

基于霾层学习的单幅图像去雾算法

肖进胜,周景龙,雷俊锋,刘恩雨,舒成

(武汉大学电子信息学院,湖北武汉 430072)

摘要: 针对传统去雾算法出现色彩失真、去雾不完全、出现光晕等现象,本文提出了一种基于霾层学习的卷积神经网络的单幅图像去雾算法. 首先,依据大气散射物理模型进行理论推导,本文设计了一种能够直接学习和估计有雾图像和霾层图像之间的映射关系的网络模型. 采用有雾图像作为输入,并输出有雾图像与无雾图像之间的残差图像,随后直接从有雾图像中去除此霾层图像,即可恢复出无雾图像. 残差学习的引入,使得网络来直接估计初始霾层,利用相对大的学习率,减少计算量,加快收敛过程. 再利用引导滤波进行细化,使得恢复出的无雾图像更接近真实场景. 本文对不同雾浓度的有雾图片的去雾效果进行测试,并与当前主流深度学习去雾算法及其他经典算法进行对比. 实验结果显示,本文设计的卷积神经网络模型在图像去雾的应用,不论在主观效果还是客观指标上,都有优势.

关键词: 图像去雾; 深度学习; 卷积神经网络; 残差学习; 端到端系统

中图分类号: TN911.73 **文献标识码:** A **文章编号:** 0372-2112(2019)10-2142-07

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2019.10.016

Single Image Dehazing Algorithm Based on the Learning of Hazy Layers

XIAO Jin-sheng, ZHOU Jing-long, LEI Jun-feng, LIU En-yu, SHU Cheng

(School of Electronic Information, Wuhan University, Wuhan, Hubei 430072, China)

Abstract: Considering the disadvantage of traditional dehazing algorithm, a single image dehazing algorithm based on haze layers learning is proposed. According to the atmospheric scattering model, the end-to-end network is designed which directly learn the mapping between the haze images and their corresponding haze layers. The network takes the haze image as the input. Then the recovered haze-free image can be gotten by removing the residual image from the hazy image. Residual learning allows the network to estimate the initial haze layer with relatively high learning rates, which can reduce computational complexity and speed up the convergence process. Otherwise, we use guided filter to refine images avoiding halos and block artifacts, which make the recovered image more similar to the real scene. Finally, the experimental results are analyzed and contrasted carefully. In this paper, the effect on fog images with different fog density is tested, and many comparisons are listed with other classical algorithms. Experiments demonstrate that the proposed algorithm has better results than state-of-the-art methods on both synthetic and real-world images qualitatively and quantitatively.

Key words: image dehaze; deep learning; convolutional neural network; residual learning; end-to-end system

1 引言

雾霾场景中捕获的图像,对比度和可见度明显降低,许多计算机视觉算法因此遭受影响. 图像去雾算法在计算机视觉领域有较高的应用价值^[1]. 基于图像复原的方法通过研究大气悬浮颗粒对光的散射作用,建立大气散射模型,了解图像退化的物理机理,并反复复原出未退化前的图像. 此类方法可以分为四类,基于偏振的,基于深度信息的,基于先验的^[2]以及基于学习的

去雾算法^[3],利用卷积神经网络^[4,5]进行学习的算法效果尤为突出.

基于偏振的方法. 其主要假设是直接透射率具有不显著极化,并且大气光的偏振主导着观察光. 基于深度信息的方法. 主要先通过某些算法估计深度信息,再估计大气散射模型其它参数. Kopf^[6]利用由输入场景的精确3D模型和相应模型纹理提供的信息来克服去雾问题,但应用范围很有限.

基于先验的方法. 根据大气散射模型求解无雾图

像,需要解欠定方程,且因含两个未知量,须借助一些先验知识. Kim^[7]建立一个包括对比度和信息损失的代价函数,该算法对天空具有天然的免疫力,但不能很好细化透射率,景物边缘会出现光晕. Berman^[8]提出了一种新的非基于局部先验的算法,应用聚类将像素分组,每个聚类变为一条雾线. 然后计算每个群集的最大半径,并用于估计透射率. He^[9]等人提出了一种暗原色先验的假设,利用引导滤波细化透射率恢复图像,但暗通道理论容易引起天空区域失真. Xiao^[10]针对 He 算法根据天空区域占比估计不同的大气光照强度,利用中值滤波和最小值滤波解决景物边缘光晕问题,但恢复后无雾图像对比度有待提高.

基于学习的方法. 近年来,深度学习的火热发展,在模型的基础上基于学习的方法不断涌出. Zhu^[11]提出了一种新型线性的颜色衰减先验理论,通过此先验创建场景深度估计的线性模型,并使用监督学习方法学习模型参数,深度信息可以很好地恢复. Tang^[12]通过收集多尺度特征,如暗通道、局部最大对比度等,使用随机森林回归学习特征与透射率间的相关性. Cai^[3]提出 DehazeNet 去雾网络,从训练中获得网络的所有权重,则有雾图像的传输率估计仅仅是使用网络的前向传播. Ren^[4]利用多尺度深层神经网络,学习朦胧图像和相应的透射率间的映射. 该算法在质量和速度方面对合成和真实世界图像都有很好地效果,但去雾后仍有淡淡的朦胧感. Li^[5]等人提出 AOD-Net,提出利用 CNN 网络估计模型,反推无雾图像. 该网络思路就是减少利用物理模型估计过多参数导致的误差. 在 2018 年 CVPRW 的 NTIRE 图像去雾比赛中,Engin^[13]等人提出的 Cycle-Dehaze 效果显著,该算法利用生成对抗网络,并改进循环一致性损失,对室内和室外环境的有雾图像均能很好地恢复,该算法的模型效果对于烟雾效果处理甚好,但是对雾霾效果欠佳.

2 相关工作

2.1 大气散射模型

大气散射模型^[10]常用来描述雾图像成像原因,可写成:

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

其中 $I(x)$ 是有雾图像, $J(x)$ 是真实场景, $t(x)$ 透射率, A 是全球大气光, x 是像素索引. 透射率 $t(x)$ 与深度 $d(x)$ 呈负相关, $t(x) = e^{-\beta \cdot d(x)}$, β 大气散射系数. 大气散射模型表明,基于图像复原的算法中介质透射率和大气光照强度的估计是恢复出无雾图像的最重要的步骤.

2.2 卷积神经网络

卷积层表示为 $Conv(f_i, n_i, c_i)$, 反卷积层表示为 $DeCon(f_i, n_i, c_i)$. 其中变量 f_i, n_i, c_i 分别代表滤波器尺寸,

滤波器个数以及通道数. 通过一组滤波器对图像块做卷积,其输出结果也即图像的特征. 卷积层 F_1 表示如下:

$$F_1(Y) = \max(0, \mathbf{W}_1 * Y + \mathbf{B}_1) + a_1 \min(0, \mathbf{W}_1 * Y + \mathbf{B}_1) \quad (2)$$

其中 \mathbf{W}_1 和 \mathbf{B}_1 分别表示滤波器和偏置, Y 是上一层输入, a_1 表示激活函数负数部分系数, 符号 $*$ 表示卷积. \mathbf{W}_1 对应 n_1 个 $c \times f_1 \times f_1$ 的卷积滤波器, c 是输入图像通道数, f_1 是滤波器的尺寸大小, \mathbf{B}_1 是 n_1 维向量. 因为线性模型的表达能力不够, 此处对滤波器应用 PReLU (Parametric Rectified Linear Unit) 加入非线性因素. PReLU 作为激活函数比使用 ReLU 作为激活函数, 使网络更加稳定, 充分利用参数, 能够获得更好地图像生成结果^[14].

反卷积通常用于将低维特征映射成高维输入, 反卷积层 F_2 表示为:

$$F_2(Y) = \mathbf{W}_2 *^{-1} F_1(Y) + \mathbf{B}_2 \quad (3)$$

其中, $*^{-1}$ 代表反卷积, F_1 为上层卷积输出结果, \mathbf{W}_2 指 c 个 $n_1 \times f_2 \times f_2$ 的滤波器, \mathbf{B}_2 是偏置.

3 基于卷积神经网络的图像去雾

根据大气散射模型(1), 并定义图像的雾霾层 $r(x) = I(x) - J(x)$, 可得:

$$r(x) = (J(x) - A)(t(x) - 1) \quad (4)$$

直接估计图像霾层 $r(x)$, 可以免去估计透射率以及估计大气光值引起的误差. 因此, 通过直接估计有雾图像与无雾图像之间的映射关系, 并结合以上基于学习的图像复原算法, 本文提出一种能够直接学习和估计有雾图像 $I(x)$ 和霾层 $r(x)$ 之间映射关系的网络结构.

本文基于卷积神经网络的单幅图像去雾算法整体流程图如图 1 所示.

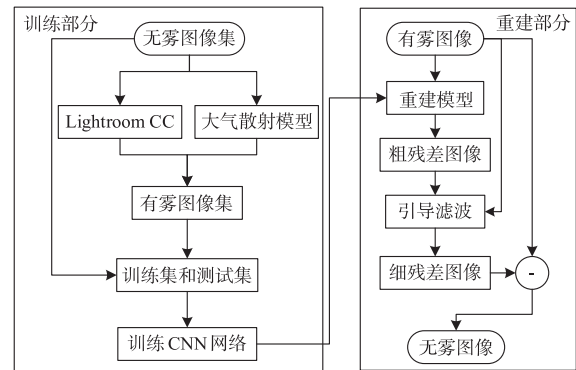


图 1 本文算法整体流程图

3.1 网络结构与分析

不同于以上 Cai^[3] 和 Ren^[4] 两种, 本文算法是一种

真正意义上的端到端系统,并结合残差学习,直接估计有雾图像 $I(x)$ 与霾层图像 $r(x)$ 之间的映射关系.

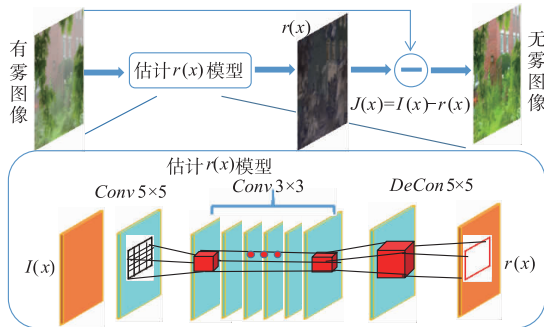


图2 本文算法的网络结构

图2显示了本文算法的网络结构,主要包括:卷积层、深度卷积和反卷积三部分.

卷积层:利用卷积对图像的特征信息降维,去掉图像信息中的冗余能提高网络效率,避免过拟合.该层由一层卷积网络构成.含32个 5×5 高斯滤波器,即 $f_1 = 5, n_1 = 32$,该部分可表示为 $Conv(5, 32, 3)$.为保证霾层图像大小与输入一致,设pad为2.

深度卷积层:深度卷积是通过多次非线性变换密集提取原始图像块特征,最大影响因素是宽度(一个层中滤波器数量)和深度(非线性映射中卷积层数量).层数量在本文被设为6,每一层都包含32个 3×3 的高斯滤波器.即 $f_2 = 3, n_2 = 32$.且 $c_2 = n_1$.则该部分可表示为 $6 \times Conv(3, 32, 32)$.设置pad为1,使深度卷积操作后图像尺寸不变.

反卷积层:反卷积将特征降维后的图像升维到原图尺寸.该部分由一层反卷积构成,包含3个 5×5 的高斯滤波器,且 $c_3 = n_2$.利用一组反卷积高斯滤波器来聚合先前的特征放大到原始尺寸恢复出无雾图像.则该部分可表示为 $DeCon(5, 3, 32)$,并设置pad为2.

3.2 霾层学习卷积神经网络去雾

为了与现有最先进的去雾技术进行公平的比较(4.2节)我们还借鉴了一个两步训练的策略.首先,使

用208幅图像数据集开始训练网络.当训练饱和,添加剩余数据集进行微调.使用这个策略,训练比从开始就使用整个数据集的训练收敛得快.初始训练时,初始学习速率被设置为 10^{-4} ,反卷积层的学习速率为 10^{-5} .微调期间,当训练误差趋于稳定时,将所有层的学习速率减少一半继续训练.由于我们在结束时没有激活函数,所以反卷积滤波器用具有零平均值和标准偏差0.001的高斯初始化.

本文设计的神经网络,若是无残差学习,通过网络直接预测无雾图像,这种情况下,学习率需设置很小才能避免梯度爆炸问题,且整个网络收敛也会非常慢.因此,我们引入残差学习,霾层图像的参考图像在公式(5)节中已经被定义为 r ,我们采用均方差作为代价函数,则优化目标变为:

$$L(\Theta) = \min_{\Theta} \left(\frac{1}{n} \sum_{i=1}^n \| r - f(x_i; \Theta) \|^2 \right) \quad (5)$$

其中 Θ 表示需要学习的整个网络的权重和偏置参数; $f(x_i; \Theta)$ 是网络预测的霾层图像.使用具有标准反向传播的随机梯度下降来优化所有参数.在网络结构中,损失函数将在损失层中反映.损失层有三个输入:霾层估计、有雾图像和无雾图像.计算将输入图像减去重建霾层图像得到的图与参考图之间的欧式距离作为损失计算.

3.3 基于引导滤波的无雾图像重建

由于直接学习出的霾层图像不够平滑,且部分恢复出的图像景物边缘光晕伪影残留,所以利用引导滤波^[9]的边缘保持功能对其进行细化,增强边缘,去除伪影.

对网络输出 $f(x)$ 进行引导滤波得到 $f'(x)$,引导图像为 $I(x)$,输入图像像素点为 i 的引导滤波公式表示为:

$$f'(x_i) = \sum_j W_{ij}(I) f(x_j) \quad (6)$$

这里 i 和 j 为像素索引, $W_{ij}(I)$ 表示由引导图像 $I(x)$ 来确定权重,最后除去有雾图像上的此细化的霾层 $f'(x)$,即得到最终输出结果,结果如图3所示.




图3 引导滤波对图像复原的影响(canyon)从左到右依次为:(a)有雾图像 (b)初始霾层 (c)细化霾层 (d)除去初始霾层的无雾图像 (e)除去细化霾层的无雾图像

从图 3 可以看出,“canyon”初始霾层红色方框中山石边缘模糊不清,这也造成了图 3(d)中山石边缘的光晕效应.而利用引导滤波细化初始霾层以后,图 3(c)中边界泾渭分明,进而使得图 3(e)图光晕效应消失,细节更逼真.

3.4 模型性能分析

为验证网络中残差学习和反卷积模块对算法的有效性,本小结将以 3.1 节中的训练集和测试集为基础,分别对 SRCNN,本文缺少残差学习的网络 Non_Res 以及将本文网络中反卷积替换为卷积的网络 Non_Decon 进行性能分析.主要从训练过程中各个迭代次数的模型针对同一验证集的 PSNR 入手.具体如下.

SRCNN 是用于图像超分辨率的,网络仅有三层:各层卷积核的尺寸 $f_1 = 9, f_2 = 1, f_3 = 5$,针对各层卷积核个数需作出部分修改使其能够处理彩色图像,各层卷积核个数设置为 $n_1 = 64, n_2 = 32, n_3 = 3$.

Non_Res 网络主要是为了验证本文网络中残差学习模块对整体算法的影响.

Non_Decon 网络主要是为了验证本文网络中反卷积模块对整体算法的影响.

训练完成后,利用四个网络训练好的不同迭代次数的模型针对同一验证集测试 PSNR 变化,PSNR 收敛曲线如下图 4.

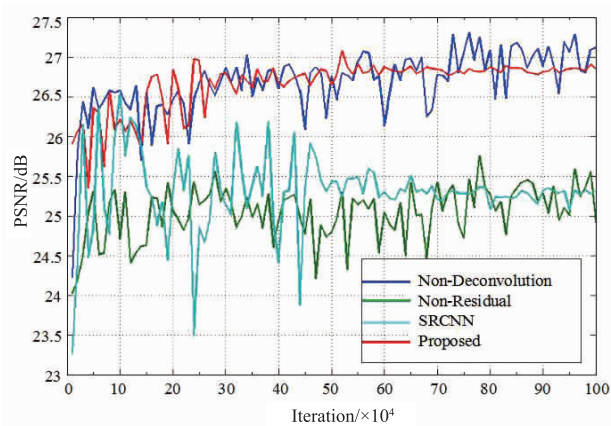


图 4 不同网络设计的 PSNR 收敛曲线

由上图 4 PSNR 收敛曲线可知, SRCNN, Non_Res 和 Non_Decon 网络的 PSNR 曲线波动幅度范围广, SRCNN, Non_Res 网络的 PSNR 相对另外两个网络较小.这间接表明了本文网络包含残差学习模块和反卷积模块的正确性.

4 实验结果及分析

本文算法的实验环境包括硬件设备和软件配置,详细信息如下.

硬件设备: CPU: Intel Core i7-5820K @ 3.30GHz x 12; GPU: NVIDIA GeForce TITAN X; 内存: 16GB;

软件配置: 操作系统为 64 位 ubuntu 14.04 LTS; MATLAB R2014a; CUDA Toolkit 7.0; OpenCV 3.0.

4.1 训练和测试集

本文在 Middlebury Stereo Datasets^[16]和网上收集的无雾图像共 96 幅, 76 幅作为训练集, 20 幅作为测试集. 分别对无雾图像集加 8 种不同浓度的雾, 得到 768 幅有雾图像, 训练集 608 幅, 测试集 160 幅. 由于图像画质较高, 尺寸较大, 且大小不一, 对去雾算法训练集和测试集进行预处理, 将图像裁剪成 29×29 大小的图像块. 因此, 训练集图像 252800 幅, 测试集图像 2176 幅.

4.2 实验对比

本节把本文算法定量和定性的与下列现如今最经典和最先进的去雾方法比较, 采用迭代 600K 的模型. 其中涉及到的对比算法有以下 7 个:

DCP-He^[9]暗通道先验图像去雾

SCDCP-Xiao^[10]天空约束暗通道先验去雾

CAP-Zhu^[11]颜色衰减先验单幅图像去雾

DehazeNet-Cai^[3]基于 CNN 图像去雾

MSCNN-Ren^[4]基于多尺度 CNN 图像去雾

AOD-Net-Li^[5]端到端 CNN 图像去雾

Cycle-Dehaze-Engin^[13]端到端的 GAN 图像去雾

测试数据选取 NYU Depth dataset、Middlebury Stereo Datasets、RESIDE^[17]中的真实场景合成一些有雾图像以及自然有雾图像. 本文客观评价指标使用图像去雾领域常用的峰值信噪比 PSNR (Peak Signal-to-Noise Ratio) 和结构相似性 SSIM (Structural Similarity) 度量.

4.2.1 视觉效果对比

在视觉效果对比输入图像将分别选用合成有雾图像以及自然有雾图像, 对不同类型算法进行对比, 具体分析如下.

(1) 合成有雾图像

该测试的合成有雾图像是在对 Middlebury Stereo Datasets 数据库中的真实图像进行加雾获得的.



图 5 各算法对合成图像视觉对比 从左到右: 上排 (a) 有雾图像 carriage (b) 参考图 (c) 本文; 下排 (d) DCP (e) SCDCP (f) DehazeNet (g) MSCNN

上图 5 都是对合成有雾图像进行去雾的结果. 由图观察可知: DCP 算法在局部平滑区域容易出现色彩失真; 肖 SCDCP^[10]算法则在此基础上一定程度的消除了色彩失真, 但该算法和 Cai^[3]的 DehazeNet 相比于参

考图存在图像局部区域过增强的问题,例如 carriage 和 buildings 中的局部缩放区域;Ren^[4]的 MSCNN 算法去雾不完全,去雾后图像仍有朦胧感.本文算法在保持较高颜色一致性的前提下,不仅较好的保留了图像的细节信息,更重要的是去雾后结果图像最接近于参考图.因此从视觉主观效果来看,针对合成有雾图像,本文算

法整体优于其他对比算法.

(2) 自然有雾图像

此部分测试图像是在相关去雾论文的主页中以及网络中获取的真实有雾测试图像,采用这些有雾图像进行去雾效果的对比更加具有说服力.



图6 各算法对真实世界图像对比 people(上)和train(下)

图6是对自然有雾图像进行去雾的结果.由图观察可知:针对自然图像,DCP^[9]算法仍然存在着局部区域色偏、块效应的问题,SCDPCP^[10]算法在此基础上问题都有所减轻;相比以上两种传统去雾算法,DehazeNet^[3]和MSCNN^[4]的算法基本消除了颜色失真,抑制了噪声的增加,DehazeNet在深色区域存在着对比度过高,细节丢失的现象.MSCNN算法的效果要出色多,整体去雾均匀,但仍有局部细节的模糊.本文算法去雾结果图像纹理结构相对比较清晰自然,不论是在近距离有雾图像还是远距离有雾图像,以及天空区域,都能保持很好的恢复效果.

(3) 端到端网络模型效果对比

本小节内,本文算法与端到端的去雾算法AOD-Net^[5]和Cycle-Dehaze^[13]进行了比较,对比了其主观效果.图像数据集采用RESIDE^[17]测试集中的自然图像和真实图像.对于自然真实图像测试集效果如图7.



图7 各算法对真实图像对比 factory(上)downtown(下)

Cycle-Dehaze图像色彩偏暗,比如factory和downtown中的树会变暗;而AOD-Net和本文算法效果十分相近.

对于合成有雾图像,测试效果如图8.




图8 各算法对合成图像对比 pagoda(上)和turret(下)

Cycle-Dehaze算法对合成图像效果较差,turret天空区域出现失真,景物的细节比较模糊,在景物和天空过渡的区域出现光晕;而AOD-Net与本文算法同样保留了很老的图像细节和色彩,但是AOD-Net去雾不完全,会有雾的残留,而本文算法得到的图像通透感更强.

综上,在主观视觉效果对比上,本文算法对真实和合成图像都表现良好.

4.2.2 客观指标对比

本文参考其他的基于卷积神经网络图像去雾的文献[3,4,11,12],通过已有的有雾与无雾图像的匹配对,采用客观指标评价PSNR和SSIM来评判图像恢复的效果.对比结果如下表1所示,鉴于篇幅限制,仅列出部分图像.

由表1可知,本文算法相比其它现阶段最先进的去雾算法表现最优或接近最优.

表 1 客观指标对比

图像	指标	DCP	SCDCP	DehazeNet	MSCNN	本文
Cable-Perfect	PSNR	23.5072	22.0395	22.3875	21.9135	28.8925
	SSIM	0.9561	0.9189	0.6473	0.8833	0.9568
Couch	PSNR	16.5143	21.8344	17.6941	21.6476	30.0735
	SSIM	0.8295	0.8516	0.8326	0.8896	0.9604
Waitress	PSNR	24.8989	24.0158	18.3658	26.0432	28.6591
	SSIM	0.9551	0.9249	0.6630	0.9477	0.9564
Carriage	PSNR	23.5568	18.8106	20.1195	23.3032	31.8152
	SSIM	0.9635	0.8875	0.7886	0.9134	0.9786
Dolls	PSNR	25.6608	22.0827	26.7270	24.7758	26.8739
	SSIM	0.9327	0.9019	0.9152	0.9426	0.9448

5 总结

深度学习在图像处理领域的成功应用,启发了本文将卷积神经网络应用于图像去雾,再结合残差网络的思想,得到了本文基于霾层学习的单幅图像去雾.本文通过网络估计霾层图像,从有雾图像中去除霾层图像,恢复出无雾图像.残差学习的引入,使得网络来直接估计初始霾层,利用相对大的学习率,减少计算量,加快收敛过程.引导滤波的使用,使得恢复出的无雾图像更接近真实场景.实验表明,本文算法能够提供优于现有方法的性能.但本文算法在处理时间上耗时较多,是我们下一步的研究重点.

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):221-238.
WU Di, ZHU Qing-song. The latest research progress of image dehaze[J]. Acta Automatica Sinica, 2015, 41(2): 221-238. (in Chinese)
- [2] 刘杰平,黄炳坤,韦岗. 一种快速的单幅图像去雾算法[J]. 电子学报,2017,45(8):1896-1901.
LIU Jie-ping, HUANG Bing-Kun, WEI Gang. A fast effective single image dehazing algorithm[J]. Acta Electronica Sinica, 2017, 45(8): 1896-1901. (in Chinese)
- [3] CAI B, XU X, 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.
- [4] REN W, LIU S, ZHANG H, et al. Single image dehazing via multi-scale convolutional neural networks[A]. European Conference on Computer Vision[C]. Springer, 2016. 154-168.
- [5] LI B, PENG X, WANG Z, et al. AOD-net: all-in-one dehazing network[A]. IEEE International Conference on Computer Vision (ICCV)[C]. IEEE, 2017. 4770-4778.
- [6] KOPF J, NEUBERT B, CHEN B, et al. Deep photo: model-based photograph enhancement and viewing[J]. ACM Transactions on Graphics, 2008, 27(5): 1-10.
- [7] KIM J H, JANG W D, SIM J Y, KIM C S. Optimized contrast enhancement for real-time image and video dehazing[J]. Journal of Visual Communication and Image Representation, 2013, 24(3): 410-425.
- [8] DANA B, TALI T, SHAI A. Non-local image dehazing[A]. IEEE Conference on Computer Vision and Pattern Recognition[C]. IEEE, 2016. 1674-1682.
- [9] HE K M, SUN J, TANG X. Guided image filtering[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(6): 1397-1408.
- [10] 肖进胜,高威,邹白昱,等. 基于天空约束暗通道先验的图像去雾[J]. 电子学报,2017,45(2):346-352.
XIAO Jin-sheng, GAO Wei, ZOU Bai-yu, et al. Image dehazing based on sky-constrained dark channel prior[J]. Acta Electronica Sinica, 2017, 45(2): 346-352. (in Chinese)
- [11] ZHU Q, MAI J, SHAO L. A fast single image haze removal algorithm using color attenuation prior[J]. IEEE Transactions on Image Processing, 2015, 24(11): 3522-3533.
- [12] TANG K, YANG J, WANG J. Investigating haze-relevant features in a learning framework for image dehazing[A]. IEEE Conference on Computer Vision and Pattern Recognition[C]. IEEE, 2014. 2995-3000.

- [13] ENGI D, GENC A, EKENEL H K. Cycle-dehaze: enhanced cycleGAN for single image dehazing [A]. IEEE Conference on Computer Vision and Pattern Recognition Workshops [C]. IEEE, 2018. 825 - 833.
- [14] DONG C, LOY C C, HE K M, et al. Image super-resolution using deep convolutional networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 38(2) : 295 - 307.
- [15] HE K M, ZHANG X, REN S, et al. Deep residual learning for image recognition [A]. IEEE Conference on Computer Vision and Pattern Recognition [C]. IEEE, 2016. 770 - 778.
- [16] DANIEL S, HEIKO H, et al. High-resolution stereo datasets with subpixel accurate ground truth [A]. German Conference on Pattern Recognition [C]. Springer, 2014. 31 - 42.
- [17] LI B, REN W, FU D, et al. Benchmarking single-image dehazing and beyond [J]. IEEE Transactions on Image Processing, 2019, 28(1) : 492 - 505.

作者简介



肖进胜 男, 1975 年 7 月出生, 湖北武汉, 博士, 武汉大学电子信息学院副教授, 主要研究方向为视频图像处理, 计算机视觉.

E-mail: xiaojis@whu.edu.cn



周景龙 男, 1996 年 9 月出生, 湖北孝感, 武汉大学电子信息学院硕士生, 主要研究方向为视频图像处理.

E-mail: zhoujl@whu.edu.cn

雷俊锋 (通信作者) 男, 1975 年 6 月生, 武汉大学电子信息学院副教授, 主要研究方向为视频图像处理.

刘恩雨 女, 1994 年生, 武汉大学电子信息学院硕士生, 研究方向为图像处理.

舒成 男, 1994 年生, 武汉大学电子信息学院硕士生, 研究方向为图像处理.