

DOI:10.3969/j.issn.1003-5060.2026.04.010

基于YOLOv5和UNet++深度学习方法的 岩体裂隙智能定位与识别

杨曼¹, 马雷¹, 昌仪², 左琛¹, 周杰²

(1. 合肥工业大学资源与环境工程学院, 安徽合肥 230009; 2. 安徽省地质测绘技术院, 安徽合肥 230022)

摘要:针对传统岩体裂隙地面调查效率低、高陡边坡环境裂隙调查困难、裂隙图像识别精度低等问题,文章利用地理信息技术中无人机航拍采集的图像,结合YOLOv5和UNet++深度学习网络的方法进行岩体裂隙智能定位与识别。首先利用YOLOv5进行岩体裂隙结构面的检测与定位,然后基于UNet++深度学习网络对检测到的裂隙结构面进行图像识别,并对野外环境下裂隙图像识别的鲁棒性和准确率进行评价。结果表明,在相同样本条件下,YOLOv5的检测精确率达到85.41%,高于Faster R-CNN(faster region-based convolutional neural network)、YOLOv3, UNet++的识别精确率达到82.33%,高于FCN(fully convolutional networks)、UNet。基于YOLOv5和UNet++的深度学习方法能够相对高效准确地实现岩体裂隙的检测定位与识别,可满足野外环境下裂隙批量化快速识别的要求。

关键词:无人机;深度学习;裂隙识别;YOLOv5;UNet++

中图分类号:TU454; TP391.413

文献标志码:A

文章编号:1003-5060(2026)04-0505-07

Intelligent positioning and identification of rock mass fractures based on YOLOv5 and UNet++ deep learning methods

YANG Man¹, MA Lei¹, CHANG Yi², ZUO Chen¹, ZHOU Jie²

(1. School of Resources and Environmental Engineering, Hefei University of Technology, Hefei 230009, China; 2. Anhui Institute of Geological Surveying and Mapping Technology, Hefei 230022, China)

Abstract: Aiming at the problems of low efficiency in traditional ground survey of rock mass fractures, difficulty in environmental fracture investigation of high-steep slope, and low accuracy of fracture image recognition, this paper employs images collected by unmanned aerial vehicle(UAV) aerial photography in geographic information technology as well as the YOLOv5 and UNet++ deep learning methods to conduct intelligent positioning and identification of rock mass fractures. YOLOv5 is used to detect and locate the fracture plane of rock mass, and then image recognition of the detected fracture plane is carried out based on the UNet++ deep learning network to further evaluate the robustness and accuracy of fracture image recognition in the field environment. The results show that under the same sample conditions, the detection accuracy of YOLOv5 reaches 85.41%, which is higher than that of faster region-based convolutional neural network(Faster R-CNN) and YOLOv3, and the recognition accuracy of UNet++ reaches 82.33%, which is higher than that of fully convolutional networks(FCN) and UNet. The deep learning algorithm based on YOLOv5 and UNet++ can realize the detection, positioning and identification of rock mass fractures efficiently and accurately, which can meet the requirements of rapid batch identification of fractures in the field environment.

Key words: unmanned aerial vehicle(UAV); deep learning; fracture identification; YOLOv5; UNet++

收稿日期:2024-02-27;修回日期:2024-04-26

基金项目:国家重点研发计划资助项目(2022YFC3702205);国家自然科学基金资助项目(42072276)

作者简介:杨曼(1997—),女,四川广安人,合肥工业大学硕士生;

马雷(1985—),男,安徽灵璧人,博士,合肥工业大学教授,硕士生导师,通信作者, E-mail:Lei8505@hfut.edu.cn.

裂隙广泛分布在浅表基岩中,在岩体力学特性分析、隧洞与矿坑涌水量估算、地热资源开发等诸多领域,高效准确地获取具有代表性的岩体裂隙信息具有重要的意义^[1]。传统的岩体裂隙信息主要通过人工地面测量得到,但人工测量的工作效率较低、主观性误差较大,并且易受地形和环境条件影响,在高陡边坡、地势险要的地区还存在严重的安全隐患。

随着现代科技的进步,将地理信息技术与图像处理方法相结合为岩体裂隙的检测与识别提供了新路径。利用地理信息技术中无人机的低空摄影,能够大量获取地表岩体裂隙的图像,再结合图像处理方法进行裂隙的检测与识别,可以方便快捷地获取裂隙信息,大幅度提高裂隙识别效率,也能在一定程度上补充或部分代替传统的岩体裂隙人工调查方法。

采用数字图像处理的方法进行裂隙识别时,主要是利用裂隙和背景的灰度值差异^[2-4],但需要人为地设定参数,不仅降低了检测的自动化水平,也不利于大范围使用。近年来,利用深度学习进行裂隙检测识别的方法受到广泛关注,深度学习方法可以有效提高图像识别的自动化程度,从图像中检测识别裂隙的深度学习方法主要分为筛选、检测和识别 3 种^[5],具体如下所述:裂隙筛选是区分图像中是否含有裂隙^[6];裂隙检测是区分图像中是否含有裂隙,然后将裂隙的大致位置或种类进行标注^[7];裂隙识别是将图片中的每个像素分类为裂隙像素或非裂隙像素,从而得到裂隙轮廓的形状特征^[8-9]。

在目标检测方面,相关研究主要是利用以 YOLO(You Only Look Once)^[10]和 R-CNN(region-based convolutional neural network)^[11]系列算法进行检测。文献[12-15]在道路、桥梁、房屋等多个领域,利用 R-CNN 算法对混凝土中的裂隙进行检测,但 R-CNN 算法在计算时间方面存在缺陷^[16],因为它是在对图像提取约 2 000 个候选区域并将其扭曲成正方形后,在每个扭曲的图像上进行检测,所以检测花费的时间较长。与 R-CNN 算法不同,YOLO 算法是在整个图像上使用 1 个神经网络,并将图像划分为多个区域,然后该网络在具有预测概率的区域上绘制边界框,从而提高了检测速度。其中 YOLOv5 算法是 YOLO 算法较新的框架,用于目标的智能检测时,YOLOv5 算法模型比传统模型检测快、精度高,可有效提高目标物的识别准确率^[17]。

在图像识别方面,相关研究主要是利用 FCN(fully convolutional networks)、UNet(UNet)系列算法进行识别。文献[18]基于岩石图像开展多尺度岩性识别;文献[19]利用 FCN 算法对混凝土大坝裂隙进行像素级识别;文献[20-21]利用 UNet 算法及其改进算法对混凝土裂隙、岩体裂隙、路面裂隙进行量化识别。UNet++是对 UNet 网络模型的改进^[22],解决了随着 UNet 网络深度的增加,识别效果不一定越好的局限。

对已有相关研究进行分析发现,上述目标检测和图像识别方法多用于道路、桥梁、大坝等混凝土裂隙识别中,在岩体裂隙领域中的应用较少。在目前的岩体裂隙研究中,一般只采用目标检测方法对裂隙进行粗略定位,没有对裂隙轮廓进行精确提取,有的只是采用图像识别方法进行裂隙迹线的提取,在大范围复杂背景下无法进行实时检测。本文基于无人机拍摄的岩体裂隙图像,结合深度学习方法进行岩体裂隙检测与识别。首先使用目标检测算法 YOLOv5 对野外岩体的裂隙区域进行定位;再利用语义分割网络 UNet++对已定位的裂隙区域图像进行细节识别,实现岩体裂隙的快速检测与识别。

1 岩体裂隙智能定位与识别方法

1.1 总体流程

本文方法分为 2 步:第 1 步是基于 YOLOv5 算法进行裂隙检测和定位,岩体裂隙检测的目的是找到含有裂隙的岩体进行定位;第 2 步是基于 UNet++进行岩体裂隙分割和识别,裂隙分割的目的是从含裂隙的岩体背景中提取裂隙像素。将第 1 步裂隙检测的结果用于第 2 步裂隙分割,能够针对性地对岩体裂隙进行识别,提高裂隙信息获取的速度。

1.2 裂隙识别方法

1.2.1 基于 YOLOv5 的岩体裂隙定位

YOLO 算法是基于深度神经网络对目标进行识别和定位的算法,它将图片分成若干个网格单元进行图像特征提取,然后输出目标物的预测边界框^[22]。目标边界框坐标的预测过程如图 1 所示^[23-24]。

在 YOLO 算法中, σ 函数的目的是将预测偏移量缩放至 0~1 之间。预测偏移量用 t_x 、 t_y 、 t_w 、 t_h 表示, t_x 、 t_y 是预测的坐标偏移值, t_w 、 t_h 是在宽度、高度上的尺度缩放值;最终的检测结果用 b_x 、 b_y 、 b_w 、 b_h 表示。图 1 中:虚线矩形框为锚框(anchor)

chor box);实线矩形框为通过网络预测的偏移量计算得到的预测边界框(bounding box)。假设 1 个网格相对于图像左上角的偏移量是 c_x 、 c_y , 锚框的宽度和高度分别为 p_w 、 p_h , 锚框与预测边界框的对应关系如图 1 中公式所示。




图 1 目标边界框预测过程

在 YOLO 算法目标检测序列中, YOLOv5 算法推理速度最强,模型尺寸最轻,且输入端中更新的自适应锚框计算^[25]是基于训练数据,在训练时对真实框相对于预测框的位置偏移反复进行迭代更新,才得到最合适的预测框^[25],故选取 YOLOv5 作为裂隙区域检测的方法。

1.2.2 基于 UNet++ 的岩体裂隙识别

UNet++ 是对 UNet 网络模型的改进^[22]。UNet++ 在 UNet 网络原有结构基础上,添加了密集跳跃连接模块,这让底层和高层之间的信息能实现多层次融合^[22];该跳跃连接使得图像的细节能够更完整地保留,从而被分割出来,其结构如图 2 所示^[22]。




图 2 UNet++ 框架

从图 2 可以看出,在 UNet++ 中,2、3、4、5 深度处的 UNet 依次叠加,各层互不孤立,通过跳跃连接,依次被连接起来。由于不同层级 UNet 最后得到的特征维度不同,在每个 UNet 的右端

模块,其与 1×1 卷积核的卷积层连接,通过降低维度并监督各层训练,使各个深度的特征都被兼顾,再通过不同路径的解码还原不同层次的特征,最后将每层特征图相加,得到相加特征。因此,UNet++ 能够考虑不同尺度图像特征的特点,非常适用于同时识别岩体裂隙图像中不同大小的裂隙。

1.3 评价指标

采用精确率(Precision) P 、召回率(Recall) R 和 F_1 分数(F_1 -score)3 个经典评价指标对裂隙检测和识别的结果进行评估。

精确率是真阳性(T_P)和假阳性(F_P)组成的检测值中真阳性(T_P)的百分比。召回率是由真阳性(T_P)和假阴性(F_N)组成的检测值中真阳性(T_P)的百分比。 F_1 分数是精确率和召回率的调和平均值。 P 、 R 、 F_1 分数计算公式分别为:

$$P = \frac{T_P}{T_P + F_P} \tag{1}$$

$$R = \frac{T_P}{T_P + F_N} \tag{2}$$

$$F_1 = \frac{2PR}{P + R} \tag{3}$$

为了获得更精确的评估结果,将数据集随机分为 3 组,每组数据集经过 3 次训练和测试,得到稳定结果后,才用以评估裂隙检测结果。将 3 组测试结果(P 、 R 、 F_1 分数)的平均值作为总体评估结果。

对图像中的裂隙进行定位,检测结果是裂隙周围的边界框,即含有裂隙的岩体区域,以下简称裂隙区域。裂隙检测的评估指标中,真阳性指裂隙区域被正确检测为裂隙区域,假阳性指被错误地检测为裂隙区域的非裂隙区域,假阴性指错误地检测到的裂隙区域不是裂隙区域。

对检测到的裂隙进行识别,分割结果是每条裂隙的形状轮廓,即将图像按像素分为裂隙和非裂隙。裂隙分割的评估指标中,真阳性指裂隙被正确分割为裂隙的像素数量,假阳性指被错误分割为裂隙的非裂隙的像素数量,假阴性指被错误分割为非裂隙的裂隙的像素数量。

2 智能定位与识别方法的应用与分析

2.1 岩体裂隙区域检测

2.1.1 参数设置

由于 YOLO 算法不是专门为地质和岩土工程而开发的,为了使 YOLO 算法参数满足岩体裂

隙自动检测的要求,根据岩体裂隙的特殊性,在训练前,一方面对训练数据进行数据增强操作,增强方法包括水平翻转、随机裁剪、亮度调节和旋转等,另一方面对本文应用的 YOLOv5 参数设置进行修改,通过增加分辨率参数,进行不同分辨率的随机多尺度训练,提高裂隙检测的精度。训练时,为了使模型训练结果达到最佳,设置训练次数为 200;根据显卡内存大小,以 2 幅图像为 1 个批次,每训练 1 批图像,都进行 1 次权值参数的更新,并保存最优权重进行预测;学习率调整策略采用阶梯衰减的方法,动量因子设为 0.9,初始学习率设为 0.000 1。

2.1.2 检测结果与分析

YOLOv5 模型训练过程的总体损失变化如图 3 所示。从图 3 可以看出,训练过程中总体损失先迅速下降,随后缓慢下降并趋于平稳,这表明网络训练已收敛,可以进行裂隙检测。




图 3 YOLOv5 模型训练过程的总体损失变化

为验证 YOLOv5 的有效性,本文对 Faster R-CNN 和 YOLOv3 2 种目标检测方法都基于同一数据集进行训练测试,并对比 3 种方法的检测精度。


3 种目标检测方法的测试结果见表 1 所列。

表 1 3 种目标检测方法测试结果 %

网络类别	P	R	F_1
Faster R-CNN	45.26	82.31	58.40
YOLOv3	78.64	81.68	80.13
YOLOv5	85.41	83.42	84.40

从表 1 可以看出,YOLOv5 的 P 、 R 、 F_1 分数分别为 85.41%、83.42%、84.40%,均高于 Faster R-CNN 和 YOLOv3 的裂隙检测结果。由此可知,YOLOv5 检测性能更强,可用于野外岩体裂隙的检测。


利用 YOLOv5 检测出的野外岩体裂隙区域如图 4 所示。




(a)



(b)



(c)



(d)

图 4 野外岩体裂隙区域的检测定位

图4中:黑色框区域为岩体裂隙区域;白色框区域为未被识别检测的岩体裂隙区域。从图4可以看出,YOLOv5能够检测到大部分的裂隙区域,且能较好地地区分裂隙区域与碎石堆等其他非裂隙区域,对于裂隙区域检测有较好的适用性。

由于无人机航拍图像的拍摄范围较大,图像中一般包含除山体、裂隙以外的多种复杂背景信息,且不同飞行高度下的光照环境不同,导致虽然检测得到的评估数值较高,与背景差异明显的裂隙能被成功检测(图4a、图4b),但差异不明显的图像测试结果仍然存在少量错误。在图4c中,虽然裂隙区域被成功检测出来,但检测边框有所重叠;在图4c、图4d的白色框标注部位,由于岩体本身的颜色与裂隙颜色接近,且裂隙微小,受图像分辨率的影响未能被检测,部分裂隙未被成功检测定位。这表明本文YOLOv5中用于区分背景和真实裂隙的训练仍然不够,因此,需要在数据集中添加更多不同情况下的岩体裂隙图像,以提高检测网络的性能。

2.2 岩体裂隙识别

2.2.1 裂隙样本构建与训练策略优化

与背景区域相比,裂隙的像素数量较少,为了提高UNet++识别效率,一方面根据岩体裂隙特征多样、噪声干扰多、语义信息丰富等特点,从YOLOv5检测到的裂隙结构面中选取含单裂隙、多裂隙、交叉裂隙等多种裂隙形态特征以及背景含有噪声干扰的裂隙图像进行训练;另一方面,对裂隙图像进行直方图均化、双边滤波等预处理,以尽量降低裂隙图像识别不利因素的干扰。

在进行样本训练时,采用学习率调度策略中的单周期策略与随机梯度下降相结合的方法

来确定学习率。通过随机梯度下降引入一些噪声到梯度更新中,这些噪声可以帮助模型跳出局部最优点,更好地逼近全局最优。此外,采用单周期训练机制来加快损失函数的收敛速度,在保证模型收敛的同时,提高训练的效率和最终模型的性能。

2.2.2 识别结果与分析

UNet++模型训练过程的总体损失变化如图5所示。

从图5可以看出,训练集损失和验证集损失迅速减小并趋于稳定,最终训练集损失稳定在0.33左右,验证集损失稳定在约0.35,且两者在训练过程中非常接近,说明模型对数据拟合效果较好,能够满足裂隙识别的基本要求。




图5 UNet++模型训练过程的总体损失变化

使用训练好的UNet++模型对前述利用YOLOv5检测到的裂隙区域进行进一步识别,以准确提取岩体裂隙的具体形态特征。为了对比UNet++的裂隙识别效果,同时采用FCN和UNet 2种语义分割网络,基于同一数据集进行训练测试,从而对比3种方法的检测精度,识别结果如图6所示。




图6 3种图像识别方法识别结果

从图 6 可以看出:FCN 和 UNet 的识别结果都存在严重的裂隙不连续、噪点多、漏识别等情况;而 UNet++ 的识别结果有明显提升,受图像中光照条件和其他噪声的影响较小,可准确识别大部分岩体裂隙像素,遗漏的裂隙像素较少,且裂隙连通性良好,测试结果接近地面实况,由此可知 UNet++ 能够准确地识别图像中的岩体裂隙。

3 种图像识别神经网络的测试结果见表 2 所列。由表 2 可知,UNet++ 的 P 、 R 、 F_1 分数均高于 FCN 和 UNet,UNet++ 较好地分割了更多的实际裂隙像素和更少的假裂隙像素,更适用于岩体裂隙的准确识别。

表 2 3 种图像识别方法测试结果 %

网络类别	P	R	F_1
FCN	72.64	51.48	60.25
UNet	78.82	42.39	55.13
UNet++	82.33	64.88	72.57

岩体裂隙数据集的背景一般非常复杂,给神经网络模型准确提取岩体裂隙特征带来一些困难和干扰,如图 6 场景 2 中红色边框标注部位,岩体上的水渍被 UNet++ 模型误判为裂隙。后续研究需要尝试寻找尽可能消除多种噪声影响的方法,以进一步提高野外岩体裂隙的识别精度。

3 结 论

本文基于无人机航拍技术得到的复杂环境岩体图像,利用 YOLOv5 和 UNet++ 深度学习方法进行裂隙的智能定位与识别,得出以下结论:

1) 根据岩体裂隙的特点对 YOLOv5 参数进行调整,并采用多种数据增强方法和多尺度训练方法,使大部分裂隙结构面被检测定位,岩体裂隙检测的精确率、召回率和 F_1 分数分别为 85.41%、83.42%、84.40%,高于同样数据集下的 Faster R-CNN 和 YOLOv3 目标检测方法。

2) 采用 UNet++ 模型,根据岩体裂隙特征选取训练图像,通过对数据进行预处理和调整学习率策略,使裂隙图像识别连通性、完整性都较高,更接近于地面真实情况,岩体裂隙识别的精确率、召回率和 F_1 分数分别达到 82.33%、64.88%、72.57%,岩体裂隙识别效果优于 FCN 和 UNet。

3) 基于无人机航拍图像和深度学习算法相结合的野外岩体裂隙智能定位和识别方法,不仅能够对野外岩体的裂隙区域进行有效定位,而且能够进一步识别该区域内的岩体裂隙信息。

岩体裂隙检测的精度受到无人机航拍的复杂背景信息和飞行高度等带来的图像噪声影响,检测结果存在裂隙检测不到或检测面重叠等情况,未来需要添加更多不同情况和不同尺度的岩体裂隙图像数据,以提高检测网络的性能。岩体裂隙数据集的背景一般也非常复杂,给利用神经网络模型准确提取岩体裂隙特征带来一些困难和干扰,如岩体上的水渍被模型误判为裂隙,后续研究需要尝试寻找尽可能消除多种噪声影响的方法,以进一步提高野外岩体裂隙识别精度。

[参 考 文 献]

- [1] 姚荣文,张云辉,赵晓彦,等. 岩体裂隙三维可视化新方法及其应用[J]. 地球科学,2022,47(9):3463-3476.
- [2] ZOU Q, CAO Y, LI Q Q, et al. CrackTree: automatic crack detection from pavement images[J]. Pattern Recognition Letters, 2012, 33: 227-238.
- [3] 王一兵,包腾飞,高治鑫. 基于 LabVIEW+VDM 的混凝土坝裂缝检测方法[J]. 水利水电科技进展,2021, 41(5):76-82.
- [4] 张小伟,包腾飞,高兴和. 基于计算机视觉的混凝土坝裂缝检测方法[J]. 水利水电科技进展,2021,41(5):83-88.
- [5] 李怡静,程浩东,李火坤,等. 基于改进 U^2 -Net 与迁移学习的无人机影像堤防裂缝检测[J]. 水利水电科技进展,2022, 42(6):52-59.
- [6] LI B X, WANG K C P, ZHANG A, et al. Automatic classification of pavement crack using deep convolutional neural network[J]. International Journal of Pavement Engineering, 2020, 21: 457-463.
- [7] PARK S E, EEM S H, JEON H. Concrete crack detection and quantification using deep learning and structured light[J]. Construction and Building Materials, 2020, 252: 119096.
- [8] JI A K, XUE X L, WANG Y N, et al. An integrated approach to automatic pixel-level crack detection and quantification of asphalt pavement[J]. Automation in Construction, 2020, 114: 103176.
- [9] KANG D, BENIPAL S S, GOPAL D L, et al. Hybrid pixel-level concrete crack segmentation and quantification across complex backgrounds using deep learning[J]. Automation in Construction, 2020, 118: 103291.
- [10] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). [S. l.]: IEEE, 2016: 779-788.
- [11] GIRSHICK R. Fast R-CNN [C]//2015 IEEE International Conference on Computer Vision (ICCV). [S. l.]: IEEE, 2015: 1440-1448.
- [12] CHA Y J, CHOI W, SUH G, 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(9): 731-747.

(下转第 529 页)

- forced concrete with basalt-polypropylene fibers[J]. *Advances in Structural Engineering*, 2019, 22(10): 2278-2288.
- [5] LI J C, QIAO H X, ZHU F F. Reliability analysis of freeze-thaw damage of fiber reinforced concrete based on Miner theory[J]. *Emerging Materials Research*, 2019, 8(3): 1-7.
- [6] 杨虹, 王海龙, 王红珊, 等. 碳纤维轻骨料混凝土力学性能试验研究[J]. *建筑结构*, 2021, 51(11): 108-112.
- [7] 吕志恒, 程铭, 蒋喜生. 玻璃纤维和聚丙烯纤维改善混凝土微观结构研究[J]. *中外公路*, 2020, 40(6): 267-270.
- [8] 黄艳. 耐碱玻璃纤维在道路混凝土中的应用[J]. *交通标准化*, 2014, 42(12): 68-70, 73.
- [9] 杜向琴, 刘志龙. 水工钢纤维混凝土抗渗性和抗冻性的研究[J]. *四川建筑科学研究*, 2015, 41(2): 199-201.
- [10] 程红强, 高丹盈. 聚丙烯纤维混凝土冻融损伤试验研究[J]. *东南大学学报(自然科学版)*, 2010, 40(增刊2): 197-200.
- [11] 党军亮, 牛建刚, 唐好令, 等. 碳纤维掺量及长度对混凝土力学性能的影响[J]. *合成纤维工业*, 2021, 44(4): 55-58.
- [12] 王孟言. 玻璃纤维混凝土结构特性及抗震性能研究[J]. *造纸装备及材料*, 2023, 52(7): 78-80.
- [13] 杜向琴, 刘志龙. 碳纤维对混凝土力学性能的影响研究[J]. *混凝土*, 2018(4): 91-94.
- [14] 罗辉. 碳纤维轻骨料混凝土力学性能试验研究[J]. *四川建材*, 2022, 48(4): 22-23.
- [15] 李黎, 曹明莉, 冯嘉琪. 纤维增强水泥基复合材料的纤维混杂效应研究进展[J]. *应用基础与工程科学学报*, 2018, 26(4): 843-853.
- [16] 轩倩茹. 混凝土盐冻破坏机理分析[J]. *四川建材*, 2020, 46(5): 3-4.
- [17] 文可, 周珣. 玄武岩纤维混凝土抗冻性能试验研究[J]. *山西建筑*, 2017, 43(34): 102-104.
- [18] 赵燕茹, 范晓奇, 王利强, 等. 不同冻融介质作用下混凝土力学性能衰减模型[J]. *复合材料学报*, 2017, 34(2): 463-470.
- [19] 朱晨飞, 刘晓军, 李文哲, 等. 混杂纤维混凝土冻融耐久性与损伤模型研究[J]. *工业建筑*, 2015, 45(2): 10-14.
- [20] 张广泰, 刘诗拓, 耿天娇, 等. 基于 Weibull 分布的冻融循环下纤维混凝土损伤模型[J]. *科学技术与工程*, 2020, 20(29): 12078-12084.
- [21] 王立久, 汪振双, 崔正龙. 基于冻融损伤抛物线模型的再生混凝土寿命预测[J]. *应用基础与工程科学学报*, 2011, 19(1): 29-35.

(责任编辑 吴亮)

(上接第 510 页)

- [13] WANG N N, ZHAO X F, ZHAO P, et al. Automatic damage detection of historic masonry buildings based on mobile deep learning[J]. *Automation in Construction*, 2019, 103: 53-66.
- [14] XU Y, WEI S Y, BAO Y Q, et al. Automatic seismic damage identification of reinforced concrete columns from images by a region-based deep convolutional neural network[J]. *Structural Control and Health Monitoring*, 2019, 26(3): e2313.
- [15] 章世祥, 张汉成, 李西芝, 等. 基于机器视觉的路面裂缝病害多目标识别研究[J]. *公路交通科技*, 2021, 38(3): 30-39.
- [16] 张婷婷, 章坚武, 郭春生, 等. 基于深度学习的图像目标检测算法综述[J]. *电信科学*, 2020, 36(7): 92-106.
- [17] 张庆贺, 陈晨, 袁亮, 等. 基于 DIC 和 YOLO 算法的复杂裂隙岩石破坏过程动态裂隙早期智能识别[J]. *煤炭学报*, 2022, 47(3): 1208-1219.
- [18] 马泽栋, 马雷, 李科, 等. 基于岩石图像深度学习的多尺度岩性识别[J]. *地质科技通报*, 2022, 41(6): 316-322.
- [19] LI S Y, ZHAO X F, ZHOU G Y. Automatic pixel-level multiple damage detection of concrete structure using fully convolutional network[J]. *Computer-aided Civil and Infrastructure Engineering*, 2019, 34(7): 616-634.
- [20] LIU J W, YANG X, LAU S, et al. Automated pavement crack detection and segmentation based on two-step convolutional neural network[J]. *Computer-Aided Civil and Infrastructure Engineering*, 2020, 35(11): 1291-1305.
- [21] LAU S L H, CHONG E K P, YANG X, et al. Automated pavement crack segmentation using U-Net-based convolutional neural network[J]. *IEEE Access*, 2020. DOI: 10.1109/ACCESS.2020.3003638.
- [22] 张靖, 俞锡光, 郑东旭, 等. 基于 GAN-UNet++ 的汽车铝铸件图像缺陷分割算法研究[J]. *模具工业*, 2023, 49(11): 6-11.
- [23] REDMON J, FARHADI A. YOLO9000: better, faster, stronger[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). [S. l.]: IEEE, 2017: 6517-6525.
- [24] REDMON J, FARHADI A. YOLOv3: an incremental improvement [PP/OL]. arXiv (2018-04-08) [2024-02-10]. <https://doi.org/10.48550/arXiv.1804.02767>.
- [25] XIANG X, WANG Z, QIAO Y. An improved YOLOv5 crack detection method combined with transformer[J]. *IEEE Sensors Journal*, 2022, 22(14): 14328-14335.

(责任编辑 张淑艳)