

DOI: 10.19650/j.cnki.cjsi.J2107826

# 基于特定任务肌肉协同的用户无关肌电手势识别研究\*

郑楠<sup>1,2</sup>, 李玉榕<sup>1,2</sup>, 张文萱<sup>1,2</sup>, 李吉祥<sup>1,2</sup>

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

**摘要:**表面肌电信号可以反映用户的动作意图,因而成为人机交互的主要控制信号。然而,个体差异性使得用户模型不通用,不利于发展普适性的肌电设备。本文从神经协同控制角度出发,通过非负矩阵分解算法提取肌肉协同,并利用少量新用户预实验数据和最小二乘法,得到与预实验协同相近的新协同作为特征量。为了在低频可穿戴场景的应用考虑,分别在支持向量机、误差反向传播网络、K近邻算法这3个简单易移植的分类器上训练与测试。在Ninapro数据库的DB1(100 Hz)和DB5(200 Hz)中分别开展了4组手势识别实验,平均识别正确率分别为81.12%、78.19%、74.07%、60.11% (DB1)和85.75%、83.25%、79.07%、66.10% (DB5),比现有的低频可在线识别算法高了10%以上。本文算法简单方便,利用现有用户数据和少量新用户预实验数据即可训练分类器,并且从神经协调角度去判断意图,更有利于发展符合人体自然运动的控制方式,为可穿戴肌电设备的普及提供了可行的方案。

**关键词:**用户无关;肌肉协同;可穿戴设备;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

## User-independent EMG gesture recognition based on task-specific muscle synergy

Zheng Nan<sup>1,2</sup>, Li Yurong<sup>1,2</sup>, Zhang Wenxuan<sup>1,2</sup>, Li Jixiang<sup>1,2</sup>

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

**Abstract:** The surface electromyography signal can reflect the user's action intention. Therefore, it becomes the main control signal for human-computer interaction. However, the individual variability makes the user model universally un-applicable, which is not conducive to the development of the universal EMG equipment. In this paper, from the perspective of neural synergy control, muscle synergy is extracted by the non-negative matrix factorization algorithm. Then, the pre-experimental data of new user are combined with least squares to obtain training synergy as a feature quantity, which is similar to pre-experimental synergy. For application consideration in low-frequency wearable scenarios, three simple and easily portable classifiers (i. e., support vector machine, error back propagation network, and K-nearest neighbor algorithm) are trained and tested, respectively. Four sets of gesture recognition experiments are implemented in DB1 (100 Hz) and DB5 (200 Hz) of the Ninapro database. The average recognition accuracy rates are 81.12%, 78.19%, 74.07%, 60.11% (DB1) and 85.75%, 83.25%, 79.07%, 66.10% (DB5), which are higher than the existing low-frequency online recognition algorithms by more than 10%. The proposed algorithm is simple and easy to train the classifier using existing user data and a small amount of pre-experimental data from new users. Meanwhile, the action intention can be judged from the perspective of neural coordination, which is more conducive to the development of a control method that conforms to the natural movement of the human body. It provides a feasible solution for the popularization of wearable electromyography equipment.

**Keywords:** use-independent; muscle synergy; wearable devices; gesture recognition

收稿日期:2021-04-25 Received Date: 2021-04-25

\* 基金项目:国家自然科学基金(61773124)、福建省自然科学基金(2019J01544)项目资助

## 0 引言

表面肌电信号 (surface electromyogram, sEMG) 是一种能反映肌肉兴奋程度的电信号<sup>[1]</sup>, 与动作直接相关, 因此对肌电信号的模式识别有助于实现人机交互控制。在日常生活中, 交互设备需要具备简便性和非侵入性两个特性, 常见的肌电交互设备有手表、臂章等<sup>[2]</sup>。由于信号处理、数据传输和消耗等因素的限制, 高采样频率的肌电信号并不适用于穿戴式肌电交互设备, 因此现有的穿戴式肌电交互设备基本都是根据低采样频率设计<sup>[3]</sup>。低频穿戴式肌电交互设备在假肢控制、基于游戏的肌电假体训练、运动功能康复训练系统等方面有着重要的应用。但 Phinyomark 等<sup>[3]</sup>和 Li 等<sup>[4]</sup>的研究发现, 采样频率降低会严重影响识别正确率。因此提高低采样频率信号的识别正确率成为研究的热点。Tavakoli 等<sup>[5]</sup>利用高维空间特征和支持向量机 (support vector machines, SVM) 对五个手势进行分类, 最终结果可达 95% ~ 100%; Jiang 等<sup>[6]</sup>结合 EMG 和 FMG 对美国手语数字进行手势识别, 识别准确率为 91.6%。

可见, 合适的特征可以提高识别正确率。目前, 常用的特征包括时域特征、频域特征和时-频特征<sup>[7-9]</sup>。但上述特征容易受肌肉疲劳和电极移位等因素的影响, 导致识别的结果鲁棒性差<sup>[10-11]</sup>。因此, 新的研究期望从神经控制运动的原理中找到一种鲁棒性强的特征。

神经控制运动的假说认为, 肌肉协同 (muscle synergy) 是中枢神经系统控制肌肉骨骼系统完成各种动作的最小受控单位, 即使在不同因素影响下也能具有很好的鲁棒性<sup>[12]</sup>。Luo 等<sup>[13]</sup>利用肌肉协同方法, 在 5 个手势的识别准确率达到 96%; Zhang 等<sup>[14]</sup>设计了一种基于肌肉协同的多自由度并联控制框架, 在 18 个手指运动中得到  $96.79\% \pm 2.46\%$  的识别精度; Masoumidoost 等<sup>[15]</sup>提取了 6 个手腕动作的肌肉协同, 在多层感知器 (multilayer perceptron, MLP) 中获得了  $99.78 \pm 0.45\%$  的识别精度; Naik 等<sup>[16]</sup>提出一种非负矩阵分解与人工神经网络结合的方法, 该算法对 10 个手指屈曲动作的准确率高达 92%。

研究表明, 基于肌肉协同的模式识别方法在识别正确率的表现令人满意。然而, 上述的模型都是用户相关模型, 即模型的训练数据和测试数据均来自同一用户。由于受试者之间的解剖结构差异, 如肌肉厚度、神经控制区域等, 用户相关模型应用于新用户的识别问题上表现不佳, 这一缺点不利于开发普适性的肌电交互设备。

为了弥补用户相关模型的缺陷, 学者们提出了两种类型的用户无关方案: 一种是利用少量数据更新通用模型。Matsubara 等<sup>[17]</sup>基于用户因子和动作因子构建双线

性模型, 针对新用户时需要全部动作的一次实验数据更新模型, 此方法显示了不同用户 5 种手势动作的分类准确性大约为 73%; Khushaba 等<sup>[18]</sup>提出了使用规范相关分析 (canonical correlation analysis, CCA) 的相关模型。该方法需要预先确定一个专家矩阵, 利用 CCA 算法将多个用户的数据映射到专家矩阵的空间中。然后, 寻找少量新用户数据和专家矩阵之间的矩阵, 改造新用户数据即可, 该方法针对 10 类手势动作的准确性约为 83%; Kim 等<sup>[19]</sup>提出了一种基于肌肉源激活模型的自主手势识别方法, 该方法需要利结合少量的新用户数据才能完成模型的训练, 对于 4 种腕/手运动, 最佳的识别准确率为 78.3%; Ketykó 等<sup>[20]</sup>提出了一种结合两阶段域适应和深度学习的方法 (2SRNN), 该方法对输入特征进行线性变换, 在 12 个手指动作中取得了 65.7% 的识别正确率。另一种是利用深度学习模型进行特征表征和特征学习。Wei 等<sup>[21]</sup>提出了一种新的多视图卷积神经网络框架, 利用该方法在 NinaPro 数据集中取得 82% 的识别正确率; Chen 等<sup>[22]</sup>提出了一种基于卷积神经网络的特征提取方法 (a convolutional neural network based feature extraction approach, CNNFeat), 并与传统特征比较, 实验结果表明, CNNFeat 的表现优于所有被测试的传统特征。深度学习模型在学习肌电信号内部特征的方面具有潜在优势, 但是模型相对复杂, 硬件要求高, 且需要大量的数据进行模型训练, 现阶段还不适用于可穿戴设备的开发; 利用少量数据更新模型的方法, 模型简单易理解, 更新代价小, 更适用于穿戴式设备。

为了更好的将用户无关的研究成果更好的应用于后续的肌电控制, 还需考虑以下几点: 1) 不同的手势任务是由不同激活水平的肌肉协调完成的, 手势任务与协同之间呈现相关性, 常用的特征向量组合方法没有考虑到这一因素。2) 可穿戴设备通常需要少量的数据处理, 而现有方法的结果都需要依靠大量的训练样本。3) 大部分用户无关算法都只考虑较少类型的手势识别研究, 在面对生活中的多种任务时, 很难实现灵巧的控制。

针对上述分析, 本文将特定任务协同和最小二乘法结合, 通过最小二乘法得到现有用户数据向着预实验数据近似的转换矩阵, 利用转换矩阵改造训练数据, 提高了用户无关手势识别正确率的同时减少了训练数据的数据量, 针对手指、手腕、抓握等日常动作均取得较为满意的效果, 为后续的肌电控制提供了简单可行的方案。

## 1 材料与方法

### 1.1 EMG 数据集

NinaPro Database 是认可度较高的肌电标准数据集, 其采集的肌肉包括手指的伸肌和屈肌, 主要分布在前臂

肘关节下方。本次实验用到的数据来自 NinaPro Database<sup>[23]</sup> 的两个低频子数据库 DB1 和 DB5,数据库的具体信息如表 1 所示。

表 1 数据库信息  
Table 1 Database information

	DB1	DB5
采样频率/Hz	100	200
通道	10	16
人数	27	10
重复次数	10	6
动作	12 个手指屈伸动作 17 个手腕、手屈伸动作 23 个抓握动作	

考虑了日常生活中的常用动作类型后,本文选取 3 个抓握动作、5 个手/手腕动作和 12 个手指动作。为了和其他文献的研究结果进行对比,将上述手势动作分为 4 组,具体的手势分组情况如图 1、2、3、4 所示。



图 1 3 个抓握动作(第①组)  
Fig. 1 Three grasp motion (group ①)



图 2 4 个手/手腕动作(第②组)  
Fig. 2 Four wrist motion (group ②)




图 3 5 个手/手腕动作(第③组)  
Fig. 3 Five wrist motion (group ③)




图 4 12 个手指动作(第④组)  
Fig. 4 Twelve finger motion (group ④)

### 1.2 预处理与活动段检测

信号要先进行全波整流,再经过 3 阶巴特沃夫低通滤波得到包络线。其中,100 Hz 的肌电信号,截止频率取为 3 Hz; 200 Hz 的肌电信号,截止频率取为 0.1 Hz。

数据预处理后便进行活动段的提取,其目的是找到每个动作的起始点和终止点。考虑到算法实际的处理效果以及面向可穿戴设备的计算效能,本文主要采用移动平均法处理 sEMG 信号序列的瞬时能量,再结合阈值提取活动段<sup>[24]</sup>。首先计算各通道的平均序列  $S(t)$ ,  $S(t)$  的平方值即为瞬时能量序列  $E(t)$ ; 然后,对  $E(t)$  进行窗长为 128 个采样点,步长为 1 个采样点的滑窗处理,求窗内数据的平均值,重新组合成新的序列  $Em(t)$ 。最后,取阈值为瞬时能量峰值的 0.008 5 倍,当  $Em(t)$  某一点大于阈值且以后的 128 个点都大于阈值时,该点被确定为起始点;同样的,当  $Em(t)$  某一点小于阈值且以后的 128 个点都小于阈值时,该点确定为终止点。考虑信号噪声的原因,将起始点到终止点之间距离少于 200 个点的信号段舍弃。

### 1.3 基于肌肉协同的用户无关手势识别方法

本文整体的实验流程如图 5 所示。由于肌肉协同的结构分布在任务间具有差异性,因此在训练阶段,利用非负矩阵分解(non-negative matrix factorization, NMF)提取现有用户不同手势任务的协同充当训练协同。然后,提取预实验数据的肌肉协同作为目标协同。利用最小二乘法得到使两个协同距离最小的转换矩阵。将训练协同通过转换矩阵进行空间坐标变换后,得到最后的拟合协同,送进分类器中进行训练。

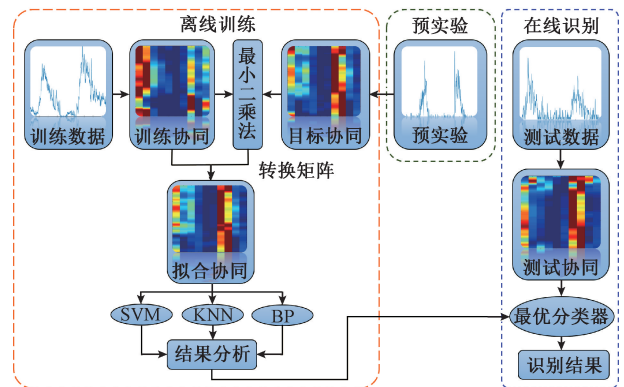


图 5 用户无关手势识别流程

Fig. 5 User-independent gesture recognition process

测试阶段,新用户数据进行同样的数据处理过程并提取协同后,即可送进训练好的网络进行分类测试。

#### 1) 肌肉协同的提取方法

人体多自由度的控制机制给实际的控制带来了困难,为了解决该问题,学者提出了肌肉协同假设(muscle

synergy hypothesis)。按照该理论的阐述,肌肉协同是定义为控制一组肌肉相对激活程度的向量,而绝对激活程度则是由下行的神经信号控制<sup>[25]</sup>。对于一个动作的肌电信号,可以抽象为两个矩阵的乘积,如式(1)所示:

$$\mathbf{V}(m \times n) = \mathbf{W}(m \times r) \times \mathbf{H}(r \times n) \quad (1)$$

其中, $\mathbf{V}$ 为样本集矩阵; $\mathbf{W}$ 为肌肉协同矩阵; $\mathbf{H}$ 为激活稀疏矩阵; $m$ 为肌肉数目; $n$ 为采样点数; $r$ 为肌肉协同数目。由于NMF的部分表示整体、以模式基之间的叠加来表征对象的思想<sup>[26]</sup>与肌肉协同框架十分契合,因此NMF是应用最为普遍的肌肉协同提取算法。为了解决式(1)的矩阵分解问题,本文采用基于欧氏距离的优化函数:

$$\min \text{De}(\mathbf{V} \parallel \mathbf{WH}) = \frac{1}{2} \|\mathbf{V} - \mathbf{WH}\|_2^2 \quad (2)$$

将上式分别对 $\mathbf{W}$ 和 $\mathbf{H}$ 求导,并结合梯度下降法,有

$$\mathbf{W}(ik) = \mathbf{W}(ik) + \mu[(\mathbf{V} - \mathbf{WH})\mathbf{H}^T](ik) \quad (3)$$

$$\mathbf{H}(kj) = \mathbf{H}(kj) + \varphi[\mathbf{W}^T(\mathbf{V} - \mathbf{WH})](kj) \quad (4)$$

设置 $\mu, \varphi$ 使得算法变成乘法算法,令:

$$\mu(ik) = \frac{\mathbf{W}(ik)}{[\mathbf{WHH}^T](ik)} \quad (5)$$

$$\varphi(kj) = \frac{\mathbf{H}(kj)}{[\mathbf{W}^T\mathbf{WH}](kj)} \quad (6)$$

最后,有:

$$\mathbf{W}(ik) = \mathbf{W}(ik) \frac{[\mathbf{VH}^T](ik)}{[\mathbf{WHH}^T](ik)} \quad (7)$$

$$\mathbf{H}(kj) = \mathbf{H}(kj) \frac{[\mathbf{W}^T\mathbf{V}](kj)}{[\mathbf{W}^T\mathbf{WH}](kj)} \quad (8)$$

其中, $i=1,2,3,\dots,m;k=1,2,3,\dots,r;j=1,2,3,\dots,n$ ; $m, r$ 和 $n$ 的定义与上述一致。

可穿戴交互设备的相关研究显示,窗口长度在150~300 ms之间,用户才不会有明显的延迟感<sup>[27]</sup>。因此,本实验选择窗口长度为200 ms的滑动窗,滑动步长为25 ms,利用式(7)和(8),可以提取不同用户的肌肉协同,表示为 $\mathbf{W}_p^{sl}$ ,其中, $s=1,2,3,\dots,N;l=1,2,3,\dots,L$ ; $p=1,2,3,\dots,M$ ;N表示用户数量,L表示手势数量,M表示动作重复次数。

## 2) 基于最小二乘法的空间转换法

本文主要是利用最小二乘法进行数据拟合,其本质是寻找一组 $\mathbf{w}$ ,使得 $\mathbf{xw}$ 与 $\mathbf{y}$ 的距离最近,2范数形式为:

$$\min_{\mathbf{x} \in R^n} \|\mathbf{xw} - \mathbf{y}\|_2 \quad (9)$$

其中, $\mathbf{y}$ 为目标矩阵; $\mathbf{x}$ 为初始矩阵; $\mathbf{w}$ 为转换矩阵,为了方便计算,将求解目标改为:

$$J = \min_{\mathbf{x} \in R^n} \|\mathbf{xw} - \mathbf{y}\|_2^2 \quad (10)$$

将上式展开并对 $\mathbf{w}$ 求导,有:

$$\frac{\partial J}{\partial \mathbf{w}} = 2\mathbf{x}^T(\mathbf{xw} - \mathbf{y}) \quad (11)$$

令式(11)等于零,得到:

$$\mathbf{w} = (\mathbf{x}^T\mathbf{x})^{-1}\mathbf{x}^T\mathbf{y} \quad (12)$$

通过矩阵 $\mathbf{w}$ 可以实现矩阵 $\mathbf{x}$ 对矩阵 $\mathbf{y}$ 的拟合。

设用户1为新用户,用户2为现有用户,肌肉协同的转换过程如图6所示。现有用户的特定肌肉协同 $\mathbf{W}_1^{21}$ 和预实验相同动作的肌肉协同 $\mathbf{W}_1^{11}$ 在A空间( $ij$ 坐标系)中分布有较大差异;令 $\mathbf{W}_1^{11}$ 为 $\mathbf{y}$ , $\mathbf{W}_1^{21}$ 为 $\mathbf{x}$ ,代入式(12)后,可以得到 $\mathbf{W}_1^{21}$ 对 $\mathbf{W}_1^{11}$ 的转换矩阵;转换矩阵 $\mathbf{w}$ 相当于提供了一个B空间( $i'j'$ 坐标系),将 $\mathbf{W}_1^{21}$ 在B空间上进行旋转、伸缩处理后,重新置于A空间中,此时处理后的协同 $\mathbf{W}_1^{21}$ 与预实验的协同 $\mathbf{W}_1^{11}$ 具有相似性,因此能反映新用户该动作肌肉的协作模式。剩余的其它组的特定肌肉协同也按照类似的方式进行空间的转换。




图6 空间转换示意图

Fig. 6 Schematic diagram of space transformation

## 1.4 分类器的选择与结构

鉴于误差反向传播网络(back propagation, BP)、支持向量机和K近邻算法(k-nearest neighbor, KNN)具有计算简单、易于实现的优点,符合穿戴设备的要求,本文选择这三个常用的分类器<sup>[28]</sup>来验证算法的有效性和对分类器的独立性。

本研究中,所有分类任务的结构参数如下:SVM分类器选择径向基函数作为核函数;BP网络选择3层网络结构,隐含层的神经元个数为40,学习率为0.1,迭代次数为200,允许误差为 $4 \times 10^{-7}$ ;KNN的最近距离点数为3。

## 1.5 数据交叉验证方式

不同用户甚至同一个用户执行相同动作时,肌电信号会存在一定程度的差异,为了客观评估结果,本文采用两重交叉验证方式评估算法性能:

1) 第一重:每次选取1名用户数据充当训练数据,对剩余用户(新用户)进行测试。这个过程重复N次(N为用户数),直到每个用户都被作为一次训练数据,且被测

试  $N-1$  次;

2)第二重:在上述循环中,每次选取新用户的 1 组重复作为预实验数据,对剩余重复进行测试。这个过程重复  $M$  次( $M$  为动作的重复组数),直到每组重复都被作为一次预实验。

### 1.6 评 估

使用分类正确率评价算法在 4 组手势的分类表现,即分类正确的样本数除以样本总数。

本文采用的数据处理和分类方法在 MATLAB R2018a 平台上实现,并采用单因素变量分析方法分析实验结果, $P$  值小于 0.05 表现出显著性。

## 2 实验结果与分析

### 2.1 表面肌电信号包络线与活动段划分

以 DB5 的手腕弯曲动作为例,根据 1.2 小节的方法,将包络线和活动段划分的结果表述在图 7。可见处理后的信号更有利于后续的分类。


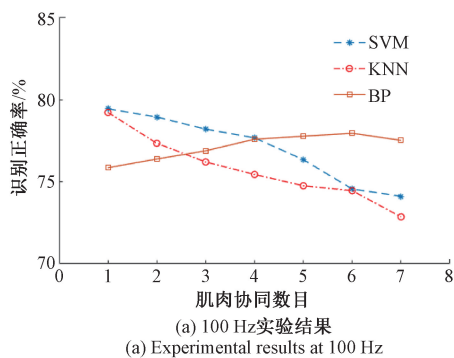


图 7 包络线和活动段划分图

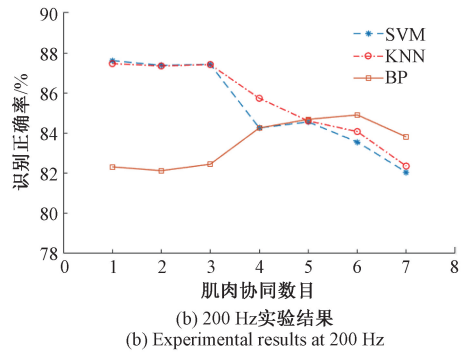
Fig. 7 Envelope diagram and activity segment division

### 2.2 肌肉协同数目对识别正确率的影响

肌肉协同的数目通常由方差占比率 (variance account for, VAF) 来确定,但有实验表明 VAF 与分类任务表现并非正相关<sup>[29]</sup>。因此,本文根据识别正确率确定协同数目。10 名用户在 100 Hz 和 200 Hz 的情况下,平均识别正确率随肌肉协同数目的变化曲线如图 8 所示。



(a) 100 Hz 实验结果  
(a) Experimental results at 100 Hz



(b) 200 Hz 实验结果  
(b) Experimental results at 200 Hz

图 8 平均识别正确率和协同数目的关系图

Fig. 8 Relationship between average recognition accuracy and number of synergy

从图 8 可以看出,SVM 和 KNN 的平均识别正确率在协同数目为 1 时达到最大,BP 网络在协同数目为 6 时达到最大值,但比协同数目为 1 时仅仅提高了 2%,而计算量却多了 6 倍,因此三种分类器的协同数目均取 1。

### 2.3 预实验数目对识别正确率的影响

以 DB5 的 3 个抓握动作为例(第①组),预实验数目和识别正确率的关系如图 9 所示。




图 9 平均识别正确率和预实验数目关系图

Fig. 9 Relation between average recognition accuracy and the number of pre-experimental groups

用户无关的手势识别算法的目的是在提高用户体验的前提下保持高识别率,预实验数目为 1 时,用户能拥有较好的体验感,且能保证识别正确率。

### 2.4 手势识别结果

综合以上的参数分析,4 组实验的识别正确率如表 2 所示。

从表 2 看,DB5 的识别正确率明显高于 DB1,表明了采样频率的降低会在一定程度影响识别正确率。

#### 1)与基准算法的对比

为了验证本文提出的用户无关手势识别方法的有效性,我们设置了 1 个基于预实验的用户无关基准对

比方案(方案 A);为了验证我们算法的性能以及肌肉协同的优势,设置了 2 个用户相关的基准对比方案

表2 4组实验结果(均值±标准差)

Table 2 Results of 4 groups of experiments (MEAN ± STD)

%

数据库组别(采样频率/Hz)	SVM	KNN	BP	mean
DB1-①(100)	80.75±8.20	<b>81.71±7.47</b>	80.90±6.99	81.12±7.55
DB1-②(100)	<b>79.45±6.27</b>	79.23±6.39	75.86±6.29	78.18±6.31
DB1-③(100)	<b>75.59±6.30</b>	75.22±6.35	71.42±6.45	74.08±6.36
DB1-④(100)	61.42±6.01	61.41±5.78	57.51±5.85	60.11±5.88
DB5-①(200)	<b>87.21±6.02</b>	87.07±6.12	82.98±6.90	85.75±6.34
DB5-②(200)	83.80±4.25	<b>85.88±3.88</b>	80.06±3.80	83.25±3.97
DB5-③(200)	79.78±6.20	<b>81.61±5.87</b>	75.83±5.83	79.07±5.96
DB5-④(200)	68.65±6.86	<b>68.81±6.13</b>	60.85±5.81	66.10±6.27

(方案B和C)。以DB5为例,具体的基准方案如下:

方案A(用户无关):选择1名用户作为现有用户,剩余用户轮流充当新用户。提取现有用户的肌肉协同和新用户预实验数据的肌肉协同充当训练数据,用来训练BP、SVM和KNN;将新用户舍去预实验后的剩余数据充当测试数据。

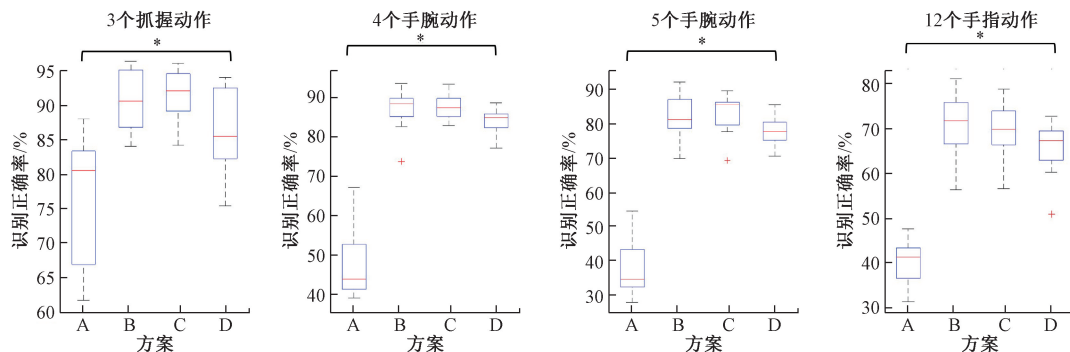
方案B(用户相关):针对每个用户,对信号的每个通道提取3个常用的时域特征:平均绝对值(mean absolute value, MAV),方差(variance, VAR),均方根(root mean square, RMS)作为特征向量,向量的维数为 $16 \times 3$ ;每名

用户全部特征向量的70%充当训练数据;剩余的30%进行分类测试。

方案C(用户相关):针对每个用户,提取肌肉协同作为特征量,将每名用户全部协同的70%训练模型;剩余的30%进行分类测试。该方案与方案B的区别在于特征不同,其余均一致。

方案D为本文所提算法,该方案与方案A的区别在于使用了空间坐标转换。

将上述各方案应用于本文的4组实验中,识别正确率和显著性情况如图10所示。

图10 在4组手势动作时不同方案的显著性差异对比图(\*:  $P < 0.05$ )Fig. 10 Comparison of significant differences among different schemes (\*:  $P < 0.05$ )

分析图10,可知:

(1)方案B与方案C无显著性差异( $P = 0.70$ ,  $P = 0.81$ ,  $P = 0.95$ ,  $P = 0.55$ ),但是方案C的平均识别正确率(91.60%, 87.70%, 83.29%, 70.7%)高于方案B(90.82%, 86.01%, 82.17%, 70.48%),且方案C的标准差(3.77, 3.41, 6.72, 6.33)低于方案B(4.76, 5.42, 7.63, 7.16);上述分析说明肌肉协同作为特征量的表现要好于常用的时域特征的组合,且维数比组合时域特征要低。

(2)本文所提算法与方案A有显著性差异( $P =$

$0.03$ ,  $P = 5.06 \times 10^{-9}$ ,  $P = 9.47 \times 10^{-10}$ ,  $P = 1.53 \times 10^{-7}$ ),说明本文基于预实验数据,将肌肉协同和最小二乘法结合的方案用于用户无关的手势识别是有效的。

(3)本文所提算法与方案B( $P = 0.093$ ,  $P = 0.202$ ,  $P = 0.158$ ,  $P = 0.124$ )和方案C( $P = 0.094$ ,  $P = 0.052$ ,  $P = 0.127$ ,  $P = 0.21$ )相比,并无显著性差异,说明本文的用户无关的算法所起到的效果和用户相关的效果相当。

上述对比结果说明了本文算法的有效性。

2)与其他研究结果的对比

目前,与本文实验相同数量和相同类型的手势动

作的用户无关研究也有很多,大多数方案都采用域适应和深度神经网络相结合的方法,也有部分采用传统机器学习方法。其中,部分文献的信号采样频率虽然

与本文不同,但基本都是参考 Ninapro 数据库的采集协议,因此比较结果有意义。相似研究的文献结果展示在表3。

表3 与其他研究结果的对比

Table 3 Comparison of results with other researches

组别	数据来源	方法	采样频率/Hz	识别正确率/%
第①组	DB1	Atzori <sup>[30]</sup>	100	48.52±10.03
	DB1	本文的方法	100	<b>81.12±7.55</b>
	DB5		200	<b>85.75±6.34</b>
第②组	文献[31]采集	成娟 <sup>[31]</sup>	1 000	<b>88.44±8.45</b>
	文献[19]采集	Kim <sup>[19]</sup>	200	61.32±13.34
	DB1	本文的方法	100	78.18±6.31
	DB5		200	83.25±3.97
第③组	文献[22]采集	Chen <sup>[22]</sup>	1 000	68.23±4.81
	DB1	本文的方法	100	74.08±6.36
	DB5		200	<b>79.07±5.96</b>
第④组	DB1	Atzori <sup>[30]</sup>	100	20.78±2.36
	文献[32]采集	Du <sup>[32]</sup>	1 000	35.10
	DB1	Patricia <sup>[33]</sup>	100	25.00
	DB1	Atzori <sup>[34]</sup>	100	55.00
	DB1	Ketykó <sup>[20]</sup>	100	65.45
	DB1	本文的方法	100	60.11±5.88
	DB5	本文的方法	200	<b>66.10±6.27</b>

从表3可知,本文的方法在第①组和第③组的手势识别正确率上高于以往的研究,而在第②组和第④组的手势识别正确率上,存在有文献的效果优于本文结果。在第②组的实验中,本文的识别结果低于文献[31],考虑原因是文献采用的采样频率比本文高800 Hz,以及训练的数据量比本文多9倍。在先前的研究文献[3]和文献[4],以及对表2的分析均显示了采样频率的降低会影响识别正确率;在第④组的实验中,对于100 Hz的12个手指动作,本文的识别正确率低于文献[20]中的结果,该文献采用了域适应和RNN网络结合的方法,所需要的训练数据量是我们的26倍,需要花费更多的数据获取成本;采用的窗口长度是400 ms,比我们的窗口长了200 ms,影响肌电控制系统的实时性;需要5次重复动作进行域适应,降低了用户的使用体验。本文研究的重点在于寻找适用于在线实时识别的低频穿戴式肌电设备的手势识别算法,因此在满足实时性和低采样频率的条件下,本文的方法具有优势。

### 3 结 论

为了解决不同用户的肌电差异性问题,并将算法应用于实际的低频可穿戴设备上,本文提出一种结合肌肉协同和最小二乘法的用户无关手势识别方法。通过最小二乘法得到空间转换矩阵,减少训练数据的同时提高用户无关手势识别的正确率;并选择生活中常用的手指、手腕、抓握等多个类型的动作作为研究手势,有利于在实际应用中实现更为灵巧的控制。本文方法算法简单,计算量小,实际应用时只需要新用户做少量的调整即可进行手势识别,且从神经协作的角度判别动作意图,有利于后续的控制更贴近人体的自然运动,是普适性的可穿戴肌电设备的有效方案。

未来可以引进新数据处理方案,消除用户自身由于电极偏移等原因导致的数据差异,或是引入新的特征提取方法,提取更加有利于用户无关分类的特征,都会使识别效果进一步提升。

## 参考文献

- [ 1 ] 陈思佳,罗志增. 基于长短时记忆和卷积神经网络的手势肌电识别研究[J]. 仪器仪表学报, 2021, 42(2): 162-170.  
CHEN S J, LUO ZH Z. Research on gesture EMG recognition based on long short-term memory and convolutional neural network [J]. Chinese Journal of Scientific Instrument, 2021, 42(2): 162-170.
- [ 2 ] YANG G, PANG G, PANG Z, et al. Non-invasive flexible and stretchable wearable sensors with nano-based enhancement for chronic disease care[J]. IEEE Reviews in Biomedical Engineering, 2018, 12: 34-71.
- [ 3 ] PHINYOMARK A, KHUSHAB R, SCHEME E. Feature extraction and selection for myoelectric control based on wearable EMG sensors [J]. Sensors, 2018, 18(5): 1615.
- [ 4 ] LI G, LI Y, YU L, et al. Conditioning and sampling issues of EMG signals in motion recognition of multifunctional myoelectric prostheses [J]. Annals of Biomedical Engineering, 2011, 39(6): 1779-1787.
- [ 5 ] TAVAKOLI M, BENUSSI C, LOPES P A, et al. Robust hand gesture recognition with a double channel surface EMG wearable armband and SVM classifier [J]. Biomedical Signal Processing and Control, 2018, 46: 121-130.
- [ 6 ] JIANG S, GAO Q, LIU H, et al. A novel, co-located EMG-FMG-sensing wearable armband for hand gesture recognition [J]. Sensors and Actuators A: Physical, 2020, 301: 111738.
- [ 7 ] PHINYOMARK A, CAMPBELL E, SCHEME E. Surface electromyography (EMG) signal processing, classification, and practical considerations [M]. Biomedical Signal Processing. Springer, Singapore, 2020: 3-29.
- [ 8 ] 丁其川,熊安斌,赵新刚,等. 基于表面肌电的运动意图识别方法研究及应用综述[J]. 自动化学报, 2016, 42(1): 13-25.  
DING Q CH, XIONG AN B, ZHAO X G, et al. A review on researches and application of sEMG-based motion intent recognition methods [J]. Acta Automatica Sinica, 2016, 42(1): 13-25.
- [ 9 ] TOO J, ABDULLAH A R, ZAWAWI T N S T, et al. Classification of emg signal based on time domain and frequency domain features [J]. International Journal of Human and Technology Interaction (IJHaTI), 2017, 1(1): 25-30.
- [ 10 ] YOUNG A J, HARGROVE L J, KUIKEN T A. The effects of electrode size and orientation on the sensitivity of myoelectric pattern recognition systems to electrode shift [J]. IEEE Transactions on Biomedical Engineering, 2011, 58(9): 2537-2544.
- [ 11 ] TURLAPATY A C, GOKARAJU B. Feature analysis for classification of physical actions using surface EMG data [J]. IEEE Sensors Journal, 2019, 19(24): 12196-12204.
- [ 12 ] GHISLIERI M, AGOSTINI V, KNAFLITZ M. Muscle synergies extracted using principal activations: Improvement of robustness and interpretability [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2020, 28(2): 453-460.
- [ 13 ] LUO X, WU X, CHEN L, et al. Synergistic myoelectrical activities of forearm muscles improving robust recognition of multi-fingered gestures [J]. Sensors, 2019, 19(3): 610.
- [ 14 ] ZHANG S, ZHANG X, CAO S, et al. Myoelectric pattern recognition based on muscle synergies for simultaneous control of dexterous finger movements [J]. IEEE Transactions on Human-Machine Systems, 2017, 47(4): 576-582.
- [ 15 ] MASOUMDOOST A, SAADATYAR R, KOBRAVI H R. A muscle synergies-based movements detection approach for recognition of the wrist movements [J]. Eurasip Journal on Advances in Signal Processing, 2020(1): 1-19.
- [ 16 ] NAIK G R, NGUYEN H T. Nonnegative matrix factorization for the identification of EMG finger movements: Evaluation using matrix analysis [J]. IEEE Journal of Biomedical and Health Informatics, 2014, 19(2): 478-485.
- [ 17 ] MATSUBARA T, MORIMOTO J. Bilinear modeling of EMG signals to extract user-independent features for multiuser myoelectric interface [J]. IEEE Transactions on Biomedical Engineering, 2013, 60(8): 2205-2213.
- [ 18 ] KHUSHABA R N. Correlation analysis of electromyogram signals for multiuser myoelectric interfaces [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2014, 22(4): 745-755.
- [ 19 ] KIM M, CHUNG W K, KIM K. Subject-independent sEMG pattern recognition by using a muscle source activation model [J]. IEEE Robotics and Automation Letters, 2020, 5(4): 5175-5180.
- [ 20 ] KETYKÓ I, KOVÁCS F, VARGA K Z. Domain adaptation for semg-based gesture recognition with recurrent neural networks [C]. 2019 International Joint Conference on Neural Networks (IJCNN). IEEE, 2019: 1-7.



- [21] WEI W, DAI Q, WONG Y, et al. Surface-electromyography-based gesture recognition by multi-view deep learning [J]. *IEEE Transactions on Biomedical Engineering*, 2019, 66(10): 2964-2973.
- [22] CHEN H, ZHANG Y, LI G, et al. Surface electromyography feature extraction via convolutional neural network[J]. *International Journal of Machine Learning and Cybernetics*, 2020, 11(1): 185-196.
- [23] ATZORI M, GIJSBERTS A, KUZBORSKIJ I, et al. Characterization of a benchmark database for myoelectric movement classification [J]. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2014, 23(1): 73-83.
- [24] QI J, JIANG G, LI G, et al. Intelligent human-computer interaction based on surface EMG gesture recognition[J]. *IEEE Access*, 2019, 7: 61378-61387.
- [25] EBIED A, KINNEY-LANG E, SPYROU L, et al. Evaluation of matrix factorisation approaches for muscle synergy extraction[J]. *Medical Engineering & Physics*, 2018, 57: 51-60.
- [26] LEE D D, SEUNG H S. Learning the parts of objects by non-negative matrix factorization [J]. *Nature*, 1999, 401(6755): 788-791
- [27] JARAMILLO-YÁNEZ A, BENALCÁZAR M E, MENA-MALDONADO E. Real-time hand gesture recognition using surface electromyography and machine learning: A systematic literature review[J]. *Sensors*, 2020, 20(9): 2467.
- [28] PHINYOMARK A, QUAIN F, CHARBONNIER S, et al. Feature extraction of the first difference of EMG time series for EMG pattern recognition [J]. *Computer Methods and Programs in Biomedicine*, 2014, 117(2): 247-256.
- [29] IOANNIS D. Quantitative evaluation of muscle synergy models: A single-trial task decoding approach [J]. *Frontiers in Computational Neuroscience*, 2013: 7-8.
- [30] ATZORI M, GIJSBERTS A, HEYNEN S, et al. Building the ninapro database: A resource for the biorobotics community[C]. 2012 4th IEEE RAS & EMBS International Conference on Biomedical Robotics and Biomechatronics (BioRob), 2012: 1258-1265.
- [31] 成娟,陈勋,彭虎. 基于双线性模型的动作肌电信号用户无关识别研究[J]. *中国生物医学工程学报*, 2016, 35(5): 526-532.
- CHENG J, CHEN X, PENG H. Research on user-independent gesture recognition based on bilinear model for sEMG signals [J]. *Chinese Journal of Biomedical Engineering*, 2016, 35(5): 526-532.
- [32] DU Y, JIN W, WEI W, et al. Surface EMG-based inter-session gesture recognition enhanced by deep domain adaptation[J]. *Sensors*, 2017, 17(3): 458.
- [33] PATRICIA N, TOMMASIT T, CAPUTO B. Multi-source adaptive learning for fast control of prosthetics hand[C]. 2014 22nd International Conference on Pattern Recognition, Stockholm, 2014: 2769-2774.
- [34] ATZORI M, GIJSBERTS A, CASTELLINI C, et al. Electromyography data for non-invasive naturally-controlled robotic hand prostheses [J]. *Scientific Data*, 2014, 1(1): 1-13.

### 作者简介



郑楠, 2019年于广东石油化工学院获得学士学位, 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: zn190120078@163.com

**Zheng Nan** received his B.Sc. degree from Guangdong University of Petrochemical Technology in 2019. 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.