

基于可穿戴设备的障碍人群问题行为识别

马 仑^{1,2}, 王瑞平¹, 赵 斌¹, 刘 鑫¹, 廖桂生², 张亚静¹

(1. 长安大学信息工程学院, 西安 710064; 2. 西安电子科技大学雷达信号处理国家重点实验室, 西安 710071)

摘 要: 障碍人群的问题行为给个体、家庭和整个社会带来了沉重的心理压力和经济负担。为此, 本文致力于探索利用可穿戴设备内置的9轴运动传感器结合先进的人工智能技术对障碍人群的问题行为进行感知的可行性, 以期防止事故发生, 降低看护成本。首先, 对采集数据进行分析 and 预处理, 提取共108维特征; 其次, 在特征选择过程中, 分别采用原理性分析和随机森林两种方法, 划分为3个特征子集, 其目的是在保证识别精度的前提下降低时间开销; 最后, 采用两种验证方法, 利用6种分类器进行评价。实验结果表明, 特征融合能有效提高分类器的识别率; 特征选择能在较低性能损失的前提下, 保证分类器的识别率; 综合考虑运算开销和识别精度, 特征子集3更适用于问题行为识别, 轻量梯度提升机(Light gradient boosting machine, LightGBM)具有明显的性能优势, 10倍交叉验证的平均识别率可达93%。

关键词: 障碍人群; 可穿戴设备; 特征提取; 特征选择; 问题行为识别; 机器学习

中图分类号: TP391 **文献标志码:** A

Impaired Behavior Classification for People with Special Needs Based on Wearable Devices

MA Lun^{1,2}, WANG Ruiping¹, ZHAO Bin¹, LIU Xin¹, LIAO Guisheng², ZHANG Yajing¹

(1. School of Information Engineering, Chang'an University, Xi'an 710064, China; 2. National Lab of Radar Signal Processing, Xidian University, Xi'an 710071, China)

Abstract: The impaired behaviors of people with special needs bring heavy psychological pressure and economic burden to individuals, families and the whole society. This paper aims to explore the possibility of sensing the impaired behaviors of people with special needs by combining advanced AI techniques with wearable device embedded with 9-axis motion sensors to prevent accidents and reduce nursing costs. Firstly, the self-collected data are analyzed and preprocessed to extract the features of 108 dimensions. Secondly, in the process of feature selection, the feature is divided into three feature subsets by using two methods of priori analysis and random forest respectively. The purpose is to reduce the time cost on the premise of ensuring the recognition accuracy. Finally, two validation methods and six classifiers are used for evaluation. Experimental results show that multi-sensor data fusion can greatly improve the recognition rate of the classifier and the feature selection can ensure the recognition rate of the classifier under the premise of low performance loss. Feature subset 3 is more suitable for representing impaired behaviors of people with special needs. The light gradient boosting machine (LightGBM) has an obvious performance

基金项目: 中国博士后科学基金(2015M582586); 长安大学大学生创新创业训练计划(S202110710222)。

收稿日期: 2021-06-11; **修订日期:** 2021-10-19

advantage, and the average recognition rate of 10-fold cross-verification can reach 93%, which turned out to be more feasible and practical considering both computation cost and classification accuracy.

Key words: people with special needs; wearable devices; feature extraction; feature selection; impaired behavior recognition; machine learning

引言

人类行为识别(Human activity recognition, HAR)技术已经在人机交互、移动和普适计算等领域得到了广泛的关注和应用。将HAR应用于医疗保健这个新兴领域,涉及老年人和体弱者的健康监测和康复评估等^[1]。基于可穿戴设备的HAR已成为帮助患者进行康复治疗、日常行为监测以及其他健康问题的重要工具^[2],如老年人的跌倒^[3]和中风的康复监测^[4]等。

相比于普通人群,在临床上被诊断为生理和心理层面有残疾(如自闭症、抽动症等)和有特殊需要的人群(障碍人群)所表现出的问题行为尤为引人关注。通常情况下,问题行为根据严重性和复杂性分为3类^[5]:自我刺激性行为,如不停的眨眼、挤眉、点头和摇头等;自我伤害性行为,如打自己的头、抽撞和撞墙等;破坏性行为,如打架等;这3种问题行为普遍具有刻板性和周期性。国内外大量研究表明^[5-6],问题行为已严重影响障碍人群的健康及发展。然而,鲜有研究考虑到障碍人群的行为识别。将先进的HAR系统应用于问题行为识别,可以解放人工成本,对障碍人群融入社会提供更好的帮助。

基于传感器的HAR研究主要集中在特征提取、特征选择和算法设计等方面。从特征角度来看,特征提取主要包括时域和频域等^[7],特征选择主要包括嵌入法和包装法等^[8]。特征提取作为行为识别的重要环节,提取结果的好坏在很大程度上影响着行为识别效果的实时性与准确性。特征选择能提升模型的效率,增加模型的可解释性。从算法角度来看,常用的算法分为深度学习和机器学习两类。深度学习能自动提取特征,包括卷积神经网络(Convolutional neural networks, CNN)^[9]等;机器学习需要根据先验知识手动提取特征,主要包括K近邻(K-nearest neighbor, KNN)^[10]、支持向量机(Support vector machine, SVM)^[11]、决策树(Decision tree, DT)^[12]等基分类器和随机森林(Random forest, RF)、装袋算法(Bootstrap aggregating, Bagging)等^[13]集成分类器。研究发现集成分类器可以提高识别准确率^[14]。近年来,国内外研究者对不同识别算法展开研究并取得了一定的进展,虽然基于可穿戴设备的HAR研究已取得一些成果,但目前仍没有统一的分类方法。根据所分析行为的种类、最终的应用程序、可用的计算能力和处理时间,可以选择不同的算法对行为进行识别。如何对数据进行预处理并提取有效特征,如何设计有效的算法以实现不同行为的准确识别,仍需要进一步开展研究工作。

目前,对障碍人群的问题行为进行智能感知尚未引起HAR研究领域的广泛关注,且缺少与之相应的数据处理方法。本文拟利用可穿戴设备内置的9轴传感器,结合先进的人工智能技术对障碍人群的问题行为进行识别。首先,通过分析问题行为的运动学特性,使用采样频率为20 Hz的可穿戴设备对3个位置(颈部、手腕和脚踝)的5种行为(走路、用拳猛击头部、头部撞墙、拳打脚踢他人和抽撞)进行数据采集;进一步,探索适用于问题行为分类器的特征集,在数据处理初始阶段提取尽可能多的特征,并采用特征融合和两种特征选择方法,将所有特征划分为3个特征子集;最后,采用2种验证方法、5种评价指标以及6种分类器(SVM、KNN、DT、RF、极限梯度提升(eXtreme gradient boosting, XGBoost)和轻量梯度提升机(Light gradient boosting machine, LightGBM)进行性能评价,进而为HAR面向障碍人群提供理论以及实践支撑。

1 数据采集和特征提取

1.1 数据采集

通过走访特殊教育学校以及文献检索^[6],如表1所示,本文选定4种问题行为和1种正常行为作为研究对象(样本)。其中自伤行为(行为2和3)与伤人行为(行为4)多见于脑瘫与自闭症,尤其是特殊儿童,而抽搐行为(行为5)则多见于脑瘫与癫痫。通过分析5种行为的运动学特征,发现行为3和5的主要发力部位为躯干而行为2和4为四肢。因此,将3个传感器分别佩戴于测试者的颈部、手腕和脚踝。图1为5种行为合加速度幅值示例,根据主要发力部位,行为1、行为2和行为4给出手腕可视化数据,行为3和行为5给出颈部可视化数据。

本文使用采样频率为20 Hz的MPU9250传感器模拟感知障碍人群的问题行为,其由一个三轴加速度计、一个三轴陀螺仪和一个三轴磁强计组成^[15]。自采集数据集收集了22名测试者(年龄从18~39岁,18名男性,4名女性)模拟障碍人群的4种问题行为与1种正常行为,每人每种行为分别做3次,每次持续时间为10 s,共得到330个样本。自采集数据集包含全身3个部位(颈部、手腕和脚踝)数据,佩戴于3个位置的传感器通过内置的同步模块保证其同步记录行为数据。值得说明的是,每一位测试者在实验中均佩戴实验防护装备并签署了《测试者知情同意书》。

1.2 特征提取

通常情况下,人类日常行为提取的统计特征主要为均值、方差、最大值等,以上特征能够很好区分静态行为与动态行为,且除走路等是周期性行为外,很多行为不具有周期性。由图1可知,障碍人群的问题行为表现出较强的“类周期性”和“突变性”,且自伤行为(行为2)和伤人行为(行为4)在某种程度上存在较强的相似性。“类周期性”和“突变性”为区分正常行为与问题行为提供更高的可行性,但对于不同问题行为的分类还缺乏区分度。为探索适用于问题行为分类的特征集,如表2所示,本文在数据处理初始阶段提取尽可能多的特征,即对3个位置的传感器数据提取了时域、频域和小波域共108维特征^[4,7]。

考虑到问题行为的“类周期性”(自采集数据的周期一般小于2 s,对应40个采样点),本文选取步长为20,窗口为40,重叠率为50%的滑动窗口^[16]对自采集数据集进行处理,将数据分割成相同长度的序列,然后对每个序列样本提取特征,构成特征样本。值得说明的是,为了更好地从时序样本中分离出问题行为,在表2中提取特征27~36时,对时序样本进行了高通滤波(截止频率1 Hz)^[4]。

表1 问题行为描述

Table 1 Description of impaired behaviors

序号	行为描述
1	在活动区域任意走动
2	用拳猛击头部(包括顶部与侧面)
3	头部撞墙(包括前额、后脑及侧面)
4	拳打脚踢他人
5	以躺姿侧面抽搐、小幅抽搐、大幅抽搐及左抽搐

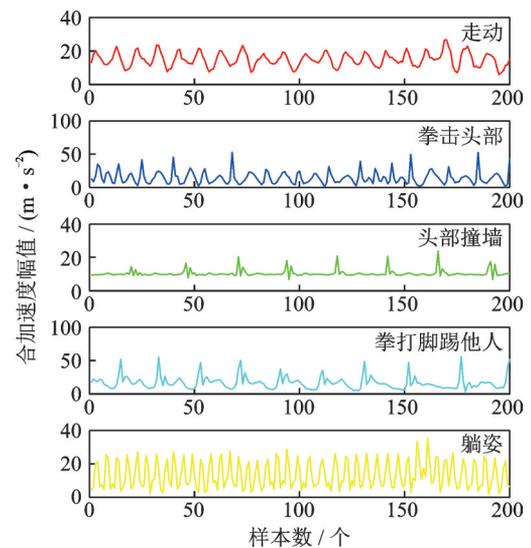


图1 5种行为合加速度幅值示例

Fig.1 Five examples of acceleration amplitude combined with behavior

表2 传感器数据提取的特征
Table 2 Extracted features of sensor data

原始数据		高通滤波数据			
编号	特征	编号	特征	编号	特征
1	均值	14	信号幅度区域	27	熵
2	方差	15	信号幅度向量	28	能量
3	标准差	16	均方根	29	均方根
4	众数	17	四分位距	30	求导后均方根
5	最大值	18	自相关	31	求导后能量
6	最小值	19	互相关最大值	32	峰值速度
7	过零点	20	互相关均值	33	峰值速度归一化的均方根序列
8	范围	21	互相关标准差	34	FFT系数和
9	中位数	22	小波所有层系数和	35	传感器时间序列对零时延互相关
10	绝对中位差	23	小波第二层系数和	36	1 s时窗传感器序列对互相关峰值
11	样本差异	24	直流分量		
12	角度	25	能量		
13	角速度	26	FFT系数和		

2 数据处理

2.1 特征融合

信息融合可以用来克服单个传感器的局限性,融合可以在信号级、特征级和决策级实现^[17]。本文致力于探索适用于障碍人群问题行为的特征集合,因此采用特征级融合,将不同位置提取的特征进行拼接,构成特征集。

2.2 特征选择

如上所述,本文首先建立尽可能大的特征集,从中探索适用于问题行为分类的特征子集。但高维度的特征集将引入巨大的运算开销,因此,有必要对初始特征集进行降维,选出真子集,在保证识别精度的前提下降低运算开销,进而提升模型的效率、降低学习任务的难度。

2.2.1 原理性分析进行特征选择

结合问题行为采集信号的数学特性,针对表2特征集中各个特征对于问题行为识别的贡献进行原理性分析:

(1)特征2、特征3能较好地反映行为中的平动^[18],有助于区分行为1和其他4种问题行为。

(2)特征10和17常用于异常值检测,是识别异常值的一个标准,考虑到问题行为表现出的“突变性”,这两个特征对于区分不同的问题行为应具有较大贡献;表1中的5种行为均为动态行为,常规用于区别动态行为和静态行为的特征显然不适用于本文,考虑到特征19被广泛应用于识别不同波形的相似性,进而对不同的动态行为进行分类,因此,该特征有助于问题行为识别。

(3)特征8反映数据分布的变异范围和离散幅度,能体现一组数据波动的范围,对于类似的行为,如行为2和行为4,标准差或平均值等特征可能是相同的,但最大值和最小值的差值却有较大的可能性是不同的,如果最大值和最小值的差值足够小,说明佩戴者处于静止状态,反之,可以根据差值的大小来对相似的行为进行分类,因此,这个特征对于区分相似的问题行为应具有较大贡献。

(4)特征 25、28 和 31 常用于识别具有周期性的行为^[19],特征 26 和 34 可作为识别特定动作的关键指标^[20],以上特征均是基于 FFT 的频域特征,已被广泛用于捕捉与周期有关的传感器信号的重复性质,考虑到表 1 中 5 种行为表现出的“类周期性”,因此,上述特征对于区分这 5 种行为应具有较大贡献。

(5)特征 27 常用于识别具有相似能量的不同行为^[21],特征 16、29 和 30 表示时域信号的有效值,常用于识别相似行为^[22],考虑到行为 2 和 4 都是手腕特征较为明显,且两种行为比较相似,很可能具有相似的信号能量,以上特征对于区分这两种行为应有较大贡献。另外,文献[2]指出特征 27 以及特征 16、29 和 30 是判别运动障碍的最佳特征,鉴于运动障碍行为与本文研究的问题行为从行为学的角度来看较为相似,故认为上述特征有助于本文讨论的问题行为识别。最后,文献[4]提到特征 33 和 36 是检测中风后的运动能力主要依据之一,中风后患者常表现出现各种肢体运动功能障碍(如抽搐),具有较高的参考性。

综上所述,结合问题行为的运动学特点与表 2 特征的数学特性,初步认定特征 2、3、8、10、16、17、19、25、26、27、28、29、30、31、33、34 和 36 能更好地地区分表 1 中的 5 种行为。

2.2.2 随机森林进行特征选择

采用随机森林^[23]对 3 个位置的 108 维特征(手腕 1~36、脚踝 37~72 和颈部 73~108)进行重要性评估,筛选重要性分数大于 0.01 的特征,如图 2 所示,将 108 维特征降为 32 维。将随机森林选择的特征与原理性分析选择的特征进行对比,可以看出特征选择的结果基本一致,其中随机森林额外选择了特征 21 同时未选择特征 16、25、28 和 29。

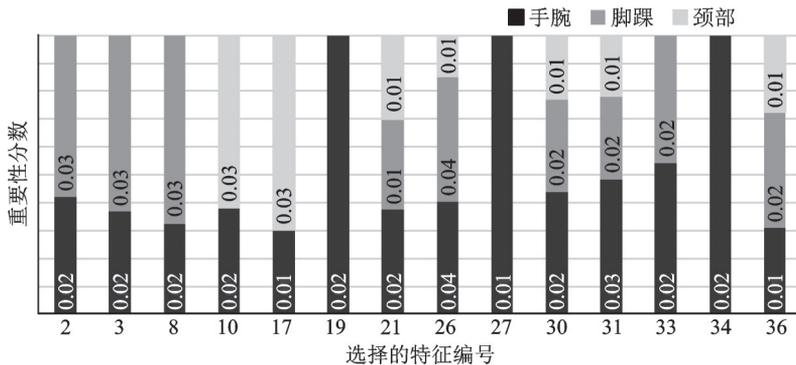


图2 随机森林特征选择结果

Fig.2 Random forest feature selection results

为验证以上特征选择的可行性,进一步将特征数据划分为 3 个特征子集,特征子集 1:根据表 2,选取初始完备特征集合共 108 维特征(颈部、手腕和脚踝各 36 维特征);特征子集 2:根据表 2 特征集中各个特征对于问题行为识别进行原理性分析选择的 51 维特征(颈部、手腕和脚踝各 17 维特征);特征子集 3:如图 2 所示,随机森林筛选的 32 维特征。

3 分类方法及评价指标

本文选取 3 种基分类器 SVM、KNN、DT 和 3 种集成分类器 RF、XGBoost 和 LightGBM 构成分类模型。以上 6 种分类器都是在 Python(scikit-learn 库)环境下实现的,分别将第 2 节所选的特征输入到分类器,以完成 5 种行为(4 种问题行为和 1 种正常行为)识别。

本文通过两种验证方法:(1)10 倍交叉验证(将数据集分成 10 份,轮流将其中 9 份作为训练数据,1 份作为测试数据),将 10 倍交叉验证的平均准确率作为算法识别精度的估计;(2)Holdout 验证(包含

80%的训练集和20%的测试集),将测试集的准确率作为算法识别精度的估计。以准确率、精确率、召回率、F1-score^[13,24]和混淆矩阵^[3]作为评价指标。

4 实验结果与分析

4.1 特征融合结果与分析

如图3所示,不同位置分类器的识别率不同,由高到低为手腕、脚踝和颈部;相同位置分类器的识别率也不同,由高到低依次为LightGBM、XGBoost、RF、DT、KNN和SVM。将3个位置的特征进行融合后,所有分类器的识别率都有显著提升,与手腕相比,SVM识别率提高7%,KNN识别率提高7%,DT识别率提高9%,RF识别率提高10%,XGBoost识别率提高9%,LightGBM识别率提高9%,故采用特征融合可以提高分类器的识别率。

4.2 特征选择结果与分析

如图4所示,对于基分类器采用特征选择后,SVM和KNN识别率有所提升,在特征子集3上识别率最高约为82%,DT的变化较小。对于集成分类器采用特征选择后,LightGBM、XGBoost和RF识别率略微下降,在特征子集1上识别率最高,相较于特征子集1,在特征子集2和3上降低约2%。3个特征子集上分类器识别率由高到低为LightGBM、XGBoost、RF、DT、KNN和SVM,集成分类器总体表现优于基分类器。总体来看,基分类器在特征子集3上识别率最高,集成分类器在特征子集1识别率最高,且集成分类器在特征子集2和3上的识别率基本一致,说明原理性分析进行特征选择是可行的,两种特征选择方法都保留了问题行为识别的关键特征。

结合分类器的性能进一步分析,如表3所示,Holdout验证下,集成分类器在特征子集1上的识别率高于特征子集3上的识别率,但是,集成分类器在特征子集1上的运行时间明显高于特征子集3上的运行时间,特征选择后,集成分类器的识别率相对减少约1%,而运行时间相对减少51.9%~67.4%,说明特征子集3能在保证识别精度的前提下降低时间开销。

表3 Holdout验证下集成分类器的准确率和运行时间

Table 3 Accuracy and running time of the integrated classifier under Holdout verification

分类器	特征子集1		特征子集3		相对减少	
	准确率/%	运行时间/s	准确率/%	运行时间/s	准确率/%	运行时间/%
RF	98.7	21.6	97.5	10.4	1.2	51.9
XGBoost	99.4	72.3	98.3	26.1	1.1	63.9
LightGBM	99.4	9.2	98.3	3.0	1.1	67.4

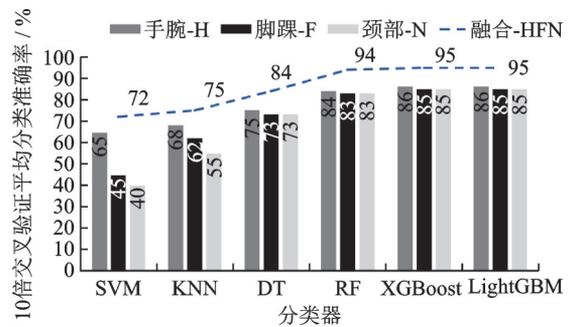


图3 颈部、手腕和脚踝传感器特征融合的分类结果

Fig.3 Classification results of fusion of sensor features in neck, wrist and ankle

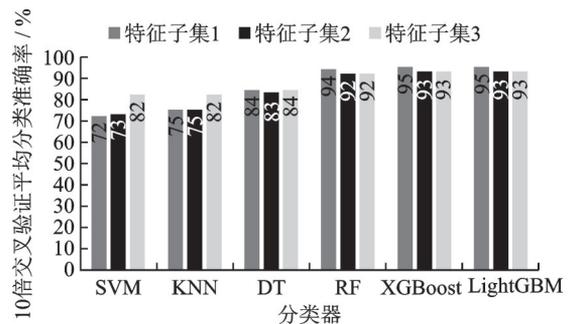


图4 不同特征集的分类结果

Fig.4 Classification results of different feature sets

对于基分类器,SVM适合小样本及高维数据,但存在内存消耗大和运行速度慢的问题;KNN容易实现,可用于非线性分类,适合小样本且精度要求不高的数据;DT计算简单,可解释性强,运行速度比较快,但容易过拟合。对于集成分类器,RF处理高维特征的数据训练速度快,易实现并行;而XGBoost时间消耗大,占用更多的硬件资源;LightGBM占用的硬件资源更低,速度更快。本文要求分类器在保证精度的前提下具有较低的运算开销,根据以上分析,LightGBM分类器在实际应用中更适用于本文针对的问题行为识别。

为进一步研究不同分类器对5种行为的分类性能,在特征子集3下观察识别率最高的LightGBM分类器和识别率最低的SVM分类器对单个行为的识别结果。如表4所示,LightGBM分类器和SVM分类器10倍交叉验证的平均识别率分别为93%和82%。在精确率方面,LightGBM分类器在行为3上最高为97%,SVM分类器在行为1和5上最高为89%,对于其他行为,LightGBM分类器在85%至96%之间比SVM分类器(77%至78%)显示出更优的精确率结果。在召回率方面,LightGBM分类器在行为1和3上最高为97%,SVM分类器在行为3上最高为93%,对于其他行为,LightGBM分类器在87%至96%之间比SVM分类器(63%到90%)显示出更优的召回率结果。在F1-score方面,LightGBM分类器在行为1和行为3上最高为97%,SVM分类器在行为1上最高为89%,对于其他行为,LightGBM分类器在87%至96%之间比SVM分类器(69%到85%)显示出更优的F1-score性能。LightGBM分类器对于5种行为识别率由高到底为行为3、1、5、2和4,SVM分类器对于5种行为识别率由高到底为行为1、3、5、2和4。综上,不同评价指标下,LightGBM对于5种行为的分类性能均优于SVM,且对于不同分类器,行为1、3、5容易识别而行为2和4不易识别。

表4 LightGBM和SVM 10倍交叉验证的分类报告

Table 4 10-fold cross-validation classification reports of LightGBM and SVM

%

行为	LightGBM			SVM		
	精确率	召回率	F1-score	精确率	召回率	F1-score
1	96	97	97	89	90	89
2	91	87	89	77	81	79
3	97	97	97	78	93	85
4	85	88	87	77	63	69
5	96	96	96	89	82	85

如图5所示,观察LightGBM分类器和SVM分类器10倍交叉验证的混淆矩阵,发现两个分类器最易混淆的行为是行为2和行为4。如上所述,以捶打为主的行为2和以击打为主的行为4在腕部的运动特征较为相似,容易产生混淆,这与之前的理论分析是一致的。值得说明的是对图5中错误概率小于0.01的元素置零。

5 结束语

针对障碍人群的问题行为,本文展开探索性研究。首先,利用可穿戴设备内置的9轴运动传感器模拟感知障碍人群的1种正常行为和4种问题行为;然后,对自采集数据集进行分析和预处理,为探索适用于问题行为分类的特征集,采用特征融合和两种特征选择方法将初始特征集划分为3个特征子集;最后,采用2种验证方法和5种评价指标,对6种分类器在3个特征子集上的分类性能进行评估。实验结

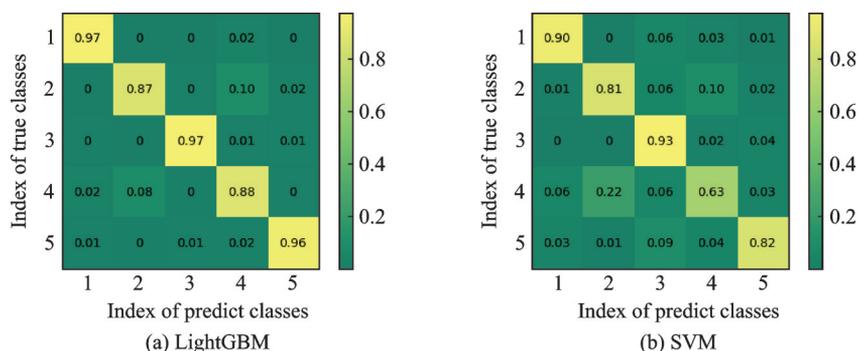


图5 特征子集 3 下 LightGBM 和 SVM 10 倍交叉验证混淆矩阵

Fig.5 10-fold cross validation of the confusion matrix of LightGBM and SVM under feature subset 3

果表明,本文对问题行为进行智能感知的探索性研究在理论上是可行的,有利于 HAR 系统应用于障碍人群的问题行为监测,可为障碍人群融入社会提供更好的帮助。

参考文献:

- [1] YAMINI G, GANAPATHY G. Enhanced sensing and activity recognition system using IoT for healthcare[J]. *International Journal of Information Communication Technologies and Human Development*, 2021, 13(2): 42-49.
- [2] PATEL S, LORINCZ K, HUGHES R, et al. Analysis of feature space for monitoring persons with Parkinson's disease with application to a wireless wearable sensor system[J]. *Proc of IEEE Eng Med Biol Soc*, 2008, 2007: 6291-6294.
- [3] LI H, SHRESTHA A, FIORANELLI F, et al. Multisensor data fusion for human activities classification and fall detection[C]//*Proceedings of 2017 IEEE Sensors*. [S.l.]: IEEE, 2017: 909-911.
- [4] HESTER T, HUGHES R, SHERRILL D M, et al. Using wearable sensors to measure motor abilities following stroke[C]//*Proceedings of International Workshop on Wearable and Implantable Body Sensor Networks (BSN'06)*. [S.l.]: IEEE, 2006: 1-12.
- [5] 郭雷祥. 自闭症儿童的问题行为表现及体育游戏干预[J]. *宜春学院学报*, 2012, 34(12): 139-141.
GUO Leixiang. The problem behavior of children with autism and sports games intervention[J]. *Journal of Yichun University*, 2012, 34(12): 139-141.
- [6] 孙立双, 韦小满. 国外关于特殊儿童自伤行为的研究综述[J]. *中国特殊教育*, 2008(4): 41-45.
SUN Lishuang, WEI Xiaoman. Foreign studies on self-injury behavior of special children: A review[J]. *Chinese Journal of Special Education*, 2008(4): 41-45.
- [7] FIGOET D, DINIZ C, DIOGO R, et al. Preprocessing techniques for context recognition from accelerometer data[J]. *Personal and Ubiquitous Computing*, 2010, 14(7): 645-662.
- [8] LI H, SHRESTHA A, HEIDARI H, et al. A multisensory approach for remote health monitoring of older people[J]. *IEEE Journal of Electromagnetics RF and Microwaves in Medicine and Biology*, 2018(99): 1-9.
- [9] 吴潇颖, 李锐, 吴胜昔. 基于 CNN 与双向 LSTM 的行为识别算法[J]. *计算机工程与设计*, 2020, 41(2): 361-366.
WU Xiaoying, LI Rui, WU Shengxi. Action recognition algorithm based on CNN and bidirectional-LSTM[J]. *Computer Engineering and Design*, 2020, 41(2): 361-366.
- [10] LEI J, CHENG Z. Recognition of daily routines and accidental event with multipoint wearable inertial sensing for seniors home care[C]//*Proceedings of IEEE International Conference on Systems*. [S.l.]: IEEE, 2017.
- [11] ABIDINE B M, FERGANI L, FERGANI B, et al. The joint use of sequence features combination and modified weighted SVM for improving daily activity recognition[J]. *Pattern Analysis & Applications*, 2018, 21(1): 119-138.
- [12] DE CILLIS F, DE SIMIO F, SETOLA R. Long-term gait pattern assessment using a tri-axial accelerometer[J]. *Journal of Medical Engineering & Technology*, 2017, 41(5): 346-361.

- [13] KU K A R, ELAMVAZUTHI I, IZHAR L, et al. Classification of human daily activities using ensemble methods based on smart phone inertial sensors[J]. Sensors, 2018, 18(12): 1-8.
- [14] 徐继伟,杨云.集成学习方法:研究综述[J].云南大学学报(自然科学版),2018,40(6): 1082-1092.
XU Jiwei, YANG Yun. A survey of ensemble learning approaches[J]. Journal of Yunnan University(Natural Sciences Edition), 2018, 40(6): 1082-1092.
- [15] LIU R, PENG L, TONG L, et al. The design of wearable wireless inertial measurement unit for body motion capture system [C]//Proceedings of IEEE International Conference on Intelligence and Safety for Robotics. [S.l.]: IEEE, 2018.
- [16] BANOS O, GALVEZ J M, DAMAS M, et al. Window size impact in human activity recognition[J]. Sensors, 2014, 14(4): 6474-6499.
- [17] KING R C, VILLENEUVE E, WHITE R J, et al. Application of data fusion techniques and technologies for wearable health monitoring[J]. Medical Engineering & Physics, 2017, 42: 1-12.
- [18] KAWAHARA Y, KURASAWA H, MORIKAWA H. Recognizing user context using mobile handsets with acceleration sensors[C]//Proceedings of IEEE International Conference on Portable Information Devices. [S.l.]: IEEE, 2007.
- [19] KERN N, SCHIELE B, Schmidt A. Recognizing context for annotating a live life recording[J]. Personal & Ubiquitous Computing, 2007, 11(4): 251-263.
- [20] WELBOURNE E, LESTER J, LAMARCA A, et al. Mobile context inference using low-cost sensors[C]//Proceedings of the First International Workshop on Location and Context-Awareness(Lo CA 2005). [S.l.]: Springer, 2007: 254-263.
- [21] BAO L, INTILLE S S. Activity recognition from user-annotated acceleration data[C]//Proceedings of Second International Conference, PERVASIVE. [S.l.]: [s.n.], 2004.
- [22] RANDELL C, MULLER H. Context awareness by analysing accelerometer data[C]//Proceedings of Fourth International Symposium on Wearable Computers. [S.l.]: IEEE, 2000: 175-176.
- [23] GENUER R, POGGI J M. Variable selection using random forests[J]. Pattern Recognition Letters, 2010, 31(14): 2225-2236.
- [24] 韩锟,黄泽帆.基于人体姿态动态特征的跌倒行为识别方法[J].湖南大学学报(自然科学版),2020,47(12): 69-76.
HAN Kun, HUANG Zefan. Falling behavior recognition method based on dynamic characteristics of human body posture[J]. Journal of Hunan University(Natural Sciences), 2020, 47(12): 69-76.

作者简介:



马仑(1981-),男,博士,副教授,硕士生导师,研究方向:雷达信号处理、人工智能与行为识别,E-mail:lunma@126.com。



王瑞平(1994-),通信作者,女,硕士研究生,研究方向:人工智能与行为识别等,E-mail: 2382227469@qq.com。



赵斌(1994-),男,硕士研究生,研究方向:传感器与行为识别,E-mail:zhaob6001@163.com。



刘鑫(1997-),男,硕士研究生,研究方向:人工智能与行为识别,E-mail:3231077923@qq.com。



廖桂生(1963-),男,博士,教授,博士生导师,研究方向:雷达系统技术与阵列处理、雷达稀疏成像处理等,E-mail: gsliao@xidian.edu.cn。



张亚静(2000-),女,本科生,研究方向:人工智能与行为识别,E-mail:2316592715@qq.com。

(编辑:夏道家)