

## 单传感器数据驱动的人体日常短时行为识别方法

苏本跃<sup>1,2</sup>, 郑丹丹<sup>1,2</sup>, 汤庆丰<sup>3</sup>, 盛敏<sup>2</sup>

- (1. 安庆师范大学 计算机与信息学院, 安徽 安庆 246011;
2. 安徽省智能感知与计算重点实验室, 安徽 安庆 246011;
3. 杭州师范大学 医学院, 浙江 杭州 311121)

**摘要:** 在基于惯性传感器的人体行为识别研究中, 特征提取是其中的关键环节之一。而离散数据统计特征的稳定性依赖于特征提取的窗口大小。一般来说, 训练数据的窗口长度需要大于一个运动周期。因此, 针对测试数据远小于一个运动周期的短序列样本识别问题, 提出了一种基于模板匹配的新解决方案。首先, 通过适当分割训练数据的长序列样本, 构建一个过完备的短时行为模板库, 将待测短时样本与模板库中样本进行一致化处理并进行匹配; 其次, 在匹配算法中, 采用样本间的  $F$  范数与整体梯度向量的 2 范数累加作为匹配度量准则, 得到相似度直方图; 最后, 基于相似度直方图, 根据投票策略得到最终分类识别结果。实验表明: 在使用单传感器识别短时行为的情况下, 新算法比传统算法在精度和稳定性上具有更好的性能, 并能适应不同窗口下短时行为分类问题。

**关键词:** 短时行为; 模板匹配; 行为模板库; 相似度直方图; 单传感器  
中图分类号: TP181 文献标志码: A DOI: 10.3788/IRLA201948.0226003

## Human daily short-time activity recognition method driven by single sensor data

Su Benyue<sup>1,2</sup>, Zheng Dandan<sup>1,2</sup>, Tang Qingfeng<sup>3</sup>, Sheng Min<sup>2</sup>

- (1. School of Computer and Information, Anqing Normal University, Anqing 246011, China;
2. The Key Laboratory of Intelligent Perception and Computing of Anhui Province, Anqing 246011, China;
3. Medical College, Hangzhou Normal University, Hangzhou 311121, China)

**Abstract:** In the study of human activity recognition (HAR) based on the inertial sensor, feature extraction was one of the key points. The stability of discrete data statistical features depended on the window size of feature extraction. Generally speaking, the length of window needed to be greater than one motion cycle. Therefore, compared to the traditional behavior recognition, short-time behavior recognition was more difficult. Thus a novel template matching method was proposed for recognizing the test samples whose durations were shorter than one motion cycle. Firstly, by properly dividing the long sequence samples, a complete short-time activity template library was constructed. The short-time samples to be tested and the samples in the template library were processed and matched. Secondly, in

收稿日期: 2018-09-10; 修订日期: 2018-10-20

基金项目: 国家自然科学基金(61603003, 11471093); 教育部“云数融合科教创新”基金(2017A09116); 安徽省高校优秀拔尖人才培养资助项目(gxbjZD26)

作者简介: 苏本跃(1971-), 男, 教授, 博士, 主要从事机器学习、图形、图像处理等方面的研究。Email: subenyue@sohu.com

the matching algorithm, the similarity histogram was obtained by utilizing the sum of the  $F$  norm distance between the samples and the 2 norm distance of the global gradient vector as the matching metric. Finally, based on the similarity histogram, the final classification recognition results were obtained according to the voting strategy. Experiments show that in the case of using a single sensor to identify short-term behavior, the new algorithm had better performance than traditional algorithms in accuracy and stability, and can be adapted to short-term behavior classification problems under different windows.

**Key words:** short-time activity; template matching; activity template library; similarity histogram; single sensor

## 0 引言

人体行为识别 (Human Activity Recognition, HAR) 发展迅速, 且该研究领域一直受到人们的广泛关注。一般来说, HAR 分为基于计算机视觉的行为识别<sup>[1-2]</sup>和基于传感器的行为识别<sup>[3-4]</sup>。区别于基于计算机视觉的行为识别方法, 加速度传感器设备简单、成本低、信息量丰富, 不受时间和空间的限制。随着智能手机等设备的普及, 目前基于单传感器的行为识别方法研究已经越来越得到重视。但由于数据维度较低, 在一些识别精确度要求高, 且须具有较强的泛化能力的应用场合, 基于单传感器的行为识别在特征选择和提取、分类器设计等方面具有一定的难度。

可穿戴行为识别在健康监测、智能看护、影视动漫、人机交互都有广泛应用。在传统行为识别中, 对测试样本的要求通常包含一个运动周期以上, 即大于 1.0~1.5 s。故在传统行为识别中, 分割的窗口大小一般在 2~10 s 之间<sup>[5-6]</sup>。由于传统特征的稳定性依赖于长时运动下的大样本数据序列, 在小样本情况下, 一般在运动序列小于 30 帧时(0.3 s), 其统计特征不稳定<sup>[7]</sup>。因此, 面向窗口长度较小的短时行为分类识别问题, 涉及到运动序列数据是小样本分类, 传统的依赖大样本统计的特征提取方法并不适用。

由于同一个长时行为可以分割成多个不同的短时行为, 因此, 在人体短时行为识别研究中, 笔者不仅需要考虑到不同行为类别的类间差异性和相同行为类别的类内相似性, 还需要研究相同行为类别之间的类内差异性。同时注意到, 待测短时行为的起始点和持续时间都是不确定的。因此, 短时行为的研究无疑比长时行为更加复杂。

为了避免在短时行为识别算法中由传统统计特征带来的不稳定性, 基于 Object Bank<sup>[8]</sup>和 Action Bank<sup>[9]</sup>的思想, 提出了一种基于构建短时行为模板库的算法。通过对长时行为运动序列样本的切割, 建立一个带有标签的短时行为模板库, 其中包含了在一个运动周期内任一时刻为起始点的固定大小的短时行为模板。在分类过程中, 采用样本间的  $F$  范数距离和整体梯度向量的 2 范数距离和作为匹配度量准则, 得到相似度直方图。根据投票策略得到最终识别结果。

在整个模型构建中, 需要考虑以下三个问题:

(1) 短时行为库中模板数量的多少和模板长度的大小。库中模板数量的多少直接影响模型性能。当模板库中模板过多, 测试样本需要与库中模板一一匹配, 导致计算量增大, 使得模型过于冗余。另一方面, 模板的大小直接影响算法的性能。模板样本长度越大, 所包含的运动信息越多, 导致计算量增加。模板样本过小, 所包含的信息过少, 则直接影响其识别效果;

(2) 测试样本与模板样本长短不一致问题。在实际应用中, 得到的测试样本大小不固定, 针对测试样本长度大于模板样本和小于模板样本两种情况, 需要通过对其中较长的样本进行分割去解决这两种情况;

(3) 样本间匹配度量准则的确定。采用合适的匹配度量方法求测试模板与模板样本的相似度尤为重要。文中提出采用样本间的  $F$  范数距离和整体梯度向量的 2 范数距离和去度量样本间相似度。

短时行为识别方法还可以在智能下肢假肢的运动意图识别中得到较好应用。研究步态运动意图主要分为稳态模式和转换模式的识别<sup>[10-14]</sup>。稳态模式是运动中保持同一种运动形态, 转换模式是从一种

运动转换为另一种运动的中间过渡模式。其中 Liu 等<sup>[10]</sup>识别出三种不同速度水平下平地行走、上楼、下楼、上坡以及下坡五种稳态运动模式,识别率为 95.8%。稳态模式的意图识别从数据处理角度看,与传统行为识别方法具有相似性。两者都是在采集不同运动数据后进行数据训练和数据识别。不同的是传统行为识别中,需要长序列数据以包含更加丰富的信息,并使得其统计特征相对稳定,而意图识别的本质是在极短的运动序列中识别行为的类别。因此,在算法设计过程中,核心问题是及时识别短时行为,即把稳态模式的运动意图识别问题转变为短时行为识别问题。

### 1 短时行为库的建立

由于原始数据采集过程中不可避免地存在噪声和丢包情况,因此需要在计算前对数据进行平滑处理。为了消除噪声对分类器的干扰,采用移动平均滤波方法对数据进行平滑处理。如图 1 所示,同一动作在三个方向上的加速度数据经过滤波后,数据不仅保留了原始信号的基本趋势,而且还反映了信号的局部特征。

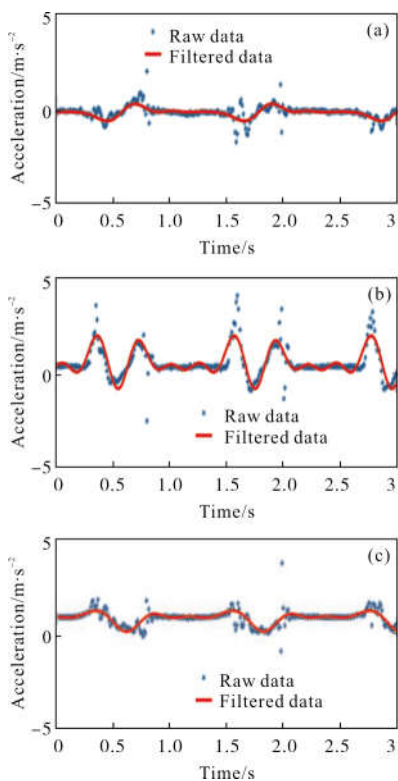


图 1 数据预处理示例

Fig.1 Data preprocessing example

### 1.1 数据分割

数据预处理过后,则通过滑动窗口对长时运动数据进行分割,得到不同模式的短时人体行为序列。由于短时行为库中模板数量的多少影响模型的冗余程度,模板数量过多,增加计算复杂度,模板数量过少,不足以囊括不同的行为模式,将出现欠拟合的情况。通过对行为曲线的分析,发现大部分日常行为具有周期性连续性,不同行为曲线之间形状和数值具有明显差异,且在单个周期就能区分,因此,在构建短时行为模板库时,只需提取合适的待分割的长时行为序列。

图 2 中曲线上的 A 点和 B 点是一个周期运动序列的起始点和结束点,则一个完整的行为周期长度为  $DS$ ,滑动窗口长度为  $WS$ ,由上文分析可得,短时样本起始点可以是周期任一点,所以,待分割的长时行为序列长度为  $WS+DS$ 。

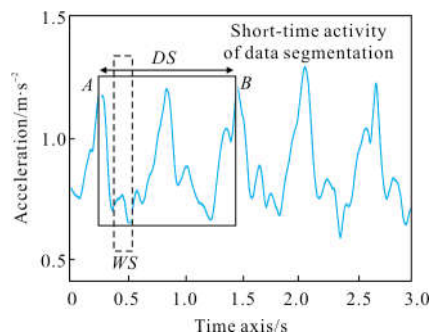


图 2 短时行为数据分割

Fig.2 Segmentation for short-time activity data

不同行为和不同样本的周期不同,对每个样本先提取周期再进行分割比较复杂,因此,在具体试验中,为了算法的简便,选取一个大于所有样本周期的长度作为待分割的长时行为序列的长度,以保证笔者构建的短时样本库的过完备性。

传感器对人体连续运动采样,产生一个长时行为的观测矩阵如下:

$$S = \begin{bmatrix} a_1(t_1) & a_2(t_1) & \cdots & a_M(t_1) \\ a_1(t_2) & a_2(t_2) & \cdots & a_M(t_2) \\ \vdots & \vdots & \vdots & \vdots \\ a_1(t_n) & a_2(t_n) & \cdots & a_M(t_n) \end{bmatrix}_{n \times M} \quad (1)$$

式中: $n$ 表示采样帧数; $M$ 表示传感器产生的数据维度(自采集数据集包括三个方向的加速度和三个方向的角速度,则  $M$  为 6;WARD1.0 包括三维加速度和两

维偏转角速度,则  $M$  为 5)。短时样本矩阵则通过滑动窗口分割方法从原始样本矩  $S$  阵中分割得到,窗口大小为  $WS$ ,周期为  $DS$ ,滑动窗口的滑动步长为 1,则有:

$$S_i = \begin{bmatrix} a_1(t_i) & a_2(t_i) & \cdots & a_M(t_i) \\ a_1(t_{i+1}) & a_2(t_{i+1}) & \cdots & a_M(t_{i+1}) \\ \vdots & \vdots & \vdots & \vdots \\ a_1(t_{i+WS}) & a_2(t_{i+WS}) & \cdots & a_M(t_{i+WS}) \end{bmatrix}, \dots, S_{i+DS-1} = \begin{bmatrix} a_1(t_{i+DS-1}) & a_2(t_{i+DS-1}) & \cdots & a_M(t_{i+DS-1}) \\ a_1(t_{i+DS}) & a_2(t_{i+DS}) & \cdots & a_M(t_{i+DS}) \\ \vdots & \vdots & \vdots & \vdots \\ a_1(t_{i+WS+DS-1}) & a_2(t_{i+WS+DS-1}) & \cdots & a_M(t_{i+WS+DS-1}) \end{bmatrix} \quad (2)$$

式中:  $i$  是长时行为周期的任意起始时刻。由滑动窗口分割得到的  $\{S_i, S_{i+1}, \dots, S_{i+DS-1}\}$  即为由一个长时样本分割得到的短时行为矩阵集合。

### 1.2 短时样本长度的确定

短时行为库中模板的长短至关重要。由步态周期中的知识可知,一个步态周期都要经历支撑相和摆动相。支撑相指脚与地面接触的时期,支撑身体的重量实现重心转移。包含单足支撑相与双足支撑相,单侧下肢站立时称“单支撑相”,双侧下肢同时站立时称为“双支撑相”。在文中,将短时行为定义为一个步态的一次变化的,若将短时行为持续时间看作步态周期的一次变化持续时间,那么当一个完整步态周期为 1.0~1.5 s 时,则可在持续时间为 0.25~0.375 s 的短时行为中识别出其运动类别。

通过大量对比实验(自采集数据集,采样频率 96 Hz),得到模板样本窗口的大小与识别率的对应关系,如图 3 所示,当窗口大小在 15 帧(约 0.15 s)时,识别率在 90% 以上,当窗口长度小于 10 帧时,算法识别效果便大幅度下降。分析得到,模板样本选取

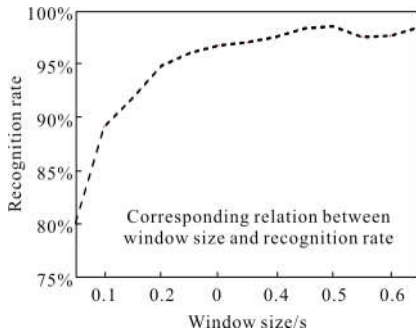


图 3 模板样本大小对识别率的影响

Fig.3 Relationship between template size and recognition accuracy

窗口长度为 30 帧(约 0.31 s)的短时行为作为样本库中的模板样本最佳。且对于测试样本的选取,长度在 10 帧(0.10 s)以上。

## 2 测试样本与模板样本的匹配算法

一般机器学习算法中,测试样本的特征向量和训练样本特征向量大小需要一致,但在实际应用中,采集到的测试样本长度往往与模板库中样本长度不一致,针对这种情况,将在下文中详细介绍。

### 2.1 相似性度量

测试样本与模板样本的匹配过程中,采用样本间的  $F$  范数距离和整体梯度向量的 2 范数距离和作为匹配度量准则。具体来说,在构建短时行为模板  $S = \{S_1, S_2, \dots, S_k\}$  后,对于一个测试样本

$$T = \begin{bmatrix} \bar{a}_1(t_i) & \bar{a}_2(t_i) & \cdots & \bar{a}_M(t_i) \\ \bar{a}_1(t_{i+1}) & \bar{a}_2(t_{i+1}) & \cdots & \bar{a}_M(t_{i+1}) \\ \vdots & \vdots & \vdots & \vdots \\ \bar{a}_1(t_{i+n}) & \bar{a}_2(t_{i+n}) & \cdots & \bar{a}_M(t_{i+n}) \end{bmatrix}, \text{ 需要逐一与}$$

短时行为模板对比。单个模板样本为:

$$S_i = \begin{bmatrix} a_1(t_i) & a_2(t_i) & \cdots & a_M(t_i) \\ a_1(t_{i+1}) & a_2(t_{i+1}) & \cdots & a_M(t_{i+1}) \\ \vdots & \vdots & \vdots & \vdots \\ a_1(t_{i+WS}) & a_2(t_{i+WS}) & \cdots & a_M(t_{i+WS}) \end{bmatrix}. \text{ 则测试样本与}$$

模板样本的距离度量如下:

$$D_i = \|T - S_i\|_F^2 \quad (3)$$

矩阵  $F$  范数的定义如下,若  $A = (\alpha_1, \alpha_2, \dots, \alpha_n)$ ,

其中  $a_i = (a_{1i}, a_{2i}, \dots, a_{ni})^T$ , 则  $\|A\|_F^2 = \sum_{i=1}^n \|\alpha_i\|_2^2$ 。在求得测试样本与模板样本的  $F$  范数后,将其标准化得到:

$$d_i = \frac{D_i - D_{\min}}{D_{\max} - D_{\min}} \quad (4)$$

通过对短时行为离散数据分析观测到短时行为在每个维度的时间序列数据,其整体的曲线梯度是运动行为的重要特征。图 4 中,可选取其整体斜率差作为样本间的匹配度量准则。即每个短时行为有  $M$  个维度,则测试样本整体斜率向量为  $k(T) = (k(T_1), k(T_2), \dots, k(T_M))$ , 模板样本的整体斜率向

量为： $k(S_i)=(k(S_{i_1}),k(S_{i_2}),\dots,k(S_{i_w}))$ 。

则两者的斜率差为：

$$ek_i = \left\| k(T) - k(S_i) \right\|_2 = \sum_{j=1}^M \left\| k(T_j) - k(S_{ij}) \right\|_2 \quad (5)$$

同样的,将其标准化:

$$\overline{ek}_i = \frac{ek_i - ek_{\min}}{ek_{\max} - ek_{\min}} \quad (6)$$

最后,采用  $\theta_i$  来度量样本间相似度,即:

$$\theta_i = 1 - wd_i - (1-w)\overline{ek}_i \quad (7)$$

式中： $\theta_i$  反映了测试样本与模板样本的相似性,  $\theta_i$  越大,则说明测试样本与模板样本越相似。




图 4 短时行为曲线斜率示例

Fig.4 Slope of short-time activity curve examples

## 2.2 相似度直方图

将一个测试样本与模板库中所有模板样本按公式(7)进行运算,可得到所有相似度值  $\theta = \{\theta_1, \theta_2, \dots, \theta_k\}$ , 由于模板库中的样本容量足够大,故相似度值趋于 1 时,在大样本环境下近似呈现正态分布特性。按照正态分布中  $3\sigma$  原则,选取若干个最接近 1 的  $\theta$  值(一般取  $\theta \geq 0.985$ ),在此基础上将同类别的  $\theta$  值相加,从而构建相似度直方图,如图 5 所示。最后基于投票原则,得到识别分类结果。图 5 是测试样本总的识别流程。

## 2.3 测试样本与模板样本不一致问题

由上文可知,短时行为模板库中模板为  $S_i =$

$$\begin{bmatrix} a_1(t_i) & a_2(t_i) & \dots & a_M(t_i) \\ a_1(t_{i+1}) & a_2(t_{i+1}) & \dots & a_M(t_{i+1}) \\ \vdots & \vdots & \vdots & \vdots \\ a_1(t_{i+WS-1}) & a_2(t_{i+WS-1}) & \dots & a_M(t_{i+WS-1}) \end{bmatrix}, \text{长度为 } WS,$$

$$\text{测试样本为 } T = \begin{bmatrix} \bar{a}_1(t_i) & \bar{a}_2(t_i) & \dots & \bar{a}_M(t_i) \\ \bar{a}_1(t_{i+1}) & \bar{a}_2(t_{i+1}) & \dots & \bar{a}_M(t_{i+1}) \\ \vdots & \vdots & \vdots & \vdots \\ \bar{a}_1(t_{i+n-1}) & \bar{a}_2(t_{i+n-1}) & \dots & \bar{a}_M(t_{i+n-1}) \end{bmatrix},$$

长度为  $n$  (在实际应用中,  $n$  的长度是随机不确定的)。当测试样本长度等于模板样本长度,即  $n=WS$ ,测试样本可直接与模板样本进行距离求解。当测试样本长度大于模板样本,即  $n>WS$  时,虽然可以通过将测试样本适当切割,得到一个与模板样本长度相同的短时样本,然后与模板样本求相似度,但是这种切割方法过于武断,为了使算法具有较高的鲁棒性,基于遍历思想,首先,用长度为  $WS$  的滑动窗口将测试样本分割,滑动步长为 1,则可以提取出  $n-WS+1$  个短时样本。然后将  $n-WS+1$  个短时样本与模板样本逐一进行下文中的相似度量,从  $n-WS+1$  个距离值中取最小值作为两者的距离。同理,整体梯度向量的 2 范数距离也可相应求得。当测试样本长度小于模板样本长度,即  $n<WS$ 。用长度为  $n$  的滑动窗口将模板样本分割成  $WS-n+1$  个待比较模板。用待比较模板与测试样本距离值和总体梯度向量的差异。取其中距离最小值作为测试样本与模板样本的距离。取整体梯度向量的 2 范数距离最小值作为其梯度差。

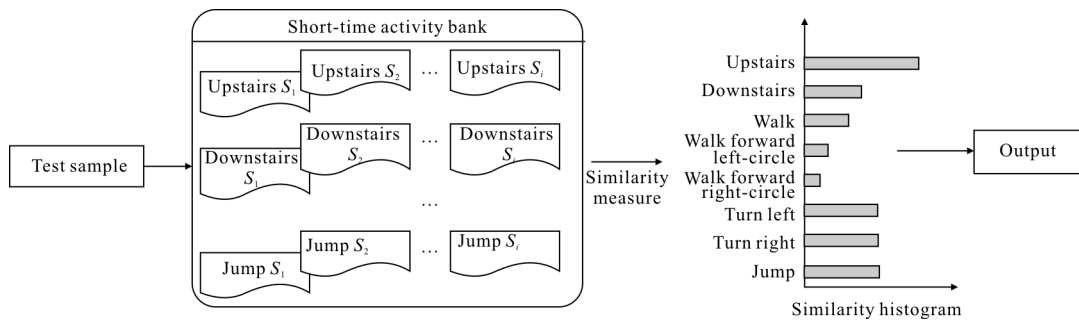


图 5 短时行为识别过程

Fig.5 Recognition process of short-time activity

### 3 实验与分析

#### 3.1 数据集介绍

WARD1.0 数据集<sup>[15]</sup>是由美国加州大学伯克利分校提供的公开数据集。包括 20 位采集者(年龄从 18~70 岁,13 位男性和 7 位女性)的 13 种日常动作。共 1 300 个数据样本。WARD1.0 包含全身五个关节点(左手手腕、右手手腕、腰部、左脚踝、右脚踝)数据。

自采集数据集<sup>[16]</sup>收集了 8 位测试者(年龄从 17~58 岁,4 位男性,4 位女性)的 八种日常行为的动作捕捉数据,每人每种动作分别做五次,共得到 320 个样本。两个数据集的具体介绍见表 1。

表 1 数据集的行为描述

Tab.1 Behavior description of data sets

Activity category	Details	Our database	WARD1.0
Go upstairs	Going up more than 10 steps	✓	✓
Go downstairs	Going down more than 10 steps	✓	✓
Walk forward	Walking forward more than 10 steps	✓	✓
Walk left-circle	Walking left-circle more than 10 s	✓	✓
Walk right-circle	Walking clockwise more than 10 s	✓	✓
Turn left	Turning left more than 10 s	✓	✓
Turn right	Turning right more than 10 s	✓	✓
Jog	Jogging more than 10 s	✓	✓
Jump	Jumping more than 10 s	-	✓
Push wheelchair	Pushing chair more than 10 s	-	✓
Stand	Standing more than 10 s	-	✓
Sit	Sitting more than 10 s	-	✓
Lie down	Lying down more than 10 s	-	✓

表 2 显示了两者在采样设备上的一些区别,在 WARD1.0 数据集中每个传感器由一个三轴加速度计和一个双轴陀螺仪构成,即在每个时间点生成一

个五维的数据向量,而自采集数据集由一个三轴加速度计和一个三轴陀螺仪构成,在每个时间点生成一个六维的数据向量。并且,自采集数据集使用的设备频率高于 WARD1.0 数据集使用的设备。通过之后实验结果和进一步分析,WARD1.0 缺少的这一维数据对上楼和带偏转的运动有着重要的区分度。

表 2 两个数据集采样设备的参数对比

Tab.2 Difference of main parameters between the two systems

	Structure of sensor	Number of sensors	Sampling frequency/Hz
WARD1.0	Triaxial accelerometer (±2 g) and biaxial gyroscope (±500(°)/s)	5	30
Our database	Triaxial accelerometer (±2 g) and triaxial gyroscope (±2 000(°)/s)	17	96

试验中,只采用单个传感器数据用以行为的分类识别,旨在实际应用中缩减成本并降低算法复杂度,同时,单传感数据获取简单,便于实现。而腰部作为人体的质心,基本能反映人体的运动规律。因此,仅采用自采集数据集和 WARD1.0 数据集中腰部传感器的数据进行短时行为识别。

#### 3.2 实验结果

文中算法均在同一实验环境下进行。实验条件为 Windows 7 系统,软件为 MATLAB R2016a。每次实验随机选取 80% 样本作为训练样本,20% 作为测试样本,且测试样本大小不一,随机生成大小长度 0.2~0.5 s 的样本进行 10 次实验。得到平均识别率。在自采集数据集和 WARD1.0 数据集中分别取得 97.25% 和 88.73% 的识别率结果,混淆矩阵如图 6、7 所示。

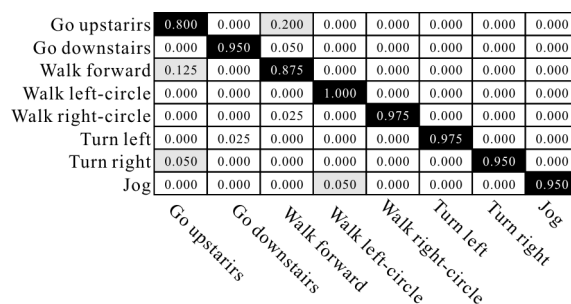


图 6 自采集数据集的混淆矩阵

Fig.6 Confusion matrix of our database

Go downstairs	0.936	0.050	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
Jog	0.230	0.770	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
Jump	0.000	0.000	1.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
Push wheelchair	0.020	0.005	0.000	0.393	0.030	0.000	0.000	0.020	0.005	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.025	0.000
Rest at standing	0.040	0.005	0.000	0.020	0.780	0.000	0.145	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.010	0.000
Rest at sitting	0.000	0.005	0.000	0.005	0.000	0.005	0.000	0.080	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.005	0.000
Rest at lying	0.000	0.000	0.000	0.000	0.035	0.000	0.985	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
Walk forward	0.000	0.000	0.000	0.000	0.000	0.000	0.975	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.000
Walk left-circle	0.025	0.000	0.000	0.045	0.000	0.000	0.000	0.840	0.025	0.000	0.015	0.015	0.050	0.000	0.000	0.000	0.000	0.000	0.000
Walk right-circle	0.010	0.015	0.000	0.010	0.005	0.000	0.000	0.035	0.035	0.393	0.000	0.010	0.020	0.000	0.000	0.000	0.000	0.000	0.000
Turn left	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.015	0.015	0.915	0.015	0.020	0.000	0.000	0.000	0.000	0.000	0.000	0.000
Turn right	0.000	0.000	0.000	0.000	0.000	0.000	0.000	0.020	0.020	0.010	0.010	0.950	0.020	0.000	0.000	0.000	0.000	0.000	0.000
Go upstairs	0.040	0.005	0.000	0.050	0.000	0.000	0.000	0.085	0.085	0.005	0.005	0.010	0.605	0.000	0.000	0.000	0.000	0.000	0.000

图 7 WARD1.0 数据集混淆矩阵

Fig.7 Confusion matrix of WARD1.0

通过对短时行为的分析，发现用短时行为数据代替传统的时域和频率特征来描述行为更加有效率。在分类方法的比较中，同样条件下采用 HMM、KNN 等算法和文中对比。实验结果如图 8 所示。在窗口大小不足一个周期的情况，文中算法比传统算法在精度和稳定性上具有更好的性能。

当用短时行为数据代替传统特征，文中算法设计思路和 KNN 接近，但是在匹配算法中，加入短时行为数据的角度特征，使得该算法比 KNN 效果更佳，稳定性更高。

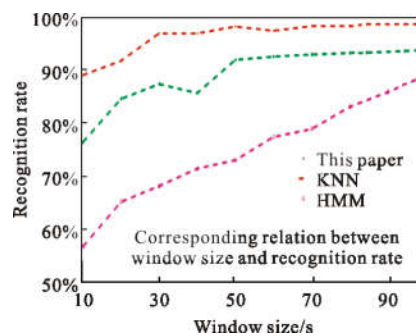


图 8 不同算法在不同窗口下的识别效果

Fig.8 Accuracy of different algorithms with different windows sizes

表 3 中，仅使用腰部传感器在两个数据集上进行算法对比发现，笔者的算法结果与传统算法接近，但算法仅需要 0.3 s 的运动数据。并且可以观察到，仅使用腰部传感器，识别两种数据集的数据，自采集数据集表现优于 WARD1.0 数据集。分析可知，腰部垂直方向的角速度对于区分带有左右偏转的运动，识别能力较强，在自采集数据集中，由于一半的动作是带偏转的动作(逆时针行走、顺时针行走、向左转弯、向右转弯)，所以得到的识别结果较高。

WARD1.0 中有三种静态行为，站立、坐和躺，考

表 3 与传统算法实验结果对比

Tab.3 Comparison of experimental results with traditional algorithms

	Number of sensors	Window size/s	Features	Methods	WARD1.0	Our database
Traditional algorithm	1	>1.5	Time domain feature and frequency-domain characterization	KNN, SVM, DT, HMM	83%–93%	88%–98%
Proposed algorithm	1	0.3	Data of short-time activity	Template matching	86%–92%	92%–97%

考虑到该算法针对动态行为，且推轮椅的动作与其他行为的区别更多表现在手部传感器上，所以在实验对比中，增加一组实验，将 WARD1.0 中静止行为和

推轮椅去掉，剩下九种行为进行实验。结果如表 4 所示。可以发现，在自采集数据集中即使将传感器的数量由五个降到一个，且窗口长度减少到 0.3 s，识

表 4 文中算法与其它算法结果对比

Tab.4 Comparison between the results of this algorithm and other algorithms

	Database	Number of sensors	Activity category	Frame/f	Window size/s	Accuracy
He et al. 2012[17]	WARD1.0	5	13	256/30	8.5	96.1%
	Our database	5	8	512/96	5.3	96.9%
Xiao et al. 2013[18]	WARD1.0	5	13	40/30	1.3	89.0%
	Our database	5	8	150/96	1.6	92.0%

续表 4  
Continued Tab.4

	Database	Number of sensors	Activity category	Frame/f	Window size/s	Accuracy
Li and Pan 2016[19]	WARD1.0	5	13	300/30	10	96.0%
	Our database	5	8	600/96	6.7	96.9%
Sheng et al. 2016[20]	WARD1.0	5	13	15/30	0.5	95.9%
	Our database	5	8	45/96	0.5	96.3%
Proposed method		1	13	10/30	0.3	88.7%
	WARD1.0	1	9	10/30	0.3	92.4%
	Our database	1	8	30/96	0.3	97.3%

别结果依然很好。在 WARD 数据集中,区分 13 种动作量由五个降到一个,且窗口长度减少到 0.3 s,识别结果依然很好。在 WARD 数据集中,区分 13 种动作的效理想,区分九种动态行为结果提升,而且考虑到传感器的数量由五个降到一个,依然能够说明,笔者的算法不仅大大简化穿戴设备,对短时行为的识别效果良好。

#### 4 结 论

使用便捷低廉的可穿戴设备进行行为识别是今后的研究热点之一。针对短时行为识别在传统识别算法中由于特征不稳定带来的识别效果不佳,从而提出一种通过构建短时行为库的模板匹配算法。它解决了传统统计特征在短时行为识别算法具有不稳定性的局限性。此外,与几种传统的经典算法进行了比较,结果表明文中算法在识别短时活动方面更具有优势。同时,该算法对于测试样本长短没有限制,对于大于 0.15 s 以上样本,都有较高识别率,最后,通过加入相似度直方图增强了算法的鲁棒性。当然,文中对于复杂动作的短时行为的处理还需要进一步研究。

#### 参考文献:

[1] Poppe R. A survey on vision-based human action recognition [J]. *Image & Vision Computing*, 2010, 28 (6): 976-990.  
 [2] Wang J, Liu Z, Wu Y, et al. Learning actionlet ensemble for 3D human action recognition [J]. *IEEE*

*Transactions on Pattern Analysis & Machine Intelligence*, 2014, 36 (5): 914-927.  
 [3] Bulling A, Blanke U, Schiele B. A tutorial on human activity recognition using body-worn inertial sensors [J]. *Acm Computing Surveys*, 2014, 46(3): 1-33.  
 [4] Lara O D, Labrador M A. A survey on human activity recognition using wearable sensors [J]. *IEEE Communications Surveys & Tutorials*, 2013, 15 (3): 1192-1209.  
 [5] Yang J, Wang S, Chen N, et al. Wearable accelerometer based extendable activity recognition system [C]//IEEE International Conference on Robotics and Automation. Piscataway, 2010: 3641-3647.  
 [6] Davis K, Owusu E, Bastani V, et al. Activity recognition based on inertial sensors for ambient assisted living [C]//International Conference on Information Fusion, 2016: 371-378.  
 [7] Su B, Tang Q F, Jiang J, et al. A novel method for short-time human activity recognition based on improved template matching technique [C]//ACM SIGGRAPH Conference on Virtual-Reality Continuum and Its Applications in Industry, 2016: 233-242.  
 [8] Li L J, Su H, Lim Y, et al. Object bank: An object-level image representation for high-level visual recognition [J]. *International Journal of Computer Vision*, 2014, 107(1): 20-39.  
 [9] Sadanand S, Corso J J. Action bank: A high-level representation of activity in video [C]//Computer Vision and Pattern Recognition (CVPR), 2012: 1234-1241.  
 [10] Liu Z J, Lin W, Geng Y L, et al. Intent pattern recognition of lower-limb motion based on mechanical sensors [J]. *Journal of Automatica Sinica*, 2017, 4(4):



- 651–660.
- [11] Young A J, Simon A M, Hargrove L J. A training method for locomotion mode prediction using powered lower limb prostheses [J]. *IEEE Transactions on Neural Systems & Rehabilitation Engineering*, 2014, 22 (3): 671–677.
- [12] Young A J, Simon A M, Fey N P, et al. Intent recognition in a powered lower limb prosthesis using time history information [J]. *Annals of Biomedical Engineering*, 2014, 42(3): 631–641.
- [13] Yuan K B, Wang Q N, Wang L. Fuzzy–logic–based terrain identification with multisensor fusion for transtibial amputees [J]. *IEEE/ASME Transactions on Mechatronics*, 2015, 20(2): 618–630
- [14] Zheng E H, Wang Q N. Noncontact capacitive sensing–based locomotion transition recognition for amputees with robotic transtibial prostheses [J]. *IEEE Transactions on Neural Systems & Rehabilitation Engineering*, 2016, 25(2): 161–170.
- [15] Yang A Y, Jafari R, Sastry S S, et al. Distributed recognition of human actions using wearable motion sensor networks [J]. *Journal of Ambient Intelligence & Smart Environments*, 2009, 1(2): 103–115.
- [16] Su B, Tang Q, Wang G, et al. Transactions on Edutainment XII: The Recognition of Human Daily Actions With Wearable Motion Sensor System [M]. Germany: Springer, 2016:68–77.
- [17] He W, Guo Y, Gao C, et al. Recognition of human activities with wearable sensors[J]. *Eurasip Journal on Advances in Signal Processing*, 2012, 2012(1): 1–13.
- [18] Xiao L, Li R F, Luo J. Recognition on human activity based on compressed sensing in body sensor networks [J]. *Journal of Electronics & Information Technology*, 2013, 35(1): 119–125.
- [19] Li F, Pan J K. Human motion recognition based on triaxial accelerometer [J]. *Journal of Computer Research and Development*, 2016, 53(3): 621–631.
- [20] Sheng M, Jiang J, Su B, et al. Short–time activity recognition with wearable sensors using convolutional neural network [C]//Proceedings of the 15th ACM SIGGRAPH Conference on Virtual–Reality Continuum and Its Applications in Industry, 2016: 413–416.