

基于改进YOLOv8s的排水管道缺陷检测算法

吴德华¹, 陈礼洪^{1,2}, 黄淑萍¹, 马世斌³

(1. 福建理工大学生态环境与城市建设学院; 2. 福建省水污染阻控与系统智能技术工程研究中心, 福建 福州 350118;
3. 福建省融旗建设工程有限公司, 福建 福州 350300)

摘要: 针对城市排水管道缺陷检测算法参数量和计算量大、管道内部环境复杂导致缺陷检测困难的问题, 提出一种基于改进YOLOv8s的排水管道缺陷检测算法。首先, 使用MobileNetV3特征提取网络作为主干, 并引入ECA注意力模块改进倒残差结构, 增强了模型的特征提取能力; 其次, 利用Slim-Neck架构改进原有颈部结构, 进一步提高了网络的轻量化水平; 最后, 结合自适应空间特征融合方式改进检测头, 有效过滤冲突信息, 增强了尺度不变性。实验结果表明, 与原始YOLOv8s模型相比, 改进后的YOLOv8s模型在管道缺陷数据集上的mAP@0.5、mAP@50:95分别提升了4.7%、3.6%, 整体性能有所提高。

关键词: YOLOv8s; 排水管道; 缺陷检测; 目标识别; 注意力模块

DOI: 10.11907/rjtk.241860

中图分类号: TP391

文献标识码: A

文章编号: 1672-7800(2026)001-0166-06

扫描二维码阅读全文:



Improved Drainage Pipe Defect Detection Algorithm Based on YOLOv8s

WU Dehua¹, CHEN Lihong^{1,2}, HUANG Shuping¹, MA Shibin³

(1. College of Ecological Environment and Urban Construction, Fujian University of Science and Technology;

2. Fujian Engineering Research Center of Water Pollution Control and System Intelligence Technology, Fuzhou 350118, China;

3. Fujian Rongqi Construction Engineering Co., LTD., Fuzhou 350300, China)

Abstract: A drainage pipeline defect detection algorithm based on improved YOLOv8s is proposed to address the problem of large parameter and computational complexity in urban drainage pipeline defect detection algorithms, as well as the difficulty of defect detection caused by the complex internal environment of pipelines. The algorithm first uses the MobileNetV3 feature extraction network as the backbone and introduces an ECA attention module to improve the inverse residual structure, enhancing the model's feature extraction ability; Secondly, utilizing the Slim Neck architecture to improve the original neck structure further enhances the lightweight level of the network; Finally, by combining adaptive spatial feature fusion, the detection head is improved to effectively filter out conflicting information and enhance scale invariance. The experimental results show that compared with the original YOLOv8s model, the improved YOLOv8s model performs better on the pipeline defect dataset, the mAP@0.5 and mAP@50:95 has improved by 4.7% and 3.6% respectively, indicating an overall improvement in performance.

Key Words: YOLOv8s; drainage pipe; defect detection; target recognition; attention mechanism

0 引言

排水管道是城市关键基础设施, 但受多种因素影响, 内部易出现裂纹、漏水、堵塞等缺陷, 若未及时检测修复, 将威胁城市运行与安全, 故及时精准检测缺陷至关重要^[1]。管道检测机器人技术因直观高效等优势, 成为当前

主流检测手段^[2]。然而, 管道内光照、水流、杂物等复杂环境干扰大, 技术人员在运用算法进行缺陷识别时常面临精度与速度难以兼顾的挑战。

随着人工智能技术的不断发展, 基于深度学习的排水管道缺陷检测算法逐渐得到应用。例如, 彭述刚等^[3]提出基于改进卷积神经网络的IM-CNN算法, 设计了面向管道识别的改进特征融合策略及新的目标函数。李广超等^[4]

收稿日期: 2024-10-10

基金项目: 福建理工大学—福建省融旗建设工程有限公司产学研项目横向课题(GY-H-23249)

作者简介: 吴德华(2000-), 男, 福建理工大学生态环境与城市建设学院硕士研究生, 研究方向为给排水系统智能化; 陈礼洪(1969-), 男, 硕士, 福建理工大学生态环境与城市建设学院教授、硕士生导师, 研究方向为给排水系统安全与节能技术。本文通讯作者: 陈礼洪。

提出基于 ResNet 模型的排水管道缺陷内窥检测智能识别算法 Pipe ResNet。王庆等^[5]提出一种基于 K-means 聚类改进的 Faster R-CNN 排水管道缺陷检测模型。何嘉林等^[6]提出一种基于随机森林与贝叶斯优化算法的排水管道缺陷检测算法。娄爱涛^[7]结合无人机平台和红外检测技术,使用 Efficient Net 改进 YOLOv3 管道缺陷算法。韩崔燕等^[8]构建了基于 YOLOv5s 的排水管道缺陷识别模型,对 10 种常见的排水管道缺陷进行检测。

以上算法虽然在原有网络的基础上进行了一定改进和创新,但大多只考虑了精度提升,忽略了与模型参数量和计算量之间的平衡,不利于排水管道检测任务中边缘设备的部署。为解决上述目标检测网络存在的问题,本文以 YOLOv8s 算法为基础,融合 MobileNetV3 轻量化网络作为其主干,并通过 ECA(Efficient Channel Attention)模块改进其倒残差结构,同时引入 Slim-Neck 架构以及自适应空间特征融合(Adaptively Spatial Feature Fusion, ASFF)策略,最终降低了模型的计算负担,提高了检测性能和效率^[9-12]。

1 模型构建

YOLOv8 是一种高效的目标检测模型,是 YOLO 系列的最新版本之一^[13-15]。与传统的目标检测方法相比,YOLOv8 采用单阶段检测器,通过一次前向传播便可以同时预测出图像中所有目标的边界框和类别概率,在保持较高检测速度的同时具备较高的准确性。YOLOv8 模型分为主干网络(Backbone)、颈部网络(Neck)和检测头(Head)3 个关键模块。主干网络负责提取输入图像的特征信息,以确保对目标进行准确描述;颈部网络用于进一步整合和增强特征表示,核心结构融合了特征金字塔网络(Feature Pyramid Networks, FPN)的改进版本(如 BiFPN 或 PAN-FPN)以及残差连接等机制;检测头则负责输出目标检测结果,包括目标的位置、类别以及置信度等信息。YOLOv8 包含多个版本,如 YOLOv8n、YOLOv8s、YOLOv8m、YOLOv8l、YOLOv8x,这些版本通过调整模型参数数量和计算量来平衡精度与推理速度。其中,YOLOv8s 是 YOLOv8 系列的 small 类别,主要针对资源受限环境或需要快速推理的场景设计^[16-17]。因此,本文选取该版本进行改进。

1.1 基于 Mobilenetv3 的主干网络改进

MobileNetV3 在倒残差结构中引入 SE(Squeeze-and-Excitation)注意力模块,通过动态调整通道权重增强特征表达能力;同时,结合硬件感知的神经架构搜索技术自动优化网络结构,使其在特定硬件平台上实现更高的效率和性能^[18]。具体来说,倒残差结构首先通过一个逐点卷积操作来增加通道数;其次使用深度卷积处理每个通道的特征;最后通过一个逐点卷积将通道数降回至原始数量,用于恢复原始特征维度。结构如图 1 所示。为提高模型的稳定性以及量化时的有效性,倒残差结构使用 ReLU6 作为

激活函数,用于防止激活值过大或过小,在低精度计算中表现优异。同时,MobileNetV3 使用 h-swish 函数替换 swish 函数,用于减少计算开销。h-swish 函数的计算公式为:

$$h-swish[x] = x \frac{ReLU6(x+3)}{6} \quad (1)$$




Fig. 1 Inverted residuals structure

图 1 倒残差结构

为了在增加检测精度的同时保证模型的实时性,MobileNetV3 中引入 SE 注意力模块,放置于深度可分离卷积层之后,并将维度拓展层的通道数变为原来的 1/4。该模块虽然使用降维操作降低了模型复杂性,但通道与其权值的对应关系也因此被破坏。同时,捕获所有通道之间的注意力权重关系所带来的计算成本与取得的效果之间是不对等的。为此,本文引入轻量化注意力模块 ECA(Efficient Channel Attention),替换原有的 SE 注意力模块^[10]。该模块结构如图 2 所示。首先,输入的特征图首先被映射到通道维度进行比较,通过平均池化操作对每个通道的特征值求平均,以获得通道的全局信息;其次,应用一维卷积计算每个通道的注意力权重来捕捉通道间的依赖关系;最后,使用计算得到的通道注意力权重对原始特征图进行加权融合,得到最终输出结果。与 SE 模块相比,ECA 模块使用一维卷积来实现通道之间的注意力机制,而不是全连接层,这种设计大大减少了计算复杂度和参数量,在资源受限的环境中更为适用。




Fig. 2 ECA module structure

图 2 ECA 模块结构

1.2 基于 Slim-Neck 架构的颈部结构改进

原始 YOLOv8s 网络在特征提取过程中将空间特征转化为通道特征,每次进行空间缩减和通道增加时都可能会

间信息融合在一起,使最终的特征图不仅保留了各个输入特征图的有效信息,而且通过自适应机制提升了特征表示的丰富性和准确性。ASFF模块涉及的计算公式为:

$$y_{ij}^l = \alpha_{ij}^l \cdot x_{ij}^{1 \rightarrow l} + \beta_{ij}^l \cdot x_{ij}^{2 \rightarrow l} + \gamma_{ij}^l \cdot x_{ij}^{3 \rightarrow l} \quad (2)$$

式中: y_{ij}^l 为第*i*个尺度的输出特征图; $\alpha_{ij}^l, \beta_{ij}^l, \gamma_{ij}^l$ 为3个权值; $x_{ij}^{1 \rightarrow l}, x_{ij}^{2 \rightarrow l}, x_{ij}^{3 \rightarrow l}$ 为3个尺度的输入特征图; α, β, γ 的关系为:

$$\alpha^l + \beta^l + \gamma^l = 1 \quad (3)$$

以 α_{ij}^l 为例,其计算公式为:

$$\alpha_{ij}^l = \frac{e^{\lambda_{\alpha_{ij}}^l}}{e^{\lambda_{\alpha_{ij}}^l} + e^{\lambda_{\beta_{ij}}^l} + e^{\lambda_{\gamma_{ij}}^l}} \quad (4)$$

式中: $\lambda_{\alpha_{ij}}^l, \lambda_{\beta_{ij}}^l, \lambda_{\gamma_{ij}}^l$ 由1×1卷积得到。

2 实验方法与结果分析

2.1 实验环境与参数设置

本文实验训练平台使用 Windows 11 操作系统, CPU 为 Intel Core (TM) i5-12450H@2.00 GHz, GPU 为 NVIDIA GeForce RTX 4060。深度学习框架 Pytorch 版本为 1.12.1, 使用 CUDA 11.8 版本加速训练。输入图片尺寸大小为 640×640, 批次大小为 16, 初始学习率大小为 0.01, 动量大小为 0.937, 优化器采用 SGD, 共训练 250 轮次。

本文模型训练使用的损失函数包括边界框回归损失 (Box Regression Loss)、置信度损失 (Confidence Loss) 和分类损失 (Classification Loss) 3 个部分, 分别用于优化模型的检测位置精度、预测目标置信度和类别概率。边界框回归损失使用完全交并比损失 (CIoU Loss) 来衡量预测框与真实框的差异。计算公式为:

$$CIoU = 1 - IoU + \frac{\rho^2(b, b^*)}{c^2} + \alpha v \quad (5)$$

式中: IoU 为预测框与真实框的交并比; $\rho^2(b, b^*)$ 为预测框与真实框中心点间的欧氏距离; c 为包含预测框和真实框的最小闭包框的对角线距离; v 用于预测框与真实框的长宽比一致性; α 为平衡项系数。

置信度损失和分类损失使用二元交叉熵损失 (BCE Loss) 来衡量预测框中目标存在的可能性。计算公式为:

$$BCE = -\sum_{i=1}^N [y_i \log(p_i) + (1 - y_i) \log(1 - p_i)] \quad (6)$$

式中: N 为总的预测目标数量; y_i 为真实标签; p_i 为模型预测概率。

2.2 数据集

采用来源于 Roboflow University 的管道缺陷检测数据集图像以及福州市管网项目中巡检机器人所收集的影像构建数据集, 比例为 8:2^[19]。该数据集包含 2 080 张图片以及所对应的标注信息, 分为附着沉积物、破裂、结垢、树根、沉降沉积物 5 类管道缺陷, 按照 8:2 的比例分为训练集和验证集。

2.3 评价指标

选取 mAP@0.5、mAP@50:95、浮点运算次数 (Giga Floating-point Operations Per Second, GFLOPs)、参数量 (Parameter) 作为模型评价指标。其中, mAP@0.5 表示在 IoU (Intersection over Union, 交并比) 阈值为 0.5 时所有类别平均精度 (Average Precision, AP) 的平均值。mAP@50:95 表示在 IoU 阈值从 0.5 到 0.95 (步长为 0.05) 的范围内计算每个 IoU 阈值下的 mAP 值, 然后对这些 mAP 值取平均。相关计算公式为:

$$AP = \int_0^1 PR dr \quad (7)$$

$$mAP = \frac{1}{N} \sum_{i=0}^{\pi} AP_i \quad (8)$$

式中: P 为精确率; R 为召回率。

2.4 比较实验


为验证本文模型的有效性, 与当前目标主流检测模型进行比较, 包括 Faster-RCNN^[20]、YOLOv5s、YOLOv8n、YOLOv7-tiny^[21]、YOLOv3s^[22]、YOLOv8m, 所有实验参数均相同。比较实验结果见表 1。可以看出, 本文模型在参数量、计算量和平均精度上有明显优势。Faster RCNN 和 YOLOv3s 的参数量和计算量较大, 不适合边缘设备部署和实时监测。YOLOv5s、YOLOv8n、YOLOv7-tiny 的参数量虽然较少, 但是精度指标与其他模型相差较大, 无法满足准确性需求。与 YOLOv8m 相比, 本文模型的参数量和计算量只有其 52.0% 和 32.6%, 但 mAP@0.5 和 mAP@50:95 分别提升了 2.1% 和 2.0%, 整体性能大幅提高。

Table 1 Comparative experimental results

表 1 比较实验结果


模型	mAP@0.5	mAP@50:95	参数量/M	GFLOPs
Faster RCNN	68.3	47.2	167.7	364.5
YOLOv5s	67.9	42.0	7.0	16.0
YOLOv8n	63.7	40.3	3.0	8.1
YOLOv7-tiny	54.9	29.8	6.0	13.2
YOLOv8m	69.4	47.0	25.8	79.1
YOLOv3s	68.5	48.2	208.0	283.9
本文模型	71.5	49.0	13.4	25.8

为比较本文模型与原始 YOLOv8s 模型的效果, 选取两组管道缺陷图像进行检测, 结果如图 8 所示。可以看出, 由于管道内部环境较为复杂、光线昏暗, 原始 YOLOv8s 模型难以准确检测目标缺陷, 例如第 1 组第 2 张、第 13 张图片中 (从左向右顺序) 的破裂现象, 以及第 2 组中第 3 张和第 9 张图片中的结垢现象均被漏检。此外, YOLOv8s 模型亦出现误检问题, 例如第 1 组第 11 张图片中将管道裂缝误判为树根; 第 2 组第 9 张图片中错误地将正常的墙体判定为附着沉积物。相比之下, 本文模型的漏检和误检现象大大减少, 能够准确识别出不同类型的缺陷, 整体检测精度超过原始 YOLOv8s。




(a) The first experiment of YOLOv8s

(a) YOLOv8s 第1组实验




(b) The first experiment of the proposed model

(b) 本文模型第1组实验



(c) The second experiment of YOLOv8s

(c) YOLOv8s 第2组实验



(d) The second experiment of the proposed model

(d) 本文模型第2组实验

Fig. 8 Comparison of detection performance between the proposed model and original YOLOv8s model

图8 本文模型与原始YOLOv8s模型检测效果比较

2.5 消融实验

为验证各改进模块的有效性,在实验参数相同的前提下,以YOLOv8s为基准模型设计消融实验。结果如表2所示。可以看出:A模型使用MobileNetV3网络替换YOLOv8s原有的主干网络后计算量和参数量分别减少了22.89%和6.30%,mAP@0.5和mAP@50:95分别提升了1.50%和0.90%,性能提升明显;B模型在A模型的基础上使用ECA模块改进了原有MobileNetV3网络中的SE模块,参数量和计算量分别减少14.42%和5.48%,精度也有略微提升,可见ECA机制比SE机制在特征提取中更有优势。C、D模型分别在MobileNetV3的基础上加入Slim Neck结构和ASFF-Head结构;在C组实验中,模型精度略微下降,但参数量和计算量大幅减少,分别降低了21.62%和34.50%,可见Slim-Neck中的GSCSP模块和VoV-GSCSP模块可以很好地融合不同尺度的特征,降低模型计算成本,提高检测效率;D组实验在检测头中融合ASFF后得到了2个变量下的最好精度结果,可见改进后的ASFF检测头结构提升了模型对于多尺度特征的感知和学习能力;E、F、G组在前4组的基础上进行了新的组合,其检测效果均能在原有改进的基础上再次得到提升;H组实验将4种改进同时加入到模型中(即本文模型),与原始YOLOv8s模型相比参数量仅增加了2.3 M,但计算量减少了9.1%,同时mAP@0.5、mAP@50:95分别提升了4.7%、3.6%,得到了最好的精度结果。

Table 2 Ablation experiment result
表 2 消融实验结果

消融模型	改进模块				mAP @0.5	mAP @50: 95	参数 量/M	GFLOFs
	MobileNetV3	ECA	Slim- Neck	ASFF				
YOLOv8s					66.8	46.6	11.1	28.4
A	√				68.3	46.9	10.4	21.9
B	√	√			68.5	47.9	8.9	20.7
C	√		√		67.3	46.4	8.7	18.6
D	√			√	68.7	46.0	15.8	30.3
E	√	√	√		68.0	46.0	8.0	17.4
F	√	√		√	68.7	46.8	14.3	29.1
G	√		√	√	67.9	46.7	15.0	27.0
H	√	√	√	√	71.5	49.0	13.4	25.8

3 结语

为提高排水管道缺陷检测任务的准确性,为排水管道模型边缘化部署提供参考,本文提出一种基于 YOLOv8s 的排水管道缺陷检测改进模型。该模型引入 MobileNetV3 轻量化网络作为骨干,设计了 MobileNetV3-ECA 模块改进原有网络中的倒残差结构,减少了模型的参数量和计算量,提高了检测精度。同时引入 Slim-Neck 架构改进原有颈部结构,通过 GS bottleneck 模块和 VoV-GSCSP 模块提高了模型的学习效率和特征处理能力;通过 ASFF 改进检测头增强了模型的多尺度感知和特征表达能力。实验结果显示,所提模型的参数量和计算量均不足 YOLOv8m 模型的 50%,但检测精度却有所提升,满足了资源受限条件下排水管网缺陷检测任务的需求,具备一定的工程意义。然而,本研究存在数据集规模较小、缺陷类型覆盖有限以及实际工程环境长期验证缺乏等问题,未来应扩大数据收集范围、增加缺陷类型覆盖面,并结合多模态传感器与自适应算法进一步优化模型的检测性能。

参考文献:

[1] WANG S J, HOU R F, CUI Y L, et al. Discussion on the application of detection and repair technologies for drainage pipeline networks[J]. Urban Surveying, 2023(S1): 198-201.
王圣杰,侯荣夫,崔英良,等. 浅谈排水管网检测修复和信息化建设技术的应用[J]. 城市勘测, 2023(S1): 198-201.

[2] YANG M X. Research progress on urban drainage pipeline detection robots[J]. Guangdong Building Materials, 2023, 39(8): 132-134.
杨明霞. 城市排水管道检测机器人研究进展[J]. 广东建材, 2023, 39(8): 132-134.

[3] PENG S G, WANG D C, TAN J H, et al. Intelligent video recognition of urban underground drainage pipelines based on improved convolutional neural networks[J]. Surveying and Mapping Bulletin, 2021(10): 132-135,167.
彭述刚,王大成,谭军辉,等. 基于改进卷积神经网络的城市地下排水管道视频智能识别[J]. 测绘通报, 2021(10): 132-135,167.

[4] LI G C, LI Z W, RUAN D Y, et al. Intelligent recognition of drainage pipeline defects based on ResNet network model[J]. Journal of Engineering Geophysics, 2023, 20(6): 695-701.
李广超,李泽伟,阮殿勇,等. 基于 ResNet 网络模型的排水管道缺陷

检测智能识别[J]. 工程地球物理学报, 2023, 20(6): 695-701.

[5] WANG Q, YAO J, TAN W L, et al. Research on drainage pipeline defect detection based on Faster R-CNN[J]. Software Guide, 2019, 18(10): 40-44,49.
王庆,姚俊,谭文禄,等. 基于 Faster R-CNN 的排水管道缺陷检测研究[J]. 软件导刊, 2019, 18(10): 40-44,49.

[6] HE J L. Research on drainage pipeline defect detection algorithm based on random forest and Bayesian optimization[D]. Guangzhou: Guangdong University of Technology, 2018.
何嘉林. 基于随机森林与贝叶斯优化算法的排水管道缺陷检测算法研究[D]. 广州: 广东工业大学, 2018.

[7] LOU A T. Technology of infrared image temperature calibration and defect detection of pipelines based on machine vision[D]. Ji'nan: Qilu University of Technology, 2021.
娄爱涛. 基于机器视觉的管道红外图像温度标定与缺陷检测技术[D]. 济南: 齐鲁工业大学, 2021.

[8] HAN C Y, ZHOU Y, WANG L H, et al. Research on defect recognition method for CCTV drainage pipelines based on YOLOv5s[J]. Municipal Technology, 2024, 42(3): 230-236.
韩崔燕,周扬,汪犁辉,等. 基于 YOLOv5s 的 CCTV 排水管道缺陷识别方法研究[J]. 市政技术, 2024, 42(3): 230-236.

[9] HOWARD A, SANDLER M, CHEN B, et al. Searching for MobileNetV3[C]//2019 IEEE/CVF International Conference on Computer Vision, 2019: 1314-1324.

[10] WANG Q, WU B, ZHU P, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 11531-11539.

[11] LI H L, WEI H B, LIU Z. Slim-neck by GSConv: a better design paradigm of detector architectures for autonomous vehicles[DB/OL]. <https://arxiv.org/abs/2206.02424>.

[12] LIU S, HUANG D, WANG Y. Learning spatial fusion for single-shot object detection[DB/OL]. <https://arxiv.org/abs/1911.09516>.

[13] BETTI S F, PALAZZETTI L, PINOTTI C M. YOLO-based detection of halyomorpha halys in orchards using RGB cameras and drones[J]. Computers and Electronics in Agriculture, 2023, 213: 108228.

[14] SINGHA S, AYDIN B. Automated drone detection using YOLOv4[J]. Drones, 2021, 5(3): 95.

[15] LI Y, YUAN H, WANG Y, et al. GGT-YOLO: a novel object detection algorithm for drone-based maritime cruising[J]. Drones, 2022, 6(11): 335.

[16] HOWARD A G, ZHU M, CHEN B, et al. MobileNets: efficient convolutional neural networks for mobile vision applications[DB/OL]. <https://arxiv.org/abs/1704.04861>.

[17] SANDLER M, HOWARD A, ZHU M, et al. MobileNetV2: inverted residuals and linear bottlenecks[DB/OL]. <https://arxiv.org/abs/1801.04381>.

[18] CHENG D, MENG G, CHENG G, et al. SeNet: structured edge network for sea-land segmentation[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(2): 247-251.

[19] DWYER B, NELSON J, HANSEN T, et al. Roboflow (version 1.0)[EB/OL]. <https://roboflow.com>.

[20] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.

[21] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464-7475.

[22] REDMON J, FARHADI A. YOLOv3: an incremental improvement[DB/OL]. <https://arxiv.org/pdf/1804.02767v1>.

(责任编辑:尹晨茹)