

基于 MobileNetV2-DeepLabv3+ 的混凝土坝水下裂缝语义分割模型

何旺¹, 钮新强^{2,3}, 田金章^{3,4}, 朱延涛^{1,3}

(1. 河海大学水利水电学院, 江苏 南京 210098; 2. 长江设计集团有限公司水资源工程与调度全国重点实验室, 湖北 武汉 430010; 3. 国家大坝安全工程技术研究中心, 湖北 武汉 430010; 4. 长江勘测规划设计研究有限责任公司, 湖北 武汉 430010)

摘要:为解决深度学习算法难以有效检测混凝土坝水下裂缝的问题, 构建了基于 MobileNetV2-DeepLabv3+ 的混凝土坝水下裂缝语义分割模型。该模型引入轻量化网络 MobileNetV2, 同时将深层特征下采样倍数降为 8, 以提高小数据集工况下的识别准确率和推理速度; 将交叉熵损失函数与 Dice 损失函数的组合作为模型的损失函数, 以缓解类别不平衡问题。工程实例验证结果表明: 该模型在测试集上的平均像素准确率和平均交并比分别高达 90.87% 和 86.33%, 满足水下裂缝语义分割精度要求; 典型工况下的混凝土坝水下裂缝的分割效果优于其他对比模型, 泛化能力强; 模型具有内存占比小、推理速度快的特点, 可用于混凝土坝水下裂缝的检测。

关键词: 混凝土坝; 水下裂缝; MobileNetV2-DeepLabv3+; 语义分割; 机器视觉

中图分类号: TV698.1

文献标志码: A

文章编号: 1006-7647(2024)06-0106-07

Semantic segmentation model for underwater cracks in concrete dams based on MobileNetV2-DeepLabv3+//HE Wang¹, NIU Xinqiang^{2,3}, TIAN Jinzhang^{3,4}, ZHU Yantao^{1,3} (1. College of Water Conservancy and Hydropower Engineering, Hohai University, Nanjing 210098, China; 2. State Key Laboratory of Water Resources Engineering and Management, CISPDR Corporation, Wuhan 430010, China; 3. Research Center on National Dam Safety Engineering Technology, Wuhan 430010, China; 4. Changjiang Institute of Survey, Planning, Design, and Research Co., Ltd., Wuhan 430010, China)

Abstract: To tackle the difficulty of detecting underwater cracks in concrete dams effectively with deep learning algorithms, a semantic segmentation model for underwater cracks in concrete dams based on MobileNetV2-DeepLabv3+ was proposed. The lightweight network MobileNetV2 was introduced into the model and the deep feature downsampling multiplier was reduced to 8, so as to improve the recognition accuracy and inference speed under small dataset conditions. To alleviate the problem of category imbalance, the combination of cross entropy loss function and Dice loss function was used as the loss function of the model. The validation results from an engineering case show that the mean pixel accuracy and mean intersection over union of the model on the test set are as high as 90.87% and 86.33%, respectively, meeting the requirements for underwater cracks of high-precision semantic segmentation. Compared with other models, the proposed model shows better segmentation effect of underwater cracks of concrete dams under typical conditions, with strong generalization ability. With features of low memory usage and high inference speed, the proposed model is suitable for underwater crack detection of concrete dams.

Key words: concrete dam; underwater crack; MobileNetV2-DeepLabv3+; semantic segmentation; machine vision

混凝土坝是我国高坝的重要组成部分^[1], 但是其工作条件复杂, 在运行过程中长期承受水流冲刷以及内部应力、化学反应的影响, 加之有时施工质量差或基础处理不完善, 其表面会出现开裂现象^[2-3]。

相比于水上裂缝, 水下裂缝往往更难发现, 且增长速度更快, 对混凝土坝的稳定性威胁更大。目前混凝土坝水下裂缝的检测仍以人工定期检测为主, 潜水员通过目视或探摸桩基的方式对水下混凝土结构进

基金项目: 国家重点研发计划项目 (2022YFC3005404); 国家自然科学基金项目 (52309152, U23B20150); 江苏省自然科学基金项目 (BK20220978)

作者简介: 何旺 (2002—), 男, 博士研究生, 主要从事水工程安全与智慧运维研究。E-mail: hewang@hhu.edu.cn

通信作者: 朱延涛 (1993—), 男, 助理研究员, 博士, 主要从事水工程智慧运维与风险防控研究。E-mail: zhuyantao@hhu.edu.cn

行检测,但水下环境复杂且暴露的钢筋混凝土结构多,对检测人员的专业性要求高,且存在检测效率低、漏检率高的问题。因此,探究精准、高效的混凝土坝水下裂缝识别方法对保障混凝土坝的安全运行具有重要意义。

近年来,随着远程控制技术的不断发展,混凝土坝水下裂缝的检测方法逐渐转变为通过无人机和下水机器人代替人工获取大量图像,再结合数字图像处理算法提取特征信息的方式来识别裂缝,该方式大大提高了裂缝检测效率^[4-5]。目前数字图像处理算法主要有传统图像处理算法和机器学习算法(人工神经网络^[6]、支持向量机^[7]和K均值聚类^[8]等),多应用于桥梁、隧洞和路面等领域的裂缝检测中。例如: Talab 等^[9]提出了一种基于 Sobel 和 Otsu 的组合处理方法来检测裂缝,该方法能从周围物体中分离出清晰的裂缝轮廓;谭卫雄等^[10]建立了一种基于人工蜂群算法和 BP 神经网络的路面裂缝识别算法,实现了复杂背景下的裂缝识别;张小伟等^[11]采用自适应区域生长算法和局部 K 均值聚类算法先后获取裂缝粗细分割图,解决了坝面裂缝噪声严重的问题。虽然上述方法在裂缝识别方面取得了一定的效果,但还需要过多的人工预处理操作,对于大规模的图像数据处理效率低,自动化程度不高,难以满足实际裂缝识别需求。

相比于数字图像处理算法,深度学习算法能直接从图像中获取特征信息并整合,实现端对端的学习,有效提高了图像识别的自动化程度。目前深度学习算法在裂缝识别领域主要有图像分类、目标检测和语义分割 3 种应用,其中前两者重点是通过滑动窗口或矩形框对裂缝进行简单定位,无法精细化分割裂缝的形态,而语义分割利用不同的颜色标记不同类别的像素,可实现对裂缝的边缘轮廓提取和特征参数识别。例如:李良福等^[12]通过构建深度桥梁裂缝分类模型和运用 Otsu 阈值分割算法,实现了对桥梁裂缝的精确提取,但是该方法检测过程复杂,而且推理速度慢;Vu Dung 等^[13]提出了一种基于全连接网络的混凝土裂缝检测方法,能很好地分割复杂背景下的混凝土裂缝像素,但受噪声影响较大;Badrinarayanan 等^[14]利用编码-解码器和像素级分类层搭建了 SegNet,能精准分割缺陷图像,但主要用于路面场景和室内场景;李原等^[15]提出了一种基于改进 Res-UNet 的钢铁表面缺陷分割算法,有效解决了缺陷图像样本不均衡的问题,但对小样本缺陷的分割效果差;Zhu 等^[16]基于 DeepLabv3+ 模型,引入自适应注意力机制,提出了一种针对水工混凝土结构损伤检测的语义分割方法,可实现高精度的裂缝

识别,但其主干网络采用 Xception 结构,性能受数据集数量影响较大;黄思文等^[17]同样基于 DeepLabv3+ 模型,引入轻量化网络和空洞深度可分离卷积,并降低深层特征下采样倍数,提出了一种针对水工混凝土裂缝的语义分割方法,可有效分割多种类型的混凝土裂缝,但还未考虑表面噪声严重的水下缺陷检测情况。

基于深度学习的裂缝图像识别研究虽已取得一些成果,但受混凝土坝水下裂缝图像存在表面噪声干扰严重、可获取样本少以及类别不平衡(水下裂缝与背景的像素占比相差悬殊)等问题的影响,直接使用现有算法难以有效检测混凝土坝水下裂缝。为克服这些局限性,本文构建了基于 MobileNetV2-DeepLabv3+ 的混凝土坝水下裂缝语义分割模型(以下简称“本文模型”)。该模型选用 DeepLabv3+ 作为基础模型,引入 MobileNetV2 网络作为主干网络,并将深层特征下采样倍数降为 8,来提高小数据集工况下的识别准确率和推理速度,同时提出将交叉熵损失函数和 Dice 损失函数的组合作为模型损失函数,以缓解类别不平衡问题,并结合实际工程构建数据集,验证本文模型的可靠性与有效性。

1 模型构建

1.1 经典 DeepLabv3+ 网络模型

DeepLab 系列网络模型^[18]是针对卷积神经网络在高层特征映射时需进行多次池化导致分辨率降低、分割精度不高提出的,也是目前广泛使用的语义分割模型。相比于之前的模型,DeepLabv3+^[19]提出了全新的编码-解码结构,并引入 Xception 网络^[20],将 ASPP 模块和解码结构的卷积操作改为深度可分离卷积,在一定程度上既减少了计算参数,又保证了模型的识别准确率。

经典 DeepLabv3+ 网络模型的特征提取过程为:①输入图像经主干网络 Xception 提取后分为两部分:一部分为深层特征,经 16 倍下采样后传入 ASPP 模块,另一部分为浅层特征,经 4 倍下采样后传入解码结构;②在 ASPP 模块中对深层特征进行上下文信息的结合,并通过 1×1 卷积调整通道数后,输出高层语义特征层;③对高层语义特征层 4 倍上采样后,与经 1×1 卷积调整通道数的浅层特征层融合拼接,得到复合特征图;④通过 3×3 卷积运算和 4 倍上采样操作,将复合特征图尺寸恢复到与原始图像一致,并对每一个像素点进行分类,输出预测结果。

1.2 MobileNetV2 网络

MobileNetV2 网络^[21]是轻量级卷积神经网络,参数少,推理速度快,且在小数据集工况下仍能实现

较高的分割精度。该网络非常重要的特点是引入了倒残差结构,倒残差结构主要包括通道扩张、特征提取和通道压缩三部分,这与 ResNet 的残差结构^[22]刚好相反,同时将 3×3 卷积换为 3×3 深度可分离卷积,表现为两头小中间大的结构,此结构可减少网络参数和降低计算复杂度,同时提高网络的鲁棒性和表达能力。

1.3 模型结构

经典 DeepLabv3+模型的主干网络为 Xception,该网络的优异性能是在识别目标种类和训练集数量都较多的基础上实现的,而在混凝土坝水下裂缝识别中,公开且满足要求的水下裂缝图像较少,这会导致模型的识别效果不够理想,且本身结构复杂,推理速度慢,难以满足实际识别要求。同时经典 DeepLabv3+模型对深层特征的下采样倍数为 16~32,过高的下采样倍数会丢失裂缝特征信息,降低分割准确度。故本文引入 MobileNetV2 代替原主干网络,以适应小数据集工况和减少参数来提高运行速度,同时将深层特征下采样倍数降为 8,以减少裂缝特征信息丢失,构建基于 MobileNetV2-DeepLabv3+的混凝土坝水下裂缝语义分割模型,结构如图 1 所示。




图 1 模型结构

1.4 损失函数

在语义分割领域中,损失函数是用于度量模型预测结果与真实标签之间差异程度的函数。目前常用的损失函数有交叉熵损失函数^[23]和 Dice 损失函数^[24]。交叉熵损失函数会单独评估每一个像素,并将其平均以获得该像素所属类别的预测值,这会导致它在处理类别不平衡的问题时,更容易把所有像素识别为背景,使得模型分割精度降低;而 Dice 损失函数是基于预测结果和真实标签的像素交集与并集之比的度量函数,它可以缓解样本中类别不平衡问题,但会存在损失饱和问题。故为缓解类别不平

衡问题,进一步提高模型的分割精度,本文提出将交叉熵损失函数和 Dice 损失函数的组合作为模型损失函数。

1.5 模型工作流程

依据上述模型与方法,本文模型的主要实现过程如下:①结合工程现场采集的影像构建数据集,并划分为训练集、验证集和测试集;②搭建本文模型并设置初始训练参数;③训练模型并依据总损失函数的计算结果调整模型参数,待验证集损失函数满足要求后输出模型权重;④在测试集上进行消融试验分析,评估本文模型的改进效果,若满足分割精度要求则结束,反之继续调整参数重新训练。具体的工作流程如图 2 所示。




图 2 模型工作流程

2 工程实例验证

2.1 数据集来源与处理

本文使用自制混凝土坝水下裂缝数据集,原始数据来源于水下机器人在长江中游某水库主坝现场拍摄获取的影像数据,影像分辨率为 720×480 像

素,帧率为 30 帧/s。数据集的构建过程为:①从水下机器人拍摄的视频中逐帧提取清晰且能人眼分辨的原始图像;②为提高本文模型的泛化能力和鲁棒性,对原始图像使用局部放大、旋转 90°、拉伸 30°和左右镜像 4 种图像增强方法进行处理;③在 Labelme 软件界面中经人工精细标注后,生成相应的 PNG 标签文件。经过处理得到的水下裂缝图像及其对应的标签文件共有 400 张,按 8 : 1 : 1 进行划分,即训练集 320 张、验证集 40 张以及测试集 40 张。

2.2 环境配置与训练参数

深度学习模型的训练需要占用大量的显存,本文模型是利用超算云服务器来进行训练的,其中单张计算卡的软硬件环境配置见表 1。

表 1 模型环境配置	
环境	配置说明
硬件环境	CPU:Platinum82 系列(80vCPU) v6@ 2.5 GHz; 内存:38 GB;GPU:NVIDIA © Tesla © V100 SXM2;显存:32 GB
软件环境	操作系统:CentOS7.8
开发环境	Pycharm 集成开发环境
算法编程环境	深度学习框架 Pytorch 1.7.1 和 GPU 加速 CUDA 11.0

模型结合迁移学习策略,采用 VOC2007 数据集作为预训练权重,训练优化器为 Adam,训练过程分为冻结阶段和解冻阶段两部分:在冻结阶段,模型的主干特征提取网络不参与训练,此时模型占用的显存小,可节省电脑运算资源与空间,仅用于微调模型参数;在解冻阶段,模型的主干特征提取网络参与训练,此时占用的显存大,用于调整模型所有参数,具体的训练参数见表 2。

表 2 训练参数设置			
阶段	训练轮数	批尺寸大小	学习率
冻结	0~50	8	1×10^{-4}
解冻	51~100	4	1×10^{-5}

2.3 评价指标

语义分割领域常用的评价指标有像素准确率(PA)、召回率(Recall)、平均像素准确率(MPA)和平均交并比(MIoU)等,本文选用 MPA 和 MIoU 来评价模型对混凝土坝水下裂缝的分割精度^[25-27]。MPA 为模型对各类别图像正确分类的像素占总像素的平均值;MIoU 为每个类别预测结果与真实标签的交集与并集之比的平均值。

2.4 结果分析与对比

为验证本文模型在混凝土坝水下裂缝检测中的可靠性,对其在训练集和验证集中的损失函数进行可视化评估,然后利用优化后的权重文件,在 40 张测试集上进行消融试验分析并与多种模型对比,测

试本文模型对混凝土坝水下裂缝的分割效果。

2.4.1 训练过程评估

训练集和验证集损失函数经 100 轮训练的变化情况如图 3 所示。从图 3 可以看出,随着训练轮次的增加,模型在训练集和验证集上的损失函数均呈现先快速降低后缓慢降低并逐渐稳定的趋势;在第 50 轮引入主干网络参与训练后,其损失函数小幅波动后继续呈现下降趋势,说明模型有效地从数据集中学习了检测规则;模型在训练结束后训练集与验证集损失函数均小于 0.15,说明模型的损失函数在混凝土坝水下裂缝数据集上收敛效果较好,模型训练得很充分。




图 3 训练集和验证集损失函数随训练轮次的变化

2.4.2 消融试验分析

本文对经典 DeepLabv3+ 有两次改进:引入 MobileNetV2 网络代替原主干网络 Xception;将深层特征下采样倍数改为 8。为评估各项改进对经典 DeepLabv3+性能的提升效果,进行了消融试验分析各种改进组合的精度指标,结果见表 3。由表 3 可以看出,引入 MobileNetV2 网络和降低深层特征下采样倍数均在一定程度上提高了模型在测试集上的检测效果,且只引入 MobileNetV2 网络的效果明显比只降低深层特征下采样倍数的效果要好。

表 3 消融试验结果			
主干网络	下采样倍数	MPA/%	MIoU/%
Xception	16	87.94	83.45
	8	90.11	85.06
MobileNetV2	16	90.96	85.71
	8	90.87	86.33

为缓解类别不平衡问题,本文将交叉熵损失函数和 Dice 损失函数的组合作为模型的损失函数。类别不平衡问题会让损失函数将更多水下裂缝像素识别为背景,故本文统计了不同损失函数下模型对水下裂缝像素的分类情况,涵盖 40 张 720×480 像素的图像,总共包含 13 824 000 个像素,其中水下裂缝像素数为 377 718 个。结果表明,当模型仅使用交叉熵损失函数时,正确分类的水下裂缝像素数为 294 366 个;仅使用 Dice 损失函数时,该数值为

311 824 个,后者的表现略优于前者。然而,当应用本文提出的损失函数时,模型正确分类的水下裂缝像素数最高,达到了 315 090 个,说明该损失函数能进一步提升模型对水下裂缝正确分类率,使模型的整体性能更优。

2.4.3 与其他模型对比

为验证本文模型的优越性,选取典型的图像分割模型在测试集中进行对比试验,对比模型分别为:经典 DeepLabv3+模型^[19]和基于两种主干网络 VGG16 和 ResNet50 的 U-Net 模型^[15,28](以下分别简称为“U-Net(VGG16)模型”和“U-Net(ResNet50)模型”)。不同分割模型的精度见表 4。本文模型的 MPA 和 MIoU 值分别高达 90.87%和 86.33%,两项指标均高于所有对比模型。

表 4 不同分割模型的分割精度

模型	MPA/%	MIoU/%
本文模型	90.87	86.33
经典 DeepLabv3+模型	87.94	83.45
U-Net(VGG16)模型	85.90	82.38
U-Net(ResNet50)模型	87.52	84.35

为检验本文模型的泛化能力,从测试集中选取表面不平整、成像模糊、颜色干扰和局部阴影 4 种典型工况下的混凝土坝水下裂缝来测试模型性能,并与上述对比模型进行可视化效果分析。不同模型的分割效果如图 4 所示。从图 4 可以看出,本文模型不受凹凸不平表面的干扰,表现为抗噪性能强,对主裂缝的分割完整度略差于 U-Net(VGG16)和 U-Net(ResNet50)模型,但 U-Net(VGG16)和 U-Net(ResNet50)模型将多处背景像素识别为裂缝,受噪声影响更大;本文模型能清晰地识别出水下裂缝,对

主裂缝的分割完整度好,而经典 DeepLabv3+模型对主裂缝的分割不全面,且存在多处间断,难以识别出水下裂缝的边缘轮廓。因此,本文模型除了在局部阴影的工况下存在部分小间断外,对水下裂缝的整体识别效果最优,边缘分割更精确,优于其他模型。

为实现精准高效的混凝土坝水下裂缝检测,除了分割效果外,还需考虑模型的复杂程度与推理速度。表 5 为不同模型的权重文件大小(所占内存空间)、对单张分辨率为 720×480 像素的混凝土坝水下裂缝图像的识别时间以及经 100 次检测后得到的帧率值,可以看出,本文模型权重文件最小、所占用的空间最少,仅为经典 DeepLabv3+模型的 1/9;识别速度最快,对单张图像的检测只需 0.018 s,对应的帧率值为 56.23 帧/s,相比于经典 DeepLabv3+模型提升了 29.37 帧/s,即模型平均每秒能多处理 29.37 张图片。故相比于其他模型,本文模型分割效果最优,识别速度最快,综合性能最强。

表 5 不同模型的权重文件大小及识别速度

模型	权重文件大小/MB	单张图像识别时间/s	帧率/(帧/s)
本文模型	22.44	0.018	56.23
经典 DeepLabv3+模型	209.71	0.037	26.86
U-Net(VGG16)模型	94.97	0.026	37.98
U-Net(ResNet50)模型	167.91	0.023	43.15

2.4.4 测试结果可视化

为进一步评价本文模型在混凝土坝水下裂缝分割中的识别效果,重新选择了 3 张未标注的水下裂缝图片来评价其分割性能,原图和分割结果图如图 5 所示,可以看出本文模型在 3 张水下裂缝图片上仍表现出优异的分割性能,可有效用于混凝土坝水下裂缝的检测。





图 4 4 种典型工况下不同模型的分割效果



(a) 原图 (b) 分割结果

图5 测试结果

3 结 语

针对深度学习算法难以有效检测混凝土坝水下裂缝的问题,基于经典 DeepLabv3+模型,通过引入轻量化网络 MobileNetV2,将深层特征下采样倍数为 8 以及将交叉熵损失函数和 Dice 损失函数的组合作为模型损失函数,构建了基于 MobileNetV2-DeepLabv3+的语义分割模型,并通过工程实例验证了该模型的可靠性与有效性。结果表明,基于 MobileNetV2-DeepLabv3+的语义分割模型在测试集上的 MPA 和 MIoU 值分别达到 90.87% 和 86.33%,可实现高精度的语义分割。此外,将交叉熵损失函数和 Dice 损失函数的组合作为模型损失函数能有效缓解水下裂缝图像的类别不平衡问题。在面对表面不平整、成像模糊、颜色干扰和局部阴影等复杂工况时,该模型的识别效果优于其他比较模型,且模型的权重文件大小仅为 22.44 MB,帧率高达 56.23 帧/s,具有内存占比小、推理速度快的特点,适合实际工程的水下裂缝检测。

参考文献:

[1] 王浩然,钮新强,徐利福,等. 基于奇异谱分析和改进 WOA-BP 的大坝变形预测模型[J]. 水力发电学报, 2023,42(11):136-145. (WANG Haoran, NIU Xinqiang, XU Lifu, et al. Dam deformation prediction model based on singular spectrum analysis and improved whale optimization algorithm-optimized BP neural network[J]. Journal of Hydroelectric Engineering, 2023,42(11):136-145. (in Chinese))

[2] XU Wenlei, NIU Xinqiang, ZHU Yantao. Deformation behavior and damage evaluation of fly ash-slag based geopolymer concrete under cyclic tension[J]. Journal of Building Engineering, 2024,86:108664.

[3] 张国新,刘毅,刘有志,等. 高混凝土坝温控防裂研究进展[J]. 水利学报, 2018,49(9):1068-1078. (ZHANG

Guoxin, LIU Yi, LIU Youzhi, et al. Reviews on temperature control and crack prevention of high concrete dam[J]. Journal of Hydraulic Engineering, 2018, 49(9):1068-1078. (in Chinese))

[4] 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))

[5] 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))

[6] ROWSHANDEL H, NICHOLSON G L, SHEN J L, et al. Characterisation of clustered cracks using an ACFM sensor and application of an artificial neural network[J]. NDT & E International, 2018,98:80-88.

[7] 何昊,贺福强,谢丹,等. 基于 SVM 和改进区域生长法的桥梁裂缝分割算法[J]. 公路交通科技, 2022, 39(11):115-123. (HE Hao, HE Fuqiang, XIE Dan, et al. A bridge crack segmentation algorithm based on SVM and improved region growing method[J]. Journal of Highway and Transportation Research and Development, 2022, 39(11):115-123. (in Chinese))

[8] 王惠琴,侯文斌,彭清斌,等. 基于 K 均值聚类的 SPPM 分步分类检测算法[J]. 通信学报, 2022, 43(1):161-171. (WANG Huiqin, HOU Wenbin, PENG Qingbin, et al. Step-by-step classification detection algorithm of SPPM based on K-means clustering[J]. Journal on Communications, 2022,43(1):161-171. (in Chinese))

[9] TALAB A M A, HUANG Zhangcan, XI Fan, et al. Detection crack in image using Otsu method and multiple filtering in image processing techniques[J]. Optik, 2016, 127(3):1030-1033.

[10] 谭卫雄,王育坚,李深圳. 基于改进人工蜂群算法和 BP 神经网络的沥青路面表裂缝识别[J]. 铁道科学与工程学报, 2019, 16(12):2991-2998. (TAN Weixiong, WANG Yujian, LI Shenzhen. Crack identification of asphalt pavement surface based on improved artificial bee colony algorithm and BP neural network[J]. Journal of Railway Science and Engineering, 2019, 16(12):2991-2998. (in Chinese))

[11] 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))
- [12] 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 Liangfu, MA Weifei, LI Li, et al. Research on detection algorithm for bridge cracks based on deep learning[J]. Acta Automatica Sinica,2019,45(9):1727-1742. (in Chinese))
- [13] VU DUNG C, ANH L D. Autonomous concrete crack detection using deep fully convolutional neural network [J]. Automation in Construction,2019,99:52-58.
- [14] BADRINARAYANAN V, KENDALL A, CIPOLLA R. SegNet;a deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2017,39(12):2481-2495.
- [15] 李原,李燕君,刘进超,等. 基于改进 Res-UNet 网络的钢铁表面缺陷图像分割研究[J]. 电子与信息学报,2022,44(5):1513-1520. (LI Yuan, LI Yanjun, LIU Jinchao, et al. Research on segmentation of steel surface defect images based on improved Res-UNet network[J]. Journal of Electronics & Information Technology,2022,44(5):1513-1520. (in Chinese))
- [16] ZHU Yantao, TANG Hongwu. Automatic damage detection and diagnosis for hydraulic structures using drones and artificial intelligence techniques [J]. Remote Sensing,2023,15(3):615.
- [17] 黄思文,包腾飞,李扬涛,等. 基于改进 Deeplab V3+网络的水工混凝土裂缝语义分割方法[J]. 水利水电科技进展,2023,43(1):81-86. (HUANG Siwen, BAO Tengfei, LI Yangtao, et al. Semantic segmentation method of hydraulic concrete cracks based on improved Deeplab V3+ network[J]. Advances in Science and Technology of Water Resources,2023,43(1):81-86. (in Chinese))
- [18] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2018,40(4):834-848.
- [19] CHEN L C, ZHU Yukun, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]//Proceedings of the 15th European Conference on Computer Vision - ECCV 2018. Munich:Springer,2018:833-851.
- [20] CHOLLET F. Xception: deep learning with depthwise separable convolutions [C]//Proceedings of 2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu:IEEE,2017:1800-1807.
- [21] SANDLER M, HOWARD A, ZHU Menglong, et al. MobileNetV2: inverted residuals and linear bottlenecks [C]//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE,2018:4510-4520.
- [22] ZHANG Ke, SUN Miao, HAN T X, et al. Residual networks of residual networks:multilevel residual networks [J]. IEEE Transactions on Circuits and Systems for Video Technology,2018,28(6):1303-1314.
- [23] GHIASI-SHIRAZI K. Competitive cross-entropy loss: a study on training single-layer neural networks for solving nonlinearly separable classification problems [J]. Neural Processing Letters,2019,50(2):1115-1122.
- [24] ZHAO Rongjian, QIAN Buyue, ZHANG Xianli, et al. Rethinking dice loss for medical image segmentation [C]//Proceedings of 2020 IEEE International Conference on Data Mining. Sorrento:IEEE,2020:851-860.
- [25] 田莹,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 Xuan, WANG Liang, DING Qi. Review of image semantic segmentation based on deep learning [J]. Journal of Software,2019,30(2):440-468. (in Chinese))
- [26] 李怡静,程浩东,李火坤,等. 基于改进 U²-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. (LI Yijing, CHENG Haodong, LI Huokun, et al. Crack detection of embankment in UAV images based on improved U²-Net and transfer learning [J]. Advances in Science and Technology of Water Resources,2022,42(6):52-59. (in Chinese))
- [27] 牛慧余,包腾飞,李扬涛,等. 基于改进 Mask R-CNN 的混凝土坝裂缝像素级检测方法[J]. 水利水电科技进展,2023,43(1):87-92. (NIU Huiyu, BAO Tengfei, LI Yangtao, et al. Pixel-level crack detection method of concrete dam based on improved Mask R-CNN [J]. Advances in Science and Technology of Water Resources,2023,43(1):87-92. (in Chinese))
- [28] 张伟光,钟靖涛,呼延菊,等. 基于 VGG16-UNet 语义分割模型的路面龟裂形态提取与量化[J]. 交通运输工程学报,2023,23(2):166-182. (ZHANG Weiguang, ZHONG Jingtao, HU Yanju, et al. Extraction and quantification of pavement alligator crack morphology based on VGG16-UNet semantic segmentation model[J]. Journal of Traffic and Transportation Engineering,2023,23(2):166-182. (in Chinese))

(收稿日期:2023-10-18 编辑:俞云利)