

# 基于 Hausdorff 距离的视觉监控轨迹分类算法

曲琳, 周凡, 陈耀武

(浙江大学 数字技术及仪器研究所, 杭州 310027)

**摘要:** 针对智能视觉监控系统中的运动目标轨迹分类问题, 提出了一种基于多维 Hausdorff 距离的轨迹聚类算法。该算法使用流矢量序列描述目标运动轨迹, 由多维 Hausdorff 距离进行轨迹相似性测量, 通过谱聚类实现轨迹分类。该算法在轨迹描述中同时包含位置和方向信息, 解决了 Hausdorff 距离不能区分轨迹运动方向的问题。为降低计算复杂度, 本文还提出一种保距变换对轨迹相似性测量进行优化。与相关算法的对比实验表明, 提出的轨迹分类算法可达到更高的聚类准确率; 提出的保距变换可以显著降低算法的计算复杂度。

**关键词:** 人工智能; 轨迹分类; Hausdorff 距离; 谱聚类; 保距变换

**中图分类号:** TP391.4    **文献标识码:** A    **文章编号:** 1671-5497(2009)06-1618-07

## Trajectory lclassification based on Hausdorff distance for visual surveillance system

QU Lin, ZHOU Fan, CHEN Yao-wu

(Institute of Advanced Digital Technology and Instrument, Zhejiang University, Hangzhou 310027, China)

**Abstract:** A trajectory clustering algorithm based on multi-dimensional Hausdorff distance is proposed for classification of trajectories of moving objects in intelligent visual surveillance system. First, the trajectory of a moving object is described using a sequence of flow vectors. Then the similarity between trajectories is measured by their respective multi-dimensional Hausdorff distances. Finally, the trajectories are clustered by the spectral clustering algorithm. The proposed algorithm is different from other schemes using Hausdorff distance that it includes both the position and direction information in the flow vectors; hence it can distinguish the trajectories in different directions. A distance preserving transformation is also proposed to reduce the computational complexity of the similarity measure. Experimental results show that, comparing with other algorithm, the clustering accuracy of the proposed algorithm is better, and the proposed distance preserving transformation can greatly reduce the computational cost.

**Key words:** artificial intelligence; trajectory classification; Hausdorff distance; spectral clustering; distance preserving transformation

**收稿日期:** 2008-03-12.

**基金项目:** “863”国家高技术研究发展计划项目(2003AA1Z2130); 浙江省重大科技攻关项目(2005C11001-02).

**作者简介:** 曲琳(1979-), 男, 博士研究生. 研究方向: 嵌入式系统, 计算机视觉, 模式识别.

E-mail: tsulin@zju.edu.cn; tsu\_lin@sina.com

**通信作者:** 陈耀武(1963-), 男, 教授, 博士生导师. 研究方向: 嵌入式系统, 智能信息处理, 网络多媒体技术.

E-mail: cyw@mail.bme.zju.edu.cn

基于视觉的智能监控系统是计算机视觉的一个新兴研究方向,其主要研究内容包括运动检测、目标跟踪、目标分类和目标行为理解<sup>[1-2]</sup>。对监控场景中的运动目标轨迹分类,实现目标行为描述并探测场景中的异常事件,是目标行为理解的重要研究内容之一。

为实现轨迹分类,首先需要测量轨迹间的相似性。现有轨迹分类算法中使用的相似性测量方法包括:基于 Euclidean 距离的方法<sup>[3]</sup>、基于 DTW(Dynamic Time Warping)的方法<sup>[4]</sup>、基于 HMM(Hidden Markov Model)的方法<sup>[5]</sup>、基于 LCSS(Longest Common Subsequence)的方法<sup>[6]</sup>和基于 Hausdorff 距离的方法等。文献[7]对上述方法进行了综述。在使用 Hausdorff 距离进行轨迹相似性测量的方法中,文献[8]和[9]使用轨迹二维空间坐标序列的 Hausdorff 距离测量轨迹相似性,这种方法不能区分运动方向信息,可能产生错误的分类结果。文献[10]分别测量轨迹空间坐标序列和速度序列的 Hausdorff 距离,通过计算两距离的加权和测量轨迹相似性,但这种方法需要预先指定两序列的距离权重。

本文提出一种基于多维 Hausdorff 距离的运动目标轨迹分类算法,首先使用流矢量序列描述目标运动轨迹,然后用多维 Hausdorff 距离测量流矢量序列间的距离,最后使用谱聚类完成轨迹分类。实际监控场景中的实验结果表明,本文提出的轨迹分类算法可达到比试验中其他算法更高的聚类准确率;提出的保距变换可以显著降低分类过程的时间复杂度。

## 1 轨迹相似性测量与聚类算法

### 1.1 轨迹预处理与描述

运动目标的轨迹由目标跟踪算法生成。给定目标的图像序列,跟踪算法按照等间隔  $\Delta t$  进行采样,每次采样都可以得到目标的质心位置。按顺序连接不同时刻目标的质心即可得到运动轨迹。由于原始目标轨迹中存在较多噪声,本文首先使用移动平均滤波对原始轨迹进行平滑处理。平滑后目标运动轨迹的空间坐标序列为

$$t = \{(x_1, y_1), (x_2, y_2), \dots, (x_l, y_l)\} \quad (1)$$

式中:  $(x_i, y_i)$  为目标质心在第  $i$  次采样中的二维坐标;  $l$  为目标运动持续的采样次数。

除位置外,运动方向也是描述轨迹的重要信息。第  $i$  次采样中目标运动方向可由下式表示

$$dx_i = (x_{i+1} - x_i) / \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2}$$

$$dy_i = (y_{i+1} - y_i) / \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2}$$

因此,目标运动方向序列可由下式描述

$$d = \{(dx_1, dy_1), (dx_2, dy_2), \dots, (dx_l, dy_l)\} \quad (2)$$

为使运动方向序列与空间坐标序列  $t$  等长,在式(2)添加了第  $l$  个采样点的运动方向,并设为  $(dx_l, dy_l) = (dx_{l-1}, dy_{l-1})$ 。

### 1.2 轨迹相似性测量

Hausdorff 距离是描述两组点集之间相似程度的一种度量,也是集合之间距离的一种定义形式。给定两轨迹的空间坐标序列  $t_i$  和  $t_j$ ,可直接使用 Hausdorff 距离对其进行相似性测量<sup>[8-9]</sup>。然而这种方法不能区分运动方向信息,可能产生错误的测量结果。例如,它不能区分形状相同、方向不同的轨迹。

为在轨迹描述中同时包含位置信息和运动方向信息,与文献[11]类似,本文定义如下的流矢量(flow vector)  $f$  来代替二维坐标对目标运动轨迹进行描述:

$$f_i = (x_i, y_i, dx_i, dy_i) \quad (3)$$

流矢量中运动方向属性已进行规范化变换。为平衡流矢量  $f$  中位置属性和方向属性对相似性测量的影响,本文对位置属性进行规范化变换,将  $x_i$  和  $y_i$  缩放到范围  $[0, \sqrt{2}/2]$  内。经过上述处理后,目标轨迹可描述为长度为  $l$  的流矢量序列:

$$F = \{f_1, f_2, \dots, f_l\} \quad (4)$$

使用流矢量序列  $F$ , 轨迹  $F_i$  和  $F_j$  间的距离可由多维 Hausdorff 距离测量(以下简称为 MDHS 算法)

$$\begin{cases} H_{\text{md}}(F_i, F_j) = \max\{h_{\text{md}}(F_i, F_j), h_{\text{md}}(F_j, F_i)\} \\ h_{\text{md}}(F_i, F_j) = \max_{f_a \in F_i} \min_{f_b \in F_j} d(f_a, f_b) \\ h_{\text{md}}(F_j, F_i) = \max_{f_b \in F_j} \min_{f_a \in F_i} d(f_b, f_a) \end{cases} \quad (5)$$

式中:  $d(f_a, f_b)$  为流矢量  $f_a$  与  $f_b$  之间的 Euclidean 距离。

### 1.3 基于谱聚类的轨迹分类算法

在确定轨迹相似性测量算法后,本文提出基于谱聚类的轨迹分类算法(以下简称为 SC 算法)对轨迹集合进行分类。谱聚类<sup>[12]</sup>算法的思想源于谱图划分理论,它将输入特征矢量做为图中的顶点,将特征矢量间的相似度做为连接顶点的边,通过寻找图的最优划分来实现输入特征矢量的分类。

给定轨迹集合  $T = \{t_1, \dots, t_n\}$ , SC 算法通过以下步骤将其分为  $m$  类:

(1) 对轨迹集合中的每条轨迹  $t_i$ , 由式(3)、式(4)计算其对应的流矢量序列  $F_i$ 。

(2) 计算  $n \times n$  相似性矩阵(affinity matrix)  $A$ :

$$A_{ij} = \begin{cases} 0, & i=j \\ \exp(-\mathbf{H}(F_i, F_j)^2 / (2\sigma^2)), & i \neq j \end{cases} \quad (6)$$

式中:  $\sigma$  为尺度参数, 控制  $A_{ij}$  随  $F_i$  和  $F_j$  间距离增加而衰减的速度;  $\mathbf{H}(F_i, F_j)$  为轨迹间距离, 由式(5)计算。

(3) 定义对角矩阵  $D$ , 其主对角元素  $D_{ii}$  为相似性矩阵  $A$  中第  $i$  行所有元素之和,  $D_{ii}$

$$= \sum_{j=1}^n A_{ij}。$$

(4) 构造矩阵  $L = D^{-1/2} A D^{-1/2}$ , 并对  $L$  进行特征值分解, 取特征值最大的  $m$  个特征向量  $x_1, x_2, \dots, x_m$ 。

(5) 将每个特征向量做为一列, 构造  $n \times m$  矩阵  $X = [x_1, x_2, \dots, x_m]$ 。对  $X$  的每一行进行归一化, 得到矩阵  $Y$ , 其中

$$Y_{ij} = X_{ij} / (\sum_j X_{ij}^2)^{1/2}$$

(6) 将  $Y$  中每个行向量视为  $m$  维空间中的一点, 使用模糊  $C$  均值聚类将  $Y$  的行向量分为  $m$  个簇。

(7) 将轨迹  $t_i$  分配到矩阵  $Y$  第  $i$  个行向量对应的簇中。

上述算法中, 尺度参数  $\sigma$  由文献[12]所述方法自动确定。首先由  $\mathbf{H}(F_i, F_j)$  确定轨迹间距离的最大值  $d_{max}$  和最小值  $d_{min}$ ; 然后按对数尺度间隔在  $[d_{min}, d_{max}]$  范围内选择尝试值  $\sigma'$ , 并计算其聚类结果的平方误差;  $\sigma$  最终取为使平方误差最小的尝试值。

轨迹数据集中的类别数  $k$  由相似性矩阵的特征值估计<sup>[13]</sup>。设相似性矩阵  $A$  的特征值为  $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$ , 类别数  $k$  可通过查找相邻特征值之差的最大值获得:  $k = \arg \max_i |\lambda_i \lambda_{i-1}|$ 。

## 2 轨迹相似性测量算法优化

使用式(5)定义的 Hausdorff 距离进行轨迹相似性测量时, 需要计算轨迹间任意两点的 Euclidean 距离。对长度为  $u$  和  $v$  的两条轨迹, 计算复杂度为  $O(uv)$ , 计算量较大。另外, 多数聚类 and 检索算法依赖向量空间(vector space)上的操

作进行优化(例如计算簇的中心), 而 Hausdorff 距离定义的却是一个度量空间(metric space), 使这些算法不能得到应用。

为解决上述问题, 本文提出一种轨迹保距变换<sup>[14-15]</sup> (Trajectory distance preserving transformation)。将轨迹描述由基于 Hausdorff 距离的度量空间映射到基于参考点集的向量空间中, 并在目标向量空间中使用 Chebyshev 距离进行轨迹相似性测量, 使轨迹在目标向量空间中的距离等于或小于在原度量空间中的距离。

### 2.1 轨迹保距变换

以下首先给出原始度量空间中点到序列的距离定义。

**定义 1** 给定原始度量空间中的点  $p$  和点序列  $A = \{a_1, a_2, \dots, a_n\}$ ,  $p$  到  $A$  的距离定义为点  $p$  与  $A$  中所有点间距离的最小值:

$$d(p, A) = \min_{a \in A} d(p, a) \quad (7)$$

由定义 1, 给定原始度量空间中的点集  $P = \{p_1, p_2, \dots, p_m\}$ , 序列  $A$  到点集  $P$  的距离可表示为向量  $A'$ :

$$A' = \{d(p_1, A), d(p_2, A), \dots, d(p_m, A)\} \quad (8)$$

而  $A'$  所在的向量空间即可做为变换的目标向量空间。

**定义 2** 给定原始度量空间中的点集  $P = \{p_1, p_2, \dots, p_m\}$ , 式(8)中的向量  $A'$  定义为点序列  $A$  的映象(image); 映象  $A'$  所在的  $m$  维空间称为目标向量空间(target vector space); 点集  $P$  称为参考点集(reference point set); 目标向量空间中的向量间距离由 Chebyshev 距离计算

$$d'(A', B') = \max_{k \in [1, m]} |A'_k - B'_k| \quad (9)$$

定义 2 给出了一个由原始度量空间至向量空间的变换, 以下定理证明该变换是一个保距变换。

**定理 1** 点序列  $A, B$  在目标向量空间中的 Chebyshev 距离  $d'(A', B')$  与原始度量空间中的 Hausdorff 距离  $H(A, B)$  间有以下关系

$$d'(A', B') \leq H(A, B) \quad (10)$$

为证明定理 1, 首先证明以下引理。

**引理 1** 任意给定原始度量空间中的点  $p$  和点序列  $A, B$ , 则  $p$  到  $A, B$  的距离之差小于  $A, B$  间的 Hausdorff 距离

$$|d(p, B) - d(p, A)| \leq H(A, B) \quad (11)$$

**证明** 不失一般性, 假设  $d(p, A) \leq d(p, B)$

B), 设序列 A 中与点  $p$  距离最小的点为  $a$ , 由式 (7) 可知

$$d(p, A) = d(p, a) \quad (12)$$

设序列 B 中与点  $a$  距离最小的点为  $b$ , 则由式 (5) 可知

$$H(A, B) \geq d(a, b) \quad (13)$$

由式 (7) 可知

$$d(p, B) \leq d(p, b) \quad (14)$$

由三角不等式可知

$$d(p, a) + d(a, b) \geq d(p, b) \quad (15)$$

将式 (12)(13)(14) 代入式 (15) 可得

$$d(p, B) - d(p, A) \leq H(A, B)$$

同理可证  $d(p, B) < d(p, A)$  情况。命题得证。

图 1 为引理 1 在二维 Euclidean 空间内的证明过程示例。由式 (8)、式 (9) 和引理 1 易知定理 1 成立。以下定理表明, 若参考点集包含各点序列中的所有点, 则点序列在目标向量空间中的距离与在原始度量空间中的距离相等。




图 1 二维空间中引理 1 证明过程示例

Fig. 1 Proof of Lemma 1 in 2-dimensional space

**定理 2** 若参考点集 P 包含原始度量空间内点序列 A、B 中的所有点, 则 A、B 的 Hausdorff 距离  $H(A, B)$  与其在目标向量空间的 Chebyshev 距离  $d'(A', B')$  之间有下式成立

$$d'(A', B') = H(A, B) \quad (16)$$

### 2.2 参考点集选择与变换算法

由定理 2 可知, 以轨迹数据集中的流矢量集合做为参考点集, 可以将所有轨迹映射到目标向量空间, 且变换后任意两轨迹间距离保持不变。对轨迹的分类问题也就可以转化为目标向量空间中的聚类问题<sup>[15]</sup>。然而, 轨迹数据集中的流矢量数量巨大, 用所有流矢量做为参考点集同样需要很大的计算量。而由定理 1 可知, 使用部分流矢量组成的参考点集仍然可以定义一个保距变换,

实现对轨迹间 Hausdorff 距离的近似。

在轨迹数据集中选择出现最频繁的  $m$  个流矢量模式做为参考点集, 实现对轨迹相似性的近似测量。频繁出现的流矢量模式通过对所有流矢量进行模糊 C 均值聚类获得。流矢量模式数  $m$  可以任意选择, 较大的  $m$  可使测量结果更接近实际值, 但也会使计算量增大。目标向量空间中的轨迹相似性测量算法(简称为 VCS 算法)步骤如下:

(1) 对轨迹集合  $T = \{t_1, \dots, t_n\}$  中的每条轨迹  $t_i$ , 由式 (3)、式 (4) 计算其对应的流矢量序列  $F_i$ 。

(2) 对所有流矢量序列中的流矢量进行模糊 C 均值聚类, 将获得的  $m$  个流矢量模式做为参考点集。

(3) 对每个流矢量序列  $F_i$ , 由式 (7) 计算  $F_i$  到各参考点的距离。

(4) 由式 (8) 计算各流矢量序列在目标向量空间的映射。

(5) 将式 (9) 计算得到的映射间距离做为对应轨迹之间的距离。

以式 (9) 定义的 Chebyshev 距离代替式 (6) 中的  $H(F_i, F_j)$ , 即可在目标向量空间对所有轨迹映射进行谱聚类。

在 VCS 算法中, 对长度为  $u$  的轨迹, 变换到向量空间所需的计算复杂度为  $O(mu)$ ,  $m$  为参考点集大小; 向量空间中轨迹间距离的计算复杂度仅为  $O(m)$ , 可见 VCS 算法的计算量远小于 MDHS 算法。另外, 由于 VCS 算法使用频繁流矢量模式做为参考点集, 在空间转换过程中减弱了轨迹中异常点的影响, 有利于提高轨迹分类的准确率。

## 3 实验结果与分析

本节对提出的运动目标轨迹分类算法进行实验分析。测试序列为户外实际场景的监控记录, 来自 i-Lids(AVSS 2007) 数据集。目标运动轨迹由二维目标跟踪算法对运动目标跟踪获得。数据集中仅包含车辆的运动轨迹, 共 246 条。样本轨迹经过平滑后如图 2(a) 所示。

在实验过程中, 为与提出的 MDHS 和 VCS 算法进行对比, 还实现了 WTHS、SPHS 和 PWEU 算法进行轨迹相似性测量。表 1 给出了上述算法的详细描述。在对轨迹进行分类时, 使用凝聚层次聚类(简称为 HC 算法)与提出的基于谱聚类的轨迹分类算法(SC 算法)进行对比。

表 1 轨迹相似性测量算法描述

Table 1 Trajectory similarity measure algorithms		
相似性测量算法	轨迹描述	距离函数
MDHS	流矢量序列(式(4))	Hausdorff
VCS	目标向量空间坐标(式(8))	Chebyshev
WTHS	二维点坐标序列(式(1))+ 二维运动方向序列(式(2))	各自 Hausdorff 距离的加权和
SPHS	二维点坐标序列(式(1))	Hausdorff
PWEU	二维点坐标序列(式(1))	Euclidean

本文使用聚类时间和聚类准确率来衡量聚类算法的有效性。实验分析的数据均为 5 次实验结果的平均值。与文献[7]类似,设通过轨迹聚类算法获得的簇集合为 C,共包含 M 个簇;轨迹数据集实际的簇集合为 G。则对任何一个簇  $c_i \in C$ ,在 G 中对应的簇  $g_m \in G$  可以通过  $\arg \max_j |c_i \cap g_j|$  获得。因此,聚类准确率  $\alpha$  可定义为轨迹数据集被正确分类的比率

$$\alpha = \frac{1}{N} \sum_{i=1}^M p_i$$

式中:N 为数据集中的轨迹数; $p_i$  为第 i 个簇中被正确分类的轨迹数,表示为

$$p_i = \begin{cases} 0, & \exists c_k \in C, |c_k \cap g_m| > |c_i \cap g_m| \\ |c_i \cap g_m|, & otherwise \end{cases}$$


$$m = \arg \max_j |c_i \cap g_j|$$

### 3.1 算法性能分析


图 2 给出了部分轨迹相似性测量和聚类算法的聚类结果。由图可见,MDHS+SC 算法的聚类结果更符合视觉分类;PWEU+SC 算法未能区分出图中自左上方至右下方的轨迹(对应图 2(b)中蓝色的轨迹);MDHS+HC 和 WTHS+SC 算法则将自左上方至右下方的轨迹和部分自上而下的轨迹(对应图 2(b)中绿色的轨迹)归为一类;SPHS+SC 算法则未能区分出图上方相反方向运动的两类目标轨迹(对应图 2(b)中紫色和深黄色的轨迹)。




(a) Trajectory Dataset




(b) MDHS+SC




(c) MDHS+HC



(d) PWEU+SC



(e) WTHS+SC



(f) SPHS+SC

图 2 轨迹聚类结果比较

Fig. 2 Comparison of the trajectory clustering results

图 3 比较了不同轨迹相似性测量和聚类算法的聚类准确率。图中左侧 6 种算法使用原始轨迹描述进行轨迹相似性测量,右侧 2 种算法使用映射后的向量空间坐标进行轨迹相似性测量,其中参考点集大小设为 20。比较图 3 中左侧 6 种算法可见,本文提出的 MDHS+SC 算法的聚类准确率最高,这与图 2 所示结果一致;WTHS+SC 算法考虑了运动方向信息,准确率高于 PWEU+SC 算法;而 SPHS+SC 算法由于不能识别形状相同、方向不同的轨迹,准确率最低。分别比较图 3 中 MDHS+SC 和 VCS+SC 以及 MDHS+HC 和 VCS+HC 算法可见,使用 VCS

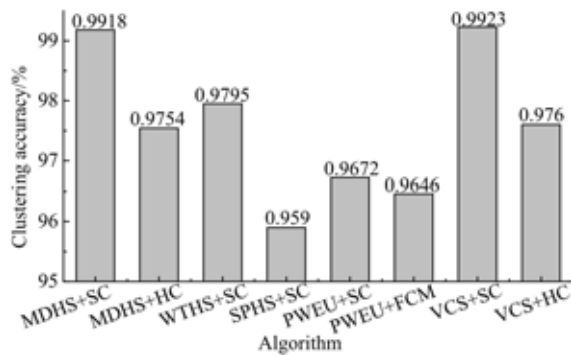


图 3 轨迹聚类准确率比较

Fig. 3 Comparison of the trajectory clustering accuracy of the two algorithms. Since the two algorithms are less affected by abnormal points in the trajectory, the clustering accuracy is slightly improved. Figure 4 compares the clustering time of different trajectory similarity measurement and clustering algorithms. The algorithm in Figure 4 corresponds to the algorithm in Figure 3. Comparing the six algorithms using original trajectory description for similarity measurement, it can be seen that using Hausdorff distance for trajectory clustering takes about 100 times longer than using Euclidean distance. Comparing the two algorithms on the right side of Figure 4, it can be seen that mapping to the vector space after the clustering algorithm reduces the time cost by about 100 times, and is close to the computational complexity of the PWEU+SC algorithm.

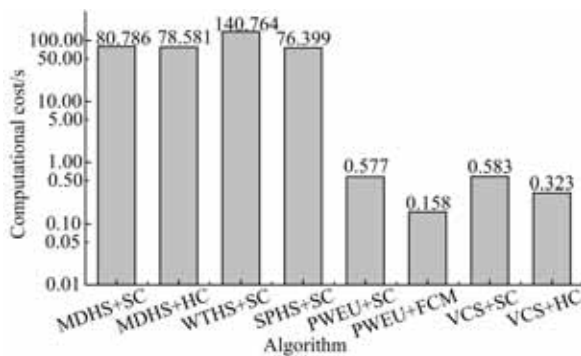


图 4 轨迹聚类时间比较

Fig. 4 Comparison of the trajectory clustering cost

### 3.2 参考点集和数据集规模的影响分析

图 5 给出了 VCS+SC 和 VCS+HC 算法的聚类准确率随参考点集大小的变化曲线。由图可见,使用谱聚类比使用凝聚层次聚类的准确率更高,这与 3.1 节的结论相同。两算法的聚类准确率随参考点集大小的增加而迅速增大。当参考点数大于 8 后,聚类准确率即趋于稳定。可见,提出的算法使用较少的参考点即可实现较高的聚类准确率。图 6 给出了五种轨迹聚类算法的聚类准确率随数据集规模的变化曲线。不同规模的数据集通过在轨迹数据集中随机采样获得。由图可见,各算法的聚类准确率随数据集规模的增加而增大。当数据集中的轨迹数超过 160 后,聚类准确率趋于稳定。在不同的数据集规模下,提出的 MDHS+SC 和 VCS+SC 算法均可达到比试验中其他算法更高的聚类准确率。

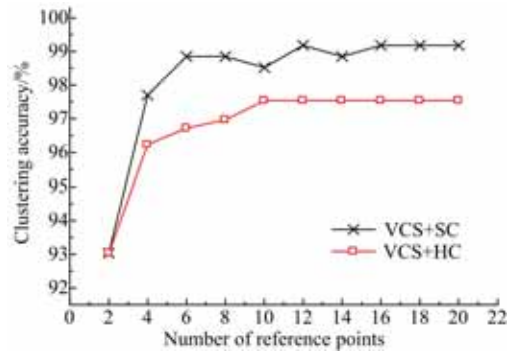


图 5 参考点集大小对聚类准确率的影响

Fig. 5 Clustering accuracy vs. the number of reference points for difference clustering algorithms




图 6 数据集规模对聚类准确率的影响

Fig. 6 Clustering accuracy vs. the number of sampled trajectories for difference clustering algorithms

## 4 结束语

提出了一种基于多维 Hausdorff 距离的运动目标轨迹相似性测量算法,并使用谱聚类实现轨

迹分类。为降低计算复杂度,还提出了一种轨迹保距变换对相似性测量算法进行优化。实验表明,提出的算法可达到更高的聚类准确率、显著降低了分类过程的时间复杂度。

#### 参考文献:

- [ 1 ] Hu Wei-ming, Tan Tie-niu, Wang Liang, et al. A survey on visual surveillance of object motion and behaviors[J]. IEEE Transactions on Systems, Man and Cybernetics, Part C: Applications and Reviews, 2004, 34(3): 334-352.
- [ 2 ] Valera M, Velastin S A. Intelligent distributed surveillance systems: A review[C]// Proceedings of the Vision, Image and Signal Processing, 2005: 192-204.
- [ 3 ] Fu Zhou-yu, Hu Wei-ming, Tan Tieniu. Similarity based vehicle trajectory clustering and anomaly detection[C]// Proceedings of the IEEE International Conference on Image Processing, 2005: 602-605.
- [ 4 ] Keogh E J, Pazzani M J. Scaling up dynamic time warping for data mining application[C]// Proceedings of the 6th International Conference on Knowledge Discovery and Data Mining, 2000: 285-289.
- [ 5 ] Porikli F. Trajectory distance metric using Hidden Markov model based representation[C]// Proceedings of the IEEE European Conference on Computer Vision (ECCV), 2004: 1-8.
- [ 6 ] Fashandi H, Moghaddam A M E. A new rotation invariant similarity measure for trajectories[C]// Proceedings of the IEEE International Symposium on Computational Intelligence in Robotics and Automation, 2005: 631-634.
- [ 7 ] Zhang Z, Huang K Q, Tan T N. Comparison of similarity measures for trajectory clustering in outdoor surveillance scenes[C]// Proceedings of the 18th International Conference on Pattern Recognition, 2006: 1135-1138.
- [ 8 ] Lou Jian-guang, Liu Qi-feng, Tan Tie-niu, et al. Semantic interpretation of object activities in a surveillance system[C]// Proceedings of the 16th International Conference on Pattern Recognition (ICPR02), 2002: 777-780.
- [ 9 ] Junejo I N, Javed O, Shah M. Multi feature path modeling for video surveillance[C]// Proceedings of the Pattern Recognition, 17th International Conference on (ICPR04), 2004: 716-719.
- [ 10 ] Khalid S, Naftel A. Evaluation of matching metrics for trajectory-based indexing and retrieval of video clips [C]// Proceedings of the Seventh IEEE Workshops on Application of Computer Vision (WACV/MOTION05), 2005: 242-249.
- [ 11 ] Johnson N, Hogg D. Learning the distribution of object trajectories for event recognition[J]. Image Vision Computing, 1996, 14(8): 609-615.
- [ 12 ] Andrew Y N, Michael I J, Yair W. On spectral clustering: analysis and an algorithm[C]// Proceedings of the Advances in Neural Information Processing Systems, 2002.
- [ 13 ] Zelnik L, Perona P. Self-tuning spectral clustering [C]// Proceedings of the Advances in Neural Information Processing Systems, 2004.
- [ 14 ] Ganti V, Ramakrishnan R, Gehrke J, et al. Clustering large datasets in arbitrary metric spaces[C]// Proceedings of the 15th International Conference on Data Engineering, 1999: 502.
- [ 15 ] Faloutsos C, Lin K I. FastMap: a fast algorithm for indexing, data-mining and visualization of traditional and multimedia datasets [C] // Proceedings of the 1995 ACM SIGMOD International Conference on Management of Data, 1995: 163-174.