

双注意力引导的细节和结构信息融合图像去雾网络

高继蕊^{1,2}, 李华锋^{1,2}, 张亚飞^{1,2}, 谢明鸿¹, 李 凡^{1,2}

(1. 昆明理工大学信息工程与自动化学院, 云南昆明 650500; 2. 云南省人工智能重点实验室, 云南昆明 650500)

摘要: 雾图像结构信息弱化、边缘细节信息丢失,严重影响其在高水平视觉任务的使用. 现有大部分去雾方法对图像细节信息的恢复并不理想,影响了图像去雾的整体效果. 为此,本文提出一种双注意力引导的细节和结构信息融合去雾网络. 该网络主要由空间-通道双注意力联合模块、细节和结构信息融合模块以及多尺度特征重建模块组成. 其中,空间-通道双注意力联合模块通过联合空间和通道两个维度的注意力进行特征提取,实现雾图像中细节和结构信息的增强;细节和结构信息融合模块将结构信息和边缘细节信息融合为注意力权重和逆向注意力权重,以进一步增强这两种信息;多尺度特征重建模块将提取到的特征重建为清晰图像. 实验结果表明,本文方法的去雾效果在定量评价和视觉效果上均优于对比方法.

关键词: 图像去雾;图像恢复;信息融合;注意力;特征重建

基金项目: 国家自然科学基金(No.62161015)

中图分类号: TP399

文献标识码: A

文章编号: 0372-2112(2023)01-0160-12

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20211549

Dual Attention-Guided Detail and Structure Information Fusion Network for Image Dehazing

GAO Ji-rui^{1,2}, LI Hua-feng^{1,2}, ZHANG Ya-fei^{1,2}, XIE Ming-hong¹, LI Fan^{1,2}

(1. Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming, Yunnan 650500, China;

2. Yunnan Key Laboratory of Artificial Intelligence, Kunming, Yunnan 650500, China)

Abstract: Haze weakens the structural information of an image and makes the edge information lost, which negatively affects the performance of high-level vision tasks. The details recovered by most existing dehazing methods are unsatisfactory, affecting the overall effect of image dehazing. To this end, this paper proposes a dual-attention guided detail and structure information fusion network composed of spatial-channel dual attention joint module, detail and structure information fusion module, and multi-scale feature reconstruction module. The spatial-channel dual attention joint module performs feature extraction by combining spatial attention and channel attention to enhance details and structural information in the hazy image. The detail and structure information fusion module fuses structure and edge into attention weights and inverse attention weights to further enhance both information. The multi-scale feature reconstruction module reconstructs the extracted features into a clear image. The experiment results show that the dehazing effect of the proposed method is superior to that of the compared methods in both quantitative evaluation and visual effect.

Key words: image dehazing; image restoration; information fusion; attention; feature reconstruction

Foundation Item(s): National Natural Science Foundation of China (No.62161015)

1 引言

雾霾天气条件下拍摄到的图像会出现对比度和清晰度下降、边缘细节信息丢失严重等问题. 雾天图像质量的退化会影响后期计算机视觉任务(如图像分割^[1-3]、目标检测^[4-7]、卫星定位^[8]等)的开展. 因此,图像去雾受到了研究者的广泛关注. 根据大气散射模

型^[9-11],雾图像的成像过程如式(1)所示:

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

其中, $I(x)$ 表示有雾图像; $J(x)$ 表示清晰图像; $t(x)$ 表示透射率; A 表示全局大气光.

一些研究者利用图像先验知识估计出透射率 $t(x)$ 和全局大气光 A ,并根据式(1)恢复出清晰图像. 常用

的图像先验有暗通道先验^[12]、颜色衰减先验^[13]、非局部先验^[14]等. 虽然, 基于图像先验的去雾方法实现了有雾图像的恢复, 但是图像先验带有统计特性, 估计出的透射率和全局大气光存在误差, 导致其去雾效果不理想.

近年来, 研究者们开始利用深度学习来解决图像去雾问题. 基于神经网络的图像去雾方法可分为两类: 一类是基于大气散射模型的方法^[15-18], 另一类是端到端的方法^[19-24]. 以大气散射模型为基础的方法通过神经网络估计出透射率和全局大气光, 并根据式(1)恢复出清晰图像. 这类方法要利用雾图像和其对应的透射率标签图像来训练透射率估计网络. 但是, 现实中的透射率标签图像一般由深度相机获取, 与实际雾图的透射率存在偏差. 因此, 基于大气散射模型去雾时, 由透射率网络估计出的透射率并不准确, 以致影响了算法的去雾效果. 端到端的图像去雾方法则将雾图像作为神经网络的输入, 通过网络直接估计出清晰图像. 这类方法主要通过残差、跳跃连接、密集连接、注意力等设计去雾模型, 以学习有雾图像到清晰图像之间的映射来实现图像去雾. 但是, 现有去雾方法对图像细节信息的恢复效果并不理想, 影响了图像去雾的整体性能.

为改善去雾图像边缘细节信息丢失的问题, 本文提出一种双注意力引导的细节和结构信息融合的图像去雾网络. 具体地, 本文构建了空间-通道双注意力联合模块分别对图像中的结构信息和边缘细节信息进行提取并初步增强. 在特征提取过程中, 该模块不仅分别在空间维度和通道维度上提取相关信息, 而且能联合空间-通道维度, 挖掘两个维度在特征提取过程中遗漏的信息. 为实现边缘细节和结构信息的恢复, 本文设计了细节和结构信息融合模块, 该模块利用注意力和逆向注意力(即注意力未注意到的区域)互补的思想增强图像中的边缘细节和结构信息. 同时, 本文利用不同感受野的卷积核能处理不同尺度信息的思想, 设计了多尺度特征重建模块, 将提取到的特征重建为清晰图像. 本文提出的方法在实现去雾的同时有效地恢复了有雾图像中的边缘细节信息.

综上所述, 本文的主要贡献包括以下3个方面.

(1) 构建了空间-通道双注意力联合模块. 不仅能够空间维度和通道维度上提取边缘细节信息和图像结构信息, 而且能够挖掘两个维度在特征提取中遗漏的信息, 有效地实现图像结构信息和边缘细节信息的初步恢复和增强.

(2) 设计了细节和结构信息融合模块. 将图像结构信息和边缘细节信息融合为注意力权重和逆向注意力权重, 使图像中的结构和边缘细节通过注意力权重和逆向注意力权重得到增强. 该模块实现了图像结构信息和边缘细节信息的进一步增强和恢复.

(3) 从图像恢复和增强的角度出发, 将图像去雾视为一个恢复和增强图像中结构信息和边缘细节信息的过程. 实验结果表明, 本文方法取得了良好的去雾效果.

2 相关工作

2.1 先验知识为基础的去雾方法

以先验知识为基础的图像去雾方法主要通过图像先验估计出透射率和全局大气光, 然后通过大气散射模型求出清晰图像. He 等人^[12]通过观察发现清晰图像块中的像素至少在一个颜色通道上的值接近于零, 并根据这一观察结果提出基于暗通道先验的去雾方法. 为了改善暗通道先验算法处理时间过长, 计算资源消耗过大的问题, 张等人^[25]提出一种基于暗通道先验的快速图像去雾算法, 该算法有针对性的解决了计算效率低和明亮区域暗通道先验失效的问题. 刘等人^[26]针对去雾后图像的明亮区域颜色失真的问题, 基于HSI色彩空间对透射率和全局大气光进行估计, 并对估计的白色区域的透射率进行矫正, 改善了颜色失真的情况. Berman 等人^[14]发现在RGB颜色空间中, 清晰图像由数百种颜色值构成, 且这些颜色值中某一颜色值不是分布于某一局部区域, 而是分布在整幅图像的各个区域中, 并且, 他们通过这一发现提出非局部先验算法. Fattal 等人^[27]根据在小图像块中的像素在RGB颜色空间中呈一维分布这一先验, 提出基于颜色线的图像去雾方法. 上述以先验知识为基础的方法虽能实现图像去雾, 但因先验知识带有统计特性, 与现实场景存在误差, 因此, 去雾效果受到影响.

2.2 深度学习为基础的去雾方法

以深度学习为基础的图像去雾方法可分为两类: 以大气散射模型为基础的方法和端到端的方法. 以大气散射模型为基础的图像去雾方法^[15,16,18,28]用神经网络估计出透射图和大气光, 然后利用大气散射模型求出清晰图像. Cai 等人^[15]设计了特征提取、多尺度映射与局部极值结合的网络来估计透射图. Ren 等人^[16]提出用粗尺度网络和细尺度网络共同来估计透射图. Li 等人^[18]提出一种用于单幅图像去雾的层次感知渐进网络(Level-aware progressive Network, Lap-Net), Lap-Net由离散大气光估计子网络、传输图估计子网络和自适应一体化子网络三部分构成, 通过三部分相互作用实现图像去雾. 肖等人^[28]提出一种基于霾层学习的卷积神经网络单幅图像去雾方法, 该方法能够直接从有雾图像中去除霾层以实现图像去雾. 以上方法常常因为缺乏准确的透射率和大气光的标签, 导致网络估计结果不准确, 使最终的图像去雾效果欠佳.

端到端的图像去雾方法^[20,22,23,29]直接以有雾图像作为深度神经网络的输入, 通过学习有雾图像到清晰

图像之间的映射,实现图像去雾.如Liu等人^[20]提出一种端到端的可训练的卷积神经网络GridDehazeNet,该网络中的预处理、主干和后处理三个模块利用各自的优势并相互作用实现图像去雾.Qin等人^[22]提出一种特征融合注意力图像去雾网络,该网络利用通道注意力和像素注意力提取特征,并为不同层的特征赋予不同的权重以实现图像去雾.Dong等人^[23]提出一种密集特征融合的多尺度增强去雾网络,该网络以U-Net为基础,设计了可移植性较好的密集特征融合模块和深度增强去雾网络实现图像去雾.Shao等人^[29]提出一种域自适应图像去雾方法,该方法通过图像翻译网络减小域差异.这些方法主要通过学习有雾图像到清晰图像之间的映射来实现图像去雾,忽略了在雾图像形成过程中图像边缘细节的退化问题.本文考虑雾图像边缘细节信息的丢失问题,构建了细节和结构信息融合的双注意力特征提取网络,通过恢复边缘细节和结构信息来实现图像去雾.

3 方法

3.1 方法概述

本文提出方法的总框架如图1所示,主要包括空间-通道双注意力联合模块(Spatial-Channel Dual Attention Joint Module, S-CDAJM)、细节和结构信息融合模块

(Detail and Structure Information Fusion Module, DSIFM)和多尺度特征重建模块(Multi-scale Feature Reconstruction Module, MFRM).雾图特征提取分支和边缘图特征提取分支中分别包含9个结构相同的S-CDAJM模块,两个分支通过9个结构相同的DSIFM模块进行信息传递,每个模块不共享参数.空间-通道双注意力联合模块负责对图像结构信息和边缘细节信息进行特征提取和初步增强.细节和结构信息融合模块负责将图像的结构信息和边缘细节信息融合为注意力权重和逆向注意力权重,进一步增强这两种信息.多尺度特征重建模块利用不同感受野的卷积核实现图像细节和结构特征的重建.通过三个模块共同作用,本文所构建的模型能够有效地增强图像的结构信息和边缘细节信息.具体地,给定一张有雾图像 I ,利用Sobel边缘检测算子计算出 I 的边缘图 I_{Sobel} .将 I 和 I_{Sobel} 分别输入网络,经过空间-通道双注意力联合模块、细节和结构信息融合模块和多尺度特征重建模块三个模块的处理,最终恢复出清晰图像 J .此外,为了保证网络能提取到较完整的边缘信息,本文也恢复出边缘图 J_s ,同时将清晰标签图像 \tilde{J} 的边缘图 \tilde{J}_s 作为 J_s 的标签,对网络进行约束.




图1 本文提出方法的总体框架图

3.2 空间-通道双注意力联合模块

雾弱化了图像中的结构和边缘细节信息.雾图像中的结构信息虽被弱化,但由于其尺度大则较容易增强,而雾图像中的边缘细节信息特征表现较弱,很难对其进行直接增强.Sobel边缘检测算子是高斯平滑与微分操作的结合体,它的抗噪能力强且边缘定位准确,因此,本文使用Sobel边缘检测算子检测出雾图像的边缘图,并将雾图对应清晰图像的边缘图作为标签,对边缘图特征提取进行约束.增强或补充被弱化的信息常用方法是使用注意力机制.在基于注意力的图像去雾方法中,Yu等人^[30]仅使用了通道注意力,Qin等人^[22]将通道注意力和空间注意力串联.然而,这些方法因没有充分利用通道注意力和空间注意力提取的特征,影响了其去雾性能.

不同于这些方法,本文将通道注意力和空间注意力联合起来,不仅能同时关注到通道维度上的信息和空间维度上的信息,而且将通道和空间注意力联合得

到联合注意力权重.使用联合注意力权重增强的特征能有效地补充单独使用通道注意力、空间注意力或者两者串联时遗漏的信息.具体地,空间-通道双注意力联合模块的结构如图2所示.设 $F_l \in \mathbb{R}^{H \times W \times 64}$ ($l=1, 2, \dots, 9$)为第 l 个S-CDAJM的输入.首先引入一个残差结构对 F_l 进行处理.该结构由2个 3×3 卷积层和一个ReLU激活函数组成,经过残差结构处理后的特征 F_l^r 可表示为

$$F_l^r = \text{conv} \left(\text{relu} \left(\text{conv} \left(F_l, k=3 \right) \right), k=3 \right) \quad (2)$$

其中,conv表示卷积操作,relu表示ReLU激活函数, k 表示卷积层的卷积核大小.然后将 F_l^r 通过通道注意力得到 F_l^{ca} ,再将 F_l^{ca} 通过空间注意力得到 F_l^{pa} . F_l^{ca} 和 F_l^{pa} 可用式(3)表示:

$$\begin{cases} F_l^{\text{ca}} = \text{CA} \left(F_l^r \right) \\ F_l^{\text{pa}} = \text{PA} \left(F_l^{\text{ca}} \right) \end{cases} \quad (3)$$

其中, $CA(\cdot)$ 和 $PA(\cdot)$ 分别表示通道注意力和空间注意力. 在图 2 的 CA 模块中, AGAP(Adaptive Global Average Pooling) 表示自适应全局平均池化. 为了补充在空间注意力和通道注意力特征提取过程中丢失的信息, 本文对通道和空间维度的注意力进行联合处理, 得到




图 2 空间-通道双注意力联合模块结构图

3.3 细节和结构信息融合模块

在 3.2 节中, 通过空间-通道双注意力联合模块分别对图像结构信息和边缘细节信息进行了初步增强. 为了将雾图特征提取分支和边缘图特征提取分支提取的特征融合起来, 本文设计了细节和结构信息融合模块. 在该模块中, 本文设计了注意力机制 (包括正向注意力和逆向注意力), 引导网络进一步增强图像的结构和边缘细节信息.

具体地, 细节和结构信息融合模块的结构如图 3 所示. 本文将雾图特征提取分支中第 l 个 S-CDAJM 模块提取的特征 \hat{F}_l^h 和边缘图特征提取分支中第 l 个 S-CDAJM 模块提取的特征 \hat{F}_l^s , 通过图 3 所示的方式生成正向注意力 p (在生成正向注意力 p 的过程中, 本文使用全局最大池化和全局平均池化以注意到图像的细节信息), 生成 p 的过程如式 (5) 所示:

$$\begin{cases} F_{\text{pool}} = \text{cat} \left(\text{GAP} \left(\text{cat} \left(\hat{F}_l^h, \hat{F}_l^s \right) \right), \text{GMP} \left(\text{cat} \left(\hat{F}_l^h, \hat{F}_l^s \right) \right) \right) \\ p = \delta \left(\text{FC} \left(\text{relu} \left(\text{FC} \left(F_{\text{pool}} \right) \right) \right) \right) \end{cases} \quad (5)$$

其中, F_{pool} 表示经过全局平均池化和最大池化后的特征, $\text{GMP}(\cdot)$ 和 $\text{GAP}(\cdot)$ 分别表示全局平均池化和最大池化, $\delta(\cdot)$ 表示 Softmax 激活函数, $\text{FC}(\cdot)$ 表示全连接层.

然而, 传统的注意力^[31]通常只突出注意力关注的地方, 而注意力未关注的部分往往被忽略. 虽然, 在注意力结构中增加残差结构^[32]可以在一定程度上缓解上述问题, 然而还不能满足要求. 受逆向注意力^[33]的启发, 本文在注意力的基础上引入逆向注意力 \tilde{p} . 逆向注意力 \tilde{p} 即为正向注意力未关注到的区域权重, 可表示为

$$\tilde{p} = e - p \quad (6)$$

其中, e 是与 p 具有相同维度的向量, 其中的所有元素都为 1. \tilde{p} 对输入的特征进行反向增强, 并通过两个卷积核大小为 3×3 的卷积层对增强后的特征进行提取. 最后, 将增强后的特征 \tilde{F}_l^h 和 \tilde{F}_l^s 分别输入到雾图特征提取分

支和边缘图特征提取分支中进行下一轮增强. 细节和结构信息融合的具体过程可用式 (7) 表示:

$$\hat{F}_l = \sigma \left(\text{conv} \left(\text{cat} \left(F_l^{\text{ca}}, F_l^{\text{pa}} \right), k=1 \right) \right) \odot F_l^{\text{ca}} + F_l^{\text{pa}} \quad (4)$$

其中, $\sigma(\cdot)$ 表示 Sigmoid 激活函数, cat 表示拼接操作, \odot 表示对应元素相乘.

支和边缘图特征提取分支中进行下一轮增强. 细节和结构信息融合的具体过程可用式 (7) 表示:

$$\begin{cases} \tilde{F}_{\text{en}}^h = \hat{F}_l^h \odot p + \text{conv} \left(\text{conv} \left(\hat{F}_l^h \odot \tilde{p}, k=3 \right), k=3 \right) + \hat{F}_l^h \\ \tilde{F}_{\text{reen}}^h = \sigma \left(\text{conv} \left(\text{relu} \left(\text{conv} \left(\tilde{F}_{\text{en}}^h, k=1 \right) \right), k=1 \right) \right) \odot \tilde{F}_{\text{en}}^h \\ \tilde{F}_l^h = \tilde{F}_{\text{en}}^h + \hat{F}_l^h + \tilde{F}_{\text{reen}}^h \\ \tilde{F}_{\text{en}}^s = \hat{F}_l^s \odot p + \text{conv} \left(\text{conv} \left(\hat{F}_l^s \odot \tilde{p}, k=3 \right), k=3 \right) + \hat{F}_l^s \\ \tilde{F}_{\text{reen}}^s = \sigma \left(\text{conv} \left(\text{relu} \left(\text{conv} \left(\tilde{F}_{\text{en}}^s, k=1 \right) \right), k=1 \right) \right) \odot \tilde{F}_{\text{en}}^s \\ \tilde{F}_l^s = \tilde{F}_{\text{en}}^s + \hat{F}_l^s + \tilde{F}_{\text{reen}}^s \end{cases} \quad (7)$$

其中, \tilde{F}_{en}^h 和 \tilde{F}_{en}^s 表示通过正向注意力和逆向注意力增强后的雾图和边缘图的特征, $\tilde{F}_{\text{reen}}^h$ 和 $\tilde{F}_{\text{reen}}^s$ 表示经过注意力再次增强之后的特征, \tilde{F}_l^h 和 \tilde{F}_l^s 表示细节和结构信息融合模块的输出.

3.4 多尺度特征重建模块

增强图像中的结构信息和边缘细节信息的最终目的是重建出清晰的去雾图像. 在进行卷积操作时, 较小的卷积核有较小的感受野, 因此对局部变化剧烈的图像边缘较为敏感, 而较大的卷积核则拥有较大的感受野, 对图像的结构信息相对较敏感. 因此, 使用不同大小的卷积进行特征提取, 能得到更丰富的特征. 文献 [34] 验证了多尺度特征提取的优越性. 鉴于此, 本文采用 $1 \times 1, 3 \times 3, 5 \times 5$ 三种不同大小的卷积核来提取多尺度特征并重建出清晰图像.

多尺度特征重建模块的具体结构如图 4 所示. \tilde{F}_l 为多尺度特征重建模块的输入, 它由各空间-通道双注意力联合模块以及细节和结构信息融合模块的输出经拼接和卷积后得到. 在多尺度特征重建模块中, 通过多尺度特征提取块 (Multi-scale Feature Extraction Block, MFEB) 对 \tilde{F}_l 进行多尺度特征提取. 多尺度特征提取过程可用 (8) 式表示:

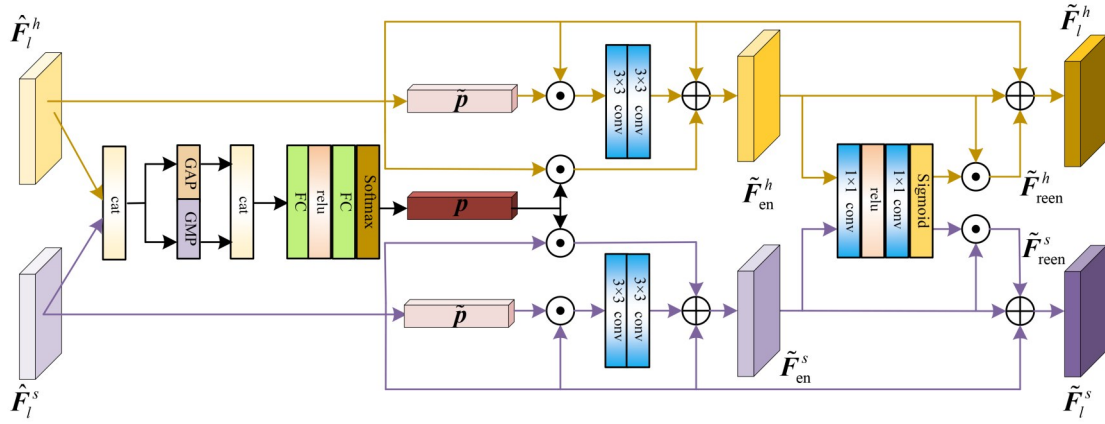


图3 细节和结构信息融合模块结构图

$$\begin{cases} \tilde{F}_L = \text{conv} \left(\text{cat} \left(\text{conv} \left(\text{cat} \left(\tilde{F}_1^h, \hat{F}_1^h \right), k=1 \right), \dots, \text{conv} \left(\text{cat} \left(\tilde{F}_9^h, \hat{F}_9^h \right), k=1 \right) \right), k=1 \right) \\ \tilde{F}_L^1 = \text{conv} \left(\text{relu} \left(\text{conv} \left(\tilde{F}_L, k=1 \right) \right), k=1 \right) \\ \tilde{F}_L^3 = \text{conv} \left(\text{relu} \left(\text{conv} \left(\tilde{F}_L, k=3 \right) \right), k=3 \right) \\ \tilde{F}_L^5 = \text{conv} \left(\text{relu} \left(\text{conv} \left(\tilde{F}_L, k=5 \right) \right), k=5 \right) \end{cases} \quad (8)$$

其中, \tilde{F}_L^1 , \tilde{F}_L^3 和 \tilde{F}_L^5 分别表示网络提取到的尺度为 1, 3 和 5 的特征. 将提取到的多尺度特征进行拼接, 并通过空间注意力和通道注意力得到重建后的清晰图像 J , 如式(9)所示:

$$\begin{cases} \tilde{F}_J = \text{cat} \left(\tilde{F}_L^5, \tilde{F}_L^3, \tilde{F}_L^1 \right) \\ J = \text{conv} \left(\text{conv} \left(\text{PA} \left(\text{CA} \left(\tilde{F}_J \right), k=3 \right), k=3 \right) \right) \end{cases} \quad (9)$$

其中, \tilde{F}_J 表示拼接后的特征.




图4 多尺度特征重建模块结构图

3.5 损失函数

为了使本文构建的网络能够达到良好的去雾效果,使用以下损失函数来训练去雾网络.

(1) **重建损失函数** 在去雾网络训练的过程中,重建损失函数分别约束网络重建去雾图像和边缘图,使去雾后的图像和清晰图像一致,重建的边缘图和清晰图像的边缘图一致. 具体损失函数如式(10)所示:

$$\begin{cases} L_c^J = \| J - \tilde{J} \|_1 \\ L_c^S = \| J_s - \tilde{J}_s \|_1 \end{cases} \quad (10)$$

其中, J 表示去雾后的结果, \tilde{J} 表示清晰图像, J_s 和 \tilde{J}_s 分别表示重建后的边缘图像和清晰图像边缘图, L_c^J 和 L_c^S 分别表示去雾图像重建损失和边缘图重建损失.

$$L_c = L_c^J + L_c^S \quad (11)$$

其中, L_c 表示重建总损失.

(2) **感知损失函数** 为了度量去雾图像 J 和清晰标签图像 \tilde{J} 之间的视觉相似度,提升去雾图像的视觉效果,本文采用感知损失函数来约束训练网络. 感知损失定义如式(12)所示:

$$L_p = \left\| \phi(J) - \phi(\tilde{J}) \right\|_2^2 \quad (12)$$

其中, ϕ 表示从 VGG16 模型^[35]提取到的特征图, J 表示去雾结果, \tilde{J} 表示清晰的标签图像.

(3) **结构相似性损失函数** 结构相似性 SSIM^[36]可度量两幅图像之间的结构是否相似,两幅图像之间的结构相似性可定义为

$$\text{SSIM}(J, \tilde{J}) = \frac{(2\mu_J\mu_{\tilde{J}} + c_1)(2\sigma_{J\tilde{J}} + c_2)}{(\mu_J^2 + \mu_{\tilde{J}}^2 + c_1)(\sigma_J^2 + \sigma_{\tilde{J}}^2 + c_2)} \quad (13)$$

其中, J 和 \tilde{J} 分别表示去雾后的图像和清晰的标签图像, μ_J 和 $\mu_{\tilde{J}}$ 分别表示去雾后图像和清晰标签图像均值, σ_J^2 和 $\sigma_{\tilde{J}}^2$ 分别表示去雾后图像和清晰标签图像的方差, $\sigma_{J\tilde{J}}$ 表示去雾后图像和清晰标签图像的协方差, c_1 和 c_2

表示为了避免出现分母为0而设定的常数. $SSIM(\mathbf{J}, \tilde{\mathbf{J}})$ 的取值范围为 $(0, 1]$. $SSIM(\mathbf{J}, \tilde{\mathbf{J}})$ 值越大, 表明去雾后图像和清晰标签图像越相似, 即去雾效果越好.

为了更好地优化模型, 本文用结构相似性损失函数训练模型. 结构相似性损失函数定义为

$$L_{SSIM} = 1 - SSIM(\mathbf{J}, \tilde{\mathbf{J}}) \quad (14)$$

其中, L_{SSIM} 的取值范围为 $[0, 1)$. 模型训练的目标是使 L_{SSIM} 的取值尽可能小, 即使去雾后图像和清晰标签图像尽可能相似.

综上所述, 训练本文提出模型的总的损失函数如式(15)所示:

$$L_{total} = \alpha L_c + \beta L_p + \gamma L_{SSIM} \quad (15)$$

其中, α, β, γ 为平衡参数, 具体的参数分析见 4.6 节.

4 实验

4.1 数据集

4.1.1 训练数据集

RESIDE^[37] 是一个大规模的合成雾图像数据集, 该数据集包含室外训练集 (Outdoor Training Set, OTS)、室内训练集 (Indoor Training Set, ITS)、合成目标测试集 (Synthetic Object Testing Set, SOTS)、混合主观测试集 (Hybrid Subjective Testing Set, HSTS)、真实世界任务驱动测试集 (Real Task-driven Testing Set, RTTS) 和非标记的真实有雾图像 (Unannotated Real Hazy Images, URHI). 本文模型的训练数据来自 RESIDE 的室外训练集 OTS. OTS 包含 8 970 幅清晰室外图像, 每张清晰图像合成 35 张有雾图像, 共有 313 950 幅合成有雾图像. 为了加快模型的收敛速度, 本文从 OTS 中随机选取了 40 000 幅合成雾图像. 利用这 40 000 幅合成雾图像和其对应的清晰图像来训练网络. 此外, 本文将训练数据集中的图像剪裁成 128×128 的图像块, 并对图像块进行随机角度 ($90^\circ, 180^\circ, 270^\circ$) 的旋转和翻转 (水平方向和垂直方向) 或者不做任何操作, 以增加数据的多样性, 达到数据增强的目的.

4.1.2 测试数据集

本文采用 3 个测试集来评估提出方法的有效性. SOTS 包含 500 幅室内 (indoor) 雾图像和 500 幅室外 (outdoor) 雾图像. 由于雾主要存在于室外场景, 因此, 本文将 SOTS 中的 500 幅室外图像作为测试集一, 记为 SOTS-outdoor; HSTS 包含 10 幅真实雾图像和 10 幅合成雾图像, 本文将 10 幅合成雾图像作为测试集二, 记为 HSTS-Syn; 测试集三为 HAZERD 数据集^[38]. HAZERD 包含 15 幅清晰图像, 每幅清晰图像对应 5 幅不同雾浓度的图像, 共计 75 幅雾图像. 为了保证对比的公平性, 本文中所有对比方法的实验结果都是在测试数据集

SOTS-outdoor, HSTS-Syn 和 HAZERD 上测试得到的.

4.2 评价指标

为了定量评价不同方法的去雾效果, 本文采用 PSNR^[39] (Peak Signal to Noise Ratio), SSIM^[36] (Structural SIMilarity) 和 LPIPS^[40] (Learned Perceptual Image Patch Similarity) 为客观评价指标. PSNR 能够度量去雾后图像和标签清晰图像对应像素之间的差异. SSIM 反映图像场景中物体结构的属性, 是一种衡量两幅图像相似度的指标. LPIPS 表示学习感知相似度, 用于度量两幅图像之间的视觉差异. PSNR 和 SSIM 两个评价指标值越大, 表明去雾效果越好. LPIPS 的值越低表示两幅图像越相似, 反之, 则差异越大.

4.3 实验实施细节

本文使用 PyTorch 框架, 在 NVIDIA GeForce RTX 2080 Ti GPU 上开展实验. 采用 Adam^[41] 优化器来优化去雾网络, 初始学习率设置为 1×10^{-4} , 并采用余弦退火策略^[42] 来调整学习率, 优化器的其他参数为默认值, 批次大小设置为 4. 整个网络训练 500 000 步. 此外, 根据实验经验本文将所构建模型中的 S-CDAJM 模块和 DSIFM 模块数量分别设置为 9. 本文方法的代码可在 <https://github.com/lhf12278/DS-Net> 下载.

4.4 方法比较

为验证所提去雾方法的有效性, 将本文方法与 8 种经典的图像去雾方法在测试集 SOTS-outdoor^[37], HSTS-Syn^[37], HAZERD^[38] 上进行比较. 对比方法有 CAP^[13], DehazeNet^[15], AOD-Net^[43], DPSID^[44], EPDN^[21], DA^[29], FFA-Net^[22], TBNN^[30]. 其中, CAP, DPSID 为基于先验知识的方法, DPSID 主要任务为恢复图像细节. 其他 6 种对比方法都是基于深度神经网络的图像去雾方法.

4.4.1 视觉效果分析

图 5 是不同方法在测试集 SOTS-outdoor^[37] 上的测试结果. 从图 5 可以看出, 以先验为基础的 CAP 和 DPSID 方法存在去雾过度的现象, 导致图像颜色失真严重. 基于深度学习的 AOD-Net 方法也存在颜色失真的现象, 其原因在于该方法在一定程度上依赖于大气散射模型. 观察 EPDN 的去雾结果, 可以发现图像整体出现偏红的现象. DA 方法局部区域的边缘细节信息丢失严重, 如树叶边缘模糊不清. TBNN 方法的去雾结果存在大量的雾残留. DehazeNet 和 FFA-Net 方法的去雾结果与本文提出方法的结果较接近, 但 FFA-Net 方法细节恢复效果稍差; 在第 4 行图像中, DehazeNet 方法去雾结果的天空区域存在雾残留.

图 6 为不同方法在 HSTS-Syn^[37] 测试集上的测试结果. 从图 6 可以看出, DehazeNet, AOD-Net, TBNN 的去雾结果中都存在一定程度的雾残留. CAP, DPSID 和 EPDN 方法的去雾结果存在颜色失真. DA 的去雾结果




图5 不同方法在SOTS-outdoor测试集上的测试效果

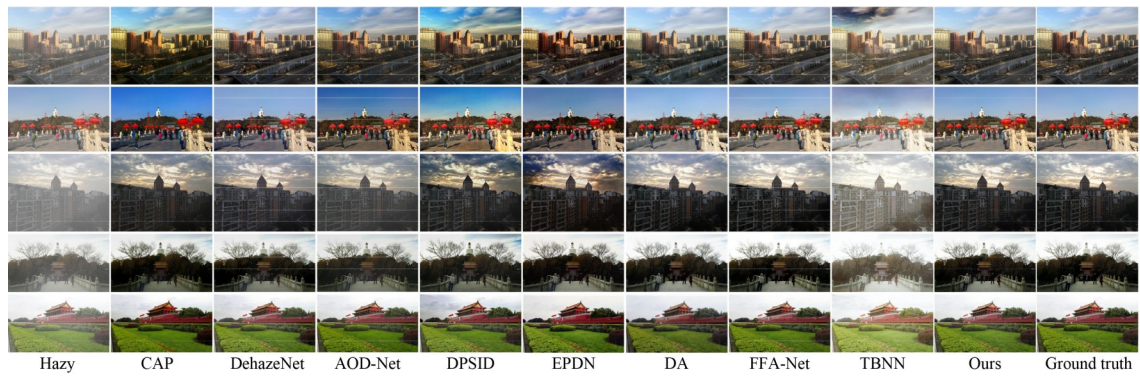


图6 不同方法在HSTS-Syn测试集上的测试效果

边缘细节信息丢失严重,如第5行图像中的草坪区域; FFA-Net的测试结果图像细节较模糊且存在振铃现象,如第2行图像红色灯笼边缘模糊和第5行图像“天安门房檐”上存在振铃状的伪影。

图7是不同方法在HAZERD^[38]数据集上的去雾效果.该数据集使用物理上真实且经散射理论证明合理

的参数对雾进行更真实的模拟,因此,该数据集更加接近真实场景的有雾图像.从图7可以看出,DA方法的去雾结果中,边缘结构(如房檐)出现模糊和伪影.此外,CAP,DehazeNet,AOD-Net,DPSID,EPDN方法存在颜色失真,整体偏暗.FFA-Net方法和TBNN方法都有大量的雾残留.



图7 不同方法在HAZERD测试集上的测试效果

综上所述,对比方法的结果要么颜色失真,要么有雾残留,要么细节信息模糊.相比之下,本文提出的方法在一定程度上克服了以上问题.总体来说,本文提出方法的去雾结果和标签图像最接近,有最好的视觉

效果.

4.4.2 边缘细节信息恢复情况

为了能更直观地展示本文提出方法的边缘细节信息恢复情况,利用Sobel算子检测出本文方法去雾结果

的边缘图和原始雾图像的边缘图,以观察去雾前后图像边缘细节变化情况.为了方便观察,本文将边缘图中变化较明显的区域用红色虚线框标记.

图 8 共展示了 3 组图像去雾前后的细节图.其中“Hazy”列表示有雾图像和与之相对应的细节图,

“Ours”列表示本文提出方法的去雾结果和与之相对应的边缘细节图.比较同一组图像去雾前后红色虚线框出区域的边缘细节变化情况,可以看出,去雾后图像对应的边缘图包含更多的细节信息.这表明本文提出的方法对恢复边缘信息起到了促进作用.

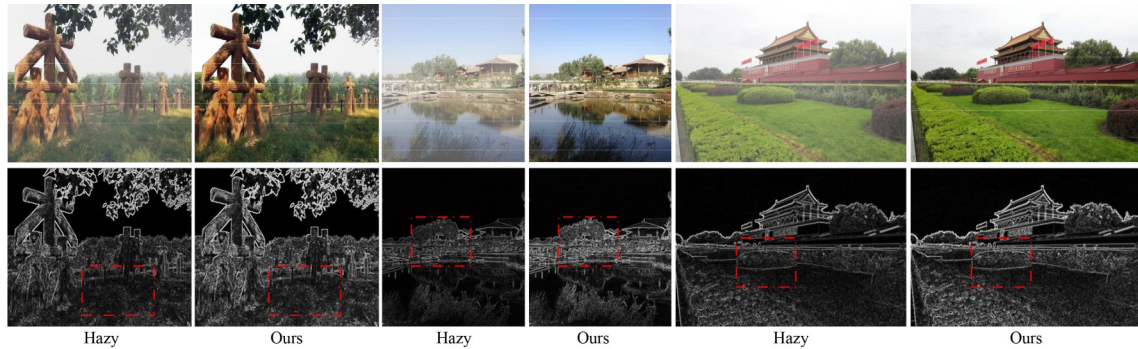


图 8 去雾前后图像细节信息对比

此外,为了比较本文提出方法与其他对比方法的细节信息恢复情况,本文对不同方法去雾结果的局部区域进行了放大,如图 9 所示.观察图 9 中用红框框出的区域,可以发现本文对比方法中木头横截面上的年轮信息丢失.同时,CAP,DehazeNet,AOD-Net,DPSID,FFA-Net 方法的去雾结果在木头截面周围都存在明显

的振铃状伪影.特别的,DPSID 方法的主要目标是恢复图像中的细节信息.但是,与本文算法相比,DPSID 方法去雾结果中木头截面的中心位置是平滑的,而本文算法恢复的结果仍然可看到中心位置的年轮痕迹.因此,由比较结果可知,本文提出的方法能有效地恢复雾图像中的边缘细节信息.




图 9 不同方法去雾细节信息恢复情况对比

4.4.3 定量分析

本文在 3 个测试集上对不同方法进行了定量评价,结果如表 1 所示.表 1 中评价指标的值都是各测试集中所有图像测试结果的平均值,各指标最好的结果用加粗字体表示,排在第二的用下划线表示.对比表 1 中各方法所得的测试结果,可以发现:在测试集 SOTS-outdoor^[37]和测试集 HSTS-Syn^[37]上,本文算法的 SSIM 和 LPIPS 都取得最优值,PSNR 排在第二;在测试集 HAZARD^[38]上,本文算法的 SSIM 取得最好的值,PSNR 和 LPIPS 排在第二.总的来说,在所有测试集上,本文提出方法的去雾结果与标签图像最相似.

4.5 消融实验

本节通过消融实验来验证本文提出的空间-通道双注意力联合模块(S-CDAJM)、细节和结构信息融合模块(DSIFM)和多尺度特征重建模块(MFRM)的有效性.表 2 给出了不同模块组合的模型在 SOTS-outdoor^[37]测试集上的定量评价结果.在消融实验中,本文把去除 S-CDAJM,DSIFM 和 MFRM 后的模型作为 Baseline,在表中用“BL”表示. Baseline+S-CDAJM 表示 Baseline 加空间-通道双注意力联合模块,在表中用“BL+S-C”表示. Baseline+S-CDAJM+DSIFM 表示 Baseline 加上空间-通道双注意力联合模块以及细节和结构信息融合模

表1 不同方法在不同测试集上去雾结果的定量评价结果(PSNR/SSIM/LPIPS)

方法	SOTS-outdoor	HSTS-Syn	HAZARD
CAP(TIP'15) ^[13]	18.12/0.758 1/0.135	19.71/0.809 5/0.114	14.12/0.708 2/0.267
DehazeNet(TIP'16) ^[15]	22.61/0.863 3/0.075	23.92/0.888 0/0.065	15.52/0.760 1/0.236
EPDN(CVPR'19) ^[21]	19.96/0.834 2/0.144	21.35/0.883 3/0.098	15.70/0.754 7/0.267
FFA-Net(AAAI'20) ^[22]	30.89/0.936 7/0.038	31.36/0.927 9/0.031	16.26/0.791 0/0.253
DA(CVPR'20) ^[29]	25.79/0.886 4/0.197	26.26/0.864 7/0.170	17.65/0.804 3/0.243
TBNN(CVPRW'21) ^[30]	15.21/0.780 6/0.186	13.65/0.747 9/0.186	12.03/0.745 7/0.293
AOD-Net(ICCV'17) ^[43]	19.65/0.854 8/0.097	19.77/0.839 4/0.099	15.45/0.749 3/0.269
DPSID(ITM'18) ^[44]	18.44/0.861 7/0.119	18.45/0.849 5/0.120	15.52/0.772 4/0.224
本文方法	29.43/0.968 5/0.014	29.76/0.972 9/0.011	16.93/0.812 5/0.227

块,在表中用“BL+S-C+DS”表示. Baseline+S-CDAJM+DSIFM+MFRM表示Baseline加上空间-通道双注意力联合模块,细节和结构信息融合模块以及多尺度特征重建模块为本文最终的模型,在表中用“B+S-C+DS+MR”表示. 此外,本文将S-CDAJM替换成FFA-Net^[22]中的CA+PA模块来验证所提出的S-CDAJM相较于CA+PA的优越性,在表中记为“B+CP+DS+MR”. 为了验证结构和细节信息融合模块中注意力权重 p 和逆向注意力权重 \tilde{p} 的有效性,本文分别做了去掉 p (在表中记为“W/O p ”)和去掉 \tilde{p} (在表中记为“W/O \tilde{p} ”)的消融实验. 最后,本文还验证了多尺度特征重建模块中多尺度特征提取块(MFEB)的有效性,去掉MFEB其他部分保持不变,在表中记为“W/O MFEB”.

表2 本文提出的方法中不同模块消融实验的结果

方法	PSNR	SSIM	LPIPS
BL	26.50	0.954 9	0.022 4
BL+S-C	27.90	0.962 8	0.017 7
BL+S-C+DS	28.75	0.963 3	0.016 5
BL+S-C+DS+MR	29.43	0.968 5	0.014 3
BL+CP+DS+MR	27.70	0.957 8	0.019 7
W/O p	29.03	0.966 2	0.016 7
W/O \tilde{p}	28.05	0.962 1	0.018 1
W/O MFEB	28.80	0.965 3	0.015 5

4.5.1 空间-通道双注意力联合模块的有效性

空间-通道双注意力联合模块通过融合通道注意力和空间注意力提取的特征,有效地挖掘了通道和空间维度的信息. 对比表2中第3行(BL+S-C)和第2行(BL)可以发现,Baseline加上S-CDAJM后去雾结果的PSNR/SSIM值都有所提升,LPIPS值下降,表明S-CDAJM对去雾图像质量的提升起着重要的作用. 此外,本文的S-CDAJM模块是在FFA-Net中的CA+PA结构的基础上设计的,因此,为了更进一步验证S-CDAJM的有效性,本文将S-CDAJM模块替换成CA+PA来进行消融实验. 观察表2中的第5行(BL+S-C+DS+MR)和第6行(BL+CP+DS+MR)可发现,将网络中S-CDAJM替换成CA+PA之

后,其去雾结果的PSNR和SSIM值都在下降,LPIPS值上升,说明本文中的S-CDAJM模块更有效.

4.5.2 细节和结构信息融合模块的有效性

细节和结构信息融合模块主要作用是将雾图特征提取分支和边缘图特征提取分支提取的特征融合起来,以提升去雾图像的质量. 比较表2中的第3行(BL+S-C)和第4行(BL+S-C+DS)中的数据,可以发现,加入该模块后,去雾结果的质量(PSNR值)提升,结构改善(SSIM值上升),和标签图像视觉差异降低(LPIPS下降). 该变化说明本文提出的细节和结构信息融合模块确实对提升去雾结果的质量起到了有效的作用. 此外,通过观察表2中的第5行(BL+S-C+DS+MR)、第7行(W/O p)和第8行(W/O \tilde{p})发现,去掉细节和结构信息融合模块中的注意力权重 p 或逆向注意力权重 \tilde{p} ,模型性能都有所下降,这说明注意力权重和逆向注意力权重对模型性能提升都起到了促进作用.

4.5.3 多尺度特征重建模块的有效性

多尺度特征信息重建模块通过不同感受野的卷积核重建不同类型的特征信息. 本文验证了多尺度特征信息重建模块的作用,如表2中的第4行(BL+S-C+DS)和第5行(BL+S-C+DS+MR)所示,在第4行的基础上加上多尺度特征重建模块,模型性能提升. 此外,为了验证该模块中多尺度特征提取块(MFEB)的作用,本文做了消融实验,结果如表2中的第9行(W/O MFEB)所示. 对比表2第5行和第9行,可以看出,去掉多尺度特征提取块后,模型性能有所下降. 这些消融实验的结果表明,多尺度特征提取块以及整个多尺度特征信息重建模块都对图像特征的重建都起到了良好的作用.

4.5.4 不同方法的模型大小、参数量和计算量大小比较

在这一部分,本文对不同方法的模型大小、参数量和计算量大小作出说明.“—”表示无相关量表示,“Model size”表示模型大小,“Params”表示参数量,“FLOPs”表示计算量,结果如表3所示.

表 3 不同方法的模型大小、参数量和计算量大小比较

方法	Model size/MB	Params/M	FLOPs/G
CAP	—	—	—
DehazeNet	0.030	0.008	0.394
AOD-Net	0.009	0.002	0.088
EPDN	66.300	17.379	3.677
DA	208.354	54.591	30.041
FFA-Net	25.390	4.456	220.551
TBNN	192.769	50.352	64.736
DPSID	—	—	—
Ours	5.410	1.342	71.562

观察表 3,对比以深度学习为基础的几种方法的模

型大小和参数量,本文提出的方法具有较小的模型和较少的参数量.对于 FLOPs 而言,本文方法的计算量中等.虽然,本文方法的计算量大于 DehazeNet, AOD-Net, EPDN, DA 和 TBNN 方法,但在去雾效果上优于它们.总的来说,根据去雾结果的视觉效果和定量分析,本文方法在较少参数的情况下取得了比其他方法更好的去雾效果.

4.6 参数的选择和分析

在这一部分,本文对式(15)中的 3 个权重系数 α, β 和 γ 的选择进行分析.为了能有效地对参数进行选择和分析,本文将 α 设定为 1,对参数 β 和 γ 进行分析,结果如图 10 所示.

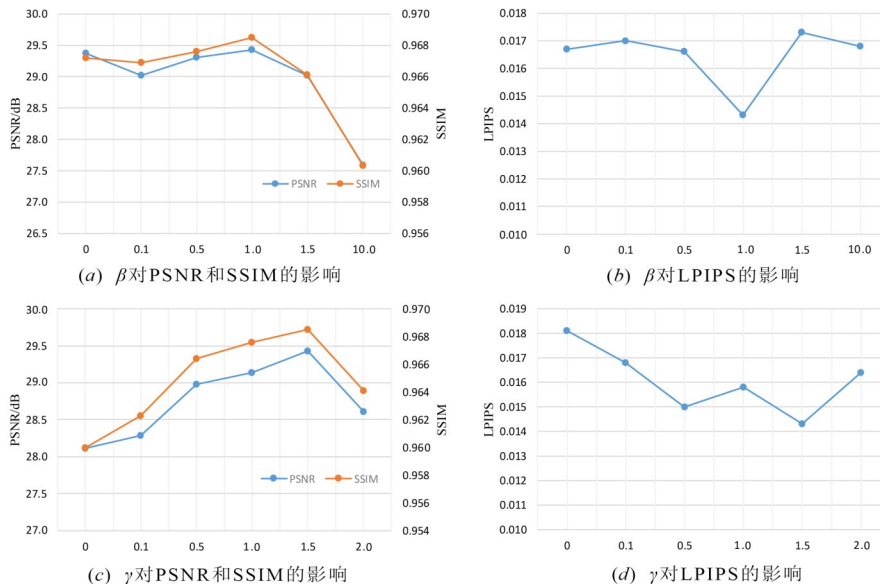


图 10 损失函数 L_{total} 权重参数分析图

(1) 参数 β 的选择和分析.如图 10 中的第一行所示:当 $\beta < 1$ 时,模型在 SOTS-outdoor^[37] 上测试结果的 PSNR 和 SSIM 值总体处于上升趋势, LPIPS 总体呈下降趋势;当 $\beta > 1$ 时, PSNR 和 SSIM 的值呈下降趋势, LPIPS 总体呈上升趋势;当 $\beta = 1$ 时, PSNR, SSIM, LPIPS 取得最优值,因此,本文将权重 β 设置为 1.

(2) 参数 γ 的选择和分析.如图 10 中第二行所示:当 $\gamma < 1.5$ 时,模型在 SOTS-outdoor^[37] 上测试结果的 PSNR 和 SSIM 值处于上升趋势; LPIPS 总体呈下降趋势;当 $\gamma > 1.5$ 时, PSNR 和 SSIM 的值整体呈下降趋势, LPIPS 的值整体呈上升趋势.虽然在 $\gamma = 0.5$ 时也出现折点,但当 $\gamma = 1.5$ 时, PSNR, SSIM 和 LPIPS 取得最优值.因此,本文将权重 γ 设置为 1.5.

5 结论

本文提出一种双注意力引导的细节和结构信息融合

图像去雾网络.该网络将图像去雾看作增强和恢复图像中结构信息以及边缘细节信息的过程,为此本文设计了用于初步增强两者信息的空间-通道双注意力联合模块以及用于将边缘细节信息和结构信息融合的细节和结构信息融合模块.同时,本文设计了多尺度特征重建模块将含有结构和细节信息的特征重建为清晰图像.实验结果表明,去雾后的图像拥有比原始雾图像更加丰富的边缘细节信息.与对比方法相比,本文方法有更优异的去雾效果.

参考文献

[1] PANG Y W, LI Y Z, SHEN J B, et al. Towards bridging semantic gap to improve semantic segmentation[C]//2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019: 4229-4238.
 [2] MA S, PANG Y, PAN J, et al. Preserving details in semantics-aware context for scene parsing[J]. Science China In-

- formation Sciences, 2020, 63(2): 120106.
- [3] ZHANG Z J, PANG Y W. CGNet: Cross-guidance network for semantic segmentation[J]. Science China Information Sciences, 2020, 63(2): 120104.
- [4] NIE J, ANWER R M, CHOLAKKAL H, et al. Enriched feature guided refinement network for object detection[C]//2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019: 9536-9545.
- [5] PANG Y W, XIE J, KHAN M H, et al. Mask-guided attention network for occluded pedestrian detection[C]//2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, : 4966-4974.
- [6] CAO J L, PANG Y W, HAN J G, et al. Hierarchical shot detector[C]//2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019: 9704-9713.
- [7] LI Y Z, PANG Y W, SHEN J B, et al. NETNet: Neighbor erasing and transferring network for better single shot object detection[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 13346-13355.
- [8] NI W P, GAO X B, WANG Y. Single satellite image dehazing via linear intensity transformation and local property analysis[J]. Neurocomputing, 2016, 175: 25-39.
- [9] MCCARTNEY E J, HALL F F. Optics of the atmosphere: Scattering by molecules and particles[J]. Physics Today, 1977, 30(5): 76-77.
- [10] NARASIMHAN S G, NAYAR S K. Chromatic framework for vision in bad weather[C]//Proceedings IEEE Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 598-605.
- [11] NARASIMHAN S G, NAYAR S K. Vision and the atmosphere[J]. International Journal of Computer Vision, 2002, 48(3): 233-254.
- [12] 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, 2011, 33(12): 2341-2353.
- [13] ZHU Q S, MAI J M, SHAO L. A fast single image haze removal algorithm using color attenuation prior[J]. IEEE Transactions on Image Processing, 2015, 24(11): 3522-3533.
- [14] BERMAN D, TREIBITZ T, AVIDAN S. Non-local image dehazing[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 1674-1682.
- [15] 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, 2016, 25(11): 5187-5198.
- [16] REN W, LIU S, ZHANG H, et al. Single image dehazing via multi-scale convolutional neural networks[C]//European Conference on Computer Vision. Amsterdam: Springer Cham, 2016: 154-169.
- [17] ZHANG H, PATEL V M. Densely connected pyramid dehazing network[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 3194-3203.
- [18] LI Y N, MIAO Q G, OUYANG W L, et al. LAP-Net: Level-aware progressive network for image dehazing[C]//2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019: 3275-3284.
- [19] REN W Q, MA L, ZHANG J W, et al. Gated fusion network for single image dehazing[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 3253-3261.
- [20] LIU X H, MA Y R, SHI Z H, et al. GridDehazeNet: Attention-based multi-scale network for image dehazing[C]//2019 IEEE/CVF International Conference on Computer Vision. Seoul: IEEE, 2019: 7314-7323.
- [21] QU Y Y, CHEN Y Z, HUANG J Y, et al. Enhanced pix2pix dehazing network[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, : 8152-8160.
- [22] QIN X, WANG Z L, BAI Y C, et al. FFA-Net: Feature fusion attention network for single image dehazing[C]//Proceedings of the AAAI Conference on Artificial Intelligence. New York: AAAI Press, 2020: 11908-11915.
- [23] DONG H, PAN J S, XIANG L, 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.
- [24] ZHANG X Q, JIANG R H, WANG T, et al. Single image dehazing via dual-path recurrent network[J]. IEEE Transactions on Image Processing, 2021, 30: 5211-5222.
- [25] 张登银, 鞠铭焯, 王雪梅. 一种基于暗通道先验的快速图像去雾算法[J]. 电子学报, 2015, 43(7): 1437-1443.
- ZHANG D Y, JU M Y, WANG X M. A fast image haze removal algorithm using dark channel prior[J]. Acta Electronica Sinica, 2015, 43(7): 1437-1443. (in Chinese)
- [26] 刘杰平, 黄炳坤, 韦岗. 一种快速的单幅图像去雾算法[J]. 电子学报, 2017, 45(8): 1896-1901.
- LIU J P, HUANG B K, WEI G. A fast effective single image dehazing algorithm[J]. Acta Electronica Sinica, 2017, 45(8): 1896-1901. (in Chinese)
- [27] FATTAL R. Dehazing using color-lines[J]. ACM Transactions on Graphics, 2014, 34(1): 13.
- [28] 肖进胜, 周景龙, 雷俊锋, 等. 基于霾层学习的单幅图像去雾算法[J]. 电子学报, 2019, 47(10): 2142-2148.
- XIAO J S, ZHOU J L, LEI J F, et al. Single image dehazing algorithm based on the learning of hazy layers[J]. Acta Electronica Sinica, 2019, 47(10): 2142-2148. (in Chinese)

- [29] SHAO Y J, LI L, REN W Q, et al. Domain adaptation for image dehazing[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle: IEEE, 2020: 2805-2814.
- [30] YU Y K, LIU H, FU M H, et al. A two-branch neural network for non-homogeneous dehazing via ensemble learning[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Nashville: IEEE, 2021: 193-202.
- [31] MNIH V, HEES N, GRAVES A. Recurrent models of visual attention[C]//Proceedings of the 27th International Conference on Neural Information Processing Systems, Montreal: MIT Press, 2014: 2204-2212.
- [32] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE, 2016: 770-778.
- [33] Fan D P, Ji G P, Zhou T, et al. PraNet: Parallel reverse attention network for polyp segmentation[C]//International Conference on Medical Image Computing and Computer Assisted Intervention. Lima: Springer, 2020: 263-273.
- [34] LI S L, ZHAO M, FANG Z Y, et al. Image super-resolution using lightweight multiscale residual dense network [J]. International Journal of Optics, 2020, 2020: 2852865.
- [35] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2015-04-10)[2021-11-10]. <https://arxiv.org/abs/1409.1556v6>.
- [36] WANG Z, BOVIK A C, SHEIKH H R, et al. Image quality assessment: From error visibility to structural similarity [J]. IEEE Transactions on Image Processing, 2004, 13(4): 600-612.
- [37] LI B Y, REN W Q, FU D P, et al. Benchmarking single-image dehazing and beyond[J]. IEEE Transactions on Image Processing, 2019, 28(1): 492-505.
- [38] ZHANG Y F, DING L, SHARMA G. HazeRD: An outdoor scene dataset and benchmark for single image dehazing[C]//2017 IEEE International Conference on Image Processing. Beijing: IEEE, 2017: 3205-3209.
- [39] Mannos J, Sakrison D. The effects of a visual fidelity criterion of the encoding of images[J]. IEEE Transactions on Information Theory, 1974, 20(4): 525-536.
- [40] ZHANG R, ISOLA P, EFROS A A, et al. The unreasonable effectiveness of deep features as a perceptual metric [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 586-595.
- [41] Kingma D P, Ba J. Adam: A method for stochastic optimization[EB/OL]. (2014-10-22) [2021-11-10]. <https://arxiv.org/abs/1412.6980v9>.
- [42] HE T, ZHANG Z, ZHANG H, et al. Bag of tricks for im-

age classification with convolutional neural networks[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Long Beach: IEEE, 2019: 558-567.

- [43] LI B Y, PENG X L, WANG Z Y, et al. AOD-net: All-in-one dehazing network[C]//2017 IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 4780-4788.
- [44] GAO Y Y, HU H M, LI B, et al. Detail preserved single image dehazing algorithm based on airlight refinement[J]. IEEE Transactions on Multimedia, 2019, 21(2): 351-362.

作者简介



高继蕊 女, 1996年9月出生于云南省临沧市. 昆明理工大学信息工程与自动化学院硕士研究生. 主要研究方向为计算机视觉与图像处理.

E-mail: 2945266153@qq.com



李华锋 男, 1983年7月出生于安徽省阜阳市. 昆明理工大学信息工程与自动化学院教授, 博士生导师. 主要研究方向为计算机视觉.

E-mail: hfchina99@163.com



张亚飞(通讯作者) 女, 1981年5月出生于河南省洛阳市. 昆明理工大学信息工程与自动化学院副教授, 硕士生导师. 主要研究方向为图像处理、模式识别.

E-mail: zyfeimail@163.com



谢明鸿 男, 1976年12月出生于云南省昭通市. 昆明理工大学信息工程与自动化学院高级工程师, 硕士生导师. 主要研究方向为计算机视觉.

E-mail: minghongxie@163.com



李凡 男, 1986年8月出生于云南省楚雄市. 昆明理工大学信息工程与自动化学院副教授, 硕士生导师. 主要研究方向为计算机视觉.

E-mail: 478263823@qq.com