

# 基于多类运动想象任务的 EEG 信号分类研究

马满振, 郭理彬, 苏奎峰

(装甲兵工程学院 控制工程系, 北京 100072)

**摘要:** 针对多类运动想象脑电信号个体差异性强和分类正确率比较低的问题, 提出了一种时-空-频域相结合的脑电信号分析方法: 首先利用小波包对 EEG 原始信号进行分解, 根据 EEG 信号的频域分布提取出运动想象脑电节律, 通过“一对多”共空间模式 (CSP) 算法对不同运动想象任务的脑电节律进行空间滤波提取特征; 然后将特征向量输入到“一对多”模式下的支持向量机 (SVM) 中, 并利用判断决策函数值的方法对 SVM 的输出结果进行融合; 最后通过引入时间窗对脑电信号进行时域滤波, 消除运动想象开始和结束时脑电的波动, 进一步提高信号信噪比和算法的分类效果; 实验结果显示: 在时间窗为 2 s 时, 平均最大  $Kappa$  系数达到了 0.72, 比脑机接口竞赛第一名提高了 0.15, 验证了该算法能够有效减小脑电信号个体差异性影响, 提高多类识别正确率。

**关键词:** 脑机接口; 运动想象; 共空间模式; 支持向量机; 时间窗

## Research on EEG Signal Classification Based on Multi-class Motion Imagination Task

Ma Manzhen, Guo Libin, Su Kuifeng

(Department of Control Engineering, Academy of Armored Force Engineering, Beijing 100072, China)

**Abstract:** For the problem of the individual difference and the classification accuracy of multi-class motor imagery EEG signal, a new analysis method for EEG signal based on time-space-frequency domain is put forward: firstly, the wavelet packet is used to decompose the original signal of EEG, and the motor imagery EEG rhythm is extracted according to the frequency distribution of EEG signal, and the spatial features of EEG are extracted from different motor imagery tasks through the "one-to-rest" common space pattern (CSP) algorithm; then the feature vector is input to the support vector machine (SVM) in "one-to-rest" mode, the output value of SVM is fused via the method of judging the decision function value; finally, the time domain window is used to filter the EEG signals to eliminate the fluctuations of the brain at the beginning and end of motor imagery, and further improve the signal to noise ratio and the classification accuracy of the algorithm. The experimental results show that, when the time window is 2 s, the average maximum coefficient is 0.72, which is 0.15 higher than the first of BCI competition. Meanwhile, the results verify that the algorithm can effectively reduce the influences of the individual differences of EEG signals, and improve the accuracy of multi-class recognition.

**Keywords:** brain-computer interface (BCI); motor imagery; common spatial patterns (CSP); support vector machine (SVM); time window

## 0 引言

脑-机接口 (brain-computer interface, BCI) 是允许人脑与外部接口直接交流的一种系统。它通过实时测量与使用者意图相关的脑电 (electroencephalogram, EEG), 并将其转化为相应的控制信号, 从而达到对设备实时控制的目的<sup>[1]</sup>。目前, BCI 的研究不仅仅停留在助残服务、医疗康复相关领域, 已经拓展到智能家电、娱乐、航天以及军事等各个领域, 受到了世界范围内的广泛关注和研究。

基于运动想象 EEG 信号的 BCI 系统国内外已经进行了较多研究, 但对于多类运动想象任务的识别还存在个体差异性强、分类识别率不高、采集脑电导联数目过多以及算法实时性不好等问题, 导致了 BCI 在实际应用中进展缓慢。Luis F Nicolas-Alonso 等人<sup>[2]</sup>直接利用 CSP 提取特征, 通过谱回归

核判别分析对 4 类运动想象任务进行分类, 最高分类正确率达到了 94%,  $Kappa$  系数为 0.92, 但平均分类正确率只有 73%,  $Kappa$  系数为 0.64, 平均分类正确率较低, 实际应用的稳定性较差。Ghaehri H 等人<sup>[3]</sup>采用 CSP 对每个 EEG 信号时间段进行空间滤波提取特征, 利用 LDA 线性分类器进行分类, 分类正确率为 80%, 由于时域分析的时间太长, 导致算法实时性较差。王瑞敏等人<sup>[4]</sup>利用短时傅里叶变换将运动想象 EEG 信号进行多频段分解, 通过 CSP 结合 SVM 的方法对单个导联信号进行分类识别, 平均分类正确率仅为 65%, 且当导联数目减少时, 分类正确率会大幅降低。万柏坤等人<sup>[5]</sup>利用二维时频分析与 Fisher 分析相结合提取 4 类运动想象脑电特征, 使用 SVM 进行分类, 分类正确率达到了 85.71%, 实验中分析了 60 个导联的数据, 数据量大导致算法实时性不好, 实际应用价值较低。

针对多类运动想象脑电特征提取与分类识别效果不好的问题, 本文利用频域、空域、时域相结合的方法, 对 4 类运动想象 (左手、右手、双脚和舌头) 脑电信号进行分类识别。首先利用小波包对 EEG 原始信号进行分解, 根据 EEG 信号的频域分布提取出运动想象脑电节律, 提高信号信噪比; 利用“一对多”CSP 算法对 4 类运动想象任务的脑电节律进行空间滤波提

收稿日期: 2017-04-13; 修回日期: 2017-04-27。

**作者简介:** 马满振 (1994-), 男, 河北保定人, 硕士研究生, 主要从事模式识别与智能系统方向的研究。

苏奎峰 (1976-), 男, 河北承德人, 副教授, 硕士生导师, 主要从事自主车辆导航与控制, 多传感器信息融合方向的研究。

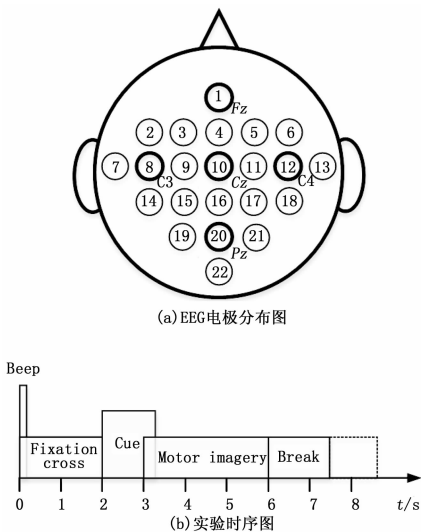
取特征; 在“一对多”模式下构建 4 个 SVM 子分类器, 利用判断决策函数值的方法对分类器的输出结果进行融合, 取得了较好的分类效果。通过引入时间窗对脑电信号进行时域滤波, 可有效消除运动想象开始和结束时脑电的波动, 进一步提高信号信噪比和算法的分类正确率。结合时一空一频域运动想象脑电信息利用“一对多”SVM 进行分类, 实验取得了很好的分类效果。

## 1 实验数据

### 1.1 实验数据来源

实验数据采用 2008 年第四届脑机接口竞赛提供的 Data sets 2a 的校准数据, 该实验采用 22 个电极记录脑电信号 (图 1 (a) 为电极分布图), 左乳突作为参考电极, 右乳突接地, 采样频率为 250 Hz, 所有数据都经过 0.5~100 Hz 的带通滤波和 50 Hz 的工频陷波。实验时受试者放松安静的坐在电脑前舒适的座椅上, 根据屏幕上出现的提示进行运动想象, 如图 1 (b) 所示, 每个实验周期分为以下几个环节:

- 1) 试验开始时计算机发出短促的声音, 同时屏幕上出现十字标志持续两秒, 提醒受试者注意;
- 2) 2 s 后, 屏幕上随机出现向左、向右、向上或向下的箭头 (分别对应左手、右手、舌头和双脚运动想象任务), 持续 1.25 s;
- 3) 3 s 后, 受试者根据箭头指向进行相应的运动想象任务, 持续 3 s;
- 4) 6 s 时屏幕上的十字标志消失, 受试者进入放松状态。



共有 9 名受试者 (受试 A01~A09) 参加了实验。每名受试者的实验分为两个阶段, 每个阶段进行 6 组试验, 每组包含 48 次运动想象任务, 共得到 288 个训练样本和 288 个测试样本。按照竞赛标准, 利用有效时间内误差最低的时间点的  $Kappa$  系数对分类算法进行评价。 $Kappa$  系数计算公式为:

$$Kappa = \frac{P - \frac{1}{C}}{1 - \frac{1}{C}} \quad (1)$$

$P$  为分类正确率,  $C$  为类别数。

### 1.2 实验数据预处理

人在放松清醒的状态下进行运动想象时, 在大脑的感觉运动皮层区域就会产生 8~12 Hz 的  $\mu$  节律和 18~26 Hz 的  $\beta$  节律脑电。人在进行单侧肢体运动想象时, 大脑中对侧的  $\mu$  节律和  $\beta$  节律会出现幅值衰减的现象, 这种现象被称为事件相关去同步 (event related desynchronization, ERD); 而大脑中同侧的  $\mu$  节律和  $\beta$  节律会出现幅值增强的现象, 这种现象被称为事件相关同步<sup>[6-7]</sup> (event related synchronization, ERS)。依据 ERD/ERS 现象, 利用小波包变换的多分辨率特性<sup>[8]</sup>, 选择 EEG 原始信号中的最佳分量组合关系, 从而可提取出包含有用信息频段的  $\mu$  节律和  $\beta$  节律。

提取出 9 名受试者的运动想象脑电信号, 即每个实验周期 3~6 s 的数据。采用 db4 小波基对信号进行小波包 3 层分解, 各个分量分解在同一水平, 且拥有相同的采样率和数据长度, 分解后得到 8 个频率成分。由于采样频率为 250 Hz, 根据 Nyquist 采样定理, 待分析的 EEG 信号频带宽为 125 Hz, 则每个子带重构信号的带宽为  $\Delta f = \frac{125 \text{ Hz}}{8} = 15.625 \text{ Hz}$ 。获得的小波包各个子带所对应的频率范围如表 1 所示。

表 1 各子带所对应的频率范围 Hz

子带	频率范围	子带	频率范围
(3,0)	0~15.625	(3,1)	15.625~31.25
(3,2)	31.25~46.875	(3,3)	46.875~62.5
(3,4)	62.5~78.125	(3,5)	78.125~93.75
(3,6)	93.75~109.375	(3,7)	109.375~125

从表 1 中可以看出,  $\mu$  节律脑电包含在小波包子带 (3, 0) 中,  $\beta$  节律脑电包含在小波包子带 (3, 1) 中。由于  $\mu$  节律的带宽较小, 子带带宽较大, 因此子带 (3, 0) 中信号的信噪比较低, 同时为了减小特征向量维数, 缩短计算时间, 只对信噪比较高的小波包子带 (3, 1) 进行重构, 提取  $\beta$  节律脑电, 作为后期运动想象脑电特征提取和分类的依据。图 3 为不同运动想象任务的小波包子带 (3, 1) 重构信号。




图 2 不同运动想象任务的小波包子带 (3, 1) 重构信号

## 2 基于改进 CSP 的多类特征提取

传统 CSP 算法适用于二分类问题, 通过两类数据的协方差矩阵同时对角化, 并应用主成分分析方法提取出两类数据的不同部分, 构建出最优的空间滤波器, 两类数据经过空间滤波

后, 其空间成分在能量上的差异达到最大, 即一类的方差最大化, 另一类的方差最小化, 从而有效提取出两类数据的特征<sup>[9]</sup>。

对于多类任务运动想象 EEG 信号的分类, 本文利用“一对多”的方法对 CSP 进行改进, 即把多类任务的特征提取问题转化为多个一类任务对其余所有任务的两类特征提取问题<sup>[10]</sup>, 对于  $N$  类任务可转化为  $N$  个一类对其余所有类别的两类问题。如图 3 所示为 4 类运动想象实验数据在“一对多”方法下完成 CSP 特征提取的流程。




图 3 “一对多”方法下的 CSP 特征提取

每一类运动想象任务都将除自身的其它 3 类看成一类, 形成 4 对两类问题, 利用 CSP 获得每对两类问题的投影模式 (分别为  $W_1$ 、 $W_2$ 、 $W_3$ 、 $W_4$ ), 利用 4 个投影模式分别对训练数据集和测试数据集进行空间滤波, 提取出“一对多”CSP 方法下的训练数据集特征  $f_{train}^{OVR} = (f_{train}^1, f_{train}^2, f_{train}^3, f_{train}^4)$  和测试数据集特征  $f_{test}^{OVR} = (f_{test}^1, f_{test}^2, f_{test}^3, f_{test}^4)$ 。具体算法步骤如下。

2.1 求 4 类任务的混合空间协方差矩阵

每类任务的单次实验 EEG 数据可表示为  $N \times T$  的矩阵  $E_i$ , 其中  $i$  表示第  $i$  类 ( $i \in 1, \dots, 4$ ),  $N$  是数据采集时的通道数,  $T$  是每一个通道的采样点数。EEG 数据的归一化空间协方差如式 (2) 所示:

$$C_i = \frac{E_i E_i^T}{tr(E_i E_i^T)} \quad (2)$$

$tr(\mathbf{X})$  表示矩阵  $\mathbf{X}$  对角线元素的和, 为了获得更好的空间滤波效果, 利用训练数据集求得每一类实验数据的平均归一化空间协方差矩阵  $\bar{C}_i$ 。根据式 (3) 得到 4 类任务的混合空间协方差矩阵  $\bar{C}$ 。

$$\bar{C} = \bar{C}_1 + \bar{C}_2 + \bar{C}_3 + \bar{C}_4 \quad (3)$$

2.2 应用主成分分析法, 求出白化值矩阵  $\mathbf{P}$

对混合空间协方差矩阵  $\bar{C}$  按式 (4) 进行特征值分解。

$$\bar{C} = U_c \lambda_c U_c^T \quad (4)$$

$U_c$  是矩阵  $\bar{C}$  的特征向量矩阵,  $\lambda_c$  是对应的特征值构成的对角阵。将特征值进行降序排列, 特征向量也重新排列, 使其与特征值对应, 则白化值矩阵为:

$$\mathbf{P} = \sqrt{\lambda_c^{-1}} U_c^T \quad (5)$$

2.3 构造空间滤波器

针对类 1 时, 利用白化值矩阵  $\mathbf{P}$  对协方差矩阵做如下

变换:

$$S_1 = P \bar{C}_1 P^T = B \lambda B^T$$

$$S_2 = P(\bar{C}_2 + \bar{C}_3 + \bar{C}_4) P^T = B(I - \lambda) B^T \quad (6)$$

$\mathbf{I}$  为单位矩阵, 由此可以发现,  $S_1$  最大特征值对应的特征向量是  $S_2$  最小特征值对应的特征向量; 反之,  $S_2$  最大特征值对应的特征向量是  $S_1$  最小特征值对应的特征向量。利用特征向量矩阵  $\mathbf{B}$  构造针对类 1 时的空间滤波器为:

$$W_1 = B^T P \quad (7)$$

同理, 可分别构造出针对其它三类的空间滤波器  $W_2$ 、 $W_3$ 、 $W_4$ 。

2.4 提取脑电特征

将单次实验数据  $E_i$  分别经过 4 组空间滤波器进行滤波,

$$Z_i = W_j E_i (i, j \in 1, \dots, 4) \quad (8)$$

按式 (8) 变换后, 求得单次实验数据的特征模式矩阵  $Z_i$ 。 $Z_i$  的每一个行向量对应一个通道的特征模式, 每个通道特征模式的方差可作为脑电特征, 本文为了解决脑电信号个体差异性大, 个别受试者脑电部分特征值波动剧烈的问题, 对特征值取对数运算, 求得用于分类的脑电特征。

$$f_i^j = \log\{\text{var}(Z_i^j)\} \quad (9)$$

将训练数据集和测试数据集分别经过 4 类空间滤波器进行空间滤波, 提取出“一对多”CSP 特征提取方式下训练数据集特征  $f_{train}^{OVR} = (f_{train}^1, f_{train}^2, f_{train}^3, f_{train}^4)$  和测试数据集特征  $f_{test}^{OVR} = (f_{test}^1, f_{test}^2, f_{test}^3, f_{test}^4)$ 。4 类任务的运动想象脑电特征分布如图 4 所示。




图 4 4 类运动想象脑电特征值分布

3 多类任务模式的分类

3.1 基于 SVM 的多类任务模式分类

支持向量机 (support vector machines, SVM) 是一种基于统计学习理论的机器学习方法, 它在解决小样本、非线性及高维模式识别中表现出很好的效果。SVM 的基本思想是: 通过非线性映射的方法将低维空间线性不可分的样本映射到高维特征空间, 通过构建特征空间中的最优分割超平面, 使机器学习器达到全局最优化, 并且在整个样本空间的期望风险以某个概率满足一定上界。如图 5 所示, 圆点和五角星分别代表两类样本,  $H$  为分类线,  $H_1$ 、 $H_2$  是分别为过各类中离分类线最近的样本且平行于分类线的直线,  $H_1$ 、 $H_2$  之间的距离叫做分类间隔 (margin)。最优分类线不但能正确分开两类, 同时要使分类间隔达到最大。

SVM 是一种典型的二分类器, 针对 4 类任务模式的分类问题采用“一对多”的分类方法需要构建 4 个子分类器  $\{f_i$ ,




图 5 最优超平面示意图

$f_2, f_3, f_4$ 。在对分类器  $f_i (i = 1, \dots, 4)$  进行训练时, 将第  $i$  类的数据作为正训练数据集, 其余 3 类数据作为负训练数据集, 训练后的分类器  $f_i$  可将属于第  $i$  类的数据和其余 3 类的数据分开。如图 6 所示, 本文利用判断决策数值的方法对 4 个子分类器的输出结果进行融合: 11 找到判定结果为正集的子分类器  $f_i$ ; 22 提取出这些子分类器进行判定的决策值  $D_i$ ; 33 比较这些决策值的绝对值大小, 将绝对值最大的子分类器输出为正集类别  $C_i$  作为最终的判定结果。




图 6 判断决策函数值方法的 4 类任务分类流程

由于每组数据提取到的特征包含 22 个特征点, 为了得到最佳的分类结果, 需要对特征向量维数进行选择。由于不同任务的 CSP 特征值分布在两端差异较大, 因此选择每组数据的前  $m$  个特征点和后  $m$  个特征点组成长度为  $2m$  的特征向量作为分类器的输入, 通过对比  $m$  (范围 1~11) 取不同值时的分类结果, 最终确定当  $m=5$  时分类效果最好。在“一对多”分类模式下, 利用训练数据集对每个 SVM 子分类器进行训练, 通过判断决策函数值的方法对测试数据集进行分类, 得到 9 名受试者的分类结果如表 2 所示。

表 2 BCI 竞赛前 3 名与本文方法的最大 Kappa 系数

方法	A01	A02	A03	A04	A05	A06	A07	A08	A09	平均值
第 1 名	0.68	0.42	0.75	0.48	0.40	0.27	0.77	0.75	0.61	0.57
第 2 名	0.69	0.34	0.71	0.44	0.16	0.21	0.66	0.73	0.69	0.52
第 3 名	0.38	0.18	0.48	0.33	0.07	0.14	0.29	0.49	0.44	0.31
SVM/OVR	0.82	0.65	0.84	0.53	0.43	0.48	0.81	0.69	0.54	0.64

分析表 2 可以得到: 利用判断决策函数值的方法对“一对多”模式下的 CSP 特征进行分类时, 受试者 A01、A03、A07 的最大 Kappa 系数均大于 0.8, 得到了较好的分类效果; 受试者 A05、A06 的分类效果较差, 最大 Kappa 系数低于 0.5, 可能是由于脑电信号存在很强的个体差异性, 该受试者的脑电特征相比于其他受试者不显著; 9 名受试者的平均 Kappa 系数达到了 0.64, 高于竞赛第 1 名 0.07。

### 3.2 基于不同时间窗的运动想象任务分类

考虑到每名受试者的运动想象时间为 3 s, 在运动想象开始和结束时都存在受试者的思维转换和思维延迟问题, 导致运动想象脑电在每个周期的开始和结束时会产生较大波动, 降低

了信号的信噪比, 从而影响了特征提取和分类识别的效果。针对该问题, 可利用时间窗的方法消除运动想象开始和结束时脑电的波动。实验将时间窗设为 0.5 s、1 s、1.5 s、2 s、2.5 s 五种情况, 截取 3 s 运动想象数据的中间部分, 提取出每种情况的“一对多”CSP 特征, 通过多任务模式的 SVM 分类器对 9 名受试者的数据进行分类, 分类结果如图 7 所示。




图 7 9 名受试者在不同时间窗下的最大 Kappa 系数

由图 7 可看出: 11 时间窗设为 2.5 s 时, 除受试者 A06、A08 的其余 6 名受试者的最大 Kappa 系数均有所提高; 时间窗设为 2 s 时, 9 名受试者的最大 Kappa 系数均达到了最大值, 9 名受试者的平均 Kappa 系数达到了 0.72, 明显优于时间窗为 3 s 时的分类结果, 验证了时间窗的设置, 可有效消除运动想象开始和结束时脑电的波动, 进一步提高了运动想象脑电特征提取的效果和分类识别的正确率。22 时间窗小于 2 s 时, 每名受试者的最大 Kappa 系数均有所降低; 当时间窗为 0.5 s 时, 除受试者 A09 外, 8 名受试者的最大 Kappa 系数均低于 3 s 时间窗, 说明当时间窗太小时, 在消除脑电波动的同时也会丢失大量运动想象有用信息, 导致分类正确率不高。综合以上, 时间窗设为 2 s 时, 在消除脑电波动的同时可保留运动想象主要信息, 分类效果达到最好。

## 4 结论

本文利用小波包对 9 名受试者的运动想象脑电信号进行预处理, 提取脑电  $\beta$  节律, 有效地消除了原始 EEG 信号中的大量频域噪声, 提高了 EEG 信噪比。通过“一对多”CSP 算法对 4 类运动想象脑电信号进行空间滤波提取特征, 将特征向量作为“一对多”模式下 4 个 SVM 子分类器的输入, 在分类器输出端利用判断决策函数值的方法对 4 个子分类器的输出结果进行融合, 得到了较好的分类结果。通过对数据设置时间窗的方法有效的消除了运动想象开始和结束时脑电的波动, 进一步提高了信号信噪比和算法的分类正确率。本文方法充分结合了脑电信号的频域、空域、时域信息, 有效的改善了多类运动想象脑电信号个体差异性强和分类正确率较低的问题, 为多类运动想象任务的特征提取与分类提供了新的思路。

### 参考文献:

[1] Daly L, Muller-Putz G, et al. Fully online and automated artifact removal for brain-computer interfacing [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2015, 23 (5): 725-736.




图 1 被攻陷的网络节点和被攻陷节点占有所有节点比例关系




图 3 物联网密钥认证成功功率与节点数量关系

是最为安全的, 在这种情况下使用 LHKE 算法完成密钥树内部共享的密钥的转换与传递, 可以保证低数据下物联网密钥的安全性, 并防止物联网网络节点攻陷过多对物联网造成的影响。为了保证信息的安全性, 引入了非对称的认证协议, 使得物联网网络信息传输的安全性得到有效的改善。图 2 为引入非对称的认证协议后 LHKE 算法的安全性。当移动节点增多时, 对低数据环境下物联网密钥管理的影响, 如图 2 所示。




图 2 物联网密钥认证成功功率与节点移动速度关系

在低数据环境下保证物联网密钥的安全性的前提下, 将对物联网密钥的可靠性进行实验。在相同的实验环境下进行实验。物联网密钥的可靠性即物联网认证性能, 假设该算法认证成功概率为  $P(E)$ , 即物联网认证性能的公式为:

$$P(E) = N_s / N_b \tag{17}$$

其中:  $N_s$  为已认证的物联网网络节点;  $N_b$  是待认证的物联网网络节点。并将所有实验数据进行整理, 整理后的结果如图 3 所示, 从图 3 可以看出, 网络节点数量的增加使物联网密钥认证的成功率下降, 但对物联网密钥可靠性的影响并不大。由此说明该算法有效地提高了低数据环境下物联网密钥的可靠性与安全性。

### 3 结论

针对当前算法在低数据量环境下管理物联网密钥时, 无法安全可靠的管理物联网数据。提出一种基于 LHKE 的低数据量环境物联网密钥管理算法与设计。仿真实验结果表明, 所提算法提高了低数据量环境下物联网密钥的安全性及可靠性。

#### 参考文献:

- [1] 曾 萍, 张 历, 杨亚涛, 等. 一种基于 HECRT 的物联网密钥管理方案 [J]. 计算机工程, 2014, 40 (8): 27-32.
- [2] 沈海波, 陈勇昌. 联邦物联网中的认证机制研究 [J]. 计算机工程, 2016, 42 (9): 110-115.
- [3] 朱坤崧, 戴紫彬, 张立朝, 等. 面向物联网的 SM4 算法轻量级实现 [J]. 电子技术应用, 2016, 42 (12): 27-30.
- [4] 钱晓军, 范冬萍, 吉根林. 物联网环境下实时任务传输的分簇调度算法 [J]. 计算机科学, 2016, 43 (11): 176-179.
- [5] 张子木. 物联网接入技术研究与系统设计 [J]. 电子设计工程, 2016, 24 (2): 157-160.
- [6] 陈 昊, 黄海平. 基于节点间信任评估算法的无线传感器网络密钥管理方案 [J]. 计算机科学, 2015, 42 (s1): 395-398.
- [7] 王 刚, 孙良旭, 曾子维, 等. 一种非对等无线传感器网络环境中安全高效的混合密钥管理机制 [J]. 计算机科学, 2016, 43 (7): 153-156.
- [8] 闫玺玺, 胡前伟, 魏文燕, 等. 外包环境中一种支持数据完整性验证的密钥管理方案 [J]. 小型微型计算机系统, 2016, 37 (12): 2654-2659.
- [9] 周大伟, 魏国珩, 张焕国. 基于无证书公钥体制的层簇式 WSN 密钥管理方案 [J]. 北京工业大学学报, 2016, 42 (5): 707-712.
- [10] 任炯炯, 陈少真. 11 轮 3D 密码算法的中间相遇攻击 [J]. 通信学报, 2015, 36 (8): 182-191.

(上接第 235 页)

- [2] Luis F. Alonso N, Corralejo R, et al. Adaptive semi-supervised classification to reduce intersession non-stationarity in multiclass motor imagery-based brain-computer interfaces [J]. Neurocomputing, 2015, 159: 186-196.
- [3] Ghaheri H, Ahmadyfard A R. Extracting common spatial patterns from EEG time segments for classifying motor imagery classes in a brain computer interface (BCI) [J]. Scientia Iranica D, 2013, 20 (6): 2061-2072.
- [4] Ge S, Wang R, Yu D. Classification of Four-Class Motor Imagery Employing Single-Channel Electroencephalography [J]. Plos One, 2014, 9 (6): e98019.
- [5] 万柏坤, 刘延刚, 明 东, 等. 基于脑电特征的多模式想象动作识别 [J]. 天津大学学报, 2010, 43 (10): 895-890.

- [6] 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.
- [7] 李明爱, 刘净瑜, 郝冬梅. 基于改进 CSP 算法的运动想象脑电信号识别方法 [J]. 中国生物医学工程学报, 2009, 28 (2): 161-165.
- [8] 李明爱, 林 琳, 杨金福. 基于小波包最优基的运动想象 EEG 自适应特征提取方法 [J]. 计算机测量与控制, 2011, 19 (11): 2755-2758.
- [9] 叶 柠, 孙宇舸, 王 旭. 基于共空间模式和神经网络的脑-机接口信号的识别 [J]. 东北大学学报, 2010, 31 (1): 12-15.
- [10] 刘 冲, 王 宏, 赵海滨, 等. 基于多类运动想象任务的脑电信号分类研究 [J]. 生物医学工程学报, 2012, 29 (6): 1027-1031.