

DOI:10.19651/j.cnki.emt.2518883

基于YOLOv8改进的无人机航拍路面损伤检测算法*

张亚军 苗皓源 马薇 马冲

(新疆大学软件学院 乌鲁木齐 830091)

摘要: 针对无人机航拍路面损伤检测任务中,现有路面损伤检测算法存在模型复杂度过高以及复杂背景下漏检、误检的问题,提出了一种轻量化的路面损伤检测算法DFS-YOLO。首先,提出C2f-DWR模块,引入多膨胀率并行空洞卷积结构,扩大模型感受野,增强对高层语义信息的利用。其次,设计了轻量化的快速层次尺度特征金字塔FHSFPN,在减少模型冗余的同时提升特征融合效果。最后,引入ShapeIoU损失函数,关注路面损伤的自身形状与尺度,提高模型的鲁棒性。实验结果表明,DFS-YOLO在China Drone和UAPD数据集上的mAP50分别较YOLOv8s提升4.6%和2.1%,参数量和计算量分别降低39.1%和20.4%,实现了轻量化与准确性的良好平衡,展现出较高的实际应用潜力。

关键词: 路面损伤检测;YOLOv8;C2f-DWR;FHSFPN;ShapeIoU;轻量化

中图分类号: TP391.4;TN919.8 **文献标识码:** A **国家标准学科分类代码:** 520.20

YOLOv8-based improved algorithm for road damage detection in UAV aerial images

Zhang Yajun Miao Haoyuan Ma Wei Ma Chong
(School of Software, Xinjiang University, Urumqi 830091, China)

Abstract: In road damage detection tasks using UAV aerial images, existing algorithms face challenges including high computational complexity, false negatives, and false positives in complex backgrounds. To address these problems, we propose a lightweight road damage detection model, DFS-YOLO. First, we introduce the C2f-DWR module, which employs a parallel structure with dilated convolutions of multiple dilation rates to expand the model's receptive field and enhance the utilization of high-level semantic information. Second, we design a lightweight Faster Hierarchical Scale-based Feature Pyramid Network (FHSFPN) to reduce model complexity while improving feature fusion. Finally, we introduce the ShapeIoU loss function, which focuses on the shape and scale of road damage to improve the model's robustness. Experimental results demonstrate that DFS-YOLO outperforms YOLOv8s, achieving a 4.6% and 2.1% improvement in mAP50 on the China Drone and UAPD datasets, respectively. Additionally, the model reduces the number of parameters and computational complexity by 39.1% and 20.4%, respectively, achieving a good balance between lightweight design and accuracy. These results highlight its significant potential for practical applications.

Keywords: road damage detection;YOLOv8;C2f-DWR;FHSFPN;ShapeIoU;lightweight

0 引言

面向交通强国“安全、便捷、高效、绿色、经济”的建设目标,推进公路基础设施数字化检测与预防性养护已成为提升路网全生命周期服务效能的核心突破口。在多元化交通体系中,公路网络作为覆盖范围最广的基础性运输载体,承担着串联多种运输模式、提升综合交通效能的关键支撑作用。据《2023年交通运输行业发展统计公报》^[1]显示,全国

公路总里程已突破543万千米,较上年新增超过8万千米,路网密度提升至每百平方公里56.63千米,增幅达每百平方公里0.85千米,公路规模扩张与养护需求矛盾日益凸显。在公路的使用过程中,由于气候变化、极端荷载与材料疲劳等复合因素,会逐渐导致路面出现不同程度的各种损害,这些损害不仅影响行车舒适性,而且大幅缩短道路设计使用年限,甚至可能引发交通事故。因此,需要定期开展道路损害巡查,并对道路损害进行修补。

收稿日期:2025-05-22

*基金项目:新疆维吾尔自治区自然科学基金面上项目(2022D01C54)资助

传统人工巡检依赖主观经验判断,存在效率低下、主观偏差及交通干扰等问题,难以满足大规模路网的实时监测需求。近年来,随着深度学习快速发展,基于深度学习的目标检测技术通过端到端特征学习机制,突破了传统人工特征工程的局限性,为自动化损伤识别提供了新范式。目标检测技术主要分为单阶段目标检测和两阶段目标检测。单阶段目标检测以 YOLO (you only look once) 系列, SSD (single shot multi-box detector)^[2] 系列等为代表。两阶段目标检测以 R-CNN (region-based convolutional neural networks)^[3]、Faster-RCNN (faster region-based convolutional neural network)^[4] 等为代表。单阶段目标检测通过将目标定位和分类任务统一到神经网络中完成,避免了两阶段目标检测中先生成候选区域的复杂计算流程,显著提升推理效率。YOLO 系列算法作为单阶段目标检测的代表性模型,近年来,有很多学者将 YOLO 算法运用到道路损伤识别中并进行深入研究。Wan 等^[5] 提出了一种基于改进 YOLOv5s 的道路损伤检测轻量级方法 YOLO-LRDD,减少了模型的复杂度,提升计算效率。张咏琪等^[6] 在 YOLOv7 的基础上,提出了 Crack-YOLOv7,增强了道路裂缝特征图上下文融合能力,改善了道路裂缝检测精度。Wang 等^[7] 提出了一种基于 YOLOv8s 的道路损伤检测方法 YOLO-RD,在主干部分引入了星形操作模块 (star operation module, SOM) 增强对细小道路裂缝的敏感性,并在颈部网络引入了多尺度辅助融合模块 (multi-dimensional auxiliary fusion, MAF) 进一步融合多尺度特征。Liu 等^[8] 提出一种基于 YOLOv8n 的道路缺陷检测改进模型 RIEC-YOLO,使用 RepViT 代替了 YOLOv8 的主干网络,提高了检测精度,并使用 ConvNeXtV2 结构嵌入 C2f 取代原有的 C2f 模块,提高对重要损伤特征的敏感度,最后提出 iEMA 注意力机制模块增强对缺陷的多尺度检测能力。

随着无人机技术的成熟和生产成本的降低,其在道路巡查中的应用越来越广泛。无人机的灵活性和高效性使其能够显著提升道路巡查的效率,有效降低人工巡查所需的时间与人力成本,克服了传统巡检的空间覆盖局限与人为观测偏差,同时避免对交通通行效率产生影响。近几年,有越来越多的研究人员利用无人机采集的图像,结合 YOLO 系列算法,实现了对道路损害的自动化识别和定位。Zhang 等^[9] 对 YOLOv3 进行改进,提出了一种多级注意力机制模块 (multi-level attention block, MLAB) 来增强模型对关键特征的关注。Zhang 等^[10] 基于 YOLOv5s 提出了一种无人机图像道路裂缝检测模型 USSC-YOLO,使用了 ShuffleNetV2 代替 YOLOv5 的主干网络,减少计算开销,实现模型轻量化,并在颈部网络中引入 Swin Transformer 块,提升对小尺度裂缝的特征提取能力,减少漏检和误检率。Du 等^[11] 提出了一种无人机图像的道路裂缝检测方法 LEE-YOLO,在 YOLOv8n 的基础上引入 GhostConv 网络

和创新的 SGC2f 结构,显著减少模型的参数数量和计算复杂度,并在颈部网络采用高效双向特征金字塔网络 (efficient bidirectional feature pyramid network, EBiFPN) 增强不同尺度特征的融合,提高对关键特征的关注。Geng 等^[12] 提出一种基于 YOLOv8s 算法的改进模型 SDFC-YOLO,用于无人机道路裂缝检测,通过引入动态下采样模块 (dynamic downsampling module, DDM) 解决感受野固定的问题,并在原始 YOLOv8 的主干和颈部网络之间引入高级特征引导选择模块 (high-level feature guided selection module, HFGSM),提取边界特征增强检测效果。

尽管现有方法通过轻量化设计与特征增强模块优化了道路损伤检测性能,但在无人机路面损伤检测场景中仍面临两大核心矛盾:特征提取能力与模型效率的权衡,以及轻量化引发的细粒度特征丢失与漏检误检率上升问题。如在算法中引入增强特征提取模块提升检测精度时,往往伴随着参数量与计算量的激增,难以满足无人机边缘端部署的实时性约束;采用轻量化网络替代主干网络时,虽降低计算开销,却因感受野压缩与空间细节丢失导致小目标漏检率上升。为了解决上述问题,本文基于 YOLOv8s 模型提出了一种轻量化检测算法 DFS-YOLO。通过在不同数据集上的实验验证了模型有效性,主要创新点如下:

1) 设计多膨胀卷积融合的 C2f-DWR 模块替换主干网络中的 C2f 模块,通过使用多个不同膨胀率的并行膨胀卷积,有效扩展感受野,提高主干网络对路面损伤特征图高层语义提取能力。

2) 重新设计 YOLOv8s 的颈部网络,提出快速层次尺度特征金字塔 (fast hierarchical scale-based feature pyramid network, FHSFPN),将层次尺度特征金字塔 (hierarchical scale-based feature pyramid network, HSPFN)^[13] 特征融合网络引入 YOLOv8s 的颈部网络中,并使用了 FasterNet^[14] 的思想改进 HSPFN,减少模型冗余的同时提高了模型的特征融合能力。

3) 使用 ShapeIoU^[15] 替换 YOLOv8s 原有的损失函数 CIoU (complete intersection over union),将路面损害的自身形状与尺度纳入损失计算中,提高模型对不同形状损害的检测精度与鲁棒性。

1 YOLOv8 检测算法

YOLOv8 是 Ultralytics 公司于 2023 年 1 月 10 日发布的一种目标检测算法。相较于先前的 YOLO 系列目标检测算法,检测精度和速度都得到了提升。研究人员运用 YOLOv8 并对其进行改进,在障碍物检测^[16],无人机红外目标检测^[17],遥感图像检测^[18] 等领域均取得了良好的效果。YOLOv8 由主干网络 (Backbone)、颈部网络 (Neck) 和检测头 (Head) 3 部分组成。YOLOv8 的主干网络基于改进后的 CSPDarknet53 架构,使用了 C2f 模块来取代 YOLOv5 中的 C3 模块。相较于 C3 模块,C2f 模块通过更

为高效的梯度流设计,提升了模型训练稳定性,取得了更好的表现。颈部网络使用了特征金字塔网络(feature pyramid network, FPN) + PAN (path aggregation network)结构,优化了特征金字塔的构建方式,充分融合了主干网络中提取的不同尺度的特征信息。YOLOv8的检测头使用了解耦头设计,将分类和回归任务分离,避免任务冲突,提升多类别检测精度。相较于YOLOv7及之前的版本,YOLOv8的检测头使用了Anchor-Free机制,无需预设锚框,减少对数据分布的先验依赖,避免了设计锚框时超参数对检测效果的影响,提升了模型的泛化性。在损失函数方面,YOLOv8在分类任务中使用了二元交叉熵(binary cross-entropy, BCE),回归任务采用CIoU + DFL (distribution focal loss)组合。此外还引入了Task-Aligned Assigner动态分配正样本,增强了模型对样本的学习能力和检测准确率。YOLOv8根据模型规模划分为5个标准版本,分别为YOLOv8n、YOLOv8s、YOLOv8m、YOLOv8l以及YOLOv8x,参数量及计算量依次增大。其中,YOLOv8n和YOLOv8s较为适合资源有限的场景,本文为实现精确度和实时性的平衡,选择YOLOv8s作为基准模型,并在此基础上进行改进。YOLOv8s模型结构如图1所示。

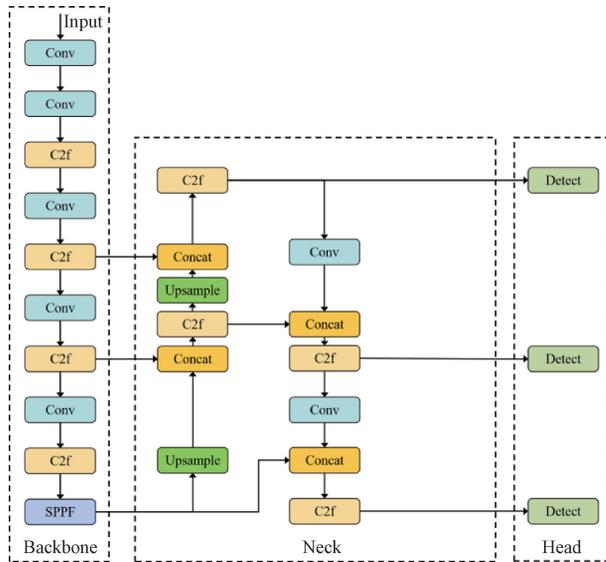


图1 YOLOv8s模型结构

Fig.1 YOLOv8s model architecture

2 DFS-YOLO 算法

DFS-YOLO对YOLOv8的主干网络、颈部网络和损失函数部分进行了改进,其模型结构如图2所示。主干网络部分,将YOLOv8s主干网络高层的两个C2f模块替换为C2f-DWR。在颈部网络部分,使用重新设计的FHSFPN重构YOLOv8s的颈部网络。最后,引入ShapeIoU代替YOLOv8s中的CIoU损失函数。

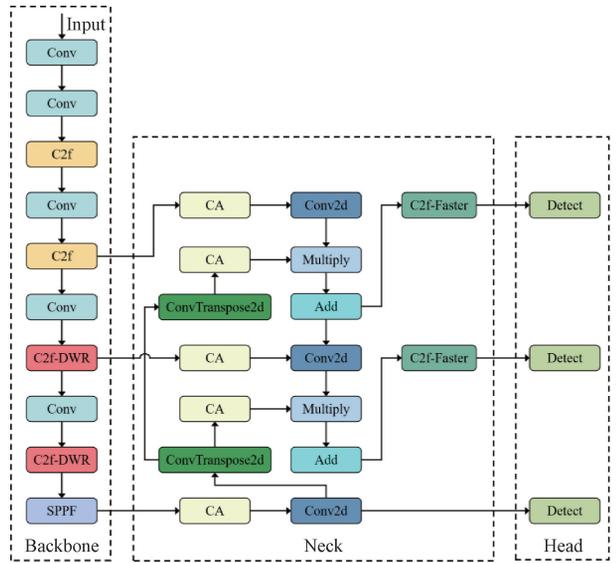


图2 DFS-YOLO模型结构

Fig.2 DFS-YOLO model architecture

2.1 C2f-DWR

为了提高实时语义分割任务中模型提取上下文特征的效率,Wei等^[19]提出了一种多尺度实时语义分割模型DWRSeg,在精度和速度之间取得了良好的平衡。受到DWRSeg的启发,本文将DWRSeg中的DWR(dilation-wise residual)模块引入到YOLOv8主干网络中的C2f模块中,替代C2f模块中的Bottleneck部分,最终形成C2f-DWR模块,提高主干网络对路面损伤的特征提取能力。DWR模块通过两步法融合多尺度上下文信息,有效提升了对高层语义特征的提取能力。第1步称为区域残差,使用 3×3 卷积和批量归一化(batch normalization, BN)层和ReLU(rectified linear unit)层相结合,初步提取特征,生成一系列不同区域形式的特征图,作为下一步的输入。第2步称为语义残差,将上一步的区域特征图分成3组,使用膨胀率为1,3,5的三支并行空洞卷积进行形态过滤。最后使用 1×1 逐点卷积将上述3个分支进行特征融合,并通过残差连接,将原始输入特征图与融合后的特征图相加,形成更加全面的特征表现。通过使用不同膨胀率的空间卷积,可以有效扩大感受野,增强对路面损害的多尺度特征捕获能力。与文献[20]中使用多尺寸普通卷积核相比,空洞卷积不仅可以实现同等感受野,而且显著减少了参数量,从而提高了模型的效率和性能。C2f-DWR结构图如图3所示。

2.2 FHSFPN

在无人机道路损害图像中,损害的尺度差异显著,并且背景复杂,存在着汽车、树枝、路灯、阴影等干扰,对模型排除图像的干扰信息,及提取多尺度特征提出了更高的要求。YOLOv8的FPN+PAN结构虽能实现多尺度特征融合,但其特征金字塔设计存在冗余结构,增加了模型的参数量和计算量;且在自顶向下的特征提取过程中,高层语义特征

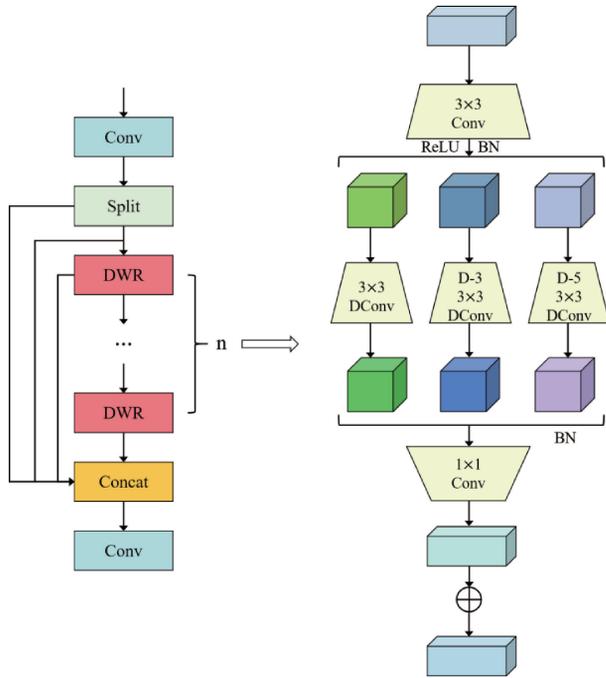


图 3 C2f-DWR 模块结构

Fig. 3 C2f-DWR module architecture

图经过多次下采样处理后,导致微小损害特征信息损失,存在漏检现象。自底向上的特征融合过程中,将低层特征中的噪声传递至高层特征图中,与路面损害信息产生干扰,影响了复杂环境下对道路损伤的判别与定位能力。为了解决以上问题,本文引入了 HSFPN,并在此基础上使用 FasterNet

的思想进一步减少结构中的冗余信息,加强特征提取能力,最终形成 FHSFPN 结构替代 YOLOv8 中的 FPN+PAN 结构。HSFPN 结构如图 4 所示,主要由两大部分组成,即特征选择模块和特征融合模块。在特征选择模块中,输入特征图经过通道注意力(channel attention, CA)模块,如图 5 所示,实现通道权重筛选,最终将权重通过逐通道相乘应用于原输入特征图中,加强关键特征,减少冗余信息。CA 模块中输入的特征图为 $f_{in} \in R^{C \times H \times W}$,其中 C 表示通道数, H 表示特征图的高度, W 表示特征图的宽度。特征图经过双池化操作,即全局平均池化和全局最大池化后,将双池化的结果相加并通过 Sigmoid 激活函数后,得到每个通道的权重 $f_{ca} \in R^{C \times 1 \times 1}$ 与原特征图相乘,在保持轻量化的前提下,兼顾全局依赖与局部特征,减少信息损失,提升检测准确性。

在特征融合模块中,使用选择性特征融合模块(selective feature fusion, SFF),如图 6 所示,筛选低级特征并将筛选后的低级特征与高级特征融合,形成增强后的特征图。SFF 模块中,输入的高级特征为 $f_{high} \in R^{C \times H \times W}$,低级特征为 $f_{low} \in R^{C \times H_1 \times W_1}$ 。首先,将高级特征通过步长为 2 的 3×3 转置卷积扩展高级特征,得到 $\hat{f}_{high} \in R^{C \times 2H \times 2W}$ 。随后,通过双线性插值对扩展后的高级特征进行上采样或下采样,将特征图转换为与低级特征匹配的维度,得到 $f_{at} \in R^{C \times H_1 \times W_1}$ 。最后,将转换后的高级特征通过 CA 模块筛选低级特征,并将扩展后的高级特征与筛选后的低级特征进行相加融合。

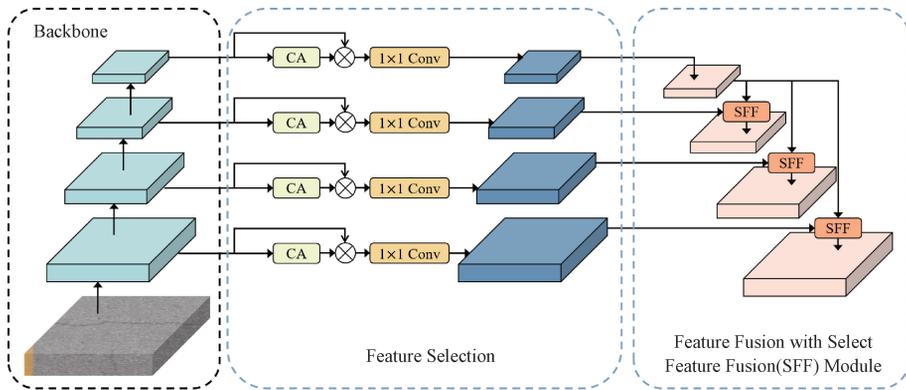


图 4 HSFPN 模块结构

Fig. 4 HSFPN module architecture

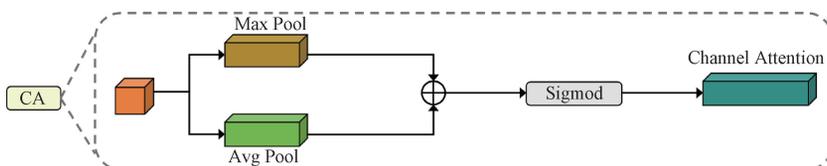


图 5 CA 模块结构

Fig. 5 CA module architecture

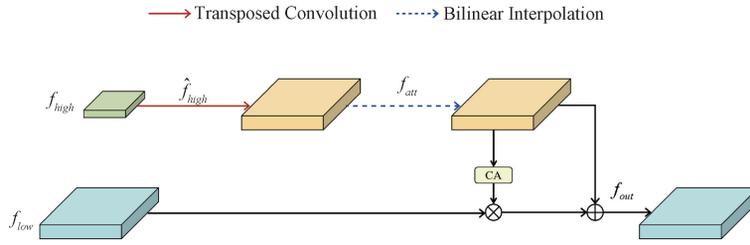


图6 SFF 模块结构

Fig. 6 SFF module architecture

在HSFPN的颈部结构中,SFF模块完成多尺度特征交互后,其输出特征进一步通过C2f模块进行深层语义增强与空间信息聚合,最终生成优化后的多层次特征金字塔,并作为检测头的输入源。为了进一步减少颈部网络中的参数量与计算量,本文将FasterNet思想引入到HSFPN网络中,利用FasterNet模块代替C2f模块中的Bottleneck,能够更加高效地利用路面损伤特征,减少冗余计算与内存访问,从而提高模型运算效率。在FasterNet中,本研究提出了一种简单高效的卷积PConv,兼顾效率与特征完整性,如图7所示,其将输入通道分为两部分,并对其中一部分应用标准卷积,另一部分则保持不变,原理图如图7所示。FasterNet模块由一个3×3的PConv层,后接2个1×1的Conv层组成,并使用了残差连接提高模型的鲁棒性,其结构图如图8所示。

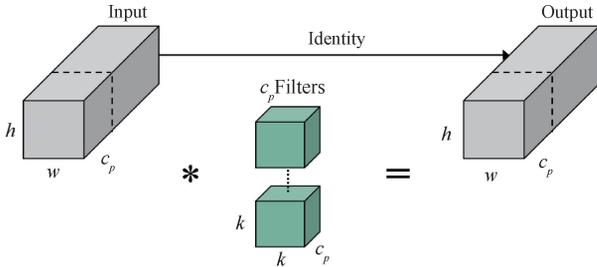


图7 PConv 结构

Fig. 7 PConv architecture

2.3 ShapeIoU

YOLOv8采用了CIoU作为边界框回归的核心损失函数,CIoU在DIoU(distance intersection over union)的基础上进一步改进,考虑了形状相似性的影响,将形状损失项引入到损失函数中,减少锚框与真实标注框之间的宽高比差异。但CIoU未考虑目标自身形状对回归的影响,且未考虑小目标对回归结果的敏感度,小目标的细微偏移会导致IoU(intersection over union)显著下降。在无人机道路损伤图像中,存在相当数量的小目标损伤以及形状多样的各种损伤,为了解决CIoU的不足,本文引入了ShapeIoU作为损失函数,其通过形状权重动态分配和尺度自适应机制,针对目标的形状和尺度计算损失,提升检测的准确性与鲁棒性。IoU表示交并比损失,是目前广泛使用的目标检测评估标准,其计算方法如式(1)所示。

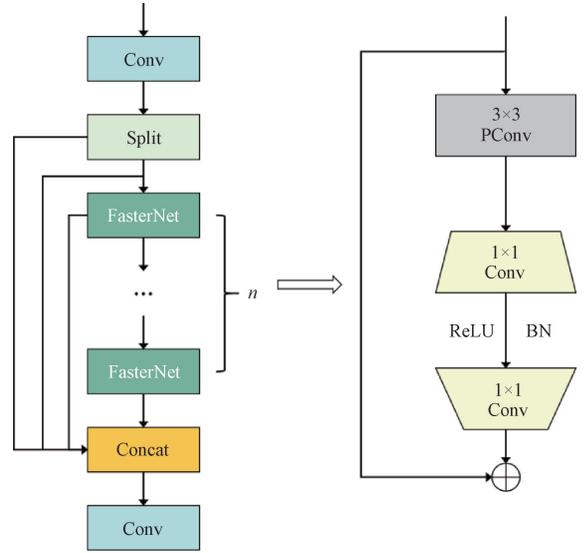


图8 C2f-Faster 模块结构

Fig. 8 C2f-Faster module architecture

$$IoU = \frac{|B \cap B^{gt}|}{|B \cup B^{gt}|} \quad (1)$$

式中: B, B^{gt} 代表了预测框与真实框的位置。

ShapeIoU的计算公式如式(2)~(8)所示

$$\omega\omega = \frac{2 \times (\omega^{gt})^{scale}}{(\omega^{gt})^{scale} + (h^{gt})^{scale}} \quad (2)$$

$$hh = \frac{2 \times (h^{gt})^{scale}}{(\omega^{gt})^{scale} + (h^{gt})^{scale}} \quad (3)$$

式中: $scale$ 为缩放因子,其取值与数据集中目标大小的比例有关, $\omega\omega$ 和 hh 分别为水平和垂直方向的权重系数,其值与预测框与真实框的形状有关。 ω^{gt} 与 h^{gt} 为真实标注框的宽和高。

$$distance^{shape} = hh \times \frac{(x_c - x_c^{gt})^2}{c^2} + \omega\omega \times \frac{(y_c - y_c^{gt})^2}{c^2} \quad (4)$$

$$\Omega^{shape} = \sum_{t=\omega, h} (1 - e^{-\omega^t})^\theta, \theta = 4 \quad (5)$$

$$\omega_\omega = hh \times \frac{|\omega - \omega^{gt}|}{\max(\omega, \omega^{gt})} \quad (6)$$

$$\omega_h = \omega\omega \times \frac{|h - h^{gt}|}{\max(h, h^{gt})} \quad (7)$$

式中: $distance^{shape}$ 为形状距离损失, (x_c, y_c) 为预测框的中心坐标, (x_c^{gt}, y_c^{gt}) 为真实标注框的中心坐标, c 表示真实标注框和预测框的中心距离, Ω^{shape} 为距离损失, ω_w 和 ω_h 分别为水平和垂直方向的动态权重系数。ShapeIoU 的边界框回归损失如式(8)所示。

$$L_{Shape-IoU} = 1 - IoU + distance^{shape} + 0.5 \times \Omega^{shape} \quad (8)$$

ShapeIoU 损失函数结构如图 9 所示。

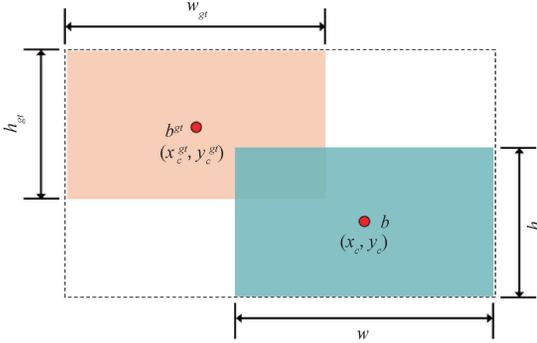


图 9 ShapeIoU 损失函数结构

Fig. 9 Architecture of the ShapeloU loss function

3 实验与结果分析

3.1 实验环境与参数

本实验采用 Ubuntu 20.04 操作系统,训练框架为 Pytorch 2.3.0, Python 版本为 3.10.16, CUDA 版本为 11.8,显卡型号为 NVIDIA Tesla A40,具体实验参数如表 1 所示。

3.2 数据集

本实验使用的数据集源自 RDD-2022^[21]道路损伤数据集,该数据集整涵盖了全球六国的道路图像数据,总量达 47 420 张道路图像。为了更好地反应中国路面损伤情况,实验采用了 RDD-2022 数据集的中国图像部分。中国道路数据集由无人机航拍与车载移动设备采集两部分构成,实验选取了无人机平台获取的高空影像,经过数据

清洗后构建最终数据集 China Drone。China Drone 数据集共包含 2 396 张图像,共含有五种标签: D00、D10、D20、D40、Repair,分别对应纵向裂缝、横向裂缝、龟裂、坑洞和修补五种道路损伤类型。将数据集按照 7 : 1 : 2 的比例随机打乱划分为训练集、验证集和测试集。

表 1 实验参数设置

Table 1 Experimental parameter settings

参数	参数值
图片尺寸	640×640
训练轮次	300
批次大小	16
初始学习率	0.01
权重衰退系数	0.000 5
优化器	SGD

3.3 模型评价指标

为了评估模型改进后的综合检测效果,同时考虑模型的检测效率,本文选择了精确率 (precision, P)、召回率 (recall, R)、平均精度均值 (mean average precision, mAP)、参数量 (parameter, Params) 和计算量 (GFLOPs) 作为模型评价指标。

3.4 对比实验

1) 不同检测模型的对比实验

为了进一步评估本文提出的模型在道路损害检测中的实际表现,本文在 China Drone 数据集上,使用相同的实验设备及参数设置,与主流的单阶段与两阶段目标检测算法进行对比。实验结果如表 2 所示。双阶段目标检测算法 Faster-RCNN 参数量与计算量最大,但检测效果相比其他算法并不出色。YOLO 系列算法中, YOLOv7-tiny 参数量最小,与本文提出的模型相当,但 mAP50 指标与其他 YOLO 系列算法相比表现最差。本文提出的模型与基线模型 YOLOv8s 相比,参数量和计算量分别降低 39.1% 和

表 2 不同算法在 China Drone 数据集上的检测结果对比

Table 2 Performance comparison of different algorithms on the China Drone dataset

模型	P/%	R/%	mAP50/%	mAP50-95/%	GFLOPs	Params/M
Faster-RCNN	56.1	47.3	49.1	24.1	134.0	41.37
SSD	68.8	59.4	62.9	30.9	30.63	24.28
YOLOv5s	72.1	58.7	61.7	37.8	23.8	9.11
YOLOv6s	61.5	55.9	56.5	32.6	44.0	16.30
YOLOv7-tiny	60.5	51.4	55.3	30.9	13.1	6.02
YOLOv8s	67.1	61.9	63.8	38.7	28.4	11.13
YOLOv9s	65.2	58.4	59.4	37.0	26.7	7.17
YOLOv10s	68.6	57.4	62.9	38.1	24.5	8.04
YOLO11s	67.1	61.5	62.1	37.9	21.3	9.41
DFS-YOLO	74.4	65.3	68.4	41.1	22.6	6.78

20.4%, mAP50 提升 4.6%。与最新的 YOLO 系列算法 YOLO11s 相比,参数量降低 27.9%, mAP50 提升 6.3%。

2) 不同位置替换 C2f-DWR 模块的对比实验

在 YOLOv8 的主干网络设计中,输入图像沿层级式下采样路径进行特征提取,特征图的尺寸逐级减小。本文根据特征图尺寸的变化,按照尺寸从大到小的顺序,将主干网络中的 C2f 模块划分为 4 个层级(C2f-1~C2f-4)。为探究 C2f-DWR 模块在主干网络中不同位置替换对检测性能的影响,在保持其他网络结构及超参数不变的情况下,依次将各层级的 C2f 模块替换为改进的 C2f-DWR 模块,实验结果如表 3 所示。从实验结果可以看出,在主干网络的低层 C2f 模块中,特征图尺寸较大,需要较小的卷积核聚焦局部特征,而 C2f-DWR 的大膨胀率空洞卷积分支会引入过多背景噪声,破坏高频细节。而高层特征图本身需捕获大范围上下文,在高层 C2f 模块中引入 C2f-DWR 模块,DWR 模块的多尺度空洞卷积能有效扩大感受野,提升损伤区域与背景的分度,从而提高路面损伤检测效果。

表 3 不同位置替换 C2f-DWR 模块在 China Drone 数据集上的结果对比

Table 3 Comparative results of replacing the C2f-DWR module at different positions on the China Drone dataset

模型	替换位置	mAP50 /%	GFLOPs	Params /M
YOLOv8-C2f-DWR-1	1	61.8	28.3	11.13
YOLOv8-C2f-DWR-2	1,2	63.1	28.1	11.10
YOLOv8-C2f-DWR-3	1,2,3	62.6	27.8	11.02
YOLOv8-C2f-DWR-4	1,2,3,4	64.8	27.7	10.86
YOLOv8-C2f-DWR-1-H	4	60.7	28.3	10.96
YOLOv8-C2f-DWR-2-H	3,4	66.2	28.1	10.88
YOLOv8-C2f-DWR-3-H	2,3,4	63.9	27.8	10.86

3) 不同颈部特征融合网络的对比实验

为了验证本文提出的 FHSFPN 网络的性能优势,本文选取五种主流特征融合网络架构,在 China Drone 数据集上与 FHSFPN 进行对比实验,实验结果如表 4 所示。实验数据证明 FHSFPN 网络相较于其他特征融合网络,在 mAP50 以及 mAP50-95 指标均有显著优势。与 HSFPPN 相比,精确率、mAP50 以及 mAP50-95 均明显提高。

4) 不同损失函数的对比实验

为了验证本文引入的 ShapeIoU 损失函数在路面损伤检测中的检测性能,本文在结合其余两种改进算法的基础上,使用几种常见的损失函数在 China Drone 数据集上与 ShapeIoU 进行对比实验。对比结果如表 5 所示。从表 5 中实验结果可知,ShapeIoU 在 mAP50 及 mAP50-95 指标上明显优于其他常见损失函数的表现。与基准模型的 CIoU 损失函数相比较, mAP50 提升 0.4%, mAP50-95 提

升 0.3%。

表 4 不同特征融合网络在 China Drone 数据集上的结果对比

Table 4 Performance comparison of different feature fusion networks on the China Drone dataset

特征融合网络	P /%	R /%	mAP50 /%	mAP50-95 /%
PAN-FPN	67.1	61.9	63.8	38.7
Bi-FPN ^[22]	68.9	58.5	62.4	38.5
AFPN ^[23]	69.1	54.8	60.6	36.6
GD ^[24]	74.3	56.2	63.2	39.3
HSFPN	67.8	63.4	64.7	38.5
FHSFPN	75.6	61.6	65.2	40.2

表 5 不同损失函数在 China Drone 数据集上的结果对比

Table 5 Performance comparison of different loss function on the China Drone dataset

损失函数	mAP50 /%	mAP50-95 /%
CIoU	68.0	40.8
DIoU	66.6	40.2
GIoU	65.3	39.7
EIoU	64.6	39.1
SIoU	64.5	39.6
MPDIoU	64.9	38.4
WIoU	64.7	39.5
Inner_CIoU	64.7	37.9
ShapeIoU	68.4	41.1

在 2.3 节中提到,损失函数 ShapeIoU 存在缩放因子 $scale$, 本文对超参数 $scale$ 的取值进行了实验,实验结果如表 6 所示。可以看出, $scale$ 取值为 0.1 时, mAP50 与 mAP50-95 表现最佳,所以本文所有实验中 $scale$ 均选取为 0.1。从式(2)及式(3)中可知,较小的 $scale$ 值会保留对水平和垂直方向的均衡加权。当 $scale$ 较大时,权重变化被抑制,导致动态权重对形状差异不敏感。

3.5 消融实验

为了探究本文提出的不同改进对模型综合检测效果的影响,在 China Drone 数据集上进行了一系列模块消融实验,实验结果如表 7 所示。

表 7 中“√”表示在基准模型 YOLOv8s 模型的基础

上加入改进的方法,算法 1 为 C2f-DWR,算法 2 为 FHSFPN,算法 3 为 ShapeIoU。由表 7 的结果可知,本文提出的 3 种算法在单独添加到基准模型中时,mAP50 及 mAP50-95 均有提升,在引入 C2f-DWR 后,小幅减少参数量及计算量的同时,mAP50 与 mAP50-95 相较于基准模型分别提高 2.4%与 1.9%。在引入 FHSFPN 颈部网络后,参数量与计算量相较于基准模型降低 36.8%与 19.0%,mAP50 及 mAP50-95 分别提高 1.4%与 1.5%。在引入 ShapeIoU 后,不增加额外参数量与计算量,且 mAP50 与 mAP50-95 相较于基准模型分别提高 1.1%与 0.8%。在融合所有的改进点之后,最终的模型相比基准模型 P、R、mAP50、mAP50-95 分别提高 7.3%、3.4%、4.6%、2.4%,同时参数量与计算量分别降低 39.1%和 20.4%,表明了 DFS-YOLO 在保持轻量

化的同时,提高了对路面损伤的检测精度。

表 6 不同 scale 取值在 China Drone 数据集上的结果对比

Table 6 Performance comparison of different scale settings on the China Drone dataset

损失函数	P/%	R/%	mAP50 /%	mAP50-95 /%
ShapeIoU(scale=0)	79.0	61.0	68.1	40.9
ShapeIoU(scale=0.05)	67.7	59.6	62.6	37.9
ShapeIoU(scale=0.1)	74.4	65.3	68.4	41.1
ShapeIoU(scale=0.15)	68.9	63.2	64.9	39.4
ShapeIoU(scale=0.2)	69.8	62.6	64.7	39.3
ShapeIoU(scale=0.25)	70.7	60.6	64.0	39.2

表 7 China Drone 数据集上的消融实验结果

Table 7 Ablation study results on the China Drone dataset

YOLOv8s	算法 1	算法 2	算法 3	P/%	R/%	mAP50/%	mAP50-95/%	GFLOPs	Params/M
✓				67.1	61.9	63.8	38.7	28.4	11.13
✓	✓			75.0	64.0	66.2	40.6	28.1	10.88
✓		✓		75.6	61.6	65.2	40.2	23.0	7.03
✓			✓	70.5	59.0	64.9	39.5	28.4	11.13
✓	✓	✓		78.2	62.0	68.0	40.8	22.6	6.78
✓	✓		✓	73.6	66.0	66.5	41.0	28.1	10.88
✓		✓	✓	69.9	63.1	65.4	40.0	23.0	7.03
✓	✓	✓	✓	74.4	65.3	68.4	41.1	22.6	6.78

3.6 模型泛化性分析

为了进一步分析本文提出的 DFS-YOLO 在不同路面环境下的实际泛化能力,本文选择在公开数据集 UAPD^[25] 上进行泛化性测试。UAPD 数据集使用大疆 M600 Pro 无人机在南京市东吉大道进行拍摄,最终共获取 2401 张图片,包含了纵向裂缝、横向裂缝、龟裂、斜向裂缝、坑洞和修补。相较于 China Drone 数据集,额外增加了斜向裂缝这一损伤类型。同样,按照与 China Drone 数据集相同的划分方式,并使用与 3.1 节中相同的实验设备及参数,最终得到的实验结果如表 8 所示。实验结果再次证明了 DFS-YOLO 在无人机航拍路面损伤检测场景下的优良表现。相较于基准模型 YOLOv8s,mAP50 与 mAP50-95 分别提高 2.1%与 1.7%。相较于最新的 YOLO 系列模型 YOLO11s,mAP50 与 mAP50-95 分别提高 2.3%与 2.2%。以上实验充分证明 DFS-YOLO 具有较好的泛化性。

3.7 可视化分析

为了更直观展示改进后的 DFS-YOLO 的检测性能,本文从 China Drone 数据集中选择 4 组具有代表性的图片,将 DFS-YOLO 与基准模型 YOLOv8s 进行可视化对比,效果如图 10 所示。

从图 10 中可以看出,组别 1 的图片中,基准模型 YOLOv8s 将 D40 坑洞误检为 D20 龟裂;组别 2 基准模型 YOLOv8s 漏检 D10 横向裂缝;组别 3 基准模型 YOLOv8s 将 Repair 修补误检为 D10 横向裂缝;组别 4 基准模型 YOLOv8s 漏检 D20 龟裂。实验结果表明,DFS-YOLO 在形态与颜色特征弱化的 D10 横向裂缝(组别 2)及 D20 龟裂(组别 4)检测任务中仍保持高召回率,验证了其对于细微损伤特征提取的鲁棒性优势。

表 8 不同算法在 UAPD 数据集上的检测结果对比

Table 8 Performance comparison of different algorithms on the UAPD dataset

模型	P/%	R/%	mAP50/%	mAP50-95/%
YOLOv5s	66.5	66.9	68.3	40.6
YOLOv6s	57.6	62.9	58.6	33.6
YOLOv7-tiny	54.8	57.9	59.9	31.9
YOLOv8s	72.1	67.0	68.8	41.3
YOLOv9s	62.7	66.8	66.0	40.6
YOLOv10s	62.4	58.5	61.6	38.0
YOLO11s	65.8	67.9	68.6	40.8
DFS-YOLO	75.7	67.1	70.9	43.0

此外,为了展示 DFS-YOLO 在复杂背景的干扰下路面损害的关注情况,本文使用热力图来展示算法对路面损害的关注程度。如图 11 所示,可以看出,在行人、汽车、树枝和阴影等干扰下,DFS-YOLO 相较于基准模型更加关注图像中的路面损害特征,排除背景的干扰,提高预测的准确性。

此外,为了展示 DFS-YOLO 在复杂背景的干扰下路面损害的关注情况,本文使用热力图来展示算法对路面损害的关注程度。如图 11 所示,可以看出,在行人、汽车、树枝和阴影等干扰下,DFS-YOLO 相较于基准模型更加关注图像中的路面损害特征,排除背景的干扰,提高预测的准确性。

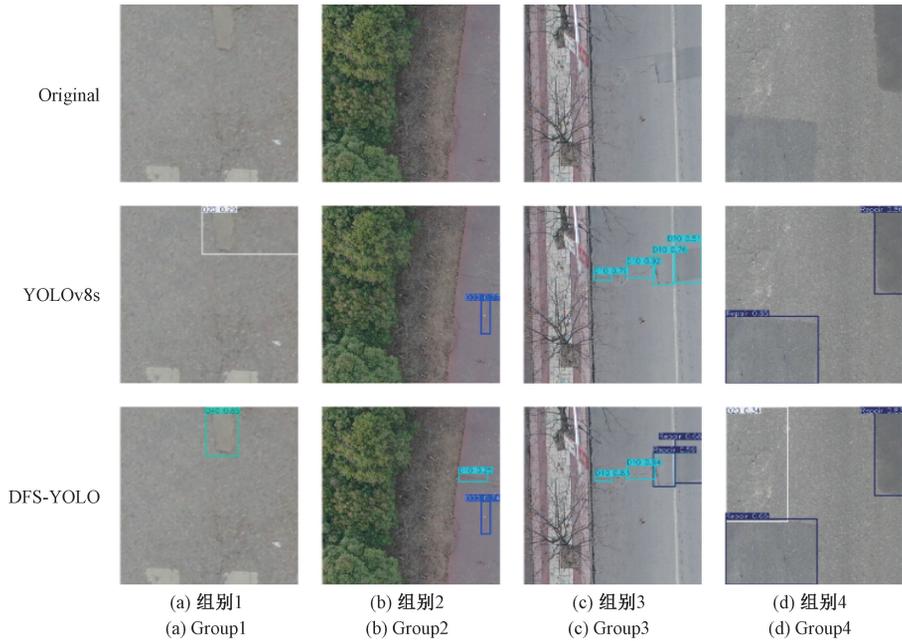


图 10 在 China Drone 数据集上的检测效果对比图
Fig. 10 Detection performance comparison on the China Drone dataset

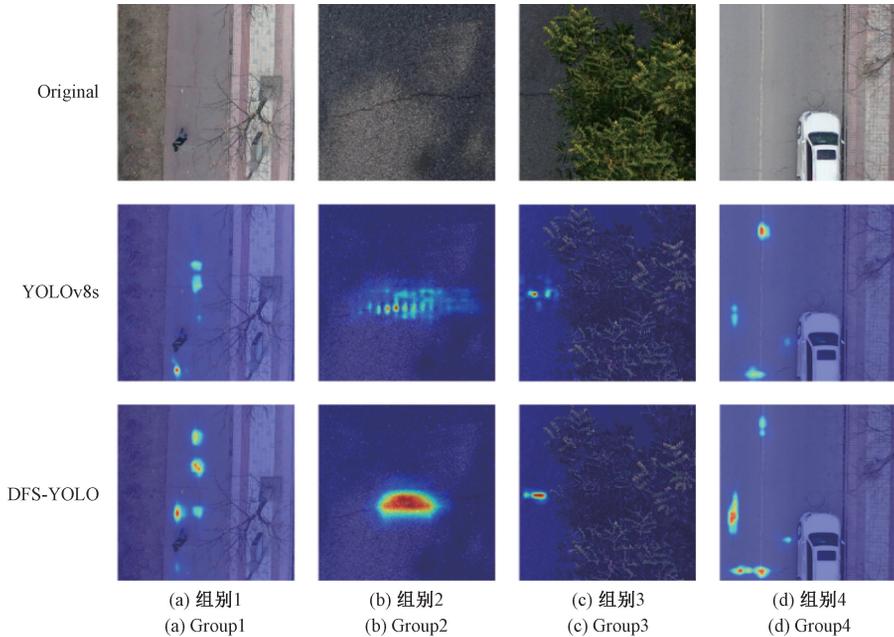


图 11 在 China Drone 数据集上的热力图对比图
Fig. 11 Heatmap comparison on the China Drone dataset

4 结 论

本文针对无人机航拍路面损伤检测算法存在的复杂度较高、复杂背景下存在漏检和误检等问题,提出一种基

于 YOLOv8s 的轻量化的目标检测模型 DFS-YOLO。首先,构建了 C2f-DWR 模块,通过引入不同膨胀率的空洞卷积并行提取特征,扩大模型感受野,增加了主干网络对高层语义信息的利用;其次,设计了轻量化颈部网络

FHSFPN 替代基准模型的颈部网络,在降低模型复杂度的同时,解决原特征金字塔在特征融合过程中的信息丢失问题;最后,引入了损失函数 ShapeIoU,使得损失计算过程关注路面损害自身的形状与尺度,提高了模型的鲁棒性。通过实验得知,在 China Drone 和 UAPD 数据集上,DFS-YOLO 的 mAP50 相较于基准模型分别提高了 4.6% 和 2.1%,参数量与计算量分别下降了 39.1% 与 20.4%,表明模型兼具轻量化与准确性。在未来的工作中,考虑使用剪枝、蒸馏和量化等模型轻量化技术,保持模型准确性的同时进一步压缩模型的参数量与计算量,为模型部署嵌入式设备等算力受限场景提供理论与实践支撑。

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 of China. Statistical bulletin on transport development for the year 2023 [N]. China Transport News, 2024-06-18(002).
- [2] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multi-box detector[C]. Computer Vision-ECCV. Amsterdam: Springer, 2016; 21-37.
- [3] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2014; 580-587.
- [4] REN SH 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, 2016, 39(6): 1137-1149.
- [5] WAN F, SUN CH, HE H Y, et al. YOLO-LRDD: A lightweight method for road damage detection based on improved YOLOv5s [J]. EURASIP Journal on Advances in Signal Processing, 2022, 2022(1): 98.
- [6] 张咏琪, 王杰, 邓彬, 等. Crack-YOLOv7: 深度特征提取与多尺度信息融合的道路裂缝检测[J]. 计算机工程与应用, 2025, 61(18): 198-208.
ZHANG Y Q, WANG J, DENG B, et al. Crack-YOLOv7: Road crack detection based on deep feature extraction and multi-scale information fusion [J]. Computer Engineering and Applications, 2025, 61(18): 198-208.
- [7] WANG W, YU X R, JING B, et al. YOLO-RD: A road damage detection method for effective pavement maintenance[J]. Sensors, 2025, 25(5): 1442.
- [8] LIU T Q, GU M M, SUN S H. RIEC-YOLO: An improved road defect detection model based on YOLOv8[J]. Signal, Image and Video Processing, 2025, 19(4): 285.
- [9] ZHANG Y CH, ZUO ZH W, XU X B, et al. Road damage detection using UAV images based on multi-level attention mechanism [J]. Automation in Construction, 2022, 144: 104613.
- [10] ZHANG Y X, LU Y, HUO Z J, et al. USSC-YOLO: Enhanced multi-scale road crack object detection algorithm for UAV image [J]. Sensors (Basel, Switzerland), 2024, 24(17): 5586.
- [11] DU Y J, CHENG Q M, LIU X F, et al. Enhancing road maintenance through cyber-physical integration: the LEE-YOLO model for drone-assisted pavement crack detection[J]. IEEE Transactions on Intelligent Transportation Systems, 2025, 26(9): 14169-14178.
- [12] GENG H T, LIU ZH Y, WANG Y R, et al. SDFC-YOLO: A YOLO-based model with selective dynamic feature compensation for pavement distress detection [J]. IEEE Transactions on Intelligent Transportation Systems, 2025, 26(5): 6556-6569.
- [13] CHEN Y F, ZHANG CH Y, CHEN B, et al. Accurate leukocyte detection based on deformable-DETR and multi-level feature fusion for aiding diagnosis of blood diseases[J]. Computers in Biology and Medicine, 2024, 170: 107917.
- [14] CHEN J R, KAO SH H, HE H, et al. Run, don't walk: Chasing higher FLOPS for faster neural networks [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 12021-12031.
- [15] ZHANG H, ZHANG SH J. Shape-iou: More accurate metric considering bounding box shape and scale[J]. ArXiv preprint arXiv:2312.17663, 2023.
- [16] 向雷, 蒋文波. 改进 YOLOv8 的城市行车道路障碍物检测算法研究[J]. 电子测量技术, 2025, 48(1): 29-38.
XIANG L, JIANG W B. Research on improved YOLOv8 urban driving road obstacle detection algorithm [J]. Electronic Measurement Technology, 2025, 48(1): 29-38.
- [17] 张瑞芳, 刘占占, 程小辉, 等. 基于改进 YOLOv8 的无人机红外目标检测算法[J]. 电子测量技术, 2025, 48(7): 46-54.
ZHANG R F, LIU ZH ZH, CHENG X H, et al. UAV infrared target detection algorithm based on improved YOLOv8 [J]. Electronic Measurement Technology, 2025, 48(1): 29-38.
- [18] 宋树成, 程换新. 基于改进 YOLOv8 的遥感图像检测算法[J]. 电子测量技术, 2025, 48(3): 52-59.
SONG SH CH, CHENG H X. Remote sensing image detection algorithm based on improved YOLOv8 [J]. Electronic Measurement Technology, 2025, 48(3):

- 52-59.
- [19] WEI H R, LIU X, XU SH CH, et al. DWRSeg: Rethinking efficient acquisition of multi-scale contextual information for real-time semantic segmentation [J]. ArXiv preprint arXiv:2212.01173, 2022.
- [20] 古莹奎,胡宇辉,陈孝鑫,等.基于改进YOLOv8n的铁谱图像磨粒多目标识别方法[J/OL].润滑与密封,1-9 [2025-05-22]. <http://kns.cnki.net/kcms/detail/44.1260.TH.20250317.0953.016.html>.
- GU Y K, HU Y H, CHEN X X, et al. Multi-target recognition method of wear particles in ferrographyImages based on improved YOLOv8n[J/OL]. Lubrication Engineering, 1-9 [2025-05-22]. <http://kns.cnki.net/kcms/detail/44.1260.TH.20250317.0953.016.html>.
- [21] ARYA D, MAEDA H, GHOSH S K, et al. RDD2022: A multi-national image dataset for automatic road damage detection[J]. Geoscience Data Journal, 2024, 11(4): 846-862.
- [22] TAN M X, PANG R M, LE Q V. Efficientdet: Scalable and efficient object detection[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 10781-10790.
- [23] YANG G Y, LEI J, ZHU ZH K, et al. AFPN: Asymptotic feature pyramid network for object detection [C]. 2023 IEEE International Conference on Systems, Man, and Cybernetics(SMC). IEEE, 2023: 2184-2189.
- [24] WANG CH CH, HE W, NIE Y, et al. Gold-YOLO: Efficient object detector via gather-and-distribute mechanism [J]. Advances in Neural Information Processing Systems, 2023, 36: 51094-51112.
- [25] ZHU J Q, ZHONG J T, MA T, et al. Pavement distress detection using convolutional neural networks with images captured via UAV [J]. Automation in Construction, 2022, 133: 103991.

作者简介

张亚军(通信作者),博士,教授,主要研究方向为智能物联网,数据融合。

E-mail:zyj@xju.edu.cn

苗皓源,硕士研究生,主要研究方向为图像处理与识别。

E-mail:107552304959@stu.xju.edu.cn

马薇,硕士研究生,主要研究方向为点云分类,深度学习。

E-mail:107552304956@stu.xju.edu.cn

马冲,硕士,讲师,主要研究方向为大数据处理,人工智能,物联网。

E-mail:814018229@qq.com