

引用格式: 魏赞, 卢可可, 丁元, 等. 二阶段沙尘降质图像增强算法 [J]. 电子科技大学学报, 2026, 55(2): 191-200.

WEI Y, LU K K, DING Y, et al. Two-stage dust-degraded image enhancement algorithm[J]. Journal of University of Electronic Science and Technology of China, 2026, 55(2): 191-200.

## 二阶段沙尘降质图像增强算法



魏 赞, 卢可可\*, 丁 元, 尹 杰, 邬开俊

(兰州交通大学电子与信息工程学院, 兰州 730070)

**摘要:** 针对沙尘降质图像存在色偏、对比度低和能见度差等问题, 提出二阶段沙尘降质图像增强算法。算法包含沙尘图像颜色校正算法和基于残差融合的尘雾去除网络。第 1 阶段提出在沙尘降质图像的 Lab 颜色空间中用以图像饱和度为权重的加权灰色世界理论进行颜色校正, 有效解决沙尘降质图像色偏问题。第 2 阶段设计基于残差融合的尘雾去除网络提升图像对比度和清晰度。实验结果表明, 算法可以有效去除色偏问题, 并在提高图像对比度的同时增强图像细节的可见度, 相比对比实验结果, 该文算法的 PSNR 和 SSIM 分别提高 2.338 0% 和 3.066 2%。

**关键词:** 沙尘降质图像; 图像增强; 加权灰色世界理论; 颜色校正; 残差融合

中图分类号: TP751.1; R318

文献标志码: A

DOI: 10.12178/1001-0548.2024325

## Two-stage dust-degraded image enhancement algorithm

WEI Yun, LU Keke\*, DING Yuan, YIN Jie, and WU Kaijun

(School of Electronics and Information Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China)

**Abstract:** To address the issues of color bias, low contrast and poor visibility in dust-degraded images, a two-stage dust-degraded image enhancement algorithm is proposed. The algorithm comprises a dust-degraded image color correction algorithm and a residual fusion-based haze removal network. In the first stage, a weighted gray-world theory based on image saturation in the Lab color space is proposed for color correction, effectively addressing the color bias issue in dust-degraded image. In the second stage, a residual fusion-based dust and haze removal network is designed to enhance the contrast and clarity of the images. The experimental results show that the algorithm can effectively remove color bias and enhance the visibility of image details while improving image contrast. Compared to the best results from the comparative experiments, the proposed algorithm improves PSNR and SSIM by 2.338 0% and 3.066 2%, respectively.

**Key words:** dust-degraded image; image enhancement; weighted gray-world theory; color correction; residual fusion

在沙尘天气的影响下, 大气光中蓝色、绿色光线被沙尘吸收的速度远比红光和黄光快, 色彩通道一致性遭到破坏; 此外, 大气中干燥的沙土、矿物粉尘等粗颗粒会与空气中的雾、霾相互混合, 进而形成尘雾。因此成像设备获取的图像总是存在颜色偏差、对比度低、清晰度下降和识别性差等问题, 在遥感任务、道路监控中发挥不利作用, 严重干扰智能信息处理系统的性能。所以, 沙尘降质图像的质量增强技术是图像处理和计算机视觉领域的一个

重要研究课题。目前可用于图像去沙的主流算法大致可以分为: 图像增强方法、图像恢复方法和基于数据驱动的方法。

图像增强方法主要通过传统图像处理算法提高沙尘降质图像的清晰度与对比度。文献 [1] 提出一种基于归一化伽马变换的对比度受限自适应直方图均衡化 (CLAHE), 在 Lab 颜色空间中进行颜色校正, 用于沙尘降质图像增强。文献 [2] 提出使用连续的色彩平衡和重合的色彩直方图, 同时引入一

收稿日期: 2024-11-28

基金项目: 内蒙古自治区重点研发与成果转化计划 (2023YFSH0043, 2023YFDZ0043); 全国高等院校计算机基础教育研究会项目 (2023-AFCEC-039); 甘肃省教育厅高校教师创新基金项目 (2025A-054)

作者简介: 魏赞, 博士, 副教授, 主要从事车联网、智能交通与图像处理方面的研究。

\*通信作者 E-mail: lukeke\_1@163.com

种基于色彩直方图 SD 的像素自适应颜色校正算法, 然后采用绿色均值保持归一化技术, 最后引入基于直方图匹配的颜色校正技术, 使红色、蓝色直方图最大限度与绿色直方图重叠。文献 [3] 利用新亮度、原始图像的亮度与 RGB 分量值之比相乘, 计算新的值, 来进行色彩失真调节。上述增强方法采用图像处理理论来优化图像的颜色和对比度, 能在一定程度上提高图像的清晰度, 增强后图像在视觉上仍是模糊的, 且并没有全面考虑到沙尘降质图像的退化机制, 不足以面对复杂多变的沙尘场景。

图像恢复旨在从退化观测中重建清晰的图像, 主要方法是依靠大气散射模型<sup>[4]</sup>, 该模型被广泛用于描述雾霾天气的成像过程。这些图像恢复算法利用先验知识来估计中间参数, 然后将其带入大气散射模型用于恢复图像。在图像恢复算法中, 研究人员首先设计了颜色校正算法来进行平衡沙尘降质图像的色调, 然后通过 DCP<sup>[5]</sup> 估计大气光值和透射图必要参数, 最后, 将参数代入退化模型, 恢复无尘的图像。文献 [6] 提出了基于暗通道先验和颜色校正加权最小二乘滤波的去雾算法, 涉及颜色透射图的自动检测。文献 [7] 考虑到蓝色通道衰减可能导致 DCP 恢复方法失败, 提出基于逆转蓝色通道先验的沙尘降质图像恢复方法。文献 [8] 提出基于色偏校正与光晕减少 DCP 去雾的沙尘降质图像增强算法, 使用 Gamma 函数对比 Lab 颜色空间中的拉伸。上述方法将沙尘降质图像特有的退化机制与传统图像增强技术相结合, 从而显著改善了图像的颜色失真和模糊问题。然而, 在复原过程中, 由于计算误差的逐步累积, 使得最终输出的图像存在明显的噪声, 同时不准确的中间参数估计可能会导致图像暗色调和伪影。

基于数据驱动的深度学习技术在解决沙尘降质图像增强任务方面得到了广泛关注, 文献 [9] 提出基于融合策略的沙尘降质图像重构算法, 将去沙尘任务拆解为去沙和去尘, 首先使用改进的高斯模型均衡沙尘图像色偏问题, 然后通过雾霾图像训练得到的网络模型消除尘造成的视觉影响以提高图像清晰度。文献 [10] 提出一种端到端模型 TOENet, 基于多层感知器的通道相关提取模块来学习和重建低能见度图像通道之间的相关性, 用来恢复沙尘图像。文献 [11] 提出多分支修复网络, 包含迁移学习、色彩恢复和数据拟合 3 个子网, 通过可学习融合层将各个子网结果合成清晰图像。由于沙尘降质图像退化场景建模困难、关键参数估计复杂, 加之

缺乏有效的成对训练数据集, 深度学习技术在该领域的发展较为缓慢。

相较于去沙尘, 基于深度学习的去雾算法取得了较好成效。文献 [12] 提出 ChaIR 去雾算法, 在频域和空间域交互使用通道注意力机制, 在多种图像恢复任务中取得较好效果。文献 [13] 提出了端到端特征融合注意力网络 FFA-Net, 对雾霾图像取得了清晰的效果。文献 [14] 提出基于对比学习的单幅图像修复网络 AECR-Net, 比 FFA-Net 取得了更佳的图像去雾效果。文献 [15] 提出基于物理感知的课程对比正则化的去雾网络 C<sup>2</sup>PNet, 显著提高了图像去雾效果。虽然现有单幅图像去雾算法在针对雾霾图像时有较好进展, 但是若将去雾方法直接应用到沙尘降质图像颜色校正后的处理上, 可能会导致输出图像的色彩出现不同程度的失真, 此外, 处理后的图像在清晰度方面也不尽如人意。

针对当前沙尘降质图像增强算法面对真实场景沙尘图像处理时依旧存在颜色失真、对比度提高不明显以及细节丢失等问题, 本文提出二阶段沙尘降质图像增强算法。

## 1 本文总体结构

本文提出的二阶段沙尘降质图像增强算法, 将传统颜色校正方法与基于数据驱动的深度学习方法相结合, 提高沙尘降质图像的可见性, 该方法原理如图 1 所示。

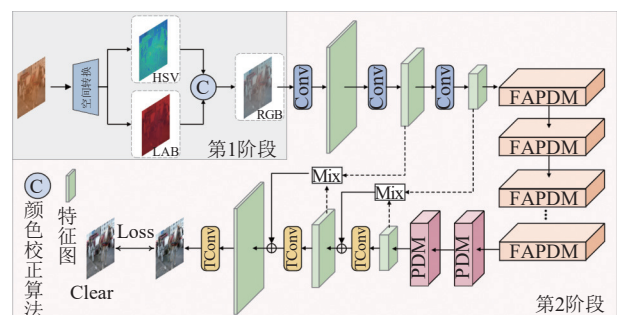


图 1 二阶段沙尘降质图像增强算法

提出算法包括第 1 阶段颜色校正预处理算法和第 2 阶段基于残差融合的尘雾去除网络。第 2 阶段中 FAPDM 表示的是特征注意力参数双分支模块（feature attention parameter dual-branch model）；PDM 表示的是参数双分支模块（parameter dual-branch model）。

### 1.1 颜色校正算法

直接使用合成沙尘数据集<sup>[11]</sup>所训练的基于残

差融合的尘雾去除网络, 对沙尘图像增强并不能产生满意的效果, 因此先对沙尘降质图像进行颜色校正是有必要的。对于沙尘图像的颜色校正, 最常用的传统方法是自动白平衡算法中的灰色世界理论<sup>[16]</sup>, 传统的灰色世界理论是基于颜色通道中 RGB 彩色图像的平均值相等的假设。然而, 这一假设一般情况下并不成立, 为了改进它的不足, 提出以图像饱和度为权重因子的加权灰色世界理论进行颜色校正, 以更好地反映场景中颜色通道的重要性。高饱和度表示场景中颜色鲜艳的部分; 低饱和度区域是接近灰色区域, 更加接近真实世界的光照条件。以饱和度为权重的加权灰色世界理论给予低饱和度的像素更高的权重, 给予高饱和度像素较低的权重, 从而降低高饱和度像素的影响, 更好地适应沙尘降质的图像特点以校正色偏。

颜色校正算法如图 2 所示, 将图片从 RGB 空间转换到 HSV 色彩空间。HSV 色彩空间中,  $H$  表示色相分量及颜色的种类,  $S$  表示饱和度分量,  $V$  表示亮度分量。其中,  $S$  也通常被认为直观地反映了人类视觉系统对饱和度的感知。




图 2 颜色校正算法

因此, 使用 HSV 色彩空间中的饱和度分量进行计算, 将饱和度归一化为权重, 具体实现如式 (1) 和式 (2) 所示:

$$S = \frac{\max(R, G, B) - \min(R, G, B)}{\max(R, G, B)} \quad (1)$$

$$\omega = 1 - \frac{S}{\max(S)} \quad (2)$$

式中,  $S$  表示的是 HSV 色彩空间的饱和度;  $\max(S)$  是图像中饱和度的最大值; 饱和度  $S$  归一为权重  $\omega$ 。

在 RGB 颜色空间中, 不同颜色通道的变换不是线性变化, 进行上述颜色校正会导致 RGB 颜色空间颜色失真。然而 Lab 颜色空间特性, 其颜色变换是  $a$  和  $b$  分量的线性变换。Lab 颜色空间中,  $L$  表示亮度,  $a$  的正值为红色, 负值为绿色;  $b$  的正值

为黄色, 负值为蓝色。通过调节  $L$  通道进行亮度调节, 通过调节  $a$  和  $b$  来调节色彩平衡, 且两者互不影响。因此, 本文算法将沙尘降质图像从 RGB 颜色空间转换到 Lab 颜色空间, 并对 Lab 颜色空间中的  $a$  和  $b$  使用基于加权灰色世界理论的白平衡算法来调节  $a$  和  $b$  颜色分量, 得到颜色校正后的图像, 其具体实现如式 (3) 和式 (4) 所示:

$$\begin{cases} a_{\text{avg\_weighted}} = \frac{\sum(a\omega)}{\sum\omega} \\ b_{\text{avg\_weighted}} = \frac{\sum(b\omega)}{\sum\omega} \end{cases} \quad (3)$$

$$\begin{cases} a' = a - a_{\text{avg\_weighted}} \\ b' = b - b_{\text{avg\_weighted}} \end{cases} \quad (4)$$

综上, 颜色校正算法首先将沙尘降质图像从 RGB 空间转换到 HSV 空间获得饱和度信息, 计算出权重  $\omega$ , 同时转换为 Lab 颜色空间并分离  $L$ 、 $a$ 、 $b$  这 3 个分量, 并对  $a$  和  $b$  分量进行加权平均后得到  $a_{\text{avg\_weighted}}$ 、 $b_{\text{avg\_weighted}}$ 。然后, 对  $a$  和  $b$  分量减去加权平均值, 得到新的颜色校正值  $a'$ 、 $b'$ , 使得图像的平均  $a$ 、 $b$  分量趋向于 0, 实现白均衡效果。最后, 转换到 RGB 空间, 完成对沙尘降质图像颜色的校正, 除去了沙尘降质图像偏黄或偏橘色调, 并且不会改变原图像中的物体颜色。

## 1.2 基于残差融合的尘雾去除网络

上述算法对沙尘降质图像进行颜色校正操作后, 图像从原先的偏橘或偏黄色调转换为灰暗或偏白色调, 图像对比度低且图像模糊, 如图 3 所示。真实、合成沙尘降质图像直方图分布中显示三通道依次按照红、绿、蓝的顺序排列, 两者颜色校正后的图像与真实雾霾图像的颜色直方图分布类似, 三通道按照蓝、绿、红的顺序排列, 但与合成雾霾图像的颜色直方图分布存在一些细微差异。受此启发, 设计了一个基于残差融合的尘雾去除网络, 去除尘雾的同时进一步提高图像的对比度和清晰度。

设计的基于残差融合的尘雾去除网络中, 特征注意力参数双分支模块 FAPDM 作为网络构架的基本块, 其包含 2 个卷积层、1 个激活函数, 1 个特征注意力机制模块<sup>[14]</sup> (feature attention model, FAM)。考虑沙尘降质图像颜色校正之后类雾霾的特征, 以雾霾先验知识为指导, 提出一个参数双分支模块 PDM, 促进特征空间中的特征传输和提

取, 更好地提高沙尘降质图像的对比度和清晰度, 结构如图 4 所示。其中, FAM 模块由通道注意力机制 (channel attention, CA) 和像素注意力机制 (pixel attention, PA) 组成, 串联两者并为通道特

征和像素特征分配不同的权重, 使得特征注意力机制模块可以灵活处理不同类型的信息, 有效避免去尘雾网络中平等对待通道和像素特征而忽略尘雾分布不均匀的情况。

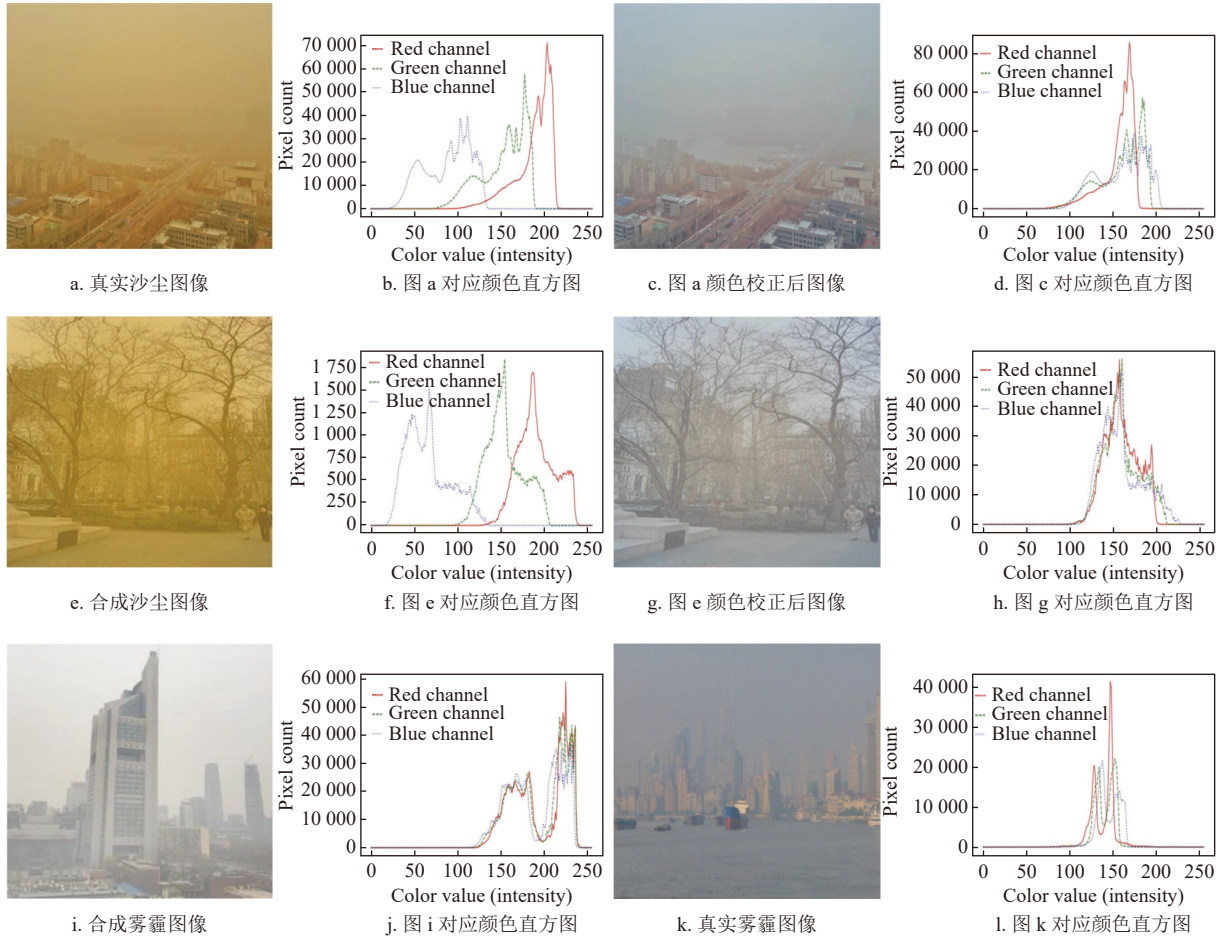


图 3 各场景颜色直方图

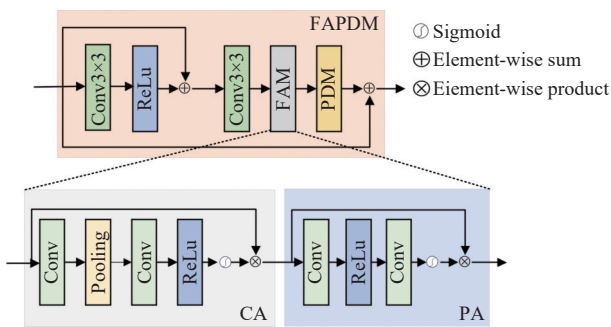


图 4 FAPDM 模块结构

通道注意力机制首先使用全局平均池化提取通道级的全局信息, 同时减少网络的参数。然后, 将特征图经过 2 个卷积层和 Sigmoid、Relu 激活函数, 为不同通道进行不同权重分配。最后, 将通道注意力输入与权重进行逐元素相乘, 为通道特征分

配不同权重, 其通道注意力机制表示如式 (5) 和式 (6) 所示:

$$CA = \sigma(\text{Conv}(\delta(\text{Conv}(P(F)))))) \quad (5)$$

$$F' = CA \otimes F \quad (6)$$

式中,  $F$  表示输入特征;  $F'$  表示通道注意力输出特征;  $P$  表示自适应平均池化层;  $\sigma$ 、 $\delta$  分别表示 Sigmoid 函数、Relu 函数;  $\otimes$  表示逐元素相乘。

像素注意力机制串联在通道注意力机制之后, 将通道注意力的输出经过具有 Relu、Sigmoid 激活函数的卷积层中, 并将通道注意力的输出与像素注意力的输出进行相乘, 得到特征注意力机制模块的输出。其像素注意力机制表示如式 (7) 和式 (8) 所示:

$$PA = \sigma(\text{Conv}(\delta(\text{Conv}(F')))) \quad (7)$$

$$\bar{F} = \mathbf{PA} \otimes F' \quad (8)$$

式中,  $\bar{F}$  表示特征注意力机制的输出特征;  $\mathbf{PA}$  表示像素注意力机制的输出特征。

PDM 模块受大气散射模型启发, 大气散射模型表示为式 (9) 和式 (10):

$$I(x) = T(x)J(x) + (1 - T(x))A \quad (9)$$

$$T(x) = e^{-\beta d(x)} \quad (10)$$

式中,  $I(x)$  为成像的雾霾图像;  $J(x)$  表示清晰图像;  $A$  表示大气中的环境光, 通常近似为天空的颜色;  $T(x)$  表示在位置  $x$  处的投射, 是光衰减的指数衰减项;  $\beta$  表示光谱衰减系数;  $(1 - T(x))A$  是受到浮动气溶胶反射太阳光而散射出的附加光, 除去散射光线, 即没有散射情况下到达相机的场景辐照度数量。想要恢复无尘雾图像, 需要估计大气透射率和大气光强度, 但是这是一个不适定的问题。

直接估计原始空间的  $T$  和  $A$  容易导致累积误差, 而在特征空间中施加物理先验可以促进与雾霾过程相一致的可解释性, 这样就不直接依赖原始图像对大气透射率和大气光强度的估计。经过运算, 得到新的计算清晰图像的公式, 如式 (11) 所示:

$$J' = M \odot t + A'(1 - t) \quad (11)$$

式中,  $M$  表示输入特征;  $\odot$  表示 Hadamard 乘积;  $A'$  表示与大气光对应的特征近似值;  $t$  表示与投射图相关的近似值, 假设  $t$  和  $M$  的通道数匹配。

PDM 模块主要由 2 个分支构成, 主要结构如图 5 所示。




图 5 PDM 模块结构

上面分支利用含有激活函数的卷积层提取特征空间的  $t$ , 使用较大卷积核提取大尺度特征, 利于捕捉图像整体结构特征。下面分支用于生成  $A$ , 由于大气散射模型中假设大气光为均匀分布, 为避免学习特征时引入不必要的信息, 添加全局平均池化层, 以消除特征空间的冗余信息、提高效率。利用 PDM 模块, 可以从输入特征  $M$  中生成可解释性

特征  $J'$  来恢复尘雾图像, 有效结合  $t$  和  $A'$  这 2 个因素相应的物理特征, 允许在双重交互中估计更加有用的特征来恢复尘雾图像, 具体如式 (12) 和式 (13) 所示:

$$A' = H(\sigma(\text{Conv}^N(\delta(\text{Conv}^{\frac{N}{8}}(\text{GAP}(M)))))) \quad (12)$$

$$t = \sigma(\text{Conv}^N(\delta(\text{Conv}^{\frac{N}{8}}(\text{Conv}^N(M)))))) \quad (13)$$

式中,  $\sigma$  表示 Sigmoid 函数;  $H$  表示复制操作;  $\text{Conv}^{\frac{N}{8}}$  是具有  $N$  卷积核的卷积层, 设置为 256。

同时, FAPDM 模块中包含局部残差学习, 通过多个局部残差连接, 一方面避免图片的特征丢失, 另一方面使得主干网络更加关注尘雾较浓或高频区域等比较重要的信息。

整体尘雾去除网络架构先进行下采样操作, 通道数从 3 变换至 256, 将低分辨率空间中提取的特征传入 6 块 FAPDM 模块中进行特征学习, 接下来连接 2 个 PDM 模块进行估计有用特征, 然后利用相应的上采样生成恢复后的图像。为了提高层之间的信息流并融合更多空间结构化信息, 引入自适应混合动态融合<sup>[13]</sup>来融合下采样层和上采样层之间的特征, 保持图像特征, 提高网络的鲁棒性, 加快网络的收敛速度。轮廓边缘等低级特征主要在卷积层浅层捕获, 随着网层数的增加, 网络深度也随之增加, 导致浅层的特征也逐渐减少。为了避免浅层特征随着网络深度的增加而丢失, 在 2 个下采样和 2 个上采样层应用自适应性混合操作融合信息, 表示为式 (14) 和式 (15):

$$F_1 = \text{Mix}(f_1, f_1') = \sigma(\theta_1) * f_1 + (1 - \sigma(\theta_1)) * f_1' \quad (14)$$

$$F = \text{Mix}(f_2', F_1) = \sigma(\theta_2) * F_1 + (1 - \sigma(\theta_2)) * f_2' \quad (15)$$

式中,  $f$  表示第 1 个下采样的特征图;  $f_i'$  表示与上采样对应第  $i$  个上采样层的特征图;  $F_1$  表示第 1 个上采样和下采样自适应混合后的结果特征图;  $F$  表示最终融合输出, 其中  $\sigma(\theta_i)$  ( $i=1, 2$ ), 为第  $i$  个可学习的因子, 用于融合对应的第  $i$  个上采样层和第  $i$  个下采样层的输入, 其值主要由 Sigmoid 的  $\sigma$  算子决定。在模型训练期间, 能够有效学习这 2 个可学习因子, 相较于常数因子可使模型获得更优的性能。

### 1.3 损失函数

#### 1.3.1 优化 L1 损失

本文使用优化 L1 损失函数<sup>[13]</sup>作为算法的损失

函数, 现有文献 [17] 表明, 与大多数单幅图像去雾任务所采用 L2 损失和均方误差 (MSE) 作为损失函数相比, 使用 L1 损失训练的图像恢复任务, 在峰值信噪比和结构相似指数指标上可取得更优的性能。具体实现表示为:

$$L(\theta) = \frac{1}{N} \sum_{i=1}^N \left\| I_{\text{gt}}^i - \text{Net}(I_{\text{hazy}}^i) \right\| \quad (16)$$

式中,  $\theta$  表示整体网络架构的参数;  $I_{\text{hazy}}$  和  $I_{\text{gt}}$  分别表示输入模糊图像和原始图像。

### 1.3.2 MS-SSIM 损失

引入多尺度结构相似度 (MS-SSIM) [18], 先计算像素的 SSIM 值:

$$\text{SSIM}(i) = \frac{2\mu_H\mu_O + R_1}{\mu_H^2 + \mu_O^2 + R_1} \times \frac{2\sigma_{HO} + R_2}{\sigma_H^2 + \sigma_O^2 + R_2} \quad (17)$$

式中,  $H$ 、 $O$  表示两个固定大小窗口, 分别以增强图像和清晰图像中的当前像素  $i$  为中心;  $R_1$ 、 $R_2$  是 2 个小常数; 对窗口应用高斯滤波器之后计算相应均值  $\mu_H$ 、 $\mu_O$ 、标准差  $\sigma_H$ 、 $\sigma_O$ 、协方差  $\sigma_{HO}$ 。MS-SSIM 损失描述为:

$$L_{\text{MS-SSIM}} = 1 - \prod_{s=1}^S (l^\alpha(i) c s^{\beta_s}(i)) \quad (18)$$

式中,  $S$  表示尺度的总数;  $\alpha$ 、 $\beta$  表示默认参数。

综上, 用于端到端网络的总损失表示为:

$$L = L_1(\theta) + \lambda L_{\text{MS-SSIM}} \quad (19)$$

式中,  $\lambda$  为平衡损失比例的超参数, 设置为 0.2。

## 2 实验与结果

### 2.1 数据集和训练细节

文献 [9] 使用 RESIDE 数据集训练深度学习网络。由于合成沙尘雾霾数据集的颜色直方图分布与真实沙尘降质图像颜色校正之后的颜色直方图分布存在一定差异, 网络无法准确学到真实的相关信息, 尘雾去除效果不佳。但真实沙尘降质图像颜色校正之后的颜色直方图分布与合成沙尘数据集 [11] 颜色校正之后的图像颜色直方图分布有较高的相似度, 因此, 为第 2 阶段网络构建训练数据集, 如图 6 所示, 将现有合成沙尘数据集经过基于加权灰色世界理论进行颜色校正预处理, 即第 1 阶段的输出图像作为第 2 阶段的训练输入图像, 且训练图片分辨率大小都为  $256 \times 256$ 。此外, 从合成沙尘数据集的 10 000 张图片中挑出 1 000 张作为测试集; 真实数据集通过网络搜集 80 张图像用于测试, 另外

测试数据和真实沙尘降质数据均采用的分辨率为  $1\ 600 \times 1\ 200$ 。



图 6 部分构建训练数据集

基于残差融合的尘雾去除网络中批次大小设置为 1,  $1.0 \times 10^6$  步的训练, 使用 Adam 优化器, 其中  $\beta_1$  和  $\beta_2$  分别取 0.9 和 0.999, 初始学习率设置为  $1 \times 10^{-4}$ , 算法采用余弦退火策略, 遵循余弦函数将初始值调整为 0, 如式 (20) 所示:

$$\lambda_n = \frac{1}{2} \left( 1 + \cos \left( \frac{n\pi}{N} \right) \right) \lambda \quad (20)$$

式中,  $N$  表示批次总数;  $\lambda$  表示初始收益率。本文算法在一个 NVIDIA GeForce RTX 4060 Laptop GPU 上使用 PyTorch 11.8 实现。

### 2.2 实验结果与分析

将本文方法与传统算法和基于深度学习的图像去雾、去沙算法进行比较, 选择 6 种算法从定性和定量两方面对测试结果进行比较。其中, 3 种为典型的传统算法, 包括 Park<sup>[2]</sup>、CLAHE<sup>[19]</sup>、MSRCR<sup>[3]</sup>; 3 种为基于深度学习的算法, 包括 CHaIR<sup>[12]</sup>、TOENet<sup>[10]</sup>、FFA-Net<sup>[13]</sup>。

#### 2.2.1 合成数据集实验结果

合成沙尘数据集的定性比较结果如图 7 所示, 定量比较如表 1 所示, 定量结果主要采用峰值信噪比 (PSNR) 和结构相似指数 (SSIM) 作为评价指标。结合图 7 和表 1 可以看出, 在 3 种传统算法中, Park 方法都取得了最好的结果, 明显改善了图像的色偏问题, 但是该方法保持绿色直方图的均值, 因此图片中间部分还有一些沙尘浮色, 不利于色彩恢复; MSRCR 方法由于对图像动态范围压缩, 易出现像素负值, 处理结果较为暗沉, 部分会有颜色失真的问题; CLAHE 增强图像局部对比度, 因此处理结果中放大背景噪声, 从而影响到图像质量, 出现颜色色彩失真, 效果不佳。本文算法相较于传统算法, 定量结果相对于最好的 Park 方法, PSNR 和 SSIM 分别提升 7.267 3% 和 5.679 8%; 定性结果从图 7 中可以看到, 既消除了沙尘色偏问题, 又提高了图像的对对比度。



图 7 合成沙尘图像上的定性比较

表 1 合成沙尘数据集上的定量比较结果

Method	PSNR/dB	SSIM
Park <sup>[2]</sup>	28.498 7	0.871 5
CLAHE <sup>[19]</sup>	28.095 6	0.723 0
MSRCR <sup>[3]</sup>	27.869 8	0.823 4
TOENet <sup>[10]</sup>	28.095 5	0.854 0
ChaIR <sup>[12]</sup>	28.627 3	0.747 8
FFA-Net <sup>[13]</sup>	29.871 4	0.893 6
本文方法	30.569 8	0.921 0

相对于传统算法, 使用合成沙尘数据集训练的基于深度学习的算法效果更佳, 在沙尘图像增强上面有很大优势。TOENet 产生的结果虽结构清晰但只去除部分沙尘降质图像的色偏, 没有去除彻底, 整体表现一般; CHaIR 在一些图片上效果不错, 可以去除沙尘色偏, 但在一些图像上有明显失真情况, 整体颜色恢复深于真实图像颜色, 图像细节恢复良好; FFA-Net 在三者中表现最佳, 图像细节恢复较好, 但还是与原本图像有色差。本文算法与基于深度学习的算法相比, 定量结果相对于最好的 FFA-Net 方法, PSNR 和 SSIM 分别提升 2.338 0% 和 3.066 2%, 整体的图像视觉更加和谐, 同时在色彩恢复、对比度提升以及细节信息保留方面更优。

### 2.2.2 真实数据集实验结果

在沙尘天气中, 沙尘降质图像的浓度分布并不均匀, 导致真实世界退化图像法的颜色偏差范围比合成图像更大。因此, 真实场景图像中的沙尘去除

的难度高于合成图像法, 为了进一步评估算法的性能, 对真实世界沙尘的比较是有必要的。

图 8 为本文方法和几种传统算法与深度学习算法在沙尘降质图像上的定性比较结果, 表 2 为将 80 张真实沙尘降质图像的平均定量指标进行比较的结果。由于真实沙尘降质图像没有清晰图像进行比较, 且目前尚无现成的图像质量定量评价指标, 因此, 采用非参考评价指标, 包括自然图像质量评价 (natural image quality evaluator, NIQE), NIQE 指标越小表示效果越佳。同时, 还采用平均标准差 (mean standard deviation) 和平均梯度 (mean gradient) 进行评价对比。其中, 标准差的大小表示图像中像素值的变化程度, 较大的标准差意味着图像具有较高的对比度, 存在较多的细节和纹理; 梯度表示图像中像素值的变化率, 较大的梯度值表示存在明显的边缘和边界, 同时也意味着图像具有清晰的结构和轮廓。

结合图 8 和表 2 中可以看出, 传统方法中 Park 方法在真实沙尘数据集上依旧表现良好, 可以有效去除沙尘, 展示更接近真实的颜色, 但是对比度和清晰度并不高, 一些沙尘浮色处理不彻底; NIQE 取得传统算法中最低的数值, CLAHE 方法可以去除沙尘颜色但是有一些颜色失真, 图像的对比度与清晰度也没有得到更好的提升; MSRCR 方法针对真实沙尘相对前面 2 个传统算法来说效果并不是很好, 图像对比度、清晰度不佳, 色偏依旧存在。相较传统算法, 本文算法取得最低的 NIQE 值, 以及

取得最佳的平均标准差以及平均梯度值, 在视觉效果上优于传统算法。




图 8 真实沙尘图像的定性比较

表 2 真实沙尘数据集上的定量比较结果

Method	NIQE	Mean Standard Deviation	Mean Gradient
Park <sup>[2]</sup>	5.321 2	64.163 6	73.159 0
CLAHE <sup>[19]</sup>	5.538 6	73.771 1	117.216 5
MSRCR <sup>[3]</sup>	5.560 2	14.459 4	32.491 3
TOENet <sup>[10]</sup>	5.561 5	59.260 2	81.418 0
ChaIR <sup>[12]</sup>	5.521 7	69.325 6	195.710 8
FFA-Net <sup>[13]</sup>	5.441 6	73.664 5	158.153 8
本文方法	4.322 3	78.060 3	181.162 3

在基于深度学习的算法中, TOENet 可以消除真实沙尘中一定沙尘图像的色偏, 但并不彻底; CHaIR 算法处理真实沙尘降质图像时颜色失真严重, 出现严重的色彩偏差, 视觉观感较差, 模型不具有好的泛化性; FFA-Net 处理之后的图片颜色出现偏差。相较于深度学习算法处理的真实沙尘降质图像, 传统算法的效果更胜一筹。相较基于深度学习的算法, 本文算法在 NIQE 取得最低值, 虽然在平均梯度上低于 CHaIR 算法, 但图 8 中可以看出由于 CHaIR 算法处理后的图像颜色失真太大及像素值的变化大, 相对应的平均梯度也就越高。

综上所述, 本文算法可以更好地校正真实沙尘图像的色偏问题, 恢复更加符合现实场景的颜色,

图像对比度提高, 图像的细节更加清晰, 相比于其他算法在真实沙尘场景中依旧表现良好。

### 2.2.3 算法时间效率

为测试所提出算法的时间效率, 将算法第 2 阶段基于残差融合的尘雾去除网络与 3 种基于深度学习的算法进行比较。在 10 000 张合成沙尘图片的数据集上训练 100 个 epoch, 记录其训练时间和参数量结果, 如表 3 所示。从表中可以看出本文算法所花费时间低于其他对比算法, 说明所提算法在保证生成质量的同时, 消耗的时间也是最短的。

表 3 算法时间效率比较结果


Method	Training Time/min	Total Parameters
TOENet <sup>[10]</sup>	3 980	202 526
ChaIR <sup>[12]</sup>	32 000	15 017 001
FFA-Net <sup>[13]</sup>	8 060	4 455 913
本文方法	3 240	3 470 822

### 2.3 消融实验

进一步分析和讨论提出算法的效果。验证本文方法先进行颜色校正, 然后使用深度学习提升图像清晰度的重要性, 而不是直接使用合成沙尘降质图像训练深度学习算法来增强沙尘图像。具体来说, 设计了 3 组消融实验方案, 包括: 实验方案

1 使用合成沙尘数据集训练基于残差融合的尘雾去除网络; 实验方案 2 单独采用沙尘降质图像颜色校正算法; 实验方案 3 沙尘降质图像颜色校正后使用公开合成雾霾图像训练第 2 阶段网络。方案 1、方案 3 和本文方法使用相同的迭代次数。

合成沙尘数据集消融实验定性比较如图 9 所示, 定量结果如表 4 所示。



a. Hazy b. 方案1 c. 方案2 d. 方案3 e. 本文方法 f. Clear

图 9 合成沙尘图像的消融实验定性比较结果

表 4 合成图像消融实验定量比较结果

方案	PSNR/dB	SSIM
方案1	29.444 7	0.861 5
方案2	27.879 8	0.619 2
方案3	28.000 4	0.733 4
本文方法	30.569 8	0.921 0

结合定性和定量结果, 方案 1 显示直接使用合成沙尘数据集训练的网络测试结果中, 图像偏色消除并不彻底, 且有部分颜色出现失真情况, 表明先进行颜色校正算法能够预先处理偏色问题, 减轻基于残差融合的尘雾的学习压力。方案 2 显示直接对沙尘降质图像进行颜色校正算法虽然可以平衡沙尘降质图像色偏问题, 但是尘雾对于图像对比度及清晰度的影响并未解决, 表明基于残差融合的尘雾去除网络对于图像清晰度、对比度的提升。方案 3 显示使用合成雾霾数据集训练的网络测试结果图像暗沉、清晰度不高, 存在噪声问题的同时还有部分颜色失真, 表明第 1 阶段的输出图像作为第 2 阶段的训练输入图像是重要的, 对网络的效果有着至关重要的影响。因此, 本文将颜色校正之后的图像经过基于残差融合的尘雾去除网络处理, 消除了图像中的尘雾, 提升图像对比度且图片看上去更加清晰,

解决了校正之后的视觉模糊以及暗沉的问题, 并且处理完的结果在视觉上更接近参考图像。同时, 本文算法处理的结果取得了最好的评价指数, PSNR 相比于方案 1、方案 2 和方案 3 分别提高 3.821 0%、9.648 5% 和 9.176 2%, SSIM 分别提高 6.906 5%、48.740 3% 和 25.579 4%, 进一步证明本文模型每一部分的重要性及必要性。

此外, 还对真实世界的沙尘降质图像进行消融实验, 定性结果如图 10 所示, 定量结果如表 5 所示。结合定量结果和定性结果可以看到, 算法结果基本上与合成沙尘数据集测试结果保持一致, 但是方案 1 存在偏色解决不彻底的问题; 方案 2 对比度和清晰度低; 方案 3 的噪声及暗沉在真实沙尘数据集上更为明显。表 5 中也可以看出评价指标的变化, 方案 1、方案 2 和方案 2 这 3 种消融情况指标值都低于本文模型的指标值。综上所述, 从定性和定量两方面证明本文提出方法在真实沙尘数据集测试结果上取得了较优的性能。



a. Hazy b. 方案1 c. 方案2 d. 方案3 e. 本文方法

图 10 真实沙尘图像的消融实验定性比较结果

表 5 真实沙尘图像消融实验定量比较结果

方案	NIQE	Mean Standard Deviation	Mean Gradient
方案1	4.693 8	74.365 6	152.013 5
方案2	6.327 0	36.448 7	32.851 4
方案3	5.320 2	45.122 4	56.494 3
本文方法	4.322 3	78.060 3	181.162 3

### 3 结束语

本文提出的二阶段沙尘降质图像增强算法, 结合沙尘退化机制, 先将沙尘降质图像进行颜色校正, 显著改善了沙尘降质图像中存在的色偏问题; 再提出基于残差融合的尘雾去除网络, 缓解了图像

中尘雾所导致的对比度下降、清晰度不足等问题。该算法表明,适当的先验处理在基于深度学习的算法中能发挥积极的作用,可降低网络直接学习沙尘降质图像特征的学习压力;同时算法结合传统增强算法和基于深度学习的算法优势,实现了两者优势互补。

本文算法在远景图像细节保留、部分场景曝光等方面仍存在提升空间。此外,由于基于深度学习的算法所使用的数据集主要以合成沙尘数据为主,如何利用现有真实数据集复原高质量沙尘图像仍是一个难题,这也为未来的研究指明了明确的方向。

### 参考文献

- [1] SHI Z, FENG Y, ZHAO M, et al. Normalised gamma transformation based contrast limited adaptive histogram equalisation with colour correction for sand-dust image enhancement[J]. *IET Image Processing*, 2020, 14(4): 747-756.
- [2] PARK T H, EOM I K. Sand-dust image enhancement using successive color balance with coincident chromatic histogram[J]. *IEEE Access*, 2021, 9: 19749-19760.
- [3] ZOTIN A G. Fast algorithm of image enhancement based on multi-scale retinex[J]. *International Journal of Reasoning-Based Intelligent Systems*, 2020, 12(2): 106-116.
- [4] NARASIMHAN S G, NAYAR S K. Vision and the atmosphere[J]. *International Journal of Computer Vision*, 2002, 48(3): 233-254.
- [5] HE K, SUN J, TANG X. Single image haze removal using dark channel prior[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2010, 33(12): 2341-2353.
- [6] DHARA S K, ROY M, SEN D, et al. Color cast dependent image dehazing via adaptive airlight refinement and nonlinear color balancing[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2020, 31(5): 2076-2081.
- [7] GAO G X, LAI H C, JIA Z H, et al. Sand-dust image restoration based on reversing the blue channel prior[J]. *IEEE Photonics Journal*, 2020, 12(2): 1-16.
- [8] SHI Z, FENG Y, ZGAO M, et al. Let you see in sand dust weather: A method based on halo-reduced dark channel prior dehazing for sand-dust image enhancement[J]. *IEEE Access*, 2019, 7: 116722-116733.
- [9] SI Y, YANG F, LIU Z. Sand dust image visibility enhancement algorithm via fusion strategy[J]. *Scientific Reports*, 2022, 12(1): 13226.
- [10] GAO Y, XU W, LU Y. Let you see in haze and sandstorm: Two-in-one low visibility enhancement network[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 1-12.
- [11] 丁元, 邬开俊. 多分支修复网络的沙尘降质图像增强算法[J]. *计算机工程与应用*, 2023, 59(24): 227-237.  
DING Y, WU K J. Sand dust degradation images enhancement algorithm via multi-branch restoration network[J]. *Computer Engineering and Applications*, 2023, 59(24): 227-237.
- [12] CUI Y, KNOLL A. Exploring the potential of channel interactions for image restoration[J]. *Knowledge-Based Systems*, 2023, 282: 111156.
- [13] QIN X, WANG Z, BAI Y, et al. FFA-Net: Feature fusion attention network for single image dehazing[C]// *Proceedings of the AAAI Conference on Artificial Intelligence*. New York: AAAI, 2020: 11908-11915.
- [14] 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*. [S. l.]: IEEE, 2021: 10551-10560.
- [15] ZHENG Y, ZHAN J, HE S, et al. Curricular contrastive regularization for physics-aware single image dehazing[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Vancouver: IEEE, 2023: 5785-5794.
- [16] BUCHSBAUM G. A spatial processor model for object colour perception[J]. *Journal of the Franklin Institute*, 1980, 310(1): 1-26.
- [17] LIM B, SON S, KIM H, et al. Enhanced deep residual networks for single image super-resolution[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. [S. l.]: IEEE, 2017: 136-144.
- [18] WANG X, HAN X, HUANG W, et al. Multi-similarity loss with general pair weighting for deep metric learning[C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Long Beach: IEEE, 2019: 5022-5030.
- [19] SAHU S, SINGH A K, GHRERA S P, et al. An approach for denoising and contrast enhancement of retinal fundus image using CLAHE[J]. *Optics & Laser Technology*, 2019, 110: 87-98.

责任编辑 刘飞阳