

基于融合特征多尺度的抗遮挡核相关滤波算法

王兴¹ 毛羽忻² 江凯¹ 毛征¹

(1.北京工业大学 北京 100124; 2.北方车辆研究所 北京 100072)

摘要: 针对传统相关滤波算法进行改进,以提高算法在目标发生尺度变化、遮挡形变等复杂场景时的跟踪性能,提出一种融合尺度自适应和重检测机制的鲁棒性能的跟踪算法。该算法在融合 FHOG 和 CN 两种互补特征基础上,引入一种尺度自适应策略解决了尺度变化的问题,此外还进一步优化了模型更新策略并加入重检测机制,增强算法鲁棒性能。通过 OTB100 数据集测试结果表明,所提出算法相对于 KCF 算法精确度和成功率分别提升 4.9% 和 17%,平均跟踪速度为 45 帧/s,且在遮挡、尺度变化和光照变化等场景下表现优异,能有效实现长期跟踪目标。

关键词: 目标跟踪;模型更新;尺度估计;重检测机制

中图分类号: TP391 **文献标识码:** A **国家标准学科分类代码:** 520.4030

Multi-scale anti-occlusion kernel correlation filtering algorithm based on fusion features

Wang Xing¹ Mao Yuxin² Jiang Kai¹ Mao Zheng¹

(1. Beijing University of Technology, Beijing 100124, China; 2. Northern Vehicle Research Institute, Beijing 100072, China)

Abstract: The traditional correlation filtering algorithm is improved to improve the tracking performance of the algorithm in complex scenes such as scale change and occlusion deformation. A robust tracking algorithm combining scale adaptation and re detection mechanism is proposed. Based on the fusion of FHOG and CN complementary features, a scale adaptive strategy is introduced to solve the problem of scale change. In addition, the model updating strategy is further optimized and the re detection mechanism is added to enhance the robustness of the algorithm. The OTB100 dataset test results show that the accuracy and success rate of the proposed algorithm are improved by 4.9% and 17%, respectively, compared with KCF algorithm. The average tracking speed is 45 frames/s, and the performance is excellent in occlusion, scale change and illumination change scenes, which can effectively achieve long-term target tracking.

Keywords: target tracking; model updating; scale estimation; redetection mechanism

0 引言

目标跟踪对计算机视觉领域的发展有着非常重要的意义^[1],广泛应用于智能交通管理、人工智能、视频监控等领域。一般来说,目标跟踪的目的就是要确定目标在视频每一帧的位置和尺度信息,并且找到它的运动轨迹。虽然近年来目标跟踪方向取得了显著进展,但仍有许多因素会对跟踪算法的效果造成影响。比如在光照变化、遮挡变形以及尺度变化等复杂场景下跟踪效果较差,难以达到实时的跟踪速度和长期跟踪的要求。

近年来,基于判别方法的单目标跟踪算法性能得到了显著提升,这其中跟踪-学习-检测^[2](tracking-learning-detection, TLD)算法和核相关滤波器^[3](kernel correlation

filter, KCF) 算法是两种比较有代表性的判别式模型, TLD 算法是长时跟踪算法的代表, KCF 算法因为其优良的性能一直是广大学者青睐的算法。判别式模型将目标跟踪看作是一个二元分类问题,通过对目标和背景信息同时进行训练得到一个分类器,进而选取候选样本中概率最高的作为目标。随着 Bolme 等^[4]将相关滤波的概念引入到目标跟踪领域中,提出了误差最小平方和滤波器(minimum output sum of squared error, MOSSE)算法, MOSSE 算法第一次将相关滤波引入了跟踪领域,在保持精确度不输于同时期的算法时速度可以达到 600 多 FPS,引起了很多人的关注。由此,相关滤波跟踪(CFTs)得到了快速的发展。Henriques 等^[5]提出了一套循环结构的核化跟踪(circulant structure of tracking with kernels, CSK)算法,该算法可以

看作是对 MOSSE 算法升级和拓展,引入了核技巧和岭回归方法,跟踪精度有所上升,但是速度有所下降。之后 Henriques 等又提出了核化相关滤波器算法,在 CSK 算法的基础上扩展了多通道方向梯度直方图^[6] (histogram of oriented gradient, HOG) 特征,利用循环矩阵构造训练样本,巧妙地利用快速傅里叶变换大大提高了跟踪速度^[7]。在保证实时性的同时,目标的跟踪精度也得到了提高,但 KCF 算法在当目标发生形变遮挡、目标丢失等复杂场景时,跟踪效果仍不理想。之后 Danelljan 等^[8]提出的 DSST (discriminative scale space tracker) 算法是在 KCF 框架引入尺度自适应策略,很好地解决了 KCF 算法尺度变化问题。同时期 Danelljan 等^[9]在 CSK 的基础上加入颜色名 (color name, CN) 特征^[10],使用主成分分析 (principal components analysis, PCA) 从 11 维颜色特征选取 2 个主要的通道进行处理,并结合灰度特征一起输入 CSK 跟踪器中,提升了跟踪的精确度。

鉴于传统 KCF 算法使用单一的特征描述目标,不能很好地表达目标外观模型;在跟踪过程中目尺度大小发生变化时,由于缺少尺度自适应策略,跟踪框不能根据目标尺度变化灵活的调整大小,导致目标模型不断累积错误信息,容易跟丢目标;此外,由于 KCF 算法模型更新方式采用的是简单的在线更新,当目标发生遮挡或这形变情况时,容易造成模型污染,从而无法继续跟踪目标。本文在 KCF 算法的基础上进行改进,融合了 FHOG 和 CN 颜色特征,采用互补特征的方式增强对跟踪目标外观模型的表达能力,提高算法的鲁棒性;针对尺度变化问题,引入尺度自适应机制,采用尺度金字塔预估出目标的尺度,将最大响应值对应的尺度作为最终结果;通过引入 APCE 模型更新机制,优化模型更新策略,当跟踪结果不可靠时,停止模板更新,启动重检测算法重新定位目标并初始化模型参数,增强了算法的鲁棒性。通过在 OTB100 (object tracking benchmark) 数据集^[11]上测试结果表明,改进后的算法在光照变化、目标发生遮挡形变或者尺度变化等复杂场景下,跟踪效果相对于 KCF 算法有较大提升,并可以达到实时性和长期跟踪的要求^[12]。

1 核相关滤波器

KCF 跟踪算法不同于稀疏采样算法, Henriques 巧妙地将相关滤波器的求解转化为岭回归问题,并采用循环矩阵来训练分类器,之后将运算法转换到频域进行,极大地简化了运算,为了使该算法能够处理非线性分类问题,这里引入了核方法。首先训练最小化回归误差,损失函数可以表示为:

$$\min_{\omega} \sum_i (f(x_i) - y_i)^2 + \lambda \|\omega\|^2 \quad (1)$$

核相关滤波器引入了核函数,通过非线性映射函数 $\omega = \sum_i \alpha_i \varphi(\chi_i)$ 将线性函数映射成非线性,从一维转换到高维空间中,最终得到傅里叶空间中的解:

$$\hat{a} = \frac{\hat{y}}{\hat{k}^{xx} + \lambda} \quad (2)$$

其中, ω 是训练样本线性组合的形式, α 是滤波器系数, \hat{k}^{xx} 为核函数矩阵 $k = C(k^{xx})$ 的第 1 行元素,一旦两个向量元素的次序先后变化不会对核函数计算结果产生影响,那么称这个核函数构成的矩阵为循环矩阵。在样本检测时,基于傅里叶对角化性质,计算循环移位得到的候选样本输出响应值,表示为:

$$\hat{f}(z) = \hat{k}^{xz} \odot \hat{a} \quad (3)$$

为了更好地适应跟踪背景和目标外形的变化,需要对滤波器进行更新,更新模型 \hat{a} 和 \hat{x} 为:

$$\hat{a}_t = (1 - \eta) \hat{a}_{t-1} + \eta \hat{a} \quad (4)$$

$$\hat{x}_t = (1 - \eta) \hat{x}_{t-1} + \eta \hat{x} \quad (5)$$

式中: η 表示学习率; t 表示帧数; \hat{a}_{t-1} 和 \hat{x}_{t-1} 表示上一帧分类器的模板参数和目标外观模型; \hat{a}_t 和 \hat{x}_t 表示当前帧分类器的模板参数和目标外观模型。

2 改进的核相关滤波算法

传统的 KCF 特征单一,没有尺度自适应机制,模型更新方式为简单的在线更新,在复杂的场景下跟踪目标的效果往往不太理想。本文通过融合多通道特征,并引入尺度滤波器进行目标尺度估计,优化模型更新策略等一系列改进策略来提高算法的鲁棒性^[13]。

2.1 多特征融合

在 KCF 核化相关滤波器中,使用单一 FHOG 特征表征目标,不能在跟踪过程中始终保持对目标鲁棒的表征能力。本文融合 FHOG 特征以及 CN 颜色特征两种互补特征对目标外观进行表征, CN 颜色特征注重描述目标的颜色信息,而对目标形变不敏感、跟踪效果较好,对光照变化等情况较为敏感、跟踪效果较差。而 FHOG 特征描述的是边缘特征,在图像发生几何或光学形变时对它影响较小,但是难处理目标遮挡、形变等场景,所以二者的结合能够更好地表征目标外观,提高滤波器对目标和背景的区别能力。本文算法通过提取 31 维 FHOG 特征以及 11 维 CN 特征进行级联得到 42 通道多通道特征矩阵,能够很好地提高滤波器模型对目标的表征能力,减少漂移现象发生。

2.2 尺度自适应策略

本文采用 DSST 算法类似的尺度估计方法,首先利用相关滤波方法获得目标的预估位置,然后采用尺度估计方法,通过训练 1 个一维的尺度滤波器,在已确定的目标位置处根据前一帧目标大小获得多种尺度样本,利用双线性插值方法将这些样本转换到与初始目标块一样的大小,提取外观特征进行检测,最大响应值所对应的样本即为当前目标尺度。尺度自适应核相关滤波器具体步骤如下:

1) 目标模板大小记为 M , 第 $t-1$ 帧的目标尺度大小

记为 S_{i-1} , 由相关滤波器预估的当前帧的位置记为 P_i 。

2) 在 P_i 处以 S_{i-1} 为基准, 提取多种尺度样本块, 记为 $S_j = r^i S_{i-1} (j = 1, 2, \dots, 2l + 1)$, r 是尺度变化因子。

3) 利用双线性插值将尺度为 S_j 的图像块调整到与模板 M 大小相同的尺寸。

4) 然后根据目标的多尺度样本集, 训练得到岭回归的目标模型:

$$\hat{a}^i = \frac{\hat{y}^i}{k^{xz} + \lambda}, \quad i = 0, 1, \dots, 2n + 1 \quad (6)$$

其中, \hat{a}^i 是多尺度目标模型, i 是对应的尺度, x 代表目标的特征, z 代表待检测的图像。

5) 最后根据 \hat{a}^i 计算得到最合适尺度大小:

$$\hat{f}^i(z) = \hat{k}^{xz} \odot \hat{a}^i, \quad i = 0, 1, \dots, 2n + 1, \text{argmax} \hat{f}^i(z) \quad (7)$$

6) 更新滤波器的目标模型参数 a 和目标特征 x , 具体过程见下文。

尺度滤波器工作流程如图 1 所示。




图 1 尺度估计滤波器流程

2.3 改进的模型更新策略

1) 高置信度模型更新策略

传统的相关滤波算法比如 DSST、KCF 都采用在线更新的方式, 缺少一种跟踪结果可靠性的验证机制。或者像 MDNet 或者 TCNN 那样每隔 N 帧更新一次, 当目标被遮挡或者跟踪效果比较差时, 再去更新模型往往会加大背景干扰, 导致模型漂移。文献[14]提出一种 APCE (average peak-to-correlation energy) 模型更新策略, 首先设置一个更新的阈值, 预先判断更新结果的可信度, 从而决定是否对现有的跟踪模型进行更新。提升速度的同时, 能够避免目标模型被污染^[15]。

$$F_{\max} = \max F(s, y, w) \quad (8)$$

$$APCE = \frac{|F_{\max} - F_{\min}|^2}{\text{mean}(\sum_{w,h} (F_{w,h} - F_{\min})^2)} \quad (9)$$

其中, $F_{\max}, F_{\min}, F_{w,h}$ 分别表示响应最高、最低和 (w, h) 位置上的响应。

这个更新方式反映了响应图的震荡程度, APCE 突然减小, 很有可能出现目标遮挡或者目标丢失的情况, 此时 APCE 相对于视频序列 APCE 的历史均值小得多, 应该停止模型更新。当 APCE 如图 2 所示, 图 2(d) 中下方框表示传统的模板更新机制, 上方框代表采用 APCE 的高置信度模型更新策略。目标区域在没有被干扰的情况下, 响应图波动比较小, 但是响应图在被遮挡时震荡剧烈, 可以通过观察响应图震荡程度避免错误更新。第 461 帧发生遮挡时的 APCE 为 12.27, 比 491 帧没有遮挡时的 APCE 小很多。这种情况下选择不更新, 从而避免了模型的漂移。

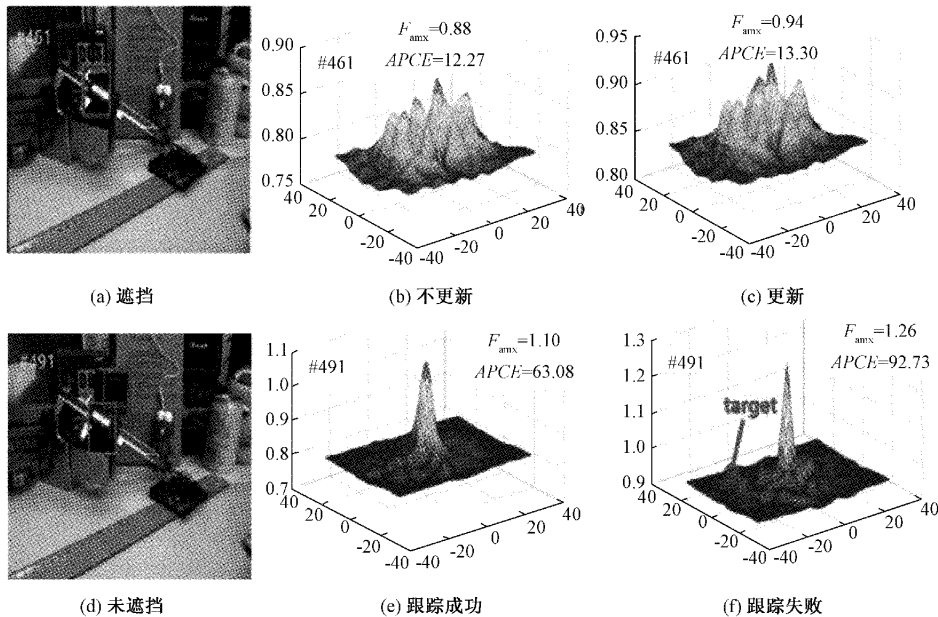


图 2 APCE 实验结果

KCF 中模板参数的 a 的更新方式如式(4)和(5)所示,其中 η 为更新模型的学习率, a_t 为第 t 帧求得的系数矩阵。在采用 APCE 更新机制后,检测到跟踪不可靠时,停止更新。只有当 APCE 和 F_{\max} 都以一定比例大于历史值的时候模型才进行更新,下面是新的模型更新公式。

$$\eta = \begin{cases} 0.02, & (F_{\max} > \sigma_1 * \text{average}(F_{\max})) \& \& \\ & (APCE > \sigma_2 * \text{average}(APCE)) \\ 0, & \text{其他} \end{cases} \quad (10)$$

2) 检测模块

在复杂的场景下,当对象发生快速移动,运动中出现了形态变化,又或者是严重遮挡的情况发生,目标特征就会丢失和变化,导致和目标特征模板之间相似度下降。需要建立目标与特征模板之间的匹配程度度量机制,来确定模型是否发生大的偏移。这里使用上述 APCE 判据来进行可靠性检测,当计算得到的 APCE 值明显比之前的值小时,就认为跟踪结果表现很差,出现了严重遮挡或者形变,需要放弃此帧的跟踪结果,重新执行目标检测算法根据结果重新初始化模型。如果检测到目标可靠,那么根据结果重新初始化目标位置并更新模型,否则进入下一帧继续检测。这里的检测算法采用 YOLOv3 算法,因为此算法在保持较高的检测精度同时有着较快的速度。

2.4 算法流程

本文算法整体框架如图 3 所示,该算法能同时进行位置与尺度估计,并且优化了模型更新策略。

3 实验结果与分析

3.1 实验环境与评价指标

本程序采用了 C++ 语言,实验运行环境为 MATLAB R2018b, Windows 10 操作系统 64 位, Intel(R) Core (TM) i5-9400F, CPU 2.9 GHz, 8 GB 内存。为了验证算法改进后在复杂场景下的跟踪目标遮挡处理的性能提升,本文使用公开的 OTB100 视频序列进行测试,验证算法在改进后的算法跟踪效果。这些视频序列包含的挑战因素主要包括光照变化(illumination variation, IV), 尺度变化(scale variation, SV), 遮挡(Occlusion, OCC), 非刚性形变(DEFOrmation, DEF), 运动模糊(motion blur, MB), 快速运动(fast motion, FM), 平面外旋转(out-plane-rotation, OPR), 平面内旋转(in-plane-rotation, IPR), 背景杂乱(background clutters, BC), 目标超出图像画面(out-of-view, OV), 图像分辨率低(low resolution, LR)。

为了对本文提出的改进的核相关滤波算法进行性能测试,这里采用 TLD 算法、DSST 算法、CSK 算法和 KCF 算法与本文算法进行对比,本文将这 5 个算法在 100 个视频序列进行性能测试。采用 OTB100 中的精确度图和成功率图 2 种评价方法作为定量评价指标。精确度图表示目标中心位置误差小于 20 pixel 的帧数占视频总帧数的百

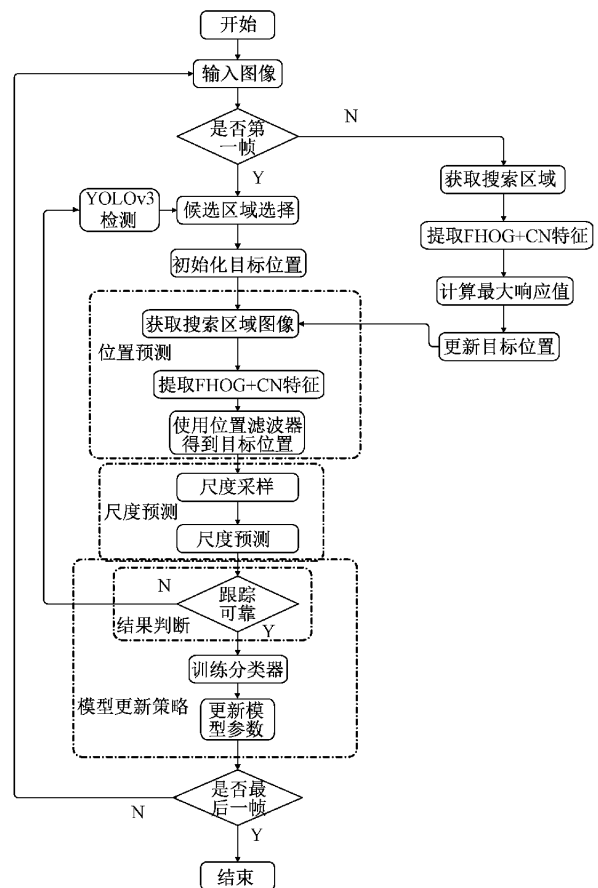


图 3 本文算法流程

分比;成功率图显示重叠率大于 0.5 的帧数占视频序列总帧数。这里主要采用定性分析和定量分析两种分析方式。

3.2 定量分析

1) 总体性能比较

如图 4 所示,本文算法在 OTB100 视频序列的精度为 0.730, 成功率为 0.646, 总体精确度和成功率在 5 个算法中都排第 1, 相比较其他相关滤波及其改进算法整体性能有着显著的提高。相较于 KCF 算法, 本文算法的精度和成功率分别提高了和 4.9% 和 17%。

2) 不同场景性能分析

为了充分对比针对不同场景各个算法的性能差异, 图 5 是 OTB100 数据集中包含的光照变换, 遮挡, 变形和尺度变换情况下的精度图和成功率图。从跟踪结果可以看出本文算法在各个场景下表现优异, 也说明了改进算法相较于 KCF 算法在复杂跟踪场景中具有更好的鲁棒性和跟踪效果。

3.3 定性分析

本节选取 OTB100 基准数据集的部分视频序列做定性分析, 主要包含遮挡、形变、尺度变化和光照变化、快速运动等场景的测试序列, 分析对比 TLD、KCF、DSST 以及本文算法的跟踪测试结果。如图 6 所示, 从上到下展示了

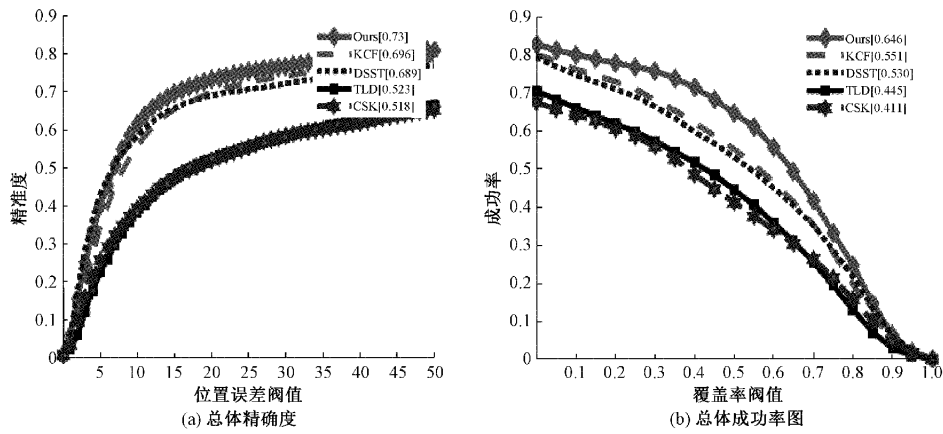








图 4 精确度和成功率图



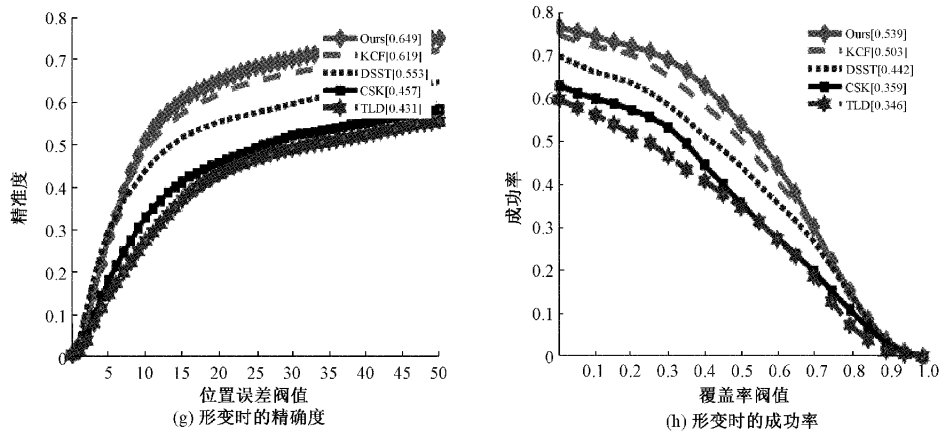


图 5 不同场景 OPE 跟踪精度和成功率

这些算法依次在 (a) Jogging1, (b) Singer1, (c) Lemming, (d) Tiger2, (e) CarScale, (f) Dog1, (g) Car4 测试序列上的跟踪结果。表 1 所示为这 7 段视频序列的详细信息, 这些视频序列基本包含了跟踪过程中面临的主要挑战。

表 1 实验中的测试视频序列

视频序列	帧数	主要影响因素
Jogging1	308	尺度、遮挡、快速运动、旋转
Singer1	351	光照变化、尺度变化、形变
Lemming	1 336	遮挡、尺度变化、快速运动
Tiger2	365	光照变化, 遮挡, 形变, 目标丢失
CarScale	253	尺度变化, 遮挡, 旋转, 快速移动
Dog1	1 350	尺度变化, 旋转
Car4	659	光照变化, 尺度变化

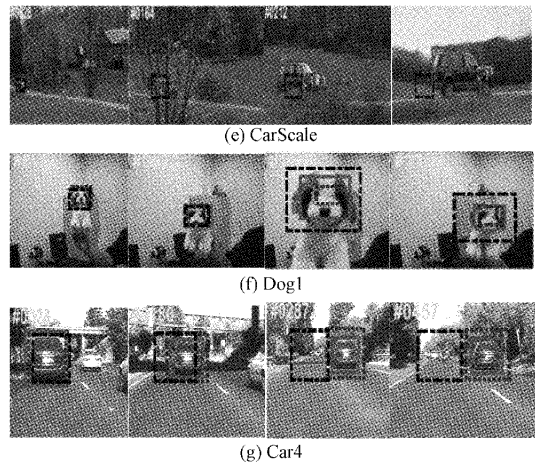
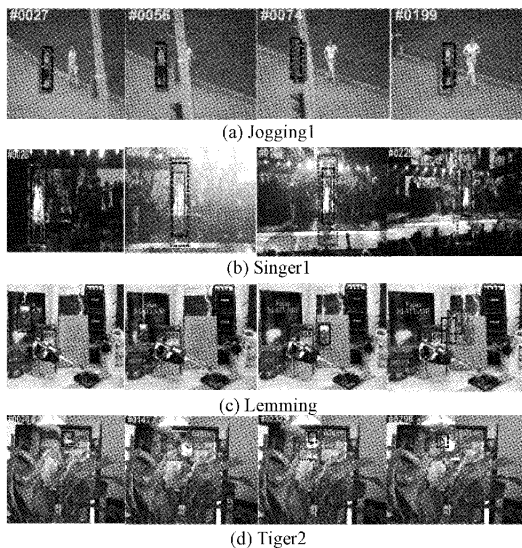


图 6 不同算法的跟踪结果比较

图 6 中, 实线代表本文算法, 虚线代表 DSST 算法, 实线和虚线组合代表的是 TLD 算法, 短实线代表 KCF 算法。



1) 遮挡重检测分析

图 6(a) Jogging1、(c) Lemming 和 (d) Tiger2 视频序列都存在严重遮挡情况, 这里主要观察 KCF 和本文改进算法跟踪效果。图 6(a) Jogging1 视频中, 存在遮挡, 形变, 快速运动现象, 当目标在第 74 帧发生遮挡后重新出现在视野中, 除了本文算法和 TLD 算法一直有效跟踪目标, 其他算法都在目标发生遮挡后跟丢目标, 说明本文算法改进了模型更新机制的有效性, 在目标被遮挡后停止模型更新, 采用检测算法重新定位目标并初始化模型, 避免发生漂移。图 6(c) Lemming 视频中主要有光照变化, 遮挡, 快速运动等场景, 当目标被遮挡后, 只有本文算法和 TLD 算法能快速准确地重新定位到跟踪目标, 之后 TLD 算法跟丢了目标, 只有本文算法一直保持着较好的跟踪效果。图 6(d) Tiger2 视频序列存在遮挡, 形变, 目标丢失等场景, 从 28 帧开始被不断被遮挡和移动, 其他算法都发生了不同程度漂移现象, 只有本文算法能一直较准确的跟踪目标。结果表明, 本文算法通过改进模型更新机制能有效应对遮挡情况。

2) 尺度变化分析

图 6(e) CarScale 视频中主要存在尺度变化, 遮挡, 旋

转,快速移动现象,目标由近及远经历了显著的尺度和外观变化,本文算法对尺度外观模型自适应更新,跟踪结果准确有效,表现优于其他几种算法。图6(b) Singer1 视频序列中,目标逐渐变小,只有本文算法和 TLD 算法对目标尺度变化鲁棒性较好,跟踪准确度较高,而其他如 KCF 算法由于缺少尺度自适应策略,跟踪效果不理想。结果表明,本文提出的尺度自适应策略能有效应对跟踪目标尺度变化问题。

3) 其他因素分析

本文提出的算法除了在尺度变化,遮挡形变等情景下具有良好的鲁棒性,其他如快速移动,光照变化,背景杂乱等因素下效果也有明显提升。如在图6(d) Tiger2 和(g) Car4 的光照变化问题,以及在图6(a) Jogging1 和(e) CarScale 中涉及快速运动问题等;本文算法均可以长期、稳定地跟踪。在视频序列的跟踪结果可以看出,4种算法中,本文算法跟踪精确度和鲁棒性最好,具有较好的应用前景。

4 结 论

本文提出了一种抗遮挡的融合多特征尺度自适应相关滤波跟踪算法,通过融合 CN 颜色特征,来弥补 FHO 单一特征应对复杂环境适应能力差的不足,增强了对目标外观模型的表征能力。在多特征核相关滤波器的基础上,提出了一种自适应尺度的变换方法,通过训练分类器获得最大响应值所在的尺度特征即为最合适的目标尺度,从而可以更好地应对尺度变换;在此基础上通过引入高置信度模型更新策略,当判断出跟踪结果不可靠时,停止模型更新,通过目标检测算法重新定位目标位置,初始化跟踪模型,实现长期稳定的目标跟踪。实验部分通过在标准数据集 OTB100 的 100 个视频序列进行测试,通过定量和定性分析得出结论,本文算法相较于 KCF 算法跟踪性能有较大提升,具有一定的理论和应用研究价值。下一步研究可以尝试将单目标跟踪扩展到多目标跟踪,并且可以考虑利用 GPU 的强大算力,结合 CUDA 编程优化算法。

参考文献

- [1] 张微,康宝生. 相关滤波目标跟踪进展综述[J]. 中国图象图形学报, 2017, 22(8):1017-1033.
- [2] KALAL Z, MIKOLAJCZYK K, MATAS J. Tracking-learning-detection[J]. IEEE Transactions on Software Engineering, 2011, 34(7):1409-1422.
- [3] HENRIQUES J F, CASEIRO R, MARTINS P, et al. High-speed tracking with kernelized correlation filters[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, 37(3):583-596.
- [4] BOLME D S, BEVERIDGE J R, DRAPER B A, et al.

Visual object tracking using adaptive correlation filters[C]. The Twenty-Third IEEE Conference on Computer Vision and Pattern Recognition, 2010, 44(6):13-18.

- [5] HENRIQUES J F, RUI C, MARTINS P, et al. Exploiting the circulant structure of tracking-by-detection with kernels[C]. Proceedings of the 12th European Conference on Computer Vision, 2012, 13(10):23-41.
- [6] 王松. 基于视频的运动检测和跟踪技术研究[D]. 杭州:浙江大学, 2017.
- [7] 张晓玄. 基于相关滤波器的单目标跟踪算法研究[D]. 无锡:江南大学, 2018.
- [8] 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.
- [9] DANELLJAN M, KHAN F S, FELSBERG M, et al. Adaptive color attributes for real-time visual tracking[C]. IEEE Conference on Computer Vision & Pattern Recognition, 2014, 35(3):17-23.
- [10] DANELLJAN M, KHAN F S, FELSBERG M, et al. Adaptive color attributes for real-time visual tracking[J]. IEEE Conference on Computer Vision and Pattern Recognition, 2014, 21(3):1090-1097.
- [11] WU Y, LIM J, YANG M H. Object tracking benchmark[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, 37(9):1834-1848.
- [12] 贺倩倩. 目标检测与跟踪系统的设计与实现[D]. 西安:西安电子科技大学, 2018.
- [13] 程语嫣,张九根,杨圣伟. 多特征融合和尺度适应的相关滤波跟踪算法[J]. 计算机工程与设计, 2020, 41(12):3444-3450.
- [14] 孙蕾. 尺度特征自适应的相关滤波跟踪算法研究[D]. 南京:南京邮电大学, 2018.
- [15] 李牧子. 基于图像识别的目标检测与跟踪系统的设计与实现[D]. 北京:北京邮电大学, 2019.

作者简介

王兴, 硕士研究生, 主要研究方向为图像处理、目标跟踪。
E-mail: 1024034775@qq.com

毛羽忻, 博士, 主要研究方向为三维图形处理技术。
E-mail: m_williamm@sina.com

江凯, 硕士研究生, 主要研究方向为系统仿真、数据融合。
E-mail: 602066755@qq.com

毛征, 博士, 教授, 主要研究方向为光电信息处理, 系统仿真。
E-mail: maozheng@bjut.edu.cn