

基于时序分析的人体摔倒预测方法^{*}

佟丽娜^{1 2} 宋全军¹ 葛运建¹

¹(中国科学院合肥智能机械研究所 机器人传感器与人机交互实验室 合肥 230031)

²(中国科学技术大学 信息科学与技术学院 自动化系 合肥 230027)

摘要 提出一种基于人体动作状态序列时序分析法的人体摔倒预测方法. 融合特征部位加速度信息为时间序列, 选取摔倒过程中人体与低势物体碰撞前的过程序列段作为样本训练隐马尔可夫模型(HMM), 通过分析输入序列与 HMM 的匹配程度实时分析当前时刻人体摔倒的风险. 实验证明该方法取得良好的预测效果, 并且可有效区分摔倒过程与其它日常生活行为过程.

关键词 摔倒预测, 时间序列, 隐马尔可夫模型

中图分类号 TP 391.4

Time Series Analysis Based Human Fall Prediction Method

TONG Li-Na^{1 2} SONG Quan-Jun¹ GE Yun-Jian¹

¹(Laboratory of Robot Sensor and Human-Machine Interaction, Institute of Intelligent Machines, Chinese Academy of Sciences, Hefei 230031)

²(Department of Automation, School of Information Science and Technology, University of Science and Technology of China, Hefei 230027)

ABSTRACT

A method for human fall prediction based on time series of human action states is proposed. Firstly, the acceleration time series in characteristic body region is got by information fusion procedure. Secondly, the segments before the collision of body with lower objects in fall processes is chosen as samples to train hidden Markov model (HMM). Then, the current-time fall risk is analyzed by the real-time matching degree between input series and HMM. The experimental result shows that the proposed method gets good result in predicting falls, and the fall events and other daily life activities can be distinguished effectively by it.

Key Words Fall Prediction, Time Series, Hidden Markov Model

1 引言

据中国康复医学会调查结果显示,目前我国 60

岁以上老年人口已超过 1.44 亿,占总人口的比例达 11%. 我国老龄化进程正在加剧. 老年人属于易摔倒人群,其摔倒致病率高、住院率高、死亡率高,带来严

^{*} 国家自然科学基金项目(No. 60874097, 60875047)、国家 863 计划项目(No. 2008AA040202, 2006AA040204)和安徽省优秀青年科技基金项目(No. 10040606Y06)资助

收稿日期: 2011-01-07; 修回日期: 2011-03-01

作者简介: 佟丽娜,女,1982 年生,博士研究生,主要研究方向为机器人与人机接触交互. E-mail: linatong@mail.ustc.edu.cn. 宋全军,男,1972 年生,副研究员,主要研究方向为仿生感知、机器人及人机接触交互. 葛运建,男,1947 年生,研究员,主要研究方向为信息获取与处理、机器人感知系统、人机接触交互、运动生物力学等.

重的经济负担和社会负担,并已引起业界的高度重视.以不影响老年人正常活动为前提,通过科学手段及时预测老年人摔倒并依靠保护装置降低碰撞伤害可有效减少老年人摔倒带来的健康伤害及医疗开支,现已成为国际上新的研究热点之一^[1].可随身携带的高速充气式气囊^[4]是较常见的保护装置,可穿戴式助老助残机器人^[2]的安全保护系统也可依靠改变身体运动姿态来减小摔倒伤害.但是无论何种方式的保护装置都需要一定的准备时间,因此在摔倒冲击到来之前一定的裕量时间内准确预测人体摔倒对摔倒保护装置的应用具有重要意义.

近年来,微机电系统(Micro-Electro-Mechanical System, MEMS)器件及无线通信技术的发展使得远距离监测人体运动行为成为可能.一些自主检测人体摔倒并且无线报警的微型便携式设备装置也相继问世,其中最常见的方法是通过采集人体线加速度及角速度信息并通过实验设定其阈值来检测佩戴者是否有摔倒行为发生^[3-8].例如,美国的Li等^[3]设计一种由三轴加速度计和三轴陀螺仪组成的装置佩带于人体胸部和大腿部,并通过实验设置两部位各自的合加速度和角速度阈值,达到92%的检测率并具备较强的时效性.其误判主要来源于单时间点对应的传感信息不具备描述人体运动过程的完备性.爱尔兰的Bourke等^[4]使用两轴陀螺仪检测人体前后及左右方向的角速度并进行微积分运算得到角加速度及倾斜角度,依靠实验设定人体躯干倾斜角度和角加速度阈值来检测摔倒的发生,取得100%的检测率,但没有涉及预测研究.众所周知修正陀螺仪输出数据经微积分运算的误差需要地磁计的辅助,其计算复杂、实时性较差,不利于摔倒预测判断.此类方法在国内外许多研究机构出现过^[5],主要是检测人体是否已摔倒并呼叫救援,但是对摔倒预测问题的研究相对较少.Li团队^[9]开发一种用于摔倒时保护老年人臀部的高速充气气囊装置,利用支持向量机对实验数据进行分类,设置人体躯干部位的三轴加速度信息和角速度信息阈值来预测摔倒,具体预测准确度及裕量时间并没有公布.

人体摔倒预测方法应具备两个要素:1)准确,必须能有效识别摔倒过程与其它日常生活运动行为;2)及时,以便保护装置有充足的准备时间于碰撞到来之前及早做出预测.阈值法多利用不连续的单时间点传感信息,并不具备描述人体运动过程的信息完备性,容易带来误判.较复杂的陀螺仪信息处理则增加经济和时间成本.而时序分析法是根据某一个指标的长期资料,通过统计处理,从不规则的表

面现象中体现出某种规律性本质的方法^[10],具备描述人体运动状态改变及全运动过程特点的可行性.因此,本文提出一种使用人体运动过程中的加速度时间序列信息预测摔倒的方法,具备描述摔倒过程较为完备的传感信息,同时简化硬件设计需求、避免复杂的数学运算,提高系统的容错能力.虽然人体运动具有高度的复杂性,但是不同运动过程具备不同特点,同类运动过程中各状态之间的转移概率及检测到各状态传感信息的出现概率具有一定的规律性,并且在时序上显现出特点.

为预测老年人摔倒,本文提出一种基于人体运动动作序列时序分析的人体摔倒预测方法,利用摔倒过程运动状态来分析即将与低势物体冲击的风险.首先分析适宜区别人体摔倒运动过程与其它运动过程特点的运动学信息——三维加速度变化及相应的特征部位——上躯干部位,即获取上躯干前后、左右、上下方向的加速度信息.其次将摔倒过程中与低势物体接触前过程的加速度信息融合为表征该运动过程特点的时间序列并作为训练样本建立用于摔倒预测的隐马尔可夫模型(HMM),可实时分析人体在当前时刻即将摔倒的风险.实验证明该方法可有效区分摔倒过程与其它日常生活行为运动过程,并可在200~300ms裕量时间条件下对摔倒做出预测.

2 结合摔倒过程的特征提取

2.1 摔倒过程与加速度变化

摔倒是指人身体的任何部位(不包括双脚)意外触及地面或其它较低的区域,而当事人无法实时做出反应,并且着地部位会受到不同程度的撞击伤害.当人体从较高处跌落地面时,作用在人体与接触面的平均冲击力为^[11]

$$F_0 \approx q \frac{mv}{\Delta t} \approx ma \cdot q,$$

其中 v 为碰撞速度,在摔倒过程结束时刻通常减为0; $q \in [1, 2]$,由碰撞的弹性决定, $q=1$ 时人体没有弹跳, $q=2$ 时人体完全弹跳; Δt 为碰撞时间, F_0 越大则人体的不适感越强,其超过一定数值时将引起组织损伤.摔倒过程中人体与地面等产生的作用力通常要比其它日常生活运动的要大,因此 F_0 的大小可用来区别摔倒与一般日程动作行为. q 由接触面性质决定,不易测量.为使摔倒预测方法更具有普适性,应研究与个体特征关联较小的可测量量,故可通过研究加速度的变化来识别摔倒过程.

2.2 特征部位

运动过程中人体不同部位的加速度变化不同, 为提高摔倒识别准确率, 应选择不易与其它运动过程产生相似加速度的部位作为信息获取的基准对象。腕部、手臂等部位因为在日常生活中活动频繁、复杂、具有很强的随机性, 因而不适合作为特征部位; 腿部、踝部等同样也不合适。而上躯干部位——颈部以下、腰部以上的躯干部位, 在安全的日常生活中, 例如行走、坐下等动作变化过程较平稳, 而在摔倒过程中姿态变化、加速度变化皆较为剧烈^[7], 因此较适合作为加速度信息获取的特征部位。

2.3 数据样本

如图 1 所示定义人体上躯干坐标 $oxyz$ 随人体运动而运动, $OXYZ$ 为大地坐标系, 当上躯干直立时 $oxyz$ 与 $OXYZ$ 平行。上躯干运动中 x 轴(前后)、 y 轴(左右)、 z 轴(上下)方向的加速度分别为 a_x 、 a_y 、 a_z , 合加速度为 $a = \sqrt{a_x^2 + a_y^2 + a_z^2}$ 。




图 1 坐标轴定义

Fig. 1 Definition of axis

为采集数据样本, 我们用美国 Xsens 公司出品的 MTi 微型姿态航向测量系统 (<http://www.xsens.com/en/general/mti>) 作为加速度信息的获取装置, 经改装后通过弹性绑带固定在人体上躯干部位。设置采样频率 $T = 10\text{ms}$, 8 位青年学生作为志愿模特(体重: 45 ~ 80kg) 进行以下实验。摔倒(模拟因眩晕摔倒, 包括前向及侧向两种摔倒, 并使用厚海绵垫保护) 80 次, 站立(同时说话)、行走、蹲下-起立(非快速)、坐下-起立(非快速)各 40 次, 及行走过程中摔倒 40 次。

通过信息获取结果可看到, 各类运动过程对应的加速度曲线均有显著特点, 如从前向摔倒曲线可看到摔倒过程中剧烈的冲击高达 $6g$ (g 为重力加速度) 以上, 从行走过程曲线中可看到在某些周期性运动中加速度亦具有周期性特征; 而坐下-起立过程和蹲下-起立过程的起立过程相似。

在本文中, 所采集到的数据样本被分为 3 个彼此各不相交的集合。

1) 训练样本集 Φ_T , 由 40 次摔倒过程数据样本组成。

2) 统计样本集 Φ_S , 由 40 次摔倒过程数据样本及站立、行走、蹲下-起立、坐下-起立过程数据样本各 20 次组成。

3) 实验样本集 Φ_E , 由 40 次行走时摔倒过程的数据样本及站立、行走、蹲下-起立、坐下-起立过程数据样本各 20 次组成。

2.4 加速度时间序列的特征提取

在人体运动过程中, 由于重力作用、自身运动及与其它物体碰撞使自身加速度实时变化, 形成一个加速度时间序列。对于身体某部位, 不同运动状态组合构成不同的运动过程, 也产生不同的加速度时间序列。采集分析加速度时间序列可识别运动状态, 从而监测人体运动过程。我们通过滑动时间窗口 S 来获得上躯干运动过程中的表征运动特征的加速度时间序列。为此 S 与加速度时间序列拥有相同的采样周期 T_s 和长度 n , 覆盖时间长度为 $T_s \cdot n$, 包含 n 个按时间顺序排列的元素 c_i , $i = 1, 2, \dots, n$, 每个元素表征相应时间段 T_s 内的运动特征。若 T_s 时间段内传感器采集到的加速度数据 (a_x, a_y, a_z) 的数量为 m , $m \geq 1$, 则计算得到的合加速度 a 的数量亦为 m 。本文实验设置传感器的采样周期为 $T = 10\text{ms}$, 则 $T_s = mT$ 。特征提取的过程就是将每段 T_s 时间段内的 m 组传感数据经融合后提取出 1 个表征该时间段内运动特征的元素 c_i , 再将 n 个元素组成 1 个表征 $T_s \cdot n$ 时间段内运动特征的加速度时间序列即为特征提取的过程。可见 m 取值越大则传感信息的利用率越低, 丢失有用信息的可能性越大; m 取值越小则描述某一运动过程的加速度时间序列的元素数量越多, 算法计算更复杂。

本文为使简化算法使用合加速度来描述人体运动特征, 特征提取的过程如下。

1) 使用最大距离法确定表征任意 T_s 时间段内的运动状态特性的合加速度 a_c 。MEMS 加速度传感器的输出包括重力加速度及物体自身运动产生的加速度^[12]。因此在静止状态下, 由于重力作用、人体呼吸等生理运动、噪声干扰等, 使得人体上躯干部位于 X 轴、 Y 轴、 Z 轴方向的加速度于 $(0, 0, -g)$ 附近做小范围变化。因此静止状态下上躯干合加速度 a 在 g 附近做小范围变化。将这一范围的加速度定义为一个基准带: $B = [b_1, b_2]$ 其中 $b_1 < g$, $b_2 > g$ 。本文按照统计学方法统计数据样本中人体静止状态下上躯

干合加速度变化范围, 设置 $B = [9\text{m/s}^2, 11\text{m/s}^2]$. 在运动过程中产生的加速度偏离 B 越大表示运动状态的改变越为剧烈, 故按最大距离法确定 T_s 时间段内特征加速度 a_c . 定义 t 时刻加速度 a 与 B 的距离:

$$d(a, B) = |a - b_1| + |a - b_2|,$$

则 T_s 内合加速度值 $\{a_i\}$, $i = 1, 2, \dots, m$ 与 B 的最大距离:

$$\max [d(a_i, B) \mid i = 1, 2, \dots, m].$$

如果

$$d(a_j, B) = \max [d(a_i, B)], \forall i, j = 1, 2, \dots, m,$$

则 $a_c = a_j$.

2) 分段符号化 a_c 的值域, 得到滑动时间窗口 S 的元素 c_i , $i = 1, 2, \dots, n$. 人体摔倒过程合加速度峰值最大可超过 $12g$ (见文献 [7]). 其传感数据的值域范围十分巨大, 计算所得的合加速度值域范围较大. 为简化算法, 可对 a_c 的值域分段符号化. 定义符号有限集 $S = \{s_1, s_2, \dots, s_k\}$, $k \geq 1$. 记 a_c 的值域 θ 为

$$\theta = [\theta_0, \theta_1) \cup [\theta_1, \theta_2) \cup \dots \cup [\theta_{k-1}, \theta_k),$$

$$\theta_0 = 0, \theta_k \rightarrow +\infty.$$

当前时间窗口第 i 个元素 c_i 的符号化结果: 如果 $a_c \in [\theta_{j-1}, \theta_j)$, 则 $c_i = s_j$, 即加速度时间序列中某元素取值为 s_j 的意义为此时特征加速度 $a_c \in [\theta_{j-1}, \theta_j)$.

θ 的分段方法及数量可根据数据样本的特点决定. 由于人体日常活动中上躯干合加速度在 B 范围内较为频繁, 正常日常生活活动的合加速度一般小于 50m/s^2 (见文献 [7]). 本文以 B 为中心采用分段平均法, 取 $B = [b_1, b_2]$ 为其中 1 段, 取 $\theta_{k-1} = 50\text{m/s}^2$, 将 $[0, b_1)$ 段及 $[b_2, \theta_{k-1})$ 段分别平均分为 k_1 段及 k_2 段.

3 摔倒过程动作状态序列的识别

HMM 具有较好的统计特性, 能够针对随机过程的特点建立概率模型并实现对时序信号的识别^[13], 已成功应用在语音识别、手写识别、手势识别、步态动作识别等领域^[14-16]. 本文将 HMM 应用于人体摔倒运动动作过程的识别, 实现人体摔倒检测及预测. 首先将人体摔倒过程中的特征部位加速度数据经特征提取融合为时间序列, 分析摔倒过程中与低势物体碰撞前过程的加速度变化规律, 识别人体摔倒的碰撞前过程, 建立用于摔倒预测的 HMM 并对输出概率做归一化处理来评估即将摔倒的风险.

HMM 是一个双重随机过程, 由一个描述状态转移的不可测的一阶有限马尔可夫链和一个用于描述

状态与观测序列之间关系的一般随机过程组成, 可通过分析观测序列来间接分析隐状态的转移^[13]. 结合本文, 定义摔倒运动过程中通过信息获取及特征提取过程得到的加速度时间序列为长为 L 的观测值序列 $O = \{O_1, O_2, \dots, O_t, \dots, O_L\}$, 其中 O_t 为时间序列的第 t 个元素. 与此观测值序列对应的隐含运动状态序列为 $Q = \{Q_1, Q_2, \dots, Q_t, \dots, Q_L\}$, 其中 Q_t 对应 O_t . 描述摔倒运动过程的 HMM 可由一个五元组来表示, 即 $\lambda = (M, N, \pi, A, B)$, 其参数描述如下.

1) 人体摔倒过程的隐含运动状态数 M . 摔倒运动过程中各运动状态的有限集 $U = \{u_1, u_2, \dots, u_M\}$, 如倒前安全态、失去平衡态、与低势物体冲击态、倒后平稳态等.

2) 信息获取融合后的观测值数 N , 即运动过程中产生的加速度时间序列中所有元素种类的数量. 观测值有限集 $V = \{v_1, v_2, \dots, v_N\}$, 其中观测量取值为加速度时间序列中的元素值.

3) 初始概率分布

$$\pi = \{\pi_i\}, \pi_i = P(Q_1 = u_i), \sum_{i=1}^M \pi_i = 1,$$

$$i = 1, 2, \dots, M.$$

4) 状态转移概率

$$A = \{a_{ij}\}, a_{ij} = P(Q_{t+1} = u_j \mid Q_t = u_i),$$

$$\sum_{j=1}^M a_{ij} = 1, j = 1, 2, \dots, M.$$

5) 输出概率

$$B = \{b_{jk}\}, b_{jk} = P(O_t = v_k \mid Q_t = u_j),$$

$$\sum_{k=1}^N b_{jk} = 1, k = 1, 2, \dots, N.$$

对于给定的人体摔倒过程产生的加速度时间序列 (作为 HMM 的观测值序列) O , 通过调整 λ 的参数使 $P(O \mid \lambda)$ 局部最大可训练得到描述摔倒运动过程的 HMM. 之后对于给定 λ , 可求得其产生某个给定观测值序列 (某运动过程产生的加速度时间序列) O 的输出概率 $P(O \mid \lambda)$, 即估计 λ 和 O 的匹配情况, 从而评估该运动过程为摔倒过程的概率. 本文采用标准 Baum-Welch (B-W) 算法^[13] 对 HMM 进行参数估计并计算输出概率以提高时效性. B-W 算法的核心思想是通过递归方式更新权重, 以得到能更好解释训练样本序列的模型参数, 并且计算复杂度相对较低, 是一种广义期望最大化算法.

使用 B-W 算法计算输出概率 $P(O \mid \lambda)$ 需要定义两个变量: 1) 定义前向变量 $\alpha_t(i)$ 为给定 HMM 参数 λ , 系统在 t 时刻处于运动状态 u_i , 并且此时已输出部分观测序列 (人体运动产生的加速度时间序

列) $\{O_1, O_2, \dots, O_L\}$ 的概率:

$$\alpha_i(i) = P(O_1, O_2, \dots, O_i, Q_i = u_i | \lambda);$$

2) 定义后向变量 $\beta_i(i)$ 为给定 HMM 参数 λ , 系统在 t 时刻处于运动状态 u_i , 并且输出 t 时刻之后部分观测序列(运动过程产生的加速度时间序列) $\{O_{t+1}, O_{t+2}, \dots, O_L\}$ 的概率:

$$\beta_i(i) = P(O_{t+1}, O_{t+2}, \dots, O_L, Q_t = u_i | \lambda).$$

从定义可看出 $\alpha_i(i)$ 、 $\beta_i(i)$ 可通过递归方式计算得到. 于是得到输出概率:

$$\begin{aligned} P(O | \lambda) &= \sum_{i=1}^M \alpha_i(i) \beta_i(i) \\ &= \sum_{i=1}^M \sum_{j=1}^M \alpha_i(i) a_{ij} b_j(O_{t+1}) \beta_{t+1}(j) \\ &= \sum_{i=1}^M \alpha_L(i). \end{aligned}$$

在通过 B-W 算法训练描述摔倒过程的 HMM 时, 需要定义两个变量: 1) 定义 $\gamma_t(i, j)$ 为给定训练序列(按 2.4 节方法提取的人体摔倒过程加速度时间序列) O 和模型 λ , 则结合前向变量和后向变量的定义, 在时刻 t 处于运动状态为 u_i 且时刻 $t+1$ 处于运动状态转移为 u_j 的概率:

$$\begin{aligned} \gamma_t(i, j) &= P(Q_t = u_i, Q_{t+1} = u_j | O, \lambda) \\ &= \frac{\alpha_t(i) a_{ij} b_j(O_{t+1}) \beta_{t+1}(j)}{P(O | \lambda)}, \end{aligned}$$

2) 定义 $\delta_t(i)$ 为给定训练序列(摔倒过程加速度时间序列) O 和模型 λ , 则在时刻 t 处于运动状态为 u_i 的概率:

$$\delta_t(i) = P(Q_t = u_i | O, \lambda) = \frac{\alpha_t(i) \beta_t(i)}{P(O | \lambda)}.$$

可见, $\sum_{i=1}^{L-1} \delta_t(i)$ 表示运动状态从 u_i 转移出去的次数的期望, 而 $\sum_{i=1}^{L-1} \gamma_t(i, j)$ 表示运动状态从 u_i 转移到 u_j 次数的期望. 由此得 B-W 算法中的重估公示:

$$\begin{aligned} \bar{\pi}_i &= \delta_1(i), \\ \bar{a}_{ij} &= \frac{\sum_{t=1}^{L-1} \gamma_t(i, j)}{\sum_{t=1}^{L-1} \delta_t(i)}, \bar{b}_{jk} = \frac{\sum_{t=1}^L \delta_t(j) \rho_k = v_k}{\sum_{t=1}^L \delta_t(j)}. \end{aligned}$$

将摔倒过程加速度时间序列作为训练序列反复对 λ 的参数进行重估, 直到参数改变小于给定阈值或用尽所有的训练样本, 即可训练得到描述摔倒运动过程的 HMM.

起始于安全运动状态, 人体摔倒过程先后经历失去平衡、与低势物体冲击(某些冲击为震荡型, 有多个冲击峰值)及倒后相对平稳的运动状态. 为在

第一次冲击到来之前做出预测, 应取摔倒过程中撞击到来之前的状态对应的特征时间序列作为样本训练 HMM. 本文取隐状态数 $M=3$, 观测值数量 $N=8$. 序列从起始安全态开始, 因此训练 HMM 的初始值: $\pi_1=1, \pi_i=0, i=2, 3, \dots, M$; A, B 皆为均匀分布. 训练得摔倒预测相关的 HMM: $\lambda_p = (M, N, \pi, A, B)$. 之后通过估计输入的加速度时间序列与 λ_p 的匹配程度(模型输出的概率值)可评估序列对应的运动状态与摔倒前状态的关系来预测摔倒风险. 匹配度越高, 即将摔倒(碰撞)的风险越高. 其预测方法框图如图 2 所示.

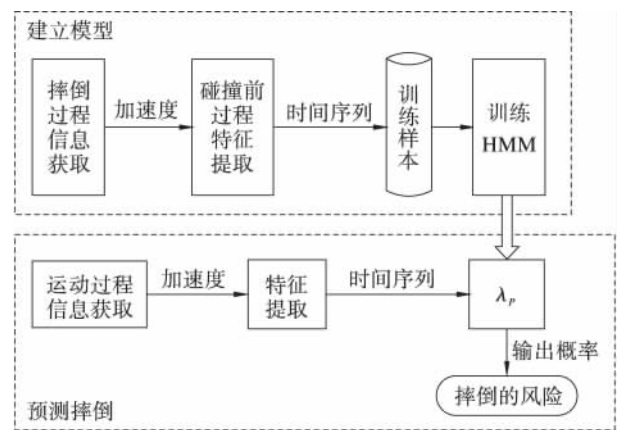


图 2 摔倒预测方法框图


Fig. 2 Diagram of prediction method

从时序分析的角度来说, 本文方法是通过分析当前时刻前一时间段内的运动过程来评估即将摔倒的概率, 得到预测摔倒发生的效果. 从 HMM 的角度来说则是通过分析加速度序列(观测值序列)来分析人体运动状态(隐状态序列)的转移. 预测方法必须有效区分摔倒过程与其它日常行为过程以减小误判. 本文将站立、行走、坐下、蹲下、起立过程实验样本经数据融合后输入 λ_p , 对比摔倒过程对应的输出值来验证 λ_p 对摔倒过程识别的有效性.


4 实验与结果分析

根据人体摔倒过程特点及本文实验获得的数据特点, 特征提取过程 $m=4$, 加速度时间序列长度 $n=12$. 训练样本集 Φ_T , 摔倒开始到碰撞前数据段融合提取为加速度时间序列作为训练样本训练 HMM 得预测模型 λ_p , 将 λ_p 的输出概率值做归一化处理, 以此来评估即将摔倒的风险. 取实验样本集 Φ_E 中各运动过程的数据样本, 经融合提取为加速度时间


序列后输入模型 λ_p 进行实验验证. 如图 3 所示, (a)、(b) 分别为将坐下-起立、蹲下-起立过程两组样本输入 λ_p 得到的预测曲线图, 两过程中均未出现摔倒, 故 λ_p 输出概率值较低, 均在 $[0, 0.1]$ 范围内. (c) 的情况有所不同, 横坐标起始于 1 000ms



(a) 坐下-起立过程
(a) Sit-to-stand process



(b) 蹲下-起立过程
(b) Squat-to-stand process



(c) 行走-摔倒过程
(c) Falling-walking process

图 3 3 种过程中摔倒风险预测结果图

Fig. 3 Prediction results for 3 kinds of motion processes

的曲线是一次行走中摔倒过程的加速度曲线, 将其融合为时间序列输入 λ_p , 其输出的是即将摔倒的概率值曲线即为星线曲线. 在站立和行走过程中, 即将摔倒的概率很低. 在时刻 $t = 4\ 640\text{ms}$ 时, 风险值开始明显升高, 加速度曲线对应碰撞状态前的失去平衡状态, 即将摔倒的概率升高. 在 $t = 4\ 880\text{ms}$ 时, 风险值降为 0, 加速度曲线对应碰撞状态的开始, 即身体已与碰撞面接触, 因而从运动生物力学特点来说, 之后的过程中再发生摔倒的概率很低. 通过实验可看出, 预测模型对站立、行走、蹲下、坐下、起立、摔倒过程中与低势物体碰撞及倒后状态的输出很低, 在失去平衡状态输出较高, 具备摔倒预测可行性, 同时也可有效区分摔倒中碰撞前过程与其它日常生活运动过程.

针对本文的预测模型 λ_p , 通过实验统计了预测阈值 P 及区分摔倒过程与其它日常生活行为过程的阈值 P' . 将统计样本集 Φ_s 中的各运动过程数据样本融合为时间序列后输入 λ_p , 采用支持向量的方法设定 $P' = 0.334\ 0\%$. 在倒前 (与碰撞面接触前) 300ms 裕量条件下预测摔倒的概率阈值为 $P = 5.670\%$. 在模型 λ_p 和阈值 P 及 P' 下, 对实验样本集 Φ_E 中各运动过程的数据样本进行实验, 得到摔倒识别率为 100%, 误判率为 0. 在满足 300ms 裕量条件下的预测成功率为 80%, 其余 20% 只能满足 200ms 的裕量. 这种差异主要来自阈值法的局限: 受到样本数量以及人为经验的影响, 在大样本条件下可得到改善.

本文模型 λ_p 描述的是一个随机过程的特点, 其输出的风险概率值经过数学上的归一化处理, 用于物理上对人体摔倒的预测. 风险概率值越大, 表示人越接近碰撞物体. 故模型 λ_p 和阈值 P 及 P' 均不代表病理学特性. 对比利用传感信息阈值来识别摔倒过程的方法, 本文模型在人体摔倒过程识别问题上具有以下特点. 首先, 阈值法多采用不连续的单时间点传感信息的处理结果作为判别的标准, 由于传感信息的不完备性而带来一定的误判; 本文方法分析摔倒过程中人体与低势物体碰撞前的加速度时间序列, 采用较完备的传感信息分析人体摔倒运动过程特点及运动状态转移情况, 可有效区分摔倒过程与其它日常生活运动过程. 其次, 目前阈值法多用于人体摔倒检测, 本文方法可预测人体摔倒风险, 实现摔倒预测.

5 结束语

人体摔倒预测技术是老年人防摔倒系统的重要

组成部分之一。在助老助残及康复医疗领域中具有广泛的应用价值。本文提出使用时序分析法分析人体运动动作过程结构序列,提取上躯干加速度信息并融合为时间序列,学习摔倒过程中与低势物体接触前过程的加速度变化规律,建立用于摔倒预测的 λ_p 并对输出概率做归一化处理来评估即将摔倒的风险。实验证明本文方法可在摔倒过程与地势物体接触前200~300ms做出预测,并且能有效区分摔倒过程与其它日常生活行为过程。受样本种类和数量的影响,本文模型在实际应用中的鲁棒性仍欠佳,尤其是仅利用上躯干加速度信息,如何更有效利用人体运动学信息来进行摔倒预测研究是作者今后的主要工作。

致 谢 感谢合肥智能机械研究所机器人传感器实验室的同学们参与实验,为本文提供数据基础。

参 考 文 献

- [1] Zhang Yu, Chen Wei. Summary and Development of Fall Study for the Elders. *Chinese Journal of Gerontology*, 2008, 28(9): 929 - 931 (in Chinese)
(张玉,陈蔚. 老年跌倒研究概况与进展. *中国老年学杂志* 2008, 28(9): 929 - 931)
- [2] Sun Zhaojun, Yu Yong, Ge Yunjian. Study on Sensing Information Forecasting of Wearable Power Assist Walking Legs Based on Time Series Analysis. *Chinese Journal of Sensors and Actuators*, 2009, 22(3): 345 - 349 (in Chinese)
(孙兆军,余永,葛运建. 基于时间序列分析的可穿戴助力机器人传感信号预测的研究. *传感技术学报*, 2009, 22(3): 345 - 349)
- [3] Li Qiang, Stankovic J A, Hanson M A, *et al.* Accurate, Fast Fall Detection Using Gyroscopes and Accelerometer-Derived Posture Information // *Proc of the 6th International Workshop on Wearable and Implantable Body Sensor Networks*. Berkeley, USA, 2009: 138 - 143
- [4] Bourke A K, Lyons G M. A Threshold-Based Fall-Detection Algorithm Using a Bi-Axial Gyroscope Sensor. *Medical Engineering & Physics*, 2008, 30(1): 84 - 90
- [5] Noury N, Rumeau P, Bourke A K, *et al.* A Proposal for the Classification and Evaluation of Fall Detectors. *IRBM*, 2008, 29(6): 340 - 349
- [6] Chen Guanchun, Huang C N, Chiang C Y, *et al.* A Reliable Fall Detection System Based on Wearable Sensor and Signal Magnitude Area for Elderly Residents // *Proc of the 8th International Conference on Smart Homes and Health Telematics*. Seoul, Korea, 2010: 267 - 270
- [7] Tong Lina, Chen Wei, Song Quanjun, *et al.* A Research on Automatic Human Fall Detection Method Based on Wearable Inertial Force Information Acquisition System // *Proc of the IEEE International Conference on Robotics and Biomimetics*. Guilin, China, 2009: 949 - 953
- [8] Quagliarella L, Sasanelli N, Belgiore G. An Interactive Fall and Loss of Consciousness Detector System. *Gait & Posture*, 2008, 28(4): 699 - 702
- [9] Shi Guangyi, Chan C S, Li W J, *et al.* Mobile Human Airbag System for Fall Protection Using MEMS Sensors and Embedded SVM Classifier. *IEEE Sensors Journal*, 2009, 9(5): 495 - 503
- [10] Gullo F, Ponti G, Tagarelli A, *et al.* A Time Series Representation Model for Accurate and Fast Similarity Detection. *Pattern Recognition*, 2009, 42(11): 2998 - 3014
- [11] Zheng Xiuyuan. *Modern Sport Biomechanics*. 2nd Edition. Beijing, China: National Defence Industry Press, 2007 (in Chinese)
(郑秀媛. *现代运动生物力学*. 第2版. 北京: 国防工业出版社, 2007)
- [12] Su Weijia, Wang Xuhui. Application and Research of a New Accelerometer in Angle Measurement. *Mechanical Research and Application*, 2007, 20(5): 62 - 65 (in Chinese)
(苏维嘉,王旭辉. 新型加速度传感器在倾角测量中的应用研究. *机械研究与应用*, 2007, 20(5): 62 - 65)
- [13] Duda R O, Hart P E, Stork D G. *Pattern Classification*. 2nd Edition. New York, USA: John Wiley & Sons, 2001
- [14] Günter S, Bunke H. HMM-Based Handwritten Word Recognition: On the Optimization of the Number of States, Training Iterations and Gaussian Components. *Pattern Recognition*, 2004, 37(10): 2069 - 2079
- [15] Gomez R, Toda T, Saruwatari H, *et al.* Techniques in Rapid Unsupervised Speaker Adaptation Based on HMM-Sufficient Statistics. *Speech Communication*, 2009, 51(1): 42 - 57
- [16] Cheng M H, Ho M F, Huang C L. Gait Analysis for Human Identification through Manifold Learning and HMM // *Proc of the IEEE Workshop on Motion and Video Computing*. Austin, USA, 2007: 2541 - 2553