DOI:10.20040/j.cnki.1000-7709.2025.20240874

基于改进 CycleGAN 与 YOLOv8s 的混凝土坝水下裂缝识别方法

赵 阳[1],康 飞[1],万 刚[2]

(1. 大连理工大学建设工程学院,辽宁 大连 116024; 2. 中国长江电力股份有限公司,湖北 宜昌 443000)

摘要:针对受水下环境影响造成的混凝土坝水下裂缝图像获取困难、样本稀缺,裂缝检测效率低、精度差、主观性强等问题,提出基于生成对抗网络 CycleGAN 和目标检测网络 YOLOv8s 的水下裂缝检测方法。首先,引入梯度惩罚 WGAN-GP 损失与相似性度量 LPIPS 损失,提出一种改进的 CycleGAN 图像风格迁移网络,以此生成高质量水下裂缝图像,解决数据样本不足的问题;之后,添加 SimAM 无参注意力并引入 WIoU 损失,提出改进的 YOLOv8s 水下裂缝识别网络,以提高水下裂缝图像识别的精度。试验结果表明,改进 CycleGAN 方法起到了良好的数据扩充作用,能有效提升后续检测任务的精度;改进 YOLOv8s 方法在消融、对比试验中,裂缝识别精度较原网络、Faster R-CNN、YOLOX-s、YOLOv5s 分别提高 2.4%、5.4%、2.4%、1.2%,检测效果满足高效、精确的要求,可为混凝土坝水下裂缝识别提供技术支持。

关键词:水下裂缝识别;生成对抗网络;数据扩充;损失函数;注意力机制

中图分类号:TV698.1 **文献标志码**:A **文章编号**:1000-7709(2025)04-0158-05

1 引言

水库大坝兼顾防洪、发电、供水、灌溉,对保护人民生活和促进经济发展起着关键作用。而混凝土坝在服役期间由于受到基础荷载和突发灾害的影响,常会出现裂缝等坝面表观缺陷,不仅会破坏结构完整性,还可能诱发其他缺陷对结构安全造成隐患[1]。因此,定期对坝面进行缺陷排查至关重要。由于坝体大部分结构长期位于水面下,水下部分的检测更为困难。传统水下检测主要依靠潜水员,但该方法限制多、效率低、危险性高,难以满足检测需求,目前水下机器人已取代人工成为主要检测手段[2]。随着机器视觉技术的发展,深度学习方法为水下检测提供了新思路。深度学习方法以图像作为学习样本,但受水下环境影响,混凝土坝水下裂缝图像的获取需要大量时间与昂贵设备的支持,当前该类图像十分稀缺[3]。HUANG B 等[4]采用无监督学习网络 CycleGAN 实现了大坝水下裂缝图像的生成。对此,本文基于循环一致性生成对抗网络 CycleGAN 和单阶段目标检测网络 YOLOv8s 做出改进,提出一种混凝土坝水下裂缝图像生成与识别方法,并通过试验验证了该方法的可行性。

2 基于改进 CycleGAN 与 YOLOv8s 的水下裂缝识别方法

2.1 改进 CycleGAN 的数据扩充方法

2.1.1 CycleGAN 网络

CycleGAN 网络相较于传统 GAN 网络实现了无监督图像域转换,这意味着网络在采用非配对训练数据的情况下可直接实现图像的转换,为水下裂缝图像生成提供了巨大便利。

CycleGAN 的损失函数由对抗性损失和循环一致性损失构成。由于网络建立了一组图像域间的联系,因此具有一组对抗性损失,可表示为:

$$L_{GAN}(G,D_Y,X,Y)=E_{y\sim P_{data}(y)}[\log D_Y(y)]+E_{x\sim P_{data}(x)}[\log(1-D_Y(G(x)))] \quad (1)$$

$$L_{GAN}(F,D_X,X,Y)=E_{x\sim P_{data}(x)}[\log D_X(x)]+E_{y\sim P_{data}(y)}[\log(1-D_X(F(y)))] \quad (2)$$

收稿日期:2024-05-13,**修回日期**:2024-06-17

基金项目:国家重点研发计划(2022YFB4703404);广西重点研发计划(AB24010003);国家自然科学基金项目(52079022)

作者简介:赵阳(1998-),男,硕士研究生,研究方向为大坝安全监测与数值分析,E-mail:dlutzy06@163.com

通讯作者:康飞(1982-),男,博士、教授、博导,研究方向为大坝安全监测与数值分析,E-mail:kangfei@dlut.edu.cn

中国知网 https://www.cnki.net

式中,$L_{GAN}(G,D_Y,X,Y)$、$L_{GAN}(F,D_X,X,Y)$为一组对抗性损失;G、F 为一组生成器;X、Y 分别为两域中的图像;$E_{x\sim P_{data}(x)}$、$E_{y\sim P_{data}(y)}$ 为一组生成器产生的样本分布的数学期望;D_Y、D_X 为一组判别器对应的概率函数。

循环一致性损失用于约束训练方向,可确保生成图像能够保留原域图像特征,循环一致性损失通过 $L1$ 损失来衡量图像之间的差异,具体为:

$$L_{cyc}(G,F)=E_{x\sim P_{data}(x)}[||F(G(x))-x||_1]+E_{y\sim P_{data}(y)}[||G(F(y))-y||_1] \quad (3)$$

式中,$F(G(x))$、$G(F(y))$均为经过两次循环生成的新图像。

2.1.2　改进的 CycleGAN 网络

CycleGAN 损失函数由 JS 散度构成,JS 散度会不断调整生成样本的分布,使其逼近真实样本的分布。但若两个分布没有交集,则 JS 散度为零。在训练中存在生成器梯度消失难以收敛的问题。生成器的图像优化方向“保守”,网络生成的图像往往会风格单一。对此,将损失函数 WGAN-GP[5] 引入 CycleGAN 代替对抗性损失。WGAN-GP 损失函数基于 Wasserstein 距离得出,并由 Wasserstein 距离代替 JS 散度衡量两个分布距离。比起 JS 散度,Wasserstein 距离的优点在于即使两个分布无交集,Wasserstein 距离仍可以表达他们的远近。WGAN-GP 损失函数为:

$$L(D)=-E_{x\sim P_r}[D(x)]+E_{x\sim P_g}[D(x)]+\lambda E_{x\sim X}[||\nabla_x D(x)||_p-1]^2 \quad (4)$$

式中,$E_{x\sim P_r}$、$E_{x\sim P_g}$ 均为分布 γ 下样本距离的数学期望;$D(x)$为判别器 D 对样本 x 的输出结果;λ 为惩罚因子的权重;∇_x 为计算梯度。

由于 Wasserstein 距离的特性,即使损失函数向缩小方向优化,生成器的梯度也不会消失。

结合 CycleGAN 损失函数原理,融合后的 CycleGAN 对抗性损失表示为:

$$L_{GAN}(G,D_Y,X,Y)=E_{y\sim P_{data}(y)}[D_Y(y)]-E_{x\sim P_{data}(x)}[D_Y(G(x))]+\lambda E_{y\sim Y}[||\nabla_y D_Y(y)||_2-1]^2 \quad (5)$$

$$L_{GAN}(F,D_X,X,Y)=E_{x\sim P_{data}(x)}[D_X(x)]-E_{y\sim P_{data}(y)}[D_X(G(y))]+\lambda E_{x\sim X}[||\nabla_x D_X(x)||_2-1]^2 \quad (6)$$

深度特征度量图像相似度(LPIPS)是一种用于评估图像之间相似度的指标,可以更好地反映人类对图像相似度的主观感知,评估结果更贴近人类视觉感知,并且在无监督学习中 LPIPS 能更准确地捕捉图像之间的语义信息。LPIPS 的损失函数 $L_{LPIPS}(\cdot)$为:

$$L_{LPIPS}(x,x_0,x_1,h)=-h\lg G(d(x,x_0),d(x,x_1))-(1-h)\lg(1-G(d(x,x_0),d(x,x_1))) \quad (7)$$

式中,$d(x,x_0)$ 为 LPIPS 的构造函数。

通过 LPIPS 损失构建关于 CycleGAN 的新循环一致性损失,可以得到:

$$L_{LPIPS}(X,F(G(x)),G(F(y)),h)=-h\lg G(d(X,F(G(x))),d(X,(F(y))))-(1-h)\lg(1-G(d(X,(G(x))),d(X,(F(y)))) \quad (8)$$

综上可以得到改进 CycleGAN 总体损失函数:

$$L(G,F,D_X,D_Y)=L_{GAN}(G,D_Y,X,Y)+L_{GAN}(F,D_X,X,Y)+L_{LPIPS}(X,F(G(x)),G(F(y)),h) \quad (9)$$

2.1.3　裂缝图像生成试验数据集

如图 1 所示,选择 600 张针对多座实际混凝土坝拍摄的水上裂缝图像作为水上图像域,并通过人工打造混凝土裂缝试件,选择 600 张于水下拍摄的试件裂缝图像作为水下图像域,共同构成裂缝图像生成试验数据集,并按 4∶1 比例划分训练集与测试集。

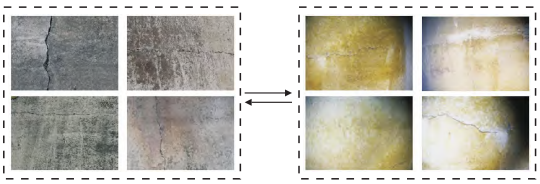

图 1　裂缝图像生成试验数据集

Fig. 1　Experimental dataset for crack image generation

2.1.4　裂缝图像数据扩充方法

将水下拍摄的混凝土裂缝试件图像作为原始数据集,记为数据集 UC。在 UC 的基础上加入改进 CycleGAN 数据扩充方法生成水下裂缝图像,记为数据集 UC-Ⅰ。为进一步扩充数据集,对 UC-Ⅰ的图像进行旋转、翻转、擦除、加噪等数据增强处理,记为数据集 UC-Ⅱ。

2.2　改进的 YOLOv8s 目标检测网络

2.2.1　YOLOv8s 网络

YOLOv8s 网络是 Ultralytics 发布的 YOLO 系列目标检测模型,实现了精度与速度之间的最佳平衡。

2.2.2　SimAM 注意力机制

注意力机制的灵感来源于人类视觉系统,针对水下图像裂缝特征模糊的问题,注意力机制允许网络在处理图像时,将更多的计算资源分配给图像中的裂缝区域,帮助网络忽略无关背景信息,

中国知网　https://www.cnki.net

从而提高图像识别的准确率。因此，即使图像存在噪声、遮挡或光线变化等因素，网络仍能准确地识别图像裂缝内容。不同于通道注意力 SE 模块和融合通道与空间注意力的 CBAM 模块，SimAM[6]模块是一种轻量级三维注意力模块，其原理如图 2 所示，图 2 中 X、C、H、W 分别为特征图、通道数、特征图的宽与高。

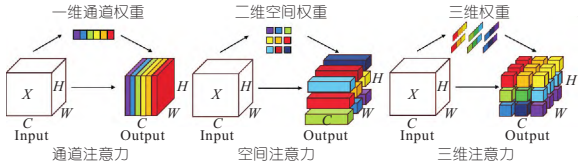

图 2 不同注意力机制示意图

Fig. 2 Schematic representation of different attention mechanisms

2.2.3 YOLOv8s 损失函数

YOLOv8s 网络采用 CIoU 作为回归损失函数，CIoU 考虑了边界框的重叠面积、中心点距离与宽高比。但由于 CIoU 是对框宽高的相对比例进行优化，因此训练过程中宽高并不能保持同增同减。若目标框的宽高存在线性相关，则会影响收敛速度。针对该问题，WIoUv2 设计了一种针对交叉熵的单调聚焦机制，并将小梯度增益分配给高质量锚框，计算公式为：

$$L_{\mathrm{WIoUv1}}=R_{\mathrm{WIoU}}L_{\mathrm{IoU}} \tag{10}$$

$$R_{\mathrm{WIoU}}=\exp\left(\left[(x-x^{gt})^2+(y-y^{gt})^2\right]/c^2\right) \tag{11}$$

$$L_{\mathrm{WIoUv2}}=(L_{\mathrm{IoU}}^{*}/\bar{L}_{\mathrm{IoU}})^{\gamma}L_{\mathrm{WIoUv1}} \tag{12}$$

式中，x、y、x^{gt}、y^{gt} 分别为框 A、B 的中心点坐标；c 为覆盖两框最小矩形框的对角线距离；$L_{\mathrm{IoU}}=1-\mathrm{IoU}$，IoU 用于测量目标检测任务中锚框和目标框之间的重叠程度；L_{IoU}^{*} 为梯度增益，$L_{\mathrm{IoU}}^{*}\in[0,1]$；$\bar{L}_{\mathrm{IoU}}$ 为动量的平均值。

2.2.4 改进 YOLOv8s 网络结构

将注意力机制融入 C2f 模块 Bottleneck 结构中，并采用 WIoU 损失，提出改进 YOLOv8s 网络。为避免因过多添加模块提升精度而牺牲大量检测速度，将少量 C2f 模块替换为带有注意力机制的 C2f-Att 模块，使网络将更多计算资源集中于裂缝区域，并抑制其他区域算力，从而提高网络对水下裂缝的检测效果，改进 YOLOv8s 网络结构见图 3。

2.3 基于改进 CycleGAN 与 YOLOv8s 的水下裂缝识别步骤

步骤 1 采用改进 CycleGAN 图像生成方法生成水下裂缝图像，扩充水下裂缝样本数量。

步骤 2 采用 LabelImg 软件为步骤 1 中图像制作数据标签，建立水下裂缝数据集。

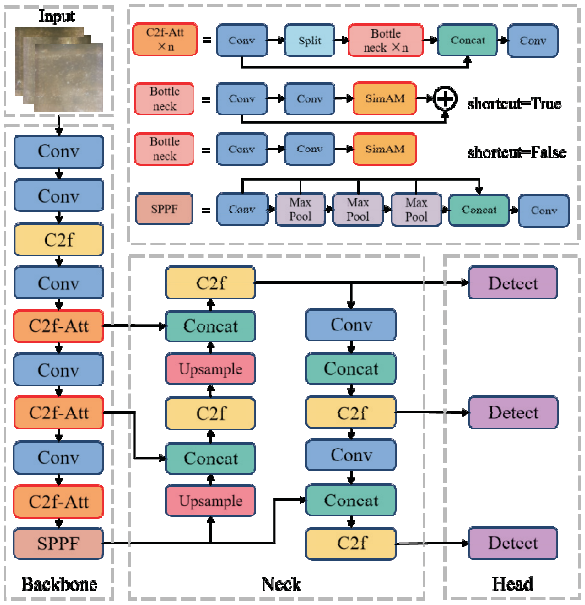

图 3 改进 YOLOv8s 网络结构

Fig. 3 Improvement of YOLOv8s network structure

步骤 3 对步骤 2 中数据集训练并测试不同改进模块对网络性能的提升，提出改进网络。

步骤 4 采用训练好的改进 YOLOv8s 网络进行水下裂缝智能识别。

3 试验结果与分析

3.1 试验环境与评价指标

试验在搭载了 Inter Core i7-12700F 中央处理器、NVIDIA 3080 显卡的工作站进行，算法运行环境为 CUDA 12.2＋python 3.9＋pytorch 1.12。评价指标采用针对目标检测任务的精确率(P)、召回率(R)、精确率 P 与召回率 R 的调和平均数(F_1 值)、单类别平均精度($P_{\mathrm{AP0.5}}$)和检测速度(S_{FPS})。

3.2 数据扩充试验

为验证改进 CycleGAN 网络的有效性，使用裂缝图像生成试验数据集针对 CycleGAN 网络和改进网络进行对比试验，训练时批大小 batchsize 设为 2，初始学习率为 0.000 2，共训练 200 轮。完成训练后，两组网络生成图像见图 4。由图 4 可以观察到，两组网络都较好地保留了裂缝纹理特征，但改进网络所生成的图像更好地还原了低对比度下的细节模糊与颜色失真，更符合真实水下

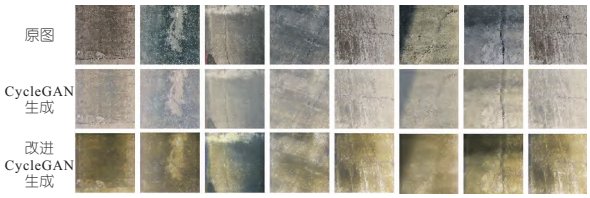

图 4 数据扩充试验结果

Fig. 4 Data expansion experiment results

中国知网 https://www.cnki.net

场景的特征。

为进一步验证改进 CycleGAN 数据扩充方法的应用效果,对采用数据扩充方法得到的数据集进行裂缝识别测试,测试网络选择目标检测网络 Faster R-CNN、YOLOX-s、YOLOv5s 和 YOLOv8s。其中 UC 共 600 张,UC-Ⅰ共 800 张,UC-Ⅱ共 1 600 张。将各检测网络训练至收敛并保证最佳检测性能,评价指标选择 $P_{AP0.5}$,试验结果见表 1。

表 1　裂缝识别测试结果

Tab. 1　Crack identification test results

测试数据集	$P_{AP0.5}$/%			
	Faster R-CNN	YOLOX-s	YOLOv5s	YOLOv8s
UC	68.7	71.9	75.8	74.2
UC-Ⅰ	72.8	75.6	78.2	77.3
UC-Ⅱ	75.2	78.2	79.4	78.2

综合表 1 中数据,各检测网络在数据集 UC-Ⅱ上检测精度最高,较 UC 分别提高 6.5%、6.3%、3.6%、4.0%。表明采用改进 CycleGAN 网络进行数据扩充后,能有效提升网络的检测精度。同时不同网络的精度均有所提升,证明该数据扩充方法具有普适性。

3.3　消融试验

为测试各个模块改进 YOLOv8s 网络性能的影响,在数据集 UC-Ⅱ上进行消融试验,各组试验模块安排见表 2。为保证试验结果的客观性,各组试验环境与参数设置相同,批大小设为 4,共训练 300 轮,并在最后 10 轮关闭 Mosaic 增强。

表 2　消融试验模块设置

Tab. 2　Ablation experiment module setting

试验编号	WIoU	SE	CBAM	SimAM
1	—	—	—	—
2	√	—	—	—
3	√	√	—	—
4	√	—	√	—
5	√	—	—	√

注:表中“√”表示训练时采用该模块。

5 组试验训练过程见图 5,图 5 中 $P_{mAP0.5}$ 为平均类别平均精度。由图 5 可看出,训练损失缓慢下降后趋于收敛,关闭 Mosaic 增强后损失进一步下降至稳定。替换 WIoU 损失后训练收敛更快,证明该损失有助于提高网络收敛速度。同时训练精度逐步上升,最终到达峰值,添加注意力机制的试验组 $P_{AP0.5}$ 更高,表明注意力机制提高了模型对裂缝等关键信息的捕捉能力,有效提高了网络的性能。

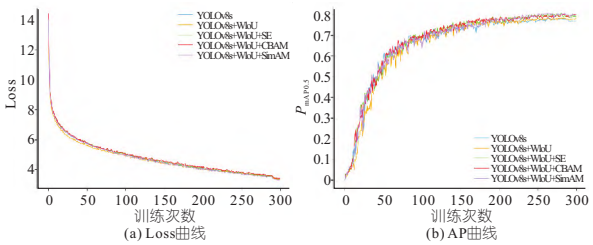

图 5　各组试验训练过程的 Loss 和 AP 曲线

Fig. 5　Loss and AP curves for each group of experimental training processes

训练结束后,对各试验组网络进行测试,将试验结果汇总,见表 3。添加 SimAM 模块并引入 WIoU 损失的试验组效果最好,P、R、F_1、$P_{AP0.5}$ 分别较原始网络提高了 0.3%、4.0%、2.2%、2.4%。表明改进网络在保证检测速度的同时提高了检测精度,结果满足预期。

表 3　消融试验结果

Tab. 3　Results of ablation experiment

试验编号	P/%	R/%	F_1	$P_{AP0.5}$/%	S_{FPS}
1	82.1	74.2	0.780	78.2	105
2	83.2	72.5	0.775	78.3	100
3	83.9	74.6	0.790	79.8	90
4	80.1	76.1	0.781	80.5	87
5	82.4	78.2	0.802	80.6	92

在测试集上对比原网络与改进网络的检测效果,结果见图 6。由图 6 可看出,改进的网络在总体上有效提升了检测能力,且具有较好的鲁棒性。同时采用神经网络可视化热力图(Grad-CAM)展示改进网络的检测效果。具体来说,在图 6(a)~(b)中,改进网络实现了复杂裂缝的检测全覆盖,完整地检测出长裂缝的分布情况;在图 6(c)~(d)中,改进网络对裂缝的漏检、误检样例减少,检测结果更加准确;在图 6(e)~(f)中,改进网络的预测框更贴近真实的边界框,在分布上也更加合理。从整体上看,改进网络预测结果的置信度更高,证明网络对裂缝的判断可信度更高。在 Grad-CAM 可视化图中,高亮部分代表网络重点关注部分,证明添加注意力机制后,网络的计算资源被有效集中在裂缝区域。综合以上结论,改进的网络能够准确检测出水下裂缝缺陷,表明网络在裂缝识别任务中具有较高的适用性和可信度。

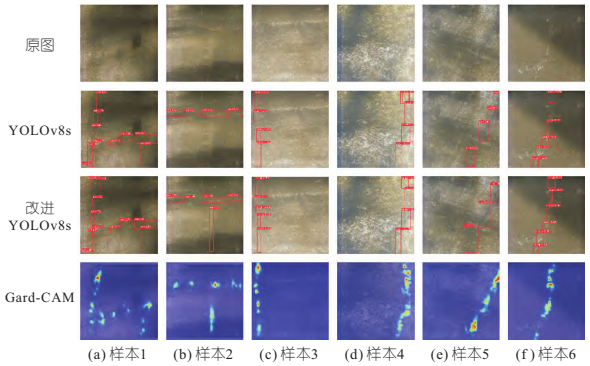

图 6　改进 YOLOv8s 网络检测效果

Fig. 6　Improvement of YOLOv8s network detection effect

中国知网　https://www.cnki.net

3.4 多种检测网络性能对比试验

为进一步验证改进方法的性能，将改进网络与 Faster R-CNN、YOLOX-s、YOLOv5s、YOLOv8s 等检测网络进行对比。各网络均训练至收敛且保证最佳效果，试验结果见表 4。改进网络的裂缝识别精度较原网络、Faster R-CNN、YOLOX-s、YOLOv5s 分别提高 2.4%、5.4%、2.4%、1.2%，检测效果能满足高效、精确的要求，因此具有更高的应用价值。

表 4 试验结果对比

Tab. 4 Comparison of experimental results

测试网络	P/%	R/%	F_1	$P_{AP0.5}$/%	S_{FPS}
Faster R-CNN	86.1	57.5	0.690	75.2	34
YOLOX-s	83.4	76.0	0.795	78.2	71
YOLOv5s	82.2	77.8	0.799	79.4	83
YOLOv8s	82.1	74.2	0.780	78.2	105
改进 YOLOv8s	82.4	78.2	0.802	80.6	92

4 结论

a. 提出了基于改进 CycleGAN 与 YOLOv8s 的水下裂缝图像识别方法。

b. 改进 CycleGAN 网络生成的图像更加符合真实水下场景特征，并且通过该方法进行数据扩充后在不同网络中都能有效提高后续识别任务的检测精度，证明该方法具有普适性。

c. 改进 YOLOv8s 网络有效提升了水下裂缝的检测性能与检测效果，在水下裂缝识别任务中具有较高的适用性和可信度。

参考文献：

[1] 吴中如. 重大水工混凝土结构病害检测与健康诊断[M]. 北京：高等教育出版社，2005.

[2] 来记桃，聂强，李乾德，等. 水下检测技术在雅砻江流域电站运维中的应用[J]. 水电能源科学，2021，39(11)：207-210，144.

[3] CHEN D，HUANG B，KANG F. A review of detection technologies for underwater cracks on concrete dam surfaces[J]. Applied sciences，2023，13(6)：3564.

[4] HUANG B，KANG F，LI X，et al. Underwater dam crack image generation based on unsupervised image-to-image translation[J]. Automation in construction，2024，163：105430.

[5] ARJOVSKY M，CHINTALA S，BOTTOU L. Wasserstein generative adversarial networks[C]//International Conference on Machine Learning. PMLR，2017：214-223.

[6] YANG L，ZHANG R Y，LI L，et al. Simam：A simple，parameter-free attention module for convolutional neural networks[C]//International Conference on Machine Learning. PMLR，2021：11863-11874.

Underwater Crack Identification for Concrete Dams Based on Improved CycleGAN and YOLOv8s

ZHAO Yang[1]，KANG Fei[1]，WAN Gang[2]

(1. School of Infrastructure Engineering，Dalian University of Technology，Dalian 116024，China；
2. China Yangtze Power Co.，Ltd.，Yichang 443000，China)

Abstract：Aiming at the problems of difficult image acquisition，scarcity of image samples，low efficiency，poor accuracy and subjectivity of crack detection for underwater cracks in concrete dams caused by the influence of the underwater environment，this study proposes an underwater crack detection method based on generative adversarial network CycleGAN and objtect detection network you only look once (YOLOv8s). Firstly，an improved CycleGAN image style migration network is proposed by introducing the Wasserstein Generative Adversarial Networks-Gradient Penalty (WGAN-GP) loss and the Learned Perceptual Image Patch Similarity (LPIPS) loss as a means to generate high-quality underwater fracture images，and solve the problem of insufficient data samples；After that，an underwater crack recognition network based on improved YOLOv8s is proposed to improve the accuracy of underwater crack image recognition by adding the parameter-free attention mechanism (Simple Attention Mechanism，SimAM) and introducing the cross-entropy monotonic focusing mechanism Wise Intersection over Union (WIoU) loss；The experimental results show that the improved CycleGAN method plays a good role in data expansion，and can effectively improve the accuracy of the subsequent detection task；The improved YOLOv8s method improved the crack identification accuracy by 2.4%，5.4%，2.4% and 1.2% compared with the original network，Faster R-CNN，YOLOX-s and YOLOv5s in the ablation and comparison experiments，and the detection effect can satisfy the requirements of high efficiency and accuracy，which can provide technical support for the identification of underwater cracks in concrete dams.

Key words：underwater crack identification；generative adversarial network；data augmentation；loss function；attention mechanism

中国知网 https://www.cnki.net