

# 基于频率与注意力机制的图像去雾算法<sup>①</sup>

王军<sup>1,2</sup>, 孟儒君<sup>1</sup>, 程勇<sup>1,2</sup>

<sup>1</sup>(南京信息工程大学 软件学院, 南京 210044)

<sup>2</sup>(南京信息工程大学 科技产业处, 南京 210044)

通信作者: 孟儒君, E-mail: [202212490388@nuist.edu.cn](mailto:202212490388@nuist.edu.cn)



**摘要:** 由于大气雾和气溶胶的存在, 图像能见度显著下降且色彩失真, 给高级图像识别带来极大困难。现有的图像去雾算法常存在过度增强、细节丢失和去雾不充分等问题。针对过度增强和去雾不充分的问题, 本文提出了一种基于频率和注意力机制的图像去雾算法 (frequency and attention mechanism of the image dehazing network, FANet)。该算法采用编码器-解码器结构, 通过构建双分支频率提取模块获取全局和局部的高低频信息。构建频率融合模块调整高低频信息的权重占比, 并在下采样过程中引入附加通道-像素模块和通道-像素注意力模块, 以优化去雾效果。实验结果显示, FANet 在 SOTS-indoor 数据集上的 PSNR 和 SSIM 分别为 40.07 dB 和 0.995 8, 在 SOTS-outdoor 数据集上分别为 39.77 dB 和 0.995 8, 同时, 该算法也在 HSTS 和 Haze4k 测试集上取得了不错的成绩, 与其他去雾算法相比有效缓解了颜色失真和去雾不彻底等问题。

**关键词:** 图像去雾; 双分支频率提取模块; 注意力机制; 特征融合; 编码器-解码器结构

引用格式: 王军, 孟儒君, 程勇. 基于频率与注意力机制的图像去雾算法. 计算机系统应用, 2025, 34(1):161–170. <http://www.c-s-a.org.cn/1003-3254/9736.html>

## Image Dehazing Algorithm Based on Frequency and Attention Mechanism

WANG Jun<sup>1,2</sup>, MENG Ru-Jun<sup>1</sup>, CHENG Yong<sup>1,2</sup>

<sup>1</sup>(School of Software, Nanjing University of Information Science & Technology, Nanjing 210044, China)

<sup>2</sup>(Science and Technology Industries Division, Nanjing University of Information Science & Technology, Nanjing 210044, China)

**Abstract:** Atmospheric fog and aerosols can significantly reduce visibility and distort colors in images, bringing great difficulties to advanced image recognition. Existing image dehazing algorithms often face problems such as excessive enhancement, loss of details, and insufficient dehazing. To avoid excessive enhancement and insufficient dehazing, this study proposes an image dehazing algorithm based on frequency and attention mechanisms. The algorithm adopts an encoder-decoder structure and constructs a dual-branch frequency extraction module to obtain both global and local high and low-frequency information. A frequency fusion module is then constructed to adjust the weight proportions of the high and low-frequency information. To optimize the dehazing effect, the algorithm introduces an additional channel-pixel module and a channel-pixel attention module during down sampling. Experimental results show that FANet achieves a PSNR of 40.07 dB and an SSIM of 0.995 8 on the SOTS-indoor dataset, and a PSNR of 39.77 dB and an SSIM of 0.995 8 on the SOTS-outdoor dataset. The proposed algorithm also achieves good results on the HSTS and Haze4k test sets. It effectively alleviates color distortion and incomplete dehazing compared with other dehazing algorithms.

**Key words:** image dehazing; dual branch frequency extraction module; attention mechanism; feature fusion; encoder-decoder structure

① 基金项目: 国家自然科学基金 (41975183)

收稿时间: 2024-06-19; 修改时间: 2024-07-10; 采用时间: 2024-07-18; csa 在线出版时间: 2024-11-28

CNKI 网络首发时间: 2024-11-29

## 1 引言

图像去雾是计算机视觉和图像处理领域的一项重要技术,具有广泛的应用前景和深远的社会意义。在环境监测和气象预报中,清晰的图像数据是准确分析和预测的基础,去雾技术可以提高图像数据的可靠性。在公共安全领域,如监控系统和自动驾驶技术<sup>[1]</sup>中,去雾技术可以提升系统的稳定性和可靠性,保障公众安全。此外,在影视制作和摄影艺术领域,去雾技术也可以用于改善图像质量,创造更高水准的视觉作品。总之,图像去雾技术不仅在科学的研究中具有重要的理论价值,还在实际应用中展现出巨大的潜力,为多个领域的发展提供了有力支持。

目前,现有的图像去雾算法主要分为3类方法:图像增强法、物理模型法和深度学习法。这3类方法有着不同的优缺点。

### 1.1 基于图像增强的去雾算法

基于图像增强的算法主要有提升图像的亮度和对比度两个方面,亮度确定图片的明暗程度,对比度增强图像细节。其中具有代表性的算法包括直方图均衡化、同态滤波、小波变换、Retinex 理论等。Retinex 理论<sup>[2]</sup>的数学原理包括对数变换、高斯滤波、反射成分的计算、平滑处理和对数逆运算等几个部分,主要用来解决图像中光照不均和色彩偏移等问题,早在 2008 年, Rajput 等人<sup>[3]</sup>将其应用在雾天飞机跑道检测的图像处理中,而后随着 Retinex 算法的发展,图像去雾从一开始全局化去雾发展成多子块局部去雾<sup>[4]</sup>,但 Retinex 算法容易产生颜色失真和算法复杂度过高问题;同样由全局发展到局部去雾的增强型算法还有直方图均衡化,Stark 等人<sup>[5]</sup>提出的传统的直方图均衡化算法首先统计图片中各个灰度级出现的频率并计算分布函数,将灰度值集中的部分进行对比度增强,稀疏部分对比度减弱,将图片的灰度值重新射,以达到图像整体去雾的效果。此外,具有代表性的算法还有同态滤波算法和小波变换算法等。小波变换算法通过结合空域与时域信息进行特征分析,同态滤波只考虑时域信息,现有研究中会将这两个算法作为辅助算法与其他去雾算法结合以达到去雾效果。

### 1.2 基于物理模型的去雾算法

由 McCartney<sup>[6]</sup>提出, Nayar 等人<sup>[7]</sup>完善总结的大气散射模型是基于物理模型去雾算法的开始,模型表达式为:

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

其中,  $I(x)$  代表有雾图像,  $J(x)$  代表无雾图像,  $A$  代表大气光值,  $t(x)$  代表透射率。该方法通过估算大气光值  $A$  和透射率  $t(x)$ , 反推出无雾图像  $J(x)$ , 这种方法的效果取决于估值的准确性。在这个模型基础上, 国内外学者提出了很多算法, 其中最经典的是由 He 等人<sup>[8]</sup>提出的暗通道先验 (dark channel prior, DCP) 去雾算法。该理论通过大量无雾图像分析出在图片的 RGB 三色通道中, 每个像素点总存在一个颜色通道的值趋近于 0, 首先将每个像素点中最接近 0 的像素值记录下来得到灰度图 1, 再在此基础上以每个像素点为中心划分出同样大小的区域, 取此区域中最小像素值得到灰度图 2, 研究者们通过该理论预测透射率, 再通过大气散射模型恢复干净图像, 获得了当时比较好的效果, 但是, 该算法在面对天空区域较多的图片和图片里存在白色物体的时候去雾效果偏差较大。针对这两点不足, 后续产生了一些基于 DCP 算法的优化算法, 如杨燕等人<sup>[9]</sup>提出新的估计大气散射模型参数的方法以应对天空去雾缺陷问题; Zhu 等人<sup>[10]</sup>提出将亮度与暗通道相结合, 将图片分割出天空区域, 但此算法的缺点在于无法精准分割出天空区域, 并对天空区域的透射率参数估计不准; Yang 等人<sup>[11]</sup>利用深度图和密度图来预估透射率, 此方法不需要配对的噪声图像与干净图像, 取得较好的效果, 并且参数较少; 除此之外, 还有颜色衰减先验算法<sup>[12]</sup>和基于马尔可夫随机场 (MRF) 模型求透射率的去雾算法<sup>[13]</sup>等。

### 1.3 基于深度学习的去雾算法

在深度学习发展初期, 图像去雾算法大多仍依赖物理模型和先验知识。随着深度学习的发展, 学者们逐渐从结合物理模型与卷积神经网络的去雾方法, 转向直接学习成对图像关系的去雾模型, 在这一过程中取得了诸多研究成果。

Cai 等人<sup>[14]</sup>提出的 DehazeNet 算法, 采用的是基于卷积神经网络 (CNN) 的深度架构, 利用 Maxout 单元层进行特征提取, 以有雾图像为输入, 输出介质传输图, 最后通过大气散射模型恢复无雾图像, 但计算时假设大气光值  $A$  为常量, 这与实际大气值有一定差异, 相应的结果也会出现偏差。为了解决这种差异问题, Li 等人<sup>[15]</sup>将大气散射模型中的截止透射率  $t(x)$  与大气光值  $A$  进行变形, 用一个  $K(x)$  变量统一, 此时只需要求解出  $K(x)$

的值就可以实现去雾, 这使得误差进一步减小. 具体统一方式如下:

$$J(x) = K(x)I(x) - K(x) + b \quad (2)$$

其中,  $K(x)$ 的具体公式如下:

$$K(x) = \frac{1}{t(x)}(I(x) - A) + (A - b) \quad (3)$$

其中,  $b$ 为常量,  $K(x)$ 由 AOD-Net 神经网络估算, 此方法计算复杂度低, 同时去雾效果也得到了明显提升.

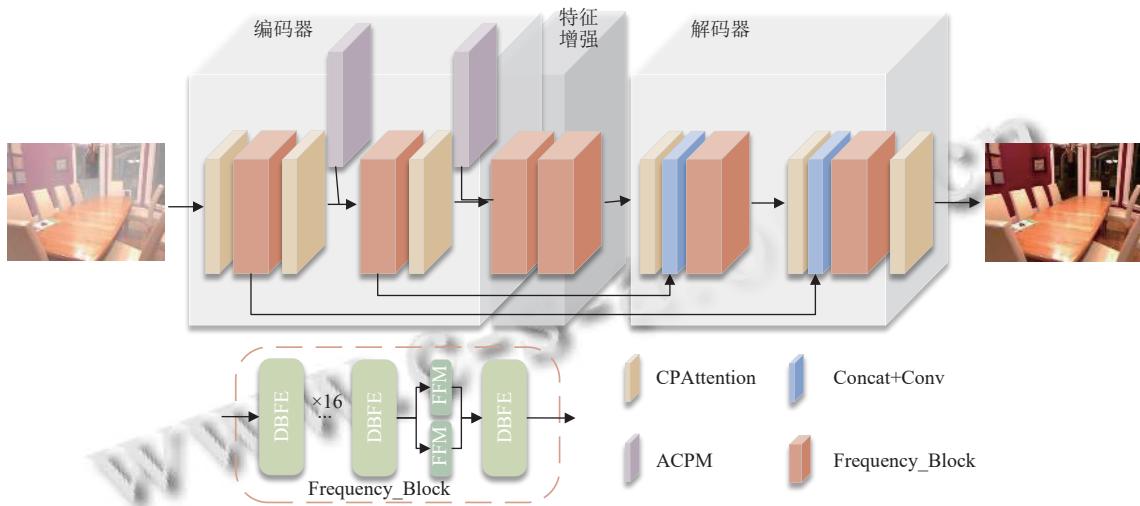


图1 FANet 算法总体框架图

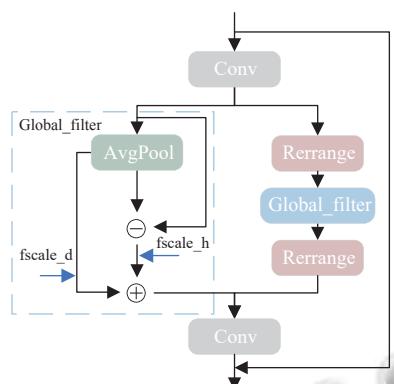


图2 DBFE 结构图

此外, 在 DehazeNet 算法基础上出现了一系列改进算法<sup>[16-19]</sup>. 其次, Zhang 等人<sup>[20]</sup>将语义分割领域知识引入去雾模型提出 DCPDN 算法再一次推动了去雾研究的发展. 2014 年, 随着生成对抗网络 GAN<sup>[21]</sup>的提出, Chen 等人<sup>[22]</sup>提出了 GCANet 算法, 该算法是基于 GAN 的端到端去雾模型, 提出平滑扩展卷积来解决网格伪影的问题. 2018 年, Engin 等人<sup>[23]</sup>在 CycleGAN 模型的基础上, 将循环一致性和感知损失与之结合, 提出 Cycle-Dehaze 网络, 该网络在恢复图像细节方面具有很好的效果. 此外, 还有一些效果较好的去雾网络, 如 Zhang 等人<sup>[24]</sup>提出的模型 FAMED-Net、Li 等人<sup>[25]</sup>提出的单图

像水平感知渐进网络 LAP-Net、FFA-Net<sup>[26]</sup>网络采用特殊的特征注意力机制, 从受雾霾影响的图像中恢复出具有清晰细节和真实色彩的无雾图像, 在评价标准上取得了较高的数值. 另外, Wu 等人<sup>[27]</sup>基于对比学习的新型对比正则化 (CR), 分别利用模糊图像和清晰图像的信息作为负样本和正样本, 提出了基于自动编码器 (AE) 框架的紧凑去雾网络 (AEGR-Net), 其中包括自适应混合操作和动态特征增强模块. Ji 等人<sup>[28]</sup>则表示将 Transformer 与编码器-解码器结构融合, 会导致自注意力计算负荷过重以及不同深度之间的特征通信效率低下, 在此基础上, 提出一种基于 Transformer 的深度有效图像恢复网络, 称为 U2-Former, 它使用 Transformer 作为核心操作在深度编码和解码空间中执行图像恢复. Song 等人<sup>[29]</sup>通过改进 Swin Transformer 中的激活函数和规范化层等, 提出了 DehazeFormer, 该算法是将 Transformer 应用在图像去雾领域的一个重大突破. 之后, 他们将 U-Net 中的卷积块替换为具有门控机制的残差块, 以获得一个紧凑的去雾网络 gUNet. Zheng 等人<sup>[30]</sup>根据大气散射模型构建了一个物理感知的双分支单元, 提出了一种新颖的课程对比正则化, 针对一致的对比空间而不是非一致的对比空间, 构建出 C2PNet 去雾网络. Lu 等人<sup>[31]</sup>提出用于图像去雾的混合结构块

网络 MixDehazeNet, 他提出引入大卷积核容易忽略图像的多尺度特性; 标准的串联注意力模块没有充分考虑不均匀雾分布。针对这两个问题提出多尺度并行大卷积核模块和增强并行注意力模块。Cui 等人的团队先后提出 SFNet<sup>[32]</sup>、FSNet<sup>[33]</sup>、OKNet<sup>[34]</sup>、DSANet<sup>[35]</sup>、SANet<sup>[36]</sup>等网络主要应用于图像恢复, 其主要特点都是采用编码器解码器结构, 通过多分支动态选择频率模块, 从理论上证明频率信息对图像恢复任务的重要性。选用不同大小的深度卷积核进行调制, 使得这些算法在图像去雾领域取得很好的效果。

综上所述, 虽然国内外研究人员在图像去雾方面取得了一定的研究成果, 但是由于没有考虑导致图像退化的真实原因、去雾不彻底以及图像过增强等问题, 导致得到的去雾图像总是效果不理想, 本文针对图像过增强等问题设计出基于全局自适应平均池化操作来重点关注图片高低频信息。在此基础上引入通道注意力和像素注意力, 从而对全局与局部特征进行有效平衡以减少过增强的问题, 提升了网络的性能, 使得恢复的无雾图像色彩更均衡, 最大尺度地保留了图像信息。

## 2 FANet 算法设计

本文提出了一个基于频率与注意力的端到端单图像去雾网络模型 (frequency and attention mechanism of the image dehazing network, FANet), 其主要网络结构如图 1 所示。网络主要分为编码器、特征增强和解码器 3 个阶段: 在第 1 阶段, 有雾图像作为输入, 分别经过通道-像素注意力 (channel-pixel attention, CPAAttention) 模块和频率模块 (frequency block), 频率模块由双分支频率提取 (dual branch frequency extraction, DBFE) 模块和频率融合 (frequency extraction module, FFM) 模块组成, 其网络结构详见图 1 左下角, 通过这两个模块使得本文算法更加精确地选择需要关注的通道和像素信息作为频率提取特征的输入, 再经过频率提取和融合模块最终输出低层细节特征。第 2 阶段通过两个频率模块更加精准的提取图像信息, 并反向传播权重信息, 使特征信息得到增强。在第 3 阶段, 将增强后的特征图输入解码器阶段, 并通过反卷积进行上采样操作, 再次利用通道-像素注意力 (CPAttention) 模块和频率模块, 将特征图进行融合学习, 输出最终的无雾图像。需要注意的是, 在编码器阶段为了防止丢失上下文信息, 额外引入了通道-像素模块 (additional channel-pixel

module, ACPM), 增加了更多的细节信息。

### 2.1 双分支频率提取模块 (DBFE)

DBFE 模块的网络结构如图 2 所示, 它由 2 个卷积层和 2 个分支组成。双分支频率提取模块包括了基于全局特征分支和基于局部特征分支。通过这 2 个分支, 可以更全面地捕获图像的频率特征, 从而提高模型在图像去雾任务中的性能。相比于单一分支或其他提取模块, 它能够更好地平衡全局结构信息和局部细节信息, 使模型更加全面地理解和利用输入数据的特征。

具体来说, 输入特征图首先通过一个  $3 \times 3$  卷积层和 ReLU 激活函数进行特征提取, 并扩展到指定的通道数。然后, 将上述得到的特征图分成两个通道数相等的特征图, 分别作为 2 个分支的输入。

将其中一个特征图作为输入, 传递到基于全局的分支。首先, 通过自适应平均池化得到全局的低频图。然后, 将输入特征图与低频图相减, 得到高频图。接下来, 对低频图和高频图分别应用可学习参数。在训练过程中, 通过反向传播调整全局低频图与高频图之间的映射关系, 从而有效地学习它们之间的特征。过程如式(4) 和式(5) 所示:

$$x_d = \text{AvgPool}(x) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W X_c(i, j) \quad (4)$$

$$Y_1 = (x - x_d) \times \alpha_1 + x_d \times \beta_1 \quad (5)$$

其中,  $x$  表示输入特征,  $X_c(i, j)$  表示第  $C$  个通道  $X_c$  所在位置  $(i, j)$  处的值,  $\text{AvgPool}(\cdot)$  表示自适应平均池化操作,  $\alpha_1$ 、 $\beta_1$  分别为可学习参数,  $Y_1$  表示输出特征。

将另一个特征图输入至基于局部的分支。在这个分支中, 首先将输入的大小为  $C/2 \times H \times W$  的图像重新划分为 4 个大小为  $2 \times C \times H \times W$  的局部特征图。为了获取每个特征图的低频部分, 对每个局部特征图使用自适应平均池化, 得到局部低频图。然后, 将局部特征图与局部低频图相减, 得到局部高频图。为了提取有用的频率部分, 使用两个可学习的权重参数重新调整局部低频图与局部高频图之间的映射关系。这些权重参数在训练过程中通过反向传播进行优化。最后, 将更新后的局部频率图恢复到原始输入大小。过程如式(6)–式(8) 所示:

$$\text{low} = \text{AvgPool}(\text{rearrange}(x)) \quad (6)$$

$$Y_2 = (\text{rearrange}(x) - \text{low}) \times \alpha_2 + \text{low} \times \beta_2 \quad (7)$$

$$Y_2 = \text{rerrange}(Y_2) \quad (8)$$

其中,  $x$ 表示输入特征,  $\text{rerrange}(\cdot)$ 表示划分特征图操作,  $\text{AvgPool}(\cdot)$ 表示自适应平均池化操作,  $\alpha_2$ 、 $\beta_2$ 分别为可学习参数,  $Y_2$ 表示输出特征.

接着, 将两分支得到的  $Y_1$  和  $Y_2$  特征图进行拼接, 再通过一个  $3 \times 3$  普通卷积调整特征图大小, 并与输入特征图进行残差连接, 随后将结果输入到下一个双分支频率提取模块. 过程如式(9)所示:

$$Y = x + \text{conv}(\text{cat}(Y_1, Y_2)) \quad (9)$$

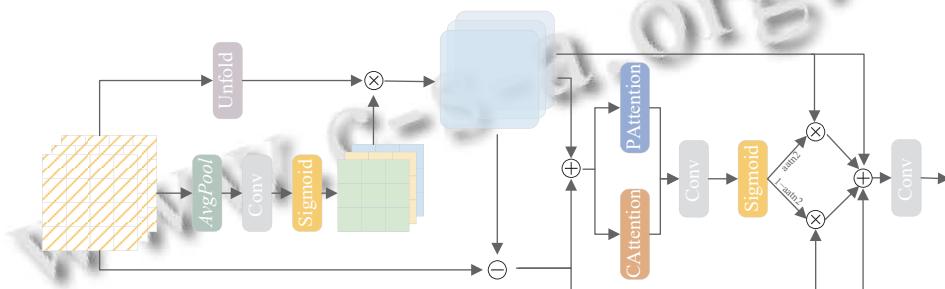


图3 FFM结构图

具体来说, 第1阶段首先对输入特征图进行自适应平均池化, 然后通过  $1 \times 1$  卷积处理池化后的特征图, 得到初步的低频特征. 接着, 将初步低频特征调整形状并增加一个维度. 随后, 对调整后的低频特征应用 Sigmoid 激活函数, 并与填充后并展开的输入特征进行点乘, 得到低频部分特征图和高频特征图.

在第2阶段, 首先将低频特征与高频特征进行逐元素相加融合, 然后分别经过通道注意力和像素注意力后再次使用逐元素相加融合特征. 随后, 通过 Sigmoid 激活函数将注意力值限制在 0~1 之间. 最后, 利用权重注意力机制融合低频特征和高频特征, 通过  $1 \times 1$  卷积进一步处理融合后的结果, 然后将其作为输出特征.

### 2.3 附加通道-像素模块 (ACPM)

在深度学习中, 注意力机制已经被广泛地应用于各种图像处理任务中, 其中一些常见的注意力模块包括自注意力机制 (self-attention mechanism)、通道注意力机制 (channel attention mechanism)、空间注意力机制 (spatial attention mechanism)、多头注意力机制 (multi-head attention mechanism) 等, 在本文中将通道注意力和像素注意力组合成两个不同的基于注意力机制的特征提取模块. 其中, 通道注意力通过对特征和像素

其中,  $Y$  表示模块的输出,  $\text{conv}$  表示  $3 \times 3$  卷积,  $\text{cat}(\cdot)$  表示拼接操作.

### 2.2 频率融合模块 (FFM)

FFM模块的网络结构如图3所示, 可以分解为两个阶段. 在第1个阶段, 输入特征经过自适应平均池化、卷积和激活函数处理, 以提取低频特征. 然后, 将输入特征图与低频特征相减, 得到高频特征. 在第2个阶段, 将第1阶段得到的低频特征和高频特征作为输入, 经过注意力机制和卷积操作, 有效结合不同尺度的信息, 提高特征表示的丰富性和精确性.

区域生成不同的权重来获取通道之间的注意力, 像素注意力可以关注到图像中的细节特征信息. 这两个模块能够充分利用通道和空间信息, 提升特征表征能力, 并且可以减少模型的参数量和计算成本.

在编码器阶段, 输出的特征图不可避免的丢失了许多细节信息与上下文信息, 为了使模型更多地关注到丢失的信息, 提高模型预测的准确性, 提出了附加的通道-像素模块 (additional channel-pixel module, ACPM).

该模块将输入的有雾图像进行卷积与激活函数操作后, 再分别输入至通道注意力和像素注意力中提取特征, 得到特征图后, 将两个特征图分别与输入特征图进行拼接与卷积. 最后, 再次执行拼接卷积操作. 其过程如图4.

### 2.4 通道-像素注意力模块 (CPAttention)

在整个编码过程中, 本文算法采用 CPAttention 模块替代原本的下采样操作, 从而在下采样过程中更完整地保留图像特征信息, 使其拥有更丰富的细节. CPAttention 模块的网络结构如图5所示.

与 ACPM 模块不同, ACPM 模块是将有雾图像经过卷积后, 使用并行同步的方式提取特征, 再进一步融合两个特征图. CPAttention 模块是由通道注意力和像

素注意力串型组合而成,即将输入的特征图首先经过通道注意力得到特征图 $CA$ ,随后将 $CA$ 输入至像素注意力中得到 $PA$ ,最终将 $CA$ 与 $PA$ 逐元素相乘得到输出特征图。具体来说,设输入CPAttention的特征图为 $F_c$ ,大小为 $C \times H \times W$ ,首先,将特征图 $F_c$ 输入通道注意力模块,通过平均池化得到大小为 $C \times 1 \times 1$ 的特征,再经过两个卷积层及ReLU、Sigmoid函数得到通道注意力权重大小为 $C \times 1 \times 1$ 。最后,将权重与输入特征各通道中各像素相乘,得到通道注意力输出大小为 $C \times H \times W$ 。计算过程如式(10)~式(12)所示:

$$X_1 = \text{AvgPool}(F_c) \quad (10)$$

$$CA_c = \sigma(\text{conv}(\delta(\text{conv}(X_1)))) \quad (11)$$

$$CA = CA_c \otimes F_c \quad (12)$$

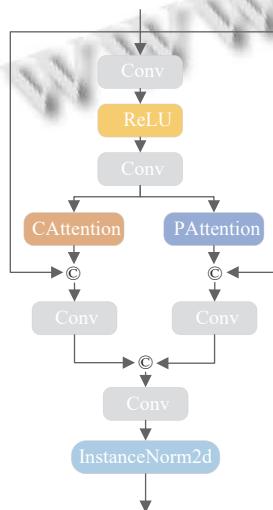


图4 ACPM结构图

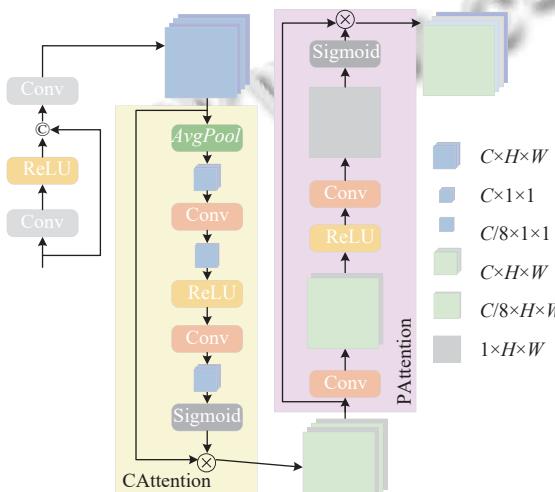


图5 CPAttention结构图

其中,  $\text{AvgPool}(\cdot)$ 表示全局池化函数,  $\delta$ 是ReLU激活函数,  $\sigma$ 是Sigmoid激活函数,  $\otimes$ 表示逐元素相乘。

与通道注意力相似,将 $CA$ (CAttention的输出)输入到具有ReLU和Sigmoid激活函数的两个卷积层中,使得到的像素注意力 $PA$ 权重大小为 $1 \times H \times W$ 。最后对输入 $CA$ 与 $PA$ 采用逐元素相乘法,得到输出 $Out$ 。

$$PA = \sigma(\text{conv}(\delta(\text{conv}(CA)))) \quad (13)$$

$$Out = CA \otimes PA \quad (14)$$

## 2.5 损失函数

为了促进反向传播,利用损失函数的梯度信息更新模型参数,使得模型预测值更加准确。在本文中,使用L1损失函数作为空间和频域的损失函数。

总损失函数表示如下,其中 $\lambda$ 设置为0.1:

$$L = L_{\text{spatial}} + \lambda L_{\text{frequency}} \quad (15)$$

空间的L1损失函数可以表示如下:

$$L_{\text{spatial}} = \sum_{r=1}^3 \frac{1}{N} \|I_{fa} - I_{gt}\|_1 \quad (16)$$

频域的L1损失函数可以表示如下:

$$L_{\text{frequency}} = \sum_{r=1}^3 \frac{1}{N} \|\mathcal{F}(I_{fa}) - \mathcal{F}(I_{gt})\|_1 \quad (17)$$

其中,  $N$ 为单通道上像素总量,  $I_{fa}$ 是经过FANet输出的无雾图像,  $I_{gt}$ 是真实地面情况,  $\mathcal{F}(\cdot)$ 是快速傅里叶变换。

## 3 实验结果与分析

### 3.1 实验数据集

本文在综合基准去雾数据集RESIDE上进行去雾实验,针对RESIDE数据集中室内和室外的场景分别进行模型训练,得到了针对室内与室外的两个不同权重文件,然后在对应的SOTS-indoor、SOTS-outdoor、HSTS和Haze4k测试集上进行评估。

RESIDE室内数据集(reside-indoor)包含1399张干净图片以及对应生成的13990张有雾图像。RESIDE室外数据集(reside-outdoor)包含由8970张干净图片生成的313950张有雾图像。SOTS-Indoor和SOTS-Outdoor均包含500张有雾图像。为了证明本文算法在实际有雾情况下的去雾效果,本文还在HSTS数据集上进行测试,HSTS数据集包含10张有雾图像。Haze4k

数据集包含 500 张室内有雾图像和 500 张室外有雾图像。为更高效地进行批量计算,本文使图像输入训练和测试模型时统一裁剪成  $256 \times 256$  大小的图像,在可视化图片对比阶段使用原数据集图像大小进行图像去雾效果展示。

### 3.2 实验环境和评价指标

本文使用 Python 3.8.10 和 Torch 1.11.0+Cu113 搭建模型,在 RTX 4090 (24 GB) 上展开实验。操作系统为 Ubuntu 20.04, 该算法采用 Adam 优化器并设置  $\beta_1$  和  $\beta_2$  分别为 0.9 和 0.999, 批量大小设置为 4, 在室内 reside-indoor 数据集上迭代时, 前 3 轮训练中学习率采用线性预热策略从 0.000003 线性增加至  $1E-4$ , 在第 4 轮训练时学习率采用余弦退火策略使得学习率从  $1E-4$  降至  $1E-8$ , 共迭代 300 次。在室外 reside-outdoor 数据集上训练模型时, 学习率在前 3 轮学习时均为 0.0001, 从第 4 轮训练时使用余弦退火策略, 共迭代 30 次。

评价指标采用峰值信噪比 (PSNR) 和结构相似性指标 (SSIM) 评估去雾效果。PSNR 和 SSIM 指标的值越大意味着去雾效果越好。

### 3.3 实验结果及对比分析

为验证 FANet 算法的去雾效果, 本文选取 DCP<sup>[8]</sup>、AOD-Net<sup>[15]</sup>、GridDehazeNet<sup>[37]</sup>、FFA-Net<sup>[26]</sup>、MSBDN<sup>[38]</sup>、DehazeFormer-t<sup>[29]</sup>、SFNet<sup>[32]</sup>、OKNet<sup>[34]</sup>等经典算法, 从定性和定量两个方面进行对比实验, 结果如表 1 所

示。可以看出, 本文所提出的算法在峰值信噪比 (PSNR) 和结构相似度 (SSIM) 指标上获得最高分。

表 1 不同方法在 SOTS 测试集上的定量评价结果

方法	reside-indoor		reside-outdoor	
	PSNR (dB)	SSIM	PSNR (dB)	SSIM
DCP	16.62	0.8179	19.13	0.8148
AOD-Net	19.06	0.8504	20.29	0.8765
FFA-Net	36.39	0.9886	33.57	0.9840
GridDehazeNet	32.16	0.9843	30.86	0.9823
MSBDN	32.77	0.9813	34.81	0.9858
DehazeFormer-t	35.20	0.9890	36.30	0.9910
SFNet	39.25	0.9951	37.37	0.9940
OKNet	39.08	0.9952	36.87	0.9944
FANet (本文方法)	<b>40.07</b>	<b>0.9958</b>	<b>39.77</b>	<b>0.9958</b>

#### 3.3.1 SOTS 测试集上测试结果

从 SOTS 测试集中选取部分室内雾图和室外雾图, 经过各算法后恢复的无雾图如图 6 所示。由表 1 可以发现本文算法无论在室内数据集还是在室外数据集上训练的结果都明显优于其他方法。其中加粗字体表示为表内最大的值。具体来说, 在所有比较方法中, 测试效果最好的均是 SFNet, 其 PSNR 值分别在室内数据集和室外数据集上达到了 39.25 dB 和 37.37 dB。更值得注意的是, 本文算法相较于 SFNet 的 PSNR 在室内数据集上提高了 0.82 dB; 在室外数据集上提高了 2.4 dB。本文算法相较于 OKNet 的 SSIM 在室内数据集上提高了 0.0006; 在室外数据集上提高了 0.0014。

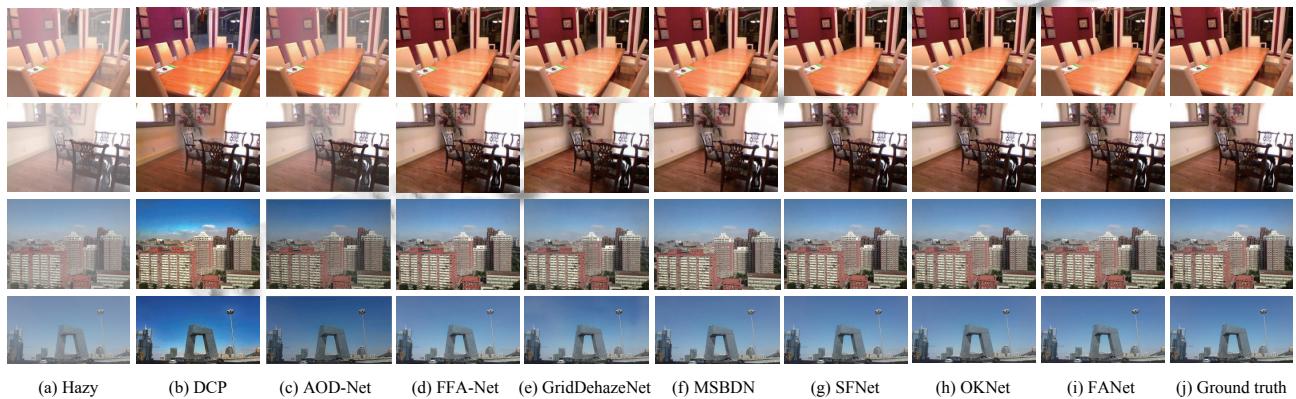


图 6 不同方法可视化结果图

由图 6 可以看出 DCP 方法在处理天空区域时容易出现过暗的情况, 这是因为该算法在对大气光的估计过程中存在误差, 尤其是在光源明亮的情况下。AOD-Net 相较于 DCP 更关注整体去雾, 但也带来了细节丢失和边缘模糊等问题。FFA-Net 和 GridDehazeNet 明显比前

3 种传统经典算法效果更好, 但出现了部分区域过增强现象。其中, FFA-Net 算法中采用了注意力机制来增强图像去雾效果, 这也在一定程度上造成注意力分配不平衡, 从而造成过度增强的现象, GridDehazeNet 的泛化能力较差, 因此得到的去雾效果并不理想。最后, SFNet、

OKNet 去雾效果虽有一定的改善,但在与本文算法的对比下,并没有很好的在细节与整体直接达到平衡,这是因为这两个算法都只采用了频率机制来关注图像中的高低频信息,并未关注到图像中通道与像素之间存在的特征关联。因此,经过 FANet 算法得到的去雾图片无论是在视觉上,还是在指标上都展现出了更好的效果。

### 3.3.2 HSTS 和 Haze4k 测试集上测试结果

为进一步验证 FANet 算法在其他数据集上的去雾效果,本文在 HSTS 和 Haze4k 测试集上分别进行 3 组子对比实验。为保证测试的公平性,本文算法将 Haze4k 测试集按照室内与室外重新划分为 Haze4k-indoor 和 Haze4k-outdoor 数据集,再依次使用对应的权重文件进行测试,得到的结果如表 2—表 4 所示。由表 3 看出,本文算法在 Haze4k-indoor 测试集上并未取得最佳结果,在 PSNR 评价指标上与最高的 SFNet 算法相差 1.19 dB,但在 SSIM 上仍略优于其他算法。这是由于该数据中的有雾图像存在雾度不均的现象,这也使得本文算法在一定程度上出现过增强现象,导致最终结果与预期有所差异。由表 2 和表 4 可以看出,本文算法在室外薄雾数据集上的去雾效果,在 PSNR 和 SSIM 指标上均优于近两年经典算法,进一步证明了 FANet 算法去雾效果的有效性和鲁棒性。

表 2 不同方法在 HSTS 测试集上的定量评价结果

方法	PSNR (dB)	SSIM
DehazeFormer-t	36.55	0.9910
MSBDN	36.76	0.9838
SFNet	38.93	0.9927
OKNet	39.25	0.9918
FANet	<b>41.57</b>	<b>0.9951</b>

表 3 不同方法在 Haze4k-indoor 测试集上的结果

方法	PSNR (dB)	SSIM
DehazeFormer-t	16.73	0.7328
MSBDN	22.88	0.9532
SFNet	20.58	0.9254
OKNet	<b>22.95</b>	0.9327
FANet	21.76	<b>0.9621</b>

## 3.4 消融实验

为了进一步验证本文所提出算法各模块的有效性,在 SOTS 室内测试集上进行消融实验。

### 3.4.1 算法各模块的消融实验

为验证模型中各模块的有效性,设计了 5 组实验组,分别添加双分支频率提取模块(DBFE)、额外的通

道像素模块(ACPM)、频率融合模块(FFM)和通道像素注意力模块(CPAttention)进行消融实验。表 5 中“√”表示添加了相应的模块,而“—”表示未添加。Base 表示只由双分支频率提取模块(DBFE)、3 个下采样层和 3 个上采样层构成基础特征提取网络。消融实验的各个结果如表 5 所示。

表 4 不同方法在 Haze4k-outdoor 测试集上的结果

方法	PSNR (dB)	SSIM
DehazeFormer-t	18.55	0.8133
MSBDN	23.10	0.8532
SFNet	23.01	0.9227
OKNet	23.15	0.9183
FANet	<b>23.39</b>	<b>0.9593</b>

表 5 各模块消融实验的定量评价结果

Model name	Module				Evaluation index	
	DBFE	FFM	ACPM	CPAttention	PSNR (dB)	SSIM
Base	√	—	—	—	38.20	0.9937
Base+CPAttention	√	—	—	√	38.93	0.9947
Base+FFM	√	√	—	—	38.87	0.9947
Base+ACPM	√	—	√	—	39.51	0.9950
Base+ACPM+	√	√	√	√	<b>40.07</b>	<b>0.9958</b>
CPAttention+FFM						

通过 Base 模型所得到的结果相较于对比实验中绝大多数算法效果要更好,得到 DBFE 是本文算法的核心模块。将表 5 中第 2—4 行的消融模型与 Base 消融模型对比,得到 CPAttention、FFM、ACPM 这 3 个模块均对本文算法有着不同程度的提升。具体来说,CPAttention 使得算法 PSNR 增加 0.73 dB, FFM 使得算法 PSNR 增加 0.67 dB。另外,ACPM 使得算法 PSNR 增加 1.31 dB。最终,将 3 个模块全部加入 Base 模型中,使得本文算法(FANet)得到最高效果。

### 3.4.2 双分支频率提取模块消融实验

针对堆叠双分支频率提取模块(DBFE)的个数选择,本文做了以下实验,分别选取 8 和 16 做消融实验,结果如表 6 所示,可以看出,在选取堆叠次数为 8 相较于 16 在 PSNR 指标上低了 1.96 dB,在 SSIM 指标上低了 0.0315。因此,本文算法选取堆叠双分支频率提取模块(DBFE)的个数为 16。

表 6 DBFE 模块数量消融实验定量评价结果

Num	PSNR (dB)	SSIM
8	38.11	0.9643
16	<b>40.07</b>	<b>0.9958</b>

## 4 结束语

本文提出了一种基于频率和注意力机制的端到端单幅图像去雾算法。该算法引入了双分支频率提取模块、通道-像素注意力模块以及频率融合模块，并结合编码-解码器结构，使得算法不仅能够关注图像的频率信息，还能有效捕捉通道与像素之间的关系，从而实现特征的充分融合，显著提升了去雾效果。在实验中，我们的算法在合成有雾图像数据集和实际有雾图像数据集上均表现出色，取得了理想的去雾效果。未来的工作将着重于进一步轻量化模型，以减少训练参数和降低训练成本，同时致力于继续对真实和不均匀雾的图像进行恢复，从而提升算法的实用性和鲁棒性。

## 参考文献

- 1 苏彤, 王颖, 邓启扬, 等. 基于 YOLOv5 改进的雾天行人与车辆检测算法. 系统仿真学报, 2024, 36(10): 2413–2422. [doi: [10.16182/j.issn1004731x.joss.23-0725](https://doi.org/10.16182/j.issn1004731x.joss.23-0725)]
- 2 刘姝廷, 孙诚志, 娄浩云, 等. 基于直方图均衡化和 Retinex 的图像去雾研究. 信息与电脑(理论版), 2023, 35(15): 172–175.
- 3 Rajput GS, Rahman ZU. Hazard detection on runways using image processing techniques. Proceedings of the Enhanced and Synthetic Vision 2008. Orlando: SPIE, 2008. 69570D.
- 4 高原原, 胡海苗. 基于多子块协同单尺度 Retinex 的浓雾图像增强. 北京航空航天大学学报, 2019, 45(5): 944–951. [doi: [10.13700/j.bh.1001-5965.2018.0528](https://doi.org/10.13700/j.bh.1001-5965.2018.0528)]
- 5 Stark JA. Adaptive image contrast enhancement using generalizations of histogram equalization. IEEE Transactions on Image Processing, 2000, 9(5): 889–896. [doi: [10.1109/83.841534](https://doi.org/10.1109/83.841534)]
- 6 McCartney EJ. Optics of the Atmosphere: Scattering by Molecules and Particles. New York: Wiley, 1976.
- 7 Nayar SK, Narasimhan SG. Vision in bad weather. Proceedings of the 7th IEEE International Conference on Computer Vision. Kerkyra: IEEE, 1999. 820–827.
- 8 He KM, Sun J, Tang XO. Single image haze removal using dark channel prior. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(12): 2341–2353. [doi: [10.1109/TPAMI.2010.168](https://doi.org/10.1109/TPAMI.2010.168)]
- 9 杨燕, 王志伟. 基于均值不等关系优化的自适应图像去雾算法. 电子与信息学报, 2020, 42(3): 755–763. [doi: [10.11999/JEIT190368](https://doi.org/10.11999/JEIT190368)]
- 10 Zhu YY, Tang GY, Zhang XY, et al. Haze removal method for natural restoration of images with sky. Neurocomputing, 2018, 275: 499–510. [doi: [10.1016/j.neucom.2017.08.055](https://doi.org/10.1016/j.neucom.2017.08.055)]
- 11 Yang Y, Wang CY, Liu RS, et al. Self-augmented unpaired image dehazing via density and depth decomposition. Proceedings of the 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans: IEEE, 2022. 2027–2036.
- 12 Zhu QS, Mai JM, Shao L. A fast single image haze removal algorithm using color attenuation prior. IEEE Transactions on Image Processing, 2015, 24(11): 3522–3533. [doi: [10.1109/TIP.2015.2446191](https://doi.org/10.1109/TIP.2015.2446191)]
- 13 Tan RT. Visibility in bad weather from a single image. Proceedings of the 2008 IEEE Conference on Computer Vision and Pattern Recognition. Anchorage: IEEE, 2008. 1–8.
- 14 Cai BL, Xu XM, Jia K, et al. DehazeNet: An end-to-end system for single image haze removal. IEEE Transactions on Image Processing, 2016, 25(11): 5187–5198. [doi: [10.1109/TIP.2016.2598681](https://doi.org/10.1109/TIP.2016.2598681)]
- 15 Li BY, Peng XL, Wang ZY, et al. AOD-Net: All-in-one dehazing network. Proceedings of the 2017 IEEE International Conference on Computer Vision. Venice: IEEE, 2017. 4780–4788.
- 16 Yeh CH, Huang CH, Kang LW. Multi-scale deep residual learning-based single image haze removal via image decomposition. IEEE Transactions on Image Processing, 2020, 29: 3153–3167. [doi: [10.1109/TIP.2019.2957929](https://doi.org/10.1109/TIP.2019.2957929)]
- 17 Yuan KL, Wei JG, Lu WH, et al. Single image dehazing via NIN-DehazeNet. IEEE Access, 2019, 7: 181348–181356. [doi: [10.1109/ACCESS.2019.2958607](https://doi.org/10.1109/ACCESS.2019.2958607)]
- 18 Chen WT, Fang HY, Ding JJ, et al. PMHLD: Patch map-based hybrid learning DehazeNet for single image haze removal. IEEE Transactions on Image Processing, 2020, 29: 6773–6788. [doi: [10.1109/TIP.2020.2993407](https://doi.org/10.1109/TIP.2020.2993407)]
- 19 Bhola A, Sharma T, Verma NK. DCNet: Dark channel network for single-image dehazing. Machine Vision and Applications, 2021, 32(3): 62. [doi: [10.1007/s00138-021-01173-x](https://doi.org/10.1007/s00138-021-01173-x)]
- 20 Zhang H, Patel VM. Densely connected pyramid dehazing network. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018. 3194–3203.
- 21 Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative adversarial networks. Proceedings of the 2014 Conference on Neural Information Processing Systems. 2014. 1–9.
- 22 Chen DD, He MM, Fan QN, et al. Gated context aggregation network for image dehazing and deraining. Proceedings of the 2019 IEEE Winter Conference on Applications of

- Computer Vision (WACV). Waikoloa: IEEE, 2019. 1375–1383.
- 23 Engin D, Genc A, Ekenel HK. Cycle-dehaze: Enhanced CycleGAN for single image dehazing. Proceedings of the 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Salt Lake City: IEEE, 2018. 938–9388.
- 24 Zhang J, Tao DC. FAMED-Net: A fast and accurate multi-scale end-to-end dehazing network. *IEEE Transactions on Image Processing*, 2020, 29: 72–84. [doi: [10.1109/TIP.2019.2922837](https://doi.org/10.1109/TIP.2019.2922837)]
- 25 Li YN, Miao QG, Ouyang WL, et al. LAP-Net: Level-aware progressive network for image dehazing. Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019. 3275–3284.
- 26 Qin X, Wang ZL, Bai YC, et al. FFA-Net: Feature fusion attention network for single image dehazing. Proceedings of the 34th AAAI Conference on Artificial Intelligence. New York: AAAI, 2020. 11908–11915.
- 27 Wu HY, Qu YY, Lin SH, et al. Contrastive learning for compact single image dehazing. Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville: IEEE, 2021. 10546–10555.
- 28 Ji HB, Feng X, Pei WJ, et al. U2-former: A nested u-shaped Transformer for image restoration. arXiv:2112.02279, 2021.
- 29 Song YD, Zhou Y, Qian H, et al. Rethinking performance gains in image dehazing networks. arXiv:2209.11448, 2022.
- 30 Zheng Y, Zhan JH, He SF, et al. Curricular contrastive regularization for physics-aware single image dehazing. Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver: IEEE, 2023. 5785–5794.
- 31 Lu LP, Xiong Q, Chu DF, et al. MixDehazeNet: Mix structure block for image dehazing network. arXiv:2305.17654, 2023.
- 32 Cui YN, Tao Y, Bing ZS, et al. Selective frequency network for image restoration. Proceedings of the 11th International Conference on Learning Representations. Kigali: ICLR, 2022.
- 33 Cui YN, Ren WQ, Cao XC, et al. Image restoration via frequency selection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024, 46(2): 1093–1108. [doi: [10.1109/TPAMI.2023.3330416](https://doi.org/10.1109/TPAMI.2023.3330416)]
- 34 Cui YN, Ren WQ, Knoll A. Omni-kernel network for image restoration. Proceedings of the 38th AAAI Conference on Artificial Intelligence. Vancouver: AAAI, 2024. 1426–1434.
- 35 Cui YN, Knoll A. Dual-domain strip attention for image restoration. *Neural Networks*, 2024, 171: 429–439. [doi: [10.1016/j.neunet.2023.12.003](https://doi.org/10.1016/j.neunet.2023.12.003)]
- 36 Cui YN, Tao Y, Jing LX, et al. Strip attention for image restoration. Proceedings of the 32nd International Joint Conference on Artificial Intelligence. Macao: IJCAI, 2023. 645–653.
- 37 Liu XH, Ma YR, Shi ZH, et al. GridDehazeNet: Attention-based multi-scale network for image dehazing. Proceedings of the 2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019. 7313–7322.
- 38 Dong H, Pan JS, Xiang L, et al. Multi-scale boosted dehazing network with dense feature fusion. Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020. 2154–2164.

(校对责编: 张重毅)