

4-15-2024

Incremental Image Dehazing Algorithm Based on Multiple Transfer Attention

Jinyang Wei

*Zhengzhou Hengda Intelligent Control Technology Company Limited, Zhengzhou 450000, China,
1020763449@qq.com*

Keping Wang

*School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo 454003, China,
wangkp@hpu.edu.cn*

Yi Yang

School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo 454003, China

Shumin Fei

College of Automation, Southeast University, Nanjing 210096, China

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation. For more information, please contact xtfzxb@126.com.

Incremental Image Dehazing Algorithm Based on Multiple Transfer Attention

Abstract

Abstract: In order to improve the processing ability of the depth-neural network dehazing algorithm to the supplementary data set, and to make the network differently process the image features of different importance to improve the dehazing ability of the network, an incremental dehazing algorithm based on multiple migration of attention is proposed. The teacher's attention generation network in the form of Encoder-Decoder extracts the multiple attention of labels and haze, which is used it as the label of the characteristic migration media network to constrain the network training to form the migration media attention as close as possible to the teacher's attention. The attention is integrated into the characteristics of the student's dehazing network to improve the dehazing ability of the student's dehazing network. The incremental training method is used to improve the processing ability of students' dehazing network to the supplementary data set. The results show that the proposed algorithm has good processing ability on ITS, OTS and real hazy images, and has good dehazing effect while ensuring the integrity of pixel structure and color distortion of the dehazing image. The image processed by the algorithm is superior to the contrast algorithm in subjective visual effect and objective evaluation index.

Keywords

deep learning, image dehazing, transfer attention, incremental training

Recommended Citation

Wei Jinyang, Wang Keping, Yang Yi, et al. Incremental Image Dehazing Algorithm Based on Multiple Transfer Attention[J]. Journal of System Simulation, 2024, 36(4): 969-980.

基于多重迁移注意力的增量式图像去雾算法

韦金阳¹, 王科平^{2*}, 杨艺², 费树岷³(1. 郑州恒达智控科技股份有限公司, 河南 郑州 450000; 2. 河南理工大学 电气工程与自动化学院, 河南 焦作 454003;
3. 东南大学 自动化学院, 江苏 南京 210096)

摘要: 为提高深度神经网络去雾算法对增补数据集的处理能力, 并使网络差异化处理重要程度不同的图像特征以提高网络去雾能力, 提出一种基于多重迁移注意力的增量式去雾算法。通过自编码器形式的教师注意力生成网络提取标签和雾霾的多重注意力, 作为特征迁移媒介网络的标签约束网络训练, 形成与教师注意力尽可能相近的迁移媒介注意力, 并将其融入学生去雾网络的特征中, 提高学生去雾网络的去雾能力; 通过增量式训练方法提高学生去雾网络对增补数据集的处理能力。结果表明: 所提算法对 ITS、OTS 以及真实雾图上皆具有较好的处理能力, 在保证去雾图像像素结构完整、颜色不失真的同时具有较好的去雾效果, 算法处理后的图像在主观视觉效果和客观评价指标上皆优于对比算法。

关键词: 深度学习; 图像去雾; 迁移注意力; 增量式训练

中图分类号: TP391.9 文献标志码: A 文章编号: 1004-731X(2024)04-0969-12

DOI: 10.16182/j.issn1004731x.joss.22-1538

引用格式: 韦金阳, 王科平, 杨艺, 等. 基于多重迁移注意力的增量式图像去雾算法[J]. 系统仿真学报, 2024, 36(4): 969-980.

Reference format: Wei Jinyang, Wang Keping, Yang Yi, et al. Incremental Image Dehazing Algorithm Based on Multiple Transfer Attention[J]. Journal of System Simulation, 2024, 36(4): 969-980.

Incremental Image Dehazing Algorithm Based on Multiple Transfer Attention

Wei Jinyang¹, Wang Keping^{2*}, Yang Yi², Fei Shumin³

(1. Zhengzhou Hengda Intelligent Control Technology Company Limited, Zhengzhou 450000, China; 2. School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo 454003, China; 3. College of Automation, Southeast University, Nanjing 210096, China)

Abstract: In order to improve the processing ability of the depth-neural network dehazing algorithm to the supplementary data set, and to make the network differently process the image features of different importance to improve the dehazing ability of the network, an incremental dehazing algorithm based on multiple migration of attention is proposed. The teacher's attention generation network in the form of Encoder-Decoder extracts the multiple attention of labels and haze, which is used it as the label of the characteristic migration media network to constrain the network training to form the migration media attention as close as possible to the teacher's attention. The attention is integrated into the characteristics of the student's dehazing network to improve the dehazing ability of the student's dehazing network. The incremental training method is used to improve the processing ability of students' dehazing network to the supplementary data set. The results show that the proposed algorithm has good processing ability on ITS, OTS and real hazy images, and has good dehazing effect while ensuring the integrity of pixel structure and color distortion of the dehazing image. The image processed by the algorithm is superior to the

收稿日期: 2022-12-02 修回日期: 2023-04-06

基金项目: 河南省科技攻关(232102210040)

第一作者: 韦金阳(1996-), 男, 硕士, 研究方向为深度学习、图像去雾。E-mail: 1020763449@qq.com

通讯作者: 王科平(1976-), 女, 副教授, 博士, 研究方向为深度学习、图像去雾、模式识别。E-mail: wangkp@hpu.edu.cn

contrast algorithm in subjective visual effect and objective evaluation index.

Keywords: deep learning; image dehazing; transfer attention; incremental training

0 引言

雾霾对光学仪器的成像效果影响很大,大量的细节信息被雾霾掩盖,严重影响图像质量及后期应用。雾霾本质上是非均匀的,造成雾霾在图像中的位置处于随机状态。因此,消除雾霾对图像的影响,实现图像清晰化,是一项重要而艰巨的任务。

目前,国内外学者处理雾霾的方法分为:基于图像增强的去雾算法、基于图像复原的去雾算法和基于深度学习的去雾算法。其中,基于图像增强的去雾方法^[1-2]是通过优化图像的某个特定属性实现图像去雾的,此方法原理简单,处理速度快,但并未考虑图像退化的原理,因此,处理后的图像易丢失像素信息,效果不尽人意。基于图像复原的去雾算法^[3-7]通过提出先验求解物理模型获得清晰图像。这类方法大多基于大气散射模型^[8]进行去雾,相较于基于图像增强的去雾方法,此方法考虑到雾图成像原理,去雾性能有所提高,但在估计中间参数时计算量较大,影响算法的去雾效率,同时参数估计过程中产生的误差叠加到一起,导致处理后的图像出现去雾不完全、颜色失真等现象。基于深度学习的去雾算法通过设计不同的神经网络实现雾图清晰化。此类算法相较于传统算法泛化能力更强,处理后的图像更加清晰自然。文献[9]提出一个不依赖大气散射模型的去雾网络 EPDN(enhanced pix2pix dehazing network)。文献[10]基于稠密残差块与通道像素注意力设计出一种图像去雾网络,取得了良好的去雾效果。

2018年,河南理工大学电气学院人工智能团队建立面向真实场景的雾霾样本库,并以深度神经网络为核心,研究图像去雾算法。文献[11]提出一种基于金字塔多尺度转置卷积网络的图像去雾算法,通过多通道级联结构提取输入图像的多样化特征信息。文献[12]提出一种并联异构双胞胎去

雾算法,特别针对非均匀雾霾图像进行处理,利用增强网络从雾霾图像中提取高频特征以补偿物体的边缘和纹理。

在人的视觉感受中,不同的目标会产生不同的视觉注意力。因此,相同场景的雾霾图像和清晰化标签所表征的视觉注意存在一定差异,且该差异在各个尺度的特征图中均有体现。为此,本文提出一种基于多重迁移注意力的图像去雾算法,以视觉注意力机制为基础,提取清晰化标签和雾霾的各尺度特征图中的注意力先验知识,加强深度神经网络处理雾霾图像通道特征和空间像素时的差异性,提升算法的去雾能力。

另外,神经网络功能的实现需要大量的数据进行训练,且网络性能与训练数据的分布息息相关。在深度学习去雾领域中,不同数据集的图像在光照、场景深度等属性上存在较大的差异,导致已训练完善的神经网络无法较好地处理增补样本。以往算法通常采用增补样本对网络重新训练,这种方法变相地抛弃了网络处理原有数据集的能力,且耗时较长。因此,如何减少网络对原有知识的遗忘,同时提高对增补数据的处理能力,是深度学习领域的难题之一^[13]。为此,本文提出一种增量式训练方法,以教师数据清晰化标签和雾霾分布的注意力先验作为约束,减少网络在增量训练的过程中对教师知识的遗忘。同时,算法采用的增补数据集规模远小于以往算法重新训练所需,从而提高网络训练效率。

1 多重注意力迁移机制及去雾算法

算法总体网络结构如图1所示。图中, C_1 和 C_2 为雾层和标签不同维度的教师通道注意力,标签 S_1 和 S_2 为雾层和标签不同维度的教师空间注意力; C_1^* 和 C_2^* 为雾霾图像不同维度的迁移通道注意力, S_1^* 、 S_2^* 为雾霾图像不同维度的迁移空间注意力。

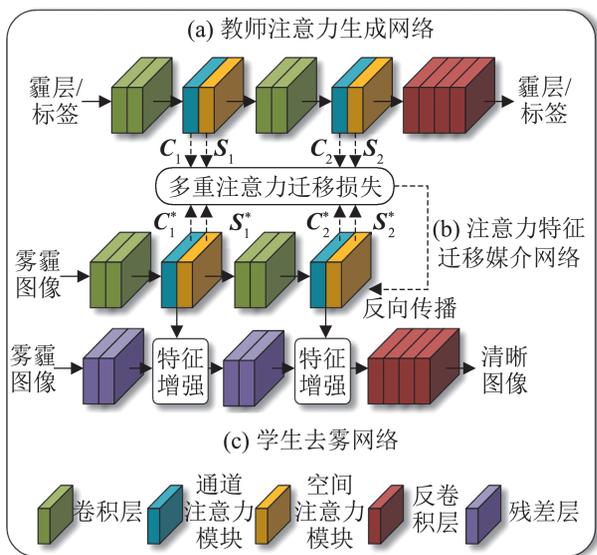


图 1 总体网络结构
Fig. 1 Overall network structure

雾霾在人的视觉感官中呈现明显的分布特征, 当人观察图像时注意力机制会引导人类给与雾霾更多的关注度, 从而更好地获取图像信息。另外, 相较于雾霾图像, 视觉感官可以从清晰图像中获取更加明显的边缘、颜色等特征。因此, 针对雾霾、清晰图像的分布特征, 将视觉注意力抽象成动态机制加入神经网络的训练过程中, 将更有利于网络去除雾霾。图像中雾霾的分布注意力最直接的体现是雾霾图像和清晰标签之间的差值。为此, 本文构建教师注意力生成网络, 分别以清晰标签样本、雾霾图像与标签的差值作为输入, 提取多重注意力信息作为去雾的教师注意力, 在后续网络的训练过程中起到指导性作用。

教师注意力包含了从清晰标签图像中提取的注意力, 以及从雾霾部分获取的雾霾特征注意力, 两者可在神经网络的去雾过程中起到指导性作用, 使网络为重要特征分配到更大的权重, 是理想的去雾先验知识。然而, 在实际应用中, 雾霾图像的清晰化标签是未知的, 这使得教师注意力无处获取, 从而导致从标签中提取的教师注意力无法作为先验知识直接融入学生去雾网络。针对此问题, 本文设计注意力特征迁移媒介网络从雾霾图像中提取与教师注意力相近的迁移注意力, 作为先验知识直接融入

学生去雾网络的中间特征, 以实现其特征的差异化增强。网络以雾霾图像作为输入, 由教师注意力生成网络提供的教师注意力作为软标签, 使其输出的媒介注意力向教师注意力逼近。

1.1 注意力迁移机制及网络结构

1.1.1 教师注意力生成网络结构

本文采用自编码器构建教师注意力生成网络, 作为教师网络指导后续网络的学习。将雾霾图像和标签分别作为输入, 并从各卷积层输出的不同维度的特征信息中获取多尺度教师通道注意力和空间注意力。教师注意力生成网络如图 2(a)所示。

首先, 输入图像经卷积层 Conv1_1、1_2 进行特征下采样。其中, Conv1_1 步长为 2, 用于压缩特征图尺寸从而减少网络参数。然后, 提取的特征信息先后通过通道注意力模块和空间注意力模块。注意力模块根据特征重要性生成对应的权重, 并附加到对应特征上后, 将包含注意力信息的特征再与教师特征求和, 以达到特征增强的作用, 提高网络的特征表达能力。接着, 增强后的特征在 Conv4_1 和 Conv4_2 中进一步进行特征下采样, 并再次由通道注意力模块和空间注意力模块进行处理。最后, 空间注意力模块输出的特征经过 4 个反卷积层 TranConv1~4 恢复为图像。

通道注意力模块由全局平均池化和卷积层组成。首先, 通道注意力模块采用全局平均池化将通道的空间特征信息聚合到一个像素点上。接着, 通过 2 个 1×1 卷积层学习通道之间的相关性, 并用 Sigmoid 函数将输出的特征图转化为数值为 (0,1) 之间的权重。最后, 将权重和教师特征图求积再求和, 得到附加通道注意力的特征图。附加通道注意力的过程为

$$F'_c = F_c + F_c \times \eta(\text{Conv}(\sigma(\text{Conv}(g_c)))) \quad (1)$$

式中: F'_c 为附加通道注意力后的特征; F_c 为教师特征; η 为 Sigmoid 函数; Conv 为卷积操作; σ 为 ReLU 激活函数; g_c 为经过全局平均池化操作后的特征。

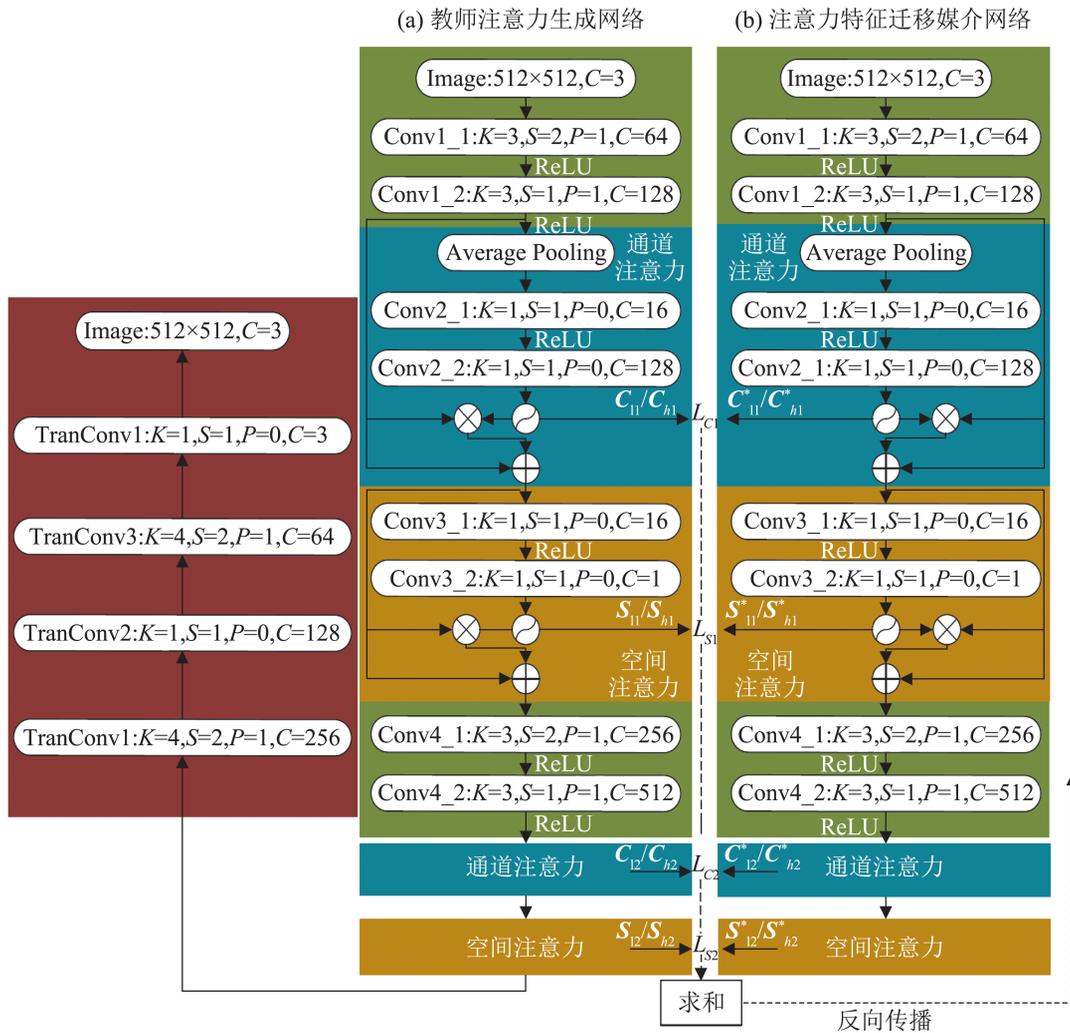


图2 教师注意力生成网络和注意力特征迁移媒介网络

Fig. 2 Teacher attention generation network and attention feature transfer media network

$$g_c = P(F_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W F_c(i, j) \quad (2)$$

式中： P 为全局平均池化操作； H 为特征图的高； W 为特征图的宽； F_c 为特征图； i, j 为像素点位置。

空间注意力模块首先通过卷积操作将通道信息集成到同一个通道上。然后，通过 1×1 卷积抓取像素之间的相关性，并通过Sigmoid函数将特征图转化为注意力图与教师特征图求积再求和，得到附加空间注意力的特征图。附加空间注意力的过程为

$$F_s = F'_c + F'_c \times \eta(\text{Conv}(\sigma(\text{Conv}(F'_c)))) \quad (3)$$

1.1.2 教师注意力生成网络损失

教师注意力生成网络由自编码器构成，并选

用Smooth L1损失函数衡量重建的清晰化图像和输入图像的差距。Smooth L1损失是在L1损失上改进得到的^[14]：

$$L(J, \hat{J}) = \frac{1}{N} \sum_{i=1}^N \begin{cases} 0.5x^2, & |x| \leq 1 \\ |x| - 0.5, & |x| > 1 \end{cases} \quad (4)$$

式中： N 为图像像素数量； J 为输入图像； \hat{J} 为网络输出图像； $x = J_i - \hat{J}_i$ ， J_i 为输入图像第 i 个像素点的值， \hat{J}_i 为网络输出图像第 i 个像素点的值。

1.2 注意力迁移媒介网络

1.2.1 媒介网络的结构

教师注意力生成网络所提取的标签和雾霾注意力具有很强的去雾指导能力。然而，实际应用

和测试中, 雾霾图像的清晰标签是未知的。因此, 有标签参与所提取的教师注意力无法直接融入学生去雾网络的训练过程, 此时, 需要构建一个注意力特征迁移媒介网络。本文以已知的雾霾图像作为输入, 教师注意力作为标签, 构建注意力特征迁移媒介网络, 从雾霾图像中提取近似于教师注意力的媒介注意力。训练完善的迁移媒介网络所提取的媒介注意力可直接融入学生去雾网络的训练过程中, 对重要特征进行增强, 使学生去雾网络的特征表达能力进一步提高。注意力特征迁移媒介网络如图2(b)所示, 网络下采样模块采用生成网络相同的结构。网络的主要目的是学习教师注意力构建的软标签, 无需像素级标签, 因此未使用上采样模块。

1.2.2 媒介网络损失

深度神经网络的训练通常通过损失函数的约束完成, 损失函数的选用很大程度上影响着网络的性能。本文采用多重注意力迁移损失为媒介网络提供多个约束, 使其较好地将教师注意力生成网络的知识迁移到自身网络中。多重注意力迁移损失为

$$L_{\text{all}} = L_{C_1} + L_{S_1} + L_{C_2} + L_{S_2} \quad (5)$$

式中: L_{C_1} 为第一部分通道注意力损失, 衡量教师通道注意力 C_1 和迁移媒介通道注意力 C_1^* 的差异; L_{S_1} 为第一部分空间注意力损失, 衡量教师空间注意力 S_1 和迁移媒介空间注意力 S_1^* 间的差异; L_{C_2} 为第二部分通道注意力损失, 衡量教师通道注意力 C_2 和迁移媒介通道注意力 C_2^* 间的差异; L_{S_2} 为第二部分空间注意力损失, 衡量教师空间注意力 S_2 和迁移媒介空间注意力 S_2^* 间的差异。以上损失皆应用 Smooth L1 损失函数:

$$L_C/L_S = \frac{1}{N} \sum_{i=1}^N \begin{cases} 0.5x^2, & |x| \leq 1 \\ |x| - 0.5, & |x| > 1 \end{cases} \quad (6)$$

式中: N 为注意力图像像素点数量; $x = J_i - \hat{J}_i$, J_i 为教师注意力生成网络的通道注意力或空间注意力第 i 个像素点的值, \hat{J}_i 为注意力媒介网络的通道注意力或空间注意力第 i 个像素点的值。

1.3 融合迁移注意力的学生去雾网络

1.3.1 学生去雾网络结构

本文学生去雾网络将注意力迁移媒介网络提取雾霾图像的多重迁移媒介注意力引入训练过程中, 提高网络对尘雾区域和重要特征的针对性, 学生去雾网络如图3所示。首先, 雾霾图像经过步长为2的 Conv1 进行特征提取并减小特征图尺寸, 图像特征再通过两个残差层及 Conv4 处理, 由低维特征转化为高维特征。然后, 图像特征先后在两个残差层之后的特征增强模块中融入注意力迁移媒介网络所提供的先验知识, 从而提高特征的表达能力。最后, 图像特征通过反卷积模块还原为清晰图像。

1.3.2 学生去雾网络损失

学生去雾网络同样选用 Smooth L1 损失函数衡量重建的清晰化图像和标签图像的差距。数学表达式为

$$L(J, \hat{J}) = \frac{1}{N} \sum_{i=1}^N \begin{cases} 0.5x^2, & |x| \leq 1 \\ |x| - 0.5, & |x| > 1 \end{cases} \quad (7)$$

式中: N 为图像像素数量; J 为标签图像; \hat{J} 为网络输出图像; $x = J_i - \hat{J}_i$, J_i 为标签图像第 i 个像素点的值, \hat{J}_i 为网络输出图像第 i 个像素点的值。

2 增量式训练

采用深度神经网络去雾时, 由于样本场景和状态不断增多, 经常出现数据集需要增补的情况。然而, 当神经网络对原始数据集完成收敛后, 常常对增补数据集的泛化能力不强。因此, 需要对增补数据集做重新训练, 这种做法不但会使网络完全抛弃原有的知识, 同时耗时很长。为此, 提出一种增量式的神经网络训练方法, 采用小样本增补数据来提高网络对新数据的处理能力, 并在迁移媒介网络提取的注意力先验约束下, 减少网络对初始知识的遗忘。增量式训练结构如图4所示。首先, 以大量初始样本作为去雾网络的初始训练的数据集, 使网络具备处理初始样本的能力。

(gated context aggregation network)^[19], FFA-Net (feature fusion attention network)^[20]算法做对比分析, 其中, DCP为基于图像复原的去雾方法的代表性算法, 其余为基于深度学习的去雾算法, 基于深度学习的去雾算法采用传统训练方式, 即处理增补数据前, 需要大量增补数据对网络进行重新训练且遗忘处理原始数据的相关知识。本文所采用的增量式训练方法, 保留原始知识的同时使网络快速具备处理增补数据的能力, 大幅度提高训练效率。

3.1 数据集设置

算法训练过程分为三步: 教师注意力生成网络的训练、注意力特征迁移媒介网络的训练和学生去雾网络的训练, 学生去雾网络的训练分为初始训练和增量训练。RESIDE数据集为人工合成的均匀雾图, 其中, ITS每张标签对应10张浓度不同的雾霾图像, 共计13 990张室内雾霾图像。OTS含有9 870张标签, 每张标签生成浓度不同的雾霾图像35张。教师注意力生成网络的训练随机采用ITS的4 000对样本, 网络输入的清晰图像即为网络的标签。注意力媒介网络随机采用7 000张ITS图像, 此网络的训练标签由生成网络提供, 数据集不包含标签。学生去雾网络的初始训练采用7 000对ITS雾霾图像与对应的清晰图像, 训练完备后保留350对ITS图像, 增加700对OTS图像作为增量数据集对网络进行增量训练。分别在ITS和OTS中选取与训练集不重叠的1 000张图像作为测试集, 测试算法性能。

经实验, 当保留1 000对ITS图像、增加2 000对OTS图像构造增补数据集时, 网络增量训练所需时间大幅增加, 在ITS测试集上所测客观评价指标SSIM和PSNR分别为0.88、26.23 dB, 在OTS测试集上测试两个指标分别为0.9、26.88 dB。保留350对ITS图像, 增加700对OTS图像, 共1 050对图像对网络增量训练时, 在ITS测试集上2个指标分别为0.9、26.74 dB, OTS测试集上分

别为0.9、26.68 dB。而保留200对ITS图像, 增加300对OTS图像, 共500对图像对网络增量训练时, 在ITS测试集上2个指标分别为0.9、27.22 dB, 在OTS测试集上2个指标分别为0.85、23.45 dB。经多次实验, 本文所采用的数据比例既能保证网络的良好性能, 又能提高网络训练的效率。

3.2 ITS实验结果

3.2.1 主观视觉效果

本文用不同算法对1000张ITS图像组成的测试集进行处理, 并随机选取5张图像进行主观视觉效果对比分析, 如图5所示。其中, DehazeNet、AOD-Net算法取得了较好的去雾效果, 但多数处理后的图像仍有少量的雾残留。DCP处理后的图像出现整体变暗的现象, 同时伴随颜色失真。FFA-Net处理后的图像有较多的雾残留, 不能有效处理雾图。GCANet具有较好的去雾能力。相比之下, 本文算法网络增量前和增量后保证图像的颜色、结构完好, 在视觉效果上与标签最为接近。

为进一步对比各个算法的去雾性能, 选取图5中的一张图像, 并在图像中随机选取一个像素区域放大, 便于观察实验结果的细节信息, 如图6所示。图6表明, 本文所提算法处理图像细节的能力更加强大, 处理后的图像更加接近于清晰标签。

3.2.2 客观评价指标

为更加客观公正地评价不同算法的去雾性能, 选取结构相似性(structural similarity, SSIM)^[21]和峰值信噪比(peak signal-to-noise ratio, PSNR)^[22]评价指标来衡量各个算法处理后的1 000张ITS测试集图像与清晰无雾图像之间的差距, 并取平均值进行对比分析, ITS客观评价指标如表1所示。SSIM通过计算目标图像与待评价图像之间的像素相关性来计算, SSIM的值域为[0, 1], SSIM值越

大,表明所得结果图像与标签图像越相似,结果图像质量越高。峰值信噪比PSNR经常用来作为计算机视觉领域中信号重建质量评价的指标,为信号最大可能功率和影响它的表示精度的破坏性

噪声功率的比值,PSNR值越大,表明待评价图像与基准图像之间的差异越小,待评价图像的质量越好。增量前后本文算法相较其他对比算法在2个指标上均表现最优。

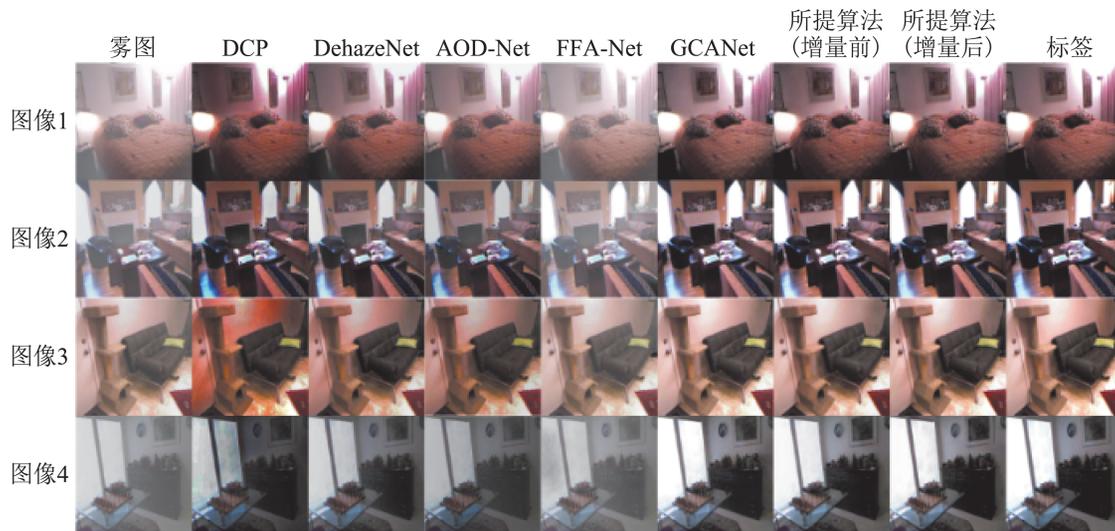


图5 ITS图像主观视觉效果
Fig. 5 Subjective visual effects of ITS images

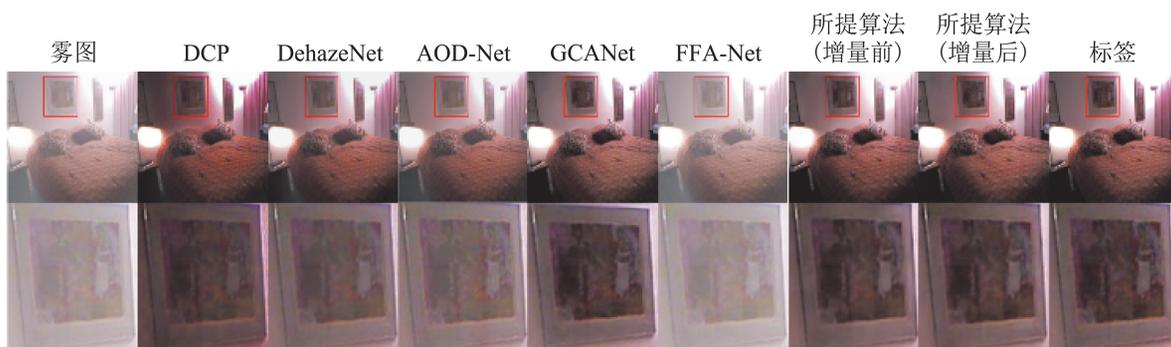


图6 ITS图像主观视觉效果细节展示
Fig. 6 Detailed display of subjective visual effects of ITS images

表1 ITS客观评价指标
Table 1 ITS objective evaluation indices

算法	SSIM	PSNR/dB
DCP	0.81	17.04
DehazeNet	0.84	20.55
AOD-Net	0.80	18.42
GCANet	0.89	27.50
FFA-Net	0.73	14.36
所提算法(增量前)	0.90	27.52
所提算法(增量后)	0.90	26.74

3.3 OTS实验结果

3.3.1 主观视觉效果

用不同算法对1 000张OTS图像组成的测试集进行处理,并随机选取5张图像进行主观视觉效果对比分析,如图7所示。FFA-Net处理后的图像普遍有少量雾残留。DehazeNet对光线较暗的区域处理能力较弱。AOD-Net和DCP算法处理后的图像出现整体变暗的现象。GCANet部分图像出现

颜色失真的现象。本文算法增量前的网络未使用OTS训练, 因此, 处理后的部分图像效果不理想, 增量后的网络得到的清晰图像在主观视觉效果上最接近无雾的标签图像。

为进一步观察处理后图像的细节, 选取图7中的一张图像, 并对其天空区域进行放大, OTS图像主观视觉效果细节展示如图8所示。DCP、GCANet、AOD-Net算法处理后的天空区域颜色出现偏差, DehazeNet与FFA-Net算法处理后的图像有雾残留, 在本算法增量训练前, 处理后的图像出现颜色失真现象, 增量训练后, 算法处理后的图像与标签图像最为相近。

3.3.2 客观评价指标

选取结构相似性SSIM和峰值信噪比PSNR评

价指标来进一步对比不同算法的去雾性能, OTS客观评价指标如表2所示。

3.4 真实有雾图像实验结果

3.4.1 主观视觉效果

随机选取5张处理后的真实有雾图像做主观视觉上的对比分析, 如图9所示。其中, FFA-Net处理后的图像仍含有大量的雾。DehazeNet、AOD-Net算法处理后的图像有少量雾的残留。DCP处理后的图像出现不同程度的变暗现象。GCANet具有较好的去雾效果。本文算法处理后的图像更加自然, 保证了图像颜色、结构等属性的完好, 从视觉上更加接近清晰无雾图像。



图7 OTS图像主观视觉效果
Fig. 7 Subjective visual effects of OTS images

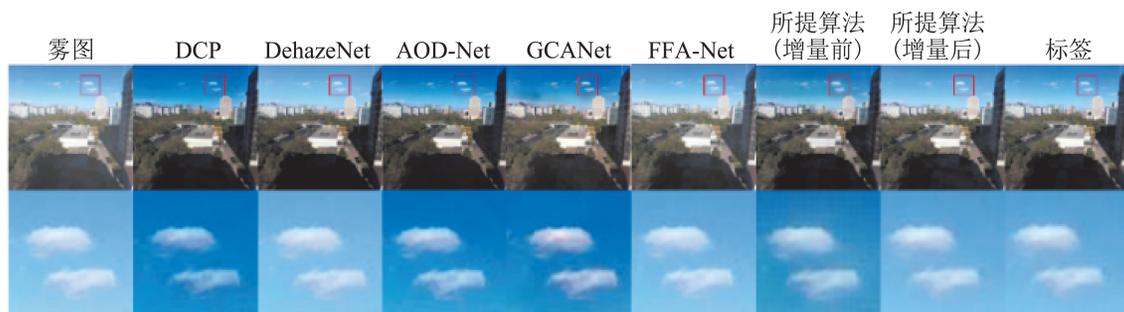


图8 OTS图像主观视觉效果细节展示
Fig. 8 Detailed display of subjective visual effects of OTS images

表 2 OTS 客观评价指标
Table 2 OTS objective evaluation indices

算法	SSIM	PSNR/dB
DCP	0.83	16.94
DehazeNet	0.83	22.25
AOD-Net	0.83	19.38
GCANet	0.89	22.74
FFA-Net	0.87	22.09
所提算法(增量前)	0.85	21.91
所提算法(增量后)	0.90	26.68

为进一步观察图 9 中图像的细节, 选取图 9 中的一张图像, 放大其随机像素区域, 如图 10 所示。本文算法在细节的处理上表现最优, 处理后的图像质量更高。

3.4.2 客观评价指标

真实雾图没有对应的清晰化标签, 但为了消除评价的主观性, 计算 3.4.1 节中的 5 张图像 的方差和图像熵作为客观评价指标进行对比分析, 这 2 个指标不需要清晰化标签参与计算, 真实雾图处理结果方差值如表 3 所示, 真实雾图处理结果图像熵值如表 4 所示。方差是指图像像素灰度值相对于均值的离散程度, 方差越大, 表明图像中灰度级别越分散, 图像质量也就越好。图像熵是衡量图像信息丰富程度的一个重要指标, 图像熵越大, 图像信息越多, 图像越清晰。本文算法在 2 个评价指标上皆表现为最优值。

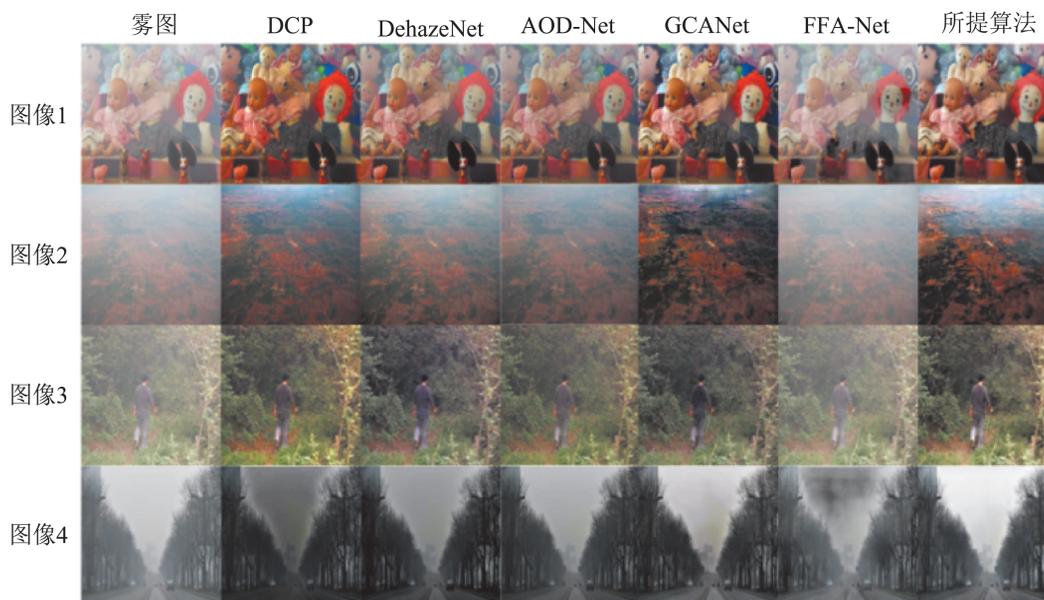


图 9 真实雾图主观视觉效果
Fig. 9 Subjective visual effect of real haze images



图 10 真实雾图实验结果细节展示
Fig. 10 Detailed display of experimental results of real haze images

表3 真实雾图处理结果方差值
Table 3 Variance of real haze image processing results

图像	DCP	DehazeNet	AOD-Net	GCANet	FFA-Net	本文
1	978	2 404	2 035	3 034	2 610	3 106
2	2 828	4 171	2 717	1 510	3 530	4 259
3	1 418	1 325	1 023	1 193	627	2 280
4	1 701	3 404	3 775	4 833	2 151	5 854

表4 真实雾图处理结果图像熵值
Table 4 Image entropy of real haze image processing results

图像	DCP	DehazeNet	AOD-Net	GCANet	FFA-Net	本文
1	12.30	12.19	12.04	12.91	11.36	13.00
2	11.71	12.06	11.40	11.80	10.72	12.86
3	11.63	11.65	11.21	11.48	10.32	12.42
4	11.00	11.84	11.86	12.50	11.30	12.55

3.5 消融实验

为证明算法模块的有效性, 在测试集上对学生网络进行消融实验, 计算输出结果与标签图像之间的 PSNR 和 SSIM, 并进行对比分析, 如图 11~12 所示。

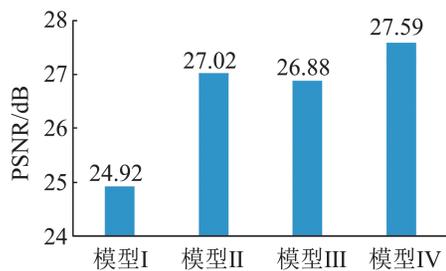


图 11 PSNR 结果对比

Fig. 11 Comparison of PSNR results in ablation experiments

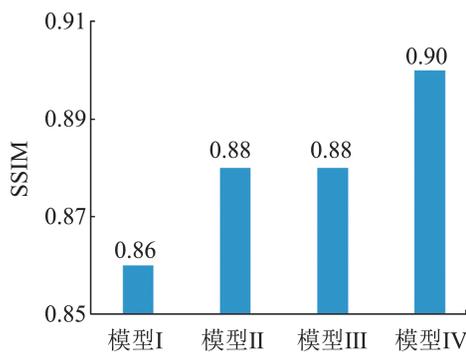


图 12 SSIM 结果对比

Fig. 12 Comparison of SSIM results in ablation experiments

模型I为残差模型; 模型II为残差模型、迁移通道注意力的组合; 模型III为残差模型、迁移空间注意力的组合; 模型IV为残差模型、迁移通道注意力和迁移空间注意力的组合, 即最终选用网络。

4 结论

本文以注意力机制为基础提出一种基于多重迁移注意力的增量式去雾算法, 主要工作如下:

(1) 采用自编码器结构分别提取清晰标签样本和雾霾分布的通道、空间注意力生成多重教师注意力信息。

(2) 以多重教师注意力信息为软标签, 构建注意力迁移媒介网络, 在损失函数的约束下使网络提取的多重迁移注意力向生成网络的教师注意力逼近。然后, 将注意力媒介网络学到的通道、空间注意力融入学生去雾网络的训练过程, 提高网络对重要区域的针对性。

(3) 采用增量式训练方法, 使网络在多重迁移注意力先验信息的约束下快速提高对增补数据的处理效果, 迁移媒介注意力约束网络在学习新知识时, 不会遗忘已学到的知识。

算法在 ITS 测试集上的 SSIM 达到 0.9, PSNR 为 27.52, 在 OTS 测试集上的 SSIM 为 0.9, PSNR 表现为 26.68, 在所选对比算法中皆表现为最优值。为测试算法的泛化能力, 在真实雾图上进行实验, 选用无参考客观评价指标: 方差与熵函数以对比图像质量, 同样在对比算法中表现为最优。最后, 为了测试本文所提各个模块的有效性, 进行了消融实验, 模型加入迁移通道注意力后在测试集上 SSIM、PSNR 分别为 27.02、0.88; 模型加入迁移空间注意力后分别为 26.88、0.88; 两个模块皆加入后, 指标分别为 27.59、0.9。

参考文献:

- [1] 金炜东, 胡燕花, 唐鹏, 等. 基于结构化森林的前向车载视频图像的细节强化[J]. 系统仿真学报, 2018, 30(12): 4602-4609, 4617.

Jin Weidong, Hu Yanhua, Tang Peng, et al. Detailed

- Enhancement of Forward Vehicle Video Images Based on Structured Forest[J]. *Journal of System Simulation*, 2018, 30(12): 4602-4609, 4617.
- [2] 杨凯, 陈纯毅, 胡小娟, 等. 蒙卡渲染画面多特征非局部均值滤波降噪算法[J]. *系统仿真学报*, 2022, 34(6): 1259-1266.
Yang Kai, Chen Chunyi, Hu Xiaojuan, et al. Denoising Algorithm Based on Multi-feature Non-local Mean Filtering for Monte Carlo Rendered Images[J]. *Journal of System Simulation*, 2022, 34(6): 1259-1266.
- [3] He Kaiming, Sun Jian, Tang Xiaou. Single Image Haze Removal Using Dark Channel Prior[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2011, 33(12): 2341-2353.
- [4] 麻文刚, 张亚东, 郭进. 基于景深先验引导与环境光优化的图像去雾[J]. *电子学报*, 2022, 50(7): 1708-1721.
Ma Wengang, Zhang Yadong, Guo Jin. Image Dehazing Based on Prior Guidance of Depth of Field and Optimization of Ambient Light[J]. *Acta Electronica Sinica*, 2022, 50(7): 1708-1721.
- [5] 吕建威, 钱锋, 韩昊男, 等. 结合光源分割和线性图像深度估计的夜间图像去雾[J]. *中国光学*, 2022, 15(1): 34-44.
Lü Jianwei, Qian Feng, Han Haonan, et al. Nighttime Image Dehazing with a New Light Segmentation Method and a Linear Image Depth Estimation Model[J]. *Chinese Optics*, 2022, 15(1): 34-44.
- [6] 姜雨彤, 杨忠琳, 朱梦琪, 等. 适应性双通道先验的图像去雾方法[J]. *光学精密工程*, 2022, 30(10): 1246-1262.
Jiang Yutong, Yang Zhonglin, Zhu Mengqi, et al. Image Dehazing Method Based on Adaptive Bi-channel Priors[J]. *Optics and Precision Engineering*, 2022, 30(10): 1246-1262.
- [7] 张楠楠, 李志伟, 郭新军, 等. 使用改进型大气散射模型的双阶段图像修复[J]. *光学精密工程*, 2022, 30(18): 2267-2279.
Zhang Nannan, Li Zhiwei, Guo Xinjun, et al. Two-stage Image Restoration Using Improved Atmospheric Scattering Model[J]. *Optics and Precision Engineering*, 2022, 30(18): 2267-2279.
- [8] Narasimhan S G, Nayar S K. Vision and the Atmosphere[J]. *International Journal of Computer Vision*, 2002, 48(3): 233-254.
- [9] Qu Yanyun, Chen Yizi, Huang Jingying, et al. Enhanced Pix2pix Dehazing Network[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2019: 8152-8160.
- [10] 金炜东, 张述礼, 唐鹏, 等. 基于稠密残差块与通道像素注意力的图像去雾网络[J]. *系统仿真学报*, 2022, 34(8): 1663-1673.
Jin Weidong, Zhang Shuli, Tang Peng, et al. Image Dehazing Network Based on Densely Connected Residual Block and Channel Pixel Attention[J]. *Journal of System Simulation*, 2022, 34(8): 1663-1673.
- [11] Wang Keping, Duan Yumeng, Yang Yi. Single Image Dehazing Algorithm Based on Pyramid Mutil-scale Transposed Convolutional Network[J]. *Systems Science & Control Engineering*, 2021, 9(S1): 150-160.
- [12] Wang Keping, Yang Yi, Li Bingfeng, et al. Uneven Image Dehazing by Heterogeneous Twin Network[J]. *IEEE Access*, 2020, 8: 118485-118496.
- [13] Francisco M Castro, Manuel J Marín-Jiménez, Nicolás Guil, et al. End-to-end Incremental Learning[C]//Computer Vision-ECCV 2018. Cham: Springer International Publishing, 2018: 241-257.
- [14] Girshick R. Fast R-CNN[C]//2015 IEEE International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2015: 1440-1448.
- [15] 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.
- [16] Zeiler M D. Adadelta: An Adaptive Learning Rate Method[J]. *Computer Ence*, 2012, 27(12): 1-6.
- [17] 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.
- [18] Li Boyi, Peng Xiulian, Wang Zhangyang, et al. AOD-net: All-in-one Dehazing Network[C]//2017 IEEE International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2017: 4780-4788.
- [19] 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 (WACV). Piscataway, NJ, USA: IEEE, 2019: 1375-1383.
- [20] Qin Xu, Wang Zhilin, Bai Yuanhao, 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.
- [21] Wang Zhou, 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.
- [22] Huynh-Thu Q, Ghanbari M. Scope of Validity of PSNR in Image/Video Quality Assessment[J]. *Electronics Letters*, 2008, 44(13): 800-801.