



基于粗到细的多尺度单幅图像去雾方法

王德文, 陈威, 苏攀

引用本文:

王德文, 陈威, 苏攀. 基于粗到细的多尺度单幅图像去雾方法[J]. 智能系统学报, 2024, 19(5): 1102-1110.

WANG Dewen, CHEN Wei, SU Pan. Single-image dehazing via a coarse-to-fine multiscale approach[J]. *CAAI Transactions on Intelligent Systems*, 2024, 19(5): 1102-1110.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202305005>

您可能感兴趣的其他文章

双向特征融合与注意力机制结合的目标检测

Target detection based on bidirectional feature fusion and an attention mechanism

智能系统学报. 2021, 16(6): 1098-1105 <https://dx.doi.org/10.11992/tis.202012029>

空洞卷积与注意力融合的对抗式图像阴影去除算法

An antagonistic image shadow removal algorithm based on dilated convolution and attention mechanism

智能系统学报. 2021, 16(6): 1081-1089 <https://dx.doi.org/10.11992/tis.202011022>

改进MobileNet的图像分类方法研究

Research on the improved image classification method of MobileNet

智能系统学报. 2021, 16(1): 11-20 <https://dx.doi.org/10.11992/tis.202012034>

一种基于雨线主方向自适应的全局稀疏去雨模型

A global sparse rain removal model based on rain streaks main direction adaptation

智能系统学报. 2020, 15(2): 271-280 <https://dx.doi.org/10.11992/tis.201809042>

基于注意力机制的显著性目标检测方法

Salient object detection method based on the attention mechanism

智能系统学报. 2020, 15(5): 956-963 <https://dx.doi.org/10.11992/tis.201903001>

基于生成对抗网络的机载遥感图像超分辨率重建

Super-resolution reconstruction of airborne remote sensing images based on the generative adversarial networks

智能系统学报. 2020, 15(1): 74-83 <https://dx.doi.org/10.11992/tis.202002002>

DOI: 10.11992/tis.202305005

网络出版地址: <https://link.cnki.net/urlid/23.1538.TP.20240828.1012.018>

基于粗到细的多尺度单幅图像去雾方法

王德文^{1,2}, 陈威¹, 苏攀^{1,2}

(1. 华北电力大学 控制与计算机工程学院, 河北 保定 071003; 2. 华北电力大学 复杂能源系统智能计算教育部工程研究中心, 河北 保定 071003)

摘要: 为了解决现有图像去雾算法易出现细节纹理丢失、颜色失真或对非均匀浓雾处理不彻底的问题, 提出一种基于粗到细的多尺度单幅图像去雾方法。首先, 主干网络使用残差特征注意力模块对有雾图像进行特征提取; 其次, 将不同尺度的输入图像进行卷积预处理, 通过多尺度特征融合模块将预处理的浅层特征与主干网络融合; 再次, 将不同粒度的非对称特征进行有效融合; 最后, 将浅层信息与深层信息自适应混合输出, 通过对比正则损失构建正负样本信息, 使得去雾图像更接近无雾图像。实验结果表明, 与已有代表性的去雾方法相比, 提出的方法能对合成数据集与真实数据集进行有效去雾, 在细节保留与色彩还原上优于对比方法。

关键词: 图像去雾; 粗到细; 多尺度特征融合; 残差特征注意力; 非对称特征融合; 自适应混合; 对比正则; 正负样本

中图分类号: TP391 文献标志码: A 文章编号: 1673-4785(2024)05-1102-09

中文引用格式: 王德文, 陈威, 苏攀. 基于粗到细的多尺度单幅图像去雾方法 [J]. 智能系统学报, 2024, 19(5): 1102-1110.

英文引用格式: WANG Dewen, CHEN Wei, SU Pan. Single-image dehazing via a coarse-to-fine multiscale approach[J]. CAAI transactions on intelligent systems, 2024, 19(5): 1102-1110.

Single-image dehazing via a coarse-to-fine multiscale approach

WANG Dewen^{1,2}, CHEN Wei¹, SU Pan^{1,2}

(1. School of Control and Computer Engineering, North China Electric Power University, Baoding 071003, China; 2. Engineering Research Center of the Ministry of Education for Intelligent Computing of Complex Energy System, North China Electric Power University, Baoding 071003, China)

Abstract: A single-image dehazing method based on a coarse-to-fine, multiscale approach is proposed to address the shortcomings of existing dehazing methods, which often result in loss of detailed texture, color distortion, or incomplete processing of non-uniform dense fog. First, features are extracted from foggy images using the residual feature attention module of the backbone network. Second, images at different scales are preprocessed using convolution, and the preprocessed shallow features are fused with the backbone network through a multiscale feature fusion module. Asymmetric features at different levels are then effectively fused. Finally, shallow information is adaptively combined with deep information at the output. Compared with contrastive regularization loss, positive and negative sample information is constructed to make the defogged image more similar to a fog-free image. The experimental results show that, compared with existing representative defogging methods, the proposed method effectively defogs synthetic and real datasets and outperforms comparison methods in terms of detail retention and color reproduction.

Keywords: image dehazing; coarse to fine; multiscale feature fusion; residual feature attention; asymmetric feature fusion; adaptive mixup; contrastive regularization; positive and negative sample

收稿日期: 2023-05-05. 网络出版日期: 2024-08-28.

基金项目: 河北省自然科学基金项目 (F2021502013); 河北省高等学校科学技术研究项目 (QN2023181); 中央高校基本科研业务费专项资金项目 (2021MS094).

通信作者: 王德文. E-mail: wdewen@gmail.com.

在有雾条件下, 大气中的微小悬浮颗粒会极大地吸收和散射光线, 与良好天气条件下获取的图像相比, 有雾图像通常会受到模糊、颜色失真

和低对比度等图像退化现象的影响^[1], 进而无法获取真实的图像信息。退化现象会对后续的高级计算机视觉任务的性能造成不利的影响, 例如物体的检测和识别。因此, 图像去雾在图像恢复领域得到了大量研究者的关注。克服雾天环境造成的图像退化, 对有雾图像进行去雾预处理, 有助于提升高级视觉任务的性能。

早期去雾模型是基于物理先验的方法, 如大气散射模型^[2]。He 等^[3]通过总结大量户外无雾图像, 发现了在局部区域内, 存在一些像素至少在一个 RGB 通道的值接近于 0, 并将其命名为暗通道先验 (dark channel prior, DCP) 理论, 将此先验理论与雾霾成像模型相结合, 可以直接估计雾霾厚度, 对图像进行去雾。但该方法在图像的天空区域无效, 导致参数估计不准确, 会造成此先验信息失效^[4]。Zhu 等^[5]提出颜色衰减先验 (color attenuation prior, CAP) 的图像去雾算法, 并利用该先验建立了有雾图像场景景深的线性模型。然而, 上述参数估计算法非常依赖先验信息的选择, 且先验信息不具有通用性, 当假设的先验不足以合理描述有雾图像时, 则有可能导致透射率估计不准确, 从而导致去雾效果不佳和色彩失真等现象。

随着深度学习的发展, 许多去雾方法开始依赖于卷积神经网络 (convolutional neural network, CNN)。基于深度学习的图像去雾方法可以分为 2 种。

第 1 种是通过深度神经网络直接估计大气模型中的透射率和全局大气光^[6]。Cai 等^[7]根据大气先验知识, 设计 DehazeNet 用于估计有雾图像与透射率之间映射关系, 将透射率结合大气散射模型实现图像去雾。与 DehazeNet 不同, Li 等^[8]基于重构的大气散射模型, 提出 K-estimating 模块来估计介质传输函数与全局大气光, 提出一个端到端的轻量级的去雾网络 AOD-Net(all-in-one dehazing network)。以大气退化模型为基础的端到端去雾网络在细节恢复效果上有一定提升, 但多数方法把大气光值设置为不变常量值, 可能导致去雾图像出现色彩偏差。

第 2 种是使用深度神经网络构建有雾图像到清晰图像的端到端映射。端到端算法无需考虑有雾图像降质原因和成像过程, 网络输入有雾图像, 经过学习后, 输出即为清晰图像^[9]。Chen 等^[10]提出一种增强的 pix2pix 去雾网络, 该网络将图像去雾视为图像到图像的转换问题。Qu 等^[11]提出了一种端到端门控上下文聚合网络实现图像去雾。Qin 等^[12]提出了一种特征融合注意力 (feature fusion attention, FFA) 网络, 通过处理不同类型

的特征信息以实现图像去雾。Wu 等^[13]提出了一种基于对比学习的紧凑图像去雾方法, 通过引入负样本, 并充分挖掘负样本中的信息, 进一步约束去雾问题解空间的上下界。上述不依赖大气退化模型的端到端的去雾网络, 虽然在一定程度上能去除有雾图像中的雾, 但是在去雾过程中过度提取输入分辨率下的全局多尺度特征, 缺乏关注局部细节纹理信息的能力。

目前提出的基于端到端的 CNN 模型存在以下问题: 大多数现有方法^[11-12]通常采用清晰的图像作为正样本, 通过基于 L1 损失或 L2 损失的图像重构损失来指导去雾网络的训练, 仅使用图像重构损失无法有效处理图像细节, 这可能导致恢复图像中的颜色失真, 作为负样本的有雾图像却没有很好地被利用。为更好地利用负样本, 在图像去雾中引入对比学习, 将真实无雾图像和有雾图像分别作为正样本与负样本, 将去雾网络生成的去雾图像作为样本的锚, 在潜在的特征空间中对三者进行对比, 拉近去雾图像与真实无雾图像的距离, 推远其与有雾图像的距离^[14]。

在现实世界的场景中, 雾往往会呈现出不均匀的浓度分布, 在一幅图像中, 不同区域和不同场景深度, 会受到不同雾浓度条件的影响, 其退化程度也有很大差异。通常, 距离越远, 雾的影响越大, 导致图像的细节丢失和对比度下降越严重。多尺度模型和尺度循环模型通过对图像不同空间尺度的特征进行整合, 从而实现粗到细的学习, 可有效解决雾浓度不均与不同场景深度造成的退化程度不同现象^[15]。即采用多尺度模型和尺度循环模型聚合来自图像不同空间尺度的特征, 可以学习浅层网络的部分局部特征细节, 也能捕获到深层网络的更多全局信息。

针对上述问题, 本文受粗到细学习与对比学习的启发提出一种基于粗到细的多尺度单幅图像去雾方法, 命名为 MIOC-UNet。首先, 为减轻训练的难度, MIOC-UNet 只采用单个编码器, 输入多尺度图像。其次, MIOC-UNet 的单个解码器输出多个不同尺度的去雾图像, 用单一的 U-Net^[16]网络模拟多级联 U-Net 网络。再次, 引入非对称特征融合模块, 有效地合并多尺度特征。最后, 与传统的 U-Net 跳跃连接不同, MIOC-UNet 采用了自适应特征混合 (adaptive feature mixup) 模块将浅层特征和深层特征进行动态融合, 实现特征保留。通过引入对比正则损失, 将多输出的去雾图像作为锚点, 清晰图像作为正样本, 原始有雾图像作为负样本, 输入到预训练的 VGG 网络中并计算对比正则。

1 相关技术和理论

1.1 U-Net 网络

U-Net 是一种广泛使用的深度学习架构,由 1 个编码器和 1 个解码器组成,由此搭建成一个 U 型的网络结构,在编码器入口处输入图像,并通过下采样获得图像的低维特征,再通过上采样将图像进行恢复输出。U-Net 网络还使用了跳跃连接,将上采样后的特征图和对应阶段的下采样的特征图进行连接,作为解码器的下一个子模块的输入,为图像恢复提供多尺度多层次的信息,即通过融合深层语义信息和浅层特征细节,避免了在编解码过程中图像局部细节的丢失。本文采用类 U-Net 结构,通过单编码器实现多输入多输出,通过融合不同尺度的特征信息,提高去雾性能。

1.2 残差特征注意力模块

卷积神经网络的每一层分别对应提取不同层

次的特征信息,从浅层的特征逐渐提取到深层抽象特征,进而提高网络特征的表达能力。然而当神经网络达到一定深度后,网络性能会陷入一个瓶颈,难以提升,随着网络的继续加深,网络在测试集上的性能反而下降,出现网络退化问题。He 等^[17]提出残差网络可以解决网络退化问题,即通过恒等映射的方式,可以让网络随着深度的增加而不退化。以往的去雾网络对通道和像素赋予了相同的处理权重,未能有效地处理加权通道和雾浓度分布不均匀的图像^[18]。因此,本文在局部残差模块中引入了特征注意力,赋予重要通道信息更高的权重进而提高网络对浓雾像素区域的关注。

2 网络模型

本文提出的 MIOC-UNet 去雾网络模型整体框架如图 1 所示。




图 1 MIOC-UNet 框架

Fig. 1 MIOC-UNet framework

本文受文献 [19] 的启发,构建了一个多输入多输出的单编码器。编码器模块 (encoder module, EM) 包含 1 个 3×3 卷积层和 1 个残差特征注意力 (residual feature attention, RFA) 模块。将分辨率大小为 $256 \text{ 像素} \times 256 \text{ 像素}$ 的有雾图像 I_1 输入到 RFA 模块中提取特征,然后下采样到不同层级的 EM_k 中提取更低维度的特征。为了能让不同比例的有雾图像 (I_2, I_3) 输入到网络中,使用预处理卷积模块 (preprocessed convolution module, PCM) 对 I_2 和 I_3 进行预编码。PCM_k 由 1 个 3×3 卷积和 2 个

1×1 卷积进行浅层特征的提取,将第 2 层 1×1 卷积的特征输出与 I_k 进行特征拼接,再用 1 个 1×1 卷积层进一步细化特征输出为 O_k^{PCM} ,然后将 O_k^{PCM} 与 O_{k-1}^{EM} 输出特征送入多特征融合 (multi-feature fusion, MFF) 模块,在 MFF_k 进行融合。通过利用缩小后的特征和从下采样图像中获得特征的互补信息, RFA 模块可以有效地处理各种有雾图像。为了能让 EM_k 中 3 个不同层级大小的特征图融合,将 O_k^{EM} 通过上采样或下采样后送入到非对称特征融合 (asymmetric feature fusion, AFF) 模块

中融合非对称特征, 随后将 O_k^{AFF} 与 O_{k+1}^{DM} 拼接, 输入到解码器模块 (decoder module, DM) 中, 经过 1 层步长为 1 的 3×3 卷积后输出 O_k^{DM} 。随后将 O_k^{DM} 与 I_k 通过自适应混合 Mixup 操作后, O_k^{Mixup} 即为得到的去雾图像 O_k 。

2.1 局部残差特征注意力模块

有雾图像被输入到一个浅层特征提取部分, 即先经过 1 个 3×3 卷积, 然后被送入局部残差特征注意力模块中, 局部残差可以通过学习多个局部残差连接, 减少薄雾或低频等非主要信息的干扰。每个通道的特征都有其独特的权重信息, 而有雾图像也存在雾浓度的空间变化问题。因此, 为了让局部残差块提高对重要通道和浓雾像素的敏感度, 在每个残差块后加入特征注意力模块^[12]。RFA 模块由 8 个残差特征注意力块组成。残差特征注意力块如图 2 所示。




图 2 残差特征注意力块
Fig. 2 Residual feature attention block

从图 2 可以清晰地看出, 残差注意力块由 2 个 3×3 卷积和特征注意力组成。特征注意力由通道注意力子模块和像素注意力子模块组成。

2.1.1 通道注意力子模块

通道注意力 (channel attention, CA) 包含 1 个自适应全局平均池化层、2 个 1×1 卷积层、1 个 ReLU 激活函数和 1 个 Sigmoid 激活函数。由 DCP 理论^[3]可以得出, CA 主要关注不同通道的特征, 使得这些特征具有完全不同的加权信息, 即根据不同通道的特征重要程度学习权重, 重新加权通道特征以增强不同特征图的一致性。首先, 通过使用全局平均池化压缩空间信息, 通过收缩特征图的空间维度 $H \times W$ 来生成统计量 g , 从而 g 的第 c 个元素的计算公式为

$$g_c = H_p(F_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W X_c(i, j)$$

式中: $X_c(i, j)$ 为第 c 个通道 X_c 在位置 (i, j) 处的值, $H_p(\cdot)$ 为全局池化函数, F_c 为输入第 c 个通道的特征图, g_c 为输出第 c 个通道的特征图。特征图大小

由 $C \times H \times W$ 经自适应全局平均池化变为 $C \times 1 \times 1$, 将全局空间信息纳入通道描述符中, 使得网络更加关注全局空间信息。为了得到不同通道的权重, 特征经过 2 个 1×1 卷积层、ReLU 激活函数和 Sigmoid 激活函数, 计算公式为

$$W_{CA} = \sigma(\text{Conv}(\delta(\text{Conv}(g_c))))$$

式中: $\sigma(\cdot)$ 为 Sigmoid 激活函数, $\delta(\cdot)$ 为 ReLU 激活函数。最后通过逐元素乘法运算将通道 CA 的权值和输入特征图 F_c 组合以生成特征图, 计算公式为

$$F_c^* = W_{CA} \otimes F_c \quad (1)$$

式中 F_c^* 为 CA 输出的特征图。由式 (1) 可以看出, F_c^* 不再平等地处理有雾图像中的通道特征。

2.1.2 像素注意力子模块

由于有雾图像的薄雾区域和浓雾区域的像素权重不同, 而像素注意力 (pix attention, PA) 可以使网络更加关注像素级特征信息, 如厚雾像素和低频图像区域。与 CA 类似, PA 直接将 F^* 输入到 2 个具有 ReLU 激活函数和 Sigmoid 激活函数的卷积层中, 特征图形状由 $C \times H \times W$ 变为 $1 \times H \times W$, 其计算公式为

$$W_{PA} = \sigma(\text{Conv}(\delta(\text{Conv}(F^*))))$$

最后, 将输入 F^* 和 PA 的元素相乘, 其计算公式为

$$\tilde{F} = F^* \otimes W_{PA} \quad (2)$$

式中 \tilde{F} 为 PA 输出的特征图。由式 (2) 可以看出, \tilde{F} 不再平等地处理有雾图像中像素特征。

2.2 预处理卷积模块与多特征融合模块

为了让不同尺寸的有雾图像能够通过单编码器参与到网络信息流中, 通过预处理卷积模块 PCM_k 从输入图像 I_k 中提取浅层特征。PCM_k 如图 3 所示。 I_k 通过步长皆为 1 的 3×3 卷积和 1×1 卷积操作后, 卷积输出与 I_k 输入进行拼接, 再通过 1 个步长为 1 的 1×1 卷积输出 O_k^{PCM} 。




图 3 PCM 结构
Fig. 3 PCM structure

O_k^{PCM} 与 O_k^{EM} 通过 MFF_k 模块进行特征融合, 其中 O_k^{EM} 表示 O_k^{EM} 的下采样输出。MFF_k 模块如图 4 所示。 O_k^{PCM} 与 O_k^{EM} 相乘后输入到 1 个 3×3 卷积中, 再将 3×3 卷积输出与 O_k^{EM} 进行相加, 得到输出 O_k^{MFF} 。




图 4 MFF 模块

Fig. 4 MFF module

2.3 非对称特征融合模块

细粒度子网络更关注局部细节信息,粗粒度子网络则更关注全局语义信息,有效整合不同粒度特征信息,融合非对称不同尺度特征有利于提高去雾图像的质量。为了能在单个编码器中融合非对称尺度的特征,引入非对称特征融合模块。

AFF 模块将所有的 RFA 模块的输出作为输入, O_k^{EM} 通过上采样与下采样恢复对应层级的尺寸,并将 3 个相同尺寸的特征进行拼接,然后使用 1 个 1×1 卷积和 1 个 3×3 卷积融合多尺度特征, O_k^{AFF} 与 O_{k+1}^{DM} 进行拼接, O_{k+1}^{DM} 表示为 O_{k+1}^{DM} 的上采样输出,随后将拼接后的输出送到 DM_k 中。AFF 模块如图 5 所示。




图 5 AFF 模块

Fig. 5 AFF module

通过非对称特征的融合,去雾网络可以有效地利用不同粒度的特征信息,提高局部细节纹理的恢复效果,提升图像去雾性能。

2.4 自适应融合操作

低级特征可以在卷积神经网络的浅层中提取,能够获得更多的细粒度特征信息。但随着网络深度的增加,浅层特征会逐渐退化。来自上采样层和下采样层的特征之间缺少连接,这容易导致浅层特征(如边缘和轮廓)丢失。为避免在编解码的过程中图像局部细节的丢失,与传统 U-Net 采用跳跃连接产生新的特征不同,本文受文献 [20] 启发,引入自适应混合 Mixup 操作 [13],考虑到 3 个不同尺度之间的输入与输出之间的跨层连接混合相加,采取加权融合的方式进行混合相加。融合的权重是由参数学习得到的,权重的取值采用 Sigmoid 函数转换到 (0,1) 区间。Mixup 操作的输出公式为

$O_k^{\text{Mixup}} = \text{Mix}(I_k, O_k^{\text{DM}}) = \sigma(\theta_k) \times I_k + (1 - \sigma(\theta_k)) \times O_k^{\text{DM}}$
式中: O_k^{Mixup} 为最终输出; $\sigma(\theta_k)$, $k = 1, 2, 3$ 是第 k 个可学习因子,用于融合第 i 层级,其值由参数 θ_k 上的

Sigmoid 函数 $\sigma(\cdot)$ 决定。

2.5 损失函数

2.5.1 对比正则损失函数

在深度学习中,对比学习因其可以利用大量、易获取的无标注数据增强神经网络模型的特征表达能力,近年来得到了学术界的广泛关注 [21]。对比学习本质是在拉近同类图像的特征之间的距离、推远不同类图像之间的距离,以获得更好的特征提取模型。

本文引入对比正则化损失函数 [13] 来生成更好的去雾图像,与感知损失 [22] 不同的是,对比正则还推离锚与负样本的距离。对比正则化损失对每个输出进行监督,组成对比正则联合损失,共同训练去雾网络。具体而言,通过构造“正对”和“负对”,即将去雾图像作为锚,清晰图像作为正样本,有雾图像作为负样本;“正对”由锚与正样本组成,“负对”由锚与负样本组成;通过找到“正对”与“负对”潜在的特征空间进行对比。潜在特征空间从相同的固定预训练 VGG-19 模型中选取 5 个公共隐藏层权重,然后分别计算“正对”与“负对”经过隐藏层得到的特征图的差异,拉近去雾图像与清晰图像的距离,推离与有雾图像的距离。对比正则损失函数公式可以表示为

$$L_c = \alpha \sum_{i=0}^k \sum_{j=1}^n \beta_j \frac{D_i(G_j(J), G_j(\phi(I, \omega)))}{D_i(G_j(I), G_j(\phi(I, \omega))) + \varepsilon}$$

式中: I 为有雾图像, J 为无雾图像, $\phi(I, \omega)$ 为去雾图像, $\phi(\cdot, \omega)$ 为带 ω 参数的去雾网络。 G_j , $j = 1, 2, 3, 4, 5$ 为从固定预训练模型 VGG-19 中提取的第 j 个潜在特征; D_i , $i = 1, 2, 3$ 为 i 层网络; ε 为防止除零设置的超参数,值为 1×10^{-7} ; β_j , $j = 1, 2, 3, 4, 5$ 为权重系数,取值为 $1/32, 1/16, 1/8, 1/4, 1$ 。

2.5.2 重构损失函数

除对比正则化损失函数以外,本文还采用 L1 损失作为去雾图像与清晰图像之间的重构损失。L1 损失函数 L_1 的计算公式为

$$L_1 = \sum_{i=1}^n \|J_i - \phi(I_i, \omega_i)\|$$

式中: J_i , $i = 1, 2, 3$ 表示第 i 层尺寸的无雾图像; $\phi(I_i, \omega_i)$ 表示为第 i 层输出的去雾图像。

最后,总体损失函数 L 定义为

$$L = \alpha L_c + L_1$$

式中 α 为对比正则损失的权重。

3 实验结果及分析

3.1 数据集

本文选用图像去雾领域应用广泛的 RESIDE [23]

数据集中室外训练集 (outdoor training set, OTS) 对网络进行训练, 使用合成客观数据集 (synthetic objective testing set, SOTS) 对网络进行测试。OTS 总共包含 8 970 幅清晰图像及其生成的 313 950 幅合成雾图像。SOTS 包含 500 幅室外有雾图像。此外, 为了进一步测试模型的有效性与鲁棒性, 选用非均匀雾质真实数据 NH-HAZE^[24] 和 NTIRE21^[25] 数据集进行定性和定量分析, 其中 NH-HAZE 包含 55 对户外场景雾图, NTIRE21 为 NH-HAZE 的扩充, 其中 20 对户外场景雾图作为训练集, 5 对为测试集。

3.2 实验设置与评价指标

本实验使用操作系统为 Ubuntu 18.04.6 LTS, GPU 为 Tesla V100, CUDA 为 11.6, 深度学习框架为 PyTorch, 版本为 1.10.1。本文将所有图像都随机剪切成大小为 256 像素×256 像素的图像块用于训练。将初始学习率设置为 1×10^{-4} , 使用余弦退火策略^[26] 来调整学习率, batch size 设置为 4, 使用 Adam 优化器来优化模型参数, 其中 $\beta_1 = 0.9$, $\beta_2 = 0.999$, 对比正则损失权重 $\alpha = 0.1$ 。

为了客观评价图像去雾效果, 本文选取峰值信噪比 (peak signal to noise ratio, PSNR) 和结构相似度指数 (structural similarity index, SSIM) 对实验结果进行定量分析。PSNR 是通过计算对应像素点之间的误差来判断图像之间的差异, 其值越高表示失真越小, 图像与原图之间越相似; SSIM 是将感知误差的度量转移到对感知结构失真的度量, 其值越大, 代表图像去雾效果越好。

3.3 实验结果及分析

本文将从合成雾数据集与真实雾数据集上对

所提出的方法与目前流行的去雾方法进行定性和定量比较。对比方法包括基于大气散射模型的 DCP^[3]; 基于大气散射模型的深度学习方法 AOD-Net^[8]; 基于端到端的深度学习方法, 包括 GCA-Net^[11]、FFA-Net^[12]、MSBDN^[27]。所有方法均采用相同环境进行训练及验证。

3.3.1 基于合成雾数据集的对比与分析

将上述对比算法与本文提出的模型在 OTS 数据集上进行训练, 在 SOTS 进行测试, 测试结果如表 1 所示。从表 1 中可以看出, 与对比算法相比, 本文提出的模型实现了最佳的性能指标, PSNR 为 34.20 dB, SSIM 为 0.986 5。与性能次优的 MSBDN 模型相比, 在 SOTS 数据集上 PSNR 提高了 0.52 dB, SSIM 提升了 0.004 4。证明了本文提出的模型在去雾性能上优于对比方法。

表 1 各算法在 SOTS 数据集上的定量对比

Table 1 Quantitative comparison of each algorithm on SOTS dataset

算法	PSNR/dB	SSIM
DCP	19.14	0.861 0
AOD-Net	24.33	0.927 7
GCA-Net	31.66	0.972 8
FFA-Net	33.41	0.984 1
MSBDN	33.68	0.982 1
本文模型	34.20	0.986 5

为进一步验证本文提出的模型对合成雾图像的有效性, 图 6 给出了本文模型与对比去雾算法比较的可视化结果。




图 6 SOTS 数据集上的定性评估

Fig. 6 Qualitative evaluation on the SOTS dataset

观察图 6 可知, DCP 由于其对先验信息的依赖而导致对颜色的严重失真; AOD-Net 对图像局

部细节的雾不能完全去除, 这是因为其倾向于生成暗图像; GCA-Net 对颜色的恢复产生严重偏

移,对纹理、边缘的恢复有所不足;而 FFA-Net 与 MSBDN 模型整体去雾效果良好,但仍存在边界模糊的视觉问题;相比以上方法,本文提出的模型在视觉效果上进一步得到了改善,在恢复图像细节和恢复色彩上更加接近真实的无雾图像。

3.3.2 基于真实雾数据集的对比与分析

为了验证本文模型在真实世界有雾图像上的

有效性和适应性,将本文模型与对比方法在 2 个真实数据集 NH-HAZE 与 NTIRE21 上作定量与定性比较。表 2 给出了定量比较实验结果。从表 2 可以得出,在 NH-HAZE 数据集上,与对比算法相比,本文提出的模型在 PSNR 指标上最高,与次优的 MSBDN 相比,提高了 0.32 dB;而在 SSIM 指标上处于次优,与 FFA-Net 相比仅低 0.000 6。

表 2 各算法在真实数据集上的定量对比
Table 2 Quantitative comparison of each algorithm on real datasets

算法	NH-HAZE		NTIRE21	
	PSNR/dB	SSIM	PSNR/dB	SSIM
DCP	12.29	0.411 3	11.30	0.605 1
AOD-Net	14.49	0.584 4	15.43	0.671 1
GCA-Net	17.11	0.635 2	17.33	0.721 5
FFA-Net	18.26	0.666 0	19.80	0.814 9
MSBDN	18.33	0.650 9	19.12	0.752 6
本文模型	18.65	0.665 4	21.16	0.822 0

在 NTIRE21 数据集上,与对比算法相比,本文模型在 PSNR 指标和 SSIM 指标上均为最高,相比次优的 FFA-Net, PSNR 值提高了 1.36 dB, SSIM 值提高了 0.007 1。与 RESIDE 数据集相比, NH-HAZE 真实数据集与 NTIRE21 真实数据集样本极少,网络模型训练难度大,且为非均匀密集团雾,所以在该类数据集上指标普遍偏低。以上对真实数据集的客观指标进一步证明了本文模型的有效性。

将提出的模型与对比方法在真实去雾图像的可视化质量上进行了定性的比较。针对 NH-HAZE 数据集的定性评估如图 7 所示。基于物理先验

的 DCP 和依赖大气模型的深度神经网络 AOD-Net 去雾功能几乎失效,且经 DCP 去雾操作后的图片出现严重的颜色失真,整体色彩偏蓝。GCA-Net 对密集雾的去雾效果几乎无效,且容易出现伪影现象。FFA-Net 去雾之后对细节的颜色恢复失效,且对浓雾的去雾效果欠佳。MSBDN 方法去雾不彻底,存在细节丢失的问题。相比以上算法,本文模型仅在局部区域存在少量雾残留,但整体去雾效果良好,在细节纹理恢复上有更好的表现,且无明显偏色问题,去雾图像基本能够保持较好的视觉效果。




图 7 NH-HAZE 数据集上的定性评估

Fig. 7 Qualitative evaluation on the NH-HAZE dataset

针对 NTIRE21 数据集的定性评估如图 8 所示。DCP 和 AOD-Net 同样对非均匀团雾失效。GCA-

Net 在稠密雾中效果不佳,且去雾图像存在严重颜色失真现象。FFA-Net 和 MSBDN 虽然比上述

方法有着更好的去雾效果,但仍存在明显的视觉问题,例如对比度偏低和边界模糊等。本文模型在

去雾图像的视觉效果上,色彩恢复最接近无雾图像,对细节的恢复也相比上述算法有着更好的效果。



(a) 有雾图像 (b) DCP (c) AOD-Net (d) GCA-Net (e) FFA-Net (f) MSBDN (g) 本文模型 (h) 无雾图像

图 8 NTIRE21 数据集上的定性评估

Fig. 8 Qualitative evaluation on the NTIRE21 dataset

4 结束语

本文提出了一种基于粗到细的多尺度单幅图像去雾方法,由单编码器-解码器构成。编码器通过输入多尺度图像并组合来自不同层级的特征,将 RFA 模块作为特征提取模块,不仅使去雾网络有更深的网络结构,而且引入特征注意力使得网络更加关注雾图中的重要通道和像素区域。采用非对称特征融合模块,使不同层级的信息流互相融合。通过将浅层信息与深层信息的自适应混合,在对图像进行去雾的同时,更好地保留了图像的细节纹理信息。编码器是多输入的同时,解码器输出多尺度去雾图像,并计算它们与负样本的对比正则损失,联合 L1 损失使得去雾图像更接近无雾图像,相较于对比算法,拥有更好的去雾效果。如何针对小样本非均匀雾数据集进行图像去雾将是未来研究的主要方向。

参考文献:

- [1] 王道累, 张天宇. 图像去雾算法的综述及分析 [J]. 图学学报, 2020, 41(6): 861–870.
WANG Daolei, ZHANG Tianyu. Review and analysis of image defogging algorithm[J]. Journal of graphics, 2020, 41(6): 861–870.
- [2] NARASIMHAN S G, NAYAR S K. Vision and the atmosphere[J]. International journal of computer vision, 2002, 48(3): 233–254.
- [3] HE Kaiming, SUN Jian, TANG Xiaoou. Single image haze removal using dark channel prior[J]. IEEE transactions on pattern analysis and machine intelligence, 2011, 33(12): 2341–2353.
- [4] 张世辉, 路佳琪, 宋丹丹, 等. 基于多尺度特征结合细节

恢复的单幅图像去雾方法 [J]. 电子与信息学报, 2022, 44(11): 3967–3976.

ZHANG Shihui, LU Jiaqi, SONG Dandan, et al. Single image dehazing method based on multi-scale features combined with detail recovery[J]. Journal of electronics & information technology, 2022, 44(11): 3967–3976.

- [5] ZHU Qingsong, MAI Jiaming, SHAO Ling. A fast single image haze removal algorithm using color attenuation prior[J]. IEEE transactions on image processing, 2015, 24(11): 3522–3533.
- [6] 王科平, 杨艺, 费树岷. 雾霾图像清晰化算法综述 [J]. 智能系统学报, 2023, 18(2): 217–230.
WANG Keping, YANG Yi, FEI Shumin. Review of hazy image sharpening methods[J]. CAAI transactions on intelligent systems, 2023, 18(2): 217–230.
- [7] CAI Bolun, XU Xiangmin, JIA Kui, 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] LI Boyi, PENG Xiulian, WANG Zhangyang, et al. AOD-net: all-in-one dehazing network[C]//2017 IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 4780–4788.
- [9] REN Wenqi, LIU Si, ZHANG Hua, et al. Single image dehazing via multi-scale convolutional neural networks[C]//European Conference on Computer Vision. Cham: Springer, 2016: 154–169.
- [10] CHEN Dongdong, HE Mingming, FAN Qingnan, et al. Gated context aggregation network for image dehazing and deraining[C]//2019 IEEE Winter Conference on Applications of Computer Vision. Waikoloa: IEEE, 2019: 1375–1383.
- [11] QU Yanyun, CHEN Yizi, HUANG Jingying, et al. Enhanced pix2pix dehazing network[C]//2019 IEEE/CVF

- Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019: 8152–8160.
- [12] QIN Xu, WANG Zhilin, BAI Yuanchao, et al. FFA-net: feature fusion attention network for single image dehazing[J]. *Proceedings of the AAAI conference on artificial intelligence*, 2020, 34(7): 11908–11915.
- [13] WU Haiyan, QU Yanyun, LIN Shaohui, et al. Contrastive learning for compact single image dehazing[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville: IEEE, 2021: 10546–10555.
- [14] 高峰, 汲胜昌, 郭洁, 等. 采用对比学习的多阶段 Transformer 图像去雾方法 [J]. *西安交通大学学报*, 2023, 57(1): 195–210.
- GAO Feng, JI Shengchang, GUO Jie, et al. A multi-stage transformer network for image dehazing based on contrastive learning[J]. *Journal of Xi'an Jiaotong University*, 2023, 57(1): 195–210.
- [15] ZHANG Hongguang, DAI Yuchao, LI Hongdong, et al. Deep stacked hierarchical multi-patch network for image deblurring[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019: 5971–5979.
- [16] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[M]//Lecture Notes in Computer Science. Cham: Springer, 2015: 234–241.
- [17] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770–778.
- [18] 范新南, 赵忠鑫, 严炜, 等. 结合注意力机制的多尺度特征融合图像去雾算法 [J]. *计算机科学*, 2022, 49(5): 50–57.
- FAN Xinnan, ZHAO Zhongxin, YAN Wei, et al. Multi-scale feature fusion image dehazing algorithm combined with attention mechanism[J]. *Computer science*, 2022, 49(5): 50–57.
- [19] CHO S J, JI S W, HONG J P, et al. Rethinking coarse-to-fine approach in single image deblurring[C]//2021 IEEE/CVF International Conference on Computer Vision. Montreal: IEEE, 2021: 4621–4630.
- [20] ZHANG Hongyi, CISSE M, DAUPHIN Y N, et al. Mixup: beyond empirical risk minimization[EB/OL]. (2017–10–25)[2023–05–05]. <https://arxiv.org/abs/1710.09412>.
- [21] 张重生, 陈杰, 李岐龙, 等. 深度对比学习综述 [J]. *自动化学报*, 2023, 49(1): 15–39.
- ZHANG Chongsheng, CHEN Jie, LI Qilong, et al. Deep contrastive learning: a survey[J]. *Acta automatica sinica*, 2023, 49(1): 15–39.
- [22] LEDIG C, THEIS L, HUSZÁR F, et al. Photo-realistic single image super-resolution using a generative adversarial network[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 105–114.
- [23] LI Boyi, REN Wenqi, FU Dengpan, et al. Benchmarking single-image dehazing and beyond[J]. *IEEE transactions on image processing*, 2019, 28(1): 492–505.
- [24] ANCUTI C O, ANCUTI C, TIMOFTE R. NH-HAZE: an image dehazing benchmark with non-homogeneous hazy and haze-free images[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Seattle: IEEE, 2020: 1798–1805.
- [25] ANCUTI C O, ANCUTI C, VASLUIANU F A, et al. NTIRE 2021 NonHomogeneous dehazing challenge report[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Nashville: IEEE, 2021: 627–646.
- [26] HE Tong, ZHANG Zhi, ZHANG Hang, et al. Bag of tricks for image classification with convolutional neural networks[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019: 558–567.
- [27] DONG Hang, PAN Jinshan, XIANG Lei, et al. Multi-scale boosted dehazing network with dense feature fusion [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 2154–2164.

作者简介:



王德文, 副教授, 主要研究方向为人工智能、图像处理。主持或参与国家自然科学基金项目 4 项, 获河北省科技进步奖 3 项, 以第一完成人获得国家专利授权 3 项, 发表学术论文 50 余篇。E-mail: wdewen@gmail.com。



陈威, 硕士研究生, 主要研究方向为人工智能、图像处理。E-mail: 644691154@qq.com。



苏攀, 副教授, 博士, 主要研究方向为机器学习、模糊系统、图像处理。E-mail: supan@ncepu.edu.cn。