

文章编号:1001-2486(2011)05-0103-07

基于运动相似性的监控轨迹聚合分析*

梁浩哲,黄魁华,李国辉,张军

(国防科技大学 信息系统工程重点实验室,湖南 长沙 410073)

摘要:对于监控轨迹序列集,提出一种使用运动特征发现其潜在语义内容的方法。在特征统计估计阶段,将轨迹曲线中的拐点特征加入到核密度估计过程中,得到准确平滑的方向多性态分布;使用隐马尔科夫模型估计轨迹子类中存在的串行或并行空间模式。最后以运动特征分布为基础,提出一种基于运动相似性的轨迹层次聚合模型。实验结果表明,该模型可以有效地分析轨迹序列集的潜在结构,反映了场景中存在的运动区域信息。

关键词:轨迹聚合;核密度估计;隐马尔科夫模型;视频监控;

中图分类号:TP391 **文献标识码:**A

Aggregation Analysis of Surveillance Trajectory Based on Motion Similarity

LIANG Hao-zhe, HUANG Kui-hua, LI Guo-hui, Zhang Jun

(Science and Technology on Information Systems Engineering Laboratory, National Univ. of Defense Technology, Changsha 410073, China)

Abstract: For surveillance trajectory, a potential semantic content discovering method based on motion features was investigated. In the phase of feature estimation, precise and smooth multi-modal distribution of direction was obtained by combining inflection points of trajectory curve with the kernel density estimation. Then sequential and concurrent temporal patterns of trajectory sub-class were modeled by Hidden Markov Model. With motion feature distribution, a hierarchical trajectory aggregation model based on motion similarity was proposed. Experimental results show that the model can be used to discover potential structure of trajectory set which reflect the motion region information of surveillance scene.

Key words: trajectory aggregation; kernel density estimation; hidden Markov model; visual surveillance

在视觉监控过程中,受场景上下文约束,轨迹序列间存在较强的特征关联。视觉运动是反映轨迹时空演化的重要线索,针对运动特征的轨迹分析,可获得诸如运动起始区域、运动空间分布等高层语义知识,进而提高检测的初始化精度,推理跟踪中受遮挡、亮度变化或图像噪声影响产生的轨迹片段间的一致性^[1-2]。

统计轨迹分析可降低底层数据中存在的噪声影响,与传统的欧式空间分析相比,有较强的鲁棒性,主要包括特征分布估计与轨迹模式识别两部分^[3-6]。Wang 结合运动目标的尺寸、方向识别场景布局,在关键点通过趋势密度估计判别进出区域^[3];Saleemi 使用核密度估计轨迹模式的重要运动参数,建立特征的统计分布模型^[5];Bicego 使用森林隐马尔科夫模型刻画像素时空状态,识别静态背景序列群与运动时空序列群间的关联^[6]。

目前研究较多直接利用高斯或混合高斯刻画运动特征分布。对于远景监控中的平稳轨迹序列,仅用单态型分布可满足尺寸等近刚体特征的估计精度,但不能刻画运动方向在演化过程中的多主方向特性,混合分布同样需设定组件个数,同时简单分布的单一分布形状也不适合描述轨迹的有向空间拓扑延续。为克服以上缺点,本文使用核密度估计方向分布,根据轨迹拐点自适应地改善核密度估计精度;其次,使用隐马尔科夫模型(Hidden Markov Model,以下简称 HMM)拟合了轨迹序列的运动空间;最后提出一种层次轨迹聚合模型,实验结果验证了模型的有效性。

1 运动特征估计

本文集中研究远景监控下平稳轨迹序列的多性态方向分布估计与空间拓扑估计方法,针对轨

* 收稿日期:2011-05-06

基金项目:国家自然科学基金资助项目(60902093);国防科技大学优秀研究生创新基金资助项目(S080501)

作者简介:梁浩哲(1983—),男,博士生。

迹序列 $T_i = \{S_i\}$, 定义运动矢量为 $S_i = \{x, y, u, v\}$, (u, v) 为方向分量, (x, y) 为位置分量, 特征估计方法分为两部分: 结合轨迹拐点的 Von Mises 核密度方向估计; 基于 HMM 的运动空间拓扑估计。

1.1 Von Mises 核密度估计

Von Mises 分布(以下简称 VM 分布)用于描述方向随机量分布, 可视为单位圆上的高斯分布, 存在单个局部峰值^[7]。对于轨迹 T_i , 其角度样本集 a 可能存在多个主方向, 如图 1(a) 所示, 拐点 G 将轨迹分割为不同的主方向, 因此单峰的 VM 分布不能表达实际分布。文献[8]使用 VM 混合模型(Von Mises Mixture Model, 以下简称 VMM)拟合多向分布, 但需要手动定义组件数; 小样本量时, 由于对参数量增长的惩罚值过高, BIC 准则下的模型选择也存在欠拟合问题^[6]。VM 核密度估计根据样本值自适应地估计多主方向分布, 其估计式为^[7]

$$p(\hat{a}) = \frac{1}{N_k} \sum_{n=1}^{N_k} \frac{1}{2\pi I_0(k)} e^{k \cos(a-a_n)} \quad (1)$$

N_k 为样本量, a_n 为角度样本, k 为精度参数, $I_0(\cdot)$ 为修正的零阶贝塞尔函数。 k 等价于核密度估计中的窗宽参数, k 值越大, 估计窗宽越小, 采样点的贡献越大。

1.2 基于轨迹拐点的主方向数量估计

充足样本量时, VM 核密度估计在大 k 值下可提供准确平滑的方向估计: 准确代表正确的局部峰值数量, 平滑表示分布具有良好的性态。当 k 趋于无穷小时, 估计式(1)收敛到真实分布^[7]。由于单帧检测跟踪存在误差, 需对轨迹 T_i 进行平均采样, 提高特征质量, 如式(2)所示:

$$(x'_i, y'_i, u'_i, v'_i) = \frac{1}{h} \sum_{i=1+h}^{h+h} (x_i, y_i, u_i, v_i) \quad (2)$$

本文设定 $h = 8$, 即平均每 8 帧为一特征点。式(2)在降低噪声影响的同时会减少特征样本量, 进而影响 VM 核密度估计精度。在有限样本的情况下, k 值增长导致分布局部尖锐化, 不满足平滑条件; k 值过小会使分布过于平滑, 影响估计准确性(如图 1(c) 所示)。对窗宽值的最优估计多采用变窗宽思想, 通过计算单样本的个体窗宽值, 达到分布最优估计, 此类方法具有较高的计算复杂度^[9-10]。

为了得到准确平滑的多方向分布, 本文利用简单的曲线几何原理计算主方向数量。方向分布

的局部峰值有明显的几何意义: 路径拐点造成主方向变化(如图 1(a) 所示)。从中得到启发, 利用拐点量可近似计算运动主方向数量。对于平面曲线: $C = (x, y)$, 曲率 K 表示其弯曲度(如图 1(b) 所示)。表 1 给出了算法 1: 基于轨迹拐点的主方向数量估计。

表 1 算法 1: 基于轨迹拐点的主方向数量估计

Tab. 1 Algorithm 1: Dominant direction number estimator of pdf based on geometric inflection points

| | |
|--------|---|
| Step 1 | 对轨迹 T_i , 插值平滑得其空间曲线 C_i 。 |
| Step 2 | 计算 C_i 的曲率集 $K_i = \{kc_1, kc_2, \dots, kc_n\}$, 其中 kc_i 为曲率采样点; 计算曲率局部极值点, 其数量为 N_K 。 |
| Step 3 | 首先保证分布准确性, 使用大 k 值进行核密度估计分布函数 P ; 由于窗宽较小, 分布可能存在局部尖点。 |
| Step 4 | 为满足平滑条件, 进入循环步: 计算 P 函数的局部极值点, 数量为 P_k , 如果 $P_k = N_K + 1$, 则终止。 否则, 转入 Step 3, 降低 k 值, 增加估计窗宽。 |

其中, K 值计算公式: $kc = \frac{|x'y'' - x''y'|}{(x' + y')^{3/2}}$, 曲率与分布局部极值满足条件 $\frac{d_K}{d_n} \approx 0, \frac{d_p}{d_k} \approx 0$ 。

1.3 轨迹空间拓扑估计

轨迹 T_i 空间有向序列表示为 $\{\vec{X}_i\}$, $\vec{X}_i = (\vec{x}_i, \vec{y}_i)$, (\vec{x}_i, \vec{y}_i) 为位置分量, 对轨迹空间估计需刻画其拓扑延续性。HMM 是一种序列分析方法, 包含一个马尔科夫隐状态链, 隐状态根据某分布产生可见观察, 通过观察链可对隐状态链的统计分布进行推理^[11-12]。针对轨迹样本集 $T = \{T_i\}$, 本文给出基于 HMM 的轨迹空间估计方法如下:

步骤 1 使用样本集 T 训练其 HMM 的运动参数, 利用有向观察分布描述轨迹运动空间。HMM 结构为(如图 2(a) 所示): 状态集 $S = \{s_1, s_2, \dots, s_n\}$, 定义 $n = 3$, 状态变量为 q , 观察变量 $o = (x, y)$, 一般假设观察为高斯分布^[11], 其概率密度函数为: $p = (\sqrt{2\pi}|\sigma_j|^2)^{-1} e^{-\frac{(o-\mu_j)^2}{2|\sigma_j|^2}}$, μ_j 为均值矢量, σ_j 为协方差阵, 它们反映了轨迹集的有向空间中心与离散度(如图 2(b) 二维正态圆所示)。

步骤 2 由于 HMM 仅能表示串行结构, 为克服此局限性, 使用 k-means 进一步分裂观察分布

p , 会发现轨迹集 T 中存在的并行结构(如图 2(b) 所示), 具体计算过程见算法 2(Step 2)。

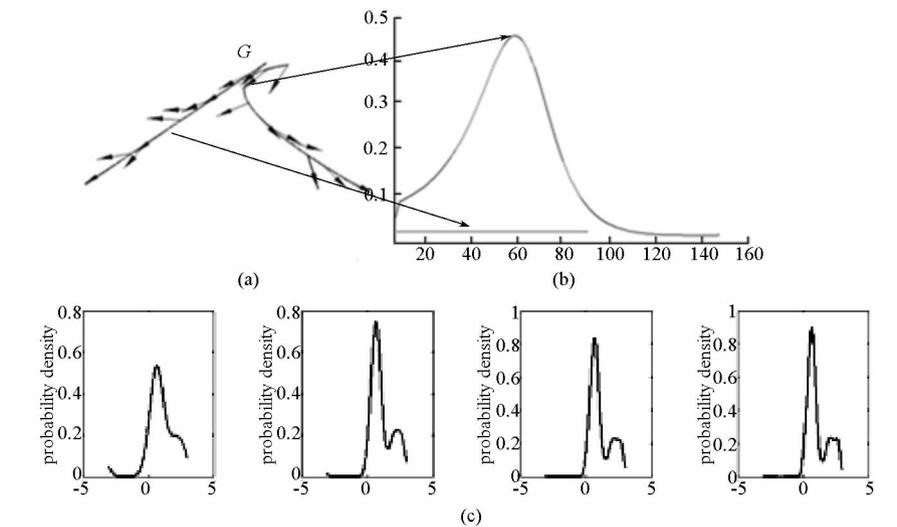


图 1 运动方向分布估计图。(a) 原始轨迹,(b) 曲率值曲线,(c) 窗宽 k 影响,从左至右 k 依次增强,其中, 2 或者 3 为较为精确的核密度估计子,1 过于平滑,分布不准确,4 核密度估计存在局部尖点,不满足平滑条件。

Fig.1 Motion direction estimation. (a) Original Trajectory, (b) Curvature Curve. (c) Concentration Parameter k Analysis: from left to right, value of k increase; 1 is too flat and 4 is too spiky when 2 and 3 is the approximate optimal estimator.

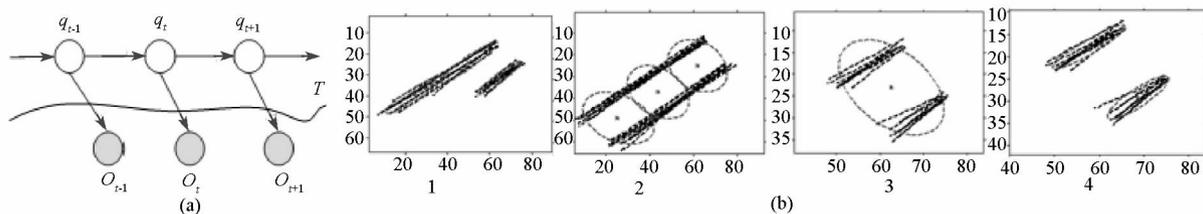


图 2 基于 HMM 的轨迹空间拓扑估计。(a) 基于 HMM 的轨迹序列演化;(b) 1:HMM 最优估计可表达轨迹的串行结构; 2:HMM 空间估计不能准确表达并行轨迹;3,4:对每一观察分布,使用 k -means 聚类得到并行的高斯观察。

Fig 2 Spatial variance estimation of trajectory based on HMM. (a) HMM structure of T . (b) According to 1 and 2; sequential HMM can not estimate the concurrent structure of trajectory; As seen in 3 and 4, using k -means clustering to partition every Gaussian.

2 基于运动相似性的轨迹聚合模型

监控上下文可定义为对场景运动的产生与演化相关联的关键区域,例如路径与起始点等,在其约束下,轨迹的运动特征存在较强的关联性^[3],由此假设出发,本文提出一种基于运动相似性的轨迹聚合模型。

2.1 运动方向分布相似度

对于轨迹集 $T = \{T_i\}$,使用算法 1 估计轨迹样本 T_i 的方向分布集为 $P = \{p_1, p_2, \dots, p_n\}$, n 为轨迹量。 (p_i, p_j) 可描述 (T_i, T_j) 间的方向相似度:样本自然 log 似然值 $p_{ij} = \ln(p(a_j | p_i))$ 度量 T_j 的样本 a_j 服从分布 p_i 的可能性^[12],定义基于统计分布的轨迹方向相似度为

$$ds(i, j) = \frac{1}{n_j} \sum_{j=1}^{n_j} \ln(p(a_j | p_i)) \quad (3)$$

n_j 为 T_j 的样本量,式(3)度量 T_i, T_j 间方向同分布的可能性。基于式(3)给出对称相似度为

$$\begin{aligned} s(i, j) &= \frac{1}{2} (ds(i, j) + ds(j, i)) \\ &= \frac{1}{2} \left(\frac{1}{n_i} \sum \ln(p(a_i | p_j)) + \frac{1}{n_j} \sum \ln(p(a_j | p_i)) \right) \end{aligned} \quad (4)$$

2.2 基于运动相似性的层次轨迹聚合算法

由于 VM 核密度估计精度与样本量相关,基于相似矩阵进行单步式聚类会受到噪声影响,因此本文提出一种基于运动相似性的层次轨迹聚合算法,可分为两步:基于方向分布的轨迹聚类;轨迹空间融合(如表 2 所示)。

在算法 2 中, $\text{kernel}()$ 表示 VM 核密度估计算子; $P \rightarrow AP$ 表示根据式(4)计算轨迹样本的方向

相似矩阵;length()为轨迹长度函数,定义 $t_{length1}$ 为噪声轨迹长度阈值,降低由于光照变化与遮挡等问题造成的短轨迹片段对聚合精度的影响,本文使用 $t_{length1} \geq 20$; $t_{length2}$ 为轨迹充分采样量阈值:当采样量 $\leq t_{length2}$ 时,将轨迹样本 (T_i, T_j) 合并,重新估计概率密度,提高估计精度;当采样量 $\geq t_{length2}$

时,可认为估计精度与窗宽参数关联较低,使用长轨迹的分布为聚类中心分布。Terminal 为终止条件。在步骤 2 的 *k-means* 聚类中,为对相似方向轨迹的并行路径进行识别,设定类数为 2,根据距离阈值 t_d 判断聚类中心是否为并行关系。

表 2 算法 2:基于运动相似的层次轨迹聚合法

Tab. 2 Algorithm 2: Hierarchical trajectory-aggregation based on motion similarity

| | |
|-----------------------|---|
| Initialization: | 轨迹预处理,噪声轨迹筛选: $(\text{length}(T) > t_{length1}) \rightarrow (T' := \{T_1, T_2, \dots, T_m\}, m < n)$ 。 kernel(T') $\rightarrow P := \{p_1, p_2, \dots, p_m\}$, 初始化类个数 $class_number \leftarrow n, id_i \leftarrow i$, 对 T' 使用相似测度 $s(i, j)$, 计算相似矩阵 $P \rightarrow AP := \text{Affinity}(P)$, 轨迹类号向量: $id = \{id_1, id_2, \dots, id_m\} = \{1, 2, \dots, m\}$ |
| Step 1 clustering: | 层次运动方向分布集聚类: 进入循环: 寻找最大相似性轨迹对, $[i, j] = \text{find_Max}(AP)$ 。 更改 (T_i, T_j) 类号为, $(id_i, id_j) = b = \min(i, j), c = \max(i, j)$, 判断 (T_i, T_j) 长度是否达到充分采样量: $\text{length}(T_{id_i}) < t_{length2}$ 并且 $\text{length}(T_{id_j}) < t_{length2}$ 1) 为真时合并轨迹: $T_b = \{\text{unique}(T_i), \text{unique}(T_j)\}$, 重新进行 $p_c \leftarrow \text{kernel}(T_c)$ 2) 否则使用更新中心轨迹为较长轨迹,使用长轨迹分布为类心分布。 $T_{id_i} = \max(\text{length}(T_i), \text{length}(T_j)), p_{id_i} \leftarrow p_b$ 形成新的轨迹样本集: $T' \leftarrow T' - T_c; P \leftarrow P - p_c$; 降低类个数: $class_number = class_number - 1$; 相似矩阵计算: $P \rightarrow AP := \text{Affinity}(P)$ 针对 AP , 如果 $\text{Terminal}(AP) = \text{true}$ 终止; 归一化 $id := \{id_1, id_2, \dots, id_m\}$ 至范围 $[1, \text{unique}(id)]$; 对 $t_{length1}$ 阈值筛除掉轨迹使用类心分布,进行极大似然分类: $id[m + 1 \rightarrow n] = \text{classify}(T - T')$; 形成轨迹类号 $id = id \cup id[m + 1 \rightarrow n]$; 否则转入循环步。 |
| Step 2 fusion: | 基于 HMM 的轨迹空间拓扑散度估计: 对 $id := \{id_1, id_2, \dots, id_n\}$, 形成轨迹子类 $c := \{c_1, c_2, \dots, c_k\}$, 其中, $c_i := \{T'_1, T'_2, \dots, T'_l \in T\}$ 。 循环: 对每一 c_i , 训练其 HMM 模型, 输出观察分布 $\{b_1^i, b_2^i, b_3^i\}$ 。 对每一 $b_j^i (1 < j < 3)$: 计算极大似然轨迹点集, 对其进行 <i>k-means</i> 聚类, 定义类数为 2, 计算类中心点 (p_1, p_2) 距离 $d(p_1, p_2)$, 若 $d > t_d, t_d$ 为并行轨迹距离阈值, 则使用高斯分布 b_{p1}, b_{p2} 代替 b_j^i , 描述轨迹空间分布。 |

Terminal 定义为: 每一子类 c_i , 对其 p_i 计算 3 个峰值向量 $\mu_i = \{\mu_1^i, \mu_2^i, \mu_3^i\}$, 即本文假设 c_i 场景中路径的拐点数为 2, 计算:

$$D(c_i, c_j) = \min(|\mu_i^k - \mu_j^k|, l, k \in (1, 2, 3)), \quad \forall c_i, \forall c_j \quad (5)$$

式(5)求解轨迹子类 (c_i, c_j) 之间的最小夹角, 终止条件为

$$\text{Terminal}(AP) = \begin{cases} 1, & D(c_i, c_j) > t_{angle} \\ 0, & \text{else} \end{cases}$$

t_{angle} 为方向差异阈值。在实验中, $t_{angle} \in [\pi/10,$

$\pi/8]$ 会产生相似结果, 此值也是视觉角度差异的理想取值^[8]。

3 实验结果与分析

本文使用户外远景图像序列测试轨迹聚合模型, 帧速为 15 帧/s, 图像分辨率为 320 × 240。使用基于自适应 GMM 背景模型、粒子滤波器的多目标检测跟踪系统 Smart Video^[13-14] 收集轨迹样本集(如图 3 所示)。工作区间为 7:30AM 至 9:30AM。视频中运动在此区间中有潜在规律性, 轨迹量为 500; 为集中测试本文提出算法, 搭建的实

验环境中运动目标的尺寸速率等近似刚体的平稳特征量并不具备强分离性,可用简单分布刻画其特征,实验过程中省略其估计过程(如图 3 所示)。

3.1 模型阈值分析

算法 2 精度影响因素主要包括两方面:算法 1 中利用曲率极值数量 N_k 计算分布峰值量 P_k 的有效性;算法 2 中的循环估计在提高精度的同时会增加计算量,需要合适的阈值参数 $t_{length2}$ 。

针对前一问题,观察轨迹样本的曲率曲线。如图 4(a)所示,轨迹 T_i 经过插值平滑处理后具备明显的几何特征形态;在图 4(b)中,给出 T_i 的曲率 $K_i = \{kc_1, kc_2, \dots, kc_n\}$ 曲线,由于平滑效果,轨迹曲线出现了较小的局部峰值点(如图 4(a)中的 G' 点)。在具体执行算法 1 时,使用阈值 t_k 过滤

曲率峰值:

$$N_k = \text{maxima}(K'_i = (K_i > t_k)),$$

$\text{maxima}(\cdot)$ 为曲率极值数量算子。

本文使用 $t_k = 0.02$ (如图 2(b) 二维正态圆所示)。

针对后一问题, $t_{length2}$ 值与样本量相关。如图 4(c)所示,小样本且 k 值较大时,分布的平滑性较差,执行算法 1 将概率密度曲线逐步改善到双峰性态,得到与大样本估计相似的真实分布;随样本量 n 增加,窗宽参数值与估计精度相关性降低,如图 4(c)所示,在 $n = 100, 200$ 的情况下,大 k 值下会获得稳定的多方向分布;在实验中使用 $t_{length2} = 200$ 作为轨迹充分样本量阈值。



图 3 (a) 原始帧 (b) 目标检测 (c) 自适应 Gaussian 背景 (d) 目标跟踪 (e) 部分轨迹样本
Fig.3 (a) original frame (b) motion detection (c) adaptive Gaussian background (d) motion tracking (e) samples of trajectory

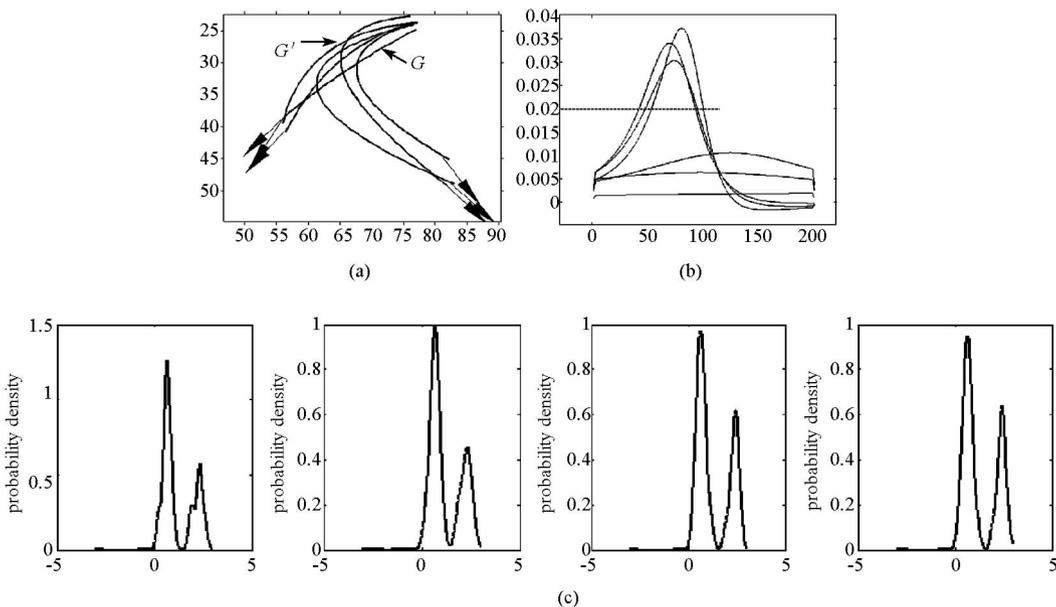


图 4 阈值分析。(a) 原始轨迹曲线;(b) 曲率值及阈值曲线;(c) 从左至右依次为:
 $n = 25, k = 50; n = 25, k = 30; n = 100, k = 50; n = 200, k = 50$; n 为样本量, k 为分布聚集度

Fig.4 Thresholds analysis. (a) Original Tracks; (b) Curvature curve and threshold; (c) From left to right:
 $n = 25, k = 50; n = 25, k = 30; n = 100, k = 50; n = 200, k = 50$; n : number of samples; k : concentration parametre.

3.2 基于方向分布的相似性轨迹聚类

针对实验监控场景中的样本集 $T = \{T_i\}$ (如

图 3 所示),执行算法 2(Step 1),聚类结果为 5 类运动轨迹 $c = \{c_1, c_2, c_3, c_4, c_5\}$,图 5(a) 为聚类中心分布集 $p = \{p_{c_1}, p_{c_2}, p_{c_3}, p_{c_4}, p_{c_5}\}$;图 5(b) 显示了

极坐标系下的方向均值, 值域为 $[0, 360]$; 表 3 为分布参数估计值; $c = \{c_1, c_2, c_3, c_4, c_5\}$ 具备明显的语义信息, 可通过 5 类语义事件描述轨迹子类: $E = \{E_1, E_2, E_3, E_4, E_5\}$, 其语义描述如表 3 所示。

观察概率密度曲线图 5 (a), 语义事件 E_1, E_2, E_3, E_5 对应的轨迹中不存在强拐点, 分布为单峰值性态, 聚集度参数 k 值相似; 事件 E_4 中存在较大的主方向变化, 具备两个主方向; 使用单峰分

布下有较小的 k 值, 说明 E_4 中方向样本点的发散程度较大, 使用单峰值的方向均值不能描述其真实主方向, 本文使用 **VMM-EM**^[8] 算法估计 E_4 对应的概率密度曲线中两个峰值组件参数, 可看出其均值矢量由类似 (E_2, E_5) 的两个方向构成 (如表 3 所示), 各组件 k 值与其它事件相似。图 5 (c) 给出各轨迹子类可描述语义事件的关键帧。

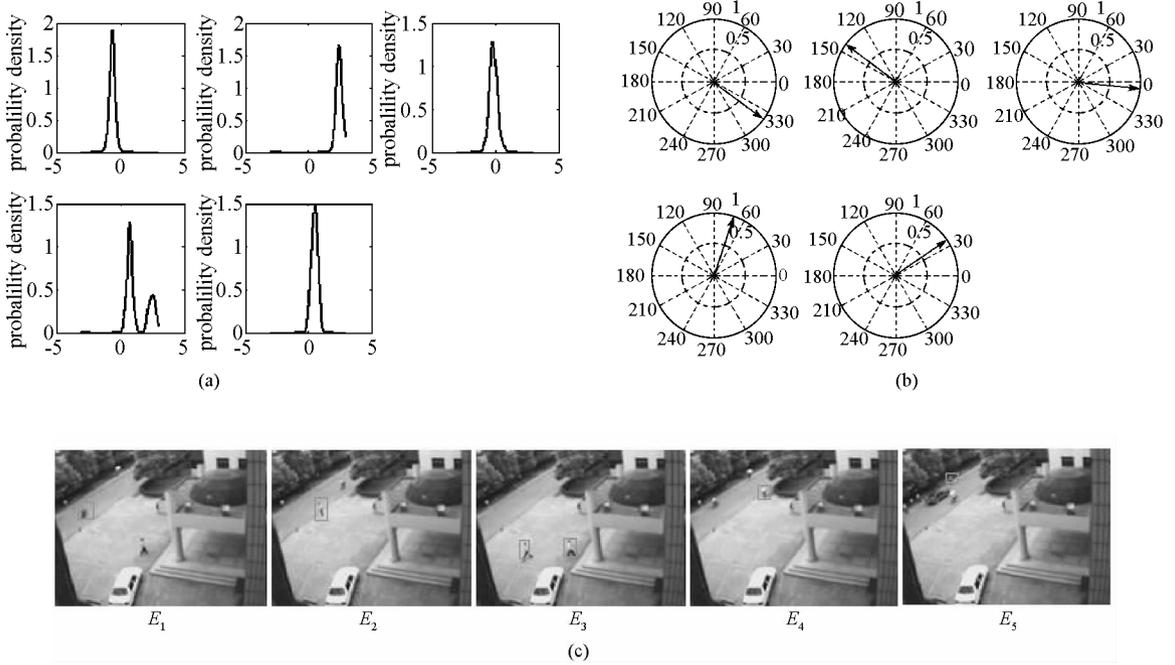


图 5 方向相似聚类结果。(a) 概率密度函数曲线; (b) 方向均值; (c) 语义事件关键帧

Fig. 5 Results of direction clustering. (a) pdf curve; (b) mean of direction variable; (c) key frame of semantic events

表 3 运动事件参数表

Tab. 3 Motion event parameters estimation

| 运动事件 | 均值 & 精度 | 运动事件 | 均值 & 精度 |
|----------------|---|------------------|------------------|
| E_1 : 主道路上行 | -0.6366 & 24.1688 | E_2 : 主道路下行 | 2.5182 & 20.1483 |
| E_3 : 右行人建筑物 | -0.0986 & 17.5377 | E_5 : 树丛直行入建筑物 | 0.5720 & 19.6471 |
| E_4 : 折线入建筑物 | 1.2278 & 2.8644 | | |
| E_4 (VMM-EM) | 均值: [0.6448, 2.5016] 精度: [26.2493, 17.8155] 混合比: [0.6705, 0.3295] | | |

3.3 轨迹空间拓扑估计

针对语义事件集 $E = \{E_1, E_2, E_3, E_4, E_5\}$, 执行算法 2 (Step 2) 估计运动空间拓扑。结果如图 6 所示, E_i 都近似对应于场景中的运动路径, 圆形为各二维正态观察分布; E_1, E_2 对应相似的空间拓扑, 涵盖了场景左上角的主路径; E_3 定义了由场景左下角进入主建筑物的一般路径。 E_4, E_5 所定义路径的空间拓扑散度较小。 E_4 为折线路径, 由主路径右上角延伸入建筑物, 其状态 s_1 定义的

视觉长度与 s_2, s_3 长度之和满足表 3 中的方向混合比, 约为 7:3; 状态 s_1 中存在并行结构, 对其观察分布极大似然空间点的 k -means 聚类结果如图 6 (下) 所示, 得到两条在空间分离性的并行路径; E_5 的状态 s_1 为场景中一个隐藏入口, 如 E_5 中的加深标注, 而在监控图像中很难被监控者发现; 因此, 利用轨迹聚合模型可以发现监控场景中存在的潜在以及隐藏性的运动区域信息。

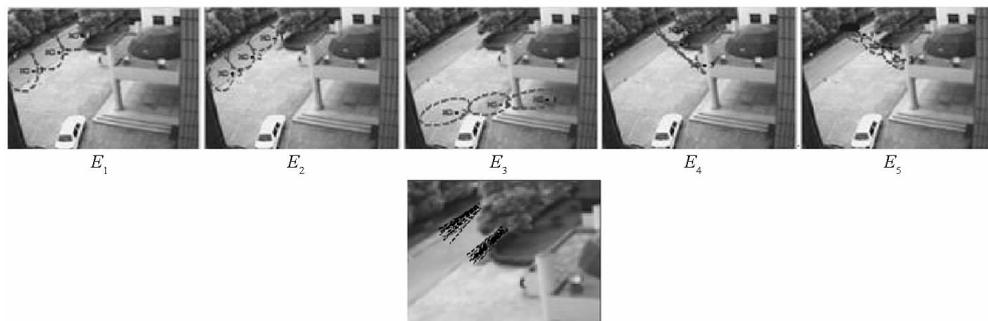


图6 语义事件拓扑估计

Fig.6 Spatial variance estimation of semantic events

4 结论

本文讨论了监控场景中的统计轨迹分析问题。由于简单分布在描述运动多向性上存在局限性,同时并不能有效刻画轨迹序列的有向空间拓扑,因此集中研究了以上两种特征估计方法。使用VM核密度方向估计方法并将轨迹拐点作为一种几何知识加入估计过程,在有限样本下得到准确平滑的多方向分布;在聚合模型中,通过方向分布聚类 and HMM 空间融合得到轨迹集的统计分布。

本文利用监控轨迹样本建立了场景运动规则,以此为基础可进一步深入研究运动规则的监控应用,例如使用轨迹子类HMM产生随机路径,在目标跟踪的同时提供异常运动预测;使用出入口区域加速目标轮廓跟踪的初始化。在未来研究中,将进一步改良轨迹分析方法,使用在线式的增量^[12]轨迹聚合提高整个模型在实时监控中的应用价值。

参考文献:

[1] Turaga P, Chellappa R, Subrahmanian V S, et al. Machine Recognition of Human Activities: A Survey [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2008, 18(11): 1473-1488.

[2] Stauffer C. Estimating Tracking Sources and Sinks [C]// Proceedings of the 2003 Conference on Computer Vision and Pattern Recognition Workshop, Wisconsin: IEEE Computer Society, 2003: 35-42.

[3] Wang X, Ma K T, Gee-Wah N G, et al. Trajectory Analysis and Semantic Region Modeling Using A Nonparametric Bayesian Model [C]//Proceedings of IEEE conference on computer vision and patter recognition. Anchorage: IEEE

Computer Society, 2008, 1-8.

[4] 文军, 吴玲达, 曾璞, 等. 新闻视频中基于“场景词汇”的故事单元相似度分析[J]. 国防科技大学学报, 2009, 31(6): 121-125.

[5] Salleem 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): 1472-1484.

[6] Bicego M, Cristani M, Murino V. Unsupervised Scene Analysis: A Hidden Markov Model Approach [J]. Computer Vision and Image Understanding, 2006, 102(1): 22-41.

[7] Skabar. M. Density Estimation-based Document Categorization using von Mises - Fisher Kernels [C]//International Joint Conference on Neutral Networks, Barcelona: IEEE Computer Society, 2010: 1-8.

[8] Mammassis M, Stewart R W, Thompson J S. Spatial Fading Correlation Model using Mixtures of Von Mises Fisher Distributions [J]. IEEE Transaction on Wireless Communication, 2009, 8(4): 2046-2055.

[9] 于传强, 郭晓松, 张安, 等. 基于估计点的滑动窗宽核密度估计算法[J]. 兵工学报, 2009, 30(2): 615-620.

[10] 李甫, 石光明, 张梨, 等. 应用于光电目标跟踪的变窗宽核粒子滤波[J]. 光学精密工程, 2010, 18(3): 716-722.

[11] Xiang T, Gong S. Beyond Tracking: Modeling Activity and Understanding Behavior [J]. International Journal of Computer Vision, 2006, 67(1): 21-51.

[12] Xiang T, Gong S. Incremental and Adaptive Abnormal Behavior Detection [J]. Computer Vision and Image Understanding, 2008, 111(1): 59-73.

[13] 焦波. 面向智能视频监控的运动目标检测与跟踪方法研究[D]. 长沙: 国防科技大学, 2009.

[14] Stauffer C, Grimson W L. Learning Patterns of Activity using Real - Time Tracking [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(8): 747-757.