

DOI:10.16136/j.joel.2022.10.0008

ATOM 多注意力融合工件跟踪方法研究

徐 健^{1*}, 张林耀¹, 袁 翱¹, 刘秀平¹, 闫焕营²

(1. 西安工程大学 电子信息学院, 陕西 西安 710048; 2. 深圳罗博泰尔机器人技术有限公司, 广东 深圳 518109)

摘要: 针对工业生产复杂环境下, 工件跟踪鲁棒性差且精确度低的问题, 本文提出了一种基于重叠最大化精确跟踪算法(accurate tracking by overlap maximization, ATOM)的多注意力融合工件跟踪算法。该算法采用 ResNet50 为骨干网络, 首先融入多注意力机制, 使得网络更关注目标工件的关键信息; 其次, 使用注意力特征融合(attentional feature fusion, AFF)模块融合深层特征与浅层特征, 更好地保留目标工件的语义与细节信息, 以适应工业生产复杂多变的环境; 最后将骨干网络第 3 层和第 4 层特征送入 CSR-DCF 分类器中, 对得到的响应图进行融合, 用以获取目标工件的粗略位置, 通过状态估计网络获取精确目标框。实验表明, 本文算法在 OTB-2015 数据集上的成功率(Success)与准确率(Precision)分别达到 67.9% 和 85.2%; 在 VOT-2018 数据集上的综合评分达到 0.434, 具有较高的精度和鲁棒性; 在 CCD 工业相机拍摄的目标工件序列上, 进一步验证了本文算法能高效应对工件跟踪过程中的常见挑战。

关键词: 深度学习; 目标跟踪; 注意力机制; 特征融合

中图分类号: TP391.41 文献标识码: A 文章编号: 1005-0086(2022)10-1047-08

Research on ATOM multi-attention fusion workpiece tracking method

XU Jian^{1*}, ZHANG Linyao¹, YUAN Hao¹, LIU Xiuping¹, YAN Huanying²

(1. School of Electronics and Information, Xi'an Polytechnic University, Xi'an, Shaanxi 710048, China; 2. Municipal Robotel Robot Technology Co., LTD, Shenzhen, Guangdong 518109, China)

Abstract: To solve the problem of poor robustness and low accuracy of workpiece tracking in complex industrial production environment, this paper presents a multi-attention fusion workpiece tracking algorithm based on accurate tracking by overlap maximization (ATOM). The algorithm uses ResNet50 as the backbone network, first incorporating a multi-attention mechanism, which makes the network pay more attention to the key information of the target workpiece. Secondly, the attention feature fusion (AFF) module is used to fuse the deep and shallow features to better preserve the semantics and details of the target workpiece in order to adapt to the complex and changeable environment of industrial production. Finally, the third and fourth layers features of the backbone network are fed into the CSR-DCF classifier, and the resulting response graphs are fused to obtain rough locations of target workpieces and accurate target frames through the state estimation network. Experiments show that the Success and Precision of the algorithm on OTB-2015 dataset are 67.9% and 85.2%, respectively. The overall score on VOT-2018 dataset is 0.434, which has high accuracy and robustness. On the target workpiece sequence taken by the CCD industrial camera, the algorithm is further validated to meet the common challenges efficiently in the workpiece tracking process.

Key words: deep learning; target tracking; attention mechanism; feature fusion

* E-mail: xujian@xpu.edu.cn

收稿日期: 2022-01-04 修订日期: 2022-02-28

基金项目: 陕西省科技厅项目(2018GY-173)和西安科技局项目(GXYD7.5)资助项目

1 引言

目标跟踪作为计算机视觉重要分支,在诸多领域应用广泛^[1]。近些年来,随着我国制造产业转型不断深入,智能工厂已成为未来工业生产的发展趋势,通过对目标工件跟踪可以有效提高工业生产效率。实际工业生产环境往往存在遮挡、背景信息复杂、尺度变化、光照变化等问题,对目标工件跟踪算法的精度和鲁棒性有着较高要求,因此研究高效的目标工件跟踪算法有着重要现实意义。

现如今目标跟踪算法大致分为相关滤波(correlation filtering)^[2]和孪生网络(siamese network)^[3]两大类。基于相关滤波的目标跟踪算法,如连续卷积跟踪算法(learning continuous convolution operators for visual tracking, C-COT)^[4]提出了连续空间域插值转换操作,解决了不同卷积层分辨率不同的问题,提高了算法精度。基于高效卷积运算的跟踪算法(efficient convolution operators for tracking, ECO)^[5]在C-COT算法基础上对训练集大小、模型大小以及模型更新策略进行优化,提高了算法速度。相关滤波类算法在目标跟踪的速度和精度上有一定提升,但滤波器面对较为复杂的环境,性能会大幅下降。为解决上述问题,众多学者使用深层卷积神经网络的强大表征能力来提高精度,但会导致计算量的增加从而降低跟踪速度。相比于相关滤波类算法,孪生网络类算法在平衡跟踪精度与跟踪速度方面取得不错成果,如全卷积孪生网络(fully-convolutional siamese networks, SiamFC)^[6]将模板图像作为卷积核与搜索图像进行卷积,保证算法精度的同时保证了跟踪

速度。孪生区域候选网络算法(high performance visual tracking with siamese region proposal network, SiamRPN)^[7]在SiamFC的框架上引入区域建议网络(region proposal network, RPN),使得网络进一步提高了跟踪速度与精度。SiamRPN++(evolution of siamese visual tracking with very deep networks)^[8]算法在SiamRPN算法基础上采用一种简单而有效的采样策略,打破了空间不变性的限制,成功训练了一种基于ResNet网络结构的Siamese跟踪器。在实际工业生产中,目标工件尺度的准确估计是影响生产效率的一个重要因素,上述孪生网络类算法大多存在尺度变化差且未考虑背景信息的问题,为此,重叠最大化精确跟踪算法(accurate tracking by overlap maximization, ATOM)^[9]基于孪生网络和相关滤波提出一种全新的跟踪架构,由专门的目标估计模块和分类模块组成,通过梯度上升迭代使得预测框与真实框之间的重叠率更高,实现对目标的跟踪。

综上所述,本文提出了一种基于ATOM框架的跟踪算法,如图1所示。在目标估计模块加入多注意力机制使得网络可以正确地关注目标工件,同时使用注意力特征融合(attentional feature fusion, AFF)模块更好地融合多层特征信息;在分类模块采用一种多层次特征聚合策略,将得到的特征图输入到具有通道和空间可靠性的判别相关滤波器(discriminative correlation fiber tracker with channel and spatial reliability, CSR-DCF)中进行预测分类,获取目标工件的粗略位置;最后由测试分支IoU(intersection over union)预测的特征与参考分支生成的调制向量相乘,获取精准目标框。在后续跟踪过程中,根据前一帧目标框尺度大小,在

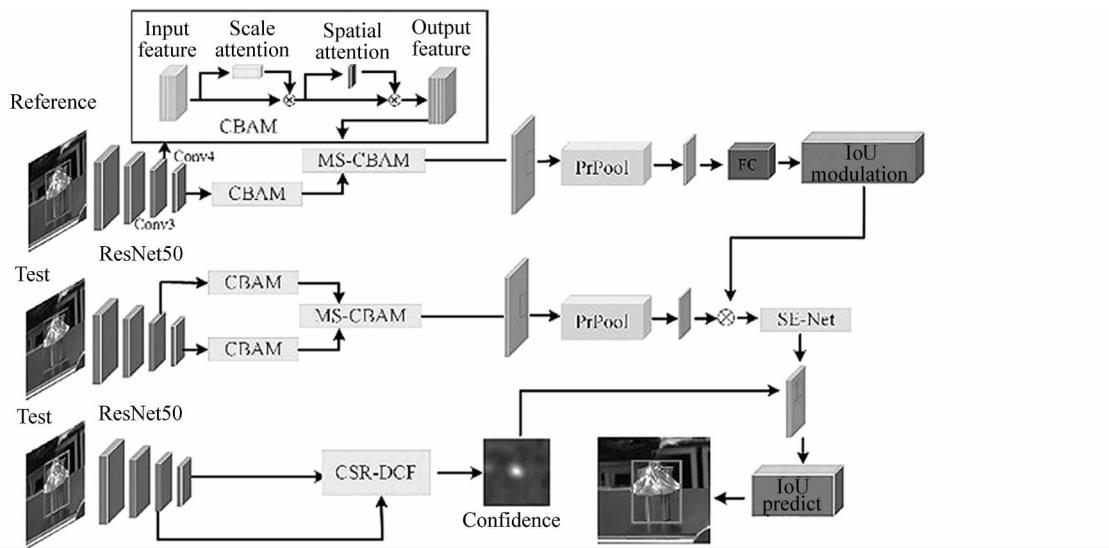


图1 本文算法框架

Fig. 1 The algorithm framework of this paper

目标工件定位处产生一些候选框,使用 IoU Predict 模块对候选框进行评估,选取得分最高的候选框为跟踪结果。实验结果表明改进后的算法在精度和鲁棒性上得到显著的提升。

2 ATOM 框架概述

ATOM 算法通过借鉴 DCF^[10] 和 IoU-Net (intersection over union net)^[11], 将目标跟踪分为在线的目标分类和离线的状态估计两个子问题。其中在线的目标分类网络以 ResNet50 为骨干网络, 使用两层全卷积层来兼顾效率和收敛性, 提供粗略的 2D 目标位置, 将目标从背景中分离, 全卷积层公式如下:

$$f(x; \omega) = \varphi_2(\omega_2 * \varphi_1(\omega_1 * x)), \quad (1)$$

式中, x 表示骨干网络提取的特征, ω_1 为 1×1 , 输出通道为 64 的卷积层, ω_2 为 4×4 , 输出通道为 1 的卷积层, φ_1 、 φ_2 表示激活函数。

通过采用相关滤波的方法计算损失函数, 建立 L2 目标函数。

$$L(\omega) = \sum_{j=1}^m \gamma_j \| f(x_j; \omega) - y_j \|^2 + \sum_k \lambda_k \| \omega_k \|^2, \quad (2)$$

式中, y 表示回归目标, γ_j 表示权重, λ 表示正则项。同时为使损失函数收敛得更快, 设计了一种新的基于共轭梯度和高斯牛顿优化的算法, $\gamma_j(\omega) = \sqrt{Y_j}(f(x_j; \omega) - y_j)$ 和 $\gamma_{m+k}(\omega) = \sqrt{Y_k}\omega_k$, 其中 $j \in \{1, \dots, m\}$, $(k=1, 2)$ 。损失函数可写为 $L(\omega) = \|\gamma(\omega)\|^2$, 其中 $\gamma(\omega)$ 是所有 $\gamma_j(\omega)$ 的串联。

离线的状态估计模块在得到由分类模块所提供的粗略目标位置后, 对回归框进行优化, 提出一种基于调制的网络结构, 使用 ResNet50 作为骨干网络, 分为参考分支和测试分支, 通过参考分支对当前图像进行处理, 在测试分支采用多层卷积和池化来提取 IoU 预测的特征, 使用 Channel-wise 的矩阵乘法, 将测试分支 IoU 预测的特征与参考分支生成的调制向量相乘, 为 IoU 预测提供了特定目标, 公式如下:

$$IoU(B) = g(c(x_0, B_0) \cdot z(x, B)), \quad (3)$$

式中, $c(x_0, B_0)$ 表示参考分支输出的调制矢量, $z(z, B)$ 表示测试分支通过 PrPooling 之后的目标特征, g 为 IoU 预测模块。

3 多注意力融合工件跟踪方法

3.1 多注意力机制

为使网络在工业生产环境中更加关注目标工件

的特征信息, 提高抑制噪音干扰的能力, 本文采用结合空间注意力模块(spatial attention module)和通道注意力模块(channel attention module)的双重注意力机制模块(convolutional block attention module, CBAM)^[12]。通过加入双重注意力机制, 使改进后的网络可以更正确地关注目标对象, 有效提高算法成功率。

通道注意力机制通过学习不断调整各通道的权重, 使得网络更加关注目标工件的可视区域, 其原理如图 2 所示。将输入的特征采用平均池化(average-pooling)和最大池化(max-pooling)来池化特征, 通过共享网络将输出的特征进行基于逐元素(element-wise)的加和操作, 经过 Sigmoid 激活操作最终生成的通道注意力特征图(channel attention feature map), 通道注意力计算式如下:

$$\begin{aligned} M_C(F) &= \sigma(MLP(AvgPool(F)) + \\ &\quad MLP(MaxPool(F))) = \\ &\quad \sigma(W_1(W_0(F_{avg}^c)) + W_1(W_0(F_{max}^c))), \end{aligned} \quad (4)$$

式中, $M_C(F)$ 为通道注意力参数矩阵, F 为输入的特征图, F_{avg}^c 和 F_{max}^c 表示平均池化特征和最大池化特征, σ 为 Sigmoid 函数, MLP 表示 3 层感知机, W_0 和 W_1 为 MLP 的权重, $W_0 \in R^{C/r \times C}, W_1 \in T^{C \times C/r}$, r 表示减少率。

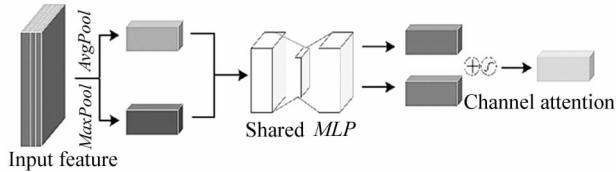


图 2 通道注意力机制

Fig. 2 Channel attention mechanism

将得到的通道注意力特征图与输入的特征图做逐元素的乘法操作, 生成空间注意力机制模块的输入特征, 如图 3 所示。

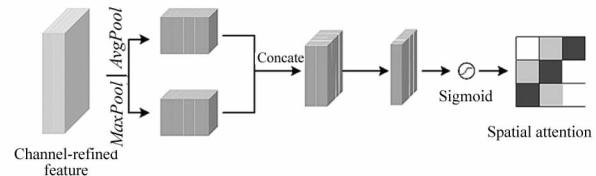


图 3 空间注意力机制

Fig. 3 Spatial attention mechanism

首先通过最大池化与平均池化操作, 将生成的信息通过 Concat 操作进行连接, 其次经过一个卷积

层产生空间注意力特征图,最后通过 Sigmoid 函数进行标准化,得到最终的注意力特征图。计算式如下:

$$M_s(F) = \sigma(f^{7 \times 7}([AvgPool(F); MaxPool(F)])) = \sigma(f^{7 \times 7}([F_{avg}; F_{max}])), \quad (5)$$

式中,7×7 表示卷积核的大小,为空间注意力参数矩阵。加入空间注意力机制后的网络提高了对目标工件的识别能力和鲁棒性。

本文将压缩和激励网络(squeeze-and-excitationNet, SENet)^[13]部署在由测试分支生成的 IoU 预测特征与参考分支生成的调制向量相乘之后,使用自适应的通道注意力对目标工件特定位置进行关注以突出目标工件的主体部分,SENet 注意力模块如图 4 所示。对于通过 SENet 的特征图使用 IoU Predict 模块对所有的候选框进行评估最终得到最优边界框。

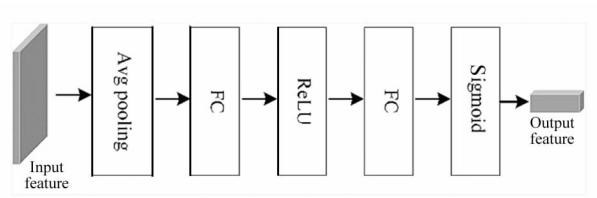


图 4 SENet 模块

Fig. 4 SENet module

3.2 AFF 模块

目标工件实际跟踪过程中,难免会出现运动模糊、尺度变换和遮挡等问题,导致后续目标工件的状态出现较大差异。考虑到深层特征中的高级语义信息可以鲁棒地表征目标工件,而浅层特征中具有如颜色、边缘等细节信息可以更精确地定位目标工件,因此本文为了更好地融合语义信息与细节信息,使用 AFF 模块^[14],将深层特征与浅层特征进行融合,如图 5 所示。

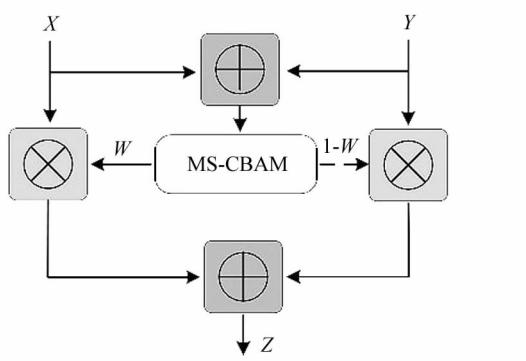


图 5 AFF 模块

Fig. 5 Attention feature fusion module

将 X、Y 两个维度相同的特征相加作为 AFF 模块的输入,将注意力权重 W、1-W 分别作用于 X、Y,保留特征图中的有效信息,最后将深层与浅层的注意力特征图相加,Z 为注意力特征融合后的输出。AFF 表达式如下所示:

$$Z = W \otimes X + (1 - W) \otimes Y, \quad (6)$$

式中,M=M(X⊕Y),M 为 MS-CBAM,图 5 中虚线部分为 1-W,融合权重 W 的输出值与 1-W 的值为 0—1,使得网络可以在 X 与 Y 之间进行软选择或者加权平均。

本文还将 AFF 作为特征融合方式,对 ResNet50 中的 Bottle Neck3 和 Bottle Neck4 进行改进,使用改进后的残差块替换原特征提取网络中的残差块,如图 6 所示。

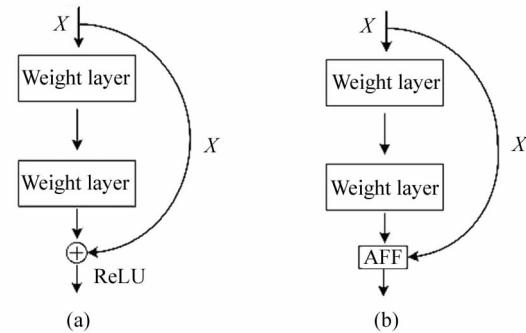


图 6 改进前后的残差块结构:

(a) ResNet 残差块;
(b) 改进后的 ResNet50 残差块

Fig. 6 Residual block structure before and after

improvement: (a) ResNet residual block;
(b) Improved ResNet50 residual block

图中(a),(b)分别为改进前与改进后的残差块。相比于改进前采用原特征与剩余特征加和的方式,改进后网络结构更有利子不同层次特征的融合。

3.3 多层特征聚合与难例挖掘

本文在目标分类模块采用一种多层次特征聚合策略并使用 CSR-DCE^[15]作为分类器,使得目标工件在定位更准确的同时平衡了跟踪速度。由于卷积神经网络的不同层对于目标跟踪的效果不同,因此本文对骨干网络 ResNet50 中的第 3 层,第 4 层,第 5 层作为分类模块的输入进行对比,在 OTB-2015 数据集上进行测试,结果如图 7 所示。

其中第 3 层与第 4 层作为分类模块输入时,会得到较好的结果,使用第 5 层时,效果会明显地降低,因此本文实验使用第 3 层,第 4 层作为 CSR-DCE 分

类器中的输入。将得到的融合响应图用以实现目标的定位,如图 8 所示。

由于工业生产中存在各种干扰,为了进一步加强网络分类部分的鲁棒性,本文采用了一种难例挖掘策略,该策略在许多视觉跟踪器中普遍应用^[16],如果在分类中检测到干扰峰值,就将该训练样本的学习率提高一倍,并使用标准设置($\text{NGN}=1$, $\text{NCG}=5$)进行优化。当分类分数低于 0.3 时,将目标确定为失败,通过使用难例挖掘策略,为算法提供了一些额外的鲁棒性。

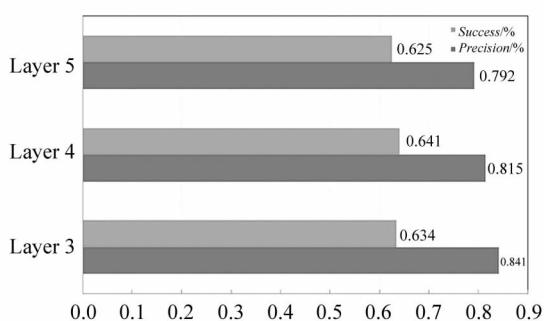


图 7 不同卷积层性能对比

Fig. 7 Performance comparison of different accretion layers

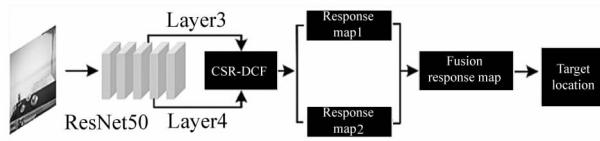


图 8 多层特征聚合

Fig. 8 Multilayer feature aggregation

4 实验结果与分析

本实验基于 Pytorch 深度学习框架,使用 Linux

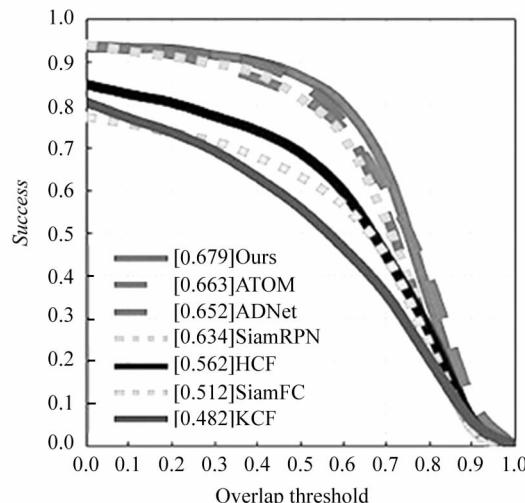


图 9 不同算法在 OTB-2015 的评估结果

Fig. 9 Evaluation results of different algorithms on OTB-2015

操作系统,CPU 为 Intel i7-7800X,GPU 为 NVIDIA RTX2080Ti,内存为 16 GB,编程语言为 python3.7。使用 Adam 优化器训练 50 个 epoch,初始学习率为 1×10^{-3} ,Step Size 为 15,Batch Size 为 16,在第 1 帧使用高斯牛顿迭代 $\text{NCN}=6$,共轭梯度迭代 $\text{NCG}=10$ 进行优化,后续每 10 帧使用高斯牛顿迭代 $\text{NCN}=1$,共轭梯度迭代 $\text{NCG}=5$ 进行优化。使用 TrackingNet, Lasot, CoCo 3 个大型数据集作为训练数据集。

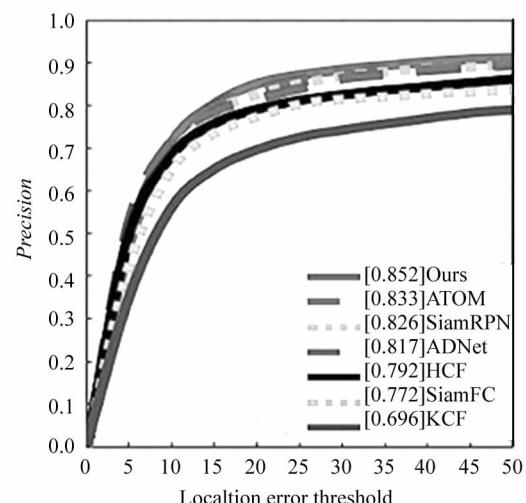
4.1 定量分析

为了验证本文算法模型的有效性,将改进后的算法与当前的主流算法在 OTB-2015^[17] 和 VOT-2018^[18] 两个标准测试集上进行对比。

4.1.1 OTB-2015 数据集测试

OTB-2015 数据集作为单目标跟踪领域内最常用的基准数据集,包含 100 个视频序列,不仅场景复杂多变,且数据集存在不少目标从画面完全消失的情况,对模型的鲁棒性和精准性要求较高。采用一次通过评估的方式(one-pass-evaluation,OPE)进行测试,使用成功率(Success)和准确率(Precision)对算法进行评估。

改进后的算法在 OTB-2015 数据集上与主流的 6 种算法进行比较,如图 9 所示。本文算法的 Precision 与 Success 分别为 0.852 和 0.679,整体跟踪效果均高于其余六种主流算法。在平均跟踪精准度上比次优的 ATOM 算法提高 1.6%;并在平均跟踪成功率上较次优的 ATOM 算法提高 1.9%。精准度与成功率的提升得益于多注意力机制对网络的改进,使得网络可以获得更多目标工件所需要关注区域的



细节信息。

4.1.2 VOT-2018 数据集测试

VOT-2018 数据集包含 60 个视频序列,采用跟踪失败再重启的机制提高对数据集的有效利用。通过准确性 (accuracy, $Acc.$)、鲁棒性 ($Rob.$) 以及预期平均重叠率 (expected average overlap, EAO), 来评估跟踪器的性能。当跟踪失败再重启的次数越少, $Rob.$ 越小, 表明算法的鲁棒性越好; $Acc.$ 反应了预测框与真实框的重合率; EAO 越高, 表明算法的综合性能越高。

如表 1 所示, 本文算法在 VOT-2018 数据集上的 $Acc.$ 、 $Rob.$ 以及 EAO 分别为 0.594、0.179 和 0.434, EAO 和 $Acc.$ 均超越了近年的主流跟踪算法, $Rob.$ 也达到了次优。

表 1 VOT-2018 数据集上实验结果对比

Tab. 1 Comparison of experimental results on VOT-2018 dataset

Tracker	$Acc.$	$Rob.$	EAO
DLST	0.543	0.224	0.325
CPT	0.507	0.239	0.339
DaSiamRPN	0.586	0.476	0.383
MFT	0.505	0.140	0.385
ATOM	<u>0.590</u>	0.204	<u>0.401</u>
Ours	0.594	<u>0.179</u>	0.434

注: 加粗与下划线分别表示最优和次优结果。

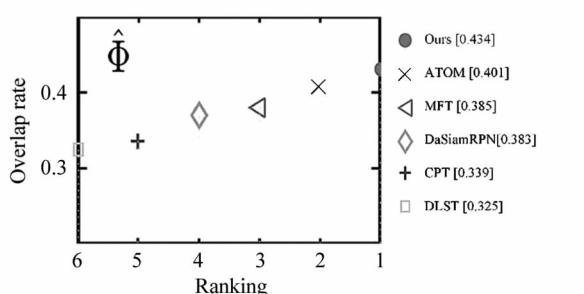


图 10 VOT-2018 上预期平均重叠性能

Fig. 10 Expected averaged overlap performance on VOT-2018

4.2 跟踪算法性能分析

为直观展示和验证双注意力机制对目标提取特征的有效性, 使用 Grad-CAM^[19] 进行可视化, 如图 11 所示。Grad-CAM 通过生成的类激活热力图 (class activation map, CAM) 将分类结果可视化, 在热力图中, 区域温度越高表示类别的激活值越大, 即该区域是该类别的可能性越大。

从图 11 中可以看出: 使用双重注意力机制对

ResNet50 输出特征进行调整, 能够提供更多的工件细节特征, 从而使分类结果更加准确。这表明 CBAM 模块可以提取出积极有效的特征, 进而加强网络对目标的分辨能力, 抑制干扰, 提高算法的跟踪精度。

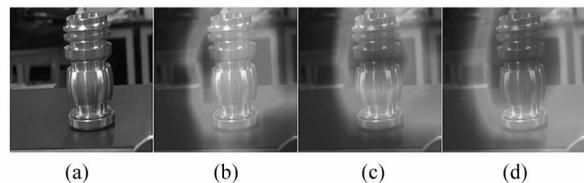


图 11 Grad-CAM 可视化:(a) 工件;

(c) ResNet50-SE; (d) ResNet50-CBAM

Fig. 11 Grad-CAM visualization:(a) Workpiece;

(b) ResNet50; (c) ResNet50-SE;

(d) ResNet50-CBAM

为了进一步验证本文算法的实用性, 使用 CCD 工业相机拍摄 3 段不同场景下的工件视频序列, 如表 2 所示。自动化工业流水实验平台传送带运转速度为 0.7 m/min, 实验机械臂负重 250 g 时, 大小臂、底座最大旋转运动速度为 320°/s, 末端旋转速度 480°/s。

表 2 工件视频序列

Tab. 2 Workpiece video sequence

Sequence name	Frame	Challenge
Sequence 1	152	SV、OCC、BC、FM、CM、SOB
Sequence 2	683	SV、OCC、BC、FM、SOB、MB
Sequence 3	234	SV、OCC、BC、FM、CM、SOB、MB

序列中的目标主要存在尺度变化 (scale variation, SV)、遮挡 (occlusion, OCC)、运动模糊 (motion blur, MB)、背景干扰 (background clutter, BC)、快速运动 (fast moving, FM)、相机运动 (camera motion, CM)、相似目标 (similar object, SOB) 等挑战。将本文算法与其他主流跟踪算法进行对比测试, 如图 12 所示。

图 12(a) 工件序列 1 为模拟工件在工业生产流水线中, 存在相似目标、背景干扰等挑战, 除 KCF 算法在第 76 帧出现错误跟踪外, 其余 4 种算法均可完成对目标工件的跟踪, 但本文算法所受到的干扰影响最低。图 12(b) 工件序列 2 在较为复杂的背景条件下使用机械臂对目标工件进行移动, 该序列中 SiamFC 和 KCF 算法在 364 帧由于目标工件周围出

现相似目标,跟踪器难以确定目标工具位置,从而导致跟踪失败。其余两种算法出现了轻微的漂移,本文算法通过多注意机制抑制相似目标干扰,可以精准地对目标工件进行跟踪。图 12(c)工件序列 3 为

模拟工业生产流水线上使用机械臂对目标工件进行抓取工作,本文算法使用 AFF 模块和难例发掘策略等方法提高网络的鲁棒性,面对部分遮挡、尺度变换等一系列挑战,只有本文算法仍能实现目标

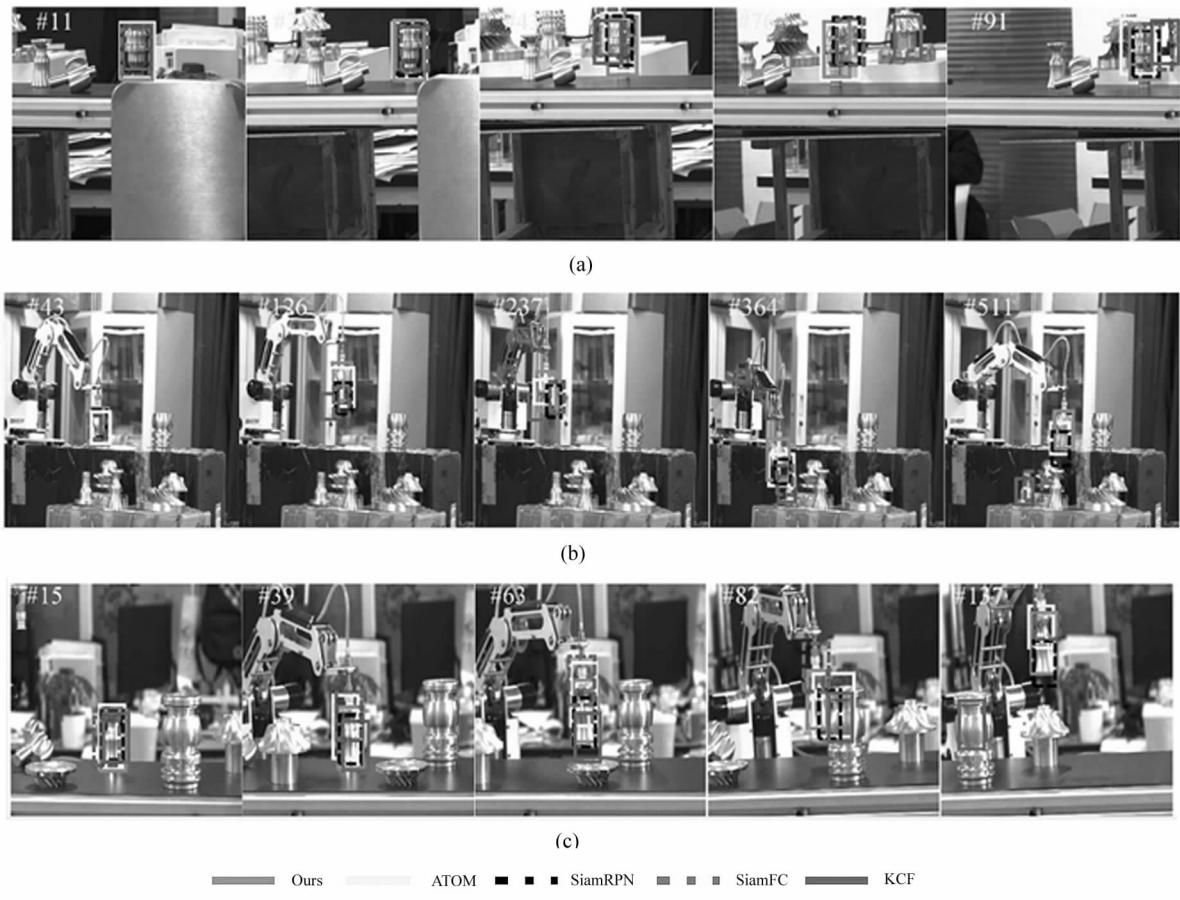


图 12 目标工件跟踪结果图:(a)工件序列 1; (b) 工件序列 2; (c) 工件序列 3

Fig. 12 Result diagram of target workpiece tracking: (a) Workpiece sequence 1;
(b) Workpiece sequence 2; (c) Workpiece sequence 3

工件的稳定准确跟踪。

5 结 论

本文针对目标工件跟踪问题,提出了一种 ATOM 多注意力融合工件跟踪方法,在 ATOM 算法的基础上对骨干网络进行改进,融入多注意力机制的同时引入 AFF 模块对深层特征与浅层特征进行融合,并采用一种多层次特征聚合与难例挖掘策略用于增强网络分类部分的鲁棒性,解决了工业生产复杂环境下对目标工件长时间稳定跟踪的问题。通过在 OTB-2015,VOT-2018 数据集以及实际工件视频序列中测试,本文算法在精确度与成功率上都取得了提升,同时面对诸多场景中存在的不同干扰,改进后的算法具备更强的鲁棒性。但当目标工件出现长时

间遮挡时会对算法造成一定影响,在未来的工作中将着重对此方面进行改进,进一步提高算法的跟踪性能。

参 考 文 献:

- [1] MENG L,YANG X. Overview of target tracking algorithms [J]. Journal of Automation, 2019, 45(7):1244-1260.
孟琭,杨旭. 目标跟踪算法综述[J]. 自动化学报, 2019, 45(7):1244-1260.
- [2] LUKEZIC A,VOJIR T,CEHOVIN Z L,et al. Discriminative correlation filter with channel and spatial reliability[C]// IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York:IEEE, 2017:6309-6318.
- [3] CHEN Y F,WU Y,ZHANG W. Overview of target tracking

- algorithms based on twin network structure[J]. Computer Engineering and Application, 2020, 56(6): 10-18.
- 陈云芳, 吴懿, 张伟. 基于孪生网络结构的目标跟踪算法综述[J]. 计算机工程与应用, 2020, 56(6): 10-18.
- [4] DANELLJAN M, ROBINSON A, KHAN F S, et al. Beyond correlation filters: Learning continuous convolution operators for visual tracking [C]// European Conference on Computer Vision, October 8-16, 2016, Amsterdam, the Netherlands. Cham: Springer, 2016: 472-488.
- [5] DANELLJAN M, BHAT G, SHAHBAZ K F, et al. Eco: Efficient convolution operators for tracking [C]// IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017: 6638-6646.
- [6] BERTINETTO L, VALMADRE J, HENRIQUES J F, et al. Fully-convolutional siamese networks for object tracking [C]// European Conference on Computer Vision. October 8-16, 2016, Amsterdam, the Netherlands. Cham: Springer, 2016: 850-865.
- [7] LI B, YAN J, WU W, et al. High performance visual tracking with siamese region proposal network [C]// 2018 IEEE Conference on Computer Vision and Pattern Recognition, June 18-22, 2018, Salt Lake City, UT, USA. New York: IEEE, 2018: 8971-8980.
- [8] LI B, WU W, WANG Q, et al. Evolution of siamese visual tracking with very deep networks [C]// IEEE Conference on Computer Vision and Pattern Recognition, June 15-20, 2019, Long Beach, CA, USA. New York: IEEE, 2019: 16-20.
- [9] DANELLJAN M, BHAT G, KHAN F S, et al. Atom: Accurate tracking by overlap maximization [C]// IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 15-20, 2019, Long Beach, CA, USA. New York: IEEE, 2019: 4660-4669.
- [10] 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.
- [11] BERTINETTO L, VALMADRE J, HENRIQUES J F, et al. Fully-convolutional siamese networks for object tracking [C]// European Conference on Computer Vision (ECCV), October 8-16, 2016, Amsterdam, the Netherlands. Cham: Springer, 2016: 850-865.
- [12] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C]// European Conference on Computer Vision (ECCV), September 8-14, 2018, Munich, Germany. Cham: Springer, 2018: 3-19.
- [13] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]// IEEE Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE, 2018: 7132-7141.
- [14] DAI Y, GIESEKE F, OEHMCKE S, et al. Attentional feature fusion [C]// IEEE/CVF Winter Conference on Applications of Computer Vision, January 3-8, 2021, Waikoloa, HI, USA. New York: IEEE, 2021: 3560-3569.
- [15] LUKEZIC A, VOJIR T, CEHOVIN Z L, et al. Discriminative correlation filter with channel and spatial reliability [C]// IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE, 2017: 6309-6318.
- [16] ZHU Z, WANG Q, LI B, et al. Distractor-aware siamese networks for visual object tracking [C]// European Conference on Computer Vision (ECCV), September 8-14, 2018, Munich, Germany. Cham: Springer, 2018: 101-117.
- [17] WU Y, LIM J, YANG M H. Object tracking benchmark [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1834-1848.
- [18] KRISTAN M, LEONARDIS A, MATAS J, et al. The sixth visual object tracking VOT2018 challenge results [C]// European Conference on Computer Vision (ECCV) Workshops, September 8-14, 2018, Munich, Germany. Cham: Springer, 2018: 3-53.
- [19] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-CAM: Visual explanations from deep networks via gradient-based localization [C]// IEEE International Conference on Computer Vision, October 22-29, 2017, Venice, Italy. New York: IEEE, 2017: 618-626.

作者简介:

徐健 (1963—),男,硕士,教授,硕士生导师,主要从事机器视觉、图像处理方面的研究。