

均值漂移算法中的目标模型更新方法研究

沈志熙¹ 杨欣¹ 黄席樾¹

摘要 均值漂移 (Mean shift) 是一种鲁棒的快速模式匹配算法, 但该算法框架下现有的整体模型更新策略不足以对场景中目标外观变化、遮挡等情况进行有效处理. 为此, 本文提出了一种 Mean shift 框架下的选择性子模型更新策略, 将特征模型中的每个分量作为单独个体, 基于每个分量的匹配贡献度, 分别选择当前帧中需要更新的子模型分量及其更新权值. 实验结果表明本文算法具有比整体模型更新策略更好的跟踪鲁棒性.

关键词 目标跟踪, 均值漂移, 目标模型, 选择性子模型更新
中图分类号 TP391

Study on Target Model Update Method in Mean Shift Algorithm

SHEN Zhi-Xi¹ YANG Xin¹ HUANG Xi-Yue¹

Abstract Mean shift is a robust and real-time pattern matching algorithm. At present, the total model update strategy of the mean shift algorithm still has shortage under changed scenes, e.g., target appearance changes, non-target occlusion. Therefore, the paper presents a selective sub-model update strategy for the mean shift algorithm. The proposed method treats each sub-model of target model as singleton, selects and updates sub-model and its weight based on match contributing degree of each sub-model in the current frame. The experiment result shows the proposed method is more robust and effective than the total model update strategy.

Key words Object tracking, mean shift, target model, selective sub-model update

目标跟踪一直是机器视觉研究领域的热点问题, 对运动模型的建立和求解主要有两大类方法: 一类是统计的方法, 把跟踪问题当作状态估计问题来处理, 以获得状态的最优估计为目的, 其代表包括卡尔曼滤波器 (Kalman filter, KF)/扩展 Kalman 滤波器 (Extended Kalman filter, EKF)^[1]、采样卡尔曼滤波器 (Unscented Kalman filter, UKF)^[2]、粒子滤波器 (Particle filter, PF)^[3-4] 等; 另一类是确定的方法, 把跟踪问题当作最优化问题来处理, 转化为求代价函数极值问题, 其中最具有代表性的是由 Comaniciu 等引入的均值漂移 (Mean shift) 算法^[5-7].

Mean shift 算法由于采用了核函数直方图进行建模和匹配, 因此具有特征稳定、鲁棒性强、实时性好等诸多优势, 能够快速实现模式匹配. 但是, 当场景中目标外观变化较大或非目标干扰较为严重时, 仍可能因目标模型的偏移而导致跟踪失败, 所以在较长时间的跟踪中, 目标模板的更新势在必行. 然而, 目前针对 Mean shift 算法中模型更新的研究和

报道仍相对较少. 基本的 Mean shift 算法^[5-7] 基于目标模型在跟踪过程中基本不发生改变这一前提假设, 跟踪过程中一直采用初始目标模型, 并无模型更新机制的研究. 在大多数 Mean shift 及其改进算法中, 都采用的是对目标模型进行简单线性加权的机制^[3, 8]; 文献 [9-10] 针对跟踪过程中的特征进行了研究, 通过选择对当前场景可分性较高的特征模型进行目标的跟踪和模型更新; 文献 [11-13] 则将卡尔曼滤波器用于跟踪过程中的模型更新. 这些模型更新方法, 都是将目标模型作为一个整体, 同时对模型中的每个分量进行更新, 区别只在于赋予每个分量的权值是否相同, 本文将这类方法统称为整体模型更新策略. 但是, 在实际的目标运动中, 随着场景和外观的变化, 目标模型内有些分量的变化是缓慢的, 而有些则是突变的, 整体更新策略显得过于粗糙; 此外, 对于非目标遮挡情况, 随着遮挡程度的加剧, 当前模型中将逐渐引入越来越多的非目标模型分量, 此时, 更不能将目标模型作为一个整体进行更新, 而应该对不同分量加以区别对待.

针对整体模型更新策略的不足, 本文提出了一种 Mean shift 框架下的选择性子模型更新策略. 改进方法的基本思路就是将特征模型中的每个分量作为单独个体, 基于每个分量的匹配贡献度, 分别选择当前帧中需要更新的子模型分量及其更新权值. 在本文以下章节中, 首先对 Mean shift 算法框架进行介绍, 并着重分析整体模型更新策略的不足; 在此基

收稿日期 2008-07-08 收修改稿日期 2008-11-26
Received July 8, 2008; in revised form November 26, 2008
国家自然科学基金 (69674012), 重庆市自然科学基金 (2006BA6016) 资助

Supported by National Natural Science Foundation of China (69674012) and Chongqing Natural Science Foundation of China (2006BA6016)

1. 重庆大学自动化学院导航制导实验室 重庆 400030
1. Navigation and Guidance Laboratory, College of Automation, Chongqing University, Chongqing 400030
DOI: 10.3724/SP.J.1004.2009.00478

基础上, 提出 Mean shift 框架下的选择性子模型更新策略及其算法; 最后是本文的实验和结论.

1 基于 Mean shift 的目标跟踪

Mean shift 是一种基于核概率密度估计的快速模式匹配算法, 它采用某 (几) 种特征 (如灰度、颜色、纹理等) 的核函数直方图来描述目标, 在每帧中对目标模型 (Target model) 和候选目标 (Target candidate) 进行相似性度量, 并沿着核直方图相似性的梯度方向迭代搜索目标位置, 最终实现模式匹配和目标跟踪.

1.1 目标模型描述

定义被跟踪目标为“目标模板”, 当前帧中候选目标为“目标候选”. 由于颜色特征具有较好的鲁棒性, 目前大多数 Mean shift 算法都采用颜色特征对目标进行描述. 为了与前人工作便于比较, 且不失一般性, 本文研究中也采用颜色特征进行分析.

令 q_u 、 p_u 分别表示目标模板和候选目标颜色特征的核直方图各级概率密度, m 为直方图量化等级, 则目标模型描述为:

目标模板:

$$\mathbf{q} = \{q_u\}_{u=1, \dots, m}, \quad \sum_{u=1}^m q_u = 1$$

目标候选:

$$\mathbf{p}(y) = \{p_u(y)\}_{u=1, \dots, m}, \quad \sum_{u=1}^m p_u = 1$$

目标模板模型和目标候选模型中, 第 $u = 1, \dots, m$ 级特征子模型的概率密度分别为

$$q_u = C \sum_{i=1}^n k(\|x_i\|^2) \delta[b(x_i) - u] \quad (1)$$

$$p_u(y) = C_h \sum_{i=1}^{n_h} k\left(\left\|\frac{y - x_i}{h}\right\|^2\right) \delta[b(x_i) - u] \quad (2)$$

式中, C 、 C_h 为归一化系数; k 为核剖面函数; δ 为 Kronecker delta 函数; $b: \mathbf{R}^2 \rightarrow \{1, \dots, m\}$ 是像元在直方图中的颜色索引值; x_i 为目标窗口区域像素的归一化位置; y 为当前帧中候选目标中心; h 为核函数带宽, 通常取为窗宽的一半.

1.2 相似性度量及目标跟踪

在获得目标及候选目标的核直方图模型后, Mean shift 中定义模型间的匹配距离为

$$d(y) = \sqrt{1 - \rho[\mathbf{p}(y), \mathbf{q}]} \quad (3)$$

其中, ρ 为两个模型之间的相似性, Mean shift 中引入了 Bhattacharyya 系数对两个离散概率分布 $\mathbf{p}(y)$

和 \mathbf{q} 之间的相似性进行度量

$$\rho(y) \equiv \rho[\mathbf{p}(y), \mathbf{q}] = \sum_{u=1}^m \sqrt{p_u(y)q_u} \quad (4)$$

目标定位就是在每一帧中寻找使距离 d 最小, 或者相似性 ρ 最大的位置 y . 设上一帧的目标位置为 y_0 , 将 $\rho(y)$ 在 y_0 处泰勒展开, 相似性函数可近似为

$$\rho(y) \approx \frac{1}{2} \sum_{u=1}^m \sqrt{p_u(y_0)q_u} + \frac{C_h}{2} \sum_{i=1}^{n_h} w_i k\left(\left\|\frac{y - x_i}{h}\right\|^2\right) \quad (5)$$

其中,

$$w_i = \sum_{u=1}^m \sqrt{\frac{q_u}{p_u(y_0)}} \delta[b(x_i) - u] \quad (6)$$

由于式 (5) 第一项为常量, 因此欲使式 (5) 最大, 则应使第二项最大化. 注意到第二项表示使用核剖面函数 $k(x)$ 计算出的当前帧中位置 y 处的核密度估计, 该密度估计可通过对相似性函数式 (4) 求最大值得到, 具体推导过程可参见文献 [6]. 从而有 Mean shift 关于相似性度量最大化的迭代公式

$$y_1 = \frac{\sum_{i=1}^{n_h} x_i w_i g\left(\left\|\frac{y_0 - x_i}{h}\right\|^2\right)}{\sum_{i=1}^{n_h} w_i g\left(\left\|\frac{y_0 - x_i}{h}\right\|^2\right)} \quad (7)$$

其中, $g(x) = -k'(x)$. 基于 Mean shift 的目标跟踪, 就是通过反复迭代式 (7), 使候选目标从当前位置 y_0 不断地沿着相似性度量的梯度方向移动到新的位置 y_1 , 直至总的相似性 ρ 达到最大.

1.3 整体模型更新策略

以上的基本 Mean shift 算法, 是基于目标模型基本不发生改变这一假设的, 跟踪过程中一直采用初始目标模型, 并无模型更新机制的研究^[5-7]. 但是, 在实际的跟踪过程中, 由于目标自身的运动、视角的变化以及环境条件的改变, 都会使得固定的目标模型不能长时间稳定地跟踪目标, 因此需要对基本 Mean shift 算法中的目标模型 \mathbf{q} 进行及时动态更新, 以适应目标的变化.

目前, 几乎所有 Mean shift 及其改进算法都采用整体模型更新策略, 即将目标模型作为一个整体, 在当前帧跟踪结果和目标历史模型间进行加权折衷, 并对模型中全部分量进行统一更新, 以获取下一帧所需的模型. 该策略下典型更新公式为

$$\mathbf{q}^{(t)} = \alpha \mathbf{p}^{(t)} + (1 - \alpha) \mathbf{q}^{(t-1)} \quad (8)$$

其中, $\mathbf{q}^{(t)}$ 为当前帧更新后目标模型, $\mathbf{p}^{(t)}$ 为当前帧跟踪结果目标模型, $\mathbf{q}^{(t-1)}$ 为前一时刻目标模型, α 为当前帧跟踪结果权重, 也称为模型更新速度因子。

现有的模型更新方法中: 1) 文献 [3, 8] 中每个分量都有相同的权重, 并同时更新整个模型; 2) 文献 [9–10] 中虽可对模型 \mathbf{p} 和 \mathbf{q} 进行选择, 但对于某个选定的特征模型, 其每个分量的权重仍然相同, 也同时更新整个模型; 3) 文献 [11–13] 中虽然每个分量的权重可以不同, 但仍同时更新整个模型, 其实质仍然是整体更新策略。然而, 在实际的跟踪过程中, 随着目标和场景的变化, 获得的跟踪结果可能逐渐偏离真实目标, 如果用这种逐渐不准确的结果去整体性地更新模型, 往往导致跟踪结果的进一步恶化, 最终丢失目标。因此, 必须对这种整体模型更新策略进行改进, 以克服跟踪过程中的模型偏移问题。

2 基于选择性子模型更新的跟踪

基于以上分析, 本文提出的选择性子模型更新策略主要从两个方面加以改进: 1) 选择性的子模型更新准则; 2) 选择性的子模型更新权重。

2.1 选择性子模型更新策略

在基于 Bhattacharyya 系数的模型相似性度量中, 由于特征直方图中每个分量是独立的, 因此总的匹配度实际上就是各子模型分量的相似度线性累加。由此, 本文将每个分量对总的相似性度量的有效性, 定义为如下匹配贡献度函数

$$MCD_u = \frac{\sqrt{p_u q_u}}{\rho} = \frac{\sqrt{p_u q_u}}{\sum_{u=1}^m \sqrt{p_u q_u}} \quad (9)$$

由此, 本文提出如下选择性子模型更新策略: 首先采用 Bhattacharyya 系数衡量跟踪结果的有效性, 如果 ρ 很小, 说明本次跟踪结果受到了剧烈干扰, 不应更新模型而仍采用前一时刻的目标模型; 如果 ρ 满足一定要求, 则根据每个子模型的贡献度排序, 前 k 个贡献度高的子模型表示当前模型与目标模型较为吻合, 为避免过度更新而造成的模型偏移, 对这些子模型不进行更新, 仅选择余下的 $m - k$ 个贡献度较小即当前模型中与目标模型吻合较差的子模型进行更新:

$$\begin{cases} k = \arg \min_d \left(\sum_{u=1}^d MCD_u \geq T_d \rho \right), & \rho \geq \gamma \\ k = m, & \rho < \gamma \end{cases} \quad (10)$$

其中, γ 为跟踪可靠性阈值, 本文取 $\gamma = 0.7$; $T_d \in [0, 1]$ 为子模型更新比例, 当 $T_d = 0$ 时, 该准则等价

于整体模型更新机制, 当 $T_d = 1$ 时, 该准则退化为不更新模型的机制, 一般取 $T_d = 0.5$ 即可满足要求。

基于以上更新策略, 本文选择性子模型更新准则讨论如下: 1) $q_u = p_u = 0$, 表示当前模型和目标模型中均未出现该子模型, 对其不予更新; 2) $q_u > 0, p_u = 0$, 表示前一时刻有的子模型在当前时刻不再出现, 这通常对应于目标外观变化的情况, 此时应更新子模型, 但为了避免模型对变化过于敏感, 此时应采用一定比例进行加权; 3) $q_u = 0, p_u > 0$, 表示前一时刻没有的子模型在当前时刻出现, 这通常对应于非目标遮挡发生的情况, 此时也应更新子模型, 并同样采用一定比例进行加权; 4) $q_u > 0, p_u > 0$ 且 $u \leq k$, 表示该子模型的匹配度较好, 此时不应更新子模型; 5) $q_u > 0, p_u > 0$ 且 $u > k$, 表示该子模型的匹配度较差, 此时根据其匹配贡献度进行加权更新。令 $\beta_u = MCD_u$, 可得具体更新公式为

$$\begin{cases} q_{u1}^{(t)} = C_q [\alpha p_{u1}^{(t)} + (1 - \alpha) q_{u1}^{(t-1)}], & \beta_{u1} = 0 \\ q_{u2}^{(t)} = C_q q_{u2}^{(t-1)}, & \beta_{u2} > 0, u2 \leq k \\ q_{u3}^{(t)} = C_q [\beta_{u3} p_{u3}^{(t)} + (1 - \beta_{u3}) q_{u3}^{(t-1)}], & \beta_{u3} > 0, u3 > k \end{cases} \quad (11)$$

式中 α 为模型更新速度因子, C_q 为归一化系数。

可见, 基于本文提出的选择性子模型更新策略, 可对目标模型中的每个子模型进行有选择性的更新, 而不再是必须同时更新或不更新整个目标模型。

2.2 本文算法

基于本文提出的选择性子模型更新策略, 改进后的 Mean shift 算法完整描述如下:

步骤 1. 假定初始目标位置为 y_0 , 按式 (1) 计算目标模型 $q_u, u = 1, \dots, m$;

步骤 2. 分别按式 (2) 和 (4) 计算候选目标模型 $\mathbf{p}(y_0)$ 及其与目标模型的相似度 $\rho(y_0)$;

步骤 3. 按式 (6) 确定权值 $\{w_i\}, i = 1, \dots, n_h$, 并按式 (7) 确定目标新位置 y_1 ;

步骤 4. 计算新位置 y_1 的候选目标模型 $\mathbf{p}(y_1)$ 及其与目标模型的匹配度 $\rho(y_1)$;

步骤 5. 若 $\rho(y_1) < \rho(y_0)$, 则令 $y_1 \leftarrow (y_0 + y_1)/2$, 并转步骤 4;

步骤 6. 若 $\|y_1 - y_0\| < \varepsilon$, 结束迭代; 否则令 $y_0 = y_1$, 返回步骤 1 继续迭代;

步骤 7. 按式 (9) 计算跟踪结果的每个子模型匹配贡献度 MCD_u ;

步骤 8. 按式 (10) 和 (11) 选择匹配度较差的 $m - k$ 个子模型 $u_i, i = k + 1, \dots, m$ 进行更新。

3 实验结果

为验证本文算法, 我们分别采用 PETS 2001 视频序列和重庆大学智能车辆 CQAC-I 的车载视频序列进行测试, PETS 序列图像大小为 576 像素 × 768 像素, CQAC-I 车载序列图像大小为 240 像素 × 320 像素. 分别针对无模型更新 (Non-model update, NMU)、整体模型更新 (Total model update, TMU) 以及本文提出的选择性子模型更新 (Selective sub-model update, SSMU) 这三种机制进行测试. 实验中初始目标手动选取, 采用量化等级为 16 × 16 × 16 的 RGB 颜色特征, 核函数为 Epanechnikov 核, 模型更新速度因子取 $\alpha = 0.1$. 为便于对比和分析, 且结论也不失一般性, 几种方法均采用文献 [7] 提出的基本 Mean shift 算法框架, 窗宽简单地采用 ±10% 比例缩放, 其他改进措施 (如背景滤除、目标旋转等) 均未添加.

实验 1. 从 PETS 2001 Dataset-1 视频序列中选取图像共 300 帧, 跟踪对象为行人, 考虑到该序列图像较大, 为便于显示, 结果中除第 1 帧保持原始大小, 其余各帧只显示图像右下部分 288 × 384 像素区域. 图 1 (见本页下方) 为三种模型更新算法的部分跟踪结果.

由图 1 可见: 1) 最初, 三种算法都能正确跟踪目标; 2) 随着跟踪进行, TMU 对目标和非目标特征都一视同仁地进行更新, 导致很快发散 (163 帧), 虽仍能跟踪目标一段时间, 但结果已明显不再准确; 3) 跟踪过程中, 目标有一段时间被电线杆所遮挡, 在逐渐进入遮挡过程中, NMU 很快认为目标丢失 (181 帧), 直至完全脱离遮挡才继续跟踪 (195 帧),

而 SSMU 在逐渐进入和脱离遮挡过程中, 几乎一直能正确跟踪目标, 直到发生严重遮挡才认为目标丢失 (186 ~ 189 帧), 图 1 中给出第 190 帧的结果对比; 4) 最后阶段, 目标与背景颜色纹理逐渐混杂, 采用初始模型的 NMU 也丢失目标 (208 帧), 图 1 中给出第 218 帧的结果对比, 而本文提出的 SSMU 在整个跟踪过程中, 都能一直保持对不同场景中目标的稳定跟踪能力 (296 帧).

图 2 给出了跟踪过程中三种算法的目标模型与真实目标模型的 Bhattacharyya 系数 (Bhattacharyya coefficient, BHC) 对比, 真实目标模型采用手工逐帧标定并计算. 由于 BHC 反映了两个概率分布的匹配程度, 且三种模型更新机制都基于相同的算法框架, 因此如果每帧中所采用的目标模型与真实模型越接近, 则最终算法将越具有更好的跟踪能力和定位精度.

由图可见, TMU 与真实目标模型的差异很快变大, 最终导致目标丢失; NMU 在后期目标与背景颜

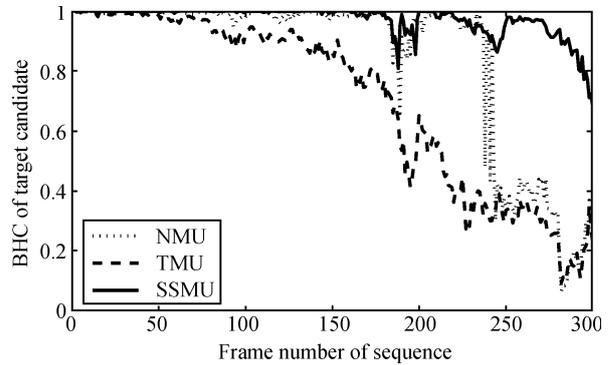


图 2 PETS 序列的目标模型 BHC 对比

Fig. 2 The BHC comparison of PETS sequence



图 1 PETS 序列在三种模型更新机制下的跟踪结果 (1~3 行: NMU、TMU、SSMU; 1~5 列: 1、163、190、218、296 帧)

Fig. 1 Tracking results of PETS sequence (1~3 rows: NMU, TMU, SSMU; 1~5 columns: 1, 163, 190, 218, 296 frames)

色混杂的时候, 所采用的初始目标模型与真实模型的差异也将很快变大, 从而丢失目标; SSMU 在整个跟踪过程中, 都能较为准确地更新目标模型, 具有与真实目标模型最为接近的匹配度, 因此具有最好的跟踪性能. 这一分析和结论也与前面的实际跟踪过程完全吻合.

实验 2. CQAC-I 车载视频序列中选取图像 125 帧, 跟踪对象为车尾牌照. 该实验是为进一步验证本文算法在实际应用中对目标稳定跟踪的能力, 图 3 为三种模型更新机制的部分跟踪结果.

由图 3 可见, 对该序列的跟踪实验得到了与实验 1 类似的结果: TMU 逐渐发生模型偏移, 虽仍能跟踪目标, 但结果已明显不再准确 (46 帧后); NMU 最初虽能较为准确地跟踪目标, 但随着目标的外观变化以及遮挡发生, 也将偏离对目标的正确跟踪 (70 帧后); 而本文提出的 SSMU 在整个过程中都能稳定地跟踪目标, 包括自身外观变化以及逐渐被非目标遮挡等情况.

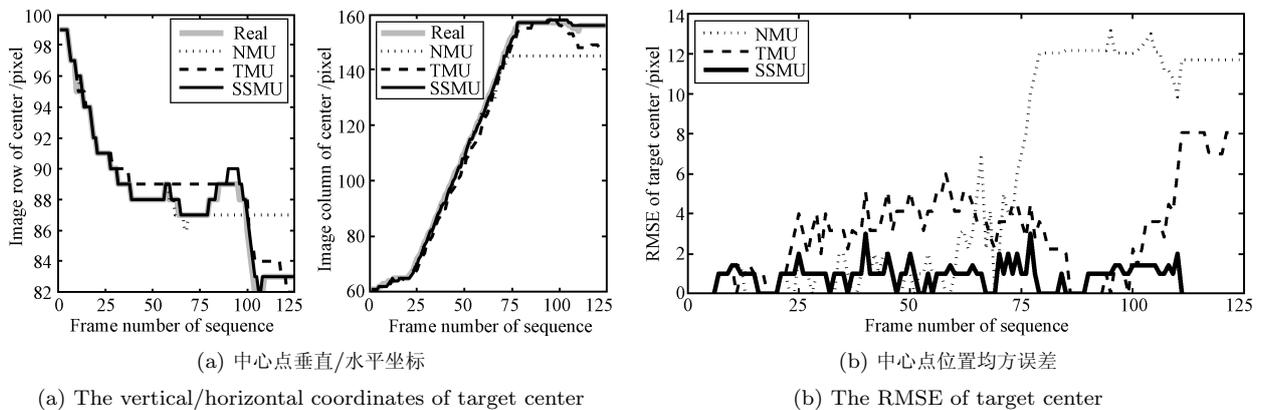
最后, 我们对跟踪过程中几种机制下目标定位结果进行了对比. 图 4(a) 和 4(b) 分别给出跟踪结果中心点与目标真实中心点之间的距离和均方根误差 (Root of mean square error, RMSE), 其中, 真实位置仍采用手工逐帧标定. 由图 4 可见, 相对于 NMU 和 TMU, 本文提出的 SSMU 能更为准确和稳定地跟踪目标, 其跟踪结果与目标真实位置的误差最小, 完全能满足智能车辆的目标跟踪精度要求. 同时, 考虑到 Mean shift 算法的特点, 上一帧跟踪结果越准确, 则下一帧中就可使用更少的迭代步数收敛到目标位置, 因此本文提出的 SSMU 具有比基本 Mean shift 更好的实时性.

4 结 论

针对 Mean shift 在变化场景中的目标跟踪问题, 本文提出了一种基于子模型选择机制的目标模型更新算法. 该方法克服了无模型更新算法对变化场



图 3 CQAC-I 序列在三种模型更新机制下的跟踪结果 (1~3 行: NMU、TMU、SSMU; 1~5 列: 1、46、70、98、106 帧)
Fig. 3 Tracking results of CQAC-I sequence (1~3 rows: NMU, TMU, SSMU; 1~5 columns: 1, 46, 70, 98, 106 frames)



(a) 中心点垂直/水平坐标 (b) 中心点位置均方误差
(a) The vertical/horizontal coordinates of target center (b) The RMSE of target center

图 4 CQAC-I 序列的目标定位结果对比
Fig. 4 The location comparison of CQAC-I sequence

景无法动态适应的不足; 同时, 改进了整体模型更新算法中较为严重的模型漂移问题. 实验结果显示了该算法对目标跟踪的有效性和鲁棒性. 需要说明的是, 本文提出的方法与其他的 Mean shift 改进算法并不冲突, 在此基础上从其他算法的角度出发, 必将进一步提高 Mean shift 算法对目标的跟踪能力.

References

- 1 Weng S K, Kuo C M, Tu S K. Video object tracking using adaptive Kalman filter. *Journal of Visual Communication and Image Representation*, 2006, **17**(6): 1190–1208
- 2 Chen Y Q, Rui Y, Huang T S. Multicue HMM-UKF for real-time contour tracking. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2006, **28**(9): 1525–1529
- 3 Nummiaro K, Meier E K, Gool L J V. An adaptive color-based particle filter. *Image and Vision Computing*, 2003, **21**(1): 99–110
- 4 Nummiaro K, Meier E K, Gool L J V. Object tracking with an adaptive color-based particle filter. In: *Proceedings of the 24th DAGM Symposium on Pattern Recognition*. London, UK: Springer, 2002. 353–360
- 5 Comaniciu D, Ramesh V. Mean shift and optimal prediction for efficient object tracking. In: *Proceedings of IEEE International Conference on Image Processing*. Vancouver, Canada: IEEE, 2000. 70–73
- 6 Comaniciu D, Meer P. Mean shift: a robust approach toward feature space analysis. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2002, **24**(5): 603–619
- 7 Comaniciu D, Ramesh V, Meer P. Kernel-based object tracking. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2003, **25**(5): 564–577
- 8 Porikli F, Tuzel O, Meer P. Covariance tracking using model update based on Lie algebra. In: *Proceedings of IEEE Computer Society Conference on Computer Vision and Pattern Recognition*. New York, USA: IEEE, 2006. 728–735
- 9 Collins R T, Liu Y X, Leordeanu M. Online selection of discriminative tracking features. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, **27**(10): 1631–1643
- 10 Wang Yong-Zhong, Liang Yan, Zhao Chun-Hui, Pan Quan. Kernel-based tracking based on adaptive fusion of multiple cues. *Acta Automatica Sinica*, 2008, **34**(4): 393–399 (王永忠, 梁彦, 赵春晖, 潘泉. 基于多特征融合自适应融合的核跟踪方法. *自动化学报*, 2008, **34**(4): 393–399)

- 11 Nguyen H T, Worring M, van den Boomgaard R. Occlusion robust adaptive template tracking. In: *Proceedings of the 8th International Conference on Computer Vision*. Vancouver, Canada: IEEE, 2001. 678–683
- 12 Peng N S, Yang J, Liu Z. Mean shift blob tracking with kernel histogram filtering and hypothesis testing. *Pattern Recognition Letters*, 2005, **26**(5): 605–614
- 13 Babu R V, Pérez P, Bouthemy P. Robust tracking with motion estimation and local kernel-based color modeling. *Image and Vision Computing*, 2007, **25**(8): 1205–1216

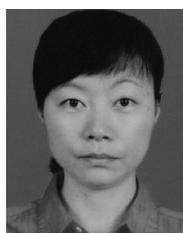


沈志熙 重庆大学自动化学院博士研究生. 主要研究方向为机器视觉, 模式识别和人工智能. 本文通信作者.

E-mail: shenzxcq@yahoo.com.cn

(**SHEN Zhi-Xi** Ph. D. candidate at the College of Automation, Chongqing University. His research interest covers machine vision, pattern recognition,

and artificial intelligence. Corresponding author of this paper.)



杨欣 重庆大学自动化学院博士研究生. 主要研究方向为图像处理和信息安全. E-mail: cindyyoung@cqu.edu.cn

(**YANG Xin** Ph. D. candidate at the College of Automation, Chongqing University. Her research interest covers image processing and information security.)



黄席樾 重庆大学教授. 主要研究方向为智能算法, 模式识别, 人工智能和智能故障诊断.

E-mail: xyhuang@cqu.edu.cn

(**HUANG Xi-Yue** Professor at Chongqing University. His research interest covers intelligent algorithm, pattern recognition, artificial intelligence,

and intelligent fault diagnosis.)