

基于TN-YOLOv9的隧道病害智能检测

吴回获¹, 左传文², 李 宽³, 樊 刚², 刘康睿⁴, 宋霄罡⁴

(1. 中铁一局集团有限公司, 陕西 西安 710054; 2. 中铁一局集团电务工程有限公司, 陕西 西安 710025; 3. 中铁一局集团城市轨道交通工程有限公司, 江苏 无锡 214104; 4. 西安理工大学 计算机科学与工程学院, 陕西 西安 710048)

摘 要: 隧道在长期使用过程中易出现裂缝、渗漏与剥落等病害, 影响结构的安全与耐久性。为提高隧道病害检测在复杂环境下的准确性, 降低人工成本并推动检测自动化, 提出一种基于YOLOv9算法改进的隧道病害智能检测模型TN-YOLOv9。该方法引入多尺度注意力模块MAB以提升多尺度病害识别能力, 结合选择性注意力模块SAB强化关键特征提取, 采用深度可分离卷积降低模型复杂度, 并利用数据增强技术优化训练集。实验表明, TN-YOLOv9相较原YOLOv9, 浮点运算量与参数量分别减少7.3 G和1.7 M, mAP@0.5与mAP@0.5-0.95分别提高2.9%和9.3%。为了验证该算法的有效性, 将TN-YOLOv9进一步与LiteYOLO-ID、DINO、DDQ及CA-AutoAssign等检测算法进行对比分析。在裂缝、渗漏、剥落这3种病害检测的准确率、召回率、均值平均精度以及计算效率方面均表现优异, 证明了其在隧道病害智能检测中的能力, 满足了轻量级部署的需求。

关键词: 隧道工程; 病害检测; 深度学习; 隧道衬砌病害图像; 数据增强

DOI: 10.11907/rjdlk.251645

扫描二维码阅读全文:



中图分类号: U457

文献标识码: A

文章编号: 1672-7800(2026)005-0158-10

Intelligent Tunnel Defect Detection Based on TN-YOLOv9

WU Huihuo¹, ZUO Chuanwen², LI Kuan³, FAN Gang², LIU Kangrui⁴, SONG Xiaogang⁴

(1. China Railway First Group CO., Ltd., Xi'an 710054, China; 2. China Railway First Bureau Group Electric Engineering Co., Ltd., Xi'an 710025, China; 3. China Railway First Bureau Group Urban Rail Transit Engineering Co., Ltd., Wuxi 214104, China; 4. School of Computer Science and Engineering, Xi'an University of Technology, Xi'an 710048, China)

Abstract: Tunnels are prone to developing cracks, leakage, and spalling during long-term operation, which compromises structural safety and durability. To improve the accuracy of tunnel defect detection in complex environments, reduce labor costs, and promote automation in inspection, this study proposes an intelligent tunnel defect detection model named TN-YOLOv9, an improved version of the YOLOv9 algorithm. The method introduces a Multi-scale Attention Block (MAB) to enhance multi-scale defect recognition, incorporates a Selective Attention Block (SAB) to strengthen key feature extraction, employs depthwise separable convolution to reduce model complexity, and utilizes data augmentation techniques to optimize the training set. Experimental results show that TN-YOLOv9 reduces floating point operations and parameter count by 7.3 G and 1.7 M, respectively, while improving mAP@0.5 and mAP@0.5-0.95 by 2.9% and 9.3%, compared to the original YOLOv9. To further validate its effectiveness, TN-YOLOv9 is compared with detection algorithms such as LiteYOLO-ID, DINO, DDQ, and CA-AutoAssign. The proposed model demonstrates excellent performance in accuracy, recall, mean average precision, and computational efficiency for detecting cracks, leakage, and spalling, confirming its capability in intelligent tunnel defect detection and its suitability for lightweight deployment.

Key Words: tunnel engineering; defect detection; deep learning; tunnel lining defect images; data augmentation

收稿日期: 2025-12-31

基金项目: 国家自然科学基金面上项目(52372418); 陕西省创新能力支撑计划科技创新团队项目(2025RS-CXTD-006)

作者简介: 吴回获(1974-), 男, 中铁一局集团有限公司正高级工程师, 研究方向为计算机视觉、大数据处理; 左传文(1976-), 男, 中铁一局集团电务工程有限公司正高级工程师, 研究方向为智能计算、计算机视觉、大数据分析; 李宽(1976-), 男, 中铁一局集团城市轨道交通工程有限公司工程师, 研究方向为人工智能、计算机视觉; 樊刚(1975-), 男, 中铁一局集团电务工程有限公司工程师, 研究方向为计算机视觉; 刘康睿(2000-), 男, 西安理工大学计算机科学与工程学院硕士研究生, 研究方向为计算机视觉、智能计算; 宋霄罡(1987-), 男, CCF杰出会员, 西安理工大学计算机科学与工程学院教授、博士生导师, 研究方向为计算机视觉、无人系统自主导航。本文通讯作者: 宋霄罡。

0 引言

隧道病害识别在维护隧道安全、提升隧道稳定性方面发挥着重要作用。随着时间的推移,铁路和公路等领域的营业里程不断增长,建成隧道数也随之上升^[1]。但由于隧道运营情况复杂,传统病害检测精度和效率较低,难以确保隧道检测的准确性和可靠性^[2]。研究显示,处于服役期间的隧道结构常出现的病害包括混凝土裂缝、渗漏等^[3]。病害的发生受周围环境及结构特性的影响,且不同类型的病害之间存在相互作用与紧密联系,在特定条件下这种关系尤为显著。如若忽略这些病害,将削弱结构的稳固性,甚至导致重大交通事故,严重威胁隧道内车辆及人员的安全。因此,提升运营期隧道病害识别的可靠性对维护隧道日常安全至关重要。

近年来,科学技术的快速发展为隧道病害检测方法的革新提供了坚实基础。业内人士也逐步从效率较低的周期性人工巡检过渡到采用探地雷达^[4]、红外热成像检测^[5]、移动激光扫描^[6]等无损技术。然而这些方法主要依赖专业技术人员,容易造成检测过程效率低下且主观等问题。因此,非常有必要研制一种自动检测模型,用于从隧道图像中智能识别内部病害。

随着深度学习在目标检测领域的快速发展,各种检测算法不断涌现,为隧道病害的自动识别与评估提供了新的思路。目前,许多学者利用深度学习卓越的信息提取能力,实现了病害的智能化识别,但仍存在一些局限性^[7-14]。在简单数据集上训练的模型,应用于具有复杂背景的隧道图像时,其准确性可能会有所下降。研究者发现,现有的深度学习算法并不能完全适用于隧道病害的识别,因为这些算法需进一步改进,以适应隧道环境的复杂性和病害特征的多尺度变化^[15]。

为了在复杂环境下提高隧道病害检测的准确性和效率,研究人员探索了改进的算法架构。朱磊等^[16]在Mask R-CNN模型的基础上通过改进程序参数,优化模型自动检测裂缝结果。Wang等^[17]采用Mask R-CNN作为基础模型,引入了一种掩模级联策略来提高阳性样本的质量,在隧道渗漏检测方面实现了更高的精度。然而,这种方法存在计算复杂性较高的问题,这是由于Mask R-CNN在训练和推理过程中包含了区域候选框的提议、对象的分类与回归以及分割等多个复杂步骤,需要消耗大量资源和时间。Li等^[18]基于Faster R-CNN提出了一种改进算法,结合了多层特征融合与锚点增强技术,旨在提升隧道内细小裂缝的识别精度。与Mask R-CNN相似,这种方法同样对计算资源有较高的要求。Feng等^[19]提出了基于TDDNet的多检测头和注意力模块的隧道衬砌多缺陷检测,显著提高了隧道渗漏、裂缝和剥落等缺陷的检测准确率和效率。然而,其计算复杂度依然较高,模型训练和推理过程中的资源消

耗较大。Lu等^[20]设计的CA-AutoAssign方法旨在消除缺陷检测中复杂背景的干扰,并提升检测精度。实验表明,该方法在精度上有一定提升。然而,由于其算法结构较为复杂,改进后需要多次调整现有架构,导致运算速度变慢,实时性受限。尽管精度有所提高,算法在实际应用中的效率问题仍需进一步优化。Li等^[21]设计的轻量级LiteYOLO-ID模型旨在降低模型参数,满足实时缺陷检测的要求。Luo等^[22]设计的SFW-YOLO轻量级多尺度检测网络旨在通过高分辨率特征层与动态注意力机制增强小缺陷的识别能力,并在复杂背景下提升检测精度。

上述目标检测算法在某些场景中表现良好,但大多数算法计算复杂度较高,且难以适应复杂环境中的目标检测任务。鉴于此,本文提出采用基于YOLOv9改进的病害识别方法,即TN-YOLOv9算法,对隧道裂缝、渗漏和剥落进行检测和识别。首先,通过数据增强方法生成囊括多种缺陷的病害样本,在YOLOv9的基础上引入MAB模块,捕捉病害的多尺度特征;其次,引入SAB模块以增强对隧道病害检测关键层的识别,促进病害的边缘检测;最后,从减小模型规模、实现轻量化部署的角度出发,模型在部分卷积层中引入深度可分离卷积,从而有效减少参数量与计算开销。

1 隧道病害检测方法

1.1 TN-YOLOv9算法架构

YOLO(you only look once)系列算法经历了持续的发展与优化,其中,YOLOv9通过引入可编程梯度信息(PGI)和广义有效分层聚合网络(GELAN),在特征传递稳定性与跨层融合能力方面较以往方法有所提升^[23]。然而,在隧道裂缝、渗漏和剥落等病害检测任务中,YOLOv9仍存在3个方面的不足:①病害目标存在明显的尺度差异,极细裂缝等小目标易在特征采样过程中丢失;②病害多表现为弱纹理或细边缘结构,YOLOv9的标准特征融合对这类细粒度信息关注不足;③模型计算量较大,难以满足现场检测和轻量级部署的需求。

针对上述问题,本文提出改进的TN-YOLOv9算法,在YOLOv9的Backbone主干网络、Neck和Head模块的基础上,本文从多尺度表征、边缘敏感性和轻量化结构3个方面对网络进行了针对性增强,其整体结构如图1所示。

由图1可知,Backbone主干网络负责从输入图像中提取不同深度的特征。为解决YOLOv9在小目标和多尺度病害表达不足的问题,Backbone融合了多尺度注意力模块(Multi-scale Attention Block),通过自适应关注不同尺度的信息以提升特征区分能力。同时,为降低模型复杂度并适应现场部署需求,引入深度可分离卷积(DWConv),使Backbone在保持表达能力的同时显著减少计算量。最终,Backbone输出三组关键特征层,尺寸分别为 $20 \times 20 \times 128$ 、 $40 \times 40 \times 192$ 和 $80 \times 80 \times 128$ 。




Fig. 1 Structure of TN-YOLOv9 network

图 1 TN-YOLOv9 网络结构

Neck 模块负责对上述三组特征进行跨尺度融合,以进一步提升模型对裂缝、渗漏和剥落等病害的检测能力。为增强 YOLOv9 对弱纹理与边缘特征响应不足的问题,Neck 中引入选择性注意力模块(Selective Attention Block),通过强化关键区域特征,使模型对细粒度边缘结构更加敏感。具体而言,细粒度特征图首先通过空间金字塔池化的 ELAN 结构(SPPELAN)增强局部几何特征,并与中等粒度与粗粒度特征进行上采样与拼接;其次,多级 MAB、SAB、平均池化和卷积进一步融合全尺度信息;最终,输出 6 组多尺度关键特征层,尺寸分别为 $40 \times 40 \times 128$ 、 $40 \times 40 \times 192$ 、 $80 \times 80 \times 256$ 、 $20 \times 20 \times 128$ 、 $40 \times 40 \times 192$ 以及 $80 \times 80 \times 128$ 。

在最终阶段,Head 模块负责处理来自 Neck 模块的 6 个关键特征层,通过卷积层和激活函数融合特征,生成边界框坐标、置信度以及每个类别的概率分布,以输出病害的具体位置和类别。

1.2 MAB 模块

MAB 模块是通过将本文提出的 MA(Multi-scale Atten-

tion)模块集成到 YOLOv9 结构中形成的,其模块结构如图 2 所示。该模块通过卷积操作与本文设计的注意力机制,在特征融合的基础上有效捕捉多尺度特征,提高病害目标的检测能力。MA 模块通过深度卷积与膨胀卷积相结合,进一步增强特征表示能力,并利用注意力机制动态调整特征权重,从而使得算法能够自适应地关注多尺度病害的重要特征。




Fig. 2 Structure of MAB module

图 2 MAB 模块结构

由图可知, MAB 模块由 MA 模块和 4 个卷积层串联组成, 包含初始卷积层、两个特征提取卷积层以及最终的特征融合卷积层。首先, 初始卷积层通过 1×1 卷积将输入特征图的通道数调整为中间通道数, 以确保后续处理的维度匹配; 其次, 特征进入两个特征提取卷积层, 每个卷积层由一个 3×3 卷积和一个 MA 模块组成, 分别将通道数转换并提炼深层次特征信息; 最后, 通过 1×1 卷积将所有提取的特征图在通道维度上拼接, 输出的融合特征经过特征融合卷积层处理后, 通道数调整为目标输出通道数。此外, MA 模块如图 3 所示, 它由多种卷积操作和注意力机制并行连接构成。

首先,模块采用了 5×5 深度卷积和 7×7 膨胀卷积,分别获取不同尺度的局部和全局特征,深度卷积和膨胀卷积计算公式如式(1)一式(2)所示:

$$\text{DepthwiseConv}(\mathbf{X}) = f_{5 \times 5}(\mathbf{X}) + \mathbf{b}_d \quad (1)$$

$$DilatedConv(\mathbf{F}_l) = f_{7 \times 7}(\mathbf{F}_l) + \mathbf{b}_{dil} \quad (2)$$

其中, $\mathbf{X}$ 表示输入特征矩阵, $f_{5 \times 5}$ 和 $f_{7 \times 7}$ 分别表示 5×5 深度卷积和 7×7 膨胀卷积, $\mathbf{b}_d$ 和 $\mathbf{b}_{dil}$ 分别表示深度卷积和膨胀卷积的偏置项, $\mathbf{F}_l$ 为深度卷积经过 ReLU 的输出特征矩阵, 定义如式 (3) 所示:

$$F_l = \text{ReLU}(\text{DepthwiseConv}(X)) \quad (3)$$

两者的输出经过 1×1 卷积进行通道压缩,从而降低特征的维数,并通过拼接操作合并,合并后的特征矩阵定义如式(4)一式(6)所示:

$$\mathbf{F}_{combined} = [\mathbf{F}'_1, \mathbf{F}'_2] \quad (4)$$

$$\mathbf{F}'_l = \mathbf{f}_{1 \times 1}(\mathbf{F}_l) + \mathbf{b}_{rl} \quad (5)$$

$$\mathbf{F}'_2 = \mathbf{f}_{1 \times 1}(\mathbf{F}_2) + \mathbf{b}_{r2} \quad (6)$$

其中, $\mathbf{F}_{combined}$ 是合并后的特征矩阵, $\mathbf{F}'_1$ 和 $\mathbf{F}'_2$ 分别表示通道压缩后的输出特征矩阵, $f_{1 \times 1}$ 表示 1×1 卷积, b_{r1} 和 b_{r2} 分别表示 1×1 卷积的偏置项, $\mathbf{F}_s$ 为膨胀卷积经过 ReLU 的

输出特征矩阵,定义如式(7)所示:

$$\mathbf{F}_2 = \text{ReLU}(\text{DilatedConv}(\mathbf{F}_1)) \quad (7)$$

随后,合并后的特征通过全局平均池化和最大池化操作生成汇聚特征,输入到注意力机制模块。注意力机制使用 7×7 卷积和Softmax进行空间权重分配,将权重应用于特征通道上,进一步突出关键区域的特征。汇聚特征矩阵和权重的计算公式如式(8)一式(9)所示:

$$\mathbf{x} = [\text{MeanPool}(\mathbf{F}_{combined}), \text{MaxPool}(\mathbf{F}_{combined})] \quad (8)$$

$$weight = softmax(f_{7 \times 7}(x) + b) \quad (9)$$

其中, $\mathbf{x}$ 表示全局平均池化和最大池化生成的汇聚特征矩阵, $\mathbf{b}$ 表示偏置项。权重分配矩阵如式(10)所示:

$$\mathbf{F}_{weighted} = \mathbf{F}'_1 \cdot \mathbf{weight}[:, 0:1, :, :] + \mathbf{F}'_2 \cdot \mathbf{weight}[:, 1:2, :, :] \quad (10)$$

最终,经过 1×1 卷积恢复原始通道数,以确保特征输入维度与原始特征相匹配。通过元素级加法操作,将原始输入与输出进行融合如式(11)所示:

$$Output = X + f_{1 \times 1}(F_{weighted}) \quad (11)$$

其中, *Output* 是最终的输出特征矩阵。

1.3 SAB模块

Neck可以通过结合不同尺度的特征,从而增强模型的检测性能。然而,现有的方法往往忽略了对深层次局部特征的充分挖掘,特别是在边缘和边界信息上的强化。选择性注意力模块(Selective Attention Block, SAB)的提出能够有效提高对隧道病害关键层的识别,特别是在深层次特征的提取上,促进了对边缘或边界信息的强化。SAB模块通过聚焦这些重要的局部区域,能够进一步提升模型对复杂病害特征的挖掘能力,从而更加准确地识别隧道病害。在Neck的关键层中融入SAB模块,能够更有效地挖掘深层次特征的上下文关联与细节特征,增强对关键病害主要特征的捕捉。SAB模块如图4所示。




Fig. 3 Structure of MA module

图 3 MA 模块结构




Fig. 4 Structure of SAB module

图4 SAB模块结构

该架构集成了带有批量归一化和自适应通道混合注意力机制(ACmix)的卷积框架,其具体结构见图5^[24]。首先,输入特征通过一个 1×1 卷积进行通道压缩后分成两个分支,其中,a分支保留原始压缩特征,b分支则送入ACmix模块进行进一步处理。其次,在ACmix模块中,输入特征

图先经过 1×1 卷积生成多样化的中间特征集,这些中间特征随后被重复利用,并分别沿自注意力和卷积两条并行路径进行聚合。在卷积路径中,模块通过全连接层对特征进行整合与降维,再经过移动与聚合操作,以强化对深层局部特征的捕捉能力;在自注意力路径中,则通过查询、键和值的特征映射获取全局信息,提升模型对边缘和边界信息的敏感度。然后,b分支输出的特征经过由两个 1×1 卷积组成的前馈网络进行整合,并与a分支特征拼接。最终,拼接后的特征图经过一个 1×1 卷积恢复至原始通道数,得到整合后的输出特征。




Fig. 5 Structure of ACmix module

图5 ACmix模块结构

2 实验设置

2.1 隧道病害数据集

在隧道病害数据集方面,将收集到的真实病害图像构建一套数据集,用于隧道病害检测。该数据集包括3种类型的隧道病害:裂缝、渗漏和剥落。本文在数据处理过程中随机分配80%为训练集,10%为验证集,10%为测试集。其中,训练集被用于模型的构建与学习过程;验证集用于模型训练阶段的中间校验;而测试集则最终应用于对模型性能的全面评估。各类型数据集中包含的具体隧道病害图像数量如表1所示。

隧道裂缝、渗漏和剥落图像的数量相对较少且亮度多

Table 1 Image quantity of various types of tunnel diseases

表1 各类型隧道病害图像数量

病害类型	真实病害图像/张	扩充病害图像/张	总和/张
训练集	1 352	1 352	2 704
验证集	168	168	336
测试集	170	170	340
总和	1 690	1 690	3 380

样性有限,单用这些图像训练的模型可能无法在其他环境中的隧道病害图像上实现良好泛化。为提高模型的鲁棒性,使用数据增强方法对训练集、验证集和测试集进行扩充。此方法共获得3 380张包含不同类型缺陷的病害图像。

具体而言,本文通过调节图像的对比度和亮度、水平翻转、添加噪声等方法扩充数据集。随后,本文使用LabelImg标注软件对隧道病害图像进行标注,并将数据格式转换为符合COCO与YOLO标准的格式,便于更好地开展后续的模型训练及性能评估工作。

2.2 实验环境

本文提出的TN-YOLOv9模型在PyCharm平台上通过Python 3.9.20计算机编程语言进行编译。在两个工作站上进行了病害图像标注和病害检测实验。图像标注在Windows 10操作系统的工作站(Intel酷睿i7-7700HQ CPU)上进行;病害检测则在配置Ubuntu 20.04操作系统的NVIDIA GeForce RTX 4090 GPU上进行。

2.3 评估指标

本文的目标是在确保检测准确性的同时实现模型轻量化。本文选择准确率、召回率、均值平均精度、浮点运算

量和参数量这 5 个广泛使用的指标,以全面评价模型的分类性能。

准确率计算公式如式(12)所示。式中, TP 代表模型准确判定为病害的数量, FP 代表模型误判为病害的数量。 P 越大,表明模型对该类别目标的预测性能愈加优越。

$$P = \frac{TP}{TP + FP} \quad (12)$$

召回率计算公式如式(13)所示。式中, FN 代表未能检测出实际为病害的数量。 R 值越高时,模型在检测方面的表现越全面。

$$R = \frac{TP}{TP + FN} \quad (13)$$

均值平均精度计算公式如式(14)所示。式中, C 是类别的数量,表示类别 c 的精度作为召回率 R 的函数。均值平均精度用于评价模型的综合性能,值越接近 1 表示分类效果越好。

$$mAP = \frac{1}{C} \sum_{c=1}^C \int_0^1 P_c(R) dR \quad (14)$$

浮点运算量计算公式如式(15)所示。式中, k^2 是卷积核大小,输出特征图的高度和宽度分别用 H_{out} 和 W_{out} 表示,输入和输出通道数则分别为 C_{in} 和 C_{out} 。

$$FLOPS = k^2 * H_{out} * W_{out} * C_{in} * C_{out} \quad (15)$$

参数量计算公式如式(16)所示。参数量越小,表明模型的存储需求越低,训练和推理过程更为轻量化,适用于计算能力和存储要求较高的场景。

$$Parameters = k^2 * C_{in} * C_{out} \quad (16)$$

3 实验与分析

3.1 模型训练设置

本文各项实验均在隧道病害数据集上进行训练,并对每个算法的训练性能进行评估。为了提升训练的速度和效果,训练过程使用 SGD 优化器对超参数进行微调,初始学习率设为 0.01,采用指数衰减策略。当图像尺寸较小时,关键特征的像素数量会减少,从而影响算法识别;尺寸过大则会导致运行时间延长、显存占用增加。为增强对小物体的识别并优化显存使用,将输入图像尺寸设为 640×640。此外,一阶动量系数设为 0.937,权重衰减系数设为 0.0 005,并进行训练轮数为 450 轮的训练。同时,保存在训练过程中达到最高性能的模型,并在验证集上进行测试。

3.2 消融实验

通过 TN-YOLOv9 的消融实验,本文评估了算法模型中 MAB 模块和 SAB 模块对整体性能的影响。消融实验的结果如表 2 所示。

从表 2 可以明显看出,相较于原始模型, MAB 模块和 SAB 模块对大多数检测指标均有不同程度的提升。具体而言,当仅在颈部网络和检测头之间引入 SAB 模块时,与原始模型相比,渗漏和剥落两类病害的准确率和召回率均

Table 2 Ablation experiment results

表 2 消融实验结果

模型	病害种类	P/%	R/%	mAP@0.5/%	mAP@0.5-0.95/%
YOLOv9	Leakage	88.4	89.4	88.8	71.4
	Spalling	87.0	75.1		
	Crack	93.6	74.6		
	Leakage	89.2	90.6		
YOLOv9_SAB	Spalling	87.2	77.6	90.1	71.8
	Crack	91.7	73.2		
	Leakage	97.4	93.9		
YOLOv9_SAB_MAB	Spalling	93.3	89.6	91.7	80.7
	Crack	94.7	76.1		

有小幅提升,仅在裂缝检测上略有下降。其 mAP@0.5 提高了 1.3%, mAP@0.5-0.95 提高了 0.4%。在引入 SAB 模块的基础上,将 MAB 模块加入骨干网络与颈部网络后,相较于 YOLOv9_SAB 模型,各项检测指标均有所提升。在三类病害的检测中,准确率分别提高了 8.2%、6.1% 和 3.0%,召回率分别提高了 3.3%、12.0% 和 2.9%, mAP@0.5 提高了 1.6%, mAP@0.5-0.95 提高了 8.9%。

为了更直观地展示 SAB 模块和 MAB 模块的有效性,部分模型识别结果如图 6 所示。通过对比 YOLOv9、YOLOv9_SAB (包含 SAB 模块的 YOLOv9 模型) 和 YOLOv9_SAB_MAB (包含两个模块的 YOLOv9 模型) 生成的预测图,可以发现 YOLOv9_SAB 模型较原模型对渗漏和剥落病害具有更强的适用性, YOLOv9_SAB_MAB 较 YOLOv9_SAB 模型对裂缝和渗漏病害识别的效果有进一步的提升。这些定性结果再次证明了设计 MAB 模块和 SAB 模块并将其纳入模型是合理的。

3.3 对比实验

为了验证 TN-YOLOv9 的性能,本文不仅将其与主流目标检测算法进行了比较,还与其他在缺陷检测领域表现出色的检测算法进行了比较。具体包括: YOLOv9^[23]、LiteYOLO-ID^[21]、DINO^[25]、DDQ^[26]、YOLOv13^[27] 和 CA-AutoAssign^[20]。对比实验结果如表 3 所示。

由表可知,在渗漏病害的检测中, TN-YOLOv9 模型的准确率和召回率分别为 97.4% 和 93.9%, 相较原模型 YOLOv9 提高了 9% 和 4.5%; 相较 LiteYOLO-ID 提高了 3.6% 和 7%; 相较 DINO 提高了 6.6% 和 13.8%; 相较 DDQ 提高了 5.2% 和 23.7%; 相较 CA-AutoAssign 提高了 8.1% 和 17.1%; 相较 YOLOv13 提高了 4.2% 和 7.3%。

在剥落病害的检测中, TN-YOLOv9 模型的准确率和召回率分别为 93.3% 和 89.6%, 相较原模型 YOLOv9 提高了 6.3% 和 14.5%; 相较 LiteYOLO-ID 提高了 1.3% 和 9.6%; 相较 DINO 提高了 5.8% 和 16.1%; 相较 DDQ 提高了 12.9% 和 22.3%; 相较 CA-AutoAssign 提高了 15.3% 和 24.1%; 相较 YOLOv13 提高了 4.8% 和 21.5%。

在裂缝病害的检测中, TN-YOLOv9 模型的召回率为 76.1%, 略低于 LiteYOLO-ID 的 78.0% 和 DDQ 的 77.1%, 其余均表现不俗。




Fig. 6 Identification results of different models

图6 不同模型识别结果

Table 3 Comparative experiment results

表3 对比实验结果

模型	病害种类	P/%	R/%	mAP@		Flops	Params
				0.5/%	0.95/%	/G	/M
CA-AutoAssign	Leakage	89.3	76.8				
	Spalling	78.0	65.5	82.4	53.5	79.7	43.7
	Crack	76.9	64.4				
DDQ	Leakage	92.2	70.2				
	Spalling	80.4	67.3	86.7	66.2	156.6	32.0
	Crack	87.4	77.1				
DINO	Leakage	90.8	80.1				
	Spalling	87.5	73.5	88.2	69.0	221.1	47.5
	Crack	84.2	74.5				
LiteYOLO-ID	Leakage	93.8	86.9				
	Spalling	92.0	80.0	86.4	63.7	9.6	3.7
	Crack	86.2	78.0				
YOLOv9	Leakage	88.4	89.4				
	Spalling	87.0	75.1	88.8	71.4	38.7	9.5
	Crack	93.6	74.6				
YOLOv13	Leakage	93.2	86.6				
	Spalling	88.5	68.1	81.4	60.7	6.2	2.4
	Crack	88.4	64.7				
本文模型 (TN-YOLOv9)	Leakage	97.4	93.9				
	Spalling	93.3	89.6	91.7	80.7	31.4	7.8
	Crack	94.7	76.1				

此外,通过比较结果可以发现,本文模型的 mAP@0.5 和 mAP@0.5-0.95 均有所提升。其中, TN-YOLOv9 模型的 mAP@0.5 为 91.7%, 相较 YOLOv9、LiteYOLO-ID、DINO、DDQ、CA-AutoAssign 和 YOLOv13 分别提高了 2.9%、5.3%、3.5%、5.0%、9.3% 和 10.3%。TN-YOLOv9 模型的 mAP@0.5-0.95 为 80.7%, 相较 YOLOv9、LiteYOLO-ID、DINO、

DDQ、CA-AutoAssign 和 YOLOv13, 分别高出 9.3%、17.0%、11.7%、14.5%、27.2% 和 20.0%。同时, TN-YOLOv9 模型的浮点运算量和参数量分别为 31.4 G 和 7.8 M, 比 YOLOv9 减少了 7.3 G 和 1.7 M, 明显低于 DINO、DDQ、CA-AutoAssign 模型。虽然 TN-YOLOv9 比 LiteYOLO-ID 和 YOLOv13 拥有更多的参数量和浮点运算量, 但其检测性能优于二者, 还能够有效识别不同类型的隧道衬砌病害。

3.4 各模型检测效果比较

为进一步验证 TN-YOLOv9 的病害检测能力, 选取本文模型与其他 5 种对比模型分别针对隧道衬砌结构中的裂缝病害、渗漏病害以及剥落病害进行检测。检测效果如图 7 所示。

在隧道运营过程中, 受复杂地质条件及多种因素的共同影响, 病害往往集中在某些隧道段。当一张图像中同时出现多种病害时, 需要准确区分不同类型的病害, 并将其识别为独立的病害。因此, 本文既选取了单一病害图像, 也选取了混合病害图像。第 3 至 8 行展示了一些具有代表性的检测结果, 每行对应一个不同的模型, 每列分别为一张隧道病害图像, 每张图像包含一种或多种病害。其中, 第一张和第四张为单一病害图像, 其余三张为混合病害图像。

针对单一病害图像, 所有模型均成功定位病害, 错误识别和遗漏情况较少。其中, LiteYOLO-ID 模型误将第一张图像中的污渍识别为渗漏, 而 TN-YOLOv9、DDQ 和 CA-AutoAssign 模型则出现了重叠边界框的错误。DDQ 和 CA-AutoAssign 模型误将第四张图像中的线缆识别为渗漏, 而该图像中管道下方的渗漏仅被 TN-YOLOv9 和 DDQ 模型检测到。




Fig. 7 Comparison of detection performance of different models
图 7 各模型检测效果对比

在混合病害图像检测方面,5种比较模型则均存在一定的遗漏。第二张图像为混合病害图像,其渗漏特征相对明显,因此大多数模型能够识别该缺陷。然而,由于背景复杂、环境亮度较低,裂缝和剥落的检测效果均不佳。YOLOv9、LiteYOLO-ID 和 DDQ 在识别剥落时表现不佳,CA-AutoAssign 未能准确识别裂缝和剥落,只有 TN-YOLOv9 和 DINO 模型准确地定位了这些病害。此外,第三张图像包含一处渗漏和4处剥落病害,仅 TN-YOLOv9 和 YOLOv9 模型完整地识别出所有病害,其余模型均存在对不同区域剥落病害的遗漏。而在最后的混合病害图像中,由于管片接缝的不规则分布和复杂的背景纹理,5个对比模型均未能完全识别出剥落,仅 TN-YOLOv9 模型取得了较为不错的表现。

由此可知,TN-YOLOv9 的可视化效果总体上优于5种比较模型。这表明,无论在单一病害图像还是混合病害图像下,TN-YOLOv9 模型能够有效识别不同类型的隧道衬砌病害,实现了复杂环境条件下隧道衬砌多重病害的高精度检测。这些直观的识别结果验证了 TN-YOLOv9 对多尺度缺陷的适应性和对环境干扰的鲁棒性。

3.5 数据增强条件下的检测效果对比

为验证模型在真实复杂隧道环境下的鲁棒性与泛化能力,本文使用经数据增强处理的测试集对 TN-YOLOv9 进行了评估,结果如图8所示。实验表明,本文引入的多尺度注意力模块 MAB 与选择性注意力模块 SAB 能够提取更具鲁棒性的特征,减轻了环境干扰对检测性能的影响,从而增强了模型在实际复杂场景中的适用性。




Fig. 8 Comparison of detection performance under data augmentation conditions

图8 数据增强条件下模型检测效果对比

4 结语

本文提出了一种基于 YOLOv9 的隧道病害检测模型,并利用深度可分离卷积来降低模型复杂度。首先,使用数据增强技术优化并扩充数据集;其次,通过引入多尺度注意力模块 MAB 和选择性注意力模块 SAB,提升了对不同尺

度病害的检测精度,同时,促进了病害的边缘检测;最后,实现对隧道衬砌中裂缝、渗漏和剥落三类病害的检测。本文的主要结论如下:

(1)消融实验验证了 YOLOv9 算法、MAB 模块和 SAB 模块的有效性。每一项改进都对提升模型的 mAP@0.5 和 mAP@0.5-0.95 有所贡献,从而在一定程度上增强了模型的病害检测性能。

(2)对比实验表明,TN-YOLOv9 模型 mAP@0.5 为 91.7%,mAP@0.5-0.95 为 80.7%,均优于比较模型 YOLOv9、LiteYOLO-ID、DINO、DDQ 和 CA-AutoAssign;浮点运算量和参数量分别为 31.4G 和 7.8M,仅比 LiteYOLO-ID 和 YOLOv13 的参数量和浮点运算量高,均低于其他检测模型,相较于其他模型在检测精度和模型参数量之间取得了出色的平衡,进一步证明了模型的鲁棒性和优异的泛化能力。

(3)从真实病害图像检测效果方面分析,TN-YOLOv9 模型与比较模型 YOLOv9、LiteYOLO-ID、DINO、DDQ 和 CA-AutoAssign 相比,即使在复杂背景环境和混合病害等挑战性条件下,依然能够保持对多种衬砌病害的高精度检测,展现出更优越的病害检测性能和更高的应用价值。

参考文献:

- [1] GONG J F, WANG W, WANG F, et al. Statistics of China's railway tunnels by the end of 2023 and overview of tunnels of key new projects in 2023 [J]. Tunnel Construction, 2024, 44(2): 377-392.
况江峰,王伟,王芳,等.截至2023年底中国铁路隧道情况统计及2023年新开通重点项目隧道情况介绍[J].隧道建设,2024,44(2): 377-392.
- [2] ZHOU Z, YAN L, ZHANG J, et al. Real-time tunnel lining crack detection based on an improved You Only Look Once version X algorithm [J]. Georisk: Assessment and Management of Risk for Engineered Systems and Geohazards, 2023, 17(1): 181-195.
- [3] HUANG J, ZHANG D L, LIANG W H, et al. Research overview on safety control technology for tunnel structure during service period [J]. Railway Standard Design, 2024, 68(4): 1-19.
黄俊,张顶立,梁文灏,等.服役期隧道结构安全控制技术综述[J].铁道标准设计,2024,68(4):1-19.
- [4] JIANG T, QU Y L. Study on the detection method of tunnel lining seepage water by ground penetrating radar [J]. Journal of Highway and Transportation Research and Development, 2022, 39(6): 119-123, 135.
姜涛,曲英丽.探地雷达检测隧道衬砌渗漏水方法研究[J].公路交通科技,2022,39(6):119-123,135.
- [5] WANG K, LIU J, LYU G H, et al. Identification method and engineering application of lining damage seepage water based on infrared image enhancement [J]. Chinese Journal of Applied Basic and Engineering Science, 2023, 31(6): 1444-1460.
王康,刘健,吕高航,等.基于红外图像增强的衬砌裂损渗漏水识别方法及工程应用[J].应用基础与工程科学学报,2023,31(6):1444-1460.
- [6] MENG Q N, ZHANG H D, WANG Z, et al. Application of mobile 3D laser scanning technology in metro tunnel defect detection [J]. Urban Surveying and Mapping, 2021(2): 143-148.

- 孟庆年,张洪德,王智,等. 移动三维激光扫描技术在地铁隧道病害检测中的应用[J]. 城市勘测, 2021(2): 143-148.
- [7] XIONG L, ZHANG D, ZHANG Y. Water leakage image recognition of shield tunnel via learning deep feature representation[J]. Journal of Visual Communication and Image Representation, 2020, 71: 102708.
- [8] LIU J, ZHAO Z, LV C, et al. An image enhancement algorithm to improve road tunnel crack transfer detection[J]. Construction and Building Materials, 2022, 348: 128583.
- [9] ZHOU Z, ZHANG J, GONG C, et al. Automatic tunnel lining crack detection via deep learning with generative adversarial network-based data augmentation[J]. Underground Space, 2023, 9: 140-154.
- [10] LEE K, LEE S, KIM H Y. Deep learning-based defect detection framework for ultra high resolution images of tunnels[J]. Sustainability, 2023, 15(2): 1292.
- [11] WANG H Y, PAN Z J, CAO J K, et al. Pavement crack recognition method based on dual convolutional neural network of composite images[J]. Journal of Highway and Transportation Research and Development, 2024, 41(9): 1-9.
- 王浩仰,潘宗俊,曹建坤,等. 基于复合图双卷积神经网络的路面裂缝识别方法[J]. 公路交通科技, 2024, 41(9): 1-9.
- [12] WANG J, ZHANG J, COHN A G, et al. Arbitrarily-oriented tunnel lining defects detection from ground penetrating radar images using deep convolutional neural networks[J]. Automation in Construction, 2022, 133: 104044.
- [13] MAN K, LIU R, LIU X, et al. Water leakage and crack identification in tunnels based on transfer-learning and convolutional neural networks[J]. Water, 2022, 14(9): 1462.
- [14] ZHOU Z, ZHANG J, GONG C. Automatic detection method of tunnel lining multi-defects via an enhanced You Only Look Once network[J]. Computer-Aided Civil and Infrastructure Engineering, 2022, 37(6): 762-780.
- [15] TAN Y, CAI R, LI J, et al. Automatic detection of sewer defects based on improved you only look once algorithm[J]. Automation in Construction, 2021, 131(6): 103912.
- [16] ZHU L, LI D B, YAN X Z, et al. Study on intelligent detection method of tunnel cracks based on improved mask R-CNN deep learning algorithm[J]. Journal of Graphics, 2023, 44(1): 177-183.
- 朱磊,李东彪,闫星志,等. 基于改进Mask R-CNN深度学习算法的隧道裂缝智能检测方法[J]. 图学学报, 2023, 44(1): 177-183.
- [17] WANG W, XU X, YANG H. Intelligent detection of tunnel leakage based on improved mask R-CNN[J]. Symmetry, 2024, 16(6): 709.
- [18] LI D, XIE Q, GONG X, et al. Automatic defect detection of metro tunnel surfaces using a vision-based inspection system[J]. Advanced Engineering Informatics, 2021, 47: 101206.
- [19] FENG Y, FENG S J, ZHANG X L, et al. A two-step deep learning-based framework for metro tunnel lining defect recognition[J]. Tunneling and Underground Space Technology, 2024, 150: 105832.
- [20] LU H, FANG M, QIU Y, et al. An anchor-free defect detector for complex background based on pixelwise adaptive multiscale feature fusion[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 72: 1-12.
- [21] LI D, LU Y, GAO Q, et al. LiteYOLO-ID: a lightweight object detection network for insulator defect detection[J]. IEEE Transactions on Instrumentation Measurement, 2024, 73: 3418082.
- [22] LUO Y, LING J, WANG J, et al. SFW-YOLO: a lightweight multi-scale dynamic attention network for weld defect detection in steel bridge inspection[J]. Measurement, 2025, 253: 117608.
- [23] WANG C Y, YE H I, LIAO H Y M. YOLOv9: learning what you want to learn using programmable gradient information[DB/OL]. <https://arxiv.org/abs/2402.13616>.
- [24] PAN X, GE C, LU R, et al. On the integration of self-attention and convolution[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2022: 815-825.
- [25] ZHANG H, LI F, LIU S, et al. DINO: DETR with improved DeNoising anchor boxes for end-to-end object detection[DB/OL]. <https://arxiv.org/abs/2203.03605>.
- [26] ZHANG S, WANG X, WANG J, et al. Dense distinct query for end-to-end object detection[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7329-7338.
- [27] LEI M, LI S, WU Y, et al. YOLOv13: real-time object detection with Hypergraph-Enhanced adaptive visual perception[DB/OL]. <https://arxiv.org/abs/2506.17733>.

(责任编辑:陈维捷)