

DOI: 10.13382/j.jemi.B2407249

一种基于相位与残差信息的运动想象分类方法研究*

张家琦¹ 漆石钰²

(1. 海军工程大学兵器工程学院 武汉 430030; 2. 吉林工程技术师范学院数据科学与人工智能学院 长春 130000)

摘要:运动想象是脑-机接口领域中一类经典研究范式,该任务旨在研究仅通过大脑想象来完成对外部电子设备的信息传递与控制。共空间模式算法是运动想象研究中不可或缺的经典特征提取算法,该算法可以通过最大化类间方差来获得区分度较高的特征,从而获得分类性能良好的模型。然而,共空间模式算法对于噪声等干扰较为敏感,并且要求尽可能多的类间信息,导致其在非侵入式脑成像研究中运用效果不佳。针对该问题,提出了一种基于频域相位信息与时域趋势信息的数据处理算法,利用脑电信号的瞬时相位序列与经验模态分解残差分量构建了相位-残差序列,在保留大脑神经活动信息最大化的同时摒弃外界或其他噪声所带来的干扰,并通过共空间模式算法提取区分性更强的特征,最终获得识别和泛化性能更优的分类模型。实验结果表明,所提方法在52名受试者之间的平均分类准确率为88.19%,高于原始序列的79.67%,同时在不同受试者的运动想象数据中表现出了更为平稳的分类性能,证明了该方法在基于脑电信号的运动想象分类中具有良好的识别与泛化能力。

关键词:脑-机接口;希尔伯特变换;经验模态分解共空间模式;支持向量机

中图分类号: TN98 **文献标识码:** A **国家标准学科分类代码:** 510.4030

Research on a motion imagery classification method based on phase and residual information

Zhang Jiaqi¹ Qi Shiyu²

(1. School of Weaponry Engineering, Naval University of Engineering, Wuhan 430030, China;

2. School of Data Science and Artificial Intelligence, Jilin Engineering Normal University, Changchun 130000, China)

Abstract: Motor imagery is a classic research paradigm in the field of brain computer interfaces, which aims to study the information transmission and control of external electronic devices solely through brain imagination. The Common spatial paternal algorithm is an indispensable classic feature extraction algorithm in motor imagery research. This algorithm can obtain highly discriminative features by maximizing inter class variance, thereby obtaining models with good classification performance. However, the common spatial paternal algorithm is sensitive to noise and other interferences, and requires as much inter class information as possible, resulting in poor performance in non-invasive brain imaging research. To address this problem, a data processing algorithm based on phase information in frequency domain and trend information in time domain is proposed. The phase residual sequence is constructed using the instantaneous phase sequence and the empirical mode decomposition residual component of electroencephalogram signals. The algorithm maximizes brain neural activity information while eliminating interference from external or other noise, and extracts more discriminative features through common spatial paternal algorithm, ultimately obtaining a classification model with strong recognition and generalization performance. The experimental results show that the proposed method has an average classification accuracy of 88.19% among 52 subjects, which is higher than the original sequence's 79.67%. At the same time, it exhibits more stable classification performance in motor imagery data of different subjects, proving that the method has good recognition and generalization ability in electroencephalogram-based motor imagery classification.

Keywords: brain-computer interfaces; hilbert transform; empirical mode decomposition; common spatial paternal; support vector machines

收稿日期: 2024-01-28 Received Date: 2024-01-28

* 基金项目:湖北省自然科学基金(2024AFB404)项目资助

0 引言

脑-机接口 (brain computer interface, BCI) 是一种旨在建立大脑与外部计算机或其他电子设备的通讯与控制技术^[1]。该技术不依赖于常规信息传输通路,即大脑神经与肌肉组织,而是直接将大脑电生理活动与外部设备进行连接,进而完成信息交互与远程控制^[2]。运动想象 (motor imagery, MI) 是一种经典的 BCI 系统^[3-5],是当下最受关注的研究范式之一。该任务要求人在不产生实际运动输出的前提下,想象控制自身肌肉来完成肢体运动,从而在这一过程中完成特定脑区的激活。脑电信号 (electroencephalography, EEG) 主要来源于皮层锥体细胞群体的同步突触活动,是大脑思维活动的主要映射^[6]。EEG 拥有无创性、高时间分辨率以及可以精确反映大脑时变特性的特点,使得其面对 MI 任务时可以及时描述不同脑区的激活状态^[7-8]。

在 MI 任务期间,大脑主要产生 μ 节律 (8~14 Hz) 以及 β 节律 (18~24 Hz)^[9]。这一过程中,对侧大脑运动皮层的脑电节律活动会出现显著降低,即事件相关去同步 (event related desynchronization, ERD); 相反,同侧皮层脑电节律活动增强,这种变化情况称之为事件相关同步^[10-12] (event related synchronization, ERS)。因此,通过对 EEG 信号中 μ 节律和 β 节律进行分析,可以准确辨别出 MI 任务类别,进而完成与外部设备的信息交互。

共空间模式 (common spatial pattern, CSP) 是在二分类 MI 任务中常用的特征提取算法,该算法依靠矩阵对角化寻找最优空间滤波器,将多通道序列中每一类数据的空间分布成分投影至最优子空间,进而最大化两类信号类间方差,并得到区分度较大的特征值。近年来,已有多数研究证明了 CSP 算法在 BCI 领域的有效性。Wang 等^[13]利用 CSP 算法与判别规范模式匹配算法相结合,有效提高了左右手指运动意图的分类性能,为运动前脑电模式的解码提供了一种有效方法。Shi 等^[14]提出了一种基于 CSP 和自适应自回归的脑电特征提取算法,该算法能够有效地提取 MI 过程中脑电信号的特征,为 BCI 特征提取的进一步研究提供了参考。Ali 等^[15]基于 CSP 算法,利用网格搜索方法进行特征选择完成了 MI 任务中分类性能的提升。

CSP 算法依靠其与多通道 EEG 数据源的匹配性及其强大的特征提取能力已被广泛应用于多种脑认知研究当中,并成为 BCI 领域中不可或缺的经典算法之一^[16]。然而,CSP 算法也存在有局限性,其对噪声的敏感性将直接导致最终分类性能的下降。噪声是 EEG 信号中不可避免的干扰来源,其主要来自于外界噪声、人体生理电噪声以及大脑各个通道之间电活动的互相干扰。针对该问

题,提出了一种基于相位的经验模式分解 (empirical mode decomposition, EMD) 残差分量加权处理算法。

有研究表明,相位同步与幅值相关是一种功能独立的现象,其在神经元之间信息的传递存在不同^[17-18]。此外,在视觉信息的处理中,相位信息的编码过程比幅值信息蕴含更多神经活动数据,证明了相位信息在神经信息传导过程中的重要性^[19]。EMD 方法可以将任意非平稳信号分解为多个线性稳态信号^[20],其中包括有多个本征模函数 (intrinsic mode function, IMF) 以及一个残差分量^[21]。有研究表明,EMD 算法分解得出的残差分量可以作为序列的趋势项^[22]。该分量只表征信号的趋势图,忽略了信号中原有的细节信息,包括大部分的噪声干扰。因此,利用相位与残差分量的加权可以构建出蕴含更多信息且包含更少干扰项的序列。将该序列送入 CSP 算法进行特征提取,可以获得区分度更高的特征用于 MI 任务的分类识别。

经过测试表明,所提出的处理方法可以更好的提升 CSP 算法提取特征的性能,使最终的分类模型拥有更强的鲁棒性能以及模型泛化能力。

1 相位-残差序列构建

1.1 相位序列

所提出算法中相位需与残差分量进行加权,为保证二者序列长度一致,使用希尔伯特变换方法 (hilbert transform, HT) 求解 EEG 序列在各个点的瞬时相位。HT 能够将一维信号转换为二维复平面上的解析信号。实际上,时间序列经过 HT 后,其实部仍旧是其原信号本身,虚部则为实际上的 HT 信号。

HT 的计算过程可以看作是一个系统。输入 x_t 为原始信号,系统冲激响应为 $h_t = \frac{1}{\pi t}$,输出为 x_t 与 h_t 的卷积结果 \hat{x}_t 。其 HT 可以写为:

$$\hat{x}_t = x_t \times h_t = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t - \tau} d\tau \quad (1)$$

原始信号 x_t 的解析式可以写为:

$$\tilde{x}_t = x_t + \hat{x}_t \quad (2)$$

瞬时相位的求解过程为:

$$\varphi_t = \arctg\left(\frac{\hat{x}_t}{x_t}\right) \quad (3)$$

式中: φ_t 表示在 t 时刻下瞬时相位值。

1.2 残差序列

EMD 分解由在 1998 年提出,适用于非平稳非线性时间序列的分析与处理,因此,该理论在 EEG 信号的处理上被广泛运用^[23]。

EMD 分解不需要对信号进行预先分析以确定基函数,因此该方法在处理一些未知信号时具有良好的性能表现。EMD 分解过程较为简单,其本质上是依据信号的上下包络特性将信号按照频率递减的规律进行逐级分离,最终分离出的各个分量即为该信号的 IMF,最后无法继续分解的分量则为残差分量。具体的分解过程为:

1) 找出原始序列 x_i 的所有极大值点,并使用三次样条差值函数将所有极大值点拟合为 x_i 的上包络线,记为 \hat{x}_i ;

2) 找出原始序列 x_i 的所有极小值点并将其拟合为 x_i 的下包络线,记为 \tilde{x}_i ;

3) 求出 \hat{x}_i 与 \tilde{x}_i 的均值序列 m_i ,并让原始序列 x_i 减去均值序列 m_i ,得到新序列,如果新序列中不存在负的极大值点以及正的极小值点,则该新序列为 IMF1。若不满足条件,则对新数据重复以上步骤;

4) 若新序列满足条件为 IMF 时,则由原始序列 x_i 减去 IMF1 得到新序列 x_{1i} 。此时 x_{1i} 将作为新的原始序列重复以上步骤直到找到 IMF2、IMF3... ,以及最后的残差序列 r_i 。

1.3 相位-残差序列

相位-残差序列由 HT 求解的瞬时相位 φ_i 与 EMD 分解产生的残差序列 r_i 在各个 t 时刻相乘得到。其可以表示为:

$$Pr_i = \varphi_i \times r_i \quad (4)$$

式中: Pr_i 表示相位-残差序列在 t 时刻的值。

1.4 CSP 算法

CSP 算法可以在二分类任务中找到数据区分度最大的特征值,是一种被广泛用于 MI 分类的特征提取算法。

CSP 算法要求输入数据为多通道形式,即通道数 \times 采样点。假设给定两个不同类别的多通道 EEG 序列 x_1 和 x_2 ,求解其归一化后的协方差矩阵为:

$$E_i = \frac{x_i x_i^T}{\text{trace}(x_i x_i^T)} \quad (5)$$

式中: $i = 1, 2$ 表示数据类别; $\text{trace}(\cdot)$ 符号表示求解矩阵的迹。二者协方差之和为:

$$E = \sum_{i=1}^2 E_i \quad (6)$$

对 E 进行奇异值分解可以得到:

$$E = U \Lambda U^T \quad (7)$$

式中: λ 表示为特征值; U 为对应的特征向量。将特征值按降序排列,对 U 进行白化转换可得:

$$P = \frac{1}{\sqrt{\lambda}} U^T \quad (8)$$

之后,构建空间滤波器:

$$S_1 = P E_1 P^T \quad (9)$$

$$S_2 = P E_2 P^T \quad (10)$$

对 S_1 与 S_2 进行主分量分解可得:

$$S_1 = B \Lambda_1 B^T \quad (11)$$

$$S_2 = B \Lambda_2 B^T \quad (12)$$

S_1 与 S_2 的特征向量矩阵 B 相同。此时,空间滤波器表示为:

$$W = B^T P \quad (13)$$

需要注意的是,投影矩阵 W 由训练集序列求出。在特征提取时,对于训练集,特征提取过程为:

$$Y_1 = W x_1 \quad (14)$$

$$Y_2 = W x_2 \quad (15)$$

对于测试集:

$$Y = W x \quad (16)$$

在 1.3 节中,最后计算得到的 Pr_i 将替代原始 EEG 序列送入 CSP 算法中进行特征提取。

2 实验数据分析

2.1 数据来源

使用由 Cho 等^[24]于 2017 年提供的 MI-EEG 数据集。为保证数据质量的均匀性,数据集由可分性较强的多数数据(38 名受试者)和可分性较弱的少数数据组成。该数据集共包括 52 名受试者,每名受试者包含有 100 次左手任务实验和 100 次右手任务实验。每名受试者单次实验过程持续 7.5 s 左右。首先,实验开始后的 2 s 期间内受试者会看到一个“+”符号,用于提示受试者集中注意力并开始准备左手或右手想象任务,之后 2 ~ 5 s 内屏幕上会出现一个向左或向右的箭头标志,提示受试者在此期间持续进行左手或右手的想象任务。5 ~ 7 s 屏幕会再次出现“+”符号,此时受试者可以短暂休息,并准备进入下一个实验试次。

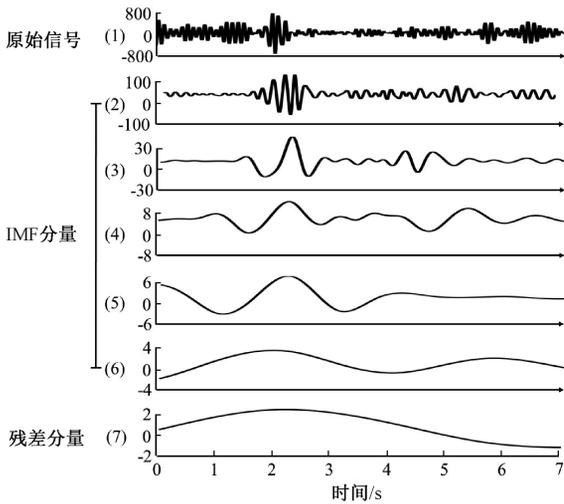
该实验使用基于国际 10-10 系统的 64 通道电极帽完成数据采集,采样频率为 512 Hz。在数据预处理过程中,使用 EEGLab 对数据进行 0.3 ~ 30 Hz 带通滤波,更改参考电极至 P9, P10 电极。之后,利用独立成分分析(independent component algorithm, ICA)去除 EEG 眼电伪影等成分,并以刺激前 1 s 数据作为基线进行基线校正并提取两类实验试次。

2.2 数据分析

由于 μ 节律与 α 节律基本重合,并且 α 节律与大脑的注意力机制密切相关^[25-26]。因此,相较于 β 节律, μ 节律数据对 MI 分类研究更有价值。

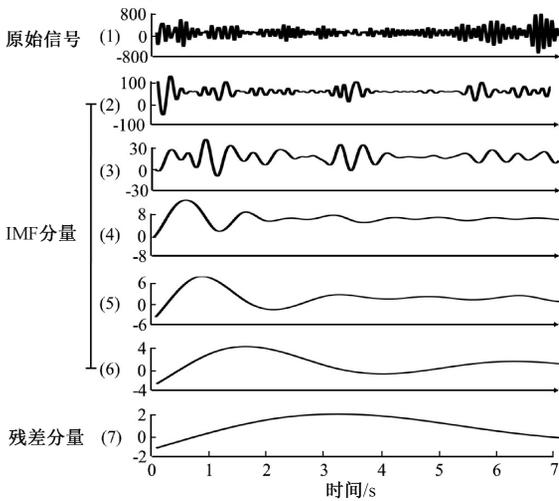
MI 任务期间主要激活脑区为初级运动皮层,对应电极为 C3, C4。二者分别反映了左、右脑在 MI 任务下的神经激活反应。为对比不同任务下大脑的反应模式,选取

1号受试者 C3 电极 EEG 信号进行分析。通过对其 EMD 分解发现,两类任务下 C3 电极的 EMD 残差分量存在较大差异,并且该差异从实验开始一直持续到单次任务结束。该现象表明受试者在集中注意力时刻,即 MI 任务前,受试者大脑两侧运动皮层已经开始出现了不同的激活反应。 μ 节律的趋势变化说明在 MI 任务前大脑的编码模式已经开始出现了改变,该现象与 Wang 等^[13]的研究结果一致。图 1 为 1 号受试者 EMD 分解图。其中,图 1(a)和(b)分别表示右手任务与左手任务下 C3 电极 EEG 信号 EMD 分解图。图中共包含 5 个 IMF 分别为(2)~(6)以及一个残差分量(7),(1)表示 C3 电极经过带通滤波后的 μ 节律原始信号。



(a) 右手任务 C3 电极 EMD 分解图

(a) EMD decomposition diagram of C3 electrode for right-handed task



(b) 左手任务 C3 电极 EMD 分解图

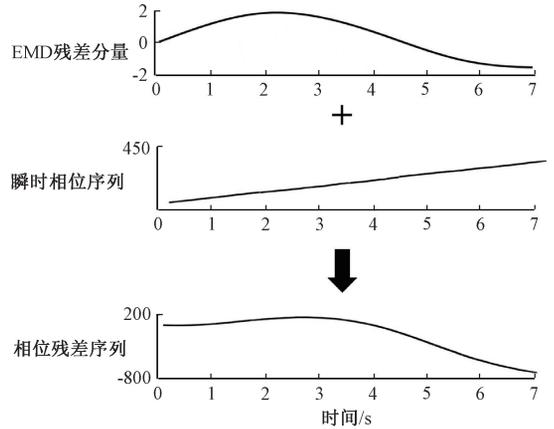
(b) EMD decomposition diagram of C3 electrode for left-handed task

图 1 两类任务下 C3 电极脑电信号 EMD 分解图

Fig. 1 EMD decomposition diagram of C3 electrode EEG signals under two types of tasks

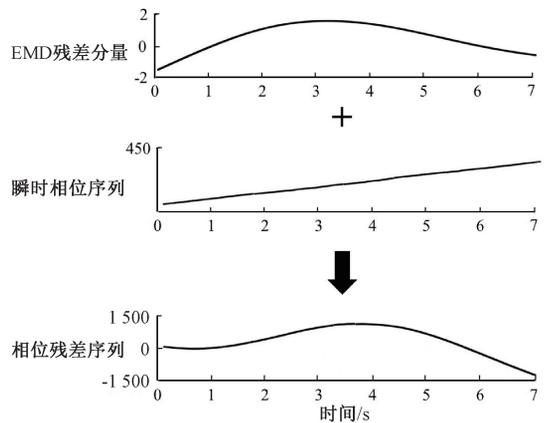
2.3 特征提取

在特征提取前,需要先完成相位-残差序列的构建。通过提取每名受试者各个通道下的 EEG 信号瞬时相位以及 EMD 残差分量,对其进行相乘加权,以获得最终相位-残差序列。1 号受试者相位-残差序列的构建过程如图 2 所示。图 2(a)和(b)分别表示右手任务与左手任务下 C3 电极的相位-残差序列构建图。



(a) 右手任务 C3 电极相位-残差序列构建

(a) Construction of phase-residual sequence for C3 electrode in right hand task



(b) 左手任务 C3 电极相位-残差序列构建

(b) Construction of phase-residual sequence for C3 electrode in left hand task

图 2 两类任务下 C3 电极相位-残差序列构建

Fig. 2 Construction diagram of C3 electrode phase-residual sequence under two types of tasks

图 2(b)中,EMD 残差分量表示趋势信息,瞬时相位序列为相位信息。相位-残差序列构建过程为 EMD 残差分量与瞬时相位序列的逐点相乘。完成所有相位-残差序列构建后,将重构后的序列送入 CSP 算法进行特征提取,并选取 CSP 特征中前 3 维与后 3 维特征作为分类特征。

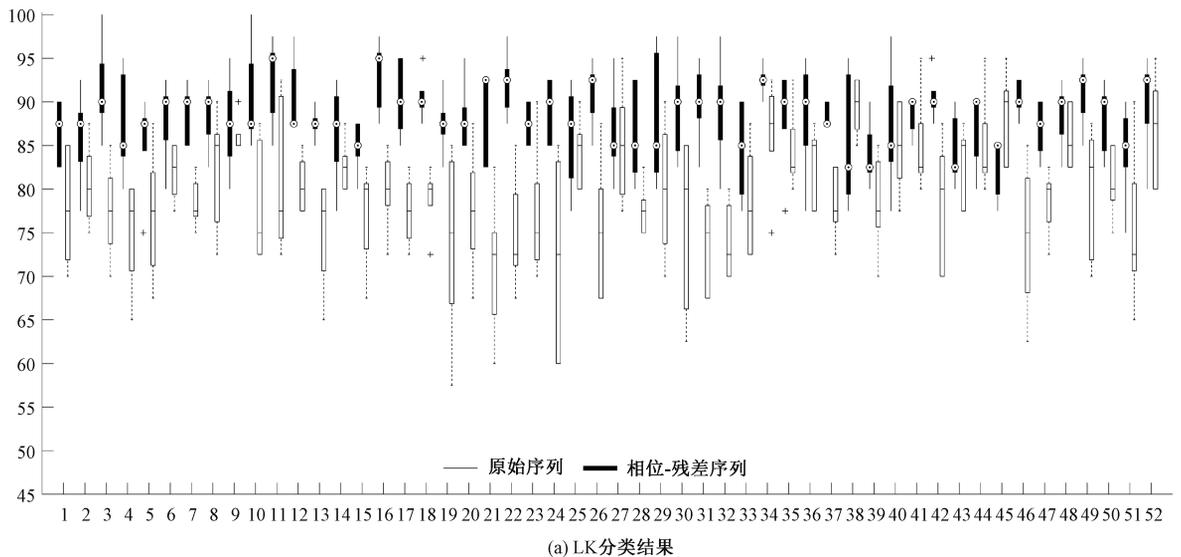
3 实验结果

支持向量机(support vector machines, SVM)作为较

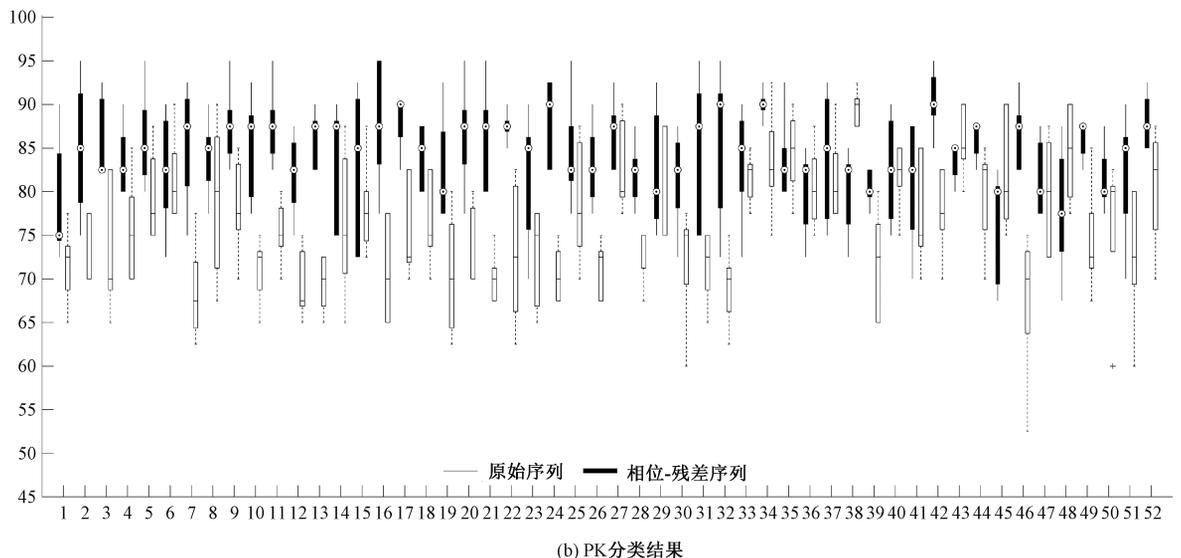
早出现的二分类机器学习算法,其分类原理适用于高维小样本数据,且能够在小样本训练中获得较高的分类准确率^[27]。SVM 有多个核函数,在面对未知数据时,核函数的选择直接影响模型最终的性能。因此,为进一步评估所提出方法的有效性,选用线性核函数(linear kernel, LK)、多项式核函数(polynomial kernel, PK)以及高斯核函数(radial basis function Kernel, RBF)分别作为 SVM 分类模型的核函数用于模型训练。其中, LK 拥有更快的计算速度,但实际上其并没有将样本映射至高维特征空间中,因此 LK 仅在面对线性可分的问题上表现较为突出;PK 本质上是 LK 的一种广义表示,等价于一个多项式变化,依靠升维使得原来线性不可分的特征线性可分;RBF 可以将输入样本以非线性的方式投

影到更高维度的特征空间中,以获得对非线性数据更好的划分平面。

为保证最终分类模型的泛化性能,使用 5 折交叉验证完成对模型的性能评估。图 3 显示了不同核函数下,相位-残差序列与原始序列分类准确率的箱型图对比。其中,图 3(a)表示 LK 分类结果;图 3(b)表示 PK 分类结果,图 3(c)表示 RBF 分类结果。图 3 横轴为受试者编号,纵轴表示 5 折交叉验证的分类结果分布。箱型图两侧的离散点为异常点。从图 3 中可以看出,对于大部分受试者的 EEG 数据,相位-残差序列通过 CSP 特征提取后分类准确率明显上升。此外,经过 5 折交叉验证可以发现,所提出方法可以在一定程度上增加模型的泛化能力,在不同测试集上表现出较为稳定的分类表现。



(a) Classification results of LK



(b) Classification results of PK

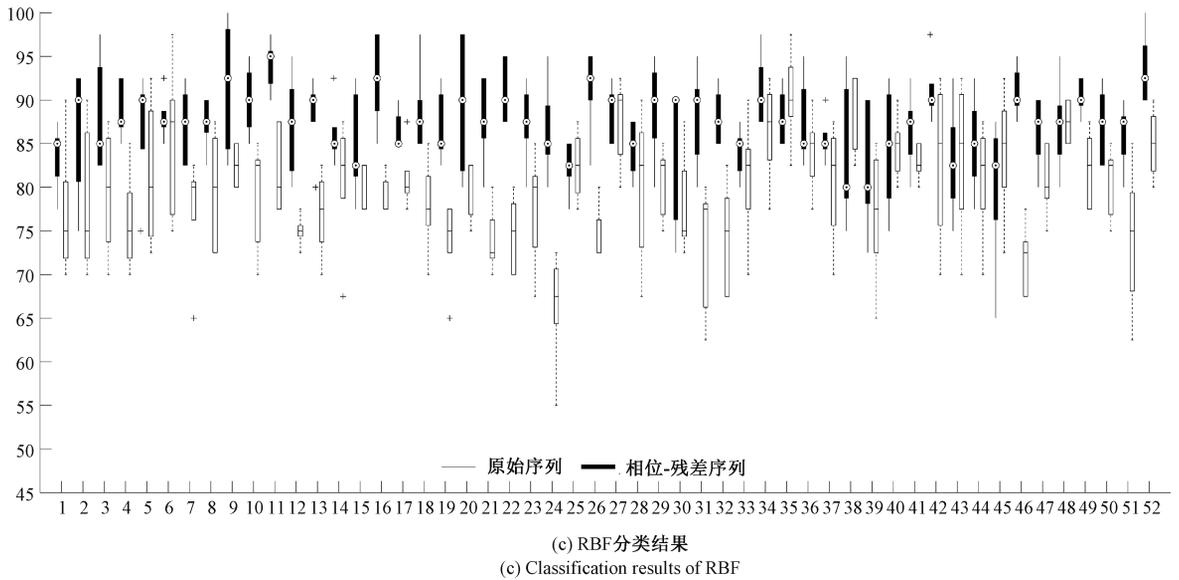


图 3 3 种核函数下 SVM 准确率箱型对比

Fig. 3 Comparison of box plots for SVM accuracy under three kernel functions

表 1 给出了 3 种核函数下 52 名受试者的平均分类准确率。其中,平均准确率为 52 名受试者全部分类准确率平均,最高准确率为 52 名受试者交叉验证最高准确率的均值。从表中可以发现,无论是平均准确率或是最高准确率,所提出方法得到的分类性能均远高于原始序列。此外,相位-残差序列的准确率在 LK 下获得了最佳分类性能,说明所提出算法具有良好的线性可分能力,证明该方法在提高分类性能的同时,有效降低了分类模型的计算成本与时间成本。

表 1 3 种核函数下 52 名受试者的 SVM 平均分类准确率
Table 1 The average classification accuracy of SVM for 52 subjects under three kernel functions (%)

核函数	原始序列		相位-残差序列	
	平均准确率	最高准确率	平均准确率	最高准确率
LK	79.67	87.07	88.19	93.41
PK	76.33	82.84	84.07	90.63
RBF	79.90	86.39	87.41	93.13

4 讨论

相位-残差序列结合了 MI 任务中原始 EEG 信号的相位信息及其 EMD 残差分量信息,在保证获得更多序列信息的同时,降低了噪声等异常点干扰。该方法对于对噪声和异常点敏感的 CSP 算法来说,在获得足够方差最大化信息的同时,避免了异常点对特征的干扰。此外,该方法的目的旨在尽可能收集原始序列中所蕴含的分类信息,并最小化外界噪声所造成的干扰,因此,理论上该方

法适用于大多数特征提取算法。

对于深度学习等模型,由于该方法实际上去除了原始序列中幅值的大部分细节信息,仅保留了趋势信息,因此,对于含有多层隐层网络的学习模型应考虑过拟合等风险。但相对的,应用该方法后可以在一定程度上减少深度学习的网络层数,在避免过拟合风险的同时,也可以加快模型的拟合速度。

考虑到选用数据集中,单个受试者的单类样本数据量只有 100,选择 SVM 作为最终的分类模型。该模型在小样本数据中具有强大分类性能和良好的鲁棒性,可以在样本量不足的情况下完成对特征的边界划分。最终的性能评估结果表明,SVM 在原始序列和相位-残差序列中均具有不错的分类表现。不同核函数下的平均分类性能结果表明,原始序列的 CSP 特征可能更加接近于非线性特征,因此其在 RBF 核函数下的平均准确率最高。而经过处理后的相位-残差序列,其准确率不仅仅在 3 类核函数下均高于原始序列,且在 LK 核函数下即可完成最优分类模型的收敛。因此,所提出算法的 CSP 特征更加满足线性可分的条件,在一定程度上可以加快分类模型的收敛速度。最后,使用 5 折交叉验证完成了对模型泛化能力的评估。从评估结果上来看,相位-残差序列的 CSP 特征拥有更小的准确率方差,这一点在 LK 的分类结果中最为明显。

然而,本算法也存在一些不足之处。由于在序列构建的同时考虑了相位信息,因此相位噪声的存在可能会干扰特征提取以及分类模型的性能。此外,舍弃幅值的细节信息可能导致多分类情况下,模型的准确率出现下

降。然而,对于两分类 MI 任务来说,所提方法仍旧为 CSP 等特征提取算法提供了一条新的优化途径。

5 结 论

针对 MI 分类中的噪声干扰问题,设计了一种具备高信息、低干扰的 EEG 序列处理方法。该方法通过 HT 和 EMD 算法提取了 EEG 信号的相位信息以及趋势信息,利用相位序列与残差分量加权构建出蕴含更多信息且包含更少干扰项的相位-残差序列,有效降低了噪声对 CSP 算法造成的干扰,并为 CSP 算法提供了更多的类别信息用以提取区分性更强的特征,保证了最终分类模型的分​​类能力以及抗干扰能力。同时,经过该方法提取的特征具有良好的线性可分性,保证分类器在提高分类能力的同时,提高了模型的拟合速度,确保了模型的收敛能力。实验结果表明,所提出算法在不同受试者之间的平均分类准确率为 88.19%,高于原始序列的 79.67%,证实了所提出方法在提高模型分类性能的可靠性。并且,通过对模型进行 5 折交叉验证发现,所提方法对模型的泛化能力也具有一定的增强作用,在抑制模型过拟合的同时,增强了模型的鲁棒性。该方法完成了 MI 二分类任务的准确分类,并在原有序列基础上得到了较高准确率的提升,为后续基于 EEG 的 MI 分类提供了一种新的优化途径。在未来的工作中,该方法将被推广至多分类模型中,并将其引入深度学习用于对不同认知分类任务进行研究。

参考文献

- [1] GAO X R, WANG Y J, CHEN X G, et al. Interface, interaction, and intelligence in generalized brain-computer interfaces [J]. *Trends in Cognitive Sciences*, 2021, 25(8): 671-684.
- [2] SAHA S, MAMUN K A, AHMED K, et al. Progress in brain computer interface: Challenges and opportunities[J]. *Frontiers in Systems Neuroscience*, 2021, 15: 578875.
- [3] AL-SAEGH A, DAWWD S A, ABDUL-JABBAR J M. Deep learning for motor imagery EEG-based classification: A review[J]. *Biomedical Signal Processing and Control*, 2021, 63: 102172.
- [4] ALTAHERI H, MUHAMMAD G, ALSULAIMAN M, et al. Deep learning techniques for classification of electroencephalogram (EEG) motor imagery (MI) signals: A review [J]. *Neural Computing and Applications*, 2023, 35(20): 14681-14722.
- [5] PADFIELD N, ZABALZA J, ZHAO H, et al. EEG-based brain-computer interfaces using motor-imagery: Techniques and challenges[J]. *Sensors*, 2019, 19(6): 1423.
- [6] KHOSLA A, KHANDNOR P, CHAND T. A comparative analysis of signal processing and classification methods for different applications based on EEG signals [J]. *Biocybernetics and Biomedical Engineering*, 2020, 40(2): 649-690.
- [7] ZHANG C, KIM Y K, ESKANDARIAN A. EEG-inception: An accurate and robust end-to-end neural network for EEG-based motor imagery classification [J]. *Journal of Neural Engineering*, 2021, 18(4): 046014.
- [8] LIAO J J, LUO J J, YANG T, et al. Effects of local and global spatial patterns in EEG motor-imagery classification using convolutional neural network [J]. *Brain-Computer Interfaces*, 2020 (1): 1-10.
- [9] YU H L, BA S D, GUO Y X, et al. Effects of motor imagery tasks on brain functional networks based on EEG mu/beta rhythm [J]. *Brain Sciences*, 2022, 12(2): 194.
- [10] LUO J, GAO X, ZHU X, et al. Motor imagery EEG classification based on ensemble support vector learning [J]. *Computer Methods and Programs in Biomedicine*, 2020, 193: 105464.
- [11] ASI Z U, SULTAN M, MUNEER U, et al. Classification of non-discriminant ERD/ERS comprising motor imagery electroencephalography signals [J]. *International Journal of Advanced Computer Science and Applications*, 2020, 11(1), DOI:10.14569/IJACSA.2020.0110146.
- [12] LIU Y H, LIN L F, CHOU CH W, et al. Analysis of electroencephalography event-related desynchronisation and synchronisation induced by lower-limb stepping motor imagery [J]. *Journal of Medical and Biological Engineering*, 2018, 39(4): 1-16.
- [13] WANG K, XU M P, WANG Y J, et al. Enhance decoding of pre-movement EEG patterns for brain-computer interfaces [J]. *Journal of Neural Engineering*, 2020, 17(1): 016033.
- [14] SHI T, REN L, CUI W. Feature extraction of brain-computer interface electroencephalogram based on motor imagery [J]. *IEEE Sensors Journal*, 2020, 20(20): 11787-11794.
- [15] ALI S, FERDOUS J, HAMID E, et al. A novel features selection approach with common spatial pattern for EEG based brain-computer interface implementation [J]. *IETE Journal of Research*, 2022, 68(3): 1757-1771.
- [16] TANG ZH CH, LI CH, WU J F, et al. Classification of EEG-based single-trial motor imagery tasks using a B-CSP method for BCI [J]. *Frontiers of Information Technology & Electronic Engineering*, 2019, 20(8): 1087-1098.
- [17] PALVA J M, WANG S H, PALVA S, et al. Ghost interactions in MEG/EEG source space: A note of

- caution on inter-areal coupling measures[J]. *Neuroimage*, 2018, 173: 632-643.
- [18] CHIARION G, SPARACINO L, ANTONACCI Y, et al. Connectivity analysis in EEG data: A tutorial review of the state of the art and emerging trends[J]. *Bioengineering*, 2023, 10(3): 372.
- [19] KANG H, ZHANG X F, ZHANG G B. Phase permutation entropy: A complexity measure for nonlinear time series incorporating phase information[J]. *Physica A: Statistical Mechanics and its Applications*, 2021, 568: 125686.
- [20] 蔡昕一, 马军, 李祥. 改进复合插值包络经验模态分解的滚动轴承故障特征提取方法[J]. *电子测量与仪器学报*, 2023, 37(1): 191-203.
CAI X Y, MA J, LI X. Fault feature extraction method of rolling bearing based on the improved composite interpolation envelope empirical mode decomposition[J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(1): 191-203.
- [21] 吕峥, 庄炜, 吴越, 等. 基于改进 EMD 方法的 FBG 传感网络光谱基线校正研究 [J]. *仪器仪表学报*, 2022, 43(1): 190-197.
LYU ZH, ZHUANG W, WU Y, et al. Research on spectral baseline correction of FBG sensor network based on the improved EMD method[J]. *Chinese Journal of Scientific Instrument*, 2022, 43(1): 190-197.
- [22] ZHANG W H, WANG T. Short-term power load forecasting model design based on EMD-PSO-GRU[J]. *Scientific Programming*, 2022, DOI:10.1155/2022/4755519.
- [23] WANG X, SHI J, ZHANG J. A power information guided-variational mode decomposition (PIVMD) and its application to fault diagnosis of rolling bearing [J]. *Digital Signal Processing*, 2022, 132: 103814.
- [24] CHO H, AHN M, AHN S-K, et al. EEG datasets for motor imagery brain-computer interface[J]. *GigaScience*, 2017, 6: 1-8.
- [25] PEYLO C, HILLA Y, SAUSENG P. Cause or consequence? alpha oscillations in visuospatial attention [J]. *Trends in Neurosciences*, 2021, 44(9): 705-713.
- [26] MAGOSSO E, CRESCENZIO F D, RICCI G, et al. EEG alpha power is modulated by attentional changes during cognitive tasks and virtual reality immersion[J]. *Computational Intelligence and Neuroscience*, 2019(1): 7051079.
- [27] KOKOL P, KOKOL M, ZAGORANSKI S. Machine learning on small size samples: A synthetic knowledge synthesis[J]. *Science Progress*, 2022, 105(1): 368504 211029777.

作者简介



张家琦, 2017 年于河南科技大学获得学士学位, 2021 年于中南民族大学获得硕士学位, 现为海军工程大学博士研究生, 主要研究方向为脑认知、脑-机接口。

E-mail: JiaqiZhang_work@163.com

Zhang Jiaqi received his B. Sc. degree from Henan University of Science and Technology in 2017 and M. Sc. degree from South-Central Minzu University in 2021, respectively. Now he is Ph. D. Candidates in Naval University of Engineering. His main research interests include brain cognition and brain computer interface.



漆石钰(通信作者), 现为吉林工程技术师范学院本科生, 主要研究方向为信号处理。

E-mail: 2271911202@qq.com

Qi Shiyu (Corresponding author) now he is an undergraduate student at Jilin Engineering Normal University. His main research interests include brain cognition and brain computer interface.