

大气散射模型的物理机制及其对单图像去雾的理论指导研究

刘 宇

贵州大学大数据与信息工程学院, 贵州 贵阳

收稿日期: 2026年8月3日; 录用日期: 2026年8月27日; 发布日期: 2026年9月2日

摘 要

单幅图像去雾在计算机视觉的高层任务中具有重要意义。本文以大气散射模型为核心, 系统梳理了去雾技术的理论基础与发展脉络。首先阐述了光传播的物理机制与去雾的病态逆问题本质; 其次, 对比分析了基于先验知识的传统参数估计方法与基于深度学习的端到端范式, 并重点探讨了无监督与零参考框架在解决真实场景域偏移中的优势; 最后, 针对非均匀雾霾与零参考先验缺失等难题, 提出了非均匀物理模型拓展、物理模型引导的微观网络轻量化以及物理规律正则化等优化方向。本文旨在为去雾技术的物理可解释性与工程落地提供理论参考。

关键词

单图像去雾, 大气散射模型, 深度学习, 无监督学习, 零参考去雾

The Physical Mechanism of Atmospheric Scattering Model and Its Theoretical Guidance for Single Image Dehazing

Yu Liu

College of Big Data and Information Engineering, Guizhou University, Guiyang Guizhou

Received: August 3, 2026; accepted: August 27, 2026; published: September 2, 2026

Abstract

Single image dehazing is of profound significance for high-level computer vision tasks. Centered on the atmospheric scattering model, this paper systematically reviews the theoretical foundation and technological evolution of dehazing methods. First, the physical mechanism of light propagation

文章引用: 刘宇. 大气散射模型的物理机制及其对单图像去雾的理论指导研究[J]. 现代物理, 2026, 16(5): 155-162.

DOI: 10.12677/mp.2026.165017

and the ill-posed nature of the dehazing problem are elaborated. Second, traditional prior-based parameter estimation methods and deep learning-based end-to-end paradigms are compared, highlighting the advantages of unsupervised and zero-reference frameworks in addressing domain shift in real-world scenarios. Finally, focusing on challenges such as non-uniform haze and the lack of zero-reference priors, future optimization directions including the expansion of non-uniform physical models, micro-network lightweight design guided by physical models, and physical law regularization are proposed. This paper aims to provide a theoretical reference for the physical interpretability and practical deployment of dehazing technologies.

Keywords

Single Image Dehazing, Atmospheric Scattering Model, Deep Learning, Unsupervised Learning, Zero-Reference Dehazing

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

雾霾等恶劣天气会导致户外图像对比度下降、细节模糊及色彩偏移,严重影响自动驾驶、安防监控等高层视觉任务的准确性与可靠性[1]。因此,研究高效鲁棒的单幅图像去雾技术具有重要意义。该领域研究始终围绕大气散射模型展开,该模型从光传播的物理规律出发描述成像退化过程,为去雾算法提供了统一的理论框架[2]。早期方法依赖多幅图像或额外硬件,因采集条件苛刻难以普及。目前单幅去雾主要分为两类:基于统计先验的传统方法,通过自然图像统计规律求解模型参数;以及基于深度学习的数据驱动方法,通过神经网络构建端到端的图像恢复映射[3]。

尽管两类方法在合成数据集上效果显著,但在真实复杂场景下仍存局限:传统先验方法在大面积天空或高亮区域易失效;深度学习方法依赖合成数据,面临严重的域偏移问题;完全零参考场景下的去雾性能与可解释性仍显不足。本文以大气散射模型为核心,系统梳理去雾技术的理论基础、实现路径与局限,并探讨物理模型指导下的技术优化方向。

2. 大气散射模型:单图像去雾的物理基石

2.1. 大气光学散射机制与基本方程

大气散射模型源于对光线在悬浮粒子介质中传播时能量衰减与散射叠加效应的研究[4]。Narasimhan等将其完整引入计算机视觉,成为单幅去雾的标准物理框架[5]。根据该模型,相机传感器接收到的总光强由两部分构成:一是场景表面反射的光线,在穿过大气介质的过程中被粒子吸收与散射,最终到达相机的直接衰减分量;二是大气环境中的自然光被气溶胶粒子散射后,直接进入相机的大气光分量。两种分量的叠加共同导致了有雾图像的对比度降低与整体亮度抬升,其数学表达式可写为:

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

其中, $I(x)$ 表示相机采集到的有雾退化图像, $J(x)$ 表示待求解的理想无雾清晰图像, A 表示全局大气光强度, $t(x)$ 表示场景点到相机之间的介质传输率。公式右侧第一项 $J(x)t(x)$ 为直接衰减项,反映了场景反射光经介质衰减后的剩余能量;第二项 $A(1-t(x))$ 为大气光项,反映了环境光散射对成像的叠加干扰。

这一简洁的数学形式完整涵盖了雾霾成像的核心物理机制，许多传统去雾方法和物理模型引导的学习方法均以该方程为理论基础，通过引入不同约束来反演求解清晰图像 $J(x)$ 。

2.2. 传输率与全局大气光的物理内涵

传输率 $t(x)$ 与全局大气光 A 是大气散射模型中两个核心宏观参数，分别对应着成像退化的不同物理机制。传输率 $t(x)$ 描述了场景反射光能够穿过大气介质到达相机的能量比例，其数值与场景深度、大气散射系数直接相关，满足指数衰减规律：

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

式中， $d(x)$ 为场景点 x 对应的深度值，即场景表面到相机的空间距离； β 为大气散射系数，由空气中悬浮粒子的浓度、粒径分布与光学折射率共同决定。雾霾天气下，气溶胶粒子浓度显著升高，散射系数 β 随之增大，光线衰减速率加快。由公式可知，场景深度越深，传输率数值越小，图像受雾霾的退化影响越严重；当深度趋近于无穷大时，传输率趋近于 0，成像结果近似等于全局大气光 A ，这也是远处景物呈现灰白色的物理本质[6]。

全局大气光 A 代表无穷远处环境光强，决定了图像的整体亮度基线与色彩偏移。其估计精度至关重要，偏高会导致复原图像整体偏暗，偏低则去雾不彻底[1]。

2.3. 单幅图像去雾的病态性本质

从数学反演的角度看，单幅图像去雾是典型的病态逆问题。在大气散射模型的基本方程中，已知量仅为单幅观测图像 $I(x)$ ，而待求解的未知量包含清晰图像 $J(x)$ 、空间变化的传输率 $t(x)$ 与全局大气光 A 三类，未知量的数量远多于已知约束条件。在没有额外深度信息、多视角观测或场景先验的前提下，该方程存在无穷多组可行解，无法得到唯一符合真实场景的结果[7]。因此，任何去雾算法本质上都是通过引入合理的物理先验或数据驱动约束来缩小解空间，从而得到符合真实物理规律的合理估计结果。

3. 单幅图像去雾的核心实现路径与原理

3.1. 基于先验知识的物理参数估计方法

3.1.1. 暗通道先验的统计规律与求解逻辑

He 等提出的暗通道先验(DCP)指出，在绝大多数非天空区域的局部块内，至少有一个颜色通道的像素强度趋近于零[8]。暗通道的数学定义为：

$$J^{dark}(x) = \min_{y \in \Omega(x)} \left(\min_{c \in \{r, g, b\}} J^c(y) \right) \approx 0 \quad (3)$$

其中 $\Omega(x)$ 表示以像素 x 为中心的局部图像块， $J^c(y)$ 表示清晰图像第 c 个颜色通道的像素值。将这一先验规律代入大气散射模型方程，对等式两边同时执行局部最小值与通道最小值运算，可推导出粗略传输率的估计公式：

$$\tilde{t}(x) = 1 - \omega \min_{y \in \Omega(x)} \left(\min_{c \in \{r, g, b\}} \frac{I^c(y)}{A^c} \right) \quad (4)$$

式中 ω 为透视保留系数，通常取值 0.95，用于保留少量雾气以维持场景的深度感。为消除基于块运算导致的块效应，进一步采用导向滤波精细化传输率，在保留边缘的同时平滑区域内部数值[9]，最终得到自然的去雾结果。

3.1.2. 经典先验方法的衍生发展与局限

暗通道先验之外,研究者还从不同角度提出了多种统计先验,丰富了参数估计的技术路径。Tan 等人提出对比度最大化先验,假设清晰图像的局部对比度显著高于有雾图像,通过最大化复原图像的局部对比度实现去雾,但该方法容易出现局部过增强与色彩失真[10],一些典型的缺陷情况如下图 1 所示。Berman 等人提出非局部先验,利用自然图像中纹理结构的重复性,通过聚类寻找不同深度的相似像素块,实现更鲁棒的传输率估计[11]。Hu 等人通过自适应区分天空区域与非天空区域,优化了大气光估计方式,有效缓解了天空区域的色彩失真问题[12]。然而,传统先验方法存在本质缺陷:一是大面积天空、白色建筑或浓雾区域易导致统计先验失效;二是算法依赖人工设计,参数调节的自适应性差,难以应对非均匀雾霾场景。



Figure 1. Typical limitations of image dehazing methods

图 1. 去雾方法存在的典型缺陷

3.2. 有监督深度学习的端到端映射范式

3.2.1. 端到端去雾网络的基础架构

DehazeNet 是首个基于深度学习的端到端去雾网络,其设计思路仍以大气散射模型为理论基础:网络的核心功能是估计介质传输率,再结合单独估计的大气光值,通过大气散射模型公式计算得到清晰图像[3]。随后, AOD-Net 通过公式变形,将传输率与大气光合并为一个自适应一体化参数,实现了端到端的轻量化重建,大幅降低了计算开销[13]。这类物理模型引导的网络设计思路,既保留了物理过程的可解释性,又发挥了深度学习的特征拟合优势,是早期有监督去雾网络的典型特征。

3.2.2. 多尺度特征与注意力机制的融合增强

早期端到端网络在浓雾区域的细节恢复能力不足,且对不同浓度的雾霾适应性有限。后续研究通过引入多尺度特征提取与注意力机制,显著提升了网络的去雾性能。多尺度特征融合通过不同感受野的卷积模块提取不同层级的图像信息:大感受野捕捉全局雾气分布与场景结构,小感受野保留局部纹理与边缘细节,两者结合能够有效提升网络对不同浓度雾霾的适应能力[14]。

注意力机制则通过自适应权重聚焦浓雾和细节损失严重的区域。Qin 等人提出的 FFA-Net 构建了通

道注意力与像素注意力相结合的特征融合注意力模块，能够自适应地关注雾气浓度高、细节损失严重的区域，在多个合成基准数据集上取得了领先的峰值信噪比与结构相似性指标[15]。这表明精细化权重分配能有效提升去雾网络的重建上限。

3.3. 基于 Transformer 与扩散模型的新型去雾架构

近年 Vision Transformer 与扩散模型逐渐成为单幅图像去雾领域的重要研究方向。相较于传统卷积神经网络，Transformer 通过自注意力机制能够有效建模图像区域之间的长距离依赖关系，为非均匀雾霾条件下的全局特征提取提供了新的技术路径。Song 等人提出的 DehazeFormer [16]以 Swin Transformer 为基础构建多阶段编码-解码网络，并针对图像去雾任务对归一化方式、非线性激活函数和空间信息聚合机制进行了改进；同时，通过窗口注意力与卷积操作相结合，在建模较大范围特征依赖的同时补充局部空间及高频信息，并利用通道注意力实现多尺度特征的自适应融合。此外，该方法根据大气散射成像关系设计了软重建机制，将物理模型以弱先验形式融入网络重建过程，从而兼顾数据驱动特征学习与一定的物理可解释性。

扩散模型则通过渐进式逆向去噪生成更细腻自然的纹理，避免了传统网络复原图像过度平滑的缺陷。现有融合物理模型的主流方案分为两类：一是将大气散射重构损失作为采样约束，二是借助物理模型生成多浓度雾图作为训练样本。但扩散模型存在计算复杂度高、推理速度慢的落地短板，当下主流优化思路包括轻量化网络、减少采样步数、模型蒸馏，如何兼顾图像复原质量与运行效率，是该类模型工程化应用的核心难题。

3.4. 无监督与零参考去雾的物理约束框架

3.4.1. 成对数据集的域偏移困境

有监督网络高度依赖合成数据(基于固定散射系数和已知深度图人工加雾)，这与真实雾霾的物理特性存在本质差异，导致模型在真实场景中泛化表现下降，即域偏移问题[17]。

为解决成对数据集的局限，研究者引入生成对抗网络构建无监督去雾框架。Engin 等人提出的 Cycle-Dehaze 基于 CycleGAN 的循环一致性思想，利用不成对的有雾图像与清晰图像进行训练，实现了无需严格配准数据的去雾学习[18]。但纯数据驱动在无监督方法缺乏物理规律约束，容易生成不符合光学特性的结果，出现色彩偏移、纹理畸变等问题，其鲁棒性与物理合理性仍有待提升。

3.4.2. 大气散射模型嵌入的无监督学习

将大气散射模型嵌入无监督学习可显著提高物理合理性。An 等提出的半监督框架将多重散射模型引入网络，利用模糊图像先验求解模糊核，缓解了真实雾图的域偏移[19]。其核心机制是构建物理重构损失，通过网络输出的清晰图像、传输率与大气光反向重构输入有雾图。在零参考场景下，物理重构是一种重要且具有物理解释性的约束，能有效缩小解空间，避免异常结果。

本节选取具有代表性的几类方法进行横向对比。结果如表 1 所示。

Table 1. Comparison of representative single image dehazing methods

表 1. 具有代表性的几类去雾方法对比

方法	类别	核心思想	SOTS-indoor 数据集基准性能(PSNR/SSIM)	计算复杂度
DCP	传统物理先验	暗通道统计规律，估计透射率与大气光后复原	16.62/0.8179	无训练参数，CPU 可运行
AOD-Net	轻量 CNN	联合参数替代分离估计，端到端轻量化	19.06/0.8504	参数量 1.76 K，支持边缘实时

续表

FFA-Net	注意力 CNN	通道 + 像素双注意力, 自适应处理不均雾	36.39/0.9886	参数量 4.5 M, 算力需求中等
Dehaze Former	Transformer	定制 Swin 结构, 适配全域非均匀去雾	36.82/0.9891	1.28 M~25 M 参数, 算力跨度大
PD-DDPM [20]	扩散模型	引入全局先验和局部先验	31.46/0.9721	参数量 13.4 M
Cycle-Dehaze	无监督 GAN	循环约束 + 感知损失, 无需配对数据	23.63/0.887	双生成器架构, 推理耗时中等

4. 大气散射模型指引下的技术挑战与优化方向

4.1. 非均匀复杂场景的参数估计偏差问题

基于经典均匀大气散射模型的部分去雾方法通常假设散射系数在场景中保持恒定, 即大气散射系数 β 在整个场景中为恒定值, 传输率仅由场景深度决定。但在真实场景中, 雾霾的空间分布往往是非均匀的: 例如近地面区域雾霾浓度更高, 局部区域可能存在烟尘、水雾等局地性颗粒物, 甚至不同高度的大气层存在不同的散射特性。此时, 恒定散射系数的假设会失效, 导致传输率估计出现系统性偏差, 最终引发局部去雾不足或过度去雾。

解决这一问题的核心方向, 首先需要在理论上对经典大气散射模型进行松绑, 将恒定的散射系数拓展为空间坐标的函数 β ; 在此物理拓展的指引下, 再引入多尺度特征提取与全局上下文建模捕捉雾气的空间分布差异, 从而真正提升算法对复杂场景的理论与工程适应性。

4.2. 零参考去雾的物理先验缺失难题

零参考去雾不依赖清晰图像标签, 是真实场景落地的核心需求。但在完全无监督条件下, 大气散射模型的病态性被放大, 且通用无参考指标难以提供精准的梯度指导, 导致算法极易出现色彩失真、过曝或欠曝等问题。为降低解空间的不确定性, 将大气散射模型的物理约束转化为损失函数的正则项成为突破口, 这能在无标签情况下约束网络优化方向, 确保生成结果符合光传播规律。

在此思路下, 模块化解耦与物理先验嵌入成为主流方案。以 YOLY [21]为例, 它将网络拆解为环境光估计、传输率估计与图像重构三个模块, 分别对应大气散射模型的全局大气光 A 、传输率 $t(x)$ 与清晰图像 $J(x)$, 各子网络专注单一物理参数估计, 避免端到端黑盒网络的参数冗余与功能重叠。其网格注意力在多尺度网络上估计传输率, 浅层捕捉近景浓雾的精细变化, 深层捕捉远景薄雾的全局趋势, 贴合不同深度的雾气衰减规律。DehazeFormer 的轻量化变体也遵循该思路: 基于传输率局部空间连续的物理先验, 设计带局部窗口约束的自注意力机制, 既保留 Transformer 的全局建模能力, 又大幅削减计算量, 在压缩参数量的同时增强了网络的物理可解释性。

4.3. 物理驱动的网络性能优化路径

4.3.1. 模型引导的轻量化网络设计

在自动驾驶、移动终端等实时应用中, 去雾算法的计算效率与参数量至关重要。大气散射模型为轻量化设计提供了理论指引, 可避免盲目堆砌层带来的结构冗余。早期 AOD-Net 通过公式变形合并参数实现了宏观精简; 未来的轻量化设计则需将模型子模块与现代轻量级微观算子进行深度融合。

基于物理过程的模块化解耦是另一核心思路。将网络拆分为传输率估计、大气光估计与图像重构三

个子模块,使其分别专注单一物理参数的反演。相比黑盒端到端网络,这种设计能以更少的参数量实现优异性能,并显著提升网络的可解释性。

在物理模型引导的深度学习去雾研究中,将大气散射模型所描述的成像规律转化为网络训练过程中的正则化约束,是增强模型物理可解释性的重要思路。根据大气散射模型,在散射系数近似均匀的条件下,介质传输率随场景深度增加而减小,因此可利用深度信息或估计的场景结构对传输率施加合理的空间约束。同时,传输率具有明确的物理取值范围,大气光在同一场景中通常具有较强的全局一致性,这些物理特征均可作为网络优化的先验条件。此外,还可利用网络估计的清晰图像、传输率和大气光重新构造有雾图像,并通过重构误差约束模型输出满足大气散射成像关系。将上述物理约束与像素重建损失、感知损失等数据驱动目标结合,有望在保证图像恢复质量的同时,减少不符合物理规律的异常解,并提升模型在真实复杂雾霾场景中的泛化能力。

4.3.2. 物理损失函数的正则化约束

深度学习去雾网络的训练通常采用均方误差、感知损失等通用损失函数,这类损失容易导致复原图像过平滑、纹理丢失,或出现不符合物理规律的色彩偏移。将大气散射模型的物理规律转化为损失函数的正则项,能够有效约束网络的解空间,提升结果的物理合理性与泛化能力。

常用的物理约束损失包括三类:一是输入重构损失,利用网络估计的清晰图像、传输率与大气光,通过大气散射模型重构输入的有雾图像,以重构误差衡量参数估计的准确性;二是传输率平滑损失,约束传输率的空间连续性,符合真实场景中深度连续变化的物理特性;三是大气光一致性损失,保证大气光的全局稳定性,避免出现不合理的空间突变。多项实验表明,加入物理约束损失的网络在真实雾天图像上的泛化能力显著优于纯数据驱动的网络,能够有效缓解域偏移问题,是提升模型鲁棒性的重要手段。

5. 结语

大气散射模型作为单幅图像去雾技术的物理基石,不仅为理解雾霾成像的光学机制提供了定量的理论框架,也贯穿了从传统先验方法到深度学习方法的整个技术发展脉络。传统先验方法基于模型的参数分解思路,通过对自然图像的统计总结实现物理参数的估计,在场景明确的静态图像中取得了良好的去雾效果;深度学习方法则借助数据驱动的特征提取能力,实现了端到端的高效图像重建,而大气散射模型的嵌入能够有效弥补纯数据驱动方法的泛化性缺陷与可解释性不足。

当前单幅图像去雾技术仍面临非均匀场景适应性不足、零参考场景性能受限、实时性与效果难以平衡等现实挑战。未来的研究应当进一步深化物理模型与深度学习的融合,以大气散射的物理规律指导网络架构设计、损失函数构建与训练流程优化,推动去雾技术从经验性的数据映射向物理可解释的智能推理转变。这一发展方向不仅能够提升去雾算法在真实复杂场景中的鲁棒性,也将为自动驾驶、遥感监测、安防监控等领域的视觉系统提供更可靠的图像质量保障。

参考文献

- [1] Li, G., Li, J., Chen, G., Wang, Z., Jin, S., Ding, C., *et al.* (2023) Delving Deeper into Image Dehazing: A Survey. *IEEE Access*, **11**, 131759-131774. <https://doi.org/10.1109/access.2023.3335618>
- [2] Li, A., Xu, G., Yue, W., Xu, C., Gong, C. and Cao, J. (2024) Object Detection in Hazy Environments, Based on an All-in-One Dehazing Network and the YOLOv5 Algorithm. *Electronics*, **13**, Article 1862. <https://doi.org/10.3390/electronics13101862>
- [3] Cai, B., Xu, X., Jia, K., Qing, C. and Tao, D. (2016) DehazeNet: An End-to-End System for Single Image Haze Removal. *IEEE Transactions on Image Processing*, **25**, 5187-5198. <https://doi.org/10.1109/tip.2016.2598681>
- [4] Cantor, A. (1978) Optics of the Atmosphere—Scattering by Molecules and Particles. *IEEE Journal of Quantum Electronics*, **14**, 698-699. <https://doi.org/10.1109/jqe.1978.1069864>

- [5] Narasimhan, S.G. and Nayar, S.K. (2008) Vision and the Atmosphere. *ACM SIGGRAPH ASIA 2008 Courses on SIGGRAPH Asia 08*, Singapore, 10-13 December 2008, 1-22. <https://doi.org/10.1145/1508044.1508113>
- [6] Wang, S. and Zhang, M. (2025) Atmospheric Scattering Prior Embedded Diffusion Model for Remote Sensing Image Dehazing. *Atmosphere*, **16**, Article 1065. <https://doi.org/10.3390/atmos16091065>
- [7] Fattal, R. (2008) Single Image Dehazing. *ACM Transactions on Graphics*, **27**, 1-9. <https://doi.org/10.1145/1360612.1360671>
- [8] He, K.M., Sun, J. and Tang, X.O. (2009) Single Image Haze Removal Using Dark Channel Prior. 2009 *IEEE Conference on Computer Vision and Pattern Recognition*, Miami, 20-25 June 2009, 1956-1963. <https://doi.org/10.1109/cvpr.2009.5206515>
- [9] He, K., Sun, J. and Tang, X. (2013) Guided Image Filtering. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **35**, 1397-1409. <https://doi.org/10.1109/tpami.2012.213>
- [10] Tan, R.T. (2008) Visibility in Bad Weather from a Single Image. 2008 *IEEE Conference on Computer Vision and Pattern Recognition*, Anchorage, 23-28 June 2008, 1-8.
- [11] Berman, D., Treibitz, T. and Avidan, S. (2016) Non-Local Image Dehazing. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27-30 June 2016, 1674-1682. <https://doi.org/10.1109/cvpr.2016.185>
- [12] Hu, Q., Zhang, Y., Zhu, Y., Jiang, Y. and Song, M. (2022) Single Image Dehazing Algorithm Based on Sky Segmentation and Optimal Transmission Maps. *The Visual Computer*, **39**, 997-1013. <https://doi.org/10.1007/s00371-021-02380-3>
- [13] Li, B., Peng, X., Wang, Z., Xu, J. and Feng, D. (2017) AOD-Net: All-in-One Dehazing Network. 2017 *IEEE International Conference on Computer Vision (ICCV)*, Venice, 22-29 October 2017, 4780-4788. <https://doi.org/10.1109/iccv.2017.511>
- [14] Ji, L. and Chen, C. (2025) Multi-Scale Image Defogging Network Based on Cauchy Inverse Cumulative Function Hybrid Distribution Deformation Convolution. *Sensors*, **25**, Article 5088. <https://doi.org/10.3390/s25165088>
- [15] Qin, X., Wang, Z., Bai, Y., Xie, X. and Jia, H. (2020) FFA-Net: Feature Fusion Attention Network for Single Image Dehazing. *Proceedings of the AAAI Conference on Artificial Intelligence*, **34**, 11908-11915. <https://doi.org/10.1609/aaai.v34i07.6865>
- [16] Song, Y., He, Z., Qian, H. and Du, X. (2023) Vision Transformers for Single Image Dehazing. *IEEE Transactions on Image Processing*, **32**, 1927-1941. <https://doi.org/10.1109/tip.2023.3256763>
- [17] Zhao, S., Zhang, L., Huang, S., Shen, Y. and Zhao, S. (2020) Dehazing Evaluation: Real-World Benchmark Datasets, Criteria, and Baselines. *IEEE Transactions on Image Processing*, **29**, 6947-6962. <https://doi.org/10.1109/tip.2020.2995264>
- [18] Engin, D., Genc, A. and Ekenel, H.K. (2018) Cycle-Dehaze: Enhanced CycleGAN for Single Image Dehazing. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, Salt Lake City, 18-22 June 2018, 938-9388. <https://doi.org/10.1109/cvprw.2018.00127>
- [19] An, S., Wang, L. and Wang, L. (2024) Semi-Supervised Dehazing Network Using Multiple Scattering Model and Fuzzy Image Prior. *Applied Intelligence*, **54**, 5794-5812. <https://doi.org/10.1007/s10489-024-05443-9>
- [20] Sun, H., Xu, J., Gong, J. and Wang, Y. (2026) PD-DDPM: Prior-Driven Diffusion Model for Single Image Dehazing. *Image and Vision Computing*, **167**, Article 105888. <https://doi.org/10.1016/j.imavis.2025.105888>
- [21] Li, B., Gou, Y., Gu, S., Liu, J.Z., Zhou, J.T. and Peng, X. (2021) You Only Look Yourself: Unsupervised and Untrained Single Image Dehazing Neural Network. *International Journal of Computer Vision*, **129**, 1754-1767. <https://doi.org/10.1007/s11263-021-01431-5>