

DOI: 10.11835/j.issn.2096-6717.2022.079



开放科学(资源服务)标识码 OSID:



基于M-Unet的混凝土裂缝实时分割算法

孟庆成¹, 李明健¹, 万达¹, 胡垒¹, 吴浩杰¹, 齐欣²

(1. 西南石油大学土木工程与测绘学院, 成都 610500; 2. 西南交通大学土木工程学院, 成都 610031)

摘要:针对主流深度学习裂缝分割算法消耗大量计算资源、传统图像处理方法检测精度低、丢失裂缝特征等问题,为了实现对混凝土裂缝的实时检测和在像素级水平上分割裂缝,提出一种基于轻量级卷积神经网络M-Unet的裂缝语义分割模型,首先对MobileNet_V2轻量网络进行改进,修剪其网络结构并优化激活函数,再用改进的MobileNet_V2替换U-Net参数量巨大的编码器部分,以实现模型的轻量化并提升裂缝的分割效果。构建包含5 160张裂缝图像的SegCracks数据集对提出方法进行验证,试验结果表明:优化后的M-Unet裂缝分割效果优于U-Net、FCN8和SegNet等主流分割网络和传统图像处理技术,获得的IoU_Score为96.10%,F1_Score为97.99%。与改进前U-Net相比,M-Unet权重文件大小减少了7%,迭代一轮时间和预测时间分别缩短了63.3%和68.6%,IoU_Score和F1_Score分别提升了5.79%和3.14%,并且在不同开源数据集上的交叉验证效果良好。表明提出的网络具有精度高、鲁棒性好和泛化能力强等优点。

关键词:混凝土裂缝;卷积神经网络;深度学习;裂缝检测;裂缝分割

中图分类号: TU755.7 **文献标志码:** A **文章编号:** 2096-6717(2024)01-0215-08

Real-time segmentation algorithm of concrete cracks based on M-Unet

MENG Qingcheng¹, LI Mingjian¹, WAN Da¹, HU Lei¹, Wu Haojie¹, QI xin²

(1. School of Civil Engineering and Geomatics, Southwest Petroleum University, Chengdu 610500;

2. School of Civil Engineering, Southwest Jiaotong University, Chengdu 610031)

Abstract: Mainstream deep learning algorithm for crack segmentation consumes a lot of computing resources while the traditional image processing methods are of low detection accuracy and lost crack features. In order to realize the real-time detection of concrete cracks and the segmentation of cracks at the pixel level, a crack semantic segmentation model based on lightweight convolutional neural network M-Unet is proposed. Firstly, the MobileNet_V2 lightweight network is improved, its network structure is trimmed and the activation function is optimized, and then the encoder part with huge parameters of U-Net is replaced by the improved MobileNet_V2 to realize the lightweight of the model and improve the segmentation effect of cracks. The SegCracks data set containing 5 160 crack images is constructed to verify the proposed method. The experimental results show that the crack segmentation effect of the optimized M-Unet is better than the

收稿日期: 2022-05-04

基金项目: 国家自然科学基金(52078442);四川省科技计划(2021YJ0038)

作者简介: 孟庆成(1980-),男,博士,主要从事桥梁结构健康监测与损伤识别研究, E-mail: 214400395@qq.com。

Received: 2022-05-04

Foundation items: National Natural Science Foundation of China (No. 52078442); Science and Technology Program of Sichuan Province (No. 2021YJ0038)

Author brief: MENG Qingcheng (1980-), PhD, main research interests: bridge structure health monitoring and damage identification, E-mail: 214400395@qq.com.

mainstream segmentation networks of U-Net, FCN8 and SegNet and the traditional image processing techniques, the obtained IoU_Score is 96.10%, F1_Score is 97.99%. Compared with the original U-Net, the weight file size M-Unet is reduced by 7%, the iteration time and prediction time are reduced by 63.3% and 68.6% respectively, and the IoU_Score and F1_Score are increased by 5.79% and 3.14% respectively. The cross validation results on different open source data sets are good, which shows that the proposed network has the advantages of high accuracy, good robustness and strong generalization ability.

Keywords: concrete cracks; convolutional neural network; deep learning; crack detection; crack segmentation

在混凝土自身材料特性影响及多重因素作用下,混凝土结构服役期间会不可避免地产生裂缝。裂缝是混凝土结构病害的一种初期表现,若初期裂缝得不到即时修补,在外力的作用下,裂缝的长度、宽度、深度会不断地增加,使得混凝土构件的有效截面面积减小,承载力降低,继而可能会导致事故的发生^[1]。早期的裂缝检测主要是人工检测方法,人工检测可以直接对裂缝的特征进行判断,较为简便灵活,但人工检测的结果受限于主观判断,依赖检测人员的经验储备,且人力物力消耗大,容易发生安全事故,导致人工检测难以完成大量的裂缝检测任务^[2]。后来出现了基于传统图像处理技术的裂缝检测方法,常见的有基于阈值的裂缝图像分割方法和边缘检测方法^[3]。传统图像处理技术促进了混凝土裂缝检测技术的发展,取得了一定的成就,但在解决复杂裂缝以及背景噪声多的图像时,传统图像处理技术存在较多的局限性,使其无法获得稳定的检测结果,无法适应复杂的实际场景^[4]。

深度学习(Deep Learning, DL)算法具有强大的特征提取能力,早期受限于计算机硬件设备的性能而没有得到普遍的应用^[5]。随着计算机硬件设备性能的提升和现代科技的飞速发展,深度学习算法的应用得到了普及并促进了图像识别技术的发展。深度学习算法是一种包含多隐含层和多感知层的网络结构,相比于传统算法能更好地描述物体抽象的和深层次的信息,在图像识别领域表现突出,因此越来越多的科研人员将其应用于结构损伤检测任务中^[6]。胡文魁等^[7]针对传统方法去除裂缝图像噪声不明显以及输出结果中裂缝不连续的问题提出一种BCI-AS方法,在像素级水平上的裂缝分割精度达到了94.45%。李良福等^[8]先利用滑动窗口算法对裂缝图像切割成多个区域,再用卷积神经网络(Convolutional Neural Network, CNN)对切割后图像分类,最后用改进的滑动窗口算法检测裂缝,取得良好的检测效果。Liu等^[9]采用U-Net方法识别混凝土裂缝,与全卷积网络(Fully Convolutional Networks, FCN)相比,该方法的效率更高、准确性

更好,但存在边缘平滑、细节丢失的问题。Ren等^[10]提出了一种改进的深度全卷积网络CrackSegNet,可有效地消除噪声的干扰,可从复杂背景的裂缝图像中执行端到端的裂缝分割。Xue等^[11]提出基于R-FCN的隧道衬砌裂缝图像检测方法,获得了比GoogLeNet和VGG等模型更好的检测效果。王森等^[12]提出一种深度全卷积神经网络用于裂缝图像的分割,该算法准确率达92.46%,但没有用其他数据对算法的有效性进行测试,缺乏对模型泛化能力的验证。

上述网络模型均取得了较好的裂缝分割效果,但所需的计算量大、缺乏对裂缝分割速度的考虑,在裂缝检测量巨大和设备计算资源有限的前提下,难以满足裂缝检测实时性的要求。提出一种结合改进的MobileNet_V2轻量网络和U-Net网络的裂缝语义分割模型M-Unet,利用改进的MobileNet_V2网络替换U-Net网络的下采样部分,减少参数量,达到网络轻量化的效果,并设置多组对比实验以验证方法的有效性。

1 数据集的制作

1.1 采集裂缝图像

图像采集于已投入使用的包括桥梁、挡土墙、大坝和隧道等各种混凝土结构,经过一周的采集,共计采集到1 226张分辨率为4 032×3 024的三通道RGB原始混凝土裂缝图像。为了让网络学习到更多不同背景噪声条件下的裂缝特征,反映混凝土结构在服役期间所处的真实环境,采集到的裂缝图像包含了不同时间段、不同光照条件、不同污渍情况、不同清晰度等情况的图像,采集到的部分裂缝图像如图1所示。

1.2 图像标注及增强

从1 226张裂缝图像中挑选出250张效果较好的裂缝图像,利用语义分割标注软件Labelme对250张裂缝图像进行标注,标注过程如图2所示,不同于目标检测任务中的数据标注,在目标检测中对图像数据的标注仅需用矩形框将目标区域框住,而在语




图 1 混凝土裂缝图像
Fig. 1 Image of concrete cracks

义分割任务的图像标注过程中,需要将裂缝图像放大,并沿着目标的轮廓逐点标注,实现亚像素级别的裂缝标注,标注点间的线宽与裂缝尺寸相比是微不足道的,不会对裂缝几何尺寸测量造成影响。将所有标注点闭合成环即完成对裂缝的标注,闭合区域以外的其他区域为背景区域。



图 2 混凝土裂缝标注过程
Fig. 2 Labeling process of concrete cracks

对标注后的裂缝图像进行切分,将每一张裂缝图像切分成分辨率大小为 512×512 的不重叠区域,并从中剔除缺乏裂缝特征的图像。使用 Labelme 标注的图像会生成记录标注过程中关键点位置信息的 json 文件,但 json 文件并不能作为裂缝语义分割网络训练所需的直接数据,为了将其用于训练,通过编写的 Python 脚本将 json 文件中的位置信息转换为可直接训练的掩码位图 Ground Truth 图像,图 3 为转换后的部分图像。

对标注好的裂缝图像进行数据增强,使用数据扩增工具 Augmentor 对裂缝数据集扩增操作,如旋转、放大、扭曲等,最终得到 5 160 张带有掩码位图的裂缝图像,将数据集命名为 SegCracks,将




图 3 已标注的裂缝图像
Fig. 3 Labeled crack images

SegCracks 按 7: 2: 1 划分成训练集、验证集和测试集。

2 M-UNet 裂缝语义分割网络

2.1 改进的 MobileNet_V2 网络

MobileNet_V2^[13]是一种适用于移动设备的轻量级的卷积神经网络,其核心是采用反向残差的深度可分卷积代替了普通卷积,使用深度可分卷积可显著降低网络计算复杂度,减少参数量。MobileNet_V2 在网络训练中使用的激活函数为 ReLU6,并采用批量标准化 Batch Normalization 和 Dropout 操作,以达到加快网络收敛速度和防止过拟合现象。对 MobileNet_V2 的改进主要有以下两方面。

一是对网络结构层进行修剪,减少线性瓶颈结构 bottleneck 的重复次数,以减少网络复杂度并且进一步轻量化模型,改进后的 MobileNet_V2 网络结构如表 1 所示。

二是优化了原始网络的激活函数。激活函数是神经网络处理非线性问题的关键,在 MobileNet_V2

表 1 改进后的 MobileNet_V2 网络结构

Table 1 Network structure of improved MobileNet_V2

输入	操作	扩展率 t	特征矩阵深度 c	重复次数 n	步距 s
$224^2 \times 3$	Conv2d		32	1	2
$112^2 \times 32$	Bottleneck	1	16	1	1
$112^2 \times 16$	Bottleneck	6	24	2	2
$56^2 \times 24$	Bottleneck	6	32	2	2
$28^2 \times 32$	Bottleneck	6	64	3	2
$14^2 \times 64$	Bottleneck	6	96	2	1
$14^2 \times 96$	Bottleneck	6	160	2	2
$7^2 \times 160$	Bottleneck	6	320	1	1
$7^2 \times 320$	Conv2d $\times 1$		1 280	1	1
$7^2 \times 1 280$	Avgpool 7×7			1	
$1 \times 1 \times 1 280$	Conv2d 1×1		1 000		

V2网络中使用的是ReLU6激活函数,函数图像如图4(a)所示,虽然ReLU6激活函数可以显著提高网络非线性映射能力,但由其函数图象也可看出,当 $x < 0$ 时,激活函数的梯度为零,并且在其后面的神经元梯度也将变为零,神经元坏死后不会对传入的数据响应,参数也得不到更新。因此,对原网络激活函数进行优化,引入LeakyReLU激活函数,其表达式如式(1)所示,其函数图像如图4(b)所示。与ReLU6激活函数相比,使用LeakyReLU不仅能有效解决ReLU6梯度消失和神经元坏死等问题,而且因其函数图象左侧的软饱和性使其具备更强的噪声干扰抵抗能力。

$$f(x) = \begin{cases} x & x \geq 0 \\ \alpha x & x < 0 \end{cases} \quad (1)$$

式中: α 为偏移量,默认值为0.01。




图4 原激活函数和改进的激活函数

Fig. 4 Original and improved activation function

2.2 M-Unet网络

U-Net^[14]网络主要是由左边的压缩路径和右边的扩展路径两部分组成,是一种典型的编码-解码结构,如图5所示。压缩路径由 3×3 的卷积层和 2×2 的池化层组成,主要用于对裂缝图像特征信息的逐层提取和压缩,而扩展路径由卷积层和反卷积层组成,用于还原裂缝图像特征的位置信息,从而实现端到端的裂缝检测。U-Net网络的压缩路径在池化操作前都会自动保存裂缝特征图像,并以跳跃连接的方式将裂缝图像特征传输给对应的扩展路径部

分,这样可以有效弥补因池化操作而丢失的裂缝特征信息。




图5 U-Net网络结构

Fig. 5 Network structure of U-Net

U-Net网络的下采样部分通常是参数数量很大的VGG16网络,在裂缝分割任务中会消耗大量的计算资源,难以满足在实际工程应用中的实时性要求。轻量级卷积神经网络MobileNet_V2的模型参数数量仅为VGG16网络的1/41,为了进一步降低对设备性能的要求和提高裂缝语义分割速度,对U-Net网络进行优化,采用改进后MobileNet_V2网络替换U-Net网络的下采样部分,以实现模型的轻量化、减少计算复杂度并提高裂缝的语义分割效果,将优化后的轻量级语义分割网络命名为M-Unet。

3 实验与结果分析

3.1 实验环境与实验设置

实验硬件环境为第10代英特尔处理器i7-10700,32 GB的运行内存,NVIDIA GeForce RTX 2060显卡,显存为6 GB。软件环境为64位Windows 10操作系统,使用高级程序设计语言Python,在深度学习框架Pytorch下运行。

实验使用的数据集为SegCracks数据集,经过超参数的调优,最终选取批量大小为4、Adam自适应学习率优化器和指数衰减学习率的组合。共设置4组实验:第1组实验为对比3种损失函数,选取1种最适用于裂缝语义分割任务的损失函数;第2组实验是对提出的M-Unet网络进行迭代训练,通过多种指标对网络的性能进行分析;第3组实验是将M-Unet网络与3种主流的深度学习语义分割网络 and 传统图像处理方法的裂缝分割结果进行对比分析,以验证提出方法的有效性;第4组实验是为验证网络的泛化能力,在CFD^[15]、CRACK500^[16]、GAPS384^[17]3个开源数据集进行交叉验证。

3.2 模型性能评价指标

通常情况下,单一的准确率评判标准不一定能全面反映网络的裂缝分割效果,为更加全面准确地评估网络性能而引入混淆矩阵。混淆矩阵是一种可视化工具,其中每一行表示网络预测值,每一列表示真实值,通过将网络的预测结果和真实结果放

在同一个表中,混淆矩阵能清楚地表示出每个类别识别正确和错误的数量,如表 2 所示。

表 2 混淆矩阵
Table 2 Confusion matrix

混淆矩阵		真实值	
		裂缝	背景
预测值	裂缝	TP	FP
	背景	FN	TN

由混淆矩阵可以定义裂缝语义分割网络的重要评价指标,包括交并比(IoU)、精确率(Precision)、召回率(Recall)和 F1_Score,其值越高,表示网络的裂缝语义分割越好、综合性能越优,计算公式如式(2)~式(5)。

$$I = \frac{T_p}{T_p + F_p + F_n} \quad (2)$$

$$P_r = \frac{T_p}{T_p + F_p} \quad (3)$$

$$R = \frac{T_p}{T_p + F_n} \quad (4)$$

$$F_1 = \frac{2 \cdot P_r \cdot R}{P_r + R} \quad (5)$$

式中: T_p 、 F_p 、 F_n 分别为表 2 中的 TP、FP、FN; I 为模型的预测窗口与原来标记窗口的交叠率,是语义分割中常用的一种度量标准; P_r 为正确预测为裂缝占全部预测为裂缝的比值; R 为正确预测为裂缝占全部实际为裂缝的比值; F_1 为精确率和召回率的调和指标。

3.3 损失函数的选取

损失函数用于衡量预测值和真实值之间的误差,其决定了网络的训练方法,在网络训练优化过程中起指导性作用,可通过损失函数的反馈来调整和改进模型的权重系数。第 1 组实验是对比语义分割领域常用的 Dice Loss、BCE Loss 和 BCEWithLogits Loss 损失函数的性能,在其余参数相同的情况下,经过 10 轮的迭代,3 种损失函数的训练集损失曲线如图 6 所示、验证集损失曲线如图 7 所示。可以看出,在训练集损失曲线图中,选用不同损失函数的损失




图 6 训练集损失曲线

Fig. 6 Loss curves of training set

值随着迭代次数不断增加而逐渐降低,网络逐渐收敛。在验证集损失曲线图中,选用 Dice Loss 损失函数的模型损失值明显小于其余两种,对网络的优化有更好的指导作用。因此,选用 Dice Loss 作为搭建网络的损失函数。




图 7 验证集损失曲线

Fig. 7 Loss curves of verification set

3.4 测试模型性能

采用构建的 SegCracks 数据集对搭建的 M-UNet 网络进行训练,经过 50 次迭代后,网络损失值变化曲线如图 8 所示,可以看出,迭代 35 次以后损失值变化波动趋于稳定,网络开始收敛,且验证集准确率小于训练集准确率,未产生过拟合现象。IoU_Score 变化曲线和 F1_Score 变化曲线如图 9 和图 10 所示,量化结果如表 3 所示,提出的网络在训练集和验证集上获得的 IoU_Score 分别为 97.34% 和 96.10%, F1_Score 分别为 98.65% 和 97.99%,在 SegCracks 数据集上取得了较好的裂缝分割结果,表明所提出的网络模型具有良好的性能。使用完成训练后保存的最优网络权重对测试集进行测试,结果表明分割一张裂缝图像所需时间为 0.211 s,




图 8 损失值变化曲线

Fig. 8 Variation curves of loss value




图 9 IoU_Score 变化曲线

Fig. 9 Variation curves of IoU_Score

满足了实际工程应用中对实时性的要求。




图 10 F1_Score 变化曲线

Fig. 10 Variation curves of F1_Score

表 3 网络评价指标结果

Table 3 Results of network evaluation indicators

数据集	Loss	IoU_Score/%	F1_Score/%
训练集	0.134 9	97.34	98.65
验证集	0.200 7	96.10	97.99

3.5 不同模型性能对比

将搭建的 M-Unet 网络与 U-Net、FCN8 和 SegNet 主流语义分割网络模型进行对比分析,采用建立的数据集进行训练,经过 50 次迭代后 4 种网络的评价指标如表 4 所示,模型权重文件大小和每轮迭代所需时间如图 11 所示。由图 11 可知,FCN8 网络模型权重文件较大且运行时间长,难以应用于现场检测移动端平台并满足实时检测的需求,SegNet 网络虽然权重文件最小,但其迭代时间和预测时间均比 M-Unet 网络长,且裂缝分割效果不如 U-Net 网络和 M-Unet 网络。搭建的网络迭代时间最短,相比于 U-Net 网络,由于 M-Unet 网络采用改进后的 MobileNet_V2 替换了原 U-Net 网络中参数量巨大的下采样部分,使得权重文件大小减少了 7%,迭代时间缩短 63.3%。

表 4 不同网络结果对比

Table 4 Comparison of results for different networks

网络	数据集	Loss	IoU_Score/%	F1_Score/%	预测速度/(s/张)
FCN8	训练集	0.378 5	90.79	95.14	1.577
	验证集	0.563 5	87.10	93.05	
SegNet	训练集	0.160 5	94.05	96.92	0.482
	验证集	0.317 5	89.56	94.43	
U-Net	训练集	0.158 1	94.40	97.10	0.672
	验证集	0.315 6	90.31	94.85	
M-Unet	训练集	0.134 9	97.34	98.65	0.211
	验证集	0.200 7	96.10	97.99	

由表 4 可以看出,在 4 个网络模型中, M-Unet 网络在训练集和验证集上的 IoU_Score 和 F1_Score 均最高,网络损失值最小,对裂缝的语义分割效果最好,且对裂缝的预测时间最短,分割一张裂缝的




图 11 权重文件大小及迭代时间

Fig. 11 Weight file size and iteration time

时间仅为 SegNet 的 43.88%、U-Net 的 31.40%、FCN8 的 13.38%。与未改进的 U-Net 网络相比, M-Unet 网络在测试集上分割一张裂缝图像时间仅需 0.211 s,比 U-Net 缩短了 68.6%,且 IoU_Score 和 F1_Score 有较大的提升,在训练集上分别提升 2.94% 和 1.55%,在验证集上分别提升 5.79% 和 3.14%。综上, M-Unet 网络在实现模型轻量化的同时提升了对裂缝的分割精度,验证了改进方法的有效性。

除与几种主流深度学习语义分割网络进行对比外,还将传统图像处理方法中基于 Prewitt 算子、Canny 算子、Sobel 算子 3 种边缘检测方法^[18]以及大津阈值法 Otsu^[19]与网络分割结果进行对比分析,不同方法的裂缝分割效果如图 12 所示。由图 12 可以看出,传统图像处理方法受噪声影响较大,分割结果中噪声干扰点较多,其中大津阈值法 Otsu 受噪声和光照不均的影响最大,只能分割出部分裂缝,漏检问题较严重,难以满足实际需求。基于边缘检测方法能分割出裂缝大致形状,分割效果优于大津阈值法,但抵抗噪声能力差,分割结果中也存在较多噪声点,裂缝分割效果一般。其中基于 Canny 算子




图 12 不同方法语义分割结果

Fig. 12 Semantic segmentation results of different methods

在分割细小的裂缝时难以保证裂缝边缘的连续性,存在部分漏检问题。相比于以上 4 种传统图像处理裂缝分割方法,基于深度学习的 M-Unet 网络通过堆叠多层卷积层,可更好地提取裂缝更抽象的和更高层的特征,能够获得丰富的裂缝信息,且具有较强的去噪能力,提出的 M-Unet 网络分割结果中仅有极少量的噪声干扰点,且裂缝的连续性好,边缘分割结果清晰,表明该方法具有比传统图像处理方法更好的裂缝语义分割效果。

3.6 不同数据集上交叉验证

为进一步验证网络的性能,在 CFD、CRACK500 和 GAPS384 三个开源数据集上进行交叉验证。3 个数据集上包含多种不同背景,不同噪声和不同形态特征的裂缝,契合混凝土结构服役运营期间所处的实际环境。M-Unet 网络在 3 种不同数据集上的模型评价指标如表 5 所示,其中 IoU_Score 均达到了 97% 以上, F1_Score 均达到了 98% 以上,表明优化后的 M-Unet 网络在新的数据集上也能获得很高的裂缝分割精度,具有良好的鲁棒性和泛化能力,可满足实际工程对裂缝检测的需求。

表 5 交叉验证结果

Table 5 Results of cross validation

数据集	IoU_Score/%	F1_Score/%
CFD	98.94	99.49
CRACK500	97.20	98.58
GAPS384	98.90	99.04

4 结论

针对混凝土结构裂缝检测量大、噪声干扰多和检测时间较长等问题,提出 M-Unet 轻量级裂缝语义分割网络,实现了对混凝土裂缝图像在像素级上的分类,并进行多组对比实验,得出以下结论:

1) 构建包含 5 160 张裂缝图像的 SegCracks 数据集,并基于此训练集对 M-Unet 网络迭代优化,优化后的 M-Unet 网络获得 IoU_Score 为 96.10%, F1_Score 为 97.99%,对裂缝的分割效果优于主流语义分割网络 U-Net、FCN8 和 SegNet,且在保持高检测精度的同时大幅降低模型权重文件体积和减少裂缝分割时间。

2) M-Unet 通过将改进 MobileNet_V2 轻量级网络替换 U-Net 的编码器部分,与原始 U-Net 相比,在实现模型轻量化的同时提高裂缝的分割精度,使得权重文件大小减少了 7%,迭代一轮时间缩短 63.3%,预测时间缩短 68.6%,在验证集上获得的 IoU_Score 和 F1_Score 分别提升 5.79% 和 3.14%,

证明了改进方法的有效性。

3) 与传统的图像处理方法相比,提出的 M-Unet 网络对混凝土裂缝语义分割具有更强的抗噪性,且裂缝分割结果连续性好,边缘清晰,很好地契合了裂缝的实际走向和形状。

4) 将 M-Unet 网络在 CFD、CRACK500 和 GAPS384 三个开源数据集上进行交叉验证,获得的 IoU_Score 均达到了 97% 以上, F1_Score 均达到了 98% 以上,表明搭建的网络具有精度高、鲁棒性好和泛化能力强等优点。

参考文献

- [1] LI Y, ZHANG J H, GUAN Z G, et al. Experimental study on the correlation between crack width and crack depth of RC beams [J]. Materials, 2021, 14(20): 5950.
- [2] 舒江鹏, 李俊, 马亥波, 等. 基于特征金字塔网络的超大尺寸图像裂缝识别检测方法[J]. 土木与环境工程学报(中英文), 2022, 44(3): 29-36.
SHU J P, LI J, MA H B, et al. Crack detection method based on feature pyramid network for super large-scale images [J]. Journal of Civil and Environmental Engineering, 2022, 44(3): 29-36. (in Chinese)
- [3] DONG J X, LIU J H, WANG N N, et al. Intelligent segmentation and measurement model for asphalt road cracks based on modified mask R-CNN algorithm [J]. Computer Modeling in Engineering & Sciences, 2021, 128(2): 541-564.
- [4] ZHANG L X, SHEN J K, ZHU B J. A research on an improved Unet-based concrete crack detection algorithm [J]. Structural Health Monitoring, 2020, 20(4): 1864-1879.
- [5] ZHAO Z Q, ZHENG P, XU S T, et al. Object detection with deep learning: A review [J]. IEEE Transactions on Neural Networks and Learning Systems, 2019, 30(11): 3212-3232.
- [6] 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.
- [7] 胡文魁, 邓晖, 付志旭, 等. 基于全卷积神经网络的桥梁裂缝分割和测量方法[J]. 工业建筑, 2022, 52(4): 192-201, 218.
HU W K, DENG H, FU Z X, et al. Bridge crack segmentation and measurement method based on full convolutional neural network [J]. Industrial Construction, 2022, 52(4): 192-201, 218. (in Chinese)
- [8] 李良福, 马卫飞, 李丽, 等. 基于深度学习的桥梁裂缝检测算法研究[J]. 自动化学报, 2019, 45(9): 1727-1742.

- LI L F, MA W F, LI L, et al. Research on detection algorithm for bridge cracks based on deep learning [J]. *Acta Automatica Sinica*, 2019, 45(9): 1727-1742. (in Chinese)
- [9] LIU Z Q, CAO Y W, WANG Y Z, et al. Computer vision-based concrete crack detection using U-net fully convolutional networks [J]. *Automation in Construction*, 2019, 104: 129-139.
- [10] REN Y P, HUANG J S, HONG Z Y, et al. Image-based concrete crack detection in tunnels using deep fully convolutional networks [J]. *Construction and Building Materials*, 2020, 234: 117367.
- [11] XUE Y D, LI Y C. A fast detection method via region-based fully convolutional neural networks for shield tunnel lining defects [J]. *Computer-Aided Civil and Infrastructure Engineering*, 2018, 33(8): 638-654.
- [12] 王森, 伍星, 张印辉, 等. 基于深度学习的全卷积网络图像裂纹检测[J]. *计算机辅助设计与图形学学报*, 2018, 30(5): 859-867.
- WANG S, WU X, ZHANG Y H, et al. Image crack detection with fully convolutional network based on deep learning [J]. *Journal of Computer-Aided Design & Computer Graphics*, 2018, 30(5): 859-867. (in Chinese)
- [13] SANDLER M, HOWARD A, ZHU M L, et al. MobileNetV2: Inverted residuals and linear bottlenecks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA. IEEE, 2018: 4510-4520.
- [14] 朱苏雅, 杜建超, 李云松, 等. 采用U-Net卷积网络的桥梁裂缝检测方法[J]. *西安电子科技大学学报*, 2019, 46(4): 35-42.
- ZHU S Y, DU J C, LI Y S, et al. Method for bridge crack detection based on the U-Net convolutional networks [J]. *Journal of Xidian University*, 2019, 46(4): 35-42. (in Chinese)
- [15] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2020, 42(2): 318-327.
- [16] YANG F, ZHANG L, YU S J, et al. Feature pyramid and hierarchical boosting network for pavement crack detection [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2020, 21(4): 1525-1535.
- [17] EISENBACH M, STRICKER R, SEICHTER D, et al. How to get pavement distress detection ready for deep learning? A systematic approach [C]//2017 International Joint Conference on Neural Networks (IJCNN). Anchorage, AK, USA. IEEE, 2017: 2039-2047.
- [18] DORAFSHAN S, THOMAS R J, MAGUIRE M. Comparison of deep convolutional neural networks and edge detectors for image-based crack detection in concrete [J]. *Construction and Building Materials*, 2018, 186: 1031-1045.
- [19] CHEN X L, LI J, HUANG S W, et al. An automatic concrete crack-detection method fusing point clouds and images based on improved otsu's algorithm [J]. *Sensors*, 2021, 21(5): 1581.

(编辑 胡英奎)