

DOI:10.19651/j.cnki.emt.2518143

多尺度轻量化道路病害检测算法^{*}

李昊炎¹ 姜男² 梁虹¹ 吴蓉¹ 黄斯琪¹

(1. 云南大学信息学院 昆明 650504; 2. 云南省公路科学技术研究院 昆明 650051)

摘要: 道路病害检测对于交通安全和道路管养维护至关重要,但现有算法普遍存在检测精度低、计算成本高昂以及难以部署于移动端设备的问题。为解决这些问题,提出了一种基于YOLOv8n的轻量化多尺度道路病害检测算法LMR-YOLO-P。通过设计多尺度组卷积模块以适应病害尺寸多变性,并构建轻量化共享检测头降低计算成本并保留精细特征,引入感受野注意力卷积RFACConv增强全局信息捕捉能力,结合DFP模块和高效局部注意力机制构建SAC模块增强多尺度特征融合,最后利用基于层自适应幅度剪枝方法进一步压缩模型。实验结果表明,在RDD2022数据集上,该算法相较于YOLOv8n网络的mAP50提升了1.8%,同时参数量和计算量分别降低了46%和40%,成功实现了道路病害的轻量化与实时高精度检测,为智能道路管养提供了有效工具。

关键词: 道路病害检测; YOLOv8; 多尺度; 轻量化; 感受野注意力卷积

中图分类号: TP391.4; U418; TN207 **文献标识码:** A **国家标准学科分类代码:** 520.20

Multi-scale lightweight road damage detection algorithm

Li Haoyan¹ Jiang Nan² Liang Hong¹ Wu Rong¹ Huang Sqi¹

(1. School of Information Science and Technology, Yunnan University, Kunming 650504, China;

2. Yunnan Provincial Highway Science and Technology Research Institute, Kunming 650051, China)

Abstract: Road disease detection is crucial for traffic safety and road maintenance, but existing algorithms generally suffer from low detection accuracy, high computational costs, and difficulty in deploying on mobile devices. To address these issues, we propose a lightweight multi-scale road disease detection algorithm LMR-YOLO-P based on YOLOv8n. By designing a multi-scale group conv module to adapt to the variable sizes of road diseases, and constructing a light weight shared detection head to reduce computational costs while preserving fine details, introducing receptive field attention convolution RFACConv to enhance global information capture capability, combining the DFP module and efficient local attention mechanism to build a SAC module for enhanced multi-scale feature fusion, and finally utilizing the layer-adaptive sparsity for the magnitude-based pruning method to further compress the model. Experimental results show that on the RDD2022 dataset, the algorithm improved mAP50 by 1.8% compared to the YOLOv8n network, while reducing parameter count and computational cost by 46% and 40% respectively, successfully achieving lightweight and real-time high-precision detection of road diseases, providing an effective tool for intelligent road maintenance.

Keywords: road damage detection; YOLOv8; multi-scale; light weight; receptive-field attention convolution

0 引言

公路交通一直是国家的经济命脉与人民幸福的重要保障。随着国家工业化进程的推进,截止2024年,我国的公路总里程达到了544.1万公里,高速公路里程增长至18.36万公里,稳居世界第一。我国幅员辽阔,交通流量大,各种极端气候环境导致路面更易于产生裂缝、坑洞等病

害。早期的道路病害检测方法通过人工巡检的方式,通过人为主观的目视观察,敲击路面发现病害。这种方法存在着大量依靠个人主观经验,检测排查的效率低下,以及单次检测对所需要排查的道路范围小的缺陷。

随后提出的一系列半自动道路病害检测算法,如将动态阈值分割算法应用于道路裂缝图像的提取,以及利用基于网格单元分析链技术对道路病害的纹理特征进行检测,

收稿日期:2025-02-23

*基金项目:云南大学研究生科研创新基金(KC-242410664)、云南省现代综合交通数字技术创新中心(202405AK34003)项目资助

虽然取得了一定的检测性能提升,但无法满足高效道路病害的检测需求。尤其在面对复杂背景环境时,半自动的检测算法使得对道路病害的检测任务更加困难。因此,研究快速、准确的道路病害检测算法对保障人民财产安全、提高交通道路巡检养护效率至关重要。

近年来,随着深度学习技术的飞速发展,基于深度学习的道路病害分割与目标检测算法也逐步提出。邹凯鑫等^[1]在 U-Net 的基础上提出 SN-Disout 残差块与循环十字交叉模块,增强模型对拟合鲁棒性的同时增强特征图不同位置的捕获特征能力,并在解码器端引入空间通道挤压与激励模块,能够在保证分割精度的情况下满足实时性的道路缺陷的分割要求。于天河等^[2]提出了一种低成本高精度的道路裂缝自动分割量化算法 SW-Net,通过转置卷积优化上采样模块,增强对局部细小裂缝特征的捕捉能力,同时,引入跳跃级往返多尺度融合机制,增强网络对不同感受野的感知能力。目标检测算法分为单阶段和以 Mask R-CNN^[3]、Faster R-CNN^[4]为主的两阶段算法。研究者们对上述算法进行了诸多改进,有力地推动了该领域的发展。Li 等^[5]基于 Faster RCNN 使用 ResNet50 与 squeeze-and-excitation network(SENNet)集成作为特征提取的骨干网络,增强对裂纹的特征提取能力,实现了对路面裂纹检测性能的提升。Lyu 等^[6]以 Mask RCNN 为基础,通过提取 Mask RCNN 的输出裂纹的掩膜结果,建立出所有裂纹的轨迹形态特征,使得模型可以有效识别真假裂纹,提高了模型对混凝土裂缝的检测能力。然而,两阶段目标检测算法的检测效率低的问题。相比之下,以 YOLO^[7-10]为主的单阶段算法以其轻量化的模型架构以及快速的检测速度,在道路病害检测领域受到了广泛关注。胡晓伟等^[11]在 YOLOv9c 的基础上设计出全新的轻量化 YOLOM 路面病害检测算法,设计多扫描模式的视觉 Mamba 层与空间金字塔 Mamba 层 SPMELAN,增强模型的长程信息捕捉能力。罗向龙等^[12]提出了一种道路病害检测模型 RGT-YOLOv7,在主干网络部分引入三重注意力机制,并引入快速全连接空间金字塔卷积模块和新的损失函数加强在复杂场景下的道路病害检测性能。

然而,目前道路病害检测算法仍然面临多方面的挑战与局限性:

1)首先是特征的多尺度提取与融合能力较弱。道路病害从微小裂缝到大型坑洞跨越了多个尺度范围。现有的单一感受野的传统卷积神经网络难以同时捕获不同尺度的特征信息。

2)其次是上下文信息的获取能力不足。道路病害通常不是孤立存在的,周围的背景环境提供了重要的判断依据。目前的检测方法大多仅关注局部的特征提取,缺乏对高级语义上下文的建模能力。

3)同时,随着网络深度的增加,在特征提取和融合过程中可能会出现关键信息的丢失,导致模型无法获取部分

如病害中复杂形状以及边缘等重要细节,进而影响检测性能。

4)随着智能交通系统的普及和移动设备的广泛应用,道路病害检测系统面临着日益增长的轻量化需求。复杂的深度网络模型虽然在检测精度上效果优秀,但是庞大的参数规模和高计算成本使其难以在资源受限的设备上实时运行。因此,如何在有限的计算资源约束下,平衡检测精度和模型效率成为了一个亟待解决的挑战。

与上述的算法相比,YOLOv8 作为一种先进与成熟的目标检测算法,具有参数量更小,检测精度更高,以及检测速度更快的优势,创新的 C2f 模块和优化的检测头设计显著提升了特征提取效率,同时多种模型规格能够灵活地适应不同的计算资源约束条件,特别适合于道路巡检等移动应用场景,得到了广泛的关注。张强等^[13]基于 YOLOv8,通过引入深度可分离卷积与最大池化提取不同尺度的目标信息,同时使用 dynamic head 提升模型头部表征能力,并将卷积模块与 ECA 注意力机制结合提高对目标网络定位能力,但其模型计算量仍较大,难以在资源受限的设备上部署;王海群等^[14]引入 rep conv 和 DBB 重参数化模块解决参数冗余问题,提高特征表达,但未考虑对小尺寸病害目标检测的局限性。

综上,现有基于 YOLOv8 的道路病害检测任务仍存在以下不足:未针对深度网络中的信息丢失提出专门的解决方案;其次没有一种较为完善的多尺度特征提取架构,难以适应道路病害尺寸多变性;没有全面考虑模型在实际应用中的计算资源的限制问题,难以保持或提高检测性能的同时实现模型压缩。

针对以上问题,提出了一种基于 YOLOv8n 的轻量化多尺度自适应的道路病害检测算法 LMR-YOLO-P。主要贡献如下:

1)针对在道路病害检测任务中存在的多尺度特征提取与融合能力有限的问题,设计新的多尺度组卷积模块(multi-scale group convolution, MSGConv),并融合 C2f 中瓶颈结构的高效特征提取能力,替换原先的 C2f 结构;

2)构建了一个关注局部上下文信息与多尺度特征的融合模块(scale-aware context block, SAC)。通过构建的空洞特征金字塔模块(dilated-feature pyramid block, DFP)使得模型充分捕捉到所有尺度的病害信息。同时,引入高效局部注意力机制(efficient local attention, ELA)进一步增强模型的空间感知与上下文提取能力,优化 YOLOv8 的 SPPF 模块;

3)针对卷积神经网络深度增加带来的道路病害关键信息丢失的问题,引入细节增强卷积模块(detail-enhance convolution, DEConv),设计新的融合细节增强的轻量化共享参数检测头(light weight shared detection head, LWSD)替换网络中原有的检测头,减少了由于网络深度增加带来的道路病害关键信息丢失;

4) 采用基于层的自适应幅度的剪枝(layer adaptive sparsity for the magnitude-based pruning, LAMP)策略,在保证检测性能的前提下最大限度地压缩模型大小,同时提升模型的检测效率。

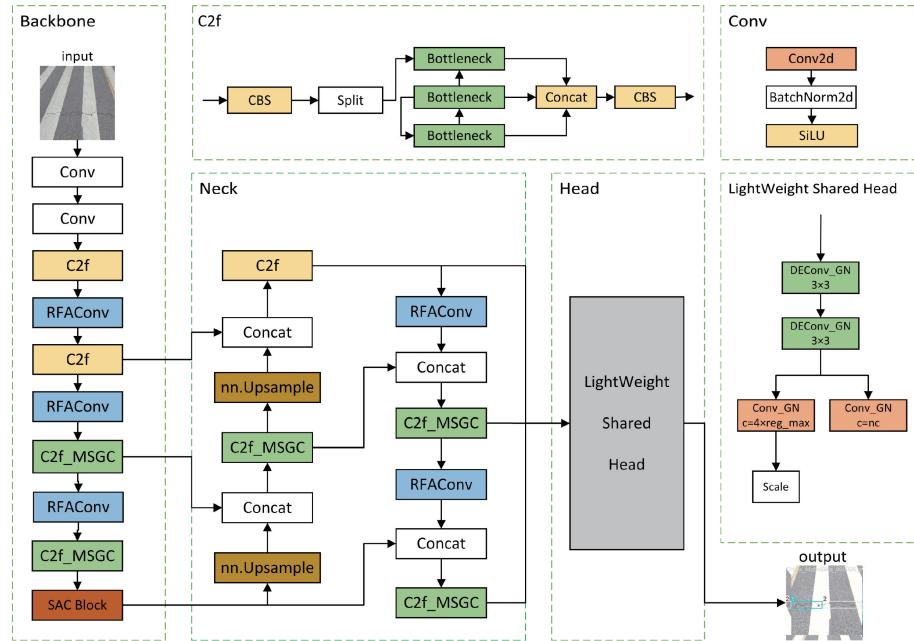


图 1 LMR-YOLO 算法模型

Fig. 1 LMR-YOLO algorithm model

由图 1 可知,本研究在 YOLOv8 的基础之上对网络中的 backbone 和 head 部分进行改进。首先,针对 C2f 模块中 bottleneck 的局限性,创新性提出了一种新的 MSGConv 卷积模块,该模块能够更充分地挖掘高维特征中的多尺度信息,适应不同尺度的目标病害,从而提升模型的表达能力。此外,设计了一种融合细节增强能力的全新轻量化共享参数卷积头 LWSD,共享参数卷积的设计大幅降低模型的参数量与计算量,同时细节增强卷积能够以普通卷积的参数量提取更为丰富的特征,弥补了因网络深度增加而导致的关键信息丢失。其次,为了增强模型的长程信息获取能力,将网络中的下采样模块轻量化为感受野空间注意力卷积模块 (receptive-field attention convolution, RFACConv)。最后,在骨干网络末端,设计了全新的 SAC 模块,通过全新构建的 DFP 模块配合 ELA 局部注意力机制,增强骨干网络对病害图像的多尺度特征高效提取与融合性能,同时扩展模型的局部细节与全局语义的表达能力。

1.1 基于多尺度组卷积模块 multi-scale group convolution 的 C2f_MSGC

在处理道路病害检测任务时,YOLOv8 对病害特征的形变适应能力往往不佳。单一的卷积核尺度的卷积操作会使得图像中的高频信息失真,尤其是针对道路病害中各种尺度变化较大的裂缝坑洞信息时难以进行全面捕捉。

1 LMR-YOLO 改进算法网络模型设计

本研究在 YOLOv8n 的基础上,构建出了全新针对道路病害的轻量化检测算法 LMR-YOLO,图 1 为改进模型结构。

这就要求检测模型能够同时处理不同尺度的目标。针对以上问题,根据组卷积能够高效并行处理多路信息的特点,以及通过调节卷积核大小进行提取多尺度信息的思想,构建了一种全新的用以增强模型对道路病害中尺寸变化感知能力的卷积模块称为多尺度组卷积 MSGConv。如图 2 所示,通过引入多个不同大小的卷积核,构建了 MSGConv 卷积模块,首先将输入的道路病害特征图按其通道数进行分组,每组对应不同大小的卷积核进行卷积操作。卷积核的尺寸设定为 $1 \times 1, 3 \times 3, 5 \times 5, 7 \times 7$ 。分别能够从小到大提取病害图片中细节与局部的信息,且组卷积的思想使得模型在提高并行度的同时降低模型的计算量。多个并行的相异大小的卷积核使得检测网络的骨干和颈部部分可以同时提取不同尺度的特征,从而可以更全面地捕捉目标细节与上下文信息。最后将各个支路的卷积结果进行拼接,从而融合多尺度信息,增强特征表达能力,使得模型能够更好区分不同类型的病害。

在 C2f 的瓶颈结构中采用的是 3×3 的普通卷积,假设输入输出通道数为 C , H 和 W 分别代表特征图的高度和宽度,则对于普通 3×3 卷积层来说,参数量 $P_{3 \times 3}$ 为:

$$P_{3 \times 3} = (c \times 3 \times 3 + 1) \times c = 9c^2 + c \quad (1)$$

计算量 $C_{3 \times 3}$ 为:

$$C_{3 \times 3} = H \times W \times c \times 3^2 \times c = 9c^2 + c \quad (2)$$

而对于 MSGConv 卷积模块,由于分别将特征图分为

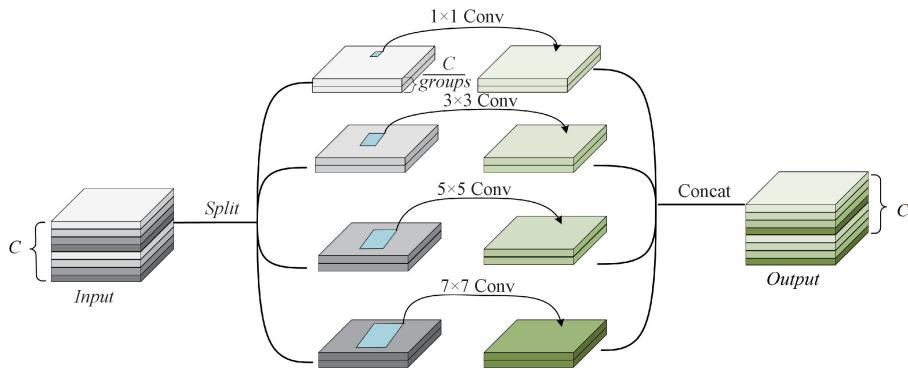


图 2 MSGConv 结构

Fig. 2 MSGConv model structure

了 4 组,并分别进行卷积核大小为 1、3、5、7 的卷积操作,其参数量 $P_{MSGConv}$ 为:

$$P_{MSGConv} = (1 + 3^2 + 5^2 + 7^2) \times \left(\frac{c}{groups}\right)^2 + \frac{4c}{groups} \quad (3)$$

计算量 $C_{MSGConv}$ 为:

$$C_{MSGConv} = H \times W \times \left(\frac{c}{groups}\right)^2 \times (1 + 3^2 + 5^2 + 7^2) \quad (4)$$

其中, $groups$ 是分组卷积的组数,由上可知,组数为 4,则普通 3×3 多尺度组卷积的计算量和参数量的比值为:

$$\frac{P_{3 \times 3}}{P_{MSGConv}} = \frac{9c^2}{\frac{84c^2}{16} + c} > 1 \quad (5)$$

$$\frac{C_{3 \times 3}}{C_{MSGConv}} = \frac{9c^2 \times H \times W}{H \times W \times \frac{84c^2}{16}} > 1 \quad (6)$$

当输入特征图通道数较大时,MSGConv 卷积模块通过分组卷积将特征通道划分为多个组,并对每个组分别进行卷积,有效降低了模型的计算量和参数量。将 MSGConv 模块嵌入 C2f 瓶颈结构中,能够充分挖掘道路病害图像中多尺度、复杂纹理等特征,增强模型的特征表达能力。实验结果验证了 MSGConv 模块的有效性,模型对不同尺度、不同类别的道路病害具有更强的鲁棒性。此外,MSGConv 的高效计算特性使其在保证模型性能的同时,降低了模型的计算复杂度。

根据 MSGConv 的优势设计了图 3 的 MSGConv_bottleneck 结构。MSGConv_bottleneck 由一个普通卷积模块与 MSGConv 模块堆叠而成。第 1 个普通卷积层用以在进行降维与特征变换,普通卷积的计算方式相对简单,可以一定程度保证计算效率。第 2 个卷积层使用了 MSGConv 模块,通过多尺度特征提取和特征融合,即使当病害特征发生弯曲和扭曲,MSGConv_bottleneck 仍可以很好的捕捉到其主要特征。

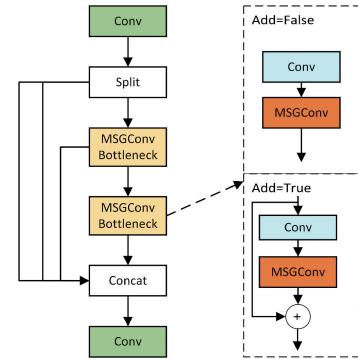


图 3 C2f_MSGC 结构

Fig. 3 C2f_MSGC model structure

1.2 融合细节增强的轻量化共享参数检测头

YOLOv8 中通过解耦头的设计结构,将检测模块分为了类别损失与边界框损失两条支路。两条支路通过对通道数的遍历进行卷积操作,导致模型的计算量与参数量显著增加,不利于模型的轻量化部署。同时,随着网络深度的加深,特征提取和融合过程中极易出现关键信息的损失,这种信息损失主要体现在对病害目标的如裂缝精细纹理以及病害不规则边缘的精细化特征捕捉能力的下降。为了解决上述问题,通过引入细节增强卷积模块(detail-enhanced convolution)设计并构建了一个新的轻量化共享卷积参数检测头 LWS,为在有效增强模型精细化也在捕捉能力、缓解网络深度增加导致的关键信息损失的同时,维持了较低的计算成本。

卷积神经网络中,批归一化(batch normalization, BN)层被广泛应用与特征归一化。然而,BN 层对批大小(batch size)较为敏感,当批大小较小时,BN 层基于小批量数据统计量的估计精度会显著下降,导致归一化效果不佳,进而影响模型的泛化能力。Tian 等^[15]的研究表明,在检测头中引入组归一化(group normalization, GN)层,能够有效缓解由批大小引起的统计估计不准确的问题,从而提升检测头的分类与回归性能。

针对在检测阶段模型由于网络堆叠导致的道路病害

关键信息的损失问题,引入 Chen 等^[16]设计的细节增强卷积模块 DEConv,其能够将先验信息整合到正卷积层中,增强了模型对细微特征的学习能力。

DEConv 由两条平行的支路构成,如图 4 所示。其中一条支路为普通卷积,另一条支路上由 4 个差分卷积构成,通过中心差分卷积(CDC)、角差分卷积(ADC)、水平差分卷积(HDC)和垂直差分卷积(VDC)将传统的局部描述子整合到卷积层中,增强了表征和泛化能力。同时,5 个并行的卷积层在以相同步幅和填充操作时,能够相加以得到一个等价的核,公式如下:

$$\begin{aligned} \mathbf{F}_{out} &= DEConv(\mathbf{F}_{in}) = \sum_{i=1}^5 \mathbf{F}_{in} * \mathbf{K}_i = \\ \mathbf{F}_{in} * \left(\sum_{i=1}^5 \mathbf{K}_i \right) &= \mathbf{F}_{in} * \mathbf{K}_{tot} \end{aligned} \quad (7)$$

其中, $\mathbf{K}_{i=1,\dots,5}$ 分别表示 Conv、CDC、ADC、HDC 以及 VDC 的核,* 表示卷积操作, \mathbf{K}_{tot} 表示将并行卷积组合在一起的转换核。权重分解的重参数化能够将该卷积模块以与普通卷积相同的参数量的同时提取更丰富的特征,并且在推理阶段不引入额外的计算成本与内存负担。

依据上面提出的改进思路,设计并构建了一种融合细节增强的轻量化共享卷积参数检测头(LWSD)。

为了平衡参数共享带来的性能损失,引入组归一化(group normalization,GN)来替代传统的批归一化(batch normalization,BN),GN 能够更好地适应小批量数据和不同尺度的特征,从而保持检测头的分类和回归精度。此外,为了解决不同检测头所对应目标尺度差异的问题,设计了 Scale 层,通过引入可学习的缩放因子,对不同尺度

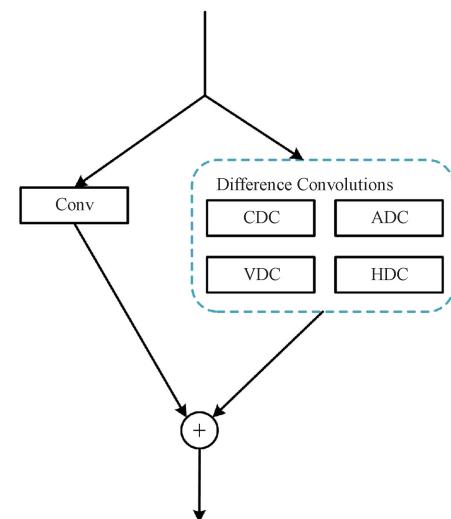


图 4 DEConv 结构

Fig. 4 DEConv model structure

的特征进行自适应缩放使得模型能够更好地适应不同尺度目标的检测。这种自适应缩放机制不仅提高了模型的训练效率和稳定性,同时增强了模型对多尺度目标的鲁棒性。

如图 5 所示,该检测头通过在不同尺度的特征图 P3、P4、P5 上共享参数的细节增强卷积模块,显著降低了模型的计算复杂度。细节增强卷积模块能够在图像的不同方向上计算像素差异,并将这些差异作为先验知识编码进网络中,从而提升模型对细小物体、纹理和边缘等细节特征的感知能力。提升对关键信息的提取能力。

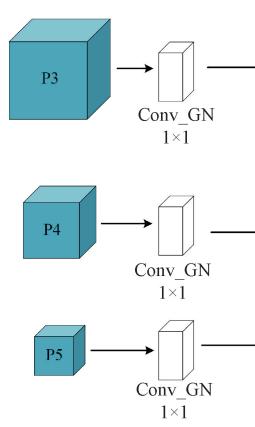


图 5 LWSD 结构

Fig. 5 LWSD model structure

1.3 基于感受野空间特征的注意力卷积模块 RFACConv

在依赖空间特征的道路病害检测任务中,道路病害的图像特征的多样性、尺度变化大且复杂,仅依靠局部卷积

难以充分捕捉道路病害的空间上下文信息,基于 Transformer 的自注意力机制虽然能够解决远程信息的建模问题,但也给模型带来了显著的计算开销与复杂性。理

想的病害检测模型需要具备更强大的全局感知能力,以便更好地理解图像的整体语义,从而准确地定位和分类病害区域。

为了弥补下采样中处理全局空间特征信息方面的不

足,同时保证模型的轻量化架构,引入了一种低计算成本,通过将空间注意力机制引导到感受野的空间特征的感受野空间注意力卷积模块 RFAConv^[17]称为感受野注意力卷积,如图 6 所示。

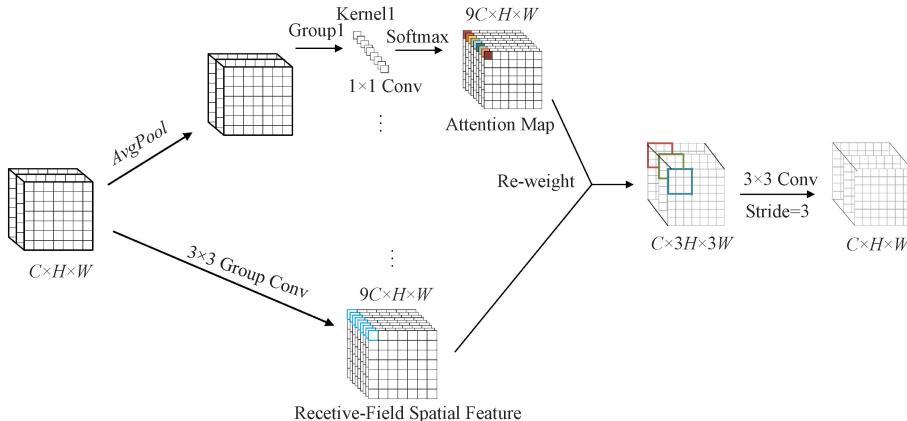


图 6 RFAConv 结构

Fig. 6 RFAConv model structure

整个感受野空间注意力卷积模块由两条支路组成,如图 6 所示。首先是注意力图支路,将输入特征图经过平均池化聚合特征图的全局特征,并通过 1×1 的多个组卷积的进行高效的局部特征提取,并将提取的局部特征用于生成计算注意力关系的权重,实现了感受野特征信息的交互。组卷积在一定程度上降低了模型的计算量和参数量。最后使用 softmax 来强调每个特征在感受野特征内的重要性,并将感受野滑块中不同特征重要性进行了优先级排序,生成注意力图。从而保证了得到的卷积核能够对重要的特征进行优先提取;其次是感受野空间特征支路,将特征图进行组卷积后得到了与注意力图相同尺寸的感受野空间特征, 3×3 的组卷积使得感受野滑块展开速度更快,效率更高。

1.4 引入高效局部注意力机制模块 ELA

注意力机制由于其能够有效地增强深度神经网络的性能而取得巨大的成功。然而现有的注意力机制能力往往难以有效利用空间信息,或者即使有效利用也会以降低通道维数或增加神经网络的复杂性为代价。Hou 等^[18]提出了一种高效的局部注意力 ELA 方法,通过结合 1D 卷积和群归一化特征增强技术,有效地编码两个 1D 位置特征映射而无需降维,从而实现了局部上下文信息的捕捉,同时允许轻量级的实现。

如图 7 所示,与 CA 坐标注意力机制相比,ELA 通过在高度与宽度两个维度上进行平均池化,得到了两个方向的注意力权重,从而实现了局部上下文信息的捕捉;同时,由于主要关注局部上下文信息,并使用了平均池化与一维卷积等计算效率较高的操作,因此 ELA 能够在更加关注微小病害的同时保证了高效计算。

1.5 构建 SAC 模块

SPPF 模块由普通卷积与最大池化组成,通过普通卷

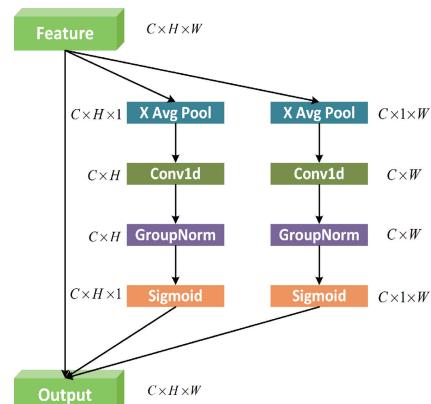


图 7 ELA 结构

Fig. 7 ELA model structure

积对输入特征图进行通道数压缩与特征融合。然而,SPPF 模块仅关注不同尺度的空间信息,最大池化可能会丢失部分关键信息,无法充分捕捉到所有尺度的病害信息。同时,忽略了病害纹理细节等局部上下文信息。

针对以上问题,构建出了通过膨胀卷积与共享卷积核高效提取不同尺度特征的 DFP 模块,并配合高效局部注意力机制 ELA 的轻量级和局部上下文信息提取能力构建了如图 8 所示的 SAC 模块。增强骨干网络多尺度特征提取融合能力的同时提高了模型对局部上下文信息的捕捉能力。如图 8 所示,多尺度注意上下文模块 SAC 分为了两条主要支路,分别为多尺度空洞卷积支路与局部信息增强支路。

多尺度空洞卷积通路主要由构建出的 DFP 模块构成。通过不同的空洞率的卷积操作,捕捉到不同尺度的病害特征,并通过类似于特征金字塔 FPN 的结构,融合多尺度信

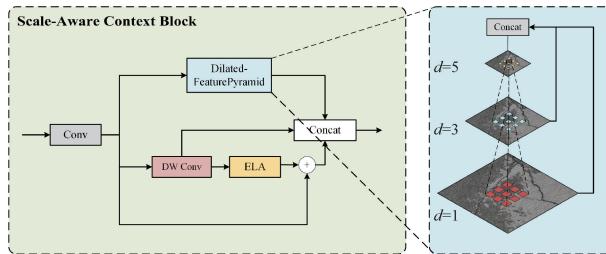


图 8 SAC 模块结构

Fig. 8 SAC block model structure

息,实现了多尺度特征的高效提取与融合。同时,空洞卷积可以有效扩大卷积核的感受野,使得模型可以更好地捕捉到全局上下文信息。

局部信息增强支路主要由深度可分离卷积 DWConv 与高效局部注意力机制组成。通过低运算成本的深度可分离卷积提取局部特征后,利用 ELA 注意力机制增强局部信息,从而提高模型对病害细节的感知能力。

SAC 模块通过将不同空洞率卷积核提取的特征、原始输入特征以及经局部注意力机制处理后的特征进行通道维度的拼接,实现更丰富的特征融合,从而提高了检测性能。

1.6 基于层自适应幅度的剪枝

为了进一步降低模型的计算量与参数量,提升改进模型的检测效率,实现稀疏性与性能之间的最佳权衡,引入了基于层自适应幅度 LAMP^[19]剪枝算法。

LAMP 基于失真的最小化框架,提出了新的全局剪枝重要性评分。通过重新调整的权重大小,近似于剪枝造成的模型级失真,如式(8)所示。

$$score(u; W) = \frac{(W[u]^2)}{\sum_{v \geq u} (W[v]^2)} \quad (8)$$

其中, $W(1) \dots, W(k)$ 为一个深度为 k 的前馈神经网络中的权重,LAMP 评分通过将当前权重大小的平方除以所有幸存权重的综合进行归一化,使得不同层间的权重参数具有可比性。

LAMP 分数的大小决定了该权重对于模型输出的影响大小,通过剪去分数较小的权重,实现了自适应剪枝的功能。LAMP 剪枝流程如图 9 所示。

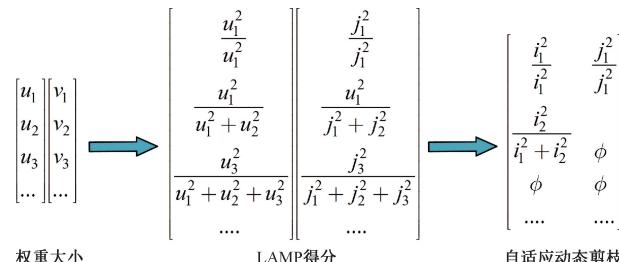


图 9 LAMP 剪枝流程

Fig. 9 LAMP pruning process

2 实验结果与分析

2.1 数据集与实验环境

为了验证改进模型的有效性,本实验选用 RDD2022 数据集^[20]作为实验基准。该数据集是一个大规模的多国道路损坏图像数据集,包含来自中国、印度、日本、捷克、美国、挪威等 6 个国家地区的 47 420 张图像,涵盖了裂缝、坑洞、隆起等多种道路病害。为了确保研究的针对性,并考虑到数据集在不同病害类别分布不均衡的问题,本研究基于《公路技术状况评定标准》(JTG 5210-2018)^[21],选取了 D00(纵向裂缝)、D10(横向裂缝)、D20(网状裂缝)和 D40(坑洞)经过数据清洗,最终获得 23 767 张带标注图像,并按照 7:2:1 的比例随机划分为训练集、验证集和测试集,用于后续模型的训练和评估。实验环境与平台如表 1 所示。训练过程中均使用了相同的超参数,如表 2 所示。

表 1 实验环境及平台配置

Table 1 Experimental environment configuration

名称	配置
操作系统	Windows 11
CPU	Intel(R)Core(TM) i5-12400f
GPU	GeForce RTX 4060Ti
内存大小	32 G
显存	8 GB
学习框架	PyTorch 2.2.2 + CUDA12.1
编程语言	Python3.9

表 2 实验参数配置

Table 2 Experimental parameter configuration

名称	配置
数据增强	Mosaic
更新学习率	余弦退火算法
优化器	SGD
训练轮数	300
Batch	16
Patience	0
Workers	8

2.2 评价指标

为了量化改进算法的检测效果,采用精准率(precision, P)、召回率(recall, R)、平均精度均值(mean average precision, mAP)、以及每秒十亿次浮点运算数(giga floating-point operations per second, GFLOPs)作为算法的评价指标。假设 TP、FP、FN 分别是检测中正确、错误以及缺失的目标数。

精准率是描述在检测过程中将正例样本检测为正确的比例,计算式为:

$$P = \frac{TP}{TP + FP} \quad (9)$$

召回率是指正例样本中检测正确的正例所占全部正例样本的比例,计算式为:

$$R = \frac{TP}{TP + FN} \quad (10)$$

平均精度均值衡量了模型在所有目标类别上的平均精度,计算式为:

$$mAP = \frac{1}{n} \sum_{i=1}^n \int_0^1 P_i(R) dR \quad (11)$$

其中, $\int_0^1 P_i(R) dR$ 是第 i 个目标类别的 Precision-Recall 曲线下围成的面积。

F1 为精确率与召回率的算术平均值,计算式为:

$$F1 = 2 \times \left(\frac{PR}{P+R} \right) \quad (12)$$

每秒帧数(frame per second, FPS)是指网络结构每秒能够处理的图片数量(帧数),该指标用于评估模型在给定硬件条件下的处理速度。

2.3 C2f_MSGC 模块对网络性能的影响

为了验证在检测网络的不同位置添加 C2fMSGC 自研模块对检测效果的影响,设计了如表 3 所示的消融实验。MSGC-backbone 表示将骨干网络中的 C2f 模块替换为 C2fMSGC 而颈部网络保持不变,MSGC-neck 表示将颈部网络的 C2f 模块替换为 C2fMSGC,而骨干网络保持不变。

表 3 C2f_MSGC 不同位置对比结果

Table 3 Comparison results of different C2f_MSGC positions

算法	P/%	R/%	mAP50/%	mAP50-95/%	Params/M	GFLOPs
YOLOv8n	63.6	53.2	57.0	28.8	3.0	8.1
+ backbone	64.9	52.4	57.3	29.5	2.9	8.0
+ neck	65.5	52.2	57.7	29.6	2.9	8.0
本文	65.8	52.0	57.8	29.9	2.8	7.9

在骨干网络中引入 C2fMSGC 模块后,相比于 YOLOv8n 略微降低了模型计算量,且略微提升了检测精度。由于 MSGConv 的多尺度特征提取能力能够提高骨干网络对道路病害的特征提取能力,并行分组卷积的思想在一定程度上降低了模型大小;将颈部网络中的 C2f 替换为 C2fMSGC 模块后,提升了模型融合多尺度特征的能力,mAP50 得到了进一步提升。最终,实验结果表明将骨干与颈部网络中的 C2f 模块替换为 C2f_MSGC 能够获得最佳性能。

2.4 消融实验

为了验证改进模型 LMR-YOLO 算法在道路病害检测中的性能优势,设计了以 YOLOv8n 为基线模型,通过依次添加模块得到了如下的消融实验如表 4 所示。首先将骨干与颈部网络的 C2f 进行替换后,参数量与计算量下降的同时,精度上升了 0.8%,有效地解决了道路病害特征存在尺寸差异较大的问题;其次在改进模型检测头模块后,共享卷积参数的低运算成本使得模型的计算量和参数量分别降低了 18% 和 23%,轻量化的同时细节增强卷积使得模型的检测精度略微提升。SAC 模块在关注图像空间特征的同时融合了高效计算的局部注意力机制,充分捕捉所有尺度的病害信息。引入基线网络后使得平均精度上升了 1.1%。

表 4 消融实验结果

Table 4 Results of ablation experiment

模型	C2f_MSGC	RFAConv	SAC	LWSD	mAP50/%	mAP50-95/%	GFLOPs/G	Params/M	FPS
YOLOv8n					57.0	28.8	8.1	3.0	151.9
Model-1	✓				57.8	29.9	7.9	2.8	105.8
Model-2		✓			58.3	29.6	8.4	3.0	109.4
Model-3			✓		58.1	29.7	8.1	3.1	114.2
Model-4				✓	57.3	29.3	6.6	2.3	123.1
Model-5	✓	✓			58.4	30.2	8.0	2.9	94.5
Model-6		✓		✓	57.9	29.5	6.8	2.4	110.2
Model-7	✓	✓	✓		58.5	30.2	8.4	3.2	99.6
Model-8	✓	✓	✓	✓	58.9	30.4	6.7	2.6	88.4

综合以上的实验结果,提出的 LMR-YOLO 道路病害

检测算法通过结合 C2f_MSGC、LWSD 检测头、RFAConv

以及 SAC 模块在经过了 300 轮迭代计算下,模型精度提升了 1.9%,同时模型参数量降低了 13%,计算量降低 18%,实现了模型在性能与效率之间的良好平衡,满足实时检测道路病害的要求。

2.5 剪枝结果分析

为了进一步降低模型大小,同时提升模型的实时性,采用了 LAMP 剪枝算法对模型进行轻量化改进。能够尽量实现无损的轻量化。实验结果如表 5 所示。通过在剪枝算法中调整 Speed_up 参数以对模型进行剪枝。Speed_up 表示的是剪枝前模型的浮点运算数除以剪枝后模型的浮点运算数的倍数,Speed_up 参数越大,需要剪除的模型权重也就越多,但是对模型的影响也就越大。分别设置

Speed_up 为 1、1.2、1.5、1.8、2.0 进行对比实验。可以发现,当 Speed_up 为 1.2 时,模型在轻量化的同时精度得到了提升,这是由于模型具有冗余的权重,剪枝能够帮助模型剪除不重要的参数,减少其中噪声的影响。在 Speed_up 为 1.5 时模型的精度基本保持不变,同时相比于 Speed_up 为 1.2 时的模型大小进一步减小,而在 Speed_up 为 1.8 和 2.0 时,虽然模型大小有了更大程度的压缩,但是也带来了一定的精度丢失。综合以上实验结果,最终使用 Speed_up 为 1.5 作为模型的最终剪枝轻量化模型。剪枝后的模型通过聚焦关键特征,在道路病害的多尺度特征中能够更高效的分配计算资源,实现了模型实时性与检测准确率之间的平衡。

表 5 不同 speed_up 实验结果
Table 5 Results of different speed_up

算法	Speed_up	mAP50/%	P/%	R/%	Params/M	GFLOPs/G	Size/MB	FPS
YOLOv8n	—	57.0	63.6	53.2	3.0	8.1	6.1	151.9
LMR-YOLO	—	58.9	64.1	54.5	2.6	6.7	6.0	88.4
LMR-YOLO-P	1.2	59.1	64.1	54.7	2.0	5.7	4.9	106.8
LMR-YOLO-P	1.5	58.8	64.0	54.5	1.6	4.8	4.2	127.3
LMR-YOLO-P	1.8	56.9	63.4	52.4	1.4	4.2	3.7	131.5
LMR-YOLO-P	2.0	56.5	63.7	51.8	1.3	3.9	3.4	138.2

2.6 热力图可视化分析

为直观展示 LMR-YOLO-P 模型相较于基础 YOLOv8n 模型在病害目标检测上的显著优势,本研究利用 Grad-CAM 热力图对两种模型的检测结果进行了可视化对比。如图 10 所示。其中,热力图中的红色区域表示重

点关注的特征区域,可以看出,YOLOv8 基础模型在面对道路病害的多尺度特性以及复杂纹理影响导致模型的检测精度不佳。提出的 LMR-YOLO-P 算法能够准确识别出病害区域,识别结果与病害所在区域较高重合,表明改进算法在道路病害检测任务中具有较高精度。

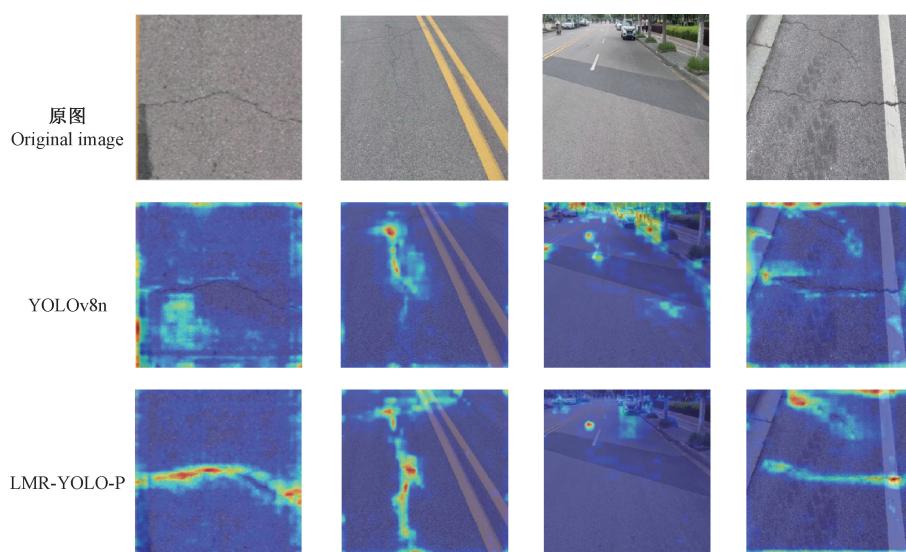


图 10 改进模型热力图可视化结果

Fig. 10 Visualization results of improved model heat map

2.7 不同目标检测算法对比分析

为了验证提出的道路病害检测算法的有效性与可行

性,本节选取了几种主流的目标检测算法进行对比,包括 FasterR-CNN 以及几种主流的 YOLO 算法(YOLOv5n、

YOLOv7n-tiny、YOLOv8n、YOLOv10n、YOLOv11n) 和 LMR-YOLO-P 算法,结果如表 6 所示。可以发现,相较于两阶段的 FasterR-CNN 目标检测算法,LMR-YOLO-P 仅拥有其 2.1% 与 2.2% 的计算量与参数量,但 mAP50% 与 mAP50-95% 均提高了 7.6%。与主流的 YOLO 算法相比,LMR-YOLO-P 的 mAP50 分别提高了 4.7%、2.3%、1.8%、3.1%、2.0%,mAP50-95 分别提高了 1.8%、4.8%、1.7%、1.6%、1.7%。有效地提高了模型在复杂背景以及遮挡等不良条件下的检测效果。检测准确度对比 YOLOM^[12]、RGT-YOLOv7^[13] 提出的改进算法有明显提升,模型大小明显降低。此外,相较于目前针对 YOLOv8n

的改进算法,LMR-YOLO-P 算法为深度网络的信息丢失提出了解决方案,保证低廉计算成本的同时,提出了完善的多尺度特征提取架构以适应道路病害的尺寸多变性。相较于文献[12]、文献[13]和 DML-YOLO^[22],mAP50 分别提高了 1.5%、0.5% 和 1.1%,mAP50-95 分别提高了 1.4%、0.3% 和 0.5%,同时 LMR-YOLO-P 的计算量仅为他们的 48%,45% 与 20%,参数量仅为他们的 47%,44% 与 21%。且 LMR-YOLO-P 的实时性实现了最佳效果。以上的实验结果可以表明,本研究提出的 LMR-YOLO-P 模型在满足了低廉运算成本的同时,大幅提升了检测精度,增强了模型在复杂背景下的检测能力,拥有更强的泛化能力。

表 6 不同算法对比试验

Table 6 Comparative experiments of different algorithms

算法	mAP50/%	mAP50-95/%	F1	Params/M	GFlops/G	FPS
FasterR-CNN	51.2	22.5	49.4	137.1	370.2	11.0
RT-detr	57.6	29.4	58.2	29.2	105.2	47.0
YOLOv5n	54.1	28.7	54.8	2.5	7.1	134.5
YOLOv7n-tiny	56.5	25.7	57.1	6.9	13.0	144.3
YOLOv8n	57.0	28.8	57.8	3.0	8.1	151.9
YOLOv10n	55.3	28.9	56.3	2.7	8.2	125.0
YOLOv11n	56.8	28.8	57.6	2.5	6.3	118.2
YOLOM ^[10]	58.2	30.2	57.7	26.3	102.6	88.5
RGT-YOLOv7 ^[11]	56.8	28.7	57.4	57.6	144.1	54.0
文献[12]	57.3	29.1	57.2	3.4	9.8	39.8
文献[13]	58.3	30.2	58.5	3.6	10.5	86.3
DML-YOLO ^[23]	57.8	30.0	58.3	7.52	24.0	77.0
LMR-YOLO	58.9	30.5	59.0	2.6	6.1	88.5
LMR-YOLO-P	58.8	30.5	59.0	1.6	4.8	127.3

3 结 论

针对道路病害检测面临的多尺度特征提取不足、上下文信息获取有限以及轻量化部署需求等关键挑战,基于 YOLOv8n 模型提出了一种轻量化多尺度的道路病害检测改进算法 LMR-YOLO-P。

MSGConv 卷积结构通过多尺度特征提取与融合,显著增强了模型对从微小裂缝到大型坑洞等不同尺寸病害的感知能力,同时减少了模型的计算量与参数量,解决了现有方法难以适应道路病害尺寸多变性的问题。创新设计的 LWSD 轻量化共享参数检测头结构优化了网络参数分配,在减少计算成本的同时提升了检测精度,解决了现有算法模型在资源受限设备上难以部署的问题。引入的 RFACConv 卷积以较低的计算成本增强了模型对全局上下文信息的感知能力,弥补了传统卷积操

作感受野有限的缺陷。构建的 SAC 模块通过 DFP 结构和 ELA 注意力机制,充分捕捉不同尺度的病害信息,同时增强了对局部与全局上下文信息的提取能力,提升了道路病害检测的准确性,克服了现有算法在小尺寸病害检测方面的局限性。此外,采用的 LAMP 剪枝策略在保证检测性能的前提下最大限度地压缩了模型大小,进一步提升了检测效率。

实验表明,LMR-YOLO-P 在道路病害检测任务中表现出卓越的性能,具有检测精度高、计算量与参数量低的突出优势,同时满足实时检测的要求。与现有模型相比,该算法能够更好地适应不同尺寸道路病害特征,获得明显的检测精度提升。这些改进在智能交通系统和道路养护领域具有重要的现实意义,特别是在资源受限的移动设备上进行实时道路病害检测应用中,可以显著提升巡检效率、降低养护成本、保障交通安全,为我国公路交通基础设施建设提供有力支撑。

施的智能化管理提供了新的技术支持。

参考文献

- [1] 邹凯鑫,张自嘉,孙伟,等.改进 U 型网络的路面缺陷图像分割算法[J].电子测量与仪器学报,2024,38(8):15-25.
- [2] ZOU K X, ZHANG Z J, SUN W, et al. Improved U-network image segmentation algorithm for pavement defects[J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(8): 15-25.
- [3] 于天河,徐博超,侯善冲,等.基于图像的道路裂缝分割及量化方法研究[J].仪器仪表学报,2024,45(9):77-91.
- [4] YU T H, XU B CH, HOU SH CH, et al. Research on image-based road crack segmentation and quantization method[J]. Journal of Instrumentation, 2024, 45(9): 77-91.
- [5] HE K M, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN [C]. IEEE International Conference on Computer Vision, 2017: 2961-2969.
- [6] 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.
- [7] LI Q L, XU X Y, GUAN J J, et al. The improvement of Faster-RCNN crack recognition model and parameters based on attention mechanism [J]. Symmetry, 2024, 16(8): 1027.
- [8] LYU J L, XU X, WU CH, et al. Crack detection based on mask RCNN and trajectory similarity measurement[C]. Fifteenth International Conference on Graphics and Image Processing (ICGIP 2023). SPIE, 2024, 13089: 232-239.
- [9] REDMON J. You only look once: Unified, real-time object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016.
- [10] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2017: 7263-7271.
- [11] REDMON J. YOLOv3: An incremental improvement[J]. ArXiv preprint arXiv:1804.02767, 2018.
- [12] BOCHKOSKIY A, WANG CH Y, LIAO H Y M. Yolov4: Optimal speed and accuracy of object detection [J]. ArXiv preprint arXiv: 2004.10934, 2020.
- [13] 胡晓伟,闫奕昕,王大为,等.基于 YOLOM 算法的路面病害轻量化检测方法[J].中国公路学报,2024,37(12):381-391.
- [14] HU X W, YAN Y X, WANG D W, et al. Lightweight detection method of pavement distress based on YOLOM algorithm [J]. China Highway Journal, 2024, 37(12): 381-391.
- [15] 罗向龙,王彦博,蒲亚亚,等.多病害并发复杂场景下的道路病害检测 RGT-YOLOv7 模型[J].湖南大学学报(自然科学版),2024,51(12):107-118.
- [16] LUO X L, WANG Y B, PU Y Y, et al. RGT-YOLOv7 model for road disease detection in complex scenarios with multiple disease concurrency [J]. Journal of Hunan University (Natural Science Edition), 2024, 51(12): 107-118.
- [17] 张强,杜海强,赵伟康,等.基于改进 YOLOv8 的道路病害视觉识别算法[J].现代电子技术,2024,47(23):119-124.
- [18] ZH Q, DU H Q, ZHAO W K, et al. Visual recognition algorithm for road disease based on improved YOLOv8 [J]. Modern Electronic Technology, 2024, 47(23):119-124.
- [19] 王海群,王炳楠,葛超.重参数化 YOLOv8 路面病害检测算法[J].计算机工程与应用,2024,60(5):191-199.
- [20] WANG H Q, WANG B N, GE CH. Reparameterized YOLOv8 pavement distress detection algorithm [J]. Computer Engineering and Applications, 2024, 60(5): 191-199.
- [21] TIAN Z, SHEN C, CHEN H, et al. FCOS: A simple and strong anchor-free object detector [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 44(4): 1922-1933.
- [22] CHEN Z X, HE Z W, LU ZH M. DEA-Net: Single image dehazing based on detail-enhanced convolution and content-guided attention[J]. IEEE Transactions on Image Processing, 2024, 33:1002-1015.
- [23] ZHANG X, LIU C, YANG D, et al. RFACConv: Innovating spatial attention and standard convolutional operation[J]. ArXiv preprint arXiv:2304.03198, 2023.
- [24] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13713-13722.
- [25] XU W, WAN Y. ELA: Efficient local attention for deep convolutional neural networks [J]. ArXiv preprint arXiv:2403.01123, 2024.
- [26] LEE J, PARK S, MO S, et al. Layer-adaptive sparsity for the magnitude-based pruning[J]. ArXiv preprint arXiv:2010.07611, 2020.
- [27] ARYA D, MAEDA H, GHOSH S K, et al.

- Crowdsensing-based road damage detection challenge (CRDDC'2022) [C]. 2022 IEEE International Conference on Big Data. IEEE, 2022: 6378-6386.
- [22] 交通运输部公路科学研究院. JTG 5210-2018 公路技术状况评定标准[S]. 北京:人民交通出版社,2019.
- Ministry of Transportation and Highway Research Institute. JTG 5210-2018 Highway technical condition assessment standard[S]. Beijing: People's Transportation Press, 2019.
- [23] 王雪秋,高换兵,郑泽萌. 改进 YOLOv8 的道路缺陷检测算法[J]. 计算机工程与应用, 2024, 60(17): 179-190.
- WANG X Q, GAO H B, JIA Z M. Improved road defect detection algorithm for YOLOv8 [J]. Computer

Engineering and Applications, 2024, 60(17): 179-190.

作者简介

李昊炎,硕士,主要研究方向为计算机视觉、图像识别及分类相关应用。

E-mail: lihaoyan@stu.ynu.edu.cn

姜男(通信作者),本科,工程师,主要研究方向为智慧交通、公路基础设施数字化等。

E-mail: 1186285437@qq.com

梁虹,硕士,教授,主要研究方向为深度学习和信号处理。

E-mail: liangh@ynu.edu.cn

吴蓉,硕士,主要研究方向为计算机视觉与目标检测。

E-mail: agnes782@163.com

黄斯琪,硕士,主要研究方向为桥梁三维重建。

E-mail: 1209007582@qq.com