

DOI:10.19651/j.cnki.emt.2517861

基于改进 YOLOv8 的道路缺陷检测^{*}

王晓雯 孙琪瑞 常居泰

(山西大学物理电子工程学院 太原 030006)

摘要: 针对目前道路缺陷检测模型在复杂背景下检测精度不高、计算复杂度高、错检漏检率高的问题,本文基于YOLOv8模型进行了改进。首先,在模型的特征提取网络(Backbone)中融入EMA注意力机制,提高模型的特征表示能力,同时保留重要信息、减少计算成本;其次,将轻量级的特征融合网络结构 SlimNeck 与加权特征融合机制 Weighted Fusion 结合构成新的颈部网络结构 SWNeck,有效降低模型参数量与计算复杂度,提高特征融合效率,减少噪声的特征冗余;最后,引入 Slide Loss 权重函数,给难以正确分类的样本赋予更大的权重,提高模型对于道路缺陷中的难样本数据的学习能力,进一步增强模型检测性能。实验结果表明,改进后的道路缺陷检测模型相较于原YOLOv8n模型 mAP 提高 2.7%,模型参数量、计算量分别降低 7% 和 10%。

关键词: 道路缺陷检测;YOLOv8;注意力机制;Slide Loss

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: 520.6040

Road defect detection based on improved YOLOv8

Wang Xiaowen Yu Qirui Chang Jutai

(College of Physics and Electronic Engineering, Shanxi University, Taiyuan 030006, China)

Abstract: In order to solve the problems of low detection accuracy, high computational complexity and high false detection and missed detection rate of the current road defect detection model in complex background, this paper is improved based on the YOLOv8 model. Firstly, the EMA attention mechanism is integrated into the feature extraction network(Backbone) of the model to improve the feature representation ability of the model, while retaining important information and reducing the computational cost . Secondly, the lightweight feature fusion network structure SlimNeck and the weighted feature fusion mechanism Weighted Fusion were combined to form a new neck network structure SWNeck, which effectively reduced the number of model parameters and computational complexity, improved the feature fusion efficiency, and reduced the feature redundancy of noise. Finally, the Slide Loss weight function is introduced to give greater weight to the samples that are difficult to classify correctly, improve the learning ability of the model for difficult sample data in road defects, and further enhance the detection performance of the model. The experimental results show that the improved road defect detection model improved mAP by 2.7% compared to the original YOLOv8n model, and the amount of parameters and computational complexity of the model were reduced by 7% and 10%, respectively.

Keywords: road defect detection; YOLOv8; attention mechanisms; Slide Loss

0 引言

随着交通运输业和城市化的飞速发展,作为城市交通主动脉的道路,其质量与完整性会极大地影响人们的日常通行安全、效率以及财产等。然而,由于路面长期承受车辆负载、自然环境的侵蚀以及施工和维护的不足,道路表面及内部结构容易出现不同类型的缺陷,如裂缝、坑洼、坑洞、剥

落等问题。若利用传统人工方法采集路面状况并加以分析,造成的时间及人工成本偏高。因此,为了保持道路的安全性、提升道路养护效率,有效准确的道路缺陷检测至关重要。

道路缺陷检测大致分为两类,一类为传统的道路缺陷检测方法,包括阈值分割法^[1]、边缘检测法^[2]、区域增长法^[3]。传统方式需要人为提取缺陷特征,导致效率低且实

收稿日期:2025-01-09

*基金项目:山西省基础研究计划项目(202203021222016)资助

用性差,无法满足日益增加的道路维护需求。随着深度学习方法在各种目标检测、图像处理的任务中获得了硕大的关注。在道路缺陷检测任务中,越来越多的学者选择利用深度学习的方法来实现。其中大致分为两大类:两阶段检测算法及单阶段检测算法。两阶段检测算法中,Faster R-CNN^[4]、Mask R-CNN 等^[5]模型占据重要地位。如 Sekar 等^[6]提出一种基于感兴趣区域和全局平均池化对齐的 Faster R-CNN 方法来检测不同的道路缺陷;Kim 等^[7]介绍了一种新型缺陷检测模型,该模型使用掩码和基于位置的完全卷积神经网络(Mask R-CNN)来检测裂缝。单阶段算法以 SSD(single shot multiBox detector)算法^[8]和 YOLO(you only look once)系列算法为代表,YOLO 算法不仅速度更快,检测精度也更高,因此引起了更多的关注。如 Wang 等^[9]使用 YOLOv3 算法构建了路面缺陷检测模型,实现了自动特征提取,检测速度有所提高,但灵活性仍然较差,难以满足嵌入式系统所需的灵活性。Zhu 等^[10]提出了 TPH-YOLOv5。他们用 Transformer 预测头^[11]取代了以前的预测头,并添加了卷积块注意力模块(convolutional block attention module,CBAM)^[12]来处理航拍图像。然而,transformer 结构在图像上产生了非常高的计算复杂性。Huang 等^[13]提出了一种基于改进的 YOLOv7 架构的轻量级道路缺陷检测模型,模型通过融合四个关键加强功能,实现了参数和计算量的均衡。高敏等^[14]基于 YOLOv7 进行了改进,融入坐标注意力机制(coordinate attention,CA)注意力机制同时利用双向特征金字塔网路来提高模型的检测精度,但其模型的泛化性能不足。周建新等^[15]提出一种改进的 YOLOv8 算法,设计了新的 C2f-Dysnake 模块及 RDIFPN 网络,使模型对细长裂缝的提取能力提高,但代价是增加了模型的体积和计算复杂度。王雪秋等^[16]提出一种新型道路缺陷检测模型 DML-YOLO,利用可变形卷积技术及多路径聚合的坐标注意力机制(multiPath coordinate attention,MPCA)进一步提升

了模型的检测精度,但其仍存在部分漏检情况。

虽然上述研究所提出的方法在道路缺陷检测上有不同程度的提升,但仍存在模型体积偏大、计算复杂度高、误检漏检的问题。并且目前的道路缺陷检测依然面临着不同的挑战与困难,比如:在真实路面环境中由于树木遮盖、阳光照射不均匀和行人等的干扰,有些检测模型对道路进行检测时易发生错检和遗漏的情况;并且其检测精度与计算成本无法同时兼顾。基于此,本文以 YOLOv8n 模型为基础,对以上难点进行优化改进。具改进方案如下:

1) 将基于跨空间学习的高效多尺度注意力机制(efffient multi-scale attention,EMA)^[17]融入原模型的特征提取网络(Backbone)的末尾,通过跨空间学习来捕捉多尺度信息,同时减少计算开销,提高计算效率。

2) 对特征融合(Neck)部分进行了重新设计,提出将基于轻量级卷积技术 GSConv 设计的颈部网络 SlimNeck^[18]与加权特征融合机制 Weighted Fusion 相结合构成新的颈部网络 SWNeck 替换原有的颈部网络,其提升了模型的特征融合效率,提高了模型的检测性能,并实现了模型的轻量化。

3) 对于数据集中存在部分难以准确检测的样本的问题,引入 Slide Loss^[19]权重函数对原模型的分类损失函数进行优化改进,其在训练过程中可以赋予更大的权重给难检测的样本,使模型更有效地学习并区分难易样本数据。

1 YOLOv8 网络结构

YOLOv8 是 YOLOv5 的更新版本,其在 YOLOv5 的基础上首先将 C3 模块替换为了梯度流更丰富的 C2f 模块;其次,采用了目前主流的解耦头设计,将分类与检测头分离,同时其采用了无锚框(Anchor-Free)的设计;最后,采用了 TAL(task alignment learning)动态分配策略,应用了更多的数据增强技术,如随机裁剪、颜色调整等。YOLOv8n 模型结构如图 1 所示。

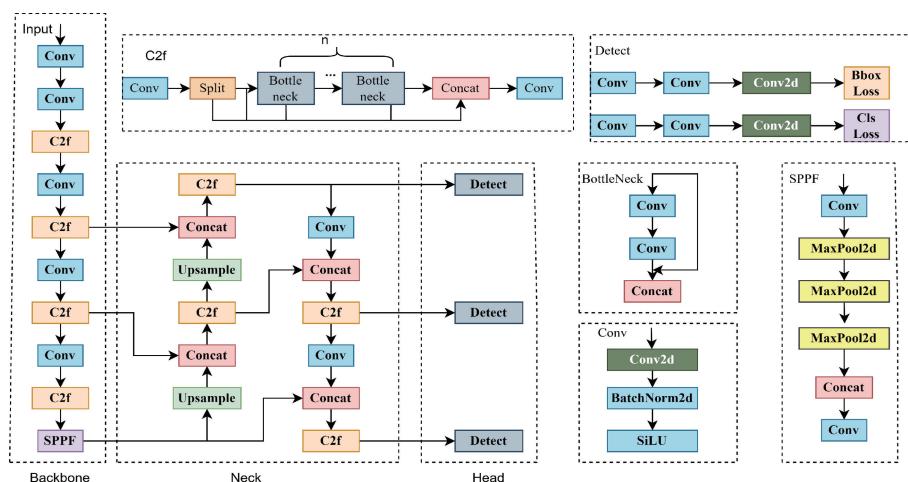


图 1 YOLOv8n 模型

Fig. 1 YOLOv8n model

2 改进的 YOLOv8 模型

为了解决 YOLOv8n 模型检测时的误检、漏检以及计算复杂度和参数量较大的问题。本文基于 YOLOv8n 模型进行了改进,首先,在 Backbone 的末端融入一种高效多尺度注意力机制模块 EMA,增强模型的特征提取及表示能力同时减少计算开销;其次,将原有的颈部网络结构替换为由 SlimNeck 以及加权特征融合机制^[20](weighted fusion)结合的 SWNeck 颈部网络结构,其不仅可以降低模型的参数量和计算量,并且有效地增强了模型的检测性能;最后,利用 Slide Loss 权重函数优化原有的分类损失函数,在模型训练阶段赋予更大的权重给难检测样本数据,使模型充分学习道路缺陷数据集中的难辨别、易混淆的样本,从而进一步提升模型的检测准确度。改进后的 YOLOv8n 网络模型结构如图 2 所示。

fusion)结合的 SWNeck 颈部网络结构,其不仅可以降低模型的参数量和计算量,并且有效地增强了模型的检测性能;最后,利用 Slide Loss 权重函数优化原有的分类损失函数,在模型训练阶段赋予更大的权重给难检测样本数据,使模型充分学习道路缺陷数据集中的难辨别、易混淆的样本,从而进一步提升模型的检测准确度。改进后的 YOLOv8n 网络模型结构如图 2 所示。

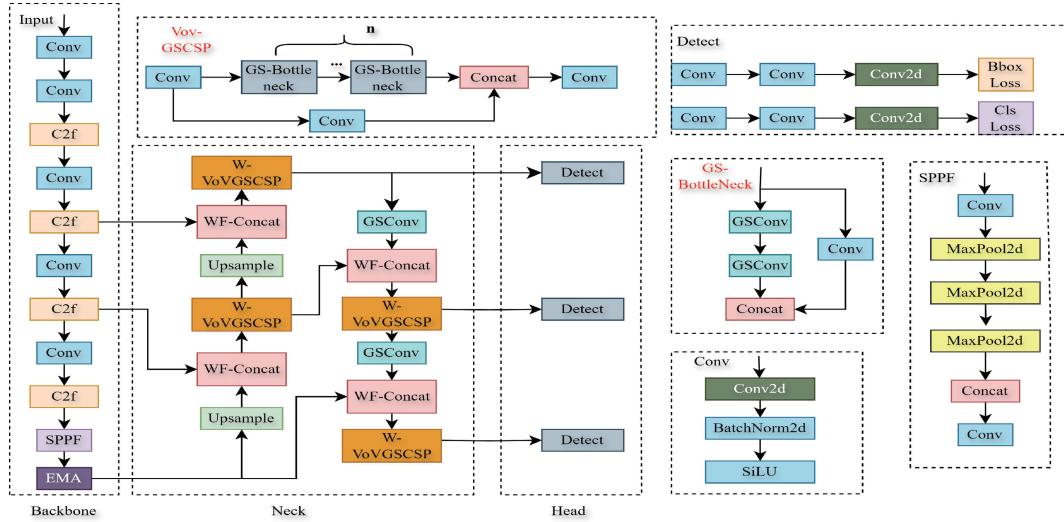


图 2 改进 YOLOv8n 模型

Fig. 2 Improved YOLOv8n model

2.1 EMA 注意力机制

由于真实道路环境存在干扰因素,且在部分背景环境特征的影响下,难以准确区分道路表面缺陷目标特征,进而导致模型无法有效准确地辨别和提取缺陷特征。同时,道路图像通过网络卷积层之后,会造成模型通道中存在冗余信息、特征图缩小,进而在模型检测过程中遗漏部分特征信息,使模型检测准确度低。综上,本文在特征提取网络(Backbone)的输出之后融入一种跨空间学习的高效多尺度注意力机制 EMA,它采用了多尺度并行子网路结构,可以在通道不降低维度的前提下,有效融合跨纬度交互信息,显著提升模型的特征表示能力。

输入特征图经过 EMA 注意力机制时,其部分通道首先被重塑至批次维度,同时,通道维度被分成若干子特征,随后这些子特征分别经过不同的分路进行进一步的处理:一路通过一维全局池化来处理,一路经过 3×3 的卷积操作生成特征图;之后,利用 Sigmoid 激活函数及归一化操作对两个分路的输出特征进行调制,同时各并行分路之间进行信息交换并更新通道权重,以此来获得像素级的关系;最终,各分路特征信息输出叠加后通过最后的 Sigmoid 激活函数调节得到输出特征。综上,在 Backbone 的末尾引入 EMA 可以有效提升模型特征提取能力及检测精度。EMA 注意力机制的结构如图 3 所示。

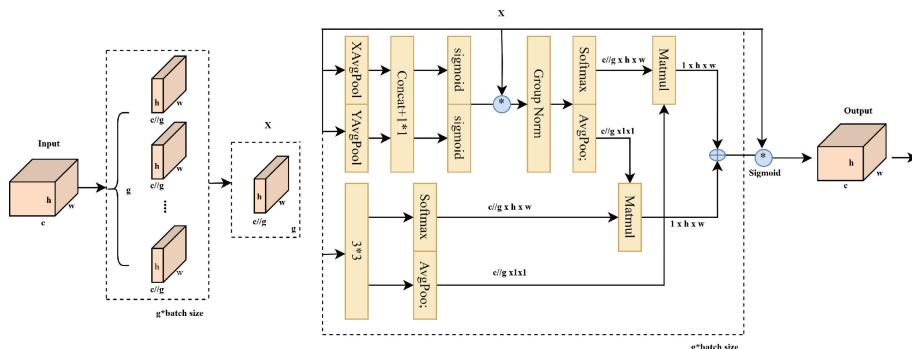


图 3 EMA 结构

Fig. 3 EMA structure

2.2 SWNeck 颈部网络

YOLOv8 的颈部网络采用的是 PAN-FPN(路径聚合网络-特征金字塔网络)的结构,可以有效聚合捕获的多尺度特征信息,实现了信息的跨尺度传递。然而,颈部网络中的卷积以及 C2f 模块参数量较大,同时会造成冗余计算。并且,其特征融合仅仅是通过简易的相加或者叠加方式实现的,无法对缺陷目标的特征进行有效的聚合,从而导致检测精度较低。因此,本文将基于 GSConv 卷积技术设计的轻量化网络结构 SlimNeck 与加权特征融合机制(weighted fusion)融合构成了新的颈部网络 SWNeck,在降低了模型的参数量和计算复杂的同时提高了特征融合效率,减少噪声的特征冗余,从而提升模型的性能。

首先,本文将原颈部网络中的标准卷积 Conv 替换为轻量级卷积 GSConv,其有效减少了模型的计算量和参数量,并保证了模型的准确性;其次,将 VoVGSCSP(vanilla object vocabulary global semantic contextual spatial pyramid)模块中的特征融合模块 Concat 结合加权特征融合机制(weighted fusion)构成一种新的特征融合模块 WF-Concat,因此 VoVGSCSP 模块改进为 W-VoVGSCSP 模块,提升特征融合性能的同时实现了轻量化;同时,利用 WF-Concat 模块替换颈部网络中的 4 个 Concat 模块,进一

步提升模型检测精度,这样改进后,原 YOLOv8 模型的 Neck 即替换为改进后的 SWNeck。VoVGSCSP 及 W-VoVGSCSP 结构如图 4 所示。

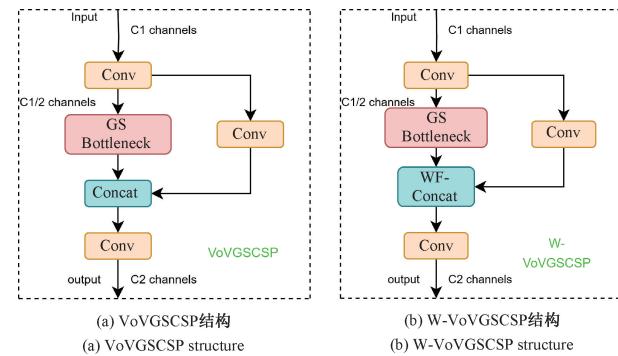


图 4 模块改进对比图

Fig. 4 Comparison chart of module improvement

GSConv 与标准卷积相比拥有更少的参数量和计算量,但其与标准卷积的学习能力相当。它首先通过标准卷积生成特征图,再将此特征图经过深度可分离卷积操作得到新的特征图,之后将两个特征图拼接之后经过一个通道混洗操作重新排列特征通道,提高特征间的信息流动,最后得到输出特征图。GSConv 结构如图 5 所示。

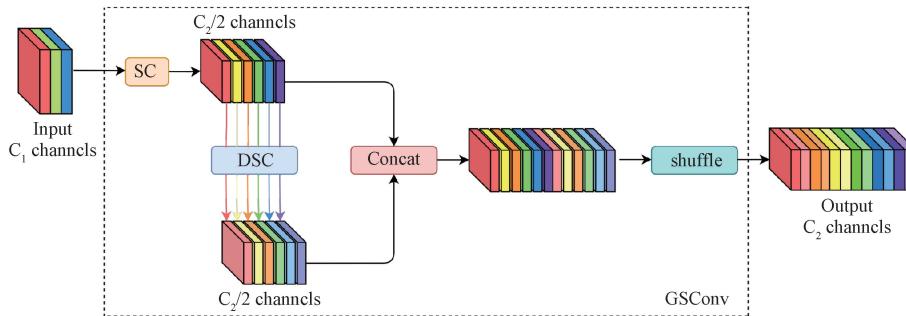


图 5 GSConv 结构

Fig. 5 The structure of the GSConv

加权特征融合机制(Weighted Fusion)可以进一步增强模型的特征融合能力,其通过把输入特征图加权并求和的方式,来整合不同尺度的特征图。权重系数是一种可学习的参数,通过网络的自主学习可以获得。这些参数通过调整不同尺度特征在融合过程中的重要性,赋予更高的权重给信息量更大的特征,以此来更好地融合多尺度特征信息。其输入输出关系如下:

$$\mathbf{O} = \sum_i \frac{\omega_i}{\epsilon + \sum_j \omega_j} \cdot \mathbf{I}_i \quad (1)$$

其中, \mathbf{I}_i 是输入特征图, ω_i 是输入特征 \mathbf{I}_i 的一个可学习的权重, 初始率 $\epsilon = 0.0001$, ω_i 是学习权重, \mathbf{O} 是输出特征。

2.3 Slide Loss 权重函数

YOLOv8 模型中使用的是结合了 Sigmoid 激活函数和二元交叉熵损失的复合损失函数(BCEWithLogitsLoss)。这个函数在处理二分类问题时非常有用,因为其内部进行了 Sigmoid 操作。但在道路缺陷检测时,由于数据集中的简单样本占多数,样本分布不均衡,模型会更聚焦于简单样本,使模型不能够正确分类困难样本数据。基于此,本文引入了 Slide Loss 权重函数改进分类损失函数,用于解决样本不平衡问题。在模型训练阶段,它通过给不同难度的样本赋予不同的权重,使模型更聚焦于难以正确分类的样本,进而增强模型的泛化能力,提升检测准确性。具体来说,它通过对预测框和真实框之间的交并比(IoU)进行加权,设置一个阈值 μ ,其值为所有边界框交并比(IoU)的均值,比 μ 小的属于负样本,比 μ 大的属于正样本,使得难分类样本获得更高的权重。然后,根据样本的交并比(IoU)值和阈值 μ 的关系,使用不同的权重函数对损失进行加权。该函数可视化如图 6 所示。

YOLOv8 模型中使用的是结合了 Sigmoid 激活函数

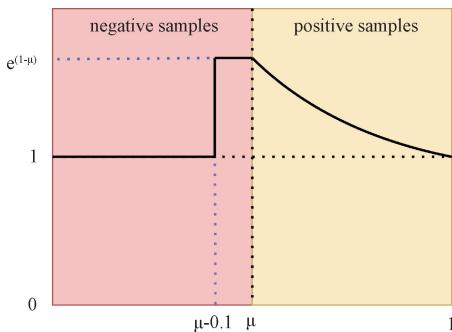


图 6 Slide Loss 权重函数

Fig. 6 Slide Loss weighting function

Slide Loss 权重函数如下：

$$f(x) = \begin{cases} 1, & x \leqslant \mu - 0.1 \\ e^{(1-\mu)}, & \mu < x < \mu - 0.1 \\ e^{(1-x)}, & x \geqslant \mu \end{cases} \quad (2)$$

其中, μ 是所有边界框交并比(IoU)的均值。

将 Slide Loss 权重函数与原分类损失函数相乘即得到改进后的分类损失函数：

$$\text{loss}_{\text{new}} = f(x) \times \text{BCEWithLogitsLoss} \quad (3)$$

3 实验分析

3.1 数据集介绍及预处理

本文使用 RDD2022(Road Defect Detection2022)开源数据集^[21],其涵盖了来自中国、印度、日本、捷克、美国及挪威等 6 个国家所收集的 47 420 张图像。本文挑选其中的中国数据集部分,包括 China_Drone 图像集以及 China_Motorcycle 图像集,总共有 4 378 张图像,共计 4 650 个道路缺陷。缺陷样本种类有纵向裂缝 D00、横向裂缝 D10、网状裂缝 D20、坑洞 D40 以及修补 Repair 五类。由于数据集中的类别分配不平衡,导致检测准确度低,模型泛化能力低。因此,本文采用上下翻转、90°旋转、25% 的灰度级处理等数据增强手段来提高模型的泛化能力,最终得到 9 204 张图像。实验按照 8:1:1 将数据集随机划分为训练集、验证集、测试集。其中训练集有 7 292 张图像、验证集 955 张图像、测试集 957 张图像。

3.2 实验设置

本文实验环境及参数设置如表 1 所示。

3.3 评价指标

本文使用的模型评价指标包含每秒十亿次浮点运算数(GFLOPs)、模型参数量(Parameters)、模型体积大小(Size)以及以下 3 种重要指标:

精度值(precision, P):

$$P = \frac{TP}{TP + FP} \quad (4)$$

召回率(recall, R):

$$R = \frac{TP}{TP + FN} \quad (5)$$

表 1 实验参数配置

Table 1 Experimental parameter configuration

名称	参数
操作系统	Ubuntu 22.04.3
GPU	RTX 3080, 10 G
编程语言	Python3.11
深度学习框架	PyTorch2.4.0+Cuda12.1.1
训练轮数	300
图像尺寸	640×640
优化器	AdamW
学习率	0.001
Batchsize	16
Workers	8
Pretrained	False

平均精度均值(mean average precision, mAP):

$$AP = \int_0^1 P(R) dR \quad (6)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP(i) \quad (7)$$

其中, P 与 mAP 值越大说明模型检测精度越高, GFLOPs、模型参数量及模型体积是反应模型轻量化的程度,值越小说明轻量化程度越高。召回率 R 代表数据集中正样本被正确预测为正的比例。

上述式中: TP 为真阳性, 代表真实类别为正例且正确预测的正样本数目; FP 为假阳性, 代表真实类别为负例但预测错误的样本数目; FN 为假阴性, 代表真实类别为正例且预测错误的样本数目; AP 是 $P(R)$ 曲线的面积; n 表示种类总数。

3.4 消融实验对比

为了验证本文改进模型检测性能的有效性, 进行了一系列消融实验。如表 2 所示, 第 1 组代表原 YOLOv8n 模型, 即基线模型。本文在 YOLOv8n 模型的基础上分别加入 EMA 注意力机制(第 2 组)、SWNeck(第 3 组)、Slide Loss(第 4 组), 之后在第 1 组的基础上加入 SWNeck(第 5 组), 在第 5 组的基础上加入 Slide Loss(第 6 组), 将它们与基线模型进行比较。通过表中的数据可以得出, 相比于原 YOLOv8n 模型, 改进后的模型拥有更高的精度以及相对更低的计算量和参数量。其中第 2 组在主干网络的末尾引入 EMA 注意力机制使 P 值提升 3.8%, mAP 提高 1.3%, GFLOPs 和参数量与基线持平; 第 3 组将原颈部网络替换为改进后的颈部网络 SWNeck 使 P 值提升 1.3%, mAP 提高 1%, 同时参数量下降 7%, GFLOPs 下降 10%; 第 4 组引入 Slide Loss 权重函数使 P 值提升 0.6%, mAP 提高 0.4%, GFLOPs 及参数量与基线持平; 第 5 组同时引入 EMA 注意力机制及 SWNeck 使 P 值提升 4%, mAP 值提高 2.5%, 参数量下降 7%, GFLOPs 下降 10%; 第 6 组同时

引入EMA、SWNeck以及Slide Loss函数使P值提升3.6%，mAP值提升2.7%，参数量下降7%，GFLOPs下降10%。通过对原YOLOv8n模型，改进后的模型的精度P、平均

精度均值mAP以及召回率R都有较大的提升，同时参数量和GFLOPs也有所下降，证明改进后的模型在准确性及轻量化上实现了均衡，从而有效地降低了模型的计算成本。

表2 消融实验结果对比

Table 2 Comparison of ablation results

组别	EMA	SWNeck	Slide Loss	P/%	R/%	mAP50/%	Parameter/10 ⁶	GFLOPs	Size/MB
1				80.9	76.8	83.6	3.01	8.1	6.0
2	√			84.7	75.5	84.9	3.01	8.1	6.0
3		√		82.2	77.6	84.6	2.80	7.3	5.6
4			√	81.5	78.3	84.0	3.01	8.1	6.0
5	√	√		84.9	79.0	86.1	2.80	7.3	5.7
6	√	√	√	84.5	82.0	86.3	2.80	7.3	5.7

3.5 不同模型对比实验

为了进一步验证本文改进模型的性能，将改进后的模型与其他传统算法进行了比较，包括两阶段算法如Faster RCNN、单阶段YOLO系列算法如YOLOv5s^[22]、YOLOv6n、YOLOv7tiny、YOLOv8n及两个最新的基于YOLOv8的改进模型^[23-24]，结果如表3所示。

表3 不同模型对比

Table 3 Comparison of different models

模型	mAP50/%	Parameters	GFLOPs
Faster RCNN	75.9	136.51	370.2
YOLOv5s	83.2	9.12	23.8
YOLOv6n	78.4	4.23	11.8
YOLOv7tiny	84.9	6.02	13.2
YOLOv8n	83.6	3.01	8.1
文献[23]	85.3	13.16	17.6
文献[24]	85.7	2.50	7.2
改进模型	86.3	2.80	7.3

实验结果表明，本文改进后的模型相较于所比较的模型，在平均准确值mAP50上均优于所比较的模型。文献[24]的改进模型虽然参数量及计算复杂度要比本文模型低，但mAP50方面有一定程度的差距。因此，相比之下本文改进后的模型的精度最优，并且满足了实时监测的需求，展现出了优于其他对比模型的性能，可以有效且高精度地实施道路缺陷检测。

3.6 改进模型有效性分析

将YOLOv8n与改进后的模型做进一步的对比，以此来证明改进模型的有效性。如图7(a)所示为YOLOv8n模型检测效果，图7(b)为改进模型的检测效果。图中可以看出，第1张图及第4张图中YOLOv8n出现了漏检情况，改进模型检测出更多的缺陷；第2张图与第3张图中原模型出现了错检现象，其对同一个缺陷目标检测出了多个结果，而改进模型有效地解决了这个问题，并且检测精度更高。说明改进后的模型对不同缺陷的识别和检测更准确。



(a) 原YOLOv8n模型
(a) Original YOLOv8n model



(b) 改进YOLOv8n模型
(b) Improved YOLOv8n model

图7 检测效果对比

Fig. 7 Comparison of detection effects

4 结 论

为了解决复杂背景下道路缺陷检测容易出现漏检误检的问题以及数据集中的样本不平衡问题,本文基于YOLOv8n模型进行了改进。首先,在主干网络的末尾引入EMA注意力机制,在降低计算成本的同时有效保留了每个通道的特征信息,增强特征提取能力;其次,利用GSConv设计的SlimNeck结构融合加权特征融合机制设计一种新的颈部网络结构SWNeck,提升特征融合效率并降低模型的复杂度,从而提高了模型的检测精度;最后,引入Slide Loss权重损失函数,对数据集中的困难样本进行重新的权重分配,使难样本在训练过程中获得更高的关注,从而提升模型的检测性能。实验结果表明改进后的模型拥有更高的精度,其平均精度均值提高了2.7%,同时模型的参数量降低7%,GFLOPs降低10%。因此,本文的改进方案在提升精度的同时,也实现了模型的轻量化,为真实道路环境下的道路缺陷检测提供了新的方案。未来工作的重点将聚焦于体积更小的模型,进一步降低模型的计算量及参数量,同时保证准确度,以提升模型在真实环境下的道路养护及缺陷检测的实用价值。

参考文献

- [1] DEVI M P A, LATHA T, SULOCANA C H. Iterative thresholding based image segmentation using 2D improved Otsu algorithm [C]. 2015 Global Conference on Communication Technologies(GCCT). IEEE, 2015: 145-149.
- [2] 包启龙,景会成,张靖轩,等.一种改进Canny算子的图像边缘检测方法[J].现代电子技术,2024,47(23):36-42.
BAO Q L, JING H CH, ZHANG J X, et al. An improved image edge detection method for Canny operator[J]. Modern Electronic Technology, 2024, 47(23):36-42.
- [3] HU W B, WANG W D, AI CH B, et al. Machine vision-based surface crack analysis for transportation infrastructure[J]. Automation in Construction, 2021, 132: 103973.
- [4] 刘应桃,郭世伟,付孟新,等.基于改进Faster RCNN的轮对踏面缺陷检测[J].电子测量技术,2023,46(12):34-41.
LIU Y T, GUO SH W, FU M X, et al. Wheelset tread defect detection based on improved Faster RCNN[J]. Electronic Measurement Technology, 2023, 46 (12): 34-41.
- [5] 石杰,周亚丽,张奇志.基于改进Mask RCNN和Kinect的服务机器人物品识别系统[J].仪器仪表学报,2019,40(4):216-228.
- [6] SHI J, ZHOU Y L, ZHANG Q ZH. Item recognition system for service robot based on improved Mask RCNN and Kinect[J]. Chinese Journal of Scientific Instrument, 2019, 40(4): 216-228.
- [7] SEKAR A, PERUMAL V. Automatic road crack detection and classification using multi-tasking Faster RCNN[J]. Journal of Intelligent & Fuzzy Systems, 2021, 41(6): 6615-6628.
- [8] KIM B, CHO S. Image-based concrete crack assessment using mask and region-based convolutional neural network [J]. Structural Control and Health Monitoring, 2019, 26(8): e2381.
- [9] 赵友章,吕进.基于改进SSD的交通标志检测算法[J].电子测量技术,2023,46(7):151-158.
ZH Y ZH, LYU J. Traffic sign detection algorithm based on improved SSD[J]. Electronic Measurement Technology, 2023, 46(7): 151-158.
- [10] WANG Q L, MAO J CH, ZHAI X, et al. Improvements of YOLOv3 for road damage detection[C]. Journal of Physics: Conference Series. IOP Publishing, 2021, 1903(1): 012008.
- [11] ZHU X, LYU S, WANG X, et al. TPH-YOLOv5: Improved YOLOv5 based on transformer prediction head for object detection on drone-captured scenarios [C]. IEEE/CVF International Conference on Computer Vision, 2021: 2778-2788.
- [12] 钱承山,沈有为,孙宁,等.基于Transformer改进YOLOv5的山火检测方法研究[J].电子测量技术,2023,46(16):46-56.
QIAN CH SH, SHEN Y W, SUN N, et al. Research on improved wildfire detection method of YOLOv5 based on Transformer [J]. Electronic Measurement Technology, 2023, 46(16): 46-56.
- [13] 杨昆,孙宇峰,汪世伟,等.YOLOF-CBAM:一种新的结直肠息肉实时分类与检测方法[J].电子测量技术,2023, 46(16):138-147.
YANG K, SUN Y F, WANG SH W, et al. YOLOF-CBAM: A new real-time classification and detection method for colorectal polyps [J]. Electronic Measurement Technology, 2023, 46(16):138-147.
- [14] HUANG P L, WANG SH H, CHEN J Y, et al. Lightweight model for pavement defect detection based on improved YOLOv7 [J]. Sensors, 2023, 23(16): 7112.
- [15] 高敏,李元.基于YOLOv7-CA-BiFPN的路面缺陷检测[J].计算机测量与控制,2024,32(9):9-14.
GAO M, LI Y. Pavement defect detection based on YOLOv7-CA-BiFPN[J]. Computer Measurement and

- Control, 2024, 32(9): 9-14.
- [15] 周建新,张媛,贾梓涵,等.改进 YOLOv8 的路面缺陷检测算法[J].电子测量技术,2024,47(19):146-154.
- ZHOU J X, ZHANG Y, JIA Z H, et al. Improved pavement defect detection algorithm of YOLOv8[J]. Electronic Measurement Technology, 2024, 47 (19): 146-154.
- [16] 王雪秋,高焕兵,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. Road defect detection algorithm for improved YOLOv8 [J]. Computer Engineering and Applications, 2024, 60(17): 179-190.
- [17] OUYANG D L, HE S, ZHANG G ZH, et al. Efficient multi-scale attention module with cross-spatial learning [C]. ICASSP 2023-2023 IEEE International Conference on Acoustics, Speech and Signal Processing(ICASSP). IEEE, 2023: 1-5.
- [18] LI H L, LI J, WEI H B, et al. Slim-neck by GSConv: A lightweight-design for real-time detector architectures [J]. Journal of Real-Time Image Processing, 2024, 21(3): 62.
- [19] YU Z P, HUANG H B, CHEN W J, et al. YOLO-facev2: A scale and occlusion aware face detector[J]. Pattern Recognition, 2024, 155: 110714.
- [20] 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.
- [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] 李金涛,周兴林,尹雨飞,等.基于 TAS-YOLO 的道路表面缺陷检测[J].电子测量技术,2024,47 (13): 148-156.
- LI J T, ZHOU X L, YI Y F, et al. Road surface defect detection based on TAS-YOLO[J]. Electronic Measurement Technology,2024,47(13):148-156.
- [23] 李昊璇,苏艳琼.基于改进 YOLOv8 的道路缺陷检测[J].测试技术学报,2024,38(5):506-512.
- LI H X, SU Y Q. Road defect detection based on improved YOLOv8 [J]. Chinese Journal of Testing Technology, 2024, 38(5):506-512.
- [24] 张旭中,李波,贝绍轶,等.改进 YOLOv8 的道路凹陷检测算法[J].重庆理工大学学报(自然科学),2024,38(10):79-87.
- ZHANG X ZH, LI B, BEI SH Y, et al. Improved road depression detection algorithm of YOLOv8[J]. Journal of Chongqing University of Technology (Natural Science), 2024,38(10):79-87.

作者简介

王晓雯,副教授,硕士,主要研究方向为网络通信。

E-mail:yuqirui0225@163.com

于骐瑞(通信作者),硕士研究生,主要研究方向为深度学习、目标检测。

E-mail:976866097@qq.com

常居泰,硕士研究生,主要研究方向为深度学习、目标检测。