

DOI:10.3969/j.issn.1005-202X.2023.05.012

医学信号处理与医学仪器

基于多特征多关系图卷积神经网络的癫痫脑电分类

于永强¹, 刘健², 孙仁诚¹, 隋毅¹

1. 青岛大学计算机科学技术学院, 山东 青岛 266071; 2. 青岛市口腔医院, 山东 青岛 266000

【摘要】目的:提出一种基于多特征多关系图卷积神经网络的癫痫脑电分类方法,改进图卷积神经网络在癫痫脑电分类领域的应用,提升分类准确率。**方法:**分别提取癫痫脑电信号的1个频域特征、3个时频域特征和2个非线性动力学特征作为模型节点的特征。提取脑电通道之间的空间相似性和频谱相似性,融合两种通道相似性作为整体图节点之间的边关系矩阵。**结果:**在TUEP数据集上进行实验,准确率、精确率、召回率、F1分数、AUC结果分别为:0.87±0.02、0.91±0.04、0.82±0.04、0.86±0.02、0.90±0.03。**结论:**提出的模型与单特征和单关系的图卷积神经网络相比,对于癫痫脑电分类的提升效果明显。**【关键词】**脑电图;癫痫;图卷积神经网络;多关系图
【中图分类号】R318;TP391 **【文献标志码】**A **【文章编号】**1005-202X(2023)05-0595-07

Classification of epileptic electroencephalogram signal using graph convolutional neural network with multiple features and multiple relations

YU Yongqiang¹, LIU Jian², SUN Rencheng¹, SUI Yi¹

1. College of Computer Science and Technology, Qingdao University, Qingdao 266071, China; 2. Qingdao Stomatological Hospital, Qingdao 266000, China

Abstract: Objective To present a graph convolutional neural network (GCNN) based on multi-feature and multi-relations for the electroencephalogram (EEG) signal classification in epilepsy for promoting the application of GCNN in epileptic EEG signal classification and improving the classification accuracy. **Methods** One frequency domain feature, 3 time frequency domain features and 2 nonlinear dynamical features of epileptic EEG signals were taken as features of model nodes. The spatial similarity and spectral similarity between EEG channels were extracted and fused as the edge relationship matrix between the overall graph nodes. **Results** Experiments were conducted on the TUEP dataset to evaluate the classification performance. The proposed model achieved an accuracy, precision, recall, F1-score, and AUC of 0.87±0.02, 0.91±0.04, 0.82±0.04, 0.86±0.02, and 0.90±0.03, respectively. **Conclusion** The proposed model is advantageous over the single-feature and single-relation GCNN in the classification of epileptic EEG signal.
Keywords: electroencephalogram; epilepsy; graph convolutional neural network; multiple-relation graph

前言

癫痫俗称“羊角风”或“羊癫疯”,是一种非传染性脑部慢性疾病。据世界卫生组织的统计(数据截止2022年2月9日),癫痫大概影响到全球大约6500万人,多达10%的人在其一生中至少会经历一次癫痫发作^[1]。自

发脑电活动是由大脑皮层神经元产生的一种自发、节律性的电位变化。用脑电图仪在头皮表面或内部记录到的自发脑电活动,称为脑电图(Electroencephalogram, EEG)。脑电信号是一种时变的非平稳信号,信号幅度非常微弱,约为50 μV。与其他情感载体(如面部表情、姿势以及语音信号)能够人为刻意伪装不同,脑电信号是由中枢神经系统支配,而中枢神经系统在很大程度上是非自愿激活的,因此不容易遭受人主观意识的控制,更具客观真实性^[-2-3]。

1 相关工作

近年来,基于机器学习的癫痫脑电分类是热点研究方向。Torlay等^[4]基于55名参与者两个半球的5

【收稿日期】2022-12-10

【基金项目】国家自然科学基金青年基金项目(41706198);青岛市自主创新重大专项子课题(21-1-2-1hy)

【作者简介】于永强,硕士研究生,研究方向:机器学习和深度学习, E-mail: yongqiang169@foxmail.com

【通信作者】隋毅,博士,副教授,研究方向:大数据分析、机器学习, E-mail: sui yi@qdu.edu.cn

个语言区域(3个额叶和2个颞叶)的神经生理学特征进行研究,组合成135个特征子集,使用极致梯度提升算法对这些特征子集进行分类,结果显示,在SEM_LHBA_47-21子集取得了最好的分类效果。Li等^[5]提出一种基于小波非线性分析和遗传算法优化支持向量机的方法,取得了较好的效果,并且具有较低的复杂度和更好的可扩展性。Mursalin等^[6]提出一种基于随机森林分类器的改进相关性特征选择方法的脑电图信号中检测癫痫发作的分析方法,实验结果表明,该方法优于其他一些使用相同的基准脑电图数据集的癫痫发作检测方法。相较于传统机器学习方法,深度学习具有更佳的性能优势,许多研究者将其应用于脑电情绪识别以及疾病分类等领域,应用于脑电识别的深度网络包括卷积神经网络(Convolutional Neural Network, CNN)、递归神经网络(Recurrent Neural Network, RNN)、深度信念网络(Deep Belief Network, DBN)及其混合网络架构^[3]。大约40%的研究使用CNN,而14%的研究使用RNN,通常共3到10层^[7]。Aliyu等^[8]提出一种基于RNN的癫痫性脑电图信号的分类模型,与Logistic回归、支持向量机、k-最近邻、随机森林和决策树进行比较,实验表明RNN获得了99%准确率并且泛化能力最强。Ullah等^[9]提出一个基于深度学习的系统,这是一个金字塔式的一维卷积神经网络(P-1D-CNN)模型的集合,P-1D-CNN采用细化方法的概念,与传统的CNN模型相比,它的参数减少60%,在波恩大学的数据集上的准确率为 0.991 ± 0.009 。Zhou等^[10]基于原始脑电图信号特征来进行癫痫发作检测,区分脑电发作前期和发作期,实验表明频域信号的分类精度明显高于时域信号,并且发现频域信号在CNN应用中比时域信号具有更大的潜力。

然而,标准神经网络只能处理欧氏空间中的数据,而面对非欧空间的脑电数据处理能力则相对较弱,因此将图卷积神经网络(Graph Convolutional Neural Network, GCNN)用于脑疾病的分类和预测已成为趋势^[11-12]。Wagh等^[13]提出一种新的基于GCNN的方法(EEG-GCNN),利用脑电图来改进神经系统疾病的诊断,在TUAB数据集的实验证明EEG-GCNN效果明显优于全连接神经网络。全航等^[14]提出一种基于多头自注意力机制神经网络的癫痫脑电检测方法(CABLNet),在CHB-MIT头皮脑电数据库进行实验,实验结果表明CABLNet优于两个基线实验CNN+LSTM和CNN+BiLSTM,在癫痫检测性能方面有显著提高。脑电通道之间存在复杂的关系,目前GCNN在癫痫脑电领域还存在对脑电多通道间的空间信息挖掘力度不足以及提取特征组合过少的

问题^[15]。针对该问题,本研究提出一个基于多特征多关系GCNN的癫痫脑电自动分类模型。

2 脑电特征

癫痫脑电的特征提取是诊断、定位以及癫痫发作预报的基础^[16]。如表1所示,医学界普遍认为脑电信号主要存在至少6种不同的脑波,按照频率从低到高的顺序依次为:Delta(δ)、Theta(θ)、Alpha(α)、Beta(lower- β , higher- β)和Gamma(γ)。对不同频段的脑电信号通常采用频域分析和时频分析方法进行特征提取。

表1 常见脑波带的介绍

Table 1 Introduction of common brain wave bands

脑波带		频率/Hz	幅度/ μ V	出现位置
Delta(δ)		1~4	10~20	额区
Theta(θ)		4~8	20~150	额区、中央区、颞区， 顶区少量
Alpha(α)		8~12	20~100	枕区、双侧和中央区
Beta(β)	lower- β	12~16	5~20	中央区和额区
	higher- β	16~30	5~20	中央区和额区
Gamma(γ)		30~50	<2	中央区和额区

功率谱密度(Power Spectral Density, PSD)是一种典型的频域分析方法,通过将脑电时域信号转换到脑电功率随频率变化的频率谱,可以观察到脑电节律的分布与变换情况^[17]。本研究采用Welch方法^[18]计算PSD,对于一个长度有限的非连续EEG信号分成 M 段,把窗函数加到每段上,求出周期图 I_i ,将每个周期图近似看成互不相关, $PSD = \frac{1}{M} \sum_{i=1}^M I_i$,根据频率范围求出每个脑波带的PSD。

小波变换是常用的时频分析方法,时频分析能够准确地反映出信号的局部时变频率特性^[19]。小波包变换在小波分析理论的基础上,引入最优基选择的观念,并且能够对信号的低频部分和低频部分进行分解。通过使用小波包分解对脑电信号进行处理,分别提取每个脑波带的波段能量和 P ,计算 P 与通道的总能量和的比值,从而得到每个脑波带的小波包能量比 Pr 。小波能量熵 W 在宏观上对复杂的时变信号在各时频空间的能量分布进行量化,熵值的大小描述了信号频率组成的复杂度。脑波带 i 的小波能量熵的计算公式如式(1)所示,其中 m 在 i 范围内的频率, Pr_j 表示频率 j 的小波能量比:

$$W = -\sum_{j=1}^m Pr_j \ln Pr_j \quad (1)$$

近年来,越来越多的研究表明大脑是一个复杂的非线性混沌系统,脑电信号可以被看作其输出^[20]。近似熵和香农熵是较为常用的两个描述脑电信号的非线性动力学指标,近似熵可用于度量脑电信号时间序列波动的规律性和不可预测性。它用一个非负数来表示一个脑电信号时间序列的复杂性,越复杂的脑电信号时间序列对应的近似熵越大^[21-22]。以 m 为窗口大小,将一个 n 维时间序列 $[X(i), i = 1, 2, \dots, n]$ 分为 $k = n - m + 1$ 个序列。 $C_i^m(t)$ 表示每个序列与所有 k 个序列的距离大于给定阈值的个数占总数比值, $\Phi^m(t) = (n - m + 1)^{-1} \sum_{i=1}^{n-m+1} \log C_i^m(t)$ 表示 k 个 $C_i^m(t)$ 的对数平均数^[21]。近似熵的计算如式(2)所示:

$$\text{ApEn}(t) = \Phi^m(t) - \Phi^{m+1}(t) \tag{2}$$

香农熵又被称为信息熵,表征的是一个事物包含的信息量的大小,事物的不确定性越大,则信息量越大,香农熵越大^[23]。按照脑电信号的幅值范围将脑电数据平均分割成 N 个幅值区间,统计脑电信号幅值落在各个区间内数据点的个数,除以脑电信号数据点总数得到各个脑电片段的概率。计算脑电数据

的香农熵公式如式(3)所示:

$$H(X) = -\sum_{i=1}^N p(x_i) \log_2 p(x_i) \tag{3}$$

其中, x_i 指的是第 i 个幅值区间, $p(x_i)$ 是脑电数据点落在 x_i 段的概率。

3 E-GCNN 模型

为了探索脑电数据多通道之间的内在关系,更好地对癫痫脑电分类,本设计提出基于多特征多关系的癫痫脑电自动检测分类模型(Epilepsy EEG Graph Convolutional Neural Network, E-GCNN)。E-GCNN 关注脑电通道之间存在的复杂关系,通过聚合邻近节点的信息更新中心节点的状态。E-GCNN 模型架构分别是输入层、图卷积层、全连接层以及分类层,如图 1 所示。使用图描述连续 10 s 的脑电数据,将图作为 E-GCNN 模型的输入;模型对输入数据进行图卷积,生成节点嵌入(node embedding);对全图的节点嵌入进行全局平均池化操作,返回图的嵌入向量(graph embedding);将图嵌入作为输入经过一个全连接层,从而预测输出类别。

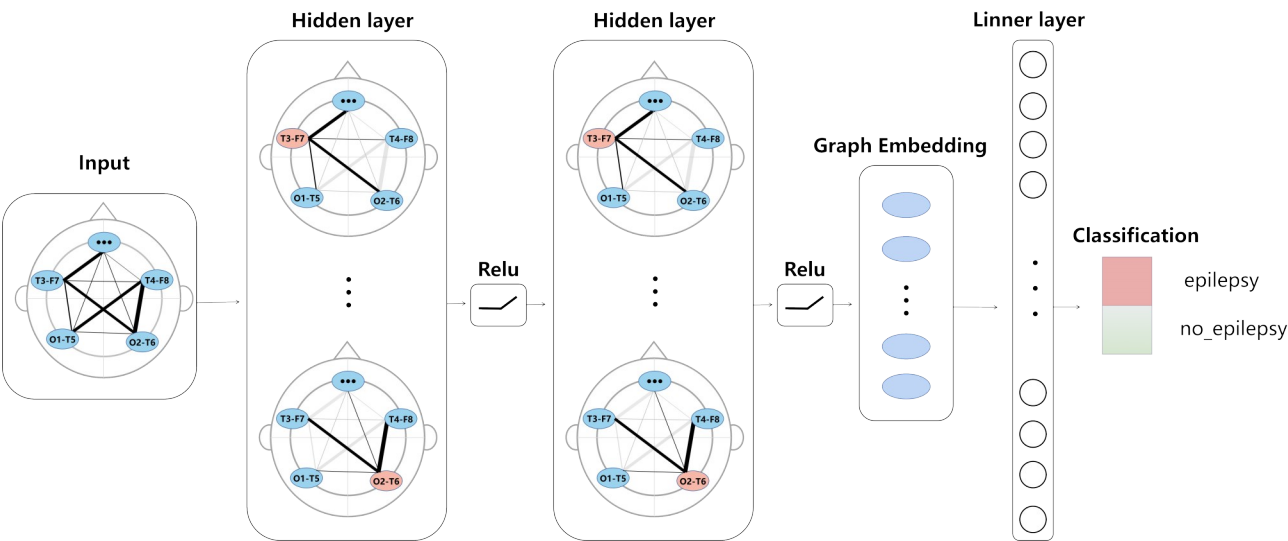


图1 E-GCNN 模型的网络结构示意图
Figure 1 Network structure of E-GCNN model

3.1 模型输入

E-GCNN 的输入包括两部分,第一部分是 M 个双极脑电通道对提取的多个特征数据,进行拼接融合后组成的最终的图节点特征;第二部分是脑电通道与通道之间的相关系数,即通过特定映射关系,以图的形式描述通道间存在的空间关系。如图 2 所示,通道数据的特征映射至图中顶点,通道间相关系数映

射至图中边,构成图数据,作为 E-GCNN 模型的输入。图 2 中表示图数据的拓扑相关图为例图,实际输入图是一个全连接图,以确保模型输入数据的拓扑稳定性。

将受试者的脑电数据以连续 10 s 为单位划分为 N 个切片。一个受试者的脑电图数据被划分成若干个时长为 10 s 的 M 通道脑电数据。定义无向全连接

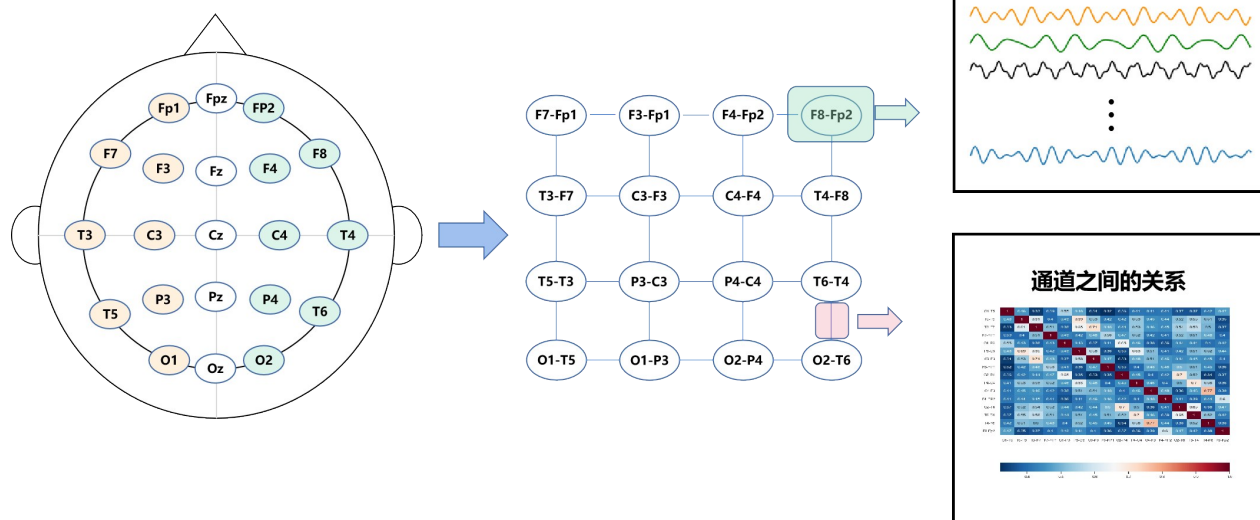


图2 E-GCNN模型输入示意图

Figure 2 Schematic diagram of E-GCNN input

左侧图是脑电通道的俯瞰图,颜色标识的是实验选中的通道;中间图是网络拓扑图;右上图是采集的脑电数据,右下图是通道之间的关系热图

图 $G_i = (V, E_i)$, 表示切片 i 的通道之间的相互作用关系。其中 V 表示 M ($M = |V|$) 个通道的集合, $E_i \subset V \times V$ 表示节点集 V 之间的无向边的集合, 用一个加权邻接矩阵 $A \in R^{M \times M}$ 来表示, 其中每个节点的自连边 $A_{ii} = 1, i = 1, 2, \dots, M$ 。

受 Wagh 等^[13]相关研究的启发, 设计通道 i 与通道 j 之间的关系 A_{ij} 由两部分组成, 分别是通道 i 与通道 j 之间的空间距离关系 A_{ij}^s , 以及通道 i 与通道 j 之间频谱相关性 A_{ij}^f 。根据 10-10 国际标准导联系统各个通道的位置信息, 得到通道在笛卡尔坐标系中的具体坐标值。通道 i 和通道 j 在笛卡尔坐标空间中定位到半径为 r 的球面上的点 (x_i, y_i, z_i) 与点 (x_j, y_j, z_j) 之间的测地线距离 A_{ij}^s 定义为:

$$A_{ij}^s = \arccos\left(\frac{x_i x_j + y_i y_j + z_i z_j}{r^2}\right) \quad (4)$$

设 $x_i(f)$ 和 $x_j(f)$ 分别为通道 i 和通道 j 的时间序列 $\hat{x}_i(t)$ 和 $\hat{x}_j(t)$ 的傅里叶变换。交叉谱定义^[24]为 $S_{ij}(f) \equiv x_i(f) x_j^*(f)$, $x_j^*(f)$ 为 $x_j(f)$ 的复共轭。通道 i 和通道 j 的频谱相关性定义为归一化交叉谱的绝对值:

$$A_{ij}^f \equiv \left| \frac{S_{ij}(f)}{\sqrt{S_{ii}(f) S_{jj}(f)}} \right| \quad (5)$$

3.2 图卷积

空间 GCNN 卷积的本质目的就是用来提取拓扑图的空间特征, 在每一层卷积中, 每个节点特征的更新依据其邻居节点, 对其所有邻居的特征进行加权

求和, 从而得到新一层的节点特征^[25]。卷积层的数据更新规则如下所示:

$$H^{(l+1)} = \sigma\left(\tilde{D}^{-\frac{1}{2}} \tilde{A} \tilde{D}^{-\frac{1}{2}} H^{(l)} W^{(l)}\right) \quad (6)$$

其中, $H^{(l)}$ 表示 l 层的特征向量矩阵, I 是单位矩阵, A 表示图 G_i 的邻接矩阵, $\tilde{A} = A + I$, D 是 A 的度矩阵, $\tilde{D} = \sum \tilde{A}_{ij}$, σ 是非线性激活函数 (如 RELU 函数), $W^{(l)}$ 表示的是 l 层卷积变换的可训练的参数矩阵。

4 实验设置与结果分析

4.1 数据集介绍

使用 TUEP (The TUH EEG Epilepsy Corpus) 数据集, 来自 TUH 脑电资料库的一个子集 (下载地址 https://isip.piconepress.com/projects/tuh_eeg/downloads/tuh_eeg_epilepsy/)。该数据集共有 237 名受试者的脑电信息, 其中包含 133 名癫痫病患者在病发状态下的 1360 个脑电信号记录文件和 104 名受试者 (为了平衡语料库, 有些受试者是不患癫痫病的普通人) 在静息状态所获取的 288 个脑电信号记录文件, 共计 1648 个脑电信号文件。数据采集过程中共有 3 种单极电极的记录参考, 分别为: 01_tcp_AR、02_tcp_LE、03_tcp_AR_a。该数据集中所有样例全部以 EDF 的格式存储, EDF 文件中最常见的脑电通道数为 31 个。大部分脑电图数据采样率为 250 Hz, 少数为 256、400 和 512 Hz^[26]。

4.2 预处理

为了平衡正负样本, 经过选择保留了 195 个受试者共计 1602 个脑电记录文件。对于每个记录文件,

分别按照其采集数据时使用的3种参考规则(01_tcp_AR、02_tcp_LE、03_tcp_AR_a),从所有通道中选择其16个原始通道:["F7", "F3", "F8", "F4", "T3", "C3", "T4", "C4", "T5", "P3", "T6", "P4", "O1", "O2", "FP1", "FP2"],将通道集合中两个通道电极的电位差作为新的通道,称之为双极通道,用以组成新的双极通道集合:["O1-T5", "T5-T3", "T3-F7", "F7-FP1", "O1-P3", "P3-C3", "C3-F3", "F3-FP1", "O2-P4", "P4-C4", "C4-F3", "F4-FP2", "O2-T6", "T6-T4", "T4-F8", "F8-Fp2"]。将所有记录文件以10 s为单位进行切分,分成若干个相互独立的切片,即每一个记录文件都将被分成若干个长度为10 s并且互不重叠的小记录文件,最后剩余不足10 s的部分被清除,一共产生23 331个切片,包括99个癫痫受试者的切片12 762个和96个非癫痫受试者的切片10 569个。最后使用

MNE-Python^[27]工具包,对每个切片重新统一按照250 Hz进行下采样,使用1 Hz的高通滤波以及50 Hz的陷波过滤去除噪声^[13]。

4.3 特征工程

如图3所示,对预处理之后的切片数据提取第2小节中介绍的功率谱密度、小波能量和、小波能量比、小波能量熵、近似熵和香农熵特征,得到6个单特征的特征矩阵,特征维度分别为 16×6 、 16×6 、 16×6 、 16×6 、 16×1 、 16×1 。把切片 i 的6个单特征矩阵拼接成一个切片特征矩阵 X_i , X_i 特征维度为 16×26 ,压缩成维度为 1×416 的一维矩阵,并且将压缩后的一维切片特征矩阵连接组成总特征矩阵 X ,维度为 $23\ 331 \times 416$ 。对 X 进行标准化,以消除不同特征所带来的差异化,减少对模型的影响。




图3 特征提取拼接过程图

Figure 3 Feature extraction and splicing process

对TUEP数据集的癫痫病和非癫痫病两类正负样本进行独立样本 t 检验, P 值为 $3.17e-12$,远小于0.01,表明正负样本具有显著性差异。图4的箱线图展示了6个特征进行z-score标准化后的的组间差异,功率谱密度和3个时频特征的6个频带执行了平均操作,可以看到不同的脑电特征在普通受试者和癫痫患者之间有着不同程度的差异。

4.4 实验环境与网络参数

E-GCNN使用Pytorch以及PYG进行搭建。Python版本为3.8.12,Pytorch版本为cpu-1.8.0,PYG版本为1.7.2。经多次实验调试后选择效果最优的超参数,其中优化器选择Adam,学习率为0.01,样本批次为64,dropout层系数为0.5,损失函数使用的是二分类交叉熵损失函数。

4.5 模型评估

为了评估E-GCNN模型的性能,设计多个对照实验,分别是只考虑单个特征图神经网络:功率谱密度特征模型E-GCNN-PSD、小波能量和特征模型E-GCNN-Pyenergy、小波能量比特征模型E-GCNN-PyenergyRate、小波能量熵特征模型E-GCNN-Pyen、近似熵特征模型E-GCNN-Apen、香农熵特征模型E-GCNN-Shen;以及单个边关系的图神经网络:空间相关性关系模型E-GCNN-Dist和频谱相关性关系模型E-GCNN-Spec。

在模型评估中,为了更加严谨地评估E-GCNN以及对照实验结果,都采用了准确率(Accuracy)、精确率(Precision)、召回率(Recall)、F1分数(F1-Score)、AUC(Area Under Curve)等评价指标对模型进行综合评价。

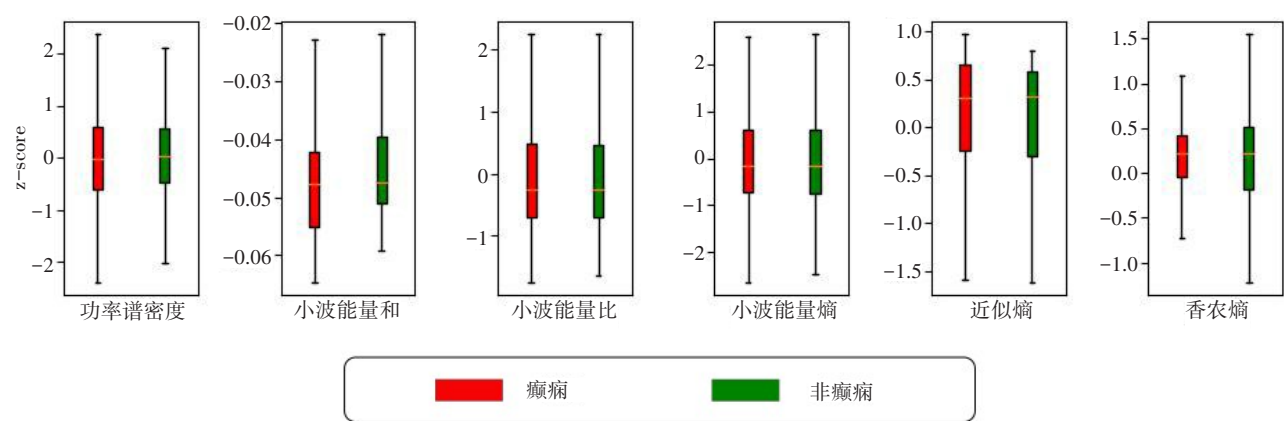


图 4 多个特征组间差异的箱线图

Figure 4 Boxplots of differences between multiple feature groups

每个模型评价指标都是受试者级别的,即针对每个受试者,对其所分出的所有切片的预测值执行平均操作,作为该受试者经过模型的输出值。每个指标的实验结果均是十折交叉验证的平均值。如表 2 所示,E-GCNN 模型的准确率、精确率、召回率均大于其它两个模型,F1 分数相较于其它两个模型分别提高 4% 和 5%。在图 5a 中展示出的受试者工作特征(ROC)曲线可以看到 E-GCNN 的 AUC 是明显大于其他两者,AUC 达到 90%,该对照实验表明通道之间采用空间相关性与频

谱相关性两种关系组合的 E-GCNN 模型的效果要优于 E-GCNN-Dist 模型和 E-GCNN-Spec 模型效果。如表 3 所示,通过组合多种 EEG 特征作为最终模型输入特征的 E-GCNN 的效果也要优于单一特征在图神经网络上的效果,各评价指标提升约 10%~20%,对于部分特征的提升效果甚至达到 30%。图 5b 选择展示部分采用单特征的图网络模型以及 E-GCNN 的 ROC 曲线图,可以看到 E-GCNN 的 AUC 明显大于其他采用单特征的图神经网络对照实验。

表 2 E-GCNN 与单关系图模型的效果

Table 2 Performances of E-GCNN and single-relation model

模型	准确率	精确率	召回率	F1 分数	AUC
E-GCNN-Dist	0.86±0.02	0.87±0.03	0.77±0.08	0.82±0.04	0.86±0.01
E-GCNN-Spec	0.81±0.02	0.85±0.04	0.77±0.06	0.81±0.03	0.85±0.02
E-GCNN	0.87±0.02	0.91±0.04	0.82±0.04	0.86±0.02	0.90±0.03

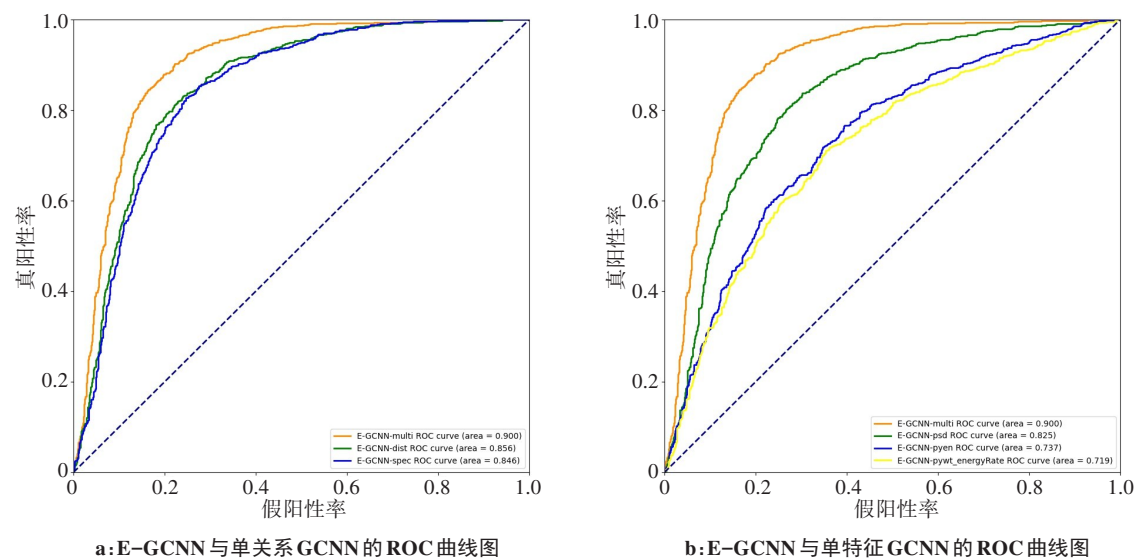


图 5 E-GCNN 分别与单特征图 and 单关系图的 ROC 结果比较

Figure 5 Comparison of ROC results of E-GCNN with single-feature graph or single-relation graph

表3 E-GCNN与单特征模型的效果
Table 3 Performances of E-GCNN and single-feature models

模型	准确率	精确率	召回率	F1 分数	AUC
E-GCNN-PSD	0.79±0.02	0.83±0.04	0.76±0.06	0.79±0.02	0.83±0.02
E-GCNN-Pyen	0.72±0.02	0.74±0.04	0.70±0.08	0.72±0.02	0.74±0.01
GCNN-PyenergyRate	0.71±0.02	0.72±0.04	0.72±0.05	0.72±0.03	0.72±0.03
E-GCNN-Pyenergy	0.61±0.02	0.62±0.04	0.67±0.12	0.64±0.04	0.60±0.03
E-GCNN-Apen	0.56±0.01	0.58±0.01	0.60±0.04	0.59±0.01	0.54±0.01
E-GCNN-Shen	0.54±0.02	0.58±0.06	0.54±0.10	0.56±0.12	0.53±0.01
E-GCNN	0.87±0.02	0.91±0.04	0.82±0.04	0.86±0.02	0.90±0.03

5 结 论

本研究针对多数研究对癫痫脑电数据通道之间复杂关系考虑不足的问题,提出E-GCNN模型,提取多个脑电特征并进行拼接融合,实验结果表明分电线脑病分类性能提升明显;设计两种通道相似性计算方法,分别是空间相似性和频谱相似性,通过平均两种关系作为最终的结构特征,实验表明其效果优于分别只采用单边关系的模型效果。综上所述,本文设计的基于多特征多关系GCNN对癫痫脑病自动分类具有较好的技术支撑能力。

【参考文献】

[1] World Health Organization. Epilepsy[EB/OL]. <https://www.who.int/zh/news-room/fact-sheets/detail/epilepsy>.

[2] 孙中皋, 薛全德, 王新军, 等. 基于脑电信号的情感识别方法综述[J]. 北京生物医学工程, 2020, 39(2): 186-195.
Sun ZG, Xue QD, Wang XJ, et al. A survey of emotion recognition method based on EEG signals[J]. Beijing Biomedical Engineering, 2020, 39(2): 186-195.

[3] 李颖洁, 李玉玲, 杨帮华. 基于脑电信号深度学习的情绪识别研究现状[J]. 北京生物医学工程, 2020, 39(6): 634-642.
Li YJ, Li YL, Yang BH. A review of EEG emotion recognition based on deep learning[J]. Beijing Biomedical Engineering, 2020, 39(6): 634-642.

[4] Torlay L, Perrone-Bertolotti M, Thomas E, et al. Machine learning-XGBoost analysis of language networks to classify patients with epilepsy[J]. Brain Inform, 2017, 4(3): 159-169.

[5] Li M, Chen W, Zhang T. Automatic epilepsy detection using wavelet-based nonlinear analysis and optimized SVM[J]. Biocybern Biomed Eng, 2016, 36(4): 708-718.

[6] Mursalin M, Zhang Y, Chen Y, et al. Automated epileptic seizure detection using improved correlation-based feature selection with random forest classifier[J]. Neurocomputing, 2017, 241: 204-214.

[7] Roy Y, Banville H, Albuquerque I, et al. Deep learning-based electroencephalography analysis: a systematic review[J]. J Neural Eng, 2019, 16(5): 051001.

[8] Aliyu I, Lim YB, Lim CG. Epilepsy detection in EEG signal using recurrent neural network [C]//Proceedings of the 2019 3rd International Conference on Intelligent Systems, Metaheuristics & Swarm Intelligence. 2019: 50-53.

[9] Ullah I, Hussain M, Aboalsamh H. An automated system for epilepsy detection using EEG brain signals based on deep learning approach [J]. Expert Syst Appl, 2018, 107: 61-71.

[10] Zhou M, Tian C, Cao R, et al. Epileptic seizure detection based on EEG signals and CNN[J]. Front Neuroinform, 2018, 12: 95.

[11] 张格, 林岚, 吴水才. 基于脑网络的图卷积神经网络在脑疾病中的研究进展[J]. 医疗卫生装备, 2021, 42(8): 85-92.
Zhang G, Lin L, Wu SC. Research progress of brain network-based graph convolutional neural networks for brain diseases[J]. Chinese Medical Equipment Journal, 2021, 42(8): 85-92.

[12] 张格, 林岚, 吴水才. 脑群体图中图卷积神经网络应用研究综述[J].

生命科学仪器, 2021, 19(4): 23-30.
Zhang G, Lin L, Wu SC. Review on the application of graph convolutional neural network in brain population graph [J]. Life Science Instruments, 2021, 19(4): 23-30.

[13] Wagh N, Varatharajah Y. EEG-GCNN: augmenting electroencephalogram-based neurological disease diagnosis using a domain-guided graph convolutional neural network[C]. Machine Learning for Health, 2020: 367-378.

[14] 全航, 杨燕, 江永全. 检测脑电癫痫的多头自注意力机制神经网络[J]. 计算机科学与探索, 2023, 17(2): 1-14.
Tong H, Yang Y, Jiang YQ. Multi-head self-attention neural network for detecting EEG epilepsy [J]. Journal of Frontiers of Computer Science and Technology, 2023, 17(2): 1-14.

[15] 陈鑫. 基于图卷积网络的癫痫脑电信号分析与研究[D]. 济南: 山东师范大学, 2021.
Chen X. Epilepsy EEG signal analysis and research based on graph convolutional network[D]. Jinan: Shandong Normal University, 2021.

[16] 尹永强. 基于卷积神经网络的脑电情绪识别方法研究[D]. 济南: 山东师范大学, 2021.
Yin YQ. Research on EEG emotion recognition methods based on convolutional neural networks [D]. JiNan: Shandong Normal University, 2021.

[17] 李忠, 秦树人, 彭丽玲. 脑电信号的现代分析方法[J]. 重庆大学学报(自然科学版), 2002, 25(9): 108-112.
Ji Z, Qin SR, Peng LL. Signal processing of electroencephalogram and it's application [J]. Journal of Frontiers of Computer Science and Technology, 2002, 25(9): 108-112.

[18] Welch P. The use of fast Fourier transform for the estimation of power spectra: a method based on time averaging over short, modified periodograms[J]. IEEE Trans Acoust, 1967, 15(2): 70-73.

[19] 董建华, 顾汉明, 张星. 几种时频分析方法的比较及应用[J]. 工程地球物理学报, 2007, 4(4): 312-316.
Dong JH, Gu HM, Zhang X. A comparison of time-frequency analysis methods and their applications[J]. Chinese Journal of Engineering Geophysics, 2007, 4(4): 312-316.

[20] 孟欣, 欧阳楷. 脑电信号的几个非线性动力学分析方法[J]. 北京生物医学工程, 1997, 16(3): 135-140.
Meng X, Ouyang K. Several nonlinear dynamic methods of EEG signal analysis[J]. Beijing Biomedical Engineering, 1997, 16(3): 135-140.

[21] Pincus SM. Approximate entropy as a measure of system complexity [J]. PNAS, 1991, 88(6): 2297-2301.

[22] 白冬梅, 邱天爽, 李小兵. 样本熵及在脑电癫痫检测中的应用[J]. 生物医学工程学杂志, 2007, 24(1): 200-205.
Bai DM, Qiu TS, Li XB. The sample entropy and its application in EEG based epilepsy detection[J]. Journal of Biomedical Engineering, 2007, 24(1): 200-205.

[23] Shannon CE. A mathematical theory of communication[J]. Bell Syst Tech J, 1948, 27(3): 379-423.

[24] Nolte G, Bai O, Wheaton L, et al. Identifying true brain interaction from EEG data using the imaginary part of coherency [J]. Clin Neurophysiol, 2004, 115(10): 2292-2307.

[25] 徐冰冰, 岑科廷, 黄俊杰, 等. 图卷积神经网络综述[J]. 计算机学报, 2020, 43(5): 755-780.
Xu BB, Cen KT, Huang JJ, et al. A survey on graph convolutional neural network[J]. Chinese Journal of Computers, 2020, 43(5): 755-780.

[26] Obeid I, Picone J. The temple university hospital EEG data corpus [J]. Front Neuroenergetics, 2016, 10: 196.

[27] Gramfort A, Luessi M, Larson E, et al. MEG and EEG data analysis with MNE-Python[J]. Front Neuroenergetics, 2013, 7: 267.

(编辑:陈丽霞)