

面向癫痫脑电的简化深度学习模型*

张锦¹, 刘熔¹, 田森², 陈胜¹, 魏建好³

(1. 湖南师范大学信息科学与工程学院, 湖南长沙 410081;

2. 湖南师范大学数学与统计学院, 湖南长沙 410081; 3. 湖南大学信息科学与工程学院, 湖南长沙 410082)

摘要:针对脑电信号随机性强、动态变化迅速等特点,提出了一种简化深度学习模型研究癫痫脑电识别问题。提出的模型以一维卷积神经网络为基础,在结构方面简化了卷积层、池化层等以提高模型效率,在整体框架方面应用了 Keras 框架,在训练优化算法方面采用 RMSProp 算法作为模型优化算法,通过预定义的目标函数来进行损失估计,模型设计上加入了批标准化层和全局均值池化层。基于所提模型,从三个方面研究了癫痫脑电识别问题,即:利用经验模态分解,分别选取前三阶、前五阶、前七阶、前八阶的本征模态函数分量,在简化模型上进行对比分析;利用提出模型所具备的深度学习特点,直接识别原始脑电信号而无须特征提取环节;增加了三种不同方法分别提取 7 类特征,对相同的脑电数据进行对比分析。性能分析结果表明:对于五类不同的脑电信号,前三阶的本征模态函数分量的识别率达到 92.1%,比其他几种处理方式识别率高;前八阶的本征模态函数分量识别率不及原始信号,表明人工数据处理时会给数据带来噪声;所提出的简化深度学习模型能高效处理癫痫脑电识别问题,具备较高效率和较好性能。

关键词:癫痫脑电;卷积神经网络;Keras 框架;经验模态分解

中图分类号:TP391.4 文献标志码:A 文章编号:1001-2486(2020)06-106-06

Simplified deep learning model for epilepsy electroencephalogram

ZHANG Jin¹, LIU Rong¹, TIAN Sen², CHEN Sheng¹, WEI Jianhao³

(1. College of Information Science and Engineering, Hunan Normal University, Changsha 410081, China;

2. College of Mathematics and Statistics, Hunan Normal University, Changsha 410081, China;

3. College of Information Science and Engineering, Hunan University, Changsha 410082, China)

Abstract: A simplified deep learning model was proposed to solve the problem of recognition based on the strong randomness and rapid dynamic change of EEG (epilepsy electroencephalogram) signals. The proposed model utilizes one-dimensional convolutional neural network, which simplifies the convolutional layers and pooling layers to improve the efficiency. Based on the overall Keras framework, the RMSProp algorithm was used for the model in the training process, and the algorithm estimated the loss through a predefined objective function. The model design incorporated a batch normalization layer and a global mean pooling layer. The EEG recognition was researched from two aspects based on the proposed model: with empirical mode decomposition, the first three orders, the first five orders, the first seven orders, and the first eight orders of intrinsic mode functions were selected for comparative analysis on the simplified model. Because of deep learning characteristics, the proposed model can directly recognize the original EEG signals without feature extraction. After extracting 7 types of features, it adds three different methods to compare the accuracy. The experimental results show that: the recognition rate of the first three orders of intrinsic mode function reaches the level of 92.1% for the five different types of EEG signals, which is higher than that of other features. The first eight orders' recognition rate is lower than the original signal, which indicates that data preprocessing will lead to the noise. The proposed simplified deep learning model can effectively deal with the epileptic EEG recognition problem with higher efficiency and better performance.

Keywords: epilepsy electroencephalogram; convolutional neural network; Keras framework; empirical mode decomposition

癫痫 (epilepsy), 又名“羊癫疯”, 是最为常见的神经系统疾病^[1]之一, 据 WHO 最新统计, 全球约有 5000 万癫痫病患者, 且每年儿童患病者逐步增加^[2]。癫痫年龄跨度大, 且趋于年轻化, 目前

治疗方式主要有药物保守治疗、手术切除病灶治疗^[3]等, 治疗周期长, 副作用大。

癫痫脑电 (Epilepsy ElectroencephaloGram, EEG) 研究主要包括特征提取^[4-5]和分类两个方

* 收稿日期: 2019-09-24

基金项目: 国家教育部产学研合作协同育人基金资助项目(201702001043, 201801037136, 201901051021); 湖南省教育厅创新平台开放基金资助项目(15K082); 湖南省研究生教改基金资助项目(JG2018A012); 湖南省交通运输厅科技进步与创新计划资助项目(201927)

作者简介: 张锦(1979—), 男, 湖南长沙人, 教授, 博士, 博士生导师, E-mail: jinzhang@hunnu.edu.cn

面。近年来,越来越多的研究者开始对不同场景下的信号去噪,以提高检测率^[6]。文献[7]提出采用小波系数分解的方式提取癫痫脑电信号特征,实现对正常期、发作期和发作间期的癫痫脑电分类。近年来,Wang等采用主成分分析和方差性分析降低原始特征空间维数,对癫痫脑电发作期和非发作期进行自动分类^[8]。

深度学习目前被认为是较为先进的模型,在模式识别和机器学习方面有广泛的应用^[9],在基准数据集分类方面达到甚至比人类本身更高的准确度。大脑对某些刺激、任务或生理状态的电响应通常包括许多子反应,这些子反应被组合以提供完整的反应。深度学习现已用于癫痫脑电图中的分类以及癫痫发作预测等领域。深度学习在结构上与深度神经网络类似,文献[10]提出采用长短时记忆网络(Long Short-Term Memory, LSTM)结构对癫痫脑电数据进行分类,此外,也可通过基于 Softmax 回归方法对癫痫脑电信号进行分类。

目前癫痫脑电识别的方法过程较烦琐,中间过程参数过多。针对该问题,本文提出一种简化版的深度学习模型 L-NET,首先将原始信号进行经验模态分解(Empirical Mode Decomposition, EMD),分别选取前几阶本征模态(Intrinsic Mode Function, IMF),使用一维卷积替换传统的二维卷积以保留更丰富的局部特征,通过使用 L-NET 进行训练,对五类不同的脑电信号进行对比识别研究;将 L-NET 模型直接对原始癫痫脑电数据进行五分类,没有进行数据预处理;基于前面已有实验,对前三阶的本征模态分量分别重构 7 种典型特征,利用 K 近邻和随机森林两种方法分别进行五分类对比。实验结果表明,经过 EMD 数据预处理后前三阶的 IMF 分量的识别率最高;通过前八阶本征模态分量识别率较低,表明在处理的过程中,后几阶为残差分量,这些对于癫痫脑电识别研究具有重要意义。

1 面向癫痫脑电的简化深度学习模型

1.1 面向癫痫脑电的一维卷积神经网络

1.1.1 模型结构

面向癫痫脑电的一维卷积神经网络(Convolutional Neural Network, CNN)包含很多一维卷积层,一个卷积层可以包含很多卷积面。激活函数有很多不同的选择,但一般为 sigmoid 函数或校正线性单元(Rectified Linear Unit, ReLU)。池化层将输入数据划分为许多小的子区域,每次

只提取子区域最大值的方法就称为最大值池化。池化层的意义在于提取出数据中的显著特征而忽略细节特征,以减少网络中的参数和计算量,并且能够控制过拟合。

卷积神经网络在图像^[11]、语音识别方面取得非常好的成绩,核心想法在于物体的特征往往可以提取出来,且通过卷积、池化可以大大减少输入数据,加快训练效率。一维卷积神经网络可以很好地应用于传感器数据的时间序列分析^[12]也可以实时抗噪诊断^[13],还能应用于自然语言处理的任务^[14]。深度卷积神经网络在实际应用中取得了不错的成果^[15]。

1.1.2 算法设计

简化深度学习模型如算法 1 所示。

算法 1 简化深度学习模型 L-NET

Alg. 1 Simplified in-depth learning model L-NET

输入: Q 维 EEG 信号 x ; 训练的 L-NET 模型

输出: 预测的 EEG 类别标签 $y \rightarrow \{1, 2, 3, 4, 5\}$

1. 初始化: $Q \rightarrow 4097$
2. 初始化: $K \rightarrow$ 本征模态分量维度: $K = 3, 5, 7, 8$
3. 过程: L-NET(x, y, CNN)
4. softmax \rightarrow 计算 $P = \{P_1, P_2, P_3, P_4, P_5\}$
5. 找到概率最大的 P 归属于哪一类
6. 结束

设计算法重要的指标之一是优化器,实验所用到的为 RMSProp,其全称叫 Root Mean Square Prop,为了进一步优化损失函数在更新中存在摆动幅度过大的问题,RMSProp 算法对权重 W 和偏置 b 的梯度使用微分平方加权平均数。

另一个重要参数为目标函数,或称损失函数,是编译一个模型必要的参数之一。本文中损失函数是 binary crossentropy (亦称作对数损失, logloss),该函数主要用来做极大似然估计,以方便计算。

1.2 模型参数设计

本文模型建立在一般的卷积神经网络基础上,同时也增加了部分结构,如图 1 所示,模型结构主要是由一维卷积层(conv1D)、一维池化层(max_pooling1D)、批标准化层(batch_normalization)、全局均值池化层(global_average_pooling1D)、全连接层(Dense)和 Dropout 层等构成。

由于原始输入数据是列向量,根据输入数据的特殊性设计两层卷积层叠加结构,增加一层批标准化层,使网络训练 CNN 时更加稳定。随后再

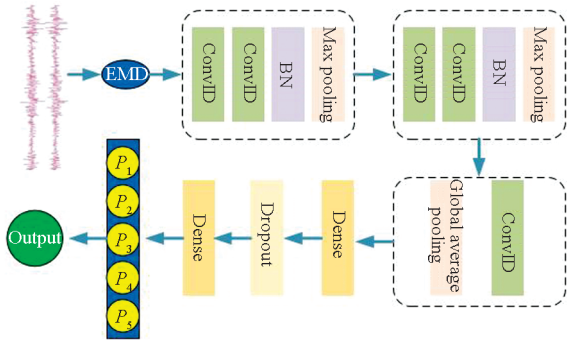


图 1 简化深度学习模型 L-NET 结构

Fig. 1 Simplified deep learning model L-NET structure

增加一个最大池化层,减小模型结构复杂度。全局平均池化层,与普通池化不同之处在于不需要池化窗口在输入数据上进行滑动采样,全局平均池化能够替代卷积神经网络中的全连接层,好处是能够减少整个网络结构的参数数量。两个全连接层之间是 dropout 层,是在训练过程中,对每一个全连接层的神经网络单元,按照一定的概率将其随机地丢弃,所以每一个批次 (batch) 都在训练不同的网络,从而增加了网络的健壮性。另外也设置了 L2 正则化,使权值变化率相应减小,通过这一系列设置从而减少了过拟合现象的发生,表 1 为前三阶实验中模型结构的具体参数。

表 1 模型结构参数表

Tab. 1 Model structure parameter table

层级结构	输出矩阵	参数个数
conv1D_1	(None, 4095, 64)	640
conv1D_2	(None, 4093, 64)	12 352
batch_normalization_1	(None, 4093, 64)	256
max_pooling1D_1	(None, 1364, 64)	0
conv1D_3	(None, 1362, 128)	24 704
conv1D_4	(None, 1360, 128)	49 280
batch_normalization_2	(None, 1360, 128)	512
max_pooling1D_2	(None, 453, 128)	0
conv1D_5	(None, 451, 128)	49 280
global_average_pooling1D_1	(None, 128)	0
Dense_1	(None, 600)	77 400
Dropout_1	(None, 600)	0
Dense_2	(None, 5)	3005
总参数个数:		217 429
训练参数个数:		217 045
非训练参数个数:		384

2 性能分析

2.1 数据集

癫痫脑电信号本质上是一种时序信号,本实验采用的脑电数据是印度学者 Varun Bajaj 和 Ram Bilas Pachori 对正常人和癫痫病患者实际测试的数据。脑电信号数据总共分为 5 类,分别为 Z、O、N、F、S,每类脑电子集包含 100 个信道序列,总共 500 个信道序列。每个信道持续时间为 23.6 s,信号采样点数为 4097。五类信号分别代表不同人的脑电测试信号,其中 Z、O 表示的是正常清醒的健康人,N、F 表示的是未发作的癫痫病人,S 表示癫痫病发作时的病人;记录位置不同,Z、O 两类是在颅外记录的数据,而其余三类是在颅内记录的。所有的 EEG 信号都是由 128 通道的放大器系统记录下的,都采用常用的参数设置。在经过 12 位模数转换后,数据以 173.6 Hz 的采样频率连续读入,在本实验过程中,将行信号转置成列信号方便数据处理及后面模型的设计。

2.2 基于数据预处理的 EEG 识别

2.2.1 基于 EMD 数据预处理的识别框架

经验模态分解算法^[16]是一种适用于处理非平稳非线性序列的自适应时空分析方法。EMD 提取特征后,将一个序列分成多个 IMF 分量而不偏离时间域。这与一些时空分析方法相似^[17],如傅里叶变换和小波分解。这种方法尤其适用于分析自然信号,而自然信号通常是非线性和非平稳的^[18]。

基于 EMD 数据预处理的 EEG 识别流程如图 2 所示,这种方法对前面输入的 500 个列向量进行数据预处理,每一条原始数据经过 EMD 后形成 8~13 不等阶数的 IMF 分量。由于后几阶的分量中包含较多的残差噪声,为了保证输入统一,分别取前三、前五、前七、前八阶分量作为模型的输入。




图 2 基于 EMD 数据预处理的 EEG 识别流程图

Fig. 2 EEG identification flow chart based on EMD feature extraction

2.2.2 实验结果

实验将数据集划分为 3 个部分——训练数据、验证数据和测试数据(总共五类共 500 条数

据)比例为 3 : 1 : 1。这些数据每次读入的时候都是随机打乱的,训练过程对训练数据进行调参,经过一次 epoch 后,得到一个训练结果和验证结果,通过验证集对模型的准确率进行评估,训练完成后,用测试集对最后的结果进行总体检测。

各阶数在参数设置环境相同的情况下,分别进行 30 次独立实验,表 2 中数据分别表示第 1 ~ 6 次、第 7 ~ 12 次、第 13 ~ 18 次、第 19 ~ 24 次和第 25 ~ 30 次实验的平均准确率结果。此外,评价指标损失值(loss),通过 30 次重复实验得到相应的平均 loss 值。实验结果表明,前三阶的 IMF 分量的整体效果是最好的,前三阶、前五阶准确率逐渐升高,loss 值基本持平;前七阶、前八阶准确率逐渐降低,loss 值也逐渐增加。具体实验数据如表 2 所示。

表 2 基于 EMD 数据预处理的 EEG 识别结果

Tab.2 EEG recognition results based on EMD feature extraction

阶数	识别率/%					准确 率/%	loss 值
	1 ~ 6 次	7 ~ 12 次	13 ~ 18 次	19 ~ 24 次	25 ~ 30 次		
前三阶	92.00	92.30	92.23	91.20	92.20	92.00	0.22
前五阶	91.30	91.20	91.60	91.52	91.20	91.30	0.22
前七阶	90.30	90.37	90.50	90.70	90.27	90.44	0.24
前八阶	89.80	89.80	90.20	89.50	89.90	89.84	0.25

2.3 基于深度学习的 EEG 识别

2.3.1 基于原始数据的识别框架

本实验硬件环境:操作系统为 Windows10;处理器为 AMD Ryzen 5 2600X 六核;内存为金士顿 DDR4 2400 MHz,采用 GPU 加速,基于 MATLAB 平台和 Keras 平台,MATLAB 由一系列工具组成,其中包含一些内置的函数和文件。Keras 框架是一个高层神经网络应用程序接口,Keras 框架由纯 Python 编写而成并基于 Tensorflow、Theano 以及 CNTK 后端。可以直接调用图像处理中的一些内置函数及封装的库,支持 CPU 和 GPU 无缝切换。在基于原始数据的实验中是直接进行模型训练,而未进行数据预处理。

基于原始数据的 EEG 识别流程如图 3 所示,首先将其中一道原始波形记录 4097 个采样点,数据采集后组合形成一个行向量,再将原始数据进行转置变成一个列向量。总共 500 道波形,将这些波形依次转置后形成 500 个列向量直接作为

L-NET 的输入,通过训练模型后识别属于哪一类。

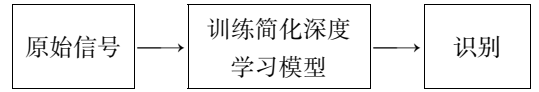


图 3 基于原始数据的 EEG 识别流程图

Fig.3 EEG identification flow chart based on raw data

2.3.2 实验结果

基于原始数据的 EEG 识别结果如表 3 所示,本类实验总共进行 30 次,以 6 组实验为一单位,分别取其平均值,共有 5 组实验数据,另外再把 5 组实验数据取平均值得到最终的识别结果。输入数据为转置后的一维列向量,不需要进行数据预处理,因为 L-NET 模型是一种深度学习模型,其卷积层可自动提取特征并进行分类。实验结果表明,未经处理的原始信号识别率基本上能达到 90%。

表 3 基于原始数据的 EEG 识别结果

Tab.3 EEG recognition results based on raw data

阶数	识别率/%					准确 率/%	loss 值
	1 ~ 6 次	7 ~ 12 次	13 ~ 18 次	19 ~ 24 次	25 ~ 30 次		
原始 数据	90.80	90.87	90.80	90.83	90.97	90.85	0.23

本实验分为两部分,即基于原始数据的 EEG 识别和基于 EMD 数据预处理的 EEG 识别。主要是探究简化的一维卷积神经网络对于原始脑电信号以及经过 EMD 数据预处理后的不同 IMF 分量识别分析,原始信号输入大小为 4097 * 1,前三阶 IMF 输入为 4097 * 3,前五阶输入为 4097 * 5,前七阶输入为 4097 * 7,前八阶输入为 4097 * 8。

将基于原始数据的 EEG 识别结果和基于 EMD 数据预处理的对比识别结果如图 4 所示,根据图中五类数据,前三阶准确率基本高于其他几类,前七阶和前八阶本征模态分量明显低于原始数据。这些说明通过合适的预处理方式能够提高准确率。另外五类输入迭代 200 次的运行时间基本保持在 2 min 至 2 min 40 s 以内,时间效率非常高。

图 4 也表明经过 EMD 后确实把噪声过滤到后几阶 IMF 中,因此选取的 IMF 分量越是前几阶,信号中包含的信号噪声越少,信号的差异越不受噪声影响,识别率越高。所以,前三阶 IMF 分量因为包含的噪声较少,识别率最高。由于前八

阶信号的后几阶信号中包含较多的噪声,影响信号的真实差异,得到的整体识别率最低。在实验中,原始信号的识别率高于前七、前八阶的识别率,而低于前三、前五阶的识别率。这是因为前三、前五阶的信号经过 EMD 后,保留了原始信号的主要信息,同时去除了噪声,因此识别率高于原始信号。但是当选取的阶数越多时,比如,前七、前八阶 IMF 分量信号,这些信号包含被 EMD 后的低频信号(例如第 7 阶、第 8 阶 IMF 分量)和原始信号差异明显,可能含有较多的噪声,导致前七阶、前八阶 IMF 分量的整体识别率低于原始信号的识别率。




图 4 两类方法结果对比图

Fig. 4 Comparison of the results of the two types of methods

2.4 对比实验

2.4.1 对比方法

K 近邻(K-Nearest Neighbor, KNN)分类算法是一种既可用于分类又可用于回归的机器学习算法。其基本思想是找到与当前样本特征最相近的 K 个样本,这 $K + 1$ 个样本均属于同一类。这种方法中 K 的取值较为敏感,通过对距离进行加权,可以优化最终的结果。

随机森林(Random Forest, RF)算法也是一种既可用于分类问题也可用于回归问题的机器学习算法。它是一种由多棵决策树组成的集成模型,决策树本质上是一种树形结构,每一个节点表示相关测试,其叶节点表示分类属性的概率。对于分类问题,随机森林通过多棵决策树投票得到最终的结果,而对于回归问题,则是根据平均值而得到。

文献[19]采用最小二乘支持向量机(Least Squares Support Vector Machine, LSSVM)是为了克服标准支持向量机复杂度大、计算难度大的问题而提出的。

2.4.2 实验结果

根据上述实验结果,经过 EMD 数据处理后前三阶实验效果最好,基于上述实验结果,对前三阶的本征模态分量分别重构 7 种典型特征^[20],包括波动指数、变化系数、方差、相对能量、平均频率、偏斜度和峰度。将五类信号提取特征后,500 个信道分别都有 7 个特征。然后分别采用 KNN 和随机森林进行五分类,第三组实验引用了文献[20]的实验结果,最终的实验结果如表 4 所示。

表 4 对比实验结果

Tab. 4 Comparison of experimental results

模型	实验结果					平均值
	1	2	3	4	5	
KNN	52.00	53.00	60.00	50.00	56.00	54.20
RF	72.00	70.00	71.00	69.00	69.00	70.20
LSSVM						76.25
L-NET	92.00	92.30	92.23	91.20	92.20	91.99

K 近邻和随机森林两组对比实验均是基于相同的环境,进行五次对比实验然后取平均值。通过实验结果说明,针对癫痫脑电这类时序数据,相对于 KNN、随机森林和最小二乘支持向量机三种方法,本文所提出的方法中癫痫脑电的识别平均准确率分别提升了 69.72%、31.04%、20.64%。并且本文中的简化深度学习模型没有提取特征这一环节,只是对数据进行预处理。

3 结论

针对癫痫脑电数据这种时序信号,本文以一维卷积神经网络为基础,设计简化深度学习模型对癫痫脑电信号进行识别研究。相比于二维 CNN,这样设计的模型参数更少,效率更高。通过研究发现,原始数据经过 EMD 处理后取前三阶分量,再利用一维 CNN 做分类识别这种方式识别率最高。随着采用分量数越多识别率降低,实验结果表明在数据预处理的过程中会给原始信号带来噪声。在实验过程中,以基本调参方法为基础,L-NET 做相应改进,如增加全局均值池化,每一层加入权重和偏置初始化等,使识别率有所提高。这种调参方法对于今后其他模型的参数调整具有借鉴意义。

基于现有的研究,本文将一维 CNN 应用到其他方面,例如人脸识别,可以将手动预处理后的数

据以及数据不做处理进行对比研究。将一维 CNN、二维 CNN 和 VGG 等一系列网络结构进行对比分析,通过研究这些模型,可以了解它们之间更多的共性和特性。目前这一方面存在诸多可研究的问题,一般的人脸识别过程包含人脸检测、特征提取以及人脸识别几个重要组成部分。其中,人脸检测是整个识别过程的关键部分,已有的检测方法大部分都是基于目标检测的方法,另外在人脸识别过程中,已有的研究基本上是基于卷积神经网络,并在此基础上进行改进并不断优化,一般的网络结构非常复杂并且训练模型复杂,训练要求设备配置高并且耗时长。本论文中所提出的简化深度学习模型也可尝试用于此过程中,将提取人脸面部的 128 维特征向量作为本文所提出模型的输入部分,然后进行训练并进行分类来实现整个人脸识别过程。这种方式使人脸识别几个过程分离,并且整个过程更加简化,这是下一步所要研究的方向。

参考文献 (References)

- [1] 常琳,王小珊. 中国癫痫流行病学调查研究进展[J]. 国际神经病学神经外科学杂志, 2012, 39(2): 161-164.
CHANG Lin, WANG Xiaoshan. Advances in epidemiological investigation of epilepsy in China[J]. Journal of International Neurology and Neurosurgery, 2012, 39(2): 161-164. (in Chinese)
- [2] Datta A N, Wallbank L, Wong P K H, et al. Co-existence of rolandic and 3 Hz spike-wave discharges on EEG in children with epilepsy[J]. Canadian Journal of Neurological Sciences, 2019, 46(1): 64-70.
- [3] Lopes M A, Perani S, Yaakub S N, et al. Revealing epilepsy type using a computational analysis of interictal EEG [J]. Scientific Reports, 2019, 9(1): 1-10.
- [4] Fu Q, Jing B, He P J, et al. Fault feature selection and diagnosis of rolling bearings based on EEMD and optimized elman_adaboost algorithm[J]. IEEE Sensors Journal, 2018, 18(12): 5024-5034.
- [5] 李明爱,崔燕,杨金福,等. 基于 HHT 和 CSSD 的多域融合自适应脑电特征提取方法[J]. 电子学报, 2013, 41(12): 2479-2486.
LI Mingai, CUI Yan, YANG Jinfu, et al. An adaptive multi-domain fusion feature extraction with method HHT and CSSD[J]. Acta Electronica Sinica, 2013, 41(12): 2479-2486. (in Chinese)
- [6] 李辉,金炜东. 基于白噪声统计特性与 EEMD 的高速列车横向减振器故障诊断[J]. 计算机应用研究, 2016, 33(9): 2648-2651.
LI Hui, JIN Weidong. Lateral damper fault diagnosis of high-speed train based on statistical characteristics of white noise and EEMD[J]. Application Research of Computers, 2016, 33(9): 2648-2651. (in Chinese)
- [7] Janjarasjitt S. Epileptic seizure classifications of single-channel scalp EEG data using wavelet-based features and SVM[J]. Medical & Biological Engineering & Computing, 2017, 55(10): 1743-1761.
- [8] Wang L N, Xue W N, Li Y, et al. Automatic epileptic seizure detection in EEG signals using multi-domain feature extraction and nonlinear analysis [J]. Entropy, 2017, 19(6): 222.
- [9] Sun Y, Wang X, Tang X, et al. Deep learning face representation by joint identification-verification [C]// Proceedings of Advances in Neural Information Processing Systems, 2014: 1988-1996.
- [10] 王晓丽. 基于深度学习的癫痫脑电信号分析与预测[J]. 长春大学学报, 2019, 29(6): 15-18, 33.
WANG Xiaoli. Analysis and prediction of epileptic EEG signal based on deep learning [J]. Journal of Changchun University, 2019, 29(6): 15-18, 33. (in Chinese)
- [11] Chao D, Chen C L, He K M, et al. Image super-resolution using deep convolutional networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(2): 295-307.
- [12] Huang S Z, Tang J, Dai J Y, et al. Signal status recognition based on 1DCNN and its feature extraction mechanism analysis[J]. Sensors, 2019, 19(9): 1-19.
- [13] 刘星辰,周奇才,赵炯,等. 一维卷积神经网络实时抗噪故障诊断算法[J]. 哈尔滨工业大学学报, 2019, 51(7): 89-95.
LIU Xingchen, ZHOU Qicai, ZHAO Jiong, et al. Real-time and anti-noise fault diagnosis algorithm based on 1-D convolutional neural network[J]. Journal of Harbin Institute of Technology, 2019, 51(7): 89-95. (in Chinese)
- [14] Sajjad A, Patrick C, Alessandro L K. End-to-end environmental sound classification using a 1D convolutional neural network[J]. Expert Systems with Applications, 2019, 136: 252-263.
- [15] Buterin S A. Inverse spectral reconstruction problem for the convolution operator perturbed by a one-dimensional operator[J]. Mathematical Notes, 2006, 80(5/6): 631-644.
- [16] Li Y B, Xu M Q, Wei Y, et al. An improvement EMD method based on the optimized rational Hermite interpolation approach and its application to gear fault diagnosis [J]. Measurement, 2015, 63: 330-345.
- [17] 王婷. EMD 算法研究及其在信号去噪中的应用[D]. 哈尔滨: 哈尔滨工程大学, 2010.
WANG Ting. EMD algorithm research and its application in signal denoising [D]. Harbin: Harbin Engineering University, 2010. (in Chinese)
- [18] Ghasemifard H, Behnam H, Tavakkoli J, et al. High intensity focused ultrasound lesion detection using adaptive compressive sensing based on empirical mode decomposition[J]. Journal of Medical Signals & Sensors, 2019, 9(1): 24-32.
- [19] Wang W, Chen X Y. Multiscale modeling of fiber optic gyroscope temperature drift based on improved ensemble empirical mode decomposition [J]. Applied Optics, 2018, 57(28): 8443-8450.
- [20] 魏建好. 基于同步的癫痫脑电识别研究[D]. 长沙: 湖南师范大学, 2017.
WEI Jianhao. Research on recognition of epilepsy EEG based on synchronization [D]. Changsha: Hunan Normal University, 2017. (in Chinese)