

# 融合多注意力机制的轻量化综合管廊裂缝实例分割模型

郑家乐<sup>1</sup>, 郑翥鹏<sup>1\*</sup>, 黄 钺<sup>2</sup>, 廖斯汉<sup>3</sup>

(1. 厦门大学建筑与土木工程学院, 福建 厦门 361005; 2. 厦门路桥百城建设投资有限公司, 福建 厦门 361009; 3. 福建建工集团有限责任公司, 福建 福州 350003)

**摘要:** [目的] 为了解决城市综合管廊裂缝细微、环境复杂造成现有算法检测裂缝难度大、效果差的问题, 提出一种融合多注意力机制及轻量化的综合管廊裂缝实例分割模型 DG-YOLO. [方法] 原模型 YOLOv8 的卷积核数量较多, 卷积操作会生成大量冗余特征图的问题, 本研究通过在主干网络中引入 Ghost 模块以有效降低模型的复杂性, 同时通过将检测层替换为 Dynamic 模块, 融入动态特征选择机制, 以根据特征的相对重要性自适应地加权 and 选择输入特征. [结果] 经综合管廊裂缝数据集训练验证后证明模型在现实应用中变得更加实用和高效, 同时在处理不同输入时具备更强的适应能力, 从而提升模型的整体性能和检测精度. [结论] 研究表明构建的改进模型 DG-YOLO 能准确地实现管廊复杂背景下细微裂缝特征的提取, 证明了本模型在识别细小裂缝方面的准确性, 同时在综合管廊复杂环境下具有一定的鲁棒性和精度.

**关键词:** 城市综合管廊; 实例分割; 注意力机制; 轻量化网络

**中图分类号:** TP 391.4; TU 990.3

**文献标志码:** A

**文章编号:** 0438-0479(2025)06-1034-07

## Lightweight utility tunnel crack instance segmentation model with multi-attention mechanisms integration

ZHENG Jiale<sup>1</sup>, ZHENG Zhupeng<sup>1\*</sup>, HUANG Cheng<sup>2</sup>, LIAO Sihan<sup>3</sup>

(1. School of Architecture and Civil Engineering, Xiamen University, Xiamen 361005, China; 2 Xiamen Road & Bridge Baicheng Construction Investment Co., Ltd., Xiamen 361009, China; 3 Fujian Construction Engineering Group Co., Ltd., Fuzhou 350003, China)

**Abstract:** [Objective] Challenges of detecting fine cracks in urban utility tunnels, characterized by their subtle nature and complex environments, are addressed herein. We propose a novel instance segmentation algorithm for utility tunnel cracks, DG-YOLO, which integrates multiple attention mechanisms and a lightweight design. [Method] The original YOLOv8 model contains a large number of convolutional kernels, leading to numerous redundant feature maps generated through convolution operations. By contrast, we introduce the Ghost module into the backbone network to effectively reduce model complexity. Furthermore, the detection layer is replaced with a Dynamic module, which incorporates a dynamic feature selection mechanism that adaptively weights and selects input features based on their relative importance. [Result] After training and validation on a utility tunnel crack dataset, we have demonstrated that the proposed model secures superior practicality and efficiency in real-world applications. The model also exhibits enhanced adaptability to various inputs, thereby improving overall performance and detection accuracy. [Conclusion] This research indicates that the improved DG-YOLO model can accurately extract features of fine cracks in complex utility tunnel environments.

收稿日期: 2025-01-15 录用日期: 2025-05-08

基金项目: 福建省科学技术计划项目(2022-K-256)

\* 通信作者: xpeng@xmu.edu.cn

引文格式: 郑家乐, 郑翥鹏, 黄钺, 等. 融合多注意力机制的轻量化综合管廊裂缝实例分割模型[J]. 厦门大学学报(自然科学版), 2025, 64(6): 1034-1040.

Citation: ZHENG J L, ZHENG Z P, HUANG C, et al. Lightweight utility tunnel crack instance segmentation model with multi-attention mechanisms integration[J]. J Xiamen Univ Nat Sci, 2025, 64(6): 1034-1040. (in Chinese)



hence demonstrating the precision of the proposed method in identifying small cracks. Additionally, the model shows robustness and accuracy in the challenging conditions of utility tunnels.

**Keywords:** urban utility tunnel; instance segmentation; attention mechanism; lightweight network

地下综合管廊是用于集中敷设电力、通信、给水、排水等市政管线的公共隧道,是城市运行的重要基础设施和“生命线”,其安全运营对城市正常生活和生产至关重要<sup>[1-2]</sup>。由于地质条件复杂,地下管廊长期使用过程中易受地震、沉降、土壤水分等影响,导致裂缝等缺陷。裂缝的形成演化不仅会使管廊结构承载性能下降,还会诱发渗漏水等病害,给管廊安全运营带来不利影响,甚至引发渗水或倒塌,危及结构安全<sup>[3]</sup>。因此,针对管廊裂缝开展定期巡检,掌握裂缝数量及开裂位置,并采取相对应的加固处置措施以确保管廊安全运营是十分必要的<sup>[4]</sup>。

目前针对综合管廊进行裂缝巡检的主要途径为人工巡检,但这种方式存在成本高且检测效率低、主观性强且准确率低、无法实时监控等缺点,并且巡检人员在这样的环境下工作存在一定的安全隐患。在计算机视觉技术飞速进步的大背景下 YOLO(you only look once)系列、SSD(single shot multibox detector)和 Faster R-CNN(faster region-based convolutional neural network)等基于深度学习算法的目标检测模型被广泛应用于各种场景裂缝智能化检测工作。如 Uwanuakwa 等<sup>[5]</sup>介绍了一种用于识别桥梁表面裂缝的改进 YOLOv5s,在该网络中,GhostBottleneck(ghost bottleneck module)取代了骨干网络中的 C3 模块,以减少可训练参数的数量,实现了一定的轻量化。Du 等<sup>[6]</sup>通过高分辨率工业相机构建了一个大规模且包含路面裂缝的数据集,采用基于深度学习算法的目标检测框架 YOLOv3 来预测包含裂缝的路面病害,综合检测精度达到 73.64%。

然而,目前很少有人将机器视觉应用到综合管廊场景的裂缝识别中。对比分析现有的一些裂缝识别模型发现,这些使用神经网络的检测方法依旧面临复杂背景下裂缝检测精度低等问题,尤其是城市综合管廊这样空间狭窄、照明条件不均匀、多样化管线布局遮挡及管廊裂缝细小且形态复杂的场景<sup>[7-8]</sup>。如:Kulkarni 等<sup>[9]</sup>提出一种整合沥青、陶瓷、玻璃等多种材质的裂缝数据集,并使用 Deeplab(deep labelling)模型进行模型训练,该方法在线状裂缝上表现出色,但在识别复杂形态特征的裂缝上分割效果不佳;Zhang 等<sup>[10]</sup>提出一种基于卷积神经网络(convolutional neural network,CNN)的无监督分割方法用于油气勘

探的储层裂缝检测,但该模型未能考虑管廊的复杂情况导致应用场景受限。同时在综合管廊这种移动设备资源受限的场景下,如何在保证一定准确率的基础下实现轻量快速化也是需要考虑的问题。Zhang 等<sup>[11]</sup>使用小核卷积层、并行最大池和卷积运算提出了 ECSNet(efficient crack segmentation neural network),一定程度上提高了模型的效率性能。Zhu 等<sup>[12]</sup>使用轻量化注意力特征融合单次激发多箱检测器进行混凝土裂缝检测。Wu 等<sup>[13]</sup>设计了一个新颖的轻量级网络构建模块——LWC,该模块包括基本单元和空间下采样单元,这样能减少一定的计算负担。但这些模型都没有很好地考虑综合管廊这种复杂场景,同时很好地兼顾检测精度与模型复杂度。

为了解决城市综合管廊裂缝检测中因裂缝细微、形态复杂和背景干扰导致的精度下降问题,同时应对资源受限场景下模型的轻量化需求,本研究在 YOLOv8 模型的基础上提出了 DG-YOLO(Dynamic-Ghost-YOLO)模型。与以前的 YOLO 版本相比,YOLOv8 在准确性和速度方面都有了显著的改进<sup>[14-15]</sup>。YOLOv8 根据不同的缩放因子提供了不同大小的模型,即 n/s/m/l/x 比例,以适应不同的场景需求。该模型由主干网络(Backbone)、特征融合层(Neck)和检测层(Head)组成,这种设计允许主干网的每个分支、颈部和头部集中其各自的任务,从而提高模型的整体精度。DG-YOLO 引入了 Dynamic Head 模块,以增强对多尺度特征的动态自适应融合,从而有效提高模型对复杂裂缝形态的精细化识别能力,减少对无用特征的关注,该改进使模型能够更灵活地处理裂缝与复杂背景的特征差异,显著提升了分割的精度和鲁棒性;同时加入了 Ghost 模块,以降低计算复杂度并加速模型推理过程,同时保持对裂缝细节特征的提取能力,通过这种轻量化设计,有效提升了模型在资源受限场景中的应用效率,在保证检测性能的同时显著减少了计算开销。

## 1 模型 DG-YOLO 构建

### 1.1 YOLO 模型相关概念

YOLOv8 是 Ultralytics 团队推出的新一代实时目标检测框架,继承了 YOLO 系列的高效特性,同时

在精度、速度和功能上进行了全面升级. 其核心网络结构采用 CSPDarknet 作为骨干, 通过跨阶段局部连接结构减少计算冗余, 并引入 SPPF 模块增强多尺度特征提取能力. 在特征融合部分, YOLOv8 采用改进的 PAN-FPN 结构, 通过双向跨尺度连接实现更精细的多尺度目标检测. YOLO 系列是基于 CNN 的目标检测方法, 其网络结构如图 1 所示.




图 1 CNN 结构

Fig. 1 Structure of CNN

### 1.2 轻量快速化检测模块 Ghost

在 YOLO 模型中, 主干网络的 C2F 模块增强了对不同尺度特征的识别能力, 但其较早接触图像数据导致推理速度较慢. 为提高效率, 减少计算量和参数数量, 本研究在 YOLOv8 中引入 Ghost 模块, 形成 Ghost-YOLO 模型. Ghost 模块将常规卷积分为两步: 一部分使用标准卷积提取特征, 另一部分通过线性变换生成相似特征<sup>[16]</sup>. 最终将这两部分特征图拼接, 从而减少卷积通道数, 节省计算和内存开销, 在保持特征图尺寸一致的情况下提升模型的推理速度, 适用于资源受限设备和高效分割任务.

对于标准卷积操作, 给定输入数据  $X \in R^{h \times w \times c}$ , 其中  $h, w$  和  $c$  分别为输入特征图的高度、宽度和输入通道数, 则生成  $n$  个特征图的任意卷积层的运算如式(1)所示:

$$Y = X * f + b, \quad (1)$$

其中:  $b$  为偏差项,  $f \in R^{c \times k \times k \times n}$  为卷积运算(卷积核大小为  $c \times k \times k$ , 个数为  $n$ ),  $Y$  表示输出通道数量为  $n$  的输出特征图. 通常来说, 标准卷积会带来巨大的计算量, 其运算如式(2)所示:

$$f_{\text{FLOPs}} = c \times k \times k \times n \times h' \times w', \quad (2)$$

其中:  $h', w'$  分别为输出特征图的高度和宽度,  $k$  为卷积核的尺寸. Ghost 模块仅选取部分特征图进行标准卷积操作, 即采用标准卷积完成对  $m$  个原始特征图的映射, 其中  $m \leq n$ , 运算如式(3)所示:

$$Y' = X * f' + b, \quad (3)$$

其中,  $f' \in R^{c \times k \times k \times m}$  为卷积运算(卷积核大小为  $c \times k \times k$ , 个数为  $m$ ), 为方便计算, 省略偏差项  $b$ . 剩余输出特征图通过对卷积生成的  $m$  个特征图进行线性变换获得. 变换如式(4)所示:

$$y_{i,j} = \phi_{i,j}(y'_i), \quad \forall i = 1, \dots, m, j = 1, \dots, s, \quad (4)$$

其中:  $y'_i$  是  $Y'$  中的第  $i$  个原始特征图,  $\phi_{i,j}$  是第  $j$  个线性计算, 用于生成第  $j$  个相似特征图  $y_{i,j}$ . 最后一个  $\phi_{i,s}$  为原始特征图的恒等映射, 变换后可获得  $n = m \times s$  个特征图.

GhostNet 模块的计算量如式(5)所示:

$$f_{\text{FLOPs}} = c \times k \times k \times \frac{n}{s} \times h' \times w' + \frac{n}{s} \times d \times d \times (s-1) \times h' \times w' \approx s, \quad (5)$$

其中  $d \times d$  为每个线性操作的平均内核大小. 由式(5)可知, Ghost 模块将计算拆分为标准卷积运算和线性变换运算两部分, 结合式(5)可求出模型的压缩比约为  $s$ , 参数量显著减少.

### 1.3 融合多尺度特征动态自适应模块 Dynamic Head

YOLOv8 模型仅包含 3 个检测头, 这导致在检测被遮挡或小物体时可能出现漏检或误检的问题. 由于 YOLOv8 的 Backbone 网络输出的是一个具有宽度、高度和通道的三维张量, 本研究引入一个动态检测头(Dynamic Head)的模块, 得到 Dynamic-YOLO 模型. 这个额外的检测头通过整合尺度感知注意力、空间感知注意力和任务感知注意, 在特征张量的特定维度上引入注意力机制<sup>[17]</sup>. 通过这种方式, 模型在检测被遮挡和小物体时的性能得到了有效提升.

给定特征张量  $\mathcal{F} \in R^{L \times S \times C}$ , 应用自注意力的一般公式为

$$W(\mathcal{F}) = \pi(\mathcal{F}) \cdot \mathcal{F}, \quad (6)$$

其中  $\pi(\cdot)$  是注意力函数. 这种注意力功能的一个简单的解决方案是通过完全连接的层来实现. 但是直接学习所有维度上的注意力函数在计算上是昂贵的, 并且由于张量的高维数实际上是负担不起的.

相反, 本研究将注意力函数转换为 3 个连续的注意力, 每个注意力只关注一个视角:

$$W(\mathcal{F}) = \pi_C \{ \pi_S [ \pi_L (\mathcal{F}) \cdot \mathcal{F} ] \} \cdot \mathcal{F}, \quad (7)$$

其中  $\pi_L(\cdot), \pi_S(\cdot)$  和  $\pi_C(\cdot)$  分别是应用于尺度  $L$ 、空间  $S$  和任务  $C$  的 3 个不同维度的注意力函数.

这 3 个注意力机制在 Dynamic Head 中分别发挥以下作用: 尺度感知注意力  $\pi_L$  用于动态融合不同特征尺度, 以增强模型对多尺度目标的感知; 空间感知注意力  $\pi_S$  通过稀疏采样和自学习偏移聚焦在判别性空间区域, 提升特征的空间聚焦能力; 任务感知注意力  $\pi_C$  则动态激活或关闭特征通道, 以适应不同任务需求. Dynamic Head 模块通过自适应调整网络感受野与特征融合策略, 增强 YOLOv8 对细小裂缝的多尺度

特征提取能力,使得模型在裂缝的边界上具有良好的分割能力.

### 1.4 DG-YOLO 模型

通过将上述 2.1 节与 2.2 节中的轻量快速化模块 Ghost-YOLO 模型与融合多尺度特征动态自适应模

块 Dynamic-YOLO 模型相结合,得到了 DG-YOLO 模型. Ghost 模块有效提升了推理速度,而 Dynamic Head 模块增强了对复杂且细小裂缝特征的检测能力,从而提升精确率,使得模型在轻量化与精确性之间达到了良好的平衡. DG-YOLO 模型网络结构图如图 2 所示.

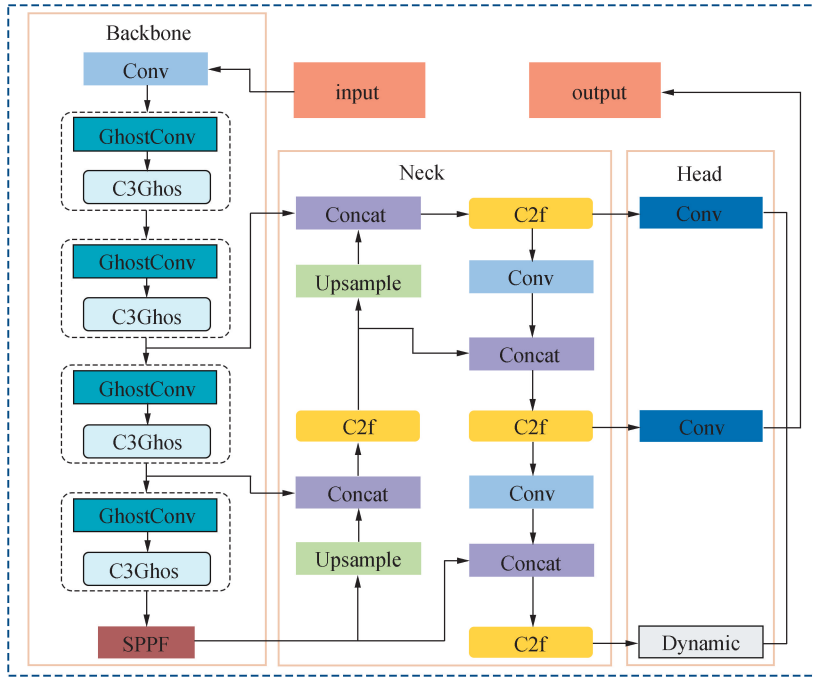


图 2 DG-YOLO 的网络结构

Fig. 2 Network architecture of DG-YOLO

在该模型中,本研究采用 YOLOv8 作为基础架构,并集成了 Ghost 模块和 Dynamic Head,以提高城市综合管廊裂缝检测的效率与精度. 输入图像后,首先进行标准化并调整为  $640 \times 640$  像素的尺寸,确保数据一致性,避免输入尺寸对模型性能的负面影响. 这一过程有助于加速训练并提高模型的泛化能力,使其在各种环境下都能稳定工作. 然后,图像进入 YOLOv8 的主干网络, Ghost 模块通过传统卷积操作提取“真实”特征,并利用线性变换(如逐点卷积)生成冗余特征,从而减少计算量,降低内存消耗,同时保持高精度. 这使得 Ghost 模块在处理大规模、高分辨率图像时,能够显著提高模型的效率和实时性.

处理后的多尺度特征图进入特征金字塔网络(feature pyramid network, FPN),进行不同尺度间的特征融合. FPN 帮助模型在面对各类大小不一的裂缝时,保持较高的检测精度,避免漏检或误检,特别适合复杂的管廊环境. Dynamic Head 模块通过 3 种注意力机制自适应地选择和聚焦最有价值的特征,抑制背景噪声和无关信息<sup>[18]</sup>. 这使得模型能够精确地识别裂缝

区域,尤其在背景复杂或裂缝遮挡时, DyHead 能够自适应地调整关注区域,提供更准确的分割和定位. 最终,模型输出裂缝的检测框和分割掩码,提供精准的裂缝位置和区域信息,可用于进一步分析如裂缝长度和宽度等参数. 综上,集成 Ghost 模块和 DyHead 模块的 YOLOv8 模型,凭借高效的计算和精确的特征提取,在复杂环境中能实时、准确地识别裂缝,为城市管廊的安全监测提供了强大的技术支持.

## 2 模型实验训练和验证

### 2.1 实验训练参数及训练集

本研究实验使用的数据集涵盖了各种细小且不规则形态的裂缝,并提供了精确的像素级标注,即每一张图像中的裂缝部分都经过精细的手动标注,具有明确的边界和形状. 这种精确标注使得该数据集非常适合用于训练和评估分割模型,并通过人工筛选出 500 张代表性强且符合管廊实际场景特点的图片. 针对城市综合管廊中的实际情况,在数据集中通过对亮

度对比度和随机局部亮度变化的随机调节,模拟管廊中灯光不均匀的情况;并且通过随机添加遮挡物来模拟管廊中有大量的各种管道造成遮挡干扰的情况,最后将被管道覆盖的标注区域从 Label 文件中截除掉即可.其中部分图像处理后如图 3 所示.后续继续通过旋转、平移、缩放、镜像等手段<sup>[19]</sup>增加训练数据量至 2 000 张,提高场景丰富度与泛化能力,最后在模型训练时将数据集按照 6 : 2 : 2 的比例划分为训练集、验证集和测试集.




图 3 随机遮挡和光照处理

Fig. 3 Random occlusion and illumination processing

## 2.2 参数选择和模型训练

YOLOv8 默认采用 SGD 优化器,其计算高效但存在收敛慢、学习率敏感性问题.本研究设计多级学习率( $10^{-1} \sim 10^{-4}$ ),通过损失分析优选参数,实验证明阶梯式衰减策略可有效提升收敛效率,对比结果见




图 4(本研究采用 AutoDL 云服务器进行实验).实验结果表明,学习率对模型性能具有显著影响: $10^{-1}$  学习率导致训练损失剧烈波动,验证损失反常上升,表明模型过拟合; $10^{-2}$  学习率实现最佳平衡,损失曲线平稳且收敛速度理想;更低的  $10^{-3}$  和  $10^{-4}$  学习率虽提升精度但显著降低收敛效率.基于上述分析,本研究确定  $10^{-2}$  为最优学习率参数.

本研究构建的数据集用于训练 DG-YOLO 及 Dynamic-YOLO、Ghost-YOLO、YOLO 3 种对比模型,并记录每轮训练中的训练误差和验证误差.观察所得到的损失函数曲线,模型在 150 轮次时便已确定较好的收敛,为了进一步拟合结果,训练轮次(epochs)均设置为 200 次.初始权重采用 YOLOv8 的预训练权重,优化器选择随机梯度下降法,动量设为 0.937,初始学习率为  $10^{-2}$ .结果如图 5 所示,训练初期,采用基础模型预设权重时损失迅速下降.在经过 20 轮训练后,模型对数据集回归准确度逐渐升高,在 20 次之后的损失值逐渐趋于缓和,后续训练损失值逐渐稳定在一定范围内,这说明模型的参数达到了一个最优状态,可以使模型对未知数据有良好的预测能力,此时的权重文件能够作为管廊裂缝检测的权重参数.为获得更加精确的结果,训练图像的大小为  $640 \times 640$  像素;根据所选择的服务器硬件的显存大小,每次训练的批量大小为 550,用于数据加载的工作线程数为 4;为保证模型过拟合时,云服务器能够及时停止,关闭 Mosaic 数据增强的轮数为 10;损失函数选择模型默认的二元交叉熵(binary cross-entropy, BCE)损失函数与 Dice 损失函数的组合.

## 2.3 对比实验

为验证 DG-YOLO 模型的有效性,在相同的训练参数下,将其与原模型 YOLOv8、Ghost-YOLO、




图 4 训练损失(a)和验证损失(b)

Fig. 4 Training loss (a) and validation loss (b) curves

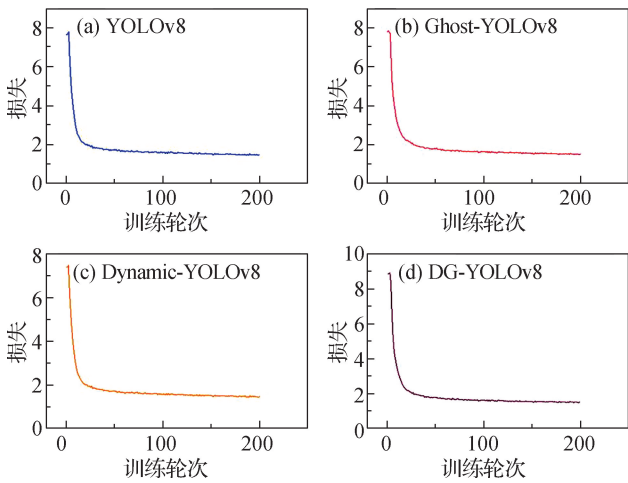


图 5 4 种模型损失曲线

Fig. 5 Loss curves of four models

Dynamic-YOLO 3 种模型进行测试集预测性能对比, 4 种模型测试结果如表 1 所示. 其中, mAP 代表阈值为 0.50 时的平均精度, Params 代表模型的参数量, GFLOPs 代表模型在推理时需要进行的浮点运算次数, Inference 代表模型推理一次所需的时间.

表 1 对比实验结果

Tab. 1 Result of comparative experiment

模型	mAP50	Params/M	GFLOPs	Inference/ms
YOLOv8	85.6	3.26	8.1	10.5
Ghost-YOLO	85.1	2.56	6.2	7.8
Dynamic-YOLO	87.4	2.75	7.7	10.1
DG-YOLO	87.2	2.04	5.8	5.3

由表 1 可知, 模型 Ghost-YOLO 相较原模型检测精度 mAP 50 虽然下降了 0.5 个百分点, 但是参数量和计算量分别减少了 21.5% 和 23.5%, 这是因为 Ghost 模块将传统卷积操作拆解为两部分: 一部分使用标准卷积提取特征, 另一部分通过简单的线性变换生成相似的特征图. 这种设计大幅减少了参数量和计算量, 从而降低了模型的计算复杂度. 模型 Dynamic-YOLO 相较原模型检测精度 mAP 50 提升了 1.8 个百分点, 同时参数量和计算量也分别减少了 15.6% 和 4.9%, 这得益于 Dynamic 模块通过动态特征选择机制, 根据输入的特征自适应地选择最相关的特征进行处理, 这使得模型能够在推理时集中关注最重要的特征, 从而提高检测精度, 同时也减少了不必要的计算. 与其他 3 种模型相比, DG-YOLO 模型的参数量、计算

量和单幅图像推理时间都有明显下降; DG-YOLO 与原模型相比, 检测精度 mAP50 上升了 1.6 个百分点. 综上所述本研究提出的 DG-YOLO 模型在精度与复杂度之间取得了良好的平衡, 在综合管廊这样资源受限的场景下可以大幅降低资源消耗, 提高处理效率, 增强模型的适用性和鲁棒性. 改进后的 3 种模型的 4 个指标相较于原模型的提升百分比如表 2 所示.

表 2 各指标提升百分比

Tab. 2 Percentage improvement of various indicators

模型	mAP50	Params	GFLOPs	Inference
Ghost-YOLO	-0.6	21.5	23.5	25.7
Dynamic-YOLO	2.1	15.6	4.9	3.8
DG-YOLO	1.9	37.4	28.4	49.5

## 2.4 可视化分析

DG-YOLO 与 YOLOv8 相比大幅提高了处理效率, 现在为了更直观地对 DG-YOLO 模型检测性能进行评价, 与原模型在裂缝数据集上进行对比测试, 如图 6 所示. 总的来说, 通过对比结果与标定区域, 可以看出本研究提出的改进模型能够较为准确地提取裂缝特征, 提取出的裂缝整体轮廓与标定区域相符, 没有明显的错误. 由于裂缝 (b) 的裂缝特征较明显, 两种模型都能较好地提取出裂缝特征; 并且 YOLO 漏检或中断多出现在裂缝末端或裂缝较窄处, 对细小裂缝 [如裂缝 (a) 和 (c)] 的分割效果欠佳, 导致分割掩码不完整; 得益于 Dynamic Head 检测层支持多尺度特征

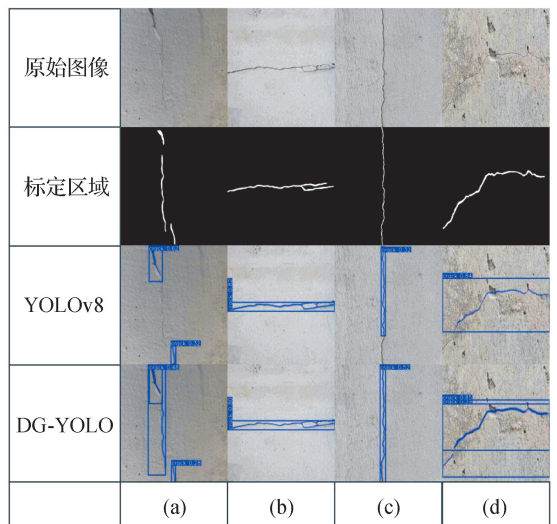


图 6 结果可视化对比

Fig. 6 Visualization comparison of results

的融合,可以更好地识别和提取细小裂缝信息,使得 DG-YOLO 能够有效检测出这些细微裂缝。

### 3 结 论

本研究提出的 DG-YOLO 引入 Dynamic Head 模块,提升多尺度特征融合,增强裂缝识别精度与鲁棒性;同时加入 Ghost 模块,降低计算复杂度,加速推理,保持裂缝细节特征提取能力. 管廊裂缝检测性能实验结果表明, DG-YOLO 模型在检测精度和模型复杂度之间取得了良好平衡,适用于资源受限的管廊场景. 与原始 YOLOv8 模型相比, DG-YOLO 模型的 mAP50 提高 1.6 个百分点,达到 87.2%,同时模型参数量、计算量和推理时间分别减少 37.4%、28.4% 和 49.5%. 对比测试显示, DG-YOLO 模型有效克服了原模型在细小裂缝检测中的不足,尤其在裂缝末端或窄小区域表现更优. DG-YOLO 模型提取的裂缝轮廓与标定区域高度吻合,无明显误差. 在保证高检测精度的同时, DG-YOLO 模型显著降低了计算复杂度和资源消耗,满足管廊裂缝实时检测需求. 本研究为裂缝检测领域提供了新思路,具有较高的实用价值和推广潜力。

### 参考文献:

- [1] 油新华,何光尧,王强勋,等. 我国城市地下空间利用现状及发展趋势 [J]. 隧道建设(中英文),2019,39(2):173-188.
- [2] 钱七虎. 建设城市地下综合管廊,转变城市发展方式[J]. 隧道建设,2017,37(6):647-654.
- [3] 张涛,丁宁,蔡晓坚,等. 综合管廊巡检机器人综述 [J]. 地下空间与工程学报,2019,15(增2):522-533.
- [4] AB RASHID M Z, MOHD YAKUB M F, AHMAD ZAKI BIN SHAIKH SALIM S, et al. Modeling of the in-pipe inspection robot: a comprehensive review[J]. Ocean Engineering, 2020, 203: 107206.
- [5] UWANUAKWA I D, IDOKO J B, MBADIKE E, et al. Application of deep learning in structural health management of concrete structures [J]. Proceedings of the Institution of Civil Engineers - Bridge Engineering, 2024, 177(2): 99-106.
- [6] DU Y C, PAN N, XU Z H, et al. Pavement distress detection and classification based on YOLO network[J]. International Journal of Pavement Engineering, 2021, 22(13): 1659-1672.
- [7] 黄远远,彭潜,徐兵. 一种考虑遮挡物的地铁隧道表面裂缝识别方法 [J]. 长江科学院院报,2023,40(5):145.

- [8] 任莎莎,刘琼,张晓东. 基于 Deeplab-v3+ 的小目标与边缘增强热图像语义分割网络[J]. 厦门大学学报(自然科学版),2022,61(4):701-713.
- [9] KULKARNI S, SINGH S, BALAKRISHNAN D, et al. CrackSeg9k: a collection and benchmark for crack segmentation datasets and frameworks [C] // Computer Vision - ECCV 2022 Workshops. Cham: Springer Nature Switzerland, 2023: 179-195.
- [10] ZHANG W, WU T, LI Z P, et al. Fracture recognition in ultrasonic logging images via unsupervised segmentation network [J]. Earth Science Informatics, 2021, 14(2): 955-964.
- [11] ZHANG T J, WANG D L, LU Y. ECSNet: an accelerated real-time image segmentation CNN architecture for pavement crack detection [J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(12): 15105-15112.
- [12] ZHU W, ZHANG H, EASTWOOD J, et al. Concrete crack detection using lightweight attention feature fusion single shot multibox detector [J]. Knowledge-Based Systems, 2023, 261: 110216.
- [13] WU C G, YE M, ZHANG J L, et al. YOLO-LWNet: a lightweight road damage object detection network for mobile terminal devices [J]. Sensors, 2023, 23(6): 3268.
- [14] BAO Z. The UAV target detection algorithm based on improved YOLO v8 [C] // Proceedings of the International Conference on Image Processing, Machine Learning and Pattern Recognition. Guangzhou: ACM, 2024: 264-269.
- [15] SOHAN M, SAI RAM T, RAMI REDDY C V. A review on YOLOv8 and its advancements [C] // Data Intelligence and Cognitive Informatics. Singapore: Springer Nature Singapore, 2024: 529-545.
- [16] HAN K, WANG Y H, TIAN Q, et al. GhostNet: more features from cheap operations [C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2020: 1577-1586.
- [17] DAI X Y, CHEN Y P, XIAO B, et al. Dynamic head: unifying object detection heads with attentions [C] // 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville: IEEE, 2021: 7369-7378.
- [18] ZHOU Y. A YOLO-NL object detector for real-time detection [J]. Expert Systems with Applications, 2024, 238: 122256.
- [19] 邵桂芳,陈鸿荣,李志超,等. 基于正例学习的纹理表面缺陷检测 [J]. 厦门大学学报(自然科学版), 2024, 63(4): 619-629.

(责任编辑:汪 军)