

文章编号:1673-9469(2024)03-0067-07

DOI:10.3969/j.issn.1673-9469.2024.03.009

改进 YOLOv5 的沥青路面裂缝检测方法

王莉静,孙泽然,李志猛*,丰吉科

(天津城建大学 控制与机械工程学院,天津 300384)

摘要: 针对 YOLOv5 在裂缝图像目标检测中未能考虑到裂缝图像背景复杂,检测目标较小导致检测效果不佳和易出现误检漏检的问题,提出了一种改进 YOLOv5 的沥青路面裂缝检测方法。该算法首先将轻量级 Mobilenet v3 的网络作为 YOLOv5 的特征提取骨干网络,以降低模型复杂度并加快推理速度。同时,在网络预测端引入高效通道注意力机制,提升网络局部特征捕获和融合能力。最后,通过一个嵌入 Panet 模块来强化裂缝图像的多尺度特征表达能力,提高对小目标的检测效果。实验结果表明,相比于原始 YOLOv5 算法,改进后的 YOLOv5 进行沥青路面裂缝检测的平均精度提高了 5.6%,模型参数量降低了 86.3%,图像检测时间减少了 75.8%。

关键词: YOLOv5; 目标检测; 沥青路面; 裂缝检测

中图分类号:U416

文献标识码:A

Asphalt Pavement Crack Detection Method Based on Improved YOLOv5

WANG Lijing, SUN Zeran, LI Zhimeng*, FENG Jike

(School of Control and Mechanical Engineering, Tianjin Chengjian University, Tianjin 300384, China)

Abstract: A improved YOLOv5 asphalt pavement crack detection method is proposed to address the issues of complex crack image backgrounds, small detection targets, poor detection performance, and missed detections in YOLOv5 crack detection. Firstly, the lightweight Mobilenet v3 network, as the feature extraction network of YOLOv5, is used to reduce the complexity of the model and speed up reasoning. Secondly, an efficient channel attention mechanism (CBAM) is employed to enhance the network's ability to capture and fuse local features. Finally, an embedded Panet module is used to enhance the multi-scale feature expression ability of crack images and improve the detection performance of small targets. The experimental results show that compared to the original YOLOv5 algorithm, the improved YOLOv5 algorithm improves the mAP of asphalt pavement crack detection by 5.5%, reduces the number of model parameters by 86.3%, and reduces image detection time by 75.8%.

Key words: YOLOv5; object detection; asphalt pavement; crack detection

公路是交通运输领域的重要组成部分,多数公路路面通过将沥青材料与碎石、石屑、矿粉等混料按一定比例混合后进行铺设,从而提高了路面结构稳定性及其延展性。但是,受到天气变化和行驶压力等因素影响,沥青路面在使用一段时间后容易产生裂缝。如果不及时进行修复则易导致裂缝不断增加,进而对公路的结构稳定性产生影响,同时也给行车安全带来隐患^[1]。因此,对沥青路面裂缝进行及时的检测与识别具有极其重要的

意义^[2-3]。

近年来随着深度学习理论不断发展,国内外学者开始不断将其用于裂缝检测的研究^[4-8]。其中 YOLO 算法的基本原理是对输入原始图像采用直接回归的方法,在输出端输出目标位置及其类别。之后的 YOLO 系列算法在此基础上通过改进特征信息提取网络,扩展了检测对象种类,并提高了目标检测准确率和检测速度。Cui 等^[9]通过混凝土侵蚀试验建立了数据集,提出了一种改进

收稿日期:2023-06-09

基金项目:天津市自然科学基金资助项目(20YDTPJC00840);天津城建大学研究生教育教学改革与研究项目(重点项目)(JG-ZD-2205)

作者简介:王莉静(1974-),女,山西阳泉人,博士,副教授,研究领域为图像处理、智能诊断。

* 通信作者:李志猛(1987-),男,内蒙古赤峰人,博士,讲师,研究领域为智能制造、状态监测与故障诊断。

的 YOLO-v3 算法模型,通过修改模型的损失函数、激活函数及插入 CSP 模块,提高了模型的检测能力。Shao 等^[10]将 YOLOv5 的特征融合网络进行优化,提出自适应空间特征融合网络以获得更好的特征融合效果,模型在夜间遥感图像检测上取得了良好效果。Gong 等^[11]还将自注意力机制引入 YOLOv5 以解决小目标密集分布的问题,虽然增加了部分计算量,但取得了不错的检测效果。罗晖等^[12]基于 YOLOv4 模型,通过使用深度可分离卷积,改进损失函数的方法,解决了公路路面裂缝检测困难等问题。YOLOv5 作为 YOLOv4 的升级版,通过在数据增强、骨干网络、激活函数和损失函数方面的改进,从而使其目标检测速度和检测准确率得到有效提升。

然而,由于沥青路面裂缝与其路面背景特征的相似性极高,使用 YOLOv5 模型进行裂缝检测时易造成误检现象的发生。针对上述问题,本文以 YOLOv5 模型为基础,在模型骨干段引入轻量化 Mobilenet v3 模块和卷积注意力 (Convolutional Block Attention Module, CBAM) 机制,提升检测速度并实现模型轻量化,增强模型图像特征提取通道之间的特征响应,更大地关注目标的位置和类别。在模型输出端引入一个嵌入 Panet 模块的小

目标预测层,用于识别极小尺度的裂缝目标,提升模型的识别准确度。

1 YOLOv5 模型结构

YOLOv5 模型结构主要由输入端、骨干段、颈部段和输出端四部分组成,其结构如图 1 所示。

在输入端使用马赛克算法对输入图像进行数据增强,并将选定的 1 张图片和随机选择的 3 张图片进行缩放、叠加或拼接成一幅图片作为训练样本放入样本集,从而降低内存占用率,缩短训练时间。训练中,根据目标尺寸及其占比自动获取最适合的锚框尺寸,并保证输入图像的尺寸统一。在骨干段采用聚焦模块对输入图像进行裁剪处理。例如,将 $640 \times 640 \times 3$ 输入图像裁剪为 4 份,即得到 2 倍采样下的 $320 \times 320 \times 12$ 特征图。通过 8 倍、16 倍、32 倍连续采样,经 CBL 模块对输入特征进行转换和提取,经 C3 模块提高特征提取能力,经 SPP 模块进行多尺度特征融合,减少冗余计算,形成不同分辨率的特征图输入到颈部段。在颈部段采用 PANet 结构对输入图像进行多尺度特征融合重构,如图 2 所示。其中 PANet 由 FPN 结构和 PAN 结构组成,FPN 结构使用自顶向下方式完成




图 1 YOLOv5 网络结构示意图

Fig. 1 Schematic diagram of YOLOv5 network

上采样,使底层图含有最强图像语义特征;PAN 结构使用自底向上方式完成下采样,使顶层图包含图像位置特征。对上述特征融合重构后进行回归分类预测。




图2 PANet 结构

Fig.2 PANet structure

输出端通过三个预测层对三种不同尺度的特征图进行目标预测。首先,使用 K -means 方法对训练集的目标框聚类生成对应不同尺度的预测框。然后,采用损失函数 Loss 和非极大值抑制 (Non Maximum Suppression, NMS) 对预测框进行回归分类处理,从而获取目标位置。

1.1 损失函数

损失函数由分类损失函数、定位损失函数和置信度损失函数按不同权重组合而成。其中分类损失函数用于计算锚框与对应的标定分类是否正确。定位损失函数用于计算预测框与真实框之间的误差。置信度损失函数用于计算网络的置信度。Loss 采用下式进行计算:

$$\text{Loss} = \lambda_1 A + \lambda_2 B + \lambda_3 C \quad (1)$$

式中, A 表示分类损失函数,由式(2)计算得到; B 表示定位损失函数,由式(3)计算得到; C 表示置信度损失函数,由式(4)计算得到。 λ_1 取 0.05, λ_2 取 0.5, λ_3 取 1。

$$A = \text{BCE}_{\text{obj}}^{\text{sig}}(p_o, p_{\text{iou}}; w_{\text{obj}}) \quad (2)$$

式中: p_o 是预测框中的分类目标置信度分数; p_{iou} 是预测框对应的目标框的值; w_{obj} 表示正样本的权重; $\text{BCE}_{\text{obj}}^{\text{sig}}$ 表示二分类交叉熵损失。

定位损失函数 B 用于计算预测框与真实框之间的误差,其值为

$$B = \text{BCE}_{\text{cls}}^{\text{sig}}(\mathbf{c}_p, \mathbf{c}_{\text{gt}}; w_{\text{cls}}) \quad (3)$$

式中: $\mathbf{c}_p$ 为模型真实类别; $\mathbf{c}_{\text{gt}}$ 为模型预测类别;

w_{cls} 为类别数量; $\text{BCE}_{\text{cls}}^{\text{sig}}$ 表示 sigmoid 的二进制交叉熵函数。

$$C = 1 - \text{IoU} + \frac{\rho^2(\mathbf{b}, \mathbf{b}^{\text{gt}})}{c^2} + av \quad (4)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{\text{gt}}}{h^{\text{gt}}} - \arctan \frac{w}{h} \right)^2 \quad (5)$$

$$\alpha = \frac{v}{(1 - \text{IoU}) + v} \quad (6)$$

式中: IoU 为交并比 (Intersection over Union, IoU); ρ 为 $\mathbf{b}$ 和 $\mathbf{b}^{\text{gt}}$ 之间的欧氏距离, $\mathbf{b}$ 为预测中心的坐标参数, $\mathbf{b}^{\text{gt}}$ 为实际目标边界框中心的坐标参数; v 用来衡量长宽比一致性; $\frac{w^{\text{gt}}}{h^{\text{gt}}}$ 用来预测框宽高比; $\frac{w}{h}$ 为目标框宽高比。

1.2 非极大值抑制

对于多个目标预测框,采用 NMS 搜索局部的极大值,剔除冗余的预测框,从而获取精准的预测结果。NMS 算法流程如图3所示。首先,将所有的




图3 NMS 算法流程

Fig.3 NMS algorithm flow

预测框按照不同类别标签进行分组,组内选出置信度值最高的预测框放入结果框;然后,遍历剩余预测框,计算与结果框之间的重叠面积,若大于设定阈值,则将其剔除。重复上述操作,直到处理完所有预测框,输出预测结果。

2 改进 YOLOv5 算法原理

由于沥青路面裂缝与其背景特征的相似度较高,直接使用 YOLOv5 模型检测时,容易造成误检现象。因此,针对沥青路面裂缝的特点,对 YOLOv5 模型进行改进,主要包括以下 3 个方面。(1)为减少同一特征所产生冗余背景特征信息的干扰,在模型骨干段引入轻量化 Mobilenet v3 特征提取模块。(2)为增强模型对图像中目标区域的敏感度,加大关注度,在模型骨干段 Mobilenet v3 和颈部段的特征提取中嵌入卷积注意力 CBAM 机制。(3)为增强对小目标图像的识别准确度,增强特征提取能力,在模型输出端引入一个嵌入 Panet 模块的小目标预测层。

2.1 轻量化 Mobilenet v3 模块

经过多个卷积核计算,YOLOv5 模型在处理输入图像的同一个特征时,会不断衍生并产生大量的相似图,增大计算量。同时也会导致特征提取时对目标区域的关注度不够,从而产生漏检目标。在 YOLOv5 模型骨干段引入轻量化 Mobilenet v3 模块,在保持提取特征精度的前提下,从模型大小和检测速度两方面对模型进行轻量化改造。轻量化 Mobilenet v3 使用由深度卷积(Depthwise Conv)和逐点卷积(Pointwise Conv)组合而成的深度可分离卷积(Depthwise Separable Conv)减少模型计算量和参数量。在图 4 中,深度卷积核通道数量恒为 1,其中 D_k 为卷积核尺寸, D_F 为输出特征图尺寸,深度可分离卷积




图 4 深度可分离卷积

Fig. 4 Deep separable convolution

M, N 分别为输入、输出特征图通道数量,则卷积核尺寸恒为 1×1 。此外,相比于原始 YOLOv5 骨干段网络, Mobilenet v3 模块可通过更少的网络层实现特征提取。同时, Mobilenet v3 采用线性整流激活函数实现卷积过程,可起到改进模型精度和减少参数数量的作用。从网络结构中可以看出,原始 YOLOv5 骨干段网络具有 24 层,总参数量为 27 MB,而 Mobilenet v3 模块具有 17 层,总参数量为 2.9 MB。

2.2 卷积注意力机制模块

针对裂缝目标小且与背景特征相似度高的问题,在模型进行图像特征提取时引入 CBAM,其网络结构如图 5 所示。CBAM 以自学习方式获取每个特征通道和特征空间的重要程度,根据各自重要程度提升特征或抑制对当前不重要的特征,即针对不同部分的特征图赋予不同的权重,从而加强重要特征,削弱非重要特征。通过通道注意力和空间注意力两个维度分配注意力,形成从通道到空间的顺序注意力架构。其中通道注意力模块用于处理特征图通道的分配关系,空间注意力模块使模型更加关注对分类起决定作用的目标区域,而忽略不相关区域。




图 5 CBAM 网络结构图

Fig. 5 Network structure of CBAM

通道注意力模块流程如图 6 所示。首先通过全局最大池化(Max Pooling)和全局平均池化(Average Pooling)分别提取每个输入特征图的最大值和平均值,实现特征映射的压缩,其中特征图的数量代表通道数量。然后将池化结果输送到一个共享网络,其由一个隐藏层和两个感知器组成,输出结果经过叠加得到每个通道的权重,供空间注意力模块使用。




图 6 通道注意力模块

Fig. 6 Channel attention module

空间注意力模块流程如图7所示。与通道注意力模块不同,这里将全局最大池化和全局平均池化串联起来,以获取更高效的特征描述。然后,使用 3×3 大小的卷积核融合通道信息,使用 sigmoid 函数对特征图的空间权重做归一化处理,再将输入特征图与其权重对应相乘得到新特征图。




图7 空间注意力模块

Fig.7 Spatial attention module

因此,CBAM 增强了图像特征提取通道之间的特征响应,降低了冗余复杂背景信息的干扰,更多地关注目标的位置和类别,从而提升模型检测准确度。

2.3 改进自适应特征提取模型

输入图像经 YOLOv5 模型骨干段下采样后,进行特征融合并输出 20×20 、 40×40 、 80×80 三种尺寸的特征图。其中, 20×20 尺寸特征图用于识别大型尺度的裂缝目标, 40×40 尺寸特征图用于识别中型尺度的裂缝目标, 80×80 尺寸特征图用于识别小型尺度的裂缝目标。

当目标裂缝在图像中的面积占比较小,且与背景图像相似度较高时,导致其通过颈部段进行上采样时获取的特征信息不充分。因此,在 YOLOv5 模型输出端引入一个嵌入 Panet 模块的小目标预测层,对图像进行加强特征提取并输出 160×160 尺寸的特征图,用于识别小尺度的裂缝。从图8可以看出,图像中存在一个微小裂缝,且其特征与背景图相似度较高,通过 160×160 的小尺度特征图可以有效检测到该裂缝,而在 80×80 的特征图无法有效检测。




图8 小目标预测特征图

Fig.8 Small target prediction feature map

3 模型验证

3.1 实验设置

本文所用数据集采集于 G307 国道黄山线,全

长上下行合计 61.6 km,其中一级公路 21.8 km,二级公路 39.8 km。采用大疆 Mavic Air 2 无人机搭载 4 800 万像素的 IMX586 CMOS 图像传感器对路面进行拍摄,经筛选,最终获取 2 000 张有效裂缝图片。通过翻转、镜像对称、尺度变换等操作,将数据集扩充到 4 000 张裂缝图片,并使用 Labelme 工具对图片进行标记。原始图像尺寸为 $1\,024 \times 1\,024$,通过自适应缩放后统一调整为 640×640 。在训练过程中,按照 8:1:1 的比例将数据集随机分为训练集、验证集和测试集三部分。实验环境配置见表1,模型参数如表2所示。

表1 实验环境

Tab.1 Experimental environment

操作系统	Window10
CPU	i7-10875 3.60 GHz
GPU	NVIDIA GeForce GTX2060
GPU 显存	12 G
内存	16 G
加速环境	CUDA v10.0
Pytorch 版本	1.7
Python 版本	3.8

表2 模型参数

Tab.2 Model parameters



参数设置	设置值
批量大小	8
轮数	400
学习率	0.01
权重	Yolov5s. pt

3.2 实验结果及分析

通过训练的 YOLOv5 模型对沥青路面裂缝进行识别,并以卷积神经网络生成的边框与实际裂缝区域的 IoU 评价 YOLOv5 裂缝检测模型的效果。根据是否存在裂缝和交并比是否超过阈值,将识别结果划分为 4 种类型,如表3所示。本文设定交并比阈值为 0.5,则当交并比大于或等于 0.5 时,识别结果认定为真阳性 (True Positive, TP);当交并比小于 0.5 时,识别结果认定为假阳性 (False Positive, FP);当图像中不存在裂缝,且模型也未生成边框时,识别结果认定为真阴性 (True Negative, TN);当图像中存在裂缝,但模型没有生成边框时,识别结果认定为假阴性 (False Negative, FN)。

使用准确率和召回率评价 YOLOv5 模型的识别效果。准确率表示模型识别的准确程度,为正确预测出的裂缝数量与预测出的裂缝总数量的

表 3 YOLOv5 识别结果类别
Tab. 3 YOLOv5 identification result categories

类别	真阳性	假阳性	真阴性	假阴性
图像示例				
交并比	$\text{IoU} \geq 0.5$	$\text{IoU} < 0.5$	不存在	不存在
说明	识别到裂缝, 裂缝存在	识别到裂缝, 裂缝不存在	未识别到裂缝, 裂缝不存在	未识别到裂缝, 裂缝存在

比值。召回率表示模型查全的能力, 为正确预测出的裂缝数量与实际存在裂缝数量的比值。准确率 P 与召回率 R 的计算公式如下:

$$P = \frac{TP}{TP + FB} \quad (7)$$

$$R = \frac{TP}{TP + FN} \quad (8)$$

精度均值 (Average Precision, AP) 是以精确率 P 和召回率 R 所围成的曲线面积值, 是用来衡量模型预测某一类型裂缝的效果, 计算方法如式 (9) 所示。而要衡量模型对所有类型裂缝的整体预测效果, 则需采用平均精度均值 (mean Average Precision, mAP), 计算方法见式 (10), 其中 N_{cls} 为样本类别数。

$$AP = \int_0^1 P(R) dR \quad (9)$$

$$mAP = \frac{1}{N_{cls}} \sum_i AP_i \quad (10)$$

模型的 mAP 和损失函数随着迭代的变化规律如图 9 和图 10 所示。迭代完成后模型的损失逐渐降低并趋于稳定, 从模型的收敛情况可知, 训练过程没有出现过拟合现象, 模型训练效果比较理想, mAP 最终趋近于 0.97 左右。




图 9 mAP 曲线

Fig. 9 mAP curve




图 10 损失函数曲线

Fig. 10 Loss function curve

本文考虑 3 种不同类型的裂缝, 分别为横向裂缝 (标记为 D00), 纵向裂缝 (标记为 D10), 龟裂 (标记为 D20)。由于拍摄照片时角度固定, 且相机沿着公路方向行进, 因此图片中的横向裂纹呈左右方向延伸, 纵向裂纹呈上下方向延伸, 具体检测效果如图 11 所示。




图 11 裂缝分类结果图

Fig. 11 Classification results of cracks

为分别验证改进轻量化 Mobilenet v3 模块和 CBAM 注意力机制对裂缝目标检测的有效性,本文以 YOLOv5 为基准,结合不同的改进策略设计了消融实验。实验结果如图 12—图 14 所示,使用 Mobilenet v3 作为 YOLOv5 骨干网进行特征提取时,模型参数量比原 YOLOv5 降低了 86.30%,改进后的 YOLOv5 比原始 YOLOv5 的平均精度提高了 5.6%,改进后的 YOLOv5 图像检测时间降低了 75.8%,同时提高了检测速度,改进后的 YOLOv5 模型参量为 27.8 MB,达到了模型轻量化的效果。为了减少模型大小和模型参数降低对裂缝检测精度的影响,本文通过引入高效通道注意机制 CBAM 进一步增强裂缝特征的有用信息,抑制无用的特征信息,从而增强对裂缝特征的提取能力。因此,本文在 Mobilenet v3 作为 YOLOv5 模型骨干网的基础上引入 CBAM 注意力机制,在保证模型轻量化的基础上提高了识别率,取得了最佳效果。




图 12 消融实验结果(mAP)
Fig. 12 Results of ablation study(mAP)

模型训练完成后,采用矩形滑动窗口方式扫描整张图像,并将每个图片导入训练好的 YOLOv5




图 13 消融实验结果(模型参量)
Fig. 13 Results of ablation study(model parameters)




图 14 消融实验结果(运行时间)
Fig. 14 Results of ablation study(run time)

模型中,实现裂缝识别和标记。分析检测结果,所训练的神经网络模型对沥青路面裂缝检测结果良好,误判率较低。在不同光照强度下,不同类型的裂缝均能够有效地识别,示例结果如图 15 所示。




图 15 沥青路面不同类型裂缝识别结果

Fig. 15 Identification results of different types of cracks on asphalt pavement

(下转第 79 页)

- bration method based on a multi-plane stereo target[J]. Applied Optics, 2019, 58(34): 9353-9359.
- [5] ZHANG Z. A flexible new technique for camera calibration[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2000, 22(11): 1330-1334.
- [6] CAI C, WENG X, FAN B, et al. Calibration and rectification of vertically aligned binocular omnistereo vision systems[J]. Journal on Image and Video Processing, 2017, 2017(1): 1-14.
- [7] 傅其凤, 崔彦平. 双目视觉摄像机神经网络标定方法[J]. 工程图学学报, 2005, 26(6): 93-97.
- [8] 李晶, 袁峰, 丁振良. 基于BP神经网络的外姿态测量系统线阵CCD标定[J]. 仪器仪表学报, 2010, 31(05): 1138-1141.
- [9] 崔岸, 袁智, 王龙山. 基于自适应神经网络的双摄像机标定[J]. 计算机工程与应用, 2009, 45(21): 55-

57+60.

- [10] 胡志新, 王涛. 改进遗传算法优化BP神经网络的双目相机标定[J]. 电光与控制, 2022, 29(01): 75-79.
- [11] 张峰峰, 陈龙, 薛保珊, 等. 差分遗传算法优化BP神经网络的双目相机标定[J]. 哈尔滨工程大学学报, 2021, 42(07): 928-935.
- [12] 高帅, 贺伟, 李涛, 等. 改进的Harris角点检测目标识别方法[J]. 探测与控制学报, 2022, 44(06): 81-86.
- [13] TONG Y, LI H, CHEN J, et al. Dual-band stereo vision based on heterogeneous sensor networks[J]. Signal Processing, 2016, 126: 87-95.
- [14] 沈花玉, 王兆霞, 高成耀, 等. BP神经网络隐含层单元数的确定[J]. 天津理工大学学报, 2008(05): 13-15.

(责任编辑 王利君)

(上接第73页)

4 结论

本文提出一种改进的YOLOv5裂缝检测方法,通过在模型骨干段引入轻量化Mobilenet v3特征提取模块,并在模型颈部段加入了CBAM注意力机制,最后在模型输出端引入一个嵌入Panet模块进行小目标检测。该方法平均检测精度达97%,图像检测时间降低了75.8%,模型大小仅27.8 MB,该方法有效提升了路面裂缝的检测,表明提出的改进方法有效。

参考文献:

- [1] 郭林飞, 柴仕琦, 董静怡, 等. 我国城市路面塌陷事故统计分析[J]. 工程管理学报, 2020, 34(02): 49-54.
- [2] 杨泽, 孙静宇. 复杂背景下的路面裂缝检测的关键技术[J]. 计算机工程与设计, 2023, 44(05): 1519-1527.
- [3] 俞逸舟. 不同裂缝形式下沥青混凝土路面内孔压变化规律研究[J]. 河北工程大学学报(自然科学版), 2018, 35(03): 54-58.
- [4] 单俊鸿, 王书报, 李裕双, 等. 桥梁承台大体积混凝土的裂缝控制措施[J]. 河北工程大学学报(自然科学版), 2007(03): 4-6.
- [5] 李丽宏, 谢东阳, 王琳, 等. 纹理图像多尺度灰度共

生矩阵步长参数的研究[J]. 河北工程大学学报(自然科学版), 2021, 38(03): 108-112.

- [6] 张跃飞, 王敬飞, 陈斌, 等. 基于改进的Mask R-CNN的公路裂缝检测算法[J]. 计算机应用, 2020, 40(S2): 162-165.
- [7] 李雪露, 杨永辉, 储茂祥, 等. 基于改进Faster R-CNN的钢板表面缺陷检测[J]. 安徽大学学报(自然科学版), 2023, 47(02): 66-73.
- [8] 黄尚安, 阮太元, 周昊, 等. 基于改进Faster R-CNN的道路坑洞检测方法[J]. 科学技术创新, 2023(09): 112-115.
- [9] CUI X, WANG Q, DAI J, et al. Intelligent recognition of erosion damage to concrete based on improved YOLO-v3[J]. Materials Letters, 2021, 302: 130363.
- [10] SHAO Yongxin, SUN Zhetao, TAN Aihong, et al. Efficient three-dimensional point cloud object detection based on improved Complex-YOLO[J]. Frontiers in Neurobotics, 2023, 17: 1092563.
- [11] GONG Hang, MU Tingkui, LI Qiuxia, et al. Swin-transformer-enabled YOLOv5 with attention mechanism for small object detection on satellite images[J]. Remote Sensing, 2022, 14(12): 2861.
- [12] 罗晖, 贾晨, 李健. 基于改进YOLOv4的公路路面病害检测算法[J]. 激光与光电子学进展, 2021, 58(14): 336-334.

(责任编辑 王利君)