

9-18-2020

## EEG Classification Based on Multi-domain Features and Random Subspace Ensemble

Deng Xin

*Key Laboratory of Data Engineering and Visual Computing, College of Computer Science and Technology  
Chongqing University of Posts and Telecommunications, Chongqing 400065, China;*

Can Long

*Key Laboratory of Data Engineering and Visual Computing, College of Computer Science and Technology  
Chongqing University of Posts and Telecommunications, Chongqing 400065, China;*

Jianxun Mi

*Key Laboratory of Data Engineering and Visual Computing, College of Computer Science and Technology  
Chongqing University of Posts and Telecommunications, Chongqing 400065, China;*

Boxian Zhang

*Key Laboratory of Data Engineering and Visual Computing, College of Computer Science and Technology  
Chongqing University of Posts and Telecommunications, Chongqing 400065, China;*

*See next page for additional authors*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

# EEG Classification Based on Multi-domain Features and Random Subspace Ensemble

## Abstract

**Abstract:** Aiming at the preprocessing feature extraction and classification recognition in BCI system, a method for EEG classification of motion imagery based on random subspaces ensemble learning of multi-domain features is proposed. Based on the analysis on the ERD/ERS characteristics of motion imagery (MI) signals, the multi-domain features of best effective time and frequency bands are extracted as the feature vectors, and the scale of the random subspace ensemble with cross-validation is adaptively chosen, and the EEG classification is realized by using linear discriminant analysis (LDA) classifiers ensemble. The test results show that the accuracy of the multi-domain features and random subspace ensemble can reach 90.71% and the Kappa coefficient can be 0.63, which are better than those of the first place in the competition, and thus prove the algorithm's effectiveness and progressiveness.

## Keywords

EEG signal, motion imagery, multi-domain features, ensemble learning, random subspace

## Authors

Deng Xin, Can Long, Jianxun Mi, Boxian Zhang, Kaiwei Sun, and Wang Jin

## Recommended Citation

Deng Xin, Long Can, Mi Jianxun, Zhang Boxian, Sun Kaiwei, Wang Jin. EEG Classification Based on Multi-domain Features and Random Subspace Ensemble[J]. Journal of System Simulation, 2020, 32(9): 1787-1798.

# 基于多域特征与随机子空间集成的脑电分类

邓欣, 龙灿, 米建勋\*, 张博宪, 孙开伟, 王进

(重庆邮电大学 计算机科学与技术学院 数据工程与可视计算重点实验室, 重庆 400065)

**摘要:** 针对脑机接口 (Brain-Computer Interface, BCI) 中脑电信号预处理、特征提取、分类识别等过程, 提出一种基于多域特征的随机子空间集成方法实现运动想象脑电分类。该方法的基本思想是通过事件相关同步/事件相关去同步特性分析, 提取出最佳时频段的多域特征作为特征向量, 结合交叉验证自适应地选择特征随机子空间的集成规模, 集成线性判别分析分类器实现脑电信号分类。实验结果表明, 多域特征和随机子空间集成分类正确率可达 90.71%、Kappa 系数可达 0.63, 均优于 BCI 竞赛第一名成绩, 从而证明了该算法在脑电分类中的有效性和实用性。

**关键词:** 脑电信号; 运动想象; 多域特征; 集成学习; 随机子空间

中图分类号: TP391.9 文献标识码: A 文章编号: 1004-731X (2020) 09-1787-12

DOI: 10.16182/j.issn1004731x.joss.19-0038

## EEG Classification Based on Multi-domain Features and Random Subspace Ensemble

Deng Xin, Long Can, Mi Jianxun\*, Zhang Boxian, Sun Kaiwei, Wang Jin

(Key Laboratory of Data Engineering and Visual Computing, College of Computer Science and Technology Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

**Abstract:** Aiming at the preprocessing feature extraction and classification recognition in BCI system, a method for EEG classification of motion imagery based on random subspaces ensemble learning of multi-domain features is proposed. Based on the analysis on the ERD/ERS characteristics of motion imagery (MI) signals, the multi-domain features of best effective time and frequency bands are extracted as the feature vectors, and the scale of the random subspace ensemble with cross-validation is adaptively chosen, and the EEG classification is realized by using linear discriminant analysis (LDA) classifiers ensemble. The test results show that the accuracy of the multi-domain features and random subspace ensemble can reach 90.71% and the Kappa coefficient can be 0.63, which are better than those of the first place in the competition, and thus prove the algorithm's effectiveness and progressiveness.

**Keywords:** EEG signal; motion imagery; multi-domain features; ensemble learning; random subspace

## 引言

脑机接口 (Brain-Computer Interface, BCI) 作为一门新兴交叉学科, 一直是神经科学、人工智能、

模式识别等众多领域的研究热点。自 1973 年 Vidal 教授提出脑机接口概念以来<sup>[1]</sup>, 脑机接口以其不依赖肌肉组织和外周神经回路就能在脑和外部设备之间通信的全新对外信息交流和控制技术而受到广泛关注<sup>[2]</sup>。在大脑活动中, 运动想象 (Motor Imagery, MI) 只需要被试进行简单的动作想象就可以在大脑皮层产生相应信号作为 BCI 的输入, 因此受到特别关注。为了推动 BCI 研究的发展, 国



收稿日期: 2019-01-22 修回日期: 2019-12-03;  
基金项目: 国家自然科学基金(61806033), 重庆市重点产业共性关键技术创新专项(cstc2017zdcy-zdyfX0012), 国家社会科学基金西部项目(18XGL013);  
作者简介: 邓欣(1981-), 男, 重庆, 博士, 副教授, 研究方向为脑机接口; 龙灿(1994-), 女, 重庆, 硕士, 研究方向为智能信息处理; 米建勋(通讯作者 1982-), 男, 重庆, 博士, 副教授, 研究方向为模式识别。

<http://www.china-simulation.com>

• 1787 •

际上著名的几个 BCI 研究中心联合举办了名为“BCI competition”的脑电数据分析竞赛,自 1999 年起,该竞赛已经成功举办了四届。

BCI 系统主要组成包括:信号采集、预处理,特征提取,分类识别以及输出设备等模块。任何 BCI 驱动设备的先决条件是分类特征的良好识别率。脑电图(Electroencephalography, EEG)一直是 BCI 研究中最常用的脑部信号采集方式。作为非侵入式的脑信号记录技术,EEG 具有无创性、易用性、便携性、良好的时间分辨率和相对低廉的价格。脑电是非平稳、非高斯的低信噪比复杂信号<sup>[3-4]</sup>,如何从中产生特征,需要使用各种时域、频域、时频和非线性信号处理算法,如自回归参数模型(AR)、共同空间模式(CSP)、独立成分分析(ICA)、快速傅里叶变换(FFT)、小波变换(WT)等<sup>[5-7]</sup>。在特征分类方面,常用的有线性判别分析(LDA)、人工神经网络(ANN)、支持向量机(SVM)等<sup>[8-9]</sup>。时域分析是早期的脑电分析主要方式,直接提取波形特征,与之相似的是频域特征提取,例如,功率谱估计可以直观观察脑电节律的分布情况。单一的时域或频域提取方法物理意义明确、直观性强、可抑制混杂在原信号中的干扰信号,但是会损失频率或时间信息,不能完全体现信号隐藏特性。CSP 从空间域提取特征,是运动想象脑机接口中一种非常有效的方法,可是 CSP 在少通道 EEG 信号时,能提取的空间域信息有限。也有不少研究者提出了改进 CSP 的算法,比如李明爱等提出的改进 CSP 算法用在单侧肢体运动想象任务中就有很好的优势,单侧识别率为 99.29%,孟建军等<sup>[10]</sup>利用通道延时的 CSP 算法可以和 BCI 竞赛第一名成绩相当。小波变换是现阶段运用最广的一种方法,小波变换的基函数可以在时间上局部化,从而在特定时间点获得频率的变化,实现时域和频域联合分析,但此方法很大程度依赖先验知识,即直接获取感兴趣的频段作为特征,但是脑电信号产生机理复杂,很难获取准确的先验知识。如上所述,单一的脑电特征具有不同程度的局限性,不少学者开始融合这些特征并

取得不错成果<sup>[11-12]</sup>,比如徐宝国等<sup>[13]</sup>提出了一种将离散小波变换和 AR 模型结合的特征提取方式,在控制机器人的在线系统中平均分类正确率达到了 89.5%。

集成学习是近来发展起来的机器学习方法,其“好而不同”的集成思想很适合具有时变性的脑电信号分析<sup>[14]</sup>。在集合了时域、频域、空间域和时频特征的 BCI 系统中,集成学习确实能提升系统可靠性。研究发现在运动想象任务中集成学习相对传统方法有明显优势,可以很好的实现分类。李明爱等<sup>[15]</sup>使用 BP 网络作为 AdaBoost 集成学习框架下的弱分类器相比传统的 BP 神经网络分类正确率提高了 23.42%。Nicolosalonso<sup>[16]</sup>利用滑动时间窗采集的 CSP 特征综合了时间和空间信息,利用集成学习集成的 LDA 分类器比传统的 LDA 分类结果更好,将 Kappa 系数从 0.6 提高到 0.66。

BCI 技术的关键在于对大脑信号的正确识别和分类。本文针对预处理、特征提取、分类识别提出了一种基于多域特征的随机子空间集成学习算法实现运动想象脑电分类,并结合了 ERD/ERS 现象分析和交叉验证自适应选择集成规模,本文方法在 BCI 竞赛数据集上的正确率可达 90.71%。

## 1 数据及预处理

### 1.1 数据集描述

本文所使用的运动想象数据集有 2 个,都来自世界著名的 4 个 BCI 研究中心联合举办的脑电信号分析竞赛。第 1 个数据集来自 BCI 2003 年的数据集(Data set III),第 2 个数据集来自 BCI 2008 年的数据集(Data set 2b)。本文方法在第 1 个较小数据集上取得理想效果后,再运用在第 2 个较大的含伪迹复杂数据集上,验证算法的有效性。

#### 1.1.1 BCI II 2003 年竞赛数据集

数据采自一名 25 岁的健康女性,实验要求被试根据提示方向想象左右手的运动。

实验共分为 7 组,每组进行 40 次实验,每次

实验记录时长为 9 s, 每次实验范例如图 1 所示。

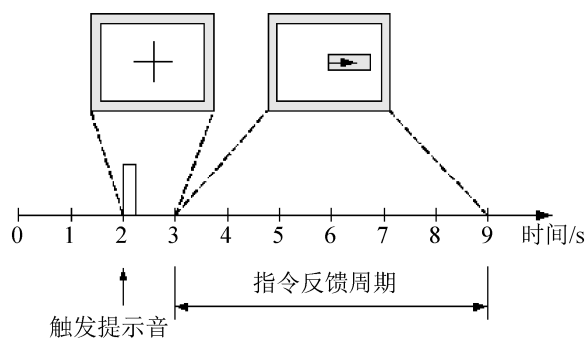


图 1 数据集 III 的实验范例  
Fig. 1 Paradigm of Data set III

0~2 s 被试处于安静状态, 2~3 s 短暂的提示音之后屏幕中央会有一个持续 1 s 的“+”, 3~9 s 会有一个提示方向的箭头, 被试想象同方向的手部运动移动屏幕上的条状棒。

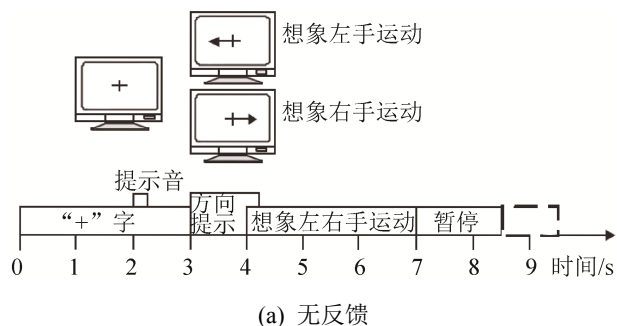
实验记录了 C3, Cz, C4 三个双极导联 EEG 信号, 采样率为 128 Hz, 并进行 0.5~30 Hz 的初始滤波。总计 280 次实验, 选取其中 140 次实验用于训练分类器, 剩下 140 次实验验证分类器性能。

### 1.1.2 BCI IV 2008 年竞赛数据集

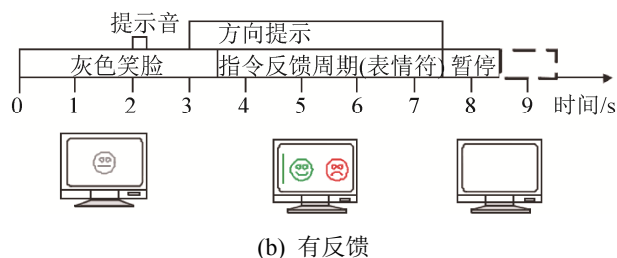
数据采自 9 名健康且为右利手的被试, 实验要求被试根据提示方向想象左右手的运动。实验范例如图 2 所示。

每个被试进行 5 组实验, 前 2 组无反馈实验, 每组 120 次实验, 每次实验记录时长为 8 s, 后 3 组为表情符反馈实验, 每组 160 次实验, 每次实验记录时长为 8.5 s。在每组实验之前还要进行 5 min 眼电模块记录, 2 min 睁眼, 1 min 闭眼, 1 min 眼动时间。

本次实验记录了 C3, Cz, C4 三个双极导联 EEG 信号和单极电极组成的三导眼电 EOG 信号, 采样率为 250 Hz, 0.5~100 Hz 的初始滤波, 50 Hz 陷波滤波去除工频干扰。每个被试总计进行 720 次实验, 选取每个被试前 3 组 400 次实验作为训练集, 后 2 组 320 次实验作为测试集。



(a) 无反馈



(b) 有反馈


图 2 数据集 2b 的实验范例  
Fig. 2 Paradigm of Data set 2b

## 1.2 预处理


研究表明, 大脑在进行某一意识活动时, 大脑皮层相应区域产生的脑电信号中的某些频段成分 ( $\mu$  节律和  $\beta$  节律) 的功率谱会发生显著改变<sup>[17]</sup>, 这一现象被称之为事件相关同步 (event related synchronization, ERS) 和事件相关去同步 (event related desynchronization, ERD)。例如, 在想象左手运动时, 大脑右半球区域的特定频率脑电信号幅值降低, 功率谱比率减弱, 对应 ERD 现象, 其左半球的特定频率脑电信号幅值增加, 功率谱比率上升, 对应 ERS 现象; 与此相反, 想象右手运动时, 大脑右半球将出现 ERD 现象, 其左半球出现 ERS 现象。并且, 对应于大脑主观想象肢体动作思维提示所诱发被动思维的 ERD/ERS 在具体表现的特征频段和运动皮层区域均有所不同, 比如, 对应于想象手部运动的 ERD/ERS 现象多发生于 10~11 Hz ( $\mu$  节律段) 和 20~24 Hz ( $\beta$  节律段), 基于此, 本文将通过分析找到 ERD/ERS 现象最明显的频率段和时间段。

运动想象的 ERD/ERS 现象发生于大脑感觉运动皮层区域, 本文对采自该区域的三导信号 Cz、C3、C4 进行功率谱密度估计, 如图 3 所示, 在想

象右手运动时, C3 在 8~12 Hz ( $\mu$  节律段)以及 19~24 Hz ( $\beta$  节律段)出现明显的幅值减弱,功率谱比率下降的 ERD 现象, C4 在 8~12 Hz 以及 19~24 Hz 频段里出现幅值升高,功率谱比率上升的 ERS 现象;想象左手运动时, C3 在这 2 个频段出现明显 ERS 现象, C4 在这 2 个频段出现明显 ERD 现象。在左右手运动想象过程中, Cz 这两个频段的功率谱密度估计的值相对稳定,没有明显的幅值变化。



(a) 想象右手运动



(b) 想象左手运动


图 3 C3, C4 功率谱密度随频率变化

Fig. 3 Power spectral density varies with frequency in C3, C4.


对原始信号进行多层小波分解,提取  $\mu$  节律和  $\beta$  节律所在频段的小波系数进行重构,得到原始信号在 8~30 Hz 的频段信号,然后按照公式(1)计算各导 EEG 信号的平均能量:

$$p(j) = (1/N) \sum_{i=1}^N x^2(i, j) \quad (1)$$

式中:  $x(i, j)$  为第  $i$  个频段信号的第  $j$  个 EEG 数据;  $N$  为信号个数;  $p(j)$  为平均能量。计算 C3, C4 平均能量的结果如图 4 所示,想象右手运动时, C3 在 3.5~8 s 的时间出现明显的幅值减弱,功率谱比率下降的 ERD 现象, C4 在 3.5~8 s 的时间里出现幅值升高,功率谱比率上升的 ERS 现象;想象左手运动时, C3 在 3.5~7 s 的时间段出现明显 ERS 现象, C4 在 3.5~7 s 的时间 ERD 现象最明显。而且在实验中,左右手的提示出现在 3 s 之后,只需选择 3.5~7 s 作为最有效的时间段, 2~24 Hz 作为滤波范围,选择 C3, C4 两导信号作为分析信号进行特征提取,在提高信噪比的同时降低了计算复杂度。



(a) 想象右手运动



(b) 想象左手运动

图 4 C3, C4 平均能量随时间变化

Fig. 4 Average energy varies with time in C3, C4

## 2 特征提取

### 2.1 基于 AR 模型系数的时域特征提取

自回归模型(Autoregressive Model, AR)是统计上一种处理时间序列的方法。一个  $p$  阶的 AR 模型是之前若干时刻的输出和白噪声的线性组合。公式如下:

$$y(n) = -\sum_{k=1}^p a(k)y(n-k) + x(n) \quad (2)$$

式中:  $y(n)$  当前输出;  $x(n)$  为零均值, 方差为  $\sigma$  的白噪声序列;  $a(k)$ ,  $k=1,2,\dots,p$ , 为 AR 模型的系数。

在构建 AR 模型时, 首先就是模型阶数的选择, 在之前研究当中<sup>[13]</sup>, 6 阶和 8 阶 AR 模型在脑电分类实验中取得了较好的实验效果, 本文通过实验对比最终选择了在运动想象实验中有更高正确率的 8 阶 AR 模型。Burg 算法计算模型系数, 得到的系数作为时域特征向量, 因此对每导脑电信号使用 8 阶的 AR 模型, 每导信号的特征维数是 9 维, 本文提取的时域特征一共是 18 维。

### 2.2 基于 PSD 的频域特征提取

功率谱密度(Power Spectral Density, PSD)估计是脑电信号频域分析的主要方法, 把脑电幅值随时间变化变换为功率随频率变化的直观谱图。韦尔奇(Welch)方法计算出每导信号的功率谱密度, 再在功率谱密度的基础上选择以下六种统计量作为特征向量<sup>[18]</sup>:

(1) 每导信号功率谱密度的均值:

$$\mu = \frac{1}{M} \sum_{j=1}^M y_j \quad (3)$$

(2) 每导信号功率谱密度的平均功率:

$$\lambda = \sqrt{\frac{1}{M} \sum_{j=1}^M y_j^2} \quad (4)$$

(3) 每导信号功率谱密度的标准差:

$$\sigma = \sqrt{\frac{1}{M-1} \sum_{j=1}^M (y_j - \mu)^2} \quad (5)$$

(4) 每导信号功率谱密度的偏度:

$$\phi = \sqrt{\frac{1}{M} \sum_{j=1}^M \frac{(y_j - \mu)^3}{\sigma^3}} \quad (6)$$

(5) 每导信号功率谱密度的峰度:

$$\phi = \sqrt{\frac{1}{M} \sum_{j=1}^M \frac{(y_j - \mu)^4}{\sigma^4}} \quad (7)$$

(6) 每导信号功率谱密度能量占总能量的权重:

$$w = \frac{\sum_{j=1}^M y_{(i,j)}^2}{\sum_{i=1}^N \sum_{j=1}^M y_{(i,j)}^2} \quad (8)$$

式中:  $y_{(i,j)}$  为第  $i$  导信号第  $j$  个样本的幅值;  $M$  为信号的长度;  $N$  为导联个数。因为选取的 C3, C4 两导信号, 每导信号的特征维数是 6 维, 本文提取的频域特征一共 12 维。

### 2.3 基于 CSP 的空间域特征提取

共同空间模式(Common Spatial Pattern, CSP)算法的基本原理是利用 2 个协方差矩阵对角化来设计最优的空间滤波器。

单次脑电实验数据是一个  $N \times M$  维的矩阵  $E$ ,  $N$  为导联个数,  $M$  为采样点数, 则归一化的协方差矩阵可表示为:

$$C = \frac{EE^T}{trEE^T} \quad (9)$$

式中: 用  $C_L$ 、 $C_R$  表示左右手两种实验的协方差矩阵, 计算所有实验的平均协方差矩阵  $\bar{C}_L$ 、 $\bar{C}_R$ 。那么合成的空间协方差矩阵可以表示为:

$$C_C = \bar{C}_R + \bar{C}_L \quad (10)$$

将  $C_C$  用特征值  $\lambda_C$  和特征向量  $U_C$  的形式表示, 即  $C_C = U_C \lambda_C U_C^T$ , 按照特征值降序排序, 相应的特征向量也重新排列。求白化变换:

$$P = \sqrt{\lambda_C^{-1}} U_C^T \quad (11)$$

则白化后的协方差矩阵可表示为:

$$S_L = P \bar{C}_L P^T \quad (12)$$

$$S_R = P \bar{C}_R P^T \quad (13)$$

$S_L$  和  $S_R$  有共同的特征向量  $B$ , 即  $S_L = B \lambda_L B^T$ ,

$S_R = B\lambda_R B^T$  且  $\lambda_L + \lambda_R = I$ 。由于 2 类矩阵特征值和等于 1，则  $S_L$  最大特征值对应的特征向量使得  $S_R$  有最小特征值。将白化后的脑电信号投影在特征向量  $B$  的前  $m$  列和后  $m$  列后获得投影矩阵可表示为：

$$W = B^T P \quad (14)$$

则单次实验脑电数据  $E$  可变换为  $Z_p = WE$ ， $p=1,2,\dots,2m$ 。选择投影信号的如下变化作为空间域特征向量：

$$f_p = \log \left( \frac{\text{var}(Z_p)}{\sum_{i=1}^{2m} \text{var}(Z_i)} \right) \quad (15)$$

特征维数  $f$  根据脑电信号的噪声和分类器要求改变，但不能超过所选择的导联数  $N$ ，本文提取空间域特征一共 2 维。

## 2.4 基于 LWT 的时频特征提取

小波变换(Wavelet Transform, WT)能够在高频处对时间细分，低频处对频率细分，是处理脑电信号这类非平稳信号的理想时频分析工具。但是，传统小波变换在自身构造和时频转换过程需要占用大量的系统资源，运算速度慢，本文中使用提升小波算法(Lifting Wavelet Transform, LWT)相比传统小波分析不依赖傅里叶变换实现小波变换的原位计算，开销小、运算速度快，计算复杂度低<sup>[19]</sup>。

LWT 主要有 3 个步骤：分裂、预测和更新。

(1) 分裂。将原信号分裂为偶下标样本点和奇下标样本点。

$$S_i^0 = X_{2i} \quad (16)$$

$$D_i^0 = X_{2i+1} \quad (17)$$

(2) 预测。用奇样本点周围的偶样本点获得奇样本点估计值，将奇样本点的原始值与预测值的差值作为高频系数。

$$D_i^1 = D_i^0 - (S_i^0 + S_{i+1}^0)/2 \quad (18)$$

(3) 更新。用预测步骤的多个奇样本点估计值更新偶样本点的值，并将其作为低频部分。

$$S_i^1 = S_i^0 + (D_{i+1}^1 + D_i^1)/4 \quad (19)$$

通过多层次分解，以上 3 个步骤可以实现信号

高低频的分离，如图 5~6 所示。

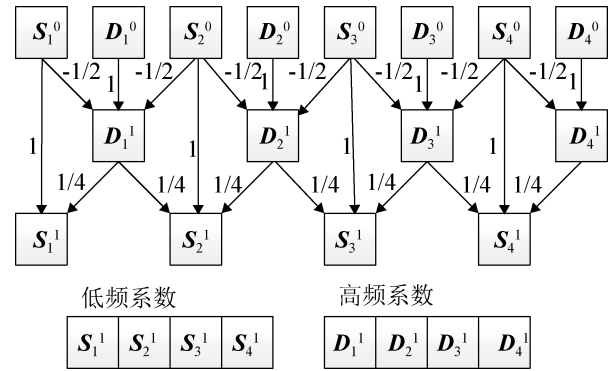


图 5 LWT 分解过程

Fig. 5 LWT decomposition process




图 6 2 层 LWT 分离系数过程

Fig. 6 Two-Layer LWT Separation Coefficient

利用提升小波变换将信号按照多频带分解，再重构各个子频带的系数，进而获得每个子频带的信号，就可以在分解和重构的过程中提取脑电信号隐藏的特征属性。

本文数据集 III 的采样率为 128 Hz，由奈奎斯特定理知有效频率为 64 Hz，故采用 4 层小波分解，其分解后对应频段为 0~4 Hz，4~8 Hz，8~16 Hz，16~32 Hz 和 32~64 Hz，如图 7 所示，选择的提升小波基函数为‘bior4.4’。cD1 频段在预处理滤波时已经去除，不做考虑，所以只用重构 4 个节律段。在 1.2 小节提过运动想象 ERD/ERS 现象最明显的  $\mu$  节律段和  $\beta$  节律段刚好对应 4 层小波分解后的细节系数 cD3 和 cD2，选取这 2 个频段的能量占总能量的权重作为特征向量的一部分，另外，分别计算 4 个频段的均值、平均功率、标准差、峰度、偏度，为了减少特征维度，做了统计学处理，取 cD3 频段占 4 个频段的权重作为特征向量。所以 LWT 一共提取 14 维时频域特征向量。






图 7 采样频率 128 Hz 信号 4 层小波分解过程  
Fig. 7 Four-layer wavelet decomposition with sampling frequency 128 Hz

### 3 集成学习分类

集成学习有几个重要因素, 比如使用的集成算法, 经典算法有 AdaBoost、Bagging; 选用的基学习器类型以及基学习器的数量等等。本文使用的集成方法为随机子空间, 选用的基分类器为线性判别分析。

#### 3.1 随机子空间算法


随机子空间(Random Subspaces, RS)方法能够从原始特征空间中随机选择子空间构造多个特征子空间训练基学习器, 一个基学习器对一个特征子空间数据集进行学习<sup>[20]</sup>。最后将所有基学习器的输出结合起来, 通过某种结合策略, 比如简单平均法, 多数投票法, 得到最终的预测结果。

使用随机子空间集成方法, 先要确定集成规模, 即构造子空间的特征维数以及分类器数量。对于同一被试  $R$  次实验提取的  $D$  维特征矩阵  $F^{R \times D}$ , 当选择  $M$  维特征组成特征子空间时, 那么可能的子空间和基学习器数量  $N$  满足:

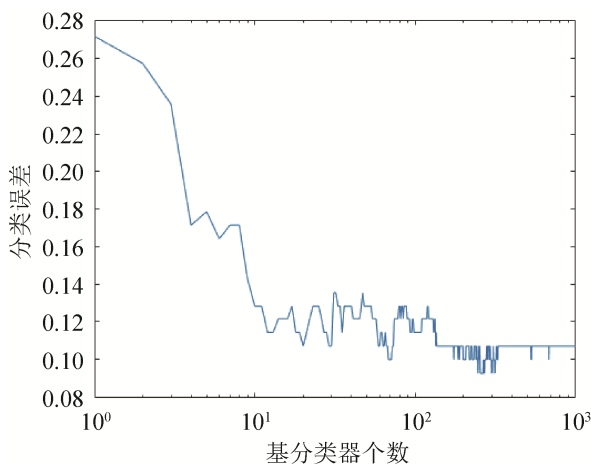
$$N \leq C_D^M = \frac{D!}{M!(D-M)!} \quad (20)$$

可见, 随机子空间的维数组合对基学习器数量的影响, 进而对特征样本子空间和基分类器差异性的扰动来影响分类正确率。图 8 展示了集成规模对交叉验证误差的影响, 也是本文确定这 2 个重要参数的方式, 在不同特征维数和不同数量基学习器的情况下计算训练集交叉验证的误差, 并取使得误差最小时的特征维数和基学习器数量。在本文中, 当交叉验证误差取最小且最优子空间特征维数不大

于 3 时, 保留了所有的基分类器。



(a) 不同的特征子空间维数



(b) 不同的基分类器数量

图 8 集成规模对交叉验证误差的影响

Fig. 8 Effect of ensemble size on cross validation error

#### 3.2 基于判别分析的基分类器

判别分析是一种在分类类别确定的情况下, 根据研究对象的特征值判别其类型归属的一种分析方法。运动想象脑电分析正是这样的一类问题。因此, 本文选择的基分类器的类型是线性判别分析 (Linear Discriminant Analysis, LDA)。线性判别分析的优势在于对分布、方差等都有限制, 其基本思想是将高维空间的样本投影到低维空间, 投影原则是使样本在新空间的类内差异尽可能小, 类间差异尽可能大, 使得样本在新空间有最佳的可分离性。可表示为:

$$J(\mathbf{w}) = \frac{(\tilde{m}_1 - \tilde{m}_2)^2}{\tilde{s}_1^2 + \tilde{s}_2^2} \quad (21)$$

式中： $\tilde{m}_1$ ， $\tilde{m}_2$  分别为定投影后的类均值， $\tilde{s}_1^2$ ， $\tilde{s}_2^2$  对应投影后的类内方差。重写类内总方差和类间距离(公式 22-23)，可得广义瑞利商的形式见式(24)：

$$\tilde{s}_1^2 + \tilde{s}_2^2 = \mathbf{w}^T (s_1^2 + s_2^2) \mathbf{w} = \mathbf{w}^T S_w \mathbf{w} \quad (22)$$

$$\begin{aligned} (\tilde{m}_1 - \tilde{m}_2)^2 &= (\mathbf{w}^T m_1 - \mathbf{w}^T m_2)^2 = \\ &= \mathbf{w}^T (m_1 - m_2)(m_1 - m_2)^T \mathbf{w} = \\ &= \mathbf{w}^T S_b \mathbf{w} \end{aligned} \quad (23)$$

$$J(\mathbf{w}) = \frac{(\tilde{m}_1 - \tilde{m}_2)^2}{\tilde{s}_1^2 + \tilde{s}_2^2} = \frac{\mathbf{w}^T S_b \mathbf{w}}{\mathbf{w}^T S_w \mathbf{w}} \quad (24)$$

## 4 结果分析与讨论

### 4.1 评价指标

分类正确率和 Kappa 系数是评价 BCI 好坏的常用指标，分类正确率用于表示精度，Kappa 系数判断分析方法在预测结果和实际结果上的一致性。Kappa 值介于 0~1，0 表示分类结果是机遇造成的，1 表明 2 次结果具有完全一致性。例如，对于二分类问题，随机分类的正确率为 50%，Kappa 系数却等于 0。Kappa 计算公式为：

$$k = (p_o - p_e) / (1 - p_e) \quad (25)$$

式中： $p_o$  为分类正确率， $p_e$  表示为：

$$p_e = \frac{a_1 \times b_1 + a_2 \times b_2 + \dots + a_i \times b_i}{n \times n} \quad (26)$$

式中： $a_i$  和  $b_i$  分别为第  $i$  类真实样本和预测样本个数。

Kappa 系数可分为 5 个等级来说明预测结果和实际结果的一致性：0.0~0.2 代表极低的一致性；0.21~0.4 代表一般的一致性；0.41~0.60 代表中等的一致性；0.61~0.80 代表高度的一致性；0.81~1 代表几乎完全一致。

### 4.2 实验结果

本文提取的多域 EEG 信号的特征共有 46 维：时域特征 18 维，频域特征 12 维，空间域特征 2 维和时频域特征 14 维。将所有的特征融合后采用随机子空间集成学习方法生成特征向量，送入线性

判别分析基分类器中学习，本文实验方法流程如图 9 所示。本文中的子空间和集成规模都是基于 10 倍交叉验证保证最低误差计算所得。由于集成的分类器和随机采样有关，为排除偶然性，本文实验运行了 30 次，然后计算得其平均分类正确率为 89.17%，最高分类准确率为 90.71%。

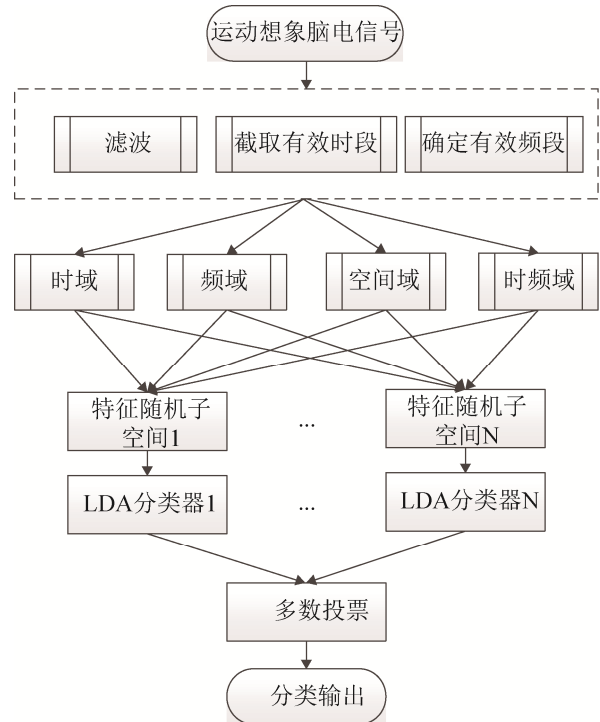


图 9 本文实验方法流程

Fig. 9 Workflow of proposed method

将本文分类结果对比 BCI 竞赛 II 2003 年的竞赛结果前 3 名：89.29%、84.29%、82.86%，本文方法所取得结果明显高于竞赛第一名的成绩。

为了证明本文所提方法在运动想象脑电分类任务中的有效性，特将本文方法与集成学习中的经典算法 AdaBoost、Bagging 作为对照试验，再加一组对比试验是把本文方法步骤的基分类器替换为  $k$  近邻( $k$ -Nearest Neighbor, KNN)分类器，对比结果如表 1 所示。纵向结果显示，本文提取的多域特征比起同样算法提取的单一特征能够有效提高分类正确率；横向结果表明，基于特征随机子空间的集成学习分类方法能够有效实现运动想象脑电信号

分类, 不仅在运动想象脑电分类研究当中有很高的正确率且高于 AdaBoost、Bagging 这 2 类经典集成学习算法的分类正确率; 对比整个表中结果, 不难发现本文方法取得了最高正确率 90.71%, 即基于多域特征的随机子空间集成学习在运动想象脑电分类任务当中是有效的。

在 BCI 2003 年竞赛数据集上本文方法取得较理想的分类结果, 为了进一步验证该方法的有效性, 特将本文方法在 BCI 2008 年数据集上验证, 该数据集共 9 个被试, 每个被试 400 个训练集, 320 个测试集。实验结果如表 2 和图 10 所示。

从图 10(a)可以看出 9 个被试的多域特征比单一域的特征获得了更高的正确率, 从图 10(b)可以得出随机子空间的集成分类方法比其他分类方法有更高的分类识别率。

最后, 将本文方法与竞赛第一名和文献[10]的结果进行对比, 结果如表 3 所示: 竞赛第一名和文献[10]的 Kappa 值都是 0.6, 本文方法可以达到 0.63, 说明本文方法实现的运动想象分类结果与实际结果不仅具有高度一致性且优于现有的运动想象分类方法。

表 1 数据集 III 分类结果  
Tab. 1 Classification accuracy of data set III /%

特征提取方法	AdaBoost	Bagging	Subspace(KNN)	Subspace(LDA)	
				平均正确率	最高正确率
时域 AR	79.29	85	80.71	84.79	87.14
频域 PSD	85	83.57	83.57	87.24	87.86
空间 CSP	85	82.86	86.43	86.62	87.86
时频 LWT	85.71	83.57	84.29	85.83	87.86
多域特征	88.57	86.43	85	<b>89.17</b>	<b>90.71</b>

表 2 数据集 2b 中 9 个被试分类正确率  
Tab. 2 Classification accuracy of 9 subjects in data set 2b /%

被试编号	特征提取方法	AdaBoost	Bagging	Subspace(kNN)	Subspace(LDA)
被试 1	时域 AR	59.38	58.44	56.88	62.81
	频域 PSD	58.13	57.19	55.94	57.5
	空间 CSP	56.56	61.25	56.25	58.44
	时频 LWT	57.19	57.81	51.56	63.75
	多域特征	59.06	57.81	56.56	<b>63.75</b>
被试 2	时域 AR	51.43	51.43	52.14	55.36
	频域 PSD	55.36	58.93	48.93	55.71
	空间 CSP	52.86	50.71	53.21	50
	时频 LWT	57.14	50.71	57.14	55.71
	多域特征	51.79	55.71	56.43	<b>57.14</b>
被试 3	时域 AR	50.94	54.06	52.19	52.5
	频域 PSD	53.44	52.19	50.63	52.81
	空间 CSP	53.13	50.94	56.88	58.75
	时频 LWT	46.88	53.13	49.38	51.88
	多域特征	50.94	49.69	48.75	<b>57.19</b>
被试 4	时域 AR	85.94	87.81	86.88	93.13
	频域 PSD	93.44	94.06	94.06	95.31
	空间 CSP	92.19	89.06	90.63	92.19
	时频 LWT	85.94	88.44	88.13	90.94
	多域特征	93.75	95.94	96.25	<b>97.19</b>

续表

被试编号	特征提取方法	AdaBoost	Bagging	Subspace(kNN)	Subspace(LDA)
被试 5	时域 AR	53.13	47.5	52.19	70.63
	频域 PSD	57.5	56.56	58.44	61.56
	空间 CSP	59.69	59.69	61.88	62.19
	时频 LWT	63.44	62.5	52.19	66.25
	多域特征	64.69	62.5	64.06	<b>70.94</b>
被试 6	时域 AR	64.06	60.94	52.5	80.31
	频域 PSD	70	59.69	68.13	70
	空间 CSP	67.5	59.06	65.31	68.44
	时频 LWT	66.56	69.06	63.13	73.13
	多域特征	71.56	74.06	71.88	<b>82.19</b>
被试 7	时域 AR	61.25	58.44	64.69	72.19
	频域 PSD	66.25	65.94	64.69	69.06
	空间 CSP	65.94	69.06	73.44	72.81
	时频 LWT	59.69	56.56	59.06	65.31
	多域特征	64.06	66.25	71.25	<b>74.06</b>
被试 8	时域 AR	80	79.06	80	90
	频域 PSD	88.75	86.56	89.38	91.25
	空间 CSP	89.38	88.44	92.81	90
	时频 LWT	87.81	84.38	80.94	86.56
	多域特征	89.38	90.31	88.75	<b>91.25</b>
被试 9	时域 AR	68.44	70.63	64.38	76.25
	频域 PSD	75.94	75	76.56	76.56
	空间 CSP	75.94	71.56	75.31	74.38
	时频 LWT	70	65	68.44	75.31
	多域特征	76.25	76.88	77.81	<b>81.25</b>

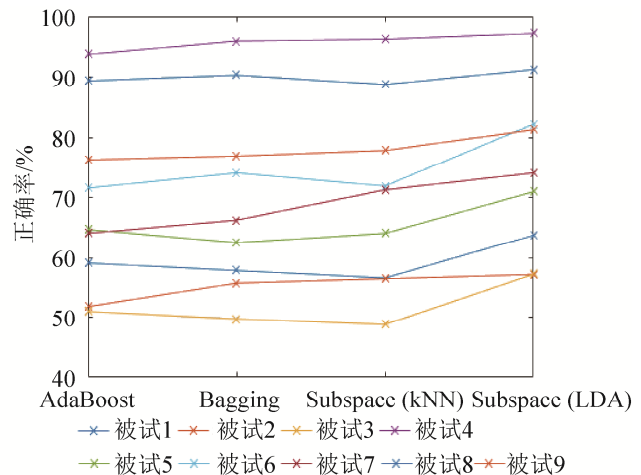
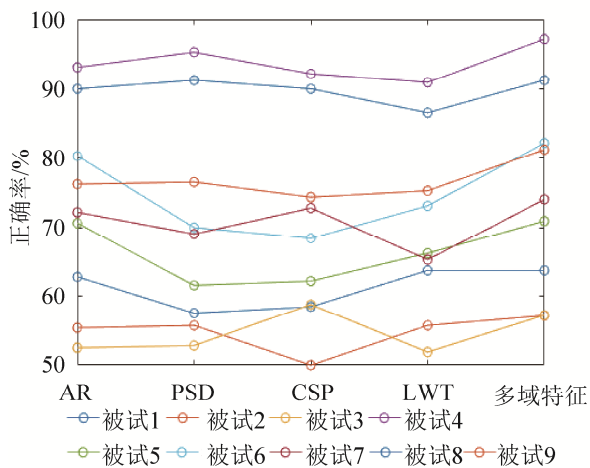


图 10 数据集 2b 中 9 个被试的分类正确率  
Fig. 10 Classification accuracy of 9 subjects in data set 2b

表 3 本文方法与其他方法的对比结果(数据集 2b)  
Tab. 3 Comparisons between present method and other methods (data set 2b)

被试编号	竞赛第一名	文献 10	本文方法
1	0.40	0.37	0.41
2	0.21	0.21	0.43
3	0.22	0.11	0.36
4	0.95	0.93	0.96
5	0.86	0.77	0.53
6	0.61	0.69	0.77
7	0.56	0.61	0.64
8	0.85	0.86	0.89
9	0.74	0.83	0.72
平均	0.60	0.60	<b>0.63</b>

### 4.3 讨论

脑电信号是一种非平稳的信号,而单一的时域或者频域分析由于分辨率的不确定性原理,无法获得较高的分辨率。小波变换虽然具有多分辨率的特性,但是 EEG 信号低信噪比且某些伪迹成分和脑电信号具有相似的时频特性,因此单一的时频分析也无法完全区分,从而影响分类效果。鉴于此,本文融合多域特征,结合 MI 信号 ERD/ERS 特性,提取出有效时段和频段作为特征向量。从表 1~2 可以看出,针对同一种分类方法,多域特征作为特征向量比单一域的特征向量的分类正确率可以较大幅度的提高 1.43%~9.28%,对比广泛运用的时频特征提取方式,多域特征也能提高 0.71%~2.86%。

随机子空间集成作为集成学习的一种,通过随机部分特征而非所有特征来训练分类器,降低了每个分类器之间的相关性。本文实验证明,基于 LDA 的随机子空间集成学习方法对运动想象脑电信号的分类性能有较明显的提高。

在表 2 的 9 个被试中被试 4 的分类正确率可以高达 97.19%,但被试 2 的分类正确率却只有 57.14%,略高于随机正确率 50%。由于大脑是一个复杂的结构,脑电信号只是大脑意识活动的一种反应,其包含的信息也是多种多样,集聚个体差异性、时变性,容易受到精神状态、身体状态等因素影响,不能保证每个被试都能及时并正确的做出应激反

应。此外,目前大部分运动想象研究的都是 C3、C4 两个中央运动区导联,但其实即使是非常简单的脑认知活动,也依赖多个功能脑区的协同合作。因此,本文通过实验证明所提出的多域特征结合随机子空间集成学习能有效识别运动想象分类任务。

## 5 结论

本文提出了一种多域特征结合随机子空间的集成学习算法对运动想象脑电信号进行分类,从而提高其分类准确率。首先对运动想象任务中大脑皮层产生的 ERD/ERS 现象进行分析,确定脑电信号在运动想象任务中出现的最佳特征频段和时段。然后在最佳的时间、频段提取了时域、频域、空间域、时频域等多种单一域特征,并将所得单一域特征融合成多域特征。在分类识别阶段,采用随机子空间从多域特征中选择出最佳规模的特征向量,送入集成的线性判别分析基分类器当中进行分类识别。同时,本文利用交叉验证的最小损失误差确定了集成规模,最终实现了运动想象分类,且取得较好实验效果,在公开数据集上的测试结果也表明了本文所提方法的有效性。本文采用的多域特征避免了单一的脑电特征具有不同程度的局限性的弊端,尽可能的提取脑电信号隐藏特性,同时也为随机子空间分类器集成增加了样本扰动,相比于传统集成学习得到了更高的分类正确率。本文方法不仅仅适用于运动想象脑电研究,也对以后的脑电研究提出可靠的研究依据,为实际 BCI 系统广泛运用奠定了基础。

### 参考文献:

- [1] Wolpaw J R, Birbaumer N, Heetderks W J, et al. Brain-computer interface technology: a review of the first international meeting[J]. International Conference of the IEEE Engineering in Medicine and Biology Society (S1063-6528), 2000, 8(2): 164-173.
- [2] 陈超, 平尧, 郝斌, 等. 基于脑机接口技术的写字系统建模仿真与实现[J]. 系统仿真学报, 2018, 30(12): 4499-4505.  
Chen Chao, Ping Yao, Hao Bin, et al. Modeling, Simulation and Realization of Writing System Based on BCI Technology[J]. Journal of System Simulation, 2018,

- 30(12): 4499-4505.
- [3] Chavez M, Grosselin F, Bussalib A, et al. Surrogate-Based Artifact Removal From Single-Channel EEG[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering* (S1534-4320), 2018, 26(3): 540-550.
- [4] 闫国强, 周宁宁, 张少白. 基于 MMTD 与小波硬阈值的脑电信号去噪方法[J]. *系统仿真学报*, 2018, 30(4): 1490-1495.  
Yan Guoqiang, Zhou Ningning, Zhang Shaobai. De-noising Method of EEG Signal Based on MMTD and Wavelet Hard-threshold[J]. *Journal of System Simulation*, 2018, 30(4): 1490-1495.
- [5] Zhang Yu, Wang Bei, Jing Jin, et al. A Comparison Study on Multidomain EEG Features for Sleep Stage Classification[J]. *Computational Intelligence and Neuroscience* (S1687-5265), 2017: 1-8.
- [6] Lin S, Guo S, Huang Z, et al. Determining AR order for BCI based on motor imagery[C]. *Biomedical Engineering and Informatics*. Shenyang: IEEE Press, 2015: 174-178.
- [7] Song Y J, Sepulveda F. A Novel Technique for Selecting EMG-Contaminated EEG Channels in Self-Paced Brain-Computer Interface Task Onset[J]. *IEEE Transactions on Neural Systems & Rehabilitation Engineering* (S1534-4320), 2018(99): 1.
- [8] 裴一飞, 杨淑娟. 运动想象脑电信号算法研究进展[J]. *北京生物医学工程*, 2018, 37(2): 208-214.  
Pei Yifei, Yang Shujuan. Research progress on motor imagery EEG signals[J]. *Beijing Biomedical Engineering*, 2018, 37(2): 208-214.
- [9] Wang L, Xu G, Wang J, et al. Motor Imagery BCI Research Based on Sample Entropy and SVM[C]. *International Conference on Electromagnetic Field Problems and Applications*. Dalian: IEEE Press, 2012: 1-4.
- [10] 孟建军, 盛鑫军, 姚林, 等. 基于共空域频谱模式的少通道运动想象分类[J]. *中国生物医学工程学报*, 2013, 32(5): 553-561.  
Meng Jianjun, Sheng Xinjun, Yao Lin, et al. Common Spatial Spectral Pattern for Motor Imagery Tasks in Small Channel Configuration[J]. *Chinese Journal of Biomedical Engineering*, 2013, 32(5): 553-561.
- [11] Tan C Q, Sun F C, Zhang W C, et al. Spatial and spectral features fusion for EEG classification during motor imagery in BCI[C]. *2017 IEEE EMBS International Conference on Biomedical Health Informatics (BHI)*. Orlando: IEEE Press, 2017: 309-312.
- [12] 王月茹, 李昕, 李红红, 等. 基于时-频-空间域的运动想象脑电信号特征提取方法研究[J]. *生物医学工程学杂志*, 2014, 31(5): 955-961.  
Wang Yueru, Li Xin, Li Honghong, et al. Feature Extraction of Motor Imagery Electroencephalography Based on Time-frequency-space Domainis[J]. *Journal of Biomedical Engineering*, 2014, 31(5): 955-961.
- [13] 徐宝国, 宋爱国, 费树岷. 在线脑机接口中脑电信号的特征提取与分类方法[J]. *电子学报*, 2011, 39(5): 1025-1030.  
Xu Baoguo, Song Aiguo, Fei Shumi. Feature Extraction and Classification of EEG in Online Brain-Computer Interface[J]. *Acta E1 Ecrromca Simca*, 2011, 39(5): 1025-1030.
- [14] Bhattacharyya S, Konar A, Tibarewala D N, et al. Performance analysis of ensemble methods for multi-class classification of motor imagery EEG signal[C]. *International Conference on Control Instrumentation Energy Communication*. Calcutta: IEEE Press, 2014: 712-716.
- [15] 李明爱, 杨林豹, 杨金福. 具有在线自学习能力的脑电信号分类方法[J]. *计算机测量与控制*, 2011, 19(11): 2763-2765, 2784.  
Li Mingai, Yang Linbao, Yang Jinfu. A online Self-learning Approach to EEG Classification[J]. *Computer Measurement & Control*, 2011, 19(11): 2763-2765, 2784.
- [16] Nicolasalonso L F, Corralejo R, Gomezpilar J, et al. Ensemble learning for classification of motor imagery tasks in multiclass brain computer interfaces[C]. *Computer Science and Electronic Engineering Conference*. Colchester: IEEE Press, 2014: 79-84.
- [17] 王夏爽, 龚光红, 李妮. 视觉诱发脑电信号的处理研究[J]. *系统仿真学报*, 2017, 29(增 1): 146-154.  
Wang Xiashuang, Gong Guanghong, Li Ni. Study and Processing of Visual Evoked EEG[J]. *Journal of System Simulation*, 2017, 29(S1): 146-154.
- [18] Kevric J, Subasi A. Comparison of signal decomposition methods in classification of EEG signals for motor-imagery BCI system[J]. *Biomedical Signal Processing and Control* (S1746-8094), 2017, 31: 398-406.
- [19] Jirayucharoensak S, Israsena P, Pannung S, et al. Online EEG artifact suppression for neurofeedback training systems[C]. *Biomedical Engineering International Conference*. Amphur Muang: IEEE Press, 2013: 1-5.
- [20] Hosseini M, Hajisami A, Pompili D, et al. Real-Time Epileptic Seizure Detection from EEG Signals via Random Subspace Ensemble Learning[C]. *International Conference on Autonomic Computing*. Wurzburg: IEEE Press, 2016: 209-218.