

DOI: 10.7672/sjgs2024210006

基于无人机与深度学习的少样本混凝土 表面裂缝检测方法*

张慧乐¹, 杨发¹, 吴丹¹, 张淳杰²

(1. 中国京冶工程技术有限公司, 北京 100088; 2. 北京交通大学, 北京 100089)

[摘要] 混凝土表面裂缝检测是混凝土建筑安全评估和风险预警的重要手段。传统人工检测方法工作量大,且需考虑复杂环境下影响人身安全等因素。基于无人机的裂缝检测方法得到了应用,但当受不确定因素影响时,无人机无法采集足够的训练样本,限制了其检测性能。为此,基于无人机与深度学习,提出少样本条件下混凝土表面裂缝检测方法,采用主流深度学习网络 Faster-RCNN 和 YOLOX,利用 WBF 算法将检测结果进行融合,有效弥补了像素级标签信息较少导致的检测性能下降。在少样本裂缝图像库及户外场地进行了试验测试,试验结果表明,在少样本条件下基于无人机与深度学习的裂缝检测方法性能得到有效提升,对裂缝检测的准确率达到 58.67%。

[关键词] 混凝土;裂缝;检测;无人机;深度学习

[中图分类号] TU528

[文献标识码] A

[文章编号] 2097-0897(2024)21-0006-05

Few-sample Concrete Surface Crack Detection Method Based on UAV and Deep Learning

ZHANG Huile¹, YANG Fa¹, WU Dan¹, ZHANG Chunjie²

(1. China Jingye Engineering Co., Ltd., Beijing 100088, China;

2. Beijing Jiaotong University, Beijing 100089, China)

Abstract: Concrete surface crack detection is an important means of concrete building safety assessment and risk early warning. The traditional manual detection method has a large workload, and it is necessary to consider factors such as personal safety in complex environments. The crack detection method based on UAV has been applied, but when affected by uncertain factors, UAV cannot collect enough training samples, which limits their detection performance. Therefore, based on UAV and deep learning, a crack detection method for concrete surface under the condition of few samples is proposed. The mainstream deep networks Faster-RCNN and YOLOX are used, and the detection results are fused by WBF algorithm, which effectively alleviates the detection performance degradation caused by less pixel-level label information. Experimental tests were carried out in a few sample crack image library and outdoor sites. The test results show that the performance of the crack detection method based on UAV and deep learning is effectively improved under the condition of few samples, and the accuracy of crack detection is 58.67%.

Keywords: concrete; cracks; detection; unmanned air vehicle (UAV); deep learning

0 引言

混凝土建筑在我国基础设施建设中得到了广泛应用,由于受施工、维护、老化等多重因素影响,混凝土建筑表面会产生裂缝,这些表面裂缝往往是

更严重的内部裂损起因或前兆。因此,对混凝土表面裂缝进行检测是混凝土建筑安全评估及风险预警的重要手段。对于传统的人工巡检方式,一方面由于工作量大,效率较低,且易受主观经验影响,无法快速准确完成表面裂缝检测工作;另一方面由于混凝土建筑分布环境较复杂,巡检过程中需要考虑诸多影响人身安全的因素,进一步限制了人工作业

* 国家自然科学基金(62072026)

[作者简介] 张慧乐,高级工程师,E-mail:zhanghuile@cribe.com

[收稿日期] 2024-07-02

的高效性。因此,对混凝土建筑表面裂缝进行快速、准确、安全、高效地检测是结构安全维护重难点^[1-2]。

无人机作为常见的小型飞行器,具有快速灵活、对不同目标建筑物可达性较高的特点。随着飞控及导航系统的不断发展,其对复杂环境的适应性大大提高,这为使用无人机进行工程检测提供了坚实的保障。随着深度学习技术的快速发展,其在图像分类、目标检测、语义分割等任务上的速度与准确性不断提高^[3-7],甚至在某些任务上超越了人类水平。因此,近年来,基于无人机和深度学习的混凝土表面裂缝检测方法得到了广泛应用^[8-10]。利用无人机携带摄像机,在符合相关安全规定的前提下,对目标建筑物进行贴近飞行,在有效悬停状态下采集高清图像。利用基于深度学习的目标检测及语义分割技术,对图像中包含的裂缝进行自动识别定位。作为图像信息的采集平台,无人机常受诸多不可抗力因素的限制,无法采集足够多的图像样本供深度网络进行学习,如受恶劣天气影响导致无人机无法飞行或飞行时长有限,也可能因安全规定等导致无人机无法贴近飞行到目标区域。即使不考虑上述因素的影响,无人机在悬停状态下采集的图像质量也会受拍摄环境的影响,如逆光、光线不足及机体轻微抖动造成运动模糊,或雨雪天气导致图像出现雨化、雾化等噪声现象,在少样本条件下最终会影响基于深度网络的目标检测、语义分割算法性能及其对复杂环境的鲁棒性^[11-13]。

针对上述问题,本文提出少样本条件下混凝土表面裂缝检测方法,训练 2 种主流目标检测网络 Faster-RCNN, YOLOX, 通过对比分析其性能表现,提出有效的融合算法,将不同网络学习到的特征进行有效融合,进一步提高目标检测算法的性能。在少样本裂缝图像库进行了试验测试,结果表明在少样本条件下,通过数据增强及各环节方法的互补融合,有效提升了基于深度学习的裂缝检测方法性能。

1 少样本条件下基于深度学习的裂缝检测方法

1.1 少样本裂缝图像库

利用网络资源及已收集到的 200 张不同大小、形状的混凝土表面裂缝图像,采用双线性插值法将其统一缩放至 256 像素×256 像素,方便后续网络训练。这些裂缝图像包含多种不同混凝土构件,如结构墙体、混凝土路面,总体背景较复杂,且包含如阴影等环境因素的干扰。使用 LabelImg, Labelme 软件对裂缝图像进行人工标注,每张图像包含的类别标签与位置标签供裂缝检测网络进行学习测试,像素

级的语义标签供裂缝分割网络进行学习测试。按照 4 : 1 的比例划分训练集和测试集,建立了完整带标签信息的少样本裂缝图像库。

1.2 裂缝检测

本文使用 Faster-RCNN, YOLOX 目标检测网络对裂缝进行识别定位^[14-17]。在训练阶段,对 2 种网络分别进行训练;在测试阶段,使用加权框融合 (weighted boxes fusion, WBF) 算法^[18],对 2 种网络产生的目标候选框结果进行有效融合,进一步提升其定位精度,整体架构及流程如图 1 所示。

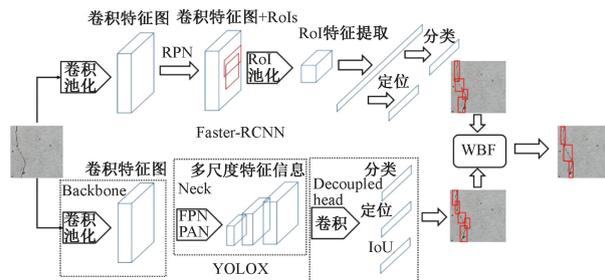


图 1 裂缝检测整体架构与流程

Fig. 1 Overall structure and process of crack detection

Faster-RCNN 为经典的两阶段目标检测算法,其在 Fast-RCNN 基础上加入了区域生成网络 RPN (region proposal network),代替原有的选择性搜索方法,进一步提高了定位区域的搜索效率。通过卷积神经网络提取图像特征,包含卷积、池化、激活等操作,本研究选取 Resnet 作为主干网络提取图像高层视觉特征。将得到的特征图通过 RPN 网络生成候选框,RPN 网络通过全连接层进行分类与回归,判断锚点框中目标是否存在,将分类为正例的锚点框定位感兴趣区域 RoI (region of interest)。通过 RoI 池化层将锚点框对应的坐标信息从卷积特征图中分离,生成对应的 RoI 特征图。通过全连接层进行分类及回归,分别给出对应的类别信息及位置信息。

相比于 Fast-RCNN 的选择性搜索策略,RPN 网络可提前判断锚点框中是否有目标,并修正其坐标信息,在准确性及速度方面均有所提升。

YOLO 系列算法作为最具代表性的单阶段目标检测算法^[19],其速度与精度均达到了较高水平,其中 YOLOX 是目前较为新颖的算法之一,主要包含三部分,即主干网络 (Backbone)、特征利用 (Neck) 和解耦的检测头 (Decoupled head)。主干网络用于提取图像特征信息,并送入 Neck 进行特征融合与拼接。Neck 包含特征金字塔网络 FPN (feature pyramid network) 及路径聚合网络 PAN (path

aggregation network)。FPN 采用自顶向下的结构,对高层特征信息通过上采样的方式进行传递融合,得到用于预测的特征图;PAN 用于将不同网络层数之间的特征信息进行高效传递。基于经过 Neck 得到的多尺度特征信息,经过解耦头将特征信息根据任务的不同分为分类和回归部分。分类部分用于输出对应的类别标签,回归部分用于输出预测框坐标信息及根据 IoU (intersection over union) 判断预测框中是否有目标。采用解耦头不仅可以提升模型精度,还可以在训练时增加网络收敛速度。

对于单个目标检测模型来说,非极大值抑制 (non-maximum suppression, NMS) 是常用的后处理手段。通过 NMS 筛选高于 IoU 阈值的检测框,从而剔除冗余检测框。但对于少样本条件下的目标检测任务来说,单一的目标检测网络性能往往较差,需要通过融合多种目标检测网络提升最终的检测精度。相比于 NMS 对预测框的简单剔除操作,WBF 算法可有效利用多个模型产生的多个预测框,通过置信度排序及融合算法,生成最终的平均预测框。

WBF 算法应用不同框的置信度作为融合框权重。融合框在形状与位置上更偏向于权重大的一方。在少样本条件下,应用 WBF 算法将 Faster-RCNN 与 YOLOX 检测结果进行融合,相比于采用 NMS 算法或单一目标检测网络,其性能均有所提升。

2 少样本裂缝图像库试验

2.1 试验设置

利用建立的少样本裂缝图像数据库测试目标检测网络性能。首先将少样本图像数据库按照 4 : 1 的比例划分训练集与验证集,对使用的深度网络分别进行训练和测试。在裂缝检测部分,使用 WBF 算法将 Faster-RCNN 与 YOLOX 检测结果进行融合,并测试其性能指标。

本试验采用 python3.7 作为程序语言,使用的深度学习框架为 pytorch-1.8.2,网络模型训练使用的服务器配置为 Inter Xeon Gold 处理器,NVIDIA GeForce RTX3090 显卡。不同网络主干模型及训练参数设置如表 1 所示,迭代次数设置满足网络收敛要求。

表 1 模型训练参数设置

Table 1 Model training parameter setting

模型	主干网络	优化器	迭代次数/次
Faster-RCNN	Resnet50	SGD	6 000
YOLOX	Darknet53	Adam	1 200
DeepLabv3+	Xception	Adam	2 000
U-net	VGG16	Adam	3 200

2.2 裂缝检测

模型的性能分析通常依赖于混淆矩阵中的 4 个基本元素,即真阳性 (TP)、假阳性 (FP)、真阴性 (TN) 和假阴性 (FN)。真阳性指模型预测为正类 (阳性),且实际标签也为正类,即模型正确地识别出了正样本,反映了模型正确识别裂缝的能力。真阴性指模型预测为负类 (阴性),且实际标签也为负类,即模型正确地识别出了负样本,代表模型正确排除非裂缝区域的准确性。假阳性指模型预测为正类,但实际标签为负类,即模型错误地将负样本预测为正样本,代表模型误将非裂缝分类为裂缝的情况。假阴性指模型预测为负类,但实际标签为正类,即模型错误地将正样本预测为负样本,代表模型未能检测到实际裂缝的情况。裂缝检测使用的评价指标主要有精度 P 、召回率 R 和 F_1 分数 (精度与召回率的调和平均,确保了当精度和召回率同时较高时,模型预测结果较准确),其定义如下:

$$P = \frac{TP}{TP + FP} \quad (1)$$

$$R = \frac{TP}{TP + FN} \quad (2)$$

$$F_1 = \frac{2PR}{P + R} \quad (3)$$

F_1 分数作为衡量模型性能的重要指标,尤其在处理类别分布不均的数据集时显得尤为关键,通过结合精度与召回率,提供了单一的度量标准,能够全面评价模型的效能。不同模型性能对比如表 2 所示,IoU 阈值设置为 0.5。

表 2 裂缝检测网络性能对比

Table 2 Performance comparison of crack detection network

深度网络	精度 P /%	召回率 R /%	F_1 分数/%
Faster-RCNN	38.17	55.46	45.22
YOLOX	61.26	37.31	46.38
WBF 融合	58.67	46.23	51.71

由表 2 可知,Faster-RCNN 在召回率上表现最好,YOLOX 在精度上表现最好。采用 WBF 算法将 2 种网络检测结果进行融合后,虽降低了精度与召回率,但得到的 F_1 分数最高,说明经过 WBF 融合后的网络综合性能更强。

2.3 融合试验

在裂缝检测任务中,分别采用 WBF 算法、传统 NMS 算法及二者叠加对不同模型检测结果进行融合试验,以提高模型整体性能,结果如表 3 所示。

表 3 裂缝检测融合试验结果

Table 3 Experimental results of crack detection ablation

网络模型		融合方法			F_1 分数/%
Faster-RCNN	YOLOX	WBF	NMS	WBF 与 NMS 叠加	
采用	不采用	不采用	不采用	不采用	45.22
不采用	采用	不采用	不采用	不采用	46.38
采用	采用	采用	不采用	不采用	51.71
采用	采用	不采用	采用	不采用	47.17
采用	采用	不采用	不采用	采用	43.23

由表 3 可知,相比于 NMS 简单剔除预测框或直接不同模型预测框进行叠加的方法,利用不同网络预测结果的置信度得分对检测框进行加权融合(利用 WBF 算法进行融合)得到的模型综合性能最好。

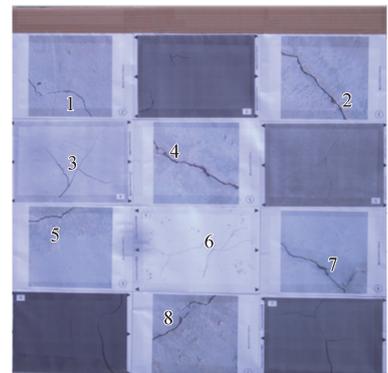
3 裂缝检测结果

依据上述方法制作了 2 组靶标用于仿真测试(见图 2),均可用于验证裂缝检测性能。靶标 1 图像来源为少样本裂缝图像库测试集和手绘不同宽度及形态裂缝,靶标 2 图像来源为使用 AutoCAD 软件绘制和手绘不同宽度及形态裂缝。

使用无人机搭载 16mm 定焦镜头,在距靶标 4m 处进行悬停拍摄,采集测试样张,并将测试图像输入基于少样本的裂缝图像检测系统,得到检测结果如图 3,4 所示,图中图像自上而下依次为原图、初步检测结果和最终结果。由图 3,4 可知,本文所提方法可有效检测裂缝目标,且对于不同宽度及形态的裂缝检测具有较高的鲁棒性。由检测结果可知,裂缝检测准确率达 58.67%。

4 结语

本文提出了少样本条件下基于无人机和深度学习的混凝土表面裂缝检测方法。通过少样本裂缝图像库及户外测试,对试验结果进行定量分析,验证所提方法的有效性。未来的研究中将继续探索更深层次的网络结构和优化策略,以进一步提升



a 靶标1



b 靶标2

图 2 测试靶标

Fig. 2 Test targets

模型检测性能和效率。在性能提升方面,设计更高

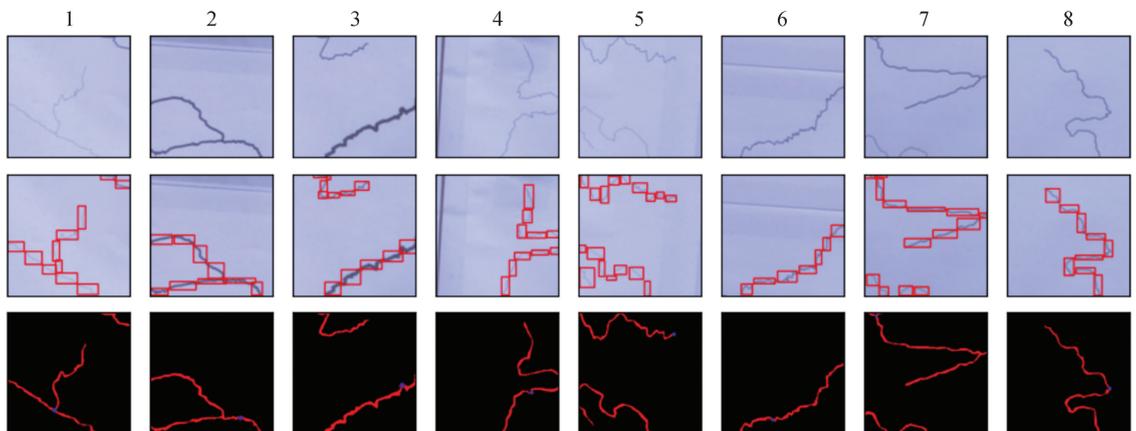


图 3 靶标 1 裂缝检测结果

Fig. 3 Crack detection results of target 1

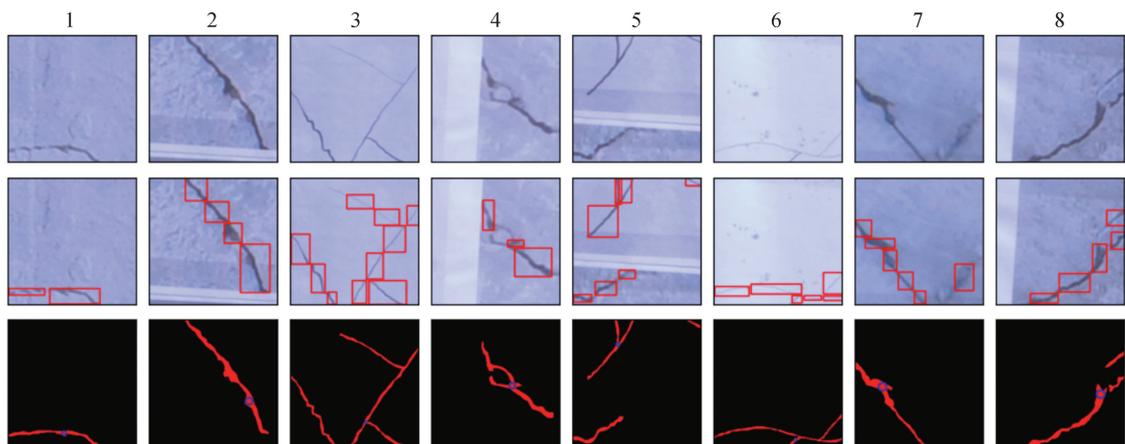


图 4 靶标 2 裂缝检测结果

Fig. 4 Crack detection results of target 2

效、准确的裂缝检测模型,通过将裂缝产生机理融入模型设计中,以期获得更好的裂缝检测、分割效果;通过领域自适应技术提高模型在多变环境中的泛化能力,进一步优化用户界面和交互设计,以满足更广泛的需求;通过引入更多样化的数据增强方法和考虑不同尺度的裂缝特征,提高模型对不同类型和尺寸裂缝识别能力。在样本获取方面,将现有大语言模型生成能力和裂缝检测任务相结合,尝试自动生成裂缝样本,以达到扩展现有数据集、提升模型训练效率的目的。

参考文献:

- [1] 方恩权,王耀东,袁敏正,等. 地铁隧道表面裂缝智能视觉采集系统[J]. 铁道科学与工程学报, 2019, 16(4): 1074-1080.
FANG E Q, WANG Y D, YUAN M Z, et al. An intelligent visual acquisition system for surface cracks of subway tunnels [J]. Journal of railway science and engineering, 2019, 16(4): 1074-1080.
- [2] 王保宪,白少雄,赵维刚. 基于特征增强学习的路面裂缝病害视觉检测方法[J]. 铁道科学与工程学报, 2022, 19(7): 1927-1935.
WANG B X, BAI S X, ZHAO W G. Visual detection method of pavement crack disease based on feature enhancement learning [J]. Journal of railway science and engineering, 2022, 19(7): 1927-1935.
- [3] 陈辉,张甜,陈润斌. 基于轻量级卷积 Transformer 的图像分类方法及在遥感图像分类中的应用[J]. 电子与信息学报, 2022, 44:1-9.
CHEN H, ZHANG T, CHEN R B. Image classification method based on lightweight convolution transformer and its application in remote sensing image classification[J]. Journal of electronics & information technology, 2022, 44:1-9.
- [4] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [C]// IEEE Conference on Computer Vision and Pattern Recognition, 2016.

- [5] 赵荣欣,王枫,吴华勇,等. 桥梁病害自动检测研究综述[J]. 施工技术, 2023, 52(9): 1-6.
ZHAO R X, WANG F, WU H Y, et al. Research review of automatic inspection of bridge defects [J]. Construction technology, 2023, 52(9): 1-6.
- [6] 张慧,王坤峰,王飞跃. 深度学习在目标视觉检测中的应用进展与展望[J]. 自动化学报, 2017, 43(8): 1289-1305.
ZHANG H, WANG K F, WANG F Y. Application progress and prospect of depth learning in object vision detection [J]. Acta automatica sinica, 2017, 43(8): 1289-1305.
- [7] 田萱,王亮,丁琪. 基于深度学习的图像语义分割方法综述[J]. 软件学报, 2019, 30(2): 440-468.
TIAN X, WANG L, DING Q. A survey of image semantic segmentation methods based on depth learning [J]. Journal of software, 2019, 30(2): 440-468.
- [8] 徐昊,彭雪村,卢志芳. 基于四旋翼无人机的桥梁裂缝检测系统设计[J]. 水利水运工程学报, 2018(1):102-110.
XU H, PENG X C, LU Z F. Design of bridge crack detection system based on four rotor UAV [J]. Hydro-science and engineering, 2018(1):102-110.
- [9] 陶晓力,武建,杨坤. 基于无人机视觉的桥梁裂缝检测[J]. 计算机技术与发展, 2018, 28(3): 174-177.
TAO X L, WU J, YANG K. Bridge crack detection based on UAV vision [J]. Computer technology and development, 2018, 28(3):174-177.
- [10] 丁威,俞珂,舒江鹏. 基于深度学习和无人机的混凝土结构裂缝检测方法[J]. 土木工程学报, 2021, 54(S1): 1-12.
DING W, YU K, SHU J P. Concrete structure crack detection method based on depth learning and UAV [J]. China civil engineering journal, 2021, 54(S1): 1-12.
- [11] 李新叶,龙慎鹏,朱婧. 基于深度神经网络的少样本学习综述[J]. 计算机应用研究, 2020, 37(8): 2241-2247.
LI X Y, LONG S P, ZHU J. Overview of deep neural network based small sample learning [J]. Application research of computers, 2020, 37(8): 2241-2247.

(下转第 16 页)

更多数据后进一步研究。

参考文献:

- [1] 翟雷,李文涛,王永生,等. 大跨度钢结构空间张弦桁架施工全过程监测与分析[J]. 施工技术(中英文), 2022, 51(14): 77-82.
ZHAI L, LI W T, WANG Y S, et al. Monitoring and analysis of the whole construction process of long-span steel structure spatial tensioned truss[J]. Construction technology, 2022, 51(14): 77-82.
- [2] 符湛,赵东拂,刘育民. 钢结构厂房火灾后安全性鉴定[J]. 施工技术(中英文), 2024, 53(9): 79-83.
FU Y, ZHAO D F, LIU Y M. Safety evaluation of steel structure plant after fire [J]. Construction technology, 2024, 53(9): 79-83.
- [3] 汤东婴,魏晓斌,孙正华,等. 空间钢桁架结构卸载施工模拟及监测技术应用研究[J]. 施工技术(中英文), 2023, 52(14): 17-22.
TANG D Y, WEI X B, SUN Z H, et al. Research on application of unloading construction simulation and monitoring technology for space steel truss structure[J]. Construction technology, 2023, 52(14): 17-22.
- [4] 卢树杰,陈庆诚,文祥,等. 基于无人机的钢结构锈蚀视觉检测[J]. 工业控制计算机, 2019, 32(7): 79-81, 87.
LU S J, CAI Q C, WANG X, et al. Visual inspection of steel structure corrosion based on UAV [J]. Industrial control computer, 2019, 32(7): 79-81, 87.
- [5] WANG C Y, WANG N, HAO S C, et al. Design of a new vision-based method for the bolts looseness detection in flange connections [J]. IEEE transactions on industrial electronics, 2020(2): 1366-1375.
- [6] ZHANG Y, SUN X W, LOH K J, et al. Autonomous bolt loosening detection using deep learning [J]. Structural health monitoring, 2020(19): 105-122.
- [7] 胡欣,周运强,肖剑,等. 基于改进 YOLOv5 的螺纹钢表面缺陷检测[J]. 图学学报, 2023, 44(3): 427-437.
HU X, ZHOU Y Q, XIAO J, et al. Surface defect detection of threaded steel based on improved YOLOv5 [J]. Journal of graphics, 2023, 44(3): 427-437.
- [8] CHA Y J, CHOI W, SUH S M, et al. Autonomous structural visual inspection using region-based deep learning for detecting multiple damage types [J]. Computer-aided civil and infrastructure engineering, 2018, 33(4): 731-747.
- [9] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. IEEE transactions on pattern analysis and machine intelligence, 2017, 39(6): 1137-1149.
- [10] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C]//IEEE Conference on Computer Vision and Pattern Recognition, 2016.
- [11] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE transactions on pattern analysis and machine intelligence, 2015, 37(9): 1904-1916.
- [12] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression [C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2020.
- [13] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks [J]. IEEE transactions on pattern analysis and machine intelligence, 2020, 42(8): 2011-2023.
- [14] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [C]//European conference on computer vision, 2018.
- [15] LIU Y C, SHAO Z R, TENG Y Y, et al. NAM: Normalization-based attention module [C]//35th Conference on Neural Information Processing Systems, 2021.
- (上接第 10 页)
- [12] 郑欣悦. 基于深度学习的少样本图像分类方法[D]. 北京: 中国科学院大学(中国科学院国家空间科学中心), 2019.
ZHENG X Y. A few sample image classification method based on deep learning[D]. Beijing: University of Chinese Academy of Sciences (National Space Science Center, CAS), 2019.
- [13] 卢依宏,蔡坚勇,郑华,等. 基于深度学习的少样本研究综述[J]. 电讯技术, 2021, 61(1): 125-130.
LU Y H, CAI J Y, ZHENG H, et al. A review of small sample research based on deep learning [J]. Telecommunications engineering, 2021, 61(1): 125-130.
- [14] 徐佳琦. 基于边缘提取与 VGG16 深度卷积神经网络的混凝土裂缝识别方法研究[J]. 施工技术, 2023, 52(9): 11-15.
XU J Q. Concrete crack recognition method based on edge extraction and VGG16 deep convolutional neural network [J]. Construction technology, 2023, 52(9): 11-15.
- [15] 高友文,周本君,胡晓飞. 基于数据增强的卷积神经网络图像识别研究[J]. 计算机技术与发展, 2018, 28(8): 62-65.
GAO Y W, ZHOU B J, HU X F. Research on convolutional neural network image recognition based on data enhancement[J]. Computer technology and development, 2018, 28(8): 62-65.
- [16] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks [J]. IEEE transactions on pattern analysis and machine intelligence, 2017, 39(6): 1137-1149.
- [17] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]//IEEE Conference on Computer Vision and Pattern Recognition, 2016.
- [18] ROMAN S, WEIMIN W, TATIANA G. Weighted boxes fusion: Ensembling boxes from different object detection models [J]. Image and vision computing, 2021, 107: 104117.
- [19] 陈志强,杨霞,陈小杰. YOLO 与 SAHI 模型在建筑外立面表面损伤检测中的协同应用[J]. 施工技术, 2022, 51(24): 114-119.
CHEN Z Q, YANG X, CHEN X J. Collaboration application of YOLO and SAHI models in the detection of apparent damage of building facades[J]. Construction technology, 2022, 51(24): 114-119.