




主办: 中国科学院遥感与数字地球研究所
中国图象图形学学会
北京应用物理与计算数学研究所

中国图象图形学报

2015
05
VOL.20


ISSN1006-8961
CN11-3758/TB




风场云场混合可视化



面向彩色增强图像的客观质量评价算法(第0643页)



使用柯西分布点扩散函数模型的单幅散焦图像深度恢复(第0708页)



基于蛙跳算法的离散粒子群优化端元提取(第0724页)

综述

中国图像工程: 2014

章毓晋 0585

图像分割中的超像素方法研究综述

宋熙煜, 周利莉, 李中国, 陈健, 曾磊, 闫钊 0599

图像处理和编码

结合通道共生和选择集成的彩色图像隐写分析

栗风永, 张新鹏 0609

复数基下的图像伪装算法

朱喜玲, 陈伟, 宋瑞霞, 齐东旭 0618

复杂自然环境下感兴趣区域检测

肖志涛, 王红, 张芳, 耿磊, 吴骏, 李月龙, 李峰 0625

结合调整差值变换的(K,N)有意义图像分存方案

欧阳显斌, 邵利平, 陈文鑫 0633

图像分析和识别

面向彩色增强图像的客观质量评价算法

李子印, 倪军 0643

基于局部模型匹配的几何活动轮廓跟踪

刘万军, 刘大千, 费博雯, 曲海成 0652

密集特征加权跟踪算法

罗会兰, 梅晶, 孔繁胜 0664

利用Kolmogorov-Smirnov统计的区域化图像分割

赵泉华, 张洪云, 李玉 0678

混合生成式和判别式模型的图像自动标注

李志欣, 施智平, 张灿龙, 王金艳 0687

基于协作表示残差融合的3维人脸识别

詹曙, 臧怀娟, 相桂芳 0700

图像理解和计算机视觉

使用柯西分布点扩散函数模型的单幅散焦图像深度恢复

明英, 蒋晶珏 0708

计算机图形学

用户驱动的微博可视化搜索

周霞娟, 汪飞, 金玲, 陈为, 王章野 0715

遥感图像处理

基于蛙跳算法的离散粒子群优化端元提取


吴国伟, 赵艳玲, 王龙, 倪巍, 许立江, 冉艳艳 0724

CONTENTS


JOURNAL OF IMAGE AND GRAPHICS



Objective quality assessment
for enhanced chromatic
images(P0643)



Depth recovery from a single
defocused image using a
Cauchy-distribution-based
point spread function model
(P0708)



Discrete particle swarm
optimization endmember
extraction based on shuffled
frog leaping algorithm
(P0724)

Review

Image engineering in China: 2014 Zhang Yujin	0585
Review on superpixel methods in image segmentation Song Xiyu, Zhou Lili, Li Zhongguo, Chen Jian, Zeng Lei, Yan Bin	0599

Image Processing and Coding

Steganalysis for color images based on channel co-occurrence and selective ensemble Li Fengyong, Zhang Xinpeng	0609
Image disguise algorithm based on complex number base Zhu Xiling, Chen Wei, Song Ruixia, Qi Dongxu	0618
ROI detection under the complicated natural environment Xiao Zhitao, Wang Hong, Zhang Fang, Geng Lei, Wu Jun, Li Yuelong, Li Feng	0625
Meaningful (K, M) image sharing scheme combined with the adjusting difference transformation Ouyang Xianbin, Shao Liping, Chen Wenxin	0633

Image Analysis and Recognition

Objective quality assessment for enhanced chromatic images Li Ziyin, Ni Jun	0643
Geometric active contour tracking based on locally model matching Liu Wanjuan, Liu Daqian, Fei Bowen, Qu Haicheng	0652
The dense feature-weighted object tracking Luo Huilan, Mei Jing, Kong Fansheng	0664
Regionalized image segmentation using Kolmogorov-Smirnov statistics Zhao Quanhua, Zhang Hongyun, Li Yu	0678
Hybrid generative/discriminative model for automatic image annotation Li Zhixin, Shi Zhiping, Zhang Canlong, Wang Jinyan	0687
Three dimensional face recognition by fused residual based on collaborative representation Zhan Shu, Zang Huaijuan, Xiang Guifang	0700

Image Understanding and Computer Vision

Depth recovery from a single defocused image using a Cauchy-distribution-based point spread function model Ming Ying, Jiang Jingjue	0708
--	------

Computer Graphics

User-driven visual micro-blog search Zhou Xiajuan, Wang Fei, Jin Ling, Chen Wei, Wang Zhangye	0715
--	------

Remote Sensing Image Processing

Discrete particle swarm optimization endmember extraction based on shuffled frog leaping algorithm Wu Guowei, Zhao Yanling, Wang Long, Ni Wei, Xu Lijiang, Ran Yanyan	0724
--	------

中图法分类号: 文献标识码: A 文章编号: 1006-8961(2015)05-0664-14

论文引用格式: Luo H L, Mei J, Kong F S. The dense feature-weighted object tracking[J]. Journal of Image and Graphics, 2015, 20(5): 0664-0677. [罗会兰, 梅晶, 孔繁胜. 密集特征加权跟踪算法[J]. 中国图象图形学报, 2015, 20(5): 0664-0677.] [DOI:10.11834/jig.20150509]

密集特征加权跟踪算法

罗会兰¹, 梅晶¹, 孔繁胜²

1. 江西理工大学信息工程学院, 赣州 341000; 2. 浙江大学计算机科学技术学院, 杭州 310027

摘要: 目的 当前大多数基于 Mean-shift 的跟踪算法都忽视了目标中密集的特征信息, 本文有效利用密集特征信息, 来提高跟踪的准确性。方法 在目标模型中, 常存在一些颜色特征相对聚集, 形成一定大小的特征密集区, 这些区域的面积或大或小, 对人眼视觉跟踪异常重要。这些区域形成的空间结构信息, 可以被利用到目标跟踪。提出一种高效的目标模型, 通过计算密集特征区域面积, 以及密集区质心到目标中心的距离, 构建加权系数, 通过该系数, 来增加目标中分布相对集中的特征的权值, 同时削弱离散特征的权值。同时使用零阶矩和目标模型与候选模型之间的相似度系数, 估算目标的面积; 再使用预测目标面积补偿法, 对目标中因使用背景加权法而权重被削弱的特征区域, 进行面积补偿; 最后使用估算的目标区域面积以及二阶中心距, 估算目标尺度和方向的变化。在跟踪过程中, 背景如发生较大变化, 则对目标模型进行更新。结果 本文算法具有很好的尺度适应性, 跟踪平均准确率在 94.6% 以上, 得到较当前一些先进方法更好的准确度和效率。结论 提出的算法能增加目标模型中不同特征权值间的差异, 使得构建的目标模型具有较强区分目标和背景的能力, 提高了定位目标的准确性; 面积补偿法解决了目标因特征权重被削弱, 而导致估算的目标面积小于实际面积的问题。

关键词: 目标跟踪; 尺度自适应; 密集特征加权; Mean-shift

The dense feature-weighted object tracking

Luo Huilan¹, Mei Jing¹, Kong Fansheng²

1. School of Information Engineering, Jiangxi University of Science and Technology, Ganzhou 341000, China;

2. School of Computer Science and Technology, Zhejiang University, Hangzhou 310027, China

Abstract: **Objective** Most mean-shift based object tracking algorithms neglected information on the spatial distribution of dense features. This study uses dense features to enhance the reliability of tracking. **Method** Some color features gather on tracking objects, and each feature forms a region of certain size. These dense feature regions play an important role in human vision. Information regarding the spatial structures of these dense feature regions can be used in object tracking. An effective and efficient tracking object model is presented. Intensive features are found, and the areas and distances between the dense region centroids and the target object center are calculated to obtain the weight of each feature, which is applied to describe the tracked object. The intensive features in the target model are heavier than the discrete features. Simultaneously, the zero-order moment and the similarity coefficient between the target model and candidate models are used to estimate the target area. Subsequently, an area compensation method is used to compensate the object areas that are weakened by background weighting. Finally, the estimated area and the second-order center moment are used to adaptively estimate the object scale and direction. The object models are updated when the background shows significant

收稿日期: 2014-06-24; 修回日期: 2014-12-22

基金项目: 国家自然科学基金项目(61105042, 61462035); 江西省教育厅科技项目(GJJ13421)

第一作者简介: 罗会兰(1974—), 女, 教授, 2008 年于浙江大学获计算机科学与技术专业博士学位, 主要研究领域为机器学习、模式识别。E-mail: luohuilan@sina.com

Supported by: National Natural Science Foundation of China (61105042, 61462035)

changes. **Result** Experimental results show that the proposed method can adapt well to the object scale changes, with an average tracking accuracy of $>94.6\%$. In addition, the proposed method has higher accuracy, efficiency, and robustness than some state-of-the-art methods. **Conclusion** The proposed method increases the weight difference between different features in the target model. This method is efficient in distinguishing the target from the background. The area compensation method solves the problem wherein the estimated target area is less than the actual area because of the weakened target feature weight.

Key words: object tracking; scale-adaptive; weighted dense features; Mean-shift

0 引言

在跟踪过程中,由于目标所处环境的复杂性,以及目标本身存在的各种原因,导致在视频中对目标物体的跟踪存在一定的挑战性,为了解决这些问题,已经有很多算法被提出。Kalal 等人^[1]使用 Lucas-Kanade 光流算法对目标进行跟踪,并提出利用 Forward-Backward Error 方法对跟踪结果进行取舍。Kalal 等人^[2]提出一种新颖在线跟踪学习检测方法(TLD),其中跟踪部分采用文献[1]中的 Median Flow 方法,它将传统的跟踪算法和传统的检测算法相结合来解决被跟踪目标在被跟踪过程中发生形变,部分遮挡等问题,同时通过一种改进的在线学习机制不断更新跟踪模块的“显著特征点”和检测模块的目标模型及相关参数,从而使得跟踪效果更加稳定、鲁棒、可靠。Zhang 等人^[3]提出了一种简单高效的基于压缩感知的跟踪算法(CT),首先利用符合压缩感知 RIP(restricted isometry property)条件的随机感知矩对多尺度图像特征进行降维,然后在降维后的特征上采用简单的朴素贝叶斯分类器进行分类。该跟踪算法非常简单,但是实验结果很鲁棒。文献[4,5]中,采用粒子滤波算法对目标进行跟踪,并取得较好效果。在主流的跟踪算法中,Mean-shift 跟踪算法因其简单且高效的特性得到广泛的应用,它最初是由 Fukunaga 等人^[6]提出,之后 Cheng 在文献[7]中将其引入计算机视觉领域,从此 Mean-shift 被应用到图像滤波^[8-9],图像分割^[10]和物体跟踪^[11]上。

在 Mean-shift 跟踪算法中,常使用目标的归一化加权颜色直方图来表示目标,因为它对目标的缩放、旋转和部分遮挡具有一定的鲁棒性。但归一化的颜色直方图是目标概率密度分布的离散化估计,是对目标特征数量的统计,并不包含目标特征的空

间结构信息。Comaniciu 等人^[12]提出了背景加权直方图(BWH)算法,试图通过同时减少在目标模型和候选模型中显著背景特征的分布概率,来减少跟踪时背景信息对目标的干扰,增加跟踪的稳定性。文献[13-15]对 BWH 做了进一步改进。但 Zhang 等人^[16]指出文献[12]中的 BWH 转换方法并不正确,并证明了 BWH 算法和常规的 Mean-shift 算法等效,无实质改进,进而提出了修正背景加权直方图(CBWH)算法,并取得较好的实验结果。BWH 和 CBWH 算法的出发点都是减少背景中显著特征的权值,当背景中存在的显著特征不存在于目标模型,或该显著特征在目标模型上分布极少时,它们与使用传统 Mean-shift 算法构建的目标模型并没有实质的改变。Zhang 等人^[16]提出一种基于 Mean-shift 的尺寸和方向自适应跟踪算法(SOAMST),利用包含了目标像素点密度分布情况的权重图,使用 Mean-shift 跟踪,达到较好自适应目标缩放的效果。目标候选区像素点的权重值代表该像素点属于目标的概率,所有像素点权重的总和可以用来表示目标在目标候选区的权重面积,即权重图的零阶矩大小的变动能反映目标区域大小的变化。

在目标模型中,通常存在同一特征聚集而形成的特征密集区,这些特征密集区在目标模型上的特有分布对人眼视觉跟踪异常重要。这些区域形成的空间结构信息,可以利用于目标跟踪。为了充分利用这些特征密集区,提出一种新的目标模型,首先找出目标模型中特征聚集的区域,计算出每种特征的平均区域质心到目标模型中心的距离,即质心离心距,同时算出每种密集特征的总区域面积。然后利用每种特征的质心离心距和总面积,构建一个加权系数。利用此加权系数构建一个新的目标模型,从而相对淡化目标模型中跟踪意义不大的离散特征(这些离散特征可能在目标模型总的数量可观),突出相对聚集的特征,达到提高跟踪鲁棒性的目的。

同时为了使跟踪具有尺度自适应性,在文献[17]的基础上,首先使用零阶矩和目标模型与候选模型之间的相似度系数,估算目标的面积。因为在构造目标模型时,使用了修正背景加权直方图算法,使得预测得到的目标面积小于目标真实面积,提出预测目标面积补偿法,进行面积补偿,使预测面积更加接近真实。最后利用估算的目标区域面积以及目标权重图的二阶中心距,估算目标的宽、高和方向变化。在跟踪过程中,依据背景信息变化的强度,对目标模型进行实时更新。

1 Mean-shift 跟踪算法和修正背景加权直方图方案

1.1 Mean-shift 跟踪算法

在目标跟踪中,目标被定义为一个椭圆或矩形,通常选取颜色特征空间直方图来表示目标。用 $\{x_i^*\}_{i=1,\dots,n}$ 表示目标区域,其中 n 表示该区域有 n 个像素点,每个像素点的坐标以区域中心点为原点。目标模型中, u 代表目标模型中的一种特征,目标模型表示为

$$\begin{aligned} \mathbf{q} &= \{q_u\}_{u=1,\dots,m} \\ q_u &= C \sum_{i=1}^n k(\|x_i^*\|^2) \delta[b(x_i^*) - u] \end{aligned} \quad (1)$$

式中, $\mathbf{q}$ 表示目标模型, q_u 是第 u 个特征在 $\mathbf{q}$ 上的分布概率, δ 是 Kronecker 函数, $b(x_i^*)$ 表示位于 x_i^* 的像素点对应量化颜色特征值。 $k(x)$ 是一个单调递减的函数,它为距离中心远的像素分配更小的权值。 C 为归一化系数,定义为

$$C = \frac{1}{\sum_{i=1}^n k(\|x_i^*\|^2)} \quad (2)$$

类似地,对于来自目标候选区域(中心位置为 y)的目标候选模型,其特征 $u = 1, 2, \dots, m$ 的分布概率计算为

$$\begin{aligned} \mathbf{p}(y) &= \{p_u(y)\}_{u=1,\dots,m} \\ p_u(y) &= C_h \sum_{i=1}^{n_h} k\left(\left\|\frac{y - x_i}{h}\right\|^2\right) \delta[b(x_i) - u] \end{aligned} \quad (3)$$

式中, $\mathbf{p}(y)$ 是目标候选模型, $p_u(y)$ 是第 u 个特征在 $\mathbf{p}(y)$ 上的分布概率, $\{x_i\}_{i=1,\dots,n_h}$ 是位于目标候选区的像素点,且该目标候选区中心为 y , h 是目

标候选区域的宽度,归一化常量

$$C_h = \frac{1}{\sum_{i=1}^{n_h} k\left(1 \left\|\frac{y - x_i}{h}\right\|^2\right)}$$

利用 Mean-shift 迭代算法,计算目标中心从当前位置 y 移动到新的位置 y_1 ,即

$$y_1 = \frac{\sum_{i=1}^{n_h} x_i w_i g\left(\left|\frac{y - x_i}{h}\right|^2\right)}{\sum_{i=1}^{n_h} w_i g\left(\left|\frac{y - x_i}{h}\right|^2\right)} \quad (4)$$

$$w_i = \sum_{u=1}^m \sqrt{\frac{q_u}{p_u(y)}} \delta[b(x_i) - u] \quad (5)$$

式中, $g(x) = -k'(x)$ 。为了简化计算,选函数 $k(x)$ 为 Epanechnikov 核函数^[12],即 $g(x) = -k'(x) = 1$,因此式(4)可简化为

$$y_1 = \frac{\sum_{i=1}^{n_h} x_i w_i}{\sum_{i=1}^{n_h} w_i} \quad (6)$$

通过式(6),Mean-shift 跟踪算法可以在新的一帧中找到与目标最相似的区域。同时由式(6)可知,使用 Mean-shift 算法进行目标跟踪,关键在于目标特征权值的选取。

1.2 修正背景加权直方图

在目标跟踪过程中,在检测目标区域常常存在背景信息,当目标与背景信息相似度较高时,对目标位置的定位准确性将会降低。为了减少背景显著特征对目标定位的影响,Zhang 等人^[16]提出了一个背景特征替代模型来从目标模型中选取具有区别能力的特征,即

$$q_u = C v_u \sum_{i=1}^n k(\|x_i^*\|^2) \delta[b(x_i^*) - u] \quad (7)$$

通过对包围在目标周围的背景特征信息统计,背景特征分布概率可以表示为 $\{o_u\}_{u=1,\dots,m}$ ($\sum_{i=1}^m o_u = 1$),在文献[12]中建议背景区域的大小是目标的3倍。令 O^* 值为 $\{o_u\}_{u=1,\dots,m}$ 中的最小非零值,同时令系数

$$v_u = \min(o^*/o_u, 1), u = 1, \dots, m \quad (8)$$

$$C = \frac{1}{\sum_{i=1}^n k(\|x_i^*\|^2) \sum_{u=1}^m v_u \delta[b(x_i^*) - u]} \quad (9)$$

对于同时存在于显著背景特征中的目标区域特

征, v_u 能有效降低该特征在目标候选区域的权值, 达到降低背景区域信息对目标定位的干扰。

2 密集特征加权目标跟踪算法

本文提出的密集特征加权跟踪算法的主要思想是: 找出目标中密集的特征, 增大该类特征的权值, 构建一个新的目标模型, 然后利用目标权重图信息完成目标尺度的自适应, 最后对模型进行实时更新。此算法简称为 DFWOT (the dense feature-weighted object tracking)。

为了构建目标模型, 首先从初始化图像中提取目标模型原始特征, 并对目标模型的特征分布进行统计, 找出所有特征密集区。然后, 计算出各个密集区的面积, 以及同一特征的所有密集区的平均质心, 并计算出平均质心到目标中心的距离, 简称质心离心距。最后, 利用密集特征的面积和质心离心距, 构建一个加权系数。让目标中面积越大, 质心离心距越小的密集特征的加权系数越大; 密集特征的面积越小, 质心离心距越大的密集特征的加权系数越小。对于其他没有形成一定密集区域的特征, 给予最小的加权系数。达到降低背景中显著特征权值的同时, 提高目标中密集特征的权值, 从而增大不同特征权值间的差异和区分度, 实现增加目标跟踪准确性的同时提高算法的收敛速度。其次, 利用权重图信息估算目标面积, 提出预测目标面积补偿法重新调整权重图, 对预测目标进行面积补偿, 最后利用估算的目标区域面积以及目标权重图的二阶中心距, 估算目标尺寸和方向。

2.1 密集特征表示

在图像或视频帧中, 常因跟踪目标形状不规则、光照不均匀以及物体颜色分布不均等因素, 导致即使密集的颜色特征, 其分布区域也是不规则的, 因此精准找出特征密集区域是比较困难的。为了找到并更好表达密集特征, 在构建目标模型前, 对目标区域进行分割。本文使用矩形框框选目标区域, 将目标区域以网格形式进行划分, 单元格的大小设置成 n^2 像素 (即包含 n^2 个像素点), 将目标区域进行分割。本文实验中单元格的大小设置成 5^2 像素, 将目标区域进行分割, 构成目标区域划分图, 如图 1 所示, 将目标区域划分为许多小的单元格。目标上的密集特征区域, 因此也被划分

成为多个相邻的单元格, 这些相邻的单元格共同构成一个特征密集区。




图 1 密集特征表示

Fig. 1 The dense feature

通过对目标区域的分割, 对特征密集区的寻找就变为对特征密集单元格的寻找。对整幅分割图的搜索, 以单元格为单位进行。当搜索到一个单元格时, 如果该单元格中有一种颜色特征的数目多于 n^2/k 个 (k 为 1 到 $n^2/2$ 的整数, 通过实验, k 取值 2 到 9 之间的整数时, 跟踪效果较好), 则认为该特征在该单元格密集, 同时也将该单元格以此特征进行标记。若该单元格中不存在特征个数大于 n^2/k 的特征, 则认为该单元格内不存在密集特征, 将其以 0 标记。有相同特征标记的密集区域面积的和作为此密集特征的面积。同一特征的密集区域的平均质心离心距作为此特征的质心离心距。

如图 1 所示, 以目标分割图替代需要跟踪的目标, 其中不规则连通区域 S_1 和 S_2 代表密集特征。网格将 S_1 分为 6, 7, 8, 14, 15, 16, 17, 24, 25, 26, 33, 34, 35 共 13 个单元格, 将 S_2 划分为 39, 40, 47, 48, 49, 57, 58, 59, 66, 67, 68 共 11 个单元格。在 S_1 中, 有 15, 16, 17, 24, 25, 26, 34 共 7 个单元格包含该特征的数量大于单元格像素点的四分之一 (本文实验设置 k 值为 4), 于是可用该 7 个单元格所构成的面积区域来表示密集特征区域 S_1 的面积 $A_1 = 7a$, 其中 a 为单元格的面积。 S_1 的质心离心距可用该 7 个单元格到目标模型中心的平均质心离心距表示, 即 $d_{s1} = (d_{15} + d_{16} + d_{17} + d_{24} + d_{25} + d_{26} + d_{34})/7$, 其中 $d_{15}, d_{16}, d_{17}, d_{24}, d_{25}, d_{26}, d_{34}$ 分别代表序号为 15, 16, 17, 24, 25, 26, 34 的单元格的中心到目标模型中心点的距离。同理可算出密集区 S_2 的面积 A_2

和质心离心距 d_{s2} 。若在目标区域中特征 u 的密集区只有 S_1 和 S_2 两个区域,那么它的密集区面积为 S_1 和 S_2 面积的总和,即 $S_u = A_1 + A_2$,质心离心距为 S_1 和 S_2 质心离心距的平均值,即 $d_u = (d_{s1} + d_{s2})/2$ 。

2.2 构建新的目标模型

对于在目标模型中存在密集区的特征 u ,其质心离心距 d_u 为平均质心离心距,面积 S_u 为该种特征密集面积的总和。对于不存在密集区的特征 u ,其质心离心距为所有密集特征质心离心距和的平方,面积设置为一个常量 S_u 。为了增大密集分布特征在目标定位时发挥的作用,定义一个加权系数 l_u 为

$$l_u = \begin{cases} e^{\frac{d^* - S_u}{S}} & k \geq 1 \\ 1 & k = 0 \end{cases} \quad (10)$$

式中, d^* 是所有密集特征中质心离心距的最小非零值, S 为目标模型面积, k 表示特征 u 的密集区个数, e 为自然指数。由式(10)可知,当目标模型中的一种特征聚集的区域面积越大,质心离心距越小,其特征加权系数就会越大,在目标定位时,该特征就能够发挥更大的作用。同时为了降低背景中显著特征的权值,结合加权系数 l_u 与抑制背景相似特征系数 v_u (式(8))得到目标特征加权系数: $f_u = v_u \times l_u$ 。

通过系数 f_u 构建新的目标模型的 q_u ,即

$$q_u = C_f f_u \sum_{i=1}^n k(\|x_i^*\|^2) \delta[b(x_i^*) - u] \quad (11)$$

式中,归一化常量

$$C_f = \frac{1}{\sum_{i=1}^n k(\|x_i^*\|^2) \sum_{u=1}^m f_u \delta[b(x_i^*) - u]}$$

假设目标候选区上像素点 x_i 的特征标签为 u' ,则有 $\delta[(b(x_i) - u')] = 1$, 当 $u \neq u'$ 时, $\delta[(b(x_i) - u)] = 0$, 因此像素点 x_i 的权值计算式(5)可以简化为

$$w_i = \sqrt{\frac{q_{u'}}{p_{u'}(y)}} \quad (12)$$

将新目标模型的 q_u (式(11))和目标候选模型的 $p_u(y)$ (式(3))代入式(12)后,像素点 x_i 的权值计算为

$$w_i = \sqrt{\frac{C_f f_{u'} \sum_{i=1}^n k(\|x_i^*\|^2) \delta[b(x_i^*) - u']}{C_h \sum_{i=1}^{n_h} k\left(\left\|\frac{y - x_i}{h}\right\|^2\right) \delta[b(x_i) - u']}}$$

引入归一化因子 C (式(2)), 则有

$$w_i =$$

$$\sqrt{\frac{C}{C_h} \cdot \frac{C_f f_{u'} \sum_{i=1}^n k(\|x_i^*\|^2) \delta[b(x_i^*) - u']}{\sum_{i=1}^{n_h} k\left(\left\|\frac{y - x_i}{h}\right\|^2\right) \delta[b(x_i) - u']}} = \sqrt{\frac{C_f f_{u'}}{C}} \cdot \sqrt{\frac{q_{u'}}{p_{u'}(y)}}$$

又常量 $\sqrt{C_f/C}$ 对 Mean-shift 跟踪没影响,所以可以省略它,即可得到简化的像素点 x_i 的权值计算公式为

$$w_i = \sqrt{f_{u'}} \cdot \sqrt{\frac{q_{u'}}{p_{u'}(y)}} \quad (13)$$

背景加权系数的作用是降低存在于目标模型中的背景显著特征的权值,而目标密集特征加权系数的作用是加大目标模型密集分布的特征权值,所以结合两者的加权系数 f_u 能进一步增大目标模型特征权值间的差别,使具有区分度的特征在目标模型中起到主要作用,提高目标定位的准确度和收敛速度。假设目标中只有红,绿,蓝,黄4种颜色特征,且这4种颜色特征中,分布密度由大到小依次为红,绿,黄,蓝,且绿色特征为零散分布的特征,不存在密集区,蓝色和黄色两种特征密集区的面积相当,但黄色特征密集区的质心离心距要小于蓝色(示例图见图1)。利用 f_u 得到如图2所示的颜色特征权值分布直方图,使得具有重要判别性的密集红色特征的权值与其他特征的权值差异很大。




图2 特征权值分布直方图示意图

Fig. 2 The distribution histogram of the features' weight

2.3 基于密集特征的目标区域尺寸和方向的预测

使用2.2节的方法,根据式(13)得到目标各个像素点的权值,这些权值能组成一幅权重图,并用其替代传统的权重图(使用式(5)构成的权重图),目标权重图的零阶矩为

$$M_{00} = \sum_{i=1}^n w(x_i) \quad (14)$$

目标权重图的零阶矩大小的变动能反映目标区域大小的变化^[17],为了估算出目标真实面积,提出了估算目标面积的方法,即

$$A = c(\rho) M_{00} \quad (15)$$

式中, $c(\rho)$ 是 ρ 的一个单调递增函数 ($0 \leq \rho \leq 1$), ρ 为目标候选模型与目标模型的相似度系数。根据经验通常选取 $c(\rho) = \exp\left(\frac{\rho-1}{\sigma}\right)$, σ 为常数。可以通过权重图一阶距和零阶矩的比值,得出目标候选区几何中心点。其中权重图一阶距为

$$M_{10} = \sum_{i=1}^{n_h} w_i x_{i,1}, M_{01} = \sum_{i=1}^{n_h} w_i x_{i,2}$$

式中, $(x_{i,1}, x_{i,2})$ 为像素点 i 在候选区相应的坐标, n_h 为目标候选区像素点的个数。

$$y_1 = (\bar{x}_1, \bar{x}_2) = (M_{10}/M_{00}, M_{01}/M_{00}) \quad (16)$$

$(\bar{x}_1, \bar{x}_2)$ 代表目标候选区的几何中心点。而二阶中心距能包含目标的形状和方向信息,权重图二阶距为

$$M_{20} = \sum_{i=1}^{n_h} w_i x_{i,1}^2$$

$$M_{02} = \sum_{i=1}^{n_h} w_i x_{i,2}^2$$

$$M_{11} = \sum_{i=1}^{n_h} w_i x_{i,1} x_{i,2}$$

为了估算目标的宽、高以及方向,利用协方差矩

阵, $Cov = \begin{bmatrix} u_{20} & u_{11} \\ u_{11} & u_{02} \end{bmatrix}$, 将其转化为 SVD 矩阵, 即

$$Cov = \begin{bmatrix} u_{11} & u_{12} \\ u_{21} & u_{22} \end{bmatrix} \times \begin{bmatrix} a^2 & 0 \\ 0 & b^2 \end{bmatrix} \times \begin{bmatrix} u_{11} & u_{12} \\ u_{21} & u_{22} \end{bmatrix} \quad (17)$$

式中, $u_{20} = M_{20}/M_{00} - \bar{x}_1^2$, $u_{02} = M_{02}/M_{00} - \bar{x}_2^2$, $u_{11} = M_{11}/M_{00} - \bar{x}_1 \bar{x}_2$ 。

如果用椭圆来表示目标模型形状,那么 a 和 b 分别代表目标的长半轴和短半轴。其中向量 $[u_{11}, u_{21}]^T$ 和 $[u_{12}, u_{22}]^T$ 分别代表真实目标区域两坐标轴(长半轴和短半轴)的轴方向。

2.4 目标预测面积补偿

对目标进行建模时,同时使用了背景加权法和密集特征法,使得目标各个特征的权值均得到不同程度

的削弱,导致目标所有像素点权重的总和变小,估算的目标面积小于实际面积。为了获得正确的目标面积,需要对估算目标进行面积补偿。首先使用普通的归一化权值颜色直方图方法,得到目标特征权值图的所有像素点权重总和,使用式(5)计算出目标模型的权值 w'_i , 由该权值组成的权重图的零阶矩为

$$M'_{00} = \sum_{i=1}^n w'(x_i) \quad (18)$$

为了使得目标特征权值在具有较大区分度的同时,又能反映目标真实面积,使用式(19)对基于密集特征加权得到的目标权重图进行补偿,构建新的目标权值用于估算目标的尺度和方向,即

$$w_i = (M'_{00}/M_{00}) \times w_i \quad (19)$$

这样得到的目标权值图,既具有对目标模型中密集特征与零散特征,以及目标特征与背景特征区分的能力,也让预测目标区域大小更加接近目标真实尺度。

2.5 目标模型的更新

在跟踪过程中,目标背景常会随着目标的移动而发生变化,此前构建的目标模型已不能有效区分目标和背景,所以需要目标模型进行实时更新。

在跟踪新的一帧时,首先统计该帧背景特征分布概率,表示为 $\{o'_u\}_{u=1,\dots,m}$ ($\sum_{i=1}^m o'_u = 1$), 如果 $\sum \sqrt{o_u o'_u} < 0.5$ 其中 o_u 为构建当前目标模型所使用的背景特征分布概率模型,则认为背景发生了较大变化,更新背景特征的分布概率,即 $o_u = o'_u$ 。再利用式(8)重新计算抑制背景相似特征系数 v_u , 结合加权系数 l_u (式(10))得到新的目标特征加权系数 $f_u = v_u \times l_u$, 再使用式(11)结合新的目标特征重新构建目标模型 q , 完成目标模型的更新。

DFWOT 跟踪算法步骤如下:

1) 首先通过式(1)计算目标模型 q , 然后计算出背景特征概率分布 $\{o_u\}_{u=1,\dots,m}$, 最后通过式(8)(10)分别算出 $\{v_u\}_{u=1,\dots,m}$ 和 $\{l_u\}_{u=1,\dots,m}$ 。构建加权系数 $\{f_u\}_{u=1,\dots,m}$, 利用加权系数通过式(11)构建目标模型 q 。在第一帧中初始化目标候选区的位置 y_0 。

2) 迭代次数 $k \leftarrow 0$ 。

3) 在当前帧,通过式(2)计算出目标候选区模型。

4) 通过式(13)计算出 $\{w_i\}$, 通过式(5)算出

$\{w'_i\}$, 然后通过式(19)构建全新的权重图。

5) 通过式(6)计算目标候选区的新位置 y_1 。

$d \leftarrow \|y_1 - y_0\|$, $y_0 \leftarrow y_1$, $k \leftarrow k + 1$ 。设置收敛阈值为 ε_1 (默认值为 0.1), 最大迭代次数 N (默认为 15)。

如果 $d < \varepsilon_1$ 或 $k \geq N$, 则停止迭代, 输出预测目标位置, 并通过式(17)估算目标的尺寸和方向, 进入下一帧, 并计算背景特征概率分布 $\{o'_u\}_{u=1, \dots, m}$ 。

若 $\sum \sqrt{o_u o'_u} < 0.5$, $o_u = o'_u$, 返回步骤 1);

否则返回步骤 2)。

否则返回步骤 3)。

DFWOT 算法流程示例图如图 3 所示。首先, 在第 1 帧中, 依据目标颜色特征的概率密度分布, 构建初始目标模型。利用目标密集特征信息构造密集特征加权系数, 同时根据背景显著特征信息 (背景区域限定为: 与目标矩形具有相同中心点,

长宽均为目标矩形长宽的 2 倍, 且不包含目标矩形的区域) 构造背景特征加权系数。然后用密集特征加权系数和背景特征加权系数构造出目标特征加权系数, 并得到目标模型。利用预测面积补偿法, 构建出能反映目标真实尺寸和方向信息的权重图。在后续帧中 (第 2, $\dots$, N 帧), 依据上一帧的目标位置, 计算当前帧中的背景显著特征信息, 并计算当前帧和上一帧的背景相似度, 当相似度不小于阈值 0.5 时, 认为背景变化不明显, 利用上帧中的目标模型对当前帧的目标位置进行预测; 当相似度小于 0.5, 则认为背景发生明显变化, 用当前背景显著特征信息构造新的背景特征加权系数, 完成对背景的更新, 结合第 1 帧中的密集特征加权系数, 以及依据目标颜色特征概率密度构建的初始目标模型, 重新构建目标模型, 对当前帧目标位置进行预测。




图 3 DFWOT 算法流程示例图

Fig. 3 The flow diagram of DFWOT algorithm

3 实验结果及分析

实验的硬件环境为 Intel Core i3 2.4 GH, 内存 2 G, 显存 1 GMB。操作系统是 32 位 WINDOWS 7, 仿真软件为 Matlab 2012b。在实验中, 单元格的大小设置为 5^2 个像素(实验效果较好)。候选目标搜索范围是在上帧目标基础上向四周扩大 7 个像素点的区域, 这是基于运动连续的假设, 也是目前基于 Mean-shift 跟踪算法常采用的方法。Mean-shift 收敛

阈值为 0.1, 最大迭代次数为 15, 背景相似度系数阈值为 0.5, 目标模型中离散特征所占最大面积设置为单元格面积的四分之一(实验测试选取该值效果较好), 即 k 值设为 4, $\sigma = 1.6$ 。数据集 racecar, mountainbike, tours 使用 RGB 颜色空间作为特征空间, 且量化为 $16 \times 16 \times 16$ 。数据集 panda, Vid_A_ball, waking 使用 HSV 颜色空间作为特征空间。

采用具有挑战性的 6 组图像序列, 并对它们进行长时间跟踪, 实验中使用的图像序列信息如表 1 所示。

表 1 测试图片序列信息
Table 1 The information of the test image sequence

视频序列	类型	注释	帧数	初始目标位置(左上和右下坐标)
racecar ^[18]	刚体	缩放, 运动	564	392, 127, 466, 187
mountainbike ^[19]	人	旋转, 缩放, 运动	228	340, 183, 377, 231
tours ^[20]	物体	旋转, 缩放, 运动	264	166, 81, 220, 133
panda ^[2]	动物	旋转, 缩放, 运动	2 727	56, 99, 90, 123
Vid-A-ball	刚体	缩放, 运动	603	203, 112, 249, 159
waking	人	缩放, 运动	200	692, 443, 720, 517

注: Vid_A_ball 和 waking 序列来自 BoBoT 视频库(bonn benchmark on tracking)。

实验中参与对比的算法为 SOAMST^[17], CBWH^[16], CT^[3], TLD^[2] 以及 SPT^[21], 所使用的代码和参数设置均来自文献作者的个人网站。其中 SOAMST 算法参数设置为: 选择 RGB 颜色特征空间, 并量化为 $16 \times 16 \times 16$, 每帧的搜索范围是将上帧目标所在区域坐标, 在当前帧中向四周扩大 7 个像素点大小的区域, $\sigma = 1.6$ 。CBWH 算法参数设置为: Mean-shift 收敛阈值为 0.1, 每帧的搜索范围是将上帧目标扩大 7 个像素点大小的区域, 最大迭代次数为 15, 使用 RGB 颜色空间作为特征空间, 且量化为 $16 \times 16 \times 16$ 。CT 参数设置为: 训练负样本个数为 50, 每帧在上一帧跟踪到的目标区域周围扩大 4 个像素点的区域采样, 搜索窗口大小为 20×20 , 学习参数 $\lambda = 0.85$, 弱分类器的数量为 50。TLD 参数设置为: 最小框大小为 24×24 , 模板设置大小为 15×15 , 随机森林分类器过滤使用阈值为 10×0.6 , 更新模板库阈值为 0.65, 负模板库的更新阈值为 0.5, 初始用来训练的负样本数为 100, 待匹配模板与正负模板匹配的相似度系数

为 0.95。SPT 参数设置为: 使用 HIS 颜色空间, 均值漂移聚类的带宽为 0.18, 超像素的权重和数量分别设置为 10 和 300, 视频序列的前 4 帧用于样本的训练。

3.1 不同跟踪算法效果对比

图 4 为 6 种算法在 6 个不同数据集上跟踪的效果示例图。图 4 的效果显示, 提出的 DFWOT 算法能较好的定位目标, 且能较为准确地自适应目标的尺寸和方向, 本文使用的其他 5 种对比算法, 对目标的定位均出现了不同程度的偏离, 且自适应目标的效果远不如 DFWOT 算法。

图 5 为本文 DFWOT 算法和 SOAMST, CBWH, CT, TLD 以及 SPT 算法在 6 个数据集上的跟踪误差分析。横坐标为图像序列帧数变化, 纵坐标为预测得到的目标中心位置 and 实际目标中心位置之间的偏差。偏差越小, 预测位置越接近真实目标位置, 跟踪定位越精确。其中图 5(f) panda 曲线空白段为目标在图像上消失所导致的。由图 5 可知, DFWOT 算法相对其他 5 种算法, 跟踪相对更稳定和更精确。




图4 实验跟踪结果

Fig. 4 Experimental results




图5 DFWOT,SOAMST,SPT,CWBH,CT 和 TLD 跟踪误差

Fig. 5 The tracking error between DFWOT,SOAMST,SPT,CWBH,CT and TLD

DFWOT 算法与 SOAMST,CBWH,CT,TLD 以及 SPT 在 6 个数据集上的跟踪目标中心位置误差的平均值比较结果如表 2 所示,除 waking 数据集外,在其他 5 组数据集上,DFWOT 算法的平均误差最小。数据集 waking 中,使用 SPT 跟踪算法的平均误差最小,其次为 DFWOT 算法,DFWOT 算法的误差较 SPT 仅仅小 3.283 4 个像素点。结合图 5 的误差曲线图,DFWOT 算法能对目标持续定位跟踪,相对其他 5 种算法,表现出较好的稳定性,且在目标发生形变后,也有较好的跟踪效果。

3.2 不同算法预测目标面积效果对比

图 6 为 DFWOT 算法与 SOAMST,CBWH,CT,TLD 以及 SPT 算法在 6 个不同数据集上的预测目标面积效果对比图。图 6 中纵坐标表示预测目标面积减去目标真实面积,所以纵坐标的值越接近零值,表明预测越准确。其中图 6(d) panda 曲线空白段为目标在图像上消失所导致的。因 CBWH 跟踪算法和 CT 跟踪算法所提供的源代码并不具备自适应目标尺寸缩放的能力,两种算法采用固定大小的窗口进行跟踪,所以图 6 中,CBWH 和 CT 算法曲线发生重叠。

表 2 DFWOT,SOAMST,CBWH,CT,TLD 及 SPT 算法在各个图片序列中的中心位置误差平均值比较

Table 2 The average center error between DFWOT,SOAMST,CBWH,CT,TLD and SPT in each image sequence

算法	racecar	mountainbike	tours	panda	Vid_A_ball	waking
DFWOT	2. 597 9	7. 086 8	3. 792 7	39. 766 6	2. 498 9	8. 717 6
SOAMST	193. 430 0	19. 357 5	14. 930 2	95. 743 0	3. 561 5	10. 257 5
CT	215. 692 1	7. 842 4	66. 379 5	100. 140 0	50. 313 1	7. 895 8
SPT	8. 881 8	9. 378 3	7. 784 1	90. 652 3	3. 053 8	5. 434 2
CBWH	11. 206 2	14. 928 9	9. 398 5	110. 578 2	4. 562 0	11. 453 8
TLD	31. 754 3	164. 634 2	43. 643 2	56. 745 3	42. 527 4	45. 799 2




图 6 DFWOT,SOAMST,SPT,CBWH,CT 和 TLD 预测目标面积误差比较

Fig. 6 The estimate target area error between DFWOT,SOAMST,SPT,CBWH,CT and TLD

如图6所示,DFWOT算法在6组实验数据集中,预测目标面积只在少数帧中出现较大偏差,预测的面积误差基本维持在1000个像素点以内,甚至更小(数据集 mountainbike, Vid_A_ball 中,预测面积误差在400个像素点以内。数据集 waking 在前160帧,也能把面积预测误差控制在400个像素点以内),这样就保证了算法在对目标运动跟踪过程中,能较好的完成自适应的缩放,让预测的区域不过多的包含目标以外的部分的同时,也最大可能的包含目标所有区域。而其他5种对比算法在6组数据集中预测的目标面积不同程度的包含了较大(相对目标区域)的背景信息。图6(f) Vid_A_ball 中,除DFWOT外的其他5种算法对应的曲线有明显的波峰和波谷,这是因为在这些帧中出现干扰物和跟踪目标速度的瞬间变化,导致该5种算法预测的目标面积出现较大偏差,而DFWOT算法表现出较强的抗干扰能力。

3.3 不同算法速度对比

DFWOT和SOAMST,CBWH,CT,TLD,SPT算法在6组数据集上的跟踪总耗时对比如表3所示,显

示的是测试6次的耗时平均值。

表3显示,CT和CBWH算法耗时相对其他4种算法具有明显的优势,这是因为CT和CBWH只考虑到对目标的定位,并未做目标自适应的工作。在DFWOT,SOAMST,SPT以及TLD算法中,除数据集 racecar 外,DFWOT在其他5组数据集中耗时最少,有较快的处理速度。racecar 序列中,从图5(a)可知,SOAMST算法在 racecar 序列,从第99帧开始丢失目标,以后的跟踪都是无效的,而DFWOT算法全程较精准跟踪目标,且在前99帧中,DFWOT算法6次实验平均耗时31.9984s,而SOAMST平均耗时为56.4266s,DFWOT算法运行速度较SOAMST有明显优势。从图6可知,在不丢失目标的情况下,整体而言DFWOT算法预测得到的目标面积最接近目标实际面积,而SOAMST预测得到的目标面积大于目标实际面积,这就导致了使用SOAMST算法对目标进行预测时,目标候选区域变大,加大了目标匹配时的计算量,从而导致耗时增加。而本文提出的DFWOT算法能更加精确预测目标面积,所以在跟踪速度上有明显优势。

表3 DFWOT,SOAMST,CBWH,CT,TLD及SPT算法跟踪耗时

Table 3 The time has been take by the tracking algorithm between DFWOT,SOAMST,CBWH,CT,TLD and SPT

算法	racecar	mountainbike	tours	panda	Vid_A_ball	waking
DFWOT	123.341 2	37.814 1	46.460 1	250.547 2	101.266 5	40.929 8
SOAMST	90.470 6	78.701 4	68.817 1	507.153 5	137.067 0	58.585 8
CT	47.403 7	18.959 7	17.301 3	230.153 5	38.267 3	20.897 8
SPT	25 140.765	14 945.262	23 310.309	38 140.765	32 270.035	1 068.309
CBWH	31.456 3	10.309 9	10.070 5	109.329	22.826 5	12.649 0
TLD	254.739	174.794	155.342	579.535	130.247	164.334

3.4 DFWOT与CBWH,Mean-shift算法特征权值对比

DFWOT算法、CBWH算法,以及Mean-shift算法在跟踪过程中,所选取的特征均为颜色特征。图7所示为分别在 racecar, mountainbike, tours, panda, Vid_A_ball, waking 共6组数据集上使用DFWOT,CBWH算法和Mean-shift算法得到的目标模型中权值非零的特征权值分布图。图7显示,通过使用DFWOT算法能明显提升目标密集特征的权值,DF-

WOT算法能有效增大不同特征权值之间的区分度。

4 结 论

提出的DFWOT算法能在利用背景信息的同时,充分利用目标颜色特征的空间分布结构,通过计算出目标的颜色特征密集区的面积,以及平均质心离心距,进而构建特征加权系数,并利用加权系数构建出新的目标模型。在预测目标面积之前,对目标




图7 非零特征权值的分布

Fig. 7 The distribution of the nonzero feature-weighted

权重图进行补偿,然后通过目标特征权重图,估算出目标尺寸和方向信息。并依据背景变化的剧烈程度,判断是否对目标模型进行更新。提出的目标模型能在降低目标模型中背景显著特征权值同时,提升目标密集特征权值,较为正确的预测目标区域,让预测的区域较少的包含除目标以外的信息,有利于减少迭代搜索的次数,从而减少整个跟踪过程中所使用的时间。实验结果表明,本文算法能有效定位目标,对目标尺寸和方向有较好的自适应性,且能做到实时跟踪。同时实验结果表明无论是采用 RGB 颜色特征空间,还是 HSV 颜色特征空间,提出的跟踪算法都有相对更好的跟踪效果,意味着本文提出的密集特征加权思想可以应用于不同的特征,提高目标显著特征的区分度,从而提高跟踪效果和效率。

参考文献 (References)

- [1] Kalal Z, Mikolajczyk K, Matas J. Forward-backward error: automatic detection of tracking failures [C] // Proceeding of the 20th International Conference on Computer Vision and Pattern Recognition. Istanbul: IEEE Computer Society, 2010: 2756-2759.
- [2] Kalal Z, Mikolajczyk K, Matas J. Tracking-learning-detection [J]. IEEE Transactions on Pattern Analysis And Machine Intelligence, 2012, 34(7): 1409-1422.
- [3] Zhang K, Zhang L, Yang M H. Real-time compressive tracking [M] // Computer Vision-ECCV 2012. Berlin: Springer, 2012: 864-877.
- [4] Zha Y, Cao T Y, Huang H, et al. Object tracking based on learning a dictionary joint practical filter [J]. Journal of Image and Graphics, 2013, 18(12): 1628-1636 [查泽, 曹铁勇, 黄辉, 等. 字典学习联合粒子滤波鲁棒跟踪 [J]. 中国图象图形学报, 2013, 18(12): 1628-1636.] [DOI: 10. 11834/jig. 20131211]
- [5] Zhang Q R, Feng X Y. Object tracking based on visual saliency and particle filter [J]. Journal of Image and Graphics, 2013, 18(5): 515-522 [张巧荣, 冯新扬. 利用视觉显著性和粒子滤波的运动目标跟踪 [J]. 中国图象图形学报, 2013, 18(5): 515-522.] [DOI: 10. 11834/jig. 20130504]
- [6] Fukunaga K, Hosteller L. The estimation of the gradient of a density function, with applications in pattern recognition [J]. IEEE Transactions on Information Theory, 1975, 21(1): 32-40.
- [7] Cheng Y. Mean shift, mode seeking, and clustering [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1995, 17(8): 790-799.
- [8] Comaniciu D, Ramesh V, Meer P. Real-time tracking of non-id objects using mean shift [C] // Proceedings of Computer Vision and Pattern Recognition, Hilton Head Island, SC: IEEE, 2000, 2: 142-149.
- [9] Comaniciu D, Ramesh V. Mean shift and optimal prediction for

- efficient object tracking[C]// Proceedings of Image Processing, Vancouver, BC: IEEE, 2000, 3: 70-73.
- [10] Comaniciu D, Meer P. Mean shift: a robust approach toward feature space analysis[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2002, 24(5): 603-619.
- [11] Vojir T, Neskova J, Matas J. Robust Scale-Adaptive Mean-Shift for Tracking[M]//Image Analysis. Berlin Heidelberg: Springer, 2013: 652-663.
- [12] Comaniciu D, Ramesh V, Meer P. Kernel-based object tracking[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2003, 25(5): 564-577.
- [13] Jeyakar J, Babu R V, Ramakrishnan K R. Robust object tracking with background-weighted local kernels[J]. Computer Vision and Image Understanding, 2008, 112(3): 296-309.
- [14] Li L, Feng Z. An efficient object tracking method based on adaptive nonparametric approach [J]. Optoelectronics Review, 2005, 13(4): 325-330.
- [15] Allen J G, Xu R Y D, Jin J S. Mean shift object tracking for a SIMD computer[C]//Proceedings of the 3rd International Conference on Information Technology and Applications. Washington DC: IEEE, 2005, 1: 692-697.
- [16] Ning J, Zhang L, Zhang D, et al. Robust mean-shift tracking with corrected background-weighted histogram[J]. Computer Vision, IET, 2012, 6(1): 62-69.
- [17] Ning J, Zhang L, Zhang D, et al. Scale and orientation adaptive mean shift tracking[J]. Computer Vision, IET, 2012, 6(1): 52-61.
- [18] Bretzner L, Lindeberg T. Qualitative multi-scale feature hierarchies for object tracking[M]//Scale-Space Theories in Computer Vision. Berlin Heidelberg: Springer, 1999: 117-128.
- [19] Godec M, Roth P M, Bischof H. Hough-based tracking of non-rigid objects[J]. Computer Vision and Image Understanding, 2013, 117(10): 1245-1256.
- [20] Cehovin L, Kristan M, Leonardis A. An adaptive coupled-layer visual model for robust visual tracking [C] // Proceeding of IEEE International Conference on Computer Vision. Barcelona: IEEE, 2011: 1363-1370.
- [21] Wang S, Lu H, Yang F. et al. Superpixel tracking[C]//Proceedings of the 13th International Conference on Computer Vision. Barcelona, Spain; IEEE, 2011: 1323-1330.