

doi:10.3969/j.issn.1003-3114.2025.05.013

引用格式:黄佳一.基于改进Mask R-CNN的红外图像坝体渗水区域检测研究[J].无线电通信技术,2025,51(5):1008-1015.
[HUANG Jiayi. Detection Research of Dam Seepage Areas in Infrared Images Based on the Improved Mask R-CNN[J]. Radio Communications Technology, 2025, 51(5): 1008-1015.]

基于改进Mask R-CNN的红外图像坝体渗水区域检测研究

黄佳一

(福建水口发电集团有限公司,福建福州350004)

摘要:渗水病害监测是大坝安全运行及运维的重点。针对传统大坝观测方法偶然误差大、汛期检测频次无法满足要求等缺点,提出以无人机搭载红外测温相机对坝体表面进行渗水检测。通过红外相机采集坝体表面影像,建立渗水病害区域影像集,将Swin Transformer架构整合到基于区域掩码的卷积神经网络(Mask Region-based Convolutional Neural Network, Mask R-CNN)中,提升该掩码区域检测网络的性能,据此提取渗水区域数据,实现坝体表面渗水区域的快速检测。通过对渗水区域数据二值化处理,统计坝体表面渗水区域面积。以某电站下游坝面为试验对象,结果表明,该方法相比传统大坝观测方法,检测周期缩短80%,渗水区域检测准确率达97%,满足大坝日常观测需求,有效实现大坝渗漏水定量分析。

关键词:大坝;渗水特征提取算法;无人机摄影测量;深度卷积神经网络;渗水识别

中图分类号:TN92

文献标志码:A

开放科学(资源服务)标识码(OSID):

文章编号:1003-3114(2025)05-1008-08



Detection Research of Dam Seepage Areas in Infrared Images Based on the Improved Mask R-CNN

HUANG Jiayi

(Fujian Shuikou Power Generation Group Co., Ltd., Fuzhou 350004, China)

Abstract: Seepage monitoring is crucial for the safe operation and maintenance of dams. Traditional dam observation methods suffer from significant random errors and insufficient inspection frequency during flood seasons. To address these limitations, this study proposes an infrared thermography-based unmanned aerial vehicle inspection system for detecting surface seepage on dam bodies. First, an image dataset of seepage-affected areas on the dam surface was collected and established using an infrared camera. Then, an improved Mask Region-based Convolutional Neural Network (Mask R-CNN) framework was employed to extract seepage region data, enabling rapid detection of surface seepage. Subsequently, binary processing was applied to quantify the seepage area. Finally, the proposed method was validated on the downstream face of a hydropower station. Experimental results demonstrate that the proposed approach reduces the inspection cycle by 80% compared to traditional methods while maintaining sufficient accuracy for routine dam monitoring. This study provides a novel technique for seepage detection and quantitative analysis, offering a new solution for dam leakage inspection and seepage-related damage assessment.

Keywords: dam; seepage feature extraction algorithm; unmanned aerial vehicle photogrammetry; DCNN; seepage identification

收稿日期:2025-04-28

基金项目:国网福建省电力有限公司科技项目(5213S2220004)

Foundation Item: Science and Technology Project of State Grid Fujian Electric Power Co., Ltd. (5213S2220004)

0 引言

大坝是调控水资源和防洪的关键工程,但其安全运行面临严峻挑战。我国 2008 年数据显示,大中型水库大坝安全达标率仅为 64.1%,病险水库占比高达 36%,其中小型水库问题尤为突出^[1-2]。渗漏作为大坝主要病害之一,不仅影响工程效益,更可能引发溃坝风险^[3-4]。为此,国家能源局提出建设智能化监测系统,加强人工智能在病害识别中的应用,以提升大坝安全水平。深入研究渗漏探测技术与评价方法对保障大坝安全具有重要意义。

传统的大坝渗水检测主要依赖人工目测法,这种方法虽然操作简单,但在实际应用中存在诸多局限性。一方面,该方法高度依赖监测人员的技术经验与操作熟练度,导致检测质量存在较大差异;另一方面,手动测量过程容易引入人为误差,显著影响监测数据的可靠性^[5]。

近年来,目标检测技术在工程病害识别领域得到广泛应用,主要分为 2 类典型方法:以 R-CNN^[6]、Fast R-CNN^[7]和 Faster R-CNN^[8]为代表的双阶段神经网络,以及以单次检测多框探测器^[9]和单次检测器系列^[10-12]为代表的单阶段神经网络。在渗水检测方面,田有良等^[13]开发了一种基于 Mask R-CNN 的移动扫描检测系统,结合深度学习与三维激光扫描技术,提升了识别精度和效率,但硬件成本较高。Mask R-CNN 模型实现了渗水区域的快速定位,但检测精度仍有提升空间^[14]。Li 等^[15]提出了一种融合 EfficientNet 深度学习模型与灰度阈值分割的水迹识别算法,提取了渗水特征,但传统图像预处理步骤增加了计算复杂度。针对复杂环境下渗漏检测的挑战,研究人员构建了一种多级 Transformer 编码器与自适应多任务解码器结合的渗水分割模型^[16],解决了湿渍区域边缘模糊的难题,但较高的计算开销影响了实时性能。

针对上述问题,本文面向大坝日常观测的需求,创新性地提出一套基于无人机红外热成像坝体表面渗水检测的统计算法。利用无人机搭载红外测温相机构建坝体表面渗水病害影像数据库,采用改进的 Mask R-CNN 深度学习方法,实现渗水区域的智能识别与数据提取,再通过图像二值化处理定量计算渗水区域面积。以某电站下游坝面为试验对象进行实验,结果表明该方法较传统观测方式检测效率提升 80%,同时达到 97% 的渗水区域检测准确率,满

足大坝日常监测精度要求,为渗漏检测和病害定量分析提供了高效可靠的技术手段。

1 主要工作

1.1 渗水区域快速检测

渗流区域的温度特征呈现显著的环境依赖性:在日照条件下,渗水部位因蒸发冷却效应形成明显的低温异常区;而在无光照环境中,由于水分的热容特性及蒸发减缓,该区域反而表现出相对高温特征。这种现象为红外热成像检测提供了物理依据^[17]。

本文采用 DJI Mavic 3T 无人机进行数据采集,其搭载的 DFOV 为 61°,等效焦距 40 mm,红外相机分辨率为 640 pixel×512 pixel,搭配实时动态差分定位模块及额外惯导单元。红外图像采集覆盖整个研究区,且图像在左右岸方向及垂直高度方向的重叠度均大于 90%,经过拼接、重采样后得到分辨率为 640 pixel×1 024 pixel 的坝体表面红外影像数据集。


1.1.1 大坝渗水病害数据集

首先,对坝体表面影像集基于温度值进行增强、去噪处理。突出温度异常区域,如渗水导致的低温区,并消除环境干扰,如日照反射等。

其次,通过摄影测量技术拼接生成红外图像点云。红外图像是通过捕捉物体自身辐射出的红外光波生成图像,受环境变化的影响较小,即使在恶劣条件下也能有效捕获目标的位置和轮廓信息,缺点是细节纹理信息丢失严重,空间分辨率低^[18]。通过红外热像仪来采集目标物体的表面温度分布信息,并将其与三维空间坐标系统一融合,同时保留物体的几何形貌和热特征,实现温度场在三维空间中的精准定位及热异常区域的空间量化分析。

然后,经过控制测量、点云重投影、数字微分纠正、灰度赋值、锐化增强,将原始红外图像完整地投影至大坝工程平面坐标,得到高精度的大坝表面红外灰度图像。综合实验目的与硬件条件,采用 1 024 pixel×1 024 pixel 分割完整坝体表面影像得到大坝渗水病害数据集与镶嵌线,对数据集进行筛选和检查,再细分为训练集、验证集和测试集。

最后,由于坝体表面渗水病害的温度值与正常混凝土表面有区别,使用多边形图像标注工具对测试集的坝体表面渗水区域影像进行手动标注,制作语义分割数据集。数据处理流程如图 1 所示。



(a) 红外图像拼接 (b) 灰度数据集制作 (c) 分割模型训练

图 1 数据处理流程

Fig. 1 Data processing flowchart

1.1.2 基于改进 Mask R-CNN 模型的渗水区域检测

本文采用改进 Mask R-CNN 模型,旨在精准定位红外灰度图像中的渗水位置,实现坝体表面渗水病害的高效识别。作为语义分割领域的代表性算法,Mask R-CNN 框架^[19]实现了多任务协同处理能力,包括目标分类、边界框回归和像素级语义分割,其结构如图 2 所示。首先,待处理图像由残差网络(Residual Network, ResNet)^[20]和特征金字塔网络(Feature Pyramid Network, FPN)^[21]共同实现特征提取,由此生成若干特征图。然后,通过区域建议网络

(Region Proposal Network, RPN)对输出的若干特征图进行处理,进而提取出目标候选框^[22]。最后,目标候选框经过感兴趣区域对齐层(RoI Align)处理后,通过分支网络处理后得到渗水区域分类、边框及分割结果^[19]。




图 2 Mask R-CNN 算法模型结构

Fig. 2 Mask R-CNN algorithm model structure

经过测试,坝体红外灰度图像经过 FPN 多层卷积以及池化后,出现少许细小的渗水特征被忽视,且一些其他部件被识别为渗水特征的情况。因此,本文将 ResNet 网络替换为 Swin Transformer^[23-24]主干网络,在最终特征层后引入挤压激励网络(Squeeze-and-Excitation Network, SENet)模块,采用 Transformer CNN 替代原有结构,通过图像分割和特征划分弥补了 Mask R-CNN 的不足。该改进利用多头自注意力机制增强渗水区域像素权重,显著降低误检率,同时保持像素间关联性,完整保留渗水区域边缘特征,为后续渗水面积统计奠定基础。而最后一个特征层后面加入的 SENet 模块^[25]本质上是提取通道特征,把注意力放在有效的通道信息上,不重要的特征就会被忽略掉,进一步提升了分割的准确性。具体改进算法结构如图 3 所示。

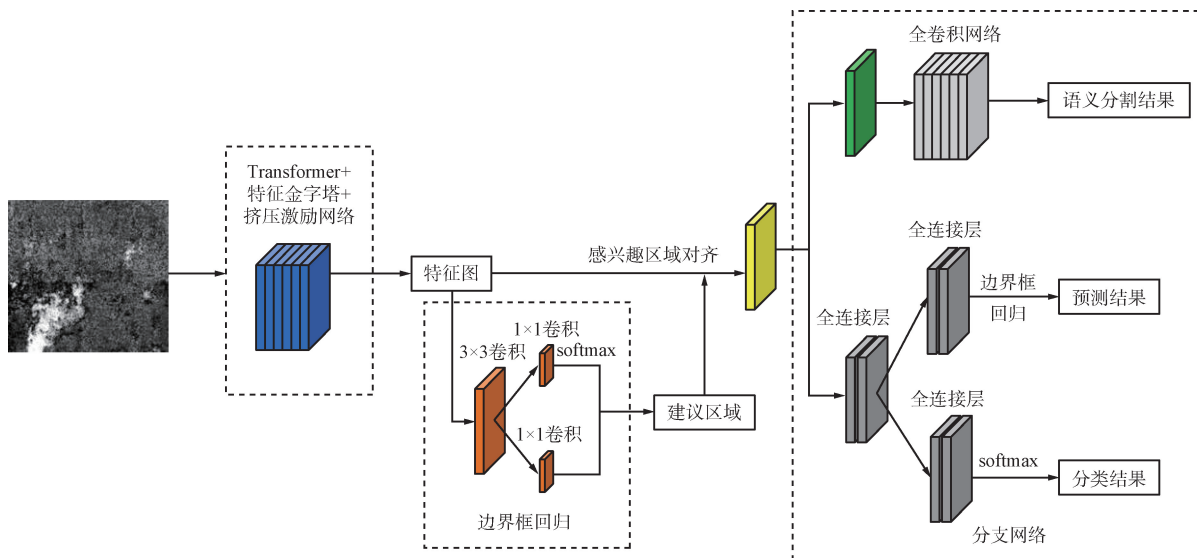


图 3 改进的 Mask R-CNN 算法结构

Fig. 3 Improved structure of Mask R-CNN algorithm

Swin Transformer 算法模型结构如图 4 所示。首先,图像分块模块和线性嵌入层将输入的坝体表面图片进行分块处理,采用 4 pixel×4 pixel 块划分策略,沿深度方向展开以增加图像维度。然后,块合并层执行下采样操作,生成多尺度特征图。最后,Swin Trans-

former Block 含有 2 个结构,如图 5 所示,分别使用基于窗口的多头自注意力(Window-based Multi-head Self-Attention, W-MSA)和基于滑动窗口的多头自注意力(Shifted Window-based Multi-head Self-Attention, SW-MSA),二者配对使用实现特征处理。




图 4 Swin Transformer 算法模型结构

Fig. 4 Swin Transformer algorithm model structure




图 5 2 个连续的 Swin Transformer Block 结构

Fig. 5 Structure of two consecutive Swin Transformer Blocks

(1) 多头注意力机制

W-MSA 和 SW-MSA 采用窗口划分策略处理输入图像,通过局部区域内的注意力计算增强特征提取能力。该方法利用多头注意力机制^[26]突出渗水区域像素的显著性,抑制背景干扰信息,从而提升模型对关键特征的识别精度并降低误判率。

对于每个窗口 X_w , 通过线性变换生成 $Q/W/V$ 矩阵,假设使用 H 个注意力头,每个头的维度是 $d_h = d/H$, 计算为:

$$Q_w^h = X_w W_q^h, K_w^h = X_w W_k^h, V_w^h = X_w W_v^h, \quad (1)$$

式中: W_q^h, W_k^h, W_v^h 为学习权重矩阵,用于生成查询、键、值; Q_w^h, K_w^h, V_w^h 表示窗口内第 h 个头的 $W/K/V$ 矩阵。通过式(1)能够将输入特征映射到不同语义空间($Q/K/V$),捕捉不同角度的特征关系。

计算窗口内所有像素的注意力权重,并加权求和值特征,计算为:

$$Attention(Q_w^h, K_w^h, V_w^h) = \text{softmax}\left(\frac{Q_w^h (K_w^h)^T}{\sqrt{d_h}}\right) V_w^h, \quad (2)$$

式中: $Q_w^h (K_w^h)^T$ 用于计算窗口中每个像素对其他像素的相似度; $\sqrt{d_h}$ 为缩放因子,防止点积过大导致梯度不稳定; softmax 将相似度归一化为注意力权重; V_w^h 用注意力权重加权聚合值特征。

通过式(2)捕捉窗口内的局部上下文信息,例如渗水或物体局部结构。对多头注意力的输出采用拼接方式处理,并通过线性计算与变换融合:

$$MultiHead(X_w) = \text{Concat}(Head_w^1, Head_w^2, \dots, Head_w^H) W_o, \quad (3)$$

式中: $Head_w^h = Attention(Q_w^h, K_w^h, V_w^h)$, $Head_w^h$ 表示第 h 个头的输出; W_o 为可学习的输出投影矩阵; Concat 用于拼接所有头的输出。通过融合不同注意力头学到的多样化特征,增强表达能力。

在注意力得分中加入相对位置偏置 B , 提升对空间位置关系的建模,计算为:

$$Attention(Q_w^h, K_w^h, V_w^h) = \text{softmax}\left(\frac{Q_w^h (K_w^h)^T}{\sqrt{d_h}} + B\right) V_w^h, \quad (4)$$

式中: B 表示可学习的相对位置偏置矩阵,用于编码像素的相对位置。

(2) 基于 FPN 的特征图融合

以 Swin Transformer 充当主干网络,在 4 个阶段依次生成原图尺寸的 1/4、1/8、1/16 和 1/32 的特征图 $\{C_1, C_2, C_3, C_4\}$, 随后通过 FPN 对如上特征图进行特征融合得到新一轮的特征图 $\{P_1, P_2, P_3\}$ 。FPN 具体网络结构如图 6 所示。

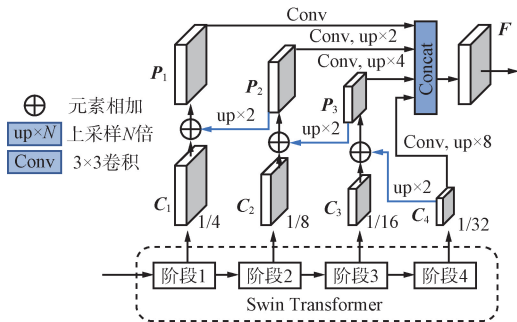


图 6 FPN 网络结构

Fig. 6 FPN network structure

$$P_1 = ReLU(Bn(Conv(C_1))) + UpSample(P_2), \quad (5)$$

$$P_2 = ReLU(Bn(Conv(C_2))) + UpSample(P_3), \quad (6)$$

$$P_3 = ReLU(Bn(Conv(C_3))) + UpSample(C_4). \quad (7)$$

标准化处理由 $Bn()$ 完成, 激活函数采用 $ReLU()$, 上采样操作 $UpSample()$ 将特征图放大 2 倍, 而 $Conv()$ 则实现 3×3 卷积运算。

通过卷积平滑和上采样处理后的特征图 $\{P_2, P_3, C_4\}$, 其尺寸最终与仅进行卷积平滑操作的 P_1 特征图保持一致。随后通过通道 $\{P_1, P_2, P_3, C_4\}$ 拼接生成特征图 F , 最终输入至 SENet 模块, 计算为:

$$F = Concat(P_1, P_2, P_3, C_4). \quad (8)$$

(3) SENet 模块

注意力机制是一种受人类认知机制启发的关键信息筛选方法^[27-28], 其核心优势在于赋予模型自适应调整关注区域的能力, 通过动态权重分配策略^[29], 引导模型聚焦于输入数据中的关键特征。

本文引入 SENet 注意力机制, 其网络结构图如图 7 所示。SENet 的创新点在于引入了一种由挤压和激励操作 2 个关键部分组成的轻量化注意力模块。




图 7 SENet 注意力机制网络结构

Fig. 7 Architecture of SENet attention network

在挤压阶段, 对输入的特征图进行全局平均池

化, 以压缩通道维度, 即输入形状为 (C, H, W) 的特征图 F , H 和 W 分别是高度和宽度, C 是通道数。该网络采用全局平均池化获得 $(C, 1, 1)$ 维度的通道描述符, 这些描述符编码了各通道的全局统计特性, 使模型能够理解不同通道的重要性, 降维特征向量可计算为:

$$z_c = F_{sq}(u_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W u_c(i, j), \quad (9)$$

式中: z_c 和 $F_{sq}(u_c)$ 为第 c 通道中的降维特征向量, u_c 为输入矩阵, i, j 为输入矩阵的行和列。

在激励过程中, 系统先对特征张量进行全连接降维, 再施加 ReLU 和 Sigmoid 函数变换, 从而自动学习通道间的相关性权重:

$$s = F_{ex}(z, W) = \sigma(g(z, W)) = \sigma(W_2 \delta(W_1 z)), \quad (10)$$

式中: δ 为 ReLU 激活函数, σ 为 Sigmoid 激活函数, $W_1(\cdot)$ 、 $W_2(\cdot)$ 为全连接层操作, z 为所有通道 z_c 拼成的向量, 作为式 (10) 的输入。

本文模型在最后一个特征层后加入 SENet 模块, 旨在提取通道特征, 将注意力聚焦于有效的通道信息, 同时忽略不重要的特征, 进一步提升了分割的准确性。

1.2 渗水病害面积快速统计

1.2.1 渗水病害图像二值化

本节使用改进的 Mask R-CNN 模型获取坝体渗水区域表面渗水病害的数据集作为研究基础, 对渗水病害的面积进行详细的统计分析。对模型输出的掩码进行二值化处理, 将其转化为高精度的二值图像数据集, 作为渗水病害统计分析的基础。

通过设定合理的阈值 T , 将掩码中概率值大于 T 的像素判定为渗水区域 (赋值为 1), 其余区域判定为正常 (赋值为 0)。这种基于模型置信度的二值化处理, 显著提升了渗水边界的清晰度, 消除了因温度渐变导致的模糊效应。在本数据集分析中, 当阈值 T 设定为 0.7 时 (基于验证集 ROC 曲线分析), 模型在准确率与误率之间达到最优平衡, 具体效果如图 8 所示。



图 8 基于二值化图像的渗水面积快速统计

Fig. 8 Rapid estimation of seepage area based on binarized images

1.2.2 渗水病害面积快速统计

在实际的检测工作中,需要获取坝体表面中渗漏水的面积、数量、位置等信息。对灰度栅格图像,运用图像处理技术对渗水区域进行通道增强、图像腐蚀、图像膨胀、图像填充等步骤提取出若干个不相连的区域,对这些区域进行连通域标记并统计格网数量^[30],记为 n_1, n_2, \dots, n_i 。图像上每个像素都代表大小相同的正方形,最终渗水面积可计算为:

$$\sum S_i = n_i \cdot Step^2, \quad (11)$$

式中:Step 代表像素的边长,设定为 0.2 cm。

2 试验分析与评价

2.1 研究场景

为验证本文方法的可行性和精度,2022 年 9 月—2023 年 9 月在某大坝下游坝面进行了渗水面积统计的试验研究,某电站是一座以发电为主的引水式电站,在通过竣工验收投入使用后,由于坝体渗漏和析钙等问题曾被评为病坝,后期经补强加固处理后恢复正常,每周仍需对其进行表面渗水情况检查。

2.2 模型训练

根据前文所述,将 2022 年 9 月—2023 年 8 月拍摄的坝体图片作为数据集,其中训练集 11 211 张、验证集 2 151 张,共计 13 362 张大坝表面红外灰度图像用于模型的训练工作。

改进后的 Mask R-CNN 模型在初次训练时,先在 ImageNet 数据集上进行预训练。完成预训练后,采用相同的参数配置,选取 10 240 张坝体表面渗水区域的红外灰度图像作为训练集,进行模型的迭代训练,最后使用另外选取的 2 048 张验证集红外灰度图像进行准确度评价后完成模型训练。模型迭代选择的参数如表 1 所示,一般情况下,交并比(Intersection over Union, IoU)的值为 0.5 或以上时,表示检测成功。

表 1 模型训练参数设置

Tab. 1 Model training parameter settings

序号	参数类型	参数值
1	权重衰减值	0.005
2	学习率	0.000 1
3	Epoch 值	100
4	学习率调度流程策略	Step
5	预热起始学习率	0.000 1
6	预热策略	Linear
7	预热迭代次数	100

续表

序号	参数类型	参数值
8	衰减学习率起回合数	50
9	衰减学习率止回合数	100

本实验将 IoU 的阈值设为 0.7,表 2 展示了多个经典分割模型的训练结果。相较之下,CenterMask^[31]相比原始 Mask R-CNN 在精度和召回率上略有提升。而改进后的模型对比其他 2 个方案,在准确率、召回率和整体性能上均有优势。

表 2 不同模型的训练结果

Tab. 2 Training results of different models

模型	准确率	召回率	AP	mAP
Mask R-CNN	0.942	0.856 0	0.916 0	0.916 0
CenterMask	0.963	0.887 0	0.952 0	0.959 0
改进后的 Mask R-CNN	0.970	0.897 5	0.973 7	0.973 7

表 3 进一步给出比较模型的复杂度,可以看出改进后的 Mask R-CNN 引入 Swin Transformer 主干网络,在保持原有结构的基础上提升了分割精度,但也带来了参数量和计算量的增加,模型复杂度高于原始 Mask R-CNN 和 CenterMask,推理速度略有下降。

表 3 复杂度比较

Tab. 3 Comparison of complexities

模型	参数量/M	每秒帧率/(帧/秒)
Mask R-CNN (ResNet50)	44	5~8
CenterMask	34	12~15
改进后的 Mask R-CNN	60	3~6

2.3 坝体表面渗水面积输出

将 2023 年 9 月 12 日的 923 幅样本数据集作为测试集输入训练完成的 Mask R-CNN 模型,输出 641 幅分割出渗水特征的红外灰度图像,其中坝左岸 298 幅,坝右岸 343 幅,将分割出的红外灰度图像进行二值化处理后采用式(10)进行面积统计,最终输出某电站下游坝面的总渗水面积 $S_{\text{总}} = 105.342 \text{ m}^2$,其中,坝左岸渗水面积 $S_{\text{左}} = 23.684 \text{ m}^2$,坝右岸渗水面积 $S_{\text{右}} = 81.658 \text{ m}^2$ 。

同一时间段,投入 8 组人员采用传统方法观测,总耗时 8 h,得到下游坝面总渗水面积 $S'_{\text{总}} = 101.22 \text{ m}^2$,坝左岸渗水面积 $S'_{\text{左}} = 21.24 \text{ m}^2$,坝右岸渗水面积 $S'_{\text{右}} = 79.98 \text{ m}^2$ 。左、右岸坝渗水统计叠加如图 9 所示。




图9 左、右岸坝段渗水统计叠加


Fig. 9 Overlay of seepage statistics for left and right dam sections

2.4 方法精度评价


以渗水区域分布为指标验证本文方法输出的面积精度,核心思路是将分割后的图像重新根据镶嵌线还原回一整张大图并叠加在传统观测方法得到的坝体表面渗水区域 CAD 图上。将分割后的渗水区域与传统方法得到的渗水区域的分布位置、渗水面积等指标对比,实现对方法精度的评价。

采用本文方法对 2023 年 9 月 12 日所采集的数据集中右岸桩号坝 0+021~坝 0+069、左岸桩号坝 0+144~坝 0+178 的红外灰度数据集进行处理,共识别出渗漏水病害 131 处,集中在坝右岸桩号坝 0+025~坝 0+069、高程 105~140 m 以及坝左岸桩号坝 0+147~坝 0+151、坝 0+157~坝 0+167 处。本文方法与传统人工目测法所得出的渗水面积分布基本一致,渗水结果分析如图 10 所示,分析得出以上所列渗漏水区域需要日常维护重点关注。

本文方法发现有 95 处面积小于 0.5 m² 渗水病害(即湿斑),而传统人眼观察仅记录其中 7 处,这表明本文方法在检测面积较小、目视特征不明显的渗水病害方面性能显著优于人眼观测,能够弥补人眼观测的不足。以人工测量的面积为基准,本文方法得出的坝体渗水面积准确率在 90%以上,能够满足日常坝体渗水观测要求。



(a) 本文方法与传统人工目测法对比结果



(b) 各区域面积的渗水数量统计

图 10 渗漏水分析结果

Fig. 10 Results of water seepage analyses

3 结束语

坝体表面渗水严重威胁大坝运行安全,本文基于改进的 Mask R-CNN 深度学习神经网络模型实现了对大坝表面渗水区域面积的快速检测、提取、统计。采用摄影测量技术,得到以无人机红外灰度图像为基础的大坝渗水病害数据集,基于此数据集进行神经网络训练与测试,对改进后的 Mask R-CNN 模型在坝体渗水病害快速检测中的准确性、有效性进行了评估。将本文方法所得出的渗水面积与传统方法统计的渗水面积对比,得出本文方法的渗水精度误差在 3%~7%,能够满足大坝日常观测需求;而在检测面积较小、目视特征不明显的渗水病害区域上,该方法明显优于人眼观测性能。结果表明,基于改进的 Mask R-CNN 深度学习神经网络模型的图像处理技术在渗水病害中能够极大地提升渗漏水检测的效率与自动化程度,为其他工程场景渗漏水检测工作提供新的方法。

此外,本文所检测的大坝病害只包括渗水病害,病害种类单一,未来研究可考虑增加病害种类,扩大改进模型的应用范围。

参考文献

- [1] 方卫华. 纵论大坝安全监测[J]. 水利水文自动化, 2001(3):9-12.
- [2] 杨杰. 大坝安全监控中若干不确定性问题的分析方法与应用研究[D]. 南京:河海大学,2006.
- [3] 王周蓉,王小波,杜国平. 基于声呐技术的霍林河水库大坝渗漏区分分析[J]. 长江技术经济,2023,7(2):58-62.
- [4] 杭辉. 地球物理计算在大坝渗漏检测中的应用[J]. 水利科技与经济,2025,31(7):145-149.
- [5] 陈文燕,朱林,王文韬. 大坝安全监测的现状与发展趋势[J]. 电力环境保护,2009,25(6):38-42.

- [6] CAI Z W, VASCONCELOS N. Cascade R-CNN: Delving into High Quality Object Detection [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 6154-6162.
- [7] 郭磊, 王洋, 靳正轩, 等. 基于改进 Faster RCNN 的化纤丝缺陷检测[J]. 毛纺科技, 2023, 51(3): 74-79.
- [8] CHERPANATH E D, NASREEN P R F, PRADEEP K, et al. Food Iage Recognition and Calorie Prediction Using Faster R-CNN and Mask R-CNN [C] // 2023 9th International Conference on Smart Computing and Communications (ICSCC). Kharagpur: IEEE, 2023: 83-89.
- [9] 汪宋, 费树岷. SSD (Single Shot MultiBox Detector) 目标检测算法的研究与改进[J]. 工业控制计算机, 2019, 32(4): 103-105.
- [10] REDMON J, FARHADI A. YOLO9000: Better, Faster, Stronger [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 7263-7271.
- [11] REDMON J, DIVVALA S, GIRSHICK R, et al. You Only Look Once: Unified, Real-time Object Detection [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 779-788.
- [12] ZHANG S S, YANG J, SCHIELE B. Occluded Pedestrian Detection Through Guided Attention in CNNs [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 6995-7003.
- [13] 田有良, 樊廷立, 唐超. 面向地铁隧道表面渗漏水快速检测技术[J]. 测绘通报, 2022(9): 29-33.
- [14] 周宝定, 谢沛瑶, 郭文浩, 等. 基于激光点云灰度图像的隧道渗水病害检测[J]. 测绘通报, 2023(8): 34-39.
- [15] LI J Q, HE Z Y, LI D X, et al. Research on Water Seepage Detection Technology of Tunnel Asphalt Pavement Based on Deep Learning and Digital Image Processing [J]. Scientific Reports, 2022, 12(1): 11519.
- [16] ZHAO L, WANG J W, LIU S P, et al. An Adaptive Multi-task Network for Detecting the Region of Water Leakage in Tunnels [J]. Applied Sciences, 2023, 13(10): 6231.
- [17] 肖翠翠, 远航. 基于红外热成像技术的建筑外墙渗漏及空鼓检测研究[J]. 北方建筑, 2025(1): 70-73.
- [18] 朱自文, 宋晓鸥, 崔巍, 等. 可见光-红外图像融合的目标检测综述 [J/OL]. 计算机工程与应用 (2025-03-21) [2025-04-07]. <http://kns.cnki.net/kcms/detail/11.2127.TP.20250321.1453.006.html>.
- [19] HE K, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN [C] // Proceedings of the IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 2961-2969.
- [20] HE K M, ZHANG X Y, REN S Q, et al. Deep Residual Learning for Image Recognition [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770-778.
- [21] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature Pyramid Networks for Object Detection [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 2117-2125.
- [22] REN S Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards Real-time Object Detection with Region Proposal Networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(6): 1137-1149.
- [23] LIU Z, LIN Y T, CAO Y, et al. Swin Transformer: Hierarchical Vision Transformer Using Shifted Windows [C] // Proceedings of the IEEE/CVF International Conference on Computer Vision. Montreal: IEEE, 2021: 10012-10022.
- [24] 马文轩, 蔡卓燃, 徐从安, 等. 基于深度学习的认知无线电调制参数估计[J]. 无线电通信技术, 2023, 49(2): 216-230.
- [25] HU J, SHEN L, SUN G. Squeeze-and-excitation Networks [C] // Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 7132-7141.
- [26] VASWANI A, SHAZEER N, PARMAR N, et al. Attention Is All You Need [C] // Advances in Neural Information Processing Systems. Long Beach: Curran Associates, Inc, 2017: 5998-6008.
- [27] 陈池瑶, 苗世洪, 殷浩然, 等. 基于注意力机制-卷积神经网络的配电网单相接地故障选线方法[J]. 电力建设, 2023, 44(4): 82-93.
- [28] 张学军, 周云, 牡丹, 等. 基于多尺度注意力特征的识别算法研究[J]. 无线电通信技术, 2021, 47(4): 513-518.
- [29] KONG Z Q, TANG B P, DENG L, et al. Condition Monitoring of Wind Turbines Based on Spatio-temporal Fusion of SCADA Data by Convolutional Neural Networks and Gated Recurrent Units [J]. Renewable Energy, 2020, 146: 760-768.
- [30] 朱林川, 黄声享, 张赛, 等. 一种基于点云的隧道渗漏检测方法[J]. 测绘通报, 2021(增刊2): 140-144.
- [31] LEE Y W, PARK J. CenterMask: Real-time Anchor-free Instance Segmentation [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 13906-13915.

作者简介:

黄佳一 女, (1996—), 工程师。主要研究方向: 水利工程水工建筑物观测。