

DOI:10.3969/j.issn.1005-202X.2025.02.011

医学信号处理与医学仪器

多通道时空特征提取的癫痫发作预测模型

额吉纳¹, 喻文杰¹, 费凌霄², 庄君², 梁国华¹, 杨丰¹

1. 南方医科大学生物医学工程学院, 广东 广州 510515; 2. 广东三九脑科医院癫痫内科, 广东 广州 510520

【摘要】提出一种基于多通道时空特征提取的癫痫发作预测模型。该模型首先对原始多通道脑电图(EEG)信号进行斯托克韦尔变换,提取时频成分。针对癫痫发作前期和间期时频特征差异不明显的问题,设计了由ConvNeXt网络、SENet和金字塔池化模块组成的自适应特征提取模块,增强对每个EEG通道内关键时频特征的捕获能力。同时,构建基于Bi-NLSTM的预测模型,增强多通道高阶EEG时频特征之间的时空依赖性,进一步提高癫痫分类性能。在CHB-MIT数据集上,该模型的准确率、灵敏度、特异性和AUC分别达到96.0%、97.8%、96.8%和0.987,每小时假阳性率降至0.038,优于现有主流方法。消融实验验证各组件对提升模型性能的实际效果。本方法通过优化局部时频特征提取和增强多通道时空依赖性,有效提升癫痫发作预测的整体性能。

【关键词】癫痫发作预测;多通道头皮脑电信号;斯托克韦尔变换;自适应特征提取;双向邻域长短期记忆网络

【中图分类号】R318;TP391

【文献标志码】A

【文章编号】1005-202X(2025)02-0213-07

Epileptic seizure prediction model based on multichannel spatiotemporal feature extraction

E Ji'na¹, YU Wenjie¹, FEI Lingxia², ZHUANG Jun², LIANG Guohua¹, YANG Feng¹

1. School of Biomedical Engineering, Southern Medical University, Guangzhou 510515, China; 2. Department of Epilepsy, Guangdong Sanjiu Brain Hospital, Guangzhou 510520, China

Abstract: A novel epileptic seizure prediction model based on multichannel temporal and spatial feature extractions is presented. The model applies Stockwell transform to the original multichannel electroencephalogram (EEG) signals for extracting time-frequency components. To address the issue of insignificant difference between pre-seizure and inter-seizure time-frequency features, an adaptive feature module composing of ConvNeXt, SENet and pyramid pooling module is designed to enhance the ability of capturing key time-frequency features in each EEG channel. Meanwhile, a prediction model based on Bi-NLSTM is constructed to improve the spatiotemporal dependence between the time-frequency features of multichannel high-order EEG for further promoting the epilepsy classification performance. On the CHB-MIT dataset, the model has an accuracy, sensitivity, specificity and AUC of 96.0%, 97.8%, 96.8% and 0.987, respectively, and the false positive rate per hour decreased to 0.038, outperforming the existing mainstream methods. In addition, the effect of each component on the model performance is verified by ablation study. The proposed method improves the overall performance for seizure prediction effectively by optimizing local time-frequency feature extraction and enhancing multichannel spatiotemporal dependence.

Keywords: epileptic seizure prediction; multichannel scalp EEG signal; Stockwell transform; adaptive feature extraction; bidirectional neighborhood long short-term memory network

前言

癫痫是一种常见的神经系统疾病,严重影响患者的生活质量。脑电图(Electroencephalogram, EEG)

能直观反映癫痫发作时大脑活动的变化,被广泛用作观测癫痫发作的基础信号^[1-2]。精准的癫痫发作预测有助于提高癫痫患者的生活质量,为患者提供早期医疗干预和及时的心理疏导^[3]。目前,基于EEG的癫痫发作预测方法主要包括传统方法、机器学习方法和深度学习方法。早期的阈值法预测性能不佳^[4-6],机器学习方法虽然具有较高的发作前状态检测精度,但泛化能力有限^[7-10]。近年来,基于卷积神经网络(Convolutional Neural Networks, CNN)的深度学习方法取得显著进展,但在处理信号时间依赖性

【收稿日期】2024-10-17

【基金项目】国家自然科学基金(61771233)

【作者简介】额吉纳,硕士研究生,研究方向:癫痫发作预测, E-mail: 934250561@qq.com

【通信作者】杨丰,博士,教授,博士生导师, E-mail: yangf@smu.edu.cn

方面仍存在局限性^[11-12]。为解决这一局限,研究者引入时间序列建模技术,提出结合CNN与循环神经网络(Recurrent Neural Network, RNN)的混合模型,在时序建模方面取得突破。Ryu等^[13]设计结合DenseNet与长短期记忆网络(Long Short-Term Memory, LSTM)的模型^[14],进一步增强EEG信号的时间依赖性建模,提升分类性能。Sun等^[15]进一步提出一种通道注意力双输入卷积神经网络(CADCNN),引入通道注意力机制,能够动态调整每个通道的权重,识别出最为关键的脑电通道,提升预测性能。然而,这些模型仍未能充分捕捉EEG信号在时间演化过程中的动态交互,难以建模大脑不同区域之间的时空依赖关系和相互作用。要实现更准确的癫痫发作预测,模型不仅需要精细提取各通道的时频特征,还需实时建模大脑区域之间的复杂动态交互。

针对现有研究在时频特征提取和时空依赖建模方面的不足,本文提出一种多通道时空特征提取的癫痫发作预测算法。主要工作包括:(1)采用斯托克韦尔变换(Stockwell Transform, ST)对EEG信号进行时频变换,精确呈现发作前期和间期信号的时频特征。(2)设计一种多通道自适应特征学习模型,并行处理每个EEG通道的时频图。该模型中的自适应特征模块集成了ConvNeXt卷积网络、SENet和金字塔池化模块(Pyramid Pool Module, PPM),能够确保特征提取的准确性,从而为后续的时空建模提供高质量的输入特征。(3)采用基于Bi-NLSTM的分类网络作为后端分类器,挖掘EEG信号的时空依赖性,捕捉多通道之间的复杂动态交互。在CHB-MIT数据集上的实验结果表明,本模型可以有效提升癫痫发作的预测性能。

1 方法

1.1 数据收集及处理

CHB-MIT数据集由美国波士顿儿童医院和麻省理工学院合作建立,包含儿童癫痫患者的EEG数据。该数据集包含23名患者的EEG数据,这些数据均经过专家标注。患者年龄为1.5~22.0岁,总计198次癫痫发作记录,见表1。由于CHB-MIT数据集在规范性方面存在较大差异,本研究对其进行筛选,以选择适合实验的子集。筛选标准包括:(1)在癫痫发作前至少包含35 min的无发作记录;(2)使用最后连续的EEG记录补充不足35 min的数据;(3)EEG记录的间隔不超过5 s。此外,考虑患者的发作频率,本研究仅选择每日发作次数少于10次的患者资料用于预测任务,排除了发作频率过高的患者,因其已需要实时监护或手术干预。最终筛选出16名患者的数据用于研究。

表1 CHB-MIT数据集的主要统计信息
Table 1 Main statistics of CHB-MIT database

| 数据编号 | 性别 | 年龄/岁 | 发作次数 | 总发作时间/s |
|-------|----|------|------|---------|
| chb01 | 女 | 11 | 7 | 442 |
| chb02 | 男 | 11 | 3 | 172 |
| chb03 | 女 | 14 | 7 | 402 |
| chb04 | 男 | 22 | 4 | 378 |
| chb05 | 女 | 7 | 5 | 558 |
| chb06 | 女 | 1.5 | 10 | 153 |
| chb07 | 女 | 14.5 | 3 | 325 |
| chb08 | 男 | 3.5 | 5 | 919 |
| chb09 | 女 | 10 | 4 | 276 |
| chb10 | 男 | 3 | 7 | 447 |
| chb11 | 女 | 12 | 3 | 806 |
| chb12 | 女 | 2 | 40 | 1475 |
| chb13 | 女 | 3 | 12 | 535 |
| chb14 | 女 | 9 | 8 | 169 |
| chb15 | 男 | 16 | 20 | 1992 |
| chb16 | 女 | 7 | 10 | 84 |
| chb17 | 女 | 12 | 3 | 293 |
| chb18 | 女 | 18 | 6 | 317 |
| chb19 | 女 | 19 | 3 | 236 |
| chb20 | 女 | 6 | 8 | 294 |
| chb21 | 女 | 13 | 4 | 199 |
| chb22 | 女 | 9 | 3 | 204 |
| chb23 | 女 | 6 | 7 | 424 |
| chb24 | - | - | 16 | 511 |

chb01和chb21是同一患者不同年龄段数据

1.1.1 电极通道选择与数据平衡 数据集中,大多数患者使用不同的电极配置,因此本研究选择18个相同的通道,包括FP1-F7、F7-T7、T7-P7、P7-O1、FP1-F3、F3-C3、C3-P3、P3-O1、FP2-F4、F4-C4、C4-P4、P4-O2、FP2-F8、F8-T8、T8-P8、P8-O2、FZ-CZ和CZ-PZ,其余的EEG数据则被排除。为了平衡发作间期和发作前期的样本数量,本研究对发作间期的数据进行下采样,使其与发作前期的数据量相当。

1.1.2 滑动窗口划分与时频分析 考虑到EEG信号具有非平稳特性和癫痫发作预兆的瞬时性,本研究采用滑动窗口的方式对连续的EEG记录进行划分。综合考虑EEG节律的特点和计算效率,本研究选择1 s的窗口长度,并以无重叠的方式在时间轴上滑动,将每个EEG片段转化为一个 $C \times T$ 的矩阵(C 为通道数, T 为时间点数)。为了进一步探索EEG片段中蕴含的

时频域预兆信息,本文引入了ST^[16]。ST是一种时频变换方法,通过自适应的滑动窗口,在保持时间分辨率的同时提供良好的频率分辨率。通过对每个通道的EEG片段进行ST变换,将一维时域信号转化为二维时频矩阵(图1)。ST变换的数学表达式为:

$$S_x(\tau, d) = \frac{|f|}{\sqrt{2\pi}} \int_{-\infty}^{\infty} x(t) \exp\left(-\frac{f^2(\tau - t)^2}{2} - j2\pi ft\right) dt \quad (1)$$

其中, f 表示频率, d 是 f 的倒数($d=1/f$)。ST的窗口宽度取决于频率 f ,在低频下增加以获得高频率分辨率,在高频下减小以获得高时间分辨率。与传统的预处理方法不同,本文没有对EEG信号进行滤波,因为已有研究表明高频振荡是癫痫发作前期的重要标志物。

1.2 多通道时空特征提取的癫痫发作预测方法

本研究提出的方法如图2所示。首先,多通道自

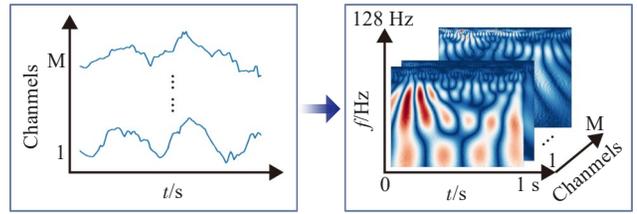


图1 EEG片段的斯托克韦尔时频变换

Figure 1 Stockwell time-frequency transform of an EEG segment

适应特征学习模型并行处理每个EEG通道的时频图,利用自适应特征模块提取关键时频特征。接着,每个通道的时频特征分别输入到对应的Bi-NLSTM层中,Bi-NLSTM分类网络建模各通道之间的时空交互关系,捕捉多通道EEG信号中的复杂依赖性,从而提升癫痫发作预测的准确性和稳健性。

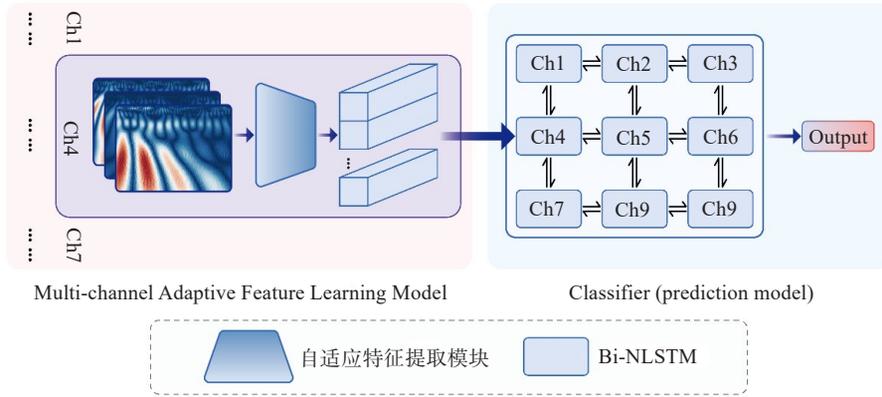


图2 多通道时空特征提取与癫痫发作预测模型架构

Figure 2 Architecture of multichannel spatiotemporal feature extraction and epileptic seizure prediction model

1.2.1 多通道自适应特征学习模型 本文提出的多通道自适应特征学习模型专门用于从每个EEG通道中独立提取高级时频特征。每个EEG通道都配备了一个自适应特征提取模块,这些模块结构一致,并共享参数,以确保特征提取的一致性和计算效率。通过对每个通道的特征进行独立处理,这种设计有效避免了多通道时频图堆叠所导致的特征提取能力下降问题,并为后续分类网络提供精确的高级时频特征输入,使其能够更有效地建模各通道之间的时空交互信息。

自适应特征提取模块的设计如图3所示,负责提取每个通道的时频特征。该模块借鉴了ConvNeXt卷积神经网络的架构,采用分层结构,将网络划分为多个阶段,并按1:1:3:1的比例进行模块分配。通过

使用7×7的大卷积核,模块能够扩大感受野,捕捉更多上下文信息。此外,残差连接的引入有助于梯度的稳定传播,提升模型的收敛速度。Layer Normalization和GELU激活函数进一步增强训练过程的稳定性,并提升模型的泛化能力。在ConvNeXt架构的基础上,自适应特征模块还集成了SENet^[17]。SENet模块嵌入在每个卷积块内部,在卷积处理后加入。通过全局平均池化,SENet对特征图进行压缩,生成全局特征向量,并通过全连接层学习不同通道之间的依赖关系,动态调整各通道的权重。这样模型能够自适应地突出癫痫发作预测相关的重要特征,同时抑制无关信息。为了进一步增强对多尺度时频特征的捕捉,自适应特征提取模块在最后一个阶段引入PPM^[18]。PPM通过不同大小的池化核从多

个感受野中提取特征,经过 1×1 卷积调整通道数后,再通过上采样恢复到原始特征图的尺寸。然后,这些多尺度特征与原始特征图进行通道拼接,形成增强的特征图。通过这种多尺度特征融合,自适应特征模块能够更好地捕捉不同时频尺度上的特征变化,提升对时频信息的表达能力。

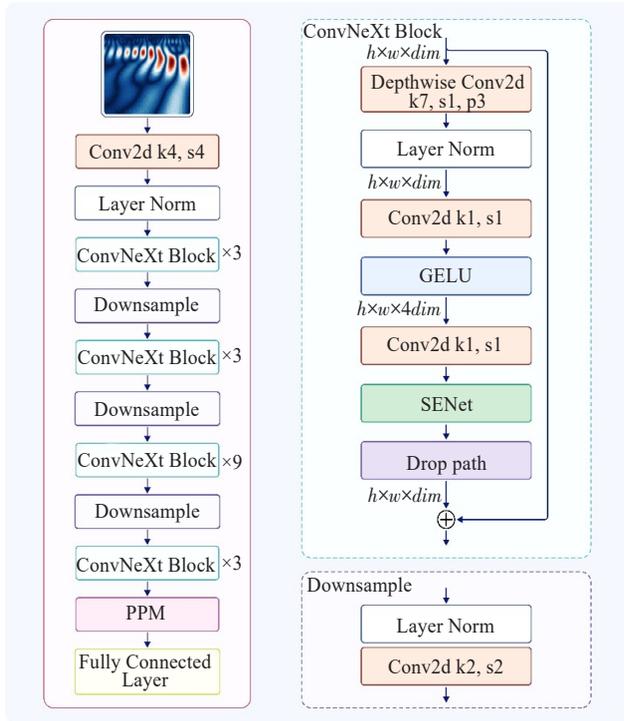


图3 自适应特征提取模块结构

Figure 3 Adaptive feature extraction module structure

1.2.2 分类模型 在多通道特征提取器生成高级时频特征后,分类模型需要自适应地学习这些特征,并将输入数据分类为发作前期或发作间期,同时输出相应的预测概率。由于大脑活动不仅依赖于过去的信号,还与未来的信号及邻近脑区的信号密切相关,因此,分类模型必须具备对这些时空相关性进行有效建模的能力。为实现这一目标,本文采用Bi-NLSTM作为分类模型的核心部分。Bi-NLSTM将时间序列和邻近单元的输出特征输入至两个NLSTM模块,分别在前向和后向两个相反方向上进行学习。在前向传播学习过程中,将多通道自适应特征学习模型生成的高级时频特征(X_1, \dots, X_n)以及邻近单元的输出特征(N_0, \dots, N_n)依次输入到后续的网络层中;在后向传播学习中,这些数据则以相反顺序,从 X_n 到 X_1 以及从 N_n 到 N_0 进行处理。通过这种双向学习,Bi-NLSTM能够有效捕捉时间依赖关系。

本研究将多通道自适应特征学习模型作为特征提取器,用于提取多通道EEG信号的时频图特征,并

将其与基于Bi-NLSTM构建的分类网络相结合,组成分类器模型。该分类器模型采用多通道阵列结构,如图4所示。首先,多通道自适应特征学习模型用于独立处理每个EEG通道,提取高级时频特征。提取的特征展平后,通过全连接层降维至32维,以减少计算复杂度并提升后续建模效率。接着,每个通道的时频特征分别输入至对应的Bi-NLSTM层。这些Bi-NLSTM层不仅独立捕捉每个通道的时序特征,还通过跨通道建模来反映通道间的动态交互,从而有效提取多通道EEG信号中的复杂时空依赖关系。这种设计显著增强了模型对癫痫发作预测的准确性和鲁棒性。最后,所有Bi-NLSTM层的输出特征被聚合为全局特征,输入至全连接层,并利用Softmax激活函数生成发作前期与发作间期的分类预测结果。

1.3 训练细节

本研究在配备NVIDIA GeForce RTX 4060 Ti显卡的计算机上,使用PyTorch深度学习框架构建和训练模型。为充分利用有限的的数据并评估模型性能,本研究对每位患者数据采用留一法交叉验证(Leave-One-Out, LOO)策略。在每次迭代中,将一次发作事件作为测试集,其余事件的数据用于训练和验证,重复LOO过程 N 次,获得对模型整体性能的可靠估计。在模型训练过程中,本研究采用二元交叉熵损失函数作为优化目标,其适用于癫痫发作预测的二分类问题,衡量模型预测概率与真实标签之间的差异。二值交叉熵损失的计算公式如下:

$$L_{BCE} = -\frac{1}{N} \sum_{i=1}^N \left[y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i) \right] \quad (2)$$

其中, N 表示样本数量, y_i 表示第 i 个样本的真实二元标签(0表示发作间期,1表示发作前期), \hat{y}_i 表示第 i 个样本的预测发作概率。通过最小化该损失函数,模型可以学习调整其预测概率,使其尽可能接近真实标签。本研究选择Adam优化器,设置初始学习率为0.0001, batch size为64,训练轮数为20。为防止过拟合,应用了0.3的dropout正则化技术。训练终止条件为连续5轮训练后模型损失无明显下降。本研究持续监测模型在验证集上的评价指标,并保存性能最优的模型参数。考虑到癫痫发作预测的特殊性,引入癫痫发作预测视界(Seizure Prediction Horizon, SPH)和癫痫发作发生期(Seizure Onset Period, SOP)的概念。参考先前研究^[9],设定SOP为30 min,SPH为5 min,以确保评估结果与临床实践相关并具有可比性。

2 实验结果

2.1 消融实验

为验证本研究提出的多通道时空特征提取的癫痫发作预测模型中各组件的有效性,设计一系列

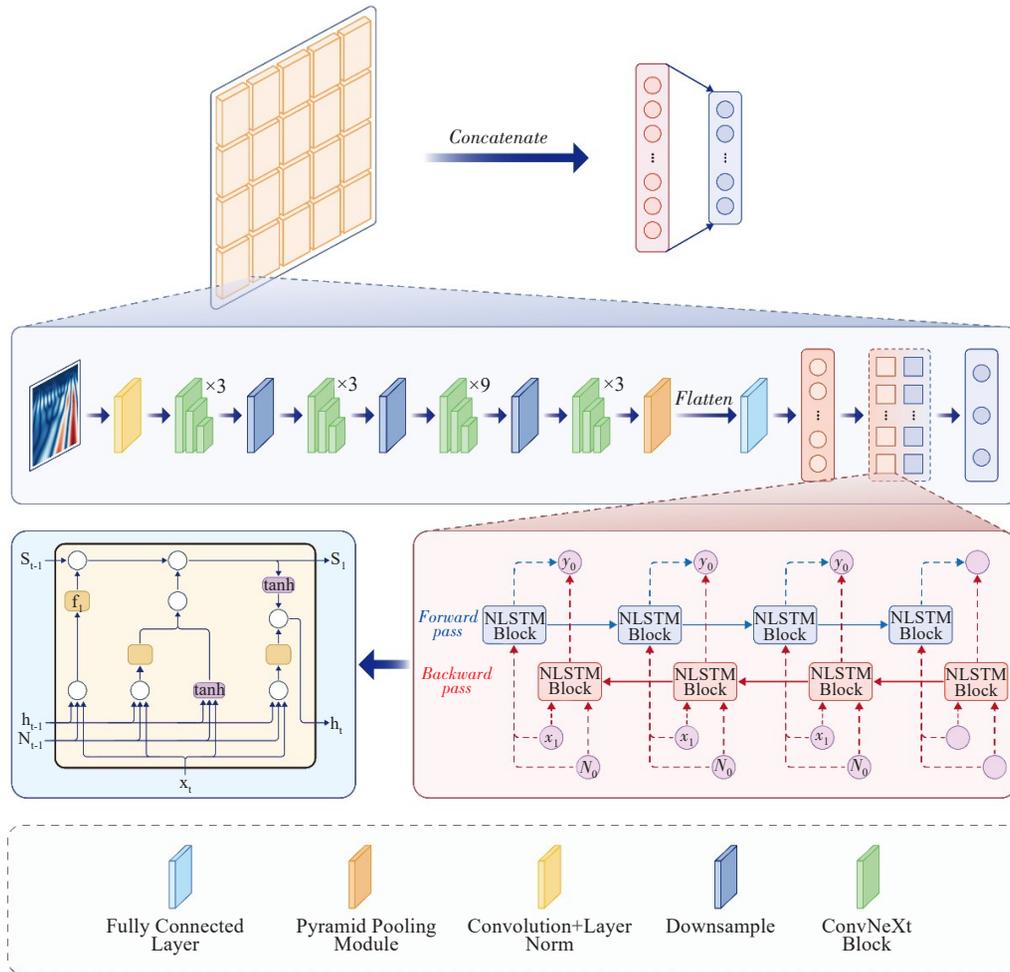


图4 分类器模型的网络结构

Figure 4 Architecture of the classifier model

消融实验,逐步引入不同模块以验证其对模型性能的影响(表2),并在公开的CHB-MIT数据集上进行评估。以基础模型M1(DCNN+Bi-LSTM)为基准^[20],结果显示其准确率、灵敏度和接受者操作特征曲线下面积(Area Under Curve, AUC)均较低,主要因其仅关注局部特征,未能充分捕捉全局时空依赖关系。在M1基础上,引入基于Bi-NLSTM的分类网络,同时将前端DCNN替换为多通道DCNN特征提取器(每个EEG通道对应一个共享参数的独立DCNN),构建M2模型。引入Bi-NLSTM层使模型更好地捕捉EEG信号的动态依赖性,M2的灵敏度提升至91.0%,特异性提升至88.0%,AUC提升至92.0%。M3在M2基础上扩展Bi-NLSTM层的邻域连接范围至8个层,包括对角线方向,进一步提升了模型捕捉EEG信号空间传播特征的能力,灵敏度和特异性分别达到93.0%和89.5%,AUC达到93.5%。在M4模型中,将多通道DCNN特征提取器替换为多通道ConvNeXt特征提取器,通过大卷积核和逆

瓶颈结构增强特征提取能力,准确率达到93.5%,AUC为95.0%。M5在M4基础上加入SENet模块,自适应调整各通道权重,提升关键特征关注度,准确率和AUC分别提高至95.0%和96.5%。M6在M5基础上引入PPM,实现多尺度特征融合,增强对不同时频尺度特征的捕捉能力,最终达到最优性能,灵敏度为97.8%、特异性为96.8%、AUC为98.7%。实验结果表明,逐步引入Bi-NLSTM、多通道ConvNeXt特征提取器、SENet和PPM,有效提高模型对癫痫发作预测的准确性和稳健性。

2.2 与其他主流方法的比较

本文提出的多通道时空特征提取的癫痫发作预测模型表现优异。为评估其优越性,本研究选取了近期6种深度学习方法作为基准进行比较,性能比较结果见表3。

Sui等^[21]和Zhang等^[22]分别提出TFHybridNet和CSP+CNN模型,采用短时傅里叶变换(STFT)和小波包分解提取脑电时频特征,并使用CNN进行特征学

表2 CHB-MIT数据集上的消融研究
Table 2 Ablation study on the CHB-MIT dataset

| 模型 | 准确率/% | 特异性/% | 灵敏度/% | AUC | FPR/h |
|----|-------|-------|-------|-------|-------|
| M1 | 81.5 | 76.3 | 87.2 | 0.823 | 0.275 |
| M2 | 90.0 | 88.0 | 91.0 | 0.920 | 0.200 |
| M3 | 93.0 | 89.5 | 93.0 | 0.935 | 0.170 |
| M4 | 93.5 | 91.0 | 94.5 | 0.950 | 0.130 |
| M5 | 95.0 | 93.0 | 95.5 | 0.965 | 0.090 |
| M6 | 96.5 | 96.8 | 97.8 | 0.987 | 0.038 |

FPR/h: 每小时假阳性率

表3 不同方法在CHB-MIT数据集上的实验结果比较

Table 3 Comparison of experimental results of different methods on the CHB-MIT dataset

| 模型 | 准确率/% | 特异性/% | 灵敏度/% | AUC | FPR/h |
|-----------------------------------|-------|-------|-------|-------|-------|
| TFHybridNet ^[21] | 94.30 | 94.30 | 94.30 | - | 0.220 |
| CSP+CNN ^[22] | 90.00 | - | 92.20 | - | 0.120 |
| DWT+DenseNet+LSTM ^[13] | 93.28 | 93.65 | 92.92 | 0.933 | 0.063 |
| Dilated CNN ^[24] | - | - | 93.30 | - | 0.007 |
| STFT+ResNet+LSTM ^[23] | 91.90 | 94.20 | 89.64 | 0.942 | 0.058 |
| CADCNN ^[15] | - | 95.60 | 97.10 | - | 0.029 |
| 本文方法 | 96.50 | 96.80 | 97.80 | 0.987 | 0.038 |

最佳表现。与DWT+DenseNet-LSTM方法相比,准确率、灵敏度、特异性和AUC分别提高2.72%、4.88%、3.15%和0.054,每小时假阳性率(False Positive Rate per Hour, FPR/h)降低0.025;与CADCNN相比,灵敏度提高0.7%,特异性提高1.2%。

3 结论

本文提出多通道时空特征提取的癫痫发作预测模型。该模型将多通道自适应特征学习模块作为特征提取器,并结合基于Bi-NLSTM构建的分类网络,形成一个创新性分类器模型,能有效提取多通道EEG信号中的复杂时空依赖关系。实验结果表明,本文提出的模型在多项指标上均显著优于现有公开癫痫发作预测模型,且各个组件对模型性能的提升均有积极作用,证明了所提方法在癫痫发作预测任务中的优越性。未来工作将引入迁移学习策略,以提升模型在新患者上的泛化能力,并开发自适应通道筛选和无监督伪影清洗方法,以进一步增强模型的实用性和临床应用潜力。

【参考文献】

[1] Mahmoodian N, Haddadnia J, Illanes A, et al. Seizure prediction with cross-higher-order spectral analysis of EEG signals[J]. Signal Image Video Process, 2020, 14(4): 821-828.

习,但未能有效捕捉时间依赖关系,性能较低。Ryu等^[13]和Lee等^[23]分别提出DWT+DenseNet-LSTM和STFT+ResNet+LSTM模型,引入LSTM增强时间建模能力,相较于Zhang等^[22]方法,Ryu等^[13]方法在准确率、灵敏度上分别提高3.28%、0.72%,但这些方法未充分考虑空间依赖。Gao等^[24]提出Dilated CNN模型,通过多尺度CNN模拟时空关系,整体效果有限。Sun等^[15]提出的CADCNN模型引入通道注意力机制,提升了性能,但未能捕捉通道间动态交互。本文提出的模型在所有评价指标上均取得

- [2] Hussein R, Palangi H, Ward RK, et al. Optimized deep neural network architecture for robust detection of epileptic seizures using EEG signals[J]. Clin Neurophysiol, 2019, 130(1): 25-37.
- [3] Kuhlmann L, Lehnertz K, Richardson MP, et al. Seizure prediction-ready for a new era[J]. Nat Rev Neurol, 2018, 14(10): 618-630.
- [4] 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 CM, Peng FL, Chen C, et al. Research progress of epileptic seizure predictions based on electroencephalogram signals[J]. Journal of Biomedical Engineering, 2021, 38(6): 1193-1202.
- [5] Massoud YM, Abdelzاهر M, Kuhlmann L, et al. General and patient-specific seizure classification using deep neural networks[J]. Analog Integr Circuits Signal Process, 2023, 116(3): 205-220.
- [6] Shahidi Zandi A, Tafreshi R, Javidan M, et al. Predicting epileptic seizures in scalp EEG based on a variational Bayesian Gaussian mixture model of zero-crossing intervals[J]. IEEE Trans Biomed Eng, 2013, 60(5): 1401-1413.
- [7] Mühlberg K, Müller J, Tetzlaff R. Seizure prediction by multivariate autoregressive model order optimization[J]. Curr Dir Biomed Eng, 2018, 4(1): 395-398.
- [8] Osman AH, Alzahrani AA. New approach for automated epileptic disease diagnosis using an integrated self-organization map and radial basis function neural network algorithm[J]. IEEE Access, 2019, 7: 4741-4747.
- [9] 张瑞,宋江玲,胡文凤.癫痫脑电的特征提取方法综述[J].西北大学学报(自然科学版),2016,46(6): 781-788.
- Zhang R, Song JL, Hu WF. A review of feature extraction method for epileptic EEGs[J]. Journal of Northwest University (Natural Science Edition), 2016, 46(6): 781-788.
- [10] Bou Assi E, Nguyen DK, Rihana S, et al. Towards accurate prediction of epileptic seizures: a review[J]. Biomed Signal Process Control, 2017, 34: 144-157.
- [11] Khan H, Marcuse L, Fields M, et al. Focal onset seizure prediction using convolutional networks[J]. IEEE Trans Biomed Eng, 2018, 65(9): 2109-2118.

- [12] Liu CL, Xiao B, Hsaio WH, et al. Epileptic seizure prediction with multi-view convolutional neural networks[J]. IEEE Access, 2019, 7: 170352-170361.
- [13] Ryu S, Joe I. A hybrid DenseNet-LSTM model for epileptic seizure prediction[J]. Appl Sci, 2021, 11(16): 7661.
- [14] 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.
Tang YQ, Guo B, Li KX. Research on epilepsy prediction algorithm based on improved LSTM[J]. Journal of Changchun University of Science and Technology (Natural Science Edition), 2021, 44(4): 37-42.
- [15] Sun B, Lü JJ, Rui LG, et al. Seizure prediction in scalp EEG based channel attention dual-input convolutional neural network [J]. Phys A, 2021, 584: 126376.
- [16] Kaur N, Gupta B, Verma AK, et al. Offset linear canonical Stockwell transform for boehmians [J]. Mathematics, 2024, 12 (15): 2379.
- [17] Ovalle-Magallanes E, Avina-Cervantes JG, Cruz-Aceves I, et al. LRSE-net: lightweight residual squeeze-and-excitation network for stenosis detection in X-ray coronary angiography [J]. Electronics (Basel), 2022, 11(21): 3570.
- [18] Yang JH, Zhang Y, Liu Y, et al. Automatic segmentation of cervical precancerous lesions in colposcopy image using pyramid scene parsing network and transfer learning [J]. Rev Comput Eng Stud, 2023, 10(2): 28-34.
- [19] 廖家慧, 李涵懿, 詹长安, 等. 癫痫发作预测模型: 斯托克韦尔变换的生成对抗与长短时记忆网络半监督方法[J]. 南方医科大学学报, 2023, 43(1): 17-28.
Liao JH, Li HY, Zhan CA, et al. Construction of an epileptic seizure prediction model using a semi-supervised method of generative adversarial and long short term memory network combined with Stockwell transform [J]. Journal of Southern Medical University, 2023, 43(1): 17-28.
- [20] Daoud H, Bayoumi MA. Efficient epileptic seizure prediction based on deep learning [J]. IEEE Trans Biomed Circuits Syst, 2019, 13(5): 804-813.
- [21] Sui LF, Zhao XY, Zhao QB, et al. Hybrid convolutional neural network for localization of epileptic focus based on iEEG [J]. Neural Plast, 2021, 2021: 6644365.
- [22] Zhang Y, Guo Y, Yang P, et al. Epilepsy seizure prediction on EEG using common spatial pattern and convolutional neural network [J]. IEEE J Biomed Health Inform, 2020, 24(2): 465-474.
- [23] Lee D, Kim B, Kim T, et al. A ResNet-LSTM hybrid model for predicting epileptic seizures using a pretrained model with supervised contrastive learning [J]. Sci Rep, 2024, 14(1): 1319.
- [24] Gao YK, Chen X, Liu AP, et al. Pediatric seizure prediction in scalp EEG using a multi-scale neural network with dilated convolutions [J]. IEEE J Transl Eng Health Med, 2022, 10: 4900209.

(编辑: 薛泽玲)