DOI: 10.11999/JEIT210778

基于相关性和稀疏表示的运动想象脑电通道选择方法

孟明*① 董芝超^① 高云园^{①②} 孔万增^②
 ^①(杭州电子科技大学自动化学院 杭州 310018)
 ^②(浙江省脑机协同智能重点实验室 杭州 310018)

摘要:在基于运动想象(MI)的脑机接口(BCI)中,通常采用较多通道的脑电信号(EEG)来提高分类精度,但其中会有包含与MI任务无关或冗余信息的通道,从而影响BCI的性能提升。该文针对运动想象脑电分类中的通道选择问题,提出一种采用相关性和稀疏表示对通道进行选择的方法(CSR-CS)。首先计算训练样本每个通道的皮尔逊相关系数来选择显著通道,然后提取显著通道所在区域的滤波器组共空间模式特征拼接成字典,利用由字典所得到的非零稀疏系数的个数表征每个区域的分类能力,选出显著区域所包含的显著通道作为最优通道,最后采用共空间模式和支持向量机分别进行特征提取与分类。在对BCI第3次竞赛数据集IVa和BCI第4次竞赛数据集I两个二分类MI任务的分类实验中,平均分类精度达到了88.61%和83.9%,表明所提通道选择方法的有效性和鲁棒性。
 关键词:脑机接口;运动想象;共空间模式;支持向量机:通道选择
 中图分类号:TN911.7; TP391
 文献标识码:A
 文章编号: 1009-5896(2022)02-0477-09

Correlation and Sparse Representation Based Channel Selection of Motor Imagery Electroencephalogram

MENG Ming^① DONG Zhichao^① GAO Yunyuan^{①②} KONG Wanzeng^②

^①(School of Automation, Hangzhou Dianzi University, Hangzhou 310018, China)

⁽²⁾(Key Laboratory of Brain Machine Collaborative Intelligence of Zhejiang Province, Hangzhou 310018, China)

Abstract: In Motor Imagery (MI) based Brain Computer Interface (BCI), more channels of ElectroEncephaloGram (EEG) signal are usually adopted to improve the classification accuracy. But there will be channels containing irrelevant or redundant information about MI tasks, which degenerate the performance improvement of BCI. A Channel Selection method based on Correlation and Sparse Representation (CSR-CS) is proposed for EEG classification. Firstly, the Pearson correlation coefficient of each channel of the training sample is calculated to select the significant channels. Then the filter bank common spatial pattern features of the region where the significant channels are located are extracted and spliced into a dictionary. The number of non-zero sparse coefficients obtained from the dictionary is used to characterize the classification ability of each region, and the significant channels contained in the significant regions are selected as the optimal channels. Finally, the common spatial pattern and support vector machine are employed for feature extraction and classification respectively. In the classification experiments of two categories of MI task with BCI competition III dataset IVa and BCI competition IV dataset I, the average classification accuracy reaches 88.61% and 83.9%, which indicates the effectiveness and robustness of the proposed channel selection method.

Key words: Brain Computer Interface (BCI); Motor Imagery (MI); Common spatial pattern; Support Vector Machine (SVM); Channel selection

1 引言

脑机接口(Brain Computer Interface, BCI)是

收稿日期: 2021-08-04; 改回日期: 2021-12-09; 网络出版: 2021-12-25 *通信作者: 孟明 mnming@hdu.edu.cn

基金项目: 国家自然科学基金(61871427, 61971168, U20B2074)

Foundation Items: The National Natural Science Foundation of China (61871427, 61971168, U20B2074)

一种先进的通信系统,旨在大脑和计算机之间建立 直接的通信^[1]。脑电信号(ElectroEncephaloGram, EEG)因为其低成本、高时间分辨率而成为BCI中 最常用和广泛研究的信号^[2]。目前,最广泛采用的 实验范式有事件相关电位(Event-Related Potentials, ERP)^[3]、稳态视觉诱发电位(Steady-State Visual Evoked Potentials, SSVEPs)^[4]和运动想象(Motor Imagery, MI)^[5, 6]。根据EEG研究表明,不同身体 部位的想象运动可以导致在相应的活跃皮层区域的 感觉运动节律(α 和 β 节律)的功率衰减,称为事件相 关去同步(Event-Related Desynchronization, ERD);与此同时,在相应的对侧皮层区域的感觉 运动节律的功率增强,称为事件相关同步(Event-Related Synchronization, ERS)^[7]。通过ERD/ ERS模式的分类,可以识别不同身体部位的想象运 动,从而产生控制信号用于MI-BCI系统中。

现有研究中,通常利用较多的EEG通道信号 获得更多的空域信息来提升性能^[8]。然而同时也会 引入包含与MI任务无关或冗余信息的通道^[9],从而 使用较多的EEG通道并不能保证性能的提升^[10]。为 了去除与MI任务无关的、冗余的通道,研究者提 出了许多通道选择的方法。Feng等人^[11]提出了基 于多频带的共空间模式滤波器排序进行通道选择的 方法(Common Space Pattern-Rank channel selection for Multi-Frequency band, CSP-R-MF), 结 合多频带信号分解滤波和CSP-Rank方法选择通 道; Jin等人^[12]提出了基于皮尔逊相关系数进行通 道选择的方法(Correlation based Channel Selection, CCS), CCS利用皮尔逊相关系数选择与MI任 务相关的通道,之后对这些通道进行正则化共空间 模式(Regularized CSP, RCSP)^[13]特征提取; Han等人^[14]提出了基于特征压缩和通道排序(Feature Compression and Channel Ranking, FCCR)的通 道选择方法,通过K-Means方法聚类降低特征维 数,进而通过结构稀疏最小二乘回归等特征选择方 法,对脑电通道进行排序和选择。

MI任务的执行需要多个大脑区域的参与,并 且这些区域相互联系[15,16]。因此通道选择方法应充 分考虑通道间的整体性和大脑区域内电极的相互联 系。为此,本文提出一种基于相关性和稀疏表示的 运动想象脑电通道选择方法(Correlation and Sparse Representation based Channel Selection, CSR-CS),用以选择含有判别性信息的通道。首先计算 训练样本通道的皮尔逊相关系数来选择显著通道, 对显著通道所在的每个区域提取滤波器组CSP(Filter Bank CSP, FBCSP)^[17]特征并拼接成字典矩阵,通 过验证样本的FBCSP特征用字典稀疏表示^[18],得 到每个区域的非零稀疏系数个数,利用其个数表征 每个通道区域的分类能力来选出显著区域,将显著 区域所包含的显著通道作为最优通道,最后用CSP 和支持向量机(Support Vector Machine, SVM)分 别进行特征提取与分类,利用BCI 第3次竞赛数据 集IVa(Competition III Dataset IVa)和BCI第4次

竞赛数据集I (Competition IV Dataset I)对提出的方法进行验证。

2 方法

本文所提基于相关性和稀疏表示的运动想象脑 电通道选择方法考虑了通道间的整体性和大脑区域 内电极的相互联系,可以有效排除与MI任务无关 的冗余通道,从而改善后续特征提取和分类的准 确性。

图1是CSR-CS方法的框图。首先计算训练样本 EEG通道的皮尔逊相关系数,选择高于阈值的通道,称为显著通道;然后将每个区域提取的FBCSP特 征拼接成字典,利用得到的每个区域非零稀疏系数 个数表征其区域分类的能力;接着在通道区域的选 择中选出K个显著区域,显著区域所包含的显著通 道称为最优通道,从而构造新的EEG矩阵作为 CSP的输入,并提取CSP特征,最后采用SVM进行 分类。

2.1 基于相关性的显著通道选择

相关性有利于检测出与MI任务相关的活跃皮 层区域^[19]。研究表明当受试者执行MI任务时,与 MI任务相关的那些通道应该包含共同信息,并且 在多次MI任务中都存在这种通道之间的相关性^[12]。 基于这一结论,本文使用皮尔逊相关系数去除一些 与MI任务不相关或者相关性小的通道,从而减少 后续特征提取和分类所需要的脑电通道数量。计算 皮尔逊相关系数具体步骤如下:

首先,采用Min-Max归一化方法将所有通道的 EEG数据归一化。

然后,计算 X_i, X_i 通道的皮尔逊相关系数

$$\rho(\boldsymbol{X}_{i}, \boldsymbol{X}_{j}) = \frac{1}{T-1} \sum_{t=1}^{T} \left(\frac{\boldsymbol{X}_{i}^{t} - \operatorname{mean}(\boldsymbol{X}_{i})}{\operatorname{std}(\boldsymbol{X}_{i})} \right) \\ \cdot \left(\frac{\boldsymbol{X}_{j}^{t} - \operatorname{mean}(\boldsymbol{X}_{j})}{\operatorname{std}(\boldsymbol{X}_{j})} \right)$$
(1)

其中,*T*是每个通道的采样点数,mean(•),std(•) 分别表示EEG通道数据的平均值和标准差。 $\rho(X_i, X_j)$ 在0~1, $\rho(X_i, X_j)$ 越接近0,说明两通道 间的相关性越弱,反之相关性越强。

最后,记*N*_{ch},*N*_{trial}分别为通道数和实验次数, 计算单次实验相关系数后会得到*N*_{ch} × *N*_{ch}的系数矩 阵,计算该矩阵的行平均值,平均值较大的行说明 其对应的通道与其他通道含有较多与MI任务相关 的共同信息;经过*N*_{trial}次计算相关系数,并最终得 到系数矩阵行平均值的平均值,选择其平均值大于 预先设置的阈值的通道作为显著通道,反之去除。



图 1 CSR-CS方法框图

2.2 CSP特征提取

共空间模式(CSP)是处理二分类任务的空域滤 波算法,该算法提取多通道的脑电信号中每类的空 间分布成分,通过空间投影寻找最好的投影方向, 使其中一类方差最大化而另一类最小化,从而达到 分类的目的。

设单次实验EEG信号为矩阵 $X_{N \times T}$,其中N为通道数。首先,计算两类的空间协方差矩阵

$$\boldsymbol{C}_{i} = \frac{\boldsymbol{X}_{i} \boldsymbol{X}_{i}^{\mathrm{T}}}{\operatorname{trace}(\boldsymbol{X}_{i} \boldsymbol{X}_{i}^{\mathrm{T}})}$$
(2)

其中,*i*代表运动想象类别(i = 1, 2), C_1, C_2 分别为 第1类和第2类想象运动的协方差矩阵,trace(•)表 示矩阵的迹, X_i^{T} 表示 X_i 的转置矩阵。则可以得到 混合空间协方差矩阵 C_c

$$\overline{C_1} = \frac{1}{N_1} \sum_{n=1}^{N_1} C_1^n$$
(3)

$$\overline{C_2} = \frac{1}{N_2} \sum_{n=1}^{N_2} C_2^n \tag{4}$$

$$\boldsymbol{C}_c = \overline{\boldsymbol{C}_1} + \overline{\boldsymbol{C}_2} \tag{5}$$

其中, N₁和N₂分别是第1类和第2类想象运动的实验次数。

第2步,对混合空间协方差矩阵*C*。进行特征值 分解

$$\boldsymbol{C}_c = \boldsymbol{U}_c \boldsymbol{\lambda}_c \boldsymbol{U}_c^{\mathrm{T}} \tag{6}$$

其中, *U*_c为混合空间协方差矩阵*C*_c的特征向量矩阵, *λ*_c是对应降序排列的特征值构成的对角阵。白 化矩阵*P*为

$$\boldsymbol{P} = \sqrt{\boldsymbol{\lambda}_c}^{-1} \boldsymbol{U}_c^{\mathrm{T}} \tag{7}$$

第3步,将两类平均空间协方差矩阵进行如 式(8)的变换,有

$$\boldsymbol{S}_1 = \boldsymbol{P} \overline{\boldsymbol{C}_1} \boldsymbol{P}^{\mathrm{T}} = \boldsymbol{B} \boldsymbol{\Lambda} \boldsymbol{B}^{\mathrm{T}}$$
(8)

$$\boldsymbol{S}_2 = \boldsymbol{P}\overline{\boldsymbol{C}_2}\boldsymbol{P}^{\mathrm{T}} = B(E-\Lambda)\boldsymbol{B}^{\mathrm{T}}$$
(9)

其中, E为单位阵; 由式(8)、式(9)可知, 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,反之亦然, S_1 最小特征值对应的特征向量是 S_2 最大特征值对应的特征向量。所以,投影矩阵 W为

$$\boldsymbol{W} = \boldsymbol{B}^{\mathrm{T}} \boldsymbol{P} \tag{10}$$

其中, W是一个N×N的矩阵。

第4步,从投影矩阵**W**中选取前M列和后 M列,构造最优空间滤波器**W***

$$\boldsymbol{W}^* = [W_1, \cdots, W_M, W_{N-M}, \cdots, W_N] \qquad (11)$$

将两类的EEG信号经最优空间滤波器 W^* 滤波, 对滤波后的EEG信号提取特征 $f = (f_1, f_2, \dots, f_{2M})$, 其中

$$\boldsymbol{f}_{m} = \lg \left(\operatorname{var}(\boldsymbol{W}_{m}^{*\mathrm{T}}\boldsymbol{X}) / \sum_{m=1}^{2M} \operatorname{var}(\boldsymbol{W}_{m}^{*\mathrm{T}}\boldsymbol{X}) \right),$$
$$m = 1, 2, \cdots, 2M$$
(12)

FBCSP的主要流程是将EEG信号划分为多个 子带,对每个子带提取CSP特征。本文中,将每个 通道区域的4~40 Hz 的EE信号划分为P个子带, 每个子带提取2M个特征,则每个通道区域共有 $2M \times P$ 个特征。

2.3 基于稀疏表示的显著通道区域选择

近年来,稀疏表示(Sparse Representation, SR)^[20]作为一种新的信号采集方法受到了广泛的关 注。稀疏表示可以使数据的表示形式更加简洁清 晰,其原理为利用字典中的少量原子进行线性叠加 来重构输入信号。稀疏表示算法中重要的两个部分 是字典的构建和利用字典表示信号^[21]。图2是稀疏 表示方法的模型构建。

在字典的构建阶段,将给定的训练特征集合记 为X,得到的字典记为D,本文将得到的每个通道 区域的训练特征集拼接成字典。



图 2 稀疏表示方法

建立字典矩阵后,可以通过矩阵形式来获得输 入的验证样本信号的稀疏表示,其表示形式为

$$\boldsymbol{y} = \boldsymbol{D}\boldsymbol{u} \tag{13}$$

其中, $u=[u_1, u_2, \dots, u_n]^T$, $u_i, (i=1, 2, \dots, N)$ 为稀疏系数。

稀疏表示的目的是估计系数,以便将输入信号 稀疏地表示为**D**的几个原子的线性组合。输入信号 的稀疏表示可以通过l₁范数最小化得到

$$\min \|\boldsymbol{u}\|_1, \text{ s.t. } \boldsymbol{y} = \boldsymbol{D}\boldsymbol{u}$$
(14)

可以将式(14)转换为一个最优凸近似问题,通 过4正则化近似得到

$$\boldsymbol{u} = \operatorname*{argmin}_{\boldsymbol{u}} ||\boldsymbol{y} - \boldsymbol{D}\boldsymbol{u}||_{2}^{2} + \lambda ||\boldsymbol{u}||_{1}$$
(15)

通过式(15)可以得到每个通道区域的稀疏系数,同时每个通道区域的非零稀疏系数个数表征其分类能力,所以将每个区域的非零系数个数降序排列,选出显著区域,显著区域中包含的显著通道即最优通道将会进行后续的特征提取和分类。

2.4 分类

支持向量机(Support Vector Machine, SVM) 在分类中有着广泛的应用,并且可以取得良好的分 类效果。本实验采用SVM作为分类工具。SVM的 基本思想是首先通过非线性变换将输入空间变换到 一个高维空间,然后在这个新空间中求最优分类面 即最大间隔分类面。SVM分类器旨在解决优化问题

$$\min_{\boldsymbol{w},\boldsymbol{b}} \frac{1}{2} ||\boldsymbol{w}||_2^2 + C \sum_{i=1}^n \xi_i,$$
s.t. $\boldsymbol{y}_i \left(\boldsymbol{w}^{\mathrm{T}} \boldsymbol{f}^{(i)} + \boldsymbol{b} \right) \ge 1 - \xi_i, \xi_i \ge 0$ (16)

其中,w和b分别是超平面的权向量和偏置,C是软间隔的正则化参数, ξ_i 是松弛变量, y_i 为类标签, $f^{(i)}$ 为第i次实验的特征向量。

3 实验

3.1 数据描述

数据集 I: 第1个数据集来自BCI Competition III Dataset IVa。该数据集记录了5个健康受试者 (aa, al, av, aw, ay)的两类运动想象任务EEG数据,每位受试者要求在视觉提示后想象右手或者脚的运动,每次实验持续时间3.5 s,每组EEG信号均采用118个电极进行记录,采样率为100 Hz,每个受试者进行每类运动想象140次实验,共280次实验。每次实验流程:前3.5 s内在电脑屏幕上出现向右或者向下的箭头,受试者根据箭头方向执行对应的运动想象,然后放松1.75~2.25 s,单次实验时间轴如图3(a)所示。

数据集 II: 第2个数据集来自BCI Competition IV Dataset I。该数据集记录了4个健康受试者 (a, b, f, g)的两类运动想象任务EEG数据,每位受 试者要求完成左手或者双脚的两类运动想象任务各 100次实验,每组EEG信号均采用59个通道进行记 录,采样率为100 Hz。每次实验流程:首先一个固 定十字显示在电脑屏幕的中央,时间为6 s,第2 s 时电脑屏幕出现向左或者向下的箭头,受试者根据 箭头方向执行对应的运动想象,然后在6~8 s内出 现黑屏,单次实验时间轴如图3(b)所示。

3.2 数据预处理

由于EEG是一种非平稳、低幅值、低信噪比 的生物电信号,并且运动想象系统的稳定性较差, 易受干扰,所以EEG信号通常含有不同形式的噪 声和干扰,比如50 Hz工频干扰(脑电信号频谱图在 50 Hz处有一个明显的干扰脉冲),还有眼电、心 电、肌电的干扰。结合运动想象任务的特点,即执 行运动想象任务时会出现ERD和ERS现象,执行 单手和双脚运动想象任务时会在对侧和中央运动皮 层区域的α频段(8~12 Hz)和β频段(13~30 Hz)出 现明显的ERD现象,故本文截取每次实验中视觉 提示后0.5~2.5 s的EEG数据,并且采用有限单位 冲激响应滤波器(Finite Impulse Response, FIR)对 EEG信号进行4~40 Hz的带通滤波。

3.3 通道选择及分类

(1)选择显著通道。计算训练样本所有通道的 皮尔逊相关系数 ρ_i , ($i = 1, 2, ..., N_{ch}$),并将 ρ_i 的平均 值设置为阈值,低于阈值的通道将被去除,高于阈 值的通道称为显著通道,并选择进行后续操作。

(2)划分通道区域。将分布在脑皮层的所有通 道划分*K*个区域(数据集 I: *K*=9; 数据集 II: *K*=7), 如图4所示,中央区域一些通道(Fpz, AFz, Fz, FCz, Cz, CPz)的填充色和线框色是属于两个颜色的,说 明该通道同时属于两个通道区域。图4(a)是数据集 I的9个通道区域,图4(b)是数据集 II的7个通道区域。

(3)选择通道区域。使用4阶巴特沃斯滤波器将 每个通道区域的EEG信号划分为P=17个带宽为



图 4 通道区域划分

4 Hz, 重叠率为2 Hz的子频带(4~8 Hz, 6~10 Hz, 8~12 Hz, …, 32~36 Hz, 34~38 Hz, 36~40 Hz), 用以FBCSP特征的提取(2*M* = 4),所以每个通道 区域得到68维的特征向量。

将训练样本的特征向量拼接成字典 $D \in \mathbb{R}^{F \times (N_{tr} \times K)}$, D = [f(1), f(2), ..., f(K)], 其中f(i)为第i个通道区域的特征向量;验证样本用字典D稀疏表示,求解稀疏向量u的目标函数如式(15)所示,可以得到每个通道区域的非零稀疏系数个数,将其降序排列设置阈值进而选择显著的通道区域。

(4)分类。显著区域内的显著通道作为最优通 道提取CSP特征,用SVM进行分类,本文中采用 径向基(Radial Basis Function, RBF)函数作为 SVM的核函数,正则化参数C通过交叉验证确定。

4 结果与讨论

4.1 电极分布

将CSR-CS方法应用于数据集II,图5是数据集II经过通道选择后的电极分布,黄色填充部分代表被选择通道。由图5可以看出,4个受试者所选择的通道都位于通道CCP3和CCP4附近,这一结果表明CSR-CS方法基本符合神经生理学意义;同时每个受试者经过选择后通道分布各不一样,这也充分说明了基于不同受试者进行通道选择的必要性。



(c) 受试者f

图 5 数据集 II 电极分布

4.2 分类性能比较

用CSR-CS方法分别在两个数据集上进行实 验,并与CCS-RCSP,CSP-R-MF和FCCR方法进 行比较,10折交叉验证得到的测试集平均分类精度 如表1所示。

针对上述两个数据集, CSR-CS方法表现出了 最佳的分类性能。针对数据集 I, 与上述3种方法 相比,本文方法的平均分类准确率分别提高了 1.17%, 6.13%, 2.7%; 针对数据集 II, 与上述3种方 法相比,本文方法的平均分类准确率分别提高了 2.3%, 6.1%, 3.8%。与CSP-R-MF方法相比, CSR- CS方法在分类精度上取得了非常显著的提高 (p<0.01)。虽然与另外两种方法相比没有体现出非 常显著的优势,但是无论是在数据集 I 还是数据集 II, CSR-CS方法在经过通道选择后并没有降低分 类性能反而有一定提升。

与上述3种方法相比,其中受试者aa,a和f的 分类准确率提升较多,说明CSR-CS方法所选择的 最优通道多位于运动想象区域,在运动想象时该区 域内信号更具有区分性。FCCR作为一种通过特征 压缩和特征选择来选择通道的方法在个别受试者上 表现出了一定的优越性,但通过此方法选出来的通

483

道并不像CSR-CS方法选出来的通道那样考虑了通 道间的整体性和大脑区域内电极的相互联系,而 CSP-R-MF方法更偏向于子带的特征选择,缺少对 通道的选择,CCS-RCSP方法没有考虑到通道间的 整体性,这都导致部分分类精度的损失。

综上所述,CSR-CS方法在电极数量较多和较 少的数据集都可以展现出较好的分类效果,从而验 证了本文提出的通道选择方法的可行性。

4.3 通道选择的比较

(1)选择通道区域个数k对分类准确率的影响。以数据集 I 中的5位受试者为例介绍选择通道 区域个数k对分类准确率的影响,由图6看出对于大 多数受试者来说,随着所选通道区域数量的增加, 分类准确率的总体趋势是先增加后降低的。这是因 为最初选择的通道数量太少,导致特征太少,分类 精度较低。当通道数量过大时,含有冗余信息的通 道或者与MI任务无关的通道会降低分类精度。受 试者aa和aw使用CSR-CS方法选择较少通道区域 时,分类准确率可以达到最高,这是因为选择的较 少通道区域中的特征已经足够用以准确分类;其 中,受试者al,av和ay达到最高分类准确率时选择 了较多通道区域,这是其通道含有较少的判别性特 征信息的缘故。

(2) 通道选择与否对分类准确率的影响。为了

文讽有 CCS-RCSP CSP-R-MF FCCR CS	SR-CS
aa 82.50 81.43 78.57 8	86.31
al 96.80 92.41 98.21 9	97.74
av 71.10 70.00 72.45 7	72.83
aw 92.90 83.57 87.05 9	90.48
ay 93.90 85.00 93.25 9	95.71
均值 87.44 82.48 85.91 8	88.61
a 85.50 81.50 83.50 9	92.00
b 67.00 63.00 72.50 6	62.50
f 79.50 79.00 81.00 8	86.30
g 94.50 87.50 83.50 9	94.70
均值 81.60 77.80 80.10 8	83.90
p-value 0.21 <0.01 0.16	-

表1 数据集Ⅰ、数据集Ⅱ分类精度比较

验证进行通道选择可以提升分类精度的必要性,本 文还对上述两个数据集进行了没有通道选择用 CSP进行特征提取进而分类(All-Channel CSP. AC-CSP)和使用本文提出的通道选择方法对比, 从表2可以看出, CSR-CS方法在两个数据集的9位 受试者的分类精度均高于AC-CSP。对于数据集 Ⅰ中的al,ay和数据集Ⅱ中的f,g4位受试者,可 以看到经过通道选择后分类精度的提升幅度很小, 对于其他受试者,经过通道选择后分类精度的提升 幅度很大,所以这也充分说明了基于不同受试者进 行通道选择的必要性。与AC-CSP方法相比,本文所 提方法在分类精度上取得了非常显著的提高(p<0.01)。 图7绘制了最显著的两个CSP特征的分布,这两个 特征是由CSR-CS和AC-CSP方法从数据集 I 中的 受试者aa中提取的。显然, CSR-CS方法的特征相 对于不同的MI任务更具有可分离性。

(3)选择显著通道或者通道区域与否对分类精度的影响。为了验证选择显著通道和通道区域的必要性,本文将仅选择通道区域(Sparse Representation based Channel Selection, SR-CS)、仅选择显著通道(Correlation based Channel Selection, C-CS)方法和CSR-CS方法进行对比。SR-CS方法不通过相关性选择显著通道,而是将所有的电极划分固定通道区域,与CSR-CS方法的通道区域划分规则是一样的。C-CS方法通过计算皮尔逊相关系数选择显著通道,进而特征提取与分类。同样在上述的两个数据集进行实验,测试集10折交叉验证分类精度对比结果如图8所示。

可以看出,两个数据集的所有受试者在选择相同通道区域时,CSR-CS的分类性能明显优于SR-



图 6 选择通道区域个数对分类精度的影响

表 2	通道选择与否对分类准确率的影响

方法	数据集I					数据集 II						
	aa	al	av	aw	ay	均值	a	b	f	g	均值	p-value
AC-CSP	76.19	95.12	66.02	83.69	94.88	83.18	82.50	52.50	85.10	92.30	78.10	$<\!0.01$
CSR-CS	86.31	97.74	72.83	90.48	95.71	88.61	92.00	62.50	86.30	94.70	83.90	_



图 7 受试者aa在CSR-CS和AC-CSP方法上获得的最显著的两个特征的分布



图 8 选择显著通道或区域与否对分类精度的影响

CS;在选择相同显著通道时,CSR-CS的分类性能 明显优于C-CS。这表明通过稀疏表示选择显著区 域和通过计算皮尔逊相关系数选择显著通道,可以 去除含有冗余信息和与MI任务无关的通道,从而 可以提取判别性特征,最终提高分类精度。其中, 对于数据集 I 中的受试者ay和数据集 II 中的受试 者f,CSR-CS方法与SR-CS方法、C-CS方法得到 的分类准确率相差很小(<1.5%),这是因为一些与 MI任务无关的冗余通道包含在未选择的通道区域 中或者受试者ay和f含有冗余信息的通道较少。

5 结束语

本文提出一种对于多通道脑电信号的通道选择 方法CSR-CS,即基于相关性和稀疏表示选择运动 想象脑电通道的方法。首先,通过计算皮尔逊相关 系数选择显著通道,将通道划分为K个通道区域, 然后通过稀疏表示得到每个区域的非零稀疏系数个 数来选择显著区域,最后用显著区域中的显著通道 作为最优通道进行特征提取和分类。在电极数分别 为118和59的公共数据集进行测试,并与其他3种通 道选择算法进行对比,且对不同的受试者给出了利 于分类的最优通道,结果表明通道的选择是有必要 的,分类精度有一定提升。此外,频段信息对EEG 分类也十分重要,使用稀疏组表示方法^[23]同时选择 最优通道和最佳频段将是后续工作的研究内容。

参考文献

- BIRBAUMER N. Brain-computer-interface research: Coming of age[J]. Clinical Neurophysiology, 2006, 117(3): 479-483. doi: 10.1016/j.clinph.2005.11.002.
- [2] BLANKERTZ B, DORNHEGE G, KRAULEDAT M, et al. The non-invasive Berlin Brain-Computer Interface: Fast acquisition of effective performance in untrained subjects[J]. *NeuroImage*, 2007, 37(2): 539-550. doi: 10.1016/j. neuroimage.2007.01.051.
- [3] ALLISON B Z, KÜBLER A, and JIN Jing. 30+years of P300 brain-computer interfaces[J]. *Psychophysiology*, 2020, 57(7): e13569. doi: 10.1111/psyp.13569.
- [4] HSU C C, YEH C L, LEE W K, et al. Extraction of highfrequency SSVEP for BCI control using iterative filtering based empirical mode decomposition[J]. Biomedical Signal Processing and Control, 2020, 61: 102022. doi: 10.1016/j. bspc.2020.102022.
- [5] ANG K K and GUAN Cuntai. EEG-based strategies to detect motor imagery for control and rehabilitation[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2017, 25(4): 392–401. doi: 10.1109/TNSRE. 2016.2646763.
- [6] RONG Yuying, WU Xiaojun, and ZHANG Yumei. Classification of motor imagery electroencephalography signals using continuous small convolutional neural network[J]. International Journal of Imaging Systems and Technology, 2020, 30(3): 653–659. doi: 10.1002/ima.22405.
- PARK Y and CHUNG W. A novel EEG correlation coefficient feature extraction approach based on demixing EEG channel pairs for cognitive task classification[J]. *IEEE* Access, 2020, 8: 87422–87433. doi: 10.1109/access.2020.
 2993318.
- [8] BLANKERTZ B, LOSCH F, KRAULEDAT M, et al. The Berlin brain-computer interface: Accurate performance from first-session in BCI-naive subjects[J]. *IEEE Transactions on Biomedical Engineering*, 2008, 55(10): 2452–2462. doi: 10. 1109/TBME.2008.923152.
- [9] LIU Ye, ZHANG Hao, CHEN Min, et al. A boosting-based

spatial-spectral model for stroke patients' EEG analysis in rehabilitation training[J]. *IEEE Transactions on Neural* Systems and Rehabilitation Engineering, 2016, 24(1): 169–179. doi: 10.1109/TNSRE.2015.2466079.

- [10] ASENSIO-CUBERO J, GAN J Q, and PALANIAPPAN R. Multiresolution analysis over simple graphs for brain computer interfaces[J]. *Journal of Neural Engineering*, 2013, 10(4): 046014. doi: 10.1088/1741-2560/10/4/046014.
- [11] FENG Jiankui, JIN Jing, DALY I, et al. An optimized channel selection method based on multifrequency CSP-Rank for motor imagery-based BCI system[J]. Computational Intelligence and Neuroscience, 2019, 2019: 8068357. doi: 10.1155/2019/8068357.
- [12] JIN Jing, MIAO Yangyang, DALY I, et al. Correlationbased channel selection and regularized feature optimization for MI-based BCI[J]. Neural Networks, 2019, 118: 262–270. doi: 10.1016/j.neunet.2019.07.008.
- [13] VARSEHI H and FIROOZABADI S M P. An EEG channel selection method for motor imagery based brain-computer interface and neurofeedback using Granger causality[J]. *Neural Networks*, 2021, 133: 193–206. doi: 10.1016/j.neunet. 2020.11.002.
- [14] HAN Jiuqi, ZHAO Yuwei, SUN Hongji, et al. A fast, open EEG classification framework based on feature compression and channel ranking[J]. Frontiers in Neuroscience, 2018, 12: 217. doi: 10.3389/fnins.2018.00217.
- [15] CONA F, ZAVAGLIA M, ASTOLFI L, et al. Changes in EEG power spectral density and cortical connectivity in healthy and tetraplegic patients during a motor imagery task[J]. Computational Intelligence and Neuroscience, 2009, 2009: 279515. doi: 10.1155/2009/279515.
- [16] HAMEDI M, SALLEH S, and NOOR A M. Electroencephalographic motor imagery brain connectivity analysis for BCI: A review[J]. Neural Computation, 2016, 28(6): 999–1041. doi: 10.1162/NECO_a_00838.
- [17] ANG K K, CHIN Z Y, ZHANG Haihong, et al. Filter bank common spatial pattern (FBCSP) in brain-computer interface[C]. 2008 IEEE International Joint Conference on

Neural Networks (IEEE World Congress on Computational Intelligence), Hong Kong, China, 2008: 2390–2397. doi: 10. 1109/IJCNN.2008.4634130.

- [18] SHIN Y, LEE S, AHN M, et al. Noise robustness analysis of sparse representation based classification method for nonstationary EEG signal classification[J]. Biomedical Signal Processing and Control, 2015, 21: 8–18. doi: 10.1016/j.bspc. 2015.05.007.
- [19] LI Yuanqing, NAMBURI P, YU Zhuliang, et al. Voxel selection in fMRI data analysis based on sparse representation[J]. IEEE Transactions on Biomedical Engineering, 2009, 56(10): 2439-2451. doi: 10.1109/TBME. 2009.2025866.
- [20] XU Chunyao, SUN Chao, JIANG Guoqian, et al. Two-Level multi-domain feature extraction on sparse representation for motor imagery classification[J]. Biomedical Signal Processing and Control, 2020, 62: 102160. doi: 10.1016/j. bspc.2020.102160.
- [21] SREEJA S R, HIMANSHU, and SAMANTA D. Distancebased weighted sparse representation to classify motor imagery EEG signals for BCI applications[J]. *Multimedia Tools and Applications*, 2020, 79(19): 13775–13793. doi: 10. 1007/s11042-019-08602-0.
- [22] JIAO Yong, ZHANG Yu, CHEN Xun, et al. Sparse group representation model for motor imagery EEG classification[J]. IEEE Journal of Biomedical and Health Informatics, 2019, 23(2): 631-641. doi: 10.1109/JBHI.2018. 2832538.
- 孟明:男,1975年生,副教授,硕士生导师,研究方向为脑机接口、机器人智能控制.
- 董芝超: 男, 1997年生, 硕士生, 研究方向为模式识别与脑机接口.
- 高云园: 女,1980年生,副教授,硕士生导师,研究方向为生物信 号处理、脑机接口.
- 孔万增: 男,1980年生,教授,博士生导师,研究方向为人工智能 与模式识别、脑机交互与认知计算.

责任编辑:余 蓉