

DOI: 10.19650/j.cnki.cjsi.J2210146

基于自适应标签和稀疏学习相关滤波的 红外目标跟踪算法研究*

黄月平, 李小锋, 卢瑞涛, 齐乃新, 张胜修
(火箭军工程大学导弹工程学院 西安 710025)

摘要:针对背景杂乱、遮挡、热交叉以及目标形变等复杂跟踪场景下目标跟踪算法出现性能严重退化问题,提出一种基于自适应标签和稀疏学习相关滤波的实时红外单目标跟踪算法。首先,根据目标响应情况自适应地构造样本标签,通过自适应标签训练提升相关滤波器的分类能力,抑制干扰区域对跟踪模型的污染。其次,加入稀疏学习策略,通过目标响应 L1 范数抑制复杂跟踪场景下目标响应多峰分布,提高跟踪算法的鲁棒性;与基线算法相比,该算法精度和 AUC 分别提升了 19.3% 和 39.8%。在数据集 GTOT、RGBT234 和 VOT-2016TIR 上的实验结果表明,该算法对上述复杂跟踪场景具有良好的应对能力,运行速度超过 35 fps,综合性能优于对比跟踪算法。

关键词: 计算机视觉; 红外目标跟踪; 相关滤波; 稀疏学习

中图分类号: TP391 TH741 **文献标识码:** A **国家标准学科分类代码:** 520.20

Research on infrared object tracking algorithm via adaptive label and sparse-learning correlation filter

Huang Yueping, Li Xiaofeng, Lu Ruitao, Qi Naixin, Zhang Shengxiu

(College of Missile Engineering, Rocket Force University of Engineering, Xi'an 710025, China)

Abstract: To deal with the serious performance degradation of target tracking algorithms in complex tracking scenes, such as background clutter, occlusion, thermal crossover, and target deformation, a real-time infrared single object tracking algorithm based on the adaptive label and sparse-learning correlation filter is proposed. First, sample labels are constructed based on the target response adaptively, and the discrimination ability of the correlation filter is enhanced by training with adaptive sample labels, which suppresses the pollution of the interference region to the tracking model. Secondly, the sparse learning strategy is introduced to suppress the multi-peak distribution of the response map in complex tracking scenes by its L1 norm, resulting in improving the robustness of the tracking algorithm. Compared with the baseline algorithm, the precision and AUC of the proposed algorithm are improved by 19.3% and 39.8%, respectively. Experimental results on datasets GTOT, RGBT234, and VOT-2016TIR show that the proposed algorithm has a strong ability to deal with the above complex tracking scenes. Its running speed is over 35 fps, and its comprehensive performance is better than the compared tracking algorithms.

Keywords: computer vision; infrared object tracking; correlation filter; sparse learning

0 引 言

红外目标跟踪是计算机视觉的重要研究领域,其在给定目标初始状态的前提下,对红外视频序列中目标的位置和尺寸进行估计。红外目标跟踪具有全天候工作、

抗干扰能力强等优点,被广泛应用于军事侦察、精确制导武器、智能视频监控、智能导航系统以及人机交互等领域。与可见光图像相比,红外图像通常具有纹理缺失、空间分辨率低以及信噪比低等特点^[1]。跟踪过程中目标尺寸、形状等外观变化以及遮挡、热交叉、背景杂乱等场景复杂性,使得对红外目标进行实时可靠地跟踪仍然面临

收稿日期:2022-07-17 Received Date: 2022-07-17

* 基金项目:国家自然科学基金(62006240)、陕西省自然科学基金(2021JQ-373)项目资助

严峻挑战。

基于相关滤波的目标跟踪算法根据相关性理论,利用循环移位构建密集样本,将相关滤波器作为二分类器,通过对目标和背景的区分,实现对目标的跟踪^[2-4]。该类算法具有跟踪速度快、跟踪精度高的优良综合性能,已成为红外目标跟踪领域的研究热点。2010年 Bolme 等^[5]提出的最小输出平方误差和(minimum output sum of squared error, MOSSE)算法以及2015年 Henriques 等^[6]提出的核相关滤波算法(kernelized correlation filter, KCF)算法奠定了相关滤波目标跟踪算法的理论基础,此后该类算法在尺度估计、边界效应抑制、特征选择以及模型退化缓解等方面不断改进。Mueller 等^[7]将目标周围的4个背景块作为负样本,训练具有上下文信息感知能力的相关滤波器,显著提高了相关滤波器在背景杂乱、形变等挑战下的分类能力。相关滤波跟踪算法的目标响应图蕴含丰富信息,其最大值可以预测目标位置,其峰值和波动可以评估跟踪结果的置信度、预测是否出现异常干扰等情况。Fu 等^[8]利用目标响应图的局部极大值定位干扰物,训练过程中通过对干扰区域的相关滤波器响应进行抑制,从而达到提升跟踪模型的抗干扰能力。黄月平等^[9]提出难例挖掘策略,利用目标响应图的极值确定干扰区域,将干扰区域作为额外负样本对相关滤波器进行训练,提高了相关滤波器的抗干扰能力,从而缓解了模型退化问题。文献[7]和[9]通过提升相关滤波器训练负样本的数质量,有效提升了相关滤波器的分类能力,但需要额外提取相关负样本的特征图,显著增加了跟踪算法的计算负担。为缓解训练样本有限造成的相关滤波器过拟合,相关滤波目标跟踪算法常采用L2范数对相关滤波器系数进行稀疏正则化。Zhang 等^[10]在相关滤波器训练时,利用目标响应稀疏正则化替代相关滤波器系数稀疏正则化,在防止过拟合的同时对响应图的异常峰值进行抑制。Xu 等^[11]认为L2范数降低了模型可解释性,其对相关滤波器系数和时间一致性均采用L1范数约束,利用相邻时刻相关滤波器相似性进一步强化相关滤波器系数的稀疏性。该方法在低维流形上学习相关滤波器,具有良好解释性,但在求解过程中将时间一致性项L1范数替代为L2范数,对目标函数进行了近似求解。

针对上述问题,本文提出了基于自适应标签和稀疏学习相关滤波(adaptive label and sparse-learning correlation filter, ALSCF)的红外单目标跟踪算法。在相关滤波器训练时,样本标签函数由目标响应情况自适应确定,通过将干扰区域的样本标签置零,实现隐性挖掘困难负样本,以提高相关滤波器的抗干扰能力;通过目标响应L1范数约束,获得稀疏目标响应图,防止相关滤波器过拟合,并对复杂跟踪场景导致的目标响应多峰干扰进行缓解;最后利用交替方向乘子法和软阈值方法高效求解跟踪模型。

1 ALSCF 算法

1.1 自适应标签策略

当基于相关滤波的目标跟踪算法对目标进行可靠跟踪时,目标响应最大值对应的区域通常为区域,其余局部极大值对应于干扰区域。但是当跟踪场景出现背景杂乱、相似物干扰、目标形变等不利因素时,目标响应图容易呈现多峰分布,甚至出现目标区域响应值低于干扰区域响应值,造成模型退化以及跟踪漂移。

针对上述情况,本文在相关滤波器训练时提出了自适应标签策略。常规相关滤波器训练时,通过将训练图像块循环移位生成密集样本,并对训练样本分配高斯分布型的软标签 \mathbf{y} ,其计算公式为:

$$\mathbf{y}(m, n) = e^{-\frac{1}{2\sigma^2} \left(\left(m - \frac{M}{2} \right)^2 + \left(n - \frac{N}{2} \right)^2 \right)} \quad (1)$$

式中: M 和 N 分别为训练图像块的高和宽, $m \in \{0, 1, \dots, M-1\}$, $n \in \{0, 1, \dots, N-1\}$; σ 为高斯函数方差。

本文在相关滤波器训练时,根据当前帧的目标响应情况在固定的高斯分布型的软标签 \mathbf{y} 的基础上自适应调整样本标签值。自适应标签策略具体过程为:在第 t 帧中,将目标响应图 \mathbf{R}_t 中取值排名前 K 的局部极大值对应的区域视为干扰区域;在相关滤波器训练时,采用空间正则化方法将相关滤波器系数集中于中心区域,并将干扰区域视作困难负样本;然后通过第 $t-1$ 和 t 帧的目标响应最大值之间的位移量确定困难负样本对应的样本标签在 \mathbf{y} 中的位置;最后在 \mathbf{y} 中将困难负样本所对应的标签值设置为0,其余标签值保持不变,从而获得自适应标签函数 \mathbf{y}_t 用于相关滤波器训练。此时,自适应标签函数 \mathbf{y}_t 为:

$$\mathbf{y}_t = \mathbf{y} \odot \mathbf{m}_t \quad (2)$$

$$\mathbf{m}_t = \mathbf{I} - \Gamma(\mathbf{R}_t \oplus \Delta) \quad (3)$$

式中: t 为序列帧号; \odot 为哈达玛(hadamard)乘积; \mathbf{I} 为全1矩阵; \mathbf{R}_t 为第 t 帧的目标响应图; Δ 为第 $t-1$ 和 t 帧的目标响应最大值之间的位移; \oplus 为循环移位操作符。 $\Gamma(\cdot)$ 为局部极大值截取函数,排名前 K 的局部极大值处取值为1,其余位置均为0。如图1所示,本文根据目标响应图的最大值和局部极大值分别确定当前帧的目标区域和干扰区域,其中实线框代表目标区域、虚线框代表干扰区域; \mathbf{m}_t 为由0和1构成的二值矩阵,其中干扰区域对应的位置取值为0,其余位置取值为1。

自适应标签策略根据目标响应情况自适应地构造样本标签函数,能够实现困难负样本的隐性挖掘,改善训练样本质量,从而增强相关滤波器的分类能力,抑制背景杂乱、相似物干扰、目标形变等不利因素造成的模型退化以及跟踪漂移。

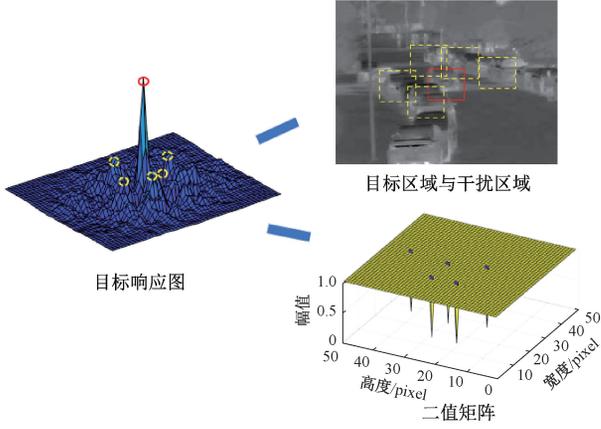


图1 自适应标签策略示意图

Fig.1 Diagram of adaptive label strategy

1.2 ALSCF 跟踪模型

在跟踪背景简单均匀的理想情况下,相关滤波跟踪算法的目标响应图容易获得具有单一峰值的高斯型分布。但在实际跟踪过程中,场景复杂性和目标外观变化等使得该条件难以满足,目标响应图通常呈现多峰分布。利用稀疏正则化对目标响应进行约束,可缓解响应图多峰干扰情况,并抑制相关滤波器过拟合。因此,参考文献[10]和[11],本文提出了稀疏学习策略。该策略为在相关滤波器的目标函数中加入目标响应的L1范数约束。通过该约束可获得稀疏的目标响应,使目标响应的能量主要集中于目标区域,抑制非目标区域的异常峰值,从而建立稳健的跟踪模型。为进一步实现在背景杂乱、遮挡、热交叉以及目标形变等复杂跟踪场景下对红外目标的可靠跟踪,本文利用自适应标签策略来缓解边界效应和隐性提高相关滤波器训练样本质量。因此,本文ALSCF算法中相关滤波器通过将下列目标函数最小化进行训练:

$$\mathcal{L}(\mathbf{h}_t) = \frac{1}{2} \left\| \sum_{d=1}^D \mathbf{x}_t^d \otimes \mathbf{h}_t^d - \mathbf{y}_t \right\|_2^2 + \frac{1}{2} \lambda_1 \sum_{d=1}^D \|\mathbf{w} \odot \mathbf{h}_t^d\|_2^2 + \frac{1}{2} \lambda_2 \left\| \sum_{d=1}^D \mathbf{x}_t^d \otimes \mathbf{h}_t^d \right\|_1 \quad (4)$$

式中: $\mathbf{x}_t = [\mathbf{x}_t^1, \mathbf{x}_t^2, \dots, \mathbf{x}_t^D] \in R^{T \times D}$ 为训练图像特征图; T 为训练图像像素个数; D 为特征图通道数; $\mathbf{h}_t = [\mathbf{h}_t^1, \mathbf{h}_t^2, \dots, \mathbf{h}_t^D] \in R^{T \times D}$ 为相关滤波器; \otimes 为循环相关操作符; \mathbf{y}_t 为向量化自适应标签函数; \mathbf{w} 为空间正则化的权重矩阵; λ_1 为空间正则化系数; λ_2 为稀疏正则化系数。

式(4)在频域中可简化表示为:

$$\mathcal{L}(\hat{\mathbf{g}}_t, \mathbf{h}_t, \hat{\mathbf{p}}_t) = \frac{1}{2T} \left\| \sum_{d=1}^D \hat{\mathbf{g}}_t^{d*} \odot \hat{\mathbf{x}}_t^d - \hat{\mathbf{y}}_t \right\|_2^2 +$$

$$\frac{1}{2} \lambda_1 \sum_{d=1}^D \|\mathbf{w} \odot \mathbf{h}_t^d\|_2^2 + \frac{1}{2} \lambda_2 \|\hat{\mathbf{p}}_t\|_1$$

$$\text{s. t. } \hat{\mathbf{g}}_t^d = \sqrt{T} \mathbf{F} \mathbf{h}_t^d$$

$$\hat{\mathbf{p}}_t = \sum_{d=1}^D \hat{\mathbf{g}}_t^{d*} \odot \hat{\mathbf{x}}_t^d \quad (5)$$

式中: $\hat{\mathbf{x}}_t$ 和 $\hat{\mathbf{y}}_t$ 分别为 \mathbf{x}_t 和 \mathbf{y}_t 的离散傅里叶变换; \mathbf{F} 为离散傅里叶变换矩阵; $\hat{\mathbf{g}}_t = [\hat{\mathbf{g}}_t^1, \hat{\mathbf{g}}_t^2, \dots, \hat{\mathbf{g}}_t^D] \in R^{T \times D}$ 和 $\hat{\mathbf{p}}_t \in R^{T \times 1}$ 为松弛变量; $()^*$ 为复共轭运算。

式(5)可利用交替方向乘法求解,其增广拉格朗日方程为:

$$\begin{aligned} \mathcal{L}(\hat{\mathbf{g}}_t, \mathbf{h}_t, \hat{\mathbf{p}}_t, \hat{\mathbf{v}}_t, \hat{\mathbf{s}}_t) = & \frac{1}{2T} \left\| \sum_{d=1}^D \hat{\mathbf{g}}_t^{d*} \odot \hat{\mathbf{x}}_t^d - \hat{\mathbf{y}}_t \right\|_2^2 + \\ & \frac{1}{2} \lambda_1 \sum_{d=1}^D \|\mathbf{w} \odot \mathbf{h}_t^d\|_2^2 + \frac{1}{2} \gamma_1 \sum_{d=1}^D \|\hat{\mathbf{g}}_t^d - \sqrt{T} \mathbf{F} \mathbf{h}_t^d + \hat{\mathbf{v}}_t^d\|_2^2 + \\ & \frac{1}{2} \lambda_2 \|\hat{\mathbf{p}}_t\|_1 + \frac{1}{2} \gamma_2 \left\| \hat{\mathbf{p}}_t - \sum_{d=1}^D \hat{\mathbf{g}}_t^{d*} \odot \hat{\mathbf{x}}_t^d + \hat{\mathbf{s}}_t \right\|_2^2 \end{aligned} \quad (6)$$

式中: γ_1 和 γ_2 为惩罚系数; $\hat{\mathbf{v}}_t = [\hat{\mathbf{v}}_t^1, \hat{\mathbf{v}}_t^2, \dots, \hat{\mathbf{v}}_t^D] \in R^{T \times D}$ 和 $\hat{\mathbf{s}}_t \in R^{T \times 1}$ 为缩放增广拉格朗日乘子。

给定 $\hat{\mathbf{p}}_t, \mathbf{h}_t, \hat{\mathbf{v}}_t$ 和 $\hat{\mathbf{s}}_t, \hat{\mathbf{g}}_t$ 的优化函数为:

$$\begin{aligned} \hat{\mathbf{g}}_t = \arg \min_{\hat{\mathbf{g}}_t} & \frac{1}{2T} \left\| \sum_{d=1}^D \hat{\mathbf{g}}_t^{d*} \odot \hat{\mathbf{x}}_t^d - \hat{\mathbf{y}}_t \right\|_2^2 + \\ & \frac{1}{2} \gamma_1 \left\| C_j(\hat{\mathbf{g}}_t) - C_j(\sqrt{T} \mathbf{F} \mathbf{h}_t) + C_j(\hat{\mathbf{v}}_t) \right\|_2^2 + \\ & \frac{1}{2} \gamma_2 \left\| \hat{\mathbf{p}}_t - \sum_{d=1}^D \hat{\mathbf{g}}_t^{d*} \odot \hat{\mathbf{x}}_t^d + \hat{\mathbf{s}}_t \right\|_2^2 \end{aligned} \quad (7)$$

$\hat{\mathbf{y}}_t$ 中第 j 元素只与 $\hat{\mathbf{x}}_t$ 和 $\hat{\mathbf{g}}_t$ 所有通道上第 j 元素相关,按照每个元素处理 $\hat{\mathbf{g}}_t$ 所有通道的方式,可将式(7)分解成 T 个子问题:

$$\begin{aligned} C_j(\hat{\mathbf{g}}_t) = \arg \min_{C_j(\hat{\mathbf{g}}_t)} & \frac{1}{2} \left\| C_j(\hat{\mathbf{x}}_t)^H C_j(\hat{\mathbf{g}}_t) - (\hat{\mathbf{y}}_t)_j \right\|_2^2 + \\ & \frac{1}{2} \gamma_2 \left\| C_j(\hat{\mathbf{p}}_t) - C_j(\hat{\mathbf{x}}_t)^H C_j(\hat{\mathbf{g}}_t) + C_j(\hat{\mathbf{s}}_t) \right\|_2^2 + \\ & \frac{1}{2} \gamma_1 \left\| C_j(\hat{\mathbf{g}}_t) - C_j(\sqrt{T} \mathbf{F} \mathbf{h}_t) + C_j(\hat{\mathbf{v}}_t) \right\|_2^2 \end{aligned} \quad (8)$$

式中: $C_j(\hat{\mathbf{g}}_t) \in R^{D \times 1}, j=1, \dots, T$ 为由 $\hat{\mathbf{g}}_t$ 所有通道中第 j 元素所构成的向量, $()^H$ 为复共轭转置运算。

根据谢尔曼-莫里森(Sherman-Morrison)公式,式(8)的解为:

$$\begin{aligned} C_j(\hat{\mathbf{g}}_t) = & \frac{1}{\gamma_1 T} \left(I - \frac{(1 + \gamma_2 T) C_j(\hat{\mathbf{x}}_t) C_j(\hat{\mathbf{x}}_t)^H}{\gamma_1 T + (1 + \gamma_2 T) C_j(\hat{\mathbf{x}}_t)^H C_j(\hat{\mathbf{x}}_t)} \right) \\ & (C_j(\hat{\mathbf{x}}_t) \rho + \gamma_1 T C_j(\sqrt{T} \mathbf{F} \mathbf{h}_t) - \gamma_1 T C_j(\hat{\mathbf{v}}_t)) \end{aligned} \quad (9)$$

式中: $\rho = (\hat{\mathbf{y}}_t)_j + \gamma_2 T C_j(\hat{\mathbf{p}}_t) + \gamma_2 T C_j(\hat{\mathbf{s}}_t)$ 。

给定 $\hat{\mathbf{g}}_t, \mathbf{h}_t, \hat{\mathbf{v}}_t$ 和 $\hat{\mathbf{s}}_t, \hat{\mathbf{p}}_t$ 的优化函数为:

$$\begin{aligned} \hat{\mathbf{p}}_t = \arg \min_{\hat{\mathbf{p}}_t} & \frac{1}{2} \lambda_2 \|\hat{\mathbf{p}}_t\|_1 + \\ & \frac{1}{2} \gamma_2 \left\| \hat{\mathbf{p}}_t - \sum_{d=1}^D \hat{\mathbf{g}}_t^{d*} \odot \hat{\mathbf{x}}_t^d + \hat{\mathbf{s}}_t \right\|_2^2 \end{aligned} \quad (10)$$

根据软阈值方法,式(10)的封闭解为:

$$\hat{\mathbf{p}}_t^d = \text{sgn}\left(\sum_{d=1}^D \hat{\mathbf{g}}_t^{d*} \odot \hat{\mathbf{x}}_t^d - \hat{\mathbf{s}}_t\right) \max\left\{0, \left|\sum_{d=1}^D \hat{\mathbf{g}}_t^{d*} \odot \hat{\mathbf{x}}_t^d - \hat{\mathbf{s}}_t\right| - \frac{\lambda_2}{2\gamma_2}\right\} \quad (11)$$

式中: $\text{sgn}(\cdot)$ 为符号函数。

给定 $\hat{\mathbf{g}}_t, \hat{\mathbf{p}}_t, \hat{\mathbf{v}}_t$ 和 $\hat{\mathbf{s}}_t, \mathbf{h}_t$ 的优化函数为:

$$\mathbf{h}_t = \arg \min_{\mathbf{h}_t} \frac{1}{2} \lambda_1 \sum_{d=1}^D \|\mathbf{w} \odot \mathbf{h}_t^d\|_2^2 + \frac{1}{2} \gamma_1 \sum_{d=1}^D \|\hat{\mathbf{g}}_t^d - \sqrt{T} \mathbf{F} \mathbf{h}_t^d + \hat{\mathbf{v}}_t^d\|_2^2 \quad (12)$$

令 $\mathbf{W} = \text{diag}(\mathbf{w}) \in R^{T \times T}$, 按照通道分解,式(12)可写为:

$$\mathbf{h}_t^d = \arg \min_{\mathbf{h}_t^d} \frac{1}{2} \lambda_1 \|\mathbf{W} \mathbf{h}_t^d\|_2^2 + \frac{1}{2} \gamma_1 \sum_{d=1}^D \|\hat{\mathbf{g}}_t^d - \sqrt{T} \mathbf{F} \mathbf{h}_t^d + \hat{\mathbf{v}}_t^d\|_2^2 \quad (13)$$

求解式(13)可得:

$$\mathbf{h}_t^d = (\lambda_1 \mathbf{W}^T \mathbf{W} + \gamma_1 T)^{-1} \gamma_1 T (\hat{\mathbf{v}}_t^d + \hat{\mathbf{g}}_t^d) = \frac{\gamma_1 T (\hat{\mathbf{v}}_t^d + \hat{\mathbf{g}}_t^d)}{\lambda_1 \mathbf{w} \odot \mathbf{w} + \gamma_1 T} \quad (14)$$

拉格朗日乘子 $\hat{\mathbf{v}}_t$ 和 $\hat{\mathbf{s}}_t$ 更新为:

$$\hat{\mathbf{v}}_t^{i+1} = \hat{\mathbf{v}}_t^i + (\hat{\mathbf{g}}_t^{i+1} - \hat{\mathbf{h}}_t^{i+1}) \quad (15)$$

$$\hat{\mathbf{s}}_t^{i+1} = \hat{\mathbf{s}}_t^i + \hat{\mathbf{p}}_t^{i+1} - \left(\sum_{d=1}^D \hat{\mathbf{g}}_t^{d*} \odot \hat{\mathbf{x}}_t^d\right)^{i+1} \quad (16)$$

式中: i 为迭代次数;迭代过程中惩罚系数设置为 $\gamma_1^{i+1} = \min(r_{\max 1}, \beta_1 \gamma_1^i), \gamma_2^{i+1} = \min(r_{\max 2}, \beta_2 \gamma_2^i)$, 其中 $r_{\max 1}, r_{\max 2}, \beta_1$ 和 β_2 为常值系数。

检测阶段,搜索区域的目标响应图为:

$$f(\mathbf{z}) = \mathcal{F}^{-1}\left(\sum_{d=1}^D \hat{\mathbf{g}}_t^{d*} \odot \hat{\mathbf{z}}^d\right) \quad (17)$$

式中: $\hat{\mathbf{z}} = [\hat{\mathbf{z}}^1, \hat{\mathbf{z}}^2, \dots, \hat{\mathbf{z}}^D] \in R^{T \times D}$ 为搜索区域特征图; \mathcal{F}^{-1} 为离散傅里叶逆变换。目标位置通过目标响应图的最大值定位,目标尺寸参照判别尺度空间跟踪(discriminative scale space tracking, DSST)算法^[12]进行估计。模型更新采用增量更新方式,每3帧更新一次。

$$\hat{\mathbf{g}}_t = \begin{cases} \eta \hat{\mathbf{g}}_t + (1 - \eta) \hat{\mathbf{g}}_{t-1}, & \text{mod}(t, 3) = 0 \\ \hat{\mathbf{g}}_{t-1}, & \text{其他} \end{cases} \quad (18)$$

式中: η 为相关滤波器学习率; $\text{bmod}(\cdot)$ 为求余函数。

ALSCF 算法总体跟踪框架如图2所示,算法采用方向梯度直方图(histogram of oriented gradient, HOG)特征和灰度特征,跟踪目标时先估计目标位置后估计目标尺寸,然后每3帧利用自适应标签策略和稀疏学习策略对位置相关滤波器进行更新。其具体工作流程如算法1所述。

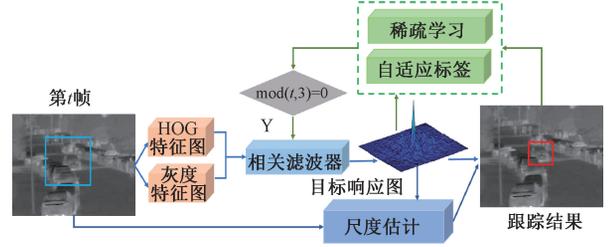


图2 ALSCF 算法总体跟踪框架

Fig. 2 Overall tracking framework of the ALSCF algorithm

算法1: ALSCF 算法

输入: 红外跟踪序列的第 t 帧, 上一帧目标状态 $(\mathbf{p}_{t-1}, \mathbf{s}_{t-1})$ 及相关滤波器 $\hat{\mathbf{g}}_{t-1}$

输出: 第 t 帧的目标跟踪结果 $(\mathbf{p}_t, \mathbf{s}_t)$ 和相关滤波器 $\hat{\mathbf{g}}_t$

Repeat

- 1) 根据 $(\mathbf{p}_{t-1}, \mathbf{s}_{t-1})$ 截取第 t 帧的目标搜索区域;
- 2) 利用式(17)计算目标响应图, 确定目标在第 t 帧的位置 \mathbf{p}_t ;
- 3) 参照 DSST 算法估计目标尺寸 \mathbf{s}_t 及更新尺度相关滤波器;

4) If $\text{bmod}(t, 3) = 0$

利用式(2)计算标签函数 \mathbf{y}_t ;

for $i = 1$; 迭代次数

利用式(9)、(11)和(14)分别计算 $\hat{\mathbf{g}}_t^i, \hat{\mathbf{p}}_t^i$ 和 $\hat{\mathbf{h}}_t^i$;

利用式(15)和(16)分别更新 $\hat{\mathbf{v}}_t^i$ 和 $\hat{\mathbf{s}}_t^i$;

End

End if

5) 根据式(18)更新相关滤波器 $\hat{\mathbf{g}}_t$;

Until 视频序列最后一帧

2 实验结果与分析

2.1 实验环境设置

本文首先在配置为 Intel(R) Core(TM) i5-8300 CPU @ 2.30 H 的计算机上进行消融实验和对比实验, 红外测试序列来源于公开数据集 GTOT^[13]、RGBT234^[14] 和 VOT-TIR2016^[15]。其中, 数据集 GTOT 和 RGBT234 均由配准的可见光序列和红外序列组成, 本文实验只使用红外序列, 分别包含 50 和 234 个红外序列。数据集 VOT-TIR2016 由 VOT-TIR2016 挑战赛提供, 其包含 25 个红外序列。其次, 基于 NVIDIA 公司的 Jetson Xavier NX 开发者套件, 利用六旋翼无人机实拍红外序列进一步验证本文 ALSCF 算法的实时性。

在数据集 GTOT 和 RGBT234 上测试时,遵循数据集 RGBT234 的测试基准,采用精度 (precision) 和曲线下面积 (area under curve, AUC) 作为评估指标^[14]。在数据集 VOT-TIR2016 测试时,遵循 VOT 挑战赛的测试基准,采用期望平均重叠 (expected average overlap, EAO)、准确度 (accuracy) 和鲁棒性 (robustness) 作为评估指标^[15]。跟踪算法运行速度利用每秒处理帧数 (frames/second, fps) 作为衡量。

如图 3 所示, $P_0(m_0, n_0)$ 为目标标注框 B_0 的中心点, $P_1(m_1, n_1)$ 为目标跟踪框 B_1 的中心点, 目标跟踪框的中心定位误差定义为:

$$e = \sqrt{(m_0 - m_1)^2 + (n_0 - n_1)^2} \quad (19)$$

精度为测试序列中目标跟踪框的中心定位误差小于设定阈值的帧数占比。其中,数据集 GTOT 中阈值设定为 5 pixel,数据集 RGBT234 中阈值设定为 20 pixel。

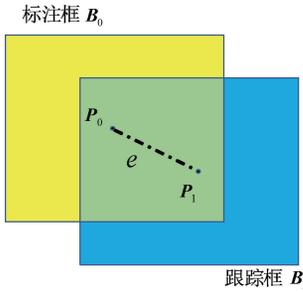


图 3 中心定位误差和重叠率示意图

Fig. 3 Schematic diagram of the center location error and overlap

目标跟踪框和目标标注框的重叠率定义为:

$$O = \frac{|B_0 \cap B_1|}{|B_0 \cup B_1|} \quad (20)$$

式中: $| \cdot |$ 为区域像素个数。跟踪算法的成功率定义为测试序列中目标跟踪框与目标标注框重叠率大于给定阈值的帧数占比。成功率随阈值变化的曲线称为成功率曲线, AUC 为该曲线下面积。

VOT 测试基准中将目标跟踪框与目标标注框重叠率为 0 视为跟踪失败。其中,准确度 (accuracy) 为跟踪算法成功跟踪期间目标跟踪框和目标标注框之间的平均重叠率。EAO 用于估计跟踪算法在大量具有相同视觉属性的短时跟踪序列集合上期望获得的平均重叠率。鲁棒性 (robustness, R) 度量跟踪算法在跟踪过程中跟踪失败的次数,其归一化计算公式为:

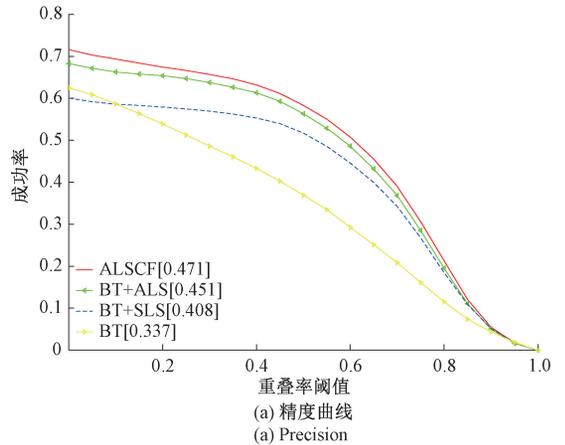
$$R = e^{-\left(\frac{S}{N_a}\right)} \quad (21)$$

式中: S 为归一化参数,通常设置为 100; Q 为跟踪算法失败总次数; N_a 为测试序列帧数。

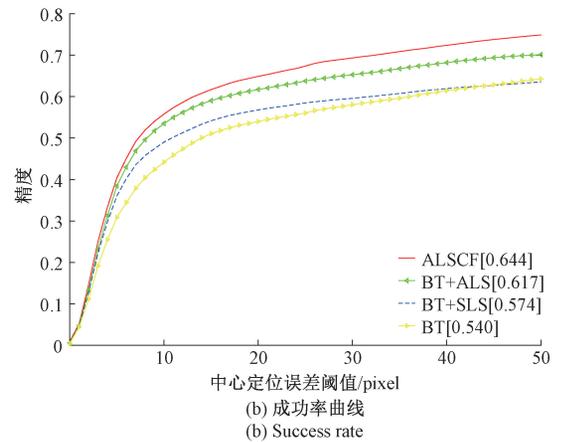
ALSCF 算法参数设置如下:干扰区域个数 $K = 5$;空间正则化中权值矩阵设置参照文献[16],正则化系数 $\lambda_1 = 0.45, \lambda_2 = 0.01$;拉格朗日乘子常值系数 $r_{\max 1} = 1\ 000, r_{\max 2} = 1\ 000, \beta_1 = 10, \beta_2 = 1.2$;迭代次数 $i = 6$;相关滤波器学习率 $\eta = 0.03$;尺度估计参数设置参照 DSST 算法。

2.2 消融实验

ALSCF 算法主要创新在于自适应标签策略和稀疏学习策略。本文通过数据集 RGBT234 上的消融实验,评估各创新点对算法跟踪性能的贡献。消融实验中,将 DSST 算法作为基线跟踪器 (baseline tracker, BT),然后在 BT 基础上分别添加自适应标签策略 (adaptive label strategy, ALS) 和稀疏学习策略 (sparse learning strategy, SLS)。实验结果如图 4 所示,图注分别为各对比算法的精度和 AUC 值。



(a) 精度曲线
(a) Precision



(b) 成功率曲线
(b) Success rate

图 4 数据集 RGBT234 上的消融实验结果

Fig. 4 Ablation experiment results on the RGBT234 dataset

由图 4 可知,自适应标签策略能够显著提高算法的跟踪性能,基线算法加入该策略后精度为 0.617、AUC 为 0.451,分别提高了 14.3% 和 33.8%。该策略的有效

性在于,采用自适应标签函数训练相关滤波器时,可在无需额外提取干扰区域图像作为负样本的情况下,实现困难负样本的隐性挖掘,通过改善训练样本质量来提高相关滤波器的分类能力;同时,加入空间正则化抑制了边界效应。基线算法加入稀疏学习策略后,其精度和 AUC 分别提高了 6.3% 和 21.1%。这得益于加入目标响应 L1 范数后,缓解了复杂跟踪场景下目标响应多峰分布情况,使得目标响应的能量主要集中于目标区域,同时增强了相关滤波器的稀疏性、提高了泛化能力。在基线算法基础上,融合两策略构成 ALSCF 算法,其精度和 AUC 与基线算法相比,分别提高了 19.3% 和 39.8%。ALSCF 算法跟踪性能的显著提升源于自身跟踪模型的稳健性,自适应标签策略隐性挖掘困难负样本,提升了相关滤波器抗干扰能力,稀疏学习策略进一步抑制了目标响应多峰异常干扰,缓解了复杂跟踪场景下模型退化问题。上述消融实验充分验证了自适应标签策略和稀疏学习策略的有效性,两者均能显著改善算法的跟踪性能。

2.3 定量实验

为定量评估 ALSCF 算法的有效性,在数据集 GTOT 和 RGBT234 红外序列上对其进行测试,并与近年来具有代表性的 7 种相关滤波目标跟踪算法进行对比。它们分别为 DR2Track 算法^[8]、STRCF 算法^[16]、ECO 算法^[17]、Staple-ca 算法^[7]、SRDCF 算法^[18]、DSST 算法^[12] 和 KCF 算法^[6]。

图 5 所示为上述 8 种算法在数据集 GTOT 上的整体性能,表 1 所示为各算法的精度、AUC 和运行速度。从图 5 可以看出,ALSCF 算法的整体性能优于其他对比算法。ALSCF 算法精度为 0.727、AUC 为 0.611,与排名第二的 STRCF 算法相比,其精度和 AUC 分别提高了 3.4% 和 5.2%。在数据集 GTOT 上 ALSCF 算法的运行速度为 49.525 fps,可满足实时目标跟踪需求。

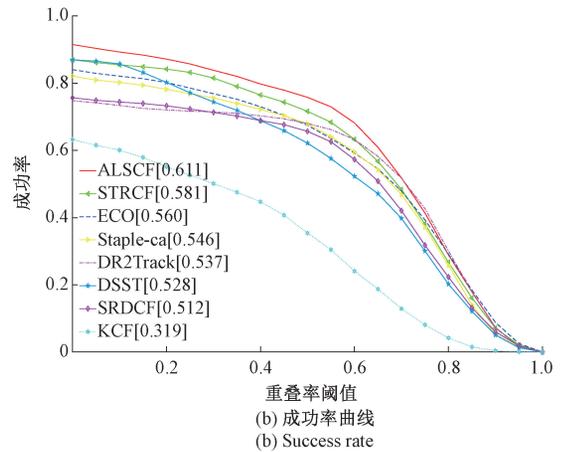
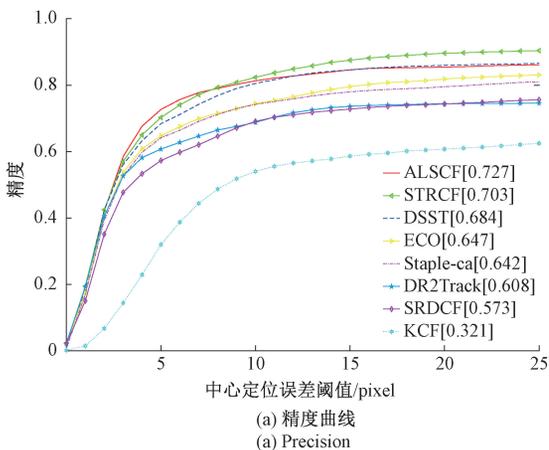


图 5 数据集 GTOT 上的整体性能

Fig. 5 Overall performance on the GTOT dataset

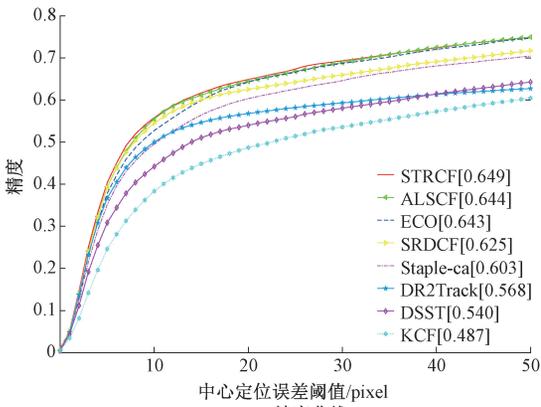
表 1 数据集 GTOT 上的性能对比

Table 1 Performance comparison on the GTOT dataset

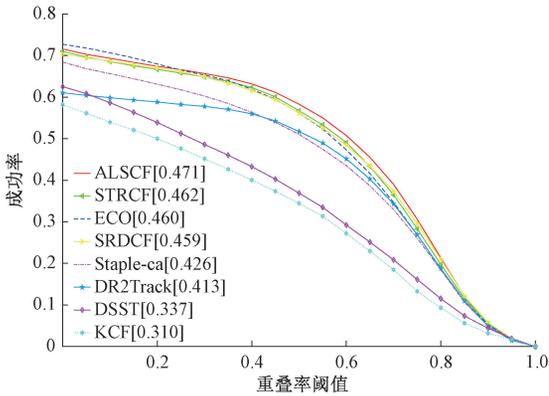
算法	精度	AUC	速度/fps
ALSCF	0.727	0.611	49.525
DR2Track	0.608	0.611	36.868
STRCF	0.703	0.581	31.205
ECO	0.647	0.560	5.847
Staple-ca	0.642	0.546	61.410
SRDCF	0.573	0.512	9.859
DSST	0.684	0.528	81.210
KCF	0.321	0.319	381.346

图 6 所示为上述 8 种算法在数据集 RGBT234 上的整体性能,表 2 所示为各算法的性能指标。由图 6 可知,在精度图中 STRCF 算法、ALSCF 算法和 ECO 算法优于其他对比算法,在成功图中 ALSCF 算法优于其他对比算法。在精度方面,ALSCF 算法为 0.644,排名第二;在 AUC 方面,ALSCF 算法为 0.471,排名第一。虽然 ALSCF 算法精度比 STRCF 算法低 0.005,但其运行速度提升了 67.2%,更符合实时性需求,由此可知 ALSCF 算法综合性能更优。

为验证 ALSCF 算法应对各类跟踪挑战的能力,表 3 所示为上述 8 种算法在数据集 RGBT234 上 11 类红外目标跟踪挑战下的 AUC。该 11 类跟踪挑战分别为背景杂乱 (background clutter, BC)、相机运动 (camera moving, CM)、形变 (deformation, DEF)、快速运动 (fast motion, FM)、严重遮挡 (heavy occlusion, HO)、低分辨率 (low resolution, LR)、运动模糊 (motion blur, MB)、无遮挡 (no occlusion, No)、部分遮挡 (partial occlusion, PO)、尺寸变化 (scale variation, SV) 以及热交叉 (thermal crossover, TC)。由



(a) 精度曲线
(a) Precision



(b) 成功率曲线
(b) Success rate

图 6 数据集 RGBT234 上的整体性能

Fig. 6 Overall performance on the RGBT234 dataset

表 3 数据集 RGBT234 分类挑战下的 AUC 对比

Table 3 AUC comparison in different challenges on the RGBT234 dataset

算法	BC	CM	DEF	FM	HO	LR	MB	NO	PO	SV	TC
ALSCF	0.373	0.454	0.433	0.337	0.363	0.441	0.405	0.586	0.526	0.485	0.389
DR2Track	0.339	0.396	0.325	0.293	0.291	0.405	0.354	0.539	0.477	0.435	0.290
STRCF	0.364	0.435	0.406	0.336	0.365	0.451	0.401	0.580	0.501	0.473	0.361
ECO	0.347	0.428	0.404	0.285	0.357	0.421	0.400	0.560	0.518	0.474	0.324
Staple-ca	0.366	0.382	0.385	0.302	0.329	0.403	0.346	0.522	0.482	0.439	0.332
SRDCF	0.370	0.434	0.411	0.310	0.344	0.447	0.405	0.598	0.515	0.470	0.386
DSST	0.288	0.296	0.328	0.205	0.273	0.346	0.227	0.412	0.371	0.323	0.245
KCF	0.261	0.269	0.291	0.206	0.244	0.305	0.224	0.361	0.355	0.282	0.205

第一,比排名第二的 Staple_TIR 算法提高了 5.5%;与挑战赛排名前 2 的 EBT 算法和 SRDCFir 算法相比,ALSCF 算法与两者之间的 EAO 仅相差 0.01 和 0.008,但 ALSCF 算法运行速度超过 35 fps,是 EBT 算法和 SRDCFir 算法运行速度的 10 倍以上,可满足实时性需求。综上可知,在数据集 VOT-TIR2016 上 ALSCF 算法的综合跟踪性能优于挑战赛前 7 名红外目标跟踪算法。

表 2 数据集 RGBT234 上的性能对比

Table 2 Performance comparison on the RGBT234 dataset

算法	精度	AUC	速度/fps
ALSCF	0.644	0.471	38.928
DR2Track	0.568	0.413	27.849
STRCF	0.649	0.462	23.284
ECO	0.643	0.460	4.582
Staple-ca	0.603	0.426	47.281
SRDCF	0.625	0.459	5.379
DSST	0.540	0.337	35.638
KCF	0.487	0.310	271.043

于自适应标签策略提高了相关滤波器对目标和背景的区分能力,目标响应稀疏性缓解了目标响应多峰干扰,ALSCF 算法在背景杂乱、相机运动、形变、快速运动、运动模糊、部分遮挡、尺寸变化和热交叉 7 种挑战中 AUC 排名第一。在严重遮挡和低分辨率挑战下,由于 ALSCF 算法采用固定频率模型更新方式,其 AUC 略低于采用时间正则化的 STRCF 算法,排名第二。

为进一步验证 ALSCF 算法的跟踪性能,表 4 给出了 ALSCF 算法与 VOT-TIR2016 挑战赛排名前 7 的红外目标跟踪算法(即:EBT 算法^[19],SRDCFir 算法^[19],TCNN 算法^[15],Staple_TIR 算法^[15],SHCT 算法^[15],MDNet_N 算法^[15]以及 Staple_plus 算法^[15])的性能对比。从表 4 可知,在准确度方面,ALSCF 算法准确度为 0.672、排名

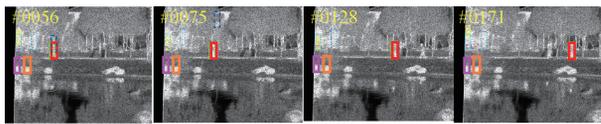
2.4 定性实验

为了更加直观地验证 ALSCF 算法的有效性,利用数据集 GTOT 和 RGBT234 中具有典型代表性的红外序列,对本文 ALSCF 算法、DR2Track 算法^[8]、STRCF 算法^[16]、ECO 算法^[17]、Staple-ca 算法^[7]、SRDCF 算法^[18]、DSST 算法^[12]和 KCF 算法^[6]进行定性对比分析,部分跟踪结果如图 7 所示,图中 GT 代表目标标注框。

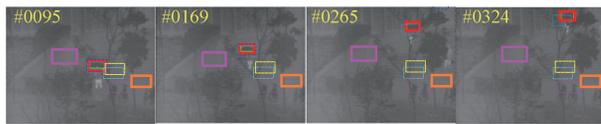
表4 数据集 VOT-TIR2016 上的性能对比

Table 4 Performance comparison on the VOT-TIR2016 dataset

算法	EAO	准确度	鲁棒性	速度/fps
ALSCF	0.351	0.672	0.747	35.864
EBT	0.361	0.438	0.823	3.403
SRDCFir	0.359	0.62	0.812	3.183
TCNN	0.283	0.614	0.694	1.307
Staple_TIR	0.264	0.637	0.603	20.526
SHCT	0.263	0.588	0.612	1.234
MDNet_N	0.24	0.642	0.639	0.784
Staple_plus	0.241	0.588	0.591	18.680



(a) Pool



(b) Mancrossandup



(c) Elecbike



(d) Biketwo



图7 8种跟踪算法部分跟踪结果

Fig. 7 Partial tracking results of eight tracking algorithms

图7(a)为上述8种算法在Pool序列上的部分跟踪结果。Pool序列主要存在的跟踪挑战为背景杂乱和热交叉。从第56~75帧可以看出,当目标经过背景杂乱区域后,仅有ALSCF算法能可靠地跟踪目标;在第128~171帧之间,目标因迎面而来的行人遭遇热交叉,ALSCF算法仍然能够正确跟踪目标。ALSCF算法取得成功的原因在于,其稀疏学习策略能有效抑制背景杂乱区域目标响应图的多峰分布。在第128~171帧之间目标遭遇行人热交叉干扰时,ALSCF算法能够通过自适应标签策略及时感知该干扰情况,提高了相关滤波器对该行人热交叉干扰的识别。

图7(b)所示为mancrossandup序列上的部分跟踪结果,该目标主要面临形变和部分遮挡挑战。当目标面临形变后,在第169帧中除ALSCF算法、Staple-ca算法 and DR2Track算法外,其余算法均已跟丢目标。随着目标遭遇部分遮挡,在第324帧中Staple-ca算法和DR2Track算法已经丢失目标;ALSCF算法采用自适应标签和稀疏学习策略,对干扰区域的目标响应值进行抑制,使目标响应的能量主要集中于目标区域,从而能够稳定地跟踪目标。

在图7(c)中elecbike序列的第40~43帧之间,目标因相机运动遭遇显著位置改变,除ALSCF算法外,其余对比算法均遭遇跟踪失败;在43~94帧之间,目标遭遇树木部分遮挡,此时ALSCF算法仍能对其稳定跟踪。ALSCF算法在该序列的良好表现主要得益于自适应标签策略,该策略不仅扩大了目标搜索范围,还强化了相关滤波器对目标和背景的分类能力。

图7(d)所示序列为biketwo,其目标面临尺寸变化、以及运动模糊等多种挑战。在第34帧目标遭遇运动模糊时,DSST算法和KCF算法丢失目标,在第177帧目标再次遭遇运动模糊挑战时,仅剩凭借自适应标签和稀疏学习策略建立稳健跟踪模型的ALSCF算法能够有效应对该挑战,准确跟踪目标。

通过上述对比结果可知,ALSCF算法采用自适应标签和稀疏学习策略能够有效应对背景杂乱、热交叉、部分遮挡、目标形变以及运动模糊等多种挑战。

2.5 实际场景实验

为进一步验证本文ALSCF算法的实时性,基于六旋翼无人机搭载NVIDIA公司的Jetson Xavier NX开发者套件和SIP10S32双光吊舱进行了实际场景实验,如图8所示。实验拍摄场景为校园主干道,跟踪目标为行进中的行人和车辆,红外图像分辨率为480×640。



图8 实验设备

Fig. 8 Experimental equipment

图9给出了ALSCF算法在实拍序列1和序列2的部分跟踪结果,表5给出了ALSCF算法在上述序列的实时性能评估结果。结合图9和表5可知,ALSCF算法能够稳定地跟踪目标,对序列1和序列2的跟踪速度分别为32.601 fps和31.229 fps。实验结果表明,在嵌入式系统中ALSCF算法能够满足实时性需求。

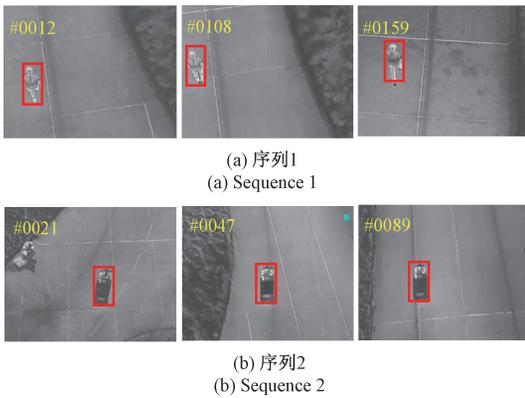


图9 ALSCF算法在实拍序列上的部分跟踪结果
Fig.9 Partial tracking results of the ALSCF algorithm on real sequences

表5 ALSCF算法实时性能评估结果

Table 5 Real-time performance evaluation results of the ALSCF algorithm

算法	序列名称	图像分辨率	目标类型	速度/fps
ALSCF	序列1	480×640	行人	32.601
	序列2	480×640	车辆	31.229

3 结 论

本文对目标跟踪算法在复杂跟踪场景下的性能退化问题进行研究,提出了一种基于自适应标签和稀疏学习相关滤波的红外目标跟踪 ALSCF 算法。ALSCF 算法通过自适应标签策略隐性挖掘困难负样本、抑制边界效应,缓解了复杂跟踪场景下相关滤波器分类能力的退化,并利用稀疏学习策略抑制复杂跟踪场景中目标响应多峰分布,增强了跟踪模型的稳健性,从而使算法跟踪性能得到显著提高。在数据集 GTOT、RGBT234 和 VOT-2016TIR 上的评测结果,充分验证了 ALSCF 算法的有效性,其能够在背景杂乱、热交叉、部分遮挡以及目标形变等复杂场景下实时可靠地跟踪目标;实际场景下实验结果进一步验证了 ALSCF 算法的实时性。本文算法属于短时目标跟踪算法,无法有效应对遭遇长时严重遮挡或者短暂出视野的目标,后续研究中拟加入重检测模块解决该问题。

参考文献

[1] HU Y G, XIAO M Q, LI S Y, et al. Aerial infrared target tracking based on a Siamese network and traditional features [J]. Infrared Physics & Technology, 2020, 111: 103505.

[2] 韩晓微, 王雨薇, 谢英红, 等. 基于双相关滤波器的多通道尺度自适应目标跟踪[J]. 仪器仪表学报, 2019,

40(11):73-81.

HAN X W, WANG Y W, XIE Y H, et al. Multi-channel scale adaptive target tracking based on double correlation filter [J]. Chinese Journal of Scientific Instrument, 2019, 40(11):73-81.

[3] 高赞, 徐子钦, 王涛, 等. 采用多边形质心的相关滤波跟踪位置校正方法[J]. 仪器仪表学报, 2021, 42(5): 159-172.

GAO Y, XU Z Q, WANG T, et al. Polygon centroid based position correction method for correlation filter tracking [J]. Chinese Journal of Scientific Instrument, 2021, 42(5): 159-172.

[4] 刘秀平, 袁皓, 李梦璐, 等. ECO 多特征融合目标工件跟踪方法研究[J]. 电子测量与仪器学报, 2021, 35(10): 161-167.

LIU X P, YUAN H, LI M L, et al. Research on target work-piece tracking method based on ECO multi-feature fusion [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10): 161-167.

[5] BOLME D S, BEVERIDGE J R, DRAPER B A, et al. Visual object tracking using adaptive correlation filters [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2010: 2544-2550.

[6] HENRIQUES J F, CASEIRO R, MARTINS P, et al. High-speed tracking with kernelized correlation filters[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(3): 583-596.

[7] MUELLER M, SMITH N, GHANEM B. Context-aware correlation filter tracking [C]. 30th IEEE/CVF Conference on Computer Vision and Pattern Recognition, Honolulu, HI: IEEE, 2017: 1396-1404.

[8] FU C, DING F, LIY, et al. DR2Track: Towards real-time visual tracking for UAV via distractor repressed dynamic regression [C]. IEEE International Conference on Intelligent Robots and Systems, 2020: 1597-1604.

[9] 黄月平, 李小锋, 齐乃新, 等. 基于干扰抑制和稀疏学习相关滤波的红外目标跟踪[J]. 机器人, 2021, 43(3): 350-363.

HUANG Y P, LI X F, QI N X, et al. Visual object tracking algorithm based on hard negative mining and adaptive temporal regularization [J]. Robot, 2021, 43(3): 350-363.

[10] ZHANG W, JIAO L, LI Y, et al. Sparse learning-based correlation filter for robust tracking [J]. IEEE Transactions on Image Processing, 2021, 30: 878-891.

- [11] XU T, FENG Z H, WU X J, et al. Learning adaptive discriminative correlation filters via temporal consistency preserving spatial feature selection for robust visual object tracking [J]. IEEE Transactions on Image Processing, 2019, 28(11): 5596-5609.
- [12] DANELLJAN M, HAGER G, KHAN F S, et al. Discriminative scale space tracking [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(8): 1561-1575.
- [13] LI C L, CHENG H, HU S Y, et al. Learning collaborative sparse representation for grayscale-thermal tracking [J]. IEEE Transactions on Image Processing, 2015, 25(12): 5743-5756.
- [14] LI C L, LIANG X Y, LU Y J, et al. RGB-T object tracking: Benchmark and baseline [J]. Pattern Recognition, 2019: 106977.
- [15] FELSBERG M, KRISTAN M, MATAS J, et al. The thermal infrared visual object tracking VOT-TIR2016 challenge results [C]. European Conference on Computer Vision, 2016: 824-849.
- [16] LI F, TIAN C, ZOU W, et al. Learning spatial-temporal regularized correlation filters for visual tracking [C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, IEEE, 2018: 4904-1913.
- [17] DANELLJAN M, GOUTAM B, FAHAD S K, et al. ECO: Efficient convolution operators for tracking [C]. 30th IEEE/CVF Conference on Computer Vision and Pattern Recognition, IEEE, 2017: 6931-6939.
- [18] DANELLJAN M, HAGER G, KHAN F S, et al. Learning spatially regularized correlation filters for visual tracking [C]. IEEE International Conference on Computer Vision, IEEE, 2015: 4310-4318.

- [19] FELSBERG M, BERG A, HAGR G, et al. The thermal infrared visual object tracking VOT-TIR2015 challenge results [C]. IEEE International Conference on Computer Vision, CHILE: IEEE, 2015: 639-651.

作者简介



黄月平, 2012年于西北工业大学获得学士学位, 2017年于西北工业大学获得硕士学位, 现为火箭军工程大学博士研究生, 主要研究方向为视觉目标跟踪和检测。

E-mail: hypsc1990@163.com

Huang Yueping received her B. Sc. degree from Northwestern Polytechnical University in 2012, and received her M. Sc. degree from Northwestern Polytechnical University in 2017. She is currently a Ph. D. candidate at Rocket Force University of Engineering. Her main research interests include visual object detection and tracking.



李小锋(通信作者), 2005年于火箭军工程大学获得学士学位, 2008年于火箭军工程大学获得硕士学位, 2012年于火箭军工程大学获得博士学位, 现为火箭军工程大学讲师, 主要研究方向为图像处理和飞行器导航

与控制。

E-mail: xiaofeng_li2006@126.com

Li Xiaofeng (Corresponding author) received his B. Sc. degree from Rocket Force University of Engineering in 2005, received his M. Sc. degree from Rocket Force University of Engineering in 2008, and received his Ph. D. degree from Rocket Force University of Engineering in 2012. He is currently a lecturer at Rocket Force University of Engineering. His main research interests include image processing, guidance and control of aircrafts.