

DOI: 10.19650/j.cnki.cjsi.J2109039

基于力度无关鲁棒特征的肌电手势识别方法*

林恒^{1,2}, 李玉榕^{1,2}, 施正义^{1,2}, 朱菲菲^{1,2}

(1. 福州大学电气工程与自动化学院 福州 350108; 2. 福建省医疗器械和医药技术重点实验室 福州 350108)

摘要:为了减小肌肉收缩力变化对肌电信号模式识别的影响,提出了DCSP特征。该特征首先通过CSP算法得到最大化类与类之间距离的空间投影矩阵,然后对投影后的新信号进行差分 and 归一化处理,最终通过非相关线性判别分析将数据投影到类内距离最小、类间距离最大的低维空间而得到。在两个数据集上验证基于DCSP特征的肌电手势识别正确率,第1个数据集包含10名完整肢体受试者的数据,第2个数据集包含9名上肢截肢者的数据。在识别率测试的4个方案中,DCSP特征的识别正确率均高于CSP特征,在全部力训练,全部力测试的方案上取得最高的识别率(数据集1:95.83%,数据集2:86.93%),相比CSP特征(数据集1:89.01%,数据集2:70.03%),分类准确率分别提升6%和16%。在特征空间分布的2个测试方案上,DCSP特征比CSP特征都具有更小的类内距离和更大的类间距离。相比较于其他研究的识别正确率,DCSP特征比现有的力度鲁棒特征提升了约5%(数据集1)和8%(数据集2),并且性能不依赖于分类器类型。

关键词:肌肉收缩力;共空间模式;手势识别

中图分类号: TP391.4 TH77 **文献标识码:** A **国家标准学科分类代码:** 510.40

EMG gesture recognition method based on robust feature independent of strength

Lin Heng^{1,2}, Li Yurong^{1,2}, Shi Zhengyi^{1,2}, Zhu Feifei^{1,2}

(1. College of Electrical Engineering and Automation, Fuzhou University, Fuzhou 350108, China;
2. Fujian Key Laboratory of Medical Instrument and Pharmaceutical Technology, Fuzhou 350108, China)

Abstract: In order to reduce the influence of the change of muscle contraction force on EMG pattern recognition, this paper proposes the feature of DCSP. Firstly, the spatial projection matrix that maximizes inter-class distance is obtained by the CSP. Then, the new signal after projection is differentiated and normalized. Finally, the data are projected into the low-dimensional space with the smallest intra-class distance and the largest inter-class distance by the uncorrelated linear discriminant analysis, the EMG gesture based on DCSP feature is verified on two datasets. The first dataset contains data from 10 complete limb subjects, and the second dataset contains data from 9 upper limb amputees. Among the four schemes of recognition rate testing, the recognition accuracy of the DCSP feature in this paper is higher than that of the CSP feature, and the highest recognition rate is achieved in all force training and all force testing schemes (dataset1: 95.83%, dataset2: 86.93%). Compared with CSP feature (dataset1: 89.01%, dataset2: 70.03%), the classification accuracy rates are increased by 6% and 16%, respectively. In the two test schemes of feature spatial distribution, the DCSP feature has a smaller intra-class distance and a larger inter-class distance than the CSP feature. In the comparison results of other studies, the DCSP feature improves the recognition accuracy by about 5% (dataset1) and 8% (dataset2) compared with the existing robust features, and the performance does not depend on the classifier.

Keywords: muscle contraction force; common spatial pattern; gesture recognition

0 引言

表面肌电信号(surface electromyogram, sEMG)由于

其包含大量受试者的运动信息,且采集简单,过程无创,被认为是获取受试者运动意图的有效来源。由于模式识别技术的发展,肌电信号模式识别(EMG pattern recognition, EMG-PR)也被广泛研究^[1-2]。肌电信号模式

识别中,受试者在离线阶段被要求进行不同的动作并同时采集了表面肌电信号,这些信号通过了预处理,特征提取,训练分类器等步骤,最终在测试阶段,经过训练的分类器就可以输出测试数据对应的类别。经过多年的研究,基于表面肌电信号的人机交互系统可以识别几十类手部、腕部的动作,识别准确率基本超过了90%^[3]。

但是在实际应用当中,肌电信号受到肌肉收缩力^[4]、肢体姿态^[5]、电极偏移^[6]、个体性差异、肌肉疲劳,等因素的影响,肌电模式很难保持稳定,识别正确率大大下降,这其中力度的变化是影响分类准确率的一个主要因素。

构造对力度变化具有鲁棒性的特征,将极大地提高系统的鲁棒性,同时也能降低因为数据量或数据类型扩增而引起的数据采集阶段和模型训练阶段的耗时^[5],因此近年开始致力于提出力度鲁棒特征来减小力度的影响。He等^[7]提出了一种基于跨通道归一化的频域特征的鲁棒特征提取方法,识别率达到91%。但是文中的方法要求电极放置在前臂的指定位置,不利于实际的应用。Khushaba等^[8]为解决不同因素对肌电信号模式识别的联合影响,在一个包含3个手臂位置,3种收缩力度的数据集上,验证所提特征时域功率谱描述符(time-domain power spectral descriptors, TD-PSD)的性能。此外,实验还包括了受试者手腕3个方向上的加速度信号,实验结果表明:TD-PSD可以减小手臂位置和收缩力度变化二者对肌电信号的联合影响,加速度信号则可以进一步提高分类准确率。Liu等^[9]提出了一种对数-梅尔-频谱特征(log-mel-frequency spectrum, Log-MFS)。Log-MFS特征对比常用的时域特征集,在3个力水平上都实现了较高的分类准确率,在低水平力度和高水平力度上,分类准确率提高了约27%和11%。

然而,之前的许多研究都是在四肢健全的受试者上进行的,事实上肌电假肢最终面向的用户是截肢的残疾人,他们失去的肢体导致他们无法接收到肌肉收缩的反馈,并且截肢后的肌肉结构也与上肢健全的人不同^[10]。从截肢者的残肢中提取运动信息仍然是一项艰巨的任务,但是研究发现,在不同的力水平下,也可以从中提取到信息丰富且可分离的特征^[11]。

Ali等^[12]在包含9名经桡骨截肢者的数据集上,提出了一种新的特征(TD-PSD),当采取所有力度数据去训练分类器时,该特征可以达到接近90%的分类准确率。Islam等^[13]提出了一种在特征提取前进行肌电信号跨通道归一化的方案,在信号归一化的基础上,利用对数函数对特征进行非线性变换,提出的方案在9名经桡骨截肢者的数据集上进行了验证,实验结果表明,跨通道归一化方案和特征的非线性变换能够提高力度变化下的分类准确率。

上述文献的通过减小力度变化对同一动作特征的偏移大小,即减小动作的类内距离来设计力度无关鲁棒特征。但如果原本两类动作特征的类间距离太小,即使力度变化下各自偏移的程度都不大,却依然很可能在特征空间中发生重叠,最终导致动作的误判,所以设计特征时也应增大不同动作的类间距离考虑在内。

共空间模式(common spatial patterns, CSP)是一类可以最大化不同动作类间距离的算法^[14]。算法通过创建一个最优的共空间滤波器,在最大化一类方差的同时最小化另一类方差,从而使两类之间的区别最大化。CSP最早用于脑电二分类任务的特征提取。但是近年来也有研究将其应用于减小干扰因素对EMG-PR的影响中^[15-16],其中用于解决收缩力变化时,只在相同作用力训练和测试的情况下取得了理想的效果。

本文将CSP算法结合差分处理、幂指数归一化、对数归一化,改善了CSP应用于跨力度识别性能不佳的情况,接着根据非相关线性判别分析(uncorrelated linear discriminant analysis, ULDA)能够使用类别的先验信息,将数据投影到分类性能最佳的投影方向这一优势,将数据投影到类间距离最大、类内距离最小的低维空间,在CSP可以最大化类间距离的基础上,同时考虑减小同一动作的类内距离,最终提取到的DCSP特征维数较低,系统运行速度快,在力度变化情况下,鲁棒性更强,并且性能不依赖于分类器。在健全人和上肢截肢者常用手势的识别上都取得了满意的效果,为力度变化下的肌电控制提供了一种方便、可靠的策略。

1 材料与方法

1.1 数据集1介绍

数据集1来自Khushaba等^[8],通过了澳大利亚悉尼科技大学伦理委员会的批准。

数据集主要包含了6类动作:手张开(hand open, HO)、手闭合(hand close, HC)、手腕伸展(wrist extension, WE)、手腕弯曲(wrist flexion, WF)、尺侧偏移(wrist ulnar deviation, WUD)、桡侧偏移(wrist radial deviation, WRD)。每个手势用低、中、高3种力度分别进行,每种力度下的每个手势重复3次,受试者实验中通过查看屏幕上实时显示的肌电信号的幅值来产生对应的力度进行运动。

1.2 数据集2介绍

数据集2取自Ali等^[12]的相关研究,数据集包括9名截肢者的肌电信号数据,通过了当地伦理委员会的批准。

数据集包括了9名截肢者6个动作的肌电信号数据,这6个动作分别是:球形握(spherical grip, SG)、食指

屈(index flexion, IF)、钩握(hook grip, HG)、拇指屈(thumb flexion, TF)、细捏(fine pinch, FP)、三脚架握(tripod grip, TP)。为了让截肢者能够在实验的不同阶段产生对应的力度,9名受试者都经过一段时间熟悉了实验流程,并且在实验过程当中,受试者可以通过查看LABVIEW中实时显示的肌电信号幅值来调整当前的力度大小。数据集记录了每个受试者3种力度下(小、中、大)下6个动作的5~8次实验的肌电数据。

1.3 不同作用力下鲁棒特征提取

实验的过程都在MATLAB 2019上进行。方法主要分训练阶段和测试阶段两个部分。

在训练阶段,首先对肌电信号进行预处理,然后用CSP算法计算空间投影矩阵 \mathbf{W} ,得到投影后的新信号,接着对信号进行差分处理、取方差、归一化,用非相关线性判别分析将特征投影到类内距离最小,类间距离最大的低维空间,同时得到降维矩阵 \mathbf{G} 。最后训练特征和训练标签共同训练分类器。

测试阶段,测试信号同样经过预处理,然后用训练阶段的空间投影矩阵得到新信号,接着同样对信号进行差分处理、取方差、归一化,通过训练阶段的降维矩阵 \mathbf{G} 对数据进行降维。最后将测试特征输入训练阶段得到的分类器,输出分类结果。

1) 预处理

首先对原始肌电数据进行全波整流,根据表面肌电信号的频率范围,采用4阶巴特沃斯带通滤波器对整流后的信号进行20~450 Hz滤波,最后用50 Hz陷波器来消除电力干扰。

2) CSP特征

CSP最早被用在脑电信号二分类中。该方法的原理是:通过空间投影寻找最优的投影方向,在这个投影方向上,第1类信号的方差最大,第2类的方差最小,从而使得两类信号的差别最大。两类CSP算法的实现过程如下:设 X_i 和 X_j 分别是第 i 类和第 j 类的肌电信号,它们的信号维度是 $m \times n$, m 为通道数, n 为每个通道的采样点数。根据CSP的原理,需要找到一个最佳投影矩阵使得在这个方向上第 i 类和第 j 类的差别最大,这个过程可以用一个优化公式所表示:

$$\mathbf{w} = \arg \max_{\mathbf{w}} \frac{\mathbf{w}^T \mathbf{R}_i \mathbf{w}}{\mathbf{w}^T \mathbf{R}_j \mathbf{w}} \quad (1)$$

其中, \mathbf{R}_i 和 \mathbf{R}_j 分别为第 i 类信号和第 j 类信号的平均协方差矩阵,其数学表达式如式(2)所示:

$$\mathbf{R}_i = \frac{\mathbf{X}_i \mathbf{X}_i^T}{n-1} \quad (2)$$

式(1)中的问题可以转换为解决广义特征值的问题形式: $\mathbf{w} \times \mathbf{R}_i = \lambda \times \mathbf{w} \times \mathbf{R}_j$,其中 λ 是对角线包含 \mathbf{R}_i 和 \mathbf{R}_j 降序排序后的特征值的对角矩阵,矩阵 \mathbf{W} 为对应的特征

向量,利用变换矩阵对原始肌电信号 \mathbf{X} 进行空域滤波,如式(3)所示,再取 \mathbf{Z} 中前 l 行和后 l 行的组成特征向量来区分第 i 类和第 j 类。

$$\mathbf{Z} = \mathbf{W} \mathbf{X} \quad (3)$$

最后对投影后的新信号取对数方差特征并且标准化,得到最终的CSP特征如式(4)所示。

$$f_i = \frac{\log(\text{var}(Z_i))}{\sum_{k=1}^{2l} \log(\text{var}(Z_k))}, \quad i = 1, 2, \dots, 2l \quad (4)$$

传统CSP算法仅仅适合二分类的情况,由于一对一的CSP方法将多分类问题转换为两类明确的类别之间的优化问题,能够更好地反映不同类别间的区别^[16],因此本文采用的一对一的方法来提取特征。

3) DCSP特征

CSP特征在力度变化的情况下,即测试数据包含训练数据中没有的力度数据时,训练集计算得到的投影矩阵往往不能使测试集各类动作之间的差别最大化。因此,我们需要对传统的CSP算法进行改进。由于CSP算法将时间序列看作是高斯信号,完全忽略了隐含在时间序列中的时间相关性信息^[17]。因此在CSP算法中加入时间相关性是改进CSP算法的一个方向,如公共空间频率模式,该算法对每个通道信号做一个延时操作加到原始信号中^[18],增强了CSP算法的性能。

本文将差分运算加入到CSP特征的提取过程当中,不仅加入了时间相关性信息,更由于肌电信号是一种非平稳信号,不同力度的影响下,数据的波动变得更加不稳定,差分运算的加入减轻了数据之间的不规则波动,使得曲线更加平稳。

差分共空间模式(differential CSP, DCSP)特征提取的步骤如下:首先原始肌电信号 \mathbf{X} 按照1.3节2)中的步骤得到投影后的新信号 \mathbf{Z}_0 ,求出 \mathbf{Z}_0 的一阶、二阶差分信号并取方差,得到 d_0, d_1, d_2 。如式(5)所示:

$$d_0 = \text{var}(\mathbf{Z}_0) \quad d_1 = \text{var}(\Delta \mathbf{Z}_0) \quad d_2 = \text{var}(\Delta^2 \mathbf{Z}_0) \quad (5)$$

式中: $\Delta \mathbf{Z}_0$ 表示 \mathbf{Z}_0 的一阶差分信号, $\Delta^2 \mathbf{Z}_0$ 表示 \mathbf{Z}_0 的二阶差分信号,由于对信号取差分会降低信号的总能量,因此采用幂变换的方法来对差分信号进行标准化^[12],如式(6)所示:

$$f_0 = \frac{d_0^\lambda}{\lambda} \quad f_1 = \frac{d_1^\lambda}{\lambda} \quad f_2 = \frac{d_2^\lambda}{\lambda} \quad (6)$$

其中, $\lambda = 0.1$,如式(7)、(8)所示,将差分处理后的信号组合在一起,再对特征进行对数变换,得到 \mathbf{C} 。其中的对数变换有以下优势:(1)不会改变数据的性质和相关关系,进行转换后不会改变CSP算法的性质。(2)经过对数变换之后,力度小的数据范围变大,而力度大的数

据范围变小,不同力度的数据之间的差异被减小。已有文献证明对数变换可以提高力度影响下的动作识别率^[13]。

$$f = [f_0 \quad f_1 \quad f_2] \quad (7)$$

$$C = \log(f/\text{sum}(f)) \quad (8)$$

以上步骤完成之后,为了在 CSP 最大化类间距离的基础上,减小同类动作的类内距离并且降低特征维数。本文将非相关线性判别分析(uncorrelated linear discriminant analysis, ULDA)引入特征提取的过程中。ULDA 是一种监督学习的降维算法,是一种增强的 LDA,由于加入减少不相关特征的要求,因此可以最小化冗余。ULDA 通过求取一个线性无关且向量之间相互正交的转换矩阵,将原始数据映射为类内距离最小,类间距离最大的低维空间矩阵,降低了特征维数的同时增强了特征的分度,有利于后续的分类。并且测试阶段可以直接使用训练阶段计算得到的降维矩阵 G ,加快了系统的运行速度。

1.4 特征性能评价

1) 训练集和测试集划分

数据集 1 采用窗口长度为 150 ms 的滑动窗,滑动步长为 75 ms。每组实验中,前两次实验的数据用于生成训练集,第 3 次实验用于生成测试集,和 Khushaba 等^[8]的处理方式相同。数据集 2 采用窗口长度为 150 ms 的滑动窗,滑动步长为 50 ms。由于比上肢健全人更容易产生疲劳,因此每个截肢受试者单次实验活动段时间和每个动作的实验次数都不相同。本文采取和 Ali 等^[12]相同的处理方式:两次实验的数据用于生成训练集,2~5 次实验用于生成测试集。

2) 验证方案设计

肌电信号经过预处理后分别取 CSP 特征和 DCSP 特征,本文将从手势识别正确率和特征空间的分布来比较本文提出的 DCSP 特征和 CSP 特征。

结合其他文献的工作,本文设计了 4 个验证方案比较识别正确率:

方案 A:某一力度的特征训练分类器,同一力度的特征测试。

方案 B:某一力度的特征训练分类器,所有力度的特征测试。

方案 C:所有力度的特征训练分类器,某一力度的特征测试。

方案 D:所有力度的特征训练分类器,所有力度的特征测试。

同时,本文设计了 2 个方案用于比较特征空间分布:方案 E:中等力度的训练数据计算得到投影矩阵,比

较测试集的特征空间分布。

方案 F:所有力度训练数据计算得到投影矩阵,比较测试集的特征空间分布。

此外,为了量化特征空间分布的变化,引入了两个特征空间指标:类内距离(Din)和类间距离($Dout$)。类内距离 Din 用于衡量同一个动作不同力度之间的距离。设有 M 个类别, $\Omega_1, \dots, \Omega_M, \Omega_i$ 类样本集 $\{x_1^{(i)}, x_2^{(i)}, \dots, x_{N_i}^{(i)}\}$, Ω_i 的散度矩阵 $S_w^{(i)}$ 定义为:

$$S_w^{(i)} = \frac{1}{N_i} \sum_{k=1}^{N_i} (X_k^{(i)} - m^{(i)})(X_k^{(i)} - m^{(i)})^T \quad (9)$$

其中, N_i 为 Ω_i 类样本集的数量,接着可以得到所有类的散度矩阵 S_w :

$$S_w = \sum_{i=1}^M P(\Omega_i) S_w^{(i)} \quad (10)$$

其中, $P(\Omega_i)$ 为 Ω_i 类样本数占总样本数的比例。最后可以得到:

$$Din = \text{trace}(S_w) \quad (11)$$

式中: $\text{trace}(\quad)$ 为矩阵的迹。 Din 的值越小,代表同一动作不同力度之间的距离越小。

类间距离 $Dout$ 衡量的是不同动作之间的距离。第 i 类和第 j 类之间的散度矩阵定义为:

$$S_B^{(ij)} = (m^{(i)} - m^{(j)})(m^{(i)} - m^{(j)})^T \quad (12)$$

其中, $m^{(i)}$ 为 Ω_i 的样本均值,接着可以得到总的散度矩阵:

$$S_B = \frac{1}{2} \sum_{i=1}^M P(\Omega_i) \sum_{j=1}^M P(\Omega_j) S_B^{(ij)} \quad (13)$$

最后可以得到: $Dout = \text{trace}(S_B)$ 。 $Dout$ 的值越大,代表不同动作之间的距离越大。

CSP 特征通过主成分分析(principal component analysis, PCA)降维到和 DCSP 特征同样的维数,计算两个特征空间指标,取前两个主要成分生成二维特征空间散点图。

3) 分类器的选择

之前相关的研究工作中,相同的特征在不同分类器下得到的识别正确率相差比较大^[7],本文采用线性判别分析(linear discriminant analysis, LDA)、支持向量机(support vector machine, SVM)、K 近邻(k-nearest neighbor, KNN)、朴素贝叶斯 NB(naive bayes, NB)和决策树(decision tree, TREE)等 5 个分类器,验证所提出特征在不同分类器下手势识别正确率的鲁棒性,分类器训练在 MATLAB 2019 Classification Learner App 中进行。

4) 统计显著性分析

本文采用单因素方差分析检测不同特征的识别正确率在统计上是否有显著性差异,所有的显著性水平均为 0.05。

2 实验结果与分析

2.1 识别正确率的比较

数据集 1 和数据集 2 上的识别正确率如图 1 所示。

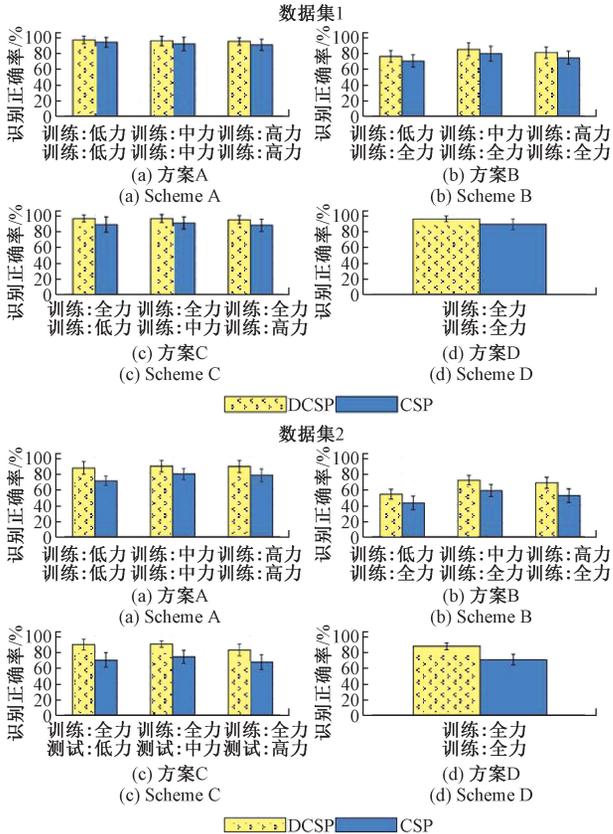


图 1 数据集 1 和数据集 2 识别正确率

Fig. 1 Recognition accuracy rate of Dataset 1 and Dataset 2

在数据集 1 上,方案 A 中,当训练数据和测试数据是同一等级力度时,CSP 特征平均识别率为 93.39%、91.29%、90.20%,DCSP 特征的平均识别率 96.41%、95.26%、94.47%,单因素方差分析显示二者的差异显著 ($p=0.004$)。二者在作用力没有变化的情况下,识别正确率都超过 90%。DCSP 特征的平均识别率相比 CSP 特征,提升了约 3%。方案 B 中,当测试数据包含训练数据没有的力度数据时,两个特征的识别正确率都受到了作用力变化的影响,CSP 特征的平均识别率为 69.73%、79.00%、73.91%,而 DCSP 的平均识别率为 75.65%、84.46%、80.42%。单因素方差分析显示二者的差异显著 ($p=0.0027$)。方案 C 中,CSP 特征的平均识别率为 88.62%、90.64%、87.79%,DCSP 特征的识别率为 96.35%、96.32%、94.80%。单因素方差分析显示二者差异显著 ($p=1.57 \times 10^{-5}$)。方案 D 中,CSP 的平均识别率

为 89.01%,DCSP 的平均识别率为 95.83%,单因素方差分析显示二者的差异显著 ($p=1.51 \times 10^{-5}$)。

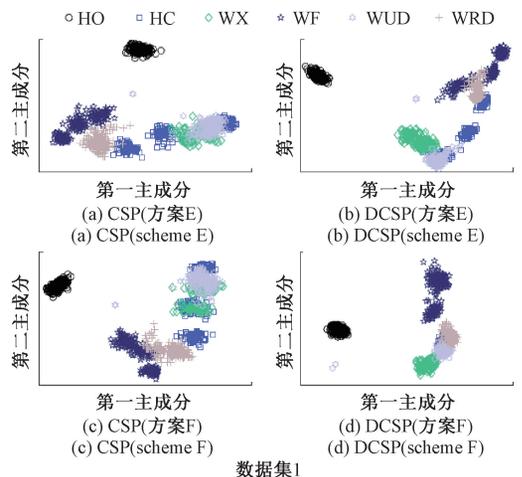
在数据集 2 上,方案 A 中,CSP 的平均识别正确率为 70.64%、79.33%、77.72%,而 DCSP 的平均识别正确率为 86.94%、89.24%、88.76%。单因素方差分析显示二者的差异显著 ($p=9.40 \times 10^{-5}$)。方案 B 中,CSP 的平均识别率分别为 42.74%、58.41%、52.08%,而 DCSP 特征的平均识别率为 53.84%、71.43%、68.13%。单因素方差分析显示二者的差异显著 ($p=0.00042$)。方案 C 中,CSP 的平均识别率为 69.47%、73.57%、67.02%,DCSP 的平均识别正确率为 87.35%、87.64%、80.50%,单因素方差分析显示二者的差异显著 ($p=1.91 \times 10^{-5}$)。方案 D 中,CSP 在 5 个分类器下的平均识别率为 70.03%,而 DCSP 的平均识别正确率为 86.93%,单因素方差分析显示二者差异显著 ($p=1.92 \times 10^{-5}$)。

在数据集 1 和数据集 2 上,DCSP 在设计的 4 个验证方案上的识别正确率均高于 CSP,而方案 C 和方案 D 相比于方案 B 识别正确率有所提升则说明当更多的力度数据参与训练时能够提高识别正确率,但是这种方法给数据采集和系统的训练带来了负担,DCSP 在数据集 2 方案 B 中用中等力度训练的识别率 (71.43%) 高于 CSP 在方案 D 用全部力度训练的识别率 (70.03%),说明了 DCSP 在实际应用当中更加方便有效。

2.2 特征空间的比较

CSP 和 DCSP 在数据集 1 和数据集 2 上的特征空间分布如图 2 所示。数据集 1、数据集 2 计算得到的特征空间指标 D_{out} 、 D_{in} 如表 1、2 所示。

在两个方案的测试上,DCSP 特征都有比 CSP 特征更小的 D_{in} 和更大的 D_{out} 。并且 DCSP 特征在方案 E (中等力度参与训练) 上的 D_{in} 、 D_{out} 就已经优于 CSP 特征在方案 F (全部力度参与训练) 上的指标。



数据集 1

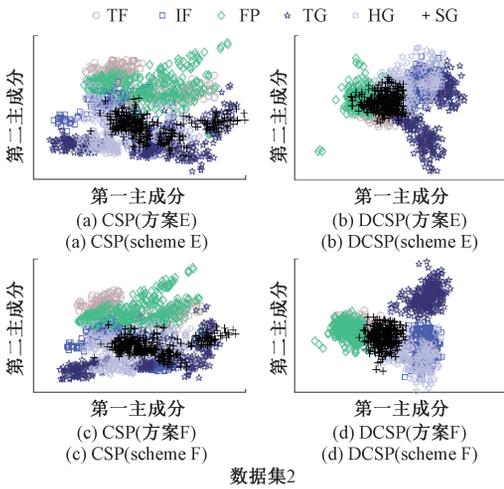


图2 数据集1和数据集2特征分布

Fig. 2 The feature distribution of dataset 1 and dataset 2

表1 数据集1的 *Din* 和 *Dout* 指标

Table 1 *Din* and *Dout* metrics of dataset 1

方案	特征	<i>Din</i>	<i>Dout</i>
方案 E	CSP	2.82	3.19
	DCSP	1.95	4.05
方案 F	CSP	2.80	3.20
	DCSP	1.59	4.42

表2 数据集2的 *Din* 和 *Dout* 指标

Table 2 The *Din* and *Dout* metrics of dataset 2

方案	特征	<i>Din</i>	<i>Dout</i>
方案 E	CSP	4.56	1.45
	DCSP	3.76	2.25
方案 F	CSP	4.24	1.77
	DCSP	2.67	3.33

2.3 与其他研究中的特征比较

将 DCSP 特征与 Khushaba 相关文献^[8]中的 TD-PSD、时域自回归 (time domain auto regressive, TDAR)、时域 (time domain, TD) 特征相比较, 数据集 1 采用和文献中相同的验证方案 (1.4 节 2) 中的方案 B)。数据集 2 也采用和文献中相同的验证方案:

方案 1: 即 1.4 节 2) 中的方案 A。

方案 2: 某一力度的特征训练分类器, 其余力度的特征进行测试。

方案 3: 即 1.4 节 2) 中的方案 C。

实验结果如表 3 所示。平均识别率和显著性情况如图 3 所示。

表3 与其他研究中的识别正确率比较

Table 3 Comparison with features in other research

(a) 数据集 1 正确率

(a) Accuracy of dataset 1

方案/特征	DCSP	TD-PSD	TD	TDAR
小力度训练, 全部力度测试	75.65	71.21	71.43	65.76
中力度训练, 全部力度测试	84.46	78.64	79.11	72.73
大力度训练, 全部力度测试	80.42	73.50	72.16	64.29

(b) 数据集 2 正确率

(b) Accuracy of dataset 2

方案/特征	DCSP	TD-PSD	TD	TDAR
小力度训练, 小力度测试	86.94	79.04	75.47	69.30
中力度训练, 中力度测试	89.24	81.84	81.49	74.15
大力度训练, 大力度测试	88.76	80.63	78.68	72.15
小力度训练, 中、大力度测试	42.23	34.87	33.95	33.30
中力度训练, 小、大力度测试	61.14	51.94	51.44	48.37
大力度训练, 小、中力度测试	55.69	46.12	42.26	41.37
全部力度训练, 小力度测试	87.35	79.09	73.79	68.19
全部力度训练, 中力度测试	87.64	79.85	78.58	70.73
全部力度训练, 大力度测试	80.50	71.38	71.53	64.69

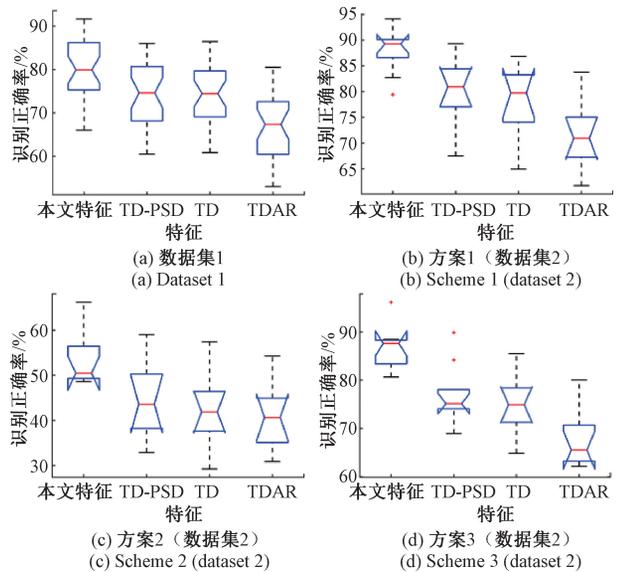


图3 不同特征在不同方案上的显著性差异对比图

Fig. 3 Comparison of significant differences of different features in different schemes

数据集 1 上, DCSP 在 3 个方案上的平均识别正确率 (80.17%) 相比 TD-PSD (74.45%), TD (74.23%), TDAR (67.59%), 提升了 6% 左右。数据集 2 上, DCSP 特征在 3 个方案上的平均识别正确率 (方案 1: 88.31%、

方案 2:53.02%、方案 3:85.16%),相比 TD-PSD(方案 1:80.50%、方案 2:44.31%、方案 3:76.78%),TD(方案 1:78.54%、方案 2:42.55%、方案 3:76.77%),TDAR(方案 1:71.87%、方案 2:41.01%、方案 3:67.87%),提升了约 8%。除此之外,本文的 DCSP 特征相比其他研究中的特征,还有如下优点:1) DCSP 特征的特征维数更少,TD-PSD、TD、TDAR 的特征维数分别是 36、30、36,而 DCSP 特征降维后的维数只有 6,远远小于其他特征的维数。2)其他研究成果中,训练特征和测试特征提取步骤是完全相同的,需要耗费同样的时间,而本文的特征提取过程当中在线阶段的肌电信号只需要乘上离线阶段计算好的空间滤波矩阵再进行下面的步骤,在线阶段的运行速度相比离线阶段要快。

2.4 不同分类器下的识别正确率

选取 TD-PSD、TDAR、TD 和 DCSP 来比较说明力度鲁棒性特征是否依赖于分类器的选择。选择 LDA、SVM、KNN、NB、TREE 等 5 种分类器,数据集 1 验证方案为 B,数据集 2 验证方案为 A。不同特征的平均识别正确率如表 4 所示。

表 4 不同特征在 5 个分类器下的识别正确率

Table 4 The recognition accuracy of different features under 5 classifiers

(a) 数据集 1 正确率

(a) Accuracy of dataset 1 %

分类器	DCSP	TD-PSD	TD	TDAR
LDA	82.28	81.64	78.23	77.63
KNN	80.09	73.53	75.02	54.68
SVM	81.39	78.48	77.63	73.20
NB	81.32	71.66	70.73	65.57
TREE	75.81	66.93	69.55	66.89

(b) 数据集 2 正确率

Accuracy of dataset 2 %

分类器	DCSP	TD-PSD	TD	TDAR
LDA	89.52	90.95	87.12	87.44
KNN	88.53	79.40	77.63	60.42
SVM	88.20	85.97	84.52	81.53
NB	89.80	73.59	72.88	64.45
TREE	84.32	72.61	70.58	65.50

从表 4 中可以看出,相同特征在不同分类器下的识别正确率相差较大。

数据集 1 上,本文 DCSP 特征在不同分类器下的识别正确率高于其他研究中的特征,且所有特征都在 LDA

作为分类器时达到了最高的识别正确率,这是因为 LDA 分类器的基本思想是:对于给定标签的训练集,通过将样本投影到一条直线上,使得同类的样本点尽可能近,异类的样本点尽可能远,这与本文特征提取的思路是相似的。数据集 2 上,当采用 KNN、SVM、NB、TREE 这 4 个分类器时,DCSP 的识别正确率高于其他研究中的特征,而当采用的是 LDA 分类器时,TD-PSD 特征的识别正确率高于本文的特征。TD-PSD 通过使用导数和信号范数在时域提取功率谱,接着用余弦相似函数计算原始信号和原始信号的非线性版本之间的方向来形成一组与力度无关的特征,取得了理想的效果,但是在实际使用时 TD-PSD 计算量大,而 DCSP 特征维数小、计算简单,在准确性和实时性方面更具优势。

3 结 论

为了减小力度对于肌电信号模式识别的影响,本文提出了 DCSP 特征,在 CSP 算法中加入差分信号运算,并通过归一化方法,改善了常规 CSP 算法用于在跨力度情况下识别率低的问题,使得不同动作有较大的类间距离,最后通过 ULDA 降维,不仅减少了特征的维数,还将特征投影到了类内距离最小,类间距离最大的空间,在提高识别正确率的同时减小了运算量。在上肢健全人和上肢截肢者两个数据集上验证了所提特征的性能,实验结果表明:本文 DCSP 特征相比 CSP 特征和其他文献中提出的特征有更高的分类精度,动作分类准确率在不同分类器具有鲁棒性,不依赖分类器的选择。

参考文献

[1] 石欣,范智瑞,张杰毅,等.基于 LMS-随机森林的肌电信号下肢动作快速分类[J].仪器仪表学报,2020,41(6),218-224.
 SHI X, FAN ZH R, ZHANG J Y, et al. Rapid classification of lower limb movements of EMG signals based on LMS-random forest [J]. Chinese Journal of Scientific Instrument, 2020, 41(6): 218-224.
 [2] NG C L, REAZ M B I, CHOWDHURY M E H. A low noise capacitive electromyography monitoring system for remote healthcare applications [J]. IEEE Sensors Journal, 2019, 20(6): 3333-3342.
 [3] IQBAL N V, SUBRAMANIAM K. A review on upper-limb myoelectric prosthetic control [J]. IETE Journal of Research, 2018, 64(6): 740-752.
 [4] 徐瑞,李志才,王雯婕,等.基于肌电的人机交互控制策略及其应用与挑战 [J]. 电子测量与仪器学报, 2020, 32(2): 1-11.
 XU R, LI ZH C, WANG W J, et al. Human-computer

- interaction control strategies based on electromyography and their applications and challenges [J]. *Journal of Electronic Measurement and Instrumentation*, 2020, 34(2): 1-11.
- [5] 李自由, 赵新刚, 张弼, 等. 基于表面肌电的意图识别方法在非理想条件下的研究进展[J]. *自动化学报*, 2021, 47(5): 955-969.
- LI Z Y, ZHAO X G, ZHANG B, et al. Review of sEMG-based motion intent recognition methods in non-ideal conditions [J]. *Acta Automatica Sinica*, 2021, 47(5): 955-969.
- [6] AMERI A, AKHAEI M A, SCHEME E, et al. A deep transfer learning approach to reducing the effect of electrode shift in EMG pattern recognition-based control[J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2019, 28(2): 370-379.
- [7] HE J, ZHANG D, SHENG X, et al. Invariant surface emg feature against varying contraction level for myoelectric control based on muscle coordination [J]. *IEEE Journal of Biomedical & Health Informatics*, 2017, 19(3): 874-882.
- [8] KHUSHABA R N, AL-TIMEMY A, KODAGODA S, et al. Combined influence of forearm orientation and muscular contraction on EMG pattern recognition [J]. *Expert Systems with Applications*, 2016, 61: 154-161.
- [9] LIU Y, TIAN L, ZHENG Y, et al. Toward reducing the effect of force variations on electromyography pattern recognition by Mel-frequency spectrum [C]. 2021 IEEE International Conference on Real-time Computing and Robotics (RCAR). IEEE, 2021: 309-313.
- [10] IQBAL N V, SUBRAMANIAM K. Robust feature sets for contraction level invariant control of upper limb myoelectric prosthesis[J]. *Biomedical Signal Processing and Control*, 2019, 51: 90-96.
- [11] ONAY F, MERT A. Phasor represented EMG feature extraction against varying contraction level of prosthetic control[J]. *Biomedical Signal Processing and Control*, 2020, 59: 101881.
- [12] ALI H A T, KHUSHABA R N, BUGMANN G, et al. Improving the performance against force variation of emg controlled multifunctional upper-limb prostheses for transradial amputees [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2016, 24(6): 650-661.
- [13] ISLAM M J, AHMAD S, HAQUE F, et al. A novel signal normalization approach to improve the force invariant myoelectric pattern recognition of transradial amputees [J]. *IEEE Access*, 2021, 9: 79853-79868.
- [14] KHAN J, BHATTI M H, KHAN U G, et al. Multiclass EEG motor-imagery classification with sub-band common spatial patterns [J]. *EURASIP Journal on Wireless Communications and Networking*, 2019, 2019(1): 1-9.
- [15] PAN L, ZHANG D, JIANG N, et al. Improving robustness against electrode shift of high density EMG for myoelectric control through common spatial patterns [J]. *Journal of Neuroengineering and Rehabilitation*, 2015, 12(1): 1-16.
- [16] LI X, FANG P, TIAN L, et al. Increasing the robustness against force variation in EMG motion classification by common spatial patterns [C]. *Engineering in Medicine & Biology Society, IEEE*, 2017: 406-409.
- [17] HUANG Y, JIN J, XU R, et al. Multi-view optimization of time-frequency common spatial patterns for brain-computer interfaces [J]. *Journal of Neuroscience Methods*, 2022, 365: 109378.
- [18] MIRZAEI S, GHASEMI P. EEG motor imagery classification using dynamic connectivity patterns and convolutional autoencoder [J]. *Biomedical Signal Processing and Control*, 2021, 68: 102584.

作者简介



林恒, 2020 年于桂林电子科技大学获得学士学位, 现为福州大学硕士研究生, 主要研究方向为肌电信号的特征提取与模式识别。
E-mail: lh200120088@163.com

Lin Heng received his B. Sc. degree from Guilin University of Electronic Technology in 2020. He is currently a master student at Fuzhou University. His research interests include pattern recognition and feature extraction of EMG signals.



李玉榕 (通信作者), 1994 年于福州大学获得学士学位, 1997 年于浙江大学获得硕士学位, 2001 年于浙江大学获得博士学位, 现为福州大学电气工程与自动化学院教授, 主要研究方向为非线性随机系统滤波、计算智能理论及其在生物医学中的应用。

E-mail: liyurong@fzu.edu.cn

Li Yurong (Corresponding author) received her B. Sc. degree from Fuzhou University in 1994, and received her M. Sc. degree and Ph. D. degree both from Zhejiang University in 1997 and 2001, respectively. She is currently a professor in the College of Electrical Engineering and Automation at Fuzhou University. Her main research interests include nonlinear stochastic system filtering, computational intelligence theory and its application in biomedicine.