

一种基于特征增强和决策融合的人体行为识别方法

宦若虹 陈 月

(浙江工业大学计算机科学与技术学院 杭州 310023)

摘 要 利用三轴加速度传感器进行人体行为识别一直是传感器数据处理、模式识别领域的研究热点。加速度数据往往存在着多种动作数据难以区分的情况,特别是走、上楼、下楼这 3 个动作数据非常相似,这给正确识别这 3 种人体动作带来了较大的难度。提出一种基于特征增强与决策融合的行为识别方法,通过对部分特征值进行增强处理和对多个分类结果进行决策融合来识别走、上楼、下楼这些难以区分的相似动作。实验验证,所提方法可克服由于加速度数据的相似性而导致的动作识别正确率低、识别误差大的情况,有效提高人体行为识别率,且可在实际应用中实时识别人体行为动作。

关键词 三轴加速度传感器,行为识别,特征增强,决策融合

中图分类号 TP391 文献标识码 A

Method of Human Activity Recognition Based on Feature Enhancement and Decision Fusion

HUAN Ruo-hong CHEN Yue

(College of Computer Science and Technology, Zhejiang University of Technology, Hangzhou 310023, China)

Abstract Activity recognition via tri-axial accelerometer has been a research focus in the fields of sensor data processing and pattern recognition. In some cases, it is difficult to distinguish the similar acceleration data, especially the data of walking, ascending stairs and descending stairs, which makes it difficult to recognize those three activities correctly. In this paper, a method of activity recognition based on feature enhancement and decision fusion was proposed for recognizing similar activities such as walking, ascending stairs and descending stairs, which is implemented by enhancing a part of features and decision fusing several classification results. Experimental results show that the method can overcome the situations of low correct recognition rate and high recognition error due to the similarity of acceleration data, and effectively improve the correct recognition rate of human activity and distinguish human activities in actual applications in real time.

Keywords Tri-axial accelerometer, Activity recognition, Feature enhancement, Decision fusion

1 引言

使用传感器对人体的行为动作进行识别一直是传感器数据处理、模式识别领域的研究热点。在以往的研究中,研究者通过在人体的不同部位安装传感器来检测人的动作^[1,2],这种方法虽然有着良好的效果,但从长期使用方面考虑,其过于繁琐。相比之下,使用单个加速度传感器来完成行为识别^[3-6],虽然在识别精度上有所欠佳,但大大提高了使用的方便性。在手机普及的今天,通过手机内置的传感器来检测人的日常动作,无疑是更好的选择。目前,研究者已提出了多种利用手机传感器数据进行人体行为识别的方法。Duarte F 等人^[7]将手机固定在人体腰部,通过读取分析加速度传感器数据,可以识别人体多种动作且识别率高达 95% 以上。Henpraserttae A 等人^[8]通过设定不同的识别模型以对应手机处于不同的姿态,实现了无论手机处于何种位置姿态都可通过加

速度数据识别出人体动作。

行为识别可分为数据采集与预处理、特征值提取、行为分类等几个步骤,其中关键步骤是特征值提取和行为分类。提取的特征值主要包括时域特征值和频域特征值,可用的特征值非常多,但可能会出现特征值冗余的现象,所以在行为识别前必须对特征集进行选择。行为分类可用的分类算法包括支持向量机(Support Vector Machine, SVM)^[9]、决策树、K 近邻算法、神经网络^[2,10]等。学者们对人体行为识别中的特征值提取和行为分类已展开了深入的研究。

Khan A M 等人^[5]提出了一个分层体系,低层使用统计信号特征和人工神经网络识别出动作属于静态、过渡态还是动态,高层结合加速度信号的自回归模型系数和手机倾斜角建立一个增广特征矩阵,特征矩阵经过线性判别分析(Linear Discriminant Analysis, LDA)和人工神经网络识别出人体行为动作。文献^[6]通过特征选择算法和分类算法的配合使用,

本文受国家自然科学基金项目(61302129)资助。

宦若虹(1979—),女,博士,副教授,CCF 会员,主要研究方向为视频图像处理;陈 月(1991—),男,硕士,主要研究方向为模式识别, E-mail: 837969469@qq.com。

可以找到最佳的特征集,摒弃冗余的特征值,最大化地利用特征值进行动作识别。文献[11]采用多层分类方法,首先将多种动作区分成两类,再对同类动作进行细分,直至得到最终分类结果。这种多层分类可以有效避免所有动作一起分类时动作之间的相互干扰问题。文献[12]选用几个基础的分类算法和几个元级分类算法,通过基础分类算法和元级分类算法的不同组合来选择出最佳组合算法。上述方法中的特征选择、多层分类、算法组合使用在行为识别方面都取得了不错的效果。但是,上述方法都是在动作数据是可区分的情况下进行的,现实情况中三轴加速度传感器数据可能存在着不可区分的情况,如走、上楼、下楼这3个动作非常相似,即使在高精度采集频率下数据之间的差异也非常小,特别是一旦数据集变大,这3个动作之间存在的相互干扰数据就更多,并且由于手机并不是固定在人体上,所以采集的数据难免有因为抖动产生的误差,在极端情况下,这3种动作的数据可能存在着不可区分的情况,这给正确识别人体动作带来了较大的难度。本文基于手机三轴加速度传感器数据识别出日常生活中常见的5种人体动作:走、跑、上楼、下楼、站立。为了克服由于三轴加速度数据的相似性而导致的动作识别正确率低、识别误差大的情况,提出一种基于特征增强和决策融合的行为识别方法,对部分特征值进行增强处理和对多个分类结果进行决策融合,从而有效区分走、上楼、下楼这些难以区分的相似动作,提高人体行为识别率。

2 基于特征增强与决策融合的行为识别方法

本文提出的基于特征增强与决策融合的行为识别方法包括数据采集与预处理、特征提取、特征选择、特征增强、分类器训练、参数设计与权重训练、二层分类7个步骤,如图1所示。




图1 行为识别流程图

2.1 数据采集与预处理

本文实验采用自主采集的传感器数据做训练和测试,数据采集时传感器应尽量靠近人体重心^[5],所以采集过程中实验人员手持手机紧靠胸口。共采集了10个人的走、跑、上楼、下楼、站立5个动作数据,每个动作采集时间为10min,因而共有500min的数据,采样频率为100Hz。

采集到的三轴加速度数据有两方面需要注意:1)由于三轴加速度传感器采集的数据是包括重力的,为了减小重力对加速度数据的影响,需要减去传感器数据上的重力分量,手机中有专门的重力传感器读取三个轴上的重力分量。2)由于手机所在的坐标系相对于手机是固定的,而相对于全球坐标系却会随手机方位的变化而变化,为了让行为识别系统能够识别手机处于各种方位时的行为动作,需要实时地将手机坐标系(Local Coordinate System, LCS)转换为全球坐标系(Global Coordinate System, GCS),从手机坐标系到全球坐标系的转换可以通过一个实时旋转矩阵 R_t 完成^[13],其定义如下:

$$R_t = \begin{bmatrix} c\omega s\varphi - s\omega s\theta s\varphi & -s\omega c\theta & c\omega s\varphi + s\omega s\theta c\varphi \\ -s\omega c\varphi - c\omega s\theta s\varphi & -c\omega c\theta & -s\omega s\varphi + c\omega s\theta c\varphi \\ -c\theta s\varphi & s\theta & c\theta c\varphi \end{bmatrix} \quad (1)$$

其中, c, s 分别表示 \cos 与 \sin , θ, φ, ω 分别表示 t 时刻手机绕 x, y, z 轴旋转的角度,分别称为手机的俯仰角、翻滚角和偏航角。然后,可以通过式(2)实时将加速度数据从 LCS 转换到 GCS:

$$a_t^{GCS} = R_t a_t^{LCS} \quad (2)$$

其中, a_t^{GCS} 和 a_t^{LCS} 分别是 GCS 和 LCS 上的加速度数据。

由于采集的数据是一段连续的数据流,为了方便后面的特征提取和识别模型训练,预处理需要进行数据分割。常用的数据分割方法包括:1)有数据重叠的分割;2)没有数据重叠的分割。文献[14]指出使用有数据重叠的分割方法有利于去除因行为转换对识别结果带来的影响。除了是否有数据重叠,另一个非常重要的分割要素是数据分割窗口的大小,窗口太大包含的动作太多,而窗口太小数据可能不能包含一个完整的动作^[14]。综合考虑数据重叠和分割窗口大小,本文采用6s窗口50%数据重叠的数据分割方法。

2.2 特征提取

行为识别是通过比较每个窗口的加速度数据来完成的,但是即使是相同的动作,窗口中的数据也不可能完全一致,而且加速度数据具有很强的波动性,用原始数据进行行为识别是几乎不可能的,所以必须计算每个窗口中加速度数据的特征值,通过比较特征值来区分各个动作。特征值主要在时域和频域提取,本文从6s50%数据重叠的加速度数据窗口中提取特征值,包括时域特征值:均值、均方根、标准差、均值的模、标准差的模、信号幅度区域、偏度和相关系数(见式(3a)一式(3g));频域特征值:能量和熵(见式(3i)和式(3j))。

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (3a)$$

$$RMS(X) = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \quad (3b)$$

$$\sigma_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} \quad (3c)$$

$$avg_mod = \sqrt{\bar{x}^2 + \bar{y}^2 + \bar{z}^2} \quad (3d)$$

$$\sigma_mod = \sqrt{\sigma_x^2 + \sigma_y^2 + \sigma_z^2} \quad (3e)$$

$$SMA = \sum_{i=1}^n (|x_i| + |y_i| + |z_i|) \quad (3f)$$

$$Skew(X) = \frac{\sum_{i=1}^n (x_i - \bar{x})^3}{(n-1)(n-2)\sigma_x^3} \quad (3g)$$

$$\rho_{xy} = \frac{Cov(X, Y)}{\sigma_x \sigma_y} \quad (3h)$$

$$Energy(X) = \frac{\sum_{i=1}^n F_i^2}{n} \quad (3i)$$

$$Entropy(X) = \frac{-\sum_{i=1}^n F_i \log F_i}{n} \quad (3j)$$

其中, x_i, y_i, z_i 是 x, y, z 轴加速度数据, $Cov(X, Y)$ 是 x 轴和 y 轴加速度数据的协方差, F_i 是 x 轴加速度数据的傅里叶变换。

2.3 特征选择

一些特征值可能包含冗余或者无关的信息,这些信息会

影响识别的准确性,因此需要进行特征选择,这样不但可以有效提高识别准确性,并且可以降低计算复杂度和简化训练模型。本文采用了序列前向特征选择(Sequential Forward Selection, SFS)算法作为最佳特征集的选择算法, SFS的主要思想是:特征子集 X 从空集开始,每次从总特征集中选择一个特征值加入特征子集 X ,使识别率达到最高,若新加入的特征值不能提高识别率,就不将其加入特征子集。当搜索完整个特征集后,算法结束,所得的特征子集作为最优特征集。本文最终选择出了 11 个特征值作为最佳特征集,如表 1 所列。

表 1 最佳特征集

特征值	
最佳特征集	x 轴的平均值, y 轴的平均值, z 轴的标准差, x, y, z 三轴平均值的模, y 轴的偏度, z 轴的偏度, x 轴的均方根, y 轴的均方根, x, y 轴间的相关系数, x, z 轴间的相关系数, y, z 轴间的相关系数

2.4 特征增强

选定最优特征集后,由于其中每个特征值对动作识别的贡献大小不同,某些特征值可能对走、上楼、下楼这 3 个较难区分的动作的识别作用较大,所以本文选择对区分走、上楼、下楼 3 个动作贡献较大的特征值进行特征增强处理。

首先使用 Relief-F 算法计算出每个特征值的权重,过程如下:从训练样本集中随机取出一个样本 R ,然后从与 R 同类的样本集中取出 R 的 k 个近邻样本,再从与 R 不同类的样本集中取出 k 个近邻样本,最后通过权重更新式(4)更新每个特征值的权重,迭代上述过程 m 次,可以得到每个特征值的权重,权重越大的特征值表示该特征值对这个多类别分类问题的贡献越大。

$$W(A) = W(A) - \frac{\sum_{j=1}^k \text{diff}(A, R, H_j)}{m * k} + \frac{\sum_{j=1}^k \text{diff}(A, R, M_j)}{m * k} \quad (4)$$

$$\text{diff}(A, R_1, R_2) = \begin{cases} \frac{|R_1[A] - R_2[A]|}{\max(A) - \min(A)}, & A \text{ 连续} \\ 0, & A \text{ 离散且 } R_1[A] = R_2[A] \\ 1, & A \text{ 离散且 } R_1[A] \neq R_2[A] \end{cases} \quad (5)$$

其中, $R_1[A], R_2[A]$ 表示样本集 R_1, R_2 中的特征值 A , $\max(A), \min(A)$ 表示特征值 A 的最大值和最小值, H_j 表示从同类样本集中找出的第 j 个最近邻样本, $M_j(C)$ 表示从不同类样本集 C 中找出的第 j 个最近邻样本, m 表示样本抽样次数, k 表示最近邻样本个数。

得到每个特征值的权重后,设定阈值,选择权重高于该阈值的特征值进行特征增强。本文设定阈值 $k=0.05$,最终选定 4 个特征值进行特征增强,分别是: z 轴的标准差, x 轴与 y 轴间的相关系数, x 轴与 z 轴间的相关系数, y 轴与 z 轴间的相关系数,特征增强过程如下式所示:

$$p_i = \begin{cases} p_i, & k < 0.05 \\ m * p_i, & k \geq 0.05 \end{cases}, i=1, 2, 3, \dots, 11 \quad (6)$$

其中, p_i 为特征值, m 为特征增强系数, k 为阈值。

特征增强系数 m 的取值由实验获得。本文取 $1 \leq m \leq 5$ 进行实验,各个特征增强系数下的识别率如图 2 所示,可见,随着 m 的增大,识别率先迅速增大,然后随着 m 的增大而逐渐呈下降趋势,当 $m > 5$ 时,特征增强后得到的识别率提高效果不明显。最终本文选定特征增强系数 $m=1.6$ 。




图 2 不同特征增强系数下的识别率

2.5 分类器训练

本文使用的分类器是支持向量机,一共需要训练 4 个分类器,包括一个基础分类器和 3 个根据 AdaBoost 算法思想得到的弱分类器。

考虑到走、上楼、下楼这 3 个动作的相似性,仅仅使用一个分类器很容易识别错误,融合多个分类器的识别结果可以提高识别正确率,因此本文训练一个基础分类器完成对走、跑、上楼、下楼、站立 5 个动作的识别,并专门针对走、上楼、下楼 3 个动作训练 3 个弱分类器,每个弱分类器的作用是保证对某一个动作识别率较高,而不保证其它动作的识别率。AdaBoost 算法本身是通过改变数据分布来得到一个弱分类器。以针对“走”这个动作训练的弱分类器为例,在弱分类器训练过程中需要不断地从原始训练数据中找出对识别“走”动作有利的样本,删除对识别“走”动作有干扰的样本,最终得到一个专门为“走”这个动作而规划的训练样本。

2.6 参数设计与权重训练

本文的人体行为动作转换图如图 3 所示,这里将走、上楼、下楼这 3 个动作之外的动作合并为其它动作。从图 3 中可以看出人的行为动作都会以一定概率转换到另一个动作或者维持不变,且转换只与上个行为动作有关而与之前的行为动作无关,因此可以将人体行为动作的转换过程看作一个马尔可夫过程,根据行为动作之间存在的转换关系用上个动作的识别结果来帮助识别当前动作。所以,本文设定一个人体行为动作转换的概率矩阵 P :

$$P = \begin{bmatrix} 0.9 & 0.03 & 0.03 & 0.04 \\ 0.03 & 0.9 & 0.03 & 0.04 \\ 0.03 & 0.03 & 0.9 & 0.04 \\ 0.03 & 0.03 & 0.03 & 0.91 \end{bmatrix} \quad (7)$$

其中,每行依次表示的状态是:走、上楼、下楼、其它,每列依次表示的状态是:走、上楼、下楼、其它, P 中的每一个元素 p_{ij} 表示状态 i 转换到状态 j 的概率。




图 3 行为动作转换图

本文将基础分类器和 3 个弱分类器对当前动作的识别结果作为 4 个参数,将上一个动作的识别结果作为第 5 个参数,因此共有 5 个参数,记作 $label_i, i=1, 2, 3, 4, 5$,通过训练来确定这 5 个参数的权重 $w_i, i=1, 2, 3, 4, 5$ 。权重的大小代表该参数对识别结果的贡献大小,权重越大说明该参数是正确识

别结果的可能性越大。权重训练方法如下：

(1) 首先设定参数 $\delta = 1/num$, num 是走、上楼、下楼 3 个动作的训练样本总数；

(2) 设定权重的初始值： $w_i = 1, i = 1, 2, 3, 4, 5$ ；

(3) 权重训练过程中只更新基础分类器识别结果 $label_1$ 的权重 w_1 和上个动作识别结果 $label_5$ 的权重 w_5 。由于本文主要识别的是走、上楼、下楼这 3 个相似动作，且这 3 个动作对应的弱分类器识别结果应当有着一样的权重，所以 3 个弱分类器识别结果的权重设定为 1 且不变，即 $w_2 = 1, w_3 = 1, w_4 = 1$ 不变；

(4) 对参数权重进行迭代更新，即采用二层分类对训练样本进行识别，根据每个样本的识别结果对参数权重进行更新，更新公式如下：

$$w_i = \begin{cases} w_i + \delta * n, & label_i = activity \\ w_i - \delta * n, & label_i \neq activity \end{cases}, i = 1, 5 \quad (8)$$

其中， $activity$ 是样本的正确动作。更新过程其实是一个奖惩机制：如果样本识别结果与样本实际结果一致，那么设定参数 $n = 1$ ，识别正确或错误的参数权重相应增加或减少 δ ；如果样本识别结果与样本实际结果不一致，那么设定参数 $n = 8$ ，识别正确或错误的参数权重相应增加或减少 $\delta * 8$ 。

所有训练样本识别结束后调整 $label_5$ 的权重 w_5 为：

$$w_5 = w_5 * (1/p_{iA, iA}) \quad (9)$$

其中， $p_{iA, iA}$ 表示走、上楼、下楼 3 个动作不转换到此 3 个动作之外其它动作的概率。

该权重训练方法是通过识别结果的反馈对权重进行更新的，如果参数显示的是正确的识别结果就通过公式增加其权重，反之减少，并且通过奖惩机制使对正确识别帮助越大的参数获得越大的权重。这样经过大量样本训练后的参数权重可以很好地反映出每个参数对正确识别动作的贡献大小。

2.7 二层分类

完成以上 6 个步骤后，采用二层分类对人体行为进行识别。第一层分类用基础分类器对走、跑、上楼、下楼、站立 5 个动作进行识别，如果识别结果为跑或站立即为最终识别结果，如果识别结果为走、上楼、下楼 3 个动作之一就进行第二层分类，二层分类示意图如图 4 所示。




图 4 二层分类示意图

第二层分类使用 3 个弱分类器对动作进行识别，将基础分类器的识别结果、3 个弱分类器的识别结果和上个动作的识别结果作为 5 个参数，采用加权投票方法进行决策融合得到识别结果，融合公式如下：

$$a_{\underline{s}} = \begin{cases} \sum_{i=1}^4 w_i + w_5 \times p_{A, A}, & \text{for } label_5 = a_{\underline{n}}, label_i = a_{\underline{n}} \\ \sum_{i=1}^4 w_i + w_5 \times p_{lastA, A}, & \text{for } label_5 \neq a_{\underline{n}}, label_i = a_{\underline{n}} \end{cases} \quad (10)$$

其中， $a_{\underline{n}}$ 表示当前动作， $a_{\underline{s}}$ 表示 $a_{\underline{n}}$ 所代表动作的得分， $p_{A, A}$ 表示上一动作保持不变的概率， $p_{lastA, A}$ 表示 $label_5$ 所属的动作转换到当前动作的概率。决策融合的具体过程如下：

(1) 根据基础分类器和 3 个弱分类器的识别结果 $label_i$ ($i = 1, 2, 3, 4$)，将参数权重 $w_i = 1$ ($i = 1, 2, 3, 4$) 分别加到 $label_i$ 对应的动作得分上；

(2) 根据上一个动作的识别结果 $label_5$ ，将其权重乘以动作保持不变的概率 $p_{A, A}$ ，并将结果加到与其一致动作的得分上；同时将其权重分别乘以转换到其它动作的概率，并将结果分别加到转换到的动作得分上；

(3) 将得分最高的动作类别作为识别结果。

使用本文的决策融合方法，根据 5 个参数所表示的动作，将其权重根据公式分别加到对应的动作得分上，即使某个参数表示的识别结果是错误的，这个错误也可以被权重更大的参数弥补，或者被多个参数共同弥补，从而提高正确识别率，这就是使用多个加权分类器的作用。

3 实验结果与分析

表 2 是未使用特征增强和决策融合方法识别效果的混淆矩阵。表 3 是本文方法识别效果的混淆矩阵。从这两个表中可以看出，无论是否使用本文方法，跑和站立这两个动作都能取得较高的正确识别率；未使用特征增强和决策融合方法时，走、上楼、下楼这 3 个动作识别率略低且这 3 个动作相互之间出现较多错分，使用本文方法可改善走、上楼、下楼这 3 个动作之间的错分情况，提高正确识别率。

表 2 未使用特征增强和决策融合方法识别效果的混淆矩阵

	走	跑	上楼	下楼	站立	总数
走	787	9	146	58	0	1000
跑	2	1031	5	4	0	1042
上楼	62	2	883	33	0	980
下楼	37	3	46	878	0	964
站立	0	8	0	0	996	1004

表 3 本文方法识别效果的混淆矩阵

	走	跑	上楼	下楼	站立	总数
走	956	9	21	14	0	1000
跑	0	1038	4	0	0	1042
上楼	62	1	901	16	0	980
下楼	31	11	28	894	0	964
站立	0	8	0	0	996	1004

表 4 是未使用特征增强和决策融合方法、仅使用特征增强方法、仅使用决策融合方法和本文方法识别走、跑、上楼、下楼、站立 5 个动作的识别率比较，从表中可以看出单独使用本文方法中的特征增强和决策融合方法都能有效地提高走、上楼、下楼这 3 个相似动作的正确识别率，联合使用特征增强和决策融合方法得到的识别率提高效果最佳，5 个动作的平均识别率可接近 96%。其原因是：

(1) 在选择的最佳特征集中，每个特征值对动作识别的贡献大小不一，存在对识别走、上楼、下楼这 3 个相似动作识别作用更大的特征值，使用 Relief-F 算法可以找出这些特征值，通过对这些特征值进行特征增强处理可有效提高识别相似动作的正确率。

(2) 在加权投票决策融合中使用 3 个弱分类器，这 3 个弱分类器是针对走、上楼、下楼 3 个动作训练的，每个弱分类器的作用是保证对对应动作的识别率较高。在行为识别过程

中,可以认为这 3 个弱分类器中至少有一个弱分类器会正确识别出当前行为动作,其它两个弱分类器也有一定概率识别正确,这样就进一步提高了识别的正确性。

(3)将人体行为转换过程看成是一个马尔可夫过程,引入转换概率矩阵,将上个动作识别结果的参数权重分别乘以转换到其它动作的概率,将结果分别加到转换到的动作得分上,这样做不但可以在基础分类器识别错误的情况下纠正识别结果,而且在动作发生转换的情况下也能帮助提高识别正确率。

表 4 方法 1(未使用特征增强和决策融合方法)、方法 2(仅使用特征增强方法)、方法 3(仅使用决策融合方法)和方法 4(本文方法)的识别率对比(%)

方法	走	跑	上楼	下楼	站立	平均
方法 1	78.70	98.94	90.10	91.08	99.20	91.68
方法 2	80.50	99.14	91.63	93.57	99.20	92.87
方法 3	94.20	99.62	91.63	93.05	99.20	95.61
方法 4	95.60	99.62	91.94	92.74	99.20	95.89

图 5 是未使用特征增强和决策融合方法、仅使用特征增强方法、仅使用决策融合方法和本文方法的耗时比较图,表 5 是各个方法的平均耗时比较。从图 5 和表 5 可以看出,特征增强步骤基本不会增加额外的时间开销,本文方法的主要耗时集中在决策融合,这是因为在决策融合过程中有 3 个弱分类器需要额外对样本进行识别,增加了时间开销。从表 5 中可以看出,本文方法平均识别一个样本需要 6.34ms,虽然较其他方法耗时较多,但本文采用的是 6s 窗口 50%数据重叠的数据分割方法,在实际应用中,每 3s 才进行一次行为识别,6.34ms 的识别耗时完全可以在实际应用中实时地识别出行动为动作的种类,因而,本文方法具有实时性和实用性。




图 5 方法耗时比较图

表 5 方法平均耗时对比(ms)

	未使用特征增强和决策融合	仅使用特征增强方法	仅使用决策融合方法	本文方法
耗时	2.47	2.68	6.17	6.34

表 6 是本文方法与文献[11,12]方法的平均识别率对比,文献[11]中采用多层分类,识别跑、走、上楼、下楼、摔倒 5 个动作,文献[12]采用组合不同基础分类算法和元级分类算法来寻找最佳组合算法,识别走、坐、站立、上楼、下楼 5 个动作,从表 6 可见,本文方法较文献[11,12]中的方法有着更好的识别效果。

表 6 本文方法与其他方法的平均识别率对比(%)

	本文方法	文献[11]方法	文献[12]方法
平均识别率	95.89	83.09	94.29

结束语 本文基于三轴加速度传感器的行为识别方法采用 Relief-F 算法找出对识别走、上楼、下楼这些相似动作作用更大的特征值并进行特征增强处理;训练 4 个分类器,包括 1 个基础分类器和 3 个根据 AdaBoost 算法思想的弱分类器,并

用上个动作的分类结果来帮助识别当前动作,将 5 个分类结果加权投票决策融合进行行为识别,得到行为类别。该方法可有效识别相似动作,如走、上楼、下楼,明显提高人体行为的正确识别率,并可在实际应用中实时使用。下一步,我们将扩大数据集,采集包含更多人体行为动作的更多样本数据进行实验,并将进一步研究行为识别中的关键算法,获得更优的特征提取、特征选择算法和分类算法,进一步提高人体行为识别率。

参考文献

- [1] 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
- [2] Mi Z, Sawchuk A A. Human Daily Activity Recognition With Sparse Representation Using Wearable Sensors[J]. IEEE Journal of Biomedical & Health Informatics, 2013, 17(3): 553-560
- [3] Karantonis D M, Narayanan M R, Mathie M, et al. Implementation of a real-time human movement classifier using a triaxial accelerometer for ambulatory monitoring[J]. IEEE Transactions on Information Technology in Biomedicine, 2006, 10(1): 156-167
- [4] 刘鹏, 卢潭城, 吕愿愿, 等. 基于 MEMS 三轴加速度传感器的摔倒检测[J]. 传感技术学报, 2014(4): 570-574
- [5] Khan A M, Lee Y K, Lee S Y, et al. A triaxial accelerometer-based physical-activity recognition via augmented-signal features and a hierarchical recognizer[J]. IEEE Transactions on Information Technology in Biomedicine, 2010, 14(5): 1166-1172
- [6] Gupta P, Dallas T. Feature selection and activity recognition system using a single triaxial accelerometer[J]. IEEE Transactions on Bio-medical Engineering, 2014, 61(6): 1780-1786
- [7] Duarte F, Lourenco A, Abrantes A. Activity classification using a smartphone[C]// 2013 IEEE 15th International Conference on e-Health Networking, Applications & Services (Healthcom). IEEE, 2013: 549-553
- [8] Henpraserttae A, Thiemjarus S, Marukatat S. Accurate Activity Recognition Using a Mobile Phone Regardless of Device Orientation and Location[C]// International Conference on Body Sensor Networks. IEEE Computer Society, 2011: 41-46
- [9] Ravi N, Dandekar N, Mysore P, et al. Activity recognition from accelerometer data[C]// AAAI. 2005, 3: 1541-1546
- [10] Giansanti D, Macellari V, Maccioni G. New neural network classifier of fall-risk based on the Mahalanobis distance and kinematic parameters assessed by a wearable device[J]. Physiological measurement, 2008, 29(3): N11-N19(9)
- [11] Mandal I, Happy S L, Behera D P, et al. A framework for human activity recognition based on accelerometer data[C]// 2014 5th International Conference Confluence The Next Generation Information Technology Summit (Confluence). IEEE, 2014: 600-603
- [12] Lau S L, König I, David K, et al. Supporting patient monitoring using activity recognition with a smartphone[C]// 2010 7th International Symposium on Wireless Communication Systems (ISWCS). IEEE, 2010: 810-814
- [13] Kang W, Han Y. SmartPDR: smartphone-based pedestrian dead reckoning for indoor localization[J]. IEEE Sensors Journal, 2015, 15(5): 2906-2916
- [14] Su X, Tong H, Ji P. Activity recognition with smartphone sensors[J]. Tsinghua Science and Technology, 2014, 19(3): 235-249