

DOI: 10.12382/bgxb.



基于多特征融合与记忆重检测的无人机目标跟踪

朱凯峰^{1,2}, 武丹凤^{1,2*}, 朱纪洪³, 周芬芬^{1,2}, 靳爽², 匡敏驰³

(1. 北京联合大学北京市信息服务工程重点实验室, 北京 100101; 2. 北京联合大学 机器人学院, 北京 100101; 3. 清华大学 精密仪器系, 北京 100084)

摘要: 针对无人机目标跟踪中目标尺度与视角变化、遮挡以及目标丢失后再出现等复杂情形, 提出一种增强型核相关滤波跟踪框架。通过构建尺度金字塔并引入旋转不变描述子, 实现对目标尺度与视角变化的协同感知; 结合基于空间正则化的抗遮挡模块, 提高遮挡条件下的跟踪鲁棒性; 融合基于卡尔曼滤波的记忆引导重检测与局部搜索策略, 增强目标丢失后的恢复能力。在 UAV123 与 OTB100 数据集上的实验结果表明: 所提方法在资源受限平台上分别可实现 33.21 帧/s、35.39 帧/s 的实时处理性能, 并分别获得 54.6%/66.0% 的定位精度和 37.6%/55.8% 的成功率; 该方法在目标外观变化与短时遮挡场景下具有良好的稳定性, 并能够在目标丢失后实现快速恢复, 具备工程应用价值。

关键词: 目标跟踪; 卡尔曼滤波; 无人机; 尺度适应; 抗遮挡

中图分类号: TJ301 **文献标志码:** A **文章编号:** 1000-1093(XXXX)XX--12

UAV Target Tracking Based on Multi-Feature Fusion and Memory Re-Detection

ZHU Kaifeng^{1,2}, WU Danfeng^{1,2*}, ZHU Jihong³, ZHOU Fenfen^{1,2}, JIN Shuang², KUANG Minchi³

(1. Beijing Key Laboratory of Information Service Engineering, Beijing Union University, Beijing 100101, China; 2. College of Robotics, Beijing Union University, Beijing 100101, China. ; 3. Department of Precision Instruments, Tsinghua University, Beijing 100084, China)

Abstract: To address the challenges of target scale and viewpoint variations, occlusion, and target reappearance after loss in unmanned aerial vehicle target tracking, an enhanced kernelized correlation filter tracking framework is proposed. The framework constructs a scale pyramid and incorporates rotation-invariant descriptors to achieve collaborative perception of target scale and viewpoint variations; a spatial regularization-based anti-occlusion module is integrated to improve tracking robustness under occlusion; and a memory-guided re-detection strategy combined with Kalman filtering and local search is employed to enhance recovery capability after target loss. Experimental results on the UAV123 and OTB100 datasets demonstrate that the proposed method achieves real-time performance of 33.21/35.39 FPS on resource-constrained platforms, with localization accuracies of 54.6%/66.0% and success rates of 37.6%/55.8%, respectively. The results indicate that the proposed approach maintains stable tracking performance under target appearance variations and short-term occlusion, and is capable of rapid recovery after target loss, showing strong potential for practical engineering applications.

收稿日期: 2026-01-11

基金项目: 时空信息精密感知技术全国重点实验室开放基金项目 (STL2023-B-06-01 (K)); 北京联合大学科研资助项目 (ZK20202201)

* 通信作者邮箱: 邮箱: jqrdanfeng@buu.edu.cn

Keywords: target tracking; Kalman filtering; unmanned aerial vehicle; scale adaption; anti occlusion

DOI:10.12382/bgxb.2026.0036

0 引言

随着信息化作战形态的演进,空基无人系统在边境巡逻^[1]与战场态势感知^[2]等任务中的作用日益凸显。对战术级无人平台而言,视觉目标跟踪不仅承担持续观测与目标维护的功能,还直接影响后续目标识别、火力指示与动态决策流程。在实际军事部署中,空基平台常受载荷、功耗与算力等约束,同时需满足强实时性与高可靠性。因此,面向战术级无人系统的跟踪算法必须在有限计算资源下兼顾精度、鲁棒性与工程可部署性。

近年来,目标跟踪技术^[3-5]取得了显著进展,涌现了大量算法。总体而言,根据模型构建与学习方式的不同,可将其划分成两类,分别为基于深度学习的方法和基于传统相关滤波的方法。其中,基于深度学习的方法核心思想是利用深度神经网络进行端到端特征学习与目标建模。近年来,随着注意力机制与 Transformer 结构的引入,深度跟踪方法在复杂场景下的建模能力得到显著提升。如 Cao 等^[6]提出了一种基于 Transformer 的目标跟踪方法,通过跨注意力机制对模板特征与搜索区域特征进行全局建模,从而增强了目标与背景之间的判别能力。Zhu 等^[7]进一步将目标跟踪建模为时序预测问题,利用时空 Transformer 对目标状态变化进行联合建模,在长时跟踪与遮挡场景下取得了较好的稳定性。随后, Fan 等^[8]提出统一的单流 Transformer 跟踪框架,将目标定位与特征建模整合到同一网络结构中,在保证精度的同时简化了模型设计。针对深度模型计算复杂度较高的问题, Cai 等^[9]通过神经架构搜索方法设计轻量化跟踪网络,在一定程度上降低了参数规模与计算量。此外, Sun 等^[10]通过引入多级注意力机制进一步增强了深度跟踪器在复杂背景与遮挡条件下的鲁棒性。Lu 等^[11]的可逆提示学习通过双向编解码器在模态缺失时生成虚拟特征表示,实现跨模态映射不变性,但依赖历史帧记忆导致目标长期消失后重建质量下降。Li 等^[12]将模板作为跨模态桥接单元并引入目标保持更新策略,但对初始帧质量敏感且未充分利用多历史帧上下

文。Lai 等^[13]首次将 Mamba 状态空间模型引入多模态跟踪,通过双向状态空间实现线性复杂度的全局建模,但因因果结构限制了对未来帧的利用,在快速相机运动下存在预测滞后,并且对高频纹理细节的建模能力较弱。尽管上述方法在精度与表达能力方面取得了显著进展,其网络结构普遍较为复杂,对计算资源和运行环境依赖较强,推理延迟和功耗开销较大,仍难以满足无人机视角下对低算力、强实时性和高可靠性的工程应用需求。

不同于深度学习方法,基于传统相关滤波的目标跟踪算法首先通过初始帧训练获得滤波器,对目标外观进行建模,然后利用傅里叶变换在频域内寻找相邻帧中与目标样本相关性最大的图像块,从而实现实时跟踪。这些特点使得此类算法在无人机目标跟踪领域具有广泛的应用前景。Henriques 等^[14]引入带内核的循环检测方法,通过循环矩阵理论获得密集近似采样,解决了稀疏采样带来的冗余问题。而在此基础上, Henriques 等^[15]提出的核相关滤波算法实现了多通道特征的有效融合。为适应目标尺度变化, Danelljan 等^[16]提出判别尺度空间跟踪器(Discriminative Scale Space Tracking, DSST),利用 33 个尺度下的位置信息确定目标大小。Kiani Galoogahi 等^[17]则针对滤波器边界效应问题,提出背景感知相关滤波器并采用交替方向乘子法对滤波器进行优化求解。Pi 等^[18]提出的时空正则化相关滤波器缓解了滤波器退化问题。近年来,长期跟踪作为研究热点,其任务要求对大量连续帧进行稳定跟踪,期间可能因部分或完全遮挡引起目标丢失。为此,针对目标遮挡、运动模糊等场景下目标跟踪整体性能难以平衡的问题, Cai 等^[19]提出一种融合颜色与梯度直方图特征、引入尺度滤波器的改进核相关滤波跟踪算法,通过四评价指标加权融合与双阈值机制判断遮挡状态,并基于此自适应调整模型更新策略。此外, Ma 等^[20]提出了长期相关性跟踪(Long-term Correlation Tracking, LCT)算法,在相关滤波器基础上融入重新检测机制,利用在线随机森林对遮挡或快速运动后的目标进行重检测,但由于检测模块相对单一,整体鲁棒性仍有待提高。Yan 等^[21]则开发了细化模块 Alpha-Refine,在低延迟条件下显著提升了基础跟踪器边界框估计精度。

在军事无人机及战术平台中, Zynq-7000 等异

构嵌入式处理器应用广泛,其低功耗特性适合资源受限环境。鉴于该类平台对算法轻量化的严苛要求,本文针对相关滤波算法在复杂场景下的鲁棒性瓶颈,提出一种判别—感知—恢复统一跟踪框架。该框架将跟踪流程建模为闭环系统:首先,利用响应矩阵特征判别目标状态(正常、遮挡或丢失);其次,通过尺度金字塔与旋转不变描述子增强观测方程,实现对几何形变的自适应感知;最后,针对目标丢失,借助卡尔曼滤波预测与局部搜索机制完成状态恢复。本文主要贡献如下:

1)针对核相关滤波在处理目标尺度和视角变化时的不足,本文构建尺度金字塔并引入旋转不变描述子,实现了相关滤波框架下的准确估计。

2)针对遮挡判断和跟踪难的问题,通过目标响应矩阵判别遮挡状态并通过基于空间正则化的抗遮挡跟踪匹配模块实现鲁棒的目标跟踪。

3)针对目标丢失后难以重新跟踪的问题,引入基于卡尔曼滤波器的记忆引导重检测模块,借助历史轨迹预测和局部搜索策略,提高目标丢失后的恢复能力。

1 基础跟踪器设计

针对资源受限无人机平台,现有相关滤波改进方案在应对“尺度-旋转耦合、模型退化、丢失恢复”三大挑战并存的复杂场景时存在明显的局限性:以DSST为代表的尺度类算法维度单一,在面对无人机电视角频繁发生的旋转形变时表现欠缺,且由于缺乏有效的遮挡判别,在干扰下仍盲目更新模型导致漂移;SRDCF(Spatially Regularized Correlation Filters)等空间正则化算法虽抑制了边界效应,但计算开销巨大且不具备丢失自愈能力;而以LCT为代表的长时跟踪框架,其跟踪与重检测模块通常孤立运行,由于缺乏精准的状态切换逻辑,导致在高功耗的全局重检测与高频更新难以平衡,冗余计算严重,无法适配Zynq-7000等嵌入式平台的实时性要求。

本文提出的“判别—感知—恢复”一体化框架与上述方案的本质差异在于:构建了以“状态判别”为逻辑核心的闭环触发机制,实现了从“无差别全量计算”向“按需精准分配算力”的范式转变。该框架并非模块的机械叠加,而是通过响应矩阵多特征融合构建了“正常—遮挡—丢失”三状态分级判别模型,作为整个系统的“神经中枢”:在正常或遮挡状态下,通过轻量化尺度金字塔与旋转不变描述子的解耦协同,解决了DSST系算法几何感知维度不

足的痛点;在丢失状态下,利用判别信号精准启动由卡尔曼滤波引导的局部区域搜索,以低开销的运动先验替代LCT式的全局盲扫。这种“状态驱动—模块互补”的设计逻辑,确保了各算法组件在资源受限平台上能够按需、协同运行,从而在保障跟踪鲁棒性的同时,实现了计算效率的本质提升。算法流程图如图1所示。




图1 算法流程

Fig. 1 Algorithm flowchart

具体而言,算法以初始帧图像中的目标区域框为起点,执行跟踪器的初始化操作。随后进入循环处理阶段,依次读取后续帧图像。在每帧图像中,首先判断目标是否出现遮挡或丢失情况。若未发生遮挡或丢失,则直接预测目标在当前帧中的位置,根据预测结果调整目标坐标,并利用新的观测数据更新卡尔曼滤波器的参数,以适应目标的运动变化。若判断目标被遮挡,则进一步计算尺度响应值,根据响应值进行尺度选择,判断目标是否发生了尺度变化。若未发生尺度变化,则仅更新目标模板和滤波器参数,以保持跟踪器的跟踪能力;若发生了尺度变化,则根据尺度变化的具体数值,相应地修正目标边界框的尺寸,确保边界框能够准确地包含目标,之后再更新模板和滤波器。这一系列操作持续进行,直至处理完最后一帧图像,整个跟踪流程随之结束。

1.1 抗遮挡丢失模块

在无人机目标跟踪过程中,遮挡是导致滤波器模型退化的主要因素。当目标被部分或完全遮挡时,响应图的峰值会减弱甚至消失,如果此时仍直接更新滤波器模板,极易引入遮挡物特征,从而造成漂移或跟踪失败。传统相关滤波方法普遍忽略

了这一问题,隐含假设观测始终可靠。为提升在复杂场景下的鲁棒性,本文从观测可信度建模的角度出发,引入遮挡检测与空间正则化机制,从而实现遮挡情况下滤波更新的抑制。

1.1.1 遮挡判断

遮挡检测通过分析目标响应矩阵的特征变化来判断目标是否受到遮挡。如图2所示,当目标未被遮挡时,响应矩阵呈现类似二维正态分布的特征,响应最大值明显且周围响应值较低。而当目标受到遮挡时,响应矩阵的极大值会减小,周围响应值上升,响应矩阵的平均值发生剧烈变化。具体检测步骤如下:假当前帧目标跟踪的搜索窗口尺寸为 $W \times H$, 对应的二维响应矩阵为 $F \in R^{W \times H}$ 。首先获取响应矩阵中最大值 $\max \hat{f}_i(z)$ 及其坐标值 $\text{pos} \max(\hat{f}_i(z)) = (x_{\max}, y_{\max})$, 其中 $x_{\max} \in [1, W], y_{\max} \in [1, H]$ 。然后筛选出响应矩阵中所有大于均值 $\hat{f}_i(z)$ 的点的坐标 $\text{pos}(\hat{f}_i(z_i))$ 。接着计算这些坐标与最大响应点坐标之间的绝对距离和 $\frac{1}{L} \sum \| \text{pos}(\hat{f}_i(z_i)) - \text{pos} \max(\hat{f}_i(z)) \|$ 其中, L 为归一化因子,使得距离取值与窗口绝对像素解耦,确保了判断在不同尺度下的跨场景一致性。最后根据大量实验结果设定的阈值 ξ_1, ξ_2 进行判断,当距离和大于 ξ_1 时,判定目标受到遮挡,当距离和大于 ξ_2 时,判断目标进入丢失状态。




图2 目标被遮挡时响应矩阵变化

Fig. 2 Response matrix changes when the target is obstructed

1.1.2 空间正则化的抗遮挡模块

首先,通过上一节中的方法分析响应矩阵中的最大值及其坐标,判断目标是否受到遮挡。在此基础上,该方法从降低背景干扰、构建大范围负样本以及实现在线自适应更新三个关键方面进行了优化,以提高模型在遮挡情况下的鲁棒性和适应性。

为抑制目标背景混淆问题,首先在滤波器学习

过程中引入空间正则化。设计正则化权重函数对滤波器系数进行区域性惩罚,使得在目标区域内滤波器的响应较低惩罚,而在背景区域则受到更强约束,参数优化的可视化图像如图3所示。具体定义如式(1)所示:

$$\omega(m, n) = \mu + \eta \left(\left(\frac{m}{P} \right)^2 + \left(\frac{n}{Q} \right)^2 \right) \quad (1)$$




图3 空间正则化权重与训练区域可视化图

Fig. 3 Spatial regularization weights and visualization of training regions

其中 $P \times Q$ 表示目标区域的尺寸, μ 为基础正则化参数,而 η 控制了位置依赖的惩罚幅度。该函数使得滤波器在目标中心附近赋予较低的正则化权重,从而更关注目标本身,抑制了外部遮挡或背景噪声的负面影响。

为了适应目标外观变化及由遮挡引起的目标部分信息缺失,本文采用了在线更新滤波器参数的方法。具体的滤波器更新模型如式(2)所示:

$$\begin{cases} A_t = (1 - \gamma)A_{t-1} + \gamma(D_t^T D_t + W^T W) \\ \tilde{b}_t = (1 - \gamma)\tilde{b}_{t-1} + \gamma D_t^T \tilde{y}_t \end{cases} \quad (2)$$

其中, γ 为学习率(通常取值为 0.025), A_t 和 $\tilde{b}_t$ 分别表示用于求解滤波器的矩阵和向量,矩阵 W 来源于前述正则化权重函数。此在线更新机制能够动态调整滤波器,使得模型在目标遭遇遮挡后迅速更新,恢复对目标的有效捕捉。

最后,为了求解上述大规模的线性方程组,本文采用了高斯-赛德尔迭代方法。通过多次迭代,滤波器系数能够稳定收敛,确保在受到部分遮挡情景下依然保持良好的目标跟踪性能。

1.2 尺度不变旋转不变设计

传统相关滤波跟踪器通常仅利用 HOG 特征在平移域进行匹配,隐含假设目标在相邻帧间的几何外观保持近似不变。然而在无人机场景中,目标因距离变化、航向调整或拍摄角度偏移而频繁发生尺

度缩放与旋转,导致固定模板匹配失效。因此,如何在轻量化计算开销下同时建模尺度与旋转变化,是实现鲁棒跟踪的关键挑战。

为了解决上述问题,本文将尺度估计与平移估计分离^[16],以提高跟踪性能。首先引入尺度金字塔策略获取判别性高分辨率特征(如图4所示),在目标周围不同尺度上提取图像块,通过在线学习目标在尺度变化下的外观模式,实现对目标尺度的自适应估计,有效避免了传统方法中穷举搜索带来的高计算开销。其次,为提高对旋转变化的鲁棒性,改进了一种旋转不变HOG描述子,通过对梯度方向进行归一化处理,使其不依赖于目标的绝对方向,从而更好地捕捉目标的局部特征。这些改进措施显著提升了跟踪器在处理尺度变化和旋转变化时的性能,同时降低了计算成本,使其更适合实时应用。




图4 基于尺度金字塔的尺度不变设计

Fig. 4 Scale invariant design based on scale pyramid

1.2.1 尺度自适应机制

首先在检测阶段利用平移滤波器确定目标的大致位置,随后在目标中心附近根据预设的尺度因子采样出一系列尺度候选。具体地,定义尺度因子序列为 $s_i = a^{i-\lfloor M/2 \rfloor}$, $i = 1, 2, \dots, M$ 。其中, a 为尺度步长, M 为尺度样本数量。对于每个尺度样本,从对应图像补丁中提取经过旋转不变处理的HOG特征,记第 m 个尺度样本在第 d 个特征通道上的响应 $z_{d(m)}$ 。

接着构造尺度滤波器,通过最小化正则化均方误差目标函数(式(3))来在线学习尺度变化下的目标外观:

$$\min_h \sum_{m=1}^M \left(\sum_{d=1}^D h_d z_d(m) - y(m) \right)^2 + \lambda \|h\|^2 \quad (3)$$

其中, h_d 为尺度滤波器在第 d 个特征通道上的系数, $y(m)$ 为期望的尺度响应函数(通常设计为在真实尺度对应位置处呈高斯型峰值), λ 为正则化参数,防止模型过拟合; D 为特征通道数。

为了提高计算效率,本方法利用频域求解技

巧。将上述问题转换到频域后,对每个频率分量 ω 的解按式(4)表示为:

$$\hat{h}_d(\omega) = \frac{\hat{y}(\omega) \overline{\hat{z}_d(\omega)}}{\sum_{d=1}^D \hat{z}_d(\omega) \overline{\hat{z}_d(\omega)} + \lambda} \quad (4)$$

其中 $\hat{h}_d(\omega)$ 、 $\hat{z}_d(\omega)$ 和 $\hat{y}(\omega)$ 分别表示 h_d 、 z_d 和 y 的傅立叶变换, $\overline{\hat{z}_d(\omega)}$ 为共轭复数。

1.2.2 旋转不变性设计

传统HOG描述子在计算梯度方向直方图时,对图像局部的梯度信息进行编码,然而,直接使用原始梯度方向容易受到目标旋转的干扰。为使描述子在目标旋转时仍能保持不变性,本文改进了一种旋转不变的HOG描述子,其核心思想是将梯度方向归一化到目标的主要朝向,从而消除了绝对方向的影响。

首先,对输入图像块 $I(x, y)$ 利用Sobel梯度计算算子求解水平方向与垂直方向的梯度 $G_x(x, y)$ 和 $G_y(x, y)$ 。接着求解每个像素的梯度幅值和梯度方向 $\text{mag}(x, y) = \sqrt{G_x(x, y)^2 + G_y(x, y)^2}$ 和 $\theta(x, y) = \arctan\left(\frac{G_x(x, y)}{G_y(x, y)}\right)$ 。

接着,为了实现旋转不变性,本文对图像块内各像素的梯度方向进行加权累加,以确定一个主方向 θ 。通过构造一个旋转直方图来实现这一目标,该直方图统计了图像块内各像素梯度方向的分布情况。通过分析直方图的峰值,可以确定图像块的主方向 θ_0 。具体如式(5)所示:

$$\theta_0 = \arg \max_{\theta} \left\{ \sum_{(x, y) \in R} \text{mag}(x, y) \omega(x, y) \delta(\theta(x, y) - \theta) \right\} \quad (5)$$

其中, R 表示图像块内所有像素的集合, $\omega(x, y)$ 为像素位置处的权重,而 $\delta(\cdot)$ 为指示函数。

在确定主方向 θ_0 后,为实现描述子的旋转不变性,将每个像素的原始梯度方向进行归一化处理。经过此处理后,所有梯度方向均以主方向为参考基准,构成的HOG描述子便不会受到目标绝对旋转角度的影响。归一化处理后,统计每个区间内像素的梯度幅值和频率,构造出局部梯度方向直方图,如式(6)所示:

$$\text{HOG}(k) = \sum_{(x, y) \in R_k} \text{mag}(x, y) \quad (6)$$

其中 R_k 表示归一化梯度方向落在第 k 个角度区间的像素合集。

最后,为了增强描述子对光照变化和噪声的鲁

棒性,对构造的直方图使用 L2 范数进行归一化处理。通过上述对尺度滤波和旋转不变描述子的改进,算法能够适应不同尺度下的无人机目标跟踪任务。

1.3 目标丢失搜索机制

为了提高核相关滤波算法在目标丢失情况下的搜索重跟踪能力,本文在基础相关滤波器的基础上融合卡尔曼滤波器的搜索机制。该机制通过结合卡尔曼滤波器的预测能力和核相关滤波器的检测能力,形成预测-跟踪-校准的闭环流程,从而有效应对目标丢失问题。

在跟踪开始之前,初始化卡尔曼滤波器的状态向量 $\mathbf{X}$ 和协方差矩阵 $\mathbf{P}$ 。状态向量包括目标在图像中的位置 (x_k, y_k) 以及目标的速度 (v_x, v_y) 。

预测步骤包括预测目标位置和速度以及相关预测状态的协方差矩阵(不确定性)。对于输入帧图像,首先利用卡尔曼滤波器预测目标中心点坐标。根据递归运算原理,其预测方程如式(7)所示:

$$\begin{cases} \hat{\mathbf{x}}_k^- = \mathbf{F}\hat{\mathbf{x}}_{k-1} \\ \mathbf{P}_k^- = \mathbf{F}\mathbf{P}_{k-1}\mathbf{F}^T + \mathbf{Q} \end{cases} \quad (7)$$

其中, $\hat{\mathbf{x}}_{k-1}$ 为 $k-1$ 时刻的状态向量, $\mathbf{P}_{k-1}$ 为其对应的协方差矩阵, $\mathbf{F}$ 为状态转移矩阵。

在跟踪阶段,系统首先利用卡尔曼滤波器预测目标位置,并在预测坐标附近提取目标区域的 HOG 特征,对其进行傅里叶变换以获得特征向量 $\mathbf{x}_k^f$ 。随后,借助核相关滤波器对所提取的特征进行相关性计算,从而检测当前帧中与目标样本相关性最高的图像块,并通过最大化相关性响应确定目标在该帧中的位置。该过程将不断重复,保持待跟踪目标的状态更新。

当遮挡检测模块判断连续 n 帧丢失阈值大于 ξ , 时目标进入丢失状态时,系统进入搜索模式。这时,基础检测器提供目标最后时刻出现的位置用于更新卡尔曼滤波器,滤波过程包括预测和更新两个步骤。

更新步骤发(式(8))生在目标未丢失时,主要负责更新卡尔曼增益、目标位置速度和更新后状态估计的不确定性:

$$\begin{cases} \mathbf{K}_k = \mathbf{P}_k^- \mathbf{H}^T (\mathbf{H} \mathbf{P}_k^- \mathbf{H}^T + \mathbf{R})^{-1} \\ \hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k (\mathbf{z}_k - \mathbf{H} \hat{\mathbf{x}}_k^-) \\ \mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k \mathbf{H}) \mathbf{P}_k^- \end{cases} \quad (8)$$

其中, $\mathbf{H}$ 为观测矩阵, $\mathbf{z}_k = [x_k, y_k]$ 表示 k 时刻由核相

关滤波器检测的目标中心点坐标, $\mathbf{K}_k$ 为卡尔曼增益矩阵。

值得注意的是,若目标长时间丢失,卡尔曼滤波器由于缺乏有效观测,其预测结果将趋于发散。因此,当连续丢失帧数超过 200 帧时,系统将发出错误警告,并暂停跟踪,直至手动重新选择待跟踪目标。

2 实验分析

2.1 实验环境

本文实验基于 Zynq-7000 系列中的 7020 型号芯片进行算法验证。该平台采用异构架构,融合了处理系统(PS)和可编程逻辑(PL)。PS 部分搭载双核 ARM Cortex-A9 处理器,主频 1GHz,配备浮点运算单元,提供强大的处理能力。PL 部分基于 28nm 工艺 FPGA,拥有 85K 逻辑单元和 900 个 DSP 切片,支持高效硬件加速。PS 与 PL 通过高带宽 AXI 总线互联,实现低延迟数据传输和软硬件协同处理。

2.2 参数设置

相关滤波参数包括正则化系数 $\lambda = 0.0001$ 、高斯目标带宽因子 $\sigma_1 = 0.125$ 、模型更新插值因子 $\theta = 0.012$ 以及高斯核带宽 $\sigma_2 = 0.6$ 。尺度高斯带宽因子 $\sigma_3 = 1/16$ 、尺度学习率 $lr = 0.025$ 。此外,特征提取参数包括 HOG 单元格大小 $cell_size = 4$ 和模板尺寸 $template_size = 96$,用于保证目标区域的特征提取效果和尺度归一化。

2.3 数据集及其评价标准

实验数据集采用 UAV123、OTB100 数据集和几段自有无人机实时采集数据,利用一次性评估算法(One-Pass Evaluation, OPE),精度-阈值曲线、成功率-阈值曲线及实时帧率指标综合评估跟踪算法性能。

精度评价方面,本研究采用中心位置误差(Center Location Error, CLE)作为量化指标,其定义为算法预测目标边界框中心点与真实标注中心点之间的欧氏距离,如式(9)所示:

$$C_{LE} = \sqrt{(x_t - x_t^{truth})^2 + (y_t - y_t^{truth})^2} \quad (9)$$

其中 (x_t, y_t) 表示计算的目标中心点坐标; $(x_t^{truth}, y_t^{truth})$ 表示目标的真实中心点坐标。该指标数值越小表明目标定位越精准,本文评估中使用的对应距离阈值为 $[1, 50]$ 像素。

成功率采用重叠率 O_R 指标来计算,该指标量化

预测区域与真实目标的覆盖程度,取值范围 $[0,1]$,数值越大表示跟踪越精确。成功率 O_R 计算,具体为数据集视频序列中大于某阈值的帧数与总帧数的比值。 O_R 定义如式(10)所示:

$$O_R = \frac{|r_t \cap r_t^{truth}|}{|r_t \cup r_t^{truth}|} \quad (10)$$

式中: r_t 为算法求出的目标边界框; r_t^{truth} 为目标的真实边界框,本文对IoU阈值计算帧交并比得到成功率曲线图,取值范围为 $(0, 0.05, 0.10, \dots, 1.00)$ 。

实时性评估方面,通过计算算法每秒处理帧数(Frames Per Second, FPS)衡量其计算效率,该指标直接影响算法在无人机等实时系统中的工程适用性。完整评估体系通过综合上述精度、成功率及实时性指标,为跟踪算法性能提供多维度的量化分析框架。

2.4 定量分析

为了全面评估本文所提出算法的性能,我们在UAV123^[22]与OTB100^[23]两个常用目标跟踪基准数据集上开展了对比实验。鉴于本文研究目标为面向空基无人系统的嵌入式实时跟踪应用,对比算法选择遵循可在无GPU条件下稳定运行的原则,包括基于深度学习的SiamFC^[24],以及基于相关滤波SRDCF^[25]、ASLA^[26]、STRCF^[27]、AutoTrack^[28]、ECO^[29]、fDSST^[16]和KCF^[15]。实验结果以精确度曲线、成功率曲线和表格形式呈现(见图5~8与表1~2),从而在精度—鲁棒性—实时性三个维度全面验证了算法的有效性。




图5 七种算法在UAV123上的精确度

Fig. 5 Accuracy curve of seven algorithms on UAV123

2.4.1 UAV123数据集评估

在UAV123数据集上的结果如图5(精确度)、图6(成功率)以及表1所示。可以看出,本文方法在




图6 七种算法在UAV123上的成功率

Fig. 6 Success rate curve of seven algorithms on UAV123




图7 七种算法在OTB100上的精确度

Fig. 7 Accuracy curve of seven algorithms on OTB100




图8 七种算法在OTB100上成功率

Fig. 8 Success rate curve of seven algorithms on OTB100

七种方法中精度和成功率排名中游,分别为54.6%与37.6%,与fDSST方法表现接近。然而在实时性方面,本文方法以33.21帧/s显著领先所有对比方法,是唯一突破30帧/s的方案,较第二名KCF方法

表 1 七种算法在 UAV123 数据集验证结果
Tab.1 Validation results of seven algorithms on UAV123 dataset

方法	精确度/%	成功率/%	帧率/(帧·s ⁻¹)
ECO ^[29]	61.1±6.8	41.2±4.9	12.00
STRCF ^[27]	68.3±6.3	48.3±4.9	15.00
SiamFC ^[24]	72.7±6.0	50.0±4.6	5.00
AutoTrack ^[28]	68.5±6.2	47.2±4.5	23.22
fDSST ^[16]	54.3±6.9	37.3±4.9	25.40
KCF ^[15]	29.5±5.7	19.7±4.0	26.47
本文方法	54.6±6.9	37.6±4.9	33.21

表 2 七种算法在 OTB100 验证结果
Tab.2 Validation results of seven algorithms on OTB100

方法	精确度/%	成功率/%	帧率/(帧·s ⁻¹)
ECO_HC ^[29]	77±5.8	57.14±5.4	13.40
STRCF ^[27]	76±5.9	52.41±5.5	15.00
SiamFC ^[24]	64±6.2	46.17±5.6	4.00
AutoTrack ^[28]	57±6.4	44.58±5.6	21.46
fDSST ^[16]	55±6.5	41.29±5.7	26.74
KCF ^[15]	51±6.7	40.91±5.8	28.41
本文方法	66±6.1	55.80±5.4	35.39

提升了约 25%。这一结果表明:本文方法在精度上虽不及 SiamFC 与 STRCF 等深度学习方法(72.7%/50.0% 与 68.3%/48.3%),但在嵌入式平台部署场景下,通过牺牲部分精度换取 121.4% 的帧率提升(相对 STRCF 方法的 15 帧/s 对比),实现了实时性与鲁棒性的高效平衡。相比传统轻量算法 KCF 刚刚(29.5%/19.7%),本文方法在精度与成功率上均显著提升,同时保持远高于 fDSST 方法的运行速度(25.4 帧/s)。因此,该方法在资源受限的无人机平台上展现了更强的实用价值。

2.4.2 OTB100 数据集评估

在 OTB100 数据集上的结果如图 7(精确度)、图 8(成功率)以及表 2 所示。本文方法取得 66% 的精度与 55.8% 的成功率,分别位列七种方法的第三与第二,仅次 ECO_HC 与 STRCF 方法。与 SiamFC、AutoTrack、fDSST 和 KCF 方法相比,本文方法在精度上分别提升约 2%、9%、11% 与 15%。更重要的是,本文方法在 OTB100 数据集上保持了 35.39 帧/s 的实时处理能力,显著优于 AutoTrac(21.46 帧/s)、SiamFC(4 帧/s)等方法,而高精度的 ECO_HC 与 STRCF 方法受限于深度特征与强正则化约束,仅能在嵌入式平台实现 12~15 帧/s,难以满足无人机低

算力场景下的在线跟踪需求。

2.5 定性实验

为验证本文提出的尺度自适应、遮挡匹配与目标丢失搜索模块的有效性,在自建无人机数据集上开展定性实验。该数据集由三段视频组成,分别对应视角变换、部分遮挡及目标丢失三种典型场景,用于针对性验证各模块性能。

2.5.1 尺度自适应算法验证

实验在传统 KCF 跟踪方法与尺度自适应改进算法在跟踪中遇到的视角缩放场景下进行试验。

实验效果如图 9 所示,两种跟踪算法在初始阶段均能完整覆盖目标区域,表现出良好的目标跟踪性能。在视角收缩过程中(见图 9 中(1)和(2)),随着目标在成像平面中的占比持续增大,KCF 算法(见图 9(a))由于缺乏尺度自适应机制,其固定尺寸的跟踪框无法有效匹配目标形态变化,导致跟踪区域仅能覆盖目标局部特征。这种尺度失配现象显著降低了目标交叠率(IoU)和中心定位精度(CLE)。相比之下,本文方法(见图 9(b))通过引入动态尺度估计模块,能够实时调整跟踪框尺寸,确保了跟踪过程的鲁棒性。




图 9 本文算法与 KCF 方法在尺度变化下的对比
Fig.9 Comparison of proposed algorithm and KCF under scale variation

2.5.2 遮挡匹配的改进算法验证

在不同程度遮挡条件下,对 KCF 跟踪方法与动态阈值丢失匹配改进方法的跟踪性能进行对比实验,实验效果如图 10 所示。

由图 10 所示,图 10(b)为 KCF 算法在受到遮挡时的表现,图 10(a)为本文方法在受到遮挡时的表现。其中,KCF 在场景一、二中,在收到遮挡时会失败,但是遮挡结束后又能重新跟踪上目标,表现出一定的抗遮挡性。但在场景三中,KCF 算法在受到遮挡后无法重新跟踪上目标,传统 KCF 算法跟踪目标失败。而改进的算法在三个场景下均能成功跟踪目标。




图10 遮挡匹配的改进算法效果图

Fig. 10 Effect diagram of improved occlusion matching algorithm

本文提出的方法通过综合多种机制,有效区分了正常目标运动与遮挡引起的响应变化,从而实现了鲁棒稳定的跟踪。首先,利用响应图与理想二维高斯分布的高相关性,通过计算响应值,当目标遮挡时响应值显著下降,便于快速识别遮挡状态。其次,采用空间正则化的抗遮挡跟踪匹配机制,动态调整遮挡判断标准,使得算法能适应复杂场景中的变化;同时。最后,在检测到连续遮挡信号时,采用了在线更新滤波器参数的方法,避免了错误信息对模板的污染,确保了模型参数的稳定性。综合这些策略,即使在目标受到部分遮挡的情况下,算法依然能够准确捕捉目标状态,从而实现持续稳定的跟踪。

2.5.3 基于卡尔曼滤波目标丢失搜索改进算法验证

在传统KCF方法中,当目标遭遇完全遮挡并丢失后,跟踪则会失败,如图11(b)所示。本文将提出的基于卡尔曼滤波器的改进方法在目标完全丢失场景下进行丢失搜索实验,实验效果如图11(a)

所示。

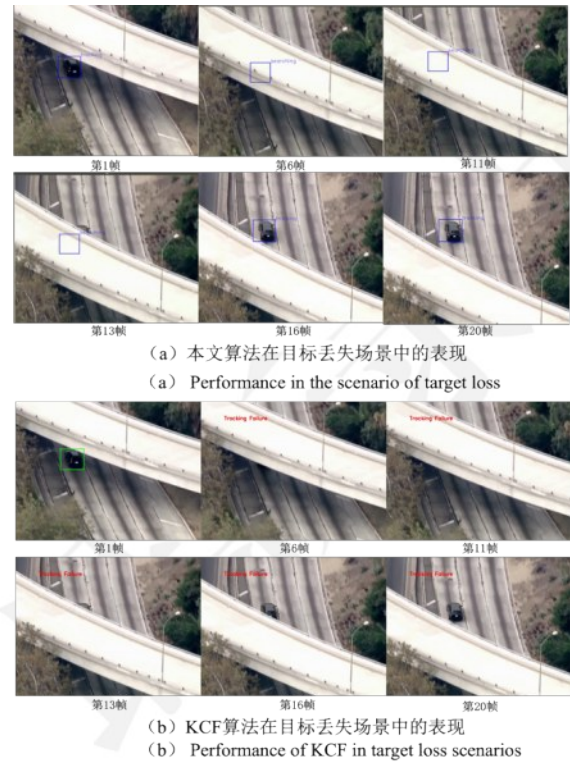


图11 基于卡尔曼滤波目标丢失搜索改进方法性能效果

Fig. 11 Performance improvement of an enhanced algorithm for target loss search based on Kalman filtering

本文方法(见图11(a))在初始阶段(第1帧),系统检测到目标进入遮挡预判状态。经过连续5帧的遮挡状态确认后,于第6帧触发目标丢失机制。此时,系统启动基于卡尔曼滤波的运动学模型进行目标轨迹预测,并在第6~第13帧期间,通过区域搜索策略在预测位置周边进行多尺度模板匹配。至第16帧时,目标显露面积恢复至60%以上,视觉特征匹配置信度超过恢复阈值,跟踪器成功重捕获目标。最终在第20帧,目标完全脱离遮挡,系统恢复至标准跟踪模式,PSR值回升至基准水平。这一过程充分验证了算法在目标部分遮挡阶段的鲁棒跟踪能力,以及丢失恢复机制的有效性。相比之下,传统KCF算法(见图11(b))在面对目标丢失场景时,一旦目标完全丢失,便失去了继续跟踪的能力,导致跟踪失败。

当场景切换为镜头拉伸时(见图9中(3)、(4)),目标在成像平面中的像素占比呈指数衰减。KCF方法在此过程中持续采用固定尺度跟踪策略,导致跟踪框内目标特征逐渐被背景噪声污染,形成误差累积效应。实验数据显示,该情况下传统方法的平

均重叠率较初始阶段下降明显。本文方法通过构建多尺度特征金字塔,实现了对目标尺度变化的快速响应,其自适应机制可有效抑制背景干扰,在目标尺度缩小时仍保持较高的平均跟踪精度。

2.6 消融实验

2.6.1 各子模块消融实验

为定量评估本文算法中各核心组件——空间正则化抗遮挡模块、尺度金字塔/旋转不变描述子以及卡尔曼滤波重检测模块的有效性,并验证多模块融合的协同增益,在 UAV123 数据集上开展了渐进式消融实验。实验以基础 KCF 方法为基准,采用逐项叠加模块的方式,遵循 2.3 节所述的 OPE 评估准则,以成功率和精确度作为核心评价指标。实验旨在通过横向对比,揭示各功能模块对跟踪性能的独立贡献及其在全模块集成下的最优表现,结果如表 3 所示。

表 3 各模块在 UAV123 数据集上的消融结果

Table 3 Ablation results of each module on UAV123 dataset

方法	精确度/%	成功率/%
基线 KCF	29.5±5.7	19.7±4.0
空间正则化	42.7±9.2	28.9±6.2
尺度金字塔	44.6±6.9	33.0±4.9
卡尔曼重检测	52.7±8.8	35.5±6.0
全部(本文方法)	54.6±6.9	37.6±4.9

由表 3 消融实验结果可见,各模块均对提升跟踪性能贡献显著且呈现出良好的协同增益:空间正则化抗遮挡模块通过抑制背景噪声干扰,使基线 KCF 的成功率和精确度分别大幅增长 9.2% 和 13.2%,有效缓解了复杂场景下的模型退化;在此基础上,尺度金字塔与旋转不变描述子的引入进一步提升了 4.1% 的成功率,增强了算法对目标尺度缩放与旋转形变的感知力;而卡尔曼滤波重检测模块针对目标丢失后的恢复难题,使精确度实现了 8.1% 的跨越式增长,显著提升了算法的重定位能力。最终,全模块融合达到了 37.6% 和 54.6% 的最优表现,证明了本文算法通过构建状态判别-几何感知-异常恢复的闭环互补框架,全面增强了在复杂无人机场景下的跟踪鲁棒性。

2.6.2 不同遮挡策略消融实验

为验证本文提出的基于响应矩阵特征的遮挡判别策略的有效性与优越性,在 UAV123 数据集上开展遮挡判别策略对比消融实验。实验保持本文

跟踪框架的其余模块(尺度金字塔/旋转不变描述子、卡尔曼滤波重检测、空间正则化抗遮挡)完全一致,仅替换遮挡判别模块,将本文方法与目标跟踪领域经典的遮挡判别指标峰值旁瓣比(PSR)、平均峰值相关能量(APCE)进行对比,以成功率和精确度为核心评价指标,定量验证不同遮挡判别策略对整体跟踪性能的影响,实验结果如表 4 所示。

表 4 不同遮挡策略的消融结果

Table 4 Ablation experiment results of different occlusion discrimination strategies on UAV123 dataset

遮挡判别策略	精确度/%	成功率/%
APCE	42.8±9.1	28.9±6.3
PSR	42.8±9.3	29.6±6.5
本文方法	54.6±6.9	37.6±4.9

由实验结果分析可知,本文提出的遮挡判别策略显著优于经典的 PSR 与 APCE 指标。APCE 与 PSR 由于判别维度单一且缺乏对响应矩阵全局特征的考量,易受背景噪声及尺度形变干扰,导致跟踪成功率与精确度均处于较低水平。相比之下,本文方法通过融合响应矩阵峰值、均值及高响应点空间分布等多维特征,既捕捉了全局分布变化,又量化了局部响应的空间显著性,实现了对目标正常形变与真实遮挡的精准区分。在数据表现上,本文方法较 APCE 在成功率与精确度上分别提升了 8.7% 和 11.8%;在架构协同上,本文策略通过双阈值机制构建了正常-遮挡-丢失三状态分级判别体系,能够为空间正则化模块与重检测模块提供精准的触发信号,弥补了传统指标仅能进行二分类判别而导致的模块协同性不足。综上,本文策略通过多特征融合与分级判别,有效解决了复杂无人机场景下传统指标的判别局限性,为整体框架的性能跨越提供了重要支撑。

2.6.3 不同尺度/步长消融实验

尺度金字塔的尺度样本数 $nscale$ 与尺度步长 $step$ 是影响尺度自适应模块性能的核心参数:样本数决定了尺度变化的覆盖范围,步长决定了尺度采样的精细度,二者不仅直接影响目标尺度估计的准确性,更通过改变特征提取与匹配的计算开销,决定算法的实时性,最终形成速度-精度的权衡关系。为确定无人机资源受限平台下的最优参数组合,在 UAV123 数据集上开展消融实验,保持本文跟踪框架其余模块不变,仅调整尺度样本数与步

长,设计四组不同参数组合进行对比,以成功率和精确度为精度评价指标,结合计算开销分析实时性变化规律,实验结果如表5所示。

表5 不同尺度/步长的消融结果

Table 3 Ablation experiment results of different scale sample numbers/step sizes on UAV123 dataset

<i>n</i> scale	<i>step</i>	精确度/%	成功率/%
5	1.02	43.7±9.1	30.3±6.5
17	1.01	44.9±9.6	34.0±7.2
33	1.05	42.8±9.4	34.3±7.2
7(本文方法)	1.02	54.6±6.9	37.6±4.9

结合无人机平台的算力约束与尺度参数的消融实验结果可知,尺度采样精细度对精度的正向增益存在显著的边际效应,且过量采样会导致背景噪声干扰与冗余计算。对比实验显示,当尺度样本数增加至33组时,由于引入过多背景冗余且超出了Zynq-7000平台的实时处理能力,精确度反而下降至42.8%。本文选取的 n scale=7/ $step$ =1.02参数组合在四组实验中表现最优,成功率与精确度分别达到37.6%和54.6%。这表明无人机场景下的目标尺度缩放多为缓变,参数设计无需追求极致的采样密度,而应贴合平台特性采取适度采样方案,在有效捕捉几何形变的同时将计算开销控制在合理区间,从而实现速度与精度的最优权衡。

3 结论

本文针对无人机航拍场景下目标跟踪易受尺度与视角变化、遮挡干扰及目标丢失影响的问题,提出了一种基于统一状态空间建模的自主恢复式相关滤波框架。该方法通过尺度金字塔与旋转不变描述子提升几何适应性,结合响应图可信度建模与空间正则化机制增强遮挡鲁棒性,并利用卡尔曼滤波预测实现目标丢失后的快速重捕获。在UAV123、OTB100及自建航拍数据集上的实验表明,该方法在低算力平台上兼顾了高实时性与可靠精度,整体性能显著优于传统轻量化算法,展现出良好的跨场景适应性与工程应用潜力。

参考文献 (References)

[1] 张栋, 李林, 王孟阳, 等. 不确定环境下多无人机察打一体任务规划方法[J]. 北京理工大学学报, 2025, 45(2): 111-125.
Zhang D, Li L, Wang M Y, et al. Mission planning method for multi-UAV reconnaissance-attack integrated operations under

uncertain environments [J]. Transactions of Beijing Institute of Technology, 2025, 45(2): 111-125. (in Chinese)

- [2] 相晓嘉, 谭沁, 王菡, 等. 无人机先进地面站关键技术综述[J]. 国防科技大学学报, 2023, 45(2): 1-14.
Xiang X J, Tan Q, Wang C, et al. Review on key technologies of advanced UAV ground control stations [J]. Journal of National University of Defense Technology, 2023, 45(2): 1-14. (in Chinese)
- [3] 赵军民, 何浩哲, 王少奇, 等. 复杂环境下多无人机目标跟踪与避障联合航迹规划[J]. 兵工学报, 2023, 44(9): 2685-2696.
Zhao J M, He H Z, Wang S Q, et al. Coordinated trajectory planning for multi-UAV target tracking and obstacle avoidance in complex environments [J]. Acta Armamentarii, 2023, 44(9): 2685-2696. (in Chinese)
- [4] 樊小冬, 谭天一, 吴江. 轻量化低慢小无人机多目标检测及跟踪方法[J]. 北京航空航天大学学报, 2026, 52(2): 610-619.
Fan X D, Tan T Y, Wu J. Lightweight multi-object detection and tracking method for low-altitude slow and small UAVs [J]. Journal of Beijing University of Aeronautics and Astronautics, 2026, 52(2): 610-619. (in Chinese)
- [5] 党昭洋, 孙晓永, 郭润泽, 等. 融合多视角投影与时空拓扑的多无人机多目标跟踪方法[J]. 仪器仪表学报, 2025, 46(11): 215-228.
Dang Z Y, Sun X Y, Guo R Z, et al. Multi-UAV multi-object tracking method integrating multi-view projection and spatio-temporal topology [J]. Chinese Journal of Scientific Instrument, 2025, 46(11): 215-228. (in Chinese)
- [6] Cao Z A, Huang Z Y, Pan L, et al. Towards real-world visual tracking with temporal contexts [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(12): 15834-15849.
- [7] Zhu Y B, Li C L, Wang X, et al. RGBT tracking via progressive fusion transformer with dynamically guided learning [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2024, 34(9): 8722-8735.
- [8] Fan H J, Yu Z C, Wang Q, et al. QueryTrack: joint-modality query fusion network for RGBT tracking [J]. IEEE Transactions on Image Processing, 2024, 33: 3187-3199.
- [9] Cai Y J, Sui X B, Gu G H, et al. Multi-modal interaction with token division strategy for RGB-T tracking [J]. Pattern Recognition, 2024, 155: 110626.
- [10] Sun M, Liu X T, Wang H Y, et al. MixRGBX: universal multi-modal tracking with symmetric mixed attention [J]. Neurocomputing, 2024, 603: 128274.
- [11] Lu A D, Li C L, Zhao J C, et al. Modality-missing RGBT tracking: invertible prompt learning and high-quality benchmarks [J]. International Journal of Computer Vision, 2025, 133(5): 2599-2619.
- [12] Li B, Peng F G, Hui T R, et al. RGB-T tracking with template-bridged search interaction and target-preserved template updating [J]. IEEE Transactions on Pattern Analysis and Machine

- Intelligence, 2025, 47(1): 634–649.
- [13] Lai S M, Liu C, Zhu J W, et al. MambaVT: spatio-temporal contextual modeling for robust RGB-T tracking [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2025, 35(9): 9312–9323.
- [14] Henriques J F, Caseiro R, Martins P, et al. Exploiting the circulant structure of tracking-by-detection with kernels [C]//Computer Vision – ECCV 2012: 12th European Conference on Computer Vision, 2012: 702–715.
- [15] 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.
- [16] 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.
- [17] Kiani Galoogahi H, Fagg A, Lucey S. Learning background-aware correlation filters for visual tracking [C]//2017 IEEE International Conference on Computer Vision, 2017: 1144–1152.
- [18] Pi Z X, Shao Y, Gao C, et al. Instance-based feature pyramid for visual object tracking [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2022, 32(6): 3774–3787.
- [19] Cai Z M, Wang Z Z, Huang J C, et al. A target tracking method based on adaptive occlusion judgment and model updating strategy [J]. PeerJ Computer Science, 2023, 9: e1562.
- [20] Ma C, Yang X K, Zhang C Y, et al. Long-term correlation tracking [C]//2015 IEEE Conference on Computer Vision and Pattern Recognition, 2015: 5388–5396.
- [21] Yan B, Zhang X Y, Wang D, et al. Alpha-Refine: boosting tracking performance by precise bounding box estimation [C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 5289–5298.
- [22] Mueller M, Smith N, Ghanem B. A benchmark and simulator for UAV tracking [C]//Computer Vision – ECCV 2016, 2016: 445–461.
- [23] Wu Y, Lim J, Yang M H. Object tracking benchmark [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1834–1848.
- [24] Bertinetto L, Valmadre J, Henriques J F, et al. Fully-convolutional siamese networks for object tracking [C]//Computer Vision – ECCV 2016 Workshops, 2016: 850–865.
- [25] Danelljan M, Häger G, Khan F S, et al. Learning spatially regularized correlation filters for visual tracking [C]//2015 IEEE International Conference on Computer Vision, 2015: 4310–4318.
- [26] Jia X, Lu H C, Yang M H. Visual tracking via adaptive structural local sparse appearance model [C]//2012 IEEE Conference on Computer Vision and Pattern Recognition, 2012: 1822–1829.
- [27] Li F, Tian C, Zuo W M, et al. Learning spatial-temporal regularized correlation filters for visual tracking [C]//2018 IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4904–4913.
- [28] Li Y M, Fu C H, Ding F Q, et al. AutoTrack: towards high-performance visual tracking for UAV with automatic spatio-temporal regularization [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11923–11932.
- [29] Danelljan M, Bhat G, Khan F S, et al. ECO: efficient convolution operators for tracking [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition, 2017: 6931–6939.