

DOI:10.16136/j.joel.2022.02.0382

# 自适应时空正则的无人机目标跟踪算法

吴 捷<sup>1,2\*</sup>, 马小虎<sup>2</sup>

(1. 泰州职业技术学院信息技术学院, 江苏 泰州 225300; 2. 苏州大学 计算机科学与技术学院, 江苏 苏州 215006)

**摘要:**针对无人机跟踪场景中目标分辨率较低且易受无人机(unmanned aerial vehicle, UAV)飞行姿态、速度变化等因素的影响而难以对目标进行鲁棒跟踪的问题,提出了一种自适应时空正则的无人机目标跟踪算法以有效解决上述问题。在时空正则相关滤波器(spatial temporal regularized correlation filter, STRCF)算法基础上引入 AutoTrack 中的空间正则性代价并利用峰值旁瓣比和局部响应变化量,在线动态更新时空正则化参数以提升跟踪器的准确性,通过在跟踪器中嵌入遮挡处理模块解决目标遭遮挡后跟踪漂移的问题。在多个无人机基准数据集上进行了测试,实验结果表明,与基准算法 AutoTrack 相比,本文算法具有更高的精确度和更快的处理速度。其中在 DTB70 数据集上跟踪精度和速度分别提升了 1.5% 和 74.4%;在 UAVDT 数据集上 9 个属性的分类对比中,本文算法在尺度变化(scale variation, SV)、目标模糊(object blur, OB)等 7 个属性上取得较高的性能,均排在第一位。由此可见本文算法可以更好地满足无人机应用需求。

**关键词:**目标跟踪; 峰值旁瓣比; 局部响应变化向量; 时空正则化参数

**中图分类号:** TP391.41 **文献标识码:** A **文章编号:** 1005-0086(2022)02-141-08

## UAV target tracking algorithm based on adaptive spatial-temporal regularization

WU Jie<sup>1,2\*</sup>, MA Xiaohu<sup>2</sup>

(1. College of Information technology, Taizhou Polytechnic College, Taizhou, Jiangsu 225300, China; 2. School of Computer Science and Technology, Soochow University, Suzhou, Jiangsu 215006, China)

**Abstract:** Aiming at the problem that the target resolution in unmanned aerial vehicle (UAV) tracking scene is low and it is difficult to track the target robustly due to the influence of UAV flight attitude, speed change and other factors, an adaptive spatial-temporal regularization algorithm for UAV target tracking is proposed. Based on the spatial temporal regularized correlation filter (STRCF) algorithm, the cost of spatial regularity in AutoTrack is introduced, and the spatial-temporal regularization parameters are dynamically updated online by using the peak side lobe ratio and local response variation vector to improve the accuracy of the tracker. Occlusion processing module is embedded in the tracker to solve the tracking drift problem after the target is occluded. Experimental results on several UAV benchmark datasets show that the proposed algorithm has higher accuracy and faster processing speed than the benchmark algorithm Autotrack. The tracking accuracy and speed of DTB70 data set are improved by 1.5% and 74.4% respectively. In the classification comparison of nine attributes on UAVDT data set, this algorithm achieves high performance on seven attributes, such as scale variation (SV), object blur (OB), etc. It can be seen that this algorithm can better meet the requirements of UAV applications.

**Key words:** target tracking; peak side lobe ratio; local response variation vector; spatial-temporal weighting regularization parameter

\* E-mail: wujie22@sina.com

收稿日期: 2021-06-03 修订日期: 2021-06-30

基金项目: 国家自然科学基金项目(61402310)、江苏省自然科学基金项目(BK20141195)和泰州职业技术学院重点科研项目(1821819039)资助项目

## 1 引言

随着科学技术的不断发展,无人机被广泛应用于军事侦察、环境监测、航空摄影、交通巡逻等领域。作为无人机应用的关键技术之一,目标跟踪技术已成为机器视觉领域的研究热点。目前关于目标跟踪有两个主要的研究分支领域:基于判别相关滤波器(discriminative correlation filter, DCF)的方法及基于深度学习的方法<sup>[1]</sup>。考虑到无人机功率容量以及计算能力的限制,由于DCF框架快速高效的特性成为无人机应用领域的首选。

近年,基于DCF的跟踪器的改进主要集中在3个方面:1)建立更鲁棒的外观模型;2)减弱边界效应的限制;3)防止滤波器退化。

文献[2]基于Camshift算法,通过提取跟踪目标的色度、饱和度和局部二值模式(local binary pattern, LBP)纹理特征建立基于三维联合直方图的跟踪模板以提高算法的跟踪准确度。文献[3]提出多特征重检测的相关滤波无人机视觉跟踪,解决目标遮挡的问题。吴贵山等<sup>[4]</sup>融合HOG特征和CN特征,并通过对比峰响应进行抑制,将多个次峰聚合为一个中心主峰提出一种多特征融合的次峰响应抑制的无人机目标跟踪算法。

上述文献仅利用手工特征来建立外观模型,没有充分利用待跟踪视频序列的上下文关系,在复杂场景下跟踪精度不高。

LI等<sup>[5]</sup>提出的时空正则相关滤波器(spatial temporal regularized correlation filter, STRCF)算法,通过引入预定义的时间正则化项来提高目标对象的学习性能,有效地解决了遮挡和大幅形变等问题,并可实时追踪目标,非常适合应用于无人机跟踪领域。文献[6]在基准BACF算法框架下引入时间一致性约束项和空间一致性约束项,提出了学习时空一致性相关滤波(temporal-spatial consistency correlation filter, TSCF)跟踪算法。文献[7]提出了一种称之为AutoTrack的在线自动学习时空正则项的方法,该算法在多个无人机测试集上均达到最优的效果。

本文提出了一种新的自适应时空正则的无人机目标跟踪算法。利用AutoTrack中提出的局部响应变化向量并结合峰值旁瓣比在线动态更新时空正则化参数,另外在跟踪器中嵌入遮挡判断模块用于评估当前帧的跟踪效果,根据结果来判断是否对滤波器的样本模型予以更新。在3个无人机数据集上进行测试并与其他算法进行对比,实验结果表明本文算法优于当前性能达到最优的几

种算法,在无人机的快速运动、镜头抖动、视角变化、目标遮挡等挑战场景中表现出较好的精度和鲁棒性。

## 2 相关跟踪算法

### 2.1 STRCF 算法

在此章节中,首先描述时空正则相关滤波器(spatial temporal regularized correlation filter, STRCF)算法,通过最小化以下目标函数来学习 $t$ 帧中的最优滤波器为:

$$\epsilon(H_t) = \frac{1}{2} \|y - \sum_{k=1}^K x_t^k \cdot h_t^k\|_2^2 + \frac{1}{2} \sum_{k=1}^K \|\mu \cdot h_t^k\|_2^2 + \frac{\theta}{2} \sum_{k=1}^K \|h_t^k - h_{t-1}^k\|_2^2, \quad (1)$$

式中, $x_t^k$ 为当前帧图像中提取到的样本, $k$ 表示特征通道索引, $y$ 为高斯响应函数。

在正则化方面,STRCF借鉴SRDCF<sup>[8]</sup>中的空间正则化参数 $u$ 来减小边界效应,并首次提出了时间正则化的概念,即式(1)中的第3项,通过惩罚当前滤波器和之前滤波器之间的差异来限制滤波器的退化。

尽管STRCF取得了令人满意的性能,但它仍然存在两个局限性:1)时间正则化参数 $\theta$ 设置为常数15不具有普适性,在很多视频序列中无法取得理想的跟踪结果;2)固定空间正则化无法有效应对无人机跟踪场景中不可预见的外观变化问题。

### 2.2 AutoTrack 算法

为了解决STRCF中存在的问题,AutoTrack充分利用局部和全局响应变化,实现了自动空间和时间正则化。

在AutoTrack中,首先定义了局部响应变化向量 $\Pi = [|\Pi^1|, |\Pi^2|, \dots, |\Pi^T|]$ ,其中第 $i$ 个元素 $|\Pi^i|$ 定义为:

$$\Pi^i = \frac{R_i[\Psi_\Delta]^i - R_{i-1}^i}{R_{i-1}^i}, \quad (2)$$

式中, $[\Psi_\Delta]$ 是为了消除运动影响,使两个响应图 $R_i$ 、 $R_{i-1}$ 中的峰值相一致的移位运算符, $R_i$ 表示响应图 $R$ 中的第 $i$ 个元素。

基于此,AutoTrack中的自动空间和时间正则化实现如下:

自动空间正则化:局部响应变化揭示当前帧搜索区域中每个像素的可信度。因此,对于像素可信度较低的滤波器,在学习时应加以限制。AutoTrack通过在空间正则化参数 $\hat{\mu}$ 中引入局部变化向量 $\Pi$ 来实现,其计算式为:

$$\mu = P^T \delta \log(\Pi + 1) + \hat{\mu}, \quad (3)$$

式中,  $P^T \in R^{T \times T}$  用于裁剪目标对象所在滤波器的中心部分。 $\delta$  是一个常数, 用于调整局部响应变化的权重,  $\mu$  继承自 STRCF 以减轻边界效应的影响。

自动时间正则化: 在 STRCF 中, 通过一个固定的参数  $\theta$  来调节滤波器在两帧之间的变化率。在此基础上, AutoTrack 利用全局响应变化量定义了变量  $\bar{\theta}$ , 计算式为:

$$\bar{\theta} = \frac{\zeta}{1 + \log(\nu \|\prod\|_2 + 1)}, \|\prod\|_2 \leq \varphi, \quad (4)$$

式中,  $\zeta$  和  $\nu$  表示超参数。当全局变化大于阈值  $\varphi$  时, 意味着响应图中存在偏差, 因此相关滤波器停止学习。如果它低于阈值, 响应图变化越剧烈, 参数  $\bar{\theta}$  就越小, 这样就可以放松对相关滤波器时间变化的限制, 并且可以在外观变化较大的情况下更快地学习。

因此, AutoTrack 的时空正则化目标函数可以写成:

$$\begin{aligned} \epsilon(H_t, \theta_t) = & \frac{1}{2} \|y - \sum_{k=1}^K x_t^k \times h_t^k\|_2^2 + \\ & \frac{1}{2} \sum_{k=1}^K \|\tilde{\mu} \cdot h_t^k\|_2^2 + \frac{\theta_t}{2} \sum_{k=1}^K \|h_t^k - \\ & h_{t-1}^k\|_2^2 + \frac{1}{2} \|\theta_t - \bar{\theta}\|_2^2, \end{aligned} \quad (5)$$

式中,  $\bar{\theta}$  和  $\theta_t$  分别表示优化的时间正则化参数, 而  $\tilde{\mu}$  表示通过式(3)计算得到的空间正则化参数。

通过最小化等式(5), 并利用交替方向乘数法(ADMM)可获得最优解, 具体求解过程可见文献[7]。

### 3 本文改进算法

和 STRCF 相比, AutoTrack 的主要改进之处在于在线动态计算空间正则化参数  $\tilde{\mu}$  及时间正则化参数  $\bar{\theta}$  和  $\theta_t$ 。而实际上 AutoTrack 在目标函数中引入的  $\|\theta_t - \bar{\theta}\|_2^2$  项虽然提升了跟踪的准确性, 但引入全局响应变化量等操作也显著增加了算法的执行时间, 因此本文对其目标函数进行了简化, 简化后的目标函数如下:

$$\begin{aligned} \epsilon(H_t, \theta_t) = & \frac{1}{2} \|y - \sum_{k=1}^K x_t^k \times h_t^k\|_2^2 + \\ & \frac{1}{2} \sum_{k=1}^K \|\tilde{\mu} \cdot h_t^k\|_2^2 + \frac{\theta_t}{2} \sum_{k=1}^K \|h_t^k - \\ & h_{t-1}^k\|_2^2. \end{aligned} \quad (6)$$

式(6)相当于在 STRCF 基础上引入了 AutoTrack 中的空间正则化参数  $\tilde{\mu}$ 。本文利用峰值旁瓣比设置式(3)中的局部响应变化权重因子  $\delta$ , 并动态更新式(6)中的时间正则化参数  $\theta$ , 另外在跟踪器中嵌入遮挡检测模块以提升跟踪器处理遮挡的能力。

#### 3.1 自适应时间权重因子设置

AutoTrack 算法利用全局响应变化向量来自适应设置时间正则化参数, 增加了算法运算时间, 本文对 AutoTrack 算法进行了优化, 引入峰值旁瓣比作为跟踪模型可靠性的度量因子, 在线动态计算并更新时间正则化参数。下面首先给出峰值旁瓣比的定义。

设第  $t$  帧的特征响应图为  $R_t$ , 则其峰值旁瓣比(PSR)定义为:

$$P_t = \frac{\max(R_t) - \mu_t}{\sigma_t}, \quad (7)$$

式中,  $\max$  为求最大值函数,  $\mu_t, \sigma_t$  分别为特征响应图的均值和方差。

峰值旁瓣比主要体现跟踪的可靠性。因此, 峰值旁瓣比和时间正则化参数成正比关系, 当峰值旁瓣比较大时, 说明目标定位的可靠性较高, 增大时间正则化参数可以加快模型学习速度。

本文通过下式计算得到时间正则化参数  $\theta$ :

$$\theta = 8 + \exp(P_t/11). \quad (8)$$

#### 3.2 自适应空间权重因子设置

AutoTrack 算法中计算空间正则化的参数  $\delta$  为常数, 而实际上当跟踪的可靠性较高时, 目标的空间变化范围相对较小。相应地, 当存在快速运动、空间位置变化较大时, 跟踪的可靠性较低。

因此, 本文同样利用峰值旁瓣比自适应地计算空间正则化系数  $\delta$ :

$$\delta = \alpha / \text{psr}(\text{frame}), \alpha = 5. \quad (9)$$

#### 3.3 遮挡处理

在无人机跟踪场景中不可避免会遇到目标被遮挡的问题, 如何进行遮挡检测与处理一直是无人机跟踪领域的一大难点。

在目标函数中引入时间正则化项可以一定程度上增强算法抵抗遮挡的能力, 但对于严重遮挡效果不佳。本文在此方面进行了改进, 通过将当前峰值旁瓣比与历史峰值旁瓣比极值及均值分别做比较, 设定满足式(10)条件即认为发生了遮挡, 停止对目标位置的更新, 但仍然利用时间正则化参数保持对跟踪模型的更新。

$$\begin{cases} P_{\text{frame}} < \lambda_1 \times \sum_{i=2}^{\text{frame}} P_i / (\text{frame} - 1) \\ P_{\text{frame}} < \lambda_2 \times \max(P_i), (i = 2, \dots, \text{frame}) \end{cases}. \quad (10)$$

### 4 实验结果与分析

#### 4.1 实验环境

为了全面评估所提算法的性能, 在 DTB70<sup>[9]</sup> 及 UAVDT<sup>[10]</sup> 及 UAV123\_10fps<sup>[11]</sup> 等 3 个无人机基准数据集上进行了实验, 并与 AutoTrack、STRCF、

ECO\_HC<sup>[12]</sup>、BACF<sup>[13]</sup>、Staple\_CA<sup>[14]</sup>、fDSST<sup>[15]</sup>、SAMF<sup>[16]</sup>等7个先进的跟踪器进行了比较。所做实验是在16 GB内存,Inter(R)Xeon(R)E3-1225处理器(3.3 GHz)、16 GB内存的PC上进行。

#### 4.2 DTB70 数据集实验分析

DTB70 是一个高多样性基准视频数据集,由70个难处理的无人机图像序列组成,主要解决无人机的纵向运动问题。此外,还包括各种大小和纵横比不同的杂乱场景和对象。

图1给出8种算法在DTB70的距离精度曲线图和成功率曲线图,可以得出本文算法在DTB70上的精度和成功率超过了所有基于CPU的跟踪器。

DTB70 数据集上实验结果,如表1所示。从表1数据可以得出,本文算法运行速度达到42.9 fps,在跟踪精度高于0.6的算法中,仅比ECO\_HC(51.1 fps)慢,但是与ECO\_HC相比,本文算法的平均精度提高了11.9%。此外,与基准算法AutoTrack相比,本文算法在精度和速度上分别有1.5%和74.4%的优势。与STRCF相比,本文算法在精度和速度上分别有16.5%和72.3%的优势。图2则给出8种算法在DTB70遮挡场景下的距离精度曲线图和成功率曲线图。本文算法具有最好的抗遮挡性能,相比于AutoTrack和STRCF,成功率分别提高了6.6%和5.0%,说明本文增加遮挡处理模块的有效性。




图1 8种算法在DTB70的距离精度曲线图和成功率曲线图

Fig. 1 Distance accuracy plot and success rate plot of eight algorithms in DTB70




图2 8种算法在DTB70遮挡场景下的距离精度曲线图和成功率曲线图

Fig. 2 Distance accuracy plot and success rate plot of eight algorithms in DTB70 occlusion scene

表 1 DIB70 数据集上实验结果  
Tab. 1 Experimental results on DIB70 dataset

| Tracker   | FPS   | Accuracy |
|-----------|-------|----------|
| Ours      | 42.9  | 0.726    |
| AutoTrack | 24.6  | 0.715    |
| ECO_HC    | 51.1  | 0.649    |
| STRCF     | 24.9  | 0.623    |
| BACF      | 37.0  | 0.581    |
| fDSST     | 111.5 | 0.534    |
| Staple_CA | 44.8  | 0.504    |
| SAMF      | 7.3   | 0.488    |

4.3 UAVDT 数据集实验分析

UAVDT 是 ICCV2018 提出的一个数据集,共包含 80 000 帧图片,主要用于测试天气状况、飞行高度和摄像机视角等发生变化时的车辆跟踪。8 种算法在 UAVDT 的距离精度曲线图和成功率曲线图如图 3 所示,本文算法同样具有最好的精度和成功率,可

以较好地满足无人机的轻量化运算和实时性的要求。

为了进一步分析本文所提出的跟踪算法在 UAVDT 数据集上的表现,将本文跟踪算法与其他 7 个先进的跟踪算法在 9 个属性上进行分类对比。在 UAVDT 数据集上多属性比较结果如表 2 所示,其中加粗为最佳结果。表 2 数据显示,本文算法在微小目标 (small object, SO)、尺度变化 (scale variation, SV)、目标移动 (object motion, OM)、目标模糊 (object blur, OB)、严重遮挡 (large occlusion, LO)、光照变化 (illumination variation, LV) 和摄像机移动 (camera motion, CM) 7 个属性上取得较高的性能,均排在第一位。在背景干扰 (background clutter, BC) 属性上性能也仅次于 ECO\_HC 算法,在长时跟踪 (long-term tracking, LTR) 属性上排在第 4 位。下一步将着重研究加入新的处理机制,增强算法处理长时跟踪的能力。




图 3 8 种算法在 UAVDT 的距离精度曲线图和成功率曲线图  
Fig. 3 Distance accuracy plot and success rate plot of eight algorithms in UAVDT

表 2 在 UAVDT 数据集上多属性比较结果  
Tab. 2 Multi attributes comparison results on UAVDT dataset

| Attributes | SO           | SV           | OM           | OB           | LO           | LV           | CM           | BC           | LTR          |
|------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|--------------|
| Ours       | <b>0.854</b> | <b>0.644</b> | <b>0.669</b> | <b>0.783</b> | <b>0.524</b> | <b>0.807</b> | <b>0.699</b> | 0.647        | 0.879        |
| AutoTrack  | 0.851        | 0.636        | 0.662        | 0.776        | 0.522        | 0.804        | 0.696        | 0.647        | 0.880        |
| STRCF      | 0.791        | 0.574        | 0.585        | 0.716        | 0.442        | 0.729        | 0.618        | 0.568        | 0.830        |
| ECO_HC     | 0.808        | 0.619        | 0.637        | 0.712        | 0.521        | 0.743        | 0.667        | <b>0.652</b> | 0.924        |
| BACF       | 0.815        | 0.604        | 0.635        | 0.743        | 0.487        | 0.775        | 0.648        | 0.633        | 0.886        |
| Staple_CA  | 0.839        | 0.621        | 0.649        | 0.756        | 0.493        | 0.805        | 0.688        | 0.623        | <b>0.945</b> |
| SAMF       | 0.666        | 0.451        | 0.470        | 0.649        | 0.353        | 0.669        | 0.577        | 0.493        | 0.694        |
| fDSST      | 0.833        | 0.552        | 0.583        | 0.703        | 0.483        | 0.743        | 0.683        | 0.592        | 0.863        |

#### 4.4 UAV123\_10fps 数据集实验分析

UAV123 是由低空无人机捕获视频组成的数据集,共包含 123 个视频序列。其跟踪对象包括人员、车辆、船只、飞行器等,主要涉及步行、驾驶、水上运动和飞行等活动。而 UAV123\_10 fps 是 Muller 等人从 UAV123 中创建的基于 10fps 的数据集,相比于 UAV123,UAV123\_10 fps 中的跟踪对象在连续帧之间的移动更大,带来了更多的挑战。

图 4 给出 8 种算法在 UAV123\_10 fps 的距离精度曲线图和成功率曲线图,本文算法的跟踪成功率略逊色于 AutoTrack,排在第二位,跟踪精度则优于其他 7 种算法。UAV123\_10 fps 数据集上实验结果如表 3 所示,且跟踪速度达到 44.8 fps,接近 AutoTrack 和 STRCF 的两倍。综合评估,本文算法性能最为优秀,更加适合应用于无人机领域。


表 3 UAV123\_10fps 数据集上实验结果

Tab.3 Experimental results on UAV123\_10fps


| Tracker   | FPS   | Accuracy |
|-----------|-------|----------|
| Ours      | 44.8  | 0.670    |
| AutoTrack | 25.5  | 0.668    |
| ECO_HC    | 56.6  | 0.627    |
| STRCF     | 25.7  | 0.622    |
| Staple_CA | 45.7  | 0.587    |
| BACF      | 41.8  | 0.572    |
| fDSST     | 127.1 | 0.516    |
| SAMF      | 8.6   | 0.471    |

#### 4.5 定性比较

为了直观展示可视化跟踪结果,图 5 给出了本文算法与 AutoTrack、STRCF、ECO\_HC、BACF 等 4 种算法在 3 个视频序列的跟踪结果比较,这 3 个视频依次为 DTB70 中的 BMX3\_1、ChasingDrones\_1 及



(a) Precision comparison



(b) Success rate comparison

图 4 8 种算法在 UAV123\_10fps 的距离精度曲线图和成功率曲线图

Fig.4 Distance accuracy curve and success rate curve of eight algorithms in UAV123\_10fps



(a) Frame 35,90,121



(b) Frame 100,165,182



图5 5种算法在3个视频序列的跟踪结果比较

Fig.5 Comparison of tracking results of five algorithms in three video sequence

UAV123\_10fps 中的 Car16\_2。定性分析如下:

1) BMX3\_1 视频序列中目标存在旋转、变形等运动。从第 90 帧和第 121 帧的截图可以看出其他 4 种算法的跟踪框都发生了漂移,只有本文算法能够正确跟踪。ChasingDrones\_1 视频序列中无人机跟踪镜头发生抖动且视角发生变化,第 165 帧时只有本文算法和 AutoTrack 能正常跟踪,而第 182 帧时只有本文算法能准确定位目标并进行跟踪。

2) UAV123\_10fps 中的 Car16\_2 视频序列存在跟踪视角变化和目標尺度变化等。在第 404 帧汽车转弯时有 3 种算法出现漂移和丢失跟踪目标,第 440 帧时只有本文算法、AutoTrack、ECO\_HC 算法能定位到目标,而本文算法跟踪镜头最为准确。

## 5 结 论

本文基于 AutoTrack 和 STRCF 算法,提出了一种适用于高性能无人机跟踪的自适应时空正则化算法。利用峰值旁瓣比和局部响应变化向量动态更新时空正则化参数,并设定条件判断目标遮挡情况,提升了跟踪器处理各种复杂场景的能力。在 DTB70、UAVDT 及 UAV123\_10fps 数据集上评估本文算法的性能,相对于 AutoTrack、STRCF 等算法均有了一定幅度的提高,综合性能超过目前已有的相关滤波类算法。将来的工作在于进一步优化跟踪模型,提升算法性能,促进视觉跟踪技术的发展及其在无人机中的应用。

## 参考文献:

- [1] MENG L, YANG X. A survey of object tracking algorithms [J]. Acta Automatica Sinica, 2019, 45(7): 1244-1260.  
孟磊, 杨旭. 目标跟踪算法综述[J]. 自动化学报, 2019,

45(7): 1244-1260.

- [2] SHEN S Y, LI Z X, SUN W. Research on target tracking of UAV based on improved Camshift algorithm[J]. Micro Electronics & Computer, 2019, 36(11): 76-83.  
沈思源, 李震霄, 孙伟. 基于改进 Camshift 的无人机目标跟踪算法研究[J]. 微电子学与计算机, 2019, 36(11): 76-83.
- [3] DONG M B, YANG H W, GUO W, et al. UAV visual tracking via multi-cue fusion correlation filter with re-detection [J]. Journal of Graphics, 2019, 40(6): 1079-1086.  
董美宝, 杨涵文, 郭文, 等. 多特征重检测的相关滤波无人机视觉跟踪[J]. 图学报, 2019, 40(6): 1079-1086.
- [4] WU G S, LIN S B, YANG W Y. Sub-peak suppression of multi-feature fusion in UAV object tracking[J]. Computer Engineering and Applications, 2020, 56(14): 104-110.  
吴贵山, 林淑彬, 杨文元. 多特征融合的次峰抑制无人机目标跟踪[J]. 计算机工程与应用, 2020, 56(14): 104-110.
- [5] LI F, TIAN C, ZUO W, et al. Learning spatial-temporal regularized correlation filters for visual tracking [C]// IEEE Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE, 2018: 4904-4913.
- [6] ZHU J Z, WANG D, LU H C. Learning temporal-spatial consistency correlation filter for visual tracking[J]. Sci Sin Inform, 2020, 50(1): 128-150.  
朱建章, 王栋, 卢湖川. 学习时空一致性相关滤波的视觉跟踪[J]. 中国科学: 信息科学, 2020, 50(1): 128-150.
- [7] 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]// IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 13-19, 2020, Seattle, WA, USA. New York: IEEE, 2020: 11923-11932.

- [8] DANELIJAN M, HAGER G, KHAN F S, et al. Learning spatially regularized correlation filters for visual tracking [C]//IEEE International Conference on Computer Vision, December 7-13, 2015, Santiago, Chile. New York: IEEE, 2015: 4310-4318.
- [9] LI S Y, YEUNG D Y. Visual object tracking for unmanned aerial vehicles: a benchmark and new motion models [C]//AAAI Conference on Artificial Intelligence, February 4-9, 2017, San Francisco, CA, USA. Menlo Park: AAAI, 2017: 4140-4146.
- [10] DU D W, QI Y K, YU H Y, et al. The unmanned aerial vehicle benchmark: object detection and tracking[EB/OL]. (2018-03-26) [2021-06-03]. <https://arxiv.org/abs/1804.00518v1>.
- [11] MUELLER M, SMITH N, GHANEM B. A benchmark and simulator for UAV tracking[C]//The 14th European Conference on Computer Vision, October 8-16, 2016, Amsterdam, Netherlands. Berlin: Springer, 2016: 445-461.
- [12] DANELLJAN M, BHAT G, KHAN F S, et al. ECO: Efficient convolution operators for tracking[C]//IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017: 6931-6939.
- [13] GALOOGAHI H K, FAGG A, LUCEY S. Learning background aware correlation filters for visual tracking[C]//IEEE International Conference on Computer Vision, October 22-29, 2017, Venice, Italy. New York: IEEE, 2017: 1144-1152.
- [14] MUELLER M, SMITH N, GHANEM B. Context-aware correlation filter tracking[C]//IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017: 1387-1395.
- [15] DANELLJAN M, BHAT G, KHAN F S, et al. Discriminative scale space tracking[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39 (8): 1561-1575.
- [16] LI Y, ZHU J K. A scale adaptive kernel correlation filter tracker with feature integration[C]//13th European Conference on Computer Vision, September 6-12, 2014, Zurich, Switzerland. Berlin: Springer, 2014: 254-26.

#### 作者简介:

吴捷 (1982—),男,硕士,副教授,主要从事计算机视觉方面的研究。