

DOI: 10.13382/j.jemi.B2508847

基于双路径重参数化网络的图像去雾方法^{*}

郭嘉城¹ 罗晓忠² 钟 寒¹

(1. 中国人民公安大学信息安全学院 北京 100038; 2. 北京警察学院科技信息网络处 北京 102202)

摘 要:针对密集非均匀雾霾场景中雾分布复杂、空间变化剧烈,导致现有深度去雾模型在真实场景下泛化能力不足、细节恢复不稳定且部署开销较高的问题,设计了一种双路径结构重参数化去雾网络(re-parameterized large kernel dehaze, RepLKDehaze)。该网络由大核结构重参数化子网(large-kernel rep subnet, RepLK)与全分辨率注意力子网(full-resolution attention subnet, FRA)构成:前者基于裁剪的 UniRepLKNet-s 编解码框架,在训练阶段通过扩张重参数化构建多分支表示,并在推理阶段等效折叠为单一大核卷积,实现对全局雾分布的高效建模;后者在原始分辨率下引入残差通道注意力机制,用于补偿下采样带来的局部纹理与边缘信息损失。两路特征经融合后实现清晰图像重建,从而在全局一致性与局部细节恢复之间取得平衡。实验结果表明,尽管 RepLKDehaze 在 RESIDE-SOTS 等合成数据集上并未在所有指标上取得最优,但在更贴近真实成像退化的 Dense-Haze 与 NH-Haze(2020/2021)数据集上表现出明显优势:在 Dense-Haze 上达到 17.66 dB/0.613/0.494 (PSNR/SSIM/LPIPS),在 NH-Haze 2020 上达到 21.66 dB/0.716/0.254,在 NH-Haze 2021 上取得 22.74 dB/0.857/0.169,在颜色还原、结构保真与残差抑制方面均优于对比方法。结果表明,所提出的双路径结构重参数化去雾网络能够有效提升真实、密集非均匀雾场景下的去雾鲁棒性,并兼顾模型部署效率,为实际雾天视觉感知任务提供了一种可行解决方案。

关键词: 图像去雾;结构重参化;大核卷积;密集非均匀雾霾

中图分类号: TP391.41 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Dual-path structural reparameterized network for high-quality image dehazing

Guo Jiacheng¹ Luo Xiaozhong² Zhong Han¹

(1. School of Information Network Security, People's Public Security University of China, Beijing 100038, China;
2. Technology Information Network Department, Beijing Police College, Beijing 102202, China)

Abstract: Dense and non-uniform haze in real-world scenes exhibits complex spatial variations, which significantly degrades the generalization ability of existing deep image dehazing models, leading to unstable detail recovery and high deployment costs. To address these challenges, this paper proposes a dual-path structurally re-parameterized dehazing network (re-parameterized large kernel dehaze, RepLKDehaze). The proposed framework consists of a large-kernel structural re-parameterization subnet (large-kernel rep subnet, RepLK) and a full-resolution attention subnet (full-resolution attention subnet, FRA). The former is built upon a trimmed UniRepLKNet-s encoder-decoder backbone, where multi-branch representations are introduced via dilated re-parameterization during training and equivalently merged into a single large-kernel convolution at inference, enabling efficient modeling of global haze distribution. The latter operates at full spatial resolution and incorporates residual channel attention to compensate for local texture and edge information loss caused by downsampling. By fusing features from both paths, RepLKDehaze achieves a balanced reconstruction between global consistency and fine-grained detail preservation. Experimental results demonstrate that although RepLKDehaze does not achieve the best performance across all metrics on synthetic datasets such as RESIDE-SOTS, it consistently outperforms state-of-the-art methods on real-world datasets that better reflect realistic imaging degradation. Specifically, it achieves 17.66 dB/0.613/0.494 (PSNR/SSIM/LPIPS) on Dense-Haze, 21.66 dB/0.716/0.254 on NH-Haze 2020, and 22.74 dB/0.857/0.169 on NH-Haze 2021.

收稿日期:2025-11-12 Received Date: 2025-11-12

^{*} 基金项目:中国人民公安大学“双一流”创新研究项目(2023SYL07)、高等学校学科创新引智基地项目(B20087)资助

The proposed method shows clear advantages in color fidelity, structural preservation, and residual haze suppression. These results indicate that the proposed dual-path structurally re-parameterized dehazing network effectively enhances robustness in real dense non-uniform haze scenarios while maintaining deployment efficiency, providing a practical solution for real-world hazy-scene visual perception tasks.

Keywords: image dehazing; structural reparameterization; large kernel convolution; dense non-uniform haze

0 引言

工业化进程加速使雾霾、烟尘等低能见度天气更为频发。悬浮颗粒导致光线散射与吸收,引起对比度下降、颜色失真和细节模糊,不仅影响人类视觉感知,也显著降低自动驾驶、遥感监测、安防取证等系统的可靠性。尤其在公安侦查(如经济犯罪侦查)的实战取证中,雾霾会削弱监控与执法记录仪对关键线索的可见性(车牌、集装箱编号、铅封号、条形码、POS屏显、人脸与衣着特征等),进而影响证据固定、时空还原与串并案研判。在夜间灯光、强反射或逆光条件下,雾霾与照明耦合还会放大色偏与低对比问题,使得细节线索更难分辨。面向一线部署的去雾算法还需兼顾终端算力、实时响应与复杂场景泛化等要求,因此研究高效、可靠的图像去雾技术具有重要意义。

传统的图像去雾方法多基于大气散射模型进行复原,通过估计透射率与大气光值恢复图像清晰度。代表性方法包括暗通道先验 DCP^[1]、颜色衰减先验 CAP^[2]及非局部先验^[3]等;此外,RefinedNet模型中的“先验+对抗学习”弱监督框架在成对数据时亦能获得较好的视觉效果^[4]。然而,物理模型通常隐含均匀光照、单一大气光值等理想假设,真实场景中的非均匀雾与复杂光照会造成透射率估计偏差,例如 DCP^[1]在明亮或者天空区域易过曝并产生伪影,CAP^[2]虽高效但对光照变化敏感,非局部先验依赖聚类与统计计算、资源开销较大。总体而言,该类方法在复杂雾场下鲁棒性与实时性仍受限制。

图像增强类方法不依赖成像模型,而是通过对比度拉伸与色彩校正提升可见性,如直方图均衡、Retinex处理与频域滤波等^[5]。该类方法实现简单、速度快,但多以主观观感为目标,缺乏对雾霾物理退化的显式建模,常出现噪声放大、过度增强、光晕等问题;同时对雾浓度的空间变化缺乏自适应调节,在浓雾与非均匀雾场景中稳定性不足,难以为后续检测识别提供一致可靠的输入。

深度学习技术推动了端到端图像去雾算法的发展。DehazeNet^[6]、AOD-Net^[7]与 DCPDN^[8]等将透射率、大气光估计融入网络推理,GridDehazeNet^[9]、FFA-Net^[10]、MSBDN^[11]等通过多尺度与注意力网络提升复原质量。针对成对数据难获取的问题,EDPN^[12]、GCA-Net^[13]等引入对抗学习降低伪影;TDN^[14]与 DW-GAN^[15]在挑战赛中

验证了“多分支协同+频域约束”的有效性。另一方面,结构重参数化^[16]被用于轻量化部署,RepDehazeNet^[17]通过训练多分支、推理单路径降低存储与计算。尽管 CNN方法在效率上具有优势,但多数高性能模型依赖深层堆叠与注意力模块,推理开销仍偏大;同时其局部感受野与静态融合策略使得对全局雾分布与长程依赖的刻画仍不足,浓雾、非均匀雾下易出现局部残雾或纹理模糊。再者,合成数据与真实数据存在域偏差^[18],导致跨场景泛化不稳定,面向真实场景的 RIDCP^[19]也从侧面反映了真实雾图像的复原难度。

Transformer 为去雾提供了更强的全局建模能力,如 Restormer^[20]、引入传输感知位置编码的去雾 Transformer^[21]以及 DehazeFormer^[22]等在多基准数据集上表现突出。但标准自注意力在高分辨率下的计算开销随像素规模快速增长,难以满足终端的实时性要求;且其更注重全局相关性,若缺少局部约束易导致高频细节过度平滑,模型规模与训练成本普遍较高。因此,如何在全局建模、细节恢复和计算效率之间取得更优平衡仍是关键问题。特别是在密集非均匀雾图像中,雾浓度在空间上快速变化,既需要大范围上下文来判断雾层分布,也需要精细纹理来支撑后续识别,这对网络的感受野、特征融合策略与部署效率提出了更高要求。

针对上述问题,本文提出双路径结构重参化去雾网络(re-parameterized large kernel dehaze, RepLKDehaze),主路径为大核结构重参化子网(large-kernel rep subnet, RepLK),其基于裁剪的 UniRepLKNet-s 骨干并利用预训练权重增强小数据泛化,训练阶段以“非扩大核卷积+扩张小核卷积”多分支提升表达并扩大有效感受野,推理阶段通过参数等效融合折叠为单一大核卷积,从而以较低计算成本实现类似全局注意力的长程依赖建模,同时消除冗余计算;辅路径为全分辨率注意力子网(full-resolution attention subnet, FRA),在原始尺度下持续强化纹理与边缘细节以补偿下采样信息损失;2路特征经轻量融合尾部重建清晰图像。与 RepDehazeNet^[17]相比,本文进一步引入更强的大核全局建模与“全局-细节”协同机制以提升非均匀雾适应性。

1 结构重参化

结构重参化(structural reparameterization, Rep)是深

度学习领域近年来出现的一种网络设计方法,旨在通过动态调整网络结构的形态,解决模型在训练与推理阶段的效率与性能矛盾。该方法在 RepVGG 模型^[16]中首次系统化阐述,其核心思想是将网络的训练结构与推理结构解耦:在训练阶段引入多分支复杂架构(如并行卷积、残差连接等),利用多路径的梯度多样性增强模型的特征提取能力和优化稳定性;而在推理阶段通过数学等价变换将多分支结构合并为单一分支的直筒网络(如 VGG 式结构),从而显著降低计算复杂度。例如,RepVGG 在训练时采用 3×3 卷积、 1×1 卷积和恒等映射的 3 分支设计,推理时则通过卷积核的空间叠加、偏置项的代数合并以及批量归一化(batch normalization, BN)参数的吸收融合,将多分支操作转换为等效的单一卷积操作。这种“训练复杂化、推理简单化”的范式,既保留了复杂结构的训练优势,又规避了其在部署时的计算冗余,实现了模型精度与效率的平衡。

UniRepLKNet^[23]创新性地引入大卷积核设计思想,通过扩大卷积核尺寸显著增强感受野(effective receptive field, ERF),以更有效地捕捉图像中的长程空间模式与全局上下文信息。该网络融合了通道注意力模块(SE blocks)和膨胀重参数化模块(dilated reparam Block)等结构,通过多维度特征交互提升网络深度与表征能力。其架构由交替堆叠的 LarK Block 和 SmaK Block 构成:LarK Block 整合了膨胀重参数化模块、SE Block、前馈网络(FFN)及批归一化层,而 SmaK Block 则以深度可分离卷积替代

膨胀重参数化模块以优化计算效率。在结构重参数化策略上,通过引入膨胀卷积捕捉稀疏特征——特别设计的 Dilated Reparam Block 在训练阶段并行使用大核卷积与膨胀卷积,基于卷积核数学等效性原理(小尺寸膨胀卷积核可等价转换为大尺寸非膨胀卷积核),最终在推理时将多分支操作合并为单一等效大核卷积,实现全局特征建模能力与计算效率的统一。

如图 1 所示,该模块由一个非扩张的大核卷积层、一个非扩张的小核卷积层和多个扩张的小核卷积层组成。其超参数包括大核卷积层的核大小 K ,并行卷积层的核大小 k 以及扩张率 r 。一个大核卷积层与 4 个并行层的示例可表示为 $K = 9, k = (5, 5, 3, 3), r = (1, 2, 3, 4)$ 。对于更大的 K ,可以使用更多的扩张层,并选择更大的卷积核与扩张率。并行分支的核大小和扩张率是灵活的,取值条件是 $(k-1)r + 1 \leq K$ 。为了在推理阶段将扩张重参数化块转换为大核卷积层,首先将每个批归一化(BN)层合并到前面的卷积层,接着使用上述转换代码来处理所有扩张率 $r > 1$ 的层,最后将所有经过转换的卷积核进行适当的零填充后相加。例如在图 1 中,核大小为 $k = 3, r = 3$ 的层将被转换为一个稀疏的 7×7 卷积核,并在四周各填充一个零像素后,与 9×9 卷积核相加。扩张重参数化块使用扩张的小核卷积层来增强非扩张的大核卷积层,这些扩张卷积层等效于一个具有更大稀疏核的非扩张卷积层,因此整个模块可以等效转换为单个大核卷积层。




图 1 扩张重参数化块示意

Fig. 1 Dilated reparam block

2 模型结构

2.1 网络总体结构(RepLKDehaze 的整体架构)

如图 2 所示,RepLKDehaze 采用双分支网络架构,包含大核结构重参数化子网和全分辨率注意力子网 2 个核心模块。具体而言:大核结构重参数化子网基于 ImageNet 预训练权重初始化,通过 UniRepLKNet 框架执行多级下采样,经上采样模块重构后,可有效提取图像的全局上下

文特征;全分辨率注意力子网在原始分辨率空间进行操作,采用注意力机制增强局部细节特征的提取能力。2 路分支输出的特征张量通过通道拼接后,经过包含卷积层和激活函数的融合模块进行特征整合,最终重构出高质量的无雾图像。

本文采用“双路径结构重参数化”架构,其核心思想并非在所有分支中同时引入结构重参数化,而是将重参数化大核建模集中于主路径,用于高效建模全局雾分布;同时引入一条不进行重参数化的全分辨率辅助路径,用于




图 2 RepLKDehaze 模型整体架构

Fig. 2 RepLKDehaze model overall architecture

补偿下采样与大核建模可能带来的局部细节损失。该设计基于如下考虑:密集非均匀雾的去除需要强全局建模能力,但细节恢复更依赖高分辨率特征表达,若在单一路径中同时兼顾二者,容易导致结构冗余或计算开销过大。因此,本文通过双路径协同的方式,将全局建模与细节补偿在结构上解耦,并仅对承担全局建模任务的路径引入结构重参数化,从而在去雾效果与推理效率之间取得平衡。

2.2 大核结构重参化子网

RepLK 由编码器与解码器 2 部分构成,编码器部分支持结构重参化操作。编码器采用 UniRepLKNet-s^[23] 作为主干网络,如图 3 所示,UniRepLKNet-s 的架构包含 4 个层级化特征处理阶段 Stage1-4,其模块组合策略如下:阶段 1 采用 3 个小核模块 (SmaK Block) 堆叠;阶段 2 和阶段 4 各部署 3 个大核模块 (LarK Block);阶段 3 采用混合架构,包含 9 个大核模块与 18 个小核模块的交替组合。其中,大核模块 (LarK Block) 由扩张重参数化模块 (dilated reparam block)、通道注意力机制 (SE Block)、前馈网络 (FFN) 及批归一化层 (BN) 构成;而小核模块 (SmaK Block) 则通过深度可分离 3×3 卷积层替代大核模块中的扩张重参数化模块,形成差异化设计。层级间通过步幅为 2 的标准 3×3 卷积层实现特征图降维,完成跨阶段的层级特征转换。该分层设计通过大感受野建模与局部细节增强的协同作用,优化了网络的多尺度特征提取能力。

本算法的大核结构重参化子网保留 UniRepLKNet-s 的前 3 个阶段 (阶段 1~3) 作为主干编码器,通过裁剪第 4 阶段及全连接层实现结构精简,同时加载 ImageNet 预

训练权重进行迁移学习,使模型在非均匀雾霾数据集不足的情况下仍能有效捕捉复杂雾分布的全局特征。特别值得注意的是,阶段 3 输出的深层特征通过定制化解码器进行多层级特征融合:解码器采用像素重组 (PixelShuffle) 实现特征图上采样,以跳跃连接机制将阶段 2、1 的中间特征以及初始 3×3 卷积层输出的浅层特征进行跨尺度拼接,形成“深层语义引导-中层结构修正-浅层细节增强”的递进式特征优化路径。解码器由上采样模块 (Up-sampling Module)、注意力模块 (Attention Module) 和增强模块 (Enhancing Module) 组成。其中:上采样模块基于像素重组层 (PixelShuffle),通过多通道特征卷积与重组,将低分辨率特征图恢复至高分辨率;注意力模块引入特征注意力机制 (FAM),采用带跳跃连接的双注意力块结构以支持残差学习;增强模块对解码器输出特征进行优化处理,再将其输入融合尾部 (Fusion Tail)。训练阶段,编码器通过扩张重参数化块 (Dilated Reparam Block) 实现多尺度特征提取,而在推理时借助大核结构重参化技术将其转换为等效的大核卷积层,该策略在保持模型性能的同时减少 0.53×10^6 参数量,显著降低推理计算复杂度。

2.3 全分辨率注意力子网

在大核结构重参化子网中,从编码器到解码器的下采样和上采样方法可能会导致图像细节恢复时丢失重要信息。受到文献[24]的启发,本文以 RCAN^[25] 为另一子网的研究基础,并引入了全分辨率注意力子网 (full-resolution attention subnet, FRA)。RCAN 模型在图像超分辨率方面表现出色,这也是本文设计该子网的动机。




图 3 UniRepLKNNet-s 的架构示意

Fig. 3 UniRepLKNNet-s architecture diagram

为了保留去雾图像的复杂细节,全分辨率注意力子网避免使用下采样和上采样技术。如图 4 所示,该子网在头部和尾部分别包含 2 个 3×3 卷积层,并在中间部分设置了 5 个残差通道注意力组(RCAG)。每个 RCAG 由 10 个残差通道注意力块(RCAB)组成。通过采用残差设计和长跳跃连接,该网络能够更有效地避免梯度消失问题^[26]。该子网通过训练得到的细节特征可以被视为大核结构重参化子网的补充。由于全分辨率注意力子网是从零开始训练并专为全分辨率任务构建,因此它能够更好地适应当前数据并提取更加特定的特征。然而,其强大的拟合能力也使其更容易遇到过拟合问题。值得注意的是,本文采用了不同的超参数,以减少该子网的参数量和计算量。通过在原始分辨率尺度上计算通道与空间的注意力权重,该子网能够持续改善局部纹理细节的恢复效果,从而提升整体去雾图像的细节表现。




图 4 全分辨注意力子网图

Fig. 4 Full-resolution attention subnet

2.4 融合尾部

融合尾部(fusion tail)作为一种集成方法,用于生成最终输出。具体而言,融合尾部将两个子网的特征进行拼接,并学习将这些特征映射为清晰的图像。

不同于当前大多数去雾算法^[15,24]常用的融合尾部,这些方法通常采用带有 Tanh 激活函数的卷积层,而在本

研究中,使用了带有 ReLU 激活函数的 7×7 卷积层作为融合尾部(如图 5 所示)。由于 2 个子网络输出的特征已经足够恢复清晰图像,而 ReLU 计算比 Tanh 更简单,并且可以有效避免梯度消失问题,同时实现更好的收敛性能。融合尾部第一层采用 ReflectionPad(反射填充)而非零填充,主要原因在于去雾任务对边界区域的颜色一致性与纹理连续性非常敏感。若使用零填充,在大核卷积(7×7)下容易在图像边缘引入非自然的暗边并放大边界伪影;反射填充通过镜像延拓边界邻域像素,可在保持输出尺寸不变的同时降低边界伪影与条带效应,使去雾结果在全图范围内更平滑一致。因此,Fusion Tail 采用“ReflectionPad + Conv 7×7 + ReLU”的轻量映射结构,以实现两路特征的稳定融合与高质量重建。




图 5 融合尾部(Fusion Tail)结构示意图

Fig. 5 Fusion tail structure diagram

为了进一步证明该融合尾部的有效性,对使用不同激活函数的融合尾部进行了实证分析,如表 1 所示,可以看出,相较于 Tanh,使用 ReLU 作为融合尾部的激活函数进一步提升了性能。

表 1 融合尾部激活函数使用 Tanh 或 ReLU 时的性能表现

Table 1 The performance of the method proposed when the fusion tail activation function uses Tanh or ReLU

融合尾部使用的 激活函数	RESIDE (ITS)		Dense-Haze		NH-Haze 2020		NH-Haze 2021	
	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM
Tanh	32.79	0.979	17.42	0.601	21.47	0.712	22.54	0.856
ReLU	33.97	0.982	17.66	0.612	21.66	0.715	22.74	0.857

在该模块中,使用了带 ReLU 激活函数的 7×7 卷积层作为融合尾部。该设计能够将大核结构重参化子网提取的全局上下文特征与全分辨率注意力子网增强的局部特征有效融合,最终生成去雾后的高质量图像。

3 实验与结果分析

3.1 损失函数

在损失函数的设计上,采用与很多最先进的去雾算法类似的方式,即多任务损失函数联合优化模型,具体包括平滑 L1 损失 (smooth-L1 loss)、感知损失 (perceptual loss)、多尺度结构相似性损失 (MS-SSIM loss)、对抗损失 (adversarial loss)。这里设有雾图像为 J ,去雾后的图像为 K ,参考图像即对应场景的清晰无雾图像为 I 。其中:

1) 平滑 L1 损失:克服了 L1 损失的不稳定性。使用平滑 L1 损失可以使模型更加稳健,在许多图像修复任务中表现良好。平滑 L1 损失可表示为:

$$L_{smooth-L1} = \frac{1}{N} \sum_{n=1}^N smooth_{L1}(K_n - I_n) \tag{1}$$

$$smooth_{L1}(x) = \begin{cases} \frac{1}{2}x^2, & |x| < 1 \\ |x| - \frac{1}{2}, & \text{其他} \end{cases} \tag{2}$$

2) 感知损失:在图像修复任务中,感知损失被广泛用于衡量两幅图像之间的感知差异,并获取更多的细节信息。本文利用感知损失来获取去雾图像 K 与清晰图像 I 之间的高层次感知信息,以优化网络参数。感知损失定义如下:

$$L_{per} = \sum_{i \in S} \frac{1}{C_i H_i W_i} \| \theta_i(K) - \theta_i(I) \|_2^2 \tag{3}$$

式中: θ_i 表示 VGG-16 网络第 i 层的特征图,特征图的尺寸是 $C_i \times H_i \times W_i$, S 为选取的特征层集合。

3) 多尺度结构相似性损失:为了提高图像的视觉质量并保留高频信息,本文在模型训练中采用了多尺度结构相似性损失。多尺度结构相似性 (MS-SSIM) 是结构相似性 (SSIM) 的扩展版本,它通过在多个尺度上计算结构相似性来更全面地评估图像的感知质量。多尺度结构相似性损失通常用于训练图像增强或去雾模型,以使模型生成的图像在多个尺度上更接近清晰图像。不同于感知

损失,多尺度结构相似性损失旨在衡量图像结构在多个尺度上的相似性,使用该损失函数有助于提升模型的去雾性能。

$$L_{MS-SSIM} = 1 - MS-SSIM(I, K) \tag{4}$$

4) 对抗损失:对抗损失在恢复照片级真实感图像方面的有效性已被证明^[27]。特别是在处理小规模数据集时,像素级损失函数往往无法提供足够的监督信号来训练网络以恢复逼真的细节。因此本文选择结合对抗损失,并采用模型 DW-GAN^[15]中提出的判别器。为了展示这一方法的影响,在图 6 中提供了一个可视化表示。该图包括一个去雾后的图像 (Dehazed Image) 和一个真实图像 (Ground Truth),它们都会通过判别器 (Discriminator),生成一个输出,标记为“真实” (Real) 或“伪造” (Fake)。这一过程是计算我们对抗损失的关键部分,其定义如下:

$$L_{adv} = \sum_{n=1}^N -\log D(G(J)) \tag{5}$$

其中, J 代表输入的有雾图像,生成器 G 负责将 J 转换为去雾后的图像 $K=G(J)$,判别器 D 试图区分去雾图像 K 和真实清晰无雾图像 I 。它衡量了判别器对生成图像与真实图像判断之间的差异,并在优化我们的方法以生成照片级真实感结果的过程中发挥关键作用。




图 6 对抗损失函数示意

Fig. 6 Schematic diagram of adversarial loss function

本文提出的去雾网络在训练过程中使用的损失函数由上述四种损失函数组合而成,即:

$$L_{total} = \alpha L_{smooth-L1} + \beta L_{per} + \gamma L_{MS-SSIM} + \delta L_{adv} \tag{6}$$

式中:超参数设置为 $\alpha=1, \beta=0.01, \gamma=0.5, \delta=0.0005$ 。

3.2 实验数据集

为了评估本算法,采用了合成数据集和真实世界数

数据集。合成数据集包括 RESIDE 提供的室内训练集 (ITS) 和合成客观测试集 (SOTS), 训练集由 ITS 中随机选取 1 399 对图像组成, 测试集则从 SOTS 中选取 500 对图像进行测试。真实世界数据集包括 NTIRE2019 的 Dense-Haze、NTIRE2020 的 NH-Haze 2020 以及 NTIRE2021 的 NH-Haze 2021。在 Dense-Haze 和 NH-Haze 2020 数据集上, 采用官方划分的训练集、验证集和测试集进行评估。对于 NH-Haze 2021, 由于官方尚未发布测试集的真实清晰图像, 因此本算法仅使用前 20 对官方训练图像进行训练, 剩余 5 对用于评估。本算法在每个数据集上分别进行实验, 未使用额外数据提升性能。

3.3 实验环境与训练过程

实验在 Ubuntu 22.04 LTS 64 位操作系统下进行, 使用的计算设备配备 Intel Core i5-9600K 处理器、32 GB 内存及 NVIDIA RTX 3090 显卡, 能够满足深度学习模型训练和推理所需的性能需求。算法实现依托于 PyTorch 1.11.0 框架, 该框架支持 GPU 加速, 便于在高性能计算环境下高效完成各项实验流程。在模型训练过程中, 为增强其泛化能力, 实验引入了包括随机裁剪、水平与垂直翻转、以及随机角度旋转在内的数据增强策略。这些操作有助于提升训练样本的多样性, 降低模型对特定雾化模式的依赖。所有输入图像在训练前被随机裁剪为统一尺寸, 以优化显存使用并提高训练稳定性。模型优化采用了 AdamW 优化器^[28], 设置初始学习率为 1×10^{-4} , 并使用较小的权重衰减系数 (1×10^{-8}) 以缓解过拟合现象, 同时促进模型收敛。模型性能的量化评估主要依托 3 个指标: 峰值信噪比 (PSNR)、结构相似性 (SSIM) 与感知图像相似性 (LPIPS), 分别用于从信号质量、结构一致性及人眼视觉角度评估去雾效果的整体表现。

3.4 实验结果与分析

为了验证所提出的双路径结构重参数化去雾网络 RepLKDehaze 的有效性, 本文与如下经典的 9 种去雾算法进行了对比, 包括: DCP^[1]、CAP^[2]、UCL-dehaze^[29]、Dehazeformer^[30]、MB-TaylorFormer^[31]、MB-TaylorFormer V2^[32]、ConvIR-S^[33]、ConvIR-B^[33] 和 Dehaze XL^[34]。其中 DCP 和 CAP 属于基于传统先验知识进行图像复原的去雾算法, UCL-dehaze 为基于 GAN 的方法, Dehazeformer、MB-TaylorFormer 和 MB-TaylorFormer V2 是基于 Transformer 的方法, ConvIR-S 和 ConvIR-B 是基于 CNN 的方法, Dehaze XL 是基于深度学习的方法。本章算法去雾测试分别在合成雾图数据集与真实雾图数据集上进行了实验。

1) 合成雾图数据集去雾测试结果

图 7 展示了多个算法在室内合成图像上的处理结果, 其中“Hazy”表示原始有雾图像, “GT”为其对应的清晰图像, “Ours”为本文提出方法的结果。从图像表现来看, DCP 算法整体上具备一定的去雾能力, 但由于暗通道先验在白色区域中容易失效, 导致第 4 张图中的墙壁区域出现明显的伪影, 同时白色墙体及桌面部分存在细节缺失问题。CAP 方法在轻度与中度雾霾场景下表现尚可, 但对浓雾区域的处理能力有限, 恢复结果整体偏白, 存在一定程度的视觉偏差。Dehaze XL 去雾后仍存在一定程度的雾霾残留, 而 UCL-dehaze、Dehazeformer、MB-TaylorFormer、MB-TaylorFormer V2、ConvIR-S、ConvIR-B 以及本文提出的算法均展现出优秀的去雾能力, 去雾后雾霾残留极少, 仅在第 3 张图像的部分区域略有残留。综合来看, 本文所提出的去雾方法在大多数测试场景中均展现出不差于现有算法的性能, 特别是在颜色还原的准确性及图像细节的保留方面具有明显优势。其去雾结果在整体视觉效果上更为自然, 与参考清晰图像的相似度更高。




图7 各算法在 SOTS 测试集室内图像去雾效果对比

Fig. 7 Comparison of indoor image dehazing effects of various algorithms on the SOTS test set

图 8 展示了各算法在室外合成图像去雾后的效果。DCP 方法在处理过程中出现图像整体偏暗的现象,尤其在天空区域表现较为明显,呈现出明显的偏蓝色调。这主要归因于其暗通道先验在天空等低纹理区域失效,导致对全局大气光和透射率的估计存在误差。CAP 方法整体表现较为稳健,在多数图像中实现了较为有效的雾气消除;然而在某些复杂场景下,仍存在残留雾气及图像暗化的现象,影响了视觉质量。Dehazeformer 与 MB-TaylorFormer 两种方法在大多数情况下均能有效去除图

像中的雾气,但在第 2 张图像中,Dehazeformer 处理后的天空区域云彩颜色偏深,而 MB-TaylorFormer 则出现了云彩过亮的现象,UCL-dehaze 和 ConvIR-S 也出现微小的过曝现象。MB-TaylorFormer V2、Dehaze XL 以及本文提出的去雾算法均展现出良好的去雾效果。测试选取的对比算法是近三年来的图像去雾算法,在视觉感官上可能无法分辨出差异,但是本文提出的去雾算法在颜色还原和细节保留方面依旧保持优势,去雾后的图像在视觉上接近清晰图像。




图 8 各算法在 SOTS 测试集室外图像去雾效果对比

Fig. 8 Comparison of the dehazing effects of various algorithms on outdoor images in the SOTS test set

表 2 展示了各算法在 SOTS 测试集中室内、室外图像去雾后的 PSNR、SSIM 和 LPIPS 评价结果。其中,PSNR 和 SSIM 值越高,表示去雾效果越好,而 LPIPS 值越低,则说明去雾后的图像与清晰图像更接近,表格中加粗项为最优值。DCP 和 CAP 均属于传统先验方法,UCL-dehaze 为基于 GAN 的方法,Dehazeformer、MB-TaylorFormer 和 MB-TaylorFormer V2 是基于 Transformer 的方法,ConvIR-S 和 ConvIR-B 是基于 CNN 的方法,Dehaze XL 是基于深度

学习的方法。在室内数据集上,ConvIR-B 的表现最优,基于 Transformer 的方法和基于 CNN 的方法整体上优于传统先验方法。由表 2 可知本文提出的去雾算法在各项指标上并不全部都是最优的,这种结果是基于 RESIDE 数据集得来的,RESIDE 数据集是人工合成的雾图像,雾分布均匀而且较薄,仅由 RESIDE 数据集测试结果并不能说明本章提出算法的有效性和实用性,本文提出的算法优势在于对密集非均匀雾图像的处理上。

表 2 各算法在 SOTS 测试集中去雾结果

Table 2 Dehazing results of each algorithm in the SOTS test set

模型	SOTS (indoor)			SOTS (outdoor)		
	PSNR ↑ /dB	SSIM ↑	LPIPS ↓	PSNR ↑ /dB	SSIM ↑	LPIPS ↓
DCP	18. 78	0. 865	0. 089	16. 91	0. 867	0. 106
CAP	17. 50	0. 830	0. 096	22. 11	0. 911	0. 045
Dehazeformer	37. 84	0. 994	0. 213	34. 95	0. 984	0. 240
MB-TaylorFormer	36. 85	0. 902	0. 190	29. 79	0. 912	0. 314
UCL-dehaze	34. 73	0. 915	0. 255	25. 21	0. 927	0. 311
ConvIR-S	41. 53	0. 974	0. 014	37. 95	0. 924	0. 034
ConvIR-B	42. 72	0. 981	0. 020	39. 24	0. 990	0. 201
MB-TaylorFormer V2	38. 69	0. 979	0. 015	29. 88	0. 946	0. 295
Dehaze XL	26. 76	0. 944	0. 014	27. 70	0. 959	0. 184
Ours(本文方法)	33. 97	0. 982	0. 012	27. 85	0. 961	0. 021

2) 真实雾图数据集去雾测试结果

不同算法在真实雾图数据集上的去雾效果如图 9、

10 和 11 所示。




图 9 各算法在 Dense-Haze 数据集图像去雾效果对比

Fig. 9 Comparison of image dehazing effects of various algorithms on the Dense-Haze dataset




图 10 各算法在 NH-Haze2020 数据集图像去雾效果对比

Fig. 10 Comparison of image dehazing effects of various algorithms in NH-Haze2020 dataset




图 11 各算法在 NH-Haze2021 数据集图像去雾效果对比

Fig. 11 Comparison of image dehazing effects of various algorithms on the NH-Haze2021 dataset

由于 Dense-Haze 数据集的雾浓度较高,各算法去雾后的图像仍与清晰图像存在一定差距。其中,DCP、CAP 和 Dehaze XL 的去雾效果较为有限,复原图像中仍残留大量雾气,且 DCP 复原的图像整体偏蓝。Dehazeformer 和 MB-TaylorFormer 在去雾过程中丢失了大量颜色信息,使图像整体偏灰。UCL-dehaze 算法复原的图像较不真实,出现了部分白斑,ConvIR-S 和 ConvIR-B 复原的图像虽较为清晰,但仍旧丢失大量颜色信息,MB-TaylorFormer V2 整体偏暗。本文提出的算法在处理浓雾图像时表现出很强的去雾能力,不论是颜色信息还是视觉感受都很符合真实图像。整体而言,本文提出的算法在视觉效果上更接近清晰图像。

NH-Haze 2020 和 NH-Haze 2021 数据集的雾呈现非均匀分布,更符合实际环境。在 NH-Haze 2020 数据集的测试结果中,DCP、CAP 和 Dehaze XL 的去雾能力较弱,复原图像中依然残留大量雾气,且 DCP 仍然输出整体偏蓝的图像。Dehazeformer 在去雾过程中仍有部分白色雾气。MB-TaylorFormer 去雾后整体偏暗,UCL-dehaze 算法复原的图像出现幻觉感并且有红斑。




图 12 本算法与基于 Transformer 算法在 NH-Haze 2021 数据集图像去雾效果对比

Fig. 12 Comparison of the dehazing effect of this algorithm and DW-GAN on the NH-Haze 2021 dataset

进一步评估 RepLKDehaze 算法和其他算法在真实雾图数据集上的性能,如表 3 所示,量化指标进一步印证了视觉分析的结论。RepLKDehaze 在 Dense-Haze 数据集以 17.66 PSNR 和 0.613 SSIM 领先,较 UCL-dehaze (12.49/0.468) 提升 41.3%/14.5%,其 LPIPS 值 0.494 较 UCL-dehaze 降低 9.1%。在 NH-Haze 系列中,算法保持全面优势:2020 数据集 PSNR (21.66) 与 SSIM

ConvIR-S 和 ConvIR-B 复原的图像随较为清晰,但仍旧丢失少许颜色信息,MB-TaylorFormer V2 整体偏红。本文算法的复原效果较好,去雾后的图像整体接近清晰图像。

在 NH-Haze 2021 数据集的测试结果中,DCP 和 CAP 整体偏蓝色,Dehazeformer 在去雾后整体颜色变暗,并且第 3 张图片中有明显雾团没有去掉。MB-TaylorFormer 去雾后整体变亮,UCL-dehaze 算法复原的图像出现明显的曝光现象。ConvIR-S 和 ConvIR-B 复原的图像随较为清晰,但与真实图像比较色彩度仍较低,MB-TaylorFormer V2 和 Dehaze XL 仍旧保留雾团。

进一步与基于 Transformer 类的方法进行比较,如图 12 所示,Dehazeformer 模型去雾后图像中的通道细节显得过暗,而且仍有部分雾未处理干净,整体偏灰暗,色彩度缺失。MB-TaylorForme 算法和 MB-TaylorFormer V2 算法处理后的图像仍有雾,出现较小的曝光,而且色彩度仍是缺少,可能 Transformer 类方法不适合于密集非均匀雾的处理。本文算法生成的结果颜色更接近原始图像,显示区域的细节更清晰,雾团几乎全被去除。

(0.716) 较 MB-TaylorFormer V2 提升 105.7%/32.5%,2021 数据集 LPIPS 值 0.169 为全域最优,较次优模型压缩 2.3%。所有数据验证了算法在物理精度与感知质量间的均衡性突破。在真实数据集上的视觉与量化表现进一步验证了 RepLKDehaze 算法其跨场景鲁棒性,对于真实雾图,尤其是密集非均匀雾的处理效果较优。

表 3 各算法在真实雾图数据集上去雾结果

Table 3 Dehazing results of each algorithm in real foggy image dataset

模型	Dense-Haze			NH-Haze 2020			NH-Haze 2021		
	PSNR ↑/dB	SSIM ↑	LPIPS ↓	PSNR ↑/dB	SSIM ↑	LPIPS ↓	PSNR ↑/dB	SSIM ↑	LPIPS ↓
DCP	10.01	0.412	0.835	12.26	0.452	0.558	11.49	0.637	0.457
CAP	9.89	0.450	0.743	13.02	0.429	0.556	12.64	0.642	0.455
Dehazeformer	16.11	0.517	0.752	18.09	0.727	0.526	17.67	0.819	0.369
MB-TaylorFormer	16.66	0.560	0.348	17.14	0.600	0.377	18.02	0.779	0.298
UCL-dehaze	12.49	0.468	0.585	12.89	0.549	0.479	13.15	0.636	0.481
ConvIR-S	17.45	0.608	0.531	20.65	0.692	0.284	20.94	0.715	0.192
ConvIR-B	16.86	0.600	0.498	20.66	0.691	0.278	21.01	0.758	0.201
MB-TaylorFormer V2	16.95	0.611	0.546	10.53	0.391	0.637	16.69	0.762	0.317
Dehaze XL	15.24	0.554	0.687	18.25	0.599	0.475	17.99	0.694	0.368
Ours (本文方法)	17.66	0.613	0.494	21.66	0.716	0.254	22.74	0.857	0.169

3) 模型参数与去雾时间对比

为验证结构重参数化技术对算法效率的提升效果,本研究在标准化实验环境下 (Intel i5-9600K/RTX 3090/32 GB) 对多类去雾算法进行对比测试。选用分辨率

1 600×1 200 pixel 的图像作为测试样本,采用批量处理 (10 张/次) 方式计算平均单图处理耗时。表 4 详细展示了各模型的性能对比数据,其中 RepLKDehaze (本文方法) 展现出显著优势。

表 4 模型参数与去雾时间对比

Table 4 Comparison of model parameters and defogging time

模型	Dehazeformer	UCL-dehaze	ConvIR	Dehaze XL	Ours (训练)	Ours (推理)
参数量/(×10 ⁶)	25. 4	22. 8	8. 6	125. 4	41. 3	40. 7
推理时间/s	0. 153	0. 091	0. 102	0. 157	0. 105	0. 085

值得注意的是,通过应用大核结构重参数化技术,RepLKDehaze 的参数量从训练阶段的 41.3×10^6 优化至推理阶段的 40.7×10^6 。结合 iGEMM-cutlass 加速框架的部署,其推理时间进一步降低至 0.085 s。实验数据表明,该模型不仅在 PSNR/SSIM 等客观指标上保持优势,同时在实际部署中展现出更优的计算效率,验证了结构重参数化在平衡模型性能与计算开销方面的有效性。

3.5 消融实验

通过消融实验来验证迁移学习 (transfer learning, TL) 以及各子网的作用,主要考察以下 3 个因素:RepLK 是否加载 ImageNet 预训练权重、是否启用 RepLK、是否启用 FRA。实验采用 NH-Haze 2021 数据集,其中前 20 对图像用于训练,剩余 5 对用于测试。表 5 列出了 5 种网络配置及其性能指标:1) RepLK (no TL), 仅使用 RepLK 单分支模型,所有参数随机初始化;2) RepLK (TL), RepLK 单分支模型,加载 ImageNet 预训练权重;3) FRA, 仅使用 FRA 的单分支模型;4) RepLK (no TL) + FRA, 由未加载预训练权重的 RepLK 与 FRA 组成的双分支结构;5) 本文提出的方法 (RepLKDehaze), 将加载了 ImageNet 预训练参数的 RepLK 与 FRA 组合成双分支模型,分为训练与推理两种状态。

从表 5 中结果可以看出,引入 ImageNet 预训练权重后,RepLK 的 PSNR 和 SSIM 均有显著提升。相比之下,FRA 采用随机初始化,在 PSNR 上稍逊于未加载预训练权重的 RepLK (no TL),但在 SSIM 上又优于后者。得益于 UniRepLKNet 架构本身卓越的表征能力,即便只使用加载预训练参数的 RepLK (TL),也能实现相当可观的去雾效果。由于 FRA 参数量仅为 0.999×10^6 ,而 RepLK 达

到 40.3×10^6 ,对网络整体负担极小,因此在进一步优化去雾性能时,合理地引入了 FRA 子网。最终,通过结构重参数化技术,整体模型参数量仅为 40.7×10^6 。

表 5 消融实验模型参数与去雾结果对比

Table 5 Comparison of ablation experiment model parameters and dehazing results

模型方法	PSNR/dB	SSIM	参数量/(×10 ⁶)
RepLK (no TL)	20. 92	0. 822	40. 3
RepLK (TL)	21. 83	0. 848	40. 3
FRA	20. 79	0. 835	1. 0
RepLK (no TL) + FRA	21. 79	0. 839	41. 3
Ours (训练)	22. 74	0. 857	41. 3
Ours (推理)	22. 74	0. 857	40. 7

深入分析可知,UniRepLKNet 通过大核卷积的层级化设计强化了特征提取能力,其动态稀疏权重机制有效平衡了感受野扩展与细节保持之间的矛盾。结合大核结构重参数化技术,使得模型推理速度进一步提升。这一改进使得模型在增强去雾效果的同时,更在推理时间上有了优势。

为进一步验证大核建模在图像去雾任务中的适配性,特别是其在密集非均匀雾场景下的有效性,本文以 NH-Haze 2021 数据集为例,对不同大核使用策略进行了对比实验。实验重点考察大核卷积在不同层级的放置方式对去雾性能的影响,具体包括仅使用小核卷积的结构 (Small-Kernel Only)、在所有编码阶段均引入大核的结构 (Early-Large-Kernel), 以及本文的仅在中深层使用大核的结构配置 (Mid-Depth Large-Kernel), 实验结果如表 6 所示。

表 6 大核结构在去雾任务中的适配性消融实验结果

Table 6 Ablation study on task-specific suitability of large-kernel modeling for image dehazing

方法配置	大核使用位置	主干结构	PSNR/dB	SSIM	LPIPS
Small-Kernel Only	无	全部 DW 3×3	21. 36	0. 812	0. 241
Early-Large-Kernel	Stage1-3	各层 LarK	21. 98	0. 831	0. 212
Mid-Depth Large-Kernel (Ours)	Stage2-3	LarK +SmaK	22. 74	0. 857	0. 169

可以看出,仅采用小核卷积的模型在密集非均匀雾场景中表现出明显不足,其 PSNR、SSIM 及 LPIPS 均落后于引入大核建模的结构。这表明仅依赖局部感受野逐层累积上下文信息,难以稳定刻画非均匀雾在空间上的整体分布特征。当在所有阶段引入大核结构(Early-Large-Kernel)时,模型性能相较 Small-Kernel Only 有所提升,说明大核卷积对捕获全局雾分布具有积极作用。然而,该配置在局部纹理与细节恢复方面并未取得最优结果,推测其原因在于浅层特征对边缘与高频信息较为敏感,过早引入大核建模可能削弱对细节结构的刻画能力。相比之下,本文使用的 Mid-Depth Large-Kernel 结构在 NH-Haze 2021 数据集上取得了最优的综合表现。通过仅在中深层引入大核结构以建模全局雾分布,并在浅层保留小核卷积以稳定提取局部纹理特征,该配置在 PSNR、SSIM 以及 LPIPS 指标上均优于其他对比方案。这一结果表明,大核结构在图像去雾任务中的有效性依赖于合理的层级放置,而非简单地在所有层级使用大核。

4 结 论

本文面向密集非均匀雾霾条件下“全局雾分布难建模、局部细节易受损、部署开销偏高”等实际问题,提出双路径结构重参化去雾网络 RepLKDehaze。方法上,一方面在主干分支中引入 UniRepLKNet 的扩张重参数化思想,使网络在训练阶段以多分支形式增强大感受野表征,并在推理阶段折叠为等效的大核卷积,从而在保持长程依赖建模能力的同时降低冗余计算;另一方面,引入全分辨率注意力分支在原始分辨率上持续强化纹理与边缘细节,用于补偿编解码过程中可能产生的信息损失。双分支特征在融合尾部进行整合,最终实现对全局雾分布与局部细节的协同恢复。在合成数据集与真实雾数据集上验证了方法有效性:在合成数据集上,RepLKDehaze 的指标并非全面最优,但能够保持与主流方法相当的复原质量;更重要的是,在更贴近真实成像退化的 Dense-Haze、NH-Haze 2020 与 NH-Haze 2021 数据集上,RepLKDehaze 在 PSNR/SSIM/LPIPS 等指标上取得领先表现(Dense-Haze 为 17.66 dB/0.613/0.494, NH-Haze 2020 为 21.66 dB/0.716/0.254, NH-Haze 2021 为 22.74 dB/0.857/0.169),表明该双路径结构在真实、密集且非均匀雾分布条件下具有更强的跨场景鲁棒性与感知质量优势。本文从“结构重参化的大核全局建模”与“全分辨率注意力的细节补偿”2个角度,为真实雾场景下的高质量去雾提供了一种更易部署且更稳定的解决思路。后续将进一步扩展对不同传感器、不同光照/曝光条件与跨域数据的系统评测,并探索更轻量的细节分支设计,以进一步提升边缘部署的适配性。

参考文献

- [1] HE K, SUN J, TANG X. Single image haze removal using dark channel prior [C]. Proceedings of the 2009 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Miami, USA, 20-25 June 2009: 1956-1963. DOI: 10.1109/CVPR.2009.5206515.
- [2] ZHU Q, MAI J, SHAO L. A fast single image haze removal algorithm using color attenuation prior [J]. IEEE Transactions on Image Processing, 2015, 24(11): 3522-3533.
- [3] BERMAN D, AVIDAN S. Non-local image dehazing [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Las Vegas, USA, IEEE, 2016: 1674-1682.
- [4] ZHAO S, ZHANG L, SHEN Y, ZHOU Y. RefinedNet: A weakly supervised refinement framework for single image dehazing [J]. IEEE Transactions on Image Processing, 2021, 30: 3391-3404.
- [5] 郑凤仙,王夏黎,何丹丹,等. 单幅图像去雾算法研究综述[J]. 计算机工程与应用, 2022, 58(3): 1-14.
ZHENG F X, WANG X L, HE D D, et al. A survey on single image dehazing algorithms [J]. Computer Engineering and Applications, 2022, 58(3): 1-14.
- [6] CAI B, XU X, JIA K, et al. DehazeNet: An end-to-end system for single image haze removal [J]. IEEE Transactions on Image Processing, 2016, 25(11): 5187-5198.
- [7] LI B, PENG X, WANG Z, et al. Aod-net: All-in-one dehazing network [C]. IEEE International Conference on Computer Vision (ICCV), Venice, Italy, 2017: 4780-4788.
- [8] ZHANG H, PATEL V M. Densely connected pyramid dehazing network [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Salt Lake City, UT, USA, 2018: 3194-3203.
- [9] LIU X, MA Y, SHI Z, et al. GridDehazeNet: Attention-based multi-scale network for image dehazing [C]. 2019 IEEE/CVF International Conference on Computer Vision (ICCV), Seoul, Korea (South), 2019: 7314-7323.
- [10] QIN X, WANG Z, BAI Y, et al. FFA-Net: Feature fusion attention network for single image dehazing [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 11908-11915.
- [11] DONG H, PAN J, XIANG L, et al. Multi-scale boosted dehazing network with dense feature fusion [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern

- Recognition (CVPR), Seattle, WA, USA, 2020: 2157-2167.
- [12] QU Y, CHEN Y, HUANG J, et al. Enhanced pix2pix dehazing network [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, Long Beach, CA, USA, 2019: 8152-8160.
- [13] CHEN D, HE M, FAN Q, et al. Gated context aggregation network for image dehazing and deraining [C]. Proceedings of the 2019 IEEE Winter Conference on Applications of Computer Vision (WACV), Waikoloa, HI, USA, 2019: 1375-1383.
- [14] LIU J, WU H, XIE Y, et al. Trident dehazing network [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, Seattle, WA, USA, 2020: 1732-1741.
- [15] FU M, LIU H, YU Y, et al. Dw-gan: A discrete wavelet transform gan for nonhomogeneous dehazing [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, Nashville, TN, USA, 2021: 203-212.
- [16] DING X, ZHANG X, MA N, et al. Repvgg: Making vgg-style convnets great again [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, Nashville, TN, USA, 2021: 13728-13737.
- [17] LUO X, ZHONG H, LU J, et al. RepDehazeNet: Dual subnets image dehazing network based on structural reparameterization [J]. Computers & Graphics, 2024, 118: 71-79.
- [18] LI B, REN W, FU D, et al. Benchmarking single-image dehazing and beyond [J]. IEEE Transactions on Image Processing, 2019, 28(1): 492-505.
- [19] WU R, DUAN Z, GUO C, et al. RIDCP: Revitalizing real image dehazing via high-quality codebook priors [EB/OL]. (2023-04-08) <https://doi.org/10.48550/arXiv.2304.03994>.
- [20] ZAMIR S W, ARORA A, KHAN S, et al. Restormer: Efficient transformer for high-resolution image restoration [EB/OL]. (2021-09-18) <https://doi.org/10.48550/arXiv.2111.09881>.
- [21] GUO C, YAN Q, ZHANG B, et al. Image dehazing transformer with transmission-aware 3D position embedding [C]. 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), New Orleans, LA, USA, 2022: 5812-5820.
- [22] SONG Y, HE Z, QIAN H, et al. Vision transformers for single image dehazing [J]. IEEE Transactions on Image Processing, 2023, 32: 1927-1941.
- [23] DING X, ZHANG Y, GE Y, et al. Unireplknet: A universal perception large-kernel convnet for audio video point cloud time-series and image recognition [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024.
- [24] YU Y, LIU H, FU M, et al. A two-branch neural network for non-homogeneous dehazing via ensemble learning [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, Nashville, TN, USA, 2021: 193-202.
- [25] ZHANG Y, LI K, LI K, et al. Image super-resolution using very deep residual channel attention networks [C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018.
- [26] PASCANU R, MIKOLOV T, BENGIO Y. On the difficulty of training recurrent neural networks [C]. Proceedings of the International Conference on Machine Learning, 2013. PMLR.
- [27] LEDIG C, THEIS L, HUSZÁR F, et al. Photo-realistic single image super-resolution using a generative adversarial network [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017.
- [28] LOSHCHILOV I, HUTTER F. Decoupled weight decay regularization [C]. Proceedings of the 7th International Conference on Learning Representations (ICLR 2019), New Orleans, USA, 2019.
- [29] WANG Y Z, YAN X F, WANG F L, et al. UCL-Dehaze: Toward real-world image dehazing via unsupervised contrastive learning [J]. IEEE Transactions on Image Processing, 2024, 33: 1361-1374.
- [30] SONG Y, HE Z, QIAN H, et al. Vision transformers for single image Dehazing [J]. IEEE Transactions on Image Processing, 2023, 32: 1927-1941.
- [31] QIU Y, ZHANG K, WANG C, et al. MB-TaylorFormer: Multi-branch efficient transformer expanded by taylor formula for image dehazing [C]. 2023 IEEE/CVF International Conference on Computer Vision (ICCV), Paris, France, 2023.
- [32] JIN Z, QIU Y, ZHANG K, et al. MB-TaylorFormer V2: Improved multi-branch linear transformer expanded by taylor formula for image restoration [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2025, 47: 5990-6005.
- [33] CUI Y, REN W, CAO X, et al. Revitalizing convolutional network for image restoration [J]. IEEE

Transactions on Pattern Analysis and Machine Intelligence, 2024, 46: 9423-9438.

[34] CHEN J, YAN X, XU Q, et al. Tokenize image patches: Global context fusion for effective haze removal in large images[C]. 2025 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), Nashville, TN, USA, 2025.

作者简介



郭嘉城, 2025 年于中国人民公安大学获得学士学位, 现为中国人民公安大学硕士研究生, 主要从事图像处理、视觉侦察等方面的研究。

E-mail: 1550721612@ qq. com

Guo Jiacheng received his B. Sc. degree

from the People’s Public Security University of China in 2025. He is currently a M. Sc. student at the People’s Public Security University of China, mainly engaged in research in image processing and visual detection.



罗晓忠, 2025 年于中国人民公安大学获得硕士学位, 主要从事图像处理等方面的研究。

E-mail: repdehazenet@ outlook. com

Luo Xiaozhong received his M. Sc.

degree from the Chinese People’s Public Security University in 2025. His research focuses on image processing.



钟寒(通信作者), 博士, 副教授, 硕士生导师, 2015 年于北京工业大学获得博士学位, 主要从事网络安全、数据分析、图像处理等方面的研究。

E-mail: zhonghan@ ppsuc. edu. cn

Zhong Han (Corresponding author)

Ph. D. , associate professor, M. Sc. supervisor, received her Ph. D. from Beijing University of Technology in 2015. She is mainly engaged in research in network security, data analysis and image processing.