

频域注意力机制下的癫痫脑电信号分类

孙红帅, 王霞, 柳萱, 张连超, 赵兴杰

(西安交通大学电子与信息学部, 710049, 西安)

摘要: 为提高癫痫脑电信号特征分类的准确率, 基于残差网络结构的深度学习, 提出了一种频域注意力机制下的癫痫脑电信号分类(FDAM)算法。首先分析所提取的脑电信号特征, 然后根据信号特征主要分布在时频域的幅值中的特点, 通过残差网络对时频域幅值特征进行二次提取, 最后为了使残差网络提取的特征集中在与分类结果相关性较大的频域, 设计了一种频域注意力机制, 在深度学习过程中增强该类频域的幅值特征, 有效提高了癫痫脑电信号的分类准确率。采用公开数据库PhysioNet中的CHB-MIT Scalp EEG Database数据库对算法的分类性能进行了验证, 实验结果表明, FDAM算法对正常状态和癫痫发作状态的脑电信号分类准确率达到98.05%, 特异性为99.34%, 灵敏度为96.12%。

关键词: 频域注意力机制; 残差网络; 时频域特征; 癫痫; 脑电信号

中图分类号: TN911.6 **文献标志码:** A

DOI: 10.7652/xjtub202102015 **文章编号:** 0253-987X(2021)02-0129-07



OSID 码

A Classification Method of Epileptic Electroencephalograms Under Frequency-Domain Attention Mechanism

SUN Hongshuai, WANG Xia, LIU Xuan, ZHANG Lianchao, ZHAO Xingjie

(Faculty of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: A classification method of epileptic EEG signals under frequency domain attention mechanism (FDAM) based on a deep learning of residual network structure is proposed to improve the classification accuracy of epileptic electroencephalogram (EEG) signals. Firstly, the algorithm of extracting epileptic EEG signal features is analyzed. Then, according to the characteristics of the amplitude that the signal features are mainly distributed in the time-frequency domain, the amplitude features in the time-frequency domain are extracted twice through the residual network. Finally, in order to focus the features extracted from the residual network on the frequency domain which is more relevant to the classification results, a frequency domain attention mechanism is designed to enhance the amplitude characteristics of the frequency domain in the process of deep learning and effectively improve the classification accuracy of epileptic EEG signals. The classification performance of the proposed algorithm is tested by experiments and the experimental data are obtained from the CHB-MIT Scalp EEG Database in the open PhysioNet database. The experimental results show that FDAM algorithm can classify EEG signals in normal state and epileptic state with 98.05% in accuracy, 99.34% in specificity and 96.12% in sensitivity.

收稿日期: 2020-06-15。 作者简介: 孙红帅(1995—),男,硕士生;王霞(通信作者),女,教授。 基金项目: 陕西省国际科技合作计划重点资助项目(2020KWZ-014)。

网络出版时间: 2020-11-02

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1069.T.20201102.0909.003.html>

Keywords: frequency domain attention mechanism; residual network; time-frequency characteristics; epilepsy; electroencephalogram

脑电信号是神经细胞的电活动在大脑的总体反映,包含了大量的生理活动与思维活动的信息^[1]。在临床医学研究方面,脑电信号的处理可以为脑部疾病或精神类疾病提供诊断的依据。癫痫是一种常见的神经系统疾病,其特征是在部分或整个大脑区域突然出现异常的电活动,存在如棘波、锐波、尖慢复合波等波形的脑电信号,会直接导致中枢神经系统的功能发生短暂障碍。

由于脑电信号长期记录的性质,其分析是一项耗时的工作。当前在临床诊断和监测中,这种分析依然由医生人工进行,效率低且具有主观性^[2]。而软件算法的分析处理更为快速且客观,因此癫痫的发作与正常状态的分类研究是很有意义的。

目前研究人员已提出了多种方法来自动检测癫痫发作,这些方法中的分类算法主要有基于人工神经网络、时频分析的分类算法以及模糊聚类、迁移聚类、多视图聚类、多任务聚类等类型的分类算法^[3-10]。

当前存在的分类算法中采用的特征主要是癫痫患者脑电信号的时域或频域特征。

应用时域特征的脑电信号分类算法有基于图论的算法、基于神经网络的算法等。Fan 等提出了一个基于混沌理论和频谱图理论的描述脑电信号时间动态的框架,通过状态向量表示脑电信号的各个状态,将多变量脑电信号映射到一个 n 维状态空间,重构状态空间轨迹来描述系统如何随时间演化,采用复杂的网络模型来表示 EEG 的递归模式,并在此基础上利用频谱图理论特征对时间同步模式进行量化,从模型中构造的递归中提取递归量化分析特征和图论特征^[11]。Yuan 等利用脑电信号通道间的相互关系,构建了一种新的基于自编码的多视角深度学习模型,通过在训练阶段增加一个通道感知的竞争机制,提出了一个通道感知的癫痫检测模块来关注重要的和相关的脑电信号通道^[12]。

应用频域特征的脑电信号分类算法有基于熵变换的算法、基于小波变换的算法等。Marcelo 等利用基于频域表示的 Renyi 熵及其时域变化的 Renyi 熵和基于奇异值分解的熵作为脑电信号分类特征,对 EEG 进行时频复杂度测量,提出了一种新的时变复杂度度量方法^[13]。Wang 等将小波分解与定向传递函数算法相结合,提出一种新的基于小波的定向传递函数方法,用定向传递函数方法计算了 EEG 的

5 个子带和全频带的信息流动特征用于癫痫发作的检测^[14]。Abhijit 等提出了基于经验小波变换的癫痫发作脑电信号检测方法,对多通道的脑电信号进行经验小波变换,确定信号自适应频率尺度下的联合瞬时振幅和频率,然后用 KNN、RF、朴素贝叶斯分类器进行了对比,研究了经验小波变换在多变量脑电图信号上的多元扩展^[15]。

Aldana 等利用小波变换将脑电信号扩展成三阶张量表示,通过典型多元分解(CPD)和块项分解(BTD)得到特征,采用 k 近邻法、径向基支持向量机和线性判别分析分类器对正常和癫痫发作的脑电信号进行鉴别^[16]。Gu 等从发作状态的脑电信号中提取癫痫特征,然后对待检测的样本进行小波变换,小波系数反映了所记录的脑电信号与癫痫特征波形的相似性,对小波变换系数矩阵进行数据融合后,可以确定癫痫发作的边界,可以用来检测癫痫特征波形是否存在于脑电信号中^[17]。

上述文献中,已有的特征提取算法多是直接应用癫痫患者脑电信号的时域或频域特征,分类正确率较低。针对以上问题,本文提出了将时频域幅值转化为图片作为初始特征,在残差网络结构的深度学习中,提出了一种频域注意力机制,对癫痫脑电信号的时频域幅值进一步提取特征,以提高发作状态和正常状态的脑电信号分类准确率。采用公开数据库 PhysioNet 中的 CHB-MIT Scalp EEG Database 数据库对算法进行验证,结果表明:本文算法对正常状态和癫痫发作状态的脑电信号的分类准确率达到 98.05%,灵敏度为 96.12%,特异性为 99.34%,且该算法对于不同测试者的信号样本分类准确率都在 97%以上。

1 分类算法及频域注意力机制

本文提出的癫痫脑电信号分类算法主要包括预处理、特征提取和分类 3 个步骤。其中特征提取又包括短时傅里叶变换、图片化和加入频域注意力机制的 ResNet-50 训练。本文算法流程如图 1 所示。

1.1 预处理

脑电信号属于连续采集的多通道时序微弱电信号,首先需要通过带通滤波器去除噪声,根据脑电信号的生物节律性选择需要的频带。本文针对癫痫疾病脑电信号,希望能尽可能多地保留频域特征,滤波




图 1 分类算法流程模块图

器通带选择为 $0 \sim 0.5f_s$ 。其中 f_s 为采样频率。

在特征提取之前,每 2 s 截取一段信号作为一个样本。设脑电采集的电极通道数为 N ,则每一个脑电信号样本为 N 个长度为 $2f_s$ 的序列。

对每一个序列进行中心化,表达式如下

$$x'(t) = x(t) - \mu \tag{1}$$

式中: $x(t)$ 为中心化前的序列; $x'(t)$ 为中心化后的序列; μ 为该序列的均值。

1.2 特征提取

1.2.1 短时傅里叶变换与图片化 为展现信号样本在时频域的状态,需对信号进行短时傅里叶变换(STFT)。脑电信号是一种非周期的无限长序列信号,设为 $f(t)$,由于直接对信号截断会产生信息丢失,所以在 STFT 中,窗函数选择汉明窗,设为 $g(t)$,该窗的幅频特性主要表现为旁瓣较小,更容易对信号在样本上进行时域上的分割。 $f(t)g(t)$ 在不同的有限时间宽度内是平稳信号,从而计算出各时刻的功率谱。

对一个脑电信号样本进行 STFT 变换后,原数据变为 N 个时频域矩阵,其中元素为复数, N 为采集脑电信号的电极通道数。时频域矩阵中行元素之间代表时间顺序,列元素之间代表频率顺序。将时频域矩阵中元素取模值,得到实数矩阵。将该矩阵变为图片,横轴为时间顺序,纵轴从上到下为频率,顺序从小到大,颜色代表本通道脑电信号在该时段该频率的幅度大小,颜色越亮表明幅度越大。

每个脑电信号样本由 N 个时序信号组成,经过预处理转化为 N 个表示时频域特征的图片,以此来表示该信号样本。将 N 个表示时频域特征的图片作为一组特征输入添加了频域注意力机制的 ResNet 神经网络,以进一步提取特征并分类。

1.2.2 ResNet 残差网络 本文算法将癫痫患者脑

电信号的时频域幅值转化为图片做样本特征,因此选择一种用于图片分类的深度学习神经网络来作为网络框架。

He 等提出了一个残差学习的框架,以有效减轻神经网络学习训练的压力和负担^[18]。该框架将输出层定义为根据输入来学习残差函数,而不是直接学习目标函数。

文献[18]指出,对于一个多层网络,当其输入特征为 x 时,其学习所得到的特征标记为 $H(x)$,可以通过网络学习得到特征残差 $F(x) = H(x) - x$,从而得到其实原始的学习特征 $H(x) = F(x) + x$ 。残差网络的学习流程如图 2 所示。




图 2 残差网络的学习流程示意图

鉴于 ResNet 神经网络在图像分类中优异的表现,本文采用其中 ResNet-50 结构对脑电信号的时频域特征图组进行提取特征并分类。

该网络中损失函数选用交叉熵损失函数。在样本二分类的情况下,模型最后需要预测的结果只有两种情况,对于每个类别,预测得到的概率为 p_i 和 $1 - p_i$ 。此时损失函数的表达式如下

$$L = \frac{1}{N} \sum_{i=1}^n L_i = \frac{1}{N} \sum_{i=1}^n -[l_i \log(p_i) + (1 - l_i) \log(1 - p_i)] \tag{2}$$

式中: l_i 为样本 i 的标签,发作状态为 1,正常状态为 0; n 为样本数; p_i 为样本 i 预测为发作的概率。

1.2.3 频域注意力机制 该注意力机制即卷积网络通过多个共享卷积核提取具有局部感受野的空间信息和通道信息。在网络中添加注意力机制可以有效地提高网络的表达能力。目前主要有两种添加注意力机制的方式:空间注意力机制和通道注意力机制。通道注意力机制是在卷积网络不同通道间添加注意力机制。空间注意力机制是在卷积网络的空间域内添加注意力机制,例如借鉴非局部均值方法的 Non-local Neural Networks 网络结构。

目前存在的注意力机制都是以正常图像作为处理对象,来进行特征增强。本文处理的图像中的元素是存在现实物理意义的时域和频域,因此处理普通图像的注意力机制并不适合本文中提取的脑电信号时频域特征图。

本文提出一种针对频域的注意力机制。该频域注意力机制模块在 ResNet 神经网络中每一个残差学习模块结束时加入,增强频域的特征。

设残差模块输出的特征矩阵为 w 行 h 列的特征矩阵 $\mathbf{Y}$,如下式所示

$$\mathbf{Y} = \begin{bmatrix} y_{11} & y_{12} & \cdots & y_{1h} \\ y_{21} & y_{22} & \cdots & y_{2h} \\ \vdots & \vdots & & \vdots \\ y_{w1} & y_{w2} & \cdots & y_{wh} \end{bmatrix} \quad (3)$$

由于 STFT 后的时频域矩阵中行代表时域,列代表频域,卷积后相对位置不变,在 $\mathbf{Y}$ 中列向量依然可以视为在频域的特征。

设 $\mathbf{Y}$ 中每一个列向量 $\mathbf{y}$ 为式(4),引入频域注意力机制的计算如式(5)所示

$$\mathbf{y} = [y_1, y_2, \cdots, y_w]^T \quad (4)$$

$$\hat{y}_i = \sum_{j=1}^n \frac{1}{s(y_i)} f(y_i, y_j) y_i \quad (5)$$

式中: $\hat{y}_i$ 为 y_i 加入频域注意力机制计算得到的元素; $f(y_i, y_j)$ 表示 y_i 与 y_j 之间相关程度的函数; $s(y_i)$ 为对元素 y_i 计算得到的标准化因子; n 为信号采样通道数。

频域注意力机制的计算原理如下。

(1) 计算列向量 $\mathbf{y}$ 的自相关矩阵 $\mathbf{M}$

$$\mathbf{M} = \begin{bmatrix} y_1 y_1 & y_1 y_2 & \cdots & y_1 y_w \\ y_2 y_1 & y_2 y_2 & \cdots & y_2 y_w \\ \vdots & \vdots & & \vdots \\ y_w y_1 & y_w y_2 & \cdots & y_w y_w \end{bmatrix} \quad (6)$$

$$\mathbf{M}_e = \begin{bmatrix} e^{y_1 y_1} & e^{y_1 y_2} & \cdots & e^{y_1 y_w} \\ e^{y_2 y_1} & e^{y_2 y_2} & \cdots & e^{y_2 y_w} \\ \vdots & \vdots & & \vdots \\ e^{y_w y_1} & e^{y_w y_2} & \cdots & e^{y_w y_w} \end{bmatrix} \quad (7)$$

式(7)中, $y_i y_j$ 表示这两个频率的幅值的相关性,对 $\mathbf{M}_e$ 矩阵的行求和得到的列向量代表该频率在整个频域中的重要程度,该列向量可作为权重与原特征数据相乘,引入 e^x 使权重能与原特征数据非线性相乘,并且权重越小,经过神经网络层的加深,该频率的权重越靠近 0。

(2) 对式(7)中的每一列进行归一化,令 $s(y_i)$

$= \sum_{j=1}^w e^{y_j y_i}$,相关程度的矩阵变为

$$\frac{1}{s(\mathbf{y})} \mathbf{M}_e = \begin{bmatrix} \frac{e^{y_1 y_1}}{s(y_1)} & \frac{e^{y_1 y_2}}{s(y_2)} & \cdots & \frac{e^{y_1 y_w}}{s(y_w)} \\ \vdots & \vdots & & \vdots \\ \frac{e^{y_w y_1}}{s(y_1)} & \frac{e^{y_w y_2}}{s(y_2)} & \cdots & \frac{e^{y_w y_w}}{s(y_w)} \end{bmatrix} \quad (8)$$

(3) 对式(8)矩阵中的行求和得到

$$\mathbf{F} = \begin{bmatrix} \sum_{j=1}^w \frac{1}{s(y_1)} f(y_1, y_j) \\ \sum_{j=1}^w \frac{1}{s(y_2)} f(y_2, y_j) \\ \vdots \\ \sum_{j=1}^w \frac{1}{s(y_w)} f(y_w, y_j) \end{bmatrix} \quad (9)$$

式中: $\mathbf{F}$ 代表了对式(8)矩阵中的行求和得到的列向量; $\sum_{j=1}^w \frac{1}{s(y_i)} f(y_i, y_j)$ 表示 y_i 点与同一列向量中其他元素之间的相关性,也代表了该点所代表的频域对于该特征提取网络的重要程度,作为权值与原特征矩阵中的列向量 $\mathbf{y} = [y_1, y_2, \cdots, y_w]^T$ 点对点相乘,得到 $\mathbf{F}\mathbf{y}$,使重要的点增加权重,不重要的点减少权重,使整个网络注意力集中在重要的频带。

(4) 为了保留更多的信息,注意力机制输出的向量与原向量相加,得到特征向量 $\hat{\mathbf{y}}$ 如下

$$\hat{\mathbf{y}} = \mathbf{F}\mathbf{y} + \mathbf{y} \quad (10)$$

(5) 对 $\mathbf{F}$ 去均值,使重要点的权值为正数,不重要点的权值为负数,减少点在特征提取网络中的权重,由推导过程可知,归一化后的 $\mathbf{F}$ 矩阵所有元素的和为 w ,均值为 1,去均值的过程为 $\sum_{j=1}^w \left[\frac{1}{s(y_i)} \cdot f(y_i, y_j) \right] - 1$ 。

(6) 特征向量的加权式如下

$$\hat{\mathbf{y}} \left(\sum_{j=1}^w \frac{1}{s(y_i)} f(y_i, y_j) - 1 \right) \mathbf{y} + \mathbf{y} = \sum_{j=1}^w \frac{1}{s(y_i)} f(y_i, y_j) \mathbf{y} \quad (11)$$

式中: $\hat{\mathbf{y}}$ 中每个元素 $\hat{y}_i$ 的计算过程为式(5)。

1.3 识别分类

脑电信号样本经过 ResNet-50 神经网络最后一个残差模块后,输出的特征为 1×2048 维特征数据向量,经过全连接层后,输出样本为两种分类的可能性,再经过 softmax 层输出最终的分类判断。

2 实验过程及结果

2.1 实验数据

本文的实验数据来自于网络上免费公开的生物信号数据库 PhysioNet, 选用了其中的 CHB-MIT Scalp EEG Database 数据库。该数据库收集于波士顿儿童医院, 由顽固性癫痫患儿的脑电信号记录组成。该数据库包含 22 个患者的脑电信号, 每个患者的脑电信号监测总时长为 30 h, 分别保存在 15 个文件中, 每个文件时长为 2 h。在监测期间每个患者都出现了癫痫发作的状态。

信号采样频率 f_s 为 256 Hz, 每个信号样本包含 23 个通道脑电的信号。这些记录使用了国际 10-20 脑电图电极位置和命名法。

本文以 2 s 时长为一个样本, 将正常状态下和发作状态下的脑电信号分别分段为独立样本。每个样本为 23×512 维的矩阵。

2.2 实验过程

本文对频域注意力机制加入前后的效果进行了对比实验, 实验过程如下。

2.2.1 信号预处理 预处理是对数据库中的脑电信号进行去噪。由于本文对脑电信号特征提取时, 要保留全部大脑活动时的脑电频率特征, 因此选择 $0 \sim 0.5 f_s$ 的低通滤波器对脑电信号滤波。

正常状态样本和发作状态样本中 FP1-F7 通道的脑电信号如图 3 所示。




图 3 正常状态和发作状态 FP1-F7 通道脑电信号

2.2.2 短时傅里叶变换并图片化 对样本中每个通道的信号进行 STFT, 选择汉明窗作为窗函数, 设

置输出的时频域矩阵中行代表时域, 列从上到下为 $0 \sim 128$ Hz 的频率, 每个元素为该信号在对应时段对应频率的幅值。本文实验在脑电信号频域特征选择的频率为 $0 \sim 128$ Hz。窗函数长度应该大于等于 128, 本实验中窗函数长度选择为 128。本文 STFT 采用重叠 50% 的方法滑动窗函数, 所以对于每个样本分为 7 段。所以每个样本中的一个信号经过短时傅里叶变换后, 计算得到的时频域矩阵维数为 128×7 维。每一个样本有 23 通道脑电信号, 共生成 23 个 128×7 的矩阵。

在图片化过程中, 需要将时频域矩阵中的元素取模值变为实数。ResNet 神经网络处理的图片为方阵, 所以对原矩阵右侧补 0, 生成 128×128 的方阵。

为直观观察时频域矩阵模值图片化得到的图片, 将多个矩阵连在一起生成效果图。癫痫患者正常状态和发作状态 FP1-F7 通道的脑电信号样本对 STFT 矩阵取模值后变换得到的图片如图 4 所示。




图 4 正常状态和发作状态脑电信号时频图

由图可知, 正常状态下, 脑电信号在全频段的幅度都有较高幅值的出现, 而发作状态下, 脑电信号只在低频带的幅值比较高。

通过观察得知,对 STFT 生成的时频域矩阵取模值生成的图片在正常状态和发作状态具有区分性。

2.2.3 实验结果 设 N 表示测试集中正常状态样本个数, P 表示测试集中异常状态样本数, N_T 表示测试集中正常状态分类正确的数量, N_{TP} 表示测试集中异常状态样本分类正确的个数, 分类准确率为 A_c , 灵敏度为 S_e , 特异性为 S_p , 则分类准确率、灵敏度及特异性的计算公式如下

$$A_c = (N_{TP} + N_T) / (P + N) \tag{12}$$

$$S_e = N_{TP} / P \tag{13}$$

$$S_p = N_T / N \tag{14}$$

为保证分类器不会对其中一类过拟合, 实验中两类样本的数量接近 1:1, 其中 80% 分为训练集, 20% 分为测试集。

本文算法在 CHB-MIT 数据库的数据下运行结果如图 5 所示, 图中本文算法为加入频域注意力机制后的算法, ResNet-50 表示未加入频域注意力机制的算法, 对比算法 1 为 Muhammad 等提出的基于动态模式分解的头皮脑电图癫痫发作检测算法^[19], 主要应用信号的时域特征, 对比算法 2 为 Nhan 等提出的利用生成对抗网络预测癫痫发作算法^[20], 主要应用信号的时频域特征。




图 5 不同算法的分类结果对比

本文算法的分类准确率与训练次数的关系如图 6 所示。




图 6 分类准确率与训练次数关系图

2.3 实验分析

由图 5 结果可知, 本文提出将脑电信号短时傅

里叶变换后的时频域特征图片化, 作为区分癫痫病人正常状态和发作状态脑电信号的特征, 用 ResNet 神经网络进一步提取特征并分类, 能达到很高的分类正确率, 高于另外两种直接应用时频域特征的算法。

再加入本文中提出的频域注意力机制, 能进一步提升算法的分类性能, 分类准确率达到 98.05%, 灵敏度为 96.12%, 特异性为 99.34%。

3 结 论

癫痫疾病的脑电信号异常的特征分布在频域幅值中, 为了使提取的特征集中在对分类结果相关性更大的频域中, 增强该类频域的幅值特征, 并降低与分类结果相关性较小的频域幅值特征, 本文基于残差网络结构的深度学习, 将时频域幅值转化为图片作为初始特征, 提出了一种频域注意力机制, 提高了发作状态和正常状态的脑电信号分类准确率, 并进行了实验验证。

实验数据为公开数据库 PhysioNet 中的 CHB-MIT Scalp EEG Database 数据库, 实验结果表明, 本文算法对正常状态和癫痫发作状态分类准确率达到 98.05%, 灵敏度为 96.12%, 特异性为 99.34%。

参考文献:

[1] SILBERMAN E K, WEINGARTIER H, 王益明. 情绪的大脑半球功能的单侧化 [J]. 心理科学进展, 1992(1): 26-31.
SILBERMAN E K, WEINGARTIER H, WANG Yiming. Unilateral hemispheric function of emotion [J]. Advances in Psychological Science, 1992(1): 26-31.
[2] 孟庆芳, 周卫东, 陈月辉, 等. 基于非线性预测效果的癫痫脑电信号的特征提取方法 [J]. 物理学报, 2010, 59(1): 123-130.
MENG Qingfang, ZHOU Weidong, CHEN Yuehui, et al. Feature extraction method of epileptic EEG signal based on nonlinear prediction effect [J]. Journal of Physics, 2010, 59(1): 123-130.
[3] SAMIEE K, KOVACS P, GABBOUJ M. Epileptic seizure classification of EEG time-series using rational discrete short-time Fourier transform [J]. IEEE Transactions on Biomedical Engineering, 2015, 62(2): 541-552.
[4] ALEXANDROS T, MARKOS G, DIMITRIOS I. Epileptic seizure detection in EEGs using time-frequency analysis [J]. IEEE Transactions on Information Tech-

- nology in Biomedicine, 2009, 13(5): 703-710.
- [5] GHOSH-DASTIDAR S, ADELI H, DADMEHR N. Mixed-band wavelet-chaos-neural network methodology for epilepsy and epileptic seizure detection [J]. IEEE Transactions on Biomedical Engineering, 2007, 54(9): 1545-1551.
 - [6] 崔昊天, 宋森. 基于图注意力深度神经网络的癫痫脑电尖波识别 [J]. 生物学杂志, 2020(1): 11-15.
CUI Haotian, SONG Sen. Epileptic EEG sharp wave recognition based on graph attention depth neural network [J]. Journal of Biology, 2020(1): 11-15.
 - [7] NIKNAZAR M, MOUSAVI S R, VAHDAT B V, et al. A new framework based on recurrence quantification analysis for epileptic seizure detection [J]. IEEE Journal of Biomedical and Health Informatics, 2013, 17(3): 572-578.
 - [8] CHISCI L, MAVINO A, PERFERI G, et al. Real-time epileptic seizure prediction using AR models and support vector machines [J]. IEEE Transactions on Biomedical Engineering, 2010, 57(5): 1124-1132.
 - [9] 齐永锋, 李陇强. 基于局部模式的癫痫脑电信号自动分类方法 [J]. 计算机工程, 2020(2): 298-303.
QI Yongfeng, LI Longqiang. Automatic classification of epileptic EEG signals based on local mode [J]. Computer Engineering, 2020(2): 298-303.
 - [10] CHAOCALITWONGSE W A, FAN Y J, SACHDEO R C. On the time series K-nearest neighbor classification of abnormal brain activity [J]. IEEE Transactions on Systems Man & Cybernetics: Part A Systems & Humans, 2007, 37(6): 1005-1016.
 - [11] FAN Miaolin, CHOU Chun-An. Detecting abnormal pattern of epileptic seizures via temporal synchronization of EEG signals [J]. IEEE Transactions on Biomedical Engineering, 2019, 66(3): 601-608.
 - [12] YUAN Ye, XUN Guangxu, JIA Kebin, et al. A multi-view deep learning framework for EEG seizure detection [J]. IEEE Journal of Biomedical & Health Informatics, 2019, 23(1): 83-94.
 - [13] MARCELO A C, MOHAMAD E S H J, JRAD N, et al. Time-varying time-frequency complexity measures for epileptic EEG data analysis [J]. IEEE Transactions on Biomedical Engineering, 2018, 65(8): 1681-1688.
 - [14] WANG Dong, REN Doutian, LI Kuo, et al. Epileptic seizure detection in long-term EEG recordings by using wavelet-based directed transfer function [J]. IEEE Transactions on Biomedical Engineering, 2018, 65(11): 2591-2599.
 - [15] ABHIJIT B, PACHORI R B. A multivariate approach for patient-specific EEG seizure detection using empirical wavelet transform [J]. IEEE Transactions on Biomedical Engineering, 2017, 64(9): 2003-2015.
 - [16] ALDANA R Y, HUNYADI B, MARAMON R E J, et al. Nonconvulsive epileptic seizure detection in scalp EEG using multiway data analysis [J]. IEEE Journal of Biomedical and Health Informatics, 2019, 23(2): 660-671.
 - [17] GU Zhenghui, YAN Gang, ZHANG Jun, et al. Automatic epilepsy detection based on wavelets constructed from data [J]. IEEE Access, 2018, 6: 53133-53140.
 - [18] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition [C]// 29th IEEE Conference on Computer Vision & Pattern Recognition. Los Alamitos, CA, USA: IEEE Computer Society, 2016: 770-778.
 - [19] MUHAMMAD S J S, SAJID S, KHAWAR K, et al. Dynamic mode decomposition based epileptic seizure detection from scalp EG [J]. IEEE Access, 2018, 6: 38683-38692.
 - [20] NHAN D T, LEVIN K, MOHAMMAD R B, et al. Epileptic seizure forecasting with generative adversarial networks [J]. IEEE Access, 2019, 7: 143999-144009.

(编辑 刘杨)