

基于注意力机制和马尔可夫判别器的图像去雾算法

林克正¹, 耿佳浩^{1*}, 程卫月², 李骛¹¹哈尔滨理工大学计算机科学与技术学院, 黑龙江 哈尔滨 150080;²黑龙江工商学院, 黑龙江 哈尔滨 150025

摘要 针对现有去雾算法无法根据有雾图像的不同区域特征进行差异化处理的问题,提出了一种基于注意力机制和马尔可夫判别器(PatchGAN)的图像去雾算法。注意力机制的加入使所提算法能够为不同区域的特征自适应分配权重;同时使用带有Inception机制的模块来预测全局相关的大气光值更加准确,也更为有效。将预测到的大气光值、透射率及有雾图像输入大气散射模型中即可得到去雾图像,最后将去雾图像输入PatchGAN中,由其判断真假。实验结果表明,所提算法在室内有雾图像和室外有雾图像上均取得了良好的去雾效果,并且提高了去雾图像的亮度和饱和度。

关键词 图像处理; 模式识别; 图像去雾; 深度学习; 注意力机制; 马尔可夫判别器

中图分类号 TP391.4

文献标志码 A

DOI: 10.3788/LOP202259.1610003

Image Dehazing Algorithm Based on Attention Mechanism and Markov Discriminant

Lin Kezheng¹, Geng Jiahao^{1*}, Cheng Weiyue², Li Ao¹¹School of Computer Science and Technology, Harbin University of Science and Technology, Harbin 150080, Heilongjiang, China;²Heilongjiang College of Business and Technology, Harbin 150025, Heilongjiang, China

Abstract An image defogging algorithm based on attention mechanism and Markov discriminator (PatchGAN) is proposed herein to differentiate features according to the different regional features of foggy images, which cannot be achieved using existing defogging algorithms. Combined with attention mechanism, the proposed algorithm can adaptively assign weights to the features of different regions while using the module with Inception mechanism to predict the globally relevant atmospheric light value more accurately and effectively. The predicted atmospheric light value, transmittance, and foggy image are input into the atmospheric scattering model to obtain the defogged image. Finally, the defogging image is input into PatchGAN to determine whether it is true or false. The experimental results show that the proposed algorithm achieves good defogging effect on indoor and outdoor foggy images and improves the brightness and saturation of defogging images.

Key words image processing; pattern recognition; image defogging; deep learning; attention mechanism; Markov discriminator

1 引言

近年来,我国经济的高速发展使工业化和城市化速度过快,全国各地出现雾霾天气的频率显著提升,在这种能见度较低的雾霾环境下,受大气中的悬浮水滴和气溶胶的影响,室外拍摄设备获取的图像会出现饱和度与对比度下降的问题,图像失去了很多重要细节,

不利于后续设备对其进行特征提取,增加了图像处理的难度,使得各种安全性措施如监控系统、目标检测系统难以发挥正常作用。因此,关于图像去雾算法的研究有重大的意义、实用价值及巨大的应用前景^[1-2]。随着图像处理技术的发展,图像去雾算法可分为传统去雾算法和基于深度学习的图像去雾算法,如何有效地将模糊环境下的退化图像还原成清晰图像已经成为了

收稿日期: 2021-05-17; 修回日期: 2021-06-16; 录用日期: 2021-06-27

基金项目: 国家自然科学基金(61501147, 62071157)、黑龙江省自然科学基金(F2015040)

通信作者: *417782934@qq.com

一个重要的研究课题^[3-5]。

传统的图像去雾算法又可以分为经典图像增强算法^[6]及基于大气散射模型的图像复原算法两类。第 1 类经典图像增强算法包括直方图均衡化^[7-8]、Retinex 算法^[9-10]、小波变换^[11]等,这一类经典图像增强算法主要通过增强对比度,对有雾图像进行增强饱和度处理,达到提高图像质量的目的,虽然提出较早且实现简单,但由于其并没有考虑到雾气生成的真正原因,所以实际使用中图像去雾效果并不理想。第 2 类基于图像复原的图像去雾算法利用先验知识估算出大气散射模型中的物理量再反演复原成无雾图像,如暗通道先验去雾算法(DCP)^[12]、非局部先验去雾算法^[13]、变分模型去雾算法^[14]、包含天空区域的图像去雾算法^[15]、椭圆模型去雾方法^[16]、自适应雾度衰减算法^[17]、颜色衰减模型(CAP)^[18]等,由于先验知识无法适应所有的雾天场景,基于先验的图像去雾算法鲁棒性较差。

基于深度学习的图像去雾算法能够通过卷积神经网络获取大气光值、介质透射率等与图像雾度相关的信息,具有良好的鲁棒性。如 Cai 等^[19]提出的 DehazeNet 利用卷积神经网络直接估计有雾图像的透射率和大气光值,从而获得无雾图像;Ren 等^[20]提出了基于一种多尺度卷积神经网络的去雾算法(MSCNN);Li 等^[21]提出的 AOD-Net 是一种端到端去雾算法,该算法将透射率和大气光值合并为一个未知量,并将大气散射模型变形来获得无雾图像;Zhang 等^[22]提出了一种基于金字塔稠密连接和 u-net 的去雾网络;Shao 等^[23]提出的域适应范式可以弥补合成域与真实域的差距。

本文提出了一种基于注意力机制和马尔可夫判别器(PatchGAN)的图像去雾算法。所提算法中的注意力机制可以给图像不同区域特征自适应分配权重,使算法

更专注于处理与雾度相关的特征信息,雾度越大则获得权重越大,雾度越小则获得权重越小;同时,Inception 机制使得所提算法可以获得更大的感受野,加快去雾网络收敛速度的同时,降低了算法的计算复杂度。

2 相关算法

2.1 大气散射模型

大气散射模型通常被应用在模拟有雾图像的退化过程中,由于其通用性强,也被广泛用于图像去雾算法的研究中。大气散射模型的表达式为

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

式中: $I(x)$ 为有雾图像在 x 处的观测值; $J(x)$ 为清晰图像在 x 处的观测值; A 代表大气光值; $t(x)$ 为介质的透射率,用来表示光线到达相机镜头的衰减。从式(1)可以看出,当有雾图像的大气光值和透射率已知时,就可以将有雾图像还原成无雾图像,所以去雾算法需要正确地估计出介质透射率和大气光值。然而,估计得到的介质透射率和大气光值的精度具有不确定性,这将对去雾效果产生极大的影响。所提算法采用的 Inception 和注意力机制可以有效增加介质透射率和大气光值的准确度。

2.2 网络注意力机制

传统的深度学习去雾网络模型会均等地处理各个通道和各个区域的像素特征,然而绝大多数有雾图像的雾度分布是不均匀的,不同区域的雾度不同,所对应的权重也应该不同,此外每个通道也应具有不同的权重信息,均等地处理这些本应具有不同权重的特征信息将会在大量无用信息上浪费资源,降低去雾算法的有效性与精确性。为了使所提算法能够根据不同区域特征的特点自适应分配权重,在其中加入了注意力机制,注意力机制模块如图 1 所示。




图 1 注意力模块

Fig. 1 Attention module

在注意力机制模块中,首先通过最大池化将通道空间信息转换成通道描述符,即

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

式中: $X_c(i, j)$ 表示图像通道 C 在 (i, j) 位置的值; Z_{mp} 代表最大池化函数; H 表示图像的高度; W 代表图像的宽度。使用与图片大小相同的卷积核来进行最大池化,使特征图的大小从 $C \times H \times W$ 转换为 $C \times 1 \times 1$,

随后将特征图输入两层卷积层、Relu 激活函数和 Sigmoid 激活函数中,即

$$A_c = \sigma \left\{ \text{Conv} \left\{ \omega \left[\text{Conv} (g_c) \right] \right\} \right\}, \quad (3)$$

式中: ω 为 Relu 函数; σ 为 Sigmoid 函数;Conv 为卷积层函数; A_c 为输出的权重。最后将对应的 F_c 与 A_c 相乘,即

$$F_c^* = A_c F_c. \quad (4)$$

将 F_c^* 输出到下一阶段,与第 1 阶段不同,在这一阶段没有池化层,直接将 F_c^* 输入两层卷积层、Relu 激活函数和 Sigmoid 激活函数中。

$$A_p = \sigma \left\{ \text{Conv} \left\{ \omega \left[\text{Conv} \left(F_c^* \right) \right] \right\} \right\} \quad (5)$$

式中: A_p 为输出的权重。最后将对应的 F_c^* 与 A_p 相乘,即得到注意力模块的输出。

$$F_p^* = A_p F_c^* \quad (6)$$

2.3 Inception 机制

Inception 卷积神经网络是由 GoogleNet 提出的,一共经历了 4 个版本。Inception 1 使用 $1 \times 1, 3 \times 3, 5 \times 5$ 的卷积核来进行不同尺度的特征提取,同时还加入了最大池化;Inception 2 在 Inception 1 的基础上进行了优化,为了减小网络的参数量,降低运算难度加快收敛速度,在加入了批归一化的同时使用了 2 个 3×3 的卷积核代替了原有的 5×5 的卷积核。Inception 3 在 Inception 2 的基础上增加了一种并行卷积结构,使步长为 2 的卷积与池化并行运行,然后结合起来,降低了维度,还不会造成信息提取上的损失。Inception 4 在 Inception 3 的基础上增加了残差网络 (ResNet),取得了较好的效果。所使用的 Inception 模块如图 2 所示。

3 所提算法

首先将有雾图像输入去雾网络中,分别预测有雾图像的大气光值与介质透射率;然后将预测到的大气光值、介质透射率及有雾图像输入大气散射模型中即可得到无雾图像;最后将无雾图像输入马尔可夫判别器中,由其判断真假。所提算法的整体框架如图 3 所示。

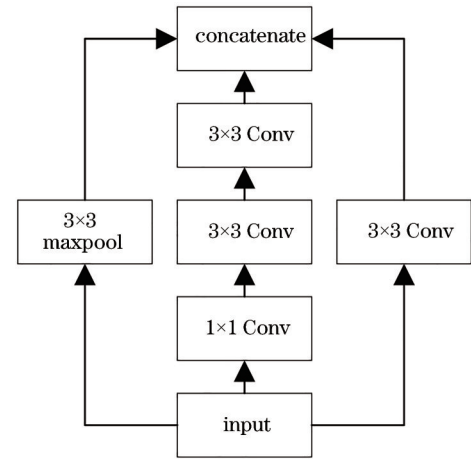


图 2 Inception 机制图

Fig. 2 Diagram of Inception mechanism

3.1 预测介质透射率

基于注意力机制的介质透射率估计网络能够根据不同的雾度特征自动分配权重,整个网络可将浅层的信息传送到深层,此外,注意力机制能够利用权重不同的特征进行互补,而不仅仅专注于局部特征,这使得卷积网络的感受野变得更大,可以更好地利用全局相关的信息,使结果更精确,并且加快了网络的收敛速度。所提算法使用的基于注意力机制的介质透射率估计网络如图 4 所示。

为了获得图像不同区域的雾度、边缘、纹理等信息,在预测透射率模块的浅层网络进行特征提取。浅层网络包括卷积层、批处理层 (BN 层)。在 BN 层中, batch-size 既不能过大也不能过小, batch-size 过小会导致模型的收敛速度过慢,适当增大 batch-size 可以增加模型的泛化能力和收敛速度,但过大可能会导致模

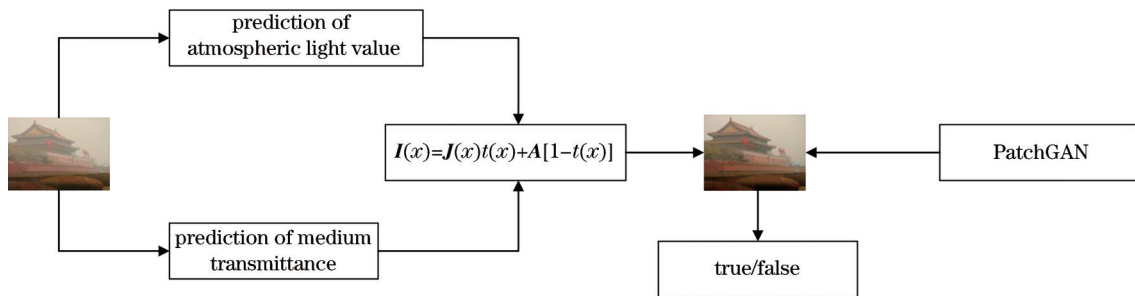


图 3 网络框架图

Fig. 3 Network framework




图 4 预测透射率网络图

Fig. 4 Predictive transmission network

型出现梯度消失或梯度爆炸等问题。实验中 batch-size 设置为 64, 并且使用 Relu 激活层和池化层 (Pooling) 对图像进行处理, 即

$$\mathbf{F}_s = H_{SF}(\mathbf{I}), \quad (7)$$

式中: \mathbf{I} 为输入的有雾图像; H_{SF} 为特征提取函数; \mathbf{F}_s 为浅层特征的输出。将 \mathbf{F}_s 输入后续的残差模块以及注意力模块中进行下采样操作, 其中残差模块在特征提取模块的基础上加入了残差连接, 残差连接能够在减少计算资源消耗的同时有效解决去雾网络在训练时出现的梯度消失等问题, 其后的注意力机制模块可以为提取到的特征自动分配权重, 使该模块能够更加专注于处理与介质透射率有关的相关特征信息。

$$\mathbf{F}_d = H_{AM} \left\{ H_{RN,d} \left\{ \dots \left[H_{RN,1}(\mathbf{F}_s) \right] \dots \right\} \right\}, \quad (8)$$

式中: $H_{RN,d}$ 表示第 d 个残差卷积网络函数; H_{AM} 表示注意力模块函数; \mathbf{F}_d 表示该段函数的整体输出。为了能够重建透射率图, 使用反卷积神经网络对 \mathbf{F}_d 进行上采样操作。

$$\mathbf{F}_b = H_{DRN,b} \left\{ \dots H_{DRN,2} \left[H_{DRN,1}(\mathbf{F}_d) \right] \right\}, \quad (9)$$

式中: $H_{DRN,b}$ 表示第 b 个残差卷积网络; \mathbf{F}_b 表示该段函数的整体输出。最后将 \mathbf{F}_b 输入下一层卷积神经网络, 经过映射层即可以得到介质透射率图。

$$t = H_{MAP}(\mathbf{F}_b). \quad (10)$$

3.2 预测大气光值

在预测大气光值的网络设计中, 为了提高网络的收敛速度, 降低计算的复杂度, 这里不采用预测介质透射率所用到的先下采样再上采样的方法, 而是使用基于 Inception 模块的网络不断地进行下采样, 从图到点, 最终的 1×1 的结果即为预测到的大气光值。大气光值是一个与全局有关的变量, 采用 Inception 机制的好处是可以获得更大的感受野, 提取更多与全局有关的信息, 对大气光值的预测更为精准, 不会出现把局部最优大气光值当成全局大气光值的问题, 同时 Inception 模块可以加快网络的收敛速度。利用带有 Inception 模块的网络预测大气光值时, 图像处理过程如图 5 所示。




图 5 图像处理过程图

Fig. 5 Image processing process

3.3 判别器网络

使用 PatchGAN 判断去雾后无雾图像的真假。与传统判别器不同, 在 PatchGAN 中, 输入不再是随机高

频变量, 而是图像。将图像输入 PatchGAN 中, 判别器会首先把图像分割成 $N \times N$ 大小的矩阵 (Patch), 然后对所有的 Patch 分别进行判别, 最后根据一张图片全部 Patch 判别结果的平均值来输出 true 或者 false。

3.4 算法描述

所提算法损失函数包括两部分, 第 1 部分为均方误差损失函数, 其表达式为

$$L_{MSE} = \frac{1}{N} \sum_{x=1}^N \|\mathbf{I}(x) - \mathbf{J}(x)\|_2, \quad (11)$$

式中: N 代表训练集包含的图像总数。第 2 部分为判别器损失函数, 其表达式为

$$L_{GAN}(G, D) = E_{x,y} [\log_{10} D(x, y)] + E_{x,y} \left\{ \log_{10} \left\{ 1 - D[x, G(x, z)] \right\} \right\}, \quad (12)$$

式中: $E_{x,y} [\log_{10} D(x, y)]$ 为将原始无雾图像判定为真的概率; $E_{x,y} \left\{ \log_{10} \left\{ 1 - D[x, G(x, z)] \right\} \right\}$ 为将去雾图像判定为假的概率。

则总损失函数的表达式为

$$L = \partial L_{MSE} + \beta L_{GAN}, \quad (13)$$

式中: ∂, β 分别为均方误差损失函数和判别器误差损失函数的系数, 默认均为 0.5。

所提去雾算法的具体流程如下:

algorithm 1 A&P-dehaze algorithm

input: Foggy image

output: Defogging image

- 1) Input foggy image \mathbf{I} ;
- 2) Use formula (7) to extract shallow features and get feature map \mathbf{F}_s ;
- 3) First, \mathbf{F}_s is downsampled by residual network, and attention mechanism is used to allocate weight $\mathbf{F}_d = H_{AM}[\mathbf{F}_s + \mathcal{F}(\mathbf{F}_s, W_l)]$, H_{AM} is the whole function of attention mechanism, $\mathcal{F}(\mathbf{F}_s, W_l)$ is the residual;
- 4) Then the deconvolution residual network is used for upsampling to get \mathbf{F}_b , $\mathbf{F}_b = \mathbf{F}_d + \mathcal{F}(\mathbf{F}_d, W_l)$;
- 5) The transmittance map is obtained by using the mapping function, $t = H_{MAP}(\mathbf{F}_b)$;
- 6) Using Inception module, the atmospheric light value of foggy image is predicted $\mathbf{A} = F_{Inc,n}[\dots F_{Inc,1}(\mathbf{I})]$;
- 7) The defogging image \mathbf{J} can be obtained by using the atmospheric scattering model,
$$\mathbf{J}(x) = \frac{\mathbf{I}(x) - \mathbf{A}[1 - t(x)]}{t(x)};$$
- 8) Using PatchGAN to judge whether it is true or false;
- 9) Further training the network, repeat formula (8) until the loss function of the network is optimal, and the training is completed;
- 10) Save the optimal model.

4 实验结果与分析

4.1 实验环境配置与数据集

实验的硬件环境配置为 Interi7-9700K 处理器、NvidiaGTX-2060Ti 显卡;操作系统为 Ubuntu 20.04,在深度学习框架 PyTorch 下进行模型的搭建与训练。

使用的训练数据是 RESIDE 数据集,数据集中的图像为室内有雾图像,共 13900 张,均由现有的室内深度数据集 NYU2 中的 1390 个图像合成,根据大气散射模型将每个图像合成 10 个有雾模糊图像。此外,在验证所提算法的有效性时,采用 SOTS 数据集和 HSTS 数据集作为测试集。

4.2 评价指标

使用峰值信噪比 (PSNR) 和结构性相似度 (SSIM) 这两种不同的评价指标对处理后的无雾图像进行评价。PSNR 值越大,两张图像相似度越大,其表达式为

$$R_{PSNR} = 20 \log_{10} \left(\frac{V_{MAX}}{\sqrt{E_{MSE}}} \right), \quad (14)$$

式中: V_{MAX} 是像素点颜色的最大值; E_{MSE} 是有雾图像和无雾图像的均方误差。

与 PSNR 不同,SSIM 从亮度、对比度、结构 3 个方面来评价两张图像的相似度,取值范围在 $[0, 1]$ 之间,SSIM 值越大说明图像越相似,图像失真越小。

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (15)$$

式中: μ_x 代表 x 的平均值; μ_y 代表 y 的平均值; σ_x^2 代表 x 的方差; σ_y^2 代表 y 的方差; σ_{xy} 代表 x 、 y 的协方差; c_1 和 c_2 代表两个常数。

4.3 算法有效性验证

使用 RESIDE 数据集作为训练集,使用 SOTS 数据集和 HSTS 数据集作为测试集来验证所提算法的有效性。SOTS 数据集由室内图像生成的有雾图像组成,HSTS 数据集则是由室外图像生成的有雾图像组成。

所提算法与其他算法在 SOTS 部分数据集的 PSNR 与 SSIM 对比结果如图 6、图 7 所示,在 HSTS 部分数据集的 PSNR 与 SSIM 对比结果如图 8、图 9 所示。从图 6~9 可以看出,在处理室内有雾图像时,所提算法无论是在 PSNR 还是 SSIM 上均表现良好,相较于 CAP 算法、DCP 算法、MSCNN 算法均有所提升,部分图像的评价指标略低于 Dehaze 算法。对这一部分评价指标略低的去雾前后图像进行分析发现,这些图像均含有大量的天空区域,对大气光值的估计产生了影响,导致去雾后图像评价指标略低。此外,CAP 算法、DCP 算法在处理某些室外去雾难度较大的图像时,PSNR 值和 SSIM 值下降较大,去雾效果较差,所

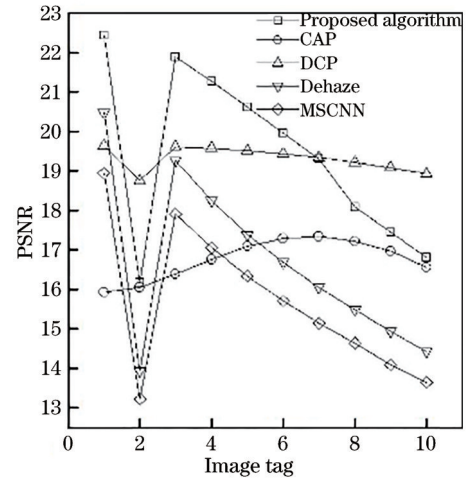


图 6 室内 PSNR 对比图

Fig. 6 Comparison of indoor PSNR

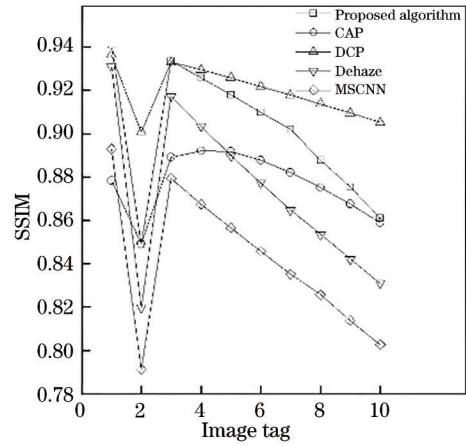


图 7 室内 SSIM 对比图

Fig. 7 Comparison of indoor SSIM

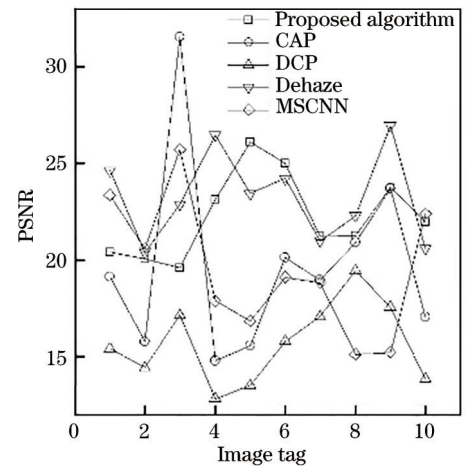


图 8 室外 PSNR 对比图

Fig. 8 Comparison of outdoor PSNR

提算法和 Dehaze 算法虽然有所下降,但下降幅度较小,相对比较稳定。

所提算法与其他算法在全部测试集的平均对比结果,包括 SOTS 数据集 SSIM 与 PSNR 的平均对比结

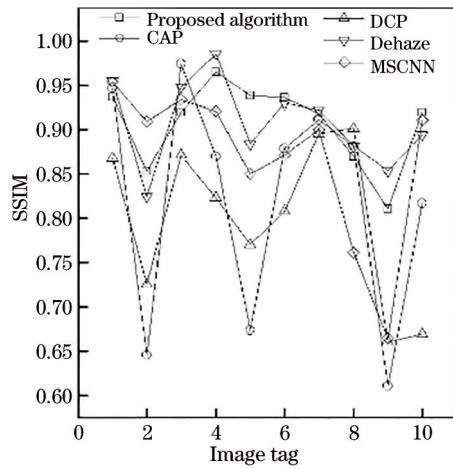


图9 室外 SSIM 对比图

Fig. 9 Comparison of outdoor SSIM

果和 HSTS 数据集 SSIM 与 PSNR 的平均对比结果如表 1、表 2 所示。从表中可以看出,所提算法在 SOTS 数据集上,SSIM 分别比 CAP、DCP、Dehaze、MCSNN 高 0.024、0.0059、0.0008、0.0695,PSNR 比 Dehaze 低 0.48,但分别比 CAP、DCP、MCSNN 高 1.9、1.89、3.74。在 HSTS 数据集上,SSIM 分别比 CAP、DCP、Dehaze、MCSNN 高 0.1079、0.0843、0.0052、0.0306,PSNR 分别比 CAP、DCP、MCSNN 高 4.12、6.37、2.75,验证了所提算法的有效性。

表 1 SOTS 数据集对比结果

Table 1 Comparison results on SOTS dataset

Algorithm	SSIM	PSNR
CAP	0.8524	18.96
DCP	0.8705	18.97
Dehaze	0.8756	21.34
MCSNN	0.8069	17.12
Proposed algorithm	0.8764	20.86

表 2 HSTS 数据集对比结果

Table 2 Comparison results on HSTS dataset

Algorithm	SSIM	PSNR
CAP	0.7859	18.24
DCP	0.8095	15.99
Dehaze	0.8886	22.94
MCSNN	0.8632	19.61
Proposed algorithm	0.8938	22.36

所提算法和其他对比算法在部分室外场景有雾图像的直观对比结果如图 10 所示。从图 10 可以看出:CAP 算法处理后的图像整体颜色偏暗,图像天空部分轻微失真;DCP 算法由于去雾不彻底导致天空区域以及人物边缘出现失真严重;Dehaze 算法处理后的图像,去雾效果良好,但对比度不够明显;所提算法处理后的图像去雾效果良好,在亮度和对比度上均有所提高。




图 10 室外场景各算法对比。(a)有雾图像;(b) CAP 结果;(c) DCP 结果;(d) Dehaze 结果;(e) MSCNN 结果;(f)所提算法结果
Fig. 10 Comparison of algorithms in outdoor. (a) Foggy images; (b) CAP results; (c) DCP results; (d) Dehaze results; (e) MSCNN results; (f) results of proposed algorithm

所提算法和其他算法在 4 张室外场景图像的 PSNR 值和 SSIM 值的对比结果如图 11、图 12 所示。从图 11、图 12 可以看出,所提算法的去雾性能较为稳定,在 4 张室外场景图的 PSNR 和 SSIM 均表现良好,DCP 算法与 MSCNN 算法在部分图像的指标下浮较大。

4.4 运行时间对比

所提算法与 CAP 算法、DCP 算法、Dehaze 算法、MSCNN 算法的平均运行时间对比结果如表 3 所示,所提算法的单张图像的平均处理时间为 0.93 s,具有较高的运行效率。

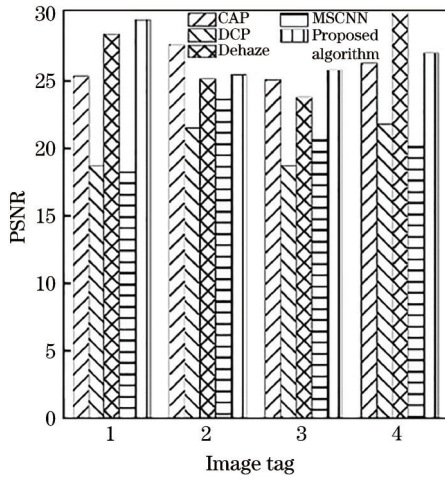


图 11 PSNR 对比图

Fig. 11 Comparison of PSNR

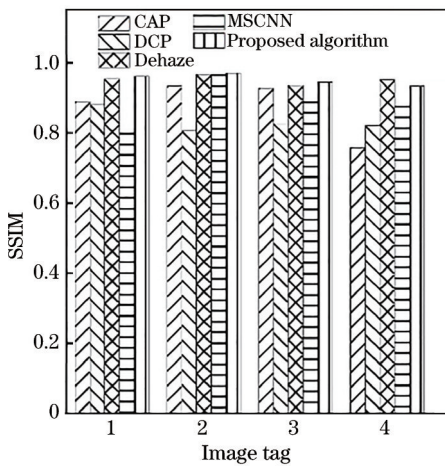


图 12 SSIM 对比图

Fig. 12 Comparison of SSIM

表 3 不同算法的运行时间对比

Table 3 Comparison of average running time of different algorithms

Algorithm	CAP	DCP	Dehaze	MSCNN	Proposed algorithm
Time /s	1.42	9.86	1.78	1.70	0.93

5 结 论

提出了一种基于注意力机制和 PatchGAN 的图像去雾算法,一方面解决了传统的图像去雾算法无法根据不同的雾度特征进行差异化处理的问题,另一方面该算法能够利用权重不同的特征进行互补,而不是仅仅专注于局部特征,这使得卷积网络的感受野变得更大,可以更好地利用全局相关的信息,使结果更精确,并且加快了网络的收敛速度。实验结果表明,所提算法无论是在室内数据集还是室外数据集均取得了良好的去雾效果,在有效去雾的同时,提高了图像的亮度和饱和度。

参 考 文 献

- [1] Shu Q L, Wu C S, Zhong Q X, et al. Alternating minimization algorithm for hybrid regularized variational image dehazing[J]. Optik, 2019, 185: 943-956.
- [2] 蒲亨飞, 黄治勇. 图像去雾算法研究综述[J]. 软件工程, 2021, 24(5): 2-6.
Pu H F, Huang Z Y. An overview of research on image dehazing algorithms[J]. Software Engineering, 2021, 24(5): 2-6.
- [3] Tufail Z, Khurshid K, Salman A, et al. Improved dark channel prior for image defogging using RGB and YCbCr color space[J]. IEEE Access, 2018, 6: 32576-32587.
- [4] Zhang W D, Dong L L, Pan X P, et al. Single image defogging based on multi-channel convolutional MSRCR [J]. IEEE Access, 2019, 7: 72492-72504.
- [5] 张登银, 鞠铭焯, 钱雯. 图像去雾算法研究现状与展望 [J]. 南京邮电大学学报(自然科学版), 2020, 40(5): 101-111.
Zhang D Y, Ju M Y, Qian W. Research status and prospect of image dehazing algorithm[J]. Journal of Nanjing University of Posts and Telecommunications (Natural Science Edition), 2020, 40(5): 101-111.
- [6] Nnolim U A. Single image de-hazing using adaptive dynamic stochastic resonance and wavelet-based fusion [J]. Optik, 2019, 195: 163111.
- [7] Gonzalez R C, Woods R E. Digital image processing[J]. Prentice Hall International, 2008, 28(4): 484-486.
- [8] Kim T K, Paik J K, Kang B S. Contrast enhancement system using spatially adaptive histogram equalization with temporal filtering[J]. IEEE Transactions on Consumer Electronics, 1998, 44(1): 82-87.
- [9] 史瑞雪, 高保禄, 乔颖婧. 基于融合策略的改进 Retinex 低照度图像增强算法[J]. 计算机测量与控制, 2021, 29(4): 159-164.
Shi R X, Gao B L, Qiao Y J. Improved Retinex low-light image enhancement algorithm based on fusion strategy[J]. Computer Measurement & Control, 2021, 29(4): 159-164.
- [10] 欧嘉敏, 胡晓, 杨佳信. 改进 Retinex-Net 的低光照图像增强算法[J]. 模式识别与人工智能, 2021, 34(1): 77-86.
Ou J M, Hu X, Yang J X. Low-light image enhancement algorithm based on improved Retinex-net[J]. Pattern Recognition and Artificial Intelligence, 2021, 34(1): 77-86.
- [11] 张振华, 陆金桂. 基于小波变换和改进的 Retinex 雾天图像增强[J]. 计算机应用与软件, 2021, 38(1): 227-231.
Zhang Z H, Lu J G. Foggy image enhancement based on wavelet transform and improved Retinex[J]. Computer Applications and Software, 2021, 38(1): 227-231.
- [12] 陈永, 郭红光, 艾亚鹏. 基于双域分解的多尺度深度学习单幅图像去雾[J]. 光学学报, 2020, 40(2): 0210003.
Chen Y, Guo H G, Ai Y P. Single Image Dehazing of Multiscale Deep-Learning Based on Dual-Domain Decomposition[J]. Acta Optica Sinica, 2020, 40(2): 0210003.
- [13] 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.
- [14] Berman D, Treibitz T, Avidan S. Non-local image dehazing[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 1674-1682.
- [15] 刘柯, 李旭健. 水下和微光图像的去雾及增强方法[J]. 光学学报, 2020, 40(19): 1910003.
Liu K, Li X J. De-Hazing and Enhancement Methods for Underwater and Low-Light Images[J]. Acta Optica Sinica, 2020, 40(19): 1910003.
- [16] 苏畅, 毕国玲, 金龙旭, 等. 基于暗通道图像质心偏移量的去雾算法[J]. 光学学报, 2019, 39(5): 0533001.
Su C, Bi G L, Jin L X, et al. Dehazing Algorithm Based on Dark-Channel Image Centroid Offset[J]. Acta Optica Sinica, 2019, 39(5): 0533001.
- [17] 杨燕, 张金龙. 基于雾度分布与自适应衰减的图像去雾算法[J]. 激光与光电子学进展, 2021, 58(22): 2210012.
Yang Y, Zhang J L. Image dehazing algorithm based on haze distribution and adaptive attenuation[J]. Laser & Optoelectronics Progress, 2021, 58(22): 2210012.
- [18] Liu Y, Shang J X, Pan L, et al. A unified variational model for single image dehazing[J]. IEEE Access, 2019, 7: 15722-15736.
- [19] 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: a Publication of the IEEE Signal Processing Society, 2016, 25(11): 5187-5198.
- [20] Ren W Q, Liu S, Zhang H, et al. Single image dehazing via multi-scale convolutional neural networks[M]//Leibe B, Matas J, Sebe N, et al. Computer vision-ECCV 2016. Lecture notes in computer science. Cham: Springer, 2016, 9906: 154-169.
- [21] 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, October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 4780-4788.
- [22] Zhang H, Patel V M. Densely connected pyramid dehazing network[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 3194-3203.
- [23] 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 (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 2805-2814.