

文章编号: 2095-2163(2022)06-0097-06

中图分类号: TP212.9

文献标志码: A

基于惯性传感器的人体姿态识别算法

魏旋旋

(上海工程技术大学 机械与汽车工程学院, 上海 201620)

摘要: 针对惯性传感器(IMU)采集数据庞大、不便处理的缺点,本文提出了一种全新的惯性传感器信号处理算法。该算法首先利用切比雪夫二型高通滤波器对身体相对于垂直引力场位置的变化所导致的“缓慢”变化进行消除;接着,提取惯性传感器信号功率谱密度曲线、加速度平均值、均方根等,共60个特征代替原有信号;最后,利用HAR公开数据集进行人体动作识别实验对算法的优越性进行验证。试验结果表明,该算法识别准确率为92.1%,训练时间为5.268 s。

关键词: IMU; 信号处理; 功率谱密度; HAR; 动作识别

Human posture recognition algorithm based on inertial sensors

WEI Xuanyuan

(School of Mechanical and Automotive Engineering, Shanghai University of Engineering Science, Shanghai 201620, China)

【Abstract】 Aiming at the disadvantage of huge data collected by inertial sensor (IMU) and inconvenient processing, a new inertial sensor signal processing algorithm is proposed in this paper. Firstly, the Chebyshev II high pass filter is used to eliminate the "slow" change caused by the change of the position of the body relative to the vertical gravitational field. Then, the power spectral density curve, average acceleration value and root mean square of inertial sensors signal are extracted, and a total of 60 features are extracted to replace the original signal. Finally, human motion recognition experiments are carried out using HAR public data set to verify the superiority of the algorithm. The experimental results show that the recognition accuracy of the algorithm is 92.1% and the training time is 5.268 s.

【Key words】 IMU; signal processing; power spectral density; HAR; action recognition

0 引言

人体运动信息广泛应用于运动康复、人机交互、医疗健康及人体姿态评估等领域^[1]。通过检测和识别人体特定动作可以为运动员的训练管理、医院患者的康复提供数据支持,同时在虚拟现实、人机交互上也具有广阔的应用前景^[2]。

惯性传感器(Inertial Measurement Unit)具有体积小、重量轻、成本低、精度高的特点^[3]。通过将加速度计、陀螺仪、磁力计等微型传感器内置于可穿戴设备,获取人体不同部位的加速度、角速度等信息^[3]。利用支持向量机、神经网络和深度学习等热门算法可以对人体运动信息进行识别^[4-5]。Yang等人^[6]在人体的15个部位佩戴惯性传感器对人体动作进行数据采集,并建立基于惯性传感器的数据库。吴军等人^[7]利用智能手机自带的加速度传感器采集人体运动三轴加速度信息,并利用深度卷积神经网络对走、坐、躺、跑、站五类动作进行识别,准确率可达91.2%。佟丽娜等人^[8]利用长短期记忆网络,

实现了特征自动提取,并对多类运动模式进行时序建模。实验证明此方法对慢跑、步行等识别准确率为97.5%,但自动提取的特征过多导致计算过于复杂。Hashim等人^[9]提出了一种降维技术,成功将UCI HAR数据集的561个特征减少到66个,提高计算速度的同时将活动识别精度保持在98.72%,但该方法网络结构及参数较为复杂,难以布置在小型移动设备上。

惯性传感器采集的数据量庞大且具有一定噪声,高通滤波器可以分离信号中的噪声,在特征提取的同时可以减少数据量。因此,本文提出利用切比雪夫二型高通滤波器消除由于身体相对于垂直引力场位置的变化所导致的“缓慢”变化,并提取功率谱密度曲线的峰值及坐标作为特征的数据处理算法。该算法大大减少了神经网络的训练时间,可以实时快速进行人体运动信息的处理和识别。

1 HAR数据集

HAR数据集^[10]是由19~48岁年龄段内与30

作者简介: 魏旋旋(1995-),男,硕士研究生,主要研究方向:人体姿态评估研究。

通讯作者: 魏旋旋 Email:18110337970@163.com

收稿日期: 2021-09-08

名志愿者,每人在腰部佩戴智能手机(三星 Galaxy S II)进行6项活动(行走、上楼、下楼、坐下、站立、躺下)的加速度和减速度采集所获得。该数据采用50 Hz的恒定速度捕获了3轴线加速度和角速度,并手动标记数据。获得的数据集被随机分成2组,其中70%的志愿者被选中生成培训数据,30%的测试数据被选中。传感器的佩戴位置如图1所示。



图1 传感器配置位置图

Fig. 1 Sensor configuration location

2 人体运动信息的处理和识别

2.1 信号处理算法

本文采用 Matlab2020a 对 HAR 数据进行处理。

首先将行走、上楼、站立、躺下4种活动的加速度直方图进行可视化,如图2所示。从图2中可以发现行走的平均加速度在 10 m/s^2 ,而躺下的平均加速度在 1 m/s^2 ,所以根据加速度的平均值可以很好地区分行走和躺下;行走和站立的均方根或标准偏差差距较大可以作为区分特征。而行走和上楼的加速度的平均值、均方根和标准偏差都相差不大,需要用其他方法进行区分。

惯性传感器信号的变化主要由如下因素来确定:

(1) 身体动力学导致的随时间的“快速”变化。

(2) 身体相对于垂直引力场位置的变化导致的随时间的“缓慢”变化。

本文以研究身体动力学为主,所以利用切比雪夫二型高通滤波器将第二种原因引起的信号波动淡化。滤波后的信号与原始信号的对比如图3所示。

将单个活动的加速度信号和时间信息提取出来并进行绘图。可以观察到一定的周期性变化,如图4所示。研究中可通过频域分析中的功率谱密度来寻找数据特征。

在估计加速度功率谱密度时,加速度 $a_T(t)$ 是有限持续时间内的加速度,对此进行傅里叶变换:

$$a_T(v) = \int_{-\infty}^{\infty} a_T(t) e^{-i2\pi vt} dt = \int_{-T}^T a(t) e^{-i2\pi vt} dt \quad (1)$$

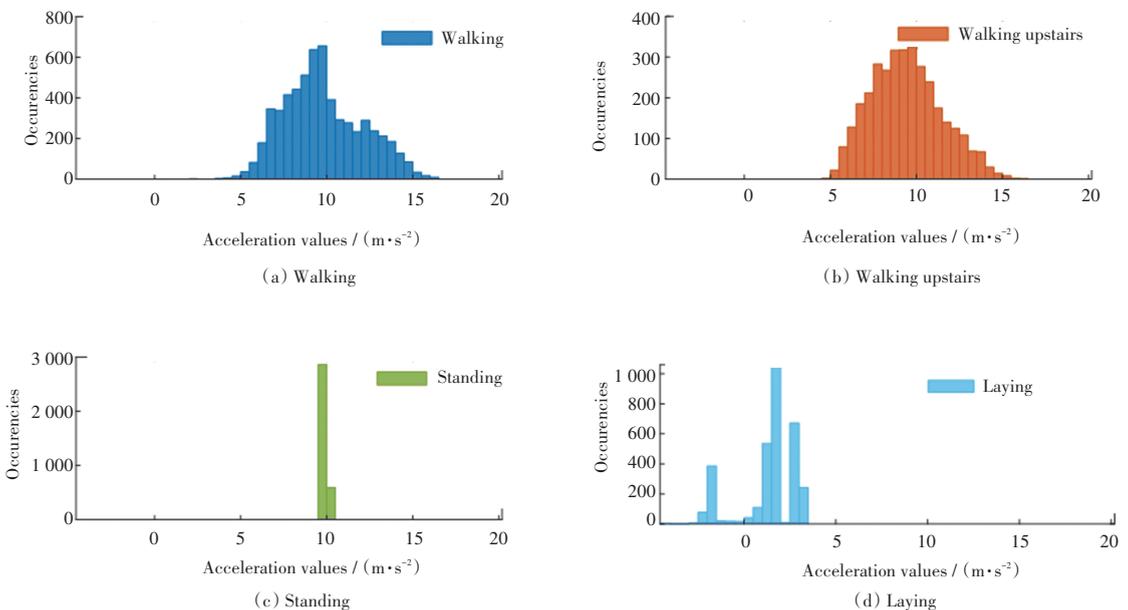


图2 加速度直方图

Fig. 2 Acceleration histogram

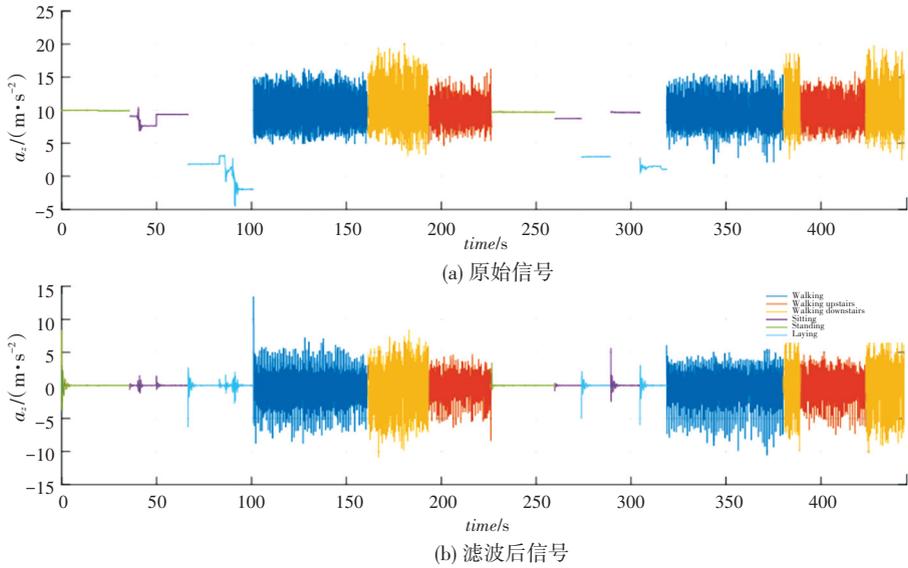


图 3 原始信号与滤波后的信号

Fig. 3 Original signal and filtered signal

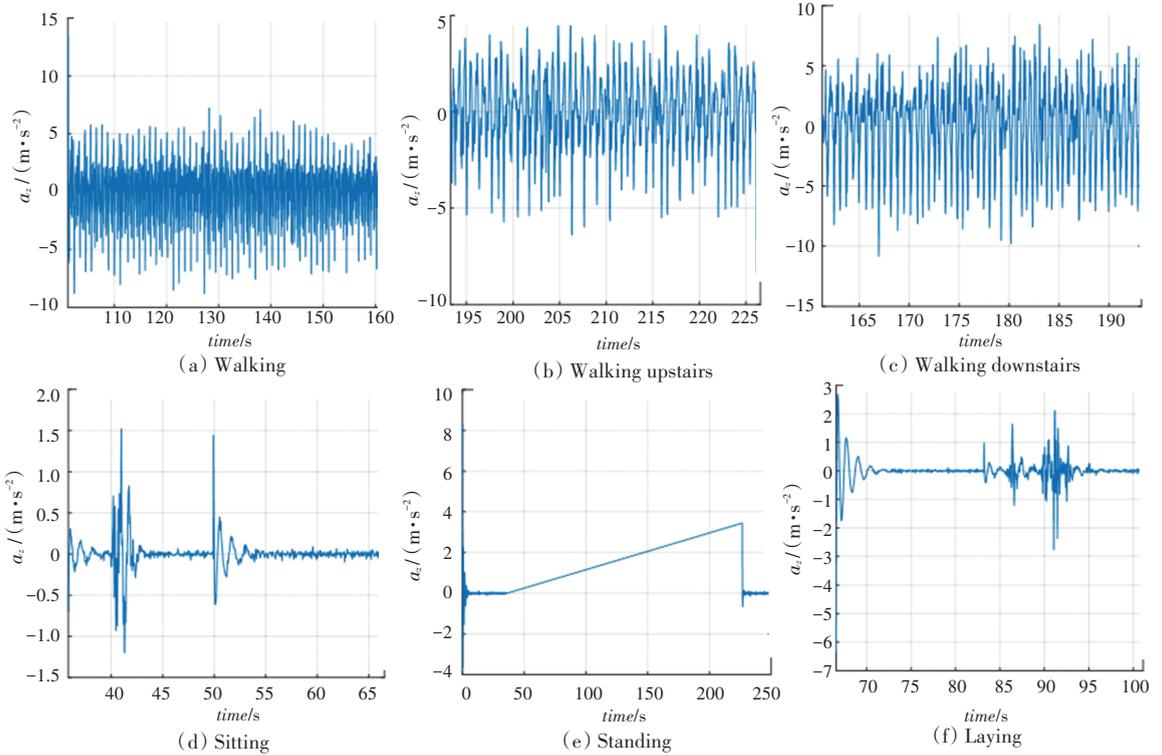


图 4 单个活动加速度与时间关系图

Fig. 4 Relationship between acceleration and time of single activity

同时,满足巴塞伐(Parseval)公式:

$$\int_{-\infty}^{\infty} a_T^2(t) dt = \int_{-\infty}^{\infty} |a_T(v)|^2 dv \quad (2)$$

式(2)中,等式左端表示加速度在时间域内的总能量,等式右端积分中的被积函数则称为能谱密度,该值表示了单位频率所含有能量,能谱密度是一个非负实数。

式(2)联立函数 $a_T(t) = \begin{cases} a(t) & |t| \leq T \\ 0 & |t| > T \end{cases}$,并对

两端同时除以 $2T$ 和令 T 趋于无穷大得:

$$\lim_{T \rightarrow \infty} \frac{1}{2T} \int_{-T}^T a^2(t) dt = \int_{-\infty}^{\infty} \lim_{T \rightarrow \infty} \frac{1}{2T} |a_T(v)|^2 dv \quad (3)$$

由式(3)可知功率谱密度为:

$$P(v) = \lim_{T \rightarrow \infty} \frac{1}{2T} |a_T(v)|^2 \quad (4)$$

行走和主楼的加速度功率谱密度对比曲线如图 5 所示。由图 5 可以发现不同活动加速度的功率谱密度曲线的峰值以及峰值所对应的坐标是不同的。

最终通过时域和频域分析以及各种直方图的分析,提取了60个特征。特征总结详见表1。

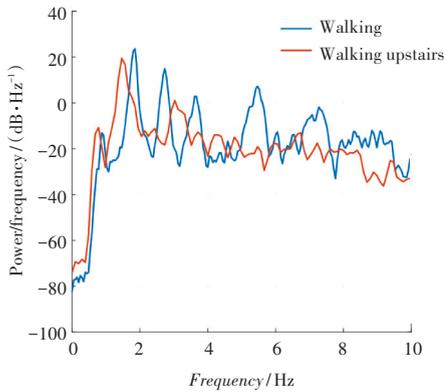


图5 行走和上楼的加速度功率谱密度对比图

Fig. 5 Comparison of acceleration power spectral density between walking and walking upstairs

表1 特征总结表

Tab. 1 Summary of characteristics

特征	描述
特征 1~3	3轴加速度平均值
特征 4~6	3轴加速度均方根
特征 7~15	3轴加速度的自相关函数的主峰高度、第二个峰高度和位置
特征 16~51	3轴加速度的功率谱密度前6个峰的高度和位置
特征 51~60	3轴加速度的功率谱密度3个相邻频段的总功率

2.2 人体姿态识别

本文利用上文数据处理算法提取数据特征,并结合已有的RNN与LSTM结合的方式搭建递归神经网络对行走、上楼、下楼、坐下、站立、躺下六项活动进行识别。网络结构设计如图6所示。本文在尝试了各种不同优化器后,最终采用Adam优化算法对参数进行优化。预处理好的60个特征经过9个递归LSTM层、1个全连接层和输出层后,给出识别结果。这种方法的预测精度达到了92.1%。

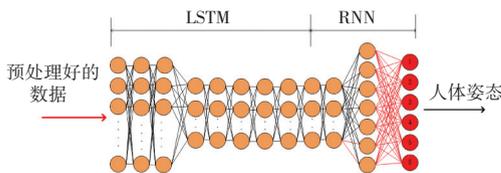


图6 递归神经网络模型

Fig. 6 Recurrent neural network model

3 实验及对比分析

为了证明本文提出的人体动作识别算法的运行性能,设计了不同算法下的准确率和运行时间对比试验。实验所需硬件系统为联想Y9000K 2019SE笔记本电脑;软件为Matlab2020a。利用本文提出的数据处理算法,处理HAR公开数据集,在利用

Matlab神经网络工具包进行人体动作识别。最终得到HAR数据集的训练集、验证集、测试集以及总的分类结果混淆矩阵,如图7所示。

Training confusion matrix

Output class	1	2	3	4	5	6	
1	881	23	21	0	0	0	95.2%
2	22	761	25	2	0	0	94.0%
3	18	29	683	0	0	0	93.6%
4	0	0	0	782	131	0	85.7%
5	0	2	0	147	866	0	85.3%
6	0	0	0	0	0	1014	100%
	16.3%	0.4%	0.4%	0.0%	0.0%	0.0%	4.8%
	0.4%	14.1%	0.5%	0.0%	0.0%	0.0%	6.0%
	0.3%	0.5%	12.6%	0.0%	0.0%	0.0%	6.4%
	0.0%	0.0%	0.0%	14.5%	2.4%	0.0%	4.3%
	0.0%	0.0%	0.0%	2.7%	16.0%	0.0%	4.7%
	0.0%	0.0%	0.0%	0.0%	0.0%	18.8%	0.0%
	95.7%	3.4%	3.7%	34.0%	36.9%	100%	92.2%
	4.3%	6.6%	6.3%	16.0%	13.1%	0.0%	7.8%

(a) 训练集混淆矩阵

Validation confusion matrix

Output class	1	2	3	4	5	6	
1	177	8	1	0	0	0	95.2%
2	6	156	6	1	0	0	92.3%
3	2	5	167	0	0	0	96.0%
4	0	0	0	165	31	0	84.2%
5	0	0	0	30	180	0	85.7%
6	0	0	0	0	0	224	100%
	15.3%	0.7%	0.1%	0.0%	0.0%	0.0%	4.8%
	0.5%	13.5%	0.5%	0.1%	0.0%	0.0%	7.7%
	0.2%	0.4%	14.4%	0.0%	0.0%	0.0%	4.0%
	0.0%	0.0%	0.0%	14.2%	2.7%	0.0%	5.8%
	0.0%	0.0%	0.0%	2.6%	15.5%	0.0%	4.3%
	0.0%	0.0%	0.0%	0.0%	0.0%	19.3%	0.0%
	95.7%	3.4%	3.7%	34.0%	36.9%	100%	92.2%
	4.3%	7.7%	4.0%	15.8%	14.7%	0.0%	7.8%

(b) 验证集混淆矩阵

Test confusion matrix

Output class	1	2	3	4	5	6	
1	178	6	6	0	0	0	93.7%
2	4	160	4	0	0	0	95.2%
3	4	8	141	0	1	0	91.6%
4	0	0	0	169	34	0	83.3%
5	0	0	0	36	187	0	83.9%
6	0	0	0	1	0	220	99.5%
	15.4%	0.5%	0.5%	0.0%	0.0%	0.0%	6.3%
	0.3%	13.8%	0.3%	0.0%	0.0%	0.0%	4.8%
	0.3%	0.7%	12.2%	0.0%	0.1%	0.0%	8.4%
	0.0%	0.0%	0.0%	14.6%	2.9%	0.0%	6.7%
	0.0%	0.0%	0.0%	3.1%	16.1%	0.0%	6.1%
	0.0%	0.0%	0.0%	0.1%	0.0%	19.0%	0.5%
	95.7%	3.4%	3.7%	34.0%	36.2%	100%	92.1%
	4.3%	8.0%	6.6%	18.0%	15.8%	0.0%	9.0%

(c) 测试集混淆矩阵

All confusion matrix

Output class	1	2	3	4	5	6	
1	1236	37	28	0	0	0	95.0%
2	32	1077	35	3	0	0	93.9%
3	24	42	991	0	1	0	93.7%
4	0	0	0	1116	196	0	85.1%
5	0	2	0	213	1233	0	85.2%
6	0	0	0	1	0	1458	99.9%
	16.0%	0.5%	0.4%	0.0%	0.0%	0.0%	5.0%
	0.4%	13.9%	0.5%	0.0%	0.0%	0.0%	6.1%
	0.3%	0.5%	12.8%	0.0%	0.0%	0.0%	6.3%
	0.0%	0.0%	0.0%	14.4%	2.5%	0.0%	4.9%
	0.0%	0.0%	0.0%	2.8%	16.0%	0.0%	4.8%
	0.0%	0.0%	0.0%	0.0%	0.0%	18.9%	0.1%
	95.7%	3.4%	3.7%	34.0%	36.2%	100%	92.1%
	4.3%	7.0%	6.0%	16.3%	13.8%	0.0%	7.9%

(d) 总的分类结果混淆矩阵

图7 混淆矩阵

Fig. 7 Confusion matrix

神经网络的接收机工作特性曲线,简称 ROC 曲线,如图 8 所示。

为了进一步验证本文提出的人体动作识别算法的优越性,本文利用其他算法模型在相同实验条件

下对 HAR 公开数据集进行处理,并识别 6 种人体姿态。试验结果与本文提出人体动作识别算法进行对比,见表 2。

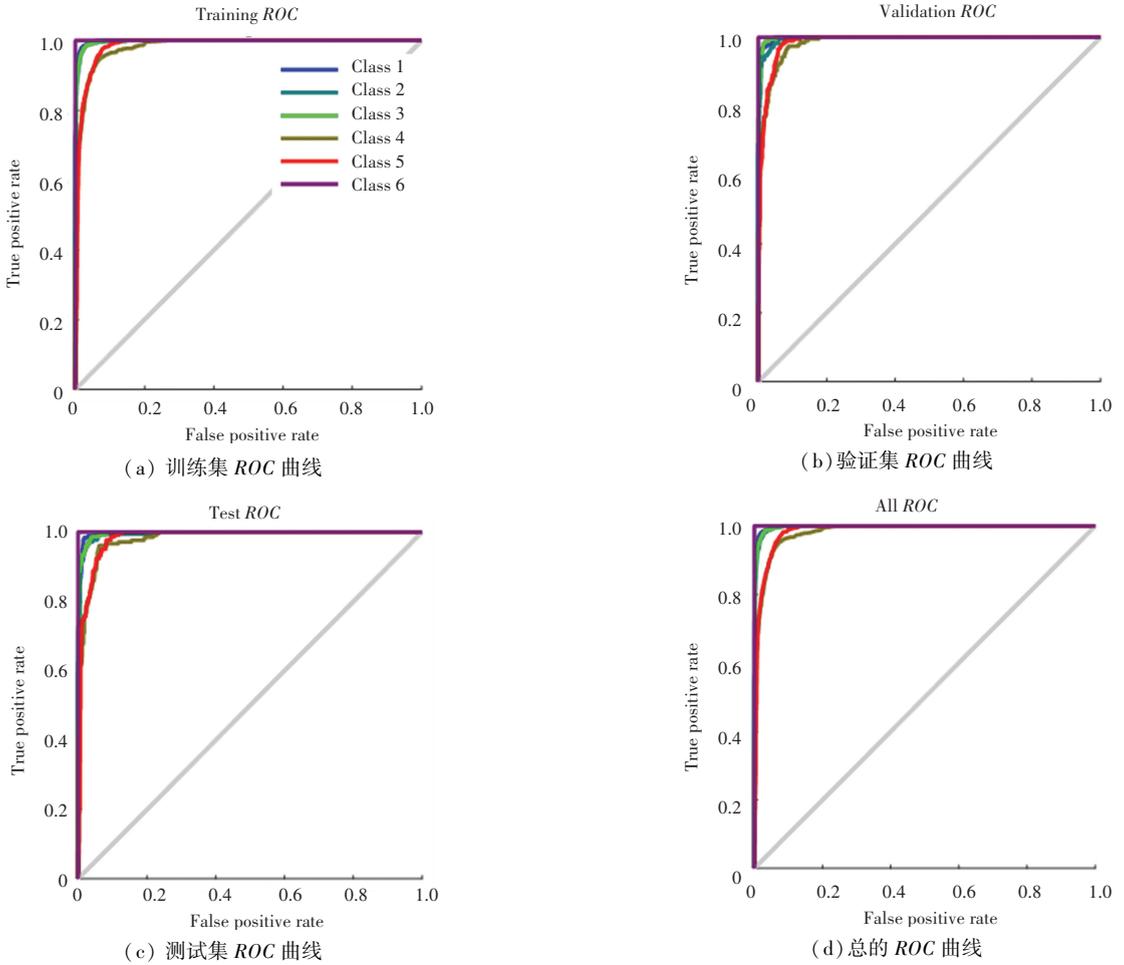


图 8 ROC 曲线

Fig. 8 ROC curve

表 2 本文算法与其他算法模型的识别准确率和训练时间对比

Tab. 2 Comparison of recognition accuracy and training time between this algorithm and other algorithm models

模型名称	识别准确率/%	训练时间/s
CNN	91.2	13.529
J48	85.1	9.683
多层感知器	91.7	10.256
SVM	91.9	7.229
本文算法	92.1	5.268

由表 2 可以看出,相同实验条件下本文提出算法在识别率上与其他算法相差不多,但在算法运行时间上得到了很大的提高,有利于对数据的实时训练识别。

4 结束语

本文提出了一种基于惯性传感器识别人体姿态的算法,解决了人体运动信息量大和识别时间长的问题。设计了不同算法在识别精度和训练时间上的对比试验,结果表明本文算法在训练时间上远快于其他算法。本研究成果有利于对人体的运动状态进行实时采集和分析,为研究人类行为打下基础。利用本文提出的算法还可以对脑卒中病人进行步态的分析和识别,同时也可以对老人跌倒行为进行识别。该算法在医疗康复上具有良好的发展空间。

(下转第 105 页)