

# 基于注意力学习的正则化相关 滤波跟踪算法

仇祝令<sup>1</sup>, 查宇飞<sup>1,2</sup>, 吴敏<sup>3</sup>, 王青<sup>3</sup>

(1. 中国人民解放军空军工程大学航空工程学院, 陕西西安 710038;  
2. 西北工业大学计算机学院, 陕西西安 710072; 3. 95894 部队, 北京 102211)

**摘要:** 边界效应是制约相关滤波跟踪性能的一个重要因素. 目前大多数方法只是简单地采用先验知识, 如逆高斯分布, 预设掩模等, 或者分割前景目标作为正则化项, 进行约束求解, 并没有考虑目标的空时域特性. 针对这一问题, 本文提出一种基于注意力学习的正则化相关滤波跟踪算法. 该方法考虑目标在空间中的分布特性, 利用注意力机制学习目标的特定空间权重, 适应目标在空域中的变化; 同时利用目标在时域中的连续性, 通过对注意力权重矩阵的约束来间接调整滤波器; 最后通过交替方向乘子 (ADMM) 算法迭代优化模型. 我们在标准的数据集上进行大量实验, 结果表明本文算法能实时跟踪目标, 并且在精确度和成功率上都有了一定的提升.

**关键词:** 单目标; 视觉跟踪; 机器学习; 正则化; 相关滤波; 注意力学习

**中图分类号:** TN919.82      **文献标识码:** A      **文章编号:** 0372-2112 (2020)09-1762-07

**电子学报 URL:** <http://www.ejournal.org.cn>

**DOI:** 10.3969/j.issn.0372-2112.2020.09.014

## Learning Attentional Regularized Correlation Filter for Visual Tracking

QIU Zhu-ling<sup>1</sup>, ZHA Yu-fei<sup>1,2</sup>, WU Min<sup>3</sup>, WANG Qing<sup>3</sup>

(1. Aeronautics Engineering College, Air Force Engineering University, Xi'an, Shaanxi 710038, China;  
2. School of Computer Science, Northwestern Polytechnical University, Xi'an, Shaanxi 710072, China;  
3. Unit 95972 of the PLA, Beijing 102211, China)

**Abstract:** Boundary effect is an important factor which restricts the performance of correlation filter. At present, most methods simply use the prior knowledge, such as inverse Gaussian distribution, preset masks, etc., or segment the foreground target to constrain solving as the regularization term, which do not consider characteristics of the target in the spatial and temporal domain. To address this problem, this paper proposes a learning attention regularized correlation filter for visual tracking. The method uses the attention mechanism to learn the specific spatial weight of the target, which can adapt to the variations of target in the spatial domain by considering the spatial distribution characteristics of the target. At the same time, this paper uses the continuity of the target in the temporal domain. The filter is indirectly adjusted by constraining the attention weight matrix. Finally, the alternating direction method of multipliers (ADMM) is employed to iteratively optimize the model. We conduct extensive experiments on the proposed method in the standard tracking database. The results show that the proposed algorithm can track the target in real time, and has a certain improvement in precision and success rate.

**Key words:** single target; visual tracking; machine learning; regularization; correlation filter; attention mechanism

### 1 引言

视觉跟踪是依据初始帧中给定的目标, 在后续帧中连续稳定的跟踪该目标<sup>[1]</sup>. 在过去的二三十年中, 视

觉跟踪算法一直是学术界关注的一个议题, 同时也取得长足的进步. 但在实际中光照变化、复杂背景、相机抖动、模糊、遮挡等情况限制了跟踪算法的应用范围, 特别是随着时间变化, 目标在空间也会呈现出不同的外观

收稿日期: 2019-12-26; 修回日期: 2020-01-26; 责任编辑: 覃怀银

基金项目: 国家自然科学基金 (No. 61472442, No. 61773397, No. 61701524); 航空科学基金 (No. 2020-HT-XG); 中央高校基本科研业务费专项资金资助 (No. 3102019ZY1003, No. 3102019ZY1004)

变化,这对跟踪算法提出了巨大的挑战<sup>[2]</sup>.

近年来,判别式相关滤波器<sup>[3]</sup>(Discriminative Correlation Filter, DCF)已经在主流跟踪数据库(Object Tracking Benchmark, OTB)<sup>[4]</sup>和竞赛(Visual Object Tracking, VOT)<sup>[5]</sup>中显示了其作为跟踪框架的优越性,但是由于循环移位而产生的边界效应限制了跟踪性能的进一步提升. 因此,如图 1(a)和(b)所示, Danneljan 等人<sup>[6]</sup>和 Galoogahi<sup>[7]</sup>等人分别从目标空间分布的先验知识入手,构建固定掩模来降低滤波器在边界附近的值,达到抑制背景的目的. 最近,一些工作(图 1(c))利用图像分割<sup>[8]</sup>、显著性检测<sup>[8]</sup>等方法来构建包含目标不规则形状的掩模,期望获得更为准确的滤波器. 这些方法忽略目标在空域中的变化情况,导致滤波器不能随着目标变化准确学习特定的特征.

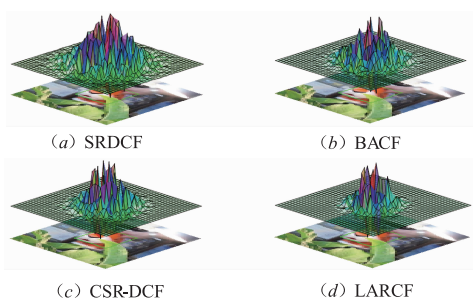


图1 不同方法的空间正则化对比图

与传统的基于空间正则化的跟踪方法不同,如图 1(d)所示,我们希望滤波器可以在复杂的环境中更多关注目标本身鲁棒性特征. 因此,本文将视觉注意力机制与相关滤波器结合,引入注意力权重矩阵,提出了一种基于注意力学习的正则化相关滤波(Learning Attentional Regularized Correlation Filter, LARCF)跟踪方法. 该方法不再将掩模看作独立超参,而是将其看作滤波器的注意力权重,并当作变量嵌入优化模型中,与滤波器同步进行联合求解,约束滤波器可以根据目标变化自适应在空域中进行特征选择.

## 2 基于注意力学习的正则化相关滤波

### 2.1 问题提出

判别式相关滤波器<sup>[3]</sup>本质上是一种岭回归,旨在从一系列的训练样本中学习一个多通道卷积滤波器. 由于采用循环移位的方式构建样本必然会产生虚假的轮廓,导致训练得到的滤波器判别力不足,从而限制了跟踪性能的提升.

为了解决这个问题,SRDCF<sup>[6]</sup>采用逆高斯分布矩阵作为空间正则化项,约束滤波器在目标边界之外的附加值. 利用空间正则化的方法来训练滤波器,其损失函数为:

$$L(\Phi) = \sum_{k=1}^T \varepsilon_k \left\| \sum_{l=1}^D \Phi_l * x_{kl} - y_k \right\|^2 + \sum_{l=1}^D \|\mathbf{w} \odot \Phi_l\|^2 \quad (1)$$

其中  $\Phi \in \mathbb{R}^D$  表示滤波器,  $*$  表示相关卷积运算,  $\odot$  表示点乘操作,  $x_{kl}$  是第  $k$  个样本的第  $l$  层特征值,  $D$  是通道数,  $y_k$  是样本回归值,  $T$  是样本数量,  $\varepsilon_k$  是每个样本影响权重,  $\mathbf{w}$  是空间正则化矩阵,预先定义为逆高斯分布.

本质上来说,SRDCF<sup>[6]</sup>利用了目标在边界矩形框中的先验分布,约束滤波器在边界上的值,达到抑制背景的目的. 后续算法,如 CSR-DCF<sup>[8]</sup>等,期望通过分割前景获得更为准确的掩模,约束滤波器的学习. 这些方法本质上都是通过先验分布,或者是通过其它方法,将目标和背景进行分离获得掩模  $\mathbf{w}$ ,进而约束滤波器的求解,但是他们获取  $\mathbf{w}$  的方式与跟踪算法本身是独立的,在模型求解过程中,  $\mathbf{w}$  始终作为超参,没有根据滤波器的更新进行同步调整,导致学到的滤波器并不是当前目标的最优解. 事实上,  $\mathbf{w}$  也是一个时变量,目标变化时也会导致其剧烈变化. 根据目标在空间位置上的重要性,分别赋予不同的权值:数值越大表示滤波器应给予相应空间位置更大的约束,根据每一帧图像中目标的变化来学习更新注意力权重,从而在空域上实现自适应约束滤波器的学习. 同时注意力权重矩阵在时域上具有连续性,通过约束注意力权重的变化可以间接调整滤波器的变化,避免滤波器出现剧变,消除边界效应的影响.

### 2.2 基于注意力学习的联合模型

为了能够更加准确地表示滤波器的掩模参数,本文在 DCF 模型<sup>[3]</sup>中引入注意力权重参量,构建空间正则化相关滤波器的联合模型,同时学习注意力权重矩阵和滤波器,使得学到的滤波器更加关注目标本身,降低背景对目标的干扰. 所提出模型的损失函数可以写为:

$$L(\Phi, \mathbf{w}) = \frac{1}{2} \left\| \sum_{l=1}^D \Phi_l * x_l - y \right\|^2 + \frac{1}{2} \sum_{l=1}^D \|\mathbf{w} \odot \Phi_l\|^2 + \frac{\mu}{2} \|\mathbf{w} - \mathbf{w}_0\|^2 \quad (2)$$

其中,  $\mu$  是时间正则化系数,  $\mathbf{w}$  是注意力正则化矩阵.  $\mathbf{w}$  不再是固定的超参,而是一个需要学习的注意力权重矩阵变量.  $\mathbf{w}_0$  是先验分布,本文选用逆高斯分布作为先验分布,使滤波器能够在首帧信息中快速关注目标.

图 2 是本文跟踪方法的流程图,利用跟踪过程中的每一帧视频信息  $I_l$  (图 2 左侧部分所示)来更新滤波器  $\Phi$  和注意力权重矩阵  $\mathbf{w}$ . 首先利用第一帧的先验信息  $I_0$  来初始化滤波器和注意力权重矩阵  $\mathbf{w}_0$ ,其中  $\mathbf{w}_0$  赋予逆高斯分布. 在跟踪过程中的模型更新如图 2 中间部分所示,提取以当前帧目标位置为中心的训练区域  $g$ ,利用注意力掩模  $\mathbf{w}$  来约束滤波器  $\Phi$  的学习,同时根据所学习的滤波器  $\Phi$  与目标的先验分布  $\mathbf{w}_0$  来更新  $\mathbf{w}$ . 最后,将训练

得到滤波器与下一帧中的搜索区域进行卷积,如图 2 右侧部分所示得到响应值的最大值即为目标的位置估计。

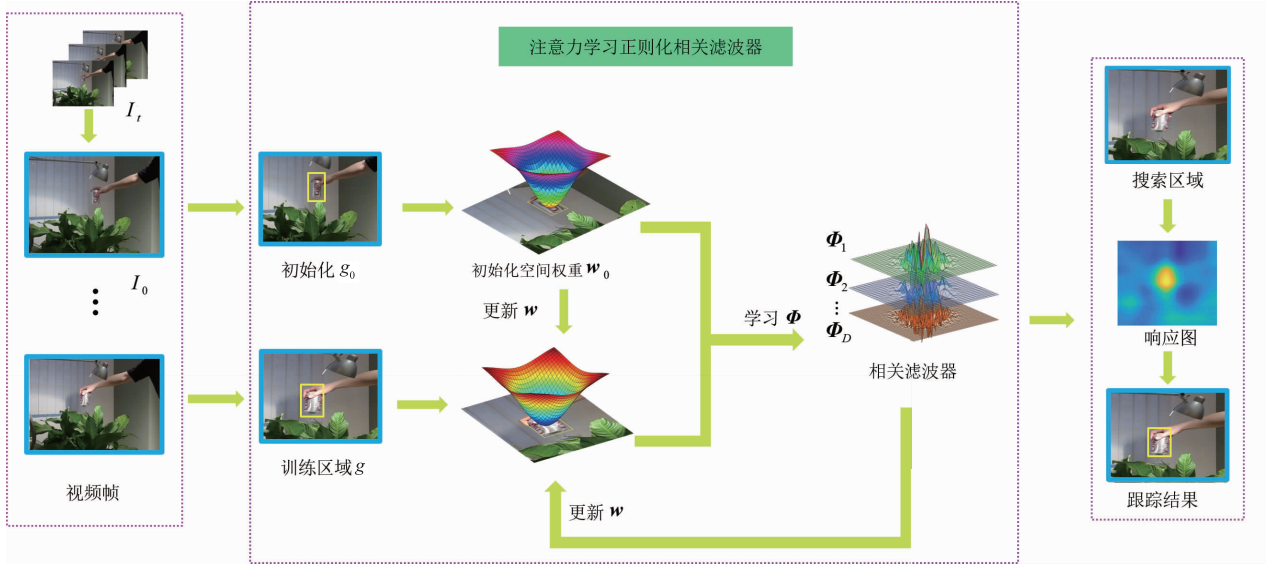


图2 基于注意力学习正则化跟踪器的流程图

### 2.3 联合优化

由于目标的损失函数式(2)不存在闭式解,所以根据其凸函数的特性,我们采用迭代交替方向乘子(ADMM)算法<sup>[9]</sup>来求解最优解.因此,引入约束条件 $\Phi = \theta$ ,式(2)的拉格朗日方程可以表示为:

$$L(\Phi, \theta, w) = \frac{1}{2} \left\| \sum_{t=1}^D \Phi_t * x_t - y \right\|^2 + \frac{1}{2} \sum_{t=1}^D \|w \odot \theta_t\|^2 + \frac{\mu}{2} \|w - w_0\|^2 + \sum_{t=1}^D \beta_t^T (\Phi_t - \theta_t) + \frac{\alpha}{2} \sum_{t=1}^D \|\Phi_t - \theta_t\|^2 \quad (3)$$

其中,  $\beta$  拉格朗日数乘因子,  $\alpha$  是惩罚参数.

当  $\delta = \beta/\alpha$  时, 增广拉格朗日方程(3) 可以写成:

$$L(\Phi, w, \theta, \delta) = \frac{1}{2} \left\| \sum_{t=1}^D \Phi_t * x_t - y \right\|^2 + \frac{1}{2} \sum_{t=1}^D \|w \odot \theta_t\|^2 + \frac{\mu}{2} \|w - w_0\|^2 + \frac{\alpha}{2} \sum_{t=1}^D \|\Phi_t - \theta_t + \delta_t\|^2 \quad (4)$$

ADMM 算法<sup>[9]</sup>用于解决拆分后的子问题:

$$\begin{cases} \Phi^{(i+1)} = \arg \min_{\Phi} \left\| \sum_{t=1}^D \Phi_t * x_t - y \right\|^2 + \alpha \|\Phi - \theta + \delta\|^2 \\ \theta^{(i+1)} = \arg \min_{\theta} \sum_{t=1}^D \|w \odot \theta_t\|^2 + \alpha \|\Phi - \theta + \delta\|^2 \\ \delta^{(i+1)} = \delta^{(i)} + \Phi^{(i+1)} - \theta^{(i+1)} \end{cases} \quad (5)$$

(1) 子问题  $\Phi$ :

根据 ADMM 算法<sup>[9]</sup>的迭代方程,子问题  $\Phi$  的解可以转换为频域中求解:

$$L(\hat{\Phi}) = \left\| \sum_{t=1}^D \hat{\Phi}_t \odot \hat{x}_t - \hat{y} \right\|^2 + \alpha \|\hat{\Phi} - \hat{\theta} + \hat{\delta}\|^2 \quad (6)$$

其中  $\hat{\Phi}$  是滤波器  $\Phi$  的离散傅里叶变换. 从式(6)中我们可以发现标签  $\hat{y}$  的第  $j$  个元素值是由滤波器  $\hat{\Phi}$  和样本  $\hat{x}$  在所有通道中的第  $j$  个值的决定. 因此,我们令  $G_j(\cdot) \in \mathbb{R}^D$  表示在  $D$  个通道中第  $j$  个元素值,式(6)可以改写为:

$$L(G_j(\hat{\Phi})) = \|G_j(\hat{x})^T G_j(\hat{\Phi}) - \hat{y}_j\|^2 + \alpha \|G_j(\hat{\Phi}) - G_j(\hat{\theta}) + G_j(\hat{\delta})\|^2 \quad (7)$$

因此得到  $G_j(\hat{\Phi})$  的闭式解:

$$G_j(\hat{\Phi}) = \frac{\alpha G_j(\hat{\theta}) - \alpha G_j(\hat{\delta}) + \hat{y}_j G_j(\hat{x})}{G_j(\hat{x}) G_j(\hat{x})^T + \alpha I} \quad (8)$$

(2) 子问题  $\theta$ :

对于子问题  $\theta$  的解,可以直接在时域中得到  $\theta$  封闭解:

$$\theta = \frac{\alpha \Phi + \alpha \delta}{w \odot w + \alpha I} \quad (9)$$

(3) 子问题  $w$ :

为了在时域上更新空间权重  $w$ ,我们可以利用式(4)直接得到  $w$  的导数:

$$\frac{\partial L(\Phi, \theta, \delta)}{\partial w} = \theta \odot \theta \odot w + \mu(w - w_0) \quad (10)$$

通过对  $\frac{\partial L(\Phi, \theta, \delta)}{\partial w} = 0$  求解,可以得到  $w$  的封闭解:

$$w = \frac{\mu w_0}{\theta \odot \theta + \mu I} \quad (11)$$

通过上述公式,我们可以更新包含当前帧目标信息的  $w$ .

(4)更新惩罚参数  $\alpha$ .步长参数可更新为:

$$\alpha^{(i+1)} = \min(\alpha_{\max}, \rho\alpha^{(i)}) \quad (12)$$

其中  $\alpha_{\max}$  是  $\alpha$  的最大值,  $\rho$  是尺度参数.

### 3 实验分析与讨论

在本节中,我们在标准的视觉跟踪基准数据集 OTB100<sup>[4]</sup>上,对提出的算法进行了大量的实验评估.接下来,我们将描述实现细节和评估准则,并通过与目前最先进的跟踪方法对比,对所提算法进行实验评估.

#### 3.1 实现细节

本文所提出的算法是基于正则化的相关滤波器,为保证跟踪速度跟踪器采用 HOG 与 CN 结合的手工特征,通过多次实验增广拉格朗日优化参数设置为  $\mu = 18$ . 初始约束参数  $\alpha$ , 最大约束参数  $\alpha_{\max}$  和比例因子  $\rho$  分别设为 10, 100 和 1.2.

本文使用平均中心位置误差和平均重合率度量方法评价在一个视频上的跟踪效果,根据成功率曲线评价算法在所有视频上的整体效果.成功率曲线定义为将重合率大于给定阈值的视频帧做为成功跟踪的帧,当阈值从 0 变化到 1 时,记录成功跟踪的帧数占视频总帧数的比率,得到成功率曲线,使用成功率曲线下的面积(Area Under Curve, AUC)作为目标跟踪算法在所有视频上整体跟踪效果的度量.精确度(Precision, DP)曲线是根据跟踪轨迹的中心位置与人工标记的基准结果中心位置的欧式距离,并根据达到设定阈

值的帧数与总帧数的比率得出曲线图,并以阈值为 20 时的比率作为精确度的排序标准.根据基准库的设定,本文使用一次通过评估(One Pass Evaluation, OPE)策略(每个跟踪器在初始帧中用地面实况框进行评估,直到每个序列结束)与其他当前先进的跟踪器进行比较.

在标准目标跟踪数据集 OTB100<sup>[4]</sup>上,我们将提出的跟踪器与最先进的跟踪器进行比较,这些跟踪器可以分类如下:(1)基于正则化的跟踪器:包括 SRDCF<sup>[6]</sup>, BACF<sup>[7]</sup>, CSR-DCF<sup>[8]</sup>, STRCF<sup>[10]</sup>; (2)基于神经网络的跟踪器:包括 DAT<sup>[11]</sup>, ACFN<sup>[12]</sup>; (3)经典的先进跟踪器:包括 SiamFC<sup>[13]</sup>, DSST<sup>[14]</sup>, ECO<sup>[15]</sup>.

#### 3.2 定量分析

在图 3 中显示本文所提出的算法与其他运用不同方法跟踪算法的成功率曲线面积(AUC)和精确度(DP)得分.在 AUC 和 DP 上,我们的方法分别取得了 66.6% 和 87.0% 的成绩,在两种评价指标下分别获得了第二名的好成绩,而且跟踪速度可以达到 27FPS(超过 25FPS).尽管在性能上稍落后于排名第一的 DAT<sup>[11]</sup> 算法,但我们的方法在速度上明显优于 DAT<sup>[11]</sup> 算法.同时与基准算法 SRDCF<sup>[10]</sup> 相比在性能上有了大幅提升,其中成功率提升了 6.6%,精确度提高了 7.8%.总体上,本文所提出的算法在 OTB100 数据集中各项性能都能排在前列,优于目前大多数先进的算法,这表明根据目标在空域和时域中的变化特性,引入注意力权重矩阵,与滤波器联合建模进行迭代更新可以使滤波器始终关注目标本身,实现准确跟踪.

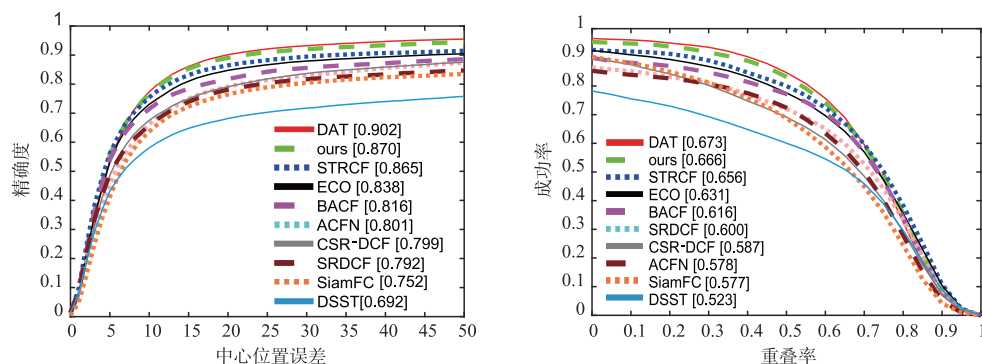


图3 OTB100序列中成功率与精确率曲线图

#### 3.3 消融分析

本文在空域与时域中,直接学习注意力权重,与滤波器联合建模,期望获得最优解.为了证明时域和空域正则化对于算法性能的提高,我们将分析空域正则化和时域正则化对最终性能的影响.

时间正则化利用目标在时域上具有连续性的特性,能够有效解决目标被遮挡的问题.我们将去掉时间正则化,使用固定掩模的算法用 LARCF<sub>q</sub> 表示,我们将去掉注

意力学习的算法用 LARCF<sub>p</sub> 表示,结果如表 1 所示,从中可以明显看出,只考虑目标在空域中的分布情况的 LARCF<sub>q</sub> 在成功率与精确度上分别下降 6.9% 和 4.1%,其速度性能可以达到 32FPS,而 LARCF<sub>q</sub> 目标在空域与时域的变化都不考虑,跟踪速度可以达到 58FPS,但其性能分别下降了 17.6% 和 17.8%.结果表明注意力权重矩阵的引入使滤波器在时域与空域可以充分适应目标的变化,具有更强的鲁棒性,尽管带来一定的计算损耗,但其

跟踪速度达到 27FPS,仍可以实现实时跟踪.

表 1 结果对比

Trackers	AUC (%)	DP (%)	Speed(FPS)
LARCF <sub>p</sub>	49.0	69.2	<b>58</b>
LARCF <sub>q</sub>	62.5	80.1	32
Ours	<b>66.6</b>	<b>87.0</b>	27

### 3.4 属性分析

我们使用 OTB100 数据集集中的 11 个注释属性分析跟踪器性能:光照变化(38)、平面外旋转(63)、尺度变化(64)、遮挡(49)、变形(44)、运动模糊(29)、快速运动(39)、平面内旋转(51)、视野外(14)和低分辨率(9)(每个属性的视频数量附加到每个难度




图4 不同属性下的成功率曲线

属性的末尾). 图 4 显示了在这些挑战性属性上的成功率比较分析结果. 在图 4 中, 本文所提出的跟踪器表现出优异的性能, 尤其是在背景杂波与遮挡环境下, 我们所提出的算法与基准算法 SRDCF 相比有了明显提升, 而其他采用正则化的算法由于滤波器约束权重系数固定导致跟踪器产生目标和背景分辨不清, 掩模分配不均匀, 识别性差的问题, 致使跟踪的整体效果不佳.

### 3.5 定性评估

图 5 显示了本文提出的算法与其他五种算法的定性比较 (包括 SRDCF<sup>[6]</sup>, STRCF<sup>[10]</sup>, BACF<sup>[7]</sup>, SiamFC<sup>[13]</sup>, DAT<sup>[11]</sup>). 在典型的视频序列尤其是在复杂背景与遮挡条件下, 进行各个算法的比较分析.



图5 不同算法在视频中的跟踪结果

## 4 结论

在本文中, 我们提出一种基于注意力学习的正则化相关滤波跟踪算法, 注意力权重与滤波器联合建模, 在空域中约束滤波器, 增强滤波器对目标的判别能力; 同时在时域利用目标在跟踪过程中变化的连续性, 通过对注意力权重矩阵的约束来间接控制滤波器的变化, 当有遮挡情况出现时使其变化趋于平缓, 保证滤波器在跟踪过程关注目标鲁棒特征, 抑制背景信息. 通过 ADMM 算法进行迭代求解, 减少计算的复杂度. 实验结果表明, 注意力权重矩阵的引入可以有效提升滤波器的性能, 实现鲁棒跟踪.

从图 5 中可以看出, 在 blot 和 girl 视频中存在大量的相似目标干扰, 随着目标周围相似目标的增多, SRDCF, BACF 以及 SiamFC 开始出现跟踪漂移, 甚至丢失目标的情况. 我们的方法由于考虑目标在空域的变化情况, 可以有效增强滤波器对目标的判别能力, 实现鲁棒跟踪. bird 和 box 视频序列的主要难度是存在遮挡问题, 尤其是在 bird 中从第 128 帧开始存在云层的遮挡, 在第 259 帧中目标又重新出现, 此时只有我们的方法和 DAT<sup>[11]</sup>可以准确跟踪. 这表明在时域中利用目标的相干性, 依据目标在每一帧中的连续变化, 使滤波器关注目标鲁棒的特征而平滑变化, 当有遮挡出现时仍能准确区分目标.

## 参考文献

- [1] 孙航, 李晶, 杜博, 等. 基于多阶段学习的相关滤波目标跟踪[J]. 电子学报, 2017, 45(10): 2337-2342.  
Sun Hang, Li Jing, Du Bo, et al. Correlation filter target tracking based on multi-stage learning[J]. Acta Electronica Sinica, 2017, 45(10): 2337-2342. (in Chinese)
- [2] 范舜奕, 管桦, 侯志强, 等. 基于多表观特征子模型更新的鲁棒视觉跟踪[J]. 电子学报, 2018, 46(02): 440-446.  
Fan Shun-yi, Guan Hua, Hou Zhi-qiang, et al. Robust visual tracking based on multi-epitopic characterization sub-model

- updating[J]. Acta Electronica Sinica, 2018, 46(02): 440 – 446. (in Chinese)
- [3] 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, 2014, 37(3): 583 – 596.
- [4] Wu Y, Lim J, Yang M H. Object tracking benchmark[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1834 – 1848.
- [5] Kristan M, Leonardis A, Matas J, et al. The visual object tracking vot2017 challenge results[A]. Proceedings of the International Conference on Computer Vision[C]. Venice: IEEE, 2017. 1949 – 1972.
- [6] Danelljan M, Hager G, Khan F S, et al. Learning spatially regularized correlation filters for visual tracking[A]. Proceedings of the International Conference on Computer Vision[C]. Santiago: IEEE, 2015. 4310 – 4318.
- [7] Kiani Galoogahi H, Fagg A, Lucey S. Learning background-aware correlation filters for visual tracking[A]. Proceedings of the International Conference on Computer Vision[C]. Venice: IEEE, 2017. 1135 – 1143.
- [8] Lukezic A, Vojir T, Cehovin Zajc L, et al. Discriminative correlation filter with channel and spatial reliability[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition[C]. Honolulu, HI: IEEE, 2017. 6309 – 6318.
- [9] Ghadimi E, Teixeira A, Shames I, et al. Optimal parameter selection for the alternating direction method of multipliers (ADMM): quadratic problems[J]. IEEE Transactions on Automatic Control, 2014, 60(3): 644 – 658.
- [10] Li F, Tian C, Zuo W, et al. Learning spatial-temporal regularized correlation filters for visual tracking[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition[C]. Las Vegas: IEEE, 2018. 4904 – 4913.
- [11] Pu S, Song Y, Ma C, et al. Deep attentive tracking via reciprocal learning[A]. Advances in Neural Information Processing Systems[C]. Montréal: Curran Associates Inc, 2018. 1931 – 1941.
- [12] Choi J, Jin Chang H, Yun S, et al. Attentional correlation filter network for adaptive visual tracking[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition[C]. Honolulu, HI: IEEE, 2017. 4807 – 4816.
- [13] Bertinetto L, Valmadre J, Henriques J F, et al. Fully-convolutional siamese networks for object tracking[A]. Proceedings of the European Conference on Computer Vision[C]. Amsterdam: Springer, Cham, 2016. 850 – 865.
- [14] Danelljan M, Häger G, Khan F S, et al. Discriminative scale space tracking[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(8): 1561 – 1575.
- [15] Danelljan M, Bhat G, Shahbaz Khan F, et al. Eco: Efficient convolution operators for tracking[A]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition[C]. Honolulu, HI: IEEE, 2017. 6638 – 6646.

#### 作者简介



仇祝令 男, 1995 年出生, 山东人. 空军工程大学在读硕士研究生, 主要研究方向: 目标跟踪、机器学习以及计算机视觉.



查宇飞(通信作者) 男, 1979 年出生, 湖北人. 西北工业大学副教授, 硕士生导师, 主要从事机器学习、计算机视觉、目标跟踪、目标检测及人工智能等方面的研究.  
E-mail: kgdqzl@ 163. com