

基于生成对抗网络的图像去雾算法

仲伟峰^{1,2*}, 赵晶¹

¹哈尔滨理工大学自动化学院, 黑龙江 哈尔滨 150080;

²黑龙江省复杂智能系统与集成重点实验室, 黑龙江 哈尔滨 150080

摘要 近几年在图像去雾领域中基于深度学习的方法层出不穷,利用循环生成对抗网络(CycleGAN)设计图像去雾算法。在CycleGAN中,通过对生成器进行改进来达到预期的处理效果。在生成器的编码网络和解码网络中选用Leaky ReLU和tanh两种激活函数,并对转换网络的残差块进行减少数量处理和加权优化处理。本设计能够更好地展示单幅有雾图像的清晰度和细节方面,峰值信噪比、结构相似性及信息熵等客观评价指标都得到了提升。

关键词 机器视觉; 图像处理; 循环生成对抗网络; 有雾图像; 光学模型

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP202259.0415007

Image Defogging Algorithm Based on Generative Adversarial Network

Zhong Weifeng^{1,2*}, Zhao Jing¹

¹School of Automation, Harbin University of Science and Technology, Harbin, Heilongjiang 150080, China;

²Heilongjiang Key Laboratory of Complex Intelligent System and Integration, Harbin, Heilongjiang 150080, China

Abstract Recently, deep learning-based algorithms have emerged in the image defogging field. A cyclic generative adversarial network (CycleGAN) was used to create an image defogging algorithm in this study. Further, the desired processing effect was achieved by optimizing the generator in the CycleGAN. In the encoding and decoding networks of the generator, Leaky ReLU and Tanh activation functions were used, and the residual blocks of the conversion network were optimized by reducing the number and weighting optimization. The use of fog in the design of a single image can result in improved clarity and detail. Peak signal-to-noise ratio, structural similarity, and information entropy are some of the objective evaluation indexes that were enhanced.

Key words machine vision; image processing; cycle generative adversarial network; image with fog; optical model

1 引言

在室外图像拍摄和采集过程中,经常受到雾霾天气的影响,导致采集到的图像质量下降,此时图像去雾处理技术就显示出了意义与价值。近些年涌现了许多图像去雾方法,其中基于深度学习的图像去雾方法得到了人们的重视。

基于深度学习的去雾方法可以分为两种:一种

是基于大气退化模型,利用神经网络对模型中的参数进行估计;另一种是利用输入的有雾图像,学习有雾图像到清晰图像之间的映射关系,直接输出去雾后的图像,完成端到端的图像去雾^[1]。2014年,Goodfellow等^[2]首先提出了生成对抗网络(GAN)这一概念,随后GAN在图像风格迁移等任务中得到了广泛的应用。Li等^[3]对大气散射模型进行了优化,基于cGAN^[4]提出了一种端到端的非线性去雾

收稿日期: 2021-07-14; 修回日期: 2021-08-19; 录用日期: 2021-09-13

通信作者: *zhongweifeng@hrbust.edu.cn

模型(an all-in-one network for dehazing and beyond, AODNet),直接利用卷积神经网络产生清晰图像。Zhu等^[5]创新性地探究图像去雾、生成式对抗网络和可微设计的联系,提出了DehazeGAN,获得了很好的去雾效果,也给图像去雾领域提供了另一种思路。Qin等^[6]在2020年提出了一种端到端特征融合注意力网络(feature fusion attention network for single image dehazing, FFANet),主要应用一种特征注意(FA)模块将通道注意与像素注意机制结合在一起。Chen等^[7]将搭建的门控上下文聚合网络应用在图像的去雾及去雨(GCANet)的任务中,搭建了GCANet模型,直接建立模糊图像和清晰图像之间的联系,不用套用先验知识。

以上模型对循环生成对抗网络进行了进一步的研究。DehazeGAN模型将生成对抗网络与图像去雾任务联系起来,GCANet模型则是直接建立了模糊图像与清晰图像之间的联系。在这个启发下,本文对基于循环生成对抗网络的图像去雾算法进行了改进,同时通过FFANet明确了在本次设计中不引入FA模块,此模块并不适合应用于图像风格转移的任务中。本次设计的主要结构是生成器和判别器,能够实现在非配对的数据集下通过损失函数对模型进行训练,学习从有雾数据域到无雾数据域之间的映射关系,从而完成去雾操作,生成无雾图像。本文设计主要是针对生成器中的转换网络结构和激活函数进行优化的,改善了去雾图像的质量,提升了客观评价指标。

2 生成式对抗网络

GAN的思想就是利用生成器和判别器两个网络彼此博弈,生成器的作用就是生成目标无雾图像,判别器的目标就是来判断生成图片的真假。

2.1 GAN

标准的GAN^[8]是一种通过对抗过程来估计生成模型的网络,此模型的思想是一种二元零和博弈思想(two-player game),由一个生成器(generator)和一个判别器(discriminator)组成,二者相互对抗来达到最好的生成效果,流程如图1所示。

随机噪声被生成器接收,通过生成模型(一般为神经网络)来生成一个假的样本。而判别器的输入是一个样本,通过判别网络对这个输入的样本进行判断,是来自于真实数据还是生成器生成的假的数据。在整个过程中,生成网络努力地生成更接近

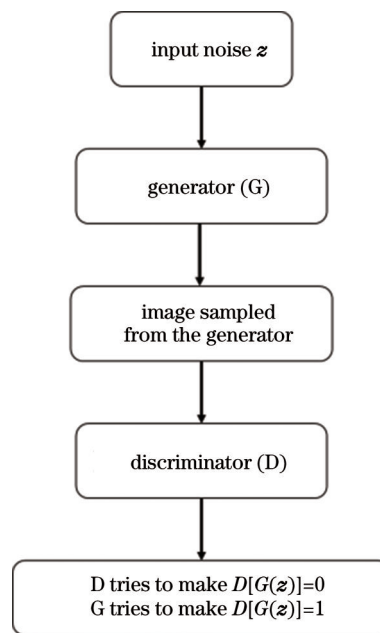


图1 GAN流程

Fig. 1 Flow chart of GAN

于真实的图像来欺骗判别网络,而判别网络则是努力去判断识别图像的真假,这就是二者之间的博弈。随着时间的推移,生成器和判别器的不断对抗最终会达到一个动态平衡:生成器生成的图像接近于真实图像的分布,而判别器则识别不出图像的真假^[9],最终的平衡点即为纳什均衡点。为了让二者在博弈中达到平衡和约束,GAN中的损失函数为

$$\min_G \max_D V(D, G) = E_{x \sim p_{\text{data}}(x)} [\log_{10} D(x)] + E_{z \sim p_z(z)} \left\{ \log_{10} \{1 - D[G(z)]\} \right\}. \quad (1)$$

这是一个最大最小优化,既包含了判别模型的优化,又包含了生成模型以假乱真的优化。判别器D的学习目标是使D(x)大,D[G(z)]小,所以要最大化(1)式;生成器G的学习目标是使D[G(z)]大,所以要最小化(1)式。两者相互对抗,共同学习,训练的过程是一个交替进行的过程。

2.2 循环生成式对抗网络

循环生成对抗网络(CycleGAN)^[10]是条件生成对抗网络,在2017年首先被Zhu等提出。最开始CycleGAN被用于对两种风格的图片进行相互的转换。传统的GAN是单向生成的,而CycleGAN是互相生成的,网络是个环形,所以命名为cycle。在CycleGAN被提出后,大量学者都将其应用于相应的图像转换方面,如对照片与油画画作之间进行风格转换。在2018年,Engin等^[11]将CycleGAN应用于单幅

图像的去雾操作,在原始的 CycleGAN 中引入循环一致性损失,并通过在跨数据集场景中进行实验来证明模型对不同域的普适性,所提算法主要是对此模型进行了传承与改进。在 CycleGAN 中,对循环损失函数

和对抗损失函数进行加权求和,约束网络学习得到有雾图像和清晰图像之间的映射关系,并且不要求训练的数据集一一对应,具体的流程如图 2 所示。




图 2 CycleGAN 示意图

Fig. 2 Schematic of CycleGAN

图 2 中, G 和 F 分别表示 X 域和 Y 域的映射函数, D_X 和 D_Y 是相应的判别网络,所以由此可以构造 GAN 损失,表达式为

$$L_{GAN}(G, D_Y, X, Y) = E_{y \sim p_{data}(y)} [\log_{10} D_Y(y)] + E_{x \sim p_{data}(x)} \left\{ \log_{10} \left[1 - D_Y[G(x)] \right] \right\}, \quad (2)$$

$$L_{GAN}(F, D_X, Y, X) = E_{x \sim p_{data}(x)} [\log_{10} D_X(x)] + E_{y \sim p_{data}(y)} \left\{ \log_{10} \left[1 - D_X[F(y)] \right] \right\}. \quad (3)$$

此网络中还有循环一致损失,即两个生成器的损失之和,表达式为

$$L_{cyc}(G, F) = E_{x \sim p_{data}(x)} \left\{ \left\| F[G(x)] - x \right\|_1 \right\} + E_{y \sim p_{data}(y)} \left\{ \left\| G[F(y)] - y \right\|_1 \right\}. \quad (4)$$

最终网络的所有损失加起来为 $L(G, F, D_X, D_Y)$, 表达式为

$$L(G, F, D_X, D_Y) = L_{GAN}(G, D_Y, X, Y) + L_{GAN}(F, D_X, Y, X) + \lambda L_{cyc}(G, F), \quad (5)$$

式中: λ 是循环一致损失的权重系数。

3 基于 CycleGAN 的去雾算法

3.1 大气散射模型

为了有效地处理雾天图像,首先就要分析雾天图像的成像机制和退化过程,建立相应的物理模型。光线从场景点到接收点的传播过程中,遇到悬浮于大气中粒径较大的气溶胶粒子,与之发生交互作用,从而导致雾天捕获的图像对比度和颜色等特征衰减明显^[12],其中散射是可见光波段雾天图像降质的主要因素。McCartney^[13]在 1977 年首次提出了经典的大气散射模型。在具体的图像处理过程中,

常用的线性模型表示为

$$I = J(x)t(x) + A[1 - t(x)], \quad (6)$$

$$t(x) = e^{-\beta(\lambda)d(x)}, \quad (7)$$

式中: $I(x)$ 和 $J(x)$ 分别代表有雾图像和无雾图像; $t(x)$ 为场景透射率; $d(x)$ 为场景深度; A 代表环境光; $\beta(\lambda)$ 为大气散射系数。这个线性模型能够很好地对雾天成像过程建模。要想复原得到场景的去雾图像,可以首先去掉大气对成像的影响,然后对衰减掉的光线进行补偿,是雾天成像的逆过程。并且透射率 $t(x)$ 与场景深度 $d(x)$ 之间的关系也为后来深度学习方法的训练数据合成提供了思路,依据大气散射模型对模型中未知参数进行估计,反向推导清晰图像,从而达到图像去雾的目的。

3.2 CycleGAN 去雾算法设计

对 GAN 的研究使得图像生成的质量达到了新的高度,利用 CycleGAN 的图像风格转换功能,可以完成有雾图像向无雾图像转换的任务。CycleGAN 模型网络不需要样本的完全对应,即不需要一一对应的成对数据集就可以完成目标任务,训练过程如图 3 所示。

由图 3 可知,在训练过程中生成器和判别器是相互约束的。其中生成器分为三个部分:编码网络、转换网络、解码网络。输入的图片经编码网络进行卷积特征提取后进入残差网络进行转换。受到如图 4 所示的 U-Net^[14] 的启发,在编码和解码间引入跳跃连接(skip connection)来进行数据流的传输,由此可以提供更多的传输信息,信息叠加后可以在原始特征信息的基础上得到新的特征表示,在进入解码器后还原出低级特征,生成无雾图像。生成器的结构如图 5 所示。

每个编码网络由卷积层、实例规范化和 Leaky ReLU 激活函数组成,每个解码网络由上采样缩放卷积、实例规范化和 tanh 激活函数组成。Leaky

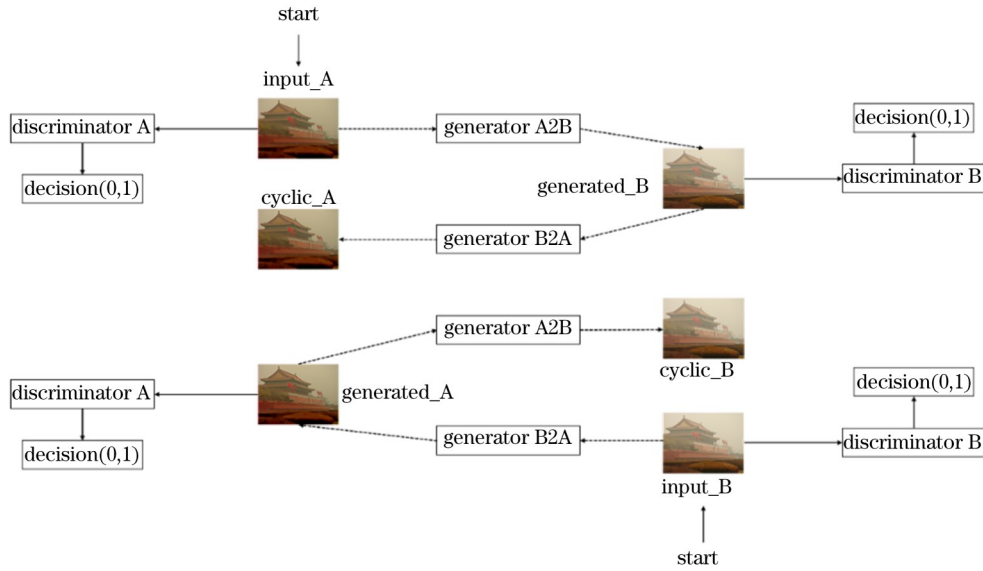


图 3 CycleGAN 结构示意图

Fig. 3 Schematic of CycleGAN structure




图 4 U-Net 结构图

Fig. 4 U-Net structure

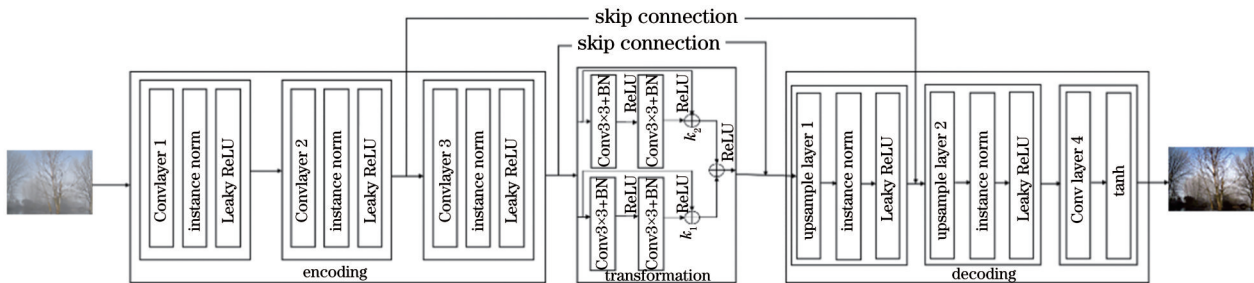


图 5 生成器结构图

Fig. 5 Generator structure

ReLU是一种改进的ReLU激活方法,ReLU的所有负值都为0,而Leaky ReLU会给所有负值赋予一个非零的斜率,具有ReLU的所有优点,可以更加有效地进行梯度下降与反向传播,在一定程度上能够避免梯度爆炸和梯度消失的问题,并且Leaky ReLU能够解决dead ReLU的问题。在编码网络中,并未选用批标准化(BN)这种对批量中所有样本进行归一化的算法,而是选用了实例归一化(IN)这种更适合对单个像素有更高要求的归一化算法^[15]。在图像风格迁移中,图片生成的结果主要依赖于某个图像实例,所以整个BN不适合图像风格化,此时使用IN不仅可以加速模型收敛,并且可以保持每个图像实例之间的独立。在解码网络中,采取的tanh激活函数在循环过程中会扩大特征效果,能够有利于提高训练的效率。其中上采样采用的是缩放卷积,首先使用最邻近插值将图像缩放到目标尺寸,即与原有雾图像尺寸相同,然后再进行卷积操作。在编码网络和解码网络中,卷积大小有

3×3 和 7×7 两种,卷积步长有1和2两种,具体尺寸信息如表1所示。

表1 生成器尺寸信息

Table 1 Size information of generator

Layer name	Kernel size	Stride
Conv layer 1	7×7	1
Conv layer 2	3×3	2
Conv layer 3	3×3	2
Conv layer 4	7×7	1
Upsample layer 1	3×3	2
Upsample layer 2	3×3	2

在近几年的研究中发现,网络的深度是使网络性能更优化的一个关键因素,但是随着网络深度的加深,暴露出了网络退化的问题,如在对20层和56层的普通网络进行对比时,就发现56层网络的性能远低于20层网络,如图6所示。这时就引入了残差网络ResNet^[16],去解决退化的问题。

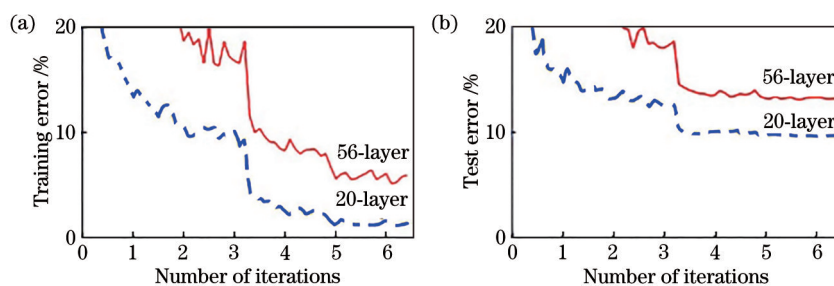


图6 20层和56层网络训练时的误差。(a)训练误差;(b)测试误差

Fig. 6 Errors in 20-layer and 56-layer network training. (a) Training error; (b) test error

在转换网络阶段,原始的CycleGAN中使用的是9个残差块串联组成的转换器。在此次设计中,选用4个带有权重的残差块两两串联后再并联作为特征转换器,结构如图7所示,减小了残差网络深度的同时增大了残差网络的宽度,这也就增加了网络对尺度的适应性。残差块不同的权值会影响生成

图片的有雾或清晰效果,权值的变化可以使生成图片不同程度地趋于有雾或者清晰的风格类型。

判别器则采用与原始CycleGAN架构判别器相同的网络结构,其在图像的风格迁移任务中取得的效果较好,所以在此不做改进。

4 实验结果与分析

本次设计均在Intel(R) Core(TM) i9-10900X CPU@3.70 GHz和NVIDIA Quadro RTX 6000 24G显存的GPU,操作系统为Window 10的工作站上进行。在数据集的选择上,基于网上的开源数据集D-Hazy、I-HAZE、O-HAZE、ITS和NYU等进行选取和整理,构建自用数据集进行训练与测试任务。

为了选取最佳的网络结构,在实验过程中进行了相应的对比。本次设计主要对生成器的结构进行了优化,在对转换网络进行结构的优化时发现,

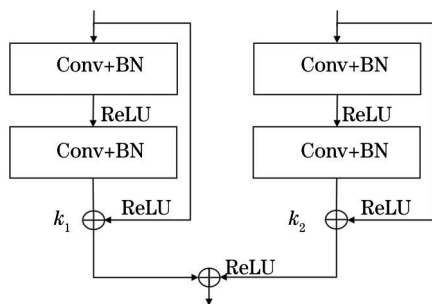


图7 权重残差模块

Fig. 7 Weighted residual module

单纯的残差块之间的串联会导致网络深度的增加,易出现梯度消失和梯度爆炸问题,之后激活函数的选取方面也是考虑到了这个问题。在残差块数量减少后进行串联再并联,首先就一定程度上减小了网络的深度,同时还增大了网络的宽度,训练更加容易。在实验后发现,4个残差块构成的两层结构对于图像去雾的任务已经可以满足,所以并未再增加残差块的数量,避免造成负担。若残差块的数量过少,则在特征的提取上效果不佳,使最终生成的图像可观性较差。所以综合以上因素,最终确定了在转换网络中使用的结构是4个残差块先两两串联后再并联和带有权重的结构。

在对比实验中发现,因为BN每次是在一个batch上计算均值和方差的,如果batch size太小的话,计算值不足以代表整体数据分布,但若batch size太大,需要更多的epoch,导致训练的总时间变长,甚至在图像转换任务中有颜色衰减问题;而IN可以在加速模型收敛的同时还能保持每个图像实例之间的独立。在激活函数中采用单一ReLU时出现了dead ReLU问题,在负数区域都被kill了,导致

之后的梯度一直为0,不再对数据有反应。ReLU的稳定性不够,过于脆弱,所以为了解决这个问题,将激活函数改为Leaky ReLU,Leaky ReLU在拥有ReLU优点的同时还能有效地进行梯度下降与反向传播。同时在解码网络中采用的是tanh激活函数,扩大了特征效果,在训练的效率方面有很大的提升。

4.1 主观评价

主观评价是从个人的角度去评价,以人为观察者,对图像的优劣做出主观的定性评价。图8和图9分别是不同算法对有雾树木图像和有雾景色图像的实验结果。结合图8和图9可以看出:在图8(b)、(e)和图9(b)、(e)中,图像的亮度得到了提高,色彩得到了丰富,但是图像的客观性较差;图8(c)和图9(c)中,DehazeNet算法对色彩的保持良好,尤其对于天空部分的去雾效果很好,但是丢失了图像在非天空区域的细节;图8(d)和图9(d)中,整体去雾效果不明显,图像整体清晰度不够;图8(f)和图9(f)中,图像整体亮度提高了,改进CycleGAN算法细节显示较好,保持了整体的客观性,且达到了去雾的目的。

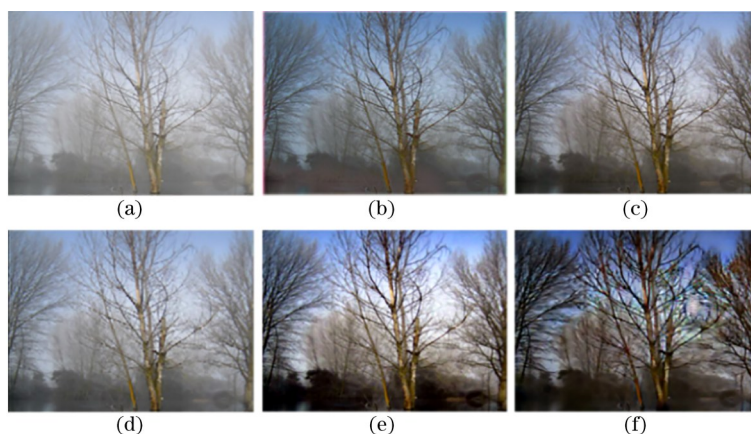


图8 不同算法对有雾树木的实验结果。(a)原图;(b) AODNet算法;(c) DehazeNet算法;(d) FFANet算法;(e) GCANet算法;(f) 改进CycleGAN算法

Fig. 8 Experimental results of different algorithms on foggy trees. (a) Original picture; (b) AODNet algorithm; (c) DehazeNet algorithm; (d) FFANet algorithm; (e) GCANet algorithm; (f) improved CycleGAN algorithm

4.2 客观评价

目前客观评价中常见的指标有峰值信噪比(PSNR)、结构相似性(SSIM)、图像信息熵(information entropy)。

峰值信噪比是目前使用最普遍的一种图像客观评价指标,用来评价一幅图像在压缩后和原始图像相比较质量的好坏,值越大代表图像的处理效果越好,失真越小。其中PSNR的计算公式为

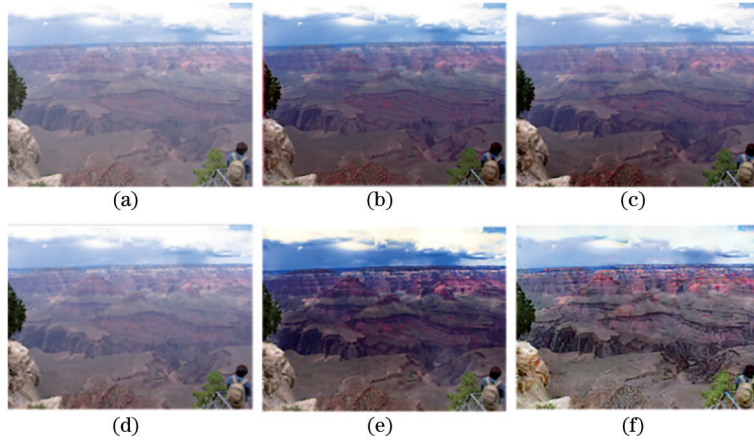


图 9 不同算法对有雾景色的实验结果。(a)原图;(b) AODNet算法;(c) DehazeNet算法;(d) FFANet算法;(e) GCANet算法;(f)改进 CycleGAN算法

Fig. 9 Experimental results of different algorithms on foggy scenes. (a) Original picture; (b) AODNet algorithm; (c) DehazeNet algorithm; (d) FFANet algorithm; (e) GCANet algorithm; (f) improved CycleGAN algorithm

$$R_{\text{PSNR}} = 20 \cdot \log_{10} \left(\frac{M_{\max}}{\sqrt{\frac{1}{MN} \sum_{i=0}^{M-1} \sum_{j=0}^{N-1} \|\mathbf{I}(i, j) - \mathbf{K}(i, j)\|^2}} \right), \quad (8)$$

式中:单色图像 \mathbf{I} 和 \mathbf{K} 的尺寸为 $M \times N$; M_{\max} 为图像点颜色的最大数值。有时会出现 PSNR 结果和主观评价不一致的情况,这是因为指标忽略了人眼的特性。

结构相似性是基于样本 x 和 y 之间的三个比较度量:亮度 (luminance)、对比度 (contrast) 和结构 (structure), 相应的计算公式分别为

$$l(x, y) = \frac{2\mu_x\mu_y + c_1}{\mu_x^2 + \mu_y^2 + c_1}, \quad (9)$$

$$c(x, y) = \frac{2\sigma_x\sigma_y + c_2}{\sigma_x^2 + \sigma_y^2 + c_2}, \quad (10)$$

$$s(x, y) = \frac{\sigma_{xy} + c_3}{\sigma_x\sigma_y + c_3}, \quad (11)$$

式中: $c_3 = c_2/2$; μ_x 和 μ_y 是 x 和 y 的均值; σ_x 和 σ_y 是图像 x 和 y 的方差; σ_{xy} 是 x 和 y 的协方差; $c_1 = (k_1L)^2$, $c_2 = (k_2L)^2$, 为两个常数, 避免除零; L 为像素值, 范围为 $2^B - 1$ 内。 $k_1 = 0.01$, $k_2 = 0.03$ 。

$$S_{\text{SSIM}}(x, y) = \left[l(x, y)^\alpha \cdot c(x, y)^\beta \cdot s(x, y)^\gamma \right]. \quad (12)$$

将 α, β, γ 设为 1, 可以得到

$$S_{\text{SSIM}}(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)}. \quad (13)$$

图像信息熵就是用来表示图像信息量的多少, 图像的细节越丰富, 所得到的信息熵越大, 代表图

像处理的效果越好。信息熵对图像中的点以及周围区域的像素点灰度分布进行提取, 获得灰度图像信息熵的表达式为

$$H = - \sum_{i=0}^{255} p(i) \log_2 p(i). \quad (14)$$

则由此可以得到彩色图像的信息熵公式为

$$\ln H = \frac{1}{3} \sqrt{\ln_R^2 + \ln_G^2 + \ln_B^2}. \quad (15)$$

图像的质量评价指标结果如表 2 和表 3 所示, 通过图表联合可以看出, 无论是在主观评价还是在客观评价上, 所提算法在图像去雾上的处理效果都有着明显的改进, 图像的细节明显, 也抑制了色彩失真和光晕现象, 但是仍然存在着处理局部区域时效果不尽如人意的情况。

在图 8(f) 和图 9(f) 中, 出现了图像的偏色现象, 如图 8(f) 中树枝树干的颜色和图 9(f) 中远处土地

表 2 图 8 的评价指标

Table 2 Evaluation indexes of Fig.8

Algorithm	PSNR /dB	SSIM	Information entropy /bit
AODNet	28.6010	0.7757	6.8782
DehazeNet	28.7951	0.5701	7.3590
FFANet	28.8670	0.7751	7.1810
GCANet	28.8296	0.6441	7.5685
CycleGAN	28.8946	0.8090	7.6027

表 3 图 9 的评价指标
Table 3 Evaluation indexes of Fig.9

Algorithm	PSNR /dB	SSIM	Information entropy /bit
AODNet	29.1986	0.7694	7.1634
DehazeNet	29.2523	0.7075	7.4437
FFANet	29.3011	0.7880	7.2855
GCANet	28.9877	0.7360	7.2636
CycleGAN	29.4215	0.8271	7.4751

颜色等都出现了不同程度的偏色问题。图像偏色是一种常见的质量损失现象,主要是产生了不需要的颜色信息,影响了图像的质量。解决图像偏色问题的有效措施是进行图像色彩的白平衡,白平衡的目的是确保场景中对象的固有颜色不会随着照明条件或景深条件而改变,这些问题都值得在之后设计中进行优化。

5 结 论

提出了基于 CycleGAN 图像去雾算法的改进算法,对生成器的结构进行了调整。在生成器的编码网络中,将 BN 调整为 IN,这样整体算法对单个图像的处理更有利;并且将转换网络中 9 个相同的残差块的单纯串联更换为 4 个带有权重的残差块先两两串联后再并联,这样整体生成的图像在清晰效果上更明显;对于激活函数,选择了 Leaky ReLU 与 tanh,在避免梯度爆炸和梯度消失的同时还对训练的效率进行了提高。实验结果表明,所提算法能够在原始 CycleGAN 的基础上,有效地显示图像的细节,在色彩未失真的情况下达到了去雾的目的且提高了训练效率,最终得到可视性较好的结果。

当然,所提算法中也存在着一些问题,比如在生成对抗网络中损失函数的选择上可能忽略了对偏色现象的鲁棒性分析,在之后的工作中需要考虑通过对图像的色彩白平衡进行控制来纠正偏色现象。本次设计也为之后利用循环生成对抗网络的去雾算法提供了新的思路与优化方向。

参 考 文 献

- [1] Gao S N. Research on image defogging based on convolutional neural network[D]. Harbin: Helongjiang University, 2021.
高树楠. 基于卷积神经网络的图像去雾研究[D]. 哈尔滨: 黑龙江大学, 2021.
- [2] Goodfellow I J, Pouget-Abadie J, Mirza M, et al.

Generative Adversarial Nets[C] // Annual Conference on Neural Information Processing Systems 2014, December 8-13, 2014, Montreal, Quebec, Canada. New York: Curran Associates, 2014: 2672-2680.

- [3] Li R D, Pan J S, Li Z C, et al. Single image dehazing via conditional generative adversarial 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: 8202-8211.
- [4] Mirza M, Osindero S. Conditional generative adversarial nets[EB/OL]. (2014-11-06) [2021-06-01]. <https://arxiv.org/abs/1411.1784>.
- [5] Zhu H Y, Peng X, Chandrasekhar V, et al. DehazeGAN: when image dehazing meets differential programming[C] // Proceedings of the Twenty-Seventh International Joint Conference on Artificial Intelligence, July 13-19, 2018, Stockholm, Sweden. California: International Joint Conferences on Artificial Intelligence Organization, 2018: 1234-1240.
- [6] Qin X, Wang Z L, Bai Y C, 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.
- [7] Chen D D, He M M, Fan Q N, et al. Gated context aggregation network for image dehazing and deraining [C] // 2019 IEEE Winter Conference on Applications of Computer Vision (WACV), January 7-11, 2019, Waikoloa, HI, USA. New York: IEEE Press, 2019: 1375-1383.
- [8] Liang T Y, Stokes J. Interaction matters: a note on non-asymptotic local convergence of generative adversarial networks[EB/OL]. (2018-02-16) [2021-06-01]. <https://arxiv.org/abs/1802.06132>.
- [9] Wang D W, Li S L, Han P F, et al. Feature constraint CycleGAN for single image dehazing algorithm[J]. Laser & Optoelectronics Progress, 2021, 58(14): 1410017.
王殿伟, 李顺利, 韩鹏飞, 等. 基于特征约束 CycleGAN 的单幅图像去雾算法研究[J]. 激光与光电子学进展, 2021, 58(14): 1410017.
- [10] 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.
- [11] 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.
- [12] 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.
- [13] McCartney E J, Hall F F. Optics of the atmosphere: scattering by molecules and particles[J]. *Physics Bulletin*, 1977, 28(11): 521.
- [14] Zhang Q, Ye B, Luo S Q, et al. Aluminum plate defect image segmentation using improved generative adversarial networks for eddy current detection[J]. *Laser & Optoelectronics Progress*, 2021, 58(8): 0815002.
张琦, 叶波, 罗思琦, 等. 基于改进生成对抗网络的铝板缺陷电涡流检测图像分割[J]. *激光与光电子学进展*, 2021, 58(8): 0815002.
- [15] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift[C]//International Conference on International Conference on Machine Learning, July 6-11, Lille, France. Cambridge: JMLR, 2015.
- [16] 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.