

DOI: 10.19650/j.cnki.cjsi.J1904693

基于多模型融合和重新检测的高精度鲁棒目标跟踪^{*}

白中浩^{1,2}, 朱磊¹, 李智强¹

(1. 湖南大学 汽车车身先进设计制造国家重点实验室 长沙 410082; 2. 福建工程学院
福建省汽车电子与电驱动重点实验室 福州 350118)

摘要:针对目标跟踪在遮挡和光照变化等复杂场景下容易跟踪失败的问题,提出一种高精度鲁棒的目标跟踪算法。首先,将基于边缘信息的目标模型、基于梯度直方图(HOG)特征的滤波器模型和基于颜色直方图的颜色模型融合为更准确和鲁棒性更强的跟踪模型;然后,提出基于特征分数的双重跟踪可靠性判断依据,检测跟踪结果的可靠性;最后,在跟踪结果可靠性较低时,采用粒子滤波、稀疏表示以及距离约束定位进行重新检测,以实现持续稳定的跟踪。算法在 OTB-2015 数据集上的平均重叠精度为 78.2%,平均中心位置误差为 23.1 pixel,平均跟踪速率为 30.8 f/s,准确度和鲁棒性优于其他算法。在移动机器人和车辆跟踪平台上进行算法验证,平均重叠精度分别为 97.5% 和 97.2%,平均中心位置误差分别为 6.8 和 12.6 pixel,平均跟踪速率分别为 29.1 和 28.4 f/s,能有效跟踪上述复杂场景的目标,且满足实时要求。

关键词: 目标跟踪;移动机器人;多模型融合;重新检测;相关滤波;粒子滤波

中图分类号: TP391.4 TH701 **文献标识码:** A **国家标准学科分类代码:** 510.4050

High-accuracy and robust object tracking based on multi-model fusion and re-detection

Bai Zhonghao^{1,2}, Zhu Lei¹, Li Zhiqiang¹

(1. State Key Laboratory of Advanced Design and Manufacturing for Vehicle Body, Hunan University, Changsha 410082, China;
2. Fujian Key Laboratory of Automotive Electronics and Electric Drive, Fujian University of Technology, Fuzhou 350118, China)

Abstract: Aiming at the problem that object tracking is subject to failure in complex scenes such as occlusion and illumination variation, a high-accuracy and robust object tracking algorithm is proposed. Firstly, the target model based on edge information, the filter model based on HOG feature and the color model based on color histogram are merged into a more accurate and strong robust tracking model. Then, the double tracking reliability judgment criterion based on the score of the feature is proposed to detect the reliability of the tracking result. Finally, when the reliability of the tracking result is low, particle filtering, sparse representation and distance constraint positioning are used for re-detection to achieve continuous and stable tracking. On the OTB-2015 dataset, the average overlap precision of the proposed algorithm is 78.2%, the average center location error is 23.1 pixel and the average tracking rate is 30.8 f/s, which indicates that the accuracy and robustness are better than those of other algorithms. The algorithm was verified on mobile robot and vehicle tracking platform, the average overlap precisions are 97.5% and 97.2%, the average center location errors are 6.8 pixel and 12.6 pixel, respectively, and the average tracking rates are 29.1 and 28.4 f/s, respectively. The proposed algorithm can effectively track the targets in above mentioned complex scenes and meet the real-time requirements.

Keywords: object tracking; mobile robot; multi-model fusion; re-detection; correlation filtering; particle filtering

0 引言

目标跟踪是计算机视觉领域的重要组成部分,广泛

应用于移动机器人跟踪导航、智能驾驶、视频监控等诸多领域^[1]。近年来目标跟踪在以上领域有了许多进展,但是由于遮挡、超出视野、光照变化和变形等因素的影响,建立准确度高、鲁棒性强且满足实时性的目标跟踪仍然

是亟待解决的难题^[2-3]。

相关滤波目标跟踪因其在速率和鲁棒性方面的优势而备受国内外学者的关注。Henriques等^[4]提出基于核空间的循环结构(circulant structure kernels, CSK)算法,采用密集采样训练得到了更加鲁棒和准确的滤波器,之后又使用核相关滤波器(kernelized correlation filters, KCF)改进CSK算法^[5],取得了较好的跟踪效果。Danelljan等^[6]引入尺度滤波器(discriminative scale space tracking, DSST)实现尺度的自适应。在DSST基础上,Li等^[7]提出多特征融合跟踪器(scale adaptive with multiple features tracker, SAMF),将梯度直方图特征(Histograms of Oriented Gradients, HOG)与颜色特征(Color Names, CN)融合实现了良好的跟踪性能。郭玲^[8]提出多尺度的核相关滤波器实现了较高的跟踪速率,但是跟踪准确度和鲁棒性还有待提高。文献[9]将卷积神经网络特征应用到跟踪中,卷积神经网络特征能够很好地表征目标的位置与语义信息,故取得了优越的跟踪效果,但是由于特征维度高,计算耗时,导致跟踪速率较慢。Bertinetto等^[10]融合滤波器模型和颜色模型(sum of template and pixel-wise learners, Staple),将二者的响应在决策层进行融合,能有效处理背景杂乱。但是,当目标经历光照变化和变形时,上述跟踪算法的准确度和鲁棒性较差,仍有很大的提升空间。戴伟聪等^[11]在Staple算法基础上提出局部敏感直方图分类器及自适应融合系数,提高了模型对于光照变化和变形等因素的鲁棒性。刘万军等^[12]提出自适应特征选择的滤波器,多融合特征能够适应目标的快速运动、变形和光照变化。但是,上述跟踪算法忽略了跟踪结果的可靠性,缺乏有效的机制来检测不可靠的跟踪结果^[13-14]。长时跟踪过程中,当目标经历严重遮挡或者超出视野时,跟踪结果可能不可靠。因此,必须检查跟踪结果的可靠性。Kalal等^[15]将跟踪任务分解为跟踪、学习和检测(tracking-learning-detection, TLD),能有效处理部分遮挡的问题。Ma等^[16]提出经典的长时跟踪算法(long-term correlation tracking, LCT),它解决了目标变形、突然运动和部分遮挡问题。刘大千等^[17]提出一种抗干扰匹配的前景约束目标跟踪算法,在目标出现遮挡时在特征集中加入特征补偿,能有效地处理部分遮挡问题。但是目标经历严重遮挡或超出视野场景时,上述跟踪算法无法进行持续稳定地跟踪。

针对以上问题,本文提出了多模型融合和重新检测的高精度鲁棒目标跟踪算法,将基于边缘信息的目标模型、基于HOG特征的滤波器模型和基于颜色直方图的颜色模型进行融合,3个互补模型融合形成了准确度更高和鲁棒性更强的跟踪模型;提出了双重跟踪可靠性判断依据,在线检测跟踪结果的可靠性,基于3个互补模型的特征分数进行结果可靠性的判断,提高了跟踪结果的可靠性;提出了基于粒子滤波、稀疏表示及

距离约束定位的重新检测模块,对于不可靠的跟踪结果,重新检测模块首先使用粒子滤波和稀疏表示进行候选结果的粗略定位,再使用距离约束定位进行精确定位,降低了遮挡、超出视野等因素的干扰;在PC、移动机器人和车辆跟踪平台上验证了本文算法进行跟踪的准确性、鲁棒性和实时性。

1 多模型融合和重新检测的高精度鲁棒目标跟踪

在相关滤波目标跟踪中,以目标为中心,循环移位选取目标周围尺寸大小为 $m \times n$ 的图像块 x ,用这些图像块训练线性分类器 $f(x) = \langle w, \varphi(x) \rangle$,对图像块 x 进行一维或多维特征提取后对应的标签数据为 y 。在采用正则化最小二乘并引入核函数的条件下可以得到:

$$\underset{w}{\operatorname{argmin}} \sum_{m,n} \|\langle w, \varphi(x_{m,n}) \rangle - y(m,n) \|_2^2 + \lambda \|w\|_2^2 \quad (1)$$

式中: $\lambda \geq 0$ 为正则化参数; $\varphi(x)$ 表示原始输入空间到Hilbert特征空间的映射函数,定义核空间内积 $k(x, x') = \langle \varphi(x), \varphi(x') \rangle$,则目标解为 $w = \sum_{m,n} \alpha(m,n) k(x_{m,n}, x)$ 。

利用循环矩阵核离散傅里叶变换,得到核化正则最小二乘的最优解为:

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

式中: $\hat{\alpha}$ 为傅里叶域中的 α 。

在下一帧图像中,获取图像块 z 来检测目标位置,分类器的输出响应为:

$$\hat{y} = F^{-1}(\hat{k}^{xz} \Theta \hat{\alpha}) \quad (3)$$

式中: F^{-1} 表示傅里叶逆变换; Θ 表示哈达玛乘积,找到最大响应 $\hat{y}$ 所在的位置即为待跟踪目标的位置。

本文算法的跟踪框架如图1所示。首先,在相关滤波目标跟踪基础上,将基于边缘信息的目标模型、基于HOG特征的滤波器模型和基于颜色直方图的颜色模型融合以形成多模型跟踪器,通过融合多通道互补特征响应,能更大程度地利用目标信息和判别式的多样性,提高跟踪器的准确度和鲁棒性,多模型融合模块负责提取跟踪目标的特征信息以及计算每个模型的响应,最后将3个模型的响应进行线性融合。然后,提出了双重跟踪可靠性判断依据,分别是宽松的可靠性判断依据和严格的可靠性判断依据,基于3个模型的特征分数,使用宽松的可靠性判断依据进行结果可靠性的初步判断,如果不满足条件则输出最初的跟踪结果,反之,则进行重新检测。最后,融入了重新检测,对于不可靠的跟踪结果基于粒子滤波、稀疏表示及距离约束定位进行重新检测,使用严格的可靠性判断依据进行

可靠性判断,如果满足条件则输出重新检测的跟踪结果

果,反之,输出最初的跟踪结果。




图1 本文的跟踪算法框架

Fig.1 Framework of the proposed tracking algorithm

1.1 多模型融合

如图2所示,对于跟踪目标,首先提取输入图像的HOG特征,再计算滤波器模型响应。因为传统的相关滤波器都以提取HOG特征作为基准,故基于HOG特征的滤波器模型响应可由式(3)求得,具体如式(4)所示。

$$f_h = F^{-1}(\hat{\mathbf{k}}^w \Theta \hat{\mathbf{a}}) \quad (4)$$




图2 基于HOG特征的滤波器模型生成响应

Fig.2 The generation response of the filter model based on HOG feature

如图3所示,对于跟踪目标,首先提取输入图像的颜色直方图特征,再计算颜色模型的响应。颜色模型是基于RGB颜色空间进行计算的,将RGB空间表示的每个像素 u 映射到索引特征 $\mathbf{j} = \varphi(u)$ 的 $32 \text{ bin} \times 32 \text{ bin} \times 32 \text{ bin}$ 颜色直方图中。根据颜色直方图跟踪器^[18],颜色直方图权重 $\mathbf{w}_c$ 可以通过式(5)求得。

$$\underset{\mathbf{w}_c}{\operatorname{argmin}} \frac{1}{|\mathbf{O}|} \sum_{u \in \mathbf{O}} \|\mathbf{w}_c^T \boldsymbol{\varphi}(u) - 1\|^2 + \frac{1}{|\mathbf{S}|} \sum_{u \in \mathbf{S}} \|\mathbf{w}_c^T \boldsymbol{\varphi}(u)\|^2 \quad (5)$$

式中: $\boldsymbol{\varphi}(u)$ 表示图像块在有限区域 $\mathbf{R}$ 中的特征像素。假设 $\mathbf{\Omega}$ 是一个区域, $\mathbf{\Omega} \in \{\mathbf{O}, \mathbf{S}\}$, $\mathbf{O}$ 为目标的前景区域, $\mathbf{S}$ 为目标的背景区域。 $\mathbf{\Omega}$ 中每个索引特征 $\mathbf{j}$ 的比例表示为 $P^j = N^j(\mathbf{\Omega}) / |\mathbf{\Omega}|$, $N^j(\mathbf{\Omega}) = |\{u \in \mathbf{\Omega} : \boldsymbol{\varphi}(u) = \mathbf{j}\}|$ 表示 $\mathbf{\Omega}$ 中索引特征 $\mathbf{j}$ 的像素点数量, $|\mathbf{\Omega}|$ 表示 $\mathbf{\Omega}$ 中所有的像素点数量。

式(5)的岭回归问题的目标解为:




图3 基于颜色直方图特征的颜色模型生成响应

Fig.3 The generation response of the color model based on color histogram feature

$$\mathbf{w}_c^j = \frac{p^j(\mathbf{O})}{p^j(\mathbf{O}) + p^j(\mathbf{S}) + \lambda} \quad (6)$$

式中: $\mathbf{j} = 1, 2, \dots, K$ 。 K 为颜色直方图空间的维度($32 \times 32 \times 32$)。在获得颜色直方图权重 $\mathbf{w}_c$ 之后,对于选取的图像块 $\mathbf{z}$,可以计算得到每个像素的颜色概率得分图。在采用积分图方法的条件下,颜色模型响应为:

$$f_c = \sum_u \mathbf{w}_c^T \boldsymbol{\varphi}_{u \in \mathbf{z}(u)} \quad (7)$$

如图4所示,对于跟踪目标,首先利用Edge Boxes算法^[19]提取输入图像的边缘信息,从而生成边缘图,再使用非极大值抑制(non-maximum suppression, NMS)将冗余的边缘剔除掉生成边缘族,一般认为目标的边缘梯度主要是分布在边缘,故用整体的边缘梯度减去目标中心区域的冗余梯度。同时,为了减少不同边界框尺度带来的边缘梯度差异性,使用边界框尺寸作为分母,使用式(8)计算目标模型的响应。

$$f_e = \frac{\sum_i \zeta_i m_i}{2(b_w + b_h)^n} - \frac{\sum_{r \in b^m} m_r}{2(b_w + b_h)^n} \quad (8)$$

式中: b_w 和 b_h 分别是边界框的宽度和高度; b^m 为宽和高分别为 $b_w/2$ 、 $b_h/2$ 的边界框中心区域; r 表示边界框中的某个边缘; m_r 为 r 的边缘梯度; $\zeta_i \in [0, 1]$ 表示连通区域 $\hat{\mathbf{g}}_i$ 属于边界框的概率; m_i 表示所有属于连通区域 $\hat{\mathbf{g}}_i$ 的边缘梯度 m_r 的总和; n 表示边界框尺寸的惩罚因子。对于每一帧图像,在计算完滤波器模型响应、颜色模型响应及

目标模型响应之后,最后的响应为三者的线性组合。

$$f^{(i)} = (\pi_c) f_c^{(i)} + (\pi_e) f_e^{(i)} + (1 - \pi_c - \pi_e) f_h^{(i)} \quad (9)$$

式中: i 表示第 i 帧图像; π_c 为颜色模型响应的权重因子; π_e 为目标模型响应的权重因子。下一帧的跟踪位置为响应 $f^{(i)}$ 最大值所在的位置。




图4 基于边缘信息的目标模型生成响应

Fig.4 The generation response of the target model based on edge information

1.2 双重跟踪可靠性判断

利用 HOG 特征分数、颜色直方图分数和边缘信息分数来估计跟踪结果的可靠性。对于基于 HOG 特征的滤波器响应,利用式(10)计算平均峰值能量(average peak-to-correlation energy, APCE)^[20]值作为 HOG 特征分数 $S_h^{(i)}$ 。该值可反映 HOG 特征滤波器响应的振荡程度,当 APCE 突然减小时,说明目标经历遮挡或者超出视野。

$$S_h^{(i)} = \frac{|f_{h_{\max}}^{(i)} - f_{h_{\min}}^{(i)}|^2}{\text{mean}(\sum_{p,q} (f_{h(p,q)}^{(i)} - f_{h_{\min}}^{(i)})^2)} \quad (10)$$

式中: $f_{h_{\max}}^{(i)}$ 是第 i 帧图像的最高响应; $f_{h_{\min}}^{(i)}$ 是第 i 帧图像的最低响应; $f_{h(p,q)}^{(i)}$ 是 (p,q) 位置上的响应。

对于基于颜色直方图的颜色模型,本文基于第1帧图像中的颜色直方图计算每个像素所对应的颜色概率得分图,并且对目标区域内的所有像素求和以获得目标前景颜色概率分布。将后续图像的颜色概率分布与第一帧图像中该概率分布进行对比,比值定义为颜色直方图特征分数 $S_c^{(i)}$ 。

$$S_c^{(i)} = \frac{\sum_u w_c^T \varphi_i(u)}{\sum_u w_c^T \varphi_1(u)} \quad (11)$$

对于基于边缘信息的目标模型,将后续图像的边缘梯度与第1帧图像的边缘梯度进行比较,利用目标模型的边缘信息响应计算得到的百分比定义为边缘信息分数,由式(8)可得边缘信息分数 $S_e^{(i)}$ 。

$$S_e^{(i)} = \frac{f_e^{(i)}}{f_e^{(1)}} \quad (12)$$

判断标准将采用所有帧图像内每种特征分数的平均值 C_v 。

$$C_v = \frac{\sum_{i=0}^{\gamma} S_v^{(i)}}{\gamma} \quad (13)$$

式中: γ 为当前跟踪序列图像的总帧数; v 分别为 h, c, e 。

为了检查跟踪结果的可靠性,本文提出双重跟踪可靠性判断依据,分别是宽松的可靠性判断依据和严格的可靠性判断依据。宽松的可靠性判断依据即:当 $S_h < \beta_h^1 \cdot C_h$ 、 $S_c < \beta_c^1 \cdot C_c$ 、 $S_e < \beta_e^1 \cdot C_e$ 不成立时,说明跟踪结果可靠,输出最初的跟踪结果,如果成立,说明跟踪结果不可靠,此时进行重新检测,在重新检测之后使用严格的可靠性判断依据进行可靠性判断:当 $S_h \cdot d^{(i)} > \beta_h^2 \cdot C_h$ 、 $S_c \cdot d^{(i)} > \beta_c^2 \cdot C_c$ 、 $S_e \cdot d^{(i)} > \beta_e^2 \cdot C_e$ 成立时,采用重新检测后 $S^{(i)}$ 最大的候选结果作为最终的跟踪结果。反之,输出最初的跟踪结果。

1.3 重新检测

为了重新跟踪目标,分别进行粗略定位和精确定位。首先使用粒子滤波在前一帧的跟踪结果周围选择 N 个跟踪候选结果,再使用稀疏表示进行粗略定位。在候选结果 x 周围选择一个样本集合 Q ,该集合包含 N_p 个接近目标的正样本 Q_p 和 N_n 个远离目标的负样本 Q_n 。然后,对于每个候选结果 x ,计算其样本系数 $\alpha, \alpha = [\alpha_p, \alpha_n], \alpha_p$ 为正样本系数, α_n 为负样本系数,系数可由式(4)求得。

$$\min_{\alpha} \|x - Q\alpha\|_2^2 + \lambda \|\alpha\|_1 \quad (14)$$

具有较小重构误差的正样本最有可能是正确的跟踪目标。通过计算每个候选结果的重构误差,可以预测第 i 个候选结果的跟踪可靠性为:

$$g_i = \|x_i - Q_n \alpha_n\|_2^2 - \|x_i - Q_p \alpha_p\|_2^2 \quad (15)$$

g_i 越高,代表该候选结果是正确跟踪结果的可靠性越大。通过对 g_i 设定阈值,可以丢弃大量可靠性较低的候选结果,有效地减少精确定位阶段的计算开销。剩下的候选结果采用多模型融合模块计算滤波器模型响应、颜色模型响应及目标模型响应。同时,计算候选结果与上一帧跟踪结果的欧氏距离分数为:

$$d^{(i)} = \cos\left(\frac{\theta}{W_i + H_i} \|L^{(i)} - L_i\|\right) \quad (16)$$

式中: θ 为距离惩罚因子; $L^{(i)}$ 为第 i 个候选结果的中心位置坐标; L_i 为上一帧的中心位置坐标; W_i 和 H_i 为上一帧图像的宽和高; $d^{(i)}$ 为第 i 个候选结果的距离分数。为了对候选结果进行精确定位,进一步地筛选候选结果,采用多模型响应和距离分数来同时约束候选结果,计算候选结果的总分数为:

$$S^{(i)} = \max(f^{(i)}) \cdot d^{(i)} \quad (17)$$

式中: $f^{(i)}$ 为由式(9)得到的第 i 个候选结果的多模型响应分数; $S^{(i)}$ 为第 i 个候选结果的总分数。选择 $S^{(i)}$ 最大的候选结果,再使用严格的可靠性判断依据对 $S^{(i)}$ 最大的候选结果的可靠性进行判断。当满足严格的可靠性判断依据时,采用 $S^{(i)}$ 最大的候选结果作为最终的跟踪结果。反之,采用最初的跟踪结果。

2 算法性能测试实验

为了评估本文算法的跟踪性能,在包含 100 个测试序列的 OTB-2015^[21]数据集上进行实验。实验配置为 Intel(R) Core(TM) i5-7200U CPU,主频 2.5 GHz,内存 8 GB 的 PC,开发工具为 MATLAB R2017a。实验中正则化参数 λ 为 0.001,边界框尺寸的惩罚因子 n 为 1.5。为了平衡跟踪精度和速率,宽松的可靠性判断依据中 $\beta_h^1 = 0.6, \beta_c^1 = 0.7, \beta_e^1 = 0.6$,严格的可靠性判断依据中 $\beta_h^2 = 0.7, \beta_c^2 = 0.8, \beta_e^2 = 0.7$ 。为了减少粗略定位过程的计算开销,重新检测模块中 $N_p = 50, N_n = 200, \theta = \pi/6$ 。评价指标除了选用重叠精度、中心位置误差和算法速率之外,还使用了一次跟踪评估(one-pass evaluation, OPE)中的成功率曲线和精度曲线。重叠精度为跟踪成功帧数占跟踪总帧数的比例,当重叠率大于 0.5 时认为跟踪成功,重叠率为跟踪框与真实框的交集与并集之比。中心位置误差为跟踪框中心与真实框中心的欧氏距离。算法速率为跟踪总帧数与跟踪算法的耗时之比。成功率为成功率曲线的线下面积。精度为中心位置误差大于 20 pixel 的跟踪帧数占跟踪总帧数的比例。

2.1 取不同的响应权重因子时的成功率实验

为了得到本文算法 3 个模型的响应权重因子的最优取值,使用 OPE 在 OTB-2015 上得到了本文算法在选取不同的响应权重因子 π_c 和 π_e 时的成功率。如图 5 所示,成功率越高代表跟踪效果越好,当 $\pi_c = 0.25, \pi_e = 0.2$

时,本文算法的成功率最高,故在后续实验中选取 $\pi_c = 0.25$ 和 $\pi_e = 0.2$ 作为本文算法的响应权重因子。




图 5 不同 π_c 和 π_e 时的成功率对比

Fig.5 Comparison of success rates for different π_c and π_e .

2.2 与 9 种主流跟踪算法的对比实验

为了对比算法的跟踪性能,选取近年来主流的 9 种跟踪算法 HCFTs (hierarchical correlation features-based tracker)^[9]、SRDCF (spatially regularized discriminative correlation filter)^[22]、Staple^[10]、LCT^[16]、SAMF^[7]、DSST^[6]、KCF^[5]、Struck (structured output tracking)^[23]、TLD^[15]和本文算法进行比较。具体结果如表 1 和图 6 所示。

由表 1 和图 6 可知,在 OTB-2015 中本文算法的重叠精度为 78.2%,中心位置误差为 23.1 pixel,成功率为 0.636,精度为 0.840,均取得了最佳的结果,整体性能优于其他 9 种主流跟踪算法。同时,本文算法速率为 30.8 f/s,满足了跟踪实时性的要求。

表 1 10 种跟踪算法的平均跟踪性能比较

Table 1 Average tracking performance comparison of ten tracking algorithms										
算法	TLD	Struck	KCF	DSST	SAMF	LCT	Staple	SRDCF	HCFTs	本文算法
重叠精度/%	44.5	48.3	54.3	60.1	67.4	70.1	69	71.6	72.0	78.2
中心位置误差/pixel	61.0	51.9	45.5	51.4	35.8	67.2	32.2	39.7	25.1	23.1
跟踪速率/f·s ⁻¹	36.7	17.8	176.0	25.2	17.1	21.4	64.9	5.4	1.5	30.8


2.3 复杂场景下的跟踪性能对比实验

为了更具体地分析跟踪算法在复杂场景下的跟踪性能,对 OTB-2015 数据集的场景进行了测试,OTB-2015 中的测试序列包含遮挡、超出视野、光照变化、变形等共 11 个场景,其中遮挡场景共有 49 个序列,超出视野场景共有 14 个序列,光照变化场景共有 38 个序列,变形场景共有 44 个序列。图 7 所示为包括本文算法在内的 10 个跟踪算法在 OTB-2015 中 100 个测试序列的 4 种复杂场景的成功率曲线,本文算法在 4 个场景的跟踪成功率均排名第 1。在图 7(a)遮挡场景和图 7(b)超出视野场景中,由于本文算法采用了双重跟踪可靠性判断依据和重新检测模块,当跟踪目标经历遮挡或者超出视野时,能够基于粒子滤波、稀


疏表示及距离约束定位进行重新检测,故对于遮挡和超出视野有很好的跟踪效果,在遮挡和超出视野场景中的成功率分别比第 2 名的 HCFTs 高 7.9%和 5.2%,比长时跟踪算法 LCT 提高了 18.7%和 20.8%。同时,由于本文算法融合了边缘信息、HOG 和颜色直方图,多特征互补使模型的判别性和鲁棒性更强,对光照变化、变形等场景有较好的适应性,故在图 7(c)光照变化场景中,成功率比第 2 名的 HCFTs 高 4.8%,在图 7(d)变形场景中,成功率比第 2 名的 HCFTs 提高了 6.4%。

2.4 定性评价实验

图 8 所示为图 6(a)中除本文算法外成功率前五名的 HCFTs、SRDCF、Staple、LCT、SAMF 算法在 3 个复




(a) 一次跟踪评估的成功率曲线
(a) Success plots of OPE




(b) 一次跟踪评估的精度曲线
(b) Precision plots of OPE

图6 本文算法和其他9种算法的一次跟踪评估的成功率曲线和精度曲线


Fig.6 The success plots and precision plots of OPE for the proposed algorithm and another nine algorithms




(a) 遮挡场景下的一次跟踪评估的成功率曲线
(a) Success plots of OPE under occlusion



(b) 超出视野场景下的一次跟踪评估的成功率曲线
(b) Success plots of OPE under out of view



(c) 光照变化场景下的一次跟踪评估的成功率曲线
(c) Success plots of OPE under illumination variation



(d) 变形场景下的一次跟踪评估的成功率曲线
(d) Success plots of OPE under deformation

图7 本文算法和其他9种算法在4种场景下的一次跟踪评估的成功率曲线

Fig.7 The success plots of OPE for the proposed algorithm and another nine algorithms under four scenes

杂场序列的实验结果。图9所示为6种算法在3个复杂场景序列上的跟踪中心位置误差,本文算法均取得了最佳的结果。图8(a)和图9(a)中Girl2跟踪结果所示,在第108帧时目标开始出现遮挡,第185帧时HCFTs、SRDCF、Staple、LCT、SAMF都跟踪到了相似干扰目标,第1156帧时HCFTs、SRDCF、Staple、LCT由于学习到目标背景信息导致模型漂移,SAMF虽然跟踪到了目标,但是跟踪中心位置误差较大,而本文算法采用多互补特征融合,增强了模型的判别性,同时,双重可靠性判断依据能够对跟踪结果进行判断,重新检测模块能够在目标出现遮挡或超出视野时进行重新检测,所以能够对目标进行持续稳定且高精度的跟踪。如图8(b)和图9(b)中ClifBar跟踪结果所示,第80帧时目标出现背景杂乱和运动模糊,采用单一特征的LCT判别性较差,故跟踪失败,第235帧和357帧时,由于遮挡、超出视野等因素的影响,HCFTs、SRDCF、Staple、SAMF出现跟踪漂移,跟踪中心位置误差逐渐累积,本文算法和LCT均有重新检测模块故可以重新检测目标继续跟踪。如图8(c)和9(c)中Tiger1跟踪结果所示,由于遮挡、变形和光照变化等因素的影响,导致SRDCF和Staple跟踪失败,本文算法的

多种模型能够针对目标的不同特征进行互补融合,可以更好地表征目标的特征,重新检测模块则能减少不可靠的跟踪结果,故跟踪定位更准确,中心位置误差相对于 HCFTs、LCT、SAMF 更低,跟踪更准确。




图 8 不同算法的跟踪结果

Fig.8 Tracking results of different algorithms




图 9 不同算法的跟踪中心位置误差

Fig.9 tracking center location errors of different algorithms

3 真实场景实验

为了验证本文算法在实际场景中的准确性、鲁棒性和实时性,分别进行了移动机器人跟踪和车辆跟踪实验,对实际应用中影响目标跟踪的遮挡、超出视野、光照变化、变形、尺度变化等主要因素进行了定量和定性分析。

3.1 移动机器人跟踪实验

如图 10 所示,移动机器人配置了 Autolabor Pro1 移动底盘,Granttech UF06388H-ZS 工控机及 Kinect 摄像头。将本文算法移植到移动机器人平台进行复杂场景下的跟踪实验,对跟踪结果进行定性和定量评价,跟踪结果如图 11 和表 2 所示。



图 10 移动机器人平台

Fig.10 Mobile robot platform




图 11 复杂场景下的跟踪效果

Fig.11 Tracking results under complex scenes

表 2 复杂场景下的平均跟踪结果

Table 2 Average tracking results under complex scenes

序列	重叠精度/%	中心位置误差/pixel	跟踪速率/ $f \cdot s^{-1}$
1	98.7	5.8	28.6
2	97.3	6.9	26.3
3	96.6	7.6	32.5
平均值	97.5	6.8	29.1

如图 11(a) 所示,序列 1 中的跟踪目标为从光线较亮处走到较暗处的行人,第 10~65 帧,目标经历了姿态的变化,移动机器人依然能够有效地跟踪目标,第 65 帧时,目标开始经历光照变化,由第 122 帧可知,移动机器人能够有效地降低光照变化的干扰,进行持续稳定的跟踪。如图 11(b) 所示,序列 2 中的跟踪目标为一本书,第 37 帧时,目标开始被遮挡,第 124 帧时,目标经历形态的变化,第 180 帧时,目标的一部分超出了跟踪的视野,但是移动机器人均能够准确鲁棒地跟踪到目标。如图 11(c) 所示,序列 3 中的跟踪目标为从光线较亮处走到较暗处的行人,期间经历了相似物的遮挡以及姿态的变化,第 26 帧时,目标开始被行人遮挡,期间有短暂的跟踪丢失,但是又立即恢复了跟踪,第 85 帧时开始进入光线较暗处,第 117 帧时已经接近完全黑暗的状态,移动机器人依然能够在保持高精度跟踪的同时,进行持续的跟踪。由表 2 可知,在 3 个序列上的平均重叠率为 97.5%,平均中心位置误差为 6.8 pixel,平均跟踪速率为 29.1 f/s。

3.2 车辆跟踪场景实验

为了验证本文算法在车辆跟踪场景中的准确性、鲁棒性和实时性,基于 Jetson TX2 开发板及车载摄像头搭建了车辆跟踪系统,如图 12 所示。针对影响车辆跟踪的主要因素,分别在真实场景序列 1(遮挡)、2(光照变化)、3(尺度变化)上进行实验。由表 3 可知,本文算法在遮挡、光照变化和尺度变化场景下均取得了较好的跟踪结果,同时,也满足了车辆跟踪实时性要求。



图 12 车辆跟踪系统
Fig.12 Vehicle tracking system

表 3 单一场景下的跟踪结果

Table 3 Tracking results under single scene			
序列	重叠精度/%	中心位置误差/pixel	跟踪速率/f·s ⁻¹
1	95.2	26.6	25.2
2	98.6	6.0	28.6
3	97.9	5.1	31.5
平均值	97.2	12.6	28.4

图 13 所示为本文算法在单一场景下的跟踪结果。如图 13(a) 所示,跟踪车辆从第 20 帧开始被后面车辆遮挡,至第 95 帧时几乎完全遮挡,双重跟踪可靠性判断依据能够有效降低不可靠的跟踪结果,采用粒子滤波、稀疏

编码以及距离约束定位进行重新检测,由第 158 帧可知,本文算法仍然能够对严重遮挡的车辆进行持续稳定的跟踪。如图 13(b) 所示,跟踪车辆在第 44 帧时开始进入光线较暗的高架桥桥洞,由第 93 帧可知,本文算法能够有效地跟踪光线较暗场景下的车辆,多模型融合模块能够充分表征车辆信息,提高了模型的判别性和鲁棒性,第 156 帧时,本文算法依然能够稳定地跟踪车辆。如图 13(c) 所示,跟踪车辆由近至远地行驶,尺度发生较大变化,本文算法的多种融合特征能有效地表征目标,适应尺度的变化,由第 163 帧可知,本文算法能够进行持续稳定的跟踪。



图 13 单一场景下的跟踪结果
Fig.13 Tracking results under single scene

4 结 论

为了弥补现有跟踪算法的不足,提出了多模型融合和重新检测的高精度鲁棒目标跟踪算法。多模型融合提高了跟踪器对于目标的判别性,其中,滤波器模型对变形敏感,颜色模型对光照变化敏感,目标模型依赖于边缘信息,对变形和光照变化有很好的适应性,将 3 个互补模型融合形成了准确度更高和鲁棒性更强的跟踪模型,解决了目标在经历变形和光照变化等场景时跟踪准确性和鲁棒性较差的问题。基于多模型融合模块提取的目标特征分数,采用双重跟踪可靠性判断依据进行跟踪可靠性判断以选择最可靠的跟踪结果,避免了跟踪误差累积,提高了跟踪结果的可靠性。引入重新检测模块,使用粒子滤波和稀疏表示进行粗略定位,再使用距离约束筛选不可靠的结果,进行精确定位,降低了遮挡、超出视野等因素对跟踪的干扰。在 PC 上验证了本文算法能够有效降低遮挡、超出视野、光照变化和变形等复杂因素的干扰,与其他主流的跟踪算法相比,本文算法的成功率、精度、

重叠精度和中心位置误差均取得了最佳的结果,在 100 个实验序列上的算法平均跟踪速率为 30.8 f/s。同时,在移动机器人上实验的平均重叠精度为 97.5%,平均中心位置误差为 6.8 pixel,算法平均跟踪速率为 29.1 f/s,满足了跟踪实时性的要求。在车辆跟踪实验中,平均重叠精度为 97.2%,平均中心位置误差为 12.6 pixel,算法平均跟踪速率为 28.4 f/s,对于影响车辆跟踪的遮挡、光照变化、尺度变化等因素也具有较好的跟踪效果,且满足了车辆跟踪实时性的要求。

本文有效降低了遮挡、超出视野、光照变化和变形等复杂环境因素对跟踪的干扰,能够对车辆跟踪、移动机器人跟踪导航、视频监控等提供参考,具有实际应用价值,尤其对于在真实交通场景中存在各种复杂环境的车辆跟踪,基于视觉的高精度鲁棒且满足实时性的车辆跟踪能够有效地辅助智能驾驶,提高驾驶安全性。但在长时间黑暗环境下,本文算法还有局限性,下一步将结合红外传感器进行夜间目标跟踪。

参考文献

- [1] 苑晶,李阳,董星亮,等.基于运动模式在线分类的移动机器人目标跟踪[J].仪器仪表学报,2017,38(3):568-577.
YUAN J, LI Y, DONG X L, et al. Target tracking with mobile robot based on on-line classification for motion patterns[J]. Chinese Journal of Scientific Instrument, 2017, 38(3):568-577.
- [2] 翟敬梅,刘坤.特征点辅助的时空上下文目标跟踪与定位[J].仪器仪表学报,2017,38(11):2839-2848.
ZHAI J M, LIU K. Object tracking and location with spatio-temporal context assisted by key points[J]. Chinese Journal of Scientific Instrument, 2017, 38(11):2839-2848.
- [3] 陆艳,孙锐,王旭.空中视角下基于局部线性判别嵌入的目标跟踪方法[J].电子测量与仪器学报,2018,32(11):90-96.
LU Y, SUN R, WANG X. Target tracking method based on local linear discriminant embedding in the air view[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(11):90-96.
- [4] 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.
- [5] 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.
- [6] DANELLJAN M, HAGER G, KHAN F, et al. Accurate scale estimation for robust visual tracking[C]. British Machine Vision Conference, 2014:1-11.
- [7] LI Y, ZHU J. A scale adaptive kernel correlation filter tracker with feature integration[C]. European Conference on Computer Vision, 2014:254-265.
- [8] 郭玲.基于核相关滤波器的多尺度目标跟踪[J].电子测量与仪器学报,2018,32(4):74-79.
GUO L. Multi-scale object tracking based on kernel correlation filter[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(4):74-79.
- [9] MA C, HUANG J B, YANG X, et al. Robust visual tracking via hierarchical convolutional features[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2018.
- [10] BERTINETTO L, VALMADRE J, GOLODETZ S, et al. Staple: Complementary learners for real-time tracking[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016:1401-1409.
- [11] 戴伟聪,金龙旭,李国宁.基于 Staple 算法改进的目标跟踪算法[J].电光与控制,2019,26(6):12-17,39.
DAI W C, JING L X, LI G N. Object tracking based on improved Staple tracker[J]. Electronics Optics & Control, 2019, 26(6):12-17,39.
- [12] 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):242-255.
LIU W J, SUN H, JIANG W T. Correlation filter tracking algorithm for adaptive feature selection[J]. Acta Optica Sinica, 2019, 39(6):242-255.
- [13] 崔盼果,周进,雷涛,等.基于核相关滤波算法的层级遮挡检测目标跟踪[J].国外电子测量技术,2018,37(7):132-137.
CUI P G, ZHOU J, LEI T, et al. Hierarchical occlusion detection tracking based on kernel correlation filters[J]. Foreign Electronic Measurement Technology, 2018, 37(7):132-137.
- [14] 孙锐,王旭,张东东,等.采用局部线性嵌入的稀疏目标跟踪方法[J].电子测量与仪器学报,2017,31(8):1312-1320.
SUN R, WANG X, ZHANG D D, et al. Sparse object tracking method using local linear embedding[J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(8):1312-1320.
- [15] KALAL Z, MIKOLAJCZYK K, MATAS J. Tracking-learning-detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2012, 34(7):1409-1422.

- [16] MA C, YANG X, ZHANG C, et al. Long-term correlation tracking [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2015:5388-5396.
- [17] 刘大千,刘万军,费博雯,曲海成.前景约束下的抗干扰匹配目标跟踪方法[J].自动化学报,2018,44(6):1138-1152.
- LIU D Q, LIU W J, FEI B W, et al. A new method of anti-interference matching under foreground constraint for target tracking [J]. Acta Automatica Sinica, 2018, 44(6):1138-1152.
- [18] POSSEGGGER H, MAUTHNER T, BISCHOF H. In defense of color-based model-free tracking [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2015:2113-2120.
- [19] ZITNICK C L, DOLLÁR P. Edge boxes: Locating object proposals from edges [C]. European Conference on Computer Vision, 2014:391-405.
- [20] WANG M, LIU Y, HUANG Z. Large margin object tracking with circulant feature maps [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2017:21-26.
- [21] WU Y, LIM J, YANG M H, et al. Object tracking benchmark [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9):1834-1848.
- [22] DANELLJAN M, HAGER G, SHAHBAZ KHAN F, et al. Learning spatially regularized correlation filters for

visual tracking [C]. IEEE International Conference on Computer Vision, 2015:4310-4318.

- [23] BOLME D S, BEVERIDGE J R, DRAPER B A, et al. Visual object tracking using adaptive correlation filters [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2010:2544-2550.

作者简介



朱磊,2017年于武汉理工大学获学士学位,现为湖南大学研究生,主要研究方向为智能驾驶、图像处理等。

E-mail: Tomingzhu@163.com

Zhu Lei received his B.Sc. degree from Wuhan University of Technology in 2017.

Now, he is a M.Sc. student in Hunan University. His main research interests include intelligent driving and image processing.



白中浩(通信作者),分别在2000年、2002年和2006年于湖南大学获学士、硕士、博士学位,现为湖南大学教授,主要研究方向为汽车安全、智能驾驶等。

E-mail: baizhonghao@hnu.edu.cn

Bai Zhonghao (Corresponding author) received his B.Sc. degree in 2000, M.Sc. degree in 2002 and Ph.D. degree in 2006 all from Hunan University, respectively. Now, he is a professor in Hunan University. His main research interests include automotive safety and intelligent driving.