

基于注意力机制的多特征图像去雾算法

王思洪

(湖南师范大学 信息科学与工程学院, 湖南 长沙 410081)

摘要: 在场景深度变化显著且雾霾浓度分布不均的环境中,传统深度学习去雾算法往往难以精确评估图像深度,导致远处物体去雾效果不佳以及近处物体细节损失。为此,提出一种基于注意力机制的多特征图像去雾算法,通过引用多种注意力机制关注图像不同特征区域,达到去除深层次雾霾、提升图像细节的目的。首先,引入一个高效的预处理模块,提取图像的初级特征;其次,多特征提取模块通过融合多种注意力机制提炼图像中不同层次的关键特征信息;最后,图像重建模块利用特征融合门技术,将多个特征整合以恢复出清晰度更高的图像。实验结果表明,所提算法能有效去除远处雾霾并恢复出清晰图像,在结构相似度和峰值信噪比等定量评估指标方面有较为明显的改善。

关键词: 图像去雾;注意力机制;多特征提取;图像重建

DOI: 10.11907/rjdk.241195

中图分类号: TP391

文献标识码: A

开放科学(资源服务)标识码(OSID):

文章编号: 1672-7800(2025)005-0186-08



Multi Feature Image Dehazing Algorithm Based on Attention Mechanism

WANG Sihong

(College of Information Science and Engineering, Hunan Normal University, Changsha 410081, China)

Abstract: In environments with significant changes in scene depth and uneven distribution of haze concentration, traditional deep learning dehazing algorithms often struggle to accurately evaluate image depth, resulting in poor dehazing performance for distant objects and loss of details for nearby objects. To this end, a multi feature image dehazing algorithm based on attention mechanism is proposed, which uses multiple attention mechanisms to focus on different feature regions of the image, achieving the goal of removing deep haze and improving image details. The algorithm first introduces an efficient preprocessing module to extract the primary features of the image; Then, the multi feature extraction module extracts key feature information at different levels in the image by integrating multiple attention mechanisms; Finally, the image reconstruction module utilizes feature fusion gate technology to integrate multiple features to restore images with higher clarity. The experimental results show that the proposed algorithm can effectively remove distant haze and restore clear images, with significant improvements in quantitative evaluation indicators such as structural similarity and peak signal-to-noise ratio.

Key Words: image dehazing; attention mechanisms; multi feature extraction; image reconstruction

0 引言

雾霾由大气中悬浮的微小水滴或冰晶引起,这些微小颗粒会散射和吸收光线,从而降低图像的对比度和颜色饱和度,导致其模糊不清^[1]。图像去雾是计算机视觉和图像处理领域的一个重要研究方向,旨在改善因雾或其他大气颗粒物散射而导致的图像质量下降^[2]。这一过程对于提升户外监控系统的可见性、增强无人驾驶车辆的视觉系统以及改善气象条件下的图像捕捉效果具有重要意义。

1 相关研究

1.1 大气散射模型

大气散射模型(Atmospheric Scattering Model, ASM)用于描述和模拟雾霾天气条件下大气对光线传播的影响^[3-4]。雾霾等其他悬浮颗粒物会散射大气中的光线,导致远处对象的颜色向大气光的颜色偏移,同时降低场景对比度。ASM试图量化这一效应,为去雾算法提供理论基础。用公式表示为:

收稿日期: 2024-03-03

扫描二维码阅读全文:

基金项目: 湖南省自然科学基金重大项目(2021JC0009)

作者简介: 王思洪(1998-),女,湖南师范大学信息科学与工程学院硕士研究生,研究方向为图像去雾算法。



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

式中: z 为有雾图像的像素坐标; $I(z)$ 为单幅有雾图像; $J(z)$ 为待恢复的单幅清晰图像; A 为大气光值(也称为环境光); $t(z)$ 为透射率,用于表示散射导致的光线衰减程度,当光在均匀介质中传播时被描述为:

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

式中: β 为大气散射系数; $d(x)$ 为景物到成像设备的距离。

图像去雾算法聚焦于透射率 $t(z)$ 和大气光值 A 的求解,根据有雾图像的形成过程逆推,以还原出清晰图像 $J(z)$ 。具体过程可描述为:

$$J(z) = \frac{A(1 - e^{-\beta d(z)}) - I(z)}{e^{-\beta d(z)}} \quad (3)$$

1.2 去雾算法

目前,图像去雾算法大致可分为基于物理模型的方法和基于深度学习的方法两大类。前者利用ASM,通过精确估算大气光和透射率来复原清晰图像,经典算法包括暗通道先验(Dark Channel Prior, DCP)、颜色衰减先验(Color Attenuation Prior, CAP)等^[5-11]。该类算法有着坚实的理论基础和较高的可解释性,但在复杂环境下对大气参数的估计可能因依赖先验知识而不够精确或鲁棒。后者利用大量有雾和无雾图像对进行学习,自动识别并理解有雾图像的复杂特征和隐藏规律,从而实现图像去雾,代表性方法包括DehazeNet、AOD-Net和GCA-Net等^[12-19]。该类方法直接从数据本身学习去雾策略,大幅度降低了对人工设定参数或特定先验知识的依赖,显著提高了去雾的自动化和智能化水平,但在复杂场景中的去雾效果仍有提升空间^[20]。

1.2.1 基于物理模型的去雾算法

基于物理模型的去雾算法对受雾霾影响的图像进行深入建模与分析,尝试逆向推导图像的退化过程,从而去除图像雾霾。这类算法大多依赖于ASM及其变体。例如,He等^[5]将暗通道作为估计透射率的工具,并结合ASM逆向推导来去除图像中的雾霾,但在处理大面积天空等高饱和度和区域时可能会导致颜色失真和曝光严重的问题;Zhu等^[6]基于雾浓度与亮度减去饱和度的值成正比的关系,以此引入一个基于场景深度的线性模型,通过解析有雾图像的景深来构建无雾图像,在特定场景下去雾效果出色,但在夜间、室内以及天空等场景下仍然存在局限性;Oakley等^[21]利用高斯函数预测光路,从而还原场景对比度;Kopf等^[22]采用软硬件设备获取景深和纹理数据,但对硬件要求高,通用性受到限制;Schechner等^[23]利用大气光的偏振性质估计图像的偏振参数,反演图像退化过程,从而恢复出清晰图像,在薄雾场景下效果显著;Tan^[24]基于无雾图像对比度较高的性质,尝试最大化有雾图像的局部对比度来实现去雾。

1.2.2 基于深度学习的去雾算法

基于深度学习的去雾算法利用深度神经网络自动学习图像去雾的复杂映射关系。例如,文献[12]提出的De-

hazeNet通过集成特征提取、多尺度映射以及非线性回归等先验知识从有雾图像中提取出透射率,并依托ASM实现了有雾图像的重建,但该模型在处理环境光分布不均或景深变化显著的场景时有一定的局限性;文献[13]提出的AOD-Net简化了ASM中的参数估计过程,将透射率和大气光统一为一个参数,实现了简单高效的去雾;文献[14]提出的GCA-Net通过引入空洞残差块,有效解决了普通卷积在去雾过程中可能出现的网格伪影现象;文献[15]提出的Cycle-Dehaze利用循环生成对抗网络,结合感知损失函数,直接从有雾图像中生成清晰图像,免去了对ASM参数的繁琐估计,但是处理后的图像存在网格伪影现象;文献[16]提出的MSCNN首先利用粗尺度网络估计整体透射率,然后由细尺度网络进一步细化特征,但是这种多阶段估计参数方式使去雾过程更为复杂;文献[17]提出的EDN-GTM采用U-Net结构和空间金字塔池化技术实现了优异的去雾效果,证明了编解码网络在图像去雾任务中的有效性;文献[18]提出的AECR-Net分别利用模糊图像和清晰图像作为负样本和正样本信息,提高算法对于图像变换的适应性,缩短了去雾后图像与原始清晰图像在表示空间的距离;其还引入一种基于类自编码器框架的紧凑型除雾网络,利用图像负面信息,在去除雾霾的同时减少了计算资源需求;文献[25]利用拉普拉斯金字塔和Tucker重建的正则化项来限制异常信号,为高分辨率图像的实时去雾提供了可能;文献[26]提出的GridDehazeNet是一种基于通道注意力的多尺度估计算法,解决了传统多尺度网络中信息流受限的问题,为去雾算法提供了更灵活的信息交换和聚合能力;文献[27]提出的MAXIM通过U-Net分层结构支持空间门控多层感知器实现远程交互,解决了高分辨率图像去雾时不灵活和局部注意力存在限制的问题;文献[28]提出的D4挖掘有雾与清晰图像中的散射系数和深度信息,而非单一估计传输图或清晰内容,通过估计场景深度重新渲染不同浓度的有雾图像,有效解决了合成有雾—清晰图像对在训练中存在的过拟合问题;文献[29]提出的RefineDNet基于两阶段弱监督去雾框架,在第一阶段恢复可见性之前采用DCP去雾;在第二阶段对第一阶段的初步去雾结果进行细化,通过对未配对的有雾和清晰图像进行对抗性学习提高图像真实感,生成了更加自然的去雾结果。

在深度变化大的场景中,同一幅图像的透射率会出现大幅度波动,现有去雾算法往往难以精确估计这种变化^[20]。在混合远近物体的场景中,这种问题更为突出,普通卷积操作可能导致远处物体的去雾效果不理想,而近处物体的细节信息丢失。针对这一问题,本研究引入位置注意力机制(Position Attention, PA),使算法拥有对图像空间细节的感知能力,能准确区分图像内的前景与背景,以及关键与非关键特征,并针对它们的重要性分配不同的权重,提高算法对场景深度变化的适应能力。

在真实的雾霾环境中,不同区域的雾霾浓度往往是不均匀的,现有算法在处理不均匀雾霾图像时往往难以达到

最佳去雾效果。针对这一问题,本文运用通道—像素注意力机制(Channel-Pixel Attention, CPA)有效识别和处理雾霾浓度不均匀的区域。其中,通道注意力用于捕获全局上下文信息,识别通道的重要性,并根据重要性赋予不同权重;像素注意力机制专注于像素特征,对有雾图像的每个像素点进行深入分析,提取重要特征。

不同层次特征具有不同的重要性,算法深层往往会丢失部分图像特征。针对这一问题,本文在图像重建模块运用了特征融合门(Feature Fusion Gate, FFG),利用跳跃链接连接不同层次间的特征,避免图像特征丢失。此外,FFG还能有效防止算法出现过拟合现象。

综上所述,本文提出一种新颖的多特征图像去雾算法,基于PA、CPA和FFG技术,通过预处理、多特征提取以及图像重建三大核心模块进行去雾。首先,在预处理模块利用标准卷积操作初步提取图像特征,同时保留其关键细节特征;其次,在多特征提取模块结合残差块和多种注意力机制深入提取不同重要性的图像特征;最后,在图像重建模块利用FFG整合深层与浅层特征,恢复并重建出清晰

图像。

2 模型构建

基于注意力机制的多特征图像去雾算法流程如图1(彩图扫描OSID码可见,下同)所示。算法起始于预处理模块,用于对输入的雾天图像进行初步处理。该模块由3个卷积块构成,每个卷积块由一个卷积核为 3×3 、步长为1的卷积层,归一化层和ReLU激活函数组成。处理后的特征图被送入由一系列残差块(ResBlock)、CPA以及PA构成的多特征提取模块,用于提取图像的多层次特征。其中,残差块用于解决深层网络训练中的梯度消失问题,可提取更深层次的特征而不丢失重要信息;CPA用于调节算法对图像中重要通道和空间特征的敏感度,加强模型对图像重要特征的响应;PA则通过调整局部区域特征来实现精准去雾。最后,图像重建模块利用FFG将不同层次的特征整合在一起,优化特征组合,确保在重建过程中能更好地恢复图像细节与特征。




Fig. 1 Flow of multi-feature image dehazing algorithm based on attention mechanism

图1 基于注意力机制的多特征图像去雾算法流程

2.1 多特征提取模块

2.1.1 残差块

在深度神经网络中,随着层数的增加,网络梯度很容易消失或爆炸,不利于模型训练。残差块是用于解决深层网络训练难题的关键构件。通过在每个单元中引入一个直接从输入跳到输出的跳跃连接,使网络能够学习到残差映射而非直接映射,既避免了梯度消失问题,又能保证学习到的特征不被后续层破坏。在图像去雾领域中,残差块

能有效保持图像内容的完整性,使深层网络能够捕捉到复杂、多尺度的特征,并提高模型收敛速度,增强去雾算法的性能和稳定性。

2.1.2 PA

PA能使算法精准地对图像中不同程度地受雾霾影响的区域进行差异化处理。具体结构见图2。在复杂场景中,PA能有效识别和清除雾霾,恢复图像的局部细节和质感,不仅提高了去雾效果的自然度和真实感,而且优化了

算法对于场景深度和雾浓度分布不均匀性的适应能力。此外,PA使算法能够更聚焦于那些对去雾效果影响最大的区域,避免了无谓的计算,在保证去雾性能的同时也提升了算法的运行效率。




Fig. 2 PA structure

图 2 PA 结构

给定一个特征图 $A \in \mathbb{R}^{C \times H \times W}$ 。首先,将其输入到卷积层中以生成两个新的特征图 B 和 C , 其中 $\{B, C\} \in \mathbb{R}^{C \times H \times W}$;其次,将其重塑为 $\mathbb{R}^{C \times N}$ 的形式,其中 $N = H \times W$ 为像素数量;再次,进行矩阵乘法,即 C 的转置与 B 之间的乘法,并利用 softmax 层计算空间注意力图 $S \in \mathbb{R}^{N \times N}$ 。计算公式为:

$$s_{ji} = \frac{\exp(B_i \cdot C_j)}{\sum_{i=1}^N \exp(B_i \cdot C_j)} \quad (4)$$

式中: s_{ji} 用于衡量第 i 个位置对第 j 个位置的影响。同时,将特征 A 送入卷积层以生成一个新的特征图 $D \in \mathbb{R}^{C \times H \times W}$,并将其重塑成 $\mathbb{R}^{C \times N}$;然后,再次执行矩阵乘法,即 D 与 S 的转置之间的乘法,并将结果重塑回 $\mathbb{R}^{C \times H \times W}$;最后,采用一个比例参数 α 对其进行乘法操作,并执行一个元素级别的求和操作,加上特征 A 以获得最终输出 $E \in \mathbb{R}^{C \times H \times W}$ 。表示为:

$$E_j = \alpha \sum_{i=1}^N (s_{ji} D_i) + A_j \quad (5)$$

式中: α 被初始化为 0,并逐渐学习分配更多权重。从式(5)中可以推断,每个位置的结果特征 E 为所有位置的特征与原始特征的加权和。因此,其具有全局上下文视图,并根据空间注意力图有选择性地聚合上下文。

2.1.3 CPA

雾霾影响的不仅仅是图像的局部区域,还包括不同通道中的特征。CPA 结合了通道注意力与像素注意力的优势,不仅在通道层面上突出重要特征,而且在像素维度上强调重要区域。具体结构见图 3。其中,通道注意力能够区分哪些通道的特征对于去雾更为重要;而像素注意力则进一步细化到像素级别,确保图像的每个部分都能得到恰当处理。这种双重注意力机制不仅能够识别整体的雾霾分布,而且能够细致地调整图像的每个细节,有效恢复其清晰度和真实颜色,在处理不均匀雾霾时更显其优势。

通道注意力首先使用全局平均池化取得通道维度全局空间信息,以此创建一个通道描述符。表示为:

$$g_c = H_p(F_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W X_c(i, j) \quad (6)$$




Fig. 3 CPA structure

图 3 CPA 结构

式中: $X_c(i, j)$ 表示位置 (i, j) 第 c 个通道 X 的值; H_p 为全局池化函数。

特征图的形状从 $C \times H \times W$ 变为 $C \times 1 \times 1$ 。为了获取不同通道的权重,通过两个卷积层和 sigmoid、ReLU 激活函数对特征进行处理。表示为:

$$CA_c = \sigma(\text{Conv}(\delta(\text{Conv}(g_c)))) \quad (7)$$

式中: σ 为 sigmoid 函数; δ 为 ReLU 函数。

其次,对输入 F_c 和通道 C 的权重 CA_c 进行元素级乘法。公式为:

$$F_c^* = CA_c \otimes F_c \quad (8)$$

像素注意力的实现方法与通道注意力类似,直接将输入 F^* (即通道注意力的输出)送入两个具有 ReLU 和 sigmoid 激活函数的卷积层。特征图的形状从 $C \times H \times W$ 变为 $1 \times H \times W$ 。计算公式为:

$$PA = \sigma(\text{Conv}(\delta(\text{Conv}(F^*)))) \quad (9)$$

最后,利用元素级乘法将输入 F^* 与 PA 结合, F^- 为 CPA 的最终输出。表示为:

$$F^- = F^* \otimes PA \quad (10)$$

2.2 图像重建模块

在深度学习模型中,不同层次的网络通常捕捉到图像不同方面的信息。浅层网络倾向于提取边缘、纹理等基础特征,而深层网络则能够捕获更加复杂的抽象特征。本文在图像重建模块中引入 FFG,用于综合来自网络不同层次的特征,解决了单一尺度特征可能忽略的细节丢失或全局信息不足等问题。其能整合浅层网络捕捉的细粒度纹理信息与深层网络提取的高级语义信息,既保留了雾前图像的细节清晰度,又重现了场景的整体视觉结构。FFG 由 3 个卷积核为 3×3 、步长为 1 的卷积组成,分别计算不同层的特征权重。

2.3 损失函数

本研究采用一种混合型 MS-SSIM+L1 损失函数,将多尺度结构相似性 (Multi Scale Structural Similarity Index Measure, MS-SSIM) 损失与 L1 损失结合起来^[26]。这种混合损失能更好地考虑人的视觉感受,有效减轻光栅效应,在保证图像亮度和颜色真实性的同时也能够保持其边缘和细节信息。损失函数的计算公式为:

$$L_{MS-SSIM+L1} = \alpha \cdot \mathcal{L}^{MS-SSIM} + (1 - \alpha) \cdot G_{\sigma_g} \cdot \mathcal{L}^1 \quad (11)$$

式中: α 为常量,用于平衡两种损失函数,一般设置为

0.84; G 为高斯分布参数; $\mathcal{L}^{MS-SSIM}$ 为 MS-SSIM 损失; $\mathcal{L}^l$ 为 L1 损失。

3 实验方法与结果分析

3.1 实验环境与参数设置

为确保实验结果具有可比性和公平性,本研究均在严格统一的实验环境下进行。所有算法实现均基于 PyTorch 框架,并统一使用 Adam 优化器进行模型优化。训练周期为 100 个 epoch,每个 epoch 处理 5 000 个样本;学习率初始值设为 0.000 1,在实验过程中不断递减,直至为 0。所有训练流程均在配备单张 GTX 1080 Ti 显卡的计算环境下完成,从训练过程中挑选出最优秀的结果作为最终实验成果。

3.2 实验数据集

从 RESIDE 数据集中选取 IST 子集中 13 990 个室内数据和 OST 子集中 13 990 个室外数据,确保算法能够有效处理多种场景下的图像去雾任务^[30]。为精确验证算法性能,从 RESIDE 数据集的 SOST 子集中挑选 500 张室内和室外图像作为验证集,实验结果均基于 SOST 子集。

3.3 评价指标

为精确评估去雾算法的性能,选取结构相似度 (Structural Similarity, SSIM) 和峰值信噪比 (Peak Signal-to-Noise Ratio, PSNR) 作为衡量图像质量的主要评价指标^[31]。

3.4 实验结果分析

3.4.1 比较实验

在 RESIDE 数据集上对本文算法与多个经典单幅图像去雾算法进行比较,包括 DCP^[5]、EPDN^[10]、AOD-Net^[13]、

GCA-Net^[14]、GridDehazeNet^[26]、PCFAN^[32]。结果如表 1 所示。可以看出,无论是在室内还是室外数据集上,本文算法均展现出更好的性能,超越了所有对照经典算法。

Table 1 Quantitative comparison results of RESIDE dataset

表 1 在 RESIDE 数据集上的定量比较结果

数据集	评价指标	DCP	AOD-Net	EPDN	GCA-Net	PCFAN	GridDehazeNet	本文模型
IST	PSNR	16.86	19.26	25.06	30.23	31.39	32.16	33.22
	SSIM	0.860 1	0.841 4	0.917 2	0.950 1	0.965 2	0.983 6	0.984 7
OST	PSNR	19.37	20.17	29.03	29.76	24.24	30.86	31.69
	SSIM	0.843 1	0.876 9	0.957 0	0.949 8	0.916 2	0.975 2	0.978 9

通过定性实验观察各算法去雾后图像的视觉质量,重点关注图像的清晰度、色彩还原度以及细节保留情况。结果见图 4。具体来说,DCP 在某些情况下可能会引起图像对比度的过度增强,导致去雾后图像的色彩过饱和,呈现出不自然的视觉效果,在光照较强的区域表现得尤为明显;AOD-Net 的去雾性能表现出一定的局限性,在某些情况下未能完全去除雾霾,结果图像中仍有轻微的雾霾痕迹;EPDN 在保留边缘信息方面表现较好,但在雾霾浓度较高区域未能完全去除雾霾,并在整体图像中引入了轻微的颜色偏差;GCA-Net 在恢复色彩方面表现更加自然,但在处理大面积单色块区域时仍然存在去雾不彻底的问题;PCFAN 在恢复图像细节时会在某些情况下产生不必要的噪声,且部分区域出现了黑色阴影;GridDehazeNet 在处理大面积相同色块时细节不够平滑,存在少量深色阴影。综上所述,本文算法在室外图像中实现了更好的去雾效果,恢复了因雾霾而损失的细节和色彩;而 AOD-Net、GCA-Net、PCFAN 未能很好地去除图像中场景较深的雾霾。



(a) Hazy image

(a) 雾图



(b) DCP

(b) DCP



(c) AOD-Net

(c) AOD-Net




Fig. 4 Qualitative experimental results

图4 定性实验结果

3.4.2 消融实验

消融实验用于考察各组件对模型性能的影响。移除每个模块,并观察这些变化对算法准确性、鲁棒性以及计算效率的影响,用于评估每个模块对整体模型的贡献。表2为在RESIDE室外数据集上的消融实验定量结果。实验使用的主干网络由1个预处理模块、7个残差块以及3层卷积块3个关键部分构成。可以看出,CPA和PA模块各自独立使用时均能增强去雾效果,当两个模块联合使用时,去雾效果得到显著提升;引入FFG机制后,模型去雾性能进一步提高,性能指标达到最优。

Table 2 Quantitative results of ablation experiment

表2 消融实验定量结果

算法	PSNR	SSIM
主干网络	31.12	0.947 3
主干网络+CPA	32.38	0.965 1
主干网络+PA	31.71	0.962 3
主干网络+CPA+PA	33.03	0.976 5
本文算法	33.22	0.984 7

图5为消融实验的部分定性结果。可以清晰地看出,本文算法引入的各个模块均对提升算法性能起到了积极作用。



Fig. 5 Partial qualitative results of ablation experiment

图5 消融实验的部分定性结果

参考文献:

4 结语

本文提出一种基于注意力机制的多特征图像去雾算法,通过预处理模块抽象出初级特征;通过多特征提取模块深入挖掘图像中的关键信息;通过图像重建模块融合不同层级间的特征,最终重建出清晰、自然的去雾图像,在定量评估指标方面优于现有经典图像去雾算法。然而,本文算法引入了多种注意力机制与残差块,可能导致模型参数量增加,计算复杂度较高,实时性受到限制。未来可通过轻量化网络优化算法结构,在保证性能的同时降低计算成本。此外,本文算法虽然在实验中表现良好,但实际场景中的雾霾类型、浓度以及光照条件复杂多变,其在训练数据以外场景下的泛化能力尚未得到充分验证。未来可通过引入更多样化的训练数据(如多场景、多天气条件、多设备拍摄的数据集),并采用自监督或无监督学习方法增强算法的泛化能力;同时可借助生成对抗网络生成多样化合成数据,进一步提升模型在未见数据上的表现。

- [1] WEI H W, TIAN J, XIAO Z P. Review of image defogging algorithms [J]. Software Guide, 2021, 20(8): 231-235.
魏红伟,田杰,肖卓朋. 图像去雾算法研究综述[J]. 软件导刊, 2021, 20(8): 231-235.
- [2] ZHANG L H, SUN G C, JIU M Y. Image defogging algorithm based on bottom hat transform and image fusion [J]. Software Guide, 2022, 21(2): 177-183.
张丽华,孙钢灿,酒明远. 基于底帽变换与图像融合的图像去雾算法[J]. 软件导刊, 2022, 21(2): 177-183.
- [3] MCCARTNEY E J. Optics of the atmosphere: scattering by molecules and particles [J]. Physics Today, 1977, 30(5): 76-77.
- [4] LEVY D, PELEG A, PEARL N, et al. SeaThru-NeRF: neural radiance fields in scattering media [C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 56-65.
- [5] HE K, SUN J, TANG X. Single image haze removal using dark channel prior [J]. Transactions on Pattern Analysis and Machine Intelligence, 2010, 33(12): 2341-2353.
- [6] 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.

- [7] SONG Y, HE Z, QIAN H, et al. Vision transformers for single image dehazing [J]. *IEEE Transactions on Image Processing*, 2023, 32: 1927–1941.
- [8] BI P, WANG D, CHEN W, et al. Image dehazing based on polarization information and deep prior learning[J]. *Optik*, 2022, 267: 169746.
- [9] GUO F, YANG J, LIU Z, et al. Haze removal for single image: a comprehensive review[J]. *Neurocomputing*, 2023, 537: 85–109.
- [10] 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*, 2019: 8160–8168.
- [11] WANG Y, WANG J, PAN W, et al. Residual dense network with an attention mechanism for image dehazing[C]//2023 IEEE 17th International Conference on Anti-counterfeiting, Security, and Identification, 2023: 25–29.
- [12] 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.
- [13] LI B, PENG X, WANG Z, et al. AOD-Net: all-in-one dehazing network [C]//2017 IEEE International Conference on Computer Vision, 2017: 4780–4788.
- [14] CHEN D, HE M, FAN Q, et al. Gated context aggregation network for image dehazing and deraining[C]//2019 IEEE Winter Conference on Applications of Computer Vision, 2019: 1375–1383.
- [15] ENGIN D, GENÇ A, KEMAL E H. Cycle-dehaze: enhanced cyclegan for single image dehazing [C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops*, 2018: 825–833.
- [16] REN W, LIU S, ZHANG H, et al. Single image dehazing via multi-scale convolutional neural networks [C]//14th European Conference on Computer Vision, 2016: 154–169.
- [17] TRAN L A, MOON S, PARK D C. A novel encoder-decoder network with guided transmission map for single image dehazing [J]. *Procedia Computer Science*, 2022, 204: 682–689.
- [18] WU H, QU Y, LIN S, 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] ZHU Y, WANG T, FU X, et al. Learning weather-general and weather-specific features for image restoration under multiple adverse weather conditions [C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2023: 21747–21758.
- [20] WANG S, MEI X, KANG P, et al. DFC-dehaze: an improved cycle-consistent generative adversarial network for unpaired image dehazing [J]. *The Visual Computer*, 2024, 40: 2807–2818.
- [21] OAKLEY J P, SATHERLEY B L. Improving image quality in poor visibility conditions using a physical model for contrast degradation [J]. *IEEE Transactions on Image Processing*, 1998, 7(2): 167–179.
- [22] KOPF J, NEUBERT B, CHEN B, et al. Deep photo: model-based photograph enhancement and viewing [J]. *ACM Transactions on Graphics (TOG)*, 2008, 27(5): 1–10.
- [23] SCHECHNER Y Y, NARASIMHAN S G, NAYAR S K. Polarization-based vision through haze[J]. *Applied Optics*, 2003, 42(3): 511–525.
- [24] TAN R T. Visibility in bad weather from a single image [C]//*IEEE Conference on Computer Vision and Pattern Recognition*, 2008: 1–8.
- [25] LIANG J, ZENG H, ZHANG L. High-resolution photorealistic image translation in real-time: a Laplacian pyramid translation network [C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2021: 9392–9400.
- [26] LIU X, MA Y, SHI Z, et al. Griddehazenet: attention-based multi-scale network for image dehazing [C]//*Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2019: 7314–7323.
- [27] TU Z, TALEBI H, ZHANG H, et al. Maxim: multi-axis mlp for image processing [C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2022: 5769–5780.
- [28] YANG Y, WANG C, LIU R, et al. Self-augmented unpaired image dehazing via density and depth decomposition [C]//*Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2022: 2037–2046.
- [29] ZHAO S, ZHANG L, SHEN Y, et al. RefinedNet: a weakly supervised refinement framework for single image dehazing [J]. *IEEE Transactions on Image Processing*, 2021, 30: 3391–3404.
- [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] CHOI S, YANG J, LEE S Y, et al. Deep learning enhances multiparametric dynamic volumetric photoacoustic computed tomography in vivo (DL-PACT)[J]. *Advanced Science*, 2023, 10(1): 2202089.
- [32] 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*, 2019: 8160–8168.

(责任编辑:尹晨茹)