

引文格式: 崔俊佳, 刘泉, 赖铭, 等. 面向航空发动机油路密封管件的高鲁棒性视觉定位算法研究[J]. 航空制造技术, 2023, 66(14): 136-142.

CUI Junjia, LIU Xiao, LAI Ming, et al. Research on robust visual localization algorithm for aero-engine oil sealing pipe fitting[J]. Aeronautical Manufacturing Technology, 2023, 66(14): 136-142.

面向航空发动机油路密封管件的高鲁棒性视觉定位算法研究*

崔俊佳¹, 刘泉¹, 赖铭¹, 王绍螺¹, 蒋浩¹, 李光耀²

(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. 北京理工大学深圳汽车研究院(电动车辆国家工程实验室深圳研究院), 深圳 518118)

[摘要] 航空航天行业零部件种类繁多、定制化程度高, 难以进行定位夹具的开发。视觉定位技术是智能制造中的关键一环, 该技术基于机器视觉确定工件位置, 不需要定位夹具, 能够被广泛运用于各种工况。但现有视觉定位算法只适用于少数种类的零件, 泛用性不高。本文提出了一种基于 YOLOv5s 目标检测网络和 Siamese 孪生网络的新型视觉定位算法(YOLO-Siamese 变化检测网络)。网络引入 ConvDiff(卷积差分)模块来提升变化检测网络的特征提取效果, 并采用半监督学习方法对模型进行训练。试验表明, 在没有使用目标工件数据集的条件下, 算法在验证集上的 AP@0.5 达到了 99.3%, AP@0.5:0.95 达到了 89.6%, 单帧推理时间为 16.13 ms。该算法无需目标工件数据、定位精度高、运算速度快, 提高了视觉定位算法的鲁棒性和泛用性。

关键词: 变化检测网络; 视觉定位; 机器视觉; YOLO; Siamese; 孪生网络

DOI: 10.16080/j.issn1671-833x.2023.14.136



崔俊佳

教授, 博士生导师, 主要研究方向为异种材料连接和智能检测。

* 基金项目: 国家自然科学基金(52175315、51975202); 深圳市科技计划(KQTD20200820113110016)。

为响应中国制造 2025 的时代主题, 制造业发展趋势将逐步向智能化靠拢。发展智能制造对于打造我国制造业竞争新优势、促进制造业迈向中高端、实现制造强国具有重要意义^[1]。航空航天制造业的零部件种类繁多、定制化程度高^[2], 为智能制造提出了新的挑战。定位是制造中的关键一环, 不论是机械加工、缺陷检测、尺寸测量或是配送生产资料都需要对目标位置进行确定^[3-4]。传统定位方式通过设计与目标零部件配套的机械装置(夹具)来实现位置确定^[5]。尽管使用夹具能达到较好的定位效果, 但会导致生产线只能生产单一类别零部件, 缺乏泛用性, 使得智能制造技术难以满足航空航天制造的需求。

随着工业化智能化进程的发展, 越来越多的工作引入了机器视觉等智能相关的技术。其中, 基于机器视觉的定位算法极大地提高了制造过程的柔性化程度。魏思铭^[6]利用检测环境下圆柱滚子和背景灰度值较大的特点, 使用边缘提取算法来确定待检测工件的位置, 从而实现了圆柱滚子的缺陷检测; 但是, 这种定位方法仅适用于待检测工件与背景亮度差异很大的场景, 在泛用性上略有欠缺。Sun 等^[7]自主开发出了边缘检测算法用于定位丝杆轮廓, 实现了一种基于两阶段视觉的滚珠丝杠关键参数测量技术; 该研究的最终测量精度在 5~8 μm 范围内, 但论文中提到的定位方法高度针对滚珠丝杠, 该算法同样具有泛用性不足的缺点。

基于深度学习的目标检测算法是一种常用的视觉定位算法。相比于传统算法,深度学习算法具有不需要手动提取特征,快速、稳定、鲁棒性高的优点^[8-10]。但是,基于深度学习的目标检测一般是一个有监督的机器学习问题,使得基于目标检测算法的视觉定位模型只是在与训练数据分布相似的数据集上具有良好的泛用性。针对视觉定位算法泛用性普遍较差的问题,本文基于 YOLOv5s 目标检测网络和 Siamese 孪生网络开发了一种高泛用性,对目标工件数据集依赖小的视觉定位算法——YOLO-Siamese 变化检测网络。该算法没有机械定位装置,不需要目标工件数据,具有较高的泛化性与鲁棒性。本文将航空发动机油路密封管件为检测对象,验证提出的 YOLO-Siamese 变化检测网络。

1 试验及方法

1.1 典型件与视觉平台

为了对本研究算法进行性能验证,本文分别列举了两种型号的航空发动机油路管件。两种型号的油路密封管件均有变形特征,具有较好的代表性,如图 1 所示。航空管路系统




图 1 航空发动机油路密封管件
Fig.1 Aero-engine oil sealing pipe fitting

被称为飞行器的“血管”和“气管”,其接头对于整个飞行器的安全至关重要。因此,本文以航空发动机油路管件为检测对象,对提出的高鲁棒性定位算法进行了验证与探究。

为了模拟零件生产后的检测平台,本文搭建了一个框架式视觉平台,如图 2 所示。主要包括工业相机模组、视觉支架、螺纹底座 3 个部分。工业相机模组包括工业相机和相机镜头两个部分,主要负责对原始图像进行采集。视觉支架则用于固定相机模组,并对拍摄高度及角度进行调节。螺纹底座可以用于安装各类附加组件,如光源、转台等,但本文只将其作为载物平台。

1.2 YOLO-Siamese 变化检测网络

本文引入 Siamese 网络(孪生网




图 2 视觉平台
Fig.2 Vision platform

络)对 YOLOv5s 目标检测算法进行改进,得到 YOLO-Siamese 变化检测网络,并基于 YOLO-Siamese 变化检测网络实现了只需少量原始训练样本的高鲁棒性视觉定位算法。如图 3 所示,算法主要流程包括图像采集、半监督训练、模型加速推理 3 个模块。图像采集模块负责获取原始背景图像和工作图像,并将图像送入检测网络中;训练模块基于半监督训练方法对网络进行训练;最后,在加速推理模块中,使用背景预推理方法对推理过程进行加速。本节将围绕变化检测网络搭建、半监督训练、网络推理加速 3 个部分进行详细介绍。

1.2.1 网络搭建

变化检测网络主要基于 Siamese 网络^[11-13],其大体思想为基于权重共享的孪生网络架构(Siamese 网络)提取特征,然后使用特征差分模块得到差分特征,进而对差分特征进行增强提取以及编码输出,得到最终预测结果。但目前的变化检测网络多应用于卫星遥感图像分析领域(如分析宏观的地貌变化),无法应用到精细的视觉定位任务中。

YOLO (You only look once) 是

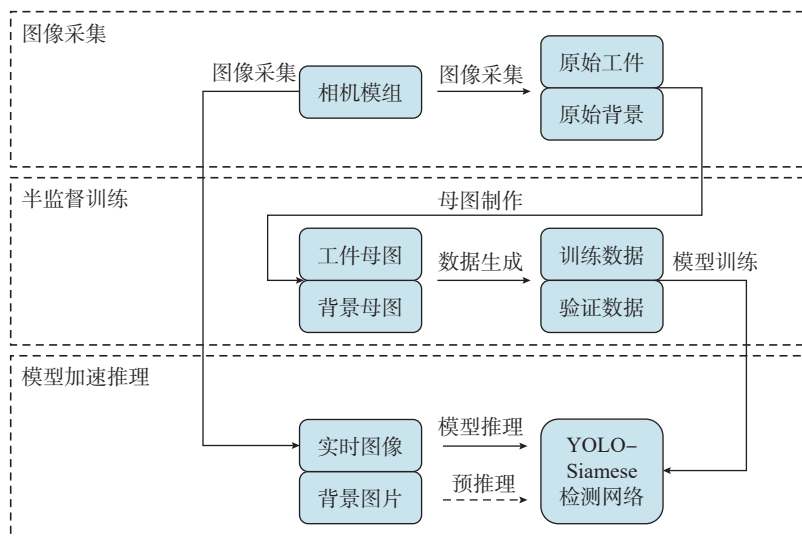


图 3 变化检测算法流程图
Fig.3 Flowchart of the change detection algorithm

一系列开源的单阶段的端对端目标检测算法,兼具高效率和高精度^[14-16],被广泛应用于工业视觉定位任务中。YOLO系列算法目前具有多个版本,其中维护频率最高,应用最广泛的版本为 Ultralytics 公司推出的 YOLOv5。从项目发布至今,YOLOv5 已经迭代到了第 6 个版本。YOLOv5 包括 YOLOv5n、YOLOv5s、YOLOv5m、YOLOv5l、YOLOv5x 这 5 个模型。其中 YOLOv5s 为轻量化版本,网络参数量小,算力需求不大,适合部署在边缘服务器上。本研究选择 YOLOv5s 作为基准检测网络。图 4 为 YOLO-Siamese 整体结构。本研究以 YOLOv5s 为基础检测框架,借鉴 Siamese 孪生网络的权重共享思想,设计了 ConvDiff (卷积差分)模块作为特征差分模块,将 YOLOv5s 改进为 YOLO-Siamese 变化检测网络。

基于孪生网络思想的变化检测网络需要对同时输入的两张图片进行特征差分,进而计算出差分特征,实现变化检测。最简单的特征差分方式为 Siamese 网络中采用的绝对值差分,只对两张图片提取到的特征作差并求绝对值,计算公式为式(1)。但使用简单的绝对值差分方式来提取特征时,效果较不稳定,特别是两张图片没有严格对齐时,算法性能将会下降。

绝对值差分方程为

$$Feature_{diff} = f_{diff}(Feature_1, Feature_2) = |Feature_1 - Feature_2| \quad (1)$$

式中, $Feature_{diff}$ 为差分特征; $Feature_1$ 和 $Feature_2$ 为骨干特征。

如图 5 所示,为了提升变化检测网络中特征差分模块的性能,本文提出了 ConvDiff 模块。ConvDiff 模块在背景图片和工件图片进行绝对值差分前,先通过一个 SE (Squeeze-and-excitation networks) 通道注意力模块及 3 层卷积激活层进行特征增强,然后再进行绝对值差分(Abs),

之后再通过一个卷积模块进一步增强特征得到最终差分特征。

SE 模块^[17]是一种有效的通道注意力模块,该模块通过一个全局平均池化(GAP)、两个全连接层(Fully connect)及一个 Sigmoid 函数获得了通道注意力权重,并基于权重对权值进行调整从而实现通道注意力。SE 通道注意力模块如图 6 所示^[17]。

Sigmoid 函数为

$$\text{sigmoid}(x) = \sigma(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

1.2.2 半监督训练

传统目标检测算法的训练需要大量的数据集,但大量数据集的获取往往存在困难,甚至无法获取。本文采用半监督训练方法,使用少量且易

获取的背景母图和工件母图自动地生成用于训练和验证的数据集,无需人工进行数据标注,从而降低了数据集的获取难度。图 7 所示为模型半监督训练流程,训练数据集需使用与航空航天零件无关的常见零件作为零件母图。具体模型训练步骤包括原始母图创建、数据集生成和在线数据增强训练。

(1) 原始母图创建。

首先拍摄几种常见的金属工件的高清图像,并对图像进行抠图操作,提取目标像素并去除背景像素。此操作得到 45 张训练集零件母图。然后,模拟工业环境拍摄 33 种背景图片作为背景母图。最后,拍摄 6 张航空发动机油路密封管件图片,在进

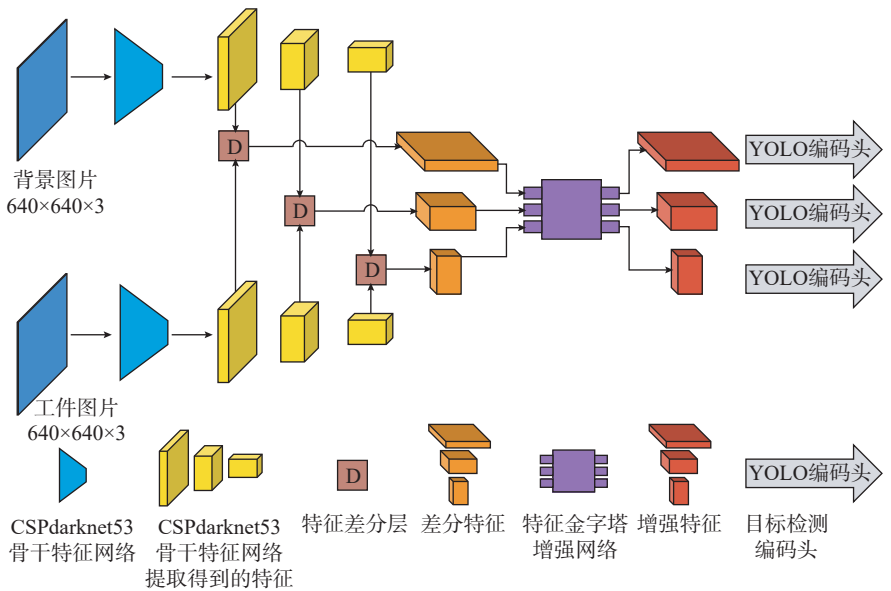


图 4 YOLO-Siamese 整体结构

Fig.4 Overall structure of YOLO-Siamese

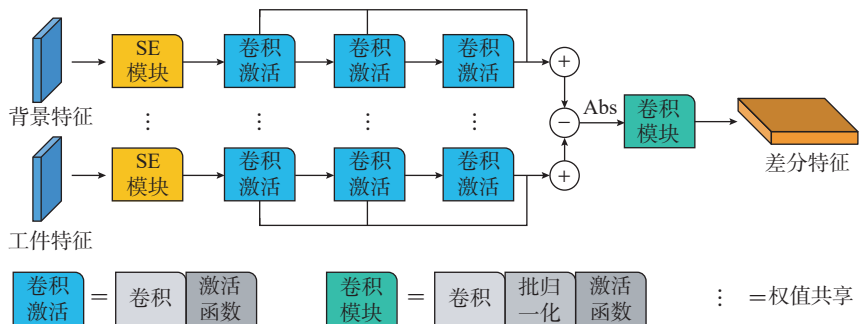


图 5 ConvDiff 模块

Fig.5 ConvDiff module

行抠图处理后作为验证母图。其中,航空发动机油路密封管件图片全程不参与模型训练,只用于对算法进行最终验证。

(2) 数据集生成。

获得原始母图后,还需对训练集进行数据增强,防止网络过拟合工件母图的特征。采用随机裁剪(范围0.5~1.0)、缩放(比例范围0.5~1.5、旋转(0~360°)、色域变换(色彩抖动系数0.2)等方式对原始母图进行扩增,每种增强方式使用的概率均为50%。最终使用40张原始训练母图生成1000张增强工件图片。

(3) 在线数据增强训练。

在训练过程中,采用在线数据集生成方式来提高模型的训练效果。具体步骤如下。

步骤1:随机读取2~4张工件母图,并进行随机缩放(比例范围0.7~1.3)、旋转(0~360°)、色域变换(色彩抖动系数0.2),生成工件图片;

步骤2:随机读取1张背景母图,并进行随机微小裁剪(比例范围为0~0.1)、旋转(-5°~5°)、色域变换(色彩抖动系数0.2),生成背景图片;

步骤3:将步骤1中生成的工件图片随机粘贴到步骤2中生成的背景图片上,生成带工件图片,并根据粘贴位置计算目标检测标签;

步骤4:将背景图片、带工件图片和目标检测标签送入YOLO-Siamese网络进行训练;

步骤5:不断重复步骤1~4,直至迭代次数到达目标值,完成模型训练。

1.2.3 加速推理

本研究算法由于采用了孪生网络,每次推理会分别对背景图片和工件图片进行运算,极大地增加了运算时间。因此本文采用背景特征预推理方法,在不降低模型精度的情况下,加速模型运算过程。背景预推理方法流程如图8所示,首先,对背景

图片进行特征提取并保存。之后直接使用提取得到的背景特征与工件图片提取得到的特征进行特征差分。该方法可以在背景未发生显著变化时,节省背景特征提取的时间,同时不会对算法精度造成影响。

2 结果与讨论

本节将以航空发动机油路密封管件为对象,对本文提出的变化检测网络进行性能验证,主要包括网络性能验证及变化检测可视化两个部分。表1为本研究用于训练及验证的计算平台的详细配置,使用1.2.2




图6 SE模块^[17]
Fig.6 SE module^[17]

节中生成的数据集进行模型训练及验证。

模型训练采用带动量的SGD优化器,动量值为0.937,权值衰减系数为0.0005。学习率下降方式为余弦下降,初始学习率为0.01,最小学习




图7 半监督训练流程
Fig.7 Semi-supervised training process

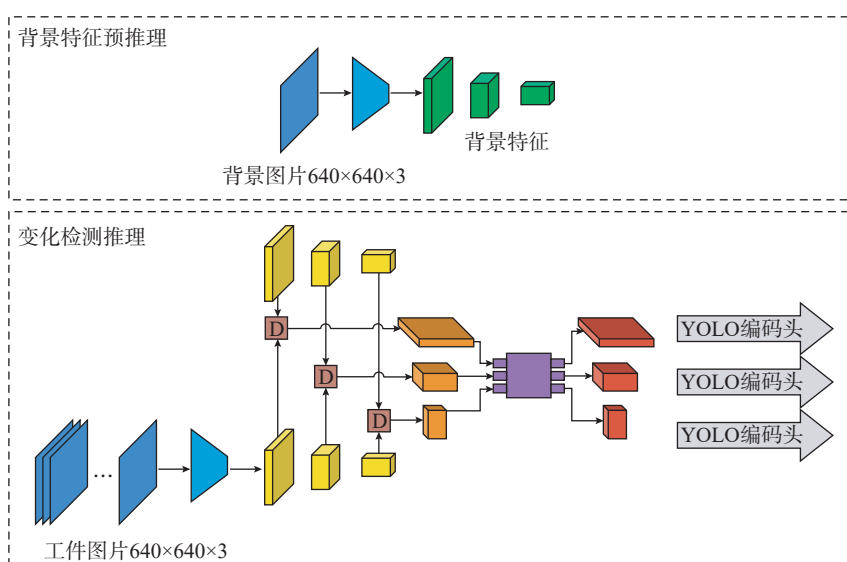


图8 背景预推理方法
Fig.8 Background pre-inference method

率为 0.0001。数据集及数据增强方式详见第 1.2.2 节。模型训练轮次数为 100,在本文计算平台的配置下训练时间约为 10 h (YOLOv5s)及 16 h (YOLO-Siamese)。

2.1 YOLO-Siamese 变化检测网络验证结果

精度值 (AP) 是目标检测算法中最常用的评价指标,其代表的物理意义为在某一交并比阈值 (IOU) 下,绘制的准确率-召回率曲线 (PR 曲线) 与坐标轴围成的面积。精度值越高则表明算法效果越好,交并比阈值越高则代表算法判定越严格。准确率和召回率计算方法为

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (3)$$

$$\text{Recall} = \frac{\text{TP}}{\text{TP} + \text{TN}} \quad (4)$$

式中, TP 为被预测正确的正样本数目; FP 为被预测错误的负样本数目; TN 为被预测正确的负样本数目。

采用消融试验法,对 YOLOv5s、YOLO-Siamese (Abs)、YOLO-Siamese (ConvDiff)、YOLO-Siamese (ConvDiff + SE) 及 YOLO-Siamese (ConvDiff + SE + 背景预推理) 分别进行训练及验证。其中, YOLO-Siamese (Abs) 是指采用原始 Siamese 网络的特征差分层,只使用一个绝对距离函数来计算差分特征的 YOLO-Siamese 版本; YOLO-Siamese (ConvDiff) 是指采用不带 SE 模块

的 ConvDiff 模块作为特征差分模块; YOLO-Siamese (ConvDiff + SE) 则采用带 SE 模块的 ConvDiff 模块作为特征差分模块。训练及验证数据集为第 1.2.2 节中生成的数据集。性能指标包括 IOU 设置为 0.5 时的平均精度值 AP@0.5 和 IOU 从 0.5 逐步增加到 0.95 时的平均精度值 AP@0.5:0.95。

各模型性能曲线如图 9 所示。本文提出的 YOLO-Siamese (ConvDiff+SE) 在各 IOU 下都具有最高的精度值,验证了所提出的网络结构的有效性。验证结果表明,采用 ConvDiff 模块的精度值高于采用绝对值差分 (Abs) 模块的精度值,验证了所提出的 ConvDiff 结构可以提升特征差分模块的性能。并且,在 ConvDiff 模块中引入 SE 模块后,模型性能进一步得到了提升。

4 个检测模型的模型大小、检测

精度、推理时间如表 2 所示。原始 YOLOv5s 的推理时间为 11.61 ms,无法进行变化检测。只采用原始绝对值差分的 YOLO-Siamese 变化检测网络的 AP@0.5 为 98.4%, AP@0.5:0.95 为 76.8%,具有一定的变化检测效果,网络的推理时间为 15.82 ms。采用不带注意力机制的 ConvDiff 模块的 YOLO-Siamese 变化检测网络 AP@0.5 为 99.3%, AP@0.5:0.95 为 86.2%,推理时间为 19.37 ms,模型的 AP@0.5:0.95 提升了 12.2%,但运算时间也增加了 3.55 ms。采用本研究开发的带注意力卷积差分模块 (ConvDiff + SE) 的 YOLO-Siamese 变化检测网络 AP@0.5 为 99.3%, AP@0.5:0.95 为 89.6%,模型精度得到了进一步提升,但是网络的推理时间也达到了 20.45 ms。最后,在引入背景特征预推理方法后,本研究算法的推理时间降低了 4.32 ms,达到

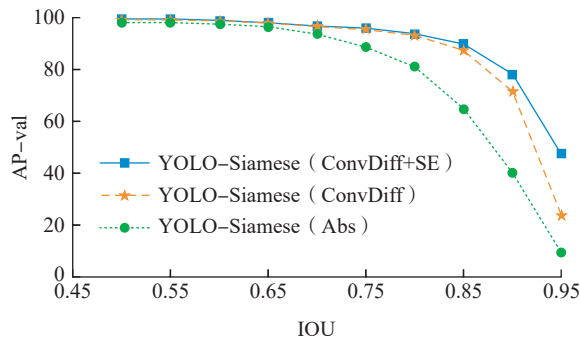


图 9 模型性能曲线

Fig.9 Model performance curves

表 1 计算平台配置

Table 1 Computer configuration

名称	配置
CPU	Intel Core i7-11700K@3.60 GHz
GPU	RTX 3060 (12 G)
GPU 加速库	Cuda11.1、Cudnn8.0
操作系统	Win10
编程环境	Python3.8.5
深度学习框架	Pytorch1.8.0

表 2 检测模型验证结果

Table 2 Validation results of detection models

检测模型	模型大小 /MB	AP@0.5/%	AP@0.5:0.95/%	推理时间 /ms
YOLOv5s	27.64	—	—	11.61
YOLO-Siamese (Abs)	27.64	98.4	76.8	15.82
YOLO-Siamese (ConvDiff)	38.10	99.3	86.2	19.37
YOLO-Siamese (ConvDiff + SE)	38.27	99.3	89.6	20.45
YOLO-Siamese (ConvDiff + SE + 背景预推理)	38.27	99.3	89.6	16.13

16.13 ms, 相比于 YOLO-Siamese (Abs) 模型的推理时间只增加了 2%, 模型精度 AP@0.5:0.95 提升了 16.7%。

2.2 变化检测网络推理可视化

为了对变化检测网络性能进行探究, 使用热力图对模型检测过程进行可视化。在热力图中, 网络推理过程中对结果贡献大的区域使用红色标记, 没有贡献或贡献较小的区域使用蓝色标记^[18]。图 10 为变化检测网络对包含航发管件的推理及热力图可视化结果, 可以看到本研究算法非常精准地检测到了变化区域, 实现了航发管件的定位, 该结果证明了本研究设计的变化检测网络的有效性。

3 结论

(1) 结合 Siamese 和 YOLO 目标检测网络提出了 YOLO-Siamese 变化检测网络, 并在该网络中引入了本文自主设计的 ConvDiff 模块作为特征差分层。训练得到的模型 AP@0.5 达到 99.3%, AP@0.5:0.95 达到 89.6%, 证明本文提出的变化检测网络具有较高的检测精度。

(2) 提出了一种基于半监督的模型训练方法。该方法可以基于预先提取好的原始母图自动生成训练集和标签集, 不需要使用目标数据集, 也不需要人工标注便可完成模型的训练。

(3) 提出了背景预推理方法对模型推理过程进行加速。验证结果表明, 背景预推理方法可以在不损失任何精度的情况下, 节省 4.32 ms 的背景图片特征提取时间, 提升了 21.12% 孪生网络计算速度。

参考文献

- [1] 韩君, 王菲. 新发展阶段中国装备制造业智能制造发展测度[J]. 财经理论, 2022(4): 74-86.
- [2] 田宗军, 顾冬冬, 沈理达, 等. 激光增材制造技术在航空航天领域的应用与发展[J]. 航空制造技术, 2015, 58(11): 38-42.
- [3] TIAN Zongjun, GU Dongdong, SHEN Lida, et al. Application and development of

laser additive manufacturing technology in aeronautics and astronautics[J]. Aeronautical Manufacturing Technology, 2015, 58(11): 38-42.

[3] 张辉, 宋雅男, 王耀南, 等. 钢轨缺陷无损检测与评估技术综述[J]. 仪器仪表学报, 2019, 40(2): 11-25.

ZHANG Hui, SONG Yanan, WANG Yaonan, et al. Review of rail defect non-destructive testing and evaluation[J]. Chinese Journal of Scientific Instrument, 2019, 40(2): 11-25.

[4] 李光耀, 刘泉, 赖铭, 等. 基于自适应视觉检测的磁脉冲接管件接头深度智能检测算法研究[J]. 航空制造技术, 2022, 65(7): 54-63.

LI Guangyao, LIU Xiao, LAI Ming, et al. Research on intelligent crimping depth detection algorithm for magnetic pulse crimping pipe based on adaptive vision[J]. Aeronautical Manufacturing Technology, 2022, 65(7): 54-63.

[5] 夏群峰, 彭勇刚. 基于视觉的机器人抓取系统应用研究综述[J]. 机电工程, 2014, 31(6): 697-701, 710.

XIA Qunfeng, PENG Yonggang. Review on application research of robots scraping system based on visual[J]. Journal of Mechanical & Electrical Engineering, 2014, 31(6): 697-701, 710.

[6] 魏思铭. 基于机器视觉的轴承圆柱滚子表面缺陷检测系统研究[D]. 哈尔滨: 哈尔滨理工大学, 2022.

WEI Siming. Research on surface defect detection system of bearing cylindrical roller based on machine vision[D]. Harbin: Harbin University of Science and Technology, 2022.

[7] SUN W F, CAO X C, CHEN B Q, et al. A two-stage vision-based method for measuring the key parameters of ball screws[J]. Precision Engineering, 2020, 66: 76-86.

[8] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]// Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: NIPS Foundation, 2017: 6000-6010.

[9] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks: IEEE Transactions on Pattern Analysis and Machine Intelligence[J]. IEEE, 2017, 39(6): 1137-1149.

[10] CARION N, MASSA F, SYNNAEVE




图 10 变化检测可视化
Fig.10 Change detection visualization

G, et al. End-to-end object detection with transformers[C]//Computer Vision—ECCV 2020. Cham: Springer International Publishing, 2020: 213–229.

[11] CHOPRA S, HADSELL R, LECUN Y. Learning a similarity metric discriminatively, with application to face verification[C]//2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. San Diego: IEEE, 2005: 539–546.

[12] BANDARA W G C, PATEL V M. A transformer-based Siamese network for change detection[C]//IGARSS 2022—2022 IEEE International Geoscience and Remote Sensing Symposium. Kuala Lumpur: IEEE, 2022: 207–210.

[13] CHEN P, HONG D F, CHEN Z.

FCCDN: Feature constraint network for VHR image change detection[J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2022, 187: 101–119.

[14] REDMON J, DIVVALAS, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016: 779–788.

[15] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu: IEEE, 2017: 6517–6525.

[16] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[J]. Computer Vision

and Pattern Recognition, 2020: 10934[2020–04–23]. <https://arxiv.org/abs/2004.10934>.

[17] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 7132–7141.

[18] ZHOU B L, KHOSLA A, LAPEDRIZA A, et al. Learning deep features for discriminative localization[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas: IEEE, 2016: 2921–2929.

通讯作者: 李光耀, 教授, 博士生导师, 研究方向为轻量化制造和智能制造。

Research on Robust Visual Localization Algorithm for Aero-Engine Oil Sealing Pipe Fitting

CUI Junjia¹, LIU Xiao¹, LAI Ming¹, WANG Shaolu¹, JIANG Hao¹, LI Guangyao²

(1. State Key Laboratory of Advanced Design and Manufacturing for Vehicle Body, Hunan University, Changsha 410082, China;
2. Shenzhen Automotive Research Institute (Shenzhen Research Institute of National Engineering Laboratory for Electric Vehicles), Beijing Institute of Technology, Shenzhen 518118, China)

[ABSTRACT] The wide variety of components and high degree of customization used in the aerospace industry make it difficult to develop positioning fixtures. Visual localization technology is a key part of intelligent manufacturing, which is based on machine vision to determine the position of the workpiece. It does not require a positioning fixture, and can be widely used in a wide variety of work conditions. However, the generality of common visual localization algorithms is not very high. Algorithms are usually only used to detect specific objects. In this paper, a novel visual localization algorithm based on YOLOv5s object detection network and Siamese network (YOLO–Siamese change detection network) was proposed. The network introduced the ConvDiff (Convolutional Difference) module to improve the effect of the feature extraction in the change detection network, and a semi-supervised learning method was used to train the model. Experiments show that without using the target artifact dataset, the algorithm reached 99.3% of the AP@0.5, 89.6% AP@0.5:0.95 on the validation set, and the single frame inference time was 16.13 ms. Without requiring target artifact data, the proposed algorithm achieved high localization accuracy and fast operation speed, thus improving the robustness and versatility of visual localization algorithms.

Keywords: Change detection network; Visual localization; Machine vision; YOLO; Siamese; Twin network

(责编 晓月)