

基于改进 Deeplab V3+网络的水工混凝土 裂缝语义分割方法

黄思文¹, 包腾飞^{1,2,3}, 李扬涛¹, 牛慧余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:为实现水工混凝土裂缝快速而准确的检测,提出了一种基于改进 Deeplab V3+网络的水工混凝土裂缝语义分割方法。该方法采用 Mobilenetv2 网络替换原主干网络,将空洞卷积金字塔池化模块 (ASPP) 的空洞卷积替换为空洞深度可分离卷积,以提升运算速度,降低深层特征下采样倍数以减少语义信息丢失。实例验证结果表明:本文方法帧率达到 51.11 帧/s,较原网络提高了 23.33 帧/s,推理速度大幅提升;平均交并比和平均像素精度分别达到 89.45 和 95.19,分割精度高;针对典型混凝土裂缝的分割效果也优于比较方法,泛化能力较强。

关键词: Deeplab V3+; 水工混凝土; 裂缝识别; 语义分割; 深度学习

中图分类号: TV698.1

文献标志码: A

文章编号: 1006-7647(2023)01-0081-06

Semantic segmentation method of hydraulic concrete cracks based on improved Deeplab V3+ network//HUANG Siwen¹, BAO Tengfei^{1,2,3}, LI Yangtao¹, NIU Huiyu¹ (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 realize the rapid and accurate detection of hydraulic concrete cracks, a semantic segmentation method based on improved Deeplab V3+ network is proposed. In this method, the Mobilenetv2 network is used to replace the original backbone network, and the hole convolution of the hole convolution pyramid pooling module (ASPP) is replaced by the hole depth separable convolution, so as to improve the operation speed, reduce the sampling multiple of deep features and decrease the loss of semantic information. The experimental results show that the frame rate can reach 51.11 frame/s, which is 23.33 frame/s higher than that of the original network, and the reasoning speed is greatly improved. The mean intersection over union and mean pixel accuracy are 89.45 and 95.19, respectively, with high segmentation accuracy. The segmentation effect of typical concrete cracks is also better than the comparison method, indicating a strong generalization ability.

Key words: Deeplab V3+; hydraulic concrete; crack identification; semantic segmentation; deep learning

水工混凝土建筑物工作条件复杂^[1],在太阳辐射、干湿循环、冻融循环等作用下易产生裂缝^[2]。裂缝的存在和发展,轻则引发渗漏、溶蚀破坏,重则引发大坝失事,危及下游人民生命财产安全。因此,及时发现裂缝并采取相应除险加固措施对保障大坝安全十分重要。目前国内外大坝裂缝检测方法主要采用传统的人工巡视^[3],该方法不仅费时费力,且水下区域通常无法到达。近年来,出现了利用无人

机和水下机器人拍摄大量影像资料,然后通过人工解读影像识别大坝裂缝的方式,该方式虽然减轻了野外工作的强度,但人工解读影像工作量巨大,效率低下。

采用图像处理方法可以替代人工解读工作,一定程度实现图片中裂缝的自动化识别。徐欢等^[4]提出了一种基于 Canny 算子的路面裂缝检测方法,引入形态学滤波进行改进,使用 Ostu 算法实现双阈

基金项目: 国家重点研发计划(2018YFC1508603)

作者简介: 黄思文(1997—),男,硕士研究生,主要从事水工结构安全监测研究。E-mail: swhuang@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

值的自适应获取。王丽^[5]提出了基于樽海鞘群优化的大坝裂缝图像分割算法,并建立了混凝土坝病害监测 GUI 系统。张小伟等^[6]基于自适应区域生长和局部 K-Means 聚类,提出了一种针对混凝土坝面裂缝检测的图像处理算法。王一兵等^[7]提出基于 LabVIEW+VDM 的混凝土坝裂缝分析方法,利用 VDM 视觉开发包独立完成混凝土坝裂缝的检测。陶健等^[8]基于 Retinex 算法和百分比阈值法,提出了一种沥青路面裂缝检测方法。虽然上述方法取得了一定的裂缝识别效果,但这些图像处理方法都存在处理速度慢的问题,针对海量的图片数据,处理效率不高,且自动化程度较低。

使用深度学习方法可以有效提高图像识别的自动化程度,近年来,众多研究人员将深度学习方法应用到裂缝识别中。刘承飞^[9]构建了双卷积神经网络(CNN-Segnet),提出了一种混凝土桥梁裂缝识别方法,但以目前相机传感器的分辨率水平,在保证识别精度的前提下,其推理速度较慢。任松等^[10]基于 R-FCN 网络,提出了一种公路隧道裂缝检测方法,冯春成^[11]提出了一种基于深度学习的溢流坝表面裂缝检测方法,二者推理速度均较快,但识别精度较低、泛化能力较弱。李良福等^[12]基于 PSPNet 网络,引入自注意力机制,提出了一种针对桥梁裂缝的语义分割方法,其测试平均交并比(mean intersection over union, MIoU)为 84.31,一定程度提升了分割精度,但分割仍不够精确。张鹏^[13]提出了一种基于 Deeplab V3+网络^[14]的混凝土裂缝识别方法,其识别精度较高,但主干网络使用 Xception 网络,推理速度存在明显不足。祝一帆等^[15]提出了一种基于 U-Net 网络的路面裂缝检测方法,采用密集连接结构,在以往结构的基础上提高了网络各层特征信息利用率,该方法增强了网络的泛化能力,但其推理速度较慢。

为实现对水工混凝土裂缝快速而准确地检测,本文将 Deeplab V3+网络应用于水工混凝土裂缝检测中,提出了基于改进 Deeplab V3+网络的水工混凝土裂缝语义分割方法(以下简称“本文方法”)。本文方法采用 Mobilenetv2 网络替换原主干网络,将空洞卷积金字塔池化模块(ASPP)的空洞卷积替换为空洞深度可分离卷积,以提升运算速度,降低深层特征下采样倍数以减少语义信息丢失。并结合实际工程数据集,对本文方法可靠性进行了验证。

1 水工混凝土裂缝语义分割方法

1.1 主干特征提取网络

目前,Deeplab V3+网络使用的主干特征提取网络(以下简称主干网络)主要为 Xception 网络,对于

识别目标种类多,且训练集数据大的情况,具有很好的识别效果。但实际应用中,数据集通常很难满足此要求,其识别效果往往不够理想,而且因其参数多、结构复杂,网络推理速度较慢。而 Mobilenetv2 网络^[16]是轻量级卷积神经网络,参数少、结构相对简单,推理速度快,且在数据集数据较少时仍能实现较高的分割精度。因此,本文采用 Mobilenetv2 网络替换原主干网络(Xception 网络)。

Mobilenetv2 网络引入了倒残差结构和线性瓶颈结构。Mobilenetv2 网络获取输入信息后,先利用 1×1 卷积将输入升维并使用非线性激活函数 ReLU6 激活,再利用 3×3 深度可分离卷积进行特征提取,之后进行 1×1 卷积降维并使用线性激活函数激活,最后将其与输入进行叠加。所谓倒残差结构,即在 3×3 卷积前后各有一个 1×1 卷积分别进行升维和降维,此结构可增强梯度的传播,显著减少推理期间所需的内存占用。而线性瓶颈结构则是指进行 1×1 卷积降维时不再使用非线性激活函数 ReLU6,而采用线性激活函数,以保留更多特征信息。

1.2 改进 Deeplab V3+网络结构

Deeplab V3+网络对深层特征的下采样倍数为 16~32,下采样倍数越高则语义信息的压缩程度越高,过高的下采样倍数会丢失目标特征信息,影响识别效果。本文将深层特征下采样倍数更改为 8,以保留裂缝更多的特征信息,进而提升网络识别精度。原网络的空洞卷积金字塔池化模块(ASPP)采用 3×3 空洞卷积,本文将其替换为 3×3 空洞深度可分离卷积,以降低参数量,进而提升网络推理速度。

改进 Deeplab V3+网络结构如图 1 所示,其结构可以分为 3 个部分:主干特征提取网络、ASPP 模块和上采样模块。利用主干网络 Mobilenetv2 提取输入图片的浅层特征和深层特征。主干网络对深层特征进行 8 倍下采样后传入 ASPP 模块,ASPP 模块采用 5 种方式对深层特征进行并行处理,分别为:1×1 卷积进行特征提取,3 个空洞率分别为 6、12、18 的 3×3 空洞深度可分离卷积进行跨像素点特征提取,以及全局图像池化。5 种处理方式得到对应的 5 个特征层,将其堆叠并利用 1×1 卷积进行通道数调整后得到一个深层特征层。对其进行上采样操作后,与经过 1×1 卷积调整通道数的浅层特征层融合,得到一个包含输入图片浅层特征和深层特征的特征层,之后利用 3×3 卷积进行特征提取,最后利用上采样将结果调整为与输入图片同等大小后输出。

1.3 损失函数

训练过程采用交叉熵损失函数计算预测误差,进行反向传递,调整网络参数,损失函数计算公式为




图1 改进 Deeplab V3+网络结构

$$L = - \frac{1}{N} \sum_{i=1}^N \sum_{c=1}^K w_c \ln(p_c(z_i)) \quad (1)$$

式中: N 为像素总数; c 为某一语义分割类别; K 为语义分割类别总数(包括背景), 本文为 2; w_c 为类别 c 的损失权重; $p_c(z_i)$ 为像素 z_i 属于真实类别 c 的概率。

裂缝损失权重设置为 0.8, 背景损失权重设置为 0.2, 以解决类别不平衡问题。

2 实例验证

2.1 验证数据集与评价指标

为评估本文方法对水工混凝土裂缝的语义分割性能, 结合实际工程数据集验证该网络的可靠性。

2.1.1 数据集制作

验证试验采用自制水工混凝土裂缝数据集, 原始数据来源于中国西北地区某水利枢纽工程, 所拍摄裂缝位于坝顶路面、闸墩、溢流堰边墙、引水渠边墙等部位。使用相机 Nikon D300s 拍摄, 图片分辨率为 3 216×2 136 像素, 为了便于网络训练, 将拍摄图片裁剪至 224×224 像素, 裁剪后得到裂缝图片共 1 200 张。

数据集制作过程如图 2 所示。首先对图片裂缝进行人工精细标注, 再利用标注文件生成 PNG 标签文件。同时, 使用数据增强方法以扩充数据集, 增强方法为顺时针旋转 90°、水平翻转和局部放大。经过增强后, 数据集为 4 800 张裂缝图片及对应标签文件, 按比例 7 : 2 : 1 划分, 即训练集 3 360 张, 验证集 960 张, 测试集 480 张。

2.1.2 试验平台

试验所用计算机操作系统为 Windows 10, 运行内存 16GB, CPU 为 Intel Core i5-10400F, GPU 为 NVIDIA 1660S, GPU 加速为 CUDA 11.0, 深度学习框架为 Pytorch 1.7.1。




图2 数据集标注与增强

2.1.3 试验流程

先收集实际工程中水工混凝土裂缝图片, 将收集的图片制成数据集, 用训练集训练改进 Deeplab V3+网络, 并采用验证集进行调参。

训练使用 VOC 数据集训练得到的权重作为预训练权重, 训练优化器使用 Adam。网络共训练 100 轮, 先进行 50 轮冻结训练, 再进行 50 轮解冻训练。在冻结阶段, 网络的主干部分被冻结, 仅调整网络其余部分的参数。在解冻阶段, 主干部分被解冻, 网络所有参数都会调整。冻结阶段批尺寸设为 8, 学习率设为 5×10^{-4} ; 解冻阶段批尺寸设为 4, 学习率设为 5×10^{-5} 。

训练结束后, 将得到的权值文件载入网络并在测试集上测试, 并进行消融试验分析。同时引入对比方法, 计算各方法评估指标, 并选取典型混凝土裂缝图片以测试分割效果, 最后对网络进行光照强度影响评估。

2.1.4 评估指标选取

采用 MIoU 和平均像素精度(MPA)评价本方法对混凝土裂缝的语义分割精度。MIoU 为各类别预测值与真实值集合交集与并集比值的平均值, MPA

为各类别预测正确的像素数量与总像素数量的比值的平均值^[17-19]。

除了分割精度,评价语义分割网络性能的另一个重要指标是推理速度,即网络每秒能处理的图片数量,试验采用帧率(FPS)评估网络推理速度。

2.2 结果与分析

2.2.1 训练过程评估

训练损失函数与验证损失函数均随着训练轮次的增加而降低,第1轮训练时训练损失函数为0.139,验证损失函数为0.080;第100轮训练时训练损失函数为0.030,验证损失函数为0.046(图3)。损失函数在前几轮训练快速降低,之后缓慢降低并趋于稳定,曲线变化趋势良好,且在训练结束时训练与验证损失函数均小于0.05。说明改进 Deeplab V3+网络在混凝土裂缝数据集上收敛效果较好。




图3 损失函数随训练轮次变化

2.2.2 消融试验分析

本文对 Deeplab V3+网络做了3处改进:采用 Mobilenetv2 网络替换原主干网络 Xception,将深层特征下采样倍数降低为8,将 ASPP 模块的空洞卷积

替换为空洞深度可分离卷积。为评估各项改进对网络性能的提升效果,进行了消融试验测试各种改进组合的精度及推理速度指标,结果见表1。

表1 消融试验评价指标统计

编号	主干网络	下采样倍数	卷积类型	MIoU	MPA	FPS/(帧·s ⁻¹)
1				88.72	93.27	27.78
2	√			88.81	94.12	54.10
3		√		89.34	94.37	17.32
4			√	88.69	93.28	33.58
5	√	√		89.46	95.14	45.03
6	√		√	88.85	94.13	55.95
7		√	√	89.33	94.30	26.26
8	√	√	√	89.45	95.19	51.11

注:√表示对该项做了改进,原 Deeplab V3+网络下采样倍数为16~32,改进前的下采样倍数取16。

由表1可知,替换主干网络可以大幅提升网络推理速度,并一定程度提升精度;降低深层特征下采样倍数会使推理速度有所降低,但精度有明显提升;改变 ASPP 模块的空洞卷积类型能一定程度提升推理速度,对精度影响很小。做3项改进的网络(第8组)MPA 最高,MIoU 比最高的第5组仅低0.01,而MPA和FPS均高于第5组,FPS比最高的第6组低4.84帧/s。综合来看,做3项改进的网络综合性能最优,在大幅提升推理速度的同时,精度也有明显提升。

2.2.3 分割效果评估

从测试集中选取4张典型混凝土裂缝图片,包含单条裂缝、多条裂缝以及交叉裂缝,测试本文方法对典型裂缝图片的分割效果。并将其与 Deeplab V3+网络、U-Net 网络、基于2种主干网络的 PSPNet 网络^[20]、Canny 边缘检测算法^[21]作比较,结果如图4所示。




图4 典型裂缝分割效果对比

Canny 边缘检测算法提取的裂缝存在多处间断,且提取了很多非裂缝部分的边缘,检测效果受噪声影响较大。PSPNet 网络将很多裂缝像素点识别为背景,将背景识别为裂缝,尤其在识别交叉裂缝时存在多处间断,可见 PSPNet 网络对于混凝土裂缝识别能力较弱。U-Net 网络对裂缝 2 识别效果较差,该图混凝土表面不平整,网络将部分凹陷识别成裂缝,抗噪性较差,且对裂缝 4 识别存在间断。

Deeplab V3+网络对裂缝 1 分割存在间断,对表面不平整的裂缝 2 的分割也有问题,其中较短裂缝两端均有局部被识别为背景。而本文方法对这些部位分割更精确,尤其对 Deeplab V3+网络和 U-Net 网络分割效果不佳的裂缝 2,其分割效果明显更优,体现出网络更强的泛化能力。经过改进,网络的分割精度和泛化能力都有一定提升,其混凝土裂缝分割效果优于所有比较方法。

2.2.4 分割精度评估

经测试集测试,不同分割方法的精度见表 2。本文方法的 MIoU 达到了 89.45,MPA 达到了 95.19,两项精度指标均高于所有比较方法,相较于 Deeplab V3+网络,分别提高了 0.73 和 1.92。

表 2 不同裂缝分割方法的分割精度

方法	MIoU	MPA
本文方法	89.45	95.19
Deeplab V3+网络	88.72	93.27
U-Net 网络	88.69	93.96
PSPNet 网络 (Mobilenetv2)	81.45	90.64
PSPNet 网络 (ResNet50)	83.94	92.68

2.2.5 推理速度评估

本文方法、Deeplab V3 + 网络、U-Net 网络、PSPNet (Mobilenetv2) 网络、PSPNet (ResNet50) 网络、Canny 边缘检测算法的 FPS 分别为 51.11 帧/s、27.78 帧/s、27.22 帧/s、64.23 帧/s、39.89 帧/s、13.64 帧/s。本文方法的 FPS 相较 Deeplab V3+网络提升了 23.33 帧/s,即网络平均每秒钟能多处理 23.33 张图片。几种比较方法中,仅基于 Mobilenetv2 的 PSPNet 网络推理速度略高于本文方法,但由前文可知,其分割精度显著低于本文方法。因此,本文方法裂缝分割精度最高、推理速度快,综合性能最优。

2.2.6 光照强度影响评估

为评估拍摄照片时的光照强度对识别效果的影响,使用不同亮度的图片对本文方法进行测试,测试结果见图 5。光照强度升高加强了裂缝内部混凝土的反光,对于较窄裂缝,识别结果可能会出现间断;当光照强度很低时,混凝土表面以及裂缝均较暗,导致裂缝边缘识别不够精确。光照强度对网络识别效

果有一定影响,但网络仍能较准确地识别裂缝。




图 5 不同亮度图片的分割效果

3 结 语

为实现水工混凝土裂缝快速而准确的检测,提出了一种基于改进 Deeplab V3+网络的水工混凝土裂缝语义分割方法。实例验证结果表明本文方法能实现推理速度大幅提升的同时,分割精度也能有一定幅度的提升。本文方法具有以下优点:①具有一定的混凝土裂缝快速检测能力。其 FPS 达到 51.11 帧/s,即平均每秒可以处理 51.11 张大小为 224×224 像素的图片,推理速度快。②可以实现混凝土裂缝的高精度分割。其 MIoU 和 MPA 分别达到 89.45 和 95.19,均高于比较方法,分割精度高。③可以有效分割多种类型的混凝土裂缝。对于含有单条裂缝、多条裂缝以及交叉裂缝的典型裂缝图片,其分割效果优于比较方法,尤其对于多条裂缝图像,分割效果明显更优,网络泛化能力更强。且在光照强度过高和过低时仍能较好地实现裂缝分割。

验证数据集裂缝图片噪声较少,未考虑裂缝表面存在较多覆盖的情况。后续将针对裂缝图片存在较多噪声的情况开展更深入的裂缝检测研究。裂缝检测工作是基于离线数据进行的,后续可将检测网络与图像采集系统融合,实现对混凝土裂缝的实时检测。

参考文献:

[1] 沈长松,刘晓青,王润英,等. 水工建筑物[M]. 第二版,北京:中国水利水电出版社,2016.
[2] 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))
- [3] 任秋兵,李明超,沈扬,等. 水工混凝土裂缝像素级形态分割与特征量化方法[J]. 水力发电学报, 2021, 40(2): 234-246. (REN Qiubing, LI Mingchao, SHEN Yang, et al. Pixel-level shape segmentation and feature quantification of hydraulic concrete cracks based on digital images[J]. Journal of Hydroelectric Engineering, 2021, 40(2): 234-246. (in Chinese))
- [4] 徐欢,李振璧,姜媛媛,等. 基于 OpenCV 和改进 Canny 算子的路面裂缝检测[J]. 计算机工程与设计, 2014, 35(12): 4254-4258. (XU Huan, LI Zhenbi, JIANG Yuanyuan, et al. Pavement crack detection based on OpenCV and improved Canny operator [J]. Computer Engineering and Design, 2014, 35(12): 4254-4258. (in Chinese))
- [5] 王丽. 混凝土坝裂缝识别的数字图像处理算法研究[D]. 大连:大连理工大学, 2019.
- [6] 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))
- [7] 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 Lab VIEW+VDM[J]. Advances in Science and Technology of Water Resources, 2021, 41(5): 76-82. (in Chinese))
- [8] 陶健,田霖,张德津,等. 基于局部纹理特征的沥青路面裂缝检测方法[J]. 计算机工程与设计, 2022, 43(2): 517-524. (TAO Jian, TIAN Lin, ZHANG Dejin, et al. Asphalt pavement crack detection method based on local texture features [J]. Computer Engineering and Design, 2022, 43(2): 517-524. (in Chinese))
- [9] 刘承飞. 基于双卷积神经网络的桥梁裂纹实时检测技术研究[D]. 哈尔滨:哈尔滨工业大学, 2020.
- [10] 任松,朱倩雯,涂歆玥,等. 基于深度学习的公路隧道衬砌病害识别方法[J]. 浙江大学学报(工学版), 2022, 56(1): 92-99. (REN Song, ZHU Qianwen, TU Xinyue, et al. Lining disease identification of highway tunnel based on deep learning [J]. Journal of Zhejiang University (Engineering Science), 2022, 56(1): 92-99. (in Chinese))
- [11] 冯春成. 基于深度学习的水电站溢流坝表观裂缝检测方法研究[D]. 绵阳:西南科技大学, 2021.
- [12] 李良福,王楠,武彪,等. 基于改进 PSPNet 的桥梁裂缝图像分割算法[J]. 激光与光电子学进展, 2021, 58(22): 101-109. (LI Liangfu, WANG Nan, WU Biao, et al. Segmentation algorithm of bridge crack image based on modified PSPNet[J]. Laser and Optoelectronics Progress, 2021, 58(22): 101-109. (in Chinese))
- [13] 张鹏. 深度学习算法在混凝土材料组分及构件表面裂缝识别中的应用[D]. 合肥:合肥工业大学, 2021.
- [14] CHEN L, ZHU Y, PAPANDREOU G, et al. Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation[C]//FERRARI V. Computer Vision-ECCV 2018. Cham: Springer International Publishing, 2018: 833-851.
- [15] 祝一帆,王海涛,李可,等. 一种高精度路面裂缝检测网络结构: Crack U-Net[J]. 计算机科学, 2022, 49(1): 204-211. (ZHU Yifan, WANG Haitao, LI Ke, et al. Crack U-Net: towards high quality pavement crack detection [J]. Computer Science, 2022, 49(1): 204-211. (in Chinese))
- [16] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: Inverted residuals and linear bottlenecks [C]//IEEE. IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2018: 4510-4520.
- [17] 戴雨舒,仲晓春,孙成明,等. 基于图像处理和 Deeplabv3+模型的小麦赤霉病识别[J]. 中国农机化学报, 2021, 42(9): 209-215. (DAI Yushu, ZHONG Xiaochun, SUN Chengming, et al. Identification of fusarium head blight in wheat-based on image processing and Deeplabv3+ model [J]. Journal of Chinese Agricultural Mechanization, 2021, 42(9): 209-215. (in Chinese))
- [18] 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))
- [19] 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))
- [20] ZHAO H, SHI J, QI X, et al. Pyramid scene parsing network [C]//IEEE. IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2017: 6230-6239.
- [21] CANNY J. A computational approach to edge detection. [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1986, 8(6): 679-698.

(收稿日期: 2022-01-25 编辑: 刘晓艳)