

尺度自适应核相关滤波目标跟踪

高美凤, 张晓玄*

江南大学轻工过程先进控制教育部重点实验室, 江苏 无锡 214122

摘要 针对传统跟踪方法难以实时准确适应目标尺度变化这一问题, 基于核相关滤波跟踪框并采用尺度估计方法, 提出一种自适应尺度的目标跟踪算法。对正则化最小二乘分类器进行求解, 获得滤波模板, 并对候选样本进行检测, 估计出目标的位置; 利用尺度估计方法, 在已确定目标位置处根据前一帧目标的大小对当前帧目标尺度进行检测, 由最大的响应值确定当前帧目标的尺度; 根据遮挡检测机制, 在线更新目标和尺度模型参数。实验结果表明, 所提出的算法与其他跟踪算法中的最优者相比, 距离精度提高了 17.12%, 成功率提高了 10.77%; 在目标发生背景干扰、严重遮挡以及在光照、姿态和尺度变化等复杂场景下, 该算法仍具有较好的跟踪效果。

关键词 机器视觉; 目标跟踪; 核相关滤波; 最小二乘分类器; 尺度估计; 遮挡检测

中图分类号 TP391

文献标识码 A

doi: 10.3788/LOP55.041501

Scale Adaptive Kernel Correlation Filtering for Target Tracking

Gao Meifeng, Zhang Xiaoxuan

Key Laboratory of Advanced Process Control for Light Industry, Ministry of Education,
Jiangnan University, Wuxi, Jiangsu 214122, China

Abstract Focusing on the issue that the traditional tracking method is difficult to adapt to the target scale variation in real time accurately, an adaptive scale target tracking algorithm based on kernel correlation filtering tracking framework, which adapts a scale estimation method, is proposed. Firstly, the regularized least squares classifier is used to obtain the filter template, and the position of the target is estimated by detecting the candidate samples. Then, the scale of current frame is determined based on the target size of the previous frame, and the scale samples are obtained by the maximum response value through the scale estimation method. Finally, the target and scale model parameters are updated online according to the occlusion detection mechanism. The experimental results show that the proposed algorithm improves the distance precision by 17.12% and the success rate by 10.77% as compared with the best of the other tracking algorithms. In complex scenes, such as background clutters, severe occlusion, and illumination, posture and scale variation, the proposed algorithm still has a good tracking performance.

Key words machine vision; target tracking; kernel correlation filtering; least squares classifier; scale estimation; occlusion detection

OCIS codes 150.1135; 100.3008; 100.4999; 070.4550

1 引言

目标跟踪是在视频序列中估计出感兴趣的目标位置及其运动轨迹的过程, 在视频处理中有很多实际的应用, 如视频监控^[1]、智能工业控制^[2]和机器人学^[3]等, 因此成为计算机视觉的一个重要研究领域。

目前, 目标跟踪技术已经取得了很大的进步, 但是仍面临很多挑战, 如目标尺度和光照变化、目标旋转和遮挡、目标快速移动、相机抖动和背景干扰等^[4]。

近年来, 基于判别式的跟踪方法表现出了良好的跟踪性能, 该方法引入机器学习的思想, 将目标跟踪看成一个二分类问题, 利用目标及其周围的背景

收稿日期: 2017-09-13; 收到修改稿日期: 2017-10-20

基金项目: 国家自然科学基金(61373126)

作者简介: 高美凤(1963—), 女, 博士, 副教授, 硕士生导师, 主要从事图像处理、无线传感网定位技术方面的研究。

E-mail: gaojndx@163.com

* 通信联系人。E-mail: 1762248458@qq.com

信息,通过在线学习一个判别式的分类器,对候选样本进行评估来定位目标区域^[5]。具有代表性的判别式跟踪器有 Ensemble Tracking^[6]、多示例学习跟踪器^[7]和跟踪学习检测(TLD)算法^[8]等。最近,基于深度学习的跟踪方法也表现出了较好的跟踪性能,最新的相关算法,如多域网络^[9]和全卷积孪生网络跟踪算法^[10],在目标跟踪标准库的跟踪性能检测中表现卓越^[11]。

有时为了实时性的考虑,算法在训练和检测过程中只选取有限数量的样本,无法获得可靠的分类器模型。为了解决此问题,Henriques等^[12]提出了基于循环结构的检测跟踪(CSK)算法,该算法通过对训练样本和候选样本进行循环移位,近似目标的密度采样,获得可靠的目标外观模型和目标位置的检测。Danelljan等^[13]在CSK框架的基础上,用色名(CN)属性对目标进行描述,并采用自适应降维的方法,提出了色名跟踪器(CNT),CNT比其他基于颜色空间的特征有更好的跟踪效果。核相关滤波(KCF)跟踪^[14]算法用方向梯度直方图(HOG)特征代替CSK算法中的灰度特征,提高了算法跟踪的稳健性。刘行等^[5]在CSK算法的基础上,将灰度、CN与HOG特征进行融合,提出了自适应多特征融合目标跟踪算法,提高了算法的跟踪精度和稳健性。然而,以上算法都用固定的跟踪框去跟踪不断变化的目标,这不仅影响跟踪精度,也可能导致跟踪漂移,甚至跟踪失败。

针对KCF目标跟踪算法在跟踪过程中无法解决目标尺度变化的问题,在KCF跟踪框下,引入一种尺度估计方法,并提出了一种自适应尺度的KCF跟踪算法。该算法通过KCF获得目标的估计位置,然后根据尺度估计输出的最大响应值,确定当前帧目标的尺度,并根据遮挡检测在线更新尺度与滤波模板,使算法的跟踪框能够实时地适应目标尺寸大小的变化。

2 KCF跟踪器

KCF跟踪器是在CSK跟踪器框架的基础上,以HOG代替最初的灰度值扩展而来的。KCF跟踪器通过在线密度采样获得大量训练样本,构建目标外观模型,训练一个正则化最小二乘分类器,利用核函数进行求解,以获得滤波模板。获得滤波模板后,即可对候选样本进行检测,实现目标的在线学习与跟踪^[14]。

2.1 正则化最小二乘分类器的求解

在KCF跟踪器中,训练分类器 $f(x)$ 的目的是

找到最小化风险参数 w ,使目标周围大小为 $m \times n$ 的图像块 x 的所有循环移位样本集 $x_i (i \in \{0, \dots, m-1\} \times \{0, \dots, n-1\})$ 与其对应的回归标签 r_i 的平方误差和最小^[14]。训练分类器的最小代价函数可表示为

$$\min_w \sum_{i=1}^n [f(x_i) - r_i]^2 + \epsilon \|w\|^2, \quad (1)$$

式中 $\epsilon \|w\|^2$ 为惩罚项; ϵ 为正则化参数,用来防止过拟合。(1)式的解可表示为所有输入样本 x_i 的线性联合,由于 $w = \sum_i \alpha_i \varphi(x_i)$,则对 w 的求解可转化为对单一因数对偶变量 α_i 的求解^[15],其中 $\varphi(x_i)$ 表示将 x_i 映射到Hilbert特征空间。于是,正则化最小二乘分类器的封闭解为

$$\alpha = (\mathbf{k} + \epsilon \mathbf{I})^{-1} \mathbf{r}, \quad (2)$$

式中 \mathbf{I} 为单位矩阵; \mathbf{k} 为核矩阵,其元素 $k_{ij} = k(x_i, x_j) = \langle \varphi(x_i), \varphi(x_j) \rangle$; \mathbf{r} 为每个样本对应的回归标签矩阵。文献[12]证明了 \mathbf{k} 具有循环矩阵的结构,根据循环矩阵的性质可得到(2)式在频域中的解为

$$\alpha = \mathcal{F}^{-1} \left[\frac{\mathcal{F}(\mathbf{r})}{\mathcal{F}(\mathbf{k}) + \epsilon} \right], \quad (3)$$

式中 \mathcal{F} 与 \mathcal{F}^{-1} 表示离散傅里叶变换与离散傅里叶逆变换。将(3)式代入 $f(\mathbf{z}) = \sum_{i=1}^n \alpha_i k(\mathbf{z}, x_i)$ 中,得到正则化最小二乘分类器的响应值为

$$f(\mathbf{z}) = \alpha \mathbf{K}(\mathbf{z}, \mathbf{x}) = \mathcal{F}^{-1} \{ A \mathcal{F}[\mathbf{K}(\mathbf{z}, \mathbf{x})] \}, \quad (4)$$

式中 $A = \mathcal{F}(\alpha)$, $\mathbf{K}(\mathbf{z}, \mathbf{x}) = [k(z_i, x_i)] = [\varphi^T(x_i) \varphi(\mathbf{z})]$, \mathbf{x} 为训练样本向量, \mathbf{z} 为测试样本向量, $\varphi(\mathbf{x})$ 与 $\varphi(\mathbf{z})$ 分别为训练和测试样本的特征向量。

2.2 目标检测

在当前帧与前一帧目标中心相同的位置处,提取大小为 $m \times n$ 的图像块作为基候选样本,建立目标外观模型,对其进行循环移位操作,获得候选样本集合 $z_i (i \in \{0, 1, \dots, m-1\} \times \{0, 1, \dots, n-1\})$ 。对每一个输入分类器的候选样本 z_i 进行检测,利用训练获得的滤波系数对检测样本与目标图像块的相似度进行加权求和,得到分类器的响应 $r'_i = \sum_j \alpha_j k(x_j, z_i)$ 。类似训练过程,响应值的求解可转换到频域,以降低求解过程的运算量,即

$$\mathbf{r} = \mathbf{F}^{-1} [\mathbf{F}(\mathbf{k}) \cdot \mathbf{F}(\alpha)]. \quad (5)$$

KCF算法通过检测过程获得最大的响应值来估计当前帧的目标位置,跟踪效果较好,但是在一些复杂的场景中,由于尺度变化、遮挡等因素的干扰,

算法的跟踪框不能随着目标大小自适应地变化,且在模型更新中未考虑目标遮挡的情况,容易引入背景信息,从而导致跟踪精度较低。

3 基于 KCF 的自适应尺度跟踪

所提出的算法在传统的跟踪算法上增加了尺度估计策略和遮挡检测更新策略,旨在解决以下两个问题:1) 传统算法跟踪框不能随目标大小自适应变化,导致跟踪准确率低;2) 遮挡情况下的目标模型不断更新,导致跟踪误差不断积累。

3.1 自适应尺度估计

KCF 算法中的目标跟踪框是固定的,当目标逐渐变大时,只能捕捉到目标的某一部分,当目标逐渐变小时,跟踪的目标区域又易于掺杂干扰的背景信息,这不仅影响算法的跟踪精确度,还会影响后期的姿态估计和行为分析等操作。为了解决这一问题,在原始算法的跟踪过程中加入尺度估计的方法。

假设目标模板为 M ,第 $t-1$ 帧检测出的目标尺度为 S_{t-1} 。由 KCF 算法获得的当前帧的目标位置为 p_t ,在 p_t 处以 S_{t-1} 为基准,提取多种不同尺度的图像块 $r^a S_{t-1}$,记为 $S_i (i=1,2,\dots,2l+1)$,其中 r 为尺度变换因子, a 为 $[-l,l]$ 之间的整数。利用双线性插值的方法将尺度为 S_i 的图像块调整到与 M 大小相同的尺寸,提取 HOG 的特征 f_i ,将其输入到尺度估计模型,即(6)式中进行检测,由最大的响应值 y 确定当前帧目标的尺度 S_t ,即

$$\min \left\| \sum_{l=1}^d h^l \otimes f^l - y \right\|^2 + \lambda \sum_{l=1}^d \|h^l\|^2, \quad (6)$$

式中 \otimes 表示卷积; h 为滤波模板, $h^l = \mathcal{F}^{-1}(A/B) = \mathcal{F}^{-1} \left[\frac{\mathcal{F}^*(y)\mathcal{F}(f^l)}{\sum_{i=1}^l \mathcal{F}(f_i)\mathcal{F}^*(f_i) + \lambda} \right]$,其中 $*$ 表示共轭; y 为满足一维高斯分布的函数。尺度检测的过程即为获得最大的 y 对应的尺度的过程,即

$$y = \mathcal{F}^{-1} \left(\frac{\sum_{i=1}^l A_i^* Z_i}{B + \lambda} \right). \quad (7)$$

获得当前帧的尺度后,更新 h 的分子和分母,即

$$\begin{aligned} A &= (1-\theta)A_{t-1} + \theta A_t = \\ &= (1-\theta)A_{t-1} + \theta \mathcal{F}^*(y)\mathcal{F}(f^l), \end{aligned} \quad (8)$$

$$\begin{aligned} B &= (1-\theta)B_{t-1} + \theta B_t = \\ &= (1-\theta)B_{t-1} + \theta \sum_{i=1}^l \mathcal{F}^*(f_i)\mathcal{F}(f_i), \end{aligned} \quad (9)$$

式中 θ 为学习速率, $f_i (i=1,2,\dots,2l+1)$ 为当前帧

尺度的训练样本。

3.2 分类器的更新

对当前帧获得的目标区域 x 进行循环移位操作,得到训练样本集合。通过求解正则化最小二乘分类器获得学习系数,更新滤波模板系数 α ,同时对目标外观模型 H 进行更新,即

$$\alpha = (1-\theta)\alpha_{\text{pre}} + \theta\alpha_{\text{new}}, \quad (10)$$

$$H = (1-\theta)H_{\text{pre}} + \theta H_{\text{new}}, \quad (11)$$

式中 α_{pre} 和 H_{pre} 分别为前一帧获得分类器的模板系数和目标外观模型, α_{new} 和 H_{new} 分别为当前帧获得分类器的模板系数和目标外观模型。但跟踪环境复杂多变,目标难免受到干扰物的遮挡。当目标受到遮挡时,如果仍采用连续的模板更新方法,难免会掺杂遮挡物的信息而导致跟踪误差不断积累,为了解决此问题,采用了一种遮挡检测更新方法。

当目标正常运动时,KCF 跟踪器的响应函数为高斯分布,峰值很明显;当目标受到遮挡时,峰值不明显且峰值旁瓣比减小,目标的可能位置点增多,目标位置与尺度的确定变得困难。假设最大响应值为 $r_{\text{max}}(z)$,其对应的目标位置为 p_{max} ,记大于 $T_1 \cdot r_{\text{max}}(z)$ 的最小响应值对应的位置为 p_{min} ,其中, T_1 为距离阈值两个位置点之间的欧式距离为

$$d = \sqrt{[p_{\text{max}}(x) - p_{\text{min}}(x)]^2 + [p_{\text{max}}(y) - p_{\text{min}}(y)]^2}, \quad (12)$$

式中 $p_{\text{max}}(x)$ 、 $p_{\text{min}}(x)$ 分别为最大、最小响应值在 x 方向的坐标, $p_{\text{max}}(y)$ 、 $p_{\text{min}}(y)$ 分别为最大、最小响应值在 y 方向的坐标。计算一定响应值内目标可能出现的位置点区域的面积 S , $S = \pi d^2$,如果 $S > T_2 \omega' h'$ (T_2 为面积阈值, ω' 为搜索域的宽, h' 为搜索域的高),则判断目标受到遮挡,减弱当前帧的模型参数在尺度模板、外观模型和滤波模板更新中的比重,即令(8)~(11)式的 $\theta = 0.01$,否则按照原来的更新方法继续跟踪,即 $\theta = 0.02$ 。

3.3 算法步骤

自适应尺度跟踪算法是以 KCF 算法为跟踪框、在获得目标位置后引入目标的尺度估计方法,算法的跟踪框能随着目标大小自适应地变化,同时引入判断模板更新的遮挡检测方法,避免了引入过多背景信息和丢失过多目标信息的问题,从而建立了更可靠的目标外观模型,提高了算法的准确性。

所提算法的具体步骤为:

1) 输入第一帧目标的位置 p_1 、尺度 S_1 和外观模型 H_1 ,记模板为 M 。

2) 输出当前帧的位置 p_t 、尺度 S_t 、滤波模板系数 α_t 、外观模型 H_t 和尺度滤波模板 h_t 。

for $t=1, 2, \dots, n_{\text{frame}}$

① 在前一帧的位置 p_{t-1} 处提取图像块 z , 循环移位获得候选样本集 $z_i (i=1, 2, \dots, n)$, 对其进行检测, 由(5)式获得的最大响应值确定当前帧目标的位置 p_t ;

② 在 p_t 处以前一帧目标尺度 S_{t-1} 为基准, 提取多种不同尺度 $S_i (i=1, 2, \dots, 2l+1)$ 的图像块;

③ 将尺度为 S_i 的图像块调整到与 M 大小相同的尺寸, 对候选尺度样本进行检测, 由(7)式获得各个候选尺度样本的响应值, 根据最大响应值对应的尺度样本的大小获得当前帧的目标尺度 S_t ;

④ 将大小为 S_t 的候选尺度样本调整到与 M 大小相同的尺寸, 获得当前帧的目标外观模型 H_t , 训练其循环移位样本集, 由(3)式获得当前帧滤波模板系数 α_t , 同时确定尺度滤波模板 h_t ;

⑤ 根据遮挡检测机制判断目标是否受到遮挡, 如果目标受到遮挡, 令(8)~(11)式中的 $\theta=0.01$, 否则令 $\theta=0.02$;

end

4 实验结果与分析

为了验证所提算法的性能, 对 Benchmark 视频库中的 50 组视频进行测试, 并对实验结果进行了定性和定量分析。实验分析采用文献[11]中的评估方法, 将该方法与近年来出现的几种基于检测的优秀跟踪方法[包括 Struck^[16]、多示例学习(MIL)^[7]、时空上下文(STC)^[17]、压缩跟踪(CT)^[18]、TLD^[8]、CSK^[12]以及KCF^[14]]进行比较。

4.1 实验装置与评价标准

实验仿真环境为: Matlab R2012b, Windows 7 系统, Intel Core i3-4170 CPU, 主频 3.7 GHz, 4 GB 内存。实验对所有视频序列参数保持不变, 高斯核的标准差 $\sigma=0.1$, 正则化参数 $\lambda=0.01$, θ 随遮挡检测机制自动变化, 尺度估计因子 $\gamma=1.02$, 尺度数 $l=16$, 选取 HOG 作为图像特征并选取大小为 $4 \text{ pixel} \times 4 \text{ pixel}$ 的单元, 初始化第一帧自动完成。

本实验通过两种评估标准来衡量跟踪器的性能, 分别为距离精度(DP)和成功率(SR), 均称为一次性评估(OPE)。DP 为中心位置误差小于某一阈值的帧数占总帧数的比值, DP 的计算公式为

$$V_{\text{DP}} = n'/n, \quad (13)$$

式中 n' 为跟踪结果的位置与目标的真实位置小于

一定阈值时的帧数, n 为跟踪视频的总帧数。选取与文献[11]相同的阈值(20 pixel)。SR 表示实验获取的跟踪框与其真实跟踪框之间的重叠度超过一定阈值 $T (T \in [0, 1])$ 的帧数与总帧数的比值, 选取与文献[11]相同的阈值 ($T=0.5$)。SR 的计算公式为

$$V_{\text{SR}} = \frac{\text{area}(R_i \cap R_{\text{gt}})}{\text{area}(R_i \cup R_{\text{gt}})}, \quad (14)$$

式中 R_i 表示实验获取的跟踪框区域面积, R_{gt} 表示 ground-truth 中跟踪框区域面积, $\text{area}(\cdot)$ 表示求取括号内结果的面积。

4.2 定性分析

为了比较直观地证明所提算法的有效性, 将多组测试后的视频序列在所有跟踪器中的跟踪结果进行对比, 结果如图 1 所示。图中, 为了区分, 各跟踪器的跟踪框类型分别采用不同颜色的实线框, 红色框表示所提算法的跟踪框, 绿色框表示 KCF 跟踪器的跟踪框, 黄色框表示 TLD 跟踪器的跟踪框, 紫色框表示 CSK 跟踪器的跟踪框, 黑色框表示压缩跟踪器的跟踪框, 蓝色框表示 STC 跟踪器的跟踪框, 橙色框表示 MIL 跟踪器的跟踪框, 灰色框表示 Struck 跟踪器的跟踪框。

1) 尺度与光照变化

在 Singer1 视频中, 目标除了发生尺度与光照的剧烈变化, 还存在遮挡与旋转的问题, 如图 1(a)所示。目标由近及远, 在整个跟踪过程中, 虽然所有算法的跟踪框都能捕捉到目标, 但除了所提方法和 TLD 算法外其他算法的跟踪框都发生了偏移, 而从第 308 帧可以看出, 所提方法略优于 TLD 算法; 在 Car4 视频中, 目标除了发生尺度、光照及姿态的变化外, 还存在背景干扰问题, 如图 1(b)所示。在整个跟踪过程中, 只有所提方法能够根据目标尺度的变化自动调整跟踪窗口的大小, 减少引入背景信息的干扰, 因此能够一直准确地检测目标的位置与尺度; 在 Walking2 视频中, 目标发生了严重的遮挡与尺度变化, 如图 1(c)所示。其他算法的跟踪框发生偏移甚至丢失目标, 所提算法能够较好地完成整个跟踪过程。

2) 遮挡、旋转与运动模糊

在 Jogging2 视频中, 如图 1(d)所示, 目标发生了严重的遮挡后, 其他算法全部跟踪漂移, 目标再次出现时, 只有所提方法和 TLD 可以准确地跟踪; 在 CarScale 视频中, 被跟踪目标存在遮挡和尺度变化的情况, 目标由远及近, 期间并未被树木遮挡, 如图 1(e)所示, 在整个跟踪过程中, 只有所提方法能够较好地跟踪目标; 在 Dog1 视频中, 如图 1(f)所

示,目标除了发生剧烈的尺度变化外,还存在姿态的变化,KCF算法与所提算法表现较好,但KCF算法

跟踪框却不能随着目标大小自适应地变化,而所提算法却能解决这一问题。

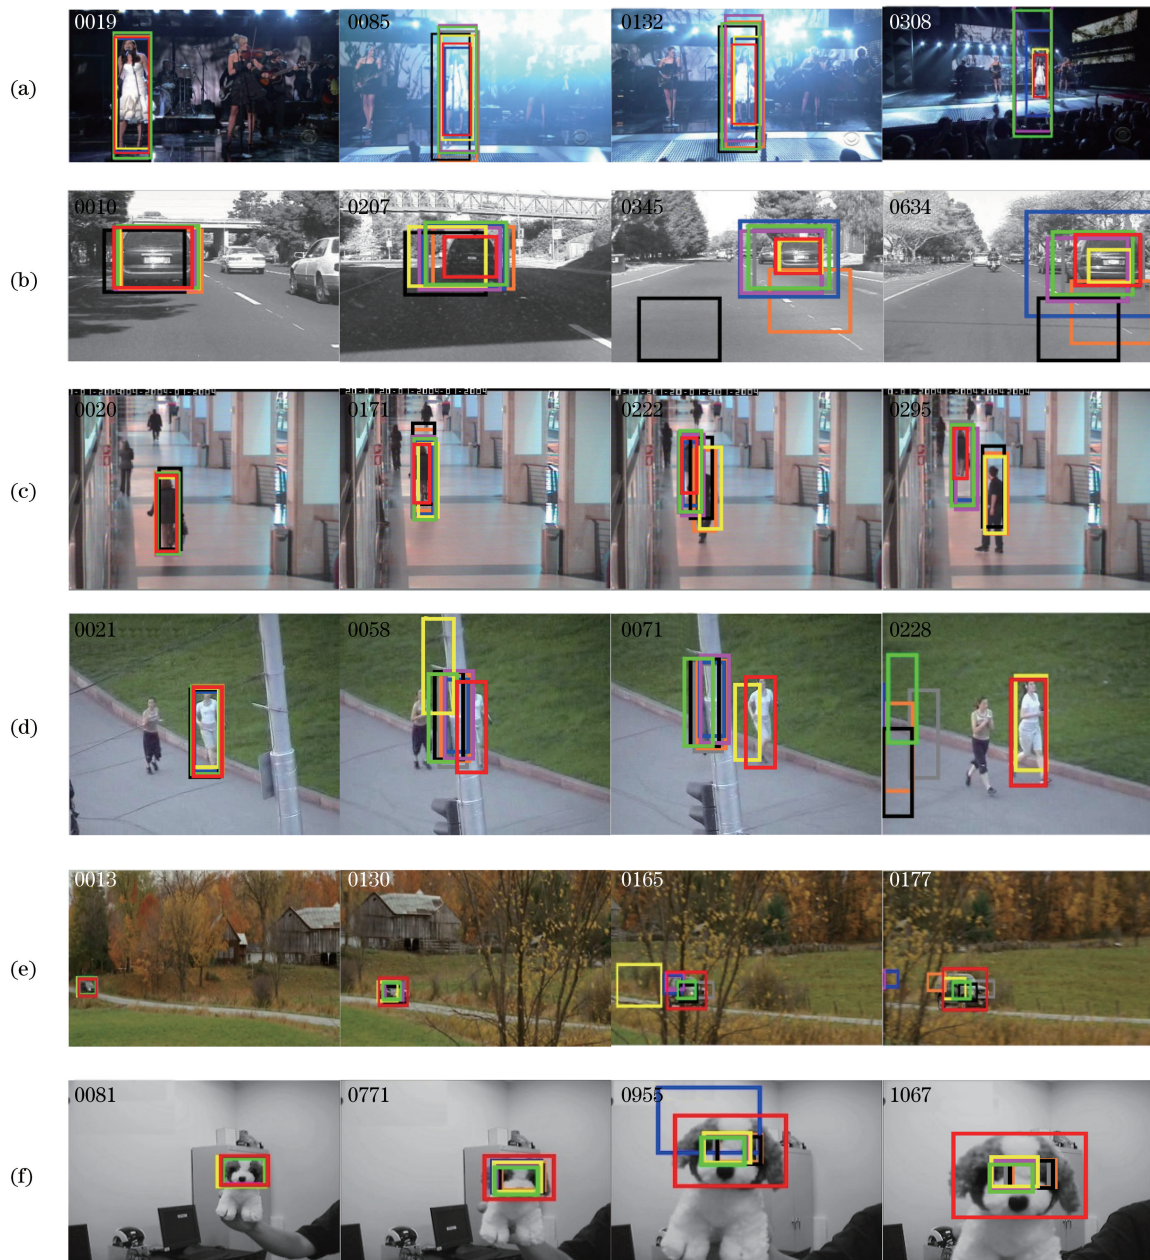


图1 不同算法的跟踪结果对比图。(a) Singer1;(b) Car4;(c) Walking2;(d) Jogging2;(e) CarScale;(f) Dog1

Fig. 1 Comparison of tracking results of different algorithms.

(a) Singer1; (b) Car4; (c) Walking2; (d) Jogging2; (e) CarScale; (f) Dog1

4.3 定量分析

为了验证所提算法的有效性,对 Benchmark 视频库中的 50 组视频序列进行了距离精度与成功率的评估,并与其他几种近年来出现的优秀算法进行对比。图 2(a)、(d)为所有发生尺度变化的 26 组视频序列的距离精度和成功率曲线图,从表 1 的对比数据可以看出,与比较算法中的最优者相比,所提算法的距离精度提高了 53.23%,成功率提高了

40.65%。图 2(b)、(e)为所有发生遮挡(OCC)情况的 27 组视频序列的距离精度和成功率曲线图。从表 1 的对比数据可以看出,与比较算法中的最优者相比,所提算法的距离精度提高了 9.87%,成功率提高了 3.70%。图 2(c)、(f)为考虑所有挑战(AC)因素的所有视频序列的距离精度和成功率曲线图,从表 1 的对比数据可以看出,与比较算法中的最优者相比,所提算法的距离精度提高了 17.12%,成功率

提高了 10.77%。从对比曲线与数据可看出所提算法的优越性。

通过对 50 组视频序列的运行速度求平均得知, KCF 的运行速度为 190.26 frame/s。虽然所提算法

中增加了对目标多种尺度的检测与估计, 计算效率有所降低, 但是在目标的训练与检测过程采用了快速傅里叶变换的方法, 平均运行速度为 35.66 frame/s, 仍然满足实时性的要求。

表 1 不同算法对比数据

Table 1 Comparison data of different algorithms

Factor	Struck		MIL		STC		CT		CSK		TLD		KCF		Proposed	
	V_{DP}	V_{SR}	V_{DP}	V_{SR}	V_{DP}	V_{SR}	V_{DP}	V_{SR}	V_{DP}	V_{SR}	V_{DP}	V_{SR}	V_{DP}	V_{SR}	V_{DP}	V_{SR}
Scale variation	0.327	0.387	0.301	0.329	0.286	0.334	0.267	0.291	0.293	0.341	0.372	0.399	0.339	0.401	0.570	0.554
OCC	0.388	0.412	0.312	0.329	0.263	0.319	0.290	0.308	0.338	0.365	0.348	0.412	0.466	0.487	0.501	0.505
AC	0.427	0.446	0.354	0.348	0.315	0.346	0.287	0.294	0.373	0.389	0.411	0.419	0.479	0.492	0.561	0.545

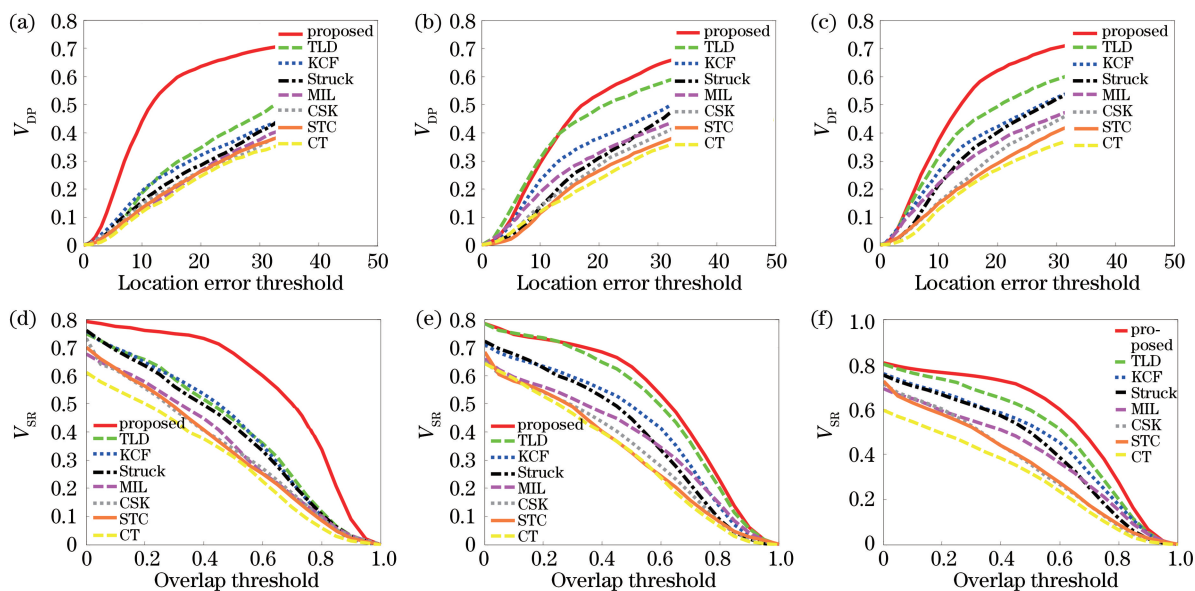


图 2 各算法的 DP 和 SR 曲线图。(a) OPE-SR 的 DP 曲线; (b) OPE-OCC 的 DP 曲线; (c) OPE 的 DP 曲线; (d) OPE-SR 的 SR 曲线; (e) OPE-OCC 的 SR 曲线; (f) OPE 的 SR 曲线

Fig. 2 DP and SR plots of different algorithms. (a) DP plots of OPE-SR; (b) DP plots of OPE-OCC; (c) DP plots of OPE; (d) SR plots of OPE-SR; (e) SR plots of OPE-OCC; (f) SR plots of OPE

5 结 论

提出了一种自适应尺度的 KCF 目标跟踪算法, 在 KCF 的基础上引入尺度估计方法。根据对目标区域采样的多种尺度的检测结果, 判断目标的大小, 使算法的跟踪框能随着目标大小自适应地变化。通过遮挡检测判断目标的遮挡情况, 更新滤波模板系数、外观模型和尺度模板。从 Benchmark 视频库中选取 50 组视频序列进行测试, 并与其他几种优秀的跟踪算法相比。由测试结果可以看出所提算法不仅能适应目标尺度变化与严重遮挡的情况, 而且当考虑光照和姿态变化、背景干扰等复杂情况时, 与比较算法中的最优者相比, 所提算法的 DP 提高了 17.12%, SR 提高了 10.77%, 具有重要的理论和应

用研究价值。但是所提算法对于快速运动的目标跟踪效果较差, 主要是因为搜索的中心点是根据前一帧目标的中心点来确定的, 且搜索的范围有限。未来的研究重点是在 KCF 的基础上引入运动状态估计的方法, 使得跟踪能够在更为复杂的场景中更加稳健和高效。

参 考 文 献

- [1] Zhu J, Lao Y, Zheng Y F. Objecttracking in structured environments for video surveillance applications[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2010, 20(2): 223-235.
- [2] Zou Y B, Zhou W L, Chen X Z. Research of laser

- vision seam detection and tracking system based on depth hierarchical feature[J]. Chinese Journal of Lasers, 2017, 44(4): 0402009.
- 邹焱飏, 周卫林, 陈向志. 基于深度分层特征的激光视觉焊接检测与跟踪系统研究[J]. 中国激光, 2017, 44(4): 0402009.
- [3] Xie Z X, Chen W Z, Chi S K, *et al.* Industrial robust positioning system based on the guidance of the structured-light vision [J]. Acta Optica Sinica, 2016, 36(10): 1015001.
- 解则晓, 陈文柱, 迟书凯, 等. 基于结构光视觉引导的工业机器人定位系统 [J]. 光学学报, 2016, 36(10): 1015001.
- [4] Qiu C C, Li Q W, Wang T, *et al.* An improved IVT algorithm for object tracking[J]. Laser & Optoelectronics Progress, 2016, 53(1): 011002.
- 仇春春, 李庆武, 王恬, 等. 一种改进的 IVT 目标跟踪算法 [J]. 激光与光电子学进展, 2016, 53(1): 011002.
- [5] Liu H, Chen Y. Target tracking based on adaptive fusion of multi-feature[J]. Opto-Electronic Engineering, 2016, 43(3): 58-65.
- 刘行, 陈莹. 自适应多特征融合目标跟踪 [J]. 光电工程, 2016, 43(3): 58-65.
- [6] Avidan S. Ensemble tracking[J]. IEEE Transactions Pattern Analysis & Machine Intelligence, 2007, 29(2): 261-271.
- [7] Babenko B, Yang M H, Belongie S. Robust object tracking with online multiple instance learning [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(8): 1619-1632.
- [8] Kalal Z, Mikolajczyk K, Matas J. Tracking-learning-detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(7): 1409-1422.
- [9] Nam H, Han B. Learning multi-domain convolutional neural networks for visual tracking[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016: 4293-4302.
- [10] Bertinetto L, Valmadre J, Henriques J F, *et al.* Fully-convolutional Siamese networks for object tracking[C]. European Conference on Computer Vision, 2016: 850-865.
- [11] Wu Y, Lim J, Yang M H. Object tracking benchmark[J]. Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1834-1848.
- [12] Henriques J F, Caseiro R, Martins P, *et al.* Exploiting the circulant structure of tracking-by-detection with kernels[C]. European Conference on Computer Vision, 2012: 702-715.
- [13] Danelljan M, Khan F S, Felsberg M, *et al.* Adaptive color attributes for real-time visual tracking[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2014: 1090-1097.
- [14] 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.
- [15] Scholkopf B, Smola A J. Learning with kernels: Support vector machines, regularization, optimization, and beyond[M]. London: The MIT Press, 2002.
- [16] Hare S, Saffari A, Philip H S. Structured output tracking with kernels [C]. International Conference on Computer Vision, 2011: 263-270.
- [17] Zhang K, Zhang L, Yang M H, *et al.* Fast tracking via spatio-temporal context learning [C]. European Conference on Computer Vision, 2014: 127-141.
- [18] Zhang K, Zhang L, Yang M H. Real-time compressive tracking [C]. European Conference on Computer Vision, 2012: 864-877.