

# 基于三轴传感器的老年人日常活动识别

汪成亮<sup>1,2</sup>, 王小均<sup>2</sup>

(1. 重庆大学信息物理社会可信服务计算教育部重点实验室, 重庆 400044; 2. 重庆大学计算机学院, 重庆 400044)

**摘 要:** 本文针对老年人日常活动类型及特点提出了一种基于三轴加速度传感器和 HMM (Hidden Markov Model) 的活动识别方法. 本文首先提取了针对老年人相异、相似活动的标准差、能量、相关系数、RAF (RAtio Forward)、RVF (Ratio Vertical Forward) 等特征值. 然后定义老年人的 HMM 活动识别模型. 最后在经过 Baum-Welch 算法对 HMM 进行参数训练后使用 Viterbi 算法来进行老年人活动识别. 实验结果表明, 本文方法适用于老年人的日常活动的识别, 平均识别精度达到了 93.3%, 尤其是对于相似步态活动的识别准确率达到 93.7%.

**关键词:** 活动识别; 三轴传感器; 特征提取; 隐马尔科夫模型

**中图分类号:** TP391.4

**文献标识码:** A

**文章编号:** 0372-2112 (2017)03-0570-07

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.3969/j.issn.0372-2112.2017.03.010

## Daily Activity Recognition Based on Triaxial Accelerometer of Elderly People

WANG Cheng-liang<sup>1,2</sup>, WANG Xiao-jun<sup>2</sup>

(1. Key Laboratory of Dependable Service Computing in Cyber Physical Society, Ministry of Education College of Computer Science, Chongqing University, Chongqing 400044, China; 2. Computer School, Chongqing University, Chongqing 400044, China)

**Abstract:** In the light of the motion type and characteristics of elderly people, we propose an approach which is based on triaxial accelerometer and hidden Markov model (HMM) for activities recognition. Firstly, we extract standard deviation (SD), energy, correlation coefficients, ratio forward (RAF), ratio vertical forward (RVF) as the features corresponding to different and similar activities of elderly people. Secondly, we define the activities recognition model based on HMM for elderly people. Finally, we use the Viterbi algorithm to recognize the activities for elderly people after the parameters are trained by Baum-Welch algorithm. The experimental results shows that our approach is can be applied for daily activity recognition of elderly people and the average recognition accuracy is 93.3%, specifically the accuracy of similar walking activities is 93.7%.

**Key words:** activity recognition; triaxial accelerometer; feature extract; hidden Markov model (HMM)

### 1 引言

身体活动及锻炼<sup>[1]</sup>正成为了糖尿病、骨关节炎等慢性疾病辅助治疗的重要手段之一. 老年人的活动监测有助于医生或家人了解其活动规律、类型及运动量, 提高医生对健康评价的准确性, 以制定更合适的康复治疗策略.

现有活动识别主要基于计算机视觉<sup>[2,3]</sup>及传感器技术, 前者利用图像技术, 缺点是无法识别复杂活动、易受干扰、侵犯隐私等. 而后者则具有数据获取自由、抗干

扰、保护隐私等优点. Khan Z. A 等<sup>[2]</sup>使用基于图像的老年人异常活动识别, 能有效识别相异度大的活动, 但相似活动识别不理想. Assam, R 等<sup>[3]</sup>提出的基于二进小波和 HMM 的识别方法, 该方法能有效区分相似动作. 然而在区分轴向相关性强的活动上存在一定的缺陷.

本文采用基于传感器技术进行活动识别, 解决了老年人活动的特有特征的选取及识别方法问题, 通过对比实验验证本文方法在老年人活动识别中的可行性和准确度, 同时也对比了不同传感器佩戴位置对活动识别精度的影响.

## 2 问题描述

### 2.1 数据收集

本文采用 ADXL345 三轴加速度传感器. 传感器和 PC 的通讯方式是在离线状态下通过 telosW 平台的 USB 接口来上传数据(如图 1(c)所示). 在对老年人日常活动的模拟测试后发现活动的最大加速度值不会超过 6g, 因此将  $\pm 8g$  作为传感器的测量量程, 同时采样频率设置为 100Hz.



图1 参加实验的志愿者及ADXL345三轴加速度传感器

### 2.2 问题定义

经统计, 典型日常活动主要有 standing, sitting, lying, walking, upstairs, downstairs, running 等 7 种<sup>[4]</sup>, 对于老年人来讲通常不会进行如 jumping, bicycling, swimming 等的剧烈运动. 因此定义集合  $A = \{A_1: \text{standing}, A_2: \text{sitting}, A_3: \text{lying}, A_4: \text{walking}, A_5: \text{upstairs}, A_6: \text{downstairs}, A_7: \text{running}\}$  表示老年人的日常活动集.

问题定义: 已知某时间段的加速度数据序列为  $\mathbf{d} = (d_1, d_2, d_3, \dots, d_m)$ , 其中  $d_i = (x_i, y_i, z_i)$  为  $t_i$  时刻的加速度数据, 且  $t_1 < t_2 < t_i < t_m$ . 如何根据可测量的加速度数据序列推断出该时间段内人体最可能进行的活动序列  $A^* = \{A_1, A_2, A_3, \dots, A_n\}$ , 其中  $A_i \in A$ .

针对上述活动识别问题, 本文提出的识别方法如图 2 所示: (1) 将原始信号划分为训练集和测试集; (2) 对原始信号进行简要的滤波、分段预处理后选择时域、频域或者时频域上的特征量来表示分段窗口信号特征; (3) 将所有窗口的特征向量应用聚类算法形成  $k$  个子类, 这  $k$  个子类标号作为模型的观测值; (4) 使用 Baum-Welch 算法对不同传感器佩戴位置的 HMM 模型进行参数训练, 得到参数  $\lambda$ ; (5) 使用 Viterbi 算法对活动进行识别.

## 3 识别框架

### 3.1 特征提取

由于原始数据会包含随机噪声, 在进行特征提取前须使用移动平均滤波器<sup>[5]</sup>进行滤波. 为了便于数据处理及特征的提取, 需对原始数据进行分段操作. 本文

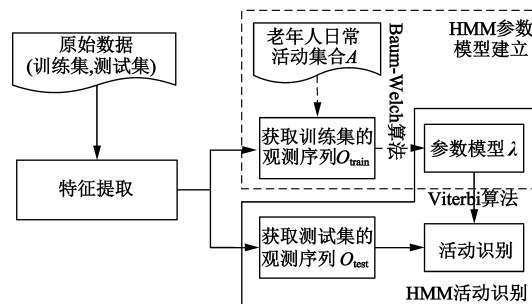


图2 基于HMM的老年人日常活动识别流程图

记  $f$  为采样频率,  $t$  为窗口的时间长度,  $T_0$  为相邻窗口的重叠率.

从老年人日常活动集中的活动类型来看,  $A_1 \sim A_3$  属于静态活动,  $A_4 \sim A_6$  则属于相似的步态活动, 而  $A_7$  在运动幅度、频率上均远大于其余活动. 为了便于识别不同的活动及对比相似步态活动的识别率, 本文将  $A$  集合分为两类:  $S = \{A_1: \text{standing}, A_2: \text{sitting}, A_3: \text{lying}, A_7: \text{running}\}$  和  $D = \{A_4: \text{walking}, A_5: \text{upstairs}, A_6: \text{downstairs}\}$ . Stephen J. Preece 等<sup>[6]</sup>的实验结果充分说明综合时、频域特征相对于只使用时频特征在识别精度上有着巨大优势. 根据不同活动的特点及上述实验结论, 本文提取的特征值如下所示.

标准差: 标准差反映了数据的离散程度. 人在静态时标准差几乎为零, 而在运动时标准差总是远大于零, 因此标准差是识别静态与动态活动的一个重要特征. 标准差 (SD) 定义如式 (1) 所示:

$$SD = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \bar{x})^2} \quad (1)$$

其中  $N$  为样本数,  $\bar{x}$  为均值,  $x_i$  为第  $i$  个样本.

能量: 为了反映不同活动在频率上的差异, 本文采用快速傅里叶变换 (FFT) 方法将信号从时域变换到频域然后计算信号能量. 频域能量 (能量) 在总体上反映了整个信号的强度. 能量 (Energy) 定义如式 (2) 所示:

$$Energy = \sum_{i=1}^N |x_i|^2 \quad (2)$$

其中  $N$  为样本数,  $x_i$  为第  $i$  个 FFT 系数.

极峰值: 在下楼时重力势能转换为动能, 使得垂直方向加速度信号的峰-峰值大于上楼时的值. 定义极峰值为垂直方向信号的峰-峰值. 利用这个特征作为正常上、下楼的一个判断条件. 极峰值 (Amp) 定义如式 (3) 所示:

$$Amp = \max(V) - \min(V) \quad (3)$$

其中  $\max(V)$ 、 $\min(V)$  分别为垂直方向信号的最大、最小值.

相关系数: 通常平地的运动, 只涉及到前进方向. 而对于上下楼活动来讲则明显的在前进、垂直方向均有

运动. 本文引入相关系数来描述前进、垂直方向运动的相关程度. 相关系数 (Corr) 定义如式(4)所示:

$$\text{Corr\_VF} = \text{corr}(\mathbf{V}, \mathbf{F}) = \frac{\text{Cov}(\mathbf{V}, \mathbf{F})}{(\sqrt{D(\mathbf{V})} \sqrt{D(\mathbf{F})})} \quad (4)$$

其中  $\text{Cov}(\mathbf{V}, \mathbf{F})$  是垂直、前进方向信号之间的协方差,  $D(\mathbf{V})$ 、 $D(\mathbf{F})$  分别为垂直、前进方向信号的方差. 相关系数特别有助于区分仅涉及到一维方向的活动<sup>[7]</sup>, 如  $A_4$  &  $A_7$  与  $A_5$  &  $A_6$ .

比例因子: 小波变换能够提取同时与时频相关的信号特征, 再结合时、频域特征, 能够较好地对不同步态活动的识别. 步态活动最有用的信息包含在 17Hz<sup>[9]</sup> 以下, 则需要对 2~6 层 (0.78~25Hz) 的信号进行特征提取. RMS (Root Mean Square)<sup>[8]</sup> 已被证明是能较好区分相似步态活动的特征量, RMS 定义如式(5)所示:

$$\text{RMS} = \sqrt{\frac{1}{N} \sum_{n=1}^N [d_j(n)]^2} \quad (5)$$

其中  $N$  为样本数,  $d_j$  为第  $j$  层分解的细节系数. 定义 RAF (RAtio Forward) 为前进方向的细节信号能量与总能量的比, 如式(6)所示; RVF (Ratio Vertical Forward) 为前进、垂直方向的 RMS 和的比, 如式(7)所示:

$$\text{RAF} = 100 \times \sum_{j=3}^{j_u} \|d_j\|^2 / \|\mathbf{F}\|^2 \quad (6)$$

$$\text{RVF} = \sum_{j=j_u}^{j_u} \text{RMS}(\text{forward}) / \sum_{j=j_u}^{j_u} \text{RMS}(\text{vertical}) \quad (7)$$

其中  $\mathbf{F}$  为前进方向信号,  $j_u$  和  $j_l$  为 RMS 的最大和第二大值对应的分解级数. 明显的 walking 活动的垂直方向的能量是小于 upstairs、downstairs 的, 那么其 RVF 值是大于后两者的, 尤其针对老年人步伐轻缓慢速的特点, 老年人步态活动的前进方向能量会显著的有异于步伐有力的年轻人. 因此使得 RVF 特征值与其他特征值相比更能体现出老年人在步态运动中的区别.

### 3.2 HMM 模型建立

HMM 是由 5 元组  $\lambda = (N, M, \pi, T, E)$  描述的, 其中  $N, M$  为状态、观测值的有限集合,  $\pi$  为初始状态概率分布,  $T$  为状态转移矩阵,  $E$  为观测值概率分布矩阵. 其中参数模型  $\lambda = (\pi, T, E)$  需用 Baum-Welch<sup>[12]</sup> 算法来训练得到, 隐藏状态序列则需 Viterbi<sup>[12]</sup> 算法求解.

#### 3.2.1 状态集合

在 HMM 解码问题中, 状态是属于待求解的有限集合. 对于活动识别来讲, 状态就是待识别的日常活动类型, 本文的 HMM 状态集合则为老年人的日常活动集  $A$ , 如图 3(b)  $A_1 - A_7$  所示.

#### 3.2.2 观测值集合

观测值集合是求解隐藏状态的重要已知条件, 值选择的好坏直接影响求解解码问题的准确性. Assam, R 等<sup>[2]</sup> 将特征向量集量化为码本, 然后将码本中的每个

码字所代表的 Voronoi 区域的质心作为观测值. Aiguang Li 等<sup>[10]</sup> 则是将提取到的特征向量  $\mathbf{V}$  编码为 16-bit 的整数, 最后将离散、分级化的特征值作为观测值.

本文观测值集合的生成是采用改进的 K-means 聚类算法<sup>[11]</sup> 对所有窗口特征向量进行聚类, 其中每个子类标号就作为一个观测值. 聚类效果评价选择 Silhouette 指标, 其定义如式(8)所示:

$$\text{Silhouette}(k) = \frac{1}{k} \sum_{i=1}^k \left\{ \frac{1}{n_i} \sum_{x \in C_i} \frac{b(x) - a(x)}{\max[b(x), a(x)]} \right\} \quad (8)$$

其中  $a(x) = \frac{1}{n_i - 1} \sum_{x, y \in C_i, x \neq y} \text{dis}(x, y)$ ,  $b(x) = \min_{j, j \neq i} \left[ \frac{1}{n_j} \sum_{x, y \in C_j} \text{dis}(x, y) \right]$ ,  $k$  为聚类的子类数,  $C_i$  为数据集的第  $i$  个子类,  $n_i$  表示子类  $C_i$  中对象的个数,  $\text{dis}(x, y)$  表示对象  $x, y$  之间的距离.  $a(x)$  为样本  $x$  与该子类中所有其他样本的平均距离,  $b(x)$  为样本  $x$  到其他每个簇中样本平均距离的最小值.

该聚类算法用以产生训练集和测试集的 HMM 的观测值集合, 观测值集合生成过程如图 3(a) 所示, 其中  $O_A = \{O_1, O_2, O_3, \dots, O_k\}$  为 HMM 观测值集合, 其中  $k$  是由该聚类算法产生的子类个数. 本文 HMM 模型如图 3(b) 所示.

### 3.3 参数训练及活动识别

前述提到 HMM 的参数模型  $\lambda$  是由 Baum-Welch<sup>[12]</sup> 算法训练得到的. 该算法的输入为观测值序列 ( $O = \{O_1, O_2, O_3, \dots, O_n\}$ , 其中  $O_i \in O_A$ ) 及产生该观测值序列的隐藏状态序列 ( $A^* = \{A_1, A_2, A_3, \dots, A_n\}$ , 其中  $A_i \in A$ ). 本文参数训练过程如算法 1 (Training Algorithm for HMM Parameters (TAHP)):

算法 1 HMM 参数训练算法 (TAHP)

---

输入: raw datalist for training (RDLTR), activities list (aList, which were labeled before)  
 输出: parameters  $\lambda$   
 初始化: set windowList (wList) & featureList (fList) & observableList (obList) to NULL;  
 1: NFDL (noise filtering Data List) = noise\_filter (RDLTR);  
 2: get each  $w_i$  from NFDL & add  $w_i$  to wList;  
 3: for each  $w_i$  in wList  
 4:  $v_i = \text{calc\_featureVal}(w_i)$ ;  
 5: add  $v_i$  to fList;  
 6: obList = improved\_K-means (fList);  
 7:  $\lambda = \text{Baum-Welch}(aList, obList)$ ;  
 8: return  $\lambda$ ;

---

TAHP 算法输入为原始加速度数据序列和经过标记的活动序列. 算法第 1 行为原始数据去噪; 第 2 行为

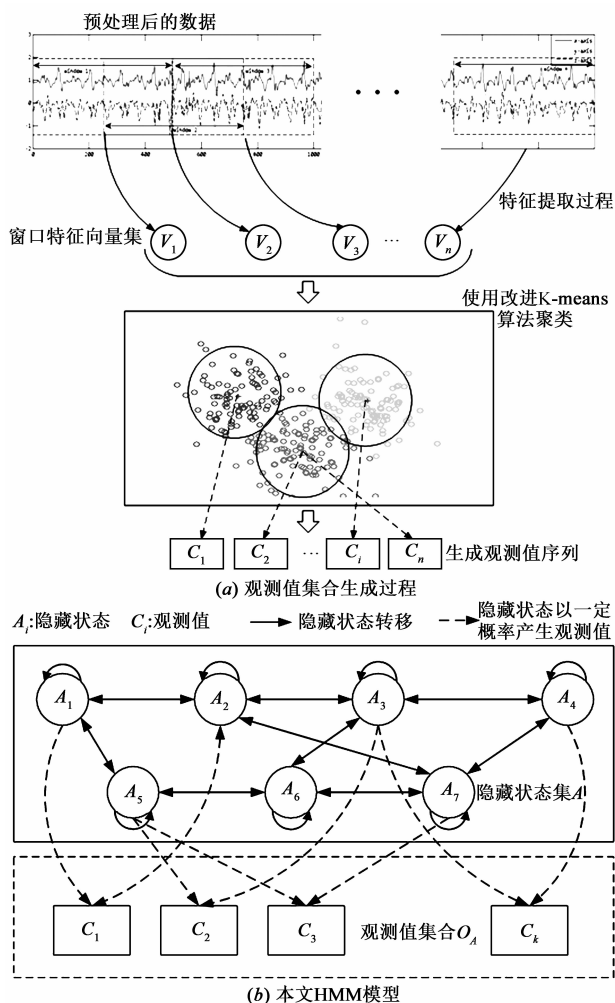


图3 观测值集合生成过程及本文HMM模型

分割加速度序列为一系列的窗口;第3~5行为计算所有窗口的特征值,并将特征值加入到 fList (特征值列表)中;第6行是将一系列的窗口特征值通过改进 K-means 算法得到 HMM 观测值序列;第7行则是将观测值序列与活动序列(已标记)作为输入使用 Baum-Welch 算法得到 HMM 的参数模型  $\lambda$ 。

在经过参数训练过程后,就得到 HMM 参数模型了,然后使用 Viterbi<sup>[12]</sup>算法识别人体活动.该算法是通过动态规划的方法来寻找出现概率最大的隐藏状态序列.本文活动识别过程如算法2(AR):

#### 算法2 活动识别算法(Activities Recognition (AR))

输入: raw datalist for testing(RDLTE), HMM( $\lambda = (\pi, T, E)$ )

输出: activitiesList(aList)

初始化: set windowList(wList) & featureList(fList) & observableList(obList) to NULL;

1: NFDL(noise filtering Data List) = noise\_filter(RDLTE);

2: get each  $w_i$  from NFDL & add  $w_i$  to wList;

3: for each  $w_i$  in wList

```

4:    $v_i = \text{calc\_featureVal}(w_i)$ ;
5:   add  $v_i$  to fList;
6: obList = improved_K-means(fList);
7: aList = Viterbi(obList);
8: return aList

```

AR 算法输入为用以测试的原始加速度数据集和经过算法1得到的参数模型  $\lambda$ . 第1~6行同算法1一致,为获取测试集的观测值序列;第7行则是根据参数模型  $\lambda$  和观测序列使用 Viterbi 算法得到隐藏的(待识别的)活动序列。

## 4 实验验证

### 4.1 实验设置

硬件参数:传感器的采样频率  $f = 100\text{Hz}$ 、量程选取  $\pm 8g$ 。

窗口参数:本文设置窗口时间长度  $t = 5\text{s}$ ,能确保能涵盖老年人的每一种活动的频率范围,相邻窗口的重叠率为  $T_o = 50\%$ <sup>[13]</sup>。

佩戴位置:老年人日常活动均与上下肢相关,因此本文选择手腕、髌部作为上下肢运动的传感器佩戴点.传感器佩戴的方向相对固定:在手腕处平行于手背方向,髌部(大腿根部)处则是平行于标准站立时的人体侧面,如图1所示。

本文设置4组实验:1. 每名实验者每次采集一种活动数据形成  $7 \times 2 = 14$  个数据文件;2. 每名实验者每次采集的数据是 A 集合的活动的随机序列组合形成  $1 \times 2 = 2$  个文件;第3、4组实验为本文活动识别方法与现有活动识别方法<sup>[3,4,10]</sup>的对比。

第1、2组实验者按照自己行为习惯进行数据收集,活动时间的长度不定,各实验者需同时在手腕和髌部佩戴传感器收集数据.其中第1组实验者需记录活动的类型;第2组实验者需记录不同活动的起止时间及相应的活动类型。

### 4.2 数据对比

本文实验需要验证不同传感器佩戴部位对识别精度的影响,因此在实验前有必要对比不同部位的数据特征值的差异,如图4~6所示。

由图4可知,当传感器佩戴位置为手腕时,各轴向数据的标准差均大于髌部.造成不同部位标准差差异的原因主要是由于手部运动灵活多变且运动幅度大,而腿部则是更趋于稳定且小幅度的运动。

由图5可知,当处于 standing、lying 活动时,不同佩戴位置对能量的影响很小. standing、lying 活动能量分别集中在  $x, z$  轴.当处于 sitting 活动时不同佩戴位置的能量也都主要集中在  $x, z$  轴,然而其能量所占比例则出现较大差异。




图4 3种静态活动(sitting、standing、lying)标准差的对比

由图 6(a)可知,垂直、前进方向的相关系数在位于手腕时均小于 0 且三者的取值较为接近;当位于腕部位置时,upstairs 的相关系数大于 0,其余则小于 0,且两者的取值相差较大。

由图 6(b)可知,手腕位置的极峰值均大于腕部,造成这一差异的原因与手部运动灵活多变、幅度大相关。由图 6(c)、6(d)可知,手腕位置的 RAF、RVF 值均相差较小,而腕部位置则能较好的区分相似步态模式。在腕部位置时 upstairs 的 RAF 值最小,可以显著的区分 upstairs 与 walking、downstairs 活动,RVF 值可以显著的区分剩余的 walking 与 downstairs 活动。

4.3 实验结果及分析

实验选取 6 名志愿者进行,使用 5 名实验者的数据进行 HMM 参数训练,剩下 1 名则作为测试。实验中需记录下窗口总数和被正确、错误识别的窗口数及类型。如此反复进行实验 6 次,最后累加各窗口数目,计算其

识别准确率。活动识别情况如表 1、表 2 所示。

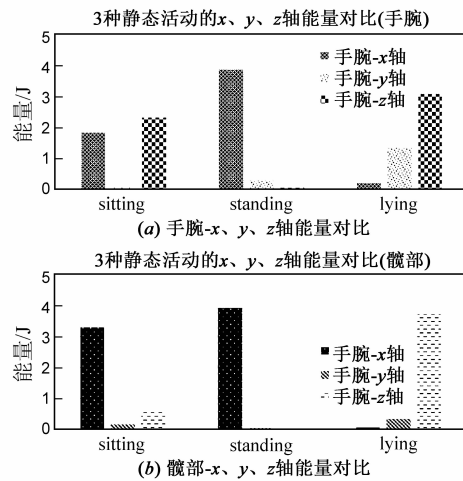


图5 3种静态活动(sitting、standing、lying)能量的对比




图6 3种相似步态活动(walking、upstairs、downstairs)在相关系数、极峰值、RAF、RVF的对比

表 1 连续单一活动识别的混淆矩阵

	手腕								腕部							
	A <sub>1</sub>	A <sub>2</sub>	A <sub>3</sub>	A <sub>7</sub>	A <sub>4</sub>	A <sub>5</sub>	A <sub>6</sub>	平均(%)	A <sub>1</sub>	A <sub>2</sub>	A <sub>3</sub>	A <sub>7</sub>	A <sub>4</sub>	A <sub>5</sub>	A <sub>6</sub>	平均(%)
A <sub>1</sub>	618	31	29	0	0	0	0	91.2	627	35	12	0	4	0	0	92.5
A <sub>2</sub>	12	578	177	0	9	0	0		rz1 74.5	22	723	18	0	9	0	
A <sub>3</sub>	28	135	534	0	0	0	0	76.7	28	19	642	0	3	5	0	92.1
A <sub>7</sub>	0	0	0	829	7	11	8	97.0	0	0	0	810	20	9	16	94.7
A <sub>4</sub>	0	0	0	4	461	389	51	rz2 50.9	0	2	1	6	841	35	20	rz4 92.9
A <sub>5</sub>	1	0	0	0	126	161	63		45.9	0	0	0	0	9	329	
A <sub>6</sub>	0	0	0	9	72	66	254	63.3	0	0	0	2	13	7	379	94.5
平均(%)	71.4								93.4							

将表 1 中的 A<sub>1</sub>,A<sub>2</sub>,A<sub>3</sub>,A<sub>7</sub> 与 A<sub>4</sub>,A<sub>5</sub>,A<sub>6</sub> 的识别率区域(recognition zone)记为 rz1-rz4。

由 rz1 可知:standing 和 running 活动与 rz3 识别准确率相差不大,然而 sitting、lying 活动的准确率则存在

较大差异. 在髌部位置的识别平均准确率达到 92.6%,但在手腕位置却只有 75.6%. 由 rz1 中的数据可知,sitting、lying 误识别是造成这一差异的原因.

由 rz3 可知:各活动的识别准确率平均达到了 93.1%. running 活动相比于其他活动在各轴向能量上都有着巨大的差异;sitting、standing 则在水平方向能量上有着巨大差距,一般的当人体处于 standing(标准站立姿势)状态时水平方向的加速度信号趋近于 0,而当处于 sitting 状态时,重力方向加速度会在水平方向上有分量而使得水平方向有一定的稳定加速度值.

由 rz2、rz4 可知:当佩戴位置为手腕时,相似步态活

动取得了较差的识别率,平均只有 53.4%. 但在髌部位置时,则取得了较好的识别率,平均达到 93.7%. 因为本文针对相似步态活动提出了 RAF 和 RVF 两个重要特征值,此外还引入了 corr\_VF 以及 Amp 作为辅助特征值来保证得到更好的相似步态活动识别准确率.

第 2 组实验目的为检验在真实环境下活动识别的准确率,实验设置同第 1 组实验. 在该组实验中要求各实验者进行真实的活动同时记录下不同活动的起止时间及其活动类型. 如图 7 所示,该名实验者进行的活动依次为:A<sub>4</sub>→A<sub>6</sub>→A<sub>4</sub>→A<sub>7</sub>→A<sub>4</sub>→A<sub>5</sub>→A<sub>4</sub>→A<sub>2</sub>,所有实验者的连续活动识别情况如表 2 所示.

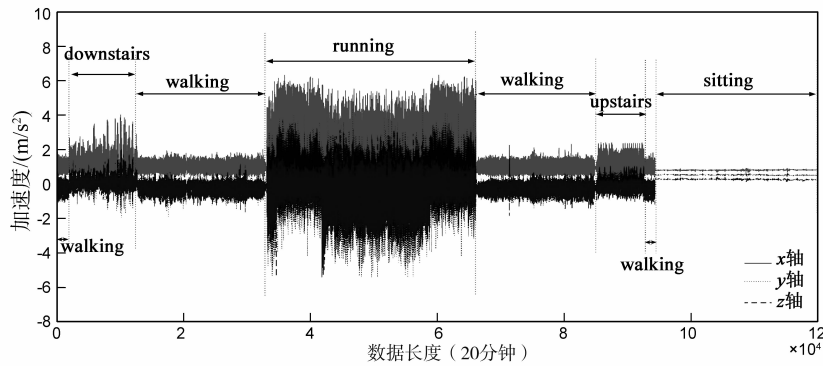


图7 真实生活活动加速度数据示例

由表 2 可知,髌部位置的活动识别率平均达到 91.1% 远高于手腕的 70.6%,但平均识别率稍低于连续单一活动的平均识别率. 原因在于不同类型活动的重叠窗口的特征值与其前后非重叠窗口的特征值差异

较大,从而导致被误识别为其他活动.

第 3、4 组实验为本文方法与现有的活动识别方法<sup>[3,4,10]</sup>识别精度对比. 实验分别使用第 1、2 组的实验数据. 活动识别率对比如表 3、表 4 所示.

表 2 连续组合活动识别的混淆矩阵

	手腕							髌部						
	sub1	sub2	sub3	sub4	sub5	sub6	平均(%)	sub1	sub2	sub3	sub4	sub5	sub6	平均(%)
正确数	338	313	403	247	441	364		438	392	517	322	568	479	
总数	480	434	561	356	620	528		480	434	561	356	620	528	
精度(%)	70.4	72.1	71.8	69.4	71.1	68.9	70.6	91.3	90.3	92.2	90.5	91.6	90.7	91.1

表 3 连续单一活动的识别率对比

	手腕(%)								髌部(%)							
	A <sub>1</sub>	A <sub>2</sub>	A <sub>3</sub>	A <sub>7</sub>	A <sub>4</sub>	A <sub>5</sub>	A <sub>6</sub>	平均	A <sub>1</sub>	A <sub>2</sub>	A <sub>3</sub>	A <sub>7</sub>	A <sub>4</sub>	A <sub>5</sub>	A <sub>6</sub>	平均
文献[3]	89.5	71.3	69.3	94.9	50.1	47.9	49.1	67.4	90.6	87.6	86.8	92.3	71.3	74.1	69.6	81.8
文献[4]	91.7	79.6	71.4	97.3	59.4	43.3	45.9	69.8	92.2	90.3	89.7	95.8	89.6	80.6	82.3	88.6
文献[10]	90.6	70.4	72.2	96.1	47.1	48.4	46.9	67.4	91.7	88.4	87.7	93.2	85.6	75.5	73.1	85.0
本文	91.2	74.5	76.7	97.0	50.9	45.9	63.3	71.4	92.5	93.2	92.1	94.7	92.9	93.7	94.5	93.4

表 4 连续组合活动的识别率对比

	手腕(%)							髌部(%)						
	sub1	sub2	sub3	sub4	sub5	sub6	平均	sub1	sub2	sub3	sub4	sub5	sub6	平均
文献[3]	62.7	64.5	67.4	65.3	63.9	69.1	65.5	83.5	86.6	80.4	78.4	82.3	81.4	82.1
文献[4]	69.6	66.4	68.3	65.4	67.4	67.2	67.4	89.2	87.3	88.4	84.3	86.1	82.8	86.4
文献[10]	64.8	61.3	61.5	68.5	65.2	64.8	64.4	84.4	83.6	80.7	81.5	82.6	84.5	82.9
本文	70.4	72.1	71.8	69.4	71.1	68.9	70.6	91.3	90.3	92.2	90.5	91.6	90.7	91.1

由表3、表4可知:1:对于所有活动识别方法来讲,腕部位置的平均识别精度远高于手腕. 2:各方法对于相异度大的活动(如 $A_1$ 、 $A_7$ )的识别精度较高,平均达到了93.2%,对于相似的步态活动则取得了较差的识别率. 3:由于提取了较多的针对于相似步态活动的特征值,因此本文的相似活动识别率高于其他方法,达到了93.7%,同时本文方法的平均活动识别率也均高于其余方法.

## 5 结论

本文方法针对老年人的活动类型及活动特点提取了标准差、能量等用以区分集合 $S$ 内的活动,提取相关系数、极峰值、RAF和RVF值用以区分 $D$ 集合中的相似的步态活动;并且使用了针对连续活动数据的HMM活动识别方法. 实验证明了本文方法能有效的识别老年人的活动,对于连续单一活动的平均准确率达到93.4%,尤其是对于相似活动其平均识别率达到了93.7%,对于随机组合序列活动的准确率达到91.1%.

### 参考文献

- [1] Durstine J L, Gordon B, Wang Z, et al. Chronic disease and the link to physical activity[J]. *Journal of Sport & Health Science*, 2013, 2(1): 3 - 11.
- [2] Khan Z A, Sohn W. Abnormal human activity recognition system based on R-transform and kernel discriminant technique for elderly home care [J]. *IEEE Transactions on Consumer Electronics*, 2011, 57(4): 1843 - 1850.
- [3] Assam, R, and T. Seidl. Activity recognition from sensors using dyadic wavelets and hidden Markov model[A]. 2014 IEEE 10th International Conference on Wireless and Mobile Computing, Networking and Communications (WiMob)[C]. Larnaca, Cyprus: IEEE, 2014. 442 - 448.
- [4] Trabelsi D, Mohammed S, Chamroukhi F, et al. An unsupervised approach for automatic activity recognition based on hidden Markov model regression [J]. *IEEE Transactions on Automation Science & Engineering*, 2013, 10(3): 829 - 835.
- [5] 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 & Biological Engineering & Computing*, 2010, 48(12): 1271 - 1279.
- [6] Preece S J, John Yannis G, Kenney L P J, et al. A comparison of feature extraction methods for the classification of dynamic activities from accelerometer data [J]. *IEEE Transactions on Biomedical Engineering*, 2009, 56(3): 871 - 879.
- [7] Ravi N, Dandekar N, Mysore P, et al. Activity recognition from accelerometer data[A]. *Proceedings of the 17th Conference on Innovative Applications of Artificial Intelligence [C]*. Pittsburgh, Pennsylvania, USA: AAAI, 2005. 1541 - 1546.
- [8] Wang N, et al. Accelerometry based classification of walking patterns using time-frequency analysis[A]. *IEEE Engineering in Medicine and Biology Society, 29th Annual International Conference of the IEEE [C]*. Lyon, France: IEEE, 2007. 4899 - 4902.
- [9] Sekine M, Tamura T, Fujimoto T, et al. Classification of walking pattern using acceleration waveform in elderly people[A]. *Proceedings of the 22nd Annual International Conference of the IEEE Engineering in Medicine and Biology Society [C]*. Chicago, Illinois, USA: IEEE, 2000. 1356 - 1359.
- [10] Li A, Ji L, Wang S, et al. Physical activity classification using a single triaxial accelerometer based on HMM[A]. *IET International Conference on Wireless Sensor Network [C]*. Beijing, China: IET, 2010. 155 - 160.
- [11] 周世兵, 徐振源, 唐旭清. 新的均值算法最佳聚类数确定方法[J]. *计算机工程与应用*, 2010, 46(16): 27 - 31.
- [12] L R Rabiner. A tutorial on hidden Markov models and selected applications in speech recognition [J]. *Proceedings of IEEE*, 1989, 77(2): 257 - 286.
- [13] Ling B, Intille S S. Activity recognition from user-annotated acceleration data [J]. *Lecture Notes in Computer Science*, 2004, 2(1): 1 - 17.

### 作者简介



汪成亮(通信作者) 男, 1975年5月生于四川资阳. 博士, 现为重庆大学计算机学院教授, 博士生导师. 主要研究领域为复杂系统智能控制, 人工智能理论与应用, 无线网络及RFID研究与应用等.

E-mail: wangcl@cqu.edu.cn



王小均 男, 1991年1月生于重庆. 硕士. 主要研究方向为物联网、穿戴式计算.

E-mail: 20095358@cqu.edu.cn