

# 基于多头交叉注意力机制融合多域特征的 癫痫分类识别研究

常文文, 王亚俊\*, 郭晋成, 舒康, 马煜

(兰州交通大学电子与信息工程学院, 甘肃兰州 730070)

**摘要:** 针对癫痫脑电信号 (Electroencephalogram, EEG) 发作前期 (preictal)、发作期 (ictal) 和发作间期 (interictal) 三种状态下的检测和识别问题, 提出了一种基于多头交叉注意力机制 (Multi-Head Cross-Attention Mechanism, MHCA) 融合脑电多域特征的分类识别模型. 该模型通过连续小波变换 (Continuous Wavelet Transform, CWT) 对癫痫脑电信号生成的二维图像按照通道进行有序拼接, 并利用浅层卷积神经网络 (Convolutional Neural Network, CNN) 对拼接后的时频图像进行特征提取以有效挖掘癫痫脑电信号的时频域特征. 同时通过构建脑功能连接矩阵, 刻画不同脑区之间的功能连接关系以捕捉癫痫发作过程中潜在的空域特征, 最终采用 MHCA 实现时频特征与空域特征之间的全局交互与自适应融合, 充分建模多维特征间的关联性与互补性, 进而构建癫痫脑电信号在时域、频域与空域三个维度上的完整且统一的特征表征. 实验结果表明, 该模型在癫痫发作前期、发作期和发作间期的多被试分类中最高分类准确率可达 92.49%, 灵敏度可达 92.48%, 体现了其在跨被试场景下良好的泛化能力与稳定性; 单被试分类中模型最高准确率为 98.39%, 灵敏度为 98.04%, 充分验证了该方法在个体化癫痫脑电识别任务中的有效性. 消融实验最终也进一步证实了脑功能连接矩阵所表征的空域信息和多头交叉注意力机制在多域特征融合与判别特征增强中的关键作用, 对模型的性能提升均具有正向贡献. 本文针对癫痫脑电分类识别的有效性验证, 不仅为临床脑电检测和识别提供了一种可靠且可行的技术手段, 也为癫痫脑电信号中关键特征的提取、表征与建模提供了新的研究思路和方法参考.

**关键词:** 癫痫检测; 脑电信号; 多域特征; 连续小波变换; 脑功能连接矩阵; 多头交叉注意力机制

**基金项目:** 国家自然科学基金 (No.62366028, No.W2421090); 甘肃省科技重大专项 (No.23ZDFA012); 甘肃省自然科学基金 (No.24JRRA256)

中图分类号: TP391 文献标识码: A 文章编号: 0372-2112(2025)12-4460-14

电子学报 URL: <http://www.ejournal.org.cn> DOI: 10.12263/DZXB.20250911

## Research on Epilepsy Classification and Recognition Based on Multi-Domain Feature Fusion via Multi-Head Cross-Attention Mechanism

CHANG Wen-wen, WANG Ya-jun\*, GUO Jin-cheng, SHU Kang, MA Yu

(School of Electronic and Information Engineering, Lanzhou Jiaotong University, Lanzhou, Gansu 730070, China)

**Abstract:** In this paper, we propose a classification and recognition model based on the multi-head cross-attention mechanism (MHCA) fusing EEG multi-domain features for the detection and recognition of epileptic electroencephalographic (EEG) signals in preictal, ictal and interictal states. The model is developed by sequentially splicing the two-dimensional images generated by continuous wavelet transform (CWT) of epileptic EEG signals according to the channels, and utilizing shallow convolutional neural network (CNN) to extract features from the spliced time-frequency images in order to effectively extract the time-frequency domain features of epileptic EEG signals. At the same time, the brain functional connectivity matrix is constructed to depict the functional connectivity between different brain regions to capture the potential spatial features during epileptic seizures, and finally, MHCA is used to realize the global interaction and adaptive fusion between time-frequency and spatial features to fully model the correlation and complementarity between multidimensional features, so as to construct a complete and unified feature characterization of epileptic EEG signals in the three dimensions of the time domain, the frequency domain, and the spatial domain. The experimental results show that the model can reach a

maximum classification accuracy of 92.49% and a sensitivity of 92.48% in multi-subject classification of preictal, ictal and interictal phases, which reflects its good generalization ability and stability in cross-subject scenarios; and the model can reach a maximum accuracy of 98.39% and a sensitivity of 98.04% in single-subject classification, which fully verifies the efficacy of the method in the task of individualized epilepsy EEG recognition. The ablation experiments ultimately further confirmed the critical role of the spatial information represented by the brain functional connectivity matrix and the multi-head cross-attention mechanism in multi-domain feature fusion and discriminative feature enhancement, both of which positively contributed to the model's performance improvement. This paper validates the efficacy of epileptic EEG classification and recognition, which not only provides a reliable and feasible technical means for clinical EEG detection and recognition, but also provides new research ideas and methodological references for the extraction, characterization and modeling of key features in epileptic EEG signals.

**Key words:** epilepsy detection; EEG signals; multi-domain features; continuous wavelet transform; functional connectivity matrix; multi-head cross-attention mechanism

**Foundation Item(s):** National Natural Science Foundation of China (No.62366028, No.W2421090); Gansu Provincial Key Science and Technology Special Project (No.23ZDFA012); Gansu Provincial Natural Science Foundation Project (No.24JRRA256)

## 1 引言

癫痫是一种由大脑神经元异常放电引发的慢性神经系统疾病,容易持续产生、反复发作<sup>[1]</sup>. 癫痫发作从极短暂的意识丧失或肌肉反射到严重且持续性抽搐不等,可能导致患者意识丧失或运动障碍,严重威胁其生命安全<sup>[2,3]</sup>. 根据 2024 年世界卫生组织(World Health Organization, WHO)的数据,全球约 5000 万人患有癫痫,癫痫成为全球范围内最常见的神经系统疾病之一<sup>[4]</sup>. 由于癫痫发作具有突发性和不可预测性,不仅威胁患者生命安全,还会造成患者严重的心理与社会负担,因此对癫痫进行提前检测,可以为患者留出足够的应对时间,便于其采取措施以减少发作带来的不便和尴尬.

脑电图作为癫痫诊断的“金标准”,具备毫秒级高时间分辨率,能够捕捉癫痫发作时特有的棘波、尖波等特征波形,同时头皮 EEG 无需侵入性操作,成本低廉,尤其适合儿童和重症患者的长期监测<sup>[5]</sup>. 传统人工判读方法面临效率低(需分析数小时至数天的数据)、主观偏差大(医生经验差异导致 20%~30% 误诊率)等瓶颈<sup>[6]</sup>. 随着 EEG 数据量的指数级增长,为了克服传统诊断手段的局限性、提高医疗效率,研究人员致力于开发智能化癫痫发作检测的自动化方法.

近年来,随着深度学习技术的突破性发展,癫痫的自动检测也进入了智能化的新阶段. 相较于传统机器学习受限于人工特征工程,如复杂网络度量、非线性动力学特征等<sup>[7-10]</sup>,深度学习通过分层特征变换机制,实现了特征提取与分类的自动化<sup>[11-13]</sup>. 卷积神经网络基于其局部感受野的设计原理,能够有效捕捉 EEG 信号时频表征中的局部时空模式,实现多层次特征的学习. 文献[14]首次将 CNN 与 Informer 结合用于癫痫发作检测,并使用 ProbSparse 自注意力机制降低复杂度. 文献[15]结合了残差网络(ResNet)和长短期记忆网络(Long

Short Term Memory, LSTM),分别提取脑电信号的空间相关性和时间依赖性特征,并引入差分层和通道注意力模块来增强 EEG 信号中的癫痫特征提取能力,最终在德国波恩大学(Bonn)公开的 EEG 数据集中,五分类任务达到了 90.17% 的准确率. 文献[16]提出了一种结合特征融合(feature fusion)的混合深度学习模型 CNN-Bi-LSTM 实现癫痫发作检测,从离散小波变换(Discrete Wavelet Transform, DWT)分解后的子频段中提取非线性和时频域特征,最终在二分类任务中的多个评估指标上均达到了满分表现. 文献[17]提出了一种新颖的余弦卷积神经网络(Cosine Convolutional Neural Network, CosCNN),通过将传统卷积核替换为仅含频率和振幅两个参数的余弦函数,最终事件敏感度(event-based sensitivity)达到 99.31%,实现了实时、低功耗的癫痫发作检测.

相比于端到端深度学习模型的可解释性差、难以理解决策过程<sup>[18-20]</sup>,基于图像的可视化方法可以更直观地展示脑区活动模式<sup>[21-23]</sup>. 并且二维图像能够保留 EEG 信号的时空信息,更适用于 CNN 处理,有助于模型更好地捕捉癫痫发作的空间模式<sup>[24]</sup>. 目前已有研究证实时频图在癫痫发作检测方面的优势,可以同时捕捉 EEG 信号的时域和频域特征,显著提升了癫痫发作检测的时间分辨率和检测灵敏度. 例如,文献[25]提出了一种基于深度学习的方法,使用公共平均参考(Common Average Reference, CAR)和低通切比雪夫无限脉冲响应(low-pass Chebyshev Infinite Impulse Response, IIR)滤波器以去除信号中的常见噪声和伪影,最终对 3 s 的信号应用短时傅里叶变换(Short-Time Fourier Transform, STFT),将其转换为二维矩阵并生成频谱图最终通过对图像进行分类来完成早期癫痫检测. 文献[26]从 CHB-MIT 数据集中选取了六个特定电极通道,结合

了STFT和图像分类中的经典模型Google-Net,实现了一种实时应用和低延迟性的癫痫发作检测方法.文献[13]提出了一种基于CWT和卷积神经网络的癫痫发作自动检测方法,使用Morlet小波函数将每个窗口内的EEG转换为时频图像(scalogram)作为CNN模型的输入,最终在Bonn数据集的多个分类任务中实现接近100%的准确率.文献[27]提出了一种结合CWT与深度卷积神经网络(Deep Convolutional Neural Networks,DCNN)的新颖方法,该方法结构简单、可扩展性强,实现了高效的癫痫自动诊断.文献[28]首次将S-变换(S-transform)与时频图像结合进行癫痫发作检测,利用S-变换在高/低频域的自适应分辨率优势提升了特征提取能力.

综上所述,基于时频域的EEG特征提取方法在癫痫自动检测和分类识别任务中已展现出较高的有效性,其核心优势在于能够捕捉脑电信号的非平稳特性及动态频谱变化.然而,现有研究中的多数方法仍存在一定的局限性,主要体现在特征提取策略的单一性上,即主要依赖于时频图像进行特征表征,并未充分考虑脑电信号的空间信息尤其是不同脑区之间的神经同步活动<sup>[29]</sup>.这种局限性可能导致模型对癫痫特异性放电的时空模式识别能力不足,进而影响分类性能的进一步提升.并且在基于CHB-MIT癫痫脑电数据集的自动分类中,绝大多数采用的仍是传统的二分类范式,即区分癫痫发作(seizure)和非发作(non-seizure)状态,缺乏更精细的时期划分.这种分类方式忽略了癫痫发作的动态演变过程,可能导致检测延迟或误判,影响临床决策的精准性.基于此,本文提出了一种基于多头交叉注意力机制的癫痫脑电信号特征融合方法,实现对癫痫发作期、发作前期和发作间期三个时段的分类识别.实验结果表明,本文提出的方法优于其他癫痫脑电信号识别方法,为癫痫发作机制的研究提供了新的分析思路.

本文的主要贡献在于:

(1)在时频域特征提取的基础上整合空域特征以提升癫痫自动检测的性能.特征提取阶段采用连续小波变换将EEG转化为二维图像以提取时频域特征并精确表征癫痫脑电信号的非平稳特性和动态节律变化;同时基于皮尔逊相关系数矩阵(Pearson Correlation Coefficient,PCC)计算不同脑区信号间的相关性作为空域特征表征.

(2)采用多头交叉注意力机制,通过并行计算架构分别在多个子特征空间中捕捉时频特征空间与空域特征空间之间的特征交互关系,实现双向的特征信息互补,有效提升特征表征的完备性.

(3)癫痫发作是一个动态过程,不同阶段的生理特征和临床干预需求不同.采用三分类范式可以实现对癫痫脑电信号的精细化阶段识别,完成对癫痫发作期、

发作前期和发作间期三个时段的分类识别,能帮助医生更准确地判断患者所处阶段,避免误诊或延迟治疗.

## 2 相关工作

### 2.1 连续小波变换

连续小波变换是一种可以将EEG等一维信号表示为小波时频图形式的时频分析方法,能够同时捕捉信号在时域和频域上的动态变化.连续小波变换生成小波时频图的具体过程如下.

(1)选择母小波.对于EEG等非平稳信号,一般选择Morlet(amor)小波进行连续小波变换,有

$$\psi(t) = \pi^{-1/4} e^{i\omega_0 t} e^{-t^2/2} \quad (1)$$

其中, $\psi(t)$ 为时域表示的母小波函数; $\omega_0$ 为中心频率,用于控制小波的振荡次数和衰减速度的平衡; $e^{-t^2/2}$ 为高斯包络函数,保证小波在时域上快速衰减.

(2)尺度转换.根据目标频带(0.5~32 Hz)计算小尺度 $a_{\min}$ (对应最高频 $f_{\max} = 32$  Hz)和大尺度 $a_{\max}$ (对应最低频 $f_{\min} = 0.5$  Hz).尺度步长通常按对数间隔采样,以均匀覆盖频带,有

$$a_{\min/\max} = \frac{f_c}{f_{\max/\min} \cdot \Delta t} \quad (2)$$

其中, $f_c$ 为小波中心频率,Morlet小波中 $f_c = \omega_0/(2\pi)$ , $f_s$ 为EEG信号的采样率, $\Delta t = 1/f_s$ 为采样间隔.

(3)快速卷积计算.为了避免循环卷积失真,需要对信号 $x[n]$ (长度为 $N$ )和小波基 $\psi_a[m]$ (长度为 $2M+1$ )分别进行补零至长度 $L \geq N+2M-1$ ,有

$$x_{\text{padded}} = [x[0], \dots, x[N-1], \underbrace{0, \dots, 0}_{L-N}] \quad (3)$$

$$\psi_{\text{padded}} = [\psi_a[-M], \dots, \psi_a[M], \underbrace{0, \dots, 0}_{L-2M-1}] \quad (4)$$

其中, $M = \lceil 10a \rceil$ 为小波支撑区半径.

将信号和小波离散化,并通过快速傅里叶变换(FFT)进行频域相乘加速计算,有

$$Y[k] = \text{FFT}(x_{\text{padded}}) \cdot \text{FFT}^*(\psi_{\text{padded}}) \quad (5)$$

其中, $Y[k]$ 为频域乘积的结果;FFT( $\cdot$ )为快速傅里叶变换;FFT\*( $\cdot$ )为FFT( $\cdot$ )的复共轭;对应时域小波的反转.

进行逆变换(IFFT)以将频域结果转换回时域,并进行截段剔除补零引入的虚假数据,保证结果与原始信号时间对齐,有

$$W[a, \tau] = \frac{1}{\sqrt{a}} \cdot \text{IFFT}(Y)[\tau] \quad (6)$$

其中, $\tau = 0, \dots, N-1$ ;IFFT( $\cdot$ )为逆快速傅里叶变换; $\frac{1}{\sqrt{a}}$ 为能量归一化因子,保证不同尺度的能量可比性; $W[a, \tau]$ 表示尺度 $a$ 、时移 $\tau$ 处的小波系数.

## 2.2 脑功能连接矩阵

采用多种不同的脑功能连接指标可以多角度刻画脑电信号的空间功能网络特征,从而更全面地评估癫痫发作过程中不同大脑区域之间的功能连接模式. 本文使用相位锁值和相位滞后指数作为评估相位同步的指标,这两个指标通过评估两个电极之间的相位关系,使用相位同步方法分析大脑的功能连接;同时通过采用皮尔逊相关系数和互信息值量化脑区间的线性和非线性依赖关系来衡量大脑内的功能连接.

(1)皮尔逊相关系数是衡量不同电极通道之间线性相关程度的指标,该值介于-1到1之间. PCC矩阵用于刻画不同脑区电极信号之间的功能连接强度,反映神经活动的同步性. 其定义如下:

$$PCC = \frac{\sum_{t=1}^T (x_t - \bar{x})(y_t - \bar{y})}{\sqrt{\sum_{t=1}^T (x_t - \bar{x})^2} \sqrt{\sum_{t=1}^T (y_t - \bar{y})^2}} \quad (7)$$

其中,  $x_t, y_t$  为两通道 EEG 信号在时间点  $t$  处的电压值;  $\bar{x}, \bar{y}$  为其对应的信号均值;  $T$  为时间序列的总长度. PCC 值为-1时,则表示两个通道的信号之间存在完全负线性相关,即两信号随时间变化呈现完全相反的线性趋势;PCC 值为0时,则表示两个通道的信号之间不存在线性相关性;PCC 值为1则表示两个通道的信号之间存在完全正线性相关.

(2)互信息(Mutual Information, MI)是用于度量两个通道信号之间相互依赖程度的指标,能够量化通过一个变量获取的关于另一个变量的信息量,同时能够捕捉到线性和非线性关系.

$$MI = \iint p(x, y) \log \frac{p(x, y)}{p(x)p(y)} dx dy \quad (8)$$

其中,  $p(x)$  为信号  $x(t)$  的边缘概率密度函数;  $p(x, y)$  为信号  $x(t)$  和信号  $y(t)$  的联合概率密度函数;  $\log$  为对数函数. 互信息值为0,则表示两个信号之间相互独立,即无共享信息;互信息值为其中一个变量的熵,则表示两个信号完全依赖,即全部信息共享.

(3)相位锁值(Phase Locking Value, PLV)是用于量化两个通道信号之间相位同步程度的指标,其基本思想是通过比较两个信号的相位差来评估它们的同步性,该值介于0~1之间. 其定义如下:

$$PLV = \left| \frac{1}{N} \sum_{t=1}^N e^{i(\phi_x(t) - \phi_y(t))} \right| \quad (9)$$

其中,  $\phi_x(t)$  和  $\phi_y(t)$  分别为信号  $x(t)$  和  $y(t)$  在时间点  $t$  的瞬时相位;  $i$  为虚数单位;  $N$  是时间点的总数. PLV 值为0表示两个通道信号之间无相位同步,即相位差随时间变化,观察到的信号区域之间没有连接;PLV 值为1代表两个通道信号之间的相位是同步的,即相位差恒定.

(4)相位滞后指数(Phase Lag Index, PLI): 与 PLV 相似,PLI 用于测量两个信号之间的相位差分布的不对称性. 它反映了两个信号之间的相位超限或滞后的一致性,是相位同步的一种有用的度量. 其计算公式为

$$PLI = \left| \frac{1}{N} \sum_{n=1}^N \text{sign}(\phi_x(t) - \phi_y(t)) \right| \quad (10)$$

其中,  $\phi_x(t)$  和  $\phi_y(t)$  分别是信号  $x(t)$  和  $y(t)$  在时间点  $t$  的瞬时相位;  $N$  是时间点的总数;  $\text{sign}(\cdot)$  为符号函数. 如果相位差为正,则  $\text{sign}(\cdot)$  函数返回1;如果相位差为负,则  $\text{sign}(\cdot)$  函数返回-1;如果相位差为0,则  $\text{sign}(\cdot)$  函数返回0.

## 2.3 多头交叉注意力机制

本文所提出的框架中的多头交叉注意力机制基于经典的自注意力机制<sup>[30]</sup>,是结合多头机制与交叉注意力的复合结构. 多头交叉注意力与自注意力共享基础公式,但输入来源不同,其计算公式如下:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax} \left( \frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_{\text{head}}}} \right) \mathbf{V} \quad (11)$$

其中,  $\mathbf{Q}$  为查询矩阵,来自序列  $A$ ,维度为  $[T_q \times d_{\text{head}}]$ ;  $\mathbf{K}$  为键矩阵,来自序列  $B$ ,维度为  $[T_k \times d_{\text{head}}]$ ;  $\mathbf{V}$  为值矩阵,来自序列  $B$ ,维度为  $[T_v \times d_v]$ ;  $d_{\text{head}}$  表示每个注意力头中特征向量的维度,用于对原始注意力得分进行缩放;总隐藏层维度  $d_{\text{model}} = h \times d_{\text{head}}$ ,其中  $h$  为注意力头数. 与多头自注意力不同,交叉注意力的查询  $\mathbf{Q}$  和键值  $\mathbf{K}, \mathbf{V}$  来自两个不同的输入序列,有

$$\text{MultiHead}(\mathbf{X}_1, \mathbf{X}_2) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h) \mathbf{W}^o \quad (12)$$

$$\text{head}_i = \text{Attention}(\mathbf{X}_1 \mathbf{W}_i^Q, \mathbf{X}_2 \mathbf{W}_i^K, \mathbf{X}_2 \mathbf{W}_i^V) \quad (13)$$

其中,  $\mathbf{X}_1$  为序列  $A$  的输入张量;  $\mathbf{X}_2$  为序列  $B$  的输入张量;  $\mathbf{W}_i^Q, \mathbf{W}_i^K, \mathbf{W}_i^V$  为第  $i$  个头的投影矩阵,维度分别为  $[d_{\text{model}} \times d_{\text{head}}]$ ;  $\mathbf{W}^o$  为最终输出投影矩阵,维度为  $[h \cdot d_{\text{head}} \times d_{\text{model}}]$ .

## 3 癫痫分类识别模型构建

### 3.1 数据集介绍

本文实验采用 CHB-MIT 数据集,该数据集是由波士顿儿童医院收集的,包含患有难治性癫痫的儿科受试者的脑电图记录. 记录分为23个案例,收集自22名受试者(5名男性,年龄3~22岁;17名女性,年龄1.5~19岁;案例 chb21 是在案例 chb01 发生1.5年后从同一名女性受试者那里获得的). 所有信号均以每秒256个样本的速度进行采样,分辨率为16位. 大多数 EEG 包含23个通道(少数情况下为24个或26个). 这些记录使用了国际10-20系统的 EEG 电极位置和命名法.

### 3.2 数据预处理

由于数据集采用了 10-20 国际定位系统,数据通道有标签,且标签是双极导联,所以对于每一对双极导联,规定了其位置是两个电极中间的电极所在位置.例如 channel 1:FP1-F7,规定标签为 AF7.为了获取高质量的数据,对原始数据采用统一滤波、全脑平均参考、通道定位等预处理,删除了可用通道数少于 20 的数据,经过通道整理,最终统一为 20 个通道(AF7、FT7、TP7、PO7、AF3、FC3、CP3、PO3、AF4、FC4、CP4、PO4、AF8、FT8、PO8、FCz、CPz、FT9、FT10、TP8),且顺序及名称一致.

发作前期数据截取为发作前 5~10 min 之内的数据段,部分前期时段在截取时避开了明显的噪声部分,但为了避免数据过短,保证数据的连续性和可用性,截取最短时段均超过了 40 s.选取距离上一次癫痫发作结束到下一次癫痫发作前 4 h 的稳定数据为发作间期数据,而且在截取时,避开了明显的噪声和伪迹时段,最短截取时间为 100 s.由于患者 chb06 和 chb16 的癫痫发作时间持续较短,大都在 20 s 以内,难以形成充分的时频及脑网络特征用于分类模型训练,因此为保证数据的完整性和特征质量,本研究未纳入 chb06 和 chb16 患者的数据.由于患者 chb24 的数据中没有详细标注每段数据的具体时间,故不考虑 chb24 的数据.最终每 4 s 截取为一个 epoch,癫痫发作间期共截取 2 559 个 epoch,发作前期共截取 2 447 个 epoch,发作时段共截取为 2 383 个 epoch.按照 9:1 划分训练集和测试集,训练集部分采用十折交叉验证方式,避免单次随机划分引入的偶然性.数据预处理过程均通过 MATLAB 工具包来完成.数据模型部分基于 Pytorch 框架搭建,所有实验均在配备了 Nvidia 4090 GPU 的服务器上进行.

### 3.3 特征提取

与传统的傅里叶变换不同,小波变换可以同时提供信号的时域和频域信息,特别适合处理非平稳信号(如 EEG).其中, Morlet 小波因其优良的时频局部化特性,并且能够同时提供较高的时间分辨率和频率分辨率,有效捕捉癫痫 EEG 中的短时尖峰和节律性异常信号,相较于其他基小波函数展现出更优的时频分析性能<sup>[13,31]</sup>.使用小波时频图能捕捉癫痫发作早期或微弱的突发频率变化(如高频振荡)和时域瞬态特征(如尖波、棘波),克服了传统时域或频域分析(如 FFT)的局限性.并且,在癫痫发作期间伴随多个脑区之间的异常同步活动,某些电极对之间的相关系数(如皮尔逊相关系数、互信息值、相位锁值或相位滞后指数)会显著升高.结合深度学习模型,将小波时频图和多种脑功能连接矩阵共同作为输入特征,充分利用脑电信号在时间-频率域和通道间功能连接两个层面的信息,从而提升模型的整体性能和鲁棒性.

通过上述 2.1 节中的变换步骤可将 20 个通道的 ep-

och 信号转化为二维的小波时频图并按通道进行拼接.图中的像素点表示各通道信号在特定时间和频率上的能量.以 chb01 患者的 epoch 数据为例,如图 1 所示. EEG 信号在该时段和频段的能量越强,则对应的时间-频率点的小波系数幅值越大,该处的颜色就越深(如图中红色部分).图中可以看到,不同时期 epoch 的能量主要集中在 30 Hz 以下频段,对于较低的  $\delta$  波段和  $\theta$  波段尤为明显.

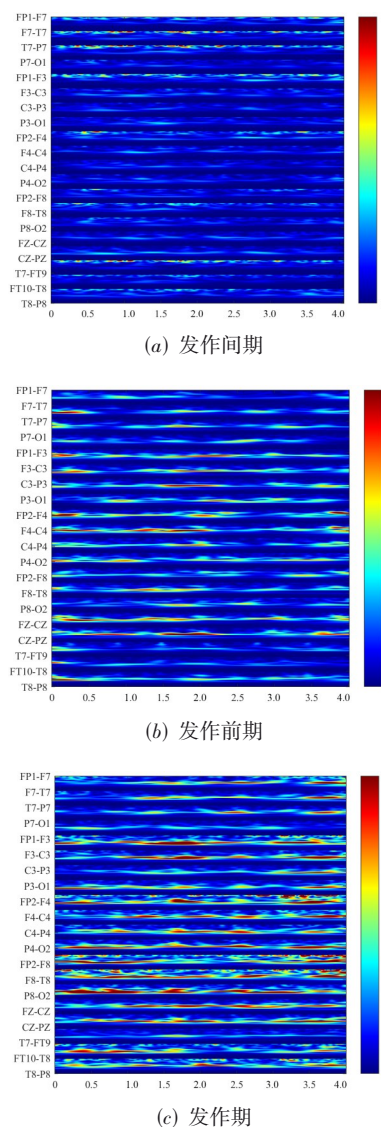


图1 chb01 患者发作不同时期的 CWT 图

通过上述 2.2 节中的计算,可将 20 个通道的 epoch 信号转化为四种  $20 \times 20$  的相关系数矩阵.如图 2 所示,以不同发作时期的 PPC 矩阵为例,图中颜色深浅代表不同通道之间信号线性相关性的强弱,反映了大脑区域间的功能连接强度. PCC 矩阵是对称的(对角线为 1, 因电极与自身的相关性为 1),因此颜色分布沿对角线

对称. 以 chb12 患者的 epoch 数据为例, 红色越深代表两个通道之间的正相关性越强(除对角线), 蓝色越深代表其负相关性越强.




图2 chb12 患者发作不同时段 PCC 矩阵

### 3.4 特征融合

目前, 基于深度学习的多特征融合方法主要有 3 种:

在输入层或浅层网络直接融合原始多类特征, 如时频特征和空域特征; 各模块独立通过子网络独立提取高层特征, 在全连接层前进行融合<sup>[32]</sup>; 或者使用注意力机制的动态融合方法, 通过自适应学习跨序列特征间的注意力权重分布, 实现对多源异构特征动态筛选与优化重组, 并且能够依据输入特征的上下文语义关联, 自主分配各序列特征的贡献度, 使得在保留特征的同时抑制冗余或噪声干扰<sup>[33]</sup>. 然而, 这些方法存在明显的局限性, 它们往往会导致特征冗余, 使得融合结果易陷入局部最优解并受到噪声干扰, 并且难以有效建模不同特征间的复杂交互关系, 从而显著制约算法性能的提升.

为了解决上述问题, 本文创新性地引入多头交叉注意力机制. 多头交叉注意力机制是 Transformer 架构中的核心模块之一, 主要用于处理两个不同序列之间的交互信息. 基于交叉注意力机制的方法不仅可以通选择性地关注模块间的有效信息并抑制冗余特征来缓解上述问题, 而且其全局交互机制能够充分捕捉不同序列数据间的复杂非线性关联<sup>[34]</sup>. 多头交叉注意力通过并行多组注意力头, 从不同子空间(subspace)捕获时频-空域特征的跨序列依赖关系, 最终融合所有头的输出以增强模型表达能力, 得到更鲁棒的特征表示. 在癫痫脑电信号分析中, 时频域特征和空域特征分别从不同维度反映神经活动的动态特性, 并且癫痫的异常放电可能表现为多种模式的叠加, 使得单一注意力机制难以全面捕捉. 此外, 还将残差连接和层归一化内置到了模块中, 并且增加了前馈神经网络以进一步非线性变换和避免特征退化. 同时采用多层级 Dropout 设计, 在注意力权重、输出投影和前馈神经网络内部都添加了 Dropout 层, 通过分层 Dropout 策略, 防止过拟合(overfitting)并增强模型泛化能力. 具体结构设计如图 3 所示.

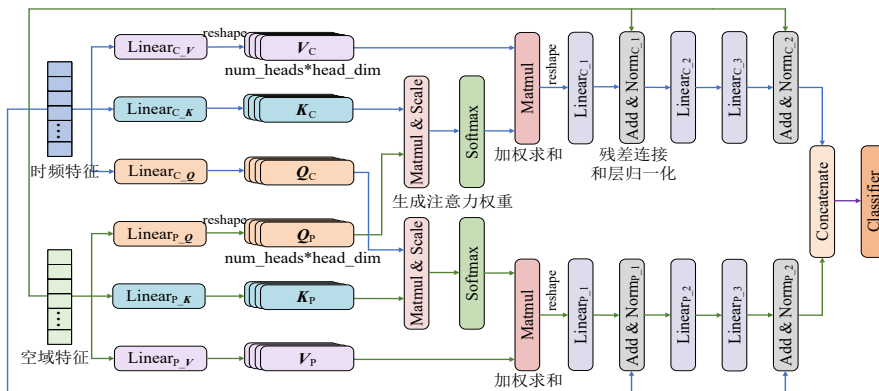


图3 多头交叉注意力机制结构设计图

表示时频域特征和空域特征的二维图像分别经过 4 层卷积、池化之后被展平成一维的特征向量, 然后采用上述的多头交叉注意力机制来实现两个特征序列之间的全局信息交换, 该设计既保留了自注意力的灵活

性, 又通过输入分离扩展了跨域信息融合能力.

### 3.5 模型构建

本文提出了一种基于多头交叉注意力机制的新型 EEG 癫痫分类识别模型, 该模型使用连续小波变换结

合空域特征并最终使用多头交叉注意力机制促进异构特征的融合,通过结合时域、频域、空域的特征,弥补单一域分析的局限性,实现对复杂癫痫脑电信号的全面表征与精准分析,整体框架如图4所示.该模型将由连续小波变换生成的时频图和四种不同的脑功能连接矩阵送入浅层CNN以提取时频特征和空域特征,然后将提取的特征使用多头交叉注意力机制进行加权融合,最后送入分类器中进行分类识别.

图4详细展示了所提出的基于多头交叉注意力机制融合脑电多域特征的分类识别模型.首先,将经过预处理之后的一维脑电信号按通道使用连续小波变换生成二维的小波时频图作为模型的时频特征输入,并使用每个 epoch 生成的不同脑功能连接矩阵作为输入以提取空域特征.分别经过浅层的 CNN 模型提取特征之后,使用多头交叉注意力机制将提取的时频域特征和空域特征进行融合,然后送入全连接层中进行分类.实验中的 CNN 模型由 4 层卷积层和 4 层池化层组成,并且每个卷积层后面都添加了批量归一化层(Batch Normalization Layers)以加速收敛,提升模型的性能并增强稳定性.在多头交叉注意力部分,对比使用 2 头、4 头和 8 头时模型的准确率和各种指标,采用 4 头时模型效果最为稳定,并且准确率最高.然后经过大小为 1 024、128 的两层全连接层,最后输出三分类结果的概率.模型训练时在全连接层后面添加 50% 的 Dropout 层随机丢弃部分神经元并配合使用 L2 正则化来防止过拟合,同时增强模型的泛化能力.具体实现细节如表 1 所示.

表 1 所提模型的实现细节

方法	Layers	Filter	Kernel	Padding	Stride	Output
CWT	Input	—	—	—	—	(3,1 280, 1 280)
	Conv1	16	(7,7)	3	2	(16,640,640)
	Maxpool1	—	(2,2)	0	2	(16,320,320)
	Conv2	32	(5,5)	2	2	(32,160,160)
	Maxpool2	—	(2,2)	0	2	(32,80,80)
	Conv3	64	(3,3)	1	2	(64,40,40)
	Maxpool3	—	(2,2)	0	2	(64,20,20)
	Conv4	128	(3,3)	1	2	(128,10,10)
	AdaptiveAvgPool	—	—	—	—	(128,4,4)
PCC	Flatten	—	—	—	—	128*4*4
	Input	—	—	—	—	(3,128,128)
	Conv1	16	(5,5)	2	2	(16,64,64)
	Maxpool1	—	(2,2)	0	2	(16,32,32)
	Conv2	32	(3,3)	1	1	(32,32,32)
	Maxpool2	—	(2,2)	0	2	(32,16,16)
	Conv3	64	(3,3)	1	1	(64,16,16)
	Maxpool3	—	(2,2)	0	2	(64,8,8)
	Conv4	128	(3,3)	1	1	(128,8,8)
特征融合	Maxpool4	—	(2,2)	0	2	(128,4,4)
	Flatten	—	—	—	—	128 × 4 × 4
	concatenate	—	—	—	—	2 × 128 × 4 × 4
	Fully connected1	—	—	—	—	1 024
特征融合	Fully connected2	—	—	—	—	128
	Fully connected3	—	—	—	—	3

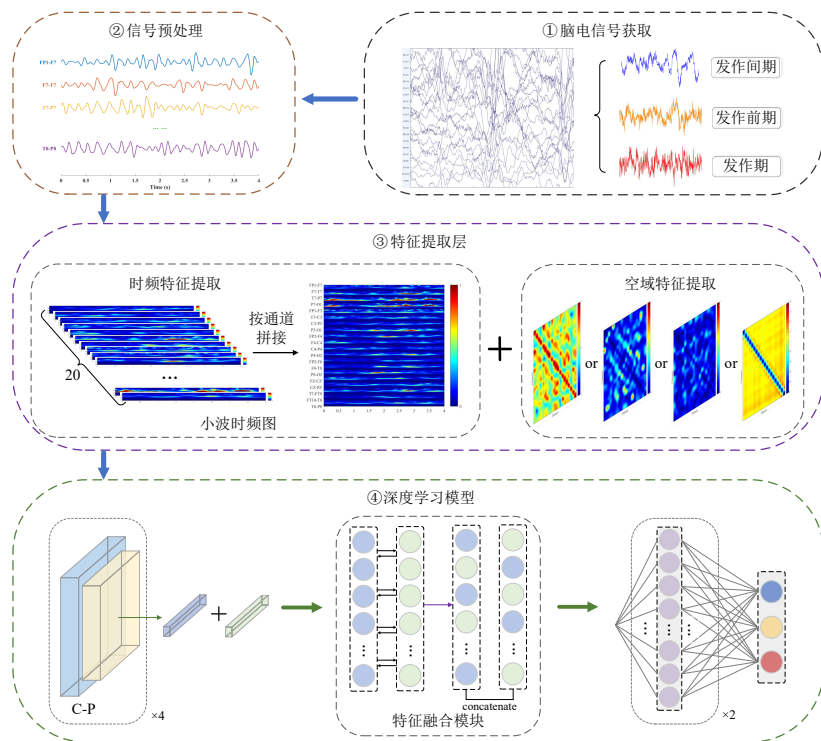


图 4 模型整体框架图

## 4 结果分析及讨论

### 4.1 不同脑功能连接矩阵对分类性能的影响分析


最终经过预处理得到不同时段的 epoch 共 7 389 个,为了检验将 EEG 使用连续小波变换并按通道进行拼接表示的二维图像结合不同脑功能连接矩阵对脑电信号特征提取的有效性和互补性,验证其对癫痫发作不同时段分类任务中的准确性,本文选择 PCC 矩阵、MI 矩阵、PLV 矩阵和 PLI 矩阵四种不同的脑功能连接矩阵分别结合二维 CWT 图像进行对比分析. 并且采用十折交叉验证方法,将训练集 epoch 等分为 10 份,依次将其中 9 份作为训练集,剩余 1 份作为验证集,共进行 10 次独立实验,避免单次随机划分引入的偶然性,最终计算 10 次实验的 Accuracy、Precision、F<sub>1</sub> Score、Specificity 和 Sensitivity 的平均值作为评估指标,用作模型的最终性能估计.

使用不同脑功能连接矩阵下的十折交叉验证结果如图 5 所示,其三分类结果准确率都在 88% 以上. 其中使用 PCC 矩阵时最低准确率为 89.62%, 对应灵敏度为 89.69%, 最高准确率为 92.49%, 对应灵敏度为 92.48%; 在使用 MI 矩阵时的最低准确率为 88.72%, 对应灵敏度为 88.73%, 最高准确率为 91.73%, 对应灵敏度为 91.67%; 在使用 PLV 矩阵时的最低准确率为 87.97%, 最高准确率为 91.73%; 在使用 PLI 矩阵时的最低准确率为 87.07%, 最高准确率为 89.32%.

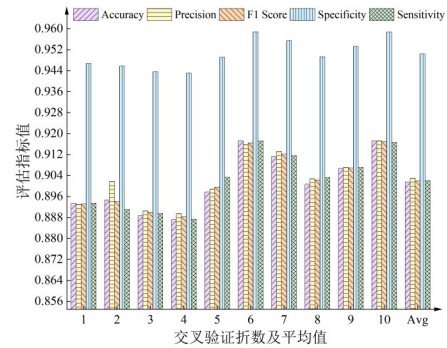
使用不同脑功能连接矩阵下的十折交叉验证的平均评估指标结果如图 6 所示,可以看出使用 PCC 矩阵时的各类评估指标值均最高,使用 PLV 矩阵和 MI 矩阵时的各类评估指标值次之且比较接近,而使用 PLI 矩阵时的各类评估指标值均最低. 这主要与不同脑功能连接度量在癫痫发作时期特征敏感性的差异相关. 癫痫发作时通常伴随明显的突发性同步放电,脑区往往表现出强烈的线性相关性,基于线性相关系数构建的 PCC 矩阵对这种同步变化比较敏感,可以有效捕捉此类特征,因此在分类任务中表现最优;MI 作为衡量变量间非线性统计依赖的指标,能够描述更复杂的耦合关系.

但其计算复杂度和对数据量的要求更高,因此在癫痫 EEG 数据有限、时间窗较短的情况下表现略逊于 PCC;对于相位同步类指标,PLV 能够反映脑区间瞬时相位一致性,但容易受噪声和容积传导的影响,可能将非生理性同步(如电极间干扰)误判为相位一致性,导致其准确率略低于 PCC 和 MI;PLI 的准确率最低是因为癫痫发作时期同步事件通常较短,而 PLI 依赖相位滞后信息,使其对短暂、快速的发作期同步事件不够敏感,容易将短时同步平滑掉,导致其特征捕捉能力下降. 尽管上述四类脑功能连接矩阵表现存在差异,但是在特征表征维度上具有明显的互补性.

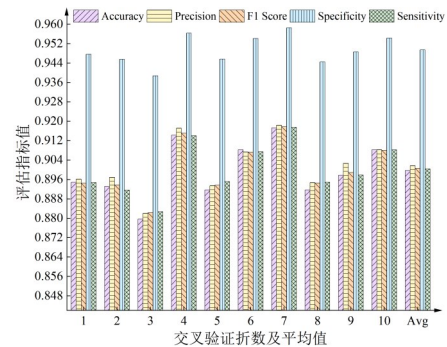
由于使用 PCC 矩阵时的各类评估指标值均最高,




(a) PCC 矩阵



(b) MI 矩阵



(c) PLV 矩阵



(d) PLI 矩阵

图 5 使用不同脑功能连接矩阵的十折交叉验证结果

因此均使用 PCC 矩阵进行后续实验. 使用 PCC 矩阵的十折交叉验证结果进行测试的结果如图 7 所示,可以看出测试集最高准确率为 93.63%, 最低准确率为

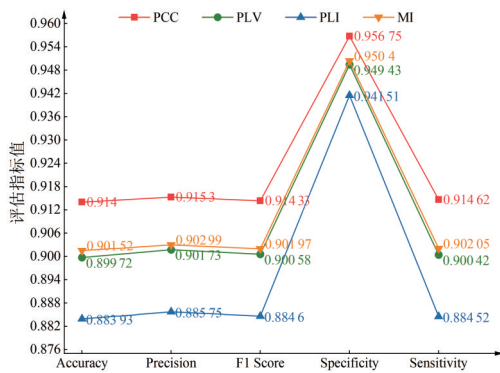


图6 使用不同脑功能矩阵的十折交叉验证结果的平均值




图7 使用PCC矩阵的十折交叉验证结果进行测试的结果

90.11%, 平均准确率为 91.53%。十折交叉验证中第七折的准确率最低, 但是第七折的模型参数对应的测试集的准确率最高, 这是因为单折验证准确率仅反映该折中验证集的表现, 容易受极端样本或类别分布影响导致模型预测偏差无法完全代表模型的泛化能力。需通过十折交叉验证的平均准确率进行综合评估, 以降低数据划分随机性的影响, 提升模型性能估计的统计可靠性。使用 PCC 矩阵的十折交叉验证结果进行测试的部分混淆矩阵如图 8 所示。

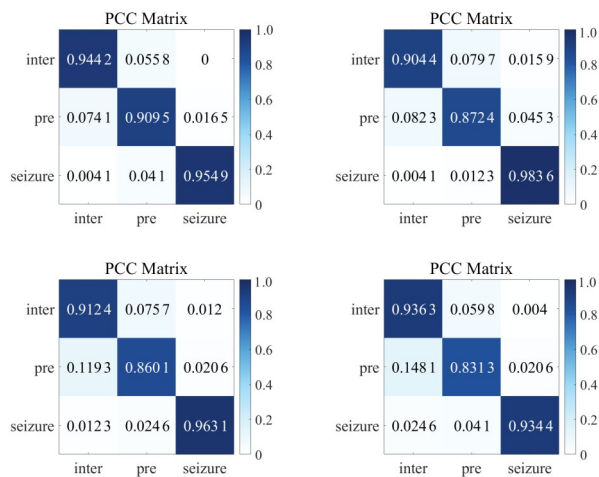


图8 使用PCC矩阵的十折交叉验证结果进行测试的部分混淆矩阵

### 4.2 多头交叉注意力机制中不同头数对分类性能的影响分析

为了验证本文所使用的多头交叉注意力机制对脑电信号特征提取的有效性, 设计不同头数的多头交叉注意力机制进行实验验证, 使用 PCC 矩阵作为脑功能连接矩阵, 其十折交叉验证的平均结果如表 2 所示。由图 9 可知, 当多头交叉注意力机制的头数设置为 1 时所得到的分类准确率、精确度、 $F_1$  分数、特异性和灵敏度均最低; 随着头数的增加, 模型可以更全面地捕捉脑电信号的时频域和空域特征, 其分类准确率也随之提高, 当头数为 4 时, 准确率等各类指标均达到最高, 且灵敏度高达 91.46%, 精确度高达 91.53%; 在增加多头交叉注意力机制的头数之后, 每个头的注意力权重因过度拟合训练数据中的噪声或无关特征而降低特征融合的有效性, 导致模型泛化能力下降, 其分类准确率、精确度、 $F_1$  分数、特异性和灵敏度也都随之降低。因此, 本文选取 4 头的多头交叉注意力机制能够更加充分有效地提取癫痫脑电信号的特征。

表2 使用多头交叉注意力机制不同头数的模型结果 单位:%

头数	Accuracy	Precision	$F_1$ Score	Specificity	Sensitivity
1	90.20	90.33	90.24	95.07	90.25
2	90.38	90.53	90.42	95.14	90.38
4	91.40	91.53	91.43	95.68	91.46
8	91.23	91.37	91.28	95.59	91.28
16	91.17	91.30	91.20	95.55	91.17

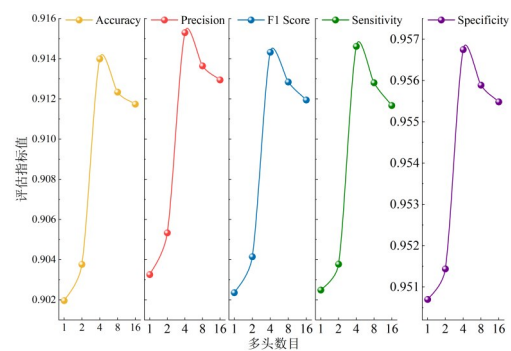


图9 使用多头交叉注意力机制不同头数的结果图

### 4.3 特征提取中不同卷积层数对分类性能的影响分析

为了验证本文所提出的特征提取框架是否能够充分提取癫痫脑电信号的深层特征, 设计不同框架的 CNN 模型进行实验验证, 并使用 PCC 矩阵作为脑功能连接矩阵, 其结果如表 3 所示。可以看到, 当卷积层数和池化层数设置为 1 时, 模型的分类准确率、精确度、 $F_1$  分数、特异性和灵敏度均最低; 随着层数的增加, 模型可以更深层次地捕捉脑电信号的时频域和空域特征, 其分类准确率也随之提升。当卷积层数和池化层数为 4

表 3 使用不同卷积层数的模型结果

单位:%

卷积/池化层数	滤波器	Accuracy	Precision	F <sub>1</sub> Score	Specificity	Sensitivity
2	3/16/32	90.54	90.85	90.52	95.27	90.46
3	3/16/32/64	91.13	91.05	90.97	95.53	90.90
4	3/16/32/64/128	91.40	91.53	91.43	95.68	91.46
5	3/16/32/64/128/256	90.83	91.12	90.90	95.40	90.83
6	3/16/32/64/128/256/384	90.68	90.67	90.69	95.33	90.73

时,模型准确率达到最高(91.40%),同时各类指标也均达到最高.当再增加模型层数之后,由于EEG数据量有限,难以支撑过深网络的有效训练,容易出现过拟合现象.并且过深的卷积堆叠在特征提取过程中会逐渐扩大感受野从而削弱或抹除原始EEG中具有短时突发性特征的局部细粒度信息,导致模型分类性能出现下降趋势.因此,本文选取4层的卷积神经网络框架可以更加充分有效地提取癫痫脑电信号的特征.

4.4 单被试分析

为了进一步验证模型的性能,从本实验所使用的21名被试中,随机挑选出10名被试进行单被试分析,表4为PCC矩阵下的单被试分析结果,其三分类准确率均在78%以上.其中chb11患者的准确率最高为98.39%,灵敏度为98.04%;chb14患者的准确率最低为78.95%,灵敏度为76.67%.造成个体指标差异较大的原因是不同被试的癫痫灶位置、发作频率和持续时间存在个体差异性,导致发作间期与发作期的区分难度不同,而且CHB-MIT数据集多包含儿童受试者,其运动伪迹、电极接触不良等因素可能导致部分被试数据信噪比偏低,影响模型对发作事件的捕捉.针对chb14的数据进一步分析发现,其EEG整体波动性明显高于其他被试,且在连续小波变换中呈现出较为广泛的高频能量分布,如图10所示,这表明chb14患者的癫痫发作特征更加

复杂且局灶不明显.这种高频成分丰富、波形剧烈波动的模式会在特征提取阶段增加噪声干扰,使典型的发作相关时频模式不够突出,从而降低模型分类精度.该现象也反映了癫痫EEG的个体异质性对模型性能的影响,虽然单被试分类结果有差异,但整体上结果较好,表明该模型针对癫痫脑电信号具有良好的分类性能.因此分别选择了准确率最高、中等和最低的被试绘制混淆矩阵,如图11所示,从上到下、从左至右分别为使用PCC矩阵挑选的准确率低、中、高被试的混淆矩阵.

表 4 部分被试实验结果

单位:%

被试名称	Accuracy	Precision	F <sub>1</sub> Score	Specificity	Sensitivity
chb01	97.50	97.62	97.53	98.77	97.62
chb03	96.97	97.62	96.20	98.33	95.24
chb04	93.10	93.94	93.94	96.30	93.94
chb05	85.37	85.93	85.03	92.37	84.72
chb11	98.39	98.72	98.34	99.10	98.04
chb12	97.14	97.70	97.42	98.45	97.33
chb13	96.55	97.22	96.40	95.83	95.83
chb14	78.95	80.56	77.27	86.51	76.67
chb15	95.46	95.38	95.20	97.76	95.11
chb18	89.29	93.75	89.14	93.33	86.67
Average	92.87	93.84	92.65	95.68	92.12

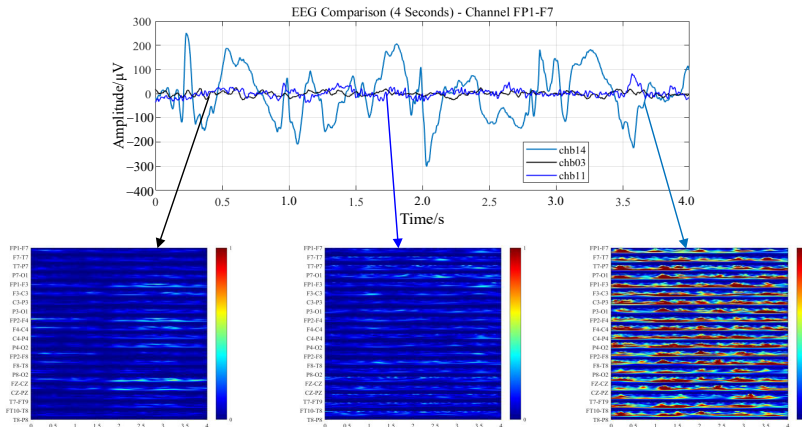


图 10 不同被试单个 epoch 下 FP1-F7 通道的脑电波形和生成的 CWT 图像

4.5 消融实验

为了验证该模型中脑功能连接矩阵和多头交叉注

意力机制的贡献度,通过对比移除这些模块前后的性能差异进行消融研究,表5给出了两项不同的消融研究

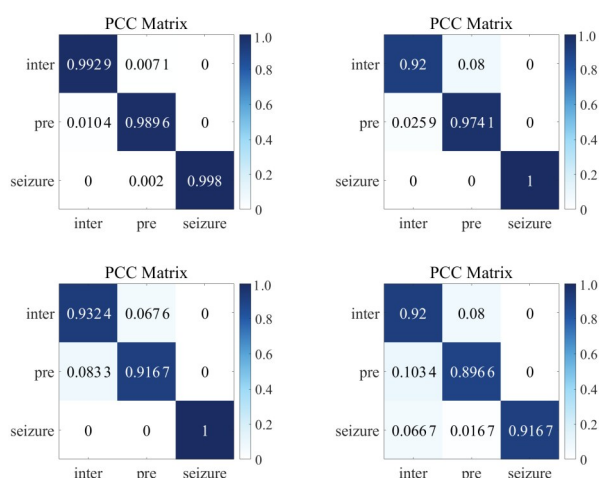


图 11 不同准确率下单被试混淆矩阵

以及本文所提出的模型。

在第一项研究中,为了研究脑功能测量矩阵的贡献度,从模型中移除该模块,仅使用连续小波变换生成的二维图像进行特征提取并分类;第二项研究中,为了研究多头交叉注意力机制的贡献度,从模型中移除该模块,将连续小波变换生成的二维图像和脑功能测量矩阵单独通过子网络提取特征后在全连接层前进行融合,后使用两层全连接层进行分类。

结果表明,在移除多头交叉注意力机制之后,准确率下降了 0.42%,移除 PCC 矩阵之后,准确率下降了 0.57%。表明 PCC 矩阵通过计算不同通道信号间的线性相关性,补充了信号间的空间关联性信息,而多头交叉注意力机制通过动态计算特征间的权重分配,能够自适应聚焦癫痫发作不同时段的关键时频成分和功能连接模式,同时抑制噪声干扰。且由图 12 可以看出,随着模型组件的逐步叠加,模型的收敛速度逐步加快,同时验证了 PCC 特征与多头交叉注意力机制对模型性能的正向贡献,表明 PCC 矩阵和多头交叉注意力机制的有效性。

## 4.6 对比分析

### 4.6.1 不同多域特征融合方式对比分析

为了验证本文所使用的多头交叉注意力机制的优越性,在相同的实验条件下分别与当下几种经典的注意力机制进行对比,包括多头自注意力机制(Multi-Head Self-Attention, MHSA)、协同注意力机制(Co-Attention)、通道注意力机制(Squeeze-and-Excitation,

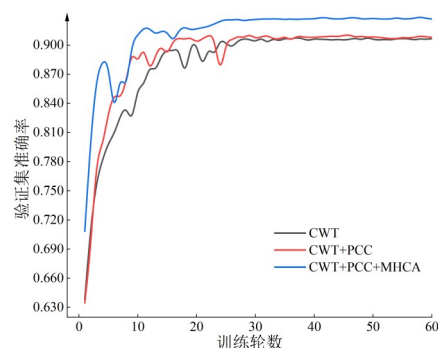


图 12 不同模型组件下的验证集准确率

SE)和卷积注意力模块(Convolutional Block Attention Module, CBAM),其结果如表 6 所示。可以看出本文所使用的 MHCA 在准确率、精确度、 $F_1$  分数、特异性和灵敏度等各项指标方面均显著优于其他注意力机制,这肯定了多头交叉注意力机制能够在特征融合过程中同时建模时频域特征与空域特征之间的双向依赖关系,可以更加高效地实现不同特征之间的双向互补与融合。相比之下,通道或空间注意力机制(如 SE、CBAM)仅在特征内部进行权重分配,难以捕捉不同特征间的结构关联,因此无法达到同等的融合效果。MHCA 的多头并行注意能力不仅可以增强模型对局部突发性癫痫事件与整体脑网络拓扑变化的联合感知能力,还提升了特征表达的判别性,使得模型最终具有更好的分类性能。

### 4.6.2 不同分类模型对比分析

为了验证本文所提出模型的优越性,在相同的实验条件下分别与几种癫痫脑电信号分类算法进行对比分析,其结果如表 7 所示,可以看出本文所使用的模型分类结果在各项指标方面均优于其他算法。侧面说明单一域的特征仅从单一视角表征癫痫活动的局部特性,难以充分捕捉癫痫发作在不同阶段所呈现的多尺度、非平稳变化模式。而多域特征结合通过利用脑电信号在时频域的局部瞬态模式以及在空间域中的脑功能连接信息,整合脑电信号在不同分析维度上的互补信息,可以更全面地表征癫痫发作不同时期的细微差异,显著提升癫痫分类识别的稳定性和准确率。整体来看,本文所提出的多域特征融合模型在癫痫脑电信号的多分类检测任务中更具优势,其对发作前期的分类检测为提前预测癫痫发作提供了潜在可行性,有助于提升模型在临床辅助诊断场景中的应用价值。

表 5 不同模块评价结果

单位: %

方法	Accuracy	Precision	$F_1$ Score	Specificity	Sensitivity
CWT	90.83	91.22	90.73	95.30	90.48
CWT+PCC	90.98	91.20	91.07	95.39	91.01
CWT+PCC+MHCA	91.40	91.53	91.43	95.68	91.46

表 6 使用不同多域特征融合方式的模型结果 单位:%

特征融合方式	Accuracy	Precision	F <sub>1</sub> Score	Specificity	Sensitivity
MHSA	91.26	91.31	91.34	95.61	91.42
Co-Attention	91.25	91.29	91.33	95.61	91.40
SE	91.12	91.25	91.23	95.53	91.21
CBAM	90.85	90.99	90.94	95.40	90.96
MHCA	91.40	91.53	91.43	95.68	91.46

表 7 不同算法分类结果 单位:%

方法	Accuracy	Precision	F <sub>1</sub> Score	Specificity	Sensitivity
CWT-CNN <sup>[13]</sup>	91.26	91.51	91.39	95.61	91.39
CNN-Bi-LSTM <sup>[16]</sup>	87.43	87.64	87.56	93.69	87.66
CE-stSENet <sup>[35]</sup>	88.18	88.37	88.27	94.03	88.24
MRCNN <sup>[36]</sup>	89.78	89.97	89.76	94.89	89.71
MAF <sup>[37]</sup>	84.71	84.88	84.70	92.31	84.62
本文提出的方法	91.40	91.53	91.43	95.68	91.46

## 5 结论

本文针对癫痫脑电信号的发作前期、发作期和发间期提出了一种基于多头交叉注意力机制融合多域特征的癫痫分类识别模型。首先,将连续小波变换对癫痫脑电信号生成的二维图像按通道进行拼接,利用浅层 CNN 提取时频域特征,同时使用脑功能连接矩阵捕捉空域特征信息,最终使用多头交叉注意力的全局交互机制融合时频空三个维度特征构建癫痫脑电信号的完整表征。该模型三分类情况下多被试分类准确率最高可达 92.49%,单被试下的最高准确率为 98.39%,且经过消融实验证实了脑功能连接矩阵和多头交叉注意力机制对模型的正向贡献。本文对癫痫脑电信号分类识别的有效性验证,不仅为临床应用提供了可靠工具,同时也为揭示癫痫的病理生理机制奠定了基础。

### 参考文献

- [1] BANDOPADHYAY R, SINGH T, GHONEIM M M, et al. Recent developments in diagnosis of epilepsy: Scope of microRNA and technological advancements[J]. *Biology*, 2021, 10(11): 1097.
- [2] RIDSDALE L, CHARLTON J, ASHWORTH M, et al. Epilepsy mortality and risk factors for death in epilepsy: A population-based study[J]. *The British Journal of General Practice*, 2011, 61(586): e271-e278.
- [3] FISHER R S, VICKREY B G, GIBSON P, et al. The impact of epilepsy from the patient's perspective I. Descriptions and subjective perceptions[J]. *Epilepsy Research*, 2000, 41(1): 39-51.
- [4] WHO. Epilepsy[EB/OL]. (2024-02-07)[2025-11-20]. <https://www.who.int/news-room/fact-sheets/detail/epilepsy>.
- [5] 韩长明, 彭福来, 陈财, 等. 基于脑电信号的癫痫发作预测研究进展[J]. *生物医学工程学杂志*, 2021, 38(6): 1193-1202.  
HAN C M, PENG F L, CHEN C, et al. Research progress of epileptic seizure predictions based on electroencephalogram signals[J]. *Journal of Biomedical Engineering*, 2021, 38(6): 1193-1202. (in Chinese)
- [6] ZHANG T, CHEN W Z. LMD based features for the automatic seizure detection of EEG signals using SVM[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2017, 25(8): 1100-1108.
- [7] JIANG L R, HE J W, PAN H Y, et al. Seizure detection algorithm based on improved functional brain network structure feature extraction[J]. *Biomedical Signal Processing and Control*, 2023, 79: 104053.
- [8] SI Y. Machine learning applications for electroencephalograph signals in epilepsy: A quick review[J]. *Acta Epileptologica*, 2020, 2(1): 5.
- [9] SIDDIQUI M K, MORALES-MENENDEZ R, HUANG X D, et al. A review of epileptic seizure detection using machine learning classifiers[J]. *Brain Informatics*, 2020, 7(1): 5.
- [10] 张学军, 景鹏, 何涛, 等. 基于变分模态分解的癫痫脑电信号分类方法[J]. *电子学报*, 2020, 48(12): 2469-2475.  
ZHANG X J, JING P, HE T, et al. An epileptic electroencephalogram signal classification method based on variational mode decomposition[J]. *Acta Electronica Sinica*, 2020, 48(12): 2469-2475. (in Chinese)
- [11] 王兴起, 李明爱. 应用基于注意力的多尺度残差网络实现癫痫脑电自动检测[J]. *生物医学工程学杂志*, 2024, 41(2): 253-261.  
WANG X Q, LI M A. Automatic epilepsy detection with an attention-based multiscale residual network[J]. *Journal of Biomedical Engineering*, 2024, 41(2): 253-261. (in Chinese)
- [12] AKOR P, ENEMALI G, MUHAMMAD U, et al. Hierarchical deep learning for comprehensive epileptic seizure analysis: From detection to fine-grained classification[J]. *Information*, 2025, 16(7): 532.
- [13] SHUKLA R, KUMAR B, GAURAV G, et al. Epileptic seizure detection using continuous wavelet transform and deep neural networks[M]//*Sensing Technology*. Cham: Springer International Publishing, 2022: 291-300.
- [14] LI C Y, LI H T, DONG X C, et al. CNN-Informer: A hybrid deep learning model for seizure detection on long-


- term EEG[J]. *Neural Networks*, 2025, 181: 106855.
- [15] QIU X J, YAN F, LIU H H. A difference attention ResNet-LSTM network for epileptic seizure detection using EEG signal[J]. *Biomedical Signal Processing and Control*, 2023, 83: 104652.
- [16] CAO X S, ZHENG S J, ZHANG J C, et al. A hybrid CNN-Bi-LSTM model with feature fusion for accurate epilepsy seizure detection[J]. *BMC Medical Informatics and Decision Making*, 2025, 25(1): 6.
- [17] LIU G Y, TIAN L, WEN Y M, et al. Cosine convolutional neural network and its application for seizure detection[J]. *Neural Networks*, 2024, 174: 106267.
- [18] LI Q, CAO W, ZHANG A Y. Multi-stream feature fusion of vision transformer and CNN for precise epileptic seizure detection from EEG signals[J]. *Journal of Translational Medicine*, 2025, 23(1): 871.
- [19] WU X, YANG Z H, ZHANG T L, et al. An end-to-end seizure prediction approach using long short-term memory network[J]. *Frontiers in Human Neuroscience*, 2023, 17: 1187794.
- [20] LI H T, DONG X C, ZHONG X W, et al. End-to-end model for automatic seizure detection using supervised contrastive learning[J]. *Engineering Applications of Artificial Intelligence*, 2024, 133: 108665.
- [21] HUANG W Q, YAN G H, CHANG W W, et al. EEG-based classification combining Bayesian convolutional neural networks with recurrence plot for motor movement/imagery[J]. *Pattern Recognition*, 2023, 144: 109838.
- [22] SHANKAR A, DANDAPAT S, BARMA S. Seizure type classification using EEG based on gramian angular field transformation and deep learning[C]//2021 43rd Annual International Conference of the IEEE Engineering in Medicine & Biology Society. Piscataway: IEEE, 2021: 3340-3343.
- [23] OZCAN A R, ERTURK S. Seizure prediction in scalp EEG using 3D convolutional neural networks with an image-based approach[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2019, 27(11): 2284-2293.
- [24] CHO K O, JANG H J. Comparison of different input modalities and network structures for deep learning-based seizure detection[J]. *Scientific Reports*, 2020, 10: 122.
- [25] BHANDAGE V, POKURI T, DESAI D, et al. Detection of epilepsy disorder using spectrogram images generated from brain EEG signals[J]. *IEEE Access*, 2024, 12: 195054-195064.
- [26] SHEN M K, YANG F W, WEN P, et al. A real-time epilepsy seizure detection approach based on EEG using short-time Fourier transform and Google-Net convolutional neural network[J]. *Heliyon*, 2024, 10(11): e31827.
- [27] DIŞLI F, GEDIKPINAR M, FIRAT H, et al. Epilepsy diagnosis from EEG signals using continuous wavelet transform-based depthwise convolutional neural network model[J]. *Diagnostics*, 2025, 15(1): 84.
- [28] LIU G Y, ZHOU W D, GENG M X. Automatic seizure detection based on S-transform and deep convolutional neural network[J]. *International Journal of Neural Systems*, 2020, 30(4): 1950024.
- [29] 吕仁杰, 常文文, 闫光辉, 等. 基于GAF和混合模型的运动想象分类研究[J]. *电子科技大学学报*, 2024, 53(6): 952-960.
- LYU R J, CHANG W W, YAN G H, et al. Research on motor imagery classification based on GAF and hybrid model[J]. *Journal of University of Electronic Science and Technology of China*, 2024, 53(6): 952-960. (in Chinese)
- [30] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[EB/OL]. (2023-08-02)[2025-11-20]. <https://arxiv.org/abs/1706.03762>.
- [31] SHARMA R, PACHORI R B. Classification of epileptic seizures in EEG signals based on phase space representation of intrinsic mode functions[J]. *Expert Systems with Applications*, 2015, 42(3): 1106-1117.
- [32] LV R J, CHANG W W, YAN G H, et al. Enhanced classification of motor imagery EEG signals using spatio-temporal representations[J]. *Information Sciences*, 2025, 714: 122221.
- [33] SUN C S, XU C, LI H W, et al. A novel multi-feature fusion attention neural network for the recognition of epileptic EEG signals[J]. *Frontiers in Computational Neuroscience*, 2024, 18: 1393122.
- [34] ZHAO J Q, ZHANG M, ZHOU Z H, et al. CFFormer: A cross-fusion transformer framework for the semantic segmentation of multisource remote sensing images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2025, 63: 4401117.
- [35] LI Y, LIU Y, CUI W G, et al. Epileptic seizure detection in EEG signals using a unified temporal-spectral squeeze-and-excitation network[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2020, 28(4): 782-794.
- [36] IBRAHIM A K, ZHUANG H Q, TOGNOLI E, et al. Epileptic seizure prediction based on multiresolution convo-

lutional neural networks[J]. *Frontiers in Signal Processing*, 2023, 3: 1175305.


[37] SU J Y, HUANG Z T, MA Y H, et al. A model for epilep-

tic EEG detection and recognition based on multi-attention mechanism and spatiotemporal[J]. *Scientific Reports*, 2025, 15: 31993.

#### 作者简介



**常文文** 男,1987年3月生,甘肃通渭人. 2019年于东北大学获得工学博士学位. 瑞士洛桑联邦理工学院神经义肢技术中心访问学者. 现为兰州交通大学副教授、硕士生导师. 主要研究方向为脑-机交互、脑电信号处理和模式识别. 中国电子学会会员编号:E190085440M.  
E-mail: changww2013@126.com



**郭晋成** 男,2002年4月生,甘肃兰州人. 现为兰州交通大学计算机技术专业硕士研究生. 主要研究方向为癫痫脑电研究.  
E-mail: 193942768@126.com



**王亚俊** 女,2002年10月生,河南南阳人. 现为兰州交通大学计算机技术专业硕士研究生. 主要研究方向为癫痫脑电检测与分类识别.  
E-mail: 155837736799@163.com