

基于多表观特征子模型更新的鲁棒视觉跟踪

范舜奕,管桦,侯志强,余旺盛,戴铂

(空军工程大学信息与导航学院,陕西西安 710077)

摘要: 在视觉跟踪中,传统模型更新算法在遮挡、光照变化及自身旋转等情况下通常存在鲁棒性较差的问题.为改善该性能,提出一种对多表观特征相应子模型进行选择性更新的鲁棒视觉跟踪算法.该算法首先建立候选子模型库,然后通过三个互补特征融合的粒子滤波跟踪确定当前帧目标位置和信息,最后将当前帧三种特征直方图信息与候选库中各子模型分别计算加权相似度,更新候选库后与阈值比较,判断是否更新当前子模型.实验结果表明:本文算法能够对特征相应子模型进行有效的选择性更新,与对比算法比较,在多种复杂变化的跟踪条件下,总体上能够具有更好的跟踪鲁棒性.

关键词: 视觉跟踪; 粒子滤波; 模型更新; 多特征融合; 候选子模型库; 加权相似度

中图分类号: TP391.4 **文献标识码:** A **文章编号:** 0372-2112 (2018)02-0440-07

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2018.02.025

Robust Visual Tracking Based on Sub-model Updating of Multiple Apparent Features

FAN Shun-yi, GUAN Hua, HOU Zhi-qiang, YU Wang-sheng, DAI Bo

(The Information and Navigation Institute of Air Force Engineering University, Xi'an, Shaanxi 710077, China)

Abstract: In computer vision tracking, the traditional model updating has poor robustness in solving the problem of occlusion, illumination change and self rotation. To improve these problems, this study proposes a new visual object tracking method. The algorithm firstly builds a candidate update sub-model library. Secondly, it determines the position and information of the current target by fusing the three complementary features of the tracking based on Particle Filter. Finally, the algorithm divides the three characteristic histogram of the target and the candidate model library to calculate the similarity of the reliability weights, then determines whether the candidate sub-model library and current sub-model can be updated. Results show that the algorithm can effectively select to update the sub-model. Rather than the contrast algorithms, our method can achieve a better tracking accuracy to deal with the situation of occlusion, illumination change and self rotation. The proposed method updates the target model effectively and keeps the good robustness under various tracking scenarios.

Key words: visual tracking; particle filter; model update; multi feature fusion; candidate sub-model library; weighted similarity

1 引言

如何适应目标的表现变化及应对背景干扰的影响是鲁棒视觉跟踪所面临的挑战之一^[1]. 其中,粒子滤波算法^[2]由于原理简单、计算复杂度低及易解决多模情况等优点已广泛应用于许多实时跟踪系统中,但由于缺少模型更新,当出现目标旋转,遮挡或光照变化时易导致跟踪失败.其他早期跟踪算法也具有此类问题^[3].

关于模型更新,往往需要考虑三个问题:(1)选择

怎样的特征才能更有效的进行模型更新?(2)大多数算法是直接对模型整体更新,如果更新目标的不同子模型分量,是否更有效?(3)如何选择恰当的更新时机?对于(1),使用多特征融合的跟踪鲁棒性优于单一特征^[4],因此其模型更新也更具有可靠性.如文献[5]针对单特征描述目标模型的缺陷,采用互补特征灰度和梯度直方图来描述;文献[6]基于相似性融合,集成多特征,计算成对模型匹配的相似度,将融合有效运用到模型更新中.针对(2),建立多子模型分量比整体更新

更具优势. 如文献[7]中提出选择性子模型更新, 将目标模型中的每个分量作为独立个体, 根据匹配贡献度大小, 选择当前帧内需更新的分量. 就(3)而言, 选择合适的门限对于更新时机尤为重要. 如封闭感知的模型更新算法^[8]利用稀疏编码确定一个强分类器, 有效判断更新区间; 文献[9]通过穷搜索跟踪确定目标, 并建立大量正负样本的预训练选择分类器, 在保留首帧同时, 在跟踪中建立 100 帧具有可靠性权值模型库, 在线持续更新模型库.

综合考虑以上三个问题及各文献, 本文提出一种多表现模型更新算法. 首先选取互补的颜色、梯度、纹理特征, 在粒子滤波中加入文献[4]融合规则, 得到跟踪结果并提取各特征直方图, 同时建立初始的候选子模型库. 不同于文献[9]将模型整体更新, 本文对候选子模型设置有效且更易于计算的可靠性权值, 然后与当前帧各特征子模型对比, 并更新候选子模型库, 最后将库中最大加权相似度值与更新阈值比较, 判断是否更新当前 3 个子模型.

2 多特征融合粒子滤波算法

2.1 粒子滤波

粒子滤波基于贝叶斯递归推理和蒙特卡洛方法对非线性非高斯系统分析^[2]. 设 $\mathbf{x}_k, \mathbf{z}_k$ 分别表示 k 时刻系统的状态和观测向量, 使用 N 个粒子构成的集合 $\{\mathbf{x}_{0:k}^i, \omega_k^i\}_{i=0}^N$ 表示状态的后验概率密度:

$$p(\mathbf{x}_{0:k} | \mathbf{z}_{1:k}) = \frac{1}{N} \sum_{i=1}^N \tilde{\omega}_k^i \cdot \delta(\mathbf{x}_{0:k} - \mathbf{x}_{0:k}^i) \quad (1)$$

式中, $\{\mathbf{x}_{0:k}^i, i=1, 2, \dots, N\}$ 是支持样本集合, 抽取自后验概率分布的状态空间. 各样本粒子权值为 $\{\omega_k^i, i=1, 2, \dots, N\}$, 且满足 $\sum_i \omega_k^i = 1$. $\tilde{\omega}_k^i$ 为归一化权值, $\tilde{\omega}_k^i = \omega_k^i / \sum_j \omega_k^j$, 重要性权值 ω_k^i 由下式得到:

$$\omega_k^i = \omega_{k-1}^i \cdot \frac{p(\mathbf{z}_k | \mathbf{x}_k^i) \cdot p(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i)}{h(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i, \mathbf{z}_{1:k})} \quad (2)$$

式中, $p(\mathbf{z}_k | \mathbf{x}_k^i)$ 为似然函数, $p(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i)$ 为概率密度转移函数, $h(\mathbf{x}_k^i | \mathbf{x}_{k-1}^i, \mathbf{z}_{1:k})$ 为重要性采样密度, 则后验滤波密度可近似为:

$$p(\mathbf{x}_{1:k} | \mathbf{z}_{1:k}) \approx \sum_{i=1}^N \omega_k^i \cdot \delta(\mathbf{x}_k - \mathbf{x}_{k-1}^i) \quad (3)$$

2.2 特征提取

2.2.1 颜色特征

传统颜色特征直方图将整个颜色空间进行均匀划分, 本文中图像按 RGB 通道划分进行直方图统计, 每个通道分为 8 个区间, 得到 $8 \times 8 \times 8 = 512$ 维.

2.2.2 HOG 特征

梯度方向直方图^[10] (Histograms of Oriented Gradi-

ents, HOG) 是描述目标边缘特征的有效算子, 使目标的表象和形状能够被梯度方向密度分布很好的描述, 在处理背景和颜色分布相近的问题上具有较强的鲁棒性, 可以弥补某些颜色直方图在跟踪中的缺陷, 但由于不具有方向和尺度不变性, 在跟踪过程中对旋转和尺度的适应性不强. 本文将图像分成 8×8 的小图像单元, 并分别计算每个单元的 HOG, 得到一个 9 维的直方图, 将每相邻 2×2 个单元组成一个块, 每块 $4 \times 9 = 36$ 维, 相邻两块部分重叠, 则共 $(8-1) \times (8-1) = 49$ 块, 最终图像得到 $49 \times 36 = 1764$ 维.

2.2.3 LBP 特征

局部二值模式^[11] (Local Binary Pattern, LBP) 是一种有效的纹理描述算子, 具有旋转及局部灰度不变性, 识别能力强, 对灰度单调变化不敏感, 计算复杂度小. 基本 LBP 是一个 3×3 的矩形块, 以中心像素的灰度值为阈值, 将其邻域 8 个灰度值与阈值相比较, 计算其 LBP 值, 例如如图 1.




图1 LBP_{8,1}纹理模式

计算公式为:

$$Lbp = \sum_{p=0}^{N-1} s(x - x_0) \cdot 2^p \quad (4)$$

式中, 指数 p 指邻域内第 p 个像素, N 表示 p 的总数, 而 $s(x)$ 是一个二值函数:

$$s(x) = \begin{cases} 1, & x \geq 0 \\ 0, & x \leq 0 \end{cases} \quad (5)$$

因此可得到一幅数值大小分布于 $0 \sim 255$ 的图像, 对其进行灰度直方图统计即可得到纹理信息.

2.3 特征融合

2.3.1 特征不确定性

特征不确定性是指特征似然函数的尖锐程度及离子的空间分布. 不同场景每种特征对目标位置估计的准确度不相同, 为描述每种特征在跟踪过程中的不确定性大小, 文献[4]提出一种自适应的特征不确定性度量:

$$U_{t+1}^i = \sigma_t \cdot H(p_t^i) \quad (6)$$

式中, σ_t 表示粒子空间分布的分散程度. 第 i 种特征下, U_{t+1}^i 表示 $t+1$ 时刻的不确定性; 似然函数 p^i 为对应的目标与候选模型的巴氏系数 (Bhattacharyya) 指标, $H(p_t^i)$ 是 t 时刻所有粒子观测概率值的熵, 表示粒子的分散程度.

2.3.2 融合策略

在假设 n 种观测特征是条件独立的情况下, 文献

[4]的融合策略中将每种特征的观测概率值加上一个正比于该特征不确定性的均匀分布,归一化处理后,结合式(6),再取乘积:

$$p(z^1 \cdots z^n | x) = \prod_{i=1}^n \left(\frac{p(z^i | x) + U^i \cdot U(x)}{1 + U^i} \right) \quad (7)$$

式中, $U(x)$ 是一个离散的均匀分布, 设粒子数为 N , 则 $U(x) = 1/N$. 这里的观测概率值即为目标与候选模型之间的相似度. 通过融合 n 种互补特征直方图信息得到的目标, 比起单一或不互补多特征更能使跟踪位置准确.

3 子模型更新

3.1 初始候选子模型库构建

设像素坐标 $X = (x, y)^T$, 第 n 帧图像信息是 $M_n(X)$, 目标区域信息是 $I_n(X)$. 由 $I_n(X)$ 可以分别得到 3 个直方图信息: $u_1(\text{Color})$ 、 $u_2(\text{HOG})$ 、 $u_3(\text{LBP})$.

本文选取前 10 帧每帧 3 种特征直方图信息组成 3×10 初始子模型库. 初始子模型为候选库首列数据, 且更新后的子模型均在候选库中.

3.2 更新策略

3.2.1 直方图相似性度量

建立初始候选库后, 需将其与每帧 3 种特征对应的直方图信息分别进行巴氏系数度量, 以更新候选子模型库. 其中, 巴氏指标是一种模型匹配指标, 当得到目标与候选模型时, 作为二者的相似性度量, 值越大, 表示越相似.

3.2.2 可靠性加权

文献[9]提出图像序列增加, 初始模型对目标的描述越来越差, 引起模型可靠性下降.

本文通过实验论证发现, 往往当前帧目标对应特征信息与相隔最近一帧的候选子模型相似度最大, 更新时便只会选择候选库中最邻近一帧的数据, 这样便失去了通过检测而选择性更新模型的意义. 在此提出一个对候选库可靠性加权的计算, 加权后的相似度为:

$$r = \rho_i - \eta_i \cdot c \quad (8)$$

ρ_i 为第 $i(i=1, 2, 3)$ 个特征的巴氏指标. η_i 为该特征对应的权值系数, 其中随着间隔帧数增加, 目标逐渐运动, HOG 特征变化相对较快, η 在相对较小时使得 r 比重微小, 增加更新可靠性, 适用于绝大多数视频序列. $c(c=1 \sim 10)$ 为子模型库数据中对应列坐标. 上式为数值相减, 即通过一个加性权值确定加权相似度值, 意味着帧数越靠前, 可靠性越大; 反之误差越大, 模型漂移可能性越大.

3.2.3 更新子模型候选库

将候选子模型库与当前帧对应特征直方图信息逐一进行巴氏系数判定, 并逐一赋予可靠性权值, 然后将同一帧不同特征对应的加权相似度值进行相加, 总共

得到 10 个加权相似度的和值. 在保留初始 3 个特征子模型的基础上, 每次替换时, 去除该和值最小的一列, 即该列数据为最不可靠的候选子模型, 候选库中被移除列的后续数据列依次前移一列, 然后将当前帧信息加入候选库, 放至最后一列.

候选库的持续在线更新具有一定的包容性且兼具更新的严谨性. 若某帧出现遮挡或光照变化等突变情况, 该帧仍进入候选库, 但在之后跟踪中的候选库更新检测时, 会很快发现该列数据的“异常”, 即相似度很低, 该帧数据会被很快剔除出候选库, 避免了候选库中候选数据出现异常, 导致模型与目标差异过大, 跟踪失败的问题.

3.2.4 更新阈值判断

更新候选子模型库后, 选取数据归一化后的候选子模型库相似度和值的最大值 r_{sum} , 与达到更新条件的阈值比较, 其中满足更新子模型的相似度值和阈值点判断为:

$$r_{sum} \geq \tau \quad (9)$$

判断表示候选库数据中与当前帧目标最相似列信息改变量不大, 即仅发生自身变化, 满足更新条件, 将该列数据标为新的当前子模型用于之后的跟踪; 反之表示目标区域出现较大改变, 可能发生遮挡或光照改变, 为避免风险不更新当前子模型.

综上所述, 为使当前各特征对应子模型能够适应目标变化, 且不因产生突变而更新使得模型漂移过大而跟丢, 在运动过程中, 目标应逐渐自适应更新模型, 即变化越小越应该更新与调整, 变化过大规避风险则应保持之前模型继续跟踪.

4 本文整体算法

算法步骤

(1) 读入视频序列.

(2) 由初始目标的颜色、HOG、LBP 特征直方图建立对应初始子模型, 并对前 10 帧进行非更新的融合粒子滤波跟踪.

(3) 建立前 10 帧 3 种特征直方图对应的 3×10 候选子模型库.

(4) 逐帧进行跟踪, 输出当前帧目标信息 $I_n(X)$.

(5) 将当前帧目标对应每种特征直方图模型都分别与候选子模型库 10 个数据进行巴氏系数判定, 3 种特征可得到 30 组数据, 然后逐一赋予可靠性权值, 最后将相同帧得出的 3 个加权相似度数据相加, 得出可能成为下一帧子模型的 10 个相似度和值, 归一化后即候选子模型结果.

(6) 将步骤(5)的结果之间进行比较, 去除对应候选库中值最小列的数据, 将当前帧对应数据加入候选

库最后一列,更新候选子模型库.

(7)将步骤(5)的结果中的最大值与子模型更新阈值 τ 比较,若大于 τ ,则将该列信息更新为当前子模型

并返回步骤(4);反之直接返回步骤(4).

流程图,如图 2 所示.

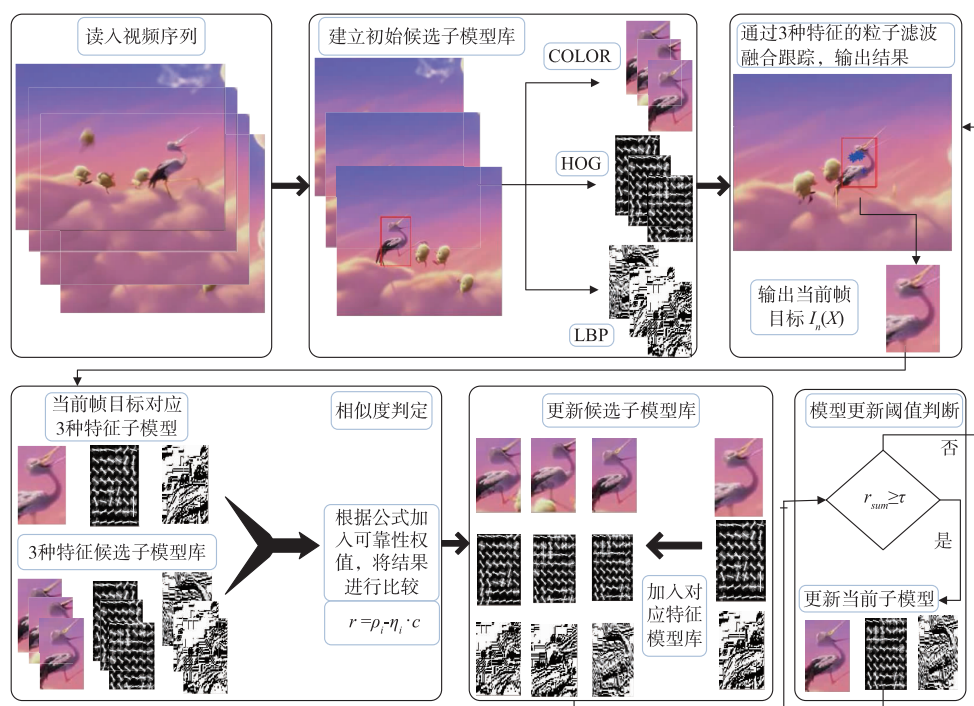


图2 算法流程图

5 实验结果对比分析

为验证本文算法的有效性,在大量的视频序列上进行测试,均表现出了较为稳定的跟踪性能.实验将本文算法(ours)与目标的真实位置(Ground Truth)、粒子滤波算法(CPF)、CT^[12]、VTD^[13]、DFT^[14]、LOT^[15]及文献[6]中 Similarity Fusion(SF)跟踪算法一同进行比较,其中,除 CPF 算法以外均有模型更新部分.本文的仿真软件为 MATLAB 7.12.0.可靠性权值 η_i 设定为(Color = 0.012, HOG = 0.009, LBP = 0.01),更新阈值 $\tau = 0.9$.

5.1 定性分析

由于篇幅有限,图 3 选取了实验结果中有代表性的 6 段视频序列,并选取其中 2 帧进行分析.

实验(a)跟踪对象为图中人物,序列中出现轻微遮挡及目标自身旋转,阻碍了跟踪完整性.86 与 333 帧目标分别出现局部遮挡和旋转,本文算法能更精确锁定目标中心.

实验(b)跟踪对象为人手中的可乐罐,序列中频繁出现遮挡、旋转和光照变化.77、181 帧目标分别出现遮挡和微小旋转,本文算法合理更新模型,保持了稳定的跟踪能力.

实验(c)跟踪对象为图中汽车,背景中存在与目标颜色、形状相似的房屋,视频中目标遭遇树木遮挡,且

目标运动速度快,尺度大幅度变化,跟踪难度增加.135、161 帧中目标分别发生轻微尺度变化及遮挡,本文算法模型漂移量小,中心位置更靠近标准点.

实验(d)跟踪对象为右边小鹿头部,跟踪过程中,目标由于快速运动造成局部模糊,且背景相似物体易造成干扰.12 与 58 帧中,本文算法有效更新模型,跟踪鲁棒性较好.

实验(e)跟踪对象为老虎玩具,序列中频繁出现遮挡、旋转和光照变化.126 与 311 帧中本文算法对目标跟踪精确,较对比算法更具模型更新有效性.

实验(f)跟踪对象为人脸部,由于光照强弱的变化,导致目标颜色特征不断变化.322 与 398 帧目标光照强弱反复变化,本文算法能够适应并获得较好跟踪鲁棒性.

5.2 定量分析

5.2.1 中心位置误差比较

中心位置误差(Center Location Error, CLE)是指跟踪结果与目标真实之间的中心位置欧氏距离,以此作为对算法跟踪精度的度量,其值越小跟踪精度越高,反之越低.图 4 为该 6 种算法对 6 段视频序列跟踪的目标中心位置误差曲线图.可以看出,本文算法相比其他对比算法,中心位置误差始终保持较低值.

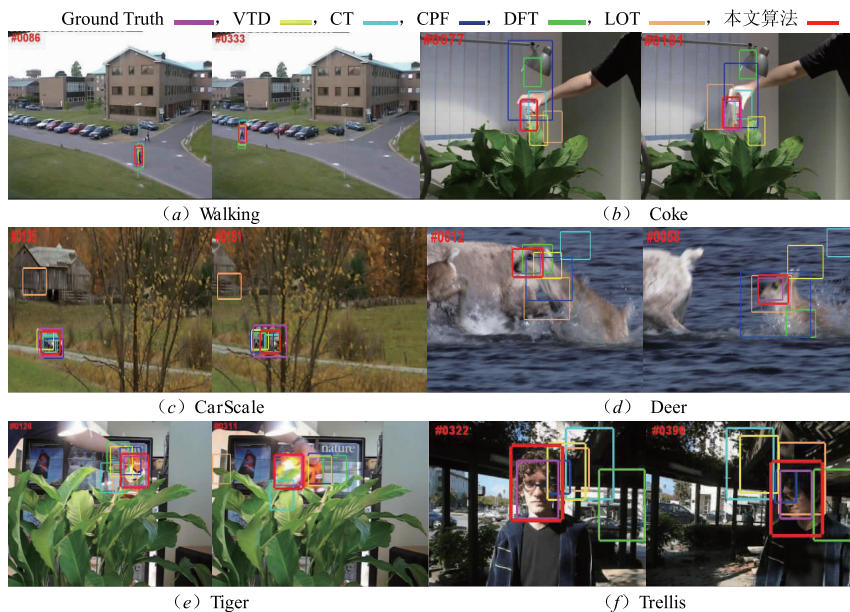


图3 算法跟踪结果比较

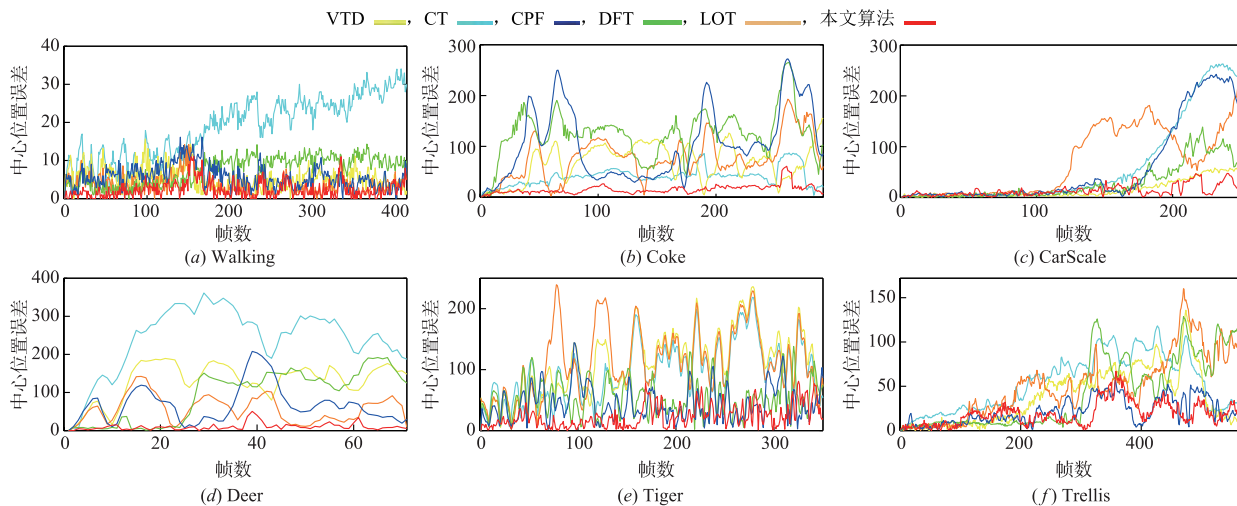


图4 中心位置误差比较

表1给出了所得的平均中心位置误差比较。数据表明,与CPF以及LOT算法相比,中心位置误差均有降低,说明通过有效模型更新提高了跟踪精度;与CT、DFT算法相比,在遮挡或光照变化强烈干扰下具有更准确的判断机制,不盲目更新模型,更好在目标小变化

及时调整模型,更能稳定跟踪目标;与VTD算法相比,本文算法整体性能相对优越;与SF算法相比,跟踪精确度上有所不足,但SF算法对特征的提取和集成主要依靠深度学习,而本文算法不需要前期大量预训练即可完成实验,有着低成本且易于操作的优势。

表1 平均中心位置误差比较

序列\算法	CPF	LOT	CT	DFT	VTD	SF*	本文算法
Walking	5.6634	3.8332	18.7534	7.5063	5.3176	2.3	2.3259
Coke	104.2281	76.9397	40.4844	110.0325	68.9282	5.9	15.4358
CarScale	57.9985	71.0212	63.6847	28.0089	15.9662	6.4	13.4517
Deer	67.8697	56.8734	242.1208	93.4671	130.5909	7.5	10.3061
Tiger	44.4894	113.0874	95.4267	54.2874	109.9829	10.3	23.1298
Trellis	21.7862	50.1371	52.7322	42.5807	37.8944	3.8	18.8196

注:其中,黑色加粗为几种算法最优,斜体为次优,SF算法数据引自文献[6].

5.2.2 精度与成功率比较

图 5 将 30 组有代表性的测试视频序列归一化的精度曲线和成功率曲线进行展示. 图 5(a) 图说明了在不同误差阈值内,跟踪到目标的帧数所占总帧数百分比;图 5(b) 图说明了在达到不同覆盖率百分比时成功跟踪到的帧数所占总帧数百分比. 本文算法与对比算法比

较可以看出综合精度与成功率最高,跟踪效果理想.

表 2 给出了 6 种跟踪算法中心位置误差阈值为 20 的精度值比较以及成功率的 AUC 指数(Area Under the Curve, 曲线覆盖面积),可以看出,本文算法跟踪效果均为最优.

表 2 精度成功率比较

指数\算法	CPF	LOT	CT	DFT	VTD	本文算法
精度	0.5103	0.5861	0.4782	0.5447	0.6233	0.6785
AUC	0.3401	0.4162	0.3287	0.4193	0.4432	0.4712

注:其中,“精度”为中心位置误差阈值为 20 的帧数百分比,“AUC”为成功率曲线的覆盖面积,加黑为最优.

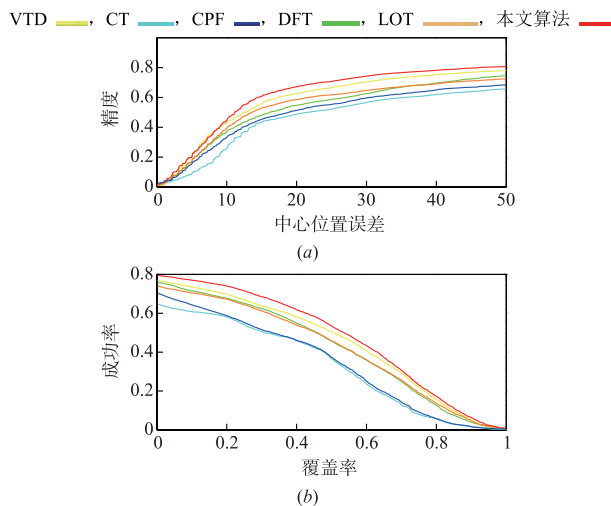


图5 精度与成功率比较

6 结论

本文针对跟踪算法存在的由于延误或无效的模型更新产生的跟踪漂移问题,从改进模型更新策略方法的角度,以粒子滤波为主要跟踪框架,多种互补特征构建候选子模型库的更新策略,提出一种多特征融合更新子模型的跟踪算法. 实验结果表明,本文算法较参考算法能够更好解决跟踪中遇到遮挡、光照变化以及自身旋转时的模型更新问题,提高了整体鲁棒性. 本文算法利用了颜色、梯度及纹理特征,因此,之后工作将会考虑空间、运动等特征信息.

参考文献

- [1] 侯志强,韩崇昭. 视觉跟踪技术综述[J]. 自动化学报, 2006,32(4):603-617.
Hou Z Q, Han C Z. A survey of visual tracking[J]. Acta Automatica Sinica, 2006,32(4):603-617. (in Chinese)
- [2] 王法胜,鲁明羽,赵清杰,等. 粒子滤波算法[J]. 计算机学报, 2014,37(8):1679-1694.
Wang F S, Lu M Y, Zhao Q J, et al. Particle filter algorithm

- [J]. Chinese Journal of Computers, 2014, 37(8):1679-1694. (in Chinese)
- [3] Wu Y, Lim J, Yang M-H. Online object tracking: a benchmark[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition[C]. Portland, United States: IEEE Press, 2013. 2411-2418.
- [4] 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. (in Chinese)
- [5] 武君胜,杨恒,李阳. 基于粒子滤波框架下的自适应多特征融合目标建模算法[J]. 西北工业大学学报, 2013, 31(5):746-752.
Wu J S, Yang H, Li Y. Object modeling algorithm based on self-adaptive multi-feature fusion in particle filter[J]. Journal of Northwestern Polytechnical University, 2013, 31(5):746-752. (in Chinese)
- [6] Zhou Y, Bai X, Liu W, et al. Similarity fusion for visual tracking[J]. International Journal of Computer Vision, 2016, 118(3):1-27.
- [7] 沈志熙,杨欣,黄席越. 均值漂移算法中的目标模型更新方法研究[J]. 自动化学报, 2009, 35(5):478-483.
Shen Z X, Yang X, Huang X Y. Study on target model update method in mean shift algorithm[J]. Acta Automatica Sinica, 2009, 35(5):478-483. (in Chinese)
- [8] Ma B, Shen J, Liu Y, et al. Visual tracking using strong classifier and structural local sparse descriptors[J]. IEEE Transactions on Multimedia, 2015, 17(10):1818-1828.
- [9] Gao C, Chen F, Yu J G, et al. Robust visual tracking using exemplar-based detectors[J]. IEEE Transactions on Circuits & Systems for Video Technology, 2015. 1-1.
- [10] Wang N Y, Shi J P, Yeung D-Y, et al. Understanding and diagnosing visual tracking systems[A]. Proceedings of the International Conference on Computer Vision, 2015[C]. Santiago, Chile: Springer-Verlag, 2015. 3101-3109.

- [11] Zhao G Y, Pietikainen M. Dynamic texture recognition using local binary patterns with an application to facial expressions[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29(6): 915 – 928.
- [12] Zhang K, Zhang L, Yang M H. Real-time compressive tracking[A]. Proceedings of the European Conference on Computer Vision [C]. Florence, Italy: Springer-Verlag, 2012. 7574(1): 866 – 879.
- [13] Kwon J, Lee K. Visual tracking decomposition[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition [C]. San Francisco, USA: IEEE Press, 2010. 119(5): 1269 – 1276.
- [14] Sevilla-Lara L, Learned-Miller E. Distribution fields for tracking[A]. Proceedings of IEEE Conference on Computer Vision and Pattern Recognition [C]. Providence: IEEE Press, 2012. 1910 – 1917.
- [15] Shaul O, Aharon B-H, Dan L, et al. Locally orderless tracking[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition [C]. Rhode Island, United States: IEEE Press, 2012. 111(2): 1940 – 1947.

作者简介



范舜奕 男, 1992 年生于陕西西安, 硕士研究生, 主要研究方向为图像处理与视觉跟踪。
E-mail: 704398924@qq.com



管 桦 男, 1962 年生于湖北孝感, 教授, 硕士生导师, 主要研究方向为图像处理与计算机视觉。