智能监控场景中运动目标轨迹聚类算法

郝久月 李超 高磊 熊璋

(北京航空航天大学 计算机学院, 北京 100191)

摘 要: 轨迹分析是视频监控场景理解的基础,但由于遮挡等原因,跟踪过程会出现不完整的噪声轨迹,导致分析结果不准确. 针对此类问题利用改进的轨迹相似度度量和聚类方法进行场景区域分割. 首先,对轨迹进行编码,提出利用轨迹的空间特征和速度方向特征改进相似性度量方法计算轨迹间距离;其次,采用改进的层次聚类算法,以该类最长轨迹作为运动物体行为模式代表,将在空间上接近且具有相似速度特征的轨迹划分为同一场景区域,得到符合实际情况的聚类结果. 本算法无需对轨迹进行复杂的预处理或过滤,并且加入速度方向特征使区域划分更加合理. 最后,在真实场景下,验证了该聚类算法的有效性和普遍适用性.

关 键 词: 轨迹分析; 相似度度量; 聚类算法; 语义区域

中图分类号: TP 391. 4

文献标识码: A **文 章 编 号**: 1001-5965 (2009) 09-1083-04

Moving object trajectory clustering method in intelligent surveillance video

Hao Jiuyue Li Chao Gao Lei Xiong Zhang

(School of Computer Science and Technology, Beijing University of Aeronautics and Astronautics, Beijing 100191, China)

Abstract: Trajectory analysis is the basis of scene understanding, however noise trajectories causing by barriers in true surveillance scene will influence the result veracity. A trajectory similarity measure and clustering method to segment a scene into semantic regions were proposed to eliminate the effect causing by noise. First, the trajectory was encoded, and then both the object position and its instantaneous velocity were computed by improved similarity measure method to represent the distance between two trajectories. Then, the improved hierarchical clustering algorithm which chooses the longest trajectory as each cluster representation was applied to cluster trajectories according to different spatial and velocity distributions. In each cluster, trajectories were spatially close, had similar velocities of motion, and represented one type of activity pattern. This algorithm doesn't need complex pre-process or filter, and because of adding velocity direction, the scene division is more reasonable. Finally, through experiment in true scene, the results show that the method can distinguish different clusters reasonably and improve the effectiveness of clustering

Key words: trajectories analysis; similarity measurement; clustering algorithms; semantic region

随着多媒体和网络技术的发展,视频监控系统日益普及,视频数据量呈爆炸性增长,如何进一步对视频内容进行智能化分析已成为人们的研究热点,因此,运动物体行为理解与目标异常检测等高级语义特征的提取受到了广泛的关注[1]. 其中,目标运动轨迹分析是行为理解的基本问题. 例如:交通路口的拐弯、直行、障碍物等导致运动物体有其特定的运动特征,物体的轨迹是表现这种行为最直观的特征. 轨迹分析是指通过分析给定的训练样本找出场景中的典型运动模式,为进一步场景理解提供语义区域.

1 轨迹分析的研究现状

目前,研究者们针对轨迹分析提出了多种方法. 文献[2]通过对轨迹进行傅里叶变换,利用自组织网络(SOM, Self-Organizing Maps)方法对变换

收稿日期: 2008-08-04

作者简介: 郝久月 (1984-),女,河北唐山人,博士生, haojiuyue@gmail.com.

后的轨迹特征进行分析;文献[3]采用层次自组织神经网络的方法学习轨迹的分布模式,但无法克服神经网络学习速度慢的缺点;文献[4]利用轨迹位置和速度特征,对轨迹进行聚类,进一步得到运动目标的统计模型;文献[5]使用动态时间规整(DTW, Dynamic Time Warping)方法建立路径模型,其缺点是划分轨迹类别的阈值无法确定;文献[6]将轨迹表示为可变长度序列,利用支持向量机的方法对其进行聚类. 尽管目前已有多种方法进行轨迹分析,但由于前期跟踪过程中可能伴随失跟及遮挡现象,致使目标运动轨迹并不完整. 这些不完整轨迹会影响后期的轨迹分类,最终导致场景理解存在很大误差. 目前上述相关文献主要依靠人工或依据轨迹长度阈值删除噪声轨迹. 这些操作无疑降低了分析的效率,并且某些噪声轨迹本身也包含了目标的行为特点. 如何解决上述问题,是轨迹分析中的难点. 为解决不完整轨迹(噪声轨迹)问题,保留轨迹特殊部分特征,文献[7]提出将轨迹进行分段后,再对线段进行分组的思想. 此方法虽然解决了短轨迹问题,但分段长度的不同对算法产生很大影响,且难以确定.

本文提出一种利用完整轨迹作为运动模式代表的聚类算法,其无需对轨迹进行任何预处理. 算法假设通过相应的跟踪算法已经得到了 n 条轨迹信息. 首先对轨迹相似度度量方法提出了改进,引入了速度夹角特征,提高相似度的准确性;其次,对层次聚类算法进行了改进,解决了不完整轨迹带来的相关问题.

2 轨迹相似度度量

2.1 轨迹编码

轨迹分析需将大量轨迹样本以统一形式进行编码. 本文采用文献[3]的轨迹编码方法. 给定场景视频,经过相等时间间隔进行多次采样,得到目标不同时刻的多个质心点,轨迹由一系列的质心点连接而成.

对于目标 o,设第 i 次采样时它的质心坐标为 (x_i, y_i). $(\delta x_i, \delta y_i)$ 表示目标 o 在 i 时刻运动速度矢量,其中 $\delta x_i = x_{i+1} - x_i$, $\delta y_i = y_{i+1} - y_i$. 由此,可以用一个流矢量序列描述目标的运动轨迹,其中流矢量 f 是一个四元组,既表示目标的位置,也表示目标的速度:

$$\mathrm{f}_i = (x_i, y_i, \delta x_i, \delta y_i)$$

最后,将流矢量的每一个元组变换到 $[0, 1]$ 范围之内. 经处理后,目标 o 的轨迹可表示为由 n 个流矢量组成的集合:

$$O_o = \{\mathrm{f}_1, \mathrm{f}_2, \cdots, \mathrm{f}_i, \cdots, \mathrm{f}_{n-1}, \mathrm{f}_n\}$$

2.2 相似性度量方法

为进一步对轨迹聚类,需要确定一种样本相似度的度量方法,衡量轨迹间的相似程度. 文献[8]总结了目前常用的轨迹相似性度量方法,包括:欧氏距离(Euclidean),主成分分析(PCA, Principal Components Analysis)+欧氏距离,豪斯多夫距离(Hausdroff)距离,最长公共序列(LCSS, Longest Common Subsequence),DTW 和隐马尔科夫模型(HMM, Hidden Markov Models). 传统的欧氏距离要求两条轨迹的轨迹点个数相同;PCA + 欧氏距离的方法有较高的效率,但是通过 PCA 对轨迹重编码,丢失了轨迹点的速度方向信息;Hausdroff的优点是可以对两条不同长度的轨迹进行编码,但其时间消耗率较高且没有考虑轨迹方向的影响;LCSS和 DTW 方法能有效地对轨迹进行度量,但其更适合于描述柔性物体的形状变化轨迹;HMM的训练方法要求大量的轨迹点,否则将出现 over-fitting的现象. 文献[8]中权衡识别率和时间消耗,对 PCA +欧氏距离的方法给予了肯定.

本文考虑到对不同长度的轨迹进行处理,因此采用 Hausdroff距离的改进方法. 轨迹方向是场景分析的重要因素,因此本文提出的轨迹相似性度量方法由空间距离和方向距离组成.

设轨迹 A 一点为 $\mathrm{a}_i = (x_i^a, y_i^a, \delta x_i^a, \delta y_i^a)$, a_i 与轨迹 B 的欧氏距离最小点 b_j 的空间距离为

$$\psi(i) = \arg\min_{j \in B} \| (x_i^a - x_j^b, y_i^a - y_j^b) \| \quad (1)$$

因此,轨迹 A 和 B 的空间距离为

$$d_s(A, B) = \frac{1}{N_A} \sum_{a \in A} \| (x_i^a - x_{\psi(i)}^b, y_i^a - y_{\psi(i)}^b) \| \quad (2)$$

设 a_i 的速度为 $\mathrm{v}_i^a = (\delta x_i^a, \delta y_i^a)$,轨迹 B 上一点 b_j 的速度为 $\mathrm{v}_j^b = (\delta x_j^b, \delta y_j^b)$,定义 a_i 与 b_j 的速度方向为

$$\cos\theta = \frac{\mathrm{v}_i^a \cdot \mathrm{v}_j^b}{|\mathrm{v}_i^a| \cdot |\mathrm{v}_j^b|} \quad (3)$$

转换为轨迹速度方向的距离为

$$d_v(\mathrm{v}_i^a, \mathrm{v}_j^b) = 1 - \cos\theta \quad (4)$$

因此轨迹 A 到 B 的距离为

$$d(A, B) = \frac{1}{N_A} \sum_{a \in A} \left[\| (x_i^a - x_{\psi(i)}^b, y_i^a - y_{\psi(i)}^b) \| + k d_v(\mathrm{v}_i^a, \mathrm{v}_{\psi(i)}^b) \right]$$

其中,k 为权重,通过改变 k 的取值,可以调整速度方向对相似度的贡献;N_A 为轨迹 A 中点的个数.

如果轨迹 A 是与轨迹 B 相邻但不完整的短轨迹,那么 $d(A,B)$ 将远远小于 $d(B,A)$. 因此最终将 A 与 B 之间的距离定义为

$$D(A,B) = \min(d(A,B), d(B,A)) \quad (5)$$

这样可以保证短轨迹被聚类算法划分到具有相似运动特征的轨迹类中,提高了聚类算法的抗干扰能力. 根据公式 (5)可计算改进后的轨迹相似度.

3 轨迹聚类

轨迹聚类是场景分析和行为理解的基础. 目前常用的聚类方法包括 K均值聚类和层次聚类. 由于 K均值聚类[9-10]需要事先估计聚类数目和聚类中心,而在复杂场景环境下,无法提前预测场景区域个数. 因此本文基于层次聚类的方法对其进行改进,以适应不同长度的轨迹.

层次聚类算法的基础是两个聚类 ω_i 和 ω_j 之间的相似度度量 $\Delta(\omega_i,\omega_j)$的计算方法. 最常用的相似度度量包括[9]:最近距离 (shortest distance),最远距离 (furthest distance),均值距离 (unweighted average distance). 但传统的层次聚类相似度度量方法不能满足轨迹聚类的需求,如图 1所示场景存在 6条轨迹.

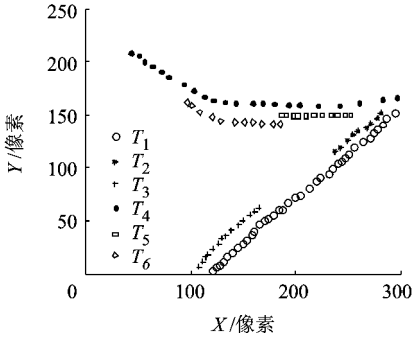

图 1　噪声轨迹示意图

按照 2.2节的轨迹相似度度量方法,得到轨迹间距离,如表 1所示. T_1和 T_4 为正常轨迹,而 T_2, T_3, T_5, T_6 为短轨迹. 以 T_1, T_2, T_3 这 3条轨迹为例, $D(T_1, T_2) = 0.044$, $D(T_1, T_3) = 0.076$, 但 $D(T_2, T_3) = 0.564$ 显然, T_1, T_2, T_3 应为同一分类,因此不完整轨迹的存在很大程度上影响了聚类的准确性. 同时,从表 1可以看出完整轨迹 T_1 和 T_4 准确反映了运动目标的运动特征,此特征是和场景密切相关的.

为计算轨迹长度,定义其计算公式为

$$L(T_i) = \sum_{k=n-1} \sqrt{(x_k - x_{k+1})^2 + (y_k - y_{k+1})^2} \quad (6)$$

表 1　轨迹间距离

A	B					
	T_1	T_2	T_3	T_4	T_5	T_6
T_1	0	0.044	0.076	1.213	0.652	1.096
T_2	0.044	0	0.564	0.413	0.374	0.551
T_3	0.076	0.564	0	1.341	0.866	1.546
T_4	1.213	0.413	1.341	0	0.056	0.083
T_5	0.652	0.374	0.866	0.056	0	0.227
T_6	1.096	0.551	1.546	0.083	0.227	0

根据上述分析,本文改进传统层次聚类的类间相似度度量标准,将轨迹长度作为标准,即当节点 1与节点 2聚为一类后,判断节点 1和节点 2的轨迹长度,用较长轨迹作为此类代表,进行下一次聚类.

算法步骤如下:

1) 给定 n条轨迹 T_i,最初把每个样本看成一类 $\omega_i = \{T_i\}$,设聚类数 $c = n$;

2) 当 $c \geq 1$时,重复进行以下操作:

①计算轨迹相似度 $D(T_i, T_j)$,确定最近的两个聚类 ω_i 和 ω_j;

②合并 ω_i 和 ω_j 为 ω_{ij},判断类别的代表轨迹 T_i 和 T_j 的长度,选取长轨迹作为类别 ω_{ij} 的代表轨迹 T_{ij},从而得到 $c-1$聚类;

③将 c值递减.

通常类内相异程度[10] (corresponding linkage distances)是评价聚类方法的标准. 在相异程度显著上升点,即在拐点前相异度越小,拐点后相异程度明显增大时能得到较好的聚类结果. 将改进的层次聚类算法与传统层次聚类 3种方法进行比较.

如图 2所示,由于样本点较少, 4种方法虽然都得到了正确的聚类结果,且由图 2可知第 4次聚类为拐点. 同时进一步比较第 4步与第 5步的联接距离:改进后方法为 1.13;最短距离为 0.29, 最远距离为 0.98;平均距离为 0.58. 采用改进方法的联接距离大于其它传统方法. 因此改进方法提高了类间的相异程度,能得到更为准确的聚类结果,更适合于本场景的应用.

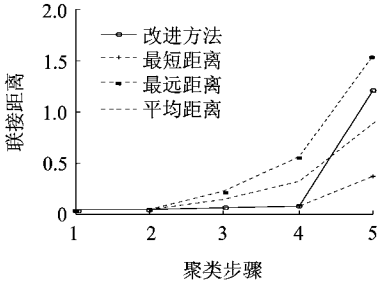

图 2　轨迹聚类步骤比较结果

4 实验结果分析

实验 1:为验证本文提出轨迹相似性度量方法,将其与文献[8]推荐的 PCA +欧氏距离的方法进行比较. PCA +欧氏距离方法的主要缺点是要求轨迹长度必须相等. 本实验采取手工标注的不同方向轨迹的 27条,每条轨迹包含 30个点,如图 3所示. 采用传统的层次聚类方法,对轨迹相似性度量进行比较,如表 2所示.

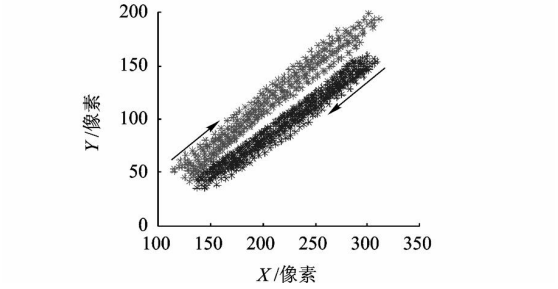

图 3 手工标注轨迹示意图

表 2 相似性度量方法比较

方 法	聚类数	正确数	错误数	识别率/%
本文方法	2	27	0	100.0
PCA +欧氏距离	2	26	1	96.3

由表 2可知,两种方法均得到了较高的识别率. 但是在实际的跟踪过程中无法保证轨迹的长度相同. 因此本文提出的相似性度量方法有更广泛的使用性和适用性.

实验 2:为验证本文提出的聚类方法,在场景 S_1 下,利用 MeanShift算法对车辆进行跟踪[11],得到 70条运动轨迹,其中包含短轨迹(小于最长轨迹的 1/2) 12条. 聚类结果如图 4所示,图 4中标出噪声轨迹示例.

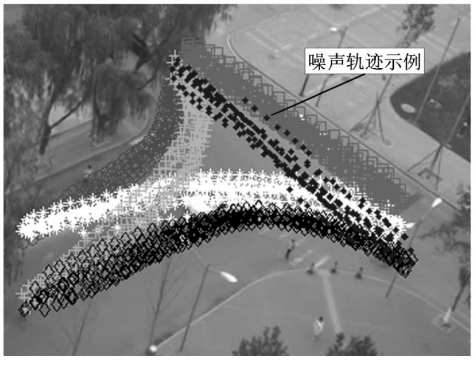

图 4 轨迹聚类场景 S_1

通常情况下,一种聚类方案越有效,其聚类结果就越趋于平衡(从各个类包含的样本数量来讲)[10]. 图 5a可以看出,由于短轨迹的影响,第 27条轨迹,甚至出现了自己单独一类的特殊情况;而图 5b每类样本数分布均匀. 图 5b从 6类到 3类过程中,联接距离(相异程度)显著上升,因此将场景分为 6个区域,符合真实情况.

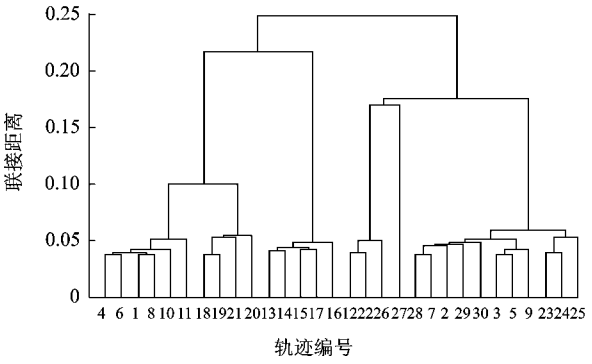

a 传统方法聚类结果

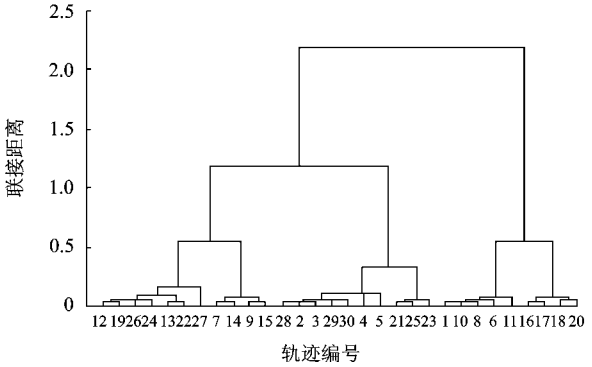

b 改进层次聚类方法结果

图 5 S_1 轨迹聚类结果直方图

为验证算法的适用性,选取如图 6所示场景 S_2,采用同样的跟踪和轨迹聚类方法,处理 40条轨迹,其中不完整轨迹 8条,同样得到了符合场景的聚类结果. 实验结果表明此方法不受监控场景的影响,不受运动物体的限制,其对后期物体行为理解、轨迹预测、异常检测等语义理解问题提供了准确的场景语义区域.



图 6 S_2 场景轨迹聚类结果

5 结束语

本文提出了一种对监控场景中运动目标轨迹进行聚类的方法. 为提高轨迹聚类的鲁棒性,降低

噪声轨迹的影响,首先利用轨迹空间距离和速度方向距离作为轨迹相似度度量,此方法能适应不同长度的轨迹,解决了噪声对轨迹相似性的影响;其次,改进了传统的层次聚类,将轨迹长度作为衡量聚类的标准,提取每类最长轨迹用于下一次聚类.通过真实场景的轨迹聚类实验,验证了此方法的有效性.本文的研究结果为目标行为理解和异常检测提供了有效的依据.

参考文献 (References)

[1] Howarth R J, Buxton H. Conceptual descriptions from monitoring and watching image sequences[J]. Image and Vision Computing, 2000, 18(2): 105 - 135

[2] Khalid S, Naftel A. Classifying spatiotemporal object trajectories using unsupervised learning of basis function coefficients[C]//Aggarwal J K. Lect Notes Comput Sci. NY: ACM, 2005: 45 - 51

[3] 胡卫明,谢丹,谭铁牛,等.轨迹分布模式学习的层次自组织神经网络方法[J].计算机学报, 2003, 26(4): 417 - 426
Hu Weiming, Xie Dan, Tan Tieniu, et al. A hierarchical self-organizing approach for learning the patterns of motion trajectories[J]. Chinese Journal of Computers, 2003, 26(4): 417 - 426 (in Chinese)

[4] Wang X G, Tieu K, Grimson E. Learning semantic scene models by trajectory analysis[C]//Pinz A. Lect Notes Comput Sci. Berlin: Springer, 2006: 110 - 123

[5] Junejo I N, Foroosh H. Trajectory rectification and path modeling for video surveillance [C]//Davies L. Proceedings of the IEEE International Conference on Computer Vision. Brazil: IEEE Press, 2007: 1 - 7

[6] Piciarelli C, Micheloni C, Foresti G L. Trajectory-based anomalous event detection[J]. IEEE Transactions on Circuits and system for Video Technology, 2008, 18(9): 1544 - 1554

[7] Lee J G, Han J W, Whang K Y. Trajectory clustering: a partition and-group framework [C]//Proceedings of the ACM SIGMOD International Conference on Management of Data. NY: ACM, 2007: 593 - 604

[8] Zhang Z, Huang K, Tan T N. Comparison of similarity measures for trajectory clustering in outdoor surveillance scenes [C]//Tang Y Y. Proceedings-International Conference on Pattern Recognition. Piscataway, NJ: IEEE Press, 2006, 3: 1135 - 1138

[9] 边肇祺,张学工. 模式识别 [M]. 2版. 北京:清华大学出版社, 2000: 244 - 247
Bian Zhaoqi, Zhang Xuegong. Pattern recognition [M]. 2nd ed. Beijing: Tsinghua University Press, 2000: 244 - 247 (in Chinese)

[10] jpMarquess de Sa. 模式识别——原理、方法及应用 [M]. 吴逸飞译. 北京:清华大学出版社, 2002: 55 - 73
jpMarquess de Sa. Pattern recognition: concepts, methods and applications[M]. Translated by Wu Yifei. Beijing: Tsinghua University Press, 2002: 55 - 73 (in Chinese)

[11] Veeraraghavanm H, Papanikolopoulos N. Combining multiple tracking modalities for vehicle tracking at traffic intersections [C]//Tam T J. Proceedings-IEEE International Conference on Robotics and Automation. Piscataway, NJ: IEEE, 2004 (3): 2303 - 2308

(责任编辑:文丽芳)

(上接第 1082页)

3 结束语

对偶密钥的建立是实现无线传感器网络安全通信最基本和重要的问题.本文提出的对偶密钥预分配方案以超立方体的维度和汉明距离门限值为参数.通过将传感器节点间的汉明距离参数化,解决了以往方案只能在汉明距离为 1时才能直接建立对偶密钥的限制.经过安全和性能的分析说明,当汉明距离门限值增大时,方案通过牺牲抗节点俘获能力可以提高直接对偶密钥建立概率,从而节省了对于传感器网络来说十分重要的能量消耗.

参考文献 (References)

[1] Akyildiz F, Su W, Sankarasubramaniam Y, et al. A survey on sensor networks[J]. IEEE Communications Magazine, 2002, 40(8): 102 - 114

[2] Diffie W, Hellman M E. New directions in cryptography[J]. IEEE Transactions on Information Theory, 1976, 22: 644 - 654

[3] Rivest R L, Shamir A, Adleman L M. A method for obtaining digital signatures and public-key cryptosystems[J]. Communications of the ACM, 1978, 21(2): 120 - 126

[4] Needham Roger M, Schroeder M D. Using encryption for authentication in large networks of computers[J]. Communications of the ACM, 1978, 21(12): 993 - 999

[5] Perrig A, Szewczyk R, Wen V, et al. SPINS: security protocols for sensor networks[J]. Wireless Networks, 2002, 8: 521 - 534

[6] Bundo C, Santis A D, Herzberg A, et al. Perfectly-secure key distribution for dynamic conferences [J]. Information and Computation, 1998, 146(1): 1 - 23

[7] Liu D, Ning P. Establishing pairwise keys in distributed sensor networks[C]//Proceedings of the 10th ACM Conference on Computer and Communication Security. New York: ACM, 2003

[8] Liu D, Ning P. Establishing pairwise keys in distributed sensor networks[J]. ACM Transaction Information Systems, 2005, 1: 41～77

(责任编辑:娄　嘉)