

文章编号: 2095-2163(2024)02-0069-07

中图分类号: R742.1; TP181; TN911.7

文献标志码: A

基于 Bi-LSTM-Attention 的癫痫发作检测方法

龚帅奎, 蒋路茸, 范骥凯

(浙江理工大学 信息科学与工程学院, 杭州 310018)

摘要: 本文针对癫痫脑电图(EEG)信号中的发作检测问题,分析了癫痫患者 EEG 信号中的特异性特征,在传统 EEG 信号时频域基础上提出了改进的脑网络特征。本文对 EEG 信号进行分解,并重构了 EEG 信号,发现在重构信号上癫痫发作和癫痫未发作表现出较大差异。因此在重构 EEG 信号上通过皮尔逊系数(PCC)构建脑网络,并在该网络上提取脑网络特征,最后将这些特征输入 Bi-LSTM-Attention 混合网络检测癫痫发作。该网络可以筛选出对癫痫发作检测结果具有决定性因素的特征,捕捉 EEG 时间序列中最重要的信息。为了评估本文的方法,在公开的 CHB-MIT 数据集上进行实验,获得了 96.20% 的准确率,96.80% 的特异性和 95.31% 的敏感性,实验结果表明该方法在癫痫发作检测这个任务上具有不错的性能。

关键词: 癫痫发作检测; 小波包变换; EEG; Bi-LSTM-Attention

A seizure detection method based on Bi-LSTM-Attention

GONG Shuaikui, JIANG Lurong, FAN Qikai

(School of Information Science and Engineering, Zhejiang Sci-Tech University, Hangzhou 310018, China)

Abstract: This study focuses on seizure detection within electroencephalogram (EEG) signals for epilepsy patients, analyzing distinctive features in epileptic EEG signals and introducing improved brain network characteristics based on the traditional EEG signal time-frequency domain. The paper involves the decomposition and subsequent reconstruction of EEG signals, revealing substantial differences between seizure and non-seizure states in these reconstructed signals. Consequently, a brain network is constructed on the reconstructed EEG signals using the Pearson Correlation Coefficient (PCC), from which brain network features are extracted. These features are then fed into a Bi-LSTM-Attention hybrid network to detect epileptic seizures. This network is capable of identifying key features crucial for the detection of epileptic seizures and capturing the most significant information in the EEG time series. To assess the effectiveness of this method, experiments were conducted on the publicly available CHB-MIT dataset, yielding an accuracy of 96.20%, a specificity of 96.80%, and a sensitivity of 95.31%. The results indicate that this method is highly effective in the task of epilepsy seizure detection.

Key words: seizure detection; wavelet packet transform; electroencephalogram; Bi-LSTM-Attention

0 引言

癫痫是因人的大脑神经元异常放电所致的一种慢性神经系统疾病,其临床表现为突发性身体痉挛、无意识动作、失神等。在临床上,EEG 作为测量大脑神经元电活动的常用技术,被广泛地应用于癫痫的诊断和治疗。头皮 EEG 信号是通过放置在头皮上的电极采集得到,这种采集方式由于具有非侵入性、廉价、方便的特点,被广泛应用于癫痫发作的检

测和诊断中^[1]。

基于癫痫发作时脑电波的异常样放电,EEG^[2]信号处理得到的特征可以作为癫痫发作的特异性指标。这些特征一般分为时域、频域、时频域 3 类。时域特征是对 EEG 进行传统统计学参数的计算,进而研究癫痫发作期和非发作期时域波形的差异。Sharmila A 等^[3]在时域上提取了斜率和波形长度等时域特征,并在朴素贝叶斯和支持向量机上进行判别脑电波形是否为癫痫发作期波形。频域特征则是在信号经过傅里叶变换的基础上,提取信号的频域

基金项目: 浙江省重点研发计划(2022C03136); 国家自然科学基金(61602417)。

作者简介: 龚帅奎(1997-),男,硕士研究生,主要研究方向:深度学习、脑电信号处理;范骥凯(1999-),男,硕士研究生,主要研究方向:机器学习、脑电信号处理。

通讯作者: 蒋路茸(1982-),男,博士,副教授,主要研究方向:网络安全与网络动力学、生物信号处理。Email: jianglurong@zstu.edu.cn

收稿日期: 2023-02-26

成分及频域能量分布来进行癫痫发作检测。EEG 信号的时频域特征^[4]则是结合时域和频域的信息进行特征提取,常见的分析方法有短时傅里叶变换 (Short-Term Fourier Transform, STFT)^[5],离散小波变换 (Discrete Wavelet Transform, DWT)^[6],连续小波变换 (Continuous Wavelet Transform, CWT)^[7]等。Chen D 等人^[8]应用 DWT 检测癫痫发作,研究发现 DWT 对癫痫发作检测性能有较大影响。

在癫痫发作检测方面,研究人员主要通过人工设计有效的特征和改进分类器模型来提高癫痫发作检测的性能。Ansari A H 等^[9]将手工提取的特征用随机森林模型进行自动优化选择,并采用卷积神经网络 (Convolutional Neural Networks, CNN) 替代传统机器学习的分类器。由于卷积神经网络提取的仅仅只是局部特征,并没有时间上的连续性,而对于具有时序性的 EEG 信号来说,长短时期记忆网络 LSTM 的网络结构能够更好的解释时序序列。Shekokar K S 等^[10]利用 3 层的长短时期记忆网络 (Long Short-Term Memory Networks, LSTM) 进行癫痫发作检测。Geng M 等^[11]将原始脑电波进行 Stockwell 变换,再输入到双向长短时期记忆网络 (Bidirectional Long Short-Term Memory Network, Bi-LSTM) 进行癫痫发作检测,表明了 LSTM 能够良好的应用在 EEG 时序信号上。但是,长短时期记忆网络 (LSTM) 模型始终具有有限的记忆内容,而注意力机制则是不同于

CNN 和 LSTM 的一种模块,其可以对全局信息进行筛选,从而过滤掉大量无关的内容,只获得自身所关心的内容,更符合人脑处理信息的机制。Zhou P 等^[12]提出一种结合了 LSTM 和注意力机制的新模型 Bi-LSTM-Attention,并用该模型进行情感分类任务。

长期依赖关系在 EEG 信号中是指当前 EEG 信号的状态受到序列起始至当前时刻状态的影响。由于 EEG 信号属于长程时间序列信号 (EEG 信号的持续时间长),这种依赖关系更加难以捕捉。因此,本文尝试用结合注意力机制的 Bi-LSTM 网络解决该问题,该模型可以使网络聚焦在对分类结果影响最大的特征上,从而提升网络捕捉序列中长期依赖关系的能力。通过在公开数据集 CHB-MIT^[13]上采用 Bi-LSTM-Attention 进行癫痫发作检测,证明了该混合模型在癫痫发作检测任务中的有效性。

1 方法

1.1 整体框架

本文实验整体流程如图 1 所示。首先,对 EEG 信号进行预处理,主要包括滤波、切片和小波包分解重构操作;其次,对预处理后的 EEG 信号进行特征提取,主要包含时域、频域、时频域和脑网络域特征;最后,将特征输入到 Bi-LSTM-Attention 网络中进行训练。




图 1 实验流程图

Fig. 1 Pipeline of the proposed method

1.2 EEG 信号预处理

本文使用的 EEG 数据集采用国际 10-20 导联系统,考虑到眼电和心电的伪差,剔除了靠近眼部的电极 Fp1 和 Fp2 与靠近耳部的电极 FT9 和 FT10^[14],以及重复的通道。根据专家标记的癫痫发作开始与结束时间,将每个癫痫发作期间以 4 s 为滑动窗口,且前后样本保持 80% 的交叠,以防止切片处的信息丢失。由于癫痫发作的时间远远少于癫痫非发作的时间^[15],为了保证数据集正负样本的平衡,本文采用负采样的方法,对非癫痫发作样本进行

随机采样,将非癫痫发作样本 (negative) 数量和癫痫发作样本 (positive) 数量保持相对平衡。通过对 CHB-MIT 数据集处理后,得到 27 260 个数据样本,其中包含 13 535 个正样本、13 725 个负样本。

1.3 输入特征

本文所用特征主要包含时域、频域、时频域和脑网络域。

时域特征主要包含每个通道的最大值、最小值、峰值及偏度^[16];频域特征包含每个 EEG 信号频域分量的振幅。具体计算方式见表 1。

表 1 时域、频域、时频域特征计算公式

Table 1 Calculation of time domain, frequency domain and time-frequency domain characteristic

特征名称	计算公式	参数说明
最大值	$X_{\max} = \max(x_i)$	x_i : 采样点 i 的值
最小值	$X_{\min} = \min(x_i)$	X_{mean} : 一个切片中幅值的均值
峰度	$X_{\text{kur}} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - X_{\text{mean}})^4}{\left(\frac{1}{n} \sum_{i=1}^n (x_i - X_{\text{mean}})^2\right)^2} - 3$	
偏度	$X_{\text{ske}} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - X_{\text{mean}})^3}{\left(\frac{1}{n} \sum_{i=1}^n (x_i - X_{\text{mean}})^2\right)^{\frac{3}{2}}}$	
能量	$E(k) = \sum_{t=1}^N s_k(t) ^2$	$s_k(t)$: k 尺度上重构信号 N : 采样点个数

由于 EEG 信号是非平稳信号,因此本文也对其进行了时频分析。小波变换通过平移和伸缩,将非平稳随机信号分解为细节系数和近似系数,用来表示不同时频尺度上的信号分量^[17]。小波包变换对信号的分解比小波变换更加彻底,其不但对信号的低频部分进行分解,也对信号的高频部分进行分解。

因此在提取时频域特征前首先通过 Daubechies-4 小波对 EEG 信号进行 5 尺度小波包分解,小波分解示意如图 2 所示。其中, A_i^j 和 D_i^j 分别表示第 i 层第 j 个近似系数和细节系数,最后通过各层的细节系数进行 EEG 信号的重构。

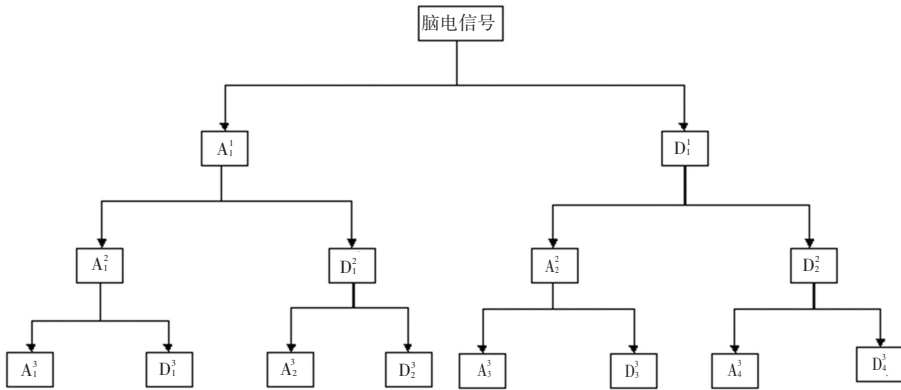


图 2 小波分解示意图

Fig. 2 Schematic diagram of wavelet decomposition

重构后的信号如图 3 所示。图中(0)表示原始 EEG 信号,(1)到(5)表示 1~5 尺度上的重构信号。从图中可以看出,癫痫发作和癫痫未发作的重构信号在 3~5 尺度上表现出明显的幅值差异。因此,本文通过 3~5 尺度上的细节系数重构了 EEG 信号,

并提取重构 EEG 信号的能量作为时频域特征。

通过计算重构 EEG 信号不同通道间的皮尔逊相关系数(PCC),得到 EEG 的脑网络,并提取网络聚集系数、特征路径长度和模块度^[18]作为脑网络特征,具体计算方式见表 2。

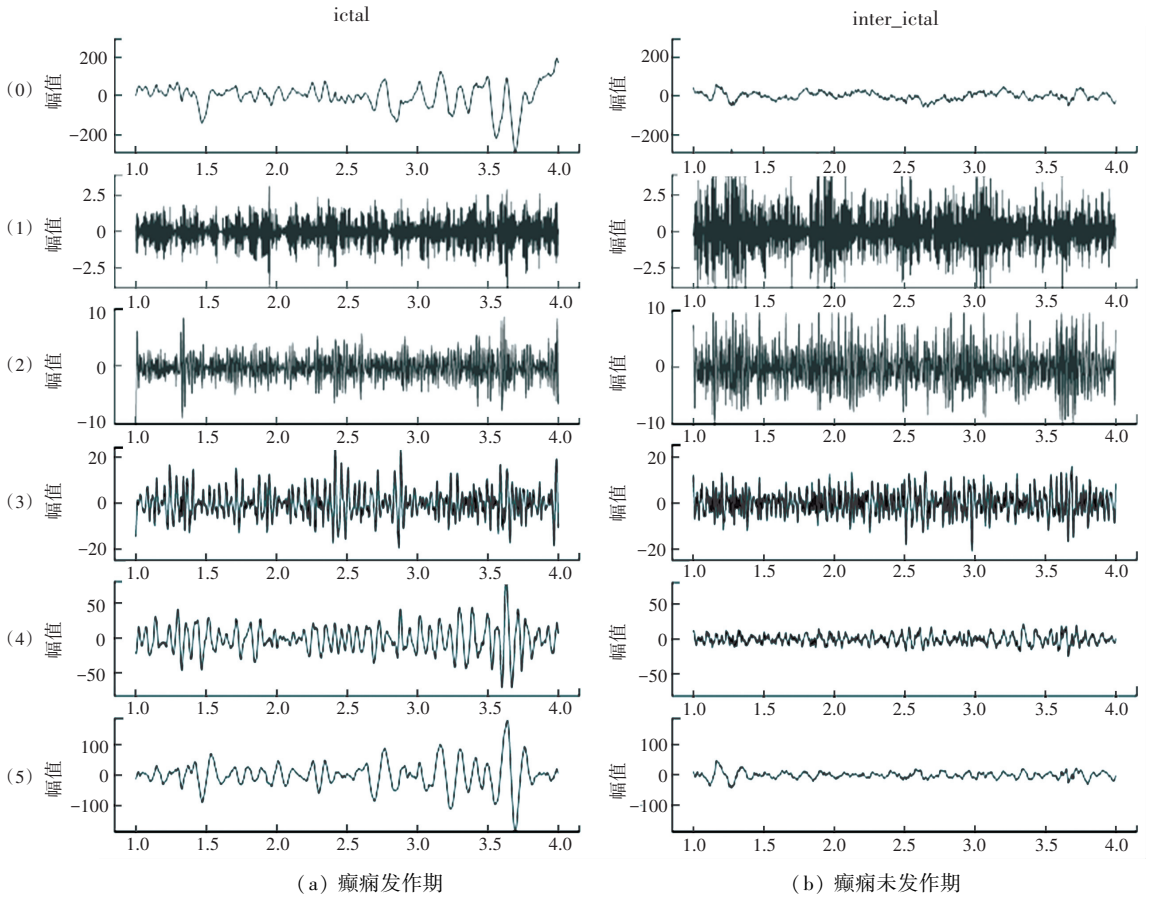


图3 癫痫发作期和未发作期的 EEG 信号和 5 个尺度上的重构信号

Fig. 3 EEG signals and reconstructed signals on five scales in epileptic and non-epileptic phases

表2 脑网络特征计算公式

Table 2 Brain network characteristic calculation formula

特征名称	计算公式	参数说明
网络聚集系数	$C = \frac{1}{n} \sum_{i \in N} C_i = \frac{1}{n} \sum_{i \in N} \frac{2t_i}{k_i(k_i - 1)}$	C_i : 每个节点的聚集系数 t_i : 每个节点周围的三角形数 k_i : 当前节点和其他节点相关联的数量
特征路径长度	$L = \frac{1}{n} \sum_{i \in N} L_i = \frac{1}{n} \sum_{i \in N} \frac{\sum_{j \in N, j \neq i} d_{ij}}{n - 1}$	L_i : 当前节点和其他节点最短路径长度的平均值 d_{ij} : 节点 i 和节点 j 之间的最短路径
模块度	$Q = \sum_{i \in M} L_i [e_{ii} - (\sum_{j \in M} e_{ij})^2]$	M : 网络被分成 M 个模块 e_{ij} : 模块 i 中的节点和模块 j 中的节点相连的边数和总边数的比值

1.4 Bi-LSTM-Attention 模型构建

LSTM^[19] 仍旧属于循环结构, 为了处理长期依赖问题, LSTM 引入了内部状态 c_t , 可以使网络让更多的信息进入循环进行传递, 并且能够将信息传递给外部状态 h_t , 增加模型的非线性能力。LSTM 还引入了 3 个门, 其具体定义如下:

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (1)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (2)$$

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (3)$$

式中: i_t, o_t, f_t 分别表示输入门、输出门和遗忘门, σ 表示 Sigmoid 函数, x_t 表示当前时刻 t 的输入, h_{t-1} 表示前一个时刻 $t-1$ 的隐状态, W_g, U_g, b_g 分别代表门 g 的参数。LSTM 的传播过程如下所示:

$$\tilde{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (4)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tilde{c}_t \quad (5)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (6)$$

式中: \tilde{c}_t 表示内部状态 c_t 的候选状态。

LSTM 3 种门的连接示意如图 4 所示。其中, 遗忘门用来控制内部状态 c_{t-1} 遗忘信息的多少, 输入门筛选候选状态 \tilde{c}_t , 遗忘门和输入门共同决定当前

时刻 t 的内部状态; 输出门控制 c_t 输出给外部状态的信息。LSTM 网络模型虽然可以处理时间序列, 但当时间序列达到一定长度时, 该网络对序列中依赖关系的捕捉能力便有所下降。

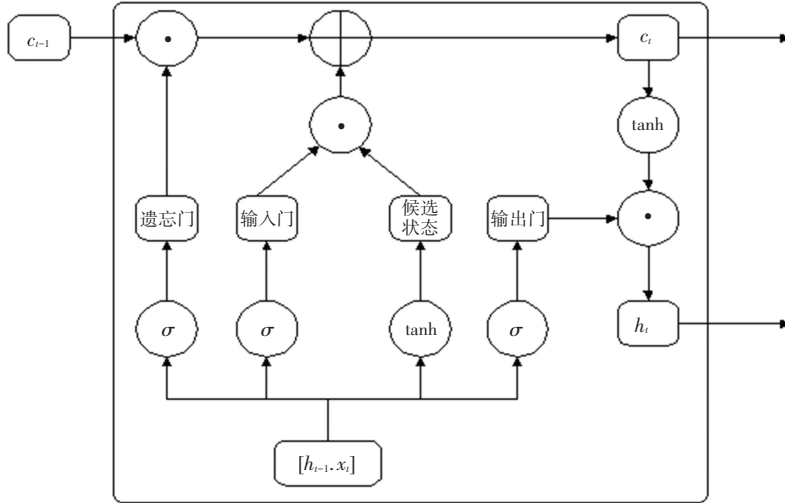


图 4 LSTM 单元示意图

Fig. 4 Diagram of LSTM unit

注意力机制参考了人体大脑的注意方式, 当人们面对大量信息时, 大脑只对人们心里最关注的信息进行处理。注意力机制在处理输入到网络中的信息时, 会筛选掉无关信息, 仅关注当前最重要的信息。自注意力模块 (Self-Attention)^[20] 通常分成两个步骤: 首先通过输入向量计算自身的注意力得分, 其次通过训练得到的 W_Q, W_K, W_V 矩阵计算 Query、Key 和 Value 向量, 然后计算输入向量的注意力得分, 最后经过 Softmax 得到注意力分布后, 使用加权

平均的方式, 对每个值向量计算最后的输出向量。计算公式如下:

$$\text{Self-Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (7)$$

Bi-LSTM-Attention 是近些年较好的模型, 在 NLP 各类任务上取得了不错的成绩。由于本文是对癫痫发作和未发作样本作二分类的任务, 所以只需在 Attention 层后再连接一个全连接层就能够完成癫痫分类任务, 网络结构如图 5 所示。




图 5 Bi-LSTM-Attention 模型结构图

Fig. 5 Structure of Bi-LSTM-Attention model

Bi-LSTM-Attention 就是在 Bi-LSTM 的模型上加入 Attention 层, 在 Bi-LSTM 中用最后一个时序的

输出向量作为特征向量, 然后进行 Softmax 层分类。Attention 是先计算每个时序的权重, 然后将所有时

序的向量进行加权求和作为特征向量,最后进行 softmax 层分类。LSTM 网络很好的解决了传统 RNN 模型不能处理时间序列中的长期依赖问题,并且 Bi-LSTM 考虑到了序列由后向前的依赖关系; Attention 模型可以很好的忽略样本中的无关信息,突出重点信息;该混合模型结合了两者的优点。

2 实验

本文实验环境基于 Windows10 操作系统, Python 3.7, 处理器为 Intel (R) Core (TM) i5-10400CPU@2.90 GHz 和 16 GB 的内存。

2.1 数据集

本文实验数据集是由波士顿儿童医院采用国际 10-20 电极导联配置收集的 EEG 信号记录。该数据集包含 23 名癫痫病例(其中:3-22 岁的 5 名男性、1.5-19 岁的 17 名女性、1 名性别和年龄未公开),并且每个病例的数据都包含多个 .edf 文件。edf 文件中记录的所有 EEG 信号都以 16 位分辨率和 256 Hz 的采样率进行采样得到,且大多数文件包含 23 个通道 EEG 信号。

2.2 评价指标

为了验证 Bi-LSTM-Attention 网络结构的优越性,将 Bi-LSTM-Attention 与其它基于 CNN 的经典网络 Resnet18、Resnet50,以及 Bi-LSTM 进行了对比实验。

本文采用带有动量的 SGD 优化器,交叉熵作为损失函数,并采用标准的二分类指标进行模型评估,根据表 3 中的混淆矩阵计算准确率 (Accuracy, AC)、敏感性 (Sensitivity, SE) 和特异性 (Specificity, SP)。准确率是指正确识别的正负样本数量和总样本数量的比值,敏感性是指正确识别癫痫发作样本数量和真正癫痫发作样本数量的比值,特异性是指正确识别非癫痫发作样本数量和真正癫痫非发作样本数量的比值,具体公式见表 4。

表 3 混淆矩阵

Table 3 Confusion matrix

	预测为癫痫发作 (Positive Class)	预测为癫痫未发作 (Negative Class)
实际为癫痫发作 (Positive Class)	True Positive (TP)	False Negative (FN)
实际为癫痫未发作 (Negative Class)	False Positive (FP)	True Negative (TN)

表 4 模型评价指标

Table 4 Evaluation index

名称	公式
Accuracy (AC)	$\frac{TP + TN}{TP + FN + FP + TN} \times 100\%$
Sensitivity (SE)	$\frac{TP}{TP + FN} \times 100\%$
Specificity (SP)	$\frac{TN}{TN + FP} \times 100\%$

2.3 实验结果分析

实验结果见表 5,在基于 CNN 的 Resnet18 和 Resnet50 中,深层的网络模型在 AC、SE、SP 等 3 个指标上都要比浅层网络模型表现的更好,可能是因为深层网络提取到了数据中更高阶的特征。Bi-LSTM 模型较于 Resnet50 来说,敏感性略低。在 Bi-LSTM-Attention 上,在 3 个指标上要优于其他 3 个模型,说明了基于 Bi-LSTM-Attention 的癫痫发作检测方法具有较大的潜力。在 3~5 尺度重构信号上构建脑网络并且提取脑网络特征对模型性能有较大提升,见表 6。

表 5 实验结果对比

Table 5 Comparison of experimental results

模型	AC	SP	SE
Resnet18	0.940 970	0.951 427	0.925 391
Resnet50	0.948 491	0.957 663	0.934 798
Bi-LSTM	0.950 947	0.960 830	0.936 480
Bi-LSTM-Attention	0.962 058	0.968 035	0.953 101

表 6 加入重构 EEG 信号上提取的特征前后模型的性能

Table 6 Performance of the model before and after adding features extracted from reconstructed EEG signals

模型	特征	AC	SP	SE
Bi-LSTM-Attention	传统特征	0.931 902	0.950 496	0.904 513
	传统特征+ 重构 EEG 信号特征	0.962 058	0.968 035	0.953 101

3 结束语

本文基于 EEG 信号和癫痫发作的特点,在提取传统特征的同时加入了新的功能网络特征,并且在算法上尝试了 Bi-LSTM-Attention 网络模型。在本文的实验中,该模型性能要比基于 CNN 和 Bi-LSTM 的网络模型的性能更加出色,最终得到了 96.20% 的准确率,96.80% 的特异性和 95.31% 的敏感性。由于本文仅仅在公开的癫痫发作数据集上进行了算法的

验证,未来可以收集更多的数据集来优化模型,提升算法性能,还可以将功能网络特征应用到癫痫发作前的EEG信号检测中,来研究癫痫预测这个问题。

参考文献

- [1] HASSAN A R, SUBASI A, ZHANG Y. Epilepsy seizure detection using complete ensemble empirical mode decomposition with adaptive noise[J]. Knowledge - Based Systems, 2020, 191: 105333.
- [2] WEI Z, ZOU J, ZHANG J, et al. Automatic epileptic EEG detection using convolutional neural network with improvements in time-domain[J]. Biomedical Signal Processing and Control, 2019, 53: 101551.
- [3] SHARMILA A, GEETHANJALI P. Evaluation of time domain features on detection of epileptic seizure from EEG signals[J]. Health & Technology, 2019, 10(3): 711-722.
- [4] WANG G, REN D, LI K, et al. EEG-based detection of epileptic seizures through the use of a directed transfer function method[J]. IEEE Access, 2018, 6: 47189-47198.
- [5] 彭禹, 宋耀莲. 基于STFT的卷积神经网络在MI-EEG分类中的应用[J]. 电子测量技术, 2021, 44(6): 36-41.
- [6] 杜云梅, 梁会营, 黄帅. 基于分层阈值的儿童脑电信号流式降噪预处理[J]. 中国数字医学, 2019, 14(3): 88-91.
- [7] 康同舟, 左润东, 钟岚峰, 等. 基于双密度双树复小波变换的癫痫发作期自动检测算法[J]. 生物医学工程学杂志, 2021, 38(6): 1035-1042, 1053.
- [8] CHEN D, WAN S, XIANG J, et al. A high-performance seizure detection algorithm based on Discrete Wavelet Transform (DWT) and EEG[J]. PloS one, 2017, 12(3): e0173138.
- [9] ANSARI A H, CHERIAN P J, CAICEDO A, et al. Neonatal seizure detection using deep convolutional neural networks[J]. International Journal of Neural Systems, 2019, 29(4): 1850011.
- [10] SHEKOKAR K S, DOUR S. Automatic epileptic seizure detection using LSTM networks[J]. World Journal of Engineering, 2021, 19(2): 224-229.
- [11] GENG M, ZHOU W, LIU G, et al. Epileptic seizure detection based on stockwell transform and bidirectional long short-term memory[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2020, 28(3): 573-580.
- [12] ZHOU P, SHI W, TIAN J, et al. Attention-based bidirectional long short-term memory networks for relation classification[C]// Proceedings of the 54th Annual Meeting of the Association for Computational Linguistics (Volume 2: Short papers). 2016: 207-212.
- [13] GOLDBERGER A L, AMARAL L. GLASS, et al. PhysioBank, PhysioToolkit, and PhysioNet: Components of a new research resource for complex physiologic signals[J]. Circulation, 2000, 101(23): e215-e220.
- [14] WU D, WANG Z, JIANG L, et al. Automatic epileptic seizures joint detection algorithm based on improved multi-domain feature of cEEG and spike feature of aEEG[J]. IEEE Access, 2019, 7: 41551-41564.
- [15] 费洪磊, 袁琦, 郑玉叶. 基于深度学习的癫痫脑电不平衡分类方法[J]. 仪器仪表学报, 2021, 42(3): 231-240.
- [16] 汝彦冬, 李金宝, 吕兴凤, 等. 基于脑电通道动态选择方法的癫痫检测[J]. 仪器仪表学报, 2021, 42(2): 180-188.
- [17] KHAN Y, GOTMAN J. Wavelet based automatic seizure detection in intracerebral electroencephalo-gram[J]. Clinical Neurophysiology, 2003, 114(5): 898-908.
- [18] BRAGA R B, LOPES C D, BECKER T. Round cosine transform based feature extraction of motor imagery EEG signals[C]// Proceedings of World Congress on Medical Physics and Biomedical Engineering 2018. Singapore: Springer, 2019: 511-515.
- [19] 杨意豪, 王梅, 左铭. 基于深度LSTM的甲亢疾病发展预测及应用系统[J]. 智能计算机与应用, 2019, 9(4): 128-131.
- [20] 黄元行, 刘晓波, 范津玮, 等. 基于注意力机制和EMD-GRU模型的电力负荷预测[J]. 智能计算机与应用, 2021, 11(3): 33-37, 43.