

基于多尺度特征的无监督去雾算法

孙祥胜, 王国中*

上海工程技术大学电子电气工程学院, 上海 201620

摘要 为了解决单幅图像的去雾问题,提出一种新型端到端的网络,该网络利用改进的多尺度特征循环生成对抗网络。不同于以往的模型,所提的网络不依赖于传统的大气散射模型,并且在训练的过程中不需要对应匹配图像,大大简化了训练过程。接着设计一种新型的多尺度生成器,采用双通道融合的特征金字塔结构来最大程度地提取图像中的特征,同时引入多个全局和局部的鉴别器来改善网络性能与图像质量。实验结果表明,所提的模型在不同的数据集上都可以取得很好的结果。

关键词 图像处理; 图像去雾; 生成对抗网络; 多尺度特征; 局部鉴别器

中图分类号 TP391

文献标志码 A

doi: 10.3788/LOP202158.1610024

Unsupervised Dehazing Algorithm Based on Multi-Scale Features

Sun Xiangsheng, Wang Guozhong*

School of Electronic and Electrical Engineering, Shanghai University of Engineering Science, Shanghai 201620, China

Abstract In order to solve the problem of dehazing a single image, a new end-to-end network is proposed, which uses an improved multi-scale feature loop to generate a confrontation network. Unlike previous models, the proposed network does not rely on traditional atmospheric scattering models, and does not need to correspond to matching images during the training process, which greatly simplifies the training process. Next, a new type of multi-scale generator is designed, which uses a dual-channel fusion feature pyramid structure to extract the features in the image to the greatest extent, and introduces multiple global and local discriminators to improve network performance and image quality. Experimental results show that the proposed model can achieve good results on different datasets.

Key words image processing; image dehazing; generative adversarial network; multi-scale features; local discriminator

OCIS codes 100.4994; 100.2980

1 引言

图像中的雾状模糊是一种自然现象,该现象是在户外拍照的过程中由大气中的灰尘和薄雾引起的,这在很大程度上会降低图像的质量与对比度。这些低质量的图像会给高级的计算机视觉任务带来困难,如语义分割和目标检测,因此一些必要的图像预处理显得尤为重要,而且越来越多的科研人员讨

论与去雾相关的算法。

基于图像增强的去雾算法是尽可能消除图像噪声并提高图像对比度的,从而恢复出清晰无雾的图像,其中代表性算法包括直方图均衡化^[1]、自适应直方图均衡(AHE)^[2]和小波变换^[3]等。近年来,对单图像去雾的研究主要从基于先验信息和基于深度学习两个方面进行。He 等^[4]提出了一种暗通道先验去雾算法,实际上是一种统计意义上的算法。He

收稿日期: 2020-09-24; 修回日期: 2020-10-21; 录用日期: 2020-12-08

基金项目: 国家重点研发计划(2019YFB1802700)

通信作者: *wanggz@sues.edu.cn

等^[4]发现无雾图像的局部区域中的一些像素至少有一个颜色通道的亮度值较低。Zhu 等^[5]认为色彩衰减先验有利于获得图像的全面信息,可以有效去雾。Tan 等^[6]认为无雾图像比其相应的有雾图像具有更好的对比度,因此建立了一个模型来最大化去除雾图像的局部对比度。

基于深度学习的算法需要估计大气光强度和透射率,但是不同之处在于该算法可以直接利用神经网络高速有效地估计出相应的参数。Cai 等^[7]提出了一种端到端的训练模型,该模型使用神经网络来估计大气散射模型中的透射率。随后,Li 等^[8]提出了一种轻型的端到端网络,该网络改进了原始大气散射模型中的网络以实现去雾。Yi 等^[9]提出了一种边缘保留的金字塔密集连接去雾网络以精确估计传输图,此外还加入新的边缘保留损失函数并进行了优化。上述算法都旨在估算大气光强度和透射率,然后通过大气散射模型来获得无雾图像。

GAN(Generative Adversarial Networks)的概念最早由 Goodfellow 等于 2014 年提出,其主要包含生成器网络和鉴别器网络^[10]。受到 GAN 成功应用的启发,DCPDN(Densely Connected Pyramid Dehazing Network)利用 GAN 与新颖的联合鉴别器来确保估计的透射率^[11]。Yang 等^[12]联合使用了三个发生器来估计透射率。GAN 在早期开发的过程中,需要训练成对的匹配图像,训练网络如 Conditional GAN^[13]和 pix2pix^[14]。Zhu 等^[15]引入了周期一致的对抗网络,即 cycleGAN。2017 年,越来越多的人将注意力转向不需要配对数据的结构。Engin 等^[16]将周期一致和感知损失应用在去雾算法中。2019 年,Zhao 等^[17]改进了双鉴别器的算法结构并取得了良好的效果。但是,上述算法依旧很

难完美地应用在去雾任务中,尤其是生成图像存在局部模糊和整体分辨率偏低等问题。

通过总结和改进先前的网络结构,本文提出一种新的端到端去雾模型,即多尺度特征循环生成对抗去雾(MCF-Dehaze)网络。所提的新结构不依赖传统的大气物理模型,也不需要成对的有雾图像及其匹配的无雾度图像进行训练。大多数传统的 cycleGAN 生成器使用基于残差网络 ResNet 的结构,但无法完全捕获图像的全局信息,为此本文提出一种多尺度特征融合生成器,其可以有效捕获图像的细节。为了获得更高质量的无雾图像,本文提出一种多尺度鉴别器,其中使用一个全局鉴别器来鉴别整个图像的真实性,并使用三个局部鉴别器来指导生成器生成细节更逼真的图像。通过在鉴别器中加入谱归一化的算法,可以有效解决训练过程中稳定性差的问题。

2 所提算法

2.1 MCF-Dehaze 的整体结构

所提的模型是基于 cycleGAN 框架进行设计的,其包含生成器 G 和 F 和鉴别器 D,G 输出清晰的图像,D 区分是否生成真实的图像。与传统的 cycleGAN 结构不同,本文提出一种新的多尺度生成器和 4 个大小不同的鉴别器,其对图像的细节更加敏感。MFC-Dehaze 去雾网络的总体结构如图 1 所示。MFC-Dehaze 网络由两个生成器 G 和 F 组成,其中 G 负责将有雾图像映射到清晰图像,F 负责将清晰图像转换到有雾图像。另外,每个单向处理过程有 4 个鉴别器,包括全局鉴别器 D_global 以及三个局部鉴别器 D_L1、D_L2 和 D_L3。其中 D_L1 指的是原始图像一半的区域,D_L2 指的是原始

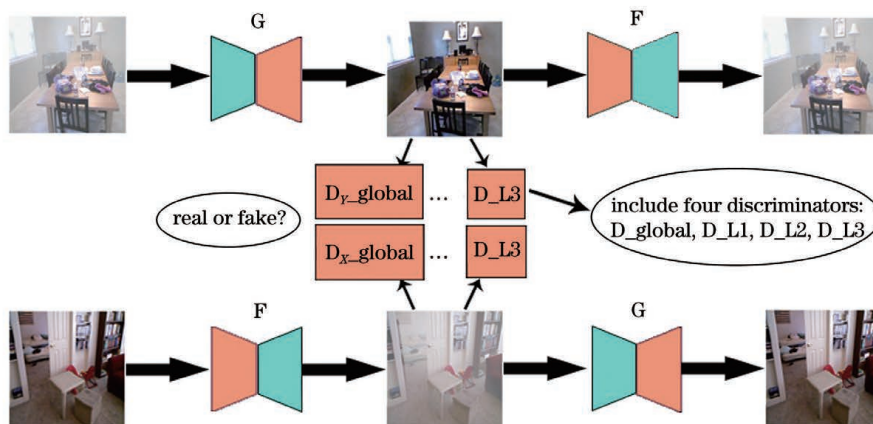


图 1 MFC-Dehaze 去雾网络的总体结构

Fig. 1 Overall structure of MFC-dehaze removal network

图像左上角 1/4 的区域, D_L3 指的是原始图像右上角 1/8 的区域。采用这种结构是希望对图像的细节进行有针对性的去雾处理,而出色的去雾网络结构必须对图像中的细节和天空敏感。一般而言,图像的细节主要集中在图像的中间,而天空部分集中在图像的左上角和右上角,这种全局和局部网络结构的设计可以使模型更好地学习图像中的细节特征。

2.2 MCF-Dehaze 的生成器结构

生成器的主要功能是将输入的有雾图像转换为无雾图像。多尺度生成器的网络结构如图 2 所示,

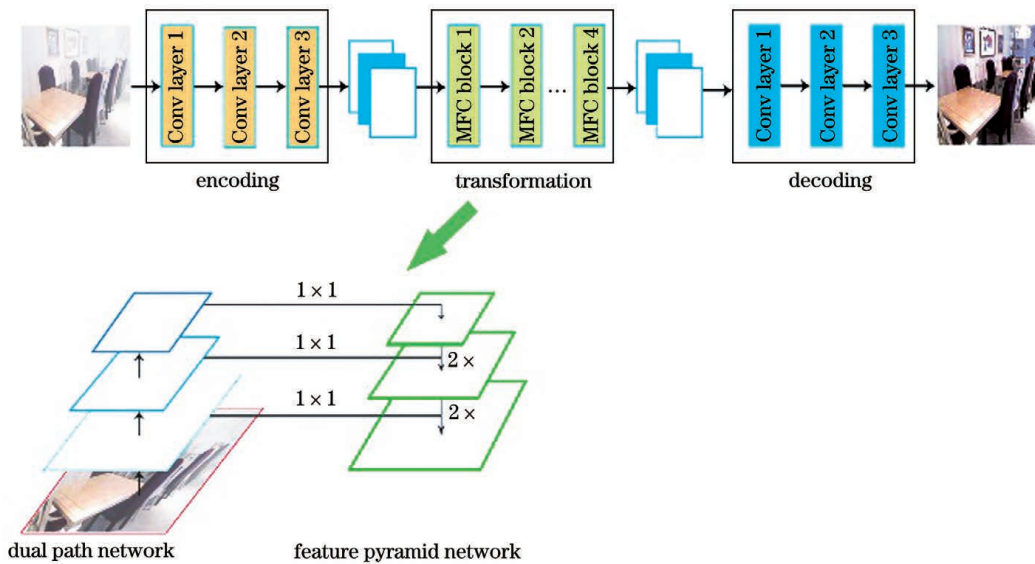


图 2 多尺度生成器的网络结构

Fig. 2 Network architecture of multiscale generator

2.3 MCF-Dehaze 的鉴别器结构

鉴别器 D 的目的是区分输入的去雾图像是否真实。多尺度特征鉴别器的框架如图 3 所示,其由一个全局鉴别器和三个局部鉴别器组成,其中 H 和 W 分别为输入图像的高和宽。全局鉴别器 D_global 负责比较整个图像以调整图像的整体特征,局部鉴别器 D_L1、D_L2 和 D_L3 用于检验不同局部区域以提高细节质量,选择这些区域的原因是通过大量实验发现这些区域对真实场景中的雾更敏感^[21-22],为此将 PatchGAN 应用在鉴别器中。对于全局鉴别器,需要提供完整的输入图像;对于局部鉴别器,需要从合成图像和地面真实的情况中提取局部区域,然后将每个部分分成几个分辨率为 70 pixel×70 pixel 的图像块,接着使用 PatchGAN 来检查每个补丁的样式并输出矩阵,最后将所有图像块的平均判断结果作为最终结果,这样的多尺度特征鉴别器可以指导发生器逐步产生更清晰的细节

其包含编码、转换和解码三个模块。编码部分使用卷积神经网络从输入图像中提取特征,利用三层卷积层将图像的特征提取为多个 32×32 的特征向量。关于编码模块,实验放弃了原始的 ResNet,而是采用双路径融合特征金字塔的新结构,双路径网络^[18]结合了 ResNet^[19]重复提取特征的能力和 DenseNet^[20]从先前层提取新特征的能力。将特征金字塔集成到网络中以便能够获取不同级别的特征,并构建各种规模的高级语义特征图。解码过程与编码过程相反,这里使用三层反卷积从特征向量逐步还原图像的低级特征,直到最终生成图像。

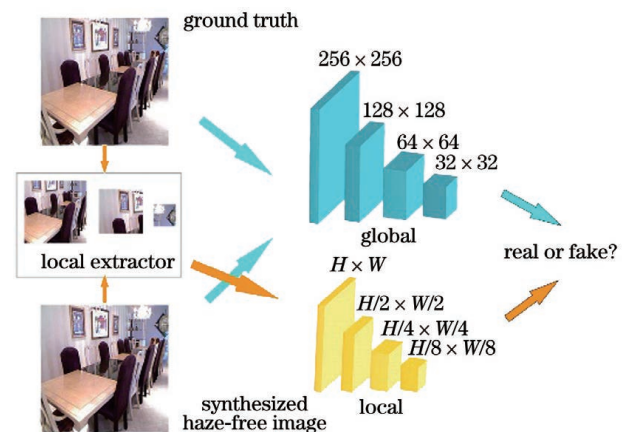


图 3 鉴别器的网络结构

Fig. 3 Network structure of discriminator

图像。

2.4 谱归一化

GAN 的训练一开始输入的是一段随机噪声,而且与真实数据分布相差很远,两个分布之间只有很

少的重叠部分。由于生成器生成的图像非常假,所以判别器一眼就能识破,这会导致判别器能够很快地区分真实数据和生成的假数据并且判别器的性能达到最优,但这会使判别器的损失急剧下降到 0,造成梯度无法更新甚至梯度消失。Dong 等^[23]提出了一种谱归一化的算法,该算法可以取得较好的效果。为此,本文在判别器中的卷积层后添加谱归一化层,使得判别器网络满足 1-Lipschitz 连续,这样网络的训练就会变得稳定。

鉴别器网络是一种多层的神经网络,可以采取单层网络的递归算法来进行分析。对于卷积层参数矩阵 \mathbf{A} 的最大奇异值,计算公式为

$$\sigma(\mathbf{A}) = \max_{\|\mathbf{h}\| \neq 0} \frac{\|\mathbf{A}\mathbf{h}\|_2}{\|\mathbf{h}\|_2} = \max_{\|\mathbf{h}\| = 1} \|\mathbf{A}\|_2, \quad (1)$$

式中: $\sigma(\mathbf{A})$ 表示 \mathbf{A} 的最大奇异值; \mathbf{h} 表示输入。使得归一化后的参数矩阵 \mathbf{W}_{SN} 的最大奇异值为 1,可表示为

$$\mathbf{W}_{\text{SN}} = \frac{\mathbf{W}}{\sigma(\mathbf{W})}。 \quad (2)$$

通过对鉴别器的网络参数进行谱归一化后,卷

积层的输入和输出均满足 1-Lipschitz 连续,这有助于网络训练稳定。

3 损失函数

设计的损失函数由 4 个部分组成,分别是对抗损失、循环一致性损失、感知损失^[24]和局部特征损失。对抗损失是为了使生成器生成的数据接近实际数据分布,循环一致性损失用于避免样本之间的冲突以确保执行无监督任务,感知损失和局部特征损失可以使去雾图像更清晰,纹理更丰富^[25-26]。

3.1 对抗损失

在 GAN 上生成数据的过程中,G 不断学习并提高制造图像数据的能力,D 逐渐提高数据辨别能力,而 G 和 D 在对抗的过程中达到平衡。这里有 4 个多尺度鉴别器,使用 D_* 来统一表示。令 \mathbf{X} 为有雾图像, \mathbf{Y} 为无雾图像,假设 $\mathbf{X} \rightarrow \mathbf{Y}$ 的映射过程是在生成器 G 中进行的, $\mathbf{Y} \rightarrow \mathbf{X}$ 的映射过程是在生成器 F 中进行的,则正向训练对抗损失函数 L_{adv} 可表示为

$$L_{\text{adv}}(G, D_{Y^*}) = \sum_{D_{Y^*}} E_{\mathbf{y} \sim P_{\text{data}}(\mathbf{y})} [\|\lg D_{Y^*}(\mathbf{y})\|_1] + E_{\mathbf{x} \sim P_{\text{data}}(\mathbf{x})} \left\{ \|\lg \{1 - D_{Y^*}[G(\mathbf{x})]\}\|_1 \right\}, \quad (3)$$

式中: D_{Y^*} 表示多尺度鉴别器; E 表示数学期望; \mathbf{x} 表示 \mathbf{X} 中的一幅有雾图像; \mathbf{y} 表示 \mathbf{Y} 中的一幅无雾图像; $P_{\text{data}}(\mathbf{x})$ 表示真实图像数据的分布。 D_{global} 、

$D_{1.1}$ 、 $D_{1.2}$ 和 $D_{1.3}$ 均属于 D_{Y^*} 。G 尝试生成类似于 \mathbf{Y} 域的图像,而 D_{Y^*} 旨在区分图像是真实的,还是伪造的。同样,后向训练损失函数可表示为

$$L_{\text{adv}}(F, D_{X^*}) = \sum_{D_{X^*}} E_{\mathbf{x} \sim P_{\text{data}}(\mathbf{x})} [\|\lg D_{X^*}(\mathbf{x})\|_1] + E_{\mathbf{y} \sim P_{\text{data}}(\mathbf{y})} \left\{ \|\lg \{1 - D_{X^*}[F(\mathbf{y})]\}\|_1 \right\}。 \quad (4)$$

由(4)式可以看到,D 希望使损失函数最大化,与此同时 G 希望损失函数最小化。

3.2 循环一致性损失

对抗损失函数只能保证生成器所生成的样本与真实样本相同,但是希望映射到 \mathbf{Y} 域的图像仍然可

以重新映射回 \mathbf{X} 域。因此,应满足 $\mathbf{x} \rightarrow G(\mathbf{x}) \rightarrow F[G(\mathbf{x})]$,使生成的有雾图像近似于原始有雾图像, $\mathbf{y} \rightarrow F(\mathbf{y}) \rightarrow G[F(\mathbf{y})]$,使生成的无雾图像近似于原始无雾图像。

使用上述条件可以将循环一致性损失函数定义为

$$L_C(G, F) = E_{\mathbf{x} \sim P_{\text{data}}(\mathbf{x})} \left\{ \|F[G(\mathbf{x}) - \mathbf{x}]\|_1 \right\} + E_{\mathbf{y} \sim P_{\text{data}}(\mathbf{y})} \left\{ \|G[F(\mathbf{y}) - \mathbf{y}]\|_1 \right\}。 \quad (5)$$

3.3 感性损失

为了进一步提高图像质量,引入感知损失函数,其可以减少细节损失,改善图像模糊,并使无雾图像

更逼真。使用预训练的 VGG (Visual Geometry Group)网络的 ReLU 激活层来实现感知损失,表达式为

$$L_P(G, F) = \frac{1}{C_i H_i W_i} \left\{ \|\varphi_i\{F[G(\mathbf{x})]\} - \varphi_i(\mathbf{x})\|_2^2 \right\} + \left\{ \|\varphi_i\{G[F(\mathbf{y})]\} - \varphi_i(\mathbf{y})\|_2^2 \right\}, \quad (6)$$

式中: C_i 、 H_i 和 W_i 分别表示第 i 层特征图的通道、高度和宽度; φ 表示可以提取不同图层特征的损失函数。

3.4 局部特征损失

使用局部提取器将图像分为感兴趣的多个区域, 这些区域对雾非常敏感, 并且能够大大提高合成图像的真实性。因此, 将损失函数添加到鉴别器中, 以便鉴别器引导生成器生成更清晰的无雾图像。正向转换过程中, 局部特征损失函数可表示为

$$L_{LF}(G, D_{Y^*}) = \min_G \sum_{D_{Y^*}} E_{x \sim P_{data}(x)} \times \sum_{i=1}^N \left\{ \|D_{Y^*}^{(i)}(\mathbf{X}) - D_{Y^*}^{(i)}[G(\mathbf{x})]\|_1 \right\}, \quad (7)$$

式中: N 表示特征提取层的数量; $D_{Y^*}^{(i)}$ 表示多尺度鉴别器标识符的第 i 层中的提取运算符。向后的过程可表示为

$$L_{LF}(F, D_{X^*}) = \min_F \sum_{D_{X^*}} E_{y \sim P_{data}(y)} \times \sum_{i=1}^N \left\{ \|D_{X^*}^{(i)}(\mathbf{Y}) - D_{X^*}^{(i)}[F(\mathbf{y})]\|_1 \right\}. \quad (8)$$

最终的目标损失函数可表示为

$$L = L_{adv} + \lambda_1 L_C + \lambda_2 L_P + \lambda_3 L_{LF}, \quad (9)$$

式中: λ_1 、 λ_2 和 λ_3 分别表示 L_C 、 L_P 和 L_{LF} 的权重。 L_{adv} 由两部分组成, 即 $L_{adv}(G, D_{Y^*})$ 和 $L_{adv}(F, D_{X^*})$ 。

4 实验结果及分析

为了验证所提的 MFC-Dehaze 网络在不同的合成数据集和真实数据集中的有效性, 将所提算法与其他去雾算法进行比较, 包括 He 等^[4]、Cai 等^[7]、Li 等^[8]、Engin 等^[16]、Zhao 等^[17] 和最近提出的其他网络。所提算法是在 Python 3.6 和 PyTorch 0.4 环

境中实现的, 实验中使用的硬件配置是具有 12 GB 内存的 NVIDIA Titan Xp GPU。

4.1 数据集

对 4 个数据集进行实验, 分别为 NYU-Depth 数据集^[27]、RESIDE 数据集^[28]、I-HAZE 数据集^[29] 和 O-HAZE 数据集。NYU-Depth 数据集由 1449 对匹配的图像组成, 包括真实无雾图像及其合成的有雾图像。RESIDE 数据集包含 5 个子集, 这些子集不仅具有合成图像, 而且还包含大量真实场景的有雾图像。I-HAZE 数据集和 O-HAZE 数据集分别包含 35 套室内和 45 套室外场景图像及其相应的无雾图像。此外, 使用相机在现实生活中拍摄大量的真实雾天图像并作为比较实验的测试集。

4.2 训练细节

在 NYU-Depth 数据集和 RESIDE 数据集中选择 5000 张图像作为训练集, 并将有雾图像放在 TrainA 文件夹中, 将无雾图放在 TrainB 文件夹中。值得注意的是, 实验不需要使两个文件夹 A 和 B 中的图像一一对应, 只需放置大量所需的图像。在参数选择方面, 将学习率调整为 0.002, Adam 优化器的批处理大小为 1, 所有样本的尺寸均调整为 256 pixel \times 256 pixel 并进行训练, 损失函数的参数 $\lambda_1 = 10$ 、 $\lambda_2 = 0.1$ 和 $\lambda_3 = 5$ 。为了客观地评估生成图像的质量, 选择峰值信噪比 (PSNR) 和结构相似指数 (SSIM) 两个指标来比较不同算法的图像质量。

4.3 NYU-Depth 数据集结果

首先在 NYU-Depth 数据集上进行实验, 将所提算法与 7 种先前提出的去雾算法进行比较, 不同算法的去雾结果如图 4 所示, 各算法的平均 PSNR 和 SSIM 如表 1 所示。从图 4 和表 1 可以看到, 对




图 4 不同算法在 NYU-Depth 数据集的去雾结果。(a) 原始图像; (b) 文献[4]; (c) 文献[7]; (d) 文献[16]; (e) 文献[17]; (f) 所提算法; (g) 真值图像

Fig. 4 Dehazing results of different algorithms in NYU-Depth dataset. (a) Original images; (b) Ref. [4]; (c) Ref. [7]; (d) Ref. [16]; (e) Ref. [17]; (f) proposed algorithm; (g) ground truth images

表 1 不同算法在 NYU-Depth 数据集中的对比结果

Table 1 Comparison results of different algorithms in NYU-Depth dataset

Index	Ref. [4]	Ref. [7]	Ref. [8]	Ref. [14]	Ref. [15]	Ref. [16]	Ref. [17]	Proposed algorithm
PSNR /dB	16.84	18.98	19.28	21.65	18.63	19.41	24.89	27.83
SSIM	0.768	0.783	0.831	0.824	0.796	0.794	0.865	0.908

于视觉角度方面,所提算法在图像的对比度和细节方面都得到极大改善,文献[4]在亮度方面产生的效果非常差,文献[16-17]的算法不能有效去除整个图像中的雾;对于 PSNR 和 SSIM 指标方面,所提算法均优于其他算法,与文献[16-17]相比,两者都有较大的提升。

4.4 I-HAZE 与 O-HAZE 数据集结果

不同算法在 I-HAZE 数据集与 O-HAZE 数据集的去雾效果如图 5 所示,各算法在 I-HAZE 数

据集与 O-HAZE 数据集的平均 PSNR 和 SSIM 如表 2 和表 3 所示。从图 5、表 2 和表 3 可以看到,所提算法可以极大地还原图像细节,相比于其他几种算法未出现模糊、光晕和色彩异常等现象,极大地保留图像的原始信息,而且所提算法比其他算法具有更高的 PSNR 值和 SSIM 值;cycleGAN 算法和 pix2pix 算法的原始结构无法同时考虑图像的整体感观,所以色彩的还原度与效果远不及所提算法。




图 5 不同算法在 I-HAZE 数据集与 O-HAZE 数据集的去雾结果。(a)原始图像;(b)文献[4];(c)文献[8];(d)文献[15];(e)文献[11];(f)文献[14];(g)所提算法;(h)真值图像

Fig. 5 Dehazing results of different algorithms in I-HAZE and O-HAZE datasets. (a) Original images; (b) Ref. [4]; (c) Ref. [8]; (d) Ref. [15]; (e) Ref. [11]; (f) Ref. [14]; (g) proposed algorithm; (h) ground truth images

表 2 不同算法在 I-HAZE 数据集的对比结果

Table 2 Comparison of results of different algorithms in I-HAZE dataset

Index	Ref. [4]	Ref. [7]	Ref. [8]	Ref. [14]	Ref. [15]	Ref. [16]	Ref. [17]	Proposed algorithm
PSNR /dB	15.84	18.43	20.42	21.65	19.88	20.67	24.87	27.61
SSIM	0.761	0.766	0.811	0.807	0.853	0.864	0.853	0.921

表 3 不同算法在 O-HAZE 数据集的对比结果

Table 3 Comparison of results of different algorithms in O-HAZE dataset

Index	Ref. [4]	Ref. [7]	Ref. [8]	Ref. [14]	Ref. [15]	Ref. [16]	Ref. [17]	Proposed algorithm
PSNR /dB	14.61	19.28	20.14	22.72	22.68	21.35	25.14	26.93
SSIM	0.781	0.804	0.842	0.821	0.845	0.826	0.833	0.937

为了更好地证明所提算法的有效性,分别从网络结构和损失函数两个方面在 O-HAZE 数据集与 I-HAZE 数据集中进行消融实验,从 4 个不同组成部分进行比较。1) cycleGAN: 仅仅使用初始的 cycleGAN 结构; 2) cycleGAN + spectral normalization: 在初始网络的基础上为鉴别器网络加上谱归一化; 3) cycleGAN + four discriminator: 为初始网络上

所设计的 4 个鉴别器; 4) ours: 同时加入多尺度生成器、谱归一化和 4 个鉴别器的网络,消融实验结果如表 4 所示。从表 4 可以看到,相比于初始的网络结构,所提网络结构的效果有了很大的提升。选择不同的 λ_1 、 λ_2 和 λ_3 值进行比较,从而找到最佳的参数,结果如表 5 所示。从表 5 可以看到,当 $\lambda_1=10$ 、 $\lambda_2=0.1$ 和 $\lambda_3=5$ 时,PSNR 与 SSIM 的指标均是最高。

表 4 网络结构的消融实验结果

Table 4 Results of ablation experiments for network structure

Index	cycleGAN	cycleGAN+	cycleGAN+	Ours
		spectral normalization	four discriminator	
PSNR /dB	22.71	23.63	25.88	26.92
SSIM	0.772	0.812	0.866	0.936

表 5 不同参数的消融实验结果

Table 5 Results of ablation experiments with different parameters

Index	$\lambda_1=5,$ $\lambda_2=5.0,$ $\lambda_3=5$	$\lambda_1=10,$ $\lambda_2=0.5,$ $\lambda_3=5$	$\lambda_1=10,$ $\lambda_2=0.1,$ $\lambda_3=5$
	PSNR /dB	21.32	23.78
SSIM	0.791	0.892	0.936

4.5 真实数据集结果

在不同的天气条件下测试真实图像,包括晴天、阴天、薄雾和重雾等,同时使用相机在有雾的天气下拍摄一些高清图像。将所提算法与其他算法进行比较,结果如图 6 所示。从图 6 可以看到,无论是色彩饱和度还是图像的细节轮廓,所提的网络结构都得到很大的改进并且更通用,具有很好的泛化性能。

5 结 论

本文提出一种新型基于循环生成对抗网络的端到端去雾框架,即 MFC-Dehaze,该框架利用一个改进的多尺度生成器和 4 个局部鉴别器对图像进行去雾。无论是在合成图像上还是在现实世界中,所提算法都可以获得令人满意的结果。实验结果表明,MFC-Dehaze 去雾网络可以稳定且有效地恢复无雾图像。在以后的工作中,将基于提出的单图像去雾网络来实时视频去雾。

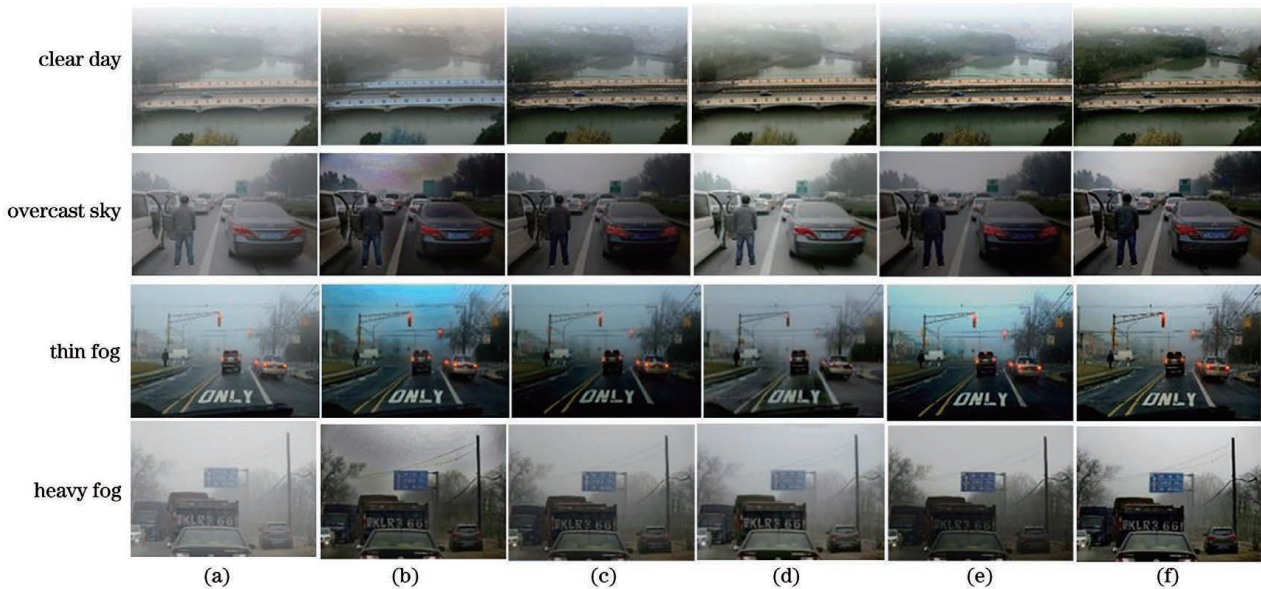


图 6 不同算法的真实数据对比结果。(a)原始图像;(b)文献[4];(c)文献[8];(d)文献[15];(e)文献[11];(f)所提算法

Fig. 6 Real data comparison results of different algorithms. (a) Original images; (b) Ref. [4]; (c) Ref. [8];

(d) Ref. [15]; (e) Ref. [11]; (f) proposed algorithm

参 考 文 献

- [1] 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.
- [2] Stark J A. Adaptive image contrast enhancement using generalizations of histogram equalization [J]. IEEE Transactions on Image Processing, 2000, 9(5): 889-896.
- [3] Antonini M, Barlaud M, Mathieu P, et al. Image coding using wavelet transform [J]. IEEE Transactions on Image Processing, 1992, 1(2): 205-220.
- [4] 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.

- [5] 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.
- [6] Tan R T, Pettersson N, Petersson L. Visibility enhancement for roads with foggy or hazy scenes [C]//2007 IEEE Intelligent Vehicles Symposium, June 13-15, 2007, Istanbul, Turkey. New York: IEEE Press, 2007: 19-24.
- [7] 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.
- [8] 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 (ICCV), October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 4780-4788.
- [9] Yi Z L, Zhang H, Tan P, et al. DualGAN: unsupervised dual learning for image-to-image translation [EB/OL]. (2018-10-09) [2020-09-23]. <https://arxiv.org/abs/1704.02510v4>.
- [10] Frid-Adar M, Diamant I, Klang E, et al. GAN-based synthetic medical image augmentation for increased CNN performance in liver lesion classification [J]. *Neurocomputing*, 2018, 321: 321-331.
- [11] 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.
- [12] Yang X T, Xu Z, Luo J B. Towards perceptual image dehazing by physics-based disentanglement and adversarial training [C] // In Association for the Advancement of Artificial Intelligence (AAAI), February 2-7, 2018, Hilton New Orleans Riverside, New Orleans, Louisiana, USA. New York: AAAI, 2018.
- [13] Mirza M, Osindero S. Conditional generative adversarial nets [EB/OL]. (2014-11-06) [2020-09-23]. <https://arxiv.org/abs/1411.1784>.
- [14] Isola P, Zhu J Y, Zhou T H, et al. Image-to-image translation with conditional adversarial networks [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 5967-5976.
- [15] Zhu J Y, Park T, Isola P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks [C]//2017 IEEE International Conference on Computer Vision ICCV, October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 2242-2251.
- [16] Engin D, Genc A, Ekenel H K. Cycle-dehaze: enhanced CycleGAN for single image dehazing [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), June 18-22, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 18347299.
- [17] Zhao J M, Zhang J, Li Z, et al. DD-CycleGAN: unpaired image dehazing via double-discriminator cycle-consistent generative adversarial network [J]. *Engineering Applications of Artificial Intelligence*, 2019, 82: 263-271.
- [18] Yi Z L, Zhang H, Tan P, et al. DualGAN: unsupervised dual learning for image-to-image translation [C]//2017 IEEE International Conference on Computer Vision (ICCV), October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 2868-2876.
- [19] 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 (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [20] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017, Honolulu, HI. New York: IEEE Press, 2017: 17355312.
- [21] Heusel M, Ramsauer H, Unterthiner T, et al. GANs trained by a two time-scale update rule converge to a local Nash equilibrium [EB/OL]. (2018-01-12) [2020-09-23]. <https://arxiv.org/abs/1706.08500>.
- [22] Liu Y H, Wu S. Image dehazing algorithm based on multi-scale fusion and adversarial training [J]. *Laser & Optoelectronics Progress*, 2020, 57 (6): 061015.
刘宇航, 吴帅. 基于多尺度融合和对抗训练的图像去雾算法 [J]. *激光与光电子学进展*, 2020, 57(6): 061015.
- [23] Dong C, Loy C C, He K M, et al. Image super-resolution using deep convolutional networks [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 38(2): 295-307.
- [24] Johnson J, Alahi A, Li F F. Perceptual losses for real-time style transfer and super-resolution [M] // Leibe B, Matas J, Sebe N, et al. *Computer vision-ECCV 2016. Lecture notes in computer science*. Cham: Springer, 2016, 9906: 694-711.
- [25] Peng Y F, Du T T, Gao Y, et al. Low-illumination

- remote sensing image enhancement based on conditional generation adversarial network[J]. *Laser & Optoelectronics Progress*, 2020, 57(14): 141015.
- 彭晏飞, 杜婷婷, 高艺, 等. 基于条件生成对抗网络的低照度遥感图像增强[J]. *激光与光电子学进展*, 2020, 57(14): 141015.
- [26] Cui X M, Yu F Q. Multi style sketch-photo generation based on conditional generation adversarial networks [J]. *Laser & Optoelectronics Progress*, 2020, 57(18): 181018.
- 崔小曼, 于凤芹. 基于条件生成对抗网络的多风格素描-照片生成[J]. *激光与光电子学进展*, 2020, 57(18): 181018.
- [27] Ancuti C, Ancuti C O, de Vleeschouwer C. D-HAZY: a dataset to evaluate quantitatively dehazing algorithms[C]//2016 IEEE International Conference on Image Processing (ICIP), September 25-28, 2016, Phoenix, AZ, USA. New York: IEEE Press, 2016: 2226-2230.
- [28] 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.
- [29] Ancuti C O, Ancuti C, Timofte R, et al. I-HAZE: a dehazing benchmark with real hazy and haze-free indoor images[EB/OL]. (2018-04-13)[2020-09-23]. <https://arxiv.org/abs/1804.05091>.