

基于大气散射物理模型的自适应雾图大气光强预测算法研究

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16日; 录用日期: 2026年9月9日; 发布日期: 2026年9月18日

摘 要

针对传统单幅图像去雾方法中大气光强度通常采用单一全局参数进行估计, 难以适应复杂场景下非均匀光照与雾气分布, 容易造成去雾图像整体偏暗、局部过曝光及色彩失真等问题, 本文提出一种基于自适应大气光强预测的单幅图像去雾方法。该方法将大气光建模为空间变化的分布, 通过构建空间自适应大气光估计网络, 实现大气光参数的动态预测。在SOTS-outdoor和HSTS两个公开数据集上进行了定量与定性实验, 实验结果表明, 本文方法相较于传统 DCP 方法均表现出更好的图像恢复精度和结构保持能力。基于自适应大气光预测能够有效改善传统方法产生的暗色伪影和色彩失真问题, 在复杂非均匀光照场景下具有更稳定的去雾效果。

关键词

单幅图像去雾, 大气光估计, 自适应预测, 图像恢复, 结构保持

Research on an Adaptive Prediction Algorithm for Atmospheric Light Intensity in Hazy Images

Yu Liu

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

Received: August 16, 2026; accepted: September 9, 2026; published: September 18, 2026

Abstract

To address the limitations of traditional single-image dehazing methods, which typically estimate atmospheric light intensity using a single global parameter and therefore have difficulty adapting

to non-uniform illumination and haze distributions in complex scenes, often resulting in overall darkened dehazed images, local overexposure, and color distortion, this paper proposes a single-image dehazing method based on adaptive atmospheric light intensity prediction. The proposed method models atmospheric light as a spatially varying distribution and dynamically predicts atmospheric light parameters by constructing a spatially adaptive atmospheric light estimation network. Quantitative and qualitative experiments were conducted on two public datasets, SOTS-outdoor and HSTS. The experimental results demonstrate that the proposed method outperforms the traditional DCP method in terms of both image restoration accuracy and structural preservation. The adaptive atmospheric light prediction effectively alleviates dark artifacts and color distortion caused by traditional methods, providing more stable dehazing performance in complex scenes with non-uniform illumination.

Keywords

Single-Image Dehazing, Atmospheric Light Estimation, Adaptive Prediction, Image Restoration, Structural Preservation

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

近年来,随着环境污染问题日益突出,雾霾天气频繁出现,对室外视觉监控、目标识别与跟踪等计算机视觉系统的性能造成了较大影响,同时也给人们的生产生活带来诸多不便。因此,研究高效、可靠的单幅图像去雾方法,对于提升图像视觉质量以及保障相关视觉系统的稳定运行具有重要的理论意义和实际应用价值。目前,通用的图像去雾算法都是基于以下物理模型[1]:

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

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,所有单幅去雾算法本质上都是基于该方程,通过引入不同约束来反演求解清晰图像 $J(x)$ 。

由大气散射模型公式可知传输率 $t(x)$ 与全局大气光 A 是两个核心宏观参数,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[2]。

而全局大气光 A 通常被假设为空间恒定的常量,代表场景中无穷远处环境光强,其数值决定了有

雾图像的整体亮度基线与色彩偏移方向。在实际场景中，大气光通常来自天空光的散射，因此多数算法通过选取图像中最亮的区域估计大气光数值。大气光的估计精度直接影响去雾后图像的色彩保真度，估计值偏高会导致去雾图像整体偏暗，估计值偏低则会出现去雾不彻底的问题。

现针对空间变化大气光 $A(x)$ 的估算，相关学者不断展开研究：Cai 等人[3]实现大气光的端到端一体化预测。为适配真实场景中非均匀光照分布，Wang 等人于 2019 年[4]提出大气光照先验，将大气光信息融入图像到图像的去雾框架，以提升复杂光照条件下的恢复能力。Dhara 等人[5]针对雾图中不同类型的色偏现象，提出依赖色偏特性的自适应大气光细化方法，并结合非线性色彩平衡改善大气光估计结果。针对夜间场景中光源分布不均的问题，Liu 等人[6]进一步对大气光的空间变化进行建模，并结合颜色通道迁移抑制局部人工光源造成的干扰。Zhu 等人[7]则基于颜色平面模型估计雾天图像中的大气光，以增强复杂颜色分布条件下估计的可靠性。近期，Yang 等人[8]引入雾浓度分类先验，根据不同雾密度特征实施相应的快速去雾处理，从而提高非均匀雾霾场景下的适应能力。

上述方法在空间可变大气光的研究上取得了优异效果，但现有研究大多仅局限于空间域内的像素级特征聚合，忽视了频域特征在感知全局背景光照、宏观环境雾浓度分布方面的固有优势。

2. 大气光强的自适应预测算法研究

针对上述问题，本文设计了空间自适应大气光估计网络。该网络将大气光建模为由潜在变量驱动的空间分布，而非单一的全局常量。具体而言，网络包括编码器和解码器以及门控融合三部分。编码器从频域和空域联合提取光照统计特征，并将其映射到潜在空间；解码器进一步从潜在表示中解码出全局大气光、局部大气光图和空间门控图。最终，网络通过门控融合在像素层面自适应协调全局照度一致性与局部光照变化，从而获得更加稳定的大气光估计结果。具体网络结构图如图 1 所示。

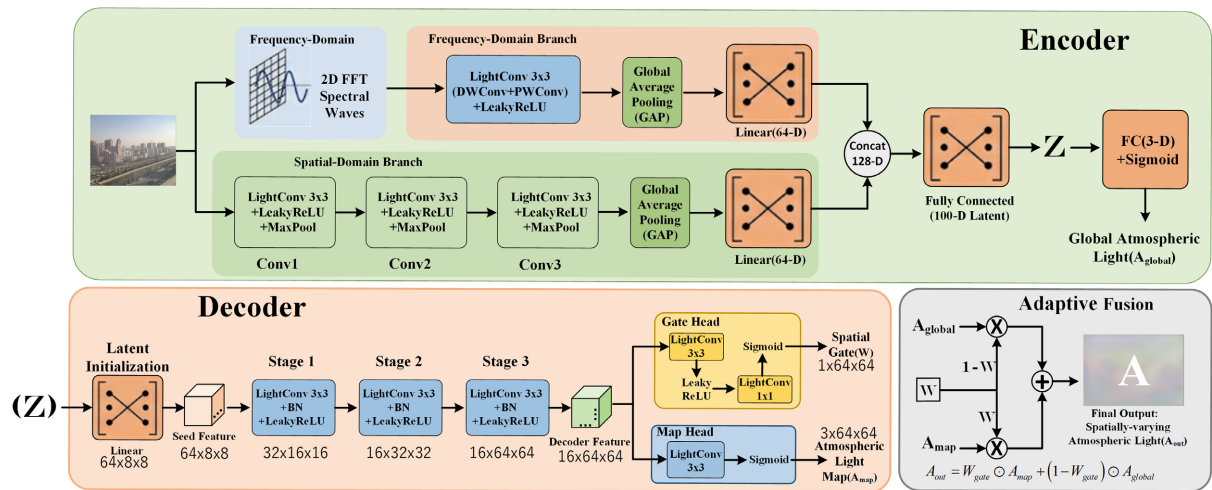


Figure 1. Overall architecture of the adaptive atmospheric light prediction network

图 1. 用于大气光的自适应预测网络总体架构图

2.1. 编码器

如图 1 上侧所示，为了同时捕捉场景的低频光照趋势和高频局部强度，我们将编码器设计为包含频域和空间域的双分支结构。图像的低频分量通常蕴含着全局的照度信息。我们首先引入快速傅里叶变换(FFT)，将输入含雾图像 $I \in \mathbb{R}^{3 \times H \times W}$ 映射到频率域。

$$F_{\text{req}} = \text{FFT}(I) \quad (3)$$

为了自适应地提取与大气光相关的低频特征，我们在频率域中引入了一个可学习的权重矩阵 W_{freq} 进行幅度调制，随后通过逆傅里叶变换(iFFT)将调制后的特征映射回空间域。紧接着，经过一个轻量级卷积块(LConv)处理后，使用全局平均池化(GAP)将其压缩为频率特征向量 $v_{\text{freq}} \in \mathbb{R}^{64}$ 。

$$v_{\text{freq}} = \text{GAP}\left(\sigma\left(f_{\text{LConv}}\left(\text{iFFT}\left(F_{\text{req}} \odot W_{\text{freq}}\right)\right)\right)\right) \quad (4)$$

$\odot$ 表示逐元素相乘， $\sigma(\cdot)$ 为 LeakyReLU 激活函数。

而与频率分支并行，空间域分支负责捕捉局部像素级的强度突变。为了在提取深层特征的同时严格控制模型参数量，我们采用了三个级联的 LConv 块，每个模块包含深度可分离卷积、LeakyReLU 激活和最大池化(MaxPool)。

$$x_{\text{spatial}}^{(i)} = \max \text{Pool}\left(\sigma\left(f_{\text{LConv}}^i\left(x_{\text{spatial}}^{i-1}\right)\right)\right), i \in \{1, 2, 3\} \quad (5)$$

其中 $x_{\text{spatial}}^{(0)} = I$ 。经过三次级联下采样后，同样使用 GAP 操作得到空间特征向量 $v_{\text{spatial}} \in \mathbb{R}^{64}$ 。

最后，我们将 v_{freq} 和 v_{spatial} 在通道维度上进行拼接，并通过全连接层(Linear)将其映射为高斯分布的均值向量 $Z \in \mathbb{R}^{100}$ ，作为解码器的潜在编码。

$$Z = W_{\text{enc}_f} \left[\text{Concat}(v_{\text{spatial}}, v_{\text{freq}}) \right] + b_{\text{enc}_fc} \quad (6)$$

其中 W_{enc_f} 和 b_{enc_fc} 分别为全连接层的权重矩阵和偏置项。

2.2. 解码器

如图 1 下侧所示，解码器主要用于生成门控信号和局部大气光特征图。解码器首先通过一个全连接层将潜在向量 Z 投影，并重塑为一个尺寸固定的紧凑基础特征图 $x_{\text{seed}} \in \mathbb{R}^{64 \times 8 \times 8}$ ，作为空间生成的“全息种子”。

$$x_{\text{seed}} = \text{Reshape}_{64 \times 8 \times 8}(W_{\text{seed}}Z + b_{\text{seed}}) \quad (7)$$

随后， x_{seed} 经过三次级联的双线性插值上采样(Up_{bilinear})和 LConv 卷积层交替处理，逐步恢复其空间分辨率并降低通道数。

$$x_{\text{feat}}^{(j)} = \sigma\left(\text{BN}\left(f_{\text{LConv}}^j\left(Up_{\text{bilinear}}\left(x_{\text{feat}}^{j-1}\right)\right)\right)\right), j \in \{1, 2, 3\} \quad (8)$$

其中， $x_{\text{feat}}^{(0)} = x_{\text{seed}}$ ， $\text{BN}(\cdot)$ 为批量归一化。经过三层解码后，得到高维融合特征 $x_{\text{feat}} \in \mathbb{R}^{16 \times 64 \times 64}$ 。

基于潜在向量 Z 和高维特征 x_{feat} 将它们分为三个并行的预测头：

1. 通过一个独立的全连接层直接从 Z 预测出全局大气光向量 $A_{\text{global}} \in \mathbb{R}^3$ ，代表场景的整体环境光强度。

$$A_{\text{global}} = \text{Sigmoid}(W_{\text{global}}Z + b_{\text{global}}) \quad (9)$$

其中， W_{global} 和 b_{global} 是该独立全连接层的可学习参数。

2. 通过一个 LConv 卷积层从 x_{feat} 预测出具有空间变化的局部大气光图 A_{map} ：

$$A_{\text{map}} = \text{Sigmoid}\left(f_{\text{LConv}_{\text{map}}}\left(x_{\text{feat}}\right)\right) \quad (10)$$

3. 为了在全局与局部之间取得平衡，我们设计了一个空间注意力门控头。该模块首先使用 1×1 的

LConv 进行跨通道交互降维，再通过 3×3 的 LConv 提取局部空间依赖，最终利用 Sigmoid 函数回归出单通道的空间注意力门控图 W_{gate} 。

$$W_{gate} = Sigmoid\left(f_{LConv_3 \times 3}\left(\sigma\left(f_{LConv_1 \times 1}(x_{feat})\right)\right)\right) \quad (11)$$

为了适应不同尺寸的输入图像，我们通过双线性插值将 A_{map} 和 W_{gate} 动态上采样至输入图像尺寸。最终的精细大气光估计图 A_{out} 由 A_{global} 和 A_{map} 根据门控权重 W_{gate} 逐像素自适应融合而成：

$$A_{out} = W_{gate} \odot A_{map} + (1 - W_{gate}) \odot Expand(A_{global}) \quad (12)$$

其中， $Expand(\cdot)$ 表示将三通道的向量在空间维度上扩展至与 A_{map} 相同的尺寸。这种门控融合机制使得网络能够自适应地处理复杂光源，在均匀雾气区域倾向于依赖 A_{global} 保持色调稳定，而在光源突变区域则提高 W_{gate} 的响应，利用 A_{map} 拟合高频光照变化。

通过上述设计，大气光估计分支能够从单一全局参数估计扩展为空间自适应预测。编码器负责提取全局照度趋势与局部光照变化，解码器则通过空间门控在全局大气光和局部大气光之间进行逐像素融合。由此，网络能够根据不同区域的光照条件和雾气分布动态调整大气光估计，缓解局部过曝光、颜色偏移和对比度失衡等问题，为复杂真实场景下的稳定去雾提供更可靠的物理参数支持。

2.3. 透射图预测

本文采用传统暗通道先验(DCP)方法估计透射率图 $t(x)$ 。对于输入含雾图像 $I(x)$ ，首先计算其暗通道：

$$I^{dark}(x) = \min_{y \in \Omega(x)} \left(\min_{c \in \{r, g, b\}} I^c(y) \right) \quad (13)$$

根据暗通道先验理论，在无雾区域暗通道值趋近于零，因此可以利用暗通道估计初始透射率：

$$t(x) = 1 - \omega \min_{y \in \Omega(x)} \left(\min_c \frac{I^c(y)}{A^c} \right) \quad (14)$$

其中， ω 为雾保留系数，通常取 0.95。

2.4. 损失函数

本文所使用的损失主要为**图像重构损失**(L_{rec})。给定输入含雾图像 I ，网络预测的去雾图像 J 、透射率 t 以及大气光 A ，基于大气散射模型的重构损失 L_{rec} 定义为：

$$L_{rec} = \|J \odot t + A \odot (1 - t) - I\|_2^2 \quad (15)$$

该损失强制网络输出的三要素能够严格重构回原始输入图像，是保证基本成像关系的底层物理约束。

3. 实验部分

3.1. 数据集和评估指标

为全面评估所提出方法的有效性，本文在具有代表性的公开图像去雾基准数据集上进行了实验，包括 SOTS-outdoor 和 HSTS [9]。为保证比较的公平性，本文未引入自定义测试集，而是遵循已有工作的常用实验设置，在公开基准上进行定量和定性评估。

1. SOTS-outdoor 是 RESIDE (REalistic Single Image DEhazing) 基准中广泛使用的户外测试集之一。该数据集包含 500 对合成含雾图像及其对应的清晰图像，主要覆盖户外城市场景、建筑结构和不同深度变化。由于其提供配对的无雾参考图像，SOTS-outdoor 常用于评估去雾模型在合成户外场景下的恢复精度

和结构保真能力。

2. HSTS 同样来源于 RESIDE 基准, 包含合成与真实场景图像, 旨在评估去雾方法在更复杂场景中的泛化能力。该数据集包含具有复杂光照、天空区域和非均匀雾气分布的户外图像, 场景类型涵盖城市、植被和道路等。通过在 HSTS 上进行测试, 可以进一步分析模型在复杂背景以及非均匀雾气条件下的视觉恢复效果。

而本文采用的评价指标为峰值信噪比(PSNR)、结构相似度(SSIM):

1. PSNR (Peak Signal-to-Noise Ratio)用于衡量去雾结果与真实无雾图像之间的像素级误差。给定真实的清晰图像 I_{gt} 和网络输出的去雾图像 I_{out} , PSNR 定义为:

$$MSE = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W [I_{gt}(i, j) - I_{out}(i, j)]^2 \quad (16)$$

$$PSNR = 10 \cdot \log_{10} \left(\frac{\max_I^2}{MSE} \right) \quad (17)$$

其中 $\max_I$ 是图像像素的最大可能值(对于 8 位图像, 通常为 255)。PSNR 的值越大, 表明恢复图像与参考图像之间的像素误差越小。

2. SSIM (Structural Similarity Index)从亮度、对比度和结构三个方面衡量两幅图像之间的相似性, 能够更好地反映图像结构保持程度。其定义为:

$$SSIM(I_{gt}, I_{out}) = \frac{(2\mu_{gt}\mu_{out} + C_1)(2\sigma_{gt,out} + C_2)}{(\mu_{gt}^2 + \mu_{out}^2 + C_1)(\sigma_{gt}^2 + \sigma_{out}^2 + C_2)} \quad (18)$$

其中 μ_{gt} 和 μ_{out} 分别是 I_{gt} 和 I_{out} 的局部均值, σ_{gt}^2 与 σ_{out}^2 是对应的局部方差, $\sigma_{gt,out}$ 是两者的协方差。 C_1 和 C_2 为稳定常数。SSIM 值越接近 1, 表示恢复结果的结构保真度越高。

3.2. 实现细节

本文方法基于 PyTorch 深度学习框架实现, 训练过程在 NVIDIA 3090 GPU 环境下完成。输入图像首先统一调整至固定尺寸, 并进行随机裁剪、随机水平翻转等数据增强操作, 以提高模型对不同场景的适应能力。在训练阶段, 本文采用 Adam 优化器对网络参数进行更新, 其初始学习率设置为 1×10^{-4} , 权重衰减系数设置为 1×10^{-5} 。模型训练共进行 200 轮(epochs), 并采用学习率衰减策略动态调整优化过程。

3.3. 实验结果的定量与定性分析

图 2 展示了所提出大气光自适应方法在 SOTS-outdoor 和 HSTS 数据集上的可视化对比结果。可以观察到, 传统的 DCP 方法在去雾过程中引入了明显的视觉退化, 结果中存在着大面积的暗色伪影, 其中一个重要原因是传统方法采用单一的全局大气光估计值, 直接影响了去雾后图像的色彩保真度, 并且会导致去雾图像整体偏暗。而我们的方法通过将大气光建模为动态的空间分布, 设计编码器从频域和空域联合提取光照统计特征, 设计解码器进一步从潜在表示中解码出全局大气光、局部大气光图 and 空间门控图, 最终通过门控融合在像素层面自适应协调全局照度一致性与局部光照变化, 从而获得更加稳定和准确的大气光估计结果。从图中能够明显看到, 我们的方法通过自适应预测大气光得到的去雾图十分接近数据集提供的清晰图, 因此验证了自适应大气光方法在视觉效果方面的优越性。

而表 1 中两个数据集上的定量结果也表明, 自适应大气光预测方法相比传统方法具有更好的去雾性能。SOTS-outdoor 数据集上取得了较高的 PSNR 值(22.20)和 SSIM 值(0.8785), 表明经过大气光自适应预测的去雾图具有较好的像素恢复精度和结构保持能力。同时在 HSTS 数据集上也取得了令人满意的结果。



Figure 2. Visual comparison of the proposed adaptive atmospheric light prediction method and the traditional DCP method on the SOTS-outdoor and HSTS datasets

图 2. 所提出的自适应预测大气光方法与传统 DCP 方法在 SOTS-outdoor 和 HSTS 数据集上的视觉效果对比

Table 1. Comparison of the proposed adaptive atmospheric light prediction method and the traditional DCP method on the SOTS-outdoor and HSTS datasets based on PSNR and SSIM evaluation metrics

表 1. 所提出的自适应预测大气光方法与传统 DCP 方法在 SOTS-outdoor 和 HSTS 数据集上的基于 PSNR 和 SSIM 评价指标对比

方法	SOTS-outdoor		HSTS	
	PSNR ↑	SSIM ↑	PSNR ↑	SSIM ↑
传统的 DCP 方法	16.82	0.8419	16.86	0.8376
我们的大气光自适应方法	22.20	0.8785	22.36	0.8819

4. 结论

综上所述，本文提出的自适应大气光预测方法能够有效缓解传统单一大气光估计带来的亮度偏暗、色彩偏移和局部光照适应能力不足等问题，并在不同类型的公开数据集上表现出较好的恢复性能，验证了频域与空域联合特征以及空间门控融合机制在大气光估计中的有效性。该方法为复杂真实场景下的单幅图像去雾提供了一种具有一定应用潜力的大气光参数估计思路。

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] 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>

-
- [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] Wang, A., Wang, W., Liu, J. and Gu, N. (2019) AIPNet: Image-to-Image Single Image Dehazing with Atmospheric Illumination Prior. *IEEE Transactions on Image Processing*, **28**, 381-393. <https://doi.org/10.1109/tip.2018.2868567>
 - [5] Kanti Dhara, S., Roy, M., Sen, D. and Kumar Biswas, P. (2021) Color Cast Dependent Image Dehazing via Adaptive Airlight Refinement and Non-Linear Color Balancing. *IEEE Transactions on Circuits and Systems for Video Technology*, **31**, 2076-2081. <https://doi.org/10.1109/tcsvt.2020.3007850>
 - [6] Liu, S., Hao, Q., Zhang, Y., Gao, F., Song, H., Jiang, Y., *et al.* (2023) Single-Image Night Haze Removal Based on Color Channel Transfer and Estimation of Spatial Variation in Atmospheric Light. *Defence Technology*, **25**, 134-151. <https://doi.org/10.1016/j.dt.2022.05.008>
 - [7] Zhu, M., He, B. and Zhang, L. (2017) Atmospheric Light Estimation in Hazy Images Based on Color-Plane Model. *Computer Vision and Image Understanding*, **165**, 33-42. <https://doi.org/10.1016/j.cviu.2017.09.005>
 - [8] Yang, Y., Zhang, J., Wang, Z. and Zhang, H. (2023) Single Image Fast Dehazing Based on Haze Density Classification Prior. *Expert Systems with Applications*, **232**, Article 120777. <https://doi.org/10.1016/j.eswa.2023.120777>
 - [9] Li, B., Ren, W., Fu, D., Tao, D., Feng, D., Zeng, W., *et al.* (2019) Benchmarking Single-Image Dehazing and Beyond. *IEEE Transactions on Image Processing*, **28**, 492-505. <https://doi.org/10.1109/tip.2018.2867951>