

基于混合高斯模型和主成分分析的轨迹 分析行为识别方法

田国会¹, 尹建芹^{1,2}, 闫云章¹, 李国栋¹

(1. 山东大学控制科学与工程学院, 山东济南 250061;

2. 济南大学信息科学与工程学院山东省网络环境智能计算技术重点实验室, 山东济南 250022)

摘 要: 针对家庭辅助生活应用场景下的目标意图识别和异常行为判别问题, 提出了一种基于目标轨迹的行为分析方法. 首先, 提出了关键点和关键区域的概念, 将家庭环境划分为不同的关键点和关键区域, 并以此来描述和区分不同轨迹; 然后, 提出了利用混合高斯模型的关键点及关键区域获取算法, 将轨迹转化为关键点及关键区域表示, 并以此为基础进行了行为意图的识别和部分异常轨迹的判断; 最后, 借助主成分分析的方法弥补混合高斯聚类在异常轨迹识别方面的缺陷, 提高了识别准确率. 实验表明, 该方法能够有效的对行为意图和异常行为进行识别.

关键词: 意图识别; 异常行为检测; 轨迹分析; 混合高斯聚类; 主成分分析

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2016)01-0143-07

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2016.01.021

Gaussian Mixture Models and Principal Component Analysis Based Human Trajectory Behavior Recognition

TIAN Guo-hui¹, YIN Jian-qin^{1,2}, YAN Yun-zhang¹, LI Guo-dong¹

(1. School of Control Science and Engineering, Shandong University, Jinan, Shandong 250061, China;

2. Shandong Provincial Key Laboratory of Network Based Intelligent Computing, School of Information Science and Engineering, University of Jinan, Jinan, Shandong 250022, China)

Abstract: In order to solve the problems of human motion intention recognition and abnormal behavior detection in home environment, a trajectory analysis based algorithm is discussed in this paper. Firstly, the home environment is divided into different key points and areas, so that the motion trajectory can be described by them. Moreover, based on mixture Gaussian model, the problems of motion intention recognition and abnormal behavior detection are analyzed. Finally, the PCA algorithm is applied to improve the accuracy of abnormal behavior detection. The experimental results show the effectiveness and reliability of the above conclusions.

Key words: motion intention recognition; abnormal behavior detection; motion trajectory analysis; Gaussian mixture clustering; principal component analysis

1 引言

随着我国社会老龄化程度的加剧,传统的家庭模式逐渐被新的4-2-1模式所代替.新的家庭模式下人力资源匮乏,人力成本增大.大量老人的照料及监护问题已经成为一个亟待解决的社会问题.通过识别人的意图从而为他们主动提供智能化的服务,可以提高老年人的生活质量;主动识别老年人生活中的异常情况并

采取实时的处理,可以提高老人生活的安全感.近年来,基于视频的人体行为分析技术的研究已经具备了大量的理论和技术积累^[1,2].为了实现空巢老人的智能监护,可以基于视频分析理论在家庭环境下对老人的行为进行分析,从而实现智能化和人性化的服务.而目标的运动轨迹较好的体现了目标的行为意图,因此,本文基于轨迹分析人的行为及意图,从而为主动式、智能化的家庭服务提供相应的服务依据.

运动轨迹是目标在空间中运动时,按照时间先后有序排列的一系列位置点的有序集合,是一条有向曲线^[3,4].目标运动轨迹的分析主要包括:轨迹表示,相似度测量,聚类和建模等^[5].常用的轨迹表示方法有曲线拟合、小波变换等.文献[6]利用卡尔曼滤波和B样条曲线来描述运动轨迹;文献[7]利用曲率尺度空间表示目标的形状,并且利用多项式拟合曲线来表示目标的轨迹曲线;文献[8]针对恒速运动的目标提出了一种基于多边形逼近的有效轨迹表示方法;文献[9]提出了基于离散傅里叶变换的轨迹表示方法,并利用自组织映射实现了轨迹间的相似性度量,这种方法比现有的其他方法效率更高.相似性度量是计算当前轨迹和模板轨迹之间相似度的过程,所以其是轨迹分析的关键^[10,11].文献[4]通过扩展卡尔曼滤波对轨迹进行估计和预测,并采用最长共同子序列(Longest Common Subsequence, LCSS)的方法进行相似性度量.文献[12]通过统计离散点的角度信息来描述轨迹,利用混合 von Mises 模型实现轨迹的相似性度量,并对混合 von Mises 模型参数的估计算法进行了改进.文献[13]针对 Euclidean 距离度量方式的缺陷,提出了基于动态时间规整(Dynamic Time Warping, DTW)的异常轨迹度量方式,并对 DTW 算法进行了改进,提高了执行效率.文献[14]针对交通路口车辆轨迹的聚类问题,结合谱聚类和 Hausdorff 距离,提出了一种轨迹相似性度量方法.文献[15]针对家庭智能环境下运动目标的轨迹描述和匹配提出了一种句法匹配方法,首先根据轨迹在时间和空间上的不连续性将轨迹用特定语法表示,然后借助生物学中 DNA 序列匹配的方法进行轨迹相似性判断,可以实现轨迹的分类、活动检测和行为理解.

轨迹分类是通过相似性度量使类似的轨迹归为同一类,而轨迹建模是为每一类轨迹构建一个模型,方便轨迹的表示和索引.文献[16]针对人体关节运动轨迹提出了一种基于 HMM 模型的轨迹分类方法,并对其中的迭代部分采用最大似然估计进行了改进.文献[17]针对常用非线性模型的缺陷提出了一种基于参数化运动矢量场的运动轨迹建模方法,该方法适用于各种轨迹并且不受全局非线性动态模型的限制.文献[18]针对复杂的动态场景提出了一种新的轨迹分析方法,首先通过 J-联动算法建立目标的运动模型,然后通过空间约束凝聚聚类对轨迹进行聚类分析.文献[19]中运动模型通过多元非参数化方法定义对象的位置和它们之间的时间过渡,训练阶段通过摄像机来长时间检测目标的运动轨迹.

本文以家庭环境为背景,以辅助生活为最终应用目的,基于轨迹对人体行为进行分析:将目标的运动与具体的环境相结合,考虑本文应用环境的特殊性——日常生活中人在家庭环境下的运动具有集中于若干关键区域的特点,选择基于混合高斯聚类^[20]的轨迹分析方法,对高斯混合聚类结果进行分析在宏观上能对目标的行为意图进行判别,但是在异常轨迹识别方面存在一定的缺陷,因此本文又引入了主成分分析(Principal Component Analysis, PCA)加最近邻的方法^[21],将其与混合高斯聚类相结合,提高了异常轨迹分析的准确性.

2 家庭环境下人体行为的基本特征及描述

轨迹描述是轨迹分析的基础,而人体行为往往与其所经历的功能区域相关,并且其活动集中于这些功能区域,因此,我们在家庭环境中引入“关键点”和“关键区域”的概念.

定义 1 关键点:是指与人的行为动作或习惯相联系而具有某种意义的位置或区域,例如,沙发、床等.

本文中,在标记了关键点的基础上,存储关键点的位置信息,关键点与此位置信息共同构成人体行为理解用的拓扑地图,这些关键点我们称其为拓扑点.另一方面,人的认知经验表明:通常目标会在关键点之间运动,也就是在关键区域内运动,并集中在关键点活动.一般来说,人的行走路线应该相对于关键区域服从概率分布,如果某次的路线发生了很大的偏移,此时目标很可能出现异常,因此通过分析目标的运动轨迹就可以确定目标当前的行为.

定义 2 关键区域:是指连接关键点的能反映人的某些具体行为意图的区域,例如客厅的地板.目标在这些关键点和关键区域之间运动就能够表达目标当前的行为意图.

本文实验环境及对应的关键点及关键区域如图 1 所示,圆圈代表桌子、床、饮水机、厕所这些关键点,关键点之间的椭圆区域表示关键区域.

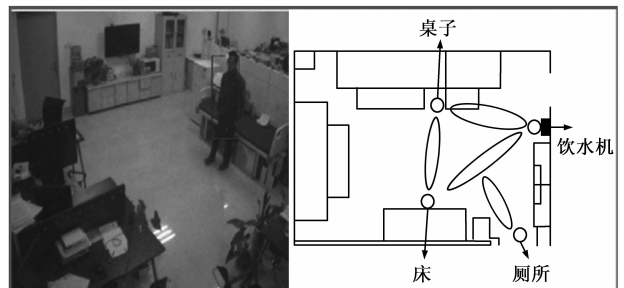


图1 所用实验环境及对应的关键点和关键区域

首先我们考虑人的行为识别过程:人在观察别人(在此,我们称其为行为人的行为时,其不需要测量行为人在空间中的精确位置,他只关心行为人所经过的大致区域,即所谓的关键点或关键区域,从而去推算人的行为.而在机器人或智能空间去观察行为人的行为时,其能得到的测量值只能是行为人在空间中的精确位置 (x,y) ,如何将该测量值映射为关键点或关键区域,是我们首要解决的问题.我们在以往的工作中,已经完成了人体的检测与定位^[22],目标在实验环境下进行特定行为时,相应的定位结果示于图 2. 而由图 2 中定位点在空间的分布可以看出,其位置服从混合高斯分布,因此,我们首先利用混合高斯模型提取关键点与关键区域.




图2 定位结果

3 基于混合高斯聚类的轨迹分析

混合高斯聚类^[23-25]是一种概率型聚类,每个高斯模型代表一个类,被估计的模型就是几个高斯模型的加权和.训练模型的输出不是一个具体的值,而是一系列的概率值,这些值就对应被划分为不同类的概率,然后可以选择概率最大的那个类作为判决结果.

可以认为人体行为轨迹的规律服从高斯混合模型 M ,用随机变量 $Z = (x,y)$ 代表人的位置,设 Z 服从以下混合高斯分布:

$$\begin{aligned}
 p(z | M) &= p(z | K, \theta_k) \\
 &= \sum_{k=1}^K \pi_k p_k(z | \theta_k) \\
 &= \sum_{k=1}^K \pi_k N(\mu_k, \Sigma_k) \quad (1)
 \end{aligned}$$

需要计算得到式(1)中的三组参数: π_k, μ_k, Σ_k ,其中 $\sum_{k=1}^K \pi_k = 1$ 其表示的是高斯模型的权重, μ_k 和 Σ_k 是第 k 个高斯成分的均值和协方差矩阵.给定 N 个人体定位观测值 $Z = \{z_1, z_2, \dots, z_N\}$,为了得到高斯混合模型,需要确定高斯分量的结构参数 K ,以及每个高斯成分的参数均值和协方差矩阵.为了求取混合高斯模型的参数,

同时为了便于计算,构造对数似然函数

$$\begin{aligned}
 \ln p(Z | M) &= \ln \prod_{i=1}^N p(z_i | K, \theta_k) \\
 &= \sum_{i=1}^N \ln \sum_{k=1}^K \pi_k p_k(z_i | \theta_k) \\
 &= \sum_{i=1}^N \ln \sum_{k=1}^K \pi_k N(\mu_k, \Sigma_k) \quad (2)
 \end{aligned}$$

其中, K 是高斯成分的个数, π_k, μ_k, Σ_k 是第 k 个混合高斯模型的权重、均值和协方差矩阵.为了确定以上各参数,采用期望最大化算法(EM, Expectation Maximal),其主要思想采用样本类别的估计值来代替样本类别的真实值.EM 算法需要迭代进行 E(期望)步和 M(最大化)步,不断的利用后验概率估计样本类别,直至收敛.其流程图如图 3,相应算法步骤如下:

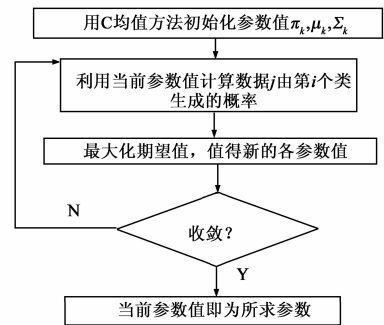


图3 EM算法流程图

Step1 先通过 C 均值方法进行初步聚类,根据聚类结果选取初值: π_k, μ_k, Σ_k ;

Step2 (E-Step)由初始值或者上一步迭代计算得到的参数值,估计数据由每个类生成的概率,用 $w_j^{(i)}$ 表示数据 j 由第 i 个类生成的概率可以由式(3)求得:

$$w_j^{(i)} = \frac{p(z_j | c_i = j, \mu_j, \Sigma_j) p(c_i = j)}{\sum_{l=1}^k p(z_j | c_i = l, \mu_l, \Sigma_l) p(c_i = l)} \quad (3)$$

Step3 (M-Step)通过最大化期望值,得到对应的各个参数值:

$$\begin{aligned}
 \pi_j &= \frac{1}{N} \sum_{i=1}^N w_j^{(i)}, \quad \mu_j = \frac{\sum_{i=1}^N w_j^{(i)} x_i}{\sum_{i=1}^N w_j^{(i)}} \\
 \Sigma_j &= \frac{\sum_{i=1}^m w_j^{(i)} (z_i - \mu_j)(z_i - \mu_j)'}{\sum_{i=1}^N w_j^{(i)}} \quad (4)
 \end{aligned}$$

Step4 判断是否收敛,若收敛(如 $w_j^{(i)}$ 不变),此时的参数 π_k, μ_k, Σ_k 即为所求参数,否则返回 Step2 继续迭代,直到收敛.

混合高斯聚类以后,即将轨迹序列转化为用关键

点表示的关键点序列. 通过对关键点序列进行分析就能识别目标当前的行为意图. 图 4 描述了人在空间中在饮水机、床、厕所、桌子之间进行日常行为时所采集的轨迹点对应的混合高斯聚类的结果, 图 4 中, 用不同的符号及灰度代表不同的类别, 共分成了 7 类, 同时, 由图 4 可见, 混合高斯模型可以较好的建模人的行为数据, 并将这些行为数据转换为了关键点序列.

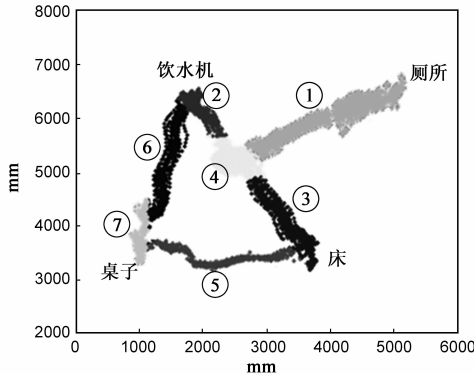


图4 混合高斯模型聚类结果

3.1 基于聚类结果的人体意图预测

某一个类或者某几个类的组合代表一种类型的运动轨迹, 例如在图 4 中, 第 7、5、3 类的顺序组合代表一种运动轨迹, 在本例中表示桌子到床之间的轨迹, 此时目标可能是去休息. 而第 3、4、2 类的顺序组合则表示了床到饮水机之间的轨迹, 此时目标可能是去倒水. 结合目标起始时所在关键点位置以及运动过程中所经历的聚类的类别, 就能判断目标当前的行为. 例如, 目标由关键点床出发, 经历了聚类 3 和聚类 4, 则目标有可能是去饮水机或者厕所, 但如果目标又经历了聚类 1, 则目标的目的地只能是厕所. 这种方法实用性更强, 通过统计关键点和经历聚类的顺序就能够实时的对目标的行为意图进行检测.

基于混合高斯聚类的轨迹分析尽管能够较好的识别目标当前的行为意图, 但是在异常行为检测方面存在缺陷. 异常轨迹可分为两大类: 第一, 不能到达目标点, 此时通过对聚类结果进行分析, 目标在关键点之间长时间没有运动就可判断发生异常; 第二, 目标能够到达目标点, 但是在运动过程中经历了圆弧形或者“s”形等有异于日常行为活动的曲线, 此时应用混合高斯聚类有可能出现错误的分析结果. 此类异常轨迹, 单独使用混合高斯聚类分析难以取得好的效果, 可以借助 PCA 的方法解决这个问题.

3.2 基于聚类结果的人体行为序列分割

进行高斯聚类后, 一方面可以进行人体行为预测及识别, 另一方面, 可以利用高斯聚类的结果进行人体

行为序列的分割. 在聚类之后, 建立当前点与拓扑点之间的映射关系: 首先判断当前点所属的关键点, 计算各拓扑点属于该关键点的概率, 选择最大概率对应的拓扑点, 如果该最大概率大于某一阈值, 则认为当前点属于拓扑点. 如果当前点属于拓扑点, 则标记该点是序列的起点或终点. 从而将不间断的行为序列分成了以关键点为起点和终点的行为序列, 在该切割序列的基础上, 则可以设计算法完成序列的分类或识别. 以序列分割结果为基础, 利用主成分分析提取轨迹的特征, 进行人体行为异常情况的判断.

4 基于 PCA 的运动目标轨迹分析

PCA 是利用数学降维的方法, 寻找高维向量的低维表示, 有效的降低了计算的复杂度^[26,27].

基于 PCA 的运动轨迹分析方法要求某一类别的运动轨迹采样点长度相同, 在此基础上, 其训练过程流程图如图 5, 训练过程步骤如下:

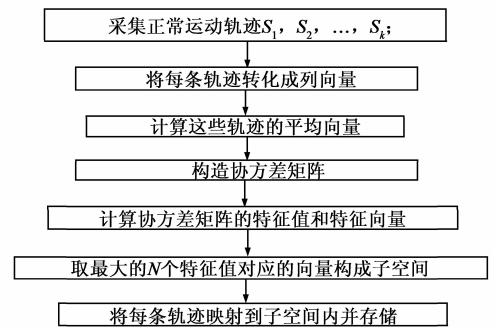


图5 PCA训练过程流程图

Step1 采集某类运动的一系列正常运动轨迹 S_1, S_2, \dots, S_k ;

Step2 将每一条轨迹 S_i 中的分量 (x, y) 首尾相接, 表示成列向量形式 T_i ;

Step3 计算这些向量的平均向量 $\Psi = \frac{1}{k} \sum_{i=1}^k T_i$;

Step4 每个向量 T_i 减去 $\Psi, \Phi_i = T_i - \Psi$;

Step5 计算协方差矩阵 $C = \frac{1}{k} \sum_{i=1}^k \Phi_i \Phi_i^T$;

Step6 计算协方差矩阵 C 的特征值 λ 和特征向量 u , 取前 N 个最大的特征值所对应的特征向量构成特征子空间, 设为 U ;

Step7 对 m 条训练轨迹逐一计算 $L_i = T_i^T U$, 并将其存储, 作为模板样本.

训练结束后, 可以进行测试. 设待测试的轨迹为 R , 按如下步骤进行测试:

Step1 将未知轨迹 R 首尾相接, 形成向量形式 R'

计算 $L_R = R^T U$;

Step2 分别计算 L_R 与 $L_i (i=1, 2, \dots, k)$ 之间的欧氏距离, 如果存在一个距离小于阈值 d , 则该未知轨迹为正常轨迹, 否则为异常轨迹.

基于 PCA 的轨迹分析具有较高的准确性, 但是该方法对数据要求较苛刻, 因为不同目标运动速度和运动习惯的不同, 同一类型的轨迹可能包含不同数量的轨迹点, 而我们需要的轨迹包含同样数量的轨迹点, 因此, 需要得到完整的运动轨迹后, 采样轨迹点来保证, 使轨迹上采样点的数目相同, 且采样点要尽量均匀分布. 在家庭环境下, 各关键点之间的运动轨迹不会太长, 完全可以对轨迹点进行统计. 利用混合高斯聚类的方法对轨迹进行预处理, 能够满足 PCA 对数据的要求: 通过聚类结果分析运动中起止关键点, 就可以判断该轨迹是否完整, 如果轨迹完整, 则在此轨迹上进行均匀采样; 然后利用 PCA 分析即可, 如果规定时间 T 内轨迹仍不完整, 可直接判断出现异常.

5 实验与分析

本文中运动轨迹通过智能空间对实际环境中的人体定位获得^[22], 图 4 描述了实际环境中的关键点以及关键点之间的轨迹曲线. 基于已经获取的定位结果, 对本文算法进行测试.

5.1 基于混合高斯模型聚类的行为分类

人在环境中进行我们感兴趣的行为: 床与桌子之间的运动行为, 饮水机与桌子之间的运动行为, 床与饮水机之间的运动行为, 还有床与厕所之间的运动行为, 以及饮水机与厕所之间的运动行为. 实验过程中, 共采集了 7087 个点, 对这些点进行混合高斯聚类, 利用 EM 算法, 得到每个高斯成分的权重、均值和协方差, 具体结果如图 4 所示, 此时各类的高斯模型参数如表 1 所示. 当人从床到桌子运动时, 选取 10 条正常运动轨迹, 对每条轨迹上的点落入各个类的数量进行统计, 结果如表 2 所示. 真实情况下从床到桌子的轨迹主要包括第 3、第 5、第 7 三种类别. 在第 3 节中已经对用混合高斯进行意图识别的方法进行了描述, 用于异常轨迹识别时, 混合高斯聚类的分析方法可能会出现错误的分析结果.

图 6 和图 7 表示两种异常轨迹的聚类结果, 这两个轨迹的起止点是饮水机和床, 在图 6 中, 共有第 2、第 6、第 7、第 5、第 3 五种类别的点, 正常情况下, 由饮水机到床不会经历该种路径, 因此此时可以判断出异常轨迹. 在图 7 中共有第 2、第 4、第 3 三种类别的点, 跟正常情况下的分类结果相同, 此时就会出现误判. 因此, 不能

单独使用高斯混合聚类的方法进行异常轨迹分析, 为了进行异常轨迹的判断, 我们采用主成分分析进行特征提取, 并利用最近邻完成异常行为识别.

表 1 混合高斯模型聚类结果

类别	权重	均值	协方差
1	0.2590	(4136.4, 6058.2)	$\begin{bmatrix} 523000 & 257890 \\ 257890 & 148220 \end{bmatrix}$
2	0.1224	(1874.0, 6277.2)	$\begin{bmatrix} 20754 & -20649 \\ -20649 & 32880 \end{bmatrix}$
3	0.1512	(3425.6, 3881.2)	$\begin{bmatrix} 80280 & -116350 \\ -116350 & 189370 \end{bmatrix}$
4	0.1670	(2495.6, 5192.9)	$\begin{bmatrix} 25887 & -6277 \\ -6277 & 17809 \end{bmatrix}$
5	0.0948	(2329.9, 3424.4)	$\begin{bmatrix} 532640 & -46790 \\ -46790 & 17280 \end{bmatrix}$
6	0.0994	(1464.7, 5195.2)	$\begin{bmatrix} 28910 & 116050 \\ 116050 & 552960 \end{bmatrix}$
7	0.1062	(1015.2, 3787.0)	$\begin{bmatrix} 3552 & 4963 \\ 4963 & 49925 \end{bmatrix}$

表 2 轨迹点统计结果(个)

轨迹序号	类 1	类 2	类 3	类 4	类 5	类 6	类 7
1	0	0	3	0	35	1	11
2	0	0	12	0	23	1	14
3	0	0	12	0	28	0	10
4	0	0	15	0	28	0	7
5	0	0	11	0	30	1	8
6	0	0	8	0	30	1	11
7	0	0	18	0	25	2	5
8	0	0	11	0	25	1	13
9	0	0	15	0	24	1	10
10	0	0	15	0	30	0	5

5.2 基于主成分分析的异常行为识别

利用 PCA 的方法对轨迹进行特征提取, 选取饮水机到床之间的 100 组正常运动轨迹作为模板, 对每条轨迹进行均匀离散化采样, 保证每条轨迹具有相同的采样点个数, 采样后得到每条轨迹有 50 个点, 如图 8 所示, 并用这 100 条轨迹计算协方差矩阵及其对应的特征向量. 此时协方差矩阵大小为 100×100 , 经实验验证, 取前 24 个最大的特征值及其对应的特征向量用于数据降维时效果最优, 此时特征向量矩阵的大小为 100×24 .

选取 10 条测试轨迹, 其中包括 7 条正常轨迹和 3 条异常轨迹, 如图 9 所示. 利用 PCA 方法对这 10 条轨迹进行降维. 分别计算测试轨迹与模板轨迹之间的欧式距离, 并选择最小值, 建立这 10 个最小欧式距离的分布图, 如图 10 所示. 经多次实验, 选定不匹配阈值为 800, 可以明显看出该方法能够较准确的识别正常轨迹和异常轨迹.

将混合高斯聚类 and 基于 PCA 的方法结合,能够有效克服各自单独使用时的缺陷,提高异常行为轨迹判断的准确

性,能够更好的为服务对象提供安全保障.




图6 圆弧形异常轨迹




图7 “s”形异常轨迹




图8 饮水机与床之间的正常运动轨迹




图9 测试轨迹




图10 最小欧氏距离分布图

6 总结

本文以家庭环境为背景,借助 PCA 和混合高斯聚类的方法,实现了家庭环境下目标行为意图的识别和异常运动轨迹的判断. 针对 PCA 数据要求苛刻和混合高斯聚类对异常轨迹判断准确性差的特点,提出了将两者结合的方法. 实验结果表明了该方法的有效性. 在下一步的工作中,重点对该方法的准确性进行改善,从而对监护对象的安全提供更有力的保障.

参考文献

[1] 王传旭,刘云,厉万庆. 基于时空特征点的非监督姿态建模和行为识别的算法研究[J]. 电子学报,2011,39(8):1751

-1756.
 Wang Chuanxu,Liu Yun,Li Wanqing. Research of unsupervised posture modeling and action recognition based on spatial-temporal interesting points [J]. Acta Electronica Sinica, 2011,39 (8) :1751 - 1756. (in Chinese)
 [2] 蒋建国,等. 多摄像机视域内的目标活动分析[J]. 电子学报,2014,42 (2) :306 - 311.
 Jiang Jianguo,et al. Activity analysis cross multi-Camera[J]. Acta Electronica Sinica,2014,42 (2) :306 - 311. (in Chinese)
 [3] Lou J,Liu Q,Tan T,et al. Semantic interpretation of object activities in a surveillance system [A]. The 16th International Conference on Pattern Recognition [C]. USA: IEEE,2002,3. 777 - 780.
 [4] Buzan D,et al. Extraction and clustering of motion trajectories in video [A]. The 17th International Conference on Pattern Recognition [C]. USA: IEEE,2004,2. 521-524.
 [5] Hu W,Li X,Tian G,et al. An incremental DPMM-based method for trajectory clustering, modeling, and retrieval [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013,35(5) :1051 - 1065.
 [6] Restrepo J C,et al. Trajectory generation for a robotic in a robocup test scenery using Kalman filter and B-spline curves [A]. XVII Symposium of Image, Signal Processing, and Artificial Vision (STSIVA) [C]. USA: IEEE, 2012. 110 - 115.
 [7] Dyana A,et al. Combining features for shape and motion trajectory of video objects for efficient content based video retrieval [A]. International Conference on Advances in Pattern Recognition [C]. USA: IEEE,2009. 113 - 116.
 [8] Kolesnikov A. Efficientonline algorithms for the polygonal approximation of trajectory data [A]. The 2th IEEE International Conference on Mobile Data Management (MDM) [C]. USA: IEEE,2011,1. 49 - 57.

- [9] Naftel A, Khalid S. Motion trajectory learning in the DFT-coefficient feature space[A]. IEEE International Conference on Computer Vision Systems[C]. USA:IEEE,2006. 47-47.
- [10] Morris B T, Trivedi M M. A survey of vision-based trajectory learning and analysis for surveillance [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2008, 18(8): 1114-1127.
- [11] Morris B, Trivedi M. Learning trajectory patterns by clustering: Experimental studies and comparative evaluation[A]. IEEE Conference on Computer Vision and Pattern Recognition [C]. USA: IEEE, 2009. 312-319.
- [12] Calderara S, Prati A, Cucchiara R. Mixtures of von mises distributions for people trajectory shape analysis[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2011, 21(4): 457-471.
- [13] Ratanamahatana C A, Keogh E. Three myths about dynamic time warping data mining[A]. Proceedings of SIAM International Conference on Data Mining[C]. USA: SIAM, 2005. 506-510.
- [14] Atev S, Miller G, Papanikolopoulos N P. Clustering of vehicle trajectories [J]. IEEE Transactions on Intelligent Transportation Systems, 2010, 11(3): 647-657.
- [15] Piotto N, Conci N, De Natale F G B. Syntactic matching of trajectories for ambient intelligence applications [J]. IEEE Transactions on Multimedia, 2009, 11(7): 1266-1275.
- [16] Choudry M U, Beach T A C, et al. A stochastic framework for movement strategy identification and analysis[J]. IEEE Transactions on Human-Machine Systems, 2013, 43(3): 314-327.
- [17] Nascimento J C, Marques J S, Lemos J M. Modeling and classifying human activities from trajectories using a class of space-varying parametric motion fields [J]. IEEE Transactions on Image Processing, 2013, 22(5): 2066-2080.
- [18] Kang J, Park S U, Chung M J. Online motion segmentation using spatially-constrained j-linkage in dynamic scene[A]. IEEE International Conference on Robotics and Biomimetics[C]. USA: IEEE, 2012. 1854-1860.
- [19] Saleemi I, Shafique K, Shah M. Probabilistic modeling of scene dynamics for applications in visual surveillance[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2009, 31(8): 1472-1485.
- [20] Bennewitz M, Burgard W, Thrun S. Using EM to learn motion behaviors of persons with mobile robots [A]. IEEE/RSJ International Conference on Intelligent Robots and Systems[C]. USA: IEEE, 2002, 1. 502-507.
- [21] Bashir F I, Khokhar A A, Schonfeld D. Segmented trajectory based indexing and retrieval of video data[A]. Proceedings of International Conference on Image Processing[C]. USA: IEEE, 2003. 623-626.
- [22] 尹建芹, 田国会, 等. 面向家庭服务的人体动作识别[J]. 四川大学学报(工程科学版), 2011, 43(4): 101-107. Yin Jianqin, Tian Guohui, et al. Human action recognition oriented to family service[J]. Journal of Sichuan University (Engineering Science Edition), 2011, 43(4): 101-107. (in Chinese)
- [23] Fraley C. Algorithms for model-based Gaussian hierarchical clustering[J]. SIAM Journal on Scientific Computing, 1998, 20(1): 270-281.
- [24] Pachoud S, Maggio E, Cavallaro A. Grouping motion trajectories[A]. IEEE International Conference on Acoustics, Speech and Signal Processing [C]. USA: IEEE, 2009. 1477-1480.
- [25] 桂树, 郭立, 陆海先. 基于 MUGG 的轨迹建模与异常检测[J]. 中国科学院研究生院学报, 2013, 30(2): 244-250. Gui Shu, Guo Li, Lu Haixian. MUGG-based modeling of trajectories and anomaly detection[J]. Journal of Graduate University of Chinese Academy of Sciences, 2013, 30(2): 244-250. (in Chinese)
- [26] Akhter I, Sheikh Y, Khan S, et al. Trajectory space: A dual representation for nonrigid structure from motion [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(7): 1442-1456.
- [27] Lee K K, Xu Y. Modeling human actions from learning[A]. IEEE/RSJ International Conference on Intelligent Robots and Systems [C]. USA: IEEE, 2004, 3. 2787-2792.

作者简介



田国会 男, 1969年8月出生, 河北河间人, 教授、博士生导师。1990年、1993年和1997年分别在山东大学、山东工业大学和东北大学获理学学士、工学硕士和工学博士学位。现为山东大学服务机器人研究室主任, 主要从事服务机器人、智能空间等方面的研究。

E-mail: g. h. tian@sdu. edu. cn



尹建芹 (通信作者) 女, 1978年11月出生, 山东潍坊人, 副教授、博士。2000年获山东工业大学工学学士学位, 2002年和2013年获山东大学工学硕士和工学博士学位。现在济南大学从事模式识别、机器学习及图像处理等相关研究。

E-mail: ise_yinjq@ujn. edu. cn