

基于HHT的视觉疲劳脑电特征提取

刘家卓, 谢云, 陈学强, 邹洋
广东工业大学自动化学院, 广东 广州 510006

【摘要】为准确提取到脑电信号中的疲劳特征,以此作为预警器提醒程序员休息,本文设计了一个基于稳态视觉诱发电位(SSVEP)的脑电实验,采用希尔伯特黄算法提取被试者脑电信号中EEG参数 θ 、 α 、 β 、 β/α 、 $(\alpha+\theta)/\beta$ 在正常状态和疲劳状态下的希尔伯特边际谱能量值,分析两种状态下的希尔伯特边际谱能量的变化趋势。单因素方差分析结果表明:在疲劳状态下 α 、 $(\alpha+\theta)/\beta$ 的边际谱能量显著上升, β 、 β/α 波边际谱能量显著下降。通过支持向量机分类, β/α 的最大分类准确率达到94.4%, β 节律的最大分类准确率达到93.3%。 α 、 $(\alpha+\theta)/\beta$ 也表现出良好的可分性。从希尔伯特黄算法中提取的4个EEG参数 $[\alpha$ 、 β 、 β/α 、 $(\alpha+\theta)/\beta]$ 的边际谱能量特征均可以作为评价视觉疲劳特性的指标。

【关键词】基于稳态视觉诱发电位;希尔伯特黄算法;视觉疲劳特性;支持向量机

【中图分类号】R318;R388.8

【文献标志码】A

【文章编号】1005-202X(2018)12-1473-06

Feature extraction of visual fatigue EEG signals based on HHT

LIU Jiazhao, XIE Yun, CHEN Xueqiang, WU Yang

School of Automation, Guangdong University of Technology, Guangzhou 510006, China

Abstract: An electroencephalogram (EEG) experiment based on steady-state visual evoked potentials is designed to accurately extract the fatigue characteristics of EEG signals and use those characteristics as warning signs to remind the programmer to rest. The Hilbert marginal spectral energy distributions of EEG parameters, namely θ , α , β , β/α and $(\alpha+\theta)/\beta$, in the normal and the fatigue states are extracted by Hilbert-Huang algorithm. The change trends of Hilbert marginal spectrum energy in both states are analyzed. The results of one-way analysis of variance reveal that in the fatigue state, the marginal spectral energy of α and $(\alpha+\theta)/\beta$ increases significantly, and that the marginal spectral energy of β and β/α decreases significantly. By support vector machine classification, the maximum classification accuracy rates of β/α and β reach 94.4% and 93.3%, respectively. A good separability is also found between α and $(\alpha+\theta)/\beta$. The marginal spectral energy characteristics of the 4 EEG parameters, namely α , β , β/α , $(\alpha+\theta)/\beta$, extracted with Hilbert-Huang algorithm can be used as indicators to evaluate the visual fatigue.

Keywords: steady-state visual evoked potential; Hilbert-Huang algorithm; visual fatigue characteristic; support vector machine

前言

视觉疲劳是指在学习或工作过程中,用眼过度,会出现眼睛干涩、大脑疲惫、注意力下降等现象^[1]。在一些需要高度集中注意力的工作中,操作人员因为视觉疲劳而导致的注意力下降、精神不集中,会引发严重的事故。在日常生活中,青少年儿童过度使

用电子产品也会产生视觉疲劳,导致视力下降,不利于身心健康。因此研究视觉疲劳并确立评价标准,是十分重要的^[2-3]。

目前主要有主观评定法和客观评定法两种方法来判断脑疲劳^[4]。主观评定法通过问卷调查的方式来获取被试者的身体感受症状从而来判别疲劳的程度^[5]。主观评定法的评分标准不易统一、且易受主观因素的影响,无法对疲劳时心理生理状态进行客观的评定^[6]。客观评定法就是使用仪器设备等工具采集人体的生理信号,对这些信号进行处理和分析来估计疲劳程度。但是这些生理信号与疲劳程度的关系是不确定的,受个体差异的影响很大,难以实现客

【收稿日期】2018-06-14

【基金项目】广东省自然科学基金(2016A030313706)

【作者简介】刘家卓,硕士研究生,研究方向:脑机接口,E-mail:72717-5900@qq.com

观和量化^[7]。

Cao等^[8]对单通道的脑电数据进行分析,发现脑电信号频谱与视觉疲劳息息相关。近年来,脑电信号的采集与分析技术的发展使得脑疲劳的检测技术有了很大提高,脑电信号是一种非线性、非平稳的信号^[9]。传统的时域方法和频域方法还有小波分析等时频结合的方法都不能较好地提取出脑电信号中的非线性特征。随着非线性科学的完善,非线性方法开始用来处理分析脑电信号,其中希尔伯特黄算法是一种经典的非线性信号处理方法^[10-11]。它通过经验模态分解将信号分解为多个固有模态函数(IMF)分量,再通过希尔伯特变换进行进一步的分析^[12]。

胡淑燕等^[13]采用的快速傅里叶变换提取的疲劳脑电频谱特征分类效果达到了84%,张崇等^[14]采用的小波变换提取疲劳脑电特征经过支持向量机(SVM)分类达到的最大准确率为87%。而本文采用的希尔伯特黄算法提取脑电信号的希尔伯特边际谱能量作为视觉疲劳脑电特征,最大分类准确率达到了94.4%,说明了希尔伯特黄算法的可靠性。

1 希尔伯特黄算法

1998年,Huang等提出了HHT算法,HHT是一种分析信号的时频算法^[15]。它由经验模态分解(Empirical Mode Decomposition, EMD)和希尔伯特变换两部分组成^[16]。

1.1 EMD

EMD对于处理非平稳和非线性过程的数据是十分有效的。EMD可以根据信号本身的特性自适应地产生合适的IMF分量,每个IMF分量都可以反映信号在任何时间局部的频率特征,不需要先选择基函数,由信号自身的物理特征选择合适的自适应基^[17-19]。由EMD分解的IMF分量必满足两个条件:

(1)在整个数据集上,极值数和过零点相等或相差最多一个。

(2)由极大值定义的上包络线和极小值定义的下包络线的均值均为零。

原始信号可以由这些IMF分量构成:

$$x(t) = \sum_{i=1}^n C_i(t) + r_n(t) \quad (1)$$

其中, $x(t)$ 为原始信号; $C_i(t)$ 为进行EMD时第 i 次筛选出的IMF,它代表了信号从高到低各个频率段的成分, $r_n(t)$ 为最后的残余分量。

1.2 希尔伯特变换

对提取出的每个IMF分量进行希尔伯特变换:

$$H[c_i(t)] = \frac{1}{\pi} P \int_{-\infty}^{\infty} \frac{c_i(\tau)}{t - \tau} d\tau \quad (2)$$

其中 P 代表的是柯西主值。利用希尔伯特变换构造出解析信号为:

$$Z_i(t) = c_i(t) + jH[c_i(t)] \quad (3)$$

瞬时相位 $\theta_i(t)$, 瞬时幅值 $a_i(t)$ 和瞬时频率 $w_i(t)$ 为:

$$\theta_i(t) = \arctan\left(\frac{H[c_i(t)]}{c_i(t)}\right) \quad (4)$$

$$a_i(t) = \sqrt{c_i^2(t) + H[c_i^2(t)]} \quad (5)$$

$$w_i(t) = \frac{d\theta_i(t)}{dt} \quad (6)$$

脑电信号是一种非平稳信号,非平稳信号的频率时随着时间变化,传统的傅里叶频率是一个独立的量,与时间无关,而瞬时频率是关于时间的函数,能更好的反映信号的局部频率。

IMF分量进行完希尔伯特变换之后,信号 $X(t)$ 可以用以下形式来表示:

$$X(t) = \sum_{j=1}^n a_j(t) \exp(i \int w_j(t) dt) \quad (7)$$

这样就得到了一个瞬时频率和振幅关于时间的函数。振幅在频率-时间上的分布图就称为希尔伯特谱^[19]。再对希尔伯特谱在时间上进行积分,就可以得到希尔伯特边际谱 $h(w)$:

$$h(w) = \int_0^T H(w, t) dw \quad (8)$$

2 实验方案

2.1 视觉疲劳脑电信号采集

实验刺激器设计成5个棋盘格的小方块。每个格子随机闪烁,刺激频率分别为9、10、11、12、13 Hz。实验流程图如图1所示。实验开始前,测试者坐在离屏幕50 cm的地方,注视屏幕中心的注视点,保持舒适的坐姿。实验开始之前先对测试者进行主观疲劳程度的检测。主观疲劳检测的调查问卷由14个问题组成,其中有8个精神疲劳的问题和6个视觉疲劳的问题。实验有4个阶段,每个阶段不同闪烁频率随机出现3次,在每个刺激频率的30 s实验中,被试者注视频率块4 s,休息1 s,一共做6组。做完一个阶段的实验,被试者休息1 min,在这段时间内,受试者填写主观疲劳评价量表,收集受试者的主观疲劳感受,作为客观分析的参考指标。

选取15名被试者参加实验(3女12男),年龄22~26岁。被试者身体健康,都有正常或矫正正常视力。脑电采集设备实用neuracle32导脑电放大器,采样频率为256 Hz。电极放在O1、O2、Pz 3个位置,如图2所示。



图1 实验流程图

Fig.1 Flow chart of experiment




图2 电极安放图

Fig.2 Electrode placement diagram

2.2 主观疲劳评价结果分析

统计15个受试者的评分表,得到归一化后的主观疲劳评分均值。如图3所示。




图3 归一化主观疲劳量值

Fig.3 Normalized subjective fatigue values

图3中的S1、S2、S3、S4代表的实验的4个阶段,0刻度处的疲劳量值是实验开始前测量得到的。总体上,受试者的平均疲劳量值随着时间的增大呈现上升的趋势,说明在实验过程中,受试者的主观疲劳感受增加,稳态视觉诱发刺激导致被试者产生疲劳。比较第一阶段和第四阶段的疲劳量值,两个阶段的值具有显著的差异。本文将这两个阶段分别定义为清醒和疲劳阶段,文中出现的清醒阶段和疲劳阶段皆是指这两个阶段。

2.3 脑电信号预处理

根据稳态视觉诱发电位(Steady-State Visual Evoked Potentials, SSVEP)性质,使用1~50 Hz的带阻滤波器对

3个通道采集到的脑电信号 $X(t)$ 进行预处理,得到低频段的脑电信号 $X'(t)$,对 $X'(t)$ 做独立成分分析(ICA)将信号中眼电和肌电等伪迹的干扰去除得到了信号 $x(t)$,再把信号 $x(t)$ 导入 Matlab 的脑电波研究工具箱中(Electroencephalogram Laboratory, EEGLAB)中。对于单个通道的脑电信号而言(以 O_1 为例),由于每一阶段的5个刺激频率都做了3次实验,在EEGLAB中选取每个刺激频率SSVEP信号质量最好的一次作为分析的脑电信号,可以得到不同刺激频率下5个脑电信号 $x_{9\text{ Hz}}(t), x_{10\text{ Hz}}(t), x_{11\text{ Hz}}(t), x_{12\text{ Hz}}(t), x_{13\text{ Hz}}(t)$ 。

3 实验数据分析

3.1 实验数据的处理

选取第一阶段的脑电数据作为清醒状态(Awake),第四阶段的脑电数据作为疲劳状态(Fatigue)。在每个刺激频率的30 s刺激中,被试者观察刺激块4 s,休息1 s。总共做6组。每个阶段都包含有5个不同刺激频率下的脑电信号,选取脑电信号 $x_{i\text{ Hz}}(t)$ 中被试者观察刺激块的这24 s的脑电信号进行分析。由于设备的采样频率为256 Hz,4 s的脑电信号可以获得1 024个采样点,对这些采样点进行经验模态分解,得到IMF分量。选取与 $x_{i\text{ Hz}}$ 中这4 s脑电信号相关系数最大的4个IMF分量(imf1、imf2、imf3、imf4),再对这些IMF分量做希尔伯特变换得到希尔伯特谱 $H_i(w, t)$ 。对希尔伯特谱 $H_i(w, t)$ 在时域上进行积分就可以得到频率-幅值的希尔伯特边际谱 $h_i(w)$,3种EEG节律[θ (4~7 Hz)、 α (8~13 Hz)、 β (14~30 Hz)]对应的能量为:

$$E_{\theta} = \sum_{i=1}^4 h_i(w), \quad (4 \text{ Hz} \leq w \leq 7 \text{ Hz}) \quad (9)$$

$$E_{\alpha} = \sum_{i=1}^4 h_i(w), \quad (8 \text{ Hz} \leq w \leq 13 \text{ Hz}) \quad (10)$$

$$E_{\beta} = \sum_{i=1}^4 h_i(w), \quad (14 \text{ Hz} \leq w \leq 30 \text{ Hz}) \quad (11)$$

式中, h_i 为每个IMF分量对应的希尔伯特边际谱, $h(w)$ 为 w 频率对应的希尔伯特边际谱的幅值。

每个被试者在一个刺激频率下单个通道4 s的脑电信号可以得到一个反映EEG参数边际谱能量的样本点。综合每个被试者3个脑电通道 $O1$ 、 $O2$ 、 Pz ,5个刺激频率(9、10、11、12、13 Hz)下的24 s的脑电信号就可以得到 $3 \times 5 \times 6$ 个样本点。再将所有被试者的数据进行统计平均,得到了该次实验清醒阶段的90个样本点,疲劳阶段的90个样本点。

3.2 单因素方差分析

单因素方差分析是通过检验多个平均数之间的

差异,从而确定因素对试验结果有无显著性影响的一种统计方法。在本文中,以边际谱能量为指标,视觉疲劳程度为因素,清醒状态和疲劳状态就是这个因素的两个不同水平。清醒状态下反映边际谱能量的90个样本点为 x_{1j} ($j=1, 2, 3, \cdots, 90$),疲劳状态下反映边际谱能量的90个样本点为 x_{2j} ($j=1, 2, 3 \cdots, 90$)。

为了得到EEG参数的边际谱能量在疲劳前后的变化特性,对 α 、 θ 、 β 、 β/α 、 $(\alpha+\theta)/\beta$ 这5个EEG参数在清醒阶段和疲劳阶段的边际谱能量(x_{1j} , x_{2j})进行单因素方差分析。结果如表1所示。并且对疲劳前后EEG参数的边际谱能量做了柱状的对比如图4所示。

表1 EEG指标边际谱的单因素方差分析结果
Tab.1 One-way analysis of variance of the marginal spectral energy of electroencephalogram (EEG) parameters

Parameter	Analysis of variance	
	Statistics (<i>F</i>)	<i>P</i> value
θ	1.254	>0.05
α	73.554	<0.001
β	246.874	<0.001
β/α	333.4	<0.001
$(\alpha+\theta)/\beta$	101.5	<0.001




图4 EEG参数疲劳前后的边际谱能量
Fig.4 Marginal spectral energy of EEG parameters before and after fatigue

综合表1和图4,对实验第一个阶段和第四个阶段的数据进行比较看出 α 、 $(\alpha+\theta)/\beta$ 的边际谱能量显著性上升($P<0.001$); θ 参数的边际谱能量没有显著性变化($P>0.05$); β 和 β/α 的边际谱能量显著性下降($P<0.001$)。选取 α 、 β 、 β/α 、 $(\alpha+\theta)/\beta$ 这4个

参数在疲劳前后的边际谱能量做出曲线对比图。从图5中我们可以看出,这4个参数具有良好的可分性。

将得到的 α 、 β 、 β/α 、 $(\alpha+\theta)/\beta$ 的边际谱能量值生成一个四维的特征向量 T ,特征 T 包含了待分类识别的特征:

$$T = \begin{bmatrix} E_{\alpha} \\ E_{\beta} \\ E_{\beta/\alpha} \\ E_{(\alpha+\theta)/\beta} \end{bmatrix} \tag{12}$$

式中列代表边际谱能量,下标代表着对应的EEG参数,特征 E_{α} 代表着参数 α 的边际谱能量值。

3.3 SVM分类

本文采用SVM对我们提取好的特征向量进行分类^[20-21],核函数选取高斯核函数。特征分类的步骤如图6所示。

(1) 选定脑电样本的训练集和测试集。经过处理后的疲劳脑电特征 T 一共有720个数据。按照3:2的比例随机划分训练集和测试集。

(2) 归一化。在脑电数据中会有一些异常的数据点,为了使这些异常的数据点不影响到我们的分类结果,使用归一化处理。

(3) 利用训练集训练SVM分类器,得到分类模型。在训练过程中采用10次交叉验证的方法,得到最优的惩罚因子。本文中惩罚因子 C 为0.5。导入测试集对训练得到的模型进行测试。

最后得到的分类准确率就是5次测试结果的平均值。表2给出了4种EEG参数边际谱能量的分类结果。

4 结 论

本文在希尔伯特黄变换的基础上,通过提取脑电节律(α 、 θ 、 β)的希尔伯特边际谱能量分析了EEG参数 α 、 θ 、 β 、 β/α 、 $(\alpha+\theta)/\beta$ 的边际谱能量在清醒和疲劳状态下的变化情况[α 、 $(\alpha+\theta)/\beta$ 显著性上升; β 、 β/α 显著性下降]。并对这5组EEG参数在清醒和疲劳状态下的边际谱能量进行SVM分类,其中EEG参数[α 、 β 、 β/α 、 $(\alpha+\theta)/\beta$]的边际谱能量表现出了良好的可分性,其中 β 节律的最大分类准确率达到93.3%,而 β/α 的最大分类准确率达到94.4%。结果表明,与传统的时域和频域方法相比,使用希尔伯特黄算法从EEG节律(α 、 θ 、 β)中提取到的边际谱能量特征进行SVM的分类准确率更高,能够更有效地检测到视觉疲劳特征。笔者在后

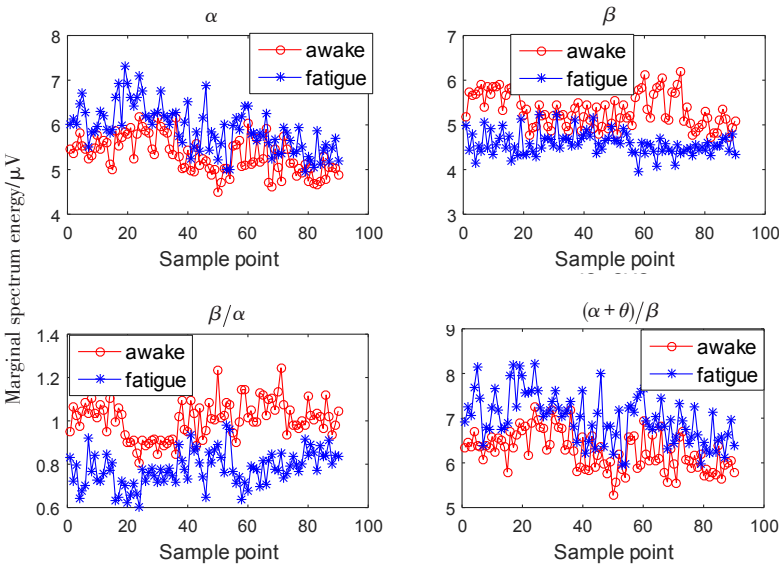


图5 清醒与疲劳状态下边际谱能量曲线图

Fig.5 Marginal energy curves in the awake and the fatigue states




图6 SVM流程图

Fig.6 Flowchart of support vector machine

表2 EEG参数疲劳的分类结果(%)

Tab.2 Classification of marginal spectral energy of EEG parameters in the fatigue state (%)

Item	α	β	β/α	$(\alpha+\theta)/\beta$
Accuracy	81.3	93.3	94.4	84.4

续的工作中,将会尝试设计一个监测仪器检测EEG节律边际谱能量的变化[α 、 $(\alpha+\theta)/\beta$ 显著性上升; β 、 β/α 显著性下降]来判定视觉疲劳,提醒程序员休息。

【参考文献】

[1] LI Y F, ZHANG L H, GENG X C. The comparison and study of WVD, PWVD, SPWVD time frequency analysis technologies based on observed dynamic EEG data [G]. Information Technology and Management Engineering, 2017: 7.

[2] ZHU D B, BIEGER J, GARCIA MOLINA G, et al. A survey of stimulation methods used in SSVEP-Based BCI[J]. Comput Intell Neurosci, 2010(1): 702357.

[3] 镐振选, 刘如如, 虞荣斌, 等. 电脑荧屏接触时间对视频显示终端综合征影响研究[J]. 中国职业医学, 2013, 40(4): 320-322.

GAO Z X, LIU R R, YU R B, et al. Study on effect of daily exposure time of computer screen to visual display terminal syndrome[J]. China Occupational Medicine, 2013, 40(4): 320-322.

[4] LIN K, CINETTO A, WANG Y, et al. An online hybrid BCI system based on SSVEP and EMG[J]. J Neural Eng, 2016, 13(2): 026020.

[5] 杨博. 长时间持续警戒任务下脑力疲劳对前注意和注意加工能力影响的ERP研究[D]. 西安: 第四军医大学, 2013.

YANG B. ERP study on the effects of mental fatigue on pre-attention and attention to processing capacity during long-term continuous warning tasks[D]. Xi'an: Fourth Military Medical University, 2013.

[6] ZHAO X, CHU Y, HAN J. SSVEP-based brain-computer interface controlled functional electrical stimulation system for upper extremity rehabilitation[J]. IEEE Trans Syst Man Cybern Syst, 2016, 46(7): 947-956.

[7] 沈学丽. 基于时频分析的头皮脑电特征提取及其模式识别应用研究[D]. 杭州: 杭州电子科技大学, 2012.

SHEN X L. Study on scalp EEG feature extraction and pattern recognition based on time-frequency analysis [D]. Hangzhou: Hangzhou Dianzi University, 2012.

[8] CAO T, WAN F, WONG C M. Objective evaluation of fatigue by EEG spectral analysis in steady-state visual evoked potential-based brain-computer interfaces[J]. Biomed Eng Online, 2014, 13(1): 28.

[9] CARVALHO S N, COSTA T, URIBE L. Comparative analysis of strategies for feature extraction and classification in SSVEP BCIs[J]. Biomed Signal Process Control, 2015, 21: 34-42.

[10] SWARNALATHA R, PRASAD D. Detection of sleep bruxism based on EEG Hilbert Huang-transform[J]. Int J Biomed Eng Technol, 2015,

- 81(7): 33-39.
- [11] 朱晓军. HHT变换及其在脑电信号处理中的应用研究[D]. 太原: 太原理工大学, 2012.
- ZHU X J. HHT transformation and its application in EEG signal processing[D]. Taiyuan: Taiyuan University of Technology, 2012.
- [12] 徐建宁. 基于HHT和ELM的水下目标识别技术研究[D]. 哈尔滨: 哈尔滨工程大学, 2014.
- XU J N. Research on underwater target recognition based on HHT and ELM[D]. Harbin: Harbin Engineering University, 2014.
- [13] 胡淑燕, 郑钢铁. 基于EEG频谱特征的驾驶员疲劳监测研究[J]. 中国安全生产科学技术, 2010, 6(3): 90-94.
- HU S Y, ZHENG G T. Study on driver fatigue detection based on EEG spectrum-related features [J]. Journal of Safety Science and Technology, 2010, 6(3): 90-94.
- [14] 张崇, 郑崇勋, 于晓琳. 基于多心理生理参数和核学习算法的脑疲劳估计[J]. 科学通报, 2008, 53(12): 1403-1413.
- ZHANG C, ZHENG C X, YU X L. Evaluation of brain fatigue based on multi-psycho physiological parameters and nuclear learning algorithms[J]. Science Bulletin, 2008, 53(12): 1403-1413.
- [15] 钟佑明. 希尔伯特-黄变换局瞬信号分析理论的研究[D]. 重庆: 重庆大学, 2002.
- ZHONG Y M. Research on Hilbert-Huang transform bureau instantaneous signal analysis theory [D]. Chongqing: Chongqing University, 2002.
- [16] 王蒙. 基于多尺度分解的次声波信号特征的提取[D]. 南昌: 南昌大学, 2015.
- WANG M. Feature extraction of infrasonic signals based on multi-scale decomposition[D]. Nanchang: Nanchang University, 2015.
- [17] 孟宗, 李姗姗. 基于小波半软阈值和EMD的旋转机械故障诊断[J]. 中国机械工程, 2013, 24(10): 1279-1283.
- MENG Z, LI S S. Research on fault diagnosis for rotating machinery based on semi-soft wavelet threshold and EMD [J]. China Mechanical Engineering, 2013, 24(10): 1279-1283.
- [18] 郑佳宁. 局域均值分解算法研究及其应用[D]. 西安: 西安电子科技大学, 2012.
- ZHENG J N. Research and application of local mean decomposition algorithm[D]. Xi'an: Xidian University, 2012.
- [19] 莫雄强. 基于脑电的疲劳度检测方法研究[D]. 秦皇岛: 燕山大学, 2009.
- MO X Q. Research on the detection method of fatigue based on EEG [D]. Qinhuangdao: Yanshan University, 2009.
- [20] 何敏. 基于Hilbert-Huang变换获得睡眠脑电信号特征[J]. 电脑知识与技术, 2015, 11(20): 161-163.
- HE M. Obtaining characteristics of the sleep EEG based on Hilbert-Huang transform[J]. Computer Knowledge and Technology, 2015, 11(20): 161-163.
- [21] 李幼军, 钟宁, 黄佳进, 等. 基于高斯核函数支持向量机的脑电信号时频特征情感多类识别[J]. 北京工业大学学报, 2018, 44(2): 234-243.
- LI Y J, ZHONG N, HUANG J J, et al. Human emotion multi-classification recognition based on the EEG time and frequency features by using a Gaussian kernel function SVM[J]. Journal of Beijing University of Technology, 2018, 44(2): 234-243.

(编辑: 薛泽玲)