

基于 Myo 旋转偏移估计与自适应校正的手势识别方法

李自由^{1, 2, 3} 王丰焱^{1, 2, 3} 赵新刚^{1, 2} 丁其川⁴ 张道辉^{1, 2} 韩建达^{1, 2, 5}

摘 要 在基于表面肌电信号 (Surface electromyography, sEMG) 的手势识别系统中, 针对 Myo 环形电极多次实验间旋转位置不同导致的识别精度降低问题, 提出了一种基于极坐标系的电极位置偏移估计与自适应校正的识别方法. 该方法首先建立相对于环形肌电传感器的极坐标系, 提出了极坐标系下活跃极角 (Activation polar angle, APA), 用于估计实验中传感器相对于初始位置的横向旋转偏移角度; 进而建立基于偏移角度的线性变换模型, 在肌电信号特征空间内, 对电极偏移位置下的样本进行自适应校正. 在 8 种常用手势识别应用中, 设计了两种实验范式: 利用传感器各通道数据循环平移模拟电极横向旋转偏移实验和肌电传感器在小臂肌肉上的真实旋转偏移实验. 结果均表明所提出方法的识别精度远高于未进行校正的模型识别精度. 因此, 所提出的电极偏移估计与自适应校正识别方法, 不仅有效提高了表面肌电交互系统识别的鲁棒性, 也降低了使用者在多次使用时训练成本与学习负担.

关键词 表面肌电信号, 电极偏移, 自适应校正, 模式识别

引用格式 李自由, 王丰焱, 赵新刚, 丁其川, 张道辉, 韩建达. 基于 Myo 旋转偏移估计与自适应校正的手势识别方法. 自动化学报, 2020, 46(9): 1896–1907

DOI 10.16383/j.aas.c190028

The Method for Gestures Recognition Based on Myo Rotation Shifts Estimation and Adaptive Correction

LI Zi-You^{1, 2, 3} WANG Feng-Yan^{1, 2, 3} ZHAO Xin-Gang^{1, 2} DING Qi-Chuan⁴
ZHANG Dao-Hui^{1, 2} HAN Jian-Da^{1, 2, 5}

Abstract In the gestures recognition system based on surface electromyography (sEMG), an electrode shifts estimation and adaptive correction solution is proposed, to the problem of low recognition accuracies interfered by the Myo armband ring-electrode rotation shifts among experiments. The proposed method first establishes a polar coordinate system that is stationary relative to the ring sEMG acquisition system, and defines an activation polar angle (APA) that will be later used for measuring the electrode rotation shifts relative to its initial position. Based on the measurement of electrode shifts, interfered sEMG samples are adaptively corrected by a linear transformation in feature space. In the sEMG-based recognition application of eight common gestures, two experimental paradigms are conducted, including a simulation rotation paradigm by right shifts of eight-channel sEMG signals and a real one by shifts of the ring acquisition system on the lower arm. Results of both experimental paradigms demonstrate that the recognition accuracies of our proposed method are much higher than those of non-corrected models. In conclusion, the proposed electrode shifts estimation and adaptive correction method, improves the robustness of sEMG-based recognition system, and reduces the training time and learning burden for users.

Key words Surface electromyography (sEMG), electrode shifts, adaptive correction, pattern recognition

Citation Li Zi-You, Wang Feng-Yan, Zhao Xin-Gang, Ding Qi-Chuan, Zhang Dao-Hui, Han Jian-Da. The method for gestures recognition based on Myo rotation shifts estimation and adaptive correction. *Acta Automatica Sinica*, 2020, 46(9): 1896–1907

收稿日期 2019-01-09 录用日期 2019-06-24
Manuscript received January 9, 2019; accepted June 24, 2019
国家自然科学基金 (61573340, 61773369, U1813214) 资助
Supported by National Natural Science Foundation of China (61573340, 61773369, U1813214)
本文责任编辑 桑农
Recommended by Associate Editor SANG Nong
1. 中国科学院沈阳自动化研究所机器人学国家重点实验室 沈阳 110016 2. 中国科学院机器人与智能制造创新研究院 沈阳 110016 3. 中国科学院大学 北京 100049 4. 东北大学机器人科学与工程学院 沈阳 110004 5. 南开大学人工智能学院 天津 300350
1. State Key Laboratory of Robotics, Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016 2. In

表面肌电信号 (Surface electromyography, sEMG) 是由肌肉的运动单元动作电位 (Motor unit action potential, MUAP) 沿着肌纤维方向传播, 在人体皮肤表面形成反映肌肉收缩状态的叠加信号^[1-2]. 该信号载有丰富的肢体行为运动信息, 通过一系列
stitutes for Robotics and Intelligent Manufacturing, Chinese Academy of Sciences, Shenyang 110016 3. University of Chinese Academy of Sciences, Beijing 100049 4. Faculty of Robot Science and Engineering, Northeastern University, Shenyang 110004 5. College of Artificial Intelligence, Nankai University, Tianjin 300350

解码方法可获取肢体运动意图, 因此表面肌电信号广泛应用于机器人交互中^[3-5], 尤其是助力机器人、康复机器人与假肢系统等. 与传统的程式控制机器人交互方式相比, 基于表面肌电信号的人机交互系统具有了主动感知人行为意图的能力, 有利于实现复杂环境下人机共融, 并完成复杂任务.

目前部分商业假肢, 如英国 Touch Bionics 的 iLimb 肌电假肢, 利用表面肌电信号活跃阈值作为动作识别的重要依据, 但该方法仅适用于少量动作识别场合, 并且不具有良好的模型泛化能力. 而该领域的研究人员更为关注基于模式识别方法的动作识别研究^[6]. 作为典型的有监督模式识别问题, 基于表面肌电信号的人体意图感知与机器人交互一般包括两个主要过程: 1) 利用训练样本训练动作识别模型, 2) 利用已经训练的识别模型进行在线的人体运动意图识别, 并将识别结果作为机器人交互控制的期望输入^[1]. 其中第一个过程, 模型训练包括数据预处理、特征提取、样本降维和分类模型训练等. 针对基于表面肌电的动作模式识别, 研究人员已经提出了多种先进的识别算法, 识别准确率也越来越高^[7].

然而大部分的识别结果仅来自于实验室理想环境, 在实际的人机交互过程中易受诸多因素约束, 造成非理想的识别结果. 一系列非理想情况, 如信号的时变性和外部新动作干扰^[8], 用户长时间佩戴引起的肌肉疲劳, 交互过程中的肢体姿态变化, 由电极多次粘贴时位置不同导致的模型通用性差, 以及个体性差异等, 严重限制了肌电信号在实际人机交互中的应用与推广.

Tkach 等展示了常规时域特征都会随着电极位置发生变化, 并严重影响分类精度^[9]; 针对电极偏移问题带来的影响, Scheme 等提出了一种基于所有电极位置下的肌电识别模型训练策略, 但是该方法在实际使用中工作量较大^[10]; He 等采用高密度表面肌电传感器 (阵列式, 8 行 $\times$ 24 列=192 通道), 将其环绕在小臂一周, 量化了电极密度与电极偏移对手势识别带来的影响, 实验表明: 垂直于肌纤维方向的位置偏移影响大于平行于肌纤维方向偏移^[11]. 在实际基于表面肌电人机交互系统的推广使用中, 尤其是肌电假肢系统, 往往由于前后两次电极粘贴位置不同导致模型识别精度降低. 一方面, 很难要求用户每次都精准且一致地配置电极位置; 另一方面, 每次重新粘贴电极后, 如果忽略前后两次电极位置略有偏移的潜在关联关系, 要求用户重新开始完整训练一个识别模型, 会大大增加用户使用负担. 有调研表明, 较高的使用负担是造成用户弃用肌电假肢的关键原因之一^[12-13].

不同粘贴过程引起的电极偏移问题, 其本质就

是电极与肌肉对应关系的变化. 因此一个重要的研究思路, 即, 在提取表面肌电信号特征时, 要能够包含信号测量位置的空间信息或者提取与电极-肌肉对应关系无关的特征. 基于该思路, Stango 等分析了表面肌电信号与电极数量、偏移量之间的空间相关性^[14]. He 等在评估了高密度电极偏移带来影响的基础上^[11], 借鉴图像领域中的纹理特征^[15], 提出了一种改进灰度共生矩阵纹理特征 (Improved gray-level co-occurrence matrix, iGLCM) 的高密度表面肌电特征, 其具有空间位置无关的特点; 对比多种常用时域、频域等特征, 该方法取得了较高的动作识别率^[16-17]. 但该方法仅适用于高密度阵列式肌电信号传感器, 与常用稀疏表面电极传感器的兼容性需要进一步验证^[18].

而另外一个重要的研究思路是利用电极偏移前后表面肌电信号在特征空间中的差异性, 估计电极偏移量 (如偏移距离或偏移角度), 并进一步设计合理的自适应校正方法. 本文基于该思路, 利用常用的稀疏表面肌电传感器, 即 Myo 臂环^[19]; 在肌电信号各通道时域特征构成的空间 S 内 (理论上可采用任何常规、有效的特征提取方法), 针对电极偏移的本质问题, 提出了一种基于偏移角度估计与自适应校正的手势识别方法, 旨在提高肌电交互系统的鲁棒性与使用的便捷性.

结合小臂肌肉的分布特点, 本文利用这类环形表面肌电传感器, 首先建立相对于环形传感器静止的极坐标系, 提出了极坐标系下的活跃极角 (Activation polar angle, APA); 通过少量旋转偏移后的肌电信号数据, 与初始或标准位置数据比较, 基于活跃极角可估计出环形传感器的横向旋转偏移角度. 进而, 提出一种基于偏移角度的自适应校正方法, 完成偏移后的样本空间到初始样本空间的映射. 因此无需重新训练模型, 仅利用初始的手势识别模型, 取得了较高的动作识别正确率.

1 实验与方法

为了估计电极在多次粘贴位置之间的偏移量, 并进行自适应校正, 本文提出了模拟法与真实法两种实验范式, 合理地设计了一系列实验内容. 本节主要介绍了相关实验的表面肌电信号采集过程和特征提取等数据处理过程, 详细阐述了两种构造 Myo 环形电极横向旋转偏移干扰的实验范式; 最后介绍了基于极坐标系的活跃极角估计方法和基于偏移角度的自适应校正方法.

1.1 数据采集

共计 12 名身体健康的被试者 (其中 10 名男性

2 名女性, 年龄 25.44 ± 1.89 岁, 体重 63.38 ± 6.84 Kg, 身高 170.11 ± 5.70 cm) 参与了所有的实验; 实验采用 Myo 臂环 (加拿大 Thalmic 实验室开发) 作为表面肌电信号采集系统, 其信号采样率为 200 Hz, 经底层硬件降采样处理后以 50 Hz 输出. 该臂环由于具有较好的便携性, 使用方便, 广泛应用于诸多人机交互场合. 在本实验中, 被试者首先按照如图 1 的 Myo 官方指导教程^[20], 将 Myo 固定在前臂松紧合适的位置处, 完成 8 种常见动作的数据采集. 在该过程中, 被试者按照电脑显示特定顺序的动作引导图片完成手部动作 (如图 2), 休息手势作为其他 7 种动作的间隔过渡状态; 动作状态与休息状态分别持续 8 s 和 6 s, 完成一个周期, 约 98 s ($(8+6) \times 7 = 98$ s); 约 1 分钟的休息后, 被试者再重复执行上述过程 3 次, 最终完成被试者一次粘贴电极后的所有实验. 该过程的数据集记 $D_p^{\text{subject}} = \{cycle_0, cycle_1, cycle_2, cycle_3\}$, 其中 $p \in \{0, 1, 2, \dots, 8\}$, 表示在肌纤维垂直方向上的 9 次不同偏移位置; $subject \in \{1, 2, 3, \dots, 12\}$ 表示 12 名参与实验的被试者.




图 1 根据官方指导说明, 将 Myo 臂环固定在小臂处; 初始位置: 带有 Logo 指示灯的通道与中指对齐

Fig.1 The Myo around the lower arm according to official guides. The position where the logo channel and the middle finger are on one line as the initial position

1.2 基于滑动窗的特征提取

首先将每个 8 s 动作或 6 s 休息片段数据“掐头去尾”, 各舍弃掉 1 s 的数据, 消除动作间的过渡状态影响与受试者的动作反应时间干扰. 在本实验中, 为突出本文所提在特征空间内的偏移估计与校正方法, 简单起见, 仅使用了常用的时域特征平均绝对值 (Mean absolute value, MAV) 作为特征提取函数, 以此构造由各通道的 MAV 特征张成的特征空间. 设置时间窗 (Window length, LW) 为 200 ms 和增量窗 (Incremental length, LI) 为 60 ms (对应 $LW = 10$ 和 $LI = 3$, 见图 3). 因此, 原始 8 通道表面肌电信号数据, 经特征提取函数构成动作样本矩阵, 每个样本点为 8 维 (1×8).

$$f_{\text{MAV}}(x) = \frac{1}{LW} \sum_{i=1}^{LW} |x_i| \quad (1)$$




图 2 实验中 8 种常用手部动作: 休息、握拳、展掌、剪刀手、捏中指、捏食指、内翻、外翻

Fig.2 Eight common gestures in the experiment: rest, grasp, open hand, peace sign, pinch thumb finger, pinch middle finger, carpal varus, carpal valgus




图 3 基于滑动窗的特征提取, 其中窗长为 LW, 滑动为 LI

Fig.3 Feature extraction by a sliding window technique with incremental length (LI) and window length (LW)

1.3 基于模拟法与真实法的两种实验范式

由于肌电传感器电极位置在垂直于肌纤维方向上的偏移影响远大于肌纤维平行方向的偏移影响^[11], 因此本文在实验中仅考虑在肌纤维垂直方向上的旋转偏移影响.

为突出所提电极偏移估计与自适应校正方法的有效性, 如图 1, 实验中首先标记 Myo 臂环 Logo 所在的通道指向手部中指方向作为初始位置, 在该初始位置基础上提出了两种“电极旋转偏移”下表面肌电信号获取的实验范式: 模拟法和真实法.

1.3.1 基于通道循环平移的模拟电极偏移法

模拟法, 在初始采集位置的数据基础上, 如图 4 所示, 为传感器通道数据进行右循环平移 1 列情况. 模拟实验中模拟进行多次“电极旋转偏移”实验, 依次平移 0~8 列, 分别代表 Myo 臂环相对于小臂肌肉逆时针旋转 $\tau \times 45^\circ$, 其中 τ 为 0, 1, 2, $\dots$, 8, τ 为 0 或 8 时, 表示传感器旋转至初始测量位置. 利用这种通道循环平移的方法, 能够模拟理想情况下, 环形电极恰好旋转 45° 情况. 此时由通道 1 测量的肌肉位置, 恰好切换成由通道 0 检测. 由下文的线性变换关系可知, 这种由通道循环移动产生的新数据, 可由原始数据经矩阵变换得到, 而其中的变换矩阵即为 8 维单位矩阵进行列循环右平移得到. 因此, 利用这种模拟的实验范式, 能够准确描述特殊偏移位置下, 电极偏移前后所采集数据的关联性关系.




图 4 电极循环单位为 1 时, 由模拟法实验范式产生的电极偏移下表面肌电信号

Fig. 4 Electrode-shift sEMG by a simulation paradigm with a circulation step $\tau = 1$

1.3.2 基于通道旋转的真实电极偏移法

真实法, 在初始采集位置基础上, 仅沿着垂直于肌纤维方向, 将 Myo 环形肌电传感器旋转任意角度, 重复前述动作引导过程, 采集真实电极偏移下的表面肌电信号. 在小臂一周 $[0^\circ, 360^\circ)$ 范围内, 共依次任意旋转多次, 获取不同真实电极旋转偏移程度下的肌电数据.

1.4 基于极坐标系的活跃极角估计与自适应校正

针对环形电极在多次实验间旋转位置不同导致的识别精度下降的问题, 如图 5, 首先展示了本文所提旋转偏移估计与自适应校正方法的基本框架与思路, 并对比了传统基于有监督学习的表面肌电手势识别框架. 详细说明与对比如下:

如图 5 路径①, 作为典型的有监督学习模式识别思路, 将获取到带有标签信息的样本, 形成训练样本集与标签集 (X_L^{train} 和 y_L^{train}), 利用分类模型, 如本文采用支持向量机 (Support vector machine, SVM), 完成分类模型的离线训练, 进而在测试集或者在线样本集上 (X_L^{test} 和 y_L^{test}), 进行分类结果的预测.

一旦当被测试样本集受到各类因素干扰时, 如




图 5 基于极坐标系的电极偏移估计与自适应校正的表面肌电手势识别方法与传统识别框架的对比. 所采集带标签的数据集 X_L , 分割成训练集 X_L^{train} 与测试集 X_L^{test} ; 电极偏移干扰样本集 X_N , 按照原分类器得到的预测结果 $\hat{y}_N$; 或将新样本集 X_N 训练独立的分类器, 得到训练集与测试集结果 y_N^{train} 和 y_N^{test} . 点划线表示路径, 首先估计电极偏移前后的偏移角度 $\delta\alpha$, 以此建立两者之间的关系 $T_{n \times n}$, 最终经原分类器得到预测结果 y_{pN}

Fig. 5 The proposed electrode shifts estimation and adaptive correction method for sEMG-based gesture recognition and its traditional comparisons sEMG-based frameworks. Here, the labeled datasets X_L were split into the training part (X_L^{train} , y_L^{train}) and the testing part (X_L^{test} , y_L^{test}). The dataset X_N was interfered by electrode shifts, whose classification results were $\hat{y}_N$ by the pre-trained classifier. Or, X_N was used to train an individual classifier, resulting in y_N^{train} and y_N^{test} . As the dot-dash line, the shift $\Delta\alpha$ was first estimated, and then $T_{n \times n}$ was established. Finally, y_{pN} was the estimated results of the interfered by the pre-trained classifier

本文所讨论的电极旋转偏移问题, 新样本集 X_N 与原始模型训练样本集 X_L 或 X_L^{train} 的分布有较大差异, 此时仍然利用初始分类模型, 如图 5 路径②, 得到分类结果 $\hat{y}_N$ 往往不理想, 造成分类精度较低.

在实际的肌电手势识别系统中, 常采用如图 5 路径③, 要求使用者重新获取有标签的样本集, 重新训练一个分类模型. 这种方法虽然也能够获取较高的模型识别精度, 但是一方面要求使用者重复训练获取大量有标签样本集, 费时费力, 更难处理在线干扰情况; 另一方面, 也完全忽视了受干扰肌电信号与原始信号之间的潜在关联关系.

如图 5 路径④, 本文针对一类由电极旋转偏移导致的新样本 X_N 与 X_L 分布不同的问题, 最终导致识别精度降低的问题, 利用两者之间潜在的关联关系 ($T_{n \times n}$) 进行电极偏移估计, 提出了一种电极偏移自适应校正方法. 该思路借鉴了迁移学习领域的基本思想: 通过算法来最大限度地利用源领域模型, 找到源领域与目标领域问题的相似性, 解决目标领域问题. 更重要的是, 相对于路径③重新训练模型的思路, 该思路具有一个突出的优势: 重新训练有监督的模型, 其分类能力或所能识别的类别数由训练样本集决定; 而通过本文所提出的路径④, 可以通过不完整类别的少量样本进行完整类别样本

自适应校正, 利用初始完整类别分类模型, 实现具有完整类别的分类能力. 在实际肌电交互系统使用中, 该方法将大大降低使用者使用负担与学习成本.

因此, 根据图 5 路径④所提的基本框架, 为克服电极不同偏移程度下对肌电数据的干扰影响, 提高肌电识别系统的鲁棒性, 本文采取两个主要的步骤: 1) 估计电极旋转偏移角度, 2) 建立基于偏移角度的自适应校正方法.

1.4.1 基于极坐标系的活跃极角估计

利用: 1) 小臂肌肉分布不均匀特点; 2) 不同动作由不同的小臂肌肉以不同的收缩强度完成; 3) 同一动作由几乎相同的小臂肌肉以近似的收缩强度完成^[21]; 4) 所使用的表面肌电传感器为环形臂环, 建立相对于环形 Myo 臂环静止的极坐标系, 本文提出了一种基于极坐标系的活跃极角估计方法, 由此计算相对于初始佩戴位置的电极旋转偏移角度.

如图 6(a) 展示了小臂的横截面图, 显示了不同骨骼与主要肌肉, 包括尺侧腕屈肌 (1. FCU (Flexor carpi ulnaris)), 指浅屈肌 (2. FDS (Flexor digitorum sublimis)), 掌长肌 (3. PL (Palmaris longus)), 桡侧腕屈肌 (4. FCR (Flexor carpi radialis)), 肱桡肌 (5. BR (Brachioradialis)), 桡侧伸腕长肌 (6. ECRL (Extensor carpi radialis longus)), 桡侧伸腕短肌 (7. ECRB (Extensor carpi radialis brevis)), 旋前圆肌 (8. PT (Pronator teres)), 指伸肌 (9. EDC (Extensor digitorum communis)), 小指固有伸肌 (10. EDQ (Extensor digiti quinti)), 旋后肌 (11. SUP (Supinator)), 尺侧腕伸肌 (12. ECU (Extensor carpi ulnaris)), 指深屈肌 (13. FDP (Flexor digitorum profundus)). 其外周为佩戴的环形 Myo 臂环. 以通道 0 所在的方向为极坐标的 0° 极轴参考方向, 通道 1, 2, 3, $\dots$, 7 分别对应极坐标中的 45° , 90° , 135° , $\dots$, 315° 极角方向, 因此建立了图 6(b) 所示的极坐标系, 以及与 Myo 臂环、小臂肌肉之间的描述关系.

将 8 通道表面肌电信号的 MAV 特征值分别作为各个极角上的极径. 如图 6(b) 所示, 为被试者在执行“捏食指”动作状态下, 采集 8 s 过程中所有样本点在极坐标下的分布. 该极坐标内散点图的绘制可视化原理如下: 针对来自 8 通道传感器的任意样本点 x_i ,

$$x_i = (p_{i,0}, p_{i,1}, p_{i,2}, \dots, p_{i,7}) \quad (2)$$

其中, $p_{i,j}$ 表示来自第 i 个样本、通道 j 的 MAV 特征值. 并将 $(p_{i,j}, j \times 45^\circ)$ 以极坐标点表示形式绘制在极坐标系内, 即通道 0 的特征值绘制在 0° 极轴上, 通道 1 绘制在 45° 极轴上, 依次地, 通道 7 绘制在 315° 极轴上, 其中各特征值大小作为散点绘制的极径. 最




图 6 横截面图和散点图 (a) 截面视角, 包括 Myo 臂环和小臂各肌肉与骨骼的截面分布; (b) 散点图: 不同通道上的样本点绘制在不同极角的极轴上, 点划线为所提出并定义的活跃极角

Fig. 6 The cross-section diagram and scatter diagram (a) the cross-section view of proposed polar coordinate with Myo armband and the lower arm's muscles and bones; (b) the scatter plot with every channel samples on different polar angle axis, and the proposed APA with dot-dash line

终形成如图 6(b) 的黑色散点聚集分布区域.

将极坐标内的点作为矢量进行矢量叠加. 为便于进行矢量叠加运算, 将极坐标系内的任意散点作为矢量, 由极坐标系到直角坐标系的映射关系, 在直角坐标系内, 可表示为 $\bar{p}_{i,j}$,

$$\bar{p}_{i,j} = (p_{i,j} \times \cos(j \times 45^\circ), p_{i,j} \times \sin(j \times 45^\circ)) \quad (3)$$

并利用矢量叠加计算该动作下整体合成矢量, 本文

将该矢量的极角定义为活跃极角 α , 其计算原理如下所示:

$$\vec{p} = \sum_{i=1}^m \sum_{j=0}^7 p_{i,j} = (p_x, p_y) \quad (4)$$

其中,

$$p_x = \sum_{i=1}^m \sum_{j=0}^7 p_{i,j} \times \cos(j \times 45^\circ) \quad (5)$$

$$p_y = \sum_{i=1}^m \sum_{j=0}^7 p_{i,j} \times \sin(j \times 45^\circ) \quad (6)$$

$$\alpha = \arctan\left(\frac{p_y}{p_x}\right) \quad (7)$$

其中, m 表示某动作标签引导下获得的肌电特征样本量.

无论是基于模拟法还是基于真实法的电极偏转过程中, 令极坐标系的起始位置始终为通道 0 所在的方向. 因此, 当环形电极与肌肉之间发生相对偏移时, 由于同一个动作引起几乎相同的肌肉收缩状态, 对应于极坐标系内就会有不同分布, 即可重新计算电极偏移后对应的活跃极角. 不同位置活跃极角的偏差 $\Delta\alpha$, 在本文中, 用于估计环形电极相对于初始肌肉位置的偏移量.

1.4.2 基于偏移角度的自校正

为便于校正方法设计, 首先将肌电信号传感器采集肌电信号的过程, 简化成一个“多接收器—多信号源”的模型: 肌电信号传感器作为接收器, 主要获取临近肌肉的叠加活跃电信号, 且贡献程度与信号源的距离负相关. 因此, 通过上一节原理可计算出在两次佩戴前后的偏移量 $\Delta\alpha$, 假设所有通道相对于其对应的初始位置均偏转了 $\Delta\alpha$ ($\Delta\alpha \in [0^\circ, 360^\circ)$), 如图 7 所示, 当 $\Delta\alpha \in [0^\circ, 45^\circ)$ 时, 偏移后通道 0 主要来自于偏移前通道 0 和通道 1, 依据“多接收器—多信号源”模型, 叠加信号由二者加权获取, 且权重因子与距离两者的偏角负相关. 因此当 $\Delta\alpha \in [0^\circ, 45^\circ)$ 可表示为

$$\begin{aligned} \tilde{p}_i &= (\tilde{p}_{i,0}, \tilde{p}_{i,1}, \dots, \tilde{p}_{i,7}) = \\ &\left(1 - \frac{\Delta\alpha}{45^\circ}\right)(p_{i,0}, p_{i,1}, \dots, p_{i,7}) + \\ &\frac{\Delta\alpha}{45^\circ}(p_{i,1}, \dots, p_{i,7}, p_{i,0}) \end{aligned} \quad (8)$$

取 $\Delta\alpha$ 恰好为 $j \times 45^\circ$ 特殊偏移角度时, 其中 $j = 0, 1, 2, \dots, 7$, 参考图 7, 偏移后的通道 0 电极恰好位于初始位置下通道 j 所在的肌肉位置, 其他偏移后的通道测量位置则同理.

因此, 本文尝试构建一个基本关系: 偏移后通




图 7 偏移范围 $\Delta\alpha$ 为 $[0^\circ, 45^\circ)$ 时, 所有通道电极相对于初始位置偏移情况

Fig. 7 Every electrode shifts $\Delta\alpha$ in a counter-clockwise direction within the range of $[0^\circ, 45^\circ)$

道 0 的 MAV 特征值与偏移前通道 0 之间的关系, $f(\Delta\alpha)$; 当为 $j \times 45^\circ$ 特殊偏移角度时, 如图 8 中点划线的映射关系.




图 8 各电极通道 MAV 特征值映射变换与偏移角度间关系

Fig. 8 The mapping relationship between original one-channel MAV and shifted MAV on the shift angle

对其各个特殊位置之间的映射关系分段线性化, 将 $\Delta\alpha$ 拓展到 $[0^\circ, 360^\circ)$ 内任意电极偏转角度, 表示为

$$f(\Delta\alpha) = \begin{cases} 1 - \frac{\Delta\alpha}{45^\circ}, & \Delta\alpha \in [0^\circ, 45^\circ) \\ 0, & \Delta\alpha \in [45^\circ, 315^\circ) \\ \frac{\Delta\alpha}{45^\circ} - 7, & \Delta\alpha \in [315^\circ, 360^\circ) \end{cases} \quad (9)$$

并由此拓展到初始 8 通道肌电 MAV 特征值与偏移后肌电 MAV 特征值之间的线性映射关系, 矩阵表达形式为

$$T_{8 \times 8}(\Delta\alpha) = (t_{i,j})_{8 \times 8} = (f(\Delta\alpha - (i - j) \times 45^\circ))_{8 \times 8} \quad (10)$$

$$\tilde{p}_i = p_i \times T_{8 \times 8}(\Delta\alpha) \quad (11)$$

其中, i 和 j 分别表示变换矩阵中行和列序号, $t_{i,j}$ 表示该变换矩阵中的任意元素.

因此当电极位置发生横向旋转偏移时, 获取当前电极位置下的干扰肌电数据, 经由式 (7) 估计与初始电极位置的偏差 $\Delta\alpha$, 并经由式 (10) 和式 (11) 将偏移干扰后的肌电特征映射到原始样本空间内, 最后由初始手势识别模型获取手势分类结果.

1.5 手势识别模型

为验证本文所提电极偏移估计与自适应校正方法, 本文仅使用支持向量机 (SVM) 作为手势分类模型; 在训练分类器模式时, 同一被试者初始位置下获取数据集 $D_{p=0}^{\text{subject}} = \{\text{cycle}_0\}$, 将其分为 80% 作为训练集与 20% 作为测试集; 同时, 该被试者不同位置下获取数据集 $D_p^{\text{subject}} = \{\text{cycle}_0, \text{cycle}_1, \text{cycle}_2, \text{cycle}_3\}$, 其中 $p \in \{1, 2, \dots, 8\}$, 将初始位置下的模型应用于不同位置数据集, 即得到该位置下的分类识别精度.

2 实验结果与讨论

由前述两种实验范式, 模拟法和真实法, 本节分别讨论这两种实验范式下, 对比所提方法的识别精度与未处理下的电极偏移识别精度.

2.1 通道循环平移的模拟电极偏移实验

为了能够初步检验所提电极旋转偏移估计与自动校正方法的合理性, 验证方法的可行性, 我们首先模拟电极偏移实验: 由于 Myo 臂环为 8 通道环形表面肌电传感器, 并且每个通道仅提取了一个时域特征 MAV, 即得到样本矩阵 X

$$X = (p_{i,0}, p_{i,1}, \dots, p_{i,7})_{m \times 8} \quad (12)$$

其中, m 表示样本量.

8 通道环形传感器可以将相邻通道之间的偏差角度简化为 $45^\circ = 360^\circ/8$. 因此, 如果各列通道特征值进行右循环平移 τ 列 ($\tau = 0, 1, 2, \dots, 8$), 即对应模拟了实际 Myo 臂环逆时针旋转 $\tau \times 45^\circ$, 或手臂相对于 Myo 臂环顺时针旋转 $\tau \times 45^\circ$. 如图 7 所示, 偏移后的样本矩阵可以表示为

$$\tilde{X}(\tau = 1) = (p_{i,7}, p_{i,0}, \dots, p_{i,6})_{m \times 8} \quad (13)$$

如图 9(a)~(i), 展示了被试者 1 在多次模拟电极偏转实验中的样本分布情况. 在这一系列实验中, 通过样本矩阵各列循环平移模拟了电极偏移情况 ($\tau = 0, 1, 2, \dots, 8$), 由于所建立的极坐标系相对于 Myo 各通道静止, 样本矩阵右循环平移, 等效于肌肉相对 Myo 臂环为逆时针变化. 因此在图 9 所有极坐标内, 样本点分布呈现顺时针变化趋势; 利

用所提出基于极坐标系下矢量叠加的活跃极角计算方法, 计算出各个位置下“捏食指”动作的活跃极角 (表 1). 如图 9 及表 1 中能够明显表明活跃极角 α 随着模拟电极偏移而变化, 与模拟电极偏移情况方向相同, 呈现顺时针变化; 并且相邻模拟偏移位置下活跃极角之间的偏差 $\Delta\alpha$ 始终为 45° , 完全符合模拟法的设计原理. 因此, 通过一系列的模拟实验, 验证了基于极坐标系下电极偏移估计方法的合理性与可行性, 能够准确地估计出电极偏移方向与角度.

表 1 基于通道循环平移下的模拟电极偏移实验, 活跃极角估计, 与相对于初始位置旋转角度估计 ($^\circ$)

Table 1 The simulation experiments by circulations of each channel, the estimation of proposed activation polar angle – APA, and the estimation of shifts angle relative to the initial position ($^\circ$)

偏转实验 τ	活跃极角 α	偏转角度 $\Delta\alpha$
0	-173.15	—
1	141.85	45
2	96.85	90
3	51.85	135
4	6.85	180
5	-38.15	225
6	-83.15	270
7	-128.15	315
8	-173.15	360

在偏移角度准确估计的基础上, 利用所提的自校正算法 (式 (9)~(11)), 如图 10 为被试者 1 不同位置下的识别精度统计结果, 对比了自适应校正模型与未校正偏移干扰的手势识别精度. 在利用各通道循环平移的一系列模拟电极偏移实验中, 未经处理的识别精度结果显示, 整体而言电极位置偏移极大地降低了手势识别精度 ($31.40 \pm 29.28\%$); 并且在电极偏移一周 $[0^\circ, 360^\circ)$ 过程中, 识别精度呈现先下降后上升的趋势, 当偏移角度为 180° 附近时精度最低. 这是由于 Myo 臂环在旋转过程中, 当偏移角度为 180° 时, 各个电极此时所对应的肌肉位置与初始肌肉位置偏差最大、距离最远, 数据分布与初始样本分布差异最大.

如图 10 所示, 其中横坐标为 0° 时对应了在没有电极模拟偏移情况下的识别精度, 即 $99.90 \pm 0.10\%$. 而经过本文所提方法的手势识别精度达到 $99.90 \pm 0.10\%$, 所有模拟电极偏移的识别结果均接近 100%, 明显高于未经处理的分类精度 ($p < 0.001$); 并且在偏移角度准确估计结果的基础上, 所提出的自适应校正变换, 可适用于不同程度电极偏移情况, 量化




图9 模拟电极偏移情况下, 极坐标内的肌电信号样本点的散点图与虚线所代表的活跃极角

Fig.9 Scatter plots in the polar coordinate of sEMG samples from simulated electrode shifts and the proposed activation polar angle (APA) in dash line

了电极偏移引起的分布差异性, 并进行了映射校正, 得到了与初始位置完全一致的样本集, 因此具有与初始分类模型训练集几乎一致的识别精度。

2.2 通道旋转的真实电极偏移实验

在前述“通道循环平移的模拟电极偏移实验”基础上, 更进一步, 在实际中进行了环形 Myo 臂环相对于小臂肌肉肌纤维垂直方向偏转的数据采集与处理、偏移角度估计与自适应校正, 以及手势识别精度的量化比较。

在初始位置的基础上, 将环形 Myo 臂环沿着

肌纤维垂直方向递增地偏转 9 次, 近似完成绕小臂一周的旋转偏移。电极处于任意位置上, 均按照规定实验采集过程, 获取不同动作下的肌电信号数据。

如图 11 和表 2 所示, 在极坐标内展示了被试者 1 的 9 个电极偏移位置下, “捏食指”动作的样本分布与活跃极角估计值。

图 11 中各极坐标系内的肌电样本点 (黑色散点区域), 展示了顺次偏移不同程度下的肌电信号分布情况。整体来看, 呈现出顺时针旋转的趋势; 结合表 2, 所提偏移角度估计值, 量化了这种顺时针偏移程度, 估计了偏移下电极相对于初始位置的偏移角




图 10 不同偏移程度下的手势识别精度对比: 偏移估计与自适应校正的精度 (实线) 和未处理电极偏移干扰下的精度 (虚线)

Fig.10 Gestures recognition comparison with different shifts: proposed shifts estimation and adaptively corrected accuracies (solid line) v.s. un-corrected accuracies (dotted line)

表 2 基于电极旋转的真实电极偏移实验, 活跃极角估计, 与相对于初始位置旋转角度估计 (°)
Table 2 The real experiments by electrode rotation, the estimation of proposed activation polar angle – APA, and the estimation of shifts angle relative to the initial position (°)

偏转实验 τ	活跃极角 α	偏转角度 $\Delta\alpha$
0	-169.58	-3.57
1	150.09	36.76
2	104.74	82.11
3	64.97	121.88
4	6.29	180.57
5	-39.97	226.83
6	-83.01	269.87
7	-122.34	309.20
8	-175.31	2.17

度. 除去顺时针变化趋势, 仔细对比不同偏移情况下肌电样本分布, 仍存在着略微的差异性, 具体分析而言, 这种差异性源于同一个人在执行相同的手势时, 仍然会有动作强度、肌肉发力方式的差异性. 但即使存在这些强度等差异性, 结合式 (7), 所提出的活跃极角对其具有一定的鲁棒性. 如图 12 所示, 展示了被试者 1 在分别进行了 9 个电极偏移位置上偏移角度估计情况, 每个位置重复采集数据 4 次, 该曲线显示在任意一个位置上的估角度估计方差均比较小 ($std_{\max} = 6.56^\circ$, $std_{\min} = 0.45^\circ$), 同样表明了偏移角度估计方法的鲁棒性与稳定性.

基于被试者 1 在 9 个电极偏移位置上分别重复 4 次的实验数据, 如图 13, 其中横坐标表示基于极坐标系的偏移角度估计均值, 纵坐标表示手势识别精度, 分别展示了偏移数据与校正后数据的手势识别精度随着偏转程度的变化趋势. 与模拟电极偏

移实验效果基本一致: 在电极环绕小臂一周 $[0^\circ, 360^\circ)$ 逐渐偏移过程中, 未进行任何校正处理的识别精度仅为 $38.21 \pm 29.88\%$; 并呈现出先下降后上升的趋势, 当偏移角度位于 $[120^\circ, 180^\circ)$ 区间时, 识别精度达到最低 ($12.27 \pm 9.47\%$). 这种变化趋势比较符合偏移角度对识别精度带来的预期影响, 即相对于初始位置偏差越大、距离越远, 电极偏移对精度的恶化效果越严重. 结合图 6(a), 以通道 1 为例, 其采集到的肌电信号主要来自桡侧伸腕短肌 (7. ECRB); 当 Myo 臂环发生一定偏移时 (如在图 6(a) 中逆时针旋转 90°), 则通道 1 主要受桡侧腕屈肌 (4. FCR) 的影响, 原桡侧伸腕短肌对该通道的贡献变小; 而当逆时针旋转 180° 时, 原桡侧伸腕短肌与通道 1 距离最远, 贡献程度最低; 进一步, 继续旋转外周 Myo 臂环, 则通道 1 与原桡侧伸腕短肌间距离由长变短, 贡献程度逐渐增强.

如图 13, 电极偏移干扰数据与校正后数据的所有动作手势识别精度对比而言, 当电极发生不同程度偏移时, 本文所提出的偏移角度估计与自适应校正方法能够极大地修正偏移数据、提高手势识别精度; 实验数据表明 (表 3), 12 名被试者偏移数据的平均精度仅有 28.26%, 而经过校正后的数据其平均识别精度达到 78.37%, 显著提高了基于肌电信号的手势识别精度 ($p < 0.001$), 有效提高了识别系统准确性与鲁棒性.

进一步, 为避免特殊位置或偶然动作重复带来的干扰问题, 本文进行了交叉验证. 分别在不同位置下、不同重复实验数据集上, 训练得到初始手势识别模型, 在其他位置上或重复实验数据集上进行测试验证, 最终得到所有位置所有重复实验上的平均识别精度, 如表 3 中校正前后精度所示. 由表 3 可知, 由本文所提方法校正后的精度, 明显高于未经任何处理、电极旋转偏移的校正前识别精度.

3 结论

本文针对多次佩戴 Myo 肌电臂环时, 由电极横向位置旋转偏移导致的识别精度降低问题, 提出了一种基于极坐标系的电极旋转偏移估计与自适应校正的手势识别方法. 利用环形传感器与小臂肌肉分布的特点, 本文首先提出一种基于极坐标系下的活跃极角 (Activation polar angle, APA); 当电极相对于初始肌肉位置发生横向旋转偏移时, 利用不同位置下活跃极角间的偏角, 建立由偏移数据到初始数据空间的自适应校正模型. 为验证所提方法的有效性, 本文提出了两种实验范式: 基于通道循环平移模拟电极旋转偏移实验和基于通道旋转的真实电极偏移实验. 两种实验的手势识别结果均表明:




图 11 真实的电极-肌肉偏移情况下, 极坐标系内肌电信号样本点的散点图与虚线所代表的活跃极角

Fig.11 Scatter plots in the polar coordinate of sEMG samples from real electrode shifts and the proposed activation polar angle (APA) in the dash line

电极位置偏移导致肌电手势识别精度下降, 而本文所提方法能够极大地改善精度降低问题. 因此, 本文所提方法不仅提高了系统的鲁棒性, 更有利于基于表面肌电信号的智能交互系统在实际应用中的推广. 基于本文所提方法在实际应用中, 意味着, 当使用者再次佩戴 Myo 臂环后, 无需与初始佩戴位置完全精确一致; 在任意佩戴后, 仅仅模拟原始多类别动作之一 (如本文实验中的“捏食指”动作), 即能够重复利用初始手势识别模型, 大大地降低了使用者学习或再训练的负担与时间成本等. 这些优越的性能是传统肌电识别思路或方法所不完全具备的.

但本文所提方法仍然存在一些局限性. 如在获取动作执行期内的原始肌电信号时, “掐头去尾”

各 1 s 的操作明显是为了避免动作过渡状态的干扰, 而过渡状态与平稳动作状态下的肌电信号有较大差异, 其识别依然是限制肌电识别系统推广与应用的瓶颈之一. 文中一系列模拟与真实实验中, 尽管针对偏移干扰肌电信号提出了自适应校正方法, 仅利用少量样本数据极大地提高了识别精度, 从平均 28.26% 到 78.37%, 但目前针对 8 种常用动作的分类问题上, 仅具有 78.37% 的分类精度, 仍无法满足实际肌电假肢等系统的需求, 存在一定的应用差距. 目前, 针对常见十种以下手部动作识别精度, 其基准线一般在 90% 以上, 因此本文方法仍然具有较大的提升空间. 并且, 所设计实验是否仍受环形电极在小臂纵向方向的偏移干扰, 仍然需要进一步探讨.

表 3 每名实验参与者在不同位置或不同重复次数下的交叉验证平均识别结果 (*表示为女性受试者)(%)

被试者	校正前精度	校正后精度
1	38.21 ± 29.88	86.56 ± 12.04
2	29.98 ± 25.65	74.16 ± 26.81
3	24.54 ± 28.48	90.06 ± 8.16
4	30.11 ± 26.59	87.27 ± 9.51
5 *	36.95 ± 29.05	75.27 ± 14.20
6	31.84 ± 33.57	85.19 ± 9.50
7	25.91 ± 31.66	78.24 ± 13.61
8	22.62 ± 29.25	82.26 ± 11.81
9	26.72 ± 25.09	64.16 ± 13.50
10	25.27 ± 26.12	73.92 ± 14.72
11	21.96 ± 24.52	61.84 ± 16.01
12 *	25.00 ± 28.86	81.53 ± 13.72
均值	28.26	78.37 ($p < 0.001$)




图 12 在 9 次电极-肌肉偏移过程中, 对活跃极角的偏移角度估计

Fig.12 The estimations of activation polar angle for nine shifts in $[0^{\circ}, 360^{\circ}]$




图 13 不同真实电极-肌肉偏移程度下的手势识别精度对比: 偏移估计与自适应校正的精度(实线)和未处理电极偏移干扰下的精度(虚线)

Fig.13 Gesture recognition accuracy comparison with different electrode-muscle shifts: proposed shifts estimation and adaptively corrected accuracies (solid line) v.s. un-corrected accuracies (dotted line)


同时, 所提方法中仅采用了时域特征平均绝对值 (MAV), 在频域等更多特征方面的拓展, 以及小角度的偏移干扰问题仍是进一步深入研究的重点方向之一. 而且, 为克服环形电极横向旋转偏移带来的干扰问题, 本文方法主要分为两个步骤: 1) 基于极坐标系的电极偏移角度估计; 2) 基于线性映射的自适应校正方法. 从偏移角度到线性变换矩阵之间的假设或线性约束太强, 是否存在更优的或者一步到位 (略去偏移角度估计环节) 的线性或非线性映射关系, 仍有待进一步探索. 另外, 本文利用环形电极特点, 能否将本文方法推广到一般多个离散电极的应用上, 仍然需要进一步研究与探索.

References

- 1 Ding Qi-Chuan, Xiong An-Bin, Zhao Xin-Gang, Han JianDa. A review on researches and applications of sEMG-based motion intent recognition methods. *Acta Automatica Sinica*, 2016, **42**(1): 13–25
(丁其川, 熊安斌, 赵新刚, 韩建达. 基于表面肌电的运动意图识别方法研究及应用综述. *自动化学报*, 2016, **42**(1): 13–25)
- 2 Ding Qi-Chuan, Zhao Xin-Gang, Han Jian-Da. EMG-based estimation for multi-joint continuous movement of human upper limb. *Robot*, 2014, **36**(4): 469–476
(丁其川, 赵新刚, 韩建达. 基于肌电信号的上肢多关节连续运动估计. *机器人*, 2014, **36**(4): 469–476)
- 3 Hou Zeng-Guang, Zhao Xin-Gang, Cheng Long, Wang Qi-Ning, Wang Wei-Qun. Recent advances in rehabilitation robots and intelligent assistance systems. *Acta Automatica Sinica*, 2016, **42**(12): 1765–1779
(侯增广, 赵新刚, 程龙, 王启宁, 王卫群. 康复机器人与智能辅助系统的研究进展. *自动化学报*, 2016, **42**(12): 1765–1779)
- 4 Lu Z Y, Tong K Y, Shin H, Li S, Zhou P. Advanced myoelectric control for robotic hand-assisted training outcome from a stroke patient. *Frontiers in Neurology*, 2017, **8**: 107
- 5 Otr O V, Reinders-Messelink H A, Bongers R M, Bouwsema H, Van Der Sluis C K. The i-LIMB hand and the DMC plus hand compared a case report. *Prosthetics and Orthotics International*, 2010, **34**(2): 216–220
- 6 Chu J U, Moon I, Lee Y J, Kim S K, Mun M S. A supervised feature-projection-based real-time EMG pattern recognition for multifunction myoelectric hand control. *IEEE/ASME Transactions on Mechatronics*, 2007, **12**(3): 282–290
- 7 Scheme E J, Englehart K B, Hudgins B S. Selective classification for improved robustness of myoelectric control under nonideal conditions. *IEEE Transactions on Bio-medical Engineering*, 2011, **58**(6): 1698–1705
- 8 Ding Qi-Chuan, Zhao Xin-Gang, Li Zi-You, Han Jian-Da. The EMG-motion recognition method based on self-update hybrid classification model. *Acta Automatica Sinica*, 2019, **45**(8): 1464–1474
(丁其川, 赵新刚, 李自由, 韩建达. 基于自更新混合分类模型的肌电运动识别方法. *自动化学报*, 2019, **45**(8): 1464–1474)
- 9 Tkach D, Huang H, Kuiken T A. Study of stability of time-domain features for electromyographic pattern recognition. *Journal of NeuroEngineering and Rehabilitation*, 2010, **7**(1): 21
- 10 Scheme E, Englehart K. Training strategies for mitigating the effect of proportional control on classification in pattern recognition based myoelectric control. *Journal of Prosthetics and Orthotics*, 2013, **25**(25): 76–83
- 11 He J Y, Sheng X J, Zhu X Y, Jiang N. Electrode density affects the robustness of myoelectric pattern recognition system with

and without electrode shift. *IEEE Journal of Biomedical and Health Informatics*, 2019, **23**(1): 156–163

- 12 Kristin Östlie, Lesjø I M, Franklin R J, Garfelt B, Magnus P. Prosthesis rejection in acquired major upper-limb amputees a population-based survey. *Disability and Rehabilitation. Assistive technology*, 2011, **7**(4): 294–303
- 13 Biddiss E A, Chau T T. Upper limb prosthesis use and abandonment a survey of the last 25 years. *Prosthetics and Orthotics International*, 2007, **31**(3): 236–257
- 14 Stango A, Negro F, Farina D. Spatial correlation of high density emg signals provides features robust to electrode number and shift in pattern recognition for myoelectric control. *IEEE Transactions on Neural Systems Rehabilitation Engineering*, 2015, **23**(2): 189–198
- 15 Mohanaiah P, Sathyanarayana P, GuruKumar L. Image texture feature extraction using GLCM approach. *International Journal of Scientific and Research Publications*, 2013, **3**(5): 1–5
- 16 He J F, Zhu X Y. Combining improved gray-level co-occurrence matrix with high density grid for myoelectric control robustness to electrode shift. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, 2017, **25**(9): 1539–1548
- 17 Pan, L Z, Zhang D G, Jiang N, Sheng X J, Zhu, X. Y. Improving robustness against electrode shift of high density emg for myoelectric control through common spatial patterns. *Journal of Neuroengineering Rehabilitation*, 2015, **12**(1): 1–16
- 18 Young A J, Hargrove L J, Kuiken T A. Improving myoelectric pattern recognition robustness to electrode shift by changing interelectrode distance and electrode configuration. *IEEE Transactions on Bio-medical Engineering*, 2012, **59**(3): 645–652
- 19 Rawat S, Vats S, Kumar P. Evaluating and exploring the MYO ARMBAND. In: Proceedings of the 2016 International Conference System Modeling and Advancement in Research Trends (SMART), Moradabad, India, 2016. 115–120
- 20 Getting starting with Myo on Windows. Available from: <https://support.getmyo.com>
- 21 Wang Song. *Sport Anatomy*. Wuhan, Huazhong University of Science and Technology Press, 2018, 113–117
(王松. 运动解剖学. 武汉, 华中科技大学出版社, 2018, 113–117)



李自由 中国科学院沈阳自动化研究所博士研究生。主要研究方向为生物电信号处理, 模式识别与机器学习。

E-mail: liziyou@sia.cn

(**LI Zi-You** Ph.D. candidate at Shenyang Institute of Automation, Chinese Academy of Sciences. His

research interest covers bio-signal processing, pattern recognition, and machine learning.)



王丰焱 中国科学院沈阳自动化研究所硕士研究生。主要研究方向为智能假肢, 机器学习。

E-mail: wangfengyan@sia.cn

(**WANG Feng-Yan** Master student at Shenyang Institute of Automation, Chinese Academy of Sciences. His research interest covers intelligent prosthes-

is and machine learning.)




赵新刚 中国科学院沈阳自动化研究所研究员。2008 年获得中国科学院沈阳自动化研究所博士学位。主要研究方向为机器人控制, 智能系统与康复机器人。本文通信作者。

E-mail: zhaoxingang@sia.cn

(**ZHAO Xin-Gang** Professor at

Shenyang Institute of Automation, Chinese Academy of Sciences. He received his Ph.D. degree from Shenyang Institute of Automation, Chinese Academy of Sciences in 2008. His research interest covers robot control, rehabilitation robots, and intelligent systems. Corresponding author of this paper.)



丁其川 东北大学机器人科学与工程学院副教授。2014 年获得中国科学院大学博士学位。主要研究方向为生物电信号处理, 模式识别, 可穿戴机器人技术。

E-mail: dingqichuan@mail.neu.edu.cn

(**DING Qi-Chuan** Associate professor at the Faculty of Robot Science and Engineering,

Northeastern University. He received his Ph.D. degree from University of Chinese Academy of Sciences in 2014. His research interest covers bio-signal processing, pattern recognition, and wearable robot technology.)



张道辉 中国科学院沈阳自动化研究所副研究员。2018 年获得中国科学院大学博士学位。主要研究方向为机器人控制技术。

E-mail: peiying.chen@ia.ac.cn

(**ZHANG Dao-Hui** Associate professor at Shenyang Institute of

Automation, Chinese Academy of Sciences. He received his Ph.D. degree from University of Chinese Academy of Sciences in 2018. His research interest covers robot control technology.)



韩建达 南开大学人工智能学院教授, 中国科学院沈阳自动化研究所研究员。1998 年获得哈尔滨工业大学博士学位。主要研究方向为可穿戴机器人, 智能系统, 移动机器人自主控制。

E-mail: hanjianda@nankai.edu.cn

(**HAN Jan-Da** Professor at the

College of Artificial Intelligence, Nankai University, and Shenyang Institute of Automation, Chinese Academy of Sciences. He received his Ph.D. degree from Harbin Institute of Technology in 1998. His research interest covers wearable robots, intelligent systems, and control for the autonomy of mobile robots.)