

文章编号 1004-924X(2026)04-0640-12

## 改进 YOLO11n 的雾天路面缺陷轻量化检测

陈仁祥<sup>1\*</sup>, 邓力珩<sup>1</sup>, 杨黎霞<sup>2</sup>, 陈卓<sup>1,3</sup>, 王磊<sup>1</sup>, 罗浩铭<sup>1</sup>

(1. 重庆交通大学 交通工程应用机器人重庆市工程实验室, 重庆 400074;

2. 重庆科技大学 经济与金融学院 重庆 401331;

3. 招商局重庆公路工程检测中心有限公司, 重庆 400067)

**摘要:**针对雾天路面缺陷检测精度低、模型参数量大的问题,提出改进 YOLO11n 的雾天路面缺陷轻量化检测方法,旨在提高雾天环境检测精度和更利于轻量化部署。首先,在骨干网络中构建前端去雾网络(Dehaze-Network, DH-Net),通过通道归一化和跨层统计量传递机制,保持去雾图像结构一致性并实现检测任务导向联合优化,减小雾气对检测效果的影响;其次,采用自适应下采样模块(ADown)替代传统卷积下采样,以减少参数量并保留关键空间特征,从而增强缺陷细节的提取能力;然后,设计高效多分支辅助特征金字塔网络,通过动态卷积核适配与加权双向特征金字塔融合增强雾天模糊目标的跨尺度表征能力,进一步减少雾天对检测的影响;最后,使用部分卷积对检测头进行轻量化改进,以部分卷积运算降低计算开销。通过在不同数据集实验表明,改进模型 mAP 较基准分别提升 2.1% 和 3%,参数量降低 47.2%。该方法为雾天路面巡检提供了高精度、低资源消耗的解决方案。

**关键词:**雾天;路面缺陷检测;改进 YOLO11n;轻量化

**中图分类号:**TP391;TN911.73 **文献标识码:**A

**doi:**10.37188/OPE.20263404.0640

**CSTR:**32169.14.OPE.20263404.0640

## Lightweight detection of foggy pavement defects based on improved YOLO11n

CHEN Renxiang<sup>1\*</sup>, DENG Liheng<sup>1</sup>, YANG Lixia<sup>2</sup>, CHEN Zhuo<sup>1,3</sup>, WANG Lei<sup>1</sup>, LUO Haoming<sup>1</sup>

(1. Chongqing Engineering Laboratory of Traffic Engineering Application Robot,

Chongqing Jiaotong University, Chongqing 400074, China;

2. Chongqing University of Science & Technology, Economics and Finance College,

Chongqing 401331, China;

3. China Merchants Chongqing Highway Engineering Testing Center Co., Ltd., Chongqing 400067, China)

\* Corresponding author, E-mail: manlou.yue@126.com

**Abstract:** Aiming at the problems of low detection accuracy and large number of detection model parameters in road defect detection methods in foggy scenarios, we proposed to improve the lightweight detection

**收稿日期:**2025-10-22; **修订日期:**2025-11-26.

**基金项目:**国家自然科学基金(No. 52475548);重庆市教委科学技术研究项目(No. KJZD-M202200701);重庆市自然科学基金创新发展联合基金(No. CSTB2025NSCQ-LZX0113);重庆市专业学位研究生教学案例库(No. JDALK2022007);重庆市自然科学基金项目(No. CSTB2023NSCQ-MSX0177);重庆科技大学科研启动项目(No. ckre202212030)

method of YOLO11n foggy road defects, aiming to improve the model detection accuracy while being more conducive to its lightweight deployment. First, a front-end Dehaze-Network (DH-Net) was constructed in the backbone network, which maintained the consistency of the dehaze image structure while realizing the joint optimization of the detection task orientation through the channel normalization and cross-layer statistic transfer mechanism, and reduced the influence of the fog on the detection effect; second, in order to enhance the ability to extract the details of the defects, the Adaptive Downsampling Module (ADown) replaced traditional convolution to reduce the number of parameters and retain key spatial features; then, to reduce the impact of foggy scenes and complex road conditions on detection, an efficient multi-branch auxiliary feature pyramid network was designed to enhance the cross-scale characterization of foggy targets through dynamic convolutional kernel adaptation and weighted bi-directional feature pyramid fusion; and lastly, the lightweighting of the detection header was improved by using part of the convolution to partially convolution operation to reduce the computational overhead. Experiments across various datasets demonstrate that the improved model achieves a mAP increase of 2.1% and 3% respectively over the baseline, whilst reducing the number of parameters by 47.2%. This method provides a high-precision and low-resource-consumption solution for foggy pavement inspection.

**Key words:** foggy weather detection; pavement defect detection; YOLO11n; lightweighting

## 1 引言

公路路面健康状况直接关系行车安全与运输效率,随着公路服役年限增加,路面结构损伤(如裂缝、坑槽等)引发的缺陷问题日益突出。道路的日常检测是保障道路长期稳定运行的基础工作,不能因天气因素随意搁置。而在雾天环境中,受雾气影响,采集图像的对比度与色彩降低,会对目标检测等高级视觉任务产生极大的干扰<sup>[1]</sup>。因此,继续开展雾天环境下道路缺陷检测研究。

近年来,基于深度学习的目标检测技术在交通领域应用日益广泛。对雾天场景下目标检测方法大体可以分为去雾预处理<sup>[2]</sup>、优化模型结构和联合去雾检测三类<sup>[3]</sup>。岳永恒等<sup>[4]</sup>以CycleGAN算法为框架对图像进行去雾预处理,再将去雾后的图像导入改进YOLOv8中,从而对雾天道路车辆实现精准识别。祝琴等<sup>[5]</sup>构建时空特征融合模块SF-Module并结合YOLOv8n对雾天车辆目标进行检测。Zhang等<sup>[6]</sup>通过引入链式思考提示机制实现对雾天图像自适应增强,提升了检测性能。相较于传统去雾预处理流程,联合去雾检测方法无需单独训练去雾模型,具备资源消耗少、部署便捷的优势。相对于单纯优化模型结构,通过提升图像整体质量,对检测结果的改善

效果更为显著。雾天路面缺陷检测的关键在于:图像受雾气影响,使得部分关键特征信息丢失,导致精度下降。上述方法虽能实现雾天检测,但模型参数量和计算量较高,导致部署困难。

为解决以上问题,提出改进YOLO11n的雾天路面缺陷轻量化检测方法。该方法以保持特征一致性、增强模糊目标表征、降低计算开销为核心原则,将去雾、特征提取、多尺度融合与检测头进行协同设计。DH-Net(Dehaze Network)旨在解决去雾与检测任务间的特征对齐矛盾;自适应下采样(ADown)模块致力于在压缩特征图时最大限度保留缺陷的细微结构;EMAFPN(Efficient Multi-Branch Auxiliary Feature Pyramid Network,EMAFPN)专注于提升对尺度多变、对比度低的雾天目标的跨层级感知能力;PC-Head(Partial Convolution Head)则系统性优化检测阶段的冗余计算。

## 2 改进YOLO11n的原理

以YOLO11系列中参数量最小且检测速度最快的YOLO11n网络进行改进,图1为改进的YOLO11n整体架构(改进部分见红色虚线框,彩图见期刊电子版),该设计体现了逐阶段协同优化的思路:输入图像首先经由DH-Net进行与检




图1 改进YOLO11n结构

Fig. 1 Improve YOLO11n structure

测任务对齐的去雾预处理;得到的增强特征再通过 ADown 模块进行细节保持的下采样;随后,EMA-FPN 对多尺度特征进行动态融合以增强模糊目标的表征;最终,由轻量化的 PC-Head 完成检测。整个流程构成了一个从图像复原到高效检测的闭环优化。

## 2.1 DH-net

传统去雾网络在提升图像整体质量时,常会过度平滑或破坏对检测任务至关重要的高频特征(如边缘与纹理)<sup>[7]</sup>。为实现去雾与检测的协同优化,避免两阶段方法中的特征对齐偏差,本文以轻量化的 AOD-Net 为基础,构建了新型前端去雾网络 DH-Net。AOD-Net 通过学习一个轻量级 CNN 来直接估计大气散射模型中的合成参数  $K(x)$ 。该模型由经典大气散射模型推导而来:

$$I(x) = J(x)t(x) + A(1 - t(x)), \quad (1)$$

其中:  $I(x)$  代表有雾图像,  $J(x)$  代表无雾图像,  $t(x)$  是透射率,  $A$  是大气光值。为减少误差累积,将 AOD-Net 公式重写,将  $t(x)$  和  $A$  整合为一个新的变量  $K(x)$ :

$$K(x) = \left( A - 1 + \frac{(I(x) - A)}{t(x)} \right) \frac{1}{I(x) - 1}. \quad (2)$$

进而,得到去雾图像的代表过程为  $J(x)$ :

$$J = K(x)I(x) - K(x) + 1. \quad (3)$$

尽管 AOD-Net 效率很高,但其网络内部通常采用的批量归一化(Batch Normalization, BN)层,生成式任务中 BN 在批次维度计算统计量会模糊单个样本内的空间结构信息,不利于需要像素级定位精度的路面缺陷检测。为解决这一问题,在 AOD-Net 的编码器-解码器结构中设计部分通道归一化与均值漂移模块。该模块的核心设计如图 2,其通过两个协同工作的关键机制确保了去雾过程与检测任务的一致性:首先,部分通道归一化(Polarized Normalization, PN)在通道维度上进行操作,对特征图的每个空间位置( $h, w$ )独立计算所有通道的统计量并进行归一化,以此保留每个位置的局部结构特性,为后续检测维系关键的高频线索;其次,跨层统计量传递(Cross-Layer Statistical Transfer, MS)将编码器每一层的特征均值  $\mu$  与标准差  $\sigma$  通过快捷连接传递至对应解码器层,作为自适应偏置  $\beta$  与缩放因子  $\gamma$ ,从而迫使解码器在重建时其内部特征分布与编码器捕捉的输入结构相锚定,形成结构一致性约束以防止去雾失真。通过上述设计, DH-






图2 DH-net结构

Fig. 2 DH-net structure

Net不仅在图像层面完成去雾,更在特征层面确保了输出与检测网络需求的空问结构对齐,实现了从图像复原到高层视觉任务的无缝衔接。

## 2.2 ADown下采样模块

道路缺陷特征在外形尺寸上差异显著,为优化特征网络性能,引入YOLOv9<sup>[8]</sup>提出的ADown自适应下采样模块,该模块能依据各类数据场景,自动调节下采样的比例与形式。ADown的双分支设计具有明确的互补性:平均池化路径保留全局上下文信息,而‘卷积+最大池化’路径提取局部细节特征。这种显式的多模态处理策略特别适用于形态多变的道路缺陷,能在下采样过程中更完整地保留从细微裂缝到大型坑槽的关键特征。

在ADown结构中,首先通过平均池化操作来维持输入特征图的空间信息。随后,将通道均分为两部分:一部分送入 $3\times 3$ 卷积层,用于提取精细化的空间特征;另一部分则先经过 $3\times 3$ 最大池化层进行特征图尺寸压缩,再通过 $1\times 1$ 卷积层聚合全局信息并实现维度缩减。在原网络架构中,由于大量使用传统卷积层,导致模型参数量显著增加,采用ADown卷积替代原模型中的部分下采样卷积,不仅有效减少了网络参数量,降低了模型复杂度,同时在降低特征图分辨率的过程中,能够更好地保留图像关键特征,保证目标检测的准确性。

## 2.3 EMAFPN

针对雾天环境下路面缺陷存在的尺度多变、特征模糊、对比度低等核心问题,YOLO11n原有的特征金字塔网络在应对上述复杂场景时,存在融合能力不足、对模糊目标特征增强不够的问

题。为此在颈部设计EMAFPN结构,该结构在MAFPN<sup>[9]</sup>的基础上融合BiFPN(Bidirectional Feature Pyramid Network)<sup>[10]</sup>并在其内部针对性地集成了多个高效组件,以实现雾天模糊目标更强的跨尺度表征能力EMAFPN的整体结构如图3,输入图像经主干网络提取得到P2,P3,P4,P5四级特征图。即采用高效上采样卷积块EU-CB(Efficient Up-Convolution Block)<sup>[11]</sup>对深层特征进行上采样,并与浅层高分辨率特征进行融合。随后,通过加权双向融合路径聚合不同层级的语义信息。在关键节点,引入多尺度增强模块(Multi-Scale Enhancement Block,MSEB)对融合后的特征进行增强处理。

常规上采样(如最近邻插值)操作虽能扩大特征图尺寸,但未引入新的语义信息。高效上采样模块EUCB的核心思想是在上采样过程中,通过轻量级卷积操作增强特征图的语义表达能力,使浅层特征与经过语义增强的深层特征融合时,能获得更丰富的上下文信息,设计MSEB模块,MSEB将输入特征图拆分为两部分,一部分进行复杂变换(Bottleneck+MSDC),另一部分直接短路连接。这种设计类似于残差学习,允许原始特征无障碍流通,降低了梯度消失的风险,使网络更专注于学习残差细节特征,这对于增强雾气中模糊缺陷的识别至关重要。MSEB结构如图1所示,其中设计MSDC模块并行使用不同核大小的深度卷积,分别捕获局部细节(小感受野)和全局上下文(大感受野)。这种并行结构相当于为网络提供了一组自适应于目标尺度的特征提取器,使其能够同时感知裂缝的连续纹理和坑槽的整体形状。每个尺度的深度卷积后均通过BN和




图3 EMAFPN结构

Fig. 3 EMAFPN structure

ReLU6激活,形成多尺度特征融合,由于深度卷积通常会忽略通道间关系,MSDC通过Channel Shuffle操作将不同组的通道重新排列,增强通道间信息交互,避免分组卷积带来的信息隔离,从而增强模型对低对比度、雾天模糊目标的识别能力。因此,EMAFPN通过内部各组件的协同工作,实现了对雾天路面缺陷跨尺度表征能力的定向增强。它使YOLO11n能够更有效地利用从清晰背景到模糊缺陷的多层级信息,从而提升在雾天场景下的检测精度。

## 2.4 PC\_Head

为提升特征提取能力、加快推理速度,同时减少模型参数量与计算量,设计PC\_Head替换原模型检测头,PC\_Head检测头结构如图1所示。

通过引入PConv(Partial Convolution)<sup>[12]</sup>来替换常规卷积层和深度卷积层,构建轻量高效的头部检测网络。PConv仅对少量输入通道执行卷积操作,能大幅削减浮点运算,有效降低冗余计算和内存访问量。这不仅提升了特征提取效率与推理速度,减少了模型参数量和计算量,还缓解了内存带宽压力,从整体上优化了网络效能。PConv利用特征映射中的冗余,系统地在一部分输入通道上应用常规卷积,同时保持其余通道不变。常规卷积的计算量和内存访问情况如

式(4)~式(6)所示:

$$\text{FLOPs} = h \times w \times k^2 \times c^2, \quad (4)$$

$$h \times w \times 2c + k^2 \times c^2 \approx h \times w \times 2c, \quad (5)$$

$$\gamma = \frac{c_p}{c} = \frac{1}{4}, \quad (6)$$

其中: $h$ 为输入特征图的高度, $w$ 为宽度, $c$ 是输入通道数, $c_p$ 是部分输入通道数,引入Pconv后上述公式中 $c$ 将由 $c_p$ 进行替换, $k$ 为卷积核大小,在经典偏比 $\gamma=1/4$ 的情况下,PConv的FLOPs仅为常规卷积的1/16,显著降低了所需的计算资源。并且PConv的内存访问次数仅为常规卷积的1/4。在检测头这类计算密集区域,PConv通过稀疏化计算策略,在保持表征能力的同时实现计算效率的质的提升。这与DH-Net的特征净化、ADown的高效下采样、EMAFPN的增强融合共同构成协同优化闭环,使模型在精度与效率间获得最佳平衡。

## 2.5 雾天路面缺陷目标检测流程

改进YOLO11n的路面缺陷检测流程如图4:

(1)数据集构建:标注构建数据集并按比例划分为训练集、验证集、测试集。

(2)网络初始化:构建改进YOLO11n雾天路面缺陷目标检测网络并初始化参数。

(3)模型训练:以批处理方式将训练集输入

网络,通过损失计算与反向传播优化网络参数,训练完成后保存最终模型。

(4)模型测试:加载已训练模型,对测试集数据进行推理,输出雾天路面缺陷的检测结果。




图4 检测流程

Fig. 4 Overall Flowchart of Defect Detection

### 3 实验结果与分析

#### 3.1 实验平台与环境

实验环境基于ubuntu22.04, GPU为 NVIDIA RTX 4090D (24GB), CPU为 15 vCPU Intel (R) Xeon (R) Platinum 8474C, 使用 PyTorch2.5.1 深度学习框架, 编程语言为 Python3.12, CUDA 版本为 12.4。本文所有实验中,模型的训练、测试和验证过程使用相同的超参数。所有训练均使用SGD优化器,具体参数设置如下所示:批样本(batch size)数量为32,动量因子(Momentum)为0.937,权值初始学习率(learning rate)为0.01,权重衰减率(weight decay)为0.0005,迭代次数为300次。

#### 3.2 数据集和评价指标

在RDD2022<sup>[13]</sup>数据集上,采用深度信息模

拟大气散射效应的方法,构建雾天道路缺陷数据RDD2022-Haze。RDD2022包含了六个国家的道路缺陷数据,其中包含四种道路缺陷类型和一种道路修补类型,分别为D00(纵向裂缝)、D10(横向裂缝)、D20(网状裂缝)、D40(坑洞)和Repair(修补缺陷)。本实验使用来自中国与日本的部分数据集且只针对除Repair(修补缺陷)外的四种道路缺陷类型进行研究,为此对数据集进行数据清洗,清洗后的数据集共9830张,按照7:2:1的比例划分为训练集、验证集、测试集,分别为6881,1966,983张。

雾天图像基于深度信息模拟大气散射效应随机生成,如图5所示,使用ResNet编码器提取图像特征,Depth解码器预测视差图,生成的雾天图像在视觉上具有连贯的深度感和真实的雾气弥漫效果。



图5 部分数据集图片

Fig. 5 Some sample images of the dataset

雾效生成公式为:

$$I_{\text{haze}} = I_{\text{original}} \cdot (1 - \beta) + C_{\text{haze}} \cdot \beta, \quad (7)$$

$$\beta = (1 - D_{\text{norm}}) \cdot S, \quad (8)$$

其中:公式(7)基于大气散射物理模型,是雾效模拟的理论基础:一张有雾的图像 $I_{\text{haze}}$ 是清晰的原图 $I_{\text{original}}$ 和雾的浓度 $C_{\text{haze}}$ 按照一定比例 $\beta$ 混合的结果。实验中 $C_{\text{haze}}$ 在区间[0.7,0.9]内随机取值,使生成的雾效更多样。公式(8)中,深度归一化值 $D_{\text{norm}}$ 是通过单目深度估计模型从原图预测得到的深度信息,范围为:0~1(0近,1远),雾强度系数 $S$ 在[0.5,0.8]内随机采样,以覆盖真实的雾天浓度变化。这种方法能生成从薄雾到浓雾的连续、非均匀雾效,比简单全局加雾更能反映真实场景。

为直观地体现目标检测模型效果,使用准确率(Precision, P)、召回率(Recall, R)、平均精度



(Average Precision, AP)、平均精度均值 (Mean Average Precision, mAP)、参数量 (Params) 来评价训练后的模型<sup>[14]</sup>, 计算公式分别如下:

$$P = \frac{TP}{TP + FN} \times 100\%, \quad (9)$$

$$R = \frac{TP}{TP + FP} \times 100\%, \quad (10)$$

$$AP = \int_0^1 (P(R) dR), \quad (11)$$

$$mAP = \frac{\sum (AP)}{n}, \quad (12)$$

其中: TP (True Positive) 表示正确检测的正样本数量, FN (False Negative) 代表漏检的负样本数量, FP (False Positive) 则为误检的正样本数量, 其中  $n$  为待识别类别总数。平均精度 (AP) 通过精确率-召回率 ( $P$ - $R$ ) 曲线下面积量化模型性能, 式  $P(R)$  表征特定召回率下的精确率变化曲线, mAP50-95 表示在不同 IoU 阈值 (从 0.50 到 0.95, 步长 0.05) 上的平均 mAP。

### 3.3 去雾网络有效性分析

为验证 DH-Net 的有效性, 开展分阶段对比实验。首先, 在基准模型 YOLO11n 上单独引入经典 AOD-Net 网络 (改进 1+A), 观察传统去雾方法的效果; 随后, 在 AOD-Net 基础上加入本文提出的 PN-MS 模块 (改进 1+B), 通过对比两者性能差异, 分离出结构一致性约束的实际增益。实验过程中, 保持网络其他部分完全一致, 仅替换去雾模块以确保对比的公平性。

表 1 DH\_net 对检测影响对比

Tab. 1 Comparison of the effect of DH\_net on detection

| 模型          | mAP50/% | Param/M | FLOPS/G |
|-------------|---------|---------|---------|
| YOLO11n     | 60.9    | 2.46    | 6.3     |
| YOLO11n+A   | 61.1    | 2.47    | 7.7     |
| YOLO11n+A+B | 61.5    | 2.47    | 7.7     |

如表 1 所示, 改进 (1+A) mAP50 由 60.9% 提升至 61.1%, 参数量微增 0.4%; 进一步融合 PN-MS 跨层统计量传递机制 (B) 后, mAP50 提升 0.4%, 同时参数与计算量基本不变, 该模块通过编码器-解码器统计量共享机制, 在恢复图像结构一致性的同时强化了检测相关特征表达, 表

明该去雾方法能有效改善检测效果。

为进一步分析模型在雾天情况下的检测性能, 在测试集中选取不同拍摄角度下道路图像进行验证, 使用 YOLO11n 和 YOLO11n+DH\_net 模型进行检测。为更直观展示结果, 通过 Grad-CAMplusPlus 的方法生成热力图, 结果如图 6 (彩图见期刊电子版)。图 6(b) 中部分裂缝并未被热力区域覆盖, 第 1 组对比中图像右下角的裂缝并未被模型关注, 说明模型受雾气影响对目标的提取不够充分, 存在漏检的风险。图 6(c) 中待检目标几乎被红色区域完全覆盖, 说明在 DH\_net 网络进行图像的去雾处理后, 能够更加精确地进行特征提取, 减少漏检率, 检测结果可靠性明显提升。




图 6 热力图效果对比

Fig. 6 Comparison of heat map effect

### 3.4 特征融合网络对比实验

为验证 EMAFPN 的有效性, 将特征融合网络分别替换为 BiFPN 和 MAFPN 进行训练, BiFPN 代表高效双向融合的先进设计, MAFPN 代表多分支辅助融合的新思路。这两种网络均为当前特征金字塔研究的主流方向, 能够确保对比的先进性和全面性。对比实验结果如表 2。观察表 2, 加入 EMAFPN 特征融合网络的模型精度最佳为 61.9%, 高于 BiFPN 的 61.4% 和 MAFPN 的 61.6%。EMAFPN 的参数量与计算复杂度与 BiFPN 相似, 显著低于 MAFPN。总体来说, EMAFPN 结合了 BiFPN 和 MAFPN 的改进网络, 在保证更高精度的同时保持了较低的计算资源消耗和参数量。

表 2 特征融合结果对比

Tab. 2 Comparison of results of feature fusion networks

| 特征融合网络 | mAP50/% | Param/M | FLOPS/G |
|--------|---------|---------|---------|
| BiFPN  | 61.4    | 1.84    | 6.4     |
| MAFPN  | 61.6    | 2.58    | 7.2     |
| EMAFPN | 61.9    | 1.88    | 6.4     |

3.5 检测头对比实验

为验证轻量化检测头 PC\_Head 的性能,实验选取了当前具有代表性的两种检测头结构进行对比,DESC<sup>[15]</sup>检测头采用深度可分离卷积优化计算效率,ASFF<sup>[16]</sup>检测头通过自适应空间特征融合增强多尺度感知能力,PC\_Head 则基于部分卷积理论优化计算路径。结果如表 3。

表 3 中,ASFF 在平均精度上略高于其他检测头但与 DESC,PC\_Head 相比参数量分别增加 1.65 M,1.57 M,计算量分别增加 2.6 G,3.6 G。

PC\_Head 检测头在提升平均精度的同时拥有最低的计算量,且参数量仅比最低的 DESC 增加了 0.08 M,因此 PC\_Head 更适合本文的轻量化改进。

表 3 不同检测头对比

Tab. 3 Comparison of different detection heads

| 检测头     | MAP50/% | Param/M | FLOPS/G |
|---------|---------|---------|---------|
| DESC    | 61.1    | 2.16    | 6.1     |
| ASFF    | 61.6    | 3.81    | 8.7     |
| PC_Head | 61.4    | 2.24    | 5.1     |

3.6 消融实验

为系统评估与验证所提出的各部分改进对性能的提升效果及有效性,设计消融实验,展示改进结果,实验结果如表 4。

表 4 消融实验结果对比

Tab. 4 Comparison of ablation experiments

| 模型     | DH_Net | ADown | EMAFPN | PC_Head | mAP50/% | mAP50-95/% | Param/M | FLOPS/G |
|--------|--------|-------|--------|---------|---------|------------|---------|---------|
| YOLO11 |        |       |        |         | 60.9    | 31.1       | 2.46    | 6.3     |
| 改进 1   | ✓      |       |        |         | 61.5    | 31.3       | 2.47    | 7.7     |
| 改进 2   | ✓      | ✓     |        |         | 61.6    | 31.0       | 2.01    | 6.3     |
| 改进 3   | ✓      |       | ✓      |         | 62.3    | 31.7       | 2.02    | 6.7     |
| 改进 4   | ✓      |       |        | ✓       | 61.8    | 31.2       | 2.21    | 6.4     |
| 改进 5   | ✓      | ✓     | ✓      |         | 62.8    | 32.5       | 1.70    | 5.7     |
| 改进 6   | ✓      | ✓     |        | ✓       | 62.3    | 32.6       | 1.76    | 5.5     |
| 改进 7   | ✓      |       | ✓      | ✓       | 62.6    | 32.0       | 1.80    | 5.9     |
| 所提方法   | ✓      | ✓     | ✓      | ✓       | 63.0    | 33.0       | 1.30    | 5.2     |

本消融实验证明各改进模块均有助于提升模型性能。DH-Net 作为前端预处理模块,其去雾效果直接决定了后续特征提取网络的信息质量。在雾天场景下,若不能有效去除雾气干扰,后续任何特征优化操作都将事倍功半。因此,本实验设计将 DH-Net 作为基础模块,旨在验证在获得相对清晰的特征图后,各模块的性能增益效果。将 DH-Net 模块加入前端网络时,通过通道归一化和跨层统计量传递机制保持去雾图像结构一致性,减小雾气对检测效果的影响,MAP50 和 MAP50-95 分别提升 0.6%,0.2%;使用 ADown 模块替换传统下采样卷积后,结合卷积与池

化操作在保留关键空间特征的同时减少参数量,MAP50 提升 0.7%,参数量降低 18.3%;将 EMAFPN 网络替换原颈部网络时,通过动态卷积核适配与加权双向特征金字塔融合增强雾天模糊目标的跨尺度表征能力,MAP50 提升 1.4%,MAP50-95 提升 0.6%;使用 PC\_Head 检测头替换原检测头后,基于部分卷积运算降低计算开销,在保持精度的同时优化计算效率,MAP50 提升 0.9%,FLOPs 降低 1.4%;在 DH-Net 的基础上加入 ADown 和 EMAFPN 模块后,去雾处理与多尺度特征融合产生协同效应,MAP50 提升 1.9%,MAP50-95 提升 1.4%;在



DH-Net 的基础上加入 ADown 和 PC\_Head 模块时,轻量化组件间良好兼容,MAP50 提升 1.4%,FLOPs 降至 5.5 G;在 DH-Net 的基础上加入 EMAFPN 和 PC\_Head 模块后,在精度与效率间取得平衡,MAP50 提升 1.7%;当 DH-Net,ADown,EMAFPN 和 PC\_Head 共同作用时,性能达到峰值 MAP50 提升 2.1%,MAP50-95 提升 1.9%,参数量降低 47.2%,FLOPs 降低 17.4%。这证明了模块间的协同效应:DH-Net 提供了清晰的输入特征,ADown 在此基础上有力地保留了缺陷细节,EMAFPN 则有效地融合了这些多尺度特征,而 PC-Head 最终以低开销完成检测。这种‘净化输入-增强特征-高效输出’的设计是性能增益的关键。

### 3.7 不同模型对比实验

通过与当下主要检测方法对比,以分析所提方法的优越性。

如表 5,所提方法具有更高的检测精度,mAP 对比基准模型 YOLO11n 提高了 2.1%,相比 YOLO 系列经典模型 v5n,v8n,v10n 分别提高了 2.3%,2.2%,4.6%,与最新版本 v12n 相比提高了 1.2%。基于 transformer 的 RTDETR-L,参数量和计算量较大,但并未取得较好的检测效果。同时改进算法相比其他对比算法拥有更小的参数量和计算量,对比轻量化道路检测算法 ATLF-YOLO 在雾天检测中拥有更好的表现,精度提高了 1.4%;对比同类别的联合去雾检测算法 FFA-YOLO,CPA-YOLO,这两种算法,相较于

于原本模型具有更好的检测表现,但参数量和计算量都有所提高,本文改进方法在占用更少计算资源的基础上,拥有更高的检测精度。对比在复杂场景表现出色的 Hyper-YOLO,改进方法也具有更好地表现。上述实验表明提出的 DAEP-YOLO 凭借更高的精度以及更轻量化的特点,能够出色地胜任雾天路面缺陷检测任务。

为直观呈现改进 YOLO11n 模型在路面缺陷检测任务中的优越性能,对比改进方法与 YOLO11n 模型在测试集上的可视化检测效果,结果如图 7。从检测效果可以看出,对于各类道路缺陷,改进模型的预测置信度普遍高于原始模型,这表明其检测结果更为可靠。此外,改进模型能够更准确地识别网状裂缝与坑槽这类特征复杂、难以辨别的缺陷,有效减少漏检现象,这表明该模型适合用于雾天道路缺陷检测任务。表 6 展示了改进模型与原始模型在 RDD2022-Haze 数据集各缺陷的检测效果。改进模型在 4 类路面缺陷的 AP50 分别均有提高,所提方法能更准确识别雾天路面缺陷。

表 5 不同模型对比实验结果

Tab. 5 Comparative experimental of detection models

| 模型                         | mAP50/% | Param/M | FLOPS/G |
|----------------------------|---------|---------|---------|
| YOLOv5n                    | 60.7    | 2.08    | 5.8     |
| YOLOv8n                    | 60.8    | 2.87    | 8.1     |
| YOLOv10n                   | 58.4    | 2.16    | 6.5     |
| YOLO11n                    | 60.9    | 2.46    | 6.3     |
| YOLOv12n                   | 61.8    | 2.44    | 6.3     |
| RTDETR-L                   | 57.5    | 30.51   | 103.4   |
| Hyper-YOLO <sup>[17]</sup> | 62.5    | 3.45    | 9.5     |
| FFA-YOLO                   | 62.7    | 2.47    | 11.5    |
| CPA-YOLO <sup>[6]</sup>    | 62.0    | 2.94    | 19.2    |
| ATLF-YOLO <sup>[18]</sup>  | 61.6    | 1.61    | 5.2     |
| 所提方法                       | 63.0    | 1.30    | 5.2     |




图 7 可视化对比

Fig. 7 Visualisation comparison

表 6 各类缺陷检测精度

Tab. 6 Detection accuracy of each defect

| 模型      | AP50% |      |      |      |
|---------|-------|------|------|------|
|         | D00   | D10  | D20  | D40  |
| Yolo11n | 62    | 54.2 | 67.6 | 59.8 |
| 本文方法    | 62.9  | 56.6 | 71.1 | 61.2 |

3.8 泛化性验证

为测试所提方法在真实雾天数据上的性能：使用自建数据集进行测试,该数据集一共 507 张图像,均拍摄自大雾橙色预警下的校园路面,在 LabelImg 工具上进行手工标注,并将整个数据集按 8:2 划分训练集和验证集,图像如图 8。



图 8 校园雾天路面  
Fig8 Campus Road Surface on Foggy Day

如表 7,将所提方法与 YOLO11n 在自建数据集上进行验证。结果显示所提方法 mAP50 达到 69.4%,提升了 3%,由此可见本文方法在真实数据中也能发挥出更好的作用。

表 7 自建数据集上的泛化实验结果

Tab. 7 Generalization experiment results on self-built dataset

| 模型      | mAP50/% | mAP50-95/% | Param/M |
|---------|---------|------------|---------|
| YOLO11n | 66.4    | 29.9       | 6.3     |
| 所提方法    | 69.4    | 31.1       | 5.2     |

4 Jetson Xavier NX 部署试验

为检验所提出模型在实际应用中的可行性,将改进后的模型部署于 Jetson Xavier NX 边缘计算平台,并采用 TensorRT 优化框架实现推理加速。通过对比模型部署前后的性能表现,评估其在真实场景中的有效性。平台部署与运行情况如图 9。

根据模型部署试验结果(如表 8 所示),YO-

LO11n 模型在 Jetson Xavier NX 平台上无加速与经过 TensorRT 加速后的检测帧率分别为 20.25 FPS 与 54.46 FPS。而所提方法在相同平台上,无加速与加速后的帧率分别达到 23.71 FPS 与 64.32 FPS。相较于 YOLO11n 模型,所提方法在部署前后分别提升 3.46 FPS 与 9.86 FPS。加速前,在边缘设备计算资源受限的情况下,模型检测速度仍具有优化空间;经 TensorRT 加速后,所提方法的检测帧率进一步提升至 64.32 FPS,较加速前提升约 2.71 倍。上述结果表明,所提方法在部署推理速度方面优于原模型,展现出良好的边缘设备适应性及部署潜力,为相关视觉任务的实际应用提供了有效的技术支持。




图 9 Jetson Xaiver NX 平台  
Fig. 9 Jetson Xavier NX platform

表 8 部署检测帧率对比

Tab. 8 Deployment detection frame rate comparison

| 模型      | Jetson Xavier NX |             |
|---------|------------------|-------------|
|         | 无加速              | TensorRT 加速 |
| YOLO11n | 20.25            | 54.46       |
| 所提方法    | 23.71            | 64.32       |

5 结 论

针对雾天环境下道路缺陷检测精度不足的问题,提出了改进 YOLO11n 的轻量化检测算法。通过构建 DH-Net 模块实现去雾与检测的联合优化,结合 PN-MS 结构的跨层统计量传递机制,有效缓解了去雾过程对目标特征的失真影响;采用 ADown 下采样模块替代传统卷积,在保留关键空间信息的同时减少参数量;设计的 EMAFPN

特征金字塔网络通过多尺度卷积核适配与自适应加权融合策略,使模型对雾天模糊目标的 mAP 检测精度提升;引入的 PC\_Head 检测头以 PConv 部分卷积为核心,在降低计算量的同时维持了检测性能。实验表明,改进模型以 1.3 M 参数量与 5.2 G FLOPs 计算复杂度,在合成雾天场景和真实雾天场景下较基准模型 YOLO11n 平均精度分别提升 2.1% 和 3%,成功实现精度与效率的同步优化,其轻量化特性为移动端部署提供

了可行方案。

#### 作者贡献说明

陈仁祥:检测方法的提出;  
邓力珩:改进方法的提出,论文编辑与撰写;  
杨黎霞:审核与编辑;  
陈卓:提供资源;  
王磊:检测实验的设计;  
罗浩铭:数据整理与分析。

#### 参考文献:

- [1] 李雄心,夏丰领,张靠民,等. 强化边缘特征提取的双分支融合真实图像去雾[J]. 光学精密工程, 2025, 33(2): 247-261.  
LI X X, XIA F L, ZHANG K M, *et al.* Enhanced edge feature extraction dual branch fusion network for real image dehazing[J]. *Opt. Precision Eng.*, 2025, 33(2): 247-261. (in Chinese)
- [2] 夏平,李子怡,雷帮军,等. 小波 DehazeFormer 网络的道路交通图像去雾[J]. 光学精密工程, 2024, 32(12): 1915-1928.  
XIA P, LI Z Y, LEI B J, *et al.* Wavelet dehaze-former network for road traffic image dehazing method[J]. *Opt. Precision Eng.*, 2024, 32(12): 1915-1928. (in Chinese)
- [3] 朱开源,吴佰靖,高德勇,等. 基于在线增强和跨尺度特征重建的雾天目标检测[J]. 计算机工程与应用, 2025, 61(11): 132-143.  
ZHU K Y, WU B J, GAO D Y, *et al.* Target detection in foggy conditions based on online enhancement and cross-scale feature reconstruction [J]. *Computer Engineering and Applications*, 2025, 61(11): 132-143. (in Chinese)
- [4] 岳永恒,雷文朋. 基于改进的 CycleGAN 和 YOLOv8 联合雾天道路环境感知算法[J]. 华南理工大学学报(自然科学版), 2025, 53(2): 48-57.  
YUE Y H, LEI W P. Foggy road environment perception algorithm based on an improved CycleGAN and YOLOv8[J]. *Journal of South China University of Technology (Natural Science Edition)*, 2025, 53(2): 48-57. (in Chinese)
- [5] 祝琴,韩沈阳,曾明如,等. SFW-YOLOv8 复杂场景视频车辆检测模型[J]. 汽车工程, 2024, 46(12): 2290-2302.  
ZHU Q, HAN S Y, ZENG M R, *et al.* SFW-YOLOv8 complex scene video vehicle detection model [J]. *Automotive Engineering*, 2024, 46(12): 2290-2302. (in Chinese)
- [6] ZHANG Y W, WU Y, LIU Y M, *et al.* CPA-Enhancer: Chain-of-Thought Prompted Adaptive Enhancer for Object Detection under Unknown Degradations [EB/OL]. 2024; *arXiv*: 2403.11220. <https://arxiv.org/abs/2403.11220>
- [7] HUANG S C, LE T H, JAW D W. DSNet: joint semantic learning for object detection in inclement weather conditions[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 43(8): 2623-2633.
- [8] WANG C Y, YEH I H, MARK LIAO H Y. YOLOv9: learning what you want to learn using programmable gradient information[C]. *Computer Vision - ECCV 2024*. Cham: Springer, 2025: 1-21.
- [9] YANG Z Q, GUAN Q, ZHAO K E, *et al.* Multi-Branch Auxiliary Fusion YOLO with Re-Parameterization Heterogeneous Convolutional for Accurate Object Detection [EB/OL]. 2024; *arXiv*: 2407.04381. <https://arxiv.org/abs/2407.04381>
- [10] TAN M X, PANG R M, LE Q V. EfficientDet: scalable and efficient object detection [C]. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 13-19, 2020, Seattle, WA, USA. IEEE, 2020: 10778-10787.
- [11] RAHMAN M M, MUNIR M, MARCULESCU R. EMCAD: efficient multi-scale convolutional attention decoding for medical image segmentation [C]. 2024 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 16-22, 2024, Seattle, WA, USA. IEEE, 2024: 11769-11779.
- [12] CHEN J R, KAO S H, HE H, *et al.* Run, Don'T

- Walk: chasing higher FLOPS for faster neural networks[C]. 2023 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 17-24, 2023, Vancouver, BC, Canada. IEEE, 2023: 12021-12031.
- [13] 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: gdj3. 260.
- [14] 李大湘, 苏仲恒, 刘颖. 基于改进YOLOv4的道路交通标志识别[J]. *光学精密工程*, 2023, 31(9): 1366-1378.
- LI D X, SU Z H, LIU Y. Road traffic sign recognition algorithm based on improved YOLOv4[J]. *Opt. Precision Eng.*, 2023, 31(9): 1366-1378. (in Chinese)
- [15] 郭业才, 唐宇捷. 基于MHD-YOLO的钢表面缺陷检测算法[J]. *激光与光电子学进展*, 2025, 62(20): 2012007.
- GUO Y C, TANG Y J. Steel surface defect detection algorithm based on MHD-YOLO[J]. *Laser & Optoelectronics Progress*, 2025, 62(20): 2012007. (in Chinese)
- [16] LIU S T, HUANG D, WANG Y H. Learning Spatial Fusion for Single-Shot Object Detection[EB/OL]. 2019; *arXiv*: 1911.09516. <https://arxiv.org/abs/1911.09516>
- [17] FENG Y F, HUANG J G, DU S Y, *et al.* Hyper-YOLO: when visual object detection meets hypergraph computation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2025, 47(4): 2388-2401.
- [18] 李军, 杨飞帆, 龚胜, 等. 基于视觉的轻量化路面异常检测算法[J/OL]. *吉林大学学报(工学版)*, 1-9 [2025-04-13].
- LI J, YANG F F, GONG S. *et al.* Lightweight pavement anomaly detection algorithm based on vision[J/OL]. *Journal of Jilin University(Engineering and Technology Edition)*, 1-9 [2025-04-13]. (in Chinese)

#### 作者简介:



陈仁祥(1983—),男,四川盐源人,教授,博士生导师,2007年和2012年于重庆大学分别获得学士学位和博士学位,现为重庆交通大学机电与车辆工程学院副院长,主要从事机器视觉、智能测试技术与信号处理方面的研究。  
E-mail:manlou. yue@126.com