

DOI:10.16136/j.joel.2023.03.0250

结合强监督学习和生成对抗网络的图像去雾

翟社平^{1,2*}, 刘园彪¹, 成大宝¹

(1. 西安邮电大学 计算机学院, 陕西 西安 710121; 2. 陕西省网络数据分析与智能处理重点实验室, 陕西 西安 710121)

摘要:针对现有去雾算法的复原图像易出现颜色失真与细节丢失问题,提出了一种基于改进循环生成对抗网络(cycle-consistent generative adversarial networks, CycleGAN)的端到端图像去雾方法,并无需依赖于大气散射模型的约束。网络生成器整体采用 Encoder-Decoder 架构,同时为有效学习有雾图像与清晰图像间的映射关系,在训练优化目标中结合图像自身属性构建了增强的高频损失与特征损失函数,实现对不同数据域的特征鉴别并进一步保证图像纹理结构。此外为约束复原图像与真实清晰图像颜色的一致性,提出了二阶段学习策略。首先通过非配对数据集对改进 CycleGAN 进行弱监督训练学习,然后于第二阶段利用部分成对数据集以强监督方式训练正向生成网络,在提高去雾网络稳定性的同时,使复原效果更接近于真实清晰图像风格。实验结果表明,所提去雾方法的峰值信噪比(peak signal to noise ratio, PSNR)和结构相似性(structural similarity, SSIM)指标值相比同类 CycleGAN 算法分别提升了 12.43% 与 5.53%,并且同其他方法在视觉效果与量化指标的对比结果中也验证了其性能的有效性。

关键词:图像处理; 图像去雾; 循环生成对抗网络(CycleGAN); 监督学习; 颜色校正
中图分类号: TP391.4 **文献标识码:** A **文章编号:** 1005-0086(2023)03-0250-10

Image dehazing combining strongly-supervised learning and generative adversarial network

ZHAI Sheping^{1,2*}, LIU Yuanbiao¹, CHENG Dabao¹

(1. School of Computer Science and Technology, Xi'an University of Posts and Telecommunications, Xi'an, Shaanxi 710121, China; 2. Shaanxi Key Laboratory of Network Data Analysis and Intelligent Processing, Xi'an, Shaanxi 710121, China)

Abstract: Aiming at the problems that the restored images of existing dehazing algorithms are prone to color distortion and details lost, an end-to-end image dehazing method based on cycle-consistent generative adversarial networks (CycleGAN) is proposed, which does not rely on the constriction of atmospheric scattering model. The whole network generator adopts the Encoder-Decoder framework, and in order to effectively learn the mapping relationship between hazy images and clear images, the enhanced high-frequency loss and feature loss functions are constructed in the training optimization objective by combining the image attributes, which realizes the feature identification of different data domains and further ensures the texture structure of images. In addition, a two-stage learning strategy is proposed to constrict the color consistency between restored images and their corresponding clear images. Firstly, the improved CycleGAN is learned by weakly-supervised training with unpaired datasets. Then in the second stage, the forward generator network is trained in a strongly-supervised manner with some paired datasets, which improves the stability of dehazing network while making the restoration effect closer to the real clear image style. The experimental results show that the peak signal to noise ratio (PSNR) and

* E-mail: xupt_zhai@163.com

收稿日期: 2022-04-09 修订日期: 2022-06-23

基金项目: 国家自然科学基金(61373116)、陕西省重点研发计划项目(2022GY-038)、陕西省大学生创新创业训练计划项目(S202111664004, S202111664077)和西安邮电大学研究生创新基金(CXJLY202051)资助项目

structural similarity (SSIM) of the proposed dehazing method are improved by 12.43% and 5.53%, respectively, compared with the similar CycleGAN algorithm, and the effectiveness of the proposed method is also verified by comparing the results of visual effect and quantitative index with other methods.

Key words: image processing; image dehazing; cycle-consistent generative adversarial networks (CycleGAN); supervised learning; color correction

0 引言

在雾天场景下,由于成像设备最终接收的光线中包括周围杂散大气光以及物体反射衰减后的透射光,导致所获图像出现清晰度、饱和度下降以及色彩偏差^[1]等图像退化现象,并会在一定程度上降低户外成像系统的应用性能。因此作为计算机视觉领域一项既具实用性且需要迫切解决的课题,图像去雾技术具有十分重要的研究价值。

传统图像去雾处理包括基于图像增强以及基于物理模型两类方法。前者被广泛应用于图像去雾领域初期的研究工作中,其典型方法如直方图均衡化法^[2]、小波变换法^[3]以及基于 Retinex 理论^[4]的相关算法等。由于基于图像增强的去雾方法是通过提升图像整体视觉效果以达到去雾的目的,其本质并不涉及雾图的形成原理,因此经常会出现颜色失真以及过饱和等问题。而在后者的研究过程中,TAN 等^[5]通过最大化目标雾图的局部对比度实现了去雾效果,但该方法经常会出现光晕效应。HE 等^[6]提出暗通道先验(dark channel prior,DCP)理论,通过进一步细化透射率,并利用大气散射模型进行去雾处理。此外 ZHU 等^[7]的颜色衰减先验(color attenuation prior,CAP)算法,采用线性回归模型对相应透射图进行估计,并同样结合雾天成像原理复原出了清晰图像。基于物理模型的去雾方法虽然能合理模拟退化图像的形成过程,但由于受各自未知参数的影响,该方法难以适用于复杂多样性的场景。

目前一些基于深度学习的去雾方法通过结合物理成像模型,并采用神经网络来进行对未知参数的估计。CAI 等^[8]利用卷积神经网络(convolutional neural network,CNN)直接学习雾图与对应透射率图间的映射关系,并利用大气散射模型反演恢复无雾图像。ZHANG 等^[9]采用一种密连金字塔编解码网络,通过同步学习透射率图与大气光并进行去雾处理。LI 等^[10]利用多尺度特征融合的方法,并基于轻量级 CNN 提出了去雾网络 AOD-Net,在增强复原图像质量的同时也提升了目标检测的性能。

此外随着生成对抗网络(generative adversarial networks,GAN)^[11]在图像复原领域的成功应用,

CHEN 等^[12]提出一种端到端的门控上下文聚合网络 GCANet,通过直接学习有雾数据域与清晰数据域间的映射关系并输出去雾图像,同时无需物理模型约束。肖进胜等^[13]将生成器网络结构改造为快捷链接沙漏形,同时设计了漏斗形全域卷积判别器网络以辨别图像风格。ENGIN 等^[14]基于循环生成对抗网络(cycle-consistent generative adversarial networks,CycleGAN)^[15]提出了去雾网络 Cycle-Dehaze,并在输出阶段采用拉普拉斯变换以获取高清去雾图像。ANVARI 等^[16]通过引入全局-局部双判别器,分别对整张图像以及局部图像块进行来源鉴别,实现对不均匀雾度的去除。孙祥胜等^[17]采用双路径融合网络来提取不同级别特征,并通过多尺度判别器引导生成网络逐步产生更清晰的图像细节。目前基于深度学习的去雾方法普遍需要大量成对的有雾图像与清晰图像训练集,而 CycleGAN 的非配对映射方式虽然不再受限于匹配数据集,但由于无法根据标签信息对复原图像的颜色恢复进行约束,因而难以完整还原真实清晰图像的特征。

根据上述分析,本文提出了一种基于改进 CycleGAN 的图像去雾方法,其借助图像转换的思想实现有雾图像向清晰图像端到端的变换。同时为有效学习各数据域间的映射关系,本文方法将强监督与弱监督对抗网络相结合,采用一种二阶段学习策略,并通过实验验证所提去雾方法的有效性。

1 相关工作

1.1 大气散射模型

通过观察雾天情况下发生的光线散射现象,MCCARTNEY 等^[18]提出了如图 1 所示能有效解释雾天图像退化过程的大气射模型,为图像去雾工作提供了有力的理论支撑。在后续研究过程中,学者们进一步通过建模推导,将该降质模型表示为:

$$\mathbf{I}(\mathbf{x}) = \mathbf{J}(\mathbf{x})t(\mathbf{x}) + A(1 - t(\mathbf{x})), \quad (1)$$

$$t(\mathbf{x}) = e^{-\beta d(\mathbf{x})}, \quad (2)$$

式中, $t(\mathbf{x})$ 为透射率, A 为大气光强度, $\mathbf{J}(\mathbf{x})$ 代表清晰图像, $\mathbf{I}(\mathbf{x})$ 代表成像设备接收到的退化图像, β 为大气散射系数, $d(\mathbf{x})$ 为景深大小。根据大气散射模型原理,将透射率 $t(\mathbf{x})$ 、大气光强度 A 以及退化图像

$I(x)$ 带入式(1)中进行反演推算,便可得到解清晰无雾图像 $J(x)$ 。大气散射模型虽能够合理模拟雾图的形成过程,但由于各项未知参数难以估计,其复杂的逆求解仍属于一种病态问题。




图1 大气散射模型

Fig. 1 Atmospheric scattering model

1.2 CycleGAN

CycleGAN 模型一共由 4 个子网络构成:生成器 G 、 F 以及判别器 D_X 、 D_Y ,其中 X 与 Y 分别代表两种不同的数据域,模型整体结构如图 2 所示。




图2 CycleGAN 网络架构

Fig. 2 Architecture of CycleGAN

以图 2(b)正向生成为例,对于数据域 X 中的图像 x ,为确保其转换到 Y 域的图像仍能与 x 产生对应关系,作者在整体网络中引入了循环一致性损失。首先经正向映射 G 将图像从样本空间 X 转换到样本空间 Y ,即通过生成器 G 学习将图像 x 转换为 $G(x)$ 。然后再经反向映射 F 将转换到样本空间 Y 的图像 $G(x)$ 转换回原样本空间 X ,即通过生成器 F 学习将图像 $G(x)$ 转换为 $F(G(x))$ 。此时可以得到原样本空间的数据分布 $F(G(x)) \approx x$,同理也满足反向约束 $G(F(y)) \approx y$ 。通过这种一致性损失,使得重建图像更接近于其原始图像,同时杜绝模型将原始空间的图像全部转换为对应空间中的同一幅图像。

2 本文算法

2.1 网络整体结构

如图 3 所示,本网络的整体架构由两部分组成。

图 3(a)为基于改进 CycleGAN 的环形循环网络架构,该阶段网络的主要任务是通过非配对数据集的训练学习,实现从有雾图像向清晰图像的转换。其中生成器 G 与 F 用于学习两种不同数据域之间的映射关系,并分别输出去雾图像以及合成雾图。判别器 D_X 用于鉴别输入的有雾图像是来自真实样本还是由 F 所生成的假样本, D_Y 则用于鉴别输入的清晰图像是来自真实样本还是由 G 所生成的假样本。

以前向网络 Forward Networks 为例,将有雾图像 x 输入至正向生成器 G 中,输出去雾图像 $G(x)$,然后再通过反向生成器 F 生成合成雾图, $F(G(x))$ 则属于 x 的重建图像。判别器 D_Y 在该网络中的作用是鉴别所输入去雾图像 $G(x)$ 的真伪,使生成器 G 向生成更高质量目标域图像的目的迈进。反向网络 Backward Networks 流程与前向网络类似,区别在于图像数据域之间的转换方向不同。

图 3(b)所示为强监督正向生成架构。该阶段利用部分配对的有雾图像集 X 以及清晰图像集 Z ,仅对生成器 G 进行一对一的训练学习。通过监督信息的约束,在保证整体网络稳定性的同时,学习有雾图像与原始清晰图像更多特征间的对应关系。

2.2 生成器

生成器 G 与 F 采用完全类似的网络架构。图 4 所示为改进 CycleGAN 网络中生成器 G 的结构示意图,其主要包括 3 个组成部分:编码器(encoder)、转换器(transformation)以及解码器(decoder)。编码器将有雾图像作为输入,并通过 3 个卷积块来进行图像特征提取,其中每个卷积块都包括一个卷积层、一个实例归一化(instance normalization, IN)层以及一个 Leaky ReLU 激活层。在第一个卷积块中使用一个 7×7 ,步长为 1 的卷积,之后接连两个相同的 3×3 ,步长为 2 的下采样卷积块,完成对有雾图像的特征提取过程。本文算法所涉及的去雾处理属于一种域适应任务,在归一化处理阶段采用的是 IN 而非非常规使用的批标准化(batch normalization, BN)。同时对于单个图像数据的处理,IN 能够加速模型收敛并保证每个图像实例之间的独立性。

转换器负责将编码器的输出特征进行组合,同时提取更复杂更深层的学习特征。本文转换器由 6 个残差块(residual block)组成,每个残差块包括两个尺度大小为 3×3 的卷积层。残差块的引入确保先前编码器网络的输出能够连接至后续解码器网络的输入中,从而避免造成数据偏差,以实现有雾数据域向无雾数据域的转换,其完整结构如图 5 所示。

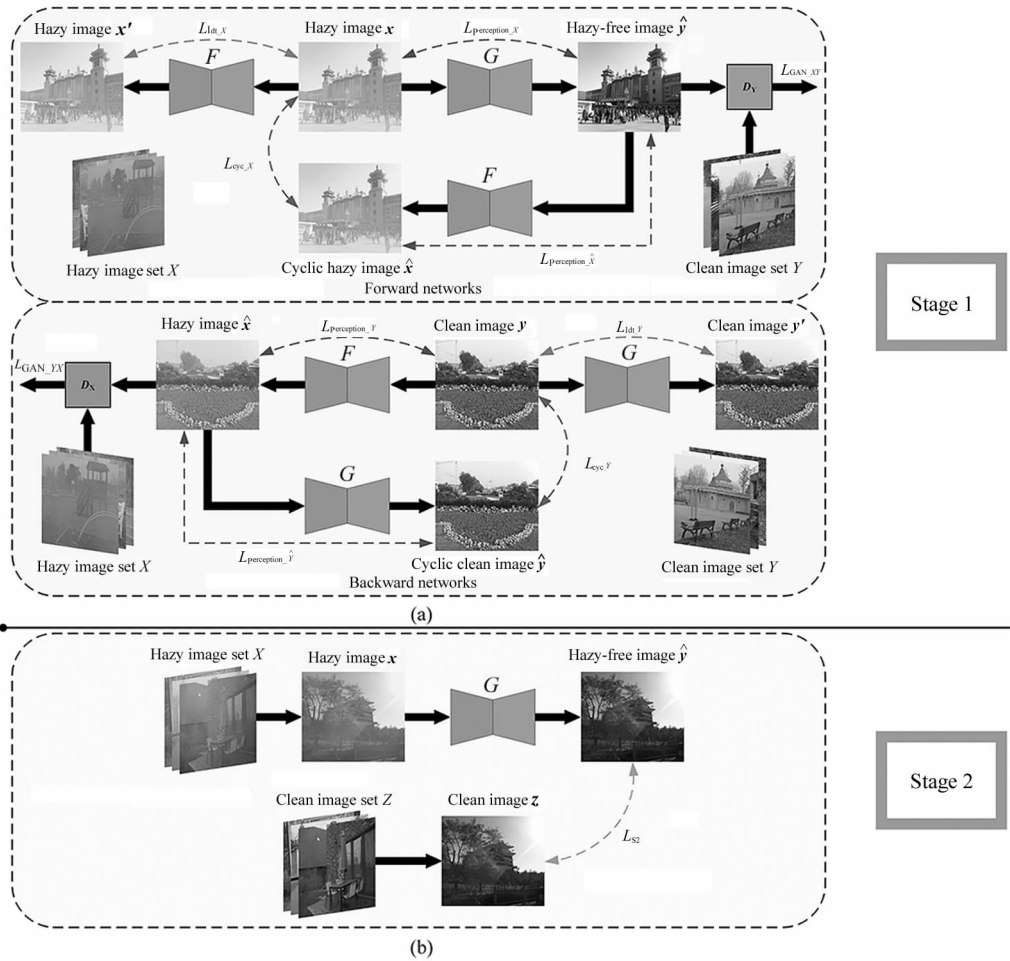


图 3 二阶段去雾网络架构:(a) 改进的 CycleGAN 网络架构;(b) 强监督正向生成网络架构
 Fig. 3 Architecture of two-stage dehazing network:(a) Architecture of enhanced CycleGAN;
 (b) Architecture of strongly-supervised forward generator network

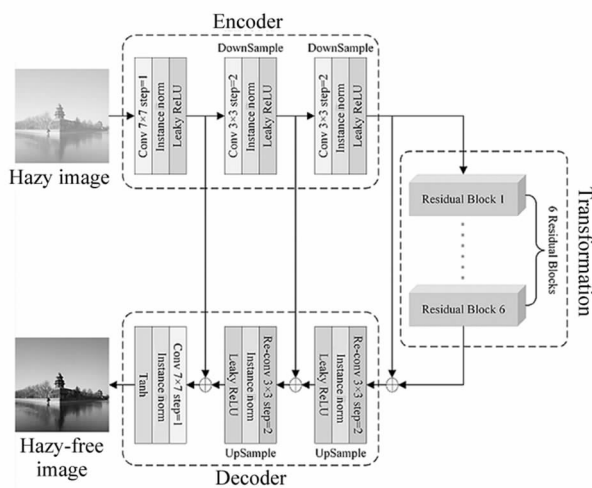


图 4 生成器结构
 Fig. 4 Architecture of generator

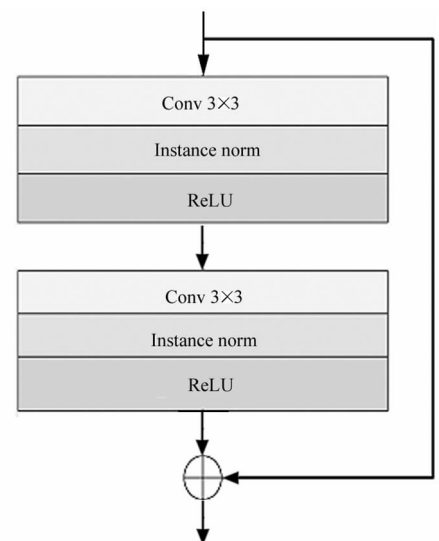


图 5 残差块结构
 Fig. 5 Architecture of residual block

解码器通过接收来自编码器与转换器输出的特征向量,并从中反演还原出低级特征,进而输出去雾图像。本文在上采样块中采用缩放卷积来代替原始的反卷积,通过双线性插值(bilinear interpolation)将图像分辨率缩放至目标尺寸,然后再进行卷积操作,这也在一定程度上有效抑制了反卷积因不均匀重叠而易造成的“棋盘效应”。每个 3×3 ,步长为2的缩放卷积层后都接连一个IN层以及Leaky ReLU激活层,最后通过一个由 7×7 尺度的卷积层与Tanh激活层所组成的卷积块,输出处理后的复原图像。此外为对网络间的浅层特征进行复用,本文在编码器与解码器两个模块之间引入了跳层连接(skip connection)^[19],以此弥补在下采样和上采样过程中可能造成的信息损失,同时为编码器与解码器间提供更多的信息传输,并有利于整体网络的训练。

2.3 判别器

判别器负责鉴别生成图像的真伪,以促使生成器生成更高质量的目标域图像。如图6所示,判别器由5个含有 4×4 尺度卷积的卷积块构成,并且除第一个与最后一个卷积块外,其余卷积块均包含IN层以及Leaky ReLU激活层。判别器网络的前4层用于提取输入图像的特征,而包含卷积操作与Sigmoid激活函数的最后一层用于判断所输入图像是否符合目标域的数据分布,若鉴别其为生成图像则输出0,若鉴别其为真实图像则输出1。




图6 判别器结构

Fig. 6 Architecture of discriminator

2.4 损失函数

整体网络的损失函数设计由两部分组成,包括在第一阶段中改进CycleGAN的对抗损失、循环一致性损失、高频损失和特征损失,以及第二阶段正向生成网络的监督一致性损失。

1) 对抗损失。网络对抗损失与原始GAN一致,其目的主要是为了将生成图像的数据分布与目标域图像数据分布相匹配,同时更准确地提取图像特征,并约束输出图像的生成效果。生成器 G 与判别器 D_Y ,以及生成器 F 与判别器 D_X 之间的对抗损

失函数分别表示为:

$$L_{GAN}(G, D_Y, X, Y) = E_{y \sim p_{data_y}} [\log(D_Y(y))] + E_{x \sim p_{data_x}} [\log(1 - D_Y(G(x)))] \quad (3)$$

$$L_{GAN}(F, D_X, Y, X) = E_{x \sim p_{data_x}} [\log(D_X(x))] + E_{y \sim p_{data_y}} [\log(1 - D_X(F(y)))] \quad (4)$$

式中, X 与 Y 分别代表有雾图像数据域和清晰图像数据域, $x \in X$ 和 $y \in Y$ 则分别表示为两种数据域中的对应图像。

2) 循环一致性损失。循环一致性损失用于约束生成网络的学习方向,以防止生成器 G 与 F 互相矛盾,同时保留图像内容信息并实现不同数据域之间的转换。在算法鲁棒性及稳定性需求下,本文网络采用Smooth L1平滑范数来代替原始CycleGAN中的L1范数损失函数。Smooth L1结合了L1与L2范数的部分优点,使得当预测值与实际值差别较小时,梯度值不至于过大;而当预测值与实际值差别较大时,梯度值又足够小,因此不易出现梯度爆炸现象。优化后的循环一致性损失函数 L_{cyc} 表示为:

$$L_{cyc}(G, F) = \begin{cases} 0.5 \times L_{cyc2}, & \text{if } |L_{cyc1}| < 1 \\ |L_{cyc1}| - 0.5, & \text{otherwise} \end{cases} \quad (5)$$

$$L_{cyc1}(G, F) = E_{x \sim p_{data_x}} [\|F(G(x)) - x\|_1] + E_{y \sim p_{data_y}} [\|G(F(y)) - y\|_1] \quad (6)$$

$$L_{cyc2}(G, F) = E_{x \sim p_{data_x}} [\|F(G(x)) - x\|_2] + E_{y \sim p_{data_y}} [\|G(F(y)) - y\|_2] \quad (7)$$

3) 高频损失。有雾图像大多已经受损,因此仅借助重建图像与原始图像之间的计算损失,并不足以恢复完整的图像纹理信息。受JUSTIN等^[20]的启发,由于感知损失和循环一致性损失仅研究重建图像与输入图像的一致性,这可能会导致重建图像更接近于原始输入图像,而中间过程的生成图像却变化极大,从而出现模型崩溃现象。因此为约束有雾图像与去雾图像在纹理结构上的一致性,本文采用一种增强的感知损失,通过将中间过程的生成图像引入损失函数计算中,在使重建图像逐渐接近输入图像的同时,进一步于高维空间中约束生成图像与原始图像的差距,避免出现过度变化的复原效果。感知损失基于VGG16预训练模型,并通过线性整流单元(ReLU)层的激活映射来进行定义。改进后的感知损失函数表示为:

$$L_{Perception}(G, F) = E_{x \sim p_{data_x}} [\|\phi(x) - \phi(G(x))\|_2^2 + \|\phi(G(x)) - \phi(F(G(x)))\|_2^2] + E_{y \sim p_{data_y}} [\|\phi(y) - \phi(F(y))\|_2^2 + \|\phi(F(y)) - \phi(G(F(y)))\|_2^2] \quad (8)$$

式中, ϕ 代表 VGG16 模型中的高维特征提取器。

4) 特征损失。以正向生成为例,生成器 G 实现映射 $X \rightarrow Y$,而当输入为 Y 数据域图像时,也应实现 $Y \rightarrow Y$ 的映射关系。利用这一原理,通过在生成器网络中引入特征损失,尽可能避免相同数据域间的转换,同时提高生成图像质量。特征损失定义为:

$$L_{\text{idt}}(G, F) = E_{x \sim p_{\text{data}_x}} [\|F(x) - x\|_1] + E_{y \sim p_{\text{data}_y}} [\|G(y) - y\|_1] \quad (9)$$

第一阶段去雾网络的整体损失表示为对抗损失、循环一致性损失、高频损失以及特征损失的加权平均和,该阶段的总优化目标函数为:

$$L(G, F, D_X, D_Y) = L_{\text{GAN}}(G, D_Y, X, Y) + L_{\text{GAN}}(F, D_X, Y, X) + \lambda_1 L_{\text{cyc}} + \lambda_2 L_{\text{Perception}} + \lambda_3 L_{\text{idt}} \quad (10)$$

式中, λ_1 、 λ_2 与 λ_3 分别代表循环一致性损失、高频损失以及特征损失的权重。为平衡各损失的约束程度以避免过度的去雾处理,将各权重系数分别设置为 $\lambda_1 = 10$, $\lambda_2 = 1 \times 10^{-4}$, $\lambda_3 = 1$ 。

在网络第二阶段的训练过程中,将生成器 G 所生成的去雾图像 $G(x)$,同与其配对的原始清晰图像 z 之间的差损进行二次监督学习,通过在一阶段训练的基础上引导更新正向生成网络 G ,学习有雾图像和清晰图像间更多特征的映射关系,并使生成图像更趋近于真实风格的清晰无雾图像。该阶段所产生的损失函数表示为:

$$L_{\text{S2}} = E_{z \sim p_{\text{data}_z}} [\|G(x) - z\|_1] \quad (11)$$

3 实验及分析

3.1 训练和测试数据集

由于整体网络训练包括弱监督以及强监督两个学习阶段,因此实验所需数据也由两部分组成。第一阶段通过非配对样本集进行弱监督训练学习,其中有雾图像与清晰图像之间无一一一对应关系。该阶段训练数据包括 3 000 幅雾天图像以及 3 000 幅清晰图像,并且雾天图像尽可能涵盖了多场景信息。第二阶段采用强监督训练学习方式,配对样本集包括 500 幅清晰图像以及 500 幅相对应的有雾图像。实验所用样本主要来源于复杂场景公开数据集 RE-SIDE,其中网络训练集取自于子集 ITS 以及 OTS,测试集取自于子集 SOTS 以及 HSTS,并从配对数据集 SOTS 中随机选取了 200 张室内与室外有雾图像用于实验阶段的复原图像质量分析。

3.2 实验设置

本实验所用系统环境为 Windows 10,配备 Intel

Core i5-8500 CPU 以及 NVIDIA GTX 1080 Ti GPU,编译软件为 Pycharm 2018。相关训练参数设置如下:batch size 大小为 1,训练样本尺寸为 256×256 ,程序共迭代 200 个 epoch,并将前 100 次迭代的学习率设置为恒定值 0.0002,后 100 次迭代学习率呈线性递减至 0。整体网络采用 Adam 优化方法,动量设置为 0.5,通过动态调整各参数的学习率并进行偏置校正,从而实现网络的快速收敛。经第一阶段的弱监督学习对整体网络进行训练更新后,在第二阶段利用配对数据集对正向生成网络 G 进一步引导优化,使其生成的去雾图像更接近于真实清晰图像风格,并在正则化处理约束下避免过拟合现象出现,提升整体网络的泛化性能。

3.3 实验结果及分析

3.3.1 消融分析

为分析第二阶段强监督学习的引入对图像复原效果的影响,本文通过设计正向生成网络的相关消融实验来研究其有效性。图 7 所示为各阶段学习的去雾效果对比,从左至右依次为有雾图像、一阶段学习生成图以及二阶段学习生成图。

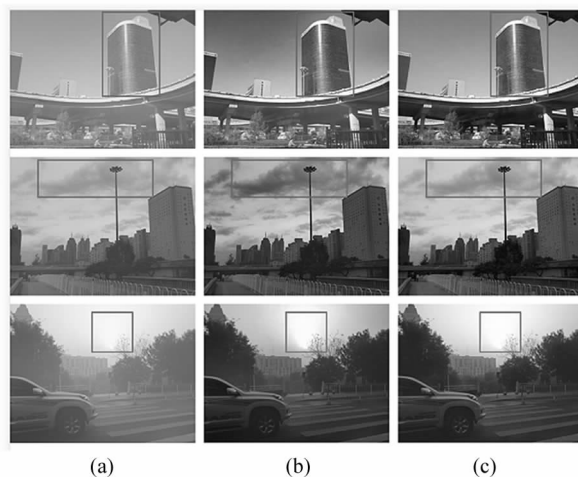


图 7 一阶段学习与二阶段学习的去雾效果对比:
(a) 有雾图像; (b) 一阶段学习; (c) 二阶段学习
Fig. 7 Comparison of dehazing results by one-stage study and two-stage study: (a) Hazy image; (b) One-stage study; (c) Two-stage study

由复原图像的特定区域可以看出,虽然第一阶段的弱监督学习没有出现细节丢失或伪影现象,但其复原效果并不符合人眼感知。如在第一幅图的建筑区域处出现了明显的色偏,第二幅图中的天空云层出现了过度增强,因而无法保留图像的原始色彩。此外在第三幅图中出现了光晕现象,且复原图像仍

存在细微雾感。因此仅通过弱监督方法学习到的特征映射并不足以还原出真实的图像效果。而强监督学习的引入,使网络在弱监督对抗训练下学习有雾图像域与清晰图像域间映射关系的同时,通过监督信息的约束保证去雾网络稳定性,并有效地抑制了图像色偏效果,使复原图像更加真实自然。因此本文所提出的联合强监督与弱监督对抗学习的二阶段学习策略是有效的。

为验证本文算法的去雾性能,将所提方法同基于传统先验知识的代表性方法 DCP^[6]、CAP^[7],基于深度学习的经典方法 AOD-Net^[10]、GCANet^[12]以及同类基于 CycleGAN 的方法 Cycle-Dehaze^[14],通过在测试数据集 SOTS 和 HSTS 上进行对比实验,分别从主观视觉效果以及客观量化指标两方面进行复原图像的质量评价。

3.3.2 主观结果分析

图 8 所示为不同去雾方法在测试集 SOTS 和 HSTS 的部分合成雾图上的处理结果对比,其中图 8

(a)–(h) 依次为有雾图像、DCP 算法、CAP 算法、AOD-Net 算法、GCANet 算法、Cycle-Dehaze 算法、本文算法去雾图以及原始清晰图像。据图观察得出,由于暗通道先验无法适用于天空区域,导致对该部分的大气光估计不够精确,因此由 DCP 算法得到的去雾图像在天空区域易出现光晕现象以及过度增强的效果。CAP 算法的复原图像存在色偏,与真实图像相比颜色并不自然。AOD-Net 算法由于去雾不够彻底而导致复原图像整体仍存在有雾感,同时图像纹理不清晰且颜色偏暗。GCANet 算法对图像边缘细节的恢复效果较差,如在图 8 倒数第二行的 Rain 图中可以观察到行人雨披边缘的残留雾。Cycle-Dehaze 算法虽然去雾力度更大,同时也取得了一定的纹理恢复效果,但其在色彩恢复上仍存在不足,复原图像易出现颜色失真现象。相比上述 5 种算法,本文去雾方法结合二阶段学习策略,在保证去雾图像纹理结构的同时,也使得到的图像色彩更加真实自然,并且不易出现偏色效果。




图 8 合成雾图去雾效果对比:(a) 有雾图像;(b) DCP;(c) CAP;(d) AOD-Net;(e) GCANet;(f) Cycle-Dehaze;(g) 本文算法;(h) 清晰图像

Fig. 8 Comparison of dehazing results on synthetic hazy images:(a) Hazy image;(b) DCP;(c) CAP;(d) AOD-Net;(e) GCANet;(f) Cycle-Dehaze;(g) Ours;(h) Clean image

真实场景下的去雾效果对比如图 9 所示。对于清晰无雾图像,本文方法的处理结果相较于原始图像没有明显变化,表明所提算法能够较好地实现对不同数据域的特征鉴别。针对不同雾度的远近交替图像,本文方法的复原图像保留了更多的纹理细节,色彩恢复自然且不易出现伪影现象,但对浓雾场景的处理效果仍需进一步提升。综合对比各幅图像的

复原结果可见,本文方法从主观视觉评价角度来看去雾效果相对较好,同时复原图像边缘层次清晰,也较为接近符合人眼感知的真实图像风格。

为进一步验证所提算法的图像视觉恢复效果,现将图 8 中包含天空、行人及道路等复杂场景因素的原始 Rain 图像作为测试样本,通过获取各算法复原图像的颜色直方图以进行直观对比,并将清晰

Rain 图像作为无算法类型参考。图 10(a)一(h)所示分别为清晰图像、有雾图像以及 DCP、CAP、AOD-Net、GCANet、Cycle-Dehaze 与本文算法所对应复原图像的颜色直方图。通过各通道的像素值分布可以观察到,除原始有雾图像外,由各去雾算法得到的直

方图分量均普遍集中于色阶中部,而本文方法的直方图整体色阶范围覆盖较宽,同时在低端色阶处也集中有像素分布,证明进行了较为彻底的去雾处理,与原始清晰图像直方图基本结构类似,并且复原图像亮度也得到了进一步提升。

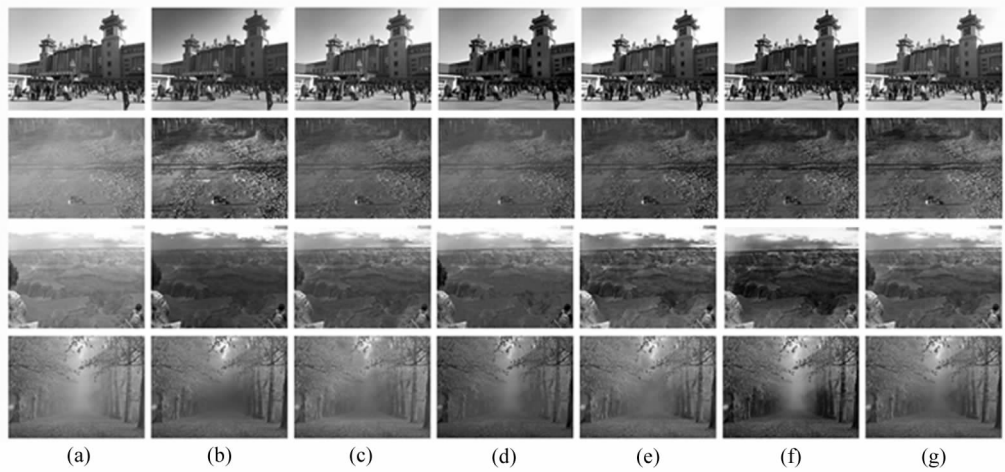


图 9 真实场景去雾效果对比:(a) 有雾图像;(b) DCP;(c) CAP;(d) AOD-Net;(e) GCANet;(f) Cycle-Dehaze;(g) 本文算法

Fig. 9 Comparison of dehazing results on real-world scenes:(a) Hazy image;(b) DCP;(c) CAP;(d) AOD-Net;(e) GCANet;(f) Cycle-Dehaze;(g) Ours

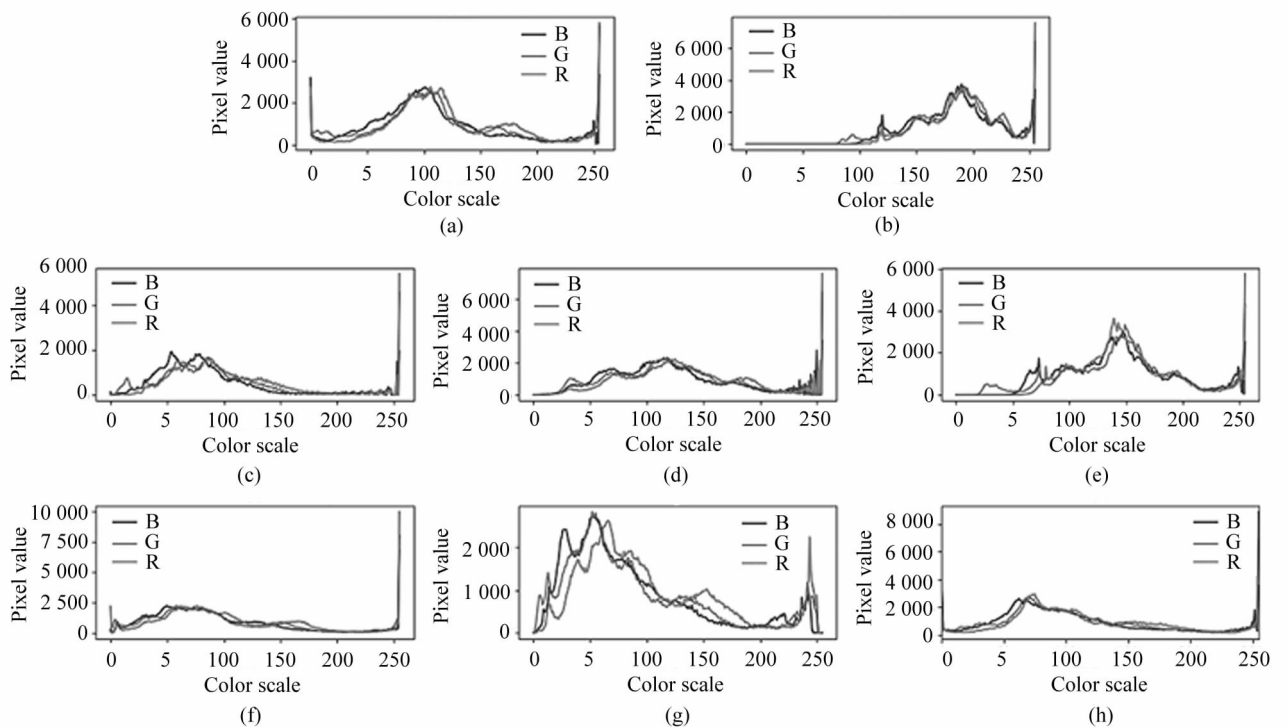


图 10 Rain 图像的颜色直方图对比:(a) 清晰图像;(b) 有雾图像;(c) DCP;(d) CAP;(e) AOD-Net;(f) GCANet;(g) Cycle-Dehaze;(h) 本文算法

Fig. 10 Comparison of color histogram on Rain image:(a) Clean image;(b) Hazy image;(c) DCP;(d) CAP;(e) AOD-Net;(f) GCANet;(g) Cycle-Dehaze;(h) Ours

3.3.3 客观结果分析

为从客观质量评价角度研究去雾算法性能,本文在 SOTS 配对数据集中随机选取 200 张室内及室外有雾图像作为测试样例一,将 HSTS 数据集作为测试样例二,分别计算 6 种算法对于测试集处理结果的峰值信噪比(peak signal to noise ratio, PSNR)和结构相似性(structural similarity, SSIM)两项客观指标值,同时以有雾图像作为无算法类型参考,得到如表 1 与表 2 所示的对比结果。据表中数据可知,

本文算法的 PSNR 指标在两项测试集中的处理结果均为最优,表明由所提算法处理得到的去雾图像较原始清晰图像失真度更低。虽然 SSIM 指标值在 HSTS 测试集中仅次于 GCANet,但结合复原图像主观视觉效果可以观察到,GCANet 易出现不同程度的颜色失真现象,而通过本文方法得到的去雾图像能够保留一定的原始图像结构,同时在颜色、亮度与对比度方面具有更好的表现,图像复原效果清晰自然。

表 1 SOTS 数据集对比结果

Tab.1 Comparison results on SOTS dataset

Method	Hazy	DCP	CAP	AOD-Net	GCANet	Cycle-Dehaze	Ours
PSNR	11.194	16.221	19.415	13.843	20.033	19.092	20.978
SSIM	0.640	0.813	0.861	0.752	0.858	0.840	0.896

表 2 HSTS 数据集对比结果

Tab.2 Comparison results on HSTS dataset

Image	Hazy		DCP		CAP		AOD-Net		GCANet		Cycle-Dehaze		Ours	
	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM	PSNR	SSIM
1	17.146	0.872	13.402	0.852	21.867	0.951	19.395	0.879	22.458	0.925	18.465	0.874	20.503	0.893
2	18.619	0.912	12.977	0.815	22.366	0.931	20.674	0.899	24.896	0.951	19.583	0.904	21.450	0.896
3	10.455	0.615	14.448	0.856	22.760	0.943	16.299	0.717	13.142	0.843	15.437	0.871	28.955	0.945
4	11.843	0.675	18.837	0.795	24.930	0.887	17.467	0.714	23.699	0.934	28.144	0.918	26.543	0.899
5	11.115	0.668	21.457	0.864	20.568	0.873	16.849	0.734	24.205	0.948	23.714	0.878	25.126	0.963
6	14.578	0.801	20.727	0.866	25.335	0.923	23.244	0.822	26.241	0.940	25.304	0.877	27.291	0.948
7	13.192	0.679	20.870	0.823	24.508	0.882	17.840	0.726	27.006	0.915	23.905	0.882	26.791	0.948
8	16.254	0.863	18.729	0.894	23.204	0.956	20.866	0.869	21.295	0.907	23.582	0.905	21.537	0.886
9	21.091	0.938	17.699	0.872	21.303	0.930	16.578	0.858	28.134	0.962	17.475	0.877	26.252	0.950
10	14.618	0.842	17.287	0.853	27.046	0.961	19.395	0.850	23.275	0.940	19.626	0.869	23.036	0.920
Mean	14.891	0.787	17.643	0.849	23.389	0.924	18.861	0.807	23.435	0.928	21.524	0.886	24.748	0.925

4 结 论

本文提出了一种基于改进 CycleGAN 的端到端图像去雾算法。该方法首先对原始 CycleGAN 的生成网络 Encoder-Decoder 架构进行了改进,同时结合图像自身属性引入重构后的高频感知损失与特征损失函数,实现生成网络对不同数据域的特征鉴别,并进一步保证生成图像与原始图像纹理内容的一致性。此外提出了一种二阶段学习策略,即在第一阶段弱监督对抗学习的基础上引入强监督学习,结合监督信息的约束提高去雾网络的稳定性,同时确保复原图像与原始清晰图像颜色的一致性,实现有雾图像向去雾图像更为自然的复原,并通过消融分析证明了二阶段学习策略的有效性。实验结果表明,

本文方法得到的去雾图像相较于原始清晰图像失真度更低,能够有效保留纹理内容结构,同时在颜色、亮度与对比度方面的恢复程度也有了明显提升。

目前算法对浓雾或雾度分布不均匀图像的处理能力有限,去雾效果仍有待进一步提升。在后期工作中将针对上述问题,探索研究在恶劣程度更高环境下的图像复原方法,以期完善本算法对复杂场景雾天图像的去雾处理。

参 考 文 献:

[1] WU D, ZHU Q S. The latest research progress of image dehazing[J]. Acta Automatica Sinica, 2015, 41(2): 221-239.
吴迪,朱青松.图像去雾的最新研究进展[J].自动化学

- 报,2015,41(2):221-239.
- [2] KIM J Y, KIM L S, HWANG S H. An advanced contrast enhancement using partially overlapped sub-block histogram equalization[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2001, 11(4): 475-484.
- [3] LIU C, YANG Y. Single image dehazing algorithm based on adaptive wavelet fusion[J]. Journal of Optoelectronics • Laser, 2020, 31(3): 318-325.
刘策, 杨燕. 基于自适应小波融合的单幅图像去雾算法[J]. 光电子·激光, 2020, 31(3): 318-325.
- [4] PENG J, XUE F J, YUAN Y B. Adaptive image defogging algorithm combining multi-scale Retinex and dark channel[J]. Laser & Optoelectronics Progress, 2021, 58(4): 0410004.
彭静, 薛奉金, 苑玉彬. 基于多尺度 Retinex 和暗通道的自适应图像去雾算法[J]. 激光与光电子学进展, 2021, 58(4): 0410004.
- [5] TAN R T. Visibility in bad weather from a single image [C]//2008 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 23-28, 2008, Anchorage, AK, USA. New York: IEEE, 2008: 1-8.
- [6] HE K, SUN J, TANG X. Single image haze removal using dark channel prior[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(12): 2341-2353.
- [7] ZHU Q, MAI J, SHAO L. A fast single image haze removal algorithm using color attenuation prior[J]. IEEE Transactions on Image Processing, 2015, 24(11): 3522-3533.
- [8] CAI B, XU X, 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.
- [9] ZHANG H, PATEL V M. Densely connected pyramid dehazing network [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE, 2018: 3194-3203.
- [10] LI B, PENG X, WANG Z, 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, 2017: 4780-4788.
- [11] GOODFELLOW I J, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial nets [C]//27th International Conference on Neural Information Processing Systems (NIPS), December 8-13, 2014, Montreal, Canada. Cambridge: MIT Press, 2014: 2672-2680.
- [12] CHEN D, HE M, FAN Q, 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, 2019: 1375-1383.
- [13] XIAO J S, SHEN M Y, LEI J F, et al. Image conversion algorithm for haze scene based on generative adversarial networks [J]. Chinese Journal of Computers, 2020, 43(1): 165-176.
肖进胜, 申梦瑶, 雷俊峰, 等. 基于生成对抗网络的雾霾场景图像转换算法 [J]. 计算机学报, 2020, 43(1): 165-176.
- [14] ENGIN D, GEN 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, 2018: 825-833.
- [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, 2017: 2242-2251.
- [16] ANVARI Z, ATHITSOS V. Dehaze-GLCGAN: unpaired single image de-hazing via adversarial training [EB/OL]. (2020-08-15) [2022-05-27]. <https://arxiv.org/abs/2008.06632>.
- [17] SUN X S, WANG G Z. Unsupervised dehazing algorithm based on multi-scale features [J]. Laser & Optoelectronics Progress, 2021, 58(16): 1610024.
孙祥胜, 王国中. 基于多尺度特征的无监督去雾算法 [J]. 激光与光电子学进展, 2021, 58(16): 1610024.
- [18] MCCARTNEY E J, HALL F F. Optics of the atmosphere: scattering by molecules and particles [J]. Physics Today, 1977, 30(5): 76-77.
- [19] OLAF R, PHILIPP F, THOMAS B. U-Net: convolutional networks for biomedical image segmentation [C]//2015 International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI), October 5-9, 2015, Munich, Germany. Singapore: Springer, 2015: 234-241.
- [20] JUSTIN J, ALEXANDRE A, LI F-F. Perceptual losses for real-time style transfer and super-resolution [C]//2016 European Conference on Computer Vision (ECCV), October 11-14, 2016, Amsterdam, The Netherlands. Singapore: Springer, 2016: 694-711.

作者简介:

翟社平 (1971—), 男, 博士, 教授, 硕士生导师, 主要从事计算机视觉、自然语言处理与人工智能方面的研究。