

多特征融合的运动想象脑电特征提取方法

罗 飞*, 刘鹏飞, 罗 元, 朱思蒙

(重庆邮电大学 光电工程学院, 重庆 400065)

(* 通信作者电子邮箱 676176555@qq.com)

摘 要:针对单一特征识别率低、自适应性差等问题,提出一种基于希尔伯特-黄变换(HHT)和共同空间模式(CSP)的特征提取方法HCHT。首先,对原始脑电信号(EEG)进行经验模态分解(EMD)得到固有模态函数(IMF),并将IMF分量合并成新的信号矩阵;然后,对IMF进行希尔伯特谱分析,得到信号的时-频域特征;接着,对构造的信号矩阵进行进一步的CSP分解,将时-频域特征扩展成时-频-空域特征;最后,通过支持向量机(SVM)对特征集进行分类。在BCI Competition II数据集的实验表明,与HHT时-频域和CSP空域特征的方法相比,所提方法的识别准确率分别提高了7.5、10.3和9.2个百分点,且标准差更小。在智能轮椅平台进行在线实验的结果表明,HCHT能有效提高识别准确率和稳定性。

关键词:脑电信号;运动想象;希尔伯特-黄变换;共同空间模式;智能轮椅

中图分类号:TP242.6 **文献标志码:**A

Motor imagery EEG feature extraction method based on multi-feature fusion

LUO Fei*, LIU Pengfei, LUO Yuan, ZHU Simeng

(School of Optoelectronic Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: To solve the problems of low recognition rate and poor adaptability of single feature, a feature extraction method named Hilbert-CSP-Huang Transform (HCHT) was proposed based on Hilbert-Huang Transform (HHT) and Common Spatial Pattern (CSP). Firstly, the Intrinsic Mode Function (IMF) was obtained by the Empirical Mode Decomposition (EMD) of original ElectroEncephaloGram (EEG) signals, and the IMF components were merged into a new signal matrix. Secondly, the time-frequency domain features were obtained by Hilbert spectrum analysis. Thirdly, the time-frequency domain features were extended into time-frequency-space features by further CSP decomposition of the constructed signal matrix. Finally, the feature set was classified by Support Vector Machine (SVM). Experiments on the BCI Competition II dataset show that compared with methods based on HHT time-frequency and CSP spatial domain features, the proposed method has the recognition accuracy increased by 7.5, 10.3 and 9.2 percentage points respectively with smaller standard deviation. The online experimental results on the intelligent wheelchair platform show that HCHT can effectively improve the recognition accuracy and robustness.

Key words: ElectroEncephaloGram (EEG); Motor Imagery (MI); Hilbert-Huang Transform (HHT); Common Spatial Pattern (CSP); intelligent wheelchair

0 引言

脑-机接口(Brain-Computer Interface, BCI)系统通过分析输入的电生理信号,将用户的意图解码成控制指令来操作输出设备^[1]。根据信号形式的不同,脑电信号主要分为脑电图(ElectroEncephalonGraph, EEG)、脑磁图(MagnetoEncephaloGram, MEG)、功能磁共振成像(Functional Magnetic Resonance Imaging, FMRI)等^[2]。其中,EEG由于其非侵入性和低成本的特点而广泛应用于BCI系统^[3]。

运动想象(Motor Imagery, MI)的原理是想象运动时会对大脑两侧的EEG信号产生事件相关去同步/同步现象^[4],已成为EEG信号领域的研究热点。其中,EEG信号因其微弱且具有非线性、非平稳及时变敏感等特点,时-频域分析和空间滤

波被广泛应用于其特征提取过程^[5]。时-频域分析主要有短时傅里叶变换(Short-term Fourier Transform, STFT)^[6]、小波变换(Wavelet Transform, WT)^[7]和小波包变换(Wavelet Package Transform, WPT)^[8],空间滤波主要为共同空间模式(Common Spatial Pattern, CSP)算法^[9]。

然而,基于STFT、WT、WPT的时-频域分析方法无法同时在时域和频域范围内取得较高的分辨率。希尔伯特-黄变换(Hilbert-Huang Transform, HHT)是一种适用于非线性非稳定信号的时-频域特征提取方法,该方法通过经验模态分解(Empirical Mode Decomposition, EMD)将信号自适应地分解成多个具有物理意义的固有模态函数(Intrinsic Mode Function, IMF),通过对各阶IMF作Hilbert变换,可以获得具

收稿日期:2019-07-03;修回日期:2019-09-01;录用日期:2019-09-02。

基金项目:重庆市技术创新与应用示范(产业类重点研发)项目(cstc2018jszx-cyzdX0112)。

作者简介:罗飞(1994—),男,四川成都人,硕士研究生,主要研究方向:脑机接口、模式识别; 刘鹏飞(1992—),男,河南周口人,硕士研究生,主要研究方向:模式识别、情感识别; 罗元(1972—),女,湖北宜昌人,教授,博士,主要研究方向:智能信号处理、模式识别、人工智能; 朱思蒙(1999—),男,重庆人,主要研究方向:脑机接口、人机交互。

有很高分辨率的时-频域特征^[10]。但随着大脑状态变化,脑电信号的时-频域特征会出现波动。因此,近年来相关研究者综合考虑多种特征方法进行特征提取。Chen等^[11]融合香农熵、小波熵和样本熵进行特征提取;杨默涵等^[12]基于总体经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)和近似熵提出一种多特征提取方法。以上方法都表现出很好的自适应性和较高的识别准确率,但考虑的都是单个角度特征的融合,不能从多个角度获取信号的更完整描述。因此,本文考虑一种综合时-频-空域特征的方法。

考虑到EMD可以将单个通道扩展成多个具有物理意义的窄带信号IMF,本文在HHT的基础上提出一种提取时-频-空域特征的方法HCHT(Hilbert-CSP-Huang Transform)。将EMD得到的各阶IMF进行Hilbert变换,获得具有很高分辨率的时-频域特征,并对各阶IMF作进一步的CSP分解,即将各阶IMF分量合并成新的信号矩阵,通过构造的IMF信号矩阵在不同类状态下的幅值差异构造空间滤波器,获取各阶IMF的空间分布特征,从而将HHT提取的时-频域特征扩展为时-频-空域特征。该方法实现了对脑电信号的多角度描述,且信号特征都是基于HHT算法,互为补充。在数据集上的实验结果表明,本文方法平均识别准确率更高,且标准差更小,鲁棒性更好。最后在智能轮椅平台上对该方法的有效性进行了进一步的验证。

1 实验数据

本文采用的数据集为BCI Competition II的Data set III数据集^[13]。实验样本记录来自一名25岁的健康女性。EEG信号从国际10-20导联系统的C3、C4和Cz通道获得,采样频率为128 Hz,滤波范围为0.5~30 Hz。单次信号采集过程如图1所示。




图1 单次信号采集过程

Fig. 1 Single signal acquisition process

整个实验分为7组,每组包括40个实验。单次实验持续9 s,实验要求受试者安静坐在显示器前,根据屏幕提示进行左手或右手运动想象(MI)任务。每次实验前2 s屏幕显示空白,提醒受试者放松; $t=2$ s时,显示器屏幕显示“+”字形,受试者准备MI; $t=3$ s时,显示器中央随机显示向左或向右的箭头,受试者根据箭头方向想象左手或右手运动,持续6 s; $t=9$ s时,单次采集结束,受试者短暂休息,准备下一次实验。

2 基于HCHT的特征提取方法

基于HCHT的特征提取方法如图2所示,具体过程分为四步:1)将预处理后的MI脑电信号经过EMD得到多个IMF;2)提取各阶IMF的Hilbert瞬时能量谱(Instantaneous Energy Spectrum, IES)和边际能量谱(Marginal Energy Spectrum, MES)分别作为脑电信号的时域特征和频域特征;3)将各阶IMF分量合并成新的信号矩阵,对各阶IMF进行进一步的CSP分解,获得表征空间信息的特征向量;4)归一化第2)步和第3)步提取到的信息,得到表征MI脑电信号的特征向量。

2.1 经验模态分解

经验模态分解其本质是通过信号的特征时间尺度判别内

蕴振荡模式,将信号自适应地分解成多个具有物理意义的固有模态函数IMF^[14]。

预处理后的输入信号经过EMD得到如下表达式:

$$X(t) = \sum_{i=1}^N C_i(t) + R_n(t) \quad (1)$$

其中: $X(t)$ 为输入信号, $C_i(t)$ 第*i*次筛选得到的IMF分量, N 为筛选次数, $R_n(t)$ 为最终的剩余分量。

对单次MI脑电信号进行经验模态分解,分解结果如图3所示。




图2 HCHT特征提取过程

Fig. 2 Feature extraction process of HCHT




图3 MI脑电信号EMD结果

Fig. 3 EMD results of EEG induced by MI

分解后的各阶IMF都是蕴含有MI脑电信息的窄带信号,每一个IMF分量都可以看作单个信号通道。本文对C3、C4通道的各阶IMF分量进行采样(采样频率为原始脑电信号的采样频率),并将两个通道的信号分量合并,构造一个 $N \times T$ 信号矩阵,其中 N 为IMF分量个数, T 为信号分量的采样点数,信号矩阵表示为:

$$X_j = (C3_{IMF1}, C3_{IMF2}, \dots, C3_{IMFn}, C4_{IMF1}, C4_{IMF2}, \dots, C4_{IMFn})^T \quad (2)$$

其中: n 为IMF个数, $j=L$ 或 R 。

2.2 Hilbert谱分析

MI脑电信号的特征信息主要集中在前三阶IMF,因此本文主要对前三阶IMF进行研究。对每个IMF分量进行Hilbert变换:

$$Y_i(t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{C_i(\tau)}{t - \tau} d\tau \quad (3)$$

则可求得解析信号:

$$Z_i(t) = C_i(t) + jY_i(t) = A_i(t)e^{j\varphi_i(t)} \quad (4)$$

其中: $A_i(t)$ 为瞬时幅值, $\varphi_i(t)$ 为瞬时相位。

由 $A_i(t)$ 和 $\varphi_i(t)$ 可进一步求取瞬时频率 $\omega_i(t)$, 即:

$$\omega_i(t) = \frac{d\varphi_i(t)}{dt} \quad (5)$$

则可描述信号幅度在时-频域的分布情况, 即 Hilbert 谱:

$$H(\omega, t) = \text{Re} \left\{ \sum_{i=1}^N A_i(t) e^{j\int \omega_i(t) dt} \right\} \quad (6)$$

其中, Re 为取实部。

根据式(6)可进一步求取 IES 和 MES:

$$\begin{cases} IES(t) = \int_{\omega_1}^{\omega_2} H^2(\omega, t) d\omega \\ MES(\omega) = \int_{t_1}^{t_2} H^2(\omega, t) dt \end{cases} \quad (7)$$

式中: $[\omega_1, \omega_2]$ 为信号的频率范围, $[t_1, t_2]$ 为信号的时间范围。

IES 和 MES 分别反映了信号在时域和频域上的能量特征。本文分别将 IES 和 MES 定义为 MI 脑电信号的时域特征 $F_1 \in \mathbb{R}^{m_1 \times 1}$ 和频域特征 $F_2 \in \mathbb{R}^{m_2 \times 1}$, 其中 m_1 和 m_2 分别表示时间点数和频率点数。

2.3 基于 CSP 的 IMF 特征提取

共同空间模式来源于共空域子空间分解 (Common Spatial Subspace Decomposition, CSSD), 是一种两分类任务下的空域滤波算法, 能够从多通道脑电信号数据里面提取出每一类的空间分布成分^[15], 主要分为两步: 构造空间滤波器和特征提取。

根据 2.1 节信号矩阵的构造方法, 将 C3、C4 通道前三阶 IMF 分量合并, 构造左右手 MI 的信号矩阵 X_L 和 X_R 。

步骤 1 构造空间滤波器。

求出左右手 MI 信号矩阵的均值空间协方差矩阵:

$$\bar{R}_c = \frac{1}{K} \sum_{i \in K} \frac{X_{c,i} X_{c,i}^T}{\text{trace}(X_{c,i} X_{c,i}^T)}; c = L, R \quad (8)$$

其中: $X_{c,i}$ 表示左右手 MI 的第 i 次实验, K 表示同一标签的信号矩阵的实验数量, $\text{trace}()$ 表示矩阵的迹。

求混合空间协方差矩阵 R , 并对其进行特征值分解:

$$R = \bar{R}_L + \bar{R}_R = U \Lambda U^T \quad (9)$$

其中: $\bar{R}_L$ 和 $\bar{R}_R$ 分别表示左手和右手的均值空间协方差, U 是 R 的特征向量, Λ 是对应的特征值矩阵。

进一步可求取白化矩阵:

$$P = \sqrt{\Lambda^{-1}} U^T \quad (10)$$

利用求取的白化矩阵 P 对 $\bar{R}_L$ 和 $\bar{R}_R$ 进行白化处理:

$$\begin{cases} S_L = P \bar{R}_L P^T \\ S_R = P \bar{R}_R P^T \end{cases} \quad (11)$$

对白化后的矩阵进行特征值分解:

$$\begin{cases} S_L = U_s \Lambda_s U_s^T \\ S_R = U_s \Lambda_s U_s^T \end{cases} \quad (12)$$

其中: U_s 是 S_L 和 S_R 的特征向量, Λ_s 和 Λ_s 分别是对应的特征值矩阵。可以证明 S_L 和 S_R 具有相同的特征矩阵 U_s , 且 Λ_s 与 Λ_s 之和为单位矩阵。因此, 当 S_L 的特征值最大时, S_R 的特征值最小, 可最大限度地地区分两类信号。则可构造出空间滤波器:

$$W = U_s^T P \quad (13)$$

步骤 2 特征提取。

对构造的信号矩阵 X_j 进行进一步的共同空间模式分解,

经空间滤波器 W 投影得到特征矩阵 Z , 如式(14)所示:

$$Z = W X_j \quad (14)$$

将特征矩阵 Z 的前 m 行和后 m 行作为信号矩阵的特征, 求取特征向量:

$$v_j = \log \left(\frac{\text{VAR}(Z_j)}{\sum_{n=1}^{2m} \text{VAR}(Z_j)} \right) \quad (15)$$

v_j 表征了两类 MI 脑电信号特征, 本文由式(10)将其表示为空域特征 $F_3 \in \mathbb{R}^{2m \times 1}$:

$$F_3 = [v_1, v_2, \dots, v_{2m}]^T \quad (16)$$

2.4 运动想象脑电特征向量构造

本文的 MI 脑电信号由上述三种特征进行描述, 将求取的 IES 和 MES 以及 CSP 方差向量整合并构造输入特征向量 $F' = \{F'_1, F'_2, F'_3\}$ 。由于不同的特征具有不同的含义, 因此有必要通过以下对输入特征向量进行归一化:

$$F'_k = (F_k - \mu_k) / \sigma_k; k = 1, 2, 3 \quad (17)$$

其中: μ_k 是第 k 个特征的平均值组成的向量, σ_k 是第 k 个特征的标准差。

最后, 将归一化的输入特征 $F = \{F'_1, F'_2, F'_3\}$ 通过支持向量机 (Support Vector Machine, SVM) 分类。SVM 的原理是使分离超平面之间的距离最大, 并选择最佳超平面作为决策边界^[16]。由于 SVM 具有出色的分类性能, 因此已广泛应用于脑电信号处理。

3 线下实验

3.1 多特征和单一特征的对比

为了验证本文方法的有效性, 将数据集随机分成 10 个子集, 每个子集包含来自各个分类的相同比例的样本。依次选取其中 1 个子集用于测试, 其余 9 个子集用于训练, 重复 10 次, 并取 10 次实验的平均准确率。为公平比较, 使用 10 折交叉验证法找到每个过程中 SVM 的最佳惩罚系数 C 和核函数参数 σ , 并采用 10 次实验的平均准确率和标准差来测量性能。单次实验准确率如图 4 所示, 平均分类准确率和标准差如表 1 所示。

表 1 平均准确率

Tab. 1 Average accuracy

特征向量	平均准确率/%	标准差	特征向量	平均准确率/%	标准差
F_1	80.5	7.7	F_3	78.8	8.1
F_2	77.7	6.3	F	88.0	5.8




图 4 单次实验准确率对比

Fig. 4 Comparison of single test accuracy

从表 1 可以看出, 当使用本文的融合特征 F 时, 可以获得 88.0% 的平均准确率, 与单一的时-频域特征和空域特征相比, 分别提高了 7.5、10.3 和 9.2 个百分点。这是因为与单一特征相比, 融合的特征实现了信号不同特征之间的互补, 可以获得更全面的信号表达, 进而可以获得更好的识别效果。并且, 本文特征提取方法的标准差均小于其他的三种方法, 说明本文提出的方法具有更强的稳健性。

3.2 多种识别方法结果比较

表 2 还给出了文献[11-12]两种多特征提取方法的识别结果。可以看出,当通道数相同时,本文方法的识别率分别比文献[11-12]的方法分别高 2.3 和 4.7 个百分点。这是因为本文方法综合考虑了脑电信号的时-频-空域信息进行特征提取,从而可以获得信号特征的更完整表达,有效提高了 MI 任务的识别能力。从耗时来看,本文方法的平均耗时比第一名多 0.5 s,整体差异不大,但识别率提高了 4.7 个百分点。

同时,为了体现对比方法的多样性,本文还在 BCI Competition III 的 Data set I 数据集进行了实验。表 2 还给出了

脑机接口竞赛“BCI Competition III Data Set I”前三名识别方法的结果(按名次由高到低分别为文献[17]、文献[18]和文献[19]的方法)。本文方法取得的识别率为 87.3%,分别比第二名和第三名高 0.3 和 1.3 个百分点,比第一名低 3.7 个百分点。然而,本文提出的特征提取方法仅提取两个通道的信号进行分析,在保证分类准确率的情况下,大大减少了通道数。从测试集的平均分类耗时对比可以看出,随着通道数的减少,计算数据量大大减少,因此,本文方法的平均耗时远少于以上三种方法,为便携式 BCI 系统的在线采集和识别提供了可行性。因此,综合来看,本文方法均优于以上提及的方法。

表 2 多种识别方法结果比较
Tab. 2 Result comparison of multiple recognition methods

数据集	特征提取方法	分类方法	通道数	耗时/s	识别率/%
Data set III (Competition II)	香农熵+小波熵+样本熵 ^[11]	SVM	2	16.4	85.7
	EEMD+近似熵 ^[12]	线性判别分析	2	12.6	83.3
	本文方法 HCHT	SVM	2	13.1	88.0
Data set I (Competition III)	CSSD+均值+Fisher 判别分析 ^[17]	SVM	64	28.6	91.0
	自回归模型+功率谱+小波系数 ^[18]	正则化逻辑回归	33	25.8	87.0
	均值+功率谱 ^[19]	逻辑回归	不确定	22.4	86.0
	本文方法 HCHT	SVM	2	12.9	87.3

4 线上实验

本文在智能轮椅平台上采用基于 HCHT 的人机交互系统进行了在线实验。令 6 位受试者通过想象左手或右手运动来控制轮椅运动。采用 Emotive 传感器作为脑电信号采集设备,16 个电极的安放位置如图 5 所示。将采样电极中的 FC5 和 FC6 电极作为输入电极,CMS 和 DRL 作为参考电极。在轮椅的方向控制中,脑电信号首先经过 0.1~30 Hz 的带通滤波,然后通过 HCHT 算法对信号特征进行提取,对提取到的特征通过 SVM 算法进行分类识别,并转化为控制指令控制轮椅转向。

椅平台上对 6 位受试者进行重复测试,完成如图 6 所示的“8”字形路线。实验场地两侧各设置一个障碍物,受试者端坐在轮椅上以 0.15 m/s 的前进速度,从起点出发,通过想象左手或右手运动来控制轮椅转向,绕过两侧的障碍物,得到如图 7 所示的运动轨迹曲线。从图 7(a)和(b)可以看出,基于 HHT 和 CSP 的 BCI 系统与图 7(c)的 HCHT 相比,其运动轨迹曲线较为混乱,不平滑,且波动较大。这是因为 HCHT 是一种多特征融合的方法,可以获得 MI 脑电信号特征的更完整表达,能够提取出更为准确的脑电信号特征,从而获得更高的分类准确率,实现对智能轮椅更精确的控制,受试者能更安全平滑地完成指定路线。除此之外,还可以看出“8”字形的右边较为混乱,这是由于受试者长时间处于 MI 状态会出现疲劳状态,使得信号的特征值发生变化,识别准确率出现略微下降。




图 5 电极安放位置
Fig. 5 Electrode placement positions






图 6 实验路径
Fig. 6 Experimental path


采用基于 HHT、CSP 和 HCHT 的人机交互系统,在智能轮



(a) 基于HHT的BCI系统



(b) 基于CSP的BCI系统



(c) 基于HCHT的BCI系统

图 7 基于三种方法的轮椅运动轨迹曲线

Fig. 7 Wheelchair trajectory curves based on three methods

图 8 为 6 位受试者分别在 HHT、CSP 和 HCHT 三种方案下控制轮椅完成“8”字形路径的耗时对比。可以看出,基于

HCHT 的控制方案耗时略微多于 HHT 和 CSP,这是因为 HCHT 算法是一种多特征提取算法,同时提取 IES、Hilbert 边际能量

谱以及 CSP 方差向量,从多个角度实现了对 MI 脑电信号特征的综合描述,因此耗时增加。三种方法的耗时主要集中在 EMD 过程,提取 IES、Hilbert 边际能量谱以及 CSP 方差向量的耗时占比并不大。因此,从图中可以看出,虽然 HCHT 耗时比 HHT 和 CSP 略多,但三者的耗时差异不大,并不影响整体系统响应,且 HCHT 算法具有更高的识别率和稳定性,更适用于实际应用环境。




图8 采用 HHT、CSP 以及 HCHT 控制轮椅运动的耗时对比

Fig. 8 Time-consuming comparison of using HHT, CSP and HCHT to control wheelchair movement

5 结语

本文基于 HHT 和 CSP 提出的 MI 脑电信号特征提取方法 HCHT,综合考虑了脑电的时间-频率-空间信息进行特征提取。即首先经过 EMD 得到各阶 IMF,接着对各阶 IMF 进行 Hilbert 变换,提取 IES 和 MES 分别作为时域特征和频域特征,并将多个 IMF 合并成新的信号矩阵,利用 CSP 进行进一步的空间滤波,获取其空间特征。最后,使用特征向量来训练 SVM 分类器,并对 MI 脑电信号模式进行分类。在竞赛数据集上得到的实验结果表明,相比单一的时频特征和空间特征,本文提出的 HCHT 特征提取方法平均准确率更高,标准差更小,鲁棒性更好。最后利用智能轮椅平台对算法进行验证,进一步验证了算法的有效性。本文方法实现了对两通道左右手 MI 脑电信号的有效识别,为便携式 BCI 技术提供了一种新的思路,但识别率和识别种类有待进一步的优化。

参考文献 (References)

- [1] WOLPAW J R, BIRBAUMER N. Textbook of neural repair and rehabilitation; brain-computer interfaces for communication and control[J]. *Nature Reviews Neurology*, 2017, 12(9): 513-524.
- [2] 王行愚,金晶,张宇,等. 脑控:基于脑-机接口的人机融合控制[J]. *自动化学报*, 2013, 39(3): 208-221. (WANG X Y, JIN J, ZHANG Y, et al. Brain control: human-computer integration control based on brain-computer interface approach[J]. *Acta Automatica Sinica*, 2013, 39(3): 208-221.)
- [3] KIM M, KIM B H, JO S. Quantitative evaluation of a low-cost non-invasive hybrid interface based on EEG and eye movement [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2015, 23(2): 159-168.
- [4] DJEMAL R, BAZYED A G, BELWAFI K, et al. Three-class EEG-based motor imagery classification using phase-space reconstruction technique[J]. *Brain Sciences*, 2016, 6(3): No. 36.
- [5] BIJU K S, JIBUKUMAR M G. Ictal EEG classification based on state space modeling of intrinsic mode functions[J]. *Procedia Computer Science*, 2018, 125: 468-475.
- [6] YÜCELBAŞ C, YÜCELBAŞ S, ÖZŞEN S, et al. Automatic detection of sleep spindles with the use of STFT, EMD and DWT methods [J]. *Neural Computing and Applications*, 2016, 29(8): 17-33.
- [7] TARAN S, BAJAJ V. Motor imagery tasks-based EEG signals classification using tunable-Q wavelet transform[J]. *Neural Computing and Applications*, 2018, 31(11): 6925-6932.
- [8] 蔡森,胡萍. 基于小波包变换的右手和脚运动想象任务分类[J]. *中国医疗器械杂志*, 2017, 41(3): 177-180. (CAI M, HU P. Task

classification of right-hand and foot motion imagery based on wavelet packet transform [J]. *Chinese Journal of Medical Instrumentation*, 2017, 41(3): 177-180.)

- [9] XYGONAKIS I, ATHANASIOU A, PANDRIA N, et al. Decoding motor imagery through common spatial pattern filters at the EEG source space [J]. *Computational Intelligence and Neuroscience*, 2018, 2018: No. 7957408.
- [10] 孙会文,伏云发,熊馨,等. 基于 HHT 运动想象脑电模式识别研究[J]. *自动化学报*, 2015, 41(9): 1686-1692. (SUN H W, FU Y F, XIONG X, et al. Identification of EEG induced by motor imagery based on Hilbert-Huang transform [J]. *Acta Automatica Sinica*, 2015, 41(9): 1686-1692.)
- [11] CHEN S, LUO Z, GAN H. An entropy fusion method for feature extraction of EEG [J]. *Neural Computing and Applications*, 2018, 29(10): 857-863.
- [12] 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. (YANG M H, CHEN W Z, LI M Y. Multiple feature extraction based on ensemble empirical mode decomposition for motor imagery EEG recognition tasks [J]. *Acta Automatica Sinica*, 2017, 43(5): 743-752.)
- [13] PFURTSCHER G, SCHLÖGL A. Data set III: BCI-experiment [EB/OL]. [2019-04-08]. <http://www.bbci.de/competition/iii/>.
- [14] 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 M A, CUI Y, YANG J F, et al. An adaptive multi-domain fusion feature extraction with method HHT and CSSD [J]. *Acta Electronica Sinica*, 2013, 41(12): 2479-2486.)
- [15] 张学军,黄婉露,黄丽亚,等. 公共空间模式算法结合经验模式分解的 EEG 特征提取[J]. *计算机工程与应用*, 2017, 53(13): 9-15, 54. (ZHANG X J, HUANG W L, HUANG L Y, et al. EEG signals feature extraction combined with empirical mode decomposition and common spatial pattern [J]. *Computer Engineering and Applications*, 2017, 53(13): 9-15, 54.)
- [16] QUITADAMO L R, CAVRINI F, SBERNINI L, et al. Support vector machines to detect physiological patterns for EEG and EMG-based human-computer interaction: a review[J]. *Journal of Neural Engineering*, 2017, 14(1): No. 011001.
- [17] 魏庆国. 基于运动想象的脑-机接口分类算法的研究[D]. 北京:清华大学, 2006: 11-16. (WEI Q G. Studies on classification algorithms of motor imagery-based brain-computer interfaces [D]. Beijing: Tsinghua University, 2006: 11-16.)
- [18] HAMMON P S, DE SA V R. Preprocessing and meta-classification for brain-computer interfaces [J]. *IEEE Transactions on Biomedical Engineering*, 2007, 54(3): 518-525.
- [19] BLANKERTZ B. BCI competition III — Final results [EB/OL]. [2019-04-08]. <http://www.bbci.de/competition/iii/results>.

This work is partially supported by the Chongqing Technology Innovation and Application Demonstration (Key Research in Industry) Project (cstc2018jszx-cyzdX0112).

LUO Fei, born in 1994, M. S. candidate. His research interests include brain-computer interface, pattern recognition.

LIU Pengfei, born in 1992, M. S. candidate. His research interests include pattern recognition, emotion recognition.

LUO Yuan, born in 1972, Ph. D., professor. Her research interests include intelligent signal processing, pattern recognition, artificial intelligence.

ZHU Simeng, born in 1999. His research interests include brain-computer interface, human-computer interaction.