

引用格式: 胡昭华, 李奇, 韩庆. 基于双检测器系统的长期目标跟踪算法[J]. 微电子学与计算机, 2021, 38(9): 31-37. [HU Z H, LI Q, HAN Q. Dual-detector system for Long-term tracking[J]. Microelectronics & Computer, 2021, 38(9): 31-37.]

基于双检测器系统的长期目标跟踪算法

胡昭华^{1,2}, 李 奇¹, 韩 庆¹

(1 南京信息工程大学 电子与信息工程学院, 江苏 南京 210044;

2 南京信息工程大学 江苏省大气环境与装备技术协同创新中心, 江苏 南京 210044)

摘 要: 针对长期目标跟踪过程中极易出现的目标漂移导致跟踪失败的问题, 在空间正则化相关滤波算法的基础上, 提出一种基于双检测器系统的长期目标跟踪算法. 为了适应不同的跟踪场景, 增加模型鲁棒性, 加入 SVM 检测器和孪生网络检测器, 并选择较为高效的 SVM 检测器作为主检测器; 只有当主检测器检测失败时, 才启动精度更高的孪生网络检测器检测目标, 通过两个检测器的协同工作可以对当前图像进行高质量的重新检测. 同时, 本算法中加入自适应空间正则化项, 可以有效抑制边界效应的影响; 并采用交替方向乘子法对目标函数进行优化, 降低计算复杂度以节约运行时间. 本文算法在 OTB-2013 和 OTB-2015 两个数据集上进行测试, 结果表明: 本文算法在多种特性上都有较强的鲁棒性, 特别是在进行长视频序列的跟踪时, 比基础算法在跟踪距离精度和成功率上分别提高了 12.9% 和 6.2%.

关键词: 目标跟踪; 长期跟踪; 双检测器系统; 重新检测; 自适应空间正则化

中图分类号: TP391

文献标识码: A

文章编号: 1000-7180(2021)09-0031-07

Dual-detector system for Long-term tracking

HU Zhaohua^{1,2}, LI Qi¹, HAN Qing¹

(1 College of Electronics and Information Engineering, Nanjing University of Information
Science and Technology, Nanjing 210044, China;

2 Jiangsu Collaborative Innovation Center on Atmospheric Environment and Equipment Technology,
Nanjing University of Information Science and Technology, Nanjing 210044, China)

Abstract: Aiming to solve the problem of target drift that occurs often in the process of long-term tracking, a dual-detector system for long-term tracking is proposed based on the spatially regularized correlation filters algorithm. In order to adapt to different tracking scenarios and increase the robustness of the model, SVM detector and siamese network detector are added, and the more efficient SVM detector is selected as the main detector. Only when the main detector fails to detect the target, the more accurate siamese network detector is started to detect the target. Through the cooperative work of the two detectors, the current image can be re-detected with high quality. At the same time, the adaptive spatial regularization term is also added in this paper, which can effectively suppress the influence of the boundary effect. The objective function is optimized by the alternating direction multiplier method to reduce the computational complexity and save running time. The experiment on datasets OTB-2013 and OTB-2015 show that the proposed algorithm has strong robustness in many characteristics. Especially in long-term tracking, the tracking distance accuracy and success rate of the proposed algorithm are improved by 12.9% and 6.2% respectively compared with the basic algorithm.

Key words: object tracking; long-term tracking; dual-detector system; re-detection; adaptive spatial regularization

1 引言

目标跟踪作为计算机视觉领域的重要研究分支之一,在近十几年中取得了很大的进步.虽然目前已经有了较为广泛应用,但实际跟踪过程中,在目标背景复杂,运动模糊或发生遮挡等方面,容易出现目标漂移从而导致长期跟踪的失败.

文献[1-2]中,提出最小误差输出和相关滤波的方法,利用核函数解决了线性不可分的问题,提高了目标跟踪的速度.但是相关滤波算法的训练集都是由循环移位产生,不可避免的会发生边界效应影响跟踪效果.2015 年,Danelljan 等人^[3]提出了空间正则化相关滤波算法(SRDCF),通过对滤波器进行负高斯形正则化权重来抑制边界效应,并采用 Gauss-Seidel 迭代法进行滤波器的求解,算法复杂度增加使得跟踪速度大大降低.后续在此基础上的研究中,虽然算法总体跟踪精度和速度都有了一定的提升,但是当发生遮挡等情况导致目标丢失时,算法很难再将目标准确地找回. Ma 等人^[4]对长视频目标跟踪算法(LCT)进行了研究,算法中加入重新检测机制,可以在目标长期遮挡或快速移动以后尝试再次捕捉目标,但是由于检测器单一,模型鲁棒性不够导致最终的跟踪结果不够理想.

本文在文献[3]的基础上,提出一种新的基于双

检测器系统的长期目标跟踪算法.主要贡献如下:(1)加入检测速度较快的 SVM 检测器和检测精度较高的孪生网络检测器的双检测器的重新检测系统.在跟踪过程中,若发生目标丢失的情况时,通过两个检测器的协同工作,可以准确找到目标并持续跟踪.(2)对空间正则化权重进行每帧更新,实现空间权重的自适应,进一步降低边界效应的影响,提高相关滤波器的鲁棒性;(3)采用 ADMM 迭代算法对目标函数进行优化求解,降低模型的计算复杂度.

2 算法整体框架

本文提出的算法框架如图 1 所示,大致分为三个部分:目标跟踪部分,目标信息处理部分和检测器部分.在处理第一帧图像时,需要分别提取包含背景的图像和目标图像的特征来训练初始滤波器 F_1 和 F_2 .在目标信息处理部分,选择提取图像的梯度方向直方图(HOG)特征,并计算最大响应值来判断跟踪状态;在目标跟踪部分,选用一种改进的梯度方向直方图特征,即 31 维梯度方向直方图特征(f HOG),该特征在反应目标图像的边缘信息和根据局部梯度将图像的局部外观和形状特征化方面有着较好的表现,且能够很好的应对光照变化和形变等情况^[5].检测器部分由 SVM 检测器和孪生网络检测器组成,分别记为 Det1 和 Det2.




图 1 算法整体框架图

3 长期跟踪算法

3.1 主体算法模型

文献[3]提出的空间正则化相关滤波算法中,使用空间惩罚权重减少边界效应的影响.其目标函数如下:

$$E(F) = \frac{1}{2} \left\| \sum_{K=1}^K \mathbf{x}_k * \mathbf{f}_k - \mathbf{y} \right\|^2 + \frac{\lambda}{2} \sum_{K=1}^K \left\| \hat{\mathbf{w}} \odot \mathbf{f}_k \right\|^2 \quad (1)$$

式中,滤波器 $\mathbf{F} = [\mathbf{f}_1, \mathbf{f}_2, \dots, \mathbf{f}_K]$. 公式第一项为岭回归项, K 表示通道总数, $\mathbf{x}_K$ 表示第 K 个样本的特征, $\mathbf{f}_K$ 表示对应的第 K 个滤波器;第二项为正则化

项,其中 $\tilde{\mathbf{w}}$ 为负高斯权重,即从图像中心到四周的正则化空间惩罚系数逐渐增大。 λ 为正则化参数。

从图1中可以看出,本文算法目标跟踪部分预测的目标位置会对算法后面的预测目标准确性的判定上造成直接影响。所以需要有一个较为稳定的相关滤波器,降低漂移现象发生的概率。由此,本文对式(1)中的空间权重进行每帧更新,让其可以针对当前跟踪的实际情况自适应的调整目标区域的空间正则化权重。算法目标函数如下:

$$E(\mathbf{F}, \mathbf{w}) = \frac{1}{2} \left\| \sum_{K=1}^K \mathbf{x}_K * \mathbf{f}_K - \mathbf{y} \right\|^2 + \frac{\lambda_1}{2} \sum_{K=1}^K \left\| \mathbf{w} \odot \mathbf{f}_K \right\|^2 + \frac{\lambda_2}{2} \left\| \mathbf{w} - \mathbf{w}^r \right\|^2 \quad (2)$$

式中, $\mathbf{w}$ 为自适应空间正则化权重,即在跟踪每一帧图像时,都会根据当前帧图像信息对其更新。第三项中为了防止模型退化,引入 $\mathbf{w}$ 的先验参考权重 $\mathbf{w}^r$ 。 λ_1 和 λ_2 为正则化参数。

3.2 模型的优化

由于目标函数无法求出闭式解,因此将交替方向乘子法(ADMM)用于本文目标函数的优化求解。首先构造约束项: $\mathbf{f} = \mathbf{g}$,加入惩罚项系数,则式(1)的不带约束项的增广拉格朗日公式可以写为:

$$L(\mathbf{F}, \hat{\mathbf{G}}, \mathbf{w}, \hat{\mathbf{S}}) = \frac{1}{2} \left\| \sum_{K=1}^K \hat{\mathbf{x}}_K \hat{\mathbf{f}}_K - \hat{\mathbf{y}} \right\|^2 + \frac{\lambda_1}{2} \sum_{K=1}^K \left\| \mathbf{w} \odot \mathbf{g}_K \right\|^2 + \frac{\lambda_2}{2} \left\| \mathbf{w} - \mathbf{w}^r \right\|^2 + \frac{\mu}{2} \sum_{K=1}^K \left\| \hat{\mathbf{f}}_K - \mathbf{g}_K + \hat{\mathbf{s}}_K \right\|^2 \quad (3)$$

式中,符号“ $\odot$ ”为对应乘子的离散傅里叶变换表示, s 为拉格朗日乘子,且 $\mathbf{S} = [\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_K]$, μ 为步进参数。样本 $\mathbf{x}_K$ 大小为 $M \times N$ 。然后应用ADMM算法可以将式(3)分解为四个子问题的求解。

子问题1:求解 f ,假设式(3)中的 g, w 和 s 都是确定值,则 f 的优化函数式可以表示为:

$$E(\hat{\mathbf{f}}) = \arg \min_{\hat{\mathbf{f}}} \left\{ \frac{1}{2} \left\| \sum_{K=1}^K \hat{\mathbf{x}}_K * \hat{\mathbf{f}}_K - \hat{\mathbf{y}} \right\|^2 + \frac{\mu}{2} \left\| \hat{\mathbf{f}}_K - \hat{\mathbf{g}}_K + \hat{\mathbf{x}}_K \right\|^2 \right\} \quad (4)$$

对上式求解的计算复杂度很高,因此考虑在所有通道上处理每个元素的方法。式中样本集大小为 $M \times N$,则可以分为 $M \times N$ 个子问题,每个子问题的目标函数如下:

$$E(\hat{\mathbf{f}}) =$$

$$\arg \min_{V_j(\hat{\mathbf{f}})} \left\{ \frac{1}{2} \left\| V_j(\hat{\mathbf{x}})^T V_j(\hat{\mathbf{f}}) - \hat{\mathbf{y}}_j \right\|^2 + \frac{\mu}{2} \left\| V_j(\hat{\mathbf{f}}) - V_j(\hat{\mathbf{g}}) + V_j(\hat{\mathbf{s}}) \right\|^2 \right\} \quad (5)$$

令 $\frac{d(E(\hat{\mathbf{f}}))}{d(V_j(\hat{\mathbf{f}}))} = 0$,可以得到:

$$V_j(\hat{\mathbf{f}}) = \frac{1}{\mu} \left(I - \frac{V_j(\hat{\mathbf{x}})^T V_j(\hat{\mathbf{x}})}{\mu - V_j(\hat{\mathbf{x}})^T V_j(\hat{\mathbf{x}})} \right) \cdot \mathbf{P} \quad (6)$$

式(6)中 $\mathbf{P} = V_j(\hat{\mathbf{x}}) \hat{\mathbf{y}}_j + \mu(V_j(\hat{\mathbf{g}}) - V_j(\hat{\mathbf{s}}))$,最后子问题的解 f 由离散傅里叶逆变换得到。

子问题2:求解 g ,假设 f, w 和 s 都是已知的确定值,则 g 的优化函数可以表示成:

$$E(G) = \arg \min_G \left\{ \frac{\lambda_1}{2} \left\| \mathbf{W} \odot G \right\|^2 + \frac{\mu}{2} \left\| f - G + s \right\|^2 \right\} \quad (7)$$

$\mathbf{G} = [\mathbf{g}_1, \mathbf{g}_2, \dots, \mathbf{g}_K]$ 为所有通道的 g 的向量化表示; $\mathbf{W}$ 为所有空间正则化权重 w 对角化后的矩阵,即 $\mathbf{W} = \text{diag}(\mathbf{w})$ 。令 $\frac{d(E(G))}{d(G)} = 0$,则子问题的解为:

$$\mathbf{g} = (\mathbf{W}^T \mathbf{W} + \mu \mathbf{I})^{-1} \mu (f + s) \quad (8)$$

子问题3:求解正则化权重 w ,假设 g, f 和 s 都是已知量,则其解可以表示为:

$$E(\mathbf{w}) = \arg \min_{\mathbf{w}} \left\{ \frac{\lambda_1}{2} \sum_{K=1}^K \left\| N_K \mathbf{w} \right\|^2 + \frac{\lambda_2}{2} \left\| \mathbf{w} - \mathbf{w}^r \right\|^2 \right\} \quad (9)$$

式中, $N_K = \text{diag}(\mathbf{g}_K)$ 。为了求得空间权重更有效的收敛值,在求解权重时需要使用额外的ADMM算法进行计算,由此求出解为:

$$\mathbf{w} = (\lambda_1 \sum_{K=1}^K N_K^T N_K + \lambda_2 \mathbf{I})^{-1} \lambda_2 \mathbf{w}^r \quad (10)$$

子问题4:拉格朗日乘子的更新表达式为:

$$\hat{\mathbf{s}}^{(i+1)} = \hat{\mathbf{s}}^{(i)} + \hat{\mathbf{f}}^{(i+1)} - \hat{\mathbf{g}}^{(i+1)} \quad (11)$$

式中, $\hat{\mathbf{f}}^{(i+1)}$ 和 $\hat{\mathbf{g}}^{(i+1)}$ 为上述两个相应子问题迭代后的结果。步进参数 μ 的更新方式为:

$$\mu^{(i+1)} = \min(\mu_{\max}, \beta \mu^{(i)}) \quad (12)$$

综上所述,ADMM算法的计算复杂度小,可以非常高效的求出目标函数的解。本文通过两次迭代计算,可以分别得到 f, g, w 和 s 的收敛值,进而求出相应的滤波器并进行后续操作。

3.3 重新检测

现有算法在进行长视频跟踪时,一旦引入背景噪声或其他原因导致跟踪失败,则整个跟踪过程都将失败。本文算法中加入了重新检测模块,该模块由一个SVM分类器^[4](Det1)和一个孪生网络检测器(Det2)组成,可以重新检测出图像中的目标。

SVM 分类器使用分类的方法可以快速地当前图片的目标区域做出一定的检测判断,适用于相对简单的图片信息.其通过跟踪的目标位置和目标尺度绘制密集的训练样本,并根据样本与目标的重叠率为样本添加正负标签来逐步对分类器进行训练.假设在一帧图像中采集到 N 个样本,则训练集为 $\{(\mathbf{v}_i, c_i) \mid i = 1, 2, \dots, N\}$; 式中的 $\mathbf{v}_i$ 为第 i 个样本的特征向量,类别标签 $c_i \in \{-1, +1\}$. 令超平面 $\mathbf{h}$ 的损失函数为 $\ell(\mathbf{h}_i) = \max\{0, 1 - c\langle \mathbf{h}_i, \mathbf{v}_i \rangle\}$, 符号 $\langle \mathbf{h}, \mathbf{v} \rangle$ 表示 $\mathbf{h}$ 和 $\mathbf{v}$ 的内积. 由此可列目标函数为:

$$\min_h \frac{\lambda}{2} \|\mathbf{h}_i\|^2 + \frac{1}{N} \sum_{i=1}^N \ell(\mathbf{h}_i) \quad (13)$$

为了在后续的检测器更新时可以更有效的求出超平面,使用在线被动攻击学习^[6] 算法更新分类器的超平面参数:

$$\mathbf{h}^{(i+1)} = \mathbf{h}^{(i)} - \frac{\ell(\mathbf{h}_i)}{\|\nabla_{\mathbf{h}} \ell(\mathbf{h}_i)\|^2 + \frac{1}{2\tau}} \nabla_{\mathbf{h}} \ell(\mathbf{h}_i) \quad (14)$$

式中, $\nabla_{\mathbf{h}} \ell(\mathbf{h}_i)$ 为关于超平面 $\mathbf{h}$ 的损失函数的梯度, $\tau \in (0, +\infty)$ 为控制 $\mathbf{h}$ 更新率的超参数.

当面对较为复杂的背景信息时, Det1 的检测效果下降明显, 此时选择启用孪生网络检测器. 因为深度学习相关的跟踪算法特点是可以清晰的表达目标特征, 在面对较为复杂的情况时, 也可以拥有较强的鲁棒性. 考虑到深度学习方面的速度弱势, 本文算法使用 Luca 等人提出的一种全卷积孪生网络^[7] 的方法, 该算法使用较为简单的网络结构取得了很好的跟踪结果, 同时简单的网络结构和端到端的离线训练方法让算法运行速度变的很快.

同时为了保证特征提取的清晰度, 在孪生网络结构中加入 VGGNet 提取图像的深度特征^[8]. 由于该检测器需要检测目标, 所以在网络结构中加入一个额外的目标模板池, 作用是可以产生多个候选目标区域, 并从中选择出与模板分支最接近的区域作为目标区域. 候选区域的选取范围是以目标跟踪部分得到的位置为中心, 边长为 $\rho(\omega^2 + h^2)^{\frac{1}{2}}$ 的正方形区域, 其中 ω 和 h 分别为当前帧中估计得到的目标宽度和高度, ρ 为控制区域大小的权重系数.

检测器 Det2 在第一帧图片时根据给定的目标信息训练检测器, 即使用 k 均值聚类的方法将目标与背景进行分类, 作为目标模板池. 后续跟踪过程中, 在得到了多个候选区域之后, 再通过孪生网络分

别计算出每个候选区域与目标模板的欧氏距离作为匹配相似度, 并选出相似度最高的区域作为跟踪目标. 由此可列公式:

$$\hat{s} = \underset{s_i}{\operatorname{argmax}} v(p, s_i), i = 1, 2, \dots, N \quad (15)$$

式中, $\hat{s}$ 表示每个候选区域的相似分数, $\{s_i\}_{i=1}^N$ 表示 N 个候选区域的样本集, $v(p, s_i)$ 表示跟踪目标 p 与第 i 个候选样本 s_i 的相似度分数.

Det1 在每次跟踪可靠性高的时候都会进行正负样本更新, 保证检测器中存有较新的目标状态; Det2 中由于使用深度网络, 检测的结果更加的准确, 但是运行花费时间较多. 综合考虑之下, 本文算法中选择速度较快且检测结果较为准确的 Det1 作为主检测器, 当结果显示检测失败的时候启动 Det2 再次检测目标.

算法中通过比较与相关阈值的大小关系, 判断当前跟踪状态. 即当目标信息处理部分的最大响应值小于重新检测阈值 T_b 时, 启动检测器使其对当前帧图片的视野区域进行重新检测; 若重新检测得到的结果可靠性更高则更新位置信息, 若发生遮挡等原因导致两个检测器都无法检测出目标, 则保留目标跟踪部分的目标位置并进行下一帧图像的处理, 等待目标重新出现. 这样既能保证检测器中的目标信息与目标最新状态最接近, 还能避免检测器在不必要的时候依然工作浪费大量计算时间.

4 实验结果与分析

4.1 参数设置与实验评估指标

本实验中使用 31 维梯度方向直方图特征进行尺度估计, 目标跟踪部分的空间正则化参数 $\lambda_1 = 1.2, \lambda_2 = 0.001$, 学习率 $\eta = 0.025$, ADMM 优化求解过程中, 在处理第一帧图像时将空间正则化权重 ω^r 初始化为负高斯形状矩阵, 步进参数 $\mu^{(0)}, \mu_{\max}$ 和尺度因子 β 分别设置为 $1, 10^4$ 和 10 , 迭代次数为 2 次. 目标信息处理部分的正则化参数设置为 $\lambda = 0.0001$, 控制检测器更新阈值 $T_a = 0.25$, 控制启动检测器的阈值 $T_b = 0.1$, 式(14)中 $\tau = 1$. 实验所用编程软件为 MATLAB R2017a, 硬件配置为 Intel i7-8700K, 3.7 GHz CPU, 8GB 内存的主机, 使用 Windows10 系统.

使用目标跟踪基准(OTB)数据集 OTB-2013^[9] 和 OTB-2015^[10] 评估本文算法的性能. 数据集中涉及到灰度图像和彩色图像以及目标跟踪的 11 个属性: 光照变化、尺度变化、遮挡、形变、运动模糊、快速运动、

平面内旋转、平面外旋转、出视野、背景干扰、低像素等.数据集的一次评估(OPE)模式,提供两种评价指标:精度测算和成功率测算.精度测算指预测位置的 中心与实际位置中心的欧氏距离是否小于阈值 20 像素的帧数所占总帧数的百分比;成功率测算指的是预测图像窗口与实际目标窗口之间的重合比率是否大于阈值 0.5 的帧数所占总帧数的百分比.

4.2 实验分析

4.2.1 长期跟踪有效性实验

本文算法致力于长视频序列目标跟踪,为验证算法进行长期跟踪时的性能,选择数据集 OTB-2015 中最长的 16 个视频序列进行实验,其中每个序列都包含超过 1 000 帧图像.将本文算法 Ours 与基准算法 SRDCF 和相似算法 LCT 进行比较,跟踪结果如表 1 所示.从表中可以看出本文算法比基准算法在距离精度(Precision)和成功率(Success)上分别提高了 12.9%和 6.2%,比相似的算法提高了 13.5%和 17.5%,性能有了一定程度的提升.

表 1 长视频序列的距离精度和成功率

	Ours	SRDCF	LCT
Precision	0.824	0.695	0.689
Success	0.632	0.570	0.457

4.2.2 重新检测有效性实验

本节中,将本文算法记为 Ours,将只加入自适应空间正则化方法但是没有加入重新检测系统的算法记为 Ours_ND,选取两种算法在实际跟踪时的几个视频序列进行实验结果对比分析,如图 2 所示.




图 2 两种算法的跟踪结果对比图

从图 2 中可以看出两种算法在跟踪前面部分的图像序列时,目标边界框完全重合,这是因为前面跟踪到的目标可靠性高,重新检测部分只执行更新检

测器的操作,并不会对当前帧图像进行重新检测.但是在后续跟踪过程中,由于不同原因都发生了目标丢失的情况,只有算法 Ours 重新找回目标并持续跟踪.由此可以看出重新检测系统可以有效的纠正算法的跟踪错误.

4.2.3 实验分析与比较

本节进行的实验中,将本文算法分别使用 OTB-2013 和 OTB-2015 两个数据集进行性能评估,并分别对实验结果进行定量分析和定性分析.得到的距离精度曲线和成功率曲线与六个近几年较新的算法结果进行比较;对比算法包括 SRDCF^[3], SiamFC^[7], PTAV^[8], UDT^[11], CACF^[12], CF-Net^[13].实验结果如图 3、图 4 和图 5 所示.

由图 3 可知,本文算法在两个数据集中都取得了非常好的效果.在跟踪成功率上,算法 Ours 比基础算法 SRDCF 分别高了 2.8%和 2.7%.这说明本文算法在跟踪时的目标窗口与实际目标窗口的重叠率更高,跟踪更准确.图 4 为七种算法在两个数据集上几种表现突出的特性的跟踪成功率曲线图.从图上可以看出本算法在平面旋转方面和形变两种特性上提高很大.主要因为:自适应空间正则化权重通过抑制背景信息充分突出目标区域;检测器存储了最新的目标变化情况,使得模型可以较为清晰的知道目标的最新状态,因此可以更加准确的检测并跟踪目标.

图 5 为算法的定性分析结果图,选取数据集中的 5 个不同场景进行分析,即背景干扰,平面旋转,遮挡,尺度变换.在(a) bolt2 序列中,目标和背景相似度高容易导致跟踪器跟踪错误,算法 PTAV,CF-Net,UDT 在序列前几帧时就已经丢失了正确的目标,本文算法 Ours 一直在持续跟踪.视频序列(d) sylvester 中,目标物体发生了平面旋转后其属性也发生了一定的改变,导致很多算法丢失目标,只有本文算法和 UDT 算法可以一直准确跟踪.遮挡在视频序列中非常常见,如(e)bird1 序列中第 122 帧处,发生接近 60 帧的云彩遮挡,(c)human3 的第 43 帧和第 95 帧图像处,出现了两次的短期遮挡,当遮挡过后,目标重新出现时本文算法可以在第一时间重新检测到目标并持续跟踪.视频序列(b) skater2 中,目标的远近移动导致目标尺度的不停变化,本文算法可以随着目标的移动计算出稳定的尺度结果.

综合以上的实验结果可以看出,本文算法加入了双检测器的重新检测机制和自适应空间正则化项后,使目标图像更加突出,并通过更新存储目标的最新状态,使算法具有较高的鲁棒性.




图 3 算法在数据集上的距离精度和成功率曲线图




图 4 几种特性的跟踪成功率曲线图

5 结束语

本文在空间正则化滤波算法的基础上,提出一种双检测器系统的长期跟踪算法.即加入了两个检测器,通过它们之间的协同工作,可以在目标丢失的时

候找回目标;还加入了自适应空间正则化项用来抑制图像背景,并使用更快速的优化方法,大大减少计算复杂度,节省运行时间.实验表明,本文提出的算法有着很好的鲁棒性,特别是进行长视频序列的跟踪时效果提升显著.在以后的研究中,将会尝试扩大检测器




图5 跟踪算法的结果对比

的搜索范围,同时尝试针对不同的场景启用不同检测器的方式,使模型可以更高效更鲁棒的工作。

参考文献:

- [1] BOLME D S, BEVERIDGE J R, DRAPER B A, et al. Visual object tracking using adaptive correlation filters[C]//Proceedings of 2010 IEEE Computer Society Conference on Computer Vision and Pattern. San Francisco: IEEE, 2010: 2544-2550. DOI: 10.1109/CVPR.2010.5539960.
- [2] 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. DOI: 10.1109/TPAMI.2014.2345390.
- [3] DANELLJAN M, HUGER G, KHAN F S, et al. Learning spatially regularized correlation filters for visual tracking[C]//Proceedings of 2015 IEEE International Conference on Computer Vision. Santiago, Chile: IEEE, 2015: 4310-4318. DOI: 10.1109/ICCV.2015.490.
- [4] MA C, HUANG J B, YANG X K et al. Adaptive correlation filters with long-term and short-term memory for object tracking[J]. International Journal of Computer Vision, 2018, 126(8): 771-796. DOI: 10.1007/s11263-018-1076-4.
- [5] FELZENSZWALB P F, GIRSHICK R B, MCALLESTER D, et al. Object detection with discriminatively trained part-based models[J]. IEEE Transactions

on Pattern Analysis and Machine Intelligence, 2010, 32(9): 1627-1645. DOI: 10.1109/TPAMI.2009.167.

- [6] CRAMMER K, DEKEL O, KESHET J, et al. On-line passive-aggressive algorithms[J]. The Journal of Machine Learning Research, 2006(7): 551-585.
- [7] BERTINETTO L, VALMADRE J, HENRIQUES J F, et al. Fully-convolutional Siamese networks for object tracking[C]//Proceedings of European Conference on Computer Vision. Amsterdam, the Netherlands: Springer, 2016: 850-865. DOI: 10.1007/978-3-319-48881-3_56.
- [8] FAN H, LING H B. Parallel tracking and verifying: a framework for real-time and high accuracy visual tracking[C]//Proceedings of 2017 IEEE International Conference on Computer Vision. Venice, Italy: IEEE, 2017: 5487-5495. DOI: 10.1109/ICCV.2017.585.
- [9] WU Y, LIM J, YANG M H. Online object tracking: a benchmark[C]//Proceedings of 2013 IEEE Conference on Computer Vision and Pattern Recognition. Portland: IEEE, 2013: 2411-2418. DOI: 10.1109/CVPR.2013.312.
- [10] WU Y, LIM J, YANG M H. Object tracking benchmark[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1834-1848. DOI: 10.1109/TPAMI.2014.2388226.
- [11] WANG N, SONG Y B, MA C, et al. Unsupervised deep tracking[C]//Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019: 1308-1317. DOI: 10.1109/CVPR.2019.00140.
- [12] MUELLER M, SMITH N, GHANEM B. Context-aware correlation filter tracking[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 1387-1395. DOI: 10.1109/CVPR.2017.152.
- [13] VALMADRE J, BERTINETTO L, HENRIQUES J, et al. End-to-end representation learning for correlation filter based tracking[C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 5000-5008. DOI: 10.1109/CVPR.2017.531.

作者简介:

胡昭华 女,(1981-),博士,副教授.研究方向为视觉跟踪、模式识别. E-mail: zhaohua_hu@163.com.

李奇 男,(1995-),硕士研究生.研究方向为计算机视觉、模式识别.

韩庆 男,(1996-),硕士研究生.研究方向为目标跟踪、机器学习.