

引用格式:付星堡,蔡琼,陈国清,等.改进 CycleGAN 的图像去雾网络[J].微电子学与计算机,2021,38(8):87-92. [FU X B, CAI Q, CHEN G Q, et al. Image dehazing network based on improved CycleGAN[J]. Microelectronics & Computer, 2021, 38(8):87-92.]

改进 CycleGAN 的图像去雾网络

付星堡¹,蔡 琼^{1,2},陈国清¹,赖远哲¹,陈 玉¹

(1 武汉工程大学 计算机科学与工程学院,湖北 武汉 430205;

2 武汉工程大学 智能机器人湖北省重点实验室,湖北 武汉 430205)

摘 要:针对传统 CycleGAN 在图像去雾后出现模糊和颜色失真等问题,给出了一种改进 CycleGAN 的图像去雾网络.所提 CycleGAN 的生成器包括特征提取、特征融合和图像复原三个子网络.图像特征提取子网络用于提取图像的内容特征和风格特征,特征融合子网络利用两种不同的注意力机制分别对提取到的内容特征和风格特征进行融合,图像复原子网络将融合后的图像特征还原成无雾图像.与传统的 CycleGAN 和已有的去雾网络相比,所提网络对合成图像和真实图像均可取得理想的去雾结果,有效解决了传统 CycleGAN 在图像去雾后出现的模糊和颜色失真的问题.

关键词:图像去雾;CycleGAN;特征提取;特征融合;注意力机制;图像复原

中图分类号: TP183

文献标识码: A

文章编号: 1000-7180(2021)08-0087-08

Image dehazing network based on improved CycleGAN

FU Xingbao¹, CAI Qiong^{1,2}, CHEN Guoqing¹, LAI Yuanzhe¹, CHEN Yu¹

(1 School of Computer Science and Engineering, Wuhan Institute of Technology, Wuhan 430205, Hubei, China;

2 Hubei Key Laboratory of Intelligent Robot, Wuhan Institute of Technology, Wuhan 430205, Hubei, China)

Abstract: In view of the blur and color distortion in traditional CycleGAN image dehazing, an improved CycleGAN image dehazing network is proposed. The generator of present CycleGAN consists three parts: feature extraction sub-network, feature fusion sub-network and image restoration sub-network. The image feature extraction sub-network is used to extract the content features and style features of the image. The feature fusion sub-network uses two different attention mechanisms to fuse the extracted content features and style features. The image complex atom network restores the fused image features to a haze free image. Compared with traditional CycleGAN and existing defogging networks, the proposed network can achieve ideal dehazing results for both synthetic images and real images, and effectively solves the problems of blurring and color distortion in traditional CycleGAN images after dehazing.

Key words: Image dehazing; CycleGAN; Feature extraction; Feature fusion; Content-maintaining; Image restoration

1 引 言

雾天天气极大地降低了摄像机和照相机等图像传感器所采集视频和图像的能见度和对比度,严重

影响视觉效果.同时也不利于图像特征的提取和分类,对目标的识别和跟踪、交通监控以及智能导航等计算机视觉系统的使用带来障碍和挑战.因此图像去雾具有重要的研究意义^[1].

图像去雾的方法可以分为基于图像增强的方法、基于大气散射模型的图像复原方法以及基于深度学习的方法^[2]. 基于图像增强的方法不考虑图像降质的原因,通过提高图像的对比度进行去雾,易实现但会出现图像失真. 常用的算法有直方图均衡化^[3]、Retinex 算法^[4]及小波变^[5]等. 基于大气散射模型的图像复原方法主要是通过构建大气散射模型来预测大气光之,利用先验信息来实现除雾目的,但由于先验信息不具有普遍适用性,容易出现去雾不彻底和颜色失真的情况. 常用的算法有基于暗通道先验原理去雾算法(DCP)^[6]、双边滤波暗原色透射率细化算法^[7]和颜色衰减先验理论^[8]等. 基于机器学习的去雾算法通过构建端到端的卷积神经网络(Convolutional Neural Network, CNN)来实现图像去雾. 常用的神经网络有 AOD-Net(All in One Dehazing Network)^[9]、DehazeNet^[10]、FFA-Net^[11]以及 Cycle-Dehaze^[12]等. 以上神经网络除了 Cycle-Dehaze 都需要大量成对的数据集进行训练,间接地增加了神经网络训练的难度. Cycle-Dehaze 虽然不需要进行数据配对,但去雾后的图片比较模糊,且出现了颜色失真的情况.

基于上述分析,本文提出了一种改进的 CycleGAN^[13]来实现端到端的图像去雾. 将基于多个级联的残差块^[14]和残差密集块^[15]设计的内容提取模块和风格提取模块融入到 CycleGAN 中以提高 CycleGAN 的特征提取能力. 另外,分别采用 CBAM(Convolutional Block Attention Module)^[16]和 CAM 注意力模块^[17]分别对提取到的内容特征图和风格特征图进行加权融合. 最后,将融合的特征图通过上采样层和反卷积层得到去雾图像. 为了提高输出图像的质量,本文采用拉普拉斯金字塔(Laplacian Pyramid)重建去雾图像. 本文所提的去雾方法能够得到比较清晰的去雾图像,且无颜色失真的情况.

2 传统 CycleGAN 算法回顾

生成式对抗网络 GAN 是 CycleGAN 的基础, GAN 由一个生成器 G 和一个鉴别器 D 构成,生成器 G 的目的是学习真实图像域的数据分布,鉴别器 D 的作用是区分真实图像和生成的图像. 在 GAN 网络训练的过程中, G 根据 D 的判断标准逐渐提高生成图像数据的能力, D 根据 G 生成的图像逐渐提高数据鉴别能力, G 和 D 在对抗博弈中达到平衡. G 和 D 的对抗关系如式(1)所示.

$$\min_D \max_G V(G, D) = E_{x \sim P_{\text{data}}(x)} [\log D(x)] + E_{z \sim P_z(z)} [\log(1 - D(G(z)))] \quad (1)$$

式中, x 表示真实的图像数据; z 为生成器 G 的输入数据; $P_{\text{data}}(x)$ 为真实数据分布; $P_z(z)$ 为输入生成器 G 的噪声分布; $\sim$ 为服从关系; E 为数学期望.

为了使网络能够使用不成对的数据集进行训练, CycleGAN 利用两个生成器和两个鉴别器来完成源域 A 到目标域 B 的相互映射. 设 $A \rightarrow B$ 的映射为 $G_{A \rightarrow B}$, B 到 A 的映射 $F_{B \rightarrow A}$, 鉴别器 D_A 用于判断 $F_{B \rightarrow A}$ 生成的图片是否为真实图片, 鉴别器 D_B 用于鉴别生成器 $G_{A \rightarrow B}$ 生成的图片是否为真实图片. 生成器 $G_{A \rightarrow B}$ 和鉴别器 D_B 之间的损失函数 L 如式(2)所示.

$$L_{\text{GAN}}(G_{A \rightarrow B}, D_B) = E_{b \sim P_{\text{data}}(b)} [\log D_B(b)] + E_{a \sim P_{\text{data}}(a)} [\log(1 - D_B(G_{A \rightarrow B}(a)))] \quad (2)$$

式中, $\sim$, P_{data} 和 E 的定义与式(1)相同; a 表示源域图像样本; b 表示目标域图像样本. 生成器 $F_{B \rightarrow A}$ 和鉴别器 D_A 之间的损失函数 L 与式(2)类似, 如式(3)所示.

$$L_{\text{GAN}}(F_{B \rightarrow A}, D_A) = E_{a \sim P_{\text{data}}(a)} [\log D_A(a)] + E_{b \sim P_{\text{data}}(b)} [\log(1 - D_A(F_{B \rightarrow A}(b)))] \quad (3)$$

CycleGAN 还通过引入循环一致性损失函数 Cycle Consistency Loss(CCL) 来解决上述两个生成器在进行对抗训练时出现的模式退化问题. CCL 能够使网络同时学习 $G_{A \rightarrow B}$ 和 $F_{B \rightarrow A}$ 两个映射, 避免 A 中所有图像都映射为 B 中某个图像的可能性, 循环一致性损失函数的训练过程如图 2 所示.




图 1 CycleGAN 的前向一致性和后向一致性

图 2 表示了 CycleGAN 训练时的前向一致性和后向一致性, 这也是 CycleGAN 的核心所在. 由图可以看出 $G_{A \rightarrow B}(F_{B \rightarrow A}(b)) \approx b$, $F_{B \rightarrow A}(G_{A \rightarrow B}(a)) \approx a$, 因此, 循环一致性损失 L_{CCL} 如式(4)所示:

$$L_{\text{CCL}}(G_{A \rightarrow B}, F_{B \rightarrow A}) = E_{a \sim P_{\text{data}}(a)} [\|F_{B \rightarrow A}(G_{A \rightarrow B}(a)) - a\|_1] + E_{b \sim P_{\text{data}}(b)} [\|G_{A \rightarrow B}(F_{B \rightarrow A}(b)) - b\|_1] \quad (4)$$

最终由式(2)、式(3)、式(4)得到 CycleGAN 的损失函数 L , 如式(5)所示:

$$L(G_{A \rightarrow B}, F_{B \rightarrow A}) = L_{\text{GAN}}(G_{A \rightarrow B}, D_B) +$$

$$L_{\text{GAN}}(F_{B \rightarrow A}, D_A) + \lambda_{\text{CCL}} L_{\text{CCL}} \tag{5}$$

式中, λ_{CCL} 为损失 L_{CCL} 的权重.

3 本文方法

针对传统 CycleGAN 网络在图像去雾时出现的模糊和严重的颜色失真问题,本文对 CycleGAN 的生成器进行了改进,将基于 CNN 设计的特征提取模块融入到传统的 CycleGAN 中,并且利用 CBAM 和 CAM 注意力模块分别对提取到的特征进行加权融合,最后经图像复原子网络得到去雾后的图像.改进后的 CycleGAN 可以在图像去雾的同时较好地保持图像的色彩,克服了传统 CycleGAN 去雾后颜色失真的问题.改进后 CycleGAN 生成器的整体结构如图 2 所示.




图 2 改进后 CycleGAN 的生成器结构图

3.1 特征提取网络

3.1.1 内容特征提取模块

图像的内容特征主要包括图像中物体的形状、轮廓以及物体的空间关系,其中前两个属于图像的全局特征,最后一个属于图像的局部特征.因此,有

效提取图像的局部特征和全局特征对于图像去雾尤为重要.

本文利用多个级联的残差块构建较深的网络来提取图像的内容特征.本文的特征提取模块共 24 层,包括 3 个卷积层和 7 个级联的残差块(RB1-RB7).其中,前 3 个卷积层的卷积核大小分别为 $7 \times 7 \times 64$ 、 $3 \times 3 \times 128$ 、 $3 \times 3 \times 512$,步长分别 1、2、2. 7×7 的卷积核可以扩大感受野,使网络可以获取更多的图像信息.后面两个可以有效降低特征图的尺寸,有益于网络的训练.此外,经实验可得,采用 7 个级联的残差块时效果最好,每个残差块都含有 3 个卷积核大小为 $3 \times 3 \times 64$ 的卷积层,步长均为 1,每个卷积层都是用 ReLU 作为激活函数,残差块的结构如图 3 所示.




图 3 残差块结构图

从图中可以看出,级联的残差块通过跳转链接的方式将信息传递到网络的更深层,可以在不增加计算复杂度的情况下有效解决深层网络梯度消失的问题.本文将残差块 RB3、RB5 和 RB7 输出的特征进行堆叠作为图像的内容特征,从而保证了图像内容特征的完整性.

3.1.2 风格特征提取模块

图像的风格特征是一种全局特征,描述了图像或图像区域所对应的景物的表面性质.为了使有雾图像能够更好地转换成去雾图像,需要准确地提取图像的风格特征.

本文使用多个级联的残差密集块来提取图像的风格特征,不仅充分利用了不同感受野下提取的特征,而且可以解决由网络过深导致的梯度消失问题.为了充分提取图像的全局特征,本文将原图片的尺寸减小为原来的一半后直接输入到风格特征提取模块进行风格特征的提取.该模块包含一个卷积层和 3 个级联的残差密集块(DRB1-DRB3),其中卷积层的卷积核大小为 $3 \times 3 \times 64$,步长为 2.由图 4 可以看出,每个残差密集块包含 4 个卷积层,每个卷积层的卷积核均为 $3 \times 3 \times 64$,步长均为 1,该模块每个卷积层后的激活函数均为 ReLU 函数,残差密集块的结构

如图 4 所示。




图 4 密集残差块结构图

从图中可以看出,残差密集块可以充分利用输入图像的所有分层特征,并且其中的残差结构也有益于网络收敛。

3.2 特征融合网络

3.2.1 内容特征加权模块

本文使用卷积模块的注意力模块 (Convolutional Block Attention Module, CBAM) 对图像的内容特征进行加权以实现网络对主要内容特征的学习,其结构如图 5 所示。




图 5 CBAM 结构图

从图中可以看出,CBAM 对特征图加权的方式可分为两部. 第一步加权的具体方式为: 输入的特征图首先分别通过平均池化层和最大池化层得到两组大小为 1×1 的特征图, 然后每组特征图各自通过两个卷积核大小为 1×1 的卷积层后求和得到第一步的权重, 将得到的权重与输入的特征图进行乘法运算即可得到基于通道加权的特征图. 第二步加权的具体方式为: 将输入的特征图在通道上分别求平均值和最大值, 从而得到两张特征图, 将这两张特征图堆叠后经过一个卷积核的大小为 $1 \times 1 \times 1$ 的卷积层即可得到第二步的权重, 将得到的权重与输入的特征图进行乘法运算从而得到基于像素加权的特征图. CBAM 的加权

方式可以突出图像内容特征的主要部分, 提高网络的内容保持能力.

3.2.2 风格特征加权模块

本文使用 CAM 注意力模块对图像的风格特征进行加权以提高网络对于不同风格特征的辨别能力, 其结构如图 6 所示。




图 6 CAM 注意力模块结构图

从图中可以看出, 输入的特征图首先分别通过一个全局平均池化层和一个全局最大池化层得到两个特征向量, 然后将这两个特征向量分别送入两个大小为 1 的全连接层进行压缩, 将这两个压缩的特征向量进行堆叠后利用 Sigmoid 函数进行二分类, 最后将两个全连接层中可训练的权重 Weight1、Weight2 分别与输入的特征图相乘, 进行堆叠后即可得到加权后的特征图. CAM 注意力模块可以使网络更容易地注意到有雾图像和无雾图像在风格特征上的不同部分, 加强网络对有雾图像风格特征的转换, 提高网络的去雾能力.

3.2.3 特征融合模块

为了充分融合加权后的内容特征和风格特征, 本文将加权后的内容特征和风格特征进行堆叠, 然后利用一个卷积核大小为 $1 \times 1 \times 128$ 、步长为 1 的卷积层进行降维. 融合后的特征图包含了完整的图像特征, 同时也减少了计算量.

3.3 图像复原

最后, 对融合后的特征图进行非线性映射, 如图 1 中图像复原模块所示. 其包含 2 个上采样层和 2 个反卷积层, 反卷积层卷积核的大小均为 1×1 , 步长均为 1, padding 均设置为 0, 该模块最终可得到与输入的图像具有相同尺寸的去雾图.

4 改进后的 CycleGAN 网络及图像增强方法

本文采用基于 CNN 设计的内容特征提取模块和风格特征提取模块对传统 CycleGAN 的生成器进行改进,并且利用 CBMA 和 CAM 注意力模块对提取到的内容特征和风格特征进行加权,使改进后的 CycleGAN 在保留有雾图像中的内容特征基础上将有雾图像转换成无雾图像.为了使去雾图像中保留更多的图像细节,本文利用图像通过 VGG-16 的 block2_conv2 层和 block5_conv3 层的输出来计算感知损失(Perceived Losses, PL),改进后的 CycleGAN 的整体结构如图 7 所示.




图 7 改进后 CycleGAN 的整体结构图

从图 7 可以看出,改进后的 CycleGAN 在传统 CycleGAN 损失函数的基础上引入了 CAM 注意力模块中的分类损失和感知损失.其中,CAM 注意力模块中的分类部分采用交叉熵损失函数,使源域和目标域尽可能地分开,损失函数如式(6)所示:

$$L_{\text{class}}(G_{A \rightarrow B}, F_{A \rightarrow B}) = - (E_{x \sim P_{\text{data}} \langle a \rangle} [\log(\eta_A(x))] + E_{x \sim P_{\text{data}} \langle b \rangle} [\log(1 - \eta_A(x))] - (E_{x \sim P_{\text{data}} \langle b \rangle} [\log(\eta_B(x))] + E_{x \sim P_{\text{data}} \langle a \rangle} [\log(1 - \eta_B(x))]) \quad (6)$$

式中, $\sim$, P_{data} 和 E 的定义与式(1)相同; $x \in \{A, B\}$; $\eta_A(x)$ 、 $\eta_B(x)$ 分别为 $x \in A$ 和 $x \in B$ 的概率.为了减少内容特征的丢失,本文利用 VGG-16 提取图像特征计算感知损失,损失函数如式(7)所示:

$$L_{\text{PL}}(G_{A \rightarrow B}, F_{A \rightarrow B}) = \frac{1}{DHW} [\|\varphi(G_{A \rightarrow B}(a)) - \varphi(a)\|_2^2 + \|\varphi(F_{B \rightarrow A}(b)) - \varphi(b)\|_2^2] \quad (7)$$

式中, $\sim$ 和 P_{data} 的定义与式(6)相同; φ 为特征提取

函数; D 、 H 和 W 分别表示特征的深度、宽度和高度.最终由式(2)、式(3)、式(4)、式(6)、式(7) 得出改进后 CycleGAN 的损失函数 L_{full} , 如式(8) 所示:

$$L_{\text{full}}(G_{A \rightarrow B}, F_{A \rightarrow B}) = L_{\text{GAN}}(G_{A \rightarrow B}, D_B) + L_{\text{GAN}}(F_{B \rightarrow A}, D_A) + \lambda_{\text{CCL}} L_{\text{CCL}} + \lambda_{\text{Class}} L_{\text{Class}} + \lambda_{\text{PL}} L_{\text{PL}} \quad (8)$$

式中, λ_{CCL} 、 λ_{Class} 、 λ_{PL} 分别为损失 L_{CCL} 、 L_{Class} 以及 L_{PL} 的权重.

为了增强去雾图像的图像细节,本文使用拉普拉斯金字塔(Laplacian Pyramid)重建去雾图像.具体的,使用有雾图像创建拉普拉斯金字塔,然后将拉普拉斯金字塔的顶端用对应的低分辨率无雾图像代替,对低分辨率的有雾图像进行高斯上采样,且每一次上采样后都加上拉普拉斯金字塔中对应层的残差,直到去雾图像恢复到原来的大小.拉普拉斯金字塔的使用能够有效地保留原始图像中物体的边缘信息,使去雾图像在细节上具有更好的表现.

5 实验与分析

5.1 实验方法与数据集

本程序采用 Python 语言编写,基于 Google 开源机器学习框架 Tensorflow,实验环境搭建于 Google Colaboratory,其平台配有 Tesla K80 GPU,且绑定了一个 Ubuntu 虚拟机(40 GB 硬盘+2 * 2.30 GHZ CPU+12.72 GB 内存).初始学习率设置为 0.000 1, batchsize 设置为 1,权重因子 λ_{CCL} 、 λ_{Class} 、 λ_{PL} 分别设置为 10、100 0、0.000 1,采用动量衰减指数 $\beta_1=0.5$ 、 $\beta_2=0.999$ 的 Adam 优化器进行优化,迭代次数为 10 000 次.

采用数据集 RESIDE 中的 ITS(indoor training set)数据集、OTS(outdoor training set)数据集、SOTS(Synthetic Objective Testing Set)数据集和 URHI(Unannotated Real-world Hazy Images)数据集.其中,选取 ITS 为室内图像训练集,共包含 8477 张清晰图像和 13990 张有雾图像;OTS 数据集共包含 2 061 张室外清晰图像和 296695 张室外有雾图像,选取其中 2061 张室外清晰图像以及 72135 张室外有雾图像作为室外图像的训练集;SOTS 为合成图像测试集,包含 500 张室内有雾图像和 500 张室外有雾图像;由于 SOTS 与训练集 ITS 和 OTS 来自同一数据分布,本文从数据集 MSD(Middlebury Stereo Datasets)中选取色彩较为丰富的图像,然后利用大气散射模型合成有雾图像来验证本文方法的

鲁棒性和去雾网络的色彩保持性能. 本文选择与目前的优势去雾方法进行对比实验, 包括经典去雾方法 DCP^[6] 以及近期基于深度学习的去雾方法: AOD-Net^[10]、DehazeNet^[11]、FFA-Net^[12]、Cycle-Dehaze^[14].


5.2 图像增强实验

为了验证本文图像增强方法的有效性和拉普拉斯金字塔的深度对重建后图像质量的影响, 本文分别构建了多个不同层数的拉普拉斯金字塔进行图像重建实验, 得到的 PSNR 和 SSIM 结果如表 1 所示.

表 1 图像增强实验结果质量评估

图像增强方法	PSNR/DB	SSIM
原始去雾图	20.09	0.827 3
1 层拉普拉斯金字塔	21.83	0.899 9
2 层拉普拉斯金字塔	20.85	0.882 7
3 层拉普拉斯金字塔	20.40	0.877 9
4 层拉普拉斯金字塔	19.76	0.876 3
5 层拉普拉斯金字塔	19.02	0.871 9

从表 1 可以看出利用有雾图像构建 1 层拉普拉斯金字塔重建去雾图像提高了原始去雾图像的 PSNR 和 SSIM 指标, 但随着拉普拉斯金字塔层数的增加重建图像的 PSNR 和 SSIM 指标也随之下降. 另外从 OTS 选取一张图片进行主观质量评价, 实验结果如图 8 所示.



(a) 有雾图; (b) 去雾图; (c) 1 层拉普拉斯金字塔重建; (d) 2 层拉普拉斯金字塔重建; (e) 3 层拉普拉斯金字塔重建; (f) 4 层拉普拉斯金字塔重建; (g) 5 层拉普拉斯金字塔重建; (h) 清晰图像

图 8 图像重建实验结果比较

从图 8 中的红框部分可以看出, 利用有雾图像构建拉普拉斯金字塔重建图像可以增强图像细节, 如图 8(b) 中和图 8(c)、8(d)、8(e)、8(f)、8(g) 中的红框部分的小车轮廓越来越清晰, 但随着拉普拉


斯金字塔的加深重建图像的雾化越来越严重, 这也是利用深层拉普拉斯金字塔重建图像后图像 PSNR 和 SSIM 指标下降的原因.

5.3 特征消融实验

为了验证本文提出的去雾网络中特征融合模块的有效性, 本文进行了特征消融实验, 共包含以下四个实验: (1) 将提取的风格特征和进行了 CBAM 加权的内容特征和风格特征堆叠融合 (Fusion of CBAM weighted content feature and style feature, WCF-SF); (2) 将提取的内容特征和进行了 CAM 注意力机制加权的风格特征堆叠融合 (Fusion of content feature and CAM attention module weighted style feature, CF-WSF); (3) 直接将提取到的内容特征和风格特征进行堆叠融合 (Fusion of content feature and style feature, CF-SF); (4) 将行了 CBAM 加权的内容特征和进行了 CAM 注意力机制加权的风格特征堆叠融合 (Fusion of CBAM weighted content feature and CAM attention module weighted style feature, WCF-WSF). 本文在 OTS 数据集上对以上四个实验得到的结果进行了质量评价, 其 PSNR 和 SSIM 结果如表 2 所示, 去雾的结果对比如图 9 所示.

表 2 特征融合实验结果质量评估

特征融合方法	PSNR/DB	SSIM
WCF-SF	20.09	0.827 3
CF-WSF	20.63	0.899 9
CF-SF	20.35	0.882 7
WCF-WSF	21.83	0.877 9



(a) 有雾图; (b) WCF-SF; (c) CF-WSF; (d) CF-SF; (e) WCF-WSF; (f) 清晰图像

图 9 特征融合实验结果比较

从表 2 可以看出, WCF-WSF 去雾网络恢复的无雾图像质量最高. 此外, 从图 9 中可以看出, WCF-SF 去雾网络得到的去雾图像桌面条纹细节丢

失;CF-WSF 去雾网络得到的去雾图像去雾较为彻底,但桌面颜色偏黄;CF-SF 去雾网络得到的去雾图像还有少量雾气残留,且墙壁颜色过暗;带有 WCF-WSF 的去雾网络得到的去雾图像去雾彻底,且墙壁颜色与清晰图像最为接近.

5.4 在合成数据集上的实验


为了测试本文去雾网络在合成数据集上的去雾性能,采用 SOTS 作为测试数据集进行对比试验,采用 PSNR 和 SSIM 对去雾算法所恢复的图像进行质量评价. 本文的去雾方法得到去雾图片的 PSNR 和 SSIM 指标优于 DCP、DehazeNet、AOD-Net 和 Cycle-Dehaze 方法. 此外,由于 FFA-Net 的网络层数较深,从而导致该方法在 SOTS 数据集上的拟合能力较强,但其对于利用 MSD 数据集中的图像制作的有雾图去雾效果欠佳.

5.5 在真实数据集上的实验

进一步,为了测试本文方法在真实有雾图上的去雾性能,本节选取了 4 幅真实有雾图进行对比试验,去雾结果如图 10 所示. 从图中可以看出,DCP 去雾图像出现了色彩分布不均的情况,如图 10(b)中第一幅图女孩的脸颊上出现了明显的红色的斑块;DehazeNet 网络对于图像中的远景去雾能力较弱,如图 10(c)中第二幅图中远处的山丘仍含有雾气;FFA-Net 网络去除背景雾气的的能力较弱,如图 10(e)中第一幅图中女孩的背景仍含有雾气;AOD-Net 网络虽然能够除去部分雾气,但恢复的无雾图像存在细节丢失的情况,如图 10(d)中第三幅图的山区颜色过暗导致无法观察到山的轮廓;Cycle-Dehaze 方法由于着重于提取图像的内容特征,导致恢复的无雾图像较为模糊且颜色偏灰. 由图 10(g)中可以看出,本文方法恢复的无雾图像色彩鲜艳且细节保持良好,有效解决了原 CycleGAN 去雾后出现的模糊细节丢失的问题.

6 结束语

本文提出了一种基于图像内容、风格特征提取和特征融合的 CycleGAN 去雾网络. 利用级联的残差块和级联的残差密集块改进 CycleGAN 的编码器部分,并利用 CBMA 和 CAM 注意力模块对提取到的特征进行加权融合,解决了传统 CycleGAN 去雾图像模糊和颜色失真的问题. 最后,利用拉普拉斯金字塔重建去雾图像,提高了 Cycle GAN 去雾图像的质量.



(a) 有雾图; (b) DCP; (c) DehazeNet; (d) AOD-Net; (e) FFA-Net; (f) Cycle-Dehaze; (g) Proposed

图 10 真实有雾图实验结果(MSD)

参考文献:

[1] 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. DOI: 10.16383/j. aas. 2015. c131137.

WU D, ZHU Q S. The latest research progress of image Dehazing[J]. Acta Automatica Sinica, 2015, 41(2): 221-239. DOI: 10.16383/j. aas. 2015. c131137.

[2] TAN R T. Visibility in bad weather from a single image[C]//Proceedings of 2008 IEEE Conference on Computer Vision and Pattern Recognition. Anchorage, AK, USA: IEEE, 2008: 1-8. DOI: 10.1109/CVPR. 2008. 4587643.

[3] 雍杨, 王敬儒, 张启衡. 弱小目标低对比度图像增强算法研究[J]. 激光与红外, 2005, 35(5): 370-373. DOI:10.3969/j. issn. 1001-5078. 2005. 05. 018.

YONG Y, WANG J R, ZHANG Q H. Enhancement of low contrast image contain small target[J]. Laser & Infrared, 2005, 35(5): 370-373. DOI: 10.3969/j. issn. 1001-5078. 2005. 05. 018.

[4] WANG W C, YUAN X H, WU X J, et al. Fast image dehazing method based on linear transformation [J]. IEEE Transactions on Multimedia, 2017, 19(6): 1142-1155. DOI: 10.1109/Tmm. 2017. 2652069.

[5] 王小霞, 黄颖雯, 谭庭均, 等. 基于 Retinex 的汽车牌照图像去雾研究[J]. 内蒙古农业大学学报(自然科学版), 2018, 39(1): 64-70. DOI: 10.16853/j. cnki. 1009-3575. 2018. 01. 011.

WANG X X, HUANG Y W, TAN T J, et al. Research on automobile license images defogging based on Retinex algorithm[J]. Journal of Inner Mongolia Agricultural University(Natural Science Edition), 2018, 39(1): 64-70. DOI: 10.16853/j. cnki. 1009-3575. 2018. 01. 011.

[6] 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. DOI: 10. 1109/TPAMI. 2010. 168.
- [7] 温立民, 巨永锋, 王会峰, 等. 基于双边滤波暗原色透射率细化的图像去雾算法[J]. 测控技术, 2020, 39 (4): 62-65. DOI:10. 19708/j. ckjs. 2020. 04. 013. WEN L M, JU Y F, WANG H F, et al. Algorithm for Image fog removal of dark channel transmissivity refinement based on bilateral filtering[J]. Measurement & Control Technology, 2020, 39 (4): 62-65. DOI:10. 19708/j. ckjs. 2020. 04. 013.
- [8] 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. DOI: 10. 1109/TIP. 2015. 2446191.
- [9] LI B Y, PENG X L, WANG Z Y, et al. AOD-Net: all-in-one Dehazing network[C]//Proceedings of 2017 IEEE international conference on computer vision. Venice, Italy: IEEE, 2017: 4770-4778. DOI: 10. 1109/ICCV. 2017. 511.
- [10] 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. DOI: 10. 1109/TIP. 2016. 2598681.
- [11] QIN X, WANG Z L, BAI Y C, et al. FFA-Net: feature fusion attention network for single image Dehazing [C]//Proceedings of the 34th AAAI Conference on Artificial Intelligence, AAAI 2020, the 32nd Innovative Applications of Artificial Intelligence Conference, IAAI 2020, the 10th AAAI Symposium on Educational Advances in Artificial Intelligence. New York, NY, USA: AAAI, 2020: 11908-11915.
- [12] ZHU J Y, PARK T, ISOLA P, et al. Unpaired image-to-image translation using cycle-consistent adversarial networks[C]//Proceedings of 2017 IEEE International Conference on Computer Vision. Venice, Italy: IEEE, 2017: 2223-2232. DOI: 10. 1109/ICCV. 2017. 244.
- [13] KIM J, KIM M, KANG H, et al. U-GAT-IT: unsupervised generative attentional networks with adaptive layer-instance normalization for image-to-image translation[J]. arXiv: 1907. 10830, 2019
- [14] CHEN Y, LAI Y K, LIU Y J. CartoonGAN: generative adversarial networks for photo cartoonization [C]//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018: 9465-9474. DOI: 10. 1109/CVPR. 2018. 00986.
- [15] ZHANG Y L, TIAN Y P, KONG Y, et al. Residual dense network for image super-resolution [C]//Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018: 2472-2481. DOI: 10. 1109/CVPR. 2018. 00262.
- [16] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module[C]//Proceedings of the 15th European Conference on Computer Vision (ECCV). Munich, Germany: Springer, 2018: 3-19. DOI: 10. 1007/978-3-030-01234-2_1.
- [17] 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. DOI: 10. 1109/TIP. 2018. 2867951.

作者简介:

付星堡 男, (1996-), 硕士研究生. 研究方向为图像处理. E-mail: fxb19960829@163.com

蔡琼 女, (1961-), 硕士, 教授. 研究方向为大数据技术.

陈国清 男, (1995-), 硕士研究生. 研究方向为大数据技术.

赖远哲 男, (1996-), 硕士研究生. 研究方向为计算机视觉.

陈玉 男, (1997-), 硕士研究生. 研究方向为图像处理.