

基于双域分解的多尺度深度学习单幅图像去雾

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 针对传统单幅图像去雾算法容易受到雾图先验信息制约而导致颜色失真,以及现有深度学习去雾算法受网络模型限制而存在去雾残留等问题,提出了一种基于双域分解的多尺度深度学习单幅图像去雾方法,设计了一个包含低频去雾子网和高频去雾子网的多尺度深度学习网络模型。首先采用双边滤波器对有雾图像进行分解,得到雾图的高、低频子图,然后通过设计的网络模型分别学习雾图高、低频子图与高、低频透射率之间的映射关系,再将模型学习得到的高、低频透射率进行融合,得到原始雾图对应的场景透射率图,最后根据大气散射模型实现有雾图像到无雾图像的恢复,采用雾图数据集对该模型进行训练测试。结果表明,所提方法在合成有雾图像和真实自然雾图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方面均优于其他对比算法。

关键词 图像处理; 图像增强; 图像去雾; 双域分解; 多尺度卷积神经网络; 大气散射模型

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/AOS202040.0210003

Single Image Dehazing of Multiscale Deep-Learning Based on Dual-Domain Decomposition

Chen Yong*, Guo Hongguang, Ai Yapeng

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

Abstract The traditional single image dehazing algorithms are susceptible to the prior information of hazy images, resulting in color distortion. Furthermore, the deep-learning dehazing algorithms are limited by the network model, leading to residual haze. To overcome these problems, this study proposes a single image dehazing method of multiscale deep-learning based on dual-domain decomposition. This method develops a multiscale deep-learning network model that includes low- and high-frequency dehazing subnets. Firstly, the hazy image is decomposed using bilateral filters to obtain high- and low-frequency sub-images of the hazy image. Subsequently, the mapping relations between the high- and low-frequency sub-images as well as the high- and low-frequency transmissivity of the hazy image are learned using the developed network model. The high- and low-frequency transmissivity obtained by model learning is fused to obtain the scene transmissivity of the original hazy image. Finally, the hazy image is restored to the dehazed image based on the atmospheric scattering model, which is trained and tested using the hazy image dataset. The experimental results denote that the proposed method can achieve a good dehazing effect for the synthetic hazy images and real natural hazy images and that it is superior to other contrast algorithms in subjective and objective evaluations.

Key words imaging processing; image enhancement; image dehazing; dual-domain decomposition; multiscale convolution neural network; atmospheric scattering model

OCIS codes 100.2980; 010.1310; 330.4060

1 引 言

雾是自然界中一种常见的天气现象。在雾天场景下,空气中的水汽凝结成大量的细微水滴悬浮于

空气中,这些水滴会对光的传播产生散射和折射作用,从而导致各种成像系统获得的图像质量严重劣化,图像的视觉效果受到了严重影响。图像主要表现为颜色偏灰白色,色彩饱和度、对比度降低,细节

收稿日期: 2019-08-08; 修回日期: 2019-09-04; 录用日期: 2019-09-23

基金项目: 国家自然科学基金(61841303,61963023)、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

不够突出,不利于图像特征的提取和辨识,导致各种依赖于成像系统的设备难以发挥作用,进而增大了对图像进行后续处理的难度^[1]。因此,对雾天场景下获得的退化图像进行去雾处理,改善图像的可视化质量,具有重要的现实意义和应用前景^[2]。

目前传统的单幅图像去雾方法主要分为两类:一类是基于非物理模型的图像增强方法,另一类是基于物理模型的图像复原方法。基于非物理模型的图像增强方法主要通过增强退化图像的整体或局部特征来提升图像的饱和度和对比度,从而在一定程度上改善图像的质量,但该类方法并不是真正意义上的图像去雾。这类算法包括基于 Retinex 理论的方法、基于直方图均衡化的方法^[3-5]等。基于物理模型的图像复原方法基于大气散射物理模型在各种先验知识的约束下,通过求解物理模型得到清晰的图像。He 等^[6-7]提出了基于暗原色先验知识统计的方法,该方法通过图像的暗通道先验信息来求解大气散射模型,取得了较好的图像去雾效果,但是当目标场景存在大面积天空区域时,该方法恢复出的图像容易出现颜色失真;此外,该算法使用软抠图方法,运算量较大。苏畅等^[8]提出了基于暗通道图像质心偏移量的去雾算法,采用 K 均值算法对雾天图像暗通道进行聚类分析,计算每个场景暗通道图像的质心偏移量,用于场景的透射率修正,但是该方法存在去雾效果受聚类个数设置影响的问题。Meng 等^[9]提出了一种基于边界约束的图像去雾方法,该方法较好地解决了去雾图像对比度低的问题,但是去雾图像部分区域会出现颜色失真的现象。郭翰等^[10]针对暗原色去雾时天空区域处理存在的“halo”现象,采用导向滤波的方法对透射率进行修复,但滤波半径对该算法的影响较大,部分去雾结果存在颜色过饱和及去雾不足的情况。

近年来,深度学习的快速发展引起研究人员的广泛关注,越来越多的研究人员开始研究基于深度学习的图像去雾问题^[11-13]。如:Cai 等^[11]利用卷积神经网络(CNN)学习雾图与透射率之间的映射关系,通过多尺度映射和最大池化等操作来学习雾霾特征,以实现单幅雾图的去雾;Ren 等^[12]提出了一种由粗尺度网络到细尺度网络的模型来学习估计透射率方法,以实现去雾;Li 等^[13]提出了一种将透射率与大气光值进行结合估计的卷积神经网络去雾方法。上述深度学习算法在进行透射率学习过程中,基本上都是从整幅有雾图像中进行透射率的特征学习,在学习过程中忽略了有雾图像本身结构信

息和纹理信息的差异性,导致学习过程中存在较大的盲目性;此外,模型中的池化操作会造成信息丢失等问题,导致去雾不彻底,部分区域仍有残雾。

针对以上问题,本文提出了一种基于双域分解的多尺度深度学习单幅图像去雾方法。首先对待去雾图像进行双域分解变换,将雾图进行分解,得到低频子图(图像的平坦区域)和高频子图(图像的纹理和轮廓边缘等)两部分,然后设计了一个包含低频去雾子网和高频去雾子网的多尺度深度学习模型,其中低频去雾子网用于实现对雾图分解后的低频子图与低频透射率之间的映射关系学习,高频去雾子网用于实现有雾图像高频子图与高频透射率之间的映射关系学习,将模型学习得到的高、低频透射率进行融合,得到原始雾图对应的透射率图特征,最后根据双域分解深度学习得到的大气场景透射率,利用大气散射模型实现有雾图像到无雾图像的恢复;最后基于预处理后的雾图数据集进行模型的训练和测试。

2 基本原理

2.1 大气散射模型

根据雾天条件下发生的光的散射现象,研究人员通常使用大气散射物理模型来模拟雾天退化图像的形成过程,该模型是复原清晰图像的重要依据^[14]。根据大气散射模型可知,太阳光等环境光受到大气中散射介质的散射作用形成了背景光,导致图像质量降低,形成了雾图;此外,目标物体本身受大气中悬浮粒子的吸收和物体本身散射作用,导致光能的亮度、颜色等特性发生改变,造成视觉成像系统所捕获的场景图像的对比度下降,颜色和分辨率等特征衰减明显,成像结果模糊不清,从而形成雾图。大气散射物理模型如图 1 所示。

大气散射物理模型描绘了雾图的形成过程,该模型的数学表达式为

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

式中: $\mathbf{I}(x)$ 为成像设备获取的有雾图像; x 为图像中的像素点; $\mathbf{J}(x)$ 为需要恢复的无雾图像; $t(x)$ 为场景透射率; \mathbf{A} 为全球大气光值。(1)式由两部分组成: $\mathbf{J}(x)t(x)$ 为入射光衰减模型,描述了光从场景点到观测点的削弱衰减过程; $\mathbf{A}[1 - t(x)]$ 为大气光成像模型,描述了周围环境中各种光因大气粒子的散射作用而对观测点所接收到的光强的影响。此外, $t(x)$ 可表示为

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

式中: β 为介质消光系数; $d(x)$ 为物体到成像系统




图 1 大气散射物理模型

Fig. 1 Physical model of atmospheric scattering

的距离,即场景深度。

为了明确恢复清晰图像 $J(x)$ 的过程,对(1)式进行变形,得到

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

对于(3)式,已知条件为有雾图像 $I(x)$,需要求解出无雾图像 $J(x)$ 。根据代数知识可知,这是一个不定方程,只有在场景透射率 $t(x)$ 和全球大气光值 A 先验信息的基础上才能求出定解。

2.2 卷积神经网络

卷积神经网络是一种深度学习模型或类似于人工神经网络的多层感知器^[15],所采用的局部感知、权值共享和池化技术等方面减少了权值的数量,使网络易于优化,另一方面降低了网络的复杂性,常被应用于分析视觉图像等。基本的卷积神经网络通常主要由卷积层和池化层等组成,在卷积层通过滑动窗口卷积核进行计算,然后通过激活函数非线性变换等操作来提取输入图像的不同特征。卷积神经网络在图像特征提取时可以提取到更深层次、更抽象的特征,使得网络对图像信息具有更高、更准确的分辨能力。根据(3)式可知,有雾图像采用卷积神经网络去雾的最终目的是从有雾图像 $I(x)$ 求解出无雾图像 $J(x)$,因此在已知有雾图像 $I(x)$ 的前提下,需要利用卷积神经网络模型,对有雾图像和对应的场景透射率 $t(x)$ 与全球大气光值 A 之间的特征关系进行学习,从而估计出场景透射率 $t(x)$ 和全球大气光值 A ,最后通过(3)式实现对有雾图像的恢复。为了训练估计透射率的卷积神经网络模型,一般使用包含有雾图像和对应透射率特征图的数据集进行网络模型训练。网络模型测试时可以直接由雾图估计得到对应的透射率图,从而实现雾图的清晰化。

3 基于双域分解的多尺度深度学习单幅图像去雾模型

3.1 网络模型设计

根据图像退化大气散射物理模型,图像去雾的首要任务是计算出有雾图像的场景透射率。传统的去雾方法需要建立在一定的先验信息或假设条件的基础上,并且当有雾图像中含有大面积天空或者白色物体时,这些区域不包含强度值趋于0的暗通道,因此不能满足暗通道理论的先验条件,导致暗通道先验去雾算法失效,致使去雾图像出现颜色失真现象。

为了解决传统去雾方法受先验信息制约,以及现有深度学习去雾方法学习过程存在盲目性等问题,本文提出了一种基于双域分解的多尺度深度学习单幅图像去雾模型,如图2所示。其中 $t_L(x)$ 为低频子网络学习到的低频透射率, $t_H(x)$ 为高频子网络学习到的高频透射率。该深度学习去雾模型主要包含两个透射率特征提取子网络,即:用于低频透射率特征学习的低频去雾子网和用于高频透射率特征学习的高频去雾子网。通过对雾图进行分解变换得到雾图的高频子图和低频子图,然后采用不同的子网络进行透射率学习特征提取,深度学习得到有雾图像与场景透射率之间的映射关系,从而克服了图像去雾算法受先验知识制约的不足,实现了去雾。采用图2所示的低频子网和高频子网并行学习的原因是在现有深度学习单幅图像去雾过程中,常用的方法将整幅有雾图像输入到深度学习模型中进行透射率学习、卷积串联操作和池化操作等,但是在学习过程中忽略了有雾图像自身结构信息和纹理信息的差异性,在透射率学习过程中对雾图组成信息不加

区分地进行透射率特征提取,导致学习过程中有较大的盲目性。此外,在雾图退化成像过程中,大气散射效应主要对雾图大片平坦区域即低频信息产生较大影响^[16]。针对上述问题及特点,本文采用对雾图高、低频信息分离的深度学习方式进行特征提取。在对雾图进行高、低频分解后,对于雾图的低频部分,由于该区域是受大气散射影响较大的区域,因此为了得到较精细的低频透射率学习效果,在低频去

雾子网络中采用较小的 3×3 卷积核进行精细化低频透射率特征提取;雾图的高频部分主要为图像边缘等信息,相比于低频透射率提取,该区域受大气散射物理模型退化的影响较小,因此建立雾图高频子图与高频透射率之间映射关系学习模型时,在高频去雾子网络中采用较大的 5×5 卷积核进行透射率特征提取,最后通过模型学习进行高、低频透射率的融合,得到原始有雾图像对应的场景透射率图。

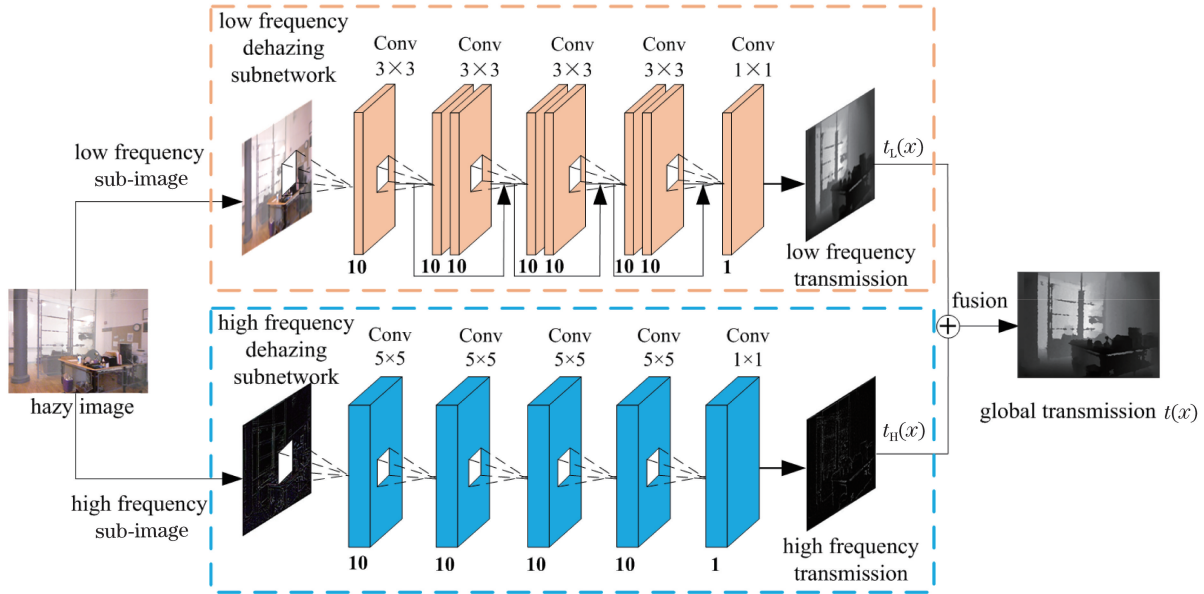


图 2 基于双域分解的多尺度深度学习单幅图像去雾模型

Fig. 2 Schematic of single image dehazing model of multiscale deep-learning based on dual-domain decomposition

3.2 雾图双域分解

在对雾图进行高、低频分解时,本文借鉴双域降噪(DDID)的思想^[17],使用双边滤波器(BF)将有雾图像分解为低频子图和高频子图。图像分解后的高频和低频是对图像各个位置之间强度变化的一种度量方法,其中低频子图主要是对整幅图像强度的综合度量,代表图像中亮度或者灰度值变化缓慢的区域,也就是图像中大片平坦的区域,描述了图像的主要部分;而高频信息主要是图像边缘和轮廓的度量,对应图像变化剧烈的部分,也就是图像的边缘、轮廓等纹理部分。

双边滤波器是一种非线性滤波器,由传统的高斯滤波改造而来,可以达到保持边缘和降噪的效果。传统的高斯滤波在进行采样时主要考虑了像素间的空间距离关系,并没有考虑像素值之间的相似程度。双边滤波器由两个函数构成,一个函数由几何空间距离决定滤波器系数,另一个函数由像素差值决定滤波器系数^[17]。双边滤波的改进就在于采样时不仅考虑像素在空间距离上的关系,还考虑像素间的

相似程度,因而可以保持原始图像的大体分块和边缘。双边滤波器的表达式为

$$f_{LP} = \frac{\sum_{q \in N_p} k_{p,q} f_q}{\sum_{q \in N_p} k_{p,q}}, \quad (4)$$

其中,

$$k_{p,q} = \exp\left(-\frac{|p-q|^2}{2\sigma_s^2}\right) \exp\left[-\frac{(f_p-f_q)^2}{\gamma_r \sigma^2}\right], \quad (5)$$

式中: f_{LP} 为双边滤波器输出的 p 点的灰度值; q 为方形窗口 N_p 中除 p 之外的其他像素点; f_p 为 p 点的像素值; f_q 为 q 点的像素值; N_p 为中心是 p 、半径是 r 的方形窗口; p, q 为点向量; $k_{p,q}$ 为在 N_p 内定义的双边滤波器核函数; σ_s 为对应核函数的空域参数; γ_r 为对应核函数的像素值域参数; σ^2 为噪声方差。

在本文中,有雾图像 $I(x)$ 经过双边滤波器分解后得到了对应的低频子图 $I(x)_L$ 和高频子图 $I(x)_H$, 即

$$\begin{cases} \mathbf{I}(x)_L = \sum_{q \in N_p} f_{LP} \\ \mathbf{I}(x)_H = \mathbf{I}(x) - \mathbf{I}(x)_L \end{cases}. \quad (6)$$

一幅原始雾图经过双边滤波后就可得到对应的高频子图和低频子图,如图 3 所示。




图 3 原始图像及其高、低频子图。(a)原始图像;(b)高频子图;(c)低频子图

Fig. 3 Original image and its high- and low-frequency sub-images. (a) Original image; (b) high-frequency sub-image; (c) low-frequency sub-image

3.3 网络模型结构

本文提出的基于双域分解的多尺度深度学习单幅图像去雾模型主要包含低频透射率特征学习的低频去雾子网络和高频透射率特征学习的高频去雾子网络。结合雾气一般存在于有雾图像低频部分的特点^[16],本文设计了如图 2 上部虚线框内所示的低频去雾子网络模型。在图 2 所示的低频子网络中,以有雾图像的低频子图作为输入,以对应的低频透射率作为输出。有雾图像的低频子图通常指大片色块区域,该区域为图像的主体部分,需要模型有较小的感受野,更有效地学习低频信息,因此低频子网络通过 3×3 卷积核的感受野进行低频透射率特征学习。为了减少模型参数,每层都使用 3×3 卷积核,个数为 10。采用多个较小的 3×3 卷积核一方面可以学习到更多的低频透射信息,另外一方面降低了卷积操作的复杂性。此外,为了进一步提高雾图低频子图透射率学习的精度,在低频子网络学习过程中使用全卷积方式,并且引入残差网络思想^[18]。残差网络可以通过旁路的支线将输入直接连到后面的层,使后面的层可以直接学习残差,这种结构被称为 shortcut 连接。残差块通过 shortcut 连接的方式直接将输入信息绕道输出,保护了信息的完整性。shortcut 连接相当于简单执行了同等映射,不会产生额外的参数,也不会增加计算复杂度。这种残差跳跃式的结构可以提高透射率学习的精度。低频子网络通过 3×3 卷积核和连续的 3 个残差单元,实现了对低频透射率特征的学习,最后使用 1×1 卷积核进行非线性回归,就可以得到有雾图像低频子图对应的低频透射率图。

高频子网络学习的是有雾图像的边缘、轮廓等

信息,本文设计了如图 2 下部虚线框所示的高频去雾子网络模型。该模型以有雾图像的高频信息作为输入,以对应的高频透射率作为输出。对于高频边缘及轮廓信息,模型采用较大的感受野进行特征学习,通过使用 5×5 卷积核来扩大模型的感受野。同样,为了避免特征学习过程中池化操作造成的信息丢失,高频子网模型也采用全卷积方式,通过连续 4 层 5×5 卷积核卷积的方式,逐步提取有雾图像的高频透射率特征,每层卷积核个数设置为 10。最后通过一个 1×1 卷积核进行非线性回归,得到有雾图像高频子图对应的高频透射率图。

在本文所提出网络模型的卷积操作中,为了保证卷积后的特征图与输入图像的大小不发生变化,卷积采用零填充操作。卷积方式为

$$f_{n,l+1} = \sigma' \left[\sum_m (f_{m,l} * k_{m,n,l+1}) + b_{n,l+1} \right], \quad (7)$$

式中: m 和 n 为特征图的个数; $f_{n,l+1}$ 为第 $l+1$ 个卷积层输出的第 n 个特征图; σ' 为激活函数; $f_{m,l}$ 为第 $l+1$ 卷积层输入的第 m 个特征图; $k_{m,n,l+1}$ 为第 $l+1$ 层的卷积核; $b_{n,l+1}$ 为第 $l+1$ 层的偏置项; $*$ 表示卷积运算。在本文提出的基于双域分解的多尺度深度学习单幅图像去雾模型中,激活函数使用带参数的修正线性单元(PReLU)函数。PReLU 函数是对 ReLU 函数的改进。相对于 ReLU 函数,PReLU 函数在负数区域内的斜率很小,这样能够在一定程度上避免梯度弥散和“特征死亡”问题的发生,并且 PReLU 函数收敛更快。PReLU 激活函数与 ReLU 激活函数的对比如图 4 所示,其中, a 为学习参数, y 为激活函数输入值, $f(y)$ 为激活后的输出值。

如图 4(b)所示,PReLU 函数 x_{PReLU} 为

$$x_{\text{PReLU}} = \max\{x_i, 0\} + a_i \min\{0, x_i\}, \quad (8)$$




图 4 激活函数对比。(a) ReLU 函数;(b) PReLU 函数

Fig. 4 Comparison of activation functions.

(a) ReLU function; (b) PReLU function

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。当 $a_i = 0$ 时, PReLU 激活函数退化为 ReLU 激活函数。在 PReLU 中, a_i 作为可学习参数, 采用带动量的方式进行更新, 初始值一般取为 $0.25^{[19]}$ 。PReLU 激活函数克服了 ReLU 激活函数“特征死亡”的缺点。从图 4(a) 中可以看出, 如果 $y \leq 0$, 即 ReLU 的输出为 0, ReLU 函数是完全不被激活的, 那么反向传播中的梯度也为 0, 此时权重不会被更新, 导致神经元不再学习, 出现“特征死亡”问题。PReLU 函数在负数区间有一个很小的斜率, 可以避免 ReLU“特征死亡”的问题。

3.4 损失函数

本文提出的基于双域分解的多尺度深度学习单幅图像去雾模型需要学习的是有雾图像高、低频子图与其对应的高、低频透射率图之间的映射关系, 因此需要对比学习得到的高、低频透射特征图与标签中的高、低频透射率图, 从而计算损失函数值。损失函数使用均方误差 (MSE), 模型的训练通过最小化损失函数来实现。低、高频去雾子网络计算的损失函数值分别为

$$\text{loss}[t_L(x), t_L^*(x)] = \frac{1}{u} \sum_{m=1}^u \|t_L(x) - t_L^*(x)\|^2, \quad (9)$$

$$\text{loss}[t_H(x), t_H^*(x)] = \frac{1}{u} \sum_{m=1}^u \|t_H(x) - t_H^*(x)\|^2, \quad (10)$$

式中: $t_L(x)$ 、 $t_H(x)$ 分别为低频子网络学习到的低频透射率和高频子网络学习到的高频透射率; $t_L^*(x)$ 、 $t_H^*(x)$ 分别为数据集中对应的低、高频透射率标签; u 为训练样本的个数。在训练过程中, 使用反向传播算法和动量为 0.9 的梯度下降法来最小化 MSE 值, 从而调整网络模型的参数。模型训练参数 Batchsize 设置为 64, 初始学习率设置为 0.001, 每 10 轮后衰减 1 次, 衰减率为 0.99, 迭代周期 epoch

设置为 100。

3.5 高、低频透射率的融合

由于本文设计的网络模型对有雾图像的高频子图和低频子图分别进行训练, 因此得到的对应透射率分别是高频透射率和低频透射率。为了得到原始有雾图像所对应的场景透射率, 将深度学习得到的高、低频透射率进行融合操作。具体融合方式如下: 首先将高、低频透射率在频域内进行相加, 然后由傅里叶逆变换得到融合后的原始有雾图像对应的场景透射率, 即

$$t(x) = \mathcal{F}^{-1}[t_L(x) + t_H(x)], \quad (11)$$

式中: \mathcal{F}^{-1} 为傅里叶逆变换, 可将融合后的透射率变换到时域。

3.6 大气光估计与无雾图像恢复

根据大气散射物理模型, 如果恢复清晰的无雾图像, 不仅需要雾图像对应的场景透射率, 还需要大气光值 A 作为计算条件。根据 (1) 式, 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, 通过在场景透射图 $t(x)$ 中选择透射率大小为前 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, 计算得到大气光值 A 。

至此, 已获得求解大气散射模型所需的全部条件, 最后进行无雾图像的恢复, 即

$$J(x) = \frac{I(x) - A}{\max\{t_0, t(x)\}} + A, \quad (12)$$

式中: t_0 为计算出的无雾图像 $J(x)$ 向白场过渡而设置的场景透射率下限, 可以避免计算出的场景透射率 $t(x)$ 过小的现象, 本文中 t_0 取值为 0.1^[6]。

3.7 算法步骤

本文提出的基于双域分解的多尺度深度学习单幅图像去雾算法如图 5 所示, 具体步骤如下:

- 1) 对有雾图像及对应场景透射率进行双边滤波器分解, 得到对应的高、低频雾图数据集和高、低频透射率标签数据集;
- 2) 使用处理后的数据集对网络模型进行训练, 得到有雾图像高、低频子图与对应高、低频透射率之间的映射关系;
- 3) 测试网络模型, 输入有雾图像, 得到对应的高频透射率 $t_H(x)$ 和低频透射率 $t_L(x)$;
- 4) 将测试得到的高频透射率 $t_H(x)$ 和低频透射率 $t_L(x)$ 进行融合, 得到原始图像对应的场景透射率 $t(x)$;
- 5) 通过原始雾图与场景透射率图计算得到大

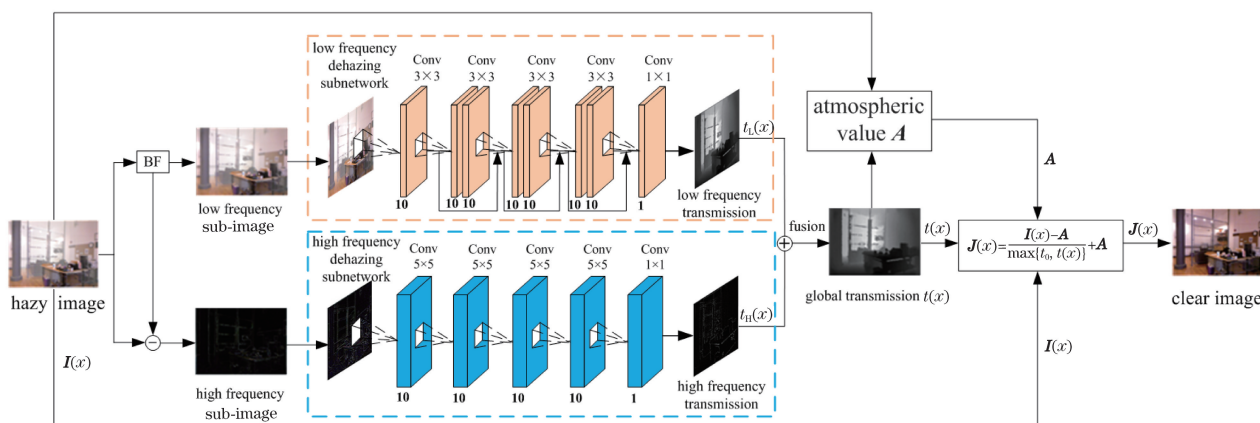


图 5 基于双域分解的多尺度深度学习单幅图像去雾算法

Fig. 5 Schematic of single image dehazing algorithm of multiscale deep-learning based on dual-domain decomposition

气光值 A ;

6) 通过大气散射模型(12)式恢复无雾图像。

4 实验结果与分析

为了验证本文方法的有效性,选择合成有雾图像与真实有雾图像进行相关实验,并与 He 等^[6]方法、Meng 等^[9]方法、Cai 等^[11]方法、Ren 等^[12]方法、Li 等^[13]方法的实验结果进行主观效果对比和客观数据分析。实验运行环境为 Ubuntu 18.04 操作系统,编程语言为 Python,使用 Tensorflow 深度学习框架搭建网络模型并编程实现,硬件配置为 Intel(R) Core(TM) 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相同。

4.1 训练数据集预处理

现有的去雾深度学习网络将整幅有雾图像输入到深度学习模型中进行透射率学习,与此不同的是,本文提出的基于双域分解的多尺度深度学习单幅图像去雾模型以有雾图像的高频子图和低频子图分别作为模型的输入,并以透射率图的高频子图和低频子图分别作为标签进行反向传播运算。本文使用 RESIDE 雾图数据集的 RESIDE-beta 室外训练集 OTS(outdoor training set)预处理后进行训练和测试^[20],OTS 收集了 2061 幅真实的复杂户外场景及相应的深度图,包含 72135 幅合成的室外有雾图像,介质消光系数的选取范围为 $\beta \in \{0.04, 0.06, 0.08, 0.10, 0.12, 0.16, 0.20\}$,结合消光系数将深度图进行预处理后,得到室外雾图与对应的场景透射率图标签,如图 6 所示。为了得到有雾图像以及透射率图的高、低频信息,本文首先将有雾图像数据集及其场景透射率图进行双边滤波,得到对应的高、低频雾图

数据集和高、低频透射率标签数据集,然后将预处理得到的高、低频雾图数据集分别作为网络模型的输入进行模型训练。训练过程中选取高、低频雾图数据集中 70% 的数据作为训练集,30% 的数据作为测试集。

4.2 合成有雾图像实验

为了验证本文方法对合成有雾图像的有效性,选取部分合成有雾图像进行对比实验,结果如图 7 所示。从图 7(c)中可以看出,对于不含大面积天空的合成有雾图像,He 等^[6]的方法能够取得较好的去雾效果,基本没有出现颜色失真现象,但是去雾图像的对比度较低,影响图像整体的视觉效果。从图 7(d)中可以看出,Meng 等^[9]的方法相对于其他几种去雾方法,去雾图像较清晰,对比度较高,但是大部分去雾图像出现了不同程度的偏色问题,影响了图像的质量,例如图 7(d)从上向下数第 3 张图片中地板区域,以及第 4 张图片中的墙壁区域都出现了颜色失真问题。从图 7(e)中可以看出,Cai 等^[11]采用了基于深度学习的去雾方法,无需利用人工方式提取雾图的相关特征,没有受到先验知识的约束,去雾整体效果好于 Meng 等^[9]和 He 等^[6]的传统去雾算法,但是在学习过程中将整幅雾图进行透射率学习,忽略了有雾图像自身结构信息和纹理信息的差异性,无法更有效地学到精细化的透射率,导致去雾图像的部分区域仍然有残雾,例如图 7(e)从上向下数第 2 张图片中的绿植区域去雾不彻底。从图 7(f)中可以看出,Ren 等^[12]的方法采用了学习能力更强的多尺度网络模型,但是该网络模型中含有多次池化操作,导致在特征图学习过程中部分细节信息丢失,没有精确地学到有雾图像的精细特征,对于有雾图像边缘信息处理不到位,例如图 7(f)从上



图 6 室外雾图与深度图预处理后所得的对应场景透射率图标签

Fig. 6 Outdoor hazy images and corresponding scene transmission labels after depth map preprocessing

向下数第 2 张图片中的花盆区域细节信息不够突出。从图 7(g)中可以看出, Li 等^[13]的方法通过对大气散射模型进行调整, 建立了深度学习网络模型, 获得了良好的去雾图像, 但在部分区域存在去雾不彻底的问题, 例如图 7(g)从上向下数第 2 张图片中的绿植部分仍有残余的雾气。从图 7(h)中可以看出, 本文方法对有雾图像的低频子图和高频子图分别进行学习, 既能学习到大片色块等低频信息, 又能学习到边缘等高频信息, 因此得到的去雾图像边缘信息保存基本完好, 且没有出现颜色失真的现象, 图像清晰自然, 视觉效果良好。由此可以看出本文方法对于合成有雾图像的有效性。

为了进一步验证本文方法有效性, 选取结构相似性(SSIM)和峰值信噪比(PSNR)这两个指标, 对不同实验得到的去雾图像进行数据量化分析。SSIM 是一种衡量两幅图像相似度的指标, 该值越大, 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, 该值越大, 表明去雾图像越接近标准无雾图像。不同方法对合成有雾图像处理后的实验结果分析如表 1 所示。从表 1 中可以看出: 在 PSNR 指标方面, 只有第 1 幅图像经本文方法处理后的 PSNR 值小于 Meng 等^[9]方法, 其他图像经本文方法处理后的 PSNR 都大于经其他 5 种方法处理后的 PSNR; 在 SSIM 指标方面, 本文方法去雾图

表 1 不同方法对合成有雾图像处理后的实验结果分析

Table 1 Analysis of experimental results of synthetic hazy images processed by different methods

Image number	Method in Ref. [6]		Method in Ref. [9]		Method in Ref. [11]		Method in Ref. [12]		Method in Ref. [13]		Proposed method	
	PSNR /dB	SSIM /%	PSNR /dB	SSIM /%	PSNR /dB	SSIM /%	PSNR /dB	SSIM /%	PSNR /dB	SSIM /%	PSNR /dB	SSIM /%
1	14.6150	75.12	19.7037	77.73	16.0349	77.67	15.9247	79.23	14.3038	70.29	17.0865	82.55
2	19.4521	78.47	20.5804	80.90	21.1854	81.05	20.8030	82.63	18.5555	76.60	21.7991	88.42
3	23.8374	86.26	17.1493	46.20	21.3263	85.79	22.4172	80.24	21.3263	85.79	24.7953	91.15
4	16.0477	76.40	17.8519	81.21	19.2110	85.38	17.6245	79.17	17.5217	77.91	22.7550	87.69
5	20.9108	88.37	18.7020	77.04	22.2080	91.74	21.6812	90.68	20.9664	89.02	22.7954	92.41



图 7 不同方法对合成有雾图像处理后的实验结果。(a)合成有雾图像;(b)标准无雾图像;(c)文献[6]方法;
(d)文献[9]方法;(e)文献[11]方法;(f)文献[12]方法;(g)文献[13]方法;(h)本文方法

Fig. 7 Experimental results of synthetic hazy images processed by different methods. (a) Synthetic hazy images; (b) standard dehazed images; (c) method in Ref. [6]; (d) method in Ref. [9]; (e) method in Ref. [11]; (f) method in Ref. [12]; (g) method in Ref. [13]; (h) proposed method

像的 SSIM 值是 6 种对比方法中最大的。上述量化指标表明,本文方法所得去雾图像更接近于标准无雾图像,复原质量相对较好,验证了本文方法对于合成有雾图像的有效性。

4.3 真实有雾图像实验

为了进一步验证本文方法对自然界真实有雾图像的有效性,选取部分真实有雾图像进行对比实验,结果如图 8 所示。从图 8(b)中可以看出,He 等^[6]方法获得的去雾图像中,雾气基本能够有效去除,但是天空部分出现了明显的颜色失真现象,这是因为天空区域基本不存在强度值为 0 的暗通道值,所以该方法对于天空区域去雾失效,例如图 8(b)从上向下数第 2 和第 3 张图片中的天空区域都出现了不同程度的颜色失真现象;此外,该方法去雾图像的整体亮度偏低,例如图 8(b)从上向下数第 1 和第 8 张图片都偏暗,视觉效果不佳。从图 8(c)中可以看出,Meng 等^[9]的方法相对于 He 等^[6]的方法,去雾图像的整体亮度明显提升,雾气也基本去除,但是部分区

域同样出现了明显的偏色现象,例如图 8(c)从上向下数第 3 和第 6 张图片中的天空区域都出现了偏色问题。从图 8(d)中可以看出,Cai 等^[11]的深度学习方法整体效果好于 Meng 等^[9]和 He 等^[6]的传统去雾算法,去雾图像没有出现颜色失真现象,但是网络模型学习能力有限,导致出现部分区域去雾不彻底的问题,例如图 8(d)从上向下数第 4 张图片中的建筑物区域仍有残雾。从图 8(e)中可以看出,Ren 等^[12]的方法得到的去雾图像整体效果良好,但是对于去雾图像边缘信息处理不到位,例如图 8(e)从上向下数第 4 张图片中的建筑物区域以及从上向下数第 8 张图片中的车头部分存在细节丢失的问题。从图 8(f)中可以看出,Li 等^[13]的方法同样存在细节处理不到位的问题,例如图 8(f)从上向下数第 4 张图片中的建筑物部分细节丢失。从图 8(g)中可以看出,本文方法得到的去雾图像中没有出现颜色失真现象,图像清晰自然且边缘保持良好,整体效果较好。由此证明了本文方法对于真实雾图像的




图 8 不同方法对自然界真实有雾图像处理后的实验结果。(a)有雾图像;(b)文献[6]方法;(c)文献[9]方法;
(d)文献[11]方法;(e)文献[12]方法;(f)文献[13]方法;(g)本文方法

Fig. 8 Experimental results of real natural hazy images processed by different methods. (a) Hazy images; (b) method in Ref. [6]; (c) method in Ref. [9]; (d) method in Ref. [11]; (e) method in Ref. [12]; (f) method in Ref. [13]; (g) proposed method

有效性。

同样,为了进一步验证本文模型对于自然真实

有雾图像的有效性,选取信息熵(IE)和平均梯度(AG)指标,对实验结果进行对比分析。信息熵(IE)

反映了图像包含信息量的大小,熵值越大,表明图像越清晰;AG反映了图像微小细节反差变化的速率,平均梯度越大,图像层次越多,也就越清晰。自然有雾图像的不同算法实验结果的对比分析如表2所示。从表2中可以看出:在IE指标方面,本文方法

去雾图像的IE值均大于其他几种对比方法;在AG指标方面,只有第6和第7幅图像,本文方法的AG值略小于Meng等^[9]方法,对于其他图像,本文方法是对比方法中最优的。数据的对比进一步验证了本文方法对于自然有雾图像的有效性。

表2 不同方法对真实有雾图像处理后的实验结果分析

Table 2 Analysis of experimental results of real hazy images processed by different methods

Image number	Method in Ref.[6]		Method in Ref.[9]		Method in Ref.[11]		Method in Ref.[12]		Method in Ref.[13]		Proposed method	
	IE	AG	IE	AG	IE	AG	IE	AG	IE	AG	IE	AG
1	7.4470	10.73	7.5599	15.48	7.7893	10.04	7.5420	11.58	7.6217	11.01	7.7991	17.96
2	7.2401	5.18	7.1003	8.84	7.3932	5.64	7.3550	6.27	7.3181	6.85	7.5302	10.05
3	7.4310	6.67	7.1498	9.45	7.3598	6.04	7.1766	6.30	7.1571	6.67	7.7243	10.46
4	7.2502	4.33	6.8430	6.61	7.3876	4.29	7.5689	4.88	7.5825	5.85	7.6140	9.99
5	7.5677	17.22	7.6955	20.55	7.6021	17.21	7.6095	16.48	7.7056	18.08	7.7745	23.61
6	7.7556	6.79	7.4930	10.03	7.3447	5.24	7.2957	6.48	7.2050	5.99	7.9862	7.75
7	7.0428	3.98	6.2422	8.79	7.4332	4.07	7.1530	4.17	7.1741	4.73	7.6025	6.36
8	7.2760	7.23	7.7191	12.37	7.7529	8.19	7.7159	8.72	7.6522	8.97	7.8779	12.99

5 结 论

针对目前单幅图像去雾算法易受先验信息约束和去雾残留等问题,提出了一种基于双域分解的多尺度深度学习单幅图像去雾方法。该方法设计了一个包含低频去雾子网络和高频去雾子网络的多尺度深度学习网络模型。首先将雾图进行双域分解得到的高、低频子图作为模型的输入进行训练,然后将模型学习得到的高、低频透射率进行融合,得到原始雾图对应的场景透射率图,最后利用大气散射模型实现有雾图像到无雾图像的恢复。测试阶段利用训练好的模型对不同场景下的有雾图像进行了多种测试,获得了清晰的无雾图像。实验结果和数据分析表明,本文提出的方法解决了单幅图像去雾算法存在的颜色失真及去雾残留等问题,去雾后的图像清晰自然,对比度合适,图像质量较好,有利于后续

image restoration and enhancement [J]. IEEE Access, 2016, 4: 165-188.

- [3] 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.

- [4] Zhang S, Tang G J, Liu X H, et al. Retinex based low-light image enhancement using guided filtering and variational framework [J]. Optoelectronics Letters, 2018, 14(2): 156-160.

- [5] Dong L L, Ding C, Xu W H. Two improved methods based on histogram equalization for image enhancement [J]. Acta Electronica Sinica, 2018, 46(10): 2367-2375.

董丽丽,丁畅,许文海.基于直方图均衡化图像增强的两种改进方法[J].电子学报,2018,46(10): 2367-2375.

- [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, June 20-25, 2009, Miami, FL, USA. New York: IEEE, 2009: 1956-1963.

- [7] 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.

- [8] Su C, Bi G L, Jin L X, et al. Dehazing algorithm

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

- based on dark-channel image centroid offset[J]. *Acta Optica Sinica*, 2019, 39(5): 0533001.
- 苏畅, 毕国玲, 金龙旭, 等. 基于暗通道图像质心偏移量的去雾算法[J]. *光学学报*, 2019, 39(5): 0533001.
- [9] 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, NSW, Australia. New York: IEEE, 2013: 617-624.
- [10] Guo H, Xu X T, Li B. Study on image dehazing methods based on dark channel prior[J]. *Acta Optica Sinica*, 2018, 38(4): 0410002.
- 郭翰, 徐晓婷, 李博. 基于暗原色先验的图像去雾方法研究[J]. *光学学报*, 2018, 38(4): 0410002.
- [11] 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.
- [12] Ren W Q, Liu S, Zhang H, et al. Single image dehazing via multi-scale convolutional neural networks[M]//Leibe B, Matas J, Sebe N, et al. *Computer vision-ECCV 2016. Lecture notes in computer science*. Cham: Springer, 2016, 9906: 154-169.
- [13] 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, Italy. New York: IEEE, 2017: 4780-4788.
- [14] Cox L J. Optics of the atmosphere-scattering by molecules and particles[J]. *Optica Acta: International Journal of Optics*, 1977, 24(7): 779-788.
- [15] LeCun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. *Proceedings of the IEEE*, 1998, 86(11): 2278-2324.
- [16] Yang A P, Wang H X, Wang J B, et al. Image dehazing based on transmission fusion and multi-guided filtering[J]. *Acta Optica Sinica*, 2018, 38(12): 1210001.
- 杨爱萍, 王海新, 王金斌, 等. 基于透射率融合与多重导向滤波的单幅图像去雾[J]. *光学学报*, 2018, 38(12): 1210001.
- [17] Knaus C, Zwicker M. Dual-domain image denoising [C]//2013 IEEE International Conference on Image Processing, September 15-18, 2013, Melbourne, VIC, Australia. New York: IEEE, 2013: 440-444.
- [18] 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. New York: IEEE, 2016: 770-778.
- [19] 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. New York: IEEE, 2015: 1026-1034.
- [20] Li B Y, Ren W Q, Fu D P, et al. RESIDE: a benchmark for single image dehazing[J/OL]. (2019-04-22) [2019-08-07]. <https://arxiv.org/abs/1712.04143v1>.