

基于多特征融合的卷积神经网络图像去雾算法

徐岩, 孙美双

天津大学电气自动化与信息工程学院, 天津 300072

摘要 针对传统去雾算法需要人工提取特征,对比度低、信噪比低等问题,提出一种基于多特征融合的卷积神经网络去雾算法。利用卷积神经网络算法模拟人类视觉系统对雾天图像进行层次化处理,实现自动提取特征。算法采用直接从雾天图像到清晰无雾图像映射的学习方式,该映射由特征提取、多尺度特征融合和浅层深层特征融合联合实现。多尺度特征融合提升网络对图像细节的重建,浅层深层特征融合则将浅层卷积得到的轮廓信息和深层卷积得到的细节信息进行融合,提升去雾重建的整体效果。实验结果表明,相比于单一尺度网络,多特征融合网络的峰值信噪比提高了 1.280 dB。本文算法对自然雾天图像去雾效果明显,细节信息和对比度均优于其他算法,为去雾方法的研究提供了新思路。

关键词 图像处理; 去雾重建; 卷积神经网络; 多尺度特征融合

中图分类号 TP751.1

文献标识码 A

doi: 10.3788/LOP55.031012

Convolution Neural Network Image Defogging Based on Multi-Feature Fusion

Xu Yan, Sun Meishuang

School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China

Abstract We propose a convolutional neural network defogging algorithm based on multi-feature fusion to overcome the problem of manual feature extraction, low contrast, and low signal-to-noise ratio in traditional defogging algorithms. The convolution neural network simulates the human visual system to hierarchically process the fog images and automatically extract image features. The algorithm adopts a learning method of the direct mapping from the hazing image to the clear defogging image, which includes feature extraction, multi-scale feature fusion, and shallow and deep feature fusion. Multi-scale feature fusion helps to rebuild details of the image. Shallow and deep feature fusion combines the contour information obtained by shallow convolution with the detail information obtained by deep convolution to enhance the overall effect of defogging. The experimental results show that the peak signal to noise ratio of the multi-feature fusion network increases by 1.280 dB compared with the single-scale network. The proposed algorithm has obvious defogging effect on natural fog image and superior detail information and contrast compared with other algorithms, which provides a new idea for defogging methods.

Key words image processing; defogging reconstruction; convolution neural network; multi-scale feature fusion

OCIS codes 100.2000; 100.2980; 100.3010

1 引言

雾天是一种特殊的自然天气现象,但由于空气中悬浮颗粒的散射和吸收作用,导致雾天采集到的图像

对比度低、局部区域亮度增加,极大地影响了图像质量,限制了图像在视频监控^[1]、智能交通^[2]、目标检测^[3-4]等方面的应用。为了获取清晰图像,确保计算机系统能更好的识别和提取图像特征,去雾清晰化技

收稿日期: 2017-09-26; **收到修改稿日期:** 2017-10-16

基金项目: 国家自然科学基金(61372145)、天津大学自主创新基金(2015XZC-0005)

作者简介: 孙美双(1991—),女,硕士研究生,主要从事图像处理、模式识别、深度学习等方面的研究。

E-mail: 18722621468@163.com

导师简介: 徐岩(1977—),女,博士,副教授,硕士生导师,主要从事图像处理、模式识别、数字视频信号处理等方面的研究。E-mail: xuyan@tju.edu.cn

术已成为计算机视觉和图像处理的重要研究课题。

目前主流的图像去雾方法主要分为 2 类: 基于非模型的图像增强算法和基于模型的图像复原算法。基于非模型的图像增强算法有全局或局部直方图均衡化^[5-6]、Retinex 算法^[7-8]等。但此种方法未从实际出发去分析雾天图像形成的原理, 只是对图像进行对比度等方面的处理, 并不能从光学成像的本质实现去雾。基于模型的图像复原算法通过图像退化的机理和先验知识, 求解图像成像逆过程来恢复出清晰的无雾图像, 这种去雾方法得到了广泛的研究和应用。例如 Tan^[9] 利用马尔可夫随机场理论拉伸图像对比度, 但该算法的去雾图像颜色过饱和, 景深突变处易产生光晕效应。Fattal^[10] 通过估算景物的反射率推断大气的传递系数, 该算法对薄雾图像处理效果较好, 但对浓雾图像处理效果不好且时间复杂度高。He 等^[11] 在大量实验的基础上提出了一种基于暗通道先验的去雾算法, 但该算法使用软抠图方法, 运算量较大。在此基础上, 研究人员提出了改进算法, Tarel 等^[12] 采用中值滤波代替软抠图算法提高去雾算法的效率, 孙小明等^[13] 通过判断大气光强度和暗通道差值的绝对值来判断雾天图像中是否含有明亮区域, 以降低时间复杂度。杨爱萍等^[14] 结合 Retinex 理论和暗通道先验来恢复夜间无雾图像。传统的基于模型的去雾方法是通过人工提取雾天图像特征得到图像的透射图, 然后根据图像的较高的亮度假设大气光, 最后根据图像成像模型的逆运算得到无雾图像, 但人工提取特征需对大量雾天图像进行特征研究, 费时费力。

2011 年以来, 随着深度学习网络, 尤其是卷积神经网络 (CNN) 的快速发展, 使其在图像分类^[15-16]、物体检测^[17-18]、动作识别^[19] 等方面的性能远优于传统方法。但目前国内外采用深度学习去雾的研究比较有限, 主要原因是数据集获取困难。训练雾天模型需要清晰图像作为训练标签, 该数据集必须在同一位置, 不同天气 (有雾和无雾) 环境下进行拍摄, 并保证雾天图像和清晰图像像素点的对应关系, 故而导致数据集获取异常困难。Cai 等^[20] 通过清晰图像模拟雾天图像的成像模型建立雾天图像库, 通过卷积神经网络的方法得到图像的传输图, 从而实现雾天图像的去雾处理, 但此种方法只获取了图像的传输图, 仍需应用大气成像模型逆运算计算清晰的图像, 且去雾效果仍受成像模型的其他参数影响。此外, 图像中物体大小不一, 景物遮挡深度不同, 此种方法只采用最深层的特征对整幅图进行

去雾重建, 而对于大目标的、雾遮挡小的物体, 其浅层特征能更好地反映这类物体特征。综上所述, 本文提出一种多特征融合的卷积神经网络模型。通过采用端到端的全卷积方式, 避免图像信息丢失, 并保证算法速度。采用多尺度特征融合与浅层深层特征融合方法, 实现细节与轮廓的去雾重建。网络的输出端为清晰的无雾图像, 避免了其他参数对图像恢复的影响, 减少了噪声。

2 基本原理

2.1 雾天图像退化模型

大气散射模型最早由 McCartney^[21] 提出, 该模型描述了雾天图像成像的机理, 并被广泛应用在计算机视觉和计算机图像学中。雾天图像退化模型^[11] 可表示为

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

式中 $I(x, y)$ 为实际拍摄的有雾图像, $J(x, y)$ 为恢复的无雾图像, A 为全球大气光强度, $t(x, y)$ 为介质透射率图 (传输图)。当大气同质时, $t(x, y)$ 可定义为

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

式中 $d(i, j)$ 为场景点到观测点的距离, β 为衰减系数。

2.2 CNN

CNN^[22] 是近几年发展起来的一种前向传播和后向传播^[23] 结合的人工神经网络, 也是一种典型的深度学习方法。其网络结构主要由卷积层和池化层组成。在卷积层中, 卷积核相当于滤波器。卷积层通过滑动窗口的方式将不同卷积核与输入图像的每个通道进行卷积操作以提取输入图像的不同特征。在卷积层后接入非线性激活函数, 一般使用修正线性单元 (ReLU) 函数。池化层为特征映射层^[24], 对经过卷积层后得到的特征进行下采样, 缩小了输入数据规模, 得到局部最优值。

3 多特征融合的卷积神经网络去雾方法

3.1 本文方法的网络结构

为实现图像的去雾重建, 提出多特征融合的卷积神经网络模型, 分为 3 部分: 特征提取、多尺度特征融合和浅层深层特征融合。

本文算法的整体网络结构如图 1 所示, 该网络输入为一幅雾天图像, 输出为清晰无雾图像。为避

免池化导致的图像信息丢失,采用全卷积网络结构,并结合多尺度特征融合和浅层深层特征融合方法,

通过一个端到端的网络结构方式,直接从雾天图像去雾重建为无雾图像。




图1 多特征融合的 CNN

Fig. 1 Multi-feature fusion CNN

3.2 特征提取

特征提取部分包含了 10 层卷积层,分为 1 个单卷积层和 3 组连续的 3 层卷积层。单卷积层用于提取图像的轮廓信息,该层卷积核大小为 5×5 ,卷积核数量为 16。为保证输出图像的大小不变,本文对所有卷积操作的输出都进行对应的零填充操作。一个连续的 3 层卷积层为一组特征提取单元,通过 3 组特征提取单元,逐步得到图像的细节信息。

网络通过卷积进行特征提取,卷积的计算公式为

$$G_l(Y) = W_l * F_{l-1}(Y), \quad (3)$$

式中 W_l 为第 l 层卷积层, G_l 为输出的特征图, $*$ 为卷积操作。 W_l 由 $n_l \times f_l \times f_l$ 个参数组成,其中 f_l 为卷积核的尺寸, n_l 为卷积核的数量。

每个卷积层后接入激活函数,本文网络采用带参数的修正线性单元 (PReLU) 作为激活函数。PReLU 是对 ReLU 的改进,增加了参数的修正,在一定程度上能起到正则的效果,且能提高模型的泛化能力。同时,PReLU 可以有效避免梯度消失,实现网络的稀疏化,加快算法的收敛速度。PReLU 定义为

$$P_{\text{ReLU}}(x_i) = \max(x_i, 0) + a_i \min(0, x_i), \quad (4)$$

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 中设置为 0,而在 PReLU 中作为可学习参数,克服了 ReLU 的“特征死亡”^[25] 缺点。最终卷积层的输出为

$$F_l(Y) = P_{\text{ReLU}}[W_l * F_{l-1}(Y) + B_l], \quad (5)$$

式中 F_l 为最终的特征输出图, B_l 为第 l 层的偏置。

3.3 多尺度特征融合

由于雾天图像中既包含小尺度的纹理信息,又包含大的轮廓信息,因此为了进一步提取细节特征,本文采用多尺度特征融合方法。该方法由 5 层可训

练的卷积层组成,多尺度卷积层将 3 组特征提取单元的输出作为输入,通过 4 种大小分别为 7×7 、 5×5 、 3×3 和 1×1 的核进行特征融合。多尺度特征融合参数如表 1 所示。

表 1 多尺度特征融合参数

Table 1 Multi-scale feature fusion parameters

Layer type	Configurations
Convolution	Fm-16, Kernel-1x1, pad-0, stride-1, PReLU
Convolution	Fm-16, Kernel-3x3, pad-1, stride-1, PReLU
Convolution	Fm-16, Kernel-5x5, pad-2, stride-1, PReLU
Convolution	Fm-16, Kernel-7x7, pad-3, stride-1, PReLU

多尺度卷积过程为

$$F_{li}(Y) = P_{\text{ReLU}}[W_{li} * F_{l-1}(Y) + B_{li}], \quad (6)$$

式中 W_{li} ($i=1,2,3,4$) 为 4 组卷积核。4 组卷积核并行运算,每组卷积操作的特征图数量为 16,然后将运算结果合并成 64 个特征图,最后将 64 个特征图通过一个卷积核大小为 1×1 的卷积层,将多尺度特征信息加权合并,更好地实现雾天图像的去雾重建。

3.4 浅层与深层特征融合

为改善雾天图像去雾重建的效果,将浅层的轮廓特征与深层的细节特征进行特征图融合,且对融合后的特征图进行卷积操作,实现不同特征的加权。网络通过最小化重建得到的结果和真实视差图之间的代价来不断调整网络参数 $\Theta = \{W_l, B_l\}$ 。网络训练时采用均方误差 (MSE) 作为损失函数:

$$L(\Theta) = \frac{1}{n} \sum_{i=1}^n \|y_i - f^i(x)\|^2, \quad (7)$$

式中 y_i 为第 i 组清晰图像值, $f^i(x)$ 为本文网络的第 i 组输出值, n 为样本训练数目。利用随机梯度

下降法和网络的反向传播^[26]来最小化 MSE 以调整网络的参数,网络权重的更新过程为

$$\begin{cases} \Delta_{k+1} = 0.9 \times \Delta_k - \eta \times \frac{\partial L}{\partial W_k^l}, \\ W_{k+1}^l = W_k^l + \Delta_{k+1} \end{cases} \quad (8)$$

式中 Δ_k 为上一次的权重更新值, l 为层数, k 为网络的迭代次数, η 为学习率, W_k^l 为第 l 层的第 k 次迭代时的权重, $\partial L / \partial W_k^l$ 为对代价函数中相应的权重求偏导。权重采用均值为 0, 方差为 0.001 的高分布进行随机初始化, 模型在训练过程中采用固定学习率。

4 实验及结果分析

4.1 实验配置

实验在 MATLAB 2016a 环境下完成, 使用深

度学习中的 Caffe 框架, 并采用图形处理器 (GPU) 加速, 机器软、硬件分别为 CPU Intel E5-2637, 内存 64 GB, GPU NVIDIA TITAN X, 操作系统 Ubuntu 14.04, 统一计算设备架构 (CUDA) CUDA 7.5。

4.2 实验数据

本文使用的实验数据分两部分: 利用大气散射模型与清晰图像建立的雾天图像库和自然场景下采集的雾天图像。

采用美国明德大学的图像库^[27-30]建立雾天图像库, 该图像库包含各种场景图以及对应深度图, 选出 61 幅图像, 通过大气成像模型模拟雾天图像形成过程, 生成 61 幅雾天图像。选出其中 52 幅作为原始训练样本, 9 幅作为测试样本。图 2 为形成的雾天图像库中的部分图像。

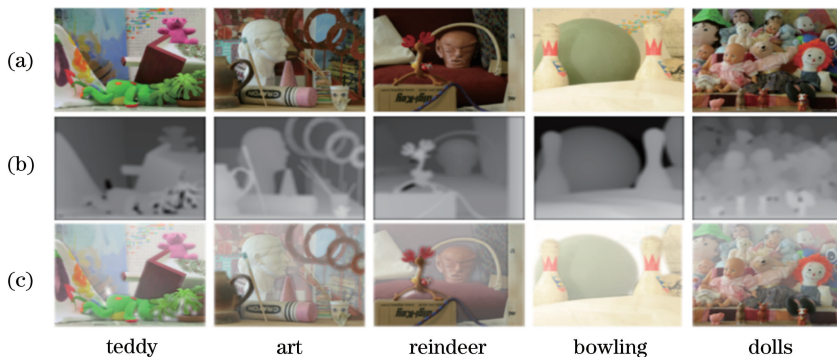


图 2 雾天图像库。(a)原始图像;(b)透射图;(c)雾天图像

Fig. 2 Fog image database. (a) Original images; (b) transmission images; (c) generated foggy images

训练样本: 卷积神经网络的训练需要大量的数据样本, 为提升训练数据的有效性, 本文对原始训练样本进行了扩大。训练样本由训练集和验证集两部分组成。训练集通过对原始的 52 幅训练样本进行 90° 、 180° 、 270° 旋转, 之后进行 2、3、4、5 倍的扩大, 得到 1040 ($52 \times 4 \times 5$) 幅图像作为最终的训练集。验证集从 52 幅雾天图像中任选 10 幅, 与训练集进行相同变换, 得到 200 ($10 \times 4 \times 5$) 幅图像作为训练过程中的验证集。

测试样本: 为了验证本文模型的有效性, 利用 Middlebury RGBD 数据集中的 9 幅图像生成雾天图像测试集, 对网络性能进行测试, 采用均方根误差 (RMSE)^[31] 和峰值信噪比 (PSNR)^[32] 作为结果的评价标准。

4.3 实验步骤

本文的实验步骤为: 1) 网络模型的训练; 2) 网络模型的测试; 3) 基于图像库的去雾结果与分析; 4) 真实场景雾天图像的去雾结果与分析; 5) 主观实验评

价。网络输入为 $64 \text{ pixel} \times 64 \text{ pixel}$ 的雾天图像, 训练标签为清晰无雾图像, 网络模型的训练学习率为 0.0001, 迭代次数为 10^6 次。本文采用全卷积网络设计, 其训练速度快于采用全连接的网络, 且避免了采用池化层后图像信息损失的问题。

4.4 基于图像库的去雾结果与分析

为了验证本文算法的有效性, 将本文方法与现有去雾方法 (Fattal 算法^[10]、He 算法^[11]、Meng 算法^[33] 和 Galdran 算法^[34]) 进行实验对比。图 3~5 分别为 cones、reindeer 和 teddy 的实验结果图。由图可知, 本文方法明显优于其他方法, 传统方法处理后图像的亮度和对比度都会与原图有所变化, 而且视觉上与原图相比有明显的失真, 本文方法更为真实, 没有对比度和亮度偏移的现象, 并且图像细节和颜色恢复较好。本文方法的 PSNR 最高达到了 28.018 dB, 远高于传统去雾方法, 这得益于卷积神经网络自动提取特征的特性, 使其能够更好地从雾天图像中提取所需要的特征并实现去雾重建。

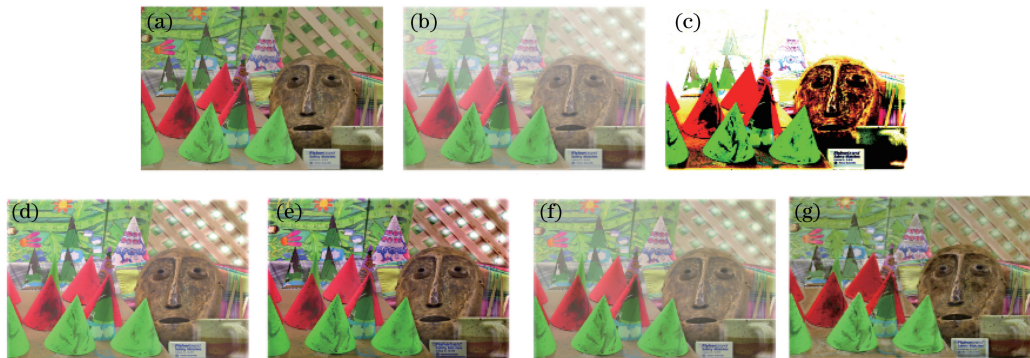


图 3 Cones 的去雾重建结果对比。(a)原始图像;(b)雾天图像;(c) Fattal 算法;(d) He 算法;
(e) Meng 算法;(f) Galdran 算法;(g)本文算法

Fig. 3 Comparison of defogging results of cones. (a) Original image; (b) foggy image; images defogged by (c) Fattal algorithm, (d) He algorithm, (e) Meng algorithm, (f) Galdran algorithm, and (g) proposed method

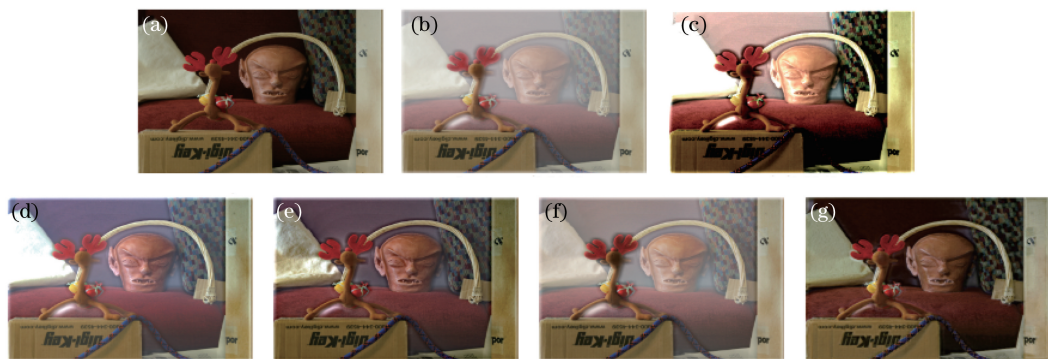


图 4 Reindeer 的去雾重建结果对比。(a)原始图像;(b)雾天图像;(c) Fattal 算法;(d) He 算法;
(e) Meng 算法;(f) Galdran 算法;(g)本文算法

Fig. 4 Comparison of defogging results of reindeer. (a) Original image; (b) foggy image; images defogged by (c) Fattal algorithm, (d) He algorithm, (e) Meng algorithm, (f) Galdran algorithm, and (g) proposed method

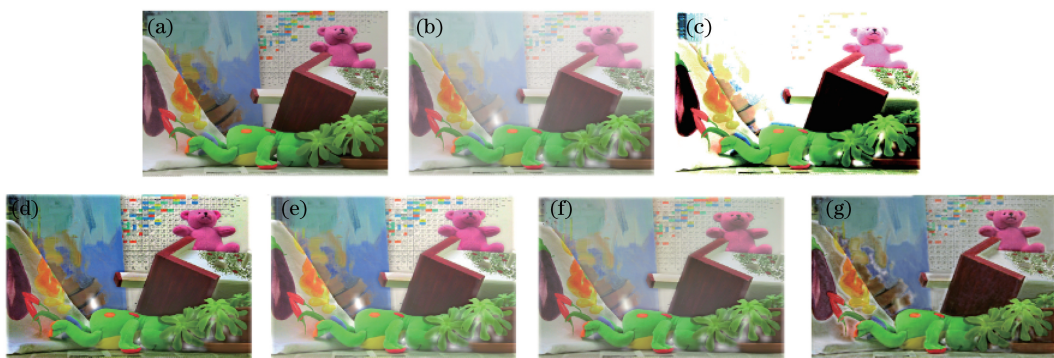


图 5 Teddy 的去雾重建结果对比。(a)原始图像;(b)雾天图像;(c) Fattal 算法;(d) He 算法;
(e) Meng 算法;(f) Galdran 算法;(g)本文算法

Fig. 5 Comparison of defogging reconstruction results of teddy. (a) Original image; (b) foggy image; images defogged by (c) Fattal algorithm, (d) He algorithm, (e) Meng algorithm, (f) Galdran algorithm, and (g) proposed method

不同图像去雾方法在 RMSE 和 PSNR 上的客观比较如表 2 所示。由表 2 可知,与传统算法相比,本文算法具有明显的优势,在所有测试图像上都能取得较好的效果,其中 RMSE 值比 Meng 算法

平均降低 2.765, PSNR 值比 Meng 算法平均提高 8.87 dB。从实验结果可知,相比于经典算法,本文模型针对不同的输入均能取得较好的去雾重建结果。

表 2 不同算法在数据集上的定量比较

Table 2 Quantitative comparison of different algorithms on the dataset

Image	Fattal algorithm		He algorithm		Meng algorithm		Galdran algorithm		Proposed algorithm	
	RMSE	PSNR /dB	RMSE	PSNR /dB	RMSE	PSNR /dB	RMSE	PSNR /dB	RMSE	PSNR /dB
Art	8.571	9.271	6.938	13.396	4.794	18.895	5.712	16.396	1.701	27.531
Bowling	8.091	9.526	5.354	16.529	4.221	19.245	6.010	15.674	1.691	28.018
Dolls	9.072	8.628	5.246	17.816	4.332	19.638	6.779	15.458	1.785	27.808
Reindeer	8.106	9.572	6.887	13.036	4.899	17.869	7.248	11.901	1.891	27.628
Cones	8.853	9.026	5.772	16.041	4.505	18.769	6.046	15.399	1.789	27.762
Teddy	8.669	9.472	6.211	15.309	4.565	18.743	5.650	16.529	1.816	27.719

为了验证本文提出的多特征融合网络模型对图像去雾重建的提升作用,采用 2 个网络模型进行定量对比分析,如图 6 所示。相对于本文提出的多特征融合网络,对比网络 1 去除了浅层与深层特征融合,通过卷积特征提取和多尺度特征融合后直接进行去雾重建;对比网络 2 采用单一尺度卷积核进行去雾重建。不同网络的实验结果对

比如表 3 所示。由表 3 可知,多特征融合对网络性能有明显提升,相对于对比网络 1,PSNR 提升最高可达 0.795 dB,平均达到 0.527 dB。对于 bowling 图像,提升最明显,这是由于 bowling 图像轮廓信息更多,而本文提出的多特征融合网络将浅层网络的轮廓信息和深层网络的细节融合,对雾天图像轮廓重建更为显著。




图 6 对比实验网络。(a)对比网络 1;(b)对比网络 2

Fig. 6 Contrastive experimental networks. (a) Compared network 1; (b) compared network 2

表 3 不同网络的 PSNR 对比结果

Table 3 Comparison of PSNR results of different networks

Image	dB		
	Multi-feature fusion network	Compared network 1	Compared network 2
Art	27.531	27.013	26.556
Bowling	28.018	27.223	27.021
Dolls	27.808	27.396	26.528
Reindeer	27.628	27.118	26.829
Cones	27.762	27.369	27.010
Teddy	27.719	27.282	26.903

由对比网络 1 和网络 2 看出,采用多尺度特征融合对图像重建具有提升作用,PSNR 提升明显,最高达到了 0.868 dB,平均达到 0.427 dB。对 dolls 图像提升最明显,这是由于 dolls 图像相对细节更多,而多尺度特征融合通过不同尺度的卷积核,从深层

特征中进一步提取特征进行去雾重建,相比于单一尺度,多尺度方式能重建出更多的图像细节。

为了比较多尺度网络和 Dehazenet 网络的性能,采用多尺度网络对有雾图像进行处理,得到雾天图像的透射图,并与 Dehazenet 网络得到的透射图进行比较。采用 PSNR、RMSE 和结构相似性(SSIM)作为透射图的评价指标。通过验证测试集中的 200 张有雾图像,得到各个指标的平均值,不同网络的实验结果对比如表 4 所示。由表 4 可知,相对于 Dehazenet 网络,多尺度网络的 SSIM 指标与 Dehazenet 网络相同,而 PSNR 和 RMSE 指标均优于 Dehazenet 网络,这是因为多尺度网络采用多特征融合方法,将浅层特征与深层特征进行融合,更多地重建了细节和轮廓信息,其表现更加优异。

表 4 不同网络实验结果对比

Table 4 Comparison of experimental results with different networks

Network	PSNR /dB	RMSE	SSIM
Dehazenet	70.9767	0.0787	0.9993
Multi-scale	71.0122	0.0774	0.9993

4.5 真实场景去雾结果与分析

为了验证本文算法对实际雾天图像的去雾效果,采用真实场景雾天图像对网络进行性能测试,如图 7 所示。由图 7 可知,本文方法可以有效地去除自然场景下的雾霾。相比于传统的方法,利用本文方法去雾处理后的图像噪声少,且细节更为丰富。利用 Fattal 算法去雾后图像颜色发生失真,且景深较大时会产生过曝光现象。He 算法能有效去雾,但在天空等雾程度大区域会出现明显噪声。Meng 算法是对暗通道方法的改进,改善了在天空等雾程度大区域的去雾效果,但仍存在噪声过大,细节不丰富的问题。Galdran 算法在景深较小时可以去除雾霾,但在景深较大时,去雾效果并不明显。本文方法对于天空等雾深的场景能很好的去雾,且无明显噪点,去雾重建后图像细节更为丰富,边缘特征更为丰富,具有更好的去雾结果。

为了进一步验证本文算法处理真实场景雾天图像的有效性,采用常用图像评价指标(图像均值、标

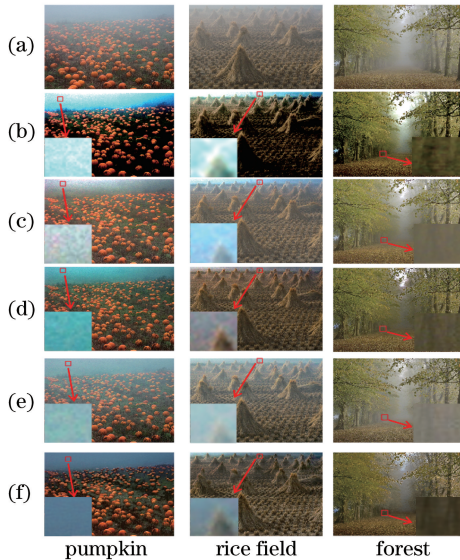


图 7 自然场景不同去雾算法比较。(a)原始图像;
(b) Fattal 算法;(c) He 算法;(d) Meng 算法;
(e) Galdran 算法;(f)本文算法

Fig. 7 Comparison of different defogging algorithms in natural scene. (a) Original image; images defogged by (b) Fattal algorithm, (c) He algorithm, (d) Meng algorithm, (e) Galdran algorithm, and (f) proposed method

准差、信息熵、彩色熵和平均梯度)对不同去雾算法进行对比。图像均值反映了图像的平均明暗程度;标准差反映了灰度均值的离散程度;信息熵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;彩色熵是图像 R、G、B 三个通道包含的信息量的总和;平均梯度即图像的清晰度,反映图像对细节对比的表达能。本文利用 CIE Lab 颜色空间的 L 分量计算对比度:

$$C = \sum_{i=1}^n \frac{\sqrt{\frac{1}{N_i} \|L_i(x) - \bar{L}_i\|_2^2}}{\bar{L}_i} \quad (9)$$

式中 n 为 L 分量分块数目, N_i 为第 i 个 L 分量块的像素数, L_i 为第 i 个 L 分量块中像素点 x 的像素值, \bar{L}_i 为第 i 个 L 分量块中像素点像素值的均值。

自然场景下不同算法的客观指标对比结果如表 5 所示,本文算法的平均标准差为最大值,比 Fattal 算法、He 算法、Meng 算法和 Galdran 算法平均提高 0.3%、2.3%、4.1% 和 16.0%。本文算法的信息熵较大,表明本文算法可以较好地恢复图像信息。本文算法的对比度比传统方法的对比度均有所提升,表明本文算法能够提高图像的对比度。本文算法在 Pumpkin 图像上对天空处理效果较好,噪声少,当景深较大时可以有效去除雾霾。

综合主观和客观评价指标可知,本文算法可以有效恢复雾天图像,相对于传统去雾算法,本文算法去雾处理后的图像噪声少、对比度较高且细节更为丰富。

4.6 主观实验评价结果

本文采用主观实验对恢复后的图像进行质量评价。随机选取雾天图像库中的图像 10 幅,真实场景雾天图像 10 幅,共 100(20×5 种算法)幅图像。采用 Eprime 实验软件、冠捷 22 英寸(1 英寸=2.54 cm) 1920 pixel×1080 pixel 显示器对图片进行显示。实验随机选取视觉生理正常的被试者共 22 人,其中男性 12 人,女性 10 人。为避免杂散光影响被试者的主观评价结果,实验需在暗室中进行^[35]。为避免视觉疲劳对实验的影响,实验的时间控制在 30 min 内完成。实验采用双刺激方法,即第 1 张为没有去雾图像,第 2 张为利用不同算法得到的去雾图像。对图像进行 1~10 分的质量评分,其中 10 代表质量最好,1 代表质量最差,被试者没有相关去雾方向的研究,其平均主观意见分(MOS)体现了个人偏好,实验结果如图 8 所示。从图 8 可以看出,在所有算法中,本文算法的 MOS 最高,表明本文算法主观评价良好,体现出人眼对本文算法的增强效果舒适度较高。

表5 自然场景下算法评价指标对比

Table 5 Comparison of algorithm evaluation index in natural scene

Method	Figure	Average	Standard deviation	Information entropy	Color entropy	Mean gradient	Contrast
Fattal	Pumpkin	68.4971	61.3326	4.8398	14.2389	10.3731	7.6360
	Rice field	45.9848	64.0856	5.0569	14.9456	11.6958	14.4347
	Forest	81.1157	66.5824	7.0815	20.6306	13.8976	13.9009
He	Pumpkin	99.3012	64.9204	7.6468	22.3456	11.1668	8.9083
	Rice field	77.0238	59.2287	7.2348	21.0209	12.2187	13.3602
	Forest	87.1907	61.9286	7.3366	21.0584	12.1417	13.6283
Meng	Pumpkin	84.5235	60.2172	7.3457	21.3919	11.6948	7.5397
	Rice field	74.0616	63.7294	6.9783	20.0772	11.9825	13.5021
	Forest	85.5998	60.5597	7.2569	20.5494	11.4450	13.3889
Galdran	Pumpkin	94.2411	50.1966	7.5738	22.5294	11.3859	7.6224
	Rice field	85.7172	47.1278	7.5238	21.4681	11.1032	10.4738
	Forest	87.6054	43.5790	7.3710	20.3288	10.4662	11.5028
Proposed	Pumpkin	84.5925	66.6132	7.6645	20.8777	10.1556	10.4233
	Rice field	79.6453	67.8168	7.1421	21.7686	11.2558	15.6302
	Forest	87.5713	58.2448	7.3712	20.5125	12.3077	14.0203

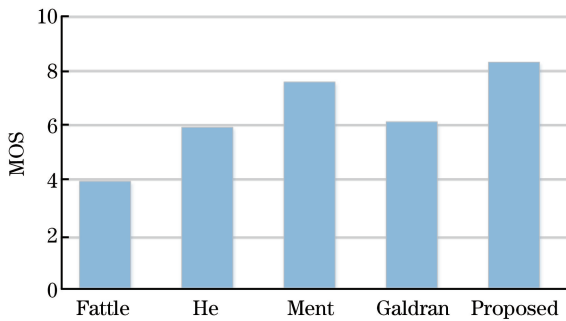


图8 不同去雾方法的主观评价

Fig. 8 Subjective evaluation of different defogging methods

5 结 论

目前的雾天图像去雾算法主要是通过手工提取特征的方法。卷积神经网络理论的出现给图像去雾重建带来了新思路,其充分考虑了图像目标在空间中的平移、旋转,以及缩放不变性,将传统图像重建技术上的特征提取和聚合结合在一起,利用网络本身的学习能力主动提取特征。通过深入研究卷积神经网络在雾天图像去雾上的应用,提出了一种多特征融合的卷积神经网络去雾重建算法。通过一个端到端的网络,将深层特征与浅层特征融合,并采用多尺度特征融合的方法克服了传统算法计算复杂度高、不能有效提取特征的缺点。实验结果表明,本文算法可重建得到清晰的无雾图像,且能应用于实际。随后的研究内容应重点考虑加深网络的深度,或采取其他更有效的网络模型,以获得更优的去雾效果。

参 考 文 献

- [1] Lu S H, Huang H Z, Zhang H Z, *et al.* Comprehensive performance evaluation for video surveillance cameras [J]. *Laser & Optoelectronics Progress*, 2015, 52(9): 091102.
卢树华, 黄鸿志, 张鸿洲, 等. 视频监控摄像机性能参数综合评价研究[J]. *激光与光电子学进展*, 2015, 52(9): 091102.
- [2] Zhang S H, Chen H F, Zhang H T, *et al.* Design of optical lens for traffic surveillance system [J]. *Laser & Optoelectronics Progress*, 2011, 48(2): 022202.
张善华, 陈慧芳, 张海艇, 等. 用于交通监控系统的光学成像镜头的设计 [J]. *激光与光电子学进展*, 2011, 48(2): 022202.
- [3] Li S J, Fan X, Zhu B, *et al.* A method for small infrared targets detection based on the technology of motion blur recovery [J]. *Acta Optica Sinica*, 2017, 37(6): 0610001.
李思俭, 樊祥, 朱斌, 等. 基于运动模糊复原技术的红外弱小目标检测方法 [J]. *光学学报*, 2017, 37(6): 0610001.
- [4] Wu Y Q, Yin D Y. Detection of small target in infrared image based on background prediction by FLS-SVM [J]. *Acta Optica Sinica*, 2010, 30(10): 2806-2811.
吴一全, 尹丹艳. 基于 FLS-SVM 背景预测的红外弱小目标检测 [J]. *光学学报*, 2010, 30(10): 2806-2811.

- [5] Stark J A. Adaptive image contrast enhancement using generalizations of histogram equalization [J]. IEEE Transactions on Image Processing, 2000, 9 (5): 889-896.
- [6] Xu Z Y, Liu X M, Ji N. Fog removal from color images using contrast limited adaptive histogram equalization [C]// 2nd International Congress on Image and Signal Processing, 2009: 10955452.
- [7] Yang W T, Wang R G, Fan S, *et al.* Variable filter Retinex algorithm for foggy image enhancement [J]. Journal of Computer-Aided Design & Computer Graphics, 2010, 22(6): 965-971.
杨万挺, 汪荣贵, 方帅, 等. 滤波器可变的 Retinex 雾天图像增强算法 [J]. 计算机辅助设计与图形学学报, 2010, 22(6): 965-971.
- [8] Yu P, Hao C C. Fractional differential and multiscale Retinex combined foggy image enhancement [J]. Laser & Optoelectronics Progress, 2018, 55 (1): 011012.
余萍, 郝成成. 分数阶微分和多尺度 Retinex 联合的雾霭图像增强 [J]. 激光与光电子学进展, 2018, 55 (1): 011012.
- [9] Tan R T. Visibility in bad weather from a single image [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2008: 1-8.
- [10] Fattal R. Single image dehazing [J]. ACM Transactions on Graphics, 2008, 27(3): 72.
- [11] He K M, Sun J, Tang X O. Single image haze removal using dark channel prior [C]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(12): 2341.
- [12] Tarel J P, Hautière N. Fast visibility restoration from a single color or gray level image [C]. IEEE 12th International Conference on Computer Vision, 2009: 2201-2208.
- [13] Sun X M, Sun J X, Zhao L R, *et al.* Improved algorithm for single image haze removing using dark channel prior [J]. Journal of Image and Graphics, 2014, 19(3): 381-385.
孙小明, 孙俊喜, 赵立荣, 等. 暗原色先验单幅图像去雾改进算法 [J]. 中国图象图形学报, 2014, 19 (3): 381-385.
- [14] Yang A P, Bai H H. Nighttime image defogging based on the theory of Retinex and dark channel prior [J]. Laser & Optoelectronics Progress, 2017, 54 (4): 041002.
杨爱萍, 白煌煌. 基于 Retinex 理论和暗通道先验的夜间图像去雾算法 [J]. 激光与光电子学进展, 2017, 54(4): 041002.
- [15] He K M, Zhang X Y, Ren S Q, *et al.* Spatial pyramid pooling in deep convolutional networks for visual recognition [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37 (9): 1904-1916.
- [16] Li T, Sun J G, Zhang X J, *et al.* Research of hyperspectral image classification based on hierarchical sparse representation feature learning [J]. Laser & Optoelectronics Progress, 2016, 53 (9): 091001.
李铁, 孙劲光, 张新君, 等. 基于分层稀疏表示特征学习的高光谱图像分类研究 [J]. 激光与光电子学进展, 2016, 53(9): 091001.
- [17] Ouyang W L, Luo P, Zeng X Y, *et al.* DeepID-Net: multi-stage and deformable deep convolutional neural networks for object detection [J]. Eprint Arxiv, 2014.
- [18] Ye G L, Sun S Y, Gao K J, *et al.* Nighttime pedestrian detection based on faster region convolution neural network [J]. Laser & Optoelectronics Progress, 2017, 54(8): 081003.
叶国林, 孙韶媛, 高凯珺, 等. 基于加速区域卷积神经网络的夜间行人检测研究 [J]. 激光与光电子学进展, 2017, 54(8): 081003.
- [19] Liu S, Liang X D, Liu L Q, *et al.* Matching-CNN meets KNN: quasi-parametric human parsing [J]. IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1419-1427.
- [20] 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.
- [21] McCartney E J. Optics of the atmosphere: scattering by molecules and particles [J]. IEEE Journal of Quantum Electronics, 1977, 24(7): 779-779.
- [22] Ma M, Li Y B. Multi-level image sequences and convolutional neural networks based human action recognition method [J]. Journal of Jilin University Engineering and Technology Edition, 2017, 47(4): 1244-1252.
马森, 李贻斌. 基于多级图像序列和卷积神经网络的人体行为识别 [J]. 吉林大学学报(工学版), 2017, 47(4): 1244-1252.
- [23] Durbin R, Rumelhart D E. Product units: a computationally powerful and biologically plausible extension to backpropagation networks [J]. Neural Computation, 1989, 1(1): 133-142.

- [24] Liu W J, Liang X J, Qu H C. Learning performance of convolutional neural networks with different pooling models [J]. *Journal of Image and Graphics*, 2016, 21(9): 1178-1190.
刘万军, 梁雪剑, 曲海成. 不同池化模型的卷积神经网络学习性能研究 [J]. *中国图象图形学报*, 2016, 21(9): 1178-1190.
- [25] Zeiler M D, Fergus R. Visualizing and understanding convolutional networks [J]. Springer International Publishing, 2014, 8689: 818-833.
- [26] 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.
- [27] Scharstein D, Szeliski R, Zabih R. A taxonomy and evaluation of dense two-frame stereo correspondence algorithms [J]. *International Journal of Computer Vision*, 2002, 47(1/2/3): 7-42.
- [28] Scharstein D, Szeliski R. High-accuracy stereo depth maps using structured light [C]. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 2003: 195-202.
- [29] Scharstein D, Pal C. Learning conditional random fields for stereo [C]. *IEEE Conference on Computer Vision and Pattern Recognition*, 2007: 9738080.
- [30] Hirschmuller H, Scharstein D. Evaluation of cost functions for stereo matching [C]. *IEEE Conference on Computer Vision and Pattern Recognition*, 2007: 9738137.
- [31] 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.
- [32] Kwon H H, Tai Y W, Lin S. Data-driven depth map refinement via multi-scale sparse representation [C]. *IEEE Conference on Computer Vision and Pattern Recognition*, 2015: 159-167.
- [33] Meng G, Wang Y, Duan J, *et al.* Efficient image dehazing with boundary constraint and contextual regularization [C]. *IEEE International Conference on Computer Vision*, 2013: 617-624.
- [34] Galdran A, Vazquez-Corral J, Pardo D, *et al.* Fusion-based variational image dehazing [J]. *IEEE Signal Processing Letters*, 2017, 24(2): 151-155.
- [35] Huynh-Thu Q, Barkowsky M, Callet P L. The importance of visual attention in improving the 3D-TV viewing experience: overview and new perspectives [J]. *IEEE Transactions on Broadcasting*, 2011, 57(2): 421-431.