

中图法分类号: T391.41 文献标识码: A 文章编号: 1006-8961(2025)03-0798-13

论文引用格式: Jin X L, Liu C X, Ye S S, Wang C H and Zhou Z X. 2025. Multi-branch non-homogeneous image dehazing based on concentration partitioning and image fusion. Journal of Image and Graphics, 30(3):0798-0810(金鑫乐, 刘春晓, 叶爽爽, 王成骅, 周子翔. 2025. 结合浓度划分与图像融合的多分支非均质图像去雾. 中国图象图形学报, 30(3):0798-0810)[DOI:10.11834/jig.240253]

结合浓度划分与图像融合的多分支非均质图像去雾

金鑫乐, 刘春晓*, 叶爽爽, 王成骅, 周子翔

浙江工商大学计算机科学与技术学院, 杭州 310018

摘要: 目的 目前的去雾算法已能够较好地处理均质的薄雾图像,但针对雾霾浓度不同的非均质雾霾图像往往具有较低的去雾性能。为此,提出了结合浓度划分与图像融合的多分支非均质图像去雾算法。**方法** 本文将单幅非均质雾霾图像视为由多个具有均质薄雾或者均质浓雾的局部区域组成,通过分别解决单幅非均质雾图中的不同均质雾霾区域来进行整幅非均质图像去雾。首先在不同均质雾霾浓度的去雾数据集上训练了多个图像增强网络,以得到针对不同均质雾霾浓度的图像增强模型,它们对于相应雾霾浓度的图像区域具有较好的增强性能。由于单个图像增强模型只能较好地增强一幅非均质雾霾图像中具有对应雾霾浓度的图像区域,但对其他不同雾霾浓度的图像区域可能存在去雾力度不足或者过度增强的现象,本文又设计了一个图像融合网络,将多个初始图像增强结果中的优势区域进行融合,得到最终的图像去雾结果。**结果** 大量的实验结果显示,在合成雾霾数据集 FiveK-Haze 上,本文算法与排名第2的SCAN(self-paced semi-curricular attention network)方法相比在峰值信噪比(peak signal-to-noise ratio, PSNR)和结构相似性(structural similarity index, SSIM)有参考指标上分别提高了 5.286 6 dB 和 0.113 8。在真实雾霾数据集 Real-World 上,本文算法与排名第2的DEAN(detail-enhanced convolution and content-guided attention network)方法相比,在FADE(fog aware density evaluator)和HazDes无参考指标上分别降低了 0.079 3 和 0.051 2。在室内合成测试数据集 SOTS-indoor(synthetic objective testing set)上,本文算法的 PSNR 和 SSIM 指标比排名第2的DeFormer方法分别提高了 2.518 2 dB 和 0.012 3。在室外合成测试数据集 SOTS-outdoor 上,本文算法在 PSNR 指标上比排名第2的SGID-PFF(self-guided image dehazing using progressive feature fusion)方法提高了 2.832 dB,在 SSIM 指标上比排名第2的DeFormer方法提高了 0.023 8。**结论** 与已有的单幅图像去雾方法相比,本文算法能够有效增强非均质雾霾图像,具有更高的鲁棒性,展现出较好的性能指标。

关键词: 图像去雾;非均质雾霾图像;雾霾浓度划分;图像融合;多分支神经网络

Multi-branch non-homogeneous image dehazing based on concentration partitioning and image fusion

Jin Xinle, Liu Chunxiao*, Ye Shuangshuang, Wang Chenghua, Zhou Zixiang

School of Computer Science and Technology, Zhejiang Gongshang University, Hangzhou 310018, China

收稿日期: 2024-05-17;修回日期: 2024-08-13;预印本日期: 2024-08-20

* 通信作者: 刘春晓 cxliu@mail.zjgsu.edu.cn

基金项目: 国家自然科学基金项目(61976188);浙江省自然科学基金项目(LY24F020004, LZ23F020004);浙江省重点研发计划资助(2023C01039);国家级大学生创新创业训练计划项目(GJ202313014);浙江工商大学“数字+”学科建设项目(SZJ2022B016);浙江省大学生科技创新活动计划暨新苗人才计划项目(2023R408035, 2023R408072)

Supported by: National Natural Science Foundation of China (61976188); Natural Science Foundation of Zhejiang Province, China (LY24F020004, LZ23F020004); Key R&D Program of Zhejiang Province, China (2023C01039); National College Students Innovation and Entrepreneurship Training Program (GJ202313014); Zhejiang Gongshang University “Digital+” Disciplinary Construction Management Project (SZJ2022B016); Zhejiang University Students Science and Technology Innovation Activity Plan and New Talent Plan (2023R408035, 2023R408072)

Abstract: Objective When capturing images using a camera, atmospheric floating particles, such as smoke, dust, and fog, can affect image quality, leading to decreased clarity. These compromised images not only increase the likelihood of human visual misjudgment but also hinder the development of visual tasks such as remote sensing monitoring and autonomous driving. Current dehazing methods are effective for homogeneous thin hazy images but often perform poorly on the nonhomogeneous hazy images. Therefore, a multibranch non-homogeneous image dehazing method combined with concentration partitioning and image fusion is proposed to address these challenges. A single non-homogeneous hazy image is regarded as a combination of multiple local regions with homogeneous thin or dense haze. The entire non-homogeneous image is dehazed by separately addressing different homogeneous hazy regions in a single nonhomogeneous hazy image.

Method Concentration partitioning and image fusion based multi-branch image dehazing neural network (CPIFNet), a two-stage network framework for image enhancement and image fusion, is then designed. Experiment results revealed that training models based on homogeneous haze image datasets with different haze concentrations can lead to enhancement in image models with varying enhancement intensities. Homogeneous hazed image datasets with different haze concentrations are necessary to obtain varying enhancement models. FiveK-Haze is a synthesized dehazing dataset based on the atmospheric physical scattering model, encompassing nine types of different homogeneous hazed images with varying haze concentrations. The hazy images in the FiveK-Haze dataset are re-partitioned based on haze concentration, dividing the dataset into 1 to 5 different haze concentration levels to exclude the hazy image samples with excessive haze concentrations. Then, the image enhancement network is trained on those new homogeneous dehazing datasets to obtain image enhancement models for different haze concentrations. In the image enhancement networks, the deep image features of hazy images are continuously extracted to obtain the stretching coefficient of the image enhancement model. This coefficient is multiplied with the hazy image to produce the image enhancement result. The image enhancement network replaces network layers with residual modules to extract deep feature information, avoiding feature information loss as the network deepens. The ReLU activation function is used after each convolutional layer to accelerate the convergence speed of network training and avoid the transmission of negative values in the feature layers. Each enhancement network performs well for the corresponding haze concentration image region. However, a single enhancement network can only effectively enhance image regions with corresponding haze concentrations, which leads to insufficient or excessive dehazing in other regions. Therefore, an image fusion network is designed to combine the advantageous regions in the multiple initial enhancement results, producing the final dehazed result. In the image fusion network, deep image features of different image enhancement results are continuously extracted, and the dehazed result is obtained by stacking and merging these deep image features. In addition to reconstruction, perceptual, and structural losses, the image enhancement and image fusion networks also utilize color loss to constrain the image dehazing results of the network modules. This condition is due to the severe loss of pixel information in dense hazy images, complicating color restoration and allowing the color loss function to guide the color of the image dehazing result closer to the reference image.

Result Theoretically, a dehazing dataset with more finely divided haze concentration levels could enable network models to learn additional information of hazed images. However, experiments reveal otherwise. When the number of haze datasets is 3, that is, the number of image enhancement models is 3, CPIFNet achieves the best dehazing performance. Large-scale experiments are conducted in comparison with more than 10 latest image dehazing algorithms, revealing that the proposed method is optimal in terms of performance indicators and dehazing effects. Compared with the second-ranked self-paced semi-curricular attention network (SCAN) method, the method improves the reference indicators of peak signal-to-noise ratio (PSNR) and structural similarity index (SSIM) by 5.286 6 dB and 0.113 8, respectively, compared with the synthetic hazy image dataset FiveK-Haze. Compared with the second-ranked DEAN method, the proposed method reduces the non-reference metrics as FAD and HazDes by 0.079 3 and 0.051 2, respectively, over the real-world hazy image dataset. Additionally, additional tests are conducted on some publicly available datasets to obtain more comparative experiments and indicator evaluations. On the SOTS-indoor dataset, the method improves PSNR and SSIM by 2.518 2 dB and 0.012 3, respectively, compared to the second-ranked DeFormer method. On the SOTS-outdoor dataset, the method improves PSNR by 2.83 2 dB compared to the second-ranked SGID-PFF method and enhances SSIM by 0.023 8 compared to the second-ranked DeFormer method. **Conclusion** A two-stage, multi-branch deep neural network is designed to remove haze from a single non-homogeneous hazy image by separately addressing different homo-

neous hazy regions. Compared to existing methods, the proposed method can enhance the structural contrast of dense hazy regions and slightly improve thin hazy regions while restoring color information.

Key words: image dehazing; non-homogeneous hazy images; haze concentration partitioning; image fusion; multi-branch neural network

0 引言

在使用相机拍摄图像时,拍摄到的图像可能会受到烟、尘、雾等大气漂浮颗粒的影响,导致拍摄到的图像质量下降。这样的雾霾图像不仅容易造成人类视觉的误判,也阻碍一些高级视觉任务的发展,如自动驾驶、遥感监测和室外监控的异常检测等。因此图像去雾算法的研究和应用对于改善图像质量、提高视觉感知和促进高级视觉任务的发展都具有重要意义。

目前的图像去雾算法在处理非均质雾霾图像方面存在挑战。非均质雾霾图像指的是单幅图像中雾霾浓度不均匀,甚至可能出现雾霾浓度跃变的情况。虽然现有的图像去雾算法可以较好地处理均匀薄雾图像,但对于非均质雾霾图像的去雾能力仍不稳定。

雾霾图像的退化过程首先引起了研究人员的注意,他们发现空气中的散射颗粒对大气光线的传输效率产生了衰退的影响。Narasimhan 和 Nayar (2000)使用大气散射模型对合成雾霾图像的过程进行建模,具体为

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

式中, p 表示图像中的像素位置, I 和 J 分别表示雾霾图像和无雾图像, A 表示大气光值, t 表示大气透射率图。

利用大气物理散射模型,赵锦威等人(2016)提出一种基于大气光校验和光晕消除策略的改进算法。针对图像去雾后天空灰暗的问题,基于大气光自适应校正与透射率鲁棒性优化的去雾方法(沈逸云等,2017a)以及基于天空检测与纹理平滑的去雾方法(沈逸云等,2017b)的出现,使得天空区域复原效果更明亮。曹绪民等人(2018)提出了一种基于亮度对比度增强与饱和度补偿的快速图像去雾算法,解决了传统去雾方法存在的恢复质量差和耗时较长等问题。但是,基于大气散射物理模型的传统去雾算法局限于人工有限的观察和总结,研究人员所观察的有限数据不足以涵盖所有现实图像的特征情况,

导致这些去雾算法的泛化性能不高。

受益于深度神经网络的健壮发展,基于深度学习的算法开始广泛应用于图像去雾领域。现有的图像去雾网络架构大多分为基于大气物理模型或基于端到端网络的图像去雾算法,前者主要通过使用估算的大气光和透射率这两个物理参数来重构无雾图像。Li等人(2017)通过变形大气散射模型的公式来预测雾霾图像与无雾图像之间的映射系数,接着将求得的系数重新代入新的物理公式中来得到无雾图像。Zheng等人(2023)根据大气散射模型建立了一个具有物理感知能力的双分支单元,提高了模型对于非均质雾霾图像的去雾效果。由于上述算法往往局限于视为全局常数的大气光值,为此,Liang等人(2024)基于超像素分割,提出了一种大气光照值图融合估计模型以估算更为准确的大气光值。

相较于基于大气散射物理模型的深度学习去雾算法,基于端到端网络的深度学习去雾算法独立于物理模型,能够通过深度神经网络更灵活地学习雾霾图像与无雾图像的映射关系。Qin等人(2020)设计了一种端到端特征融合注意力的神经网络,通过堆叠前一层网络提取的特征信息来直接增强雾霾图像的对比度。除了单一网络结构的应用,两分支网络结构也引起了广泛的关注。Zhang等人(2022)设计了两分支结构的神经网络,一个分支网络估计雾密度图用于辅助另一个分支网络去雾。随着注意力机制在计算机视觉领域的广泛应用,Guo等人(2023)利用图像的亮度差异来限制注意力图,高质量地重建浓雾区域的细节。Chen等人(2024)提出了一种由细节增强卷积和内容引导注意力组成的细节增强注意力块,促进特征学习,提高去雾性能。尽管基于端到端网络的深度学习去雾算法能够生成符合人眼感知的去雾结果,但是在处理雾度变化剧烈的雾霾图像时,这些方法的去雾性能仍存在一定的不足。原因是非均质图像去雾任务涉及图像的对比度增强、纹理细节恢复和颜色复原等问题,仅用单个网络模型无法很好地输出自然的无雾图像。考虑到上述问题,本文设计了结合浓度划分与图像融合的

多分支非均质图像去雾算法及其深度神经网络框架,主要贡献如下:

1)本文认为单幅非均质雾霾图像可以视为由多个具有均质雾霾浓度的局部区域组成,可以通过分别解决单幅非均质雾图中的不同均质雾霾区域来完成整幅非均质图像的去雾任务。

2)设计了图像增强网络(image enhancement network, IENet)。针对不同均质雾霾浓度的图像,分别训练不同增强强度的 IENet 模型。每个 IENet 模型对于相应雾霾浓度的图像区域具有较好的增强效果。

3)设计了图像融合网络(image fusion network,

IFNet)。由于单个 IENet 模型只能较好地增强一幅非均质雾霾图像中对应雾霾浓度的均质雾霾图像区域,对其余不同雾霾浓度的图像区域可能存在去雾力度不足或者过度增强的现象,因此本文通过 IFNet 将多个初始图像增强结果中的优势区域进行融合,得到最终图像去雾结果。

图 1 展示了不同图像增强模型在不同雾霾浓度的图像上的测试结果。

1 算法动机

为了训练不同增强强度的图像增强模型 IENet




图 1 不同图像增强模型在不同雾霾浓度的图像上的测试结果
Fig. 1 Test results of different image enhancement models on hazy images with different haze concentrations

(image ehancement network), 本文需要雾霾浓度不同的均质雾霾图像。为此, 本文采用了 Liu 等人 (2022) 提出的 FiveK-Haze 数据集。FiveK-Haze 数据集基于大气散射物理模型, 通过改变图像的透射率, 合成了 9 种不同雾霾浓度的均质雾霾图像去雾数据集 $H_i (i \in \{1, 2, \dots, 9\})$, 共计 46 004 对雾霾图像与无雾图像。对于 FiveK-Haze 数据集, 还可以根据透射率的大小将邻近浓度的雾霾图像进行合并, 生成涵盖更大雾霾浓度范围的均质去雾数据集。为了验证 IENet 的可行性, 本文将这 9 个不同雾霾浓度的去雾数据集分别输入相同的 U-Net (Ronneberger 等, 2015) 网络结构并在重建损失 (Girshick, 2015) 的约束之下进行网络参数的训练, 以获得相应的 9 个图像增强模型 $m_i (i \in \{1, 2, \dots, 9\})$, 并将这些针对不同雾霾浓度的图像增强模型在各个不同雾霾浓度数据集上进行测试。通过实验本文发现均质雾霾图像数据集 H_1 的雾霾浓度过于极端, 去雾难度也很大。由 H_1 训练得来的图像增强模型 m_1 在其他雾霾浓度数据集上进行去雾, 极易产生过增强的现象。因此, H_1 不参与后续实验, 只保留 FiveK-Haze 数据集中剩余 8 种浓度的雾霾图像数据集。

通过上述实验可知, 基于不同雾霾浓度的均质雾霾图像数据集的模型训练, 可以得到不同增强强度的图像增强模型。利用这一点, 可以训练针对不同均质雾霾浓度图像的 IENet 模型。

2 本文方法

2.1 网络框架

基于上述实验与观察, 本文设计了结合浓度划分与图像融合的多分支图像去雾神经网络 (concen-

tration partitioning and image fusion based multi-branch image dehazing neural network, CPIFNet)。CPIFNet 网络框架如图 2 所示, 它整体上使用了两阶段的网络框架, 即图像增强阶段和图像融合阶段。




图 2 本文提出的总体网络框架
Fig. 2 The proposed overall network architecture

2.1.1 图像增强网络

在图像增强阶段, 本文将尺寸为 256×256 像素的雾霾图像 I 输入到图像增强网络 IENet 中, 连续提取深度特征并堆叠得到雾霾图像的增强结果。如图 3 所示, 图像增强网络 IENet 首尾的卷积层使用大小为 5×5 、填充为 2 和步长为 1 的卷积核, 其中, 首个卷积层的输入通道为 3、输出通道为 16; 最后一个卷积层的输入通道为 32、输出通道为 3。这样的设置能够维持特征信息传递的尺寸大小。为了加快网络训练收敛速度以及避免特征层传递负值, 本文在每层卷积层后均使用了 ReLU (rectified linear unit) 激活函数。除了首尾是普通卷积层外, 本文将其余网络层替换成残差模块来提取深度特征信息以及缓解梯度消失的问题。每个残差模块都使用 3 个卷积组, 每个卷积组都由一个尺寸为 3×3 、步长为 1 和填充为 1




图 3 图像增强网络 IENet 框架
Fig. 3 The architecture of image enhancement network IENet

的卷积层和ReLU激活函数组成。最后一个卷积组之后,本文增加了一个尺寸为 3×3 、步长为1和填充为1的卷积层,并且该层的输出特征与残差模块的输入特征相加来进一步增强特征表示。残差模块的输出通道均为16。对于图像增强网络,可以表达为

$$R = IENet(I) \quad (2)$$

$$J_E = R \times I \quad (3)$$

式中, I 表示雾霾图像, J_E 表示图像增强结果, R 表示图像增强模型的拉伸系数, $IENet(\cdot)$ 表示图像增强模型。

2.1.2 图像融合网络

在图像融合阶段,本文首先将 n 个 256×256 像素的初始图像增强结果 $J_i (i \in \{1, 2, \dots, n\})$ 输入到图像融合网络IFNet中,再分别连续提取 n 组深度特征,最后通过堆叠深度特征来得到去雾结果。在图像融合网络中,所有的卷积模块都由大小为 3×3 、步长为1和填充为1的卷积层以及ReLU激活函数

层组成。如图4所示,每个通道数为3的初始图像增强结果首先经过一组卷积模块的特征提取尺寸不变且通道数为16的特征信息;接着,每组卷积模块输出通过连续3个卷积模块提取尺寸和通道数不变的深度特征信息,并且每一个提取的深度特征都在深度通道上进行堆叠,得到4个通道为 $n \times 16$ 的中间特征信息。为了减少参数计算量,本文将第4个通道数为 $n \times 16$ 的中间特征信息通过卷积模块降低通道维数提取通道数为16的特征信息。最后,该特征信息依次与前一个中间特征进行堆叠后,通过卷积模块输出降低通道数至16且融合前一层的有效信息。其中,最后一层卷积模块的输出通道数设置为3,可以得到最终的图像去雾结果。对于图像融合网络,可以表达为

$$J_f = IFNet(J_1, J_2, \dots, J_i), i \in \{1, 2, \dots, n\} \quad (4)$$

式中, J_f 表示图像融合结果, J_i 表示第 i 个图像增强结果, $IFNet(\cdot)$ 表示图像融合模型。




图4 图像融合网络IFNet框架

Fig. 4 The architecture of image fusion network IFNet

2.2 损失函数

本文的图像增强网络IENet与图像融合网络IFNet均采用重建损失 L_m (Girshick, 2015)、感知损失 L_p (Johnson等, 2016)、结构损失 L_s (Wang等, 2004)和颜色损失 L_c (Tang等, 2023)来约束网络模块的图像去雾结果。最终的损失函数记为 L ,计算为

$$L = L_m + L_p + L_s + L_c \quad (5)$$

式中, L_m 负责约束每一轮网络模块训练的图像去雾结果与相应的参考图像的差异程度; L_p 负责约束图像去雾结果与参考图像的语义特征相似性和感知误

差大小; L_s 负责约束图像去雾结果和参考图像之间的结构差异; L_c 负责引导图像去雾结果的颜色向参考图像靠近。

重建损失 L_m 将每一轮网络模块训练得到的图像去雾结果与相应的参考图像进行像素级的约束。重建损失计算为

$$L_m(J, Y) = |J - Y| \quad (6)$$

式中, J 和 Y 表示图像去雾结果和参考图像。

为了使图像去雾结果与参考图像具有更相近的语义特征以及更小的感知误差,本文设计了感知损

失 L_p 。将图像去雾结果与参考图像分别通过 VGG (Visual Geometry Group) 网络 (Simonyan 和 Zisserman, 2015) 的 ReLU1_2、ReLU2_2、ReLU3_3 和 ReLU4_3 层来提取不同网络层输出的特征信息,并在两者间建立起感知损失,具体为

$$L_p = \sum_{l \in \{1,2,3,4\}} \frac{1}{S_l} \|\Phi_l(J) - \Phi_l(Y)\|_2 \quad (7)$$

式中, S_l 表示 VGG 网络模型中第 l 个特征提取器 $\Phi_l(\cdot)$ 输出的特征图大小。

为了提高图像去雾结果的结构对比度且不过度增强,本文使用结构损失 L_s 来约束图像去雾结果和参考图像之间的结构差异,具体为

$$L_s(J, Y) = 1 - SSIM(J, Y) \quad (8)$$

式中, $SSIM(\cdot)$ 表示结构相似度函数 (Wang 等, 2004)。

颜色损失 L_c 通过计算两幅图像中像素向量夹角的余弦值大小来衡量图像间的颜色相似度。对于像素信息损失严重的浓雾图像来说,颜色恢复极其困难。因此,本文使用颜色损失来引导图像去雾结果的颜色向参考图像靠近,具体为

$$L_c(J, Y) = \sum_{p=1}^N CA(J(p), Y(p)) \quad (9)$$

式中, p 表示图像中的像素位置, N 表示单幅图像中的像素个数, $CA(\cdot)$ 表示将两幅图像中 p 的 RGB 值视为空间向量来计算颜色之间夹角的余弦值大小。

3 实验与分析

3.1 训练细节

本文的模型训练和测试都是在单个 NVIDIA GTX 2080Ti GPU 上使用 PyTorch 框架执行的。至于本文提出的结合浓度划分与图像融合的多分支去雾神经网络 CPIFNet, 它由 ADAM 优化器 (Kingma 和 Ba, 2017) 在 $\beta_1 = 0.9$ 、 $\beta_2 = 0.999$ 和批量大小为 22 的情况下进行 100 轮训练。本文设置初始学习率为 0.001, 衰减率为每 10 轮衰减 50%。

3.2 评价指标

除了峰值信噪比 (peak signal-to-noise ratio, PSNR)、结构相似性 (structural similarity index, SSIM) (Wang 等, 2004) 两个有参考指标外, 还采用了无参考指标 FADE (fog aware density evaluator) (Choi 等, 2015)、HazDes (haze density) (Zhang 等,

2022) 对所有方法在合成雾霾数据集 FiveK-Haze 和真实雾霾数据集 Real-World (Li 等, 2019) 上的去雾性能进行定量评估。FADE 的值越大表示图像中的雾霾浓度越浓。HazDes 的数值都在 $[0, 1]$ 范围内, 其值越大表示图像中的雾霾浓度越浓。

3.3 实验结果

为了验证本文算法的去雾性能, 本文与几种先进的图像去雾方法进行了广泛的主观与客观比较。为了公平起见, 使用作者提供的网络结构和最优参数设置来获得去雾结果。表 1 展示了不同去雾算法在合成数据集 FiveK-Haze 和真实世界雾霾图像数据集 Real-World 上的性能指标。

图 5 展示了不同去雾算法在 Real-World 数据集上的测试结果。与已有方法相比, 本文算法可以在保持薄雾区域不过度增强的前提下, 增强浓雾区域的结构对比度以及景物清晰度, 使得图像去雾结果更加符合人眼视觉感知。在合成雾霾数据集 FiveK-Haze 上, 本文算法与排名第 2 的 SCAN (self-paced semi-curricular attention network) 方法相比, 在 PSNR 和 SSIM 有参考指标上分别提高了 5.286 6 dB 和 0.113 8; 在真实雾霾数据集 Real-World 上, 本文算法与排名第 2 的 DEAN (detail-enhanced convolution and content-guided attention network) 方法相比, 在 FADE 和 HazDes 无参考指标上分别降低了 0.079 3 和 0.051 2。此外, 本文也在公开数据集 RESIDE (realistic single image dehazing) (Li 等, 2019) 上进行了算法性能比较。本文首先在室内训练数据集 RESIDE-ITS 和室外训练数据集 RESIDE-OTS 上进行训练微调之后, 再分别在室内测试数据集 SOTS-indoor 和室外测试数据集 SOTS-outdoor 上进行了性能测试。

表 2 展示了不同去雾算法在 SOTS (synthetic objective testing set)-indoor 和 SOTS-outdoor 数据集上的性能指标。在室内合成测试数据集 SOTS-indoor 上, 本文算法的 PSNR 和 SSIM 指标比排名第 2 的 DeFormer 方法分别提高了 2.518 2 dB 和 0.012 3。在室外合成测试数据集 SOTS-outdoor 上, 本文算法在 PSNR 指标上比排名第 2 的 SGID-PFF 方法提高了 2.832 dB, 在 SSIM 指标上比排名第 2 的 DeFormer 方法提高了 0.023 8。图 6 展示了不同去雾算法在 SOTS-indoor 和 SOTS-outdoor 数据集上的测试结果。

表 3 展现了不同去雾算法的参数数量和单幅

表 1 在 FiveK-Haze 和 Real-World 数据集上不同去雾算法的性能指标
Table 1 The performance of different dehazing algorithms on the FiveK-Haze and Real-World datasets

算法	FiveK-Haze		Real-World	
	PSNR/dB	SSIM	FADE	HazDes
AOD(Li 等,2017)	14.399 0	0.632 2	0.471 3	0.192 7
EPDN(Qu 等,2019)	16.796 5	0.742 1	0.382 3	0.193 4
FFA(Qin 等,2020)	12.895 2	0.595 0	0.637 9	0.248 5
DMPHN(Das 和 Dutta,2020)	9.266 7	0.537 3	0.410 9	0.190 6
LDN(Ullah 等,2021)	11.886 5	0.334 5	0.462 1	0.200 7
TBN(Yu 等,2021)	9.485 7	0.589 4	0.644 4	0.311 5
4KDN(Zheng 等,2021)	13.265 6	0.557 8	0.598 2	0.231 0
SGID-PFF(Bai 等,2022)	13.791 0	0.581 9	0.443 7	0.190 7
SCAN(Guo 等,2023)	18.621 3	0.795 3	0.372 4	0.184 4
DEAN(Chen 等,2024)	17.254 8	0.758 7	0.346 8	0.181 7
CPIFNet(本文)	23.907 9	0.909 1	0.267 5	0.130 5

注:加粗字体表示各列最优结果,AOD(all-in-one dehazing network);EPDN(enhacend pix2pix dehazing network);FFA(feature fusion attention network);DMPHN(deep multi-patch hierarchical network);LDN(light-weight dehazing network);TBN(two-branch dehazing network);4KDN(4K-image dehazing network);SGID-PFF(self-guided image dehazing using progressive feature fusion);SCAN(self-paced semi-curricular attention network);DEAN(detail-enhanced convolution and content-guided attention network)。




图 5 不同去雾算法在 Real-World 数据集上的测试结果

Fig. 5 Test results of different defogging algorithms on the Real-World dataset

256 × 256 像素测试图像上的运行时间。不难看出,在模型参数量和运算速度方面,本文算法与现有方法相比处于中间位次,与轻量级的模型和方法相比存在一定的差距,这为我们后续进一步优化算法的

性能指明了方向。

3.4 消融实验

3.4.1 雾霾浓度划分的数量

由于FiveK-Haze数据集中不同均质雾霾浓度图

表2 在SOTS-indoor和SOTS-outdoor数据集上不同去雾算法的性能指标
Table 2 The performance of different dehazing algorithms on the SOTS-indoor and SOTS-outdoor datasets

算法	SOTS-indoor		SOTS-outdoor	
	PSNR/dB	SSIM	PSNR/dB	SSIM
AOD(Li 等,2017)	17.399 0	0.854 7	20.937 1	0.914 6
GDN(Liu 等,2019)	13.200 0	0.510 8	0.400 4	0.192 7
LDN(Ullah 等,2021)	13.325 6	0.306 0	19.185 1	0.861 9
TBN(Yu 等,2021)	9.485 7	0.589 4	8.776 4	0.424 9
MSS(Jo 和 Sim,2021)	15.035 7	0.680 1	17.846 8	0.837 8
DSS(Li 等,2022)	18.038 3	0.881 3	25.883 6	0.946 5
SGID-PFF(Bai 等,2022)	20.815 9	0.939 6	28.232 1	0.947 8
SCAN(Guo 等,2023)	20.226 1	0.912 6	22.516 8	0.941 2
DeFormer(Song 等,2023)	20.909 9	0.958 9	24.367 6	0.956 3
CPIFNet(本文)	23.428 1	0.971 2	31.064 1	0.980 1

注:加粗字体表示各列最优结果。




图6 不同去雾算法在SOTS-indoor与SOTS-outdoor数据集上的测试结果

Fig. 6 Test results of different dehazing algorithms on the SOTS-indoor and SOTS-outdoor datasets

像是基于大气散射物理模型通过修改图像透射率合成的,本文将均质去雾数据集 $H_i(i \in \{2,3,\cdots,9\})$ 中相近雾霾浓度的数据集进行合并,重新划分成 $n(0 < n \leq 8)$ 种不同雾霾浓度的均质去雾数据集。对于 n 个合成去雾数据集, n 的取值不仅代表雾霾浓度划分数量,而且还代表对应雾霾浓度的图像增强模型的个数。表4展示了不同划分数量的雾霾浓度与

对应的透射率取值分布。

表5展示了不同浓度划分数量的CPIFNet在合成雾霾数据集FiveK-Haze和真实雾霾数据集Real-World上的指标性能。当与雾霾浓度划分数量 $n = 1$ 的CPIFNet相比较,可以验证本文算法的有效性。当雾霾浓度的划分数量增大时,整体指标都略低于 $n = 2$ 的CPIFNet。证明了雾霾浓度划分更精细的去

表 3 不同去雾算法的参数数量和单幅 256×256 像素测试图像上的运行时间
Table 3 Parameters and running time on single 256×256 test image of different dehazing algorithms

算法	参数量	运行时间/s
AOD(Li 等, 2017)	1.70 K	0.003
LDN(Ullah 等, 2021)	3.11 M	0.038
TBN(Yu 等, 2021)	7.02 M	0.089
4KDN(Zheng 等, 2021)	6.41 M	0.025
SGID-PFF(Bai 等, 2022)	13.87 M	0.124
SCAN(Guo 等, 2023)	2.39 M	0.016
CPIFNet(本文)	6.82 M	0.050

注:加粗字体表示各列最优结果。

表 4 不同浓度划分数量与透射率取值分布之间的关系
Table 4 The relationship between the concentration partitioning number and the transmittance value distribution

划分数量	透射率取值分布
$n = 1$	{0.02,0.04,0.06,0.09,0.14,0.22,0.36,0.57,0.99}
$n = 2$	{0.02,0.04,0.06,0.09,0.14}, {0.14,0.22,0.36,0.57,0.99}
$n = 3$	{0.02,0.04,0.05,0.07}, {0.07,0.11,0.18,0.27}, {0.27,0.42,0.64,0.99}
$n = 4$	{0.02,0.04,0.06}, {0.06,0.09,0.14}, {0.14,0.22,0.36}, {0.36,0.57,0.99}
$n = 5$	{0.02,0.03,0.04}, {0.04,0.06,0.1}, {0.1,0.14,0.21}, {0.21,0.31,0.45}, {0.45,0.74,0.99}

雾数据集并不能够让网络模型学习到更详尽的雾霾图像。

为了验证 FiveK-Haze 数据集中均质雾霾图像数据集 H_1 不利于网络训练, 本文将 H_1 内的图像归入透射率取值区 {0.02, 0.04, 0.06, 0.09, 0.14} 中, 将在此数据集上训练的图像增强模型称为 IENet_1^* 。图 7 展示了均质雾霾图像数据集 H_1 对于 IENet 的影响。 IENet_1^* 的图像去雾结果出现了明显的瑕疵与失真, 而 IENet_1 尽量维持原有图像的结构信息。该结果再次验证了均质雾霾图像数据集 H_1 不利于参与本文实验。

3.4.2 图像融合方法比较

不同的图像融合方法能够影响神经网络的去雾效果, 本文比较了常用的图像权重融合方法和图像

表 5 不同浓度划分数量的 CPIFNet 性能指标
Table 5 CPIFNet performance with different concentration partitioning numbers

划分数量	神经网络	PSNR/dB	SSIM	FADE	HazDes
$n = 1$	IENet_1	17.74	0.79	0.30	0.19
	IENet_1	17.37	0.75	0.39	0.20
$n = 2$	IENet_2	18.13	0.73	0.23	0.14
	IFNet	23.91	0.91	0.27	0.13
$n = 3$	IENet_1	16.90	0.67	0.44	0.22
	IENet_2	17.08	0.72	0.38	0.14
	IENet_3	18.04	0.65	0.49	0.36
	IFNet	19.25	0.76	0.34	0.17
$n = 4$	IENet_1	14.90	0.58	0.82	0.26
	IENet_2	14.44	0.54	0.99	0.29
	IENet_3	14.82	0.60	0.53	0.20
	IENet_4	13.63	0.60	0.71	0.27
$n = 5$	IFNet	15.12	0.61	0.62	0.21
	IENet_1	14.80	0.54	1.15	0.29
	IENet_2	14.78	0.58	0.41	0.25
	IENet_3	15.08	0.58	0.54	0.22
	IENet_4	14.78	0.63	0.45	0.21
	IENet_5	13.33	0.60	0.75	0.28
	IFNet	15.54	0.64	0.52	0.21

注:加粗字体表示各列最优结果。




图 7 均质雾霾图像数据集 H_1 对于 IENet 的影响
Fig. 7 The impact of homogeneous hazy image dataset H_1 on IENet ((a) hazy images; (b) IENet_1^* ; (c) IENet_1)

堆叠融合方法对图像融合网络 IFNet 的影响。图像权重融合方法中 IFNet 最后一层使用 sigmoid 激活函数并输出两通道的权重图用于权重相加来估计最终结果, 而图像堆叠融合方法中 IFNet 最后一层使用

ReLU 激活函数并输出三通道作为最终的图像去雾结果。表6展示了图像堆叠融合方法在合成雾图和真实雾图的性能指标,不难看出堆叠融合方法的性能指标明显优于图像权重融合方法。

表6 在FiveK-Haze和Real-World数据集上基于不同融合方法的IFNet性能指标
Table 6 IFNet performance with different fusion methods on FiveK-Haze and Real-World datasets

融合方法	PSNR/dB	SSIM	FADE	HazDes
堆叠融合	23.907 9	0.909 1	0.267 5	0.130 5
权重融合	18.963 2	0.825 1	0.287 5	0.131 5

注:加粗字体表示各列最优结果。

3.4.3 网络结构细节比较

由于更大尺寸的卷积核能够拥有更大的感知野,从而使得神经网络能够从相邻的像素信息中判断需要学习的映射关系。因此,本文比较了使用不同卷积核大小的图像增强网络IENet对去雾结果的影响。IENet-k3、IENet-k5、IENet-k7、IENet-k9、IENet-res 分别表示使用尺寸大小为 3×3 、 5×5 、 7×7 、 9×9 的卷积核以及残差模块的图像增强网络IENet。表7展示了基于FiveK-Haze数据集训练的IENet-k3、IENet-k5、IENet-k7、IENet-k9、IENet-res 在均质去雾数据集FiveK-Haze的测试集和真实的有雾数据集Real-World上的性能指标。从表7可以看出,本文使用残差模块的算法能够有效地提升去雾效果的性能指标,其主要原因是由于加深的神经网络提升了网络学习的性能和残差结构缓解了随着网

表7 在FiveK-Haze和Real-Worlds数据集上不同结构的图像增强网络的性能指标
Table 7 Image enhancement networks performance with different structures on FiveK-Haze and Real-World datasets

图像增强网络结构	PSNR/dB	SSIM	FADE	HazDes
IENet-k3	16.890 7	0.724 4	0.489 1	0.194 5
IENet-k5	17.369 3	0.748 2	0.488 5	0.192 5
IENet-k7	17.280 9	0.725 0	0.489 1	0.192 1
IENet-k9	17.069 1	0.713 0	0.490 2	0.193 8
IENet-res	17.737 5	0.787 8	0.209 5	0.193 7

注:加粗字体表示各列最优结果。

络加深而丢失特征信息的问题。

3.4.4 颜色损失的有效性

由于浓雾区域图像中像素信息损失严重的情况,导致恢复颜色变得十分困难。因此,本文利用颜色损失来指导图像去雾结果向参考图像的颜色逼近。为了验证颜色损失的有效性,本文将使用颜色损失的CPIFNet称为CPIFNet(w/L_c),将未使用颜色损失训练的CPIFNet称为CPIFNet(w/oL_c)。表8展示了CPIFNet(w/L_c)和CPIFNet(w/oL_c)在合成雾图以及真实雾图上的性能指标。不难看出,CPIFNet(w/L_c)在合成雾图和真实雾图的性能指标明显优于CPIFNet(w/oL_c)。

表8 在FiveK-Haze和Real-World数据集上基于不同损失函数的CPIFNet性能指标
Table 8 CPIFNet performance with different loss functions on FiveK-Haze and Real-World datasets

损失函数	神经网络	PSNR/dB	SSIM	FADE	HazDes
CPIFNet(w/L_c)	IENet ₁	15.62	0.69	0.43	0.18
	IENet ₂	18.03	0.70	0.27	0.10
	IFNet	19.43	0.80	0.29	0.16
CPIFNet(w/oL_c)	IENet ₁	17.37	0.75	0.39	0.20
	IENet ₂	18.13	0.73	0.23	0.14
	IFNet	23.91	0.91	0.27	0.13

注:加粗字体表示各列最优结果。

4 结 论

为了进一步提升神经网络对于非均质雾霾图像的去雾效果,本文将非均质雾霾图像视为多个具有均质薄雾或者均质浓雾的局部区域组成,通过分别解决单幅非均质雾图中的不同均质雾霾区域来进行整幅非均质图像去雾,为此提出了结合浓度划分与图像融合的多分支非均质图像去雾算法及其深度神经网络。首先在不同均质雾霾浓度的去雾数据集上训练了多个图像增强网络,以得到针对不同均质雾霾浓度的图像增强模型,它们对于相应雾霾浓度的图像区域具有较好的增强性能。由于单个图像增强网络只能够较好地增强一幅非均质雾霾图像中具有对应部分的均质雾霾浓度图像区域,对其余区域可能存在去雾力度不足或者过度增强的现象。因此,

本文又设计了一个图像融合网络,将多个初始图像增强结果中的优势区域进行融合,得到最终的图像去雾结果。相较其他算法,本文算法的去雾效果优势明显,具有更高的鲁棒性,展现了较好的性能指标。

考虑到本文算法与已有图像去雾方法相比在模型参数量和计算速度方面处于中间位次,针对非均质图像去雾任务的模型简化和加速策略将是下一个研究方向。另外,针对非均质图像去雾任务,进行困难样本挖掘,进一步提升模型在浓度较高的雾霾图像和跨域数据集上的性能表现将是下一步的另一个研究方向。

参考文献(References)

- Bai H R, Pan J S, Xiang X G and Tang J H. 2022. Self-guided image dehazing using progressive feature fusion. *IEEE Transactions on Image Processing*, 31: 1217-1229 [DOI: 10.1109/TIP.2022.3140609]
- Cao X M, Liu C X, Zhang J D, Lin Y H and Zhao J W. 2018. Fast image defogging algorithm based on luminance contrast enhancement and saturation compensation. *Journal of Computer-Aided Design and Computer Graphics*, 30(10): 1925-1934 (曹绪民, 刘春晓, 张金栋, 林宇航, 赵锦威. 2018. 基于亮度对比度增强与饱和度补偿的快速图像去雾算法. *计算机辅助设计与图形学学报*, 30(10): 1925-1937) [DOI: 10.3724/SP.J.1089.2018.17000]
- Chen Z X, He Z W and Lu Z M. 2024. DEA-Net: single image dehazing based on detail-enhanced convolution and content-guided attention. *IEEE Transactions on Image Processing*, 33: 1002-1015 [DOI: 10.1109/TIP.2024.3354108]
- Choi L K, You J and Bovik A C. 2015. Referenceless prediction of perceptual fog density and perceptual image defogging. *IEEE Transactions on Image Processing*, 24(11): 3888-3901 [DOI: 10.1109/TIP.2015.2456502]
- Das S D and Dutta S. 2020. Fast deep multi-patch hierarchical network for nonhomogeneous image dehazing//*Proceedings of 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. Seattle, USA: IEEE: 1994-2001 [DOI: 10.1109/CVPRW50498.2020.00249]
- Girshick R. 2015. Fast R-CNN//*Proceedings of 2015 IEEE International Conference on Computer Vision*. Santiago, Chile: IEEE: 1440-1448 [DOI: 10.1109/ICCV.2015.169]
- Guo Y, Gao Y, Liu R W, Lu Y X, Qu J X, He S F and Ren W Q. 2023. SCANet: self-paced semi-curricular attention network for non-homogeneous image dehazing//*Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. Vancouver, Canada: IEEE: 1885-1894 [DOI: 10.1109/CVPRW59228.2023.00186]
- Jo E and Sim J Y. 2021. Multi-scale selective residual learning for non-homogeneous dehazing//*Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. Nashville, USA: IEEE: 507-515 [DOI: 10.1109/CVPRW53098.2021.00062]
- Johnson J, Alahi A and L F F. 2016. Perceptual losses for real-time style transfer and super-resolution//*Proceedings of the 14th European Conference on Computer Vision*. Amsterdam, the Netherlands: Springer: 694-711 [DOI: 10.1007/978-3-319-46475-6_43]
- Kingma D P and Ba J L. 2017. Adam: a method for stochastic optimization [EB/OL]. [2024-05-02]. <https://arxiv.org/pdf/1412.6980.pdf>
- Li B Y, Peng X L, Wang Z Y, Xu J Z and Feng D. 2017. AOD-Net: all-in-one dehazing network//*Proceedings of 2017 IEEE International Conference on Computer Vision*. Venice, Italy: IEEE: 4780-4788 [DOI: 10.1109/ICCV.2017.511]
- Li B Y, Ren W Q, Fu D P, Tao D C, Feng D, Zeng W J and Wang Z Y. 2019. Benchmarking single-image dehazing and beyond. *IEEE Transactions on Image Processing*, 28(1): 492-505 [DOI: 10.1109/TIP.2018.2867951]
- Li Z G, Zheng C B, Shu H Y and Wu S Q. 2022. Dual-scale single image dehazing via neural augmentation. *IEEE Transactions on Image Processing*, 31: 6213-6223 [DOI: 10.1109/TIP.2022.3207571]
- Liang S, Gao T, Chen T and Cheng P. 2024. A remote sensing image dehazing method based on heterogeneous priors. *IEEE Transactions on Geoscience and Remote Sensing*, 62: #5619513 [DOI: 10.1109/TGRS.2024.3379744]
- Liu C X, Ye S S, Zhang L D, Bao H Y, Wang X and Wu F D. 2022. Non-homogeneous haze data synthesis based real-world image dehazing with enhancement-and-restoration fused CNNs. *Computers and Graphics*, 106: 45-57 [DOI: 10.1016/j.cag.2022.05.008]
- Liu X H, Ma Y R, Shi Z H and Chen J. 2019. GridDehazeNet: attention-based multi-scale network for image dehazing//*Proceedings of 2019 IEEE/CVF International Conference on Computer Vision (ICCV)*. Seoul, Korea (South): IEEE: 7313-7322 [DOI: 10.1109/ICCV.2019.00741]
- Narasimhan S G and Nayar S K. 2000. Chromatic framework for vision in bad weather//*Proceedings of 2000 IEEE Conference on Computer Vision and Pattern Recognition*. Hilton Head, USA: IEEE: 598-605 [DOI: 10.1109/CVPR.2000.855874]
- Qin X, Wang Z L, Bai Y C, Xie X D and Jia H Z. 2020. FFA-Net: feature fusion attention network for single image dehazing//*Proceedings of the 34th AAAI Conference on Artificial Intelligence*. New York, USA: AAAI Press: 11908-11915 [DOI: 10.1609/aaai.v34i07.6865]
- Qu Y Y, Chen Y Z, Huang J Y and Xie Y. 2019. Enhanced pix2pix dehazing network//*Proceedings of 2019 IEEE/CVF Conference on*

- Computer Vision and Pattern Recognition. Long Beach, USA: IEEE: 8152-8160 [DOI: 10.1109/CVPR.2019.00835]
- Ronneberger O, Fischer P and Brox T. 2015. U-net: convolutional networks for biomedical image segmentation//Proceedings of the 18th International Conference on Medical Image Computing and Computer-assisted Intervention. Munich, Germany: Springer: 234-241 [DOI: 10.1007/978-3-319-24574-4_28]
- Shen Y Y, Liu C X, Zhang J D, Shao Y Q and Zhao J W. 2017a. Atmospheric light correction and transmission optimization based robust image dehazing. Journal of Computer-Aided Design and Computer Graphics, 29(9): 1604-1612 (沈逸云, 刘春晓, 张金栋, 邵雅琪, 赵锦威. 2017a. 鲁棒图像去雾的大气光校正与透射率优化算法. 计算机辅助设计与图形学学报, 29(9): 1604-1612) [DOI: 10.3724/SP.J.1089.2017-00449]
- Shen Y Y, Shao Y Q, Liu C X, Zhou H J and Zhao J W. 2017b. Integrating sky detection with texture smoothing for image defogging. Journal of Image and Graphics, 22(7): 897-905 (沈逸云, 邵雅琪, 刘春晓, 周华健, 赵锦威. 2017b. 结合天空检测与纹理平滑的图像去雾. 中国图象图形学报, 22(7): 897-905) [DOI: 10.11834/jig.170030]
- Simonyan K and Zisserman A. 2015. Very deep convolutional networks for large-scale image recognition [EB/OL]. [2024-05-02]. <https://arxiv.org/pdf/1409.1556.pdf>
- Song Y D, He Z Q, Qian H and Du X. 2023. Vision transformers for single image dehazing. IEEE Transactions on Image Processing, 32: 1927-1941 [DOI: 10.1109/TIP.2023.3256763]
- Tang L F, Xiang X Y, Zhang H, Gong M Q and Ma J Y. 2023. DIVFusion: darkness-free infrared and visible image fusion. Information Fusion, 91: 477-493 [DOI: 10.1016/j.inffus.2022.10.034]
- Ullah H, Muhammad K, Irfan M, Anwar S, Sajjad M, Imran A S and De Albuquerque V H C. 2021. Light-DehazeNet: a novel light-weight CNN architecture for single image dehazing. IEEE Transactions on Image Processing, 30: 8968-8982 [DOI: 10.1109/TIP.2021.3116790]
- Wang Z, Bovik A C, Sheikh H R and Simoncelli E P. 2004. Image quality assessment: from error visibility to structural similarity. IEEE Transactions on Image Processing, 13(4): 600-612 [DOI: 10.1109/TIP.2003.819861]
- Yu Y K, Liu H, Fu M H, Chen J, Wang X Y and Wang K Y. 2021. A two-branch neural network for non-homogeneous dehazing via ensemble learning//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Nashville, USA: IEEE: 193-202 [DOI: 10.1109/cvprw53098.2021.00028]
- Zhang J H, Min X K, Zhu Y C, Zhai G T, Zhou J T, Yang X K and Zhang W J. 2022. HazDesNet: an end-to-end network for haze density prediction. IEEE Transactions on Intelligent Transportation Systems, 23(4): 3087-3102 [DOI: 10.1109/TITS.2020.3030673]
- Zhao J W, Shen Y Y, Liu C X and Ouyang Y. 2016. Dark channel prior-based image dehazing with atmospheric light validation and halo elimination. Journal of Image and Graphics, 21(9): 1221-1228 (赵锦威, 沈逸云, 刘春晓, 欧阳毅. 2016. 暗通道先验图像去雾的大气光校验和光晕消除. 中国图象图形学报, 21(9): 1221-1228) [DOI: 10.11834/jig.20160911]
- Zheng Y, Zhan J H, He S F, Dong J Y and Du Y. 2023. Curricular contrastive regularization for physics-aware single image dehazing//Proceedings of 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE: 5785-5794 [DOI: 10.1109/CVPR52729.2023.00560]
- Zheng Z R, Ren W Q, Cao X C, Hu X B, Wang T, Song F L and Jia X Y. 2021. Ultra-high-definition image dehazing via multi-guided bilateral learning//Proceedings of 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Nashville, USA: IEEE: 16180-16189 [DOI: 10.1109/CVPR46437.2021.01592]

作者简介

金鑫乐,男,本科生,主要研究方向为图像增强与复原技术。

E-mail: 2112190125@pop.zjgsu.edu.cn

刘春晓,通信作者,男,副教授,主要研究方向为计算机视觉与计算机图形学、机器学习与智能系统。

E-mail: cxliu@mail.zjgsu.edu.cn

叶爽爽,女,硕士研究生,主要研究方向为机器学习与计算机视觉。E-mail: 20020100039@pop.zjgsu.edu.cn

王成骅,男,本科生,主要研究方向为机器学习与计算机视觉。E-mail: 2012190218@pop.zjgsu.edu.cn

周子翔,男,本科生,主要研究方向为机器学习与计算机视觉。E-mail: 2011080223@pop.zjgsu.edu.cn