

DOI:10.19853/j.zgjsps.1000-4602.2025.03.019

# 基于YOLO-Pipe和ByteTrack的排水管道缺陷检测

凌同华<sup>1</sup>, 贝政豪<sup>1</sup>, 张胜<sup>2</sup>, 张亮<sup>3</sup>, 江浩<sup>1</sup>

(1. 长沙理工大学 土木工程学院, 湖南 长沙 410114; 2. 湖南城市学院 管理学院, 湖南 益阳 413000; 3. 湖南城市学院 土木工程学院, 湖南 益阳 413000)

**摘要:** 城市排水管道检测作为城市管理的重要组成部分,对保障城市安全运行具有重要意义。针对现有模型对排水管道检测存在的复杂度高、精度低等问题,采用C3\_PConv结构、PIoUv2损失函数和层自适应幅度剪枝算法对YOLOv5n进行优化,构建了轻量化的YOLO-Pipe模型。并将YOLO-Pipe模型与ByteTrack追踪算法进行融合,提出了一种基于排水管道检测视频的Pipe-Track缺陷追踪算法。结果表明,YOLO-Pipe模型缺陷检测的mAP@50达94.8%,推理时间为28.2 ms。与其他模型相比,YOLO-Pipe在兼顾实时检测的同时取得了更高的检测精度。融合的Pipe-Track算法实现了对视频数据集的检测,并且缺陷平均锁定率达到了92.3%,展现出了良好的缺陷检测效果。

**关键词:** 排水管道; 缺陷检测; YOLO模型; 视频检测; ByteTrack算法

**中图分类号:** TU992 **文献标识码:** A **文章编号:** 1000-4602(2025)03-0125-06

## Surface Defect Detection in Sewer Pipelines Based on YOLO-Pipe and ByteTrack Methods

LING Tong-hua<sup>1</sup>, BEI Zheng-hao<sup>1</sup>, ZHANG Sheng<sup>2</sup>, ZHANG Liang<sup>3</sup>, JIANG Hao<sup>1</sup>

(1. School of Civil Engineering, Changsha University of Science & Technology, Changsha 410114, China; 2. School of Management, Hunan City University, Yiyang 413000, China; 3. School of Civil Engineering, Hunan City University, Yiyang 413000, China)

**Abstract:** Urban sewer inspection plays a crucial role in city management and is of great significance for ensuring the safe operation of cities. In response to the high complexity and low accuracy issues associated with existing models for sewer inspection, a lightweight YOLO-Pipe model was developed by optimizing YOLOv5n with the C3\_PConv structure, PIoUv2 loss function, and layer adaptive amplitude pruning algorithm. The YOLO-Pipe model was then integrated with the ByteTrack tracking algorithm to propose a Pipe-Track defect tracking algorithm based on sewer inspection video data. Results indicated that the YOLO-Pipe model achieves a mAP@50 of 94.8% for defect detection with an inference time of 28.2 ms. Compared to other models, YOLO-Pipe achieves higher detection accuracy while maintaining real-time detection. The integrated Pipe-Track algorithm has achieved detection on video datasets, with an average defect locking rate of 92.3%, demonstrating excellent defect detection performance.

**Key words:** sewer; defect detecting; YOLO model; video detection; ByteTrack algorithm

基金项目: 湖南省教育厅科学研究项目(22A0562、23C0664); 湖南省交通运输厅科技项目(202319); 国家自然科学基金资助项目(52308399、52078061)

城市排水管道作为雨水和各种污水的主要收集和排放途径,在基础设施建设中占据重要地位。然而,随着时间的推移以及受使用不当等因素的影响,排水管道出现了各种缺陷,由此可能引发内涝积水、污水冒溢和道路塌陷等问题,对城市环境安全、交通秩序乃至人身安全构成严重威胁。

目前,排水管道的检测方法主要有管道闭路电视(CCTV)检测、潜望镜检测(QV)以及超声波检测等<sup>[1]</sup>。通常使用CCTV和QV设备进行日常巡检,检测过程中会产生大量的视频数据<sup>[2]</sup>。当前,这些数据主要依赖人工进行判读,不仅效率低,而且结果易受主观因素影响。加之,管道遍布广、里程长,技术人员相对不足,导致难以对管道实现及时全面的检查。随着计算机视觉技术的进步,基于深度学习技术的排水管道缺陷图像智能判读方法应运而生,有效降低了检测结果的主观性,提高了效率和精度<sup>[3-6]</sup>,但该方法难以处理多类别缺陷的图像。

相较于图像分类,目标检测技术能精确定位缺陷坐标,并可同时识别多个缺陷<sup>[7]</sup>。曾飞等<sup>[8]</sup>对缺陷图像应用自适应直方图均衡化增强技术,并通过改进YOLOv7模型进行检测,精度达93.3%。Yin等<sup>[9]</sup>提出了一个基于YOLOv3的污水管道检测框架,可对检测视频、缺陷图像进行标记,并输出相关缺陷信息。Kumar等<sup>[10]</sup>构建了一个基于OpenCV和Faster R-CNN的缺陷检测框架,可以30帧/s的速度从视频中采集图像,并利用Faster R-CNN模型进行检测。尽管上述研究提升了管道缺陷检测效果,但当前方法仍主要集中在缺陷图像的检测上。

图像检测结果易受模糊图像以及排水管道内部雾汽等因素影响,加之排水管道检测数据主要为视频格式,现有方法难以直接从视频中获取检测结果,进而对模型的检测性能提出了更高的挑战。针对排水管道缺陷的特性,以及现有模型精度低、复杂度高和无法直接处理检测视频等问题,笔者基于YOLOv5n模型,设计精度更高的YOLO-Pipe轻量模型,并结合ByteTrack多目标追踪算法,开发Pipe-Track算法,用于排水管道检测视频的缺陷追踪检测,进一步提高缺陷检测的高效性和智能化水平。

## 1 研究方法

### 1.1 YOLO-Pipe模型

YOLOv5作为YOLO系列中一款常用且高性能

的目标检测模型,主要由主干(Backbone)、颈部(Neck)和检测头(Head)三部分组成<sup>[11]</sup>。相较于其他模型,YOLOv5对计算机性能要求低,精度与结构复杂度间的平衡性更好,且有利于将来的模型应用集成。针对排水管道缺陷检测任务,基于YOLOv5n提出了一个精度更高且更轻量的YOLO-Pipe模型(见图1)。它采用轻量化C3\_PConv结构优化原有模型的大目标检测层,同时应用强效的PIoUv2损失函数<sup>[12]</sup>代替原本的CIoU损失函数,以增强模型对缺陷目标的聚焦性能。此外,使用层自适应幅度剪枝(LAMP)算法进行剪枝优化,进一步提升模型性能。

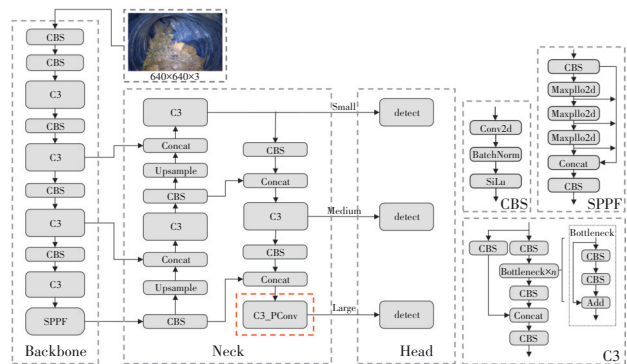
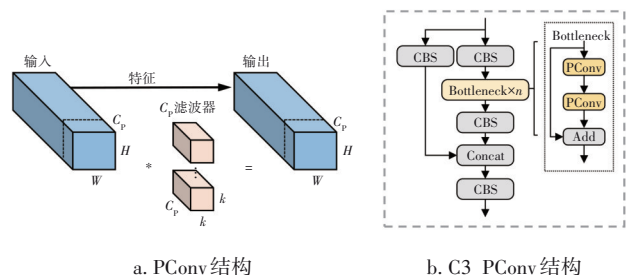


图1 YOLO-Pipe模型

Fig.1 YOLO-Pipe model structure diagram

#### 1.1.1 模块设计

通过减少冗余计算和内存访问,PConv卷积可更高效地提取空间特征。PConv在不改变特征图通道数量的前提下,仅对输入特征图的部分特征通道使用普通卷积提取空间特征。经过处理后的特征图通道将与未处理的通道进行拼接,进而获得特征图输出。为了降低排水管道缺陷检测模型的复杂度与更高效地提取空间特征,提出了一种全新的轻量化C3\_PConv结构。它使用PConv卷积替代原有Bottleneck模块中的卷积块,具体结构见图2。



a. PConv结构

b. C3\_PConv结构

图2 PConv与C3\_PConv结构

Fig.2 Structure of PConv and C3\_PConv

### 1.1.2 模型优化

#### ① PIoUv2 损失函数

YOLOv5n 模型采用 CIoU 损失函数评估矩形框的定位损失。PIoU 损失函数相比 CIoU 损失函数,其通过结合目标框尺寸的自适应惩罚因子和预测锚框质量的梯度调节函数,能更有效引导预测框回归,提高网络的收敛速度。PIoU 如图 3 所示,其中红色框为目标框,绿色框为预测框。




图 3 PIoU 示意

Fig.3 Schematic diagram of PIoU

为了进一步提高预测锚框的聚焦性能,引入 PIoUv2 版本损失函数,具体计算方法如下:

$$P = (\frac{dw_1}{w_{gt}} + \frac{dw_2}{w_{gt}} + \frac{dh_1}{h_{gt}} + \frac{dh_2}{h_{gt}})/4 \quad (1)$$

$$L_{PIoU} = L_{IoU} + 1 - e^{-P^2} \quad (2)$$

$$L_{PIoUv2} = 3 \cdot (\lambda q) \cdot e^{-(\lambda q)^2} \cdot L_{PIoU} \quad (3)$$

式中:  $dw_i, dh_i (i=1,2)$  为预测框与目标框的对应边之间距离的绝对值;  $w_{gt}, h_{gt}$  分别为目标框的宽和高;  $L_{IoU} = 1 - IoU$ ,  $IoU$  为预测框与目标框之间交集区域面积与并集区域面积的比值;  $L_{PIoU}$  值介于 0~2 之间;

$\lambda$  值取 1.3;  $q = e^{-P}, q \in (0, 1]$ 。

#### ② LAMP 剪枝算法

目前主流的剪枝算法有 L1、Slim、GroupTaylor 以及 LAMP 等。其中, LAMP 剪枝方法不仅操作简便、模型剪枝效果显著,而且在计算效率和资源消耗方面也展现出显著的优势。为简化网络结构并降低对计算机性能的要求,采用 LAMP 算法对模型进行剪枝。LAMP 算法为利用全局修剪重要性评分进行迭代修剪的失真最小化框架,其主要通过移除训练完毕后的网络模型中对排水管道缺陷检测结果影响较小的卷积层特征连接,来提升模型的紧凑性和效率。移除非必要特征连接后再经过微调步骤,获得剪枝完毕的模型。

### 1.2 缺陷追踪框架

ByteTrack 多目标追踪算法根据检测器结果进行缺陷的追踪和捕捉。作为 Tracking-By-Detection 策略的经典算法, ByteTrack 利用卡尔曼滤波以及匈牙利算法逐帧对目标进行匹配,从而形成清晰、连续的追踪轨迹<sup>[13]</sup>。

本研究将轻量且高效的 YOLO-Pipe 检测器与 ByteTrack 算法相融合,以及在 Python 平台上设计了基于排水管道视频数据的 Pipe-Track 多缺陷目标追踪检测算法,如图 4 所示。该算法能批量地对排水管道检测视频进行缺陷追踪和锁定,并过滤重复的检测结果,进而输出缺陷检测结果(缺陷出现时间点、类别与数量统计信息),为排水管道的缺陷检测与诊断提供便利。

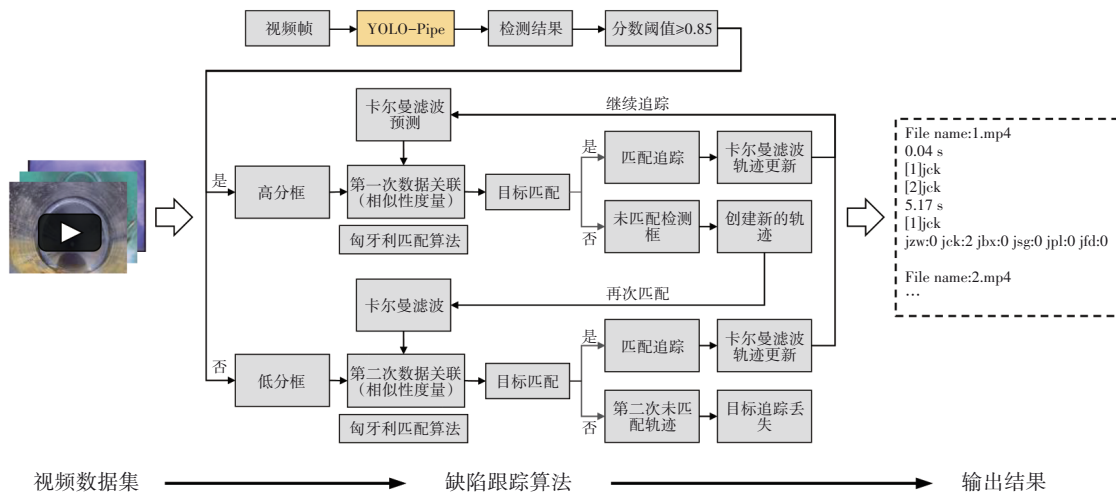


图 4 Pipe-Track 算法示意

Fig.4 Schematic diagram of the Pipe-Track algorithm



## 2 实验研究

### 2.1 数据集制作

从排水管道检测视频中抽取了1 439张缺陷图像,涵盖6种缺陷类型:障碍物(jzw)、错口(jek)、变形(jbx)、树根(jsg)、破裂(jpl)和封堵(jfd)。使用MakeSense(<https://www.makesense.ai/>)网页进行缺陷实例标注,获取包含了缺陷目标位置信息的XML标注文件。为增强数据的多样性与模型泛化能力,对原始图像采取了平移、缩放、添加噪声、调整对比度和色温操作进行扩充,最终获得3 380张缺陷图像,共包含了4 627个缺陷实例。将数据集按8:2的比例划分为训练集和验证集,分别包含了2 704张和676张缺陷图像。其中,训练集的障碍物、错口、变形、树根、破裂和封堵实例数分别为863、602、719、517、620、355个,验证集的为298、156、152、123、133、89个。

### 2.2 实验环境与评估指标

实验环境为7核Intel(R) Xeon(R) CPU E5-2680 v4 @ 2.40 GHz, RTX 3090 24 GB显存, 30 GB内存; Ubuntu20.04操作系统, Pytorch2.0.0, CUDA 11.8和Python3.8.10。模型训练参数:批次大小为16,优化器为SGD,初始学习率设为0.01,使用余弦学习率调度器,最终学习率为0.000 1,开启Mosaic数据处理设置,总迭代训练次数为200轮。

实验采用模型浮点运算量(FLOPs)、参数量(Parameters)、模型大小(Model size)作为评估模型复杂度的指标,并以平均精度均值(mAP@50)与推理时间(Inference time)衡量排水管道缺陷检测模型的精度与推理速度。其中,当推理时间小于1/24 s即41.7 ms时,便可达到实时检测的要求。mAP@50的交并比阈值取0.5,其计算方法见式(4)、(5)。

$$AP = \int_0^1 Pr(R) dR \times 100\% \quad (4)$$

表1 消融实验

Tab.1 Ablation experiment

模型	C3_PConv	PfouV2	LAMP	FLOPs/G	Parameters/10 <sup>6</sup>	Model size/MB	mAP@50/%	Inference time/ms
YOLOv5n	-	-	-	7.1	2.5	5.0	93.2	27.2
YOLO-Pipe-a	√	-	-	7.0	2.4	4.8	93.2	27.0
YOLO-Pipe-b	-	√	-	7.1	2.5	5.0	93.8	27.2
YOLO-Pipe-c	√	√	-	7.0	2.4	4.8	94.1	27.1
YOLO-Pipe-d	√	√	√(×1.3)	5.2	1.9	3.8	93.9	27.7
YOLO-Pipe	√	√	√(×1.2)	5.8	2.0	4.1	94.8	28.2

注:“√”表示使用了该模块,“-”表示未执行该操作,括号内的×1.2、×1.3表示模型FLOPs在剪枝前与剪枝后的近似比值。

$$mAP@50 = \frac{1}{n} \sum_{i=1}^n AP_i \quad (5)$$

式中:AP为平均精度,取Pr-R曲线下的面积值;Pr为精确度;R为召回率;n为缺陷的类别数。

## 3 结果分析

### 3.1 图像检测

为更直观展示YOLO-Pipe模型对排水管道缺陷的检测效果,对验证集中三种不同工况下的缺陷图像进行了检测,效果如图5所示。可见,无论在图像清晰还是模糊、雾汽干扰的情况下,该模型对各类管道缺陷均保持较高的检测置信度,展现出良好的检测性能。

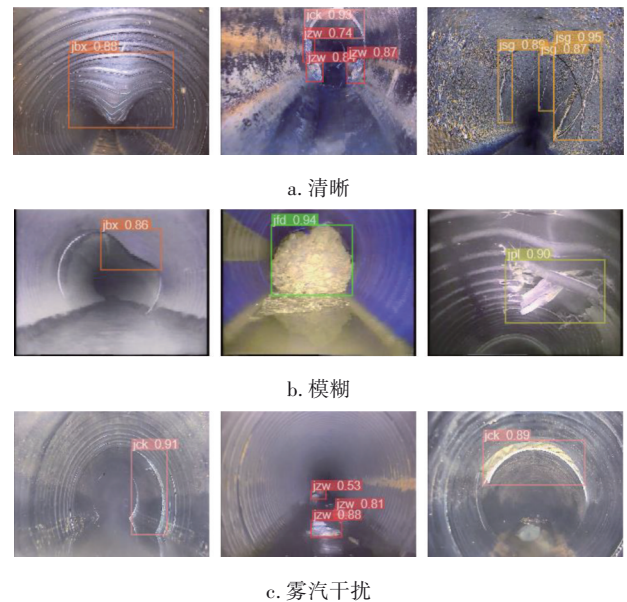


图5 YOLO-Pipe排水管道缺陷检测效果

Fig.5 Defect detection performance of YOLO-Pipe

### 3.2 消融实验

在同一训练、验证数据及设备上进行测试,并设置了YOLO-Pipe-a、YOLO-Pipe-b等4个模型以进一步对比与检验不同优化策略对模型性能的影响,结果如表1所示。

由表1可知,YOLO-Pipe模型在YOLOv5n的基础上,通过使用C3\_PConv结构、PIoUv2损失函数以及LAMP剪枝算法进行了优化与提升。这一优化不仅降低了模型的复杂度,并有效提高了模型的精度。具体而言,YOLO-Pipe模型的浮点运算量降至5.8 G,参数量减少至 $2.0 \times 10^6$ ,模型大小缩减为4.1 MB,相比原YOLOv5n模型,分别降低18.3%、20.0%和18.0%。此外,YOLO-Pipe模型在mAP@50指标上达到了94.8%,比YOLOv5n提高了1.6%,而推理时间仅增加了1.0 ms,这进一步验证了所提出优化方法的高效性。

### 3.3 对比分析

在相同实验环境下,将YOLO-Pipe模型与YOLOv5n(FasterNet)、SSD(MobileNetv2)、YOLOv8n和YOLOv3 Tiny目标检测模型进行对比,结果见表2。

表2 不同模型性能对比

Tab.2 Comparison of different model performances

Model	FLOPs/G	Parameters/ $10^6$	Model size/MB	mAP@ 50/%	Inference time/ms
YOLOv5n	7.1	2.5	5.0	93.2	27.2
YOLOv5n (FasterNet)	4.5	1.5	3.1	92.1	16.2
SSD(Mobile- Netv2)	1.5	4.2	16.8	73.4	69.4
YOLOv8n	8.1	3.0	6.0	94.1	27.5
YOLOv3 Tiny	18.9	12.1	23.3	94.7	37.2
YOLO-Pipe	5.8	2.0	4.1	94.8	28.2

由表2可知,除SSD(MobileNetv2)模型外,其余模型的mAP@50值均超过了92%。其中,YOLO-Pipe模型的精度最高,mAP@50值达到94.8%。SSD(MobileNetv2)模型尽管浮点计算量最低,但在参数量、模型大小等方面表现不佳,其模型的后处理优化不如YOLO系列,导致推理速度最慢;并且其mAP@50仅为73.4%,较YOLO-Pipe模型低21.4%。在YOLO-Pipe、YOLOv5n、YOLOv5n(FasterNet)三个模型中,YOLOv5n(FasterNet)模型的轻量化程度最高且推理速度最快,但YOLO-Pipe的缺陷识别精度比YOLOv5n、YOLOv5n(FasterNet)模型分别提高了1.6%和2.7%。

相比之下,YOLO-Pipe与YOLOv8n、YOLOv3 Tiny模型的检测精度相近,但其模型复杂度最低。具体而言,YOLO-Pipe模型的浮点运算量、参数量、

模型大小仅为模型复杂度最高的YOLOv3 Tiny的30.7%、16.5%、17.6%,表明其结构更为紧凑,更适用于算力较弱的边缘设备。YOLO-Pipe模型的推理时长为28.2 ms,这在所有模型的推理速度中处于中等水平。然而,综合考虑其较低的模型复杂度以及较高的mAP@50指标,该模型完全能够胜任高精度的缺陷实时检测任务。同时,YOLO-Pipe模型在浮点运算量与mAP@50之间取得最佳平衡,实现了轻量高效化的目标。

### 3.4 效果验证

随机选取了76个排水管道现场检测视频作为数据集,使用Pipe-Track算法对视频数据集进行缺陷追踪检测,效果如图6所示。

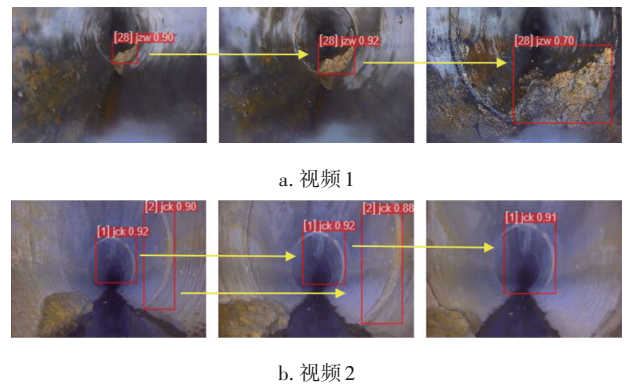


图6 缺陷追踪效果示意

Fig.6 Schematic of defect tracking performance

由图6可知,Pipe-Track算法对排水管道检测视频中的缺陷检测置信度较高,不受距离的影响,精准追踪到视频中的管道缺陷。为进一步验证算法的有效性,将算法检测结果与人工观测结果进行对比。结果表明,人工观测到障碍物、错口、变形、树根、破裂和封堵类缺陷数量分别为43、99、60、14、21、13个,算法分别锁定42、80、55、13、19、13个,锁定率分别为97.7%、80.8%、91.7%、92.9%、90.5%、100%。可见,除错口类缺陷的锁定率为80.8%外,其余5类缺陷的锁定率均在90%以上。由于视频拍摄质量、轻微的错口外观与波纹管内壁突起相似等因素,导致追踪框架出现漏检,从而降低了错口缺陷的锁定率。但排水管道整体缺陷的平均锁定率为92.3%,可满足日常检测的需求。

### 4 结论

① 与其他目标检测模型相比,YOLO-Pipe在精度与复杂度间的平衡性表现最佳,能够高效完成

管道缺陷检测任务。YOLO-Pipe模型的mAP@50达到了94.8%,同时推理速度满足实时检测的需求,可快速准确地检测排水管道缺陷。

② Pipe-Track算法能够批量处理排水管道检测视频数据,对管道中的缺陷进行追踪定位,并输出缺陷检测结果。该算法在管道缺陷检测方面表现出色,平均锁定率达到了92.3%,为管道检测技术的集成化研究和实际应用提供了扎实的基础。

### 参考文献:

- [1] 王俊岭,邓玉莲,李英,等.排水管道检测与缺陷识别技术综述[J].科学技术与工程,2020,20(33):13520-13528.  
WANG Junling, DENG Yulian, LI Ying, *et al.* A review on detection and defect identification of drainage pipeline [J]. Science Technology and Engineering, 2020, 20(33): 13520-13528 (in Chinese).
- [2] WANG M, LUO H, CHENG J C P. Towards an automated condition assessment framework of underground sewer pipes based on closed-circuit television (CCTV) images [J]. Tunnelling and Underground Space Technology, 2021, 110: 103840.
- [3] 方宏远,马铎,王念念,等.基于融合卷积神经网络的多种类管道病害检测方法[J].北京工业大学学报,2022,48(6):561-571.  
FANG Hongyuan, MA Duo, WANG Niannian, *et al.* Detection algorithm for multiple underground pipeline diseases based on a fusion convolutional neural network [J]. Journal of Beijing University of Technology, 2022, 48(6): 561-571 (in Chinese).
- [4] 李清泉,朱家松,李虹,等.基于漂流式胶囊机器人的管道快速检测系统[J].中国给水排水,2021,37(10):126-132.  
LI Qingquan, ZHU Jiasong, LI Hong, *et al.* Rapid detection system of pipeline based on floating capsule robot [J]. China Water & Wastewater, 2021, 37(10): 126-132 (in Chinese).
- [5] 王大成,谭军辉,彭述刚,等.利用深度学习模型智能识别地下排水管道缺陷[J].测绘通报,2021(10):141-145.  
WANG Dacheng, TAN Junhui, PENG Shugang, *et al.* Intelligent identification system of drainage pipelines defects based on deep learning model [J]. Bulletin of Surveying and Mapping, 2021 (10): 141-145 (in Chinese).
- [6] 周倩倩,司徒祖祥,刘汉林,等.基于生成对抗网络和迁移学习的排水管道缺陷识别[J].中国给水排水,2022,38(17):27-33.  
ZHOU Qianqian, SITU Zuxiang, LIU Hanlin, *et al.* Sewer defects recognition based on generative adversarial networks and transfer learning [J]. China Water & Wastewater, 2022, 38(17): 27-33 (in Chinese).
- [7] KUMAR S S, ABRAHAM D M, JAHANSHAH M R, *et al.* Automated defect classification in sewer closed circuit television inspections using deep convolutional neural networks [J]. Automation in Construction, 2018, 91: 273-283.
- [8] 曾飞,李斌,周健,等.改进YOLOv7算法的排水管道缺陷检测与几何表征[J].现代制造工程,2024,522(3):110-118.  
ZENG Fei, LI Bin, ZHOU Jian, *et al.* Improved defect detection and geometric characterization of drainage pipes in YOLOv7 algorithm [J]. Modern Manufacturing Engineering, 2024, 522(3): 110-118 (in Chinese).
- [9] YIN X, CHEN Y, BOUFERGUENE A, *et al.* A deep learning-based framework for an automated defect detection system for sewer pipes [J]. Automation in Construction, 2020, 109: 102967.
- [10] KUMAR S S, WANG M, ABRAHAM D M, *et al.* Deep learning-based automated detection of sewer defects in CCTV videos [J]. Journal of Computing in Civil Engineering, 2020, 34(1): 04019047.
- [11] OH C, DANG L M, HAN D, *et al.* Robust sewer defect detection with text analysis based on deep learning [J]. IEEE Access, 2022, 10: 46224-46237.
- [12] LIU C, WANG K, LI Q, *et al.* Powerful-IoU: more straightforward and faster bounding box regression loss with a nonmonotonic focusing mechanism [J]. Neural Networks, 2024, 170: 276-284.
- [13] ZHOU Z, ZHAO J, CHEN X, *et al.* A ship tracking and speed extraction framework in hazy weather based on deep learning [J]. Journal of Marine Science and Engineering, 2023, 11(7): 1353.

作者简介:凌同华(1968-),男,湖南双峰人,博士,教授,主要从事隧道与地下工程研究。

E-mail:lingtonghua@163.com

收稿日期:2024-08-01

修回日期:2024-09-20

(编辑:李德强)