

DOI: 10.19650/j.cnki.cjsi.2006726

一种基于单通道 sEMG 分解与 LSTM 神经网络 相结合的手势识别方法*

张 松^{1,2}, 李江涛^{1,2}, 别东洋^{1,2}, 韩建达^{1,2}

(1. 南开大学人工智能学院 天津 300350; 2. 南开大学 天津市智能机器人技术重点实验室 天津 300350)

摘 要:在基于表面肌电(sEMG)信号的动作识别中,使用单通道传感器能够简化系统、减少识别延时,但也存在识别精度偏低的问题。为了提高识别精度,本文提出将单通道 sEMG 信号分解策略与长短期记忆(LSTM)循环神经网络识别相结合的方法。在该方法中,先将单通道 sEMG 信号分解成多通道运动单元动作电位序列(MUAPTs),然后提取 MUAPTs 的特征,最后将这些特征对 LSTM 分类模型进行训练。为了验证该方法的有效性,本文以手势动作识别为对象,对 6 名受试者分别建立了 4 种分类模型,包括基于未分解信号的支持向量机(SVM)、基于分解信号的 SVM、基于未分解信号的 LSTM、以及本文提出的基于分解信号的 LSTM,并定义识别精度量化指标对这四种模型进行分类结果进行评估。对于旋前方肌 sEMG 信号,在使用本文所提方法进行手势识别时,平均估计精度均能达到 90% 以上,比未分解的 LSTM 高 18.7%,比分解信号的 SVM 高 4.17%,比未分解信号的 SVM 高 11.53%。实验结果验证了本文所提方法的有效性。

关键词:单通道表面肌电信号;分解;长短期记忆循环神经网络;手势识别

中图分类号:TP391.4 TH89 **文献标识码:**A **国家标准学科分类代码:**510.40

Gesture recognition by Single-Channel sEMG Decomposition and LSTM Network

Zhang Song^{1,2}, Li Jiangtao^{1,2}, Bie Dongyang^{1,2}, Han Jianda^{1,2}

(1. College of Artificial Intelligence, Nankai University, Tianjin 300350, China;

2. Tianjin Key Laboratory of Intelligent Robotics, Nankai University, Tianjin 300350, China)

Abstract:For motion recognition based on the surface electromyography (sEMG), reducing the channel number of sEMG electrodes could simplify the target hardware implementation, and improve the rapid response performance. However, it also has the disadvantage of coarse accuracy. In this study, we propose a sEMG recognition method by combining the single-channel sEMG decomposition and the long short-term memory (LSTM) recurrent neural networks. Firstly, the single-channel sEMG signals are decomposed into motor unit action potential trains (MUAPTs). Then, features are extracted from the MUAPTs, and set as inputs to train the LSTM classification model. Experiments are conducted on 6 candidates with respect to the gesture recognition scenario. Five gestures are considered as outputs of the model. Experimental results of the proposed method are extensively compared with those obtained by other three schemes, including support vector machine (SVM) with non-decomposition data, SVM with decomposed data, and LSTM with non-decomposition data. For the sEMG of Quadratipronator, the average classification accuracy is more than 90% using the proposed method. Compared with LSTM with non-decomposition data, SVM with decomposed data, and SVM with non-decomposition data, the accuracy of the proposed method is increased by 18.7%, 4.17%, and 11.53%, respectively. These results verify the efficacy of the proposed method.

Keywords:single-channel sEMG; decomposition; long short-term memory recurrent neural network; gesture recognition

收稿日期:2020-07-30 Received Date: 2020-07-30

* 基金项目:新一代人工智能重大专项(2018AAA0103003)、国家自然科学基金深圳联合基金重点项目(U1913208)、机器人技术与系统国家重点实验室开放研究项目(SKLR-2019-KF-01)资助

0 引言

假手能够帮助手部残疾患者实现部分操作功能,但基于传统控制方法的假手存在笨拙、不可靠的问题^[1]。表面肌电信号(surface electromyograph, sEMG)能够反映出人体的运动意图,将 sEMG 作为假手的控制信号,能够实现更为自然的假手控制^[2-3]。手势识别是机电假手控制中的一个重要研究内容。

为了获取较高的识别精度,人们通常使用多通道 sEMG 信号,提取其特征后进行手势识别^[4-6]。文献[7]利用八通道肌电传感器手环 MYO 采集手臂前段 sEMG 信号,并采用神经网络算法实现了 8 种手势及腕部动作的识别。文献[8]提出一种特征选取方法,使用 8 通道电极,对 6 种手势动作进行识别。文献[9]使用 3 通道的 sEMG 信息,采用小波神经网络,对 6 种手势动及手腕动作进行识别。文献[10]使用 5 通道 sEMG 传感器识别出 10 种手势及腕部动作。在这些研究中,手势识别精度均能达到 90% 以上。但随着电极数量的增多,一方面会加大系统的复杂度,增大动作识别的延时,不利于在线实现动作分类^[11];另一方面,会增大邻近电极之间在大幅度动作时产生碰撞的可能性,影响信号质量,增大分类难度。

有研究发现,无论对于分类问题还是回归问题,使用 sEMG 分解出的运动单元动作电位序列(motor unit action potential trains, MUAPTs)作为模型的输入,其预测效果明显好于使用未分解的信号^[12-13]。文献[14]提出一种将单通道 sEMG 信号分解成多通道 MUAPTs 的非监督学习方法。文献[15]中提出一种基于单通道 sEMG 信号分解的手势识别方法,仅使用指浅屈肌 sEMG 信号信息,并结合支持向量机分类器完成对 5 种动作的识别。虽然使用该方法能够使得平均分类精度达到 80%,高于未融合 sEMG 分解的传统算法,但仍然无法达到多通道信号的分类精度。

考虑到 sEMG 信号的时序性,当前时刻的信号不仅与当前时刻的动作有关,还与之前时刻的动作/信号相关。文献[16]分别使用前馈神经网络、循环神经网络、长短期记忆循环神经网络及门循环单元对 UC2018 DualMyo 数据集集中的 8 种手势及手腕动作进行分类,分类结果均达到 95% 以上。文献[17]使用长短期记忆循环神经网络映射出 sEMG 信号与手指连续动作之间的非线性关系。但在这些研究中,均使用多通道 sEMG 信号作为 LSTM 模型的输入。

本文提出一种基于单通道 sEMG 分解的 LSTM 循环神经网络方法,并针对 6 名受试者开展了 5 种手势动作识别实验研究。选取休息、握拳、伸掌、捏食指及捏中指

作为分类的目标动作。这 5 种手势动作是机电假手应用中除腕部动作外的常用动作,对其进行精确分类具有重要的现实意义^[18-19]。实验结果表明,本文提出的方法明显优于基于单通道未分解 sEMG 信号的 LSTM 方法,也优于基于分解信号的 SVM 方法。

1 方法

基于单通道 sEMG 信号分解的 LSTM 循环神经网络识别方法主要包括网络训练与后续应用两个阶段,而网络训练阶段主要包括:单通道 sEMG 信号分解成多通道 MUAPTs、MUAPTs 的特征提取、以及构建 LSTM 循环神经网络使用提取的特征进行动作识别,流程图如图 1 所示。




图1 本文所提方法流程图

Fig. 1 Flowchart of the proposed method

1.1 单通道 sEMG 分解方法

对于 sEMG 原始信号测试集 $\mathbf{X} = [x_1 \ x_2 \ \cdots \ x_N]$, 其中 $x_i, i = 1, 2, \dots, N$ 为采集的原始 sEMG 信号。

因原始 sEMG 信号中存在噪声干扰,分解前需对原始 sEMG 信号进行预处理,本文采用二阶差分滤波器,来提高 sEMG 信号的信噪比,即:

$$y_i = x_{i+2} - x_{i+1} - x_i + x_{i-1} \quad (1)$$

式中: x_i 为原始 sEMG 信号; y_i 为滤波后 sEMG 信号。

单通道 sEMG 信号分解的主要任务是获取多个子通道运动单元动作序列(MUAPTs)。MUAPT 是由多个运动单元动作电位(MUAPs)组成。本文采用基于阈值的 MUAPs 检测方法^[20]:当 sEMG 信号的幅值超过某一阈值时,将被视为产生一个峰值;而低于这一阈值的部分被视为噪声,令其值为 0。阈值计算公式描述如下:

$$\mu = s \cdot \sqrt{\frac{1}{N} \sum_{i=1}^N y_i^2} \quad (2)$$

式中: μ 为阈值; s 为经验值,本文选取 2; N 为 sEMG 信号的数据点数量。

确定阈值 μ 后,在滤波后的肌电曲线上绘制两条值为 $\pm\mu$ 且与时间轴平行的基线。将由下向上穿越正基线或由上向下穿越负基线的点记为 y_i ,下一个由上向下穿越正基线或由下向上穿越负基线的点记为 y_j ,在 $[i,j]$ 之间存在一个峰值或谷值,记为 y_{peaki} 。

$$peaki = \arg \max_{i \leq k \leq j} \{|y_i|, \dots, |y_k|, \dots, |y_j|\} \quad (3)$$

式中: $peaki$ 为第 i 个峰值点位置。

将 $peaki$ 及其相邻的11个点视为一个运动单元:

$$MUAP_{peaki} = [y_{peaki-5}, \dots, y_{peaki}, \dots, y_{peaki+6}] \quad (4)$$

进一步,需要根据获取的 MUAPs 波形信息进行聚类,类别数即为最终分解的子通道数目。本文采用 k-means 聚类方法将 MUAPs 分解成 K 类,算法如下:

1) 选取聚类个数 K 。

2) 在 MUAPs 中随机选取 K 个样本点作为起始类别集合。

3) 分别计算剩余 MUAPs 与各起始类别中心点之间的欧式距离,依据最小距离进行归类。

4) 在完成所有样本的分类后,计算每一个类别中所包含的所有样本的均值,并将结果作为新的类别中心。

5) 重复第 3)、4) 步,对点簇的结构迭代更新,当样本点分布变化趋于零,得到 K 个 MUAP 类别。

最后,对于训练集 sEMG 信号,建立 K 个与原始信号等长的序列并与 MUAP 类别一一对应。在每个序列中的 MUAPs,将其置于原始 sEMG 信号序列中的位置,其余位置设为零。进而形成 K 个通道的 MUAPTs。

1.2 子通道 MUSPTs 特征提取

单通道 sEMG 信号分解成多个子通道 MUAPTs 后,需对 MUAPTs 进行特征提取并用于手势动作的识别。sEMG 信号常用提取方法包括:时域特征提取、频域特征提取及时频域特征提取等^[21]。考虑计算复杂度对运算时间的影响,本文采用两种常见的时域特征:绝对值均值(mean absolute value, MAV)和过零点数(zero crossing, ZC)。

1) 绝对值均值

$$MAV_i = \frac{1}{N} \sum_{j=i-N+1}^i |x_j| \quad (5)$$

式中: x_i 为当前时刻 MUAPTs 序列数据, N 为时间窗长度。

2) 过零点数

$$ZC_i = \sum_{j=i-N+1}^i \text{sgn}(x_j x_{j-1}) \quad \text{sgn}(x) = \begin{cases} 1, & x < 0 \\ 0, & x \geq 0 \end{cases} \quad (6)$$

手势识别的输入端为:

$$\begin{bmatrix} MAV_1^1 & ZC_1^1 & \dots & MAV_1^k & ZC_1^k & \dots & MAV_1^m & ZC_1^m \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ MAV_n^1 & ZC_n^1 & \dots & MAV_n^k & ZC_n^k & \dots & MAV_n^m & ZC_n^m \end{bmatrix}_{n \times 2m} \quad (7)$$

式中:上标代表第几个 MUAPT,下标代表时刻。如: MAV_i^k 代表第 k 个 MUAPT 在第 i 时刻的绝对值均值特征。

1.3 长短期记忆循环神经网络分类模型构建

考虑到 sEMG 信号的时序性,本文提出一种使用 LSTM 循环神经网络的方法,将前一时刻输出的记忆输送到下一时刻,进行动作的分类识别。

LSTM 网络结构如图 2 所示, x_k 为 k 时刻输入, $x_k = [MAV_k^1 \ ZC_k^1 \ \dots \ MAV_k^m]$; y_k 为 k 时刻估计的动作。在本文中, $y_k = \{\text{休息, 握拳, 伸掌, 捏食指, 捏中指}\}$ 。 y_k 的输出由 x_k 、上一时刻输出 y_{k-1} 以及单元状态 c 共同决定。LSTM 网络在结构上使用遗忘门、输入门和输出门,来保存长期的状态。

单元状态 c 的内容由两个门控制,一个是遗忘门,决定上一时刻的单元状态有多少需要保留到当前时刻;另一个是输入门,决定当前网络的输入有多少需要保存到单元状态。输出门的作用则是控制当前单元状态需要输出到当前的输出值数量。各个神经元的输出计算如式(8)~(13)。

遗忘门的输出为:

$$g^i = \sigma(w^i[x_k, y_{k-1}]) \quad (8)$$

其中, g^i 为遗忘门的输出, w^i 为遗忘门的权重矩阵。




图 2 LSTM 结构

Fig. 2 Structure of the LSTM

$$g^f = \sigma(w^f[x_k, y_{k-1}]) \quad (9)$$

其中, g^f 为输入门的输出, w^f 为输入门的权重矩阵。

$$g^c = \tanh(w^c[x_k, y_{k-1}]) \quad (10)$$

其中, g^c 为当前的输入状态, w^c 为输入状态的权重矩阵。

$$c_k = g^f \circ g^c + g^i \circ c_{k-1} \quad (11)$$

其中, c_k 为当前状态输出。

$$g^o = \sigma(w^o[x_k, y_{k-1}]) \quad (12)$$

其中, g^o 为输出门输出, w^o 为输出门的权重矩阵。

最终的输出动作由当前 sEMG 信号的特征、前一时

刻输出以及当前单元状态共同确定的,即

$$\mathbf{y}_k = \mathbf{g}^o \circ \tanh(\mathbf{c}_k) \quad (13)$$

并建立目标方程:

$$E = \frac{1}{N} \sum_{k=1}^N e_k, \quad e_k = \begin{cases} 1, & \mathbf{y}_k \neq \hat{\mathbf{y}}_k \\ 0, & \mathbf{y}_k = \hat{\mathbf{y}}_k \end{cases} \quad (14)$$

其中, $\hat{\mathbf{y}}_k$ 为真实手势类别。

在对 LSTM 网络进行训练时,根据目标方程计算输出误差,利用反向传播算法计算出每个神经元的误差项值,最后根据相应的误差项,计算每个权重的梯度。

2 实验及结果

2.1 实验过程

本文采用基于单通道 sEMG 信号的手势识别实验来验证所提方法的有效性。实验平台如图 3 所示,主要包括无线肌电传感器、传感器基站以及上位机采集软件等。6 名肢体健康的受试者参与实验。实验过程中,分别在每名受试者小臂的旋前方肌、示指伸肌以及指浅屈肌位置上粘贴肌电传感器(位置如图 4 所示),要求每名受试者依次完成伸掌、握拳、捏食指、捏中指的动作,手势顺序如图 5 所示。每名受试者进行 10 组实验,每组实验中依次完成上述动作,每个动作持续 3 s。为了防止肌肉疲劳,每组实验之间休息 1 min。我们将前 7 组实验数据作为训练集,用来训练模型;其余 3 组数据作为测试集,用来评价分类方法。




图3 实验平台

Fig.3 Experimental setup




图4 传感器位置

Fig.4 Locations of sEMG sensors




图5 一组实验中的手势顺序

Fig.5 Gesture sequence in test session

为了展示本文所提方法的有效性,我们分别将旋前方肌、示指伸肌以及指浅屈肌位置上的肌电信号作为单通道肌电信号,用本文所提出的基于分解的 LSTM 方法进行手势识别;并将识别结果与其他 3 种识别方法进行了比较,这 3 种方法分别是:基于单通道 sEMG 分解信号的支持向量机(support vector machine, SVM)、基于单通道 sEMG 未分解信号的 SVM、以及基于单通道 sEMG 未分解信号的 LSTM。

本文定义如下分类精度函数来对分类结果进行量化比对评估。

$$\eta = \frac{\sum_{i=1}^N I(C_{prei} = C_i)}{N} \quad (15)$$

式中: I 为指示函数; η 为分类精度; N 为测试集样本总数; C_{prei} 为第 i 个样本的估计类别; C_i 为第 i 个样本的实际类别。

2.2 实验结果

按照前述方法,首先将 K-means 算法中的 K 值设置为 5,每块肌肉可分解得到 5 个 MUAPTs。受试者-1 的 5 个 MUAPTs 如图 6 所示。

本文采用 128 ms 的时间窗和 32 ms 的增量窗,分别提取各 MUAPTs 的绝对值均值和过零点特征。以这些特征作为输入、对应的手势作为输出,分别建立每名受试者每块肌肉的 SVM 分类器以及 LSTM 循环神经网络分类模型。受试者-1 的分类结果如图 7 所示;图 7 中实线为真实动作类别,虚线表示算法识别动作类别,实线与虚线重合的越多,说明预测正确的动作越多。从图 7 中可以明显看到,基于旋前方肌 sEMG 信号分解的 LSTM 循环神经网络预测出的正确动作最多。而基于示指伸肌 sEMG 未分解的 SVM 预测出的正确动作最少。

根据式(15)计算出 6 名受试者的平均分类精度如表 1 及图 8 所示。基于旋前方肌 sEMG 分解信号的 LSTM 的平均分类精度最高,达到 90% 以上,能够达到基于多通道 sEMG 信号的分类精度,验证了本文所提方法的有效性。而对于示指伸肌而言,无论基于分解的 sEMG 信号还是未分解的 sEMG 信号,分类效果均不佳,分类精度不足 80%。基于不同肌肉 sEMG 信号的分类结果相差较大,就本文所选取的 3 种肌肉而言,旋前方肌的 sEMG 信号在 5 种动作中,信号差异明显,易于分类;而示指伸肌和指浅屈肌 sEMG 信号的特征在 5 种动作中差异性






图6 受试者-1单通道 sEMG 信号分解得到的 MUAPTs

Fig. 6 Decomposed MUAPTs from the single-channel sEMG signals of candidate-1




(a) 基于单通道sEMG分解信号的LSTM分类结果

(a) Classification results by LSTM based on decomposed single-channel sEMG signals




(b) 基于单通道sEMG未分解信号的LSTM分类结果

(b) Classification results by LSTM based on undecomposed single-channel sEMG signals



(c) 基于单通道sEMG分解信号的SVM分类结果
(c) Classification results by SVM based on decomposed single-channel sEMG signals



(d) 基于单通道sEMG未分解信号的SVM分类结果
(d) Classification results by SVM based on undecomposed

图7 分类结果

Fig. 7 Results of classification

表1 手势识别分类结果

Table 1 Results of gesture recognition

%

受试者 编号	旋前方肌				示指伸肌				指浅屈肌			
	LSTM -分解	LSTM -未分解	SVM -分解	SVM -未分解	LSTM -分解	LSTM -未分解	SVM -分解	SVM -未分解	LSTM -分解	LSTM -未分解	SVM -分解	SVM -未分解
1	93.53	79.97	80.7	74	76.83	73.3	76	74.2	86.63	66.23	76.5	70.53
2	89.17	84.6	75.03	74.53	71.72	76.93	74.27	70.07	81.13	67.83	75.63	70.37
3	91.37	70.73	76.83	73.47	64.37	65	71.53	69.73	80.4	66.33	73.2	67.23
4	90.7	68.16	89.47	80.27	77.46	69.57	79.87	73.5	78.01	67.2	87	76.97
5	86.5	71.12	84.33	82.13	77.37	73.18	81	79.4	85.05	70.96	84	72.77
6	90.3	61.8	78.3	79.33	75.72	60.79	75.9	68.2	78.95	50	79.67	66.03
均值	90.26	72.6	80.78	77.29	73.91	69.8	76.43	72.52	81.7	64.76	78.83	70.65

并不明显,容易产生误分类;其原因可能与肌肉动作的相关程度有关。此外,对3种肌肉而言,无论是使用LSTM分类模型还是SVM分类器,当模型输入为sEMG分解信号特征时,其分类精度都有所提高。这说明由单通道sEMG信号分解得到的MUAPs中包含了更丰富的运动信息。

另外应指出,将子通道MUAPs的数量选择为5,即K的取值为5,这并不代表一次手部动作仅仅募集5个运

动单元。我们依次将K-means聚类算法中的K值设置为2,3,...,10。将3块肌肉sEMG信号分别分解为不同数量的运动单元,来分析K值对每一块肌肉最后的分类精度的影响,并将结果进行对比,具体结果如图9所示。从图9中可以看出在完成手部动作时,不同肌肉中起主导作用的神经元个数是不同的。此外,在各个分解通道上,基于旋前方肌sEMG信号的分类精度基本上最高,基于示指伸肌sEMG信号的分类精度最低。由此可得出,旋




图8 平均分类精度

Fig. 8 Average accuracy of classification




图9 子通道 MUAPTs 数量与分类精度之间的关系

Fig. 9 The relationship between the sub-channels number and classification accuracy

前方肌对手部动作识别的敏感度最高,指浅屈肌次之,而示指深肌最不敏感。

3 结 论

本文提出了一种基于单通道 sEMG 信号分解的 LSTM 循环网络动作识别方法,用来提高基础手势动作的识别精度。该方法将单通道 sEMG 信号分解成多通道 MUAPTs,以获取更多的运动信息。对这些 MUAPTs 进行特征提取,通过搭建 LSTM 网络建立这些特征与运动的映射关系。针对手势识别的实验结果表明,对于旋前方肌 sEMG 信号,在使用该方法进行 5 种手势识别时,平均估计精度能达到 90% 以上。比较结果显示,基于分解信号的 LSTM 平均估计精度比未分解信号的 LSTM 高 18.7%,比分解信号的 SVM 高 4.17%,比未分解的 SVM 高 11.53%。在使用单通道 sEMG 信号的情况下,本文旨在提出一种能够提高基础手势动作识别精度的方法,对于手腕运动的识别将会在下一步的工作中进行研究。

参考文献

- [1] 戴廷飞,刘邈,叶阳阳,等. 人机共享控制机器人系统的应用与发展[J]. 仪器仪表学报, 2019, 40(3): 62-73.
DAI T F, LIU M, YE Y Y, et al. Application and development of human-machine shared control robot system[J]. Chinese Journal of Scientific Instrument, 2019, 40(3): 62-73.
- [2] 吴常铨,宋爱国,曾洪,等. 基于 sEMG 和 GRNN 的手部输出力估计[J]. 仪器仪表学报, 2017, 38(1): 97-104.
WU CH CH, SONG AI G, ZENG H, et al. Force estimation based on sEMG and GRNN[J]. Chinese Journal of Scientific Instrument, 2017, 38(1): 97-104.
- [3] CÔTÉ-ALLARD U, FALL C, DROUIN A, et al. Deep learning for electromyographic hand gesture signal classification using transfer learning[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2019, 27(4): 760-771.
- [4] QI J, JIANG G, LI G, et al. Surface EMG hand gesture recognition system based on PCA and GRNN[J]. Neural Computing and Applications, 2020, 32(10): 6343-6351.
- [5] KIM M, CHUNG W K. Spatial sEMG pattern-based finger motion estimation in a small area using a microneedle-based high-density interface[J]. IEEE Robotics and Automation Letters, 2017, 3(1): 234-241.
- [6] SAYIN F S, OZEN S, BASPINAR U. Hand gesture recognition by using semg signals for human machine interaction applications[C]. 2018 Signal processing: Algorithms, architectures, arrangements, and applications (SPA), IEEE, 2018: 27-30.
- [7] 胡旭晖,宋爱国,李会军. 基于表面肌电图像的灵巧假手控制系统[J]. 控制理论与应用, 2018, 35(12): 1707-1714.
HU X H, SONG AI G, LI H J. Dexterous robots hand control system based on surface electromyography image[J]. Control Theory & Applications, 2018, 35(12): 1707-1714.
- [8] JUNIOR J, FREITAS M, SIQUEIRA H, et al. Feature selection and dimensionality reduction: An extensive comparison in hand gesture classification by sEMG in eight channels armband approach[J]. Biomedical Signal Processing and Control, 2020, 59: 101920.
- [9] DUAN F, DAI L. Recognizing the gradual changes in sEMG characteristics based on incremental learning of wavelet neural network ensemble[J]. IEEE Transactions on Industrial Electronics, 2017, 64(5): 4276-4286.
- [10] DING Q CH, ZHAO X G, HAN J D, et al. Adaptive

- hybrid classifier for myoelectric pattern recognition against the interferences of outlier motion, muscle fatigue, and electrode doffing [J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2019, 27(5): 1071-1080.
- [11] NAIK G, AL-TIMEMY A, NHUYEN H. Transradial amputee gesture classification using an optimal number of sEMG sensors: An approach using ICA clustering[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2016, 24(8): 837-846.
- [12] CHEN C, CHAI G, GUO W C, et al. Prediction of finger kinematics from discharge timings of motor units: Implications for intuitive control of myoelectric prostheses[J]. Journal of Neural Engineering, 2019, 16(2): 26005.
- [13] MUCELI S, JIANG N, FARINA D. Extracting signals robust to electrode number and shift for online simultaneous and proportional myoelectric control by factorization algorithms[J]. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 2014, 22(3): 623-633.
- [14] SUN W, ZHU J, JING Y, et al. One-channel surface electromyography decomposition for muscle force estimation[J]. Frontiers in Neurorobotics, 2018, 12: 20.
- [15] 熊安斌, 丁其川, 赵新刚, 等. 基于单通道 sEMG 分解的手部动作识别方法[J]. 机械工程学报, 2016, 52(7): 6-13.
- XIONG AN B, DING Q CH, ZHAO X G, et al. Classification of hand gestures based on single-channel sEMG decomposition [J]. Journal of Mechanical Engineering, 2016, 52(7): 6-13.
- [16] SIMAO M, NETO P, GIBARU O. EMG-based online classification of gestures with recurrent neural networks[J]. Pattern Recognition Letters, 2019, 128: 45-51.
- [17] QUIVIRA F, KOILE-AKINO T, WANG Y, et al. Translating sEMG signals to continuous hand poses using recurrent neural networks [C]. 2018 IEEE EMBS International Conference on Biomedical & Health Informatics (BHI), 2018: 166-169.
- [18] PARK S, CHUNG W K, KIM K. Training-free bayesian self-adaptive classification for sEMG pattern recognition including motion transition [J]. IEEE Transactions on Biomedical Engineering, 2019, 67(6): 1775-1786.
- [19] DUAN F, DAI L, CHANG W, et al. sEMG-based identification of hand motion commands using wavelet neural network combined with discrete wavelet transform[J]. IEEE Transactions on Industrial Electronics, 2016, 63(3): 1923-1934.
- [20] STASHUK D W. Decomposition and quantitative analysis of clinical electromyographic signals [J]. Medical Engineering & Physics, 1999, 21(6): 389-404.
- [21] 石欣, 朱家庆, 秦鹏杰, 等. 基于改进能量核的下肢表面肌电信号特征提取方法[J]. 仪器仪表学报, 2020, 41(1): 121-128.
- SHI X, ZHU J Q, QIN P J, et al. Feature extraction method of lower limb surface EMG signal based on improved energy nucleus [J]. Chinese Journal of Scientific Instrument, 2020, 41(1): 121-128.

作者简介



张松, 2012 年于东北林业大学获学士学位, 2016 年于哈尔滨工程大学获硕士学位, 现在南开大学攻读博士学位, 主要研究方向为肌电信号处理和模式识别。

E-mail: zhangsongnefu@163.com

Zhang Song received her B. Sc. degree from Northeast Forestry University in 2012, and received her M. Sc. degree from Harbin Engineering University in 2016. She is currently pursuing her Ph. D. degree at Nankai University. Her main research interests include surface electromyography signal processing and pattern recognition.



韩建达 (通信作者), 1990 年于西安交通大学获得学士学位, 1994 年于中国科学院沈阳自动化研究所获得硕士学位, 1998 年于哈尔滨工业大学获得博士学位, 现为南开大学杰出教授、博士生导师, 主要研究方向为机器人自主行为与人接协作/共融方法, 医疗康复机器人、地面移动及飞行机器人技术与系统。

E-mail: hanjianda@nankai.edu.cn

Han Jianda (Corresponding author) received his B. Sc. degree from Xi'an Jiaotong University in 1990, received his M. Sc. degree from Shenyang Institute of Automation, Chinese Academy of Sciences in 1994, and received his Ph. D. degree from Harbin Institute of Technology in 1998. He is currently an outstanding professor and a Ph. D. advisor at Nankai University. His main research interests include robot autonomy and human-robot coordination, medical and rehabilitation robotics, mobile and flying robotics.