

一种新型的基于深度学习的单幅图像去雨方法

钟 菲 杨 斌

(南华大学电气工程学院 湖南 衡阳 421001)

摘 要 雨滴严重影响了图像的视觉效果和后续的图像处理应用。目前,基于深度学习的单幅图像去雨方法能够有效挖掘图像的深度特征,其去雨效果优于传统方法;然而,随着网络深度的增加,网络容易出现过拟合的现象,使得去雨效果遇到瓶颈。文中在继承深度学习优点的基础上,学习有雨/无雨图像之间的残差,然后将残差与源图像进行重构,从而获得无雨图像。该方式大幅增加了网络深度,并加快了算法的收敛速度。分别利用通过不同方式获取的雨滴图像对所提方法进行实验验证,并将该方法与当前最新的去雨滴方法作比较,结果表明所提算法的去雨效果更好。

关键词 雨滴去除,深度学习,卷积神经网络

中图法分类号 TP391.41 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2018.11.045

Novel Single Image Raindrop Removal Algorithm Based on Deep Learning

ZHONG Fei YANG Bin

(School of Electrical Engineering, University of South China, Hengyang, Hunan 421001, China)

Abstract Raindrops seriously affect the visual effect of images and subsequent image processing applications. At present, the single image raindrop removal method based on deep learning can effectively mining depth features of image, so its effect of removing rain is better than traditional methods. However, with the increasing of network depth, overfitting is easy to occur, resulting in the bottleneck of rain removal effect. This paper proposed a novel single image raindrop removal algorithm based on deep learning. Firstly, on the basis of inheriting the advantages of deep learning, network learns the residuals between rain images and no-rain images. Secondly, the raindrop-removed image is reconstructed from the residual image and the source image. Through these steps, the depth of network is increased and the convergence speed is accelerated. In terms of performance evaluations, a dataset consisting of images in various scenes was used to test the proposed method, and the results were also compared with those of the state-of-the-art raindrop removal methods. The experimental results show the superiority of the proposed algorithm.

Keywords Raindrop removal, Deep learning, Convolutional neural network

1 引言

户外恶劣天气(如雨、雪、雾霾等)容易造成图像质量下降,严重影响图像的视觉效果以及视觉系统在目标追踪、目标识别、信息检索等方面的应用。因此,研究雨天图像的复原问题也越来越受到各国研究人员的重视。成功消除雨雪等天气对图像造成的影响可以极大地提高计算机视觉系统的稳定性,进而给工业生产、交通监控等领域带来巨大的应用价值。然而,在单幅雨滴图像中没有雨滴的动态时空特性,使得检测和去除图像中的雨滴工作变得非常困难。

近年来,大量的去雨方法被相继提出,其中典型的单幅图像去雨方法是将图像中的雨滴看成一种特殊的高频噪声,然后采用图像分解或雨滴识别的方法滤除雨滴^[1-5]。Kang 等^[4]提出了基于形态分量分析的单幅图像去雨算法。该算法利用

了稀疏表示在图像去噪上的优越性,通过字典学习建立图像高频分量的完备字典库,然后通过稀疏编码来重建无雨图像。然而,在稀疏表示恢复图像高频部分的过程中会有信息损失,容易造成修复图像局部纹理的模糊。Luo 等^[5]提出了一种具有分类能力的判别式稀疏编码方法,并用其来提高雨滴检测的准确性。这些方法的去雨效果虽有一定的改善,但由于仅利用了浅层的图像特征,去雨效果仍受到一定的限制。当图像中存在与雨滴结构和方向相似的目标时,这些方法很难在消除雨滴的同时保留原有的结构信息。

深度卷积神经网络(Convolutional Neural Network, CNN)具有深层的网络结构,可以表达复杂的深层图像特征^[6],并在图像识别^[7]、图像去雨^[8-10]、图像修复^[11-12]等领域取得了非常好的效果。2013 年,David 等^[8]通过训练一种特殊的 CNN 来去除单幅图像中的雨滴,首次将深度学习^[13]的

到稿日期:2017-10-14 返修日期:2018-01-06 本文受国家自然科学基金(61871210,61102108),湖南省自然科学基金(2016JJ3106),湖南省教育厅项目(16B225, YB2013B039),南华大学青年英才支持计划和南华大学重点学科(NHXK04)资助。

钟 菲(1991—),女,硕士生,主要研究方向为图像处理、模式识别和深度学习;杨 斌(1980—),男,博士,副教授,主要研究方向为图像信息融合、稀疏表示理论、多尺度几何分析、视觉神经计算机理及网络模型等, E-mail: yangbin01420@163.com(通信作者)。

方法用于图像去雨工作,其主要思想是收集无雨/有雨的对称图像库,通过最小化预测图像块和无雨图像块之间的均方差来训练网络参数,使网络达到去雨滴的目的。随后,Fu等^[9-10]结合图像分解和深度学习的优势,将输入图像中的雨滴作为特定的高频分量,从频域的角度去除雨滴,以提高单幅图像雨滴去除的视觉效果。基于深度学习的单幅图像雨滴去除方法有效地利用了图像的深层特征,去雨效果好,受到广泛认可。深度卷积网络往往包含较多的卷积层处理,算法效率普遍不高。为了快速且有效地去除单幅图像中的雨滴,同时保留完整的图像信息,本文在深度卷积网络的基础上引入残差学习^[14],提出了一种新型的基于深度学习的单幅图像去雨方法。该方法通过对收集无雨/有雨的对称图像库之间的残差分量进行学习,很大程度上解决了深度 CNN 随着深度增加而带来的网络退化问题^[15]。与传统的 CNN 网络相比,学习残差分量能够减少网络训练参数,网络收敛速度快,图像修复能力强。

传统单幅图像去雨算法均分别对 RGB 颜色空间的 3 个颜色通道进行去雨处理,该过程可能产生一定的颜色信息的丢失,且恢复图像的饱和度不佳。经分析发现,雨滴主要存在于图像的亮度分量中,而对分辨率较低的彩色分量影响很小。为了更有效地保留源图像的颜色信息,本文所提的基于深度学习的雨滴图像修复只对亮度分量进行处理,而对分辨率较低的彩色分量不做处理,避免了颜色信息的损失。在实验部分,分别使用人工添加雨滴的图像^[9-10,16]和真实场景下拍摄的雨滴图像对本文方法进行验证,所有实验图像中的雨滴都能够全部去除,并且源图像颜色信息保留完整,恢复图像的饱和度很好。与当前最新的单幅图像去雨滴算法相比,本文方法的实验结果具有明显的优越性。

2 基于深度学习的单幅雨滴去除模型

基于深度学习的单幅雨滴去除的核心在于设计更有效的有雨图像与无雨图像的端对端映射模型,实现雨滴区域的修复。极深网络(Very Deep Networks for SR, VDSR)^[12]是一种基于深度学习的前馈 CNN 网络,在继承 CNN 网络优点的基础上,极大地避免了深层 CNN 网络随着层数增加容易过拟合的问题,高效地探索和捕捉了图像的各种特征,在图像修复任务中表现出优异的性能。因此,将 VDSR 网络应用于单幅图像的雨滴去除过程中,可有效提高雨滴修复性能。VDSR 网络由多个级联的卷积层组成,用于学习雨滴图像和无雨滴的理想恢复图像之间的残差图像,便于雨滴图像的修复。本文基于 VDSR 的雨滴去除网络结构示意图如图 1 所示。该方法包含 YUV 空间变换、深度特征学习、图像重构以及 YUV 逆变换 4 个部分。YUV 空间变换将雨滴图像 I 由 RGB 空间变换到 YUV 空间,得到图像 I 的亮度分量 Y_I 和颜色分量 $\{U_I, V_I\}$;深度特征学习提取雨滴源图像 I 的亮度分量 Y_I 和不含雨滴的理想恢复图像 J 的亮度分量 Y_J 的残差分量,即 $F(Y_I)=Y_J-Y_I$,其中 $F(\cdot)$ 表示网络映射;图像重构将学习的残差图像 $F(Y_I)$ 与亮度分量 Y_I 重新叠加,得到重构图像的亮度分量 $\hat{Y}_J$;YUV 逆变换将重构图像 $\hat{Y}_J$ 恢复到

RGB 空间,得到最终的彩色无雨滴图像 J 。




图 1 基于 VDSR 的雨滴去除方法示意图
Fig. 1 Schematic diagram of raindrop removal algorithm based on VDSR

2.1 YUV 空间变换

图 2 给出了同一场景下无雨图像和含雨滴图像在 YUV 空间中的亮度和颜色分量对比图,其中,图 2(a)为无雨图像,图 2(b)为图 2(a)的亮度分量,图 2(c)和图 2(d)为图 2(a)的颜色分量;图 2(e)为含雨图像,图 2(f)为图 2(e)的亮度分量,图 2(g)和图 2(h)为图 2(e)的颜色分量。分别对比图 2(b)和图 2(f)、图 2(c)和图 2(g),以及图 2(d)和图 2(h),不难发现:图 2(e)中的雨滴主要存在于高分辨率的亮度分量(见图 2(f))中,而对分辨率较低的彩色分量的影响很小。因此,本文算法中仅对源图像的亮度分量进行去雨处理。该步骤不仅可以减少待处理的数据量和网络参数,便于网络学习;而且不对源图像颜色分量进行操作,可以有效地保留更多源图像的颜色信息。




图 2 无雨图像和雨滴图像的 YUV 分量对比图
Fig. 2 Comparison of YUV components between no-rain images and raindrop images

2.2 深度特征学习

基于图像修复的深层 VDSR 网络将对含雨滴图像 I 的亮度分量 Y_I 进行多层卷积处理和非线性映射,学习不含雨滴的理想恢复图像 J 的亮度分量 Y_J 的残差图像,即 $F(Y_I)=Y_J-Y_I$ 。将传统 CNN 网络对 Y_J 的学习转化为对 $F(Y_I)$ 的学习,不仅避免了随着网络深度的增加而训练产生过拟合的现象,而且使得网络整体更容易优化,效率也大幅提高。

卷积层是基于图像修复的 VDSR 网络训练雨滴去除模型的核心,其具有局部连接和权值共享的特点。以单幅图像 I 为例,网络输入图像 I 的亮度分量 Y_I ,首先通过卷积层 Conv. 1,得到特征图 $F^1(Y_I)$,表达式如下:

$$F^1(Y_I)=\max(0,W_1 * Y_I+B_1) \tag{1}$$

其中, F^1 表示第一个卷积层的输出, W_1 为第 1 层网络权值, B_1 为对应第 1 层神经元的偏置向量, “ $*$ ”表示卷积操作。 W_1 的尺寸为 $c \times f_1 \times f_1 \times n_1$, c 是输入图像中通道的数量(只对 Y 通道进行处理, 因此 $c=1$), f_1 是单个滤波器的尺寸, n_1 是滤波器的数量。

为了提取图像的深层特征, 卷积层与卷积层之间通过非线性映射增加网络深度, 即将卷积层 Conv. 1 输出的 n_1 个特征图像作为下一个卷积层的输入, 并与一个或者多个卷积核进行卷积操作, 产生一个或者多个输出, 表达式如下:

$$F^l(Y_l) = \max(0, W_l * F^{l-1}(Y_l) + B_l) \tag{2}$$

其中, F^l 表示第 $l(l=2, 3, \dots, D-1)$ 个卷积层的输出, F^{l-1} 表示第 $l-1$ 个卷积层的输出(上一层的输出作为下一层的输入), W_l 表示第 l 个卷积层的权重, B_l 表示第 l 个卷积层的偏置, 偏置的维数与该层卷积核的数量保持一致。

为了重构雨滴源图像 Y_I 和不含雨滴图像 Y_J 的残差图像 $F(Y_I)$, 需要将卷积层提取的残差特征块进行聚合, 即以传统求均值的方式对特征图进行卷积滤波操作, 表达式如下:

$$F(Y_I) = W_D * F^{D-1}(Y_I) + B_D \tag{3}$$

将残差图像 $F(Y_I)$ 与亮度分量 Y_I 进行叠加, 得到重构图像的亮度分量 $\hat{Y}_J$, 表达式如下:

$$\hat{Y}_J = F(Y_I) + Y_I \tag{4}$$

通过以上不同形式的卷积操作, 权重和偏置项被优化, 不仅简化了网络, 而且弥补了稀疏编码方法无前馈过程的缺点, 非线性映射的向前参数传递过程有助于深度图像特征的筛选, 同时, 根据输入雨滴图像与输出非雨滴图像之间信息的极大相似性计算的残差图像 $F(Y_I)$, 大部分的值接近 0, 使得整个网络在训练过程中的收敛速度更快。

2.3 去雨滴模型训练

网络通过最小化重建得到的结果和真实视图之间的代价来不断调整网络参数 $\Theta = \{W_1, W_2, \dots, W_D, B_1, B_2, \dots, B_D\}$ 。对于一组不含雨滴的理想恢复图像 $Y_{J,a}$ 和一组由网络重建得到的无雨图像 $\hat{Y}_{J,a}$, 我们使用均方差 (Mean Square Error, MSE) 作为损失函数来估计网络参数。MSE 的形式如下:

$$L(\Theta) = \frac{1}{N} \sum_{a=1}^N \| F(Y_{I,a}) + Y_{I,a} - \hat{Y}_{J,a} \|_F^2 \tag{5}$$

其中, N 为训练样本的数量, $F(Y_{I,a})$ 为第 a 个有雨滴图像的亮度分量 Y_I 预测的残差分量 $F(Y_I)$, $Y_{I,a}$ 为第 a 个有雨滴图像的亮度分量 Y_I , $\hat{Y}_{J,a}$ 为预测的第 a 个无雨滴图像 $\hat{Y}_{J,a}$ 。

利用随机梯度下降法和网络的反向传播来最小化 MSE, 以调整网络的参数。网络权重的更新过程为:

$$\Delta_{k+1} = 0.9 \times \Delta_k - \eta \times \frac{\partial L}{\partial W_k^l}, W_{k+1}^l = W_k^l + \Delta_{k+1} \tag{6}$$

其中, Δ_k 表示上一次的权重更新值, l 表示网络层数, k 表示网络的迭代次数, η 表示学习率, W_k^l 表示第 l 层的第 k 次迭代时的权重, $\frac{\partial L}{\partial W_k^l}$ 表示对代价函数中相应的权重求偏导。

3 实验结果与分析

实验环境为 Intel core i3 CPU 4170, 64 位的 Windows 7,

依赖的配置基础是 VS 2013 ultimate, Matlab R2015a, 以及深度学习工具箱 caffe^[17] 和 MatConvNet^[18]。在 caffe 上完成网络搭建和网络学习, 在 MatConvNet 上完成网络模型的性能测试。

3.1 训练样本的预处理

实验用到了 1000 幅无雨图像, 这些图像分别来源于 UCID 数据集^[19]、BSD 数据集^[20] 和谷歌图像库。针对每一幅无雨图像, 使用文献[10]提供的模拟添加雨滴的方法产生 14 幅不同方向、不同大小的雨滴图像, 共生成 14000 幅雨滴图像。实验中随机抽取 9100 幅图像, 并结合原无雨图像构成训练数据。将训练图像随机分成 982784 张 41×41 的图像块作为训练样本进行网络学习; 剩余的 4900 幅无雨/有雨滴图像对作为测试样本, 用于评估训练的网络模型。

3.2 网络参数的设置

实验设置网络训练权值衰减为 10^{-4} , 训练与测试时动量值为 0.9, 滤波块大小设为 64, 网络训练周期设为 156; 初始学习率设置为 0.1, 与文献[10, 12]的初始学习率一致。文献[12]中的实验已证明: 初始学习率越大, 网络收敛速度越快, 但学习率过大容易造成网络梯度消失/爆炸。为了避免这种现象的发生, 本文使用随机梯度下降法, 每 20 个 epochs 将学习率乘以 0.1。

此外, 为了研究网络深度对算法收敛速度以及去雨效果的影响, 在其他参数不变的情况下, 对比当网络深度参数 $D=10, 20$ 和 30, 训练 $epoch=40$ 时, 100 幅包含了 14 种不同场景、不同方向、不同雨滴大小的图像的处理效果。100 幅图像的处理结果(包含平均峰值信噪比(Peak Signal to Noise Ratio, PSNR)、结构相似性度量指标 (Structural Similarity Index Metric, SSIM) 和平均修复时间) 如表 1 所列。

表 1 100 幅雨滴图像在不同网络深度条件下的处理结果
Table 1 Processing results of 100 raindrop images with different network depth


卷积层数 D	PSNR/dB	SSIM	Time/s
10	28.65	0.8584	4.14
20	30.01	0.8892	6.67
30	30.96	0.9041	10.18

从表 1 可以看出, 随着网络层数的增加, 单幅图像的去雨效果有所提高, 但是单幅图像的测试时间增加较多。20 层的 VDSR 网络对单幅图像的测试时间只比 10 层的 VDSR 网络多 2.53s, 但是每一幅雨滴图像的 PSNR 提高了 1.36 dB, SSIM 提高了 0.0308。30 层的 VDSR 网络对单幅图像的 PSNR 和 SSIM 都有一定的提升, 但是测试单幅图像的平均时间也增加了 3.51s。因此, 选择 20 层卷积的网络实现单幅图像的雨滴去除比较合适。需要指出的是, 在更高配置的硬件平台上, 更深层的网络可以进一步提高算法的正确性并缩短计算时间。

3.3 实验结果分析

为验证本文算法的性能, 将其与基于稀疏字典学习算法^[5]、基于卷积网络的去雨算法^[9] 以及基于残差识别网络的去雨算法^[10] 的处理效果进行比较。所有对比方法的程序均为作者提供的源代码, 同时采用对应论文中提供的最优参数

设置¹⁾⁻³⁾。图 3 给出不同算法对人工雨滴图像的 3 组处理效果实例。为了更加清晰地描述雨滴去除效果的细节部分,我们使用矩形标签框任意挑选图像的一个区域,并放大显示在相应图像左下角的矩形标签框中。



注:第一行是“雨伞”图像;第二行是“鸟”图像;第三行是“兔子”图像

图 3 对称图像的去雨效果图

Fig. 3 Raindrop removal effect of symmetrical images

表 2 不同去雨算法的 PSNR 和 SSIM 评估

Table 2 Evaluation of PSNR and SSIM of different rain removal algorithms

Images	Indices	文献[2]	文献[9]	文献[10]	本文算法
雨伞	PSNR/dB	27.88	27.69	31.82	33.63
	SSIM/dB	0.8630	0.8903	0.9250	0.9278
鸟	PSNR/dB	21.31	22.12	29.35	31.59
	SSIM/dB	0.6801	0.8736	0.8940	0.9175
兔子	PSNR/dB	21.17	22.30	28.41	29.59
	SSIM/dB	0.6593	0.8613	0.8522	0.8895
Rain12 ^[16]	PSNR/dB	27.10±2.26	30.29±4.74	33.42±4.24	34.12±3.28
	SSIM/dB	0.7434±0.0741	0.9140±0.0527	0.9430±0.0357	0.9435±0.0451

表 3 给出了本文算法与其他算法在去雨速度方面的比较。可以看出,本文方法虽然比文献[10]耗时长,但可以获得更高的 PSNR 和 SSIM。而且,在测试文献[16]提供的 12 幅大小为 481×321 的雨水图像时,本文方法的计算时间更加稳定(文献[5]方法的计算时间偏差为 31.90 s,文献[9]方法的计算时间偏差为 0.49 s,文献[10]方法的计算时间偏差为 0.17 s,而本文方法的计算时间偏差只有 0.11 s)。

表 3 对称测试图像去雨滴消耗的时间

Table 3 Consumption time of raindrop removal of symmetrical test images

(单位:s)					
Images	图像尺寸	文献[5]	文献[9]	文献[10]	本文算法
雨伞	350×550×3	204.89	19.19	3.33	17.63
鸟	480×576×3	229.06	26.06	5.21	19.41
兔子	494×640×3	303.21	28.89	6.27	22.49
Rain12 ^[16]	481×321×3	200.32±	13.31±	1.88±	6.12±
		31.90	0.49	0.17	0.11

综合分析,本文算法的计算时间有一定的优势。

图 4 为不同算法对下雨天拍摄的 5 组图像的去雨结果图像。图 4(a)是在不同大小、不同落雨方向、不同场景下拍摄的真实雨景图;图 4(b)是文献[5]方法的去雨效果图,虽然去除了雨滴,但同时也使图像细节变得模糊;图 4(c)是文献[9]方法的去雨效果图,在图像中有个别雨滴没有去除干净;图

图 3(a)为原始无雨滴的参考图像,图 3(b)为含雨滴的待修复图像,图 3(c)—图 3(e)分别为文献[5]、文献[9]、文献[10]所提方法的处理结果。不难发现,图 3(c)所示图像中局部区域仍有部分雨滴没有去除干净,图像修复的纹理模糊;图 3(d)所示图像的去雨效果有所改善,但去除雨滴的同时也损失了部分高频信息,图像细节较模糊;图 3(e)所示图像的去雨效果和细节保持的效果都较好,但图像整体稍微偏暗,色彩饱和度不佳;图 3(f)为本文算法的处理结果图像,不仅去除了雨滴,而且与原始无雨图像相比,很好地保留了图像的色度信息,视觉效果良好。

表 2 给出了不同算法的评价指标。可以看出,本文算法处理结果图像的 PSNR 和 SSIM 均优于其他算法的处理结果,并且符合人眼视觉上对这些方法的评价结果。

此外,在表 2 中,我们也测试了文献[16]提供的 12 幅人工添加雨滴的图像,结果同样显示出其具有很高的 PSNR 和 SSIM。

4(d)是文献[10]方法的去雨效果图,图像的饱和度偏低,导致图像整体偏黑;图 4(e)是本文算法的去雨效果图,该算法在去除雨滴的同时,很好地保留了图像的细节信息和色度信息。



注:第一行是人行道场景图像;第二行是街道场景图像;第三行是马路场景图像;第四行是屋檐场景图像;第五行是铜像场景图像

图 4 真实场景的去雨效果图

Fig. 4 Raindrop removal effect in real scene

¹⁾ http://www.ee.nthu.edu.tw/cwlin/Rain_Removal/Rain_Remova
²⁾ <http://smartdsp.xmu.edu.cn/derainnet.html>
³⁾ <http://smartdsp.xmu.edu.cn/cvpr2017.html>

结束语 本文提出了一种新型的基于深度学习的单幅图像雨滴去除方法。该方法首先将有雨滴的源图像映射到 YUV 空间;然后在基于图像修复的极深网络框架下学习雨滴图像和无雨滴图像的深层残差特征图;最后将源图像的亮度分量与残差特征图进行叠加,得到重构的去雨图像,并将结果逆映射到 RGB 空间,更好地保留了图像的色度信息。文中还对不同环境中的雨滴图像进行了测试,并给出了主客观评价指标。实验结果表明,该方法能够更好地去除图像中的雨滴,极大地改善了图像的视觉效果。

参 考 文 献

[1] JOACHIMS T. Making Large-scale SVM Learning Practical [J]. Advanced in Kernel Methods-Support Vector Learning, 1999, 8(3): 499-526.

[2] ZAKZESKI J, BRUIJNINCX P C, JONGERIUS A L, et al. The Catalytic Valorization of Lignin for The Production of Renewable Chemicals[J]. Chemical Reviews, 2010, 110(6): 3552.

[3] HUANG D A, KANG L W, WANG Y C F, et al. Self-Learning Based Image Decomposition with Applications to Single Image Denoising[J]. IEEE Transactions on Multimedia, 2013, 16(1): 83-93.

[4] KANG L W, LIN C W, FU Y H. Automatic Single-image-based Rain Streaks Removal via Image Decomposition [J]. IEEE Transactions on Image Processing A Publication of the IEEE Signal Processing Society, 2011, 21(4): 1742-1755.

[5] LUO Y, XU Y, JI H. Removing Rain from a Single Image via Discriminative Sparse Coding[C]//Proceedings of IEEE Conference on Computer Vision. Santiago: IEEE Press, 2015: 3397-3405.

[6] YIN B C, WANG W T, WANG L C. Review of Deep Learning [J]. Journal of Beijing University of Technology, 2015, 41(1): 48-59. (in Chinese)

尹宝才, 王文通, 王立春. 深度学习研究综述[J]. 北京工业大学学报, 2015, 41(1): 48-59.

[7] HE K, ZHANG X, REN S, et al. Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2015, 37(9): 1904-1916.

[8] EIGEN D, KRISHNAN D, FERGUS R. Restoring an Image Taken through a Window Covered with Dirt or Rain[C]//Proceedings of IEEE International Conference on Computer Vision. Sydney: IEEE Press, 2013: 633-640.

[9] FU X, HUANG J, DING X, et al. Clearing the Skies: A Deep

Network Architecture for Single-image Rain Streaks Removal [J]. IEEE Transactions on Image Processing, 2017, 26(6): 2944-2956.

[10] FU X, HUANG J, ZENG D, et al. Removing Rain from Single Images via a Deep Detail Network [C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Hawaii: IEEE Press, 2017: 1715-1723.

[11] ZHANG K, CHEN Y, CHEN Y, et al. Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising[J]. IEEE Transactions on Image Processing, 2016, 26(7): 3142-3155.

[12] KIM J, LEE J K, LEE K M. Accurate Image Super-Resolution Using Very Deep Convolutional Networks [C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Sichuan: IEEE Press, 2016: 1646-1654.

[13] HINTON G E, OSINDERO S, AND TEH Y W. A Fast Learning Algorithm for Deep Belief Nets[J]. Neural Computation, 2014, 18(7): 1527-1554.

[14] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition [C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Nevada: IEEE Press, 2016: 770-778.

[15] DONG C, CHEN C L, HE K, et al. Image Super-Resolution Using Deep Convolutional Networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2016, 38(2): 295-307.

[16] LI Y, TAN R T, GUO X, et al. Rain Streak Removal using Layer Priors[C]//Proceedings of IEEE Conference on Computer Vision and Pattern Recognition. Chengdu: IEEE Press, 2016: 2736-2744.

[17] JIA Y Q, SHELHAMER, et al. Caffe: Convolutional Architecture for Fast Feature Embedding [C]//Proceedings of the 22nd ACM International Conference on Multimedia. Florida: IEEE Press, 2014: 675-678.

[18] VEDALDI A, LENC K. MatConvNet: Convolutional Neural Networks for MATLAB [C]//Proceedings of the 23rd ACM International Conference on Multimedia. Brisbane: IEEE Press, 2015: 689-692.

[19] SCHAEFER G. UCID: An Uncompressed Color Image Database [C]//Proceedings of Storage & Retrieval Methods & Applications for Multimedia. CA: IEEE Press, 2003: 472-480.

[20] BARNUM P C, NARASIMHAN S, KANADE T. Analysis of Rain and Snow in Frequency Space[J]. International Journal of Computer Vision, 2010, 86(2): 256-274.

(上接第 277 页)

[14] COPSEY K, WEBB A. Bayesian gamma mixture model approach to radar target recognition [J]. IEEE Transactions on Aerospace and Electronic Systems, 2003, 39(4): 1201-1217.

[15] QIN Y, PRIEBE C E. Maximum L q-Likelihood Estimation via the Expectation-Maximization Algorithm: A Robust Estimation of Mixture Models [J]. Journal of the American Statistical Association, 2013, 108(503): 914-928.

[16] COMER M, BOUMAN C A, DE GRAEF M, et al. Bayesian

methods for image segmentation [J]. JOM Journal of the Minerals, Metals and Materials Society, 2011, 63(7): 55-57.

[17] ZHANG M. Bilateral filter in image processing [J]. Applied Surface Science, 2006, 253(2): 468-475.

[18] MARTIN D, FOWLKES C, TAL D, et al. A database of human segmented natural images and its application to evaluating segmentation algorithms and measuring ecological statistics [C]//Proceeding of International Conference on Computer Vision. 2001: 416-423.