

## 基于固有模态分解和深度学习的抑郁症脑电信号分类分析

刘岩<sup>1,2,3</sup>, 李幼军<sup>1,2,3</sup>, 陈萌<sup>1,2,3</sup>

1. 北京工业大学电子信息与控制工程学院, 北京 100124; 2. 磁共振成像脑信息学北京市重点实验室, 北京 100124; 3. 脑信息智慧服务北京国际科技合作基地, 北京 100124

**【摘要】**以采集到的抑郁症患者和正常人的脑电信号为基础,采用固有模态分解算法对原始信号去噪处理,通过卷积神经网络对抑郁症患者和正常人进行分类分析。首先通过脑电信号的采集实验,采集15位抑郁症患者和15位正常人对照组Fp1的静息态脑电信号;之后对采集到的静息态脑电进行去噪处理,脑电去噪处理主要包括固有模态分解算法对原始信号的分解获得不同层次的IMF分量,对IMF分量进行频域分析,通过硬阈值的方法剔除原始信号中的噪声信号;最后采用卷积神经网络对抑郁症患者和正常人对照组进行二值分类,结果相较于传统的特征提取-机器学习算法,分类准确率明显提高。

**【关键词】**抑郁症;脑电信号;固有模态分解;固有模态函数;卷积神经网络

**【中图分类号】**TP391.4

**【文献标志码】**A

**【文章编号】**1005-202X(2017)09-0963-05

## Empirical mode decomposition and deep learning for classifying and analyzing electroencephalography signals of depression patients

LIU Yan<sup>1,2,3</sup>, LI Youjun<sup>1,2,3</sup>, CHEN Meng<sup>1,2,3</sup>

1. College of Electronic Information & Control Engineering, Beijing University of Technology, Beijing 100124, China; 2. Beijing Key Laboratory of Magnetic Resonance Imaging and Brain Informatics, Beijing 100124, China; 3. Beijing International Collaboration Base on Brain Informatics and Wisdom Services, Beijing 100124, China

**Abstract:** Empirical mode decomposition (EMD) was used to denoise the original electroencephalography (EEG) signal of depression patients and normal controls, and convolutional neural networks (CNN) was applied to make a classification analysis for depression patients and normal controls. The resting-state EEG signals at Fp1 collected from 15 depression patients and 15 normal controls were denoised with EMD. The original signals were decomposed with EMD method to obtain the intrinsic mode function of different layers which were analyzed with frequency-domain analysis, and the noise signals were removed with hard threshold method. Finally, CNN was applied to perform binary classification for the signals from depression patients and normal controls, and the results showed that the classification accuracy of CNN is significantly higher than that of feature extraction-machine learning algorithm.

**Keywords:** depression; electroencephalography signal; empirical mode decomposition; intrinsic mode function; convolutional neural network

### 前言

抑郁症是一种慢性精神疾病,病人心情持续低落,伴有行为和思维的变化,并且有反复发作的症状,间歇期表现正常<sup>[1-2]</sup>。通过早期研究发现,抑郁症患者与正常人脑电(Electroencephalography, EEG)表现存在很大

的差异。早期EEG研究主要通过观察EEG的变化,这种简单的目测分析很难在复杂的EEG信号中发现抑郁症患者与正常人潜在的差异。现代信号处理分析研究提出了许多算法,如时域分析、频域分析、非线性分析等<sup>[3]</sup>。利用机器对病人的诊断可以作为一个分类问题,对于传统的机器学习分类方法,获得EEG的特征成为一个必要条件,之后利用提取到的信号特征完成机器学习方法的训练与测试<sup>[4-5]</sup>。现代研究提供了大量EEG信号特征提取的方法。波动指数作为传统衡量信号波动情况的指标被广泛应用于EEG信号的特征提取<sup>[6]</sup>,同时提取EEG信号的功率谱、信息熵也被广泛应用<sup>[7]</sup>。近

**【收稿日期】**2017-04-18

**【基金项目】**国家重点基础研究发展资助计划(2014CB744600)

**【作者简介】**刘岩,硕士研究生,研究方向:机器学习、数据挖掘、脑信息学, E-mail:741642676@qq.com

些年大量的研究者利用非线性动力学方法,如混沌理论、多重分型参数对 EEG 进行研究。Guler 等<sup>[8]</sup>计算每段脑电信号的 Lyapunov 指数,并将 Lyapunov 指数的均值、最大值、方差作为脑电信号特征。Sabeti 等<sup>[9]</sup>将信息熵作为 EEG 特征之外,还研究了 L-Z 复杂度和分型维数等在脑电信号分类中的应用。Lehnertz<sup>[10]</sup>回顾了这些非线性特征。但是应用单一的特征提取方法很大程度上丢失了信号原有的信息,造成算法性能的损失。本研究提出一种结合固有模态分解(Empirical Mode Decomposition, EMD)算法滤波与卷积神经网络(Convolutional Neural Network, CNN)对 EEG 数据分类的方法。EMD 算法有直观、直接、自适应等多种优势,算法通过将复杂信号或数据序列分解为若干条简单的信号从而达到信号或者数据的平稳化<sup>[11-12]</sup>。深度学习是一种新的机器学习模型,具有独特的分层结构体系,现在最成功的深度学习模型包括深度神经网络和 CNN,它们在机器视觉领域与语音识别领域获得了非常优秀的效果<sup>[13-14]</sup>。但是将深度学习领域应用到神经科学方面 EEG 数据的挖掘依旧没有获得突破。本研究在 EMD 算法对 EEG 数据滤波的基础上,对 EEG 信号进行重构,训练 CNN 后对抑郁症的识别达到很好的效果。

## 1 EEG 信号预处理及分类算法

### 1.1 EMD 算法的原理

EMD 算法将输入数据分解为 IMFs。因为 EMD 算法依靠数据局部特征时间尺度,可以将非线性和非平稳信号分解为平稳信号 IMFs,得到的 IMFs 有以下特征:(1)整个数据范围内,极值点和过零点的数量相等或者相差一个;(2)在任意点,所有极大值点形成的包络线和所有极小值点形成的包络线的平均值为 0。

EMD 算法过程如下:(1)在输入信号  $x$  找到信号中的极值点,极大值点两侧的点全部小于此点,极小值两侧的点全部大于此点,利用三次样条插值算法将所有的极大值和极小值点进行连接,此时得到原始信号的两条包络线  $U_{max}$  和  $U_{min}$ ; (2)计算(1)中得到两条包络线的均值  $m_1 = (U_{max} + U_{min})/2$ ; (3)利用原始信号减  $m_1$ , 即  $h_1 = x - m_1$ , 检测得到的信号  $h_1$  是否满足 IMF 函数的定义,若满足则保留其作为一条 IMF 函数,若不满足则将  $h_1$  重新定义为输入信号重复(1)~(2)直至获得一条 IMF 分量  $h_1$ ; (4)在获得一条 IMF 分量后改变输入信号  $x = x - h_1$ , 利用新的输入信号  $x$  重复(1)~(3)直至原始信号  $x$  变为一条单调信号位置,到此为止 EMD 算法将一条信号分解为  $N$  条 IMF 分量。

### 1.2 EEG 信号滤波

EEG 是微弱信号,在 EEG 信号采集过程中无法

避免受到外界噪声信号的影响,例如其他生理信号和外界电磁信号都会对采集到的 EEG 信号造成一定的影响。本研究通过 EMD 算法分解原始信号为 IMF 分量,并结合快速傅立叶变换对其进行分析,对含有噪声的 EEG 信号进行滤波处理。

图 1 为原始 EEG 信号,图 2 是经过 EMD 方法滤波之后重构的 EEG 信号,从图 1 可以发现原始信号中掺杂了噪声。对 EEG 去除噪声的方法是利用 EMD 算法对 EEG 原始信号分解为 16 条 IMF 分量,其中最后一条为单增信号,如图 3 中 5 条信号分别为 IMF1~IMF5。然后对得到的各个 IMF 分量进行快速傅立叶变换,得到对应的频域分布如图 4 所示。通过之前成熟的研究结果,EEG 信号频域分布在 3~80 Hz<sup>[15]</sup>。图 4 中的 IMF1 明显包含大量高于 80 Hz 的噪声信号。因此,通过去除 IMF1,利用 IMF2~IMF16 信号对原始信号重构,发现重构后得到一条平滑的 EEG 信号。

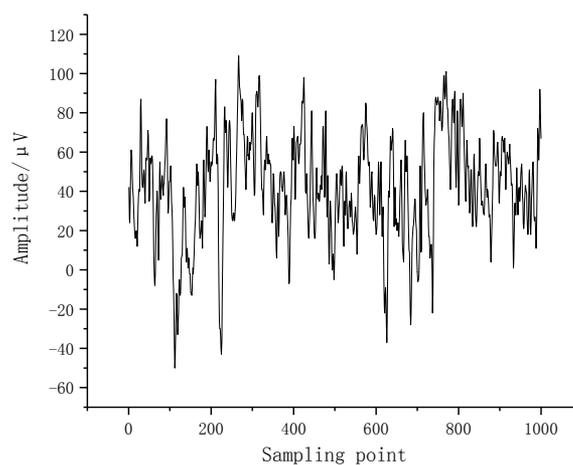


图1 原始 EEG 信号图

Fig.1 Original electroencephalography (EEG) signal

### 1.3 CNN

CNN 最初是为图像识别而设计的,CNN 包含 3 个主要层,分别为卷积层、池化层、全连接层。通过考虑图像的局部特征,利用二维的卷积核在原始图像上均匀滑动并在相应的位置做卷积运算,然后通过几个激活函数就可以得到输出的特征。

通过卷积层之后不可直接进入全连接层进行分类,因为卷积层之后下一层要求输入的特征数量还是十分可观,大量的数据输入分类器会造成运算不便,并容易出现过拟合。因此 CNN 引入了池化层,以平均池化为例,可以通过计算一个区域上的特征平均值对此区域进行替代,这些概要的统计特征不仅具有更低的维度,同时还会改善分类结果。

CNN 参数的优化方法同普通的神经网络相同,

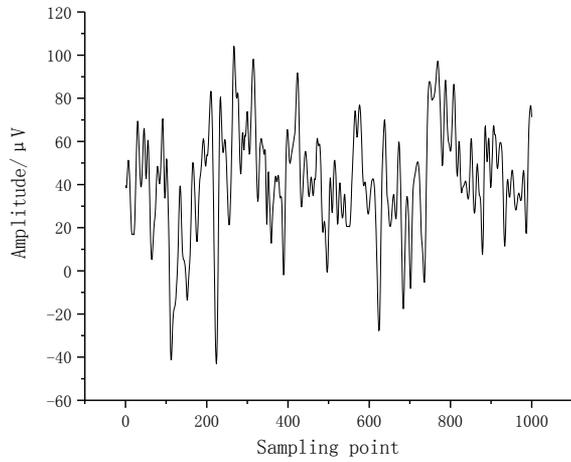


图2 滤波后的EEG信号  
Fig.2 Filtered EEG signal

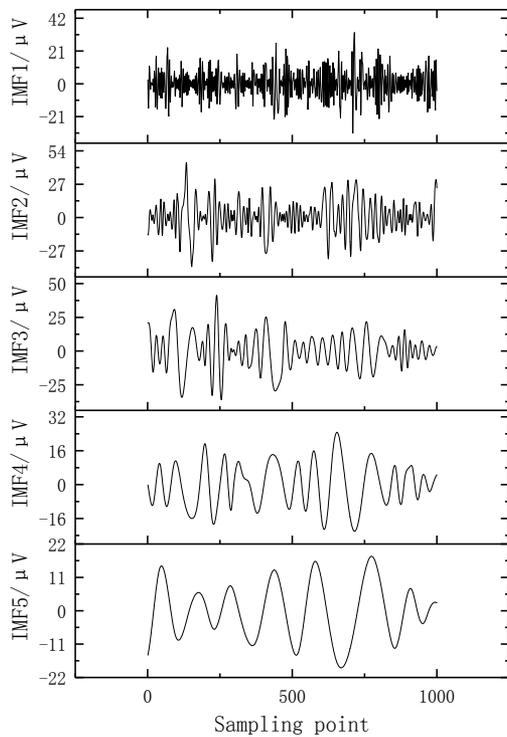


图3 IMF1-IMF5分解信号  
Fig.3 Decomposed EEG signal of IMF1-IMF5

都采用反向传播的方式,采用平方代价函数,假设有  $c$  类,  $N$  个训练样本  $t_k^n$  表示  $n$  个样本对应标签的第  $k$  维度,  $y_k^n$  表示第  $n$  个样本网络输出的第  $k$  个输出。这样,可以获得CNN总体代价函数:

$$E = \frac{1}{2} \sum_{n=1}^N \sum_{k=1}^c (t_k^n - y_k^n)^2 \quad (1)$$

对于第  $i$  个输出神经元优化的代价函数为:

$$E^i = \frac{1}{2} \|y_i - a_i\|^2 \quad (2)$$

卷积核与原始数据上的局部数据卷积,之后通

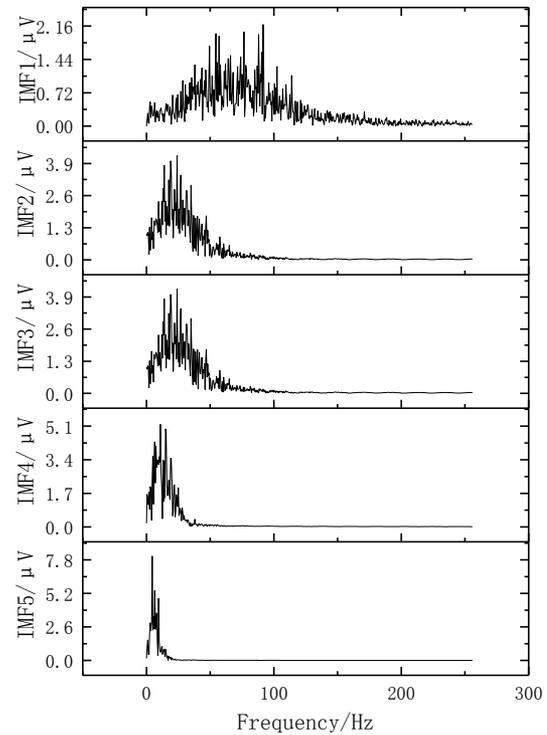


图4 IMF1-IMF5频谱  
Fig.4 Frequency spectrum of IMF1-IMF5

过激活函数作为卷积层的输出。其中  $M_j$  为卷积核在原二维数据上滑动时卷积核所在位置的原始数据:

$$x_j^l = f\left(\sum_{i \in M_j} x_i^{l-1} \cdot k_{ij}^l + b_j^l\right) \quad (3)$$

CNN参数的优化过程是更新参数使代价函数最小,为了快速达到最小值需要参数沿着梯度的反方向更新:

$$k_{ij}^l = k_{ij}^l - \alpha \frac{\partial E}{\partial k_{ij}^l} \quad (4)$$

$$b_j^l = b_j^l - \alpha \frac{\partial C}{\partial b_j^l} \quad (5)$$

池化层使输入数据的维度减小:

$$x_j^l = f(\beta_j^l \text{down}(x_j^{l-1}) + b_j^l) \quad (6)$$

池化层的参数优化同样为使代价函数达到最小,即参数沿着梯度的反方向更新。

## 2 实验验证

### 2.1 试验描述数据采集

试验目的:本试验研究抑郁症患者与正常对照组静息态脑电之间的差别,最终达到对抑郁症患者和正常人分类的目的。

试验设计:被试的选择标准为右利手,高中以上文化水平,年龄20~60岁,平均年龄26岁。其中病人选择为单向抑郁症病人,且一个月之内没有ETC诊疗记录、未服用抗抑郁药物。正常对照组被试无抑

郁症病史。病人组10男5女,正常对照组8男7女。

试验设备:采用NeuroSky公司脑电设备Mind-Wave Mobile作为EEG信号的采集设备,单通道干电极,只采集Fp1点的EEG信号。

被试采集过程:被试在静息态状态下,环境保持安静,关灯。被试闭眼静坐,佩戴设备对Fp1点进行EEG信号的采集,采样频率控制在512 Hz,采集时间为5 min。

试验数据:通过以上试验采集过程,获得30位被试的EEG信号数据。每次数据采集包含3部分信息:第一部分为时间信息;第二部分为EEG数据;第三部分为电压值数据。最终数据结果为每位被试采集到4 MB的153 600行3列文本文件。其中第二部分的EEG数据为本研究所用数据。

### 2.2 试验数据分析

不同于传统的监督机器学习方法,传统的机器学习方法在训练算法和测试之前要进行数据的特征提取。本研究中CNN的训练与测试直接利用原始EEG信号在第1.2节中滤波后的数据。因为CNN的

特殊结构,其对数据的相邻数据点进行卷积,本文对采集到的单导数据信号进行结构上的重组。因为数据采集实验中的采样频率固定在512 Hz,试验中将采集到的单导数据进行多行的划分,每行512个点,这样原始EEG数据被重构为一个二维的数组结构。

CNN结构,采用LetNet5结构使用两个卷积-池化层,每条153 600个点滤波后的数据首先重构为512×300,重构后的数据作为CNN的输入,进入第一个卷积层,第一个卷积层为5个5×5的卷积核,经过卷积之后获得5个508×296的矩阵。之后进入池化层,池化层为1个2×2的最大池化矩阵,因此,池化后的数据维度为254×148。随后数据将进入第二个卷积-池化层,第二个卷积层的规模是5×5,10个卷积核,池化层为一个2×2最大池化矩阵,两个卷积-池化层后数据将变为50个125×72维度的矩阵。经过卷积-池化层后的数据与2 000个神经元的全连接层进行全连接,最后全连接层与两个神经元的输出层进行全连接,从而进行分类。图5为CNN的结构描述。

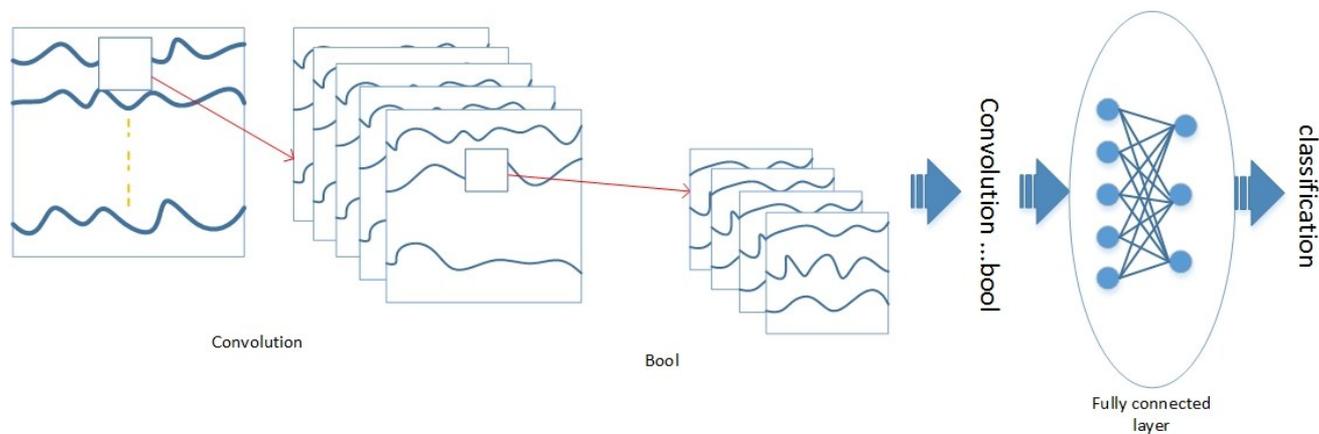


图5 CNN结构

Fig.5 Structure of convolutional neural network (CNN)

验证策略使用留一交叉验证的方法<sup>[16]</sup>:30个样本,在做数据重构之后,将其中的29个样本作为训练数据输入分类器对CNN进行训练,剩下的一个样本作为测试数据。循环训练之后,得到30个测试数据的分类标签。将预测标签与真实数据标签进行对比,得到最终分类准确率。

为了验证CNN的性能,试验结果与传统提取信号特征的方法作为对比项。第一种信号特征提取方法为EMD分解后获得IMFs,利用第1.2节中的方法滤波,提取IMF2~IMF6信号的波动指数,把它作为特征:

$$F = \frac{1}{n} \sum_{i=1}^n |c(i+1) - c(i)| \tag{7}$$

第二种首先利用第1.2节中的方法对EEG信号进行滤波,之后重构EEG信号,利用wavelet方法使用db4小波对滤波后的EEG进行5尺度的分解,重构为5条信号,利用波动指数方法对5条信号提取特征。最后用传统的支持向量机(SVM)和logistics分类器进行对照,其中CNN算法获得了最好的性能(表1)。

在表1中,作为对比项使用小波变换、EMD两种信号处理的方法,结合波动指数对原始EEG信号进行特

征提取,使用了两种分类器SVM和Logistic。利用EEG信号提取的特征对算法进行训练-测试:SVM-小波变换-波动指数获得了90.00%的对比组中最高的分类准确率。而使用EMD滤波-重构信号-CNN的分类策略获得更佳

的分类效果,获得了96.70%的分类准确率。

表1 CNN与对比算法分类效果对比

Tab.1 Classification accuracy of CNN and other algorithms

Algorithm	Feature extraction method	Accuracy/%
SVM	Wavelet-fluctuate index	86.70
SVM	EMD-fluctuate index	90.00
Logistic	Wavelet-fluctuate index	83.30
Logistic	EMD- fluctuate index	80.00
CNN	Reconstructed EEG	96.70

SVM: Support vector machine; EMD: Empirical mode decomposition

### 3 结束语及未来工作

现有的抑郁症诊疗方法包括量表的评定、家属和病人的访谈,以及医师的临床经验,这些主观的诊疗方法往往会造成抑郁症诊断中的误诊。本研究提出一种基于CNN算法结合EEG信号的客观生物指标对抑郁症患者与正常人进行分类,找到一种准确、快速的抑郁症诊疗方法。首先采用EMD算法分解EEG信号为不同频率范围的IMF分量,通过选取有效的IMF分量,达到信号滤波的目的;之后对滤波后的EEG信号结构重构为二维的矩阵形式,作为CNN的输入并训练CNN;最后采用留一验证的方法对训练后的CNN进行准确率测试。实验结果表明,本研究采用的方法基本达到有效对抑郁症患者和健康对照组EEG准确分类的目的:通过对15位患者和15位健康对照组的静息态脑电滤波、分类,正确率达到96.7%。但是较高的分类效果是在现有数据下的结果,然而现有的试验被试还没有做到囊括各个年龄段、性别、学历背景的不同人群。同时现有的分类方法仅仅限于对现有的抑郁症患者和正常对照组进行简单的二值分类。本研究实际的临床意义以及实际的临床应用效果,还需要进一步验证。

### 【参考文献】

[1] 朱艺. 抑郁症研究进展[J]. 实用中医药杂志, 2005, 24(2): 131-132.

ZHU Y. Research progress on depression[J]. Journal of Practical Traditional Chinese Medicine, 2005, 24(2): 131-132.

- [2] 李跃华, 张兰凤. 抑郁症研究现状及未来研究目标探讨[J]. 中国中医药信息杂志, 2006, 13(10): 1-3.
- LI Y H, ZHANG L F. Research status and future research goals of depression[J]. Chinese Journal of Information on Traditional Chinese, 2006, 13(10): 1-3.
- [3] 崔光照, 曹祥红, 王延峰, 等. 生物信息学中的数字信号处理方法研究[J]. 科学技术与工程, 2005, 5(20): 1494-1497.
- CUI G Z, CAO X H, WANG Y F, et al. Digital signal processing in bioinformatics[J]. Science Technology and Engineering, 2005, 5(20): 1494-1497.
- [4] KHAN Y U, GOTMAN J. Wavelet based automatic seizure detection in intracerebral electroencephalogram[J]. Clin Neurosci, 2003, 114(5): 898-908.
- [5] GUMUS E, KILIC N, SERTBAS A, et al. Evaluation of face recognition techniques using PCA, wavelets and SVM[J]. Expert Syst Appl, 2010, 37(9): 6404-6408.
- [6] LI S F, ZHOU W D, YUAN Q, et al. Feature extraction and recognition of ictal EEG using EMD and SVM[J]. Comput Biol Med, 2013, 43(7): 807-816.
- [7] WANG D, MIAO D Q, XIE C. Best basis-based wavelet packet entropy feature extraction and hierarchical EEG classification for epileptic detection[J]. Expert Syst Appl, 2011, 38(11): 14314-14320.
- [8] GULER N F, UBEYLI E D, GULER I. Recurrent neural networks employ Lyapunov exponents[J]. Expert Syst Appl, 2005, 29(3): 506-514.
- [9] SABETI M, KATEBI S, BOOSTANI R. Entropy and complexity measures for EEG signal classification of schizophrenic and control participants[J]. Artif Intell Med, 2009, 47(3): 263-274.
- [10] LEHNERTZ K. Epilepsy and nonlinear dynamics[J]. J Biol Phys, 2008, 34(3): 253-266.
- [11] 翟俊海, 翟梦尧, 张素芳, 等. 基于小波子空间集成的人脸识别[J]. 山东大学学报(工学版), 2012, 42(2): 1-6.
- ZHAI J H, ZHAI M Y, ZHANG S F, et al. Face recognition based on ensemble of wavelet subspaces[J]. Journal of Shandong University (Engineering Science), 2012, 42(2): 1-6.
- [12] 张宏兵, 陆建峰, 汤九斌. 一种基于近似EMD的DBSCAN改进算法[J]. 山东大学学报(工学版), 2012, 42(4): 35-40.
- ZHANG H B, LU J F, TANG J B. An improved DBSCAN algorithm based on the approximate EMD[J]. Journal of Shandong University (Engineering Science), 2012, 42(4): 35-40.
- [13] HINTON G, DENG L, YU D, et al. Deep neural networks for acoustic modeling in speech recognition: the shared views of four research groups[J]. IEEE Signal Proc Mag, 2012, 29(6): 82-97.
- [14] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[C]//Advances in Neural Information Processing Systems. 2012: 1097-1105.
- [15] 尧德中. 脑功能探测的电学理论与方法[M]. 北京: 科学出版社, 2003: 73-86.
- YAO D Z. Electrical theory and method of detection of brain function [M]. Beijing: Science Press, 2003: 73-86.
- [16] NANDAN M, TALATHI S S, MYERS S, et al. Support vector machines for seizure detection in an animal model of chronic epilepsy [J]. J Neural Eng, 2010, 7(3): 361-372.

(编辑:陈丽霞)