

基于多阶段学习的相关滤波目标跟踪

孙航, 李晶, 杜博, 肖雅夫, 胡云玲

(武汉大学计算机学院, 湖北武汉 430072)

摘要: 由于跟踪过程中目标外观变化和遮挡因素的影响, 采用单一迭代更新滤波器的 KCF 算法在学习过程中会积累过多的噪声信息导致目标丢失. 为解决该问题, 本文提出一种基于多阶段学习的相关滤波跟踪算法. 通过建立具有互补关系的全局阶段滤波器模型、一致性阶段滤波器模型以及初始阶段滤波器模型并行的对目标进行跟踪. 在 benchmark 数据集的 51 个视频上的实验表明, 本文算法取得的总体精度得分 77.6% 和总体成功率得分 68.9% 优于现有的大部分跟踪算法.

关键词: 目标跟踪; 多阶段学习; 滤波器更新; 一致性

中图分类号: TP391.41 **文献标识码:** A **文章编号:** 0372-2112 (2017)10-2337-06

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2017.10.004

Correlation Filtering Target Tracking Based on Online Multi-lifespan Learning

SUN Hang, LI Jing, DU Bo, XIAO Ya-fu, HU Yun-ling

(School of Computer Science, Wuhan University, Wuhan, Hubei 430072, China)

Abstract: Due to the target appearance changes and occlusion during tracking, the KCF algorithm using a single iterative update filter will accumulate much more noise information in the process of learning, which leads to the loss of the target. To solve this problem, we propose a correlation filtering target tracking algorithm based on multi-lifespan learning. We establish complementary relationship among global stage filter model, consistency stage filter model and initial stage filter model to parallel track the target. The experimental results achieved on the 51 video databases on benchmark show that our algorithm is superior to most existing methods in both overall accuracy and overall success rate with the scores of 77.6% and 68.9%, respectively.

Key words: target tracking; multi-lifespan learning; filter update; consistency

1 引言

目标跟踪是近年来计算机视觉领域中一个经典的研究问题^[1,2],它具有许多实际应用,例如:自动监控、人机交互、运动分类和识别等.在过去几十年里研究人员提出了许多算法来克服目标跟踪过程中存在的问题,但是由于受到具体视频场景中诸如姿势变换、光照、遮挡等因素的影响,目标跟踪仍然是一个具有挑战性的研究工作.

在目标跟踪领域中,寻找一个鲁棒的外观模型倍受研究人员的关注.一般来说,根据表示方式,目标跟踪算法可以分为生成模式和判别模式两大类.近年来,基于相关滤波的判别模式跟踪算法取得了重大的突破,

并引起了相关研究者的关注. Bolme^[3]首先提出基于最小输出平方误差和 (Minimum Output Sum of Squared Error, MOSSE) 的相关滤波跟踪算法.如图 1 所示,其主要思想是设计一个滤波模板,使得当滤波模板作用在跟踪目标上时,得到的响应输出最大.然后在响应输出和跟踪目标已知的条件下,在傅里叶变换域中,利用简单的元素级 (element-wise) 除法就可以求得滤波器,最后将该滤波器用于目标的跟踪.

在此之后,基于 MOSSE 的相关滤波器框架,提出了许多改进的算法. Henriques 等人^[4]通过对训练样本进行循环移位,并利用循环矩阵的性质构建密集采样的方式训练滤波器提出了核化循环结构的检测跟踪算法. Zhang



等人^[5]基于相关滤波框架提出了通过学习时空上下文的跟踪算法. Li 通过处理尺度变化提出了特征融合的相关滤波跟踪器^[6],从而解决了 CSK 算法不能有效对有尺度变化的目标进行跟踪的问题,然而速度却降为原来的五分之一. Danelljan^[7]使用颜色属性作为输入数据的特征,并指出好的特征可以提高跟踪器应对光照变化、运动模糊等干扰因素的影响. 基于 CSK 算法,原文作者利用方向梯度直方图特征取代原始的像素值特征提出了基于核化的相关滤波(Kernelized Correlation Filters, KCF)跟踪算法^[8]. 虽然 KCF 跟踪算法在精度、成功率以及速度上优于了以前提出的大部分跟踪算法. 但是,为了自适应目标的外观变化,KCF 跟踪算法固定在每帧中迭代的学习(更新)单一滤波器. 当目标经历外观变化或遮挡时,这种学习方式会导致积累越来越多的噪声信息,从而使得该算法在定位目标时容易产生漂移,甚至目标的丢失. 鉴于此,本文基于 KCF 跟踪算法提出了多阶段学习相关滤波跟踪算法. 该算法包含在定位目标时相互独立,但是外观模型又存在互补关系的三个滤波器模型可以有效的缓解 KCF 跟踪算法的漂移问题,并且在局部范围内实现目标丢失后的重新定位.

2 KCF 跟踪框架

KCF 算法将分类器的训练过程看成一个求解岭回归问题. 其目标是找到一个函数 $f(z) = \mathbf{w}^T \mathbf{z}$ 使得所有样本 x_i 和对应的回归目标 y_i 之间的平方误差最小,

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

式(1)中, λ 是用于控制过拟合的正则化参数. 式(1)复数形式的解为,

$$\mathbf{w} = (\mathbf{X}^H \mathbf{X} + \lambda \mathbf{I})^{-1} \mathbf{X}^H \mathbf{y} \quad (2)$$

式(2)中, \mathbf{X} 矩阵中每一行对应一个样本, 向量 \mathbf{y} 表示对应样本的回归值, \mathbf{X}^H 表示 \mathbf{X} 的共轭转置. 因为直接求解式(2)存在非常耗时的求逆计算, 于是利用正样本 \mathbf{x} 构建的循环矩阵可以得到式(2)在傅里叶变换域的解,

$$\hat{\mathbf{w}} = \frac{\hat{\mathbf{x}}^* \odot \hat{\mathbf{y}}}{\hat{\mathbf{x}}^* \odot \hat{\mathbf{x}} + \lambda} \quad (3)$$

式(3)中, $*$ 表示复共轭, \wedge 表示傅里叶变换, \odot 表示向量对应元素的相乘. 至此, \mathbf{w} 的求解避免了式(2)中的求逆过程, 从而使得计算量大大降低. 式(3)求得的 $\hat{\mathbf{w}}$

是线性回归模型的解, 但是在现实中很多问题都是非线性的, 为了使分类器的性能更好, 引入核技巧之后, 岭回归在傅立叶变换域的核版本解为,

$$\hat{\mathbf{a}} = \frac{\hat{\mathbf{y}}}{\hat{\mathbf{k}}^{xx} + \lambda} \quad (4)$$

其中 \mathbf{k}^{xx} 是矩阵 \mathbf{K} 中第一行元素组成的向量. 式(4)的求解的 $\hat{\mathbf{a}}$ 实际上对应图 1 中在傅里叶变换域训练的滤波器. 在得到滤波器之后需要在下一帧进行目标的检测,

$$\mathbf{y} = \mathbf{F}^{-1}(\hat{\mathbf{a}} \odot \hat{\mathbf{k}}^{xx}) \quad (5)$$

式(5)中, \mathbf{y} 最大响应值所对应的测试样本即为目标. 为了自适应目标外观的变化, 需要在每一帧中更新滤波器模型, 其主要包括滤波器的更新和目标模型的更新,

$$\hat{\mathbf{a}}_t = (1 - \eta) \hat{\mathbf{a}}_{t-1} + \eta \hat{\mathbf{a}}_t \quad (6)$$

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

其中 η 表示滤波器模型更新的学习率. $\hat{\mathbf{a}}_{t-1}$ 表示前 $t-1$ 帧迭代训练的滤波器, $\hat{\mathbf{a}}_t$ 是当前第 t 帧训练的滤波器; 目标模型的更新参数同理.

3 多阶段学习滤波器模型跟踪

3.1 多阶段滤波器学习模型

本文提出的多阶段滤波器学习 (Multi-Phase Filter Learning, MPFL) 模型主要流程如图 2 所示. MPFL 模型主要由全局阶段滤波器 (Global Phase Filter, GPF) 模型, 一致性阶段滤波器 (Consistency Phase Filter, CPF) 模型以及初始阶段滤波器 (Initial Phase Filter, IPF) 模型三个部分组成. 在 MPFL 模型中, 滤波器模型包含滤波器和目标模型, 于是将每一个滤波器模型定义为,

$$\mathbf{M}^i = \{\mathbf{F}^i, \mathbf{O}^i\}, i \in \{G, C, I\} \quad (7)$$

其中 \mathbf{F} 表示滤波器, \mathbf{O} 表示目标模型, i 表示滤波器的类型.

从第 t 帧跟踪到第 $t+1$ 帧的过程中, 为了自适应目标的外观变化, 需要利用前 t 帧的信息对全局阶段滤波器模型 \mathbf{M}^G 更新,

$$\mathbf{M}^G = \begin{cases} \mathbf{F}_t^G = (1 - \eta) \mathbf{F}_{t-1}^G + \eta \hat{\mathbf{a}}_t \\ \mathbf{O}_t^G = (1 - \eta) \mathbf{O}_{t-1}^G + \eta \hat{\mathbf{x}}_t \\ \mathbf{F}_t^G = \hat{\mathbf{a}}_1 \\ \mathbf{O}_t^G = \hat{\mathbf{x}}_1 \end{cases}, \quad \begin{matrix} t > 1 \\ t = 1 \end{matrix} \quad (8)$$

式(8)的更新方式与 KCF 模型的更新方式相同, 好处在于可以自适应目标外观的变化, 但是随着干扰因素所积累的误差增加容易造成跟踪定位的漂移现象. 为了缓解漂移问题, 文本采用向后跟踪计算一致性误差来决定一致性滤波器的更新, 具体细节在 3.2 节中介绍. 采用全局阶段滤波器模型 \mathbf{M}^G 和一致性阶段滤波器模型 \mathbf{M}^C 可以解决遮挡时间较短时的跟踪漂移问题. 但

是如果遮挡时间过长,全局阶段滤波器模型 M^C 和一致性阶段滤波器模型 M^C 的更新都受到遮挡信息的干扰. 由于历经长时间遮挡之后,在大多数情况下如果目标再次出现时,目标外观与第一帧建模的目标外观非常

相似,从而采用 MPFL 模型中的初始阶段滤波器 F^I 可以修正全局阶段滤波器 F^C 和一致性阶段滤波器 F^C 产生定位误差较大或者丢失目标的问题. 初始阶段滤波器模型 M^I 更新模型为,

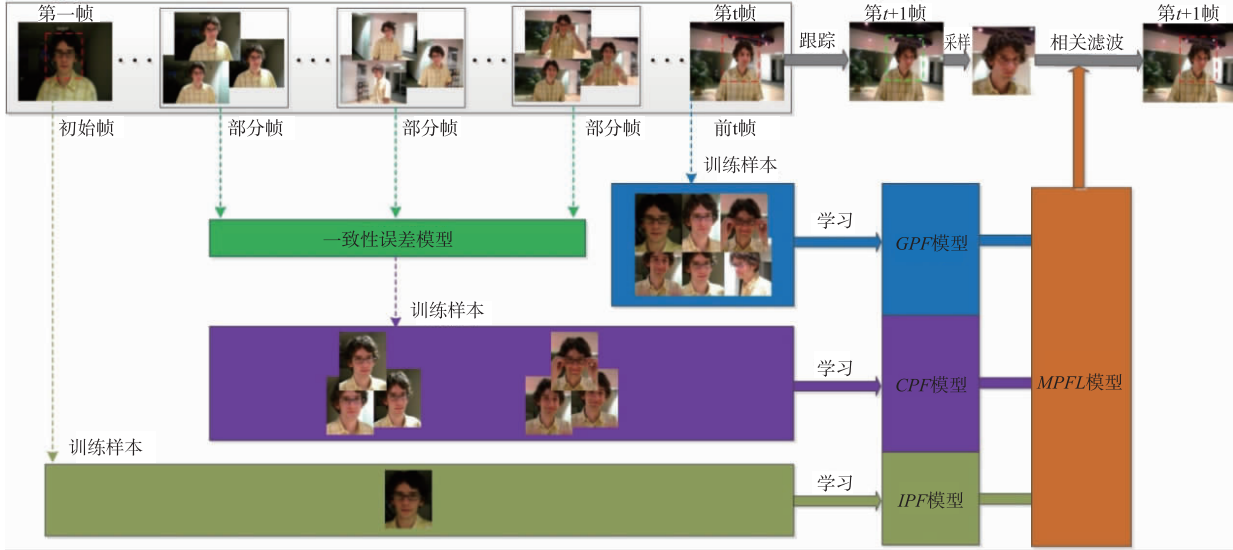


图2 多阶段滤波器学习模型

$$M^I = \begin{cases} F_t^I = \hat{\alpha}_1 \\ O_t^I = \hat{x}_1 \end{cases} \quad (9)$$

通过式(9)可以看出,初始阶段滤波器模型 M^I 只利用第一帧的信息对目标进行建模,然后在接下来的视频序列中,利用初始阶段滤波器 F^I 进行目标的定位.

3.2 一致性阶段滤波器模型

本文利用前后一致性误差来判断一段视频内是否存在严重干扰因素,从而决定是否更新一致性阶段滤波器. 这样可以减少 MPFL 模型学习时误差的引入,从而有效地缓解跟踪漂移问题. 在一段长度为 n 的视频序列 P 中,令 $s_i = (x_i, y_i)$, $i \in \{t, t+1, \dots, t+n-1\}$ 表示在视频的第 i 帧中目标定位结果的坐标. 使用一致性阶段滤波器 F^C 向前跟踪 n 帧,生成向前轨迹坐标是 $S_f^n = \{s_t, s_{t+1}, \dots, s_{t+n-1}\}$,其中下标 f 表示向前跟踪,上标 n 表示跟踪的长度. 为了验证在给定视频序列 P 中生成的轨迹 S_f^n 是否可靠,需要使用一致性阶段滤波器 F^C 从第 $t+n-1$ 帧向后跟踪到第 t 帧生成向后轨迹 $S_b^n = \{\hat{s}_t, \hat{s}_{t+1}, \dots, \hat{s}_{t+n-1}\}$,下标 b 表示向后跟踪, $s_{t+n-1} = \hat{s}_{t+n-1}$. 将一致性误差定义为向前轨迹中的 s_t 和向后轨迹中 \hat{s}_t 之间的欧氏距离,

$$C_{\text{error}} = \|s_t - \hat{s}_t\| \quad (10)$$

式(10)表示如果一段视频内存在严重干扰,那么一致性误差 C_{error} 会产生一个较大值,反之 C_{error} 较小. 一致性阶段滤波器模型 M^C 的更新表示为,

$$M^C = \begin{cases} F_k^C = (1 - \eta) F_{k-1}^C + \eta \hat{\alpha}_k \\ O_k^C = (1 - \eta) O_{k-1}^C + \eta \hat{x}_k \\ F_{t+n}^C = F_t^C \\ O_{t+n}^C = O_t^C \end{cases}, \quad \begin{cases} C_{\text{error}} < \theta \\ C_{\text{error}} \geq \theta \end{cases} \quad (11)$$

式(11)中, $k \in \{t, \dots, t+n-1\}$, θ 表示一致性误差的阈值. 一致性阶段滤波器模型 M^C 的更新分为两种情况. 第一种情况,目标没有遭受剧烈变化的因素干扰时,如式(11)上半部分. 一致性阶段滤波器 F^C 从第 $t+n-1$ 帧向后跟踪到第 t 帧,MPFL 模型跟踪结果 S_t 和一致性阶段滤波器 F^C 结果 \hat{S}_t 之间的一致性误差 $C_{\text{error}} < \theta$,这时采用第 t 帧到第 $t+n-1$ 帧之间所有的样本对一致性阶段滤波器模型 M^C 更新. 而对于第二种情况,如式(11)下半部分,目标遭受如遮挡、光照变化等剧烈变化的因素干扰时,MPFL 模型跟踪结果 S_t 和一致性阶段滤波器 F^C 结果 \hat{S}_t 之间的一致性误差 $C_{\text{error}} > \theta$. 此时,由于剧烈变化干扰因素的存在,如果继续更新一致性阶段滤波器模型 M^C ,会引入大量的噪声信息,从而使得一致性阶段滤波器 F^C 在接下来的视频中定位目标会产生漂移甚至是丢失目标. 因此,在 $C_{\text{error}} > \theta$ 的条件下,需要将第 t 帧到第 $t+n-1$ 帧之间对于一致性阶段滤波器模型 M^C 更新将全部丢弃.

3.3 多阶段滤波器学习跟踪算法

在本文跟踪算法中,在视频的每一帧中这三个滤波器模型所对应的滤波器 F^C 、 F^C 以及 F^I 是并行地对目标位置进行估计. 根据式(5),从第 t 帧到第 $t+1$ 帧定位目标的过程,滤波器 F^C 、 F^C 以及 F^I 会生成三个置

信矩阵,每一个置信矩阵中的最大值即为对应滤波器在第 $t+1$ 帧中对目标位置的估计,

$$L_{t+1}^i = \max(F^{-1}(F^i \odot \hat{k}^x)), i \in \{G, C, I\} \quad (12)$$

式(12)中 F^{-1} 表示傅立叶逆变换, \hat{k}^x 对应式(5)中测试样本的傅立叶变换. 在得到三个滤波器对于第 $t+1$ 帧中目标位置的估计之后,本文算法的决策模型为,

$$L_{t+1}^* = \begin{cases} \max(L_{t+1}^G, L_{t+1}^C, L_{t+1}^I), L_{t+1}^G \neq L_{t+1}^C \\ L_{t+1}^I, L_{t+1}^C = L_{t+1}^G \&\& L_{t+1}^I - L_{t+1}^G \geq 0 \\ \min(\frac{\Delta L_{t+1}^G}{L_t^G}, \frac{\Delta L_{t+1}^C}{L_t^C}), L_{t+1}^C = L_{t+1}^G \&\& L_{t+1}^I - L_{t+1}^G < 0 \end{cases} \quad (13)$$

式(13)中, $\Delta L_{t+1} = L_{t+1} - L_t$ 表示全局阶段滤波器 F^G 或一致性阶段滤波器 F^C 在两帧之间的一阶差分. 本文算法的基本步骤如算法 1 所示.

算法 1 多阶段滤波器学习跟踪算法

输入: 视频中的第 $t-n+1$ 帧到第 $t+1$ 帧, 多阶段滤波器学习模型 (MPFL)

1. if $L_{t+1}^C \neq L_t^C$
2. 使用 $L_{t+1}^* = \max(L_{t+1}^G, L_{t+1}^C, L_{t+1}^I)$ 所对应的滤波器对目标定位.
3. 利用第 $t+1$ 帧信息更新 M^G 和 M^C .
4. if $\text{mod}(t+1, n) = 0$
5. 使用 F^C 向后跟踪到第 $t-n+1$ 帧.
6. if $C_{\text{error}} < \theta$
7. 保留第 $t-n+1$ 帧到第 $t+1$ 帧的信息对于 M^C 的更新.
8. else
9. 丢弃第 $t-n+1$ 帧到第 $t+1$ 帧的信息对于 M^C 的更新.
10. end
11. end
12. else if $L_{t+1}^C = L_t^C \&\& L_{t+1}^I - L_t^C \geq 0$
13. 使用 F^I 对目标定位, 然后重复第 3 步到第 11 步.
14. else if $L_{t+1}^C = L_t^C \&\& L_{t+1}^I - L_t^C < 0$
15. 计算 F^G 和 F^C 的一阶差分.
16. 使用 $L_{t+1}^* = \min(\frac{\Delta L_{t+1}^G}{L_t^G}, \frac{\Delta L_{t+1}^C}{L_t^C})$ 所对应的滤波器对目标定位.
17. 重复第 3 步到第 11 步.
18. end

输出: 目标在第 $t+1$ 帧的位置和 M^G 、 M^C 以及 M^I 的相关状态.

4 实验结果和分析

为了验证本文算法的性能, 本文在文献[9]的 51 个视频数据集和 10 个跟踪算法进行试验对比. 这些算法包括: Struck^[10]、TLD^[11]、MIL^[12]、CSK、SCM^[13]、CT^[14]、ASLA^[15]、KCF 以及 STC.

4.1 实验设置

本文实验环境为 Windows 7 64 位操作系统, MATLAB R2013a, 计算机的配置为 Intel i5 2.8GHz CPU, 8GB RAM. 本文使用方向梯度直方图特征和颜色特征

的组合表示目标特征, 并且每一段视频的第一帧中目标位置由 ground-truth 给出. 本文算法的学习率、测试样本的区域、空间带宽等参数的设置与 KCF 保持一致, 针对一致性阶段滤波器向后跟踪的帧数 n 设置为 8, 一致性误差的阈值 θ 设置为 6. 在本文的全部实验过程中, 以上参数设置保持固定.

4.2 评价标准

在实验中, 本文采用精度图、成功率图以及跟踪视频截图对实验结果进行分析. 精度图说明了算法跟踪结果与 ground-truth 之间的欧氏距离在给定阈值以内的条件下帧数占总帧数的百分比. 一般情况下, 设置阈值 $\text{dis} = 20$ 像素来评价跟踪算法. 成功率图以重叠率为基

础, 重叠率 $S = \frac{\text{Area}(B_T \cap B_C)}{\text{Area}(B_T \cup B_C)}$, 其中 B_T 表示跟踪算法对应的矩形框, B_C 表示 ground-truth 对应的矩形框. 成功率图展示了重叠率大于阈值 t_0 时, 帧数占总帧数的百分比. 阈值 t_0 的取值范围是 $[0, 1]$, 通常取 $t_0 = 0.5$ 用来衡量跟踪算法. 本文的实验结果是基于一次运行评估 (One-Pass Evaluation). 图 3 和图 4 显示了 10 个算法的总体的精度图和成功率图.

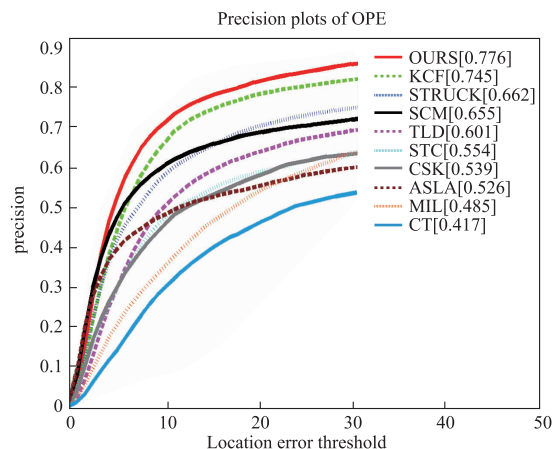


图3 总体的精度图

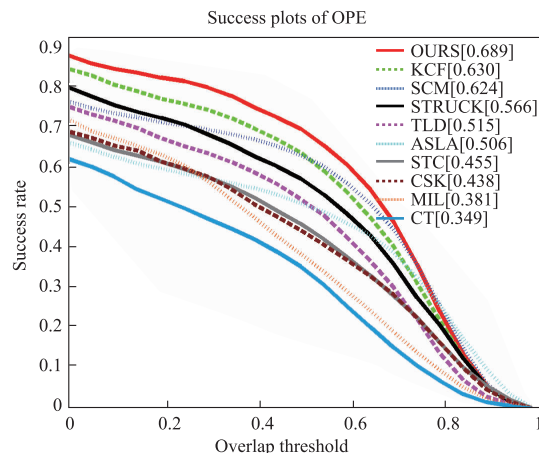


图4 总体的成功率图

4.3 实验结果分析

在图 3 和图 4 中,总体的精度图和成功率图展示了 10 个算法总体性能. 本文算法在总体的精度和成功率两个评价指标上都取得第一名. 在精度图中,本文算法在总体的精度得分方面是 0.776,相比第二名 KCF 和第三

名 STRUCK 分别提高了 3.1% 和 11.4%. 不仅如此,在成功率图中,本文算法在总体的成功率得分方面相比第二名 KCF 以及第三名 SCM 也分别提高了 5.9% 和 6.5%. 实验的部分跟踪视频截图如图 5 所示,下面针对部分视频序列进行结果分析.

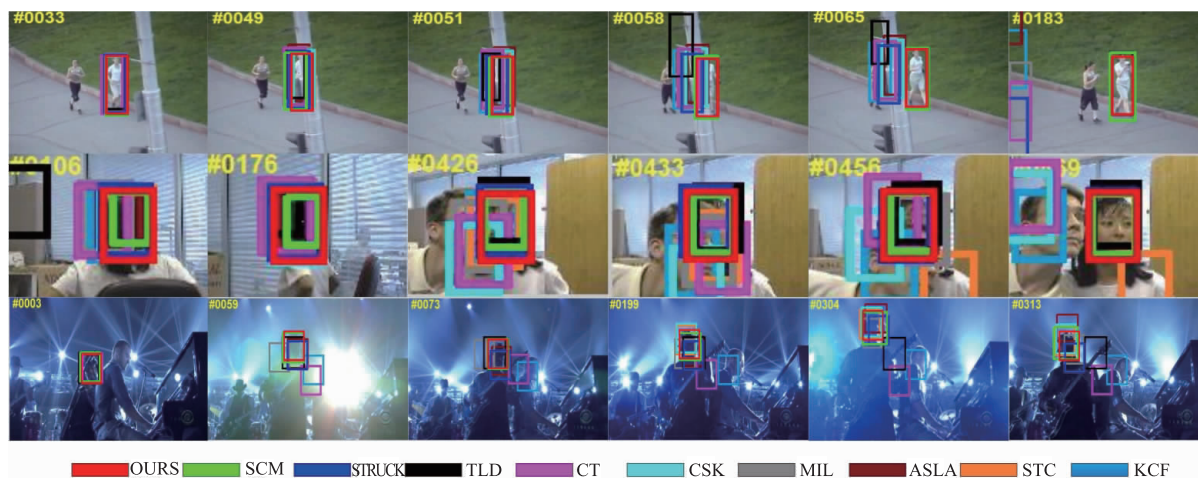


图5 部分跟踪视频结果截图

(1) Jogging-2: 当跟踪目标在经过灯柱的时候经历了部分遮挡和严重遮挡(如, #49, #51). 当目标在视频中再次出现时,只有本文算法和 SCM 算法能够重新检测到目标并且准确的进行跟踪(如, #58, #68, #183). 本文算法,在目标经过灯柱这段时间里,由于一致性阶段滤波器 F^c 向后跟踪的一致性误差 C_{error} 大于阈值,所以丢弃这段遮挡视频对于一致性阶段滤波器模型 M^c 的更新,于是当目标出现时,通过一致性阶段滤波器 F^c 可以重新检测到目标.

(2) Girl: 女孩转身的过程中, CT、CSK 以及 MIL 这几个跟踪算法会发生轻微的漂移, TLD 会丢失目标(如, #106, #176). 但是 TLD 算法的重新检测机制会让该算法重新找到目标(如, #426). 当经历男人的脸对女孩遮挡时, CSK、KCF 以及 CT 算法会跟踪到男人的脸部(如, #433, #456). 在之后的视频中,除了本文算法和 TLD 算法,还有 SCM 和 ALSA 算法能够正确的跟踪目标(如, #469),这是因为 SCM 和 ALSA 算法使用了对遮挡具有较好鲁棒性的局部特征.

(3) Shaking: 目标经历了光照变化(如, #3, #73, #199, #313)和剧烈光照(如, #59, #304)的影响, KCF、CT、MIL、TLD 以及 STRUCK 算法在视频中会丢失目标(如, #59, #73, #199, #304, #313). 只有本算法、SCM、CSK、ASLA 以及 STC 算法在整个视频序列中不会丢失目标,但是本文算法的跟踪结果最准确.

5 结论

在基于相关滤波的跟踪方法中,模型的学习对跟

踪算法的性能至关重要. 本文提出的多阶段滤波器学习模型利用三种不同学习方式的滤波器模型并行的对目标进行跟踪,从而克服了单一滤波器模型的跟踪漂移和目标丢失后无法重新定位的问题. 在 benchmark 视频库上的评估证实了本文提出的算法相比目前最流行的一些跟踪算法取得了鲁棒的跟踪结果. 为了获得更高的可靠性和广泛性的应用,未来我们将着手研究基于相关滤波的跟踪框架下目标的尺度变化以及目标丢失后的全局检测等具有挑战性的问题.

参考文献

- [1] Yang H, Shao L, Zheng F. Recent advances and trends in visual tracking: A review [J]. *Neurocomputing*, 2011, 74(18): 3823–3831.
- [2] Yilmaz A, Javed O. Object tracking: A survey [J]. *ACM Computing Surveys*, 2006, 38(4): 1–45.
- [3] D S Bolme, J R Beveridge, B A Draper. Visual object tracking using adaptive correlation filters [A]. *IEEE 23rd Conference on Computer Vision and Pattern Recognition [C]*. San Francisco, USA, 2010. 2544–2550.
- [4] J F Henriques, R Caseiro, P Martins. Exploiting the circulant structure of tracking-by-detection with kernels [A]. *12th European Conference on Computer Vision [C]*. Florence, Italy, 2012. 702–715.
- [5] K Zhang, L Zhang, Q Liu. Fast visual tracking via dense spatio-temporal context learning [A]. *13th European Conference on Computer Vision [C]*. Zurich, Switzerland,

2014. 127 – 141.
- [6] Y Li, J Zhu. A scale adaptive kernel correlation filter tracker with feature integration [A]. 13th European Conference on Computer Vision [C]. Zurich, Switzerland, 2014. 254 – 265.
- [7] M Danelljan, F S Khan, M Felsberg. Adaptive color attributes for real-time visual tracking [A]. IEEE 27th Conference on Computer Vision and Pattern Recognition [C]. Columbus, USA, 2014. 1090 – 1097.
- [8] J F Henriques, R Caseiro, P Martins. High-speed tracking with kernelized correlation filters [J]. PAMI, 2015, 37(3): 583 – 596.
- [9] Wu Y, Lim J, Yang M H. Object tracking benchmark [J]. PAMI, 2015, 37(9): 1834 – 1848.
- [10] S Hare, A Saffari. Struck: Structured output tracking with kernels [A]. IEEE International Conference on Computer Vision [C]. Barcelona, Spain, 2011. 263 – 270.
- [11] Zdenek Kalal. Tracking-learning-detection [J]. PAMI, 2011, 34(7): 1409 – 1422.
- [12] B Babenko, M-H Yang, S Belongie. Visual tracking with online multiple instance learning [A]. IEEE Conference on Computer Vision and Pattern Recognition [C]. IEEE, 2009. 983 – 990.
- [13] W Zhong, H Lu, M H Yang. Robust object tracking via sparse collaborative appearance model [J]. TIP, 2014, 23(5): 2356 – 2368.
- [14] K Zhang, L Zhang, M-H Yang. Fast compressive tracking [J]. PAMI, 2014, 36(10): 2002 – 2015.
- [15] X Jia, H Lu, M-H Yang. Visual tracking via adaptive structural local sparse appearance model [A]. IEEE 23rd Conference on Computer Vision and Pattern Recognition [C]. Providence, USA, 2012. 1822 – 1829.

作者简介



孙 航 男, 1986 年 4 月出生, 湖北武汉人. 武汉大学在读博士研究生, 主要研究方向为: 图像处理、目标跟踪.
E-mail: sunhang0418@whu.edu.cn



李 晶(通讯作者) 男, 1967 年 7 月出生, 湖北武汉人. 武汉大学教授、博士生导师. 主要研究方向为: 多媒体技术和信息系统, 计算机仿真及计算机网络.
E-mail: leejingcn@163.com