

基于特征可分性和稳定性度量的多特征融合目标跟踪算法

刘明华^{a,b}, 汪传生^b, 王宪伦^b

(青岛科技大学 a. 信息科学技术学院, b. 机电工程学院, 山东 青岛 266061)

摘要: 针对单一特征目标跟踪算法鲁棒性较差的问题, 提出一种基于特征可分性和稳定性度量的多特征融合目标跟踪算法. 在粒子滤波框架下, 通过计算不同特征对目标和背景的可区分性和稳定性, 设置重要性权值并自适应选择区分能力强、稳定性好的特征描述目标, 建立多特征融合目标模型. 在状态转移过程中, 给出一种基于特征稳定性度量的选择性模板更新策略, 并进行遮挡处理. 实验结果表明, 所提出的算法能够在复杂场景下鲁棒地跟踪目标.

关键词: 粒子滤波; 目标跟踪; 多特征融合; 特征可分性; 特征稳定性

中图分类号: TP391

文献标志码: A

Fusing multi-features target tracking algorithm based on discriminability and stability of features

LIU Ming-hua^{a,b}, WANG Chuan-sheng^b, WANG Xian-lun^b

(a. College of Information Science and Technology, b. College of Mechanical and Electrical Engineering, Qingdao University of Science and Technology, Qingdao 266061, China. Correspondent: LIU Ming-hua, E-mail: qustlmh@163.com)

Abstract: In order to solve the poor robustness problem of using single feature in the target tracking process, an adaptive fusing multi-features tracking algorithm is proposed based on the discriminability and stability of features in the particle filter framework. Several reliable features are adaptively selected by calculating their discriminative ability and stability, which are used to describe the target model, the multi-features fusion target model is established and the importance weights of features are set. In the process of state transition, a selective template updating method is presented based on the measurement of feature stability, and the occlusion problem is handled. Experimental results show that the proposed method can track the target under the complex scene in robust performance.

Keywords: particle filter; object tracking; multi-features fusion; feature discriminability; feature stability

0 引言

如何快速、稳定地进行目标跟踪是智能视频监控、人机交互和机器人导航定位等领域的核心问题, 也是机器视觉领域研究的热点之一. 复杂环境下, 受光照变化、背景相似、目标形变以及遮挡等因素的影响, 目标跟踪变得非常困难.

目前的跟踪算法主要分为3类: 基于分类器的算法^[1-2], 基于目标模板搜索匹配的确定算法^[3-4]以及基于贝叶斯估计和粒子滤波的概率算法^[5-6]. 其中: 分类器算法计算量较大, 适用于对跟踪实时性要求不高的场合; 基于目标模板搜索匹配的确定算法收敛速度快, 适合实时跟踪, 但难以适应目标尺度和形状的变

化; 基于粒子滤波的概率算法简单、灵活, 容易实现, 不受系统模型的限制, 被广泛应用于目标跟踪领域. 但是, 在复杂环境下, 使用单一特征模型或目标特征选择不当, 即使应用粒子滤波算法也会引起滤波发散, 目标丢失, 因此, 提取多个有效特征建立精确的目标模型并有效区分目标和背景是跟踪成功的关键.

在粒子滤波框架下, 多特征融合算法引起了较多学者的关注. 顾鑫等^[7]提出了特征的不确定性度量方法, 通过获取不同特征粒子的空间分布来度量特征的鉴别能力, 并选择鉴别能力强的特征进行自适应融合, 跟踪效果较好, 但未考虑模型的自适应更新; 相入喜等^[8]对多特征融合目标模型进行分块划分, 给出了

收稿日期: 2015-05-20; **修回日期:** 2015-08-23.

基金项目: 国家自然科学基金项目(51105213, 51175274); 山东省自然科学基金项目(BS2015DX010).

作者简介: 刘明华(1980—), 男, 博士生, 从事机器视觉、目标识别与跟踪的研究; 汪传生(1960—), 男, 教授, 博士生导师, 从事机电控制理论、智能信息系统等研究.

鉴别性更高的多尺度相似性度量方法,具有较强的抗遮挡能力,但需要较高的分块数量来保证跟踪精度,增加了时间开销;Zhou等^[9]将目标的时空运动特征与颜色特征相融合进行目标跟踪,该算法考虑了融合特征对目标和场景变化的适应性,但是忽略了特征退化时模型的自适应更新,使跟踪的可持续性下降;Yao等^[10]将 Mean Shift 算法与粒子滤波相结合,提出了基于核函数粒子滤波的目标跟踪算法,该算法由于要对每个粒子都进行 Mean Shift 迭代,滤波速度并未得到明显提高,且容易受到遮挡以及相似背景的干扰;Islam等^[11]将跟踪目标分割为多个不同权重的子区域,融合颜色和目标边缘轮廓特征对人体进行跟踪,取得了较好的效果,但该方法忽略了不同特征对目标和背景的可分性,复杂场景下跟踪精度不高。

针对多特征融合算法存在的问题,本文提出一种基于特征可分性和稳定性度量的多特征自适应融合跟踪算法.首先,建立多特征似然模型,通过度量不同特征的分度度和稳定性,确定特征重要性权值并进行动态更新,再根据权值大小,自适应选择合适的特征集来描述目标;然后,针对自适应跟踪算法常见的模型漂移问题,利用特征的可分性和稳定性对目标状态进行划分,给出精度更高的模型更新策略和遮挡处理方法,以实现复杂环境下鲁棒的目标跟踪。

1 基于粒子滤波的目标跟踪

基于粒子滤波的目标跟踪是利用一组在状态空间传播的加权随机样本(粒子) $\{s_t^{(i)}, w_t^{(i)}\}_{i=1}^N$ 近似表示系统状态(跟踪目标)的后验概率分布 $p(s_t|e_{1:t})$,每一个粒子描述了目标状态的一种可能,通过随机选取足够数量的粒子得到目标状态后验概率分布的较好近似,即

$$p(s_t|e_{1:t}) = \sum_{i=1}^N w_t^{(i)} \delta(s_{0:t} - s_{0:t}^{(i)}). \quad (1)$$

其中: N 为粒子数量; $\delta(\cdot)$ 为狄拉克函数; $w_t^{(i)}$ 为 t 时刻粒子 i 的归一化权值,即 $\sum_{i=1}^N w_t^{(i)} = 1$, 其值通过重要性采样原理计算得到.假设采样粒子满足重要性分布,则可得如下权值更新过程:

$$w_t^{(i)} \propto w_{t-1}^{(i)} p(e_t|s_t^{(i)}). \quad (2)$$

其中: $p(e_t|s_t^{(i)})$ 称为系统观测模型,其作用是实现粒子权值的更新,使与实际目标模型相似度高的粒子获得较大权值.由于重采样后,粒子权值表现为其后代粒子数量,其后代粒子权值被重置为 1,据此可简化式(2),并利用高斯函数定义观测似然函数

$$w_t^{(i)} = p(e_t|s_t^{(i)}) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{d_b^2}{2\sigma^2}}. \quad (3)$$

其中: d_b 为第 i 个粒子预测值与真实值之间的距离,通常定义为 Bhattacharyya 距离; σ 为系统噪声分布的标准方差,本文取 $\sigma = 10$.

2 多特征似然模型

2.1 多特征目标模型

选择颜色、边缘和纹理等多个特征的概率密度函数来描述目标模型,并统一利用直方图建立多特征模型.假设直方图模型为 $\hat{q} = \{q_k^{(f)}\}_{k=1,2,\dots,m_f}$.其中: m_f 为特征 f 的直方图量化 bin 值; $\{q_k^{(f)}\}$ 为特征 f 的概率密度函数,且有

$$q_k^{(f)} = C \sum_{\mu=1}^{\mu=K} \delta(b(x_\mu) - k). \quad (4)$$

其中: C 为归一化常数,满足 $\sum_{k=1}^{m_f} q_k^{(f)} = 1$, $\delta(\cdot)$ 为狄拉克函数, $\{x_\mu; \mu = 1 : K\}$ 为指定区域的像素位置,函数 $b(\cdot)$ 将指定像素映射到直方图相应量级的 bin.

2.2 似然函数计算

假设基于特征 f , 需要进行相似性度量的目标和候选目标模型分别为 $P_f = \{p_k^{(f)}\}_{k=1,2,\dots,m_f}$ 和 $Q_f = \{q_k^{(f)}\}_{k=1,2,\dots,m_f}$, 则其距离可计算如下:

$$d_b = \sqrt{1 - \rho(P_f, Q_f)}. \quad (5)$$

其中: $\rho(P_f, Q_f)$ 为 Bhattacharyya 系数,定义

$$\rho(P_f, Q_f) = \sum_{k=1}^m \sqrt{p_k^{(f)} q_k^{(f)}}. \quad (6)$$

两个相似性高的直方图具有较高的 Bhattacharyya 系数值.利用式(5)可以计算式(3)的似然函数值.

3 自适应多特征融合及权重计算

3.1 多特征融合似然模型

假设各观测相互独立,定义包含颜色、边缘和纹理的多特征集 $F = \{f|f \in (c, e, t)\}$, 可以得到多特征融合之后的观测似然模型,定义如下:

$$p_{fused}(e_t|s_t) = \prod_{f \in F} p_f(e_{f,t}|s_t)^{w_f}. \quad (7)$$

其中: $f \in F$, $w_f \in [0, 1]$ 为归一化自适应特征权值,即 $\sum_{f \in F} w_f = 1$, 其详细计算过程见 3.2 节.

3.2 特征可分性度量及权值计算

在度量目标和候选目标的相似性时,对目标和背景区分能力强的特征赋予较高权值,据此进行跟踪的结果将会更加可靠,因此,及时地度量不同特征对目标和背景的可分性,并调整特征权值,可以避免滤波发散。

本文采用改进的 log 似然比方法计算特征的分度,特征分度变化曲线如图 1 所示。

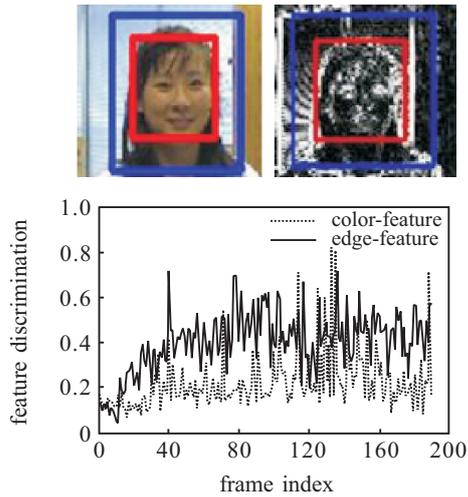


图1 特征区分度变化

由图1可见, 大部分情况下颜色和边缘特征的区分度是逆向变化的, 两者对目标和背景的区分能力可以实现互补。

1) 定义目标和背景区域. 假设目标区域为 $S_t = \{x, y, W_0, H_0\}$. 其中: $\{x, y\}$ 为矩形框的中心, W_0 和 H_0 为目标区域的宽和高. 背景区域的选择只需要考虑目标外围的局部背景, 背景区域宽 W 和高 H 的取值应覆盖目标区域, 并使目标与背景区域面积接近, 本文选择 $W = \sqrt{2}W_0$, $H = \sqrt{2}H_0$.

2) 计算指定特征的 log 似然比. 给定特征 f , 假设 h_f 为 f 的目标直方图, h_b 为背景直方图, 目标和背景的概率密度函数为 $p(i)$ 和 $q(i)$, 定义如下:

$$p(i) = \frac{h_f^{(i)}}{n_f}, \quad q(i) = \frac{h_b^{(i)}}{n_b}.$$

其中: $i = 1, 2, \dots$ 为直方图中相应 bin 的索引, n_f 和 n_b 分别为目标和背景的像素数量. 第 i 个 bin 的 log 似然比函数定义为

$$L^{(i)} = \max \left(-1, \min \left(1, \log \left(\frac{\max(p(i), \varepsilon)}{\max(q(i), \varepsilon)} \right) \right) \right). \quad (8)$$

其中: $\max(\cdot)$ 和 $\min(\cdot)$ 函数保证 $L^{(i)} \leq 1$; ε 为保证 $\log(\cdot)$ 函数有意义的极小值, 本文取 $\varepsilon = 0.001$. 该相似度函数将目标区域特征值映射为正值, 将背景区域特征值映射为负值. 从 $L^{(i)}$ 的取值可知, 目标与背景的特征值差异越大, $L^{(i)}$ 的取值越分散, 因此, 可通过特征相似度函数的方差描述各特征对目标和背景的区分度, 方差较大的特征具有较高的区分度.

对于不同特征 f , 若 $p(i)$ 与 $q(i)$ 都比较接近, 则目标和背景的可分性比较低, log 似然比函数值大多集中到 0 值附近, 此时各特征的可分性比较接近. 针对此情况, 取较小值 $\delta_0 > 0$ (如 $\delta_0 = 0.1$), 对于满足 $\left\| \frac{p(i)}{q(i)} - 1 \right\| < \delta_0$ 的 bin, 利用背景直方图信息为相应的 bin 设置权值, 即

$$\omega_i = \min \left(\frac{q^*}{q(i)}, 1 \right)_{i=1,2,\dots}. \quad (9)$$

其中 q^* 为归一化背景直方图后的最小非零 bin 值. 将 ω_i 应用到目标和候选目标模型的相似性度量中, 将所有满足上述条件的目标和候选目标的 bin 值乘上 ω_i , 可降低目标和背景相似的 bin 值对计算结果的贡献, 减轻相似背景的干扰.

由等式 $\text{var}(x) = E[x^2] - (E[x])^2$ 可计算特征 f 的相似度函数的方差

$$\text{var}(L^f) = E[L(i)^2] - (E[L(i)])^2. \quad (10)$$

于是, 特征 f 的区分度可以定义为

$$d^f = \text{var}(L^f). \quad (11)$$

将各特征的区分度归一化, 得到归一化特征权值

$$w^f = \frac{d^f}{\sum_{f \in F} d^f}, \quad (12)$$

其中 $w^f \in [0, 1]$ 为多特征融合权值. 由式(7)和(12)可知, 特征 f 的区分度越高, w^f 越大, 对观测似然模型的贡献也越大, 依赖于该特征的跟踪精度也越高; 反之, w^f 越小, 对观测似然模型的计算结果影响越小, 当 f 完全不可靠时, 置 $w^f = 0$, 此时有 $p_f(e_{f,t}|s_t)^{w^f} = 1$, 这意味着该特征对观测似然模型的计算没有影响, 保证了跟踪精度.

为了保证目标模型对特征权值的变化具有足够的适应性, 特征权值的更新按下式进行:

$$w_t^f = \tau d_t^f + (1 - \tau)w_{t-1}^f. \quad (13)$$

其中: w_t^f 为特征 f 根据当前场景更新后的特征权值; d_t^f 为当前特征的区分度; w_{t-1}^f 为该特征在前一时刻的特征权值; 参数 $\tau \in [0, 1]$ 控制权值更新的速率, d_t^f 的值越大, τ 取值越高, 即权值更新更多依赖于该特征对当前目标和背景的区分度.

3.3 特征稳定性度量

在跟踪过程中, 目标模型变化的快慢对跟踪结果也有直接影响, 如在光照突变环境下, 基于颜色特征建立的目标模型会发生显著变化, 而基于边缘和纹理特征建立的目标模型变化则较为平缓. 鉴于此, 为了表征特征模型的变化程度, 对于特征 f 引入特征变化率 η^f , 假设在 t 和 $t+k$ 帧基于特征 f 的目标模型为 p_t^f 和 p_{t+k}^f , 定义特征变化率如下:

$$\eta^f = \delta^f / k. \quad (14)$$

其中: $\delta^f = \sqrt{1 - \rho(p_t^f, p_{t+k}^f)}$, $\rho(p, q)$ 为 Bhattacharyya 系数; k 为帧的间隔距离, 本文取 $k = 7 \sim 14$.

利用 η^f 可以度量特征 f 的稳定性, 对于给定阈值 th_0 , 如果 $\eta^f > \text{th}_0$, 则认为该特征的变化率较大, 特征的稳定性较差, 本文初始化 $\text{th}_0 = 0.06$, 以步长 ± 0.02 动态更新. 图2给出了在一个视频序列中, 颜色

和边缘特征变化率度量曲线。

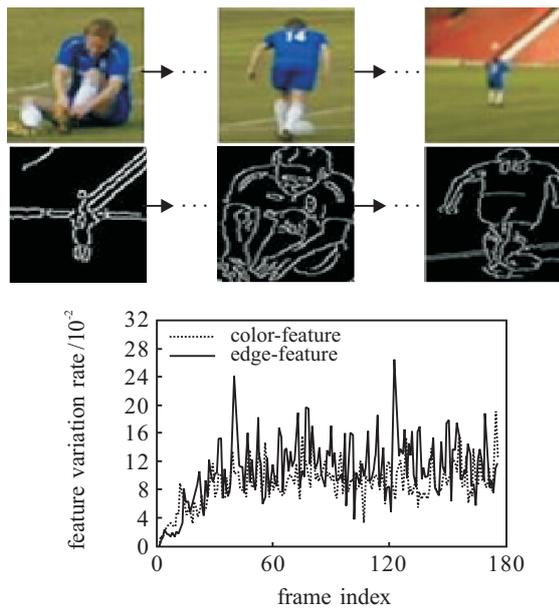


图 2 颜色和边缘特征变化率

特征变化率的引入有助于系统“感知”不同特征目标模型的变化情况,保证跟踪过程中各参数的及时调整。例如,引入 η^f 后,在式(13)中, τ 的取值应综合考虑特征的区分度和变化率的大小,本文初始化 $\tau = 0.8$,并按 $\tau \propto d^f / \eta^f$ 动态调整,由于特征权值的更新综合考虑了特征的可分性和稳定性两种因素的影响,具有更高的可靠性。

4 目标模型更新及遮挡处理

4.1 目标模型更新

为了避免目标模型漂移,本文利用特征稳定性度量的定义,充分考虑目标模型的时域相关性,对于不同特征目标模型采用异步更新的模式,提出一种目标模型的状态划分更新策略。假设初始目标模型为 s_0 。

1) 目标稳定状态。

目标稳定状态描述跟踪过程中目标的缓慢变化过程,初始化集合 $L_s = \{s_0\}$,假设候选目标模型为 $s_t (t = 1, 2, \dots)$,设定可靠性阈值 $\lambda_t^l \in (0, 1)$ (λ_t^l 的选择同下节遮挡阈值), l 为某种特征模型,计算 $w_{\max} = \max p(e_t | s_t^{(i)})$,若 $w_{\max} > \lambda_t^l$,则将当前候选目标模型加入集合 L_s ,并用其更新 s_0 。重复上述过程,直到出现第1个不满足条件的目标模型 s_{t+1} ,得到 $L_s = \{s_0, s_1, \dots, s_t\}$ 。

2) 目标不确定状态。

初始化不确定状态集合 $L_o = \phi$,将不满足1)的候选目标模型 $s_{t+i} (i = 1, 2, \dots)$ 加入 L_o ,假设经过 m 帧后,出现候选目标模型 s_{t+k} 重新满足 $w_{\max} > \lambda_t^l$,则停止上述过程,得到 $L_o = \{s_{t+1}, s_{t+2}, \dots, s_{t+k-1}\}$;否则,对于所有的特征模型,若 m 超过指定阈值 m_0 (本

文取 $m_0 = 35$),则跟踪失败。

实验表明,如果目标模型的突变是由光照变化、遮挡等因素引起的,则目标模型通常会经过不确定状态回到稳定状态, L_o 仍能表示真实的目标序列。若 $m < m_0$,则对目标模型采用下式进行更新:

$$s_t = \beta s_0 + (1 - \beta) s_{t-1}. \quad (15)$$

其中: $\beta \in (0, 1)$ 为自适应更新因子,本文初始化 $\beta = 0.1$, $\beta \propto \eta^f$ 。可靠性阈值按照下式进行更新:

$$\lambda_t^l = (1 - \alpha_l) \lambda_{t-1}^l + \alpha_l p(e_t | s_t^l). \quad (16)$$

其中: $\alpha_l \in (0, 1)$ 为场景学习因子,本文初始化 $\alpha_l = 0.2$, $\alpha_l \propto \eta^f$ 。

上述更新方式不仅考虑到初始目标模型和上一帧目标模型包含的信息以及不同特征变化率对当前目标模型的影响,而且能够保证目标模型的动态变化对不同场景有更强的适应性,具有更高的精确性。

4.2 遮挡处理

遮挡是影响跟踪效果的重要因素,本文采取以下方法进行遮挡处理。

1) 遮挡判断。当目标进入不确定状态时,设定遮挡阈值 T_o ,计算当前所有粒子的最大权值 $w_{\max} = \max p(e_t | s_t^{(i)})$,若 $w_{\max} < T_o$,则认为发生了遮挡。为了避免阈值选择对场景的变化过于敏感,将遮挡阈值设定为一段时间内粒子最大权值的平均值,即

$$T_o = \frac{1}{k} \sum_{j=1}^k w_{\max}^{(j)}.$$

其中: $w_{\max}^{(j)}$ 为目标 $s_j \in L_s (j \in [1, k])$ 的最大粒子权值, k 为在集合 L_s 选择的目标模型的个数,可以根据实际情况动态设置,本文选择 $k = 10$ 。

2) 遮挡处理。判定目标处于遮挡状态后,保存 L_s 中的最后一个目标模型,利用状态转移模型对目标位置进行传播,根据经验方程对其运动轨迹进行预测,增加粒子数量,扩大搜索范围,计算 $w_{\max} = \max p(e_t | s_t^{(i)})$,若 $w_{\max} > \lambda T_o$,则认为重新捕获了目标。其中: $\lambda \in (0, 1)$ 为调节因子,本文初始化 $\lambda = 0.8$,按 $\lambda \propto 1/\eta^f$ 动态调整。

5 基于特征可分性和稳定性度量多特征融合粒子滤波算法

假设 n 帧目标图像序列为 I_1, I_2, \dots, I_n ,确定目标在第1帧图像中的位置 \hat{y}_0 ,得到背景区域,由式(11)计算各特征的区分度,选择区分度高的两个特征融合,按式(12)计算初始特征的融合权重 $w_f (f = 1, 2)$,得到目标的初始多特征模型 $\hat{q} = \{q_k^{(f)}\}_{k=1,2,\dots,m_f}$,其中 m_f 为特征 f 对应直方图的bin值,算法具体实现如下。

1) 初始化: $t = 1$.

初始化粒子集 $\{s_0^{(i)}, w_0^{(i)}\}_{i=1}^N$, 其中 $w_0^{(i)} = \frac{1}{N}$.

2) 跟踪过程: for $t = 2, 3, \dots$.

① 传播: 通过状态转移模型, 根据 s_{t-1} 预测当前帧状态 s_t , 实现粒子传播, 得到新的粒子集 $\{s_t^{(i)}\}_{i=1}^N$;

② 观测: 由特征 f 的观测似然模型计算粒子 $s_t^{(i)}$ 的权值 $w_t^{(i),f} = p_f(e_t|s_t^{(i)})$, 根据融合权重 w_f 和多特征融合观测似然模型计算粒子的归一化权值 $w_t^{(i),f}$, 并保存其最大值 w_{\max}^f ;

③ 融合: 由式(11)计算各特征的分度, 选择分度高的两个特征, 按式(12)计算其融合权重 w_f ;

④ 估计: 根据特征融合之后的粒子权值 $w_t^{(i)}$ 估计目标当前位置 $\hat{s}_t = \sum_{i=1}^N w_t^{(i)} s_t^{(i)}$;

⑤ 更新: 依照式(14)计算各特征的稳定性, 并比较 w_{\max}^f 和 λ_t^f 的大小, 确定是否需要目标模型更新, 若需要, 则按式(15)、(16)进行;

⑥ 重采样: 根据对当前帧候选目标位置的权值估计结果, 自适应重新抽取 M 个粒子 $\{s_t^{(i)}\}_{i=1}^M$, 并令 $w_t^{(i)} = \frac{1}{M}$, 建立新的粒子集 $\{s_t^{(i)}, \frac{1}{M}\}_{i=1}^M$, 然后返回步骤①.

6 实验结果及分析

为了验证本文算法, 在 VS2010+OPENCV2.4.3 平台下分别采用经典粒子滤波算法、均值迁移算法、文献[11]算法和本文算法进行测试, 实验参数设置如下: 初始跟踪目标在第1帧手动选择, 初始粒子数目为100, 对应颜色特征、边缘特征及纹理特征为 $m_f = 512, 16, 64$.

6.1 定性分析

实验1 测试本文算法对目标旋转和尺度变化的适应性, 如图3所示.

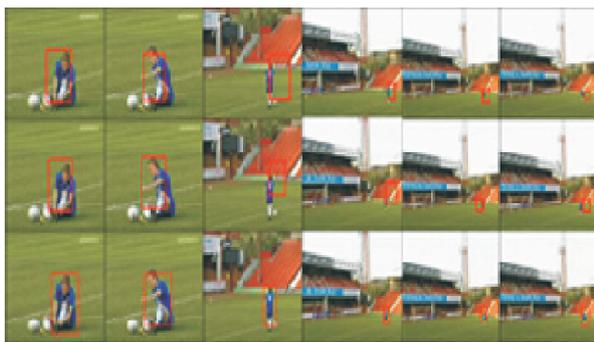


图3 实验1部分跟踪结果

在图3中: 上行为文献[11]算法, 对应第7、90、148、226、384、403帧; 中行为粒子滤波算法, 对应第7、90、148、240、307、353帧; 下行为本文算法, 对应第7、90、148、240、307、353帧.

从图3可以看出, 当光线变化, 目标旋转时: 文献[11]算法在148帧出现误差, 226帧误差变大, 403帧完全偏离目标; 粒子滤波算法在148帧偏离目标, 240~307帧出现较大偏差, 在353帧完全偏离目标; 本文算法在目标发生旋转、形变, 以及快速移动时, 能快速“感知”到当前目标状态, 并根据特征的可分性和稳定性及时更新目标模型, 准确地跟踪目标.

实验2 测试本文算法在遮挡或相似背景情况下跟踪的稳定性, 如图4所示.

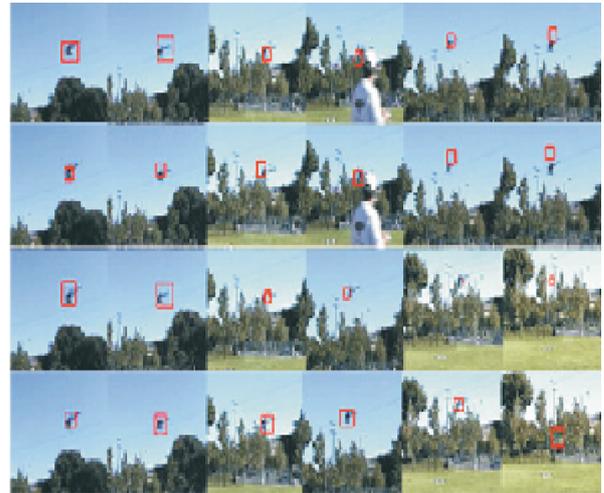


图4 实验2部分跟踪结果

在图4中: 第1行为均值迁移算法, 对应第37、121、240、272、353、365帧; 第2行为粒子滤波算法, 对应第37、121、240、272、353、365帧; 第3行为文献[11]算法, 对应37、121、240、353、457、556帧; 第4行为本文算法, 对应37、121、240、353、457、556帧.

由图4可见: 均值迁移和粒子滤波算法在目标飞离树丛时出现误差, 240帧误差变大, 并分别在365帧和353帧完全丢失目标; 文献[11]方法在240帧开始出现跟踪误差, 353帧误差变大, 457帧完全丢失跟踪目标; 本文算法在240帧目标进入丛林时进行特征权值的调整和目标模型的更新, 使跟踪系统能很快适应当前场景, 及时定位目标, 并在353帧目标飞出丛林时, 重新扑捉到目标, 继续稳定跟踪.

实验3 测试光照剧烈变化时本文算法的稳定性, 如图5所示.



图5 实验3部分跟踪结果

在图5中: 上行为文献[11]算法, 对应第74、179、194、491、556、621帧; 下行为本文算法, 对应第74、179、194、491、556、621帧. 当目标发生旋转时, 文献[11]算法在179帧逐渐偏离目标, 而本文算法通过对特征的可分性和稳定性度量, 在194帧便迅速适应了当前场景的动态变化, 重获跟踪目标.

6.2 定量分析

各算法在不同测试中的误差对比如表1所示.

表1 各算法在不同测试中的误差对比(均值±标准差)

跟踪算法	实验1	实验2	实验3
均值迁移	—	11.47±25.69	—
粒子滤波	18.75±31.95	13.83±21.29	—
文献[11]	8.78±19.12	9.41±17.35	10.76±16.18
本文算法	4.90±11.37	5.56±10.82	7.31±9.49

由表1可知, 本文算法在3个实验中的平均跟踪误差和标准偏差均小于其他跟踪方法.

对于多特征融合算法, 其时间复杂度取决于所选择的特征个数和目标的大小, 相比于单特征粒子滤波算法, 本文算法增加的时间开销主要在于多特征的提取和特征可分性度量, 特征的稳定性度量和目标状态的划分可在粒子滤波算法框架内完成. 在CORE T7300 2.0 GHZ, 1 G内存的计算机上, 对上述3个测试序列运行本文算法未经优化的C++程序, 可达到17 fps、21 fps和20 fps的跟踪速度, 基本满足实时性要求.

7 结 论

本文在粒子滤波框架下, 基于多特征的融合以及特征权值的自适应更新提出了一种复杂环境下的目标跟踪算法. 该算法利用不同特征对目标和背景区分度不同的特点, 在跟踪的不同阶段动态计算特征的区分度和融合权重, 选择区分度最高的两个特征进行融合, 提高了跟踪精度; 给出了特征稳定性度量方法, 通过度量不同特征的稳定性, 对不同特征目标模型采用异步更新的策略, 并进行遮挡处理. 实验结果表明, 本文算法在复杂环境下具有较好的鲁棒性和跟踪精度. 下一步的工作重点是寻找更高效的多特征融合策略, 建立更加简单、可靠的目标模型, 综合利用特征的可分性和稳定性实现多目标跟踪.

参考文献(References)

[1] Kalal Z, Matas J, Mikolajczyk K. *P-N learning: Bootstrapping binary classifier by structural constraints*[C].

- IEEE Conf on Computer Vision and Pattern Recognition. San Francisco: IEEE Press, 2010: 49-56.
- [2] Zhang K, Zhang L, Yang M H. Fast compressive tracking[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2014, 36(10): 2002-2015.
- [3] 董蓉, 李勃, 陈启美. 基于SIFT特征的目标多自由度 mean-shift 跟踪算法[J]. 控制与决策, 2012, 27(3): 399-407.
(Dong R, Li B, Chen Q M. Multi-degree-of-freedom mean-shift tracking algorithm based on SIFT feature[J]. Control and Decision, 2012, 27(3): 399-407.)
- [4] Li Shuxiao, Wu Ou, Zhu Chengfei, et al. Visual object tracking using spatial context information and global tracking skills[J]. Computer Vision and Image Understanding, 2014, 125(8): 1-15.
- [5] Dou J, Li J. Robust visual tracking based on interactive multiple model particle filter by integrating multiple cues[J]. Neurocomputing, 2014, 135(8): 118-129.
- [6] Juan C. Sanmiguel, Andrea Cavallaro. Temporal validation of particle filters for video tracking[J]. Computer Vision and Image Understanding, 2015, 131(2): 42-55.
- [7] 顾鑫, 王海涛, 汪凌峰, 等. 基于不确定性度量的多特征融合跟踪[J]. 自动化学报, 2011, 37(5): 550-559.
(Gu X, Wang H T, Wang L F, et al. Fusing multiple features for object tracking based on uncertainty measurement[J]. Acta Automatica Sinica, 2011, 37(5): 550-559.)
- [8] 相入喜, 李见为. 多特征自适应融合的粒子滤波跟踪算法[J]. 计算机辅助设计与图形学学报, 2012, 24(1): 97-103.
(Xiang R X, Li J W. Particle filter tracking method of multiple features based adaptive fusion[J]. J of Computer-Aided Design & Computer Graphics, 2012, 24(1): 97-103.)
- [9] Zhou Huiyu, Fei Minrui, Abdul Sadka, et al. Adaptive fusion of particle filtering and spatio-temporal motion energy for human tracking[J]. Pattern Recognition, 2014, 47(11): 3552-3567.
- [10] Yao A, Lin X, Wang G, et al. A compact association of particle filtering and kernel based object tracking[J]. Pattern Recognition, 2012, 45(7): 2584-2597.
- [11] Islam M Z, Oh C M, Lee C W. An efficient multiple cues synthesis for human tracking using a particle filtering framework[J]. J of Innovative Computing, Information and Control, 2011, 7(6): 3379-3393.

(责任编辑: 闫 妍)