

基于加速度时域特征和 Adaboost-SVM 级联分类器的跌倒检测研究

田一明¹,王喜太^{1,2,*},杨鹏¹,耿艳利¹

(1 河北工业大学 控制科学与工程学院,天津 300130;2 国家康复辅具研究中心,北京市老年功能障碍
康复辅助技术重点实验室,民政部康复辅具技术与系统重点实验室,北京 100176)

摘要 为了提高对跌倒检测的准确性和可靠性,提出了一种基于三轴加速度时域特征和 Adaboost-SVM 级联分类器的跌倒检测方法.首先,利用滑动窗口法提取加速度信号的时域特征作为唯一特征向量,以提高系统检测的实时性;然后,对传统 Adaboost 算法的样本初始权值部分进行改进,使分类器学习到更多跌倒样本的信息,从而增强系统对跌倒的识别能力;最后,针对日常活动动作类(ADL)的数目远多于跌倒类而导致的数据集不平衡问题,构建了用于跌倒检测的 Adaboost-SVM 级联分类器.根据级联结构中每个 Adaboost 分类器所包含的弱分类器数量自动决定是否由 SVM 替换 Adaboost 分类器.利用 UCI 数据库中人体运动数据集进行了实验.结果表明:文中所提方法具有最高的跌倒检测率以及较为优秀的误报警率和准确率,并且证明了放置于胸部和腰部的加速度计能够对跌倒检测产生较好效果.

关键词 跌倒检测;模式识别;集成学习;Adaboost 级联算法;时域特征

中图分类号 TP181 文献标识码 A 文章编号 1672-4321(2018)01-0093-07

FallDetection Based on Time Domain Features of Acceleration and Cascade-Adaboost-SVM Classifier

Tian Yiming¹,Wang Xitai^{1,2},Yang Peng¹,Geng Yanli¹

(1 School of Control Science and Engineering, Hebei University of Technology, Tianjin 300130, China; 2 Key Laboratory of Rehabilitation Aids Technology and System of the Ministry of Civil Affairs, Beijing Key Laboratory of Rehabilitation Technical Aids for Old-Age Disability, National Research Center for Rehabilitation Technical Aids, Beijing 100176, China)

Abstract In order to improve the accuracy and reliability in fall detection, this paper proposes a fall detection method based on time domain features extracted from triaxial accelerometer and cascade-AdaBoost-support vector machine (SVM) classifier. Firstly, sliding window method is used to extract the time domain features of acceleration signals as the only one feature vector. Secondly, on the basis of the improvement of the initial weight of the samples of the traditional Adaboost algorithm, a cascade-AdaBoost-SVM classifier is built to detect fall accidents for the dataset imbalance problem that the number of activities of daily life is far more than the fall, the algorithm can automatically determine whether to replace the AdaBoost classifier by support vector machine according to the number of weak classifier used in each Adaboost classifier to prevent overfitting of classifier. Lastly, the UCI database is used for the experiment. The results show that the proposed method have the highest detection rate as well as relatively perfect false alarm rate and accuracy rate. Furthermore, this paper proves that the triaxial accelerometers which are put on the chest and waist can produce optimal detection results.

Keywords fall detection; pattern recognition; ensemble learning; cascade Adaboost algorithm; time domain features

收稿日期 2017-08-23 * 通讯作者 王喜太,研究员,研究方向:专业化养老、康复机器人,E-mail:wxit56@sina.com

作者简介 田一明(1988-)男,博士,研究方向:模式识别,专业化养老,E-mail:yimingtian@163.com

基金项目 国家科技支撑计划项目(2015BAI06B03);国家自然科学基金资助项目(61174009);河北省青年基金资助项目(F2016202327)

在我国 65 岁以上的老年人在总人口中所占的比例由 2000 年的 6.96% 增加到了 2010 年的 8.87% , 60 岁以上人口的比例也比 2000 年上升了 2.93%^[1] , 这表明我国已经进入了老龄化社会 , 并且人口老龄化程度不断加深。跌倒是老年人中具有频发性和严重危害性的事故。调查研究发现 , 在 65 岁以上的老年人中 , 有大约 1/3 的人有过一次跌倒史 , 而其中近一半的人有过两次跌倒史^[2]。跌倒会对老年人会造成巨大的身体伤害 , 这包括擦伤、骨折、严重的甚至会导致死亡。因此 , 研究准确高效的跌倒检测方法能够使老年人及时得到救护 , 从而减轻跌倒给老年人带来的身心痛苦。

利用惯性传感器对跌倒进行检测具有成本低且不受外界环境影响和限制的优势。Paola P 等^[3]通过将跌倒过程前两个阶段的加速度均方根值与所设定的阈值进行比较来实现跌倒的预检测 , 并最终以身体的变化率与所设定阈值相比较来判定是否发生了跌倒 , 但是这种基于阈值比较的跌倒检测方法容易受到噪声、佩戴位置以及个体差异的影响。陈国兴等^[4]对假肢穿戴者的跌倒问题 , 利用相关性分析的模糊自适应方法进行了研究 , 使检测系统能够适应不同患者的跌倒状态。文献[5]通过采集人体腰部位置加速度数据 , 在运用滑动窗口法进行时域特征提取后 , 采用基于阈值的方法对包括跌倒在内的人体四种活动状态进行了识别 , 但是 , 此方法只对上半身由竖直变为水平的跌倒检测较为有效。文献[6]提出了一种使用加速度传感器和 Kinect 的跌倒检测方法 , 加速度数据用来对跌倒的趋势进行监测 , 当出现有跌倒的趋势时 , 系统发出跌倒预报警 , 而深度图用来对加速度数据的跌倒预报警做最终的验证和确认 , 但是 , 当受试者离开 Kinect 的检测范围时 , 此方法失效。文献[7]通过提取人体运动过程中加速度信号的时间序列特征来描述人体运动的状态 , 并利用隐马尔科夫模型对跌倒的风险进行评估 , 但是隐马尔科夫模型对于高维的输入向量 , 其计算复杂度会成级数增长 , 不利于跌倒检测的实时性。文献[8]比较了 ANN 分类器和 SVM 分类器在使用加速度传感器对跌倒进行检测时的性能差异。文献[9]利用所设计的多分类器框架 , 通过投票法融合各分类器的决策信息实现跌倒检测 , 但是此方法对设备要求较高 , 不利于推广和普及 , 并且 , 多分类器系统降低了检测的实时性。

跌倒检测可以归为故障检测的范畴^[4] , 然而跌倒检测问题又区别于一般的故障检测问题 , 其特殊

性主要表现在以下几个方面: (1) 跌倒检测问题对系统的实时性有较高要求 , 因此 , 既要考虑到所选特征对不同动作的区分能力 , 还要考虑到其计算的复杂程度。(2) 跌倒检测问题对系统的检测率有较高要求 , 然而 , 高检测率又容易引起系统出现高错误报警率的弊端。(3) 跌倒检测问题涉及到解决不平衡数据集的分类问题 , 传统的分类器对此类问题往往表现不佳 , 这要求所设计的分类器能够使跌倒样本在分类过程中受到更多的关注 , 从而提高对跌倒的检测率。针对以往的跌倒检测研究忽视这三个方面的问题 , 本文提出了一种基于加速度时域特征和 Adaboost-SVM 级联分类器的跌倒检测方法 , 首先 , 利用滑动窗口法提取加速度的时域特征 , 以满足系统实时性的要求; 其次 , 对 Adaboost 算法的初始权值部分进行了改进 , 使分类器更关注于对跌倒样本的检测 , 以满足跌倒检测问题需要系统具备较高检测率的要求; 再次 , 针对传统 Adaboost 级联算法在解决数据不平衡分类问题时 , 随着样本的相似性增加 , 容易造成后面级联层分类器的学习难度增加 , 出现过拟合的问题 , 对传统 Adaboost 级联算法进行改进 , 根据 Adaboost 分类器在每层使用的弱分类器个数是否超过一定的阈值来决定 SVM 是否替换掉 Adaboost 来进行跌倒检测。通过 UCI 数据库中人体运动数据集进行对比实验表明 , 本文所提出的方法在能够有效提高跌倒检测精度的基础上 , 还能够获得较高的检出率和最低的误报警率。

1 特征提取

由于加速度的频域和时频特征提取过于复杂不利于进行实时的跌倒检测 , 因此本文只对加速度信号进行时域特征提取。针对上述要求 , 采用滑动窗口作为特征提取方法获取人体的实时活动信息 , 这种方法不需要传感器信号的预处理 , 应用比较简单 , 因此适合实时的跌倒检测。目前常用的加速度时域特征有: 标准差、相关系数、和角加速度等。由于跌倒发生时 , 加速度的变化比较剧烈 , 因此 , 加速度向量幅值 SVM 可以用来确定是否出现跌倒。但是 , 当存在巨大信号噪声扰动时 , 单独考虑三轴加速度的向量幅值 SVM 是不够的 , 因此 , 有必要加入关于加速度向量区域值 SMA 作为特征来对跌倒进行检测 , 它可以避免出现较大的信号噪声而检测效果造成影响。综上 , 本文考虑 x 、 y 、 z 轴加速度值、加速度向量幅值 SMV 以及加速度向量区域值 SMA 作为特征 , 相关

的公式如下:

$$SMV[n] = \sqrt{x[n]^2 + y[n]^2 + z[n]^2}, \quad (1)$$

(1) 式中: $x[n]$ $y[n]$ $z[n]$ 分别是 x y z 三个轴在采样时间为 n 的加速度值.

SMA $[n] =$

$$\frac{1}{n} \left(\sum_{i=n}^{n-N+1} |x[i]| + \sum_{i=n}^{n-N+1} |y[i]| + \sum_{i=n}^{n-N+1} |z[i]| \right), \quad (2)$$

(2) 式中: $x[i]$ $y[i]$ $z[i]$ 分别是 x y z 三个轴在采样时间为 n 的加速度值, N 为采样点的个数.

与其他只在单一在采样时间内对信号进行特征提取的方法不同,本文把多个连续采样时间点的加速度特征(滑动窗)作为输入分类器中的特征向量 $f = [x_{n-N+1}, \dots, x_n]^T$ 其中 $x_n = [x[n], y[n], z[n], SMV[n], SMA[n]]$.

2 相关算法

2.1 Adaboost 算法的改进

Adaboost 算法^[10-12]是一种迭代算法,它能够多个弱分类器组合形成性能更为优良的强分类器.其核心思想就是针对同一个训练集训练不同的分类器,即弱分类器,然后把把这些弱分类器集合起来,构造一个更强的最终分类器.算法首先设置训练样本的权重,原始 Adaboost 算法各个样本被赋予相同的权重值,随着迭代过程的进行,算法不断对样本权重进行调整:即增大检测错误样本的权重,降低被检测正确样本的权重,从而实现了较难检测样本的着重学习.针对跌倒检测问题需要系统具备极高的检测率,本文在传统 Adaboost 算法的基础上,通过改变训练集初始权重的方式使分类器更关注于对跌倒样本的检测,以获得系统对跌倒的高检测率.假设训练集包含 p 个正样本(跌倒)和 q 个负样本(非跌倒),并且令每个正样本的权值 w_p 等于所有负样本的权值 w_n ,以表示没有正样本被分类错误,关系表示如下:

$$\begin{cases} W_p = qw_n \\ pw_p + qw_n = 1 \end{cases}, \quad (3)$$

通过式(3)可以得到正样本的权值 $w_p = 1/(p+1)$ 以及负样本的权值 $w_n = 1/q(p+1)$,利用这个结果取代 Adaboost 算法中正负样本的初始权重设定.

改进算法的流程如下:

(1) 给定训练样本 $(f_1, y_1), \dots, (f_m, y_m)$ 其中 $f_i \in R^N$ 为特征向量, $y_i = \pm 1$ 表示正负样本.

(2) 初始化样本权值:对于正样本其权值为 $w_p = 1/(p+1)$,对于负样本其权值为 $w_n = 1/q(p+1)$,其中 p 和 q 分别为正负样本的数目.

(3) For $t = 1, \dots, T$

● 寻找分类器 $h_t: f \rightarrow \{1, -1\}$ $h_t = \operatorname{argmin} \varepsilon_j$

其中 $\sum_{i=1}^m w_i(t) [y_i \neq h_t(f_i)]$ $j = 1, \dots, n$

● 设置分类器权重: $\beta_t = 0.5 \ln [(1 - \varepsilon_t) / \varepsilon_t]$

● 更新样本权重:

$w_i(t+1) = w_i(t) \exp[-\beta_t y_i h_t(f_i)] / Z_t$, 其中 Z_t 是归一化因子.

(4) 输出最终强分类器: $H(f) = \operatorname{sign}(\sum_{t=1}^T \beta_t h_t(f))$.

2.2 Adaboost 级联算法

经过少数次迭代生成的 Adaboost 分类器由于准确率较低,有时不能满足检测要求,而组合更多的弱分类器对提高检测率有一定的帮助,但这会带来计算复杂度和时间上的增加,影响到 Adaboost 分类器整体的性能.针对这一问题,有学者提出了 Adaboost 级联算法^[13-15]来提升系统的检测率,其结构如图 1 所示.当一个输入向量被第一个 Adaboost 分类器确定为负样本,那么它将从样本集中移除而不再进入下一个分类器,如果一个输入向量被确定为正样本,那么它将会到下一个 Adaboost 分类器进行判断,直到系统最后一层.这种级联 Adaboost 分类器非常适用于正负样本不平衡的跌倒检测问题,但是一个突出问题就是随着样本的相似性增加,容易造成后面级联层分类器的学习难度增加,导致分类器性能下降.




图 1 分类器的级联结构图

Fig.1 Classifier's cascade architecture diagram

2.3 支持向量机

支持向量机(SVM)首先由 Vapnik 提出来并成功应用到许多分类问题上.通过找到一个最优分类面 $f(x)$,当 y 的值落入 $f(x) < 0$ 的时候被分类为“-1”,当 y 的值落入 $f(x) > 0$ 的时候被分类为“+1”.因此,根据 $f(x)$ 来对类别进行分类,最优分类面 $f(x)$ 可以表示为:

$$f(x) = w^T x + b, \quad (4)$$

(4) 式中: w 是这个超平面的常规向量, x 是输入向

量,如果 w 是一个单位向量,这个距离就是 $-b$,因此 w 和 b 是我们寻找的参数,根据最大边缘和最小平方误差,因此目标函数能够被定义为:

$$E(w, b) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^m \alpha_i (y_i - f(x_i))^2, \quad (5)$$

(5) 式中: $\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_m\}$ 是拉格朗日常数且有 $\alpha_i > 0, i = 1, 2, \dots, m$. 最大化(5)式可以得到:

$$w = \sum_{i=1}^m \alpha_i y_i x_i \text{ and } \sum_{i=1}^m \alpha_i y_i = 0, \quad (6)$$

将上述方程带入(5)式,原目标函数转换为双目标函数,目标函数可以被重新定义为:

$$Q(\alpha) = \sum_{i=1}^m \alpha_i - \frac{1}{2} \sum_{i=1}^m \sum_{j=1}^m \alpha_i \alpha_j y_i y_j K(x_i, x_j), \quad (7)$$

它满足: $\sum_{i=1}^m \alpha_i y_i = 0; 0 \leq \alpha_i \leq C, \forall i = 1, 2, \dots, m$.

(8)

(8) 式中: $\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_m\}$ 是拉格朗日常数, $K(x_i, x_j)$ 是核函数, m 是训练集的数目, C 是一个可以调整的参数. 将 $\alpha = \{\alpha_1, \alpha_2, \dots, \alpha_m\}$ 代入方程(6)获得 w 向量,通过将 w 向量代入(4)式 b 就可以得到. 在本文中,我们使用高斯函数作为 SVM 的核函数.

3 Adaboost-SVM 级联分类器

在构造 Adaboost 级联分类器的过程中,随着负样本的移除致使训练集剩余样本变得越来越少且相似性增加,这使后面层的分类器需要融合更多的弱分类器才能满足性能要求,这容易造成分类器的过拟合. 针对此问题,本文对传统 Adaboost 级联分类器加以改进,构建 Adaboost-SVM 级联分类器. 主要思想是:设置每层 Adaboost 分类器中包含弱分类器的最大数量,当每层的 Adaboost 分类器在预先设定最大数目的弱分类器下不能达到预定的性能要求时,用 SVM 来替代 Adaboost 分类器进行检测. 这时对 SVM 的训练只需要建立在 Adaboost 分类器已选择特征的基础之上,因此,可减少其训练时间.

在建立 Adaboost-SVM 级联分类器的过程中,首先,设置每层分类器的检测率 d 以及误报警率 f ,每层包含最大的弱分类器数量 n 以及分类器整体误报警率 F_{target} . Adaboost-SVM 级联分类器的构建算法主要包括内外两个循环,内部循环通过前文所提及的 Adaboost 算法来训练分类器,在算法迭代的过程中,每个弱分类器被添加进来后,当前的 Adaboost 分类

器将会被重新评估以检查其是否满足性能要求,如果满足,则这一层的 Adaboost 训练完成;否则继续加入弱分类器直到数量达到阈值 n 后如果仍没有满足性能要求,则用 SVM 分类器替换这一层的 Adaboost,并且利用 Adaboost 分类器已选择的特征向量训练 SVM 分类器,直到外层循环达到总体误报警率要求,算法结束. 下面是所建立 Adaboost-SVM 级联算法的具体流程.

(1) 设置每层分类器的最小可接受检测率 d 以及最大可接受误报警率 f .

(2) 设置级联分类器整体误报警率 F_{target} , 以及每层最大的弱分类器个数 n .

(3) P 和 N 分别代表正负样本集,设置 $F_0 = 1, i = 0$.

(4) While ($F_i > F_{\text{target}}$)

● $i = i + 1, \mu_i = 0, F_i = F_{i-1}$.

● while ($F_i > f \times F_{i-1}$) and ($n_i < n$)

(a) $n_i = n_i + 1$

(b) 通过 Adaboost 算法训练分类器

(c) 计算当前级联分类器的 F_i

● if ($n_i \geq n$)

(a) 利用 SVM 算法训练分类器

(b) 计算当前级联分类器的 F_i

● if ($F_i > F_{\text{target}}$) $N = \text{NULL}$, 则选择一部分检测错误的样本放入集合 N .

4 实验及结果

4.1 实验样本

本文的跌倒检测实验数据来自 UCI 数据库中的人体活动数据集. 数据集中的数据采集实验分别对 5 名受试者在胸部、腰部、左右脚踝处放置加速度传感器,这四个位置的加速度传感器记录每名受试者在跌倒以及五种日常行为动作时的加速度情况,数据集分别包含每位受试者 3~5 min 的加速度记录 5 个,在每个数据记录里包含一些基本日常动作以及三次跌倒,前两次是在行走的过程中发生跌倒,第三次是从坐姿滑倒在地上.

图 2 展示了放在第一位受试者腰部位置的加速度仪信号的时域图,包括在时间段内 x, y, z 三个方向的加速度,跌倒状态 d ,以及 SMV 和 SMA 特征. d 代表跌倒发生时的人工标记位置,当 $d = 1$ 时代表跌倒发生.

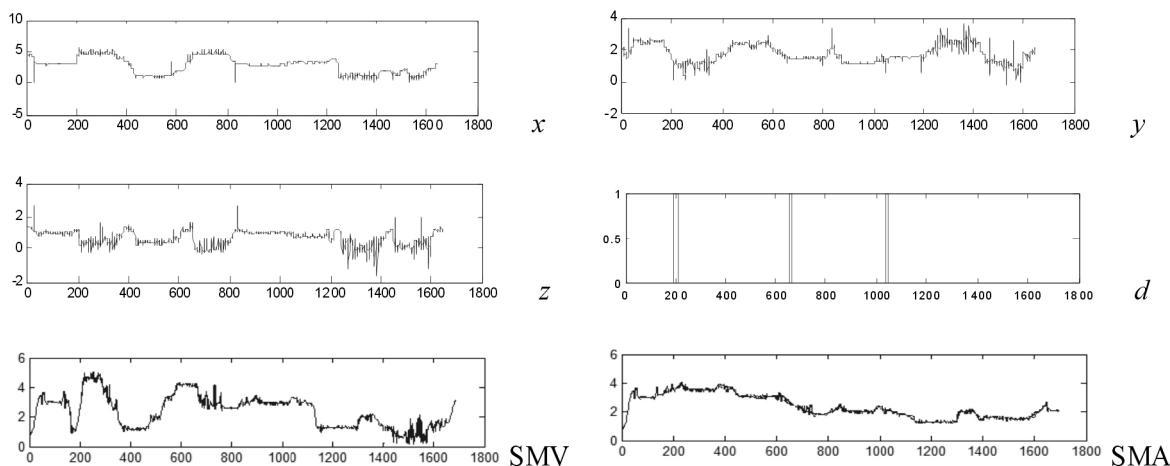


图 2 腰部位置基本生活活动的信号时域图

Fig.2 Signal timing diagram example of daily activity captured from the waist

由图 2 可见,当跌倒发生时 x, y, z 轴的加速度值变化明显,然而,当出现大量噪声或者存在比较剧烈的运动时,同样会导致其波动较大.跌倒时的 SMV 同样发生较为明显的变化.SMA 在三次跌倒中变化程度不明显,其作为特征的主要意义在于体现加速度值变化时间持续较长,变化幅度相对较小的跌倒特征.除此之外,从图中还可以分析出传统使用加速度 x, y, z 轴阈值的跌倒检测方法在某些时刻会出现误报警,并不能做到有效区分剧烈运动与跌倒.其次,传统跌倒检测方法通过当前时刻的三轴加速度值或者某些相关参数来进行检测,但是通过图中可见,跌倒是一个时间过程,本文通过滑动窗口法不仅考虑当前加速度值、SMV、SAM 特征,还将这些特征以前的情况作为考虑对象,使用滑动窗集成所有采样时间覆盖窗口的三轴加速度值和特征到一个输入向量中,这有利于在检测中将跌倒视为一个动态连续的过程来考虑,而非仅仅视为一个时刻的状态.

4.2 实验结果及分析

由于数据集包含跌倒样本的总数是 75 个,将其中的 60 个用作训练样本,其余的用作测试样本.从每个受试者的日常生活活动产生的非跌倒样本中随机选择 100 个作为非跌倒样本,构成总共 2500 个非跌倒样本,将其中的 2000 个作为训练样本,其余的作为测试样本.实验采用随机抽样 5 倍交叉验证的方法进行,为了对测试结果进行评估,本文定义了 3 个参数,分别是准确率 AR,检测率 DR,以及误报警率 FAR:

$$\begin{cases} AR = \frac{TP+TN}{p+q} \times 100\% , \\ DR = \frac{TP}{p} \times 100\% , \\ FAR = \frac{FP}{q} \times 100\% , \end{cases} \quad (9)$$

式中: p 和 q 分别代表训练样本中正样本数量(跌倒)以及负样本数量(非跌倒).TP 代表跌倒样本中被检测为跌倒数量,TN 代表非跌倒样本中被检测成非跌倒的数量,FP 代表非跌倒样本中被检测成跌倒的数量.

在实验中,分别使用 BP-NN,SVM,Adaboost 级联分类器以及 Adaboost-SVM 级联分类器对输入向量进行分类以完成跌倒检测,实验的结果展示了当加速度仪被放置于左右脚踝,胸部以及腰部时不同分类器对跌倒的检测性能,具体结果如表 1 所示.从表 1 可见,相比于其它分类器,Adaboost-SVM 级联分类器在左脚踝,胸部以及腰部的实验中获得了最高的准确率分别为:94.23%、98.18%、98.16%,以及最高的检测率分别为 53%、87.62%、78.63%和最低的误警率 3.57%、1.64%、0.78%.当加速度计放置于右脚踝时,SVM 分类器获得最高的准确率为 93.71%,Adaboost-SVM 级联分类器的准确率为 92.62%接近于 SVM 分类器性能.但是,Adaboost-SVM 级联分类器的检测率为 53%,相对于 SVM 分类器的 23.34%更具有优势.通过上述数据可见:首先,出于对跌倒检测问题要求每一个跌倒必须被检测出来的原则,级联 Adaboost-SVM 分类器拥有更好

的性能,因为在不同部位的加速度信号源下,它具有 4 种分类器中最高的 DR 指标;其次,尽管在位于右脚踝部位的加速度信号源下,级联 Adaboost-SVM 分类器并未取得最高的准确率以及最低的误报警率,但是其与在这两方面表现最好的 SVM 分类器性能并未相差很大,并且,级联 Adaboost-SVM 分类器有更为突出的检测率;最后,从实验中得知,放置于受试者胸部和腰部的加速度传感器所获得的跌倒检测准确率等指标均比放置于脚踝部位的传感器所获得的检测指标要好,这表明将胸部和腰部作为跌倒检测的信号源更为可靠.

由于参数 n 是级联算法的基础,它决定 Adaboost 是否被 SVM 分类器所取代,对于放置于脚踝的检测实验来说,设置最大允许的弱分类器数量 $n = 110$. 相对于脚踝部位,胸部以及腰部的实验每层应用的弱分类器数目要少于脚踝部位,因此,我们设置最大允许的弱分类器数量 $n = 8$. 设置 Adaboost-SVM 级联分类器每层的检测率 d 和误报警率 f 分别为 0.99 和 0.3,层数量 C 被限制在 7,表 2 展示了 Adaboost-SVM 级联分类器在选取不同位置的加速度信号源作跌倒检测实验时的层数量以及每层中的弱分类器数量.

表 1 实验结果比较表

Tab.1 Comparison table of experimental results

位置		分类器 / %			
		BP-NN	SVM	级联 Adaboost	级联 Adaboost-SVM
左脚踝	AR	92.31	92.86	90.92	94.23
	DR	36	34	53	53
	FAR	4.61	4.15	6.94	3.57
右脚踝	AR	91.63	93.71	86.7	92.62
	DR	20	23.34	53	53
	FAR	4.56	2.81	7.84	5.37
胸部	AR	95.7	96.23	97.2	98.18
	DR	75.47	78.32	84.73	87.62
	FAR	3.54	3.17	2.45	1.64
腰部	AR	96.23	94.58	97.42	98.16
	DR	66.72	71.86	78.63	78.63
	FAR	1.93	2.87	1.74	0.78

表 2 级联 Adaboost-SVM 分类器的层数以及每层弱分类器数量

Tab.2 Layer number of cascade-Adaboost-SVM classifier and the number of classifiers at each layer

位置	弱分类器数量 ($C=7$)				
	L1	L2	L3	L4	L5
左脚踝 ($n=110$ $\sigma=3.1$)	42	68	102	SVM	
右脚踝 ($n=110$ $\sigma=2.8$)	38	74	SVM		
胸部 ($n=8$ $\sigma=1.7$)	1	1	6	8	SVM
腰部 ($n=8$ $\sigma=1.3$)	1	5	8	SVM	

从表 2 可见,左脚踝的实验包括四级级联结构达到最终的跌倒检测性能要求,第四层级联结构由于弱分类器数量大于设定的阈值 110,所以 SVM 分类器取代 Adaboost. 右脚踝的实验应用到了三级级联结构 38-74-SVM,每一层所包含的弱分类器数量与左脚踝实验大体相当,可见这与左脚踝作为信号源所体现的检测性能比较接近.当加速度计放置于胸部以及腰部时,Adaboost-SVM 级联分类器则需要

四到五层完成预定要求,并且,每层最小 1 个最大 8 个的弱分类器数量就能够满足当初设定的检测率和误报警率要求.结果表明,本文所提出的级联 Adaboost-SVM 分类器能够根据训练样本以及设定的性能要求实现对其结构的自组织,相比于传统的 Adaboost 级联分类器,它能够避免由于级联后期出现的样本相似性增大而导致的分类器过拟合和检测率较低的问题.

5 结语

本文应用 UCI 数据库中的人体活动数据集作为跌倒实验数据,提出一种基于三轴加速度信号时域特征和 Adaboost-SVM 级联分类器的跌倒检测方法。本文以滑动窗作为特征提取方法,能够提取在多个采样时间点下的三轴加速度信号特征,有利于提升跌倒检测的检测率。在分类器设计方面,本文首先通过改进 Adaboost 算法在训练集上的初始权值设定,以使其更能够更关注跌倒样本的学习;其次,本文对传统 Adaboost 级联分类器加以改进,通过设定每层中所包含弱分类器的最大数量,来考虑是否由 SVM 替换 Adaboost 分类器。通过利用 UCI 数据库的实验数据测试得到的结果表明,本文提出的 Adaboost-SVM 级联分类器能够根据设定的性能要求实现对其结构的自组织,相比实验中的其他方法具有最高的跌倒检测率以及较为优秀的误报警率和准确率。除此之外,实验结果还证明了将胸部和腰部作为跌倒检测的加速度信号源具有比较好的检测效果。

参 考 文 献

- [1] 林闽钢,梁 誉,刘璐婵. 中国老年人口养老状况的区域比较研究——基于第六次全国人口普查数据的分析[J]. 武汉科技大学学报(社会科学版),2014,16(2): 204-208.
- [2] Fletcher P C, Hirdes J P. Risk factors for falling among community-based seniors using home care services[J]. J Gerontol. Ser. A: Biol Sci. Med. Sci, 2002, 57(8): M504-M510.
- [3] Paola P, Alberto B, Lorenzo P, et al. A high reliability wearable device for elderly fall detection [J]. IEEE Sensors Journal, 2015, 15(8): 4544-4553.
- [4] 陈国兴,耿艳利,刘作军,等. 假肢跌倒预警中基于相关性分析的模糊自适应反馈调节[J]. 机器人, 2015, 37(6): 732-737.
- [5] 李文锋,姚丙盟. 基于单三轴加速度传感器的人体活动状态识别[J]. 华中科技大学学报(自然科学版), 2016, 44(4): 58-62.
- [6] Kwolek B, Kepski M. Improving fall detection by the use of depth sensor and accelerometer [J]. Neurocomputing, 2015, 30: 637-645.
- [7] Tong L, Song Q J, Ge Y J, et al. HMM-based human fall detection and prediction method using tri-axial accelerometer [J]. IEEE Sensors Journal, 2013, 13(5): 1849-1856.
- [8] Nukala B T, Shibuya N, Rodriguez, A, et al. An efficient and robust fall detection system using wireless gait analysis sensor with artificial neural network (ANN) and support vector machine (SVM) algorithms [J]. Open Journal of Applied Biosensor, 2014, 3: 29-39.
- [9] Gibson R M, Amira A, Ramzan N, et al. Multiple comparator classifier framework for accelerometer-based fall detection and diagnostic [J]. Applied Soft Computing, 2016, 39: 94-103.
- [10] Viola P, Jones M. Rapid object detection using a boosted cascade of simple features [C]//IEEE. Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Kauai: IEEE, 2001: 511-518.
- [11] Zhao Y S, Gong L, Zhou B, et al. Detecting tomatoes in greenhouse scenes by combining AdaBoost classifier and colour analysis [J]. Biosystems Engineering, 2016, 148: 127-137.
- [12] 曹 莹,苗启广,刘家辰,等. AdaBoost 算法研究进展与展望[J]. 自动化学报, 2013, 39(6): 745-758.
- [13] Hassannejad H, Medici P, Cardarelli E, et al. Detection of moving objects in roundabouts based on a monocular system [J]. Expert Systems with Applications, 2015, 42(9): 4167-4176.
- [14] 崔 华,张 骁,郭 璐,等. 多特征多阈值级联 AdaBoost 行人检测器 [J]. 交通运输工程学报, 2015, 15(2): 109-117.
- [15] Viola P, Jones M. Robust real-time face detection [J]. International Journal of Computer Vision, 2004, 57(2): 137-154.

(责任编辑 颜昌学)