

基于脑电与图卷积的阿尔茨海默病分类研究

王鑫炜^{1,2}, 李 斌³, 李晓欧², 尹 钟¹

- (1. 上海理工大学 光电信息与计算机工程学院, 上海 200093;
2. 上海健康医学院 医疗器械学院, 上海 201318;
3. 杨浦区精神卫生中心, 上海 200090)

摘 要: 基于脑电信号(EEG)的阿尔茨海默病(AD)分类研究始终都是脑机接口领域的关注对象,图卷积(GCN)等神经网络已被广泛应用于该领域。然而,浅层GCN只能提取到局部特征,而深层GCN面临着数据丢失的风险。为此,提出一种改进的图卷积模块提取多个GCN层的节点特征,并设置可学习的参数对其进行动态调整与融合,以增强模型在分类任务中的性能。同时,为了解决直接利用完整的邻接矩阵进行分类引入的多余噪声和计算量,对邻接矩阵进行二值化以筛选具有高相关性的通道。在杨浦区精神卫生中心提供的数据集上的实验表明,该模型能挖掘GCN各层节点特征之间的潜在关系,简化了信号间复杂的构建过程,释放了计算资源,在阈值为0.3~0.5时具有较好的性能,精度相较于原GCN网络提升了5.3%。

关键词: 脑机接口;阿尔茨海默病;静息态脑电;图卷积;加权融合

DOI: 10.11907/rjdk.251121

扫描二维码阅读全文:



中图分类号: TP181

文献标识码: A

文章编号: 1672-7800(2026)005-0088-07

Classification Research on Alzheimer's Disease Based on Electroencephalograph and Graph Convolution

WANG Xinwei^{1,2}, LI Bin³, LI Xiaou², YIN Zhong¹

- (1. School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China;
2. Shanghai Yangpu District Mental Health Center, Shanghai 201318, China;
3. Mental Health Center of Yangpu District, Shanghai 200090, China)

Abstract: The classification of Alzheimer's disease (AD) based on electroencephalogram (EEG) signals has always been a focus of attention in the field of brain computer interfaces, and neural networks such as graph convolution (GCN) have been widely applied in this field. However, shallow GCN can only extract local features, while deep GCN faces the risk of data loss. To this end, an improved graph convolution module is proposed to extract node features from multiple GCN layers and dynamically adjust and fuse them with learnable parameters to enhance the performance of the model in classification tasks. At the same time, in order to address the excess noise and computational complexity introduced by directly using the complete adjacency matrix for classification, the adjacency matrix is binarized to screen channels with high correlation. Experiments on the dataset provided by the Yangpu District Mental Health Center showed that the model can explore the potential relationships between the features of GCN nodes at different layers, simplify the complex construction process between signals, and free up computing resources. It has good performance at a threshold of 0.3~0.5, with an accuracy improvement of 5.3% compared to the original GCN network.

Key Words: brain-computer interface; Alzheimer's disease; resting-state EEG; graph convolution; weighted fusion

收稿日期: 2025-04-15

基金项目: 上海健康医学院精神卫生研究院项目(YJYPI202402); 上海市杨浦区科学技术委员会、卫生健康委员会科研项目(YPM202114)

作者简介: 王鑫炜(1999-), 男, 上海理工大学光电信息与计算机工程学院硕士研究生, 研究方向为深度学习、医学信号处理; 李晓欧(1975-), 男, 博士, 上海健康医学院医疗器械学院教授, 研究方向为生物医学信号处理; 尹钟(1988-), 男, 博士, 上海理工大学光电信息与计算机工程学院副教授, 研究方向为认知工作负荷识别、生物医学信号处理、情感识别。

0 引言

阿尔茨海默病(Alzheimer's disease, AD)是一种起病隐匿的进行性发展的神经退行性疾病,随着病程发展会逐渐损害患者的认知功能,最终导致智力衰退及神经认知功能的中断。在世界范围内,60%~80%的痴呆症由阿尔茨海默病引发^[1]。目前,阿尔茨海默病没有有效的治愈方法,且由于其复杂的病理特征,病因及特效药物的研发仍未取得显著突破,一旦发病只能持续不间断地进行治疗,不仅给患者带来了沉重的心理负担,还对社会经济造成了巨大压力。预计到2030年,中国AD患者的总经济负担将达到17万亿元^[2]。

AD患者若得不到及时治疗,可能会对患者健康甚至生命产生很大的危害。临床研究显示,在健康老年人和AD患者之间,可观察到一个被称为轻度认知障碍(Mild Cognitive Impairment, MCI)的过渡阶段,临床上多以认知功能和记忆力的减退为特征,但该阶段并不会影响患者的日常生活。处于MCI阶段的老年人,进展为痴呆的风险是正常中老年人的10倍,因此在MCI阶段进行人为干预可有效避免病情进一步发展^[3]。

从临床角度而言,由于AD与MCI的临床症状容易与正常衰老过程相混淆,准确诊断阿尔茨海默病与轻度认知障碍患者,一直是一个具有挑战性的问题。部分AD患者的病理变化可能持续长达20年之久,早期阶段易被误诊,从而会延误治疗时机^[4]。因此,如何找到有效的早期诊断方法便显得尤为重要。

1 相关工作

脑电信号(Electroencephalogram, EEG)是一种非侵入性技术,可记录来自颅骨表面的信号,最早由Hans Berger将其应用于AD患者,并且观察到病理特征具有低成本、高时间分辨率等特点,相较于临床最常见的问诊和神经心理测验方法,能提供非常客观的生理信号辅助诊断,可在极大程度上避免不必要的误诊^[5]。有临床经验的医生可通过患者的EEG或神经测验诊断出病情,但EEG的细小波动通常难以察觉,因此借助计算机技术来挖掘有效的信息便显得愈发重要。

目前,静息态EEG已在AD诊断模型中应用广泛。研究表明,AD患者的静息态脑电信号表现出节律减慢和大脑不同区域之间连贯性降低等特征,大多数患者的慢波活动增加且脑区间的连接性出现异常。具体而言,AD患者在 δ (0.5~4 Hz)、 θ (4~8 Hz)频段表现出不同的节律特征,在 α (8~13 Hz)、 β (13~30 Hz)频段中节律下降明显^[6];MCI患者的 α 、 δ 和 θ 频段的峰值频率、功率和相关性均出现异常,其脑电特征与病理变化密切相关,主要表现为在 α 频段上

活动减少,在 θ 、 δ 频段上活动增加^[7]。

皮尔逊相关系数(Pearson Correlation Coefficient, PCC)被广泛用于测量两个目标之间的线性相关性,在以前研究中已被广泛用于构建功能性脑网络。然而,阿尔茨海默症的早期诊断涉及复杂的脑功能网络,不仅是线性关系,还有许多非线性的脑区互动。此时,PCC将难以克服复杂的非线性动态干扰。为了弥补这一缺陷,研究人员将PCC与其他特征相结合^[8,9]。例如,Tian等^[10]将最大信息系数(Maximum Information Coefficient, MIC)作为互补方法来构建静息态脑电连接组,用于捕捉成对脑区之间连接的不同之处。Li等^[6]提取原始脑电信号与VAE模型预测数据之间PCC,以量化VAE模型的可靠程度。

随着深度学习(Deep Learning, DL)在计算机视觉和语言识别领域的发展,许多研究开始将深度学习算法融入脑电信号处理过程中,使计算机具备了自动从数据中学习判别特征的能力,证明了深度学习拥有不逊于传统机器学习的性能^[11]。然而,EEG是非欧几里得结构的数据,卷积等传统DL方法很容易忽略大脑中存在的功能连接。

随着图卷积神经网络(Graph Convolutional Network, GCN)的发展,利用GCN处理非欧几里得结构化数据是较为合适的选择^[12]。然而,单一图卷积层通常只能聚合当前节点与相邻节点的特征,浅层GCN往往只能提取局部性的特征,需要堆叠深层网络以捕捉全局信息。随着GCN层数增加,节点表示会越来越相似,信息会在多层传递过程中存在过度平滑现象,使节点特征趋于相似,导致信息在传输过程中丢失。为了解决该问题,Pei等^[13]基于残差网络结构提出ResGCN模型,但模型结构也因残差结构而变得更复杂,可能会阻碍模型正确捕捉远距离节点之间的关系。

本文提出一种改进的图卷积模块提取多个GCN层的节点特征,并设置可学习的参数对其进行动态调整与融合,以增强模型在分类任务中的性能。研究内容可分为3点:①采集了新的静息态脑电数据集,可用于三分类研究;②提取了GCN中各层的节点特征并进行加权融合,缓解了深层网络信息丢失的问题,强化了全局与局部特征之间的联系,防止模型过于复杂;③对邻接矩阵进行二值化操作,通过简单方法完成通道选择。

2 数据采集与预处理

2.1 数据采集

受各方因素影响,阿尔茨海默病的公开数据集十分稀缺,因此本文实验的数据集为自采集数据集,由上海市杨浦区精神卫生中心牵头采集,用于阿尔茨海默病的三分类研究。目前,数据集包含40名受试者(14名AD患者、13名MCI受试者与13名正常对照者(Normal Control, NC)),被试平均年龄为73.3岁,男女比例为13:27,招募的NC和

MCI 受试者大部分来自上海本地社区,AD 患者大部分来自精卫中心的门诊部和住院部。完整的临床试验设计可查看文献[14],所有参与者都提供了书面知情同意书,所有实验数据都是在医生协助下,使用 Neuroscan 系统所采集。

Neuroscan-NuAmps 放大器是一款小巧轻便的 40 导联 DC 放大器,实验中将会使用其中的 32 个电极来记录信号,电极位置符合国际 10-20 系统标准(见图 1),电极包括 30 个头皮电极通道和 2 个乳突通道,采样率默认为 1 000 Hz。实验阶段,提前告知受试者调整舒适坐姿,在静坐、闭眼,在放松、清醒且无情绪波动的状态下记录脑电信号,每个被试采集两组信号,每组时长需在 6 min 以上,两组间隔 1~2 min。采集后,离线手动审查 EEG 轨迹,标记被伪影破坏的片段并丢弃。




Fig. 1 Distribution of electrodes on the scalp in the electroencephalogram acquisition system

图 1 脑电图采集系统电极在头皮上的分布情况

2.2 数据预处理与环境配置

本文使用开源 Matlab 工具箱 EEGLAB,对 1~45 Hz 之间 30 个电极通道 EEG 数据进行带通滤波,并将其降采样至 500 Hz^[15]。首先,剔除无用通道,手动审查 EEG 轨迹,采用 Spherical 法插值明显异常的通道,剔除质量太差的数据段;其次,将全脑数据的均值作为参考电极;最后,进行独立成分分析(Independent Component Analysis, ICA),利用 ICLABEL 工具箱标记并排除非脑源的成分,以进一步清除伪影。

预处理后的数据被分割为 M 个持续时间为 2 s 的非重叠时段,每个时段包含 $N=1\,000$ 个采样点。对于每个受试者,预处理后的数据被存储为通道数 $C \times$ 采样点 N 的形状。预处理完成后,将两组信号进行拼接,使用前 10 min 的信号进行实验任务。若某一名被试的可用信号长度达不到 10 min,则适当提取该被试前期符合条件的时段,以 5 个时

段为一组求取均值,作为新时段填充进该被试的信号中。

本文模型基于 PyTorch 1.12.1 进行搭建,所有训练、测试任务均利用 KAGGLE 公开服务器的 P100 GPU 完成。实验中,由于每名被试只包含有一个分类标签,且静息态数据的变化程度较低。因此,先将所有被试分段随机打乱,再将其分为训练、测试集进行十折交叉验证。该策略可视为对每个被试的每个分段进行分类,可在保证样本数量的同时,适当减小脑电信号的强个体差异对分类结果的影响。超参数设置在所有数据库中均一致,详细信息如表 1 所示。

Table 1 Hyperparameter settings

表 1 超参数设置

超参数	设置值
批量大小	128
随机种子	42
学习率	0.001
训练轮次	100

3 研究方法

3.1 模型框架

图 2 为本文模型架构。首先,对 EEG 进行预处理与特征提取,获得 PSD 特征 F_{PSD} 、PCC 矩阵 P ;其次,对 P 中的元素依次进行绝对值化和二值化操作,获得二值化 PCC 矩阵 P_b ;再次,以通道为节点,将 F_{PSD} 、 P_b 分别作为节点特征和边,以构造图结构并导入图卷积模块;接下来,获取每个图卷积层输出的节点特征,使用线性层将其变换至相同形状,并在各层设置可学习的参数来动态调整特征之间的关系,以增强特征表达能力;最后,利用多层感知机(Multilayer Perceptron, MLP)和全局池化层(Global Average Pooling, GAP)处理拼接好的特征,通过 Softmax 返回标签预测概率,取最大概率的标签作为分类结果。

3.2 特征提取

(1) 标准化。在提取所有特征前,将每个分段的采样点集合 $S=\{s_1, s_2, \dots, s_{1000}\}$ 的实际观测值重新缩放到 $[-1, 1]$ 区间内。

$$\tilde{s}_i = \frac{(s_i - \max(S)) + (s_i - \min(S))}{\max(S) - \min(S)} \quad (1)$$

式中: $\tilde{s}_i$ 表示标准化后的结果,区间为 $[-1, 1]$; s_i 为该分段中的第 i 个采样点,且 $1 \leq i \leq 1\,000$ 。

(2) PSD 特征提取。首先,通过 Welch 方法将输入信号进一步分成 K 个重叠段,每一段默认包含 $N_s=256$ 个采样点^[16];其次,通过汉明窗平滑每段信号;再次,利用傅里叶变换计算每段信号的 PSD 值;最后,将各段信号的计算结果进行平均,以获得输入信号的最终 PSD 值。实验表明,该方法能有效减少噪声影响,从而获得更平滑、稳定的特征。




Fig. 2 Main model architecture

图 2 主模块架构

$$PSD[m] = \frac{1}{K} \sum_{k=1}^K \frac{1}{N_s} |FFT(x(k)\omega(k))|^2 \quad (2)$$

式中: m 代表第 m 个非重叠分段,取值范围为 $1 \sim M$ 的任意整数; $x(k)$ 代表该分段中第 k 子段的序列信号; K 指该分段中子段的总数; $\omega(k)$ 为窗函数; $PSD[m]$ 为第 m 个分段整个频谱的PSD值。

全脑的特征为对每个被试的每个分段内所有通道的特征进行平均,分布情况如图3所示。在不同频段中,尤其在 θ 、 α 频段中,AD患者与NC组之间的PSD特征存在显著差异,说明该数据集可使用PSD特征进行分类。本文为了增加特征量以提升深度学习模型的性能,将PSD特征细分为44个维度,即从长度为1 Hz的频段中获取特征,组成集合 F_{PSD} 。




Fig. 3 Distribution of average PSD features in the whole brain

图 3 全脑平均PSD特征分布情况

(3)PCC矩阵提取。PCC是两个变量之间协方差的标准化的度量。首先,提取EEG不同通道之间的度量;其次,将其转化成邻接矩阵;最后,将两个变量的协方差除以其标

准差的乘积得到PCC矩阵^[17]。

$$PCC_{chi, chj} = \frac{cov(chi, chj)}{std_i std_j} \quad (3)$$

式中: chi 、 chj 代表第 i 、 j 个通道的信号序列; $cov(\cdot)$ 为计算通道之间的协方差; std 表示序列 i 、 j 的标准差。

本文为了保留节点之间的关系信息,并让数据处理更简单,对邻接矩阵进行了二值化。在二值化邻接矩阵的过程中,节点之间的连接关系将以阈值 $t \in [0, 1]$ 为界,大于等于 t 的元素被设置为存在(设置为1),小于 t 的元素被设置为不存在(设置为0),以提升分类任务的计算效率,如图4所示(三类标签各自第一个被试的绝对PCC矩阵和二值化邻接矩阵(阈值设置为0.3))。由此可见,AD被试通道间的相关性显著弱于其他两个标签。

3.3 图卷积模块与加权拼接

GCN主要用于聚合相邻节点的信息并更新图中的节点表示。本文将无向加权图定义为 $G = \{V, E, A\}$, V 表示节点集合, E 表示连接节点的边的集合;将 $A \in \mathbb{R}^{C \times C}$ 定义为邻接矩阵;将每个通道及其PSD特征作为图中的节点;将 P_b 设置为边及边的权重。图卷积规则为:

$$X^{(l+1)} = \sigma((\hat{D}^{-1/2} \hat{A} \hat{D}^{-1/2}) X^{(l)} W^{(l)}) \quad (4)$$


式中: $X^{(l)} \in \mathbb{R}^{(C \times D_{in})}$ 代表第 l 层的特征矩阵; $\sigma(\cdot)$ 为非线性激活函数; D 表示度矩阵; $W^{(l)}$ 为可训练权重矩阵。

实验中GCN块应用了 $L=5$ 个图卷积层,输出特征维数分别为64、64、32、16、16,每个GCN层后都衔接层归一化操作。为了便于后续操作,将各层的特征矩阵调整至统一形状并拼接。

$$F^{(l)} = \delta(W_{(l)}(X^{(l)})) \quad (5)$$


$$F = \text{Concat}(w_1 F^{(1)}, w_2 F^{(2)}, \dots, w_L F^{(L)}) \quad (6)$$

式中: F^l 表示调整形状之后的特征矩阵; δ 表示ELU激



(a) Absolute PCC matrix of EEG for subject 1 of each label

(a) 各标签被试1的绝对PCC矩阵



(b) Binarized matrix of EEG for subject 1 of each label

(b) 各标签被试1的二值化邻接矩阵

Fig. 4 Different feature graph matrices of different labels**图4 不同标签的不同特征图矩阵**

活函数; $\mathbf{W}_{(i)} \in \mathbf{R}^{(C \times D_{(i)}) / (C \times D_{(i)/r})}$ 为全连接层的权重矩阵; w_{ii} 表示第 i 层的权重参数。

3.4 后端模块

本文模型的最后部分由 MLP 与 GAP 组成, 以在融合特征的基础上学习到更复杂的特征表示。因此, 模型最终的输出特征 Z 为:

$$Z = \text{GAP}(\text{MLP}(F)) \quad (7)$$

在多元分类任务中, 交叉熵损失函数是一种常见的评估工具, 可量化模型预测的概率分布与实际标签分布之间的一致性。

$$\begin{aligned} \text{Loss} &= -\frac{1}{B} \sum_{b=1}^B \log(P_{b, y_b}) \\ &= -\frac{1}{B} \sum_{b=1}^B \log\left(\frac{\exp(z_{by_b})}{\sum_{j=1}^{y_b} \exp(z_{bj})}\right) \end{aligned} \quad (8)$$

式中: B 为样本个数; y_b 表示第 b 个样本的真实标签; 样本 b 对真实标签的预测概率为 P_{b, y_b} ; 训练过程中优化器为 ADAMW, 设置有早停机制, 最大允许无提升轮数为 12。

4 实验结果与分析

4.1 消融实验

本文模型包含 GCN 模块、加权融合模块和 MLP, 设计消融实验来验证该模块能否有效提升模型的性能, 部分实验结果如表 2、图 5 所示。实验中统一使用精度 ACC、F1 分数作为评价指标。其中, 精度用于衡量样本整体的分类准确率; 宏 F1 分数能更好地平衡各类别性能, 是对精确率 (Precision) 和召回率 (Recall) 指标的一种改进。

$$\text{ACC} = \frac{\sum_{la=1}^{LA} TP_{la}}{\sum_{la=1}^{LA} (TP_{la} + FN_{la})} \quad (9)$$

$$\text{Micro_F1} = \frac{1}{LA} \sum_{la=1}^{LA} F1_{la} \quad (10)$$

$$F1_{la} = 2 \times \frac{\text{Precision}_{la} \times \text{Recall}_{la}}{\text{Precision}_{la} + \text{Recall}_{la}} \quad (11)$$

$$\text{Precision}_{la} = \frac{TP_{la}}{TP_{la} + FP_{la}} \quad (12)$$

$$\text{Recall}_{la} = \frac{TP_{la}}{TP_{la} + FN_{la}} \quad (13)$$

式中: ACC 表示整体精度; LA 表示类别总数; TP_{la} 、 FN_{la} 分别表示第 la 类样本中被正确分类的数量和被错误分类的数量; Precision_{la} 、 Recall_{la} 分别表示第 la 类别的精确率和召回率。

Table 2 Results of ablation experiment ($t=0.4$)**表2 消融实验结果 ($t=0.4$)**

模型	平均精度	平均 F1 分数
GCN	0.683 2±0.024 6	0.679 0±0.024 4
GCN + 加权融合	0.709 1±0.029 1	0.707 2±0.029 2
GCN + 加权融合 + MLP	0.734 8±0.018 3	0.731 6±0.017 4

为了便于描述, 本文将模型 1、模型 2 和模型 3 分别定义为 GCN 模型、GCN+加权融合模型和 GCN+加权融合+MLP 模型。由表 2 可知, 模型 3 相较于其他两个模型的平均分类精度更高, 然而分类性能的提升幅度有限。当邻接矩阵阈值为 0.5 时, 模型 3 相较于模型 1 的精度提升达到最大值 5.3%。

比较模型 2、模型 3 可知, 模型 3 的分类效果始终高于模型 2, 即便在模型 2 分类效果较差的情况下, 模型 3 也几乎不受其影响, 不仅表明 MLP 具有进一步挖掘加权融合后的高阶非线性特征的能力, 还表明了加权融合各 GCN 层节点特征的方法可有效获取信号特征, 提升模型分类能力。模型 2 的分类性能与模型 1 接近, 尤其在低阈值情况下, 分类效果甚至略低于模型 1, 导致该现象的原因可能为: ①低阈值下邻接矩阵仍包含较多噪声, 各层 GCN 输出的特征可能被噪声污染, 参数 w_{ii} 的优化方向可能被干扰, 加权融合难以通过线性组合提取有效信息; ②随着阈值增大, GCN 各层的输出特征更偏向于关键连接和关键节点, 有利于加权融合模块整合并获取关键特征。




Fig. 5 Visualization of classification results
图5 分类结果可视化

4.2 分类实验

在构建二值化邻接矩阵时,相邻通道之间的相关程度会受到二值化阈值的影响,从而影响模型识别精度。为了研究选定阈值对模型性能的影响,在不同阈值下进行分类实验,如表 3、图 5、图 6 所示。实验表明,当阈值为 0.3~0.5 时,模型分类性能较好,说明在这个范围内模型能捕捉到更多有用信号。当阈值设置过大或过小时,分类性能相对较差,原因为当阈值过低时,邻接矩阵会保留大量弱连接,难以避免噪声等因素影响,GCN 会聚合过多无关节点的信息;高阈值可能导致 GCN 聚合的节点信息过少,丢失掉很多重要信息。

然而,不同阈值之间的精度差异并不巨大,可能归因于节点特征已包含较强的判别性信息,邻接矩阵的稀疏度变化对整体性能的贡献被弱化。

Table 3 Classification result of model in different threshold
表 3 不同阈值下的模型分类结果

阈值	平均精度	平均 F1 分数
0.0	0.712 8±0.032 0	0.709 8±0.031 3
0.1	0.715 8±0.020 2	0.711 5±0.021 1
0.2	0.703 0±0.047 1	0.695 6±0.052 0
0.3	0.734 8±0.018 3	0.731 6±0.017 5
0.4	0.734 2±0.023 2	0.730 2±0.024 0
0.5	0.737 1±0.022 4	0.734 4±0.022 7
0.6	0.715 2±0.044 6	0.711 9±0.045 1




Fig. 6 Relationship between the threshold and model accuracy
图6 阈值与模型精度之间的关系

4.3 比较实验

为了进一步验证所提模型的性能(本文模型性能见表 2),与 GAT、GCN-BiGRU、GIN、GraphCL、小波变换时频图+AlexNet^[21]进行比较,如表 4 所示^[18-20]。由此可知,GAT 分类效果很差,可能是需要使用原始邻接矩阵,通过注意力权重动态调整信息,而本文方法的二值化邻接矩阵丢弃了大部分边权信息,导致 GAT 难以发挥优势;GIN 等模型在当前任务中略优于本文模型,说明在 AD 识别任务中,改进后的 GCN 模型还有需要改进的地方,但本文模型的分类准确率更高、更稳定,具备一定的优势,未来可与其他模型进行融合。

Table 4 Results of comparison experiment
表 4 比较实验结果

模型	平均精度	平均 F1 分数
GAT	0.547 7±0.023 6	0.521 0±0.036 9
GIN	0.766 7±0.024 7	0.763 2±0.025 7
GraphCL	0.643 7±0.031 1	0.634 8±0.035 7
小波变换时频图+AlexNet	0.714 0±0.010 6	0.713 9±0.011 6
GCN-BiGRU	0.756 2±0.014 1	0.751 9±0.013 6

4.4 层数对照实验

为了验证改进模型是否能缓解深层网络的信息丢失问题,在不同深度条件下标准 GCN 模型和改进模型的效果如表 5 所示。由此可知,随着层数从 3 层增加到 10 层,标准 GCN 的平均精度下降 5.5%,精度标准差从 0.027 1 扩大至 0.055 4,验证了深层 GCN 可能存在较明显的过平滑问题。改进模型通过动态融合方法,虽在浅层时精度略低于标准模型,但随着层数提升,模型分类性能可保持在一个较高水平。这一现象归因于以下两点:①特征加权融合有效保留了浅层的局部特征与深层的全局特征,缓解了信息同质化问题,能充分利用中等深度网络的层次化表征优势;②10 层模型的精度相较于 5 层略有下降,但相较于标准 GCN 的差距十分明显,说明动态融合机制对深度网络的退化问题具有显著的抑制作用。

Table 5 Accuracy of model under different number of layers (t=0.5)
表 5 不同层数的模型精度 (t=0.5)

模型层数	GCN 平均精度	GCN+加权融合平均精度
3-layer	0.675 8±0.027 1	0.647 7±0.030 7
5-layer	0.673 8±0.037 0	0.718 2±0.023 2
10-layer	0.638 5±0.055 4	0.699 0±0.023 2

5 结语

本文针对 EEG 数据进行了一系列处理,利用静息态脑电图信号的二值化 PCC 邻接矩阵和 PSD 特征来提升模型识别 AD 的精确度。首先,聚合多图卷积层的输出特征提出了基于加权融合的线性组合方法,以增强模型的特征表达能力;其次,为缓解训练过程中的信息丢失问题,有效融合了局部与全局特征。实验表明,经过本文模型处理后的

特征,在阿尔茨海默病分类任务上的精度更高,对基于静息态 EEG 的 AD 深度学习分类研究具有一定的参考价值。

然而,本文仅通过简单的结构来优化、提取新特征,缺乏挖掘深层次特征的能力,且优化幅度较低,对临床研究的意义较小,后续会将所提方法融入其他更高质量的模型中进行实验。同时,为了提升临床意义,将考虑如何在跨被试的研究策略中提升分类效果,并更好地描述不同特征之间的关联性。此外,现有公开的静息态 EEG 数据集较少,后期将会进一步扩充数据集以验证所提方法的鲁棒性。

参考文献:

- [1] BETTER M A. Alzheimer's disease facts and figures[J]. *Alzheimers Dement*, 2023, 19(4): 1598-1695.
- [2] YANG Y. Expert opinion—emphasizing early screening and prevention of Alzheimer's Disease[J]. *Chinese General Practice*, 2021, 24(6): Front Insert 1.
杨宇. 专家说——重视阿尔茨海默病的早期筛查和防治[J]. *中国全科医学*, 2021, 24(6): 前插 1.
- [3] MA J, ZHANG S W, YU D H, et al. Research progress on correlation between mild cognitive impairment and symptoms of depression and anxiety[J]. *Chinese General Practice*, 2020, 23(1): 120-124.
马佳, 张韶伟, 于德华, 等. 轻度认知功能障碍与抑郁、焦虑症状的相关性研究进展[J]. *中国全科医学*, 2020, 23(1): 120-124.
- [4] ALBERDI A, AZTIRIA A, BASARAB A. On the early diagnosis of Alzheimer's disease from multimodal signals: a survey[J]. *Artificial Intelligence in Medicine*, 2016, 71: 1-29.
- [5] CHU L W. Alzheimer's disease: early diagnosis and treatment[J]. *Hong Kong Medical Journal*, 2012, 18(3): 228-237.
- [6] LI K, WANG J, LI S, et al. Feature extraction and identification of Alzheimer's disease based on latent factor of multi-channel EEG[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2021, 29: 1557-1567.
- [7] BABILONI C, ARAKAKI X, AZAMI H, et al. Measures of resting state EEG rhythms for clinical trials in Alzheimer's disease: recommendations of an expert panel[J]. *Alzheimer's & Dementia*, 2021, 17(9): 1528-1553.
- [8] SPEED T. A correlation for the 21st century[J]. *Science*, 2011, 334(6062): 1502-1503.
- [9] JEONG J. EEG dynamics in patients with Alzheimer's disease[J]. *Clinical neurophysiology*, 2004, 115(7): 1490-1505.
- [10] TIAN Y, ZHANG H, LI P, et al. A complementary method of PCC for the construction of scalp resting-state EEG connectome: maximum information coefficient[J]. *IEEE Access*, 2019, 7: 27146-27154.
- [11] 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.
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.
- [12] ZHU J, JIANG C, CHEN J, et al. EEG based depression recognition using improved graph convolutional neural network[J]. *Computers in Biology and Medicine*, 2022, 148: 105815.
- [13] PEI Y, HUANG T, VAN I W, et al. ResGCN: attention-based deep residual modeling for anomaly detection on attributed networks[J]. *Machine Learning*, 2022, 111(2): 519-541.
- [14] RAJJI T K, BOWIE C R, HERRMANN N, et al. Design and rationale of the PACT-MD randomized clinical trial: prevention of Alzheimer's dementia with cognitive remediation plus transcranial direct current stimulation in mild cognitive impairment and depression[J]. *Journal of Alzheimer's Disease*, 2020, 76(2): 733-751.
- [15] DELORME A, MAKEIG S. EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis[J]. *Journal of Neuroscience Methods*, 2004, 134(1): 9-21.
- [16] SOLOMON J O M. PSD computations using Welch's method[J]. *NASA STI/Recon Technical Report N*, 1991, 92: 23584.
- [17] SADIQ A, YAHYA N, TANG T B. Diagnosis of Alzheimer's disease using pearson's correlation and relief feature selection approach[C]// *International Conference on Decision Aid Sciences and Application*, 2021: 578-582.
- [18] XU J, YUAN S, SHANG J, et al. Spatiotemporal network based on GCN and BiGRU for seizure detection[J]. *IEEE Journal of Biomedical and Health Informatics*, 2024, 28(4): 2037-2046.
- [19] TAO T, GUO L, HE Q, et al. Seizure detection by brain-connectivity analysis using dynamic graph isomorphism network[C]// *Annual International Conference of the IEEE Engineering in Medicine & Biology Society*, 2022: 2302-2305.
- [20] YOU Y, CHEN T, SUI Y, et al. Graph contrastive learning with augmentations[J]. *Advances in Neural Information Processing Systems*, 2020, 33: 5812-5823.
- [21] HUGGINS C J, ESCUDERO J, PARRA M A, et al. Deep learning of resting-state electroencephalogram signals for three-class classification of Alzheimer's disease, mild cognitive impairment and healthy ageing[J]. *Journal of Neural Engineering*, 2021, 18(4): 46087.

(责任编辑:刘嘉文)