

DOI: 10.13382/j.jemi.B2407684

基于权重融合特征重标定网络的运动想象脑电分类*

莫云¹ 李易² 张本鑫² 路仲伟² 莫禾胜¹ 李智^{1,2}

(1. 桂林航天工业学院电子信息与自动化学院 桂林 541004; 2. 桂林电子科技大学电子工程与自动化学院 桂林 541004)

摘要:时-频-空特征在运动想象脑电分类中广泛应用,但如何有效利用这些特征提高运动想象分类准确率仍是难点。传统方法通过特征选择剔除冗余信息,但往往忽视了时-频-空特征的组间依赖关系。为此,提出一种基于权重融合特征重标定网络的脑电分类模型。首先,提取时-频-空特征,揭示其分组结构,将每组时-频-空特征作为一个整体,并视为一个特征图。然后,建立两个分支分别获取特征图的通道权重:一个分支通过全局平均池化获取全局信息的通道权重,另一个分支通过全局最大池化获取局部信息的通道权重。接着,设计权重融合操作,将两种通道权重融合,并对特征图进行重缩放,从而实现时-频-空特征的组间依赖关系建模。最后,使用两层全连接层进行分类。在4个公开的运动想象脑电数据集上进行了实验验证,所提出的方法平均分类准确率高达80.72%,优于18种特征选择方法和现有的特征重标定网络方法,以及大多数近期文献的分类结果。实验结果表明,所提方法在实际应用中具有良好的潜力,有望在未来的脑机接口研究和康复训练中得到广泛应用。

关键词:脑电分类;运动想象;特征重标定;时-频-空特征;权重融合

中图分类号: TN911.7; TH77

文献标识码: A

国家标准学科分类代码: 310.61; 520.2040

Weight fusion-based feature recalibration network for motor imagery EEG classification

Mo Yun¹ Li Yi² Zhang Benxin² Lu Zhongwei² Mo Hesheng¹ Li Zhi^{1,2}

(1. School of Electronic Information and Automation, Guilin University of Aerospace Technology, Guilin 541004, China;

2. School of Electronic Engineering and Automation, Guilin University of Electronic Technology, Guilin 541004, China)

Abstract: Time-frequency-spatial features are widely used in motor imagery EEG classification, but effectively utilizing these features to improve classification accuracy remains challenging. Traditional methods often eliminate redundant information through feature selection but tend to overlook the intergroup dependency of time-frequency-spatial features. To address this issue, we propose an EEG classification model based on a feature recalibration network with weight fusion (FRNWF). First, we extract the time-frequency-spatial features to reveal their grouping structure, treating each group of these features as a whole and considering it as a feature map. Two branches are then established to obtain the channel weights of these feature maps: one branch derives the channel weights of global information through global average pooling, while the other derives the channel weights of local information through global maximum pooling. Next, we design a weight fusion operation to merge the two sets of channel weights and rescale the feature maps, thereby achieving intergroup dependency modeling of the time-frequency-spatial features. Finally, two fully connected layers are used for classification. Experimental validation on four publicly available motor imagery EEG datasets shows that the proposed method achieves an average classification accuracy of 80.72%. This outperforms 18 feature selection methods, existing feature recalibration network methods, and most of the recent literature. The experimental results indicate that the proposed method demonstrates significant potential in practical applications and is likely to be widely adopted in future brain computer interface research and motor rehabilitation training.

Keywords: EEG classification; motor imagery; feature recalibration; time-frequency-spatial feature; weight fusion

收稿日期: 2024-07-15 Received Date: 2024-07-15

* 基金项目: 广西自动检测技术与仪器重点实验室基金项目(YQ22209)、广西自动检测技术与仪器重点实验室基金项目(YQ24208)、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(2023YCXS132)项目资助

0 引言

运动想象脑机接口(brain computer interface, BCI)系统通过检测和解码肢体运动想象引发的脑电信号,实现对外部设备的运动控制。因此,运动想象 BCI 系统在脑卒中和帕金森患者的运动康复训练等医疗领域得到广泛应用^[1-2]。然而,运动想象脑电信号具有低信噪比和高度随机性的特点,导致运动想象解码的准确性和稳定性较低^[3-4]。

近年来,时-频-空特征提取方法在运动想象脑电分类中取得不错效果^[5]。在时-频-空特征提取过程中,一般将原始脑电信号分解成多个时-频单元,然后提取每个时-频单元的空域特征,从而得到多组时-频-空特征^[6]。时-频-空特征可以获取较丰富的脑电信息,但是也存在冗余信息。这些冗余信息对运动想象分类不起作用,反而会增加分类模型的复杂度。另外,由于脑电的个体差异,需要从这些时-频-空特征中学习被试特异的脑电信息。因此,如何从时-频-空特征中学习有效信息是提高运动想象脑电分类性能的关键。

特征选择方法在时-频-空特征学习中应用最广泛。例如,过滤式特征选择方法使用特定准则评估每个特征维度对任务标签的重要性,如费舍尔评分^[7]、相关系数^[8]、库尔贝-莱布勒散度^[9]、互信息^[10]和最小冗余-最大相关^[11](minimum-redundancy maximum-relevancy, mRMR)。包裹式方法使用各种搜索策略生成和评估最佳特征子集,包括萤火虫算法^[12]、遗传算法^[13](genetic algorithm, GA)、二元微分进化^[14](binary differential evolution, BDE)和二元粒子群优化^[15](binary particle swarm optimization, BPSO)。嵌入式方法通过施加结构先验信息来识别最佳特征子集,例如最小绝对收缩和选择算子^[16](least absolute shrinkage and selection operator, LASSO)、融合 LASSO^[17]、组 LASSO^[18](group LASSO, gLASSO)和稀疏组 LASSO^[19](sparse group LASSO, sgLASSO)。然而,这些现有的特征选择方法将每个特征维度视为独立的个体,忽视了每组时-频-空特征的整体性。因此,这些工作未能考虑到脑电时-频-空特征的组间相互依存和相互作用关系。

为此,提出一种新的特征重标定网络,以建模各组时-频-空特征之间的相互依存和相互作用关系。首先,提取脑电时-频-空特征。然后,将每组时-频-空特征视为一个特征图,并将每个特征图视为一个通道。接着建立两个分支,一个通过全局平均池化获取全局信息的通道权重,另一个通过全局最大池化获取局部信息的通道权重;在此过程中采用挤压和激励操作^[20]来建模每组时-频-空特征之间的依赖关系。最后,融合两个分支的权

重,得到每组时-频-空特征的最终权重。总的来说,所提出的方法是一种基于权重融合的特征重标定网络(feature recalibration network based on weight fusion, FRNWF)。为了验证所提方法的有效性,在 4 个公开的运动想象脑电数据集上进行了实验。

以下是研究的贡献和创新点总结:

1) 揭示并构建脑电时-频-空特征的分组结构,将每组时-频-空特征视为一个特征图,为设计基于深度学习的脑电特征重标定网络建模奠定基础。

2) 设计特征重标定网络双分支结构,学习脑电全局和局部信息,建模时-频-空特征的组间相互依存和作用关系;设计特征重标定网络权重融合模块,突出有用信息,充分利用有效信息。

3) 所提方法增强了脑电特征学习的表征能力和信息挖掘能力,提高了运动想象的解码性能。

1 方法

1.1 脑电时-频-空特征的分组结构

如图 1 所示,展示了时-频-空特征的分组结构。首先,通过滑动时间窗将原始多通道脑电信号分割成多个时间窗信号,具体为:0~2 s、0.5~2.5 s、1~3 s、1.5~3.5 s、2~4 s。然后,对每个时间窗信号进行带通滤波,得到多个子带,具体为:4~8 Hz、6~10 Hz、...、36~40 Hz。至此,一共得到 $T \times F = 85$ 个时-频单元, $T = 5$ 表示时间窗个数, $F = 17$ 表示频带个数^[6]。最后,分别对每个时-频单元信号进行共空间模式^[21](common spatial pattern, CSP)变换,提取空间特征,即每个时-频单元提取一组空间特征,共有 $T \times F$ 组时-频-空特征。CSP 滤波器对数设置为 1,即在图 1 中 $m = 1$ ^[22]。

1.2 基于权重融合的特征重标定网络

如图 2 所示,展示了权重融合特征重标定网络的整体架构。每个时-频单元的特征视为一个特征图;按此思想,先将图 1 中的时-频-空特征组织成特征图的形式,即 $X \in R^{H \times W \times C}$,其中 $H = 1$ 和 $W = 2m$ 代表特征图的大小, $C = T \times F$ 代表特征图的通道,即通道数为时-频单元的个数。

1) 挤压操作

分别使用全局平均池化以及全局最大池化将每个通道的特征图信息进行挤压^[20],具体如式(1)和(2)所示。

$$\mathbf{z}_{avg}^c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W \mathbf{x}_c(i, j) \quad (1)$$

$$\mathbf{z}_{max}^c = \max(\mathbf{x}_c(i, j)) \quad (2)$$

其中, $\mathbf{x}_c \in R^{H \times W}$ 表示第 c 个通道的特征图, $\mathbf{z}_{avg}^c \in R^C$ 和 $\mathbf{z}_{max}^c \in R^C$ 分别表示两种不同挤压方式得到的第 c 个通




图 1 脑电时-频-空特征的分组结构

Fig. 1 Time-frequency-spatial features organizational structure

道的通道描述符, $c = 1, 2, \dots, C$ 。全局平均池化捕捉特征图的整体信息, 而全局最大池化捕捉局部信息。通过结合这两种方法, 可以获得更丰富的脑电信息。

2) 激励操作

激励操作^[20]分别在上述两个通道描述符上执行, 建模通道之间的依赖关系, 即特征图之间的依存关系。具体细节如式(3)和(4)所示。

$$s_{\text{avg}} = \sigma(W_{2,\text{avg}}, \delta(W_{1,\text{avg}}, z_{\text{avg}})) \quad (3)$$

$$s_{\text{max}} = \sigma(W_{2,\text{max}}, \delta(W_{1,\text{max}}, z_{\text{max}})) \quad (4)$$

其中, $s_{\text{avg}} \in R^C$ 和 $s_{\text{max}} \in R^C$ 分别表示 z_{avg} 和 z_{max} 对应的通道权重, δ 为指数线性单元 (ELU) 激活函数, σ 为 Sigmoid 激活函数。 $W_1 \in R^{\frac{C}{r} \times C}$ 和 $W_2 \in R^{C \times \frac{C}{r}}$ 分别表示第 1 个和第 2 个全连接层的权重值, 先降维后升维。 r 表示压缩比, 是一个常数因子, 设置 r 为 17^[20]。

3) 权重融合

为了充分利用特征图之间的全局信息和局部信息, 将全局平均池化和全局最大池化两个分支的通道权重进行融合, 具体为:

$$g_c = F_{\text{fusion}}(s_{\text{avg}}^c, s_{\text{max}}^c) \quad (5)$$

其中, $g_c \in R^C$ 表示第 c 个通道的融合权重。 $F_{\text{fusion}} \in \{\text{Avg}, \text{Max}\}$ 表示融合操作, Avg 和 Max 分别表示取平均值操作、取最大值操作。

4) 特征缩放

使用融合后的通道权重对每个特征图进行缩放, 即特征重标定:

$$\tilde{x}_c = F_{\text{scale}}(x_c, g_c) = g_c \cdot x_c \quad (6)$$

其中, F_{scale} 表示特征缩放, 即每个特征图与相应的

通道权重相乘, $\tilde{X} \in R^{H \times W \times C}$ 表示重新赋权重后的特征。

5) 分类模块

先将重标定的特征 $\tilde{X}$ 压平, 并连接成一个特征向量。经随机失活层处理后, 将向量送至全连接层。全连接层由两个神经元组成, 选择 Sigmoid 激活函数, 并采用二元交叉熵作为损失函数, 分类准确率为度量标准。




图 2 基于权重融合的特征重标定网络

Fig. 2 Feature recalibration network weight fusion framework

1.3 模型训练

FRNWF 模型训练采用五折交叉验证,使用 Adam 优化器,设置学习率为 0.000 1,随机失活概率值为 0.5,最大迭代次数 epoch 为 1 000,批处理大小 batch size 为 10。在训练过程中采用早停机制监控验证集损失情况。实验平台为 TensorFlow 2.10 深度学习框架,显卡为 NVIDIA RTX 3090,24 G 运行内存。

2 实验结果与分析

2.1 实验数据

数据集 1:BCI 竞赛 IV-I^[6]。该数据集包含 7 名健康被试,分别记为被试 a,b,⋯,g。被试 a 和 f 执行左手和脚运动想象任务,其余被试执行左手和右手运动想象任务。该数据集使用 59 个电极通道,采样率为 100 Hz。每个被试的训练集和测试集的样本数均为 100 个。

数据集 2:BCI 竞赛 IV-IIa^[22]。该数据集包含 9 名健康被试,分别记为 A01,A02,⋯,A09。每个被试执行 4 种类型运动想象任务,包括左手、右手、脚和舌头,但只处理左手和右手任务的数据。该数据集使用 22 个电极通道,采样率为 250 Hz。每个被试的训练集和测试集的样本数均为 144 个。

数据集 3:BCI 竞赛 IV-IIb^[7]。该数据集包含 9 名健康被试,分别记为 B01,B02~B09。每个被试分别执行两种类型的运动想象任务,包括左手和右手。该数据集使用 3 个电极通道,采样率为 250 Hz。只分析第 3 个会话的数据,每个被试的训练集和测试集的样本数均为 80 个。

数据集 4:BNCI 2020 项目数据库,编号:002-2014^[16,23]。该数据集包含 14 名健康被试,分别记为 S01,S02,⋯,S14。每个被试分别执行两种类型运动想象任务,包括右手和脚。该数据集使用 15 个电极通道,数据原采样率为 512 Hz,已下采样至 256 Hz。每个被试的训练集样本数为 100 个,测试集样本数为 60 个。

2.2 对比方法及其实施过程

首先,所提出的 FRNWF 方法将与 18 种特征选择方法进行比较,其中过滤式、包裹式和嵌入式方法各 6 种,如表 1 所示。

过滤式方法,先根据特征的重要性进行排序,然后通过 Fisher 线性判别分析 (fisher linear discriminant analysis, FLDA) 分类器和十折交叉验证确定最优的特征个数 N ,最后选择前 N 个特征进行分类。

包裹式方法,参数设置与引用文献保持一致,在得到最优特征子集后,使用 FLDA 分类器进行分类。

表 1 特征选择方法

Table 1 Feature selection methods		
类型	方法	缩写
过 滤 式	Fisher criterion	FC ^[7]
	Mutual information	MI ^[10]
	Relevant features	Relief ^[24]
	Neighborhood components analysis	NCA ^[25]
	Minimum-redundancy maximum-relevancy	mRMR ^[26]
	Variance	VAR ^[27]
包 裹 式	Binary dragonfly algorithm	BDA ^[28]
	Binary tree growth algorithm	BTGA ^[29]
	Whale optimization algorithm	WOA ^[30]
	Binary atom search optimization	BASO ^[31]
	Binary harris hawk optimization	BHHO ^[32]
	Equilibrium optimizer	EO ^[33]
嵌 入 式	Least absolute shrinkage and selection operator	LASSO ^[16, 34]
	Group LASSO	gLASSO ^[18]
	Sparse group LASSO	sgLASSO ^[18]
	Fused LASSO	fLASSO ^[18]
	Sparse Bayesian linear discriminant analysis	gBLDA ^[35]
	Group sparse Bayesian linear discriminant analysis	gsBLDA ^[35]

嵌入式方法,特征选择和分类同时进行,不需要额外的分类器。稀疏正则化方法通过十折交叉验证选择最优正则化参数,正则化参数的可选集合为 $\{2^{-5}, 2^{-4.8}, \dots, 2^{4.8}, 2^5\}$;贝叶斯稀疏优化方法没有正则化参数。

其次,FRNWF 方法与现有的特征重标定网络方法进行比较,即 SENet^[20]。SENet 只有一个分支处理,挤压操作采用全局平均池化,后续处理与 FRNWF 方法一样,并且压缩比 r 也设置为 17。

最后,FRNWF 方法与近期文献的分类结果进行比较,这些文献使用相同的数据集。FRNWF 方法与文献中的结果进行比较,没有复现文献中的算法。

2.3 实验结果

以每个被试测试集的分类准确率以及 F1 分数作为评价标准,所有方法的评估流程如下:每个被试的训练集用于模型训练,测试集用于模型测试。

1)FRNWF 与现有特征选择方法比较

FRNWF 和 18 种特征选择方法在 4 个数据集上的平均分类结果如表 2 所示,最高分类准确率以黑体加粗显示。在数据集 1 中,FRNWF 的分类结果优于大部分特征选择方法。在数据集 2~4 中,FRNWF 均取得了最高的平均分类准确率,明显优于其他方法。此外,表 2 还列出了所有数据集的平均分类准确率,FRNWF 以 80.72%的最高平均分类准确率取得最优。另外,使用配对 t 检验方法计算 FRNWF 和比较方法之间的 p 值,结果表明 p 值均小于 0.05,因此 FRNWF 显著优于其他特征选择方法。

表 2 FRNWF 与特征选择方法的平均分类准确率比较

Table 2 Comparison of average classification accuracy between FRNWF and feature selection methods

方法	数据集 1	数据集 2	数据集 3	数据集 4	所有数据集	p 值
FC	83.29	79.86	75.69	71.07	76.36	2.90×10^{-3}
MI	79.71	76.78	75.56	73.45	75.83	4.30×10^{-4}
Relief	81.57	79.01	73.89	71.55	75.61	1.99×10^{-5}
NCA	82.57	78.78	75.83	77.86	78.45	4.2×10^{-3}
mRMR	80.00	79.01	74.17	70.71	75.09	2.92×10^{-5}
VAR	82.00	77.08	73.75	72.38	75.51	5.39×10^{-4}
BDA	69.86	73.22	67.08	64.17	67.95	2.73×10^{-10}
BTGA	69.43	73.15	66.67	65.36	68.19	3.94×10^{-9}
WOA	73.14	74.77	75.00	65.24	71.11	2.71×10^{-7}
BASO	74.00	72.69	67.36	67.38	69.79	6.70×10^{-10}
BHHO	69.86	72.76	66.67	64.17	67.75	2.40×10^{-9}
EO	74.00	72.76	66.25	67.14	69.46	1.07×10^{-9}
LASSO	78.86	78.86	75.97	72.98	76.08	3.74×10^{-6}
gLASSO	78.71	81.17	75.00	72.38	76.15	1.13×10^{-5}
sgLASSO	78.43	79.40	75.97	73.45	76.30	5.77×10^{-6}
fLASSO	78.71	78.78	76.81	73.21	76.31	1.04×10^{-5}
sBLDA	73.86	74.46	68.89	68.93	71.08	4.22×10^{-8}
gsBLDA	74.57	75.69	71.94	70.24	72.67	1.88×10^{-7}
FRNWF	82.11	82.56	79.83	79.41	80.72	—

针对所有被试,比较了 FRNWF 和特征选择方法的 F1 分数如图 3~5 所示,横坐标表示特征选择方法的 F1 分数,纵坐标表示 FRNWF 方法的 F1 分数。橙色五角星代表数据集 1 所有被试的 F1 分数,红色圆圈代表数据集 2 所有被试的 F1 分数,紫色菱形代表数据集 3 所有被试的 F1 分数,蓝色倒三角代表数据集 4 所有被试的 F1 分数。位于对角线左上方的点表示 FRNWF 的 F1 分数优于对比方法。从图 3~5 可以看出,FRNWF 方法明显优于其他方法,进一步证明了 FRNWF 方法的有效性。




图 3 FRNWF 与过滤式方法的 F1 分数对比

Fig. 3 Comparison of F1 score between FRNWF and filtered methods

2) FRNWF 与现有特征重标定方法比较

FRNWF 与 SENet^[20] 的分类结果比较如图 6 所示。




图 4 FRNWF 与包裹式方法的 F1 分数对比

Fig. 4 Comparison of F1 score between FRNWF and wrapped methods

从图 6 中可以发现,FRNWF 对 SENet 的分类性能有一定程度的提升,表明建立多分支结构学习脑电的全局和局部信息并有效融合利用这些信息对运动想象脑电分类是有帮助的。

3) FRNWF 与近期文献比较

为了更全面地评价所提方法的性能,列出了 FRNWF 与近期文献方法的分类结果比较如表 3 所示。从表 3 可以看出,所提方法在 4 个数据集上得到的分类准确率优于近期大多数文献。这结果表明所提方法具有较好的分类性能。




图 5 FRNWF 与嵌入式方法的 F1 分数对比
Fig. 5 Comparison of F1 score between FRNWF and embedded methods

表 3 FRNWF 与近期文献的分类准确率比较

Table 3 Comparison of classification accuracy between FRNWF and recent literature

数据集	比较方法(年份)					FRNWF
数据集 1	CSP-R-MF ^[36]	Radman et al. ^[37]	Shi et al. ^[38]	CMFSSL ^[39]	Habashi et al. ^[40]	82. 11
	(2019)	(2019)	(2021)	(2024)	(2023)	
	77. 75	79. 80	78. 21	75. 49	76. 71	
数据集 2	Guan et al. ^[41]	R-MDRM ^[4]	Selim et al. ^[42]	Cecotti et al. ^[43]	Zhou et al. ^[44]	82. 56
	(2019)	(2019)	(2020)	(2023)	(2023)	
	79. 41	80. 98	77. 59	74. 73	74. 20	
数据集 3	SBELM ^[45]	TRMINet ^[46]	FBRK-SVM ^[47]	STFTCOV ^[48]	RCM ^[49]	79. 83
	(2020)	(2022)	(2022)	(2022)	(2023)	
	78. 50	67. 77	76. 21	78. 69	72. 01	
数据集 4	Wahid et al. ^[50]	MIN2Net ^[51]	RCM ^[49]	Carrara et al. ^[52]	MCSNet ^[53]	79. 41
	(2021)	(2021)	(2023)	(2024)	(2023)	
	78. 90	65. 90	70. 52	70. 00	73. 62	

3.2 权重融合操作对 FRNWF 分类结果的影响

不同权重融合操作对 FRNWF 分类结果的影响如图 8 所示。在此部分,脑电时-频-空特征未进行归一化操作。从图 8 可以看出,除了数据集 3 外,取最大值权重融合操作的分类性能要优于取平均值操作。使用取平均值操作进行融合时,经过全局平均池化和全局最大池化处理后的每个特征图的权重被简单地取平均,这可能会削弱局部信息和全局信息中某些重要特征的有效信息,同时也可能保留冗余信息。因此,取平均值操作有可能对全局信息和局部信息产生模糊效应,抑制一些有用的信息,导致分类效果不佳。相比之下,取最大值操作在融合时,选择了两种池化方式中较大且更突出的权重值,确保最重要或最显著的特征得到保留。这样既不会丢失关键的全局特征,也能保证重要的局部细节不被忽略。因此,取最大值操作可以突出有价值的全局或局部信息,从而得到更适合的通道权重。

3 讨论

接下来,将针对 FRNWF 方法本身的一些特性做进一步研究讨论,具体包括脑电时-频-空特征归一化以及特征图权重融合操作两方面因素对 FRNWF 方法分类性能的影响。

3.1 时-频-空特征归一化对 FRNWF 分类结果的影响

脑电时-频-空特征归一化对 FRNWF 分类结果的影响如图 7 所示。这里,FRNWF 的权重融合操作采取最大值方法,使用 LIBSVM 工具箱^[54]的 svm-scale 函数实现特征归一化操作,把每个维度的特征归一化至 0~1 范围内。从图 7 可以看出,特征归一化降低了 FRNWF 的分类性能。特征归一化可能会造成信息的丢失,从而影响 FRNWF 的分类性能。这说明 FRNWF 方法适合从原始特征中学习有效的脑电信息。

通过以上实验结果,可以得出结论,即 FRNWF 方法在脑电时-频-空特征未归一化和取最大值权重融合操作的情况下可以获得更好的分类性能。这将对后续的研究提供改进的方向以及其他脑电范式的应用提供借鉴。

4 结论

本研究提出了一种基于权重融合的特征重校准网络,旨在提高运动想象脑电信号的分类性能。该方法先通过建立两个分支分别学习运动想象脑电信号的全局和局部信息,有效地建模脑电时-频-空特征的组间相互依赖关系。此外,进一步设计了权重融合操作,以充分利用这些信息,从而实现更准确的分类结果。尽管所提方法在分类性能上表现出色,但仍有改进空间。首先,权重融合操作是人为设定的,而且每个通道都采用相同的融合操作,这可能会影响分类性能。其次,只考虑了特征的组间依赖关系,而没有探索特征的组内依赖关系。此外,特





图 6 不同特征重标定方法的分类结果比较

Fig. 6 Comparison of classification results with different feature recalibration methods





图 7 特征归一化对 FRNWF 分类结果的影响

Fig. 7 The impact of feature normalization on FRNWF classification results

征提取和特征学习是分开进行的,无法实现端到端的脑电分类解码。未来的工作将致力于开发新的网络模型,以解决这些问题,进一步提高基于脑电信号的运动想象分类性能。

参考文献

[1] 边琰,赵丽,孙永. ASMI-BCI 特征调制及分类性能研究[J]. 电子测量与仪器学报, 2022, 36 (3): 224-230.

BIAN Y, ZHAO L, SUN Y. Research on feature modulation and classification performance of ASMI-BCI[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(3): 224-230.

[2] 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), 2020: 3058-3061.

[3] 商晓锋, 罗志增, 史红斐. 基于脑肌耦合导联选择和最小生成树网络的脑电特征提取[J]. 仪器仪表学报, 2022, 43(7): 191-198.

SHANG X F, LUO ZH Z, SHI H F. EEG feature extraction based on corticomuscular coupling node selection and minimum spanning tree network [J]. Chinese Journal of Scientific Instrument, 2022, 43(7): 191-198.

[4] SINGH A, LAL S, GUESGEN H W. Small sample motor





图8 权重融合操作对FRNWF分类结果的影响

Fig. 8 The impact of weight fusion operations on FRNWF classification results

imagery classification using regularized riemannian features[J]. IEEE Access, 2019, 7: 46858-46869.

- [5] LUO T. Selective multi-view time-frequency decomposed spatial feature matrix for motor imagery EEG classification[J]. Expert Systems with Applications, 2024, 247: 123239.
- [6] MIAO Y, JIN J, DALY I, et al. Learning common time-frequency-spatial patterns for motor imagery classification[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2021, 29: 699-707.
- [7] RADMAN M, CHAIBAKHSH A, NARIMAN-ZADEH N, et al. Feature fusion for improving performance of motor imagery brain-computer interface system [J]. Biomedical Signal Processing and Control, 2021,

68: 102763.

- [8] DHIMAN R. Electroencephalogram channel selection based on pearson correlation coefficient for motor imagery-brain-computer interface [J]. Measurement: Sensors, 2023, 25: 100616.
- [9] AZAB A M, MIHAYLOVA L, ANG K K, et al. Weighted transfer learning for improving motor imagery-based brain-computer interface [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2019, 27(7): 1352-1359.
- [10] PARK S H, LEE D, LEE S G. Filter bank regularized common spatial pattern ensemble for small sample motor imagery classification[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2018, 26(2): 498-505.
- [11] KABIR M H, MAHMOOD S, AL SHIAM A, et al. Investigating feature selection techniques to enhance the performance of EEG-based motor imagery tasks classification[J]. Mathematics, 2023, 11(8): 1921.
- [12] LIU A, CHEN K, LIU Q, et al. Feature selection for motor imagery EEG classification based on firefly algorithm and learning automata [J]. Sensors, 2017, 17(11): 2576.
- [13] LUO T. Parallel genetic algorithm based common spatial patterns selection on temporal-frequency decomposed EEG signals for motor imagery brain-computer interface [J]. Biomedical Signal Processing and Control, 2023, 80: 104397.
- [14] BAIG M Z, ASLAM N, SHUM H P H, et al. Differential evolution algorithm as a tool for optimal feature subset selection in motor imagery EEG [J]. Expert Systems with Applications, 2017, 90: 184-195.
- [15] KUMAR S, SHARMA A. A new parameter tuning approach for enhanced motor imagery EEG signal classification[J]. Medical & Biological Engineering & Computing, 2018, 56: 1861-1874.
- [16] ZHANG SH R, ZHU ZH B, ZHANG B X, et al. Overall optimization of CSP based on ensemble learning for motor imagery EEG decoding[J]. Biomedical Signal Processing and Control, 2022, 77: 103825.
- [17] YANG L J, DING S J, ZHOU F, et al. Robust EEG feature learning model based on an adaptive weight and pairwise-fused LASSO[J]. Biomedical Signal Processing and Control, 2021, 68: 102728.
- [18] 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.
- [19] JIAO Y, ZHANG Y, CHEN X, et al. Sparse group representation model for motor imagery EEG classification[J]. IEEE Journal of Biomedical and Health Informatics, 2018, 23(2): 631-641.
- [20] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [21] 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.
- LU ZH W, CHEN Y, MO Y, et al. EEG channel selection method based on TRCSP and L2 norm[J]. Electronic Measurement Technology, 2023, 46(7): 94-102.
- [22] 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.
- [23] 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.
- [24] SADIQ M T, YU X, YUAN Z, et al. Motor imagery BCI classification based on multivariate variational mode decomposition [J]. IEEE Transactions on Emerging Topics in Computational Intelligence, 2022, 6(5): 1177-1189.
- [25] MALAN N S, SHARMA S. Time window and frequency band optimization using regularized neighbourhood component analysis for multi-view motor imagery EEG classification [J]. Biomedical Signal Processing and Control, 2021, 67: 102550.
- [26] XIE SH SH, ZHANG Y, LYU D, et al. A new improved maximal relevance and minimal redundancy method based on feature subset[J]. The Journal of Supercomputing, 2023, 79(3): 3157-3180.
- [27] FIDA M A F A, AHMAD T, NTAHOBARI M. Variance threshold as early screening to Boruta feature selection for intrusion detection system[C]. 2021 13th International Conference on Information & Communication Technology and System (ICTS), 2021: 46-50.
- [28] TOO J, MIRJALILI S. A hyper learning binary dragonfly algorithm for feature selection: A COVID-19 case study[J]. Knowledge-Based Systems, 2021, 212: 106553.
- [29] TOO J, ABDULLAH A R, MOHD SAAD N, et al. Feature selection based on binary tree growth algorithm for the classification of myoelectric signals [J]. Machines, 2018, 6(4): 65.
- [30] TOO J, MAFARJA M, MIRJALILI S. Spatial bound whale optimization algorithm: An efficient high-dimensional feature selection approach [J]. Neural Computing and Applications, 2021, 33: 16229-16250.
- [31] TOO J, RAHIM ABDULLAH A. Binary atom search optimisation approaches for feature selection [J]. Connection Science, 2020, 32(4): 406-430.
- [32] TOO J, ABDULLAH A R, MOHD SAAD N. A new quadratic binary harris hawk optimization for feature selection[J]. Electronics, 2019, 8(10): 1130.
- [33] TOO J, MIRJALILI S. General learning equilibrium optimizer: A new feature selection method for biological data classification [J]. Applied Artificial Intelligence, 2021, 35(3): 247-263.
- [34] 莫云, 梁国富, 路仲伟, 等. 基于 LASSO 和 PCA 降维的脑电特征选择方法[J]. 国外电子测量技术, 2022, 41(5): 9-14.
- MO Y, LIANG G F, LU ZH W, et al. EEG feature selection method based on LASSO and PCA dimensionality reduction[J]. Foreign Electronic Measurement Technology, 2022, 41(5): 9-14.
- [35] YU T Y, YU ZH L, 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.
- [36] FENG J K, JIN J, 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(1): 8068357.
- [37] RADMAN M, CHAIBAKHSH A, NARIMAN-ZADEH N, et al. Generalized sequential forward selection method for channel selection in EEG signals for classification of left or right hand movement in BCI [C]. 2019 9th International Conference on Computer and Knowledge Engineering (ICCCKE). IEEE, 2019: 137-142.
- [38] SHI B, WANG Q, YIN S, et al. A binary harmony search algorithm as channel selection method for motor imagery-based BCI [J]. Neurocomputing, 2021, 443: 12-25.
- [39] GAO Y, LI M, CAO Z, et al. Formative semi-supervised learning based on adaptive combined model for brain-computer interface[J]. International Journal of Machine Learning and Cybernetics, 2024, 15(2): 371-382.

- [40] HABASHI A G, AZAB A M, ELDAWLATLY S, et al. Motor imagery classification enhancement using generative adversarial networks for EEG spectrum image generation[C]. 2023 IEEE 36th International Symposium on Computer-Based Medical Systems (CBMS). IEEE, 2023: 354-359.
- [41] GUAN S, ZHAO K, YANG S. Motor imagery EEG classification based on decision tree framework and riemannian geometry[J]. Computational Intelligence and Neuroscience, 2019, 2019(1): 5627156.
- [42] SELIM S, TANTAWI M, SHEDEED H, et al. A comparative analysis of different feature extraction techniques for motor imagery based BCI system[C]. The International Conference on Artificial Intelligence and Computer Vision. Cham: Springer International Publishing, 2020: 740-749.
- [43] CECOTTI H. Combining density based and linear discriminant approaches for motor imagery classification[C]. 2023 11th International IEEE/EMBS Conference on Neural Engineering (NER). IEEE, 2023: 1-4.
- [44] ZHOU A, ZHANG L, YUAN X, et al. A signal prediction-based method for motor imagery EEG classification [J]. Biomedical Signal Processing and Control, 2023, 86: 105139.
- [45] JIN Z, ZHOU G, GAO D, et al. EEG classification using sparse bayesian extreme learning machine for brain-computer interface [J]. Neural Computing and Applications, 2020, 32: 6601-6609.
- [46] OU Y, SUN S, GAN H, et al. An improved self-supervised learning for EEG classification [J]. Math. Biosci. Eng, 2022, 19(7): 6907-6922.
- [47] ZHANG Y, CHEN J. Filter bank riemannian-based kernel support vector machine for motor imagery decoding [C]. ITM Web of Conferences. EDP Sciences, 2022, 47: 02013.
- [48] MA Y, WU X, ZHENG L, et al. Iterative outlier removal clustering based time-frequency-spatial feature selection for binary EEG motor imagery decoding [J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-14.
- [49] DELISLE-RODRIGUEZ D, SILVA L, BASTOS-FILHO T. EEG changes during passive movements improve the motor imagery feature extraction in BCIs-based sensory feedback calibration[J]. Journal of Neural Engineering, 2023, 20(1): 016047.
- [50] WAHID M F, TAFRESHI R. Improved motor imagery classification using regularized common spatial pattern with majority voting strategy [J]. IFAC-PapersOnLine, 2021, 54(20): 226-231.
- [51] AUTTHASAN P, CHAISAEEN R, SUDHAWIYANGKUL T, et al. MIN2Net: Endto-end multi-task learning for subject-independent motor imagery EEG classification [J]. IEEE Transactions on Biomedical Engineering, 2021, 69(6): 2105-2118.
- [52] CARRARA I, PAPADOPOULOU T. Pseudo-online framework for BCI evaluation; A MOABB perspective using various MI and SSVEP datasets [J]. Journal of Neural Engineering, 2024, 21(1): 016003.
- [53] ZHAO R, WANG Y, CHENG X, et al. A mutli-scale spatial-temporal convolutional neural network with contrastive learning for motor imagery EEG classification[J]. Medicine in Novel Technology and Devices, 2023, 17: 100215.
- [54] CHEN T, JU S H, REN F J, et al. EEG emotion recognition model based on the LIBSVM classifier [J]. Measurement, 2020, 164: 108047.

作者简介



莫云, 2020 年于桂林电子科技大学获得硕士学位, 现为桂林航天工业学院实验师, 主要研究方向为生物医学和智能仪器。

E-mail: moyun@guat.edu.cn

Mo Yun received her M. Sc. degree from Guilin University of Electronic Technology in 2020. Now she is an engineer in Guilin University of Aerospace Technology. Her main research interests include biomedical engineering and intelligent instruments.



李易, 2021 年于桂林电子科技大学获得学士学位, 现为桂林电子科技大学博士研究生, 主要研究方向为脑电信息处理与脑机接口系统。

E-mail: m18589833462@163.com

Li Yi received his B. Sc. degree from Guilin University of Electronic Technology in 2021. Now he is Ph. D. in Guilin University of Electronic Technology. His main research interests include EEG information processing and brain-computer interface systems.



张本鑫 (通信作者), 2017 年于桂林电子科技大学获得博士学位, 现为桂林电子科技大学副教授, 主要研究方向为脑电信息处理与数学优化。

E-mail: bxzhang@guet.edu.cn

Zhang Benxin (Corresponding author) received his Ph. D. degree from Guilin University of Electronic Technology in 2017. Now he is an associate professor in Guilin University of Electronic Technology. His main research interests include EEG information processing and mathematical optimization.