

DOI: 10.19650/j.cnki.cjsi.J1905276

基于组稀疏贝叶斯逻辑回归运动想象脑电信号 分类模型的通道选择与分类新算法*

张绍荣^{1,2}, 朱志斌^{3,4}, 冯宝², 余天佑⁵, 李智²

(1. 桂林电子科技大学电子工程与自动化学院 桂林 541004; 2. 桂林航天工业学院电子信息与自动化学院 桂林 541004;
3. 桂林电子科技大学数学与计算科学学院 桂林 541004; 4. 桂林电子科技大学广西高校数据分析与计算重点实验室
桂林 541004; 5. 华南理工大学自动化科学与工程学院 广州 510000)

摘要:针对脑电信号的通道选择和分类问题,提出了基于组稀疏贝叶斯逻辑回归(gsBLR)的运动想象脑电信号分类模型,同时进行通道选择和分类。首先,对多通道信号进行空间滤波和带通滤波,降低容积传导效应的影响;其次,对每个通道的信号提取具有判别信息的时域、频域以及时频域特征,并进行特征融合;最后,使用gsBLR方法进行通道选择和分类,在贝叶斯学习框架下模型参数可自动从训练数据中估计得到,避免了繁琐而耗时的交叉验证过程。在两个公开的脑机接口(BCI)竞赛数据集和自采集数据集上进行了实验验证,分别获得了81.63%、84.97%和76.47%的最高平均分类准确率;相比其他方法,所提出的方法具有较好的分类准确率和较少的通道数,同时所选通道与神经生理背景更加吻合。

关键词:运动想象脑电;脑机接口;组稀疏;贝叶斯学习;逻辑回归;通道选择

中图分类号: TH77 R318 **文献标识码:** A **国家标准学科分类代码:** 310.61 520.2040

New channel selection and classification algorithm based on group sparse Bayesian logistic regression motor imagery EEG signal classification model

Zhang Shaorong^{1,2}, Zhu Zhibin^{3,4}, Feng Bao², Yu Tianyou⁵, Li Zhi²

(1.School of Electronic Engineering and Automation, Guilin University of Electronic Technology, Guilin 541004, China; 2.School of Electronic Information and Automation, Guilin University of Aerospace Technology, Guilin 541004, China; 3.School of Mathematics and Computing Science, Guilin University of Electronic Technology, Guilin 541004, China; 4.Guangxi Colleges and Universities Key Laboratory of Data Analysis and Computation, Guilin University of Electronic Technology, Guilin 541004, China; 5.School of Automation Science and Engineering, South China University of Technology, Guangzhou 510000, China)

Abstract: Aiming at the channel selection and classification issue of EEG signals, a motor imagery EEG classification model based on group sparse Bayesian logistic regression (gsBLR) is proposed, which can simultaneously accomplish channel selection and classification. Firstly, spatial filtering and band-pass filtering are performed on the multi-channel signals to reduce the influence of volume conduction effect. Secondly, the time domain, frequency domain and time-frequency domain features with discriminant information are extracted for each channel signal, and feature fusion is performed. Finally, the gsBLR method is used for channel selection and classification. The model parameters are automatically estimated from the training data under the Bayesian learning framework, which avoids cumbersome and time-consuming cross-validation process. Experiments were carried out on two public BCI competition datasets and self-collected dataset, and the highest average classification accuracies of 81.63%, 84.97% and 76.47% were achieved, respectively. Compared with other methods, the proposed method achieves better classification accuracy and fewer number of

收稿日期:2019-06-21 Received Date:2019-06-21

* 基金项目:国家自然科学基金(61967004,11901137,81960324)、广西区自然科学基金(2018GXNSFBA281023,2016GXNSFBA380160)、广西区自动检测技术与仪器重点实验室基金(YQ19209,YQ18107)、桂林电子科技大学研究生教育创新计划项目(2019YCXB03)资助

channels. At the same time, the selected channels are more compatible with the neurophysiological background.

Keywords: motor imagery EEG; brain-computer interface; group sparse; Bayesian learning; logistic regression; channel selection

0 引言

脑机接口 (brain-computer interface, BCI) 通过识别大脑活动转换成外部控制信号, 与外部设备建立直接的信息交互^[1]。脑电 (electroencephalogram, EEG) 信号获取成本低且时间分辨率高, 在 BCI 系统中得到广泛应用^[2]。BCI 本质上是一种模式识别系统, 首先从多通道 EEG 信号中提取特征, 然后使用机器学习方法对特征进行处理和分类, 从而识别被试者的心理状态。在基于运动想象脑电信号的 BCI 系统中, 多通道和高维特征对机器学习是一个很大的挑战。另外, 基于运动想象的 BCI 系统能否走出实验室并且应用于工程实践和临床诊断, 在一定程度上依赖于较少的电极通道和高效的脑电信号解码方法。

由于容积传导效应, 电极通道采集的信号是大脑内部源信号在空间和时间上的交叠, 多数通道存在信息冗余和噪声干扰^[3]。使用大量的 EEG 通道会引入额外的噪声和冗余信息, 从而增加了分类器的复杂度, 降低 BCI 系统的性能^[4]。另外, 通道数越多, 实验准备所需要的时间就越长, BCI 系统使用的舒适性也会降低^[5]。通道选择可以有效地去除冗余信息, 减少特征维数, 避免过拟合和维数灾难, 提高分类器的性能。因此, 通道选择可以有效地提高 EEG 信号的解码性能。尽管大脑功能分区等先验知识可以帮助人工的通道选择, 但是受被试大脑皮层结构差异和电极分布不同等因素影响, 最优的通道子集往往是被试特异的。因此, 需要考虑自适应的通道选择。

现有的通道选择方法主要分为 3 类: 过滤式、包裹式和嵌入式^[6]。过滤式通道选择方法的通道选择过程与后续的分类器无关, 使用独立的评价准则, 比如距离度量和信息度量等。单海军等^[7]结合 Relief 的统计相关性原理和顺序后向选择算法的迭代思想对 EEG 通道进行选择, 并使用相关系数法进行分类, 取得最优分类准确率的通道即认定为最优通道。Miao 等^[8]使用 Fisher 判别准则 (Fisher discriminant criteria, FDC) 进行通道选择。Lan 等^[9]使用通道和类别标签之间的互信息 (mutual information, MI) 对通道进行排序, MI 较大的通道被选择为最优通道。Wang 等^[10]选择较大的共同空间模式 (common spatial pattern, CSP) 的向量系数所对应的通道作为最优通道, 然而文献^[10]得到的 CSP 权重向量是稠密的, 只有少数通道被剔除。为此, Arvaneh 等^[11]在文献^[10]基础上引入了 l_1/l_2 稀疏约束, 提出了稀疏 CSP, 结果表明所提出的方法优于 FDC^[12]、MI^[9]、CSP^[10] 和

RCSP (regularized CSP)^[13] 等方法。过滤式通道选择方法具有一定的优势, 比如计算代价小, 但是没有考虑通道之间的相关性。包裹式通道选择方法使用分类器性能作为通道选择的评价准则。Lal 等^[12]把 FDC、 L_0 范数迭代优化和基于支持向量机的递归通道剔除 (support vector machine recursive channel elimination, SVM-RCE) 方法用于运动想象脑电信号的通道选择, 发现 SVM-RCE 优于其他两种方法。Wei 等^[14]使用二值多目标粒子群优化算法和随机搜索策略进行通道选择, 使用 K 最近邻 (k-nearest neighbor, KNN)、支持向量机 (support vector machine, SVM) 和后向传播 (back propagation, BP) 神经网络 3 种分类器进行分类。Kamrunnahar 等^[15]提出了一种系统优化算法, 联合完全搜索策略进行通道选择。Yang 等^[16]使用人工神经网络和遗传算法进行通道选择。Ghaemi 等^[17]使用改进的二值引力搜索算法进行通道选择。包裹式通道选择方法在评估每一个候选通道子集时都要对选择的分类器进行训练和测试, 计算代价高, 而且倾向于过拟合。嵌入式通道选择方法的通道选择与分类器的训练过程融为一体, 在分类器训练过程中同时进行通道选择, 充分利用了现有数据, 因此嵌入式通道选择方法近年来得到了广泛应用。LASSO (least absolute shrinkage and selection operator) 方法一般用于特征选择, 但是模型正则化参数确定之后再使用一个额外的交叉验证过程, LASSO 也可用于通道选择^[5]。基于 LASSO 方法选择出的最优通道子集过于稀疏, 在通道选择过程中忽略了通道之间的相关性。组 LASSO (group LASSO, gLASSO) 方法是 LASSO 的扩展^[18], 可同时进行通道选择和分类。gLASSO 假设脑电数据具有组稀疏特性, 充分利用了 EEG 信号的结构信息, 选择的通道集中在与任务相关的大脑皮层区域, 因此所选通道更加符合神经生理特征。基于组间稀疏和组内稀疏的原理, 王金甲等^[19]提出了基于稀疏组 LASSO (sparse group LASSO, sgLASSO) 的脑机接口通道和特征选择, 实验结果表明 sgLASSO 方法优于 LASSO 和 gLASSO。值得指出的是, 虽然组稀疏结构先验在其他方面得到了广泛应用 (比如 P300 EEG 信号的特征选择和分类^[5]、功能磁共振的体素选择^[20]), 但是在运动想象 EEG 信号应用上还比较少见。嵌入式通道选择方法可同时进行通道选择和分类, 具有很大的优势; 然而, 与前面两种方法一样, 模型参数的确定需要繁琐而耗时的交叉验证。交叉验证具有一定的局限性, 首先每个被试的模型参数是特异的, 需要单独进行交叉验证确定; 其次, 当模型参数增加时, 交叉验证耗时巨大。另外, 受噪声或者小样本的影响, 交叉验证选择的

模型参数不一定是最佳的^[21]。

针对交叉验证确定模型参数的局限性,同时考虑 EEG 数据的结构信息,本文提出了基于组稀疏贝叶斯逻辑回归 (group sparse Bayesian logistic regression, gsBLR) 的运动想象 EEG 信号通道选择和分类方法,可同时进行 EEG 信号的通道选择和分类。首先,对 EEG 信号进行预处理,进行空间滤波和带通滤波;其次,对每个通道的信号序列提取时域高阶统计参数、多个频带的带通功率、AR 系数以及小波能量作为特征;最后,结合组自动相关决策 (grouped automatic relevance determination, GARD) 和稀疏贝叶斯学习构建组稀疏贝叶斯学习模型,通过引入 GARD 先验对通道选择进行建模,模型参数在贝叶斯框架下可以从训练数据中自动估计得到,避免了繁琐而耗时的交叉验证过程。在两组公开的 BCI 竞赛数据和实验室自采集数据上的实验结果表明,相比现有的方法,本文方法具有较好的分类准确率和较少的通道数,所选择的通道与神经生理更加吻合。另外,还比较了 gsBLR 与组稀疏贝叶斯线性判别分析 (group sparse Bayesian linear discriminant analysis, gsBLDA)^[5] 在运动想象 EEG 信号分类的实验效果,发现 gsBLR 相比 gsBLDA 更适合于运动想象 EEG 信号的分类。

1 信号预处理和特征提取

1.1 预处理流程

1) 使用共同平均参考 (common average reference, CAR) 对 EEG 信号进行空间滤波,可降低容积效应的影响。

2) 使用 6 阶的 Butterworth 滤波器对每个通道的 EEG 信号进行 8~30 Hz 的带通滤波,滤除与运动想象无关的脑电成分。

3) 提取单次试次数据,数据集 1 选取的时间窗为 0.5~3.5 s,数据集 2 选取的时间窗为 0.5~2.5 s。0 s 代表运动想象任务开始。

1.2 特征提取

主要提取时域、频域和时频域的特征。首先,针对 EEG 每个通道的信号提取时域高阶统计特征,分别为方差、峰度和峭度;高阶统计特征对信号漂移和放大不敏感,因此相比传统的时域信息更适合非线性和低信噪比的 EEG 信号^[22]。其次,对每个通道的信号提取 6 阶 AR 系数作为 EEG 信号的特征;AR 模型可以对时间序列进行有效的建模,在 EEG 信号分析中得到了广泛应用^[23]。另外,对每个通道的信号分别提取 8~12、12~16、16~20、20~24 和 24~30 Hz 频段的带通功率作为特征;功率谱估计可以分析 EEG 信号的功率分布和变化,有利于对事件

相关同步 (event related synchronization, ERS) 和事件相关去同步 (event related desynchronization, ERD) 的识别^[19]。最后,对每个通道的信号进行小波分解,并计算每层分解的近似系数和细节系数的小波能量;小波变换是一种有效的时频分析方法,适合非平稳 EEG 信号的分析^[24]。所有数据集使用的小波基都为 db4,数据集 1 分解层数为 3,数据集 2 分解层数为 5。

2 组稀疏贝叶斯通道选择方法

假设在 EEG 信号特征提取过程中每通道信号的特征维数为 d , EEG 信号的通道数为 c ,把每个通道的特征逐级联成一个 P -维 ($P=c \times d$) 特征向量 \mathbf{x} , $\mathbf{x} \in \mathbf{R}^P$ 。给定数据集 $\{\mathbf{x}_i, \mathbf{t}_i\}$, $\mathbf{t}_i \in \{0, 1\}$ 为特征向量 \mathbf{x}_i 对应的标签, $i \in (1, \dots, N)$, N 为数据样本总数。在逻辑回归框架下,权重向量 \mathbf{w} 的似然函数可写为:

$$p(\mathbf{t} | \mathbf{w}) = \prod_{i=1}^N y_i^{\mathbf{t}_i} (1 - y_i)^{1 - \mathbf{t}_i} \quad (1)$$

式中: $y_i = \sigma(\mathbf{w}^T \mathbf{x}_i)$; $\sigma(\cdot)$ 是逻辑 sigmoid 函数; $\mathbf{t} = (t_1, \dots, t_N)^T$; $\mathbf{w} \in \mathbf{R}^P$ 对应特征值的权重向量。

根据贝叶斯规则,权重向量 \mathbf{w} 的后验概率如下:

$$p(\mathbf{w} | \mathbf{t}) = \frac{p(\mathbf{t} | \mathbf{w})p(\mathbf{w})}{p(\mathbf{t})} \quad (2)$$

因此,求解 \mathbf{w} 的最大后验概率需先求解 w 的先验分布 $p(\mathbf{w})$ 。通过引入不同的先验可获得不同的贝叶斯学习方法。在一般的贝叶斯逻辑回归 (Bayesian logistic regression, BLR)^[25] 中,引入一个同质的零均值高斯先验 $p(\mathbf{w} | \alpha) = N(\mathbf{w} | 0, \alpha^{-1} \mathbf{I})$,相当于对权重向量 \mathbf{w} 进行正则化,估计得到的 \mathbf{w} 向原点收缩,因此可有效地减轻过拟合,而且正则化参数可以从训练数据中自动估计得到,避免耗时的交叉验证,其原理与贝叶斯线性判别分析 (Bayesian linear discriminant analysis, BLDA) 类似^[26]。

与 BLR 不同,稀疏贝叶斯逻辑回归 (sparse Bayesian logistic regression, sBLR) 采用自动相关决策 (automatic relevance determination, ARD) 先验为每个权重参数 w_i 单独分配一个超参数 α_i ^[27]。权重先验形式如下:

$$p(\mathbf{w} | \alpha) = \prod_{i=1}^P N(\mathbf{w}_i | 0, \alpha_i^{-1} \mathbf{I}) \quad (3)$$

式中: $\alpha = (\alpha_1, \dots, \alpha_P)^T$; $p(\mathbf{w} | \alpha)$ 为零均值高斯分布,其精度矩阵 (协方差的逆) 的对角元素由 α 组成; \mathbf{I} 为单位矩阵。当最大化关于这些超参数的证据时,其中很大一部分趋于无穷大,相应权重参数的后验分布趋于 0,对应的特征被自动剔除掉。因此, sBLR 可以用于特征选择。

在 EEG 通道选择的应用中,需要对某一类分组特征进行同质性处理,即属于同一信号通道的数值必须以相同的方式处理,使解的空间解释成为可能^[12]。为此,引

入 GARD 先验,把 EEG 信号每个通道的权重参数作为一组,并为每一组权重参数 \mathbf{w}_g 分配一个超参数 α_g ,即 $(\mathbf{w}_1, \dots, \mathbf{w}_d)$ 共享一个超参数 α_1 , $(\mathbf{w}_{d+1}, \dots, \mathbf{w}_{2d})$ 共享一个超参数 α_2 , 依此类推。新的权重先验如下:

$$p(\mathbf{w} | \boldsymbol{\alpha}) = \prod_{g=1}^G \mathcal{N}(\mathbf{w}_g | 0, \alpha_g^{-1} \mathbf{I}_g) \quad (4)$$

式中: G 为分组个数,也即通道总数; α_g 表示权重参数 \mathbf{w}_g 的精度; $\boldsymbol{\alpha} = (\alpha_1, \dots, \alpha_1, \alpha_2, \dots, \alpha_2, \dots, \alpha_c, \dots, \alpha_c)^\top$ 。与 ARD 类似,当最大化关于 $\boldsymbol{\alpha}$ 的边缘似然函数时,一些 α_g 的值趋于无穷大,相应权重参数的后验分布趋于 0,则对应的通道被自动剔除掉,从而实现通道选择的目的。

后验概率式(4)的求解依赖于超参数 $\boldsymbol{\alpha}$,因此先求解 $\boldsymbol{\alpha}$ 。使用证据最大化方法(也称为 type-II 最大似然估计方法),超参数 $\boldsymbol{\alpha}$ 可以从训练数据中自动估计得到^[27]。证据最大化即最大化边缘似然函数 $p(\mathbf{t} | \boldsymbol{\alpha})$, $p(\mathbf{t} | \boldsymbol{\alpha})$ 通过对权重参数 \mathbf{w} 积分得到,即:

$$p(\mathbf{t} | \boldsymbol{\alpha}) = \int p(\mathbf{t} | \mathbf{w}) p(\mathbf{w} | \boldsymbol{\alpha}) d\mathbf{w} \quad (5)$$

然而,在分类问题中,对式(5)进行显式积分不可行。因此,先使用拉普拉斯近似方法获取后验分布的高斯近似^[25]。具体如下:

$$\begin{aligned} \ln p(\mathbf{w} | \mathbf{t}, \boldsymbol{\alpha}) &= \ln \{p(\mathbf{t} | \mathbf{w}) p(\mathbf{w} | \boldsymbol{\alpha})\} - \ln p(\mathbf{t} | \boldsymbol{\alpha}) = \\ &= \sum_i \{t_i \ln y_i + (1 - t_i) \ln (1 - y_i)\} - \frac{1}{2} \mathbf{w}^\top \mathbf{A} \mathbf{w} + \text{const} \end{aligned} \quad (6)$$

式中: $\mathbf{A} = \text{diag}(\alpha_i)$ 是一个对角矩阵, const 表示与 \mathbf{w} 独立的项。使用迭代重加权最小二乘方法(iterative reweighted least squares, IRLS)^[28] 求解式(6),首先计算式(6)的梯度向量和海塞矩阵。

$$\mathbf{g} = \nabla \ln p(\mathbf{w} | \mathbf{t}, \boldsymbol{\alpha}) = \mathbf{X}^\top (\mathbf{t} - \mathbf{y}) - \mathbf{A} \mathbf{w} \quad (7)$$

$$\mathbf{H} = \nabla \nabla \ln p(\mathbf{w} | \mathbf{t}, \boldsymbol{\alpha}) = -(\mathbf{X}^\top \mathbf{B} \mathbf{X} + \mathbf{A}) \quad (8)$$

式中: \mathbf{B} 是一个 $N \times N$ 的对角矩阵,其对角线上的元素为 $b_{nn} = y_n(1 - y_n)$, $\mathbf{y} = (y_1, \dots, y_N)^\top$ 。由于海塞矩阵恒为负定,因此 $\ln p(\mathbf{w} | \mathbf{t}, \boldsymbol{\alpha})$ 为凹函数,具有唯一的最大值。Newton-Raphson 迭代更新^[29]可写为:

$$\mathbf{w}^{(iter+1)} = \mathbf{w}^{(iter)} - \mathbf{H}^{-1} \mathbf{g} \quad (9)$$

当 IRLS 算法收敛时,海塞矩阵表示后验概率高斯近似的协方差的逆;对式(7)赋值为 0 求得的权重向量 \mathbf{w} 为后验概率高斯近似的均值。高斯近似分布的均值和协方差具体如下:

$$\hat{\mathbf{w}} = \mathbf{A}^{-1} \mathbf{X}^\top (\mathbf{t} - \mathbf{y}) \quad (10)$$

$$\boldsymbol{\Sigma} = (\mathbf{X}^\top \mathbf{B} \mathbf{X} + \mathbf{A})^{-1} \quad (11)$$

使用以上的高斯近似对边缘似然函数进行估计,可得:

$$p(\mathbf{t} | \boldsymbol{\alpha}) = \int p(\mathbf{t} | \mathbf{w}) p(\mathbf{w} | \boldsymbol{\alpha}) d\mathbf{w} \approx$$

$$p(\mathbf{t} | \hat{\mathbf{w}}) p(\hat{\mathbf{w}} | \boldsymbol{\alpha}) (2\pi)^{\frac{r}{2}} |\boldsymbol{\Sigma}|^{-\frac{r}{2}} \quad (12)$$

对式(12)关于 α_g 求导,并令导数为 0,可得:

$$\alpha_g = \frac{\sum_i \gamma_i}{\hat{\mathbf{w}}_g^\top \hat{\mathbf{w}}_g} \quad (13)$$

$$\gamma_i = 1 - \alpha_i \sum_{ii} \cdot, i \in \{1, 2, \dots, P\} \quad (14)$$

式中: $\hat{\mathbf{w}}_g$ 是后验分布均值 $\hat{\mathbf{w}}$ 的第 g 组; \sum_{ii} 为协方差矩阵 $\boldsymbol{\Sigma}$ 对角线上的第 i 个元素。式(13)中, α_g 为隐含解,因为 $\hat{\mathbf{w}}_g$ 和 γ_i 都与 α_g 有关,因此需要对 α_g 进行迭代求解。

综上所述,可得 gsBLR 算法的执行过程如下:

1) 输入数据矩阵 \mathbf{X} 以及标签 \mathbf{t} , $\hat{\mathbf{w}}$ 和 α_g 初始化: $\hat{\mathbf{w}} = \mathbf{I}$, $\alpha_g = 1, g = 1, 2, \dots, G$;

2) 根据式(9)迭代更新权重参数 \mathbf{w} , 直至满足收敛条件,并根据式(10)和(11)计算后验概率分布的均值和方差;

3) 根据式(13)和(14)更新 α_g 和 γ_i ;

4) 检查似然函数收敛性或者权重参数 \mathbf{w} 的变化,如果收敛条件不满足, $\boldsymbol{\alpha} \leftarrow \boldsymbol{\alpha}^{\text{new}}$, 并且返回步骤 2), 否则 $\mathbf{w}^* = \hat{\mathbf{w}}$ 。

3 实验结果与分析

采用两个公开的 BCI 竞赛数据验证所提出方法的性能,将分类结果与现有的通道选择和分类方法比较。

3.1 数据说明

下面简要介绍两个公开的 BCI 竞赛数据,详细的信息可参考相应的文献。

数据集 1: BCI 竞赛 III (2005) 数据集 IVa^[30]。此数据集一共 118 个通道,采样率为 100 Hz。5 个健康被试(aa, al, av, aw, ay)分别执行左手、右手和右脚 3 类运动想象任务。由于竞赛只提供右手和脚的运动想象数据,因此只对这两类任务的数据进行分类。每个被试包含 280 个试次的数据,其中 aa, al, av, aw, ay 各个被试的训练集样本个数分别为 168, 224, 84, 56, 28, 剩下的为测试集。

数据集 2: BCI 竞赛 III (2005) 数据集 IIIa^[31]。此数据集一共 60 个通道,采样率为 250 Hz。3 个健康被试(K3, K6, L1)分别执行了左手、右手、脚和舌头 4 类运动想象任务。被试 K3 每类任务的训练集和测试集样本个数分别为 45, 被试 K6 和 L1 每类任务的训练集和测试集样本个数分别为 30。参考文献[32]的做法,对 4 类任务(左手、右手、脚和舌头)进行排列组合,得到多个二分类问题,即: $C_4^2 = 6$ 个二分类。因此,一共得到 18 个数据子集。把左手、右手、脚和舌头 4 类运动想象任务分别用字母 L, R, F 和 T 表示,则 L1-LR 表示被试 L1 执行左手和右手运动想象。

3.2 通道选择方法与模型参数选择

参与比较的通道选择方法一共 7 种,分别为滤波式方法:FDC,包裹式方法:SVM-RCE,以及嵌入式方法:LASSO、gLASSO、sgLASSO、gsBLDA 和 gsBLR。对于 FDC 和 SVM-RCE 方法,在训练集数据上使用 10 重交叉验证选择最优的通道数,然后使用 BLDA 作为最终的分类器计算分类准确率。对于 LASSO 方法,先使用 10 重交叉验证和格搜索方法选择合适的正则化参数,超参数备选集合为: $\lambda \in 0.1 \times \{1,2,\dots,30\}$ (参考文献[32]的做法),然后使用额外的 10 重交叉验证选择最优的通道数,最后使用 BLDA 作为最终的分类器计算分类准确率。对于 gLASSO 和 sgLASSO 方法,最优通道数可以通过剔除通道权重为 0 或者接近 0 的通道直接得到,超参数通过 10 重交叉验证选择,gLASSO 超参数备选集合为: $\lambda \in 0.1 \times \{1,2,\dots,30\}$,gsLASSO 超参数备选集合为: $\lambda_1 \in$

$0.1 \times \{1,2,\dots,30\}$ (组间稀疏正则项)以及 $\lambda_2 \in 0.1 \times \{1,2,\dots,30\}$ (组内稀疏正则项)。对于 gsBLDA 和 gsBLR 方法,最优通道数可以通过剔除通道权重为 0 或者接近 0 的通道直接得到,模型参数直接从训练集数据中学习得到而不需要进行耗时的交叉验证。FDC 和 SVM-RCE 方法实现参考文献[12],LASSO、gLASSO 和 sgLASSO 方法使用 CVX 工具箱^[33]实现,gsBLDA 方法实现参考文献[5]。所有实验在 MATLAB 2014a 软件上进行。

3.3 实验结果

1) 数据集 1

表 1 所示为每种通道选择方法和每个被试的分类准确率和最优通道数,最高的分类准确率和最少的通道数使用黑体加粗显示。gsBLR 在被试 aa、al、av 中取得了最高的分类准确率,并且取得了最高的平均准确率。在所有方法中,gsBLDA 取得了最低的准确率。

表 1 分类准确率和最优通道数(数据集 1)
Table 1 Classification accuracy and optimal number of channels(dataset 1)

被试者	方法						
	FDC	SVM-RCE	LASSO	gLASSO	sgLASSO	gsBLDA	gsBLR
aa	70.54(3)	70.54(1)	70.54(1)	68.75(9)	73.21(7)	66.96(22)	74.11(11)
al	96.43(6)	98.21(9)	100.00(5)	100.00(16)	98.21(41)	98.21(27)	100.00(9)
av	65.82(4)	64.29(22)	59.18(1)	63.27(3)	61.22(4)	61.22(14)	66.84(6)
aw	78.13(6)	78.57(42)	73.66(3)	85.27(2)	76.79(6)	71.88(10)	83.48(7)
ay	77.38(9)	77.38(21)	86.51(2)	85.71(12)	88.10(10)	84.92(6)	83.73(4)
平均	77.66(5.60)	77.80(19.00)	77.98(2.40)	80.60(8.40)	79.51(13.60)	76.64(15.80)	81.63(7.40)

LASSO 选择的平均通道数最少,SVM-RCE 选择的平均通道数最多。gsBLR 选择的平均通道数中等,但相比其他组稀疏方法(gLASSO、sgLASSO 和 gsBLDA),gsBLR 选择的通道数最少。

为了更加直观地观察被选择通道的头皮分布以及方便研究通道选择的生理可解释性,图 1 所示为各种通道选择方法的通道权重在各个被试的头皮映射,标记黑色方框的为本文方法。图 1 中显示,大部分通道选择方法选择的通道集中在大脑左半部分的运动皮层区域(比如 CCP5 和 CP3 电极通道),这与运动想象的生理背景相符,因为右手的感知运动皮层区域正好分布大脑的左半部分。虽然大部分通道选择方法都能识别运动皮层区域,但选择的位置和通道的数量有所不同,这决定了最终的分类准确率。FDC、LASSO 和 gsBLR 选择的区域较为相似,但是 FDC 和 LASSO 选择的通道数偏少。SVM-RCE 选择的通道偏多且比较分散,比如被试 av、aw、ay。在组稀疏方法中,gLASSO 在

被试 ay 中选择的通道比较分散,sgLASSO 在被试 al 中选择的通道比较分散,gsBLDA 选择的通道偏多且比较分散,gsBLR 选择的通道数最少而且选择的通道较为集中,在识别运动皮层区域和通道数方面都取得了较好的结果。因此,gsBLR 选择的通道与神经生理背景更加吻合。

2) 数据集 2

在数据集 2 中被试 K3、K6、L1 分别包含 6 种二分类任务,表 2 所示为数据集 2 每种通道选择方法和每个被试-任务的分类准确率和最优通道数。

gsBLR 在大部分被试-任务中取得了最高的分类准确率,并且在被试 L1 的平均准确率和总的平均准确率中取得了最高的分类准确率。值得指出的是,FDC 在多个被试-任务中取得了最高的准确率,在被试 K3 和 K6 的平均准确率中也取得了最高的分类准确率。在数据集 2 中,gsBLR 与 FDC 取得了最高的总平均分类准确率,但 gsBLR 选择的通道数远少于 FDC。

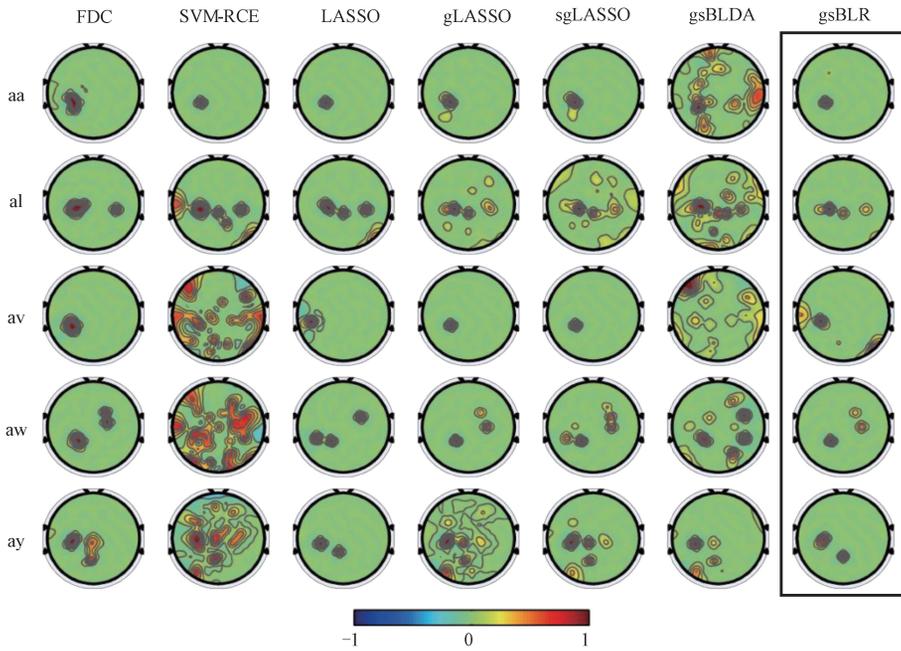


图1 脑电通道权重头皮映射图(数据集1)

Fig.1 Scalp map of EEG channel weight (dataset 1)

表2 分类准确率和最优通道数(数据集2)

Table 2 Classification accuracy and optimal number of channels (dataset 2)

被试者	方法						
	FDC	SVM-RCE	LASSO	gLASSO	sgLASSO	gsBLDA	gsBLR
K3-LR	92.22(8)	86.67(10)	90.00(2)	92.22(23)	93.33(10)	88.89(10)	93.33(4)
K3-LF	92.22(48)	82.22(4)	84.44(4)	90.00(24)	87.78(15)	85.56(13)	84.44(2)
K3-LT	95.56(52)	96.67(29)	94.44(39)	88.89(30)	91.11(32)	90.00(18)	94.44(5)
K3-RF	91.11(7)	93.33(23)	93.33(10)	93.33(10)	92.22(10)	95.56(14)	90.00(3)
K3-RT	93.33(2)	92.22(4)	93.33(6)	94.44(19)	91.11(31)	92.22(11)	94.44(4)
K3-FT	80.00(6)	78.89(39)	76.67(4)	85.56(7)	70.00(2)	80.00(13)	84.44(6)
K6-LR	65.00(2)	50.00(20)	60.00(3)	53.33(59)	50.00(59)	50.00(9)	53.33(8)
K6-LF	71.67(54)	63.33(15)	60.00(5)	66.67(16)	68.33(11)	68.33(12)	75.00(6)
K6-LT	90.00(13)	80.00(27)	81.67(34)	83.33(20)	80.00(26)	78.33(8)	85.00(6)
K6-RF	61.67(3)	68.33(31)	70.00(30)	66.67(8)	68.33(7)	55.00(12)	70.00(8)
K6-RT	81.67(46)	76.67(4)	81.67(27)	80.00(15)	83.33(19)	78.33(12)	78.33(6)
K6-FT	91.67(37)	78.33(15)	90.00(16)	78.33(21)	81.67(25)	81.67(9)	95.00(6)
L1-LR	93.33(8)	86.67(11)	93.33(6)	88.33(8)	86.67(15)	90.00(10)	88.33(7)
L1-LF	88.33(35)	88.33(6)	86.67(6)	88.33(1)	95.00(12)	88.33(10)	93.33(3)
L1-LT	93.33(1)	93.33(1)	93.33(3)	91.67(2)	93.33(3)	83.33(9)	95.00(1)
L1-RF	88.33(37)	86.67(7)	90.00(37)	83.33(11)	80.00(2)	81.67(7)	85.00(3)
L1-RT	88.33(8)	90.00(23)	93.33(3)	90.00(1)	90.00(1)	81.67(10)	93.33(2)
L1-FT	71.67(47)	65.00(3)	75.00(7)	71.67(1)	70.00(59)	61.67(8)	76.67(7)
K3 平均	90.74(20.50)	88.33(18.17)	88.70(10.83)	90.74(18.83)	87.59(16.67)	88.70(13.17)	90.19(4.00)
K6 平均	76.94(25.83)	69.44(18.67)	73.89(19.17)	71.39(13.17)	71.94(24.50)	68.61(10.33)	76.11(6.67)
L1 平均	87.22(22.67)	85.00(8.50)	88.61(10.33)	85.56(4.00)	85.83(15.33)	81.11(9.00)	88.61(3.83)
总平均	84.97(23.00)	80.93(15.11)	83.73(13.44)	82.56(15.33)	79.48(18.83)	78.86(10.83)	84.97(4.83)

相比其他方法,gsBLR 在每个被试的不同任务中都取得了最低的平均通道数。另外,gsBLR 也取得了最低的总平均通道数。在数据集 2 中,某些被试在一些任务中选择了较大的通道数,比如 FDC 方法在 K6-LF 中选择了 54 个通道,SVM-RCE 在 K3-FT 中选择了 39 个通道,LASSO 在 K3-LT 中选择了 39 个通道,gLASSO 和 sgLASSO 在 K6-LR 中都选择了 59 个通道。gsBLDA 和 gsBLR 选择的通道相对均匀而且数量较少,gsBLDA 选择的最大通道数为 18,而 gsBLR 选择的最大通道数为 8。

在所有方法中,gsBLR 选择的平均通道数最少。

图 2 所示为各种通道选择方法的通道权重在各个被试的头皮映射。由于空间限制,图 2 只给出了 10 个被试任务的通道权重拓扑分布。与数据集 1 类似,gsBLR 选择的通道比较集中而且通道数最少,而其他方法在某些被试任务中选择的通道比较分散,同时包含了一些与运动想象任务不相关的通道。大部分通道选择方法选择的通道都能识别与任务相关的运动皮层区域,比如在 L1-LT 中,选择的通道集中在大脑右半部分的运动皮层区域。

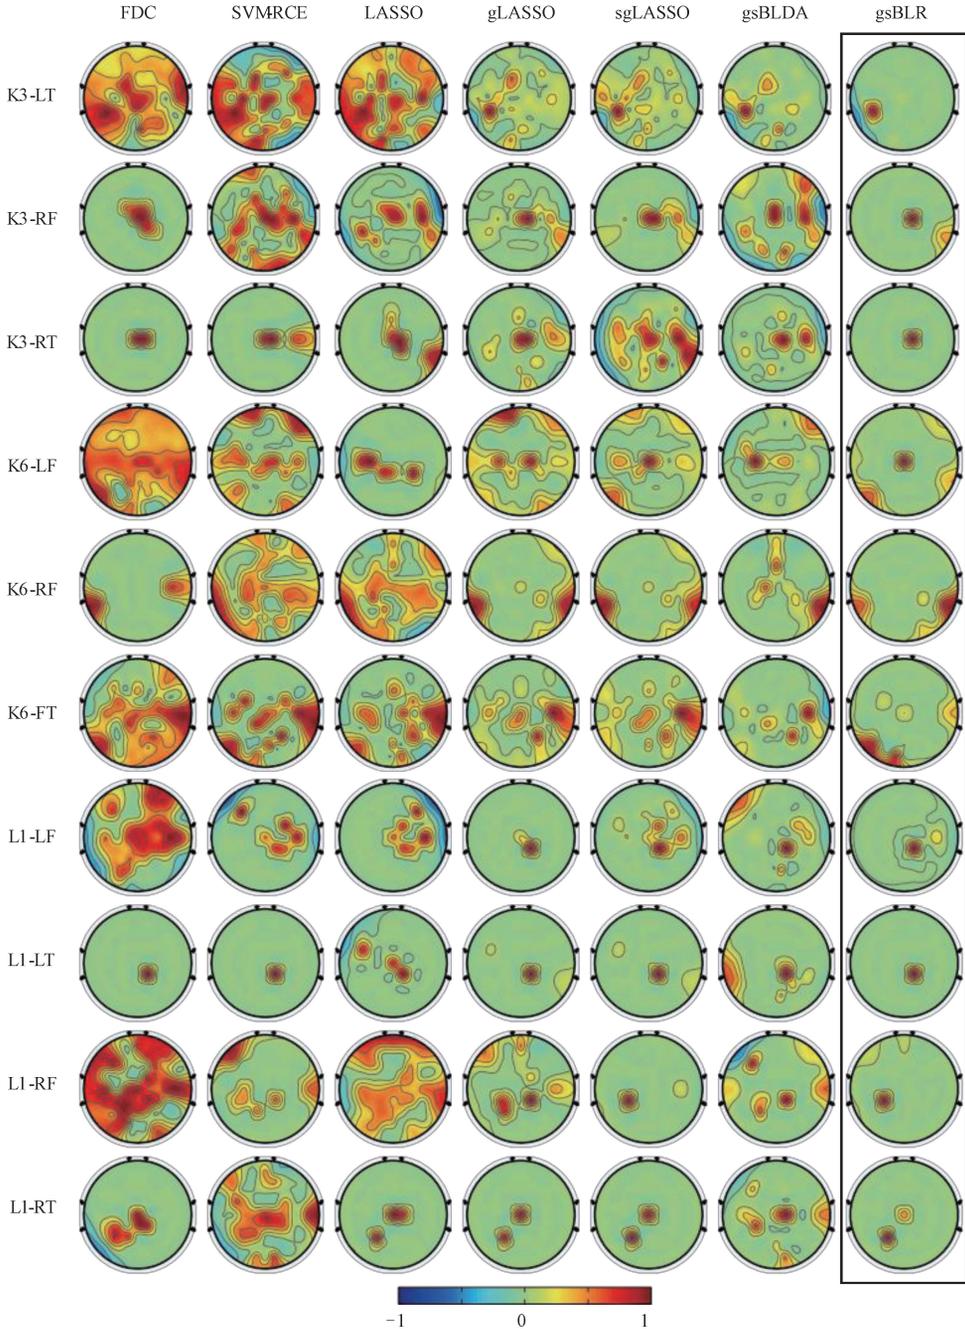


图 2 脑电通道权重头皮映射图(数据集 2)
Fig.2 Scalp map of EEG channel weight (dataset 2)

最后,图3所示为所有通道选择方法在每个被试的分类准确率,圆圈表示数据集1(一共5个被试的分类准确率),方块表示数据集2(一共18个被试-任务的分类准确率)。在对角线以上的点表示 gsBLR 优于其他方法,从图3中可以看到大多数点在对角线以上,说明了 gsBLR 的优越性。使用单因素方差分析对

这些分类准确率进行统计检验表明,gsBLR 显著优于其他方法(所有 $p < 0.05$)。使用成对 t-检验结果表明,gsBLR 显著优于 SVM-RCE、gLASSO、sgLASSO 和 gsBLDA(所有 $p < 0.05$),而 gsBLR 和 FDC 之间以及 gsBLR 和 LASSO 之间则没有显著区别(所有 $p > 0.05$)。

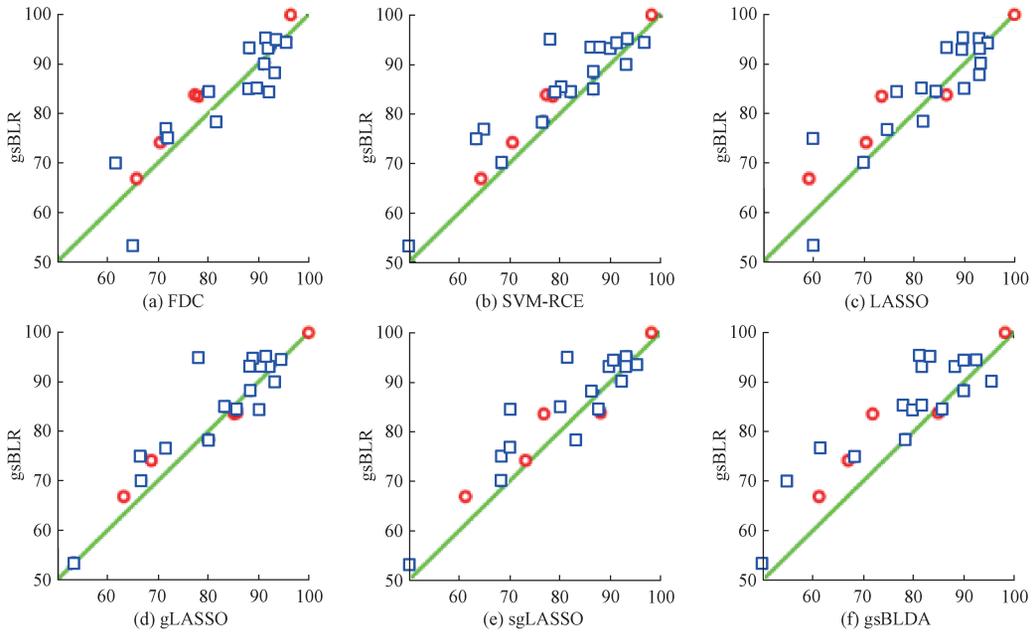


图3 分类准确率对比

Fig.3 Classification accuracy comparison

4 实际应用

为进一步验证算法的有效性,把所提出的方法应用于实验室自采集的数据集上。该数据集一共采集了10个健康被试者的数据,被试分别进行左右手运动想象任务。使用 Neuroscan 公司的 NuAmps 40 导放大器进行头皮 EEG 信号采集,采样率为 250 Hz。一共采集 36 个电极通道的数据,去除 4 个眼电电极通道(分别放置于左右两个眼睛的垂直和水平位置)和 2 个参考电极通道(A1 和 A2,分别放置于左右耳垂下方)的数据,只剩下 30 个通道的数据,本文只对这 30 个通道的数据进行分析。单次数据提取使用的时间窗为 0.5~3.5 s,其他预处理和特征提取方法与数据集 2 一样。

表 3 所示为每种通道选择方法和每个被试的分类准确率和最优通道数。gsBLR 方法在多个被试中取得了最高分类准确率,同时取得了最高的平均分类准确率。另外,gsBLR 取得了最低的平均通道数。在所有被试中,gsBLR 选择的通道数都不大于 10,其他方法选择的通道数则差异很大,比如 LASSO,最小通道数为 3,最

大通道数为 30。这进一步验证了 gsBLR 方法的鲁棒性。

图 4 所示为各种通道选择方法的通道权重在各个被试的头皮映射。由于空间限制,图 4 只给出了 5 个被试的通道权重拓扑分布。与数据集 1 和数据集 2 类似,gsBLR 选择的通道比较集中,其他方法选择的通道则比较分散,比如 SVM-RCE 和 LASSO。

虽然自采集数据的分类准确率相对公开数据有所下降,但是从整体的实验效果来看,gsBLR 明显优于其他方法。这在一定程度上验证了 gsBLR 的有效性。

5 讨论

图 5 所示为数据集 1 和数据集 2 的通道选择率对比结果,通道选择率计算等于每种方法所选择通道数的平均值除以数据集总的通道数。比较发现在所有方法中数据集 1 通道选择率都明显低于数据集 2。

换句话说,通道总数多的数据集(数据集 1 共 118 个通道)比通道总数少的数据集(数据集 2 共 60 个通道)倾向于选择更少的通道,这似乎不符合常理。然而从

表 3 分类准确率和最优通道数(自采集数据)

Table 3 Classification accuracy and optimal number of channels(self-collected dataset)

被试者	方法						
	FDC	SVM-RCE	LASSO	gLASSO	sgLASSO	gsBLDA	gsBLR
S1	67.19(1)	76.56 (3)	73.44(3)	76.56 (6)	70.31(5)	71.88(4)	75.00(4)
S2	65.63(6)	68.75 (16)	65.63(20)	65.63(14)	62.50(16)	60.94(9)	67.19(7)
S3	70.31(14)	70.31(5)	64.06(30)	75.00 (16)	64.06(29)	71.88(7)	70.31(5)
S4	64.58(1)	66.67(10)	72.92 (6)	66.67(12)	64.58(16)	70.83(5)	70.83(4)
S5	76.56(27)	81.25 (19)	78.13(24)	81.25 (16)	81.25 (13)	81.25 (12)	81.25 (8)
S6	59.38(2)	60.94(15)	64.06(11)	67.19(22)	73.44 (16)	68.75(10)	70.31(10)
S7	76.92 (11)	67.31(19)	73.08(7)	73.08(23)	71.15(2)	63.46(13)	73.08(4)
S8	82.69(18)	80.77(25)	80.77(7)	69.23(17)	75.00(17)	71.15(14)	84.62 (8)
S9	88.24(17)	90.20(20)	90.20(16)	82.35(17)	90.20(9)	82.35(9)	92.16 (4)
S10	80.00 (8)	70.77(11)	76.92(13)	76.92(19)	80.00 (9)	70.77(15)	80.00 (4)
平均	73.15(10.50)	73.35(14.30)	73.92(13.70)	73.54(16.20)	73.25(13.20)	71.33(9.80)	76.47 (5.80)

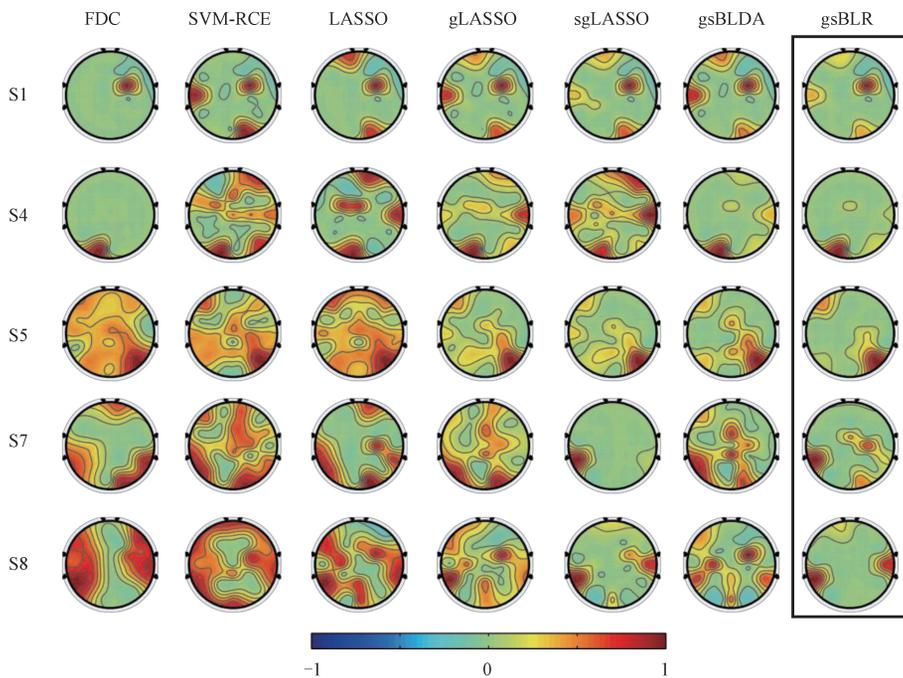


图 4 EEG 通道权重头皮映射图(自采集数据)

Fig.4 Scalp map of EEG channel weight (self-collected dataset)

EEG 的空间分辨率这个角度,可以得到合理解释。随着通道数的增多,EEG 的空间分辨率提高,对大脑内部源信号的捕捉能力增强,使得单个电极通道包含的信息量更大,因此只需少量通道就能识别运动想象任务的类别。然而当通道数增加到一定程度之后,单个通道的信息量不再增大,增加的通道反而引入了更多的噪声同时存在

大量的信息冗余。因此,通道总数多的数据集,EEG 空间分辨率高,只需少量通道即可正确识别运动想象任务的类别。这也说明了进行通道选择去除冗余信息和降低噪声的必要性。

图 6 所示为 5 个被试的电极通道被选择次数的分布情况,一共 7 种方法,因此最大的选择次数为 7。通道被

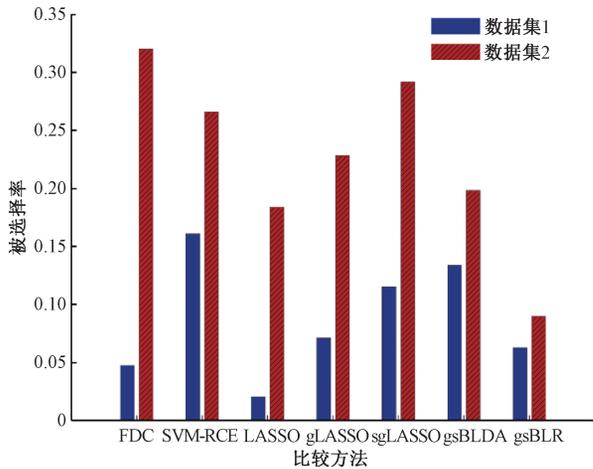


图5 通道选择率对比

Fig.5 Channel selection rate comparison

选择次数越大,说明电极通道对脑电分类越重要。比较发现不同被试通道被选择次数的分布情况有所不同,比如被试 al,通道被选择次数较多的集中在通道 50~75 之间;而被试 aw,通道被选择次数较多的集中在通道 50~65 之间以及 90~100 之间。这说明最优通道选择是被试特异的。另外,对照图 1 和 2 发现,被选择的最优通道并不总是包含 C3、C4 和 Cz 这些通道(基于神经生理背景经验知识),而是集中在其附近区域(仍然在大脑运动皮层区域),这与文献[34]观点是一致的,即最优的通道并不总是在 C3、C4 和 Cz 这些通道的正下方。因此,根据神经生理先验知识所选择的通道往往不是最优的,而应该针对不同被试者,采用数据驱动的方式自适应地选择最优的通道。最后,观察图 1、2 和 6 可知,gsBLR 方法和其他通道选择方法选择的通道区域大体一致,但是 gsBLR 选择的通道更加集中,因此生理解释更加合理。

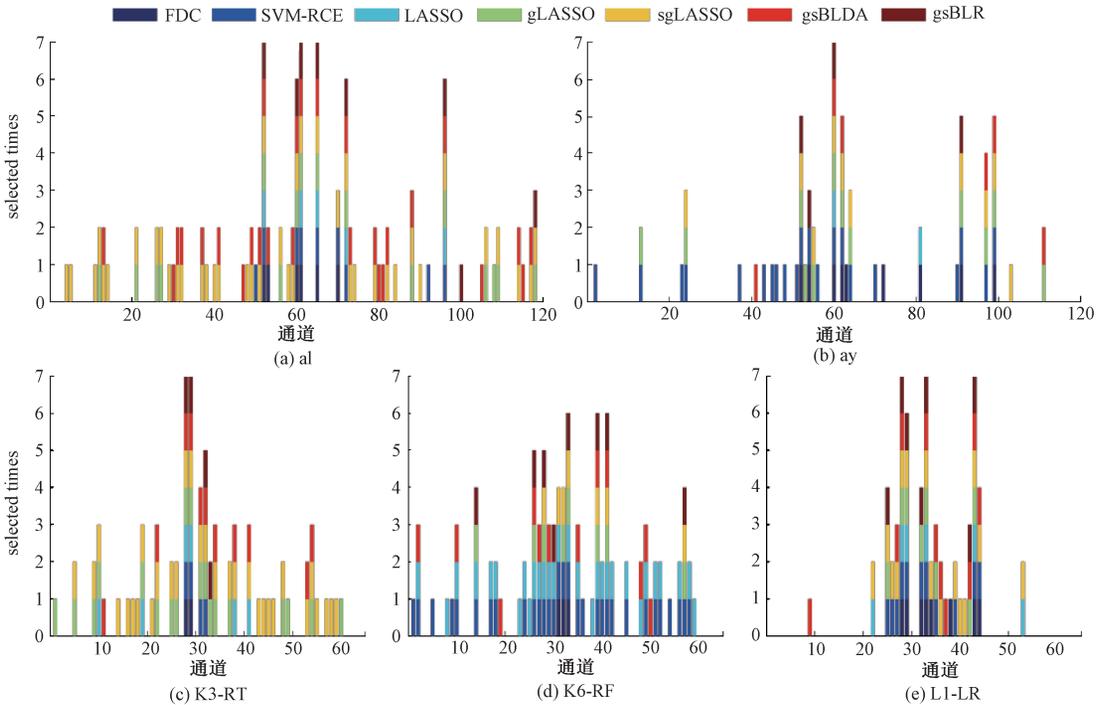


图6 通道选择分布

Fig.6 Channel selection distribution

在所有方法中,除了 gsBLDA 和 gsBLR 的模型参数能自动获取之外,其他通道选择方法都需要交叉验证来实现最优通道数的选择或者模型超参数的选择。某些方法需要多次使用交叉验证过程,比如 LASSO 进行通道选择时,先使用交叉验证选择模型参数,之后使用交叉验证选择最优通道数。本文使用 BLDA 作为 FDC、SVM-RCE 和 LASSO 最终的分类器,如果选择其他分类器(比如 SVM),则还需要额外的交叉验证来选择分类器的模型参数。gLASSO 和 sgLASSO,需要交叉验证联合搜索方

法,仔细调整正则化参数才能获得最佳性能。格搜索的参数范围并不好确定,有时候需要先大范围进行比较得到大概区域,之后再局部细化,非常繁琐耗时;在某些问题上,参数范围的选择还需要一定的经验或专业知识。相反,gsBLR 完全以数据驱动的方式工作,很大程度上降低了模型训练时间。另外,在小样本和噪声环境下,交叉验证选择的参数并不一定是最优的,容易产生过拟合。

比较 gsBLR 和 gsBLDA 方法,无论是通道数和分类

准确率,gsBLR 都优于 gsBLDA。gsBLDA 在 P300 通道选择和分类中取得了非常好的效果^[5],但在运动想象中却效果不佳,这在一定程度上反映了 gsBLDA 抗噪能力比较差。这可以通过比较两种脑电信号的不同特性得到较为合理的解释,P300 是事件相关电位的典型特征成分,由刺激事件诱发产生,具有锁时锁相的特性,信号经过叠加平均之后比较稳定;而运动想象 EEG 信号是大脑意念思维自发产生,随机性比较强、信噪比低。另外,gsBLR 噪声敏感性低于 gsBLDA 也可以从文献[35]的论述中得到进一步解释,即逻辑损失对异常值的敏感性低于平方误差损失,因此对于运动想象脑电信号的分类问题逻辑损失可能更有利。

本文只对 EEG 数据的组稀疏特性进行建模,在通道选择过程中,选择或者剔除,而没有考虑 EEG 信号的空间光滑性。EEG 信号是大脑局部区域神经元活动的共同响应,彼此靠近的电极采集的信号是相似的,因此多通道 EEG 信号具有空间光滑性。考虑空间光滑性,文献[36]在对 EEG 信号进行空间滤波时加入了空间光滑约束。在未来的研究工作中,将联合考虑 EEG 信号的组稀疏结构信息和空间光滑性,以期获得更好的效果。另外,gsBLR 方法的模型优化求解也是未来工作的研究重点。一方面,在求解 gsBLR 的过程中涉及大型的协方差矩阵逆的计算,比较耗时;Li 等^[37]提出的方法(基于对称高斯-赛德尔迭代的交替方向乘法)为此类问题的求解提供了思路。另一方面,张本鑫等^[38]提出的自适应步长梯度投影算法,有望减少权重迭代求解的收敛时间。

6 结 论

本文提出了基于组稀疏贝叶斯逻辑回归的运动想象脑电信号通道选择和分类方法。使用 GARD 先验对脑电数据的组稀疏特性进行建模,把每通道脑电信号作为一组,实现通道自动选择。在贝叶斯框架下,模型选择和参数确定直接从训练数据中自动估计得到,避免了耗时的交叉验证。BCI 竞赛数据和实验室自采集数据的实验结果表明,gsBLR 具有较好的准确率和较少的通道数,优于其他通道选择算法。另外,gsBLR 选择的通道集聚性高,与神经生理更加吻合。相比 gsBLDA,gsBLR 抗噪能力更强,更适用于运动想象脑电信号的分类。

参考文献

- [1] 徐宝国,何小杭,魏智唯,等. 基于运动想象脑电的机器人连续控制系统研究[J]. 仪器仪表学报, 2018, 39(9): 10-19.
XU B G, HE X H, WEI ZH W, et al. Research on continuous control system for robot based on motor
- imagery EEG [J]. Chinese Journal of Scientific Instrument, 2018, 39(9): 10-19.
- [2] 王行愚,金晶,张宇,等. 脑控:基于脑-机接口的人机融合控制[J]. 自动化学报, 2013, 39(3): 208-221.
WANG X Y, JIN J, ZHANG Y, et al. Brain control: Human-computer integration control based on brain-computer interface [J]. Acta Automatica Sinica, 2013, 39(3): 208-221.
- [3] 周淑伊,刘小燕,周建松,等. 基于标准时频变换的脑电信号分析方法[J]. 电子测量与仪器学报, 2018, 32(12): 127-133.
ZHOU SH Y, LIU X Y, ZHOU J S, et al. Analysis method of EEG signal based on normal time-frequency transform [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(12): 127-133.
- [4] XU M P, QI H ZH, MA L, et al. Channel selection based on phase measurement in P300-based brain-computer interface [J]. PLoS ONE, 2013, 8 (4): e60608.
- [5] YU T Y, YU ZHL, GU ZH H, et al. Grouped automatic relevance determination and its application in channel selection for P300 BCIs [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2015, 23(6): 1068-1077.
- [6] ATAIBY T, EL-SAMIE F E A, ALSHEBEILI S A, et al. A review of channel selection algorithms for EEG signal processing [J]. EURASIP Journal on Advances in Signal Processing, 2015(1): 66.
- [7] 单海军,朱善安. 基于 Relief-SBS 的脑机接口通道选择 [J]. 生物医学工程学杂志, 2016, 33 (2): 350-356.
SHAN H J, ZHU SH AN. A novel channel selection method for brain-computer interface based on relief-SBS [J]. Journal of Biomedical Engineering, 2016, 33(2): 350-356.
- [8] MIAO M, ZENG H, WANG A, et al. Discriminative spatial-frequency-temporal feature extraction and classification of motor imagery EEG: An sparse regression and weighted naive Bayesian classifier-based approach [J]. Journal of Neuroscience Methods, 2017, 278(2): 13-24.
- [9] LAN T, ERDOGMUS D, ADAMI A, et al. Salient EEG channel selection in brain computer interfaces by mutual information maximization [C]. IEEE Engineering in Medicine and Biology 27th Annual Conference, 2006: 7064-7067.
- [10] WANG Y, GAO S, GAO X. Common spatial pattern method for channel selection in motor imagery based brain-computer interface [C]. IEEE Engineering in

- Medicine and Biology 27th Annual Conference, 2006: 5392-5395.
- [11] ARVANEH M, GUAN C, ANG K K, et al. Optimizing the channel selection and classification accuracy in EEG-based BCI [J]. IEEE Transactions on Biomedical Engineering, 2011, 58(6) : 1865-1873.
- [12] LAL T N, SCHRODER M, HINTERBERGER T, et al. Support vector channel selection in BCI [J]. IEEE Transactions on Biomedical Engineering, 2004, 51(6) : 1003-1010.
- [13] FARQUHAR J, HILL N J, LAL T N, et al. Regularized CSP for sensor selection in BCI[J]. Proceeding of the 3rd International Brain-Computer Interface Workshop Training Course, 2006: 14-15.
- [14] WEI Q G, WANG Y M. Binary multi-objective particle swarm optimization for channel selection in motor imagery based brain-computer interfaces [C]. The 4th International Conference on Biomedical Engineering and Informatics (BMEI), 2011: 667-670.
- [15] KAMRUNNAHAR M, DIAS N S, SCHIFF S J. Optimization of electrode channels in brain computer interfaces[C]. Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2009: 6477-6480.
- [16] YANG J, SINGH H, HINES E L, et al. Channel selection and classification of electroencephalogram signals: An artificial neural network and genetic algorithm-based approach [J]. Artificial Intelligence in Medicine, 2012, 55(2) : 117-126.
- [17] GHAEMI A, RASHEDI E, POURRAHIMI A M, et al. Automatic channel selection in EEG signals for classification of left or right hand movement in brain computer Interfaces using improved binary gravitation search algorithm[J]. Biomedical Signal Processing and Control, 2017, 33(3) : 109-118.
- [18] YUAN M, LIN Y. Model selection and estimation in regression with grouped variables [J]. Journal of the Royal Statistical Society, 2006, 68(1) : 49-67.
- [19] 王金甲, 薛芳, 李慧. 基于稀疏组 LASSO 的脑机接口通道和特征选择研究 [J]. 仪器仪表学报, 2015, 36(8) : 1831-1837.
WANG J J, XUE F, LI H. Research on channel and feature selection for brain-computer interface based on sparse group LASSO [J]. Chinese Journal of Scientific Instrument, 2015, 36(8) : 1831-1837.
- [20] WEN ZH F, YU T Y, YU ZH L, et al. Grouped sparse Bayesian learning for voxel selection in multivoxel pattern analysis of fMRI data [J]. NeuroImage, 2019 (184) : 417-430.
- [21] LU H P, ENG H L, GUAN C T, et al. Regularized common spatial pattern with aggregation for EEG classification in small-sample setting [J]. IEEE Transactions on Biomedical Engineering, 2010, 57(12) : 2936-2946.
- [22] 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, 2017, 31(1) : 398-406.
- [23] ZHANG Y, LIU B, JI X M, et al. Classification of EEG signals based on autoregressive model and wavelet packet decomposition [J]. Neural Processing Letters, 2017, 45(2) : 1-14.
- [24] 李明爱, 张梦, 孙炎珺. 基于小波包和深度信念网络的脑电特征提取方法 [J]. 电子测量与仪器学报, 2018, 32(1) : 111-118.
LI M AI, ZHANG M, SUN Y J. EEG feature extraction method based on wavelet packet and deep belief network[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(1) : 111-118.
- [25] BISHOP C M. Pattern recognition and machine learning[M]. New York: Springer, 2006.
- [26] HOFFMANN U, VESIN J M, EBRAHIMI T, et al. An efficient P300-based brain-computer interface for disabled subjects [J]. Journal of Neuroscience Methods, 2008, 167(1) : 115-125.
- [27] TIPPING M E. Sparse Bayesian learning and the relevance vector machine [J]. Journal of Machine Learning Research, 2001, 1(3) : 211-244.
- [28] RUBIN D B. Iteratively Reweighted Least Squares [M]. Wiley StatsRef: Statistics Reference Online, 2006.
- [29] Fletcher R. Practical methods of optimization [M]. John Wiley & Sons, 2013.
- [30] DORNHEGE G, BLANKERTZ B, CURIO G, et al. Boosting bit rates in noninvasive EEG single-trial classifications by feature combination and multiclass paradigms [J]. IEEE Transactions on Biomedical Engineering, 2004, 51(6) : 993-1002.
- [31] SCHL ÖGL A, LEE F, BISCHOF H, et al. Characterization of four-class motor imagery EEG data for the BCI-competition [J]. Journal of Neural Engineering, 2005, 2(4) : L14-L22.
- [32] QI F F, LI Y Q, WU W. RSTFC: A novel algorithm for spatio-temporal filtering and classification of single-trial EEG [J]. IEEE Transactions on Neural Networks & Learning Systems, 2015, 26(12) : 3070-3082.
- [33] GRANT M, BOYD S, YE Y. CVX: MATLAB Software

for Disciplined Convex Programming [OP/OL]. CVXr. com/cvx/

- [34] PFURTSCHHELLER G, NEUPER C. Motor imagery and direct brain-computer communication [J]. Proceedings of the IEEE, 2001, 89(7): 1123-1134.
- [35] HOFFMANN U. Bayesian machine learning applied in a brain-computer interface for disabled users [R]. EPFL, 2007.
- [36] LOTTE F, GUAN C T. Regularizing common spatial patterns to improve BCI designs: Unified theory and new algorithms [J]. IEEE Transactions on Biomedical Engineering, 2011, 58(2): 355-362.
- [37] LI P L, XIAO Y H. An efficient algorithm for sparse inverse covariance matrix estimation based on dual formulation [J]. Computational Statistics & Data Analysis, 2018: 292-307.
- [38] 张本鑫, 朱志斌. 全变差图像恢复的自适应步长梯度投影算法 [J]. 自动化学报, 2016, 42(9): 1347-1355. ZHANG B X, ZHU ZH B. Gradient projection algorithm for total variation image restoration by adaptive steplength selection rules [J]. Acta Automatica Sinica, 2016, 42(9): 1347-1355.

作者简介



张绍荣, 现为桂林航天工业学院讲师、桂林电子科技大学博士研究生, 主要研究方向为最优化算法和机器学习及其在生物医学信号处理中的应用。

E-mail: zsrong@guat.edu.cn

Zhang Shaorong Now he is a lecturer at Guilin University of Aerospace Technology and a Ph. D. candidate at School of Electronic Engineering and Automation, Guilin University of Electronic Technology. His research interest covers optimization algorithm, machine learning and their applications in biomedical signal processing.



朱志斌 (通信作者), 2004 年于西安交通大学获得博士学位, 现为桂林电子科技大学数学与计算科学学院教授。主要研究方向为最优化算法及其在图像处理和反问题中的应用。

E-mail: optimization_zhu@163.com

Zhu Zhibin (Corresponding author) Now he is a professor at Guilin University of Electronic Technology. His main research interest include optimization algorithm and its applications in image processing and inverse problem.