



DOI: 10.12086/oe.2021.200068

## 基于自适应空间正则化和畸变抑制的相关滤波跟踪

王叶, 刘强, 卿琳波\*, 滕奇志, 何小海

四川大学电子信息学院, 四川 成都 610065



**摘要:** 针对背景感知相关滤波器的空间正则化权重固定, 不适应目标变化和增大搜索区域, 易引入背景噪声导致滤波器判别力下降等问题, 本文提出一种基于自适应空间正则化和畸变抑制的相关滤波跟踪算法。首先提取 FHOG 特征、CN 特征和灰度特征以增强算法模型对目标的表达能力; 其次, 在目标函数中加入畸变抑制项来约束当前帧的响应图, 增强滤波器的判别能力, 以缓解滤波器模型退化问题; 最后, 在目标函数中加入自适应空间正则化项使空间正则化权重能够随着目标的变化而更新, 使得滤波器能充分利用目标的多样性信息。本文在公开数据集 OTB-2013、OTB-2015 和 VOT2016 上进行实验, 以对所提算法进行评估。实验结果表明: 本文算法速度为 20 f/s, 距离精度和成功率等评估指标均优于对比算法, 在遮挡、背景干扰、旋转变化等多种复杂场景下都有良好的鲁棒性。

**关键词:** 目标跟踪; 相关滤波; 畸变抑制; 自适应空间正则化

**中图分类号:** TP391.41

**文献标志码:** A

王叶, 刘强, 卿琳波, 等. 基于自适应空间正则化和畸变抑制的相关滤波跟踪[J]. 光电工程, 2021, 48(1): 200068

Wang Y, Liu Q, Qin L B, et al. Learning adaptive spatial regularization and aberrance repression correlation filters for visual tracking[J]. *Opto-Electron Eng*, 2021, 48(1): 200068

## Learning adaptive spatial regularization and aberrance repression correlation filters for visual tracking

Wang Ye, Liu Qiang, Qin Linbo\*, Teng Qizhi, He Xiaohai

School of Electronics and Information Engineering, Sichuan University, Chengdu, Sichuan 610065, China

**Abstract:** This paper proposes a correlation filter tracking algorithm based on adaptive spatial regularization and aberrance repression aiming at the problem that the spatial regularization weight of the background-aware correlation filter is fixed and does not adapt to the change of the target, and the problem that enlarging search area may introduce background noise, decreasing the discrimination ability of filters. First, FHOG features, CN features, and gray features are extracted to enhance the algorithm's ability to express the target. Second, aberrance repression terms are added to the target function to constrain the response map of the current frame, and to enhance the filter's discrimination ability to alleviate the filter model degradation. Finally, adaptive spatial regularization terms are added to the objective function to make the spatial regularization weights being updated as the objective changes, so that

收稿日期: 2020-03-02; 收到修改稿日期: 2020-06-28

基金项目: 国家自然科学基金资助项目(61871278); 四川省科技厅国际科技合作与交流研发项目(2018HH0143); 成都市产业集群协同创新项目(2016-XT00-00015-GX)

作者简介: 王叶(1994-), 男, 硕士研究生, 主要从事人工智能与目标跟踪的研究。E-mail: 1553394611@qq.com

通信作者: 卿琳波(1982-), 男, 博士, 副教授, 主要从事人工智能与计算机视觉的研究。E-mail: qing\_lb@scu.edu.cn

版权所有©2021 中国科学院光电技术研究所

the filter can make full use of the target's diversity information. This paper involves experiments on the public data sets OTB-2013, OTB-2015 and VOT2016 to evaluate the proposed algorithm. The experimental results show that the speed of the algorithm used in this paper is 20 frames/s, evaluation indicators such as distance accuracy and success rate are superior to comparison algorithms, and it has good robustness in a variety of complex scenarios such as occlusion, background interference, and rotation changes.

**Keywords:** object tracking; correlation filter; aberrance repression; adaptive spatial regularization

## 1 引言

目标跟踪<sup>[1-3]</sup>是计算机视觉领域研究中基础且关键的问题,在智能视频监控、运动分析、人机交互、行为分析、无人机追踪等领域有着广泛的应用。虽然目标跟踪技术在过去几十年取得了较大进展,但在运动目标出现形变、遮挡、尺度变化、背景杂斑等情形下实现准确且鲁棒的对目标跟踪依然具有挑战性。

近年来,由于相关滤波类跟踪算法<sup>[4-15]</sup>性能优异,能够较好的平衡速度和精度,受到了国内外学者的广泛关注。Bolme 等<sup>[4]</sup>创新性地相关滤波的思想引入到目标跟踪领域,提出了 MOSSE 跟踪算法,该算法仅采用灰度特征,速度超过 600 f/s,但精度不高。Henriques 等<sup>[5]</sup>在相关滤波公式中引入核技巧,并利用循环移位样本在频域内优化滤波器系数,提出了 CSK 跟踪算法。在 CSK 的研究基础上,Henriques 等<sup>[6]</sup>之后又提出 KCF 跟踪算法,该算法通过融合多通道 HOG 特征以增强特征表达能力,提升了跟踪效果。

由于上述相关滤波跟踪算法所用特征单一,对目标描述能力不足,并且没有考虑目标尺度变化,当目标与背景相似、目标尺度发生变化时容易丢失目标。Bertinetto 等<sup>[7]</sup>提出的 Staple 算法将颜色统计特征和 HOG 特征进行融合,以达到提升跟踪算法性能的目的。Li<sup>[8]</sup>提出的 SAMF 算法和 Danelljan 等<sup>[9]</sup>提出的 fDSST 算法均采用多尺度搜索策略以达到尺度自适应的目的,从而更好地应对目标尺度的变化。

边界效应是一个值得关注的问题,由于传统相关滤波类跟踪方法利用循环矩阵性质将计算转换到频域,在提高计算速度的同时也产生了部分非真实样本,导致不期望的边界效应,降低滤波器的判别能力,影响跟踪性能。为减小边界效应带来的影响,Galoogahi 等<sup>[10]</sup>提出基于背景感知的 BACF 算法,使用了真实移位产生的负样本并增大搜索区域,但较大的搜索区域容易引入背景噪声,在背景复杂时容易造成跟踪漂移。Huang 等<sup>[11]</sup>提出基于畸变抑制的 ARCF 算法,能够抑制响应图的畸变,但是空间正则化权重没有学习能力,

不能适应目标外观变化。Dai 等<sup>[12]</sup>提出基于自适应空间正则化的 ASRCF 算法,高效地学习得到一个空间权重以适应目标外观变化,但在目标出现运动模糊及较大形变时,滤波器对不准确目标的学习容易过拟合。

为有效减小背景感知相关滤波器的边界效应带来的影响、增强滤波器的判别能力以及有效应对复杂场景的变化,本文提出一种基于自适应空间正则化和畸变抑制的相关滤波跟踪方法。本文工作可归纳如下:

1) 引入裁剪矩阵以保证足够的搜索区域;

2) 在 BACF 算法的基础上把畸变抑制项和自适应空间正则化项相结合,畸变抑制项通过约束响应图的变化率抑制响应图畸变,自适应空间正则化项则使得空间正则化权重能够适应目标外观的变化,从而在保证较大搜索区域的同时缓解边界效应和增强滤波器判别能力,使得跟踪器在复杂场景下也能稳健地跟踪;

3) 采用交替方向乘子法(ADMM)对相关滤波器和自适应空间正则化参数进行优化迭代求解,降低计算量,提高跟踪速度;

4) 在公开数据集 OTB-2013、OTB-2015 和 VOT2016 上进行性能评估,并将本文算法与近年来具有代表性的相关滤波跟踪算法进行对比。实验表明,本文算法性能优于对比算法。

## 2 算法描述

### 2.1 自适应空间正则化和畸变抑制(ASRAR)模型

为解决背景感知相关滤波跟踪(BACF)算法中存在的问题,本文在 BACF 算法的目标函数中融合自适应空间正则化项和畸变抑制项。自适应空间正则化项可以使空间正则化权重在跟踪过程中随着目标的变化而更新,增强滤波器对背景和目标的判别能力。畸变抑制项能够利用上一帧的响应图信息对当前帧生成的响应图进行约束,抑制由遮挡、背景干扰等造成的响应图畸变,提高响应图质量,进而提升跟踪器在复杂情况下的鲁棒性,融合上述两项后,本文算法的目标函数如下:

$$E(\mathbf{h}_k) = \frac{1}{2} \left\| \mathbf{y} - \sum_{d=1}^D \mathbf{C} \mathbf{x}_k^d * \mathbf{h}_k^d \right\|_2^2 + \frac{\beta}{2} \left\| \sum_{d=1}^D (\mathbf{C} \mathbf{x}_{k-1}^d * \mathbf{h}_{k-1}^d) [\psi_{p,q}] - \sum_{d=1}^D \mathbf{C} \mathbf{x}_k^d * \mathbf{h}_k^d \right\|_2^2 + \frac{\lambda_1}{2} \sum_{d=1}^D \left\| \mathbf{w} \odot \mathbf{h}_k^d \right\|_2^2 + \frac{\lambda_2}{2} \left\| \mathbf{w} - \mathbf{w}^r \right\|_2^2, \quad (1)$$

式中:  $D$  表示总通道数,  $k$  和  $k-1$  分别代表第  $k$  帧和第  $k-1$  帧,  $d$  代表  $d$  通道,  $\mathbf{x}_k^d$  代表  $k$  帧第  $d$  通道的特征,  $\mathbf{C}$  是从 BACF 中保留的裁剪矩阵用以确保足够的搜索区域,  $\lambda_1$  和  $\lambda_2$  是空间正则化参数,  $\beta$  是畸变惩罚参数,  $p, q$  表示二维空间中两幅响应图的两个峰值的位置差异,  $\psi_{p,q}$  表示使两幅响应图两个峰值重合的移位操作,  $\mathbf{w}^r$  是空间正则化参考权重, 在第一帧中被初始化为负高斯,  $\mathbf{w}$  是空间正则化权重。第二项代表畸变抑制项, 第三项和第四项代表自适应空间正则化项。

本文算法框架如图 1 所示, 空间正则化权重随着目标的变化而更新, 达到自适应的目的; 一般地, 相邻两帧的响应图变化不大, 故在目标函数中加入畸变抑制项, 在学习过程中对当前帧生成的响应图进行约束, 即通过上一帧的响应图约束当前帧响应图的变化率, 可使当前帧得到的响应图质量更高。  $\psi_{p,q}$  用于移动生成的响应图, 使得前一帧中的峰值位置与当前帧中的峰值位置相同, 从而被检测目标的位置不会受影响约束。当前帧响应图的最高点位置即为跟踪结果。

### 2.2 滤波器模型优化求解

考虑到计算方便, 首先将式(1)转换为如下形式:

$$E(\mathbf{h}_k) = \frac{1}{2} \left\| \mathbf{y} - \mathbf{X}_k (\mathbf{I}_D \otimes \mathbf{C}^T) \mathbf{h}_k \right\|_2^2 + \frac{\lambda_1}{2} \left\| \mathbf{w} \odot \mathbf{h}_k \right\|_2^2 + \frac{\lambda_2}{2} \left\| \mathbf{w} - \mathbf{w}^r \right\|_2^2 + \frac{\beta}{2} \left\| \mathbf{M}_{k-1} [\psi_{p,q}] - \mathbf{X}_k (\mathbf{I}_D \otimes \mathbf{C}^T) \mathbf{h}_k \right\|_2^2, \quad (2)$$

式中:  $\mathbf{X}_k$  是  $\mathbf{x}_k$  的向量形式,  $\mathbf{I}_D$  是  $D \times D$  的单位矩阵, 符号  $\otimes$  代表克罗内克积, 上标  $T$  代表共轭转置运算,  $\mathbf{M}_{k-1}$  代表上一帧的响应图, 其值为  $\mathbf{X}_{k-1} (\mathbf{I}_D \otimes \mathbf{C}^T) \mathbf{h}_{k-1}$ 。为减小运算量, 将式(2)转换到频域:

$$\hat{E}(\mathbf{h}_k, \hat{\mathbf{g}}_k) = \frac{1}{2} \left\| \hat{\mathbf{y}} - \hat{\mathbf{X}}_k \hat{\mathbf{g}}_k \right\|_2^2 + \frac{\lambda_1}{2} \left\| \mathbf{w} \odot \mathbf{h}_k \right\|_2^2 + \frac{\lambda_2}{2} \left\| \mathbf{w} - \mathbf{w}^r \right\|_2^2 + \frac{\beta}{2} \left\| \hat{\mathbf{M}}_{k-1}^s - \hat{\mathbf{X}}_k \hat{\mathbf{g}}_k \right\|_2^2, \quad (3)$$

式中:  $\hat{\mathbf{g}}_k = \sqrt{N} (\mathbf{I}_D \otimes \mathbf{F} \mathbf{C}^T) \mathbf{h}_k$ ,  $\hat{\mathbf{X}}_k$  代表  $\mathbf{X}_k$  的离散傅里叶变换,  $\hat{\mathbf{M}}_{k-1}^s$  代表  $\mathbf{M}_{k-1} [\psi_{p,q}]$  的离散傅里叶变换, 为了方便后续的优化求解, 在式(3)中引入一个新参数  $\hat{\boldsymbol{\alpha}} \in \mathbb{C}^{DN \times 1}$ 。

由于式(3)是凸函数, 可将式(3)写成如下的增广拉格朗日形式:

$$\hat{E}(\mathbf{h}_k, \hat{\mathbf{g}}_k, \hat{\boldsymbol{\alpha}}) = \frac{1}{2} \left\| \hat{\mathbf{y}} - \hat{\mathbf{X}}_k \hat{\mathbf{g}}_k \right\|_2^2 + \frac{\lambda_1}{2} \left\| \mathbf{w} \odot \mathbf{h}_k \right\|_2^2 + \frac{\lambda_2}{2} \left\| \mathbf{w} - \mathbf{w}^r \right\|_2^2 + \frac{\beta}{2} \left\| \hat{\mathbf{M}}_{k-1}^s - \hat{\mathbf{X}}_k \hat{\mathbf{g}}_k \right\|_2^2 + \hat{\boldsymbol{\alpha}}^T \left[ \hat{\mathbf{g}}_k - \sqrt{N} (\mathbf{I}_D \otimes \mathbf{F} \mathbf{C}^T) \mathbf{h}_k \right] + \frac{\mu}{2} \left\| \hat{\mathbf{g}}_k - \sqrt{N} (\mathbf{I}_D \otimes \mathbf{F} \mathbf{C}^T) \mathbf{h}_k \right\|_2^2, \quad (4)$$

式中:  $\mu$  是惩罚因子, 并引入傅里叶域中的拉格朗日向量  $\hat{\boldsymbol{\alpha}} = [\hat{\boldsymbol{\alpha}}^{1T}, \dots, \hat{\boldsymbol{\alpha}}^{DT}]^T$  作为辅助变量。

对第  $k$  帧运用 ADMM 算法意味着可将式(4)分解为两个子问题求解, 即求解  $\mathbf{h}_{k+1}^*$  和  $\hat{\mathbf{g}}_{k+1}^*$ 。

子问题 1: 求解  $\mathbf{h}_{k+1}^*$ 。

$$\mathbf{h}_{k+1}^* = \arg \min_{\mathbf{h}_k} \frac{\lambda_1}{2} \left\| \mathbf{w} \odot \mathbf{h}_k \right\|_2^2 + \hat{\boldsymbol{\alpha}}^T \left[ \hat{\mathbf{g}}_k - \sqrt{N} (\mathbf{I}_D \otimes \mathbf{F} \mathbf{C}^T) \mathbf{h}_k \right] + \frac{\mu}{2} \left\| \hat{\mathbf{g}}_k - \sqrt{N} (\mathbf{I}_D \otimes \mathbf{F} \mathbf{C}^T) \mathbf{h}_k \right\|_2^2, \quad (5)$$

容易求得:

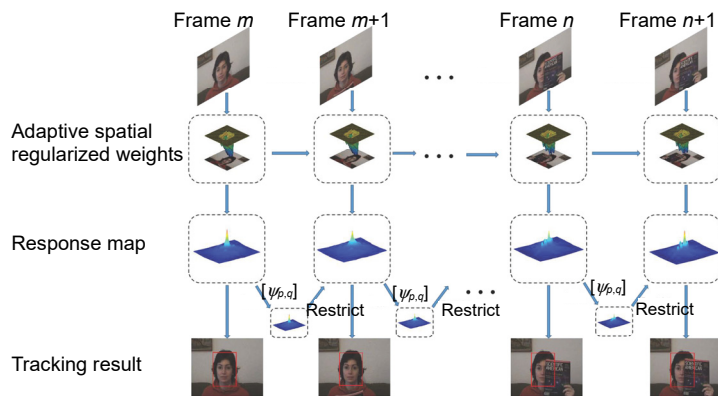


图 1 算法整体框架

Fig. 1 Overall framework of our algorithm

$$\begin{aligned} \mathbf{h}_{k+1}^* &= [\lambda_1(\mathbf{w} \odot \mathbf{w})]^{-1} \\ &\quad \cdot [\sqrt{N}(\mathbf{I}_D \otimes \mathbf{C}\mathbf{F}^T)\hat{\boldsymbol{\alpha}} + \mu\sqrt{N}(\mathbf{I}_D \otimes \mathbf{C}\mathbf{F}^T)\hat{\mathbf{g}}_k] \\ &= \left[ \frac{\lambda_1(\mathbf{w} \odot \mathbf{w})}{N} + \mu \right]^{-1} (\boldsymbol{\alpha} + \mu\mathbf{g}_k), \end{aligned} \quad (6)$$

其中:  $\mathbf{g}_k$  和  $\hat{\mathbf{g}}_k$ , 以及  $\boldsymbol{\alpha}$  和  $\hat{\boldsymbol{\alpha}}$  的转换关系如下:

$$\begin{cases} \mathbf{g}_k = \frac{1}{\sqrt{N}}(\mathbf{I}_D \otimes \mathbf{C}\mathbf{F}^T)\hat{\mathbf{g}}_k \\ \boldsymbol{\alpha} = \frac{1}{\sqrt{N}}(\mathbf{I}_D \otimes \mathbf{C}\mathbf{F}^T)\hat{\boldsymbol{\alpha}} \end{cases}. \quad (7)$$

子问题 2: 求解  $\hat{\mathbf{g}}_{k+1}^*$ 。

$$\begin{aligned} \hat{\mathbf{g}}_{k+1}^* &= \arg \min_{\hat{\mathbf{g}}_k} \frac{1}{2} \|\hat{\mathbf{y}} - \hat{\mathbf{X}}_k \hat{\mathbf{g}}_k\|_2^2 + \frac{\beta}{2} \|\hat{\mathbf{M}}_{k-1}^s - \hat{\mathbf{X}}_k \hat{\mathbf{g}}_k\|_2^2 \\ &\quad + \hat{\boldsymbol{\alpha}}^T [\hat{\mathbf{g}}_k - \sqrt{N}(\mathbf{I}_D \otimes \mathbf{F}\mathbf{C}^T)\mathbf{h}_k] \\ &\quad + \frac{\mu}{2} \|\hat{\mathbf{g}}_k - \sqrt{N}(\mathbf{I}_D \otimes \mathbf{F}\mathbf{C}^T)\mathbf{h}_k\|_2^2. \end{aligned} \quad (8)$$

为了求解方便, 将式(8)分解为  $N$  个子问题的求解,  $n=[1,2,\dots,N]$ 。

$$\begin{aligned} \hat{\mathbf{g}}_{k+1}^*(n) &= \arg \min_{\hat{\mathbf{g}}_k(n)} \frac{1}{2} \|\hat{\mathbf{y}}(n) - \hat{\mathbf{X}}_k^T(n)\hat{\mathbf{g}}_k(n)\|_2^2 \\ &\quad + \frac{\beta}{2} \|\hat{\mathbf{M}}_{k-1}^s - \hat{\mathbf{X}}_k^T(n)\hat{\mathbf{g}}_k(n)\|_2^2 \\ &\quad + \hat{\boldsymbol{\alpha}}^T [\hat{\mathbf{g}}_k(n) - \hat{\mathbf{h}}_k(n)] + \frac{\mu}{2} \|\hat{\mathbf{g}}_k(n) - \hat{\mathbf{h}}_k(n)\|_2^2, \end{aligned} \quad (9)$$

式中:  $\hat{\mathbf{h}}_k(n)=[\hat{h}_k^1(n), \dots, \hat{h}_k^D(n)]^T$ ,  $\hat{h}_k^d$  是  $h_k^d$  的离散傅里叶变换, 即  $\hat{h}_k^d = \sqrt{D}\mathbf{F}\mathbf{C}^T\mathbf{h}_k^d$ ,  $\hat{\mathbf{g}}_k(n)=[\text{conj}(\hat{g}_k^1(n)), \dots, \text{conj}(\hat{g}_k^D(n))]^T$ ,  $\text{conj}()$  表示复共轭运算。  $\hat{\mathbf{x}}_k(n)=[\hat{x}_k^1(n), \hat{x}_k^2(n), \dots, \hat{x}_k^D(n)]^T$ 。每个子问题的解如下:

$$\begin{aligned} \hat{\mathbf{g}}_{k+1}^*(n) &= \frac{1}{1+\beta} \left[ \hat{\mathbf{x}}_k(n)\hat{\mathbf{x}}_k^T(n) + \frac{\mu}{1+\beta}\mathbf{I}_D \right]^{-1} \\ &\quad \cdot \left[ \hat{\mathbf{x}}_k(n)\hat{\mathbf{y}}(n) + \beta\hat{\mathbf{x}}_k(n)\hat{\mathbf{M}}_{k-1}^s - \hat{\boldsymbol{\alpha}}(n) + \mu\hat{\mathbf{h}}_k(n) \right]. \end{aligned} \quad (10)$$

由于式(10)中含有求逆运算, 计算量较大, 采用 Sherman-Morrison 公式对其继续优化, 可得出式(10)的等价形式如下:

$$\begin{aligned} \hat{\mathbf{g}}_{k+1}^*(n) &= \beta^* \left[ \hat{\mathbf{x}}_k(n)\hat{\mathbf{y}}(n) + \beta\hat{\mathbf{x}}_k(n)\hat{\mathbf{M}}_{k-1}^s - \hat{\boldsymbol{\alpha}}(n) + \mu\hat{\mathbf{h}}_k(n) \right] \\ &\quad - \beta^* \frac{\hat{\mathbf{x}}_k(n)}{b} \left[ \hat{\mathbf{S}}_{\mathbf{x}\mathbf{x}}(n)\hat{\mathbf{y}}(n) + \beta\hat{\mathbf{S}}_{\mathbf{x}\mathbf{x}}(n)\hat{\mathbf{M}}_{k-1}^s - \hat{\boldsymbol{\alpha}}(n) + \mu\hat{\mathbf{S}}_{\mathbf{h}\mathbf{x}}(n) \right] \end{aligned} \quad (11)$$

其中:

$$\beta^* = \frac{\mu}{(1+\beta)^2}, \quad \hat{\mathbf{S}}_{\mathbf{x}\mathbf{x}}(n) = \hat{\mathbf{x}}_k(n)^T \hat{\mathbf{x}}_k(n), \quad \hat{\mathbf{S}}_{\boldsymbol{\alpha}}(n) = \hat{\mathbf{x}}_k(n)^T \hat{\boldsymbol{\alpha}},$$

$$\hat{\mathbf{S}}_{\mathbf{h}\mathbf{x}}(n) = \hat{\mathbf{x}}_k(n)^T \hat{\mathbf{h}}_k, \quad b = \hat{\mathbf{x}}_k(n)^T \hat{\mathbf{x}}_k(n) + \mu / (1+\beta).$$

至此, 子问题  $\mathbf{h}_{k+1}^*$  和  $\hat{\mathbf{g}}_{k+1}^*$  解毕。

拉格朗日乘子的更新方案为

$$\hat{\boldsymbol{\alpha}}_{k+1}^{(i+1)} = \hat{\boldsymbol{\alpha}}_{k+1}^i + \mu(\hat{\mathbf{g}}_{k+1}^{*(i+1)} - \hat{\mathbf{h}}_{k+1}^{*(i+1)}). \quad (12)$$

### 2.3 自适应空间正则化权重优化求解

为减少计算量, 对自适应空间正则化参数  $\mathbf{w}$  的求解依然采用 ADMM 算法求解。引入辅助变量  $\mathbf{f}$  构造限制等式  $\mathbf{w}=\mathbf{f}$ , 则可将目标函数写成:

$$E_2(\mathbf{w}, \mathbf{f}) = \frac{\lambda_1}{2} \sum_{d=1}^D \|\mathbf{w} \odot \mathbf{h}_k^d\|_2^2 + \frac{\lambda_2}{2} \|\mathbf{f} - \mathbf{w}^r\|_2^2. \quad (13)$$

接着将式(13)写成增广拉格朗日形式:

$$\begin{aligned} L_2(\mathbf{w}, \mathbf{f}, \mathbf{s}) &= \frac{\lambda_1}{2} \sum_{d=1}^D \|\mathbf{w} \odot \mathbf{h}_k^d\|_2^2 + \frac{\lambda_2}{2} \|\mathbf{f} - \mathbf{w}^r\|_2^2 \\ &\quad + (\mathbf{w} - \mathbf{f})^T \mathbf{s} + \frac{\delta}{2} \|\mathbf{w} - \mathbf{f}\|_2^2, \end{aligned} \quad (14)$$

式中:  $\delta$  是惩罚参数,  $s$  是拉格朗日乘子。引入参数  $m = \frac{1}{\delta}s$ , 式(14)可写成如下等价形式:

$$\begin{aligned} L_2(\mathbf{w}, \mathbf{f}, \mathbf{s}) &= \frac{\lambda_1}{2} \sum_{d=1}^D \|\mathbf{w} \odot \mathbf{h}_k^d\|_2^2 \\ &\quad + \frac{\lambda_2}{2} \|\mathbf{f} - \mathbf{w}^r\|_2^2 + \frac{\delta}{2} \|\mathbf{w} - \mathbf{f} + m\|_2^2. \end{aligned} \quad (15)$$

运用 ADMM 算法, 对式(15)的求解可以转换为两个子问题的求解。

子问题 1:  $\mathbf{w}^*$  的求解。

$$\begin{aligned} \mathbf{w}^* &= \arg \min_{\mathbf{w}} \frac{\lambda_1}{2} \sum_{d=1}^D \|\mathbf{w} \odot \mathbf{h}_k^d\|_2^2 + \frac{\delta}{2} \|\mathbf{w} - \mathbf{f} + m\|_2^2 \\ &= \arg \min_{\mathbf{w}} \frac{\lambda_1}{2} \sum_{d=1}^D \mathbf{H}_k^d \mathbf{w} + \frac{\delta}{2} \|\mathbf{w} - \mathbf{f} + m\|_2^2, \end{aligned} \quad (16)$$

$\mathbf{w}^*$  的解为

$$\mathbf{w}^* = \left( \frac{\lambda_1}{\delta} \mathbf{H}^T \mathbf{H} + \mathbf{I} \right)^{-1} (\mathbf{f} - m), \quad (17)$$

其中:  $\mathbf{H}_k^d = \text{diag}(\mathbf{h}_k^d) \in \mathbb{R}^{T \times T}$ ,  $\mathbf{H} = [\mathbf{H}_k^1, \mathbf{H}_k^2, \mathbf{H}_k^3, \dots, \mathbf{H}_k^D]^T \in \mathbb{R}^{DT \times T}$ 。

子问题 2:  $\mathbf{f}^*$  的求解。

$$\mathbf{f}^* = \arg \min_{\mathbf{f}} \frac{\lambda_2}{2} \|\mathbf{f} - \mathbf{w}^r\|_2^2 + \frac{\delta}{2} \|\mathbf{w} - \mathbf{f} + m\|_2^2, \quad (18)$$

$\mathbf{f}^*$  的解为

$$\mathbf{f}^* = \frac{\lambda_2 \mathbf{w}^r + \delta(\mathbf{w} + m)}{\lambda_2 + \delta}. \quad (19)$$

拉格朗日乘子的更新方案为

$$\mathbf{m}^{(i+1)} = \mathbf{m}^{(i)} + \mathbf{w}^{(i+1)} - \mathbf{f}^{(i+1)}. \quad (20)$$

### 2.4 模型更新

目标表现模型按照下式更新:

$$\hat{\mathbf{x}}_k^{\text{model}} = (1-\eta)\hat{\mathbf{x}}_{k-1}^{\text{model}} + \eta\hat{\mathbf{x}}_k, \quad (21)$$

式中:  $k$  和  $k-1$  分别表示  $k$  帧和  $k-1$  帧,  $\eta$  表示表现模型学习率。

### 3 实验结果与分析

#### 3.1 实验平台与参数设置

本文实验所用编程软件为 MATLAB R2017a, 操作系统为 Windows10, 计算机配置为 CPU: Intel(R) Celeron(R) G1820, 主频 2.70 GHz, 内存 8 G。算法主要参数设置如下:  $\lambda_1=0.23$ ,  $\lambda_2=0.003$ ,  $\beta=0.69$ ,  $\eta=0.0189$ , ADMM 算法迭代次数设置为 5。其余参数设置和 BACF 一致。为了充分验证本文算法的鲁棒性和准确性, 本文选用评估目标跟踪算法常用的数据集 OTB-2013<sup>[16]</sup>、OTB-2015<sup>[17]</sup>和 VOT2016<sup>[18]</sup>进行测试和评估。

#### 3.2 OTB 评估指标

OTB 数据集主要采用距离精度和成功率作为评价指标。距离精度是指中心位置误差(CLE, 用  $E_{CL}$  表示)小于某一阈值的帧数在总帧数中所占的比例, 本文将该阈值取为 20 pixels, 中心位置误差衡量的是跟踪算法预测的目标中心位置  $(x_p, y_p)$  与目标实际中心位置  $(x_T, y_T)$  之间的欧氏距离, 计算式为

$$E_{CL} = \sqrt{(x_p - x_T)^2 + (y_p - y_T)^2} \quad (22)$$

成功率是指跟踪算法预测的目标框区域  $S_p$  和目标实际框区域  $S_T$  重叠率(OP, 用  $R_{OP}$  表示)大于某一阈值的帧数占总帧数的比例, 本文将该阈值取为 0.5, 计算式为

$$R_{OP} = \frac{area(S_p \cap S_T)}{area(S_p \cup S_T)} \quad (23)$$

#### 3.3 VOT 评估指标

VOT 是一个针对单目标的测试基准数据集, 其基本评价指标是跟踪器成功跟踪期间的平均重叠率(准确率  $Acc$ , 用  $A_{cc}$  表示)和跟踪器在单个测试序列下的失败次数(鲁棒性  $Rob$ , 用  $R_{ob}$  表示)。  $Acc$  和  $Rob$  的计算公式如下:

$$A_{cc} = \frac{1}{M_{valid}} \sum_{t=1}^{M_{valid}} \varphi_t(i) \quad (24)$$

$$R_{ob} = \frac{1}{M} \sum_{k=1}^M F(i, k) \quad (25)$$

式中:  $\varphi_t(i)$  表示第  $i$  个跟踪器在第  $t$  帧上的准确率,  $M_{valid}$  表示有效帧的数量,  $F(i, k)$  表示第  $i$  个跟踪器在第  $k$  次重复中的失败次数。根据计算公式可以得知,  $Acc$  的值越大, 算法准确率就越高;  $Rob$  的值越小, 算法的鲁棒性就越好。

除了上述两个评价指标, 本文选用的 VOT2016

数据集新增了期望平均重叠率(EAO)这一新的指标。EAO 是评价算法综合性能的重要指标。首先将数据集的所有序列按照长度进行分类, 然后将待评估的跟踪器在长度为  $N_s$  的序列上进行测试并得到每一帧的准确率  $\varphi(t)$ , 接着利用式(24)求得单一序列上的准确率  $\varphi_{N_s}$ 。长度为  $N_s$  的序列不只一个, 若为  $M$  个, 则再求平均值就得到了待评估跟踪器在长度为  $N_s$  的序列上的 EAO 值  $\hat{\varphi}_{N_s}$ , 最后针对不同视频序列长度的 EAO 值求平均值:

$$\hat{\varphi} = \frac{1}{N_{hi} - N_{lo}} \sum_{N_s=N_{lo}}^{N_{hi}} \hat{\varphi}_{N_s} \quad (26)$$

式中  $[N_{lo}, N_{hi}]$  表示视频序列的长度范围。

#### 3.4 OTB 实验结果分析

在本节中, 将本文算法 ASRAR 与目前主流且跟踪效果优异的 9 种相关滤波跟踪算法在 OTB 数据集上进行比较。这 9 种算法分别是: KCF<sup>[6]</sup>, BACF<sup>[10]</sup>, ARCF<sup>[11]</sup>, ASRCF<sup>[12]</sup>, Staple<sup>[17]</sup>, ECO-HC<sup>[19]</sup>, LDES<sup>[20]</sup>, SRDCF<sup>[21]</sup>, LMCF<sup>[22]</sup>, 为保证对比公平, 在算法设置上, 将 ASRCF 算法的特征提取方式和尺度估计策略设置为和本文算法一致。实验结果如表 1 及图 2、图 3、图 4 所示。

表 1 算法平均跟踪速度  
Table 1 Mean tracking speed of different algorithms

Method	Speed/(f/s)
KCF	173.4
DSST	17.7
Staple	48.3
SRDCF	3.8
BACF	26
ARCF	22
ASRCF	24
ASRAR	20

图 2 为 10 种算法在 OTB-2013 和 OTB-2015 上的整体距离精度曲线和整体成功率曲线, 从图 2 可以看出, 本文算法在 OTB-2013 和 OTB-2015 上的整体距离精度和整体成功率都排名第一, 优于对比算法。从图 2 的子图中可以看出, 在 OTB-2013 数据集上, 相比于基准算法 BACF, 本文算法 ASRAR 距离精度提高 4%, 达到 88.9%, 成功率提高 3.3%, 达到 67.8%; 在 OTB-2015 数据集上, 相比于基准算法 BACF, 本文算法 ASRAR 距离精度提高 7.1%, 达到 88.7%, 成功率提高 5.9%, 达到 67.4%。

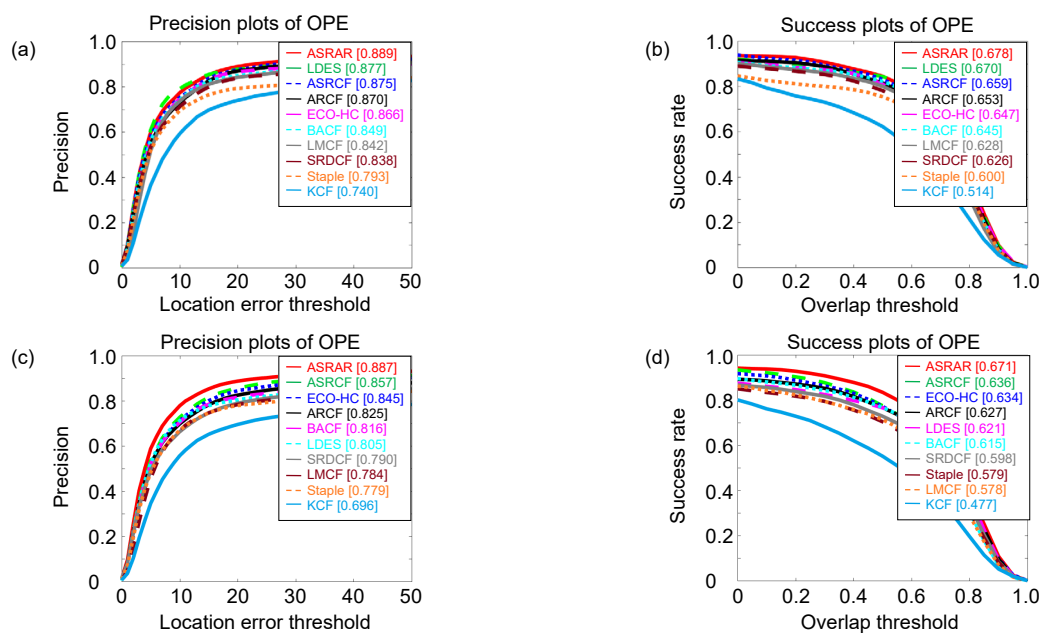


图2 算法在不同数据集上的实验结果。(a) OTB-2013 距离精度曲线; (b) OTB-2013 成功率曲线; (c) OTB-2015 距离精度曲线; (d) OTB-2015 成功率曲线

Fig. 2 Experimental results of the algorithm on different data sets. (a) Distance precision of OTB-2013; (b) Success rate of OTB-2013; (c) Distance precision of OTB-2015; (d) Success rate of OTB-2015

图3为9种算法在OTB-2013数据集下11种不同属性视频序列的跟踪成功率。各子图题目括号中的数字代表具有相应属性的视频序列数量。本文算法除了在out of view和low resolution属性下表现稍差,在其余9个属性中跟踪成功率均排在前三位,在各属性下的跟踪成功率与基准算法BACF相比均有较大提升。

图4为9种算法在OTB-2015数据集下11种不同属性视频序列的跟踪成功率,本文算法在11个属性中均为最优,表明本文算法有着较强的跟踪稳健性。

表1为本文算法ASRAR与部分算法的跟踪速度结果。本文算法ASRAR采用交替方向乘法对滤波器及空间正则化参数进行优化迭代求解,减少了计算量,故速度比采用高斯-塞德尔迭代法对滤波器进行求解的SRDCF算法快。与基准算法BACF相比,由于本文算法ASRAR在BACF的基础上融合了两个约束项,在提升距离精度和成功率的同时跟踪速度有一定的降低,但平均跟踪速度为20 f/s,能保证算法的实时性。

### 3.5 VOT 实验结果分析

在本节中,选取DSST<sup>[23]</sup>、TCNN<sup>[24]</sup>等8种性能优异的相关滤波跟踪算法与本文算法ASRAR进行对比与分析。实验结果如表2、图5及图6所示。

表2为9种算法VOT2016标准下的评估结果。从表2可以看出,本文算法ASRAR在EAO、Acc和Rob

这三个评价指标上均优于对比算法。EAO代表算法的综合性能,以EAO为例进行分析:相比于基准算法BACF,本文算法ASRAR的EAO提高了14.8%,达到0.371;相比于ASRCF算法,本文算法ASRAR的EAO提高了2.9%;相比于ARCF算法,本文算法ASRAR的EAO提高了4.1%。

图5为9种算法的EAO点图,横坐标的数字代表排名,纵坐标是各算法的EAO值。从图5可以直观地看出,本文算法的综合性能对比算法优异。

图6为9种算法在不同序列长度上的重叠率曲线。从图6中的曲线可以看出,在视频序列较短和较长的情况下,本文算法ASRAR都优于对比算法。为客观准确地评估本文算法,选用OTB-2013、OTB-2015和VOT2016数据集进行实验,且用了不同评价指标对算法进行较为全面的评估。综合OTB和VOT的实验结果可以得知,相较于基准算法BACF,本文算法ASRAR的综合性能有了较大提升,同时也证明了将自适应空间正则化项和畸变抑制项相结合的有效性。

### 3.6 定性分析

从OTB-2015中选取6组代表性的视频序列进行定性分析,OTB-2013和OTB-2015这两个数据集中的序列包含了尺度变化(SV)、运动模糊(MB)、遮挡(OCC)、复杂背景(BC)、光照变化(IV)、形变(DEF)、

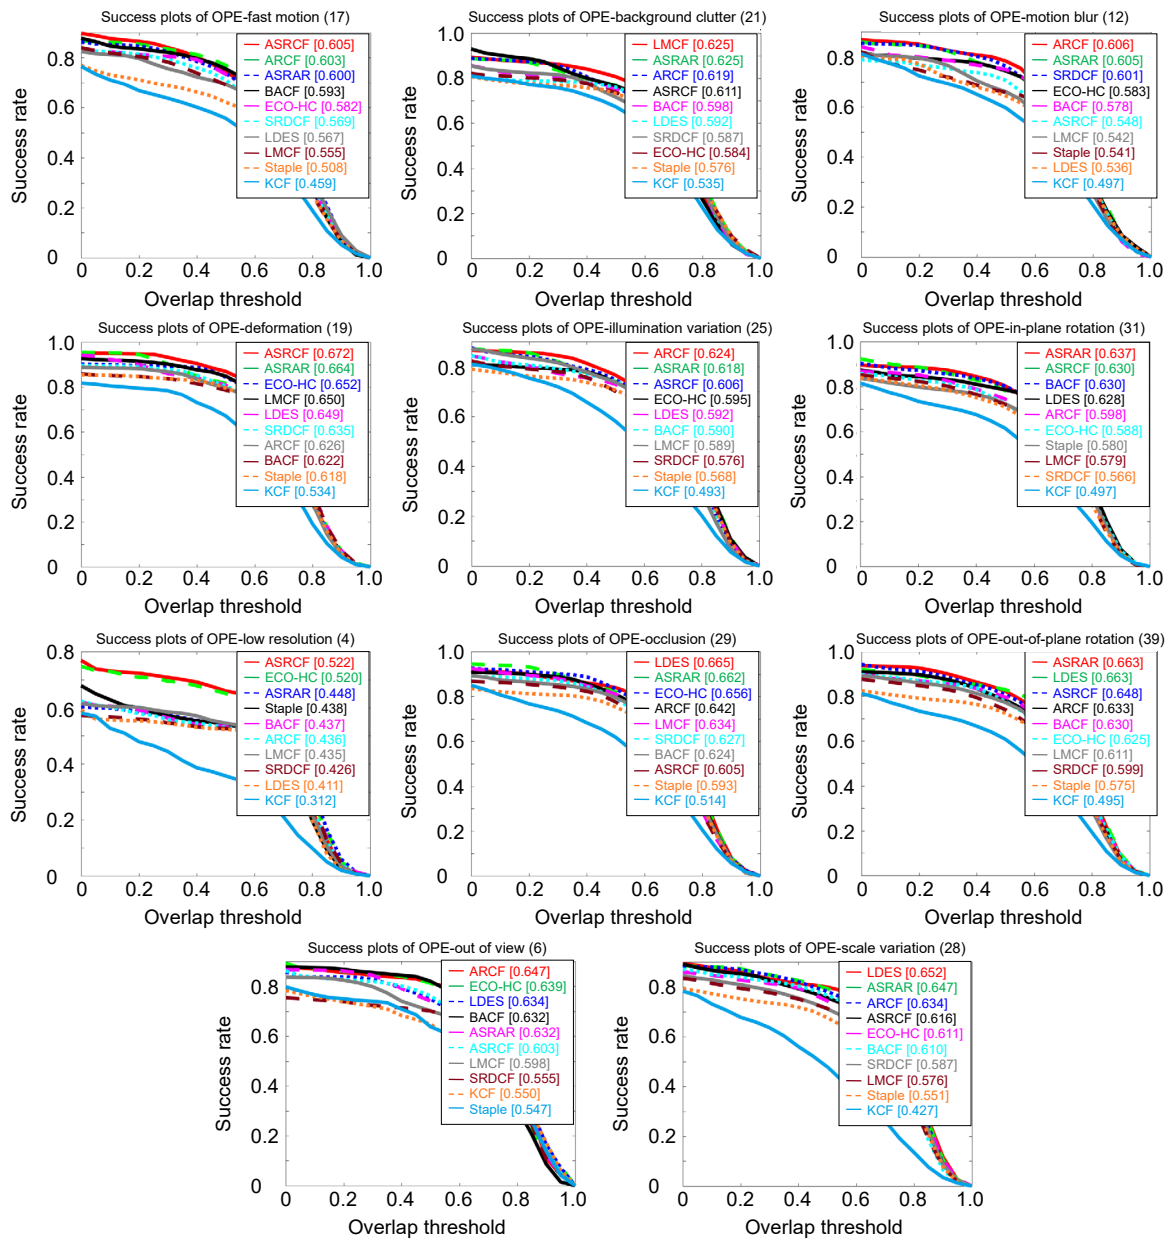


图 3 OTB-2013 数据集下 11 种不同属性视频序列跟踪成功率

Fig. 3 Tracking success rates of 11 different attribute video sequences on the OTB-2013 data set

超出视野(OV)、快速运动(FM)、运动模糊(MB)、低分辨率(LR)、平面外旋转(OPR)及平面内旋转(IPR)等 11 种干扰场景。图 7 为本文算法 ASRAR 和其它 4 种算法在选取的视频序列上的部分跟踪结果。表 3 为所选视频序列的特征。

现主要对图 7 所选用算法在光照变化、遮挡、复杂背景、形变、旋转变换等场景下的表现进行定性分析。

1) 光照变化。所选视频序列 Shaking、Biker 和 Sylvester 中的目标都受光照变化的影响。其中以序列 Shaking 最为明显。本文算法 ASRAR 提取了灰度特征，

CN 特征以及 FHOG 特征对目标进行描述,由于 FHOG 特征对光照变化不敏感,故提升了算法对光照变化的适应性。如 Shaking 序列的第 90 帧和第 175 帧。

2) 遮挡。所选视频序列 Girl2、Biker 和 Soccer 中的目标都出现部分遮挡或完全遮挡。以序列 Girl2 为例分析: 视频序列 Girl2 中,目标在第 110 帧被完全遮挡,在后续帧中目标出现后,只有本文算法能跟上目标。由于本文算法加入了畸变抑制项,通过约束响应图的变化来限制对不相关目标的学习,从而在遮挡情况下获得更好的性能。

3) 复杂背景。所选视频序列 Shaking 和 Soccer 都

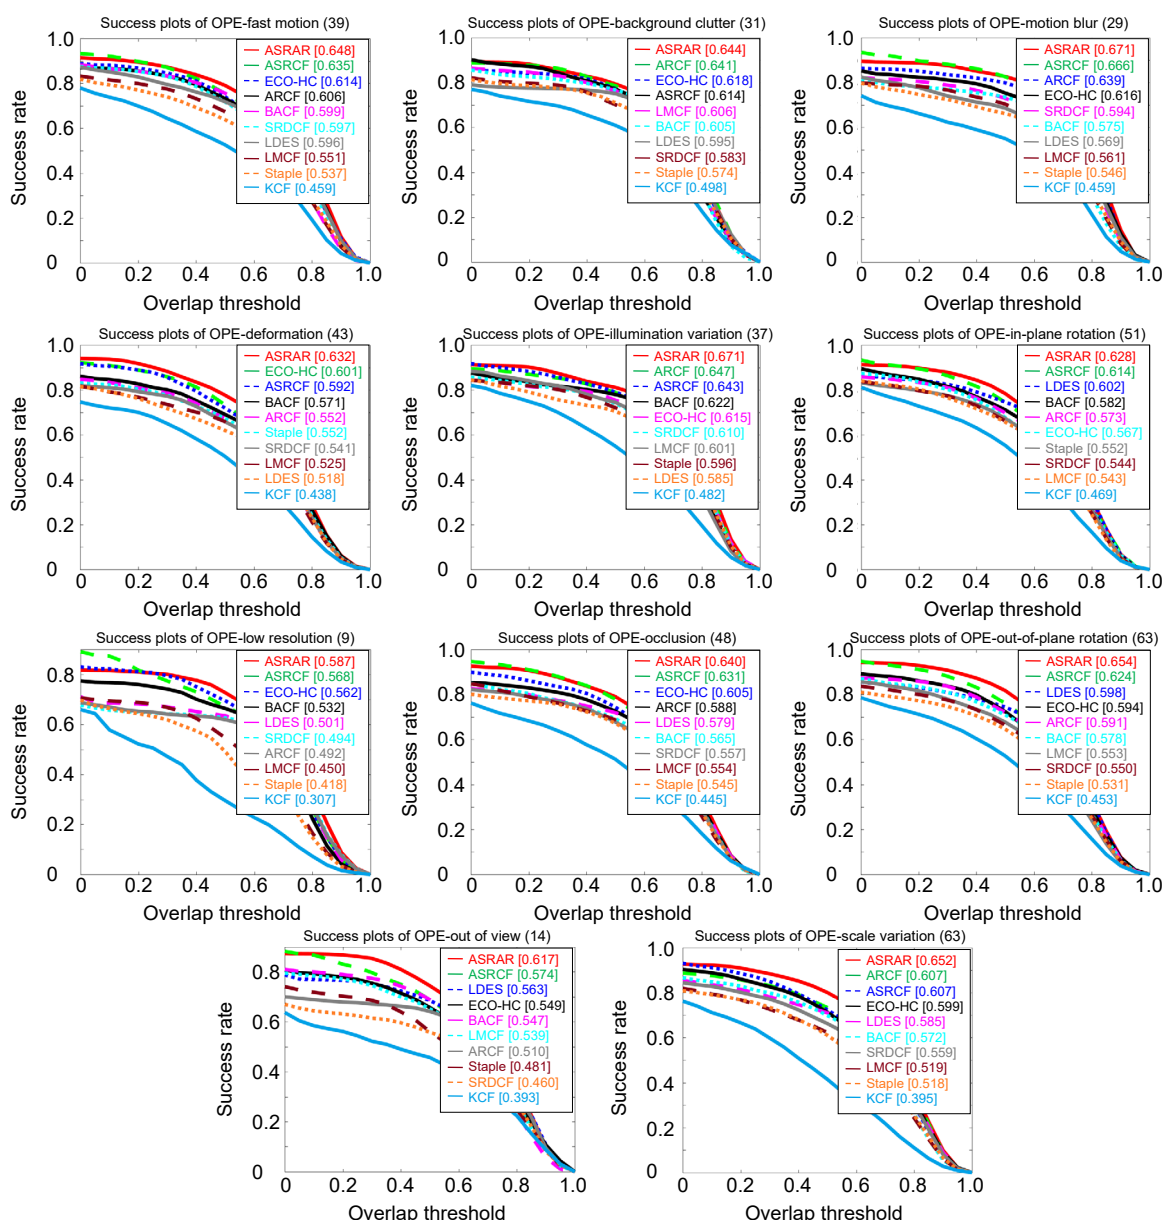


图 4 OTB-2015 数据集下 11 种不同属性视频序列跟踪成功率  
Fig. 4 Tracking success rates of 11 different attribute video sequences on the OTB-2015 data set

有这个属性。其中以序列 Soccer 最为明显，在序列 Soccer 中，目标和背景高度相似，且目标被部分或完全遮挡，跟踪算法易跟踪失败，在第 128 帧基准算法 BACF 已经跟丢目标。由于本文算法加入了畸变抑制项来约束当前帧的响应图，增强滤波器的判别能力，以缓解滤波器模型退化问题，抑制了跟踪框的漂移，故在复杂背景下也有优异的稳健性。

4) 形变。所选视频序列 Girl2 和 Bird1 都有这个属性。以序列 Bird1 为例分析：在第 45 帧、第 52 帧、第 96 帧中目标都出现了形变，在此属性上 DSST 算法和 SRDCF 算法表现较差，由于本文算法结合了自适应

表 2 VOT2016 标准下的评估结果

Table 2 Evaluation results under the VOT2016

Method	EAO	Acc	Rob
Staple	0.295	0.54	0.378
DSST	0.181	0.50	1.058
SRDCF	0.247	0.52	0.418
BACF	0.223	0.54	0.376
ECO-HC	0.322	0.54	0.263
TCNN	0.325	0.55	0.268
ASRCF	0.342	0.55	0.232
ARCF	0.330	0.53	0.241
ASRAR	0.371	0.56	0.203



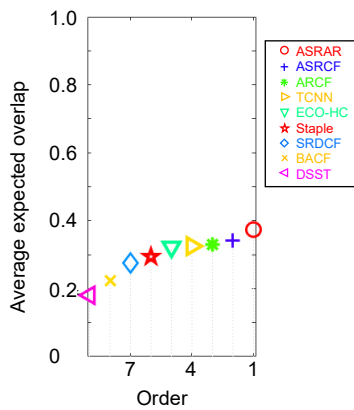


图 5 9 种算法的 EAO 点图  
Fig. 5 EAO points of 9 algorithms




图 6 算法在不同序列长度上的重叠率  
Fig. 6 Overlap rate of the proposed algorithm on different sequence length



图 7 不同算法的部分跟踪结果  
Fig. 7 Partial tracking results of different algorithms

表 3 所选视频序列特征

Table 3 Characteristics of selected video sequences

Sequence	Image size/(pixels×pixels)	Frame number	Characteristic
Shaking	624×352	365	IV, SV, IPR, OPR, BC
Girl 2	640×480	1500	SV, OCC, DEF, MB, OPR
Soccer	640×360	392	IV, SV, OCC, MB, FM, IPR, OPR, BC
Bird 1	720×400	408	DEF, FM, OV
Biker	640×360	142	SV, OCC, MB, FM, OPR, OV, LR
Sylvester	320×240	1345	IV, IPR, OPR

空间正则化项和畸变抑制项，能更精准地跟踪目标。

5) 旋转变换。所选视频序列除 Bird1 外都有这个属性。以序列 Sylvester 为例分析：在目标未出现旋转变换时，所有算法都能较好地跟踪目标，如第 1066

帧；目标出现旋转变换后，Staple 算法表现较差，而本文算法利用畸变抑制项和多通道特征较为有效地解决了此问题，如第 1138 帧。

## 4 结论

本文提出一种结合自适应空间正则化和畸变抑制的相关滤波跟踪算法,通过保留 BACF 中的裁剪矩阵以保证足够的搜索区域,在目标函数中引入畸变抑制项使得到的响应图质量更高,能有效缓解边界效应和滤波器模型退化问题,而自适应空间正则化项能够随着目标外观变化而更新惩罚权重,突出目标抑制背景。实验结果表明,本文算法不仅能适应目标外观变化,并在保证足够搜索区域的同时,减小边界效应的影响并让滤波器能够利用上一帧响应图的信息对当前帧响应图的变化率进行约束,从而抑制跟踪漂移现象,在复杂场景下有着较高精度和鲁棒性,且跟踪速度能满足实时性要求。


## 参考文献

- [1] Yilmaz A, Javed O, Shah M. Object tracking: a survey[J]. *ACM Comput Surv*, 2006, **38**(4): 1–45.
- [2] Smeulders A W M, Chu D M, Cucchiara R, et al. Visual tracking: an experimental survey[J]. *IEEE Trans Pattern Anal Mach Intell*, 2014, **36**(7): 1442–1468.
- [3] Lu H C, Li P X, Wang D. Visual object tracking: a survey[J]. *Pattern Recognit Artif Intell*, 2018, **31**(1): 61–76.  
卢湖川, 李佩霞, 王栋. 目标跟踪算法综述[J]. 模式识别与人工智能, 2018, **31**(1): 61–76.
- [4] Bolme D S, Beveridge J R, Draper B A, et al. Visual object tracking using adaptive correlation filters[C]//*Proceedings of the 2010 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2010: 2544–2550.
- [5] Henriques J F, Caseiro R, Martins P, et al. Exploiting the circulant structure of tracking-by-detection with kernels[M]//Fitzgibbon A, Lazebnik S, Perona P, et al. *Computer Vision—ECCV 2012*. ECCV 2012. Berlin, Heidelberg: Springer, 2012: 702–715.
- [6] Henriques J F, Caseiro R, Martins P, et al. High-speed tracking with kernelized correlation filters[J]. *IEEE Trans Pattern Anal Mach Intell*, 2015, **37**(3): 583–596.
- [7] Bertinetto L, Valmadre J, Golodetz S, et al. Staple: complementary learners for real-time tracking[C]//*Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016: 1401–1409.
- [8] Li Y, Zhu J K. A scale adaptive kernel correlation filter tracker with feature integration[C]//Agapito L, Bronstein M, Rother C. *Computer Vision—ECCV 2014 Workshops*. ECCV 2014. Zurich, Switzerland: Springer, 2014: 254–265.
- [9] Danelljan M, Häger G, Khan F S, et al. Discriminative scale space tracking[J]. *IEEE Trans Pattern Anal Mach Intell*, 2017, **39**(8): 1561–1575.
- [10] Galoogahi H K, Fagg A, Lucey S. Learning background-aware correlation filters for visual tracking[C]//*Proceedings of the 2017 IEEE International Conference on Computer Vision (ICCV)*, 2017: 1135–1143.
- [11] Huang Z Y, Fu C H, Li Y M, et al. Learning aberrance repressed correlation filters for real-time UAV tracking[C]//*Proceedings of the 2019 IEEE International Conference on Computer Vision (ICCV)*, 2019: 2891–2900.
- [12] Dai K A, Wang D, Lu H C, et al. Visual tracking via adaptive spatially-regularized correlation filters[C]//*Proceedings of the 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, 2019: 4670–4679.
- [13] Tang X M, Chen Z G, Fu Y. Anti-occlusion and re-tracking of real-time moving target based on kernelized correlation filter[J]. *Opto-Electron Eng*, 2020, **47**(1): 52–61.  
汤学猛, 陈志国, 傅毅. 基于核滤波器实时运动目标的抗遮挡再跟踪[J]. 光电工程, 2020, **47**(1): 52–61.
- [14] Wang H Y, Wang L, Yin W R, et al. Multi-scale correlation filtering visual tracking algorithm combined with target detection[J]. *Acta Opt Sin*, 2019, **39**(1): 0115004.  
王红雨, 汪梁, 尹午荣, 等. 结合目标检测的多尺度相关滤波视觉跟踪算法[J]. 光学学报, 2019, **39**(1): 0115004.
- [15] Liu W J, Sun H, Jiang W T. Correlation filter tracking algorithm for adaptive feature selection[J]. *Acta Opt Sin*, 2019, **39**(6): 0615004.  
刘万军, 孙虎, 姜文涛. 自适应特征选择的相关滤波跟踪算法[J]. 光学学报, 2019, **39**(6): 0615004.
- [16] Wu Y, Lim J, Yang M H. Object tracking benchmark[J]. *IEEE Trans Pattern Anal Mach Intell*, 2015, **37**(9): 1834–1848.
- [17] Wu Y, Lim J, Yang M H. Online object tracking: a benchmark[C]//*Proceedings of the 2013 IEEE Conference on Computer Vision and Pattern Recognition*, 2013: 2411–2418.
- [18] Kristan M, Matas J, Leonardis A, et al. The visual object tracking VOT2015 challenge results[C]//*Proceedings of the 2015 IEEE International Conference on Computer Vision Workshop (ICCVW)*, 2015: 1–23.
- [19] Danelljan M, Bhat G, Khan F S, et al. ECO: efficient convolution operators for tracking[C]//*Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017: 6638–6646.
- [20] Li Y, Zhu J K, Hoi S C H, et al. Robust estimation of similarity transformation for visual object tracking[C]//*Proceedings of 2019 AAAI Conference on Artificial Intelligence (AAAI)*, 2019, **33**: 8666–8673.
- [21] Danelljan M, Häger G, Khan F S, et al. Learning spatially regularized correlation filters for visual tracking[C]//*Proceedings of the 2015 IEEE International Conference on Computer Vision (ICCV)*, 2015: 4310–4318.
- [22] Wang M M, Liu Y, Huang Z. Large margin object tracking with circulant feature maps[C]//*Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2017: 4800–4808.
- [23] Danelljan M, Häger G, Khan F S, et al. Accurate scale estimation for robust visual tracking[C]//*Proceedings of the British Machine Vision Conference 2014*, 2014: 1–11.
- [24] Nam H, Baek M, Han B. Modeling and propagating CNNs in a tree structure for visual tracking[EB/OL]. (2016-08-25)[2020-04-08]. <https://arxiv.org/abs/1608.07242>.

# Learning adaptive spatial regularization and aberrance repression correlation filters for visual tracking

Wang Ye, Liu Qiang, Qin Linbo\*, Teng Qizhi, He Xiaohai

School of Electronics and Information Engineering, Sichuan University, Chengdu, Sichuan 610065, China



Partial tracking results of different algorithms

**Overview:** As the application basis of intelligent video surveillance, motion analysis, human-computer interaction, spanning monitoring, behavior analysis, and UAV tracking, object tracking is one of the most important researches and one of the basic problems in the field of computer vision. Although the object tracking technology has made great progress in the past few decades, it is still a challenging task to track the target accurately and robustly in the case of deformation, occlusion, scale change, background clutter, and so on. Owing to its excellent performance, the kernel correlation filter tracking algorithm has recently become a popular research subject in the object tracking community. However, traditional correlation filter tracking methods use the properties of the cyclic matrix to transform calculations from the spatial domain to the frequency domain. Although calculation speed is improved using this method, some nonreal samples are also generated. This leads to undesired boundary effects, which reduce the discrimination ability of the filter and affect tracking performance. To some extent, these effects were alleviated by adding pre-defined spatial constraints on the filter coefficients or expanding the search area. However, such constraints are usually fixed for different objects and do not change during the tracking process, while expanding the search area can easily introduce background noise. To overcome the shortcomings of the algorithm, a tracking method based on adaptive spatial regularization and aberrance repression is proposed. First, FHOG features, CN features, and gray features are extracted to enhance the algorithm's ability to express targets. Second, the aberrance repression term is introduced into the objective function to constrain the rate of change of the current frame's response map, which can suppress the drift of the tracking box. Finally, the adaptive spatial regularization term is introduced into the objective function, which learns an effective spatial weight for a specific object and its appearance variations. The ADMM algorithm is used to solve the filter model and reduce computation time. In this study, experiments are performed on the OTB-2013, OTB-2015, and VOT2016 public databases. These databases are commonly used to evaluate the performance of tracking algorithms. It is worth mentioning that the OTB public database includes scale variation, illumination variation, occlusion, and background clutter challenges. Thus, it can accurately and objectively evaluate algorithm performance. The authors used KCF, BACF, Staple, ECO-HC, LDES, SRDCF, LMCF, DSST, etc., as comparison algorithms and used MATLAB R2017a as a programming language. Experimental results indicate that the proposed method exhibits excellent performance in tracking accuracy and robustness in complex scenes such as occlusion, background clutter, and rotation changes.

Wang Y, Liu Q, Qin L B, *et al.* Learning adaptive spatial regularization and aberrance repression correlation filters for visual tracking[J]. *Opto-Electron Eng*, 2021, **48**(1): 200068; DOI: 10.12086/oee.2021.200068

Foundation item: National Natural Science Foundation of China (61871278), International Science and Technology Cooperation and Exchange Project of Sichuan Science and Technology Department (2018HH0143), and Chengdu Industrial Cluster Collaborative Innovation Project (2016-XT00-00015-GX)

\* E-mail: qing\_lb@scu.edu.cn