

结合TCN与自注意力的阿尔茨海默症EEG检测算法

朱辰轩¹, 张登辉², 杨昕立²

(1. 湖州师范学院信息工程学院, 浙江湖州 313000; 2. 浙江树人学院信息科技学院, 浙江杭州 310000)

摘要: 针对脑电图(EEG)在阿尔茨海默病(AD)及额颞叶痴呆(FTD)检测时缺乏有效建模的问题, 提出一种结合改进TCN与自注意力机制的EEG自动检测算法(ETConformer)。通过分层的下采样—卷积—交互架构捕获数据中的复杂非线性关系和局部特征, 并从时间及空间维度进行独立分块编码, 利用两个倒置瓶颈的组卷积建立跨时空依赖关系; 输入嵌入位置编码的自注意力模块, 以充分建模信号中的长距离全局依赖性; 通过对同一受试者的多个片段进行集成决策, 以建立分类一致性。在OpenNeuro数据集上进行跨受试实验的结果表明, 该方法在区分AD、FTD与正常对照受试(NC)时, 准确率分别为91.57%和89.34%, 可有效提高AD及FTD的检测性能。

关键词: 阿尔茨海默病; 脑电图; 卷积神经网络; 自注意力机制; 多片段决策机制

DOI: 10.11907/rjtk.241724

扫描二维码阅读全文:

中图分类号: TP3

文献标识码: A

文章编号: 1672-7800(2025)012-0118-08



EEG Detection Algorithm for Alzheimer's Disease Combining TCN and Self-Attention

ZHU Chenxuan¹, ZHANG Denghui², YANG Xinli²

(1. College of Information Engineering, Huzhou University, Huzhou 313000, China;

2. College of Information Technology, Zhejiang Shuren University, Hangzhou 310000, China)

Abstract: To address the lack of effective modeling in Electroencephalography (EEG) for the detection of Alzheimer's disease (AD) and Frontotemporal Dementia (FTD), we propose an automatic EEG detection algorithm (ETConformer) that combines an improved Temporal Convolutional Network (TCN) and a self-attention mechanism. The algorithm captures complex nonlinear relationships and local features in the data through a hierarchical downsampling-convolution-interaction architecture, with independent block encoding in both temporal and spatial dimensions. Group convolutions with two inverted bottlenecks are utilized to establish cross-temporal and spatial dependencies. The encoded signals are then fed into a self-attention module with positional embedding to fully model long-range global dependencies within the signal. Ensemble decision-making across multiple segments of the same subject is employed to ensure classification consistency. Cross-subject experimental results on the OpenNeuro dataset demonstrate that the proposed method achieves accuracies of 91.57% and 89.34% in distinguishing AD and FTD from normal controls (NC), respectively, effectively improving detection performance for both AD and FTD.

Key Words: Alzheimer's disease; electroencephalography; convolutional neural network; self-attention mechanism; multi-segment decision mechanism

0 引言

阿尔茨海默病(Alzheimer's Disease, AD)是老年痴呆

最常见的原因, 目前尚无治愈方法, 但早期发现和干预可以有效减缓其进展。因此, 迫切需要开发一种低成本、可靠且易于实施的检测手段^[1]。在AD计算机辅助检测领域, 当前研究主要集中于磁共振成像(Magnetic Reso-

收稿日期: 2024-08-19

基金项目: 浙江省自然科学基金项目(LQ21F020025); 浙江省公益技术研究计划项目(LGF21F020024)

作者简介: 朱辰轩(2000-), 男, 湖州师范学院信息工程学院硕士研究生, 研究方向为人工智能与智慧康养; 张登辉(1970-), 男, 博士, 浙江树人学院信息科技学院教授、硕士生导师, 研究方向为人工智能与智慧康养; 杨昕立(1991-), 男, 博士, 浙江树人学院信息科技学院副教授、硕士生导师, 研究方向为人工智能与智慧康养。本文通讯作者: 张登辉。

nance Imaging, MRI)以及正电子发射计算机断层扫描(Positron Emission Computed Tomography, PET)^[2]。尽管这些方法具有较高的检测准确性,但成本高昂且获取困难,通常仅在患者出现显著神经退行性变化后才确诊。脑电图(Electroencephalography, EEG)具有低成本、非侵入性和易于使用等特点,其利用头皮(或颅内)电极测量大脑神经元产生的电突触后电位,并记录大脑皮层的电活动变化^[3]。通过识别EEG活动减慢、EEG复杂性降低以及EEG同步性增加等EEG模式差异来检测AD患者^[4]。因此,EEG可作为检测阿尔茨海默病的生物标志物和有效工具^[5]。

1 相关工作

早期针对AD的EEG检测工作主要应用机器学习算法,并在特征工程方面付出了巨大努力。Sharma等^[6]手动提取8个与AD相关的脑电图特征指标,包括功率谱密度、偏度、峰度、谱偏度、谱峰度、谱波峰因数、谱熵和分形维数,并使用支持向量机(Support Vector Machine, SVM)对提取的特征进行分类。Fiscon等^[7]通过傅里叶变换与小波变换提取受试者脑电图中的频域和时频域特征,并使用决策树分类器对这些特征进行训练,以区分AD患者和健康受试者。Zheng等^[8]应用信号处理和统计方法对静息态脑电图的频谱、复杂度和同步性3类信号特征进行分析。传统机器学习方法在AD检测中取得了一定成效,但这些方法依赖于手工特征提取和选择,可能导致潜在信息丢失。

近期研究尝试应用深度学习算法进行基于EEG的AD检测。与传统的特征提取方法不同,深度学习能够在训练数据驱动下自适应提取高维和层次化的特征表示,自动捕捉传统方法可能遗漏的时频域信息,从而显著提高分类性能。Duan等^[9]利用快速傅里叶变换(Fast Fourier Transform, FFT)算法从脑电信号中提取频谱功率信息,并将其输入到卷积神经网络(Convolutional Neural Networks, CNN),通过CNN提取的频域特征进行学习,从而有效地分类和识别信号中的模式。Rad等^[10]将脑电信号转换为二维灰度图像,并嵌入AD病变特征,通过学习复杂的时频特征和病变信息实现对AD的准确分类与识别。Merlin等^[11]更全面地探讨了深度学习在AD相关EEG信号分析中的应用,其综述了多种深度学习方法及其对应的网络架构,分析的大多数文献都采用CNN或循环神经网络(Recurrent Neural Network, RNN),网络层数在3~10层之间。然而,目前用于AD脑电信号分析的卷积架构在捕捉多通道信号间的跨时空特征方面仍存在一定的局限性。

EEG的复杂性需要模型能够捕获不同电极通道之间的相互作用,这些相互作用反映了大脑不同区域的协同活动。尽管有研究通过空间滤波器实现了对EEG空间信息的捕获,但卷积核的固定大小和感受野的局限性限制了跨时间点的多通道动态相互作用,从而削弱了对跨通道相互

作用的有效表征^[12]。

此外,卷积核大小的限制也导致卷积架构在捕捉信号中的长期依赖关系方面存在局限性。因此,基于自注意力机制的Transformer架构开始应用于脑电图解码,通过自注意力机制在任意两点间建模长程关系,并利用位置编码保留序列信息,同时有效抑制高维数据中的噪声干扰^[13]。Sibilano等^[14]提出基于Transformer架构的框架,用于学习不同频带信号的长程时间依赖关系,并专注于学习最具区分力的信号模式。Miltiadous等^[15]对脑电图信号进行去噪处理后,提取了频带功率和相干性特征,并将这些特征输入到结合CNN和Transformer编码器的DICE网络中,以提取特征间的长期依赖关系。Chen等^[16]利用CNN和Vision Transformer(ViT)组件从脑电图信号中提取全局特征。上述方法通过自注意力机制捕捉EEG信号的全局依赖关系,并使用位置编码表示输入特征的位置信息。然而,自注意力机制在处理顺序信息方面存在局限性,这对EEG信号等顺序数据的有效处理仍是一个挑战。如何显式地整合顺序信息以更好地适应EEG信号的特性,仍需进一步探索和优化。

综上所述,为建模EEG信号不同通道间的跨时空依赖关系,并充分提取信号中的全局特征,以提高检测的准确性,本文提出一种结合改进时间卷积网络(Temporal Convolutional Network, TCN)和自注意力机制的EEG自动检测算法。本文主要贡献如下:

(1)改进卷积结构。通过分层的下采样—卷积聚合EEG多尺度特征,并从时间和空间维度进行独立分块编码,利用两个倒置瓶颈的组卷积模块对EEG通道的跨时空依赖关系进行建模,以捕获跨时空特征。

(2)引入时间绝对位置编码。将时间绝对位置编码嵌入自注意力模块,对信号长程顺序关系进行建模,以捕获全局特征。

(3)提出多片段决策机制。通过对同一受试者的多段脑电图信号进行集成分析,生成一致性的检测结果,减小跨被试场景下分类准确率的个体差异。

2 数据集与预处理

2.1 实验数据

本文在公开OpenNeuro数据集上进行验证,该数据集包含88名受试者的静息状态闭眼脑电图记录^[17]。这些数据由塞萨洛尼基AHEPA综合大学医院第二神经科提供,其中36名受试者被诊断为阿尔茨海默病(AD组),23名受试者被诊断为额颞叶痴呆(FTD组),29名受试者为正常对照组(NC组)。所有参与者均通过国际简易精神状态检查(Minimum Mental State Examination, MMSE)评估其认知和神经心理状态。该数据集由19个头皮电极(Fp1、Fp2、F7、F3、Fz、F4、F8、T3、C3、Cz、C4、T4、T5、P3、Pz、P4、T6、O1和

O2)记录的 EEG 信号组成,并采用两个参比电极,定位基于 10-20 国际系统。数据采集使用 500 Hz 的采样率和 10 μ V/mm 的分辨率,数据采集后进行了噪声和伪影去除等预处理。

为确保对模型性能进行客观、准确的评估,通过随机裁剪对每个受试者的数据进行划分。将单个患者样本生成 1 000 个子样本,保持标签一致,最终得到 88 000 个子样本组成完整数据集。为验证本文方法在不同任务中的适用性和鲁棒性,将数据集划分为 AD-NC 和 FTD-NC 两个子集,以验证方法对多样性的处理能力。数据集统计信息详见表 1。

2.2 数据扩充及增强

当原始数据集较小或类别分布不平衡时,数据扩充与数据增强可以提高深度模型的泛化能力以及对未见数据的预测性能。因此,本文针对 EEG 信号的特性,采用随机裁剪、噪声添加等数据增强方法,具体流程如图 1 所示。




Fig. 1 Data augmentation and enhancement process

图 1 数据扩充与增强流程

3 ETConformer 模型

ETConformer 由下采样—卷积—交互 3 部分组成。首先,将数据处理后的 EEG 输入分层的一维卷积,以聚合多尺度特征。其次,通过 TCN 模块捕获跨时空依赖,并通过

结合时间绝对位置编码的自注意力模块序列化高维特征,建模信号长程关系并提取全局特征。最后,全连接层结合多片段集成决策机制生成类别概率,确保同一受试者多段脑电信号的一致性,从而得出最终的检测结果。整体网络架构见图 2。




Fig. 2 ETConformer module and overall network architecture

图 2 ETConformer 模块及整体网络架构

3.1 改进TCN模块

为建模EEG电极通道间的动态相互作用并捕捉多尺度的非线性关系,本文借鉴了Liu等^[20]以及Lawhern等^[21]的研究思路,并针对AD脑电信号特点设计改进的卷积架构。首先将脑电信号 $X_{in} \in \mathbb{R}^{C \times T}$ 重塑(Reshape)为 $X_{in} \in \mathbb{R}^{C \times 1 \times T}$,然后将 $X_{in} \in \mathbb{R}^{(B \times C) \times 1 \times T}$ 输入到一维卷积块(Conv1d-b1)。其使用数量为 D 、大小为250的卷积核(等于500 Hz采样频率的一半),步长为8,以捕获2 Hz及以上频率的信息,并将一个输入通道映射到 D 个跨时空特征中, $X_{emb} \in \mathbb{R}^{(B \times C) \times D \times N}$ 。

在TCN Block中,首先通过深度可分离卷积(Depth-wise Separable Convolution)将 $(C \times D)$ 输入通道映射到 $(C \times D)$ 输出通道,使每个通道独立进行处理,以提取其时间依赖关系,并使用尺寸为25的大卷积核扩大感受野,并提高时间建模能力。

ConvFFN1和ConvFFN2是基于组卷积思想的ConvFFN的解耦版,ConvFFN1通过组卷积将输入通道划分为若干组,其中Group数为 C ,表示每 D 个时空特征构成一个组,使用扩展和压缩通道数($r=2$)的逐点卷积(Point-wise Conv)构建多通道间关系,以增强特征表示能力。ConvFFN2组卷积的Group数为 D ,表示每 C 个通道构成一个组,同一组中的通道特征相互交互,以构建跨时空依赖关系。单个TCN模块结构如图3所示。通过多个TCN模块应用残差连接与批归一化(Batch Normalization, BN)来提高模型训练的稳定性 and 收敛速度。




Fig. 3 TCN module structure

图3 TCN模块结构

第二个一维卷积块(Conv1d-b2)采用512个大小为25的卷积核,以进一步提取局部时空特征,并通过最大池化(MaxPooling, MP)保留最显著的特征信息。为了减少AT block输出的特征复杂度并保留关键信息,提取的高级序列化特征被传递至第三个一维卷积块(Conv1d-b3)。其中,卷积核数量为256,大小为20。卷积架构中均使用高斯误差线性单元(GELU)激活函数,以实现非线性变换并确保更平滑的决策边界^[22]。

3.2 自注意力模块

传统位置编码在脑电图建模中的局限在于其难以捕捉信号的长距离顺序信息。为此,本文在此基础上进行改进,自注意力模块(AT Block)结构如图2(c)所示。通过引入结合输入嵌入维度和长度的时间绝对位置编码(tAPE),使得输入信号具备距离感知能力,并在各方向上保持一致的特性。

3.2.1 时间绝对位置编码

时间绝对位置编码(tAPE)用于为输入向量 x 添加位置信息,以确保模型在处理序列数据时能够考虑每个元素的位置。具体生成过程如下:

$$\omega_k = 10\,000^{-2k/d_{model}} \quad (1)$$

ω_k 指传统位置编码生成输入向量的正弦和余弦函数频率,而tAPE的 ω_k 可用以下形式表示:

$$\omega_k^{new} = \frac{\omega_k \times d_{model}}{L} \quad (2)$$

其中, d_{model} 表示嵌入维数, L 表示输入序列长度。通过在位置编码中添加输入序列长度 L 以调整位置编码频率,使模型能够灵活适应不同长度的序列,并确保在各个方向(如时间步长或序列位置)上保持一致的影响力或权重,即不偏向任何特定方向或位置。接下来依次使用正弦和余弦进行固定位置编码,并将生成的位置嵌入 $P = (p_1, \dots, p_L)$ 合并到输入向量 x 中,以保留序列的位置信息。计算方式如下:

$$p_i(2k) = \sin i\omega_k^{new} \quad p_i(2k+1) = \cos i\omega_k^{new} \quad (3)$$

$$x_i = x_i + p_i \quad (4)$$

3.2.2 多头自注意力

为了并行关注不同位置编码下的特征关系,使用多头自注意力(Multi-Head Attention, MHA)进一步增强对脑电信号中各时间点复杂依赖关系的全面建模和解析。首先,将带有tAPE的特征序列 $x_i = \{x_1, x_2, \dots, x_L\}$ 线性转换为相等形状的3个副本,称为查询(Q)、键(K)和值(V)。在Q和K上使用点积来评估不同标记之间的相关性。通过一个比例因子来避免梯度的消失,并用Softmax函数得到加权矩阵,即注意力得分。具体计算流程如下:

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right) \cdot V \quad (5)$$

将标记平均分成 p 段,分别输入多头注意力,将多段结果连接作为模块输出。具体计算流程如下:

$$\text{MHA}(Q, K, V) = [\text{head}_0; \dots; \text{head}_{p-1}] \quad (6)$$

$$\text{head}_1 = \text{Attention}(Q_1, K_1, V_1) \quad (7)$$

其中, head_1 表示第一个注意力头, Q_1, K_1, V_1 分别表示使用线性变换得到的查询、键、值。接下来依次是第一个规范化层、前馈神经网络和第二个规范化层,计算方式如下:

$$E' = \text{LayerNorm}(\text{MHA}) \quad (8)$$

$$M' = \text{Gelu}(E'W_1)W_2 \quad (9)$$

$$E'' = \text{LayerNorm}(E' + M') \quad (10)$$

其中, LayerNorm 是层归一化, Gelu 是激活函数, W_1 、 W_2 是前馈全连接层的可训练权重矩阵。

3.3 多片段集成决策

为增强模型的非线性表达能力,更好地捕捉复杂模式并提高泛化性能,模型采用3个全连接层逐步提取特征并降维,将特征向量维度依次从256减少到128,再到64。最后,将降维后的特征映射到与类别数相同的维度,以生成用于决策的分类得分。在训练阶段,模型生成每个子样本的预测结果,用于计算损失值,从而指导模型参数的更新和优化。在测试阶段,模型通过整合单个受试者的多个子样本进行决策,计算每个类别的得分作为置信度,并根据综合置信度来确定最终分类结果。具体过程描述如下:

$$y^i = \text{softmax}\left(\frac{1}{M} \sum_{w=1}^M f_w(x_{t:t+T}^i)\right) y^i \in \mathbb{R}^c \quad (11)$$

其中, x^i 表示受试者的完整脑电图, $x_{t:t+T}^i$ 表示 x^i 中位于 t 起始点长度为 T 的信号片段, f_w 表示模型函数, y^i 表示单个受试者 x^i 的分类检测标签。

3.4 损失函数

为了确保分类任务的概率解释性和计算稳定性,采用交叉熵损失函数(Cross-Entropy Loss),通过 $\log_{\text{softmax}}$ 处理模型输出,分别计算原始样本标签和 Mixup 处理后样本标签的负对数似然损失,并对这两项损失进行加权平均。其中,通过将 Mixup 数据增强与加权损失函数结合使用,有助于抑制过拟合,从而提升模型在未见数据上的表现。具体过程描述如下:

$$\text{loss} = \lambda \cdot \text{loss}_1 + (1 - \lambda) \cdot \text{loss}_2 \quad (12)$$

其中, λ 通过 Beta 分布采样得到。

4 实验与结果分析

4.1 实验环境

本文所有实验都在 Windows10 系统上进行,采用的硬件设备是 Intel Core i7-12700F CPU 和 NVIDIA GeForce RTX 3060 GPU。软件环境采用 Python 3.9,并通过 PyTorch 框架构建深度学习模型。

4.2 评估方法

本文实验均采用跨被试验证策略,并构建被试间的交叉验证集,即训练集和测试集来自不同的受试者。具体步骤如下:首先,逐一剔除单个受试者的脑电样本作为测试集,确保其独立性;其次,从剩余样本中随机选取6个受试者的数据作为验证集;最后,将其余样本用于训练集。此过程对所有受试者逐一重复,以获得加权平均结果并构建混淆矩阵,最终根据混淆矩阵计算模型的各项性能指标。

鉴于医学诊断的复杂性和数据的不平衡情况,主要使用的分类性能指标包括准确率、召回率和特异性。其中,准确率衡量整体分类的正确性,召回率关注漏诊情况,特

异性关注误诊率。此外,验证实验中还评估了精确度(Precision)和 F1-Score,以全面反映结果的准确性及敏感性与精确性的平衡。评价指标和具体计算公式如表2所示。

Table 2 Evaluation metrics and mathematical expressions

表2 评价指标及数学表达式

指标	数学表达式
准确率	$ACC = \frac{TP + TN}{TP + TN + FP + FN}$
召回率	$TPR = \frac{TP}{TP + FN}$
特异性	$TNR = \frac{TN}{FP + TN}$
精确度	$PPV = \frac{TP}{TP + FP}$
F1-score	$F1 = \frac{2 \times PPV \times TPR}{PPV + TPR}$

4.3 参数设置

脑电信号样本记为 $x^i \in \mathbb{R}^{20 \times 4000}$, 其中20表示通道数及嵌入的年龄编码,4000为采样点数,表示8s的子样本。模型训练使用的数据增强参数如下:AWGN为8.05e-8, AWGN_age为2.69e-01, MWGN为7.95e-02, Mixup为0.2。训练过程中的批次大小为32,迭代次数为200,初始学习率为1.9E-05。Dropout设置为0.4,权重衰减(weight decay)设置为0.0471,采用Transformer风格的学习率衰减策略,并使用适应性矩估计优化器(Adaptive Moment Estimation, Adam)作为本文的优化器^[23]。在测试阶段,每个受试者的决策基于8个子样本($M=8$)。

4.4 模型收敛性分析

在模型收敛性分析中,通过监测训练过程中损失函数和准确率的变化趋势,评估模型在训练阶段的收敛速度和稳定性。第一轮交叉验证中的损失曲线和准确率趋势见图4、图5。损失函数在初期迅速下降,准确率迅速上升,表明模型能够有效学习并拟合训练数据。随着迭代次数的增加,损失函数趋于平稳,准确率保持在高水平,显示模




Fig. 4 Accuracy and loss values on the AD-NC dataset

图4 AD-NC数据集下的准确率和损失值

型已收敛并找到了较优的参数配置。




Fig. 5 Accuracy and loss values on the FTD-NC dataset
图 5 FTD-NC 数据集下的准确率和损失值

4.5 结果分析

4.5.1 跨被试验证结果分析

本文方法在两个跨被试任务下生成的混淆矩阵和类别度量如图 6 所示。在混淆矩阵中,每列表示预测为该类别的样本数,每行表示实际属于该类别的样本数。每位受试者的 1 000 个样本被分为 125 组,每组 8 个样本进行综合决策生成一个预测标签。根据留一交叉验证策略,对所有受试者重复此过程,最终生成平均混淆矩阵,各性能指标保留两位小数。结果表明,模型在 AD-NC 中表现出色,准确率为 0.92,召回率和 F1 得分分别为 0.94 和 0.92,表明模型能够有效区分 AD 和正常对照。对于 FTD-NC,特异性和召回率分别为 0.91 和 0.87,说明对健康受试者的预测准确,但在识别 FTD 患者时存在挑战。总体来看,模型在不同任务中展示了良好的分类能力和稳定性。

4.5.2 消融实验

为验证各模块对模型性能的贡献,使用基准数据集在




Fig. 6 Confusion matrix and class metrics for cross-subject experimental results
图 6 跨被试实验结果的混淆矩阵及类别度量

跨被试实验中进行消融实验。通过对比实验结果,评估各模块对整体模型性能的影响,结果见表 3、表 4。其中,CI 代表包含了 TCN 模块的卷积部分,C 代表删去了 TCN 模块的卷积部分,AT 代表自注意力模块,MST 代表使用了多片段集成决策模块。结果表明,本文提出的 ETConformer (CI+AT+MST)性能最佳,且在 AD-NC 数据集上 EEG 的检测 AUC 能够达到 0.915 7,而在 FTD/NC 数据集上能够达到 0.893 4。其中,任务(a)为在 AD-NC 数据集上区分阿尔茨海默病(AD)患者与健康对照(NC)的检测任务,任务(b)为在 FTD/NC 数据集上区分别额叶痴呆(FTD)患者与健康对照(NC)的检测任务。其中,任务(a)的准确率降低了 1.22%($p<0.01$),任务(b)的准确率降低了 1.85%,表明 TCN 模块能够增强模型捕获不同电极间空间关系特征的能力。当删除自注意力模块(CI+MST)后,两个任务的 EEG 检测准确率分别降低了 1.11% 和 1.69%,表明嵌入 tAPE 可以有效建模脑电图长信号的位置关系,增强模型对长距离特征的提取能力。不使用多片段集成决策模块(CI+AT)时,两个任务的 EEG 检测准确率分别下降了 1.85% 和 2.67%,表明该方法能综合分析多时间点信息,减少单一片段决策的误差和噪声。综上,本文所提出的 3 个改进项均能提升 AD 检测性能,进一步验证了本文模型的有效性及其对脑电图信号分析的重要性。

Table 3 Ablation study results on the AD-NC dataset
表 3 AD-NC 数据集消融实验结果

模型	评价指标		
	准确率	召回率	特异性
C+AT+MST	0.903 5	0.922 8	0.888 0
CI+MST	0.904 6	0.930 8	0.883 6
CI+AT	0.897 2	0.922 5	0.876 9
CI+AT+MST	0.915 7	0.936 3	0.899 1

Table 4 Ablation study results on the FTD-NC dataset
表 4 FTD-NC 数据集消融实验结果

模型	评价指标		
	准确率	召回率	特异性
C+AT+MST	0.874 9	0.900 4	0.842 8
CI+MST	0.876 5	0.897 7	0.849 7
CI+AT	0.866 7	0.886 6	0.843 3
CI+AT+MST	0.893 4	0.914 2	0.867 1

4.5.3 对比实验

为验证模型在跨被试 EEG 检测中的有效性,本文在 AD-NC 数据集上进行验证,并选择 5 种先进的脑电图信号分类深度学习架构在相同的实验设置下进行对比实验,结果见表 5。对比模型分别为 DeepConvNet^[25]、EEGNet^[24]、EEG-ConvTransformer^[26]、DICE-Net^[15]以及 EEG Conformer^[12]。可以看出,本文方法在所有对比模型中取得了最佳性能,准确率相比最佳模型的结果提升了 3.01%,召回率与特异性分别提高了 2.60% 和 2.22%。实验结果表明,本文方法能够更有效地捕捉 AD EEG 的判别特征,并在跨被试场景中表现出优异性能。主要原因为该模型增强了 EEG

空间关系特征的表达能力,提高了特征在通道和时间维度上的区分度,同时在不同被试间表现出更强的鲁棒性和一致性。

Table 5 Model comparison experimental results for the AD-NC task

表 5 AD-NC 任务的模型对比实验结果

模型	评价指标		
	准确率	召回率	特异性
EEGNet	0.818 9	0.885 6	0.729 3
DeepConvNet	0.829 5	0.853 5	0.810 2
EEG-ConvTransformer	0.881 7	0.887 7	0.876 9
DICE-Net	0.866 5	0.881 1	0.854 7
EEG Conformer	0.885 6	0.910 3	0.860 3
本文方法	0.915 7	0.936 3	0.899 1

此外,将本文方法与基于 OpenNeuro 数据集的多个相关研究进行比较,验证了其在 AD EEG 检测中的优越性,详见表 6(未包含的数据用“-”表示)。结果表明,本文方法在 AD-NC 与 FTD-NC 任务中的准确率分别为 91.56% 和 89.34%,相比之前的研究,其在 AD、FTD 和 NC 分类任务中的效果获得了显著提升。这是由于其不仅充分利用了 EEG 的空间分布特征,而且通过改进自注意力机制更有效地提取了 AD EEG 的全局信息。

Table 6 Comparison of accuracy rates among different detection methods

表 6 不同方法检测结果准确率比较

(%)

方法	模型	AD-NC	FTD-NC
Miltiadous ^[15]	CNN+ Transformer	84.97	74.96
Chen ^[16]	CNN+ VIT	88.19	83.41
Parihar ^[27]	Random Forest	88.90	84.10
Tzamourta ^[28]	Random Forest	-	86.3
本文方法	TCN+Transformer	91.56	89.34

4.6 电极通道可视化

为了探究多通道电极及不同大脑区域对分类的重要性,本文提取了模型在 19 个电极通道的平均权重,并映射到大脑地形图上。图 7 展示了任务 AD-NC(上)和 FTD-NC(下)中权重的可视化地形图,从图中的结果分析可得,对于 AD 患者,该模型主要关注颞叶(Fp1 和 Fp2 电极)、顶叶(P3、Pz 和 P4 电极)和枕叶(O1 和 O2 电极)等脑区,结果与 AD 疾病的临床研究一致^[29]。对于 FTD 患者,该模型在中央区域(C3、Cz 和 C4 电极)、左颞叶(T3 电极)和额叶(Fp1、Fp2、F7 和 F8 电极)显示出更高的敏感性。实验结果与 FTD 疾病相关的临床神经学发现一致^[30]。总体而言,模型的电极权重映射代表其对 AD、FTD 和 NC 条件下特定大脑区域的关注,电极权重的可视化进一步深化了对整个分类过程的理解,并凸显其检测和风险评估中的关键特征。

5 结语

针对脑电图在 AD 与 FTD 检测任务中所面临的多通道时空相关性与时空依赖建模的挑战,本文提出一种改进的 EEG 自动检测方法(ETConformer)。该方法采用下采样




Fig. 7 Electrode channel visualization results

图 7 电极通道可视化结果

—卷积—交互架构,通过分层的一维卷积有效聚合 EEG 多尺度特征。TCN 模块用于捕捉信号间的时空依赖特征,结合自注意力机制进一步提取信号的全局依赖关系。通过对同一受试者的多个片段进行集成决策,显著提升了分类的一致性和可靠性。该方法有效提高了 AD 和 FTD 的检测性能,并在 OpenNeuro 数据集上通过对比实验和消融实验得到了充分验证。进一步的脑电地形图可视化分析揭示了不同脑区电极在检测中的关键作用。后续研究可针对 AD 患者的个体特征,降低跨被试场景下的个体差异,以进一步提升 EEG 的检测性能。

参考文献:

- [1] FARINA F R, EMEK-SAVAŞ D D, RUEDA-DELGADO L, et al. A comparison of resting state EEG and structural MRI for classifying Alzheimer's disease and mild cognitive impairment[J]. Neuroimage, 2020, 215: 116795.
- [2] EBRAHIMIGHAHAVIEH M A, LUO S, CHIONG R. Deep learning to detect Alzheimer's disease from neuroimaging: a systematic literature review[J]. Computer Methods and Programs in Biomedicine, 2020, 187: 105242.
- [3] COHEN M X. Where does EEG come from and what does it mean?[J]. Trends in Neurosciences, 2017, 40(4): 208-218.
- [4] LIZIO R, VECCHIO F, FRISONI G B, et al. Electroencephalographic rhythms in Alzheimer's disease[EB/OL]. <https://pmc.ncbi.nlm.nih.gov/articles/PMC3100729/>.
- [5] MUSAEUS C S, ENGEDAL K, HØGH P, et al. EEG theta power is an early marker of cognitive decline in dementia due to Alzheimer's disease[J]. Journal of Alzheimer's Disease, 2018, 64(4): 1359-1371.
- [6] SHARMA N, KOLEKAR M H, JHA K, et al. EEG and cognitive biomarkers based mild cognitive impairment diagnosis[J]. IRBM, 2019, 40(2): 113-121.
- [7] FISCON G, WEITSCHKE E, COLA M C D, et al. An integrated approach based on EEG signals processing combined with supervised methods to classify Alzheimer's disease patients[C]//Proceedings of 2018 IEEE Inter-

- national Conference on Bioinformatics and Biomedicine, 2018: 2750–2752.
- [8] ZHENG X, WANG B, LIU H, et al. Diagnosis of Alzheimer's disease via resting-state EEG: integration of spectrum, complexity, and synchronization signal features [J]. *Frontiers in Aging Neuroscience*, 2023, 15: 1288295.
- [9] DUAN F, HUANG Z, SUN Z, et al. Topological network analysis of early Alzheimer's disease based on resting-state EEG [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2020, 28(10): 2164–2172.
- [10] RAD E M, AZARNOOSH M, GHOSHUNI M, et al. Diagnosis of mild Alzheimer's disease by EEG and ERP signals using linear and nonlinear classifiers [J]. *Biomedical Signal Processing and Control*, 2021, 70: 103049.
- [11] MERLIN P D, ANGELIN S D, THOMAS G S. Deep learning techniques for EEG signal applications—a review [J]. *IETE Journal of Research*, 2022, 68(4): 3030–3037.
- [12] SONG Y, ZHENG Q, LIU B, et al. EEG conformer: convolutional transformer for EEG decoding and visualization [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2022, 31: 710–719.
- [13] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C]//*Proceedings of the 31st International Conference on Neural Information Processing Systems*, 2017: 6000–6010.
- [14] SIBILANO E, BRUNETTI A, BUONGIORNO D, et al. An attention-based deep learning approach for the classification of subjective cognitive decline and mild cognitive impairment using resting-state EEG [J]. *Journal of Neural Engineering*, 2023, 20(1): 016048.
- [15] MILTIADOUS A, GIONANIDIS E, TZIMOURTA K D, et al. DICE-net: a novel convolution-transformer architecture for Alzheimer detection in EEG signals [J]. *IEEE Access*, 2023, 11: 71840–71858.
- [16] CHEN Y, WANG H, ZHANG D, et al. Multi-feature fusion learning for Alzheimer's disease prediction using EEG signals in resting state [J]. *Frontiers in Neuroscience*, 2023, 17: 1272834.
- [17] MILTIADOUS A, TZIMOURTA K D, AFRANTOU T, et al. A dataset of scalp EEG recordings of Alzheimer's disease, frontotemporal dementia and healthy subjects from routine EEG [J]. *Data*, 2023, 8(6): 95.
- [18] LIVINGSTON G, HUNTLEY J, SOMMERLAD A, et al. Dementia prevention, intervention, and care: 2020 report of the Lancet Commission [J]. *The Lancet*, 2020, 396: 413–446.
- [19] ZHANG H, CISSE M, DAUPHIN Y N, et al. Mixup: beyond empirical risk minimization [DB/OL]. <https://arxiv.org/abs/1710.09412>.
- [20] LIU M, ZENG A, CHEN M, et al. SCINet: time series modeling and forecasting with sample convolution and interaction [J]. *Advances in Neural Information Processing Systems*, 2022, 35: 5816–5828.
- [21] LAWHERN V J, SOLON A J, WAYTOWICH N R, et al. EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces [J]. *Journal of Neural Engineering*, 2018, 15(5): 056013.
- [22] HENDRYCKS D, GIMPEL K. Gaussian error linear units (gelus) [DB/OL]. <https://arxiv.org/abs/1606.08415>.
- [23] KINGMA D P, BA J. Adam: a method for stochastic optimization [DB/OL]. <https://arxiv.org/abs/1412.6980>.
- [24] LAWHERN V J, SOLON A J, WAYTOWICH N R, et al. EEGNet: a compact convolutional neural network for EEG-based brain-computer interfaces [J]. *Journal of Neural Engineering*, 2018, 15(5): 056013.
- [25] SCHIRRMESTER R T, SPRINGENBERG J T, FIEDERER L D J, et al. Deep learning with convolutional neural networks for EEG decoding and visualization [J]. *Human Brain Mapping*, 2017, 38(11): 5391–5420.
- [26] BAGCHI S, BATHULA D R. EEG-ConvTransformer for single-trial EEG-based visual stimulus classification [J]. *Pattern Recognition*, 2022, 129: 108757.
- [27] PARIHAR A, SWAMI P D. Analysis of EEG signals with the use of wavelet transform for accurate classification of Alzheimer disease, frontotemporal dementia and healthy subjects using machine learning models [J]. *Full Length Article*, 2024, 14(2): 43–55.
- [28] MILTIADOUS A, TZIMOURTA K D, GIANNAKIS N, et al. Alzheimer's disease and frontotemporal dementia: a robust classification method of EEG signals and a comparison of validation methods [J]. *Diagnostics*, 2021, 11(8): 1437.
- [29] DU A T, SCHUFF N, AMEND D, et al. Magnetic resonance imaging of the entorhinal cortex and hippocampus in mild cognitive impairment and Alzheimer's disease [J]. *Journal of Neurology, Neurosurgery & Psychiatry*, 2001, 71(4): 441–447.
- [30] RABINOVICI G D, MILLER B L. Frontotemporal lobar de-generation: epidemiology, pathophysiology, diagnosis and management [J]. *CNS Drugs*, 2010, 24: 375–398.

(责任编辑:黄健)