



武汉大学学报(信息科学版)

Geomatics and Information Science of Wuhan University

ISSN 1671-8860, CN 42-1676/TN

《武汉大学学报(信息科学版)》网络首发论文

题目: 深水大坝缺陷鲁棒实时检测方法
作者: 李扬涛, 包腾飞, 李田雨
DOI: 10.13203/j.whugis20220734
收稿日期: 2023-06-04
网络首发日期: 2023-07-10
引用格式: 李扬涛, 包腾飞, 李田雨. 深水大坝缺陷鲁棒实时检测方法[J/OL]. 武汉大学学报(信息科学版). <https://doi.org/10.13203/j.whugis20220734>



网络首发: 在编辑部工作流程中, 稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定, 且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式(包括网络呈现版式)排版后的稿件, 可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定; 学术研究成果具有创新性、科学性和先进性, 符合编辑部对刊文的录用要求, 不存在学术不端行为及其他侵权行为; 稿件内容应基本符合国家有关书刊编辑、出版的技术标准, 正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性, 录用定稿一经发布, 不得修改论文题目、作者、机构名称和学术内容, 只可基于编辑规范进行少量文字的修改。

出版确认: 纸质期刊编辑部通过与《中国学术期刊(光盘版)》电子杂志社有限公司签约, 在《中国学术期刊(网络版)》出版传播平台上创办与纸质期刊内容一致的网络版, 以单篇或整期出版形式, 在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊(网络版)》是国家新闻出版广电总局批准的网络连续型出版物(ISSN 2096-4188, CN 11-6037/Z), 所以签约期刊的网络版上网络首发论文视为正式出版。

DOI:10.13203/j.whugis20220734

引用格式：

李扬涛, 包腾飞, 李田雨. 深水大坝缺陷鲁棒实时检测方法[J]. 武汉大学学报(信息科学版), 2023, DOI: 10.13203/j.whugis20220734 (Li Yangtao, Bao Tengfei, Li Tianyu. A robust real-time detection method for deepwater dam defects [J]. *Geomatics and Information Science of Wuhan University*, 2023, DOI: 10.13203/j. whugis20220734)

深水大坝缺陷鲁棒实时检测方法

李扬涛^{1,2}, 包腾飞^{1,2}, 李田雨^{1,2,3}

(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.河海大学腐蚀与防护研究院, 江苏 南京 210098)

摘要：大坝长期服役过程中，在水环境和外部荷载交互耦合作用下，其深水结构部位易出现各类缺陷病害，影响工程服役安全稳定和功能发挥。水下机器人(Remotely Operated Vehicle, ROV)搭载可见光相机可以非接触形式实现结构损伤的高分辨率空间信息采集，然而如何从这些海量图像视频数据提取结构损伤密切相关信息成为当前亟待解决的关键问题。基于此，本文结合机器视觉和深度学习理论方法，研究并提出一种兼顾检测精度和推理效率的大坝深水多类别缺陷实时目标检测框架。该框架以单阶段目标检测网络YOLOv5-s为基模型，构建大坝多类别缺陷识别器；利用模型稀疏化和剪枝策略，改变模型批处理层权重分布并去除模型冗余参数；进一步地，综合运用模型迁移和知识蒸馏理论，恢复由于剪枝压缩参数带来的精度劣化问题，据此构建出强背景干扰下大坝深水多类别缺陷实时目标框架。以某高坝深水探测为工程实例，引入多种深度学习目标检测算法作为对比手段，验证方法在障碍物遮挡、低可见度、光照不均等复杂深水检测场景的缺陷效果。案例分析表明，该方法可有效克服多种水下不利成像环境干扰并准确辨识区分不同类型缺陷并量化其真实尺寸。此外，剪枝后轻量化模型每秒可推理超过100张缺陷图像，具备较强的实时推理能力。

关键词：深水检测；隐蔽病害识别；损伤识别；目标检测；人工智能

A robust real-time detection method for deepwater dam defects

Li Yangtao^{1,2}, Bao Tengfei^{1,2}, Li Tianyu^{1,2,3}

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 Institute of Corrosion and Protection, Hohai University, Nanjing, 210098, China

Abstract: Objectives: Under the coupling action of environment and loads, dam underwater structures suffer from defects, affecting the safety, stability, and functional performance of the project. Underwater robots like Remotely Operated Vehicles (ROVs) equipped with visible light cameras can realize the high-resolution spatial information in a non-contact form for underwater damage. However, it is still a challenging task that needs to be solved urgently to efficiently extract effective information from massive image and video data. **Methods:**

项目资助：中央高校基本科研业务费专项资金资助项目(B220203039)。

第一作者：李扬涛，博士。主要从事水工建筑物智慧运维和安全诊断方向的研究。邮箱：liyangtao@hhu.edu.cn

通讯作者：包腾飞，博士，教授。邮箱：baotf@hhu.edu.cn

Based on this, this paper proposes a real-time multi-class defect automatic identification framework for dam underwater structures. Specifically, the single-stage object detection network YOLOv5s is utilized as the base model to develop the damage detector. Then, the model sparsity and pruning strategies are combined to change the batch layer weight distribution and remove model redundant parameters. Next, transfer learning and knowledge distillation are combined to recover the accuracy degradation caused by model pruning and compression. **Results:** Take the underwater detection of a high dam as an example. The effectiveness of the proposed method was validated in complex underwater scenes like obstacle occlusion, low visibility, and uneven illumination. **Conclusions:** Experimental results indicated that the proposed method can effectively overcome the interference of complicated underwater imaging environments and accurately identify different types of defects. Moreover, it also achieves the inference speed of processing 100 defect images per second, indicating its real-time detection capability.

Keywords: deepwater detection; hidden disease identification; damage quantification; object detection; artificial intelligence

1 引言

截至 2022 年,我国已修建水库大坝 9.8 万余座,总库容 8983 亿 m^3 ,水电装机容量 3.91 亿千瓦,规模和数量均位居世界前列^[1]。这些工程在调蓄江河、抵御洪水、水力发电、航运灌溉等方面发挥重要作用,是国家水安全 and 经济发展的重要基础保障。然而,它们普遍存在有建设标准低、施工工艺差、三边工程等历史遗留问题,加之年久失修、后期养护管理不到位,坝体普遍存在诸多病害隐患。此外,不同于一般工民建基础设施,大坝服役期内需长期涉水运行,其深水结构部位在水压力、水环境冲蚀渗透和温度梯度荷载的交互耦合作用下,更易出现缺陷病害^[2-3]。大坝深水缺陷的隐蔽程度高,若不能被及时发现并加以处理,极易向结构内部延伸,形成深层结构损伤,进而破坏其完整性和抗渗性,削弱坝体刚度和承载能力,引起大坝服役性能下降甚至造成结构失稳^[4]。

人工巡视检查,辅以钢尺、锤敲、试纸等测试手段是大坝安全管理常用方法,但其存在检测效率低、危险度高、漏判率高等缺点^[5]。改进的蛙人检测手段,同样存在下潜深水有限(通常不超过 60m)、作业范围狭窄和潜在风险大等问题,难以满足大坝深水隐蔽缺陷检测需求^[6]。水下机器人(Remotely Operated Vehicle, ROV)是一类通过脐带缆实现动力和信号传输,由岸边人员操作并可执行特定水下作业任务的无人载运设备,近些年被应用于替代人工检测手段执行大坝深水缺陷探测任务。通过携带高清可见光相机,ROV 可实现大坝深水隐蔽缺陷的高分辨率图像视频信息采集,有效克服传统传感器和工程物探感知手段空间分辨率低的限

制。然而,大坝深水部位结构形式复杂多变且水下体积庞大,ROV 在一次大范围大坝深水探测任务会产生海量图像和视频数据。完全依赖人工读取和记录手段从这些海量数据中提取和结构损伤密切相关信息,不仅耗时长、人工成本高,而且识别难度大、误判率及漏检率高。此外,大坝深水部位缺陷种类繁多,不同类型缺陷存在一定特征相似性且区域交叉重叠现象,这给视觉辨识区分带来一定挑战。受水下恶劣成像环境和低可见度影响,大坝深水缺陷图像普遍存在有对比度低、噪声点多、模糊等低质量问题。此外,大坝深水结构表面多有浮游生物和藻类泥沙附着,这使得传统数字图像处理方法(Image processing technique, IPT)难以满足复杂深水强背景干扰多类别缺陷辨识区分需求^[7]。

近些年来,随着人工智能、信息科学等新兴行业的蓬勃发展,机器视觉(Machine vision, MV)和深度学习(Deep learning, DL)被提出并应用于土木基础设施结构损伤智能检测中^[8, 9]。深度学习可以端到端形式实现从视频图像中自动提取缺陷病害特征信息,简化了传统数字图像处理手段所依赖的人工特征提取设计和参数微调步骤,有效提高了缺陷视觉辨识方法在处理形态差异显著、背景特征复杂的大坝深水多类别缺陷的精度和效率。此外,深度学习自身高效数值计算及推理加速模式,使得应用搭载于移动检测设备实现实时检测成为可能,为后续开展大坝深水缺陷检测定位和量化奠定重要基础。

缺陷识别定位算法是基于机器视觉开

展结构损伤识别的重要基础性工作，其主要目的是通过矩形框标记图像中缺陷出现位置以及甄别其类别信息^[10]。依据算法理论差异，可进一步分为Fast R-CNN为代表的两阶段目标检测算法以及以YOLO为代表的单阶段检测算法。其中，两阶段算法主要是通过区域生成网络对图像进行候选区域提取，再进行分类和边界框回归，从而实现缺陷识别定位^[11]；单阶段检测算法，则是将检测任务作为回归问题进行求解，直接获取大坝深水缺陷图像中缺陷位置和类别信息。相比于两阶段目标检测算法，单阶段目标检测算法具有推理效率高、速度快等显著优势^[12]。

据此，本文综合运用深度学习、迁移学习和知识蒸馏相关理论方法，研究大坝深水多类别缺陷检测模型构建方法，研究构建适用于图像强背景特征干扰下的大坝深水多类别缺陷高鲁棒性实时目标检测框架，以期提高大坝深水隐蔽缺陷检测的自动化和信息化程度。具体而言，以ROV搭载可见光相机为图像信息采集手段，制作大坝多类别缺陷数据集；其次，结合单阶段目标检测算法YOLOv5-s，构建大坝深水多类别缺陷目标检测模型；据此，通过模型稀疏化和剪枝操作，改变批处理层的权重分布并去除模型冗余参数；再次，运用迁移学习、模型微调 and 知识蒸馏方法，以原始高精度模型为教师网络，以剪枝后检测模型为学生网络，开展先验知识迁移和模型参数微调，构建出具有高鲁棒性和泛化能力的大坝深水多类别缺陷检测框架；最终以某高坝深水检测为例，引入多种深度学习目标检测模型作为对比方法，从定性和定量评估多个角度验证方法的缺陷检测和量化评估能力。

2 方法原理

本文提出的大坝深水多类别缺陷实时目标检测框架主要包括三部分：(1)大坝深水多类别缺陷检测模型建立；(2)模型稀疏化与参数剪枝；(3)模型参数微调与知识蒸馏。具体方法原理如图1所示。

1)大坝深水多类别缺陷检测模型构建：结合可视化交互标注软件Labelme，结合ROV原型检测数据，构建大坝深水多类别缺陷数据集，涵盖裂缝、孔洞、凹陷以及骨料外露四类典型缺陷；以单阶段目标检测模型YOLOv5-s为识别器，构建大坝深水多类别缺陷目标检测模型。

2)模型稀疏化训练与参数剪枝：针对传统目标检测模型推理速度慢、实时性能差、泛化性能差等问题，以构建的大坝深水多类别缺陷目标检测模型为基础，综合运用模型稀疏化、剪枝和参数压缩手段，改变模型归一化层的权重分布使之大部分趋近于0，并据此利用剪枝手段去除了模型冗余参数和层数，提升了模型推理效率。

3)模型微调与知识蒸馏：以原始大坝深水多类别缺陷目标检测网络为教师网络，以剪枝后缺陷目标检测模型为学生网络，综合运用知识蒸馏和参数微调相关理论方法，探研剪枝后模型精度恢复和性能提升，构建出兼备高精度和高推理性能的大坝深水多类别缺陷实时检测模型。

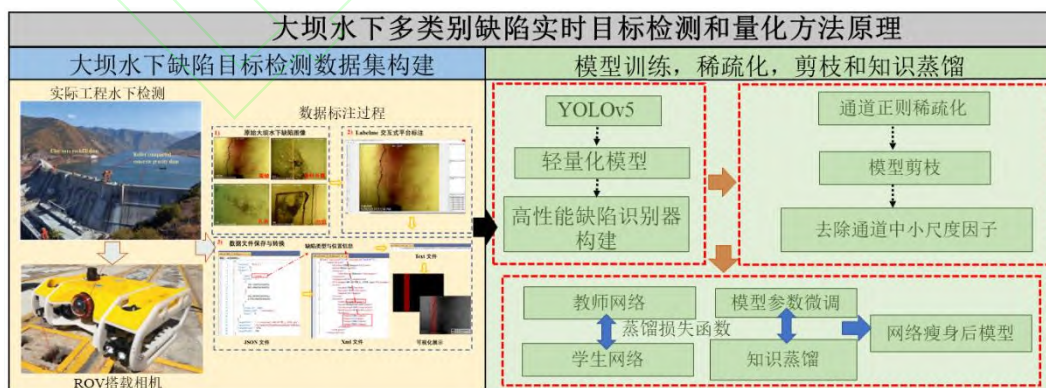


图1 方法原理

Fig. 1 Method principle

3 大坝深水多类别缺陷实时目标检测模型

3.1 改进 YOLOv5-s 模型

You Only Look Once(YOLO)目标检测网络是一种基于锚框的单阶段目标检测器。其最早是由 Joseph Redmon 于 2015 年提出并经历过多次版本迭代和改进,引入大量新颖计算机制。本文在充分考虑大坝实际深水探测边缘计算需求的基础上,以单阶段轻量化目标检测模型 YOLOv5-s 为基本框架。

然而考虑到 YOLOv5-s 模型对小尺寸缺陷特征提取能力不足易出现对小目标和低像素比物体的漏检或误检测现象,本文引入自适应空间特征融合提高模型对小目标缺陷特征提取能力。该机制的提出,可以在不增加推理开销的情况下改善尺度不变性,提高对小目标的特征提取能力,以适应大坝深水探测场景的多类别缺陷目标检测框架,其模型架构示意图如图 2 所示。从图中可以看出,该框架主要由五部分组成,即输入层(Input layer)、主干层(Backbone)、颈部层(Neck)、预测层(Prediction layer)、输出层(Output layer),具体内容如下。

YOLOv5-s 网络主干部分由 Focus 网络和跨级部分网络(Cross Stage Partial Networks, CSPNet)组合而成。图 3 展示了

Focus 结构处理大坝水下缺陷图像示意图。以一幅分辨率为 608×608 像素的大坝水下裂缝图像为例。首先通过分割操作将其转换为 $304 \times 304 \times 12$ 。然后,经过卷积运算,最终得到 $304 \times 304 \times 32$ 个特征图。Focus 结构的应用使得特征提取更加充分,同时也为后续的特征提取保留了完整的下采样信息。CSPNet 通过将梯度变化从头到尾集成到特征映射中,解决了传统神经网络框架骨干中的梯度信息复制问题,并降低了模型参数数目且提高了推理速度和精度,减小了模型规模。

在 YOLOv5-s 模型中,YOLOv5-s 的主干和颈部分别使用了两个不同的 CSPNet(即 CSP1_X 和 CSP2_X)。此外,它们在特定的模型体系结构之间也有一些差异。CSP1_X 由各种卷积层和 X ResNet 层组成,而在 CSP2_X 中,ResNet 层被卷积批归一化 Leaky Relu(CBL) 结构所取代。这两种 CSPNet 架构都被用来在不损失精确度的情况下降低计算成本。在 YOLOv5-s 的颈部,将特征金字塔网络(FPN)和路径聚合网络(PAN)相结合,以增强特征提取能力。准确地说,FPN 结构自上而上传达了强大的语义特征,而 PAN 结构自下而上传达了健壮的定位特征。

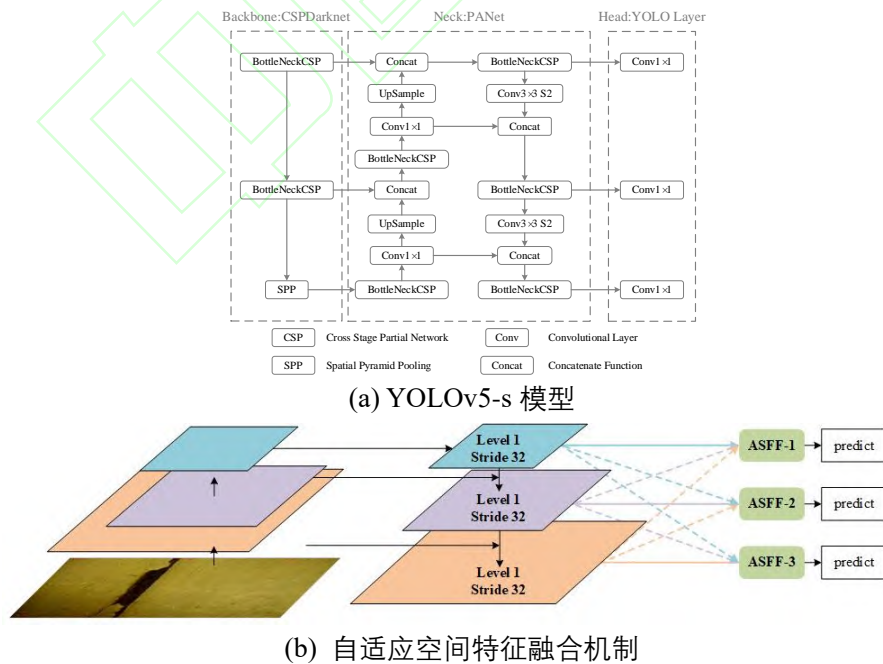


图 2 改进 YOLOv5-s 框架
Fig. 2 Improved YOLOv5-s framework

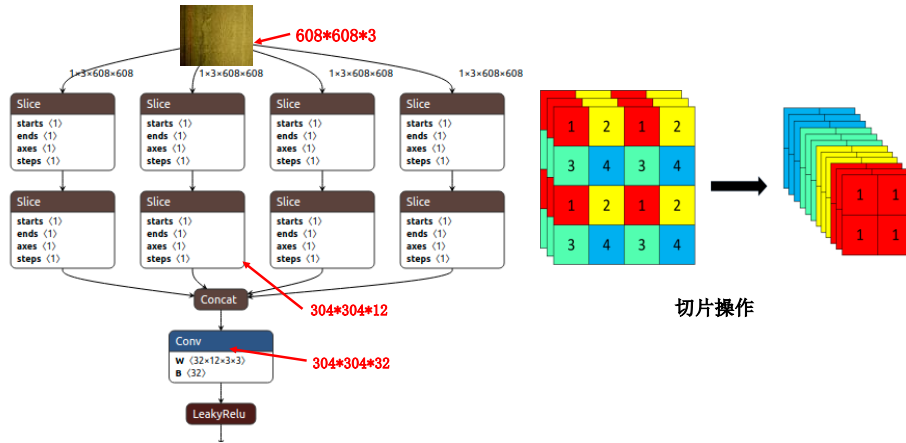


图 3 Focus 框架

Fig. 3 Focus frame

3.2 稀疏化剪枝和知识蒸馏

目前深度卷积网络朝着更深层次和更庞大架构发展，一个基于深度学习的视觉辨识模型通常包含百万甚至上亿参数量。这导致模型对计算和内存资源要求较高，给 ROV 等移动边缘设备等资源受限平台带来了更大的计算负担，难以开展实时损伤检测。此外，较大的模型尺寸同样影响嵌入式设备的存储和读取，进一步影响深度学习模型搭载于移动设备开展水下检测性能。若想在移动边缘设备上实现实时推理检测，则需要对深度学习模型的架构进行进一步优化，降低模型冗余度，提高其在边缘设备上推理能力。

模型压缩方法可通过一系列手段，在尽量少牺牲分析准确度的情况下减小模型的大小并降低参数量和计算复杂度，降低的参数量可以减小模型的内存占用，使之能加载到设备端上运行。此外，计算复杂度减少同样会带来处理速度的提升和能耗的减小。基于此，本文综合运用模型正则稀疏化、剪枝、参数微调和知识蒸馏相关方法理论，提出一种适用于大坝深水多类别缺陷目标检测模型的模型参数压缩方法。图 4(a)展示了模型稀疏化剪枝和知识蒸馏过程。从图中可以看出，宽而大的网络作为输入模型，其中不重要的通道或者参数被自动识别并修剪，从而产生具有一定精度紧凑网络。这种方法可适用于大部分卷积神经网络架构，而无需依赖特殊的硬件或者软件加速器，也不会给模型

训练过程带来过大开销。具体而言，模型剪枝和参数压缩流程主要包括参数稀疏化、参数剪枝及模型微调知识蒸馏三部分。

(1) 通道稀疏正则化

通道稀疏正则化是网络瘦身开展的重要前期工作。其基本目的是为每一个通道分配一个比例因子来表征通道重要性，并利用通道稀疏化训练来区分重要通道和不重要通道。批处理(Batch Normalization, BN)层是通道稀疏化的主要对象，其通常位于卷积层之后，用于保障模型快速收敛和泛化能力。关于 BN 层主要公式如下：

$$\hat{z} = \frac{z_{in} - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}}; \quad z_{out} = \gamma \hat{z} + \beta \quad (1)$$

式中： μ_B 和 σ_B 分别代表小批量统计中输入特征的均值和标准差； γ 和 β 分别代表可训练比例因子和偏置参数。当权重系数 γ 值变小时，相应激活函数值也会随着减少。

在卷积-批处理模块层中，BN 层主要用于实现通道放缩。通过定义卷积层中每个通道的缩放因子，可以对这些缩放因子执行稀疏正则化，以自动确定那些不重要的通道，基本计算过程如下。

$$\min_{D, \mu_i} \sum_{i=1}^m \|x_i - D\mu_i\|_2^2 + \lambda \sum_{i=1}^m \|\mu_i\|_1 \quad (2)$$

式中： x_i 代表目标数据集中的第 i -th 样本；

D 代表字典矩阵； μ_i 代表稀疏向量表示；

(2)模型参数剪枝

网络参数剪枝是一种有效的模型瘦身策略，常用于去除网络中冗余参数架构。传统非结构化权重参数剪枝策略存在依赖专用稀疏矩阵运算库和硬件平台限制等不足。为克服这些问题，本章引入结构化剪枝策略，以期在模型灵活度和易于操作实现间实现平衡。图 4(b)展示了模型参数剪枝策略的基本流程。从图中可以看出，稀疏率较小且相应激活函数值较小的网络层的输出值被剪去，经过迭代剪枝后，获取一个紧凑轻量化模型。

(3)模型微调及知识蒸馏

模型稀疏化和参数剪枝的联合应用，虽可有效去除模型冗余参数和架构，但是不可避免会造成模型网络检测精度下降。为克服此问题，本章将模型微调 and 知识蒸馏相结合，消除由模型剪枝和压缩带来的负面影响。图 4(c)展示了模型微调 and 知识蒸馏过程示意图。从图中可以看出，知识蒸馏的根本目的是利用高性能模型（教师网络）提出的监督

λ 代表稀疏化比率，其直接决定了模型正则化稀疏性能，是影响稀疏化结果重要参数。信息，增强轻量化网络模型（学生网络），使其具备更佳的性能。教师网络输出监督信息即被视为知识，而学生网络学习传递监督信息的过程即称为蒸馏。蒸馏损失函数主要用于计算教师网络和学生网络间预测值的差异，如下：

$$L_{cls} = \mu L_{hard}(P_s, y) + (1 - \mu)L_{soft}(P_s, P_t) \quad (3)$$

式中： L_{hard} 代表根据目标检测模型输出和标签值判断出的硬样本损失函数； L_{soft} 代表教师网络预测出的软样本损失函数； μ 代表硬损失和软损失之间的平衡参数。教师网络可以更好学习数据集数据分布规律，并在测试集中获取更好性能。在软损失函数中包含教师网络学习到的关于多个类别关系信息，学习到的信息可通过软标签插入到学生网络中。

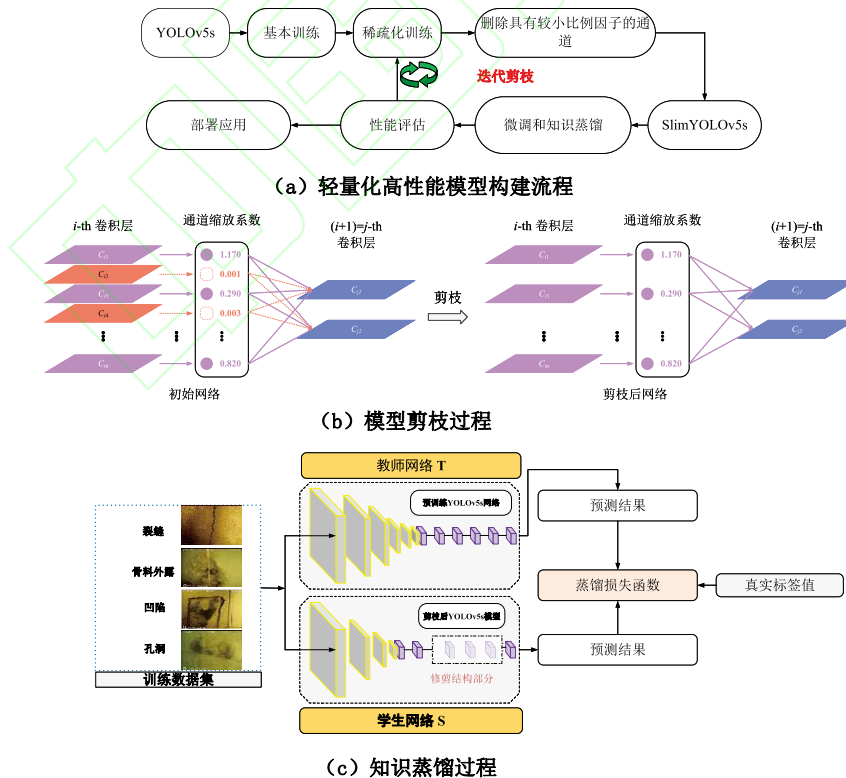


图 4 剪枝和知识蒸馏流程

Fig. 4 Pruning and knowledge distillation process

4 实验分析

4.1 背景简介

某水利枢纽工程位于云南省和四川省交界处，其主要挡水建筑物由左岸碾压混凝土重力坝和右岸粘土心墙堆石坝组合而成。大坝正常蓄水位为 1134m，总库容为 20.72 亿 m^3 ，其中碾压混凝土重力坝部分最大坝高为 159m，心墙堆石坝部分最大坝高 71m。自 2010 年 7 月起，该坝在左岸混凝土重力坝施工过程中，坝体下部多个坝段出现大面积顺河走向、陡倾产状、贯通上游库水的混凝土裂缝，相应部位出现大量渗水，渗漏现象严重。截至 2013 年初，共计发现裂缝 40 余条，发育深度数十 cm，长度延伸数米，发育高程约为 983 至 1047m。

为准确探明大坝深水结构损伤程度及发育情况，采用 ROV 搭载高清防水可见光相机检测方案开展大坝水下探测，探测区域范围如图 5 所示。从图中可以看出，大坝水下探测范围横跨 9#到 19#多个坝段，最大检测深度超过 80m。一次大范围大坝深水结构

探测任务产生海量图像和视频数据，蕴含着海量和结构健康状态、力学演变规律、荷载环境作用响应等结构性态演变密切相关重要信息。

精细化带标注缺陷数据是构建基于深度学习的大坝多类别缺陷目标检测模型的基础。然而在大坝安全监控相关领域，尚未有开源大坝深水缺陷相关数据集。基于此，本研究采用自行研制方式构建大坝深水多类别缺陷数据集。该数据集包含四类常见混凝土结构缺陷，如裂缝、凹陷、骨料外露以及坑洞，具体标注过程如图 6 所示。关于构建的数据集内不同类型缺陷数目及分布的统计性描述如图 7 所示。从图中可以看出，四种类型缺陷数目存在一定差异性，裂缝的出现频次和数目显著多于其他类型缺陷，这说明裂缝是混凝土坝常见病害类型，也是后续研究的关注重点。

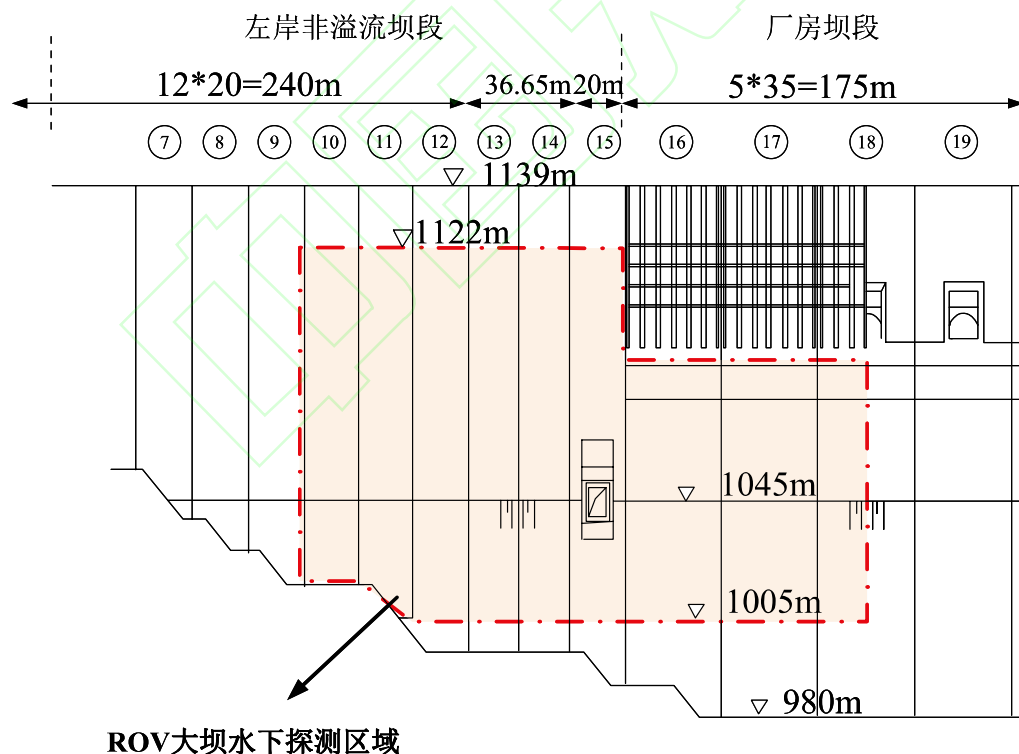


图 5 大坝深水探测范围

Fig.5 Deep water detection range of dam

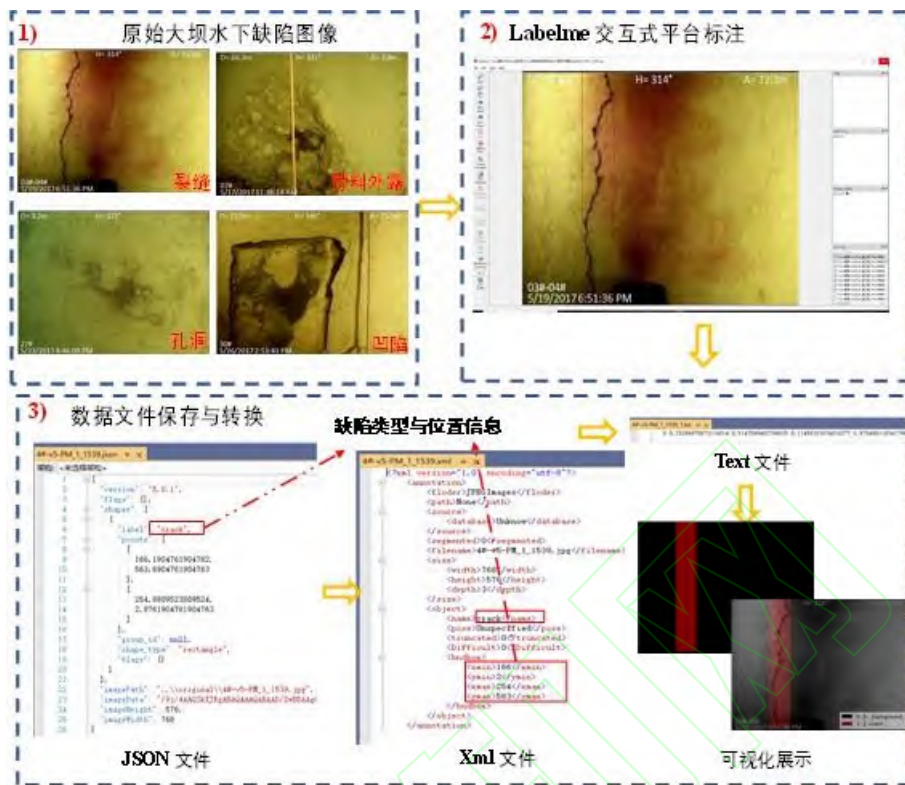


图 6 大坝深水多类别缺陷数据集构建流程

Fig. 6 Construction process of multi-category defect data set in deep water of dam




图 7 数据集的统计性描述

Fig. 7 Statistical description of the dataset

4.2 模型训练与剪枝蒸馏

本文实验程序的运行环境为 Window10，深度学习计算设备为 NVIDIA RTX 3090 显卡，CUDA 版本为 11.7。对比网络的模型训练和验证所用数据和所提方法保持完全一致。图 8 (a)反映了基本模型训练过程中训练集损失函数和验证集评估指标变化。从图中可以看出，随着迭代次数不断增加，box、obj 和 cls 三种类型损失函数均呈现逐渐下

降趋势并趋于收敛，这主要得益于迁移学习和预训练模型的应用，降低了模型从头训练和参数收敛成本，缓解了模型参数调整过程波动。相似规律可以在图 8 (b)观察到，随着迭代次数增加，目标检测算法在验证集评估指标 mAP_0.5 和 mAP_0.5:0.95 均呈现稳定上升趋势，在接近 200 次迭代后趋于收敛，其中 mAP_0.5 评估指标在 200 次迭代后超


过 0.95, 说明了模型具有较强的大坝多类别缺陷目标检测能力。

在此基础上, 为提升模型部署于边缘设备的实时推理能力, 综合运用模型稀疏化和剪枝手段, 以改变模型批处理层权重分布并降低模型参数量和冗余度。具体而言, 模型稀疏化比例系数设置为 0.01, 模型稀疏化迭代过程中损失函数和评估指标变化如图 8(c) 和(d)所示。从图中可以看出, 在模型稀疏化初期, 此时处于模型批处理层参数量大幅压缩阶段, 致使模型在训练集的损失函数上出现轻微抬升现象, 相应验证集上精度评估指标 $mAP_{0.5}$ 和 $mAP_{0.5:0.95}$ 均出现小幅下降趋势。随着迭代次数的继续增加, 得益于学习率衰减机制的启动, 模型权重稀疏化程度得到一定程度控制, 其在训练集上的损失函数逐步下降, 相应验证集上的精度评估指标大幅上升。在经过 100 次稀疏化迭代训练后, 模型在验证集上的评估指标 $mAP_{0.5}$ 和 $mAP_{0.5:0.95}$ 基本均趋于稳定。从图 9(a) 中可以看出, 开展稀疏化前的模型批处理层主要权重呈现以 1 为中心点正态分布, 而经过稀疏化后模型权重分布则集中于 0 附近, 说明稀疏化已基本充分。

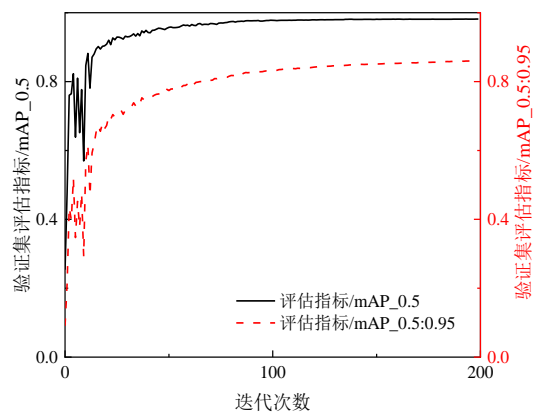
在模型稀疏化基础上, 有必要开展模型参数剪枝和量化压缩研究, 以去除冗余结构

以及降低参数量。图 9(b)展示了模型剪枝过程中评估指标变化。从图中可以看出, 随着剪枝比例的增加, 模型参数量逐步稳定下降, 而评估指标 mAP 则呈现先缓慢下降后逐步上升最终快速下降的变化趋势。结合图 9(b) 可以推断出, 剪枝率 0.6 是综合兼顾模型参数量规模以及推理效率的重要平衡点。

为恢复由于剪枝和模型参数压缩带来的负面影响, 引入跨域和域内迁移学习、模型参数微调、师徒网络和梯度下降优化等模型微调和知识蒸馏相关理论, 将原始高性能网络作为教师模型(teacher model), 而剪枝后网络作为学生模型(student model)。图 8(e) 和(f)展示了应用模型微调和知识蒸馏的网络训练过程损失函数以及评估指标变化过程。从图中可以看出, 相比于仅使用模型迁移和参数微调, 知识蒸馏技术的引入可显著提升剪枝后模型准确率恢复速度。从图 8(e) 可以看出, 知识蒸馏技术的引入可以显著提高损失函数收敛速度, 且经过 100 次迭代后损失函数值要显著低于未使用知识蒸馏策略。从图 8(f) 可以看出, 知识蒸馏和模型微调相结合策略在精确度、召回率以及综合评估指标 mAP 各项均显著高于仅使用模型微调策略, 其中验证集 mAP 值已达到 0.9, 说明模型准确度已得到有效恢复。



(a) 基本训练过程损失函数变化



(b) 基本模型训练过程评估指标变化

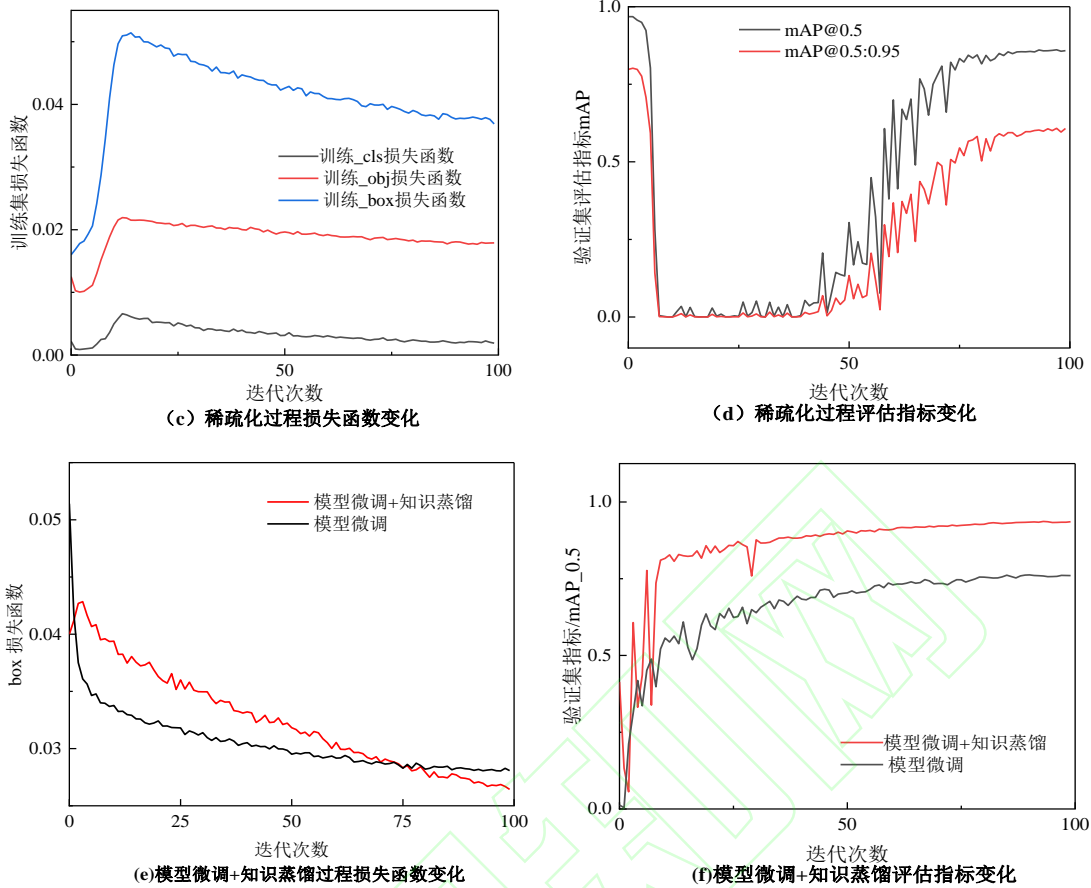


图 8 模型稀疏化、剪枝和知识蒸馏过程损失函数和评估指标变化

Fig. 8 Changes in loss function and evaluation metrics during model sparsification, pruning, and knowledge distillation

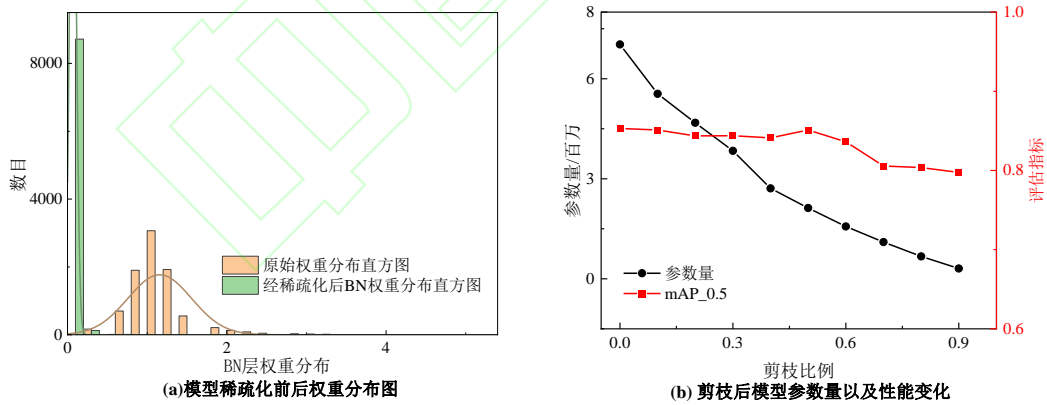


图 9 稀疏化前后以及剪枝过程参数量及性能变化

Fig. 9 Parameters and performance changes before and after thinning and during pruning

4.3 评估验证分析

为了定量且客观评估所提缺陷检测算法的有效性, 本文选择包括 Faster R-CNN^[13]、CenterNet^[14]、YOLOv4^[15]、YOLOv4_Tiny^[16]和 Mobilenet_YOLOv4^[17]在类的 5 种经典深

度学习目标检测算法进行比较。为保证评估对比过程的公平性, 这些对比模型均采用和所提方法一致的训练数据集输入, 迭代次数、批处理次数、输入图像分辨率等主要参数指

标均保持一致。

本文在测试集中引入光照不均、障碍物遮挡以及低可见度等不同复杂大坝深水检测场景，以多种先进深度学习目标检测算法作为基准方法，验证方法在复杂深水强背景干扰下的缺陷检测泛化能力和鲁棒性。所提和对比缺陷目标检测模型在测试集上的评估指标如表 1 所示。所提和对比方法在不同类型缺陷上的识别结果示意如图 10 所示。从表中可以看出，所提方法在不同类型大坝结构缺陷的识别检测精度均显著优于其他对比方法，这说明了所提方法在测试集上取得了更好的表现，验证了方法的有效性。。此外，还可以看出，对于形态特征较为明显且面积图占比较高的缺陷，如骨料外露等，不同检测方法的性能差距较小；而对于裂缝等形态特征相对复杂且面积像素占比小的缺陷，不同检测方法间检测精度差距较大。相似规律可以同样从图 10 中观察到。所提方法可以在复杂深水复杂强背景干扰的检测环境中准确检测大坝缺陷，并统计不同类

型缺陷出现的个数，有效辅助管理工程师探明并评估大坝深水结构的损伤程度。而对比方法则容易出现漏检或者错检现象，尤其是图像中存在较为复杂类似缺陷的干扰物。

推理速度是评估模型应用于实际大坝深水检测有效性的一项重要指标。本文以单张分辨率为 768×576 的大坝结构缺陷图像为推理对象，所提和对比方法均在同一台图像工作站采用相同大小分辨率作为模型输入。推理速度评估指标通过 FPS 计算，即计算模型每秒推理图片数目，所提和对比模型的推理速度评估如图 11 所示。视觉检测模型实时检测推理性能标准一般为大于等于 30FPS^[18]。从图中可以看出，所提方法的推理速度显著快于对比模型，且推理速度远超 30FPS，满足实时检测需求。这说明模型剪枝和参数压缩的应用可显著消除模型冗余结构并提升模型推理效率。这主要得益于模型剪枝和量化压缩去除了模型冗余参数所致。从图中可以看出，所提方法取得了超过 100FPS 的推理速度，说明方法具有较强的实时检测能力。

表 1 不同目标检测模型缺陷识别结果（测试集）

Tab. 1 Defect detection results of different object detection models (test set)

	类型/指标	Precision	Recall	F1	mAP0.5
所提方法	所有类别缺陷	0.951	0.970	0.960	0.986
	裂缝	0.943	0.893	0.917	0.965
	骨料外露	1.000	1.000	1.000	0.995
	凹陷	0.885	1.000	0.939	0.992
	孔洞	0.978	0.988	0.983	0.991
Faster R-CNN	所有类别缺陷	0.669	0.989	0.811	0.905
	裂缝	0.417	1.000	0.550	0.704
	骨料外露	0.870	1.000	0.930	1.000
	凹陷	0.720	1.000	0.840	0.994
	孔洞	0.56	0.955	0.923	0.923
YOLOv4	所有类别缺陷	1.000	0.624	0.698	0.720
	裂缝	1.000	0.004	0.090	0.292
	骨料外露	1.000	1.000	1.000	1.000
	凹陷	1.000	0.833	0.910	0.833
	孔洞	1.000	0.659	0.790	0.755
YOLOv4_Tiny	所有类别缺陷	0.945	0.591	0.633	0.657
	裂缝	1.000	0.045	0.090	0.214
	骨料外露	1.000	0.875	0.930	0.900
	凹陷	0.867	0.722	0.790	0.788
	孔洞	0.912	0.722	0.720	0.727
	所有类别缺陷	0.916	0.724	0.690	0.739

MobileNet_YOLOv4_all	裂缝	0.750	0.008	0.150	0.185
	骨料外露	0.976	1.000	0.990	1.000
	凹陷	1.000	0.889	0.940	0.994
	孔洞	0.940	1.000	0.680	0.775

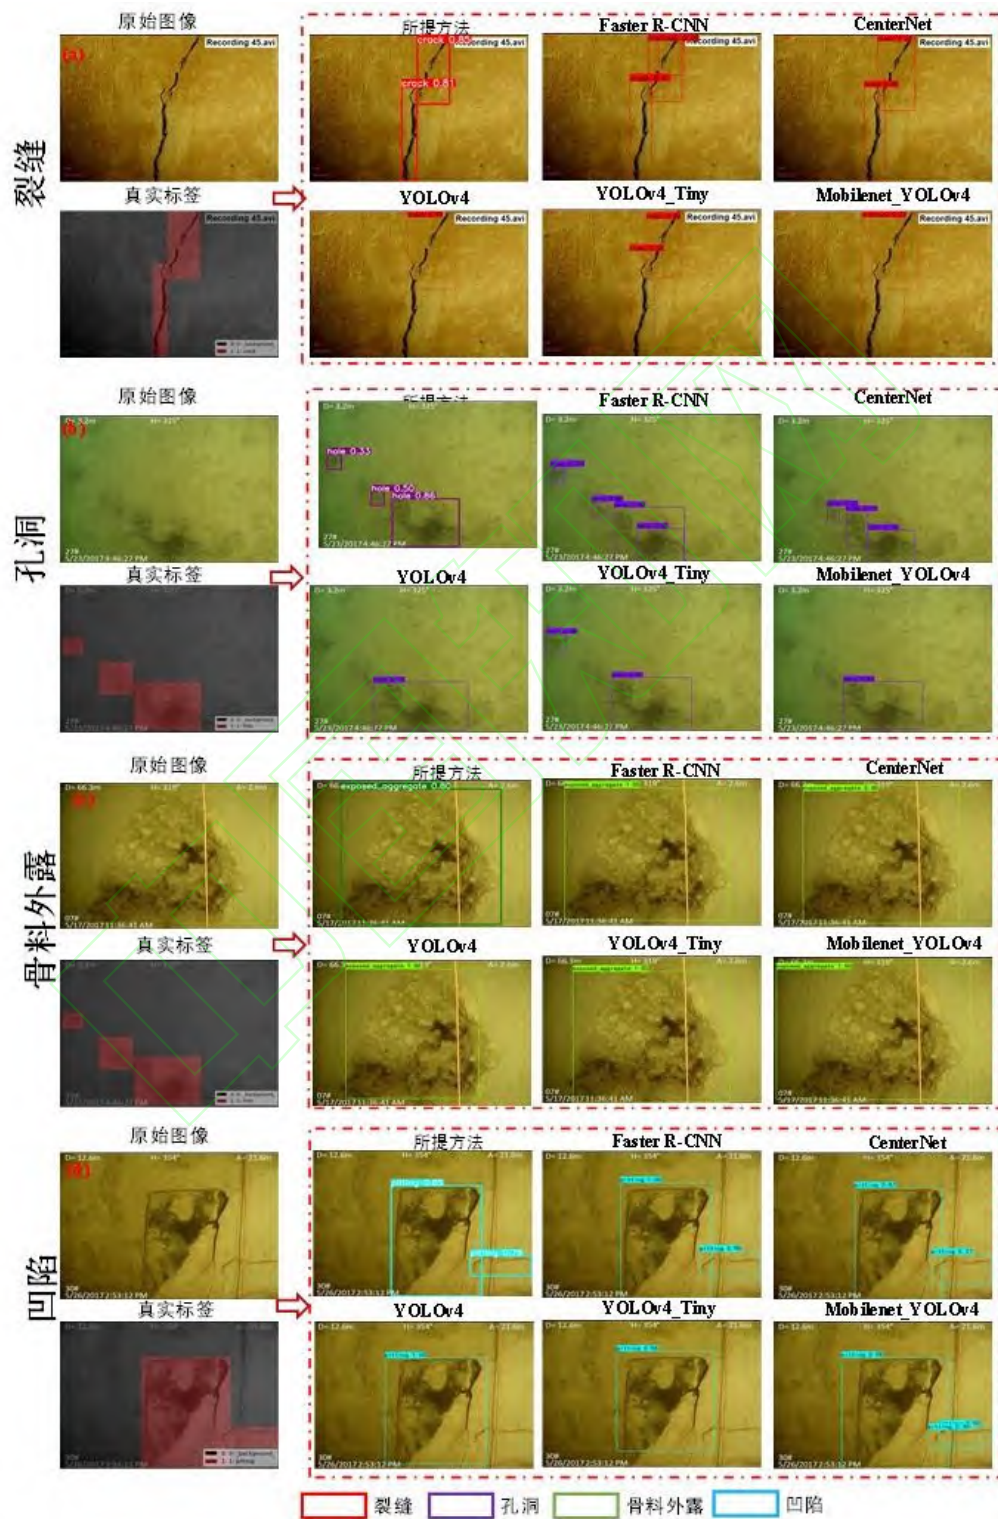


图 10 所提和对比方法的缺陷检测结果展示

Fig. 10 Display of defect detection results of the proposed and compared methods

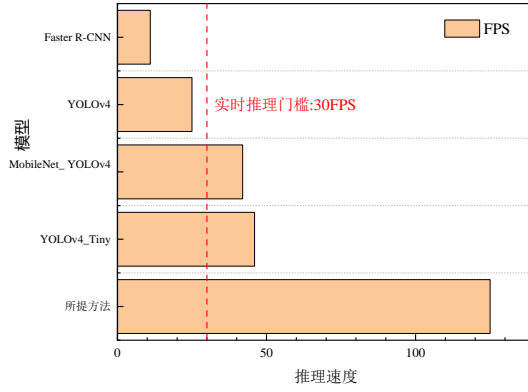


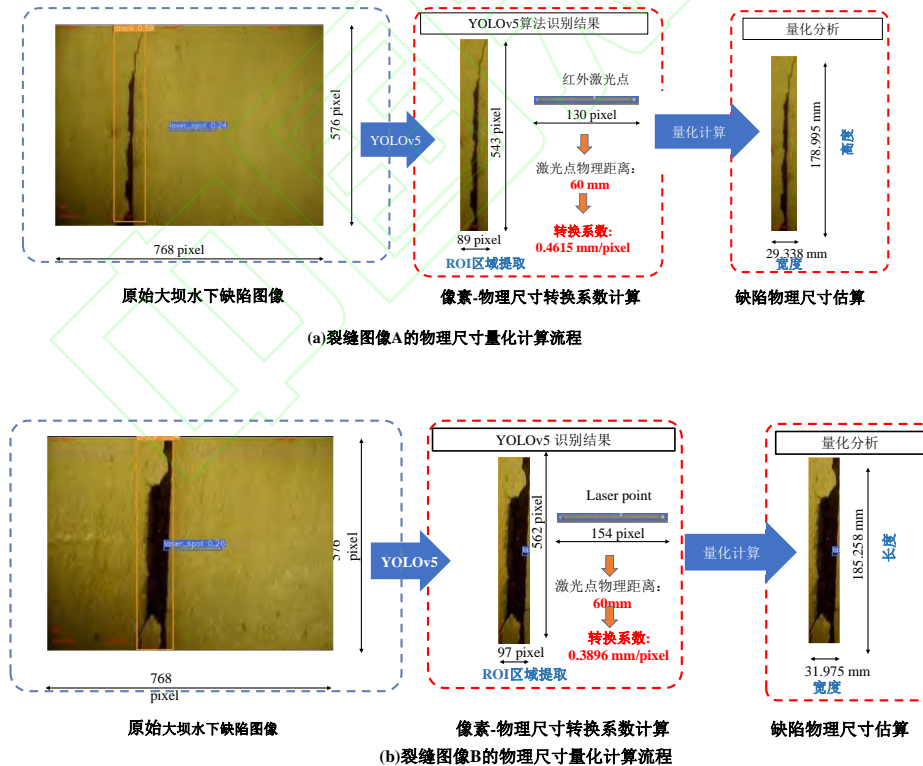
图 11 推理速度对比

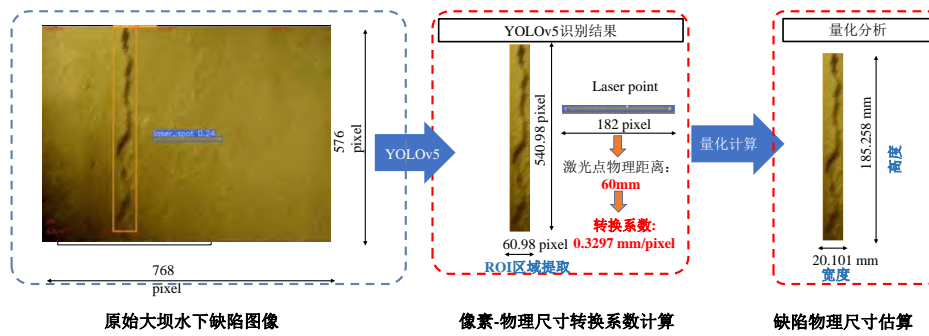
Fig .11 Inference speed comparison

4.4 缺陷量化结果分析

图 12 展示了所提方法应用于实际工程大坝深水缺陷检测与目标效果。从图中可以看出，将深度学习实时目标检测算法和红外激光测距系统相结合，可实现利用红外激光测点间距估计“像素—物理”坐标系转换系数，进而实现对实际大坝深水缺陷的几何尺

寸和形态特征进行量化估算。研究表明，该方法可有效克服实际大坝深水检测复杂环境干扰，实现从复杂深水强背景特征干扰下准确识别并分离出缺陷特征，并据此估算缺陷的形态尺寸。





(c) 裂缝图像C的物理尺寸量化计算流程

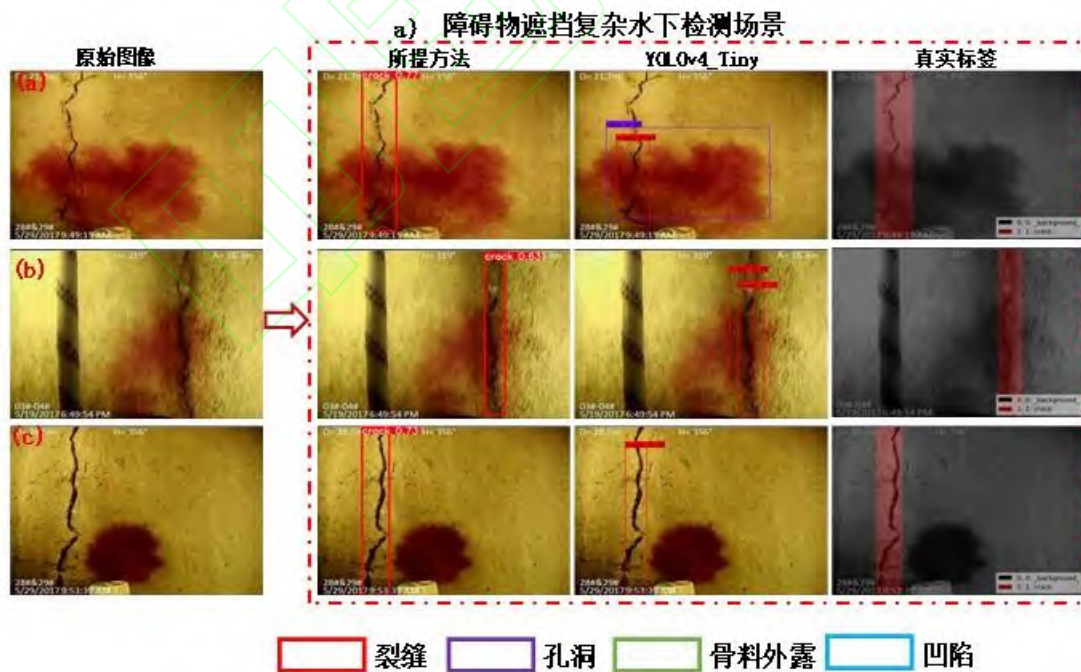
图 12 缺陷量化定位分析结果展示

Fig .12 Display of defect quantitative positioning analysis results

4.5 复杂大坝深水检测场景验证

在实际工程深水检测过程中，受恶劣复杂水下成像环境影响，获取的图像不可避免存在模糊、光照不均、障碍物遮挡等低质量现象，影响视觉检测算法的精度。为评估所提方法在实际大坝深水检测的鲁棒性，本文选取三种大坝深水探测的复杂强图像背景特征干扰场景，包括光照不均、障碍物遮挡、低可见度。以 YOLOv4_Tiny 为对比方法，图 13 展示了所提和对比方法在不同类型缺陷识别检测效果。从图中可以看出，所提大

坝深水多类别缺陷目标检测模型可有效克服红色试剂遮挡、类缺陷干扰物以及不均匀光照条件干扰，准确识别缺陷并框选出图像位置，从而为实现大坝深水缺陷的检测定位提供重要参考依据。此外，从图中还可以看出，对比方法存在一定程度的漏检和错检现象，这主要是由于其特征提取能力较弱，对小目标或者强背景干扰影响下缺陷的辨识能力弱所致。



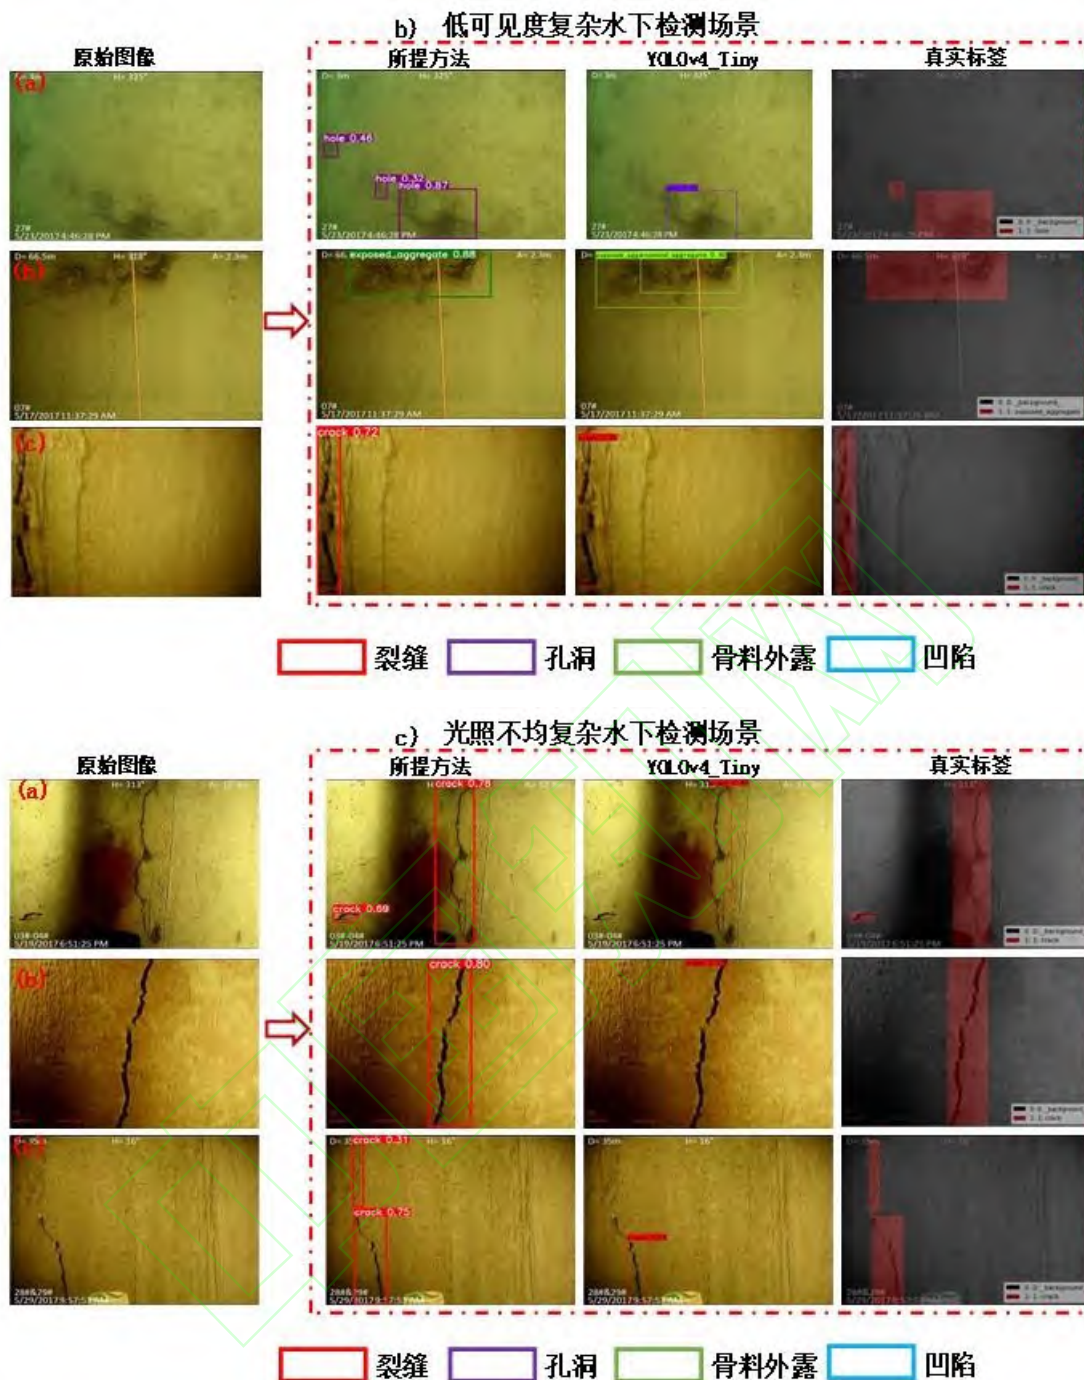


图 13 复杂大坝深水检测场景缺陷识别效果对比

Fig. 13 Comparison of defect identification results in complex dam deepwater detection scenarios

5 结论

从复杂强图像背景特征干扰下大坝深水缺陷检测定位的实际工程需要出发，在充分考虑类缺陷特征和背景干扰对视觉成像影响的基础上，结合深度学习目标检测相关理论方法，研究构建了大坝深水多类别缺陷目标检测模型，并针对实际模型部署和缺

陷实时探测工程需要，研究了模型轻量化和剪枝压缩方法融合模型迁移和知识蒸馏理论，提出了模型压缩后精度恢复与性能提升方法，据此构建出大坝深水强背景干扰的多类别缺陷实时目标检测模型，进行了所述模型的合理性、鲁棒性和实际工程应用验证。

主要研究内容和研究成果有:

(1) 以满足大坝深水缺陷的精准实时探测为目标,着力于高鲁棒性和高性能的大坝深水缺陷目标检测模型构建,研究并提出适用于复杂强背景干扰的大坝深水探测的多类别缺陷目标检测框架。

(2) 以原始大坝深水缺陷检测模型为教师网络,以轻量剪枝模型为学生网络,利用知识蒸馏和迁移学习相关理论方法,实现剪枝后的精度恢复和性能提升,以构建同时具备高检测性能推理速度的多类别水下缺陷实时检测模型。

(3) 以某实际大坝深水探测为实例,综合运用前述研发的水下缺陷图像采集试验平台和构建的缺陷实时检测模型,开展了不同复杂强背景特征干扰下的缺陷检测性能评估,验证所提方法在不同复杂强图像背景特征干扰下的缺陷辨识和量化评估能力。

本文所提出的模型在实际大坝深水探测场景对不同类别缺陷具有较高检测精度和鲁棒性,后续研究进一步将加强模型的特征提取能力、检测精度提升方面的改进等相关研究,以提升检测模型对大坝小尺寸缺陷的适用性。

参考文献

[1] Cong Xu, Shao Wei Wang, Chong Shi Gu, et al. A Probabilistic Prediction Model for Displacement of Super High Arch Dams Considering the Deformation Spatial Association, 2021: 15. (徐丛, 王少伟, 顾冲时, 等. 融合空间关联性的特高拱坝位移概率性预测模型[J]. 武汉大学学报(信息科学版). 2021: 15)

[2] JinBao Sheng, Yan Xiang, DeWei Yang, et al. Key technologies and applications of safety diagnosis and smart management of reservoir dams, 2022, 44(07): 1351-1366.(盛金保, 向衍, 杨德玮, 等. 水库大坝安全诊断与智慧管理关键技术与应用[J]. 岩土工程学报. 2022, 44(07): 1351-1366).

[3] Yan Xiang, JinBao Sheng, Hui Yuan, et al. Research on degrading and decommissioning

assessment of reservoir in China, 2015, 45(12): 1304-1310. (向衍, 盛金保, 袁辉, 等. 中国水库大坝降等报废现状与退役评估研究[J]. 中国科学:技术科学. 2015, 45(12): 1304-1310.)

2015, 45(12): 1304-1310.

[4] ZhongRu Wu, ChongShi Gu, HuaiZhiSu, et al. Review and prospect of calculation analysis methods in hydro-structure engineering, 2015, 43(05): 11.(吴中如, 顾冲时, 苏怀智, 等. 水工结构工程分析计算方法回眸与发展[J]. 河海大学学报(自然科学版). 2015, 43(05): 11.)

[5] LiYang Xiao, Wei Li, Bo Yuan, et al. Pavement Crack Automatic Identification Method Based on Improved Mask R-CNN Model, 2022: 16. (肖力扬, 李伟, 袁博, 等. 一种改进型Mask R-CNN模型的路面裂缝识别方法[J]. 武汉大学学报(信息科学版). 2022: 16.)

[6] Wen Gao Xie, Yi Xiao Zhang, Ai Rong Liu, et al. METHOD FOR CONCRETE SURFACE CRACKING DETECTION BASED ON ROV AND DIGITAL IMAGE TECHNOLOGY 2022, 39(S1): 7. (谢文高, 张怡孝, 刘爱荣, 等. 基于水下机器人与数字图像技术的混凝土结构表面裂缝检测方法[J]. 工程力学. 2022, 39(S1): 7.)

[7] Kang Wei, Fang Yuan, ZhiQiang Dong, et al. Precision analysis and civil application of multi-camera digital image correlation method based on encoded targets 2021, 51(02): 8.(魏康, 员方, 董志强, 等. 基于标志点的多相机数字图像相关方法精度分析及土木工程中的应用[J]. 东南大学学报(自然科学版). 2021, 51(02): 8.)

[8] YuFei Liu, JianSheng Fan, JianGuoNie, et al. Review and prospect of digital-image-based crack detection of structure surface 2021, 54(06): 79-98. (刘宇飞, 樊健生, 聂建国, 等. 结构表面裂缝数字图像法识别研究综述与前景展望[J]. 土木工程学报. 2021, 54(06): 79-98.)

[9] YuFei Liu, Yu Qi, BaoLuo Li, et al. Intelligent detection of sensitive service indicators in multiple scenarios of structural maintenance, 2022, 43(10): 1-15. (刘宇飞, 齐玉, 李保罗, 等. 工程结构运维多场景的敏感服役

- 指标智能识别[J]. 建筑结构学报. 2022, 43(10): 1-15.)
- [10] ChunLei Liu, Tian'en Chen, Cong Wang, et al., A Survey of Few-shot Object Detection, 2022: 23. (刘春磊, 陈天恩, 王聪, 等. 小样本目标检测研究综述[J]. 计算机科学与探索. 2022: 23.)
- [11] Xue Y, Li Y. A Fast Detection Method via Region-Based Fully Convolutional Neural Networks for Shield Tunnel Lining Defects[J]. Computer-Aided Civil and Infrastructure Engineering. 2018, 33(8): 638-654.
- [12] Zhou Z, Zhang J, Gong C. Automatic detection method of tunnel lining multi - defects via an enhanced You Only Look Once network[J]. Computer-Aided Civil and Infrastructure Engineering. 2022, 37(6): 762-780.
- [13] WenQing Shang, HongBo Qi. Identification algorithm of field weeds based on improved Faster R-CNN and transfer learning, 2022, 43(10): 7. (尚文卿, 齐红波. 基于改进Faster R-CNN与迁移学习的农田杂草识别算法[J]. 中国农机化学报. 2022, 43(10): 7.)
- [14] Wei Wang, XinYao Tang, Hua Cui, et al. Accurate Perception of Three-dimensional Vehicle Form in Roadside Monocular Perspective Based on CenterNet, 2022, 35(09):15. (王伟, 唐心瑶, 崔华, 等. 基于CenterNet的路侧单目视角车辆3D形态精确感知[J]. 中国公路学报. 2022, 35(09): 15.)
- [15] 杨真真, 郑艺欣, 邵静, 等. 基于改进路径聚合和池化YOLOv4的目标检测[J]. 南京邮电大学学报(自然科学版). 2022, 42(05): 7.
- ZhenZhen Yang, YiXin Zheng, Jing Shao, et al. 2022, 42(05): 7.
- [16] JiShang Xu, CuiYin Liu, Ming Liu. An object detection method based on improved YOLOv4 path aggregation and pooling, 2022: 8. (徐继尚, 柳翠寅, 刘明. 改进YOLOV4-Tiny的SAR图像舰船小目标检测[J]. 小型微型计算机系统. 2022: 8.)
- [17] KeYou Guo, Xue Li, Min Yang. Real-time detection method of traffic information based on lightweight YOLOv4, 2022: 9. (郭克友, 李雪, 杨民. 基于轻量化YOLOv4的交通信息实时检测方法[J]. 计算机应用. 2022: 9.)
- [18] Choi W, Cha Y. SDDNet: Real-Time Crack Segmentation[J]. IEEE Transactions on Industrial Electronics. 2020, 67(9): 8016-8025.

网络首发:

标题: 深水大坝缺陷鲁棒实时检测方法

作者: 李扬涛, 包腾飞, 李田雨

DOI: 10.13203/j.whugis20220734

收稿日期: 2023-06-04

引用格式:

李扬涛, 包腾飞, 李田雨. 深水大坝缺陷鲁棒实时检测方法[J]. 武汉大学学报(信息科学版), 2023, DOI: 10.13203/j.whugis20220734 (Li Yangtao, Bao Tengfei, Li Tianyu. A robust real-time detection method for deepwater dam defects [J]. *Geomatics and Information Science of Wuhan University*, 2023, DOI: 10.13203/j. whugis20220734)

网络首发文章内容和格式与正式出版会有细微差别，请以正式出版文件为准！

您感兴趣的其他相关论文：

深水目标定位声速剖面自适应分层方法

孙文舟, 朱忆, 曾安敏, 赵翔

武汉大学学报（信息科学版），doi: 10.13203/j.whugis20220662

<http://ch.whu.edu.cn/cn/article/doi/10.13203/j.whugis20220662>

