

doi: 10.11835/j.issn.1000-582X.2026.06.007

引用格式:唐剑,车文刚,高盛祥.一种改进的轻量型网络图像去雾方法[J].重庆大学学报,2026,49(6):71-81.



一种改进的轻量型网络图像去雾方法

唐剑,车文刚,高盛祥

(昆明理工大学信息工程与自动化学院,昆明 650500)

摘要:针对卷积神经网络进行图像去雾时存在模型复杂度高、参数量大的问题,提出一种轻量型卷积神经网络 LDNet(lightweight image dehazing network)进行图像去雾。首先,改进了大气散射模型的表达式,通过直接剔除雾噪声以减小中间变量估计的累计误差。其次,设计了融入注意力机制的倒残差模块 RNAM(reverse residual network module with attention mechanism),该模块能够多尺度提取图像特征,关注图像中重要的语义信息,同时解决网络参数量大、复杂度高的问题。最后,使用 L_1 平滑损失函数和 MS-SSIM 损失函数作为联合损失函数,使恢复的无雾图像与真实无雾图像之间的距离尽可能最小化。实验结果表明,所提出的算法在合成数据集上结构相似性和峰值信噪比均优于其他对比算法,在合成图像和真实场景都能取得良好的去雾效果,且该方法具有参数少、运算快的特点。

关键词:图像去雾;轻量型网络;注意力机制;倒残差网络

中图分类号:TP391

文献标志码:A

文章编号:1000-582X(2026)06-071-11

An improved lightweight network for image dehazing

TANG Jian, CHE Wengang, GAO Shengxiang

(School of Information Engineering and Automation, Kunming University of Science and Technology,
Kunming 650500, P. R. China)

Abstract: To address the issues of high computational complexity and large parameter size in convolutional neural network (CNN)-based image dehazing, this study proposes a lightweight dehazing network (LDNet). First, the atmospheric scattering model is reformulated to directly suppress haze noise, thereby reducing cumulative errors in intermediate variable estimation. Second, a reverse residual network module with an attention mechanism (RNAM) is designed to extract multi-scale features while emphasizing critical semantic information, effectively reducing model complexity and parameter size. Finally, a joint loss function combining L_1 smoothing loss and multi-scale structure similarity (MS-SSIM) loss is used to improve reconstruction quality. The experimental results show that the proposed method outperforms existing approaches in terms of structural similarity and peak signal-to-noise ratio (PSNR) on synthetic datasets, while also achieving effective dehazing performance on real-world images. In addition, the model exhibits reduced parameter size and improved computational efficiency.

收稿日期:2021-10-11

基金项目:国家自然科学基金(61972186);云南省重大科技专项计划(202103AA080015)。

Supported by National Natural Science Foundation of China (61972186), and Major Science and Technology Special Project of Yunnan Province (202103AA080015).

作者简介:唐剑(1996—),男,硕士,主要从事计算机视觉和图像处理方向研究,(E-mail)790245752@qq.com。

Keywords: image dehazing; lightweight network; attention mechanism; reverse residual network

在雾天,空气中各种悬浮颗粒会对大气光产生散射和吸收,导致计算机设备在采集图像时会发生图像模糊、色彩失真等现象。图像质量的严重失真阻碍了计算机视觉的后续应用,为了充分利用有雾图像的本质特征,对有雾图像进行去雾是十分有必要的。当前图像去雾算法大致可以分为两类:一是基于传统的图像去雾算法,二是基于深度学习的图像去雾算法。

传统的图像去雾算法主要是根据图像增强和图像复原两种策略进行图像去雾。图像增强主要通过过滤掉图像的噪声、增强图像的对比度,从而达到图像去雾的目的,代表方法有直方图均衡化^[1-2]、同态滤波^[3]和Retinex方法^[4]等。图像复原这类方法主要是分析雾天图像的成像原理,建立相应的雾天图像退化模型的数学表达式,从中反推出无雾图像,最著名的是Narasimhan和Nayar提出的大气散射模型^[5],该模型可以被描述为

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

其中: $I(x)$ 表示有雾图像; $J(x)$ 表示待恢复的无雾图像; $t(x)$ 表示透射率; A 表示大气光值; x 表示图像中像素点的位置。由式(1)可知,求解无雾图像是一个不适定问题,透射率和大气光值都是未知的,需要借助一些先验知识才能获取无雾图像。He等^[6]提出暗通道先验,通过大量统计图像的RGB 3个颜色通道发现每个像素总有一个通道的灰度值很低,常常趋于零,以此来估计透射率,同时选取暗通道图中最亮的前0.1%像素的最大像素值作为大气光值,最后根据大气散射模型恢复出无雾图像。Tang等^[7]将暗通道、对比度、饱和度和色度作为图像的特征,使用随机森林学习雾特征与透射率的关系得到相应的透射率,选取暗通道图中最亮的前0.1%像素的最大像素值的中位数作为大气光值。

随着深度学习理论的逐渐成熟,卷积神经网络在图像处理方面有着良好的性能。Cai等^[8]提出第一个深度学习网络DehazeNet用于图像去雾,通过卷积神经网络对透射率 $t(x)$ 进行估计,大气光 A 的取值依然和传统方法一样,缺点就是分别计算透射率 $t(x)$ 和大气光值 A ,会存在较大的误差。Zhang等^[9]受到密集连接网络的启发,提出了DCPDN,将大气散射模型嵌入到整个网络,通过密集连接的编码解码网络生成 $t(x)$,利用U-Net得到大气光值 A ,使用联合判别器对网络进行联合训练,最后得到无雾图像。Pan等^[10]通过增强和误差反馈两个原则设计出一种基于U-Net架构的具有密集特征融合的多尺度增强的去雾网络,最后通过解码器逐步恢复出无雾图像。

为了得到更好的去雾效果,图像去雾所使用的网络越来越深,模型的复杂度也越来越高,在真实的应用场景使用卷积神经网络进行图像去雾时大而复杂的模型是难以被应用的,基于此本文提出一种轻量型的卷积神经网络用于图像去雾,以减少训练参数和模型的复杂度为目标设计网络架构,从而能够实时去雾以及满足移动端和嵌入式设备的去雾需求。

1 研究工作

1.1 大气散射模型的改进

由大气散射模型式(1)可知,若想恢复出无雾图像 $J(x)$,大气光值 A 和透射率 $t(x)$ 的值必须是已知的。如果采用某种策略分别计算大气光值 A 和透射图 $t(x)$,对中间变量进行直接估计将会导致误差堆叠。受到图像去雨研究中雨模型^[11]以及DeblurGan^[12]中利用深度残差思想直接将图像中的噪声剔除的启发,让卷积神经网络自动学习有雾图像中的雾特征,直接剔除雾噪声,尽可能减少误差累计或放大,最后得到清晰的无雾图像,本文将大气散射模型式(1)重新表示为

$$I(x) = J(x)t(x) + A(1 - t(x)) = J(x) + K(x), \quad (2)$$

其中, $K(x)$ 是指有雾图像中的那部分有雾特征,进一步将 $J(x)$ 表示为

$$J(x) = I(x) - K(x) + b, \quad (3)$$

其中, b 为常量恒置偏差, b 的值取实验数据中有雾/无雾图像对的均方误差。

1.2 网络设计

受到多种网络^[13-19]以及残差连接^[20]的启发,本文根据改进的大气散射模型式(3),设计了一个合适的轻量型去雾网络 LDNet(lightweight image dehazing network)进行图像去雾,该网络主要由 3 种融入注意力机制的倒残差模块构成,如图 1 所示。将一张有雾图像输入到网络中,首先使用一个 3×3 的卷积层将图像转换到特征空间,得到的特征图输入到堆叠的融入注意力机制的倒残差网络模块 RNAM(reverse residual network module with attention mechanism)中,将每个模块得到的特征图进行特征融合作为下一个模块的输入,从而达到特征重用、提高网络效率的目的,然后通过中间模块学习输入图像的有雾特征信息,再使用一个 3×3 的卷积层将特征域转化到原始的图像空间,最后将网络学习到的 $K(x)$ 带入改进的大气散射模型中获得无雾图像。

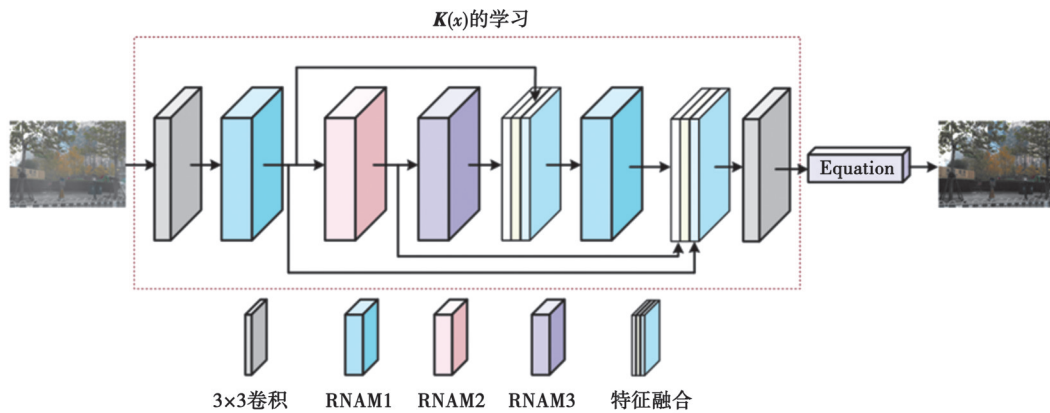


图 1 网络的总体架构

Fig. 1 The overall architecture of the network

1.2.1 倒残差模块

以往的残差模块^[20]是先使用 1×1 的卷积层进行通道压缩,中间经过一个卷积层,最后通过 1×1 的卷积层扩张到所需要的维度,结构如图 2 所示。

本文使用的残差模块与图 2 有所不同,首先使用 1×1 的卷积增加通道数,获得更多的特征图,有利于提取丰富的特征;接着采用 DW(depthwise convolution)卷积^[17]操作,该操作使用的卷积核个数与输入特征图的通道数相同,每个卷积核只跟一个通道的特征图进行卷积操作,卷积结束之后可以得到与输入通道相同数量的特征图;最后采用 1×1 的卷积降低特征图的维度,为后续的卷积操作减少参数数量和计算复杂度,由于 DW 操作没有有效地利用不同通道在相同空间位置上的特征信息, 1×1 的卷积还可以将每个通道的特征图组合生成新的特征图,使得不同通道同一空间位置上的特征信息能够具有相关性。本文提出的 3 种倒残差模块使用不同大小的卷积核,如图 3 所示。




图 2 残差模块示意图

Fig.2 Structure of resblock

输入的图像经过卷积处理得到输出数据,只有在输出的数据维度越高,经过非线性激活函数的处理后数据的损失才会越小,有 2 个解决办法:第 1 提升输出数据的维度,第 2 去掉非线性激活函数采用线性激活函数。APReLU^[21](adaptively parametric rectifier linear unit)是一种“注意力机制下的新型激活函数”,该激活函数能够实现 PReLU^[22](parametric rectified linear unit)激活函数一样的功能,当神经网络采用 APReLU 激活函数时,不像以往的非线性激活函数一旦神经网络训练完成之后,全部测试样本所采用的非线性变化都是相同的,它能够提供一种更灵活的非线性变换方式,使得每个样本都有自己独特的权重系数,即独特的非线性变换,对图像任务具有很大的潜力。同时 APReLU 激活函数的输入特征图和输出特征图有着相同的尺寸,对网

络隐含层的输入输出并没有受影响。为了避免特征退化,在这里通过先使用 1×1 卷积先升维,使输出数据达到一定的维度,在倒残差模块中最后一个卷积层采用线性激活函数,第1、第2卷积层均采用自适应参数化修正线性单元APReLU激活函数。

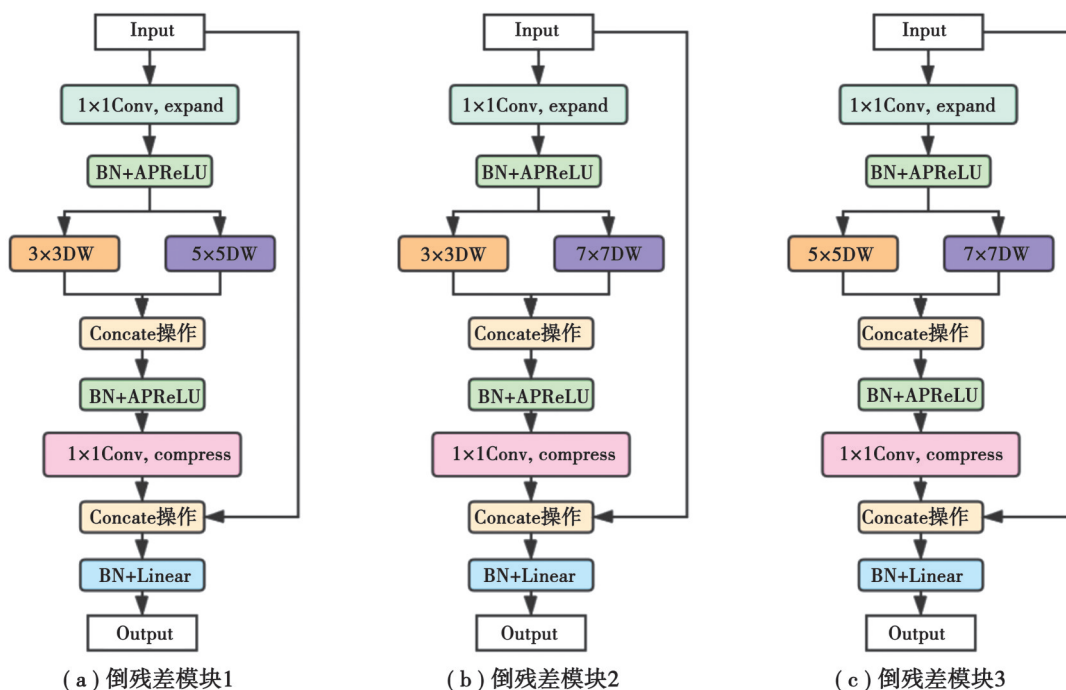


图3 3种不同卷积核的倒残差模块

Fig. 3 Three inverted residual modules of different convolution kernels

倒残差模块使用不同大小的卷积核是为了多尺度提取特征,提取更全面的特征信息从而保留原始图片中更多的细节信息,提高网络在不同尺度下的鲁棒性。对每个模块得到的特征图进行特征融合,能充分利用图像的语义信息,有助于网络学习图像中的雾特征。假设输入的图像大小为 $D \times D \times M$,输出图像为 $D \times D \times N$,卷积核大小为 $D_k \times D_k$ 。倒残差的计算量与标准卷积的计算量比可表示为

$$\frac{D \times D \times M \times D_k \times D_k + M \times N \times D \times D}{D \times D \times M \times N \times D_k \times D_k} = \frac{1}{N} + \frac{1}{D_k^2} \quad (4)$$

假如图像的输出通道为256时,式(4)中等号右边的第一项可以忽略不计,当卷积核大小为 3×3 时,计算量大约减少 $1/9$ 。通过以上所述,当采用上述的卷积方式,能够减少计算量的同时具备良好的特征学习能力。

1.2.2 注意力机制CBAM

CBAM^[23](convolutional block attention module)是一种结合了通道和空间的注意力机制,相比那些只关注通道的注意力机制能够取得更好的效果,而且它是一个轻量级的模块,可以在不显著增加计算量和参数量的前提下提升网络模型的特征提取能力。在卷积操作之后使用CBAM能对通道和空间维度的特征图进行约束增强处理,该模块会将输入特征图沿着通道和空间两个维度推断注意力图,最后将注意力图与输入特征图相乘进行自适应特征优化,结构图如图4所示。




图4 卷积注意力模块

Fig. 4 Convolutional block attention module

通道注意力机制首先将输入的特征图进行最大池化和平均池化,最大池化和平均池化可以融合特征映射的空间信息,从而达到压缩特征图的空间维数,然后将得到的特征图输入全连接神经网络,得到的输出特征图进行逐元素加和操作,再经过激活函数 Sigmoid 生成通道注意力特征图,最后将通道注意力特征图与输入特征图进行逐像素乘法操作,生成的特征图作为空间注意力机制模块的输入,通道注意力机制的结构如图 5 所示。




图 5 通道注意力机制

Fig. 5 Channel attention module

空间注意力机制将通道注意力机制输出的特征图作为本模块的输入,先对输入特征图做基于通道的最大池化和平均池化,将两个结果做基于通道的 Concat 操作,再经过一个卷积操作和激活函数 Sigmoid 生成空间注意力特征图,把该特征图与空间注意力的输入特征图做逐元素的相乘,得到注意力机制的最终结果。同时做最大池化和平均池化的好处是平均池化能够对特征图上的每一个像素都有反馈,而最大池化能够在梯度反向传播的时候,只有特征图中像素有较大的梯度时才会做出反馈,通道注意力机制的结构如图 6 所示。




图 6 空间注意力机制

Fig. 6 Spatial attention module

1.2.3 融入注意力机制的倒残差网络模块

本文将注意力机制与倒残差结构相结合,融入注意力机制的倒残差网络模块 RNAM。由于卷积操作本身是一种局部操作,往往会忽略很多重要的特征信息,采用注意力机制就能够让网络忽略无关的信息特征而关注重要的信息特征,使网络能有效地学习图像的雾特征。大量注意力机制的使用虽然能提升模型的精度,但是会增加模型的访存量和复杂度,CBAM 是一个轻量级的模块,对网络的开销影响并不大,轻量级网络有良好的性能,且不会带来更多的参数,所以本文在倒残差模块的基础上引入注意力机制 CBAM,构建出 3 种融入注意力机制的倒残差网络模块 RNAM1、RNAM2、RNAM3 如图 7 所示。

1.2.4 损失函数

研究的损失函数采用联合损失函数,由 2 部分组成,第 1 部分是平滑 L_1 损失,第 2 部分是多尺度结构相似性 MS-SSIM^[24](multi-scale structure similarity)损失函数。由于 SSIM^[25](structure similarity)作为损失函数对图像的均值方差的高斯核选择具有一定的盲目性,相对于费时费力地选择合适的高斯核,可以采用多尺度的 SSIM 损失函数也就是 MS-SSIM,MS-SSIM 对均匀的偏差并不敏感,会带来颜色的平移或者亮度的改变,但是可以保留高频区域的对比,而平滑 L_1 损失函数可以保留颜色和亮度,但是会忽略局部结构,因此将两者进行

结合,通过联合损失函数对网络进行优化。平滑 L_1 损失函数可以表示为

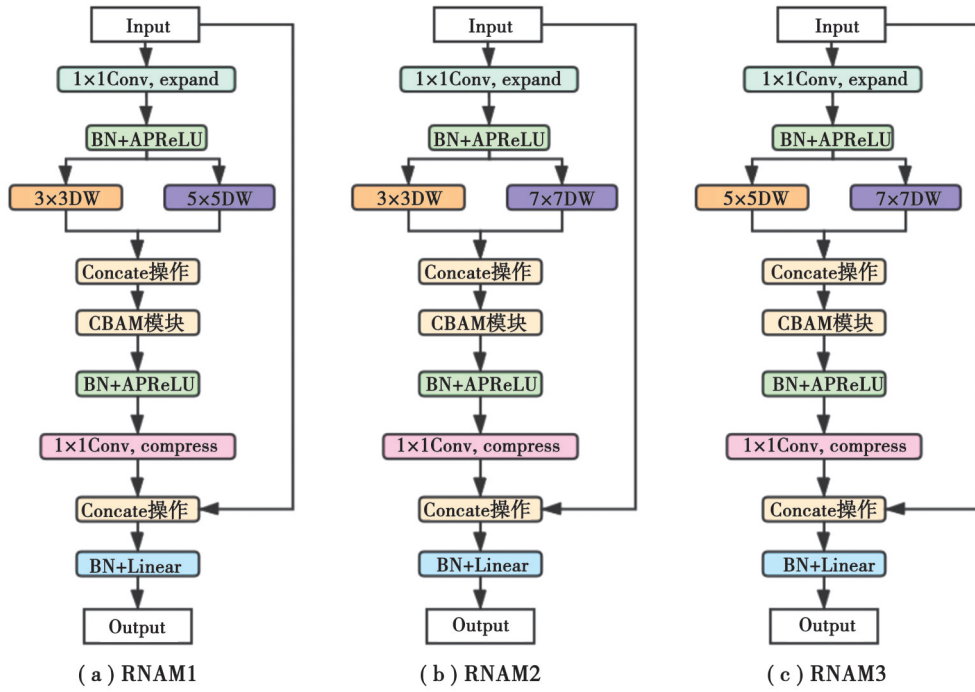


图7 融入注意力机制的倒残差网络模块 RNAM

Fig. 7 Reverse residual network module with attention mechanism

$$L_1 = \frac{1}{N} \sum_{x=1}^N \sum_{i=1}^3 \text{Smooth}(I_i(x) - J_i(x)), \quad (5)$$

$$\text{Smooth}(x) = \begin{cases} 0.5x^2, & \text{if } |x| < 1, \\ |x| - 0.5, & \text{otherwise,} \end{cases} \quad (6)$$

其中: N 表示像素的总数; i 表示图像的 R 、 G 、 B 3 个通道, x 表示图像中的像素。

SSIM 是比较 2 张图像之间的亮度、对比度和结构, SSIM 取值为 0~1, 值越大主观感觉质量越高。SSIM 定义为

$$\text{SSIM}(I(x), J(x)) = \frac{(2\mu_{I(x)}\mu_{J(x)} + c_1)(2\sigma_{I(x)J(x)} + c_2)}{(\mu_{I(x)}^2 + \mu_{J(x)}^2 + c_1)(\sigma_{I(x)}^2 + \sigma_{J(x)}^2 + c_2)}, \quad (7)$$

其中: $I(x)$ 表示有雾图像; $J(x)$ 表示 $I(x)$ 与之对应的无雾图像, x 表示图像中的像素点位置; $\mu_{I(x)}$ 和 $\sigma_{I(x)}^2$ 为 $I(x)$ 的均值和方差; $\mu_{J(x)}$ 和 $\sigma_{J(x)}^2$ 为 $J(x)$ 的均值和方差; $\sigma_{I(x)J(x)}$ 为 $I(x)$ 和 $J(x)$ 的协方差, c_1 和 c_2 分别取默认值 0.01 和 0.03。基于 SSIM 的损失函数表示为

$$L_{\text{SSIM}}(I(x), J(x)) = 1 - \text{SSIM}(I(x), J(x)), \quad (8)$$

MS-SSIM 就是图像的宽高以 2^{M-1} 为因子进行缩放, 当 $M=2$ 时, 表示原始图像缩小 1/2, 以此类推 MS-SSIM 损失函数表示为

$$L_{\text{MS-SSIM}}(I(x), J(x)) = 1 - [\text{MS-SSIM}(I(x), J(x))], \quad (9)$$

本文的复合损失函数由以上 2 种损失函数组成, 最后联合损失函数表示为

$$L_{\text{total}} = aL_1 + (1-a)L_{\text{MS-SSIM}}, \quad (10)$$

其中, a 是权重参数, 这里取 0.16。

2 实验

2.1 数据集

本文采用 RESIDE^[26]数据集,包含了合成的和真实世界的有雾图像与无雾图像的室内室外图像对,该数据集主要有室内训练集 ITS(indoor training set)、合成对象测试集 SOTS(synthetic objective testing set)、混合主观测试集 HSTS(hybrid subjective testing set)、未标注的真实有雾图像 URHI(unlabeled real-world hazy images)、室外训练集 OTS和真实任务数据集 RTTS(real-world task-driven testing set)组成。为了使得网络能够学习室内外场景的去雾能力,本文分别从 OTS 中随机抽取 10 000 对室外图像和从 ITS 中随机抽取 6 000 对室内图像作为训练集,同时为了进一步增强训练数据集,将图像随机裁剪成 256×256 尺寸大小的图片,并将它们随机水平翻转或垂直翻转作为训练图像。选取 SOTS 中的 500 张室内图像作为测试集 A,除此之外,从数据集 RTTS 随机选取 100 张真实图像作为测试集 B。

2.2 实验细节

实验环境:本文的实验训练在服务器上进行,服务器 CPU 型号为 Intel(R) Xeon(R) Gold 5218,16 核 32 线程,内存为 32 GB,显卡为 Tesla T4,显存为 16 GB,操作系统为 Ubuntu 18.04.5,深度学习框架为 Pytorch1.6.0,Python 版本为 3.6.12,CUDA 版本为 11.1。本文的实验测试在本地台式机上进行,使用的操作系统为 Windows10,内存 RAM 为 16 GB,处理器为 i7-10700F 的 8 核 16 线程的 CPU,GPU 为 GTX2060 的独立显卡,显存为 6 GB,使用深度学习框架 Pytorch1.7.1,CUDA 版本 11.1,编程环境采用 Pycharm,编程语言为 Python3.6.12。

实验设置:在网络训练阶段,卷积核的初始化设置为高斯分布,偏置初始化为 0,网络的初始化学习率设置为 0.001。模型训练采用小批量训练的方式,batch-size 设为 6,使用 ADAM^[27]优化整个网络,一共训练 100 轮,每 20 轮学习率降为原来的 1/2。

2.3 实验对比

为进一步验证所提出方法的图像去雾效果,在合成数据集和真实数据集上与几种经典的去雾方法进行比较,在合成数据集上进行主观和客观分析,采用峰值信噪比^[28](peak signal to noise ratio,PSNR)和结构相似性^[24](structural similarity,SSIM)衡量图像的去雾效果,在真实数据集上,由于没有无雾图像作为对比,只能做主观分析。所选取的算法有 DCP(dark channel prior)^[6]、DehazeNet^[8]、AODNet(all-in-one dehazing network)^[29]、GCANet(gated context-aware network)^[30]、MSBDN(multi-scale boundary-aware dehazing network)^[10],其中 DCP 算法为基于先验的传统方法中经典代表,其余的都是基于深度学习的方法。

2.3.1 合成数据集

在测试集 A 上与所选取算法做对比,由于 SOTS 包含有雾图像和相应的无雾图像,可以定性和定量地评估本文所提出的算法,在测试集中选取的几张照片作为对比,如图 8 所示。

图 8(a)是输入的有雾图片,图 8(b)是 He 等^[6]提出的 DCP 先验算法的去雾结果,由于 DCP 算法对于大气光值估计不够准确,恢复的无雾图像颜色偏深且包含有天空区域的图像进行去雾时效果并不理想。图 8(c)是 Cai 等^[8]第 1 个基于深度学习的图像去雾网络 DehazeNet,该算法是通过网络学习透射率 $t(x)$,基于人工的方法确定大气光值,恢复的图像出现色彩失真、天空区域出现泛白。图 8(d)是 Li 等^[29]提出的 AODNet,对天空去雾的效果有一定的改善,但是去雾不够彻底,恢复的图像仍存在较多的雾。图 8(e)是 Chen 等^[30]出的 GCANet,该算法主要是学习有雾图像和无雾图像的残差,利用了最新的平滑膨胀技术,图像的去雾已经具有良好的效果,在第 3 行的对比图像中,恢复的无雾图像具有一定色彩偏差。图 8(f)是 Pan 等^[10]提出的 MSBDN,采用了增强反馈和误差反馈机制,但是在边缘、纹理的处理能力并不令人满意。图 8(g)是本文的图像去雾算法,图像的清晰度有了显著的提升,能够清晰地辨别图像中的内容,恢复的无雾图像视觉上比较自然。

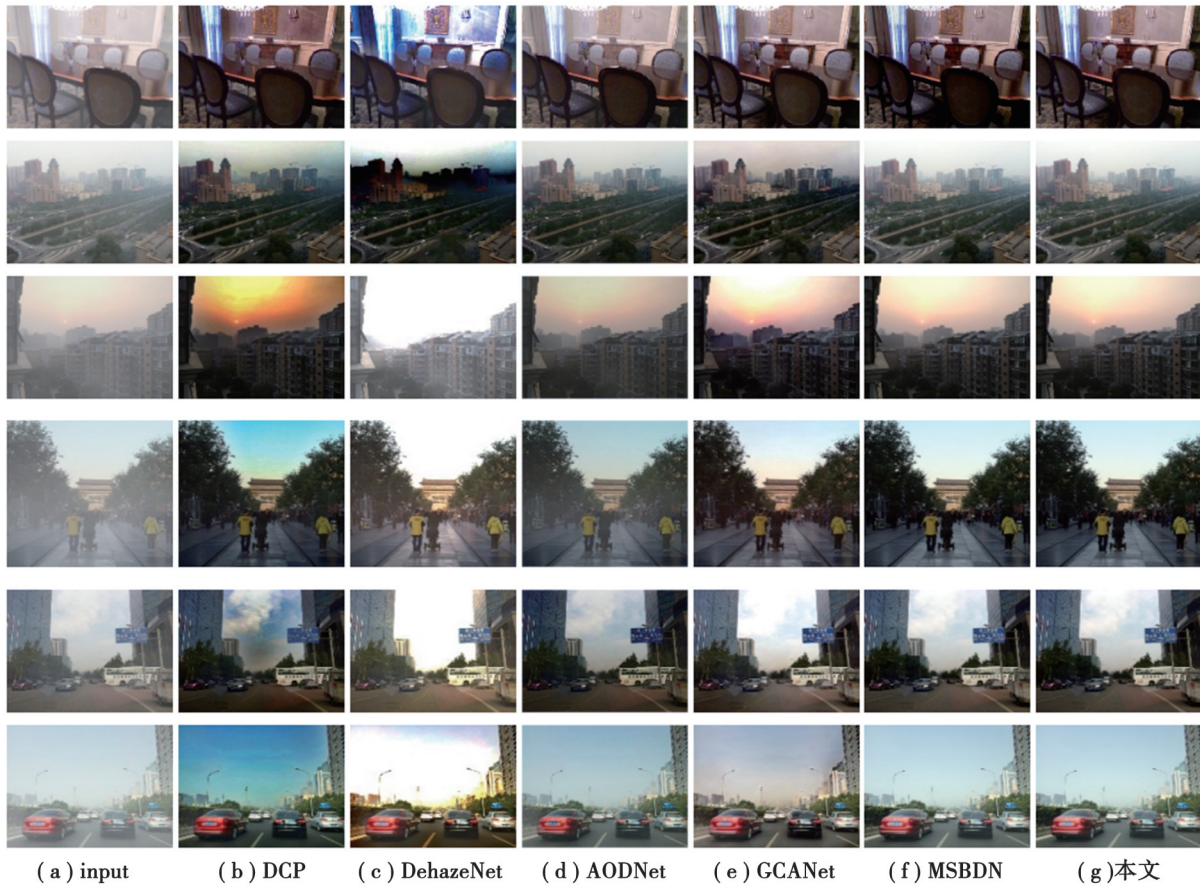


图8 SOTS上的去雾效果比较

Fig. 8 Comparison of dehazing effects on SOTS data set

表1~2是DCP^[6]、DehazeNet^[8]、AODNet^[29]、GCANet^[30]、MSBDN^[10]以及本文算法在去雾前后的平均PSNR和平均SSIM值对比。

表1 未加入CBAM注意力机制在测试集A上的PSNR值和SSIM值

Table 1 The average values of PSNR and SSIM on test set A without CBAM

指标	DCP	DehazeNet	AODNet	GCANet	MSBDN	本文
PSNR	17.560	19.150	20.250	27.110	29.180	31.230
SSIM	0.817	0.861	0.856	0.892	0.902	0.924

表2 加入CBAM注意力机制在测试集A上的PSNR值和SSIM值

Table 2 The average values of PSNR and SSIM on test set B with CBAM

指标	DCP	DehazeNet	AODNet	GCANet	MSBDN	本文
PSNR	—	21.360	22.300	29.730	30.680	33.490
SSIM	—	0.895	0.879	0.917	0.935	0.941

从表1~2分析可知,DCP^[6]、DehazeNet^[8]的PSNR、SSIM都相对较低。DCP去雾不够彻底导致峰值信噪比和结构相似性都低于其他算法,随着网络的加深,图像去雾所得到的评价指标也有所改善,GCANet^[30]和MSBDN^[10]的PSNR和SSIM值都比之前的算法高,因为随着GCANet和MSBDN网络的加深、改进和各种优化方法的提出,能够学习到更多关于雾的特征,图像的去雾的研究都具有了一定的进展,效果也比较明显。对比表1~2可知加入注意力机制CBAM能够提升模型的性能,去雾效果也相对于未加入注意力机制之前能够取得更好的结果。本文的去雾算法的PSNR值和SSIM值都高于对比算法,恢复的无雾图像更接近真实的

无雾图像,从主观分析到定量分析,本文算法的去雾效果都优于对比算法^[30]。

2.3.2 真实数据集

真实场景的雾天图像与合成的雾天图像在视觉效果上存在着一定的差距,图像去雾的最终目的最终是应用在真实场景中,将本文算法与对比算法在真实场景做对比是有必要的。同一场景下获取有雾图像与相应的无雾图像代价是非常高的,因此在真实场景下采用主观评价,本文在真实场景测试集B上选取几张照片作为对比,如图9所示。



图9 不同图像去雾方法在真实数据集上的对比

Fig. 9 Comparison of dehazing effects on real datasets

图9为真实场景的去雾效果比较图,真实场景具有较大的复杂性和不确定性,也是每个去雾算法需要解决的问题,通过对比验证本文算法在真实场景下去雾的有效性。其中图9(b)DCP^[6]先验算法存在严重的色彩失真且去雾处理之后色彩颜色较深,图9(c)是DehazeNet^[8],对比发现,DehazeNet在亮度较大的地方去雾效果较差,光线较强的图像区域出现泛白现象且天空存在伪影,图9(d)是AODNet^[28],存在着去雾不彻底,在真实场景中去雾前后图像清晰度没有多大变化,图9(e)的GCANet^[29]和图9(f)的MSBDN^[10]去雾效果有了一定的改善,GCANet在第1行的图片中,去雾不够彻底,MSBDN在第4行中的图片中道路尽头出现了颜色泛黄的现象,在细节的处理有所瑕疵,图9(g)是本文算法,相比所对比的算法去雾效果较好,恢复的无雾图像更加自然且比较真实。

2.3.3 参数量和时间的对比

表3中Parameter是每个网络的参数量的对比,Time是处理一张图片的运行时间,该时间都是在本实验环境下对测试集平均处理一张图片的所耗费的时间。

表3 参数量和时间的对比

Table 3 Comparison of parameters and time

指标	DCP	DehazeNet	AODNet	GCANet	MSBDN	本文
Parameter	—	8 240	1 761	702 818	36 845 053	1 548
Time/s	0.813 7	1.174 3	0.852 9	0.987 4	1.032 8	0.807 3

由表3所知,本文所提出算法模型的参数量比其他对比算法少,运行时间也比其所对比的算法要快。一般来说,对于卷积神经网络模型,如果网络模型中包含的参数量越少,那么模型的表达能力就越弱,由于研究

通过设计一种轻量型的融入注意力机制的倒残差网络模块RNAM,在充分提取图像特征的同时关注图像特征中的重要信息,而且模型的复杂度也比较低,具有一定的轻量型,在模型参数较少的情况下去雾效果也可以与其他算法相媲美。

3 结 语

针对现在大多数去雾网络存在网络深、参数量大的特点,提出一种轻量型网络LDNet进行图像去雾,本文的贡献主要有以下几点:1)通过对大气散射模型进行改进,让网络模型直接学习图像的雾噪声,减小中间量的估计误差,最后实现图像去雾。2)构建一种学习图像雾噪声的融入注意力机制的倒残差模块RNAM,具有多尺度、轻量级的特点,能够充分提取图像特征而且网络规模小。3)采用联合损失函数,结合平滑 L_1 损失函数和MS-SSIM损失函数的优点来指导网络学习。4)通过与其他去雾方法的对比,该网络在模型参数少、计算量少的前提下无论在合成数据集上还是真实场景数据集上都能够取得较好的去雾效果,且在合成数据集上PSNR和SSIM值均高于其他算法。

参考文献

- [1] Singh K, Vishwakarma D K, Walia G S, et al. Contrast enhancement *via* texture region based histogram equalization[J]. Journal of Modern Optics, 2016, 63(15): 1444-1450.
- [2] Rao B S. Dynamic Histogram Equalization for contrast enhancement for digital images[J]. Applied Soft Computing, 2020, 89: 106114.
- [3] Abbas A H, Harbi J. Image enhancement by using homomorphic filtering model[C]//1st International Conference on Information Technology. Erbil, Iraq: Lebanese French University, 2017: 335-342.
- [4] Li M D, Liu J Y, Yang W H, et al. Structure-revealing low-light image enhancement via robust retinex model[J]. IEEE Transactions on Image Processing, 2018, 27(6): 2828-2841.
- [5] Narasimhan S G, Nayar S K. Vision and the atmosphere[J]. International Journal of Computer Vision, 2002, 48(3): 233-254.
- [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.
- [7] Tang K, 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. June 23-28, 2014. Columbus, OH, USA: IEEE, 2014: 2995-3002.
- [8] 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.
- [9] 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: IEEE, 2018: 3194-3203.
- [10] Dong H, Pan J S, Xiang L, et al. Multi-scale boosted dehazing network with dense feature fusion[C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). June 13-19, 2020. Seattle, WA, USA: IEEE, 2020: 2154-2164.
- [11] Luo Y, Xu Y, Ji H. Removing rain from a single image via discriminative sparse coding[C]//2015 IEEE International Conference on Computer Vision (ICCV). December 7-13, 2015. Santiago, Chile: IEEE, 2015: 3397-3405.
- [12] Kupyn O, Budzan V, Mykhailych M, et al. DeblurGAN: blind motion deblurring using conditional adversarial networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. June 18-23, 2018. Salt Lake City, UT, USA: IEEE, 2018: 8183-8192.
- [13] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). June 27-30, 2016. Las Vegas, NV, USA: IEEE, 2016: 2818-2826..
- [14] Iandola F N, Han S, Moskewicz M W, et al. SqueezeNet: AlexNet-level accuracy with 50x fewer parameters and< 0.5 MB model size[EB/OL]. (2016-02-24) [2020-11-10]. <https://arxiv.org/abs/1602.07360>.
- [15] Howard A G, Zhu M L, Chen B, et al. Mobilenets: Efficient convolutional neural networks for mobile vision applications[EB/OL]. (2017-04-17) [2020-10-31]. <https://arxiv.org/abs/1704.04861>.

- [16] Ma N N, Zhang X Y, Zheng H T, et al. ShuffleNet V2: practical guidelines for efficient CNN architecture design[C]//Computer Vision-ECCV 2018. Cham: Springer, 2018: 122-138.
- [17] Sandler M, Howard A, Zhu M L, et al. MobileNet V2: inverted residuals and linear bottlenecks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. June 18-23, 2018. Salt Lake City, UT: IEEE, 2018: 4510-4520.
- [18] Xu B, Tulloch A, Chen Y P, et al. Hybrid Composition with IdleBlock: more efficient networks for image recognition[EB/OL]. (2019-11-19) [2020-11-05]. <https://arxiv.org/abs/1911.08609>.
- [19] Zhou D Q, Hou Q B, Chen Y P, et al. Rethinking bottleneck structure for efficient mobile network design[EB/OL]. (2020-07-05) [2020-12-01]. <https://arxiv.org/abs/2007.02269>.
- [20] 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. IEEE, 2016: 770-778.
- [21] Zhao M H, Zhong S S, Fu X Y, et al. Deep residual networks with adaptively parametric rectifier linear units for fault diagnosis [J]. IEEE Transactions on Industrial Electronics, 2021, 68(3): 2587-2597.
- [22] He K M, Zhang X Y, Ren S Q, et al. Delving deep into rectifiers: surpassing human-level performance on ImageNet classification[C]//2015 IEEE International Conference on Computer Vision (ICCV). December 7-13, 2015. Santiago, Chile: IEEE, 2015: 1026-1034.
- [23] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module[M]//Computer Vision-ECCV 2018. Cham: Springer International Publishing, 2018: 3-19.
- [24] Wang Z, Simoncelli E P, Bovik A C. Multiscale structural similarity for image quality assessment[C]//37th Asilomar Conference on Signals, Systems & Computers. November 9-12, 2003. Pacific Grove, CA, USA: IEEE, 2003: 1398-1402.
- [25] Wang Z, Bovik A C, Sheikh H R, et al. Image quality assessment: from error visibility to structural similarity[J]. IEEE Transactions on Image Processing, 2004, 13(4):600-612.
- [26] Li B, Ren W, Fu D, et al. Benchmarking single image dehazing and beyond[EB/OL]. (2017-12-12) [2020-10-10]. <https://arxiv.org/abs/1712.04143>.
- [27] Kingma D P, Ba J. Adam: a method for stochastic optimization[EB/OL]. (2014-12-22) [2020-11-13]. <https://arxiv.org/abs/1412.6980>.
- [28] Wang Y J, Li J H, Lu Y, et al. Image quality evaluation based on image weighted separating block peak signal to noise ratio[C]//International Conference on Neural Networks and Signal Processing. December 14-17, 2003. Nanjing, China: IEEE, 2003: 994-997.
- [29] 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: IEEE, 2017: 4780-4788.
- [30] 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 Village, HI, USA: IEEE, 2019: 1375-1383.

(编辑 侯 湘)