

基于双判别器异构CycleGAN框架下多阶通道注意力校准的室外图像去雾

但志平^{1,2}, 方帅领¹, 孙 航^{1,2}, 李 晶³, 万 俊⁴

(1. 三峡大学计算机与信息学院, 湖北宜昌 443000; 2. 三峡大学湖北省水电工程智能视觉监测重点实验室, 湖北宜昌 443000;
3. 武汉大学计算机学院, 湖北武汉 430072; 4. 中南财经政法大学信息与安全工程学院, 湖北武汉 430073)

摘 要: 图像去雾是计算机视觉领域中一个经典并具有挑战性的研究方向. 近年来, 基于深度学习的方法在图像去雾领域取得了显著的成绩. 然而, 大多数去雾算法依赖于合成配对数据训练网络, 由于合成数据与真实有雾数据在分布上存在一定的差距, 从而限制了这类去雾方法的实际应用. 目前基于CycleGAN网络框架的去雾算法将图像去雾视为一般性图像转换问题, 忽视了生成器学习的有效性; 此外, 在恢复图像时缺乏对于局部区域的探索, 构建的网络结构中仅采用一阶通道注意力, 忽略了深层次通道相关信息的有效利用. 为此, 本文提出一种基于双判别器异构CycleGAN框架下多阶通道注意力校准的室外图像去雾算法, 该方法主要包含双判别器异构循环框架和多阶通道注意力模块. 具体来说, 双判别器异构CycleGAN框架通过异构批归一化的生成器和约束生成器局部视野的方式, 提升算法的收敛效果和增加局部区域关注. 为了进一步挖掘对于图像去雾至关重要的特征通道信息, 本文通过引入一阶、二阶特征统计量提出了多阶通道注意力模块, 从而提升去雾图像的视觉质量. 实验结果表明, 在公开合成和真实室外数据集上, 本文提出的去雾方法相比现有的8种优秀的去雾算法, 取得了最好的客观评价指标和视觉效果.

关键词: 图像去雾; 批归一化; 异构CycleGAN; 双判别器; 多阶通道注意力

基金项目: 国家自然科学基金(No.62002233); 湖北省自然科学基金(No.2021CFB004)

中图分类号: TP391.4

文献标识码: A

文章编号: 0372-2112(2023)09-2558-14

电子学报URL: <http://www.ejournal.org.cn>

DOI: 10.12263/DZXB.20211337

Outdoor Image Dehazing Based on Multi-Order Channel Attention Calibration Using a Dual-Discriminator Heterogeneous CycleGAN Framework

DAN Zhi-ping^{1,2}, FANG Shuai-ling¹, SUN Hang^{1,2}, LI Jing³, WAN Jun⁴

(1. College of Computer and Information Technology, China Three Gorges University, Yichang, Hubei 443000, China;

2. Hubei Key Laboratory of Intelligent Vision Based Monitoring for Hydroelectric Engineering, China Three Gorges University, Yichang, Hubei 443000, China;

3. School of Computer Science, Wuhan University, Wuhan, Hubei 430072, China;

4. School of Information and Safety Engineering, Zhongnan University of Economics And Law, Wuhan, Hubei 430073, China)

Abstract: Image dehazing is a classic and challenging research direction in the field of computer vision. In recent years, methods based on deep learning have achieved remarkable achievements in image dehazing. However, most existing dehazing algorithms rely on synthetic paired data training network, which limits the practical application of the dehazing methods, due to the discrepancy in the distribution between the synthetic and real-world foggy images. At present, image dehazing algorithms based on the CycleGAN network framework regard image dehazing as general image transformation, ignoring the effectiveness of generator learning. In addition, these algorithms lacks the exploration of local areas in image restoration, and uses only first-order channel attention in the constructed network, ignoring the effective utilization of deep-level channel-related information. Therefore, this paper proposes a dehazing algorithm for outdoor images based on multi-order channel attention calibration using a dual-discriminator heterogeneous CycleGAN framework, which mainly consists of a dual-discriminator heterogeneous cycle framework and multi-order channel attention module. Specifically, the dual-discrimi-

nator heterogeneous CycleGAN framework improves the convergence effect of the algorithm and increases the focus of the local area through the batch normalization generator of the heterogeneous CycleGAN and constraining the generator's local field of view. To further explore the feature channel information that is essential for image dehazing, this study employs a multi-order channel attention module by introducing first-order and second-order feature statistics to improve the visual quality of dehazing images. The results of the experiment show that our proposed method outperforms eight state-of-the-art dehazing algorithms on both synthetic and real-world data sets, regarding the extent of objective evaluation and visual quality.

Key words: image dehazing; batch normalization; heterogeneous CycleGAN; dual-discriminators; multi-order channel attention

Foundation Item(s): National Natural Science Foundation of China (No.62002233); Natural Science Foundation of Hubei Province of China (No.2021CFB004)

1 引言

由于受雾霾等天气中微小粒子的影响,可见光系统在成像过程中会出现图像模糊、颜色失真、对比度下降等问题,严重影响图片质量。在诸如目标检测、人脸识别对齐、图像分类等高级视觉任务^[1-4]中,通常会把图像去雾做为高阶任务的预处理过程,以还原高质量图像内容信息便于后期处理。因此,在过去几年中,图像去雾在视觉领域受到了广泛的研究关注。

在早期的去雾算法中,大多数方法通过先验信息估计传输图和全球大气光值等中间参数,再利用大气散射模型^[5]实现图像去雾。常见的利用先验信息去雾的方法如暗通道先验^[6]、非局部先验^[7]、颜色衰减先验^[8]等。虽然基于先验信息的方法取得了显著的进展,但是,这些方法通常在无约束条件下,会发生不准确的估计,从而导致恢复出无雾图像的质量不够理想。

随着深度学习的发展,研究人员提出了许多基于卷积神经网络的去雾方法,主要分为基于中间参数估计的去雾方法^[9-11]和端到端去雾方法^[12-18]。基于中间参数估计的去雾方法直接利用卷积神经网络估计大气散射模型的中间参数,然后再利用大气散射模型进行图像去雾。虽然基于中间参数估计的方法相比基于先验信息的方法取得了一定的进步,但是在参数估计不准确的情况下,容易造成生成图像引入颜色失真和伪影现象。因此,许多研究人员提出了端到端去雾方法,这些方法通过卷积神经网络直接建立有雾图像和无雾图像之间的映射,而不需要估计任何中间参数。基于端到端的方法虽然取得了不错的去雾效果,但是大多数基于端到端的方法在训练模型时需要依赖配对的数据集。众所周知,采集大规模真实有雾无雾配对数据集难以实现,用于训练模型的数据集大多采用人工合成雾的图像,然而人工合成的有雾图像和现实场景中雾的分布具有一定的差距。因此,基于非配对数据集研究图像去雾算法具有重要意义。

近年来,随着生成对抗网络(Adversarial Generative Network, GAN)^[19]的提出,以及各种 GAN 网络变体的发

展,基于 GAN 网络思想的研究工作在图像生成领域^[20,21]展示了 GAN 网络的强大能力。特别是 Zhu 等^[22]提出了 CycleGAN 网络框架,该模型能够利用非配对数据集实现图像转换,在计算机视觉领域引起了研究人员的大量关注。最近,研究人员提出了一系列基于 CycleGAN,采用非配对图像训练网络的去雾算法。Engin^[16]提出了 Cycle-Dehaze 单幅图像去雾网络,该方法基于 CycleGAN 利用非配对数据训练网络,并增加循环感知损失提升去雾图像质量。Liu^[18]基于 CycleGAN 提出两阶段映射策略,该方法在使用非配对数据训练网络的同时,进一步提高了去雾图像质量。但是直接使用 CycleGAN 进行图像去雾,仍然存在以下几个问题:(1)在图像去雾任务中,去雾前后图像的场景内容没有改变,因此不能像一般的图像转换任务一样强调个体实例之间的差异;循环框架为了实现非配对数据集训练模型,需要具有两种任务的生成器:去雾生成器和恢复雾生成器。以去雾生成器为例,生成器的输入数据包括数据集中有雾图像和恢复雾生成器生成的图像,两种不同分布数据的输入会影响生成器网络的收敛效果。(2)目前,大多数基于 GAN 网络的去雾算法,缺乏对于图像局部区域的关注,从而导致恢复的去雾图像在局部区域质量无法达到满意的效果。(3)现有去雾网络中常用的通道注意力是一阶统计量,没有充分考虑特征通道之间的相互关系,缺乏有效的几何约束,无法有效利用特征的表达能力。

对于以上问题,本文提出了一种基于双判别器异构 CycleGAN 框架下多阶通道注意力校准的图像去雾网络。具体而言,本文通过双判别器异构 CycleGAN 框架在循环框架的生成器中引入 Batch Normalization 独立学习和权重共享机制,从而使网络中的生成器重视每个 Mini-Batch 中所有图像数据 Batch 的分布,并且使具有同一任务的生成器独立学习输入生成器中数据的分布,避免不同分布的数据引起生成器学习混乱的问题。同时,该框架通过引入全局局部双判别器机制来增加网络对局部区域的关注度,从而提升去雾图像的局部区域的质量。此外,为了从不同角度充分挖掘对于图像去雾至关重要的通道相关信息,本文设计了多阶通道注意力模块,该

模块包含一阶通道注意力和二阶通道注意力。一阶通道注意力利用一阶统计量均值可以实现快速、有效的通道权重校准;二阶通道注意力可以有效的利用特征图中的位置信息,并且有效的刻画了特征图中通道之间的相关性,因此融合一阶和二阶注意机制的多阶通道注意力模块能够进一步提升生成器网络提取特征的表达能力。综上所述,本文具体的贡献如下:

(1) 本文将图像去雾任务,视为一个以 Batch 为基本单位,两种数据分布之间的迁移问题。在此基础上,设计了双判别器异构 CycleGAN 框架。在该框架中,实现了能够独立学习不同分布数据的异构生成器,双判别器机制可以从全局和局部视野两方面,共同约束生成器的训练过程。

(2) 本文设计了多阶通道注意力模块,将融合一阶通道注意力和二阶通道注意力的优点,从不同角度探索对于图像去雾至关重要的通道信息,从而提升去雾图像的生成质量。

(3) 在 RESIDE、HazeRD、OHaze 等合成数据集和真实数据集的实验结果表明,本文提出的图像去雾方法在客观评价指标和主观视觉效果上,均优于最近提出的 8 种优秀的去雾算法。

2 相关工作

2.1 基于参数估计的方法

基于参数估计的图像去雾算法依赖于大气散射模型。在大气散射模型中有两个重要参数:传输图和全局大气光值。因此,估计传输图和大气光值是物理模型去雾的重要步骤。He 等^[6]提出基于暗通道先验的单幅图像去雾算法,暗通道先验是假设图像至少有一个通道值趋近于 0,然后利用图像的暗通道先验知识估计传输图。Berman 等^[7]提出一种基于非局部先验的方法,该方法假设组成无雾图像的紧密颜色簇会由于雾而发生变化,并在 RGB (Red Green Blue) 空间中形成一条雾信息线,然后通过自动检测雾信息线并估计每个像素的传输图。Zhu 等^[8]提出了线性颜色衰减先验去雾方法,通过对有雾图像的场景深度进行建模恢复深度信息,并利用雾信息线先验估计大气光值,从而实现图像去雾。近年来,随着大规模合成数据集的广泛应用,将依赖数据驱动的深度卷积神经网络 (Convolutional Neural Networks, CNN) 用于图像去雾受到了研究人员的大量关注。许多去雾方法直接利用 CNN 来估计传输图和大气光值,然后依据大气散射模型得到清晰图像。Cai 等^[9]提出了可训练的 Dehaze-Net 网络,该方法通过特殊设计的卷积神经网络深层架构,利用卷积神经网络强大的学习能力,建立有雾图像与其对应传输图之间的映射。He 等^[10]提出密集连接金字塔去雾网络 DCPDN

(Densely Connected Pyramid Dehazing Network), 该网络包含两个生成器,分别用于估计传输图和大气光值,然后通过大气散射模型进行图像去雾。Tang 等^[11]使用随机森林算法学习回归模型,该方法通过提取各种与雾相关的多尺度特征并进行自动评估,从而获取有用的特征信息进行中间参数的估计。虽然这些基于中间参数估计的去雾方法在一些场景中取得了不错的去雾效果,但这些去雾方法仍然直接或间接依赖估计透射图和全局大气光值。在非约束场景中,当这些中间参数的估计存在偏差时,去雾后图像容易产生伪影、颜色失真以及噪声等问题。

2.2 基于端到端的方法

基于端到端的图像去雾方法不需要估计任何中间参数,直接通过卷积神经网络完成有雾图像到无雾图像之间的映射。Li 等^[12]提出了一体化去雾网络 AOD-Net (All-in-One Dehazing Network), 该方法是基于转换变形后的大气散射模型设计,不需要估计传输图和大气光值,可以通过卷积神经网络直接生成清晰图像。Dong 等^[13]将图像的频率信息作为额外的先验知识集成到网络学习的过程中,提出了融合判别器的端到端去雾算法 FD-GAN (Generative Adversarial Networks with Fusion-discriminator for signal image Dehazing), 该方法利用融合判别器强大的判别能力,使得生成器网络模型恢复的无雾图像更加真实自然。Li 等^[14]提出一种面向任务的端到端图像去雾网络,该方法以有雾图像形成过程为依据设计卷积神经网络,并取得了良好的性能。Qu 等^[15]提出增强 pix2pix 去雾网络,该模型通过提出的多分辨率生成器、多尺度判别器和一个增强网络生成更好的去雾图像。尽管上述端到端的去雾方法取得了不错的去雾效果,但是大多数基于端到端的去雾算法依赖于合成配对数据训练网络。由于合成数据与真实有雾数据在分布上存在一定的差距,从而限制了这类方法的实际应用。因此,Engin 等^[16]基于 CycleGAN 提出单幅图像去雾网络 Cycle-Dehaze。该方法在 CycleGAN 的基础上引入感知一致损失,从而在特征层面约束原始图像和循环生成图像,使去雾生成器和恢复雾生成器能够有效的学习有雾图像与无雾图像之间的映射关系。Shao 等^[17]提出了域自适应去雾网络 DA-Dehaze, 该方法以合成数据集训练的模型在真实有雾图上泛化能力较差为出发点,基于 CycleGAN 设计了一种双向变换网络,将图像从合成域变换到真实域,从而提升网络模型对于真实有雾图像的去雾能力。Liu^[18]基于 CycleGAN 提出两阶段映射的端到端单幅图像去雾算法,该方法通过引入图像增强网络,使去雾后的图像再经过图像增强网络,取得了良好的去雾效果。虽然上述基于 CycleGAN 的去雾方法从不同层面解决了基于循环结构的去雾任务中存在的一些问题,

但是想要获得更好的去雾图像质量,仍然需要从更多的角度出发,进一步的深入研究.

3 本文方法

3.1 基于双判别器的异构 CycleGAN 框架

Cycle-Dehaze 直接继承 CycleGAN 的网络框架和网络结构,采用 Instance Normalization 对框架中生成器进行数据分布归一化. 与 Cycle-Dehaze 的思路不同,本文将图像去雾看成一个以 Batch 为基本单位,两种数据分布之间的迁移问题. 因此,本文采用 Batch Normalization 对生成器网络模型中数据分布进行归一化. 此外,如果直接使用 CycleGAN 框架进行图像去雾,需要使用两个生成器:去雾生成器 G 和恢复雾生成器 F . 假设输入网络的有雾图像 $X \in \{X_i\}_{i=1}^M$ 和清晰图像 $Y \in \{Y_j\}_{j=1}^N$ 为非配对关系, M 与 N 分别表示有雾图像和清晰图像的数量. 有雾图像 X 通过去雾生成器 G 生成清晰图像 $G(X)$,然后将生成清晰图像 $G(X)$ 输入恢复雾生成器 F 中,得到循环有雾图像 $F(G(X))$. 类似地,清晰图像 Y 通过恢复雾生成器 F 生成有雾图像 $F(Y)$,然后将生成有雾图像 $F(Y)$ 送入去雾生成器 G 中,得到循环生成清晰图像 $G(F(Y))$. 判别器 D_x 用于区分有雾图像 X 和生成有雾图像 $F(Y)$, 判别器 D_y 用于区分清晰图像 Y 和生成清晰图像 $G(X)$.

观察 CycleGAN 的循环结构可以发现,输入去雾生成器 G 的数据包含数据集中有雾图像 X 和生成有雾图像 $F(Y)$,输入恢复雾生成器 F 的数据包含数据集中清晰图像 Y 和生成清晰图像 $G(X)$. 显然,输入相同任务生成器 G 或 F 的数据具有不同的分布. 众所周知,深度学习模型的有效性是建立在训练数据集是具有相同分布假设的条件下. 然而,生成器 G 使用具有不同分布的数据

进行训练,这势必会造成生成器学习的混乱,从而影响生成器学习的有效性,生成器 F 类似. 除此之外,在基于 CycleGAN 的图像去雾框架中,仅考虑了全局视野来约束生成器,缺乏对局部区域的有效约束,从而造成去雾生成器网络恢复的图像可能产生局部雾残留以及图像局部信息恢复不理想的情况. 为了解决上述问题,本文提出了基于双判别器的异构学习 CycleGAN 框架,如图 1 所示. 以图 1 中蓝色虚线连接的两个去雾生成器为例,输入生成器的数据包括数据集中的有雾图像和恢复雾生成器生成的有雾图像,这两种有雾图像数据如果作用在同一个去雾生成器中,会对 Batch Normalization 中可学习参数 γ 和 β 的学习产生干扰,从而影响生成器中每一层 Batch Normalization 将数据强行“拉”回到均值为 0, 方差为 1 的正态分布,导致网络的收敛效果不好,橘黄色虚线连接的恢复雾生成器类似. 为了避免不同分布数据引起相同任务生成器学习混乱的问题,本文通过引入网络权重共享和 Batch Normalization 独立学习的方式,将去雾生成器构建为两个学习不同输入分布的生成器(恢复雾生成器类似),从而实现了异构 CycleGAN 框架,最终使得整个 CycleGAN 循环框架形成一个良好的平衡状态,提升网络的收敛效果.

此外,如图 1 所示,本文提出的双判别器异构 CycleGAN 框架包含两种视野的判别器,分别是全局判别器 $D_x^{global}, D_y^{global}$ 和局部判别器 D_x^{local}, D_y^{local} . 全局判别器有 8 层卷积操作,前 7 层卷积操作后都经过激活函数 LeakyReLU 和 Batch Normalization,除第一和最后一层卷积操作外,其余卷积操作会使特征图尺寸变成原来的 1/2. 全局判别器 D_x^{global} 用于区分数据集中有雾图像 X 、循环生成有雾图像 $F_{BN}^*(G_{BN}(X))$ 和生成有雾图像 $F_{BN}(Y)$. 全局判别器 D_y^{global} 用于区分数据集中

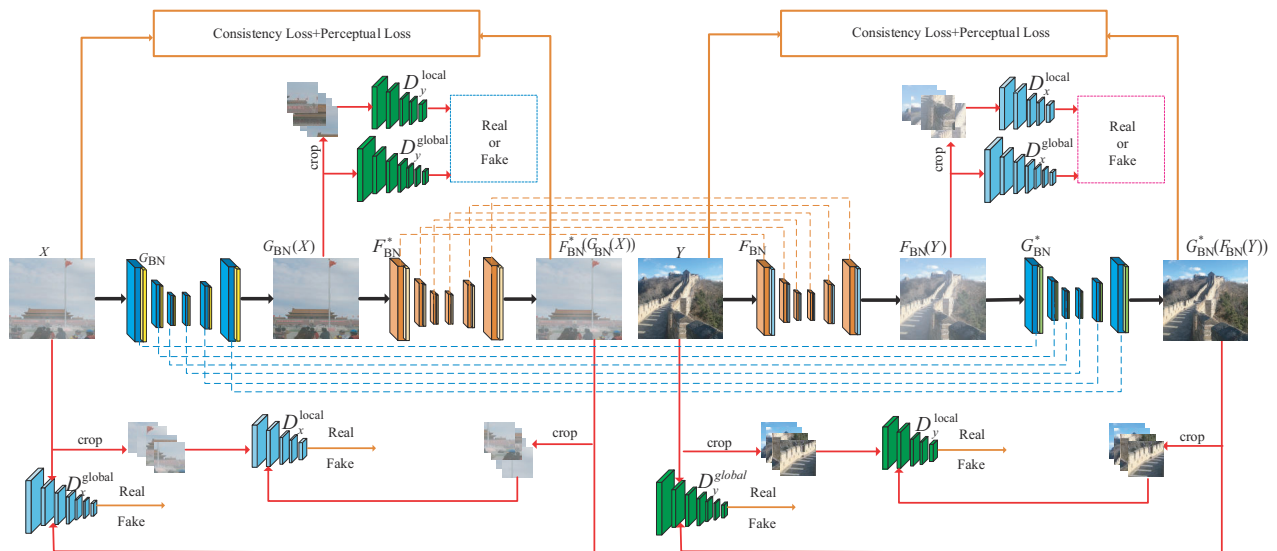


图 1 基于双判别器异构 CycleGAN 框架的结构图

清晰图像 Y 、循环生成清晰图像 $G_{BN}^*(F_{BN}(Y))$ 和生成清晰图像 $G_{BN}(X)$ 。由于局部判别器输入图像是在原始分辨率图像上随机裁剪而来,本文设计局部判别器仅采用6层卷积操作。以局部判别器 D_x^{local} 为例, D_x^{local} 用于判别数据集中有雾图像 X 、循环生成有雾图像 $F_{BN}^*(G_{BN}(X))$ 和生成有雾图像 $F_{BN}(Y)$ 随机裁剪的 $5 \times 32 \times 32$ 大小的图像。通过增加对图像局部区域关注的方式,可以有效减少去雾生成器生成图像中局部雾残留的现象,提升局部图像恢复效果,从而提高去雾图像的局部区域质量。实验部分的结果表明,在本文提出的异构 CycleGAN 网络框架和全局-局部判别器的作用下,本文去雾算法恢复的清晰图像具有更好客观评价指标和视觉效果。

3.2 生成器网络结构及多阶通道注意模块

U-Net 网络^[23]是由编码器和解码器组成的全卷积网络,在图像分割、图像去雾等领域被广泛使用。本文也采用类似 U-Net 的编解码网络结构作为生成器的基本结构,具体如图 2 所示。与基于 CycleGAN 框架的 Cycle-Dehaze 中生成器不同,本文的生成器网络结构是一个包含多次卷积下采样的 U 型编解码网络,在网络的每一层中都采用 Batch Normalization 进行归一化。此外,在本文 U 型编解码网络中有自适应平均池化操作和多阶通道注意模块。现有的大多数图像去雾算法一般都是将图像 Resize 成固定分辨率,然后送入生成器网络模型进行推理,再经过 Resize 或拉普拉斯算子等方式恢复原始图像的分辨率,这些前置和后置的处理,在一

定程度上会造成图像信息的丢失,特别是高频细节信息。为了避免前置和后置处理,本文在网络模型的深层结构中采用自适应平均池化操作,从而使得网络模型训练好之后可以处理任意分辨率的图像。

He 等人在文献[6]证明了通道对于去雾问题的重要性。目前,通道注意力机制被广泛应用于图像去雾中。然而,大部分去雾研究工作主要关注一阶通道注意力,即一阶统计量,缺乏对高阶和多阶信息的探索和研究。为了从不同角度充分挖掘通道信息,本文提出了多阶通道注意力模块如图 3 所示,多阶通道注意力模块的输入为 $X=[X_1 \ X_2 \ X_3 \ \dots \ X_n \ \dots \ X_N]$,其中 N 表示通道数。一阶通道注意力机制如图 3 上半部分所示,首先通过全局平均池化把通道中的全局空间信息转换成通道描述符 $f \in \mathbf{R}^{1 \times N}$,第 n 个通道的描述符如式(1)所示:

$$f_n = H_{gap}(X_n) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W X_n(i, j) \quad (1)$$

其中, $X_n(i, j)$ 表示第 n 个单通道特征图 X_n 在位置 (i, j) 处的值, H_{gap} 表示全局平均池化函数。特征图的形状从 $H \times W \times N$ 变成 $1 \times 1 \times N$ 。然后,将一阶通道描述符 f 经过带有 Sigmoid 激活的简单门控机制^[24],确保允许强调多个通道(而不是强制执行单热激活)。整个过程可以表示为:

$$F = \sigma(C_2(\delta(C_1(f)))) \quad (2)$$

其中, σ, δ 分别表示 Sigmoid 和 Relu 激活函数。 C_1, C_2 表示两次卷积,并且分别把特征图的通道数转换成 $N/4$ 和 N 。最后,经过一阶通道注意力模块的特征图的第 n 个通道被表示为:




图2 基于多阶通道注意力校准的生成器结构图




图3 多阶通道注意力模块

$$\mathbf{X}'_n = \mathbf{F}_n \mathbf{X}_n \quad (3)$$

一阶信息优点是简单、快速以及在大多数情况下有效,但是其采用全局平均池化将 $H \times W \times N$ 的特征图池化成 $1 \times 1 \times N$ 特征图的过程,虽然在一定程度上提升了计算速度,但是同时也会丢失许多重要的信息,缺乏有效的几何约束,无法充分利用特征的表达能。

文献[25]表明,在深度卷积神经网络中,二阶统计量协方差矩阵能够衡量不同维度的相互关系,并且获得比一阶统计量更好的表达能力。正如图3下半部分所示,二阶通道注意力是将 $H \times W \times N$ 的特征图 Reshape 成 \mathbf{S} 为 $M \times N$ 的特征图,其中 $M = H \times W$ 表示特征图按照长和宽的维度展开, N 表示通道数。相比一阶通道注意力的全局平均池化,二阶通道注意力可以有效的保留特征图中特征值的位置信息,增加了特征值之间的几何约束。协方差矩阵可表示为:

$$\boldsymbol{\Sigma} = \mathbf{S} \mathbf{R} \mathbf{S}^T \quad (4)$$

其中, $\mathbf{R} = \frac{\mathbf{I}}{M} - \frac{\mathbf{1}\mathbf{1}^T}{M^2}$, \mathbf{I} 表示 $M \times M$ 的单位矩阵, $\mathbf{1}$ 表示 $M \times M$ 的全一矩阵。计算后的协方差矩阵是一个 $N \times N$ 的矩阵。根据协方差矩阵的性质可知,其对角线上的元素为各个随机变量的方差,非对角线上的元素为两两随机变量之间的协方差,该协方差矩阵不仅包含了位置信息,而且有效的刻画了特征图中通道之间的相关性。 $\boldsymbol{\Sigma}$ 是一个对称的半正定矩阵,可以对其进行特征值分解得到:

$$\boldsymbol{\Sigma} = \mathbf{U} \mathbf{A} \mathbf{U}^T \quad (5)$$

其中, \mathbf{U} 为正交矩阵, \mathbf{A} 表示 $\boldsymbol{\Sigma}$ 的特征值组成的对角阵。将协方差矩阵归一化转换为特征值幂的形式:

$$\mathbf{Y} = \boldsymbol{\Sigma}^{\frac{1}{2}} = \mathbf{U} \mathbf{A}^{\frac{1}{2}} \mathbf{U}^T \quad (6)$$

由于在 GPU 上快速实现矩阵的特征值分解仍然是一个未解决的问题,受文献[26]的启发,本文利用牛顿-舒尔茨迭代来加快协方差矩阵归一化的计算。具体来说,在给定 $\mathbf{Y}_0 = \boldsymbol{\Sigma}$ 和 $\mathbf{Z}_0 = \mathbf{I}$ 的情况下,然后按如下所示交替更新牛顿-舒尔茨迭代:

$$\mathbf{Y}_s = \frac{1}{2} \mathbf{Y}_{s-1} (3\mathbf{I} - \mathbf{Z}_{s-1} \mathbf{Y}_{s-1}) \quad (7)$$

$$\mathbf{Z}_s = \frac{1}{2} (3\mathbf{I} - \mathbf{Z}_{s-1} \mathbf{Y}_{s-1}) \mathbf{Z}_{s-1} \quad (8)$$

其中 S 是迭代次数。然而,牛顿-舒尔茨迭代仅在局部收敛。为了保证收敛,需要对 $\boldsymbol{\Sigma}$ 进行预归一化,并在牛顿-舒尔茨迭代后,执行后补偿程序以补偿由预归一化引起的数据误差,产生最终的归一化协方差矩阵:

$$\mathbf{Y} = \sqrt{\text{tr}(\boldsymbol{\Sigma}) \mathbf{Y}_s} \quad (9)$$

令 $\mathbf{Y} = [\mathbf{Y}_1 \mathbf{Y}_2 \mathbf{Y}_3 \cdots \mathbf{Y}_n \cdots \mathbf{Y}_N]$, 得到通道方向的统计量 \mathbf{k} , $\mathbf{k} \in \mathbf{R}^{1 \times N}$, \mathbf{k} 的第 n 个维度数值计算如式(10)所示:

$$\mathbf{k}_n = H_{\text{gcp}}(\mathbf{Y}_n) = \frac{1}{N} \sum_{i=1}^N \mathbf{Y}_n(i) \quad (10)$$

其中, $H_{\text{gcp}}(\mathbf{Y}_n)$ 为全局协方差池化,该池化操作探索了特征分布并捕获了比一阶更高的特征统计信息。为充分利用从全局协方差池化得到的特征通道间的相互依赖性,采用和一阶通道注意力相同的选通机制:

$$\mathbf{K} = \sigma(C_U(\delta(C_D(\mathbf{k})))) \quad (11)$$

其中 C_D 和 C_U 表示卷积操作,分别将特征的通道维数设置为 $N/8$ 和 N 。卷积层中卷积核的大小为 1×1 。利用获得的通道注意力权重向量 \mathbf{K} 重新调整输入,经过二阶通道注意力的特征图的第 n 个通道被表示为:

$$\mathbf{X}_n^2 = \mathbf{K}_n \mathbf{X}_n \quad (12)$$

最后,本文整合一阶通道注意力和二阶通道注意力得到了多阶通道注意力,如式(13)所示:

$$\hat{\mathbf{X}} = \mathbf{X}^1 + \mathbf{X}^2 \quad (13)$$

通过上述推理和分析可知,一阶通道注意力可以衡量特征矩阵中不同通道特征图的重要程度,二阶通道注意力可以从另一个角度来获取不同特征图通道之间的信息。因此,本文融合一阶信息和二阶信息设计了多阶通道注意力模块,是从不同角度来获取特征图矩阵中和去雾相关的信息。

3.3 损失函数

本节将介绍训练网络使用到的损失函数。其中,输入网络的有雾图像 $x_i \in X$, 清晰图像 $y_i \in Y$ 。 P_C 表示从图像中随机裁剪出一个大小为 32×32 的图像块。本文生成器的对抗损失定义如下:

$$L_{adv-global}^G = E_x [D_y^{global}(G_{BN}(x_i)) - 1] + E_y [D_x^{global}(F_{BN}(y_i)) - 1] \\ + E_x [D_x^{global}(F_{BN}^*(G_{BN}(x_i))) - 1] \\ + E_y [D_y^{global}(G_{BN}^*(F_{BN}(y_i))) - 1] \quad (14)$$

$$L_{adv-local}^G = E_x [D_y^{local}(P_{G_{BN}(x_i)}) - 1] + E_y [D_x^{local}(P_{F_{BN}(y_i)}) - 1] \\ + E_x [D_x^{global}(P_{F_{BN}^*(G_{BN}(x_i)))} - 1] \\ + E_y [D_y^{global}(P_{G_{BN}^*(F_{BN}(y_i)))} - 1] \quad (15)$$

其中, x_i 表示有雾图像, $G_{BN}(x_i)$ 表示 x_i 经过去雾生成器 G_{BN} 得到的生成清晰图像, $P_{G_{BN}(x_i)}$ 表示对 $G_{BN}(x_i)$ 随机裁剪得到的一张大小为 32×32 的图像块. 本文判别器的对抗损失定义如下:

$$L_{adv-global}^D = E_x [D_x^{global}(x_i) - 1] + E_x [D_y^{global}(G_{BN}(x_i)) - 0] \\ + E_x [D_x^{global}(F_{BN}^*(G_{BN}(x_i))) - 0] + E_y [D_y^{global}(y_i) - 1] \\ + E_y [D_x^{global}(F_{BN}(y_i)) - 0] \\ + E_y [D_y^{global}(G_{BN}^*(F_{BN}(y_i))) - 0] \quad (16)$$

$$L_{adv-local}^D = E_x [D_x^{local}(P_{x_i}) - 1] + E_x [D_y^{local}(P_{G_{BN}(x_i)}) - 0] \\ + E_x [D_x^{local}(P_{F_{BN}^*(G_{BN}(x_i)))} - 0] + E_y [D_y^{local}(P_{y_i}) - 1] \\ + E_y [D_x^{local}(P_{F_{BN}(y_i)}) - 0] \\ + E_y [D_y^{local}(P_{G_{BN}^*(F_{BN}(y_i)))} - 0] \quad (17)$$

另外, 通过有雾图像 x_i 和循环生成有雾图像 $F_{BN}^*(G_{BN}(x_i))$ 以及清晰图像 y_i 和循环生成清晰图像 $G_{BN}^*(F_{BN}(y_i))$ 来构建循环一致损失. 具体损失定义如下:

$$L_{cycle-global}^G = E_x [\|F_{BN}^*(G_{BN}(x_i)) - x_i\|_1] \\ + E_y [\|G_{BN}^*(F_{BN}(y_i)) - y_i\|_1] \quad (18)$$

$$L_{cycle-local}^G = E_x [\|P_{F_{BN}^*(G_{BN}(x_i)))} - P_{x_i}\|_1] \\ + E_y [\|P_{G_{BN}^*(F_{BN}(y_i)))} - P_{y_i}\|_1] \quad (19)$$

文献[16]表明, 使用感知一致损失恢复的图像保留了更多的纹理信息. 具体的做法是, 计算原始图像和重构图像在 VGG16^[27] 网络的第 3、5、15 层的 L2 范数, 保证原始图像和重构图像在不同特征层面的相似性. 本文的感知一致损失定义如下:

$$L_{perceptual-global}^G = E_x [\|\phi(F_{BN}^*(G_{BN}(x_i))) - \phi(x_i)\|_2^2] \\ + E_y [\|\phi(G_{BN}^*(F_{BN}(y_i))) - \phi(y_i)\|_2^2] \quad (20)$$

$$L_{perceptual-local}^G = E_x [\|\phi(P_{F_{BN}^*(G_{BN}(x_i)))} - \phi(P_{x_i})\|_2^2] \\ + E_y [\|\phi(P_{G_{BN}^*(F_{BN}(y_i)))} - \phi(P_{y_i})\|_2^2] \quad (21)$$

最后, 整合生成器的全局损失, 生成器的局部损失以及双判别器的损失, 本文整体的损失如式(22)所示, 其中 $\lambda_1, \lambda_2, \lambda_3, \lambda_4$ 为其对应的权重:

$$L = (L_{adv-global}^G + \lambda_1 L_{cycle-global}^G + \lambda_2 L_{perceptual-global}^G) \\ + \lambda_3 (L_{adv-local}^G + L_{cycle-local}^G + L_{perceptual-local}^G) \\ + \lambda_4 (L_{adv-global}^D + L_{adv-local}^D) \quad (22)$$

4 实验

本节将展示本文所提出的去雾方法和目前 8 种优秀的去雾方法, 在合成和真实数据集上定量以及定性的评估结果. 对比的去雾方法包括: DCP^[6], DehazeNet^[9], AOD-Net^[12], DCPDN^[10], EPDN^[15], Cycle-Dehaze^[16], FD-GAN^[13], DA-Dehaze^[17]. 本节剩余部分将介绍实验设置、数据集、评估指标以及定量和定性的评价结果. 最后, 通过消融实验验证各个模块的作用.

4.1 实验设置及数据集

实验设置: 本文代码是基于 Pytorch 框架实现, 在 Ubuntu 环境下使用 NVIDIA 2080Ti GPU 训练网络模型. 采用 Adam 优化器进行优化网络, 其动量衰减指数 $\beta_1 = 0.9, \beta_2 = 0.999$. 初始学习率设置为 0.001, 使用指数衰减调整学习率, $\text{Gamma} = 0.98$. 在训练过程中, 输入模型的尺度大小为 256×256 , BatchSize 设置为 16, 网络模型中损失函数的参数 $\lambda_1 = 0.9, \lambda_2 = 1, \lambda_3 = 0.8, \lambda_4 = 0.5$.

数据集: 本文评估的数据集主要包括 RESIDE^[28]、HazeRD^[29] 和 OHaze^[30]. 在 RESIDE 数据集中, 采用室外训练集 OTS (Outdoor Training Set) 训练网络, OTS 训练集共包含 8 970 张清晰图像和 313 950 张有雾图像. 由于本文去雾方法是基于非配对数据训练网络, 因此从 OTS 有雾图像中随机选取 8 970 张图片与 8 970 张清晰图像一起构建室外训练数据集. SOTS (Synthetic Objective Testing Set) 为室外合成数据集 OTS 的测试集, 其中包含 500 张室外有雾图像以及相应的清晰图像 (Ground-Truth, GT). HazeRD 数据集包含 75 张合成有雾图像和相应的清晰图像, OHaze 数据集包含 45 张有雾图像和相应的清晰图像. 为了验证提出算法的鲁棒性, 本文将 HazeRD 数据集和 OHaze 数据集采用 8:2 的比例划分成训练集和测试集. 由于这两个数据集图像数量太少, 为了扩充训练集, 本文将训练集中的图像随机裁剪成 $2048, 1024, 512$ 尺度的图像, 每种尺度的图像约 1 500 张, 然后采用双线性插值的方式将这些图像 Resize 成 256×256 .

评价指标: 为了评估各种方法的性能, 本文采用峰值信噪比 (Peak Signal-to-Noise Ratio, PSNR) 和结构相似性指数 (Structural Similarity, SSIM) 作为定量评估指标, 这两个指标通常用于图像去雾任务中评估算法恢复图像质量. 此外, 本文根据主观感受在 4.3 节定性分

析展示了各种算法去雾后的可视化效果。

4.2 定量分析

本文提出的去雾方法和8种优秀去雾方法的定量评估如表1和表2所示,这两张表展示了所有评估去雾算法在PSNR和SSIM上的测试结果,第一名为黑体,第二名为斜体,第三名为粗斜体。从表1和表2中可以看出,大多数基于端到端的去雾方法,如EPDN、FD-GAN、DA-Dehaze在客观评价指标上要优于基于参数估计的方法,如DCP、Dehaze-Net、DCPDN。另外,在端到端的去雾方

法中,Cycle-Dehaze和本文去雾方法是利用非配对数据集进行训练网络,本文去雾方法在所测试的数据集中PSNR和SSIM都高于Cycle-Dehaze的方法。在RESIDE的室外合成测试集(SOTS)中,相比FD-GAN和DA-Dehaze,本文去雾方法在PSNR上分别提高了4.98 dB和0.39 dB,在SSIM上分别提高了0.074和0.037,取得了在该测试集中的SOTA(State-Of-The-Art)性能。在HazeRD和OHaze数据集中,本文去雾方法在定量指标PSNR和SSIM上也取得了最好的结果。因此,本文提出的去雾方法可以有效的提高去雾图像的质量。

表1 合成数据集中去雾算法的PSNR测试结果

单位: dB

Method	DCP	Dehaze-Net	AOD-Net	DCPDN	EPDN	Cycle-Dehaze	FD-GAN	DA-Dehaze	Ours
SOTS	15.55	15.03	19.63	20.13	20.02	16.09	22.19	26.78	27.17
HazeRD	15.18	13.60	16.07	15.28	18.14	11.92	15.93	14.68	19.13
OHaze	13.16	14.27	16.60	13.42	19.68	14.62	19.10	19.10	21.88
Average	14.63	14.12	17.43	16.27	19.28	14.21	19.07	20.18	22.72

表2 合成数据集中去雾算法的SSIM测试结果

Method	DCP	Dehaze-Net	AOD-Net	DCPDN	EPDN	Cycle-Dehaze	FD-GAN	DA-Dehaze	Ours
SOTS	0.815	0.791	0.861	0.871	0.885	0.825	0.888	0.925	0.962
HazeRD	0.798	0.651	0.769	0.738	0.792	0.687	0.787	0.780	0.803
OHaze	0.656	0.674	0.647	0.747	0.727	0.666	0.756	0.767	0.780
Average	0.756	0.705	0.759	0.785	0.801	0.726	0.810	0.824	0.848

4.3 定性分析

本节展示本文提出的去雾方法和8种优秀去雾方法的定性分析。在RESIDE室外合成测试集上的可视化去雾效果如图4所示。DCP去雾方法恢复的清晰图像存在严重的颜色失真现象。Dehaze-Net去雾方法去雾后图像在地面区域取得了比DCP更好的效果,然而在天空区域依然存在颜色失真现象,并且去雾后的图像与清晰图像在色调上存在较大的差异。AOD-Net去雾方法在部分图像上去雾效果不够理想,如图4 AOD-Net第二行红色框中的区域。DCPDN去雾方法取得了不错的去雾效果,但是在细节恢复上有略有不足,如图4 DCPDN第五行中的蓝天。EPDN去雾方法拥有非常好的去雾能力,但该去雾方法恢复的清晰图像整体偏暗,如图4 EPDN第二行中的树林区域。对于Cycle-Dehaze去雾方法,采用了与本文去雾方法一样的循环结构,并且使用非配对数据训练网络。但是,可以明显的看出,该去雾方法的去雾能力相对较差,并且色彩失真严重,产生了大量的伪影。FD-GAN去雾方法在去雾后图像中,与清晰图像相比依然有少量雾残留,并且会产生色调偏离,如图4 FD-GAN第五行中的道路区域。DA-Dehaze去雾方法通过使用域迁移的方式缩小合成域与真实域之间的差距,取得了较好的去雾效果。但是在细节处理上不如本文提出的去雾方法,如图4第一行中的

人和第三行中的五角星。另外,该方法也会引入一些噪声,如图4第四行中的红色椭圆区域。本文去雾方法如图4 Ours所示,相比其他8种去雾方法,本文去雾方法在达到去雾效果的同时,在主观视觉上如颜色、饱和度和清晰度方面最接近清晰图像。

HazeRD数据集上可视化结果如图5所示,DCP去雾方法恢复的图像整体偏暗。Dehaze-Net去雾方法恢复的图像中存在少量雾残留。AOD-Net去雾方法恢复的与原图像相比具有一定色调偏差。DCPDN去雾方法有较好的去雾能力,但是会产生灰色斑驳的伪影,如图5 DCPDN第一行中的墙壁部分。EPDN去雾方法与Cycle-Dehaze方法的去雾效果相当,然而EPDN去雾方法在达到去雾效果的同时,具有更强的色彩恢复能力。FD-GAN去雾方法表现出较好的去雾效果,然而在细节处理上略有不足。DA-Dehaze方法恢复的图片整体色调偏暗沉,与原清晰图像具有一定偏差,如图5 DA-Dehaze中红色框区域。

除了在合成数据上展示可视化结果,本文也在真实有雾数据集URHI上展示所有去雾算法可视化结果,如图6所示。由图6 DCP可以看出,DCP去雾方法对夜景图像的处理存在大量曝光问题,并会产生大量伪影。Dehaze-Net去雾方法恢复的图像在天空区域出现色彩失真现象,并且去雾后有少量雾残留。AOD-Net去雾方




图4 RESIDE室外合成测试集上可视化实验结果

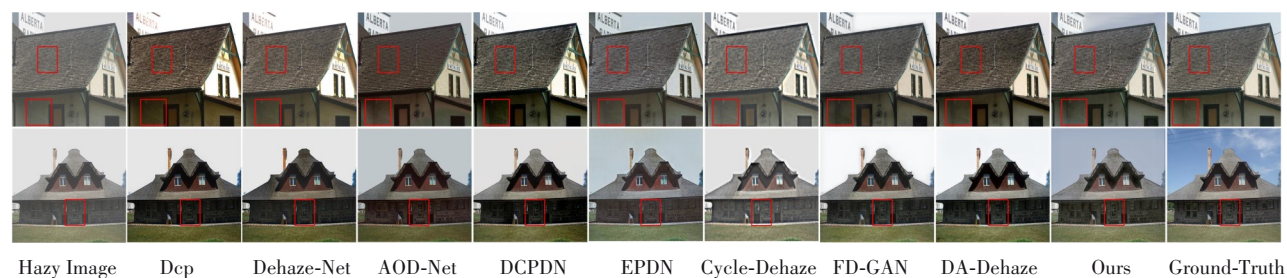


图5 HazeRD室外合成数据集上可视化实验结果

法去雾后的图像整体色调偏暗. DCPDN 去雾方法可以去除图像中大部分的雾,但其处理后的图像也会有少量雾残留. EPDN 去雾方法也可以去除图像中大部分的雾,但是其恢复的图像偏暗,并且和真实有雾图像之间存在色差,如图6 EPDN 第一行中的红色框区域. Cycle-Dehaze 去雾方法去雾后的图像存在细节模糊问题. FD-GAN 去雾方法取得了较好的去雾效果,但是该方法在图像的部分区域会产生噪声以及存在色彩失真问题,如图6 FD-GAN 第五行中的黑点,第六和第八行图像色彩失真. DA-Dehaze 去雾方法能够较好的恢复图像,并且在夜景图像同样取得了较好的视觉效果,但是该方法在细节信息处理上不够理想,如图6 DA-Dehaze 第二行中的天空以及第七行中的字体. 由图6 Ours 可以看出,本文提出的方法可以有效去雾的同时,保留了更多的细节特征,特别是在夜景图像中处理的结果相比其他方法更为出色,同时不可否认的是,本文的去雾方法

在浓雾区域的去雾效果仍有提升空间.

最后,本文在 OHaze 室外真实数据集上也验证了各种算法的去雾效果. 如图7所示,DCP 去雾方法在天空区域出现了曝光. Dehaze-Net 去雾方法恢复的图像有较多雾残留. AOD-Net 去雾方法处理后的图像色调偏暗,并且恢复的图像细节保持度不够,如图7 AOD-Net 第一行中的绿植. DCPDN 去雾方法恢复的图像色彩失真. EPDN 去雾方法虽然可以去除部分雾,但是恢复的图像细节模糊,如图7 EPDN 第一行中的地面区域. Cycle-Dehaze 去雾方法去雾后的图像中产生了大量的伪影,并且纹理损失严重. FD-GAN 去雾方法能够较好的恢复图像的色彩,但是依然会有少量雾残留. DA-Dehaze 去雾方法具有较好的去雾能力,但是对局部细节区域的处理不如本文所提出的去雾方法.

4.4 消融实验

为了验证提出去雾方法中各个模块的有效性,本

文按照框架创新和网络结构创新的思路设计了消融实验,共包含6个实验.实验1:Base表示相同任务生成器之间共享所有参数,包括共享Batch Normalization层,因此只有一个去雾生成器和一个恢复雾生成器.实验2:IBN(Independent Batch Normalization)表示相同任务生成器之间共享卷积层参数,而独立Batch Normalization层,因此在循环框架中有两个独立学习数据分布的去雾生成器,以及两个恢复雾生成器.实验

3:IBN2D(Independent Batch Normalization and 2 Discriminator)表示在实验2的基础上加入全局局部双判别器.实验4:IBN2D_FCA(Independent Batch Normalization, 2 Discriminator and First order Channel Attention)表示在实验3的基础上加入一阶通道注意力模块.实验5:IBN2D_SCA(Independent Batch Normalization, 2 Discriminator and Second order Channel Attention)表示在实验3的基础上加入二阶通道注意力模块.实验6:




图6 URHI室外真实数据集上可视化实验结果




图7 OHaze室外真实数据集上可视化实验结果

IBN2D_MCA (Independent Batch Normalization, 2 Discriminator and Multi-order Channel Attention)表示在实验3的基础上加入多阶通道注意力模块。

消融实验是在SOTS室外数据集上进行的,不同模型的PSNR和SSIM结果如表3所示.消融实验中的Base模型在PSNR和SSIM指标上取得了25.79和0.9506的成绩,相比4.2节中继承CycleGAN生成器结构,采用拉普拉斯算子处理不同输入分辨率的Cycle-Dehaze去雾算法有明显的进步,这主要是因为本文将图像去雾看成两种数据分布之间的迁移问题,采用Batch Normalization对生成器网络模型中的数据分布进行归一化、生成器的编解码网络结构以及处理不同分辨率的方式等方面的差异造成.采用IBN模型相比Base模型,PSNR

表3 在SOTS室外数据集上的PSNR和SSIM结果

Model	PSNR/dB	SSIM
Base	25.79	0.9506
IBN	26.53	0.9618
IBN2D	26.73	0.9619
IBN2D_FCA	26.76	0.9621
IBN2D_SCA	26.85	0.9624
IBN2D_MCA	27.17	0.9627

提升了0.74 dB,从而验证异构框架的有效性.如图8所示的损失函数收敛曲线,IBN模型生成器收敛的效果更好.此外,使用本文提出的双判别器异构CycleGAN框

架相较Base模型提高了0.94 dB.通过观察消融实验最后三个模型,可以发现在生成器网络中加上一阶注意力、二阶注意力和多阶注意力PSNR和SSIM指标在逐步提升,并且多阶注意力模块提升最大,相比IBN2D模型PSNR提升了0.44 dB,SSIM也有一定的提升.最终本文设计的基于双判别器异构CycleGAN框架和多阶通道模块,相比Base模型在PSNR指标上提升1.38 dB,在SSIM指标上提升0.0121.

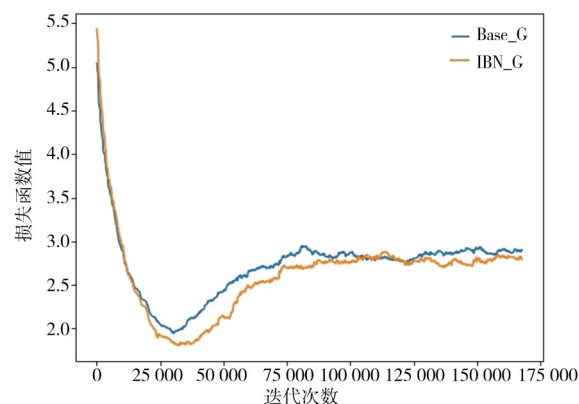


图8 Base模型生成器和IBN模型生成器收敛曲线图

图9展示了双判别器异构框架和多阶注意力消融实验可视化结果,如图9第一行中的红色框区域,IBN2D模型能够完成有效的去雾,但是恢复出的图像




图9 双判别器异构框架和多阶注意力消融实验可视化结果

在地面区域偏暗,增加了多阶注意力模型的 IBN2D_MCA 模型去雾后可视化结果图更接近清晰图像. 在图 9 的第二行,如红色框区域所示,IBN2D_MCA 模型去雾后的图像,在去雾效果和对比度上相比 IBN2D 模型取得了更好的视觉效果. 在图 9 的第三行红色框中树叶细节信息方面,加上了多阶通道注意力的 IBN2D_MCA 模型,取得更接近清晰图像的视觉结果.

图 10 展示了一阶、二阶以及多阶通道注意力消融实验可视化结果. 如图 10 第一行红色框包含的城墙区

域所示,多阶注意力的 IBN2D_MCA 模型恢复的图像在颜色上最接近清晰图像,二阶注意力的 IBN2D_SCA 模型相比一阶注意力 IBN2D_FCA 模型,颜色恢复相对更好. 如图 10 第二行图像的两个红色框区域中,一阶、二阶以及多阶通道注意力模型在行人衣服和指示牌上的去雾效果逐渐提升. 图 10 第二行图像的两个红色框区域中,不仅去雾效果逐渐提升,多阶注意力 IBN2D_MCA 模型在对比度和颜色上视觉效果与清晰图像最接近.



图 10 一阶、二阶以及多阶通道注意力消融实验可视化结果

5 结论

本文提出了一种基于双判别器异构 CycleGAN 框架下多阶通道注意力校准的室外图像去雾网络,主要包含双判别器异构 CycleGAN 框架和多阶通道注意力模块. 该框架使具有相同任务的生成器能够独立学习拥有不同分布的数据,同时增加了对局部区域的关注. 多阶通道注意力模块探索了有效的特征通道信息,从而提升去雾图像质量. 与现有 8 种优秀的去雾方法相比,本文去雾方法在合成数据集和真实数据集中均取得了最佳性能. 不可否认的是,本文去雾方法在浓雾和远景雾图像的去雾能力上仍有一定的提升空间. 未来,将重点研究浓雾和远景雾的图像去雾和恢复.

参考文献

[1] XIONG Y Y, LIU H X, GUPTA S, et al. MobileDets:

searching for object detection architectures for mobile accelerators[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2021: 3824-3833.

[2] GUO J Z, ZHU X Y, YANG Y, et al. Towards fast, accurate and stable 3D dense face alignment[C]//Computer Vision-ECCV 2020. Cham: Springer International Publishing, 2020: 152-168.

[3] LI C S, LIU C, DUAN L X, et al. Reconstruction regularized deep metric learning for multi-label image classification[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(7): 2294-2303.

[4] 孙航, 李晶, 杜博, 等. 基于多阶段学习的相关滤波目标跟踪[J]. 电子学报, 2017, 45(10): 2337-2342.

SUN H, LI J, DU B, et al. Correlation filtering target tracking based on online multi-lifespan learning[J]. Acta Electronica Sinica, 2017, 45(10): 2337-2342. (in Chinese)

- [5] CANTOR A. Optics of the atmosphere: Scattering by molecules and particles[J]. *IEEE Journal of Quantum Electronics*, 1978, 14(9): 698-699.
- [6] HE K M, SUN J, TANG X O. Single image haze removal using dark channel prior[C]//2009 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2009: 1956-1963.
- [7] BERMAN D, TREIBITZ T, AVIDAN S. Non-local image dehazing[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2016: 1674-1682.
- [8] ZHU Q S, MAI J M, SHAO L. Single image dehazing using color attenuation prior[C]//2014 British Machine Vision Conference. Nottingham: BMVA Press, 2014: 2179-2183.
- [9] 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.
- [10] ZHANG H, PATEL V M. Densely connected pyramid dehazing network[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 3194-3203.
- [11] TANG K T, YANG J C, WANG J. Investigating haze-relevant features in a learning framework for image dehazing [C]//2014 IEEE Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2014: 2995-3002.
- [12] 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). Piscataway: IEEE, 2017: 4780-4788.
- [13] DONG Y, LIU Y H, ZHANG H, et al. FD-GAN: Generative adversarial networks with fusion-discriminator for single image dehazing[J]. *Proceedings of the AAAI Conference on Artificial Intelligence*, 2020, 34(7): 10729-10736.
- [14] LI R D, PAN J S, HE M, et al. Task-oriented network for image dehazing[J]. *IEEE Transactions on Image Processing*, 2020, 29: 6523-6534.
- [15] QU Y Y, CHEN Y Z, HUANG J Y, et al. Enhanced Pix2pix dehazing network[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2020: 8152-8160.
- [16] ENGIN D, GENÇ A, EKENEL H K. Cycle-dehaze: Enhanced cyclegan for single image dehazing[C]//2018 IEEE Conference on Computer Vision and Pattern Recognition Workshop. Salt Lake City: IEEE, 2018: 825-833.
- [17] 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). Piscataway: IEEE, 2020: 2805-2814.
- [18] LIU W, HOU X X, DUAN J, et al. End-to-end single image fog removal using enhanced cycle consistent adversarial networks[J]. *IEEE Transactions on Image Processing*, 2020, 29: 7819-7833.
- [19] GOODFELLOW I, POUGET-ABADIE J, MIRZA M, et al. Generative adversarial networks[J]. *Communications of the ACM*, 2020, 63(11): 139-144.
- [20] WANG X, YU K, WU S, et al. ESRGAN: Enhanced super-resolution generative adversarial networks[C]//2018 European Conference on Computer Vision Workshops. Munich: Springer, 2018: 63-79.
- [21] NI Z K, YANG W H, WANG S Q, et al. Towards unsupervised deep image enhancement with generative adversarial network[J]. *IEEE Transactions on Image Processing*, 2020, 29: 9140-9151.
- [22] 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). Piscataway: IEEE, 2017: 2242-2251.
- [23] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation [C]//2015 International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich: Springer, 2015: 234-241.
- [24] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 7132-7141.
- [25] LI P H, XIE J T, WANG Q L, et al. Is second-order information helpful for large-scale visual recognition? [C]//2017 IEEE International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2017: 2089-2097.
- [26] LI P H, XIE J T, WANG Q L, et al. Towards faster training of global covariance pooling networks by iterative matrix square root normalization[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway: IEEE, 2018: 947-955.
- [27] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[EB/OL]. (2014-09-04) [2021-09-01]. <https://arxiv.org/abs/1409.1556>.

- [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] ZHANG Y F, DING L, SHARMA G. HazeRD: An outdoor scene dataset and benchmark for single image dehazing[C]//2017 IEEE International Conference on Image Processing (ICIP). Piscataway: IEEE, 2018: 3205-3209.
- [30] ANCUTI C O, ANCUTI C, TIMOFTE R, et al. OHAZE: A dehazing benchmark with real hazy and haze-free outdoor images[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW). Piscataway: IEEE, 2018: 754-762.

作者简介

但志平 男, 1976年3月出生于湖北省咸宁市. 现为三峡大学教授, 硕士生导师. 主要研究方向为计算机视觉、模式识别.

E-mail: zp_dan@ctgu.edu.cn

方帅领 男, 1996年1月出生于河南省商丘市. 现为三峡大学硕士研究生. 主要研究方向为计算机视觉、图像去雾.

E-mail: fslev_110@163.com

孙航(通讯作者) 男, 1986年4月出生于湖北省武汉市. 现为三峡大学校聘副教授, 硕士生导师. 主要研究方向为水下图像修复.

E-mail: sunhang0418@whu.edu.cn