

# 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

杨默涵<sup>1</sup> 陈万忠<sup>1</sup> 李明阳<sup>1</sup>

**摘要** 人的脑电信号 (Electroencephalogram, EEG) 复杂且具有非线性及非平稳性的特点使其不易分析处理, 其识别效果也依赖于数据集的不同, 而表现不稳定. 本文中应用的总体经验模态分解 (Ensemble empirical mode decomposition, EEMD) 是一种具有强自适应性的信号处理方法, 其在时频域展现的良好分辨率特别适合脑电识别任务处理. 本文提出利用 EEMD 分解后得到的较具影响能力的固有模态函数 (Intrinsic mode functions, IMFs), 利用希尔伯特变换提取边际谱 (Marginal spectrum, MS) 及瞬时能谱 (Instantaneous energy spectrum, IES) 时频特征, 同时通过加窗的方法提取非线性动力学特征近似熵特征, 利用线性判别分类器 (Linear discriminant analysis, LDA) 作为分类器, 实验结果得出, 对于被试 S2 和被试 S3 可达到识别率分别为 79.60% 和 87.77%, 实验中 9 名被试的平均识别率为 82.74%, 得到平均识别率也高于近期使用相同数据集文献的其他方法.

**关键词** 脑电信号, 运动想象, 总体经验模态分解, 线性判别分类器

**引用格式** 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. 自动化学报, 2017, 43(5): 743–752

**DOI** 10.16383/j.aas.2017.c160175

## Multiple Feature Extraction Based on Ensemble Empirical Mode Decomposition for Motor Imagery EEG Recognition Tasks

YANG Mo-Han<sup>1</sup> CHEN Wan-Zhong<sup>1</sup> LI Ming-Yang<sup>1</sup>

**Abstract** EEG signals are complicated as well as nonlinear and non-stationary, which make them hard to analyze. Recognition result is dependent on the datasets selected, and is not stable. The ensemble empirical mode decomposition (EEMD) as a kind of adaptive signal processing method is used for motor imagery recognition tasks because of its good decomposition resolution. An efficient EEMD-based feature extraction scheme is presented, which combines the Hilbert marginal spectrum (MS) and instantaneous energy spectrum (IES) features with window-added EEMD-based approximate entropy (ApEn) features. The impactful factors of IMFs and frequency bands are selected for the features as well. A linear discriminant analysis (LDA) classifier is designed for classification. The method is tested on nine subjects. The result shows that the proposed feature combination is competitive in recognition rate with other methods on the same dataset. The maximal classification accuracy for S2 and S3 can reach 79.60% and 87.77%, respectively. The mean accuracy of nine subjects is 82.74%. The average recognition rate obtained is superior to other methods on the same datasets.

**Key words** Electroencephalogram (EEG), motor image, ensemble empirical mode decomposition (EEMD), linear discriminant analysis (LDA)

**Citation** Yang Mo-Han, Chen Wan-Zhong, Li Ming-Yang. Multiple feature extraction based on ensemble empirical mode decomposition for motor imagery EEG recognition tasks. *Acta Automatica Sinica*, 2017, 43(5): 743–752

### 脑-机接口 (Brain-computer interface, BCI)

收稿日期 2016-03-03 录用日期 2016-10-05  
Manuscript received March 3, 2016; accepted October 5, 2016  
吉林省科技发展计划自然科学基金 (20150101191JC), 吉林大学研究生创新基金 (2016092) 资助  
Supported by Natural Science Foundation for Science and Technology Development Plan of Jilin Province (20150101191JC), and Graduate Innovation Fund of Jilin University (2016092)  
本文责任编辑 朱朝喆  
Recommended by Associate Editor ZHU Chao-Zhe  
1. 吉林大学通信工程学院分布式智能信息处理实验室 长春 130025  
1. Distributed Intelligent Information Processing Laboratory, College of Communication Engineering, Jilin University, Changchun 130025

旨在建立一种人脑和电脑或外部设备的直接通路, 通过这种方式人可以把命令和控制指令直接发送给外部设备而不需要任何身体上的动作<sup>[1–2]</sup>. 而随着 BCI 技术的发展, 这种人与外界交互的新方法, 在康复工程与智能辅助机器人上的应用也引起了人们的重视<sup>[3–4]</sup>, 同时几种主要并且有效的脑电活动也被人们所发现和利用, 其中包括: 感觉运动节律 (Sensorimotor rhythms, SMR)<sup>[5–6]</sup>、皮层慢电位 (Slow cortical potential, SCP)<sup>[7]</sup>、P300 事件相关电位<sup>[8–9]</sup> 以及稳态视觉诱发电位 (Steady-state

visual evoked potential, SSVEP)<sup>[10-11]</sup>. 其中一种最为重要的 BCI 系统便是以运动想象为基础的. 人通过想象运动的方式来触发感觉运动节律变化, 系统监测大脑相应电极电位的变化情况来确认相应的运动模式并发出控制指令. 目前, 这种交互策略被广泛地应用于实际 BCI 系统之中<sup>[12-13]</sup>.

运动想象是可以被人主动控制的一种意念活动, 人的想象运动或者人做出实际身体动作都会产生相关的运动想象信号. 随想象或动作产生的事件相关去同步现象 (Event-related desynchronization, ERD) 和事件相关同步 (Event-related synchronization, ERS) 现象将诱发大脑皮层电位变化<sup>[14]</sup>. 当想象左手或者右手运动时, 8~13 Hz 的 Mu 节律和 13~30 Hz 的 Beta 节律的 ERD 现象表现显著, 并出现在人大脑皮层的对侧感觉运动区<sup>[15]</sup>, 这种变化是运动想象类 BCI 系统的重要特征和依据.

近几年, 国内外研究者也提出了若干基于运动想象模式识别特征的提取方法, 其中包括时域、频域、时频域、空间滤波等多类特征提取方法. 时域特征以幅值特征和幅值能量特征为主<sup>[16]</sup>; 频域特征主要包括以快速傅里叶变换 (Fast Fourier transform, FFT) 为基础的功率谱 (Power spectral density, PSD) 特征、自回归模型系数 (Auto regressive, AR)<sup>[17-18]</sup> 及自适应自回归模型系数 (Adaptive auto regressive, AAR) 特征<sup>[19]</sup>; 时频域分析方法主要有短时傅里叶变换 (Short-term Fourier transform, STFT)、基于小波变换 (Wavelet transform, WT) 和小波包变换 (Wavelet package transform, WPT) 的能量特征<sup>[20]</sup>、希尔伯特-黄变换 (Hilbert-Huang transform, HHT) 等<sup>[18]</sup>; 空间滤波在 BCI 特征提取中较为成功的有共空间模式 (Common spatial pattern, CSP)<sup>[21]</sup>、独立分量分析 (Independent component analysis, ICA) 等方法, 其多应用于在多电极分布的 BCI 实验中, 并取得很好效果<sup>[22]</sup>, 如基于 ICA 的眼电伪迹去除方法等<sup>[19, 23]</sup>. 除此之外, 还有近期研究者提出的前沿方法: He 等提出应用朴素贝叶斯网络对多类脑电信号进行分类任务取得了很高的识别率<sup>[24]</sup>, Yuksel 等提出的利用人工神经网络的优化空间滤波器的方法<sup>[25]</sup> 等. 然而人的脑电信号的非线性非平稳等特点使其难以有一个既定的处理方法, 分类识别效果也依赖于数据集的不同, 而表现不稳定.

总体经验模态分解 (Ensemble empirical mode decomposition, EEMD)<sup>[26]</sup> 改善了经验模态分解 (Empirical mode decomposition, EMD)<sup>[27]</sup> 存在的模态混叠问题, 依据信号自身的波动特点将信号分解, 特别适合非线性非平稳信号的分析处理, 相比

于小波和小波包分解方法, EEMD 能在时频域提供更好的分辨率, 保证了更为准确时频特征. 本文提出利用 EEMD 分解对滤波后信号进行分解, 选择得到的具有较强影响能力的固有模态函数作为对象, 提取其近似熵 (Approximate entropy, ApEn) 特征, 并结合希尔伯特边际谱 (Marginal spectrum, MS) 及希尔伯特瞬时能谱 (Instantaneous energy spectrum, IES) 特征提取方法, 选取较优频带波幅特征作为特征, 以线性判别分类器 (Linear discriminant analysis, LDA) 作为分类器, 在对 9 名被试的实验中取得可观的分类效果. 最后的实验结果与使用相同数据集的其他文献得到结果进行比较, 也较有优势, 可为将来 BCI 系统研究和开发提供方法并奠定基础.

## 1 数据和方 法

### 1.1 被试、实验范式和数据采集

为验证本文提出方法的有效性和普适性, 实验中采用来自三组数据集的 9 名不同被试 (S1~S9) 运动想象实验数据. 第一组数据集包含被试 S1 来自第二次国际 BCI 大赛 Dataset III, 包含 280 次试次; 第二组包含被试 S2~S4 来自第三次国际 BCI 大赛 Dataset IIIb 数据集, S2、S4 各包含 1080 次试次, S3 包含 400 次试次; 第三组包含 S5~S9 来自第四次国际 BCI 大赛 Dataset 2b 数据集, 每个被试各包含 720 次试次.

这里我们主要对第二组数据集进行展开介绍. 被试需通过想象左手或者右手运动在线控制屏幕中的物体运动来完成单次实验, C3 和 C4 通道的数据以双导联方式被记录下来, 脑电信号采样频率为 125 Hz, 经过 0.5~30 Hz 带通滤波处理, 并且应用了陷波滤波去掉 50 Hz 工频噪声. 单次实验持续时间为 8 s, 在  $t = 0 \sim 2$  s 屏幕保持黑屏, 开始信号从  $t = 2$  s 以后开始, 被试 S3 根据 3 s 后出现的箭头提示完成左或右的想象, 被试 S2 和 S4 通过想象左或右控制  $t = 3$  s 时屏幕上方出现不断下落的小球落向规定屏幕的左侧或者右侧的 Basket 即目标物体. 真实的反馈时间取  $t = 4 \sim 7$  s 时间段内数据作为离线分析. 实验数据详见文献 [28-30].

### 1.2 数据预处理

为了提高信号的信噪比, 我们先对各数据集信号进行了简单预处理工作. 首先去除了数据为“NaN”的空白数据点并置为 0, 并对第三组数据集进行了重采样 (从 250 Hz 到 125 Hz) 来降低处理信号的复杂度. 由于运动想象所诱发的 ERD 现象主要体现在 Mu 节律与 Beta 节律<sup>[31]</sup>, 故采用 8~30 Hz 六阶巴特沃兹带通滤波器, 设置阻带截止频率分别

为 5 Hz 和 33 Hz, 阻带衰减为 50 dB, 通带衰减为 0.5 dB, 对各数据集信号进行了统一的滤波处理, 以消除低频信号带来的干扰.

### 1.3 EEMD 方法

经验模态分解是由 Wu 等<sup>[26]</sup>提出的一种自适应信号分析方法, EMD 方法不同于小波和小波包变换, 无需设定基函数, 根据数据自身特点, 规定固有时间尺度特征从而对信号进行自适应分解. 这种方法在信号分析领域中具有广泛的应用. 但 EMD 分解算法存在模态混叠及端点效应等不足, 在对信号分析过程中容易产生虚假成分, 导致最终识别率上的降低. 总体经验模态分解方法<sup>[32]</sup>针对了 EMD 的不足, 而提出的一种噪声辅助数据分析方法, 通过加入高斯白噪声使信号在不同时间尺度上具有连续性, 再经多次累加加噪分解得到的结果, 进一步求取平均值来消除噪声的影响并作为最终结果, 从而有效地消除了 EMD 过程带来模态混叠的问题, 其实现方法如下:

1) 在待处理信号整个时间域上添加白噪声, 定义参数  $k$  为添加的白噪声信号与待处理信号的标准差的比值;

2) 用 EMD 方法分解添加噪声后的信号得到固有模态函数 (Intrinsic mode function, IMF) 及余项;

3) 重复上述两个步骤  $N$  次, 对待处理信号添加具有相同标准差值比值  $k$  的白噪声序列, 得到  $N \times \text{IMF}_i$  及  $N$  个余项 ( $\text{IMF}_i, i$  表示分解得到的层数).

4) 累加  $N$  次加噪后 EMD 过程得到的  $\text{IMF}_i$  并求取平均值, 最终得到  $n$  层 IMF 分量和余项即为最终分解结果.

由于白噪声均值为 0 的特性, 通过足够次数累加求平均过程, 白噪声带来的影响就会消除, 得到的 IMF 均来源于原始信号, 每一层 IMF 可以看作其自身的滤波器<sup>[33]</sup>, 分解得到的第一层信号具有较高频率, 而后几层是信号频率递减. 实验中, 我们先对整个数据段按试次进行分割, 而后对于每个试次的数据分别做了 EEMD 分解. 在多个被试的实验中, 我们发现运动想象相关的 Beta 节律主要分布于  $\text{IMF}_1$ 、 $\text{IMF}_2$  分量, Mu 节律主要分布于  $\text{IMF}_2$  及  $\text{IMF}_3$  分量中, 但这里并不是说每层 IMF 只包含特定脑电节律或是一种脑电节律只存在一个或几个固定的 IMF 中, 而是从频率分布和能量角度说明了前三阶分量中包含了运动想象相关 EEG 的大多数信息, 通过对特定 IMF 分量分析来识别此类脑电信号方法是可行的, 后续的特征提取过程也是围绕这几层分量来进行的.

### 1.4 基于希尔伯特变换的时频特征提取

对 IMF 信号进行希尔伯特变换是提取信号时频能量特征的有效方法, 假设第  $i$  层的 IMF 分量为 ( $i = 1, 2, \dots, n$ ), 对 IMF 分量信号进行变换得到下面等式:

$$y_i(t) = \frac{1}{\pi} \text{PV} \int_{-\infty}^{\infty} \frac{c_i(\tau)}{t - \tau} d\tau \quad (1)$$

其中, PV 是柯西主值, 则进一步得到  $z_i(t)$  的解析式为

$$z_i(t) = c_i(t) + jy_i(t) = a_i(t)e^{j\theta_i(t)} \quad (2)$$

其中,  $a_i(t)$  代表瞬时幅值,  $\theta_i(t)$  代表瞬时相位, 希尔伯特变换的瞬时频率定义为

$$\omega_i(t) = \frac{d\theta_i(t)}{dt} \quad (3)$$

综上, 原始信号可以表示成变换后的 IMF 的和值形式为

$$x(t) = \text{Re} \left\{ \sum_{i=1}^n a_i(t)e^{j\theta_i(t)} \right\} = \text{Re} \left\{ \sum_{i=1}^n a_i(t)e^{j \int \omega_i(t) dt} \right\} \quad (4)$$

其希尔伯特谱定义为

$$H(\omega, t) = \text{Re} \left\{ \sum_{i=1}^n a_i(t)e^{j \int \omega_i(t) dt} \right\} \quad (5)$$

希尔伯特谱表达式涵盖了时域和频域上幅值分布情况. 本文中利用的两个重要的概念是希尔伯特边际谱和希尔伯特瞬时能量谱, 边际谱表示不同频带上幅值分布, 瞬时能谱表示时域上能量的分布, 希尔伯特其边际谱 (MS) 和瞬时能量谱 (IES) 的定义为如下形式:

$$\text{MS}(\omega) = \int_0^T H(\omega, t) dt \quad (6)$$

$$\text{IES}(t) = \int_{\omega_1}^{\omega_2} H^2(\omega, t) d\omega \quad (7)$$

实验中我们发现, 不同被试对象对于边际谱特征和瞬时能量特征敏感度存在差异, 其各层边际谱上的优选频带也不相同, 为了不遗漏边际谱上的特征频带, 并避免人为参与选择, 对前三层 IMF 采用分多子频段的幅值分析方法. 其具体做法是: 对得到的边际谱以 2 Hz 为单位长度分割 8~30 Hz 频带为 11 个子频带, 求取每个子频带内数据点的平均幅值作为该子频带的频谱特征. 对于时域能量特征, 则

计算时间段内瞬时能量的均值及方差作为特征. 则得到一层 IMF 的时频特征向量  $F_1$  可表示为

$$F_1 = \{C3_{\text{IES}}, C3_{\text{std(IES)}}, C3_{\text{MSTI}}, \dots, C3_{\text{MSTII}}, C4_{\text{IES}}, C4_{\text{std(IES)}}, C4_{\text{MSTI}}, \dots, C4_{\text{MSTII}}\} \quad (8)$$

### 1.5 EEMD-ApEn 的特征提取

实验中我们还考虑了 EEMD 方法与非线性动力学特征的结合和其带来优化作用, 近似熵 (ApEn) 是较为常用的非线性动力学特征. 近似熵最初由 Pincus 提出<sup>[34]</sup>, 并广泛应用于生物信号处理并取得良好效果, 例如癫痫识别<sup>[35]</sup> 以及心率信号监测<sup>[36]</sup> 等. 近似熵描述了信号复杂性和规律性, 它能够度量时间序列的不规则性, 假设长度为  $N$  的时间序列为  $x(i)$ ,  $X(i)$  为  $x(i)$  的  $m$  维重构向量其表达式为  $X(i) = \{x(i), x(i+1), \dots, x(i+m-1)\}$  (其中  $1 \leq i \leq N-m+1$ ), 计算  $X(i)$  与其余矢量的  $X(j)$  (其中  $j = 1, 2, \dots, N-m+1, j \neq i$ ) 间距离为  $d$ , 其中满足不大于相似容限  $r$  的点数计为  $N^m(i)$ , 则近似熵定义为

$$\text{ApEn}(m, r, N) = \Phi^m(r) - \Phi^{m+1}(r) \quad (9)$$

$$\Phi^m(r) = (N-m+1)^{-1} \sum_{i=1}^{N-m+1} \ln C_i^m(r) \quad (10)$$

其中,  $C_i^m(r) = N^m(i)/(N-m+1)$ , 本文中取  $m = 2$ ,  $r$  为原始序列标准差的 0.2 倍. 近似熵以统计学的角度定义时间序列的复杂程度, 较大的熵值表示较高的复杂度; 反之, 较小的熵值则代表序列更具规律性.

在本文中, 我们利用 EEMD 过程将复杂信号进行分解, 利用分解得到的 IMF 作为计算近似熵特征的选择. 我们的想法是, 利用分解得到的较低复杂度并包含一定有效信息的信号求解近似熵, 该熵值对不同任务中复杂度上带来的变化也更加敏感, 并能体现出更高的可信度和准确性. 在实验中, 我们还提出应用滑动窗提取所选序列的近似熵特征, 这里我们选择 2s 时长的 IMF 时间序列为例, 其步骤如下:

1) 对所选 IMF 时间序列, 选择长度为 1s 滑动窗 (包含 125 个数据点) 从  $t = 0$  时刻开始滑动取点, 窗口每次滑动距离为 0.2s, 对于长度为 2s 的数据, C3 和 C4 双通道共可截取 12 个数据段.

2) 分别计算 12 个数据段的近似熵值, 组成熵的特征向量.

综上, 其熵特征向量  $F_2$  可表示为

$$F_2 = \{C3_{\text{ApEn1}}, \dots, C3_{\text{ApEn6}}, C4_{\text{ApEn1}}, \dots, C4_{\text{ApEn6}}\} \quad (11)$$

### 1.6 单因素方差检验与特征选择

在经过上述的各类特征提取过程后, 获得的多维特征不一定都能很好地展现两类间的差异, 其中会存在能带来干扰特征或冗余成分, 如人脑不对称性带来的在单侧电极上能量变化的不显著, 以及各层 IMF 上无效的频带区间等, 这些都可能导致最后识别率的降低. 为了筛选出我们感兴趣的显著特征, 并尽可能降低特征复杂度, 我们采用了单因素方差检验 (One-way analysis of variance, ANOVA) 对取自不同层级 IMFs 最优时段的时频及熵特征进行显著度评估, 并取其中  $p < 0.001$  成分作为最终的显著性特征并进行分类.

### 1.7 线性判别分类器

线性判别分类器是 BCI 系统应用领域中较为成功的分类方法之一<sup>[37-38]</sup>, 其主要思想是通过最大化不同类间均值并最小化类内方差来获得超平面, 使投影在超平面的两类极大程度的区分开, 达到分类目的. 相比较支持向量机 (Support vector machine, SVM) 和神经网络类分类器, LDA 不需要任何参数设置又不依赖于好的隐含层节点选择等问题, 并且在脑电信号分类识别任务展现了良好的性能. 故这里我们选用了 LDA 分类器来验证提出的方案是否有效.

## 2 实验结果

实验环境为 Windows32 位系统, 4GB 内存, CPU 主频为 1.80GHz, 仿真软件为 Matlab R2014a. 为得到更加可靠和稳定的结果, 采用了五折交叉检验方法, 并进行 50 次随机交叉检验实验取平均识别率来作为最后的识别结果.

### 2.1 特征组合及对比

为了方便, 这里我们命名时频方法提取特征为  $F_1$ , EEMD-ApEn 的方法提取的特征为  $F_2$ . 为了验证两种特征选择方法是否都能取得良好的效果, 实验提出了两种特征选择方案, 一种是只考虑到时频特征的  $F_1$ , 另一种是考虑两种特征组合的形式即  $F_1 + F_2$ . 最后的识别工作中, 我们对不同被试的单个试次数据采用窗进行分割, 选择 2s 长度的滑动窗截取该数据段, 每次特征提取为 2s 内数据段的特征, 这样能更好地模拟在线识别环境. 图 1 呈现了不同被试在取不同时间段平均识别率变化曲线, 实线表示  $F_1 + F_2$  特征, 虚线表示仅  $F_1$  特征, 图 1 中的时间  $t$  表示以  $t$  为结尾的 2s 时间窗内的数据所得识别率.

表 1 呈现了不同被试在采用两种特征在不同时段下获得的平均和最高识别率对比, 最高识别率为

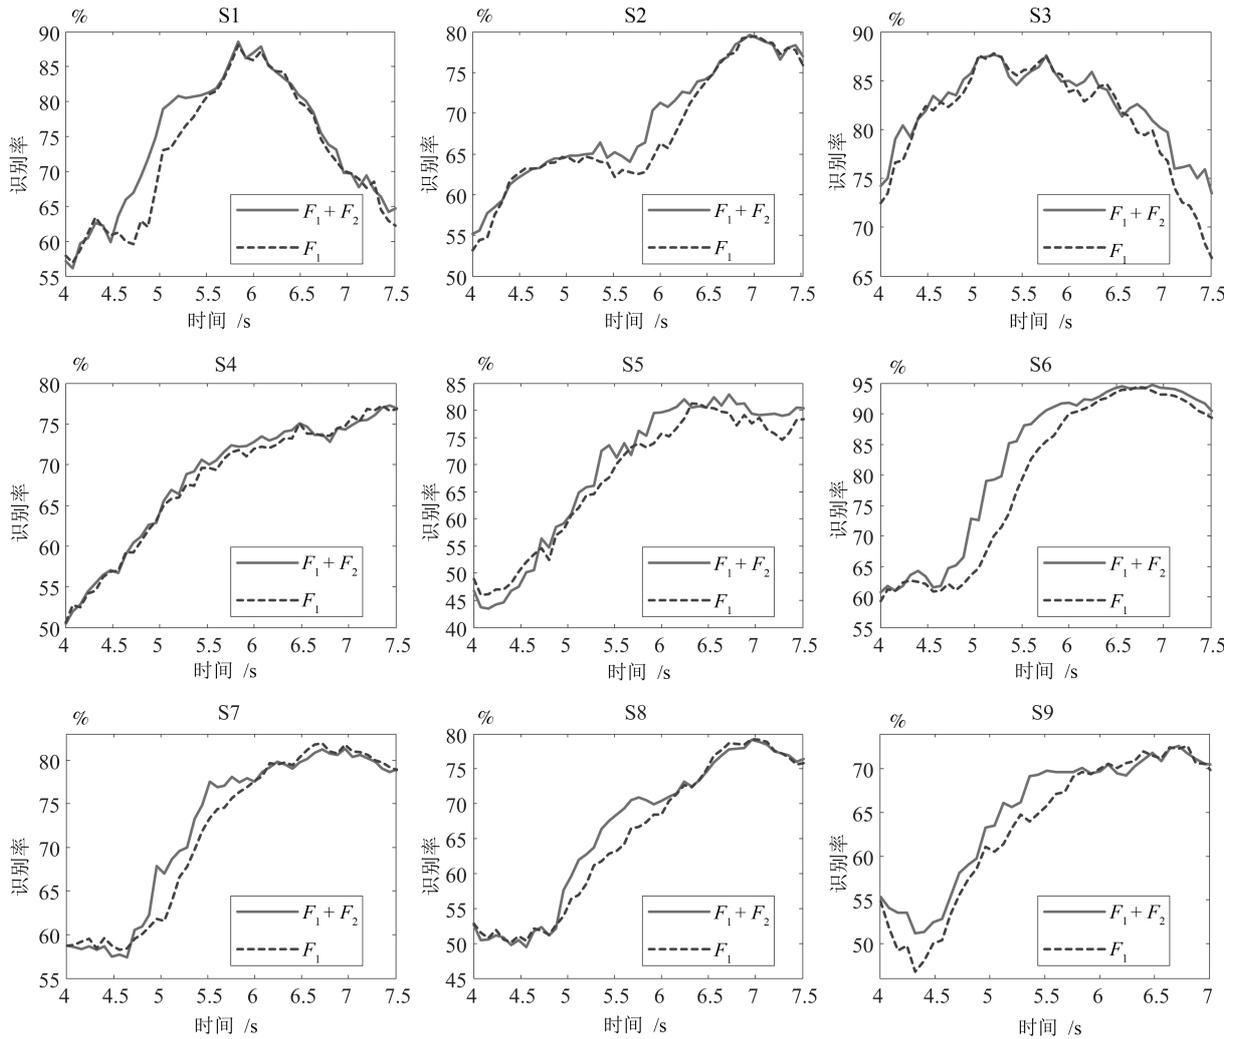


图 1 九名被试识别率曲线

Fig. 1 The classification accuracy curves of nine subjects

表 1 不同被试采用两种特征在两类时段可获得的平均识别率和最高识别率

被试	特征组合	识别率上升时段 平均识别率 (%)	最优时段平均 识别率 (%)	最优时段最高 识别率 (%)
S1	$F_1$	68.39	83.85	88.09
	$F_1 + F_2$	73.38	84.23	88.56
S2	$F_1$	69.60	78.15	79.44
	$F_1 + F_2$	71.14	78.26	79.60
S3	$F_1$	80.04	86.53	87.77
	$F_1 + F_2$	81.16	86.29	87.65
S4	$F_1$	64.82	75.33	77.25
	$F_1 + F_2$	65.41	75.13	77.22
S5	$F_1$	65.60	78.31	81.29
	$F_1 + F_2$	67.70	80.52	82.93

被试	特征组合	识别率上升时段 平均识别率 (%)	最优时段平均 识别率 (%)	最优时段最高 识别率 (%)
S6	$F_1$	72.37	92.01	94.38
	$F_1 + F_2$	78.50	93.09	94.72
S7	$F_1$	68.37	80.28	81.97
	$F_1 + F_2$	70.56	79.92	81.28
S8	$F_1$	64.62	77.52	79.23
	$F_1 + F_2$	67.67	77.26	79.14
S9	$F_1$	61.74	71.07	72.59
	$F_1 + F_2$	64.15	70.77	72.59

取不同数据区间可获得的识别率最高点. 这里选择了两个时间段作为考虑, 一个为信号反馈初期的识别率上升时段, 是被试从平静状态到形成运动想象思维的过渡阶段. 另一个是运动想象识别工作的最

优时段, 在这段期间, 被试对象的运动想象活动趋于稳定, 是运动想象识别工作的最佳时段. 可以观察到加入  $F_2$  特征前后多个被试的识别率上升时段平均识别率均有明显的提升.

## 2.2 对比加窗 ApEn 与时间均值的 ApEn

除了对两种特征的对比之外, 我们还对比了近似熵的不同求取方式带来的区别. 这里的时间均值的近似熵是直接对一层 IMF 的两秒数据直接求取熵值得到, 没有进行滑动窗的分割. 表 2 中呈现了不同被试仅使用两种熵特征最佳时段经过 50 次随机交叉检验所取得的平均识别率及标准差值.

表 2 加窗 ApEn 和时间均值 ApEn 特征对于不同被试取得的识别率对比

Table 2 The comparison of window-added ApEn feature and normal ApEn feature on accuracy for each subjects

被试	加窗 ApEn (%)	时间均值的 ApEn (%)
S1	76.14 ± 0.99	64.54 ± 1.38
S2	74.14 ± 0.40	72.86 ± 0.61
S3	84.97 ± 0.86	81.93 ± 0.84
S4	60.02 ± 0.80	59.03 ± 0.42
S5	72.38 ± 1.80	71.17 ± 1.17
S6	84.58 ± 0.28	82.58 ± 0.46
S7	75.80 ± 0.57	80.99 ± 0.40
S8	75.00 ± 0.57	73.88 ± 0.39
S9	67.04 ± 0.47	68.13 ± 0.47

## 2.3 与其他文献中方法对比

在近期使用相同数据集较有代表性的文献中, 文献 [17] 作者提出采用“留一法”在较有代表性且高效几种时频特征中 (AR 自回归系数、小波分解及功率谱等) 提取特征, 文献 [16] 在提取幅频特征基础上, 应用了相空间重构的方法考虑到其中非线性动力学特征, 文献 [18] 中提出利用 HHT 特征提取方法计算归一化能量结合 AR 参数模型作为特征. 本文提出的方法, 在保证时频域具有较高的分辨率的同时, 从时频分析角度和非线性动力学特征两方面的提取特征, 效果都要优于只考虑时频特征以及分辨率较低的时频分析方法. 表 3 呈现了对于不同被试所得到的最大识别率对比. 另外, 表 4 中呈现了使用本文提出方法和第二次国际 BCI 竞赛的结果比较, 实验采用竞赛中指定的测试集及训练集数据, 分类结果评价指标为最大互信息 (Mutual Information, MI)<sup>[39]</sup>. 相比 BCI 竞赛方法, 本文提出方法展现了良好竞争力, 较其他方法具有优势.

## 3 讨论

人的脑电信号具有高度的非平稳性和非线性以

及个体差异, 这使得难以有一个既定的处理方法对各类脑电信号都具有很好的识别效果. 本文针对这一问题, 提出了两类基于 EEMD 分解的特征提取算法并应用于运动想象脑电信号分类任务中. 两类特征均从运动想象伴随的 ERD 现象入手, 分析信号的能量分布及复杂度两方面内容, 在对 9 名被试的实验中验证了本文提出方法的有效性, 取得较为可信和稳定的结果.

表 3 对于不同被试者可得到的最大识别率 (%)

Table 3 The maximal classification accuracy (%) obtained on different subjects

被试者	S1	S2	S3	S4	平均值
文献 [18]	87.86	/	/	/	/
文献 [17]	82.14	67.18	68.95	77.78	74.01
文献 [16]	90.71	73.18	85.53	76.95	81.59
本文中 $F_1 + F_2$	88.56	79.60	87.77	77.25	83.30

表 4 本文方法与 BCI 竞赛获奖者所取得的最大互信息对比

Table 4 Comparison of maximal mutual information (MI) between our work and BCI competition winners' methods

	特征提取方法	最大互信息 (MI)
Schäfer and Lemm	Morlet 小波特征	0.61
Narayanad	AR 功率谱	0.46
Saffari	AAR 参数模型	0.45
Gao	频段能量特征	0.44
Sadashivaiah	六阶 AR 参数模型	0.29
本文方法		0.64

为了保证时频能量特征的优选, 我们同时提取了基于希尔伯特变换的瞬时能量及边际谱幅值作为特征, 实验中我们也验证了这样做具有的合理性. 从多个被试的单因素方差分析的结果中, 我们发现不同被试对这两种能量特征表现着不同的敏感程度. 如图 2 中呈现了被试者 S3 在想象两种不同动作时, 测试集平均瞬时能谱随时间变化的情况, 被试在进行左手想象运动时, 在  $t = 4 \sim 5$  s 时间段内 C3 通道具有较 C4 通道高的瞬时能量分布, 进行右手想象运动时, C4 通道则呈现较高的能量分布情况, 符合 ERD 原理. 图 4 中呈现了被试者 S4 在想象两种不同动作时 IMF<sub>2</sub> 层分量边际谱图, 可以看出, 其在 8 ~ 15 Hz 频段虽具有较高的能量分布, 但不符合运动想象中的 ERD 原理, C3 通道一直具有较高能量分布. 而在 15 ~ 30 Hz 频段内信号的特征符合 ERD 原理, 若只进行时域统一能量特征分析, 低频段具有较高能量的信号势必会掩盖高频段有较低能量信号中的有效信息, 这就造成被试对时域能量特征的不敏感, 最终导致较低的识别率. 同时, 我们对边际谱

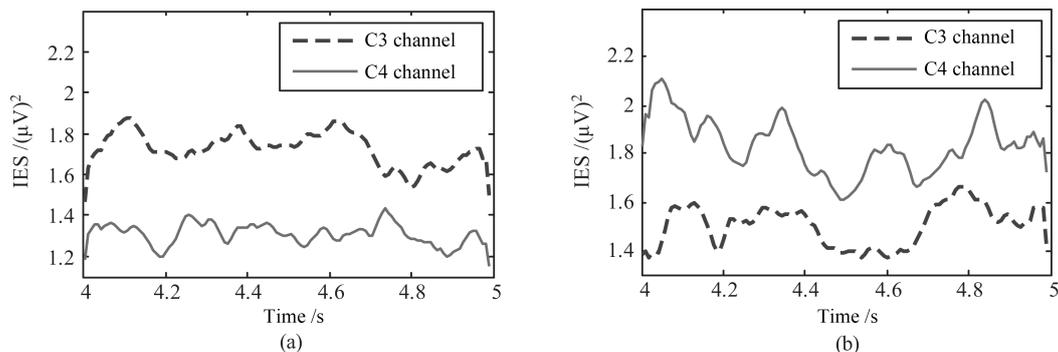


图2 被试者 S3 进行左手想象运动 (a) 和右手想象运动 (b) 两通道上信号的 IMF<sub>2</sub> 平均瞬时能量量图

Fig. 2 The averaging Hilbert instantaneous energy spectrum of IMF<sub>2</sub> for left (a) and right (b) hand motor imagery over C3, C4 channels of the training trials from subject S3

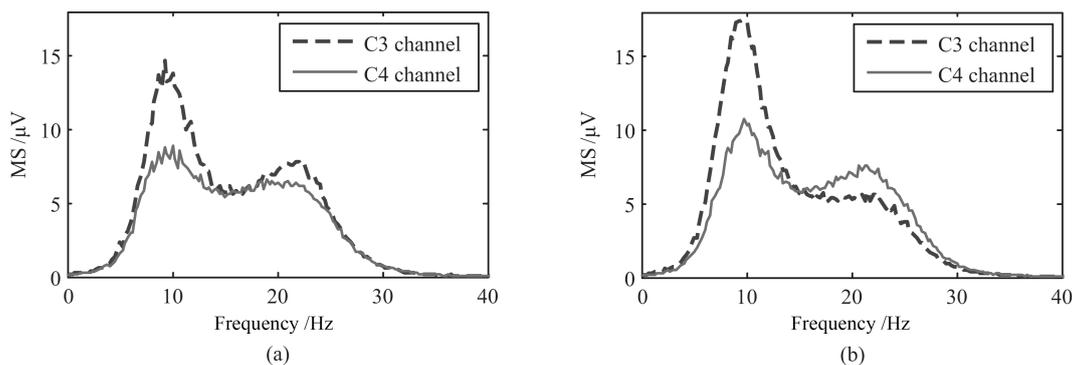


图3 被试者 S4 进行左手想象运动 (a) 和右手想象运动 (b) 两通道上信号的 IMF<sub>2</sub> 平均边际谱幅值图

Fig. 3 The averaging Hilbert marginal spectrum of IMF<sub>2</sub> for left (a) and right (b) hand motor imagery over C3, C4 channels of the training trials from subject S4

提出的多子频带的分析方法, 也能保证有效的信息不被遗漏, 从而提高识别准确率. 在对多名被试实验中, 该方法均获得了可观识别率.

除了时频特征以外, 我们还同时提取了近似熵作为特征. 人在进行左右手运动想象时, 大脑对侧的感觉运动皮层区域就会被激活, 对应区域内的神经元感受到刺激后, 其活化程度发生变化, 进而导致 EEG 信号复杂度产生变化. 实验中, 从图 1 及表 1 中我们也可以观察到, 不同被试在引入近似熵特征后, 其在任务反馈初期时间段 (4s~6s) 上的识别率有着明显的提高, 而这段时间也是人脑形成稳定运动想象思维的过渡时期, 人脑两侧的感觉运动皮层区域还没有形成稳定能量差, 而本文引入的加窗的近似熵特征, 通过揭示时间段内信号复杂度的变化, 能更好辨别出过渡间期两种运动想象状态. 同时, 我们还可以发现, 被试者若能较快地达到稳定思维状态, 即对应识别率提高快速, 该近似熵特征对于识别率的提高就越明显 (如 S1、S6 等), 识别率曲线也能较快到达识别的最优时段; 而对于思维过程变化比较平缓被试 (如 S2、S4), 加窗的近似熵特征就不易

发觉信号在短时间内在复杂度上的变化, 导致被试对此熵特征的不敏感情况. 同样的情况也体现在最优时段的识别率变化上, 被试者思维活动进入相对稳定状态, 近似熵特征所带来的影响也就不明显. 从上述规律可以看出, 该近似熵特征更能反映人的生理状态变化情况, 这也是在 BCI 系统中引入近似熵意义之一.

本文还对比了求取时间均值的近似熵值与使用的加窗的近似熵两种方法带来的识别率. 在表 2 的实验结果中, S7 表现了对第二种方法熵值特征的较为显著的高识别率, 两种方法的差别之一为求取近似熵值时所分析的数据段长度不同 (分别为 1s 和 2s), 数据段长度的选择是影响熵值特征好坏因素之一, 一个固定的数据分析长度很难适用于所有被试者, 因此造成了这种差异性. 而实验中我们发现, 对于除 S7 和 S9 以外的多数被试, 加窗的近似熵特征要优于时间均值的近似熵特征, 说明了本文提出的加窗近似熵特征提取方法具有一定的优势.

表 3 中比较了本文方法与其他文献中相同数据集上所获得的最大识别率. 本文的方法在被试者

S2、S3 的识别率以及综合识别率都有所提高, 9 名被试的平均最高识别率为 82.74%。本文方法取得了 0.64 的互信息, 相比于 BCI 竞赛成绩体现了较好的竞争力。虽已有研究使用希尔伯特边际谱和瞬时能量做运动想象识别工作<sup>[40]</sup>, 本文在此基础上, 以 ERD 现象原理入手, 提取最具特征频带作为特征, 同时在 EEMD 过程后, 加入了对非线性动力学特征近似熵的在运动想象范式中加窗提取特征方法, 在一定程度上弥补了以前方法未从信号复杂度解析信号的不足, 并分析了引入熵特征在运动想象类识别任务过程中的影响, 对多个被试的实验中也验证了本文的方法的有效性和普适性。

同时我们还统计了单次特征提取过程的时耗, 如表 5 所示。实验中, 单次处理的数据段长度取 2s, EEMD 含 EMD 次数为 20 次, 分解截止层数为 5 层, 三种特征皆是基于前三阶 IMF 分量进行提取。可以看出本文方法中 EEMD 过程和熵特征的提取过程较为耗时, 这就要求实际的 BCI 系统要有较高的运算速率。熵特征计算的时耗也是阻碍其真正应用于实际 BCI 系统的原因之一。本文仅利用时频能量特征也可获得较好的识别率, 若仅考虑 EEMD 时耗, 是可以基本满足在线 BCI 系统要求的。在接下来的工作中, 我们会对更多类熵特征进行实验, 如耗时较少的排列熵、香农熵等, 使其在提高识别率的同时能更好的符合在线 BCI 系统的要求。

表 5 本文中所用方法的时耗统计

Table 5 The time consumption of the method used in this paper

	EEMD 过程	瞬时能量特征	边际谱特征	近似熵特征
时耗 (s)	1.147	0.001	0.082	2.354

## 4 结论

本文应用 EEMD 方法对 EEG 信号进行分解, 利用希尔伯特变换得到边际谱和瞬时能谱, 选取最优频带提取时频特征, 同时, 加入了 EEMD 过程后的提取加窗的近似熵为特征, 从非线性动力学特征方向分析信号复杂度作为特征, 实验中采用 9 组数据集进行分类实验, 在左手、右手二分类运动想象识别研究中获得可观结果, 对于被试 S3 和被试 S2 可达到识别率分别为 87.77% 和 79.60%, 所有被试的平均识别率高于 80%, 为以后在线脑-机接口系统的研究打下基础。我们同时分析了熵特征在运动想象识别任务过程中带来的影响, 及其能反映人的生理状态变化, 为以后的研究提供参考。本文采用了加窗分析数据段并得到实验结果, 与实际脑-机接口系统更为切合, 可为在线 BCI 系统的研发提供借鉴方法和理论支持。

## References

- 1 Wolpaw J R, Birbaumer N, Mcfarland D J, Pfurtscheller G, Vaughan T M. Brain-computer interfaces for communication and control. *Clinical Neurophysiology*, 2002, **113**(6): 767–791
- 2 Birbaumer N. Breaking the silence: Brain-computer interfaces (BCI) for communication and motor control. *Psychophysiology*, 2006, **43**(6): 517–532
- 3 Gao Shang-Kai. Comments on recent progress and challenges in the study of brain-computer interface. *Chinese Journal of Biomedical Engineering*, 2007, **26**(6): 801–803, 809  
(高上凯. 浅谈脑-机接口的发展现状与挑战. 中国生物医学工程学报, 2007, **26**(6): 801–803, 809)
- 4 Wang Xing-Yu, Jin Jing, Zhang Yu, Wang Bei. Brain control: Human-computer integration control based on brain-computer interface. *Acta Automatica Sinica*, 2013, **39**(3): 208–221  
(王行愚, 金晶, 张宇, 王蓓. 脑控: 基于脑-机接口的人机融合控制. 自动化学报, 2013, **39**(3): 208–221)
- 5 Blankertz B, Sannelli C, Halder S, Hammer E M, Kübler A, Müller K R, Curio G, Dickhaus T. Neurophysiological predictor of SMR-based BCI performance. *Neuroimage*, 2010, **51**(4): 1303–1309
- 6 Pfurtscheller G, Neuper C. Motor imagery and direct brain-computer communication. *Proceedings of the IEEE*, 2001, **89**(7): 1123–1134
- 7 Birbaumer N, Ghanayim N, Hinterberger T, Iversen I, Kotchoubey B, Kübler A, Perelmouter J, Taub E, Flor H. A spelling device for the paralysed. *Nature*, 1999, **398**(6725): 297–298
- 8 Bayliss J D. Use of the evoked potential P3 component for control in a virtual apartment. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2003, **11**(2): 113–116
- 9 Hoffmann U, Vesin J M, Ebrahimi T, Diserens K. An efficient P300-based brain-computer interface for disabled subjects. *Journal of Neuroscience Methods*, 2008, **167**(1): 115–125
- 10 Lalor E C, Kelly S P, Finucane C, Burke R, Smith R, Reilly R B, McDarby G. Steady-state VEP-based brain-computer interface control in an immersive 3D gaming environment. *EURASIP Journal on Applied Signal Processing*, 2005, **2005**: 3156–3164

- 11 Middendorff M, McMillan G, Calhoun G, Jones K S. Brain-computer interfaces based on the steady-state visual-evoked response. *IEEE Transactions on Rehabilitation Engineering*, 2000, **8**(2): 211–214
- 12 Hwang H J, Kwon K, Im C H. Neurofeedback-based motor imagery training for brain-computer interface (BCI). *Journal of Neuroscience Methods*, 2009, **179**(1): 150–156
- 13 Tam W K, Tong K Y, Meng F, Gao S. A minimal set of electrodes for motor imagery BCI to control an assistive device in chronic stroke subjects: A multi-session study. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2011, **19**(6): 617–627
- 14 Pfurtscheller G. Functional brain imaging based on ERD/ERS. *Vision Research*, 2001, **41**(10–11): 1257–1260
- 15 McFarland D J, Miner L A, Vaughan T M, Wolpaw J R. Mu and Beta Rhythm topographies during motor imagery and actual movements. *Brain Topography*, 2000, **12**(3): 177–86
- 16 Chen M Y, Fang Y H, Zheng X F. Phase space reconstruction for improving the classification of single trial EEG. *Biomedical Signal Processing and Control*, 2014, **11**: 10–16
- 17 Rodríguez-Bermúdez G, García-Laencina P J, Roca-González J, Roca-Dorda J. Efficient feature selection and linear discrimination of EEG signals. *Neurocomputing*, 2013, **115**: 161–165
- 18 Sun Hui-Wen, Fu Yun-Fa, Xiong Xin, Yang Jun, Liu Chuan-Wei, Yu Zheng-Tao. Identification of EEG induced by motor imagery based on Hilbert-Huang transform. *Acta Automatica Sinica*, 2015, **41**(9): 1686–1692  
(孙会文, 伏云发, 熊馨, 杨俊, 刘传伟, 余正涛. 基于 HHT 运动想象脑电模式识别研究. 自动化学报, 2015, **41**(9): 1686–1692)
- 19 Hsu W Y. Assembling a multi-feature EEG classifier for left-right motor imagery data using wavelet-based fuzzy approximate entropy for improved accuracy. *International Journal of Neural Systems*, 2015, **25**(8): 1550037
- 20 Hsu W Y, Sun Y N. EEG-based motor imagery analysis using weighted wavelet transform features. *Journal of Neuroscience Methods*, 2009, **176**(2): 310–318
- 21 Wang H X. Optimizing spatial filters for single-trial EEG classification via a discriminant extension to CSP: The Fisher criterion. *Medical & Biological Engineering & Computing*, 2011, **49**(9): 997–1001
- 22 Wang Jin-Jia, Chen Chun. Multi-channel EEG feature extraction using hierarchical vector autoregression. *Acta Automatica Sinica*, 2016, **42**(8): 1215–1226  
(王金甲, 陈春. 分层向量自回归的多通道脑电信号的特征提取研究. 自动化学报, 2016, **42**(8): 1215–1226)
- 23 Yang Bang-Hua, Zhang Yun-Yuan, He Liang-Fei, Li Hua-Rong, Wang Qian. Removal of EOG artifacts from EEG signals in BCI based on ICA-RLS. *Chinese Journal of Scientific Instrument*, 2015, **36**(3): 668–674  
(杨帮华, 章云元, 何亮飞, 李华荣, 王倩. 脑机接口中基于 ICA-RLS 的 EOG 伪迹自动去除. 仪器仪表学报, 2015, **36**(3): 668–674)
- 24 He L H, Hu D, Wan M, Wen Y, von Deneen K M, Zhou M C. Common Bayesian network for classification of EEG-based multiclass motor imagery BCI. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2016, **46**(6): 843–854
- 25 Yuksel A, Olmez T. A neural network-based optimal spatial filter design method for motor imagery classification. *PLoS One*, 2015, **10**(5): e0125039
- 26 Wu Z H, Huang N E. Ensemble empirical mode decomposition: A noise-assisted data analysis method. *Advances in Adaptive Data Analysis*, 2011, **1**(1): 1–41
- 27 Huang N E, Shen Z, Long S R, Wu M C, Shih H H, Zheng Q A, Yen N C, Tung C C, Liu H H. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 1998, **454**(1971): 903–995
- 28 BCI Competition II [Online], available: <http://www.bbci.de/competition/ii/>, May 5, 2017.
- 29 BCI Competition III [Online], available: <http://www.bbci.de/competition/iii/>, May 5, 2017.
- 30 BCI Competition IV [Online], available: <http://www.bbci.de/competition/iv/>, May 5, 2017.
- 31 Pfurtscheller G, Neuper C. Event-related synchronization of mu rhythm in the EEG over the cortical hand area in man. *Neuroscience Letters*, 1994, **174**(1): 93–96
- 32 Luo Lei, Huang Bo-Yan, Sun Jin-Wei, Wen Liang. A new ANC system based on ensemble empirical mode decomposition. *Acta Automatica Sinica*, 2016, **42**(9): 1432–1439  
(罗磊, 黄博妍, 孙金玮, 温良. 基于总体平均经验模态分解的主动噪声控制系统研究. 自动化学报, 2016, **42**(9): 1432–1439)
- 33 Yeh C L, Chang H C, Wu C H, Lee P L. Extraction of single-trial cortical beta oscillatory activities in EEG signals using empirical mode decomposition. *Biomedical Engineering Online*, 2010, **9**: 25

- 34 Pincus S M. Approximate entropy as a measure of system complexity. *Proceedings of the National Academy of Sciences of the United States of America*, 1991, **88**(6): 2297–2301
- 35 Srinivasan V, Eswaran C, Sriraam N. Approximate entropy-based epileptic EEG detection using artificial neural networks. *IEEE Transactions on Information Technology in Biomedicine*, 2007, **11**(3): 288–295
- 36 Signorini M G, Magenes G, Cerutti S, Arduini D. Linear and nonlinear parameters for the analysis of fetal heart rate signal from cardiocographic recordings. *IEEE Transactions on Biomedical Engineering*, 2003, **50**(3): 365–374
- 37 Yu H, Yang J. A direct LDA algorithm for high-dimensional data with application to face recognition. *Pattern Recognition*, 2001, **34**(10): 2067–2070
- 38 Hariharan M, Fook C Y, Sindhu R, Ilias B, Yaacob S. A comparative study of wavelet families for classification of wrist motions. *Computers & Electrical Engineering*, 2012, **38**(6): 1798–1807
- 39 Schlögl A, Neuper C, Pfurtscheller G. Estimating the mutual information of an EEG-based brain-computer interface. *Biomedizinische Technik. Biomedical Engineering*, 2002, **47**(1–2): 3–8
- 40 Li Ming-Ai, Cui Yan, Yang Jin-Fu, Hao Dong-Mei. An adaptive multi-domain fusion feature extraction with method HHT and CSSD. *Acta Electronica Sinica*, 2013, **41**(12): 2479–2486  
(李明爱, 崔燕, 杨金福, 郝冬梅. 基于 HHT 和 CSSD 的多域融合自适应脑电特征提取方法. 电子学报, 2013, **41**(12): 2479–2486)



**杨默涵** 吉林大学通信工程学院硕士研究生. 2013 年获得东南大学学士学位. 主要研究方向为信号处理, 模式识别, 智能控制. E-mail: yyymmh@163.com  
(**YANG Mo-Han** Master student at the College of Communication Engineering, Jilin University. He received his bachelor degree in 2013 from South-east University. His research interest covers signal processing, pattern recognition, and intelligent control.)



**陈万忠** 吉林大学通信工程学院教授. 1994 年获得吉林工业大学通信与电子系统专业工学硕士学位, 2001 年获得吉林大学动力机械及工程专业工学博士学位. 主要研究方向是信号处理, 图像处理, 模式识别. 本文通信作者. E-mail: chenwz@jlu.edu.cn  
(**CHEN Wan-Zhong** Professor at the College of Communication Engineering, Jilin University. He received the master degree in communication engineering from Jilin University in 1994 and Ph.D. degree in mechanical science and engineering from Jilin University in 2001. His research interest covers signal processing, image processing, and pattern recognition. Corresponding author of this paper.)



**李明阳** 吉林大学通信工程学院博士研究生. 2013 年获得上海理工大学学士学位. 主要研究方向为模式识别与智能系统. E-mail: mingyang15@mails.jlu.edu.cn  
(**LI Ming-Yang** Ph.D. candidate at the College of Communication Engineering, Jilin University. She received her bachelor degree in 2013 from University of Shanghai for Science and Technology. Her research interest covers pattern recognition and intelligent system.)