

基于多尺度卷积神经网络的单幅图像去雾方法

陈永*, 郭红光, 艾亚鹏

兰州交通大学电子与信息工程学院, 甘肃 兰州 730070

摘要 针对传统的单幅图像去雾算法容易受到雾图先验知识制约及颜色失真等问题,提出了一种基于深度学习的多尺度卷积神经网络(CNN)单幅图像去雾方法,即通过学习雾天图像与大气透射率之间的映射关系实现图像去雾。根据大气散射模型形成雾图机理,设计了一个端到端的多尺度全 CNN 模型,通过卷积层运算提取有雾图像的浅层特征,利用多尺度卷积核并行提取得到有雾图像的深层特征,然后将浅层特征和深层特征进行跳跃连接融合,最后通过非线性回归得到雾图对应的透射率图特征,并根据大气散射模型恢复出无雾图像。采用雾图数据集对该模型进行训练测试。实验结果表明,所提方法在合成有雾图像和真实自然雾天图像的实验中均能取得良好的去雾效果,在主观评价和客观评价上均优于其他对比算法。

关键词 图像处理; 图像去雾; 图像恢复; 多尺度卷积神经网络; 大气散射模型

中图分类号 TP391.4

文献标识码 A

doi: 10.3788/AOS201939.1010001

Single Image Dehazing Method Based on Multi-Scale Convolution Neural Network

Chen Yong*, Guo Hongguang, Ai Yapeng

School of Electronic and Information Engineering, Lanzhou Jiaotong University, Lanzhou, Gansu 730070, China

Abstract Since the traditional single image dehazing algorithm is susceptible to the prior knowledge constraint of hazy image and color distortion, this paper proposes a multi-scale convolutional neural network (CNN) single image dehazing method based on deep learning, which realizes image dehazing by learning the mapping relationship between hazy image and atmospheric transmission. According to the hazy image forming mechanism of atmospheric scattering model, an end-to-end multi-scale full CNN model is designed. The shallow layer features of hazy image are extracted by convolution layer operation, and then the deep features are extracted by multi-scale convolution kernel in parallel. Then the shallow layer features and deep features are fused by jump connection. Finally, the non-linear regression method is used to obtain the corresponding transmission features of the hazy image. According to the atmospheric scattering model, the haze-free image is restored. The model is trained by using hazy image data sets. The experimental results show that the proposed method can achieve good dehazing effect in the experiments of synthesizing hazy images and real natural hazy images. The proposed method is superior to other contrast algorithms in subjective and objective evaluations.

Key words image processing; image dehazing; image restoration; multi-scale convolution neural network; atmospheric scattering model

OCIS codes 100.2980; 010.1310; 330.4060

1 引 言

雾是一种常见的自然天气现象。雾天场景下的空气中悬浮着大量的微小水滴,这些水滴的散射和折射作用会使成像系统获得的图像偏灰白色,导致

图像的色彩饱和度和对比度下降,从而丢失很多重要的细节信息,不利于图像特征的提取和辨识,也增加了对图像进行后续处理的难度。因此,研究如何对雾天场景下获得的退化图像进行有效处理,对大气退化图像的复原和景物细节信息的增强有着非常

收稿日期: 2019-04-28; 修回日期: 2019-05-27; 录用日期: 2019-06-03

基金项目: 国家自然科学基金(61841303)、长江学者和创新团队发展计划(IRT_16R36)、教育部人文社会科学研究基金(19YJC760012)

* E-mail: edukeylab@126.com

重要的现实意义和广阔的应用前景^[1-2]。此外,随着对计算机视觉领域研究的不断深入,人们对成像设备采集的图像清晰度有了更高的要求,雾天图像清晰化已经成为计算机视觉的重要研究内容^[3]。

众多的去雾方法主要分为以下两类:

1) 基于非物理模型的图像增强方法^[4-6]。该方法未考虑图像降质的根本原因,主要通过增强有雾图像的对比度和饱和度来突出图像中有价值的信息,从而提高图像的质量,并不是真正意义上的去雾,如基于 Retinex 理论的方法、基于小波分解变换的方法和基于直方图均衡化的方法。

2) 基于物理模型的图像复原方法^[7-11]。该方法建立在大气散射模型的基础上,在反推物理模型的过程中完成参数估计,从而实现有雾图像的清晰化。如 He 等^[7-8]提出了暗通道先验方法,通过有雾图像中的暗通道先验信息来求解大气散射模型,并取得了良好的去雾效果,但该算法使用软抠图方法,运算量较大。江巨浪等^[9]提出了将暗通道先验去雾算法与直方图均衡化结合的雾天图像融合增强算法,采用该算法去雾后,图像全局增强对比度有所改善,但是对于亮度较高的天空部分仍会出现颜色失真。卢辉斌等^[10]通过将亮通道与暗通道相结合的方法来估计大气光值和透射率,该方法可恢复图像的细节和颜色信息,但在大气光值计算过程中运算量较大,执行效率较低。Meng 等^[11]提出了一种基于边界约束的去雾方法,通过牺牲部分边界信息来获得去雾图像,该方法解决了去雾图像亮度偏低的问题,但是在去雾图像的部分区域仍然会出现颜色失真现象。尽管上述传统的图像去雾方法取得了很大进步,但它们大多依赖于各种先验信息或以假设条件为前提,并且采用人工方式提取雾的相关特征,而且有些方法中的假设条件在许多情况下并不能成立,仍然有局限性。

近几年,随着深度学习的快速发展及其在图像处理领域中的广泛应用,越来越多的研究人员利用深度学习方法来处理图像去雾问题。如 Tang 等^[12]使用随机森林研究雾气图像的暗通道优先、最大对比度、颜色衰减先验等特征来恢复无雾图像,但是当去雾算法中随机森林决策树个数较多时,训练复杂性较大,而且随机森林去雾模型容易陷入过拟合问题。Cai 等^[13]提出了一种基于深度学习的端到端的去雾方法,通过特征提取,利用多尺度映射和最大池化等操作学习雾霾特征,得到了有雾图像的透射率图,实现了有雾图像的清晰化。Ren 等^[14]通过建立

粗尺度网络和细尺度网络模型来学习有雾图像与其对应的传输透射率之间的映射关系。上述深度学习图像去雾算法在网络模型中采用最大池化等操作,容易造成透射率学习过程中部分细节丢失,从而影响去雾效果。

综上所述,针对传统去雾算法对于各种先验信息的依赖和深度学习算法对于雾图细节信息丢失的问题,本文提出了一种基于多尺度卷积神经网络(CNN)深度学习的单幅图像去雾方法,该方法通过学习雾天图像与大气透射率之间的映射关系实现图像去雾。在模型建立过程中,根据大气散射形成雾图的机理,设计了一个端到端的多尺度全 CNN 深度学习模型,首先通过卷积层运算提取有雾图像的浅层特征,接着利用多尺度卷积核并行提取得到雾图的深层特征,然后将浅层特征和深层特征进行跳跃连接融合,最后通过非线性回归得到雾图对应的透射率图特征。该算法最后根据深度学习得到大气透射率,通过计算得到大气光值,利用大气散射模型实现从有雾图像中恢复出无雾图像。通过与其他算法进行对比,可以发现本文提出的方法能够取得良好的去雾效果。

2 基本原理

2.1 大气散射模型

在计算机视觉和计算机图像中,通常使用大气散射物理模型来模拟雾天图像的退化过程^[15]。该模型认为引起观测成像图像降质(即雾图)的原因如下:太阳光等环境光受到大气中散射介质的散射作用形成背景光,以及目标物体自身受大气中悬浮粒子的吸收和物体自身散射作用,导致成像系统亮度降低,对比度下降,图像结果模糊不清,从而形成了雾图。大气散射物理模型空间表示如图 1 所示。该模型描绘了雾天图像的退化机制,可用数学模型表示为

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

式中: $I(x)$ 为成像设备获取到的有雾图像; $J(x)$ 为要恢复的无雾图像; A 为全局大气光值; $t(x)$ 为透射率; x 为图像的像素坐标。此外, $t(x)$ 还可以表示为

$$t(x) = \exp[-\beta d(x)], \quad (2)$$

式中: β 为介质消光系数; $d(x)$ 为物体到成像系统的距离,即场景深度。

对(1)式变形可以得到

$$J(x) = \frac{I(x) - A[1 - t(x)]}{t(x)}. \quad (3)$$

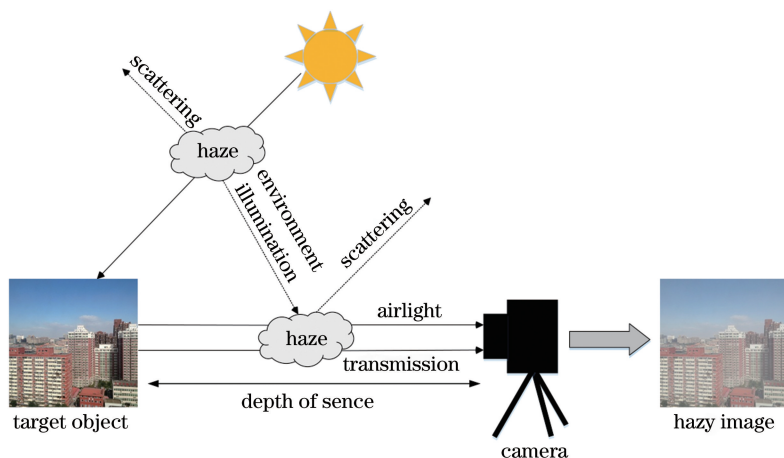


图 1 大气散射物理模型

Fig. 1 Physical model of atmospheric scattering

从(3)式中可以看出,目前已知的条件是 $I(x)$, 需要求得 $J(x)$ 。根据基本的代数知识可知, $t(x)$ 和 A 同时可变,这是一个有无数解的方程,只有在得知 $t(x)$ 和 A 先验信息的基础上才能求出定解。

2.2 CNN

CNN 是一类包含卷积计算且具有深度结构的前馈神经网络,是一种典型的深度学习网络。CNN 的本质是一个多层感知机,采用局部连接和权值共享等方式,一方面减少了传统神经网络权值的数量,使得网络易于优化,另外也降低了模型的复杂度,减少了过拟合的风险。近年来,随着高性能数值计算设备的出现以及深度学习理论的完善,CNN 得到了快速发展,并被大量应用于计算机视觉、自然语言处理等领域。CNN 在图像处理问题中有明显的优势,它可以将图像直接作为网络的输入,避免了传统图像处理算法中复杂的特征提取和数据重建过程。基本的 CNN 通常由卷积层和池化层组成,在卷积层中,通过卷积核的滑动来提取输入图像的不同特征,卷积操作后通过激活函数进行输出,然后再通过池化层缩小网络规模,降低计算复杂度,从而实现输入特征图的压缩。

3 本文方法

3.1 网络模型设计

在利用大气散射模型去雾的过程中,对于给定的一幅有雾图像,通常通过估算其透射率和大气光值来获得清晰的无雾图像。对于大气散射模型的去雾模型的求解,文中(3)式是一个不定解方程,传统的图像去雾算法,例如暗通道去雾算法需要对先验信息或假设条件进行约束后再求解,从

而达到图像去雾的效果。所谓暗通道是一个基本假设,这个假设认为,在绝大多数非天空的局部区域中,某一些像素总会有至少一个颜色通道具有很低的值。实际生活中造成这个假设的原因有很多,比如建筑物的阴影、颜色较暗的物体或者表面,这些景物的暗通道总是表现为比较暗的状态。传统图像去雾方法虽然取得了很大进步,但大部分算法依赖于各种先验信息或以假设条件为前提,具有一定的局限性。

为了克服传统大气散射模型去雾算法对先验知识的约束,根据有雾图像的特征图与透射率之间存在的非线性映射关系^[12],本文提出了一种基于多尺度的 CNN 去雾网络(MSDN)模型。通过对有雾图像特征图的不同特征进行多尺度提取,深度学习得到有雾图像与大气透射率之间的映射关系,从而克服了对图像去雾算法先验知识的制约,实现了去雾效果。本文提出的 MSDN 模型结构如图 2 所示,图中 Conv 表示卷积核。考虑到 CNN 对于图像去雾问题与传统 CNN 对于图像分类问题的差异性(在传统的 CNN 中包含池化层,通过最大池化或平均池化进行网络规模缩小,而图像去雾时需要保证深度学习训练后得到的大气透射率非常精细),为了避免池化操作对去雾图像透射率映射学习信息的丢失,MSDN 模型建立时采用全卷积方式,输入为有雾图像,输出为学习训练后的透射率图。MSDN 模型首先通过卷积操作进行特征提取得到有雾图像的浅层特征,然后进行卷积核大小分别为 3×3 、 5×5 、 7×7 的多尺度并行特征提取,得到深层特征,再将浅层特征和深层特征跳跃连接后进行卷积运算,最后经非线性回归得到透射率图。




图 2 MSDN 模型图

Fig. 2 MSDN model diagram

MSDN 模型中,浅层特征提取部分主要包括两个卷积层,作用是提取有雾图像的浅层特征,如图像的边缘等特征。为了减少模型的参数,简化模型复杂度,在两层卷积层中,每层都使用大小为 3×3 的卷积核,个数都设置为 10 个,采用多个较小的 3×3 卷积核不仅可以提取到雾图较多的浅层信息,还能够降低卷积操作的复杂性。此外,为了保证卷积后的特征图与原始雾图大小不发生变化,卷积时采用零填充操作。每层 10 个卷积核之间通过局部连接、权值共享的方式与输入图像进行运算,以实现特征的学习,卷积公式为

$$f_{n,l+1} = \sigma \left[\sum_m (f_{m,l} * k_{m,n,l+1}) + b_{n,l+1} \right], \quad (4)$$

式中: $*$ 表示卷积运算; m 和 n 为特征图的个数; l 表示第 l 个卷积层; $f_{n,l+1}$ 为第 $l+1$ 卷积层输出的 n 个特征图; $\sigma[\cdot]$ 为激活函数; $f_{m,l}$ 为第 $l+1$ 卷积层输入的 m 个特征图; $k_{m,n,l+1}$ 为第 $l+1$ 卷积层的卷积核; $b_{n,l+1}$ 为第 $l+1$ 卷积层的偏置项。在选择激活函数 $\sigma[\cdot]$ 时,采用改进的带参数的修正线性单元(PReLU)激活函数。选择 PReLU 激活函数的原因:传统的 Sigmoid 激活函数存在梯度弥散问题,即在神经网络反向传播过程中,都是通过微分的链式法则来计算各个权重 w 的微分,当反向传播经过多个 Sigmoid 函数后, w 对损失函数几乎没影响,这样不利于权重的优化,这种问题称为梯度饱和,也可以叫梯度弥散。相比于 Sigmoid 函数,PReLU 激活函数的优点是收敛速度更快,能够在一定程度上避免梯度弥散的发生。PReLU 激活函数与传统的 CNN 采用的修正线性单元(ReLU)激活函数不同,如图 3 所示。

PReLU 激活函数的表达式 X_{PReLU} 为




图 3 激活函数比较。(a) ReLU 激活函数;
(b) PReLU 激活函数

Fig. 3 Comparison of activation functions. (a) ReLU activation function; (b) PReLU activation function

$$X_{\text{PReLU}} = \max(x_i, 0) + a_i \min(0, x_i), \quad (5)$$

式中: x_i 为第 i 层的正区间输入信号; a_i 为第 i 层负区间的权系数,在 ReLU 激活函数中设置为 0,而在 PReLU 激活函数中作为可学习的参数。PReLU 激活函数克服了 ReLU 激活函数的“特征死亡”缺点,即 ReLU 神经网络的一个较大梯度值可能导致权重更新后该神经元接收到的任何数据点都不会再被激活,如果发生这种情况,之后通过该单位点的梯度将永远是零;而且当输入是负数时,ReLU 是完全不会被激活的,这就表明一旦输入负数,梯度就会完全为零。本文提出的 MSDN 模型中的激活函数采用 PReLU,它是针对 ReLU 的一个改进型激活函数。在负数区域内,PReLU 激活函数有一个很小的斜率,这样也可以避免 ReLU 激活函数出现“特征死亡”的问题。

通过前两层的卷积层操作后,特征提取得到的是输入图像的边缘等浅层特征,此外图像中还包含着很多深层的细节信息,如纹理等,这些深层信息仅仅依靠简单的卷积层特征提取无法得到。因此,为了进一步提取有雾图像的细节信息,本文在 MSDN

模型网络的第3层使用了3组不同大小的滤波器进行并行卷积运算,对大小分别为 3×3 、 5×5 、 7×7 的卷积核进行并行特征提取,以提取输入图像的深层特征,其中的卷积计算采用零填充方式。具体的多尺度特征提取卷积核参数如表1所示。

表1 多尺度特征提取卷积核参数表

Table 1 Parameter table of multi-scale feature extraction kernel

Type	Conv		
Filter size	3×3	5×5	7×7
Filter number	5	5	5
Pad	0	0	0
Stride	1	1	1

多尺度卷积操作的公式为

$$f_{n,l+1,q} = \sigma \left[\sum_m (f_{m,l} * k_{m,n,l+1,q}) + b_{n,l+1} \right], \quad (6)$$

式中: $f_{n,l+1,q}$ 为第 $l+1$ 卷积层通过不同多尺度卷积运算后输出的 n 个特征图; $k_{m,n,l+1,q}$ ($q=1,2,3$)表示多尺度卷积的3组不同大小的卷积核。每组卷积核运算后得到5个特征图,将每一组得到的特征图进行连接合并后共得到15个特征图。

为了取得较好的去雾效果,要求估算出的透射率必须精细,而单独的浅层特征或深层特征都无法达到此目标。本文MSDN模型中 \oplus 表示Concat跳跃连接操作,跳跃连接可以解决网络层数较深情况下梯度消失的问题,同时有助于梯度的反向传播,加快训练过程。在MSDN模型中首先对不同尺度卷积核提取到的特征进行Concat连接操作。为了得到较大感受野的多尺度提取后的细节特征,利用2个连续的 3×3 卷积层组成的小网络来代替单个的 5×5 卷积层堆叠的方式。这是因为 5×5 卷积核虽然有较大的感受野提取范围,但是其卷积核的参数有25个,而每个 3×3 卷积核的参数只有9个,采用堆叠后,2个连续的 3×3 卷积层与 5×5 卷积核具有同样的感受野范围,但其参数大幅减少,计算时间更加优化,而且网络容量加大,更多的卷积核的使用可以使得激活函数具有更好的特征提取能力。在本文MSDN模型中,为了将特征提取得到的浅层特征和多尺度提取得到的深层特征跳跃连接合并,继续通过Concat跳跃连接操作,然后再进行卷积操作,这样得到的特征图不仅包含了有雾图像的浅层特征,还包含了更多的细节信息,从而避免了在后续去雾过程中造成信息丢失。同理,为了获得较大的

跳跃连接后的雾图浅层和深层感受野的信息,在进行卷积操作时利用3个连续的 3×3 卷积层组成的小网络来代替单个的 7×7 卷积层堆叠,通过较小卷积核堆叠的形式在保持感受野范围的同时减少参数的数量。在雾图与透射率图映射过程中,由于特征图在输出前有多个通道,而模型最终需要的是单通道的透射率图,因此在模型最后一层采用非线性回归、使用 1×1 卷积核及应用PReLU激活函数来产生最终的输出。

3.2 损失函数

基于MSDN模型,通过深度学习得到有雾图像和透射率图之间的映射关系,使用均方误差作为损失函数,通过最小化损失函数来实现模型的训练。损失函数为

$$l_{\text{oss}}[t(x), t^*(x)] = \frac{1}{u} \sum_{i=1}^u \|t(x) - t^*(x)\|^2, \quad (7)$$

式中: $t^*(x)$ 为数据集中对应的透射率标签; u 为训练样本的数目。训练过程使用反向传播算法和0.9动量的梯度下降法来最小化损失值。输入图像的一次训练所选取的样本数为100,初始学习率设置为0.001,每10轮之后图像衰减一次,衰减率为0.99,迭代次数设置为100。

此外,为了使模型的泛化能力更强,需要避免过拟合现象的发生,因此在透射率图学习训练过程中使用了dropout方法,随机丢弃神经元的概率设置为0.5。

3.3 大气光计算

从(3)式中可得知,若要恢复清晰的无雾图像,除了需要计算出雾图场景透射率 $t(x)$ 之外,还需要计算出大气光值 A ^[14]。根据(1)式所示大气散射模型,当 $t(x)\rightarrow 0$ 时, $A=I(x)$;根据(2)式,当成像景深 $d(x)\rightarrow +\infty$ 时, $t(x)\rightarrow 0$ 。因此,通过在 $t(x)$ 中选择0.1%的最暗像素[即 $t(x)\rightarrow 0$ 的像素],然后在原始有雾图像 $I(x)$ 中寻找对应位置具有最高亮度的像素,即可计算得到 A 。

3.4 恢复无雾图像

在估算出 $t(x)$ 和 A 之后,恢复的无雾图像 $J(x)$ 可表示为

$$J(x) = \frac{I(x) - A}{\max[t_0, t(x)]} + A, \quad (8)$$

式中: t_0 是为了避免当求得的透射率过小时得出的去雾图像向白场过渡而设置的一个透射率下限,本文中取值为0.1^[7]。

3.5 算法步骤

本文提出的多尺度 CNN 去雾算法步骤为:1) MSDN 深度学习模型训练,利用该步骤可得到雾图与透射率图映射关系;2)网络模型测试,输入待去雾

图像,测试得到对应透射率 $t(x)$;3)通过原始雾图与透射率图,计算得到大气光值 A ;4)将上述值通过大气散射模型[(8)式]来恢复无雾图像。本文算法步骤如图 4 所示。

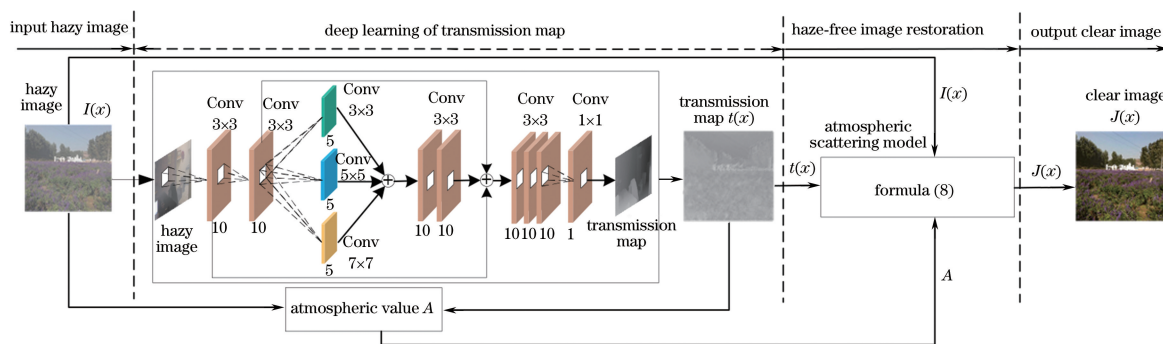


图 4 本文算法步骤

Fig. 4 Algorithmic steps in this paper

4 实验及结果分析

为了验证本文方法的有效性,从合成有雾图像和真实有雾图像两个方面进行了实验,并将本文算法与目前去雾效果较好的去雾方法(文献[7],[11-14])的去雾结果进行对比分析。实验在 Ubuntu 18.04 系统下进行,使用 Python 编程语言,应用 Tensorflow 深度学习框架搭建网络并通过编程实现本文算法,硬件环境为 Intel® Core™ i7-8750H CPU @ 3.60 GHz, 16.0 GB RAM, NVIDIA GeForce GTX 1060,对比实验的硬件配置环境与此相同。

4.1 训练数据集

本文网络模型需要有雾图像对应的透射率图作为训练标签,为了训练网络模型,本文选取了有雾图像 RESIDE 数据集^[16]的室内 ITS(Indoor Training Set)子数据集和 RESIDE-beta 室外 OTS(Outdoor Training Set)子数据集进行训练和测试,训练数据集如图 5 所示。其中室内 ITS 子数据集建立在

Middlebury 和 NYU-Depth-V2 数据集的基础上,包含了 13990 幅合成的室内有雾图像和对应的透射率图标签,如图 5(a)所示,该数据集通过光学模型合成有雾图像,介质消光系数的选取范围为 $\beta \in \{0.4, 0.6, 0.8, 1.0, 1.2, 1.4, 1.6\}$ 。OTS 数据集收集了 2061 幅真实的复杂户外场景及相应的深度图,包含了 72135 幅合成的室外有雾图像,介质消光系数的选取范围为 $\beta \in \{0.04, 0.06, 0.08, 0.10, 0.12, 0.16, 0.20\}$,结合消光系数对深度图进行预处理,得到的室外雾图与对应的透射率图标签如图 5(b)所示。在合理范围内随机选取的参数可以使生成的有雾图像更加多样化,更能体现出真实有雾图像中不同程度的雾,便于训练出泛化能力更强的网络模型。本文训练过程选取 ITS 和 OTS 数据集中 70% 的数据作为训练集,30% 的数据作为测试集。

4.2 合成有雾图像的实验结果

在合成有雾图像的实验中,部分实验结果如图 6 所示。图中显示:文献[7]方法有效去除了雾气,

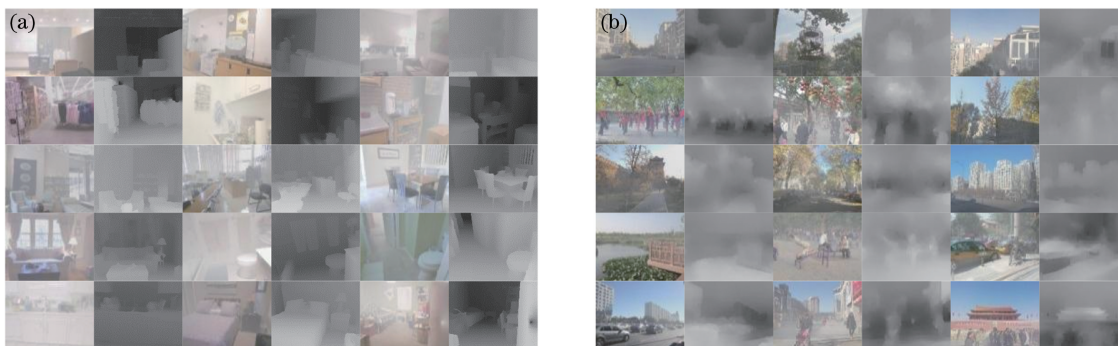


图 5 训练数据集。(a) ITS 室内数据集;(b) OTS 室外数据集

Fig. 5 Training data set. (a) Indoor data set ITS; (b) outdoor data set OTS

但是去雾图像整体亮度偏低,视觉效果不好;文献[11]方法的去雾图像亮度高于文献[7]方法,但是部分区域出现了颜色失真现象,如图6(d)第1幅图像中的地板部分;文献[12]方法的去雾图像亮度提高明显,但是部分区域仍出现了颜色失真问题,如图6(e)第5幅图像中的地面部分;文献[13]深度学习方法的去雾效果要优于文献[7]和文献[11]的传统

去雾方法,但是存在去雾不彻底的现象,如图6(f)第2幅图像中的床头区域;文献[14]方法整体效果良好,但是同样存在部分区域去雾不彻底的问题,如图6(g)第3幅图像中的红框内仍有残留的雾,图6(g)第4幅图像中床体部分去雾后雾气残留较多。本文提出的方法相比较于其他去雾方法,去雾效果良好,恢复图像的质量更高。




图6 合成有雾图像的实验结果。(a)有雾图像;(b)标准无雾图像;(c)文献[7]方法;(d)文献[11]方法;
(e)文献[12]方法;(f)文献[13]方法;(g)文献[14]方法;(h)本文方法

Fig. 6 Experimental results of synthesizing hazy images. (a) Hazy image; (b) standard haze-free image; (c) method in Ref. [7]; (d) method in Ref. [11]; (e) method in Ref. [12]; (f) method in Ref. [13]; (g) method in Ref. [14]; (h) proposed method

由于主观判断不能说明本文方法的有效性,因此进一步选取了结构相似性(SSIM)和峰值信噪比(PSNR)两个指标对实验结果进行数据分析。SSIM是一种衡量两幅图像相似度的指标,将去雾图像与真实标准无雾图像作比较,SSIM的值越大表明去雾图像的失真程度越小;PSNR是衡量图像质量的重要指标,是最大信号量与噪声强度的比值,PSNR的值越大表明去雾图像越接近于标准无雾图像。合成有雾图像的实验结果数据分析如表2所示。数据显示,本文方法去雾图像的PSNR值和SSIM值均高于文献[7]以及文献[11-14]中的方法,表明本文的去雾图像更接近于标准无雾图像,复原质量相对较高,由此验证了本文方法的有效性。

4.3 真实有雾图像的实验结果

为了验证本文模型对恢复真实有雾图像的有效

性,选择了8幅真实室外有雾图像进行了去雾实验,实验结果如图7所示。从图7中可以看出:对于文献[7]中的方法,当有雾图像中不含天空区域时,该方法能取得不错的去雾效果,但是亮度偏低,影响了整体的视觉效果;当有雾图像中含有大面积天空区域时,去雾图像的天空部分出现了不同程度的颜色失真现象,如图7(b)中的第3幅图像。文献[11]中的方法相比文献[7]中的方法亮度有所提升,但是当有雾图像中含有大面积天空时出现了颜色失真,如图7(c)中第2幅图像的框中区域。文献[12]中的方法的去雾效果良好,但是在天空部分出现了颜色过曝的现象,如图7(d)第5幅图像的框中天空部分。文献[13]中的深度学习方法相较于文献[7]和文献[11]的传统去雾方法,没有出现天空失真现象,但是在景深较远区域存在去雾不彻底的现象,如图

表 2 合成有雾图像的实验结果数据分析

Table 2 Analysis of experimental data of synthetic hazy images

Image No.	Method in Ref.[7]		Method in Ref.[11]		Method in Ref.[12]		Method in Ref.[13]		Method in Ref.[14]		Proposed method	
	PSNR / dB	SSIM / %	PSNR / dB	SSIM / %	PSNR / dB	SSIM / %	PSNR / dB	SSIM / %	PSNR / dB	SSIM / %	PSNR / dB	SSIM / %
1	23.5357	85.26	17.5424	59.51	20.1796	72.37	26.1247	85.33	22.9888	79.48	28.8218	86.41
2	19.3044	80.04	17.7552	72.36	21.6655	84.07	22.1977	88.70	20.7442	87.39	23.6027	91.66
3	17.8051	79.60	16.9521	72.87	20.3959	81.23	22.7414	89.35	19.0486	84.07	26.0691	89.73
4	20.1277	82.78	19.0534	79.38	21.5623	84.42	21.8444	86.42	19.4202	81.68	24.3402	91.60
5	20.2825	81.85	21.1444	82.85	17.8848	79.29	27.6081	93.54	25.4410	90.61	29.1285	94.78




图 7 真实室外有雾图像的实验结果。(a)有雾图像;(b)文献[7]方法;(c)文献[11]方法;(d)文献[12]方法;(e)文献[13]方法;(f)文献[14]方法;(g)本文方法

Fig. 7 Experimental results of real outdoor hazy images. (a) Hazy images; (b) method in Ref. [7]; (c) method in Ref. [11]; (d) method in Ref. [12]; (e) method in Ref. [13]; (f) method in Ref. [14]; (g) proposed method

7(e)中第2幅图像远处的房顶和图7(e)中第4幅图像远处的树林。文献[14]中的方法整体效果优于文献[13]中的方法,但是部分区域仍有残留的雾气和轻微的偏色现象,如图7(f)第5幅图像中的汽车部分有残留雾气,图7(f)中第6幅图像的地面部分有偏色现象。本文方法有效去除了图像中的雾气,没有出现天空失真现象,并且整体亮度适中,视觉效果良好。

为了进一步验证本文模型对于恢复室外有雾图像的有效性,选择了信息熵(IE)和平均梯度(AG)来

对实验结果进行数据对比分析。IE反映了图像包含信息量的大小,是衡量图像信息丰富程度的一个重要指标,IE值越大,表明图像越清晰;AG反映了图像微小细节反差变化的速率,表征图像的相对清晰程度,AG越大,图像层次越多,也就越清晰。室外有雾图像的实验结果数据分析如表3所示。从表中可以看出,本文方法的去雾图像在IE和AG方面的表现均优于其他对比方法,表明本文方法的去雾图像更加清晰,验证了本文方法对于室外有雾图像的有效性。

表3 室外有雾图像的实验结果数据分析

Table 3 Analysis of experimental data of outdoor hazy images

Image No.	Method in Ref.[7]		Method in Ref.[11]		Method in Ref.[12]		Method in Ref.[13]		Method in Ref.[14]		Proposed method	
	IE	AG	IE	AG	IE	AG	IE	AG	IE	AG	IE	AG
	1	7.0555	14.64	7.0652	18.34	7.3984	18.52	7.2445	17.22	7.4048	20.26	7.6821
2	7.5155	14.68	7.3049	17.04	7.8192	18.83	7.4186	13.93	7.6656	17.02	7.9266	18.99
3	7.3427	8.48	7.4737	10.89	7.8771	11.78	7.7043	8.62	7.6120	9.21	7.8935	12.08
4	7.5688	9.18	7.4250	11.93	7.8515	13.23	7.7608	9.62	7.7786	10.57	7.9815	14.31
5	7.2538	14.91	7.7213	18.17	7.3410	17.93	7.1746	10.43	7.3776	13.62	7.8690	19.41
6	7.1667	8.92	7.8371	10.40	7.7168	10.18	7.0263	7.85	7.2862	8.76	7.8937	10.47
7	7.2625	10.94	7.1136	12.96	7.6834	13.71	7.3200	8.67	7.5189	9.59	7.7274	14.06
8	6.2721	5.88	7.1459	7.32	7.3561	7.55	6.8363	5.97	6.9818	6.39	7.4534	7.57

4.4 运行时间

上述两部分实验结果已经验证了本文方法的有效性,为了进一步验证本文方法在效率上的表现,通过对上述室内有雾图像和室外有雾图像的实验时间进行统计,得到了不同方法的平均运行时间,如表4所示。从表中可以看出:本文方法的运行速度明显快于文献[7]和文献[11]中的传统去雾方法;与文献[12-14]中的深度学习去雾方法相比,本文方法在运行速度上也有优势。

表4 不同实验图像的算法运行时间

Table 4 Running time of different algorithms for experimental images

Method	Experiment	
	Indoor	Outdoot
Method in Ref.[7]	6.87	6.89
Method in Ref.[11]	3.41	3.65
Method in Ref.[12]	1.96	2.08
Method in Ref.[13]	1.21	1.26
Method in Ref.[14]	1.58	1.92
Proposed method	1.09	1.18

5 结 论

针对传统去雾方法需要依靠先验条件和人工提取雾的相关特征,从而导致的天空失真、对比度低等去雾效果稳定性差的问题,提出了一种基于深度学习的多尺度CNN的单幅图像去雾方法。设计了一个端到端的全CNN模型,提出了一种基于深度学习的图像去雾算法,即通过学习雾天图像与大气透射率之间的映射关系实现图像去雾。首先通过卷积层运算提取得到有雾图像的浅层特征,再通过多尺度卷积核运算映射得到有雾图像深层的不同细节特征,接着将浅层特征和深层特征进行跳跃连接融合,再经非线性回归得到雾图对应的透射率图特征,并采用雾图数据集对该模型进行训练。利用训练好的模型对室内和真实不同场景下待去雾图像进行了多种测试,获得了清晰的无雾图像。实验结果表明,本文提出的方法克服了传统单幅图像去雾算法容易受到雾图先验知识制约、对比度低的缺点,能够有效识别雾霾相关特征,增强视觉对比度,得到清晰的无雾图像,提高图像的质量和视觉效果,且能应用于实

际,为图像的后续处理提供良好的基础。下一步准备开展的工作是如何优化去雾模型,从而获得更好的去雾效果。

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] Xu Y, Wen J, Fei L K, *et al.* Review of video and image defogging algorithms and related studies on image restoration and enhancement [J]. *IEEE Access*, 2016, 4: 165-188.
- [3] Ma R Q, Zhang S J. An improved color image defogging algorithm using dark channel model and enhancing saturation [J]. *Optik*, 2019, 180: 997-1000.
- [4] Liu D M, Chang F L. Coarse-to-fine saliency detection based on non-subsampled contourlet transform enhancement [J]. *Acta Optica Sinica*, 2019, 39(1): 0115003.
刘冬梅, 常发亮. 基于非下采样轮廓小波变换增强的从粗到精的显著性检测 [J]. *光学学报*, 2019, 39(1): 0115003.
- [5] Ancuti C O, Ancuti C. Single image dehazing by multi-scale fusion [J]. *IEEE Transactions on Image Processing*, 2013, 22(8): 3271-3282.
- [6] He L Y, Zhao J Z, Zheng N N, *et al.* Haze removal using the difference-structure-preservation prior [J]. *IEEE Transactions on Image Processing*, 2017, 26(3): 1063-1075.
- [7] 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, June 20-25, 2009, Miami, FL, USA. New York: IEEE, 2009: 1956-1963.
- [8] He K M, Sun J, Tang X O. Guided image filtering [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(6): 1397-1409.
- [9] Jiang J L, Sun W, Wang Z D, *et al.* Integrated enhancement algorithm for hazy image using transmittance as weighting factor [J]. *Journal of Electronics & Information Technology*, 2018, 40(10): 2388-2394.
江巨浪, 孙伟, 王振东, 等. 基于透射率权值因子的雾天图像融合增强算法 [J]. *电子与信息学报*, 2018, 40(10): 2388-2394.
- [10] Lu H B, Zhao Y F, Zhao Y J, *et al.* Image defogging based on combination of image bright and dark channels [J]. *Acta Optica Sinica*, 2018, 38(11): 1115004.
卢辉斌, 赵燕芳, 赵永杰, 等. 基于亮通道和暗通道结合的图像去雾 [J]. *光学学报*, 2018, 38(11): 1115004.
- [11] Meng G F, Wang Y, Duan J Y, *et al.* Efficient image dehazing with boundary constraint and contextual regularization [C]//2013 IEEE International Conference on Computer Vision, December 1-8, 2013, Sydney, Australia. New York: IEEE, 2013: 617-624.
- [12] 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, June 23-28, 2014, Columbus, OH, USA. New York: IEEE, 2014: 2995-3002.
- [13] 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.
- [14] Ren W Q, Liu S, Zhang H, *et al.* Single image dehazing via multi-scale convolutional neural networks [M]//Leibe B, Mata S, Sebe N, *et al.* *Lecture notes in computer science*. Cham: Springer, 2016, 9906: 154-169.
- [15] Cox L J. Optics of the atmosphere-scattering by molecules and particles [J]. *Optica Acta: International Journal of Optics*, 1977, 24(7): 779.
- [16] Li B Y, Ren W Q, Fu D P, *et al.* RESIDE: a benchmark for single image dehazing [J/OL]. (2018-08-27) [2019-03-10]. <https://arxiv.org/abs/1712.04143v1>.