

基于 Android 智能手机内置传感器的人体运动识别

刘进磊^{1,2} 袁清珂¹ 李 焯² 吕 雪³

¹(广东工业大学机电工程学院 广州 510006)

²(中国科学院深圳先进技术研究院 深圳 518055)

³(广州松田职业学院机电与信息工程系 广州 510006)

摘 要 文章提出了一种利用智能手机的人体运动识别算法, 将手机按使用者的习惯放置在任意的口袋中(对手机的方向和位置没有任何限制)。利用手机内置的运动传感器采集人体的运动数据, 然后将手机采集的数据在 WEKA 环境下进行特征值的挖掘, 并利用其工具箱中的 J48 决策树、贝叶斯、序列最小优化 3 种分类器对实验者的数据集进行离线分析, 其中 J48 的分类精度最高达到了 90.7%。最后利用分类效果比较好的 J48 决策树, 在手机上开发了一种实时运动分类算法。

关键词 人体运动识别; 手机内置传感器; 手机位置不固定; J48 决策树
中图分类号 TP 391 **文献标志码** A

Physical Activity Recognition Based on Android Smartphone

LIU Jinlei^{1,2} YUAN Qingke¹ LI Ye² LÜ Xue³

¹(College of Mechanical and Electrical Engineering, Guangdong University of Technology, Guangzhou 510006, China)

²(Shenzhen Institutes of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518055, China)

³(Mechanical-Electrical and Information Engineering, Guangzhou Sontan Polytechnic College, Guangzhou 510006, China)

Abstract In this paper, built-in sensors were described to automatically detect human daily activities. In contrast to the previous work, this paper intends to recognize the physical activities when the phone's orientation and position are varying. The data collected from six positions of seven subjects were investigated and two signals that are insensitive to orientation were chosen for classification. Decision trees (J48), Naive Bayes and sequential minimal optimization (SMO) were employed to recognize five activities: static, walking, running, walking upstairs and walking downstairs. The classification results of three classifiers were compared. The results demonstrates that the J48 classifier produces the best performance (average recognition accuracy: 90.7%). Then we chose the J48 classifier as online classifier.

Keywords physical activity recognition; built-in sensors; varying position and orientation; J48 decision tree

收稿日期: 2014-03-03

作者简介: 刘进磊, 硕士研究生, 研究方向为人体运动识别; 袁清珂, 教授, 硕士生导师, 研究方向为知识挖掘和信息化、多体系统动力学和计算机仿真; 李焯(通讯作者), 研究员, 博士生导师, 研究方向为移动医疗、健康物联网、绿色无线通信等, E-mail: ye.li@siat.ac.cn; 吕雪, 硕士, 研究方向计算机网络。

1 引言

用户情景感知是在普适计算领域中新兴的一种移动应用和服务。用户情景通常指用户的运动行为、情绪、喜好和位置等,情景感知的目标之一是使计算设备可以感知周围的环境变化,从而根据环境的变化自动做出基于用户需要或者设定的行为。随着现代生活方式的转变,人们的日常运动量变得越来越少。日常的运动情况不仅能够为医生诊断和治疗疾病提供丰富的参考信息,而且可靠的运动监测技术还能够更智能地提醒人们保持健康的生活方式^[1,2]。本实验的目的就是研究一种利用智能手机监测用户日常运动状况的情景感知服务方法。目前国内外对人体运动监测的研究和技术大都是基于可穿戴式传感设备^[3],如集成了很多传感器的衣服,或把传感器固定在人体的某些部位。尽管这些设备具有相对高的识别精度,但是价格昂贵,且每天把这些设备穿在身上也会给日常生活带来不便。因此,这些设备没能被广泛推广。

近年来,随着智能手机技术的快速发展^[4]和传感器技术的成熟,几乎所有的智能手机内部都集成了很多传感器,如三星 I9100 智能手机内就集成了加速度、陀螺仪、磁力、光线和近距离等传感器。另外,据 Gartner Group 公司的调查报告显示,低端智能手机(即每台售价不超过 200 美元的智能手机)所占市场份额已经达到全球市场总规模的 42.6%,大约为 4.3 亿部。因此智能手机是进行运动识别^[5,6]和运动监测的理想平台。目前已有的基于智能手机的人体运动识别方法^[7]都是把手机固定在人体的某些部位。但是,日常生活中人们更习惯于把手机随意地放在裤兜或包中。由于衣服的松紧、材质和款式均会有所不同,导致手机的方向和位置具有不确定性。显然,要使算法适用性广就要考虑手机位置和方向的多样性。本文的研究目的就是:在手机位置和

方向都不确定的情况下,实时进行人体运动识别。

2 人体运动识别

2.1 数据采集

实验使用三星 I9100 手机内置的三轴加速度、陀螺仪和磁力传感器采集数据。三种内置传感器的参数如下:三轴加速度传感器型号:STM K3DH,最大量程:19.6 m/s²,分辨率为:0.019 m/s²;三轴陀螺仪的型号:STM K3G,最大量程:34.9 rad/s,分辨率为:0.0012 rad/s;三轴磁力传感器型号:Asahi Kasei AK8973,最大量程:2000 μ T,分辨率为:0.0625 μ T。

本实验选取了 7 名实验对象(4 男 3 女,年龄:30 \pm 5 岁,体重:65 \pm 20 kg,体质指数 BMI:22.0 \pm 2.8 kg/m²)。实验之前征得了实验对象的同意,对志愿者的运动没有特殊要求,实验者按照自己的日常习惯做一系列运动。本文研究的 5 种常见的日常活动形式有:静止、走路、跑步、上楼梯和下楼梯,每一种运动持续的时间为 1 分钟。为了便于区分相邻两种运动的数据,要求实验者每做完一种运动后都静止 3~5 秒后再进行其他运动。为了完成该实验的数据采集,我们开发了一款 Android 应用程序,程序界面如



图1 数据采集应用程序界面

Fig. 1. Data collection interface

图 1 所示。主要利用手机内置的近距离和光线传感器监测距离和光线的变化来控制程序的自动运行并启动数据采集。当手机放入口袋时数据采集会自动开始, 手机拿出口袋时自动停止。我们将运动传感器采集的数据以文本格式保存在手机的 SD 数据卡中, 为后续的离线数据分析做准备。由于实验者把手机放入和拿出口袋需要时间, 而这段时间运动传感器采集的数据不是运动数据, 所以为了去除开始和结尾数据的干扰, 要求实验者把手机放入口袋后和把手机拿出口袋前都需静止 5 秒钟。

2.2 数据预处理

人体日常运动的频率一般较低^[8], 综合考虑手机长时间采集数据的电量消耗情况, 本实验将传感器的采样率设定为 25 Hz。由于数据量大, 为方便数据在手机上能够进行实时处理, 我们采用了半重叠的滑动窗口^[3]方法将采集的数据划分为多个时间窗口, 每个窗口的时间为 1.6 s, 每相邻的两个窗口有 50% 的重叠。窗口的划分方法如图 2 所示, 每个数据处理单元的数据点个数为 40。

传感器相对于手机屏幕的坐标系如图 3 所

示: x 轴水平向右, y 轴竖直向上, z 轴垂直于手机屏幕向外。由此可得到 x 、 y 、 z 轴三个方向传感器的值。由于任一时刻加速度传感器的数据中都包含了重力加速度。因此, 我们采用截止频率为 5 Hz 的低通滤波器滤除噪声干扰, 并把加速度量(A)分解为重力加速度量(GA)和线性加速度量(LA), 即 A_x 可分解为 GA_x 和 LA_x , 其余的量也采用了相同的分解方法。滤波前后走路时手机线性加速度的波形图如图 4 所示。




图 3 手机的坐标系

Fig. 3. The coordinate system of the smartphone




图 2 窗口划分示意图

Fig. 2. Window dividing diagram

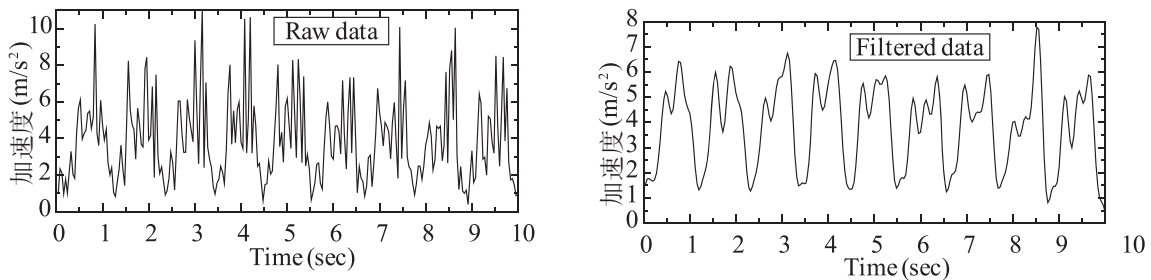


图 4 走路时采集到的手机线性加速度的值

Fig. 4. The value of acceleration of smartphone during walking

2.3 特征提取

由三轴加速度传感器的工作原理可知,传感器的方向决定坐标系 x 、 y 、 z 轴的读数。由于本实验中手机的位置和方向都不固定,因此按照手机位置固定时建立的坐标系对本实验来说是无效的。图 5 为四名志愿者随意将手机放入口袋后静止时的三轴加速度传感器的数据。尽管四名志愿者将手机放置在相同位置的口袋,但从图中我们可以看到不同的志愿者的三轴方向加速度传感器的读数完全不同。为了避免因手机方向不同而带来的麻烦,本文选取了与手机方向无关的量进行

运动识别算法的研究。设 LA_{3a} 为线性加速度的信号强度矢量(SMV), LA_{3a} 可以表示为

$$LA_{3a} = \sqrt{LA_x^2 + LA_y^2 + LA_z^2} \quad (1)$$

其中, LA_x 、 LA_y 和 LA_z 分别为 x 、 y 和 z 轴方向的线性加速度。同理,三轴陀螺仪 gry_{3z} 的 SMV 也使用了同样的计算方法。由于三轴磁力传感器的三个轴方向值比较大,我们没有使用它的 SMV 值,而是把 Ore1、Ore2 和 Ore3 (x 、 y 和 z 轴三个方向的磁力传感器值) 作为 3 个独立的特征量,加上 LA_{3a} 和 gry_{3z} 共使用了 5 个特征量。

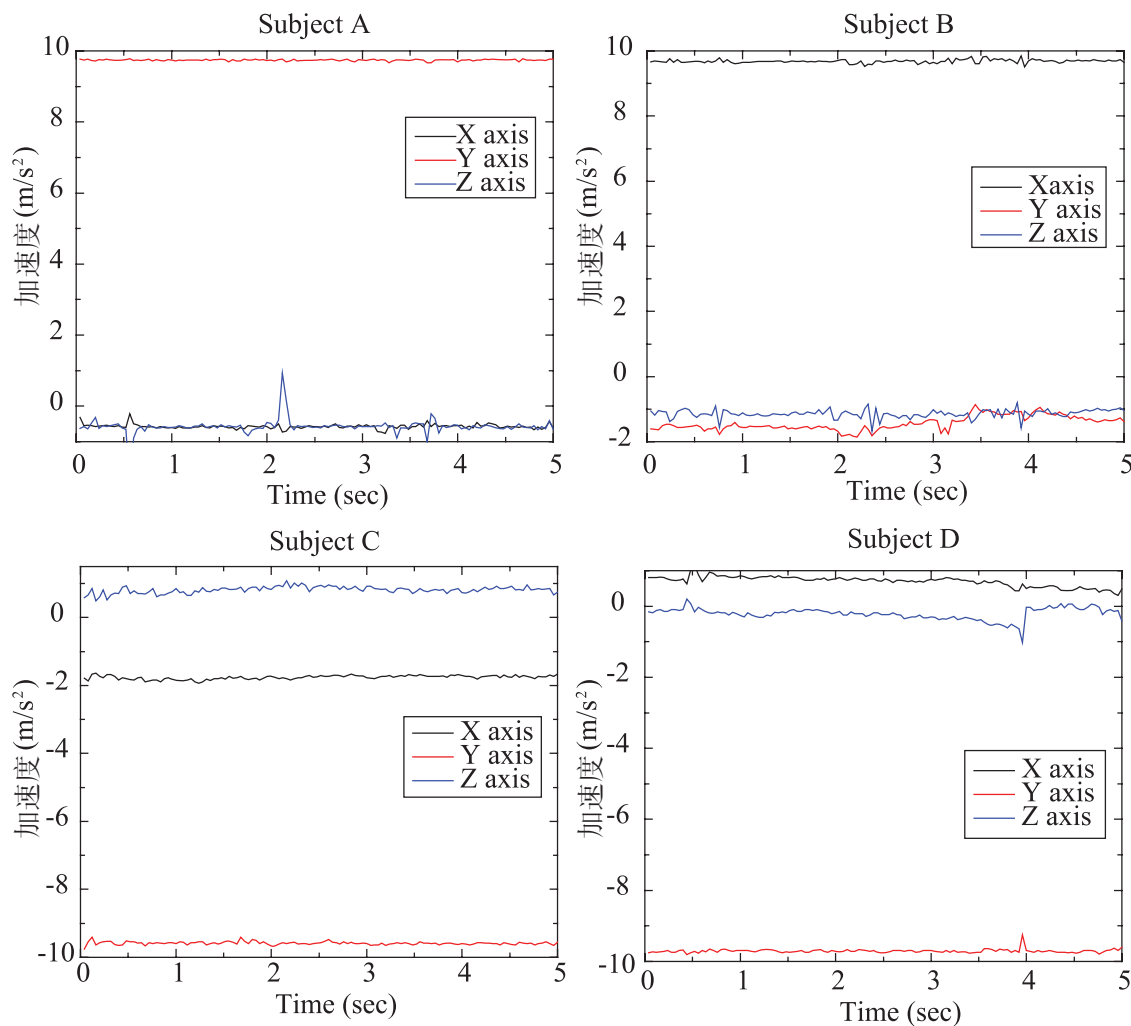


图 5 四名志愿者静止时三轴加速度传感器的读数

Fig. 5. Triaxial accelerometer sensor's reading when four subjects keep static

以每一个时间窗口为研究对象, 利用从滑动窗口提取的信号进行算法研究, 共选取了 6 个统计学特征, 它们分别是: 平均值 (Mean)、标准偏差 (Standard Deviation)、中值 (Median)、偏度 (Skewness) 和峰态 (Kurtosis) 和四分位点范围 (IR), Gyllensten 和 Zhang 等^[9, 10]已经验证了这些特征在运动识别中的有效性。

$$\text{Skewness} = \frac{n}{(n-1)(n-2)} \sum_{i=1}^n (x_i - \text{Avg})^3 / \text{std}^3 \quad (2)$$

$$\text{Kurtosis} = \frac{n(n+1) \sum (x_i - \text{Avg})^4 - 3(\sum (x_i - \text{Avg})^2)^2 (n-1)}{(n-1)(n-2)(n-3) \text{std}^4} \quad (3)$$

其中, Avg 是 x_i 的平均值, std 是 x_i 的标准偏差。

$$\text{IR} = Q_3 - Q_1 \quad (4)$$

其中, Q_3 、 Q_1 分别是窗口的 75% 和 25%。

2.4 运动状态识别算法

训练和测试数据集由 7 名志愿者身上的 6 个位置采集的传感器数据组合而成。本文选用的 5 个特征量分别又有 6 个统计学特征, 这样最终会有 30 个特征量。由于数据量非常大, 并且这 30 个特征量对分类算法的重要程度差异很大。为了减少数据量和手机的运算负荷, 我们把数据集导入 WEAK 环境下, 利用其工具箱中的 Filtered Attribute Eval 属性评估器和 Ranker 搜索方法对数据集中的数据特征量进行排序, 然后选择排名靠前的属性建立特征值集合作为实时算法的特征量。最后, 利用 WEKA 环境^[11]下的决策树 (J48)、贝叶斯 (NB)、序列最小优化 (SMO) 3 种分类器对优选后的特征值集合进行离线分析, 得到 3 种分类器的分类精度和建模时间如表 1 所示。表 1 显示, J48 决策树的分类精度为 90.7%, 高于其余两个分类器, 并且建模所需的时间也比较短。因此, 本实验最终选择 J48 决

策树分类算法来进行运动分类, 并使用十折交叉验证对决策树进行优化, 具体的设计参数如下:

- (i) confidence factor=0.25;
- (ii) minimum number of objects=30, numFolds=3;
- (iii) unpruned=True。

表 1 三种分类器的分类结果

Table 1. Classification results of three classifiers

分类器	精度 (%)	建模时间 (秒)
J48	90.7	0.98
NB	75.3	0.12
SMO	81.1	1.74

为了建立一个决策二叉树, 在训练阶段应当考虑如下设计元素: 在每一个节点, 应当确定被问到的候选问题。每个问题对应一个特定的二叉树分裂为两个后代节点。在每一个节点中, t 与训练集合 X 的特定子集 X_t 相联系。节点的分裂相当于子集 X_t 分裂为两个不相交的两个后代子集 X_{tY} , X_{tN} 。前两个包含在 X_t 中的向量, 即对应问题的结果 “yes” 和 “no”。树的第一个节点与训练集 X 有关, 对于每一次分裂下面的公式总是成立的:

$$X_{tY} \cup X_{tN} = X_t \quad (5)$$

如果较小的树的结构相对于较大的树结构能够取得较好的效果, 那么我们选择小的树结构。应当指出在每一次训练中树的大小都有可能不同。

3 结果分析与讨论

3.1 运动分类结果

根据在 WEKA 环境下的属性选择结果, 我们将排名靠前的 3 个属性特征量 LA_{3a}Mean、gyr_{3z}Mean、gyr_{3z}Std 数据导入 MATALAB, 利用

MATALAB 绘图工具得到如图 6 所示的 5 种运动分类结果的散点图。

根据 WEKA 属性选择的排序结果我们选取排名靠前的 12 个特征值建立了全特征值集合, 表 2 为使用全特征值集合时 J48 决策树分类器分类结果的混淆矩阵。由于一些特征值的计算比较

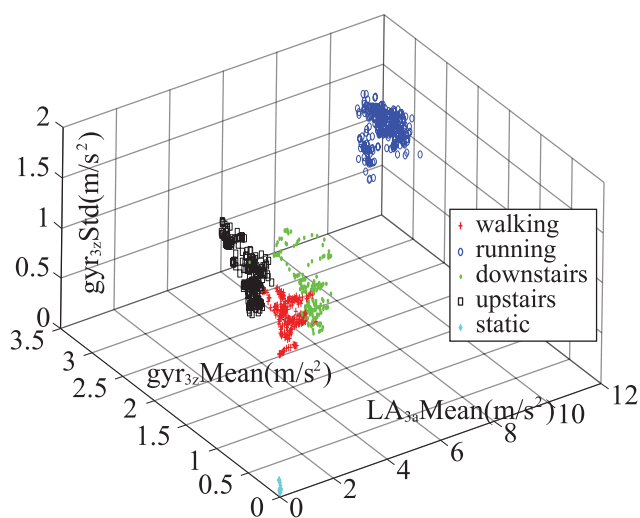


图 6 $gyr_{3z}Std$ 、 $gyr_{3z}Mean$ 和 $LA_{3a}Mean$ 3 个特征量组合得到的 5 种运动的分类散点图

Fig. 6. The scatter graphs of five activities, employing a combination of $gyr_{3z}Std$, $gyr_{3z}Mean$ and $LA_{3a}Mean$ 3

表 2 WEKA 环境下 J48 分类器的混淆矩阵

Table 2. Confusion matrix of J48 decision tree in weka environment

M \ A	W-U	W-D	W	R	S
W-U	872	16	210	15	1
W-D	32	520	74	49	0
W	120	56	2323	30	3
R	28	86	27	1939	0
S	0	0	10	0	1687

注: M 表示 Model, A 表示 Actual, W-U 表示 Walking upstairs, W-D 表示 Walking downstairs, W 表示 Walking, R 表示 Running, S 表示 Static。

复杂, 如果我们直接按照全特征集合的 WEKA 分类树在手机上建立实时分类算法, 手机的运算负荷会非常大, 严重拖累手机的运行速度。为了减少运算量, 我们对特征值进行了简化。仅选择 $LA_{3a}Mean$ 、 $gyr_{3z}Std$ 、 $gyr_{3z}Mean$ 和 $LA_{3a}MeStd$ 这几个特征值组成精简特征值集。在 WEKA 环境下进行模拟, 仅使用精简特征值集时, 分类的精度仍然可以达到 89.5%。图 7 为在 WEKA 环境下精简特征值集合使用决策树分类器的分类结果树形图, 此树形图也是我们设置实时分类算法阈值的依据。图 8 为利用此模拟分类树的结果在手机上开发的运动监测软件的实时分类效果。

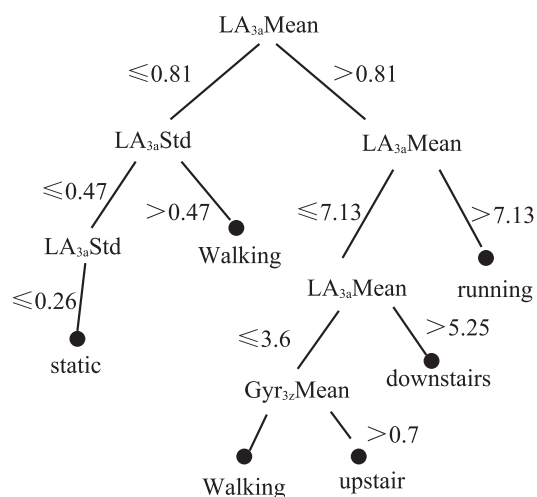


图 7 WEKA 环境下 J48 的分类结果树形图

Fig. 7. J48 tree classification results in WEKA environment



图 8 运动监测系统界面

Fig. 8. Physical activity recognition system interface

4 分类结果与讨论

由图 6 中的运动分类散点图可以看出, 静止和跑步能很明显地与其他运动区分开来。上、下楼梯和走路有很多点混淆在了一起, 主要是由于走路和上下楼梯时人体产生的加速度 LA_{3a} 值非常相似。为了能够进一步把走路和上下楼梯区分开来, 我们在随后的研究中又加入了人体倾角 (TA) 值作为我们运动划分的特征量。Sun 等^[12]通过针对某一特定位置采集的数据并对该位置的数据进行训练, 提出了基于 SVM 的算法模型, 虽然针对特定位置训练的算法使分类精度达到了 94.8%, 但是却不能自动识别手机放置的位置, 所以这种算法不具有通用性。Khan 等^[13]利用多级分类的方法, 其中用到了线性判别分析方法使离线运动识别正确率达到了 94.4%, 由于计算量比较大且计算过程相对复杂很难进行在线的实时分类。

5 结束语

本文提出的运动识别算法, 在手机位置和方向都不固定的情况下, 可实现 5 种运动类型的识别。利用 J48 决策树分类算法, 开发了一款能够监测人们日常活动的手机应用程序, 能够用于提醒人们进行合理的运动。为了减少手机的运算负荷, 采用了精简的特征值集合, 在 WEKA 环境下的仿真实验表明, 分类精度高达 89.5%。

参 考 文 献

- [1] Anderson I, Maitland J, Sherwood S, et al. Shakra: tracking and sharing daily activity levels with unaugmented mobile phones [J]. *Mobile Networks and Applications*, 2007, 12(2-3): 185-199.
- [2] Kwapisz JR, Weiss GM, Moore SA. Activity recognition using cell phone accelerometers [J]. *ACM SIGKDD Explorations Newsletter*, 2011, 12(2): 74-82.
- [3] Wang Z, Jiang M, Hu Y, et al. An incremental learning method based on probabilistic neural networks and adjustable fuzzy clustering for human activity recognition by using wearable sensors [J]. *IEEE Transactions on Information Technology in Biomedicine*, 2012, 16(4): 691-699.
- [4] Vargha D, Maia M. 运动传感器让运动变得数字化 [J]. *集成电路应用*, 2011, 2: 38-40.
- [5] 李娜, 侯义斌, 黄樟钦. 基于人体加速度特征的实时跌倒识别算法 [J]. *小型微型计算机系统*, 2012, 33(11): 2410-2413.
- [6] Khan A, Lee YK, Lee S, et al. Human activity recognition via an accelerometer-enabled-smartphone using kernel discriminant analysis [C] // *The 5th International Conference on Future Information Technology*, 2010: 1-6.
- [7] He Y, Li Y. Physical activity recognition utilizing the built-in kinematic sensors of a smartphone [J]. *International Journal of Distributed Sensor Networks*, 2013, 481580.
- [8] Wang HM, Zhu XC, Chang JB. Acceleration and orientation multisensor pedometer application design and implementation on the android platform [C] // *2011 First International Conference on Instrumentation, Measurement, Computer, Communication and Control*, 2011: 249-253.
- [9] Gyllensten I, Bonomi AG. Identifying types of physical activity with a single accelerometer: evaluating laboratory-trained algorithms in daily life [J]. *IEEE Transactions on Biomedical Engineering*, 2011, 58(9): 2656-2663.
- [10] Zhang M, Sawchuk AA. A feature selection-based framework for human activity recognition using wearable multimodal sensors [C] // *Proceedings of the 6th International Conference on Body Area Networks*, 2011: 92-98.
- [11] Hall M, Frank E, Holmes G, et al. The WEKA data mining software: an update [J]. *ACM SIGKDD Explorations Newsletter*, 2009, 11(1): 10-18.
- [12] Sun L, Zhang D, Li B, et al. Activity recognition on an accelerometer embedded mobile phone with varying positions and orientations [C] // *Proceedings of the 7th International Conference on Ubiquitous Intelligence and Computing*, 2010: 548-562.
- [13] Khan AM, Lee YK, Lee S, et al. Accelerometer's position independent physical activity recognition system for long-term activity monitoring in the elderly [J]. *Medical and Biological Engineering and Computing*, 2010, 48(12): 1-9.