

DOI:10.19322/j.cnki.issn.1006-4710.2023.04.007

<https://xuebao.xaut.edu.cn>

引文格式:刘永,宁蕊,李言,杨明顺,高新勤.用于装配动作识别的肌电信号特征优化选择方法[J].西安理工大学学报,2023,39(4):513-520.

LIU Yong, NING Rui, LI Yan, YANG Mingshun, GAO Xinqin. Optimal selection method of electromyographic signal features for assembly gesture recognition [J]. Journal of Xi'an University of Technology, 2023, 39(4): 513-520.

用于装配动作识别的肌电信号特征优化选择方法

刘永, 宁蕊, 李言, 杨明顺, 高新勤

(西安理工大学 机械与精密仪器工程学院, 陕西 西安 710048)

摘要: 在采用机器学习方法进行动作识别的研究中,识别的准确率很大程度上取决于输入数据的特征。针对基于表面肌电信号的作业动作识别,进行了特征分析与优化选择方法研究。在对采集的作业手臂肌电信号进行平滑处理的基础上,定义并提取了肌电信号时域、频域及时频域的15个特征量;将从8个通道肌电信号的每帧数据中计算获得的120个特征值用于手势姿态的表征,并进行了归一化处理;使用极限梯度提升(XGBoost)算法和单变量特征选择(UFS)算法分别从特征量和特征值两个角度对所得信号特征进行识别贡献度的分析。分析结果表明,两种方法均可大幅消减冗余特征,并且能有效提高最终的识别准确率,其中采用UFS算法选取的特征在识别速度和准确度上更具优势。

关键词: 动作识别; 表面肌电信号; 特征选择; 极限梯度提升算法; 单变量特征选择算法

中图分类号: TN911.7; TP391.4 **文献标志码:** A **文章编号:** 1006-4710(2023)04-0513-08

Optimal selection method of electromyographic signal features for assembly gesture recognition

LIU Yong, NING Rui, LI Yan, YANG Mingshun, GAO Xinqin

(Faculty of Mechanical and Precision Instrument Engineering, Xi'an University of Technology,
Xi'an 710048, China)

Abstract: In the research on gesture recognition by using machine learning methods, the recognition accuracy largely depends on the characteristics of the input data. A feature analysis and optimization selection method are proposed for operating gesture recognition with the surface EMG signal. Based on the arm EMG signal which was acquired and smoothed, 15 feature parameters are defined and extracted in the time domain, frequency domain and time-frequency domain; 120 feature values are calculated for each frame data of 8 channels EMG signal and normalized to characterize a certain gesture; the extreme gradient boosting (XGBoost) algorithm and the univariate feature selection (UFS) algorithm are used to analyze the recognition contribution degree of the features from the two perspectives of feature parameters and feature value. The analytical results show that the two methods can not only greatly reduce redundant features, but also effectively improve the final recognition accuracy. The features selected by the UFS algorithm have more advantages in recognition speed and accuracy.

Key words: gesture recognition; surface EMG signal; feature selection; XGBoost; UFS

收稿日期: 2022-09-26; 网络首发日期: 2023-07-24

网络首发地址: <https://kns.cnki.net/kcms2/detail/61.1294.N.20230724.1327.002.html>

基金项目: 陕西省重点研发计划项目(2021SF-421, 2021SF-422); 陕西省现代装备绿色制造协同创新中心自主研发基金项目(102-451421003)

通信作者: 刘永,男,博士,副教授,研究方向为智能制造系统建模、优化、控制。E-mail: liuyong@xaut.edu.cn

近年来,手势识别技术得到了飞速发展,研究者们为了提高识别精度,从不同方面进行了诸多研究。表面肌电信号能够反映肌肉收缩的情况,通过分析表面肌电信号可以获得肢体的运动信息,加之其采集方便、仿生性好,在假肢控制、辅助诊断、人机交互等领域得到了广泛应用^[1]。利用表面肌电信号进行手势识别也是人机交互的一种重要方式,其研究过程主要包括数据采集预处理、特征提取和模式识别三个基本步骤。

为提高识别率,学者们研究了众多数据预处理方法,如采用启发式方法优化滤波器参数^[2]、利用短时傅里叶变换进行特征提取并结合主成分分析和扩散图进行降维处理^[3]、采用矢量表示肌电信号特征^[4]等,这些方法均是为了获得良好的特征量以优化识别模型的输入,从而达到提高识别准确率的目的。对于模式识别方法,学者们借助机器学习技术,如线性判别树、神经网络、贝叶斯、支持向量机等理论方法,进行了多种分类器的设计^[5],在不同的应用环境下取得了良好的识别效果。同时有研究表明,一个好的模式识别系统,其识别率很大程度上依赖于特征提取而非分类器^[6]。因此,特征提取及选择是手势识别中的一个重要部分。

目前,国内外学者针对特征提取及选择开展了大量研究,提出了诸多方法,例如时域法、频域法、时-频域法、参数模型分析方法以及非线性特征法等^[7-8]。在基于表面肌电信号的手势动作识别中,针对特征值选择方面,石欣等^[9]以下肢 10 块肌肉为研究对象,基于能量核思想,使用阈值矩阵计数方法提取运动状态下的肌肉总激活值作为特征,经反向传播(back propagation, BP)神经网络训练后,得到模型的平均识别精度高于常用的 5 种特征提取方法,达到 95.2%。刘聪等^[10]将利用滑动窗口生成的表面肌电信号图像作为模型的输入,使用双层注意力机制与多流卷积弱化无关信息,通过长短期记忆网络(long short-term memory, LSTM)对输入的特征进行时序上的激励,使网络在时间维度上拥有更强的学习能力,在 NinaPro 数据集上进行实验测试,其精度高于大多数主流模型。孔康等^[11]将采集的表面肌电信号的时频特征在具有较快收敛速度的 Meyer 小波包基下分解,用小波包分解的系数构造表面肌电信号的特征矩阵,并将其与进行了最小均方(least mean square, LMS)算法二次滤波的方差特征结合,作为最终特征表示,再使用 LSTM 进行分类识别,其准确率达到 93.87%。王红旗

等^[12]把采集的表面肌电信号在指定尺度及核函数的同一组正交小波包基下分解,用小波包多尺度分解的系数构造表面肌电信号的特征基向量,并通过正交规范化对特征空间进行重构,用重构特征向量的对偶坐标向量作为最终特征表示,有效简化了分类器的结构并提高了识别率。

不难发现,以上研究多集中在模式识别算法上,均是通过优化模式识别算法来提高模型识别精度。然而,对于同一种分类器,不同的特征会对分类结果及精度产生不同程度的影响^[13]。特征选择对机器学习至关重要,在大部分机器学习任务中,特征决定了学习效果的上限,模型的选择和组合只是无限逼近于这个上限。

在动作识别过程中,随着特征量的增加,识别的精度会有一定提高,但过多的特征输入会影响模型识别的准确率,也会导致训练时间大幅增加。因此,科学有效地选取特征是进行可靠分类的基础。本文基于装配作业环境下的手臂表面肌电信号,分别对时域、频域和时频域中常用的肌电信号特征进行分析,提出了基于极限梯度提升(extreme gradient boosting, XGBoost)算法和单变量特征选择(univariate feature selection, UFS)算法的特征量评定方法,以期获得对识别精度有主要贡献的特征量,从而达到消除冗余特征、减少训练时间、增强模型泛化能力及减少过拟合的目的,使得手势识别准确率及效率得以进一步提升。

1 肌电信号数据采集及预处理

本文以减速器装配过程涉及的基本作业动作为研究对象,将其分解为表 1 所示的基本动素手势,通过手臂肌电信号采集分析,获取基本动素的手势特征,进而利用机器学习算法完成动素的识别。

本文使用 Thalmic Labs 实验室推出的 MYO 臂环进行数据采集,该臂环佩戴在前臂肘腕肌位置,手臂自然垂下时 1 号电极与中指成一线;采集得到 9 种动作的 8 个通道表面肌电信号量化数据,数值分布在 ± 128 内;利用 Butterworth 带通滤波器对其进行滤波,并采用移动平均能量法进行活动段检测,对活动段内的肌电信号进行时域、频域及时频域特征的提取,完成数据空间的降维处理。对于不同的手势动作,不同特征的特征显著性也不同,因此需要进一步优化选择有效的数据特征。本文研究的基本流程如图 1 所示。

表1 基本手势动作
Tab.1 Basic gestures

序号	手势	描述	示例
0	休息	放松	
1	手腕内翻	五指全部伸直并拢,手掌整体向下弯曲	
2	手腕外翻	五指全部伸直并拢,手掌整体向上弯曲	
3	精密抓	食指和拇指捏取微小零部件	
4	三指抓	中指、食指和拇指抓取较小零部件	
5	五指抓	五指抓取较大的零部件	
6	钩形抓	手持回钩状抓取体积较大或可拉提的零部件	
7	掌心抓	掌心抓取较小的立体零部件	
8	强力抓	握持抓取柱状零部件	

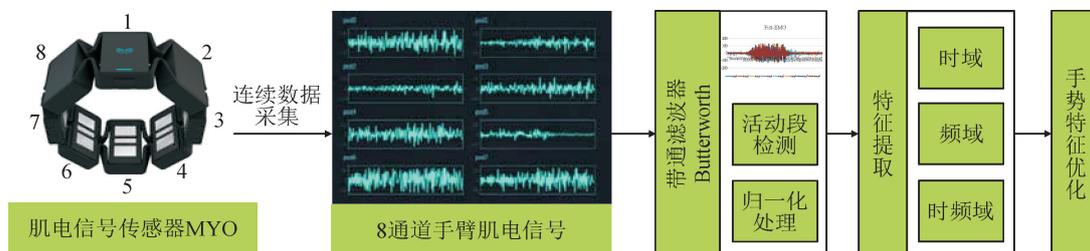


图1 肌电信号采集与预处理过程

Fig.1 EMG signal acquisition and preprocessing process

$$ma v_i = \frac{1}{N_w} \sum_{k=1}^{N_w} |x_{ik}| \quad (1)$$

2) 方差(variance):用来描述每个变量与总体样本之间的差异。在对肌电信号能量变化的判断中,将肌电信号的振幅看作是平稳性和正态分布的过程,从而反映不同动作之间的差异。

$$var_i = \frac{1}{N_w - 1} \sum_{k=1}^{N_w} (x_{ik} - \overline{x_{iw}})^2 \quad (2)$$

3) 均方根(root mean square):描述了整体肌电信号幅度的变化。

$$rms_i = \sqrt{\frac{1}{N_w} \sum_{k=1}^{N_w} x_{ik}^2} \quad (3)$$

4) 波形长度(waveform length):描述了信号波

为了保证实验数据的可靠性,召集 10 位身体健康没有任何肌肉神经疾病的受试者进行 9 种基本手势动作的肌电信号采集。每种手势动作保持 5 s,休息 10 s,9 种动作为一组,每组做完后休息 1 min,每组动作做 5 次,共 450 组肌电信号。将所有信号随机分为两部分,50%作为训练集,50%作为测试集。

2 表面肌电信号特征提取

为了获得最佳的动作表征特征量,本文基于信号处理的相关研究成果,分别从时域、频域和时频域多个维度提取了 15 个特征量。在此,对时域、频域特征值的符号变量进行统一定义:

i 为原始肌电信号分段数据序列中第 i 个通道, $i = 1, 2, \dots, 8$;

x_{ik} 为通道 i 中的第 k 个原始数据;

$\overline{x_{iw}}$ 为通道 i 中样本的均值;

N_w 为滑动窗口宽度,即活动段内的数据量;

$P_i(f)$ 为通道 i 的功率谱密度函数;

f_{ie} 为通道 i 的中值频率。

2.1 时域特征量

1) 平均绝对值(mean absolute value):描述信号的幅值大小。根据肌电信号的活动强度来判断幅度的变化,从而区分不同的手势动作。

形在空间上的周期性。

$$wl_i = \frac{1}{N_w} \sum_{k=1}^{N_w-1} |x_{ik} - x_{i(k+1)}| \quad (4)$$

5) 斜率变化数(slope sign changes):统计描述波峰波谷的个数。

$$ssc_i = \frac{1}{N_w} \sum_{k=1}^{N_w-1} f_{ik} \quad (5)$$

$$f_{ik} = \begin{cases} 1, & (x_{ik} - x_{i(k-1)})(x_{ik} - x_{i(k+1)}) > \delta \\ 0, & \text{其他} \end{cases}$$

式中: δ 为阈值,用来减少由噪声引起的对斜率变化数的干扰。

6) 过零点(zero cross):描述表面肌电信号波动的情况,即表面肌电信号的波形通过坐标零轴的次数。

$$z c_i = \frac{1}{N_w} \sum_{k=1}^{N_w-1} f_{ik} \quad (6)$$

$$f_{ik} = \begin{cases} 1, & x_{ik} x_{i(k-1)} < 0, |x_{ik} - x_{i(k+1)}| > \epsilon \\ 0, & \text{其他} \end{cases}$$

式中: ϵ 为阈值,用来减少由噪声引起的对过零点数的干扰。

7) 偏度(skewness):用来描述信号数据分布的对称性。

$$skew_i = \frac{\frac{1}{N_w} \sum_{k=1}^{N_w} (x_{ik} - \overline{x_{iw}})^3}{\left(\frac{1}{N_w} \sum_{k=1}^{N_w} (x_{ik} - \overline{x_{iw}})^2\right)^{\frac{3}{2}}} \quad (7)$$

8) 峰度(kurtosis):反映了信号数据分布平滑或是陡峭的情况。

$$kurt_i = \frac{\frac{1}{N_w} \sum_{k=1}^{N_w} (x_{ik} - \overline{x_{iw}})^4}{\left(\frac{1}{N_w} \sum_{k=1}^{N_w} (x_{ik} - \overline{x_{iw}})^2\right)^2} \quad (8)$$

9) 积分肌电值(integral EMG):反映了信号在一定时间内、一定程度上参与活动的这些运动单元数量和每个单元的放电情况。

$$iemg_i = \sum_{k=1}^{N_w} |x_{ik}| \quad (9)$$

2.2 频域特征量

1) 平均功率频率(mean power frequency):反映的是肌电信号频率特征的生物指标。

$$mpf_i = \frac{\int_0^{+\infty} f \cdot P_i(f) df}{\int_0^{+\infty} P_i(f) df} \quad (10)$$

式中: f 为肌电信号频率。

2) 中值频率(median frequency):反映的是运动单元放电频率的中间值。

$$mf_i = \int_0^{f_{ie}} P_i(f) df = \int_{f_{ie}}^{+\infty} P_i(f) df = \frac{1}{2} \int_0^{+\infty} P_i(f) df \quad (11)$$

3) 峰值频率(peak frequency):反映了信号的最大功率,其大小与参与肌肉收缩的单元肌纤维数量有关。

$$pf_i = \max(f_{i1}, f_{i2}, f_{i3}, \dots, f_{iN}) \quad (12)$$

式中: f_{iN} 为通道 i 中单元 N 的肌电信号频率。

4) 总功率(total power):反映了自主神经功能张力水平,是功率谱密度之和。

$$tp_i = \sum_{k=1}^N P_i(f) \quad (13)$$

2.3 时频域特征量

将时域特征和频域特征结合起来的特征提取方法称之为时频域特征提取方法。时频域主要提取小波变换和小波包变换两种特征量。

1) 小波变换(wavelet transform):小波变换在时频两域都具有表征信号局部特征的能力,是一种窗口大小固定不变,但其形状、时间窗和频率窗都可以改变的时频局部化分析方法。通过改变尺度和平移参数,可以对信号进行多尺度的细化分析。给定信号 $x(t)$,小波变换被定义为:

$$C_a(b) = \int_{-\infty}^{+\infty} x(t) \cdot \varphi\left(\frac{t-b}{a}\right) dt \quad (14)$$

式中: a 为尺度参数; b 为平移参数; $\varphi(t)$ 为小波函数。

2) 小波包变换(wavelet packet transform):小波包变换是在小波变换的基础上,对信号进行更为细致的分析和重构的方法,是对小波变换的进一步优化,可以同时分解低频和高频信号^[14]。小波包分解的表达式为:

$$\begin{cases} W_k^{j+1,2n} = \sum_{l=1}^L h_{2l-k} W_l^{j,n} \\ W_k^{j+1,2n+1} = \sum_{l=1}^L g_{2l-k} W_l^{j,n} \end{cases} \quad (15)$$

式中: W 为小波包分解系数; n, j 为小波包节点, $n \neq j$; h 为高通滤波器滤波系数; g 为低通滤波器滤波系数; k, l 为分解层数, $k \neq l$; L 为分解总层数。例如, $W_l^{j,n}$ 表示 l 层上小波包节点 j 和小波包节点 n 的分解系数。

2.4 特征提取前后的处理

本文采用为序列信号添加滑动窗口的方法对表面肌电信号进行特征值提取。对信号取滑动窗口的基本方法如图2所示,定义窗口长度为 w ,然后以小于 w 的增量 s 进行平移滑动,再对每个窗口的信号值进行特征提取。这样不仅能削弱原始信号过于尖锐的地方,使之变得平滑,而且能较好地表现出作业动作特征的变化趋势。

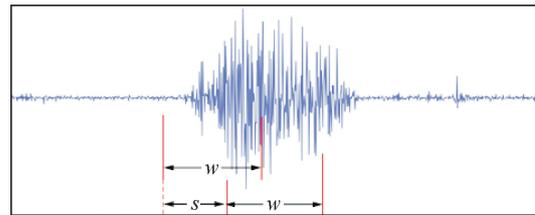


图2 滑动窗原理

Fig.2 Principle of sliding window

根据 Smith 等^[15]的研究,当窗口长度大于或等于 150 ms 且小于或等于 350 ms 时表现最佳。

MYO输出的肌电信号量化值在 $-128\sim 128$ 之间,采集信号频率为 200Hz ,故本文取窗口长度为 50 个序列点,滑动增量取 15 个序列点。

对于时域、频域和时频域特征,表面肌电信号对每个手势动作共提取了 15 种特征,由于MYO有 8 个通道,所以每个手势对应 $120(15\times 8)$ 个特征值。

特征提取之后,为了消除不同特征量之间的量纲影响,还需对其进行归一化处理。采用最大最小区间缩放法,通过特征最大值和最小值将所有的特征值缩放控制在 $0\sim 1$ 之间。利用该方法可以消除特征值之间的量纲影响,使其具有鲁棒性,同时也有利于不同量级的特征属性之间的加权和比较。归一化计算公式为:

$$x^* = a + (b - a) \times \frac{x - X_{\min}}{X_{\max} - X_{\min}} \quad (16)$$

式中: x 为原始数据; x^* 为归一化后的数据; a 为归一化规定范围的下界; b 为归一化规定范围的上界; X_{\max} 为样本数据的最大值; X_{\min} 为样本数据的最小值。

3 特征优化选择

在提取的 120 个特征值中,必定会存在一些冗余的信息,会对模型的训练造成干扰,导致模型训练时间长、泛化能力差、识别精度低等问题。因此,必须对这些特征进行优化选择,将无关特征从高维特征中剔除,降低特征维度、提高分类效率。

结合本文研究的多通道表面肌电信号的特点,提出一种针对特定通道选择特征值的特征选择方式。本文共采用两种方式进行特征选择,一种是按照各个通道的特征值进行选择,即在 120 个特征值里选择重要性程度高的特征值;另一种则是按照特征类型进行选择,即在 15 种特征量中选择重要性程度高的特征类型。结合本文研究内容的特点,采用XGBoost算法和UFS算法进行特征优选,对比两者的特征选择结果,选出较为合理的特征选择算法,来精简去除对识别结果无用或者影响不大的特征值。

3.1 XGBoost 特征选择方法

XGBoost是基于Gradient Boosting框架下实现的机器学习算法。对于给定的数据集 $D = \{(x_i, y_i)\}$,基于XGBoost算法采用以下函数对样本 y_i 进行预测:

$$\hat{y}_i = \sum_{k=1}^K f_k(X_i), f_k \in F \quad (17)$$

其中, f_k 表示回归树, K 为回归树的棵数, F 是树合集。通过多个决策树使预测值一步一步接近真实值,训练的目标函数为:

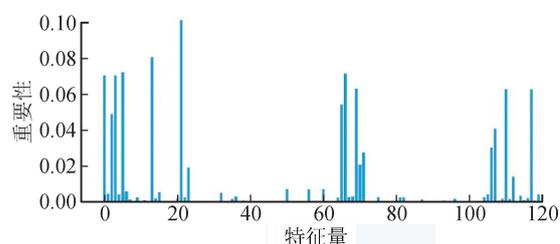
$$L(\varphi) = l(\varphi) + \Omega(\varphi) = \sum_i l(y, \hat{y}) + \sum_k \Omega(f_k) \quad (18)$$

其中, $l(\varphi)$ 为误差项, $\Omega(\varphi)$ 为正则化项。正则化项对每颗回归树的复杂度进行惩罚,衡量树的复杂度通常是根据树的深度、内部节点个数、叶子节点个数、叶子节点分数等来判断,XGBoost对叶子节点个数进行惩罚,相当于在训练过程中做了剪枝:

$$\Omega(\varphi) = \gamma T = \frac{1}{2} \lambda \|\omega\|^2 \quad (19)$$

其中, ω 为叶子节点分数, T 为叶子节点个数, γ, λ 用来增强模型控制过拟合的能力。

本文在进行特征选择时,期望得到各个特征的重要性排序,这样就可以知道哪些特征需要被保留,哪些可以舍弃。而XGBoost梯度提升算法在构建提升决策树模型时,如果多次使用某个特征,就可以说明该特征在该模型中的重要性程度较高,通过计算与提升决策树模型相关的每一个特征,并对其排序,就可以得到特征的重要性评分。本文利用Python调用XGBoost算法对这些特征值进行特征选择,结果如图3所示。



注:横坐标 $0\sim 119$ 依次表示 $mav_i, rms_i, var_i, ssc_i, wl_i, zc_i, skew_i, kurt_i, iemg_i, mf_i, mpf_i, pf_i, tp_i, wpt_i, wt_i$,其中 $i=1, 2, \dots, 8$ 。

图3 XGBoost算法特征选择

Fig. 3 XGBoost algorithm feature selection

图3中共有 120 个变量,从中选择出 54 个对识别结果有贡献率的特征,这 54 个特征及其重要性程度如表2所示。其中, wt 表示小波变换的特征量, wpt 表示小波包变换的特征量。

按每个通道特征值的贡献率及重要性,对 15 种特征量进行排序并选择,结果如图4所示。取重要性程度大于 5% 的特征量作为XGBoost算法的优选特征,即 $mav, iemg, wpt, var, rms, wt$ 共 6 种特征量,包含 48 个特征值。由此,特征量缩减到原来的 40% 。

表 2 特征重要性
Tab. 2 Importance of features

特征量	通道 1	通道 2	通道 3	通道 4	通道 5	通道 6	通道 7	通道 8
<i>mav</i>	0.070 3	0.004 2	0.048 8	0.070 4	0.003 9	0.072 1	0.005 4	0.001 0
<i>rms</i>	0.000 0	0.002 1	0.000 0	0.000 6	0.000 0	0.080 7	0.001 6	0.005 1
<i>var</i>	0.000 0	0.000 0	0.000 0	0.000 0	0.001 6	0.101 3	0.002 1	0.018 8
<i>ssc</i>	0.000 0	0.000 0	0.000 0	0.000 0	0.000 0	0.000 0	0.000 0	0.000 0
<i>wl</i>	0.004 8	0.000 0	0.000 0	0.001 1	0.002 7	0.000 0	0.000 4	0.000 0
<i>zc</i>	0.000 0	0.000 0	0.000 0	0.000 0	0.000 0	0.000 0	0.000 0	0.000 0
<i>skew</i>	0.000 0	0.000 0	0.006 7	0.000 0	0.000 0	0.000 0	0.000 0	0.000 0
<i>kurt</i>	0.006 6	0.000 0	0.000 0	0.000 0	0.006 7	0.000 0	0.000 0	0.000 0
<i>iemg</i>	0.002 0	0.054 1	0.071 4	0.002 3	0.002 6	0.062 9	0.020 5	0.027 3
<i>mf</i>	0.000 0	0.000 0	0.000 0	0.002 2	0.000 0	0.000 0	0.000 0	0.000 0
<i>mpf</i>	0.000 5	0.002 2	0.002 1	0.000 0	0.000 0	0.000 0	0.000 0	0.001 1
<i>pf</i>	0.000 0	0.000 0	0.000 0	0.000 0	0.000 0	0.000 3	0.000 0	0.000 0
<i>tp</i>	0.001 4	0.000 0	0.000 0	0.000 0	0.000 0	0.000 0	0.000 0	0.000 0
<i>wpt</i>	0.002 3	0.003 9	0.030 1	0.040 6	0.000 2	0.001 4	0.062 5	0.001 2
<i>wt</i>	0.013 8	0.000 0	0.003 1	0.000 7	0.001 8	0.062 6	0.000 3	0.003 9

注:黑体数值表示由 XGBoost 算法选择的有贡献率的特征的重要性程度。

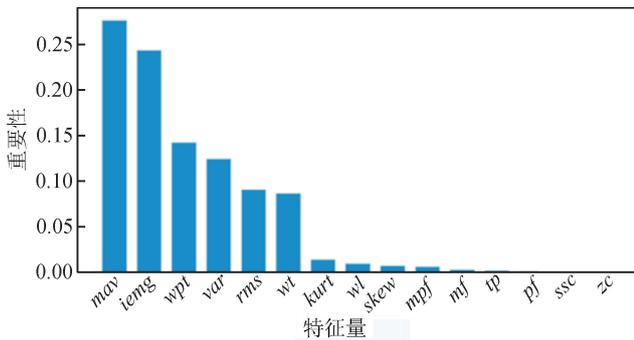
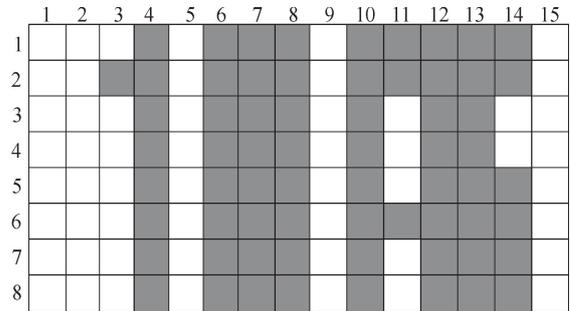


图 4 特征量重要性及排序
Fig. 4 Importance and ranking of the features

3.2 单变量特征选择方法

基于 UFS 的特征选择方法,其基本思想是分别计算每个变量的某一种统计指标,对每一个特征进行测试,衡量该特征和响应变量之间的关系,以此判断特征的重要性,最终根据得分剔除不重要的特征,进而达到提高识别速度、减少特征维度、减轻分类器工作负担的目的。

图 5 是调用 UFS 算法对 120 个特征值进行特征选择生成的结果。图中,白色和阴影方格组成了一个 15×8 的特征矩阵,对比白色部分和阴影部分,特征去除率约为 56.7%,缩减了一半以上的特征量。



注:纵坐标 1~8 表示 MYO 的 8 个通道;横坐标 1~15 表示 *mav*、*rms*、*var*、*ssc*、*wl*、*zc*、*skew*、*kurt*、*iemg*、*mf*、*mpf*、*pf*、*tp*、*wt*、*wpt* 15 个特征量;白色方格表示经过特征选择后留下的特征值;阴影方格表示被过滤掉的特征值。

图 5 单变量特征选择结果
Fig. 5 Result of univariate feature selection

3.3 特征选择结果对比

比较 XGBoost 算法和 UFS 算法所选的特征值和特征量,两者的结果存在较大差异。

按特征值来分析,XGBoost 和 UFS 算法分别从 120 个特征值里选出了 54 个特征值,包括时域、频域和时频域的特征值;但 XGBoost 选择的 54 种特征值涵盖了 13 种特征量,而 UFS 算法选择的 54 种特征值仅涵盖了 8 种特征量,特征种类更加精简。按特征量分析,XGBoost 算法选择了重要性程度大于 5% 的特征,包括 6 种特征量,分别为时域特征

$mav, iemg, var, rms$, 时频域特征 $\omega pt, \omega t$, 无频域特征量; UFS 算法保留了 7 种特征量, 分别为时域特征 $mav, rms, var, \omega l$, 频域特征 mpf , 时频域特征 $\omega pt, \omega t$ 。综合来看, 两种算法对频域特征的敏感性较低, 所选的优选特征多为时域特征和时频域特征。

为了直观体现两种算法的特征选择结果, 列表对其进行展示, 如表 3 所示。

表 3 两种算法特征选择结果

Tab. 3 Feature selection results by two algorithms

按特征值选择		按特征量选择	
XGBoost(54 个)	UFS(54 个)	XGBoost (6 种)	UFS (7 种)
$mav_i (i=1, 2, \dots, 8)$	$mav_i (i=1, 2, \dots, 8)$	mav	mav
$rms_i (i=2, 4, 6, 7, 8)$	$rms_i (i=1, 2, \dots, 8)$	rms	rms
$var_i (i=5, 6, 7, 8)$	$var_i (i=1, 3, 4, 5, 6, 7, 8)$	var	var
$\omega l_i (i=1, 4, 5, 7)$	$\omega l_i (i=1, 2, \dots, 8)$	$iemg$	ωl
$skew_3$	$iemg_i (i=1, 2, \dots, 8)$	ωpt	mpf
$kurt_i (i=1, 5)$	$mpf_i (i=3, 4, 5, 7, 8)$	ωt	ωpt
$iemg_i (i=1, 2, \dots, 8)$	$\omega pt_i (i=3, 4)$		ωt
mf_4	$\omega t_i (i=1, 2, \dots, 8)$		
$mpf_i (i=1, 2, 3, 8)$			
pf_6			
tp_1			
$\omega pt_i (i=1, 2, \dots, 8)$			
$\omega t_i (i=1, 3, 4, 5, 6, 7, 8)$			

本文采用 3 种常用的模式识别算法 (KNN、SVM、MLP) 对 450 组肌电信号进行训练, 60% 作为训练集, 40% 作为测试集。分别按照表 3 中的 4 种特征选择结果进行识别, 识别结果如表 4 所示。

表 4 XGBoost 和 UFS 算法结果分析

Tab. 4 XGBoost and UFS algorithm results analysis

特征选择方式		KNN	SVM	MLP
特征值	XGBoost	0.929	1	1
	UFS	0.947	1	1
特征量	XGBoost	0.929	1	1
	UFS	0.947	1	1

从表 4 中可以看出, 无论使用特征值还是特征量进行动作识别, 经由 UFS 算法优选特征的识别准确率均高于 XGBoost 算法。因此, 本文采用 UFS 算法进行显著特征提取。将使用全部特征的识别结果与使用 UFS 算法优选后的特征的识别结果进行

对比分析, 如表 5 所示。可以看出经由 UFS 方法优选后, 识别率有了大幅提高, 最高可达 100%, 同时模型训练学习的速度提高了 50% 以上。这充分证明了优选特征有助于提高模型的学习速度和识别率。

表 5 无特征选择与特征选择结果对比

Tab. 5 Comparison results of no feature selection and feature selection

机器学习算法	使用全部特征		使用 UFS 优选后的特征	
	准确率	学习速度/s	准确率	学习速度/s
KNN	0.929	0.258	0.947	0.109
SVM	0.963	0.271	1	0.136
MLP	0.982	0.916	1	0.327

4 结 论

本文针对装配作业中减速器装配涉及的 9 种基本动作, 使用 MYO 智能手势控制臂环, 对手臂表面肌电信号进行采集预处理、特征提取和选择, 并获得了良好的动作识别效果, 对肌电信号识别的具体实现具有重要意义。

1) 利用表面肌电信号研究了手势姿态的表征方法, 对时域、频域和时频域中的 15 个特征量, 共计来自 8 个肌电信号采集通道的 120 个特征值进行了分析处理, 构建了作业手势的有效表征数据集, 用于手势动作的准确识别。

2) 通过 XGBoost 算法和 UFS 算法对提取的 120 个特征值和 15 种特征量分别进行了重要性评测, 从不同角度获得了特征的重要度, 特征量最高缩减到原来的 40%, 大大减少了数据处理量。

3) 结合常见的机器学习算法, 通过动作识别实验证明, 经 UFS 算法优化后, 不但减少了特征量的输入, 同时提高了机器学习模型的总体性能, 识别准确率最高提升 4%, 学习速度提升 50% 以上。

然而, 单变量特征选择算法没有关注特征之间的关联性, 只根据每个特征与目标变量之间的显性关系进行特征选择, 这可能导致选择的特征仍存在冗余并且判别性不足。因此, 在后续的研究中可以针对该问题先对特征进行聚类, 筛选分布差异相近的特征, 然后基于深度学习算法训练一组可学习的特征权重, 随着训练的进行不断更新特征权重, 以实现特征的自动选择。另外, 为了增强模型的特征选择能力, 可借用注意力机制使模型更多关注于对整体影响更大的特征, 进而提升动作姿态识别的效率和精度。

参考文献:

- [1] 裴晓敏, 宋佳强, 曹江涛, 等. 基于 MEMD 和 TK 能量算子的肌电信号手势识别[J]. 电子测量与仪器学报, 2021, 35(1): 82-87.
PEI Xiaomin, SONG Jiaqiang, CAO Jiangtao, et al. Surface EMG signal hand motion recognition based on MEMD and TK energy operators[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(1): 82-87.
- [2] NAGASIRISHA B, PRASAD V V K D V. EMG signal denoising using adaptive filters through hybrid optimization algorithms[J]. Biomedical Engineering: Applications, Basis and Communications, 2021, 33(2): 2150009.
- [3] RABIN N, KAHLON M, SARIT M, et al. Classification of human hand movements based on EMG signals using nonlinear dimensionality reduction and data fusion techniques[J]. Expert Systems with Application, 2020, 149: 113281.
- [4] 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.
- [5] 肖凯, 邹任玲. 基于表面肌电信号的人体动作识别算法研究进展[J]. 生物信息学, 2018, 16(2): 76-82.
XIAO Kai, ZOU Renling. Research on human body motion recognition algorithm based on surface EMG signal[J]. Chinese Journal of Bioinformatics, 2018, 16(2): 76-82.
- [6] ENGLEHART K, HUDGINS B, PARKER P A, et al. Classification of the myoelectric signal using time-frequency based representations[J]. Medical Engineering & Physics, 1999, 21(6): 431-438.
- [7] 景元, 吉爱红, 张曦元, 等. 传感器人体运动行为特征识别研究进展[J]. 计算机工程与应用, 2019, 55(1): 23-28, 41.
JING Yuan, JI Aihong, ZHANG Xiyuan, et al. Development of human action feature recognition using sensors [J]. Computer Engineering and Applications, 2019, 55(1): 23-28, 41.
- [8] 张启忠, 席旭刚, 罗志增. 基于非线性特征的表面肌电信号模式识别方法[J]. 电子与信息学报, 2013, 35(9): 2054-2058.
ZHANG Qizhong, XI Xugang, LUO Zhizeng. A pattern recognition method for surface electromyography based on nonlinear features[J]. Journal of Electronics & Information Technology, 2013, 35(9): 2054-2058.
- [9] 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 Xin, ZHU Jiaqing, QIN Pengjie, 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.
- [10] 刘聪, 许婷婷, 马钰同, 等. 融合双层注意力与多流卷积的肌电手势识别记忆网络[J]. 光电子·激光, 2023, 34(2): 180-189.
LIU Cong, XU Tingting, MA Yutong, et al. Incorporating two-layer attention and multi-stream convolutional for sEMG gesture recognition memory networks [J]. Journal of Optoelectronics · Laser, 2023, 34(2): 180-189.
- [11] 孔康, 李德盈, 孙中圣. 基于小波包组合特征和 LMS-LSTM 的表面肌电信号分类[J]. 电子技术应用, 2022, 48(10): 92-96.
KONG Kang, LI Deying, SUN Zhongsheng. Classification of surface EMG signals based on wavelet packet combination and LMS-LSTM[J]. Application of Electronic Technique, 2022, 48(10): 92-96.
- [12] 王红旗, 李林伟, 毛啊敏. 基于小波包的表面肌电信号特征表示与识别[J]. 计算机工程与应用, 2015, 51(9): 217-220, 247.
WANG Hongqi, LI Linwei, MAO Amin. Feature representation and recognition of SEMGS based on wavelet packet [J]. Computer Engineering and Applications, 2015, 51(9): 217-220, 247.
- [13] TAGHIZADEH Z, RASHIDI S, SHALBAF A. Finger movements classification based on fractional Fourier transform coefficients extracted from surface EMG signals[J]. Biomedical Signal Processing and Control, 2021, 68: 102573.
- [14] 冯凯, 董秀成, 刘栋博. 基于经验模态分解-小波包变换的表面肌电信号手势识别[J]. 中国医学物理学杂志, 2021, 38(4): 461-467.
FENG Kai, DONG Xiucheng, LIU Dongbo. Empirical mode decomposition and wavelet packet transform applied to surface EMG signal for hand gesture recognition[J]. Chinese Journal of Medical Physics, 2021, 38(4): 461-467.
- [15] SMITH L H, HARGROVE L J, LOCK B A, et al. Determining the optimal window length for pattern recognition-based myoelectric control: balancing the competing effects of classification error and controller delay[J]. IEEE Transactions on Neural Systems & Rehabilitation Engineering, 2011, 19(2): 186-192.

(责任编辑 周 蓓)