

DOI:10.19651/j.cnki.emt.2517893

基于 RSCM 与黎曼空间的运动想象脑电分类研究^{*}

廉小亲^{1,2} 刘春权^{1,2} 高超^{1,2} 邓子谦^{1,2} 吴叶兰^{1,2}

(1.北京工商大学计算机与人工智能学院 北京 100048;2.北京工商大学中国轻工业工业互联网与大数据重点实验室 北京 100048)

摘要:近年来,运动想象(MI)在辅助医疗和人机交互领域备受关注。然而,经典的共空间模式(CSP)特征提取方法主要基于时域信号计算协方差矩阵(CM),易受噪声和伪迹干扰,且无法充分利用脑电信号(EEG)的频谱信息,导致分类精度与稳定性不足。为了解决这一问题,本研究提出了一种基于正则化频谱协方差矩阵(RSCM)与黎曼空间的 MI-EEG 分类算法。首先,对预处理后的 EEG 信号进行快速傅里叶变换,计算频谱协方差矩阵,并进行岭正则化;然后,将正则化矩阵映射到切空间中进行平滑滤波,并将结果映射回黎曼空间以提取 CSP 特征;最后,采用支持向量机(SVM)完成分类任务。实验结果表明,在 BCI 竞赛 IV 数据集 1 和 2a 上,本研究方法的二分类平均准确率分别达到了 86.95% 和 81.48%,较传统 CSP 分别提升了 7.44% 和 9.57%;在 BCI 竞赛 IV 数据集 2a 上,本研究方法的四分类平均准确率达到了 74.23%,较传统 CSP 方法提升了 14.10%。实验结果表明,本研究方法在 MI-EEG 分类中具有有效性。

关键词:运动想象;脑电信号;频谱协方差矩阵;黎曼空间;共空间模式

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

Research on motor imagery EEG classification based on RSCM and Riemann space

Lian Xiaoqin^{1,2} Liu Chunquan^{1,2} Gao Chao^{1,2} Deng Ziqian^{1,2} Wu Yelan^{1,2}

(1. School of Computer and Artificial Intelligence, Beijing Technology and Business University, Beijing 100048, China;

2. Key Laboratory of Industrial Internet and Big Data, China National Light Industry, Beijing Technology and Business University, Beijing 100048, China)

Abstract: In recent years, motor imagery (MI) has attracted significant attention in the fields of assistive healthcare and human-computer interaction. However, the classical common spatial pattern (CSP) feature extraction method is mainly based on calculating covariance matrices (CM) from time-domain signals, making it susceptible to noise and artifacts while failing to fully exploit the spectral information of electroencephalogram (EEG) signals. This limitation reduces classification accuracy and stability. To address this problem, this study proposes a MI-EEG classification algorithm based on regularized spectral covariance matrix (RSCM) and Riemannian space. Firstly, the preprocessed EEG signals undergo fast Fourier transform (FFT) to compute spectral covariance matrices, followed by ridge regularization. Then, the regularized matrices are mapped into the tangent space for geodesic filtering and projected back to the Riemannian space for CSP feature extraction. Finally, classification is performed using SVM. Experimental results demonstrate that, on BCI Competition IV datasets 1 and 2a, the proposed method achieves an average binary classification accuracy of 86.95% and 81.48%, respectively, outperforming traditional CSP by 7.44% and 9.57%. In the four-class classification task on BCI Competition IV dataset 2a, it reaches 74.23%, representing a 14.10% improvement over traditional CSP. These findings indicate the effectiveness of the proposed method in MI-EEG classification.

Keywords: motor imagery; EEG; spectral covariance matrix; Riemann space; common spatial pattern

0 引言

脑机接口(brain-computer interface, BCI)技术通过采

集和解码脑电信号(electroencephalogram, EEG)实现人机交互,是近年来迅速发展的前沿研究领域^[1]。运动想象(motor image, MI)是 BCI 技术中的重要研究方向,是指个

收稿日期:2025-01-13

* 基金项目:国家自然科学基金项目(62173007)、2024 北京工商大学研究生教育教学成果培育项目(XYCGPYLX2024006)资助

体在无实际动作的情况下,通过想象特定运动来激活大脑相关区域产生神经活动^[2]。这一过程不仅为运动功能受损的个体提供了宝贵的康复手段,还推动了神经康复技术的创新与发展,为BCI系统的进一步优化和实际应用奠定了基础。

共空间模式(common spatial pattern, CSP)是一种广泛应用于MI的特征提取算法。其通过寻找一组空间滤波器,将原始EEG投影到新的特征空间,从而最大化不同类别之间的方差差异。得益于其简单高效的特征提取能力,CSP已成为MI-BCI系统中的经典方法^[3]。然而,传统的CSP算法对噪声和数据不平衡较为敏感,这会影响到模型后续的分类性能^[4]。

为了解决这些问题,Barachant等^[5]提出了两种基于黎曼空间的方法来优化CSP算法。第1种方法利用黎曼距离和黎曼均值直接处理原始空间中EEG的空间协方差矩阵(covariance matrix, CM)。由于EEG的空间信息嵌入在空间CM中,因此不再需要空间滤波。第2种方法将CM映射到黎曼切空间中。在黎曼切空间中,矩阵可以被矢量化,并被视为欧几里德对象。实验结果表明,第2种方法能够有效地将高维的黎曼空间问题转化为低维的欧几里德空间问题,提高了对噪声和伪迹的鲁棒性,分类效果优于传统的CSP和第一种改进的CSP方法。

随后,许多研究者在第2种改进CSP方法的基础上进行了进一步的探索。Hua等^[6]提出了一种将滤波器组与黎曼切空间融合的方法。该方法将CM从黎曼空间映射到切空间,并在切空间中对其进行向量化后作为特征输入到分类器中,在BCI竞赛IV数据集2a和2b上的平均分类准确率分别为77.7%和86.9%,可以有效克服脑电频带的可变性和噪声干扰的问题。Wang等^[7]提出了一种基于黎曼空间的测地线滤波CSP和滤波器组特征加权的支持向量机(support vector machine, SVM)方法。该方法首先对映射到切空间中的CM进行线性判别分析,然后进行向量化,并将这些向量作为特征输入到分类器中,在BCI竞赛III数据集IV上达到了93.13%的平均分类准确率,证明了该方法的有效性。

除此以外,部分研究者也尝试通过融合黎曼切空间特征与其他特征来提升模型的整体性能。Shyu等^[8]将黎曼切空间提取的欧几里德空间向量特征与CSP特征相结合,并提出了一种基于数据点与SVM超平面之间距离来计算类别分数的方法,从而进一步提高了分类器的性能。实验结果表明,该方法在BCI竞赛IV数据集2a和BCI竞赛III数据集IIIa上的平均分类准确率分别达到了78.55%和83.33%。Luo^[9]提出了一种选择性多视图时频分解的空间特征矩阵方法。该方法首先融合正则化CSP和黎曼切空间特征提取技术,构建特征矩阵,随后通过监督的流形嵌入特征选择方法筛选出最具区分力的特征,最终利用稀疏支持矩阵机进行分类。实验结果表明,该方法在BCI竞赛III

数据集4a、BCI竞赛IV数据集1和数据集2a上的平均分类准确率分别达到了87.13%、90.14%和85.70%。

综上所述,通过在黎曼切空间上对CM进行优化,能够有效减少噪声干扰,提高模型的性能。然而,传统时域信号的特征提取方法仍然易受到噪声和伪迹的干扰。因此,本研究在黎曼空间的基础上提出了一种创新性方法。该方法结合了频谱协方差矩阵(spectral covariance matrix, SCM)、正则化技术、黎曼空间与CSP特征,旨在进一步提高MI-EEG分类模型的准确性与稳定性。首先,对预处理后的EEG进行快速傅里叶变换(fast Fourier transform, FFT),提取频谱幅值并计算SCM;其次,使用岭正则化(ridge regularization, RR)处理SCM,得到正则化频谱协方差矩阵(regularized spectral covariance matrix, RSCM);然后,将RSCM映射到黎曼切空间中,在切空间中进行平滑滤波后映射回黎曼空间;最后,从处理后的矩阵中提取CSP特征,并通过SVM进行分类,在两个公开数据集上验证本研究提出方法的可行性与有效性。

1 数据来源与预处理

1.1 数据来源

本研究采用BCI竞赛IV数据集1^[10](BCIIV 1)和数据集2a^[11](BCIIV 2a)进行MI-EEG分类实验。

BCIIV 1数据集使用59个通道记录了包含7名健康受试者的MI-EEG信号,每名受试者从左手、右手和脚这3个类别中选择两类进行运动想象。每名受试者每类任务包含100个样本,采样频率为100 Hz。实验过程中,屏幕显示4 s的箭头提示,受试者根据提示执行相应的两类MI任务,随后进行4 s的休息。本研究截取从提示开始后的4 s数据作为实验数据集。

BCIIV 2a数据集使用25个通道记录了包含9名健康受试者的MI-EEG信号,每名受试者进行左手、右手、脚和舌头4类运动想象。每名受试者每类任务包含72个样本,采样频率为250 Hz。其实验过程与BCIIV 1数据集一致。

本研究先基于BCIIV 2a数据集的左手和右手样本以及BCIIV 1数据集进行二分类实验,用于评估模型在简单任务下的解码性能;随后基于BCIIV 2a数据集进行四分类实验,用于评估模型在复杂任务下的解码性能。

1.2 预处理方法

在本研究中,先按照3:1的比例划分训练集和测试集,然后对训练集和测试集进行相同的预处理操作,预处理流程如图1所示。

首先,进行8~30 Hz带通滤波。这一频段涵盖了 α 波段(8~13 Hz)和 β 波段(14~30 Hz),这些波段与MI任务中的大脑活动具有显著的相关性,能够较好地捕捉与MI有关的脑电特征^[12]。接着,使用共平均参考减少伪迹影响,提升信号的空间分辨率。随后,通过去基线校正去除时间上的偏差,以增强信号的稳定性。最后,采用滑动窗口法

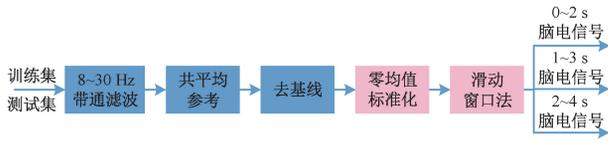


图 1 预处理流程

Fig. 1 Preprocessing flow chart

扩展样本量,以 2 s 的时间窗将 EEG 数据划分为多个时间段,以扩充数据集的数据量。

2 研究方法

基于正则化频谱协方差矩阵与黎曼空间的运动想象分

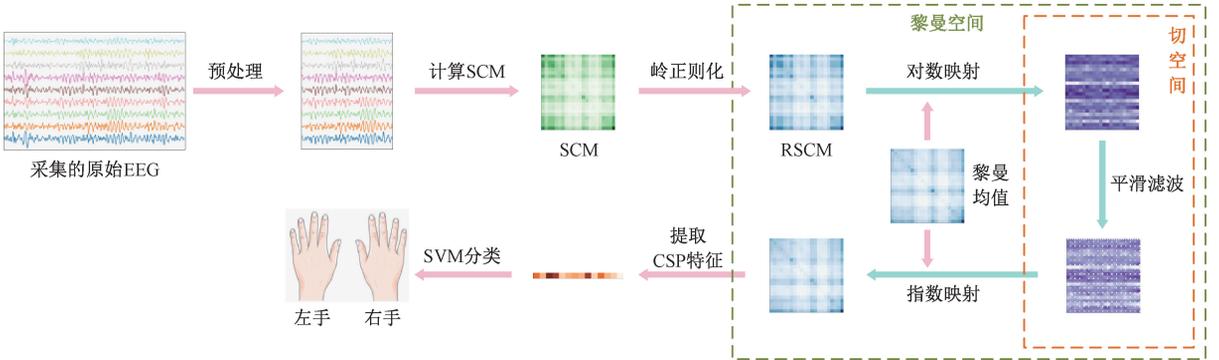


图 2 本研究算法总体流程

Fig. 2 Overall flow chart of the algorithm in this study

假设有两类 MI 脑电信号,分别为 $\mathbf{X}_{11}, \dots, \mathbf{X}_{1m}$ 和 $\mathbf{X}_{21}, \dots, \mathbf{X}_{2n}$, 其中 m 和 n 分别表示每类样本的总个数,则 CSP 的基本步骤为^[13]:

首先,计算样本总体的混合协方差矩阵 $\bar{\mathbf{C}}$, 如式(1)所示。

$$\bar{\mathbf{C}} = \bar{\mathbf{C}}_1 + \bar{\mathbf{C}}_2 = \frac{1}{m} \sum_{i=1}^m \mathbf{C}_{1i} + \frac{1}{n} \sum_{j=1}^n \mathbf{C}_{2j} \quad (1)$$

式中: $\bar{\mathbf{C}}_i$ 表示第 i 类样本的平均 CM; \mathbf{C}_{1i} 和 \mathbf{C}_{2j} 分别表示两类样本的 CM, 其计算方法为:

$$\begin{cases} \mathbf{C}_{1i} = \frac{1}{\text{tr}(\mathbf{X}_{1i}\mathbf{X}_{1i}^T)} \mathbf{X}_{1i}\mathbf{X}_{1i}^T, i = 1, \dots, m \\ \mathbf{C}_{2j} = \frac{1}{\text{tr}(\mathbf{X}_{2j}\mathbf{X}_{2j}^T)} \mathbf{X}_{2j}\mathbf{X}_{2j}^T, j = 1, \dots, n \end{cases} \quad (2)$$

式中: \mathbf{X}^T 是 \mathbf{X} 的转置; $\text{tr}(\mathbf{X})$ 是 \mathbf{X} 的迹。

然后,对混合协方差矩阵 $\bar{\mathbf{C}}$ 进行特征值分解和白化变换以构建空间滤波器 \mathbf{S}_1 和 \mathbf{S}_2 , 并对 \mathbf{S}_1 和 \mathbf{S}_2 进行主分量分解,以求解投影矩阵 \mathbf{W} 。 \mathbf{W} 的计算公式如式(3)所示。

$$\mathbf{W} = \mathbf{P}^T \mathbf{M} \quad (3)$$

式中: \mathbf{P} 为白化矩阵; \mathbf{M} 为主分量分解时的特征向量矩阵,需要满足:

$$\begin{cases} \mathbf{S}_i = \mathbf{M}\boldsymbol{\lambda}_i, \mathbf{M}\mathbf{M}^T = \mathbf{E}, i = 1, 2 \\ \boldsymbol{\lambda}_1 + \boldsymbol{\lambda}_2 = \mathbf{E} \end{cases} \quad (4)$$

类算法总体流程如图 2 所示。针对每位受试者,流程分为以下步骤:首先,对原始 EEG 进行预处理并计算 SCM,随后通过岭正则化得到 RSCM;然后,将 RSCM 映射到切空间中进行平滑滤波,并将结果重新映射回黎曼空间;最后,从处理后的矩阵中提取 CSP 特征,并使用 SVM 完成模型的训练与测试。

2.1 共空间模式

CSP 是一种常见的用于两分类任务下空间滤波的特征提取算法,广泛应用于 BCI 研究中。CSP 的基本思想是利用信号的 CM,寻找一组空间滤波器,使得在该组滤波器作用下,一个类别的信号方差达到最大,同时另一个类别的信号方差达到最小。

式中: \mathbf{E} 表示单位矩阵, $\boldsymbol{\lambda}_1$ 和 $\boldsymbol{\lambda}_2$ 分别表示 \mathbf{S}_1 和 \mathbf{S}_2 的特征值矩阵。从式(4)中可以看出,当某个信号类别(如 \mathbf{S}_1)取得较大特征时,表明该类别在特征向量方向上的信号变化显著,能够有效区分该类别的信号。而另一个信号类别(如 \mathbf{S}_2)在相同方向上的特征值较小时,表示其信号变化较小,难以被识别^[13]。这样就可以通过优化不同类别信号的空间特征,显著增强它们在特定空间下的方差差异,从而提高分类效果。

最后,使用投影矩阵 \mathbf{W} 对原始 MI-EEG 进行空间过滤,从而得到过滤后的特征矩阵为:

$$\begin{cases} \mathbf{Y}_{1i} = \mathbf{W}\mathbf{X}_{1i}, i = 1, \dots, m \\ \mathbf{Y}_{2j} = \mathbf{W}\mathbf{X}_{2j}, j = 1, \dots, n \end{cases} \quad (5)$$

通过上面的步骤,可以得知 CSP 需要计算原始 EEG 在时域上的 CM。然而,时域信号往往受到噪声和伪迹的影响^[14],且时域主要关注信号的时间变化,这使得提取的特征容易受环境干扰而不够稳定。相较之下,频域分析能够揭示大脑信号在不同频率下的活动特征,且频域特征对低频噪声和伪迹干扰的敏感度低。因此,使用 SCM 能够有效地捕捉信号的频谱特征,增强不同任务间的区分度,提高 MI 任务的分类准确性。

2.2 正则化频谱协方差矩阵

在 MI 等任务中,EEG 信号的频率成分通常比时域成

分更加显著,因此SCM成为了特征提取的重要工具。计算SCM的流程如图3所示。

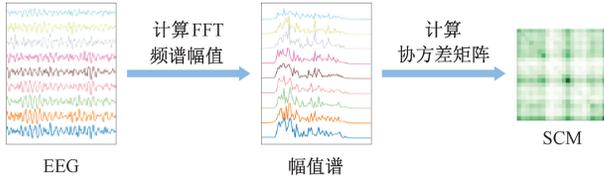


图3 计算SCM的流程

Fig. 3 Flow chart for calculating SCM

然而,EEG信号通常受到噪声的干扰,直接计算SCM可能会出现不稳定或不正定的情况。特别是在信号质量较低或样本量较少的情况下,直接计算的SCM可能包含非常小或负的特征值,这可能导致数值不稳定,进而影响后续分析和分类任务的准确性。为了解决这个问题,正则化技术可以用来改善SCM的稳定性^[15]。

RR是一种常用的正则化方法,通过向CM的对角线添加一个很小的正数,从而确保矩阵的正定性,并减少噪声的干扰。CM经过RR后的RSCM的形式为:

$$\mathbf{C}_{\text{RSCM}} = \mathbf{C}_{\text{CM}} + \lambda \mathbf{E} \quad (6)$$

式中: \mathbf{C}_{CM} 是时域协方差矩阵; λ 是正则化参数(通常是一个很小的常数,本研究取 10^{-6}); \mathbf{E} 表示单位矩阵。

在本研究中,SCM也被引入了RR进行正则化处理,以增强信号的稳定性。对SCM进行RR后的RSCM的形式为:

$$\mathbf{C}_{\text{RSCM}} = \mathbf{C}_{\text{SCM}} + \lambda \mathbf{E} \quad (7)$$

式中: \mathbf{C}_{SCM} 是频谱协方差矩阵。

通过对SCM进行正则化处理,可以确保SCM的正定性,从而避免了因噪声或数据不平衡导致的数值不稳定性。

2.3 黎曼空间

在传统的EEG处理中,CM常用于表示不同通道间的相关性。然而,受噪声和伪迹的影响,传统方法在欧几里德空间中的处理往往难以有效反映EEG的非线性特征,导致分类性能不足。作为对称正定(symmetric positive definite, SPD)矩阵,CM可以被视为SPD黎曼空间上的一个点^[16]。黎曼空间是一个可微的非欧几里德空间,是由黎曼距离给出的SPD矩阵空间。假设有两个大小为 n 的协方差矩阵 \mathbf{C}_1 和 \mathbf{C}_2 ,则它们之间的黎曼距离可以计算为:

$$\delta(\mathbf{C}_1, \mathbf{C}_2) = \|\log(\mathbf{C}_1^{-1}\mathbf{C}_2)\|_F = \left(\sum_{i=1}^n \log^2 \lambda_i\right)^{\frac{1}{2}} \quad (8)$$

式中: $\|\cdot\|_F$ 表示F-范数^[6]; $\lambda_i (i=1, \dots, n)$ 为矩阵 $\mathbf{C}_1^{-1}\mathbf{C}_2$ 的实特征值。

作为非欧几里德空间,无法直接使用欧几里德方法来度量。切空间是黎曼空间上某一点的局部线性化近似,包含了该点附近所有可能方向的集合,可以视为该点的欧几里德空间的一个局部近似^[17]。黎曼空间及其局部切空间示意图如图4所示。

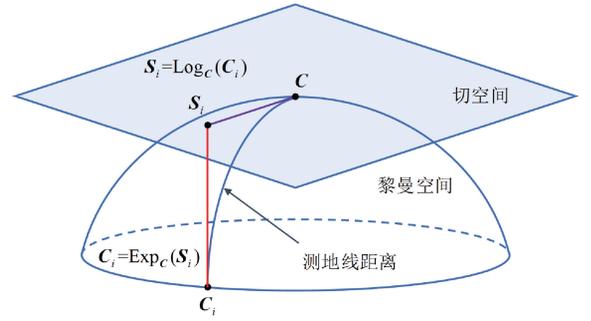


图4 黎曼空间及其局部切空间

Fig. 4 Riemann space and its local tangent space

在图4中,黎曼空间上的任意一点 \mathbf{C}_i 可以通过对数映射转换为以点 \mathbf{C} 为基的切空间中的点 \mathbf{S}_i 。反之,切空间中的点 \mathbf{S}_i 也可以通过指数映射回原始流形上的点 \mathbf{C}_i 。对数映射和指数映射的数学定义为:

$$\mathbf{S}_i = \text{Log}_{\mathbf{C}}(\mathbf{C}_i) = \mathbf{C}^{1/2} \log(\mathbf{C}^{-1/2} \mathbf{C}_i \mathbf{C}^{-1/2}) \mathbf{C}^{1/2} \quad (9)$$

$$\mathbf{C}_i = \text{Exp}_{\mathbf{C}}(\mathbf{S}_i) = \mathbf{C}^{1/2} \exp(\mathbf{C}^{-1/2} \mathbf{S}_i \mathbf{C}^{-1/2}) \mathbf{C}^{1/2} \quad (10)$$

在对EEG进行处理时,可以选择黎曼均值作为参考点,将每个样本的CM通过对数映射转换到以黎曼均值为基的切空间中。由于黎曼均值作为CM的“中心”点,代表了所有CM的平均位置,因此使用黎曼均值的切空间能够更好地捕捉数据的细微差异,减少信息丢失,提高特征提取的鲁棒性。黎曼均值通过最小化各点到均值点的黎曼距离平方和来确定最优的中心位置^[18]:

$$\theta(\mathbf{C}_1, \dots, \mathbf{C}_N) = \underset{\mathbf{C}}{\text{argmin}} \sum_{i=1}^N \delta^2(\mathbf{C}, \mathbf{C}_i) \quad (11)$$

式中: N 表示EEG样本个数。

本研究首先通过迭代计算出训练集RSCM的黎曼均值,随后将所有样本的RSCM映射到以训练集黎曼均值为基的切空间中。这样做的可以确保训练数据和测试数据在相同的空间内处理,从而保持特征提取与分类过程的一致性。

由于切空间是一个近似的欧几里德空间,将RSCM映射到切空间后,可以运用经典的线性方法对其进行处理。为了减少样本间的随机噪声,并且确保映射回的RSCM仍然是SPD矩阵,本研究采用了平滑滤波的方法进行处理:

$$f_{\theta}(\mathbf{C}_i) = \gamma \text{Log}_{\theta}(\mathbf{C}_i) + (1 - \gamma) \text{Log}_{\theta}(\mathbf{E}) \quad (12)$$

式中: \mathbf{C}_i 表示第 i 个样本的RSCM; θ 表示训练集样本的黎曼均值; γ 表示平滑系数,用于控制平滑的程度,本研究取0.7; \mathbf{E} 表示单位矩阵。

这里使用单位矩阵 \mathbf{E} 对RSCM进行滤波。因为 \mathbf{E} 在几何上相当于黎曼空间的“原点”,能够确保平滑后的RSCM保持一定的“中心性”,从而避免了因为平滑操作而导致的方向性偏差。

3 结果与分析

3.1 评价指标

本研究采用准确率(Acc)、召回率(Recall)和Kappa系

数对模型进行综合性能分析。Acc 是评估模型整体预测正确性的指标,计算公式为:

$$Acc = \frac{TP + TN}{TP + FP + TN + FN} \quad (13)$$

式中:TP 表示真正类;FP 表示假正类;TN 表示真负类;FN 表示假负类。

Recall 是衡量模型对正类样本的识别能力的指标,计算公式为:

$$Recall = \frac{TP}{TP + FN} \quad (14)$$

Kappa 系数是衡量模型预测结果与真实标签一致性程度的指标,能够更客观地反映模型在处理类别不均衡数据时的性能表现。其计算公式如下:

$$Kappa = \frac{p_o - p_e}{1 - p_e} \quad (15)$$

式中: p_o 为观测到的一致性比例,即模型准确率; p_e 为期望一致性比例,表示在纯随机情况下,模型预测与真实值一致的可能性。

3.2 消融实验

本研究首先进行了消融实验,以探究各模块对分类性能的影响。具体而言,消融实验分别移除了黎曼空间和频域特征,以评估它们在 MI-EGG 分类中的作用。消融实验共设计了 4 组,分别为:

- 1)RCM-CSP:正则化时域协方差矩阵+共空间模式;
- 2)RCM-RM-CSP:正则化时域协方差矩阵+黎曼空间+共空间模式;
- 3)RSCM-CSP:正则化频域协方差矩阵+共空间模式;
- 4)RSCM-RM-CSP:正则化频域协方差矩阵+黎曼空

表 1 二分类消融实验的平均准确率、平均标准差、平均召回率和平均 Kappa 系数对比

Table 1 Comparison of average accuracy, average standard deviation, average recall and average Kappa coefficient of binary classification ablation experiments

受试者 编号	BCIIV 1				受试者 编号	BCIIV 2a			
	RCM- CSP	RCM- RM-CSP	RSCM- CSP	RSCM- RM-CSP		RCM- CSP	RCM- RM-CSP	RSCM- CSP	RSCM- RM-CSP
a	76.00	86.00	82.67	89.33	A01	75.93	81.48	82.41	86.11
b	72.67	74.00	74.00	77.33	A02	55.56	63.89	68.52	71.30
c	74.67	75.33	72.67	76.67	A03	87.96	89.81	93.52	93.52
d	82.67	87.33	88.00	90.67	A04	62.04	71.30	74.07	75.00
e	87.33	93.33	92.67	95.33	A05	65.74	68.52	67.59	74.07
f	82.57	86.00	85.33	86.67	A06	72.22	76.85	79.63	82.41
g	80.67	88.00	90.00	92.67	A07	69.44	75.93	73.15	75.93
—	—	—	—	—	A08	86.11	91.67	87.96	93.52
—	—	—	—	—	A09	72.22	79.63	78.70	81.48
Mean±	79.51±	84.28±	83.62±	86.95±	Mean±	71.91±	77.68±	78.39±	81.48±
Std	10.63	9.69	9.21	8.86	Std	12.68	11.71	11.01	10.65
Recall	79.52	84.29	83.62	86.95	Recall	71.91	77.67	78.40	81.48
Kappa	0.590 5	0.685 7	0.672 4	0.739 0	Kappa	0.438 3	0.553 5	0.567 9	0.629 6

间+共空间模式。

本研究采用 SVM 在 BCIIV 1 和 BCIIV 2a 数据集上的二分类消融实验的结果如表 1 所示,其中平均准确率、平均标准差、平均召回率的单位均为%。从表 1 中数据可以看出,RSCM-RM-CSP 方法不仅在每个受试者上的平均准确率达到最高,而且在每个数据集上的平均准确率、标准差、召回率以及 Kappa 系数等综合指标上均表现最佳,充分展现了模型分类准确性与稳定性。

通过对比 RCM-CSP 与 RCM-RM-CSP 方法的实验结果可以发现,利用黎曼切空间进行平滑滤波后的特征在两个数据集上的分类效果均有显著提升。具体而言,平均准确率分别提高了 4.77%和 5.77%,这表明黎曼切空间的平滑处理能够有效提升模型在不同数据集上的分类准确性;平均标准差分别降低了 0.94%和 0.97%,这表明黎曼切空间的平滑处理能够提高模型的稳定性,使得模型在多个实验环境中表现更加一致;平均召回率分别提高了 4.77%和 5.76%,这表明黎曼切空间的平滑处理能够提高模型对正类样本的识别能力;平均 Kappa 系数分别提高了 0.095 2 和 0.115 2,这表明黎曼切空间的平滑处理能够增强模型与实际标签之间的一致性,进一步证明了模型在不同数据集和环境下的稳定性。

通过对比 RCM-CSP 与 RSCM-CSP 方法的实验结果可以发现,采用频域特征方法在两个数据集上的分类效果均有显著提升。具体而言,平均准确率分别提高了 4.11%和 6.48%,平均标准差分别降低了 1.42%和 0.67%,平均召回率分别提高了 4.10%和 6.49%,平均 Kappa 系数分别提高了 0.081 9 和 0.129 6。这表明,频域特征的引入不仅能够有效提取与 MI 任务相关的特征信息,提升模型分类

精度,还可以增强模型在不同数据集和环境下的稳定性。

通过对比 RCM-CSP 与 RSCM-RM-CSP 方法的实验结果可以发现,将频域特征方法与黎曼切空间的平滑滤波方法结合,能够进一步优化模型在两个数据集上的分类表现。具体而言,将二者结合之后,平均准确率分别提高了 7.44% 和 9.57%,平均标准差分别降低了 1.77% 和 2.03%,平均召回率分别提高了 7.43% 和 9.57%,平均 Kappa 系数分别提高了 0.148 5 和 0.191 3。将二者结合的方法,在各项指标上的提升幅度明显高于单独使用频域特征或黎曼切空间平滑滤波的方法。这表明,将频域特征方法与黎曼切空间的平滑滤波方法结合,能够更全面地提高模型的性能,进一步增强模型的稳定性。

随后,本研究采用一对多(one versus rest, OVR) SVM 在 BCIIV 2a 数据集上的四分类消融实验的结果如表 2 所示,其中平均准确率、平均标准差、平均召回率的单位均为%。从表 2 中数据可以看出,四分类消融实验的结果与二分类实验趋势一致,RSCM-RM-CSP 方法在四分类任务中同样能够取得最佳表现,在分类准确率、标准差、召回率及 Kappa 系数等指标上均取得最优。

3.3 对比实验

为了进一步验证本研究所提出方法的有效性,本研究还与近年来的多种 MI-EEG 分类方法进行了对比实验。其中,二分类对比实验结果如表 3 所示,四分类对比实验结果如表 4 所示。

表 2 四分类消融实验的平均准确率、平均标准差、平均召回率和平均 Kappa 系数对比

Table 2 Comparison of average accuracy, average standard deviation, average recall and average Kappa coefficient of four-class classification ablation experiments

受试者编号	RCM-CSP	RCM-RM-CSP	RSCM-CSP	RSCM-RM-CSP
A01	69.44	76.39	71.30	80.09
A02	51.85	65.28	58.33	70.37
A03	68.98	80.09	73.15	82.87
A04	66.67	73.15	74.07	76.85
A05	41.20	52.78	43.98	62.04
A06	45.37	51.85	49.07	56.94
A07	64.81	71.76	69.91	84.72
A08	69.44	77.31	74.54	83.80
A09	63.43	66.20	65.28	73.61
Average±Std	60.13±14.60	68.31±12.54	64.40±12.99	74.23±11.86
Recall	60.13	68.31	64.40	74.23
Kappa	0.443 8	0.557 6	0.506 2	0.639 2

表 3 二分类对比实验的平均准确率、平均标准差对比

Table 3 Comparison of average accuracy and average standard deviation of binary classification comparison experiments %

受试者 编号	BCIIV 1				受试者 编号	BCIIV 2a			
	Gao 等 ^[19]	Habashi 等 ^[20]	Cherloo 等 ^[21]	RSCM-RM-CSP		Fan 等 ^[22]	Ha 等 ^[23]	Riyad 等 ^[24]	RSCM-RM-CSP
a	76.55	76.00	87.50	89.33	A01	80.49	83.68	83.68	86.11
b	55.88	73.00	74.50	77.33	A02	61.32	49.31	49.65	71.30
c	64.67	69.50	75.50	76.67	A03	86.17	92.36	89.24	93.52
d	79.90	75.00	67.50	90.67	A04	64.08	61.46	68.06	75.00
e	87.95	89.00	92.00	95.33	A05	54.31	63.19	64.93	74.07
f	56.52	74.00	91.00	86.67	A06	58.14	54.86	56.25	82.41
g	76.94	76.00	90.50	92.67	A07	63.60	88.54	94.10	75.93
—	—	—	—	—	A08	81.74	80.90	82.99	93.52
—	—	—	—	—	A09	85.40	84.38	74.61	81.48
Mean±Std	75.49±11.56	76.07±10.03	82.64±9.91	86.95±8.86	Mean±Std	70.58±12.66	73.19±15.98	74.61±14.56	81.48±10.65

表 4 四分类对比实验的平均准确率、平均标准差对比

Table 4 Comparison of average accuracy and average standard deviation of four-class classification comparison experiments %

受试者编号	Li 等 ^[25]	Cecotti 等 ^[26]	金晶等 ^[27]	RSCM-RM-CSP
A01	76.74	75.09	78.85	80.09
A02	58.68	60.42	66.73	70.37
A03	81.25	89.01	82.14	82.87
A04	57.64	66.23	64.91	76.85
A05	38.54	44.20	60.88	62.04
A06	48.26	55.81	43.24	56.94
A07	76.39	79.06	87.25	84.72
A08	79.17	81.92	83.64	83.80
A09	78.82	76.14	83.93	73.61
Mean±Std	66.17±15.75	69.76±14.24	72.39±14.52	74.23±11.86

表 3 和表 4 的对比实验结果表明,RSCM-RM-CSP 方法在 BCIIV 1 和 BCIIV 2a 数据集上的二分类平均准确率均高于现有其他方法,在 BCIIV 2a 数据集上的四分类平均准确率同样表现优异,说明该方法能够更好地捕捉与 MI 任务有关的特征并提升分类性能。此外,该方法在二分类和四分类任务上的标准差均低于其他方法,表明该方法在不同个体间和实验环境下的性能更加一致,不易受到个体差异的影响。综上所述,RSCM 与黎曼空间相结合的方法在 MI-BCI 系统中的应用具有一定优势,是一种有效的 EEG 特征提取与分类策略。

3.4 可视化分析

为了直观地评估不同特征提取方法在简单分类任务

中的特征分布情况,本研首先选取了 BCIIV 1 数据集的受试者 g 和 BCIIV 2a 数据集的受试者 A08 的 EEG 数据,采用消融实验中的 4 种方法提取特征,应用 t-SNE 进行二维降维可视化,以分析二分类任务下的特征分布情况,可视化对比结果如图 5 所示。

通过对比图 5 中第 1 列和第 3 列、第 2 列和第 4 列的可视化结果,可以直观地观察到频域特征对类间可分性的提升效果。频域特征的引入显著增强了样本特征之间的区分度。无论是否使用黎曼切空间进行平滑滤波,相较于采用 RCM,采用 RSCM 时两类样本的特征分布更为集中,类间界限更加清晰。这说明频谱协方差矩阵相较于时域协方差矩阵,能够更好地捕捉 EEG 不同频段之间的相关

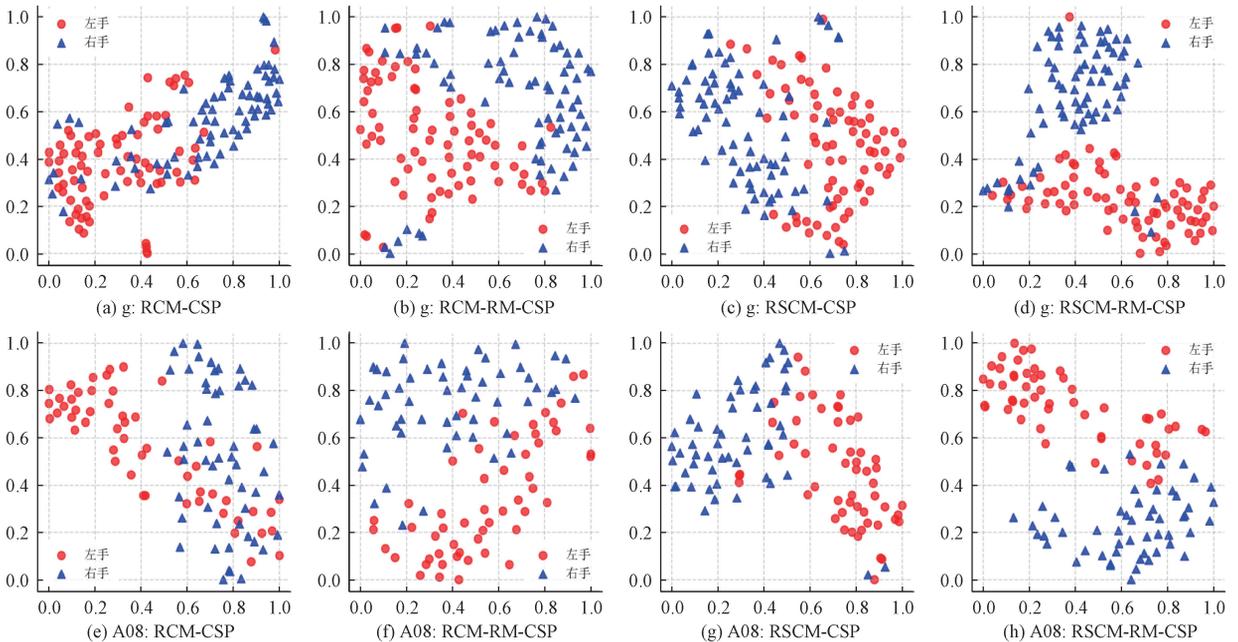


图 5 在二分类任务下,BCIIV 1 数据集的受试者 g 和 BCIIV 2a 数据集的受试者 A08 的特征 t-SNE 二维降维可视化
Fig. 5 In the binary classification task, t-SNE 2D dimensionality reduction visualization of features of subject g in the BCIIV 1 and subject A08 in the BCIIV 2a

性,增强特征的区分能力和分类效果。

通过对比图5中第1列和第2列、第3列和第4列的可视化结果,可以观察到使用黎曼切空间进行平滑滤波后的特征分布更为紧凑且类间界限更加明显。这种特征集中和类别区分的改善在第1列和第2列上最为明显。这说明,黎曼空间的处理方式可以有效保留RCM与RSCM的几何特性,进一步提升模型对MI任务的分类性能。这种性能的提升主要在于黎曼空间中对协方差矩阵的非线性处理。在本研究在RM-CSP方法中,首先将协方差矩阵映射到以黎曼均值为基的切空间中进行平滑处理,然后映射

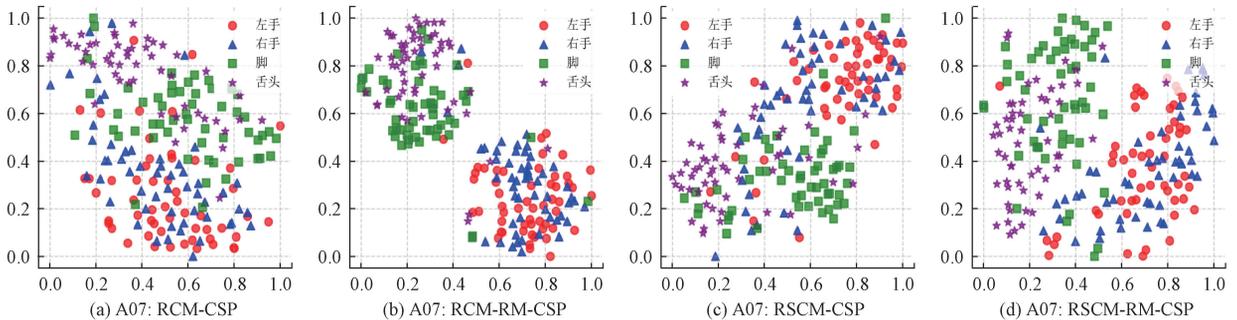


图6 在四分类任务下,BCIIV 2a数据集的受试者A07的特征t-SNE二维降维可视化

Fig. 6 In the four-class classification task, t-SNE 2D dimensionality reduction visualization of features of subject A07 in the BCIIV 2a

相比二分类任务,四分类任务的样本分布更加复杂,类间边界也更加模糊。然而,通过对比不同特征提取方法的可视化结果,可以观察到频域特征的引入和黎曼切空间平滑滤波的使用,均有助于提升类间可分性,使不同运动想象类别的特征分布更加清晰集中。这进一步验证了RSCM在捕捉EEG频域信息方面的优势,以及黎曼切空间平滑滤波在保持几何特性、增强特征区分度方面的有效性,为MI任务的特征提取提供了可靠的支持。

总体来看,图5和图6的可视化结果直观地验证了本研究方法的有效性。通过将时域协方差矩阵替换为频域协方差矩阵,并结合黎曼空间进行平滑滤波处理,不仅显著提升了传统CSP特征的分离效果,还增强了模型在处理复杂信号时的稳定性和分类性能。

4 讨论

针对传统的MI-EEG特征提取方法易受到噪声和伪迹的干扰,导致分类精度与稳定性不足的限制性,本研究提出了一种基于正则化频谱协方差矩阵与黎曼空间的运动想象脑电分类方法。从表2的结果中可以看出,本研究方法在MI-EEG分类任务中相较于现有其他方法表现出了一定的优势,在两个BCI数据集上均取得了较高的分类准确率和较低的平均标准差,证明了其在MI分类中的有效性和稳定性。

由于传统CSP特征提取方法需要计算协方差矩阵CM,但是时域下的CM相对于频域下的SCM更容易受到

回黎曼空间提取CSP特征。这种方式能够极大地保留特征的几何结构特性,避免传统欧几里德方法中可能出现的特征信息丢失的问题,增强模型对EEG中重要特征的捕捉能力。

随后,为了进一步分析不同特征提取方法在复杂分类任务下的表现,本研究选取了BCIIV 2a数据集的受试者A07的EEG数据,并采用相同的消融实验方法进行特征提取,通过t-SNE进行二维降维可视化,可视化对比结果如图6所示。

噪声和伪迹的影响。而且EEG会受到不同频段内活动的复杂调制,CM难以有效地捕捉频段之间的复杂关系和特征。因此,本研究采用频域的SCM来代替时域CM,以捕捉不同频段之间的相关性,增强CSP特征的区分能力,从而提升MI-EEG分类的准确性。

在实验过程中,本研究发现采用式(2)来计算CM和图3的流程来计算SCM时,会出现计算出来的矩阵不是SPD矩阵的问题。这可能是由于EEG采集过程中存在噪声干扰和硬件设备的测量误差^[28],累积的数值误差可能会导致某些特征值出现负值,从而导致计算的协方差矩阵失去正定性。为此,本研究引入了RR来提高矩阵的数值稳定性,确保所有特征值为正,从而使得协方差矩阵保持正定性,有助于保持数值的稳定性。

此外,由于SPD矩阵位于黎曼空间中,传统的线性空间方法无法有效地处理这类数据。为了解决这一问题,本研究将RSCM矩阵映射到黎曼切空间中。黎曼切空间是黎曼空间上某一点的局部线性化近似,可以视为该点的欧几里德空间的一个局部近似。这样就可以使用传统的线性处理方法来对RSCM矩阵进行有效的处理,从而提高特征的区分能力和稳定性,进而提升模型的准确性和稳定性。

然而,尽管通过正则化频谱协方差矩阵和黎曼空间的方式提高了特征的区分能力和模型的分类性能,但仍有进一步改进的空间。在未来的研究中,可以考虑将该方法应用于MI跨被试研究中,以评估其在不同受试者间的适应

性和推广能力。除此以外,本研究的计算复杂度仍有优化空间,未来可以考虑设计更高效的特征提取与分类算法,以降低运算时间,提高系统的实时性和实用性。

5 结 论

针对现有 MI-EEG 特征提取方法易受到噪声和伪迹干扰,导致分类精度与稳定性不足的问题,本研究提出了一种基于正则化频谱协方差矩阵与黎曼空间的特征提取与分类方法。该方法首先通过 RSCM 来捕捉 EEG 的频谱特征,并结合黎曼空间对 RSCM 进行平滑滤波处理来进一步增强特征的可区分性与模型的稳定性。实验结果表明,本研究方法在 BCI IV 数据集 1 和 2a 上均取得了优于现有其他方法的分类效果,验证了其在不同实验环境中的稳定性。但是,本研究算法在不同受试者间的适应性不足,未来将考虑使用迁移学习方法提高算法在不同受试者间的泛化能力。

参考文献

- [1] 谢平, 胡锦涛, 江国乾, 等. 基于多任务学习的快速序列视觉呈现脑电图分类[J]. 仪器仪表学报, 2023, 44(11): 215-223.
- XIE P, HU J CH, JIANG G Q, et al. Classification of rapid serial visual presentation based EEG with multi-task learning[J]. Chinese Journal of Scientific Instrument, 2023, 44(11): 215-223.
- [2] 郭玉雪, 于洪丽, 么航, 等. 基于离散小波变换的卷积自编码运动想象脑电信号的分类[J]. 电子测量技术, 2023, 46(19): 188-196.
- GUO Y X, YU H L, YAO H, et al. Classification of convolutional autoencoder motor imagery EEG signals based on discrete wavelet transform [J]. Electronic Measurement Technology, 2023, 46(19): 188-196.
- [3] DARVISH GHANBAR K, YOUSEFI REZAI T, FARZAMNIA A, et al. Correlation-based common spatial pattern(CCSP): A novel extension of CSP for classification of motor imagery signal[J]. Plos One, 2021, 19(5): e0303765.
- [4] JIN J, XIAO R CH, DALY I, et al. Internal feature selection method of CSP based on L1-norm and dempster-shafer theory [J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 32(11): 4814-4825.
- [5] BARACHANT A, BONNET S, CONGEDO M, et al. Multiclass brain-computer interface classification by Riemannian geometry[J]. IEEE Transactions on Biomedical Engineering, 2011, 59(4): 920-928.
- [6] HUA F, JING J, DALY I, et al. Feature extraction method based on filter banks and Riemannian tangent space in motor-imagery BCI[J]. IEEE Journal of Biomedical and Health Informatics, 2022, 26(6): 2504-2514.
- [7] WANG F, XU Z F, ZHANG W W, et al. Motor imagery classification using geodesic filtering common spatial pattern and filter-bank feature weighted support vector machine[J]. Review of Scientific Instruments, 2020, 91(3), DOI: 10.1063/1.5142343.
- [8] SHYU K K, HUANG S C, TUNG K J, et al. Common spatial pattern and riemannian manifold based real-time multiclass motor imagery EEG classification[J]. IEEE Access, 2023, 11: 139457-139465.
- [9] LUO T. Selective multi-view time-frequency decomposed spatial feature matrix for motor imagery EEG classification [J]. Expert Systems with Applications, 2024, 247: 123239.
- [10] 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.
- [11] BRUNNER C, LEEB R, MÜLLER-PUTZ G, et al. BCI Competition 2008-Graz data set A [J]. Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces), Graz University of Technology, 2008, 16: 1-6.
- [12] 肖健, 党选举. 多域特征融合的脑电信号肢体运动特征提取与动作识别[J]. 电子测量技术, 2024, 47(18): 23-30.
- XIAO J, DANG X J. Extraction of body movement features and action recognition based on multi-domain feature fusion in electroencephalogram signals [J]. Electronic Measurement Technology, 2024, 47(18): 23-30.
- [13] 张龙, 刘皓阳, 张号, 等. 改进共空间模式与多源特征融合的轴承智能诊断方法[J]. 西安交通大学学报, 2023, 57(8): 127-137.
- ZHANG L, LIU H Y, ZHANG H, et al. Intelligent bearing fault diagnosis using modified common spatial pattern and multi-source feature fusion[J]. Journal of Xi'an Jiaotong University, 2023, 57(8): 127-137.
- [14] UPADHYAY R, PADHY P K, KANKAR P K. EEG artifact removal and noise suppression by discrete orthonormal S-transform denoising[J]. Computers & Electrical Engineering, 2016, 53: 125-142.
- [15] LE C M, LEVIN K, BICKEL P J, et al. Comment: Ridge regression and regularization of large matrices[J]. Technometrics, 2020, 62(4): 443-446.

- [16] FU Y, GAO J, HONG X, et al. Low rank representation on riemannian manifold of symmetric positive definite matrices [C]. 2015 SIAM International Conference on Data Mining. Society for Industrial and Applied Mathematics, 2015: 316-324.
- [17] BOSE J, SMOFSKY A, LIAO R, et al. Latent variable modelling with hyperbolic normalizing flows [C]. International Conference on Machine Learning. PMLR, 2020: 1045-1055.
- [18] 徐慧, 何宏, 张慧敏, 等. 黎曼流形切平面空间中运动想象脑电信号的迁移学习[J]. 中国生物医学工程学报, 2023, 42(6): 659-667.
- XU H, HE H, ZHANG H M, et al. Transfer learning for motor imagery eeg signals in riemannian manifold tangent space [J]. Chinese Journal of Biomedical Engineering, 2023, 42(6): 659-667.
- [19] 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.
- [20] 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.
- [21] CHERLOO M N, AMIRI H K, DALIRI M R. Ensemble regularized common spatio-spectral pattern (ensemble RCSSP) model for motor imagery-based EEG signal classification[J]. Computers in Biology and Medicine, 2021, 135: 104546.
- [22] FAN ZH Y, XI X G, GAO Y Y, et al. Joint filter-band-combination and multi-view CNN for electroencephalogram decoding[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2023, 31: 2101-2110.
- [23] HA K W, JEONG J W. Temporal pyramid pooling for decoding motor-imagery EEG signals [J]. IEEE Access, 2020, 9: 3112-3125.
- [24] RIYAD M, KHALIL M, ADIB A. MI-EEGNET: A novel convolutional neural network for motor imagery classification [J]. Journal of Neuroscience Methods, 2021, 353: 109037.
- [25] LI M, HAN J, YANG J. Automatic feature extraction and fusion recognition of motor imagery EEG using multilevel multiscale CNN [J]. Medical & Biological Engineering & Computing, 2021, 59(10): 2037-2050.
- [26] 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.
- [27] 金晶, 杨益雕, 孙浩, 等. QTFD与DenseNet相结合的运动想象分类方法[J]. 信号处理, 2023, 39(8): 1443-1454.
- JIN J, YANG Y D, SUN H, et al. QTFD and DenseNet based motor imagery classification method [J]. Journal of Signal Processing, 2023, 39(8): 1443-1454.
- [28] LA ROSA A B, PEREIRA P T L, ÜCKER P, et al. Exploring NLMS-based adaptive filter hardware architectures for eliminating power line interference in EEG signals [J]. Circuits, Systems, and Signal Processing, 2021, 40: 3305-3337.

作者简介

廉小亲, 教授, 硕士生导师, 主要研究方向为智能信息处理技术。

E-mail: lianxq@263.net

刘春权, 硕士研究生, 主要研究方向为脑电信号处理。

E-mail: iwbforever@163.com

高超(通信作者), 副教授, 硕士生导师, 主要研究方向为智能检测与数据挖掘。

E-mail: gaochao9158@btbu.edu.cn