基于亮度补偿的迭代式非均质图像去雾算法

刘春晓, 厉世昌

(浙江工商大学计算机科学与技术学院 杭州 310018)
(cxliu@zjgsu.edu.cn)

摘 要: 针对现有图像去雾方法无法有效地去除非均质雾霾以及多次去雾导致图像整体变暗等问题, 提出一种基于亮度补偿的迭代式非均质图像去雾算法, 包含图像去雾和亮度补偿 2 个模块. 在每轮迭代中, 先通过图像去雾模块增强图像的对比度, 降低图像中的雾霾浓度, 再通过亮度补偿模块弥补图像去雾模块造成的亮度损失, 使得亮度补偿结果不但保持先前的图像去雾效果, 而且达到图像去雾处理之前的亮度水平, 为下一轮进一步提升图像的去雾效果创造好的条件; 在亮度补偿模块中, 根据图像去雾前后的亮度变化设计一个亮度补偿算子, 并建立一种基于亮度补偿系数的自适应亮度补偿机制, 不但能够恢复图像的原有亮度, 而且还能够提升图像的对比度, 助力图像的去雾过程. 在 FiveK-Haze, SOTS 测试集和 Real-Haze 真实雾霾数据集上的大量实验结果表明, 所提算法在处理非均质雾霾图像上表现出色, 去雾结果具有良好的亮度、对比度和颜色饱和度, 在常用的峰值信噪比、结构相似度、雾霾浓度、图像自然度和学习感知图像块相似度等评价指标上均优于对比方法.

关键词: 非均质雾霾; 亮度补偿; 迭代图像去雾
中图法分类号: TP391.41 **DOI:** 10.3724/SP.J.1089.2024-00048

Brightness Compensation Based Iterative Non-Homogeneous Image Dehazing

Liu Chunxiao and Li Shichang

(*School of Computer Science and Technology, Zhejiang Gongshang University, Hangzhou* 310018)

Abstract: In order to solve the problems that existing image dehazing methods cannot effectively remove non-homogeneous haze and their iterative dehazing results takes on overall darkening effects, a brightness compensation based iterative non-homogeneous image dehazing algorithm framework is proposed with the image dehazing module and the brightness compensation module. In each iteration, the image dehazing module is first employed to enhance the contrast of the image and reduce the haze density. Subsequently, the brightness compensation module is utilized to make up for the brightness loss caused by the image dehazing module, ensuring that the results of brightness compensation not only maintain the previous image dehazing effect but also achieve the original brightness level before the dehazing procedure. This process creates favorable conditions for further improving the dehazing effect of the image in the next iteration. In the brightness compensation module, a brightness compensation operator is designed according to the brightness changes before and after the image dehazing module, and a brightness compensation coefficients based adaptive brightness compensation mechanism is established, which can not only restore the original brightness of the image, but also improve the contrast of the image which can further boost the image dehazing effects. Extensive experimental results on the FiveK-HAZE, SOTS test set, and Real-Haze dataset demonstrate outstanding performance of the proposed algorithm in handling

收稿日期: 2024-01-22; 修回日期: 2024-10-22. **基金项目**: 国家自然科学基金(61976188); 浙江省自然科学基金(LY24F020004); 浙江工商大学“数字+”学科建设项目(SZJ2022B016); 浙江省大学生科技创新活动计划暨新苗人才计划(2023R408035). **刘春晓**(1979—), 男, 博士, 副教授, 硕士生导师, CCF 会员, 主要研究方向为计算机视觉、计算机图形学、机器学习与智能系统、视觉安全与隐私保护; **厉世昌**(1999—), 男, 硕士研究生, 主要研究方向为深度学习、计算机视觉.

non-homogeneous haze images. The dehazed results exhibit excellent brightness, contrast, and color saturation. Our algorithm outperforms comparison methods in commonly used evaluation metrics such as peak signal-to-noise ratio, structural similarity, haze density, image naturalness, and learned perceptual image patch similarity.

Key words: non-homogeneous haze; brightness compensation; iterative image dehazing

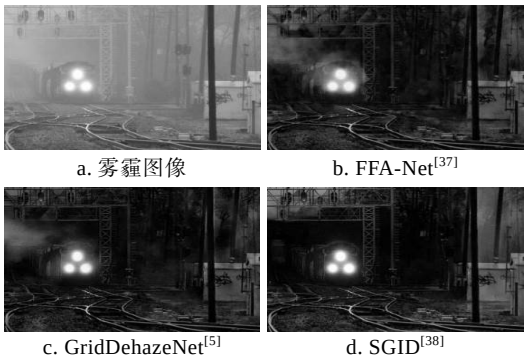
图像去雾一直都是计算机视觉领域的重要研究课题，在多个领域中发挥着关键作用，包括视频监控、地形勘测和自动驾驶等. 各种计算机视觉任务通常要求高质量的输入图像，而雾霾图像是在朦胧的条件下捕获的，导致图像信息严重退化，存在对比度和饱和度低、细节丢失以及颜色偏差等问题. 因此，面向真实场景的图像去雾是一个具有挑战性和不确定性的问题.

目前，图像去雾方法大致分为基于先验的和基于深度学习的 2 类. 基于先验的去雾方法[1-4]利用图像的统计特性和先验知识来恢复图像中的清晰信息. Tan[1]注意到雾霾图像的对比度较低，局部区域内的透射率接近恒定，并且相邻区域的透射率变化平滑; He 等[2]提出暗通道先验(dark channel prior, DCP)，即户外无雾图像的大部分局部区域，存在一些像素点(暗像素)在至少一个颜色通道中具有非常低的值，接近于零; Fattal[3]利用颜色线条的特征估计雾浓度和透射率，对图像进行恢复和色彩校正; Berman 等[4]提出一种基于非局部图像相似性的方法进行去雾. 然而，这些方法都假设所发现的先验足以描述真实世界的图像，当先验假设不成立时，去雾表现往往不佳.

基于深度学习的去雾方法[5-10]通过神经网络模型学习图像之间的复杂映射关系，从输入雾霾图像中直接生成清晰的输出图像. Liu 等[5]提出一个端到端的卷积神经网络，由预处理、主干和后处理 3 个模块组成，用于对单幅图像进行去雾; Das 等[6]提出一种快速的深度多块分层网络，通过聚合不同空间的多个图像块的特征信息恢复非均质雾霾图像; Yu 等[7]提出一种基于双分支网络和集成学习技术的去雾方法，根据图像中不同区域的雾霾浓度变化进行精细的去雾处理. 然而，基于深度学习的去雾方法在训练过程中往往会出现过拟合的情况，在真实雾霾图像上的去雾效果不够出色，去雾图像存在残雾、伪影和亮度较低等问题.

1　去雾过程中的亮度衰减现象

目前，基于深度学习的图像去雾方法分为基于大气散射模型[11-24]和基于端到端映射学习[25-36]. 不难发现，这 2 种方法在去雾过程中都会产生亮度衰减问题. 采用端到端去雾的 FFA-Net[37]和 GridDehazeNet[5]方法，以及采用模型去雾的渐进式特征融合的自引导图像去雾(self-guided image dehazing using progressive feature fusion, SGID)[38]方法的去雾结果如图 1 所示. 可以看出，这些方法得到的去雾图像整体亮度较低，局部细节丢失严重，直接影响了图像整体的视觉感知质量.



a. 雾霾图像　b. FFA-Net[37]　c. GridDehazeNet[5]　d. SGID[38]

图 1　3 种方法严重偏暗的去雾结果

图像去雾是对每个像素进行适当的非线性拉伸，将像素值恢复成无雾情况下的正常数值; 在此过程中，图像的对比度将会有所提升，同时亮度也会有所下降. 为了探究亮度衰减产生的原因，本文从大气散射模型和端到端映射学习 2 个方面阐述.

1.1　大气散射模型

雾霾形成的过程可以通过大气散射模型[10]表示为

$$I(x)=J(x)\cdot t(x)+A\cdot\big(1-t(x)\big) \tag{1}$$

其中，x 表示像素位置; I 表示雾霾图像; J 表示无雾图像; t 表示透射率图; A 是大气光值. 通过式(1)的恒等变换，去雾图像 J 可以表示为

$$J(x)=A+\frac{I(x)-A}{t(x)} \tag{2}$$

为了比较雾霾图像和去雾图像同一位置像素值的变化情况，本文对式(1)和式(2)求差，得到

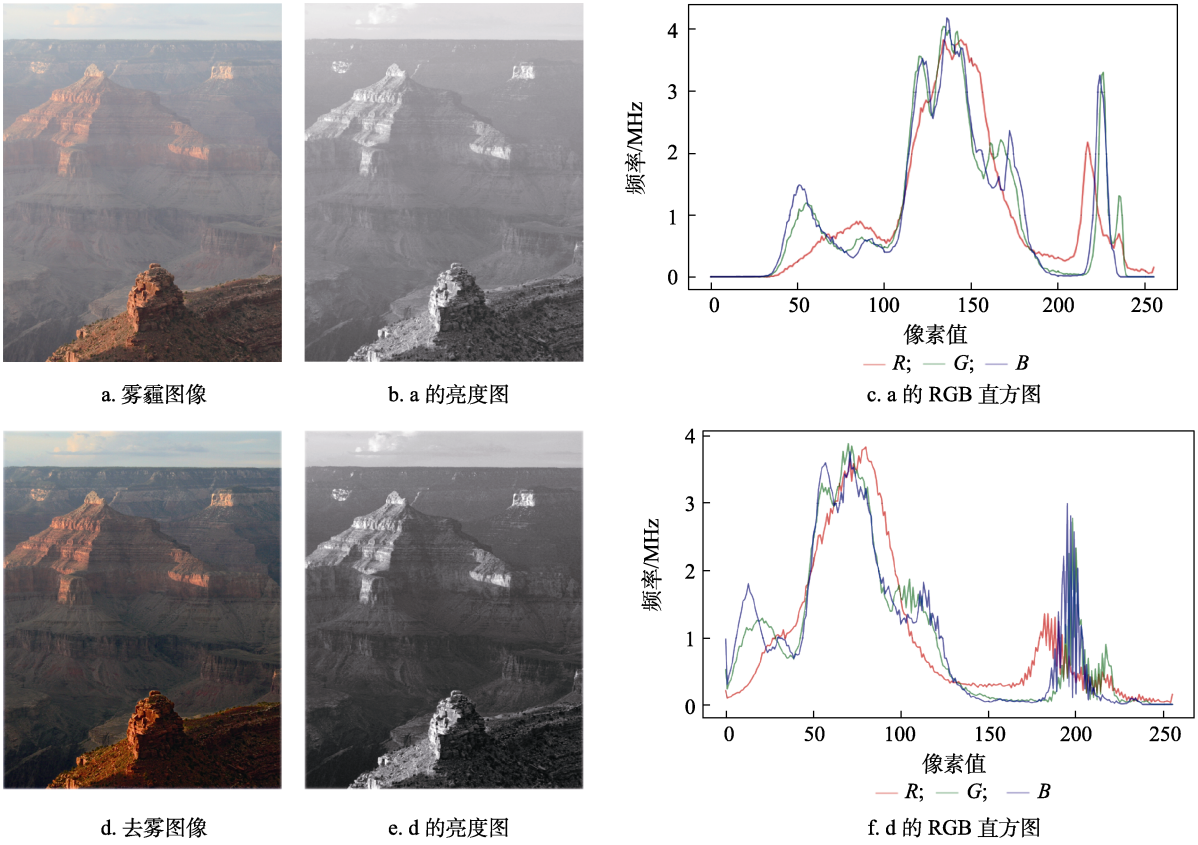
$$J(x)-I(x)=\frac{(I(x)-A)\cdot(1-t(x))}{t(x)} \tag{3}$$

其中，透射率 $t(x)\in[0,1]$. 由式(3)不难看出，$J(x)$ 与 $I(x)$ 的大小关系取决于 $I(x)$ 和 A 的大小关系，因此可以得到结论

$$\begin{cases} I(x)>A\Rightarrow J(x)>I(x) \\ I(x)=A\Rightarrow J(x)=I(x) \\ I(x)<A\Rightarrow J(x)<I(x) \end{cases} \tag{4}$$

式(4)表明：在相同像素位置 x 处，若雾霾图像的像素值 $I(x)$ 大于大气光值 A，去雾后图像的像素值 $J(x)$ 相比 $I(x)$ 将会增大；反之，去雾图像的像素值 $J(x)$ 相比 $I(x)$ 将会减小. 由于大气光值 A 通常取值偏高(接近 255)，雾霾图像 I 中大部分像素的颜色值是小于 A 的，因此去雾图像 J 大部分像素值相比去雾之前会变小，图像整体亮度变低. 此外，雾霾浓度越高(即透射率 t 取值越小)，则 $J(x)$ 和 $I(x)$ 的差值越大，图像整体变暗程度越大.

通常，基于大气散射模型的去雾方法将大气光值 A 设置为固定值 255. 然而从图 2c 不难看出，雾霾图像中绝大多数像素值低于 255. 因此，根据式(4)的结论，去雾图像中大部分像素值相比去雾前会有所降低，导致图像整体亮度下降，如图 2b 和图 2d 所示. 此外，与图 2c 相比，图 2f 整体向左偏移.



a. 雾霾图像　b. a 的亮度图　c. a 的 RGB 直方图

d. 去雾图像　e. d 的亮度图　f. d 的 RGB 直方图

图 2　雾霾图像和去雾图像的像素值变化情况

1.2　端到端映射学习

对目前公开的合成雾霾数据集 ITS-Haze[39]，OTS-Haze[39]和 NH-Haze[40]中图像的亮度均值进行比较，结果如表 1 所示. 可以看出，3 个数据集中，雾霾图像的亮度均值普遍高于无雾图像的亮度均值，因此在端到端的训练过程中，去雾网络会倾向于学习到一种高亮度到低亮度的映射关系；当将训练好的去雾网络应用在雾霾图像上时，去雾后的图像整体亮度往往会出现一定程度的下降. 综上所述，为了有效地应对亮度衰减问题，需要在去雾过程中引入适当的亮度补偿机制，旨在确保去雾后的图像既拥有良好的亮度，又具备较高的对比度，从而获得更理想的去雾效果.

表 1　3 种雾霾数据集的图像亮度均值比较

数据集	雾霾图像	无雾图像
ITS-HAZE[39]	12.40	10.02
OTS-HAZE[39]	11.95	10.85
NH-HAZE[40]	11.66	10.10

2　本文算法

由于大气散射模型以及现有数据集中雾霾图像和无雾图像的亮度差异，去雾后的图像整体亮度下降；此外，在迭代去雾中，较多迭代会导致图像过暗，而较少迭代则无法完全消除雾霾．因此，本文提出一种基于亮度补偿的迭代式去雾算法．在每轮迭代中，先通过图像去雾模块增强图像的对比度，降低图像中的雾霾浓度；然后通过亮度补偿模块弥补图像去雾模块所造成的亮度损失，使得亮度补偿结果不但保持先前的图像去雾效果，而且达到了图像去雾处理之前的亮度水平，为下一轮进一步提升图像的去雾效果创造有利条件．本文算法的框架如图 3 所示．

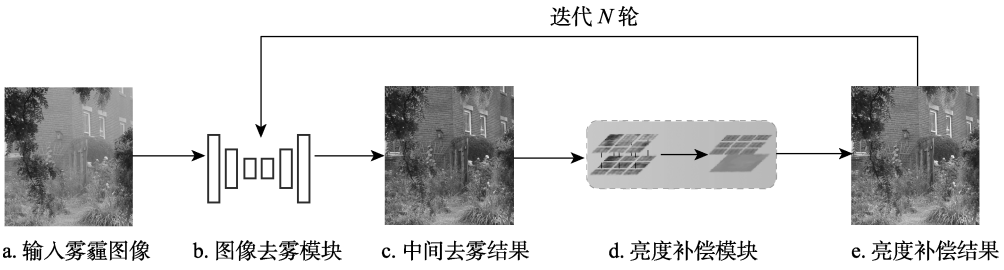


图 3　本文算法框架

对于一幅输入雾霾图像：(1) 将其输入图像去雾模块中进行第 1 轮去雾，得到中间去雾图像．由于该模块会使图像整体亮度下降，导致某些局部区域细节信息丢失，因此设计了一个亮度补偿模块．其中，亮度补偿算子通过计算输入雾霾图像去雾前后局部区域的亮度均值，得到相应的亮度补偿系数，实现对中间去雾图像的自适应亮度补偿．尽管经过亮度补偿操作后，中间去雾图像的亮度水平得到恢复并且对比度进一步提升，但仍然有一定的残雾存留．(2) 将亮度补偿结果作为图像去雾模块的输入进行第 2 轮去雾处理，去除亮度补偿结果中的剩余雾霾，达到更好的去雾效果．(3) 以此类推，上述过程共可执行 N 轮．本文算法的过程可以用公式表示为

$$\begin{cases} J_1 = B\big(D(I)\big) \\ J_2 = B\big(D(J_1)\big) \\ \vdots \\ J_N = B\big(D(J_{N-1})\big) \end{cases}.$$

其中，$D(\cdot)$ 和 $B(\cdot)$ 分别表示图像去雾模块和亮度补偿模块；J_1, J_2, J_N 分别表示第 1 轮、第 2 轮和第 N 轮的亮度补偿结果．

2.1　图像去雾模块

由于基于端到端映射学习的去雾网络难以一次性地将图像中存在的非均质雾霾全部去除干净，因此，在图像去雾模块中设计一种基于残差结构的深度雾霾消散网络，用于对雾霾图像进行迭代去雾．在每轮迭代去雾中，深度雾霾消散网络能够逐渐地提取雾霾图像中的特征信息，并不断地更新已经学习到的参数，更好地恢复图像的清晰度．

本文提出的深度雾霾消散网络如图 4 所示，其主干部分基于编码器-解码器架构，每个编码器和解码器包含一个卷积层或反卷积层，以及一个残差组(ResBlock Group)．其中，每个编码器中的卷积层使用大小为 5×5、填充为 2、步长为 2 的卷积核；每个解码器中的反卷积层使用大小为 3×3、填充为 1、步长为 2 的反卷积核．残差组由 3 个残差块(ResBlock)组成，每个残差块包含 2 个卷积层，1 个 ReLU 激活函数和 1 个残差连接．

2.2　亮度补偿模块

针对迭代去雾过程中图像整体亮度持续衰减的问题，设计了一种亮度补偿模块．

(1) 为了弥补图像去雾后损失的亮度，建立亮度补偿模型为

$$V_{\mathrm{h}} - V_{\mathrm{d}} \approx V_{\mathrm{c}} - V_{\mathrm{d}} \tag{5}$$

其中，V_{h} 和 V_{d} 分别表示雾霾图像和去雾图像的亮度；V_{c} 表示经过亮度补偿后的去雾图像的亮度．假设 $V_{\mathrm{c}} = k \cdot V_{\mathrm{d}}$，其中，$k$ 表示亮度补偿系数，则

$$k = V_{\mathrm{h}} / V_{\mathrm{d}} \tag{6}$$

(2) 得到亮度补偿系数 k 后，通过拉伸方式计算亮度补偿后图像的像素值

$$I_{\mathrm{c}}(x) = I_{\mathrm{d}}(x) \cdot k \tag{7}$$

其中，$I_{\mathrm{c}}(\cdot)$ 表示亮度补偿后图像的像素值；$I_{\mathrm{d}}(\cdot)$ 表示去雾图像的像素值．

(3) 为了实现局部区域自适应亮度补偿，依据深度学习中卷积核提取特征的方式设计一种亮度补偿算子．亮度补偿算子类似卷积核在图像上滑

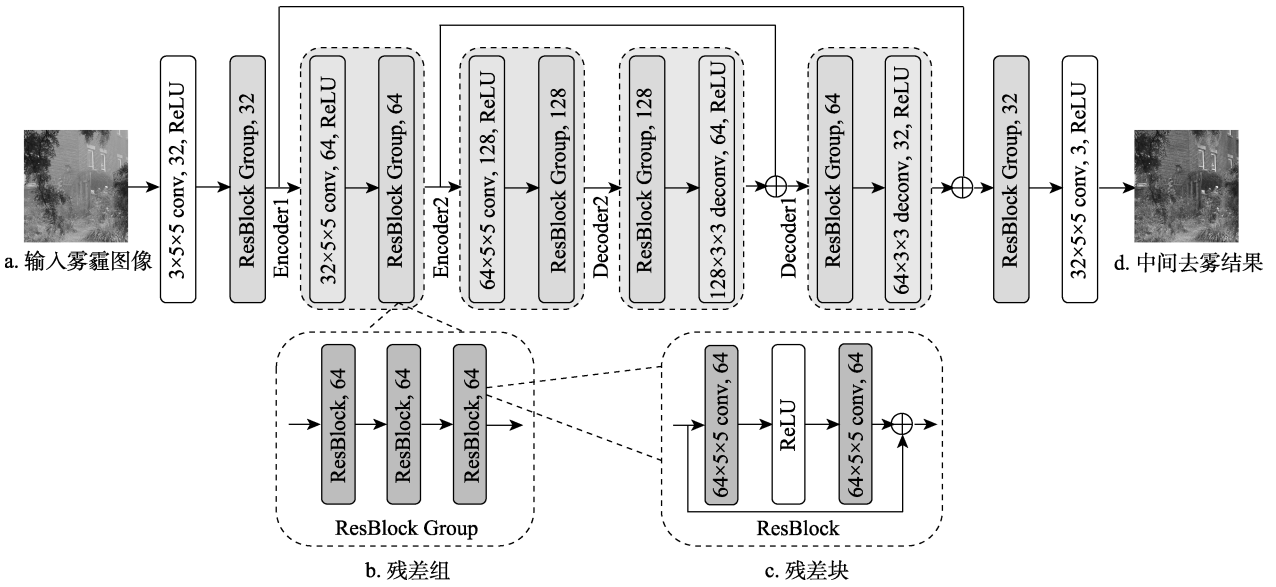


图 4 深度雾霾消散网络

动，以像素点为中心构建窗口区域；在每个窗口区域内，通过比较去雾前后的亮度变化计算出亮度补偿系数；最后根据亮度补偿系数对窗口区域进行自适应的亮度补偿. 通过上述亮度补偿方式，不仅能够恢复窗口区域原有的亮度水平，而且可以将对比度进一步提升.

亮度补偿算法步骤如下:

输入. 雾霾图像(或上一轮的亮度补偿结果)和本轮去雾图像.

输出. 本轮亮度补偿结果.

Step1. 对雾霾图像(或上一轮的亮度补偿结果)和去雾图像进行填充处理，填充后图像的高和宽均为 s (算子大小)的倍数，填充的像素值为 0.

Step2. 获取亮度补偿算子中心位置的像素坐标集合.

Step3. 获取每个中心位置 $s\times s$ 范围内的窗口区域的像素坐标集合.

Step4. 计算每个窗口区域去雾前后的亮度均值，利用式(6)计算对应的亮度补偿系数图 k .

Step5. 利用式(7)对去雾图像和亮度补偿系数图 k 进行像素级乘法操作，得到亮度补偿图像.

图 5 所示为亮度补偿过程示意图，其中，亮度补偿算子大小为 3×3，步长为 3. 首先将图 5a 和图 5b 分别划分为 16 个窗口区域；然后计算每对窗口区域的亮度均值，并利用式(6)计算对应的亮度补偿系数 k，每对窗口区域的亮度补偿系数 k 组成亮度补偿系数图，如图 5c 所示；最后利用式(7)对图 5b 和图 5c 进行像素级乘法操作，得到亮度补偿结果，如图 5d 所示.

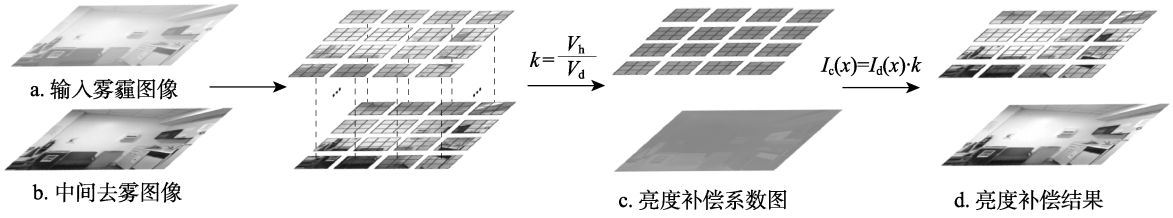


图 5 亮度补偿过程示意图

2.3 损失函数设计

在图像去雾中，常见的损失函数通常基于逐像素的差异比较，但这种方式没有考虑人类视觉感知的特点. 为了更有效地提升去雾图像的视觉效果，综合考虑多个因素，包括特征空间信息、图像结构信息等，设计了一种组合损失函数. 该函数结合多个损失函数的优势，能够更好地指导深度雾霾消散网络的训练，产生更符合人眼感知的去雾结果，其表达式为

$$L_{\text{total}} = L_{\text{VGG}} + L_{\overline{\text{SSIM}}}.$$

其中，L_{VGG} 表示感知损失函数；$L_{\overline{\text{SSIM}}}$ 表示结构相似度(structural similarity index, SSIM)损失函数.

2.3.1 感知损失函数

感知损失函数利用预训练的神经网络 VGG 提

取特征，通过比较去雾图像与基准图像在这些特征上的差异来衡量学习感知图像块相似度(learned perceptual image patch similarity, LPIPS)，其表达式为

$$L_{\mathrm{VGG}}\left(J,\hat{J}\right)=\sum_{i=1}^{4}\frac{1}{M_i}\left\|\varphi_i\left(J\right)-\varphi_i\left(\hat{J}\right)\right\|_2.$$

其中，J 表示无雾图像；$\hat{J}$ 表示去雾图像；$\varphi_i(\cdot)$ 表示 VGG 模型中第 i 层的特征提取器；M_i 表示提取特征的大小；$\|\cdot\|_2$ 表示 L_2 范式.

2.3.2　SSIM 损失函数

SSIM 损失函数体现了去雾图像和基准图像在对比度和结构信息上的差异，其表达式为

$$L_{\overline{\mathrm{SSIM}}}\left(J,\hat{J}\right)=1-\overline{\mathrm{SSIM}}\left(J,\hat{J}\right).$$

其中，$\overline{\mathrm{SSIM}}(\cdot)$ 表示改进的 SSIM 计算函数. 为了避免亮度补偿算子与损失函数的潜在冲突，对原始 SSIM[41]计算函数进行改写. 改写后的 $\overline{\mathrm{SSIM}}$ 计算函数不包含亮度信息(均值项)，只关注对比度信息(方差)和结构信息(协方差)，其表达式为

$$\overline{\mathrm{SSIM}}\left(x,y\right)=\frac{2\sigma_{xy}+c_2}{\sigma_x^2+\sigma_y^2+c_2}.$$

其中，σ_{xy} 表示 x 和 y 的协方差；σ_x^2 和 σ_y^2 分别表示 x 和 y 的方差；c_2 表示常数.

3　实验结果与分析

3.1　训练集和测试集

本文使用非均质雾霾数据集 FiveK-Haze[42]对深度雾霾消散网络进行训练. 该数据集通过超像素分割、合并像素块、引导滤波等技术合成，训练集和测试集划分比例为 9∶1. 使用 FiveK-Haze 测试集、SOTS 测试集和真实雾霾数据集 Real-Haze 对算法进行性能评估. 其中，FiveK-Haze 测试集包含 3 988 幅非均质雾霾图像；SOTS 测试集包含 500 对室内雾霾图像和 500 对室外雾霾图像；Real-Haze 数据集包括 105 幅具有不同场景、雾度和光照的真实世界雾霾图像.

3.2　环境配置和训练细节

本文实验中，硬件设备为 AMD 锐龙 5 5600G CPU 32 GB RAM，微星 RTX 3090 AERO SUPRIM GPU 24 GB；软件环境为 Ubuntu 22.04 操作系统，PyTorch 1.10 运行框架.

训练初始学习率设置为 0.000 1，优化器为 Adam，采用余弦退火策略对学习率进行周期性调整. 权重衰减系数初始化为 0.000 1，梯度剪裁范数初始化为 0.1，训练图像大小为 320×320 像素，批量大小为 32.

鉴于亮度补偿后的去雾图像在数值分布上出现了变化，采取一种端到端的训练策略，以联合优化本文算法的整体框架. 为了降低网络结构的复杂性，在去雾模块中引入参数共享机制. 每次迭代中，亮度补偿后的去雾图像将再次送入去雾模块进行训练，对网络参数进行更细致的调整，从而为亮度补偿图像的进一步去雾提供了优化空间.

3.3　评估指标

对于 FiveK-Haze 和 SOTS 等合成雾霾数据集，本文采用峰值信噪比(peak signal-to-noise ratio, PSNR)[43]，SSIM 以及 LPIPS[44]进行评估. 其中，PSNR 和 SSIM 值越高，表示去雾结果在颜色和结构层面越接近标准无雾图像；LPIPS 值越低，表示去雾结果在特征层面越接近标准无雾图像. 对于 Real-Haze 数据集，采用雾霾浓度指标(fog aware density evaluator, FADE)[45]、图像自然度评价指标(natural image quality evaluator, NIQE)[46]、亮度、对比度以及颜色饱和度等无参考指标进行全面评价. 其中，FADE 值越小，表示雾霾浓度越低；NIQE 值越小，表示图像自然度越高.

3.4　边缘亮度跳跃问题

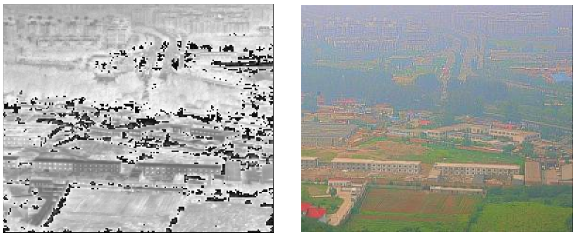
由于亮度补偿操作采取分块处理的方式，因此相邻窗口区域在补偿过程中会出现边缘亮度突变或视觉失真现象. 对引导滤波前后的亮度补偿系数图进行实验，结果如图 6 所示. 可以看出，图 6a 中，相邻窗口区域的亮度补偿系数存在较大差异，导致图 6b 出现了亮度跳变、颜色失真和内容模糊等问题. 针对亮度补偿过程中的边缘亮度跳跃问题，使用引导滤波技术，利用去雾模块输出的中间去雾图像作为引导图，对原始亮度补偿系数图进行细致的引导和优化，确保边缘区域的亮度过渡更加平滑和自然. 根据图 6c 得到的亮度补偿结果不仅展现出良好的亮度水平，同时也完好地保留了关键的边缘细节，如图 6d 所示.

3.5　消融实验

在 FiveK-Haze 数据集上，对亮度补偿算子尺寸、亮度补偿模块和迭代轮数进行消融实验.

3.5.1　亮度补偿算子尺寸设置分析

在亮度补偿模块中，算子尺寸过大会导致亮度补偿不够精细，而尺寸过小又会带来较大的计算开销. 为了选取适宜尺寸的亮度补偿算子，详细比较了不同算子尺寸对 FADE，NIQE，亮度，对比



a. 原始亮度补偿系数图 b. 原始亮度补偿结果



c. 引导后的亮度补偿系数图 d. 引导后的亮度补偿结果

图 6 引导滤波前后的亮度补偿效果对比

度以及颜色饱和度 5 个关键指标的影响，结果如表 2 所示. 可以看出，与 3×3 和 11×11 尺寸的亮度补偿算子相比，7×7 尺寸的算子不仅在雾霾浓度、图像自然度、亮度和对比度等指标上展现出更优异的性能，而且具有相对较小的计算负担. 基于这些考量，本文算法中采用 7×7 尺寸的亮度补偿算子，并基于此设置进行后续的消融实验，以进一步验证和优化本文算法.

表 2 不同尺寸的亮度补偿算子的指标对比

算子尺寸	FADE	NIQE	亮度	对比度	饱和度
3×3	0.528 6	11.864 1	11.386 2	8.064 8	7.590 6
7×7	0.516 7	11.837 5	11.387 0	8.178 3	7.588 9
11×11	0.535 4	12.547 6	11.277 9	8.074 3	7.569 1

3.5.2 亮度补偿模块有效性分析

为了验证本文提出的亮度补偿模块的有效性，设计了 2 组实验：一组未搭载亮度补偿模块，另一组集成了亮度补偿模块. 在 FiveK-Haze 数据集上，分别对 2 组实验进行 3 轮迭代，并且全面评估了 PSNR, SSIM、亮度、对比度以及颜色饱和度指标，结果如表 3 所示.

表 3 不同迭代轮数各阶段的指标评价对比

亮度补偿模块	阶段	PSNR/dB	SSIM	亮度	对比度	颜色饱和度
不搭载	第 1 轮去雾	17.892 2	0.815 0	9.139 8	2.933 1	5.341 6
	第 2 轮去雾	18.464 2	0.824 5	8.934 0	3.363 4	7.776 8
	第 3 轮去雾	19.291 9	0.838 6	8.297 2	4.249 3	8.514 6
搭载	第 1 轮去雾和亮度补偿	18.575 1	0.835 1	9.981 5	3.258 3	6.661 6
	第 2 轮去雾和亮度补偿	20.111 5	0.871 5	10.751 9	5.337 7	8.296 5
	第 3 轮去雾和亮度补偿	20.873 8	0.884 4	10.972 6	6.634 1	9.916 4

3.5.3 迭代轮数设置分析

从表 3 中搭载亮度补偿模块的实验结果可以看出，与第 1 轮去雾和亮度补偿处理相比，第 2 轮处理在各项指标上展现出显著的进步；尽管第 3 轮处理在指标上略显优势，但与第 2 轮相比差距并不明显. 考虑增加迭代轮数必然会引起算法复杂度的上升，同时过多的亮度补偿也可能会在某些场景中产生如图 7 所示的局部区域过曝现象，本文将迭代次数设置为 2 次，使整个算法在能够保证计算效率的同时，可以达到雾霾去除与亮度恢复的最佳平衡.

为了验证迭代次数为 2 对真实雾霾图像的有效性，基于 Real-Haze 数据集进行实验，分别比较第 1 轮和第 2 轮迭代过程中图像信息(亮度、对比度和雾霾浓度)的变化情况，结果如图 8 所示. 从图 8f 的曲线可以看出：图 8b 降低了雾浓度，提高了对比度，但图像亮度明显下降，并且伴有残留雾霾；图 8c 不仅在亮度上接近图 8a，同时在不增加雾霾浓度的情况下，进一步提高了图像对比度；图 8d 和图 8e 进一步去除图像中的剩余残雾并弥补去雾过程中造成的亮度损失，最终的去雾图像不仅达到了图像去雾前的亮度水平，而且具有更高的对比度和更低的雾霾浓度，视觉感知质量提升显著.

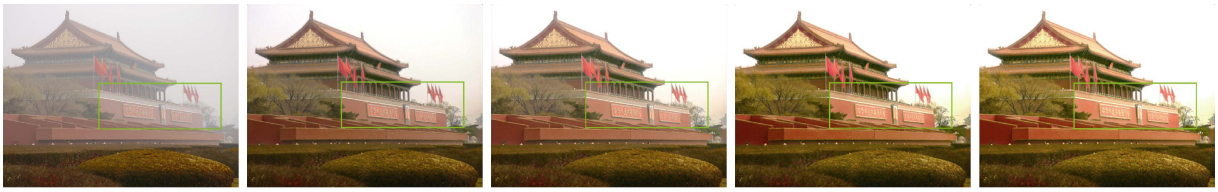


a. 雾霾图像 b. 第 1 轮结果 c. 第 2 轮结果 d. 第 3 轮结果

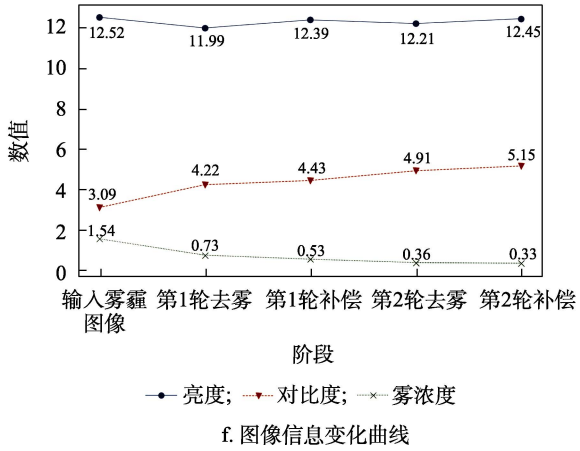
图 7 不同迭代轮数局部区域效果对比

3.6 对比实验

将本文算法与当前主流去雾算法进行对比实验，对比算法包括 DCP[2], SGID[38], AOD[47], DSS[48], DeFormer[49]和 SLP[50]；测试数据集使用 FiveK-Haze, SOTS 和 Real-Haze 数据集. 对于 Fivek-Haze 数据集，本文将对比算法进行重新训练，确保性能比较的



a. 输入雾霾图像　b. 第1轮去雾结果　c. 第1轮补偿结果　d. 第2轮去雾结果　e. 第2轮补偿结果

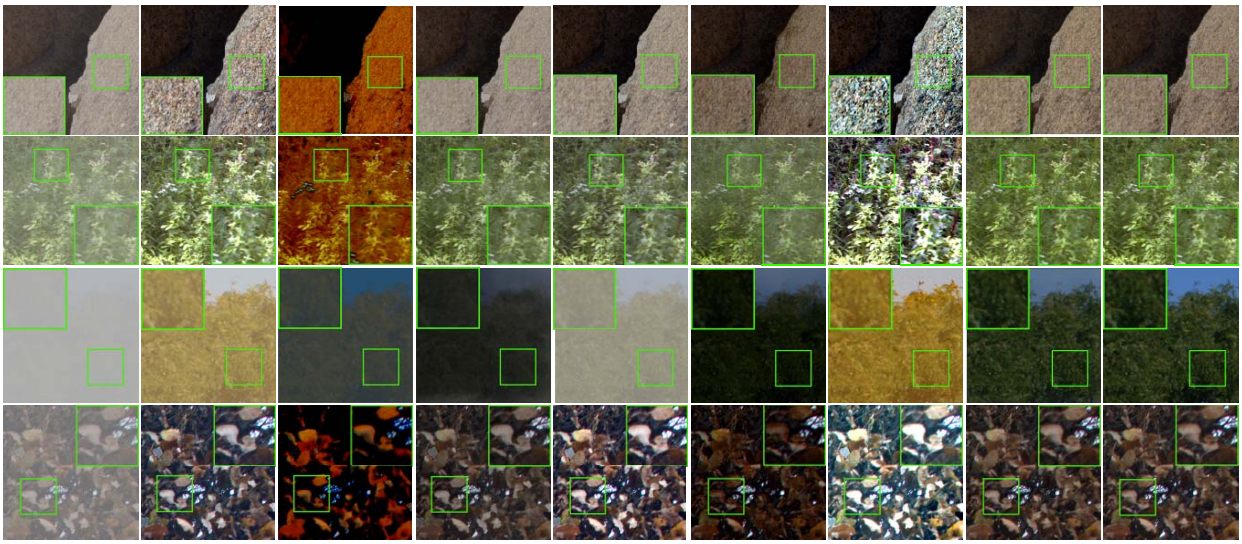


f. 图像信息变化曲线

图 8　2 轮迭代各阶段结果分析

公平性；对于ITS和OTS数据集，本文使用对比算法提供的已经训练好的模型进行指标测试. 性能指标计算均在 OpenCV 环境下进行，并使用 skimage.metrics 库中提供的 PSNR 和 SSIM 计算函数.

在 FiveK-Haze 测试集上，7 种算法的去雾结果如图 9 所示. 可以看出，DCP[2]算法在去雾过程中存在一定程度的颜色失真，去雾图像与原始图像在颜色方面存在较大差异；AOD[47]算法的去雾效果较差，去雾图像整体偏红，缺乏对图像颜色平衡的调整；SGID[38]，DSS[48]和 DeFormer[49]算法在局部区域仍然存在残余雾霾；SLP[50]算法生成的图像存在明显的过曝现象；相比之下，本文算法展现出优秀的去雾效果，去雾图像色彩保真度较高，同时，由于其使用了感知损失函数，因此去雾结果与标准无雾图像保持了较高的学习感知图像块相似度. 7 种算法在各数据集上的评价指标对比如表 4 所示. 不难看出，在 FiveK-Haze 测试集上，本文算法的 PSNR, SSIM 和 LPIPS 指标达到了最优水平.



a. 雾霾图像　b. DCP[2]　c. AOD[47]　d. SGID[38]　e. DSS[48]　f. DeFormer[49]　g. SLP[50]　h. 本文　i. 标准图

图 9　在 FiveK-Haze 测试集上 7 种算法的去雾结果对比

表 4 在 4 个数据集上 7 种算法的评价指标对比

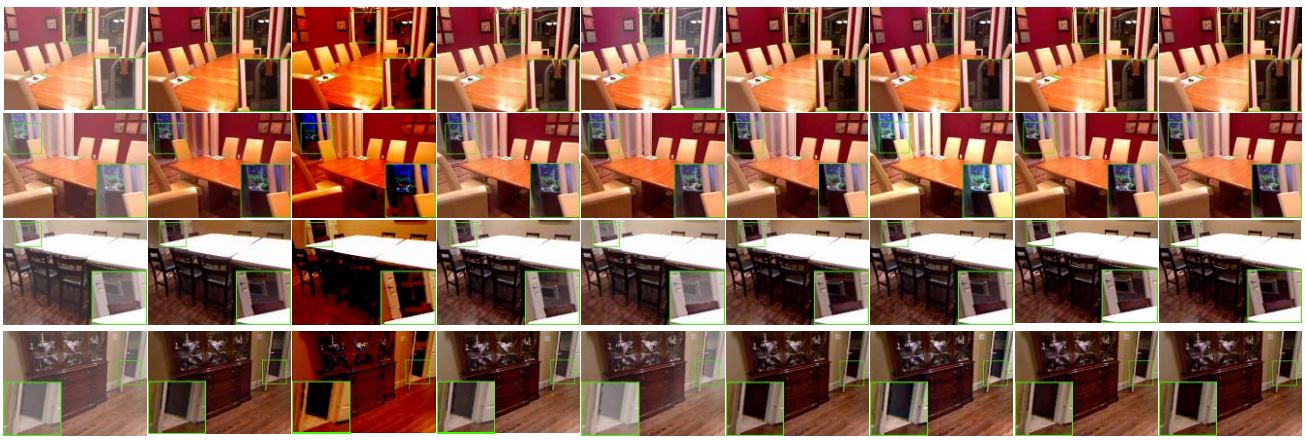
数据集	指标	DCP[2]	AOD[47]	SGID[38]	DSS[48]	DeFormer[49]	SLP[50]	本文
FiveK-Haze	PSNR/dB	17.268 6	14.399 0	13.791 0	16.063 7	16.104 4	16.545 8	**21.003 1**
	SSIM	0.822 9	0.632 2	0.581 9	0.777 4	0.737 7	0.769 7	**0.886 9**
	LPIPS	0.254 6	0.318 9	0.270 5	0.238 9	0.192 5	0.226 4	**0.184 5**
ITS-Haze	PSNR/dB	18.949 1	18.476 2	36.596 8	27.216 5	35.150 0	20.200 0	**36.812 4**
	SSIM	0.869 8	0.837 2	0.985 3	0.924 5	0.989 0	0.857 5	**0.987 4**
	LPIPS	0.211 9	0.227 1	0.013 5	0.107 3	0.025 7	0.182 8	**0.010 9**
OTS-Haze	PSNR/dB	18.221 4	22.058 0	30.200 0	21.760 0	33.710 0	22.249 7	**34.038 2**
	SSIM	0.891 7	0.914 5	0.975 4	0.909 4	**0.982 0**	0.926 6	0.971 6
	LPIPS	0.220 5	0.179 9	0.156 4	0.182 6	**0.127 2**	0.166 7	0.128 7
Real-Haze	FADE	0.419 2	0.471 3	0.443 6	0.507 2	0.517 7	0.381 3	**0.326 4**
	NIQE	12.021 1	11.781 6	12.369 7	12.819 7	10.137 9	11.795 1	**10.010 7**
	亮度	9.666 1	9.609 8	9.563 2	10.472 1	10.146 3	9.406 8	**11.529 3**
	对比度	8.130 9	8.153 9	8.347 6	8.250 3	8.093 6	9.864 6	**10.794 3**
	饱和度	9.843 6	10.169 0	10.119 3	8.356 7	8.566 1	9.842 4	**11.419 9**

注. 粗体表示最优值.

在 ITS-HAZE 数据集上, 7 种算法的去雾结果如图 10 所示. 可以看出, DCP[2]和 AOD[47]算法的去雾结果存在明显的色彩偏差; SGID[38]和 DSS[48]算法在图像中仍存在不同程度的雾霾残留, 意味着这些算法的去雾力度有限; Deformer[49]算法得到的去雾图像中, 局部区域的亮度较低, 细节不够丰富; SLP[50]算法对图像颜色的处理不准确, 在局部区域存在颜色失真现象; 相比之下, 本文算法展现出更好的去雾性能, 去雾图像具有较高的细节和纹理水平, 在 PSNR, SSIM 和 LPIPS 指标上优于对比算法.

在 OTS-HAZE 数据集上, 7 种算法的去雾结果如图 11 所示. 可以看出, DCP[2]和 SLP[50]算法在天空区域存在严重的颜色失真现象; AOD[47]算法得到的去雾图像亮度偏低, 细节丢失较严重; SGID[38], DSS[48]和 DeFormer[49]算法在整体上表现出良好的去雾效果, 但是部分区域仍存在颜色失真和亮度过暗的问题; 相比之下, 本文算法表现出色, 在 PSNR 指标上达到最优水平, 表明其在去雾任务中能够较好地保持图像的色彩准确性和细节清晰度.

在 Real-Haze 数据集上, 7 种算法的去雾结果如图 12 所示. 可以看出, DCP[2]和 SLP[50]算法在局部区域仍然存在明显的残留雾霾; AOD[47]和 DSS[48]算法在真实场景中的去雾力度非常有限, 去雾图像对比度较低; SGID[38]和 DeFormer[49]算法



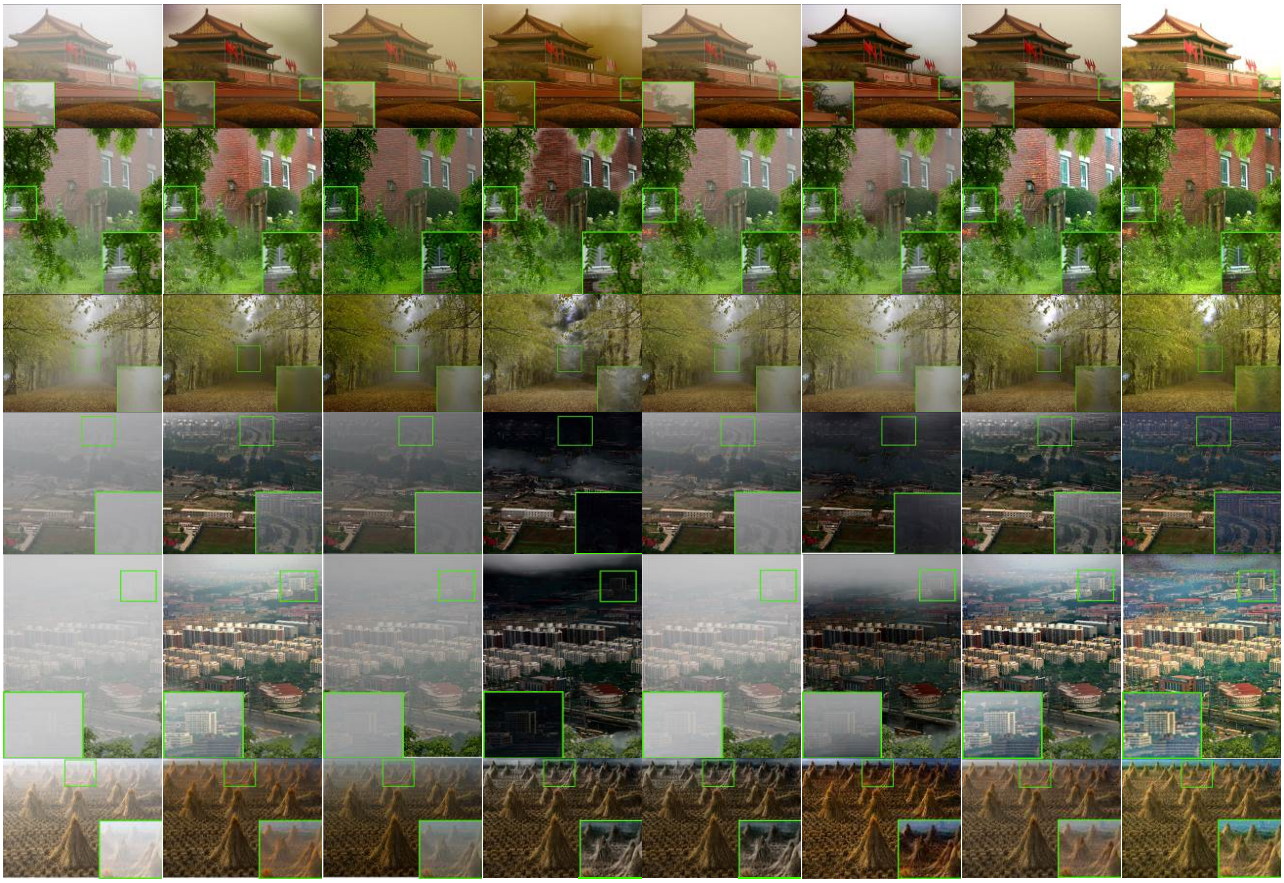
a. 雾霾图像 b. DCP[2] c. AOD[47] d. SGID[38] e. DSS[48] f. DeFormer[49] g. SLP[50] h. 本文 i. 标准图

图 10 在 ITS-HAZE 数据集上 7 种算法的去雾结果对比



a. 雾霾图像　b. DCP[2]　c. AOD[47]　d. SGID[38]　e. DSS[48]　f. DeFormer[49]　g. SLP[50]　h. 本文　i. 标准图

图 11　在 OTS-HAZE 数据集上 7 种算法的去雾结果对比



a. 雾霾图像　b. DCP[2]　c. AOD[47]　d. SGID[38]　e. DSS[48]　f. DeFormer[49]　g. SLP[50]　h. 本文

图 12　在 Real-Haze 数据集上 7 种算法的去雾结果对比

在颜色处理上存在较为严重的偏移现象，导致去雾图像整体偏暗；相比之下，本文算法展现出均匀的去雾力度，去雾图像具有良好的亮度、对比度和颜色饱和度，视觉感知质量较高，此外，在雾霾浓度 FADE 和图像自然度 NIQE 评价上，本文算法也优于对比算法．综上所述，本文算法在真实场景的去雾任务中取得了良好的效果，能够有效地减少雾霾带来的影响，显著地提升图像的视觉感知质量．

4　结　语

针对基于深度学习的去雾方法在处理真实场景下的非均质雾霾图像时效果较差的问题，本文提出一种基于亮度补偿的迭代式非均质图像去雾算法．该算法结合迭代去雾和亮度补偿 2 个关键步骤，其中，迭代去雾能够逐步增强图像的对比度，降低图像中的雾霾浓度；亮度补偿旨在弥补去雾

过程中造成的亮度损失，确保亮度补偿后的去雾图像能够达到原始雾霾图像的亮度水平．大量实验结果证明，本文算法能够产生优于已有方法的去雾结果，去雾图像更接近真实观感，具有更高的视觉感知质量，表明通过迭代去雾和亮度补偿相互交替的方式，能够更好地还原真实场景中的图像细节和纹理，有效地减少雾霾对图像的影响．在面对雾霾浓度突变较大的极端情况时，本文算法去雾效果尚不理想．因此，未来本文将通过局部增强策略，将图像中不同雾霾浓度的区域分开处理，以更好地恢复图像的局部细节信息．

参考文献(References):

[1] Tan R T. Visibility in bad weather from a single image[C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2008: 1-8

[2] He K M, Sun J, Tang X O. Single image haze removal using dark channel prior[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(12): 2341-2353

[3] Fattal R. Dehazing using color-lines[J]. ACM Transactions on Graphics, 2014, 34(1): Article No.13

[4] Berman D, Treibitz T, Avidan S. Non-local image dehazing[C] //Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2016: 1674-1682

[5] Liu X H, Ma Y R, Shi Z H, *et al*. GridDehazeNet: attention-based multi-scale network for image dehazing[C] //Proceedings of the IEEE/CVF International Conference on Computer Vision. Los Alamitos: IEEE Computer Society Press, 2019: 7313-7322

[6] Das S D, Dutta S. Fast deep multi-patch hierarchical network for nonhomogeneous image dehazing[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Los Alamitos: IEEE Computer Society Press, 2020: 1994-2001

[7] Yu Y K, Liu H, Fu M H, *et al*. A two-branch neural network for non-homogeneous dehazing via ensemble learning[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Los Alamitos: IEEE Computer Society Press, 2021: 193-202

[8] Ancuti C O, Ancuti C. Single image dehazing by multi-scale fusion[J]. IEEE Transactions on Image Processing, 2013, 22(8): 3271-3282

[9] Ren W Q, Ma L, Zhang J W, *et al*. Gated fusion network for single image dehazing[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2018: 3253-3261

[10] Narasimhan S G, Nayar S K. Contrast restoration of weather degraded images[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2003, 25(6): 713-724

[11] Yang Y, Zhang H W, Wu X D, *et al*. MSTFDN: multi-scale transformer fusion dehazing network[J]. Applied Intelligence, 2023, 53(5): 5951-5962

[12] He Y F, Li C L, Li X. Remote sensing image dehazing using heterogeneous atmospheric light prior[J]. IEEE Access, 2023, 11: 18805-18820

[13] Ju M Y, Ding C, Ren W Q, *et al*. IDBP: image dehazing using blended priors including non-local, local, and global priors[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2022, 32(7): 4867-4871

[14] Li Z G, Shu H Y, Zheng C B. Multi-scale single image dehazing using laplacian and Gaussian pyramids[J]. IEEE Transactions on Image Processing, 2021, 30: 9270-9279

[15] Ju M Y, Ding C, Guo C A, *et al*. IDRLP: image dehazing using region line prior[J]. IEEE Transactions on Image Processing, 2021, 30: 9043-9057

[16] Wang Y K, Fan C T. Single image defogging by multiscale depth fusion[J]. IEEE Transactions on Image Processing, 2014, 23(11): 4826-4837

[17] Tarel J P, Hautière N. Fast visibility restoration from a single color or gray level image[C] //Proceedings of the 12th IEEE International Conference on Computer Vision. Los Alamitos: IEEE Computer Society Press, 2009: 2201-2208

[18] Zhang Q, Li X R. Fast image dehazing using guided filter[C] //Proceedings of the 16th IEEE International Conference on Communication Technology. Los Alamitos: IEEE Computer Society Press, 2015: 182-185

[19] Soni B, Mathur P. An improved image dehazing technique using CLAHE and guided filter[C] //Proceedings of the 7th International Conference on Signal Processing and Integrated Networks. Los Alamitos: IEEE Computer Society Press, 2020: 902-907

[20] Zhuang L Y, Ma Y S, Zou Y Y, *et al*. A novel image dehazing algorithm via adaptive gamma-correction and modified AMEF[J]. IEEE Access, 2020, 8: 207275-207286

[21] Hsu W Y, Chen Y S. Single image dehazing using wavelet-based haze-lines and denoising[J]. IEEE Access, 2021, 9: 104547-104559

[22] Li P Y, Tian J D, Tang Y D, *et al*. Deep retinex network for single image dehazing[J]. IEEE Transactions on Image Processing, 2021, 30: 1100-1115

[23] Liu H, Wu Z J, Li L Y, *et al*. Towards multi-domain single image dehazing via test-time training[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2022: 5821-5830

[24] Liu X N, Li H, Zhu C. Joint contrast enhancement and exposure fusion for real-world image dehazing[J]. IEEE Transactions on Multimedia, 2022, 24: 3934-3946

[25] Li R D, Chen L. Progressive deep video dehazing without explicit alignment estimation[J]. Applied Intelligence, 2023, 53(10): 12437-12447

[26] Zhang J G, Ren W Q, Zhang S D, *et al*. Hierarchical density-aware dehazing network[J]. IEEE Transactions on Cybernetics, 2022, 52(10): 11187-11199

[27] Wang P Y, Zhu H Q, Huang H, *et al*. TMS-GAN: a twofold multi-scale generative adversarial network for single image dehazing[J]. IEEE Transactions on Circuits and Systems for

Video Technology, 2022, 32(5): 2760-2772

[28] Zhang X Q, Wang J X, Wang T, *et al*. Hierarchical feature fusion with mixed convolution attention for single image dehazing[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2022, 32(2): 510-522

[29] Zhang X Q, Jiang R H, Wang T, *et al*. Single image dehazing via dual-path recurrent network[J]. IEEE Transactions on Image Processing, 2021, 30: 5211-5222

[30] Zhao S Y, 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

[31] Kim G, Park S W, Kwon J. Pixel-wise wasserstein autoencoder for highly generative dehazing[J]. IEEE Transactions on Image Processing, 2021, 30: 5452-5462

[32] Zhu X S, Li S S, Gan Y D, *et al*. Multi-stream fusion network with generalized smooth L_1 loss for single image dehazing[J]. IEEE Transactions on Image Processing, 2021, 30: 7620-7635

[33] Li R D, Pan J S, Li Z C, *et al*. Single image dehazing via conditional generative adversarial network[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2018: 8202-8211

[34] Zhang S D, Ren W Q, Yao J. Feed-net: fully end-to-end dehazing[C] //Proceedings of the IEEE International Conference on Multimedia and Expo. Los Alamitos: IEEE Computer Society Press, 2018: 1-6

[35] Zhang J, Tao D C. FAMED-net: a fast and accurate multi-scale end-to-end dehazing network[J]. IEEE Transactions on Image Processing, 2020, 29: 72-84

[36] Guo C L, Yan Q X, Anwar S, *et al*. Image dehazing transformer with transmission-aware 3D position embedding[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2022: 5802-5810

[37] Qin X, Wang Z L, Bai Y C, *et al*. FFA-Net: feature fusion attention network for single image dehazing[C] //Proceedings of the 34th AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2020: 11908-11915

[38] Bai H R, Pan J S, Xiang X G, *et al*. Self-guided image dehazing using progressive feature fusion[J]. IEEE Transactions on Image Processing, 2022, 31: 1217-1229

[39] Li B Y, Ren W Q, Fu D P, *et al*. Benchmarking single-image dehazing and beyond[J]. IEEE Transactions on Image Processing, 2019, 28(1): 492-505

[40] Ancuti C O, Ancuti C, Timofte R. NH-HAZE: an image dehazing benchmark with non-homogeneous hazy and haze-free images[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Los Alamitos: IEEE Computer Society Press, 2020: 1798-1805

[41] Wang Z, Bovik A C, Sheikh H R, *et al*. Image quality assessment: from error visibility to structural similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4): 600-612

[42] Liu C X, Ye S S, Zhang L D, *et al*. Non-homogeneous haze data synthesis based real-world image dehazing with enhancement-and-restoration fused CNNs[J]. Computers & Graphics, 2022, 106: 45-57

[43] Huynh-Thu Q, Ghanbari M. Scope of validity of PSNR in image/video quality assessment[J]. Electronics Letters, 2008, 44(13): 800-801

[44] Zhang R, Isola P, Efros A A, *et al*. The unreasonable effectiveness of deep features as a perceptual metric[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Los Alamitos: IEEE Computer Society Press, 2018: 586-595

[45] Choi L K, You J, Bovik A C. Referenceless prediction of perceptual fog density and perceptual image defogging[J]. IEEE Transactions on Image Processing, 2015, 24(11): 3888-3901

[46] Sheikh H R, Bovik A C, Cormack L. No-reference quality assessment using natural scene statistics: JPEG2000[J]. IEEE Transactions on Image Processing, 2005, 14(11): 1918-1927

[47] Li B Y, Peng X L, Wang Z Y, *et al*. An all-in-one network for dehazing and beyond[OL]. [2024-01-22]. https://arxiv.org/abs/1707.06543

[48] Li Z G, Zheng C B, Shu H Y, *et al*. Dual-scale single image dehazing via neural augmentation[J]. IEEE Transactions on Image Processing, 2022, 31: 6213-6223

[49] Song Y D, He Z Q, Qian H, *et al*. Vision transformers for single image dehazing[J]. IEEE Transactions on Image Processing, 2023, 32: 1927-1941

[50] Ling P Y, Chen H A, Tan X, *et al*. Single image dehazing using saturation line prior[J]. IEEE Transactions on Image Processing, 2023, 32: 3238-3253