

# Journal of System Simulation

Volume 34 | Issue 8

Article 1

8-15-2022

## Image Dehazing Network Based on Densely Connected Residual Block and Channel Pixel Attention

Weidong Jin

1.School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China;2.China-ASEAN International Joint Laboratory of Integrated Transport, Nanning University, Nanning 530200, China;;  
wdjin@home.swjtu.edu.cn

Shuli Zhang

1.School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China;  
1273438490@qq.com

Peng Tang

1.School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China;

Man Zhang

1.School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>

 Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

# Image Dehazing Network Based on Densely Connected Residual Block and Channel Pixel Attention

## Abstract

**Abstract:** A lot of research achievements have been made in image dehazing based on neural network, but there aiming at the fog residue, even the color distortion and texture loss, in complex outdoor image dehazing, an image dehazing network based on densely connected residual block and channel pixel attention is proposed. *Densely connected residual blocks are used to extract and fuse the features of foggy images, and the repair module with channel pixel attention mechanism is used to repair the color and texture of the feature maps.* The experimental results show that, compared with the existing methods, the proposed method significantly improves the objective evaluation index and subjective visual quality, effectively avoid the color distortion, texture loss and residual fog in the process of image dehazing.

## Keywords

image dehazing, densely connected residual block, attention mechanism, color distortion, detail texture

## Recommended Citation

Weidong Jin, Shuli Zhang, Peng Tang, Man Zhang. Image Dehazing Network Based on Densely Connected Residual Block and Channel Pixel Attention[J]. Journal of System Simulation, 2022, 34(8): 1663-1673.

# 基于稠密残差块与通道像素注意力的图像去雾网络

金炜东<sup>1,2</sup>, 张述礼<sup>1\*</sup>, 唐鹏<sup>1</sup>, 张曼<sup>1</sup>

(1. 西南交通大学 电气工程学院, 四川 成都 610031; 2. 南宁学院 中国-东盟综合交通国际联合实验室, 广西 南宁 530200)

**摘要:** 为解决复杂的室外图像进行去雾, 依然会有雾气残留, 甚至出现颜色失真和纹理丢失问题, 提出一种基于稠密残差块与通道像素注意力的图像去雾网络, 利用稠密残差块对有雾图像进行特征提取和融合, 用带通道像素注意力机制的修复模块对特征图进行颜色和纹理上的修复。实验结果表明: 该方法在客观评价指标和主观视觉质量上都有明显提升, 有效避免了去雾过程中的颜色失真、纹理丢失和雾气残留问题。

**关键词:** 图像去雾; 稠密残差块; 注意力机制; 颜色失真; 细节纹理

中图分类号: TP391.9

文献标志码: A

文章编号: 1004-731X(2022)08-1663-11

DOI: 10.16182/j.issn1004731x.joss.21-1160

## Image Dehazing Network Based on Densely Connected Residual Block and Channel Pixel Attention

Jin Weidong<sup>1,2</sup>, Zhang Shuli<sup>1\*</sup>, Tang Peng<sup>1</sup>, Zhang Man<sup>1</sup>

(1. School of Electrical Engineering, Southwest Jiaotong University, Chengdu 610031, China;

2. China-ASEAN International Joint Laboratory of Integrated Transport, Nanning University, Nanning 530200, China)

**Abstract:** A lot of research achievements have been made in image dehazing based on neural network, but there aiming at the fog residue, even the color distortion and texture loss, in complex outdoor image dehazing, an image dehazing network based on densely connected residual block and channel pixel attention is proposed. *Densely connected residual blocks are used to extract and fuse the features of foggy images, and the repair module with channel pixel attention mechanism is used to repair the color and texture of the feature maps.* The experimental results show that, compared with the existing methods, the proposed method significantly improves the objective evaluation index and subjective visual quality, effectively avoid the color distortion, texture loss and residual fog in the process of image dehazing.

**Keywords:** image dehazing; densely connected residual block; attention mechanism; color distortion; detail texture

## 引言

由于雾气、烟尘等悬浮颗粒物的存在, 在室外有雾场景下拍摄的图像, 会出现能见度下降、对比度降低、细节纹理丢失等现象, 严重影响了图像质量, 同时也使后续一系列高级计算机视觉任务如目标检测、目标跟踪、图像分类等的准确

率大大降低<sup>[1]</sup>。因此, 如何对有雾图像进行去雾处理, 成为了计算机视觉领域的一个重要问题。

当前, 对图像去雾方法的研究主要分为图像增强和图像复原两大方向。图像增强主要通过提高图像对比度、消除噪声来提升图像的视觉效果, 大多为依靠先验知识或以大气散射模型<sup>[2]</sup>为主的物

收稿日期: 2021-11-11 修回日期: 2022-01-24

基金项目: 国家重点研发计划(2016YFB1200401-102F)

第一作者: 金炜东(1959-), 男, 博士, 教授, 研究方向为智能信息处理、模式识别等。E-mail: wdjin@home.swjtu.edu.cn

通讯作者: 张述礼(1998-), 男, 硕士生, 研究方向为深度学习、图像处理。E-mail: 1273438490@qq.com

理模型。He 等<sup>[3]</sup>通过观察大量户外无雾图像提出了暗通道先验理论(dark channel prior, DCP), 即对于无雾图像, 总会有至少一个通道有像素很低的值, 但该方法在计算大气光照时容易出现误差导致颜色失真; Zhu 等<sup>[4]</sup>发现有雾图像像素的亮度和饱和度会随着雾浓度变化而快速变化, 以此提出颜色衰减先验模型(color attenuation prior, CAP), 借助有雾图像的深度图恢复出无雾图像, 但该方法在深度图估计不准的情况下难以恢复其本来的色彩, 普适性不强; Zhao 等<sup>[5]</sup>提出了多尺度最优融合模型(multi-scale optimal fusion, MOF), 以最佳方式融合像素级(pixel-wise)和斑块级(patch-wise)的DCP传输图, 有效缓解了去雾图像过饱和, 还提出了2种后处理方法来提升模型的鲁棒性; 金炜东<sup>[6-7]</sup>等提出了基于结构化森林的图像细节强化方法, 将图像去雾应用于铁路场景, 降低了铁路异常接触网的巡检难度。

随着深度学习的发展, 越来越多的人将深度学习应用于图像复原领域, 该类方法通常基于卷积神经网络(convolution neural network, CNN)构建去雾模型。Cai 等<sup>[8]</sup>设计了一个可训练的神经网络来估计有雾图像的透射率, 再根据大气散射模型恢复出无雾图像, 但该模型只考虑了单一光源场景, 在室外场景去雾效果并不理想; Ren 等<sup>[9]</sup>提出了多尺度深度神经网络模型(multi-scale CNN, MSCNN), 用粗尺度网络估计整体传输图, 再用细尺度网络进行局部细化; Li 等<sup>[10]</sup>将大气散射模型中的2个参数透射率和大气光照合并为一个参数, 再结合CNN搭建了一个轻量级网络(all-in-one network, AOD-Net), 该网络在做到快速去雾的同时还能嵌入到其他处理高级计算机视觉任务的网络中去, 然而Ren和Li的2种方法在去除高浓度雾时会出现明显的雾气残留; Qin 等<sup>[11]</sup>设计了深度神经网络去雾模型(feature fusion attention network, FFA-Net), 加入的特征注意力机制使其更关注有雾图像中的有用信息, 提高了CNN的

表征能力, 但复杂的模型降低了去雾处理的速度。

在上述方法中, 图像增强的方法基于大量先验知识, 但这些先验知识并不能在所有场景都成立, 当环境变化时, 通过先验知识计算出的大气光照存在误差, 去雾时容易出现颜色失真; 而基于深度学习的几种方法常因无法将图像的细节特征传递到更深的网络层, 导致复原图像有雾气残留或出现纹理丢失的现象。针对这些问题, 本文提出了一种基于稠密残差块与通道像素注意力的图像去雾网络, 该网络不依靠先验知识或物理模型, 是一个端到端可训练的去雾网络, 可直接将有雾图像复原为无雾图像。

## 1 本文方法

### 1.1 网络总体结构

本文所提出的网络由特征提取(Feature Extraction)、颜色纹理修复(Color Texture Repair)和图像复原(Image Restoration)3部分构成, 总体结构如图1所示。特征提取模块主要由3个残差结构(densely connected residual with channel attention, DRCA)组成, 针对现有去雾网络提取有雾图像特征时信息易丢失, 导致复原图像仍有雾气残留的问题, 本文将残差网络<sup>[12]</sup>由普通连接方式改为稠密连接残差块(densely connected residual block, DRB)<sup>[13]</sup>, 连续的稠密连接加强了特征提取的能力, 使浅层特征能更好地传递到后续更深的网络层中去。同时, 为提高DRB处理大量信息时的效率, 还在其之后添加了通道注意力块(channel attention block, CAB)<sup>[14]</sup>对DRB的输出做通道加权。

此外, 为避免去雾图像出现颜色失真以及细节纹理丢失, 本文在网络中添加了一个由通道注意力块CAB和像素注意力块(pixel attention block, PAB)连接而成的颜色纹理修复模块, 分别由CAB提取颜色信息、PAB提取细节纹理信息。最后由图像复原模块将修复后的特征图还原为无雾图像。

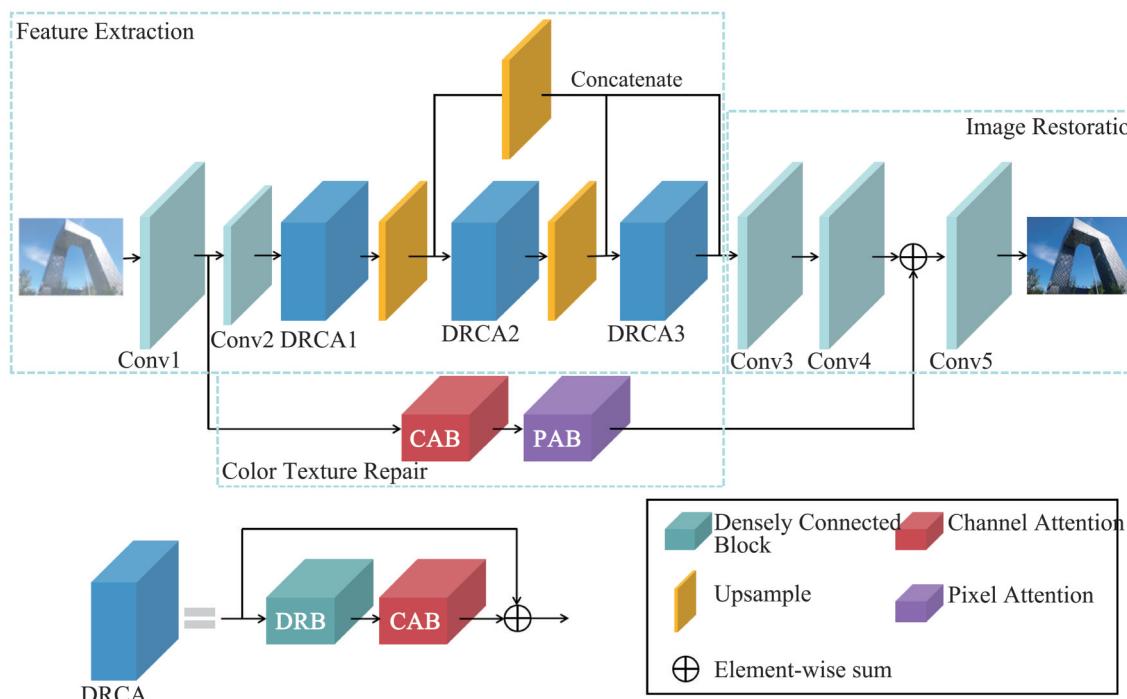


图1 网络总体结构  
Fig. 1 Architecture of network

## 1.2 特征提取模块

输入的有雾图像经过特征提取模块提取图像中物体的颜色纹理以及雾气特征等信息。该模块包含2个卷积层(Conv1, Conv2), 3个带通道注意力机制的残差结构(DRCA1-DRCA3)和3个上采样层(Upsample)。Conv1和Conv2的卷积核大小都为3, 步长分别为1和2, Conv2中还包含一个步长为2的池化层。2个卷积层全面提取特征的同时, 还通过设置卷积步长和添加池化层对特征图进行下采样, 降低了特征图尺寸, 减少了后续的计算量。

3个带通道注意力机制的残差结构DRCA由稠密连接的残差块DRB和通道注意力块CAB组成。DRB的内部结构如图2所示, 前2个 $3 \times 3$ 卷积的输入输出采用稠密连接尽可能多的提取特征, 最后的 $1 \times 1$ 卷积将特征图做信息整合, 输出通道数为32。为加快网络收敛的速度, 本文还在每个卷积层后添加批量归一化层(batch normalization, BN)<sup>[15]</sup>, 每层的激活函数都选取ReLU。DRCA通过稠密连接的方式将每一层的特征都连接起来并传递给下一

层, 达到了前后多级特征融合的效果, 这样的操作不仅可以防止随着网络层数加深而导致的细节信息丢失, 还在一定程度上避免了反向传播过程中出现梯度消失<sup>[16]</sup>。

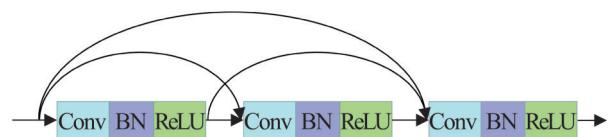


图2 稠密连接残差块结构  
Fig. 2 Architecture of DRB

为提高残差块的表征能力, 使DRB在提取特征时能更加关注有雾图像中的有用信息, 提高信息提取的效率, 本文还对DRB的输出特征图进行了通道加权, 加入的CAB块内部结构与原理将在1.3.1节和1.3.2节与像素注意力块PAB一同阐述。

上采样层(Upsample)将DRCA提取到的特征图进行上采样, 使其在传递给下一个DRCA时有不同程度的感受野, 提高了残差块提取不同尺度特征的能力。为了避免反卷积过程中出现棋盘效应(Checkerboard Artifacts)<sup>[17]</sup>, 本文采用双线性插

值法<sup>[18]</sup>完成对特征图的上采样。最后把3个稠密残差块各自的输出按通道堆叠起来,如图1中的Concatenate,堆叠操作整合了残差结构DRCA1-DRCA3输出的信息,确保了特征图在经过连续卷积操作后的内容完整性。

### 1.3 颜色纹理修复模块

颜色失真、纹理丢失是图像去雾研究中最难处理的问题之一<sup>[19]</sup>。当前大部分基于神经网络的去雾模型并没有针对该问题给出明确的解决方案,对此,本文设计了颜色纹理修复模块对特征图进行修复,该模块由通道注意力块和像素注意力块连接而成。

越来越多的研究表明,将注意力机制运用于神经网络,能显著提升模型性能。Hu等<sup>[14]</sup>通过显式地建模通道之间的相互依赖关系,自适应地校准通道的特征响应。Woo等<sup>[20]</sup>在Hu等的基础上采用最大合并和平均合并2种方式处理通道域的特征信息,再利用空间域上的注意力进一步推动模型性能。本文考虑了通道和像素点2个维度的信息,采取顺序连接、分级处理的方式,依次在特征图的通道和像素点上使用注意力机制,使模型自适应地学习通道和像素2个维度上的有用信息,同时抑制无用信息。

在RGB三通道图像中,图像的颜色是由每个通道的像素值组合后决定的,本文通过引入通道注意力的方式,给仍然留有原始图像颜色信息的浅层特征图的每个通道重新分配权重,并在网络训练过程中以监督学习的方式自适应校准该权重,改变复原图像各通道的比重,尽可能让复原图像接近其本来的颜色。类似地,图像中物体的纹理细节属于像素点特征,为了更清晰地还原物体的纹理,本文设计了像素注意力块,为仍然留有原始图像纹理信息的浅层特征图的每个像素点分配权重,使最终复原的图像在细节纹理上更接近原始图像的像素分布。另外,雾气在每个像素点上的分布通常是不均匀的,像素注意力块的加入也使得网络模型能够更加关注雾气的浓度信息,为模型处理不同浓度的雾气提供了灵活性。

#### 1.3.1 通道注意力块

本文中通道注意力块CAB的内部结构如图3所示。令输入的特征图为 $F_c$ ,  $F_c \in \mathbb{R}^{C \times H \times W}$ ,其中,C为特征图 $F_c$ 的通道数,H和W分别为 $F_c$ 的高和宽,特征图每个通道的权重以向量形式记为 $\alpha \in \mathbb{R}^{C \times 1 \times 1}$ 。

为求得通道权重 $\alpha$ ,先对 $F_c$ 进行全局平均池化(Global Average Pooling),得到大小为 $C \times 1 \times 1$ 的特征图 $G_c$ ,再对 $G_c$ 进行1次卷积,将通道数缩减为 $C/r$ , $r$ 为缩放系数<sup>[13]</sup>,第2次卷积将通道数还原为C,2次卷积在减少计算量的同时,还增加了网络的非线性,由Sigmoid函数将通道权重 $\alpha$ 约束在[0,1]之间,整个计算过程为

$$\alpha = \sigma(\text{Conv}(\delta(\text{Conv}(G_c)))) \quad (1)$$

式中:Conv为卷积操作;  $\delta$ 和 $\sigma$ 分别为ReLU和Sigmoid激活函数。

如图3中不同的颜色代表 $\alpha$ 给各通道分配的不同权重,将 $\alpha$ 与 $F_c$ 中各通道的对应元素相乘,最终得到通道注意力加权后的特征图 $F_{ca}$ ,计算过程为

$$F_{ca} = \alpha \otimes F_c \quad (2)$$

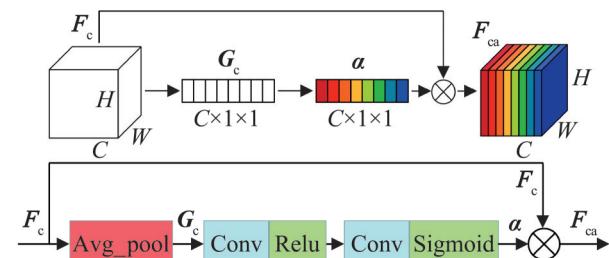


图3 通道注意力块结构

Fig. 3 Architecture of CAB

#### 1.3.2 像素注意力块

与CAB类似,像素注意力块PAB对特征图每个像素点进行加权,其内部结构如图4所示。令输入的特征图为 $F_p$ ,  $F_p \in \mathbb{R}^{C \times H \times W}$ ,特征图每个像素点的权重以向量形式记为 $\gamma \in \mathbb{R}^{1 \times H \times W}$ ,所含符号与CAB中一致,不同的是,PAB中不设置平均池化层,通过第1个卷积将 $F_p$ 的通道数缩减为 $C/r$ ,再由第2个卷积将特征图压缩为 $1 \times H \times W$ ,只关注像素点特征,由Sigmoid函数将像素点权重 $\gamma$ 约束在

[0, 1]之间，整个计算过程为

$$\gamma = \sigma(\text{Conv}(\delta(\text{Conv}(F_p)))) \quad (3)$$

如图4中将像素权重 $\gamma$ 与 $F_p$ 中的对应元素相乘，即得到像素注意力加权后的特征图 $F_{pa}$ 。 $F_{pa}$ 中不同的小方块代表 $\gamma$ 为每个像素点分配的不同权重，计算过程为

$$F_{pa} = \gamma \otimes F_p \quad (4)$$

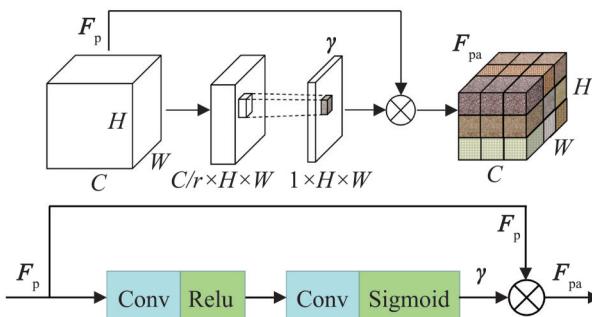


图4 像素注意力块结构  
Fig. 4 Architecture of PAB

如图1所示，有雾图像经过Conv1后得到浅层特征图，将留有原始图像颜色纹理信息的浅层特征图传入颜色纹理修复模块，由CAB进行通道加权，PAB进行像素点加权，并将得到的特征图以近似全局残差的形式传入图像复原模块。

#### 1.4 图像复原模块

由图像复原模块将前2个模块提取的特征图复原为去雾图像。该模块由3个卷积层(Conv3~Conv5)组成，Conv3用 $1 \times 1$ 大小的卷积核对特征提取模块提取的特征图做整合细化处理，Conv4和Conv5的卷积核大小均为 $3 \times 3$ ，步长均为1，Conv4主要对特征图进行降维，其输出与修复模块得到的特征图相融合后传入最后的Conv5，Conv5的输出即是复原的去雾图像。

#### 1.5 损失函数

图像去雾是图像复原任务的一种，因此本文采取监督学习的方式，选取 $L_2$ 损失即均方差损失(mean squared error, MSE)<sup>[21]</sup>作为模型的损失函数：

$$L_2 = \frac{1}{NHW} \sum_{i=1}^N \| \hat{J}_i - J_i \|^2 \quad (5)$$

式中： $N$ 为训练集的样本数； $H$ 和 $W$ 为训练集图像的高和宽； $\hat{J}_i$ 为原始清晰图像； $J_i$ 为生成的去雾图像。

## 2 实验结果与分析

### 2.1 数据集

本文选取公开数据集 RESIDE(realistic single image dehazing)<sup>[22]</sup>中的OTS(outdoor training sets)室外数据集作为训练集。OTS 数据集由 2 061 张原始室外无雾图像和 72 135 张合成室外有雾图像组成，合成雾的大气光值在 0.8~1.0 之间，大气散射系数在 0.04~0.2 之间，本文选取了大气光值 $A$ 为 {0.8, 1.0}、大气散射系数 $\beta$ 为 {0.06, 0.1, 0.16, 0.2} 的有雾图像 15 688 张以及对应的原始无雾图像 1 961 张作为训练集，剩余的 100 张原始无雾图像以及对应的 400 张有雾图像作为测试集 A，测试集 A 的有雾图像同样按 $\beta$ 分为 {0.06, 0.1, 0.16, 0.2} 4 个等级，这 4 个具有代表性的 $\beta$ 等级在主观视觉上可以等效看作雾气的浓度， $\beta$ 与雾气的浓度成正比。由于测试集 A 与训练集来源相同，且都为合成有雾图像，为验证本文模型的鲁棒性和在真实室外环境下的去雾效果，还选取了 50 张不同场景下的具有挑战性的室外真实有雾图像作为测试集 B。

### 2.2 训练设置和评价指标

本文采用监督学习的方式，将输入的合成有雾图像和对应的原始无雾图像的大小全部修改为 400×400 的 RGB 三通道图像后开始训练，取批量大小 batchsize 为 8，初始学习率设置为 0.001，每 10 轮迭代后学习率衰减为原来的 0.7，总迭代次数为 100 次。利用 Adam 优化器进行优化，动量参数 $\beta_1$ 和 $\beta_2$ 分别设置为 0.9 和 0.999，权重衰减参数设置为 0.000 1。整个过程是基于 pytorch 框架在 NVIDIA 1080Ti GPU 上训练完成的。

本文选取 PSNR 和 SSIM 作为测试集 A 的评价

指标；针对真实有雾测试集B，由于无雾图像的暗通道比有雾图像更稀疏，因此选取暗通道损失 $L_{dc}^{[23]}$ 作为真实数据集的评价指标， $L_{dc}$ 与图像上残留的雾气成正比，计算过程为

$$D(I) = \min_{y \in N(x)} (\min(I^c(y))) \quad (6)$$

$$L_{dc} = \frac{1}{N} \sum_{i=1}^N \|D_{J_i}\|_1 \quad (7)$$

式中： $x$ 和 $y$ 为像素坐标； $I^c$ 为图像第 $c$ 个通道； $N(x)$ 为以 $x$ 为中心的图像补丁； $J_i$ 为去雾图像；用 $l_1$ 正则化来约束暗通道的稀疏性； $N$ 为图像数量。

将本文所提出的方法与几个具有代表性的去雾方法进行比较，包括DCP<sup>[3]</sup>、CAP<sup>[4]</sup>、MOF<sup>[5]</sup>、MSCNN<sup>[9]</sup>和AOD-Net<sup>[10]</sup>。

### 2.3 在合成室外数据集上的结果

分别用上述提到的模型与本文所提出的方法

表1 不同 $\beta$ 下各方法在合成室外数据集上的结果Table 1 Results of each method on synthetic outdoor dataset under different  $\beta$ 

方法	$\beta=0.06$		$\beta=0.10$		$\beta=0.16$		$\beta=0.20$		Average	
	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM
DCP	16.25	0.813 3	16.01	0.818 4	15.89	0.799 8	15.91	0.790 7	16.02	0.805 6
CAP	21.61	0.881 9	22.15	0.893 2	21.98	0.874 4	20.77	0.843 2	21.63	0.873 2
MOF	18.57	0.861 2	18.65	0.872 2	18.96	0.857 3	18.63	0.833 3	18.70	0.855 1
MSCNN	20.38	0.851 0	23.61	0.894 1	22.79	0.876 9	20.17	0.838 8	21.74	0.865 2
AOD-Net	21.82	0.880 5	24.80	0.915 7	22.28	0.867 5	19.52	0.836 8	22.11	0.875 1
本文	28.46	0.921 8	27.71	0.920 1	25.34	0.888 5	24.07	0.870 2	26.40	0.900 2

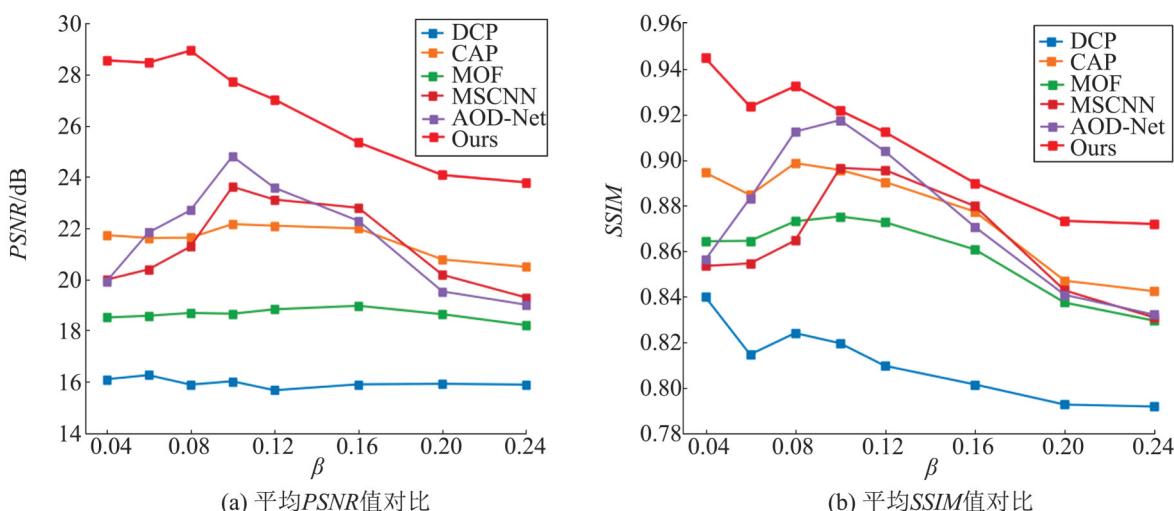


图5 扩充 $\beta$ 后各方法的测试结果  
Fig. 5 Test results of each method after extending  $\beta$

此外，在图6还展示了各模型的去雾图像以进行主观视觉质量评价。DCP恢复的图像在不同雾浓度下均出现了同样的颜色失真问题，如天空区域，该方法基于一定的先验知识，在光照、雾浓度较复杂的室外场景，很难准确估计大气光照。CAP恢复的无雾图像可以去除不同浓度的雾，但在颜色细节恢复上表现一般，第1张图天空呈淡蓝色；第2张图的树叶部分偏亮；在 $\beta = 0.2$ 的高浓度雾下，如第4张图，左下角的黄色花束部分有少许雾气残留，颜色呈淡黄色。MOF恢复的图像尽管去雾较彻底但饱和度太高，如第1~3张图出现严重的过曝现象；第4张图天空中云朵周围以及第5张图天空中出现明显的黑色伪影。MSCNN和AOD-Net在雾浓度较低，如 $\beta = 0.06$ 、0.1时去雾彻底，但在颜色纹理恢复方面往往表现不佳，第1张图红色框中的船顶颜色过深，且拱

桥的拱圈下方有少量伪影；第2张图墙壁上同样出现伪影，且砖块的纹理不够清晰，随着雾浓度上升，当 $\beta = 0.16$ 、0.2时，MSCNN和AOD-Net会出现不同程度的雾气残留现象；第3张图中景深处即道路远方红框位置有明显的雾气残留；第4张图中天空区域由于残留薄雾导致颜色偏白，另外MSCNN图左下方花束呈红色，在AOD-Net图中呈橘黄偏红，与原图的花束相比，花整体颜色偏深，且这2种方法在处理非均匀雾时表现不佳；第5张图右下角树的区域依然有大量雾气残留。本文提出的方法不仅在不同雾浓度下和非均匀雾下都表现出良好的适应能力，有明显的去雾效果，还在颜色、纹理细节的恢复上表现出了巨大的优势，恢复的无雾图像中物体的纹理轮廓清晰，且颜色更接近于原始清晰图像。

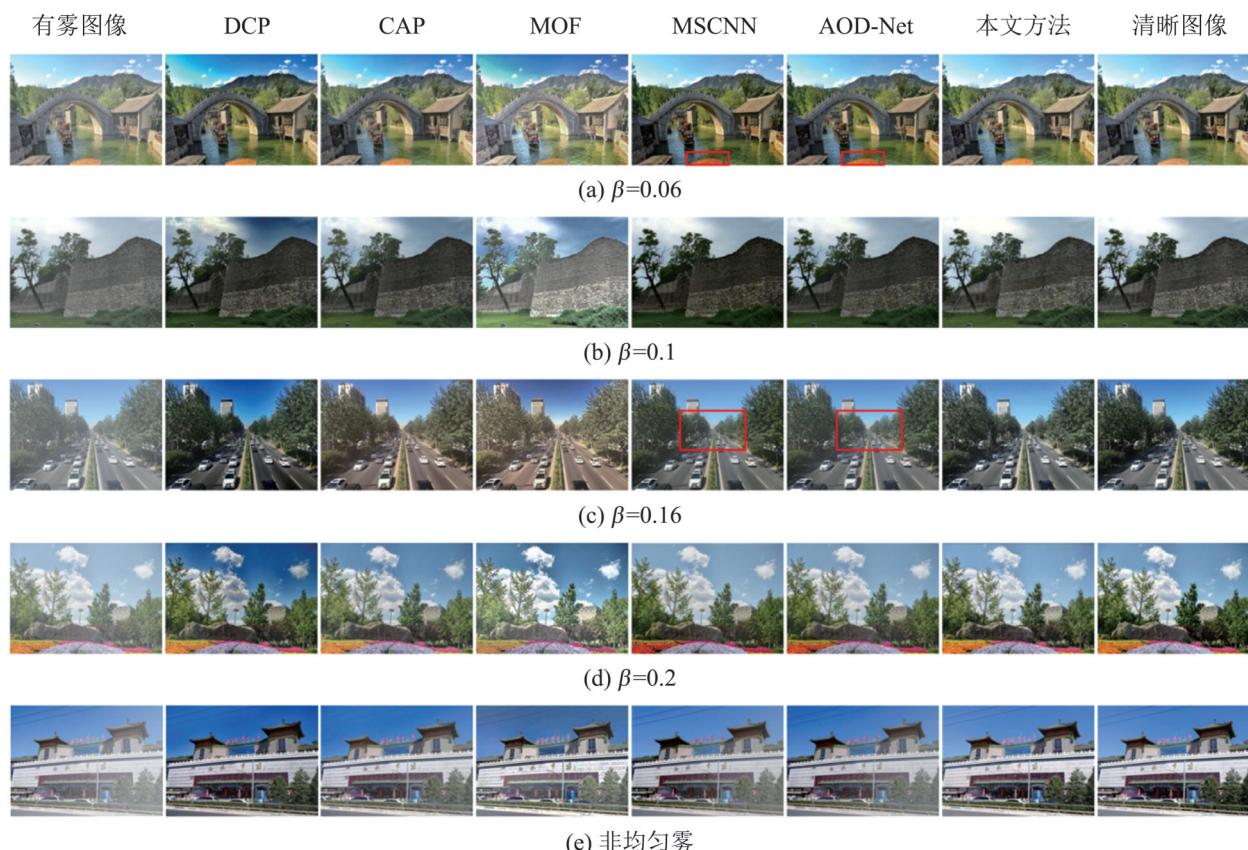


图6 合成室外有雾图像的去雾结果  
Fig. 6 Dehazing results of synthetic outdoor hazy images

## 2.4 在真实室外数据集上的结果

另外还选取了50张真实室外有雾图像，以进一步验证本文模型的普适性和真实去雾能力。首先通过 $L_{dc}$ 对各方法进行客观评价，结果如表2所示。本文方法获得的去雾图像的 $L_{dc}$ 仅次于DCP，明显低于其他几种方法。该指标用于衡量模型对雾气的去除能力，接下来还将对各去雾图像的色彩纹理进行主观评价。

表2 各方法在真实室外数据集上的结果  
Table 2 Results of each method on real outdoor dataset

方法	$L_{dc}$
DCP	0.136 4
CAP	0.172 5
MOF	0.162 3
MSCNN	0.189 3
AOD-Net	0.187 0
本文	0.149 4

各方法对真实有雾图像的去雾效果如图7所示。DCP在处理真实图像时依旧出现了颜色失真问题，如图7(b)的天空都呈深蓝色，第2张图云朵周围还出现了少许彩色斑块，尽管该方法取得了最低的 $L_{dc}$ ，但去雾前后图像颜色失真严重。CAP

的去雾能力较好，但颜色还原效果欠佳，如图7(c)第2张图天空为深蓝色，第3、4张图云朵上出现黑色伪影导致整体颜色偏黑，另外图7(c)第1张图右下角红框中背包部分细节恢复不够，有少许雾气残留。MOF获得的图像整体饱和度偏高，图7(d)第1、2张图天空呈深蓝色，第2、4张图草丛区域亮度太高，在第3张图云朵周围还出现了较多的伪影。MSCNN方法在室外环境下还原去雾图像时同样会产生较多伪影，如图7(e)第1张图红框中的背包，第3张图人物脚下的山坡，以及第4张图左侧的植被，另外，该方法的细节恢复能力欠佳，如第2张图中人物背影太模糊，存在细节纹理丢失的现象。AOD-Net方法容易产生亮度偏暗的图像，如图7(f)第2、4张图，该方法整体去雾效果较好，但在景深处表现不佳，如第1张图红框中山沟部分依然有少量雾气残留，此外，第3张图中人物脚下山坡处纹理不够清晰，且人物衣服的颜色偏深。如图7(g)所示，文中所提出的方法在处理具有挑战性的室外有雾图像时，效果依旧优于其他几种方法，在去除有雾图像景深部分和边缘部分雾气的同时，还能有效还原雾气下物体的颜色和细节纹理。

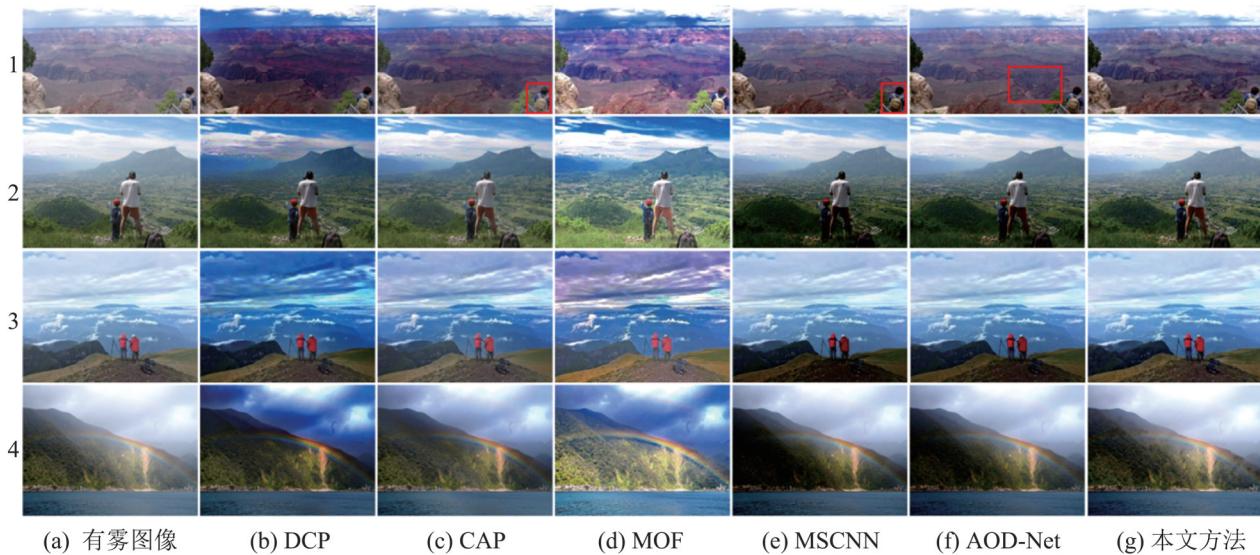


图7 真实室外有雾图像的去雾结果  
Fig. 7 Dehazing results of real outdoor hazy images

## 2.5 消融实验

本文设计了消融实验, 以验证各模块在整个去雾过程中的有效性。DRCA-CTR由带通道注意力的稠密残差块DRCA和颜色纹理修复模块(color texture repair module, CTR)组成; 模型RCA-CTR将残差块由稠密连接方式改为普通连接; DR-CTR去掉了DRCA中的通道注意力块; DRCA未添加颜色纹理修复模块。用测试集A对各模型进行测试, 结果如表3所示。本文所提出的DRCA-CTR相较于RCA-CTR和DR-CTR在PSNR和SSIM上均有明显的提升, 相较于去掉修复模块后的DRCA, 本文模型在PSNR上更是提高了1.5 dB。

表3 合成有雾图像上的消融实验结果  
Table 3 Ablation results on synthetic hazy images

方法	PSNR/dB	SSIM
DRCA-CTR	26.40	0.900 2
RCA-CTR	25.19	0.890 0
DR-CTR	25.54	0.893 2
DRCA	24.90	0.882 4

为说明颜色纹理修复模块在针对某些特殊图像, 如色调占比不均衡且色调间有强烈边界的情况下依然适用, 在图8中展示了DRCA和DRCA-CTR 2种方法的去雾结果图。天安门前的草丛主色调为绿色, 包含少量红花, 红绿色调占比不均衡且红花被绿草丛包围, 有较为强烈的边界。由局部放大区域可以看到, DRCA得到的去雾图像在靠近红花部分草丛明显变黄, 且红花色彩偏暗, 而添加修复模块后DRCA-CTR得到的图像中草丛依旧保持原图中的绿色, 且红花并没有因占比较少而受到抑制导致色彩变暗。同时观察放大部分的纹理可以清晰看到, 经修复模块处理的绿草红花在纹理上均得到明显改善, 像素点更加清晰, 占比较少的红花在像素修复过程中, 同样没有因绿色通道占比过重而导致像素权重出现偏差。为佐证上述结论, 计算了4组图像各通道的平均数值并将其约束在0~1之间得到各通道比重, 按BGR的顺序给出, 如表4

所示。添加修复模块在通道权重作用下得到的去雾图像在BGR比重上更接近原始图像。

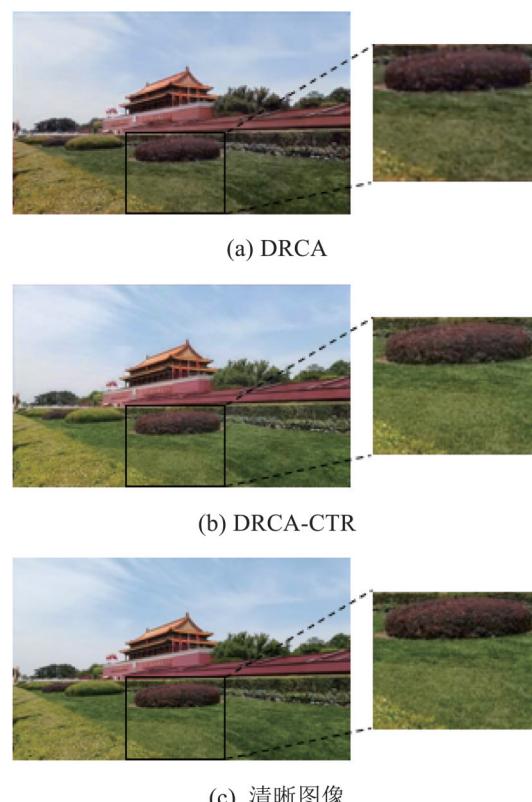


图8 模型去雾结果图

Fig. 8 Dehazing results of models

表4 图像各通道的比重

Table 4 Proportion of each channel for images

图像	BGR 比重
原始图像	(0.18, 0.36, 0.26)
有雾图像	(0.47, 0.58, 0.51)
DRCA	(0.19, 0.30, 0.21)
DRCA-CTR	(0.19, 0.38, 0.29)

图9展示了3组模型提取到的特征图, DRCA-CTR的特征图轮廓更加清晰且无明显伪影, 带通道注意力的稠密残差块显著加强了特征提取能力。

综上所述, 本文设计的带通道注意力机制的稠密残差块以及颜色纹理修复模块有效提升了模型的去雾能力, 且在色调占比不均衡时依然表现出很强的适应能力。

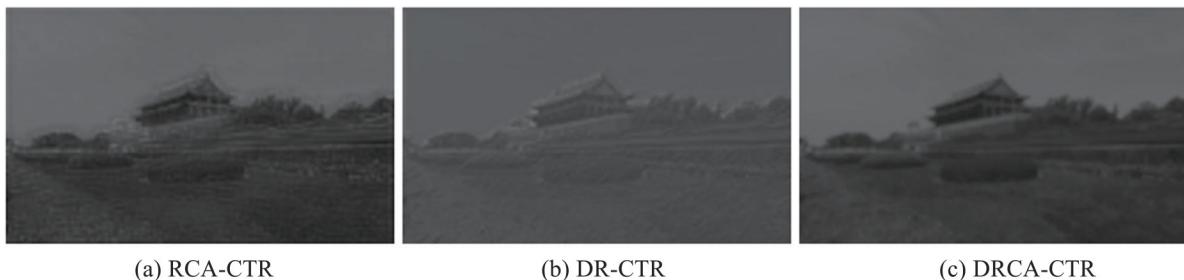


图9 特征提取模块提取的特征图  
Fig. 9 Feature map extracted by feature extraction module

### 3 结论

本文提出了一种基于稠密残差块与通道像素注意力的图像去雾网络，并验证了其在室外场景下的去雾能力，该网络利用稠密残差块提取有雾图像特征，依靠颜色纹理修复模块使去雾图像能够保持原有的色彩和细节纹理。在公开数据集上的结果表明，相较于其他几种网络，该网络在PSNR和SSIM值上都有显著提升，不仅可以解决去雾图像颜色失真、纹理不清晰的问题，还在去除室外高浓度雾气时表现出巨大优势，避免了雾气残留。为进一步提高颜色纹理修复模块的泛化能力，在接下来的研究中，还需结合图像处理领域最先进的注意力机制对其进行改进，将该方法应用于交通领域，提高雾天环境下的交通监控质量。

### 参考文献：

- [1] 蒲亨飞, 黄治勇. 图像去雾算法研究综述[J]. 软件工程, 2021, 24(5): 2-6.  
Pu Hengfei, Huang Zhiyong. An Overview of Research on Image Dehazing Algorithms[J]. Software Engineering, 2021, 24(5): 2-6.
- [2] Narasimhan S G, Nayar S K. Vision and the Atmosphere[J]. International Journal of Computer Vision(S0920-5691), 2002, 48(3): 233-254.
- [3] He K, Sun J, Tang X. Single Image Haze Removal Using Dark Channel Prior[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence (S1939-3539), 2011, 33(12): 2341-2353.
- [4] Zhu Q, Mai J, Shao L. A Fast Single Image Haze Removal Algorithm Using Color Attenuation Prior[J]. IEEE Transactions on Image Processing (S1941-0042), 2015, 24(11): 3522-3533.
- [5] Zhao Dong, Xu Long, Yan Yihua, et al. Multi-Scale Optimal Fusion Model for Single Image Dehazing[J]. Signal Processing: Image Communication (S0923-5965), 2019, 74: 253-265.
- [6] 金伟东, 胡燕花, 唐鹏, 等. 基于结构化森林的前向车载视频图像的细节强化[J]. 系统仿真学报, 2018, 30(12): 4602-4610.  
Jin Weidong, Hu Yanhua, Tang Peng, et al. Detailed Enhancement of Forward Vehicle Video Images Based on Structured Forest[J]. Journal of System Simulation, 2018, 30(12): 4602-4610.
- [7] 胡燕花. 接触网巡检图像的细节强化与场景重构[D]. 成都: 西南交通大学, 2018.  
Hu Yanhua. Detailed Enhancement and Scene Reconstruction of Catenary Inspection Images [D]. Chengdu: Southwest Jiaotong University, 2018.
- [8] Cai B L, Xu X M, Jia K, et al. DehazeNet: An End-to-End System for Single Image Haze Removal[J]. IEEE Transactions on Image Processing (S1941-0042), 2016, 25(11): 5187-5198.
- [9] Ren W Q, Liu S, Zhang H, et al. Single Image Dehazing Via Multi-Scale Convolutional Neural Networks[C]// European Conference on Computer Vision. Springer International Publishing AG, 2016: 154-169.
- [10] Li B Y, Peng X L, Wang Z Y, et al. AOD-Net: All-in-One Dehazing Network[C]// IEEE International Conference on Computer Vision. Venice, Italy: IEEE, 2017: 4780-4788.
- [11] Qin X, Wang Z L, Bai Y C, et al. FFA-Net: Feature Fusion Attention Network for Single Image Dehazing[C]// Association for the Advance of Artificial Intelligence. 2020: 11908-11915.
- [12] He K, Zhang X, Ren S, et al. Deep Residual Learning for Image Recognition[C]// IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, NV: IEEE, 2016: 770-778.
- [13] Huang G, Liu Z, Van Der Maaten L, et al. Densely Connected Convolutional Networks[C]// IEEE Conference

- on Computer Vision and Pattern Recognition. Honolulu, HI: IEEE, 2017: 2261-2269.
- [14] Hu J, Shen L, Albanie S, et al. Squeeze-and-Excitation Networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence (S1939-3539), 2020, 42(8): 2011-2023.
- [15] Ioffe S, Szegedy C. Batch Normalization: Accelerating Deep Net-Work Training by Reducing Internal Covariate Shift[C]// IEEE International Conference Machine Learning. 2015: 1-11.
- [16] Roodchild M, Gotaysardias J, Will A. A New Approach for the Vanishing Gradient Problem on Sigmoid Activation [J]. Progress in Artificial Intelligence(S2192-6352), 2020, 9(4): 351-360.
- [17] Odena A, Dumoulin V. Deconvolution and Checkerboard Artifacts[J]. Distill(S2476-0757), 2016, 1(10): e3.
- [18] 杨丽娟, 李利. 基于双线性插值的内容感知图像缩放算法仿真[J]. 计算机仿真, 2019, 36(12): 244-248.  
Yang Lijuan, Li li. Simulation of Content-Aware Image Scaling Algorithms Based on Bilinear Interpolation[J]. Computer Simulation, 2019, 36(12): 244-248.
- [19] Chen W, Ding J, Kuo S. PMS-Net: Robust Haze Removal Based on Patch Map for Single Images[C]//IEEE Conference on Computer Vision and Pattern Recognition. Long Beach, CA: IEEE, 2019: 11673-11681.
- [20] Woo S, Park J, Lee J Y. CBAM: Convolutional Block Attention Module[C]//European Conference on Computer Vision. 2018: 3-19.
- [21] Zhou W, Bovik A C. Mean Squared Error: Love It or Leave It? A New Look at Signal Fidelity Measures[J]. IEEE Signal Processing Magazine(S1053-5888), 2009, 26(1): 98-117.
- [22] Li B Y, Ren W Q, Fu D P, et al. Benchmarking Single Image Dehazing and Beyond[J]. IEEE Transactions on Image Processing(S1941-0042), 2019, 28(1): 492-505.
- [23] Li L, Dong Y, Ren W, et al. Semi-Supervised Image Dehazing[J]. IEEE Transactions on Image Processing (S1941-0042), 2020, 29: 2766-2779.