

文章编号 1004-924X(2019)05-1206-12

引入样本删除机制的 TLD 粒子群目标跟踪

郭巳秋^{1,2}, 张 涛^{1*}, 苗锡奎³

(1. 中国科学院 长春光学精密机械与物理研究所, 吉林 长春 130033;

2. 中国科学院大学, 北京 100049;

3. 中国洛阳电子装备试验中心 光电对抗测试评估技术重点实验室, 河南 洛阳 471000)

摘要:为提高 TLD 算法在广泛场景下跟踪鲁棒性和实时性的问题, 本文从跟踪模块和学习模块两个方面对 TLD 算法进行了改进, 提出引入样本删除机制的 TLD 粒子群目标跟踪算法。首先, 用基于颜色特征的粒子群目标跟踪算法替代 TLD 算法中原来的跟踪模块, 增强 TLD 算法在应对目标出现非刚性形变、尺度变化、旋转、遮挡等情况下的跟踪鲁棒性。接着, 针对 TLD 算法的学习模块引入样本删除机制, 在跟踪过程中为样本库中正负样本数量分别设定一个阈值, 当正负样本数都达到各自阈值时, 便会启动样本删除机制。然后, 对待分类进入样本库的图像块进行等级评价, 删除对正负样本表征能力都较弱图像块。最后, 将样本库中的正负样本与当前目标进行相似度匹配, 删除对当前目标表征能力低的样本。通过对 OTB2013 和 OTB2015 数据集中相关视频序列的实验结果证明, 本文算法的 OPE 精确度达到 0.687, 算法的 OPE 成功率为 0.488, 算法运算效率平均提高了 25.71%。基本满足广泛场景下目标跟踪的鲁棒性, 并显著提高了算法运算效率。

关键词: 目标跟踪; TLD 算法; 学习模块; 样本删除机制

中图分类号: TP394.1 **文献标识码:** A **doi:** 10.3788/OPE.20192705.1206

TLD particle swarm optimization target tracking using a sample deletion mechanism

GUO Si-qiu^{1,2}, ZHANG Tao^{1*}, MIAO Xi-kui³

(1. *Changchun Institute of Optics Fine Mechanics and Physics,
Chinese Academy of Sciences, Changchun 130033, China;*

2. *University of Chinese Academy of Sciences, Beijing 100049, China;*

3. *Key Laboratory of Electro-Optical Countermeasures Test & Evaluation Technology,
Luoyang Electronic Equipment Test Center of China, Luoyang 471000, China)*

* *Corresponding author, E-mail: ZhangT@ciomp.ac.cn*

Abstract: This study improved the tracking robustness and real-time performance of a tracking-learning-detection (TLD) algorithm for a wide range of scenarios by considering two important aspects, namely, the tracking and learning modules. The study proposed a TLD particle swarm optimization (PSO) target-tracking algorithm using a sample deletion mechanism. First, the original tracking mod-

收稿日期: 2018-12-05; **修订日期:** 2019-01-03.

基金项目: 中国洛阳电子装备试验中心光电对抗测试评估技术重点实验室开放课题资助项目 (No. GKCP2017001; No. GKCP2017002)

ule of a TLD algorithm was replaced by a color-feature-based PSO target-tracking algorithm, which enhanced the tracking performance of the TLD algorithm in terms of target non-rigid deformation, scale variation, rotation, and occlusion. Second, a sample deletion mechanism for the learning module of the TLD algorithm was introduced. During the tracking process, a threshold was set for the positive and negative samples. When both the positive and negative samples reach their respective thresholds, the sample deletion mechanism was initiated. The image blocks to be classified into the sample library were then graded, and those with a weak representation ability for both positive and negative samples were deleted. Finally, we matched the positive and negative samples in the sample library with the current target and delete the samples with low representational ability to the current target. Experiments on OTB2013 and OTB2015 datasets show that the one-pass evaluation (OPE) accuracy of the proposed algorithm reaches 0.687, the OPE success rate of the algorithm is 0.488, and the operation efficiency is improved by 25.64% on average. This essentially satisfies the robustness of target tracking in a wide range of scenarios and significantly improves the computational efficiency of the algorithm.

Key words: target tracking; TLD algorithm; learning module; sample deletion mechanism

1 引言

目标跟踪技术一直是计算机视觉领域的研究热点,在视觉导航、交通管理、国防监控等领域具有重要应用。但是由于跟踪过程中所观测的目标信息的多变性、目标的机动性、背景的复杂性以及目标遮挡等原因,目标跟踪仍然是一个非常具有挑战性的问题。

近几年目标跟踪领域涌现出许多新的算法,其中有代表性的包括基于相关滤波的跟踪算法和基于深度学习的跟踪算法^[1-6]。2010年,David提出一种基于自适应相关滤波的最小平方误差输出的跟踪算法(Minimum Output Sum of Squared Error, MOSSE)^[7]。该算法是将相关滤波器引入到视觉跟踪领域的开创性工作。2014年, Martin用跟踪和识别领域常用的定向梯度直方图(Histogram of Oriented Gradient, HOG)取代了MOSSE算法中的灰度特征,提出了DSST跟踪方法^[8]。该算法设计了两个一致的相关滤波器,对尺度变化情况的目标跟踪具有显著改进效果。2015年, Henriques提出了一种核化的相关滤波器(Kernelized Correlation Filter, KCF),大大降低了运算量,提高了运算效率^[9],但算法很难解决目标非刚性形变等情况的跟踪问题。基于相关滤波的跟踪算法在一定程度上很难继续突破,大部分基于相关滤波的改进算法都需要在特定场景下

才能取得了令人比较满意的跟踪效果,在广泛场景中的适应性较差。2015年,深度学习成为跟踪领域的热点。使用深度学习可以更好地提取目标的特征,从而更好地表达目标。文献[10]中提出的算法是深度学习领域中极度具有影响力的算法,其核心是基于KCF的基本跟踪框架,作者用深度卷积特征替换HOG特征,提出使用分层卷积特征来学习和表达目标。然而,深度学习的缺点在于网络学习的速度,分层卷积特征和其他离线训练十分耗时,很难实现实时应用。

跟踪学习检测算法(Tracking-Learning-Detection, TLD)是英国萨里大学的一个捷克籍博士生在2009年提出的一种具备长时间跟踪能力的算法^[11]。TLD算法作为一种基于检测和半监督学习的目标跟踪算法,在应对目标遮挡问题时具有较好的适应性和鲁棒性,但算法在应对非刚性形变、旋转和尺度变化等情况时跟踪效果不佳,并且存在实时性较差的问题。目前,针对TLD算法的改进有很多,但是每种算法都有其成立的条件和适用的范围,尤其是应对广泛场景的跟踪问题,一直没有实时性良好且具备强鲁棒性的TLD算法被提出来^[12-14]。但是,相较于难以进一步突破的相关滤波跟踪算法和很难解决实时性问题的深度学习跟踪算法, TLD算法仍具有较大的改进提升空间。

本文从跟踪模块和学习模块两个方面对TLD算法进行研究,提出了引入样本删除机制的

TLD 粒子群目标跟踪算法。针对 TLD 算法跟踪模块的局限性,用基于颜色特征的粒子群目标跟踪算法替代 TLD 算法中原来的跟踪模块,增强 TLD 算法在应对目标出现非刚性形变、尺度变化、旋转和遮挡等情况下的跟踪鲁棒性。并针对 TLD 算法的学习模块引入样本删除机制,删除对当前目标表征能力较低的样本,以解决样本累积导致的耗时过多的问题,提高算法运算效率。最后,通过实验验证改进的算法在保证算法精度的前提下提高了算法的运算效率,并在广泛场景下实现了跟踪的鲁棒性。

2 TLD 粒子群目标跟踪算法

2.1 TLD 算法跟踪框架

TLD 算法由三部分组成:跟踪模块、检测模块、学习模块,跟踪模块和检测模块互不干涉的并行进行处理^[15]。TLD 算法的流程框图如图 1 所示。




图 1 TLD 算法流程框图

Fig. 1 Flow diagram of TLD algorithm

TLD 模型的跟踪模块是金字塔 LK 光流法改进的中值流跟踪法 (Median Flow Tracker)。算法计算前向后向误差 (Forward-Backward Error) 中值并舍弃掉大于误差中值的点,用剩下的像素点估计出当帧目标的位置^[16]。误差距离与误差中值公式如下所示:

$$FB = |X_t - X_t|, \quad (1)$$

$$\text{MedianFB} = \text{Median} |X_t - X_t|. \quad (2)$$

TLD 算法的检测模块是由 3 个分类器级联而成,这 3 个分类器依次是:方差分类器、随机森林分类器和最近邻分类器^[17]。方差分类器计算图像的灰度方差,其理论表达式如下:

$$D(x) = E(x^2) - E^2(x), \quad (3)$$

其中:图像块的灰度方差为 $D(x)$,图像块的灰度均值为 $E(x)$ 。随机森林分类器作为级联检测模块的第二级,由 n 棵相互独立的决策树构成,对经过方差分类器的图像块做进一步的筛选分类工作。检测模块的第三级是最近邻分类器,需要分别计算图像块与样本库中所有正负样本的相似度。相似度的表达式如下:

$$S^+(p, M) = \max_{p_i^+ \in M} S(p, p_i^+), \quad (4)$$

$$S^-(p, M) = \max_{p_j^- \in M} S(p, p_j^-), \quad (5)$$

其中:待分类图像块由 p 表示,在线样本库由 M 表示, p_i^+ 表示正样本库中第 i 个正样本, p_j^- 表示负样本库中第 j 个负样本。 $S^+(p, M)$ 为正最近邻相似度,表示待分类图像块与样本库中正样本的相似度; $S^-(p, M)$ 为负最近邻相似度,表示待分类图像块与样本库中负样本的相似度。图像块与样本库的相对相似度 S^r 公式如式(6):

$$S^r = \frac{S^+}{S^+ + S^-}. \quad (6)$$

相对相似度表示待分类图像块是更接近正样本还是更趋向于负样本,当大于某个阈值时,待分类图像块被认为是正样本,反之,则认为是负样本。通过以上步骤,最近邻分类器才完成待分类图像块与在线样本库的一次相似度匹配的过程。只有依次经过 3 个分类器才能够被认定含有检测目标。

TLD 算法的学习模块使用的是 P-N 学习方法,这是一种半监督学习方法^[18]。P-N 学习中存在两种约束,一种是 P 约束,属于正约束;另一种是 N 约束,属于负约束,两者互相配合共同约束检测模块和跟踪模块,防止分类器的退化和跟踪漂移。P-N 学习过程的示意图如图 2 所示。




图 2 P-N 学习示意图

Fig. 2 P-N learning schematic

P-N 学习是根据已有的标签样本训练初始的

分类器,然后根据训练好的分类器对未标记样本进行分类。利用两种约束对分类结果进行判断,纠正错误分类,将改正后的样本并入样本库,继续对检测模块训练,并不断重复上述过程。TLD算法的学习模块根据跟踪模块的结果对检测模块的错误进行评估,并根据评估结果生成训练样本对检测模块的目标模型进行更新,同时对跟踪模块的“关键特征点”进行更新,以此来避免以后出现类似的错误。

2.2 TLD粒子群目标跟踪算法

由前面的介绍可知,TLD算法由3个模块组成,包括跟踪模块、检测模块和学习模块,其中跟踪模块采用的是基于金字塔LK光流法改进的中值流跟踪法,这是一种传统的跟踪算法。若被跟踪目标在跟踪的过程中消失,跟踪模块将失去作用。

基于颜色特征的粒子群目标跟踪算法在应对目标非刚性形变、尺度变化、旋转和遮挡等情况时具有良好的跟踪鲁棒性^[19]。算法采用合理加权的颜色直方图作为目标特征,选用单调递减的Epanechnikov核函数作为目标区域直方图的权值,加权的颜色特征对于目标的非刚性形变、尺度变化和旋转不敏感,其公式如式(7)所示:

$$k(x) = \begin{cases} \frac{1}{2} c_d^{-1} (d+2) (1 - \|x\|^2), & \|x\| \leq 1 \\ 0, & \text{otherwise} \end{cases} \quad (7)$$

其中直方图量化等级设为 g , c 为归一化常数。则目标的加权颜色直方图可以表示为:

$$M_j = C \sum_{i=1}^N k(\|x_i^* - x_j\|) \delta(b(x_i^*) - j). \quad (8)$$

基于颜色特征的粒子群目标跟踪算法选用Bhattacharyya系数作为目标的相似性度量,即:

$$\text{corr} = \rho(M, I) = f(X_i) = f(x_i, y_i, \text{win}x_i, \text{win}y_i). \quad (9)$$

粒子群优化算法是一种仿生学算法,具有良好的“多峰”搜索能力,可以遍历搜索空间,迅速收敛^[20]。将粒子群优化算法应用到目标跟踪系统中,优化目标相似性函数,可以良好应对目标出现遮挡,即相似性函数出现“多峰”的情况。在 n 维搜索空间中,粒子群算法数学模型如下:

$$\mathbf{v}_{id}(t+1) = \omega \times \mathbf{v}_{id}(t) + c_1 \text{rand}_1(\mathbf{pbest}_{id}(t) - \mathbf{x}_{id}(t)) + c_2 \text{rand}_2(\mathbf{gbest}_d(t) - \mathbf{x}_{id}(t)), \quad (10)$$

$$\mathbf{x}_{id}(t+1) = \mathbf{x}_{id}(t) + \mathbf{v}_{id}(t+1), \quad (11)$$

其中:第 i 个粒子位置为 $\mathbf{x}_i = (x_{i1}, x_{i2}, \dots, x_{in})^T$,其速度为 $\mathbf{v}_i = (v_{i1}, v_{i2}, \dots, v_{im})^T$,它的个体极值为 $\mathbf{pbest}_i = (pbest_{i1}, pbest_{i2}, \dots, pbest_{im})^T$,种群全局极值为 $\mathbf{gbest} = (gbest_1, gbest_2, \dots, gbest_n)^T$ 。 $d = 1, 2, \dots, n$, $i = 1, 2, \dots, \text{PopSize}$, PopSize 为种群规模, t 为当前迭代的代数, rand_1 和 rand_2 为 $[0, 1]$ 均匀分布随机数, c_1 与 c_2 为加速常数(Acceleration Coefficients), ω 为惯性权重(Inertia)。

在解决目标非刚性形变、尺度变化、旋转和遮挡等广泛场景的跟踪问题时,基于颜色特征的粒子群目标跟踪算法相较于TLD算法的跟踪模块具有明显优势。因此,本文将基于颜色特征的粒子群目标跟踪算法和TLD算法相结合,替代TLD算法的原有的跟踪模块,增强TLD算法在应对目标出现非刚性形变、尺度变化、旋转和遮挡等情况下的跟踪鲁棒性。

3 引入样本删除机制的TLD粒子群目标跟踪算法

3.1 学习模块的样本累积问题

在TLD算法跟踪过程中,若前一帧图像跟踪完毕时发现了新的目标形态,或者发现之前被检测错误的目标样本,则这样的样本就会被加入到在线样本库中作为目标样本的扩充,若 M 表示样本库, n 表示当前正样本数, m 表示当前负样本数,则样本库包含样本的情况可以描述为 $M = \{p_1^+, p_2^+, \dots, p_n^+, p_1^-, p_2^-, \dots, p_m^-\}$ 。

在目标跟踪过程中,样本库会不断的扩充。如果从目标形态的丰富程度来看,样本库的扩充显然是有益的。然而,在样本库扩充的过程中,依次通过方差分类器、随机森林分类器和最近邻分类器的待分类图像块会全部进入样本库。在最近邻分类器中相对相似度较高的待分类图像块被认为是表征能力较强的正样本,会被分类到正样本库中;相对相似度较低的待分类图像块被认为是表征能力较强的负样本,会被分类到负样本库中。而这些待分类图像块中会存在一些对正负样本表征能力都相对较差的图像块,即不是具有代表性正样本也不是具有代表性负样本,同样会分到样本库中,导致样本数量增加。

同时,由于目标在运动过程中形态会不断发

生变化,样本库中的正负样本除了已经存在的,还有就是在跟踪过程中不断添加进去的。对于较早进入样本库的样本对当前目标及目标即将发生的形态变化表征能力较弱。而样本一旦进入样本库便会一直存在,导致样本库严重冗余,降低算法运算效率。并且样本库中对真实目标表征能力低的样本也会影响算法精确度。

由 2.1 节的介绍可知 TLD 算法中检测模块的第三级是最近邻分类器,其工作实质就是将通过了方差分类器和随机森林分类器的图像块与样本库中的正负样本进行一一匹配。而相似度匹配过程十分繁琐,尤其在长时间跟踪过程中,样本库中样本数量会不断累积增加,导致算法在最近邻分类器消耗的时间也不断增加,降低算法运算效率。

为了证明不断扩充的样本库对算法运算效率的影响,以 OTB2013 中 Suv 图像序列作为实验对象,通过实验记录样本库中样本数量与在最近邻分类器消耗时间的对应情况,实验结果如表 1 所示。

表 1 样本数量与最近邻分类器消耗时间

Tab. 1 Template number and consumption time of nearest neighbor classifier

帧	正样本数	负样本数	耗时/ms
0	1	5	1.8
100	7	8	20.5
200	23	17	23.0
300	30	24	55.8
400	38	30	78.5
500	47	38	90.6
600	55	46	97.8
700	69	49	100.5
800	74	50	102.2
900	74	50	103.1

从表中可以看出,随着样本库中正负样本数量的增加,算法在最近邻分类器消耗的时间显著增加。样本库中样本数越多,算法运算效率越低,严重影响算法实时性。

3.2 引入样本删除机制的学习模块

由以上分析可以得出,样本库数量累积会导致算法运算效率降低,同时样本库不断累积的样

本中存在对真实目标表征能力低的样本,也会影响算法精确度。为了解决样本库中样本累积导致的问题,本文针对学习模块引入样本删除机制,删除对真实目标表征能力低的样本。

样本库中存在的对真实目标表征能力低的样本主要来源于两个方面,一方面是通过检测模块并新添加到样本库中的部分样本,另一方面是已经存在与样本库中较早进入样本库中的部分样本。样本删除机制主要针对这两方面对算法进行改进,分为两个部分。

在跟踪过程中,随着样本库中正负样本数量的不断增加,分别为正样本数和负样本数设定一个阈值。当正样本数和负样本数都达到各自阈值时,便会启动样本删除机制,删除对于当前目标表征能力低的样本,启动机制公式如式(12)和式(13)所示:

$$N_{p^+} \geq N_{\theta^+}, \quad (12)$$

$$N_p \geq N_{\theta}, \quad (13)$$

其中: N_{p^+} 为正样本数, N_p 为负样本数, N_{θ^+} 为正样本数量阈值, N_{θ} 为负样本数量阈值。

启动样本删除机制后,首先进入样本删除机制的第一部分。由于在目标跟踪过程中,待分类进入样本库的图像块中存在对正负样本表征能力都较弱的图像块,所以样本删除机制首先对通过检测模块的即将进入样本库的待分类图像块进行等级评价。利用检测模块中最近邻分类器的相对相似度对待分类图像块分为 3 个等级,等级一(LV1)、等级二(LV2)和等级三(LV3),公式如下所示:

$$LV(S^r) = \begin{cases} 1, S^r \geq \theta_h \\ 2, \theta_l < S^r < \theta_h, \\ 3, S^r \leq \theta_l \end{cases} \quad (14)$$

其中: θ_h 为等级一与等级二的相对相似度阈值, θ_l 为等级二与等级三的相对相似度阈值。相对相似度值大于 θ_h 的图像块为等级一,相对相似度值在 θ_h 到 θ_l 之间的图像块为等级二,相似度平均值低于 θ_l 的图像块为等级三。等级一的待分类图像块对真实目标的表征能力较强,等级三的待分类图像块具有较强的负样本表征能力。等级二的待分类图像块对于正负样本的表征能力都相对较差。因此,引入的样本删除机制中,只有等级一的待分类图像块进入正样本库中,成为正样本,等级三的待分类图像块进入负样本库中,成为负样本。

在目标跟踪过程中会出现目标非刚性形变、旋转和遮挡等复杂情况,因此当前时刻的目标区域可能对真实目标的表征能力相对较弱。利用此时的目标对已有的样本库进行样本删除,存在一定局限性。因此样本删除机制的第二部分我们首先将正样本库中的正样本与当前目标进行相似度匹配,计算样本的相似度平均值,利用正样本与当前目标相似度的平均值对当前目标评价,相似度平均值高于 0.5 的目标区域具有对真实目标较强的表征能力,才可以进入样本删除机制的第二部分,保证算法的精确度。公式如下所示:

$$S_a(t, p^+) = \frac{\sum_{i=1}^n S(t, p_i^+)}{n}, \quad (15)$$

其中: t 表示当前目标, S_a 表示当前目标与正样本的相似度平均值。

进入样本删除机制的第二部分后,将样本库中的正负样本与当前目标一一进行相似度匹配,本文计算并记录每个样本的相似度。样本删除机制的主要原理是在正样本库中保留相似度较高的样本,删除相似度较低的样本;在负样本库中保留相似度较低的样本,删除相似度较高的样本。删除机制的基本公式如下:

$$S_{p_i^+} \geq S_{\theta^+}, \quad (16)$$

$$S_{p_j^-} \leq S_{\theta^-}, \quad (17)$$

其中: $S_{p_i^+}$ 为第*i*($i=1, \dots, n$)个正样本的相似度, $S_{p_j^-}$ 为第*j*($j=1, \dots, m$)个负样本的相似度, S_{θ^+} 为正样本库的样本删除阈值, S_{θ^-} 为负样本库的样本删除阈值。

对于样本删除机制中相对相似度阈值 θ_h 和 θ_l 以及样本删除阈值的具体取值,需要在实验中不断地尝试,找到最合适的取值。通过对 OTB2013 和 OTB2015 数据集视频的测试,当 θ_h 为 0.55, θ_l 为 0.25 时,正样本删除阈值 S_{θ^+} 为 0.6,负样本删除阈值 S_{θ^-} 为 0.4 时,算法取得的改进效果最佳。

对于增加了样本删除机制的 TLD 粒子群跟踪算法而言,当跟踪过程中样本数量不断积累达到设定的阈值时,样本删除机制将会启动,对目标表征能力较低的样本进行删除。引入样本删除机制能够给算法带来两个好处:首先,跟踪过程中,样本库因删除机制的存在不会造成大量样本积

累,使样本整体数量稳定在一个合理的范围内,提高算法运算效率;其次,样本删除机制删除的是与当前目标表征能力较低的样本,保留下表征能力较高的样本,保证了算法精确度。

3.3 引入样本删除机制的 TLD 粒子群目标跟踪算法流程

引入样本删除机制的 TLD 粒子群目标跟踪算法和原始 TLD 算法相比,主要改进方面为:使用具有良好跟踪性能的基于颜色特征的粒子群优化目标跟踪算法替代 TLD 算法的跟踪模块,增强算法了在广泛场景下的跟踪鲁棒性;并对 TLD 算法中学习模块引入样本删除机制,解决了因样本积累导致的运算效率降低的问题,并保证算法精确度。本文提出引入样本删除机制的 TLD 粒子群目标跟踪算法的工作流程如下:

第一步,初始化,读取第一帧图像,标记待跟踪目标,初始化跟踪模块和检测模块。

对于跟踪模块主要初始化以下内容:

- (1)确定被跟踪目标坐标,提取目标信息;
- (2)确定目标颜色特征描述与相似性度量;
- (3)对粒子群参数进行初始化,设定加速常数 c_1 和 c_2 ,惯性权重 ω ,最大迭代代数 T_{max} ,设定粒子群体的数目 $PopSize$,参数的初始化与实际跟踪精度有关;

(4)初始化当帧粒子个体、个体最优解及全局最优解。

对于检测模块主要初始化以下内容:

- (1)利用目标位置生成初始目标样本和背景样本;
- (2)对目标样本生成特征;
- (3)初始化方差分类器,进行第一步筛选;
- (4)用初始样本训练随机森林分类器和最近邻分类器。

第二步,读取下一帧图像,分别使用跟踪模块和检测模块得到目标位置。

第三步,用 P-N 学习方法更新随机森林分类器。

第四步,综合跟踪模块与检测模块结果,得到目标在当帧的位置。

第五步,使用引入样本删除机制的样本库的正负样本对跟踪模块和检测模块进行更新。

第六步,读取下一帧图像,转到第二步进行处理,直至视频结束。

算法流程图如图 3 所示。

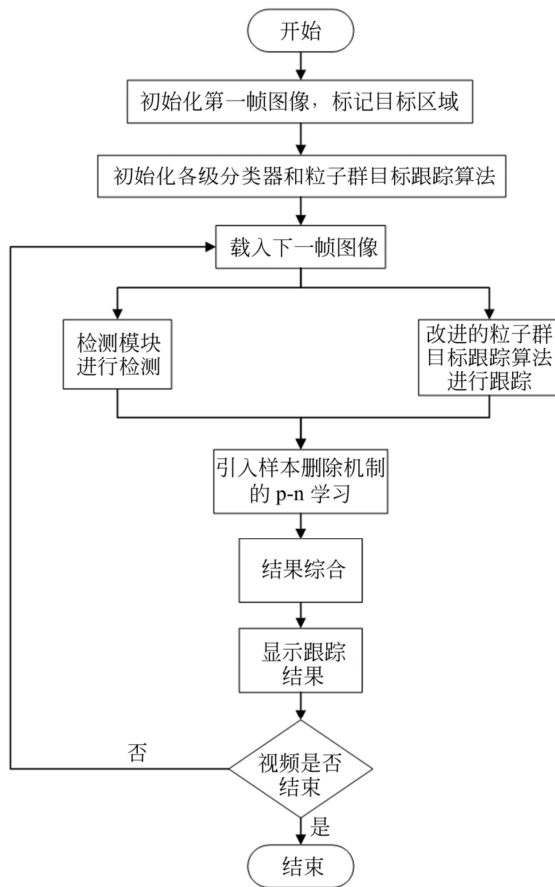


图 3 算法流程图

Fig. 3 Algorithm flow chart

4 实验与结果

4.1 改进跟踪算法定性分析

在本节中,原始 TLD 模型中跟踪模块已替换为基于颜色特征的粒子群优化目标跟踪算法,并在学习模块引入样本删除机制。在实验中我们将引入样本删除机制的 TLD 粒子群跟踪算法称为改进的算法,在图中标注为 OURS 算法,与 11 种最先进的算法进行比较,包括 TLD^[21], Struck^[22], VTD^[23], CSK^[24], CT^[25], DFT^[26], OAB^[27], MIL^[28], DSSL^[8], KCF^[9] 和 DLSSVM^[29] 跟踪算法。本节的实验是在 Windows 7 操作系统、MATLAB 2016 环境下,使用 Intel i5-5200U CPU (2.2 GHz) 处理器,内存为 8 GB 的计算机进行的。实验中跟踪模块的粒子群种群大小设置为 100,最大迭代次数为 180,整个实验期间参数是固定的。实验中的学习模块样本删除机制的正样本删除阈值设置 0.6,为负样

本删除阈值设置为 0.4。对于本文中的其他 11 种算法,使用了他们已经提供的代码,包括最佳参数值。本文以 OTB2013 和 OTB2015 数据集中相关图像序列作为测试序列,具有代表性的部分跟踪效果图如下所示。

4.1.1 非刚性形变

对于目标跟踪过程中的非刚性形变的情况,采用 Bolt 和 Skating2 图像序列作为代表测试序列,部分跟踪结果如图 4 所示。Bolt 图像序列包含了以目标形变为主的复杂情况,KCF、Struck 和 MIL 等算法在目标发生形变一段时间后开始

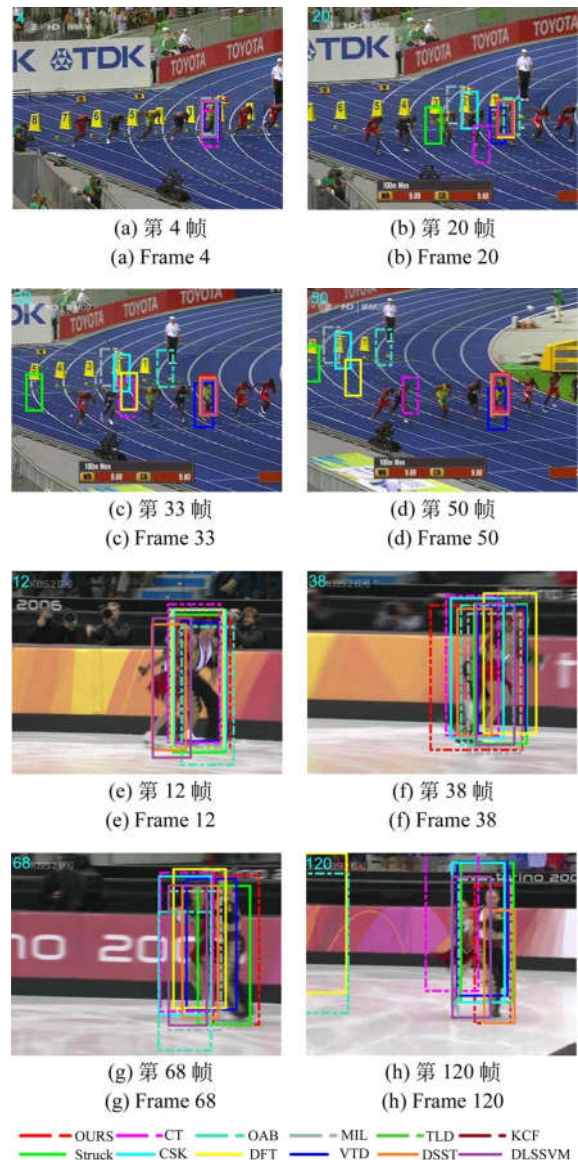


图 4 非刚性形变跟踪效果图

Fig. 4 Non-rigid deformation tracking results

丢失目标,而本文算法在整个跟踪过程中可以稳定锁定目标。在 Skating2 图像序列中,从第 38 帧开始大量算法开始出现跟踪框漂移现象,本文算法相较其他算法跟踪更准确稳定。

4.1.2 尺度变化

本文采用图像序列 Car4 和 RedTeam 作为目标运动期间具有尺度变化情况的测试序列,跟踪结果如图 5 所示。在 Car4 图像序列中,第 127 帧之前目标没有发生明显尺度变化,算法都可以稳定跟踪目标。在第 241 帧,当目标尺度变化明显时,可以看到我们的算法在大部分算法丢失目标

的情况下可以稳定锁定目标,展示出明显的跟踪优势。在 RedTeam 图像序列中,CT 算法从第 466 帧开始丢失目标。在随后的图像序列中,目标尺度持续发生变化,本文算法的跟踪框可以稳定包含目标。

4.1.3 目标旋转

图 6 展示了具有代表性的目标旋转情况的跟踪效果图。采用 Motorrolling 和 Vase 图像序列作为测试序列。在 Motorrolling 图像序列中,目标从第 65 帧开始旋转。在整个跟踪过程中,本文算法的跟踪框可以完整包含目标,除了本文提出的

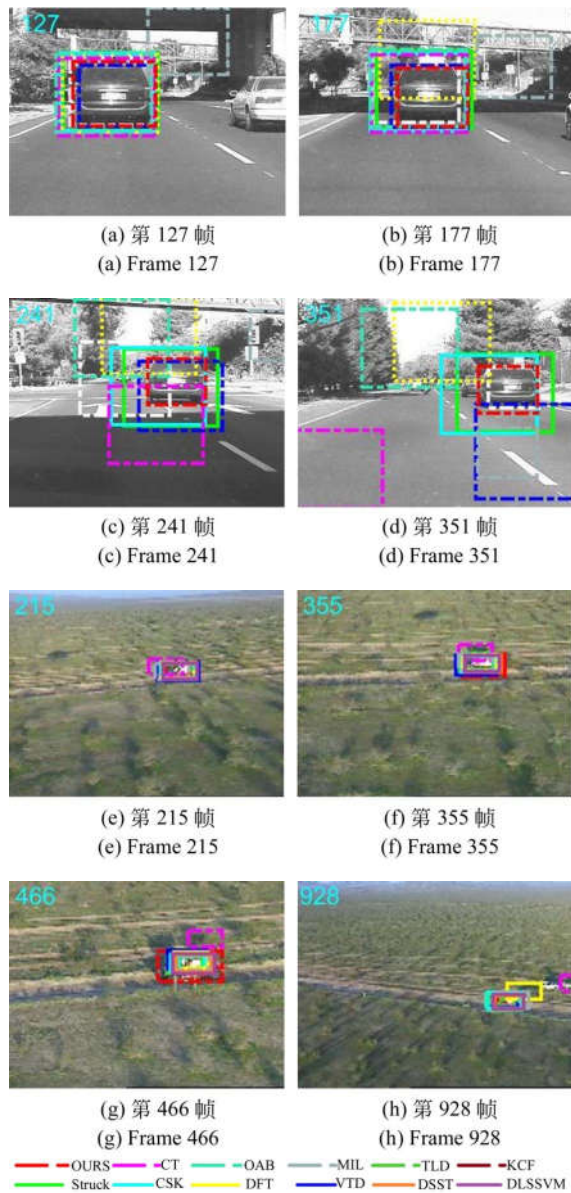


图 5 尺度变化跟踪效果图
Fig.5 Scale variation tracking results

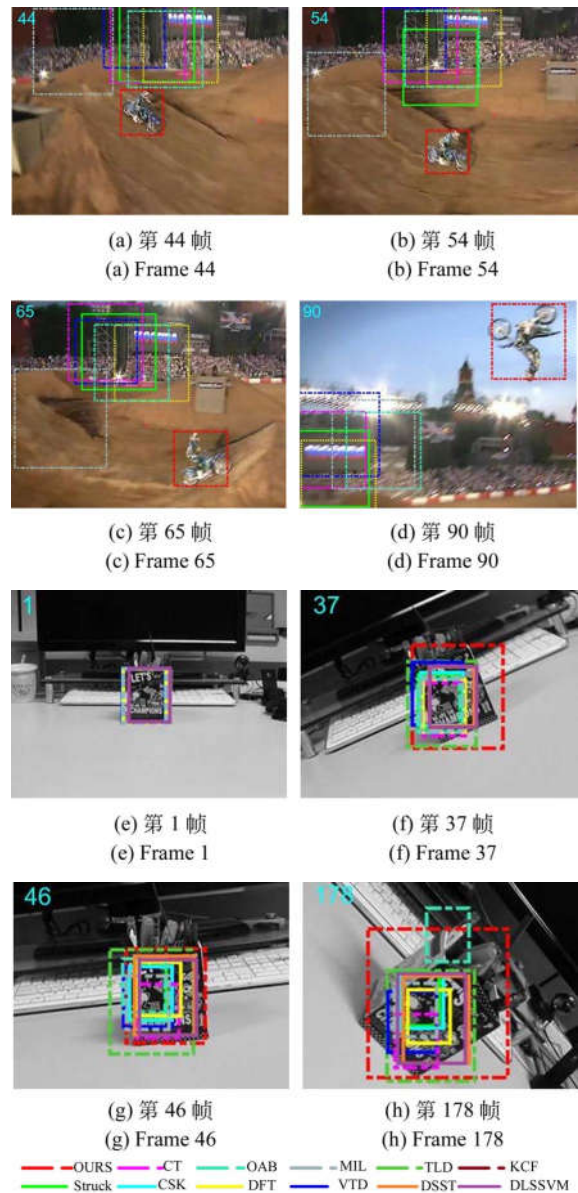


图 6 目标旋转跟踪效果图
Fig.6 Target rotation tracking results

算法其他算法都先后丢失目标。可以看出,本文提出的算法比其他算法更好地解决了旋转问题。在 Vase 图像序列中,除了 OAB 算法丢失目标外,本文算法和其它算法都可以锁定目标,但在整个跟踪过程中,本文算法的跟踪框可以完整包含目标,表现出更好的跟踪性能。

4.1.4 目标遮挡

作为重点应对的目标遮挡的情况,我们展示 Box 和 Coke 两组图像序列的跟踪效果图,跟踪结果如图 7 所示。在 Box 图像序列中,目标通过遮

挡物时 CSK、Struck 和 CT 算法开始丢失目标,而本文提出的跟踪算法可以准确、稳定地锁定目标。在 Coke 图像序列中,目标被绿叶反复遮挡,大多数跟踪算法偏离目标,本文提出的算法的跟踪框准确地覆盖了目标位置。可以看出,引入样本删除机制的 TLD 粒子群目标跟踪算法具有良好的抗遮挡性能。

4.2 改进跟踪算法定量分析

在本节中,使用文献[30]中提出的一次通过评估(One-Pass Evaluation, OPE)来评估算法跟踪准确度。采用成功率图和精度图这两个评估标准,其中精度图表示中心位置误差小于预定阈值帧数的百分比,成功率图表示跟踪区域和边界区域的重叠率大于阈值的帧数百分比。精度图的误差阈值设置为 20,对算法跟踪结果的百分比进行排序。对于成功率图,根据每个跟踪算法的曲线下面积(Area Under the Curve, AUC)对算法进行排序。

图 8 显示了本文算法和 11 种跟踪算法的精度图和成功率图。从图中可以看出,本文改进的算法在精度图和成功率图中都排名第一。在精度图中,本文改进的算法比 DLSSVM 算法提高了 1.2%,而原始 TLD 算法排在 DLSSVM、DSST、KCF 和 Struck 算法之后,排名第六位。在成功率图中,本文改进的算法 AUC 达到了 0.488,比相关滤波算法中的排名靠前的 DSST 算法高出 0.029,比排名第二的 DLSSVM 算法高出 0.019。精度图和成功率图表明,在 OTB2013 和 OTB2015 数据集的相关测试序列中,本文的算法相较 11 种先进跟踪算法展现出了良好的跟踪性能,对比原始 TLD 算法,本文改进的算法跟踪准确度得到了较大提升。

从图 8 的实验结果和分析可知,引入样本删除机制的 TLD 粒子群跟踪算法具备良好跟踪效果,在目标发生非刚性形变、尺度变化、旋转和遮挡等情况时都可以稳定锁定目标,充分发挥了算法应对广泛场景的跟踪优势。对于改进算法的运算效率,本文对比原始 TLD 算法和引入样本删除机制的 TLD 粒子群目标跟踪算法的平均单帧耗时。实验采用 4.1 小节中展示算法跟踪效果的图像序列,记录两种算法 20 次跟踪实验的平均单帧耗时,结果如表 2 所示。

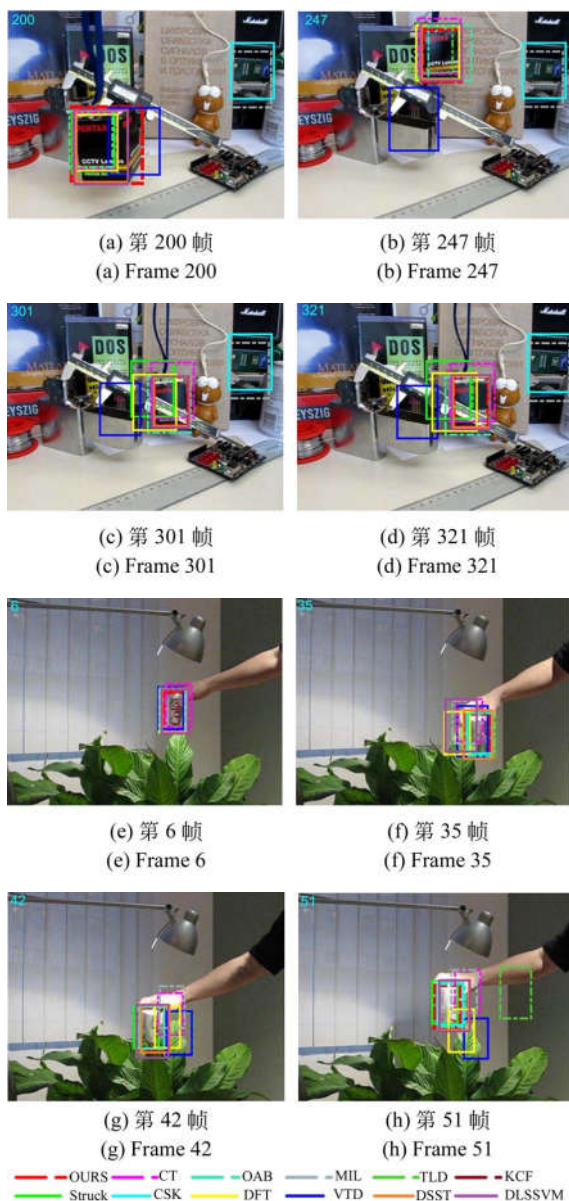


图 7 目标遮挡跟踪效果图

Fig. 7 Target occlusion tracking results

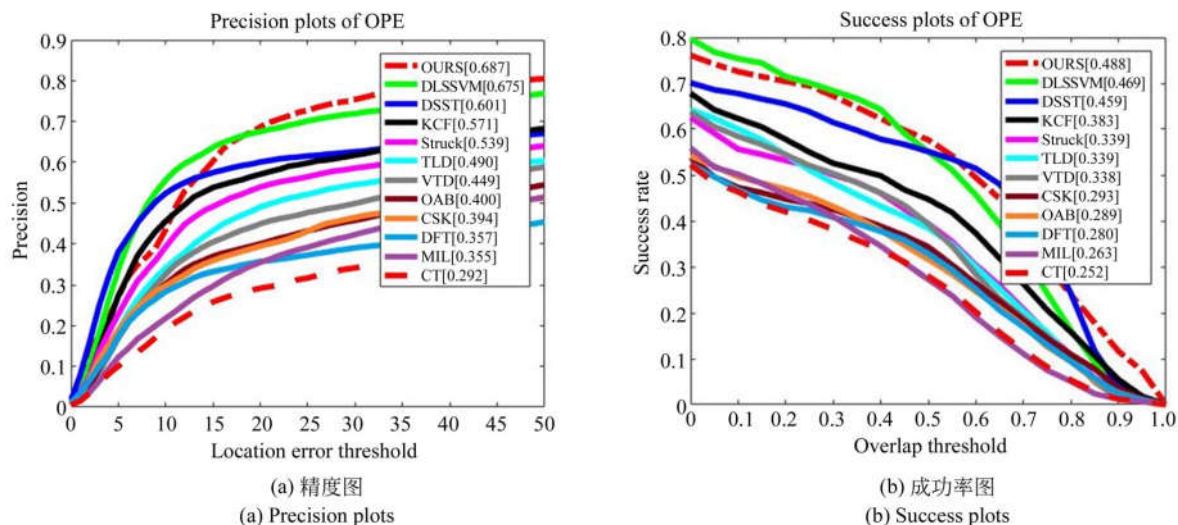


图 8 跟踪算法 OPE 曲线
Fig. 8 OPE curves for different tracking algorithms

表 2 算法平均单帧耗时对比

Tab. 2 Algorithm time-consuming contrast

视频序列	TLD 单帧耗时/ms	改进 TLD-PSO 单帧耗时/ms	提升率/%
Bolt	66.52	54.55	18
Skating2	98.10	83.23	15.2
Car4	80.26	60.05	25.2
RedTeam	100.05	78.04	22
Motorrolling	133.45	99.12	25.7
Vase	123.88	87.74	29.2
Box	126.33	77.30	38.8
Coke	155.92	106.67	31.6

从表 2 的对比数据可以看出,引入样本删除机制的 TLD 粒子群目标跟踪算法相较于原始 TLD 算法,运算效率平均提高了 25.71%。改进的算法因引入在线样本删除机制,有效解决了因样本累积造成的实时性降低的问题,在持续时间长,样本刷新多的跟踪场景中尤为明显。以 Box 和 Coke 为例,Box 测试序列的特点是持续时间长,跟踪过程中样本累积较为明显,引入了样本删除机制后,跟踪算法在处理视频的速度上有较大提高,实时性提升约 38.8%;Coke 测试序列的特点是目标跟踪过程中多次被部分遮

挡,在这种情况下,样本刷新的速度很快,给算法的处理带来压力。改进的算法有效抑制了样本累积带来的耗时问题,算法运算效率提高了 31.6%。该部分对比实验有效证明了引入样本删除机制的 TLD 粒子群目标跟踪算法在运算效率上有显著提升。

5 结 论

本文从 TLD 算法的跟踪模块和学习模块两个方面对算法进行改进,提出了引入样本删除机制的 TLD 粒子群目标跟踪算法。首先,本文将 TLD 算法和具备良好跟踪性能的粒子群目标跟踪算法相结合,提高算法应对目标出现遮挡、旋转、非刚性形变等情况下的跟踪鲁棒性。然后,为提高 TLD 算法的实时性,研究了样本库中样本累积导致的运算效率降低的问题,针对 TLD 算法学习模块引入样本删除机制,删除对当前目标表征能力低的样本。最后,通过对 OTB2013 和 OTB2015 数据集中相关图像序列进行跟踪实验证明,算法的 OPE 精度达到 0.687,算法成功率 AUC 为 0.488,算法运算效率平均提高了 25.71%。引入样本删除机制 TLD 粒子群目标跟踪算法在广泛场景下实现了跟踪鲁棒性,并提高了算法运算效率。

参考文献:

- [1] 王春平, 王晔, 刘江义, 等. 基于色度饱和度-角度梯度直方图特征的尺度自适应核相关滤波跟踪[J]. 光学 精密工程, 2016, 24(9): 2293-2301.
WANG CH P, WANG W, LIU J Y, *et al.*. Scale adaptive kernelized correlation filter tracking based on HHS-OG feature [J]. *Opt. Precision Eng.*, 2016, 24(9): 2293-2301. (in Chinese)
- [2] 程帅, 孙俊喜, 曹永刚, 等. 基于色度饱和度-角度梯度直方图特征的尺度自适应核相关滤波跟踪[J]. 光学 精密工程, 2015, 23(4): 1161-1170.
CEHNG SH, SUN J X, CAO Y G, *et al.*. Target tracking based on incremental deep learning [J]. *Opt. Precision Eng.*, 2015, 23(4): 1161-1170. (in Chinese)
- [3] LUO L S, FAN X S. Immune particle filter algorithm for target tracking based on histograms of color and oriented gradient [J]. *Optical Sensing and Imaging Technology and Applications*, 2017, 10462.
- [4] 李泽原, 孙晓刚, 林云. 基于卷积神经网络和核相关滤波的物体跟踪算法[J]. 计算机应用, 2017, 37(S2): 107-111.
LI Z Y, SUN X G, LIN Y. Object tracking algorithm based on convolutional neural network and kernel correlation filtering [J]. *Journal of Computer Applications*, 2017, 37(S2): 107-111. (in Chinese)
- [5] ZHANG D, ZHANG J, XIA C. Multi-Complementary model for long-term tracking [J]. *Sensors*, 2018, 18(2): 527.
- [6] 刘教民, 郭剑威, 师硕. 自适应模板更新和目标重定位的相关滤波器跟踪[J]. 光学 精密工程, 2018, 26(6): 1533-1541.
LIU J M, GUO J W, SHI SH. Correlation filter tracking based on adaptive learning rate and location refiner [J]. *Opt. Precision Eng.*, 2018, 26(6): 1533-1541. (in Chinese)
- [7] BOLME D S, BEVERIDGE J R, DRAPER B A, *et al.*. Visual object tracking using adaptive correlation filters [C]. *Proceedings of the IEEE International Conference on Computer Vision and Pattern Recognition*, San Francisco, CA, USA, 2010: 2544-2550.
- [8] DANELLJAN M, HAGER G, KHAN F S, *et al.*. Accurate scale estimation for robust visual tracking [J]. *British Machine Vision Conference*, 2014: 65-75.
- [9] HENRIQUES J F, CASEIRO R, MARTINS P, *et al.*. High-Speed tracking with kernelized correlation filters [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2015, 37(3): 583-596.
- [10] MA C, HUANG J B, YANG X, *et al.*. Hierarchical Convolutional Features for Visual Tracking [C]. *Proceedings of the IEEE International Conference on Computer Vision*, Santiago, Chile, 2016: 3074-3082.
- [11] KALAL Z, MATAS J, MIKOLAJCZYK K. On-line learning of robust object detectors during unstable tracking [C]. *Proceedings of the IEEE International Conference on Computer Vision Workshops (ICCV Workshops)*, Kyoto, Japan, 2009: 1417-1424.
- [12] 胡欣, 高佳丽. 基于改进的 TLD 目标跟踪算法[J]. 计算机应用研究, 2019, 36(11): 1-5.
HU X, GAO J L. Target tracking algorithm based on improved TLD [J]. *Application Research of Computers*, 2019, 36(11): 1-5. (in Chinese)
- [13] 刘曙, 狄红卫, 姚曼虹. 基于自适应尺度的 TLD 目标跟踪算法[J]. 光学技术, 2017, 43(6): 542-546.
LIU SH, DI H W, YAO M H. TLD target tracking algorithm based on adaptive scale [J]. *Optical Technique*, 2017, 43(6): 542-546. (in Chinese)
- [14] 吴忠文, 费树岷. 基于 TLD 目标跟踪算法的优化[J]. 工业控制计算机, 2018, 31(4): 77-79.
WU ZH W, FEI SH M. Optimization based on TLD target tracking algorithm [J]. *Industrial Control Computer*, 2018, 31(4): 77-79. (in Chinese)
- [15] KALAL Z, MIKOLAJCZYK K, MATAS J. Face-tld: Tracking-learning-detection applied to faces [C]. *Proceedings of the IEEE International Conference on Image Processing (ICIP)*, Hong Kong, China, 2010: 3789-3792.
- [16] KALAL Z, MIKOLAJCZYK K, MATAS J. Forward-Backward Error: Automatic Detection of Tracking Failures [C]. *Proceedings of the IEEE Computer Society International Conference on Pattern Recognition*, Istanbul, Turkey, 2010: 2756-2759.
- [17] 王明晓. 基于改进的 TLD 目标跟踪算法研究[D]. 哈尔滨: 哈尔滨理工大学, 2017.
WANG M X. *Target Tracking Algorithms Based on Improved TLD* [D]. Harbin: Harbin University of Science and Technology, 2017. (in Chinese)

- [18] KALAL Z, MATAS J, MIKOLAJCZYK K. P-N learning: Bootstrapping binary classifiers by structural constraints [J]. *IEEE Computer Vision and Pattern Recognition*, 2010;49-56.
- [19] GUO S Q, ZHANG T, SONG Y L, *et al.*. Color feature-based object tracking through particle swarm optimization with improved inertia weight [J]. *Sensors*, 2018, 18:1292.
- [20] KENNEDY J, EBERHART R. Particle swarm optimization [C]. *Proceedings of the IEEE International Conference on Neural Networks, Perth*, 1995, 4:1942-1948.
- [21] KALAL Z, MIKOLAJCZYK K, MATA J. Tracking-Learning-Detection [J]. *IEEE Transactions on Software Engineering*, 2011, 34 (7): 1409-1422.
- [22] HARE S, SAFFARI A, TORR P H S. Struck: structured output tracking with kernels [C]. *Proceedings of the IEEE International Conference on Computer Vision (ICCV), Barcelona, Spain*, 2011;263-270.
- [23] KWON J, LEE K M. Visual tracking decomposition [C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), San Francisco, CA, USA*, 2010;1269-1276.
- [24] HENRIQUES J F, CASEIRO R, MARTINS P, *et al.*. Exploiting the circulant structure of tracking-by-detection with kernels [C]. *In Proceedings of the European Conference on Computer Vision (ECCV), Florence, Italy*, 2012;702-715.
- [25] ZHANG K H, ZHANG L, YANG M H. Real-time compressive tracking [C]. *Proceedings of the European Conference on Computer Vision (ECCV), Florence, Italy*, 2012;864-877.
- [26] SEVILLA-LARA L, LEARNED-MILLER E. Distribution fields for tracking [C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, Providence, RI, USA, 2012;1910-1917.
- [27] GRABNER H, GRABNER M, BISCHOF H. Real-time tracking via on-line boosting [C]. *Proceedings of the British Machine Vision Conference (BMVC), Edinburgh, UK*, 2006;47-56.
- [28] BABENKO B, YANG M H, BELONGIE S. Visual tracking with online multiple instances learning [C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Miami, FL, USA*, 2009;983-990.
- [29] NING J, YANG J, JIANG S, *et al.*. Object tracking via dual linear structured svm and explicit feature map [C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, NV, USA*, 2016;4266-4274.
- [30] WU Y, LIM J, YANG M H. Online object tracking: a benchmark [C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Portland, OR, USA*, 2013: 2411-2418.

作者简介:



郭已秋(1989—),女,吉林长春人,博士研究生,助理研究员,2012年、2015年于北京理工大学分别获得学士、硕士学位,主要从事目标检测、跟踪算法方面的研究工作。E-mail: guo_qiuqiu@163.com



张涛(1964—),男,吉林长春人,博士研究生,研究员,1987年、1990年于浙江大学分别获得学士、硕士学位,1993年于长春光学精密机械与物理研究所获得博士学位,主要从事探测与成像技术,稳定控制技术方法的研究。E-mail: ZhangT@ciomp.ac.cn