

基于 YOLOv5s 优化模型的堤坝渗漏目标检测研究

梁建^{1,2}, 年立强³, 张广何^{1,2}, 唐邦俊⁴, 马飞跃^{1,2}

(1.安徽省·水利部淮委水利科学研究院,安徽 合肥 230088;2.安徽省水科学与智慧水利重点实验室,安徽 合肥 230088;3.中水淮河安徽恒信工程咨询有限公司,安徽 合肥 230601;4.黄山市水利局,安徽 黄山 245000)

摘要:【目的】依托无人机、红外热成像等技术,快速、准确地发现堤坝渗漏并进行定位,可大幅地提高堤坝巡检效率。开展基于 YOLOv5s 优化模型的堤坝渗漏目标检测研究,以确保及时、准确地发现堤坝汛期渗漏隐患,从而保障防洪安全。【方法】通过对 20 余座有渗漏现象的水库大坝采集图像,自制 529 张堤坝渗漏影像数据集为模型提供训练样本,提出基于 YOLOv5s 优化模型的堤坝渗漏红外图像目标检测网络,在网络中引入 CBAM 注意力机制模块提高网络模型的准确度,从通道和空间提取特征信息,引入 Ghost 模块对网络模型进行轻量化处理,应用自制数据集进行对比试验。【结果】提出的优化模型目标检测 Precision 达到 89.8%,相较于 YOLOv5s 提高了 3.1%。【结论】优化后模型可用于堤坝工程渗漏检测技术,具有重要的工程实际意义。

关键词:堤坝渗漏;红外热成像;深度学习;目标检测;YOLOv5 优化模型

中图分类号: TV221

文献标识码: A

由于外部环境、结构老化等因素,汛期高水位状态下堤坝易产生渗漏。堤坝早期渗漏渗水量较小且未对结构造成明显破坏相对容易控制。为了及时、准确地发现早期渗漏隐患,汛期需对堤坝实施 24 小时不间断、拦网式、地毯式排查,对巡堤人员数量、查险方式等有详细规定^[1]。然而依赖于人工巡视的方法制约了防汛应急处置水平,难以适应堤坝工程全天候的监测需求,亟需更为高效、精准且实时的检测方法替代人工目视巡查,以应对堤坝渗漏问题的挑战。

无人机具有灵活性、高空间分辨率等优势,适用于大场景大规模数据采集^[2],为堤坝隐患检测提供了全新的可能性^[3-4]。通过在无人机平台上搭载高清可见光相机、红外热像仪、激光雷达等先进的传感器,对堤坝进行高效、全面的检测,快速获取巡检区域的多模态图像数据^[5-6]。结合相应的图像识别算法,实现图像中裂缝、渗漏等隐患的快速高效识别,同时可满足同一隐患不同时期多次巡检比较以观察隐患发展的需求。目标检测算法中 YOLO (You Only Look Once, YOLO) 将检测任务简化为回归问题,是端到端的单阶段检测方法;YOLOv2 (You Only Look Once version 2, YOLOv2)、YOLOv3 (You Only Look Once version 3, YOLOv3) 和 YOLOv4 (You

Only Look Once version 4, YOLOv4) 改进了特征提取并引入多尺度检测方法,在实时性和检测精度之间达到了较好的平衡;YOLOv5 (You Only Look Once version 5, YOLOv5) 改进了骨干网络并采用了数据增强技术,适用于资源受限的场景^[7]。随着复杂场景需求的增加,如何在保持高效检测的同时提升模型的检测精度仍是研究重点。相比较裂缝检测模型,堤坝渗漏检测模型相对较少。周仁练等搭建了土石堤坝汛期服役条件模拟平台,结果表明午后和夜间是利用红外热成像巡查土石堤坝渗漏的较佳时段^[8],提出了基于无人机载式红外—可见光成像的土石堤坝工程渗漏巡查流程,并在多种天气条件下开展了实际工程现场巡测试验,验证了自然条件下被动红外热成像探测土石堤坝渗漏的可行性^[9-10]。朱宏亮提出了基于双模态多时相堤坝渗漏智能配准与变化识别方法,但由于样本数量较少,与真实的无人机堤坝巡检场景有所差异^[11]。

以上研究推动了高效、精准、智能的堤坝渗漏隐患识别的应用,但缺少真实的无人机巡检采集的堤坝渗漏数据集以及相应的渗漏红外影像智能识别算法。本研究借助无人机平台搭载红外热像镜头对有渗漏现象的水库大坝进行图像采集,自制堤坝渗漏影像数据集,探索基于深度学习的堤坝渗漏红

收稿日期/Received:2024-06-05

修回日期/Revised:2024-10-26

基金项目:国家自然科学基金(52178368);安徽省自然科学基金“水科学”联合基金项目(2208085US08, 2308085US15);安徽省水科院青年创新计划项目(KY202106, KY202101);安徽省建筑工程质量监督检测站专题科研项目(KYJC202201)。

第一作者:梁建(1984—),男,高级工程师,博士,从事水工结构及材料相关方面的研究。E-mail:sdaulj@163.com。

外图像目标检测方法,结合先进的传感器技术和数据处理算法,提高堤坝渗漏检测的精度、效率和实时性,为汛期堤坝渗漏区域智能检测提供更为可靠的技术支撑。

1 试验设计及模型优化研究

红外影像数据利用物体表面的温度差异来生成图像,通过分析温度差异可以识别渗漏场景。本研究基于无人机平台搭载可见光与红外镜头对多座水库大坝进行数据采集获取可见光和红外影像,分析渗漏区域在不同时段、不同天气条件下红外影像的光学特性,对比渗漏区域与非渗漏区域的区别,构建堤坝渗漏数据集,为深度学习模型训练提供样本。数据采集平台采用大疆 M300 RTK 无人机搭载禅思 H20T 镜头,镜头内置热红外和可见光传感器,通过对 20 余座有渗漏现象的水库采集图像,共收集渗漏红外影像 200 余张。

对所采集的影像进行筛选,通过使用 Labelling 开源软件对筛选的影像进行数据标定,包括渗漏目标的位置和边界框信息。将数据按 6:2:2 的比例划分为训练集、验证集和测试集。对训练数据进行随机旋转、翻转、缩放、亮度调整等数据增强操作,以增加模型的鲁棒性和泛化能力。最终构建的堤坝渗漏数据集由 529 张红外影像组成,其中 318 张用于训练,105 张用于验证,106 张用于测试。

基于采集的照片进行渗漏目标检测,目的是在图像中定位和识别出异常区域的存在及其所属类别。目标检测网络是用于执行目标检测任务的深度学习网络,主流算法包括区域卷积神经网络(Region-based Convolutional Neural Network, R-CNN)、YOLO 和单次多框检测器(Single Shot MultiBox Detector, SSD)等系列。在目标检测任务中,当目标被其他物体或场景部分遮挡时,目标检测模型可能会出现难以正确定位和识别的问题。对于小尺寸的目标,由于其在图像中的信息量相对较少模型难以准确检测和定位。针对以上问题,本文基于 YOLOv5s,在考虑检测精度与模型轻量化的基础上,融合卷积块注意力模块(Convolutional Block Attention Module, CBAM)注意力机制模块,并引入 Ghost 模块改进目标检测模型。

本研究深度学习试验均在 Windows 11 上进行,采用 PyTorch 2.1.0 深度学习框架;CUDA 版本为 11.8;CPU 为 12th Gen Intel(R) Core(TM) i7-12700KF; RAM 16 GB;GPU 为 NVIDIA GeForce RTX3080,显存为 10 GB;运行平台 PyCharm;编程语言 Python 3.8。试验迭代次数为 500 次,数据集输入尺寸大小为

640×640。

1.1 CBAM 注意力机制

为了提升模型性能与检测精度,引入 CBAM 注意力机制。CBAM 是一种用于增强卷积神经网络(CNN)性能的注意力机制^[12]。CBAM 模块主要关注特征图中的通道注意力和空间注意力,以更好地捕捉图像中重要的特征。CBAM 机制主要包含通道注意力模块(Channel Attention Module, CAM)和空间注意力模块(Spatial Attention Module, SAM),如图 1 所示。




图 1 CBAM 注意力机制^[11]

Fig. 1 CBAM attention mechanism

其中 CAM 为通道注意力模块:对于输入尺寸 $C \times H \times W$ 的特征图 F 经过并行的最大池化层(Maximum Pooling, MaxPool)和平均池化层(Average Pooling, AvgPool),将特征图沿着高度和宽度进行池化得到 $C \times 1 \times 1$ 大小的特征图。进而通过共享多层感知机层(Multilayer Perceptron, MLP),将其通道数 Channel 先压缩再扩张并经过线性整流单元(Rectified Linear Unit, ReLU)激活函数得到两个特征结果。最后将这两个特征结果在相同维度上进行元素相加并通过 Sigmoid 激活函数得到通道注意力输出结果。

SAM 为空间注意力模块:将 CAM 中得到的通道注意力输出结果 F' 先经过 MaxPool 最大池化层再经过 AvgPool 平均池化层得到两个 $1 \times H \times W$ 特征图,通过 Concat 将两个特征图进行拼接并使用 7×7 卷积将其通道数 Channel 变为 1,最后经过 Sigmoid 激活函数得到空间注意力输出结果。

1.2 Ghost 模块

引入 CBAM 注意力机制模块后,模型参数增多复杂度提升,影响模型检测效率,因此引入 Ghost 模块构建轻量化模型,来降低引入 CBAM 注意力机制模块所产生的计算量损失。Ghost 模块主要思想是在卷积操作之前引入一个较小的卷积,然后通过一个线性变换和一个标准的卷积来生成最终的输出

^[13]。Ghost 模块的目标是在减少计算成本的同时保持良好的网络表达能力。

图 2 为 Ghost 卷积操作,其操作流程为:首先,用普通卷积得到特征图 F' ,运算量约为: $F' = X * f'$,其中 X 为输入特征, f' 为卷积核;然后,将 F' 的每一个通道的特征图进行线性变换生成特征图 F'' ,图中 Φ_i 表示为用不同尺寸大小的卷积核进行线性变换;最后,将 F' 恒等映射(Identity)与 F'' 拼接得到最终输出结果。




图 2 Ghost 卷积^[13]

Fig. 2 Ghost convolution

利用轻量化的优势构建 BottleNeck,如图 3 所示。BottleNeck 由两个堆叠的 Ghost Module 组

成,用于替换网络中原有常规卷积,并将新构建的 CBAM 注意力机制模块组合成基于 CBAM 的 Ghost 跨阶段部分通道模块(Ghost Cross-Stage Partial Channel with CBAM module, Ghost C-C3C)。基于以上改进,本文提出的优化 YOLOv5s (You Only Look Once version 5 small, YOLOv5s) 算法如图 4 所示。




图 3 Ghost bottleneck 颈部网络^[12]

Fig. 3 Ghost bottleneck neck network




图 4 优化后 YOLOv5 网络结构图

Fig. 4 Optimized YOLOv5 network structure diagram

2 试验结果与分析

进行渗漏数据采集的 20 余座水库大坝均为土石坝,大坝坝后均设草皮护坡,部分水库坝脚设排水棱体。样本中设有排水棱体的大坝渗漏点一般在棱体内部,渗漏水汇集在排水棱体底部排水沟,表现在红外影像上为条形低温区域;未设排水棱体的大坝

渗漏点在坝坡上,表现在红外影像上为点状或多点的低温区域。

2.1 渗漏特征分析

红外影像融合了温度信息维度,可以获取更加全面的目标物体和场景信息。图 5 为不同场景大坝渗漏影像图片,共分 12 个场景进行讨论,每个场景中左图为可见光图像,右图为红外图像。可见光照

片在不同环境下呈现不同特征,但红外影像却呈现相似特征。从图中可以发现,渗漏区域温度明显要低于周边附近地物温度,温度信息为深度学习提供

了额外的维度进行特征提取,可以实现对渗漏场景的高效识别和分析。以下分几种典型场景对渗漏特征进行分析。




图 5 不同场景的大坝渗漏影像

Fig. 5 Dam leakage images of different scenes

红外影像在非完全遮挡状态下可以透过植被缝隙发现低温现象。图 5(a1)为无遮挡情况下的渗流影响,渗漏区域的温度在 15 °C 左右,非渗漏区域温度在 25 °C 以上;图 5(a2)为杂草遮挡情况下的渗

流影响,渗漏区域的温度在 9 °C 左右,非渗漏区域温度在 14 °C 以上;图 5(a3)为灌木遮挡情况下的渗流影响,渗漏区域的温度在 9 °C 左右,非渗漏区域温度在 15 °C 以上。图中可以发现,有遮挡的情况下在可

见光图像中很难发现渗漏现象,红外影像可通过植被的缝隙发现渗漏现象。

红外影像不受光照条件的限制,因此在光照强烈或是光照不足的环境下仍可以有效工作。图 5(b1)为渗漏出逸在光照充足的场景,图 5(b2)为渗漏出逸在夜晚光照不足的场景,光照不足的情况下可见光很难发现渗漏现象,但红外影像却能清晰的发现渗漏特征。图 5(b3)为渗漏出逸在大雾天气的场景,可见光图像可以发现场景中有大量树木,红外图像可以发现明显的渗漏明流,渗漏区域的温度在 10℃ 左右,非渗漏区域温度在 12℃ 以上,2℃ 的温差在红外图像上有明显差异。

图 5(c1)为渗漏出逸点在积水的场景,水体温度为 23.2℃,出逸点温度为 16.7℃,坝体温度约 33.6℃,渗漏水进入积水后有明显升温的过程。图 5(c1)和图 5(c2)为同一地点不同时期的渗漏情况,图 5(c2)中渗漏出逸点水温较低,水温与坝体温差较小,渗漏出逸的特征相对不明显,但也能体现相应的渗漏特征。

图 5(d)为渗漏出逸上覆盖草皮的场景。坝体渗漏出逸点上覆盖草皮后,在草皮连接处有明显的温度变化,而可见光较难发现渗漏点,红外影像显示草

皮连接处温度在 23℃ 左右,而草皮的温度在 30℃ 以上,二者有 7℃ 的温差。图 5(e)渗漏点被杂草覆盖,渗漏区域温度在 17.2℃,非渗漏区域在 26.5℃,有约 10℃ 的温差;图 6(f)为渗漏出逸成明流的场景,该大坝有多个渗漏出逸点,出逸后成明流向下游河道汇集,明流温度为 6.7℃,坝坡温度为 10.6℃,渗流点与坝体有约 4℃ 的温差;图 5(g)渗漏点为较小的面状区域,渗漏区域温度在 19.6℃,非渗漏区域在 27.3℃,有约 7℃ 的温差。

以上数据采集季节为春夏季节,气温差异较大。渗漏区域与非渗漏区域的温差为 2~10℃,图中可以发现,温差较小时渗漏区域和非渗漏区域的温度普遍偏低,温差较大时渗漏区域和非渗漏区域的温度普遍偏高。表明天气温度越高,渗漏区域与非渗漏区域的温差越大。以上不同场景大坝渗漏影像,根据渗漏区域大小呈现不同特征。图 5(a)、图 5(b)、图 5(f)面积较大,属于片状的渗漏区域;图 5(c)、图 5(e)、图 5(g)面积较小,属于点状小面积渗漏区域;图 5(d)较分散,属于多点渗漏。因此根据采集的渗漏红外影像数据特征,可将渗漏区域划分为大面积渗漏、小面积渗漏和多点渗漏三种类型,相应的典型渗漏场景如图 6 所示。




图 6 数据采集典型渗漏场景分类示意图

Fig. 6 Data acquisition typical leakage scene classification diagram

2.2 目标检测算法评价指标

通过渗漏特征分析表明红外影像可以获取更加全面的目标物体和场景信息,进而提高目标检测准确性。文章采用自制的堤坝渗漏影像数据集为模型提供训练样本,融合 CBAM 注意力机制模块,并引入 Ghost 模块改进 YOLOv5s 目标检测模型,对堤坝渗漏影像数据进行目标检测。

针对提出的优化算法进行评价,指标包括:网络

层数 (Layer)、参数量 (Parameters)、计算量 (GFLOPS)、精确度 (Precision)、召回率 (Recall) 及精度均值 mAP (mean Average Precision),计算公式如下:

$$P = TP / (TP + FP) \quad (1)$$

$$R = TP / (TP + FN) \quad (2)$$

$$mAP = \frac{1}{C} \sum_{i=1}^C AP_i = \frac{1}{C} \int_0^1 P(R) dR \quad (3)$$

式中: P 为准确率; R 为召回率; TP 为预测正实际为正; FN 为预测负实际为负; FP 为预测负实际为正。

为了验证评价模型引入 CBAM 注意力机制模块和 Ghost 模块的有效性,以及优化后对算法性能效率的提升,进行消融试验,得到优化后模型的各项参数,详见表 1。由表 1 可以看出,原始模型 5s 的网络层数 Layer 最少为 270 层,对应的参数量为 70.2 M,计算量为 15.9 GB。单独增加 CBAM 注意力机制模块后,网络层数、参数量与计算量均增多,对应的精度均值_0.5 (交并比阈值为 0.5 时的精度均值)降低了 1.8%,精确度降低了 1%。单独增加 Ghost 模


块后,网络层数虽然明显增加,但是参数量和计算量却明显降低,对应的精度均值提高到 78.3%,精确度提高到 87.1%。本文将 CBAM 注意力机制模块与 Ghost 模块引入后,网络层数为所有模型中最多的 516 层,但是参数量和计算量较原有 5s 模型分别降低了 27.3 M 和 4.4 GB。原始模型 5s 的卷积网络层数 Layer 为 270 层,在特征提取时无法较好地捕捉到准确特征细节。而 CBAM 注意力机制在 5s 模型的基础上进行特征提取导致负效果的发生。相比较之下 Ghost+CBAM 模块拥有 516 层 Layer,能够更加准确地提取有效特征,召回率整体水平较为平均。

表 1 消融试验
Tab. 1 Ablation test


模型	网络层数	参数量/M	计算量/GB	精度均值 0.5/%	精确度/%	召回率/%
5s	270	70.2	15.9	77.9	86.7	93
+Ghost	479	36.8	8.3	78.3	87.1	93
+CBAM	374	70.3	15.7	76.1	85.7	94
Ghost+CBAM	516	42.9	11.5	79.3	89.8	94

经试验证明,本文优化后的 YOLOv5s 模型针对堤坝渗漏目标检测更有优势与原始模型 5s 相比较,本文提出的模型精度均值提升 1.4%,精确度提升 3.1%。引入的 CBAM 注意力机制模块对于模型性能有提升,但同时也会增加一定的参数量和计算量。CBAM 注意力机制针对大面积渗漏、多面积渗漏和小面积渗漏三种场景,单次检测时间分别为 1.0 ms、0.7 ms 和 0.7 ms。而通过引入 Ghost 模块使得模型轻量化并降低了复杂度,单次检测时间分别降低为 0.3 ms、0.4 ms 和 0.4 ms。


模型训练验证集三个评价指标分别为精度均值、精确度、召回率曲线如图 7 所示,其中横坐标为训练迭代次数,纵坐标为三个评价指标值。随着迭代次数增加,三项评价指标不断上升,表明基于 YOLOv5s 优化模型的改进算法参数及网络模型设置合理。



(a) 精度均值_0.5



(b) 精确度



(c) 召回率

图 7 精度均值、精确度、召回率对比图
Fig.7 Accuracy mean, accuracy, recall rate comparison chart

2.3 目标检测结果分析

根据渗漏面积大小、渗漏点分布情况等特点,

将采集数据分为大面积渗漏区域、小面积渗漏区域和多点渗漏区域。渗漏区域在图像中占据较大比例,具有连续性或明显扩展的特征判断为大面积渗漏;渗漏区域较为局限,面积较小,呈现出局部渗漏或小范围集中的特征判断为小面积渗漏;渗漏点呈离散分布,多个渗漏点分布于图像的不同位置,判断为多点渗漏。试验选取三种类型的样本对改进模型进行效果检测。

模型优化前后的堤坝渗漏目标检测效果见表 2。从表中可以发现在原始模型 5s 识别结果中,大面积渗漏、小面积渗漏和多点渗漏识别平均准确率约分别为 76%、84%和 83%。使用改进后的 Ghost+CBAM 模型大面积渗漏、小面积渗漏和多点渗漏识别平均准确率分别约为 83%、86%和 87%,分别提升了 7%、2%和 4%。

表 2 堤坝渗漏目标检测对比
Tab. 2 Comparison of dam leakage target detection

模型	YOLOv5s	YOLOv5s 优化模型 (Ghost+CBAM)
大面积渗漏		
小面积渗漏		
多点渗漏		

针对大面积渗漏区域,原始模型与优化后模型均可以识别出渗漏位置。因为其渗漏面积较大,网络模型可以较为容易地提取出特征点进行深度学习,原始模型也能达到大约 80%的识别准确率;优化后的模型针对渗漏识别的准确度有一定的提升,主要得益于更深的网络层和注意力机制的作用。对多点渗漏区域检测效果也是同样的效果,虽然渗漏的区域增多了,但是与大面积渗漏检测识别准确率相似。针对小面积渗漏区域,优化后模型与原始模型的表现相当,表明小面积渗漏其特征较难提取,在原

始模型基础上使用 Ghost 卷积网络和 CBAM 注意力机制模块,对于其识别准确度提升较小。

3 结论

本文通过对 20 余座有渗漏现象的水库采集图像,自制 529 张影像堤坝渗漏数据集为模型提供训练样本,提出基于 YOLOv5s 优化后的准确、轻量模型,在此基础上进行试验研究,主要得到以下结论。

1) 渗漏区域与周围环境的温度有明显差异,不同季节、不同环境场景下,渗漏区域与坝体温度有

所不同。文中渗漏水与周围环境的温差在 2℃以上,且温度越高,渗漏区域与非渗漏区域的温差越大。在晴天、夜晚、大雾等环境下,采用红外热成像探测大坝渗漏是可行的。

2) 基于 YOLOv5s 模型引入 CBAM 注意机制模块提升堤坝渗漏目标检测识别精度,该模块兼顾通道信息特征提取与空间信息特征提取,有助于提升网络模型准确性。引入 CBAM 注意力机制模块后,模型参数增多复杂度提升影响模型检测效率,引入 Ghost 模块可以构建轻量化模型,用以降低引入 CBAM 注意力机制模块所产生的计算量损失。基于 YOLOv5s 优化模型针对三类场景的单次检测时间分别减少了 0.7 ms、0.3 ms、0.3 ms。

3) 试验表明,本文提出的优化后模型相比于原始的 YOLOv5s 模型目标检测 Precision 提高了 3.1%,针对堤坝渗漏目标检测精度更高,可用于堤坝工程渗漏目标检测。

参 考 文 献

- [1] 王荣喜,徐维国,陈祥.2020 年安徽省长江流域防汛抗洪回顾与启示[J].人民长江,2020,51(12):52-55.[WANG R X,XU W G,CHEN X.Review and enlightenment on Yangtze River flood control in Anhui Province in 2020[J].People's Yangtze,2020,51(12):52-55.]
- [2] 宋书学,孙统领,刘文锴,等.无人机序列影像快速三维重建方法研究[J].华北水利水电大学学报(自然科学版),2024,45(1):31-36.[SONG S X,SUN T L,LIU W K,et al.Research on Fast 3D Reconstruction Method for UAV Sequence Images[J].Journal of North China University of Water Resources and Electric Power (Natural Science Edition),2024,45(1):31-36.]
- [3] 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 Y J,CHENG H D,LI H K,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.]
- [4] 胡昊,李擎,马鑫,等.基于影像的道路积水监测研究[J].华北水利水电大学学报(自然科学版),2023,44(1):62-70.[HU H,LI Q,MA X,et al. Research on road water accumulation monitoring based on image[J].Journal of North China University of Water Resources and Electric Power (Natural Science Edition),2023,44(1): 62-70.]
- [5] 苏怀智,周仁练.土石堤坝渗漏病险探测模式和方法研究进展[J].水利水电科技进展,2022,42(1):1-10,39.[SU H Z,ZHOU R L.Research progress and prospect of earth-rockfill dam leakage detection modes and method[J].Advances in Science and Technology of Water Resources,2022,42(1):1-10,39.]
- [6] 王嘉浩,丁勇,黄英豪,等.基于主动激励红外成像的大坝渗漏 AI 识别方法研究[J].激光杂志,2024,45(3):81-86.[WANG J H,DING Y,HUANG Y H,et al.Study on dam leakage AI detection method based on infrared thermal imaging[J].Laser Journal, 2024,45(3): 81-86.]
- [7] ZHANG Y,GUO Z,WU J,et al.Real-time vehicle detection based on improved yolov5[J].Sustainability, 2022,14(19):12274.
- [8] SU H Z,MA J J,ZHOU R L,et al.Detect and identify earth rock embankment leakage based on UAV visible and infrared images[J].Infrared Physics and Technology,2022,122:104105.
- [9] 周仁练,苏怀智,刘明凯,等.基于被动红外热成像的土石堤坝渗漏探测试验研究[J].水利学报,2022,53(1):54-67.[ZHOU R L,SU H Z,LIU M K,et al.Discussion on water and sediment dynamic characteristics and layout optimization of typical artificial reefs in Liaodong Bay of Bohai Sea[J].Journal of Hydraulic Engineering,2022,53(1):54-67.]
- [10] ZHOU R L,SU H Z,WEN Z P.Experimental study on leakage detection of grassed earth dam by passive infrared thermography[J].NTD and E International, 2022,126:102583.
- [11] 朱宏亮.基于多时相无人机载图像的堤坝隐患变化识别方法研究[D].济南:山东大学,2023.[ZHU H L.Research on the identification method of dam defects variation based on multi-temporal UAV-borne images [D].Jinan:Shandong University,2023.]
- [12] WOO S,PARK J,LEE J Y,et al.Cbam:Convolutional block attention module [C].Proceedings of the European Conference on Computer Vision.2018,3-19.

[13] HAN K,WANG Y,TIAN Q,et al.Ghostnet:More features from cheap operations[C].Proceedings of the

IEEE/CVF conference on computer vision and pattern recognition.2020,1580-1589.

Research on Target Detection of Dam Leakage Based on YOLOv5s Optimization Model

LIANG Jian^{1,2},NIAN Liqiang³,ZHANG Guanhe^{1,2},TANG Bangjun⁴,MA Feiyue^{1,2}

(1. Anhui & Huaihe River Institute of Hydraulic Research, Hefei, 230088, China;2. Anhui Provincial Key Laboratory of Water Science and Intelligent Water Conservancy, Hefei, 230088, China ;3. Zhongshui Huaihe Anhui Hengxin Engineering Consulting Co., Ltd., Hefei, 230601, China;4. Huangshan Water Conservancy Bureau, Huangshan, 245000, China)

Abstract: [Objective] Utilizing technologies such as UAVs and infrared thermal imaging enables the quick and precise detection and localization of dam leaks, which enhances the efficiency of dam inspection processes significantly. This study develops an optimized YOLOv5s-based model for dam leakage detection to ensure timely identification of leakage hazards during the flood season and safeguard flood control security. [Methods] By collecting images from over 20 reservoirs with leakage phenomena, a self-built dataset of 529 dam leakage images was created to provide training samples for the model. An infrared image target detection network for dam leakage based on the optimized YOLOv5s model was proposed, which incorporates the Convolutional Block Attention Module (CBAM) to enhance model accuracy by extracting channel and spatial features, and introduces the Ghost module for model lightweighting. Comparative experiments were conducted using self-made dataset. [Results] The experimental results demonstrate that the proposed optimized model achieves a target detection precision of 89.8%, which is 3.1% higher than that of the YOLOv5s baseline. [Conclusion] This indicates its potential for effective leakage detection in dam engineering applications, demonstrating practical engineering value.

Keywords: Dam leakage; Infrared thermal imaging; Deep learning; Target detection; YOLOv5 optimization model