

面向航拍图像去雾的高效模型研究



杨易乾, 孙维超

哈尔滨工业大学, 黑龙江 哈尔滨 150001

摘要: 图像去雾技术致力于从受雾影响的图像中恢复出清晰的无雾图像。由于大气条件的影响, 航拍图像经常遭受雾气干扰, 导致图像退化。现有的深度学习方法在处理有雾航拍图像时, 往往难以充分应对航拍图像中广泛的场景和丰富的细节。为应对这一挑战, 本文开发了一种适用于航拍图像的高效去雾模型。该模型包括细节增强模块和雾气自适应模块两个关键组件。细节增强模块采用多分支结构增强模型对图像细节特征的捕捉能力, 并通过重参数化技术简化了推理过程。雾气自适应模块则利用局部和全局注意力机制, 灵活处理图像中不均匀分布的雾气, 以实现更良好的去雾效果。经试验验证, 本文所提出的模型在去雾性能上表现出色, 并且具有很高的运行效率。研究成果不仅为航拍图像去雾领域提供了一种快速且高效的解决方案, 而且对于推动后续相关算法在航拍图像上的应用具有重要意义。

关键词: 图像去雾; 航拍图像; 深度学习; 图像恢复; 计算机视觉

中图分类号: TP391.4

文献标识码: A

DOI: 10.19452/j.issn1007-5453.2025.06.011

航空飞行器凭借其广阔的视野、多变的拍摄角度以及丰富的应用场景, 在遥感测绘、地面目标探测和环境监测等领域扮演着举足轻重的角色^[1]。作为飞行器获取信息的核心途径, 航拍图像具有重要的应用和研究价值^[2]。然而, 在高空拍摄过程中, 航拍图像的质量常常受到天气和光照条件的显著影响。大气中的颗粒物和云雾会干扰光学成像, 导致航拍图像对比度下降、色调偏移以及细节模糊。云雾的遮挡不仅使得图像中的信息难以被准确提取, 而且容易对后续的视觉处理任务(如图像分类、检测和分割)造成不利影响。考虑到航拍图像通常覆盖大量大小不一、细节丰富的区域, 普通场景设计下的去雾算法在保留这些细节方面可能存在不足。此外, 在航空领域, 机载设备面临着物理和硬件上对计算资源与存储资源的限制。因此, 必须确保所采用的算法具备少量的资源占用和高效的快速响应能力, 以满足实时处理的需求。

近年来, 深度学习架构的进步推动了图像增强领域的研究, 不少先进的去雾算法不断涌现^[3]。早期去雾工作集中于应用大气散射模型^[4], 即直接利用神经网络估计全球大气光照值和透射率, 然后应用大气散射模型实现图像去雾。DehazeNet^[5]直接估计有雾图像的透射率, 随后使用大

气散射模型实现清晰图像的重构。使用多尺度卷积神经网络(MSCNN)^[6]以从粗到细的方式估计透射图, 提高图像的去雾效果。然而大气散射模型在预测参数时容易累积误差, 易导致最终去雾效果不彻底。针对上述问题, 研究人员提出利用卷积神经网络(CNN)强大的非线性建模能力直接在像素域建立有雾图像与清晰图像之间的端到端映射关系。该方法实现简单, 通常不需要对图像的退化过程进行复杂的物理建模, 而且可以取得很好的性能。多尺度增强去雾网络(MSBDN)^[7]能够提取不同尺度下的特征信息。特征融合注意力网络(FFA-Net)基于多尺度结构的去雾网络^[8], 通过采用注意力机制将不同像素的信息进行特征融合, 使得恢复的无雾图像更为清晰。此外, DehazeFormer^[9]引入视觉变换器(ViT)通过捕捉图像中的长距离依赖关系实现更佳的去雾效果。然而ViT通常计算要求较高, 结构比CNN复杂, 因此, 不适合部署在航空飞行器等计算资源有限的设备。尽管图像去雾领域取得了显著进展, 但当这些技术应用在航拍图像上时, 仍然面临一些挑战和不足。如图1所示, 峰值信噪比(PSNR)和结构相似性指数(SSIM)用于衡量去雾效果, 每秒处理帧数(FPS)、推理时间和参数量则用于衡量去雾效率。其中, PSNR和SSIM值越大, 表

收稿日期: 2024-11-06; 退修日期: 2025-01-23; 录用日期: 2025-03-21

基金项目: 航空科学基金(2023Z071077008)

引用格式: Yang Yiqian, Sun Weichao. Research on an efficient model for dehazing in aerial images[J]. Aeronautical Science & Technology, 2025, 36(6): 98-104. 杨易乾, 孙维超. 面向航拍图像去雾的高效模型研究[J]. 航空科学技术, 2025, 36(6): 98-104.

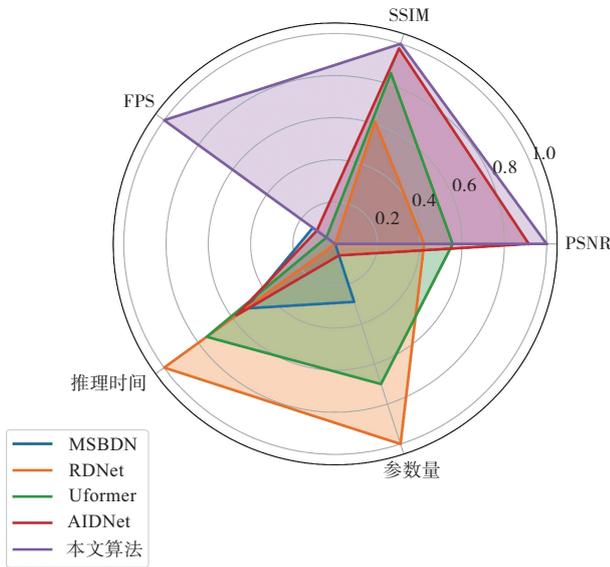


图1 现有去雾算法的性能对比

Fig.1 Performance comparison existing dehazing algorithms

明去雾效果越好；FPS 越高、推理时间越短，表明处理速度越快；参数量越小，表明模型复杂度越低。现有的去雾算法在去雾性能与算法实时性之间难以实现兼顾。一方面，这些算法在处理航拍图像时可能会造成图像细节的丢失；另一方面，它们的运行过程较为复杂，难以在较短时间内完成，从而影响了其在实际应用中的实时性表现。因此，设计专门针对航拍图像的去雾算法，旨在平衡处理速度与去雾效果的质量，以增强其实用性，对于航空摄影任务的成功有着重要的现实意义。

针对航拍图像的去雾任务，本文提出了一种融合细节增强模块和雾气自适应模块的高效去雾模型，实现了较好的去雾效果。为增强模型对特征细节的处理能力，特别设计一个细节增强模块。该模块利用多分支结构来捕捉图像中的微小变化和细节，这对于航拍图像的去雾至关重要

要，因为航拍图像通常包含大量的细节信息，如地形特征、建筑物轮廓等。为了提高模型的推理效率，采用重参数化技术进行优化，旨在加快模型的推理速度，使其更适合实时去雾应用。针对雾气不均匀分布的状况，本文提出了一种雾气自适应模块。该模块通过从全局和局部双重角度细化网络的关注点，丰富特征表达，以强化重要信息并提高去雾算法的性能。

1 高效去雾模型

1.1 整体结构

如图2所示，本文提出的去雾网络由编码器和解码器两部分组成。在编码器中采用细节增强模块和雾气自适应模块作为基本构建块，以增强网络特征提取的能力。模型的编码器部分首先将输入图像的通道数映射为32，然后通过设置步长为2的标准卷积层逐步减小特征图的空间分辨率，同时将通道数翻倍。在解码器部分，上采样操作由转置卷积层和修正线性单元(ReLU)激活函数组成，以恢复图像的空间分辨率并增强细节。本文使用平滑L1损失、多尺度结构相似性损失和感知损失的联合来最小化模型输出与真实值之间的差异，以迫使网络收敛。

1.2 细节增强模块

在去雾过程中，细节信息的保留对于最终得到的图像质量至关重要，因为雾天条件下图像往往缺乏清晰的细节和纹理特征。去雾模型通常依赖一系列 3×3 的标准卷积操作来提取特征。然而，标准的卷积操作往往难以捕捉并强化图像中的细节信息，这可能导致去雾处理后的图像细节受损^[10]。为解决该问题，部分研究^[11]将边缘先验嵌入设计的去雾模型来帮助恢复更清晰的细节特征。受此启发，本文对普通卷积层进行改进，构建了细节增强模块，如图3所示，旨在精确捕捉图像中的轮廓及其

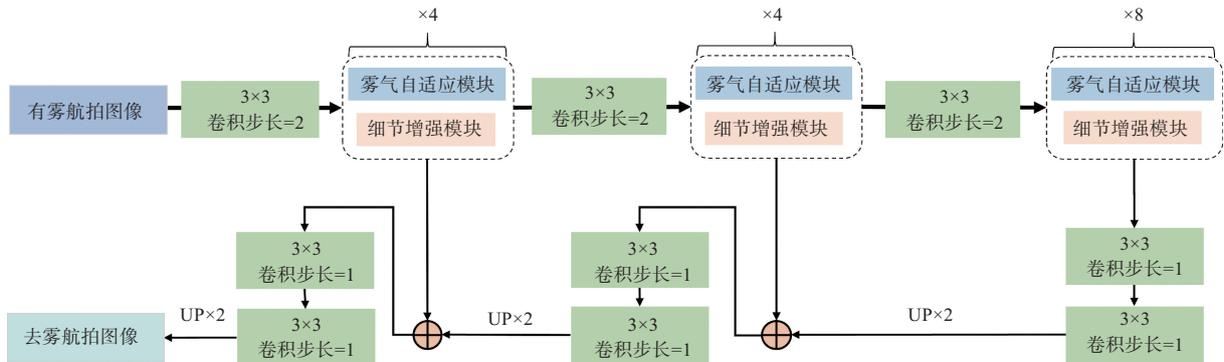


图2 本文提出的方法框架

Fig.2 Framework of this paper proposed method

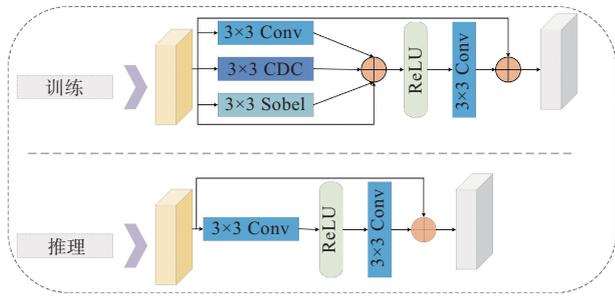


图3 细节增强模块结构图

Fig.3 Structure of detail enhancement module

他细节信息。

细节增强模块为多分支拓扑结构。细节增强模块借鉴中心差分卷积^[12]的理念,编码以中心为基准的梯度信息;并通过索贝尔(Sobel)算子来突出特征的高频区域,从而提取边缘特征。多分支结构将标准卷积提取的特征与上述细节特征进行整合。在训练完成后,利用重参数化技术可将多分支结构合并为标准的 3×3 卷积^[13],以此在保证去雾效果的同时,保持网络的高效运行。

具体地,当模型处于训练阶段时,细节增强模块包含4个并行分支。第1个分支为标准的 3×3 卷积操作,旨在提取基本特征。第2个分支是中心差分卷积(CDC),它专门用于捕捉图像中的高频信息,如边缘和轮廓。CDC通过计算中心像素与其周围像素的差异来增强边缘特征,这对于去雾任务中恢复细节至关重要。第3个分支由Sobel算子组成。Sobel算子属于经典的边缘检测算子之一,它通过计算特征的空间梯度来突出细节信息。第4个分支为残差分支,通过直接传递输入特征,可以保留原始输入中的有用信息,避免在特征提取过程中丢失重要细节。这4个并行分支的输出将被合并相加,并通过ReLU激活函数以及一个标准 3×3 卷积操作引入非线性特性,提高模型的收敛速度,使得网络能够捕捉更复杂的特征。通过这种方式,细节增强模块能够在训练阶段显式地提取和增强细节信息,从而提高模型性能。

虽然细节增强模块使用多分支结构细化了特征表达,但是部署4个并行分支进行特征提取不可避免地导致参数数量和推理时间的增加。根据重参数化技术RepVGG,本文依据卷积层的可加性来简化并行卷积分支,将其整合为单个卷积层。正如RepVGG所述,假设存在若干个尺寸相同的二维卷积核,当它们应用于同一输入数据,且采用一致的步幅和边界填充策略时,每个核独立产生的输出可以通过累加合并,从而形成单一的输出结果。基于这一性

质,本文将这些卷积核在相应位置上的权重进行累加,从而构建一个新的等效卷积核。这个等效核在应用于原始输入时,能够复现与原先多个核合并输出相同的结果。具体地,当模型进行推理时,细节增强模块先将各分支卷积层都转换为标准的 3×3 卷积层。第2个分支的中心差分卷积可通过加法交换性质转为标准卷积层,第3个分支中Sobel算子为深度卷积操作,可看作除对应通道其余通道对应卷积核权重为0的标准卷积。而第4个残差分支可以被视为卷积核大小为1的逐点卷积操作,因而可以通过零填充操作将其转换为 3×3 卷积核。重参数化过程如下所示

$$F_{\text{out}} = \sum_{i=1}^4 F * K_i = F * \sum_{i=1}^4 K_i = F * K_c \quad (1)$$

式中, F 为输入特征; $K_i, i=1,2,3,4$ 为各分支对应卷积核权重; K_c 为重参数化后的卷积核权重; F_{out} 为输出特征;*代表卷积操作。通过以上操作,各个分支被整合为一个标准卷积层,在推理阶段加速模型运行速度而不引入额外的计算成本和内存负担。

1.3 雾气自适应模块

在图像去雾任务中,由于雾气的不均匀分布,普通卷积操作往往难以妥善地应对不同的状况。因此,本文提出了雾气自适应模块。它通过结合两种不同类型的注意力机制来提高去雾算法的性能。

如图4所示,雾气自适应模块由两条支路构成。一条支路为全局注意力支路,使用全局平均池化(GAP)和全局最大池化(GMP)来捕捉整个特征图的全局信息,这有助于模型理解图像的整体特征,包括雾的总体分布情况。继而通过全连接层自适应处理全局信息,生成反映各通道重要性的全局注意力权重。另一条支路为局部注意力支路。首先采用逐点卷积对特征图进行压缩,这有助于模型在局部区域内整合信息,捕捉到图像中的局部纹理信息,获得更综合的局部特征表示。而后通过多尺度深度卷积动态调整网络的关注区域。多尺度结构使模型能够在空间上细化其关注焦点,帮助其更精确地识别和处理图像中的局部变化,如不同区域雾气的浓淡差异。雾气自适应模块的数学表达式为

$$\begin{aligned} F_c &= \sigma(\text{MLP}[\text{GMP}(F), \text{GAP}(F)]) \\ F_s &= \sigma(\text{DW}_{5 \times 5}(C_{1 \times 1}(F)) + \text{DW}_{7 \times 7}(C_{1 \times 1}(F))) \\ F_{\text{out}} &= C_{1 \times 1}(F_s + F_c) \end{aligned} \quad (2)$$

式中, F 为输入特征,GMP和GAP分别为全局最大池化和全局平均池化,MLP为全连接层, σ 为Sigmoid函数,[]为通道拼接操作, $C_{1 \times 1}$ 为卷积核大小为1的逐点卷积, $\text{DW}_{7 \times 7}$ 为

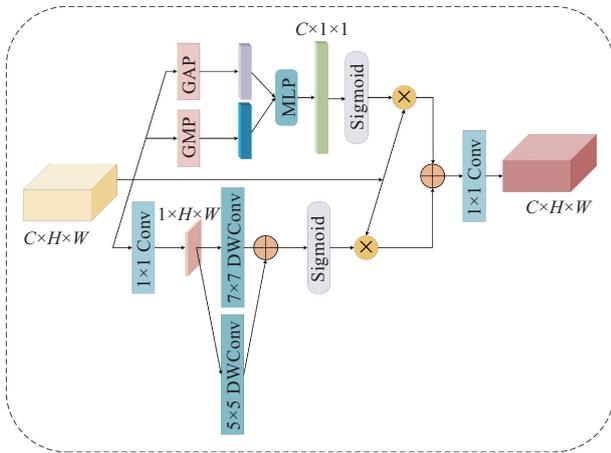


图4 雾气自适应模块结构图

Fig.4 Structure of haze adaptation module

卷积核大小为7的深度卷积, DW_{5x5}为卷积核大小为5的深度卷积。

全局注意力可以帮助模型理解整个图像的雾气分布, 而局部注意力则可以识别和处理图像中雾气浓淡不一的区域。二者结合使得特征表达更加丰富和有区分度, 促使模型能够同时考虑图像的整体和局部特征, 提高了模型对不同雾气分布情况的适应性, 使其能够在多变的环境条件下稳定工作, 从而提高去雾的精度和效果。

2 试验与分析

2.1 试验设置、数据集与评估指标

试验使用 NVIDIA RTX 3090 图形处理器, 在 PyTorch 深度学习框架下训练所提出的模型。在训练期间, 试验使用自适应矩估计优化器(Adam), 初始学习率设为 0.001, 并采用余弦退火策略进行调整。同时, 原始图像被随机裁剪为 256x256 大小, 并使用随机旋转和随机翻转等手段进行数据增强。

为了评估所提出模型的性能, 本文采用了两个公开的航拍图像数据集: Sate-1K 数据集^[14]和遥感图像云去除数据集(RICE)^[15]。Sate-1K 数据集包含了不同云雾密度级别(包括薄雾、中等雾和浓雾)的清晰与朦胧航拍图像对, 图像中的退化效果模拟了实际航拍图像中常见的非均匀云雾情况。每种云雾密度级别下, 320 对图像被挑选以进行训练, 45 对图像被挑选以进行测试。RICE 数据集则包含多种地球表面特征(如城市景观、海洋、沙漠、山脉等)的有雾航拍图像。这些退化图像模拟了航拍图像可能遇到的均匀云雾现象。在该数据集上, 400 对图像被挑选以进行模型训练, 100 对图像被选取用于测试, 以全面评估模型在处理不同类

型云雾图像时的性能。

为了全面评估算法的性能, 本文选用在图像质量评估领域广泛认可的经典指标, 即峰值信噪比(PSNR)和结构相似性指数(SSIM)来评估模型去雾性能。这两个指标与去雾性能呈正相关, 能够有效评估模型去雾处理后输出图像的质量以及保真度。

2.2 定性分析与定量分析

为了直观地展示本文所提出模型的去雾效果, 在数据集中挑选了一系列图像样本进行可视化, 结果如图 5 所示。可以发现, 所提模型有效实现了航拍图像的去雾, 同时在主观视觉上(如颜色、饱和度和清晰度方面)非常接近清晰图像。本文算法与其他先进算法在航拍有雾图像上的客观评价指标对比结果见表 1 和表 2, 其中粗体数值表示最佳结果。可以发现, 在两个数据集上, 本文算法的 PSNR 与 SSIM 指标优于其他算法。这些结果充分证明了本文所提模型在去雾性能方面的优越性。



图5 本文所提模型的去雾结果可视化图像

Fig.5 The visualization of the dehazing results of the proposed model

表1 不同算法在 Sate-1K 数据集上的对比表现

Table 1 Comparison between different algorithms on the State-1K dataset

方法	薄雾		中等雾		浓雾	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
DCP ^[16]	13.15	0.7246	9.78	0.5735	10.25	0.5850
DehazeNet	19.75	0.8950	18.12	0.8552	14.33	0.7064
UFormer ^[17]	25.79	0.9270	26.11	0.9308	25.15	0.9017
AECR ^[18]	22.91	0.8778	24.04	0.8794	20.61	0.8122
SkyGAN ^[19]	25.38	0.9248	25.58	0.9035	23.43	0.8925
本文算法	26.57	0.9351	26.28	0.9459	25.91	0.9314

2.3 复杂度分析

对航空任务而言, 具备较低的计算复杂性和较快的推理速度是必要的。试验选取参数量、浮点运算次数、每秒处

表2 不同算法在RICE数据集上的对比表现

Table 2 Comparison between different algorithms on the RICE Dataset

方法	PSNR	SSIM
MSBDN	24.58	0.8341
RDNet ^[20]	28.81	0.9193
UFormer	30.17	0.9531
SPA-GAN ^[21]	30.23	0.9540
AIDNet ^[22]	33.79	0.9703
TSDNet ^[23]	29.07	0.9274
本文算法	34.64	0.9736

理帧数以及单张图像处理时间作为衡量模型复杂度的关键指标。其中参数量、浮点运算次数和处理时间的值越小，FPS值越大，则模型复杂度越小，处理速度越快。为充分验证算法的实时性能，选用实验室现有的低算力平台NVIDIA GTX 1080Ti进行算法部署。GTX 1080Ti是英伟达推出的一款并行计算平台，该平台支持广泛的AI框架，非常适合算法的部署与验证，有助于展示提出算法的实际应用潜力。本文所提模型保持了较少的参数量和浮点运算次数，同时实现了最快的运行速度，见表3。

表3 不同算法模型复杂度对比

Table 3 Comparison between different algorithms for complexity

方法	参数量/MB	FLOPs/GB	FPS/ (帧/s)	推理时间/ (ms/张)
MSBDN	31.35	83	14.2	70.29
RDNet	65.13	154	8.4	118.54
UFormer	50.88	89	10.6	94.55
AIDNet	20.32	98	13.5	74.12
本文算法	17.58	30	51.2	19.54

2.4 消融试验

为了验证所提出的细节增强模块和雾气自适应模块的有效性，在RICE数据集上进行了系列的消融试验。在这些试验中，细节增强模块和雾气自适应模块分别被从模型中移除，随后对网络的剩余部分进行训练。表4的试验结果表明，在移除这些关键模块后，模型的性能有所下降。这一发现体现了这两个模块在提升模型去雾性能中的重要性。

3 结束语

针对航拍图像去雾问题，本文开发了一种高效的去雾

表4 消融试验

Table 4 Ablation experiments

方法	PSNR
移除细节增强模块	32.86
移除雾气自适应模块	32.47
本文算法	34.64

模型，该模型集成了细节增强模块和雾气自适应模块。细节增强模块通过将细节信息显式地融入标准卷积层，提升了模型的特征表达能力和泛化能力。利用重新参数化技术，该模块能够无损转换为标准卷积结构，从而避免了额外的参数和计算开销，优化了模型的运行效率。雾气自适应模块则采用注意力机制，整合了从全局到局部不同尺度的特征，实现了对雾气浓度的自适应处理。在两个公开的航拍图像数据集上的定量和定性分析，验证了本文提出模型在图像去雾方面的有效性。模型在性能提升和控制模型复杂度方面达到了良好的均衡，为航拍图像的后续处理和应用提供了坚实的基础。

AST

参考文献

- [1] 董凤禹,魏振忠. 面向空中小目标检测任务的YOLOV7改进模型[J]. 航空科学技术, 2023, 34(12): 111-117.
Dong Fengyu, Wei Zhenzhong. Improved YOLOV7 model for small target detection in the air[J]. Aeronautical Science & Technology, 2023, 34(12): 111-117. (in Chinese)
- [2] 王思宇,卢瑞涛,黄攀,等. 基于Swin Transformer和注意力机制的红外无人机检测算法[J]. 航空科学技术, 2024, 35(2): 39-46.
Wang Siyu, Lu Ruitao, Huang Pan, et al. Infrared UAV detection algorithm based on Swin Transformer and attention mechanism[J]. Aeronautical Science & Technology, 2024, 35(2): 39-46. (in Chinese)
- [3] Lee G Y, Chen J, Dam T, et al. Dehazing remote sensing and UAV imagery: A review of deep learning, prior-based, and hybrid approaches[J]. 10.48550/arXiv.2405.07520, 2024.
- [4] Cantor A. Optics of the atmosphere: scattering by molecules and particles[J]. IEEE Journal of Quantum Electronics, 1978, 14(9): 698-699.
- [5] Cai Bolun, Xu Xiangmin, Jia Kui, et al. DehazeNet: an end-to-end system for single image haze removal[J]. IEEE Transactions on Image Processing, 2016, 25(11): 5187-5198.

- [6] Ren Wenqi, Liu Si, Zhang Hua, et al. Single image dehazing via multi-scale convolutional neural networks[C]. Computer Vision ECCV 2016: 14th European Conference, 2016:154-169.
- [7] Dong Hang, Pan Jinshan, Xiang Lei, et al. Multi-scale boosted dehazing network with dense feature fusion[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 2157-2167.
- [8] Qin Xu, Wang Zhilin, Bai Yuanchao, et al. FFA-Net: feature fusion attention network for single image dehazing[C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2020.
- [9] Song Yuda, He Zhuqing, Qian Hui, et al. Vision transformers for single image dehazing[J]. IEEE Transactions on Image Processing, 2023, 32: 1927-1941.
- [10] Bai Haoran, Pan Jinshan, Xiang Xinguang, et al. Self-guided image dehazing using progressive feature fusion[J]. IEEE Transactions on Image Processing, 2022, 31: 1217-1229.
- [11] Zhang He, Patel Vishal M. Densely connected pyramid dehazing network[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 3194-3203.
- [12] Yu Zitong, Zhao Chenxu, Wang Zezheng, et al. Searching central difference convolutional networks for face anti-spoofing [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020: 5295-5305.
- [13] Ding Xiaohan, Zhang Xiangyu, Ma Ningning, et al. Repvgg: making vgg-style convnets great again[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13733-13742.
- [14] Huang Binghui, Zhi Li, Yang Chao, et al. Single satellite optical imagery dehazing using SAR image prior based on conditional generative adversarial networks[C]// Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision, 2020: 1806-1813.
- [15] Lin Daoyu, Xu Guangluan, Wang Xiaoke, et al. A remote sensing image dataset for cloud removal[J]. arXiv preprint Computer Vision and Pattern Recognition, 2019.
- [16] He Kaiming, Sun Jian, Tang Xiaoou. Single image haze removal using dark channel prior[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2010, 33(12): 2341-2353.
- [17] Wang Zhendong, Cun Xiaodong, Bao Jianmin, et al. Uformer: a general U-shaped transformer for image restoration[C].2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2022: 17662-17672.
- [18] Wu Haiyan, Qu Yanyun, Lin Shaohui, et al. Contrastive learning for compact single image dehazing[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 10551-10560.
- [19] Mehta A, Sinha H, Mandal M, et al. Domain-aware unsupervised hyperspectral reconstruction for aerial image dehazing[C]//Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision. IEEE/CVF, 2021: 413-422.
- [20] Zhao Shiyu, Zhang Lin, Shen Ying, et al. RefineDNet: a weakly supervised refinement framework for single image dehazing[J]. IEEE Transactions on Image Processing, 2021, 30: 3391-3404.
- [21] Pan Heng. Cloud removal for remote sensing imagery via spatial attention generative adversarial network[J]. 10.48550/arXiv.2009.13015,2020.
- [22] Kulkarni A, Murala S. Aerial image dehazing with attentive deformable transformers[C]. 2023 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV), 2023:6294-603.
- [23] Liu Yan Wen, Guo Yu, Lu Yuxu, et al. Deep network-enabled haze visibility enhancement for visual IoT-driven intelligent transportation systems[J]. IEEE Transactions on Industrial Informatics, 2022, 19(2): 1581-1591.

Research on an Efficient Model for Dehazing in Aerial Images

Yang Yiqian, Sun Weichao

Harbin Institute of Technology, Harbin 150001, China

Abstract: Image dehazing technology is dedicated to recovering clear haze-free images from those affected by haze. Due to the influence of atmospheric conditions, aerial images are often subjected to haze interference, which degrades image quality. Existing deep learning approaches often fall short in addressing the vast scenes and intricate details found in aerial images. To tackle this challenge, an efficient dehazing model suitable for aerial images has been developed. This model comprises two key components: a detail enhancement module and a haze adaptation module. The detail enhancement module employs a multi-branch structure to enhance the network's ability to capture detail features and simplifies the inference process through the reparameterization technique. The haze adaptation module, on the other hand, utilizes local and global attention mechanisms to flexibly handle unevenly distributed haze in the image, achieving better dehazing effects. Experimental validation has demonstrated that the proposed model excels in dehazing performance and possesses high operational efficiency. The research outcomes not only provide a fast and efficient solution for the field of aerial image dehazing but also hold significant implications for promoting the application of subsequent related algorithms on aerial images.

Key Words: image dehazing; aerial images; deep learning; image restoration; computer vision

Received: 2024-11-06; **Revised:** 2025-01-23; **Accepted:** 2025-03-21

Foundation item: Aeronautical Science Foundation of China (2023Z071077008)