

基于多残差和多重特征融合的去雾算法^{*}

武丽^{1,2} 俞俊² 张征浩² 葛彩成²

(1. 无锡学院电子信息工程学院 无锡 214000; 2. 南京信息工程大学电子与信息工程学院 南京 210000)

摘要:针对目前大多数图像去雾算法由于细节丢失导致去雾后的图像颜色失真,雾霾残留以及纹理细节模糊等问题,提出一种基于多残差和多重特征融合端到端去雾算法。首先通过设计浅层特征提取模块,为深层网络提高丰富信息的特征图;其次设计多残差级联模块,提取多层次特征,帮助模型学习更加复杂的特征表示;然后设计局部-全局特征融合模块,捕获从最细微到最广泛的特征;最后设计结合残差注意力的跨层特征融合模块,避免上下采样后的细节缺失,更好地提取图像中的局部与全局信息特征。实验结果表明,所提算法在 SOTS 室内、室外测试集上峰值信噪比(PSNR)分别取得了 33.12、31.07 dB,结构相似性(SSIM)分别取得 0.986、0.983,与当前大多数主流算法相比得到了明显的提升,且在合成雾图像和真实雾霾图像均取得了不错的去雾效果,复原图像细节更加清晰,更符合人类视觉感知。

关键词:图像去雾;深度学习;编解码器;残差结构;特征融合

中图分类号: TP391.41 **文献标识码:** A **国家标准学科分类代码:** 510.4050

Fog removal algorithm based on multiple residuals and multiple feature fusion

Wu Li^{1,2} Yu Jun² Zhang Zhenghao² Ge Caicheng²

(1. School of Electronic Information Engineering, Wuxi University, Wuxi 214000, China; 2. School of Electronics and Information Engineering, Nanjing University of Information Science and Technology, Nanjing 210000, China)

Abstract: To address the common issues in most existing image dehazing algorithms, such as color distortion, haze residue, and blurring of texture details due to the loss of fine details, a new end-to-end dehazing algorithm based on multi-residual and multi-feature fusion is proposed. Initially, a shallow feature extraction module is designed to provide the deep network with feature maps rich in information. Subsequently, a multi-residual cascading module is constructed to extract multi-level features, assisting the model in learning more complex feature representations. Furthermore, a local-global feature fusion module is introduced to capture features ranging from the most subtle to the most extensive. Finally, a cross-layer feature fusion module, combined with residual attention, is designed to prevent the loss of details after upsampling and downsampling, thus better extracting local and global information features from the image. Experimental results show that the proposed algorithm achieves peak signal-to-noise ratio (PSNR) of 33.12 and 31.07 dB, and structural similarity (SSIM) of 0.986 and 0.983, respectively, on indoor and outdoor SOTS test sets, which is significantly improved compared with most current mainstream algorithms. Moreover, the fog removal effect is good in both the synthetic fog image and the real haze image, and the details of the restored image are clearer and more in line with human visual perception.

Keywords: image defogging; deep learning; codec; residual structure; feature fusion

0 引言

在雾霾天气下,空气中悬浮着大量微小颗粒物和液

滴,这些颗粒物会导致空气浑浊,视线受阻,从而使拍摄的图像出现模糊、对比度降低和颜色失真^[1],降低了其在图像分类^[2]、目标检测^[3]等计算机视觉任务中的应用价值。

收稿日期:2024-01-07

^{*} 基金项目:国家青年自然科学基金(62106111)、2021年第二批产学研合作协同育人项目(202102563020)资助

图像去雾不仅对于提升图像的视觉效果至关重要,更在实际应用中发挥着重要作用,例如在交通监控、无人驾驶、户外机器人导航和遥感成像等领域。因此,图像去雾作为计算机视觉领域的基本问题之一,具有重要的应用价值而备受关注^[4]。

图像去雾算法可以分为基于先验信息的去雾算法和基于深度学习的去雾算法^[5]。基于先验信息的去雾算法主要是基于大气散射模型,试图通过估算环境光和散射参数来恢复无雾图像。在这种算法中,最为经典的就是 He 等^[6]提出的暗通道先验方法,基于自然景观图像中非天空区域至少有一个颜色通道具有较低亮度,从而利用估计的大气光和透射图来去雾。Zhu 等^[7]提出颜色衰减先验算法,通过分析图像中的颜色特性,估计透射图与大气光,从而重建无雾图像。黎楚萍等^[8]设计了一种基于先验知识的三阶段单幅图像去雨雾框架,利用暗通道先验知识对图像低频部分去雾,再引入条件生成对抗网络对图像细节精细化修复。

近年来,随着计算能力显著增强和专门的去雾数据集的建立,基于深度学习的去雾方法逐渐成为主流^[9]。基于深度学习的去雾算法主要分成两类。第1类基于大气散射模型,利用深度学习来学习并生成透射图,估计大气光值,利用这些信息通过大气散射模型实现去雾。最为经典的就是 Li 等^[10]提出的一体化去雾算法(all-in-one dehazing network, AOD-Net),通过优化大气散射模型直接生成去雾图像,Zhang 等^[11]提出了一种基于密集连接金字塔网络的去雾方法,利用生成对抗网络对大气光值与透射率进行更为准确的估计从而得到清晰图像。但这类算法还是依赖大气散射模型。第2类就是基于深度学习的端到端去雾算法。Chen 等^[12]提出一种门控上下文聚合网络(gated context attention network, GCA-Net),使用平滑空洞卷积去除网格伪影,并使用门控网络融合不同级别特征进行图像去雾。Qu 等^[13]提出一种增强型去雾网络(enhanced pix2pix dehazing network, EPDN),利用生成对抗网络架构改进,多分辨率生成器进行特征提取,增强模块来恢复图像细节,多尺度判别器来鉴别去雾结果。Liu 等^[14]提出了 GridDehazeNet 网络结构,利用其独特网格结构和多尺度特征融合来实现底层与高层特征融合,取得良好的去雾效果。Dong 等^[15]提出一种基于 U-Net 架构在网络初级阶段,图像经过 SFEM 进行浅层特征提取,为深层网络提高丰富信息的特征图,在进行下采样的同时,经过 MRCM 帮助模型提取多层次特征,更好学习图像信息,在网络的深层部分,通过 LGFFM 有效地捕获从最细微到最广泛的特征,并保持原始特征信息的同时提升特征的表达能力。通过 RACLFFM 将下采样的特征层与上采样同样大小的特征层进行融合,避免上下采样后的细节缺失,更好地提取图像中的局部与全局信息特征,最后通过残差连接,将原始的输入图像与进过网络输出的图像,得

的去雾网络(multi-scale boosted dehazing network, MS-BDN),利用反向投影技术设计密集特征融合模块、高效的特征融合策略以及增强模块来恢复细节和颜色,提升去雾效果。Qin 等^[16]提出一种端到端的特征融合注意力网络,用于直接恢复无雾图像。Zheng 等^[17]提出一种超分辨率图像去雾模型,先在低分辨率图像上通过特征提取重建双边系数,再利用回归的仿射双边网格,在全分辨率特征的指导下生成高质量的特征图。Li 等^[18]提出了一种无监督且未经训练的单图像去雾神经网络,实现了在无需成对的清晰-雾图像训练数据的情况下,仅使用观察到的雾图像本身进行去雾处理。该算法虽说提出了一种新颖的无监督^[19]和未训练的单图像去雾方法,但去雾效果不理想,对浓雾去除不太好。

综上所述,目前图像去雾领域仍具有如下挑战:1)对于编码-解码结构的去雾算法,多次使用下采样导致图像细节信息的丢失,影响图像细节的恢复;2)有些去雾算法没有充分利用原始图像信息和上下文信息,多尺度特征,导致感受野不足,导致细节丢失严重,去雾不彻底,图像不清晰。

针对上述问题,本文提出基于多残差和多重特征融合的端到端图像去雾算法。首先设计浅层特征提取模块,为深层网络提高丰富信息的特征图,设计多残差级联模块帮助模型提取多层次特征,帮助模型学习更加复杂的特征表示,设计局部-全局特征融合模块,结合残差注意力的跨层特征融合模块这两个特征融合模块帮助模型有效地捕获从最细微到最广泛的特征,避免上下采样后的细节缺失,更好地提取图像中的局部与全局上下文信息特征。实验表明,去雾效果较为真实,细节恢复较好,去雾效果好。

1 本文模型

本文介绍的去雾算法网络结构如图1所示,类似于 U-Net 这样的编解码网络,主要由浅层特征提取模块(shallow feature extraction module, SFEM),多残差级联模块(multi-residual cascading module, MRCM),局部-全局特征融合模块(local-global feature fusion module, LGFFM),结合残差注意力的跨层特征融合模块(residual attention cross-layer feature fusion module, RACLFFM)构成多级去雾网络。

到最终的复原图像。

1.1 浅层特征提取模块

图像在去雾时,浅层特征提取模块起着至关重要的作用。为了给深层网络提供信息丰富的特征图,设计了一个基于 Inception^[20]架构的浅层特征提取模块,用于在去雾过程前提取图像的特征。它通过不同大小的卷积核来捕获图像中的各种空间信息,从而提供一个全面的特征映射,这对于后续的去雾处理至关重要。

这个浅层特征提取模块包含3个并行的卷积路径

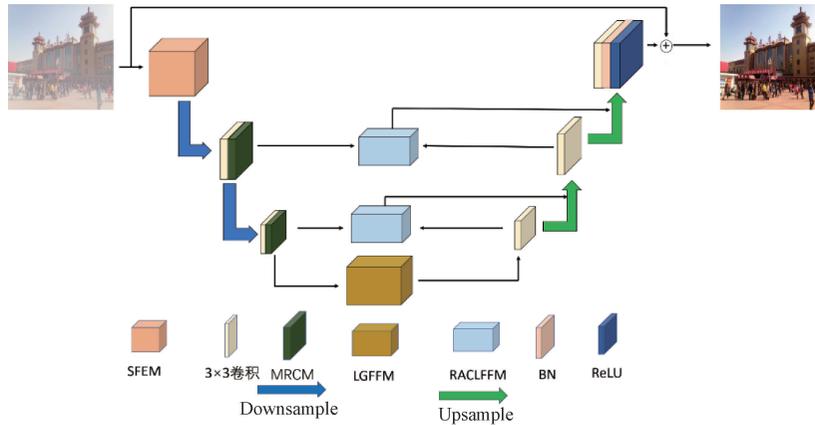


图1 网络结构

Fig. 1 Network structure diagram

(图2),分别采用 1×1 、 3×3 和 5×5 的卷积核。 1×1 、 3×3 和 5×5 的卷积层捕获不同大小的感受野,学习不同尺度的特征,使得模块能够捕捉从细粒度到粗略的空间特征,增加网络的非线性,有助于模型捕捉更复杂的特征。每个卷积操作后都跟随着一个 ReLU 激活函数,为特征提取过程增加了非线性,有助于模型学习复杂的模式。卷积后的特征图通过 concat 结合在一起,随后,一个 1×1 的卷

积层再次对特征进行整合,同时引入批量归一化(batch normalization, BN)和 ReLU 激活函数,进一步增强模型的泛化能力,并加速训练过程。其浅层特征提取模块网络可以表达为:

$$F(x) = \text{ReLU}\{\text{BN}\{\text{Conv}(1\times 1) \{ \text{concat}\{\text{ReLU}[\text{Conv}(1\times 1)] + \text{ReLU}[\text{Conv}(3\times 3)] + \text{ReLU}[\text{Conv}(5\times 5)]\}\}\}\} \quad (1)$$

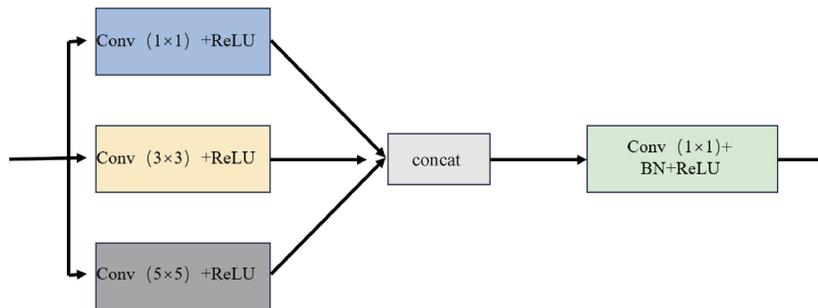


图2 浅层特征提取模块

Fig. 2 Shallow feature extraction module

这个浅层特征提取模块作为去雾模型的前端,对输入图像进行初步的处理。通过浅层特征提取模块,模型能够更有效地处理复杂的去雾任务,提高去雾的质量,同时保留更多的细节,为最终的清晰图像输出打下坚实的基础。

1.2 多残差级联模块

为了加强深度神经网络的学习能力,同时帮助模型学习更加复杂的特征表示,通过参考残差连接以及 DenseNet,设计了一个 MRCM 模块(图3)。MRCM 主要由多个 CBPR 组成,CBPR 是由 3×3 卷积层,批量归一化 BN 层以及 PReLU 激活函数构成,通过使用 BN 层,有助于网络训练的稳定性,加快收敛速度,选择 PReLU 激活函数,相比于传统的 ReLU, PReLU 允许一定程度的负值激活,从而提供更灵活的特征学习能力,提高模型的适应性与性能,使模型具有较好的平滑性以及非线性表达

能力。

由图3可以看到, MRCM 包含3个并行的路径,第1个路径通过跳跃连接,直接将输入信息传到最后,从而保留原始输入信息,防止在深层中丢失信息;第2个路径主要是多个 CBPR 组成的级联残差块,每个 CBPR 的输出作为下一个 CBPR 的输入,并且在经过第1个 CBPR 后,将输出与第3个 CBPR 残差块输出相加后输出到下一个 CBPR,这样不仅有助于解决梯度消失,使深层网络进行有效学习,而且这样迭代方式使网络能够构建出更加复杂的特征表示,捕获重要的细节特征,这对与图像去雾是非常有帮助的。第3个路径通过一个最大池化 MaxPool 减少维度来增加感受野,减少了参数数量,从而帮助模型捕获不同尺度上的特征。最后3个并行输出相加,最后经过一个 CBPR 输出。通过 MRCM,来提升学习效率,提取多层

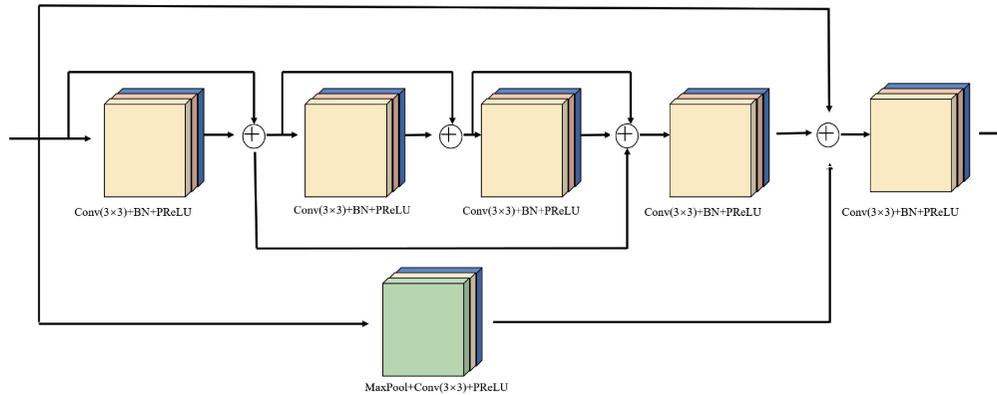


图3 多残差级联模块

Fig. 3 Multi-residual cascading module

次特征,帮助网络捕获更广泛和更深层次的信息,更好的学习图像信息,从而提升去雾效果。

1.3 局部-全局特征融合模块

由于雾通常在图像不均匀分布,会遮盖图像里的一些细节和纹理,容易在去雾过程中丢失细节边缘信息,因此

去雾算法需要能够理解和处理不同尺度的特征,同时保留关键的空间信息。针对这些问题,同时为了更好地提升去雾网络的整体特征表达能力,设计了一个LG-FFM模块(图4),它能够有效地结合局部信息和全局上下文特征。

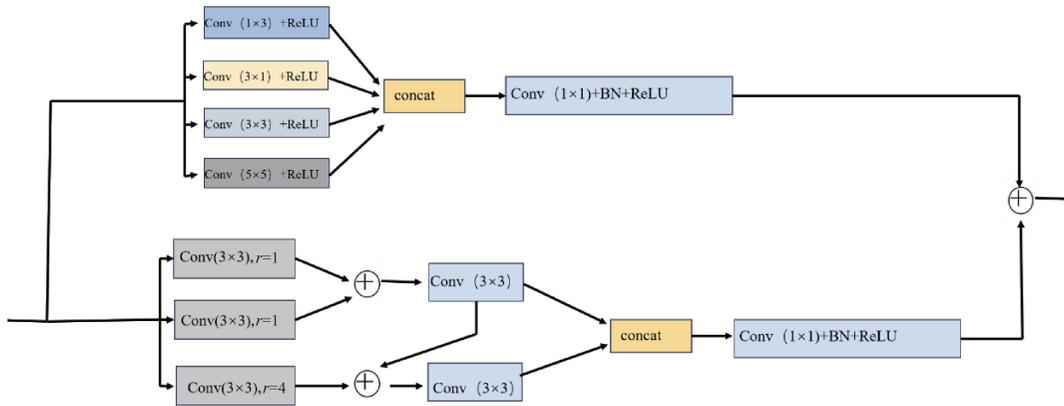


图4 局部-全局特征融合模块

Fig. 4 Local-global feature fusion module

LGFFM 主要有两个并行的小模块组成,上面模块分支主要结合了多尺度卷积,获得不同尺度的特征。为了控制模型大小减少复杂度,同时加强图像边缘、纹理等局部信息的特征提取能力,采用非对称卷积 1×3 和 3×1 。同时与 3×3 和 5×5 卷积层通过concat结合在一起,利用这不同的尺度卷积核,帮助网络捕捉丰富的特征,从局部细节到更大的空间信息。分支主要由空洞卷积构成。为了增强模型对全局上下文信息的感知能力,捕获图像多尺度上下文信息,采用3个卷积核为 3×3 ,膨胀率 r 分别为1、2、4的空洞卷积。由于空洞卷积会造成一定的网格伪影,通过在空洞卷积后面加上一层 3×3 卷积,为空洞卷积增加平滑性,减少网格伪影现象。将膨胀率为1和2先累加,实现特征的初步融合为 F_1 ,再将这个融合的特征与膨胀率为4的进一步融合为 F_2 ,再将两者进行拼接在一起,

将不同感受野的特征在通道维度上结合起来,为网络提供了一个丰富的多尺度特征表示。这种融合方法保留了各个膨胀层特有的上下文信息。最后将两个并行的模块相加起来,这样的设计可以有效地捕获从最细到最广泛的特征,并保持原始特征信息的同时提升特征的表达能力,从而提高后续图像处理任务的性能。

1.4 结合残差注意力的跨层特征融合模块

由于本文算法框架采用了类似U-Net这样的编码-解码结构,但是由于在编码过程中下采样可能导致重要的空间信息丢失,且在非相邻层级之间可能缺乏有效的特征连接,导致无法充分利用低特征来辅助解码器重建清晰图像。针对这些问题,本文设计一个RACLFFM模块,使用跨层融合,来将下采样时特征层与上采样时特征层进行充分融合,确保网络不会忽略那些重要的低级特征,从而利

用那些边缘和纹理信息来帮助图像恢复局部细节。同时改进注意力机制,引入残差注意力来帮助网络更加聚焦于关键特征并增强模型的特征选择能力。

为了加强网络的特征提取能力,充分学习特征图上的每个通道和空间位置的重要性,采用卷积块注意力模块

(convolutional block attention module, CBAM)^[21](图5),主要由通道注意力和空间注意力组成,并且引入残差结构,组成残差注意力,以此提高模型的性能,使其在学习深层特征的同时,保持对初级特征的敏感性,更好地保持特征的活性和丰富性。

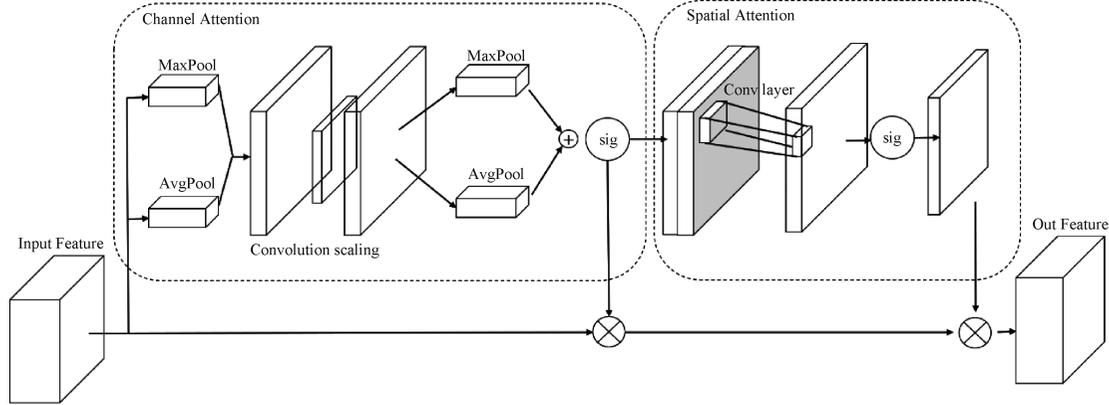


图5 CBAM 注意力模块
Fig. 5 CBAM attention module

RACLFFM 模块(图6)首先将从网络的下采样过程的浅层特征层与上采样过程中的深层特征层进行拼接,结合不同层次的信息,使其既包含全局信息也包含局部细节,然后经过深度可分离非对称卷积,一方面使用深度可分离卷积能够在以更高的计算效率来提取丰富的空间特征,另一方面利用多尺度感受野、并行操作,来更好地提取图像中的局部与全局信息特征。再通过过残差注意力,使其强化网

络对关键特征的学习,同时抑制不重要的部分,再通过 1×1 卷积层,降低特征图的通道数,为了后面与下采样的特征层和上采样的特征层相加做准备。具体的流程如下:

$$F_{fusion} = F_{down} + F_{up} + F_{mid} \quad (2)$$

式中: F_{down} 表示下采样的浅层特征; F_{up} 表示上采样的深层特征; F_{mid} 表示两个特征层进过残差注意力的中间融合特征。

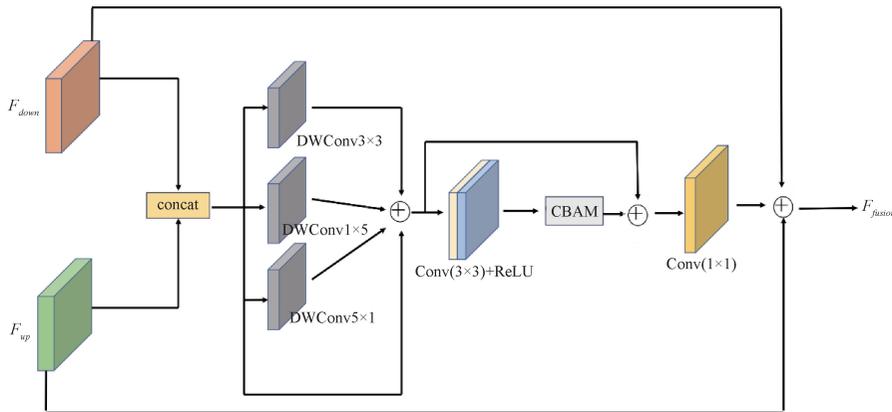


图6 结合残差注意力的跨层特征融合模块
Fig. 6 Residual attention cross-layer feature fusion module

通过 RACLFFM, 首先融合不同层次的特征,并通过残差注意力强化关键的特征,最终输出一个既包含全局抽象信息又富含局部细节信息的特征图。在去雾网络中,这样的特征融合有助于同时保留背景的全局信息和前景物体的细节信息,这对于清晰地重建整个图像非常关键。通过这样的处理,网络可以更有效地去除图像中的雾霾,恢

复真实世界的视觉信息。

1.5 损失函数

1) 平滑 L1 损失

平滑 L1 损失函数是一种广泛用于回归任务中的损失函数,结合了 L1 损失和 L2 损失的优点:在误差较小时,行为类似于 L2 损失,可以提供平滑的梯度;而在误差较大

时,行为类似于 L1 损失,对离群点较为鲁棒。平滑 L1 损失函数的表达式为:

$$L_{SL1}(x) = \begin{cases} 0.5x^2, & |x| < 1 \\ |x| - 0.5, & \text{其他} \end{cases} \quad (3)$$

式中: x 表示预测值与真实值之间的差异。

2) 感知损失

感知损失是一种在深度学习特别是计算机视觉任务中用于捕捉高层次图像内容和风格差异的损失函数,被广泛应用于两幅图像之间的感知差异,可以获得极其丰富、详细的信息。本文使用 ImageNet 上预训练的 VGG-16 作为感知损失的预训练网络,感知损失由 VGG-16 输出的特征层计算,可以表示为:

$$L_p = \sum_{j=1}^3 \frac{1}{C_j H_j W_j} \|\varphi_j(J) - \varphi_j(J_{dehaze})\|_2^2 \quad (4)$$

式中: φ_j 为 VGG-16 中网络中第 j 层的特征映射; C, W, H 表示特征映射后特征图的维度; J_{dehaze} 为去雾图像。

3) 总损失函数

为了使模型能够更全面地学习数据的底层和高层特征,本文将平滑 L1 损失和感知损失组合为整个模型训练的总损失函数。 L_{SL1} 用于计算预测值和真实值之间的误差,并在误差较大时减少对离群值的敏感性, L_p 使模型能够学习和重建图像的高级特征,从而生成在视觉上更真实的图像。总损失函数如下:

$$L_{total} = L_{SL1} + \lambda L_p \quad (5)$$

式中:平滑 L1 损失作为主要损失函数。感知损失函数在深度特征级对去雾图像和清晰图像进行微调。根据训练经验, λ 设置为 0.05。

2 实验与结果分析

2.1 实验平台

本文实验平台搭建如表 1 所示。

表 1 实验平台

Table 1 Experimental platform

类别	环境
电脑类型	笔记本电脑
CPU	AMD R7-5800H
显卡	NVIDIA GeForce RTX 3060
操作系统	Windows 10 专业版
语言框架	Anconda+Python3.8.13+Pytorch1.11.0

2.2 数据集与实验设置

由于从真实世界采集大量的无雾图片与相对应的有雾图像非常困难,所以一般用合成的有雾图像进行训练。为了客观与各类算法对比,本文使用公共的且在去雾领域广泛认可的 RESIDE 数据集的室内训练数据集(indoor training set, ITS)和室外训练数据集(outdoor training set, OTS)作为训练数据。RESIDE 数据集提供了大量的

室内外场景图像以及多种类型的雾图像,使得模型能够在不同条件和场景下进行训练,有助于提高模型的泛化能力。为了加快模型的收敛速度,从 ITS 中随机选取 1 000 张真实图像和 10 000 张对应的雾图,从 OTS 随机选取 2 000 张真实图像和 20 000 张对应的雾图,利用这些合成雾图像与相对应的清晰图像来训练网络。其中,在抽取的图像中,选取 ITS 里 200 张真实图像及其对应的 200 张雾图,从 OTS 里 400 张真实图像及其对应的 400 张雾图作为验证集,其他的都作为训练集。为了数据增强,将训练的数据集中的图像有些进行随机角度($90^\circ, 180^\circ, 270^\circ$)的旋转,有些进行水平垂直翻转,有些保持不变。选取客观测试集(synthetic objective testing set, SOTS)为测试集,其中包括 500 张室内合成图像与 500 张室外合成图像。

实验参数方面,为了提升训练效率,设置图像大小尺寸为 256×256 ,采用 ADAM 优化器优化网络,衰减系数采用默认值,即 β_1 为 0.900、 β_2 为 0.999,训练的批处理大小设置为 4,初始学习率设为 0.000 1,采用余弦退火策略对学习率进行周期调整。

2.3 评价指标

采用峰值信噪比(peak signal-to-noise ratio, PSNR)和结构相似性(structural similarity index measurement, SSIM)作为测试集图像客观评价指标。

1) 峰值信噪比

峰值信噪比用于评价图像恢复后的整体性能,衡量其与参考图像之间的失真水平。其值越大,表示图像的失真程度越小,图像恢复得越好,计算公式可以定义为:

$$PSNR = 10 \times \lg\left(\frac{(2^n - 1)^2}{MSE}\right)^2 \quad (6)$$

式中: n 代表每个像素比特数;MSE 代表恢复后图像与参考图像之间的均方误差。

2) 结构相似性

结构相似性用于评价图像恢复后的结构信息,衡量其与参考图像之间在亮度、对比度和结构上的相似程度。其值越大,表示图像与参考图像的差异越小,图像恢复越好,计算公式可以定义为:

$$SSIM = \frac{(2u_x u_y + C_1)(2\sigma_{xy} + C_2)}{(u_x^2 + u_y^2 + C_1)(\sigma_x^2 + \sigma_y^2 + C_2)} \quad (7)$$

式中: u_x 与 u_y 表示两幅图像的均值; σ_x^2 与 σ_y^2 表示两幅图像的方差; σ_{xy} 表示两幅图像的协方差。

2.4 方法比较

为了验证本文算法的有效性,将本文方法与近几年图像去雾研究算法中其他 4 种主流的图像去雾方法 DCP、AOD-Net、GridDehazeNet 和 GCA-Net 从定性和定量两个角度进行对比和分析。

1) 合成雾图像定量分析

不同算法实验结果如表 2 所示,可以看出,在室内数据集上,本文算法相比与其他的算法,在 PSNR 和 SSIM 上均取得了最高的评价指标,而在室外数据集上,本文算

法在 PSNR 上取得了最高的值,在 SSIM 上也仅比排第 1 的低 0.03,从而验证了本文算法的有效性。

表 2 SOTS 室内与室外数据集不同算法实验结果
Table 2 Experimental results of different algorithms in SOTS indoor and outdoor datasets

算法	SOTS 室内		SOTS 室外	
	PSNR/dB	SSIM	PSNR/dB	SSIM
DCP	16.15	0.835	19.68	0.835
AOD-Net	20.16	0.856	21.91	0.902
GCA-Net	29.23	0.976	29.96	0.935
GridDehazeNet	31.62	0.981	30.06	0.986
本文	33.12	0.986	31.07	0.983

2) 合成雾图像定性分析

为了验证本文算法在视觉感官上的去雾效果,本文对室内数据集以及室外数据集上的去雾图像进行定性分析比较。从室内测试集上选取 4 组室内图像,其去雾效果的定性比较如图 7 所示。由图 7(b)和(g)可以看出,DCP 去雾后的图片与真实无雾图片相比,虽说去雾效果很彻底,但是因为暗通道优先原则,出现了颜色失真问题,颜色较深。由图 7(c)和(g)可以看出,AOD-Net 去雾后,图像仍出现了残留的雾,去雾不彻底。通过图 7(d)、(e)和(g)可以看出,GCA-Net、GridDehazeNet 整体去雾效果还算可以,但一些地方仍不是太好,比如图 7(d)和(e)(第 1 和

2 组图像)可以看出,墙壁的颜色比真实无雾的图片更深一点,由此可见这两种算法细节边缘上恢复效果还是不太满意的。相比之下,本文提出的去雾算法表现出了较好的去雾效果,未出现颜色失真现象,更接近于真实无雾图像。

从室外测试集上选取 4 组室内图像,其去雾效果的定性比较如图 8 所示。可以看到 DCP 算法去雾后,图像颜色失真,颜色较深。而 AOD-Net 算法虽说颜色视觉还行,但是依旧存在着去雾不彻底的情况,而 GCA-Net 在去雾后,通过图 8(d)(第 3 和 4 组图像)可以看出,虽说颜色没有 DCO 那么明显,但依旧存在着一些色彩偏差,通过图 8(e)(第 4 组图像)可以看出,GridDehazeNet 算法处理后,虽说处理的图像已经很接近真实无雾的图像,但是依旧有些细节地方颜色较深,出现偏色现象,而本文所提算法比较好的去除了雾霾,且图像色彩饱和度最为接近真实无雾的图像。

3) 在真实图像上评估

为了进一步验证本文算法的有效性与普遍适用性,本文对其在真实场景下的效果图像进行实验评估,各算法去雾效果如图 9 所示。由图 9(b)可以看出,DCP 算法处理后的图像色彩失真严重,天空区域,高山部分颜色比较深。由图 9(c)可以看出,AOD-Net 算法处理后的图像虽然没有 DCP 算法失真那么严重,但也出现了一定程度的失真,颜色也比较深。由图 9(d)可以看出,GCA-Net 算法处理后的第 1 组图像高山区域去雾不彻底,且天空区域也有一点暗淡,第 2 组图像也有点失真的程度。由图 9(e)可以看



图 7 SOTS 室内合成有雾图像不同方法结果对比

Fig. 7 Comparison of results of different methods of SOTS indoor synthesis of fog images

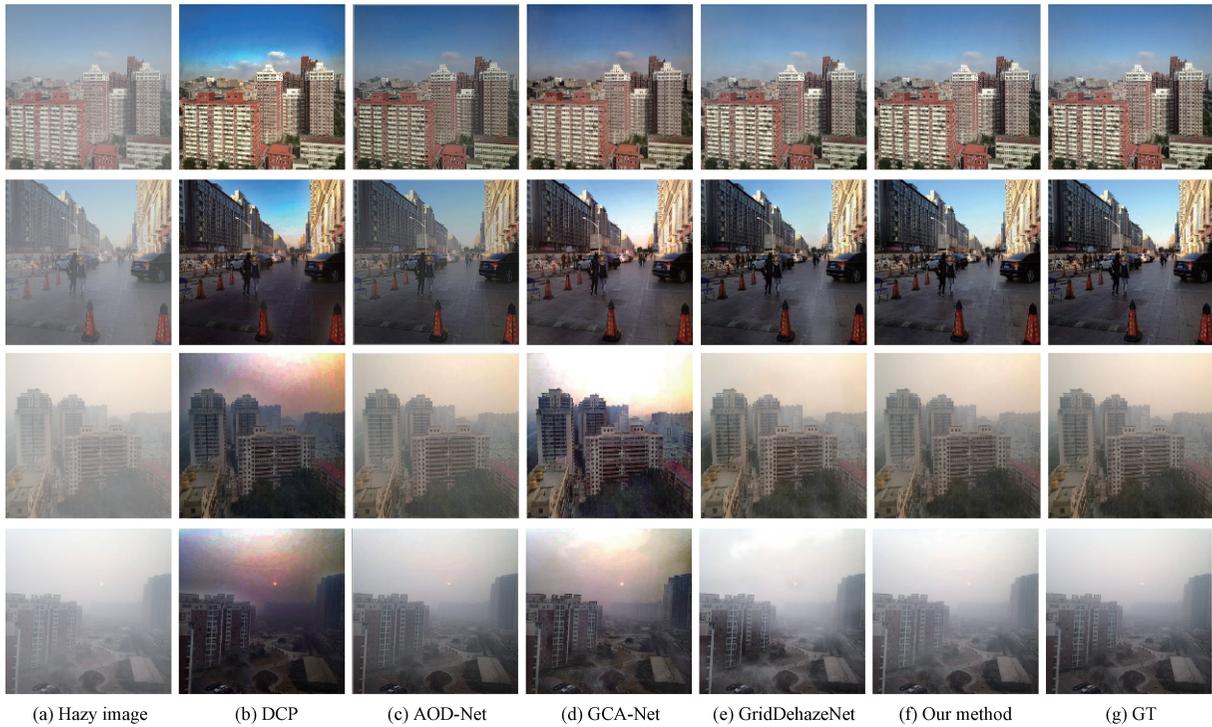


图 8 SOTS 室外合成有雾图像不同方法结果对比

Fig. 8 Comparison of results of different methods for SOTS outdoor synthesis of fog images

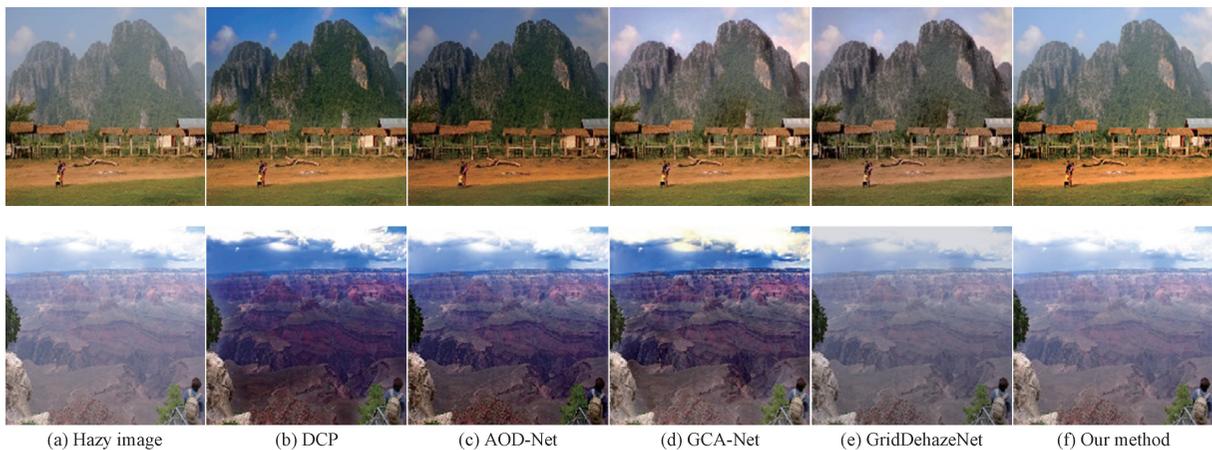


图 9 SOTS 真实雾霾图像不同方法结果对比

Fig. 9 Comparison of results of different methods in SOTS real haze image

出,GridDehazeNet 算法处理后的图像对于天空区域也有点雾残留和细节模糊,去雾不彻底,颜色也有点暗淡。相比之下,本文算法处理雾处理的比较好,亮度适中,在很好保留图像细节的同时有效地将雾霾去除,使得恢复出更加清晰自然的无雾图像。

2.5 消融实验

为了验证本文算法提出的各个模块的有效性,选择 SOTS 室内测试集进行消融实验,本文基于改进的模块设计了 5 组消融实验对比,本文一共改进了 4 处模块,浅层特征提取模块 SFEM,多残差级联模块 MRCCM,局部-全

局特征融合模块 LGFFM,结合残差注意力的跨层特征融合模块 RACLFFM。模型 1 为没有 4 处模块的网络,模型 2 是只有 SFEM 模块,模型 3 是 SFEM+MRCCM,模型 4 是 SFEM+MRCCM+LGFFM,模型 5 就是本文算法。实验表明,每个模块的加入,都对算法在 PSNR 和 SSIM 上有着不错的提升。且尤其是引入 LGFFM 后,对算法在 PSNR 和 SSIM 有着较大的提升,因为融合了局部与全局的特征信息,有效地结合局部信息和全局上下文特征,更好的帮助图像恢复。所以每个模块都对图像去雾有着不错的帮助,更好地恢复图像。

表3 消融实验结果

Table 3 Results of ablation experiment

模型	SFEM	MRCM	LGFFM	RACLFFM	PSNR/dB	SSIM
模型 1					26.51	0.875
模型 2	✓				27.86	0.902
模型 3	✓	✓			30.82	0.935
模型 4	✓	✓	✓		31.95	0.972
模型 5	✓	✓	✓	✓	33.12	0.986

3 结论

本文提出了一种基于多残差和多重特征融合的端到端图像去雾算法。通过浅层特征提取模块,为深层网络提高丰富信息的特征图,设计多残差级联模块帮助模型提取多层次特征,帮助网络捕获更广泛和更深层次的信息,设计局部-全局特征融合模块,结合残差注意力的跨层特征融合模块这两个特征融合模块帮助模型有效地捕获从最细到最广泛的特征,避免上下采样后的细节缺失,更好地提取图像中的局部与全局信息特征。实验表明,本文提出的算法在客观指标上和视觉感官上都有着不错的效果,从而验证了本文算法的有效性。

参考文献

- [1] 吴正平,程洁莹,雷帮军,等. 基于特征注意力的快速非均匀雾图像去雾算法[J]. 国外电子测量技术, 2023,42(9):9-18.
WU ZH P, CHENG J Y, LEI B J, et al. Defogging algorithm for fast non-uniform fog images based on feature attention [J]. Foreign Electronic Measurement Technology, 2023,42(9):9-18.
- [2] 陈燕,杨艳,杨春兰,等. 基于阶段聚焦损失和并行增广策略的遥感图像场景分类[J]. 电子测量与仪器学报, 2023,37(1):116-122.
CHEN Y, YANG Y, YANG CH L, et al. Remote sensing image scene classification based on phase focus loss and parallel augmentation strategy [J]. Chinese Journal of Electronic Measurement and Instrumentation, 2023,37(1):116-122.
- [3] 周道先,张吟龙,徐高飞,等. 基于形变卷积和深层聚合网络的水下文物检测[J]. 仪器仪表学报, 2023, 44(11):185-195.
ZHOU D X, ZHANG Y L, XU G F, et al. Underwater cultural relics detection based on deformation convolution and deep aggregation network [J]. Chinese Journal of Scientific Instrument, 2023,44(11):185-195.
- [4] 王子昭,景明利,史金钢,等. 一种改进 CBAM 机制和细节恢复的单幅图像去雾算法[J]. 电子测量技术, 2023,46(2):161-168.
WANG Z ZH, JING M L, SHI J G, et al. A single image defogging algorithm with improved CBAM mechanism and detail recovery [J]. Electronic Measurement Technology, 2019,46(2):161-168.
- [5] 刘宇航,吴帅. 基于多尺度融合和对抗训练的图像去雾算法[J]. 激光与光电子学进展, 2020,57(6):179-188.
LIU Y H, WU SH. Image defogging algorithm based on multi-scale fusion and adversarial training [J]. Advances in Laser and Optoelectronics, 2019,57(6):179-188.
- [6] 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.
- [7] ZHU Q, MAI J, SHAO L. A fast single image haze removal algorithm using color attenuation prior [J]. IEEE Transactions on Image Processing, 2015, 24(11):3522-3533.
- [8] 梁楚萍,冯一箴,谢浩然,等. 基于先验知识的单幅图像雨雾去除方法[J]. 浙江大学学报(理学版), 2021, 48(3):270-281,288.
LIANG CH P, FENG Y H, XIE H R, et al. Rain and fog removal method for single image based on prior knowledge [J]. Journal of Zhejiang University (Science Edition), 201,48(3):270-281,288.
- [9] 刘威,陈成,江锐,等. 四通道无监督学习图像去雾网络[J]. 通信学报, 2022,43(10):210-222.
LIU W, CHEN CH, JIANG R, et al. Four-channel unsupervised learning image de-fogging network [J]. Journal of Communications, 202,43(10):210-222.
- [10] LI B, PENG X, WANG Z, et al. AOD-Net: All-in-one dehazing network [C]. 2017 IEEE International Conference on Computer Vision. IEEE, 2017: 4770-4778.
- [11] 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.
- [12] 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 (WACV). IEEE, 2019: 1375-1383.
- [13] 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.
- [14] 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.
- [15] DONG H, PAN J, XIANG L, et al. Multi-scale boosted dehazing network with dense feature fusion[C]. 2020 IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2020: 2157-2167.
- [16] QIN X, WANG Z L, BAI Y C, et al. FFA-net: Feature fusion attention network for single image dehazing [C]. Thirty-Fourth AAAI Conference on Artificial Intelligence. Newyork: AAAI Press, 2020, 34(7): 11908-11915.
- [17] ZHENG Z R, REN W Q, CAO X C, et al. Ultra-high-definition image dehazing via multi-guided bilateral learning[C]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2021: 16180-16189.
- [18] LI L, DONG Y L, REN W Q, et al. Semi-supervised image dehazing [J]. IEEE Transactions on Image Processing, 2020, 29: 2766-2779.
- [19] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1-9.
- [20] 马龙,马腾宇,刘日升. 低光照图像增强算法综述[J]. 中国图象图形学报,2022,27(5):1392-1409.
MA L, MA T Y, LIU R SH. Review of low light image enhancement algorithms [J]. Journal of Image and Graphics,2022,27(5):1392-1409.
- [21] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]. Proceedings of the European Conference on Computer Vision (ECCV), 2018: 3-19.

作者简介

武丽, 硕士, 副教授, 主要研究方向为人工智能、模式识别。

E-mail: 79901056@qq.com

俞俊(通信作者), 硕士研究生, 主要研究方向为人工智能、目标检测、图像处理。

E-mail: 1339632139@qq.com

张征浩, 硕士研究生, 主要研究方向为图像处理, 深度学习。

E-mail: 1281593056@qq.com

葛彩成, 硕士研究生, 主要研究方向为机器学习, 图像处理。

E-mail: 853136455@qq.com