

文章编号: 1009-7767(2025)02-0117-09

DOI: 10.19922/j.1009-7767.2025.02.117

基于轻量化 GELAN 的多种类管道病害检测

曹建林¹, 周健¹, 陈雪元¹, 张志刚¹, 朱仁民¹, 唐强², 黄钰程^{2*}

(1. 江苏省地质局第四地质大队, 江苏苏州 215129; 2. 苏州大学轨道交通学院, 江苏苏州 215131)

摘要: 排水管道在城市基础设施中发挥着重要作用, 其通常具有较长的使用寿命。但长时间使用不可避免会产生各种病害, 进而引发环境、安全问题。因此, 定期检测排水管道病害类型和数量, 为排水管道维护提供数据支持显得尤为重要。针对现有排水管道病害检测模型检测精度低的问题, 基于 YOLOv9 中提出的 GELAN, 首先通过减少深度因子和宽度因子对 GELAN 进行结构轻量化, 其参数数量和计算量分别减少了 92.97% 和 92.85%; 其次, 采用深度卷积 DWConv 替换网络主干中的标准卷积, 进一步对结构进行轻量化的同时提升了模型检测精度; 最后, 引入 DySample, 其根据输入数据的特征自适应调整卷积核的权重, 从而更好地捕捉病害的细节和特征, 同时避免了耗时的动态卷积运算和额外子网络。实验结果表明, 改进的 GELAN 模型在 7 种管道病害检测任务上具有 94.5% 的平均 mAP 值, 具有较高的工程实践意义。

关键词: 多种类管道病害检测; YOLOv9; GELAN; DWConv; DySample; 轻量化

中图分类号: TU 992.23 文献标志码: A

Detection of Various Pipeline Diseases Based on Lightweight GELAN

Cao Jianlin¹, Zhou Jian¹, Chen Xueyuan¹, Zhang Zhigang¹, Zhu Renmin¹, Tang Qiang², Huang Yucheng^{2*}

(1. Fourth Geological Brigade of Jiangsu Bureau of Geology, Suzhou 215129, China;

2. School of Rail Transportation, Soochow University, Suzhou 215131, China)

Abstract: Drainage pipes play crucial roles in urban infrastructure with long service life. However, various issues are inevitably caused by long-term use that can cause environmental and safety problems. Therefore, regular detection of the types and quantities of drainage pipe diseases is crucial for providing data support for pipe maintenance. To address the issue of low detection accuracy in existing pipeline disease models, a lightweight GELAN network is proposed based on YOLOv9. Firstly, GELAN is made structural lightweight by reducing the depth and width factors, resulting in a 92.97% and 92.85% reduction in parameters and computational load, respectively; Secondly, conventional convolutions in the network backbone is replaced with depthwise convolutions (DWConv), making further structural lightweight and enhancing the model's accuracy at the same time; Finally, DySample is introduced. According to the input data features, convolution kernel weights is adaptively adjusted for capturing disease details and features more effectively, while time-consuming dynamic convolution operations and additional sub-networks is avoided. Experimental results show that the proposed model achieves an average mAP value of 94.5% of seven pipeline disease detection tasks, demonstrating significant engineering practical value.

Key words: detection of various pipeline diseases; YOLOv9; generalized efficient layer aggregation network (GELAN); DWConv; DySample; lightweight

收稿日期: 2024-08-20

基金项目: 国家自然科学基金项目 (52208360)

作者简介: 曹建林, 男, 高级工程师, 学士, 主要研究方向为水工环、物化遥感, E-mail: 157868429@qq.com。

通讯作者: 黄钰程, 男, 副教授, 博士, 主要研究方向为交通基础设施智能(监)检测、固废再生路用, E-mail: ychuang@suda.edu.cn。

引文格式: 曹建林, 周健, 陈雪元, 等. 基于轻量化 GELAN 的多种类管道病害检测[J]. 市政技术, 2025, 43(2): 117-125. (CAO J L, ZHOU J, CHEN X Y, et al. Detection of various pipeline diseases based on lightweight GELAN[J]. Journal of municipal technology, 2025, 43(2): 117-125.)

随着城市规模不断扩大,城市地下管网规模也在不断扩展。城市排水管网如同城市的血管系统,是其长期健康发展的重要支撑和保障^[1]。自《长江保护与修复行动计划》和“十四五”规划发布以来,城市排水管网的建设与改造日益受到关注和重视^[2]。因此,深入了解并掌握排水管道的健康状况,确保并提升现有排水管道的运行效能至关重要。同时,对于存在病害的排水管道进行修复显得尤为关键和紧迫^[3]。

排水管道受结构恶化和环境变化的影响,不可避免会产生多种病害,如破裂、错口、沉积和障碍物等^[4-5]。为了延长排水管道的使用寿命,对排水管道进行病害检测和状态评估至关重要,这有助于全面了解我国城市排水管道系统现状。

传统排水管道病害检测通常使用闭路电视(CCTV)采集图像数据^[6],并依赖人工识别管道病害。然而,这一过程耗时且费力。同时,人工识别的主观性容易导致错检和漏检,降低检测准确性。为了克服这些问题,提升排水管道病害检测自动化水平,研究者们开始将传统图像处理技术引入排水管道病害检测领域。

Dong 等^[7]在其研究中利用支持向量机(SVM)构建了多类别分类器模型,通过提取管道焊缝图像中的灰度差、等效面积和圆度等参数,建立了特征数据库,并成功地使用多类别支持向量机(MSVM)分类器实现了 90%的焊接缺陷识别准确率。Hawari 等^[8]使用形态学处理、Gabor 滤波和椭圆拟合算法来检测管道中的裂纹、变形和沉积物,平均准确率达到 75%。黄玉龙^[9]结合形态学处理、开放顶帽算法和 MSER(最大稳定极值区域)算法来提取天然气管道中的间隙和裂纹位置,取得了 61.5%的间隙检测分割准确率和 86.7%的裂纹检测分割准确率。然而,传统的图像处理方法存在一些限制,通常难以识别和利用图像中的高层次特征,导致可能无法有效地处理复杂的管道场景。为了克服这些挑战,研究者们正在探索更先进的计算机视觉和深度学习技术,以提高管道病害检测的准确性和效率。

随着深度学习技术的不断进步,一系列基于深度学习的目标检测算法已经广泛应用于管道病害检测研究中。Wang 等^[10]采用 Faster R-CNN 网络成功检测和识别出排水管道中的 6 种病害,其平均准确率达到 88.99%。Li 等^[11]为排水管道病害检测提出了一种新的两阶段目标检测算法,其通过多层全

局特征融合技术实现了 50.8%的 mAP 值。另外,陆绮荣等^[12]利用 StyleGAN2 对原始图像进行预处理,并对 YOLOX 的特征融合层进行改进,同时将损失函数调整为 CIoU,在识别 5 种类型的病害时取得了显著的 mAP 值(其值达到了 68.76%)。冯丽丹等^[13]将轻量化网络 MobileNetv3 和 YOLOv7 相结合,通过增加 BiFPN 特征金字塔结构来提高精确度,并在数据处理方面通过 Mosaic 数据增强方式提高该模型的鲁棒性,该模型在减少参数计算量的基础上提高了平均准确率。这些研究成果表明,计算机视觉和深度学习技术在管道病害检测领域已经取得了一定进展。然而,仍存在一些局限性,如病害识别种类有限、准确率不高以及检测速度较慢等。

近期,YOLOv9^[14]基于梯度路径规划设计了一种新的轻量级网络——广义高效层聚合网络(Generalized Efficient Layer Aggregation Network, GELAN)。笔者以 GELAN 框架为基准,针对排水管道病害检测开发了改进的 GELAN 模型。

1 GELAN 模型改进方案

1.1 GELAN 框架

YOLOv9 中的 GELAN 是基于 ELAN (Efficient Layer Aggregation Network) 和 CSPNet (Cross Stage Partial Network) 的设计。GELAN 的设计考虑了多个关键因素,包括参数量、计算复杂性、准确性和推理速度,旨在实现轻量级、快速和准确的目标检测。GELAN 的核心在于它的模块化设计,它允许网络根据不同的计算需求和资源限制灵活地调整其结构。这种设计使得 GELAN 既可以应用于计算资源受限的轻量级模型,也可以扩展到需要更高准确性的复杂模型。通过精心设计的梯度路径,GELAN 优化了网络中信息的流动,减少了信息在网络传递过程中的损失。GELAN 的另一个创新之处在于它对标准卷积操作的改进。通过使用 CSPNet 中的 Cross Stage Partial Network 结构,GELAN 能够在网络的不同阶段有效地聚合特征,增强了特征的表达能力。这种特征聚合机制不仅提高了模型对目标的检测能力,还提升了模型对不同尺度和形状目标的泛化能力。CSPNet、ELAN、GELAN 框架对比如图 1 所示。

1.2 改进的 GELAN 框架

改进的 GELAN 框架如图 2 所示。首先,参考 YOLOv8n 模型,通过减少深度因子 depth_multiple 和

表 1 模型参数量和计算量对比

Tab. 1 A comparison of model parameters and computational amount

项目	YOLOv3-Tiny	YOLOv5n	YOLOv7-Tiny	YOLOv8n	GELAN	轻量化 GELAN
参数量	12.1	1.9	6.0	3.0	31.3	2.2
计算量	18.9	4.5	13.2	8.1	117.5	8.4

1.4 深度可分离卷积

卷积在传统卷积神经网络中扮演着关键角色,其通过多层卷积有效地提取图像特征信息,并将这些特征信息传递至分类层进行图像分类。Sandler 等^[17]提出了深度可分离卷积以替代标准卷积,其参数量大幅减少。深度可分离卷积由深度卷积(DWConv)和逐点卷积(PWConv)2种主要结构组成,DWConv和PWConv均在一定程度上减少了模型参数量。PWConv仅采用 1×1 卷积核,而DWConv则适用于各种尺寸的卷积核,因此更加通用。

如图3所示,深度卷积与标准卷积操作不同。在深度卷积中,每个卷积核只处理1个输入通道,因此每个卷积核仅有1个维度。卷积核的数量必须与输入通道数相等,而输出通道数等于输入通道数。因此,深度卷积仅影响特征图的大小,而不改变通道数。该卷积操作独立地对输入层的每个通道进行卷积运算,无法有效地利用同一空间位置上不同通道的特征信息。深度卷积与标准卷积的参数计算公式如式(1)、(2)所示:

$$D_{\text{DWConv}} = K \times K \times C; \quad (1)$$

$$D_{\text{standard}} = K \times K \times C \times C. \quad (2)$$

式中: K 为卷积核大小; C 为输入、输出特征图通道数。通过比较式(1)和式(2)可以看出,与标准卷积相比,DWConv能够显著减少参数量,减少了 C 倍。在模型的后半部分,特征图的数量通常超过100。通过使用深度卷积替代标准卷积,可以大幅减少参数量,从而减少模型的计算负载,加快模型运行速度,提高运算效率。

1.5 DySample 上采样模块

DySample被设计为一种超轻量级且高效的动态上采样器,旨在增强对低分辨率图像或较小目标的检测能力。初始版本的动态上采样器如图4a)所示。在最初的动态上采样过程中,输入图像 X 中的每个点的 s^2 个采样位置都固定在同一个初始位置,如图5a)所示。这种初始化方法忽略了相邻点之间的位置关系,当生成的偏移量全为0时,上采样特征等同于网络内插特征。为了解决这个问题,DySample

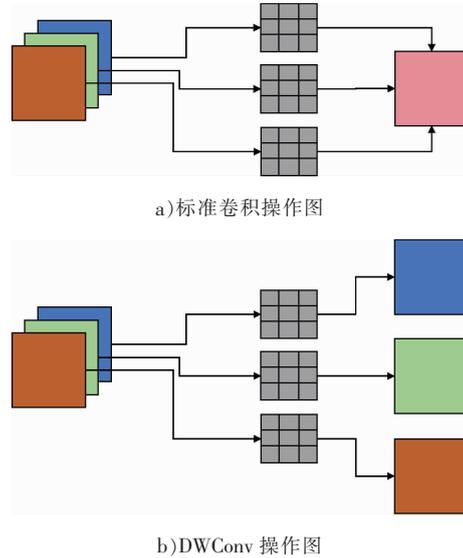


图3 标准卷积与深度卷积操作图

Fig. 3 Operation diagram of standard convolution and depth convolution

将初始采样位置改为图5b)中的“双线性初始化”,这样零偏移将产生双线性插值特征映射。为了减少归一化层可能导致的局部采样位置重叠,DySample将偏移量乘以0.25,恰好满足重叠和非重叠情况的理论边界条件,如图5c)所示。

DySample引入了分组上采样的概念,这意味着特征映射在通道维度上被分成了 g 组,并且每组共享相同的采样集合。具体而言,特征映射被划分为 g 组,并为每组生成对应的偏移量集合。为了增加偏移量的灵活性,DySample通过线性投影输入特征来生成逐点的“动态范围因子”。这个操作如图4b)所示,它使用线性投影来生成 s^2 个偏移集合,然后对这些集合进行重塑,以适应所需的空间大小。通过分组上采样和动态范围因子的引入,DySample能够更有效地处理不同分辨率的输入图像或小目标,增强检测能力并提高上采样的精度和效率。

2 实验方法

2.1 数据集

在CJJ 181—2012《城镇排水管道检测与评估技

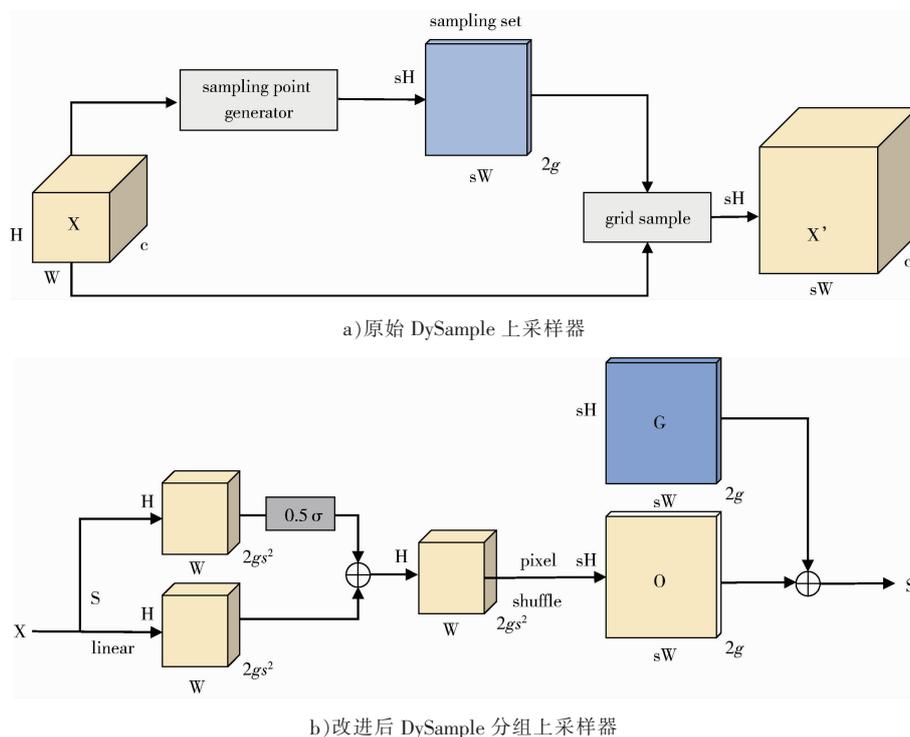


图 4 DySample 中基于采样的动态上采样和模块设计

Fig. 4 Dynamic upsampling and module design based on sampling in DySample

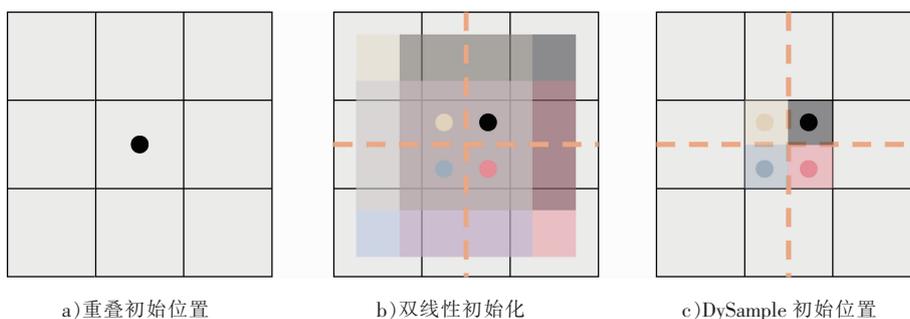


图 5 初始取样位置和偏移范围

Fig. 5 Initial sampling positions and offset ranges

术规程》中,排水管道缺陷被分为破裂、变形、沉积等 16 种功能性和结构性缺陷。笔者选取了 7 种常见的排水管道缺陷进行研究,包括裂缝(Crack)、变形(Defomation)、沉积物(Settled Deposits)、异物穿透(Foreign Object Penetration)、错位接头(Displaced Joint)、根系侵入(Roots)和断裂(Break)。将 CCTV 检测系统从无锡市区收集的排水管道视频数据作为网络训练数据来源,并将其转换为图像数据,进一步通过人工筛选,保留包含缺陷的图片作为模型训练的数据集。为了在训练过程中更真实地模拟实际情况,对训练数据进行了增强处理,具体措施包括镜像、裁剪、对比度调整等,以扩充不同病害类型的

样本数量,从而构建一个包含各类排水管道病害的数量均衡的数据集。数据增强后,该数据集共包含 6176 张排水管道样本图像,涵盖了 7 种不同的管道病害类型。在使用数据集之前,采用 LabelImg 软件对数据集中的图像进行了分类标注。图 6 展示了部分包含在该数据集中的管道病害样本图像。

2.2 实验设置

模型使用 PyTorch 深度学习框架来训练和测试。硬件测试环境处理器选用 Intel 的 i7-13700KF 的 CPU,16 G 运行内存;GPU 选用 NVIDIA 的 RTX 4090,24 G 显存。模型在训练过程中将迭代次数设置为 300,batch-size 设置为 16,初始学习率为 0.01。



图 6 管道病害样本图像

Fig. 6 Sample image of pipeline diseases

2.3 模型评价

该研究采用精确率(Precision)、召回率(Recall)、mAP、F1 分数、参数量、GFLOPs 来评价模型对排水管道病害的识别性能和效率。

精确率(用 P 表示)是对目标预测是否准确的判断标准,表示为正确被检测目标占有所有被检测到目标的比例。计算式为:

$$P(\%) = \frac{TP}{TP+FP} \times 100. \quad (3)$$

召回率(用 R 表示)是对实际目标是否全部被检测到的评价,反映了正确被检测目标在总实际目标中所占的比例。计算式为:

$$R(\%) = \frac{TP}{TP+FN} \times 100. \quad (4)$$

式中: TP 代表真阳性,是模型预测为阳性的阳性样本; FP 代表假阳性,是模型预测为阳性的阴性样本; FN 代表假阴性,是模型预测为阴性的阳性样本。

mAP(mean Average Precision)在目标检测中是衡量检测精度的指标,计算式为:

$$mAP = \int_0^1 P(R) dR. \quad (5)$$

AP 即平均精度,通过 $P-R$ 曲线积分得到各个类别的 AP 值,然后对所有类别的 AP 值求平均即为 mAP。

F1 分数综合考虑了模型的精确率和召回率,是精确率和召回率的调和平均数,其最大值为 1,最小值为 0,其值越大越好。计算式为:

$$F1 \text{ 分数} = 2 \times \frac{P \times R}{P + R}. \quad (6)$$

通常,模型的复杂度可以通过参数量和 GFLOPs 进行衡量。FLOPs 表示在同一模型中执行的浮点运算数量,GFLOPs 则等于 FLOPs 乘以 10^9 。

3 实验结果与分析

3.1 消融实验

为验证各模块改进对 GELAN 模型识别精度的影响,该研究在排水管道病害数据集上进行了消融实验,结果见表 2。

表 2 消融实验结果

Tab. 2 Ablation experiment results

模型	轻量化	引入 DWConv 模块	引入 DySample 模块	精确率/%	召回率/%	F1 分数	mAP@0.5%	参数量/M	GFLOPs
				94.6	90.5	0.925	94.1	31.3	117.5
	√			93.9	88.5	0.911	93.5	2.2	8.4
GELAN	√	√		94.6	89.6	0.920	94.1	1.9	7.0
	√		√	95.0	90.4	0.926	94.2	2.3	8.3
	√	√	√	96.5	89.6	0.929	94.5	2.0	7.0

从表 2 可以看出,对 GELAN 模型结构轻量化后,模型参数量和计算量分别减少了 92.97%和 92.85%,

模型 mAP 仅下降了 0.64%。为了提升模型检测精度,在轻量化后的 GELAN 模型结构上进一步引入了

DWConv 和 DySample 模块。其中,引入 DWConv 模块进一步减少了模型参数量和计算量,而引入 DySample 模块增加的模型参数量可以忽略不计。分别引入 DWConv 和 DySample 模块后,mAP 分别提升了 0.64% 和 0.75%,F1 分数分别提升了 0.99% 和 1.65%。最后,将 3 种改进策略结合起来的改进效果最佳,F1 分数提升了 0.43%,mAP 提升了 0.43%;同时,模型复杂度大大降低,其中参数量减少了 93.61%,计算量降低了 94.04%,进一步验证了改进方案的可行性。模型改进前后 mAP 对比如图 7 所示。

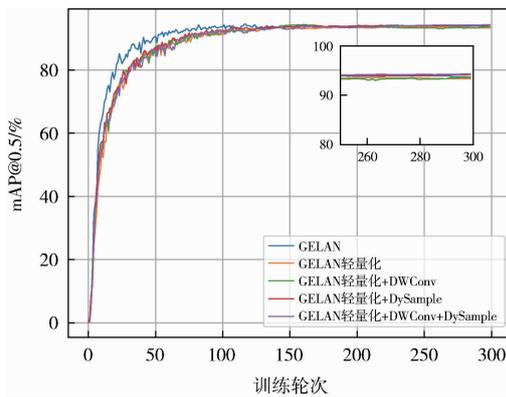


图 7 模型改进前后 mAP 对比

Fig. 7 Comparison of mAP before and after the model improvement

从图 7 可以看出,在前 150 轮次训练中,原始 GELAN 模型能够更快达到较高 mAP 值,但模型性能趋于平稳后,各改进部分与原始 GELAN 模型相比具有相对更高的 mAP 值,且最终所提模型(即改进的 GELAN 模型)具有最高的 mAP 值。

混淆矩阵是评估分类模型性能的重要工具。它以矩阵的形式直观地呈现模型对样本的分类结果,从而帮助我们分析模型在各个类别上的表现。笔者采用改进的 GELAN 算法生成了排水管道病害的混淆矩阵,如图 8 所示。其中对角线反映了正确预测的比例;深色区域表示高正确预测率,而浅色区域则显示了错误分类的情况。

从图 8 可以看出,大多数目标得到了准确预测,这表明改进的 GELAN 模型具有较高的准确性。

3.2 对比实验

为了进一步评价改进的 GELAN 模型的性能,将其与常见的目标检测模型在排水管道病害数据集上训练后的实验结果进行了对比,如表 3 所示。

从表 3 可以看出,改进的 GELAN 模型在排水管

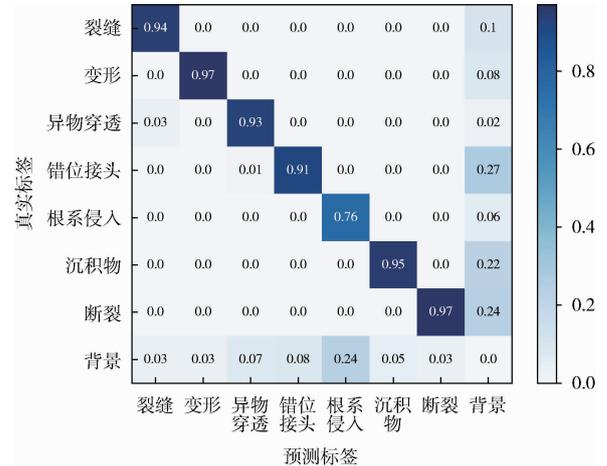


图 8 混淆矩阵

Fig. 8 Confusion matrix

表 3 模型对比实验结果

Tab. 3 Comparison results of different models

模型	精确率/ %	召回率/ %	F1 分数	mAP@ 0.5/%	参数量/ M	GFLOPs
YOLOv8n	94.6	87.5	0.910	92.4	3.0	8.1
YOLOv5n	92.5	88.8	0.906	93.1	1.9	4.5
YOLOv3-Tiny	95.2	88.2	0.916	92.6	12.1	18.9
GELAN	94.6	90.5	0.925	94.1	31.3	117.5
RT-DETR-L	95.6	89.7	0.925	91.7	24.5	67.2
RT-DETR-X	96.0	87.9	0.918	90.1	65.5	222.5
RT-DETR-SPD	94.7	88.8	0.916	90.7	30.8	80.6
Retinanet	95.2	89.2	0.921	93.3	36.4	82.3
SSD	94.2	88.3	0.912	91.3	24.1	137.2
Faster_RCNN	86.3	97.1	0.914	93.1	41.1	193.8
Spare_RCNN	87.5	97.6	0.923	92.8	105.9	149.9
Dynamic_RCNN	86.6	98.0	0.920	93.1	41.2	193.8
改进的 GELAN	96.5	89.6	0.929	94.5	2.0	7.0

道病害的识别上效果最优,其 F1 分数为 0.929,mAP 为 94.5%,参数量为 2.0M,GFLOPs 为 7.0。与常见的单阶段目标检测模型相比,该模型的复杂度与 YOLOv5n 和 YOLOv8n 相当,且 F1 分数分别提高了 2.54% 和 2.09%,mAP 分别提高了 1.50% 和 2.27%。与 Retinanet 模型相比,mAP 提高了 1.29%,且参数量仅为 Retinanet 的 5.50%,计算量仅为 Retinanet 的 8.51%。与 SSD 模型相比,F1 分数提高了 1.86%,mAP 提高了 3.50%,参数量和计算量仅分别为 SSD 的 8.30% 和 5.10%。与双阶段 RCNN 系列模型相比,该模型的参数量和计算量远低于双阶段目标检测模型;同时,该模型仍然表现出最高的 mAP 值和 F1 分

数。尽管 RCNN 系列模型的召回率较高,但综合考虑了准确率和召回率的 F1 分数更能全面评估模型在正类和负类预测方面的表现。另外,与基于 Transformer 的 RT-DETR 系列模型相比,该模型仍然具有最高

的 F1 分数和 mAP 值,且计算复杂度和参数量更低。

图 9 展示了不同模型的管道病害检测结果,可见笔者提出的改进的 GELAN 模型在相同条件下检测置信度最高,并且预测框定位更加精确。

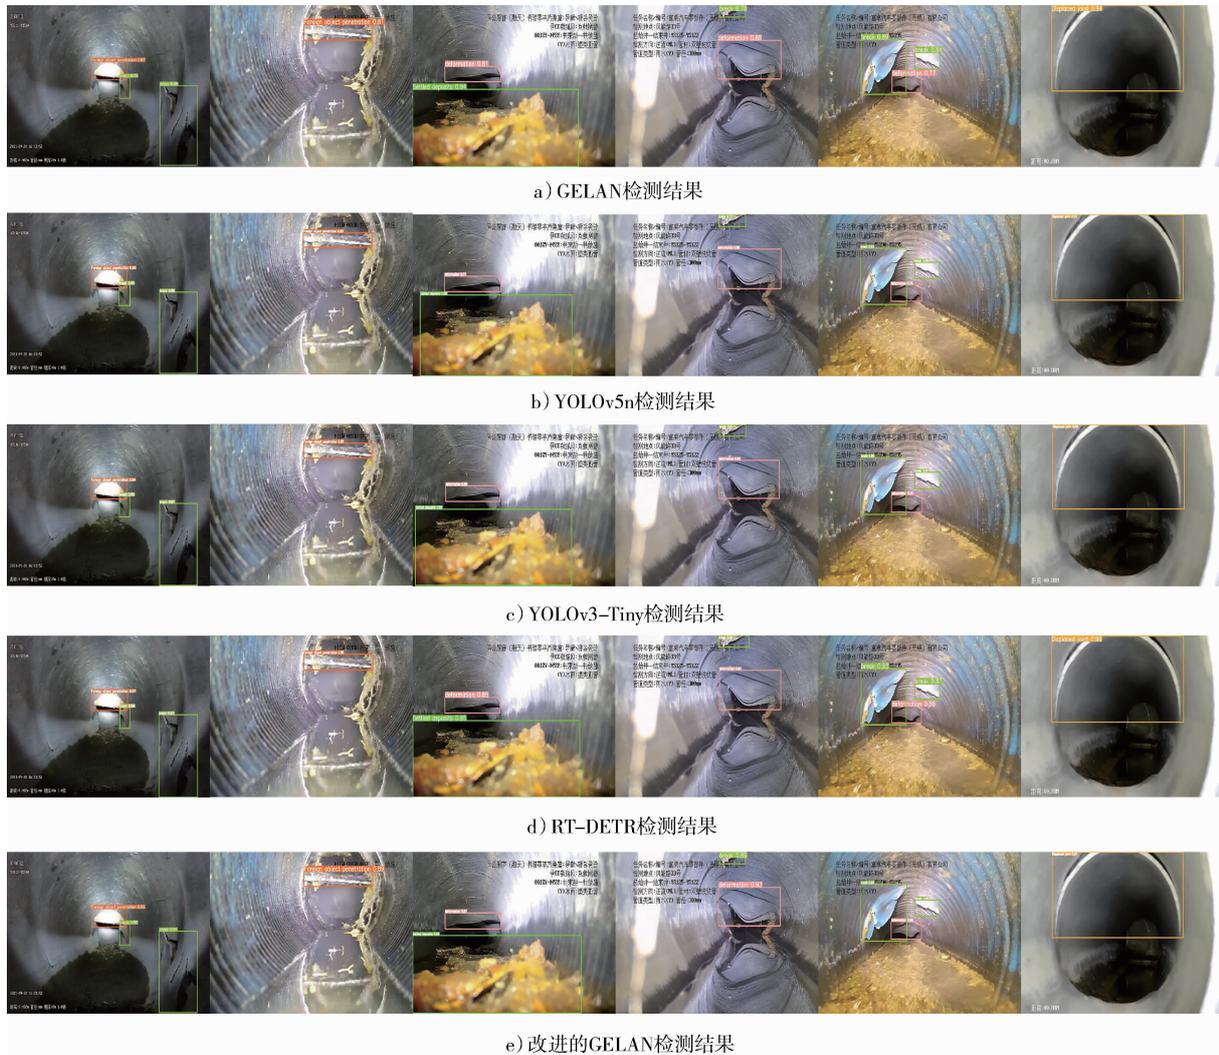


图 9 不同模型管道病害检测结果

Fig. 9 Pipeline diseases detection results of different models

4 结 语

笔者对 GELAN 模型进行了结构轻量化的研究。通过减少深度因子和宽度因子对 GELAN 模型结构进行轻量化,并将网络主干中的标准卷积替换为深度卷积 DWConv,进一步减少了模型的参数量和计算量。此外,通过引入 DySample 上采样模块,使得网络更好地捕捉病害的细节和特征。实验结果表明,无论在计算量还是精度方面,改进的 GELAN 模型的效果都比较好。改进的 GELAN 模型参数量和计算

量比 GELAN 模型分别减少了 92.97% 和 92.85%,检测平均精度达到了 94.5%,可以满足轻便型移动设备的检测要求,具有一定的实用性和应用价值。在未来的研究中,计划进一步增加排水管道样本的数量和类型,以提高模型的准确率,并使其更好地适应实际工程需求。

[参考文献]

- [1] 李若晗. 城市污水管道检测、评价与影响因素研究[D]. 北京: 清华大学, 2016. (LI R H. A study of urban sewer inspection, as-

- essment and related factors[D]. Beijing: Tsinghua University, 2016.)
- [2] HUANG R M, TAO Z K, LIN Y C, et al. Current situation of drainage pipe network in China and its detection technology: a brief review[J]. Polish journal of environmental studies, 2024, 33(1): 19-29.
- [3] 钊童辉, 宋凯. CCTV 检测在排水管道检测中的应用与研究[J]. 城市勘测, 2023(Sup1): 67-71. (ZHAO T H, SONG K. Application and research of CCTV inspection in drainage pipe detection [J]. Urban geotechnical investigation & surveying, 2023(Sup1): 67-71.)
- [4] HUANG F, WANG N N, FANG H Y, et al. Research on 3D defect information management of drainage pipeline based on BIM [J]. Buildings, 2022, 12(2): 228.
- [5] LIU X C, ZHANG H F, SONG X M, et al. Monitoring and analysis of the current situation of the drainage network in a city of northern China[J]. IOP conference series: earth and environmental science, 2018, 186(6): 012033.
- [6] 李田, 郑瑞东, 朱军. 排水管道检测技术的发展现状[J]. 中国给水排水, 2006, 22(12): 11-13. (LI T, ZHENG R D, ZHU J. Development of sewer inspection and assessment technologie [J]. China water & wastewater, 2006, 22(12): 11-13.)
- [7] DONG S H, SUN X, XIE S Y, et al. Automatic defect identification technology of digital image of pipeline weld[J]. Natural gas industry B, 2019, 6(4): 399-403.
- [8] HAWARI A, ALAMIN M, ALKADOUR F, et al. Automated defect detection tool for closed circuit television (CCTV) inspected sewer pipelines[J]. Automation in construction, 2018, 89: 99-109.
- [9] 黄玉龙. 基于视频图像的管道裂纹缺陷检测方法研究[D]. 西安: 西安理工大学, 2018. (HUANG Y L. Research on pipeline crack detection based on video image[D]. Xi'an: Xi'an University of Technology, 2018.)
- [10] WANG M Z, 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.
- [11] LI D W, XIE Q, YU Z H, et al. Sewer pipe defect detection via deep learning with local and global feature fusion[J]. Automation in construction, 2021, 129: 103823.
- [12] 陆绮荣, 丁昕, 梁雅雯. 基于改进 YOLOX 的地下排水管道缺陷识别算法[J]. 电子测量技术, 2022, 45(21): 161-168. (LU Q R, DING X, LIANG Y W. A defect recognition method of the underground drainage pipe based on improved YOLOX algorithm [J]. Electronic measurement technology, 2022, 45(21): 161-168.)
- [13] 冯丽丹, 王闯, 祁军, 等. 基于改进 YOLOv7 的管道缺陷检测技术研究[J]. 辽宁石油化工大学学报, 2024, 44(4): 82-90. (FENG L D, WANG C, QI J, et al. Research on pipeline defect detection technology based on improved YOLOv7[J]. Journal of Liaoning Petrochemical University, 2024, 44(4): 82-90.)
- [14] WANG C Y, YE H I H, LIAO H Y M. Yolov9: learning what you want to learn using programmable gradient information[J]. Arxiv preprint arxiv, 2024: 13616.
- [15] LIU W Z, LU H, FU H T, et al. Learning to upsample by learning to sample[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2023: 6027-6037.
- [16] LI Y J, MA C Y, LI L P, et al. Lightweight tunnel obstacle detection based on improved YOLOv5[J]. Sensors, 2024, 24(2): 395.
- [17] SANDLER M, HOWARD A, ZHU M L, et al. MobileNetV2: inverted residuals and linear bottlenecks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510-4520.

其他作者: 周健, 男, 高级工程师, 学士, 主要从事工程物探、地质原位测试、工程检测等工作。
 陈雪元, 男, 高级工程师, 学士, 主要从事工程物探、地质原位测试等工作。
 张志刚, 男, 高级工程师, 学士, 主要从事岩土工程、地质勘探等工作。
 朱仁民, 男, 高级工程师, 学士, 主要从事岩土工程、地质勘探等工作。
 唐强, 男, 教授, 博士, 主要研究方向为智能检测、环境岩土。

(上接第 116 页)

- cleaning technology on small diameter ductile iron water supply pipeline[J]. China water & wastewater, 2021, 37(3): 69-73.)
- [17] 苏新军, 张修刚, 王栋, 等. 水平管路中多相弹流压力降计算[J]. 油气储运, 2004, 23(10): 8-12. (SU X J, ZHANG X G, WANG D, et al. Pressure loss calculation of multiphase slug flow in horizontal pipeline[J]. Oil & gas storage and transportation, 2004, 23(10): 8-12.)
- [18] 范力杰, 郭金鹏, 王仕豪, 等. 现有供水管道冰浆冲洗技术应用案例分析与探讨[J]. 净水技术, 2024, 43(6): 204-209. (FAN L J, GUO J P, WANG S H, et al. Application case analysis and discussion of ice slurry flushing technology for existing water supply pipelines[J]. Water purification technology, 2024, 43(6): 204-209.)
- [19] 芮文江. 基于实验的管道冰浆清洗效果研究[D]. 北京: 中国石油大学, 2018. (RUI W J. Research on the cleaning effect of pipeline slurry based on experiments[D]. Beijing: China University of Petroleum, 2018.)
- [20] 杨坤. 气水脉冲清洗给水管道的两相流过程研究及其数值模拟[D]. 哈尔滨: 哈尔滨工业大学, 2014. (YANG K. Two-phase flow reserach and numerical simulation of air-water pulse cleaning process for water distribution pipe[D]. Harbin: Harbin Institute of Technology, 2014.)

其他作者: 张东, 男, 正高级工程师, 博士, 主要从事饮用水安全保障及管理研究工作。