

DOI:10.19651/j.cnki.emt.2210489

# 一种改进 CBAM 机制和细节恢复的 单幅图像去雾算法\*

王子昭<sup>1</sup> 景明利<sup>1†</sup> 史金钢<sup>2</sup> 陈腾飞<sup>1</sup> 刘婉春<sup>1</sup> 樊锐博<sup>1</sup>

(1. 西安石油大学电子工程学院 西安 710065; 2. 西安交通大学软件学院 西安 710049)

**摘要:** 图像去雾作为图像增强的基本问题得到了广泛关注,已成为具有挑战性的研究方向。针对目前图像去雾算法中先验方法与深度学习方法存在的颜色失真以及雾霾残留问题,提出了一种基于注意力机制的细节恢复的图像去雾算法。首先,引入改进 CBAM 模块,设计出注意力基本块并将基本块封装成组块;其次,为加强组块内信息交互能力,组块间引入了密集连接残差块;最后,设计细节恢复模块对去雾图像进行细节恢复,以进一步减轻雾霾残留的影响。数值仿真实验表明:在 RESIDE 数据集上,所提算法与主流去雾算法相比取得了较高的峰值信噪比和结构相似度,同时在真实图像上也得到了更好的视觉效果。

**关键词:** 图像处理;计算机视觉;图像去雾;CBAM 机制;细节恢复

**中图分类号:** TP391.4 **文献标识码:** A **国家标准学科分类代码:** 520.2040

## A single image defogging algorithm based on improved CBAM mechanism and detail recovery

Wang Zizhao<sup>1</sup> Jing Mingli<sup>1†</sup> Shi Jingang<sup>2</sup> Chen Tengfei<sup>1</sup> Liu Wanchun<sup>1</sup> Fan Ruibo<sup>1</sup>

(1. School of Electrical Engineering, Xi'an Shiyou University, Xi'an 710065, China;

2. School of Software Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

**Abstract:** As the basic problem of image enhancement, image defogging has received extensive attention. It has become a challenging area of research. For the problems of color distortion, fog residue of defogging images in prior method and deep learning method, this paper proposed an image defogging algorithm based on attention mechanism for detail recovery. Firstly, the improved CBAM (convolutional block attention module) module is introduced to design the attention basic block and encapsulate the basic block into blocks. Secondly, to strengthen the information interaction ability within the block, dense connection residual blocks are introduced between the blocks. Finally, the detail recovery module is designed to recover the detail of the fog image to further reduce the impact of fog residue. Numerical simulation experiments show that the proposed algorithm achieves higher peak signal-to-noise ratio and structural similarity compared with the mainstream defogging algorithm on the RESIDE (realistic single image defogging) data set and better visual effects on real images on the RESIDE (realistic single image defogging) data set.

**Keywords:** computer vision; image processing; image defogging; attention mechanism; detail recovery

## 0 引言

在雾霾天气下,悬浮在空气中的大气颗粒会对光线的直线传播造成严重的散射现象,导致图像退化、颜色衰减与对比度减弱,从而显著的降低了图像质量<sup>[1]</sup>。图像去雾作为雾霾降质过程的反问题,其在本质上是一个不恒定问题,

极具挑战性,所以图像去雾作为计算机视觉领域的基本问题<sup>[2]</sup>之一,具有重要的应用价值而备受关注。

目前单幅图像去雾算法大致分为两大类,一类是基于先验信息的去雾算法,一类是基于深度学习的去雾算法,基于先验信息的去雾算法以雾霾大气散射模型为理论基础。Mccartney 等<sup>[3]</sup>首先提出了大气散射模型,经过

收稿日期:2022-06-27

\* 基金项目:国家自然科学基金(62002283)、陕西省重点研发计划(2020GY-152)、西安石油大学博士创新基金(290088266)、西安石油大学研究生创新计划(YCS21113129)项目资助

Narasimhan 和 Nayar<sup>[4-5]</sup> 进一步完善, 大气散射模型为:  $I(x) = J(x)t(x) + \alpha(1-t(x))$  其中,  $I(x)$  是观测到的雾霾图像,  $J(x)$  是真实无雾霾场景,  $t(x) = e^{-\beta d(x)}$  是介质传输率,  $\beta$  是大气散射参数,  $d(x)$  为场景深度。  $\alpha$  是全局大气光,  $x$  表示观测到的雾霾图像  $I$  的像素。基于该模型的假设, 先验方法根据一定物理理论预估参数  $\alpha$  和介质传输率  $t(x)$ , 然后利用该模型重构出无雾图像。在先验方法中, He 等<sup>[6]</sup> 的暗通道先验去雾算法最典型, 该算法基于一个暗通道先验的假设, 该假设根据统计得到。结合光学模型和暗通道先验估计介质传输率  $t(x)$  和全局大气光, 进而利用大气散射模型恢复无雾图像。该算法没有引入新的参数, 且效果较好, 在一些背景较浅的远景图像中, 该算法存在颜色失真问题。

近年来, 随着算力的不断提高及去雾数据集的建立, 深度学习方法得到进一步发展, Cai 等<sup>[7]</sup> 提出了一种去雾网络 DehazeNet, 用于估计有雾图像的介质传输率, 进而利用大气散射模型恢复无雾图像。Ren 等<sup>[8]</sup> 提出了两步法, 通过粗提取网络与细提取网络进一步提取介质传输率。Li 等<sup>[9]</sup> 提出了一种一体式除雾网络 AOD-Net, 通过对大气散射模型的进一步优化直接生成去雾图像。Zhang 等<sup>[10]</sup> 提出了一种基于生成对抗网络的去雾网络 DCPDN, 可同时学习介质传输率和大气光, 并进行联合估计。以上算法基于大气散射模型, 缺少端到端的学习去雾规律, 所以这类方法存在去雾不彻底的问题。鉴于此, 近年来提出基于端到端的图像去雾网络模型, 该类模型通过训练直接学习雾霾图像与无雾图像之间的映射关系。Ren 等<sup>[11]</sup> 设计了一种端到端去雾网络 GFN, 通过融合白平衡(WB), 对比度增强(CE)和伽马校正(GC)三者信息直接生成无雾图像。Mei 等<sup>[12]</sup> 提出了一种渐进式特征融合网络 PFF-Net 以直接生成无雾图像, 通过将编码器与解码器跳跃连接以增加特征数, 进而提高去雾效果。Engin 等<sup>[13]</sup> 提出了一个端到端网络 Cycle-GAN, 在循环一致性损失的基础上增加循环感知一致性损失以提高纹理信息恢复的质量。Qu 等<sup>[14]</sup> 提出了一种增强型 pix2pix 去雾网络, 将图像去雾问题转换为图像到图像的转换问题。Shao 等<sup>[15]</sup> 在 GAN 的基础上, 提出了一个单图像去雾域适应框架, 用一个双向翻译网络, 通过将图像从一个域转换到另一个域, 来弥合成域和实域之间的差距。上述端到端网络模型比起非端到端网络模型在去雾效果上有着明显的提升, 但由于传统卷积提取特征的局限性, 在一些细节恢复上还是略有不足, 颜色上也存在一定的失真。

近年来随着注意力机制的提出, 并广泛应用于在图像分类<sup>[16]</sup>, 语义分割<sup>[17]</sup> 领域, 取得了较好的效果。受此启发, 同时为了进一步提高网络在去雾中对重要特征的关注度, 本文引入 CBAM(convolutional block attention module, CBAM)<sup>[18]</sup> 机制, 该模块作为一种轻量级注意力模块, 且结构简单, 不会引入过大参数量, 在分类问题与目标检测中有

着较好的实验效果, 但该模块中空间注意力部分特征提取受平均池化和最大池化的限制。

本文针对传统先验方法的颜色失真问题, 非端到端方法的去雾不彻底问题, 提出了一种基于改进 CBAM 注意力机制的端到端卷积神经网络模型。该模型不依赖于大气散射模型, 建立了端到端的映射模型, 同时提高对去雾图像的细节恢复, 使得图像去雾效果优于经典算法。

## 1 神经网络模型构建

### 1.1 基本块

CBAM 作为一种成熟的注意力机制结构, 主要由通道注意力和空间注意力构成。通过在通道维度和空间两个方面, 提高训练过程中重要特征的关注度。在本文所提算法中, 利用该结构替代传统卷积层, 使得网络模型进一步关注更有利于重构无雾图像的特征, 以进一步提高去雾效果。

通过实验部分的消融实验进一步发现, CBAM 模块在去雾后的性能指标上有进一步提升的空间。由于 CBAM 模块的空间注意力部分所关注到的特征是基于通道特征的平均池化和最大池化, 这样限制了空间注意力的特征表达, 在此基础上, 本文做出了进一步改进, 即利用  $1 \times 1$  卷积对多通道特征进行连续降维处理, 不局限于通道平均池化和最大池化两种特征的限制, 通过卷积动态学习特征, 改进 CBAM 注意力模块结构图如图 1 所示。

改进后的 CBAM 模块如式(2)、(3)所示, 其中  $F$  表示改进后模块的输入特征,  $F_1$  表示经过通道注意力后的特征,  $F_2$  表示经过空间注意力后的特征。  $M_c(F)$  表示通道注意力模块,  $M_s(\cdot)$  表示空间注意力模块。  $M_s(\cdot)$  表示矩阵的 Hadamard 乘积。

$$F_1 = M_c(F) \otimes F \quad (1)$$

$$F_2 = M_s(F) \otimes F \quad (2)$$

在该模块中, 通道注意力模块如式(3)所示, 其中  $Avgpool(\cdot)$  表示对特征图平均池化操作,  $Maxpool(\cdot)$  表示对特征图最大池化操作。MLP 表示多层感知机,  $\sigma$  表示激活函数, 在这里使用 Sigmoid 函数。

$$M_c(F) = \sigma(MLP(Avgpool(F))) + MLP(Maxpool(F)) \quad (3)$$

空间注意力模块如式(4)所示, 其中 Conv1, Conv2 表示卷积操作, 使用  $1 \times 1$  卷积分两步减少原特征的通道数。  $f^{7 \times 7}$  表示使用一个  $7 \times 7$  的卷积核进行卷积操作。  $\sigma$  表示激活函数, 在这里使用 Sigmoid 函数。

$$M_s(F) = \sigma(f^{7 \times 7} * Conv2 * (Conv1 * (F))) \quad (4)$$

在改进的 CBAM 模块基础上, 引入残差结构, 设计出改进 CBAM 注意力基本块, 如图 2 所示。每个基本块中引入残差, 一方面有助于网络训练, 另一方面有助于学习到不同的特征。在改进的 CBAM 模块前, 加入一个卷积层和一

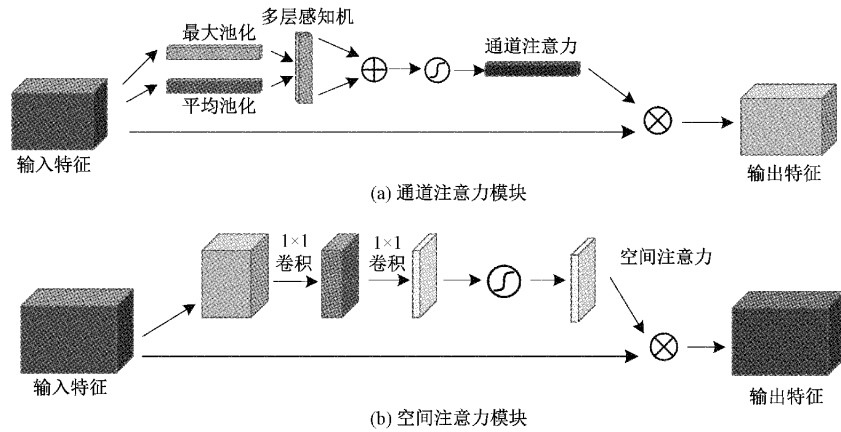


图 1 改进 CBAM 注意力模块结构图




图 2 改进 CBAM 注意力基本块结构图




图 3 残差密集连接块结构

个残差层,其中残差层由一层卷积层和一层激活层构成。两个卷积层均使用  $3 \times 3$  卷积,以保证同尺度特征提取的完整性。

### 1.2 残差密集连接块

残差密集连接模块最早是为了解决图像超分辨率问题而提出<sup>[19]</sup>。在传统卷积层与卷积层之间没有信息交互,为使在去雾过程中获得更为多样的特征信息,在本文去雾网络中引入该模块,通过致密的连通各个卷积层以进一步提取丰富的局部特征。残差密集连接块如图 3 所示,该密集连接块设计了四层卷积层,设置网络模型宽度为 64 通道数,其中每层的增长率设为 64,经过每层卷积层后,均产生 64 通道的特征。

### 1.3 Shuffle Attention 模块

本文去雾网络中,为了在不增加过多参数的情况下对融合后的特征做进一步处理,以保留重要特征,引入 SA (shuffle attention)<sup>[20]</sup> 模块。SA 模块在处理特征前,将通道维度分组为多个子特征组,对于每一个子特征,使用混洗 (shuffle) 单元来描述空间和通道维度上的特征依赖关系,后面进一步对各个子特征进行聚合,并采用“通道混洗 (channel shuffle)”算子实现不同子特征之间的信息交互。SA 模块如图 4 所示,通道注意力与空间注意力并行处理,且处理不同的特征。在融合后对子特征组进行混洗,对模型起到了一定的正则化作用。




图 4 SA 模块结构图

### 1.4 细节恢复模块

由于雾霾会遮盖原图像的部分细节,会进一步影响视觉效果。所以去雾的同时要恢复图像细节以进一步消除雾霾所引起的细节损失。传统的多尺度提取特征虽然可以得到不同尺度下的特征,但仅限于局部细节,无法获取

更大范围感受野的特征,且没有结合提取后的特征与提取前的特征关系,不利于细节的进一步恢复。基于这个问题,设计了一个细节恢复模块,该模块由局部特征恢复块和 3 个平滑扩张卷积块组成。局部特征恢复块在传统局部多尺度卷积的基础上进行了部分改进,如图 5 所示。




图 5 局部特征恢复块结构图

对于输入的特征,分别用  $3 \times 3, 5 \times 5, 7 \times 7, 9 \times 9$  四种卷积核进行并行卷积运算,在卷积过程中不进行填充操作。之后分别用  $1 \times 1$  卷积对 4 组不同尺度的特征进行降通道操作,得到四组单通道特征图,利用反卷积将四组不同尺度的特征变为原输入特征的尺度大小,与原特征进行聚合操作后再进行一次卷积操作。这种设计方式,将多尺度提取的空间信息与原特征的信息进行交互,使细节信息更为丰富。

图 6 所示。




图 6 细节恢复模块结构图

平滑空洞卷积(smoothed dilated convolution,SDC)<sup>[21]</sup>是基于传统空洞卷积而设计,使用空洞卷积的目的就是为了提取更大范围的特征。由于卷积后的特征相关性会减弱,空洞卷积会造成一定的网格伪影<sup>[22]</sup>。基于该问题,在空洞卷积层的后一层添加一层普通卷积层,卷积后的各元素具有一定相关性,为空洞卷积增加了平滑性,可以减少网格伪影现象。在细节恢复模块中,设计了 3 个平滑空洞卷积模块,扩张率分别设为 1,3,5,将其并行连接,在三者输出的基础上特征融合。对多尺度提取部分与平滑空洞卷积部分并行连接,得到细节恢复模块(detail recovery)如

### 1.5 总体结构

在基本块的基础上,对 10 个基本块进行封装得到组块,这种设计方式使网络结构更加模块化,同时在此组块后加入密集连接块,对每个组的输出特征进行进一步的特征提取,以加强组与组之间的特征信息交互。对 3 个组块产生的特征进一步融合,融合过程中利用通道注意力对 3 组特征施以合适权重进而保留有用信息,经过 SA 模块对融合后的特征作进一步并行注意力处理,通过细节恢复模块恢复细节信息后最终得到无雾图像。网络总体结构如图 7 所示。




图 7 网络结构图

### 1.6 损失函数

传统深度学习去雾使用的损失函数为 MSE 损失,由于在图像恢复任务中  $L_1$  损失在峰值信噪比(PSNR)<sup>[23]</sup>和结构相似度(SSIM)<sup>[23]</sup>两个指标上,比 MSE 损失效果更好<sup>[24]</sup>。故本文使用  $L_1$  损失,同时为了进一步描述估计的去雾图像与真实无雾图像的视觉差异,引入感知损失

$L_p$ <sup>[25]</sup>。在这里使用在 ImageNet<sup>[26]</sup>上预训练的 VGG16 作为感知损失网络,从前 3 个阶段(Conv1-2、Conv2-2 和 Conv3-3)的最后一层提取特征。 $L_1$  损失与感知损失  $L_p$  表达式如式(5)(6)所示。其中  $J_i(\cdot)$  表示真实无雾图像中第  $i$  个颜色通道的强度, $\hat{J}_i(\cdot)$  表示经过网络后去雾图像中第  $i$  个颜色通道的强度, $N$  表示图像像素, $i$  表示颜色通道

数。 $\phi_j(\cdot)$ 表示经过 VGG16 卷积层后的特征映射。 $C, W, H$ 表示特征映射后特征图的维度。

$$L_1 = \frac{1}{N} \sum_{x=1}^N \sum_{i=1}^3 (\hat{J}_i(x) - J_i(x)) \quad (5)$$

$$L_p = \sum_{j=1}^3 \frac{1}{C_j H_j W_j} \|\phi_j(\hat{J}_i(x) - \phi_j(x))\|_2^2 \quad (6)$$

通过组合  $L_1$  损失和感知损失  $L_p$ , 定义总损失如下式(7)所示, 其中  $\lambda$  为参数, 用于调整两个损失分量上的相对权重。这里  $\lambda$  设置为 0.05。

$$L = L_1 + \lambda L_p \quad (7)$$

## 2 数值实验与分析

### 2.1 实验环境

本文使用公开合成数据集 RESIDE<sup>[27]</sup> 作为网络模型的训练与测试。RESIDE 包含室内和室外场景中的合成模糊图像, 室内训练集 (ITS) 总共包含 13 990 幅雾霾室内图像, 由 1 399 张清晰图像生成, 其中  $\beta \in [0.6, 1.8]$  和  $\alpha \in [0.7, 1.0]$ ; 室外训练集 (OTS) 共包含 296 695 张模糊的室外图像, 由 8 477 张清晰图像生成, 其中  $\beta \in [0.04, 0.2]$  和  $\alpha \in [0.8, 1.0]$ 。测试采用合成客观测试集 (SOTS), 由 500 幅室内雾霾图像和 500 幅室外雾霾图像组成。

本文所做实验基于 python 语言, 使用 pytorch 深度学习框架训练网络模型并测试。实验环境在处理器为 Intel(R) Core(TM) i7-9700 CPU 3.70 GHz、内存 32 G 的主机上, 使用 NVIDIA GeForce GTX 3090 GPU 运行。在训练前把训练集图像随机裁剪为  $400 \times 400$  大小的图像子块, 使用 Adam 优化器对网络进行训练, 其中  $\beta_1$  和  $\beta_2$  分别采用默认值 0.9 和 0.999。迭代次数设为  $2 \times 10^5$  次, 初始学习率设为 0.0003, Batchsize 设为 1。本文采用余弦退火算法<sup>[28]</sup> 对学习率进行动态调整, 随着训练次数增加, 模型越接近最优解, 此时学习率应渐渐变小。通过遵循余弦函数将学习率从初始值调整为 0, 假设批次总数为  $T$ ,  $\eta$  是初始学习率, 则在批次  $t$  处, 学习率  $\eta_t$  计算如式(8)所示。

$$\eta_t = \frac{1}{2} (1 + \cos(\frac{t\pi}{T})) \eta \quad (8)$$

### 2.2 合成数据集 (SOTS) 上的定量实验

为了测试所提算法的性能, 首先在 RESIDE 合成数据

集 SOTS 进行实验, 选取峰值信噪比 (PSNR)<sup>[23]</sup> 和结构相似度 (SSIM)<sup>[23]</sup> 作为客观性能评价指标。这里与近年来图像去雾研究中的主流算法做对比, 即 DCP<sup>[6]</sup>, DehazeNet<sup>[7]</sup>, AODNet<sup>[9]</sup>, DCPDN<sup>[10]</sup>, GFN<sup>[11]</sup>, EPDN<sup>[14]</sup>, GCANet<sup>[21]</sup> 以及 GridDehazeNet<sup>[25]</sup>。室内数据集实验结果如表 1 所示, 室外数据集实验结果如表 2 所示。

表 1 室内数据集上实验结果

方法	PSNR	SSIM
DCP	16.62	0.817 9
DehazeNet	21.14	0.847 2
AOD-Net	19.06	0.850 4
DCPDN	15.85	0.844 9
GFN	22.30	0.880 0
EPDN	25.06	0.923 2
GCANet	30.23	0.980 0
GridDehazeNet	32.16	0.983 6
本文算法	<b>35.26</b>	<b>0.985 4</b>

表 2 SOTS 室外数据集上实验结果

方法	PSNR	SSIM
DCP	19.13	0.814 8
DehazeNet	22.46	0.851 4
AOD-Net	20.29	0.876 5
DCPDN	19.93	0.844 9
GFN	21.55	0.844 4
EPDN	22.57	0.863 0
GridDehazeNet	30.86	<b>0.981 9</b>
本文算法	<b>31.34</b>	0.975 2

### 2.3 合成数据集 (SOTS) 上的定性实验

为了从视觉角度进一步测试所提算法的去雾效果, 分别从合成测试集中选取了 3 组室内图像和室外图像进行定性实验。选取 DCP<sup>[6]</sup>, DehazeNet<sup>[7]</sup>, AODNet<sup>[9]</sup>, DCPDN<sup>[10]</sup>, GFN<sup>[11]</sup>, EPDN<sup>[14]</sup> 5 种去雾算法作为对比算法, 室内数据集测试如图 8 所示, 室外数据集测试如图 9 所示。

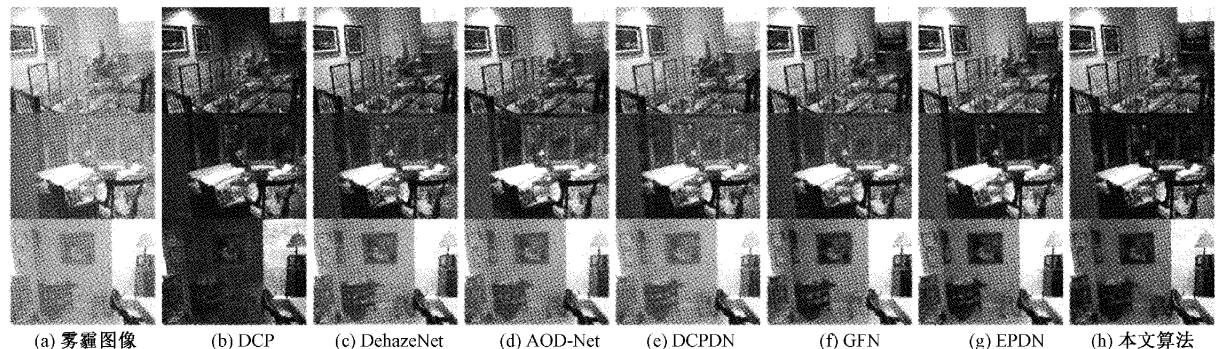


图 8 室内合成测试集 (SOTS) 结果对比

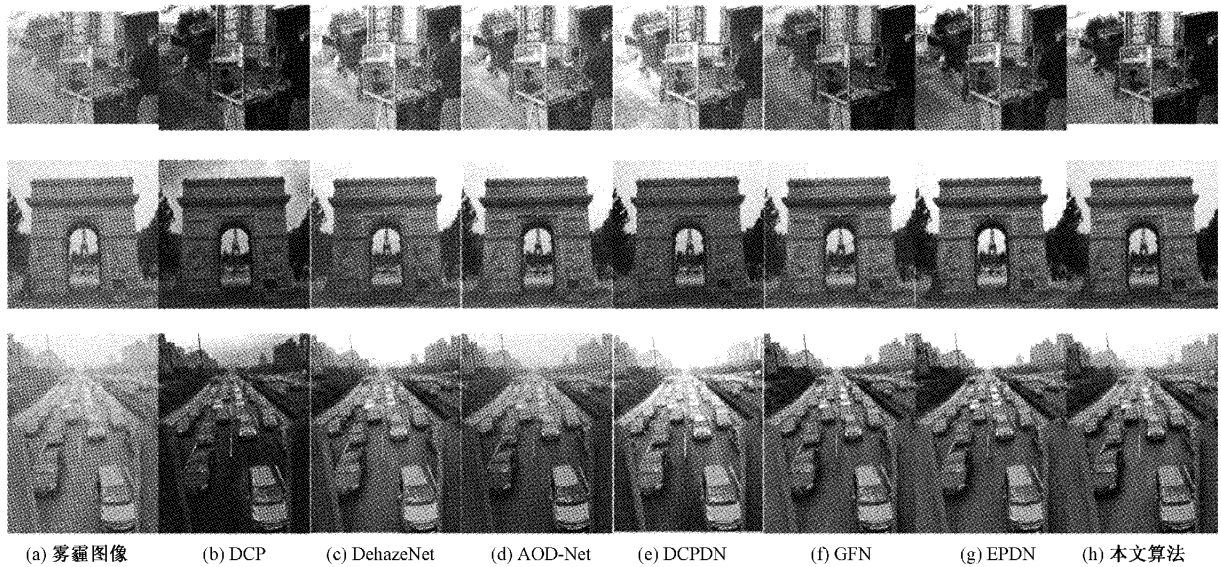


图 9 室外合成测试集(SOTS)结果对比

从测试结果可看出,DCP 算法无论是室内图像还是室外图像,去雾后的图像会出现部分颜色失真,原因在于先验知识建立的数学模型,其表达能力有限。而 DehazeNet, AOD-Net,DCPDN 算法从去雾效果上来看,去雾后的图像仍有一定的雾霾残余,去雾不够彻底。这 3 种算法网络结构不是端到端,由于网络输出的是雾霾图像的介质传输率,而去雾图像需要进一步利用大气散射模型重构,所以会产生一定误差,影响去雾效果。GFN 算法为端到端网络结构,通过选取 3 个典型特征,生成置信度图,综合特征和置信度图恢复去雾图像。其效果比前面算法有明显进步,但仍然有雾霾残余。EPDN 算法与前述算法相比,雾霾残留已大大减少,从视觉效果看与本文提出算法差异不大。本文提出算法在去雾的同时,还尽可能多的保留了图像细节,尤其是在恢复一些细节纹理方面,具有更好的效果通过恢复细节以进一步消除雾霾残留带来的影响。

#### 2.4 真实图像上的实验

为了进一步评估本文所提的算法性能,选取了四组真实世界的雾霾图像进行测试,测试结果如图 10 所示。本文提出的算法在真实图像上也有较好的去雾效果,且能恢复图像的细节。尤其是在 pumpkin 组和 road 组图像中。在 city 组,DCP 算法造成了严重的颜色失真,尤其在天空区域,图像信息丢失严重,说明了在天空区域 DCP 算法暗通道参数的估计的准确性差。DehazeNet, MSCNN, AOD-Net 存在去雾不彻底的问题,去雾后整体风格过于偏暗。在 train 组与 city 组,使用 MSCNN 算法去雾后,与原图相比颜色失真明显,同时四组图像存在光晕现象。GFN 算法存在一定的细节失真,如 road 组,GFN 算法去雾后图像中间部分颜色失真,颜色偏亮,在 city 组中,GFN 去雾效果在图像中的大楼处过于偏亮。所提算法与 GFN 算法相比,在 train 组图像中,火车部分去雾效果不如 GFN 算法,说




图 10 真实雾霾图像结果对比

明所提算法对于浓雾模块,去雾效果不够好。但整体来看,还是有一定的去雾效果,尤其是近景处,如铁轨部分。与 DCP, DehazeNet, MSCNN, AOD-Net 相比,在对远景雾霾图像去雾时,所提算法在一定程度上克服了颜色失真与雾霾残留问题,显示出其较优的去雾性能。

### 2.5 消融实验

为了进一步探讨各模块在去雾过程中对去雾的影响,设计了 5 组消融实验。其中四组探讨密集连接残差块(dense),细节恢复块(recovery)和特征融合块(feature fusion)对去雾指标的影响。以 Baseline 作为基本模型,在这个模型中,没有密集连接残差块,细节恢复块,其中特征融合块由普通卷积块(convolution)代替。消融实验结果如表 3 所示。实验结果可以表明,添加密集连接残差块对 PSNR 指标的提升有着很好的效果,同时特征融合比起传统卷积,效果更好。

表 3 消融实验结果

模型	PSNR	SSIM
baseline	32.46	0.979 6
baseline+dense	34.00	0.981 2
baseline+dense+recovery+convolution	34.27	0.983 4
baseline+dense+recovery+feature fusion	<b>35.26</b>	<b>0.985 4</b>

为了进一步证明在本文所提基本块中原 CBAM 模块去雾指标的不足,设计了一组对比实验,如表 4 所示。将改进后的 CBAM 模块用于基本块中,从实验结果可以看出,相对于 CBAM 模块,改进后的 CBAM 模块在指标性能上更优。尤其是在空间特征提取中有着更加丰富的特征表达。

表 4 基本块中改进前后 CBAM 实验对比

模型	PSNR	SSIM
CBAM	33.01	0.974 3
改进 CBAM	<b>35.26</b>	<b>0.985 4</b>

为了进一步探究细节恢复模块在网络不同位置的效果,设计了一组对比实验,实验的基础模型为上述消融实验的 baseline+dense+recovery+convolution 模型,将细节恢复模块分别放于网络前端和网络后端,并分别命名为 model1 和 model2,实验结果如表 5 所示。实验结果表明,将细节恢复模块放置在网络后端更有利于无雾图像的恢复。

表 5 细节恢复模块位于不同位置的消融实验结果

模型	PSNR	SSIM
model1	32.64	0.980 8
model2	<b>34.00</b>	<b>0.983 4</b>

## 3 结 论

本文提出了一种基于注意力机制的细节恢复网络,该网络是一个端到端去雾网络,不依赖大气散射模型。对于注意力模块,为进一步提高网络性能,在传统的 CBAM 注意力模块上进行了改进,使得其提取和表达空间注意力特征的能力进一步增强。同时还设计了细节恢复模块与密集连接残差块,不但恢复了图像细节信息并强化了卷积层之间的交互作用。实验结果表明本文所提算法模型在定量指标和视觉效果上尤其对于室内薄雾有不错的效果。

### 参考文献

- [1] 沈琛,曹风云,杨雪洁. 夜间图像去雾研究综述与展望[J]. 电子测量与仪器学报, 2020, 34(11): 101-114.
- [2] 彭熙舜,陆安江,龙纪安,等. 结合图像分层与暗通道的雾霾图像增强[J]. 电子测量技术, 2022, 45(2): 123-128.
- [3] MCCARTNEY J, HALLFREEMAN F. Optics of the atmosphere: Scattering by molecules and particles physics Today[J]. Optica Acta: International Journal of Optics, 1977, 30(5): 76-77.
- [4] NAYAR S K, NARASIMHAN S G. Vision in bad weather [C]. Pro of the 7th IEEE International Conference on Computer Vision, IEEE, 1999, 2: 820-827.
- [5] 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.
- [6] 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.
- [7] 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.
- [8] REN W, LIU S, ZHANG H, et al. Single image dehazing via multi-scale convolutional neural networks [C]. European Conference on Computer Vision. Springer, Cham, 2016: 154-169.
- [9] LI B, PENG X, WANG Z, et al. Aod-net: all-in-one dehazing network [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 4770-4778.
- [10] ZHANG H, PATEL V M. Densely connected pyramid dehazing network [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 3194-3203.

- [11] REN W, MA L, ZHANG J, et al. Gated fusion network for single image dehazing[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018; 3253-3261.
- [12] MEI K, JIANG A, LI J, et al. Progressive feature fusion network for realistic image dehazing[C]. Asian Conference on Computer Vision, Springer, Cham, 2018; 203-215.
- [13] 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.
- [14] 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.
- [15] SHAO Y, LI L, REN W, et al. Domain adaptation for image dehazing[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2020; 2808-2817.
- [16] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018; 7132-7141.
- [17] FU J, LIU J, TIAN H, et al. Dual attention network for scene segmentation[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019; 3146-3154.
- [18] WOO S, PARK J, LEE J Y, et al. Cbam: convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision, 2018; 3-19.
- [19] ZHANG Y, TIAN Y, KONG Y, et al. Residual dense network for image super-resolution [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018; 2472-2481.
- [20] ZHANG Q L, YANG Y B. SA-NET: shuffle attention for deep convolutional neural networks[C]. ICASSP 2021-2021 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), IEEE, 2021; 2235-2239.
- [21] 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, IEEE, 2019; 1375-1383.
- [22] WANG P, CHEN P, YUAN Y, et al. Understanding convolution for semantic segmentation[C]. 2018 IEEE Winter Conference on Applications of Computer Vision, IEEE, 2018; 1451-1460.
- [23] 张登银, 鞠铭焯, 钱雯. 图像去雾算法研究现状与展望[J]. 南京邮电大学学报(自然科学版), 2020, 40(5): 101-111.
- [24] ZHAO H, GALLO O, FROSIO I, et al. Loss functions for image restoration with neural networks[J]. IEEE Transactions on computational imaging, 2016, 3(1): 47-57.
- [25] 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.
- [26] RUSSAKOVSKY O, DENG J, SU H, et al. Imagenet large scale visual recognition challenge[J]. International Journal of Computer Vision, 2015, 115(3): 211-252.
- [27] LI B, REN W, FU D, et al. Benchmarking single-image dehazing and beyond[J]. IEEE Transactions on Image Processing, 2018, 28(1): 492-505.
- [28] HE T, ZHANG Z, ZHANG H, et al. Bag of tricks for image classification with convolutional neural networks [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019; 558-567.

### 作者简介

**王子昭**, 硕士研究生, 主要从事图像去雾, 深度学习相关研究。

E-mail: 20211030306@stumail.xsyu.edu.cn

**景明利**(通信作者), 博士, 副教授, 硕士生导师, 主要从事压缩感知中的稀疏低秩恢复, 数值优化算法、图像处理及机器学习相关研究。

E-mail: mljingsy@xsyu.edu.cn

**史金钢**, 博士, 副教授, 博士生导师, 主要从事计算机视觉, 机器学习, 深度学习研究。

E-mail: jinggang@mail.xjtu.edu.cn

**陈腾飞**, 硕士研究生, 主要从事图像去阴影, GAN 网络相关研究。

E-mail: 20212030318@stumail.xsyu.edu.cn

**刘婉春**, 硕士研究生, 主要从事图像去模糊, 深度学习相关研究。

E-mail: 20212030436@stumail.xsyu.edu.cn

**樊锐博**, 硕士研究生, 主要从事图像处理, 低秩与稀疏、视频前背景分离相关研究。

E-mail: fanx1997@163.com