

DOI:10.19651/j.cnki.emt.2005361

# 离散差分模块在癫痫脑电分类中的应用

潘奕竹 沈娜

(南京理工大学 瞬态物理重点实验室 南京 210094)

**摘要:** 针对癫痫脑电信号多分类的精度提升问题,提出了一种基于信号转差分模块与卷积模块结合的分类算法。信号转差分模块对原始脑电信号进行多阶差分运算,得到描述其波动特征的差分表示;然后卷积模块动态学习的方式将差分脑电信号转换为图片,利用预训练的卷积神经网络来提取信号特征并实现自动分类。分类结果表明,与现有研究相比,所提出的方法的最高提升了8.1%的分类准确率。在两分类问题上达到了99.8%的分类准确率,在三分类问题上获得了92.8%的准确率,在五分类问题上取得了86.7%的准确率。说明信号转差分模块对于脑电信号分类问题有积极作用。

**关键词:** 卷积神经网络;特征提取;脑电信号分类;多阶差分

中图分类号: TN911.72 文献标识码: A 国家标准学科分类代码: 510.4099

## Signal to difference module in epileptic electroencephalogram classification

Pan Yizhu Shen Na

(Key Laboratory of Transient Physics, Nanjing University of Science and Technology, Nanjing 210094, China)

**Abstract:** Targeting at improving the accuracy of multi-classification problems of epileptic EEG signals, one algorithm based on the combination of a signal to difference module and convolutional module is proposed. The signal to difference module performs multi-order differential operations on raw EEG signals to obtain its incremental representation which depicts the fluctuation features of EEG signals. Then, this representation is converted to images by convolutional module using dynamic learning parameters rather than static transformation. And pre-trained convolutional networks are applied to extract features and classify them automatically. The classification results show that this method improves the classification performance by up to 8.1% when compared to recent researches. This method achieved 99.8% accuracy in two-class classification problems, 92.8% accuracy in three-class classification problems and 86.7% accuracy in five-class classification problems, which indicates that signal to difference module has an important effect on EEG classification problem.

**Keywords:** CNN; feature extraction; EEG classification; multi-order difference

## 0 引言

脑电图(electroencephalogram, EEG)是大脑中神经元活动产生的电压波动的电位记录<sup>[1]</sup>。脑电信号在医疗、人工智能等领域有着广阔的应用前景,例如脑机接口、情绪识别、疾病检测和睡眠检测<sup>[2-4]</sup>。

目前关于 EEG 信号的特征处理都集中于使用频域和时频域方法,如小波分析、短时傅里叶变换、功率谱密度和希尔伯特-黄变换等。李明阳等<sup>[5]</sup>基于双密度离散小波变换对 EEG 信号提取小波域能量。李明爱等<sup>[6]</sup>利用小波包变换对 EEG 信号进行时频分解提取特征。Ramos 等<sup>[7]</sup>总结了短时傅里叶变换在 EEG 信号处理中的优缺点。Faust

等<sup>[8]</sup>提出了寻找 EEG 信号中不同功率谱密度中的局部极值作为特征的方法,这使得分类器关注于更显著的特征。杨默涵等<sup>[9]</sup>则通过总体经验模式分解将 EEG 信号分解为具有较强影响力的固有模态函数,然后提取其近似熵、希尔伯特边缘谱和希尔伯特瞬时能谱特征。使用以上特征提取方式都具有良好的时间和频率分辨率,但是需要手工进行预处理和提取特征,时间成本高。

深度学习是近年来提出的一种训练多层次神经网络解决问题的新方法。多层网络由于拥有数以百万计的神经元,使其可以从训练数据中自动学习和实现特征提取。现有研究多使用卷积神经网络<sup>[10-12]</sup>(convolutional neural network, CNN)来实现 EEG 信号的自动特征提取和分类,

收稿日期:2020-11-15

• 70 •

故本文提出一种结合信号差分模块和卷积模块的新型算法,对癫痫 EEG 信号进行分类识别。

## 1 研究方法

EEG 信号识别算法的结构框架如图 1 所示,包含了 4 个阶段:

- 1) 信号差分转换模块将原始 EEG 信号转换为差分表示;
- 2) 卷积模块将 EEG 信号的差分表示转换为图片格式;
- 3) 加载预训练的 CNN 网络,并替换最后一层来匹配特征图尺寸;
- 4) 训练模型来识别不同种类的 EEG 信号。

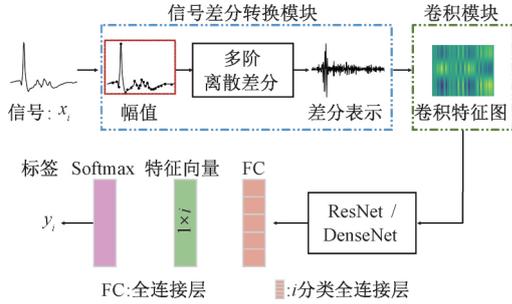


图 1 算法框架

### 1.1 信号转差分模块

导数  $f'(x)$  体现的是原函数  $f(x)$  瞬时变化的趋势与特点,一阶导数反映函数的单调性,二阶导数表示函数的凹凸性,三阶导数反映一阶导数的单调性,而四阶导数表示二阶导数的凹凸性。因此,通过求得高阶导数可以丰富原函数的变化特征。由于 EEG 信号为离散非平稳序列,故对其波形变化特点的描述可以类比连续函数,将其原始信号  $E(i)$  映射到  $E(i+1) - E(i)$  中,记其映射结果为  $Diff$ :

$$Diff = E(i+1) - E(i) \quad (1)$$

$Diff$  的取值可以反映出 EEG 信号在某一采样点处的幅度变化程度,  $|Diff|$  取值越大,则表明变化程度越剧烈。通过对每一采样点处的脑电信号运用该映射关系,便可得到每个采样点处 EEG 信号的变化情况。本文定义 5 种类别的脑电信号数据集为  $D = \{x_i, y_i\}, i = 1, 2, \dots, N$ 。其中  $N$  为信号的片段数,数据集  $D$  由脑电信号  $x_i$  和类别标签  $y_i$  组成。假设一个 EEG 信号的记录片段为  $Seg = \{x(1), x(2), \dots, x(K)\}$ ,  $K$  为该片段信号的采样点长度。对一个 EEG 信号片段进行上述映射关系的一阶离散差分运算后的信号表示如式(2)所示。

$$\begin{aligned} Seg' &= \{x'(1), x'(2), \dots, x'(K-1)\} \\ x'(k) &= x(k+1) - x(k) \end{aligned} \quad (2)$$

式中:  $k$  表示采样时间点,其取值范围为  $k = 1, 2, \dots, K-1$ 。

为保证每次运算后的信号片段维度保持不变,对初始

信号片段首位数据进行 0 值填充,则原始 EEG 信号片段  $Seg$  更新为:  $Seg = \{0, x(1), x(2), \dots, x(K)\}$ , 再进行一阶离散差分运算,式(2)变形为:

$$\begin{aligned} Seg' &= \{x'(1), x'(2), \dots, x'(K)\} \\ x'(1) &= x(1) - 0 \end{aligned} \quad (3)$$

$$x'(k) = x(k) - x(k-1)$$

其中,  $k$  的取值范围为:  $k = 2, 3, \dots, K$ 。

在新信号片段  $Seg'$  的首位数据前,实施 0 值填充,再进行离散二阶差分处理,同理操作后进行离散三阶和四阶差分运算,得到原始 EEG 信号的二阶、三阶和四阶增量表示为:

$$\begin{aligned} Seg'' &= \{x''(1), x''(2), \dots, x''(K)\} \\ Seg''' &= \{x'''(1), x'''(2), \dots, x'''(K)\} \end{aligned} \quad (4)$$

$$Seg^{(4)} = \{x^{(4)}(1), x^{(4)}(2), \dots, x^{(4)}(K)\}$$

EEG 信号波动特征的信息因此扩大了 4 倍,包含原始 EEG 信号、一阶增量、二阶增量、三阶增量和四阶增量。

### 1.2 卷积模块

CNN 正逐渐成为神经网络中空间域特征分析的首选,于是使用预训练的 ResNet<sup>[13]</sup> 和 DenseNet<sup>[14]</sup> 模型来实现图像特征提取。

定义一层卷积、两层卷积与三层卷积模块,利用网络动态学习的方式提取信号的特征。

#### 1) 一层卷积模块

如图 2 所示,一层卷积模块包含 1 个一维卷积和封装了双线性插值的函数  $f$ ,上采样后的特征图级联整合,其过程可表示为:

$$\begin{aligned} M_1 &= \text{Conv1d}(x_i) \\ M_1 &= f(M_1) \\ M_2 &= \text{concat}((M_1, M_1, M_1), 1) \end{aligned} \quad (5)$$

式中:  $x_i$  表示差分表示的 EEG 信号;  $\text{Conv1d}$  表示一维卷积运算;  $f$  表示双线性插值运算;  $\text{concat}$  为级联拼接运算(下式同理);  $M_1$  和  $M_2$  表示特征图。

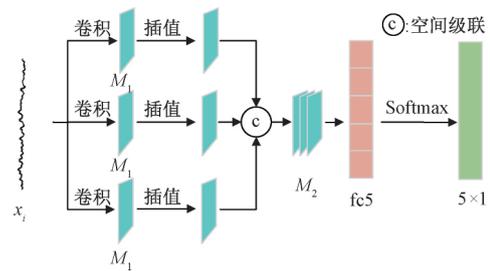


图 2 一层卷积模块

特征图  $M_2$  是由 3 张  $M_1$  特征图在垂直方向上级联而得,然后其被全连接层映射称为一个  $5 \times 1$  的特征向量,用于信号的分类。

#### 2) 两层卷积模块

如图 3 所示,两层卷积模块包含两个一维卷积层、

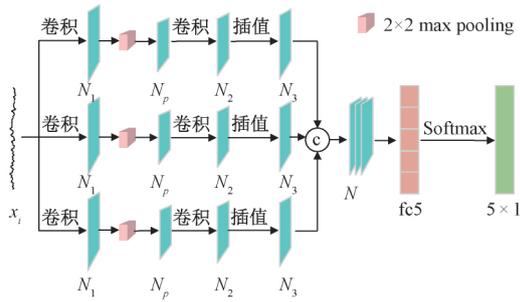


图 3 二层卷积模块

ReLU 激活函数、最大池化层、插值函数和级联函数,其过程可表示为:

$$\begin{aligned}
 N_1 &= Conv1d(x_i) \\
 N_p &= pool1d(N_1, 2) \\
 N_2 &= Conv1d(N_p) \\
 N_3 &= f(N_2) \\
 N &= concat((N_3, N_3, N_3), 1)
 \end{aligned} \tag{6}$$

式中:  $pool1d$  为最大池化操作;  $N_1$  和  $N_2$  是卷积后的特征图;  $N_p$  为池化后的特征图;  $N_3$  是双线性插值上采样后的特征图;  $N$  为级联后的特征图。

3) 三层卷积模块

如图 4 所示,三层卷积模块由 3 个一维卷积层、1 个二维卷积层和 Dropout 层组成,其过程可表示为:

$$\begin{aligned}
 F_j &= f(Conv1d(x_i)) \\
 F_k &= concat((F_{k-3}, F_{k-3}, F_{k-3}), 1) \\
 F_7 &= concat((F_4, F_5, F_6), 1) \\
 F_8 &= Conv2d(F_7)
 \end{aligned} \tag{7}$$

式中:  $F_j$  表示一维卷积运算和插值后的特征图,  $j = 1, 2, 3$ ;  $F_k$  表示  $F_j$  经过级联运算后的特征图,  $k = 4, 5, 6$ ;  $F_7$  为  $F_k$  级联后得到的特征图;  $F_8$  为  $F_7$  进行二位卷积运算后的结果。

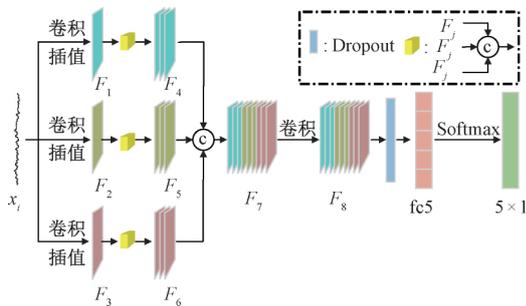


图 4 三层卷积模块

3 个一维卷积层的填充 padding 大小分别为  $1 \times 1$ 、 $2 \times 2$  和  $3 \times 3$ ,卷积核大小分别为  $1 \times 1$ 、 $3 \times 3$  和  $5 \times 5$ 。二维卷积层(卷积核大小为  $1 \times 1$ ,不进行 padding 填充)是用于将特征图  $F_8$  通道数调整为 3 通道来适配 CNN 网络的输入。

2 数据集

使用 5 类癫痫脑电信号数据集<sup>[15]</sup>来验证所设计的算法,该数据集包含 5 组 EEG 信号,每类分别记为 A, B, C, D, E。每类信号由 4 097 个样本组成,持续时间为 23.6 s,使用 173.61 Hz 的采样频率记录。每类信号包含 100 个信号片段,每组的详情如下:

- A 组:由健康受试者睁眼时的脑表面 EEG 记录组成。
- B 组:由健康受试者闭眼时的脑表面 EEG 记录组成。
- C 组:健康受试者的对侧大脑半球的 EEG 记录组成。
- D 组:癫痫病人癫痫未发作时的癫痫病区 EEG 记录组成。

E 组:癫痫病人癫痫发作时的癫痫病区的 EEG 记录组成。

设计了 3 个实验 Exp. 1、Exp. 2 和 Exp. 3,用以测试所提出的方法在识别二类、三类和五类的脑电信号时的性能。

1) Exp. 1: 二分类任务

二类分类实验分为 3 个子实验。

- (1)A 组:被试睁着眼;E 组:被试者癫痫发作。
- (2)B 组:被试闭着眼;E 组:被试癫痫发作。
- (3)A+B 组:被试睁着眼和闭着眼,由 200 个信号段组成;E 组:被试者癫痫发作,由 100 个信号段组成。

2) Exp. 2: 三分类任务

三分类实验由 3 组数据组成:A 组:被试睁着眼;D 组:受试者癫痫未发作;E 组:被试癫痫发作。

3) Exp. 3: 五分类任务

五分类实验由 5 组数据组成:A 组:被试睁着眼;B 组:被试闭着眼;C 组:无癫痫发作的健康受试者;D 组:受试者癫痫未发作;E 组:被试癫痫发作。

3 实验与结果

3.1 实验设定

所有模型均采用反向传播算法进行训练。选择交叉熵作为损失函数,以随机梯度下降(stochastic gradient descent, SGD)作为优化器,学习率 0.001,权重衰减 0.000 1,动量 0.76。权重更新公式如下:

$$w_{i+1} = w_i + \left( 0.76v_i - \beta\alpha w_i - \alpha \frac{\partial L}{\partial w_i} \right) \tag{8}$$

式中:  $w_i$  表示第  $i$  次迭代的权重;  $v_i$  表示  $i$  次迭代的动量;  $\beta$  代表权值衰减参数;  $\alpha$  代表学习率;  $L$  表示损失函数。

算法的有效性用分类准确率来表示:

$$Accu = \frac{TP + TN}{TP + TN + FP + FN} \times 100\% \tag{9}$$

式中:  $TP$  表示 EEG 信号被正确分类的样本数;  $FN$  为 EEG 信号被错误分类的样本数;  $TN$  为不属于某种 EEG 信号却被分类的样本数;  $FP$  为某种 EEG 信号被错误分类的样本数。

### 3.2 各模块实验结果

由于模型训练过程中每次实验都会产生随机数据,所以需要为GPU设置一个随机数种子,每次产生固定数量的随机数,以保证实验的公平性。

定义信号转差分模块为Dif,一层卷积模块为1layer,二层卷积模块为2layers,三层卷积模块为3layers。输入特征的形式定义为Sig和Img,分别代表信号和图像。与简单的二分类任务相比,三分类和五分类任务更具挑战性,各模块的性能如表1~3所示。

表1 各模块在数据集A、B、C、D、E上的表现

Model	ResNet		DenseNet		
	18	34	121	161	169
Sig, Dif	84.4	84.8	85.8	84.9	83.8
Img, Dif+1layer	85.9	85.7	84.6	83.8	84.6
Img, Dif+2layers	84.0	85.0	84.2	82.3	84.0
Img, Dif+3layers	86.7	85.5	84.7	85.3	84.1

由表1~3结果可以看出,当分类任务较少时(二分类和三分类),仅使用EEG信号转差分模块便可以得到较高的分类准确率,为差分EEG信号加入了卷积模块后,分类效果并没有明显的提升。而在五分类任务中,加入了卷积模块的差分EEG信号的分类准确率有了提升,其中最高

表4 与本文使用同一数据集的相关研究结果对比

文献	特征提取方法	分类方法	数据集	正确率/%
Bashivan等 <sup>[16]</sup>	时频图和卷积	CNN	A, B, C, D, E	85.3
Mao等 <sup>[17]</sup>	连续小波变换	CNN	A, B, C, D, E	76.4
Guha等 <sup>[18]</sup>	时域信号	深层神经网络	A, B, C, D, E	80.0
Sadati等 <sup>[19]</sup>	离散小波变换	自适应模糊神经网络	A, D, E	85.9
Wang等 <sup>[20]</sup>	短时傅里叶变换	支持向量机和随机树	{A, B}, E	98.9
Richhariya等 <sup>[21]</sup>	小波变换和独立成分分析	Universum支持向量机	A, E	82.6
			B, E	99.0
			A, B, C, D, E	95.0
本文方法	差分表示和卷积特征图	预训练的CNN	A, D, E	86.7
			{A, B}, E	92.8
			A, E	98.4
			B, E	99.8

1) Exp. 1: 二分类任务,数据集A和E; B和E; {A, B}和E。

(1)文献[21]中对数据集A、E和数据集B、E使用5折交叉验证划分数据集。采用同样的方法划分相同数据集。所提出的方法在数据集A、E和数据集B、E上分别获得了99.8%和97.0%的分类准确率。对于数据集A和E,本文方法的分类能力与文献[21]没有显著差异。而数据集B和E的分类性能与文献[21]相比,提高了2%。

表2 各模块在数据集A、D、E上的性能表现

Model	ResNet		DenseNet		
	18	34	121	161	169
Sig, Dif	92.5	91.6	91.9	92.8	92.1
Img, Dif+1layer	91.7	91.5	91.2	90.7	90.7
Img, Dif+2 layers	92.1	92.8	90.7	91.7	84.3
Img, Dif+3layers	92.0	92.5	90.2	90.7	90.3

表3 各模块在数据集{A, B}, E上的性能表现

Model	ResNet		DenseNet		
	18	34	121	161	169
Sig, Dif	97.2	97.5	96.7	97.3	97.4
Img, Dif+1layer	96.5	97.4	95.9	96.1	95.7
Img, Dif+2 layers	97.1	97.5	95.2	96.4	95.8
Img, Dif+3 layers	96.4	98.4	96.4	95.8	97.1

提升了2.3%。

### 3.3 与现有成果比较

二类和三类分类问题被大多数研究关注,少数研究使用整个五类数据集。表4所示为与本文使用相同数据集的类似研究比较结果,考虑到比较的公平性,所以需要调整训练数据和测试数据的比例,使之与表4中提到的参考文献的比例一致。

(2)在文献[20]中,对数据集{A, B}和E采用了10折交叉验证划分方法,采用同样的数据集划分方法,所提出的方法分类准确率达到98.4%,略微逊色于文献[20]中的98.9%。

2) Exp. 2: 三分类任务,数据集A, D, E。

文献[19]选取50%的数据作为训练集,剩余50%作为测试集。采用同样的数据集划分方法,在三分类问题上,所提出的方法获得了92.8%的分类准确率,高出文献[19]方

法 6.9%。

3) Exp. 3: 五分类任务,数据集 A, B, C, D, E。

(1)文献[16]用 76%、12%和 12%的数据作为训练集、验证集和测试集。

(2)文献[17]和[18]使用 70%的数据集作为训练集, 30%作为测试集。

(3)文献[20]采用 10 倍交叉验证法。

按照上述划分方法,得到了如下结果:

按照(1)中的数据划分,所提出的方法 5 类分类的结果为 86.7%,比文献[16]高 1.4%。

按照(2)中数据划分,所提出的方法得到 84.5%的准确率,分别比文献[17]和[18]高 8.1%和 4.5%。

按照(3)中数据划分,所提出的方法获得 84.7%的分类准确率,比文献[20]高 2.1%。

所取得的结果表明,结合动态学习的离散差分模块方法在三类和五类脑电信号分类问题上有较好的表现。

#### 4 结 论

针对 EEG 信号多分类问题中相似特征难以区分的问题,设计了信号转差分模块和卷积模块,结合预训练的 CNN 网络实现癫痫脑电信号的特征提取和分类任务。所提出的方法在两分类问题上达到了 99.8%的准确率,在三分类问题上达到了 92.8%的准确率,在五分类问题上达到了 86.7%的准确率,证明了关注 EEG 信号的波动特征,使用离散差分方法来平稳非线性信号的方法是可行的。但是为了达到更高的准确率、算法的可解释性和更快的运行速度,还需要做更多的工作。

#### 参考文献

- [1] KHAIRULLAH E, ARICAN M, POLAT K. Brain-computer interface speller system design from electroencephalogram signals with channel selection algorithms[J]. *Medical Hypotheses*, 2020, 141:109690.
- [2] MINGUILLON J, LOPEZ-GORDO M A, PELAYO F. Trends in EEG-BCI for daily life: Requirements for artifact removal[J]. *Biomedical Signal Processing and Control*, 2017, 31:407-418.
- [3] OWN Y H, SHIN S B, KIM S D. Electroencephalography based on fusion two-dimensional(2D)-convolution neural networks(CNN) model for emotion recognition system[J]. *Sensors*, 2018, 18:1383-1395.
- [4] SUPRATAK A, DONG H, WU C. DeepSleepNet: A model for automatic sleep stage scoring based on raw single-channel EEG[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2017, 25: 1998-2008.
- [5] 李明阳,陈万忠,张涛. 基于 DD-DWT 和 Log-Logistic 参数回归的癫痫脑电自动识别方法[J]. *仪器仪表学报*, 2017, 38(6):1368-1377.
- [6] 李明爱,张梦,孙炎珺. 基于小波包和深度信念网络的脑电特征提取方法[J]. *电子测量与仪器学报*, 2018, 32(1):111-118.
- [7] RAMOS R, OLVERA-LOPEZ J. Analysis of EEG signals processing techniques based on spectrograms[J]. *Research in Computing Science*, 2017, 145:1-12.
- [8] FAUST O, ACHARYA O R. Automatic identification of epileptic and background EEG signals using frequency domain parameters[J]. *International Journal of Neural Systems*, 2010, 20:159-176.
- [9] 杨默涵,陈万忠,李明阳. 基于总体经验模态分解的多类特征的运动想象脑电识别方法研究[J]. *自动化学报*, 2017, 43(5): 743-752.
- [10] MUHAMMAD A G, HOSSAIN M S. EEG pathology detection based on deep learning[J]. *IEEE Access*, 2019, 7:27781-27788.
- [11] BASHIVAN P, RISH I, YEASIN M. Learning representations from EEG with deep recurrent-convolutional neural networks[J]. *Computer Science*, 2015, DOI:10.1109/CVPR.2016.522.
- [12] ROY Y, BANVILLE H, ALBUQUERQUE I. Deep learning-based electroencephalography analysis: A systematic review[J]. *Journal of Neural Engineering*, 2019, 16(5):051001.
- [13] HE K M, ZHANG X Y, REN S Q. Deep residual learning for image recognition[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2016: 770-778.
- [14] HUANG G, LIU Z. Densely connected convolutional networks[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017: 4700-4708.
- [15] ANDRZEJAK R G, LEHNERTZ K, MORMANN F. 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*, 2001, 64:061907.
- [16] BIZPOUSLOS P, LAMBROU G I. Signal2Image modules in deep learning neural networks for EEG classification[C]. *41st Annual International Conference of the IEEE Engineering in Medicine and Biology*, 2019: 702-705.
- [17] MAO W L, FATHURRAHMAN H I K, LEE Y. EEG dataset classification using CNN method[J]. *Journal of Physics: Conference Series*, 2019, 1456:012017.
- [18] GUHA A, GHOSH S, ROY A. Epileptic seizure

- recognition using deep neural network[J]. Emerging Technology in Modelling and Graphics, 2020, 937: 21-28.
- [19] SADATI N, MOHSENI H R, MAGHSOUDI A. Epileptic seizure detection using neural fuzzy networks[C]. IEEE International Conference on Fuzzy Systems, 2006: 596-600.
- [20] WANG G J, DENG J H, CHOI K S. Detection of epilepsy with electroencephalogram using rule-based classifiers[J]. Neurocomputing, 2017, 228:283-290.
- [21] RICHHARIYA B, TANVEER M. EEG signal classification using universum support vector machine[J]. Expert Systems with Applications, 2018, 106:169-182.

#### 作者简介

潘奕竹, 硕士, 主要研究方向为脑电信号处理与模式识别。

E-mail: pyzlovelife@njust.edu.cn

沈娜, 博士, 副研究员, 主要研究方向为测试计量技术及仪器。

E-mail: snbox@163.com