

利用表面肌电进行手势自动识别

赵诗琪^{1,2,3}, 吴旭洲^{1,2,3}, 张旭^{1,2,3}, 李柄澄^{1,2,3}, 毛菁菁^{1,2,3}, 徐进^{1,2,3}

(1. 西安交通大学生命科学与技术学院, 710049, 西安; 2. 西安交通大学生物医学信息工程教育部重点实验室, 710049, 西安; 3. 国家医疗保健器具工程技术研究中心, 510500, 广州)

摘要: 针对手势自动识别研究中提高正确率和降低训练时间两者需要同时兼顾的问题,提出了一种基于 Fisher Score(FS)特征降维方法与机器学习相结合的新的手势识别模型。提取 4 通道表面肌电信号的时域、频域、时-频域和非线性特征,构成特征集;采用 FS 方法和主成分分析(PCA)方法分别进行特征降维,采用线性判别分析(LDA)和支持向量机(SVM)分别作为分类器;通过两种特征降维方法与两种分类器的不同组合构建不同的手势识别模型,并对分类模型的性能进行对比研究。实验结果表明,特征降维方法与分类器的组合能显著提高分类器的正确率、降低训练时间。与 PCA 方法相比,FS 方法是一种实现简便、效果理想的特征降维方法;与 SVM 组合的分类模型获得最高分类正确率 99.92%;与 LDA 组合的分类模型不仅获得 99.24%的分类正确率,而且花费最短的训练时间 1.44 ms,该模型可为手势的实时自动识别提供理想的方法和途径。

关键词: 表面肌电;特征提取;特征降维;机器学习;Fisher Score

中图分类号: R318.04 **文献标志码:** A

DOI: 10.7652/xjtuxb202009017 **文章编号:** 0253-987X(2020)09-0149-08



OSID 码

Automatic Gesture Recognition with Surface Electromyography Signal

ZHAO Shiqi^{1,2,3}, WU Xuzhou^{1,2,3}, ZHANG Xu^{1,2,3}, LI Bingcheng^{1,2,3},

MAO Jingjing^{1,2,3}, XU Jin^{1,2,3}

(1. School of Life Science and Technology, Xi'an Jiaotong University, Xi'an 710049, China;

2. Key Laboratory of Biomedical Information Engineering of Ministry of Education, Xi'an Jiaotong University, Xi'an 710049, China; 3. National Engineering Research Center for Healthcare Devices, Guangzhou 510500, China)

Abstract: For the aim of improving accuracy and reducing training time in automatic gesture recognition, a new gesture recognition model based on Fisher Score (FS) feature reduction combined with machine learning method is proposed. Firstly, the feature set is extracted from four-channel surface electromyography signals, involving the features of time domain, frequency domain, time-frequency domain and nonlinear dynamics. Then, FS and principal component analysis (PCA) are used for feature reduction respectively, and linear discriminant analysis (LDA) and support vector machine (SVM) are adopted as classifiers. Finally, different gesture recognition models are constructed by the two classifiers with and without two feature reduction methods, and their classification performance is compared. Experimental results demonstrate that the feature reduction method can help classifier improve accuracy and reduce training time significantly. Furthermore, compared with PCA, FS is a simple and effective feature reduction method; the combination of SVM and FS can achieve the highest classification accuracy of

99.92%; the combination of LDA and FS obtains the accuracy of 99.24% and takes the shortest training time of 1.44 ms, which suggests an ideal method for real-time automatic gesture recognition.

Keywords: surface electromyography; feature extraction; feature reduction; machine learning; Fisher Score

手是人体与外界交互最重要的功能器官之一,手的缺失不仅使人丧失很多日常生活的能力,而且会造成严重的心理伤害。智能假手将是帮助截肢者补偿功能、改善生活质量最直接有效的手段之一^[1-2]。然而,目前市场上的大部分假手仅具有装饰和支撑功能,或者只能实现简单的张合运动,很难满足患者的日常生活需求^[3]。

表面肌电(sEMG)信号是骨骼肌收缩时,在皮肤表面利用电极以无创的方式记录下来的生物电信号,其蕴含着丰富的与神经肌肉活动、运动意图相关的信息,已成为假手最理想的控制信号源^[4-5]。利用信号处理和模式识别技术,对不同手势执行过程中的运动意图实现自动识别、解码,是基于sEMG信号实现智能假手控制的关键所在^[6]。

不同手势的自动识别可以通过构建分类器实现,用于肌电模式识别的常用分类器包括:线性判别分析(LDA)、支持向量机(SVM)、人工神经网络、 k -最近邻算法等^[2,7],其中SVM可获得理想的分类正确率,LDA则具有算法简单、易于实现的优点。

获得理想分类效果的前提是要从sEMG信号中提取出能有效反映不同肌肉收缩模式的特征。目前,时域和频域特征在sEMG信号分析中比较常见,但时-频域和非线性特征很少被采用。

特征维数的增长会引起信息冗余,增加计算负担^[2]。主成分分析(PCA)、 t 检验、Fisher Score(FS)等常作为特征降维的方法,其中PCA已被广泛地用于sEMG信号特征降维处理中^[8]。FS是1995年提出的一种简单又高效的特征降维方法^[9],已在基于脑电信号的睡眠分期中得到了很好的应用^[10],但还从未被用于手势识别中。

基于信号处理技术和机器学习的各种运动模式识别算法主要应用于上肢粗大运动模式的自动识别。Guo等对肘部屈曲/伸展、前臂旋前/旋后、腕部屈曲/伸展和腕部内收/外展8种上肢动作进行分类,离线分析的平均正确率为73.1%~97.7%^[11]。León等提取了时域和频域特征,对握拳/展拳、前臂旋前/旋后、腕部屈曲/伸展、腕部桡侧/尺侧偏离和放松状态9种动作进行分类,平均正确率在94%以上^[4]。

与上肢粗大动作模式相比,由于手指精细运动获得的肌电信号幅度要弱很多,从而使其识别的难度很大。手势识别研究近两年才有所开展。2018年,Purushothaman等利用从8通道sEMG信号中提取的时域特征进行手势识别,并采用了粒子群优化和蚁群优化作为特征降维方法,结合SVM、LDA和朴素贝叶斯构建分类模型。SVM的分类正确率约为95%,其他两种方法均低于90%^[7]。

基于sEMG的手势识别模型是因人而异的,需要个性化定制。模型除了有高分类精度,还应满足训练时间短、计算复杂度低的需求,这样的模型才有利于在实际应用中的推广使用,而以往多数的研究都没有关注模型训练时间的长短和计算复杂度的大小。

本文针对上述研究中存在的不足,提取sEMG信号的时域、频域、时-频域和非线性等多种特征,采用PCA、FS方法进行特征降维,并分别与LDA、SVM两种分类器组合构建自动识别模型,开展4种手势的离线识别研究。通过不同模型的性能对比,寻找最佳性能的识别模型,为后续构建在线识别模型奠定了基础。

1 实验设计与信号采集

1.1 实验设计

选择日常生活中常用的4种功能性手势作为识别手势,包括握拳、五指伸展、三指对握和八字伸展,如图1所示。实验利用E-Prime软件呈现手势图片以规范数据采集流程,肌电信号采集实验范式如图2所示。首先在屏幕上出现一个“+”注视点,持续0.8 s;然后呈现一幅手势图片,持续2.0 s;接着是0.8 s的缓冲。实验参与者根据图片的提示做出相同的动作,每个动作完成后,必须恢复到自然放松状态再进行下一个动作。4种手势顺序呈现,每个动作连续重复5次,即1组数据包含20个动作,对每个实验参与者采集6组数据。实验参与者完成3组数据的采集后,休息5 min,以避免肌肉疲劳。

1.2 表面肌电信号采集

肌电信号采集采用美国Noraxon公司的Tele-




图 1 4 种功能性手势




图 2 肌电信号采集实验范式

Myo 2400T G2 系统,采样频率为 1 500 Hz。实验使用一次性表面粘贴电极采集 4 通道 sEMG 信号,电极贴放位置如图 3 所示。1 导联贴放于食指、中指指浅屈肌处;2 导联贴放于无名指、小指指浅屈肌处;3 导联贴放于无名指、小指指深屈肌处;4 导联贴放于指伸肌、拇长伸肌和拇短伸肌处;参考电极贴放于尺骨茎突处。

来自西安交通大学的 11 名健康青年人参加了实验,实验参与者均无上肢肌肉疾病及骨骼疾患。实验参与者的男女比例为 5:6,均为右利手,年龄为 21 ± 1.1 (均值±标准差) 岁。

2 基于 sEMG 信号的手势识别方法

2.1 信号预处理

采用数字滤波器对 sEMG 信号进行预处理。首先,50 Hz 陷波去除工频干扰;其次,4 阶 20~240 Hz 带通滤波滤除低频伪迹和 高频噪声;最后,12 阶梳状陷波滤除工频谐波(100、150 和 200 Hz)干扰。




图 3 4 通道肌电的电极贴放位置示意图

利用滤波后的信号,基于 Teager-Kaiser 能量算子,自动检测手势引发的 sEMG 信号的运动起始点^[12]。

2.2 特征提取

特征在手势识别中起着至关重要的作用,能对不同手势的信号进行区分。为了从 sEMG 信号中获取更全面的信息,提取了时域、频域、时-频域和非线性特征。用于特征提取的信号取 1 300 个样本点。

2.2.1 时域特征 本文采用了幅值绝对值均值、均方根值、幅值立方均值、过零点次数、Willison 幅值和波长 6 种时域特征^[5,13]。时域特征的数学定义如表 1 所示, $x_i(i=1,2,\cdots,N)$ 是信号的时间序列。

表 1 时域特征的数学定义

时域特征	数学定义
幅值绝对值均值	$T_{MAV} = \frac{1}{N} \sum_{i=1}^N x_i $
均方根值	$T_{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$
幅值立方均值	$T_{MCV} = \frac{1}{N} \sum_{i=1}^N x_i^3$
过零点次数	$T_{ZC} = \sum_{i=1}^{N-1} \text{sgn}(-x_i x_{i+1})$
Willison 幅值	$T_{WAMP} = \sum_{i=1}^{N-1} f(x_i - x_{i+1})$
波长	$T_{WL} = \sum_{i=1}^{N-1} x_{i+1} - x_i $

表 1 中,Willison 幅值的数学表达式中的函数 $f(x)$ 定义如下

$$f(x) = \begin{cases} 1, & x > V_{TH} \\ 0, & \text{其他} \end{cases} \tag{1}$$

式中: V_{TH} 为阈值,一般取 50~100 μV 。

2.2.2 频域特征 本文采用了4种频域特征^[5,14]: 包括平均功率频率、中值频率、2阶谱矩和7阶AR

模型参数 $a_1 \sim a_7$ 。频域特征的数学定义如表2所示, $P(f)$ 是信号的功率谱密度函数。

表2 频域特征的数学定义

频域特征	数学定义	备注
平均功率频率	$F_{\text{MPF}} = \frac{\int_0^{+\infty} fP(f)df}{\int_0^{+\infty} P(f)df}$	
中值频率	$\int_0^{F_{\text{MF}}} P(f)df = \int_{F_{\text{MF}}}^{+\infty} P(f)df = \frac{1}{2} \int_0^{+\infty} P(f)df$	F_{MF} 为中值频率
2阶谱矩	$F_{\text{SM}_2} = \int_0^{+\infty} f^2 P(f)df$	
7阶AR模型参数	$x_i = -\sum_{k=1}^7 a_k x_{i-k} + \tau w_i$	a_k 为模型参数, τw_i 为白噪声序列

2.2.3 时-频域特征 小波包变换已在生物医学信号处理中得到了广泛的应用^[15]。研究表明, Daubechies 系列基函数与运动单元动作电位的形状最相似^[16], 因此本研究选择 Daubechies 2(db2) 作为小波包基函数, 提取小波包系数的平方和、均值和方差作为时-频域特征。通过分类性能的对比, 小波包分解级数设定为3。

2.2.4 非线性特征 肌肉处于不同的收缩状态时, 由于参与的运动单元在空间、时间和数量上都存在差异, 因此肌电信号具有明显的非线性和混沌分形特性。本文采用了样本熵和分形维数2种非线性特征。

样本熵是当 d 维互相靠近的向量在增加一维时仍保持相互靠近的条件概率的负平均自然对数的精确值。样本熵通过度量信号中产生新模式的概率大小衡量时间序列的随机性或规则性。样本熵越低, 序列自我相似性越高; 样本熵越高, 序列越复杂。样本熵不进行自身匹配, 因此对信号长度依赖性更低, 并具有更好的一致性^[17]。本研究模式维数 d 取2, 相似容限取值为0.2倍的原始数据标准差。

分形维数反映了复杂形体占有空间的有效性, 是不规则性的量度^[18]。本文采用计盒维数法进行分形维数的估计^[19]。采用不同边长的格子覆盖信号波形时, 格子尺寸不同, 需要的格子数也不相同。设 ϵ 是格子边长, $N(\epsilon)$ 是覆盖被测信号的格子总数, 则计盒维数 D 的计算公式如下

$$D = \lim_{\epsilon \rightarrow 0} \left[\log N(\epsilon) / \log \frac{1}{\epsilon} \right] \quad (2)$$

采用最小二乘法拟合 $\log N(\epsilon) \sim \log(1/\epsilon)$ 直线, 该直线的斜率即为所要估计的分形维数。

按照下式对2.2.1~2.2.4小节所有提取的特

征进行0~1归一化处理^[20]

$$x'_{i,j} = (x_{i,j} - x_{\min,j}) / (x_{\max,j} - x_{\min,j}) \quad (3)$$

式中: $x'_{i,j}$ 为第 i 个样本的第 j 个特征归一化后的值; $x_{i,j}$ 为第 i 个样本的第 j 个特征的原始值; $x_{\min,j}$ 为第 j 个特征在所有样本中的最小值; $x_{\max,j}$ 为第 j 个特征在所有样本中的最大值。

2.3 特征降维

本研究基于4通道sEMG信号, 从每一通道sEMG信号中提取得到42维的特征向量, 包括6个时域特征、10个频域特征、24个时-频域特征和2个非线性特征, 所以最终可获得168维的特征集, 其中冗余的特征在模式识别中会降低分类准确性, 并增加计算负担^[7]。因此, 要进行特征降维, 选择最优特征子集用于分类以提高分类正确率, 并降低耗时。本研究采用了主成分分析和FS 2种特征降维方法。

主成分分析是一种常用的简单有效的非参数化降维方法。PCA将多个变量通过线性变换转换为少数几个新的综合变量, 这些新的综合变量(也称为主成分)可以通过计算原变量协方差矩阵的特征值和特征向量确定^[8]。主成分互不相关, 能在保留较多有用信息的情况下有效地表示原变量的信息。本研究根据分类正确率最高时对应的累积贡献率确定要保留的主成分个数。前 m 个主成分的累积贡献率(C)的计算式如下

$$C = \sum_{i=1}^m (\lambda_i / \sum_{i=1}^M \lambda_i), \quad m \leq M \quad (4)$$

式中: λ_i 为原变量协方差矩阵的特征值; M 为特征值数。

FS是一种有监督的特征降维方法, 通过分析不同类别上特征的均值和方差评价该特征类别区分性

强弱。对一个含有 c 个类别的数据集,第 j 个特征的 Fisher 得分(S_j)计算式如下

$$S_j = \frac{\sum_{i=1}^c n_i (u_j^i - u_j)^2}{\sum_{i=1}^c n_i (\sigma_j^i)^2} \quad (5)$$

式中: n_i 表示第 i 类样本数; u_j^i 、 σ_j^i 分别表示第 i 类数据集中第 j 个特征的均值及标准差; u_j 表示整个数据集中第 j 个特征的均值。

式(5)的分子部分表示样本中第 j 个特征上的类间离散度,分母部分表示第 j 个特征上的类内离散度。一个好的特征能够使类间离散度尽可能大,类内离散度尽可能小^[21]。因此, S 越大,表示特征在不同种类上差异越大,类别区分性越强。根据 S 的大小降序排列所有特征,将分类正确率最高时对应的前若干个特征作为最优特征子集。

2.4 分类器设计

鉴于 LDA 具有计算简单、易于实现、训练速度快的优点,SVM 具有良好的泛化能力和较高的识别准确性的优点,本文选择 LDA 和 SVM 作为分类器,开展手势识别研究。

LDA 是模式识别领域中应用最为广泛的分类方法之一。LDA 的核心思想是通过投影矩阵将原始的高维样本数据投影至低维空间,使样本数据在低维空间中的类间距离尽可能大,类内距离尽可能小,从而呈现出较好的类别区分状态^[2]。

SVM 是一种基于统计学习理论的机器学习方法^[7,10]。SVM 的基本思想是寻找一个到不同类别样本点的边界距离都能达到最大的最佳判别超平面,边界距离是指超平面和距其最近的样本点之间的距离^[2]。线性不可分的数据集利用核函数投影到高维空间,使其变得线性可分。本研究中,选择径向基函数(RBF)作为核函数;SVM 类型选择 C-SVC;多分类采用一对一方式实现^[22];采用网格搜索法^[5]进行惩罚因子和核函数参数 2 个参数的寻优。

2.5 分类模型评价

将特征降维方法与分类器进行组合,得到 LDA(无特征降维)、PCA-LDA、FS-LDA、SVM(无特征降维)、PCA-SVM 和 FS-SVM 6 种手势自动识别模型。本研究利用十折交叉验证^[2]评价不同组合算法的分类性能,并选取分类正确率和模型训练时间作为指标对分类模型进行评价。

分类正确率定义为判定正确的动作数占总被测动作数的比例。本文将 10 次实验正确率的均值作

为该分类模型的正确率。

模型训练时间定义为离线训练过程的耗时,对于 SVM 分类器,参数寻优的时间也被包括在内。同样,将 10 次训练时间的均值作为该分类模型的训练时间。模型训练时间的长短说明了组合算法的计算复杂程度,该指标可有效反映离线分类模型用于后续实时分类的潜力。

以上算法均利用 Matlab 软件编程实现,其中 SVM 分类器利用 Libsvm 工具包^[23]实现。

3 实验结果及对比

对所有实验参与者的两种分类器的分类正确率和训练时间进行对比。统计分析基于 SPSS 18.0 软件,显著性水平 p 设为 0.05。根据数据的正态性检验结果,采用独立样本 t 检验或秩和检验方法。

3.1 LDA 与 SVM 方法的对比

LDA 和 SVM 方法在不考虑特征降维时的分类正确率和训练时间如图 4 所示。统计结果表明,SVM 的分类正确率显著高于 LDA 的($p=0.000\ 06<0.05$),而 LDA 的训练时间显著低于 SVM 的($p=0.000\ 00<0.05$)。




图4 不考虑特征降维时 LDA 和 SVM 方法的分类性能对比

3.2 LDA、PCA-LDA 与 FS-LDA 方法的对比

LDA、PCA-LDA 与 FS-LDA 方法的分类性能对比结果如图 5 所示。LDA 的分类正确率只有 55.98%±3.72%(均值±标准差)。PCA-LDA 得到 98.94%±2.79%的分类正确率,显著高于 LDA 的($p=0.000\ 04<0.05$)。FS-LDA 的正确率为 99.24%±1.60%,也显著提高了分类正确率($p=0.000\ 05<0.05$)。

LDA 的训练时间为(0.12±0.01) s。与 LDA 相比,PCA-LDA 和 FS-LDA 的训练时间均显著减少




图5 LDA结合不同特征降维方法的分类性能对比

($p=0.000\ 05<0.05$; $p=0.000\ 07<0.05$)。PCA-LDA的训练时间仅为(1.26 ± 0.17) ms, FS-LDA的训练时间为(1.44 ± 0.43) ms。

3.3 SVM、PCA-SVM与FS-SVM方法的对比

SVM、PCA-SVM与FS-SVM方法的分类正确率和训练时间对比结果如图6所示。SVM的分类正确率为 $99.02\% \pm 1.43\%$ 。PCA-SVM与SVM的正确率没有显著性差异。FS-SVM的正确率为 $99.92\% \pm 0.25\%$,显著高于SVM的($p=0.008\ 66<0.05$)。




图6 SVM结合不同特征降维方法的分类性能对比

训练时间从(32.56 ± 0.63) s(SVM)分别降至(6.48 ± 1.16) s(PCA-SVM)和(9.84 ± 3.64) s(FS-SVM)。与SVM相比,PCA-SVM和FS-SVM的训练时间均显著降低($p=0.000\ 07<0.05$; $p=0.000\ 00<0.05$),而且采用PCA的训练时间显著低于FS方法的($p=0.023\ 49<0.05$)。

4 讨论

本文研究发现,与LDA方法相比,SVM方法具有更高、更稳定的分类正确率,但算法较复杂,耗时长。

特征降维方法与分类器的组合使用,使得分类正确率显著提高。同时,由于特征集维数减少,使得计算量显著降低,模型训练时间显著减少。尤其对于LDA分类器:平均正确率由55.98%提高到99%左右;平均训练时间由0.12 s降至1.5 ms以内。

与PCA方法相比,FS方法表现出更好的性能。只有FS方法与SVM的组合在正确率和训练时间方面的性能都得到了显著提升,且FS-SVM的分类正确率达到最高。此外,FS方法与分类器的组合可以获得更稳定的分类正确率。

虽然FS-LDA组合的平均分类正确率低于FS-SVM组合,但依然能达到99.24%,而且其训练时间很短,仅为1.44 ms,远少于FS-SVM的训练时间。

近年来,手势自动识别的研究开始引起关注,Shi等基于2通道sEMG信号,采用 k -NN分类器识别4种手势,其中一个握拳手势与本文研究相同,该研究未进行特征降维,分类正确率最高达到 $85.66\% \pm 4.77\%$ ^[24];Liang等基于3通道sEMG信号识别9种手势,其中一个八字伸展手势与本文研究相同,采用基于循环特征选择的递归特征消除算法进行特征降维,以及基于单层决策树的Ada-Boost算法进行分类,分类正确率为 $98.56\% \pm 1.44\%$,训练时间为 $3.401\ 6\ s$ ^[25];Phukpattaranont等基于6通道sEMG信号,采用PCA与SVM相结合的方法识别14种手势,其中握拳和八字伸展两个手势与本文研究相同,分类正确率为 $83.96\% \pm 6.93\%$ ^[2]。以上研究中,只有文献[25]对训练时间进行了统计分析。

通过本文的研究发现,FS方法作为一种计算简便的特征降维方法,通过与分类器的组合,在基于sEMG的手势识别中取得了理想的效果。

本文研究均选取右利手参与者进行实验,在后续的研究中,基于本文方法将会选取左利手参与者开展相应的研究。

5 结论

本文利用从4通道sEMG信号中提取的特征对4种手势进行自动识别方法研究。实验结果表

明,特征降维可以显著地提高分类正确率,降低模型训练时间。通过对比发现,本研究引进的一种新的FS特征降维方法,与两种分类器的组合均能明显改善分类模型的性能。FS-LDA可作为一种理想的用于手势实时自动识别的模型加以推广应用。

参考文献:

- [1] OMARI F A, HUI Jiang, MEI Congli, et al. Pattern recognition of eight hand motions using feature extraction of forearm EMG signal [J]. *Proceedings of the National Academy of Sciences India: Section A Physical Sciences*, 2014, 84(3): 473-480.
- [2] PHUKPATTARANONT P, THONGPANJA S, AN-AM K, et al. Evaluation of feature extraction techniques and classifiers for finger movement recognition using surface electromyography signal [J]. *Medical and Biological Engineering and Computing*, 2018, 56(12): 2259-2271.
- [3] 郑鑫. 基于表面肌电信号的手臂运动模式识别方法研究 [D]. 长春: 吉林大学, 2012: 1-4.
- [4] LEÓN M, GUTIÉRREZ J M, LEIJA L, et al. EMG pattern recognition using support vector machines classifier for myoelectric control purposes [C]// *Proceedings of the 2011 Pan American Health Care Exchanges*. Piscataway, NJ, USA: IEEE, 2011: 175-178.
- [5] OSKOEI M A, HU Huosheng. Support vector machine-based classification scheme for myoelectric control applied to upper limb [J]. *IEEE Transactions on Biomedical Engineering*, 2008, 55(8): 1956-1965.
- [6] 张志勇. 肌电信号采集与肌电假肢控制的研究 [D]. 哈尔滨: 哈尔滨工业大学, 2010: 1-3.
- [7] PURUSHOTHAMAN G, VIKAS R. Identification of a feature selection based pattern recognition scheme for finger movement recognition from multichannel EMG signals [J]. *Australasian Physical and Engineering Sciences in Medicine*, 2018, 41(2): 549-559.
- [8] NAIK G R, SELVAN S E, GOBBO M, et al. Principal component analysis applied to surface electromyography: a comprehensive review [J]. *IEEE Access*, 2016, 4: 4025-4037.
- [9] GU Quanquan, LI Zhenhui, HAN Jiawei. Generalized Fisher score for feature selection [C]// *Proceedings of the 27th Conference on Uncertainty in Artificial Intelligence*. New York, USA: ACM, 2011: 266-273.
- [10] ŞEN B, PEKER M, ÇAVUŞOĞLU A, et al. A comparative study on classification of sleep stage based on EEG signals using feature selection and classification algorithms [J]. *Journal of Medical Systems*, 2014, 38(3): 18.
- [11] GUO Shuxiang, PANG Muye, GAO Baofeng, et al. Comparison of sEMG-based feature extraction and motion classification methods for upper-limb movement [J]. *Sensors*, 2015, 15(4): 9022-9038.
- [12] SOLNIK S, RIDER P, STEINWEG K, et al. Teager-Kaiser energy operator signal conditioning improves EMG onset detection [J]. *European Journal of Applied Physiology*, 2010, 110(3): 489-498.
- [13] ZARDOSHTI-KERMANI M, WHEELER B C, BADDIE K, et al. EMG feature evaluation for movement control of upper extremity prostheses [J]. *IEEE Transactions on Rehabilitation Engineering*, 1995, 3(4): 324-333.
- [14] STULEN F B, DELUCA C J. Frequency parameters of the myoelectric signal as a measure of muscle conduction velocity [J]. *IEEE Transactions on Biomedical Engineering*, 1981, 28(7): 515-523.
- [15] HU Xiao, WANG Zhizhong, REN Xiaomei. Classification of surface EMG signal using relative wavelet packet energy [J]. *Computer Methods and Programs in Biomedicine*, 2005, 79(3): 189-195.
- [16] FLANDERS M. Choosing a wavelet for single-trial EMG [J]. *Journal of Neuroscience Methods*, 2002, 116(2): 165-177.
- [17] KOSMIDOU V E, HADJILEONTIADIS L I. Using sample entropy for automated sign language recognition on sEMG and accelerometer data [J]. *Medical and Biological Engineering and Computing*, 2010, 48(3): 255-267.
- [18] CHAKRABORTY M, PARBAT D. Fractals, chaos and entropy analysis to obtain parametric features of surface electromyography signals during dynamic contraction of biceps muscles under varying load [C]// *Proceedings of the 2017 2nd International Conference for Convergence in Technology*. Piscataway, NJ, USA: IEEE, 2017: 222-229.
- [19] GITTER J A, CZERNIECKI M J. Fractal analysis of the electromyographic interference pattern [J]. *Journal of Neuroscience Methods*, 1995, 58(1): 103-108.
- [20] VENUGOPAL V, SUNDARAM S. An online writer identification system using regression-based feature normalization and codebook descriptors [J]. *Expert Systems with Applications*, 2017, 72: 196-206.
- [21] NAIK G R, SELVAN S E, ARJUNAN S P, et al. An ICA-EBM-based sEMG classifier for recognizing lower limb movements in individuals with and without knee pathology [J]. *IEEE Transactions on Neural*

- Systems and Rehabilitation Engineering, 2018, 26(3): 675-686.
- [22] HSU C W, LIN C J. A comparison of methods for multiclass support vector machines [J]. IEEE Transactions on Neural Networks, 2002, 13(2): 415-425.
- [23] CHANG C C, LIN C J. LIBSVM: a library for support vector machines [J]. ACM Transactions on Intelligent Systems and Technology, 2011, 2(3): 27.
- [24] SHI Wanting, LYU Z J, TANG S T, et al. A bionic hand controlled by hand gesture recognition based on surface EMG signals: a preliminary study [J]. Biocybernetics and Biomedical Engineering, 2018, 38(1): 126-135.
- [25] LIANG Shili, WANG Liangliang, ZHANG Ling, et al. Research on recognition of nine kinds of fine gestures based on adaptive AdaBoost algorithm and multi-feature combination [J]. IEEE Access, 2019, 7: 3235-3246.

(编辑 武红江)

(上接第 148 页)

- [16] MONDAL A K, DOLZ J, DESROSIERS C. Few-shot 3D multi-modal medical image segmentation using generative adversarial learning [EB/OL]. [2020-02-01]. <https://arxiv.org/abs/1810.12241>.
- [17] MEDELA A, PICON A, SARATXAGA C L, et al. Few shot learning in histopathological images: reducing the need of labeled data on biological datasets [C] // 2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI). Piscataway, NJ, USA: IEEE, 2019: 1860-1864.
- [18] YE D H, POHL K M, DAVATZIKOS C. Semi-supervised pattern classification: application to structural MRI of Alzheimer's disease [C] // 2011 International Workshop on Pattern Recognition in NeuroImaging. Piscataway, NJ, USA: IEEE, 2011: 1-4.
- [19] RAHHAL M M A, BAZI Y, ALHICHRI H, et al. Deep learning approach for active classification of electrocardiogram signals [J]. Information Sciences, 2016, 345: 340-354.
- [20] BAI W, OKTAY O, SINCLAIR M, et al. Semi-supervised learning for network-based cardiac MR image segmentation [C] // 2017 International Conference on Medical Image Computing and Computer Assisted Intervention. Cham, Germany: Springer, 2017: 253-260.
- [21] CODELLA N, ROTEMBERG V, TSCHANDL P, et al. Skin lesion analysis toward melanoma detection 2018: a challenge hosted by the International Skin Imaging Collaboration (ISIC) [EB/OL]. [2020-02-20]. <https://arxiv.org/abs/1902.03368>.
- [22] GIDARIS S, KOMODAKIS N. Dynamic few-shot visual learning without forgetting [C] // Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 4367-4375.
- [23] GANIN Y, USTINOVA E, AJAKAN H, et al. Domain-adversarial training of neural networks [J]. Journal of Machine Learning Research, 2016, 17(1): 189-209.
- [24] DAMODARAN B B, KELLENBERGER B, FLAMARY R, et al. DeepJDOT: deep joint distribution optimal transport for unsupervised domain adaptation [C] // Proceedings of the European Conference on Computer Vision (ECCV). Cham, Germany: Springer, 2018: 447-463.

[本刊相关文献链接]

- 许美凤, 国雷达, 宋盼盼, 等. 多卷积神经网络模型融合的皮肤病识别方法. 2019, 53(11): 125-130. [doi:10.7652/xjtuxb201911018]
- 崔云博, 杜友田, 王航. 面向图像的有效目标区域提取方法. 2019, 53(5): 52-57. [doi:10.7652/xjtuxb201905008]
- 袁帅, 秦贵和, 晏婕. 应用残差生成对抗网络的路况视频帧预测模型. 2018, 52(10): 146-152. [doi:10.7652/xjtuxb201810020]
- 张西宁, 向宙, 唐春华. 一种深度卷积自编码网络及其在滚动轴承故障诊断中的应用. 2018, 52(7): 1-8. [doi:10.7652/xjtuxb201807001]
- 李策, 张亚超, 蓝天, 等. 一种高分辨率遥感图像视感知目标检测算法. 2018, 52(6): 9-16. [doi:10.7652/xjtuxb201806002]

(编辑 陶晴)