

DOI:10.19651/j.cnki.emt.2315156

特征可分性显式建模的跨数据库脑电解码方法^{*}

李易¹ 张本鑫¹ 莫云² 路仲伟¹ 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)

摘要: 目前,在运动想象解码领域,研究主要集中在被试依赖和被试独立解码两种方法上。然而,这两种解码方式在脑机接口(BCI)系统的实际使用中存在较大局限性。被试依赖和被试独立解码都依赖于同一中心数据集,当解码模型应用于其他中心的数据集时,性能将显著下降,无法满足BCI系统跨中心使用的需求。为提升运动想象脑电跨数据库解码性能,基于领域泛化的方法框架,提出了一种基于Fisher准则正则化的稀疏选择模型。在最小绝对值收缩和选择算子(LASSO)模型的基础上,引入Fisher准则正则项,以在特征选择过程中显式建模特征的可分性。这有助于提高领域泛化的表示学习能力,从而增强分类模型在不同数据集上的泛化性能。采用两个公开的运动想象脑电数据集,并使用滤波器组共空间模式(FBCSP)和多时频共空间模式(MTFCSP)两种特征提取方法,验证了所提方法的有效性,进一步使用自采集的数据也证实了该方法在实际应用中同样有效。与现有的方法相比,所提方法取得了最高平均分类准确率,达到67.26%。实验结果表明,所提方法在运动想象跨数据库解码中具有更好的泛化能力、更高的特征可分性、更好的鲁棒性。所提方法有望促进BCI系统跨中心使用,提高通用性。

关键词: 运动想象;脑电解码;稀疏正则化;领域泛化;跨数据库

中图分类号: TN911.7; TH77; R318 文献标识码: A 国家标准学科分类代码: 310.61; 520.2040

Cross database EEG decoding method with explicit modeling of feature separability

Li Yi¹ Zhang Benxin¹ Mo Yun² Lu Zhongwei¹ 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)

Abstract: Currently, in the field of motor imagery decoding, research has focused on two approaches, subject-dependent and subject-independent decoding. However, these two decoding approaches have major limitations in the practical use of brain-computer interface (BCI) systems. Both subject-dependent and subject-independent decoding rely on the same center dataset, and when the decoding model is applied to datasets from other centers, the performance will be significantly degraded, which cannot satisfy the demand for cross-center use of BCI systems. To improve the cross-database decoding performance of motor imagery Electroencephalogram (EEG), a sparse selection model based on Fisher criterion regularization is proposed based on the methodological framework of domain generalization. Based on the least absolute shrinkage and selection operator (LASSO) model, a Fisher criterion regularization term is introduced to explicitly model feature separability during the feature selection process. This helps to improve the representation learning ability for domain generalization, thus enhancing the generalization performance of the classification model on different datasets. The effectiveness of the proposed method is validated using two publicly available motor imagery EEG datasets and two feature extraction methods, filter bank common spatial pattern (FBCSP) and multiple time frequency common spatial pattern (MTFCSP). Further validation through the utilization of self-collected data also confirmed the effectiveness of the proposed method in practical applications. Compared with existing methods, the proposed method achieved the highest average classification accuracy of 67.26%. The experimental results show that the proposed method has better generalization ability, higher feature separability, and better robustness in motion imagery cross-database decoding. The proposed method is expected to facilitate cross-center use of BCI systems and improve generalizability.

Keywords: motor imagery; EEG decoding; sparse regularization; domain generalization; cross-database

0 引言

脑机接口(brain computer interface, BCI)系统旨在大

脑和外部环境构建一种直接的人机交互方式。它监测大脑活动产生的脑电(electroencephalogram, EEG)信号并将其转化为外部设备的控制指令^[1]。运动想象BCI系统在脑中

收稿日期:2023-12-12

* 基金项目:广西自动检测技术与仪器重点实验室基金(YQ22209)、广西高校中青年教师科研基础能力提升项目(2023KY0813)、桂林电子科技大学研究生教育创新计划项目(2023YCXS132)资助

风和帕金森病等病患的运动康复方面具有广泛应用^[2-3],而运动想象准确解码是此类 BCI 系统的关键,显著影响康复训练的效果和被试的积极性。

随着 BCI 技术的发展,运动想象被试依赖和被试独立解码已得到广泛研究^[4-5]。然而,这两种解码方式都针对同一中心数据集(相同条件采集),使得运动想象解码在 BCI 系统的实际使用中仍存在较大局限性。比如,解码模型在一个实验中心适用,但在其他中心的数据集泛化性能显著下降^[6]。这无疑会降低 BCI 系统的通用性。相比被试依赖和被试独立解码,运动想象跨数据库解码面临巨大挑战,除了克服个体内和个体间的差异,还要考虑实验设备和实验条件的影响,比如脑电放大器、电极帽、通道数、采样率等^[7]。因此,运动想象跨数据库解码是 BCI 领域亟待解决的重要问题。

近年来,运动想象跨数据库解码开始引起研究人员的关注,但是相关的研究工作还是偏少。An 等^[8]提出一种双重注意力关系网络在 3 种运动想象数据集上进行跨数据集解码实验。先利用时间注意力模块增强重要时间特征,再通过聚合注意力模块寻找重要的支持集来预测查询集的标签,最后使用目标域少量被试的支持集对模型进行额外的微调,从而提高对未知数据集的泛化能力。Li 等^[9]研究了一种基于 VGG-16 卷积神经网络的参数迁移学习方法,从 PhysioNet 数据集选取 98 名被试作为预训练网络模型的源域,再利用 BCI 竞赛 IV IIb 数据集的前 4 个被试来微调预训练模型,剩下 5 个被试作为目标域。Xu 等^[10]研究了一种双对齐的多源域自适应框架,在两种运动想象数据集上实现跨数据集迁移学习。先对齐源域的数据分布,然后学习多个域的不变表示,以此对齐目标域和已对齐源域的特定特征分布,从而减少数据集之间的分布差异。然而,以上方法全部基于域适应方法,在模型训练中仍需要目标数据集的部分数据参与模型训练或者模型微调,无法实现 BCI 系统零训练跨中心使用。

领域泛化是另外一类迁移学习方法,在模型训练期间不需要获取任何目标域的数据样本^[11]。因此,已训练好的解码模型可以直接用在新中心的 BCI 系统中,实现零样本零训练;这更切合 BCI 系统的实际使用。基于此思想,本文在领域泛化的框架下开展运动想象跨数据库解码。为了提高跨领域泛化的能力,领域泛化主要通过 3 大类方法实现,分别为数据操作、表示学习和学习策略^[12]。本文通过分类器模型提升表示学习的能力,从而提升运动想象解码模型跨数据库的泛化能力。

由于不同数据集之间的显著差异,传统的分类器模型跨数据库解码性能显著下降。这包括一些常用的分类器,如 Fisher 线性判别分析(fisher linear discriminant analysis,FLDA)^[13]、贝叶斯线性判别分析(bayesian linear discriminant analysis, BLDA)^[13]、稀疏贝叶斯逻辑回归(sparse bayesian logistic regression, SBLR)^[14]、组稀疏贝叶

斯逻辑回归(group sparse bayesian logistic regression, gSBLR)^[14]等。这些分类器在分类过程中直接进行分类任务,忽略了对特征有效性的筛选。因此,转向一些注重特征选择的方法,包括最小绝对值收缩和选择算子(least absolute shrinkage and selection operator, LASSO)^[15]、组 LASSO(group LASSO, gLASSO)^[15]、稀疏组 LASSO(sparse group LASSO, sgLASSO)^[15]等。相较于传统分类器,这些方法在进行分类的同时嵌入了特征选择过程,更有效地处理特征之间的相关性,有助于筛选出最具代表性的特征,减少冗余信息的影响。尽管 LASSO 等稀疏模型在特征选择方面表现出色,但其过度关注特征的重要性而没有考虑特征之间的可分性,可能会影响分类性能。因此,本文将在 LASSO 模型的基础上提出基于 Fisher 准则正则化的稀疏特征选择模型,在选择重要特征的同时增强整体特征的特征可分性。

一方面,对比频-空特征和时-频-空特征对运动想象跨数据库解码性能的影响,或者说特征信息完备性对跨数据库解码性能的影响。另一方面,在 LASSO 模型的基础上,提出基于 Fisher 准则正则化的稀疏特征选择模型,寻求有效的特征表示学习方法。在选择重要特征的同时增强特征的可分性,以此提升解码模型跨数据库的泛化能力。使用两个公开的运动想象脑电数据集相互作为源域和目标域数据集,分别进行实验,验证所提方法跨数据库解码的泛化性能。

1 方 法

1.1 算法框架

本文提出的算法框架如图 1 所示,主要包括模型训练和模型测试。在模型训练过程中,将源域数据集所有被试的数据混合在一起,依次训练特征提取器和分类器(包含特征选择)。在模型测试过程中,利用训练阶段的特征提取器和分类器直接对目标域数据集的单个被试数据样本依次进行特征提取和分类,并计算每个被试运动想象任务的分类准确率。接下来将对特征提取器、分类器进行详细论述。

1.2 特征提取器

本文分别使用滤波器组共空间模式(filter bank common spatial pattern, FBCSP)方法^[16]和多时频共空间模式(multiple time frequency common spatial pattern, MTCSP)方法^[17]提取运动想象脑电的频-空特征和时-频-空特征。

1) FBCSP

FBCSP 方法^[16]的数据处理流程如图 2 所示。FBCSP 方法先从原始脑电信号截取 0.5~2.5 s 时间窗的单试次数据,然后使用滤波器组将脑电信号过滤成多个频率子带,接着分别对每个频带的脑电信号进行共空间模式(common spatial pattern, CSP)^[18]变换,提取空间特征。最后将多个频带的空间特征级联成一个特征向量并实施特征选择和分类,学习有效的脑电频-空信息。

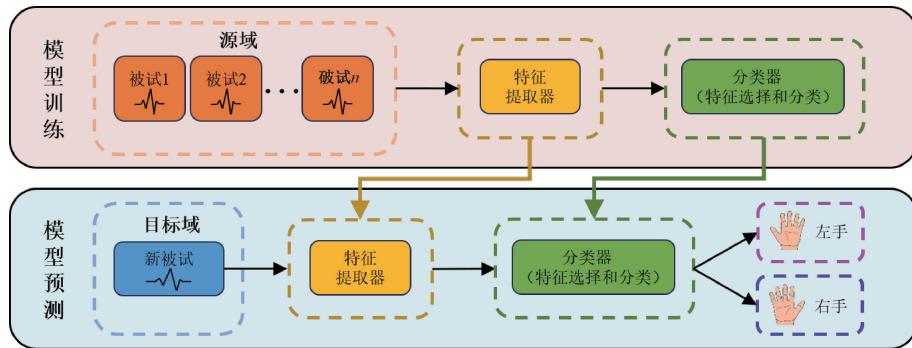


图1 本文提出的算法框架

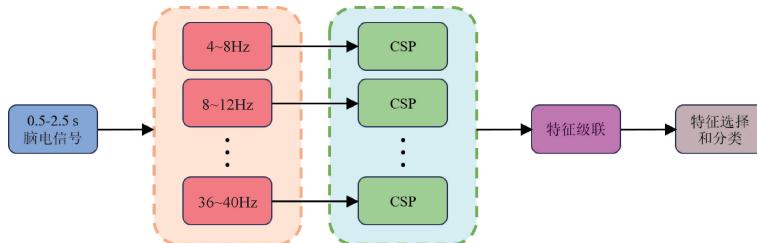


图2 FBCSP的数据处理流程(修改自文献[16])

2) MTFCSP

MTFCSP方法^[17]的数据处理流程如图3所示,在FBCSP的基础上加入时间窗选择,考虑被试特异的运动想象响应时间。MTFCSP先使用滑动时间窗将原始脑电信号分割成多个时间窗信号,然后再利用滤波器组对每个时

间窗信号进行滤波得到多个时-频单元,后续的处理过程与FBCSP一样。相比FBCSP,MTFCSP可以得到更完备的时-频-空信息,如此源域和目标域数据集可以在一个更大的特征空间学习共同特征表示。

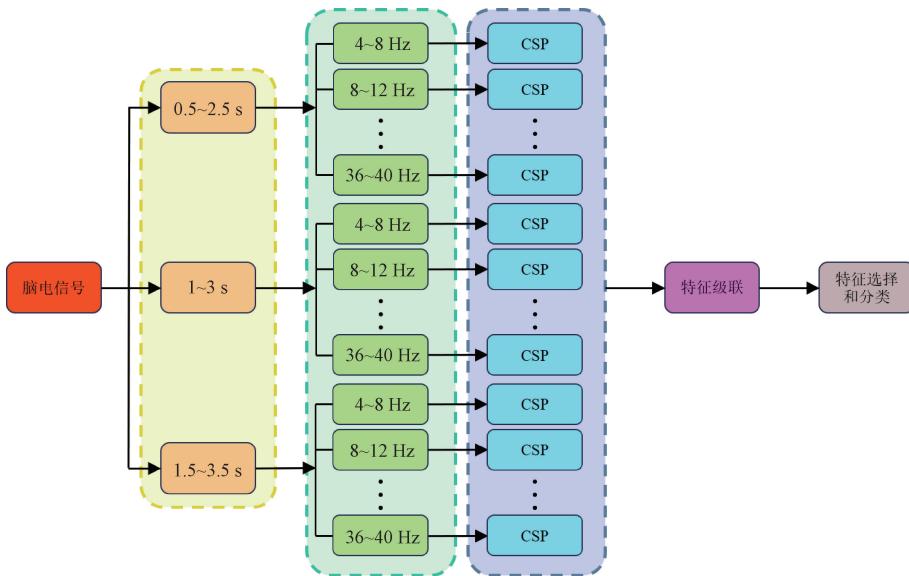


图3 MTFCSP的数据处理流程(修改自文献[17])

1.3 分类器

在本文中,考虑一类高效的分类器,该类分类器可同时进行特征选择和分类。一方面,特征选择可进一步筛选特征,提升跨域特征的稳定性;另一方面,特征选择和分类融合为一体可以减少数据处理步骤和计算量。

1) 基于 Fisher 准则正则化的稀疏特征选择模型

LASSO模型在神经解码、机器学习等领域都得到了广泛应用,其具体数学模型如下^[18]。

$$\mathbf{w} = \underset{\mathbf{w}}{\operatorname{argmin}} \frac{1}{2} \|\mathbf{y} - \mathbf{X}\mathbf{w}\|_2^2 + \lambda \|\mathbf{w}\|_1 \quad (1)$$

其中, $\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N)^T \in R^{N \times P}$ 代表脑电特征样本矩阵, N 代表样本数, P 代表单个样本的特征维度。 $\mathbf{w} \in R^P$ 代表模型权重系数, 相当于特征的权重。 $\mathbf{y} = [y_1, y_2, \dots, y_N]^T$ 为样本标签, $y_i \in \{-1, 1\}$ 。 $\|\cdot\|_2^2$ 表示 L_2 范数的平方, $\|\cdot\|_1$ 表示 L_1 范数, $\lambda > 0$ 是正则化参数。

LASSO 模型通过约束 \mathbf{w} , 使得部分特征的权重被压缩为 0, 从而选择与任务类别重要的特征。但是, LASSO 模型过度关注个体特征的重要性而没有考虑整体特征的可分性。本文将在 LASSO 模型的基础上提出基于 Fisher 准则正则化的稀疏特征选择模型, 在选择重要特征的同时增强整体特征的特征可分性。

Fisher 准则旨在寻找一个投影向量 \mathbf{w}_F , 使得两类样本在向量 \mathbf{w}_F 的投影下, 同类样本尽量靠近, 不同类别样本尽量远离。其目标函数具体如下:

$$J(\mathbf{w}_F) = \frac{\mathbf{w}_F^T \mathbf{S}_B \mathbf{w}_F}{\mathbf{w}_F^T \mathbf{S}_W \mathbf{w}_F} \quad (2)$$

其中, \mathbf{S}_B 和 \mathbf{S}_W 分别代表原始特征样本矩阵 \mathbf{X} 的类间散度矩阵和类内散度矩阵^[19]。

最大化 $J(\mathbf{w}_F)$ 等价于最大化 $\mathbf{w}_F^T \mathbf{S}_B \mathbf{w}_F$ 的同时最小化 $\mathbf{w}_F^T \mathbf{S}_W \mathbf{w}_F$, 而最大化 $\mathbf{w}_F^T \mathbf{S}_B \mathbf{w}_F$ 等价于最小化 $-\mathbf{w}_F^T \mathbf{S}_B \mathbf{w}_F$ 。因此, 最大化 $J(\mathbf{w}_F)$ 等价于最小化如下形式:

$$R(\mathbf{w}_F) = (\mathbf{w}_F^T \mathbf{S}_W \mathbf{w}_F - \mathbf{w}_F^T \mathbf{S}_B \mathbf{w}_F) \quad (3)$$

根据式(2)和(3)分析, 本文认为 $R(\mathbf{w}_F)$ 越小则特征集合的可分性越强。向量 \mathbf{w}_F 对特征样本进行投影后, 其特征可分性得到增强。据此, 将 $R(\mathbf{w}_F)$ 作为 LASSO 模型的新正则化项, 得到新的稀疏选择模型, 称之为 LASSO-F。将向量 \mathbf{w}_F 统一记为 \mathbf{w} , LASSO-F 的数学模型如下:

$$\mathbf{w} = \underset{\mathbf{w}}{\operatorname{argmin}} \frac{1}{2} \|\mathbf{y} - \mathbf{X}\mathbf{w}\|_2^2 + \lambda \|\mathbf{w}\|_1 + \rho R(\mathbf{w}) \quad (4)$$

本文认为特征可分性和标签损失同等重要, 因此将参数 ρ 设置为 1。由此可以看到, 新提出的稀疏正则化模型并没有增加模型参数。

2) LASSO-F 模型求解

LASSO-F 模型可以写成以下复合优化问题:

$$\underset{\mathbf{w}}{\operatorname{min}} g(\mathbf{w}) + h(\mathbf{w}) \quad (5)$$

其中, $g(\mathbf{w})$ 为光滑部分, $g(\mathbf{w}) = \frac{1}{2} \|\mathbf{y} - \mathbf{X}\mathbf{w}\|_2^2 + R(\mathbf{w})$, $R(\mathbf{w})$ 为正则项, $R(\mathbf{w}) = \lambda \|\mathbf{w}\|_1$ 是一个非光滑函数, 在解决问题时保留特殊的结构信息。

这里使用近端梯度法来求解式(5), 首先定义邻近算子如下:

$$\operatorname{prox}_h(\mathbf{u}) = \underset{\mathbf{w}}{\operatorname{argmin}} \left\{ h(\mathbf{w}) + \frac{1}{2} \|\mathbf{w} - \mathbf{u}\|_2^2 \right\} \quad (6)$$

由式(6)可知, 邻近算子是为了求出离点 \mathbf{u} 比较近的点, 并且使函数 $h(\mathbf{w})$ 的数值尽量小。当 $h(\mathbf{w}) = \lambda \|\mathbf{w}\|_1$ 时,

$$\operatorname{prox}_h(\mathbf{u}) = \begin{cases} \mathbf{u} - \lambda t, & \mathbf{w} > \lambda t, \\ 0, & |\mathbf{w}| \leq \lambda, \\ \mathbf{u} + \lambda t, & \mathbf{w} < -\lambda t. \end{cases} \quad (7)$$

其中, t 为步长, $t > 0$ 。

基于邻近算子的近端梯度法可以有效求解凸优化问题, 主要包含两个步骤。

(1) 梯度下降步。

给定一个迭代点 \mathbf{w}^k , 定义一个中间点 \mathbf{v}^k , 使得:

$$\mathbf{v}^k = \mathbf{w}^k - t \nabla g(\mathbf{w}^k) \quad (8)$$

式中: $\nabla g(\mathbf{w}^k)$ 为 $g(\mathbf{w})$ 在点 \mathbf{w}^k 的梯度。

$$\nabla g(\mathbf{w}^k) = \mathbf{X}^T (\mathbf{X}\mathbf{w}^k - \mathbf{y}) + 2(\mathbf{S}_W \mathbf{w}^k - \mathbf{S}_B \mathbf{w}^k) \quad (9)$$

(2) 邻近算子步。

计算 $h(\mathbf{w})$ 的邻近算子为:

$$\mathbf{w}^{k+1} = \operatorname{prox}_h(\mathbf{v}^k) = \operatorname{prox}_h(\mathbf{w}^k - t \nabla g(\mathbf{w}^k)) \quad (10)$$

以上两个步骤交替执行, 逐步逼近最优解。

2 实验结果与分析

2.1 实验数据

数据集 1: BCI 竞赛 IV(2008) 数据集 IIa^[20]。该数据集包含 9 个健康被试, 分别以 A01, A02, …, A09 标识。每个被试执行 4 种运动想象任务, 包括左手、右手、脚和舌头。该数据集采用 22 个电极通道并以 250 Hz 采样率记录头皮脑电。详细信息可在官方网站 <https://www.bbci.de/competition/iv/> 上查阅。本文将该数据集简记为 BCI2008_IIa。

数据集 2: BNCI 2020 项目数据库, 编号为 002 ~ 2014^[21]。该数据集包含 14 名健康被试, 分别以 S01, S02, …, S14 标识。每个被试执行两种运动想象任务, 包括右手和脚。该数据集采用 15 个电极通道并以 512 Hz 采样率记录头皮脑电。详细信息可在官方网站 <http://bnchi-horizon-2020.eu/database/data-sets> 上查阅。本文将该数据集简记为 BNCI2014_002。

2.2 数据预处理

由于两个数据集的电极通道、采样率和执行任务类别都不同, 对两个数据集进行统一预处理, 具体如下:

1) 通道选择。选取两个数据集共有的 3 个通道: C3、CZ、C4。

2) 任务选择。使用两个数据集共有的运动想象任务: 右手和脚。

3) 重采样。将 BNCI2014_002 数据集重采样至 250 Hz。

2.3 比较方法和参数设置

FBCSP: 时间窗为 0.5 ~ 2.5 s, 并对 3 个通道使用滤波器组进行滤波, 得到 9 个宽度为 4 Hz 的频率子带, 即 4 ~ 8 Hz, 8 ~ 12 Hz, …, 36 ~ 40 Hz。

MTFCSP: 使用滑动时间窗对原始脑电信号进行分割, 得到 3 个长度为 2 s 的时间窗信号, 即 0.5 ~ 2.5 s, 1 ~ 3 s, 1.5 ~ 3.5 s。接着对每个时间窗信号进行滤波, 得到 9 个宽度为 4 Hz 的频率子带, 即 4 ~ 8 Hz, 8 ~ 12 Hz, …,

36~40 Hz。

为了验证 LASSO-F 的有效性,将其与现有的分类方法进行比较,分别为 FLDA、BLDA、LASSO、gLASSO、sgLASSO、SBLR、gSBLR。LASSO、gLASSO、sgLASSO 3 个模型的最优正则化参数通过 10 折交叉验证和网格搜索方法选出,正则化参数的备选集合为 $\{2^{-5}, 2^{-4.8}, \dots, 2^{4.8}, 2^5\}$ 。

FBCSP 和 MTFCSP 在使用 CSP 求解空间滤波器时,空间滤波器对数都设置为 1^[22]。

2.4 实验结果

本文将从分类结果、特征可分性和鲁棒性 3 个方面分

析各种方法的运动想象跨数据库解码性能。

1) 分类结果

在 FBCSP 和 MTFCSP 特征提取方法下,各种分类器的分类结果如表 1~4 所示。表中的“BNCI2014_002 → BCI2008_Ila”表示 BNCI2014_002 为源域数据集,用于训练模型;BCI2008_Ila 为目标域数据集,模型预测目标数据集每个被试的分类结果并取平均,最优结果粗体显示。“BCI2008_Ila → BNCI2014_002”表示 BCI2008_Ila 为源域数据集,BNCI2014_002 为目标域数据集,其他的类似。

表 1 FBCSP 分类准确率(BNCI2014_002→BCI2008_Ila)

被试	FLDA	BLDA	LASSO	gLASSO	sgLASSO	SBLR	gSBLR	LASSO-F
A01	73.61	74.31	77.08	78.47	78.47	74.31	75.00	77.78
A02	50.00	50.00	50.00	50.69	50.69	50.00	50.00	50.00
A03	75.69	77.08	77.08	76.39	76.39	77.78	79.17	81.25
A04	58.33	57.64	57.64	52.08	52.78	55.56	54.86	53.47
A05	51.39	51.39	50.69	50.69	51.39	52.08	52.08	51.39
A06	49.31	49.31	49.31	49.31	49.31	47.92	47.92	50.69
A07	71.53	71.53	70.83	67.36	66.67	72.22	72.22	72.22
A08	53.47	53.47	52.78	54.17	54.17	52.08	51.39	53.47
A09	50.00	50.00	50.00	50.00	50.00	51.39	51.39	51.39
Mean	59.26	59.41	59.49	58.80	58.87	59.26	59.34	60.18
±Std	10.51	10.87	11.34	11.23	11.08	11.21	11.65	12.19

表 2 MTFCSP 分类准确率(BNCI2014_002→BCI2008_Ila)

被试	FLDA	BLDA	LASSO	gLASSO	sgLASSO	SBLR	gSBLR	LASSO-F
A01	78.47	80.56	79.86	79.17	78.47	79.86	77.78	81.94
A02	49.31	50.00						
A03	71.53	76.39	77.08	81.25	77.78	77.78	79.86	86.11
A04	56.25	57.64	56.25	54.86	54.86	56.25	54.86	52.08
A05	53.47	52.78	52.08	52.08	52.08	52.08	52.08	53.47
A06	51.39	51.39	51.39	52.08	51.39	50.69	50.69	52.08
A07	70.83	75.00	72.92	75.69	73.61	70.83	71.53	75.00
A08	56.25	54.86	52.08	52.08	52.08	52.78	54.17	50.69
A09	50.69	51.39	50.69	52.78	50.00	51.39	52.08	52.78
Mean	59.80	61.11	60.26	61.11	60.03	60.18	60.34	61.57
±Std	10.20	11.73	11.80	12.56	11.87	11.63	11.62	14.03

从表 1~4 可以看出,无论是哪种特征提取方法,LASSO-F 都取得了最高的平均分类准确率;而且无论哪个数据集作为源域训练模型,该结论也成立。对比表 1 和 2 的结果,发现 MTFCSP 特征提取方法优于 FBCSP;对比表 3 和 4 也可以得到类似的结果。

为了更直观地比较,图 4 给出了更全面的展示。很明显,各分类器在 MTFCSP 特征提取方法下取得的分类结果更佳。

另外,也发现模型从源域数据集 BCI2008_Ila 泛化到目标域数据集 BNCI2014_002 取得更好的分类结果。从分类器对比来看,LASSO-F 鲁棒性和普适性更好,无论在哪种情况下都取得了较好的分类效果,而其他分类器性能表现不稳定。比如 gLASSO 在 MTFCSP 特征上表现较好,但是在 FBCSP 特征上表现较差。

2) 特征可分性分析

本文从特征可视化和 Fisher 比值两方面评价分类模

表 3 FBCSP 分类准确率(BCI2008_IIa→BNCI2014_002)

被试	FLDA	BLDA	LASSO	gLASSO	sgLASSO	SBLR	gSBLR	LASSO-F
S01	45.00	43.33	46.67	46.67	45.00	45.00	43.33	45.00
S02	78.33	76.67	76.67	76.67	76.67	76.67	76.67	83.33
S03	65.00	63.33	66.67	63.33	65.00	63.33	63.33	61.67
S04	58.33	58.33	58.33	58.33	58.33	58.33	58.33	61.67
S05	65.00	66.67	68.33	65.00	68.33	65.00	66.67	70.00
S06	73.33	75.00	75.00	75.00	76.67	71.67	75.00	80.00
S07	63.33	63.33	58.33	60.00	60.00	60.00	60.00	61.67
S08	70.00	73.33	75.00	73.33	75.00	75.00	75.00	70.00
S09	80.00	81.67	90.00	81.67	88.33	83.33	81.67	98.33
S10	40.00	41.67	41.67	41.67	43.33	43.33	41.67	48.33
S11	45.00	43.33	41.67	43.33	41.67	41.67	43.33	43.33
S12	65.00	66.67	66.67	65.00	65.00	65.00	65.00	56.67
S13	55.00	60.00	60.00	60.00	60.00	58.33	58.33	55.00
S14	58.33	58.33	60.00	58.33	60.00	61.67	63.33	56.67
Mean	61.55	62.26	63.21	62.02	63.10	62.02	62.26	63.69
± Std	11.79	12.21	13.35	11.81	13.12	12.05	12.29	14.92

表 4 MTF CSP 分类准确率(BCI2008_IIa→BNCI2014_002)

被试	FLDA	BLDA	LASSO	gLASSO	sgLASSO	SBLR	gSBLR	LASSO-F
S01	50.00	53.33	53.33	50.00	53.33	48.33	50.00	63.33
S02	76.67	76.67	78.33	76.67	78.33	76.67	78.33	83.33
S03	71.67	63.33	60.00	61.67	60.00	65.00	61.67	73.33
S04	53.33	55.00	58.33	58.33	58.33	50.00	53.33	60.00
S05	65.00	65.00	65.00	65.00	65.00	61.67	63.33	70.00
S06	75.00	80.00	85.00	83.33	85.00	76.67	78.33	76.67
S07	66.67	68.33	68.33	68.33	68.33	68.33	65.00	75.00
S08	68.33	66.67	68.33	68.33	68.33	66.67	66.67	65.00
S09	96.67	98.33	98.33	98.33	98.33	96.67	98.33	98.33
S10	46.67	45.00	46.67	53.33	46.67	46.67	45.00	61.67
S11	45.00	46.67	41.67	45.00	41.67	46.67	46.67	55.00
S12	61.67	63.33	65.00	61.67	65.00	66.67	66.67	51.67
S13	56.67	50.00	53.33	53.33	53.33	46.67	46.67	50.00
S14	58.33	51.67	53.33	51.67	53.33	55.00	58.33	58.33
Mean	63.69	63.09	63.93	63.93	63.93	62.26	62.74	67.26
± Std	13.35	14.18	14.77	13.97	14.77	14.17	14.37	12.79

型的特征可分性。

为展示各分类模型的特征可分性,采用 t 分布随机近邻嵌入方法(t-stochastic neighbor embedding,t-SNE)^[23]进行特征可视化。在 FBCSP 和 MTF CSP 特征提取方法下,目标域数据集 BNCI2014_002 被试 S09 数据的特征可视化如图 5 和 6 所示。

在图 5 中,LASSO-F 方法的紫色方框(脚任务的样本)聚集区右上角只有 3 个不同类别的蓝色圆点(右手任

务的样本),蓝色圆点聚集区左下角不存在紫色方框,并且紫色方框聚集区域和蓝色圆点聚集区域有明显的空白区分。相比其他方法,LASSO-F 模型的特征可分性更好。在图 6 中,LASSO-F 方法的紫色方框(脚任务的样本)聚集区只有 1 个蓝色圆点(右手任务的样本),而且靠蓝色圆点聚集区的一边。相比其他方法,LASSO-F 模型的特征可分性仍然是比较好的。

进一步,通过模型分类准确率和 Fisher 比值的对应关

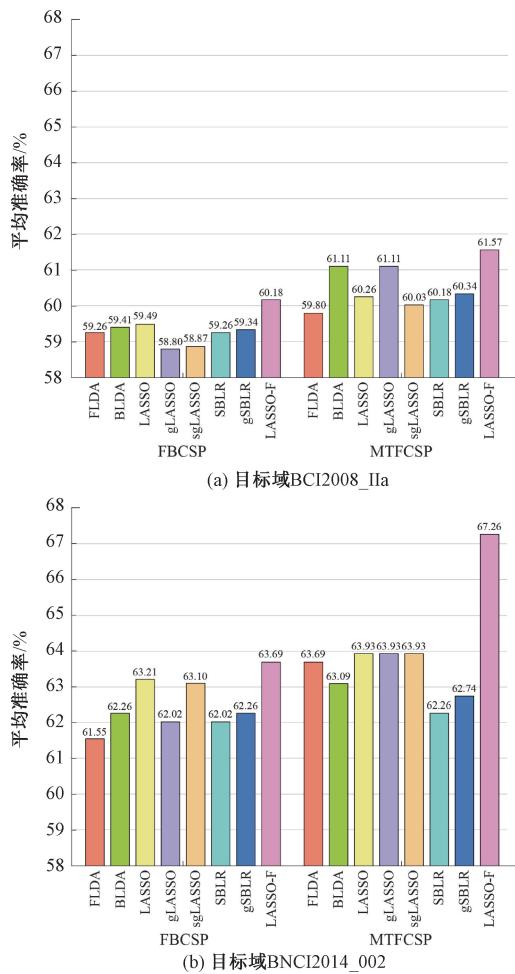


图 4 不同特征提取方法的平均分类准确率

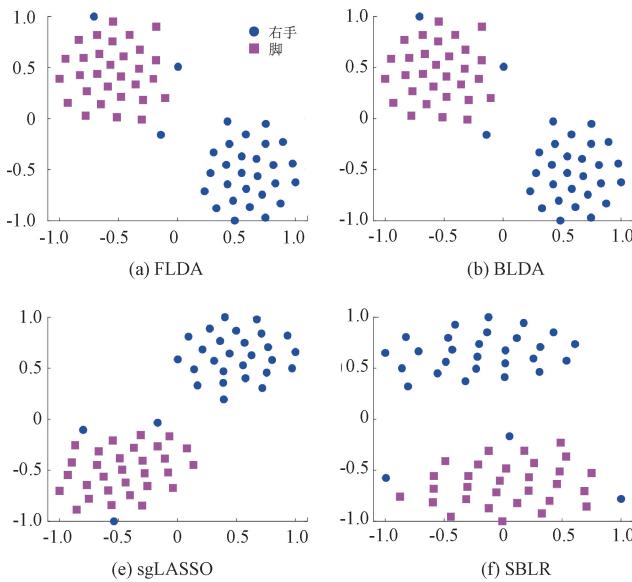


图 5 FBCSP 下各分类模型的特征可视化

由于数据集 BNCI2014_002 与自采集的数据集运动想象任务不同,这里使用 BCI2008_IIa 数据集左、右手运动想

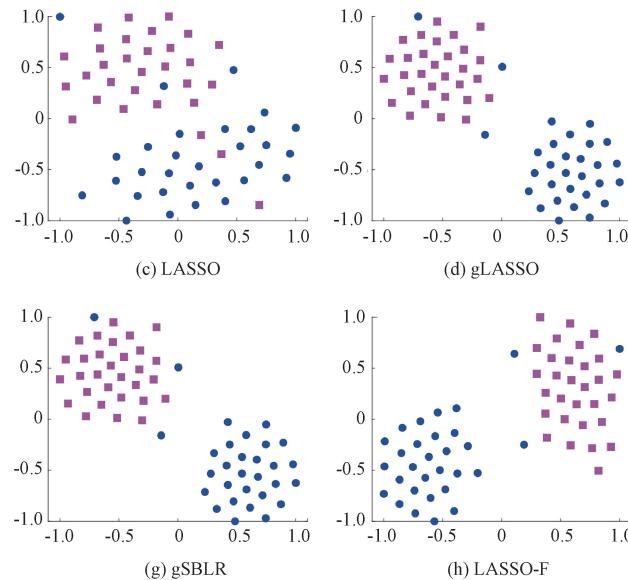
象评估 LASSO-F 方法的特征可分性,模型分类准确率和 Fisher 比值如表 5 所示。在表 5 中,分类准确率和 Fisher 比值都是目标域数据集所有被试的平均值,Fisher 比值由前文 1.3 节的式(2)计算。从表 5 中可以看到,无论哪个数据集作为源域以及哪种特征提取方法,较高的分类准确率都对应着较高的 Fisher 比值。LASSO-F 的 Fisher 比值最高,所以分类结果最好。

3) 模型鲁棒性分析

从模型的权重系数,即特征权重,分析各分类模型的鲁棒性。以 BCI2008_IIa 为源域数据集训练分类模型,在 FBCSP 和 MTFCSP 特征提取方法下,各分类模型的特征权重分布如图 7 和 8 所示。从图 7 和 8 中可以看到,相比之下,LASSO-F 模型的特征权重比较小而且差值不大,因此特征权重较为平滑,噪声敏感性较低;即使有较大的噪声或者异常值,模型输出变化导致的波动不会太大。而其他分类模型的特征权重值分布比较散乱,且权重值的变化非常大,容易受到噪声干扰,导致模型输出不稳定。总体而言,LASSO-F 模型的鲁棒性较好。

3 实际应用

为进一步验证所提方法 LASSO-F 的有效性,将其应用于实验室自采集的数据集。该数据集使用 40 导脑电放大器(Neuroscan 公司)采集了来自 5 个健康被试的脑电数据;自采集数据集记为 BCI_3G,被试分别以 G01, G02, …, G05 标识。每个被试执行两种运动想象任务,包括左手、右手。该数据集使用 30 个电极通道并以 250 Hz 采样率记录头皮脑电。



象任务的数据和自采集数据进行模型泛化实验,并选取两个数据集共有的 3 个通道:C3、CZ、C4。

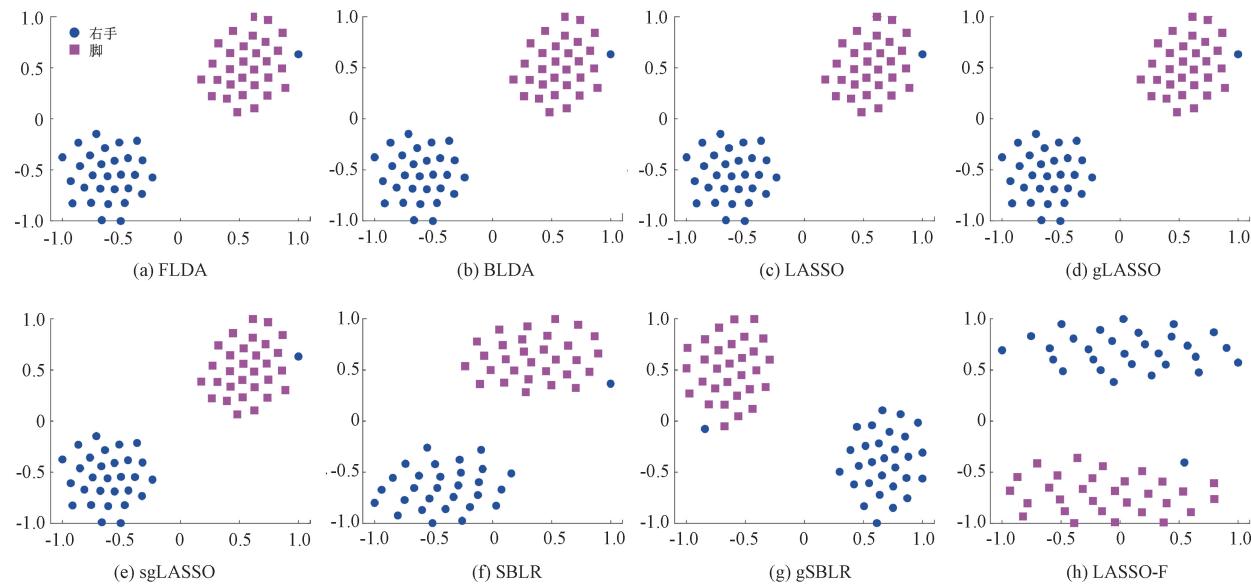


图 6 MTF CSP 下各分类模型的特征可视化

表 5 模型分类准确率和 Fisher 比值

源域→目标域		BNCI2014_002→BCI2008_Ia				BCI2008_Ia→BNCI2014_002			
特征提取器	FBCSP	MTFCSP		FBCSP		MTFCSP			
分类器	LASSO	LASSO-F	LASSO	LASSO-F	LASSO	LASSO-F	LASSO	LASSO-F	
平均分类准确率	59.49	60.18	60.26	61.57	63.21	63.69	63.93	67.26	
平均 Fisher 比值	0.353 0	0.493 6	0.562 9	0.757 7	1.087 5	1.226 9	1.354 9	1.804 8	

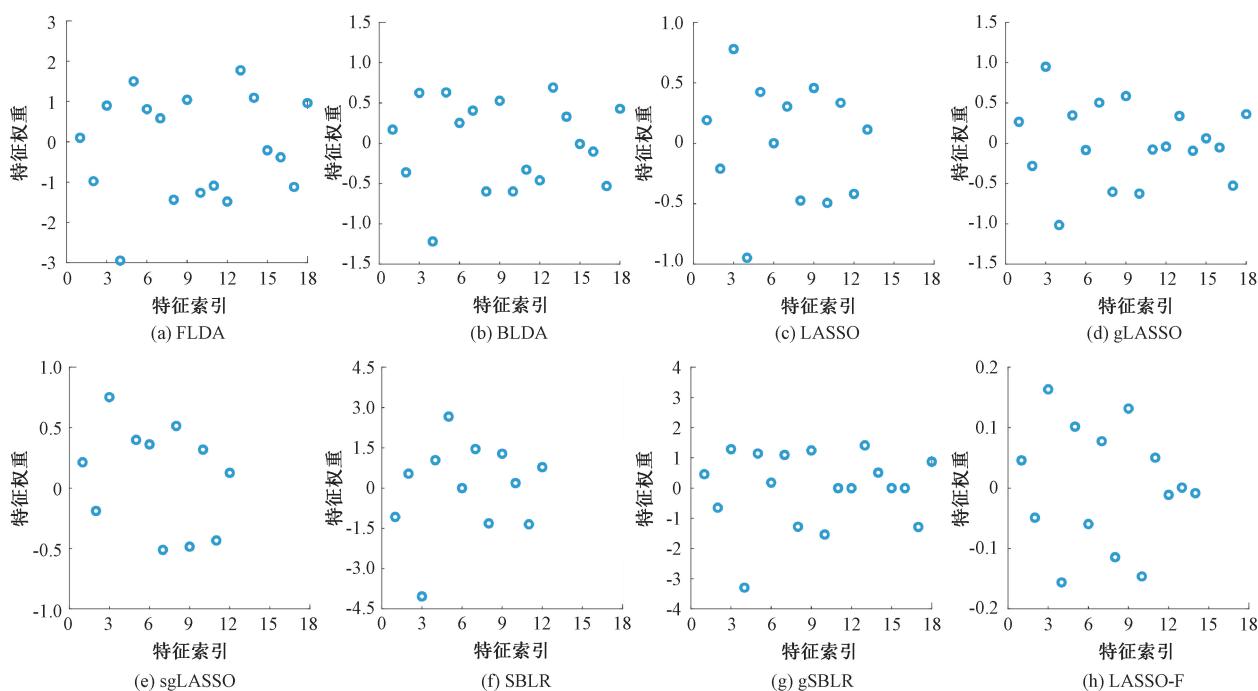


图 7 FBCSP 下各分类模型的特征权重分布

在 FBCSP 和 MTFCSP 特征提取方法下,以源域数据集 BCI2008_Ia 训练的模型泛化到目标域数据集 BCI_3G 的应用场景下,各种分类器的分类结果如图 9 所示。由于

自采集数据的信号质量相对公开数据较差,分类准确率有所下降,但无论采用何种特征提取方法,所提方法 LASSO-F 都取得最高的平均分类准确率,进一步验证所提方法在

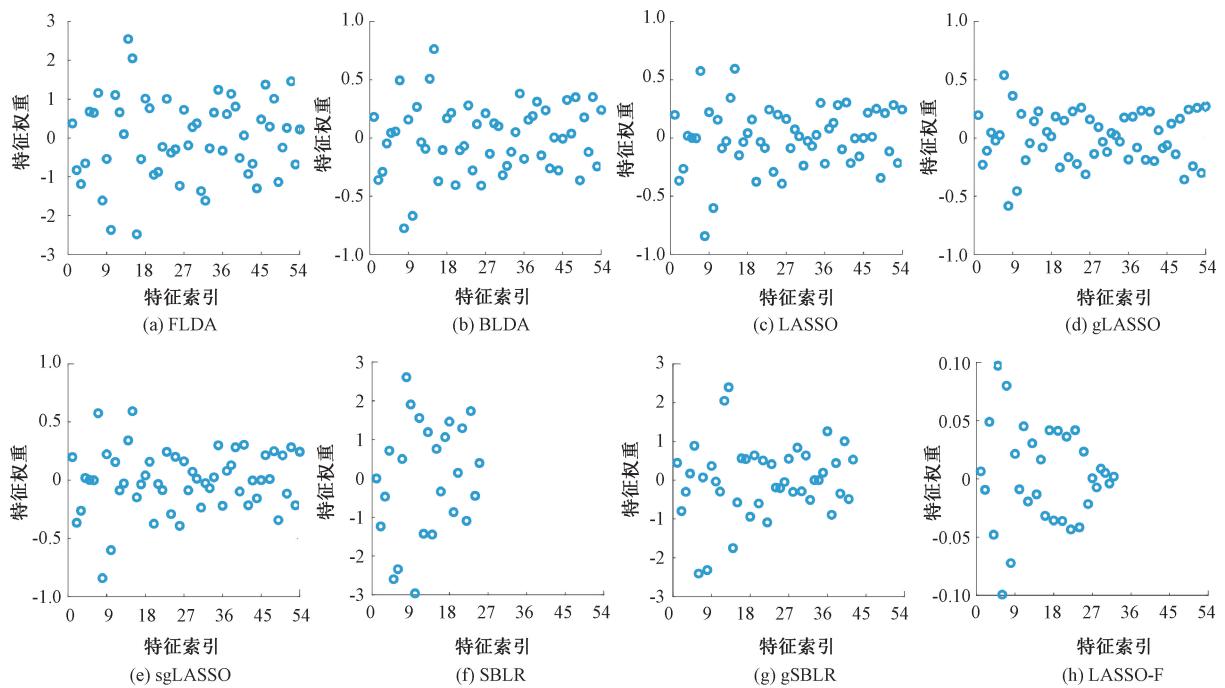


图 8 MTF CSP 下各分类模型的特征权重分布

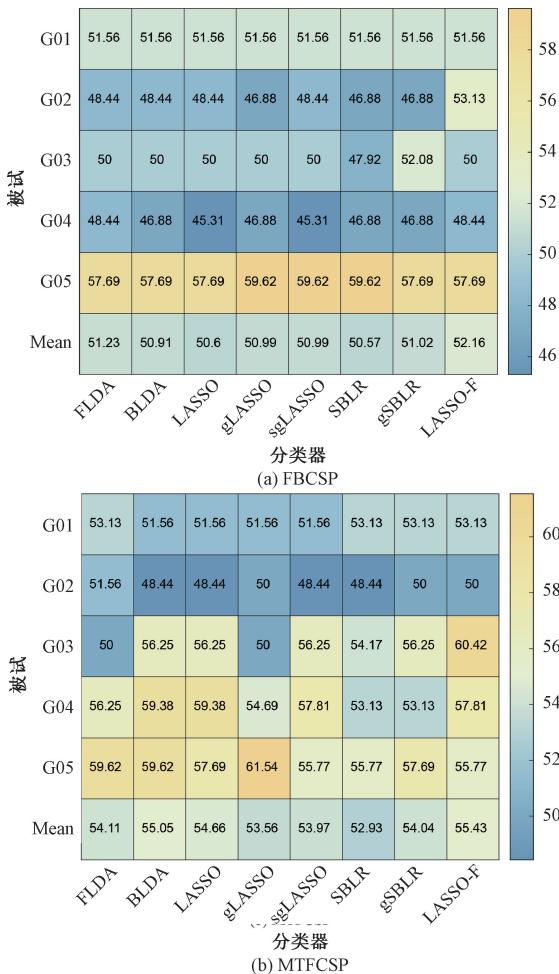


图 9 不同特征提取方法的分类结果

运动想象跨数据库解码中具有更好的泛化能力。并且所有分类器在 MTF CSP 特征提取方法下取得的分类结果更佳,进一步验证特征信息完备性能提高跨数据库解码性能。

4 讨论

从表 1~4 和图 9 的分类结果可以看到,MTFCSP 特征提取方法优于 FBCSP,其原因可能是 MTFCSP 具有更丰富的时-频-空信息。这些结果表明脑电特征信息的完备性对分类模型跨数据库泛化具有显著影响,完备的特征空间有利于分类模型学习一个更大的跨数据库共享的特征空间。

LASSO-F 在 LASSO 模型的基础上进行改进,在选择重要特征的同时强调特征可分性,因此所选择的特征集合更具判别性。从分类结果分析,LASSO-F 模型跨数据库泛化能力比现有方法更具优势;从特征可分性结果分析,LASSO-F 可以增强特征可分性,具有更大的 Fisher 比值,从而获得更高的分类准确率;从模型鲁棒性分析,LASSO-F 模型平滑稳定,具有更好的噪声抑制能力。

综上所述,本文提出的基于 Fisher 准则正则化的稀疏选择模型,即 LASSO-F 模型,在特征选择过程中显式建模特征可分性,可以有效地提高运动想象脑电跨数据库解码的泛化能力。

5 结论

本文开发有效的领域泛化方法,进行运动想象脑电跨数据库解码,旨在实现脑机接口系统跨中心零训练使用。

具体地,在 LASSO 模型的基础上,提出了一种基于 Fisher 准则正则化的稀疏选择模型,在特征选择过程中显式建模特征可分性,提升脑电特征的表示学习能力,从而提高分类模型跨数据库解码的泛化性能。采用两个公开的运动想象脑电数据集,在 FBCSP 和 MTCFSP 两种特征提取方法下,验证所提方法的有效性,进一步使用自采集的数据也证实了该方法在实际应用中同样有效。结果表明,本文提出的 LASSO-F 在运动想象跨数据库解码中泛化能力更强、特征可分性更高和鲁棒性更好,证明特征选择方法显式建模特征可分性进而提升运动想象脑电跨数据库解码性能是可行的。该工作在实际应用中具有重要意义,跨数据库解码可以促进脑机接口系统跨中心、跨被试使用,提高脑机接口系统的通用性。在未来的工作中,将转向深度学习,利用注意力机制、大模型等更先进的人工智能技术解决运动想象跨数据库解码问题。

参考文献

- [1] TANG X, SHEN H, ZHAO S, et al. Flexible brain-computer interfaces [J]. Nature Electronics, 2023, 6(2): 109-118.
- [2] NOJIMA I, SUGATA H, TAKEUCHI H, et al. Brain-computer interface training based on brain activity can induce motor recovery in patients with stroke: A meta-analysis[J]. Neurorehabilitation and Neural Repair, 2022, 36(2): 83-96.
- [3] MILADINOVIC A, AJCEVIC M, BUSAN P, et al. Evaluation of motor imagery-based BCI methods in neurorehabilitation of Parkinson's disease patients[C]. 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society(EMBC), IEEE, 2020: 3058-3061.
- [4] CHEN Y, YANG R, HUANG M, et al. Single-source to single-target cross-subject motor imagery classification based on multisubdomain adaptation network[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2022, 30: 1992-2002.
- [5] LI A, WANG Z, ZHAO X, et al. MDTL: A novel and model-agnostic transfer learning strategy for cross-subject motor imagery BCI [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2023, 31: 1743-1753.
- [6] XU L, XU M, KE Y, et al. Cross-dataset variability problem in EEG decoding with deep learning [J]. Frontiers in Human Neuroscience, 2020, 14: 103.
- [7] XU L, XU M, MA Z, et al. Enhancing transfer performance across datasets for brain-computer interfaces using a combination of alignment strategies and adaptive batch normalization[J]. Journal of Neural Engineering, 2021, 18(4): 0460e5.
- [8] AN S, KIM S, CHIKONTWE P, et al. Dual attention relation network with fine-tuning for few-shot EEG motor imagery classification [J]. IEEE Transactions on Neural Networks and Learning Systems, 2023.
- [9] LI M A, XU D Q. A transfer learning method based on VGG-16 convolutional neural network for MI classification [C]. 2021 33rd Chinese Control and Decision Conference (CCDC), IEEE, 2021: 5430-5435.
- [10] XU D, LI M. A dual alignment-based multi-source domain adaptation framework for motor imagery EEG classification[J]. Applied Intelligence, 2023, 53(9): 10766-10788.
- [11] QIN X, WANG J, CHEN Y, et al. Domain generalization for activity recognition via adaptive feature fusion[J]. ACM Transactions on Intelligent Systems and Technology, 2022, 14(1): 1-21.
- [12] WANG J, LAN C, LIU C, et al. Generalizing to unseen domains: A survey on domain generalization[J]. IEEE Transactions on Knowledge and Data Engineering, 2022.
- [13] 赵紫宁, 李智, 张绍荣. 运动想象脑机接口中两种改进的脑电共空域模式特征提取方法[J]. 电子测量与仪器学报, 2019, 33(12): 64-70.
- [14] WEN Z, YU T, YU Z, et al. Grouped sparse Bayesian learning for voxel selection in multivoxel pattern analysis of fMRI data[J]. NeuroImage, 2019, 184: 417-430.
- [15] ZHANG S, ZHU Z, ZHANG B, et al. Fused group lasso: A new EEG classification model with spatial smooth constraint for motor imagery-based brain-computer interface[J]. IEEE Sensors Journal, 2020, 21(2): 1764-1778.
- [16] 莫云. 基于 CSP 变换和滤波器组的对数带通功率特征提取方法[J]. 电子测量技术, 2021, 44(10): 33-38.
- [17] 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 naïve Bayesian classifier-based

- approach[J]. Journal of Neuroscience Methods, 2017, 278: 13-24.
- [18] 路仲伟,陈勇,莫云,等.基于 TRCSP 和 L2 范数的脑电通道选择方法[J].电子测量技术,2023,46(7): 94-102.
- [19] 高翔,侯宇超,程蓉,等.基于多特征融合与 Fisher 准则的遥感场景图像分类[J].兰州大学学报(自然科学版),2023,59(1): 90-97.
- [20] ZHANG Y, NAM C S, ZHOU G, et al. Temporally constrained sparse group spatial patterns for motor imagery BCI[J]. IEEE Transactions on Cybernetics, 2018, 49(9): 3322-3332.
- [21] STEYRL D, SCHERER R, FALLER J, et al. Random forests in non-invasive sensorimotor rhythm brain-computer interfaces: A practical and convenient non-linear classifier [J]. Biomedical Engineering/Biomedizinische Technik, 2016, 61(1): 77-86.
- [22] 张绍荣,赵紫宁,莫云,等.特征提取对通道选择方法的影响研究[J].国外电子测量技术,2020,39(9): 1-6.
- [23] AUTTHASAN P, CHAISAEN R, SUDHAWIYANGKUL T, et al. MIN2Net: End-to-end multi-task learning for subject-independent motor imagery EEG classification[J]. IEEE Transactions on Biomedical Engineering, 2021, 69(6): 2105-2118.

作者简介

李易,硕士研究生,主要研究方向为脑电信息处理与数学优化。

E-mail: m18589833462@163.com

莫云(通信作者),工程师,主要研究方向为生物医学和智能仪器。

E-mail: moyun@guat.edu.cn