

采用在线多实例学习的超像素跟踪

王 暉¹, 王春平¹, 付 强^{1,2}, 徐 艳¹, 欧新宇³

(1. 军械工程学院, 石家庄 050003; 2. 清华大学计算机科学与技术系, 北京 100084;

3. 云南开放大学云南省干部在线学习学院, 昆明 650223)

摘要: 采用矩形框表示目标会引入背景干扰, 导致跟踪性能下降, 故利用多实例学习的特点对背景干扰建模, 提出了一种采用在线多实例学习的超像素跟踪算法。在训练阶段, 以超像素作为实例, 根据位置将这些超像素分为具有明确标签的多个实例包, 进而将跟踪转换为多实例学习问题。然后, 在所提算法中实现了在线多实例学习, 通过求实例包的似然函数最大化, 从弱分类器池中选择 K 个最优的弱分类器组合为强分类器, 在下一帧的检测阶段, 利用学习的强分类器生成目标置信图。最后, 采用粒子滤波方法从置信图中估计目标状态, 在 2.6 GHz 主频的笔记本电脑上, 所提算法的跟踪速率可达 15 frame/s。在多个视频序列上的对比实验表明, 该算法对复杂背景、目标高速运动、遮挡等具有更好的鲁棒性和精度, 且跟踪精度和成功率的典型值分别达到了 91% 和 90%, 比原始超像素跟踪算法分别高出了 21% 和 26%。

关键词: 视觉跟踪; 在线多实例学习; 超像素跟踪; 特征选择; 分类器

中图分类号: TP391 **文献标志码:** A **文章编号:** 1671-637X(2017)01-0027-06

Superpixel Tracking via Online Multiple Instance Learning

WANG Wei¹, WANG Chun-ping¹, FU Qiang^{1,2}, XU Yan¹, OU Xin-yu³

(1. Ordnance Engineering College, Shijiazhuang 050003, China;

2. Department of Computer Science and Technology, Tsinghua University, Beijing 100084, China;

3. Yunnan Province Cadres Online Learning College, Yunnan Open University, Kunming 650223, China)

Abstract: Conventional tracking methods describe the target with a bounding box. As the bounding box is likely to contain some background regions and will degrade the tracking performance, a superpixel tracking method via online multiple instance learning is proposed. In training stage, input frame is segmented into superpixels, which are divided into several instance bags with clear labels according to their location. The tracking is thus converted into a multiple instance learning problem. Then, online multiple instance learning is implemented with the algorithm. The maximum of instance bags' log-likelihood function is calculated to get K best weak classifiers, which are combined into a strong classifier. In detection stage, a confidence map is generated by the strong classifier in the subsequent frame. Finally, the state of the tracking target is estimated with the confidence map in particle filter framework. The proposed method runs at a rate of 15 frames per second on a laptop. Extensive experimental results on challenging sequences show that the proposed method performs well in terms of robustness and accuracy, especially for the target under complex background, moving at high-speed or is occluded. Compared with the original superpixel tracking, the typical values of precision and success rate of the proposed method are increased by 21% and 26%, reaching 91% and 90%, respectively.

Key words: vision tracking; online multiple instance learning; superpixel tracking; feature selection; classifier

0 引言

视觉跟踪是计算机视觉领域的研究热点, 在人机

交互、监控、增强现实等场景中有着广泛的应用^[1]。当前的跟踪算法大致可分为生成式和判别式两类^[2], 其中, 判别式跟踪又称为 Tracking-by-Learning, 通过训练分类器, 在后续帧中从背景中分离目标, 由于同时考虑了背景信息, 这类方法在复杂环境中表现出了更好的鲁棒性和抗漂移能力^[3]。

超像素^[4-5]是指由图像中一系列位置相邻且颜

收稿日期: 2015-12-08

修回日期: 2016-09-10

基金项目: 国家自然科学基金(61141009)

作者简介: 王 暉(1989—), 男, 甘肃靖远人, 博士生, 研究方向为计算机视觉、嵌入式系统设计。

色、亮度、纹理等特征相似的像素点组成的小区域,这些区域保留了后续处理的有效信息,且一般不会破坏图像中物体的边界信息,具有一定的实际意义。文献[6]提出了超像素跟踪算法,具有良好的鲁棒性,验证了超像素表达在跟踪中的有效性。与多数跟踪算法相同,超像素跟踪算法(SPT)采用矩形框表示目标,不可避免地将部分背景混杂到目标中。在训练分类器时,这些矩形框内的背景超像素被标记为目标,导致学习到的分类器性能下降,引起漂移和跟踪失败^[7-8]。

多实例学习(MIL)是一种弱监督学习方法^[9],近年来在理论和应用上均有较大发展。传统机器学习方法中一个训练样本对应一个实例,而MIL的每个训练样本对应多个实例,称为实例包,只对包进行标记而不标记实例。当包内的实例至少有一个为正时,包被标记为正;当包内实例均为负时,包被标记为负。文献[10]针对跟踪中目标的不明确问题,提出了多实例跟踪算法,有效抑制了跟踪中的漂移现象^[11];文献[12]采用扫描线的方法,将交互式分割任务建模为多实例学习问题,取得了很好的分割结果。

本文针对目标矩形框内背景超像素标记错误的问题,提出了一种采用多实例学习的超像素跟踪算法(MIL-SPT),它可分为目标检测和分类器训练(或更新)两个阶段。本文的创新点在分类器训练阶段:首先,目标矩形框内每一行(列)的若干个超像素组成一个正包,而框外背景区域的所有超像素组成一个负包,将实例(即超像素)标签不确定的问题转换为多实例学习问题;其次,为了逐帧更新分类器,本文参考文献[10]实现了在线多实例学习。对多个视频序列的实验,验证了所提算法的有效性。

1 MIL-SPT 算法

1.1 算法概述

算法的基本流程如图1所示。



图1 MIL-SPT算法的基本流程

Fig. 1 Overview of proposed MIL-SPT

第 t 帧目标的状态为 $S_t = \{r_t, c_t, w_t, h_t\}$,4个参数分别表示目标中心行列中心坐标和宽高。得到第 t 帧目标状态后(第1帧目标状态由外界给定,后续帧状态由跟踪算法估计),提取中心坐标为 (r_t, c_t) ,长宽为

$(2w_t, 2h_t)$ 的矩形区域,该区域包含了目标及邻域的背景,如图2b所示。

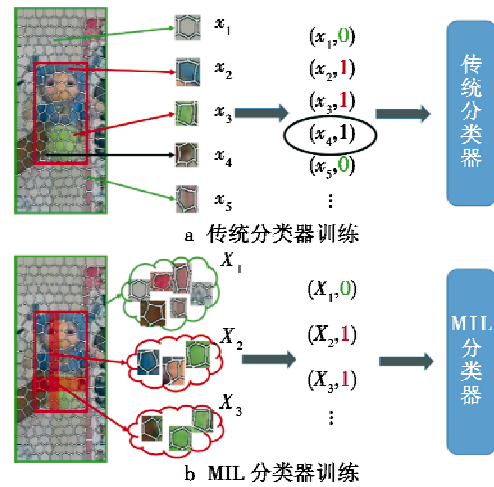


图2 判别式跟踪算法中分类器训练方式对比

Fig. 2 Comparison of training of classifiers

图2b中,红框与绿框之间的超像素均属于背景,所以这些超像素组成的样本包 X_1 为负。将红框内的目标区域在行列方向上分别分为 l 个互不重叠的矩形(如图2b中两个红色矩形块),每个矩形内的超像素组成一个样本包 $X_i, i=2, 3, \dots, (2l+1)$,其中, l 为对目标框在行列方向上的分割个数。显然,每个包都至少含有一个样本(超像素)是属于目标的,所以这些包为正。于是得到了多实例学习的训练集 $\{(X_i, y_i)\}, y_i$ 为包标签,即

$$y_i = \begin{cases} 0 & i=1 \\ 1 & \text{其他} \end{cases} \quad (1)$$

利用在线多实例学习算法(详见2.2和2.3节)训练(或更新)分类器。实验中设置 $l=7$ 。

当 $t+1$ 帧图像到来时,假设目标在相邻帧间具有连续性,所以目标包含在 $t+1$ 帧图像上中心坐标为 (r_t, c_t) ,长宽为 $(2w_t, 2h_t)$ 的矩形区域中,对该区域进行超像素分割,利用生成的分类器对每个超像素进行评分确定其属于目标的概率,生成如图1中所示的概率图。得到概率图后采用粒子滤波方法估计目标状态,具体方法参考文献[6]。

综上所述,本文算法的基本步骤为:1)输入第 t 帧图像,第 $t-1$ 帧目标 S_{t-1} ,MIL分类器;2)根据 S_{t-1} 提取候选区域,进行超像素分割;3)用MIL分类器对超像素评分,得到置信图;4)估计当前帧目标状态 S_t ;5)根据当前帧目标状态提取训练样本集,学习/更新MIL分类器;6)输出前帧目标状态 S_t ,更新的MIL分类器。

1.2 多实例学习

本文算法与传统的判别式跟踪算法的主要区别在于算法步骤5)中的学习/更新分类器,如图2所示。传统的学习算法从数据集 $\{(x_1, y_1), \dots, (x_i, y_i), \dots\}$

中学习分类器,其中, x_i 为实例(在本文中对应一个超像素), y_i 为实例标签。而多实例学习中,训练数据为 $\{(X_1, y_1), \dots, (X_i, y_i), \dots\}$, $X_i = \{x_{i1}, \dots, x_{ij}, \dots\}$ 是由多个实例组成的包, y_i 为包标签,即

$$y_i = \max_j y_{ij} \quad (2)$$

式中, y_{ij} 为实例 x_{ij} 的标签,在训练中是不确知的,如图2a所示。但是结合跟踪的特点,将实例按照图2b所示方式打包,根据式(2)可确定每个包的标签。通过最大化对数似然函数学习 MIL 分类器,即

$$L = \sum_i \ln p(y_i | X_i) \quad (3)$$

式中, $p(y_i | X_i)$ 是分类器给出的包 X_i 为 y_i 的概率。

跟踪时,为得到置信图,要对超像素评分,所以需要的 MIL 分类器 H 是针对超像素的。采用噪声-OR 模型^[13]实现对 $p(y_i | X_i)$ 的表示,即

$$p(y_i | X_i) = 1 - \prod_j (1 - p(y_i | x_{ij})) \quad (4)$$

$$p(y_i | x_{ij}) = \sigma(H(x_{ij})) \quad (5)$$

其中, $\sigma(x) = (1 + e^{-x})^{-1}$,为 sigmoid 函数。

1.3 在线多实例学习

传统的批训练(也称离线训练)要求训练时获取所有样本,而跟踪时训练样本逐帧采集,然后逐帧更新分类器,所以需要在线 MIL 算法。

本文采用 MILBoost 实现在线 MIL^[10,14]。基本思想是学习 N 个弱分类器 $h(x)$,然后加权组合为强分类器 $H(x) = \sum_n \alpha_n h_n(x)$,其中, α_n 为第 n 个分类器 $h_n(x)$ 的权重。为实现在线学习,构建大小为 $M(M > N)$ 的弱分类器池 $\{h_1, \dots, h_M\}$,在每帧估计出目标状态后,统一更新 M 个弱分类器,从池中依次选出 N 个弱分类器组成 H ,即

$$h_n = \operatorname{argmax}_{h \in \{h_1, \dots, h_M\}} L(H_{n-1} + h) \quad (6)$$

$$\alpha = L(H_{n-1} + h) \quad (7)$$

求出所有的 α_n 后,进行归一化处理。实际学习中,每个弱分类器对应一个特征,弱分类器的选择对应着选出最具判别力的特征。在更新弱分类器时,要给定实例的标签 y_{ij} ,根据文献[10],此时可用包标签代替实例标签,即 $y_{ij} = y_i$ 。

在线多实例学习的流程如下。

1) 输入:训练集 $\{(X_i, y_i)\}_{i=1}^{2+1}$, $X_i = \{x_{i1}, \dots, x_{ij}, \dots\}$ 。

2) 更新弱分类器:用当前实例样本更新 M 个弱分类器。

3) 弱分类器选择。

$H(x_{ij}) = 0$

for $n = 1$ to N 对每个 x_{ij} 进行如下操作

for $m = 1$ to M

// $H_{n-1} + h_m$ 对 x_{ij} 评分的 sigmoid,式(5)

$p^m(y_i | x_{ij}) = \sigma(H(x_{ij}) + h_m(x_{ij}))$

// $H_{n-1} + h_m$ 给出包 X_i 为 y_i 的概率,式(4)

$p^m(y_i | X_i) = 1 - \prod_j (1 - p^m(y_i | x_{ij}))$

// $H_{n-1} + h_m$ 对训练集的似然函数,式(3)

$L^m = \sum_i \ln p^m(y_i | X_i)$

end

//选择第 k 个分类器,式(6)、式(7)

$m^* = \operatorname{argmax} L^m$

$h_n = h_{m^*}$

$\alpha_n = \exp(-L^{m^*})$

$H(x_{ij}) = H(x_{ij}) + h_{m^*}(x_{ij})$

end

4) 输出:实例分类器 $H(x) = \sum_n \alpha_n h_n(x)$ 。

1.4 实现细节

跟踪中,将所有目标区域的像素大小统一为 64×64 ,超像素分割采用 SLIC 算法^[4]实现,SLIC 算法的空间距离参数和分割数分别设置为 10 和 200。

1) 超像素特征。提取每个像素在 $L * a * b$ 颜色空间和色彩名(Color Names, CN)空间^[15]的共 13 维特征($L * a * b$ 3 维, CN 特征 10 维),分别为 $L, a, b, \text{blue}, \text{brown}, \text{grey}, \text{green}, \text{orange}, \text{pink}, \text{purple}, \text{red}, \text{white}, \text{yellow}$ 。超像素特征为其包含的所有像素特征的均值。所以弱分类器池的大小 $M = 13$,跟踪中弱分类器设置为 $N = 6$ 。

2) 弱分类器。为了实现在线 MIL,需要维持一个弱分类器池,每个弱分类器对应超像素的一维特征。本文采用 K 近邻方法求弱分类器。第 t 帧的样本按标签正负可分为 D^1 和 D^0 两个集合,对某个待评分超像素 x ,在第 k 维特征空间中可从 D^1 和 D^0 中分别找到 K 个最近邻的超像素 $\{(x_{k1}^1, d_{k1}^1)\}_{k1=1}^K, \{(x_{k0}^0, d_{k0}^0)\}_{k0=1}^K, d_{k1}^1$ (或 d_{k0}^0)表示 x_{k1}^1 (或 x_{k0}^0)与 x 的特征空间距离,可得到第 k 个弱分类器定义为

$$h_k(x) = \ln[(d_{k1}^1 + \dots + d_{kK}^1) / (d_{k1}^0 + \dots + d_{kK}^0)] \quad (8)$$

即 x 与负实例距离越大,得分越高;与负实例距离越小,得分越高。KNN 算法采用 VLFeat 函数库(<http://www.vlfeat.org>)提供的 K-D 树实现,近邻个数 K 取 10。

3) 超像素样本更新。跟踪过程中目标及背景动态变化,要实时更新所有的弱分类器,但过快的更新会引起漂移,需要设计合理的更新策略。

本文中弱分类器利用 KNN 实现,更新过程就是在最初的训练集中加入新的样本实例,重新生成 K-D 树。设从第 t 帧图像提取的训练样本集为 T_t ,此时总的训练样本集更新为最近 q 帧的集合,即 $D_t = \{T_{t-q+1}, \dots, T_t\}$, q 为固定参数,综合考虑性能和实时性,在实验中设置为 $q = 10$ 。

遮挡时,如果继续更新会在训练集中引入错误信息,因此,本文采用了一个简单但有效的遮挡判断方

法。定义遮挡因子 O_t ，与给定的遮挡阈值 O_0 进行比较，如果 $O_t < O_0$ ，则判定目标被遮挡，当前帧的训练集不更新。遮挡因子定义为

$$O_t = (C_t \cdot q) / (C_{t-q} + \dots + C_{t-1}) \quad (9)$$

式中， C_t 为第 t 帧跟踪框在置信图中对应的所有像素置信度之和，表示跟踪结果的可信程度。式(9)表示当前跟踪结果的置信度与之前未遮挡的 q 帧跟踪结果置信度平均值之比，比值越大则当前跟踪结果相对越可信， O_0 设置为 0.85。

2 实验分析

为验证所提算法的性能，进行了如下实验：1) 比较 MIL 和传统学习方法，检验在超像素跟踪中引入 MIL 的合理性；2) 通过与其他相关算法对比测试，验证所提算法的有效性。实验平台为配置 2.6 GHz 处理器、4 GB 内存的普通电脑，所提算法速度约为 15 帧/s。

2.1 所提算法分析

本文通过特征选择(弱分类选择)实现在线多实例学习。图 3 所示为对图像进行超像素分割后，多实例分类器与传统分类器分别对超像素进行评分，所得置信图的伪彩色显示。

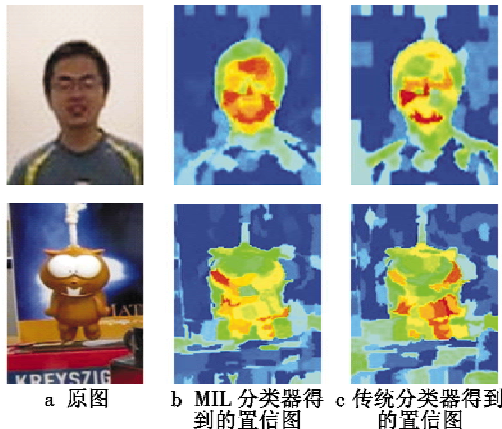


图3 置信图对比

Fig. 3 Confidence map of MIL classifier and traditional classifier

从图 3 可以看出，MIL 得到的置信图具有更清晰的目标轮廓，有利于下一步的目标定位；而传统的置信图背景干扰较为严重，容易产生不可靠的跟踪结果，导致漂移，进而降低跟踪算法性能。

表 1 为在线 MILBoost 算法在处理图 3 中第一行图像时弱分类器(或特征)及权重的选择结果，所选特征分别为 grey, L, yellow, pink, brown 和 purple。图 3 第一行原图中脸部区域比背景暗，灰色、亮度特征最具判别力，人脸偏黄色，背景墙由于光线原因偏粉色或紫色，而衣服是棕色的，所以选择了这 4 种特征。该结果验

证了本文算法在特征选择时的有效性和自适应性。

表 1 在线 MIL 算法选择的弱分类器及对应权重
Table 1 Weak classifiers and the corresponding weights of online MIL

h_1/α_1	h_2/α_2	h_3/α_3	h_4/α_4	h_5/α_5	h_6/α_6
grey/	L/	yellow/	pink/	brown/	purple/
0.25	0.23	0.19	0.16	0.11	0.06

2.2 对比实验

本文选择了与 MIL-SPT 最相关的超像素跟踪算法(SPT)^[6]、在线 Adaboost 跟踪算法(OAB)^[14]、多实例跟踪算法(MILT)^[10]进行对比实验。实验的视频序列包括 lemming, doll, basketball, skiing, carScale, boy 等，对这 6 个序列的跟踪结果如图 4 所示。

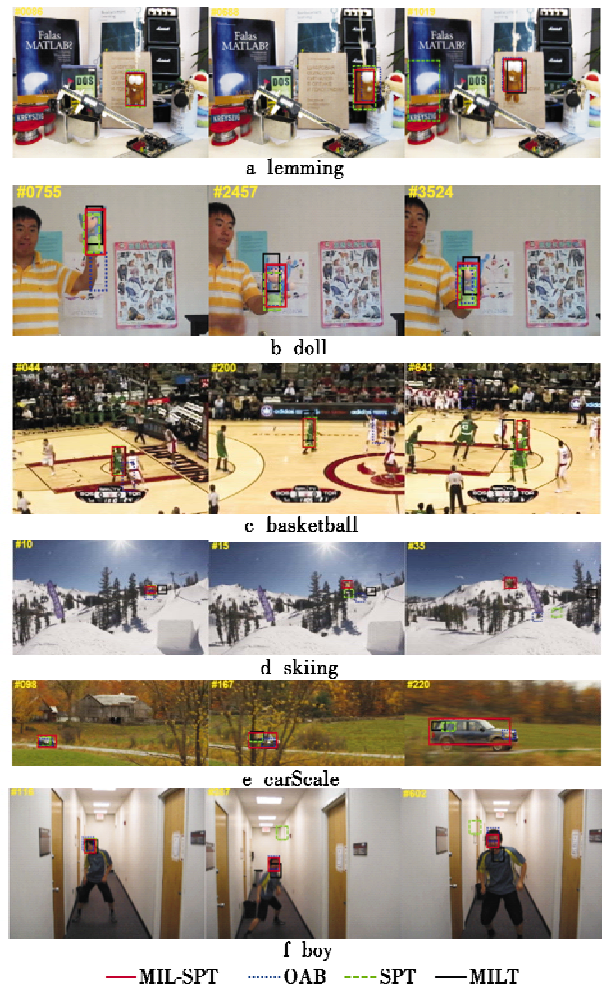


图 4 在 6 个序列上的跟踪结果

Fig. 4 Tracking results on 6 sequences

下面从算法的鲁棒性和跟踪精度两个方面对实验结果进行分析。

1) 鲁棒性。图 4 中，lemming, doll, basketball 序列中的目标在复杂背景下长时间运动，期间出现了遮挡、类目标干扰、旋转、尺度变化等情况，本文算法完整地跟踪了这 3 个序列。skiing 是一个非常有挑战性的跟踪测

试序列,第10帧时,只有MIL-SPT和SPT还在跟踪目标,表明了超像素的有效性,到第15帧时SPT算法丢失目标。只有MIL-SPT在目标持续高速运动、表现发生剧烈变化的情况下,完成了对目标精确的跟踪。序列car-Scale的跟踪结果展示了所提算法对目标尺度和遮挡的良好处理能力。上述对比实验表明,所提算法通过自适应选择超像素特征,能够应对跟踪场景中常见的遮挡、目标运动、背景复杂等挑战因素,具有良好的鲁棒性。

2) 跟踪精度。序列doll第2457帧、basketball第641帧、boy第287和620帧中所提算法对目标的跟踪更为精确,如图4所示。这得益于在线MIL算法能够选择最具判别力的特征,生成理想置信图。

为进行定量分析,本文采用精度曲线和成功率曲线对上述算法对比分析。跟踪精度指算法估计的目标位置与真实位置之间的像素距离,精度曲线度量了跟踪精度高于给定阈值的图像帧占总帧数的比例^[1]。成功率定义为算法的跟踪框与真实框的重叠率^[1],即 $score = |B_t \cap B_g| / |B_t \cup B_g|$ 。其中: B_t, B_g 分别表示跟踪框与实际框; \cap, \cup 分别表示交、并操作; $| \cdot |$ 表示区域内像素数。成功率曲线横轴为重叠率阈值,纵轴为重叠率大于某个阈值的帧数占总帧数的比例。图5和图6分别为4种跟踪算法对6个序列中所有图像帧跟踪结果的精度曲线和成功率曲线。图5、图6结果表明,所提算法性能都明显高于其他算法,尤其在跟踪精度为20、重叠率为0.5的典型值上,所提算法的两个指标分别达到了91%和90%,高于其他算法。




图5 精度曲线

Fig. 5 Precision plots




图6 成功率曲线

Fig. 6 Success rate plots

2.3 失败情况及分析

图7所示为所提算法跟踪失败的情况,图中红色与绿色框分别为真实目标与算法结果。



图7 失败情况

Fig. 7 Failure case

由于所提算法只考虑了颜色信息作为超像素特征且未对目标运动进行精确建模,而图7所示情况背景中出现了与目标外观极为相似的干扰目标,且目标本身发生了突然运动,所以所提算法跟踪失败。通过提取梯度和纹理特征,与颜色特征进行互补,同时对目标运动进行建模将有效提高算法性能,这也是下一步研究计划。

3 结论

本文对视觉跟踪中的目标表达进行了研究,基于Tracking-by-Detection框架提出了一种采用在线多实例学习的超像素跟踪算法,利用超像素分割和MIL训练分类器,解决了传统矩形框在表示目标状态时混杂背景的问题,在具体实现过程中采用扫描线的方法将超像素放入不同的样本包中。最后针对跟踪任务的特殊性,采用在线MILBoost学习超像素分类器,实现了分类器的在线更新。若干对比实验验证了所提算法的有效性和鲁棒性,该算法的运算速率为15帧/s,满足实时性要求。对实验结果的定量和定性分析表明,MIL-SPT算法具有比其他对比算法更高的跟踪精度,跟踪精度和成功率的典型值均达到了90%以上。

参考文献

- [1] WU Y, LIM J, YANG M H. Online object tracking: a benchmark [C]//IEEE Conference on Computer Vision and Pattern Recognition, 2013:1354-1362.
- [2] WANG N Y, SHI J P, YEUNG D Y, et al. Understanding and diagnosing visual tracking systems [C]//IEEE International Conference on Computer Vision, Santiago, 2015: 3101-3109.
- [3] WANG N Y, LI S Y, GUPTA A, et al. Transferring rich feature hierarchies for robust visual tracking [Z]. arXiv: 1501. 04587v1, 2015.
- [4] ACHANTA R, SHAJI A, SMITH K, et al. Slic superpixels

- compared to state-of-the-art superpixel methods [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(11):2274-2282.
- [5] RADHAKRISHNA A, SHAJI A, SMITH K, et al. Slic superpixels[R]. Technical Report 149300, EPFL, 2010.
- [6] YANG F, LU H C, YANG M H. Robust superpixel tracking [J]. IEEE Transactions on Image Processing, 2014, 23(4):1639-1651.
- [7] KWON J, JUNHA R, LEE K M, et al. Robust visual tracking with double bounding box model [C]//European Conference on Computer Vision, 2014:377-392.
- [8] NING J, ZHANG L, ZHANG D, et al. Robust mean shift tracking with corrected background-weighted histogram [J]. IET Computer Vision, 2012, 6(1):62-69.
- [9] DIETTERICH T G, LATHROP R H, LOZANO-PEREZ T. Solving the multiple instance problem with axis-parallel rectangles [J]. Artificial Intelligence, 1997, 89(1):31-71.
- [10] BABENKO B, BELONGIE S, YANG M H. Visual tracking with online multiple instance learning [C]//IEEE Conference on Computer Vision and Pattern Recognition, 2009:1003-1010.
- [11] CHEN D C, ZHU M, GAO W, et al. Real-time object tracking via online weighted multiple instance learning [J]. Optics and Precision Engineering, 2014, 22(6):1661-1667.
- [12] WU J J, ZHAO Y B, ZHU J Y, et al. MILCut: a sweeping line multiple instance learning paradigm for interactive image segmentation [C]//IEEE Conference on Computer Vision and Pattern Recognition, 2014:256-263.
- [13] VIOLA P A, PLATT J C, ZHANG C. Multiple instance boosting for object detection [C]//Advances in Neural Information Processing Systems, 2005:1417-1426.
- [14] GRABNER H, GRABNER M, BISCHOF H. Real-time tracking via on-line boosting [C]//British Machine Vision Conference, 2006:45-56.
- [15] DANELLJAN M, KHAN F S, FELSBERG M, et al. Adaptive color attributes for real-time visual tracking [C]//IEEE Conference on Computer Vision and Pattern Recognition, 2014:65-72.

(上接第 8 页)

各算法的 RMSE 计算结果如表 2 所示。

表 2 RMSE 比较 (取自然对数)

Table 2 Performance comparison (natural logarithm)

统计特性	CKF		STCKF		简化 STCKF	
	位置/ m	速度/ (m·s ⁻¹)	位置/ m	速度/ (m·s ⁻¹)	位置/ m	速度/ (m·s ⁻¹)
均值	2.72	1.65	2.46	1.38	2.46	1.38
方差	5.26	4.28	3.51	3.61	3.51	3.61

3 种算法的运行时间如表 3 所示。

表 3 运行时间比较

Table 3 Running time comparison ms

	CKF	STCKF	简化 STCKF
运行时间	426.1	526.2	457.8

对仿真结果进行分析:

1) 从图 1~图 3 及表 2 可知,在目标发生突发机动的情况下,两种滤波算法的精度及稳定性均明显优于 CKF 算法,简化的 STCKF 算法与 STCKF 算法滤波效果一致,表明对 STCKF 算法的简化没有影响原算法的滤波效果;

2) 从表 3 中看出,由于引入了渐消因子,强跟踪 CKF 算法运行时间高于 CKF 算法,而由于简化的 STCKF 算法对时间更新环节进行了简化,算法运行时间明显减少,在保证算法精度及稳定性的同时提高了实时性。

5 结束语

针对强跟踪 CKF 算法由于引入渐消因子的计算环

节而导致算法实时性下降的问题,提出了一种简化方法。首先研究了强跟踪 CKF 算法,在系统状态方程通常为线性的前提下,证明了强跟踪 CKF 算法的时间更新环节与 KF 算法的一步预测过程相一致,以此为基础,推导出一种简化的强跟踪 CKF 算法,分析了算法复杂度,进行了实验仿真。仿真结果表明,简化后的算法在保持滤波精度与稳定性的同时,实时性有了明显改善。

参考文献

- [1] 周东华,席裕庚,张钟俊.一种带多重次优渐消因子的扩展卡尔曼滤波器[J].自动化学报,1991,17(6):689-695.
- [2] 王小旭,赵琳,夏全喜,等.基于 Unscented 变换的强跟踪滤波器[J].控制与决策,2010,25(7):1063-1068.
- [3] 张文玲,朱明清,陈宗海.基于强跟踪 UKF 的自适应 SLAM 算法[J].机器人,2010,32(2):190-195.
- [4] ARASARATNAM I, HAYKIN S. Cubature Kalman filters [J]. IEEE Transactions on Automatic Control, 2009, 54(6):1254-1269.
- [5] 张鑫春,郭承军.均方根嵌入式容积卡尔曼滤波[J].控制理论与应用,2013,30(9):1116-1121.
- [6] 霍光,李冬海,李晶.基于强跟踪容积卡尔曼滤波的单站无源跟踪算法[J].现代雷达,2013,35(11):52-57.
- [7] 刘万利,张秋昭.基于 Cubature 卡尔曼滤波的强跟踪滤波算法[J].系统仿真学报,2014,26(5):1102-1107.
- [8] 何友,修建娟,张晶炜,等.雷达数据处理及应用[M].北京:电子工业出版社,2006.
- [9] 蔡宗平,牛创,戴定成.基于简化 CKF 的 IMM 算法[J].现代防御技术,2015,43(6):111-115.