

基于深度学习的癫痫脑电信号分类

徐晴, 葛成, 蔡标, 陆翼, 常珊

(江苏理工学院电气信息工程学院生物信息与医药工程研究所, 常州 213001)

摘要: 有效地分析处理癫痫脑电信号并对其准确分类可以进一步完善癫痫检测问题。因此, 各种深度学习方法逐渐应用到该问题中, 如使用BiLSTM模型对癫痫脑电的一维时间序列数据进行处理。为进一步提高癫痫脑电分类的准确率, 本文将癫痫脑电的一维时间序列数据转换为二维图像, 使用EfficientNetV2模型来实现癫痫检测的二分类。同时, 引入梯度加权类激活映射(Gradient-weighted class activation mapping, Grad-CAM)对二维图像分类进行可视化分析。对德国伯恩大学脑电癫痫脑电信号数据集的预处理版本进行分类实验, EfficientNetV2模型的准确率达到98.69%, 优于BiLSTM模型。结果表明, EfficientNetV2模型可以有效通过二维脑电图像实现癫痫脑电分类, 而且分类准确率更高。

关键词: 癫痫; 脑电信号; EfficientNetV2; BiLSTM; 梯度加权类激活映射

中图分类号: TP301 **文献标志码:** A

EEG Signal Classification of Epilepsy Based on Deep Learning

XU Qing, GE Cheng, CAI Biao, LU Yi, CHANG Shan

(Institute of Bioinformatics and Medical Engineering, School of Electrical and Information Engineering, Jiangsu University of Technology, Changzhou 213001, China)

Abstract: Effectively analyzing, processing and accurately classifying epileptic electroencephalographic (EEG) signals can further improve the problem of epilepsy detection. Therefore, various deep learning approaches have been gradually applied to this problem, such as using the BiLSTM model to process the 1D time series data of epileptic EEG. To further improve the accuracy of epileptic EEG classification, the 1D time series data of epileptic EEG is converted into 2D images and the EfficientNetV2 model is used to achieve binary classification for epilepsy detection in this paper. At the same time, the gradient-weighted class activation mapping (Grad-CAM) is introduced for visual analysis of 2D images classification. By performing classification experiments on a pre-processed version of the epilepsy EEG signal dataset from the University of Bern, Germany, the EfficientNetV2 model achieves the accuracy of 98.69%, which is better than the BiLSTM model. The result indicates that the EfficientNetV2 model can effectively achieve epileptic EEG classification by 2D EEG images with higher classification accuracy.

Key words: epilepsy; electroencephalographic (EEG); EfficientNetV2; BiLSTM; gradient-weighted class activation mapping (Grad-CAM)

引言

癫痫是一种慢性非传染性的脑部疾病,是全球最常见的神经系统疾病之一。据世界卫生组织报道,全球约超过5 000万人患有癫痫,在中国就有高达900多万的癫痫患者,而且日益年轻化^[1]。癫痫发作可以从短暂的注意力丧失以及肌肉抽搐发展到严重且长时间的抽搐,癫痫发作的频率也可能从一年一次发作发展为一天多次发作,这对癫痫预测造成了非常大的困难。而且由于癫痫发病的不确定性、突发性、反复性等,通常会导致患者对身体失去控制以及意识丧失,造成如摔倒、骨折、溺水或车祸等伤害^[2]。脑电(Electroencephalographic, EEG)信号可以反映大脑神经元放电活动,具有较高的时间分辨率以及非侵入性等优点,广泛应用于监测癫痫、帕金森、睡眠障碍、阿尔茨海默症、情绪状态以及认知负荷等^[3-5]。由于在癫痫发作期的脑电信号比正常脑电信号更混乱,会呈现出快速剧烈的变化,出现尖波、棘波、棘慢综合波等^[6],这与非发作期时的信号相比差异较大,因此通过分析脑电信号可以实现癫痫发作检测。

癫痫发作检测在本质上是属于脑电信号的二分类或多分类问题,通过对每一时刻的信号判断其所属状态来实现发作检测。癫痫脑电信号的分类研究主要由特征提取和分类两部分组成,常用的特征提取方法主要有自回归(Autoregressive, AR)模型、共空间模式(Common spatial pattern, CSP)、小波变换(Wavelet transform, WT)、功率谱密度(Power spectral density, PSD)估计、非线性动力学等^[7]。迄今为止,在很多癫痫脑电信号的特征提取中应用了这些方法。Nassim等^[8]利用自回归系数对EEG信号进行分解,将提取特征参数通过多层感知机神经网络进行分类,获得了97.76%的最高准确率;Lu等^[9]选择样本熵和分形维数两个指标作为特征,并使用支持向量机对癫痫脑电信号进行自动分类,准确率达到89.8%。刘倩倩等^[10]使用多变量符号转移熵对癫痫脑电信号进行研究分析,该实验通过将原始信号符号化后进行数值分析,并对导联信号、信号长度的选取以及稳健性进行分析,结果表明该方法可以有效区分正常人与癫痫病人的脑电信号。刘伟楠等^[11]则使用不同波段的绝对功率谱、相对功率谱和功率谱比值组成混合特征对睡眠中的癫痫发作进行预测。上述方法需要人工设计和提取信号特征再结合机器学习分类器进行分类,会存在特征提取不充分、适应性不强及准确率不高等问题。

与传统方法相比,深度学习不需要特征处理,可以学习不同的信号特征,提高分类准确性。2018年,Rajendra等^[6]首次使用了1个13层的深度卷积神经网络来检测正常、发作前期和发作期的3种类别,该模型的准确性、特异性和灵敏度分别为88.67%、90.00%和95.00%。George等^[12]将一维脑电数据转换为二维脑电图像,使用卷积神经网络的子类ResNET-50模型将波士顿儿童医院的头皮脑电数据分为发作期、非发作期和发作前期3类,最终该模型达到了94.98%的准确率。程伟等^[13]通过深度密集卷积神经网络实现癫痫脑电信号的二分类,识别的准确率、精确度、灵敏度和特异性分别达到了96.94%、97.46%、87.18%和99.42%。柯铭等^[14]提出一种1DCNN算法与XGBoost算法相结合的单通道癫痫脑电分类模型,利用一维卷积模型自动提取特征,再利用XGBoost算法实现分类,最终在波恩大学癫痫脑电数据集上得到了98.83%的分类准确率。除此之外,由于脑电信号是一种时间序列信号,鉴于循环神经网络在这方面的成功应用,Thara等^[15]使用BiLSTM模型对德国伯恩大学数据集实现癫痫发作与非发作的二分类。Kishori等^[16]分别提出了单向和双向的3层LSTM网络,用于检测癫痫发作,结果双向LSTM网络模型更优。

上述研究成果表明,基于深度学习的癫痫脑电分类与传统方法相比,准确率有所提高。但需要大量的网络层和不同深度学习算法的组合,增加了检测系统的复杂性。同时根据文献[12],除了对一维脑电数据进行处理,还可以将一维脑电数据转换为二维脑电图像进行癫痫与非癫痫的分类。目前关于图像分类的深度学习算法中,传统的卷积神经网络通过单独调整输入网络的深度、宽度及图像分辨率

来进行扩展,而 EfficientNetV2 模型使用 1 个复合系数从这 3 个维度扩展网络^[17],所以 EfficientNetV2 模型总体上显著优于其他网络。为进一步提高癫痫脑电分类的准确率,本文根据 2 种不同的脑电信号数据类型,使用 BiLSTM、DenseNet 和 EfficientNetV2 三种模型进行分类,并进行比较分析。同时采用了梯度加权类激活映射(Gradient-weighted class activation mapping, Grad-CAM)方法对分类结果进行可视化分析。

1 实验数据和方法

1.1 数据集

实验数据来自德国伯恩大学癫痫数据集的预处理版本。原始的数据集是由 A~E 五个不同子集组成,每个子集中有 100 个同类型的文件,每个文件包含了 4 097 个脑电时间序列,共计 23.6 s 的大脑活动,采样频率为 173.61 Hz。其中,子集 A 和 B 是无癫痫疾病的正常人分别在睁眼和闭眼状态下采集的脑电信号;子集 C 是癫痫患者在发作间期的病灶对侧区域采集的脑电信号;子集 D 是癫痫患者在发作间期对病灶区采集的信号;子集 E 是在发作期的脑电信号^[18]。由于本文是对癫痫脑电信号进行二分类,发作期的数据集仅有子集 E,数据量较少,所以选取该数据集的预处理版本。

预处理版本是对原始脑电数据进行预处理和重构。数据集的预处理主要是使用 0.53~40 Hz 的带通滤波器进行滤波操作,以及使用视觉检测技术去除伪迹干扰,两步操作已由德国伯恩大学完成^[13]。数据重构是指原始数据集的 4 097 个时间序列分为 23 个数据块并随机排列,每个数据块包含 178 个信号序列,时间长度共计 1 s。因此,原始数据集被拆分为 11 500 条数据,每条数据由 178 个信号序列组成,最后一列数据标签为 {1, 2, 3, 4, 5}。其中标签为 1 的是癫痫发作期的数据,标签 2~5 是癫痫未发作状态的数据。

本文采取 2 种数据类型进行处理,即一维时间序列和二维图像。在二维图像中,由于调整了电压值范围,2 个状态的波形差异增大。图 1 是癫痫未发作状态时的波形,其中图 1(a)是典型波形,整体平缓,波动幅度小;图 1(b)是非典型波形,在整体平缓无波动的情况下,有一波峰的存在,与图 1(a)有较大差异。图 2 是癫痫发作状态时的波形,其中图 2(a)波动幅度大,无明显规律,是典型的癫痫发作状态下的波形;相反,图 2(b)则呈现小幅波动。可以看出,在调整了电压值范围的条件下,仍然存在 2 种状态波形差异较小的图像,如图 1(a)和图 2(b),肉眼无法正确判断,容易造成误判,所以使用二维图像做分类处理仍然有意义。为了保持数据平衡,分别从标签为 2~5 的数据中随机抽取 2 300 条作为癫痫未发作的数据,将这些数据标签统一设置为 0,与标签为 1 的数据重组为 4 600 条数据,因此癫痫发作与未发作的数据比例为 1:1。同时,将重组的数据集按照 8:1:1 的比例随机划分为训练集、验证集以及测试集。




图 1 癫痫未发作状态

Fig.1 State of non-epileptic seizure




图2 癫痫发作状态

Fig.2 State of epileptic seizure

1.2 实验模型

(1) 一维时间序列的处理模型

长短期记忆 (Long short term memory, LSTM) 网络模型改善了循环神经网络 (Recurrent neural network, RNN) 梯度消失和爆炸的问题, 更适合处理长时序序列问题。BiLSTM 模型由前向 LSTM 和后向 LSTM 组成, 可以从两个方向更好地处理癫痫脑电数据信息。由文献[15-16]可知, 双向长短期记忆网络在处理脑电序列上更具优势, 所以本文选用 BiLSTM 模型处理一维序列信号, 算法流程如图 3 所示。本文 BiLSTM 模型的输入首先通过 1 个 ReLU 激活的线性层; 然后经过 1 个双向循环层, 将循环单元指定为 LSTM 单元, 共有 128 个; 再经过 2 个线性层, 每个线性层前都有 Dropout 和 BN 层; 最后使用 Softmax 作为激活函数, 实现癫痫发作与未发作的二分类。

(2) 二维脑电图像的处理模型

针对癫痫脑电的二维图像, 使用 EfficientNetV2 模型, 同时将 DenseNet 作为实验对照组, 算法流程如图 4 所示。EfficientNetV2 网络模型在 EfficientNetV1 的基础上进行了改进, 在训练速度和参数数量上进行了优化, 同时提出了改进后的渐进学习方法会根据训练图像的尺寸动态调整正则方法。EfficientNetV2 模型由卷积、Fused-MBConv 和 MBConv 模块组成。二维脑电图像首先通过 1 个 3×3 的卷积层提取特征值; 之后再分别通过 Fused-MBConv 和 MBConv 模块, 其中卷积核 k 的大小统一设置为 3×3 ; 最终通过 1 个 1×1 的卷积层、池化层以及全连接层实现二分类。DenseNet 在深度残差网络的基础上采用密集连接机制, 互相连接所有的层, 每层都会与前面所有层连接在一起实现特征重用, 并作为下一层的输入。在图 4 的 DenseNet 网络结构中, 除第 1 个 Conv 7×7 外, 每一个 Conv 前都有 BN 和 ReLU 层, 其中 Conv 1×1 、Conv 3×3 模块按照左侧数字设置层数, 每一层均采用密集连接机制; 最终经由平均池化层、全连接层实现线性分类并输出。

1.3 Grad-CAM

对于训练的深度学习算法, 它是如何根据图像进行分类往往是未知的, 所以深度学习算法被很多人认为是个黑匣子, 缺乏可解释性。而 Grad-CAM^[19] 是为卷积神经网络模型的视觉解释而开发的, 用于可视化模型判断的基础。通过 Grad-CAM 生成一个粗略的定位图, 对应分类类别, 突出显示网络模型关注的重要区域。而且对于图像分类, 可视化不仅可以捕捉到重要区域, 还可以对看似不合理的分




图3 基于 BiLSTM 算法的流程图

Fig.3 Workflow based on BiLSTM algorithm

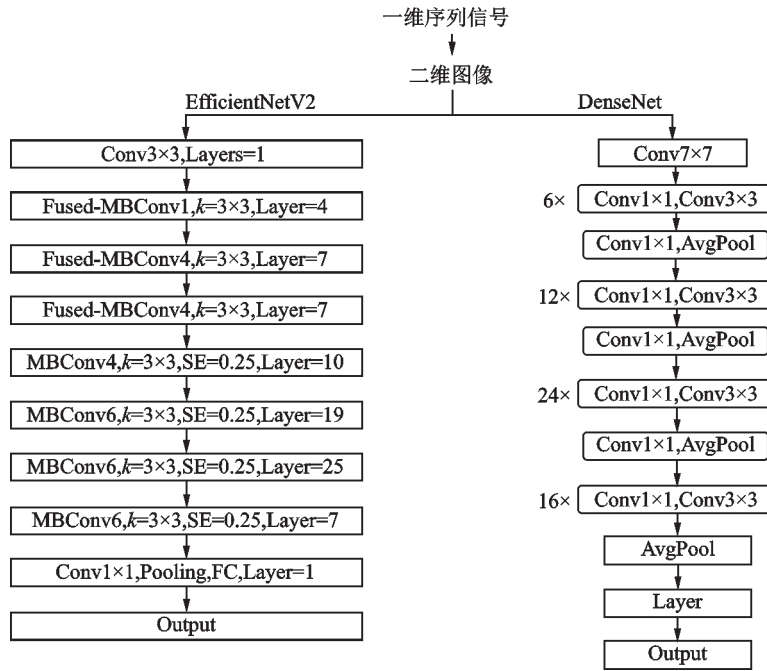


图4 EfficientNetV2和DenseNet算法流程图

Fig.4 Workflow of EfficientNetV2 algorithm and DenseNet algorithm

类有合理的解释。Grad-CAM是在不改变原网络结构的情况下,实现对不同类别的特征层加权求和后通过激活函数计算,利用梯度全局平均来计算权重,有

$$L_{\text{Grad-CAM}}^c = \text{ReLU}\left(\sum_k \alpha_k^c A^k\right) \tag{1}$$

式中: A 代表最后一个卷积层输出的特征层; k 为特征层 A 中第 k 个通道; c 代表所分类的类别; A^k 代表特征层 A 中通道 k 的数据; α_k^c 代表针对 A^k 的权重,其计算公式为

$$\alpha_k^c = \frac{1}{Z} \sum_i \sum_j \frac{\partial y^c}{\partial A_{ij}^k} \tag{2}$$

式中: y^c 代表未经Softmax激活的针对类别 c 预测的分数; A_{ij}^k 代表特征层 A 在通道 k 中坐标为 ij 处的数据; Z 为特征层的宽度 \times 高度。

1.4 评价指标

为了便于比较,采用准确性(Accuracy, Acc)、敏感性(Sensitive, Sens)、特异性(Specificity, Spec)和精确率(Precision, Prec)作为评价指标,定义为

$$\text{Acc} = \frac{\text{TN} + \text{TP}}{\text{TN} + \text{TP} + \text{FN} + \text{FP}} \tag{3}$$

$$\text{Sens} = \frac{\text{TP}}{\text{TP} + \text{FN}} \tag{4}$$

$$\text{Spec} = \frac{\text{TN}}{\text{TN} + \text{FP}} \tag{5}$$

$$\text{Prec} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (6)$$

式中:TP为真阳性;TN为真阴性;FP为假阳性;FN为假阴性。同时,采用ROC曲线和AUC来评估模型性能:ROC曲线通过真阳率与假阳率两项指标来评估分类模型的性能,AUC则是ROC曲线下的面积,越接近1表明模型越好。

2 实验与结果分析

2.1 实验设置

本文使用了3种模型处理两种类型的脑电数据:一维序列使用BiLSTM模型,二维脑电图像使用DenseNet和EfficientNetV2模型,其中DenseNet作为实验对照组。实验设置如表1所示。

表1 实验设置

Table 1 Experimental settings

数据类型	模型	深度学习框架
一维序列	BiLSTM	
二维图像	DenseNet	Pytorch
	EfficientNetV2	

2.2 实验环境与参数设置

本文实验在Linux环境下基于Pytorch深度学习框架搭建,在1台Tesla V100机器上进行训练,其显存为32 GB。在3种模型中,学习率为0.001,损失函数选择binary_crossentropy,优化函数选择adam,训练批次尺寸设置为64。通过多次参数调优,BiLSTM模型的迭代周期设置为100,DenseNet和EfficientNetV2设置为20。

2.3 分类结果与分析

本研究使用了3种分类模型对两种数据类型比较,模型分别为BiLSTM、DenseNet和EfficientNetV2,结果分析所用评价指标为准确性、敏感性、特异性、精确率以及ROC曲线,训练结果如表2所示,ROC曲线如图5所示。

表2 不同模型在同一数据集下的性能比较

Table 2 Performance comparison of different models on the same dataset

模型	Acc	Sens	Spec	Prec	AUC
BiLSTM	97.39	96.66	98.18	98.30	99.57
DenseNet	98.04	97.08	99.09	99.14	99.88
EfficientNetV2	98.69	98.33	99.09	99.15	99.90

由表2可以看出,在准确性上3种模型的效果都很好,相较于处理一维序列的BiLSTM模型,处理二维图像的DenseNet和EfficientNetV2模型结果更优,其中EfficientNetV2模型的准确性最高,达到了98.69%;同样在敏感性、特异性以及精确率中,




图5 3种模型的ROC曲线

Fig.5 ROC curves of three models

处理二维图像的2种模型优于BiLSTM模型,且2种模型中EfficientNetV2模型均是最高值,分别达到了98.33%、99.09%和99.15%。图5中的ROC曲线显示3种模型的AUC值均达到了99%以上,EfficientNetV2最高为99.90%。通过比较这3种模型的各项评判指标可以发现,3种模型对癫痫脑电信号的识别效果较好,其中EfficientNetV2模型表现最佳。

图6是BiLSTM、DenseNet以及EfficientNetV2模型在训练过程中的准确性与损失函数变化曲线。其中Train_loss和Val_loss表示模型在训练集和验证集上训练时的损失值,Train_Acc和Val_Acc表示模型在训练集和验证集上训练时的准确率。可以看出,BiLSTM模型在迭代20个周期后,准确性曲线与损失函数变化曲线逐渐进入收敛状态,虽然在后续轮次中验证集的损失函数曲线出现了振荡现象,但是仍稳定在一定范围内。最终训练集的识别准确性稳定在100%左右,验证集的准确率稳定在97%左右,最终测试集的最高准确率为97.39%。DenseNet模型在迭代4个周期后,准确性曲线与损失函数变化曲线逐渐进入收敛状态,最终测试集的最高准确率为98.04%。EfficientNetV2模型在迭代5个周期后,准确性曲线与损失函数变化曲线逐渐进入收敛状态,训练集的识别准确性稳定在100%附近,验证集的准确性稳定在99%附近,最终测试集的最高准确率为98.69%。




图6 3种模型的训练准确度-损失大小变化曲线

Fig.6 Variation curves of training accuracy-loss of three models

2.4 可视化分析

由于EfficientNetV2模型的分类结果最好,所以使用该模型利用Grad-CAM方法进行可视化分析。通过将EfficientNetV2模型最后一层卷积层的梯度信息生成加权热力图,可以显示模型的重点关注区域,并以红色、橙色标注;非重点区域以蓝紫色标注显示。从测试集中,分别选取癫痫发作与未发作状态下的典型波形以及非典型波形进行对比分析,结果如表3和表4所示。同时,对同一张脑电图像的不同预测结果,Grad-CAM方法可以对模型重点关注的区域显示,如表3和表4中的热力图1和热力图2。热力图1是针对癫痫发作,即标签为1的分类结果绘制的热力图;热力图2是针对未发作状态,即标签为0的分类结果绘制的热力图。即使模型对二维图像做出了误判,但通过2张不同的热力图对比,仍然可以作为模型错误分类的依据,并提供一个合理的解释。

在表3中,波形a和b都有明显的棘波、尖波等存在,在热力图1中由于是针对癫痫发作这一分类结果绘制的热力图,所以它的重点关注区域除了整条波形,对于波形波动幅度过大的区域即棘波、尖波等被重点标注,而在热力图2中需要关注的平稳波形较少,所以波形a和b可以经由EfficientNetV2模型被正确分类。波形c和d都是癫痫未发作时的图像,波形c整体上呈现有规律且小幅度波动,波形d则几乎无波动。在两者的热力图1中,仅有较小范围内的波形被关注,而在热力图2中模型所关注的特征是波形的平稳性,所以整条波形成为了模型的重点关注区域,自然就被正确分类为未发作状态。

表3 典型波形及其热力图

Table 3 Typical waveforms and their class activation maps

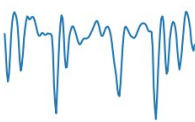
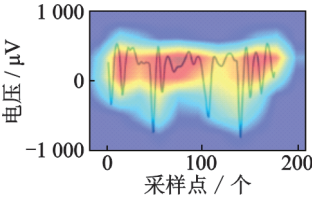
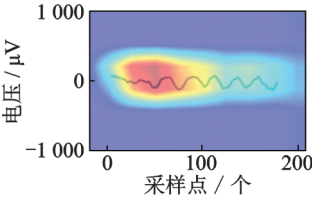
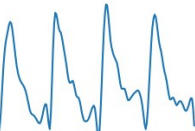
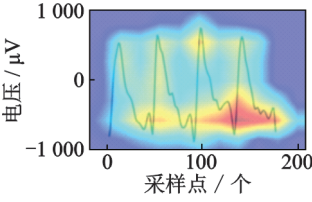
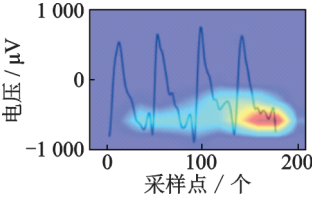

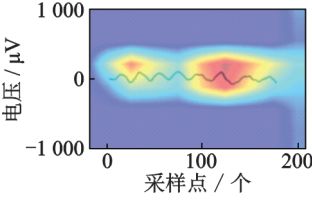
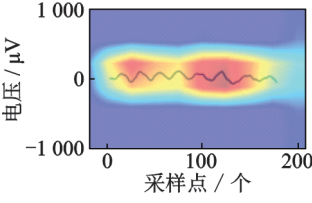

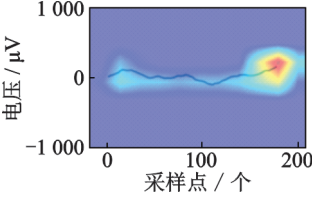
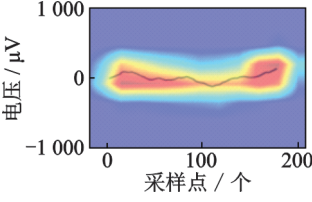

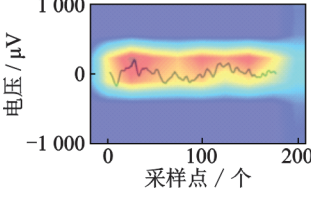
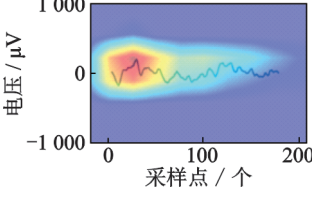

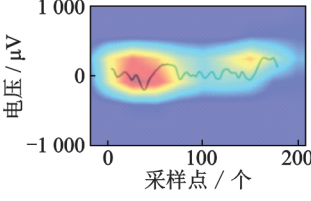
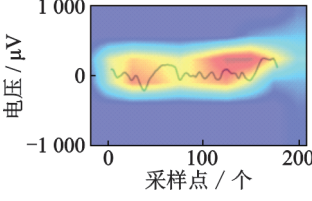

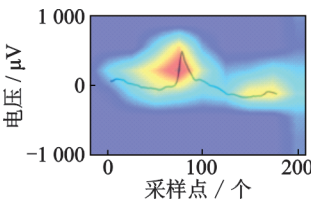
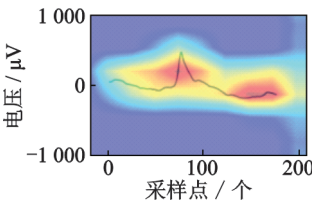

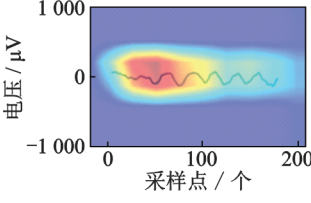
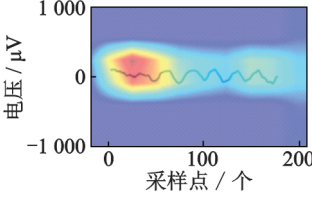
编号	波形图	热力图1	热力图2	分类结果
a				分类正确 真值为1, 预测为1
b				分类正确 真值为1, 预测为1
c				分类正确 真值为0, 预测为0
d				分类正确 真值为0, 预测为0

表4中的4个非典型的波形,波形a和b分别属于癫痫未发作和发作状态,但2个图像都被误判。波形a的热力图1误将波形的波动作为显著特征,模型将整条波形重点关注,在热力图2中仅将波形前半段作为分类特征,区域较小,所以导致了错误的分类结果。波形b的热力图1同样只将波形前半段的波动作为特征,不足以支撑它被分类为发作状态,而热力图2中模型提取的特征是整条波形,所以同样导致了误判。波形c和d分别是未发作和发作状态,但在波形c中存在一个尖波,波形d整体较平稳,与表3中的4种典型波形有较大的区别。波形c有个尖波,所以热力图1中也仅仅只关注到该区域,而热力图2整条波形都有关注,尤其是后半段,所以分类正确。波形d的2个热力图关注区域相差较小,但也能明

显看出热力图1关注区域多,将前半段的波动作为显著特征,热力图2则是仅仅关注了波形开始时的平稳波段,所以该波形可以被正确分类为癫痫发作状态。

表 4 非典型波形及其热力图

Table 4 Non-typical waveforms and their class activation maps

编号	波形图	热力图1	热力图2	分类结果
a				分类错误 真值为0,预测 为1
b				分类错误 真值为1,预测 为0
c				分类正确 真值为0,预测 为0
d				分类正确 真值为1,预测 为1

3 结束语

本文针对癫痫脑电数据的两种数据类型,即一维时间序列和二维脑电图像,分别通过BiLSTM、DenseNet和EfficientNetV2模型在德国波恩大学癫痫脑电数据集上实现癫痫发作的检测。结果表明,EfficientNetV2模型对癫痫脑电的二维脑电图像的分类效果最好,获得98.69%的准确率,证实了EfficientNetV2模型在癫痫发作检测上的可行性。同时,针对二维图像的处理,引入了Grad-CAM进行可视


化分析,对于分类结果有了更好的可解释性。一般在临床中会通过观察临床症状和脑电图2种方式来检测癫痫发作,但是人工判断脑电图不仅数据量大效率慢,而且仅依据以往经验会产生误判。所以本文针对癫痫发作与未发作状态进行二分类,有利于患者在后期病情掌控中的监护和临床诊断。如果要进一步实现患者的日常居家监护,则需要对发作前期和发作间期进行分类,本文方法也同样适用,这也是进一步需要研究的方向。

参考文献:

- [1] 张锦, 刘熔, 田森, 等. 面向癫痫脑电的简化深度学习模型[J]. 国防科技大学学报, 2020, 42(6): 106-111.
ZHANG Jin, LIU Rong, TIAN Sen, et al. Epilepsy signal recognition based on deep dense convolutional network[J]. Journal of National University of Defense Technology, 2020, 42(6): 106-111.
- [2] YILDIZ A, HASAN Z, SHERIF S. Classification and analysis of epileptic EEG recordings using convolutional neural network and class activation mapping[J]. Biomedical Signal Processing and Control, 2021. DOI: 10.1016/J.BSPC.2021.102720.
- [3] PACHORI R B, SHIVNARAVAN P. Epileptic seizure classification in EEG signals using second-order difference plot of intrinsic mode functions[J]. Computer Methods Programs Biomed, 2014, 113(2): 494-502.
- [4] 许子明, 牛一帆, 温旭云, 等. 基于脑电信号的认知负荷评估综述[J]. 航天医学与医学工程, 2021, 34(4): 339-348.
XU Ziming, NIU Yifan, WEN Xuyun, et al. A review of cognitive workload assessment based on EEG[J]. Space Medicine & Medical Engineering, 2021, 34(4): 339-348.
- [5] 张进, 许子明, 周月莹, 等. 基于脑电的虚拟现实诱发下情绪状态分类[J]. 数据采集与处理, 2021, 36(6): 1226-1236.
ZHANG Jin, XU Ziming, ZHOU Yueying, et al. Emotion classification induced by virtual reality based on EEG[J]. Journal of Data Acquisition and Processing, 2021, 36(6): 1226-1236.
- [6] RAJENDRA A, SHU L O, YUKI H, et al. Deep convolutional neural network for the automated detection and diagnosis of seizure using EEG signals[J]. Computers in Biology and Medicine, 2018, 100: 270-278.
- [7] 王海玉, 胡剑锋, 王映龙. 脑电信号处理方法的研究综述[J]. 计算机时代, 2018(1): 13-15, 19.
WANG Haiyu, HU Jianfeng, WANG Yinglong. A review of EEG signal processing methods[J]. Computer Era, 2018(1): 13-15, 19.
- [8] NASSIM B, RAFIK D. Combined strategy neural network using AR parameters for epileptic EEG signals classification[J]. Biomedical Engineering and Technology, 2016, 21(1): 67-79.
- [9] LU X J, ZHANG J Q, HUANG S F, et al. Detection and classification of epileptic EEG signals by the methods of nonlinear dynamics[J]. Chaos, Solitons & Fractals, 2021. DOI: 10.1016/J.CHAOS.2021.111032.
- [10] 刘倩倩, 戴加飞, 李锦, 等. 基于多变量符号转移熵的癫痫脑电分析[J]. 数据采集与处理, 2016, 31(5): 983-988.
LIU Qianqian, DAI Jiafei, LI Jin, et al. Epileptic EEG based on improved multivariate symbolic transfer entropy[J]. Journal of Data Acquisition and Processing, 2016, 31(5): 983-988.
- [11] 刘伟楠, 刘燕, 佟宝同, 等. 基于功率谱的睡眠中癫痫发作预测[J]. 生物医学工程杂志, 2018, 35(3): 329-336.
LIU Weinan, LIU Yan, TONG Baotong, et al. Prediction of seizures during sleep based on power spectrum[J]. Journal of Biomedical Engineering, 2018, 35(3): 329-336.
- [12] GEORGE F, ALEX J, BIBIN B, et al. Epileptic seizure prediction using EEG images[C]//Proceedings of International Conference on Communication and Signal Processing (ICCSPP). Chennai, India: [s.n.], 2020: 1595-1598.
- [13] 程伟, 龙佳伟, 郑威. 基于深度密集卷积网络的癫痫信号识别[J]. 生物医学工程研究, 2021, 40(3): 267-272.
CHENG Wei, LONG Jiawei, ZHENG Wei. Epilepsy signal recognition is based on the deep dense convolutional network[J]. Journal of Biomedical Engineering research, 2021, 40(3): 267-272.
- [14] 柯铭, 尹倡隆, 刘光耀, 等. 基于1DCNN-XGBoost混合模型的癫痫脑电分类[J]. 计算机应用研究, 2020 (S2): 90-91, 94.
KE Ming, YIN Changlong, LIU Guangyao, et al. EEG classification of epilepsy based on the 1DCNN-XGBoost hybrid model [J]. Application Research of Computers, 2020(S2): 90-91, 94.
- [15] THARA D K, PREMASUDHA B G, FAN X. Epileptic seizure detection and prediction using stacked bidirectional long short term memory[J]. Pattern Recognition Letters, 2019, 128(C): 529-535.

- [16] KISHORI S S, SHWETA D. Automatic epileptic seizure detection using LSTM networks[J]. World Journal of Engineering, 2021, 19(2): 224-229.
- [17] TAN M, LE Q V. EfficientNetV2: Smaller models and faster training[EB/OL].(2021-04-01)[2021-06-23]. <https://arxiv.org/abs/2104.00298>.
- [18] ANDRZEJAK R G, LEHNERTZ K, MORMANN F, et al. Indications of nonlinear deterministic and finite-dimensional structures in time series of brain electrical activity: Dependence on recording region and brain state[J]. Physical Review E, Statistical, Nonlinear, and Soft Matter Physics, 2001, 64(6): 061907.
- [19] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: Visual explanations from deep networks via gradient-based localization[EB/OL]. (2016-10-07)[2019-12-03]. <https://arxiv.org/abs/1610.02391v4>.

作者简介:



徐晴(1998-),女,硕士研究生,研究方向:脑电信号处理, E-mail: jsut_xq@163.com。



葛成(1996-),男,硕士研究生,研究方向:深度学习、脑电信号处理, E-mail: 13851520957@163.com。



蔡标(1993-),男,硕士研究生,研究方向:脑电信号处理、医学图像分割, E-mail: jslg_caibiao@163.com。



陆翼(1998-),女,硕士研究生,研究方向:医学信号处理, E-mail: luyi-jsut@163.com。



常珊(1982-),通信作者,男,教授,研究方向:生物信息学和医学信号处理方面的研究, E-mail: schang@jsut.edu.cn。

(编辑:张黄群)