

DOI:10.19651/j.cnki.emt.2519549

排水管道变形缺陷标注方式对智能识别的影响研究^{*}史雨霏¹ 郭 帅¹ 李 杰²

(1.合肥工业大学土木与水利工程学院 合肥 230009; 2.上海勘测设计研究院有限公司 上海 200335)

摘 要: 针对目前排水管道缺陷数据集缺乏标注标准的问题,以管道变形缺陷为研究对象,利用 YOLOv8 检测模型研究了不同的标注方式对管道缺陷识别结果的影响。首先根据变形缺陷特性将缺陷图像分为凸块变形和整体变形两大类,对凸块变形采用凸块全标和凸块半标两种标注方式,对整体变形采用整体全标和整体半标的标注方式进行标注,并对每种标注方式进行了 5 次独立实验。结果表明,对于凸块变形采用凸块全标的标注方式,其 P、R、F1 和 mAP50 这 4 项评价指标的数值分别为 76.56%、74.36%、75.43% 和 72.12%,而凸块半标的标注方式其 4 项数值分别为 88.51%、76.77%、82.17% 和 83.14%,因此凸块半标的标注方式更适用于凸块变形;对于整体变形,采用整体全标的标注方式,其 P、R、F1 和 mAP50 这 4 项评价指标的数值分别为 83.85%、84.92%、84.34% 和 84.46%,而采用整体半标的方式在训练 3 次之后发现 4 个评价指标都无法趋于稳定,表明整体全标的标注方式更适用于整体变形。

关键词: 排水管道;变形缺陷;管道缺陷识别;YOLOv8;数据集标注;标注方式

中图分类号: TU992.4;TN-9 **文献标识码:** A **国家标准学科分类代码:** 560.5510

Research on the impact of marking methods for deformation defects of
drainage pipes on intelligent recognition algorithmsShi Yufei¹ Guo Shuai¹ Li Jie²

(1. School of Civil and Hydraulic Engineering, Hefei University of Technology, Hefei 230009, China;

2. Shanghai Survey and Design Institute Co., Ltd., Shanghai 200335, China)

Abstract: In view of the lack of annotation standards in the current drainage pipe defect dataset, taking the pipe deformation defect as the research object, the YOLOv8 detection model was used to study the influence of different annotation methods on the pipe defect recognition results. Firstly, the defect images were classified into two major categories based on the characteristics of the deformation defects: Convex block deformation and overall deformation. For the convex block deformation, two labeling methods, namely convex block full marking and convex block half marking, were adopted. For the overall deformation, both overall full marking and overall half marking were used for labeling. Five independent tests were conducted for each labeling method. The results show that for the convex block deformation using the full labeling method of convex blocks, the values of the four evaluation indicators P, R, F1 and mAP50 are 76.56%, 74.36%, 75.43% and 72.12% respectively. The four values of the semi-labeled convex block annotation method are 88.51%, 76.77%, 82.17% and 83.14%, respectively. Therefore, the semi-labeled convex block annotation method is more suitable for convex block deformation. For the overall deformation, when the overall full labeling method was adopted, the values of the four evaluation indicators P, R, F1 and mAP50 were 83.85%, 84.92%, 84.34% and 84.46%, respectively. However, when the overall semi-labeling method was used for three training sessions, it was found that none of the four evaluation indicators could tend to stabilize. It indicates that the overall full-label annotation method is more suitable for overall deformation.

Keywords: drainage pipe; deformation defect; pipeline defect identification; YOLOv8; dataset annotation; annotation method

0 引 言

近年来,随着我国市政工程行业的快速发展,地下排水

管网的管理正经历着以数字化、智能化为特征的技术革新。如在管道缺陷判读领域,传统人工经验的判读模式已逐步向基于机器视觉和深度学习算法的智能化精准识别转型升

收稿日期:2025-08-06

* 基金项目:国家重点研发计划项目(2024YFC3810803)资助

级^[1]。其中,深度学习模型的性能高度依赖于高质量数据集,而数据集标注的规范性与一致性是构建高质量数据集的关键。然而,当前国内外关于数据集标注原则的研究与实践仍基于初步发展阶段^[2]。在国际上,以 Pascal VOC 2011 为代表的经典数据集确立了早期数据集标注准则的基本框架,如对“可见对象”的判定标准、边界框的紧密性要求、采用矩形框标注等等,为后续对于数据集标准标准的研究工作奠定了标准化基础。在国内,相关研究在借鉴国际通用准则的同时,更侧重于是否与本土化场景适配,例如在自动驾驶数据集中增加本土交通元素的标注类别,并对人脸、车牌等敏感信息进行模糊处理。但在道路裂缝、管道缺陷等检测场景,并没有数据集标注标准的深入研究,存在标注标准不统一以及标注主观性强等问题^[3-4],这严重限制了相关研究的发展上限。

数据集没有统一的标注标准对多方面的研究造成了影响,一方面研究学者在进行管道缺陷检测智能识别方面的研究时缺少统一标注标准的参考,会影响研究结果的可靠性;另一方面传统的人工判读检测依赖主观性,人工耗时长且容易出现误判,而规范的标注和相对合适的训练模型相配合能够减少人工判读的主观性,提高判读效率和准确率^[5],因此构建垂直领域的标准标准已成为当前需要深化研究的重要方向。研究针对管道缺陷数据集缺乏统一标注标准的问题,以排水管道变形缺陷为例,率先探讨并构建数据集标注标准,研究成果对推动排水管道缺陷检测智能识别的研究具有重要的学术价值与实践意义。

1 实验模拟

1.1 选定数据集标注工具

数据集标注工具在机器学习和深度学习中扮演着至关重要的角色。这些工具通过高效的标注流程和丰富的功能,提升数据标注的效率和质量,帮助研究人员为计算机算法提供必要的训练数据,为模型训练提供高质量的数据支持。常见的深度学习数据集标注工具有 Labelimg、Labelme 等。其中,Labelme 虽可标注多边形框,但输出格式(json)无法与 YOLO 直接对接,需要二次转化,过程 Labelimg 虽仅支持矩形框标注,但操作简单、标注速度快,且输出格式(txt)可直接与 YOLO(you only look once)对接较为繁琐。与此同时考虑到 Pascal VOC 2011 标注准则采用了矩形框标注,最终选用 Labelimg 作为数据集标注工具。

1.2 选定缺陷检测基准模型

1)YOLO 算法的介绍

YOLO 算法作为目标检测领域的突破性成果,以其高效性和准确性著称^[6]。相比于其他常见的目标检测算法 RCNN、SSD 等,YOLO 算法具有模型体量小、训练速度快、耗时少等优点,并且管道变形缺陷不属于小目标,因此对于 YOLO 算法难以检测小目标的缺点可以忽略。随着

YOLO 系列版本的迭代,已发展至 YOLOv8 版本,不仅改进了模型架构,还采用了更高效的训练策略和优化方法,使其在检测精度和速度上均有显著提升,因此综合选择 YOLOv8 算法作为研究训练的模型。

2)YOLOv8 预训练模型的选定

在正式训练之前先构建管道缺陷样本库再分别用 YOLOv8 提供的 YOLOv8s、YOLO8n、YOLO8m、YOLOv8l、YOLOv8x 这 5 个预训练模型进行检测^[7],筛选训练模型,在训练集为 2 000 张,验证集为 100 张,预训练模型超参数 batch size = 16, Epoch = 200 的前提下结果对比如表 1 所示^[8]。

表 1 预训练模型超参数设置及结果对比
Table 1 Hyperparameter settings and result comparisons of pre-trained models

权重模型	Params/ M	P	R	mAP50	训练 时间/h
YOLOv8n	3.200	0.716	0.637	0.717	2.580
YOLO8s	11.200	0.694	0.709	0.739	3.690
YOLO8m	25.900	0.703	0.682	0.721	8.080
YOLO8l	43.700	0.646	0.721	0.750	24.370
YOLO8x	68.200	0.682	0.689	0.728	33.840

其中,YOLOv8m、YOLOv8l 和 YOLOv8x 的参数量过大会造成数据冗余,且对内存部署要求高,训练时间过长,YOLOv8n 具备的网络深度最浅、宽度最小,能学习到的多样化特征较小^[9],且训练时间较 YOLOv8s 差别不大,所以根据设备内存、评价指标、训练时间等方面综合评定,最终确定采 YOLOv8s 作为训练模型。

1.3 实验设置

研究硬件设备参数如下:CPU 为 Intel(R) Xeon(R) CPU E5-2630 v4 @ 2.20 GHz, GPU 为 NVIDIA Quadro P4000。配置深度学习环境如下:PyCharm 2022.2.1, python3.8,凸块变形和整体变形统一采用 YOLOv8s 模型进行训练,图像像素至少为 500×500,训练迭代次数设置为 300 轮,初始学习率设置为 0.001,最终学习率设置为 0.01,batch 为 16,mosaic 设置为 1,mixup 设置为 0.1。

1.4 评价指标

在评估体系中,常见的评价指标如表 2 所示。

其中,P 能够衡量模型的“准确性”,即模型预测的检测框中有多少是真实目标,R 能够衡量模型的“全面性”,即模型能检测到多少真实目标,由于精确率和召回率成反比,综合考虑这两个指标研究引入 F1。mAP50 能够兼顾精确率与召回率,反映模型整体性能^[10]。为了评估不同管道图像类别的检测性能,采用 P、R、F1 和 mAP50 作为评价训练结果的标准^[11],因为 F1 综合权衡了 P 和 R,且 P 和 R 成反比,所以若 P 和 R 无法直接反映模型性能的时候将 F1 和

表 2 常见评价指标
Table 2 Common evaluation indicators

名称	简写	含义	公式
真正	TP	正例被预测为正例	无
假正	FP	负例被预测为正例	无
真负	TN	负例被预测为负例	无
假负	FN	正例被预测为负例	无
准确率	A	正例和负例中预测正确数量占总数量的比例	$A = \frac{TP + TN}{TP + TN + FN + FP}$
精确率	P	预测为正例的样本中预测正确的比例	$P = \frac{TP}{TP + FP}$
召回率	R	被预测正确的正例占总实际正例样本的比例	$R = \frac{TP}{TP + FN}$
精确率和召回率的 调和平均数	F1	中和了精确率和召回率的指标	$F1 = \frac{2PR}{P + R}$
平均精度均值	mAP50	IoU(交并比:衡量预测边界框与真实边界框重叠程度的指标)阈值>0.5 下的 mAP	无

mAP50 作为更重要的评价指标。

同时,为了判断不同缺陷标注方式间的差异是否由随机性导致,采用了配对 t 检验计算 p 值和 Cohen's d 效应量。 p 值表示由于随机性导致数据结果的概率大小,规定 $p < 0.05$ 为小概率事件。Cohen's d 效应量用来衡量差异性大小,规定 $|d| < 0.2$ 为小效应; $0.2 \leq |d| < 0.5$ 为中效应; $0.5 \leq |d| < 0.8$ 为大效应; $|d| \geq 0.8$ 为巨大效应。

2 构建管道变形缺陷数据集样本库

2.1 数据集筛选

根据《城镇排水管道检测与评估技术规程》,城镇排水管道缺陷可分为结构性和功能性缺陷两大类^[12]。其中变形作为一种典型的管道结构性缺陷,指管道受外力挤压导致其几何形态发生非设计允许的形变现象^[13]。

研究选取芜湖市和天津市共 40 多条管道进行管网缺陷检测,用 CCTV 和 QV 采集排水管道视频进行管道检测,并从视频中截取管道变形缺陷图片^[14]。对样本库图像的要求包括:

- 1)保证图像清晰,筛除模糊、拍摄视角无法直观展示全部缺陷病症的图像;
- 2)图像格式为 PNG;
- 3)图像像素至少为 500×500 ;
- 4)缺陷特征明显,对于图像缺陷能够进行无异议的人工判读。

基于以上要求,共筛选出 282 张图像,作为研究的管道变形缺陷数据集样本库。

2.2 管道变形缺陷分类

根据收集到的管道变形缺陷图像特性,可将管道变形缺陷分为两大类,一类是管道内有明显往内凸出变形的部

位,称为凸块变形;另一类管道内无明显凸突变形部位但管道发生椭圆形变或管道有明显往管道外凸出变形的部位,称为整体变形,分别如图 1、2 所示。最后得到的凸块变形图像有 178 张,整体变形图像有 104 张。




图 1 凸块变形示意

Fig. 1 Schematic of convex block deformation




图 2 整体变形示意

Fig. 2 Overall deformation

2.3 数据集划分与扩充

针对分类好的图像,首先按照训练集:验证集=5:1 的划分方式分别划分凸块变形和整体变形图像^[15]。由于可用的图片较少,不足以支撑模型训练效果,为提升数据集质量,采用上下翻转、左右翻转、随机剪裁、锐化的方式进行数据扩充,对图像进行预处理^[16],如图 3 所示,再对扩充后的图像进行再次筛选,最后得到凸块变形的训练集有 696 张,验证集有 152 张,整体变形的训练集有 501 张,验证集有 89 张,数据集扩充前后的具体数量如表 3~4 所示。




图 3 数据集扩充方式

Fig. 3 Dataset expansion methods

表 3 凸块变形数据集扩充方式及数量

Table 3 Expansion methods and quantities of the convex block deformation data set

张

数据集	原图	左右翻转	上下翻转	随机裁剪
训练集	178	178	178	162
验证集	39	39	39	35

表 4 整体变形数据集扩充方式及数量

Table 4 Expansion methods and quantities of the overall deformation data set

张

数据集	原图	左右翻转	上下翻转	随机裁剪	锐化
训练集	104	104	104	86	103
验证集	19	19	19	14	18

同时在训练过程中采用 Mixup 和 Mosaic 数据增强方法,设置模型参数 $Mixup=0.1$, $Mosaic=1$ 。Mixup 是混合两个图像及其标签,创建合成图像的一种数据增强方式,不仅保留了原始图像的关键信息,还增强了训练数据的多样性。Mosaic 是通过将 4 张图片实施马赛克式拼接来生成新图像的一种数据增强方式,采用这种方式所构建的图像,不仅能够丰富数据的多样性,还在无形中提升了批处理的数量^[17]。

2.4 数据集标注方式

为了对比出管道缺陷检测中成本效益最优的标注策略,研究提出“全标”和“半标”两种标注方式,全标方式旨在通过勾勒完整的横截面,为模型提供缺陷几何形态的完整精确信息;而半标方式仅标注缺陷存在区域,可大幅降低标注成本。

对于凸块变形(在 Labelimg 标注时简称 TKBX),研究采取两种标注方式进行对比。第 1 种是对于完全可视的凸块变形,将管道变形部位及其横截面一起圈出标注,对于不完全可视的凸块变形,则仅需把变形部分圈出来,要

求标注部分尽可能小且完全包含变形部位,此种标注方式称为凸块全标;第 2 种是对于完全可视的凸块变形需从开始变形的部位进行标注,圈出部分仅包含明显变形和开始变形部分,对于不完全可视的凸块变形则需把变形部分圈出来即可,要求标注部分尽可能小且完全包含变形部位,称此种标注方式为凸块半标。以上两种凸块变形标注方式如图 4~5 中灰色框所示。




图 4 凸块全标

Fig. 4 Full marking of convex blocks




图 5 凸块半标

Fig. 5 Convex block semi-axes

对于整体变形(在 Labelimg 标注时简称 ZTBX),研究同样采取两种标注方式:第 1 种是将整个管道变形部位横截面圈出标注,要求标注部分尽可能小且完全包含变形部位,称此种标注方式为整体全标;第 2 种是对于管道有明显往外凸出变形的折角部位需将折角的部位圈出标注,要求标注面积尽可能不超过管道变形横截面的一半且标注部分包含折角部位,而对于无明显折角的变形管道从开始变形的部位进行标注,要求标注部分尽可能小且完全包含变形部位,称此种标注方式为整体半标。以上两种整体变形标注方式如图 6~7 所示。




图 6 整体全标

Fig. 6 Overall labeling




图 7 整体半标

Fig. 7 Overall semi-axes

3 实验结果分析

为了验证对于不同的管道变形缺陷,哪种标注方式使得训练出的模型效果更好,本研究在上述 1.3 节相同的实验条件下进行对比标注实验。

为提升模型性能评估的可靠性,采用重复训练数据集对预测结果进行稳定性验证。针对各标注方式,分别进行 5 次独立实验,通过计算各评价指标的均值来综合衡量模型性能。这种评估策略有效降低了单次实验结果的随机性,确保了性能比较的客观性和科学性^[18]。

3.1 凸块变形标注实验

对于凸块变形的两种标注实验训练结果如图 8~11 和表 5~8 所示。




图 8 凸块全标训练结果

Fig. 8 Training results of fully marked convex blocks




图 9 凸块半标训练结果

Fig. 9 Training results of convex block semi-quantization

由图 8~9 可知,经过 300 轮迭代训练,两种标注方式的 P、R、mAP50 都逐渐趋于稳定,但凸块半标的各项指标在训练初期即高于全标,且收敛后波动更小,验证了半标方式的稳定性优势。

由表 5~7 可知,凸块半标的 P、R、F1 和 mAP50 相比于凸块全标分别高出 11.95%、2.41%、6.74%、11.02%,




图 10 凸块全标训练结果

Fig. 10 Training results of convex block fully labeled




图 11 凸块半标训练结果

Fig. 11 Training results of convex block semi-quantization

表 5 凸块全标训练结果

训练结果	P	R	F1	mAP50
第 1 次训练结果	78.25	77.63	77.94	72.16
第 2 次训练结果	73.85	72.46	73.15	68.98
第 3 次训练结果	76.95	75.00	75.96	72.31
第 4 次训练结果	80.71	74.32	77.38	73.22
第 5 次训练结果	73.05	72.37	72.71	73.95
均值	76.56	74.36	75.43	72.12

分别说明凸块半标方式相比于凸块全标方式的检测管道缺陷的能力更强、漏检率更小、综合反映凸块半标方式在 P 和 R 的平衡上更优、在 IoU 阈值为 0.5 时的模型检测效果更好。

由表 8 可知,分别将 5 次训练结果得出的 P、R、F1、

表6 凸块半标训练结果

Table 6 Training results of convex block semi-notation				
	/%			
训练结果	P	R	F1	mAP50
第1次训练结果	86.85	80.26	83.43	84.13
第2次训练结果	91.78	73.50	81.63	81.28
第3次训练结果	89.85	74.98	81.74	82.43
第4次训练结果	87.65	79.61	83.44	86.75
第5次训练结果	86.44	75.52	80.61	81.11
均值	88.51	76.77	82.17	83.14

表7 凸块变形标注方式训练结果对比

Table 7 Comparison of training results for notation methods of convex block deformation				
	/%			
标注方式	P	R	F1	mAP50
凸块全标	76.56	74.36	75.43	72.12
凸块半标	88.51	76.77	82.17	83.14

表8 凸块变形 p 值和 Cohen's d 效应量

Table 8 P-values for convex block deformation and Cohen's d effect size			
评价指标	样本量	p 值	d
P	5	0.003 5	-2.759 1
R		0.057 1	-1.184 4
F1		0.000 4	-4.983 9
mAP50		0.000 6	-4.446 6

mAP50 进行配对 t 检验,P、F1、mAP50 得出的 p 值均 <0.05 且 Cohen's d 效应量均 >0.8 ,R 得出的 p 值虽然略 >0.05 ,但 Cohen's d 效应量 >0.8 ,表明这种差异不仅具有统计学显著性,具有极大的实际意义。

图 10~11 为凸块全标和凸块半标训练结果的精确率和召回率(P-R)、精确率和置信度(P-C)、召回率和置信度(R-C)、精确率和召回率的调和平均数和置信度(F1-C)的关系图。

由图 10(a)和 11(a)对比可知,图 11(a)中的曲线与坐标轴围成的面积比图 10(a)更大,面积越大意味着在不同 R 水平下 P 越高,模型平衡“查全”和“查准”的综合表现更优,模型综合性能通常越好,所以图 11(a)更高精度高召回。

由图 10(b)和 11(b)对比可知,图 11(b)的曲线整体比图 10(b)更高,说明在相同置信度下 P 表现更优,模型预测的准确性和高置信度下的稳定性更出色,综合性能更强。

由图 10(c)和 11(c)对比可知,图 11(c)的曲线在置信度区间 0~0.6 内 R 都维持在 0.8 以上且曲线平缓,而图 10(c)置信度区间 0~0.4 的 R 维持在 0.8 以上,但在中置信度区间 0.4~0.6 内 R 快速跌至 0.6 以下,且图 11(c)

比图 10(c)的 R 峰值要高($0.96>0.84$),说明图 11(c)的在 R-C 平衡上表现更优。

由图 10(d)和 11(d)对比可知,图 11(d)F1 的峰值(0.83)比图 10(d)的峰值(0.78)更高,F1 越高,说明模型在精确率和召回率的平衡上表现优越,对目标的检测既准又全的能力更强,且图 11(d)的最优置信度(0.350)比图 10(d)的最优置信度(0.467)低,说明模型在更宽松的置信度要求下对凸块变形缺陷的识别能力可能更强,漏检风险相对更低。

综上所述对于凸块变形,凸块半标的标注方式相比于凸块全标的标注方式能够使得模型的检测效果更好。

3.2 整体变形标注实验

对于整体变形的两种标注实验训练结果如图 12~14 和表 9~11 所示。




图 12 整体全标训练结果

Fig. 12 Overall fully labeled training results





图 13 整体半标训练结果

Fig. 13 Overall semi-supervised training results

由图 12~13 可知,经过 300 轮迭代训练,整体半标 3 次训练发现 P、R 和 mAP50 始终无法趋于稳定,最终因模型性能不可靠而终止后续训练,而整体全标的 P、R、mAP50 逐渐趋于稳定且数值均远超整体半标,说明整体全标的标注方式要比整体半标的标注方式更稳定。






图 14 整体全标训练结果

Fig. 14 Overall training results of full labeling

表 9 整体全标训练结果

Table 9 Overall training results with full labeling %

训练结果	P	R	F1	mAP50
第 1 次训练结果	81.97	86.86	84.34	87.66
第 2 次训练结果	83.78	88.76	86.20	82.23
第 3 次训练结果	84.80	84.27	84.53	84.21
第 4 次训练结果	84.32	79.78	81.99	84.67
第 5 次训练结果	84.37	84.93	84.65	83.54
均值	83.85	84.92	84.34	84.46

表 10 整体半标训练结果

Table 10 Overall semi-supervised training results %

训练结果	P	R	F1	mAP50
第 1 次训练结果	63.22	65.66	64.42	68.11
第 2 次训练结果	52.83	31.63	39.57	41.82
第 3 次训练结果	43.12	47.96	45.41	48.34
均值	53.06	48.42	49.80	52.76

表 11 整体变形标注方式训练结果对比

Table 11 Comparison of training results for overall deformation annotation methods %

标注方式	P	R	F1	mAP50
整体全标	83.85	84.92	84.34	84.46
整体半标	53.06	48.42	49.80	52.76

由表 9~11 可知,整体全标的 P、R、F1 和 mAP50 相比于整体半标分别高出 30.79%、36.50%、34.54%、31.70%,进一步说明整体全标方式相比于整体半标方式更适用于整体变形检测。

由于整体半标训练结果不可靠,所以仅分析整体全标标注方式训练出的模型检测效果,不进行整体半标模型检测效果分析和两种标注方式间的配对 t 检验。

图 14 为整体全标训练结果的精确率和召回率(P-R)、精确率和置信度(P-C)、召回率和置信度(R-C)、精确率和召回率的调和平均数和置信度(F1-C)的关系图。

由图 14(a)可知,P 在 R 未接近 1.0 前,P 长时间维持

高位,说明模型在大部分检测场景中,能较好平衡高精度高召回的需求。

由图 14(b)可知,P 在中高置信度区间(0.2~0.8),精确率稳定且高,且在极高置信度区间(0.8~1.0)P 虽有下降,但整体仍在较高区间,未大幅暴跌,说明模型误检极少,核心检测能力可靠。

由图 14(c)可知,R 在低置信度区间(0~0.6)长期保持接近 1.0 的 R,高置信度(>0.6)后才快速下降,说明模型在低置信度预测时,漏检风险低。

由图 14(d)可知,F1 曲线下降越平缓且维持在高置信度的范围越广,说明模型稳定平衡检测准度和全度的能力较好。

综上所述对于整体变形,整体全标的标注方式相比于整体半标的标注方式能够使得模型的检测效果更好。

4 结 论

本研究针对当前排水管道缺陷标注缺乏统一标准的问题,以管道变形缺陷为例,基于管道变形缺陷数据集,选用标注工具 Labelimg 和检测模型 YOLOv8,并以 P、R、F1 及 mAP50 作为训练效果评定标准探究不同标注方式对排水管道变形缺陷检测效果的影响,以 p 值和 Cohen's d 效应量判断不同缺陷标注方式间差异是否具有统计学显著性。

为了方便研究,首先将管道变形缺陷图像分类分成凸块变形和整体变形两大类,再分别对每类用全标与半标两种不同的标注方式方式进行 5 次对比实验。通过对训练结果所得出的 P、R、F1、mAP50 最终数据、模型训练次数和 P、R、mAP50 的动态变化规律以及 P、R、F1 和 C 之间的关系图进行对比分析,并将 5 次训练结果得出的 P、R、F1、mAP50 进行配对 t 检验,表明对于凸块变形而言,半标的标注方式相比于全标能够使得模型对管道凸块变形的检测更高精度高召回高稳定,检测能力更好;对于整体变形而言,分析结果得到全标相比于半标的方式能够使得模型对管道整体变形的检测更稳定可靠。本研究为后续实现排水管道所有缺陷智能识别奠定基础,下一步,将对排水管道其他缺陷进行对比检测实验。

参考文献

[1] WANG J, LIU G H, WANG J Y, et al. Current status, existent problems, and coping strategy of urban drainage pipeline network in China [J]. Environmental Science and Pollution Research International, 2021, 28:43035-43049.

[2] 徐佳. 基于 CCTV 方法的排水管道检测技术与应用[J]. 工程建设与设计, 2024, 11(22):160-162.

XU J. Detection technology and application of drainage pipelines based on the CCTV method[J]. Engineering Construction and Design, 2024, 11(22):160-162.

[3] 林鹏. 城市排水管道泄漏检测技术现状及未来发展新见解[J]. 给水排水, 2023, 49(S1):926-935.

- LIN P. Current status and new insights into future development of urban drainage pipeline leakage detection technology[J]. Water Supply and Drainage, 2023, 49(S1):926-935.
- [4] LI D SH, CONG AN R, GUO SH. Sewer damage detection from imbalanced CCTV inspection data using deep convolutional neural networks with hierarchical classification[J]. Automation in Construction, 2019, 101:199-208.
- [5] 刘林勇. 压力管道检验检测技术的发展[J]. 化学工程与装备, 2022(10):211-213.
- LIU L Y. The development of inspection and testing technology for pressure pipelines [J]. Chemical Engineering and Equipment, 2022(10):211-213.
- [6] 赵琦. 基于视觉计算的排水管道缺陷评估方法研究[D]. 西安:西安科技大学, 2022.
- ZHAO Q. Research on drainage pipeline defect evaluation method based on visual computing [D]. Xi'an:Xi'an University of Science and Technology, 2022.
- [7] 熊玉华. 基于改进 YOLOv5 的排水管网缺陷智能识别技术[D]. 北京:北京建筑大学, 2023.
- XIONG Y H. Intelligent recognition technology for drainage pipe defects based on improved YOLOv5[D]. Beijing: Beijing University of Civil Engineering and Architecture, 2023.
- [8] 王红红. 基于 YOLOv8 的排水管道缺陷样本库构建及应用研究[D]. 北京:北京建筑大学, 2024.
- WANG H H. Research on the construction and application of drainage pipeline defect sample database based on YOLOv8[D]. Beijing: Beijing University of Civil Engineering and Architecture, 2024.
- [9] ZHANG K, QIN L X, ZHU L M. PDS-YOLO: A real-time detection algorithm for pipeline: Defect detection[J]. Electronics, 2025, 14(1):208.
- [10] 符前坤, 李强, 冉文荣, 等. 基于图像处理和机器学习的 PE 管道缺陷检测[J]. 现代电子技术, 2024, 47(21):59-66.
- FU Q K, LI Q, RAN W SH, et al. PE pipeline defect detection based on image processing and machine learning[J]. Modern Electronic Technology, 2024, 47(21):59-66.
- [11] 周梦颖, 张学武, 曾鹏源, 等. 基于改进 YOLOv8 的排水管网缺陷检测[J]. 电子测量技术, 2025, 48(3):128-137.
- ZHOU M Y, ZHANG X W, ZENG P Y, et al. Drainage network defect detection based on improved YOLOv8[J]. Electronic Measurement Technology, 2025, 48(3):128-137.
- [12] 国木源. 基于深度学习的排水管道缺陷检测与识别[D]. 西安:西安科技大学, 2022.
- GUO M Y. Drainage pipeline defect detection and recognition based on deep learning[D]. Xi'an: Xi'an University of Science and Technology, 2022.
- [13] 张官清, 黄胜, 卢芝. 基于轻量级 YOLO 算法的排水管道缺陷检测方法[J]. 水利技术监督, 2025(2):21-23, 168.
- ZHANG G Q, HUANG SH, LU ZH. A drainage pipeline defect detection method based on lightweight YOLO algorithm [J]. Water Resources Technology Supervision, 2025(2):21-23, 168.
- [14] 李伟, 刘桂雄, 曾成刚. 基于实例分割+CCTV 排水管道缺陷检测方法研究[J]. 电子测量技术, 2022, 45(3):153-157.
- LI W, LIU G X, ZENG CH G. Research on defect detection method for drainage pipelines based on instance segmentation and CCTV [J]. Electronic Measurement Technology, 2022, 45(3):153-157.
- [15] 凌晓, 刘露, 孙宝财, 等. 基于 DSG-ResNet34 的聚乙烯燃气管道电熔焊接缺陷检测[J]. 仪器仪表学报, 2025, 46(6):1-13.
- LING X, LIU L, SUN B C, et al. Detection of electrofusion welding defects in polyethylene gas pipelines based on DSG-ResNet34[J]. Chinese Journal of Scientific Instrument, 2025, 46(6):1-13.
- [16] 郑耀先. 面向排水管道缺陷检测的图像语义分割算法研究[D]. 天津:天津大学, 2020.
- ZHENG Y X. Research on image semantic segmentation algorithm for drainage pipe defect detection[D]. Tianjin: Tianjin University, 2020.
- [17] 高佳倩. 城市地下排水管道缺陷识别及现状判定研究[D]. 厦门:厦门理工学院, 2023.
- GAO J Q. Research on defect identification and current status determination of urban underground drainage pipelines[D]. Xiamen: Xiamen University of Technology, 2023.
- [18] 朱圣博, 魏利胜, 高港, 等. 基于改进 YOLOv8s 的光学遥感小型船舶检测算法[J]. 电子测量与仪器学报, 2024, 38(10):48-57.
- ZHU SH B, WEI L SH, GAO G, et al. An optical remote sensing small vessel detection algorithm based on improved YOLOv8s [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(10):48-57.

作者简介

史雨霏, 硕士研究生, 主要研究方向为市政排水管道缺陷的智能识别。

E-mail: 1337684780@qq.com

郭帅(通信作者), 博士, 副研究员, 硕士研究生导师, 主要研究方向为排水管网外来水诊断与评估、给排水管网无损检测与健康修复、城市内涝消减与海绵城市优化设计与数值模拟技术。

E-mail: guoshuai@hfut.edu.cn

李杰, 硕士研究生, 高级工程师, 主要研究方向为市政管网工程设计。

E-mail: 275129573@qq.com