

文章编号 1004-924X(2019)12-2702-11

混合残差学习与导向滤波算法在图像去雾中的应用

陈清江, 张 雪*

(西安建筑科技大学 理学院, 陕西 西安 710055)

摘要:为解决雾天场景图像恢复过程中图像清晰度和对比度下降的问题,提出了一种结合残差学习和导向滤波的单幅图像去雾算法。使用雾天图像与对应的清晰图像构建残差网络;采用多尺度卷积提取更多细节的雾霾特征;利用导向滤波各向异性的优点,对残差网络去雾后的图像进行滤波以保持图像边缘特性,得到更加清晰的无雾图像。通过与 DCP 算法、CAP 算法、SRCNN 算法、DehazeNet 算法和 MSCNN 算法相比,在合成雾天图像上,峰值信噪比值最高达到 31.9518 dB,结构相似度值最高达到 0.9796,在自然雾天图像上的运行时间最低达到了 0.4 s,主观评价和客观评价均优于其它对比算法。实验结果表明,所提去雾算法不仅去雾效果较优,而且速度较快,具有较强的实用价值。

关键词:图像去雾;残差网络;大气散射模型;导向滤波

中图分类号:TP391.4 **文献标识码:**A **doi:**10.3788/OPE.20192712.2702

Application of hybrid residual learning and guided filtering algorithm in image defogging

CHEN Qing-jiang, ZHANG Xue*

(College of Science, Xi'an University of Architecture and Technology, Xi'an 710055, China)

* Corresponding author, E-mail: 2445161583@qq.com

Abstract: To solve the problem of image clarity and contrast degradation in fog scene image restoration, a single image defogging algorithm based on residual learning and guided filtering was proposed. A residual network was first constructed by using foggy images and corresponding clear images. Multi-scale convolution was then used to extract more detailed haze features. Taking advantage of the anisotropy of the guided filter, the algorithm then obtained a clearer fog-free image after the residual network was filtered to maintain image edge characteristics. Experiments produced the following results as compared with the dark channel prior, CAP, super-resolution convolutional neural network, DehazeNet, and multi-scale convolutional neural network algorithms. On synthetic foggy images, the peak signal-to-noise ratio reached a maximum of 27.8403 dB, the structural similarity index measure reached a maximum of 0.9796, and the runtime on natural foggy images was as low as 0.4 s. In addition, the subjective and objective evaluations proved to be better than those of the other comparison algorithms. Thus, the proposed defogging algorithm not only produces a better defogging effect but is also faster, thereby offering a greater practical value for defogging applications than the other algorithms.

Key words: image defogging; residual networks; atmospheric scattering model; guided filter

收稿日期:2019-06-12;修订日期:2019-07-08.

基金项目:国家自然科学基金资助项目(No. 61403298);陕西省自然科学基金资助项目(No. 2015JM1024);陕西省教育厅专项科研计划项目(No. 2013JK0586)

1 引言

在雾、霾恶劣的天气条件下,成像设备拍摄到的图像质量降低,使得户外视觉系统的使用受限。因此,雾天图像的清晰化处理已经成为图像处理与计算机视觉领域的一个重要的研究热点。近年来,基于先验信息或假设的单幅图像去雾取得了重要突破。如 Tan 等^[1]通过最大化对比度增强了模糊图像的可见性,由于该方法在物理上是无效的,因此该方法的去雾结果往往会出现颜色失真现象。He 等^[2]提出了一种基于暗原色先验知识统计(Dark Channel Prior, DCP)的算法,但是当图像中的场景目标亮度值与大气光值接近时,暗原色先验信息将失效,并且此算法处理时间长,运算量较大。Zhu 等^[3]在对场景深度建模之前提出了颜色衰减先验(Color Attenuation Prior, CAP),通过在局部先验上建立线性模型来恢复深度信息。Liu 等^[4]提出一种基于变差函数和形态学滤波的图像去雾算法。Li 等^[5]提出了一种混合先验与加权引导滤波的图像去雾算法。Shen 等^[6]提出结合天空检测与纹理滤波的图像去雾算法。尽管在上述算法中取得了很大的进步,但它们仍然依赖于各种先验知识和假设条件,并且仍然有局限性。

最近,随着卷积神经网络的快速发展,使得在图像超分辨率重建^[7]、图像去噪^[8-9]和目标识别

别^[10-11]等方面的性能远远优于传统算法,一些学者将该理论用于图像去雾领域也获得了良好的效果。如 Cai 等^[12]提出的 DehazeNet 训练预测的传输图,但是由于某些场景的特殊性,会造成特定场景下的介质传输图预测不准确,去雾效果不理想。Ren 等^[13]提出了多尺度卷积神经网络(Multi-scale Convolutional Neural Network, MSCNN),用于估计传输映射。Li 等^[14]提出了 Cascaded CNN,该网络由两个子网络构成,分别估计大气光值和传输图。

受 ResNet^[15]网络和 DnCNNs 网络^[16]的启发,本文提出了一种结合残差学习和导向滤波的单幅图像去雾算法,将残差网络模型应用于图像去雾工作,导向滤波^[17]对残差网络去雾后的图像进行滤波,可以保护图像边缘细节信息,得到更好的去雾图像。

2 去雾算法

本文采用的残差网络为端到端的卷积神经网络,网络输入雾天图像直接估计出清晰无雾图像,一定程度地提高了估计的清晰图像的质量。残差网络不仅很好地解决了深度卷积神经网络训练难的问题,并且使得网络层数达到了一个新的高度。本文提出的残差网络模型由多尺度卷积、6 个残差单元和卷积组成。本文采用的残差网络结构如图 1 所示。




图 1 本文采用的残差网络结构

Fig. 1 Residual network structure of this paper

2.1 多尺度卷积特征提取

特征提取层采用多个尺度的滤波器进行卷积操作,直接从原始雾天图像中提取特征,设置滤波器尺寸为 $M \times M \times N$, $M \times M$ 为卷积核的大小, N 为卷积核的个数,滤波器尺寸分别为 $1 \times 1 \times 12$, $3 \times 3 \times 12$, $5 \times 5 \times 12$, $7 \times 7 \times 12$, stride 均为 1, pad 均为 0、1、2、3,卷积操作进行特征提取的计算公式为:

$$G_i(Y) = W_i * G_{i-1}(Y), \quad (1)$$

其中: $G_i(Y)$ 为输出的第 i 层的特征图; W_i 为第 i 层的卷积核; $G_{i-1}(Y)$ 为 $i-1$ 层的特征图; $*$ 表示卷积操作。

多尺度的滤波器可以捕获更加丰富的统计属性和结构属性,提高捕获图像内部信息的鲁棒性和有效性。

2.2 残差单元

对卷积神经网络而言,随着网络层数的不断加深,前面训练参数的微小变化都会被放大,导致当前层特征的概率分布发生变化,导致网络先前训练的权重和学习率不再适用,进而引起梯度弥散、特征丢失等问题,为此,所提算法采用残差单元来改善此问题。网络结构中间共包含 6 个残差单元,每个残差单元包含了 Conv+BN+Relu 和 Conv+Relu 两个结构,BN 层用来对某一层网络的输入数据进行归一化处理,使得每一维特征均值为 0,标准差为 1,公式为:

$$\hat{x}^{(n)} = \frac{x^{(n)} - E(x^{(n)})}{\sqrt{\text{Var}(x^{(n)})}}, \quad (2)$$

其中: $E(x^{(n)})$ 为每一批训练数据神经元 $x^{(n)}$ 的平均值, $\sqrt{\text{Var}(x^{(n)})}$ 为每一批数据神经元 $x^{(n)}$ 激活度的一个标准差。式(2)强制将数据作归一化处理,会影响本层网络所学习到的特征。于是引入可学习参数 α, β ,则有:

$$y^{(n)} = \alpha^{(n)} \hat{x}^{(n)} + \beta^{(n)}. \quad (3)$$

引入批量正则化(Batch Normalization, BN)可以规避参数的扰动,使用 BN 处理后的数据能够使下一层神经网络更好地学习,一定程度避免了梯度弥散现象,允许更大的学习率,进而可以提高网络的训练速度。其中,卷积层的卷积核大小均为 3×3 ,个数均为 32, pad 和 stride 均为 1,这样保证了每层输出的特征图大小是相同的。

使用非线性单元(ReLU)激活函数使得网络具有稀疏性,并减少了参数的相互依存关系,从而有助于网络训练中的过拟合。

2.3 重建

重建的作用是将信息从特征空间映射回图像空间。将单独的卷积层作为网络的重建层,卷积核大小为 3×3 ,输出预测的清晰无雾图像。

在网络训练过程中,使用欧式损失函数(Euclidean Loss),用来计算输入雾天图像与预测的清晰无雾图像两者差值的平方和,公式为:

$$L(y_i, x_i) = \frac{1}{2N} \sum_{i=1}^N \|y_i - x_i\|_2^2, \quad (4)$$

其中: y_i 表示第 i 组清晰图像值, x_i 表示网络结构的第 i 组输出值, N 为样本训练数目。对于网络结构的训练,需要收集大量的标签数据,而现实中的大量的雾天图像和对应的清晰图像是不可用的,因此,本文使用通过大气散射模型得到的雾天图像来

训练网络。利用随机梯度下降法(Stochastic Gradient Descent, SGD)和反向传播算法进行网络优化得到最优的网络参数。

2.4 导向滤波保持图像边缘特性

为了提高恢复的去雾图像的质量,采用能够保持图像边缘细节的导向滤波,对使用残差网络预测的去雾图像进一步优化,得到清晰度和对比度更加高的无雾图像。

将雾天图像作为引导图像 I ,令输入图像为 p ,滤波输出图像为 q ,假设引导图像与输出图像在一个二维窗口 ω_k 内满足:

$$q_i = a_k I_i + b_k, \quad \forall i \in \omega_k, \quad (5)$$

其中: i 为像素坐标, ω_k 为引导图像 I_i 中以像素 k 为中心的邻域,窗口半径为 r , a_k 和 b_k 在邻域 ω_k 中为常数,在局部区域,输出图像可以捕获与引导图像相似的细节信息,其捕获细节信息的能力与窗口半径的大小密切相关,本文 r 取值为 15。为确定上述线性系数,使 q 与 p 的差异最小,将滤波结果转化为求解下列函数的最优问题:

$$E(a_k, b_k) = \sum_{i \in \omega_k} [(a_k I_i + b_k - p_i)^2 + \delta a_k^2], \quad (6)$$

其中 δ 是一个正则化参数,防止 a_k 过大。通过线性回归,得到:

$$a_k = \frac{\frac{1}{|\omega|} \sum_{i \in \omega_k} I_i p_i - u_k \bar{p}_k}{\sigma_k^2 + \delta}, \quad (7)$$

$$b_k = \bar{p}_k - a_k u_k,$$

其中: $|\omega|$ 为窗口像素值; u_k, σ_k^2 分别为 I 在 ω_k 中的均值和方差; \bar{p}_k 为 p 在 ω_k 中的均值,通过求解 a_k 和 b_k ,得输出图像为:

$$q_i = \frac{1}{|\omega|} \sum_{i, k \in \omega_k} a_k I_i + b_k = \bar{a}_i I_i + \bar{b}_i, \quad (8)$$

其中: $\bar{a}_i = \frac{1}{\omega} \sum_{k \in \omega_k} a_k, \bar{b}_i = \frac{1}{\omega} \sum_{k \in \omega_k} b_k, \bar{a}_i$ 和 \bar{b}_i 为 a, b 在窗口内的均值。

提出的算法首先采用残差网络进行粗估计无雾图像,并利用导向滤波方法对其进一步细化,从而在视觉上得到更好的去雾恢复。

3 实验与结果分析

本节描述了实验数据的获取,实验设置和实验步骤,并且将本文算法的去雾结果与传统的经

典去雾算法:DCP 算法^[2]和 CAP 算法^[3],以及基于卷积神经网络的 SRCNN 算法^[18]、DehazeNet 算法^[12]和 MSCNN 算法^[13]分别在合成雾天图像数据集和真实自然雾天图像数据集上进行主观与客观的对比分析。

3.1 实验数据、实验设置和实验步骤

实验数据:因为网络结构的训练需要收集大量的标签数据,而现实中的大量的雾天图像和对应的清晰图像是不可用的,因此,本文采用数据集 Middlebury Stereo Datasets 和 Make3D Laser+Image data 通过大气散射模型^[19]得到的雾天图像来训练网络。为了能够适应不同天气下的雾浓度,将散射率 β 随机设置为(0.75,1.5),防止 β 过大使得传输图接近于 0。大气光值在图像的光亮区域取得,随机设置为(0.5,1.5),挑选有雾图像和无雾图像 6 000 对作为

训练样本,3 000 对作为测试样本。

实验设置:采用 Caffe 框架实现网络,每层的权重滤波器均采用均值为 0,方差为 $2/n$ 的高斯分布进行随机初始化,网络模型采用固定的学习率,设置为 0.000 1,动量参数设置为 0.9,迭代次数为 120 000 次,使用 SGD 优化算法使网络能更快收敛。

实验步骤为:(1)获取雾天图像数据集;(2)进行网络模型的训练与测试;(3)采用导向滤波对网络预测的去雾图像进行优化;(4)基于合成雾天图像数据集的去雾结果与分析;(5)基于真实雾天图像数据集的去雾结果与分析。

3.2 基于合成雾天图像数据集的去雾结果与分析

为验证本文算法对合成雾天图像的去雾效果,将本文算法与其他经典算法进行了比较,图 2~图 4 展示了部分合成雾天图像的去雾结果对比。

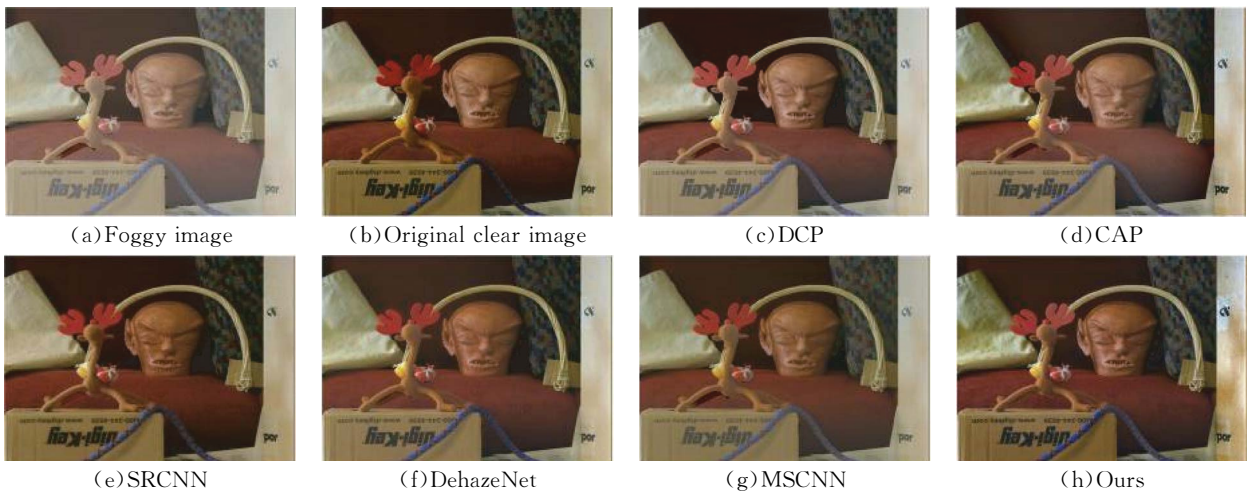


图 2 不同算法对雾天图像 Reindeer 的去雾结果
Fig. 2 Different algorithms to defog results of fog image Reindeer




图 3 不同算法对雾天图像 Dolls 的去雾结果
Fig. 3 Different algorithms to defog results of fog image Dolls




图 4 不同算法对雾天图像 Trees 的去雾结果

Fig. 4 Different algorithms to defog results of fog image trees

为了定量地评价这些方法,使用均方根误差 (Root Mean Square Error, RMSE)、互信息 (Mutual Information, MI)、平均梯度 (Average gradient)、峰值信噪比 (Peak Signal to Noise

Ratio, PSNR/dB) 和结构相似度 (Structural Similarity Index, SSIM) 重要的图像评价标准来衡量去雾图像的质量。

如表 1~表 3 所示。

表 1 图像 Reindeer 采用不同算法去雾后评价指标结果

Tab. 1 Evaluation indicators results by different defogging algorithms for image Reindeer

评价指标	DCP	CAP	SRCNN	DehazeNet	MSCNN	本文算法
均方根误差 ↓	0.027 3	0.025 9	0.025 5	0.014 7	0.032 6	0.013 9
互信息 ↑	0.127 5	0.263 4	0.350 5	0.425 9	0.282 2	0.506 3
平均梯度 ↑	11.004 4	7.149 9	6.900 7	6.633 4	7.979 9	12.200 2
峰值信噪比 ↑	15.824 6	19.870 2	25.066 5	26.372 9	20.602 2	27.840 3
结构相似度 ↑	0.778 2	0.650 5	0.943 9	0.947 3	0.830 3	0.979 6

表 2 图像 Dolls 采用不同算法去雾后评价指标结果

Tab. 2 Evaluation indicators results by different defogging algorithms for image Dolls

评价指标	DCP	CAP	SRCNN	DehazeNet	MSCNN	本文算法
均方根误差 ↓	0.032 0	0.031 3	0.021 7	0.021 3	0.024 1	0.005 6
互信息 ↑	0.136 0	0.224 4	0.366 1	0.467 9	0.308 0	0.530 1
平均梯度 ↑	6.274 6	3.949 4	6.250 5	5.822 8	7.157 1	7.553 6
峰值信噪比 ↑	11.484 5	22.282 5	25.460 6	25.897 2	21.381 0	26.311 2
结构相似度 ↑	0.841 2	0.876 9	0.947 3	0.942 6	0.879 7	0.974 4

表 3 图像 Trees 采用不同算法去雾后评价指标结果

Tab. 3 Evaluation indicators results by different defogging algorithms for image Trees

评价指标	DCP	CAP	SRCNN	DehazeNet	MSCNN	本文算法
均方根误差 ↓	0.027 6	0.053 0	0.024 4	0.020 8	0.016 9	0.002 3
互信息 ↑	0.122 0	0.254 0	0.395 1	0.365 5	0.287 0	0.454 3
平均梯度 ↑	12.354 8	10.563 2	10.003 2	10.003 3	12.530 1	13.026 9
峰值信噪比 ↑	17.754 3	22.146 3	23.553 1	26.322 1	23.852 8	27.133 2
结构相似度 ↑	0.856 6	0.882 5	0.918 0	0.911 4	0.921 0	0.955 8

各个评价指标的数学公式分别如下:

(1) 均方根误差:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (Y - X)^2}{n}}, \quad (9)$$

其中: n 是图像像素总数, Y 是清晰无雾图像, X 是去雾图像。

(2) 互信息:

$$I(X; Y) = \sum_{x, y} p(x, y) \log \frac{p(x, y)}{p(x)p(y)}, \quad (10)$$

其中: 设 $p(x, y)$ 为两个随机变量 (X, Y) 的联合分布, 边缘分布分别为 $p(x), p(y)$, 互信息 $I(X; Y)$ 是联合分布 $p(x, y)$ 与乘积分布 $p(x)p(y)$ 的相对熵。

(3) 平均梯度:

$$G = \frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N \sqrt{\frac{\left(\frac{\partial f}{\partial x}\right)^2 + \left(\frac{\partial f}{\partial y}\right)^2}{2}}, \quad (11)$$

其中: $M \times N$ 为图像的大小, $\frac{\partial f}{\partial x}$ 和 $\frac{\partial f}{\partial y}$ 分别表示水平方向和垂直方向的梯度。

(4) 峰值信噪比:

$$PSNR = 10 \log_{10} \frac{255}{\sqrt{|f_{in} - f_{out}|^2}}, \quad (12)$$

其中: f_{in} 为清晰无雾图像, f_{out} 为去雾图像。如果 PSNR 值越大, 图像的失真就越小。这意味着图像质量越高, 去雾性能越好。

(5) 结构相似度:

$$SSIM_{f_{in}, f_{out}} = \frac{(2\mu_{f_{in}}\mu_{f_{out}} + \omega_1)(2\sigma_{f_{in}f_{out}} + \omega_2)}{(\mu_{f_{in}}^2 + \mu_{f_{out}}^2 + \omega_1)(\sigma_{f_{in}}^2 + \sigma_{f_{out}}^2 + \omega_2)}, \quad (13)$$

其中: $\mu_{f_{in}}$ 是 f_{in} 的平均值; $\mu_{f_{out}}$ 是 f_{out} 的平均值; $\sigma_{f_{in}}^2$ 是 f_{in} 的方差; $\sigma_{f_{out}}^2$ 是 f_{out} 的方差。 $\sigma_{f_{in}f_{out}}$ 是 f_{in} 和 f_{out} 的协方差; ω_1 和 ω_2 是用于避免系统不稳定引起的分母为 0 的常数。SSIM 值的范围为 $[0, 1]$, 值越大, 图像失真越小。

由以上可知, 在雾天图像 Reindeer 中, DCP 算法、CAP 算法和 MSCNN 算法去雾结果效果较差, 图像表面还残留一层薄雾, SRCNN 算法和 DehazeNet 算法去雾效果较好。在图像 Dolls 中, DCP 算法出现了明显的伪影现象; DehazeNet 算法和 MSCNN 算法在图像下半部分没有完全去雾; CAP 算法和 SRCNN 算法去雾图像较接近于原清晰图像。而本文提出的去雾算法不仅在主观视觉上得到了明显提升以外, 且在客观评价指标上, 也有了显著提高。

为了验证本文提出的残差单元对恢复去雾图像具有重要的作用, 采用一个对比网络模型进行定量对比分析, 即将所提网络中的残差单元换为常规卷积层的网络模型(无残差结构), 网络结构层数不变, 实验结果对比如表 4 所示。

表 4 不同网络的 PSNR 与 SSIM 的对比结果

Tab. 4 Comparison results of PSNR and SSIM of different networks

图像名称	评价指标	常规网络结构	残差单元网络结构
Reindeer	峰值信噪比	26.372 4	27.840 3
	结构相似度	0.869 5	0.979 6
Dolls	峰值信噪比	25.295 7	26.311 2
	结构相似度	0.834 0	0.974 4
Trees	峰值信噪比	25.620 0	27.133 2
	结构相似度	0.816 5	0.955 8

由表 4 可知, 残差单元对网络的性能有较明显的提升, PSNR 值和 SSIM 值都是最高的, PSNR 值最高达到 27.840 3 dB, SSIM 值最高达到 0.979 6, 相比于常规卷积层的网络模型, 提出的残差网络结构模型能够很好地提高恢复图像的质量。

为了验证本文算法对不同程度雾天的去雾效果, 本文从采用数据集 Middlebury Stereo Datasets 中随机选取 3 幅清晰图像以及对应的深度图, 根据大气散射模型合成不同程度的雾天图像, 雾的浓度逐渐增加, 去雾结果如图 5 所示。



图 5 不同浓度的合成雾天图像去雾结果

Fig. 5 Different concentrations of synthetic foggy image defogging results

在图 5 中,第 1、3、5 列为合成的不同程度的雾天图像,第 2、4、6 列为对应的本文算法的去雾效果图。由图 5 可看出,随着雾霾浓度的增加,雾天图像的可见性和质量逐渐降低,PSNR 值最低达到 9.719 7 dB,SSIM 值最低达到 0.565 5。本文提出的去雾算法不仅具有良好的视觉效果,而且对于每一幅恢复的清晰图像,PSNR 值和 SSIM 值都有着较大的提高。PSNR 值最高达到了 31.951 8 dB,SSIM 值最高达到 0.976 2。

此外,在第 1 行中,由于图像具有较薄的雾,本文算法去雾结果对图像进行了增强,因此,评价指标值较低。最后两行中,由于图像具有较浓的雾,本文算法去雾结果的评价指标值有所下降,图像中有残留的薄雾出现,但对于对应的雾天图像,恢复的图像仍然具有一定的可见性,评价指标值和图像质量都有较大提高。综上所述,本文算法对不同程度雾天图像的去雾效果具有良好的性能,图像的对比度,可见性和图像质量有较

大提升,具有一定的实用性。

3.3 基于真实雾天图像数据集的去雾结果与分析

本节讨论了真实有雾图像的一些去雾算法,

以验证所提算法的有效性。首选现实世界中经常使用的雾天图像,将所提出的方法与其他算法进行比较,如图 6~图 8 所示。



图 6 自然雾天图像 House 的去雾结果对比

Fig. 6 Comparison of defogging results of natural foggy images House

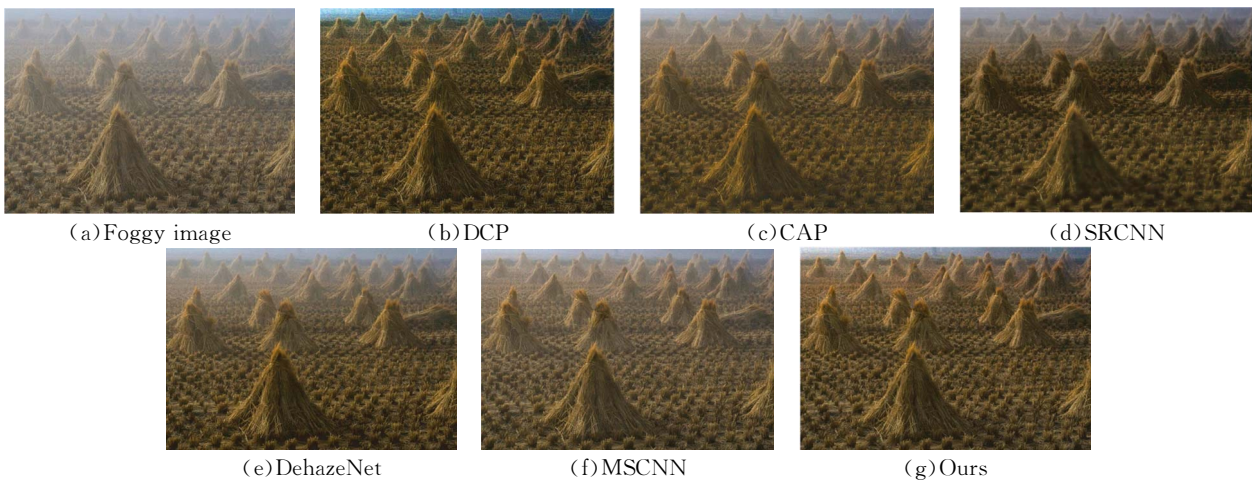


图 7 自然雾天图像 Haystack 的去雾结果对比

Fig. 7 Comparison of defogging results of natural foggy images Haystack




图 8 自然雾天图像 Pumpkin 的去雾结果对比

Fig. 8 Comparison of defogging results of natural foggy images Pumpkin

为验证本文算法处理自然雾天图像的有效性,采用标准差(Standard Deviation)、信息熵(Information Entropy)、平均梯度(Average Gradient)和对比度(Contrast)4个重要的无参考图像评价标准对自然雾天图像去雾结果进行对比。如表5~表7所示,不同算法的运行时间对比结果如表8所示。

各个评价指标的数学公式分别如下:

(1)标准差:

$$S = \sqrt{\frac{\sum_{i=1}^n (X_i - \bar{X})^2}{n}}, \quad (14)$$

其中: n 是图像像素总数, X_i 是去雾图像的像素

值, \bar{X} 是去雾图像像素值的均值。

(2)信息熵:

$$H(X) = E[\log_2 P(X)^{-1}] = - \sum_i P(x_i) * \log_2 P(x_i), \quad (15)$$

其中: X 表示随机变量, $P(X)$ 表示输出概率函数。变量的不确定性越大,熵也就越大。

(3)对比度:

$$Q = \sum_{\delta} \delta(i, j)^2 P_{\delta}(i, j), \quad (16)$$

其中: $\delta(i, j) = |i - j|$ 为相邻像素间的灰度差, $P_{\delta}(i, j)$ 为相邻像素间的灰度差为 δ 的像素分布概率。

表 5 图像 House 采用不同算法去雾后评价指标结果

Tab. 5 Evaluation indicators results by different defogging algorithms for image House

评价指标	DCP	CAP	SRCNN	DehazeNet	MSCNN	本文算法
标准差 ↑	34.509 0	28.568 1	33.926 1	37.951 2	56.165 2	59.698 5
信息熵 ↑	16.423 8	15.929 4	16.810 4	15.873 8	14.162 4	16.659 9
平均梯度 ↑	11.908 3	7.174 6	7.638 3	9.028 7	12.457 2	14.633 2
对比度 ↑	25.007 3	18.804 8	25.430 7	28.627 9	44.455 0	45.298 8

表 6 图像 Haystack 采用不同算法去雾后评价指标结果

Tab. 6 Evaluation indicators results by different defogging algorithms for image Haystack

评价指标	DCP	CAP	SRCNN	DehazeNet	MSCNN	本文算法
标准差 ↑	30.316 1	30.316 1	33.484 5	26.620 8	34.318 8	36.686 7
信息熵 ↑	6.750 3	6.750 3	6.834 4	6.675 4	7.051 5	9.603 6
平均梯度 ↑	13.361 2	5.341 8	5.182 2	6.981 6	6.964 3	13.565 9
对比度 ↑	27.078 7	25.762 6	25.448 1	31.294 2	25.797 2	35.415 0

表 7 图像 Pumpkin 采用不同算法去雾后评价指标结果

Tab. 7 Evaluation indicators results by different defogging algorithms for image Pumpkin

评价指标	DCP	CAP	SRCNN	DehazeNet	MSCNN	本文算法
标准差 ↑	47.447 9	44.814 5	44.802 0	50.428 2	43.165 8	49.966 6
信息熵 ↑	16.102 8	15.477 8	15.999 2	15.976 1	15.978 3	17.795 9
平均梯度 ↑	9.417 3	5.086 7	5.259 8	7.355 2	7.494 3	11.022 0
对比度 ↑	36.189 6	37.100 3	38.540 3	42.505 2	34.853 7	45.041 6

表 8 不同算法的运行时间对比结果

Tab. 8 Run time comparison results of different algorithms

(s)

图像名称	图像尺寸	DCP	CAP	SRCNN	DehazeNet	MSCNN	本文算法
House	441×450	1.192 040	1.083 058	1.420 000	0.712 741	2.300 000	0.386 680
Haystack	768×497	3.930 247	2.806 712	2.661 220	0.968 421	4.532 633	0.582 759
Pumpkin	600×450	1.067 169	4.097 866	2.413 527	0.643 354	2.632 809	0.401 389

由图 6~图 8 可知,DCP 算法去雾的图像色彩过于饱和,并且出现了失真和伪影现象,如在图 House 中,树叶部分出现了伪影,图 Haystack 和图 Pumpkin 中,天空区域均出现了色彩失真现象;CAP 算法为线性回归模型,很难准确的估计介质传输图,在三幅图当中,仍然有残留的雾;SRCNN 算法使得物体边缘产生了严重的光晕现象,如图 House 和图 Pumpkin;与前几种方法相比,DehazeNet 算法和 MSCNN 算法去雾图像信息完整,较为清晰,但由于这两种方法分别对大气光值和介质传输图进行估计,导致了总体估计误差放大。所提算法的去雾图像更加平滑,细节和纹理更加明显,具有良好的对比度和生动的色彩,在五种评价指标值方面,所提算法基本优于其他对比算法,由表 5~表 7 可知,本文去雾算法在各个评价指标上都有较优的结果,比目前基于卷积神经网络的 SRCNN 算法,DehazeNet 算法和 MSCNN 算法的去雾结果更加良好;并且由表 8

可知,本文在以上 3 幅图中,运行时间最短,效率较高。因此,无论在主观视觉还是在客观评价指标上,所提算法都有良好的表现。

4 结 论

现有的图像去雾方法的性能受到人工提取特征的限制,如暗通道,色差和最大对比度,去雾方法复杂,本文提出一种结合残差学习和导向滤波的单幅图像去雾算法,首先使用雾天图像与对应的清晰图像构建残差网络,得到估计的清晰无雾图像,再对卷积神经网络估计的清晰无雾图像进行导向滤波以保持图像边缘细节。提出的算法无论是合成雾天图像还是自然雾天图像的去雾图像色彩自然,具有良好的清晰度与对比度,并且在评价指标方面的值都相对于其他算法较优,表明所提算法具有一定的优越性。

参考文献:

- [1] TAN R T. Visibility in bad weather from a single image [C]. *Computer Vision and Pattern Recognition*, 2008. CVPR 2008. *IEEE Conference on. Anchorage, AK, USA: IEEE*, 2008: 1-8.
- [2] HE K, SUN J, TANG X O. Single image haze removal using dark channel prior [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2011, 33(12): 2341-2353.
- [3] 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.
- [4] 刘万军,赵庆国,曲海成. 变差函数和形态学滤波的图像去雾算法 [J]. *中国图象图形学报*, 2016, 21(12): 1610-1622.
- [5] LIU W J, ZHAO Q G, QU H CH. Image defog algorithm based on variogram and morphological filter [J]. *Journal of Image and Graphics*, 2016, 21(12): 1610-1622. (in Chinese)
- [6] 李喆,李建增,胡永江,等. 混合先验与加权引导滤波的图像去雾算法 [J]. *中国图象图形学报*, 2019, 24(2): 170-179.
- [7] LI ZH, LI J Z, HU Y J, et al.. Mixed prior and weighted guided filter image dehazing algorithm [J]. *Journal of Image and Graphics*, 2019, 24(2): 170-179. (in Chinese)
- [8] 沈逸云,邵雅琪,刘春晓,等. 结合天空检测与纹理平滑的图像去雾 [J]. *中国图象图形学报*, 2017, 22(7): 897-905.
- [9] SHEN Y Y, SHAO Y Q, LIU CH X, et al.. Integrating sky detection with texture smoothing for image defogging [J]. *Journal of Image and Graphics*, 2017, 22(7): 897-905. (in Chinese)
- [10] 张秀,周巍,段哲民,等. 基于卷积稀疏自编码的图

- 像超分辨率重建 [J]. 光学 精密工程, 2019, 48(1): 324-330.
- ZHANG X, ZHOU W, DUAN ZH M, *et al.*. Convolutional sparse auto-encoder for image super-resolution reconstruction [J]. *Opt. Precision Eng.*, 2019, 48(1): 324-330. (in Chinese)
- [8] 李传朋, 秦品乐, 张晋京. 基于深度卷积神经网络的图像去噪研究 [J]. 计算机工程, 2017, 43(3): 253-260.
- LI CH P, QIN P L, ZHANG J J. Research on image denoising based on deep convolutional neural network [J]. *Computer Engineering*, 2017, 43(3): 253-260. (in Chinese)
- [9] 刘超, 张晓晖. 超低照度下微光图像的深度学习自编码网络复原 [J]. 光学 精密工程, 2018, 26(4): 951-961.
- LIU CH, ZHANG X H. Deep convolutional autoencoder networks approach to low-light level image restoration under extreme low-light illumination [J]. *Opt. Precision Eng.*, 2018, 26(4): 951-961. (in Chinese)
- [10] 刘峰, 沈同圣, 马新星, 等. 基于多波段深度神经网络的舰船目标识别 [J]. 光学 精密工程, 2017, 25(11): 2939-2946.
- LIU F, SHEN T SH, MA X X, *et al.*. Ship recognition based on multi-band deep neural Network [J]. *Opt. Precision Eng.*, 2017, 25(11): 2939-2946. (in Chinese)
- [11] 谢冰, 段哲民, 郑宾, 等. 基于迁移学习 SAE 的无人机目标识别算法研究 [J]. 红外与激光工程, 2018, 47(6): 224-230.
- XIE B, DUAN ZH M, ZHENG B, *et al.*. Research on UAV target recognition algorithm based on transfer learning SAE [J]. *Infrared and Laser Engineering*, 2018, 47(6): 224-230. (in Chinese)
- [13] REN W Q, LIU S, ZHANG H, *et al.*. *Single Image Dehazing Via Multi-scale Convolutional Neural Networks* [M]. Computer Vision-ECCV 2016. Berlin: Springer International Publishing, 2016: 154-169.
- [14] LI C Y, GUO J C, FU H Z, *et al.*. A cascaded convolutional neural network for single image dehazing [J]. *IEEE Access*, 2018: 24877-24887.
- [15] HE K, ZHANG X, REN S, *et al.*. Identity mappings in deep residual networks [C]. *Proc. Eur. Conf. Comput. Vis.*, 2016: 630-645.
- [16] ZHANG K, ZUO W, CHEN Y, *et al.*. Beyond a gaussian denoiser: residual learning of deep CNN for image denoising [J]. *IEEE Trans. Image Process*, 2016, 26(7): 3142-315.
- [17] 廖建尚, 王立国. 两类空间信息融合的高光谱图像分类方法 [J]. 激光与光电子学进展, 2017, 54(8): 081002.
- LIAO J SH, WANG L G. Hyperspectral image classification method based on fusion with two kinds of spatial information [J]. *Laser & Optoelectronics Progress*, 2017, 54(8): 081002. (in Chinese)
- [18] DONG C, HE K, TANG X, *et al.*. Image super-resolution using deep convolutional networks [J]. *IEEE Trans Pattern Anal Mach Intell*, 2016, 38(2): 295-307.
- [19] NARASIMHAN S G, NAYAR S K. Contrast restoration of weather degraded images [J]. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2003, 25(6): 713-724.

作者简介:



陈清江(1966—),男,河南信阳人,博士,教授,2003年于信阳师范学院获硕士学位,2006年于西安交通大学获博士学位,主要从事小波分析,图像处理与信号处理方面的研究。E-mail: qjchen66xytu@126.com

通讯作者:



张雪(1995—),女,陕西宝鸡人,硕士研究生,2017年于商洛学院获得理学学士学位,主要从事小波分析,图像处理与信号处理方面的研究。E-mail: 2445161583@qq.com