

改进 YOLOv8 的路面缺陷检测算法^{*}

周建新 张媛 贾梓涵 何洋

(华北理工大学电气工程学院 唐山 063200)

摘要:为了减少背景干扰对路面缺陷检测的影响,解决对小尺寸细长裂缝能够提取的特征十分有限的问题,本文基于YOLOv8模型进行了改进。首先,将网络中的C2f融合动态蛇形卷积设计了C2f-Dysnake模块改善对目标形状和边界的敏感性,增强了对细长裂缝的特征提取能力;其次,将重参数化泛化特征金字塔网络RepGFPN与动态上采样器DySample结合构成新的颈部网络RDFPN,增加了对低层特征图的关注度,提升了对小目标的检测能力;最后在主干网络中加入MPCA注意力机制,捕捉不同尺度上的位置关系,提高主干网络的特征提取能力。实验结果表明,改进算法在RDD2022数据集上与原算法相比mAP50提高了2.3%,检测速度达到了98 fps,综合考量较其他算法有明显优势,验证了该方法的有效性和优越性。

关键词:YOLOv8;动态蛇形卷积;注意力机制;路面缺陷检测

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

The pavement defect detection algorithm of YOLOv8 was improved

Zhou Jianxin Zhang Yuan Jia Zihan He Yang

(School of Electrical Engineering, North China University of Science and Technology, Tangshan 063200, China)

Abstract: In order to reduce the influence of background interference on pavement defect detection and solve the problem that the features that can be extracted from small-sized slender cracks are very limited, this paper is improved based on the YOLOv8 model. Firstly, the C2f-Dysnake module was designed by fusing the C2f in the network with dynamic serpentine convolution, which improved the sensitivity to the shape and boundary of the target and enhanced the feature extraction ability of the slender cracks. Secondly, the reparameterized generalization feature pyramid network RepGFPN and the dynamic upsampler DySample were combined to form a new neck network RDFPN, which increased the attention to the low-level feature map and improved the detection ability of small targets. Finally, the MPCA attention mechanism is added to the backbone network to capture the position relationship at different scales and improve the feature extraction ability of the backbone network. Experimental results show that the improved algorithm improves mAP50 by 2.3% and reaches 98 fps on the RDD2022 dataset, and the detection speed reaches 98 fps, which has obvious advantages over other algorithms and verifies the effectiveness and superiority of the proposed method.

Keywords: YOLOv8; dynamic serpentine convolution; attention mechanisms; pavement defect detection

0 引言

道路是我国经济发展和人民生活保障的支柱,但随着时间的推移,道路会在自然条件与车辆荷载的共同作用下出现例如裂缝、坑洼等一系列损伤,如若不及时对道路缺陷进行检测与控制,不仅会给后续路面养护工作带来更多的困难,还会严重影响道路安全和行车安全,所以对道路进行高效精准的缺陷检测是维护道路安全的关键之一。

道路缺陷检测技术主要分为两种方式,一种是早期传

统的路面缺陷检测,主要包括基于图像阈值的分割方法^[1]、基于边缘检测的方法^[2]和基于区域生长特征的路面裂缝检测方法^[3]等。另一种检测方法是近年来被使用越来越广泛的基于深度学习的路面缺陷检测方法,包括两阶段算法和单阶段算法。两阶段目标检测算法以Fast R-CNN、Mask R-CNN、U-net为代表。Kang等^[4]使用Faster R-CNN算法的集成来检测道路的裂纹区域。牛慧余等^[5]通过对Mask R-CNN模型的主干网络进行改进,提升了对裂缝的

特征提取能力,有效提高了模型对裂缝的检测精度。单阶段目标检测算法^[6]以 YOLO(you only look once)系列和 SSD(single shot MultiBox detector)为代表。黄开启等^[7]通过对 YOLOv3 网络的多尺度预测模型进行改进,提高了对小裂缝预测的精度。周双喜等^[8]通过在 YOLOv5 主干结构中添加注意力模块,有效提高了对识别 30°裂缝的准确率,且占用的内存更小,检测速度更快。李松等^[9]基于 YOLOv8 网络,结合卷积神经网络与 Transformer 的优势,设计了 BOT 模块,引入了 C2fGhostr 模块以及坐标注意力(coordinate-attention, CA),实现了对路面损伤高准确率且低参数的检测。王海群等^[10]通过在 YOLOv8 主干网络中构建 CNX2f 特征提取模块并引入 RepConv 和重参数模块(diverse branch block, DBB),以及构建 SPPF-Avg 模块,解决了多尺度特征提取不足的问题,有效提高了对路面病害的检测精度。

然而当前道路缺陷检测仍存在一些难题,比如路面缺陷特征和背景环境特征具有相似性、实际道路环境中存在树枝遮挡或光照不均等复杂背景干扰,检测过程容易出现误检、漏检情况;以及道路缺陷形状、大小差异较大,难以对其进行有效特征提取。因此,本文基于 YOLOv8n 模型针

对上述问题进行了改进。包括如下几点贡献:

1) 利用动态蛇形卷积(dynamic snake convolution, Dysnake Conv)设计了 C2f-Dysnake 模块,有效地改善了网络对目标形状和边界的敏感性,增强了对不同尺度、形状和姿态的裂缝的感知能力,提高了模型检测精度。

2) 重新设计了颈部网络,提出了将重参数化泛化特征金字塔网络(reparametrized generalized feature pyramid network, RepGFPN)与动态上采样器 DySample 结合,构成新的颈部网络结构 RepGFPN DySample feature pyramid network(RDFPN),增加了对低层特征图的关注度,提升了对小目标的检测能力。

3) 引入了多路径聚合的坐标注意力机制模块(multipath coordinate attention, MPCA),能够捕捉不同尺度上的位置关系,使其能更好地识别并提取重要特征,减少背景干扰。

1 YOLOv8 网络结构

YOLOv8 是 YOLOv5 的更新版本,其核心改进聚焦于模型架构的优化与性能提升,由输入端、骨干网络、颈部网络和头部网络组成,其网络结构如图 1 所示。

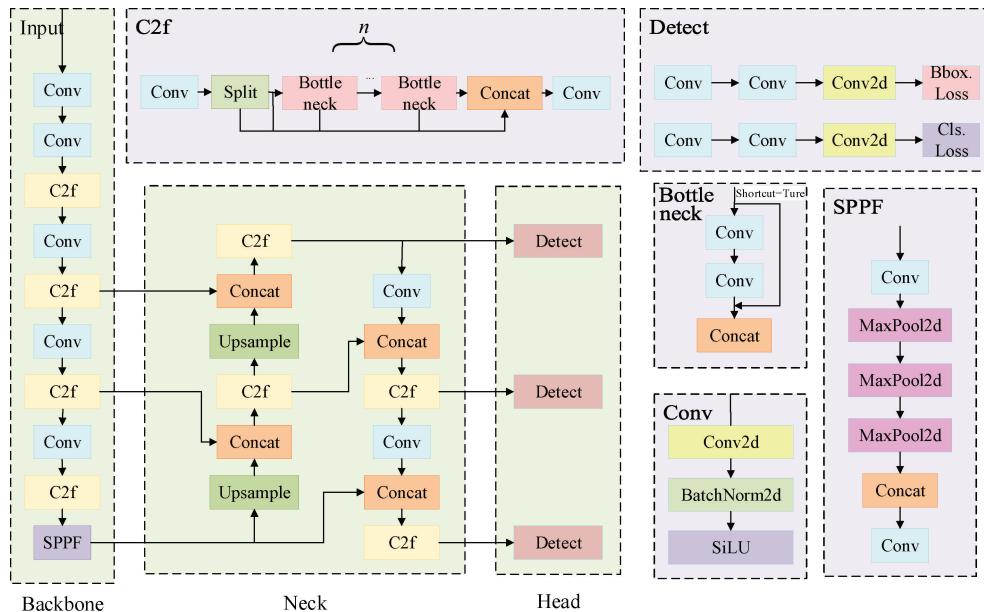


图 1 YOLOv8 网络结构

Fig. 1 YOLOv8 network structure

2 改进的 YOLOv8 网络

为了提高道路缺陷检测的精度,本文提出了一种改进 YOLOv8n 的网络模型,首先,将动态蛇形卷积 Dysnake Conv 与 C2f 模块相融合,得到的 C2f-Dysnake 模块把主干网络的倒数第一个 C2f 模块替换掉,C2f-Dysnake 模块有效地改善了网络对目标形状和边界的敏感性,增强了对不同尺度、形状和姿态的裂缝的感知能力,提高了模型检

测精度。其次,将原有的颈部结构改进为由 RepGFPN 以及动态上采样器 DySample 结合的 RDFPN 颈部网络,在不增加更多计算量的同时,有效提升了模型的精度。最后在主干网络的末端引入了一种多路径聚合的坐标注意力机制 MPCA,它能够捕捉不同尺度上的位置关系,使其在进行道路缺陷检测时,能够更好地识别并提取重要特征,减少背景干扰。改进后的 YOLOv8n 网络结构如图 2 所示。

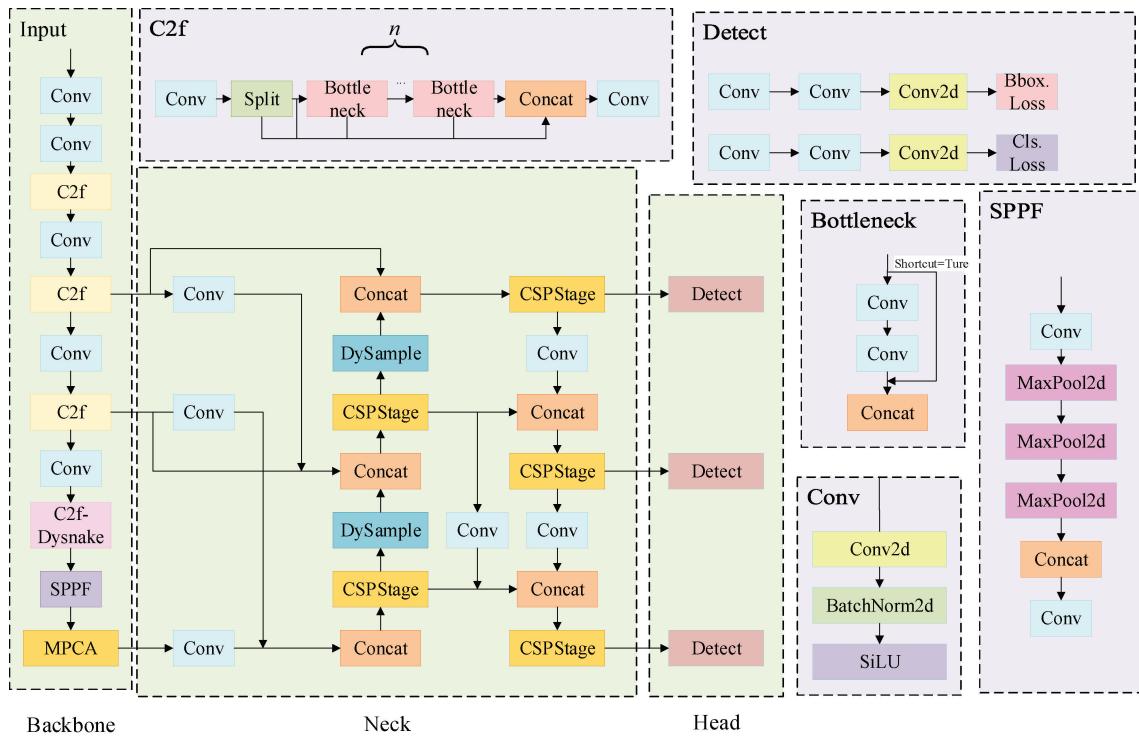


图 2 改进的 YOLOv8 网络

Fig. 2 Improved YOLOv8 network

2.1 C2f-Dyssnake 模块

道路检测的过程中,由于路面缺陷种类大多是大小长短以及弯曲程度不一的裂缝缺陷,有些小目标缺陷很容易被漏检,尤其对尺寸较小的细长裂缝能够提取的特征十分有限,造成对这类裂缝的检测精度效果不佳。为了使模型

能够更精准的识别和定位此类目标缺陷,本文引入一种通过自适应地聚焦于细长和弯曲的局部结构来准确地捕捉管状结构特征的动态蛇形卷积 Dyssnake Conv^[11]与 C2f 结合。它的设计是为了更好地适应细长管状的动态结构,从而更好地感知关键特征。Dyssnake Conv 的结构如图 3 所示。

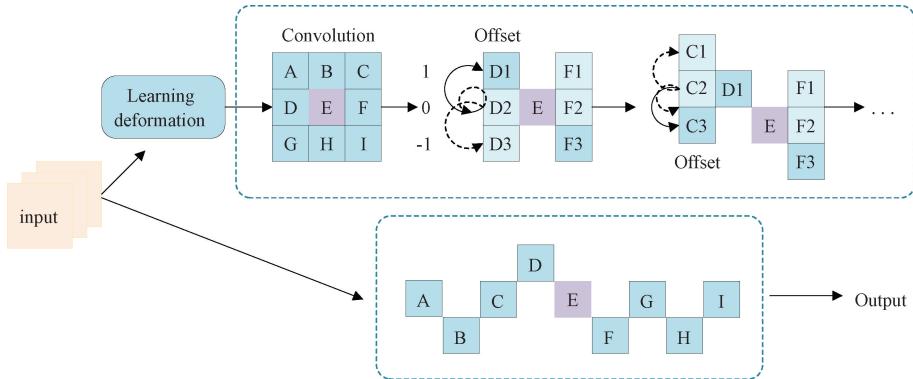


图 3 Dyssnake Conv 结构图

Fig. 3 Structure diagram of Dyssnake Conv

传统的卷积操作通常在处理规则、网格状的数据时效果最佳,但在处理目标形状变化较大的情况下可能存在一定的局限性,而动态蛇形卷积则能够通过引入动态的、可变形的卷积核自适应地调整卷积核的形状和大小,更有效地捕获目标的特征,从而更好地适应目标的特定形状。

将 Dyssnake Conv 与 C2f 模块相融合,其中 Bottleneck 模块中的卷积被替换为 Dyssnake Conv 模块,构成了新的模

块 Dyssnake Bottleneck,从而得到了 C2f-Dyssnake 模块并用其替换主干网络的倒数第一个 C2f 模块。与基准模型相比,C2f-Dyssnake 模块改善了模型对目标形状和边界的敏感性,提升了对路面缺陷的检测精度,且对模型的参数量基本没影响,还增强了模型对不同尺度、形状和姿态的目标的感知能力,从而提高了检测的准确性和鲁棒性。C2f-Dyssnake 模块如图 4 所示。

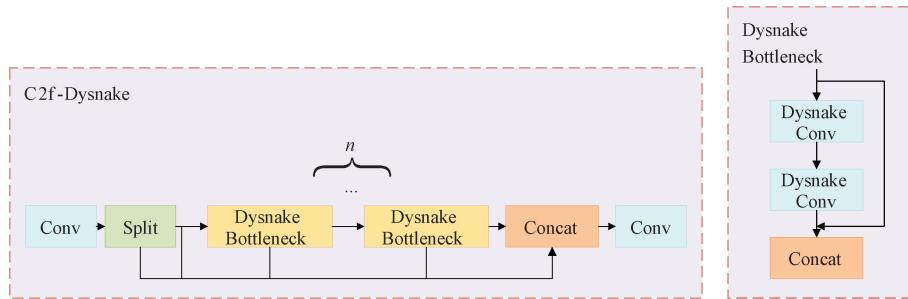


图 4 C2f-Dysnake 结构图

Fig. 4 Structure diagram of C2F-Dysnake

2.2 RDPN 颈部网络

YOLOv8 的颈部主要对提取到的特征进行融合。在原结构的特征金字塔 (feature pyramid network, FPN) 中, 多尺度特征融合旨在聚合从主干中提取的不同分辨率的特征, 从而增强输出特征的表达能力, 提升模型性能。但特征图在经过多次的上下采样后会丢失部分的原始特征信息, 且网络对低层特征图的关注度较低, 容易忽略一些细节信息, 降低对小目标的检测精度, 所以本文结合重参数化泛化特征金字塔网络 (RepGFPN)^[12] 以及超轻量级高效的动态上采样器 (DySample)^[13] 构成了新的颈部网络结构 (RDPN), 增加了模型对低层特征图的关注度, 提升了对小目标的检测能力。RepGFPN 网络结构和 DySample 中的模块设计如图 5、6 所示。

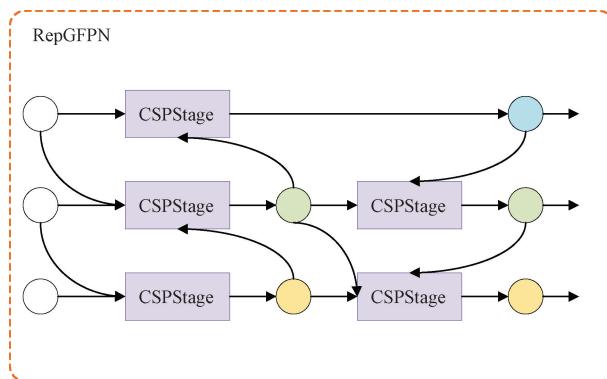


图 5 RepGFPN 结构图

Fig. 5 Structure diagram of RepGFPN

在 ICLR2022 的工作中 GiraffeDet 提出了一种新颖的 Light-Backbone Heavy-Neck 结构, 名为广义模糊神经网络 (generalized feature pyramid network, GFPN)^[14], 它能够充分交换高级语义信息和低级空间信息。RepGFPN 网络是在 GFPN 网络的基础上提出来的。相较于 GFPN, RepGFPN 在融合过程中实行了不同尺度特征使用不同的通道数, 从而在轻量级计算量的约束下, 灵活控制高层特征和低层特征的表达能力, 满足实时目标检测中颈部网络的设计。

但 RepGFPN 网络在增加模型对低层特征图的关注度的同时也会带来一些额外的参数量和运算量, 所以本文将

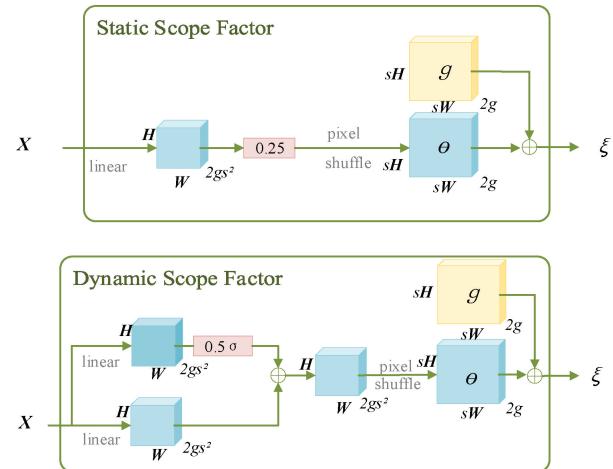


图 6 DySample 中的模块设计

Fig. 6 Module design in DySample

超轻量级高效的动态上采样 DySample 模块添加到 RepGFPN 颈部网络中的前两个 CSPStage 模块之后使得该网络模型进行路面缺陷检测时在不增加更多计算量的同时, 有效提升了模型的精度。

2.3 MPCA 注意力机制

由于路面缺陷特征与部分背景环境特征之间存在相似性, 且环境错综复杂, 为了提高模型对缺陷特征的识别与提取能力, 在基础网络架构的骨干末端融入注意力机制是一种简单有效的方法。注意力机制一般可分为通道注意力机制、空间注意力机制及二者的融合机制, 然而, 常用的通道注意力机制如 SE (squeeze-and-excitation)、CBAM (convolutional block attention module)、CA 等都有一些不足, SE 专注于通道间的相互作用, 却未能充分考虑空间位置信息的价值, 这在视觉任务中往往是至关重要的; CBAM 试图通过全局池化手段在通道层面融入位置信息, 但这种策略主要聚焦于局部信息的整合, 而无法获取长范围依赖的信息; CA 虽然保留了部分位置信息, 但会导致当某一通道中一部分的特征信息的权重较高, 而该通道的整体注意力权重较低时, 该通道中部分重要的信息就会丢失, 从而影响预测结果。

针对上述的问题, 这里引入了一种多路径聚合的坐标

注意力机制 MPCA, 它能很好的考虑多尺度位置信息, 能够捕捉不同尺度上的位置关系, 这使其在进行道路缺陷检

测时, 能够更好地识别并提取重要特征, 减少背景干扰。MPCA 模块结构如图 7 所示。

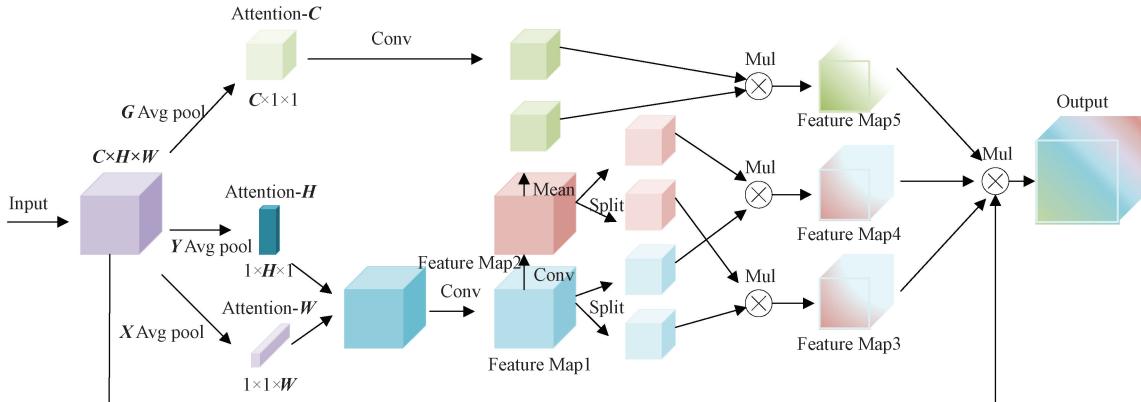


图 7 MPCA 结构图

Fig. 7 MPCA structure diagram

MPCA 注意力机制具体实现为首先分别对输入特征图的高度和宽度方向进行平均池化, 沿两个空间方向聚合特征, 得到两个方向感知的特征图, 保存沿着一个空间方向的精确位置信息, 这样有助于网络更准确地定位感兴趣的目标, 接着对特征图进行全局平均池化, 获得一个具有全局感受野的特征图, 这样可以强化特征图的通道信息, 最后, 为了防止有些部分的特征信息被孤立, 将其与具有方向感知的特征图进行交互融合得到最后结果。将其引入到主干网络的末尾后对路面缺陷检测的精度方面有着很好的提升。

3 实验与结果

3.1 实验环境与数据集

本实验的环境如表 1 所示。

表 1 实验环境

Table 1 Experimental environment

配置	参数
操作系统	Windows10
CPU	12 vCPU Intel ® Xeon ® Platinum 8255C CPU@2.50 GHz
内存	40 GB
GPU	RTX 3080
显存	10 GB
编程语言	Python3.8
深度学习框架	PyTorch 1.10.0+Cuda 11.3

在本实验的网络训练过程中, 所设定的关键超参数详情如表 2 所示。

本实验选用了全球道路损伤检测挑战赛提供的 RDD2022^[15]公开数据集, 该数据集广泛涵盖了来自中国、

表 2 训练超参数

Table 2 Training hyperparameter

名称	参数
数据增强	Mosaic
更新学习率	余弦退火算法
优化器	Auto
训练轮数	300
输入图像	640×640
Batch	16
Pretrained	False

印度、捷克、挪威、美国、日本 6 个国家的丰富道路图像资源, 总量超过四万张。鉴于挪威部分图像尺寸显著异于其他, 为保持数据一致性及训练效率, 剔除了这部分数据, 随后从剩余 5 个国家的图像中随机抽样, 构建了包含 10 000 张图像的实验数据集, 此数据集进一步被划分为训练集、测试集与验证集, 比例为 8:1:1, 以支撑模型的有效训练与性能评估。针对道路损坏的识别, 本数据集聚焦于四种典型损坏类型: D00(代表纵向裂缝)、D10(横向裂缝)、D20(网状裂缝)以及 D40(坑洞), 旨在通过模型训练实现对这些常见道路缺陷的高精度检测。4 种类型缺陷不规则分布在一万张数据集中, 经过检测可知其中 D40(坑洞)在 4 种缺陷类型中训练样本最少。

3.2 评价指标

本文选用平均精度均值 (mean average precision, mAP)、参数量 (Parameters)、每秒十亿次浮点运算数 GFLOPs 和每秒传输帧数 (frames per second, FPS) 作为评价指标, 计算公式如式(1)~(4)所示。

$$P = \frac{TP}{TP + FP} \quad (1)$$

$$R = \frac{TP}{TP + FN} \quad (2)$$

$$AP = \int_0^1 P(r)dr \quad (3)$$

$$mAP = \frac{\sum_{i=0}^n AP_{(i)}}{n} \quad (4)$$

其中, TP 代表模型正确预测的正样本数目, FP 代表模型错误预测的负样本数目, FN 表示正确目标中缺失目标的个数, n 表示缺陷类别的数量。 AP 是对 P-R 曲线的积分, 即曲线与横纵坐标所围成的面积, mAP 为各类预测对象精度的均值, $mAP@0.5$ 是指 IoU 阈值为 0.5 时的 mAP 。

3.3 不同注意力机制对网络性能的影响

为了进一步验证并选择最适宜的注意力机制, 本文不仅聚焦于 MPCA 注意力机制, 还广泛测试了多种其他注意力机制模块作为对照, 如 SE 注意力模块、CBAM 注意力模块、exponential moving average (EMA) 注意力模块、channel prior convolutional attention (CPCA) 注意力模块、SimAM 注意力模块。通过这一对比实验设计, 旨在明确展示 MPCA 注意力机制相较于其他候选方案在性能上的优越性, 从而验证其作为本研究中注意力机制首选的合理性。实验结果如表 3 所示。

从表 3 中可以看出, 添加 MPCA 注意力模块比添加 SE 模块、CPCA 模块、SimAM 模块在 $mAP50$ 上分别高 0.5%、0.3% 和 0.8%, 虽然与添加 CBAM 模块和 EMA 模块在检测精度 $mAP50$ 方面相同, 但在 $mAP50-95$ 上要分别高于 CBAM 和 EMA 0.6% 和 0.3%, 且添加了 MPCA 注意力模块在运算量 GFLOPs 方面是最少的, 所以相比于其他的注意力机制模块, 本文提出的 MPCA 注意力机制综合来看更优。

表 4 消融实验结果
Table 4 Results of ablation experiment

模型	C2f-Dysnake	GDFPN	MPCA	$mAP50/\%$	Params/ 10^6	GFLOPs	FPS
基线				59.1	3.0	8.2	103
D	√			59.8	3.2	8.2	123
R		√		60.9	3.2	8.3	154
M			√	60.3	3.3	8.0	188
DR	√	√		60.7	3.5	8.4	104
DM	√		√	60.2	3.5	8.2	118
RM		√	√	61.3	3.5	8.3	140
DRM	√	√	√	61.4	3.8	8.4	98

表 4 中的数据明确展示了, 通过在 YOLOv8n 模型中应用不同的改进方法(以“√”标记表示采用), 每种方案均成功实现了模型检测精度的提升, 相较于原始的 YOLOv8n 模型有显著的性能增强。将骨干网络的倒数第一个 C2f 模块替换为 C2f-Dysnake 模块使检测精度提高了 0.7%; 对颈部网络的改进使检测精度提高了 1.8%; 引入 MPCA 注意力机制模块使检测精度提高了 1.2%, 虽然在

表 3 不同注意力机制实验对比

Table 3 Experimental comparison of different attention mechanisms

模型	$mAP50/\%$	$mAP50-95/\%$	Params/ 10^6	GFLOPs
基线	59.1	29.6	3.0	8.2
+SE	59.8	30.0	3.0	8.2
+CBAM	60.3	29.8	3.2	8.3
+EMA	60.3	30.1	3.0	8.2
+CPCA	60.0	30.4	3.1	8.3
+SimAM	59.5	29.8	3.0	8.1
+MPCA	60.3	30.4	3.2	8.0

3.4 消融实验

为了验证所提出改进方案对模型检测性能的有效提升, 本文基于 YOLOv8n 网络框架, 设计并实施了一系列消融实验。所有实验均在统一的超参数配置和训练策略下进行, 确保了实验的公平性和可比性。实验共构建了多个模型, 包括直接对比的 YOLOv8n 基础模型, 以及分别应用不同改进策略的 YOLOv8n-D(替换骨干网络倒数第一个 C2f 模块为 C2f-Dysnake 模块)、YOLOv8n-R(将颈部结构优化为结合 RepGFPN 与 DySample 的 RDPFN 结构)、YOLOv8n-M(在骨干网络 SPPF 模块后融入 MPCA 注意力机制), 以及这些改进组合而成的 YOLOv8n-DR、YOLOv8n-DM、YOLOv8n-RM 与最终的 YOLOv8n-DRM(本文改进算法), 表中名称省略了 YOLOv8n, 实验结果如表 4 所示。

参数量上有少许的增加, 但减少了 2.4% 的运算量; 同时引入 C2f-Dysnake 模块和改进的颈部网络以及同时引入 C2f-Dysnake 模块和 MPCA 注意力机制模块分别使检测精度提高了 1.6% 和 1.1%, 且后者使运算量也降回了与基线齐平; 同时引入改进的颈部网络和 MPCA 注意力机制模块使检测精度提高了 2.2%; 最后将上述 3 部分改进全部引入原网络得到的检测效果最佳, $mAP50$ 指标实现了 2.3% 的

增长,这一结果有力地验证了本文所提出的改进算法在增强模型检测性能方面的显著效果。虽然改进的模块带来了一定的计算量和参数量,但是检测精度提高了,检测速度也达到了 98 fps,能满足实时性检测的需求。

3.5 不同算法的比较

为深入验证本文改进算法在路面缺陷检测领域的优

越性,本文将 YOLOv8-DRM 与传统的目标检测算法(涵盖两阶段如 Faster-RCNN^[16]、Cascade-RCNN^[17],及单阶段如 EfficientNet^[18]、CenterNet^[19])以及 YOLO 系列多个轻量级版本(YOLOv3tiny^[20]、YOLOv4tiny^[21]、YOLOv5s^[22]、YOLOv6n-ReLU^[23]、YOLOv7tiny^[24]、与 YOLOv8n^[25])进行了系统性比较。结果如表 5 所示。

表 5 不同算法对比试验

Table 5 Comparative testing of different models

模型	mAP50/%	mAP50-95/%	Params/10 ⁶	GFLOPs	FPS
Faster-RCNN	51.2	22.5	137.1	370.2	21
Cascade-RCNN	54.8	25.0	87.9	110.6	24
EfficientNet-b0	59.0	28.2	5.6	11.1	73
Center Net	51.0	21.5	14.4	19.3	70
YOLOv3tiny	45.5	22.7	12.1	19.0	189
YOLOv4tiny	50.6	17.8	6.1	16.5	196
YOLOv5s	56.2	25.5	7.0	16.0	85
YOLOv6n-ReLU	57.9	27.0	4.3	11.1	87
YOLOv7tiny	58.0	25.6	6.0	13.2	114
YOLOv8n	59.1	29.6	3.0	8.2	103
YOLOv8 DRM	61.4	30.8	3.8	8.4	98

实验结果表明,YOLOv8-DRM 在 mAP50 和 mAP50-95 两项关键指标上均展现出显著优势,相较于所比较的算法,分别实现了不同程度的提升,特别是在 mAP50 上,相较于两阶段算法 Faster-RCNN、Cascade-RCNN 和单阶段算法 EfficientNet、CenterNet 分别提高了 10.2%、6.6%、2.4% 和 10.4%,且 FPS 亦有显著提升。与 YOLO 系列算法相比,本文所提出的算法在 mAP50 分别提高了 15.9%、10.8%、5.2%、3.5% 和 2.3%,尽管其参数量和计算量相较 YOLOv8n 略有增加,但平均精度有 2.3% 的提升,表明该算法在精度与效率间取得了良好平衡。

综上所述,YOLOv8-DRM 在综合考量精度、模型复杂度及检测速度方面,展现出了优于其他对比算法的性能,在路面缺陷检测任务中,能够高效且精准地识别缺陷,具有良好的实际应用潜力和价值。

3.6 不同数据集算法对比

为了验证算法的泛化能力,本研究还在 Road Damage 数据集下将该算法与其他几种先进模型进行了对比实验。该数据集涵盖了 3 321 幅源自智能手机相机的真实道路缺陷图像,确保了实验数据的多样性和实际应用场景的贴近性。与之前的数据集缺陷类型划分相同,将道路缺陷目标分为 4 大类:D00(纵向裂缝)、D10(横向裂缝)、D20(网状裂缝)和 D40(坑洞),同时训练集、测试集、验证集的比例为 8:1:1。实验结果如表 6 所示。

结果表明,YOLOv8-DRM 在 mAP50 上相较于 YOLOv3tiny、YOLOv5s、YOLOv6n-ReLU 和 YOLOv8n

表 6 不同数据集算法对比

Table 6 Comparison of algorithms of different datasets

模型	mAP50/%	mAP50-95/%
YOLOv3tiny	49.7	21.6
YOLOv5s	52.3	24.1
YOLOv6n-ReLU	57.6	25.6
YOLOv8n	57.8	26.4
YOLOv8 DRM	61.5	28.4

分别增加了 11.8%、9.2%、3.9% 和 3.7%,在 mAP50-95 上分别增加了 6.8%、4.3%、2.8% 以及 2%。综上所述,YOLOv8-DRM 算法在 Road Damage 数据集上展现了卓越的性能,为算法在更广泛场景下的应用提供了坚实的数据支撑和理论依据。这一结果充分证明了本文算法的有效性及其优良的泛化能力。

3.7 实际应用检测评价

为了从实际应用方面检验改进模型的提升效果,本文将 YOLOv8n 原始算法与改进后算法进行了数据集检测对比实验。实验选取了验证集中的代表性图像样本进行检测,以直观展示改进算法的优势,检测结果如图 8 所示。在图 8(a)的示例中,针对缺陷集中的路面,改进后的算法展现出了更高的敏感性和准确性,有效弥补了原算法在检测细小裂缝时可能存在的遗漏问题;在图 8(b)所展示的场景中,针对路面存在不同颜色变化,增加了检测难度的情况,改进后的算法依然能够稳定地检测出缺陷区域;如

图 8(c)所示,改进后的算法纠正了原算法将树枝阴影误检为缺陷的错误;如图 8(d)所示,在车载记录仪拍下的阴天路面情况中,改进后的算法仍可以检测到远处不明显的缺陷。综上所述,改进后的算法较原算法有更高的检测精度,同时减少了对缺陷漏检、误检的情况发生,这一表现不

仅证明了算法在复杂环境下的鲁棒性,也体现了其在处理实际道路检测任务中的优越性。通过这一系列的实验验证,本文提出的改进算法在提升检测精度、增强适应性方面取得了显著成效,为实际应用提供了更加可靠的技术支持。

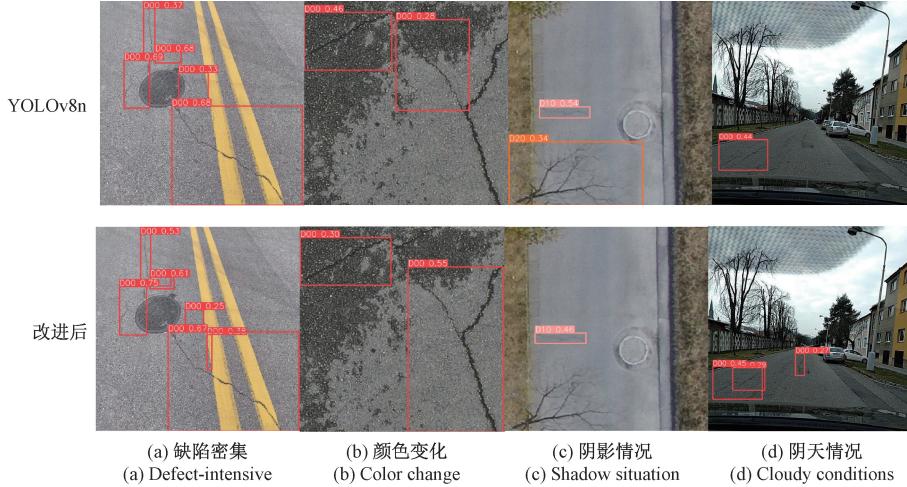


图 8 检测效果对比

Fig. 8 Comparison of detection effects

4 结 论

为了解决有些小目标缺陷容易被漏检误检的问题,减少背景干扰对路面缺陷检测的影响,从而提高对路面缺陷的检测精度,本文基于 YOLOv8n 模型进行了改进,并在数据集 RDD2022 上选取了 10 000 张图片进行训练和验证。首先,利用 Dysnake Conv 卷积设计了 C2f-Dysnake 模块,有效地改善了网络对目标形状和边界的敏感性,增强了对不同尺度、形状和姿态的裂缝的感知能力,提高了模型检测精度。其次,重新设计了颈部结构,提出了将重参数化泛化特征金字塔网络 RepGFPN 与动态上采样器 DySample 相结合构成新的颈部网络 RDGPN,增加了对低层特征图的关注度,提升了对小目标的检测能力,在不增加更多计算量的同时,有效提升了模型的精度。最后引入了 MPCA 坐标注意力机制模块,它能够捕捉不同尺度上的位置关系,使其能够更好地识别并提取重要特征,减少背景干扰。实验数据充分显示了改进后的 YOLOv8n 模型在本实验路面缺陷数据集上的良好表现,实现了平均精度均值增加 2.3%。因此,本文所提出的改进方法对于提升路面缺陷检测的准确性和效率具有重要意义。下一步研究重点,要用更轻量级的方法优化模型,在对精度不产生影响的前提下尽力缩小模型的尺寸,降低计算成本,增加模型检测速度,以提高模型的实用价值。

参考文献

[1] 伏金浩,王剑平,闻路红,等. 基于改进阈值与边缘梯度的亮场干细胞图像分割方法[J]. 电子测量技术,2020,

43(20):109-114.

FU J H, WANG J P, WEN L H, et al. Brightfield stem cell image segmentation method based on improved threshold and edge gradient[J]. Electronic Measurement Technology, 2020, 43(20):109-114.

[2] 陈奕州. 基于边缘引导网络的路面裂缝智能检测方法研究[D]. 重庆:重庆交通大学,2023.

CHEN Y ZH. Research on intelligent detection method of pavement crack based on edge guidance network [D]. Chongqing: Chongqing Jiaotong University, 2023.

[3] 韩锟,韩洪飞. 基于区域级和像素级特征的路面裂缝检测方法[J]. 铁道科学与工程学报, 2018, 15(5): 1178-1186.

HAN K, HAN H F. Pavement crack detection method based on regional-level and pixel-level features[J]. Journal of Railway Science and Engineering, 2018, 15(5): 1178-1186.

[4] KANG D, BENIPAL S S, GOPAL D L, et al. Hybrid pixel level concrete crack segmentation and quantification across complex backgrounds using deep learning [J]. Automation in Construction, 2020, 118:103291.

牛慧余,包腾飞,李扬涛,等. 基于改进 Mask R-CNN 的混凝土坝裂缝像素级检测方法[J]. 水利水电科技进展, 2023, 43(1):87-92,98.

NIU H Y, BAO T F, LI Y T, et al. Pixel-level detection method for cracks in concrete dam based on improved Mask R-CNN [J]. Progress in Water

- Resources and Hydropower Science and Technology, 2023, 43(1):87-92,98.
- [6] 李科岑,王晓强,林浩,等.深度学习中的单阶段小目标检测方法综述[J].计算机科学与探索,2022,16(1):41-58.
- LI K C, WANG X Q, LIN H, et al. Review of single-stage small target detection methods in deep learning[J]. Computer Science and Exploration, 2022, 16 (1): 41-58.
- [7] 黄开启,刘小荣,黄茂云.基于改进 YOLOv3 的小目标检测方法研究[J].传感器与微系统,2022,41(4):52-55.
- HUANG K Q, LIU X R, HUANG M Y. Research on small target detection method based on improved YOLOv3 [J]. Sensors and Microsystems, 2022, 41(4): 52-55.
- [8] 周双喜,杨丹,潘远,等.基于注意力机制的 YOLOv5 路面裂缝检测与识别[J].华东交通大学学报,2024,41(2):56-63.
- ZHOU SH X, YANG D, PAN Y, et al. YOLOv5 pavement crack detection and recognition based on attention mechanism [J]. Journal of East China Jiaotong University,2024,41(2):56-63.
- [9] 李松,史涛,井方科.改进 YOLOv8 的道路损伤检测算法[J].计算机工程与应用,2023,59(23):165-174.
- LI S, SHI T, JING F K. Improved road damage detection algorithm of YOLOv8[J]. Computer Engineering and Applications,2023,59(23):165-174.
- [10] 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.
- WANG H Q, WANG B N, GE CH. Reparameterized YOLOv8 pavement disease detection algorithm [J]. Computer Engineering and Applications,2024,60(5): 191-199.
- [11] QI Y L, HE Y T, QI X M, et al. Dynamic snake convolution based on topological geometric constraints for tubular structure segmentation [C]. IEEE/CVF International Conference on Computer Vision, 2023: 6070-6079.
- [12] XU X ZH, JIANG Y Q, CHEN W H, et al. DAMO-YOLO: A report on real-time object detection design[J]. ArXiv preprint arXiv:2211.15444,2022.
- [13] LIU W Z, LU H, FU H T, et al. Learning to upsample by learning to sample [C]. IEEE/CVF International Conference on Computer Vision, 2023: 6027-6037.
- [14] JIANG Y Q, TAN ZH Y, WANG J Y, et al. GiraffeDet: A heavy-neck paradigm for object detection [J]. ArXiv preprint arXiv: 2202.04256,2022.
- [15] ARYA D, MAEDA H, GHOSH S K, et al. Crowdsensing-based road damage detection challenge (CRDCC ' 2022) [C]. 2022 IEEE International Conference on Big Data(Big Data),2022:6378-6386.
- [16] GIRSHICK R. Fast R-CNN [C]. 2015 IEEE International Conference on Computer Vision(ICCV), 2015:1440-1448.
- [17] CAI Z, VASCONCELOS N. Cascade R-CNN: Delving into high quality object detection [C]. IEEE Conference on Computer Vision and Pattern Recognition,2018:6154-6162.
- [18] TAN M. Efficientnet: Rethinking model scaling for convolutional neural networks [J]. ArXiv preprint arXiv:1905.11946,2019.
- [19] ZHOU X, WANG D, KRÄHENBÜHL P. Objects as points[J]. ArXiv preprint arXiv:1904.07850,2019.
- [20] REDMON J, FARHADI A. YOLOv3: An incremental improvement[J]. ArXiv preprint arXiv: 1804.02767,2018.
- [21] BOCHKOVSKIY A, WANG C Y, LIAO H Y. YOLOv4: Optimal speed and accuracy of object detection[J]. ArXiv preprint arXiv:2004.10934,2020.
- [22] 卫策,吕进,曲晨阳.改进 YOLOv5s 的复杂交通场景下目标检测算法[J].电子测量技术,2024,47(2):121-130.
- WEI C, LYU J, QU CH Y. Improved object detection algorithm for complex traffic scenarios with YOLOv5s[J]. Electronic Measurement Technology, 2024,47(2):121-130.
- [23] LI CH Y, LI L L, JIANG H L, et al. YOLOv6: A single-stage object detection framework for industrial applications [J]. ArXiv preprint arXiv: 2209.02976,2022.
- [24] WANG C Y, BOCHKOVSKIY A, LIAO H Y. YOLOv7: Trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [J]. ArXiv preprint arXiv: 2207.02696,2022.
- [25] 李忠科,刘小芳.基于轻量级 YOLOv8n 网络的 PCB 缺陷检测算法 [J]. 电子测量技术, 2024, 47 (4): 120-126.
- LI ZH K, LIU X F. PCB defect detection algorithm based on lightweight YOLOv8n network [J]. Electronic Measurement Technology,2024,47(4):120-126.

作者简介

周建新,副教授,博士,主要研究方向为复杂系统建模、控制与优化。

E-mail:zhoujianxin1977@126.com

张媛(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:15075318461@163.com

贾梓涵,硕士研究生,主要研究方向为深度学习、图像处理。

何洋,硕士研究生,主要研究方向为深度学习、图像处理。