

基于注意力图池化的图卷积网络癫痫发作预测

张倩云, 乔晓艳*

(山西大学 物理电子工程学院, 山西 太原 030006)

摘要:对癫痫发作及时准确预测可在发作前对患者实施干预措施防止意外伤害。为提高癫痫发作预测的准确率,提出一种注意力图池化的图卷积神经网络模型,用于癫痫发作预测。将多导联脑电数据转换为图结构关系,设计改进的图卷积神经网络模型,通过嵌入注意力图池化,筛选重要节点信息,避免特征冗余,提高模型学习能力和稳健性。在此基础上,分析不同脑电节律、滑动时间窗口以及预测时长对癫痫预测的影响。仿真实验结果表明:采用4 s时间窗口0.5 s滑动步长,在癫痫发作前5 min预测可达到97.03%准确率,95.89%召回率,98.16%特异性和96.12%的F1值。该模型可以提高癫痫发作预测精度,具有较好泛化能力。

关键词:癫痫发作预测;脑电信号;图卷积神经网络;注意力图池化

中图分类号:TP391 **文献标志码:**A **文章编号:**0253-2395(2024)04-0767-09

Epileptic Seizure Prediction by Graph Convolutional Network Based on Graph Pooling of Attention

ZHANG Qianyun, QIAO Xiaoyan*

(College of Physics and Electronic Engineering, Shanxi University, Taiyuan 030006, China)

Abstract: Timely and accurate prediction of epileptic seizures can take intervention measures to prevent from accidental injury before epileptic seizures. In order to improve the accuracy of epileptic seizure prediction, a graph convolution neural network model, based on graph pooling of attention, is proposed for epileptic seizure prediction. The multi-lead Electroencephalography (EEG) data were converted into a graph structure, and an improved graph convolution neural network model was designed. By adding graph pooling of attention, important node information was screened to avoid feature redundancy and improve the learning ability and robustness of the model. On this basis, the effects of different EEG rhythm, sliding time window and prediction duration on epilepsy prediction were analyzed. The simulation results show that the accuracy, recall rate, specificity and F1 value of the prediction model can achieve separately 97.03%, 95.89%, 98.16% and 96.12% for 5 minutes before seizures, by using the sliding step size of 0.5 s in the 4 s time window. Therefore, this model can improve the prediction accuracy of epileptic seizure and can be easily generalized.

Key words: prediction of epileptic seizure; EEG signal; graph convolution neural network; graph pooling of attention

0 引言

癫痫是仅次于中风的常见脑神经系统疾病,其特征是反复和突然发作,容易导致严重意外

伤害,成功预测癫痫发作具有重要的现实意义。

目前,传统的机器学习广泛应用于癫痫预测。该方法首先提取与癫痫相关的脑电特征,再训练传统的机器学习模型进行预测。周梦妮

收稿日期:2023-02-08;接受日期:2023-04-17

基金项目:山西省回国留学人员科研项目(2020-009)

作者简介:张倩云(1998-),女,山西运城人,硕士研究生,研究方向为癫痫发作预测和深度学习算法。E-mail:qianyun258016@163.com

*通信作者:乔晓艳(QIAO Xiaoyan),E-mail:xyqiao@sxu.edu.cn

引文格式:张倩云,乔晓艳.基于注意力图池化的图卷积网络癫痫发作预测[J].山西大学学报(自然科学版),2024,47(4):767-775. DOI:10.13451/j.sxu.ns.2023083

等^[1]通过提取排列熵构成的脑电特征向量,并将其输入支持向量机训练机器学习模型,最终可以在发作前 50 min 预测到 81% 的癫痫发作。易芳吉等^[2]选取样本熵和皮尔逊相关性作为特征参数,并筛选出最优特征组合,将其输入支持向量机分类发作间期和发作前期的癫痫脑电信号,最后获得 91.26% 的准确率。然而,由于手工提取的癫痫脑电特征信息不充分,以及传统机器学习算法的分类能力有限,无法实现癫痫发作高精度预测。

随着深度学习技术的发展,许多学者开始研究基于深度学习的癫痫预测模型。Yang 等^[3]基于 CHB-MIT (Children's Hospital Boston-Massachusetts Institute of Technology) 数据集提出了一种双重自注意力残差网络,癫痫预测的准确率达到 92.07%。Ryu 等^[4]提出将密集卷积网络和长短时记忆网络结合的深度学习方法预测癫痫发作,可在发作前 5 min 预测到 93.28% 的癫痫发作。汤云琪等^[5]提出一种改进的长短时记忆网络模型,预测癫痫发作,通过加入电子搜索算法 (Electronic Search Algorithm, ESA) 和随时间反向传播算法 (Back Propagation Algorithm over Time, BPTT) 缩短网络训练时间,最终预测准确率达到 93.7%。Singh 等^[6]通过提取每个脑电节律的平均振幅和功率特征,并将其输入到卷积神经网络 (Convolutional Neural Network, CNN) 和长短时记忆网络 (Long Short-term Memory, LSTM) 算法分类癫痫发作间期和发作前期,最终得到 94.74% 的预测准确率。

深度学习方法一定程度提高了癫痫预测的准确率,然而由于脑电测量电极具有多导联的结构,采用上述非结构化的神经网络模型,不能综合利用脑电各个导联的关联信息,没有充分考虑大脑不同位置脑电活动之间的相互关联,在预测系统性能方面还有待提升。

图是一种表示实体关系和结构化数据的方法,由一些节点和连接这些节点的边组成,其复杂的结构蕴含着丰富的潜在价值。人脑是由功能和结构域组成的复杂网络,图打破了常用的欧氏网格结构的均匀分布,能更好地表示大脑结构连接,为分析癫痫脑电提供了一个新的视角。图卷积神经网络根据图的邻接矩阵关

系,获得当前节点的相邻节点并对其卷积,可以有效利用多导联脑电的空间结构信息。Jia 等^[7]提出了一种用于癫痫发作预测的通用图卷积网络 (Graph Convolutional Network, GCN) 模型架构,在 CHB-MIT 头皮脑电图数据集中的 18 例患者上,该模型的平均预测准确率为 92%。Lian 等^[8]提出一种全局-局部图卷积神经网络在 Freiburg 数据集上获得 95.67% 的预测准确率。但由于图卷积网络主要依赖节点特征和边结构进行卷积,节点的选择会直接影响模型的预测性能。传统的图卷积网络使用简单的图池化操作来减少节点数量,例如最大池化或平均池化。这种图池化方式没有考虑节点的重要性,即将所有的节点视为等价的,这可能会丢失与癫痫相关的节点信息,从而导致模型预测性能下降。

因此,本文提出一种基于注意力图池化的图卷积神经网络模型,提取各个导联的癫痫脑电皮尔逊相关系数,并在图池化中嵌入注意力机制,通过计算每个导联注意力分数,根据注意力分数选择重要节点信息及其连接边完成图池化。这种注意力图池化方法可以保留与癫痫特征相关的节点信息,实现自适应的降维,避免了使用多个节点特征容易造成特征信息冗余,降低算法的复杂度和模型过拟合,从而实现癫痫发作前期和发作间期的准确预测。

1 算法原理

1.1 图卷积神经网络

图卷积神经网络是能够使用卷积操作对非欧式数据进行特征提取的深度学习神经网络。谱域图卷积基于图谱理论,借助图的拉普拉斯矩阵特征值和特征向量研究图的特性。切比雪夫网络 (ChebyNet)^[9]致力于实现图卷积神经网络的局部性和加速计算,通过参数化卷积核实现局部性,同时降低参数复杂度和计算复杂度。对卷积核 g_θ 进行参数化:

$$g_\theta = \sum_{k=0}^{K-1} \theta_k T_k(\hat{\Lambda}), \quad (1)$$

其中, θ_k 是需要学习的系数, k 是多项式阶数。 $\mathbf{A} \in \mathbb{R}^{N \times N}$, 表示拉普拉斯矩阵 L 特征值构成的对角矩阵, $\hat{\Lambda} = \frac{2\mathbf{A}}{\lambda_{\max}} - I_N$, 为归一化后的 \mathbf{A} 。

$I_N \in \mathbb{R}^{N \times N}$ 是单位阵。切比雪夫多项式通过递归得到,递归表达式为:

$$T_k(x) = 2xT_{k-1}(x) - T_{k-2}(x), \quad (2)$$

其中, $T_0(x) = 1, T_1(x) = x$ 。令 $\hat{L} = \frac{2L}{\lambda_{\max}} - I_N$,

切比雪夫图卷积为:

$$x^* g_\sigma = U \left(\sum_{k=0}^{K-1} \theta_k T_k(\hat{L}) \right) U^T x = \sum_{k=0}^{K-1} \theta_k T_k(\hat{L}) x, \quad (3)$$

其中 x 是输入信号, $U = \{u_i\}_{i=1}^N$ 表示拉普拉斯矩阵 L 的特征值对应的特征向量构成的正交矩阵, N 为拉普拉斯矩阵特征值个数。切比雪夫图卷积核有 K 个可学习的参数, K 是卷积核的“感受野半径”,即把中心顶点的 K 阶近邻节点作为邻域节点。一般 K 远小于 N ,因而参数的复杂度被大大降低,并且图卷积核不需要对拉普拉斯矩阵进行特征分解。

1.2 注意力图池化

注意力图池化是将注意力机制应用到图池化过程中,同时考虑图本身的特征信息和图空间位置结构信息,利用注意力机制决定应该取舍的节点。注意力图池化使用图卷积计算注意力分数,计算方法为:

$$Z = \sigma(\hat{D}^{-\frac{1}{2}} \hat{A} \hat{D}^{-\frac{1}{2}} H \theta_{att}), \quad (4)$$

其中 $\hat{D} = D + I, \hat{A} = A + I, D$ 是度矩阵, A 是邻接矩阵, I 是单位矩阵。 H 为经过切比雪夫图卷积后的节点特征矩阵, θ_{att} 是学习的参数矩阵, $\sigma(\cdot)$ 是激活函数,用于将注意力分数控制在 $[0, 1]$ 之间。注意力图池化对每个节点计算注意力分数,分数越高,表明该节点学习到的癫痫特征更具代表性,需要保留;反之可以去除。设置一个图池化比率 $r \in (0, 1]$, 通过 r 乘以输入图节点个数确定输出图的节点个数。输入图利用图卷积和激活函数计算注意力分数后,将节点按照注意力分数从大到小排列,再根据图池

化比率筛选节点,最后对输入图进行掩膜,按照保留的节点得到输出图。图1为注意力图池化的结构图。

1.3 读出层

读出层(Readout)通常与图级别分类有关,其主要目的是从图卷积输出的节点特征表示中获得子图或整个图的特征表示。在经过 k 次迭代和注意力图池化后的节点特征向量集合 $\{h_v^{(k)}, v \in V\}$, 经过读出层:


$$h_G = \text{Readout}(\{h_v^{(k)}, v \in V\}) \quad (5)$$

得到整个图的特征向量 h_G 。常用的 $\text{Readout}(\cdot)$ 函数有 Max、Mean、Sum 等函数。

2 数据来源和预处理

2.1 CHB-MIT 数据集

研究采用的 CHB-MIT 数据集是麻省理工学院 EEG (Electro encephalography) 数据库中收录的来自波士顿儿童医院的癫痫脑电信号^[10] (<http://physionet.org/physiobank/database/chb-mit/>)。该数据集是由患有难治性癫痫儿童的头皮脑电组成,共包含来自 22 位受试者的 23 份记录(其中受试者 chb21 是 chb01 同一受试者时隔 1.5 年后再次记录到的)。所有脑电信号均使用 10~20 国际标准电极位置采集,以纵向相邻的两个电极构成一个导联,共有 18 个导联记录两电极的电压差,脑电采样频率和分辨率分别为 256 Hz 和 16 bit。整个数据集包括长达 967.85 h 的连续头皮脑电记录,其中包含 178 次癫痫发作脑电记录。每个 chb 文件中都包含 9~42 次记录,单次记录时长为 1 h(受试者 chb10 为 2 h, 受试者 chb04、chb06、chb07、chb09 和 chb23 的为 4 h)。数据集除了给出了脑电波信号,也给出了每份记录文件中是否含有癫痫发作,若含有癫痫发作则会记录癫痫发作的时间。



注: Top-rank 选择: 排列并筛选节点。

图1 注意力图池化

Fig. 1 Graph pooling of attention

2.2 数据预处理

癫痫脑电一般分为发作间期、发作前期、发作期和发作后期,如图2所示。癫痫发作开始前的一段时间称为发作前期,通常持续几分钟到几十分钟;癫痫发作开始到发作结束所经历的这段时间称为发作期,一般持续数秒钟至数分钟;癫痫发作结束后患者恢复到正常状态所经历的这段时间称为发作后期,通常持续5 min~30 min;发作后期到下一次发作前期所经历的时间称为发作间期,一般持续时间较长,这个时期患者表现的状态和正常人一样。实现癫痫发作预测,需要有效识别癫痫发作前期和发作间期的脑电,准确预测癫痫发作前期。因此,将癫痫脑电信号分为两类,即发作前期癫痫脑电和发作间期癫痫脑电。




图2 癫痫发作的四个时间段

Fig. 2 The four time periods of seizures

由于脑电信号采集中易受到肌电、眼电和工频干扰,且癫痫患者在发作时会出现痫样放电,产生某些特殊的EEG波形,如棘波、尖波、慢波、棘慢复合波和 高频震荡信号等^[11-12]。痫样波的特征频段主要介于0.5 Hz~60 Hz,因此,采用0.5 Hz~60 Hz的带通滤波器和50 Hz的陷波滤波器对脑电信号进行滤波处理和工频干扰去除,并且采用独立成分分析去除眼电、肌电伪迹。利用EEGLAB软件进行脑电信号滤波和去伪迹处理,图3和图4为预处理前后的脑电信号(2 s片段)。

采用重叠采样方法,设置4 s的时间窗口,分别使用2 s,1 s,0.5 s滑动步长,提取癫痫发作前期5 min、10 min、30 min、50 min、90 min以及发作间期的脑电数据,构成训练集、验证集和测试集,数据随机划分比例为7:2:1。表1和表2分别为chb01受试者不同滑动时间步长和不同预测时长的样本数量。

脑电节律提取分别采用0.5 Hz~4 Hz(δ 节律)、4 Hz~8 Hz(θ 节律)、8 Hz~13 Hz(α 节律)、13 Hz~30 Hz(β 节律)、30 Hz~60 Hz(γ




图3 预处理前的脑电信号

Fig. 3 EEG before preprocessing

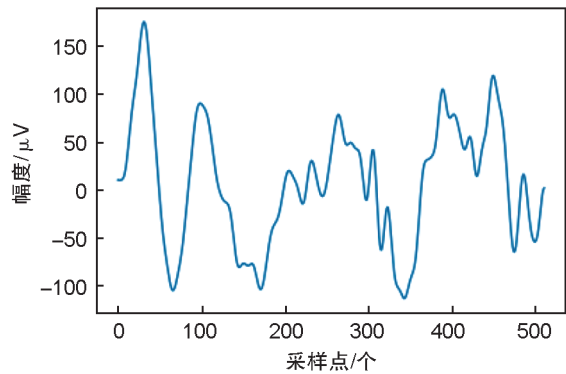


图4 预处理后的脑电信号

Fig. 4 EEG after preprocessing

表1 不同滑动步长的样本数量

Table 1 Sample number of different sliding time

滑动方法	训练样本数量	验证样本数量	测试样本数量
4 s时间窗口2 s滑动	8 183	2 338	1 169
4 s时间窗口1 s滑动	16 352	4 672	2 336
4 s时间窗口0.5 s滑动	32 704	9 344	4 672

表2 不同预测时长的样本数量

Table 2 Sample number of different prediction time lengths

不同预测时长	训练样本数量	验证样本数量	测试样本数量
发作前5 min	7 935	2 267	1 134
发作前10 min	10 875	3 107	1 554
发作前30 min	32 704	9 344	4 672
发作前50 min	36 075	10 307	5 154
发作前90 min	45 321	12 949	6 474

节律)的巴特沃斯带通滤波器实现。

3 基于自注意力图池化的癫痫发作预测

3.1 脑电数据转换及图表示

将脑电的各个导联映射为图的节点,导联

间的相关性映射为图的边,构成图 $G=(V, E)$ 。皮尔逊相关系数可以衡量两个随机变量 X 和 Y 的相关程度。因此采用皮尔逊相关系数表征脑电导联之间的相关性,并根据相关系数矩阵构建图的邻接矩阵。皮尔森相关系数计算公式为:

$$r = \frac{cov(X, Y)}{\sigma_X \sigma_Y}, \quad (6)$$

其中 $cov(X, Y)$ 是信号 X 和 Y 的协方差矩阵, $\sigma_X \sigma_Y$ 为各自标准差的乘积。 r 的值介于 $[-1, 1]$ 之间,当 $|r|$ 越接近 1,表明两个变量越相关。由于邻接矩阵是由 0(节点间无连接)和 1(节点间有连接)构成,计算皮尔逊相关系数后需要设置阈值将其转为邻接矩阵,对每个图计算一个平均皮尔逊相关系数,将此设为阈值,大于该阈值表明两通道相关,将相关系数设置为 1,小于该阈值设置为 0。采用 `torch_geometric` 库函数,将脑电数据转换为图结构矩阵。图 5 和图 6 为受试者 chb20 脑电不同导联的相关系数矩阵和邻接矩阵。

3.2 注意力图池化的图卷积网络模型设计

基于注意力图池化的图卷积网络模型如图 7 所示。

该模型由图输入层、四层切比雪夫图卷积、一层注意力图池化、一层读出层以及全连接层构成。输入的各导联脑电数据经过预处理并计算皮尔森相关系数,将脑电信号转换为节点矩阵和邻接矩阵。输入节点矩阵为 $18 \times 1\ 024$, 其




图5 chb20脑电不同导联相关系数矩阵

Fig. 5 Multichannel correlation coefficient matrix of chb20 EEG




图6 chb20脑电不同导联邻接矩阵

Fig. 6 Multichannel adjacency matrix of chb20 EEG

中,18为脑电导联数,1 024为采样点数;邻接矩阵为 18×18 。第一层图卷积层的数据维度是 18×512 ,第二层的图卷积层的数据维度是

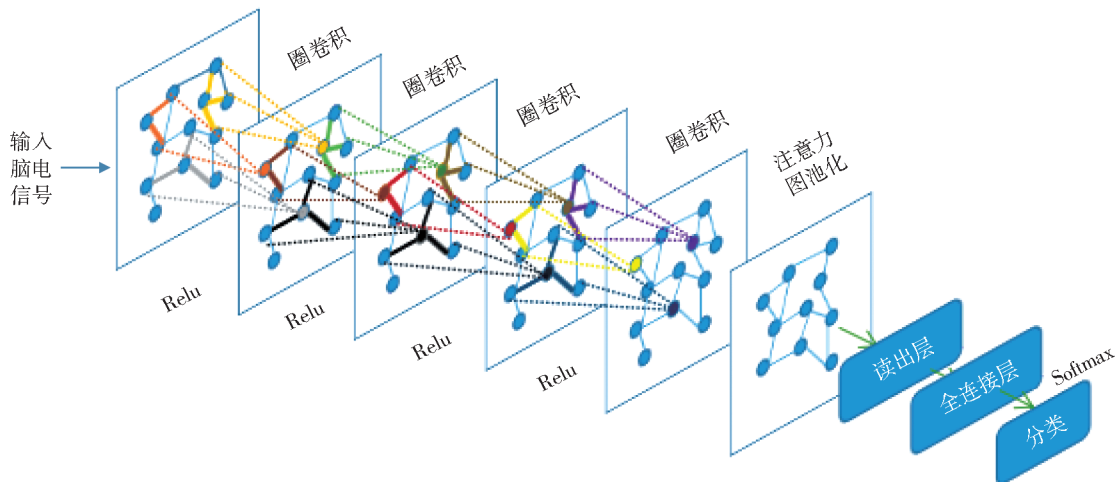


图7 基于注意力图池化的图卷积网络模型

Fig. 7 Graph convolutional network model based on attention graph pooling

18×256,第三层图卷积层数据维度为18×128,第四层图卷积层数据维度为18×64,每层卷积层之间通过 ReLu 线性激活层连接。注意力图池化层的池化比例经仿真优化,设置为0.9。读出层由均值下采样和最大下采样拼接而成,再经过全连接层整合特征,最后通过 softmax 分类器,对癫痫脑电发作前期和发作间期进行分类预测。

3.3 癫痫预测模型实现

设置初始学习率为0.001,并根据迭代次数 epoch 调整学习率,每10次 epoch 学习率减小至上一轮的0.99。模型训练利用 Adam 优化器,采用交叉熵损失函数并加入 dropout 防止过拟合,dropout 参数为0.5,切比雪夫多项式 K 值为3。图8和图9为受试者 chb16 的模型训练和验证的准确率及损失函数曲线。




图8 模型训练和验证的准确率

Fig. 8 Accuracy curves for model training and validation




图9 模型训练和验证的损失函数曲线

Fig. 9 Loss function curves for model training and validation

由图8和图9可知:模型在 epoch 为80次迭代时,预测准确率和损失函数的训练曲线和验证曲线收敛,表明该模型较好地实现了癫痫发

作预测。

3.4 模型性能评价

采用准确率 (Accuracy, Acc)、特异性 (Specificity, Sp)、召回率 (Recall, Re)、F1 值 (F1 Score) 评价预测模型的性能。特异性是指样本中的负类被预测为负类的比例,召回率是指分类正确的正样本个数占真正的正样本个数的比例,F1 值是精确率和召回率的调和平均数,最大为1,最小为0,F1 值越大,表明模型泛化性能越好。

分类准确率为

$$Acc = \frac{TP + TN}{TP + TN + FP + FN}, \quad (7)$$

特异性为

$$Sp = \frac{TN}{FP + TN}, \quad (8)$$

召回率为

$$Re = \frac{TP}{TP + FN}, \quad (9)$$

F1 值为

$$F1 = \frac{2TP}{2TP + FP + FN}, \quad (10)$$

式中: TP 表示将正类预测为正类数,即真正类; FN 表示将正类预测为负类数,即假负类; FP 表示将负类预测为正类数,即假正类; TN 表示将负类预测为负类数,即真负类。采用上述验证的图网络模型对癫痫脑电数据样本进行模型测试,图10为 chb16 受试者癫痫发作前(10 min)模型预测的混淆矩阵。

由图10混淆矩阵的数值和公式(7)–公式(10),可以计算出受试者 chb16 癫痫发作预测




图10 chb16受试者癫痫发作前模型预测的混淆矩阵

Fig. 10 Confusion matrix predicted by the model before seizures of chb16 subject

的准确率为 98.78%, 特异性为 98.47%, 召回率为 98.82%, F1 值为 98.77%。

4 结果分析

4.1 改进模型癫痫预测性能对比分析

为了验证注意力图池化改进模型对癫痫发作预测性能的改善, 对比分析加入注意力图池化的改进图卷积网络模型与传统图卷积网络模型性能的差异。选取癫痫发作前 30 min、时间窗口 4 s 且滑动步长 2 s 的脑电信号, 分别对 8 位受试者进行网络模型测试并对结果取平均, 两种模型性能指标对比如图 11 所示。




图 11 两种模型性能对比

Fig. 11 Performance comparison between the two models

由图 11 可知, 加入注意力图池化的改进模型癫痫发作预测的平均准确率、特异性、召回率、F1 值分别为 94.21%, 95.81%, 93.58%, 93.41%, 传统图卷积神经网络模型的性能指标分别为 92.81%, 95.03%, 92.12%, 91.89%, 各个性能指标均得到提高。从标准差可以看出, 加入注意力图池化后的改进模型更稳健(方差更小)。由此可见, 加入注意力图池化的改进图卷积模型性能均获得改善, 这是因为加入注意力图池化, 可以根据计算得到的注意力分数, 筛选出与癫痫相关的更重要的特征信息, 提高模型的学习能力。

4.2 脑电节律对癫痫预测影响

EEG 信号是一种复合波, 可根据脑电节律划分为五种波形, 每种节律对癫痫不同发作阶段和状态的表现能力各不相同^[13]。选取癫痫发作前 30 min、时间窗口 4 s 且滑动步长 2 s 的脑电




图 12 不同滑动时间窗口的癫痫预测结果

Fig. 12 Epilepsy prediction results of different sliding time windows

信号, 进行带通滤波获得 δ 、 β 、 θ 、 α 、 γ 节律, 分析脑电不同节律对癫痫发作预测的影响, 探寻与癫痫发作预测最为相关的脑电节律, 可为探索癫痫发作机理提供有效参考。不同脑电节律的图模型预测性能指标如表 3 所示。

由表 3 可知, γ 节律癫痫发作预测的准确率最高, 其次为 β 节律, θ 节律的预测准确率最低。 γ 节律相比于 θ 节律预测准确率可提高 11.17%, 表明 γ 节律与癫痫发作更相关, 该节律可反映脑电活动的高频振荡。

4.3 不同滑动时间窗口对癫痫预测影响

癫痫脑电预测与选取的脑电时间窗口大小及窗口滑动步长有关, 不同的滑动时间窗口对癫痫发作预测有不同的影响。为寻找最佳的时间窗口和滑动步长, 选取癫痫发作前 30 min、4 s 时间窗口以及 2 s、1 s、0.5 s 滑动步长的脑电信号, 进行癫痫发作预测, 得到模型预测性能如图 12 所示。

由图 12 可知, 时间窗口为 4 s 且滑动步长 2 s 时, 癫痫发作预测的准确率最低, 为 94.21%; 滑动步长为 0.5 s 时, 预测准确率最高, 为 96.76%, 表明滑动窗口越小, 癫痫发作预测准确率越高。采用 0.5 s 滑动步长比 2 s 滑动步长的预测准确率高 2.55%, 这是因为滑动步长越小, 提取的癫痫脑电数据样本更充分, 因此模型可选用 4 s 时间窗口和 0.5 s 滑动步长进行癫痫发作预测。

4.4 不同预测时长对癫痫发作预测影响

预测癫痫发作前的时间段在临床上具有重要参考价值。采用脑电 4 s 时间窗口和 0.5 s 滑动步

表3 不同脑电节律的癫痫预测性能

Table 3 Predictive performance of different EEG rhythms in epilepsy

	δ 节律	β 节律	θ 节律	α 节律	γ 节律
准确率/(%) (方差)	86.56±7.92	89.25±0.72	82.19±0.02	87.11±0.96	93.36±0.71
召回率/(%) (方差)	82.45±1.60	86.55±2.14	74.23±3.60	82.16±2.42	91.19±2.25
特异性/(%) (方差)	92.75±6.62	94.87±8.72	94.33±14.46	93.64±9.46	96.36±9.22
F1值/(%) (方差)	82.14±2.10	86.01±2.65	72.79±4.59	81.84±2.98	89.86±2.84

表4 不同预测时长的模型预测结果

Table 4 Prediction results of models with different prediction times

	发作前5 min	发作前10 min	发作前30 min	发作前50 min	发作前90 min
准确率/(%) (方差)	97.03±0.01	96.85±0.01	96.76±0.12	89.94±0.45	84.99±9.17
召回率/(%) (方差)	95.89±0.21	95.53±0.29	96.23±0.12	88.63±0.45	78.72±8.77
特异性/(%) (方差)	98.16±0.05	96.11±0.05	96.74±0.14	92.94±0.74	92.83±9.82
F1值/(%) (方差)	96.12±0.18	96.02±0.15	95.84±0.17	88.69±0.46	79.38±8.89

长,对比分析癫痫发作前5 min、10 min、30 min、50 min、90 min的模型预测结果,如表4所示。

由表4可知,癫痫发作前5 min模型预测的准确率、召回率、特异性和F1值均为最高,表明预测性能最好;而且癫痫预测的标准差最小,表明对不同被试预测模型性能最稳健。此外,癫痫发作前10 min模型也可以获得较好的预测效果,发作前50 min预测准确率接近90%,而发作前90 min预测准确率低于85%。表明癫痫发作预测的时间段可选择在5 min~50 min之间,最佳预测性能选择发作前5 min,实际中,综合考虑癫痫发作预测时长和预测性能,可以选择癫痫发作前30 min进行模型预测。

4.5 与现有方法对比

同样使用CHB-MIT数据集进行癫痫发作预测,本文方法较其他方法取得了更好的预测分类结果,如表5所示。与文献[3]采用的短时傅里叶变换和双自注意力残差网络进行分类比较,正确率提高了4.96%,与文献[2]采用的提取脑电时空特征结合支持向量机进行分类比较,正确率提高了5.77%,与文献[14]采用的提取皮尔森相关系数结合卷积神经网络进行分类比较,正确率提高了7.05%。本文方法优于其他方法的原因在于采用的图卷积神经网络充分考虑了脑电的空间结构信息以及注意力图池化选取了重要节点信息,使模型能够更好地学习重要特征,从而获得较高的分类准确率。

表5 同类研究对比

Table 5 Comparison with similar studies

参考文献	采用方法	预测准确率
文献[13]	短时傅里叶变换+双自注意力残差网络	92.07%
文献[2]	时空特征+支持向量机	91.26%
文献[14]	皮尔森相关系数+卷积神经网络	89.98%
本文	图卷积神经网络+注意力图池化	97.03%

5 结束语

本文设计了基于注意力图池化的图卷积神经网络模型对癫痫发作进行准确预测,通过计算通道间的皮尔逊相关系数得到邻接矩阵,采用预处理后的脑电信号作为节点矩阵,充分考虑了脑电通道间的空间位置信息。同时,在图卷积模型中嵌入注意力图池化,通过计算注意力分数,筛选出重要的节点,避免特征冗余。在CHB-MIT癫痫脑电数据集上进行仿真实验,对不同的滑动时间窗口、脑电节律、癫痫预测时长进行对比分析。结果表明:加入注意力图池化的图卷积神经网络模型性能均优于传统的图卷积神经网络模型,且选择脑电 γ 节律,癫痫发作前5 min预测,模型预测性能最好。因此,该模型可以用作癫痫发作预测,并为研究癫痫发作机理提供重要参考价值。

参考文献:

- [1] 周梦妮,崔会芳,曹锐,等.基于排列熵和支持向量机的癫痫发作预测研究[J].计算机应用研究,2019,36(6):1696-1699. DOI: 10.19734/j.issn.1001-3695.2017.12.0816. ZHOU M N, CUI H F, CAO R, et al. Epileptic Seizure

- Prediction Research Based on Permutation Entropy and Support Vector Machine[J]. *Appl Res Comput*, 2019, **36**(6): 1696–1699. DOI: 10.19734/j.issn.1001-3695.2017.12.0816.
- [2] 易芳吉, 钟丽莎, 李章勇. 基于SVM分类器的癫痫脑电时空特征提取方法的研究[J]. *重庆邮电大学学报(自然科学版)*, 2022, **34**(3): 444–450. DOI: 10.3979/j.issn.1673-825X.202011230372.
- YI F J, ZHONG L S, LI Z Y. Research on the Spatio-temporal Feature Extraction of Epileptic EEG Based on SVM Classifier[J]. *J Chongqing Univ Posts Telecommun Nat Sci Ed*, 2022, **34**(3): 444–450. DOI: 10.3979/j.issn.1673-825X.202011230372.
- [3] YANG X W, ZHAO J Q, SUN Q, *et al.* An Effective Dual Self-attention Residual Network for Seizure Prediction[J]. *IEEE Trans Neural Syst Rehabil Eng*, 2021, **29**: 1604–1613. DOI: 10.1109/TNSRE.2021.3103210.
- [4] RYU S, JOE I. A Hybrid DenseNet-LSTM Model for Epileptic Seizure Prediction[J]. *Appl Sci*, 2021, **11**(16): 7661. DOI: 10.3390/app11167661.
- [5] 汤云琪, 郭滨, 李可欣. 基于改进的LSTM癫痫预测算法研究[J]. *长春理工大学学报(自然科学版)*, 2021, **44**(4): 37–42. DOI: 10.3969/j.issn.1672-9870.2021.04.007.
- TANG Y Q, GUO B, LI K X. Research on Epilepsy Prediction Algorithm Based on Improved LSTM[J]. *J Chang Univ Sci Technol*, 2021, **44**(4): 37–42. DOI: 10.3969/j.issn.1672-9870.2021.04.007.
- [6] SINGH K, MALHOTRA J. Prediction of Epileptic Seizures from Spectral Features of Intracranial EEG Recordings Using Deep Learning Approach[J]. *Multimed Tools Appl*, 2022, **81**(20): 28875–28898. DOI: 10.1007/s11042-022-12611-x.
- [7] JIA M H, LIU W J, DUAN J W, *et al.* Efficient Graph Convolutional Networks for Seizure Prediction Using Scalp EEG[J]. *Front Neurosci*, 2022, **16**: 967116. DOI: 10.3389/fnins.2022.967116.
- [8] LIAN Q, QI Y, PAN G, *et al.* Learning Graph in Graph Convolutional Neural Networks for Robust Seizure Prediction[J]. *J Neural Eng*, 2020, **17**(3): 035004. DOI: 10.1088/1741-2552/ab909d.
- [9] DEFFERRARD M, BRESSON X, VANDERGHEYNST P. Convolutional Neural Networks on Graphs with Fast Localized Spectral Filtering[J]. *Advances in Neural Information Processing Systems*, 2016, **29**: 3844–3852. DOI: 10.48550/arXiv.1606.09375.
- [10] SHOEB A. Application of Machine Learning to Epileptic Seizure Onset Detection and Treatment[D]. Cambridge: Massachusetts Institute of Technology, 2009: 27–156.
- [11] 刘志峰. 基于高频振荡信号检测的癫痫发作起始区定位研究[D]. 北京: 北京邮电大学, 2021: 1–78.
- LIU Z F. Localization of Epileptic Seizure Onset Zone Based on High Frequency Oscillations Signal Detection [D]. Beijing: Beijing University of Posts and Telecommunications, 2021: 1–78.
- [12] 彭睿旻, 江军, 匡光涛, 等. 基于EEG的癫痫自动检测: 综述与展望[J]. *自动化学报*, 2022, **48**(2): 335–350. DOI: 10.16383/j.aas.c200745.
- PENG R M, JIANG J, KUANG G T, *et al.* EEG-based Automatic Epilepsy Detection: Review and Outlook[J]. *Acta Autom Sin*, 2022, **48**(2): 335–350. DOI: 10.16383/j.aas.c200745.
- [13] 黄瑞梅, 杜守洪, 陈子怡, 等. 癫痫脑电及节律波的非线性动力学特征研究[J]. *生物医学工程学杂志*, 2014, **31**(1): 18–22. DOI: 10.7507/1001-5515.20140004.
- HUANG R M, DU S H, CHEN Z Y, *et al.* Study on Nonlinear Dynamic Characteristic Indexes of Epileptic Electroencephalography and Electroencephalography Subbands[J]. *J Biomed Eng*, 2014, **31**(1): 18–22. DOI: 10.7507/1001-5515.20140004.
- [14] ZHANG S S, CHEN D, RANJAN R, *et al.* A Lightweight Solution to Epileptic Seizure Prediction Based on EEG Synchronization Measurement[J]. *J Supercomput*, 2021, **77**(4): 3914–3932. DOI: 10.1007/s11227-020-03426-4.