

基于改进 Mask R-CNN 的混凝土坝 裂缝像素级检测方法

牛慧余¹, 包腾飞^{1,2,3}, 李扬涛¹, 黄思文¹

(1. 河海大学水利水电学院, 江苏 南京 210098;

2. 河海大学水文水资源与水利工程科学国家重点实验室, 江苏 南京 210098;

3. 三峡大学水利与环境学院, 湖北 宜昌 443002)

摘要:为解决传统人工巡检混凝土坝裂缝效率低下的问题,将人工智能和计算机视觉技术相结合,提出了复杂背景下混凝土坝裂缝像素级精细化自动识别分割方法。为克服复杂环境背景因素干扰,基于多种数字图像处理手段对混凝土坝裂缝图像进行预处理,有效去除环境噪声。在 Mask R-CNN 基础上,对模型主干网络进行改进以提升裂缝特征提取能力。采集 500 幅包含单裂缝、多裂缝、交叉裂缝、龟裂等多种裂缝形态的混凝土坝裂缝图像用于模型训练与验证,并采用定性分析和定量评估相结合的手段多维度评估模型泛化能力和鲁棒性。结果表明:改进 Mask R-CNN 对含有多种裂缝特征及噪声背景的裂缝图像识别效果良好,模型在测试集上的目标检测和分割掩码平均精确度分别达 76.3 和 61.9,满足高精度裂缝精细分割要求;与 Cascade-Mask R-CNN、Yolact++ 等基准模型相比,改进 Mask R-CNN 在目标检测、分割掩码精确度及模型推理速度多方面均有一定的优势。

关键词:混凝土坝;裂缝检测;实例分割;改进 Mask R-CNN;人工智能

中图分类号:TV698.1

文献标志码:A

文章编号:1006-7647(2023)01-0087-06

Pixel-level crack detection method of concrete dam based on improved Mask R-CNN//NIU Huiyu¹, BAO Tengfei^{1,2,3}, LI Yangtao¹, HUANG Siwen¹(1. College of Water Conservancy and Hydropower Engineering, Hohai University, Nanjing 210098, China; 2. State Key Laboratory of Hydrology-Water Resources and Hydraulic Engineering, Hohai University, Nanjing 210098, China; 3. College of Hydraulic & Environmental Engineering, China Three Gorges University, Yichang 443002, China)

Abstract: In order to solve the problem of low efficiency of traditional manual inspection, artificial intelligence and computer vision technology was combined to propose a pixel-level refined automatic identification and segmentation method for concrete dam cracks under complex backgrounds. To overcome the interference of complex environmental background factors, the concrete dam crack image is preprocessed based on various digital image processing methods to effectively remove environmental noise. Based on the Mask R-CNN instance segmentation model, the model backbone network is optimized to improve the crack feature extraction ability. In the experiment, 500 images of concrete dam cracks, including single crack, multiple cracks, cross cracks, map cracks and other crack forms, were collected for model training and verification. A combination of qualitative analysis and quantitative evaluation was used to evaluate the generalization ability and robustness of the model in multiple dimensions. The test results show that the improved Mask R-CNN model in this paper has a good effect on crack image recognition with various crack features and noise backgrounds. The average accuracy values of the model's target detection and mask segmentation on the test set are 76.3 and 61.9, respectively, which can meet the requirements of high-precision fine segmentation for cracks. Compared with benchmark models such as Cascade-Mask R-CNN and Yolact++, the improved Mask R-CNN method has certain advantages in object detection, mask segmentation accuracy and model inference speed.

Key words: concrete dam; crack detection; instance segmentation; improved Mask R-CNN; artificial intelligence

混凝土坝是最常见的水工建筑物,由于其长期暴露于大气与水环境中,因此在流水冲刷、化学腐

蚀、冻融破坏等外界作用下,表面容易出现裂缝^[1-2],严重危害了混凝土坝的整体结构安全。工程中,识

基金项目:国家重点研发计划(2018YFC1508603)

作者简介:牛慧余(1998—),男,硕士研究生,主要从事水工结构安全检测研究。E-mail:nhy@hhu.edu.cn

通信作者:包腾飞(1974—),男,教授,博士,主要从事水工结构及岩土工程安全监控理论与方法研究。E-mail:baotf@hhu.edu.cn

别混凝土坝裂缝,并对其进行及时修补,对保障大坝在全生命周期内安全运行具有重要意义。

传统的混凝土坝裂缝检测主要依赖管理人员的定期巡检,人工巡检耗时长、效率低。通过拍摄设备采集裂缝图像,利用图像处理算法进行自动化识别可提升裂缝检测效率。目前混凝土结构裂缝图像处理算法主要有图像分割算法(阈值分割^[3-6]、边缘检测^[7-8]与数学形态学^[9-10]等)和机器学习算法,多应用于道路、桥梁等传统建筑领域;刘晓瑞等^[11]基于不同的阈值分割算法,给出了隧道表面裂缝快速检测技术;徐港等^[12]提出了一种基于多种连通域特征的工程结构表面裂缝提取方法;Katakam^[13]对路面图像进行分块,并进行阈值分割,成功提取出路面裂缝,但是该算法对图像质量要求比较高,且未对背景复杂的情况进行验证;Nishikawa 等^[14]提出了一种强鲁棒性的针对混凝土建筑物表面裂缝检测的方法;Chun 等^[15]提出一种基于两步轻度梯度提升机的混凝土表面裂缝自动检测方法,并以一座运行多年的混凝土桥作为实例验证模型有效性。针对水工建筑物的裂缝检测问题,王一兵等^[16]提出了基于LabVIEW+VDM 的混凝土坝裂缝检测方法;张小伟等^[17]提出一种基于自适应区生长和局部 K-Means 聚类的坝面裂缝检测算法;Rezaiee-Pajand 等^[18]提出了一种基于遗传算法的混凝土溢流重力坝裂缝检测方法,提取二维裂缝特征进行非线性分析,最终确定裂缝的位置和大小。但图像处理算法多针对某一特定场景设计,检测过程需要对每一张图像人工调参,并手动构建裂缝特征,很依赖工程师的调参经验,具有很大的局限性。此外,数字图像处理方法对海量图像数据处理效率较低,难以满足裂缝图像快速识别的要求。

随着计算机技术的发展,基于深度学习的卷积神经网络(convolutional neural network, CNN)在目标检测领域具有良好的效果,可以自主地从图像数据集中学习特征,避免了传统图像处理算法存在的局限性。目前 CNN 卷积神经网络已在混凝土结构裂缝检测领域得到应用^[19-20],虽然其可以进行混凝土裂缝图像识别,但无法精细化分割裂缝的形态、获取裂缝特征。针对这一问题,He 等^[21]通过改进 Faster R-CNN^[22]网络,于 2017 年提出了 Mask R-CNN,解决了精细化像素级的实例分割问题。

混凝土坝裂缝图像语义信息较为丰富,裂缝呈现单裂缝、多裂缝、交叉裂缝、龟裂等多形态特征,对深度学习模型的特征提取能力要求较高,且背景区域可能含有噪声、光照阴影等不利因素,严重影响模型的裂缝识别效果。为克服复杂环境背景因素干

扰,提升模型的图像特征提取能力,本文基于多种数字图像处理手段对混凝土坝裂缝图像进行预处理,并在 Mask R-CNN 的基础上,将 ResNet101+FPN 网络作为主干网络进行结构改进,提升模型的特征提取能力,对复杂背景下的混凝土大坝裂缝图像进行精细分割,获取裂缝的几何形态特征,并对改进 Mask R-CNN(以下简称本文模型)进行验证。

1 混凝土坝裂缝实例分割方法

1.1 复杂条件下混凝土坝的裂缝图像预处理

混凝土坝服役环境恶劣,设备采集的裂缝图像普遍存在光照不均、噪声干扰多的问题。此外,无人机等移动设备在图像获取过程中,易出现运动模糊,这些不利因素严重影响视觉检测模型的裂缝识别效果。基于此,本文提出一套组合图像预处理方法,可有效克服混凝土坝裂缝图像光照不均、噪声干扰和运动模糊的问题,提升后续裂缝分割与提取效果。

a. 直方图均衡化。直方图均衡化是一种有效处理图像光照不均的图像增强技术。直方图统计了图像中灰度值出现的概率分布情况,低照度图像的直方图分量集中于低灰度级区域,而灰度鲜明、对比度强的图像则集中于高灰度级区域。因此,可通过改变图像的直方图分布,使图像像素的每级灰度都分布均匀,以增强对比度,突出裂缝信息表达。直方图均衡计算公式为

$$s_k = (l - 1) \sum_{i=0}^k p(r_i) \quad (1)$$

式中: k 为归一化前的灰度级; s_k 为均衡化后各像素的灰度级; l 为灰度级数量; r_i 为灰度; $p(r_i)$ 为相应的直方图灰度概率值。

b. 双边滤波。双边滤波是一种消除图像背景噪声,增强重要特征信息的图像处理方法,能够保留边缘特征,使边缘不易被柔化处理。混凝土坝图像中裂缝边缘特征属于高频细节信息,因此采用非线性滤波处理能够有效地保留裂缝细节信息。双边滤波是常用的非线性滤波器,根据邻域像素加权组合输出滤波后的像素值。双边滤波计算公式为

$$f_{j,h} = \frac{\sum_{m,n} I_{m,n} w_{j,h,m,n}}{\sum_{m,n} w_{j,h,m,n}} \quad (2)$$

式中: $f_{j,h}$ 为中心点坐标滤波后的值; $I_{m,n}$ 为领域(m, n)内的图像像素; $w_{j,h,m,n}$ 表示像素(j, h)对应领域(m, n)的权重。

c. 维纳滤波。维纳滤波是一种自适应最小均方误差滤波方法,在图像复原领域有着良好的效果。它能根据图像的局部方差调整滤波器的输出,局部

方差越大,对图像的平滑作用越强,最终目的是使复原图像与原始图像的均方误差最小。

1.2 Mask R-CNN 基本原理

实例分割是一种兼具目标分类、目标检测和像素级分割的图像识别任务,在目标检测的基础上进行图像掩码的分割以达到实例分割的效果,可以看作语义分割与目标检测的结合。Mask R-CNN 是一种通用实例分割模型,在 Faster R-CNN 网络的基础上引入了掩码预测分支,并以 ROI Align 层替换 Faster R-CNN 网络中的 ROI Pooling 层,避免了 RPN 网络输出的特征图不是按照像素对齐影响掩码预测分支精度的问题。

Mask R-CNN 网络结构如图 1 所示,基本流程为:①将原始图像传入主干网络中获取特征图,对特征图中的每一点设定 ROI,获得多个 ROI 候选框;将 ROI 候选框输入区域生成网络(RPN)进行前景或后景的二值分类候选框回归,以获得目标的候选框。②获得特征图和候选框后,传入 ROI Align 层将特征图与目标的候选框进行匹配,并池化为固定大小,借助全连接层将特征图输入目标检测网络,利用分类分支对每个 ROI 区域输出对应的最大置信度标签。③检测分支预测并获得每个 ROI 区域的边界框。④掩码预测分支预测每个 ROI 最大置信度的分割掩码,将各分支输出进行汇总,得到包含目标类别、分类框和分割掩码的图像,完成像素级实例分割。

1.3 Mask R-CNN 的改进

神经网络的深度是影响模型训练效果的重要因素,网络层数增加,意味着提取到的目标特征更丰富。但训练很深的神经网络是一件比较难的事情。随着神经网络层数的增加,网络学习的效果反而比层数较少的神经网络更差^[23],这不仅是模型过拟合的原因,梯度爆炸或梯度消失成为训练更深的神经网络的阻碍,导致训练无法收敛。

He 等^[23]提出了深度残差网络(deep residual networks, ResNet),在不增加网络计算复杂度的前提

下,解决了训练深层次神经网络梯度弥散而导致无法收敛的问题。笔者通过多次训练对比发现,对于混凝土坝裂缝的目标特征,Mask R-CNN 骨干网络选取 ResNet101 时的识别效果比 ResNet50 更好(图 2)。因为混凝土大坝裂缝属于精细的图像特征,更深层次的神经网络有利于进行精细识别,提高网络的特征抽象能力。但直接使用 ResNet101 的最后一层全连接层作为特征输出,对微小裂缝的特征检测效果较差。这是因为对于目标检测网络,浅层次网络提取的特征语义信息较少但目标位置准确;深层次网络提取特征的语义信息丰富,但目标位置不够精准。特征金字塔网络(feature pyramid networks, FPN)^[24]设计了上采样与侧向连接结合的结构,上采样可以获取更丰富语义信息,侧向连接可以获得更准确的目标位置信息。特征金字塔网络结构兼顾了底层特征和语义信息,不同尺度提取的特征都具有丰富的语义信息。因此,本文选取 ResNet101 + FPN 作为 Mask R-CNN 的骨干网络对混凝土坝裂缝图像进行特征提取。

1.4 评价指标

为了更直观地评价 Mask R-CNN 对混凝土大坝裂缝图像的分割效果,选取损失函数、准确率、平均精确度(AP)定量地评估裂缝分割效果。

损失函数描述了模型预测值与真实值间的差距大小,其在训练过程中指导模型朝着收敛的方向前进。Mask R-CNN 实例分割任务中,损失函数 $L = L_{cls} + L_{box} + L_{mask}$ ^[21],其中 L_{cls} 、 L_{box} 、 L_{mask} 分别为分类误差、检测误差和分割误差。损失函数越小,检测效果越好。

准确率 A 指在目标检测任务中,使用模型对数据集进行分类,分类正确的样本数占总样本数数的比例:

$$A = \frac{T_p + T_N}{T_p + T_N + F_p + F_N} \tag{3}$$

式中: T_p 为实际为正例且被分类器划分为正例的样本数; T_N 为实际为正例且被分类器划分为负例的样本数; F_p 为实际为负例但被分类器划分为正例的样




图 1 Mask R-CNN 网络结构




图2 不同层数 ResNet 网络下 Mask R-CNN 的训练过程对比

本数; F_N 为实际为负例且被分类器划分为负例的样本数。 A 越大,表示检测结果越准确。

平均精确度是使用 coco 数据集实现目标检测任务和实例分割任务的通用评价指标^[21]。本文 AP_{50} 、 AP_{75} 、 AP_S 、 AP_M 、 AP_L 分别为交并比阈值为 0.50、0.75 及目标尺寸为小、中、大 3 个级别的平均精确度。

2 实例验证

2.1 图像的采集与预处理

数据采集于中国西北地区某混凝土大坝,为了方便训练、提高训练速度,将 5 616×3 744 的原图分割后缩放为 200×200 的裂缝图像,并根据第 1.1 节的图像增强方法对裂缝图像进行预处理,以降低裂缝图像不利因素干扰。

考虑到混凝土坝裂缝形态特征多样、噪声干扰多、语义信息丰富的特点,选取 500 张包含单裂缝、多裂缝、交叉裂缝、龟裂等多种裂缝形态特征以及背景含有噪声干扰的裂缝图像,按照训练集、验证集测试集为 3 : 1 : 1 的比例划分数据集图像,即训练集 300 张、验证集 100 张、测试集 100 张,其中训练集用于模型训练,验证集用于模型验证及参数调整,测试集用于测试模型泛化能力。

Mask R-CNN 属于有监督学习模型,需要对裂缝图像进行标注构建训练集。标注时沿着裂缝轮廓取点进行多边形的标注(图 3),得到含有目标裂缝的轮廓掩码信息的 json 文件,最终 json 文件转化为 coco 数据集输入神经网络进行训练。



图3 裂缝图像标注过程

2.2 试验平台

本文采用的深度学习模型是商汤和香港中文大学联合开源的 Mmdetection 架构下的 Mask R-CNN 开源代码(<https://github.com/open-mmlab/mmdetection>),骨干网络使用 ResNet101+FPN,在 PC 试验平台进行训练,试验平台配置:操作系统为 Windows 10,CPU 为 AMD Ryzen 5 3600,GPU 为 GeForce GTX 1660 SUPER,GPU 加速为 CUDA 10.1+cuDNN7.6.5,深度学习框架为 Pytorch1.6。

根据试验训练数据集和平台配置要求,模型训练配置参数设置如下:目标类别数为 1,检测类别为“crack”;批次处理大小为 2,线程加载数为 1;训练轮次为 100,初始学习率为 0.02,并使用 SGD 优化器进行梯度下降优化,并采取在学习轮次为 8 和 12 后,学习率乘以 0.1 的学习策略。

2.3 结果分析

为验证本文模型对混凝土大坝裂缝图像分割的效果,按照第 1.3 节提出的改进方法进行模型训练,对训练过程进行损失函数和准确率的可视化输出。利用训练得到的权重文件,测试 100 张测试集图像的裂缝分割效果,并引入多种对比模型评估本文模型在测试集上的裂缝识别精确度和推理速度。

由图 4 可知,随着训练轮次的增加,损失函数不断降低,最终收敛在 0.125 附近,说明模型训练充分,收敛良好;准确率随着训练轮次的增加不断升高最终逼近 100%,说明随着模型的不训练,裂缝图像的分割效果越来越好,证明本文模型对于混凝土大坝裂缝图像分割有着很强的可行性。




图4 Mask R-CNN 训练过程可视化结果

如图 5 所示,面对多裂缝形态特征的图像,模型对每个裂缝单体进行了分割,掩码识别结果与预先标注掩码高度吻合,证明模型分割效果良好,实现了对裂缝图像的实例分割任务。




图5 测试集裂缝图像识别结果

为验证算法去噪效果,选取 3 张包含光照不均、噪声干扰和运动模糊干扰的裂缝图像进行图像预处理,结果如图 6 所示。经预处理,光照不均图像对比度明显增强,裂缝细节更加清晰;噪声干扰图像裂缝周围背景像素变得更加平滑柔和,凸显了裂缝特征;运动模糊图像裂缝明显清晰,证明本文采用的图像增强方法效果良好。模型基于处理后的裂缝图像实现裂缝识别和分割,说明改进 Mask R-CNN 模型能有效检测复杂条件下混凝土大坝裂缝图像。

通过与 Mask R-CNN-R50、Cascade-Mask R-CNN、Yolact++对比,在相同的数据集上训练并在测试集对训练成果进行评估,验证本文模型的优越性。Cascade-Mask R-CNN、Yolact++是目标检测领域近些年较新提出的实例分割模型,在目标检测领域有着良好的效果。不同模型在测试集上评估结果对比




图6 复杂条件下裂缝图像预处理及识别结果

如表 1~3 所示。

由表 1~3 可知,改进 Mask R-CNN 模型比 Mask R-CNN 在目标检测和掩码分割两方面的平均精确度分别提升了 40.7% 和 16.2%,图像识别精确度显著提升;与 Cascade-Mask R-CNN、Yolact++这 2 种较新模型相比,改进 Mask R-CNN 模型在掩码分割精确度方面也有一定的优势;图像评估速度方面,Yolact++是一种检测速度非常快的实例分割模型,在 coco 数据集上最高可达 33.5 帧/s^[25]。本文模型的评估速度优于其他对比模型,仅次于 Yolact++模型,但由于 GPU 的限制,速度差距不是很明显。

3 结 语

改进 Mask R-CNN 对混凝土坝裂缝图像识别效果较好,可以实现裂缝图像实例分割,目标检测和分割掩码的平均精确度值达 76.3 和 61.9;与

表 1 目标检测平均精确度

单位:%

模型	骨干网络	AP	AP ₅₀	AP ₇₅	AP _s	AP _M	AP _L
改进 Mask R-CNN	ResNet101-FPN	51.9	76.3	53.5	21.9	43.7	78.7
Mask R-CNN	ResNet50-FPN	11.2	30.9	5.9	2.5	7.2	28.1
Cascade-Mask R-CNN	ResNet50-FPN	41.5	69.3	43.9	21.2	43.5	64.8
Yolact++	ResNet50	25.6	60.8	18.1	12.9	29.6	36.3

表 2 掩码分割平均精确度

单位:%

模型	骨干网络	AP	AP ₅₀	AP ₇₅	AP _s	AP _M	AP _L
改进 Mask R-CNN	ResNet101-FPN	19.9	61.9	6.6	7.9	17.4	29.4
Mask R-CNN	ResNet50-FPN	3.7	16.9	0.1	1.9	4.5	4.9
Cascade-Mask R-CNN	ResNet50-FPN	15.5	56.7	2.1	9.5	17.6	18.3
Yolact++	ResNet50	5.2	26.1	0.1	0.6	4.9	11.4

表 3 模型推理速度

模型	推理速度/(帧·s ⁻¹)	时间/s	模型	推理速度/(帧·s ⁻¹)	时间/s
改进 Mask R-CNN	13.5	9	Cascade-Mask R-CNN	10.4	12
Mask R-CNN	12	10	Yolact++	15.3	8

ResNet50 结构相比,检测和分割平均精确度分别提升了 40.7% 和 16.2%;与 Cascade-Mask R-CNN、Yolact++模型相比,分割精确度方面也有一定的优势;模型推理速度方面,本文模型较 Cascade-Mask R-CNN 更有优势,仅次于推理速度较快的 Yolact++模型,检测速度约为 13.5 帧/s。

现有研究内容下,模型对于混凝土大坝裂缝图像检测的性能尚有很大的提升空间,如水下检测时,考虑混凝土结构表面附着泥沙或水生动植物等噪声干扰,增加剥落、孔洞等多种大坝损伤特征和基于无人机搭载高清摄像头的大坝实时损伤识别等。

参考文献:

[1] 顾嘉丰,任青文. 水工混凝土弥散型裂缝数值模型中开裂判据的研究[J]. 工程力学,2015,32(6):84-91. (GU Jiafeng, REN Qingwen. Study on hydraulic concrete cracking criterion in smeared crack numerical model[J]. Engineering Mechanics, 2015, 32 (6): 84-91. (in Chinese))

[2] 陈波,刘庭赫,初文婷,等. 水工混凝土裂缝的压电智能骨料感知试验与模拟[J]. 水利水电科技进展,2021,41(6):1-6. (CHEN Bo, LIU Tinghe, CHU Wenting, et al. Sensing experiment and simulation for cracks in hydraulic concrete based on piezoelectric smart aggregates [J]. Advances in Science and Technology of Water Resources, 2021,41(6):1-6. (in Chinese))

[3] 秦武,杜成斌,孙立国. 基于数字图像技术的混凝土细观层次力学建模[J]. 水利学报,2011,42(4):431-439. (QIN Wu, DU Chengbin, SUN Ligu. Meso-level analysis model for concrete based on digital image processing[J]. Journal of Hydraulic Engineering, 2011,42(4):431-439. (in Chinese))

[4] 王宇,李晓,阙介民,等. 基于 CT 图像灰度水平的孔隙率计算及应用[J]. 水利学报,2015,46(3):357-365. (WANG Yu, LI Xiao, QUE Jiemin, et al. A porosity calculation method based on CT images and its application [J]. Journal of Hydraulic Engineering, 2015, 46 (3): 357-365. (in Chinese))

[5] 任文渊,杨贞军,黄宇劼. 基于 X 射线计算断层扫描图像的混凝土细观断裂模拟[J]. 水利学报,2015,46(4):452-459. (REN Wenyan, YANG Zhenjun, HUANG Yujie. Meso-scale fracture modelling of concrete based on X-ray computed tomography images [J]. Journal of Hydraulic Engineering, 2015, 46 (4): 452-459. (in Chinese))

[6] 覃茜,徐千军. 基于 CT 图像的混凝土初始缺陷分布规律研究[J]. 水利学报,2016,47(7):959-966. (QIN Xi, XU Qianjun. Statistics of the initial defects within concrete based on CT image[J]. Journal of Hydraulic Engineering, 2016,47(7):959-966. (in Chinese))

[7] 马建业,郑东健,孙建伟. 基于生物启发神经网络的水下坝面表观裂缝检测路径规划算法[J]. 水利水电科技

进展, 2022, 42 (6): 60-65. (MA Jianye, ZHENG Dongjian, SUN Jianwei. Path planning algorithm for underwater dam surface apparent cracks detection based on bio-inspired neural network [J]. Advances in Science and Technology of Water Resources, 2022,42(6):60-65. (in Chinese))

[8] 张大伟,许梦钊,马莉,等. 水下大坝裂缝图像分割方法研究[J]. 软件导刊,2016,15(9):170-172. (ZHANG Dawei, XU Mengzhao, MA Li, et al. Research on underwater dam crack image segmentation method [J]. Software Guide, 2016,15(9):170-172. (in Chinese))

[9] 甘磊,吴健,戴寿晔,等. 含施工裂缝隧道穿越段堤防渗流和稳定分析[J]. 河海大学学报(自然科学版), 2022,50(1):85-90. (GAN Lei, WU Jian, DAI Shouye, et al. Seepage and stability analysis of embankment with construction cracks in tunnel crossing section [J]. Journal of Hohai University (Natural Sciences), 2022,50(1):85-90. (in Chinese))

[10] 蒋小燕,张松,何松原. 基于格子波尔兹曼模型大坝裂缝检测[J]. 科技视界,2018(11):96-97. (JIANG Xiaoyan, ZHANG Song, HE Songyuan. Dam crack detection based on Lattice Boltzmann model [J]. Science & Technology Vision, 2018(11):96-97. (in Chinese))

[11] 刘晓瑞,谢雄耀. 基于图像处理的隧道表面裂缝快速检测技术研究[J]. 地下空间与工程学报,2009,5(增刊2):1624-1628. (LIU Xiaorui, XIE Xiongyao. Rapid crack inspection of tunnel surface based on image processing [J]. Chinese Journal of Underground Space And Engineering, 2009,5(Sup2):1624-1628. (in Chinese))

[12] 徐港,赵恬悦,蒋赏,等. 基于多种连通域特征的结构表面裂缝提取方法[J]. 华中科技大学学报(自然科学版), 2019,47(10):52-55. (XU Gang, ZHAO Tianyue, JIANG Shang, et al. Extraction method of structural surface cracks based on multiple connected domain features [J]. Journal of Huazhong University of Science and Technology (Nature Science Edition), 2019,47(10):52-55. (in Chinese))

[13] KATAKAM N. Pavement crack detection system through localized thresholding [D]. Toledo : University of Toledo, 2009.

[14] NISHIKAWA T, YOSHIDA J, SUGIYAMA T, et al. Concrete crack detection by multiple sequential image filtering [J]. Computer-Aided Civil and Infrastructure Engineering, 2012,27(1):29-47.

[15] CHUN P J, IZUMI S, YAMANE T. Automatic detection method of cracks from concrete surface imagery using two-step light gradient boosting machine [J]. Computer-Aided Civil and Infrastructure Engineering, 2021,36(1):61-72.

[16] 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. (WANG Yibing, BAO Tengfei, GAO Zhixin. Crack detection method of concrete dams based on LabVIEW+VDM [J]. Advances in Science and Technology of Water Resources, 2021,41(5):76-82. (in Chinese))

(下转第 98 页)

- [7] MING Pan, LU Jun, HU Shaowei, et al. Determination of the optimal decomposition layer of wavelet de-noising based on signal band feature [J]. Russian Journal of Nondestructive Testing, 2019, 55 (1) : 39-47.
- [8] TORRES M E, COLOMINAS M A, SCHLOTTHAUER G, et al. A complete ensemble empirical mode decomposition with adaptive noise [C] // 2011 IEEE International Conference on Acoustics, Speech and Signal Processing. Prague: IEEE, 2011 : 4144-4147.
- [9] 王岩, 张友桃, 胡鸿翔, 等. 基于声发射和人工神经网络的混凝土损伤程度识别 [J]. 建筑材料学报, 2014, 17 (4) : 672-676. (WANG Yan, ZHANG Youtao, HU Hongxiang, et al. Identification of damage degree of concrete by acoustic emission and artificial neural network [J]. Journal of Building Materials, 2014, 17 (4) : 672-676. (in Chinese))
- [10] 易正元, 苏怀智, 杨立夫. 混凝土坝变形监控模型的随机森林与旗鱼优化组合建模方法 [J]. 水电能源科学, 2021, 39 (10) : 106-109. (YI Zhengyuan, SU Huaizhi, YANG Lifu. Deformation monitoring model of concrete dam based on random forest algorithm optimized by sailfish optimization [J]. Water Resources and Power, 2021, 39 (10) : 106-109. (in Chinese))
- [11] 阮永芬, 高春钦, 刘克文, 等. 基于粒子群算法优化小波支持向量机的岩土力学参数反演 [J]. 岩土力学, 2019, 40 (9) : 3662-3669. (RUAN Yongfen, GAO Chunqin, LIU Kewen, et al. Inversion of rock and soil mechanics parameters based on particle swarm optimization wavelet support vector machine [J]. Rock and Soil Mechanics, 2019, 40 (9) : 3662-3669. (in Chinese))
- [12] 潘志刚, 林祥峰, 张继生. 基于支持向量机的桥墩局部冲刷深度预测模型 [J]. 水利水电科技进展, 2021, 41 (6) : 78-81. (PAN Zhigang, LIN Xiangfeng, ZHANG Jisheng. Prediction model for bridge pier local scour depth based on support vector machine [J]. Advances in Science and Technology of Water Resources, 2021, 41 (6) : 78-81. (in Chinese))
- [13] 吴鑫, 赵红霞, 罗筱毓, 等. 基于 BP 神经网络的岩石损伤声发射事件源定位研究 [J]. 中国安全生产科学技术, 2021, 17 (8) : 36-42. (WU Xin, ZHAO Hongxia, LUO Xiaoyu, et al. Study on acoustic emission event source location of rock damage based on BP neural network [J]. Journal of Safety Science and Technology, 2021, 17 (8) : 36-42. (in Chinese))
- [14] 吴贤国, 杨赛, 陈虹宇, 等. 基于随机森林的支持向量机混凝土早期抗裂性预测研究 [J]. 工业建筑, 2020, 50 (9) : 99-105. (WU Xianguo, YANG Sai, CHEN Hongyu, et al. Prediction of early crack resistance of concrete by support vector machine based on random forest [J]. Industrial Construction, 2020, 50 (9) : 99-105. (in Chinese))
- [15] 赵康, 何志伟, 宁富金, 等. 不同灰砂配比胶结材料组合体声发射特性 [J]. 硅酸盐学报, 2021, 49 (11) : 2462-2469. (ZHAO Kang, HE Zhiwei, NING Fujin, et al. Acoustic emission characteristics of cementitious material with different cement-tailing ratio [J]. Journal of the Chinese Ceramic Society, 2021, 49 (11) : 2462-2469. (in Chinese))

(收稿日期: 2021 - 12 - 02 编辑: 俞云利)

(上接第 92 页)

- [17] 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. (ZHANG Xiaowei, BAO Tengfei, GAO Xinghe. Crack detection method of concrete dams based on computer vision [J]. Advances in Science and Technology of Water Resources, 2021, 41 (5) : 83-88. (in Chinese))
- [18] REZAIEE-PAJAND M, TAVAKOLI F H. Crack detection in concrete gravity dams using a genetic algorithm [J]. Proceedings of the Institution of Civil Engineers-Structures and Buildings, 2015, 168 (3) : 192-209.
- [19] LI S, GU X, XU X, et al. Detection of concealed cracks from ground penetrating radar images based on deep learning algorithm [J]. Construction and Building Materials, 2021, 273 : 121949.
- [20] KIM B H, CHO S. Image-based concrete crack assessment using mask and region-based convolutional neural network [J]. Structural Control and Health Monitoring, 2019, 26 (8) : e2381.
- [21] HE K, GKIOXARI G, DOLLAR P, et al. Mask R-CNN [C] // Proceedings of the IEEE international conference on computer vision. Piscataway: IEEE Press, 2017 : 2961-2969.
- [22] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. Advances in neural information processing systems, 2015, 28 : 91-99.
- [23] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C] // Proceedings of the IEEE conference on computer vision and pattern recognition. Piscataway: IEEE Press, 2016 : 770-778.
- [24] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C] // Proceedings of the IEEE conference on computer vision and pattern recognition, Piscataway: IEEE Press. 2017 : 2117-2125.
- [25] BOLYA D, ZHOU C, XIAO F, et al. Yolact: Real-time instance segmentation [C] // Proceedings of the IEEE / CVF International Conference on Computer Vision. Piscataway: IEEE Press, 2019 : 9157-9166.

(收稿日期: 2022 - 01 - 14 编辑: 刘晓艳)