

文章编号:1007-2780(2025)09-1356-13

基于改进YOLOv8n的城市道路病害检测算法

朱世松¹, 高虹¹, 芦碧波^{1*}, 都海静²

(1. 河南理工大学 计算机科学与技术学院, 河南 焦作 454003;

2. 修武县林业发展服务中心, 河南 焦作 454350)

摘要:针对现阶段道路病害检测算法精度低,病害尺度多变且环境复杂导致检测准确率低的问题,提出了一种YOLOv8-road城市道路病害检测算法。首先,在主干网络中引入多层级感知注意力机制(Multi-Level Perception Attention, MLPA)捕捉长距离依赖关系,提取丰富的上下文信息,增强病害特征表达能力,使模型专注于病害区域。其次,在颈部结构中将DWR_Conv(Dilated Wrapping Residual Convolution)模块引入C2f得到C2f_D模块实现多尺度特征提取,捕捉更精细的病害特征,降低路面背景对模型的干扰。最后,采用WIoU损失函数优化目标框回归,提高模型对不同类型病害的适应性,降低低质量样本对模型学习的负面影响。实验结果表明,YOLOv8-road的mAP50达98.5%,精确率和召回率分别为96.8%和96%,较原始模型YOLOv8n分别提升4.2%、3.6%和4.7%。与其他主流的目标检测模型相比,YOLOv8-road在实际道路工程的病害检测任务中具有较好的检测性能,能够满足道路工程应用中的需求。

关键词:道路工程;道路病害;YOLOv8n;YOLOv8-road;注意力机制

中图分类号:TP391.4 **文献标识码:**A **doi:**10.37188/CJLCD.2025-0101 **CSTR:**32172.14.CJLCD.2025-0101

Urban road defect detection algorithm based on improved YOLOv8n

ZHU Shisong¹, GAO Hong¹, LU Bibo^{1*}, DU Haijing²

(1. School of Computer Science and Technology, Henan Polytechnic University, Jiaozuo 454003, China;

2. Xiuwu County Forestry Development Service Center, Jiaozuo 454350, China)

Abstract: To address the challenges of low accuracy in urban road defect detection caused by varying defect scales and complex environments, this study proposes an improved detection algorithm named YOLOv8-road. The algorithm incorporates a multi-level perception attention (MLPA) mechanism into the backbone network to capture long-range dependencies and extract rich contextual information, enhancing defect feature representation and enabling the model to focus more effectively on defective regions. In the neck structure, a dilated wrapping residual convolution (DWR_Conv) module is integrated into the C2f structure, forming a new C2f_D module that improves multi-scale feature extraction and

收稿日期:2025-05-15;**修订日期:**2025-06-24.

基金项目:国家自然科学基金(No.42272178);2024年度河南省高等学校重点科研项目(No.24B520013);河南理工大学基本科研业务费专项项目(No.NSFR240508)

Supported by National Natural Science Foundation of China (No.42272178); 2024 Key Scientific Research Project of Higher Education Institutions in Henan Province (No.24B520013); Special Fund for Basic Scientific Research of Henan Polytechnic University (No.NSFR240508)

*通信联系人, E-mail: lubibo@hpu.edu.cn

facilitates the capture of fine-grained defect information while reducing interference from road surface backgrounds. Additionally, the algorithm employs the WIoU loss function to optimize bounding box regression, increasing the model's adaptability to various defect types and mitigating the negative impact of low-quality samples. Experimental results demonstrate that YOLOv8-road achieves a mean Average Precision at 50% (mAP50) of 98.5%, with a precision of 96.8% and a recall of 96.0%. Compared to the original YOLOv8n model, these metrics represent improvements of 4.2%, 3.6%, and 4.7%, respectively. The proposed YOLOv8-road algorithm exhibits superior performance in real-world urban road defect detection tasks, meeting the practical requirements of road maintenance applications.

Key words: road engineering; road defect; YOLOv8n; YOLOv8-road; attention mechanism

1 引言

道路交通是我国经济发展的基础设施,截至2023年,全国公路总里程已达543.68万公里^[1]。但由于交通荷载、雨水侵蚀等不利因素的影响,道路会出现不同类型和程度的病害。常见的道路病害包括裂缝、修补痕迹等,若不能及时发现并修复,不仅会影响道路的使用寿命,还可能带来交通安全隐患^[2]。传统道路病害检测主要依赖人工现场识别,检测速度慢、工作强度大并且存在一定的安全风险,难以满足道路养护的精准需求。近年来,随着人工智能和计算机视觉的飞速发展,其在道路工程领域的应用日益增长,为智能化道路病害检测提供了新的机遇^[3]。

人工智能中的传统机器学习算法已在识别道路病害的任务中广泛应用^[4]。Li等人^[5]将对抗学习方法和全卷积判别器结合,设计一种半监督路面裂缝检测模型,提升对道路裂缝真实情况和分割预测结果的识别能力。Akagic等人^[6]提出一种无监督裂缝检测方法,将路面图像划分为多个子图像,并采用Otsu阈值法计算子图像的特征值,识别裂缝区域,合并子图像生成最终图像,提升了裂缝检测的自动化水平。但传统机器学习算法在复杂道路病害检测场景中面对多尺度病害特征易出现漏检、误判等问题^[7]。

近年来,深度学习技术不断进步,在道路病害检测领域已有广泛应用^[8]。目标检测方法主要分为两类:两阶段检测器(如R-CNN^[9]、Faster R-CNN^[10]、Mask R-CNN^[11])通过生成候选框进行分类和回归,精准定位识别道路病害;一阶段检测器(如YOLO^[12]、SSD^[13])将病害分类和定位任务统一,速度更快,但对细小病害的检测能力有

限,整体检测精度较低。Liu等人^[14]对Mask R-CNN进行改进,应用于裂缝识别,精度虽较高,但检测速度较慢。傅幼华等人^[15]以YOLOv7算法为基础,使用K-means++聚类算法提高锚框的广泛性,提升了沥青道路病害检测精度。宣以国等人^[16]对YOLOv7进行改进,用可变形卷积代替原始卷积,采用Wasserstein距离评估方法对不同类型的裂缝实现高效检测。耿焕同等人^[17]在YOLOv8的基础上将C2f改为C2f-Faster,同时增加SE通道注意力,提高了道路病害识别的准确率。

目前道路病害检测仍面临一些挑战,需要进一步研究解决。首先,裂缝形状通常较长,导致长距离依赖关系难以捕捉;其次,部分病害形态较小,不能准确识别,容易出现误检、漏检的情况;最后,复杂环境的影响使病害特征模糊,影响模型的整体性能。针对上述道路病害检测所存在的问题,本文在YOLOv8的基础上进行相关研究,提出一种YOLOv8-road道路病害检测算法。本文贡献如下:

(1)在主干网络(Backbone)中引入MLPA注意力机制,聚焦关键特征信息,捕捉道路病害中的长距离依赖关系。

(2)将颈部(Neck)结构的C2f_D模块代替C2f模块,利用多尺度卷积和动态权重的调整,改善不同尺寸病害的检测效果。

(3)引入WIoU作为损失函数,减少复杂环境对模型检测的负面影响,提升模型在边界框回归任务中的性能。

2 模型介绍

2.1 YOLOv8模型

YOLO系列算法在目标检测领域已有广泛应

用,表现出较好的性能。2023年提出的YOLOv8^[18]相较于YOLOv5^[19]具备较高的检测精度,根据YOLOv8网络模型的深度、宽度等不同,模型被划分为n、s、m、l、x五种类型。考虑到在实际道路工程应用中需要尽可能小的检测成本,本文在YOLOv8n基础上进行改进,以提高模型在城市道路病害检测中的准确性。

2.2 YOLOv8-road 模型

在实际道路病害检测工程应用中,由于光照变化、遮挡、细小病害难以捕捉等多种干扰因素的影响,YOLOv8n模型无法满足道路工程条件

下检测精度的要求。为此,本文对YOLOv8n进行多项改进,得到YOLOv8-road模型,该模型结构如图1所示。YOLOv8-road模型主要分为3个部分:主干特征提取网络、颈部特征融合网络和目标检测头。主干网络由多个1×1卷积核、C2f、SPPF和MLPA注意力机制组成,网络中的MLPA能够捕捉长距离上下文信息。颈部由多个1×1卷积和C2f_D组成,网络中的C2f_D高效利用特征图提升不同尺度病害的特征提取效果。目标检测头中引入WIoU损失函数,有效减少复杂环境下产生的低质量样本对训练过程的影响。




图1 YOLOv8-road网络结构
Fig. 1 Network structure of YOLOv8-road

2.2.1 MLPA 注意力机制

在道路病害检测任务中,由于裂缝、修补病害的形状通常较长,这类待检测目标往往具有较大的延展性,因此需要更好地融合上下文信息进行准确检测。标准的YOLOv8n主要以局部感知为主,对于长距离依赖关系的捕获能力表现不足,无法准确把握病害的整体特征。为了解决这一问题,本文引入多层级感知注意力机制(MLPA),利用多通道机制处理病害特征,实现对病害区域

语义信息和上下文结构的全局感知,图2为MLPA的网络结构图。

MLPA是一种结合全局上下文感知、细节增强与动态加权机制的注意力结构。输入特征图X经过1×1卷积得到处理后的特征X₁,该特征随后进入多头自注意力机制(Multi-Head Self-Attention, MHSA)^[20]模块中,进一步提取全局语义信息,图3为MHSA的网络结构。

在MHSA中,特征X₁分别通过3个独立的




图2 MLPA注意力机制

Fig. 2 Multi-level perception attention




图3 MHSA注意力机制

Fig. 3 Multi-head self-attention

线性变换生成查询向量 Q 、键向量 K 和值向量 V , 计算公式如(1)所示:

$$\begin{cases} Q = X_1 W_Q \\ K = X_1 W_K \\ V = X_1 W_V \end{cases} \quad (1)$$

其中 W_Q 、 W_K 、 W_V 分别为可训练的参数矩阵。

通过查询向量和键向量相结合后得到内容相关项 QK^T ,可以计算病害区域不同像素点之间的全局相似性,捕获病害的整体形态特征以及分布规律。然而传统的自注意力机制在建模空间位置方面存在一定不足,为此MHSA引入位置信息向量 r ,将其与查询向量相结合,增强注意力机制对空间结构的感知能力。

MHSA将内容相关项 QK^T 和位置相关项 Qr^T 相加,融合语义信息和空间信息后,经Softmax函数归一化处理得到注意力权重。之后又与值向量进行加权计算,得到上下文增强特征,计算公式如式(2)所示:

$$X_{MHSA} = \text{Softmax}(QK^T + Qr^T) \cdot V \quad (2)$$

此外,模块引入Z-Pool操作以提取全局上下文信息,增强网络对病害区域的感知能力,并利用Permute操作对特征维度进行重排,为多尺度病害特征融合提供支持^[21]。Z-Pool分别利用全局平均池化和全局最大池化提取病害的整体信息和显著特征,可以有效提取特征图中多层次的全局特征,计算公式如式(3)所示:

$$\begin{cases} Z_{\text{avg}} = \text{AvgPool}(X_2) \\ Z_{\text{max}} = \text{MaxPool}(X_2) \end{cases} \quad (3)$$

接着将 Z_{avg} 和 Z_{max} 进行拼接后形成融合特征。该特征被输入到 7×7 的BasicConv卷积模块进行处理,其目的是扩大感受野捕捉长距离空间信息。卷积输出通过Sigmoid激活函数生成动态权重系数 w ,并与输入特征 X_2 逐元素相乘,突出显著病害特征,减少背景信息的干扰,计算公式如式(4)所示:

$$\begin{cases} w = \sigma(\text{BasicConv}(Z_{\text{avg}} \oplus Z_{\text{max}})) \\ X_{\text{out}} = \text{Avg}(X_2 \odot w) \end{cases} \quad (4)$$

其中:BasicConv包括卷积操作和BatchNorm归一化, σ 表示Sigmoid激活函数, $\oplus$ 表示拼接操作, $\odot$ 表示逐元素相乘,Avg表示加权后的特征进行全局平均操作。

本文设计MLPA注意力机制进行多层次提取全局特征,捕捉病害两端的上下文信息,增强

对长条状病害的识别能力。在现实养护工作中,道路病害部分与路面背景之间的对比度通常较低,尤其是形状较长的病害边界与路面背景易发生混淆,导致检测性能下降。为解决该问题,MLPA 注意力机制在空间维度和通道维度上进行跨层次的特征融合,建立全局依赖关系,结合多层次特征融合机制有效提取病害的上下文信息,最终利用动态加权机制突出病害的关键特

征,从而提升模型对长条状病害的识别能力,增强模型在复杂场景中的鲁棒性。

2.2.2 C2f_D 模块

为了应对道路病害形状变化多样,特别是细小病害难以捕捉的挑战,本文设计了 C2f_D 模块。该模块通过多尺度特征提取,精准捕捉不同形态的病害特征,使模型能够更好地识别精细病害。C2f_D 网络结构如图 4 所示。




图 4 C2f_D 网络结构

Fig. 4 C2f_D network architecture

在 C2f_D 模块中,病害特征的处理分为两个方向:一部分进入 Bottleneck_DWRC 模块,进行不同尺度的病害区域特征提取,重点关注病害的边缘特征和纹理信息;另一部分保留全局信息,减少深度处理对原始病害特征信息的损失,保证最终输出不丢失细节。这种特征融合方式有效地结合了全局信息和局部细节,既能够保留病害整体形态的全局特征,又能突出病害边缘轮廓的细节信息,减少细小病害被路面背景信息淹没的情况,增强模型的特征表达能力,提高模型对于复杂病害的适应性。

Bottleneck_DWRC 模块中 DWR_Conv 是改

进版本的 DWR 卷积^[22],该结构能够有效简化特征处理的操作过程,提高病害区域特征的识别效率,DWR_Conv 结构如图 5 所示。DWR 卷积输入特征经过 3×3 卷积处理得到初步特征 X_c ,这些特征被分成 3 部分,分别采用不同扩张率的深度可分离卷积进行处理,目的是增大感受野提取不同尺度病害的上下文信息,计算公式如式(5)所示:

$$X_{\text{dilated}} = \text{cat}(C_{d1} * X_c, C_{d3} * X_c, C_{d5} * X_c), \quad (5)$$

其中,*为卷积操作, C_{di} 表示不同扩张率的卷积, X_{dilated} 为经过不同扩张卷积后处理的拼接特征,cat是拼接操作。




图 5 DWR_Conv 网络结构

Fig. 5 DWR_Conv network architecture

这些处理过的特征经过 1×1 卷积进行融合,再利用残差连接与原始特征相加,实现多尺度病

害特征的有效融合,解决病害形态多样的问题,计算公式如式(6)所示:

$$X_{\text{out}} = C_{1 \times 1} * X_{\text{dilated}} + X, \quad (6)$$

其中: $C_{1 \times 1}$ 为 1×1 卷积, X 为原始特征。

本文设计的 C2f_D 模块从 3 个方面对模型性能产生有利的影响: 利用多尺度特征提取机制有效捕获不同形态和尺度病害特征, 提高模型对结构多变病害的识别能力; 使用残差机制保留原始病害特征信息, 降低路面等背景噪声对模型产生的负面影响; 提升模型对边缘模糊和尺度较小病害的感知水平, 增强其在多样化病害场景的泛化能力, 从而提高模型的整体检测效率。

2.2.3 WIoU 损失函数

在实际道路病害检测工程应用中, 由于背景复杂、遮挡等不利因素的影响, 难免会有低质量样本的存在。若模型只关注采光良好、病害区域明显等高质量样本, 容易导致模型过拟合于高质量样本, 降低其对低质量样本的泛化能力, 在该应用中出现遇到低质量数据检测效果不佳的情况。YOLOv8n 所用到的 CIoU 损失函数在遇到质量参差不齐的数据时存在一定局限, 因此本文引入 WIoU 损失函数^[23] 代替 CIoU, 使其适应道路病害数据质量的差异性。WIoU 的计算公式如式(7)所示:

$$\begin{cases} R_{\text{WIoU}} = \exp\left(\frac{(x - x_{\text{gt}})^2 + (y - y_{\text{gt}})^2}{(\omega_g^2 + H_g^2) *}\right), \\ L_{\text{WIoU}} = r R_{\text{WIoU}} L_{\text{IoU}} \end{cases}, \quad (7)$$

其中: (x, y) 和 $(x_{\text{gt}}, y_{\text{gt}})$ 分别是预测框和真实框的中心坐标; ω_g 和 H_g 表示真实框的宽度和高度; $*$ 表示从计算图分离, 防止梯度爆炸; R_{WIoU} 为 WIoU 的惩罚项, 解决 IoU 对于中心点偏移不敏感的情况; r 为聚焦系数。

聚焦系数 r 用来动态控制梯度的增益, 计算公式如式(8)所示:

$$r = \frac{\beta}{\delta \alpha^{\beta - \delta}}, \quad (8)$$

其中: α 、 δ 为超参数; β 表示衡量当前损失 L_{IoU} 和最优损失 L_{IoU}^* 的比例, 动态调整边界框优化力度, 减少低质量样本的梯度影响, 降低难以检测目标对训练过程产生的负面影响。计算公式如式(9)所示:

$$\beta = \frac{L_{\text{IoU}}^*}{L_{\text{IoU}}} \in [0, +\infty), \quad (9)$$

L_{IoU} 的计算公式如式(10)所示:

$$L_{\text{IoU}} = 1 - \text{IoU}. \quad (10)$$

本文引入 WIoU 损失函数提升模型在处理背景复杂等低质量图像时的检测能力, 有效减少模型误检的风险。该方法在训练过程中有效平衡了低质量样本和高质量样本的影响, 避免模型过度关注高质量样本而导致对低质量样本的适应能力下降。该方法通过优化检测框的定位精度, 确保病害区域能够被准确识别, 增强模型的泛化能力, 使其在不同质量图像和复杂环境下依然保持较高的检测精度, 确保检测结果的稳定性与可靠性。

3 实验数据集和设置

3.1 数据集

本文通过车载摄像机采集数据, 包含河南省济源市天坛路、河南省商丘市南京路以及河南省郑州市智慧岛大厦附近的城市道路图像。图像尺寸为 512 像素 $\times$ 512 像素, 经过筛选后获得带有道路病害的图片作为数据集。为了更贴合实际道路工程应用, 数据采用垂直旋转、亮度调整和模糊处理 3 种数据增强方式^[24], 模拟低光照、模糊等复杂环境下的道路场景, 从而扩充数据集, 提升模型在复杂环境下的鲁棒性和泛化能力, 具体操作如图 6 所示。数据主要捕获 3 种常见道路病害类型, 分别为纵向裂缝(D00)、横向裂缝(D10)和修补(Repairment)。对于处理后的 2 276 张图像数据集, 按 8:1:1 的比例随机划分, 分为训练集、验证集和测试集。




图6 数据增强

Fig.6 Data augmentation

3.2 实验环境与评估参数

实验训练阶段所使用的深度学习框架为 PyTorch,硬件测试环境为 NVIDIA GeForce RTX 3090,并使用 SGD 作为优化函数训练模型。训练过程中工作线程数为 8,训练轮次为 500,批量大小为 16。

为了全面评估 YOLOv8-road 的检测性能,本文选择精确率(Precision, P)、召回率(Recall, R)、所有类别平均精度均值(mean of Average Precision, mAP)作为评价指标。此外,采用参数量(Parameters)和每秒千兆浮点运算次数(GFLOPs)作为评价模型复杂度的评价指标。相关计算公式如式(11)~(13)所示:

$$P = \frac{TP}{TP + FP}, \tag{11}$$

$$R = \frac{TP}{TP + FN}, \tag{12}$$

$$\begin{cases} AP = \int_0^1 P(r)dr \\ mAP = \frac{1}{n} \sum_{i=1}^n AP_i \end{cases}, \tag{13}$$

其中:TP 为检测出正确道路病害样本数量,FP 为检测结果中错误识别的道路病害样本数量,FN 为没有检测到的实际存在道路病害的样本数,AP 为单个类别的平均精度, n 为类别总数,

AP_i 是第 i 类的平均精度。

4 实验结果及分析

4.1 不同注意力机制对比实验

为了评估模型所采用的 MLPA 注意力机制与其他注意力机制的性能差异,实验使用 ECA (Efficient Channel Attention) 模块^[25]、SimAM (Simple Attention Module)模块^[26]、LSKA (Large Separable Kernel Attention)模块^[27]、CAA (Context Anchor Attention)模块^[28]与 MLPA 模块进行比较,实验结果如表 1 所示。

通过对比可以明显看出,本文所采用的 MLPA 注意力机制在 mAP50 值上表现最佳,同时召回率达到 91.2%,精确率达 95.9%,表明 MLPA 能有效减少漏检、误检的情况。相比之下,LSKA 的召回率最低,是因为其依赖固定空间卷积核而无法适应长距离病害特征。ECA 和 SimAM 的 mAP50 均为 93.8%,但它们的精确率和召回率有所差异,并且相较于 MLPA 更容易出现漏检、误检的情况。CAA 注意力机制专注于通道维度的信息,检测效果不及 MLPA。总体而言,MLPA 注意力机制具有处理长条状病害特征的能力,能够聚焦病害关键区域,在实际道路工程应用中的病害检测性能优于其他注意力机制。

表 1 不同注意力机制的实验结果
Tab. 1 Experimental results of different attention mechanisms

YOLOv8n	Parameters/M	GFLOPs	Precision/%	ReCall/%	mAP50/%	mAP(50~95)/%
+ECA	3.006	8.1	91.2	90.0	93.8	68.7
+SimAM	3.006	8.1	93.3	89.4	93.8	68.6
+LSKA	3.077	8.1	95.3	89.1	94.5	69.0
+CAA	3.207	8.4	94.1	89.9	94.7	70.0
+MLPA(Ours)	3.221	8.3	95.9	91.2	96.4	71.4

注:粗体数字代表最优值

4.2 不同损失函数对比实验

为了评估模型所采用的 WIoU 损失函数与其他损失函数在道路病害检测任务中的性能差异,实验选取 Focal_DIoU、EIoU、MPDIoU、PIoU 与本文的 WIoU 进行比较,实验结果如表 2 所示。结果表明,在所有对比的损失函数中,本文引入的 WIoU 性能表现最佳,mAP50 达到 95.3%,说明该方法在训练过程中能有效减少低质量样本

对回归结果的干扰,提升模型的整体检测精度。

相比之下,EIoU 的检测精度相对较低,主要是因为回归惩罚机制较为单一,未能充分考虑样本质量对模型训练的影响,导致对低质量样本的病害目标识别能力有限。Focal-DIoU、MPDIoU 和 PIoU 虽部分指标表现良好,但整体检测精度均不如 WIoU,表明仅依赖边界框的几何信息进行优化在提升模型整体性能方面仍存在一定的

表 2 不同损失函数的实验结果
Tab. 2 Experimental results of different loss functions

YOLOv8n	Parameters/M	GFLOPs	Precision/%	ReCall/%	mAP50/%	mAP(50~95)/%
+Focal_DIoU	3.006	8.1	92.8	89.7	94.6	69.4
+EIoU	3.006	8.1	93.1	90.1	93.5	68.7
+MPDIoU	3.006	8.1	93.2	90.2	94.1	68.6
+PIoU	3.006	8.1	94.2	89.8	94.6	70.5
+WIoU(Ours)	3.006	8.1	94.6	89.9	95.3	70.5

注:粗体数字代表最优值

局限,难以有效处理实际道路场景中出现低质量样本的问题。WIoU 通过引入动态聚焦系数,有效调节不同质量样本的梯度权重,实现更合理的平衡机制,既有效避免模型过拟合于高质量样本,又抑制低质量样本对模型训练产生的负面影响,从而提升模型检测性能的稳定性和可靠性。

4.3 消融实验

为了验证本文改进方法在道路病害检测中的有效性,本文以 YOLOv8n 为基础模型进行消融实验,这些实验均是在保持相同的实验环境以及训练参数下进行的,实验数据如表 3 所示。标准 YOLOv8n 的 mAP50 为 94.3%,参数量为 3.006M,精确率为 93.2%。A 组在此基础上引入 MLPA 注意力机制后,GFLOPs 仅增加 0.2,但精确率提升 2.7%,mAP50 提高 2.1%,表明该模

块优化了全局信息的提取,使模型更精准地关注病害区域的主要特征。B 组将颈部的 C2f 改为 C2f_D 后,参数量增加 0.203M,精确率和召回率均较 YOLOv8n 有所提升,mAP50 提高 2.5%,证明该模块能够提升模型对各种病害尺度的敏感度,提高了训练稳定性。C 组展示了模型在引入 Wiou 损失函数后参数量和 GFLOPs 没有变化,但精确率和 mAP50 仍有所提升,说明 Wiou 损失函数在处理样本质量不平衡的问题中存在一定优势。最终,G 组结合以上 3 项改进构建了 YOLOv8-road,实验结果显示,该模型的精确率和召回率较 D、E、F 组均有所提高,mAP50 进一步提升到 98.5%,mAP(50~95)达到 78.1%。综上所述,YOLOv8-road 可以增强模型的检测能力,有效降低误检率和漏检率,验证了其在实际道路病害检测中的可行性及应用价值。

表 3 消融实验结果
Tab. 3 Ablation study results

Method	MLPA	C2f_D	WIoU	Precision/%	ReCall/%	Parameters/M	GFLOPs	mAP50/%	mAP(50~95)/%
YOLOv8n				93.2	91.3	3.006	8.1	94.3	70.5
A	✓			95.9	91.2	3.221	8.3	96.4	71.4
B		✓		95.0	92.0	3.203	8.5	96.8	74.9
C			✓	94.6	89.9	3.006	8.1	95.3	70.5
D	✓	✓		96.0	94.3	3.417	8.7	98.2	77.8
E	✓		✓	94.6	93.3	3.221	8.3	96.9	72.6
F		✓	✓	94.5	91.0	3.203	8.5	97.6	75.7
G	✓	✓	✓	96.8	96.0	3.417	8.7	98.5	78.1

注:粗体数字代表最优值

考虑到本文所使用改进方法的训练过程较多,为便于对比分析仅选取 4 个训练过程进行比较,如图 7 所示,分别是标准算法 YOLOv8n、主干网络中引入的 MLPA 模型、结合 C2f_D 并采用 Wiou 损失函数的模型以及最终改进的 YOLOv8-road 算法。在相同的实验条件和训练参数下,图 7(a)

展示了各算法精确率的变化过程,图 7(b)展示了召回率的训练过程,图 7(c)反映了 mAP50 的训练趋势,图 7(d)展示了 mAP(50~95)的训练情况。从结果中能够明显看出,YOLOv8-road 的召回率和精确率均是最高,能够有效减少误检率和漏检率,并且它的检测精度也是最高的。




图 7 训练过程
Fig. 7 Training process

为了更直观地展示本文算法对不同病害目标的检测效果,图 8(a)组展示了横向裂缝(D10)

的检测结果,与 YOLOv8n 相比,检测精度提升了 7%;图 8(b)组展示了纵向裂缝(D00)的检测情况;图 8(c)组展示了修补(Repairment)的检测效果,3 组图像的检测精度均有不同程度的提升。通过对比结果图能够看出,YOLOv8-road 模型提供了更准确的道路病害检测结果。

为了直观验证本文改进方法在多尺度病害和细小病害检测任务中的有效性,本文引入 Grad-CAM 热力图对模型的关注区域进行可视化分析,相关检测结果如图 9 所示。图 9(a)展示了横向裂缝和细小纵向裂缝的检测情况,YOLOv8n 对于细小裂缝区域的响应程度较弱,存在关注不充分的问题;而改进后的 YOLOv8-road 对于纵向裂缝的关注程度更高,表现出更明显的激活响应,说明改进后的模型具备更精细的特征感知能力。图 9(b)展示了在车辆较多的复杂场景下的检测效果,YOLOv8n 对于该病害区域几乎未做出响应;而 YOLOv8-road 在车辆边缘激活目标病害区域,表现出更强的特征提取能力,能够有效应对复杂背景下所产生的干扰。图 9(c)展示了多尺度病害的检测效果,改进前后的模型对大




图 8 算法改进前后的检测结果。(a)横向裂缝;(b)纵向裂缝;(c)修补。

Fig. 8 Detection results before and after algorithm improvement. (a) Transverse crack; (b) Longitudinal crack; (c) Repairment.




图 9 算法改进前后的 Grad-CAM 可视化结果。(a)细小病害;(b)复杂背景下的病害;(c)多尺度病害。

Fig. 9 Grad-CAM visualization results before and after algorithm improvement. (a) Small-scale defects; (b) Damages under complex background; (c) Multi-scale defects.

尺度病害均表现出较高的关注度,但对于小尺度区域 YOLOv8n 的响应较弱,而 YOLOv8-road 能同时关注到不同尺度的病害区域,表现出更好的多尺度检测能力。

综上所述, YOLOv8-road 在细小病害检测、抗复杂背景干扰以及多尺度目标识别等方面均表现出更好的特征关注能力,能够有效识别多尺度和细小病害区域,进一步提升模型在实际复杂

道路场景下检测的鲁棒性和准确性。

4.4 不同算法的对比实验

为了进一步验证 YOLOv8-road 在道路病害检测任务中的检测效果与性能优势,本文使用相同数据集与其他算法进行对比实验,包括 YOLOv7n^[29]、YOLOv7s、YOLOv7-tiny、YOLOv9-t^[30]、YOLOv10n^[31]、YOLOv10s、YOLOv11n^[32]、FastestDet^[33]、Road-YOLOv5^[34]、Road-EfficientDet^[35],实验结果如表 4 所示。相较于其他检测算法, YOLOv8-road 具有较低的计算复杂度,其参数数量为 3.417M,GFLOPs 为 8.7,mAP50 的指标达到 98.5%,展示了较高的检测精度。具体而言,与 YOLOv7n、YOLOv7x、YOLOv9-t 相比, YOLOv8-road 具备更小的参数数量和计算量,同时 mAP50 分别提高了 2.3%、1.7%、3.0%。与 YOLOv7-tiny、YOLOv10n、YOLOv10s、YOLOv11n、FastestDet、Road-YOLOv5、Road-EfficientDet 相比,虽然 YOLOv8-road 并非参数数量最少和计算复杂度最小的模型,但其检测精度却是最高。实验结果表明,与其他较为经典的目标检测算法相比,本文所使用的 YOLOv8-road 算法在保持较小模型规模和计算开销的同时,实现了更优秀的检测性能,证明了该算法在道路病害检测的工程领域是有效方案,具有较高的道路工程应用价值。

为了更直观地比较 YOLOv8-road 与其他算法在道路病害检测中的性能差异,本文选取 YOLOv8-road、YOLOv7-tiny、YOLOv9n、

表 4 不同算法的对比实验结果

Tab. 4 Comparison of experimental results for different algorithms

Methods	Parameters/M	GFLOPs	mAP50/%	mAP(50~95)/%
YOLOv7n	37.21	105.1	96.2	83.1
YOLOv7-tiny	6.20	13.2	94.0	69.2
YOLOv7x	70.83	188.9	96.8	81.4
YOLOv9-t	60.80	266.1	95.5	73.7
YOLOv10n	2.70	8.2	93.0	67.8
YOLOv10s	8.04	24.5	94.4	71.9
YOLOv11n	2.58	6.3	94.2	68.3
FastestDet	0.24	1.7	71.4	41.6
Road-YOLOv5	3.85	8.3	95.4	76.8
Road-EfficientDet	6.58	6.0	93.0	53.6
YOLOv8-road	3.42	8.7	98.5	78.1

注:粗体数字代表最优值

YOLOv11n、FastestDet、Road-YOLOv5 以及 Road-EfficientDet 这 7 种算法对不同类型的病害图像进行检测,检测效果如图 10 所示。YOLOv8-road 模型相比于其他算法具有较高的检测精度,能够更准确地识别出病害目标,减少漏检和误检的情况。图 10(a)展示了各算法对于横向裂缝的检测结果,其中 YOLOv7-tiny 和 Road-YOLOv5 存在漏检情况;图 10(b)展示了对块状修补的检测

测情况, YOLOv7-tiny、YOLOv11n、FastestDet、Road-EfficientDet 均存在误检的情况;图 10(c)展示了多种类型病害的检测结果,能够明显看出, YOLOv8-road 算法检测精度最高。综上所述,改进后的 YOLOv8-road 在多种类型病害及多数量病害的检测任务中表现更好,漏检率和误检率较低,整体的检测效果相比较其他算法有明显提升。




图 10 对比实验结果。(a)多条横向裂缝;(b)修补;(c)多种类型裂缝。

Fig. 10 Comparison of experimental results. (a) Multiple transverse cracks; (b) Repairment; (c) Multiple types of cracks.

5 结 论

本文提出一种 YOLOv8-road 道路病害检测算法,有效解决了 YOLOv8n 在该领域所面临的检测精度低的挑战。本文在主干网络末端引入 MLPA 注意力机制,能够有效地提取上下文信息,并整合全局信息,提高模型对具有长距离依赖关系的病害特征的学习能力;其次在颈部引入 C2f_D 模块,实现特征图感受野的扩展,增强模型对于多尺度病害的检测能力,尤其在细小病害的检测方面表现更加突出;最后引入 WIoU 损失函数,以优化损失计算方式平衡复杂环境下不同

质量样本对模型的影响。实验结果表明,改进后的 YOLOv8-road 算法比标准 YOLOv8n 算法在 mAP50 的指标上提升了 4.2%,可以有效提取道路病害信息,满足道路工程应用中的检测需求。与现有目标检测算法相比, YOLOv8-road 模型具有更高的检测精度。改进后的 YOLOv8-road 模型结构简洁、检测精度较高,适用于实际道路病害检测工程应用。在道路维护工程中, YOLOv8-road 算法在前期病害检测任务中表现出色,为后续道路养护工作提供了有力支持。今后将针对大雨雷暴等天气情况进行研究,进一步提高算法的稳定性和鲁棒性。

参 考 文 献:

[1] 交通运输部. 2023 年交通运输行业发展统计公报[N]. 中国交通报, 2024-06-18(002).
Ministry of Transport. 2023 statistical bulletin on the development of the transportation industry [N]. China Transportation News, 2024-06-18(002). (in Chinese)

- [2] 胥铁峰,黄河,张红民,等. 基于改进YOLOv8的轻量化道路病害检测方法[J]. 计算机工程与应用,2024,60(14): 175-186.
XU T F, HUANG H, ZHANG H M, *et al.* Lightweight road damage detection method based on improved YOLOv8 [J]. *Computer Engineering and Applications*, 2024, 60(14): 175-186. (in Chinese)
- [3] 柳雨豪,罗浩原,黄晓明. 智能公路系统下的路面病害图像检测技术综述[J]. 现代交通与冶金材料,2023,3(1):9-20.
LIU Y H, LUO H Y, HUANG X M. Development of road distress image detection based on intelligent road system [J]. *Modern Transportation and Metallurgical Materials*, 2023, 3(1): 9-20. (in Chinese)
- [4] 周燊入,王哲涛,杨思危,等. 化学计量学和深度学习方法在拉曼光谱处理方面的应用研究进展[J]. 分析化学, 2023,51(8):1232-1242.
ZHOU C R, WANG Z T, YANG S W, *et al.* Application progress of chemometrics and deep learning methods in Raman spectroscopy signal processing [J]. *Chinese Journal of Analytical Chemistry*, 2023, 51(8): 1232-1242. (in Chinese)
- [5] LI G, WAN J, HE S H, *et al.* Semi-supervised semantic segmentation using adversarial learning for pavement crack detection [J]. *IEEE Access*, 2020, 8: 51446-51459.
- [6] AKAGIC A, BUZA E, OMANOVIC S, *et al.* Pavement crack detection using Otsu thresholding for image segmentation [C]. 2018 41st International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO). Opatija: IEEE, 2018: 1092-1097.
- [7] 徐晓龙,张成霖,翁奇萍,等. 机器学习辅助图像识别红细胞抗氧化研究[J]. 分析化学,2024,52(3):429-438.
XU X L, ZHANG C L, WENG Q P, *et al.* Study on erythrocyte antioxidation based on machine learning-assisted image recognition [J]. *Chinese Journal of Analytical Chemistry*, 2024, 52(3): 429-438. (in Chinese)
- [8] 刘振邦,张硕,包宇,等. 深度学习在化学信息学中的应用研究进展[J]. 应用化学,2023,40(3):360-373.
LIU Z B, ZHANG S, BAO Y, *et al.* Progress of application research on cheminformatics in deep learning [J]. *Chinese Journal of Applied Chemistry*, 2023, 40(3): 360-373. (in Chinese)
- [9] GIRSHICK R, DONAHUE J, DARRELL T, *et al.* Rich feature hierarchies for accurate object detection and semantic segmentation [C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Columbus: IEEE, 2014: 580-587.
- [10] REN S Q, HE K M, 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.
- [11] HE K M, GKIOXARI G, DOLLÁR P, *et al.* Mask R-CNN [C]//*Proceedings of the IEEE International Conference on Computer Vision*. Venice: IEEE, 2017: 2980-2988.
- [12] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger [C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Honolulu: IEEE, 2017: 6517-6525.
- [13] LIU W, ANGUELOV D, ERHAN D, *et al.* SSD: Single shot MultiBox detector [C]//*Proceedings of the 14th European Conference on Computer Vision*. Amsterdam: Springer, 2016: 21-37.
- [14] LIU Z, YEOH J K W, GU X Y, *et al.* Automatic pixel-level detection of vertical cracks in asphalt pavement based on GPR investigation and improved Mask R-CNN [J]. *Automation in Construction*, 2023, 146: 104689.
- [15] 倪昌双,李林,罗文婷,等. 改进YOLOv7的沥青路面病害检测[J]. 计算机工程与应用,2023,59(13):305-316.
NI C S, LI L, LUO W T, *et al.* Disease detection of asphalt pavement based on improved YOLOv7 [J]. *Computer Engineering and Applications*, 2023, 59(13): 305-316. (in Chinese)
- [16] 宣以国,余成波,蒋启超,等. 基于改进YOLOv7的道路裂缝和坑洞检测算法[J]. 科学技术与工程,2024,24(17): 7205-7213.
XUAN Y G, YU C B, JIANG Q C, *et al.* Improved YOLOv7 road crack and pothole detection algorithm [J]. *Science Technology and Engineering*, 2024, 24(17): 7205-7213. (in Chinese)
- [17] 耿焕同,刘振宇,蒋骏,等. 基于改进YOLOv8的嵌入式道路裂缝检测算法[J]. 计算机应用,2024,44(5):1613-1618.
GENG H T, LIU Z Y, JIANG J, *et al.* Embedded road crack detection algorithm based on improved YOLOv8 [J]. *Journal of Computer Applications*, 2024, 44(5): 1613-1618. (in Chinese)
- [18] VARGHESE R, SAMBATH M. YOLOv8: a novel object detection algorithm with enhanced performance and robustness [C]. 2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS). Chennai: IEEE, 2024: 1-6.
- [19] 王鹏飞,黄汉明,王梦琪. 改进YOLOv5的复杂道路目标检测算法[J]. 计算机工程与应用,2022,58(17):81-92.
WANG P F, HUANG H M, WANG M Q. Complex road target detection algorithm based on improved YOLOv5 [J]. *Computer Engineering and Applications*, 2022, 58(17): 81-92. (in Chinese)

- [20] SRINIVAS A, LIN T Y, PARMAR N, *et al.* Bottleneck transformers for visual recognition [C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Nashville: IEEE, 2021: 16514-16524.
- [21] MISRA D, NALAMADA T, ARASANIPALAI A U, *et al.* Rotate to attend: convolutional triplet attention module [C]//*Proceedings of the IEEE Winter Conference on Applications of Computer Vision*. Waikoloa: IEEE, 2021: 3138-3147.
- [22] WEI H R, LIU X, XU S C, *et al.* DWRSeg: rethinking efficient acquisition of multi-scale contextual information for real-time semantic segmentation [J/OL]. *arXiv*, 2022: 2212.01173.
- [23] TONG Z J, CHEN Y H, XU Z W, *et al.* Wise-IoU: bounding box regression loss with dynamic focusing mechanism [J/OL]. *arXiv*, 2003: 2301.10051.
- [24] 郑运, 杨思雨, 王涛, 等. 基于数据增强策略和卷积神经网络的近红外光谱分析研究[J]. *分析化学*, 2024, 52(9): 1266-1276.
- ZHENG Y, YANG S Y, WANG T, *et al.* Near infrared spectral analysis based on data augmentation strategy and convolutional neural network [J]. *Chinese Journal of Analytical Chemistry*, 2024, 52(9): 1266-1276. (in Chinese)
- [25] WANG Q L, WU B G, ZHU P F, *et al.* ECA-Net: efficient channel attention for deep convolutional neural networks [C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle: IEEE, 2020: 11531-11539.
- [26] YANG L X, ZHANG R Y, LI L D, *et al.* SimAM: a simple, parameter-free attention module for convolutional neural networks [C]//*Proceedings of the 38th International Conference on Machine Learning*. Online: PMLR, 2021: 11863-11874.
- [27] LAU K W, PO L M, REHMAN Y A U. Large separable kernel attention: rethinking the large kernel attention design in CNN [J]. *Expert Systems with Applications*, 2024, 236: 121352.
- [28] CAI X H, LAI Q X, WANG Y W, *et al.* Poly kernel inception network for remote sensing detection [C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Seattle: IEEE, 2024: 27706-27716.
- [29] 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]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Vancouver: IEEE, 2023: 7464-7475.
- [30] WANG C Y, YE H I, MARK LIAO H Y. YOLOv9: Learning what you want to learn using programmable gradient information [C]//*Proceedings of the 18th European Conference on Computer Vision*. Milan: Springer, 2025: 1-21.
- [31] WANG A, CHEN H, LIU L H, *et al.* YOLOv10: real-time end-to-end object detection [C]//*Proceedings of the 38th Conference on Neural Information Processing Systems*. Vancouver: NeurIPS, 2024: 107984-108011.
- [32] KHANAM R, HUSSAIN M. YOLOv11: an overview of the key architectural enhancements [J/OL]. *arXiv*, 2024: 2410.17725.
- [33] WEI Z W, YANG J, LI Z Y. FF-VO: fast visual odometry for dynamic environment based on FastestDet [C]//*Proceedings of the 2024 36th Chinese Control and Decision Conference (CCDC)*. Xi'an: IEEE, 2024: 5026-5031.
- [34] 文权锐, 高玮军. 基于改进YOLOv5的道路病害检测算法研究[J]. *计算机技术与发展*, 2025, 35(2): 191-198.
- WEN Q R, GAO W J. Research on road disease detection algorithm based on improved YOLOv5 [J]. *Computer Technology and Development*, 2025, 35(2): 191-198. (in Chinese)
- [35] NADDAF-SH S, NADDAF-SH M M, KASHANI A R, *et al.* An efficient and scalable deep learning approach for road damage detection [C]//*Proceedings of the 2020 IEEE International Conference on Big Data (Big Data)*. Atlanta: IEEE, 2020: 5602-5608.

作者简介:



朱世松,男,博士,教授,2009年于日本国立山形大学获得博士学位,主要从事图像处理的研究。E-mail: zss@hpu.edu.cn



芦碧波,男,博士,教授,2008年于吉林大学获得博士学位,主要从事人工智能和图像处理的研究。E-mail: lubibo@hpu.edu.cn