用效能,推动癫痫发作亚型分类技术在临床实践中的应用。

参考文献:

- [1] Ioannou P, Foster D L, Sander J W, et al. The burden of epilepsy and unmet need in people with focal seizures[J]. *Brain and Behavior*, 2022, 12(9): e2589.
- [2] 张思琪, 杨添淞, 马帅, 等. 深度学习在脑卒中诊断与防治中的研究进展[J]. *磁共振成像*, 2022, 13(11): 125-128.
- [3] 中国抗癫痫协会. 临床诊疗指南: 癫痫病分册: 2023 修订版[M]. 北京: 人民卫生出版社, 2023: 48-69.
- [4] 丁晶, 汪昕. 癫痫诊疗指南解读[J]. *临床内科杂志*, 2016, 33(2): 142-144.
- [5] Fraiwan L, Alkhdari M. Classification of focal and non-focal epileptic patients using single channel EEG and long short-term memory learning system[J]. *IEEE Access*, 2020, 8: 77255-77262.
- [6] Feng Y M, Zheng R Z, Cui X N, et al. 3D residual-attention-deep-network-based childhood epilepsy syndrome classification[J]. *Knowledge-Based Systems*, 2022, 248: 108856.
- [7] Cao J W, Chen Y H, Zheng R Z, et al. DSMN-ESS: dual-stream multitask network for epilepsy syndrome classification and seizure detection[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 4010212.
- [8] Ahmad I, Yao C, Li L, et al. An efficient feature selection and explainable classification method for EEG-based epileptic seizure detection[J]. *Journal of Information Security and Applications*, 2024, 80: 103654.
- [9] He H B, Garcia E A. Learning from imbalanced data[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2009, 21(9): 1263-1284.
- [10] Abd Elrahman S M, Abraham A. A review of class imbalance problem[J]. *Journal of Network and Innovative Computing*, 2013, 1: 332-340.
- [11] 王凤喆, 张雪英, 陈晓玉, 等. 基于有效注意力和 GAN 结合的脑卒中 EEG 增强算法[J]. *计算机工程*, 2024, 50(8): 336-344.
- [12] 曹崑, 李奇. 基于 Transformer 与 SNN 的 WGAN-GP 癫痫脑电数据增强方法[J]. *现代电子技术*, 2025, 48(23): 167-175.
- [13] Nichol A Q, Dhariwal P. Improved denoising diffusion probabilistic models[C]//*Proceedings of the 38th International Conference on Machine Learning*. PMLR, 2021: 8162-8171.
- [14] Dhariwal P, Nichol A. Diffusion models beat GANs on image synthesis[C]//*Proceedings of the 35th International Conference on Neural Information Processing Systems*. ACM, 2021: 8780-8794.
- [15] Yi H, Hou L, Jin Y, et al. Time series diffusion method: a denoising diffusion probabilistic model for vibration signal generation[J]. *Mechanical Systems and Signal Processing*, 2024, 216: 111481.
- [16] Zhao Z X, Bai H W, Zhu Y Z, et al. DDFM: Denoising diffusion model for multi-modality image fusion[C]//*2023 IEEE/CVF International Conference on Computer Vision (ICCV)*. October 1-6, 2023, Paris, France. IEEE, 2023: 8048-8059.
- [17] Gupta G, Khan S, Guleria V, et al. DDPM: a dengue disease prediction and diagnosis model using sentiment analysis and machine learning algorithms[J]. *Diagnostics*, 2023, 13(6): 1093.
- [18] Obeid I, Picone J. The temple university hospital EEG data corpus[J]. *Frontiers in Neuroscience*, 2016, 10: 196.
- [19] Ho J, Jain A N, Abbeel P. Denoising diffusion probabilistic models[C]//*Larochelle H, Ranzato M, Hadsell R, et al. Advances in Neural Information Processing Systems*. Vol. 33. Red Hook, NY: Curran Associates, Inc., 2020: 6840-6851.
- [20] Wu D, Li J, Dong F, et al. Classification of seizure types based on multi-class specific bands common spatial pattern and penalized ensemble model[J]. *Biomedical Signal Processing and Control*, 2023, 79: 104118.
- [21] 王剑, 成婷, 宋政阳, 等. 基于深度学习的癫痫异常信号检测和分类模型[J]. *电子测量技术*, 2025, 48(17): 113-124.
- [22] Tuncer E, Bolat E D. Channel based epilepsy seizure type detection from electroencephalography (EEG) signals with machine learning techniques[J]. *Biocybernetics and Biomedical Engineering*, 2022, 42(2): 575-595.
- [23] Albaqami H, Hassan G M, Datta A. Wavelet-based multi-class seizure type classification system[J]. *Applied Sciences*, 2022, 12(11): 5702.
- [24] 陈沛宇, 叶佩华, 黄辉. 基于三维卷积神经网络的多频段癫痫发作类型分类[J]. *工业控制计算机*, 2022, 35(12): 108-109.
- [25] 吴端坡, 励杰, 应娜. 基于二维脑网络特征选择的癫痫发作类型分类算法研究[J]. *实验室研究与探索*, 2023, 42(12): 73-78.
- [26] Jia G, Lam H K, Althoefer K. Variable weight algorithm for convolutional neural networks and its applications to classification of seizure phases and types[J]. *Pattern Recognition*, 2022, 121: 108226.
- [27] Hu Y, Liu J, Sun R, et al. Classification of epileptic seizures in EEG data based on iterative gated graph convolution network[J]. *Frontiers in Computational Neuroscience*, 2024, 18: 1454529.
- [28] Huang H, Chen P, Wen J, et al. Multiband seizure type classification based on 3D convolution with attention mechanisms[J]. *Computers in Biology and Medicine*, 2023, 166: 107517.