

Bagging RCSP 脑电特征提取算法

张毅¹ 尹春林² 蔡军² 罗久飞¹

摘要 正则化共空间模式 (Regularized common spatial pattern, RCSP) 解决了共空间模式 (Common spatial pattern, CSP) 对噪声敏感的问题, 但它在小样本脑电数据集中的表现并不理想. 针对上述问题, 本文提出了 Bagging RCSP (BRCSP) 算法, 通过 Bagging 方法重复选取训练数据来构造一个个包, 并提取 RCSP 特征, 再利用线性判别分析 (Linear discriminant analysis, LDA) 将特征向量映射到低维空间中, 最后采用最近邻 (Nearest neighborhood classifier, NNC) 算法判定分类结果. 线下实验证明, 相比较聚合正则化共空间模式 (RCSP with aggregation, RCSP-A), BRCSP 的平均准确率提高了 2.92%, 且方差更小, 鲁棒性更好. 最后, 在智能轮椅平台上, 10 位受试者利用 BRCSP 算法实现左右手运动想象脑电信号控制轮椅完成“8”字形路径的实验, 证明了该算法在脑电信号特征提取中的有效性.

关键词 脑电信号, 特征提取, RCSP-A, Bagging RCSP

引用格式 张毅, 尹春林, 蔡军, 罗久飞. Bagging RCSP 脑电特征提取算法. 自动化学报, 2017, 43(11): 2044–2050

DOI 10.16383/j.aas.2017.c160094

Bagging RCSP Algorithm for Extracting EEG Feature

ZHANG Yi¹ YIN Chun-Lin² CAI Jun² LUO Jiu-Fei¹

Abstract The regularized common spatial pattern (RCSP) has solved the problem that the common spatial pattern (CSP) is sensitive to noise. However, its performance on small sample of electro encephalon graph (EEG) data set is not ideal. To deal with this problem, a Bagging RCSP (BRCSP) algorithm is proposed, which divides training samples into packets and extracts RCSP features by Bagging to choose training packets. Furthermore, the feature vector is projected into the lower space with linear discriminant analysis (LDA) and a classification algorithm based on nearest neighborhood classifier (NNC) is adopted. Compared to RCSP with aggregation (RCSP-A), the accuracy of BRCSP increases by 2.92% in average and the variance is smaller and has better robustness. Results of the experiment, in which 10 subjects control an intelligent wheelchair of a fixed “8” glyph trajectory, demonstrate that the BRCSP is effective in the EEG feature extraction.

Key words Electro encephalon graph (EEG), feature extraction, RCSP-A, Bagging RCSP

Citation Zhang Yi, Yin Chun-Lin, Cai Jun, Luo Jiu-Fei. Bagging RCSP algorithm for extracting EEG feature. *Acta Automatica Sinica*, 2017, 43(11): 2044–2050

脑-机接口 (Brain-computer interface, BCI) 系统利用电生理信号, 将用户的意图解码为控制命令来操纵设备^[1]. 根据获取用户的思维意图的方式不同, 脑电信号分为脑电 (Electrocorticogram, ECoG)、电脑图 (Electro encephalon graph, EEG)、脑磁图 (Magnetoencephalogram, MEG) 和功能磁共振成像 (Functional magnetic resonance imag-

ing, FMRI) 等^[2]. 在这些信号中, EEG 脑电信号因其非入侵性和低成本的特点而广受关注, 很多脑-机接口系统都是采用 EEG 脑电信号进行研究^[3].

当前在基于 EEG 脑电信号的 BCI 研究主要集中于运动想象脑电信号方面. 运动想象是通过“想”的方式来产生相关信号, 对运动想象的研究表明, 单侧肢体运动或者想象运动会对 α 波 (8~13 Hz) 和 β 波 (14~30 Hz) 的节奏活动和功率谱产生抑制/增强的效果, 即事件相关去同步/同步 (Event related desynchronization (ERD)/Event related synchronization (ERS)) 现象^[4]. 根据这一现象, 迄今为止研究者们已经提出了许多特征提取方法, 例如 AR 模型^[5]、Wavelet 变换^[6]、希伯特黄变换 (Hilbert-Huang transform, HHT)^[7] 和 CSP 等. 近些年, 共空间模式 (Common spatial pattern, CSP) 被证明是一种提取不同类型的运动想象信息的有效方法, 该方法的关键在于联合对角化协方差矩阵. 即通过数学变换, 使得一类的方差最大化, 另一类的方差最小化.

收稿日期 2016-01-27 录用日期 2017-02-13
Manuscript received January 27, 2016; accepted February 13, 2017

重庆市科学技术委员会项目 (cstc2015jcyjBX0066, cstc2017jcyjAX0033), 重庆市教委科学技术项目 (KJ1600428) 资助
Supported by Chongqing Science and Technology Commission Project (cstc2015jcyjBX0066, cstc2017jcyjAX0033) and Chongqing Municipal Education Commission (KJ1600428)

本文责任编辑 赵新刚

Recommended by Associate Editor ZHAO Xin-Gang

1. 重庆邮电大学先进制造工程学院 重庆 400065 2. 重庆邮电大学自动化学院 重庆 400065

1. School of Advanced Manufacturing Engineering, Chongqing University of Posts and Telecommunications, Chongqing 400065
2. School of Automation, Chongqing University of Posts and Telecommunications, Chongqing 400065

CSP 方法的主要问题是噪声非常敏感^[8]. 因此, 基于 CSP 的衍生方法层出不穷, 例如复合共空间模式 (Composite common spatial pattern, CCSP)^[9]、空间稀疏共空间模式 (Spatially sparsed common spatial pattern, SSCSP)^[10]、正则化共空间模式 (Regularized common spatial pattern, RCSP)^[11]、正则化集成滤波器共空间模式 (Filter ensemble regularized common spatial pattern, FERCSPP)^[12] 和滤波器组公共空间模式 (Filter bank common spatial pattern, FBCSP)^[13]. 其中, 最有效方法是正则化共空间模式 (Regularized common spatial pattern, RCSP)^[11]. 该方法借助迁移学习的思想, 将其他被试的脑电信号引入到 CSP 学习过程中, 保证了被试的脑电信号协方差的估计偏差, 使之相较于传统的 CSP 方法表现更好, 在小训练样本集中这一点表现的尤为突出^[11], 然而, 这种算法在小样本脑电数据集中的稳定性还有待提高, 且随着训练样本的增加, 其分类准确率增长缓慢, 时间复杂度上升.

为此, 本文提出了一种 Bagging RCSP 算法, 该算法通过重复选取样本构造数据包, 并利用每个数据包分别对样本提取 RCSP 特征. 通过与包括 RCSP 在内的 CSP 衍生算法进行分析比较, 结果表明, Bagging RCSP 在时间复杂度较低的情况下, 能保持较高的识别率和稳定性, 优于 RCSP 及 CSP 的其他衍生算法. 最后, 在智能轮椅平台上对 Bagging RCSP 算法进行验证, 进一步说明该算法在脑电信号特征提取中的有效性.

1 Bagging RCSP 算法

Bagging RCSP 算法延续 RCSP-A (RCSP with aggregation) 算法中的迁移学习的思想, 在估计被试者的协方差矩阵时引入了他人的数据, 意图在保持个体差异性的同时能找寻共有的特征. 原始的 RCSP 算法在小样本脑电数据上稳定性不够高, 且随着训练数据的增加, 分类准确率增长缓慢. 若只是在此基础上增加训练样本的数据, 随之而来的是大数据带来的时间复杂度上升的问题. Bagging RCSP 正是基于这些原因, 利用 Bagging 思想, 通过重复选取训练样本的方法, 将训练数据构成一个个数据包, 在后续的 RCSP 基本算法中计算被试者的协方差矩阵时引入一部分其他人的脑电信号, 然后利用这个协方差矩阵提取 RCSP 特征, 最后决策是通过投票的方式获得最终分类结果. 基于 Bagging RCSP 的左右手运动想象脑电信号处理过程如图 1.

1) 基于被试者脑电信号的协方差矩阵

对于某一个被试者, 协方差矩阵计算方式如下: 单次脑电信号由矩阵 $D_{N \times T}$ 表示, 其中 N 代表通道

数量, T 代表每个通道的采样点数. 经过归一化后的协方差矩阵为

$$C = \frac{DD^T}{\text{tr}(DD^T)} \quad (1)$$

其中, $\text{tr}(DD^T)$ 为矩阵 DD^T 的迹. 则平均协方差为

$$\bar{C}_i = \frac{1}{M} \sum_{m=1}^M C_{\{i,m\}} \quad (2)$$

其中, M 是训练数据的数量, i 指的是运动想象信号的类别, 本文为左、右手想象运动.

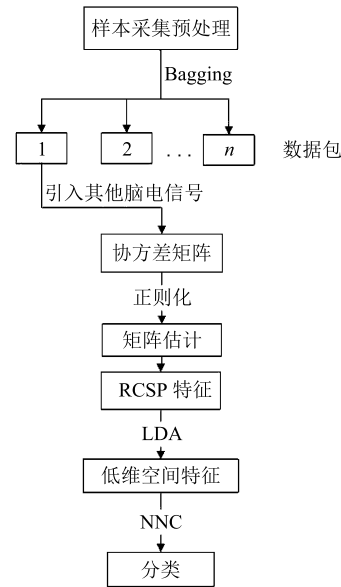


图 1 基于 Bagging RCSP 的左右手运动想象脑电信号处理过程

Fig. 1 The process of EEG induced by the left hand and right hand motor imagery based on Bagging RCSP

2) 正则化的协方差矩阵估计

在小样本估计问题中, 正则化是一种非常有效的方法. RCSP 正是基于这一方法, 通过偏置估计项的方式, 使分类结果不依赖于采样样本, 而是朝着一个更加合理的方向. 在处理“方差-偏差”窘境问题时, 该算法通过增大偏差而减小方差的方式实现. 这种“方差-偏差”平衡是由一个或多个正则化参数来调控. 为了减少协方差矩阵估计的偏差, RCSP 不仅利用该被试者的脑电信号, 还引入其他个体的脑电数据^[11]. 通过 RCSP 计算各类正则化平均空间协方差矩阵为

$$S_i(\beta, \gamma) = (1 - \gamma)X_i(\beta) + \frac{\gamma}{N} \text{tr}(X_i(\beta)) \times I \quad (3)$$

其中, β 和 γ 是两个正则化参数 ($0 \leq \beta, \gamma \leq 1$), β 控制着训练样本协方差矩阵的权重来减少协方差矩

阵估计的偏差, 而 γ 控制着多个单位矩阵的权重, I 是一个 $N \times N$ 的单位矩阵, $X_i(\beta)$ 为特定被试及其他受试者的脑电样本的协方差矩阵, 其定义为

$$X_i(\beta) = \frac{(1 - \beta) \times C_i + \beta \times C_i'}{(1 - \beta) \times M + \beta \times M'} \quad (4)$$

其中, C_i 是受试者第 i 类的 M 个训练数据组成的协方差矩阵, C_i' 是其他人第 i 类的 M' 个训练数据组成的协方差矩阵, 旨在减少协方差矩阵估计的方差, 它往往会产生更可靠的结果. 在一个特定个体的脑电信号分类中, 提出的训练过程使用其他受试者的相关样本构造了一个正则化项 C_i' , 且这些相关样本都是通用的. 若有 N 个受试者, 每类有 M 个训练样本, 则 $M' = (N - 1)M$.

3) Bagging RCSP 的特征提取和分类
受 CSP 启发, 协方差矩阵分解得

$$S(\beta, \gamma) = S_{\text{left}}(\beta, \gamma) + S_{\text{right}}(\beta, \gamma) = EVE^T \quad (5)$$

其中, E 是与特征值矩阵 V 对应的特征向量矩阵. 构造白化矩阵

$$P = V^{\frac{1}{2}}E^T \quad (6)$$

而

$$P \times S(\beta, \gamma) \times P^T = c \times I \quad (7)$$

其中, c 为一个常数. 因此, $S_{\text{left}}(\beta, \gamma)$ 和 $S_{\text{right}}(\beta, \gamma)$ 的特征向量相同, 并且对于特征向量, 二者对应的特征值之和为一个固定常数. 若

$$\begin{aligned} S_{\text{left}}(\beta, \gamma) &= UV_{\text{left}}U^T \\ S_{\text{right}}(\beta, \gamma) &= UV_{\text{right}}U^T \end{aligned} \quad (8)$$

则可得投影矩阵 $W = U^T P$.

与 CSP 类似, RCSP 选择 W 的前后各 r 列来映射一个训练样本 D .

$$Z = WD \quad (9)$$

那么分类的特征向量 y 为

$$y_q = \log \left(\frac{\text{var}(z_q)}{\sum_{q=1}^{2r} \text{var}(z_q)} \right) \quad (10)$$

再使用 LDA 将特征向量映射到低维空间, 最后采用基于 NNC 的分类算法区分左右手想象运动.

2 线下实验

2.1 基于 BCI Competition III 的数据集 IVa 的线下实验

本文在 BCI Competition III 的数据集 IVa^[14] 做了离线实验. 该数据集记录了 5 个健康的受试者 (aa, al, av, aw, ay) 想象运动的脑电数据. 实验中, 用于表示以下 2 类运动想象信号左手 (L)、脚 (F) 的视觉提示箭头显示 3.5 s^[14-15], 采集设备的采样频率为 100 Hz (原设备采样率是 1000 Hz, 但提供的数据做了降采样处理). 根据竞赛规则, 每位被试者均参与了训练和测试两个数据集的构建, 两个数据集每类各有 140 个样本. 鉴于这个数据集的目的是为了测试算法在小训练集中的性能, 5 位被试者分别提供 168, 224, 84, 56, 28 个样本进行训练, 剩下的 840 个样本用于测试. 一般情况下, 分类精度与训练样本数量是正相关的^[11]. 然而, 大规模训练样本将增加时间和空间的复杂性, 限制其实际应用. 最重要的是, 当训练规模接近极限的时候, 识别率提高得并不明显. 具体而言, 当训练样本从 40 增加到 120 时, 平均识别率仅提高了 1.9%. 而把大量训练样本分成一个个小包, 并通过提取 RCSP 特征来选择数据并预测结果, 则是一个明智的方法. 本文比较了 CSP, LW-CSP, SSCSP, RCSP-A, FERCSPP, BRCSPP 几种方法在“BCI Competition III”的数据集 IVa 上的识别率及耗时, 结果见表 1. 其中, 耗时指的是来自 5 位受试者的 840 个测试样本特征提取并分类的总耗时.

表 1 CSP、RCSP 和 Bagging RCSP 在 BCI Competition III 数据集 IVa 上的识别率比较 (%)

Table 1 The recognition rate comparison of CSP, RCSP and Bagging RCSP on Competition III data set IVa (%)

算法	aa	al	av	aw	ay	平均	耗时 (s)
CSP	66.1	98.2	59.2	88.4	61.1	74.6	5.5
LW-CSP	69.6	100.0	56.6	93.3	67.1	77.3	17.6
SSCSP	73.2	96.4	54.8	70.5	73.4	73.5	6.7
RCSP-A	76.8	98.2	74.5	92.9	77.0	83.9	62.2
FERCSPP	79.5	96.4	77.6	94.2	82.5	86.0	300.3
BRCSPP	79.3	98.6	78.3	92.9	82.5	86.3	63.3

对上述 6 种算法做 One-way ANOVA, 在方差齐性检验中, sig. 为 0.141, 大于 0.05, 表明数据满足方差齐性; 在识别率的两两比较中, CSP, LW-CSP, SSCSP 3 种算法分别与 RCSP-A, FERCS, BRCSP 的 sig. 均小于 0.05, 表明后 3 种算法与前 3 种算法提取脑电特征方法不同, 对识别率有显著影响; 在耗时的两两比较上, RCSP-A 和 BRCSP 分别与 CSP, LW-CSP, SSCSP, FERCS 4 种算法的 sig. 小于 0.05, 方法不同, 对耗时影响显著. 一方面, 本文比较了传统的 CSP, RCSP-A, Bagging RCSP 以及其他主流方法在测试集上的平均识别率, FERCS 与 Bagging RCSP 高于其他方法, 然而, BRCSP 极大地增加了特征提取所耗费的时间. 另一方面, 考虑到脑电信号处理的耗时问题, 基于 RCSP-A 和 Bagging RCSP 优于绝大多数的 CSP 方法, 且在与 RCSP-A (RCSP with aggregation) 比较中, 两者耗时最短, 但 Bagging RCSP 的平均正确率更高. 综上所述, RCSP-A 和 BRCSP 优于其他 CSP 衍生算法.

2.2 基于左右手运动想象数据集的线下实验

从表 1 的结果得出, 基于 RCSP-A 和 Bagging RCSP 优于绝大多数的 CSP 方法, 本文采用这两种方法在 10 位受试者采集的左右手想象运动数据集上做了离线实验. 想象左手运动和想象右手运动脑电数据来自 Emotiv 所有通道. 本文设定了采集信号的单次实验过程如图 2 所示, 具体实验过程为:




图 2 单个信号采集过程

Fig. 2 The process of signal sampling

1) 在实验开始 ($t = 0$ s) 时, 受试者处于放松状态, 静坐于椅子上;

2) 当 $t = 2$ s 时, 将有一个短促的提示声, 提醒受试者开始执行相应的实验任务 (想象左手运动和想象右手运动);

3) 在 $t = 6$ s 时, 会有一个停止的提示声, 受试者停止相应动作的实验任务, 在经过短暂的休息之后继续下次实验.

本文随机选取 25 岁左右、身体健康的 10 名受试者来完成实验数据的采集. 1) 让每位受试者熟悉信号采集的单个试验过程, 并知晓信号采集过程中的注意事项; 2) 每位受试者通过 Emotiv 传感器对左右手运动想象脑电信号分别进行 10 分钟的训练; 3) 每位受试者执行相应的特定动作任务并采集左右

手运动想象脑电信号, 并用 TestBench 软件保存采集的信号. 每位受试者针对每一类特定动作任务要进行 40 次实验. Emotiv 的采样频率为 128 Hz, 本文的每类信号只选取单次实验过程中第 2~6 s 间的数据, 即 4 s 的数据, 这样就有 512 个数据点. 把采集到的两类信号合成为一个样本, 建立的实验数据集共有 800 个样本. 利用 RCSP-A 和 Bagging RCSP 算法分别对左右手运动想象脑电信号进行特征提取. 根据式 (10), 本文基于 Bagging RCSP 算法进一步提取左右手运动想象脑电信号特征. 图 3 给出了其中一名受试者的左右手运动想象脑电信号的特征值分布. 再用 LDA 将提取的高维特征向量映射到低维空间, 最后采用基于 NNC 的分类算法进行分类, 得到 10 位受试者在两种算法下的识别率、平均识别率及方差, 见表 2.




图 3 左右手运动想象脑电信号的特征值分布

Fig. 3 The distribution of eigenvalue of EEG induced by the left hand and right hand motor imagery

表 2 RCSP-A 和 BRCSP 算法下的离线识别率 (%)

Table 2 The recognition rate of off-line based on RCSP-A and BRCSP (%)

受试者	RCSP-A	BRCSP
A1	80.53	86.16
A2	95.81	93.04
A3	75.56	81.08
A4	84.74	87.56
A5	78.06	83.61
A6	87.78	90.56
A7	84.72	87.50
A8	93.83	96.06
A9	85.42	87.56
A10	76.29	78.78

由图 3 可以看出, 经过特征提取后, 左右手运动想象脑电信号具有很好的可分性, 图 3 给出的是其中二维特征的分布图. Bagging RCSP 算法是在 RCSP 算法引入其他个体的脑电数据来减少协方差矩阵估计的偏差的基础上, 重复选取 5 次样本, 提取出鲁棒性较强的左右手运动想象脑电特征, 更具可分性.

表 2 显示了基于 RCSP-A 和 Bagging RCSP 算法对 10 位受试者的运动想象脑电数据特征提取后的识别结果, 使用统计分析中的 Paired-sample t-test, 结果见表 3.

表 3 RCSP-A 和 BRCSP 算法的 t-test 结果
Table 3 The result of t-test based on RCSP-A and BRCSP

	RCSP-A	BRCSP
均值	0.842740	0.871910
标准差	0.0691799	0.0523412
相关系数	0.955	
t	-3.741	
df	9	
sig. (双侧)	0.005	

从 t-test 结果得出, RCSP-A 做特征提取后的分类准确率平均值为 84.274%, Bagging RCSP 的分类准确率平均值为 87.191%, 其相关系数为 0.955. 取检验水平 $\alpha = 0.05$, 其双侧检验 $P = 0.005$, 趋近于 0, 说明基于 RCSP-A 和 Bagging RCSP 两种算法的分类准确率有显著的差异. 相比较 RCSP-A, Bagging RCSP 的平均准确率提高了 2.92%, 且标准差更小, 鲁棒性更好, 说明该方法在脑电信号特征提取方面优于其他 CSP 衍生算法.

3 线上实验

为了进一步验证 Bagging RCSP 算法的有效性, 在智能轮椅平台上进行了肌电信号辅助的试验. 采用可同时采集脑电信号和肌电信号的 Emotiv 传感器作为信号采集设备, 将双击咬牙、想象左手运动和想象右手运动作为三类特定动作信号. 该系统利用肌电信号控制轮椅行走状态, 利用左右手运动想象脑电信号控制轮椅方向. 在轮椅的方向控制中, EEG 先经过 0.1~30 Hz 的滤波器, 然后通过 Bagging RCSP 算法提取脑电信号中的有用信息, 再使用 LDA 将特征向量映射到低维空间, 最后采用基于 NNC 的分类算法区分左右手想象运动, 并转化为控制命令改变轮椅运动的方向. 该 BCI 系统主要由信号采集设备、信号处理和智能轮椅组成, 其结构如图 4 所示. 本文的信号采集设备 Emotiv 传感器有 16 个电极, 其中 2 个电极为参考电极, 14 个为采样电极, 采样频率为 128 Hz, 该传感器按照国际 10~20

标准电极安放法进行电极安放, 电极安放位置如图 5 所示.



Fig. 4 BCI system architecture




Fig. 5 Distribution of electrodes

通过让 10 位受试者使用基于 RCSP-A 的人机交互系统和基于 Bagging RCSP 的人机交互系统在轮椅平台上进行重复性实验, 完成如图 6 指定的 8 字形路线. 从图 6 可以看出, 在平地左右两边各放置一障碍物, 受试者从起点出发, 在轮椅以 0.15 m/s 前进的设定下, 通过想象左右手运动控制轮椅方向和双击咬牙控制轮椅停止, 依次绕过左右两边的障碍物. 与其他在线系统一样, 该控制命令取决于用户的思维活动^[16-17].

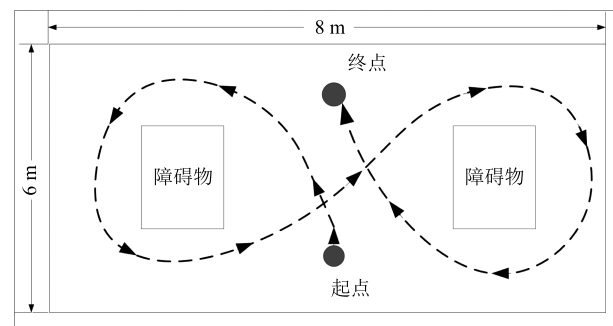


图 6 实验路径

Fig. 6 The experimental route

图 7 为 10 位受试者分别在基于 RCSP-A 和 Bagging RCSP 两种方法下, 控制智能轮椅走出的 8

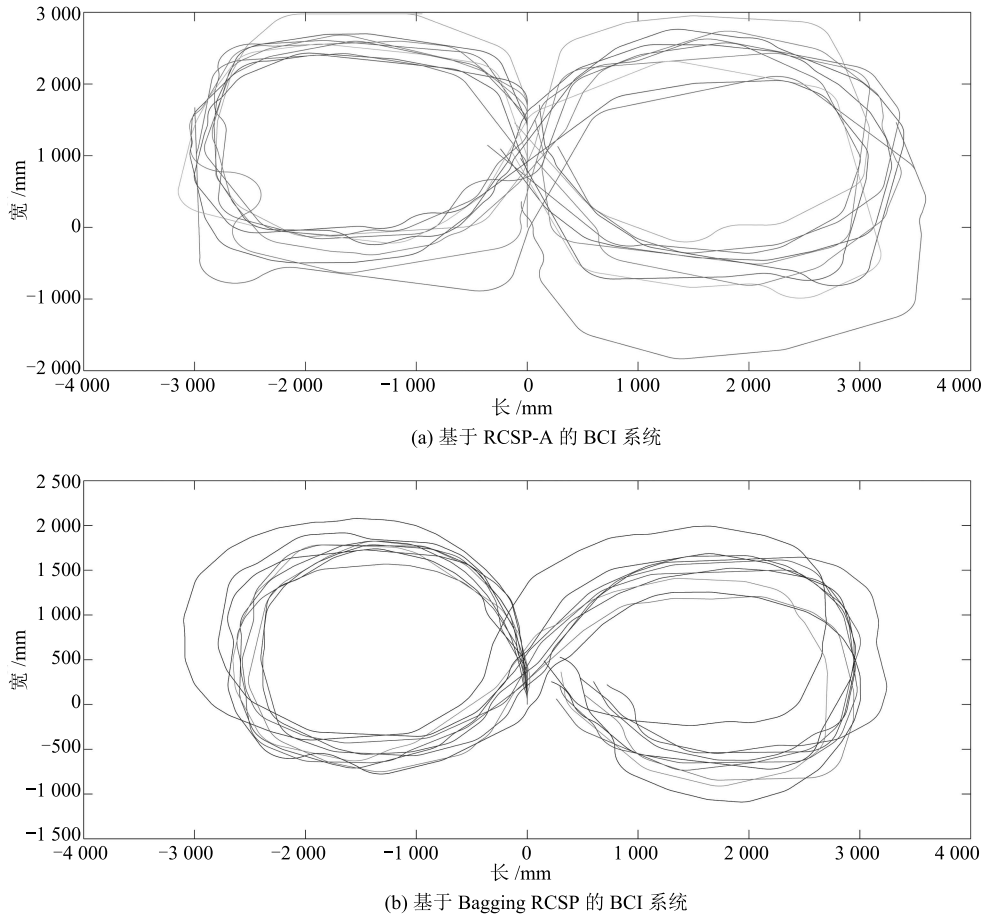


图 7 基于两种方法的 BCI 系统轨迹

Fig. 7 The wheelchair track of two kinds of BCI system

字形轨迹, 两种控制方法均能完成规定路径上的实验. 由图 7(b) 可知, 在基于 Bagging RCSP 的人机交互系统下, 受试者都能够安全平滑地完成指定路线, 但 8 字形右边没有左边顺滑, 因为受试者在左右手运动想象过程中需要高度集中注意力, 易产生疲劳使得脑电信号特征值发生变化^[18-19], 稳定性降低, 导致一些信号的误识别, 这一点从图 7(a) 左右两边轨迹对比中亦可看出. 从图 7(a) 可以看出, 虽然基于 RCSP-A 的人机交互系统也能完成指定路线, 但与 Bagging RCSP 相比, 其轨迹曲线出现较大的波动且不光滑, 轮椅开始原地打转、向非意识方向运动. 这是因为 RCSP 算法虽然引入了其他受试者的脑电数据, 减少了协方差矩阵估计的偏差, 但 Bagging RCSP 算法将训练样本分成一个个包, 并通过提取 RCSP 特征来选择训练包, 方差更小, 鲁棒性更好.

4 总结

本文提出了用于特征提取的 Bagging RCSP 算法, 并在 BCI III 数据集上验证其有效性, 结果表明, 相比较其他改进的 CSP 算法, Bagging RCSP

的平均准确率更高, 特征提取耗时更少. 然后利用 Bagging RCSP 和 RCSP-A 在 10 人采集的左右手想象运动数据集上进行离线仿真, 并对结果进行 T 检验, Bagging RCSP 较 RCSP-A 的识别率提高显著, 同时具有更小的标准差, 说明 Bagging RCSP 方法在脑电信号特征提取中的有效性. 最后, 在智能轮椅平台上, 利用该算法实现了运动想象脑电信号在线控制智能轮椅左转和右转, 其平均正确率为 87.19%, 最高时达到了 96.06%, 优于其他 CSP 及其衍生方法. 但脑电信号的平均识别率仍有待进一步的提高, 多类脑电信号的特征提取和分类还需继续探索研究.

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 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)

- 3 Iturrate I, Antelis J M, Kübler A, Minguez J. A noninvasive brain-actuated wheelchair based on a P300 neurophysiological protocol and automated navigation. *IEEE Transactions on Robotics*, 2009, **25**(3): 614–627
- 4 Fu Yun-Fa, Xu Bao-Lei, Li Yong-Cheng, Li Hong-Yi, Wang Yue-Chao, Yu Zheng-Tao. Recognition of actual grip force movement modes based on movement-related cortical potentials. *Acta Automatica Sinica*, 2014, **40**(6): 1045–1057 (张毅, 杨柳, 李敏, 罗元. 基于 AR 和 SVM 的运动想象脑电信号识别. 华中科技大学学报(自然科学版), 2014, **40**(6): 1045–1057)
- 5 Zhang Yi, Yang Liu, Li Min, Luo Yuan. Recognition of motor imagery EEG based on AR and SVM. *Journal of Huazhong University of Science and Technology (Natural Science Edition)*, 2011, **39**(S2): 103–106 (张毅, 杨柳, 李敏, 罗元. 基于 AR 和 SVM 的运动想象脑电信号识别. 华中科技大学学报(自然科学版), 2011, **39**(S2): 103–106)
- 6 Hsu W Y. EEG-based motor imagery classification using neuro-fuzzy prediction and wavelet fractal features. *Journal of Neuroscience Methods*, 2010, **189**(2): 295–302
- 7 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)
- 8 Reuderink B, Poel M. *Robustness of the Common Spatial Patterns Algorithm in the BCI-pipeline*. Centre for Telematics and Information Technology, University of Twente, Twente, Netherlands, 2008.
- 9 Kang H, Nam Y, Choi S. Composite common spatial pattern for subject-to-subject transfer. *IEEE Signal Processing Letters*, 2009, **16**(8): 683–686
- 10 Arvaneh M, Guan C T, Ang K K, Quek H C. Spatially sparsed common spatial pattern to improve BCI performance. In: Proceedings of the 2011 IEEE International Conference on Acoustics, Speech, and Signal Processing (ICASSP). Prague, Czech Republic: IEEE, 2011. 2412–2415
- 11 Lotte F, Guan C. Regularizing common spatial patterns to improve BCI designs: unified theory and new algorithms. *IEEE Transactions on Biomedical Engineering*, 2011, **58**(2): 355–362
- 12 Su Y X, Li Y L, Wang S J. Filter ensemble regularized common spatial pattern for EEG classification. In: Proceedings of the 7th International Conference on Digital Image Processing (ICDIP15). Los Angeles, USA: SPIE, 2015. Article No. 963124
- 13 Ang K K, Chin Z Y, Zhang H, Guan C T. Filter bank common spatial pattern (FBCSP) in brain-computer interface. In: Proceedings of the 2008 IEEE International Joint Conference on Neural Networks, 2008. Hong Kong, China: IEEE, 2008. 2390–2397
- 14 Data set IVa for the BCI competition III [Online], available: <http://www.bbc.de/competition/iii/>, December 18, 2015
- 15 Tangermann M, Müller K R, Aertsen A, Birbaumer N, Braun C, Brunner C, Leeb R, Mehring C, Müller K J, Müller-Putz G R, Nolte G, Pfurtscheller G, Preissl H, Schalk G, Schlögl A, Vidaurre C, Waldert S, Blankertz B. Review of the BCI competition IV. *Frontiers in Neuroscience*, 2012, **6**: Article No. 55
- 16 Bamdadian A, Guan C T, Ang K K, Xu J X. Online semi-supervised learning with KL distance weighting for motor imagery-based BCI. In: Proceedings of the 2012 Annual International Conference of the IEEE Engineering in Medicine

and Biology Society (EMBC). San Diego, CA, USA: IEEE, 2012. 2732–2735

- 17 Long J Y, Li Y Q, Wang H T, Yu T Y, Pan J H, Li F. A hybrid brain computer interface to control the direction and speed of a simulated or real wheelchair. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2012, **20**(5): 720–729
- 18 Yoo J, Yan L, El-Damak D, Altaf M A B, Shoeb A H, Chandrakasan A P. An 8-channel scalable EEG acquisition SoC with patient-specific seizure classification and recording processor. *IEEE Journal of Solid-State Circuits*, 2013, **48**(1): 214–228
- 19 Neu D, Mairesse O, Verbanck P, Linkowski P, Le Bon O. Non-REM sleep EEG power distribution in fatigue and sleepiness. *Journal of Psychosomatic Research*, 2014, **76**(4): 286–291




张毅 重庆邮电大学先进制造工程学院教授. 主要研究方向为机器人及应用, 脑电信号处理.

E-mail: zhangyi@cqupt.edu.cn

(ZHANG Yi Professor at the School of Advanced Manufacturing Engineering, Chongqing University of Posts and Telecommunications. His research interest covers robot

and its applications, the signal processing of EEG.)



尹春林 重庆邮电大学自动化学院硕士研究生. 主要研究方向为脑电信号处理. 本文通信作者.

E-mail: yinchunlin0210@foxmail.com

(YIN Chun-Lin Master student at the School of Automation, Chongqing University of Posts and Telecommunications. His main research interest is


signal processing of EEG. Corresponding author of this paper.)



蔡军 重庆邮电大学自动化学院副教授. 主要研究方向为模式识别, 智能控制.

E-mail: caijun@cqupt.edu.cn

(CAI Jun Associate professor at the School of Automation, Chongqing University of Posts and Telecommunications. His research interest covers pattern recognition, intelligent control.)



罗久飞 重庆邮电大学先进制造工程学院讲师. 主要研究方向为信号处理, 机械故障诊断与模式识别.

E-mail: luojf@cqupt.edu.cn

(LUO Jiu-Fei Lecturer at the School of Advanced Manufacturing Engineering, Chongqing University of Posts and Telecommunications. His research interest covers signal processing, mechanical fault diagnosis, and pattern recognition.)

and pattern recognition.)