

## 基于特征融合注意力和对比学习的森林图像去雾

吴文强, 陈爱斌, 李潇瑶

中南林业科技大学 人工智能应用研究所, 湖南 长沙 410004

**摘要:** 针对现有算法处理森林雾天图像时普遍存在的去雾不彻底、暗区细节丢失及色彩失真等问题, 提出一种基于特征融合注意力与对比学习的自适应森林图像去雾算法。具体而言, 首先设计了一种多尺度特征融合注意力机制, 通过联合通道与空间注意力动态调节特征响应, 增强重要特征的表达能力; 其次构建了局部对比正则模块, 提升模型对暗区与远景区域雾浓度变化的判别能力; 此外, 引入自适应色彩校正模块, 有效缓解色彩失真问题。在合成森林雾图与真实森林雾图数据集上的实验结果表明, 所提算法在多项评价指标上均优于现有方法, 峰值信噪比与结构相似度显著提升, 自然图像质量评估值降低, 展现出良好的鲁棒性和泛化能力。

**关键词:** 图像去雾; 特征融合注意力; 深度学习; 对比学习

**中图分类号:** TP391; TP18

**文章编号:** 0255-8297(2026)01-0097-13

## Forest Image Dehazing Based on Feature Fusion Attention and Contrastive Learning

WU Wenqiang, CHEN Aibin, LI Xiaoyao

*Institute of Artificial Intelligence Application, Central South University of Forestry & Technology, Changsha 410004, Hunan, China*

**Abstract:** Current algorithms often struggle with incomplete dehazing, loss of details in dark areas, and color distortion in forest foggy images. To address these issues, this paper proposed an adaptive forest image dehazing algorithm based on feature fusion attention and contrastive learning. A multi-scale feature fusion attention mechanism was designed, which dynamically adjusted feature responses by combining channel and spatial attention, thereby enhancing the representation capability of important features. A local contrast regularization module was constructed to enhance the ability of the model to discriminate variations in fog concentration in dark and distant areas. Furthermore, an adaptive color correction module was introduced to mitigate color distortion. Experimental results on both synthetic and real-world forest foggy image datasets demonstrate that the proposed algorithm outperforms existing methods, achieving significant improvements in peak signal-to-noise ratio (PSNR) and structural similarity (SSIM) and a reduction in natural image

收稿日期: 2025-08-05

基金项目: 国家自然科学基金 (No. 62276276); 湖南省自然科学基金 (No. 2024JJ6721)

通信作者: 李潇瑶, 博士, 讲师, 研究方向为图像处理。E-mail: lxy0731@csuft.edu.cn

quality evaluator (NIQE), and exhibiting strong robustness and generalization ability.

**Keywords:** image dehazing, feature fusion attention, deep learning, contrastive learning

随着无人机、自动监测等技术在林业领域的广泛应用,高分辨率森林图像已成为森林资源调查、病虫害监测和火灾预警的重要依据。然而,林区多雾的气候环境(如晨雾、山间湿气)常导致采集的图像出现对比度降低、色彩失真与细节模糊等问题,严重影响了后续植被指数(如归一化植被指数、增强型植被指数)的计算精度和目标检测的可靠性。图像去雾作为图像增强领域的重要研究方向,在自动驾驶、安防监控、遥感测绘等领域具有广泛的应用前景。森林图像通常具有景深长、纹理稀疏或重复(如远景枝叶)、天空占比较大以及逆光拍摄等特点,加之局部遮挡与非均匀雾分布,易导致如下问题:远景与暗区的透射率估计偏差较大,边缘信息易被过度平滑;天空及高亮区域容易出现色彩偏移或过饱和;传统全局对比度约束对局部雾团分布的适应性较差。现有的去雾算法在处理森林复杂场景时,往往面临去雾不彻底、暗区细节丢失和色彩失真等问题,尤其是在雾浓度分布不均匀、光照条件复杂的情况下,算法的性能显著下降<sup>[1]</sup>。

目前,国内外的图像去雾技术仍主要围绕城市场景展开,如交通监控、航拍图像与遥感影像等<sup>[2]</sup>。现有图像去雾方法大致分为3类:基于图像增强的方法、基于物理模型的方法和基于学习的方法。基于图像增强的方法(如直方图均衡算法<sup>[3]</sup>、Retinex理论<sup>[4-5]</sup>等)通常未充分考虑雾天成像的物理机制,导致去雾效果欠佳,且易受光照条件限制。基于物理模型的方法(如偏振光去雾算法<sup>[6]</sup>与暗通道先验(dark channel prior, DCP)算法<sup>[7]</sup>)通过构建大气散射模型,并利用先验信息实现图像去雾。然而,森林场景具有景深范围广、景物结构单一、天空区域占比大等特性,导致先验信息估计不准确,尤其在天空及景深突变区域易出现失真现象。基于学习的方法(如FFA-Net<sup>[8]</sup>、AOD-Net<sup>[9]</sup>、RSHazeDiff<sup>[10]</sup>、UCL-Net<sup>[11]</sup>等)无需显式估计透射率参数,即可通过端到端训练直接复原清晰图像,在简化处理流程和提升效果一致性方面表现较好,但其性能高度依赖于训练数据集的构建质量。

为此,本文以深度学习为基础,提出一种融合对比学习的森林图像去雾方法。该方法通过引入对比学习机制增强模型对雾浓度变化的感知能力,并结合多尺度特征融合与自适应色彩校正模块,全面提升图像去雾效果。本研究不仅为森林雾天图像复原提供了一种有效的技术解决方案,同时也为复杂场景下的图像增强任务提供了新的研究思路。本文的主要贡献如下:

1) 提出了一种面向森林场景的多尺度特征融合注意力机制,在通道-空间联合注意的基础上引入亮度引导与局部语义分块,提升低照度与高雾浓度区域的特征响应。

2) 构建局部对比正则模块,以块级度量与间隔约束强化暗区/远景的判别性,并对标准InfoNCE进行局部化与边界敏感优化。

3) 设计了自适应色彩校正模块,采用轻量级网络预测校正参数,并结合线性/非线性变换自适应校正色彩,有效缓解天空区域过饱和及整体图像偏色问题。

4) 在RESIDE-SOTS标准数据集和自建的FOREST数据集上进行系统评测,并提供了真实森林雾图的NIQE评价结果与可视化对比。

## 1 基本原理

### 1.1 图像去雾的物理模型

图像去雾的核心理论基础是大气散射模型<sup>[12-13]</sup>,该模型描述了雾霾环境下光线的衰减与散射过程,其数学表达式如式(1)所示:

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

式中:  $I(x)$  为观测到的有雾图像;  $J(x)$  为无雾图像;  $A$  为全局大气光;  $t(x)$  为透射率, 表示光线到达相机的衰减程度。透射率  $t(x)$  与场景深度  $d(x)$  的关系如式 (2) 所示:

$$t(x) = e^{-\beta d(x)} \quad (2)$$

式中:  $\beta$  为大气散射系数, 与雾霾浓度成正比。基于该模型, 图像去雾任务可以转化为对透射率  $t(x)$  和大气光  $A$  的估计, 进而实现无雾图像  $J(x)$  的恢复。然而, 在复杂林地场景中, 由于树木、枯枝等高频纹理的干扰, 透射率估计往往不准确, 导致去雾结果出现晕轮效应或细节丢失。

## 1.2 对比学习

对比学习是一种自监督学习方法, 其核心思想是通过构建正负样本对, 学习样本在特征空间中的表示。其目标是拉近正样本对的相似性, 同时推远负样本对的相似性, 从而增强模型对特征表示的判别能力。对比学习中的正样本对通常为语义相似的样本对, 而语义不同的样本对则作为负样本对。对于一个锚点样本  $x$ , 其正样本  $x^+$  (与  $x$  语义相似) 和负样本  $x^-$  (与  $x$  语义不同), 对比学习的目标是最小化式 (3) 所示的损失函数:

$$L_{\text{cont}} = -\ln \frac{\exp(\langle f(x), f(x^+) \rangle / \tau)}{\sum_{x^-} \exp(\langle f(x), f(x^-) \rangle / \tau)} \quad (3)$$

式中:  $f(\cdot)$  表示由编码器或特征提取网络获得的高维特征映射函数, 其输入为图像样本  $x$ , 输出为归一化后的特征向量, 用于衡量样本间的相似性;  $\langle \cdot, \cdot \rangle$  表示向量内积运算;  $\tau$  为温度参数。通过优化该损失函数, 模型能够拉近正样本对的相似性, 同时推远负样本对的相似性。在图像去雾任务中, 对比学习可通过构建清晰图像与雾霾图像的特征对比, 增强模型对雾霾分布的感知能力。

近年来, 随着自监督学习的发展, 对比学习在图像增强领域展现出了强大潜力。以 InfoNCE 为代表的对比学习在重建任务中多采用特征相似度拉近/推远策略。DehazeFormer 与 Glow-Dehaze 引入全局或块级对比以增强结构保持能力, 并通过设计全局或块级别的正负样本对, 在图像恢复中强化模型的感知能力。尤其是 Glow 方法引入了 Patch-wise 感知对比监督策略, 可有效恢复图像暗部细节与结构边缘信息。UCL-Dehaze 等无监督/自监督范式通过伪正负构造提升真实场景适配。与上述方法相比, 本文将对对比学习局部化至块级, 并引入间隔超参数与亮度感知机制, 着重提升暗区与远景的恢复一致性与边界可分性。

## 2 方法

本研究提出了一种融合对比学习的图像去雾方法, 该方法针对森林图像中雾气浓度不均匀、景深差异等问题, 通过引入对比学习机制和多尺度特征融合模块, 提升模型对雾浓度变化的感知能力, 并结合自适应色彩校正模块, 减少去雾过程中的色彩失真问题。

本文算法的整体框架如图 1 所示, 主要由自编码器去雾网络和对比正则模块构成, 具体包括以下几个步骤: 1) 特征提取与融合。首先通过卷积和下采样操作, 逐步压缩特征图的尺寸, 提取不同尺度的特征, 接着通过特征融合注意力动态调整特征权重, 增强模型对雾浓度变化的感知能力, 最后通过上采样操作逐步恢复图像分辨率。2) 自适应色彩校正模块。通过动态调整图像的色彩分布, 可有效减少去雾过程中的色彩失真问题, 进而提升去雾图像的视觉质量。3) 对比正则化。通过对比学习机制, 将自编码器去雾网络输出的初步去雾图像进行对比正则化, 增强模型对局部雾浓度变化的判别能力, 最终输出去雾后的图像。

## 2.1 多尺度特征融合注意力机制

传统的多尺度特征融合通常采用简单的拼接或加权求和操作, 缺乏对不同尺度特征的动态调整能力。本研究在 FFA-Net 的基础上, 于融合阶段引入局部语义分块, 对易雾积聚的低纹理、远景区域赋予更高权重; 同时增设亮度引导门控, 通过图像亮度直方图/局部亮度均值调节通道-空间注意力阈值, 优化暗区响应; 另外, 采用跨尺度重标定策略替代简单拼接, 有效抑制高层语义对低层边缘的淹没。此外, 设计了多尺度特征融合模块, 结合通道注意力和空间注意力机制, 动态调整不同尺度特征的权重, 增强模型对雾浓度变化的感知能力。

### 2.1.1 多尺度特征融合

多尺度特征融合是指从输入图像中提取不同尺度的特征, 并将这些特征进行有效融合, 以增强模型对图像细节和全局信息的感知能力<sup>[14]</sup>。在图像去雾任务中, 雾浓度分布不均匀, 远景和近景区域的雾浓度差异较大, 因此多尺度特征融合能够帮助模型更好地处理这些复杂场景。具体地, 首先通过多层卷积和下采样操作, 提取图像的低级特征(如边缘、纹理)和高级特征(如物体、场景)。低级特征通常包含更多的细节信息, 而高级特征则包含更多的语义信息。然后将不同尺度的特征进行融合。通常通过上采样或反卷积操作将低级特征与高级特征进行拼接或加权求和。

### 2.1.2 特征融合注意力机制

注意力机制通过动态调整特征权重, 增强模型对重要特征的关注, 同时抑制不重要的特征, 其表达式如式(4)所示:

$$F_{\text{fused}} = \sum_{i=1}^n \alpha_i F_i \quad (4)$$

式中:  $F_i$  为第  $i$  个尺度的特征图;  $\alpha_i$  为通道-空间注意力权重, 通过全局平均池化(global average pooling, GAP)和全局最大池化(global max pooling, GMP)联合计算, 如式(5)所示:

$$\alpha_i = \sigma(\text{Conv}(\text{Concat}[\text{GAP}(F_i), \text{GMP}(F_i)])) \quad (5)$$

式中: Conv 表示卷积操作; Concat 表示特征拼接;  $\sigma$  为 Sigmoid 函数。

在图像去雾任务中, 将通道注意和空间注意融合为新的注意力机制, 可以帮助模型更好地处理雾浓度分布不均匀的场景, 具体结构如图 1 中的特征融合注意力(feature fusion attention, FA)模块所示。

通道注意力机制通过计算每个通道的权重, 动态调整通道特征的贡献度。具体地, 首先对每个通道的特征图进行全局平均池化, 得到每个通道的全局特征表示。然后通过全连接层计算每个通道的权重, 通常使用 Sigmoid 函数将权重限制在  $[0, 1]$  之间。最后通过特征加权, 将计算得到的权重与原始特征图相乘, 从而得到加权后的特征图。通道注意力机制的原理具体如式(6)所示:

$$\text{CA}(x) = \sigma(\text{FC}(\text{GAP}(x))) \quad (6)$$

式中: GAP 表示全局平均池化; FC 表示全连接层。

空间注意力机制则是通过计算每个空间位置的权重, 动态调整空间特征的贡献度。具体地, 首先将不同尺度的特征图进行拼接, 得到多通道的特征图。然后通过卷积操作得到每个空

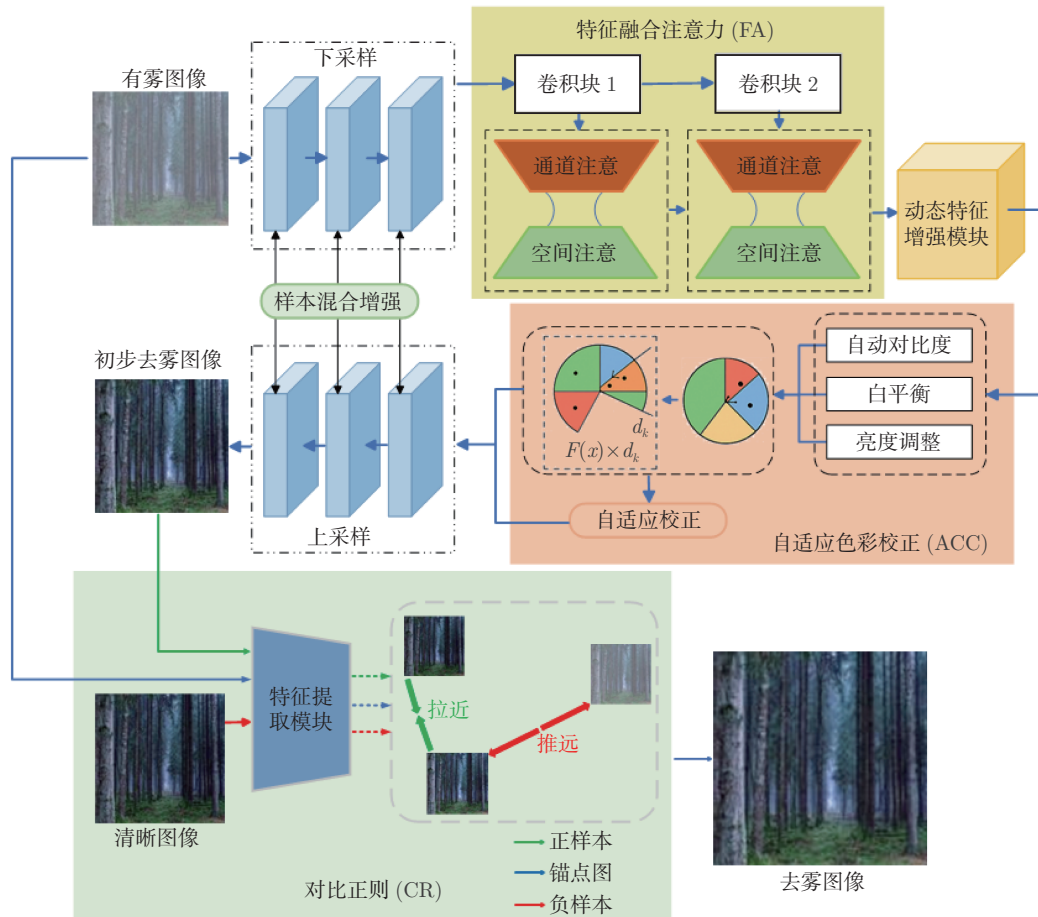


图 1 本文所提算法模型的框架结构

Figure 1 Framework structure of proposed algorithm model

间位置的权重。最后将计算得到的权重与原始特征图相乘，最终得到加权后的特征图。按照空间注意力机制的原理，最终生成的空间注意力图的表达式为

$$SA(x) = \sigma(\text{Conv}(\text{Concat}(x))) \quad (7)$$

与经典 FFA-Net 相比，本文在特征融合阶段引入局部语义分块与亮度引导机制，使通道与空间注意力权重更加适应森林图像中高低对比区域的差异分布，避免了 FFA-Net 在低光强区域响应不足的问题。

### 2.1.3 多尺度特征融合与注意力机制的结合

本研究通过将多尺度特征融合与注意力机制结合，增强模型对雾浓度变化的感知能力。具体步骤如下：首先是多尺度特征提取，即通过多层卷积和下采样操作，提取图像的低级特征和高级特征；接着将提取的不同尺度的特征进行融合，通过上采样或反卷积操作将低级特征与高级特征进行拼接或加权求和；最后在特征融合的过程中，特征融合注意力机制通过整合通道注意力与空间注意力，动态调整不同尺度及空间位置的特征权重。通过多尺度特征融合与注意力机制的结合，去雾网络能够更有效地提取图像中的特征，从而更好地处理不同浓度

和不同光照的有雾图像。

## 2.2 自适应色彩校正

自适应色彩校正 (adaptive color correction, ACC) 模块旨在解决图像去雾过程中常见的色彩失真问题<sup>[15]</sup>。通常情况下森林雾图色彩失真的原因有两个: 雾霾散射效应和光照条件复杂。雾霾会散射光线, 导致图像的色彩分布发生变化。同时, 森林场景中光照条件复杂, 进一步加剧了色彩失真问题。在去雾任务中, 由于雾霾的散射作用, 图像的色彩分布往往会发生变化, 导致去雾后的图像出现色彩偏差或失真。自适应色彩校正模块通过动态调整图像的色彩分布, 使其与清晰图像的色彩分布保持一致, 从而提升去雾图像的视觉质量。该模块首先通过估计输入图像的色彩分布特征, 构建其色彩直方图, 进而对图像的整体色彩分布进行精准分析。本研究通过设计色彩校正函数, 动态调整图像的色彩分布。色彩校正函数通常采用线性变换或非线性变换。经过线性变换和非线性变换校正后的图像分别如式 (8) 和 (9) 所示:

$$I_{\text{corrected}} = aI_{\text{input}} + b \quad (8)$$

$$I_{\text{corrected}} = aI_{\text{dehaze}}^{\beta} + b \quad (9)$$

式中:  $I_{\text{input}}$  为输入图像;  $a$  和  $b$  分别为色彩校正的缩放参数和偏移参数, 用于调整图像的亮度、对比度和整体色调; 参数  $\beta = 1.2$  用于增强暗区对比度。通过调整参数  $a$  和  $b$ , 可以动态控制图像的色彩分布, 使其与清晰图像的色彩分布保持一致。参照局部仿射颜色变换做法, 将参数  $a$  和  $b$  设计为可学习的局部仿射系数, 并通过轻量化网络进行回归; 同时, 借鉴引导滤波思想对系数施加空间平滑约束, 以抑制块状伪影的产生。无监督或消融设置中,  $a$  和  $b$  可基于 Reinhard 的均值-方差对齐方法进行闭式初始化<sup>[16]</sup>。相比传统线性变换, 动态参数可避免天空区域过饱和。

色彩校正损失函数通过 L1 范数度量校正后图像与清晰图像之间的差异, 具体如式 (10) 所示:

$$L_{\text{color}} = \|I_{\text{corrected}} - I_{\text{clear}}\|_1 \quad (10)$$

式中:  $L_{\text{color}}$  为色彩校正损失函数;  $I_{\text{clear}}$  为清晰图像;  $\|\cdot\|_1$  为 L1 范数, 表示逐像素绝对差值的总和。按照式 (10) 计算校正后图像与清晰图像之间的逐像素绝对差值, 通过最小化该损失函数可使模型输出的校正图像色彩分布与清晰图像色彩分布趋于一致。

本研究提出的自适应色彩校正模块通过动态调整图像的色彩分布, 使去雾图像的色彩分布与清晰图像的色彩分布保持一致, 从而提升去雾图像的视觉质量。与传统的色彩校正方法相比, 本研究方法能够更好地处理森林复杂场景下的色彩失真问题, 为森林图像去雾任务提供了一种新的解决方案。

## 2.3 对比正则模块

对比正则 (contrastive regularization, CR) 是一种基于对比学习的正则化方法, 旨在通过构建正负样本对, 增强模型对特征表示的判别能力。其核心思想是通过拉近正样本对的相似性, 同时推远负样本对的相似性, 从而提升模型对关键特征的捕捉能力。受对比学习启发, 本研究将对比学习模块引入图像去雾任务, 用以增强模型对雾浓度变化的判别能力, 尤其是在暗区和远景区域的去雾效果。对比正则可以有效优化模型在森林等雾浓度分布不均场景中的表现, 尤其在远景与暗区区域的去雾效果提升更为显著。

对比正则模块首先需要构建正样本对和负样本对。本文模型中, 正样本对由特征融合去雾网络输出的初步去雾图像构成, 原始有雾图像作为其对应的负样本对, 并采用与原始雾图

成对的无雾图像作为锚点图。对比正则模块通过对比学习,使正样本对更加靠近锚点图,负样本对更加远离锚点图,从而得到更加接近于真实情况的无雾图像。本研究构建的对比正则损失函数能够针对每个局部区域计算对比损失,从而增强模型对局部雾浓度变化的判别能力。通过对比损失函数,模型能够拉近正样本对的相似性,同时推远负样本对的相似性。对比正则与 L1 损失函数<sup>[17]</sup>通过联合优化,共同约束去雾图像的像素级差异和特征表示。通过该联合优化,模型能够在去雾过程中同时关注局部细节和全局结构。传统的对比损失函数如式(11)所示:

$$L_C = \frac{1}{N} \sum_{i=1}^N \left[ d(f(x_i^{\text{dehaze}}), f(x_i^{\text{clear}})) - d(f(x_i^{\text{dehaze}}), f(x_i^{\text{hazy}})) + m \right]_+ \quad (11)$$

式中:  $f(\cdot)$  表示深度特征提取;  $d(\cdot)$  表示特征空间的相似度度量;  $[x]_+$  表示 ReLU 激活函数;  $m$  为间隔超参数,确保去雾图像远离有雾图像。

1.2 节中的式(3)为标准对比学习的基础形式(即 InfoNCE 损失),本文在此基础上提出局部对比正则损失,通过局部分块与间隔约束增强模型在暗区与远景区域的判别能力。在本研究中,优化后的对比正则损失如式(12)所示:

$$L_{CR} = \sum_{P=1}^P \max \left( 0, \|f_P^{\text{dehazed}} - f_P^{\text{clear}}\|_2 - \|f_P^{\text{dehazed}} - f_P^{\text{hazy}}\|_2 + \gamma \right) \quad (12)$$

式中:  $P$  为图像分块索引;  $\gamma = 0.5$  为间隔超参数;  $\|\cdot\|_2$  为 L2 范数(欧氏距离),用于计算两个特征向量的差异。

对比正则模块通过分块策略增强局部特征的判别能力,使模型能够更好地处理局部雾浓度变化,尤其是在远景和暗区区域;同时,借助对比损失函数,模型可学习到更具判别性的全局特征表示,从而增强对雾浓度变化的感知能力;此外,该模块具备对复杂光照条件与雾浓度分布的适应性,有效提升了模型在复杂场景下的去雾性能。

### 3 实验

#### 3.1 数据集

由于自然雾天图像难以大规模构建成对的含雾和无雾图像数据集,本研究使用合成数据集 RESIDE<sup>[18]</sup>和基于公开森林图像合成的有雾数据集 FOREST 进行模型训练,并使用 RESIDE 的 SOTS 子集、自制合成的森林雾图数据集 FOREST 和从视频网站公开视频帧提取的真实森林雾图(统一裁剪为  $256 \times 256$  像素)作为验证集,以评估算法性能。各数据集构成如表 1 和 2 所示。

表 1 RESIDE 数据集子集的构成

Table 1 Composition of the RESIDE dataset subset

子集	图像数量/幅	图像场景	图像类别
SOTS	500	室内/室外	合成雾图

#### 3.2 实验设置

本研究使用 PyTorch 1.6.0 框架构建网络模型,编程环境为 Python3.8,硬件环境为 AMD Ryzen 5 7500F CPU, NVIDIA RTX 4060 Ti GPU。以 16 个样本为一个批次,迭代 200 次,

表 2 FOREST 和真实森林雾图数据集的构成

Table 2 Composition of FOREST and real-world forest foggy image datasets

数据集	图像数量/幅	图像场景	图像类别	图像大小/像素
FOREST	500	森林	合成雾图	512×512
真实森林雾图	200	森林	真实雾图	256×256

并采用余弦退火 (cosine annealing) 学习率衰减策略, 以实现平滑的学习率下降过程。具体地, 设置初始学习率为  $6 \times 10^{-2}$ , 并在训练过程中按照余弦函数曲线逐步衰减至  $1 \times 10^{-4}$ 。该策略可有效避免传统阶梯式衰减带来的震荡问题, 从而使模型在训练后期保持较高的稳定性和泛化性能。优化器选用 Adam, 参数设置具体为  $\beta_1 = 0.900$ 、 $\beta_2 = 0.999$ , 权重衰减系数为  $1 \times 10^{-4}$ 。为定量客观评价本研究算法的优越性, 除主观图像质量评价外, 选择峰值信噪比 (peak signal-to-noise ratio, PSNR)、结构相似度 (structural similarity, SSIM)<sup>[19]</sup> 和自然图像质量评估 (natural image quality evaluator, NIQE)<sup>[20]</sup> 作为去雾算法的评价指标。具体实验环境与主要参数设置如表 3 所示。

表 3 实验环境与主要超参数

Table 3 Experimental environment and main hyper-parameters

类别	配置与参数
硬件环境	AMD Ryzen 5 7500F CPU/NVIDIA RTX 4060 Ti GPU (16 GB VRAM)
操作系统	Ubuntu 22.04
框架与语言	PyTorch 1.6.0/Python 3.8
批次大小	16
训练轮数	200
初始学习率	$6 \times 10^{-2}$
学习率衰减策略	余弦退火至 $1 \times 10^{-4}$
优化器	Adam( $\beta_1 = 0.900$ , $\beta_2 = 0.999$ )

### 3.3 对比实验

相比城市场景, 森林图像中雾气通常更稠密, 分布更不均匀, 且背景纹理结构高度复杂 (如树干、枝叶重叠), 导致传统方法易发生结构错判。此外, 森林中常伴随阴影遮挡与强烈逆光, 进一步加大了对比度恢复的难度。因此, 需设计一种兼具局部精细建模与全局一致性保持能力的去雾网络架构。为了验证所提模型在处理去雾任务尤其是森林去雾时的优势, 本研究在公开数据集和自建数据集上进行与其他先进模型的对比实验。在合成森林图像数据集上的结果如图 2 所示, 其中第 1 行图像为含天空区域的森林有雾图像, 第 2 行图像为正常光照的森林有雾图像, 第 3 行图像为光照较低时的森林有雾图像。由图 2 可以看出, 对森林图像进行去雾处理时, DCP、FFA-Net 和 RSHazeDiff 去雾效果较好, 可明显去除雾气, 但存在色彩不自然、光斑与原图差距明显等问题; 而 AOD-net 去雾效果较差, 不能有效去除雾气; 此

外, FFA-Net 和 RSHazeDiff 在天空区域和低光照区域仍有雾霾残留。

为了进一步验证模型的先进性, 在合成数据集 SOTS 上进行了模型对比实验, 不同算法的去雾效果如图 3 所示, 其中第 1 行图像为室内有雾图像, 第 2 行图像为城市室外有雾图像。对合成的有雾图像进行去雾处理时, 各个模型对于光照条件较好的室内图像去雾时效果均表现良好, 可明显去除图像中的雾气。而对光照复杂的室外图像进行去雾处理时, FFA-Net 和 RSHazeDiff 能有效进行去雾处理, 但局部低光照区域仍有雾气残留; DCP<sup>[21]</sup> 在处理天空区域时出现了色彩失真问题; AOD-Net 对于低光照区域仍有雾气残留。相比较而言, 本研究算法在室内和城市室外场景下均能明显去除雾气, 并且在色彩上更加接近原图。

为了定量客观评价本研究算法的优越性, 采用 PSNR 和 SSIM 作为评价指标, 对自建森林有雾图像数据集以及开源 SOTS 数据集进行实验对比, 结果如表 4 所示, 其中加粗和下划线数值分别表示最好和次优结果。PSNR 用于量化图像相对原图的失真水平, 其数值越大说明失真程度越低, 图像质量越接近于原图; SSIM 则从亮度、对比度及结构 3 个维度综合评估图像相似性, 其数值越接近 1, 表明与原始清晰无雾图像的相似度越高。由表 4 可看出, 本研究方法在 SOTS 数据集室内图像的去雾处理中, SSIM 指标取得最优表现, PSNR 指标仅次于 RSHazeDiff, 位列第二; 而在 SOTS 数据集室外图像的去雾处理中, PSNR 与 SSIM 指标均达到最优水平。此外, 在自建森林有雾数据集上, 本方法的 PSNR 与 SSIM 指标均显著优于其他算法。由此可见, 本研究算法能高效去除森林雾图中的雾气, 同时保留场景细节, 使去雾图像更接近原始清晰图。




图 2 在 FOREST 数据集上的可视化结果

Figure 2 Visualization results on FOREST dataset

为了进一步验证本研究算法对森林场景去雾的优越性, 结果如图 4 所示, 其中第一行图像为低光照森林有雾图像, 第二行图像为正常光照森林有雾图像。森林中树木密集导致光照条件较差, DCP 和 AOD-Net 去雾效果较差, 且色彩恢复也较差; FFA-Net 和 RSHazeDiff 能去除雾气, 但在图像中的部分暗区存在雾气未能去除现象。本研究算法对于真实森林雾图进行去雾处理时, 能更好地保持场景信息。

由于该数据集并不包含对应的清晰图像, 为定量客观评价本研究算法, 使用无参考指标 NIQE 进行对比。NIQE 是一种无参考图像质量评估指标, 主要用于评估图像的自然性和质量, 而不需要原始的无失真参考图像。NIQE 数值越低, 图像质量越好, 各算法的 NIQE 结果




图3 在 SOTS 数据集上的可视化结果

Figure 3 Visualization results on SOTS dataset

表4 在 SOTS 和 FOREST 数据集上的定量评估结果

Table 4 Quantitative evaluation on SOTS and FOREST datasets

方法	SOTS-indoor		SOTS-outdoor		FOREST	
	PSNR/dB $\uparrow$	SSIM $\uparrow$	PSNR/dB $\uparrow$	SSIM $\uparrow$	PSNR/dB $\uparrow$	SSIM $\uparrow$
DCP	26.61	0.817	19.14	0.814	19.37	0.795
AOD-Net	33.56	0.978	33.88	0.922	18.28	0.774
FFA-Net	34.39	<u>0.985</u>	33.57	0.954	22.37	<u>0.839</u>
RSHazeDiff	<b>36.25</b>	0.980	<u>34.78</u>	<u>0.959</u>	<u>24.36</u>	0.824
本文模型	<u>35.98</u>	<b>0.988</b>	<b>34.91</b>	<b>0.965</b>	<b>26.87</b>	<b>0.873</b>




图4 在真实森林有雾数据集上的可视化结果

Figure 4 Visualization results on real-world forest foggy image dataset

如表5所示。在真实森林有雾数据集上，本研究方法的NIQE指标为2.7236，取得了最优结果，说明本研究方法在处理真实森林有雾场景时具有更好的效果。

### 3.4 消融实验

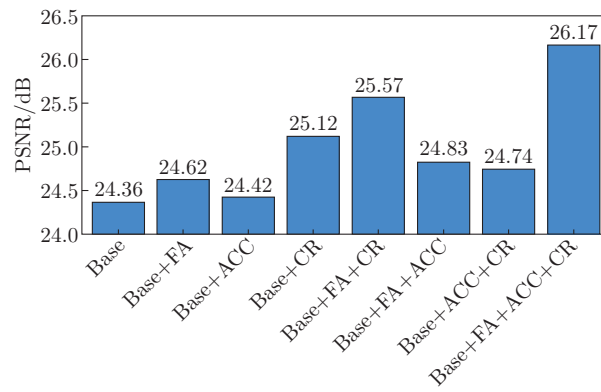
为了更好地验证模型的有效性，针对本研究提出的特征融合注意力机制、对比正则化和自适应色彩校正进行了消融实验，分别测试了单独添加、任意两种组合添加以及同时引入这3个模块到基准模型的效果，实验结果如图5所示。单独引入FA、CR和ACC后，模型输出

表 5 在真实森林有雾图像数据集上的定量评估结果


Table 5 Quantitative evaluation results on real-world forest foggy image dataset

方法	NIQE↓
DCP	3.2876
AOD-Net	3.443 2
FFA-Net	2.978 1
RSHazeDiff	<u>2.796 0</u>
本文模型	<b>2.723 6</b>

无雾图像的 PSNR 和 SSIM 均有所提升, 表明 FA、CR 和 ACC 对模型性能有正向影响。在 SSIM 与 PSNR 两个指标上, 单一或部分模块组合在缺乏有效协同时难以稳定提升性能, 甚至出现退化, 而完整的 FA+ACC+CR 组合在两项指标上均取得最优结果, 充分验证了各模块之间的互补性与整体设计的有效性。



(a) PSNR 对比结果



(b) SSIM 对比结果

图 5 消融实验结果

Figure 5 Ablation experiment results

## 4 结 语

本文提出了一种基于特征融合注意力与对比学习的森林图像去雾方法。该方法在多尺度融合阶段引入亮度引导机制,在训练过程中加入局部对比正则约束,并采用自适应色彩校正模块以增强图像色彩一致性。实验结果表明,所提方法在 RESIDE 和 FOREST 数据集上取得了最优的 PSNR 与 SSIM 性能,并在真实森林雾图场景中实现了最佳的 NIQE 评价表现。本文方法以提升去雾质量与结构还原为核心目标,尽管模型复杂度略有增加,但整体计算开销仍处于可接受范围,适用于实际森林影像处理场景。

本方法在森林图像去雾任务中表现良好,但在极端浓雾或光照条件极差的情况下,模型的泛化能力仍有待提升。未来工作中,我们将探索引入多模态信息与自监督学习策略,以增强模型在极端雾况下的鲁棒性;同时,未来研究将聚焦于轻量化改进方案的探索。此外,融合多光谱或热红外等多源信息,发展跨模态数据融合的去雾方法,也将是进一步提升森林场景图像复原质量的重要研究方向。

## 参考文献:

- [1] ZHU R, WANG L J. Improved wavelet transform algorithm for single image dehazing [J]. *Optik*, 2014, 125(13): 3064-3066.
- [2] 陆松浩. 单幅图像去雾算法研究 [D]. 南京: 南京邮电大学, 2023.
- [3] 李波, 胡红萍, 杨正民. 基于超像素分割的暗通道先验图像去雾算法 [J]. *测试技术学报*, 2025, 39(4): 415-423.  
LI B, HU H P, YANG Z M. Dark channel prior image dehazing algorithm based on super-pixel segmentation [J]. *Journal of Test and Measurement Technology*, 2025, 39(4): 415-423. (in Chinese)
- [4] LI P Y, TIAN J D, TANG Y D, et al. Deep retinex network for single image dehazing [J]. *IEEE Transactions on Image Processing*, 2020, 30: 1100-1115.
- [5] GALDRAN A, ALVAREZ-GILA A, BRIA A, et al. On the duality between retinex and image dehazing [C]//*IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 8212-8221.
- [6] 蒋华伟, 杨震, 张鑫, 等. 图像去雾算法研究进展 [J]. *吉林大学学报(工学版)*, 2021, 51(4): 1169-1181.  
JIANG H W, YANG Z, ZHANG X, et al. Research progress of image dehazing algorithms [J]. *Journal of Jilin University (Engineering and Technology Edition)*, 2021, 51(4): 1169-1181. (in Chinese)
- [7] 陈海秀, 黄仔洁, 陆康, 等. 基于特征增强的双重注意力去雾网络 [J]. *电光与控制*, 2025, 32(1): 15-20, 67.  
CHENG H X, HUANG Z J, LU K, et al. Dual-attention dehazing network based on feature enhancement [J]. *Electronics Optics & Control*, 2025, 32(1): 15-20, 67. (in Chinese)
- [8] QIN X, WANG Z L, BAI Y C, et al. FFA-Net: feature fusion attention network for single image dehazing [DB/OL]. (2019-12-05) [2025-08-05]. <https://arxiv.org/abs/1911.07559>.
- [9] LI B Y, PENG X L, WANG Z Y, et al. AOD-Net: all-in-one dehazing network [C]//*16th IEEE International Conference on Computer Vision (ICCV)*, 2017: 4780-4788.
- [10] XIONG J M, YAN X F, WANG Y Z, et al. RSHazeDiff: a unified Fourier-aware diffusion model for remote sensing image dehazing [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2025, 26(1): 1055-1070.
- [11] WANG Y Z, YAN X F, WANG F L, et al. UCL-Dehaze: toward real-world image dehazing via unsupervised contrastive learning [DB/OL]. (2022-05-04) [2025-08-05]. <https://arxiv.org/abs/2205.01871>.
- [12] LIU X H, MA Y R, SHI Z H, et al. Grid Dehaze Net: attention-based multi-scale network for image dehazing [C]//*IEEE/CVF International Conference on Computer Vision*, 2019: 7314-7323.

- [13] 禹晶, 李大鹏, 廖庆敏. 基于物理模型的快速单幅图像去雾方法 [J]. 自动化学报, 2011, 37(2): 143-149.  
YU J, LI D P, LIAO Q M. Physics-based fast single image fog removal [J]. Acta Automatica Sinica, 2011, 37(2): 143-149. (in Chinese)
- [14] 陈科圻, 朱志亮, 邓小明, 等. 多尺度目标检测的深度学习研究综述 [J]. 软件学报, 2021, 32(4): 1201-1227.  
CHEN K Q, ZHU Z L, DENG X M, et al. Deep learning for multi-scale object detection: a survey [J]. Journal of Software, 2021, 32(4): 1201-1227. (in Chinese)
- [15] LI R D, PAN J S, LI Z C, et al. Single image dehazing via conditional generative adversarial network [C]//IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8202-8211.
- [16] REINHARD E, ASHIKHMIN M, GOOCH B, et al. Color transfer between images [J]. IEEE Computer Graphics and Applications, 2001, 21(5): 34-41.
- [17] PESME S, FLAMMARION N. Online robust regression via SGD on the  $\ell_1$  loss [C]//34th Conference on Neural Information Processing Systems (NeurIPS), 2020: 2540-2552.
- [18] LI B Y, REN W Q, FU D P, et al. Benchmarking single-image dehazing and beyond [DB/OL]. (2019-04-22) [2025-08-05]. <https://arxiv.org/abs/1712.04143>.
- [19] 张丹丹, 赵迎会. 自然图像质量评价方法综述 [J]. 电脑知识与技术, 2020, 16(9): 209-211.  
ZHANG D D, ZHAO Y H. Survey of natural images-quality assessment method [J]. Computer Knowledge and Technology, 2020, 16(9): 209-211. (in Chinese)
- [20] MITTAL A, SOUNDARARAJAN R, BOVIK A C. Making a “completely blind” image quality analyzer [J]. IEEE Signal Processing Letters, 2013, 20(3): 209-212.
- [21] 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, 2010, 33(12): 2341-2353.

(编辑: 张 娟)