

MAOD-Net: 面向雾天路面病害场景的多尺度一体化去雾网络

范宇霄, 张清杨

(江苏师范大学人工智能与计算机学院, 江苏 徐州 221000)

摘要: 雾天环境会导致道路画面清晰度下降, 对路面病害检测工作产生严重影响。针对现有去雾方法在路面病害检测中存在细节恢复不足及模型较复杂的问题, 提出一种多尺度一体化去雾网络。首先, 在网络中引入多尺度特征提取与加权融合模块, 通过3个不同尺度的分支提取特征, 并结合通道注意力、空间注意力与固定权重融合策略, 增强远近景的上下文表达; 其次, 设计由平均绝对误差、均方误差与结构相似性组成的混合损失函数; 然后, 基于改进霜冰优化算法的参数优化策略, 对学习率等关键参数进行寻优; 最后, 在合成雾天道路缺陷数据集上开展实验。结果表明, 提出的多尺度一体化去雾网络参数量仅为0.137M, 帧率达到115 f/s, 轻量化程度较高, 同时在峰值信噪比、结构相似性等指标上优于其他算法。此外, 该网络在关键病害区域恢复了更丰富的纹理细节, 为后续雾天路面病害检测奠定了坚实的技术基础。

关键词: 图像去雾; 路面病害检测; 混合损失; YOLOv11; FRIME优化算法

DOI: 10.11907/rjdk.261012

扫描二维码阅读全文: 

中图分类号: TP391

文献标识码: A

文章编号: 1672-7800(XXXX)0XX-0001-09

MAOD-Net: A Multi-scale All-in-One Dehazing Network for Foggy Road Surface Defect Scenarios

FAN Yuxiao, ZHANG Qingyang

(School of Artificial Intelligence and Computer Science, Jiangsu Normal University, Xuzhou 221000, China)

Abstract: Foggy environments reduce the clarity of road images and seriously affect road surface distress detection. To address the problems of insufficient detail recovery and relatively high model complexity in existing dehazing methods for road distress detection, a multi-scale all-in-one dehazing network is proposed. First, a multi-scale feature extraction and weighted fusion module is introduced into the network. Features are extracted through three branches at different scales, enhanced by channel and spatial attention mechanisms, and then aggregated by a fixed-weight fusion strategy, thereby strengthening the contextual representation of both near and far scenes. Second, a hybrid loss function composed of Mean Absolute Error (MAE), Mean Squared Error (MSE), and Structural Similarity (SSIM) is designed. Then, a parameter optimization strategy based on an improved RIME algorithm is employed to optimize key parameters such as the learning rate. Finally, experiments are conducted on a synthetic foggy road defect dataset. The results show that the proposed network has only 0.137M parameters and runs at 115 f/s, indicating a high degree of lightweight design, while outperforming other methods in terms of Peak Signal-to-Noise Ratio (PSNR), Structural Similarity (SSIM), and related metrics. In addition, it restores richer texture details in critical distress regions, providing a solid foundation for subsequent foggy road surface distress detection.

Key Words: image dehazing; road damage detection; hybrid loss; YOLOv11; FRIME optimization algorithm

收稿日期: 2026-02-04

基金项目: 国家自然科学基金资助项目(62006103); 徐州基础研究青年科技人才项目(KC23025); 英国皇家学会国际交流计划(IEC\NSFC\211404); 国家留学基金委项目(202310090064); 江苏师范大学研究生科研与实践创新项目(2025XKT1446)

作者简介: 范宇霄(1998-), 男, CCF 学生会会员, 江苏师范大学人工智能与计算机学院硕士研究生, 研究方向为计算机视觉与进化计算; 张清杨(1990-), 男, 博士, 江苏师范大学人工智能与计算机学院副教授、硕士生导师, 研究方向为计算机视觉、进化计算与动态优化。本文通讯作者: 张清杨。

0 引言

路面安全状况直接关系着交通运输效率和公共安全,随着我国交通网络规模的不断扩大,路面的及时检测和维修已成为智能交通系统建设的重要环节之一^[1]。传统的人工巡检方式效率低下、成本高昂,难以满足大规模路网的实时监测需求。当前,基于机器视觉的自动化路面病害检测技术发展迅速,通过车载摄像头采集路面状况图像并利用深度学习算法进行智能识别,为道路养护决策提供了高效、准确的技术手段。然而,在实际应用中,雾、霾等恶劣天气条件会显著降低图像的对比度和清晰度,导致路面纹理细节模糊、边缘信息丢失,不仅严重影响检测算法的鲁棒性与准确性,还可能导致交通事故更加频繁^[2]。因此,在雾天场景下对路面进行去雾预处理,对提升路面病害检测系统在复杂气象条件下的稳定性与可靠性具有重要意义。

近年来,国内外学者已开始关注将去雾与目标检测或分割进行协同设计。杨瑗玮等^[3]提出全局-局部注意力融合的多级“U”型去雾网络,有效地缓解了细节丢失,提高了图像清晰度。夏平等^[4]在 DehazeFormer 框架中引入小波分解,构建面向道路交通图像的去雾网络,在增强雾天道路细节恢复中取得了良好效果。上述研究表明,在车载或路侧嵌入式平台上部署去雾算法和检测模型时,由于算力和存储条件有限,需要在去雾质量、模型规模与实时性之间寻求平衡,这也是智能交通系统边缘智能发展面临的关键问题之一^[5]。此外,单张图片去雾方法的发展经历了从先验驱动到数据驱动,基于 Vision Transformer 的 DehazeFormer 利用多尺度特征和频域建模,在多种室内外数据集上取得了优异的去雾性能^[6]。在真实雾天图像方面,Chen 等^[7]提出一种基于提示学习的测试时去雾工作,在无需重新训练的前提下提升了真实场景下的泛化表现。在交通应用方面,霍爱清等^[8]将改进的暗通道先验与 CycleGAN、CenterNet 相结合,提出去雾交通标志检测方法,在浓雾条件下显著提升了标志检测精度。

现有方法在雾天场景已取得显著进展,但在面向雾天路面病害检测的特定应用时,仍存在许多不足,具体包括:①网络结构规模偏大,难以在车载或路侧嵌入式平台部署;②部分方法过度追求峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)等指标,导致裂缝、坑槽等细粒度病害区域出现细节丢失或伪影;③在参数设置上高度依赖人工经验调参,缺乏自动化优化机制。针对上述问题,本文在轻量级一体化去雾网络(All-in-One Dehazing Network, AOD-Net)的基础上从网络结构、损失函数与参数优化3个层面进行了系统改进^[9]。首先,提出多尺度 AOD-Net 去雾网络(Multi-Scale All-in-One Dehazing Network, MAOD-Net),在编码阶段引入三条尺度分支进行特征提取,并结

合通道注意力(Channel Attention, CA)和空间注意力(Spatial Attention, SA)对多尺度特征进行增强^[10];其次,通过固定权重融合完成特征聚合,使其在极小参数量下兼顾远近景雾层抑制与路面病害细节恢复;再次,构建由平均绝对误差(Mean Absolute Error, MAE)、均方误差(Mean Squared Error, MSE)与结构相似性(Structural Similarity, SSIM)组成的混合损失函数,缓解仅优化单一指标带来的过度平滑或色偏问题;然后,构建参数优化框架,引入多种优化算法对学习率、权重衰减、梯度裁剪、多尺度融合权重及损失权重等关键参数进行寻优;最后,在统一的实验平台上系统比较不同优化策略的效果,从而为后续路面病害检测提供高质量的去雾前处理模块。

1 去雾原理及算法

1.1 大气散射模型

大气散射模型源自大气散射理论,用于刻画雾霾条件下场景辐亮度在成像过程中的退化机理。在单幅静态图像情形下,经典大气散射成像模型如式(1)所示:

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

其中, $I(x)$ 为相机采集到的含雾图像辐亮度, $J(x)$ 为对应的无雾场景辐亮度, A 为全局大气光, $t(x) \in [0, 1]$ 为透射率。该模型将含雾图像分解为两个部分: $J(x)t(x)$ 表示场景辐射经大气衰减后到达相机的直接透射光,反映了场景本身的信息; $A(1 - t(x))$ 表示大气光在传播路径上的散射贡献,是造成图像模糊和对比度下降的主要原因。透射率 $t(x)$ 描述了光线在传播过程中未被散射的比例,其值越小表示雾越浓,场景信息损失越严重。通常,透射率的表示如式(2)所示:

$$t(x) = e^{-\beta d(x)} \quad (2)$$

其中, β 为大气散射系数,与大气中颗粒物的浓度和性质有关; $d(x)$ 为场景深度,表示场景点到相机的距离。去雾后恢复图像的形式如式(3)所示:

$$J(x) = \frac{I(x) - A}{t(x)} + A \quad (3)$$

在基于物理模型的去雾方法中,估计全局大气光 A 和像素级透射率 $t(x)$ 是恢复清晰图像的关键。然而,从单幅图像中同时估计这两个未知量是一个高度欠定的逆问题,需要引入额外的先验知识或约束条件。深度学习方法以大量数据驱动的方式,学习从雾化图像到清晰图像的端到端映射,避免了显式估计中间变量的困难,为去雾任务提供了更加灵活和鲁棒的解决方案。

1.2 AOD-Net 去雾网络

AOD-Net 是一种轻量级端到端图像去雾网络,其网络结构如图 1 所示。其基本思想是将式(1)中的未知量 $t(x)$ 与 A 重参数化为单一映射 $K(x)$ 及偏置项 $b(x)$,从而避免显式估计透射率与大气光。




Fig. 1 Network architecture of AOD-Net

图1 AOD-Net网络结构

具体而言,将大气散射模型的恢复公式如式(4)所示:

$$J(x) = \frac{1}{t(x)} I(x) + \left(A - \frac{A}{t(x)} \right) \quad (4)$$

记 $K(x) = \frac{1}{t(x)}$ 、 $b(x) = A - \frac{A}{t(x)}$,则有线性关系如式(5)所示:

$$J(x) = K(x)I(x) + b(x) \quad (5)$$

即通过学习像素级映射 $K(x)$ 与偏置 $b(x)$ 完成去雾复原。AOD-Net 在网络实现上进一步采用更便于实现与收敛的近似形式如式(6)所示:

$$J(x) = K(x)I(x) - K(x) + b \quad (6)$$

同时,通过浅层卷积网络直接回归 $K(x)$ 。网络结构采用编码器—解码器架构,由5个卷积层组成,每层后接批归一化和修正线性单元激活函数。输入层接收含雾的RGB图像,经过多层特征提取后,最后一层输出三通道的 $K(x)$ 映射。然而,原始AOD-Net在处理复杂道路场景时存在一定局限性:①单一尺度的特征提取,难以同时兼顾近景的细粒度裂缝纹理和远景的大范围雾层分布;②网络容量较小导致对浓雾场景的处理能力不足;③缺乏对不同区域重要性的自适应调节机制。针对上述不足,研究者在AOD-Net的基础上引入了多尺度特征融合与注意力机制进行改进,以更好地适应雾天路面病害检测的实际需求。

2 MAOD-Net去雾网络

针对原始AOD-Net在道路路面病害场景下存在的不足,

本文围绕雾天道路病害检测场景中的三类核心需求进行系统改进。首先,在结构上需要同时看清近处和远处大小长宽不一的路面病害,从而兼顾细节与全局雾层分布;其次,在训练目标上需要避免只追求峰值信噪比带来的过度平滑,使恢复结果既干净又不过度锐化;最后,在参数上需要摆脱人工反复调参的低效流程,让网络可以自动找到适合路面病害检测的最优配置。基于这样的整体思路,MAOD-Net 从多尺度结构与注意力机制、混合损失函数以及参数优化3个方面对原始AOD-Net进行了系统性改进。

2.1 多尺度特征提取

与原始AOD-Net仅在单尺度上建模不同,MAOD-Net在编码阶段显式引入三条尺度分支,其网络结构如图2所示。多尺度模块位于初始卷积之后,包含3个并行分支。其中,原始分辨率分支(Scale1)直接在 $[B, 3, H, W]$ 尺度上堆叠两层 3×3 卷积、批归一化(Batch Normalization, BN)和线性整流函数(Rectified Linear Unit, ReLU),用于捕获路面裂缝、坑槽边缘等精细纹理细节,输出特征记为 $F_1 \in R^{C \times H \times W}$; $\frac{1}{2}$ 尺度分支(Scale2)先通过 2×2 最大池化下采样到 $\frac{H}{2} \times \frac{W}{2}$,再堆叠多层卷积提取中尺度结构信息,最后上采样至原始分辨率并通过 1×1 卷积压缩通道数,得到 $F_2 \in R^{C \times H \times W}$; $\frac{1}{4}$ 尺度分支(Scale3)在更低分辨率 $(\frac{H}{4} \times \frac{W}{4})$ 下进行较深的卷积堆叠,以获得大感受野下的全局上下文与雾层分布信息,经上采样与通道压缩后得到 $F_3 \in R^{C \times H \times W}$ 。




Fig. 2 Network structure of MAOD-Net

图2 MAOD-Net网络结构图

为凸显不同尺度在任务中的角色,在多尺度融合阶段,网络采用固定权重 $(w_1, w_2, w_3) = (0.5, 0.3, 0.2)$ 对三路特征进行线性组合。设融合卷积输出为 F_{fuse} , 则 SA 模块首先在通道维上进行平均池化和最大池化,得到两幅单通道特征图 $M^{\text{avg}}, M^{\text{max}} \in R^{1 \times H \times W}$, 再通过 7×7 卷积和 Sigmoid 函数映射生成空间注意力图,如式(7)所示:

$$M_s = \sigma \left(f^{7 \times 7} \left([M^{\text{avg}}; M^{\text{max}}] \right) \right), \quad M_s \in [0, 1]^{1 \times H \times W} \quad (7)$$

最终,得到加权后的空间特征,如式(8)所示:

$$F_{\text{sa}} = M_s \odot F_{\text{fuse}} \quad (8)$$

其中, $[;]$ 表示在通道维拼接, $\odot$ 为逐元素乘积。得到空间重加权特征后, MAOD-Net 将其与初始编码特征 F_{init} 拼接,输入通道注意力 CA 模块。CA 首先在空间维上对拼接特征 $F_{\text{cat}} \in R^{2C \times H \times W}$ 进行全局平均池化,得到通道描述向量 $z \in R^{2C}$, 再通过两层全连接网络(权重矩阵分别为 $W_{f_{c1}}$ 和 $W_{f_{c2}}$)和 sigmoid 函数 σ 映射生成通道权重,如式(9)-(10)所示:

$$m_c = \sigma \left(W_{f_{c2}} \delta \left(W_{f_{c1}} z \right) \right), \quad m_c \in [0, 1]^{2C} \quad (9)$$

$$F_{\text{ca}} = m_c \odot F_{\text{cat}} \quad (10)$$

其中, $\delta(\cdot)$ 为 ReLU 激活。最后, F_{ca} 依次通过 4 个具有不同感受野的 AOD 风格卷积单元,得到特征图 X_1, X_2, X_3, X_4 。

2.2 混合损失函数设计

为在像素误差、能量一致性与结构相似性之间取得平衡, MAOD-Net 采用由 MAE、MSE 与 SSIM 组成的混合损失函数。记参考清晰图为 J , 网络输出为 $\hat{J}$, 图像大小为 $H \times W$, 则 MAE 和 MSE 如式(11)所示:

$$\mathcal{L}_{\text{MAE}} = \frac{1}{HW} \sum_{i,j} |\hat{J}(i,j) - J(i,j)|, \quad \mathcal{L}_{\text{MSE}} = \frac{1}{HW} \sum_{i,j} (\hat{J}(i,j) - J(i,j))^2 \quad (11)$$

其中, H, W 为图像高和宽。SSIM 公式如式(12)所示:

$$\text{SSIM}(\hat{J}, J) = \frac{(2\mu_{\hat{J}}\mu_J + C_1)(2\sigma_{\hat{J}J} + C_2)}{(\mu_{\hat{J}}^2 + \mu_J^2 + C_1)(\sigma_{\hat{J}}^2 + \sigma_J^2 + C_2)} \quad (12)$$

其中, $\mu_{\hat{J}}, \mu_J$ 分别为局部均值, $\sigma_{\hat{J}}, \sigma_J$ 为局部方差, $\sigma_{\hat{J}J}$ 为协方差, C_1, C_2 为稳定常数; SSIM 取值范围在 $[0, 1]$, 数值越大表示复原图与参考图的结构越接近。基于式(12)中定义的结构相似性指标,构造结构损失如式(13)所示:

$$\mathcal{L}_{\text{SSIM}} = 1 - \text{SSIM}(\hat{J}, J) \quad (13)$$

综合三项损失,可得混合损失函数如式(14)所示:

$$\mathcal{L}_{\text{total}} = \lambda_1 \mathcal{L}_{\text{MAE}} + \lambda_2 \mathcal{L}_{\text{MSE}} + \lambda_3 \mathcal{L}_{\text{SSIM}} \quad (14)$$

其中, $\lambda_1, \lambda_2, \lambda_3$ 为非负权重,用于在训练过程中调节像素误差、能量一致性与结构相似性的相对重要性。合理设置三者权重有助于缓解仅优化单一指标带来的过度平滑或伪影问题,使去雾结果能够在 PSNR、SSIM 与主观视觉质量之间取得更好的折中。尤其是在裂缝和坑槽等细粒度病害区域,可以避免细节发糊的情况,从而更契合后续检测网络对边缘与纹理的需求。

2.3 参数寻优

深度学习模型的性能高度依赖于超参数配置,传统人工调参不仅耗时低效,且难以在多维空间中寻得全局最优解。为此,本文构建了自动化参数优化框架,将学习率 (lr)、权重衰减 (wd)、梯度裁剪阈值 (gc)、多尺度加权系数 (w_1, w_2, w_3) 以及损失权重 ($\lambda_1, \lambda_2, \lambda_3$) 这 9 个关键参数纳入统一搜索空间。为了确保搜索的有效性,为各参数设定了合理的上下界约束:学习率 $lr \in [10^{-4}, 10^{-2}]$; 权重衰减 $wd \in [10^{-6}, 10^{-3}]$; 梯度裁剪阈值 $gc \in [10^{-2}, 1.0]$; 多尺度权重满足 $w_i \in [0, 1]$ 且 $\sum_{i=1}^3 w_i = 1$; 损失权重 $\lambda_1 \in [0.5, 2.0], \lambda_2 \in [0.5, 2.0], \lambda_3 \in [0.05, 0.5]$ 。该框架以

验证集上的混合损失函数作为适应度评价指标,通过迭代执行种群初始化、适应度评估及进化更新操作,自动搜索并输出适应度最优的参数组合。通过统一的参数优化框架,能够避免人工调参的盲目性与低效性,为后续路面病害检测提供了稳定、高质量的前置去雾模块。

3 实验设计与结果分析

3.1 数据集与评价指标

雾天场景下的路面图像采集标注工作是路面去雾检

测任务一大难点,以无雾路面病害数据集为基础生成贴近真实场景的有雾图像是解决该难点的有效策略^[11]。实验数据以 TD-RD 路面病害数据集为基础,通过大气散射模型在每张清晰图上生成 5 档不同雾浓度的合成图像,并将合成后的数据集命名为 HTDRD^[12-13]。新的雾天路面病害样本如图 3 所示。该数据集分辨率高、病害类别划分合理,覆盖裂缝、坑槽、修补这 3 种典型病害,既能评估去雾算法对任务相关细节的恢复能力,也便于分析去雾前处理对后续路面病害检测精度的影响。




Fig. 3 Dataset samples

图3 数据集样本

采用 PSNR 与 SSIM 作为指标。设参考清晰图为 J , 复原图为 $\hat{J}$, 图像大小为 $H \times W$, 峰值信噪比的计算公式如式 (15) 所示:

$$\text{PSNR} = 10 \log_{10} \frac{L^2}{\text{MSE}} \quad (15)$$

其中, L 为像素最大值, 单位为分贝 (decibel, dB), SSIM 指标在公式 (12) 中已定义。为衡量模型复杂度与实时性, 实验进一步统计了参数量 (Params) 以及在图形处理器上的推理帧率 (Frames Per Second, FPS)。

3.2 实验设置

实验环境所用的操作系统为 Windows 11, CPU 为 Intel i7-13650HX, GPU 为 NVIDIA GeForce RTX 4060, Python 3.10, CUDA 版本为 12.8, 深度学习框架为 PyTorch 2.2.2。训练阶段采用 Adam 优化器, 基础学习率设置为 10^{-3} , 在参数优化实验中由各优化算法搜索最优值; 批大小为 8, 训练轮数 5。输入图像统一缩放至 640×640 。所有方法的对比在相同配置和数据集下进行, 以保证对比公平性。同时, 考虑到现实中车载设备在雾天情景下采集到路面病害图像较少出现严重模糊的情况, 故在可视化对比实验中选用中度雾化图进行实验对比。

3.3 消融实验

为验证多尺度模块 (Multi-Scale)、混合损失 (Loss) 和参数优化 (Optimization) 这 3 个改进方法的有效性, 在 HTDRD 数据集上进行消融实验, 实验结果如表 1 所示。以原始 AOD-Net 为基准 (Baseline), 其参数量仅为 0.002M, FPS 达到 217 f/s, 但 PSNR 和 SSIM 分别为 20.63 dB 和 0.90。引

入多尺度模块后, 参数量增至 0.137M, PSNR 和 SSIM 分别提升至 23.12 dB 和 0.93, 表明多尺度特征聚合对去雾性能提升具有显著作用。进一步联合混合损失和参数优化后, 完整 MAOD-Net 的 PSNR 和 SSIM 达到 25.22 dB 和 0.95, 虽然 FPS 降至 115 f/s, 但仍然符合实时推理速度要求。

Table 1 Ablation study results of MAOD-Net

表1 MAOD-Net 消融实验结果

Baseline	Multi-Scale	Loss	Optimization	PSNR/ dB	SSIM	Params /M	FPS f/s
✓				20.63	0.90	0.002	217
✓	✓			23.12	0.93	0.137	125
✓		✓		21.52	0.91	0.002	209
✓			✓	21.35	0.91	0.002	216
✓	✓	✓		23.64	0.93	0.137	118
✓	✓		✓	23.81	0.94	0.137	123
✓		✓	✓	22.35	0.92	0.002	208
✓	✓	✓	✓	25.22	0.95	0.137	115

为了直观展示多尺度模块带来的变化, 图 4 展示了 AOD-Net 与 MAOD-Net 在同一雾化路面图像上的残差与去雾结果对比。由图 4 可知, 改进后的 MAOD-Net 在归一化残差图中呈现出更加清晰的结构化残差分布, 特别是在裂缝周边区域残差更突出。这表明, 模型更聚焦于病害区域的雾去除, 而不是对整幅图做均匀、粗糙的调整。此外, 残差热力图显示, AOD-Net 的残差能量集中在路面的一大片区域, 表现为较粗糙的块状分布; 而 MAOD-Net 的残差能量沿着裂缝和细粒纹理分布, 更接近真实雾场沿物体边缘逐渐变化的物理特性。这表明, 改进后模型的去雾效果更加精细, 空间分布也更合理。从残差图对比中可以看到,

MAOD-Net 具有更细致的结构信息,这意味着网络主要在补偿雾造成的对比度损失,而不是简单提高整体亮度,这有利于后续路面病害检测。从去雾效果来看,AOD-Net 虽然使雾变淡,但裂缝边缘不够锐利,树影和路面之间的对

比度仍显不足。而 MAOD-Net 整体对比度略有提升,墙面纹理呈现更清晰,裂缝边缘更加锐利,阴影过渡比 AOD-Net 更自然,没有出现明显的过度增强或环状伪影,充分证明了改进的有效性。




Fig. 4 Comparison of residual maps

图4 残差图对比结果

3.4 优化算法对比实验

为全面评估不同优化算法的有效性,选取了7种具有代表性的优化算法进行对比实验^[14]:粒子群优化(Particle Swarm Optimization, PSO)^[15]、遗传算法(Genetic Algorithm, GA)^[16]、差分进化(Differential Evolution, DE)^[17]、禁忌搜索(Tabu Search, TS)^[18]、蚁群优化(Ant Colony Optimization, ACO)^[19]、混合遗传算法(Hybrid Genetic Algorithm, HGA)^[20]和FRIME算法^[21]。其参数优化算法对比结果如表2所示。

从表2的结果可以看出,相较于基准配置(采用经验参数 $lr=1.00E-03$ 、 $wd=1.00E-04$ 、 $gc=1.00E-01$ 、 $w_1=5.00E-01$ 、 $w_2=3.00E-01$ 、 $w_3=2.00E-01$ 、 $\lambda_1=1.00E+00$ 、 $\lambda_2=1.00E+00$ 、 $\lambda_3=1.00E-01$),所有优化算法均能在不同程度上提升去雾性能。其中,PSO和GA等经典算法虽然能够找到优于基准的参数配置,但提升幅度有限,其PSNR分别达到24.0 dB和23.9 dB;DE、TS和ACO通过更精细的搜索策略

将PSNR分别提升至24.8 dB、25.0 dB和24.7 dB;HGA则通过混合局部搜索进一步改善至25.2 dB;FRIME算法在9维参数空间中实现了较优的全局搜索与局部开发平衡,最终获得25.2 dB的PSNR和0.948的SSIM,显著优于多数对比方法。值得注意的是,FRIME搜索得到的学习率($8.95E-03$)明显高于常规经验值,权重衰减($4.18E-06$)则极小,这表明在MAOD-Net的轻量化结构下,较大的学习率有助于加速收敛,而过强的正则化反而会抑制模型对雾天道路细节的拟合能力。此外,FRIME优化后的多尺度权重 w_1 、 w_2 、 w_3 分别为 $5.15E-01$ 、 $2.67E-01$ 和 $2.18E-01$,与初始设定接近但更加精细,说明原始分辨率分支在裂缝恢复中的主导作用得到了算法的自动确认。损失权重 λ_1 、 λ_2 、 λ_3 分别为 $1.67E+00$ 、 $1.56E+00$ 和 $1.23E-01$,表明在路面病害场景下,MAE和MSE的像素级约束比SSIM结构约束更为关键,这与裂缝、坑槽等病害的局部纹理特性密切相关。

Table 2 Comparison results of parameter optimization algorithms

表2 参数优化算法对比结果

模型	评价指标		优化参数								
	PSNR/dB	SSIM	lr	wd	gc	w_1	w_2	w_3	λ_1	λ_2	λ_3
无优化	2.36E+01	9.34E-01	1.00E-03	1.00E-04	1.00E-01	5.00E-01	3.00E-01	2.00E-01	1.00E+00	1.00E+00	1.00E-01
PSO	2.40E+01	9.41E-01	2.43E-03	5.01E-05	5.85E-01	4.07E-01	2.01E-01	3.92E-01	1.23E+00	1.45E+00	3.21E-01
GA	2.39E+01	9.38E-01	5.88E-04	1.91E-04	1.20E-02	4.43E-01	3.34E-01	2.23E-01	9.87E-01	1.23E+00	2.13E-01
DE	2.48E+01	9.39E-01	4.88E-03	1.42E-06	6.71E-01	2.76E-01	4.79E-01	2.45E-01	1.56E+00	1.78E+00	3.45E-01
TS	2.50E+01	9.42E-01	1.71E-03	2.61E-05	1.98E-01	5.87E-01	3.11E-01	1.02E-01	1.89E+00	9.76E-01	1.45E-01
ACO	2.47E+01	9.40E-01	2.19E-03	8.64E-05	4.24E-02	6.23E-01	3.33E-01	0.44E-01	7.65E-01	1.67E+00	2.89E-01
HGA	2.52E+01	9.45E-01	3.72E-03	1.11E-06	1.33E-02	5.51E-01	1.60E-01	2.89E-01	1.11E+00	1.34E+00	1.77E-01
FRIME	2.52E+01	9.48E-01	8.95E-03	4.18E-06	9.10E-02	5.15E-01	2.67E-01	2.18E-01	1.67E+00	1.56E+00	1.23E-01

3.5 去雾算法对比

为验证MAOD-Net的综合性能,本文选取了AOD-Net、FAMED-Net^[22]、FFA-Net^[23]、GridDehazeNet^[24]以及

AECR-Net^[25]等轻量级且具有代表性的去雾网络,在HT-DRD数据集上进行去雾效果的对比实验,对比结果如表3所示。由表3可知,GridDehazeNet与AECR-Net在PSNR和

SSIM 上表现较为突出,但参数量分别接近 0.96 M 和 0.61 M,FPS 仅为 56 f/s 和 65 f/s。然而,MAOD-Net 仅以 0.137 M 的参数量,便实现了 25.22 dB 的 PSNR 和 0.95 的 SSIM,与较大模型持平甚至略优,同时保持了 115 f/s 的实时性能。

为直观展示不同去雾算法在不同场景中的表现,分别从 HTDRD 数据集和公开的 RESIDE- β Outdoor Training Set (OTS) 数据集中各选取两张具有代表性的图片进行测试^[26]。图 5 展示了 6 种算法的去雾效果对比情况。在 HT-

Table 3 Comparison results of different dehazing algorithms

表 3 不同去雾算法对比结果				
模型	PSNR/dB	SSIM	Params/M	FPS/f/s
AOD-Net	20.63	0.89	0.002	217
FAMED-Net	22.50	0.91	0.006	183
FFA-Net	23.30	0.93	0.673	61
GridDehazeNet	25.20	0.95	0.964	56
AECR-Net	24.68	0.95	0.613	65
MAOD-Net	25.22	0.95	0.137	115




Fig. 5 Comparison of dehazing effects for different algorithms
图 5 不同算法去雾效果对比

DRD 数据集上, AOD-Net 和 FFA-Net 去雾后画面整体灰暗, 裂缝与路面反差不足, 纹理细节模糊; FAMED-Net 虽能去雾, 但复原图像与真实图仍有明显视觉差距; Grid-DehazeNet 和 AECR-Net 去雾力度偏强, 细节保留却不到位; 反观 MAOD-Net, 复原结果更接近真实清晰图, 路面纹理完整, 亮度与对比度自然, 且第二列的网状交叉裂缝仍能清晰呈现结构, 可见多尺度特征提取与注意力机制在复杂路面病害中确有实效。在 OTS 数据集上, 涵盖了城市道路、高速公路等高雾典型场景, 雾气浓且景深变化大。AOD-Net 与 FFA-Net 去雾乏力, 细节仍被雾所覆盖; FAMED-Net 过度去雾处理, 导致图像失真; GridDehazeNet 去雾表现不稳定; AECR-Net 去雾效果最佳却偶有色彩畸变; MAOD-Net 去雾后路面细节完好, 车道线连贯自然, 整体画面协调。综合两个数据集的对比结果表明, MAOD-Net 在路面病害场景和一般室外场景上均取得了较好的去雾效果, 为后续路面病害检测提供了高质量的输入图像。

4 结语

本文围绕雾天路面病害检测这一特定应用场景, 提出了一种多尺度 AOD-Net 去雾网络 MAOD-Net。在原始 AOD-Net 的基础上, 首先, 设计了多尺度特征提取与加权融合模块, 并结合 SA 和 CA 双重注意力突出裂缝、坑槽等关键结构区域; 其次, 构建由 MAE、MSE 与 SSIM 组成的混合损失, 通过权重系数量化像素误差、能量一致性与结构相似性之间的折中关系; 最后, 在统一的参数优化框架下, 引入 FRIME 优化算法对学习率、权重衰减、梯度裁剪上界及损失权重、多尺度融合权重等关键参数进行寻优, 从而减轻了人工调参负担。与多种代表性去雾算法相比, 该算法在去雾质量、模型规模与推理速度上综合表现最优, 为雾天路面病害检测提供了兼具高质量与低开销的预处理模块。

未来工作将从以下 3 个方面开展: ①结合真实雾天道路采集数据, 引入无监督与半监督域适应方法, 进一步提高 MAOD-Net 在复杂气象与多场景下的稳健性; ②探索与目标检测或分割网络的联合训练机制, 将检测精度显式纳入目标函数, 使去雾模块能够根据下游任务自适应调节去雾强度与细节保留程度; ③面向嵌入式与车载平台, 结合模型剪枝、量化和蒸馏等轻量化技术, 设计更适配硬件约束的网络结构与推理流程。

参考文献:

- [1] Editorial Department of China Journal of Highway and Transport. Review on China's bridge engineering research: 2024[J]. China Journal of Highway and Transport, 2024, 37(12): 1-160.
《中国公路学报》编辑部. 中国桥梁工程学术研究综述·2024[J]. 中国公路学报, 2024, 37(12): 1-160.
- [2] CHEN L L, JIANG X H, ZHANG J, et al. DSACNet: improved YOLOX road defect detection under foggy conditions[J]. Journal of Chongqing Jiaotong University(Natural Science), 2025, 44(2): 53-60.
陈里里, 蒋晓红, 张杰, 等. DSACNet: 改进 YOLOX 的雾天条件下道路缺陷检测[J]. 重庆交通大学学报(自然科学版), 2025, 44(2): 53-60.
- [3] YANG A W, WANG H K, HOU X S. From global to local: a dual-attention fusion dehazing Network[J]. Journal of Xi'an Jiaotong University, 2023, 57(7): 191-200.
杨竣玮, 王华珂, 侯兴松. 从全局到局部: 双注意力融合去雾网络[J]. 西安交通大学学报, 2023, 57(7): 191-200.
- [4] XIA P, LI Z Y, LEI B J, et al. Wavelet DehazeFormer network for road traffic image dehazing method[J]. Optics and Precision Engineering, 2024, 32(12): 1915-1928.
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.
- [5] GONG T, ZHU L, YU F R, et al. Edge intelligence in intelligent transportation systems: a survey[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(9): 8919-8944.
- [6] SONG Y, HE Z, QIAN H, et al. Vision transformers for single image dehazing[J]. IEEE Transactions on Image Processing, 2023, 32: 1927-1941.
- [7] CHEN Z, HE Z, LU Z 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.
- [8] HUO A Q, FENG R S, XU J R. Traffic sign detection based on DCP-Imp CycleGAN CenterNet dehazing algorithm[J]. Radio Engineering, 2023, 53(10): 2311-2318.
霍爱清, 冯若水, 胥静蓉. 基于 DCP-Imp CycleGAN CenterNet 去雾算法的交通标志检测[J]. 无线电工程, 2023, 53(10): 2311-2318.
- [9] DONG W, WANG C, SUN H, et al. Multi-scale attention feature enhancement network for single image dehazing[J]. Sensors, 2023, 23(19): 8102.
- [10] CHEN D F, CHENG J, ZHAO L, et al. Semantic segmentation of tunnel handheld noodle rock mass structure images with improved U-Net model[J]. Journal of Disaster Prevention and Mitigation Engineering, 2025, 45(4): 776-783.
陈登峰, 程静, 赵蕾, 等. 改进 U-Net 模型的隧道掌子面图像语义分割研究[J]. 防灾减灾工程学报, 2025, 45(4): 776-783.
- [11] ZHAO C X, QI Y S, DING J Y. Recognition algorithm of road pavement disease in foggy scene[J]. Computer & Digital Engineering, 2024, 52(3): 852-857.
赵呈祥, 祁云嵩, 丁健宇. 有雾场景下的道路路面病害检测算法[J]. 计算机与数字工程, 2024, 52(3): 852-857.
- [12] XIAO X, LI Z, WANG W, et al. TD-RD: a top-down benchmark with real-time framework for road damage detection[C]//2025 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), 2025: 1-5.
- [13] LI Z, XIONG F, HUANG B, et al. MGD-YOLO: an enhanced road defect detection algorithm based on multi-scale attention feature fusion[J]. Computers, Materials & Continua, 2025, 84(3): 5613-5635.
- [14] ZITO F, TALBI E G, CAVALLARO C, et al. Metaheuristics in automated machine learning: strategies for optimization[J]. Intelligent Systems with Applications, 2025, 26: 200532.
- [15] GAO Y X, LIU J Y. Flight trajectory planning of UAV with adaptive fu-

- sion particle swarm algorithm[J]. Journal of Chinese Inertial Technology, 2025, 33(12): 1233-1245.
- 高永新,刘俊毅. 自适应融合粒子群算法无人机航迹规划[J]. 中国惯性技术学报,2025,33(12):1233-1245.
- [16] DU J Z, ZHU Z B, SUN G J, et al. Robot path planning based on GA and GWO algorithms[J]. Journal of Chongqing University of Technology (Natural Science), 2025, 39(11): 123-129.
- 杜谨泽,朱泽博,孙广杰,等. 融合GA与GWO算法的机器人路径规划[J]. 重庆理工大学学报(自然科学),2025,39(11):123-129.
- [17] GAO J K, YAO Z B. Research on intelligent control of rock testing machine based on LQR and DE-PSO [J]. Machine Tool & Hydraulics, 2025, 53(21): 121-126.
- 高继开,姚志宾. 基于LQR与DE-PSO的岩石试验机智能控制研究[J]. 机床与液压,2025,53(21):121-126.
- [18] XU J Q, YI Z H, CHEN C, et al. Acceleration feedback control of high-speed maglev suspension system with PSO-TS algorithm[J]. Journal of Vibration Engineering, 2025, 38(11): 2619-2631.
- 徐俊起,易芷涵,陈琛,等. 具有粒子群-禁忌搜索算法的高速磁悬浮系统加速度反馈控制[J]. 振动工程学报,2025,38(11):2619-2631.
- [19] CHE J B, TANG D L, HE Y Y, et al. Research on path planning method based on dynamic fusion of ant colony optimization and genetic algorithm [J]. Chinese Journal of Engineering Design, 2025, 32(6): 789-802.
- 车健波,唐东林,何媛媛,等. 动态融合蚁群算法与遗传算法的路径规划方法研究[J]. 工程设计学报,2025,32(6):789-802.
- [20] MAHMOUDINAZLOU S, KWON C. A hybrid genetic algorithm for the min-max Multiple Traveling Salesman Problem[J]. Computers & Operations Research, 2024, 162: 106455.
- [21] FAN Y, ZHANG Q. FRIME optimization algorithm for engineering applications [C]//Proceedings of the 2025 2nd International Conference on Modeling, Natural Language Processing and Machine Learning, 2025: 69-74.
- [22] ZHANG S, ZHANG X, WAN S, et al. Generative adversarial and self-supervised dehazing network [J]. IEEE Transactions on Industrial Informatics, 2024, 20(3): 4187-4197.
- [23] HE Q, XU W M, WANG Y H, et al. An improved single-image dehazing algorithm based on FFA-Net[J]. Journal of Wuhan University of Science and Technology, 2024, 47(6): 448-456.
- 何钦,徐望明,王义焕,等. 一种基于FFA-Net改进的单幅图像去雾算法[J]. 武汉科技大学学报, 2024, 47(6): 448-456.
- [24] DONG W, WANG C, SUN H, et al. End-to-end detail-enhanced dehazing network for remote sensing images[J]. Remote Sensing, 2024, 16(2): 225.
- [25] SONG X, ZHOU D, LI W, et al. TUSR-Net: triple unfolding single image dehazing with self-regularization and dual feature to pixel attention [J]. IEEE Transactions on Image Processing, 2023, 32: 1231-1244.
- [26] YIN X H, CHEN Q Y. Transformer-based image dehazing algorithm with aggregated pixel feature extraction [J]. Modern Electronics Technique, 2025, 48(23): 1-8.
- 尹学辉,陈秋雨. 基于聚合像素特征提取的Transformer图像去雾算法[J]. 现代电子技术,2025,48(23):1-8.

(责任编辑:陈维捷)