

DOI: 10.19650/j.cnki.cjsi.J2007199

# 基于深度学习的癫痫脑电不平衡分类方法\*

费洪磊<sup>1</sup>, 袁琦<sup>1</sup>, 郑玉叶<sup>2</sup>

(1. 山东师范大学物理与电子科学学院 济南 250358; 2. 日照市人民医院 日照 276800)

**摘要:** 癫痫发作自动检测技术对癫痫患者的诊断和治疗具有重要意义。由于癫痫发作期持续时间较短, 发作期与非发作期的脑电数据分布是不平衡的。针对该问题, 本文提出了一种不平衡分类与深度学习相结合的癫痫发作自动检测方法。首先, 为防止不同类别数据之间界限模糊, 使用 Borderline-SMOTE 算法对 1/3 训练集做平衡处理; 之后, 设计了金字塔型的一维深度卷积神经网络, 并利用平衡处理的训练集进行训练。与常见的二维卷积神经网络不同, 本文构造的一维卷积神经网络减少了训练参数, 提高了训练速率, 能够有效地避免由于训练样本较少而造成的过拟合。在长达 991 小时的长程头皮脑电数据集上的实验表明, 经过平衡处理后的检测效果得到明显改善, 最佳敏感度达到 92.35%, 特异性达到 99.88%, 阳性预测率达到 90.68%, 阴性预测率达到 99.91%。同时, 与其他癫痫检测方法的比较表明, 本文方法具有更好的检测结果, 更加符合临床应用的要求。

**关键词:** 癫痫检测; 脑电信号; 不平衡分类; Borderline-SMOTE; 一维深度卷积神经网络

中图分类号: TP391 TH776 文献标识码: A 国家标准学科分类代码: 310.6110 520.2060

## Imbalanced classification for epileptic EEG signals based on deep learning

Fei Honglei<sup>1</sup>, Yuan Qi<sup>1</sup>, Zheng Yuyue<sup>2</sup>

(1. School of Physics and Electronics, Shandong Normal University, Ji'nan 250358, China;

2. Peoples' Hospital of Rizhao, Rizhao 276800, China)

**Abstract:** Automatic seizure detection is of great significance to the diagnosis and treatment of patients with epilepsy. Due to the short duration of epileptic seizure period, the EEG signal distribution between the seizure period and the non-seizure period is imbalanced. To solve this problem, an automatic detection method of epilepsy based on the fusion of imbalanced classification and deep learning is proposed. Firstly, the Borderline-SMOTE algorithm is applied to one-third training set to prevent the boundaries between different classes from blurring. Then, a pyramidal one-dimensional convolutional neural network is designed, which is trained with the balanced processing data. Different from the common 2D convolutional neural network, the 1D convolutional neural network reduces the number of training parameters. The training rate is improved, and the overfitting is avoided effectively which is caused by the small number of training samples. By utilizing the 991 hours long scalp EEG database, the effectiveness of the seizure detection after balanced treatment is significantly improved. The sensitivity, specificity, positive predictive value, and negative predictive value reach 92.35%, 99.88%, 90.68%, and 99.91%, respectively. Meanwhile, the comparison with other seizure detection methods shows that the proposed method has better performance. It is suitable for satisfying requirements of clinical application.

**Keywords:** seizure detection; EEG signals; imbalanced classification; Borderline-SMOTE; deep one-dimensional convolutional neural network

## 0 引言

癫痫是一种慢性、复发性和非传染性的神经系统疾

病,由大脑神经细胞的突然异常放电引起<sup>[1]</sup>,它会导致意识丧失、运动、知觉、情绪或精神功能的紊乱<sup>[2-3]</sup>。全世界约有 5 000 万癫痫患者,其中的 25% 没有得到有效的手术或药物控制,必须忍受癫痫的痛苦<sup>[4]</sup>。脑电图 (electro

收稿日期: 2019-12-06 Received Date: 2020-12-06

\* 基金项目: 国家自然科学基金 (61501283) 项目资助

encephalo gram, EEG)是一种重要的临床检测手段,它是由脑内的颅内电极或头部表面的头皮电极获得的。脑电图信号反映大脑的电信号活动,并包含实时信息,如尖峰和锐波<sup>[5]</sup>。因此,脑电信号在鉴别癫痫发作和非癫痫发作信号以及在术前评估中识别癫痫区方面起着重要作用<sup>[6]</sup>。传统的癫痫检测依赖于神经学家对长期脑电图记录的视觉观察。然而,随着脑电图数据的不断增加,目视检查是一项费时且劳动任务繁重的工作<sup>[7]</sup>,并且视觉判断的准确性在很大程度上依赖于神经学家的经验和熟练程度。癫痫的自动检测将为提高癫痫诊断的效率和准确率提供一个更有效更客观的解决方案<sup>[8-9]</sup>。

癫痫发作的自动检测受到许多研究者的关注,各种癫痫发作自动检测技术已经被提出。现有的癫痫发作自动检测技术是传统的信号处理(signal processing, SP)和机器学习(machine learning, ML)。这些技术中的许多方法都显示对一个问题良好的准确性,但对其他问题却不能准确的完成<sup>[10]</sup>。近年来,深度学习模型在分析时间序列信号,特别是医学脑电信号方面取得了显著的成绩<sup>[11]</sup>。Amir等<sup>[12]</sup>和Acharya等<sup>[13]</sup>开发了一种深度卷积神经网络(convolutional neural network, CNN)来进行癫痫发作检测。与传统的人工提取特征相比,深度卷积神经网络自动提取特征的特性明显提高了癫痫发作检测的性能<sup>[14-15]</sup>。Petrosian等<sup>[16]</sup>使用循环神经网络(recurrent neural network, RNN)与小波分解系数相结合的方法进行癫痫预测;Tsiouris等<sup>[17]</sup>提出一种两次的长短期记忆神经网络(long-short term memory, LSTM)来预测癫痫发作事件,实验表明长短期记忆网络也是一种性能优于传统递归神经网络的深度模型<sup>[18]</sup>;此外,CNN与LSTM相结合的方法也用于脑电信号分类、致痫区识别和定位<sup>[19-20]</sup>;Rubén等<sup>[21]</sup>分别使用傅里叶变换、小波变换和经验模式分解处理脑电信号,然后使用两层的卷积神经网络进行特征提取和分类。本文采用金字塔型的一维深度卷积神经网络,与常见的二维卷积神经网络相比,具有较少的训练参数,从而有效节省硬件资源。

由于在长程连续脑电记录中,癫痫发作期的持续时间比非发作期短得多,因此,在癫痫发作检测中,两类脑电数据的分布是极端不平衡的。经不平衡数据集训练的分类器,判别决策可能偏向于多数类,即非发作期<sup>[22]</sup>,从而对分类器性能产生明显的不利影响,它既影响训练阶段的收敛性,也影响在测试集上的泛化。本研究组曾针对脑电数据不平衡的情况提出了一种基于加权极端学习机(extreme learning machine, ELM)的癫痫检测方法,根据类分布对脑电训练样本进行不同的权值分配,从而有效缓解了类分布不平衡造成的性能偏差<sup>[23]</sup>,但最终的检测结果还有待提高;本研究组还曾采用欠采样方法将数据分割成多个平衡子集,每个子集用于训练一个独立的

支持向量机(support vector machine, SVM)分类器,使用集成学习的方法构造一个强分类器来解决不平衡分类问题<sup>[24]</sup>。然而,欠采样方法降低了训练集的数据量,不利于对深层神经网络的训练。因此,本文提出采用过采样的算法<sup>[25]</sup>来基本实现训练集中癫痫发作期脑电数据与非发作期脑电数据分布的平衡,从而使所构造的深层神经网络模型达到更加优异的发作检测效果。

本文提出了一种一维深度卷积神经网络与不平衡分类相结合的癫痫发作自动检测方法。分别采用随机过采样、SMOTE<sup>[26]</sup>和BLSM<sup>[27]</sup>(Borderline-SMOTE)算法对数据集做平衡处理,在此基础上,设计并训练用于区分癫痫发作期和非发作期样本的一维卷积神经网络,实验结果表明,本文的方法有效提高了癫痫检测的效果。

## 1 数据库

本研究采用的儿童脑电数据集(CHB-MIT)是收集于波士顿儿童医院的开放数据集<sup>[28]</sup>。可从PhysioNet官网(<http://physionet.org/physiobank/database/chbmit/>)下载<sup>[29]</sup>。在停止抗癫痫药物治疗后,对受试者进行了长达几天的监测,以确定其癫痫特征并评估其是否适合外科干预。研究对象共有22例,其中包括5名男性,年龄3~22岁,17名女性,年龄1.5~19岁,2010年,chb24添加到这一数据集。除病例1和21来自同一受试者外,24例记录均来自单一受试者的脑电信号<sup>[17]</sup>。

样本的采样频率为256 Hz,大部分样本数据采样时长为1 h,案例10的采样时长为2 h,案例4、6、7、9、23的数据采样时长为4 h,样本数据最终被分割为每段1 h时长。这些记录采用国际10~20脑电图电极位置和命名系统。大部分受试者的脑电图通道为23个,少数为26、28或32个。每个脑电图记录包含23个常用通道,分别为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, CZ-PZ, P7-T7, T7-FT9, FT9-FT10, FT10-T8和T8-P8<sup>[30]</sup>。

在本文研究中,使用全部通道的脑电信号来评估分类器的性能,时长共计991 h。在数据处理之前,将脑电信号分割为每4 s一段,每段对应1 024个采样数据,实验中将数据集的50%作为神经网络的训练集,50%作为测试集。数据集信息如表1所示。

## 2 研究方法

### 2.1 BLSM 算法

合成新数据是处理不平衡分类问题的常用方法。BLSM是基于SMOTE算法提出的合成边界数据的不

表1 数据集信息

Table 1 Information of dataset

案例	性别	年龄	发作期/s	非发作期/s
1	F	11	420	12 600
2	M	11	164	118 800
3	F	14	384	111 600
4	M	22	368	532 800
5	F	7	544	122 400
6	F	1.5	120	147 600
7	F	14.5	316	216 000
8	M	3.5	908	54 000
9	F	10	216	212 400
10	M	3	380	129 600
11	F	12	796	115 200
12	F	2	1 372	36 000
13	F	3	504	82 800
14	F	9	148	61 200
15	M	16	1 846	93 600
16	F	7	56	46 800
17	F	12	288	61 200
18	F	18	248	104 400
19	F	19	232	97 200
20	F	6	268	82 800
21	F	13	192	97 200
22	F	9	196	100 800
23	F	6	400	68 400
24	-	-	484	36 000

平衡分类算法。为了实现更好的分类,大多数分类算法在训练过程中都试图尽可能准确的学习每个类的边界,在边界上的样本和在边界附近的样本比远离边界的样本更容易被误分类,因此边界样本信息对分类任务更有意义。BLSM 算法只是对边界附近的部分样本进行过采样,更加符合分类的预期。在 BLSM 中,容易误分类的少数类样本得到的训练更多。

首先找到边界上的少数类样本。如图 1 所示,少数类样本可分类 3 类:A 类 K 近邻样本超过一半为少数类样本;B 类 K 近邻样本超过一半为多数类样本;C 类 K 近邻样本全部为多数类样本。然后使用 B 类样本与 K 近邻中随机选取的少数类样本合成新样本。需要强调的是,不同类别的样本数量差异很大,如果使用 BLSM 算法使数据达到了完全的平衡,可能会导致不同类之间的界

限变得模糊,从而更容易导致误分类。因此,分别选取不同比例的训练集使用 BLSM 算法处理,以得到最佳分类结果。

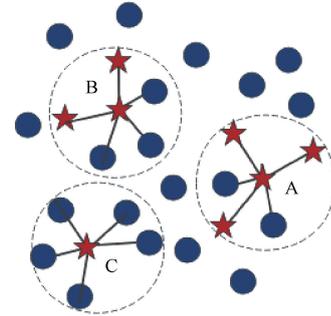


图1 BLSM 3类少数类样本

Fig. 1 Three kinds of minority samples

## 2.2 一维深度卷积神经网络

本文提出的基于一维深度卷积神经网络的癫痫发作自动检测系统的核心是一维卷积神经网络(one-dimensional convolutional neural network, 1D-CNN)。1D-CNN 模型的主要部分是卷积层,它由许多通道组成,每一个通道中神经元的输出就是对前一层卷积层的输入信号或者特征映射与固定感受野的卷积核进行卷积运算的结果,通过这种信号分析方式来学习表征信息的层次结构。

脑电信号为二维时间序列,为此,本研究提出了一个金字塔型的 1D-CNN 模型<sup>[31]</sup>,其总体结构如图 2 所示,这是一个端到端的模型。与传统的 CNN 模型不同,它不包含任何的池化层,通过设置更大的卷积步长,来减少一些不必要的特征和冗余。卷积层和全连接层从输入信号中学习层次从低到高的特征,将具有语义表示的高级特征作为输入进入到最后一层的 softmax 分类器中,对输入的脑电信号的种类进行预测。

CNN 模型通常采用由粗到细的方法构造,即低层包含少量的卷积核,而高层包含大量的卷积核,但这种结构涉及大量的参数学习,复杂度较高。本研究采用的金字塔型 CNN,在低层中包含大量卷积核,高层中包含少量卷积核,该结构大大减少了可学习参数的数量,避免了过拟合的风险。表 2 所示为金字塔型 CNN 和经典 CNN 的可训练参数对比。如表 3 所示,卷积 1 层、卷积 2 层、卷积 3 层和卷积 4 层分别包含 32、24、16 和 8 个卷积核,其目的为在低层提取大量微观结构,由更高层合成更高层次的特征,作为判别依据的特征数量较少,但区别性较大,随着网络的深入,模型会隐式的进行特征选择。

1D-CNN 模型结构如图 2 所示,将预处理后的脑电信号数据输入 1D-CNN,每个卷积块由 3 部分组成,卷积层(Conv)、批归一化层(BN)和非线性激活层(ReLU)。模型中的其他部分详情如表 3 所示。

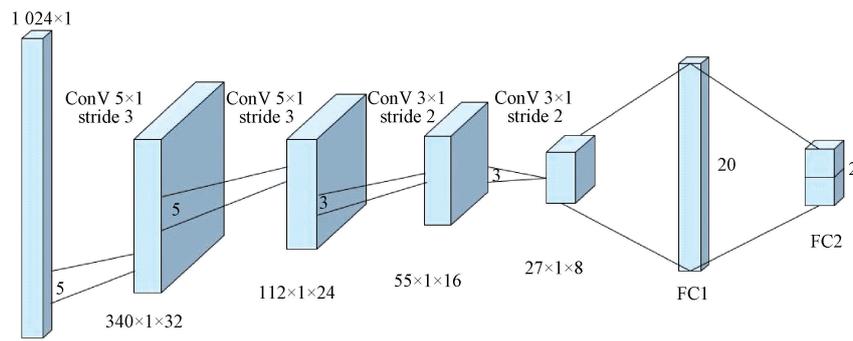


图2 神经网络架构

Fig. 2 The architecture of neural network

表2 参数对照表

Table 2 Parameters comparison

网络层类型	金字塔型 1D-CNN	经典 1D-CNN
ConV1	192	48
BN	128	32
ConV2	3 864	656
BN	96	64
ConV3	1 168	1 176
BN	64	96
ConV4	392	2 336
BN	32	128
FC1	4 340	17 300
Dropout	0	0
FC2	42	42
Total	10 318	21 878

表3 详细网络参数

Table 3 Detailed network parameters

网络层类型	卷积核数量、尺寸、步长	Dropout 率	激活函数
输入层	1 024×1	-	-
卷积块 1	ConV1	32, 1×5, 3	ReLU
	批归一化	-	-
卷积块 2	ConV2	24, 1×5, 3	ReLU
	批归一化	-	-
卷积块 3	ConV3	16, 1×3, 2	ReLU
	批归一化	-	-
卷积块 4	ConV4	8, 1×3, 2	ReLU
	批归一化	-	-
FC	全连接层 1	20	-
Dropout	Dropout	-	0.5
FC	全连接层	2	-

## 1) 卷积层

利用一维卷积运算对一维信号(如时间序列)进行滤波,提取判别特征。卷积层由感受野和深度为  $C$  的  $K$  个卷积核组成,卷积核数等于前一层中的信道数或特征映射数。卷积层  $X = \{X_{ij}; 1 \leq i \leq C, 1 \leq j \leq Z\}$  与  $K$  个卷积核  $Y = \{y_{lm}; 1 \leq l \leq K, 1 \leq m \leq K\}$  进行卷积,

$$y_{lm} = \sum_{d=1}^c \sum_{e=1}^{Rf} k_{d,e}^l \times x_{d,e+m} \quad (1)$$

式中:  $C$  是通道数;  $Z$  是每个通道上的神经元数量;  $Rf$  为接受域;  $k^l$  为卷积核,  $l = 1, 2, \dots, K$ ,  $m$  为该层各通道的神经元数,  $K$  为该层的总通道数。生成的卷积层中的通道数等于内核的数量。不同的卷积核从输入信号中提取不同类型的判别特征。内核的数量随着网络深度变化而变化,低层的内核学习微观结构,高层的内核学习高级特征。在该模型中,后一层卷积核数量比前一层少 8 个,以保持金字塔结构<sup>[30]</sup>。

## 2) 批归一化层

在训练过程中,由于参数的不断变化,特征图的分布会发生变化,这就迫使网络使用较小的学习速率和初始化参数。在饱和和非线性的情况下,这种情况会减慢学习速率,降低系统的学习能力,这种现象称为内部协变量移位,通常使用 BN 的方法来解决这一问题。在 BN 中,每一层的每个小批的激活都被规范化,有助于避免参数的特殊初始化,同时提供更快的收敛速度。在该模型中,我们只在训练过程中对每一层卷积层使用 BN。

## 3) 全连接层

在卷积层后,设计了两个全连接层(FC), ConV4 层中所有的神经元与 FC1 的所有神经元连接, FC1 的所有神经元与 FC2 中的两个神经元完全连接,最终输出判别结果。

### 3 实验结果

#### 3.1 实验过程

本研究涉及的实验过程主要由 3 部分组成:数据预处理、不平衡分类处理、特征提取与分类。数据预处理阶段,数据的采样时长大多数为 1 h,过长的数据不利于网络学习数据的特征信息,因此将头皮脑电信号分割成等长的小段数据,本实验选取的分割时长为 4 s;不平衡分类处理阶段,将预处理的数据分别进行无处理、随机过采样处理、SMOTE 和 BLSM 算法处理,其中 BLSM 分别随机选取训练集的全部、1/2 和 1/3 训练集

做平衡处理。将 6 种方法处理后的数据分别输入一维卷积神经网络中进行特征提取与分类,比较 6 种方法的分类表现;特征提取与分类,将处理的数据输入一维卷积神经网络中,由卷积神经网络进行特征提取与分类。6 次不平衡处理分别作为 1、2、3、4、5 和 6,验证处理不平衡分类算法在模型上的有效性。数据集的 50% 在经过不平衡分类处理之后作为训练集,另外 50% 作为测试集测试模型的分类能力。整个实验流程如图 3 所示。本实验实施环境配置为 64Bit Windows 10 操作系统,Intel (R) Core (TM) i7-7700 CPU 处理,GeForce GTX 1050 Ti 显卡,模型搭建基于 Python 的 Keras 深度学习框架。

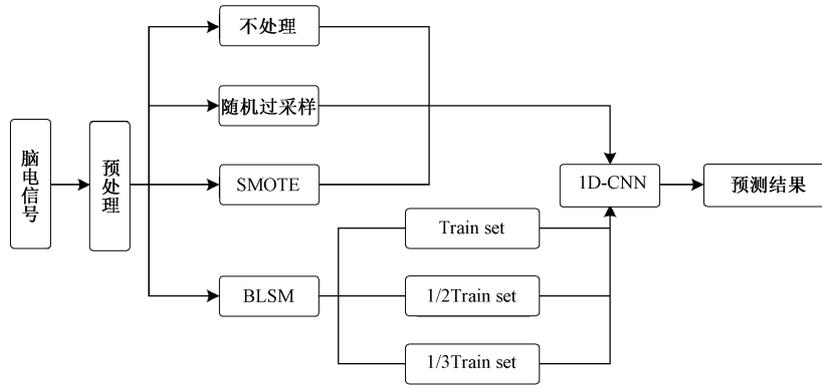


图 3 实验流程

Fig. 3 The flow of experiment

#### 3.2 评价指标

本研究采用敏感度、特异性、阳性预测率和阴性预测率对模型性能进行评估。在本文中,正例表示癫痫发作期,负例表示非发作期,则评价指标的定义如下:

1) 敏感度(true positive rate, TPR):描述识别出的正例占有所有正例的比例,

$$TPR = \frac{TP}{TP + FN} \quad (2)$$

2) 特异性(true negative rate, TNR):描述识别出的负例占有所有负例的比例,

$$TNR = \frac{TN}{TN + FP} \quad (3)$$

3) 阳性预测率(positive predictive value, PPV):描述识别出的正例占预测为正例的比例,

$$PPV = \frac{TP}{TP + FP} \quad (4)$$

4) 阴性预测率(negative predictive value, NPV):描述识别出的负例占预测为负例的比例,

$$NPV = \frac{TN}{TN + FN} \quad (5)$$

其中,  $TP$  为被正确诊断为正例的正例;  $TN$  为被正确诊断为负例的负例;  $FP$  为被错误诊断为正例的负例;  $FN$  为被错误诊断为负例的正例。

#### 3.3 实验结果

使用 3 种 BLSM 方法处理训练集训练分类器后在每个案例上进行测试,得到的分类结果如图 4 所示。

从图 4 可以看出,使用 BLSM 算法处理 1/3 训练集的整体结果最佳。病例 chb15 的分类结果较其他病例明显偏低,考虑是数据受噪声干扰过大,使不同种类样本特征界限模糊,下一步的工作是在处理之前对数据进行去噪处理,进一步明确不同种类的样本界限。

不同的数据不平衡处理方法后的分类结果如表 4 所示,本文选择了随机过采样、SMOTE 和 BLSM 3 种不平衡处理方法。从表 4 中可看出,与未经处理的数据分类结果相比,随机过采样和 SMOTE 算法对分类结果有明显的改善,BLSM 算法的分类结果优于随机过采样和 SMOTE 算法,其中针对 BLSM 算法分别采用训练集 1/2 和 1/3 处理训练集,结果显示 BLSM 算法使用 1/3 的训练集的分类结果略优于选取 1/2 和全部训练集的分类结果。

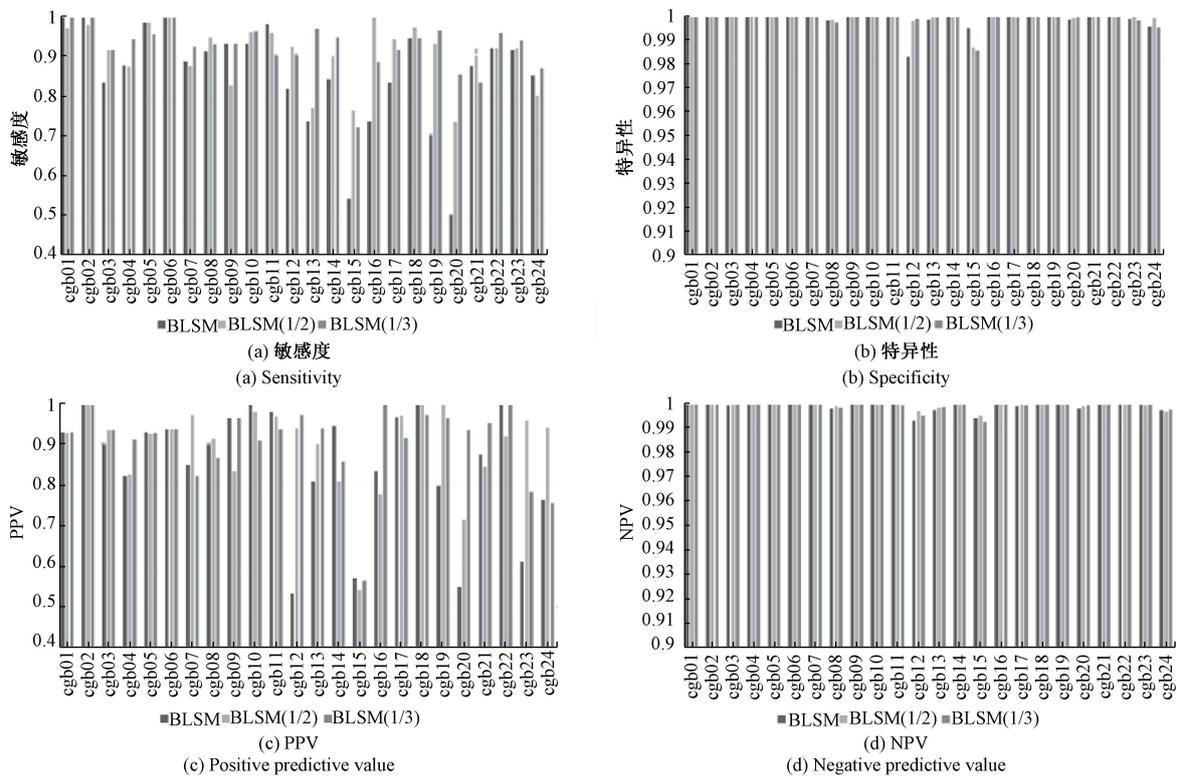


图4 3种BLSM方法处理数据集的分类结果

Fig. 4 The classification results using three methods of BLSM

表4 不同不平衡处理方法分类结果

Table 4 The classification results of different

方法	指标			
	不平衡处理方法	%		
	敏感性	特异性	PPV	NPV
不处理	55.23	95.79	57.69	99.78
随机过采样	81.12	93.86	67.70	99.92
SMOTE	84.41	93.35	69.21	99.89
BLSM	85.66	99.85	85.32	99.89
BLSM(1/2)	90.81	99.91	89.79	99.93
BLSM(1/3)	92.35	99.89	90.68	99.91

## 4 讨论

在数据集中随机抽取6名患者的数据进行对比试验。图5为实验1~4的1D-CNN在选择不同网络优化器的情况下的性能表现。网络使用RMSProp优化器时,实验1~4平均敏感性为54.87%、81.96%、94.45%和85.96%,平均特异性为95.68%、93.81%、93.42%和99.76%,平均PPV为57.76%、68.78%、69.21%和85.67%,平均NPV为99.68%、99.92%、99.88%和

99.9%,优于adam和sgd优化器。综上所述,选用RMSProp优化器网络的分类性能最佳。

在使用RMSProp作为优化器的基础上,分别选择不同的MiniBatchSize再次进行对比实验。MiniBatchSize分别选择[32,64,128,256,512],实验1、2、3和4的结果如图6所示。可以看出,MiniBatchSize值为128时的平均敏感性为54.82%、82.05%、84.85%和85.92%,平均特异性为95.12%、93.94%、93.79%和99.9%,平均PPV为57.68%、68.32%、69.62%和85.46%,平均NPV为99.87%、99.92%、99.9%和99.89%,优于其它MiniBatchSize。综上所述,MiniBatchSize的值为128时,网络分类性能最佳。

不同的癫痫检测方法在CHB-MIT脑电数据集上的分类表现如表5所示。一些研究在部分数据集上进行验证。Orosco等<sup>[32]</sup>提出一种基于小波变换和线性判别分析的非特异性癫痫检测方法,最终得到敏感性92.6%、特异性99.9%;Chandel等<sup>[33]</sup>提出了一种基于三元小波分解与KNN分类相结合的癫痫发作检测方法,最终得到敏感性98.36%、特异性99.62%;Chen等<sup>[34]</sup>提出了一种自动搜索DWT设置的癫痫检测方法,最终得到敏感性91.71%、特异性92.89%、PPV92.80%、NPV91.80%。但这3项研究只使用了少部分数据集数据,远远低于本研

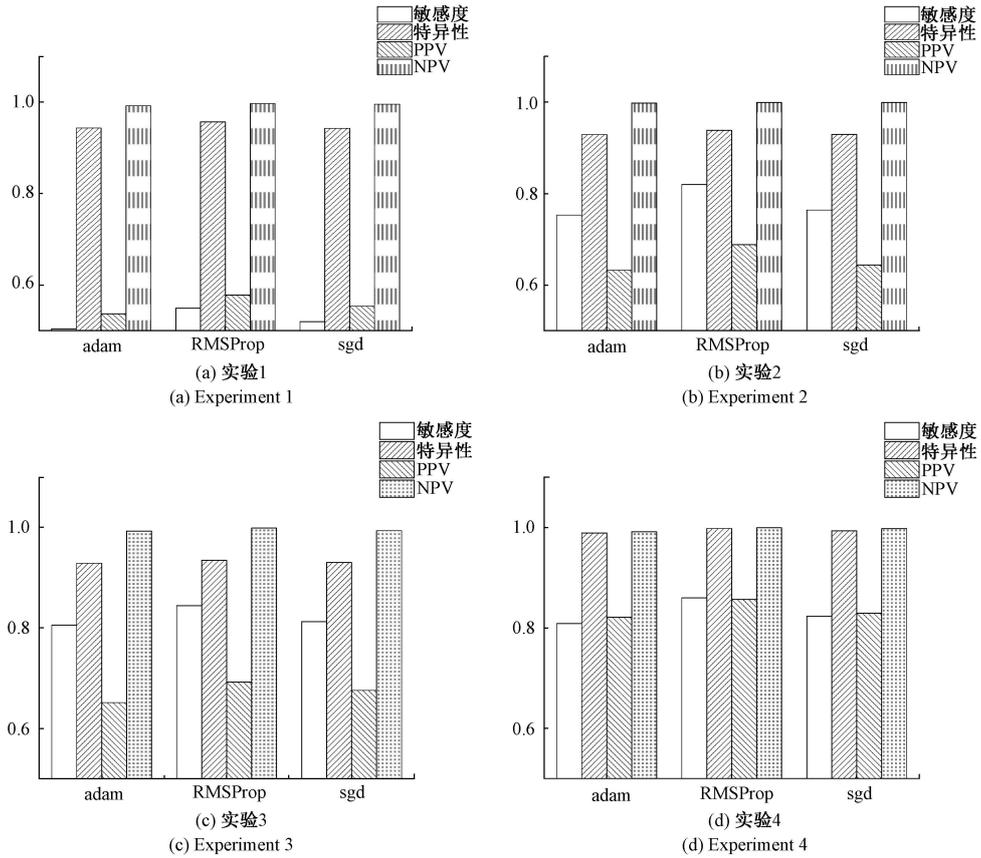


图 5 实验 1~4 不同优化器分类结果

Fig. 5 The classification results of the experiments 1 to 4 with different optimizers

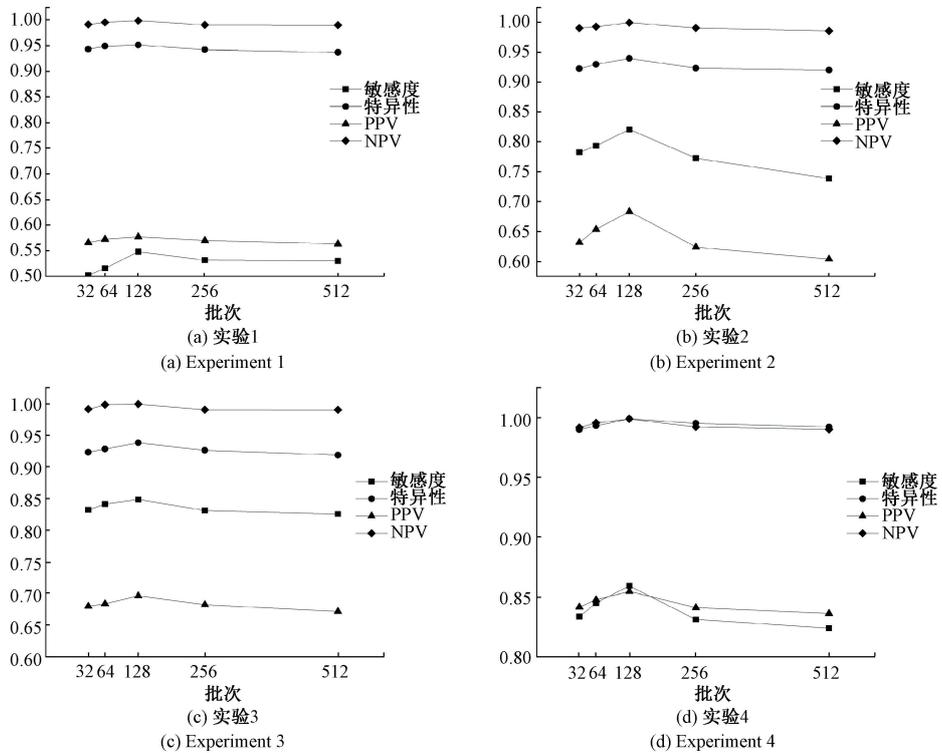


图 6 实验 1~4 不同 MiniBatchSize 分类结果

Fig. 6 The classification results of the experiments 1 to 4 with different MiniBatchSize

表5 不同癫痫检测方法在 CHB-MIT 数据集的分类结果

Table 5 The results of different methods using the CHB-MIT database

方法	案例数	时长/h	敏感度/%	特异性/%	PPV/%	NPV/%
CNN+MIDS <sup>[15]</sup>	23	-	74.08	92.46	-	-
Data augmentation <sup>[15]</sup>	23	-	72.11	95.89	-	-
LRCN(CNN+LSTM) <sup>[20]</sup>	24	-	84.00	99.00	-	-
Dyadic WT,LDA <sup>[32]</sup>	18	152.80	92.60	99.90	-	-
Triadic WT,KNN <sup>[33]</sup>	18	397.00	98.36	99.62	-	-
Dyadic WT(coif 3),SVM <sup>[34]</sup>	18	76.92	91.71	92.89	92.80	91.80
KNNC <sup>[35]</sup>	-	-	88.00	88.00	-	-
Kernel Machine(SVM) <sup>[36]</sup>	-	-	85.59	91.32	90.81	86.38
25%数据训练 <sup>[37]</sup>	23	-	89.10	94.80	-	-
50%数据训练 <sup>[37]</sup>	23	-	88.27	93.21	-	-
随机过采样+CNN	-	-	81.12	93.86	67.70	99.92
SMOTE+CNN	-	-	84.41	93.35	69.21	99.89
BLSM+CNN	24	991.00	85.66	99.85	85.32	99.89
BLSM(1/2 Train set)+CNN	-	-	90.81	99.91	89.79	99.93
BLSM(1/3 train set)+CNN	-	-	92.35	99.88	90.68	99.91

究使用的数据量。除此之外,部分研究采用还较少的评价标准,Fergus等<sup>[35]</sup>使用K最近邻域分类器,得到敏感度和特异性均为88%;Liang等<sup>[20]</sup>结合LSTM与CNN,提出一种18层的长期复发卷积网络,得到了敏感度84%,特异性99%。此结果低于本实验最佳结果,且评价标准较少。

实验结果如表5所示,本研究结果表明,数据不平衡会严重影响神经网络的分类性能,通过不平衡分类处理方法可有效改善网络的鉴别性能。未经任何处理的数据训练网络得到的分类器的分类能力较差,判别依据受到多数类样本的影响,只在极少案例上有较好表现;数据经随机过采样处理后训练网络得到的分类器性能明显得到改善,少数案例在测试时被全部判别为多数类,在部分案例上有良好表现;经SMOTE算法处理的数据训练网络得到的分类器性能得到进一步改善,大部分案例都有良好表现;使用BLSM算法处理数据的分类结果优于SMOTE算法,其中以1/3训练集数据使用BLSM算法处理后的分类结果为最佳。

本研究使用深度学习的方法,避免了手动提取特征的过程,也不需要选择最优特性训练分类器,这是相对于传统机器学习算法的优势。与传统CNN相比,大大减少了可训练参数的数量,节省了系统的内存。

本研究使用CHB-MIT数据库的全部数据,共计991h。分别使用随机过采样、SMOTE和BLSM算法对数据集做平衡处理,然后使用一维深度卷积神经网络进行

分类,在每一个案例上进行测试,最终在BLSM算法处理1/3训练集数据后,使用一维深度卷积神经网络进行分类的实验中显示最佳,得到最高平均敏感度92.35%、特异性99.88%、PPV90.68%、NPV99.91%。并且在部分案例上表现十分突出, chb01、chb02、chb06、chb18、chb19、chb22的所有评价标准均在90%以上。

另外,由于一维卷积神经网络可训练参数少,结构简单,很大程度上提高了网络的训练测试速率,经计算,该模型判别一条包含1024个采样数据的样本仅需0.12ms,相较于传统诊断方法,极大的提高了癫痫检测的效率。

## 5 结 论

本文提出了一种结合深度学习和不平衡分类的癫痫发作自动检测方法。使用CHB-MIT数据集训练网络模型。针对数据集类别不平衡问题,分别使用随机过采样、SMOTE和BLSM算法对数据集做平衡处理,比较不同方法处理不平衡分类问题的能力。使用敏感度、特异性、PPV和NPV作为模型评估指标。最终在BLSM算法处理1/3训练集数据后,使用一维深度卷积神经网络进行分类的实验中显示最佳,得到最高平均敏感度92.35%、特异性99.88%、PPV90.68%、NPV99.91%。结果显示该方法的分类性能优于许多已有的分类方法,不但对检测癫痫发作有重要意义,而且为其他领域的时间序列分类

提供了一种十分有效的方法。现阶段本实验在公共数据集进行测试,在未来的工作中,会在更多的临床脑电数据集上进一步验证所提出方法的有效性。

### 参考文献

- [ 1 ] NAGHMEH M, AXEL B, MICHAEL F, et al. Epileptic seizure detection using cross-bispectrum of electroencephalogram signal [ J ]. *Seizure*, 2019, 66: 4-11.
- [ 2 ] GANDH T, PANIGRAHI B K, BHATIA M, et al. Expert model for detection of epileptic activity in EEG signature [ J ]. *Expert Systems with Applications*, 2010, 37(4): 3513-3520.
- [ 3 ] SANEI S. EEG signal processing [ M ]. Springer Netherlands, 2013.
- [ 4 ] 张鹏博, 王雪, 张蔚航, 等. 癫痫发作瞬态带宽特征自适应检测方法 [ J ]. *仪器仪表学报*, 2016, 37(6): 1390-1397.
- ZHANG P B, WANG X, ZHANG W H, et al. Adaptive detection method based on instantaneous bandwidth feature for seizure onset [ J ]. *Chinese Journal of Scientific Instrument*, 2016, 37(6): 1390-1397.
- [ 5 ] MCSHARRY P E, HE T, SMITH L A, et al. Linear and non-linear methods for automatic seizure detection in scalp electro-encephalogram recordings [ J ]. *Medical and Biological Engineering and Computing*, 2002, 40(4): 447-461.
- [ 6 ] LEHNERTZ K, MORMANN F, KREUZ T, et al. Seizure prediction by nonlinear EEG analysis [ J ]. *Engineering in Medicine and Biology Magazine IEEE*, 2003, 22(1): 57-63.
- [ 7 ] JESUS M, MARIA J, XAVIER D T, et al. Non-linear classifiers applied to EEG analysis for epilepsy seizure detection [ J ]. *Expert Systems with Application*, 2017, 86: 99-112.
- [ 8 ] VIVEK N, ANDREW L, THEODEN I N. Seizure control in a computational model using a reinforcement learning stimulation paradigm [ J ]. *International Journal of Neural Network*, 2017, 27(7): 1750012.
- [ 9 ] BUTENEERS P, VERSTRAETEN D, NIEUWENHUYSE B V, et al. Real-time detection of epileptic seizures in animal models using reservoir computing [ J ]. *Epilepsy Research*, 2013, 103(2/3): 124-134.
- [ 10 ] ZHANG T, CHEN W, LI M. AR based quadratic feature extraction in the VMD domain for the automated seizure detection of EEG using random forest classifier [ J ]. *Biomedical Signal Processing and Control*, 2017, 31: 550-559.
- [ 11 ] ANTONIADES A, SPYROU L, MARTIN-LOPEZ D, et al. Deep neural architectures for mapping scalp to intracranial EEG [ J ]. *International Journal of Neural Systems*, 2018, 28(8): 1850009.
- [ 12 ] AMIR H, PERUMPILLICHIRA J, ALEXANDER C, et al. Neonatal seizure detection using deep convolutional neural networks [ J ]. *International Journal of Neural Systems*, 2018, 28: 1850011.
- [ 13 ] ACHARYA U R, OH S L, HAGIWARA Y, 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.
- [ 14 ] YU Z Y, NIE W, ZHOU W D, et al. Epileptic seizure prediction based on local mean decomposition and deep convolutional neural network [ J ]. *The Journal of Supercomputing*, 2020, 76(5): 3462-3476.
- [ 15 ] 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.
- [ 16 ] PETROSIAN A, PROKHOROV D, HUMAN R, et al. Recurrent neural network based prediction of epileptic seizures in intra-and extracranial EEG [ J ]. *Neurocomputing*, 2000, 30(1-4): 201-218.
- [ 17 ] TSIOURIS, KOSTAS M, PEZOULAS V C, et al. A long short-term memory deep learning network for the prediction of epileptic seizures using EEG signals [ J ]. *Computers in Biology and Medicine*, 2018, 99: 24-37.
- [ 18 ] GRAVES, ALEX. Supervised sequence labelling with recurrent neural networks [ J ]. Springer, 2012, 385: 1-23.
- [ 19 ] BALOGLU U B, YLDRM Z. Convolutional long-short term memory networks model for long duration EEG signal classification [ J ]. *Journal of Mechanics in Medicine and Biology*, 2019, 19(1): 1940005.
- [ 20 ] LIANG W X, PEI H J, CAI Q L, et al. Scalp EEG epileptogenic zone recognition and localization based on long-term recurrent convolutional network [ J ]. *Neurocomputing*, 2019, 396: 569-576.
- [ 21 ] RUBÉN S, MANUEL G, LUIS F D, et al. Classification of epileptic EEG recordings using signal transforms and convolutional neural networks [ J ]. *Computers in Biology and Medicine*, 2019, 109: 148-158.
- [ 22 ] WEISS G M. Mining with rarity: A unifying framework [ J ]. *Acm Sigkdd Explorations Newsletter*, 2004, 6(1): 7-19.
- [ 23 ] YUAN Q, ZHOU W D, ZHANG L, et al. Epileptic seizure detection based on imbalanced classification and

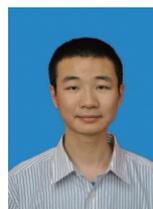
- wavelet packet transform [J]. *Seizure*, 2017, 50: 99-108.
- [24] SUN C F, CUI H, ZHOU W D, et al. Epileptic seizure detection with EEG textural features and imbalanced classification based on easyensemble learning [J]. *International Journal of Neural Systems*, 2019, 29(10): 1950021.
- [25] ZHOU Z H, LIU X Y. Training cost-sensitive neural networks with methods addressing the class imbalance problem [J]. *IEEE Transactions on Knowledge and Data Engineering*, 2006, 18(1): 63-77.
- [26] CHAWLA N V, BOWYER K W, HALL L O, et al. SMOTE: Synthetic minority over-sampling technique [J]. *Journal of Artificial Intelligence Research*, 2002, 16(1): 321-357.
- [27] HUI H, WANG W, MAO B. Borderline-SMOTE: A new over-sampling method in imbalanced data sets learning [J]. *Advances in Intelligent Computing, International Conference on Intelligent Computing*, 2005, 3644: 878-887.
- [28] JANJARASJITT, SUPARERK. Performance of epileptic single-channel scalp EEG classifications using single wavelet-based features [J]. *Australasian Physical and Engineering sciences in Medicine*, 2017, 40(1): 57-67.
- [29] BRUNO D, JOÃO D, CÉSAR T, et al. Feature selection in high dimensional EEG features spaces for epileptic seizure prediction [C]. *IFAC Proceedings Volumes*, 2011, 44(1): 6206-6211.
- [30] MUHAMMAD K, AZIZ G, SRIDHAR K. Patient-specific seizure detection in long-term EEG using wavelet decomposition [J]. *Biomedical Signal Processing and Control*, 2018, 46: 157-165.
- [31] IHSAN U, MUHAMMAD H, EMAD-UL-HAQ Q, et al. An automated system for epilepsy detection using EEG brain signals based on deep learning approach [J]. *Expert Systems with Application*, 2018, 107: 61-71.
- [32] OROSCO L, CORREA, AGUSTINA G, et al. Patient non-specific algorithm for seizures detection in scalp EEG [J]. *Computers in Biology and Medicine*, 2016, 71: 128-134.
- [33] CHANDEL G, UPADHYAYA P, FAROOQ O, et al. Detection of seizure event and its onset/offset using orthonormal triadic wavelet based features [J]. *Innovation and Research in Biomedical engineering*, 2019, 40(2): 103-112.
- [34] CHEN D, WAN S R, 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.
- [35] FERGUS P, HUSSAIN A, DAVID H, et al. A machine learning system for automated whole-brain seizure detection [J]. *Applied Computing and Informatics*, 2016, 12(1): 70-89.
- [36] LIMA C A M, COELHO A L V. Kernel machines for epilepsy diagnosis via EEG signal classification: A comparative study [J]. *Artificial Intelligence in Medicine*, 2011, 53(2): 83-95.
- [37] ZABIHI M, KIRANYAZ S, RAD A B, et al. Analysis of high-dimensional phase space via poincare section for patient-specific seizure detection [J]. *IEEE Transaction on Neural Systems and Rehabilitation engineering*, 2016, 24(3): 386-398.

#### 作者简介



**费洪磊**, 2017 年于青岛科技大学获得学士学位, 现为山东师范大学硕士研究生, 研究方向为生物医学信息处理和模式识别。  
E-mail: hongleifei1994@163.com

**Fei Honglei** received his B. Sc. degree from Qingdao University of Science and Technology in 2017. He is currently a master student at Shandong Normal University. His main research interests include biomedical information processing and pattern recognition.



**袁琦** (通信作者), 2014 年于山东大学获得博士学位, 现为山东师范大学物理与电子科学学院副教授、硕士生导师, 主要研究方向为生物医学信息处理和模式识别。  
E-mail: yuanqi@sdnu.edu.cn

**Yuan Qi** (Corresponding author) received his Ph. D. degree from Shandong University in 2014. He is currently an associate professor and a master advisor in the School of Physics and Electronics at Shandong Normal University. His main research interests include biomedical information processing and pattern recognition.