

# 复杂场景下高置信度更新策略的互补跟踪算法

顾亚雄<sup>1</sup>, 李鑫<sup>1\*</sup>, 陈苗苗<sup>2</sup>

<sup>1</sup>西南石油大学机电工程学院, 四川 成都 610500;

<sup>2</sup>西南交通大学希望学院, 四川 成都 610400

**摘要** 针对目标遮挡、形变、旋转、光照变化及背景干扰等复杂场景下的目标跟踪问题, 基于核相关滤波跟踪算法和统计颜色特征的跟踪算法, 提出了一种复杂场景下的高置信度更新策略互补跟踪算法。首先, 利用高斯拉普拉斯算子和局部二值模式增强目标边缘信息和纹理特征; 然后, 引入可调高斯窗口函数和基于关键点的尺度估计模型优化算法; 最后, 利用响应峰值与跟踪框的交并率设计了一种高置信度更新策略, 以自适应更新模板。实验结果表明, 在 OTB2013 数据集上本算法的精确度和成功率分别为 88.3% 和 72.4%。

**关键词** 图像处理; 目标跟踪; 高置信度; 互补跟踪; 模板更新; 相似性度量

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP202158.1230004

## Complementary Tracking Algorithm with High-Confidence Updating Strategy Under Complex Scenes

Gu Yaxiong<sup>1</sup>, Li Xin<sup>1\*</sup>, Chen Miaomiao<sup>2</sup>

<sup>1</sup> School of Mechanical and Electrical Engineering, Southwest Petroleum University, Chengdu, Sichuan 610500, China;

<sup>2</sup> Hope College of Southwest Jiaotong University, Chengdu, Sichuan 610400, China

**Abstract** This paper proposes a complementary tracking algorithm with high-confidence updating strategy to address target tracking problems in complex scenes such as target occlusion, deformation, rotation, illumination changes, and background interference. The algorithm is based on the core-related filter-tracking algorithm and the statistical color feature-tracking algorithm. First, the Laplacian of Gaussian operator and local binary mode are used to enhance the edge information and texture features of the target. Then, the tunable Gaussian window function and scale estimation model based on the key points optimization algorithm are introduced. Finally, the response peak value and a high-confidence updating strategy are designed for the merged rate of the tracking frame to adaptively updating the template. Experimental results show that the precision and success rate of the algorithm on the OTB2013 data set are 88.3% and 72.4%, respectively.

**Key words** image processing; target tracking; high-confidence; complementary tracking; template updating; similarity measurement

**OCIS codes** 100.4999; 150.1135; 110.4155; 100.2980

## 1 引言

人工智能的快速发展, 使计算机视觉<sup>[1]</sup>受到了

人们的广泛关注。作为计算机视觉的重要组成部分, 目标跟踪在视频监控、智能交通、无人驾驶、国防安全等领域内得到了广泛的应用。

收稿日期: 2020-08-28; 修回日期: 2020-09-17; 录用日期: 2020-09-23

基金项目: 四川省教育厅科技计划(19YYJC0802)

\* E-mail: x\_li726@163.com

近年来,国内外研究学者对目标跟踪的研究取得了多项成果<sup>[2-8]</sup>。张红颖等<sup>[9]</sup>利用 Hue 和方向梯度直方图(HOG)特征及其对应的位置滤波器获得输出响应,自适应分配权重以预测目标位置,改善了核相关滤波(KCF)跟踪算法特征表达不足且不适应于目标尺度变化的情况。茅正冲等<sup>[10]</sup>在 KCF 算法的基础上增加了角点检测和双向光流法,利用峰值旁瓣比和阈值判定目标是否发生遮挡,并对下一帧图像中的角点进行检测。同时,使用双向光流法确定目标位置,可以有效应对目标被严重遮挡的情况。李双双等<sup>[11]</sup>在统计颜色特征的 DAT(Distractor-aware tracking)算法基础上增加了 HOG 特征,以适应局部遮挡、尺度变化等情况,在一定程度上改善了 DAT 算法使用单一颜色特征导致的抗背景干扰(包括类目标干扰)能力差问题。陈法领等<sup>[12]</sup>将两个由不同特征训练的 KCF 响应结果进行加权融合,完成目标的位置估计,以适应光照变化、目标形变、尺度变化和目标遮挡情况。Bertinetto 等<sup>[13]</sup>提出了一种能实时互补跟踪的目标跟踪 Staple 算法,将判别尺度空间跟踪器(DSST)<sup>[14]</sup>和 DAT 算法得到的响应直接乘以常数系数进行线性叠加,通过叠加的响应峰对目标进行定位,以适应光照变化、目标形变及运动模糊等情况。潘长城等<sup>[15]</sup>提出了一种类残差更新策略,将保存的初始样本用于模型更新,以平衡算法的稳定性和可塑性,降低 KCF 算法跟踪模板漂移<sup>[16]</sup>的风险。林彬等<sup>[17]</sup>利用响应峰值和平均峰值能量设计了一种高置信度更新策略,一定程度上提高了相关滤波跟踪算法的稳定性。

上述方法虽然在一定程度上改善了目标跟踪算法在复杂场景下的适应性,但跟踪模板具有单一性;且实际跟踪过程中,由于模板的不断更新,目标会逐渐偏移出模板,背景物体逐渐占据整个模板,导致模板漂移。而单一性跟踪模板无法有效避免跟踪器自身导致的模板漂移情况,从而影响后续跟踪效果,甚至会导致跟踪失败。考虑到单一性跟踪模板的不足,针对复杂场景下的目标有效跟踪问题,本文将响应峰值和交并率结合,提出了一种用于更新策略的高置信度指标;同时引入相似性度量模型自适应更新模板,动态融合两种互补跟踪算法,以提高算法的跟踪精度与跟踪稳定性。

## 2 两种具有互补性的算法

KCF 算法以核化的岭回归方法学习一个用于分类的相关滤波器,从而实现目标跟踪,具体步骤

如下。

1) 通过训练模型获得一个函数,使第  $i$  个样本  $x_i$  与岭回归目标  $y_i$  之间的平方误差最小,可表示为

$$\min_w \left\{ \sum_i [y_i - f(x_i)]^2 + \lambda \|w\|^2 \right\}, \quad (1)$$

式中,  $f(x) = w^T x$ ,  $w$  为分类器加权系数向量,  $\lambda \|w\|^2$  为正则项,  $\lambda$  为正则化系数。对基础样本  $x_i$  循环采样获得的循环数据矩阵进行傅里叶变换及对角化,可得到

$$\hat{w} = \frac{\hat{x} \odot \hat{y}}{(\hat{x})^* \odot \hat{x} + \lambda I}, \quad (2)$$

式中,  $\hat{w}$  为  $w$  的离散傅里叶变换,  $(\hat{x})^*$  为  $\hat{x}$  的复共轭,  $\odot$  为逐元素乘积符号,  $I$  为单位矩阵。利用核相关将非线性问题映射到高维线性特征空间  $\phi(x)$ , 并引入核函数求核岭回归解,可表示为

$$w = \sum_i \beta_i \phi(x_i), \quad (3)$$

$$\beta = (K + \lambda I)^{-1} y, \quad (4)$$

式中,  $K$  为核矩阵,  $\beta$  为由系数  $\beta_i$  组成的向量,  $\beta_i$  为对偶空间中的解。当  $K$  为循环矩阵时,将(4)式对角化,可得到

$$\hat{\beta} = \frac{\hat{Y}}{\hat{k}^{xx} + \lambda I}, \quad (5)$$

式中,向量  $k^{xx}$  为核矩阵  $K = C(k^{xx})$  的第一行。

2) 由基础样本  $x$  及基本图像块  $z$  循环移位得到测试样本的回归函数为

$$f(z) = (K^z)^T \beta, \quad (6)$$

式中,  $K^z = C(k^{xz})$ ,  $k^{xz}$  为  $x, z$  的核相关,  $f(z)$  为所有检测的响应,将(6)式对角化,得到

$$\hat{f}(z) = \hat{k}^{xz} \odot \hat{\beta}. \quad (7)$$

对(7)式进行离散傅里叶逆变换,得到的相关响应系数最大样本即为当前帧中目标的位置。

DAT 算法提取目标颜色特征的具体步骤如下。

1) 在输入图像  $I$  上用贝叶斯分类器区分背景像素和目标像素  $x$ 。设  $H_\Omega^I(b)$  为区域  $\Omega$  ( $\Omega \in I$ ) 内计算的非格式化直方图  $H$  的第  $b$  个块,已知矩形框范围  $O$  及其邻域  $S$ , 则用贝叶斯公式得到目标区域的概率为

$$P(x \in O | O, S, b_x) \approx \frac{P(b_x | x \in O) P(x \in O)}{\sum_{\Omega \in \{O, S\}} P(b_x | x \in \Omega) P(x \in \Omega)}, \quad (8)$$

式中,  $b_x$  为分配给  $I(x)$  颜色分量的块,  $P(b | x \in O) \approx H(b) / |O|$ ,  $P(b | x \in S) \approx H(b) / |S|$ 。则

$P(x \in O) \approx |O| / (|O| + |S|)$ , (8) 式可简化为

$$P(x \in O | O, S, b_x) = \begin{cases} \frac{H_O^1(b_x)}{H_O^1(b_x) + H_S^1(b_x)}, & I(x) \in I(O \cup S) \\ 0.5, & \text{otherwise} \end{cases} \quad (9)$$

假设当前对象为  $O$  和一系列分散注意力区域  $D$ , 将对象-干扰物模型定义为

$$P(x \in O | O, D, b_x) = \begin{cases} \frac{H_O^1(b_x)}{H_O^1(b_x) + H_D^1(b_x)}, & I(x) \in I(O \cup D) \\ 0.5, & \text{otherwise} \end{cases} \quad (10)$$

结合 (9) 式和 (10) 式得到目标模型

$$P(x \in O | b_x) = \lambda_p P(x \in O | O, D, b_x) + (1 - \lambda_p) P(x \in O | O, S, b_x), \quad (11)$$

式中,  $\lambda_p$  为预定义加权参数。

为减小目标外观变化及光照对跟踪结果的影响, 用线性差值定期更新对象模型, 可表示为

$$P_{1,T}(x \in O | b_x) = \eta P(x \in O | b_x) + (1 - \eta) P_{1,T-1}(x \in O | b_x), \quad (12)$$

式中,  $T$  为周期,  $\eta$  为学习速率。

2) 在  $t$  时刻定位目标在新一帧图像中的位置, 通过提取一个与前一帧图像目标位置成正比的矩形搜索框  $O_{t-1}$ , 得到新的目标位置  $O_t^*$  为

$$O_t^* = \operatorname{argmax} [\zeta_v(O_{t,i}) \zeta_d(O_{t,i})], \quad (13)$$

$$\zeta_v(O_{t,i}) = \sum_{x \in O_{t,i}} P_{1,t-1}(x \in O | b_x), \quad (14)$$

$$\zeta_d(O_{t,i}) = \sum_{x \in O_{t,i}} \exp\left(-\frac{\|x - c_{t-1}\|^2}{2\sigma^2}\right), \quad (15)$$

式中,  $\zeta_v(\cdot)$  为基于联合多目标模型的投票得分,  $\zeta_d(\cdot)$  为基于前一目标中心  $c_{t-1}$  的巴氏距离得分,  $\sigma$  为给定参数。

### 3 互补跟踪算法的设计

KFC 跟踪算法能有效适应光照变化、目标遮挡等场景, 统计颜色特征算法能有效适应目标形变、快速运动等场景, 两者具有较强的互补性, 基于此, 提出了一种可适应复杂场景的互补跟踪算法, 其流程图如图 1 所示。

#### 3.1 算法优化

为了获取更好的 HOG 特征, 提升 KCF 算法的精度, 利用高斯拉普拉斯算子 (LoG) 增强目标边缘信息, 利用局部二值模式 (LBP) 加强图像的纹理信息。LoG 算子首先对输入图像进行平滑滤波, 再进行拉普拉斯变换, 以增强图像边缘、有效抑制噪声干

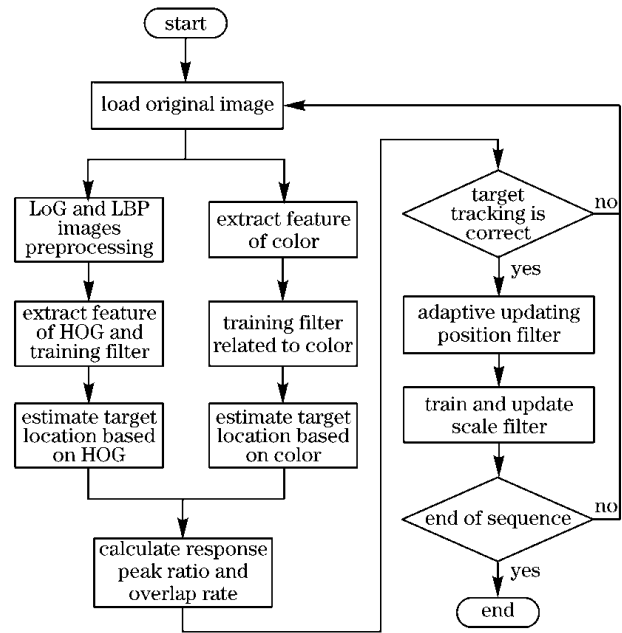


图 1 本算法的流程图

Fig. 1 Flow chart of our algorithm

扰, 可表示为

$$\nabla^2 G(x_G, y_G) = \frac{\partial^2 G(x_G, y_G)}{\partial x_G^2} + \frac{\partial^2 G(x_G, y_G)}{\partial y_G^2}, \quad (16)$$

式中,  $G(x_G, y_G)$  是标准差为  $\delta$  的二阶高斯函数,  $\nabla^2$  为二阶偏导数, 由 (16) 式可知

$$\nabla^2 G(x_G, y_G) = \left(\frac{x_G^2 + y_G^2 - 2\delta^2}{\delta^4}\right) \exp\left(-\frac{x_G^2 + y_G^2}{2\delta^2}\right). \quad (17)$$

将 LoG 算子与输入图像  $f(x_G, y_G)$  进行线性卷积运算, 寻找  $g(x_G, y_G)$  的零交叉点以获得边缘  $f(x_G, y_G)$ , 可表示为

$$g(x_G, y_G) = [\nabla^2 G(x_G, y_G)] \otimes f(x_G, y_G). \quad (18)$$

LBP 以  $3 \times 3$  窗口的中心像素为阈值, 将相邻 8 个像素中灰度值大于中心像素值的像素标记为 1, 其余像素标记为 0, 并将产生的 8 位二进制数转换成十进制数作为该窗口中心像素点的 LBP 值, 以反映该区域的纹理信息。

Montero 等<sup>[18]</sup> 提出可扩展 KCF (sKCF) 算法, 引入可调高斯窗口函数, 用基于关键点的尺度估计模型, 给予距中心点远近不同的特征点不同的权值, 以适应目标尺度的变化。但 sKCF 算法的尺度自适应过程具有独立性, 因此还需单独训练一个尺度滤波器, 以适应目标的尺度变化, 抑制模板漂移。

#### 3.2 基于峰值交并率的高置信度更新策略

实验使用的视频为每秒变化超过 24 帧的连续

图像,前一帧和当前帧的目标跟踪框交并率可表示为

$$d = \frac{S_{\text{late}} \cap S_{\text{now}}}{S_{\text{late}} \cup S_{\text{now}}}, \quad (19)$$

式中,  $S_{\text{now}}$ 、 $S_{\text{late}}$  分别为前一帧目标跟踪框与当前帧目标跟踪框的面积。

相关滤波跟踪的理想响应输出是峰值尖锐、周围平滑的二维高斯函数模型。当目标没有遇到遮挡、形变和相似目标干扰时,响应峰呈尖而窄的形状;当目标受到干扰时,类高斯函数的峰值不仅会下降,还可能出现多峰值情况。因此引入响应峰值比

$$P = \frac{y_{\text{max}}}{\bar{y}}, \quad (20)$$

式中,  $y_{\text{max}}$  为响应峰值,  $\bar{y}$  为平均响应值。

设置交并率阈值  $d_0$ , 响应峰值比阈值  $P_0$ , 当交并率与响应峰值比同时高于设定阈值则视为跟踪准确。记目标跟踪框交并率与响应峰值比的乘积为  $R$ , 则跟踪模板  $T_{\text{next}}$  可表示为

$$T_{\text{next}} = \begin{cases} T_{\text{KCF}}, & \max(R) = R_{\text{KCF}} \\ T_{\text{DAT}}, & \max(R) = R_{\text{DAT}}, \\ T_{\text{late}}, & \max(R) = R_0 \end{cases}, \quad (21)$$

式中,  $T_{\text{KCF}}$  为 KCF 算法的跟踪模板,  $T_{\text{DAT}}$  为 DAT 算法的跟踪模板,  $T_{\text{late}}$  为未更新的跟踪模板, 且  $R_{\text{KCF}} = P_{\text{KCF}} \cdot d_{\text{KCF}}$ ,  $R_{\text{DAT}} = P_{\text{DAT}} \cdot d_{\text{DAT}}$ ,  $R_0 = P_0 \cdot d_0$ 。

固定的模板更新速率在复杂场景下容易发生模板漂移, 因此, 引入相似性度量模型自适应控制更新速率。采取巴氏距离判断当前跟踪结果与前 5 帧图像平均值的相似程度, 当巴氏距离得分高于设定阈值时, 更新模板; 低于设定阈值时, 则不更新模板。第  $k$  次自适应更新模板可表示为

$$\begin{cases} D^k(\bar{R}, R_{\text{result}}) = \sqrt{1 - \frac{\sum_i [\bar{R}(i) \cdot R_{\text{result}}(i)]^2}{\sum_i \bar{R}(i) \cdot R_{\text{result}}(i)}}, \\ M_{\text{next}} = \beta M_{\text{result}} + (1 - \beta) M_{\text{cur}} \end{cases}, \quad (22)$$

式中,  $D^k(\bar{R}, R_{\text{result}})$  为当前结果的前 5 帧图像平均值  $\bar{R}$  与当前预测结果  $R_{\text{result}}$  的相似性,  $\beta$  为自适应更新参数,  $\beta = c \cdot D^k(\bar{R}, R_{\text{result}})$ ,  $c$  为固定常数,  $M_{\text{next}}$  为完成下一帧目标跟踪所需的模型,  $M_{\text{result}}$  为当前结果训练的预测模型,  $M_{\text{cur}}$  为当前模型。

## 4 实验结果及分析

为验证本算法在目标遮挡、形变、旋转、光照变

化及背景干扰等复杂场景下的跟踪性能, 将本算法与其他算法进行对比实验。

### 4.1 实验环境与参数设置

实验的硬件及软件环境如表 1 所示。

表 1 实验环境

Table 1 Experimental environment

Specific configuration	Configuration data
CPU	Intel Core i7-7700HQ
Frequency /GHz	2.80
RAM /G	8
Operating system	64bit Windows10
Development tool	MatlabR2017a

将本算法与多特征线性融合的尺度自适应核相关滤波跟踪算法 SAMF、空间正则化相关滤波跟踪算法 SRDCF、DAT 算法、基于特征融合和尺度自适应的干扰感知目标跟踪算法 DATHOG、KCF 算法、DSST 算法、Staple 算法在 OTB2013 数据集<sup>[19]</sup> 50 个视频序列上进行定量分析, 在 OTB2015 数据集<sup>[20]</sup> 中选取 7 组典型视频序列进行定性分析。视频序列涉及的属性包括光照变化 (IV)、遮挡 (OCC)、平面内旋转 (IPR)、尺度变化 (SV)、快速运动 (FM)、运动模糊 (MB)、平面外旋转 (OPR)、出视野 (OV)、形变 (DEF)、背景干扰 (BC)、低分辨率 (LR), 7 组典型视频序列的属性如表 2 所示。

表 2 实验视频序列的属性

Table 2 Properties of the experimental video sequence

Sequence	Frame	Attribute
Boy	602	SV, MB, FM, IPR, OPR
Coke	291	IV, OCC, FM, IPR, OPR, BC
Human4	667	IV, SV, OCC, DEF, MB, FM, OPR
BlurOwl	631	SV, MB, FM, IPR
Box	1161	IV, SV, OCC, MB, IPR, OPR, OV, BC, LR
FleetFace	707	SV, DEF, MB, FM, IPR, OPR
Liquor	1741	IV, SV, OCC, MB, FM, OPR, OV, BC

### 4.2 定量分析

实验以 OPE (One-pass evaluation) 为评价算法性能的标准, 包括精确度曲线和成功率曲线。精确度指中心位置误差 (CLE) 小于设定阈值的帧数占视频总帧数的比值。  $n$  帧视频序列的 CLE 可表示为

$$X_{\text{CLE}} = \frac{1}{n} \sum_{i=1}^n \left[ \sqrt{(u_i - u_0)^2 + (v_i - v_0)^2} \right], \quad (23)$$

式中,  $(u_i, v_i)$  为算法预估的目标中心位置坐标,  $(u_0, v_0)$  为目标实际的中心位置坐标。实验将中心位置误差阈值设置为 20 个像素。重叠率(OR)为预测目标区域与实际目标区域的重叠面积和预测目标区域与实际目标区域覆盖总面积的比值。成功率指重叠率大于设定阈值帧数占全部帧数的比值, 实验中的重叠率阈值均设置为 0.5。

在 OTB2013 数据集中, 含 IV 属性的序列有 22 组、含 OCC 属性的序列有 29 组、含 IPR 属性的序列有 26 组、含 SV 属性的序列有 38 组、含 FM

属性的序列有 27 组、含 MB 属性的序列有 20 组、含 OPR 属性的序列有 32 组、含 OV 属性的序列有 9 组、含 DEF 属性的序列有 23 组、含 BC 属性的序列有 20 组、含 LR 属性的序列有 10 组。测试并分别记录 8 种算法的成功率和精确度, 结果如表 3 和表 4 所示。可以发现, 本算法的跟踪精确度在 11 种属性序列中均取得第一名, 在跟踪成功率的表现上, 仅在 LR 属性序列上稍逊色于 SRDCF 算法, 这表明本算法在复杂场景下的目标跟踪稳定性较好。

表 3 8 种算法在 11 种属性序列上的跟踪精确度

Table 3 Tracking precisions of 8 algorithms on 11 attribute sequences

Algorithm	IV	OCC	IPR	SV	FM	MB	OPR	OV	DEF	BC	LR
SAMF	0.605	0.638	0.592	0.608	0.555	0.556	0.529	0.571	0.570	0.587	0.705
SRDCF	0.707	0.675	0.680	0.684	0.726	0.707	0.584	0.597	0.639	0.723	0.633
DAT	0.245	0.396	0.395	0.391	0.292	0.238	0.375	0.423	0.381	0.205	0.456
DATHOG	0.742	0.693	0.701	0.720	0.634	0.674	0.697	0.552	0.707	0.795	0.732
KCF	0.396	0.363	0.403	0.343	0.301	0.310	0.337	0.252	0.329	0.459	0.384
DSST	0.654	0.588	0.638	0.569	0.478	0.491	0.523	0.430	0.521	0.660	0.577
Staple	0.656	0.651	0.623	0.612	0.631	0.621	0.564	0.688	0.656	0.624	0.586
Ours	<b>0.821</b>	<b>0.826</b>	<b>0.817</b>	<b>0.832</b>	<b>0.844</b>	<b>0.841</b>	<b>0.792</b>	<b>0.872</b>	<b>0.798</b>	<b>0.873</b>	<b>0.903</b>

表 4 8 种算法在 11 种属性序列上的跟踪成功率

Table 4 Tracking success rates of 8 algorithms on 11 attribute sequences

Algorithm	IV	OCC	IPR	SV	FM	MB	OPR	OV	DEF	BC	LR
SAMF	0.526	0.557	0.533	0.510	0.467	0.470	0.449	0.492	0.491	0.533	0.559
SRDCF	0.617	0.587	0.612	0.612	0.676	0.632	0.503	0.528	0.549	0.624	<b>0.604</b>
DAT	0.222	0.307	0.291	0.292	0.274	0.251	0.286	0.353	0.324	0.197	0.230
DATHOG	0.632	0.607	0.591	0.653	0.691	0.620	0.571	0.552	0.582	0.672	0.586
KCF	0.323	0.271	0.336	0.261	0.282	0.284	0.261	0.241	0.270	0.401	0.258
DSST	0.569	0.492	0.539	0.473	0.426	0.427	0.423	0.391	0.469	0.589	0.439
Staple	0.588	0.570	0.545	0.524	0.553	0.529	0.478	0.507	0.590	0.576	0.466
Ours	<b>0.691</b>	<b>0.673</b>	<b>0.682</b>	<b>0.668</b>	<b>0.719</b>	<b>0.732</b>	<b>0.650</b>	<b>0.736</b>	<b>0.635</b>	<b>0.758</b>	0.587

为了进一步分析 8 种算法的综合性能, 在 OTB2013 数据集上对算法进行测试, 分别记录 8 种算法的平均中心位置误差  $X_{CLE}$  与平均处理速度  $X_{FPS}$ , 结果如表 5 所示。以曲线下面积(AUC)方式绘制曲线, 结果如图 2 所示。

实验使用的视频序列场景为 IV、SV、FM 以及 OV 等多种干扰因素并存的复杂场景。由表 4 可知, 本算法的平均中心位置误差  $X_{CLE}$  为 11.59 pixel, 比次优算法 Staple 高 34.26 pixel, 这表明本算法在复杂场景中能更好地抑制模板漂移, 实现目标的稳定跟踪。且本算法同时训练了两个跟踪器模板, 在提高精度和减小中心位置误差的同时,

表 5 不同算法的  $X_{CLE}$  与  $X_{FPS}$

Table 5  $X_{CLE}$  and  $X_{FPS}$  of different algorithms

Algorithm	$X_{CLE}/\text{pixel}$	$X_{FPS}(\text{frame} \cdot \text{s}^{-1})$
SAMF	50.04	16.84
SRDCF	53.14	5.62
DAT	90.87	60.14
DATHOG	49.12	87.23
KCF	117.76	<b>304.99</b>
DSST	61.08	41.28
Staple	45.85	6.07
Ours	<b>11.59</b>	10.74

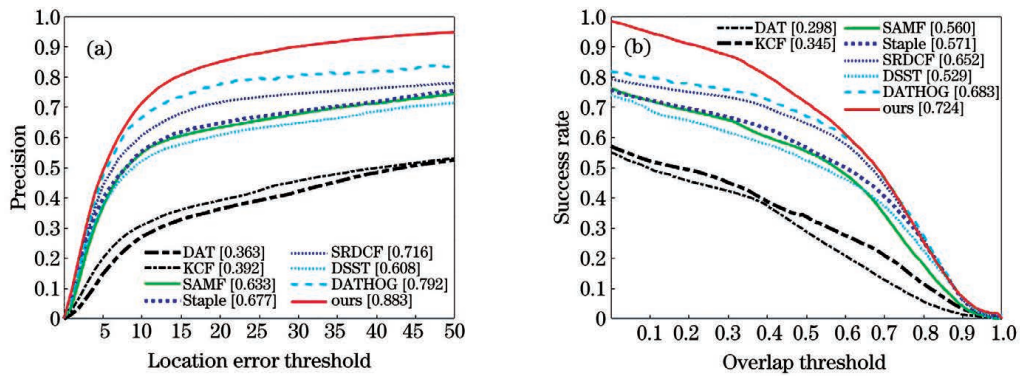


图 2 不同算法在 OTB2013 数据集上的测试结果。(a)精确度;(b)成功率

Fig. 2 Test results of different algorithms on the OTB2013 data set. (a) Precision; (b) success rate

降低了处理速度,平均处理速度  $X_{FPS}$  仅为 10.74 frame/s。由图 2 可知,本算法在 OTB2013 数据集上的总体精确度和总体成功率分别达到了 88.3%和 72.4%,相比两种基础算法有显著提升,比次优算法 DATHOG 的总体精确度和成功率分别提高了 9.1%和 4.1%,验证了本算法在复杂场景下

具有更高的跟踪精度与稳定性。

### 4.3 定性分析

选取 3 组典型视频序列,将本算法与两种基础算法进行对比实验,并进行定性分析,以验证本算法利用两个具有互补性跟踪算法的可行性,同时给出了基准跟踪框 ground truth,结果如图 3 所示。



图 3 3 种算法的定性分析结果。(a) Boy;(b) Coke;(c) Human4

Fig. 3 Qualitative analysis results of 3 algorithms. (a) Boy; (b) Coke; (c) Human4

从图 3(a)的 Boy 视频序列可以看出,在第 504 帧男孩快速跳跃旋转时,KCF 算法跟踪框逐渐漂移,最终跟踪失败,而本算法与 DAT 算法能有效应对目标的快速运动、旋转与运动模糊现象,实现目标的有效跟踪;从图 3(b)的 Coke 视频序列可以看出,在 184 帧光照强度骤然变化时,DAT 算法无法有效应对,导致跟踪失败,而本算法和 KCF 算法能有效

应对光照变化及目标遮挡,且本算法的跟踪结果更准确;从图 3(c)的 Human4 视频序列可以看出,在 133 帧目标快速运动且被路牌完全遮挡时,KCF 算法的跟踪框将目标定位到路牌上,导致跟踪失败,在 431 帧目标产生运动模糊、遮挡且存在花坛背景干扰时,DAT 算法跟踪框跟踪失败,但本算法结合 KCF 算法与 DAT 算法的优势,实现了有效且精确

的目标跟踪,这验证了利用两个具有互补性跟踪算法的可行性。

为了进一步分析本算法在复杂场景下的性能,

将本算法与 SAMF、SRDCF、Staple、DSST、DATHOG 算法在 4 组典型视频序列上进行对比实验,并给出基准跟踪框 ground truth,结果如图 4 所示。



图 4 6 种算法的定性分析结果。(a) BlurOwl1;(b) Box ;(c) FleetFace ;(d) Liquor

Fig. 4 Qualitative analysis results of 6 algorithms. (a) BlurOwl1; (b) Box; (c) FleetFace; (d) Liquor

从图 4(a) 的 BlurOwl1 视频序列可以发现,在 151 帧目标快速运动且发生运动模糊时,SAMF、SRDCF、Staple、DSST 算法的跟踪框均发生不同程度的漂移,在 159 帧时,SAMF、Staple 以及 DSST 算法的跟踪框彻底丢失目标。从第 387 帧图像可以发现,SAMF 算法扩大搜索范围后仍然无法再次跟踪目标,而本算法、DATHOG 和 SRDCF 算法均能有效应对目标的快速运动及运动模糊,实现目标的有效跟踪。从图 4(b) 的 Box 视频序列中可以看出,在 462 帧目标快速移动到遮挡物后且被严重遮挡时,SAMF、DSST 算法的跟踪框逐渐丢失目标信息,在 507 帧目标快速从遮挡物后移出时,DATHOG、SRDCF、Staple 及 DSST 算法跟踪失败,仅本算法和 SAMF 算法实现了目标的有效跟踪,且本算法的跟踪精度更高;从图 4(c) 的 FleetFace 视频序列中可以看出,在 442 帧目标开始旋转时,6 种算法的跟踪框均开始出现漂移,在 568

帧时,DATHOG 算法跟踪框丢失部分目标信息,SAMF、SRDCF、Staple、DSST 算法的跟踪框目标信息丢失严重。从第 442 帧到 604 帧可以看出,5 种对比算法跟踪框内丢失的目标信息逐渐增多,而本算法跟踪框内丢失的目标信息逐渐减少,可以很好地适应目标旋转、尺度变化、形变以及快速运动等复杂场景,体现出较好的跟踪稳定性与跟踪精度。从图 4(d) 的 Liquor 视频序列中可以发现,在 511 帧时目标瓶子被快速移动类似瓶子遮挡,SAMF 算法跟踪框错误锁定至干扰目标,导致跟踪失败;在 736 帧时目标瓶子被快速移动的绿色瓶子遮挡,DSST 算法跟踪框错误锁定至干扰目标,导致跟踪失败,而本算法和其余 3 种对比算法可以正确跟踪目标;从 1064 帧到 1565 帧可以看出,Staple 算法在跟踪过程中不断扩大搜索范围,虽然跟踪框内含有全部目标信息,但冗余信息过多,而 DATHOG、SRDCF 算法和本算法能实现目标精确的跟踪,这表明本算法

在复杂场景中的跟踪稳定性较好。

## 5 结 论

针对目标跟踪中目标遮挡、形变及旋转、光照变化及背景干扰等复杂场景下的目标跟踪问题,首先,利用 LoG 算子与 LBP 增强目标边缘信息与纹理特征;然后,引入可调高斯窗口函数和基于关键点的尺度估计模型优化算法;最后,利用峰值交并率设计了一种高置信度更新策略以自适应更新跟踪模板。实验结果表明,本算法在高置信度条件下充分发挥了两种算法各自的优势,精确度和成功率分别达到 88.3% 和 72.4%。5 种对比算法在场景复杂且帧数大于 500 帧的序列中均出现模板漂移、目标信息逐渐丢失的情况,而本算法能有效抑制模板漂移,在复杂场景下实现对目标更精确、稳定的跟踪。但算法的高复杂度导致目标跟踪的实时性较低,因此,还需在目标跟踪实时性方面对算法进行优化,以全面提升算法的综合性能。

## 参 考 文 献

- [1] Deshpande A M, Telikicherla A K, Jakkali V, et al. Computer vision toolkit for non-invasive monitoring of factory floor artifacts[J]. *Procedia Manufacturing*, 2020, 48: 1020-1028.
- [2] Shen J B, Tang X, Dong X P, et al. Visual object tracking by hierarchical attention siamese network [J]. *IEEE Transactions on Cybernetics*, 2020, 50 (7): 3068-3080.
- [3] Zhou Z W, Luo W H, Wang Q, et al. Distractor-aware discrimination learning for online multiple object tracking[J]. *Pattern Recognition*, 2020, 107: 107512.
- [4] You S X, Diao M, Gao L P, et al. Target tracking strategy using deep deterministic policy gradient[J]. *Applied Soft Computing*, 2020, 95: 106490.
- [5] Li Y, Yang D D, Han Y J, et al. Siamese neural network object tracking with distractor-aware model [J]. *Acta Optica Sinica*, 2020, 40(4): 0415002.  
李勇, 杨德东, 韩亚君, 等. 融合扰动感知模型的孪生神经网络目标跟踪[J]. *光学学报*, 2020, 40(4): 0415002.
- [6] Shen Y L, Wu Z D, Zhao R J, et al. Long-term object tracking based on model updating and fast re-detection [J]. *Acta Optica Sinica*, 2020, 40 (3): 0315002.  
沈玉玲, 伍忠东, 赵汝进, 等. 基于模型更新与快速重检测的长时目标跟踪[J]. *光学学报*, 2020, 40 (3): 0315002.
- [7] Fan M, Fan Y S, Ren F H. Moving target tracking algorithm based on improved TLD [J]. *Laser & Optoelectronics Progress*, 2020, 57(12): 121021.  
樊萌, 樊永生, 任福汉. 基于改进 TLD 的运动目标跟踪算法研究[J]. *激光与光电子学进展*, 2020, 57 (12): 121021.
- [8] Zhang J, Huang H M, Wang J M, et al. An improved TLD real-time target tracking algorithm based on CN algorithm[J]. *Computer Engineering & Science*, 2020, 42(7): 1215-1225.  
张晶, 黄浩森, 王健敏, 等. 融合 CN 跟踪算法改进的 TLD 实时目标跟踪算法[J]. *计算机工程与科学*, 2020, 42(7): 1215-1225.
- [9] Zhang H Y, Hu W B. Scale-adaptive correlation filter tracking based on multiple features[J]. *Systems Engineering and Electronics*, 2019, 41(5): 951-957.  
张红颖, 胡文博. 多特征融合的尺度自适应相关滤波跟踪算法[J]. *系统工程与电子技术*, 2019, 41(5): 951-957.
- [10] Mao Z C, Chen H D. Long-term object tracking algorithm based on kernelized correlation filter [J]. *Laser & Optoelectronics Progress*, 2019, 56 (1): 010702.  
茅正冲, 陈海东. 基于核相关滤波的长期目标跟踪算法[J]. *激光与光电子学进展*, 2019, 56(1): 010702.
- [11] Li S S, Zhao G P, Wang J Y. Distractor-aware object tracking based on multi-feature fusion and scale-adaption [J]. *Acta Optica Sinica*, 2017, 37 (5): 0515005.  
李双双, 赵高鹏, 王建宇. 基于特征融合和尺度自适应的干扰感知目标跟踪[J]. *光学学报*, 2017, 37 (5): 0515005.
- [12] Chen F L, Ding Q H, Chang Z, et al. Multi-scale kernel correlation filter algorithm for visual tracking based on the fusion of adaptive features [J]. *Acta Optica Sinica*, 2020, 40(3): 0315001.  
陈法领, 丁庆海, 常铮, 等. 自适应特征融合的多尺度核相关滤波目标跟踪[J]. *光学学报*, 2020, 40 (3): 0315001.
- [13] Bertinetto L, Valmadre J, Golodetz S, et al. Staple: complementary learners for real-time tracking [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 1401-1409.
- [14] Danelljan M, Häger G, Khan F S, et al. Discriminative scale space tracking [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2017, 39(8): 1561-1575.
- [15] Pan C C, Liu Y Y, Zheng Z Q, et al. Kernel correlation filtering target tracking based on quasi-



- residual updating strategy[J]. *Electronics Optics & Control*, 2019, 26(10): 1-6.  
潘长城, 刘妍妍, 郑志强, 等. 类残差更新策略的核相关滤波目标跟踪[J]. *电光与控制*, 2019, 26(10): 1-6.
- [16] Pan J Y, Hu B, Zhang J Q. A template-drift-resistant object tracking algorithm[J]. *Acta Electronica Sinica*, 2009, 37(3): 622-627.  
潘吉彦, 胡波, 张建秋. 抑制模板漂移的目标跟踪算法[J]. *电子学报*, 2009, 37(3): 622-627.
- [17] Lin B, Li Y. High-speed correlation filter tracking algorithm based on high-confidence updating strategy [J]. *Acta Optica Sinica*, 2019, 39(4): 0415003.  
林彬, 李映. 基于高置信度更新策略的高速相关滤波跟踪算法[J]. *光学学报*, 2019, 39(4): 0415003.
- [18] Montero A S, Lang J, Laganière R. Scalable kernel correlation filter with sparse feature integration[C]//2015 IEEE International Conference on Computer Vision Workshop (ICCVW), December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 587-594.
- [19] Wu Y, Lim J, Yang M H. Online object tracking: a benchmark[C]//2013 IEEE Conference on Computer Vision and Pattern Recognition, June 23-28, 2013, Portland, OR, USA. New York: IEEE Press, 2013: 2411-2418.
- [20] Wu Y, Lim J, Yang M H. Object tracking benchmark[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2015, 37(9): 1834-1848.