

DOI: 10.19650/j.cnki.cjsi.J2311251

基于加权在线样本更新的目标长时跟踪方法*

陈仁祥¹, 何家乐¹, 杨黎霞², 余腾伟¹, 张霞¹

(1. 重庆交通大学交通工程应用机器人重庆市工程实验室 重庆 400074; 2. 重庆科技学院工商管理学院 重庆 401331)

摘要:针对在长时跟踪过程中因丢失视野导致目标跟踪失败的问题,提出了基于加权在线样本更新的目标长时跟踪方法。首先,使用 ResNet50 网络提取目标深度特征并增强初始帧样本优化目标模型,提高初始帧样本权重影响;然后,利用目标模型对测试帧样本进行分类,并采用置信度分值加权在线学习样本以增强样本质量,提升模型的分类效果;其次,使用置信度分值判别目标状态并跟踪定位目标,目标丢失时使用时空约束搜索在丢失处自适应扩展区域并随机搜索目标,同时利用在线学习快速优化目标模型,增强其对目标的搜索能力;最后,针对搜索过程设计一种自适应阈值判别方法,充分利用图像背景信息,将目标丢失时背景置信度分值作为判别阈值,降低搜索过程中相似背景的影响以准确找回目标。使用 LTB50 数据集进行实验验证,成功率和跟踪 F-score 分别为 66.1% 和 64.4%,优于其他方法;在四足移动机器人平台上进行真实场景实验,目标完全遮挡和视野外两种情况下成功率分别为 87.8% 和 85.8%,证明了方法的有效性。

关键词:长时跟踪;在线学习;时空约束搜索;自适应阈值

中图分类号: TH39 **文献标识码:** A **国家标准学科分类代码:** 510

Target long-term tracking method based on weighted online sample update

Chen Renxiang¹, He Jiale¹, Yang Lixia², Yu Tengwei¹, Zhang Xia¹

(1. Chongqing Engineering Laboratory for Transportation Engineering Application Robot, Chongqing Jiaotong University, Chongqing 400074, China; 2. Business and Management College, Chongqing University of Science & Technology, Chongqing 401331, China)

Abstract: A long-term tracking method based on the weighted online sample updating is proposed to address the problem of tracking failure caused by target loss during long-term tracking. First, the ResNet50 network is used to extract the deep features of the target and enhance the initial frame sample to optimize the target model, which could improve the influence of the initial frame sample weight. Then, the target model is used to classify the test frame sample, and the confidence score is used to weight the online learning samples to enhance their quality and improve the classification performance of the model. Secondly, the target state is determined by the confidence score, and the target is tracked and located. When the target is lost, a spatiotemporal constraint search is used to adaptively expand the search area at the loss point and randomly search for the target, while utilizing online learning to quickly optimize the target model and enhance its search ability. Finally, an adaptive threshold discrimination method is proposed for the search process, fully utilizing the image background information, using the background confidence score when the target is lost as the discrimination threshold, reducing the influence of similar backgrounds in the search process to accurately retrieve the target. Experiments on the LTB50 dataset show a success rate of 66.1% and a tracking F-score of 64.4%, outperforming other methods. Real-world experiments on a quadruped robot platform achieved success rates of 87.8% and 85.8% under full occlusion and out-of-view scenarios, respectively. The effectiveness of the proposed method is evaluated.

Keywords: long-term tracking; online learning; spatio-temporal constraint search; adaptive threshold

收稿日期: 2023-04-02 Received Date: 2023-04-02

* 基金项目: 重庆市教委科学技术研究项目 (KJZD-M202200701)、重庆市自然科学基金 (CSTB2023NSCQ-MSX0177)、重庆市研究生联合培养基地项目 (JDLHPYJD2021007)、重庆市专业学位研究生教学案例库 (JDALK2022007)、重庆市研究生科研创新项目 (2023S0072) 资助

0 引言

目标跟踪的目的是估计一个未知目标轨迹,且只有一个初始状态的目标(初始帧)可用^[1]。长时跟踪过程中,目标丢失又重新出现,在背景信息干扰以及外观特征与目标初始状态发生较大差异时,跟踪算法无法重新找回目标,是目标跟踪领域最困难的挑战之一^[2]。

近些年来,国内外学者对目标跟踪展开了大量研究,文献[3]采用VGG特征与手工特征加权融合,有效提高跟踪精度。文献[4]利用多种特征进行自适应融合,弥补了复杂背景下存在特征提取单一问题。文献[5]将跟踪过程分为分类和回归两个分支,并使用基于交并比(intersection over union, IoU)的细化网络(IoU-Net^[6])有效地处理跟踪过程中目标的长宽比变化。文献[7]进一步分析基于IoU预测的目标跟踪框架准确率较低的问题,构建了一种结合IoU和中心点距离的新度量。这些方法从特征提取到目标回归设计跟踪网络,虽然提高了对目标持续跟踪下的鲁棒性,但忽视目标丢失情况,无法在目标丢失后准确找回目标。

针对该问题,文献[8]利用跟踪置信度评估目标遮挡状态,并采用Kalman滤波修正目标位置,缓解了跟踪过程中因遮挡导致跟踪失败问题。文献[9]提出一种快速判别尺度空间相关滤波目标跟踪算法与卡尔曼滤波结合的跟踪方法,解决了跟踪过程中因遮挡造成的目标坐标信息丢失问题。上述方法旨在解决目标短期遮挡问题,然而实际应用过程中,跟踪目标往往会长时间完全丢失视野,需在目标完全丢失的情况之下重新找回目标。文献[10]采用全局跟踪策略,在每一帧上定位整个图像中的目标。文献[11]采用多模型响应和距离分数来同时约束候选结果进行重新跟踪目标。文献[12]通过峰值旁瓣比和峰值绝对值设计一种不确定性跟踪机制。文献[13]设计了一种新的搜索模块从大量滑动窗口中有效地选择最可能区域进行跟踪。文献[14]采用全局随机搜索在滑动窗口方法基础上提高搜索效率。

这些方法与跟踪过程中目标丢失问题提供了思路,然而大多数跟踪模型未考虑目标丢失后的状态信息,直接在整张图像中搜索目标,更容易受到相似背景干扰。此外部分跟踪模型未采用在线学习方式,仅利用初始模板去搜索丢失目标,可靠性不高。

针对长时跟踪过程中的目标丢失问题,提出了基于加权在线样本更新的目标长时跟踪方法。为稳定跟踪目标,提高丢失目标搜索效率与准确性。首先,改进在线学习样本替换策略,提升高质量样本对模型的影响,并在目标丢失后更新模型权重,加强模型对目标与相似背景鉴别能力;其次,设计了一种时空约束的随机搜索方法,在

目标丢失处开始,以目标大小自适应扩散随机搜索区域,在降低区域外相似背景干扰的同时,提升搜索效率;最后,提出自适应置信度阈值判别方法,进一步降低相似背景干扰。

1 加权在线样本更新的目标长时跟踪原理

1.1 算法结构

基于加权在线样本更新的目标长时跟踪是一个改进SuperDimpSimple框架的在线跟踪网络,结合了标准DiMP分类器^[15]和PrDiMP^[16]边界框回归方法,并加入时空约束搜索和自适应阈值判别方法,充分运用其在线学习优势,自动更新模型权重。主要由特征提取、模型更新、置信度分值生成及时空约束搜索方法构成。

1)特征提取,使用ResNet50作为骨干网络和一个附加的卷积块提取目标深度特征,并采用孪生方式与测试帧样本共享特征提取网络权重。

2)模型更新,初始化模型后,使用数据增强方法增加初始帧样本量,并用最速下降法优化目标模型,在后续跟踪过程中利用目标高质量新样本更新模型。

3)置信度分值生成,将优化模型输出卷积层权重对测试帧样本进行目标分类,利用响应图生成置信度分值判别目标状态并跟踪定位目标。

4)时空约束搜索方法,目标丢失视野时,在目标丢失处自适应扩展区域并随机搜索目标,并利用自适应阈值判别目标与背景,以准确找回目标。

1.2 样本替换策略

长时跟踪过程中,在线学习方式对跟踪目标是有益的,但在学习更新过程中,如果训练样本质量较差,将直接导致优化模型效果不佳,降低模型分类效果和目标丢失后模型对目标的搜索能力。因此,样本替换过程中,应该如何保留和替换就十分重要。

样本替换过程中,采用置信度分值控制样本更新而不是简单的先入先出方式。生成样本空间 $m = \{\alpha, \beta, \gamma\}$, α 存放初始帧样本以及数据增强样本; β 存放高置信度分值样本; γ 存放低置信度分值样本。由于 α 中样本为初始帧样本,因此选择保留样本以防止模型严重失效; β 中样本根据置信度分值和时间进行加权,以便后续高置信度分值样本替换; γ 中样本则采用先入先出方式进行替换。

1.3 时空约束搜索

目标丢失主要分为视野内完全遮挡和视野外两种,针对目标丢失后难以重新跟踪的问题,设计具有时间加权的区域搜索方法。首先,将目标丢失处作为初始搜索区域;然后,根据目标大小自适应地随时间间隔增大搜索区域,

并根据区域大小与目标大小自适应地确定随机搜索次数;最后利用网络提取搜索区域特征,计算置信度分值。

$$S'_{\text{new}} = \max \{S_1, S_2, S_3, \dots, S_{\omega k}\} \quad (1)$$

式中: s'_{new} 为测试帧中最大搜索置信度分值,用于判别目标是否回归,当 s'_{new} 仍较小时继续寻找目标; k 为搜索区域内总搜索次数,并使用 ω 加权进行随机搜索,提高搜索效率。

该方法完全可以在几帧内完成区域搜索,同时相比一般滑动窗口方法和全局随机搜索方法,所提方法提高了搜索效率。此外,滑动窗口和全局随机搜索方法针对整张图像,会受到更多相似背景干扰,因此采用时空约束搜索方法缓解区域外相似背景干扰。

1.4 自适应阈值

目标丢失直到再次出现之前,图像内均为背景区域,置信度响应分值较小。如采用固定置信度阈值作为目标回归判别,但图像内出现相似背景,置信度响应分值将增大,固定置信度阈值方式无法准确判断是否为目标。针对该问题,设计自适应置信度阈值判别方法。

正常跟踪时,网络模型关注目标的同时也关注背景区域,一旦目标丢失,网络模型将以搜索区域遍历整张图像,将图像中置信度响应第2峰值 s 作为阈值判别目标是否回归。

$$Ta = \begin{cases} Tr, & s < Tr \\ s, & s \geq Tr \end{cases} \quad (2)$$

式中: Tr 为目标丢失判别阈值; Ta 为时空约束搜索判别阈值。

2 基于加权在线样本更新的目标长时跟踪流程

基于加权在线样本更新的目标长时跟踪流程如图1所示,具体步骤如下。

1) 通过旋转、模糊、左右翻转等方法对初始帧进行数据增强以扩充样本容量。

2) 使用主干网络提取初始帧样本特征,同时初始化目标模型。

3) 将初始帧样本输入对模型优化更新,得到最终优化模型,同时将初始帧样本加入样本空间。

4) 提取测试帧样本特征,使用最终优化模型生成测试帧样本置信度分值。

5) 判别测试帧目标状态。目标状态正常,进入步骤6);目标丢失,进入步骤8)。

6) 目标状态正常,跟踪定位目标,将测试帧样本加权放入在线学习样本空间。

7) 查询是否将模型优化更新(间隔20帧进行一次更新)。返回步骤4)或结束跟踪。

8) 目标丢失,将目标丢失判别阈值 Tr 替换为时空约束搜索判别阈值 Ta 。

9) 使用时空约束搜索方法在测试帧中寻找目标,并利用在线学习优化目标模型(目标丢失后进行一次更新)。返回步骤4)或结束跟踪。

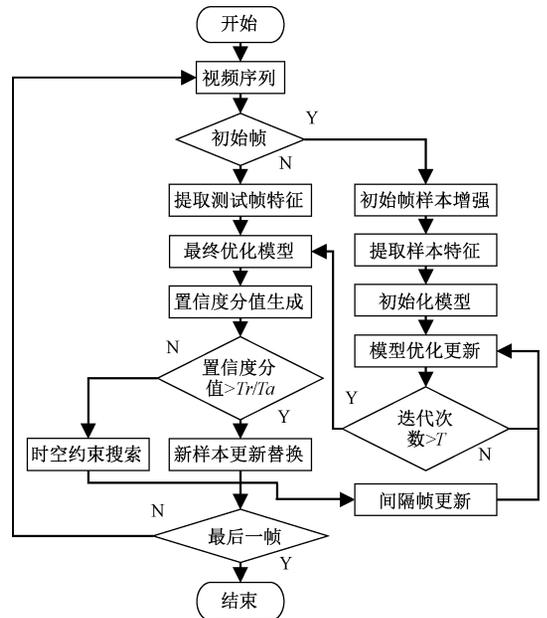


图1 长时跟踪流程

Fig. 1 Process of long-term tracking

3 实验结果分析

3.1 实验环境

实验在 Ubuntu18.04 系统环境下, Nvidia 1080Ti 显卡,并基于 Pytorch 的 pytracking 目标跟踪框架。在线学习样本空间数量为 60,区域划分为 15、15、30,目标丢失判别阈值 $Tr=0.25$,搜索过程随机因子 $\omega=0.1$ 。

实验采用 LTB50^[17] 数据集,含 50 个不同对象的序列,总长度为 215 294 帧,用于单目标对象跟踪。在每个序列中,目标平均丢失 10 次,丢失的目标平均持续 52 帧,视频序列的分辨率在 1 280×720~290×217,所有目标都用一个轴向对齐的边界框标记。包括 9 种视觉属性标注,分别为完全遮挡(O)、视野外(V)、部分遮挡(P)、摄像机运动(C)、快速运动(F)、缩放变化(S)、纵横比变化(A)、视点变化(W)、相似物体(I)。为充分分析验证本文方法的性能,针对目标丢失问题,采用完全遮挡和视野外两种视觉属性,共 38 个视频序列进行实验,并在四足移动机器人平台进行真实场景实验验证。

3.2 评价指标

为更客观地分析本文方法的性能,采用成功率作为跟踪过程的定量评价指标,即曲线下面积(area under the

curve, AUC), 采用跟踪 F-score、跟踪精度 (precision) 和跟踪召回率 (recall) 来评价本文方法针对目标丢失问题的跟踪能力。

在目标跟踪过程中, 目标可能会长时间完全遮挡或长时间离开相机视野, 跟踪模型需在每一帧中提供目标位置和 target 存在的置信度分数。

$$Pr(\tau_\theta, \tau_\Omega) = |\{t: \Omega(A_t(\tau_\theta), G_t) \geq \tau_\Omega \wedge A_t(\tau_\theta) \neq \emptyset\}| / N_p \quad (3)$$

$$Re(\tau_\theta, \tau_\Omega) = |\{t: \Omega(A_t(\tau_\theta), G_t) \geq \tau_\Omega \wedge G_t \neq \emptyset\}| / N_g \quad (4)$$

式中: G_t 为真实目标框; $A_t(\tau_\theta)$ 为跟踪模型预测目标框; τ_Ω 为真实目标框与跟踪模型预测目标框的交并比阈值; N_p 为跟踪模型预测目标不为空的帧数; N_g 为真实目标框不为空的帧数。

为减少阈值 τ_Ω 的过度限制, 通过积分将跟踪精度和召回率降低到单一阈值。

$$Pr(\tau_\theta) = \int_0^1 Pr(\tau_\theta, \tau_\Omega) d\tau_\Omega = \frac{1}{N_p} \sum_{t \in \{t: A_t(\tau_\theta) \neq \emptyset\}} \Omega(A_t(\tau_\theta), G_t) \quad (5)$$

$$Re(\tau_\theta) = \int_0^1 Re(\tau_\theta, \tau_\Omega) d\tau_\Omega = \frac{1}{N_g} \sum_{t \in \{t: G_t \neq \emptyset\}} \Omega(A_t(\tau_\theta), G_t) \quad (6)$$

为更公平地评估不同的跟踪模型, 在最佳性能阈值处取跟踪 F-score。

$$F(\tau_\theta) = \frac{2Pr(\tau_\theta)Re(\tau_\theta)}{Pr(\tau_\theta) + Re(\tau_\theta)} \quad (7)$$

3.3 LTB50 数据集实验

为验证本文方法跟踪过程的优势以及有效性, 将本文方法与现有跟踪方法 ATOM^[5]、SPLT^[13]、RLT-DiMP^[14]、DiMP50^[15]、PrDiMP50^[16] 等方法进行比较, 结果如图 2 所示。由图 2 可知, 本文方法成功率达到 66.1%, 明显高于其他方法, 说明了本文方法具有更好的跟踪能力。

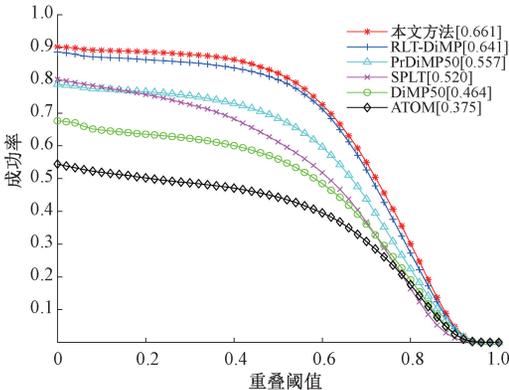


图 2 不同方法成功率对比

Fig. 2 Comparison of success rate of different methods

观察图 2 可知, ATOM 和 DiMP50 方法成功率明显低于其他方法, 虽然这两种方法采用了在线学习方式, 但忽视了样本质量问题, 导致模型出现负优化状况; PrDiMP50 和 RLT-DiMP 方法分别采用概率回归目标状态和数据增强的方式, 提高了在线更新样本质量, 相较于采用离线跟踪的 SPLT 方法具有更高的成功率; 本文方法针对在线学习改进样本替换策略, 进步提高样本质量, 增强了模型跟踪能力, 具有更好的跟踪效果。

为验证本文方法针对目标丢失问题的跟踪优势以及有效性, 给出不同方法跟踪 F-score、跟踪精度和跟踪召回率, 对比结果如表 1 所示。由表 1 可知, 本文方法在目标丢失情况下 F-score 达到 64.4%, 优于其他方法; 跟踪精度和跟踪召回率分别相较于次优的 RLT-DiMP 提升 2.7% 和 1.7%, 说明了本文方法针对目标丢失问题具有更好的跟踪结果。

表 1 不同方法跟踪结果对比

Table 1 Comparison of tracking results of different methods

methods		%	
方法	F-score	Precision	Recall
ATOM	40.9	47.3	36.1
SPLT	51.2	53.4	49.2
RLT-DiMP	62.2	61.2	63.2
DiMP50	49.9	56.0	45.0
PrDiMP50	55.2	56.2	54.3
本文	64.4	63.9	64.9

从表 1 可知, ATOM 方法跟踪结果均低于其他方法, 这是由于该方法采用 ResNet18 作为特征提取器, 同时采用较大样本空间储存新样本, 这将导致在目标丢失后更容易将背景信息作为目标错误跟踪。同时 ATOM、DiMP50 和 PrDiMP50 方法采用局部搜索方式, 不利于目标丢失在视野外的情况, 但 PrDiMP50 方法采用更大的搜索区域, 减少了局部搜索的不足。SPLT 方法基于 SiamRPN 框架采用局部和全局搜索, 但相较于本文方法缺少在线学习, 无法解决目标在不同视角重新出现或目标形变的情况, 最终跟踪 F-score 仅为 51.2%。RLT-DiMP 方法采用全局随机搜索解决目标丢失问题, 并设计了置信度分值惩罚机制来防止远距离相似背景干扰, 具有较好的跟踪结果。本文方法加入时空约束搜索并快速优化网络模型, 加强从局部到全局的搜索方式; 使用自适应阈值划分目标与背景, 降低相似背景对搜索过程的干扰, 对比其他方法, 本文方法跟踪结果均为最优。

为分析本文时空约束搜索、样本替换以及自适应阈值方法的有效性, 针对跟踪是否使用模块进行消融实验, 结果如表 2 所示。可以看出在跟踪过程中, 加入时空约

束搜索模块后,跟踪 F-score 提升了 2.9%;在时空约束搜索基础上,添加样本替换策略以及自适应阈值模块分别提升 4.3% 和 4.8%;同时使用全部模块时,最终跟踪 F-score 提升 7.5%。表明本文方法提高了针对目标丢失问题的跟踪能力。

表 2 消融实验对比

时空约束搜索	样本替换	自适应阈值	F-score	提升
×	×	×	56.9	-
√	×	×	59.8	2.9 ↑
√	√	×	61.2	4.3 ↑
√	×	√	61.7	4.8 ↑
√	√	√	64.4	7.5 ↑

为验证时空约束搜索方法在跟踪过程中的搜索效率,使用 boat、longboard、freestyle 视频序列进行实验,序列中目标丢失次数分别为 10、18、27。通过与滑动窗搜索和全局随机搜索进行对比,结果如表 3 所示。滑动窗搜索是一种经典的全局搜索方式,可在整张图像固定大小以滑动窗口的方式搜索;RLT-DiMP 提出的全局随机搜索则是在整张图像进行概率搜索;本文提出的时空约束搜索采用从局部到全局方式,在目标丢失时对区域进行概率搜索而不是整张图像,因此可以有效提升搜索效率,由表 3 可以看出,本文方法跟踪速率明显优于滑动窗搜索,相比全局随机搜索提升 0.9 fps。

表 3 不同方法搜索效率

方法	滑动窗搜索	全局随机搜索	时空约束搜索
跟踪速率	4.5	13.0	13.9

为更直观的分析本文方法的优势及有效性,选取 7 组视频序列 (boat、bull、horseride、parachute、person7、skiing、warmup) 对本文方法与其他方法进行比较。给出视频序列中目标回归时不同方法跟踪结果,不同方法的跟踪 F-score (表 4),跟踪结果如图 3 所示。

表 4 视频序列跟踪 F-score 对比

方法	boat	bull	horseride	parachute	person7	skiing	warmup
ATOM	37.3	64.4	26.5	48.2	40.6	7.4	34.6
SPLT	48.6	46.4	41.5	39.1	60.7	58.1	1.0
RLT-DiMP	44.1	76.9	72.6	36.2	79.5	67.7	73.5
DiMP50	29.9	73.7	32.6	47.5	43.0	59.7	43.2
PrDiMP50	33.5	74.6	63.8	59.9	62.9	61.6	60.9
本文	73.4	76.8	74.8	65.8	77.5	67.8	72.7

由图 3、表 4 可知,在序列 boat 中,本文方法明显优于其他方法,目标回归时迅速并准确找回目标,在第 5 353 帧中,其他方法完全退化,无法正常跟踪到目标,而本文方法利用高质量样本在线学习优势,最终找回目标并持续跟踪;在序列 bull 中,SPLT 方法缺少在线学习方式,在目标丢失且尺寸变化时无法适应,错误将背景信息作为跟踪目标;在序列 horseride 中,ATOM 和 DiMP50 方法由于其采用局部搜索方式,无法找回目标,本文方法采用时空约束搜索方式,在目标回归时迅速找回目标并持续跟踪,相较于跟踪性能较差的 ATOM 方法跟踪 F-score 提升 48.3%;在序列 parachute 中,其它方法在目标丢失后错误的将相似背景判别为目标,而本文方法使用背景信息置信度分值作为搜索判别阈值,降低了相似背景干扰并迅速找回目标;在序列 skiing 中,本文方法在目标以不同尺寸回归时快速适应,在第 637 帧中,SPLT 和 DiMP50 方法无法适应大尺寸目标回归,仅将部分目标特征信息进行跟踪,ATOM 方法则在目标丢失后将背景作为目标;在序列 person7 和 warmup 中,本文方法跟踪 F-score 略低于 RLT-DiMP 方法,但对比其它方法具有一定优势,并更加迅速找回目标,特别是在 warmup 视频序列中,SPLT 方法在大量相似背景中完全失效,无法准确跟踪目标,跟踪 F-score 基本趋于 0。

最后,为分析目标搜索框大小对跟踪的影响,在时空约束搜索基础上,利用目标丢失前最新尺寸信息 1~10 倍作为搜索框大小进行对比,结果如图 4 所示。

跟踪精度总体呈下降趋势,跟踪召回率与跟踪 F-score 总体呈上升趋势,但在 9 倍搜索框之后开始迅速下降。时空约束搜索过程中,小搜索框含有较少的背景信息,可以更少受到相似背景干扰,因此具有更高跟踪精度,但需要更多时间搜索区域中的目标,在目标回归后不能快速找回目标,跟踪召回率更小;相反,大搜索框可以快速找回目标,且可以缓解目标丢失前尺寸急剧减小或回归时尺寸较大等特殊情况,但面临更多背景干扰,因此大搜索框跟踪精度较小。然而搜索框过大不利于模型提取目标特征,全部指标都将减小。本文方法选用各项指标相对稳定的 6 倍搜索框大小进行实验。

3.4 四足机器人平台实验

为验证本文方法在真实场景中跟踪的有效性,使用四足移动机器人进行跟踪实验。如图 5 所示,四足移动机器人配置了 Intel RealSense D435i 摄像头,摄像头分辨率为 1 920×1 080,帧速率为 30 fps。对真实场景中目标完全遮挡和消失在视野外两种情况进行实验分析,给出目标即将丢失和回归时跟踪效果,如图 6 所示,并给出不同方法平均跟踪结果,如表 5、6 所示。

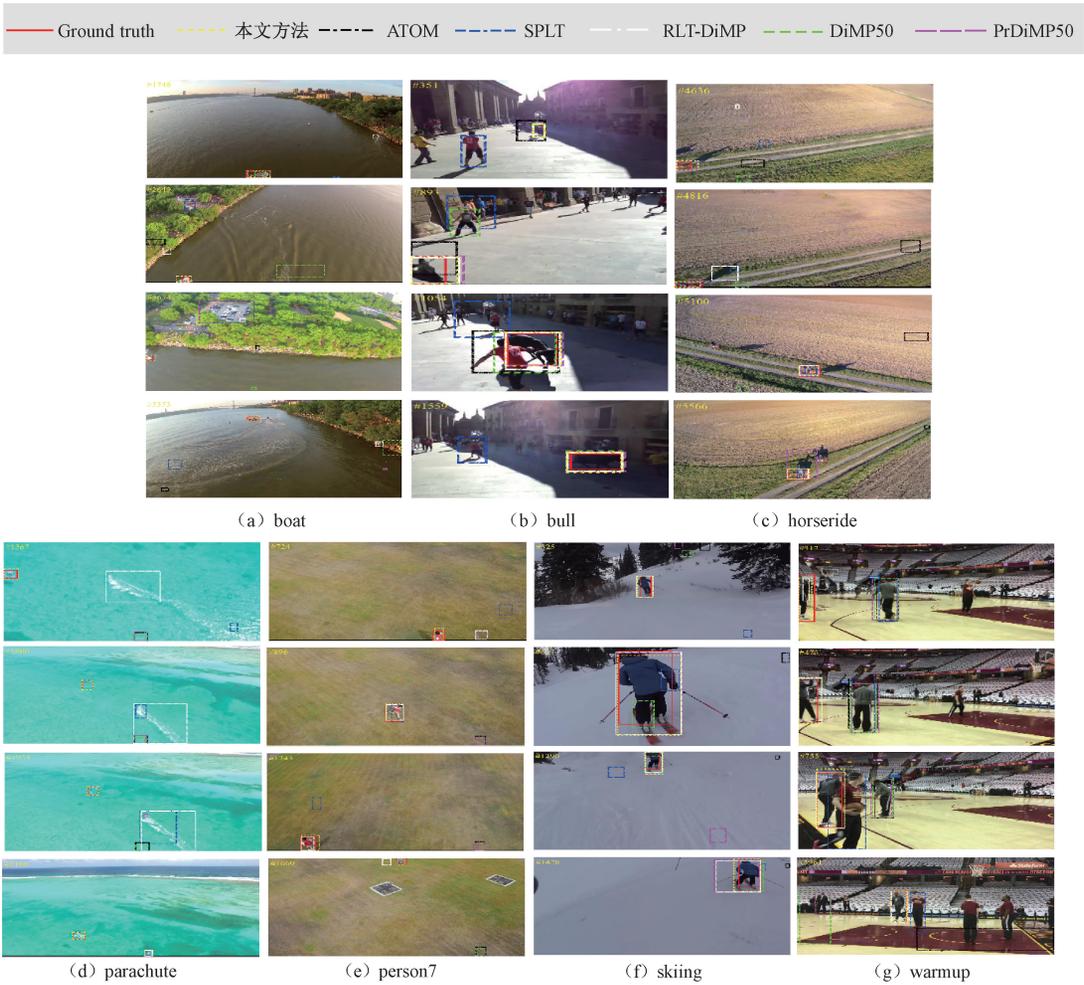


图 3 不同方法跟踪结果
Fig. 3 Tracking results of different methods

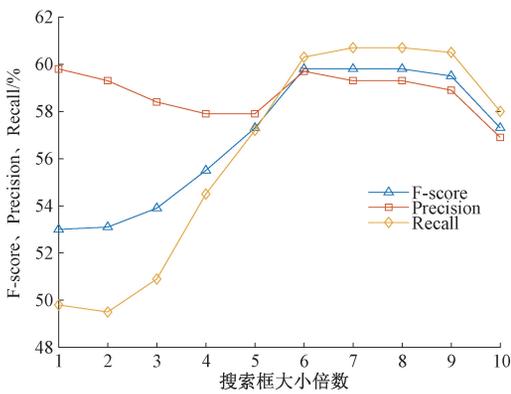


图 4 搜索框大小探寻
Fig. 4 Search box size search



图 5 四足移动机器人平台
Fig. 5 Quadruped mobile robot platform

表 5 平均跟踪结果对比(完全遮挡)
Table 5 Average tracking results compared (full occlusion) %

方法	成功率	F-score	Precision	Recall
RLT-DiMP	65.6	64.0	62.9	65.2
DiMP50	82.9	79.5	77.4	81.8
PrDiMP50	87.4	85.5	84.1	87.0
本文	87.8	85.9	84.5	87.4

由图 6(a)可知,四足移动机器人在经过 427 帧稳定跟踪后出现遮挡情况,并在完全遮挡结束后继续跟踪目标;由图 6(b)可知,在第 420 帧时目标将被完全遮



图6 真实场景跟踪效果

Fig. 6 Real scene tracking effect

挡,四足移动机器人能够在长时遮挡结束后持续稳定跟踪;由图6(c)可知,跟踪目标在第488帧走出房间丢失视野,四足移动机器人按照路线走出房间成功找回目标并持续跟踪,第1681帧目标再次丢失视野,在第1866帧时目标回归,四足移动机器人成功找回目标并持续跟踪;由图6(d)可知,四足移动机器人按照路线避开障碍物,在目标完全丢失视野且存在相似背景干扰情况下,四足移动机器人仍能够在目标回归时迅速找回并跟踪目标。

表6 平均跟踪结果对比(视野外)

Table 6 Average tracking results compared (out-of-view)

方法	成功率	F-score	Precision	Recall
RLT-DiMP	83.9	81.9	82.3	81.5
DiMP50	78.7	75.6	76.2	75.0
PrDiMP50	84.5	79.9	80.8	79.0
本文	85.8	85.3	85.4	85.1

由表5可知,本文方法在完全遮挡情况下平均跟踪结果均优于其他方法,RLT-DiMP方法成功率仅为65.6%,该方法在目标被完全遮挡时采用全局随机搜索方式找回目标,但未充分考虑相似背景影响,最终错误将远处背景作为跟踪目标。由表6可知,本文方法跟踪F-score明显均优于其他方法,这主要在于目标丢失在视野外时,四足移动机器人按照预定路线找到目标,但其他方法在这过程中错误将背景作为目标,这种情况将极大影响四足移动机器人的自主决策,导致跟踪失败。在真实场景下,四足移动机器人足部运动导致视野模糊以及

目标在光照变化等影响下,本文方法仍能在目标丢失后准确找回目标并稳定持续跟踪。

4 结 论

目标跟踪在长时间应用过程中易出现目标丢失情况,在背景干扰下找回目标十分困难,因此有效地跟踪方法以保证长时下对目标进行稳定跟踪极为重要。针对该问题,提出了基于加权在线样本更新的目标长时跟踪方法,使用置信度分值加权在线学习样本,目标丢失后利用了时空约束搜索在有效区域寻找目标,并在搜索过程中自适应设定了阈值以减少相似背景干扰。与其他方法相比,本文方法具有更优异的跟踪能力。

参考文献

- [1] MARVASTI-ZADEH S M, LI C, GHANELI-YAKHDAN H, et al. Deep learning for visual tracking: A comprehensive survey [J]. IEEE Transactions on Intelligent Transportation Systems, 2021, DOI: 10.1109/TITS.2020.3046478.
- [2] 韩瑞泽, 冯伟, 郭青, 等. 视频单目标跟踪研究进展综述[J]. 计算机学报, 2022, 45(9): 1877-1907.
HAN R Z, FENG W, GUO Q, et al. Single object tracking research: A survey [J]. Chinese Journal of Computers, 2022, 45(9): 1877-1907.
- [3] 刘秀平, 袁皓, 李梦璐, 等. ECO多特征融合目标工件跟踪方法研究[J]. 电子测量与仪器学报, 2021, 35(10): 161-167.
LIU X P, YUAN H, LI M L, et al. Research on target work-piece tracking method based on ECO multi-feature fusion [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10): 161-167.
- [4] 郭秋蕊, 李建良, 田垚, 等. 基于改进KCF算法和多特征融合的车辆跟踪研究[J]. 电子测量与仪器学报, 2022, 36(4): 231-240.
GUO Q R, LI J L, TIAN Y, et al. Research on vehicle tracking based on improved KCF algorithm and Multi-feature fusion [J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(4): 231-240.
- [5] DANELLJAN M, BHAT G, KHAN F S, et al. Atom: Accurate tracking by overlap maximization [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 4660-4669.
- [6] JIANG B, LUO R, MAO J, et al. Acquisition of localization confidence for accurate object detection[C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018: 784-799.
- [7] 李绍明, 储珺, 冷璐, 等. 目标跟踪中基于IoU和中心

- 点距离预测的尺度估计[J]. 自动化学报, 2021, 48: 1001-1014.
- LI SH M, CHU J, LENG L, et al. Accurate scale estimation with IoU and distance between centroids for object tracking [J]. Acta Automatica Sinica, 2021, 48: 1001-1014.
- [8] 陈法领, 丁庆海, 罗海波, 等. 采用时空上下文的抗遮挡实时目标跟踪[J]. 红外与激光工程, 2021, 50(1): 333-343.
- CHEN F L, DING Q H, LUO H B, et al. Anti-occlusion real time target tracking algorithm employing spatio-temporal context [J]. Infrared and Laser Engineering, 2021, 50(1): 333-343.
- [9] 余铎, 王耀南, 毛建旭, 等. 基于视觉的机器人目标跟踪方法[J]. 仪器仪表学报, 2019, 40(1): 227-235.
- YU Z, WANG Y N, MAO J X, et al. Vision-based object tracking method of mobile robot [J]. Chinese Journal of Scientific Instrument, 2019, 40(1): 227-235.
- [10] HUANG L, ZHAO X, HUANG K. Globaltrack: A simple and strong baseline for long-term tracking [C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 11037-11044.
- [11] 白中浩, 朱磊, 李智强. 基于多模型融合和重新检测的高精度鲁棒目标跟踪[J]. 仪器仪表学报, 2019, 40(9): 132-141.
- BAI ZH H, ZHU L, LI ZH Q. High-accuracy and robust object tracking based on multi-model fusion and re-detection [J]. Chinese Journal of Scientific Instrument, 2019, 40(9): 132-141.
- [12] 黄鹤, 张科, 陈永安, 等. 一种无人机航拍目标的长期跟踪算法[J]. 哈尔滨工业大学学报, 2022, 54(5): 104-116.
- HUANG H, ZHANG K, CHEN Y AN, et al. A long-term tracking algorithm for UAV aerial photography [J]. Journal of Harbin Institute of Technology, 2022, 54(5): 104-116.
- [13] YAN B, ZHAO H, WANG D, et al. ‘Skimming-perusal’ tracking: A framework for real-time and robust long-term tracking [C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 2385-2393.
- [14] CHOI S, LEE J, LEE Y, et al. Robust long-term object tracking via improved discriminative model prediction [C]. European Conference on Computer Vision, Cham: Springer, 2020: 602-617.
- [15] BHAT G, DANELLJAN M, GOOL L V, et al. Learning discriminative model prediction for tracking [C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 6182-6191.
- [16] DANELLJAN M, GOOL L V, TIMOFTE R. Probabilistic regression for visual tracking [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 7183-7192.
- [17] LUKEZIC A, ZAJC L C, VOJIR T, et al. Performance evaluation methodology for long-term single-object tracking [J]. IEEE Transactions on Cybernetics, 2021, 51(12): 6305-6318.

作者简介



陈仁祥(通信作者), 分别在2007年和2012年于重庆大学获得学士学位和博士学位, 现为重庆交通大学教授、博士生导师, 主要研究方向为智能测试技术与信号处理。

E-mail: manlou.yue@126.com

Chen Renxiang (Corresponding author) received his B.Sc. degree and Ph.D. degree both from Chongqing University in 2007 and 2012, respectively. He is currently a professor and a Ph.D. supervisor at Chongqing Jiaotong University. His main research interests include intelligent testing technology and signal processing.



何家乐, 2021年于重庆交通大学获得学士学位, 现为重庆交通大学硕士研究生, 主要研究方向为机器视觉与目标跟踪。

E-mail: 2947387504@qq.com

He Jiale received his B.Sc. degree from Chongqing Jiaotong University in 2021. He is currently a M.Sc. candidate at Chongqing Jiaotong University. His main research interests include machine vision and object tracking.