

基于多通道多尺度卷积神经网络的单幅图像去雨方法

柳长源^① 王琪^{*①} 毕晓君^②

^①(哈尔滨理工大学电气与电子工程学院 哈尔滨 150000)

^②(哈尔滨工程大学信息与通信工程学院 哈尔滨 150000)

摘要: 雨天等恶劣天气会严重影响到图像成像质量,从而影响到视觉处理算法的性能。为了改善雨天图像的成像质量,该文提出一种基于多通道多尺度卷积神经网络的去雨算法,建立了多通道多尺度卷积神经网络结构来提取雨线特征。首先利用小波阈值引导的双边滤波将有雨图像进行分解,得到高频雨线图像和轮廓保持度高的低频背景图像。然后为了使图像高频部分的雨线信息更为明显,减少雨线特征学习时高频图像中的背景误判,将得到的高频雨线图像再一次通过滤波器得到减弱背景信息同时增强雨线信息的到更高频雨线图像。其次针对低频背景图像上也残留了大量雨痕,该文提出将低频背景图像和更高频雨线图像一起送入卷积神经网络进行特征学习,其中对图像提取的是多尺度特征信息,最后得到雨线去除更彻底的复原图像。同时在构造网络模型时利用空洞卷积代替标准卷积来提取图像的特征信息,得到更丰富的图像特征,提高了算法的去雨性能。从实验结果可以看出去雨之后的图像清晰,细节保持度较高。

关键词: 深度学习; 空洞卷积; 图像分解; 多尺度提取特征

中图分类号: TN911.73; TP391.4

文献标识码: A

文章编号: 1009-5896(2020)09-2285-08

DOI: 10.11999/JEIT190755

Research on Rain Removal Method for Single Image Based on Multi-channel and Multi-scale CNN

LIU Changyuan^① WANG Qi^① BI Xiaojun^②

^①(School of Electrical and Electronic Engineering, Harbin University of Science and Technology, Harbin 150000, China)

^②(School of Information and Communication Engineering, Harbin Engineering University, Harbin 150000, China)

Abstract: Rainy days and other severe weather will seriously affect the image quality, thus affecting the performance of vision processing algorithms. In order to improve the imaging quality of rain images, a rain removal algorithm based on multi-channel multi-scale convolution neural network to extract rain line features is proposed. Firstly, the rain images are decomposed by wavelet threshold-guided bilateral filtering to obtain high-frequency rain line images and low-frequency background images with high contour preservation. Then, in order to make the rain line information in the high-frequency part of the image more obvious and reduce the background misjudgment in the high-frequency image during the rain line feature learning, the obtained high-frequency rain line image is passed through a filter again to obtain a higher-frequency rain line image with reduced background information and enhanced rain line information. Secondly, in view of the large amount of raindrop imprint left on the low-frequency background image, it is proposed to send the low-frequency background image and the higher-frequency rain line image together into the convolution neural network for feature learning, in which multi-scale feature information is extracted from the image, finally, a more complete restoration image with rain line removal is obtained. At the same time, when constructing the network model, hole convolution is used instead of standard convolution to extract the feature information of the image, thus

收稿日期: 2019-09-29; 改回日期: 2020-05-28; 网络出版: 2020-07-13

*通信作者: 王琪 1208401521@qq.com

基金项目: 国家自然科学基金(51779050)

Foundation Item: The National Natural Science Foundation of China(51779050)

obtaining richer image features and improving the rain removal performance of the algorithm. From the experimental results, after removing rain, the image is clear and the detail retention is high.

Key words: Deep learning; Dilated convolution; Image decomposition; Multi-scale feature extraction

1 引言

雨天会对图像的成像质量造成影响,使图像模糊、形变、可视性差等等。这就会使户外计算机视觉系统的工作受到影响。因此,图像去雨算法的研究越来越受到各国研究人员的重视。图像去雨是目标识别^[1]和目标跟踪^[2]等领域算法的前期工作,其对于提高这类算法的性能具有很大的帮助,所以图像去雨在机器视觉领域具有很大的应用前景。

近年来,图像去雨算法得到越来越多研究人员的关注,目前去雨算法主要分为两类,第1类是具有时间冗余性的视频图像去雨算法^[3-6],第2类是雨线分布缺少时空动态相关特性的单幅图像去雨算法^[7-13],相比于视频图像的去雨,单幅图像只包含某一时刻的雨线分布,所以基于单幅图像去雨算法是当前研究工作中的难点。针对单幅图像去雨, Kim等人^[7]先对图像中雨线的位置进行检测,再通过非均值滤波器来消除雨线,缺点是经过去雨处理后的图像仍然有雨线残留,并且使图像变得模糊。Huang等人^[8]利用支持向量机和主成分分析法对雨线进行判别分类,使得去雨效果有所提升。Luo等人^[9]利用判别性稀疏编码对雨线与背景进行判别分离,可以去除大部分的雨线,但是当背景与雨线具有相同梯度的时候就会把背景判别成雨线,从而使图像丢失了细节信息变得模糊。Kang等人^[10]使用双边滤波分解有雨图像后得到高频部分,通过字典学习高频雨线和非雨线部分再进行雨线区分,再通过稀疏编码得到无雨的高频部分,与保留的低频部分相加得到去雨图像,该方法可以有效的去除图像中的雨条纹但是损失了部分高频信息,所以也会造成图像模糊。Qian等人^[11]通过生成对抗网络消除图像上的雨滴,图像复原效果较好。He等人^[12]对雨线密度进行分类,再根据对应的雨线密度标签选择合适的去雨方法去除雨线。Fu等人^[13]利用深度学习对图像的高频部分提取特征,提升了复原图像的视觉效果,但是去雨图像上依然残留了雨痕,导致去雨效果不理想。将有雨图像分解为高频和低频部分的去雨算法不需要进行预处理,应用范围较广。基于深度学习来处理单幅图像去雨问题,充分地利用了图像中的特征信息,得到的去雨效果比较好,受到广泛认可。本文将针对基于图像分解和深度学习来对去雨算法进行进一步的研究和改进。

为了得到雨线去除较为彻底,细节和边缘保持

度高的复原图像,本文提出一种基于多通道多尺度卷积神经网络去雨算法,建立了多通道多尺度卷积神经网络结构来提取雨线特征。多通道即为卷积神经网络中两个通道分别提取有雨的低频背景图像和更高频雨线图像的特征信息,多尺度指分别对有雨的低频背景图像和更高频雨线图像提取两种尺度的特征图,使得提取的图像特征信息更为丰富,有利于提升图像去雨能力。通过对实验结果的主观观察和客观评价指标分析表明,本文提出的基于多通道多尺度卷积神经网络提取特征的去雨算法相比其他算法去雨的效果更好,图像细节保持度更高。

2 卷积神经网络去雨方法

2.1 低频与更高频图像获取

雨天图像中的雨线噪声部分存在于图像的高频部分,在图像的低频部分也会有大量的雨痕残留。本文先利用小波阈值去噪引导的双边滤波来对图像进行高低频分解,其原因在于与其他常用的滤波器相比,此滤波器可以很好地保留低频背景图像的细节纹理,具有保持边界的作用^[14]。因为高频图像中容易出现背景与雨线具有相同梯度的情况,从而导致背景误判,所以本文在得到高频图像之后对高频图像再取高频得到减弱背景信息同时增强雨线信息的更高频图像来进行特征学习。

双边滤波中两个核函数分别是组合空域函数和值域核函数,正是在滤波过程中这两个核函数的作用,使得双边滤波具有边缘和细节保持特性^[15]。小波阈值去噪的效果非常好,所以先对有雨图像进行小波阈值去噪得到较为平滑的图像,其中小波阈值去噪采用硬阈值,再将平滑的图像作为计算双边滤波的值域核函数的引导图像^[16]。几种常用的滤波器滤波结果对比如图1所示,可以看出利用小波阈值引导双边滤波得到的低频图像的细节保持度较好。

有雨图像 I 经过小波阈值引导双边滤波后得到有雨的低频背景图像 I_L 和更高频雨线图像 I_H ,为了得到更高频雨线图像 I_{HH} ,需要将高频雨线图像 I_H 再次通过滤波器,其可以表示为

$$I = I_L + I_H \quad (1)$$

$$I_H = I_{HL} + I_{HH} \quad (2)$$

图2表示同一场景下无雨图像和有雨图像所对应的低频背景图像对比示例,可以看出图像分解后的低频背景图像上仍然残留大量的雨线,图3进

一步展示了有雨痕残留的低频背景图像和无雨低频背景图像的平均颜色直方图分布，可以明显地看出两者的区别很大。因此，为了更彻底地去除图像上

的雨线，就需要把低频背景图像与高频雨线图像同时送入到卷积神经网络中学习雨线特征并向无雨图像映射。图4展示了高频雨线图像与更高频雨线图



图 1 不同滤波器滤波后得到的低频背景图像对比



图 2 低频图像对比




图 3 颜色直方图对比



图 4 高频雨线图像与更高频雨线图像对比

像的对比示例, 可以看出高频图像中含有大量的雨线信息, 同时也包含了大量的背景结构信息。而更高频图像中包含了雨线信息的同时削弱了背景结构信息, 为了减少网络学习中的背景误判, 最后选择了背景结构信息少的更高频雨线图像。

2.2 网络结构

有雨图像经分解得到的低频背景部分留有大量的雨痕, 为了使最终输出的低频图像与高频图像融合结果更好, 图像中雨线去除更彻底, 本文提出有雨的低频背景图像和前文所提的减弱了背景信息同时增强雨线信息的更高频雨线图像一同送入到卷积神经网络中进行特征学习。

为了提升算法中卷积神经网络的特征提取能力, 选择利用空洞卷积替换普通卷积来构造多通道多尺度特征提取的卷积神经网络结构, 并对有雨的低频背景图像和更高频图像分别提取两种尺度的特征图像, 所得到的特征图集合中包含的图像信息更为丰富, 这些丰富的图像特征信息更有利于后续的有雨图像与无雨图像的非线性关系映射。

对于普通的卷积, 随着卷积层数的增加感受野的大小呈线性增加, 而对于空洞卷积的感受野来说, 其可以呈指数方式增长。空洞就是在原图上做采样, 根据空洞卷积率(Dilation rate)来设置采样的频率, 当Dilation rate=1时, 空洞卷积操作就是标准的卷积操作, 当Dilation rate>1就开始在原图上采样, 采样间隔为(Dilation rate-1)。采样后的图像与卷积核做卷积。连续使用空洞卷积可以使感受野变大, 从而使每个卷积输出都包含较大范围的信息, 提取的特征信息相比于普通卷积更为丰富而且不损失特征信息。空洞卷积卷积核的感受野大小 r_i 可以表示为

$$r_1 = d \times (k - 1) + 1 \quad (3)$$

$$r_i = d \times (k - 1) + r_{i-1}, \quad i = 1, 2, \dots, n \quad (4)$$

其中, d 表示空洞卷积率(Dilation rate), k 为卷积核大小(Kernel), 卷积神经网络结构如图5所示, 算法流程分为以下几个步骤:

步骤1 图像分解: 有雨图像经过小波阈值引导双边滤波分解为有雨痕残留的低频背景部分和高频雨线部分;

步骤2 获取更高频图像: 将步骤1中的高频雨线图像再次通过滤波器得到更高频雨线图像;

步骤3 特征提取与映射: 对步骤1得到的有雨的低频背景图像和步骤2中得到的更高频雨线图像分别提取雨线特征, 这个过程两张图片分别通过通道①和通道②卷积神经网络进行分块抽取, 设定特征图的数量为256, 分别将两个通道提取的特征图像组成两个特征图像集合, 即低频图像特征图集合与更高频图像特征图集合, 特征图像集合用来估计与去雨图像的特征图像的映射关系;

步骤4 输出去雨图像: 经过训练后输出的去雨低频背景图像与去雨的更高频图像相加得到最终输出的去雨图像。

对于同时提取低频背景图像与更高频雨线图像的特征, 两个并行的卷积神经网络通道均由2个卷积层和1个输出层构成, 通道①和通道②里的第1层均是特征提取层, 分别用空洞卷积Conv11, Conv12, Conv21, Conv22提取不同尺度的图像特征。每个卷积层的kernel大小为 3×3 , 卷积层后均接有ReLU激活函数, 特征图维度为256。提取的不同尺度的特征图像组成一个特征图像集合后通过第

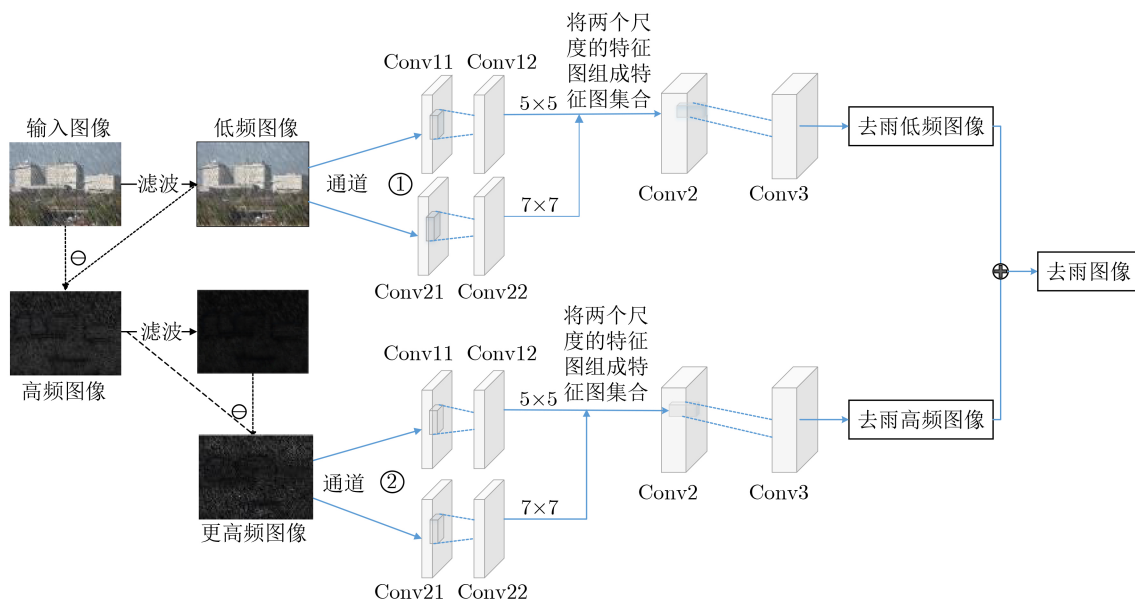


图5 多通道多尺度卷积神经网络结构

2层卷积层来估计有雨图像与去雨图像之间特征图的映射关系，这层卷积的卷积核选择 1×1 ，最后通过一层输出层输出去雨的低频背景图像与去雨的更高频图像。通过改变第1层特征提取层中的空洞卷积率，得到的特征图像的感受野大小不同，通道①和通道②中第1层卷积中Covn11, Covn12两个空洞卷积层的Dilition rate均设为1，得到空洞卷积的感受野大小为 5×5 ；Covn21, Covn22两个空洞卷积层的Dilition rate分别设为1, 2，得到空洞卷积的感受野大小为 7×7 。然后通过一个连接层将两个尺度的特征图组成一个集合。对于通道①和通道②网络结构是一样的，所以下面每层卷积的计算公式以通道①的特征提取网络结构为例。

$$\left. \begin{aligned} f_{i1} &= \rho(W_{i1} * I_x + b_{i1}) \\ f_{i2} &= \rho(W_{i2} * f_{i1} + b_{i2}), \quad i = 1, 2 \end{aligned} \right\} \quad (5)$$

$$f_2(I) = \rho(W_2 * f_1(I_x) + b_2) \quad (6)$$

$$f_3(I) = W_3 * f_2(I) + b_3 \quad (7)$$

其中， I_x 表示输入图像，即低频图像与更高频图像， $*$ 表示卷积操作， $\rho(*)$ 表示激活函数， W_{i1} 和 W_{i2} 为2个特征提取层的网络参数， b_{i1} 和 b_{i2} 为偏置值。 $f_1(I_x)$ 表示2个尺度的特征图组成的集合，里面包含512张有雨特征图，即维度为512； W_2 为第2层卷积层的网络参数， b_2 为偏置值。 W_3 为输出层的网络参数， b_3 为偏置值。由于结合2个不同尺度的特征图像比只利用单一尺度的特征图像具有更丰富的特征信息，进而有雨图像到无雨图像的映射的准确性得到了提高。网络最终输出的去雨图像表示为

$$K = f(I_L) + f(I_{HH}) \quad (8)$$

3 实验分析与结果

3.1 数据集与训练配置

为了测试所提方法的去雨效果，分别在模拟有雨图像和真实雨天图像上进行测试，并与其他算法的去雨效果做对比。用于网络训练与测试的数据集来自Fu等人^[13]提出的Rainy_image_dataest，该数据集包含1000张真实的无雨图像和在这些无雨图像上添加了不同方向、大小的雨线组成的模拟雨天图像14000张。训练时，选取数据集中的9000张雨线不同方向，不同大小的图像作为网络的训练集，在剩余的图片里随机抽取300张做测试，同时为了验证本文的网络在真实雨天环境下的有效性，本文也采用了真实的雨天图片来测试。

实验环境是Intel(R)Core(TM)i9-9900k-CPU, 64 bit, Windows10。训练网络时，随机选取有雨图像的低频图像与更高频图像和对应的无雨图像的低频图像与更高频图像上 64×64 像素大小的图像

块，将其作为一对样本送入到卷积神经网络中提取特征。采用随机梯度下降方式训练网络模型，初始学习率大小设定为0.001，批量训练样本个数为20，最大迭代次数为10000。实验过程中训练模型迭代到8710次时损失函数的值不再减小，这时模型中的参数取得了最优值，得到的最小损失函数的值是0.0019。

3.2 实验结果对比与分析

为了验证本文算法的去雨效果，将本文的方法与文献^[8]，文献^[12]和文献^[13]提出的方法进行对比试验，所用的测试图像是模拟有雨图像，实验结果如图6所示。图6(a)是原始有雨图，图6(b)是文献^[8]方法的结果，可以看出不仅雨线没有去除干净，而且使去雨图像变得模糊，图6(c)是文献^[12]方法的去雨结果，去雨效果有明显改善，但还是在图像上残留了雨痕，图6(d)是文献^[13]方法的去雨效果，复原图像的清晰度有所提高，但是雨线去除不彻底。图6(e)为本文提出的基于多通道多尺度的卷积神经网络的去雨效果，可以看出采用新方法后的雨线去除效果更好，去雨后的图像清晰而且图像的纹理和细节的保持度也较高，取得了良好的视觉效果。

由于数据集中的有雨图像均有对应的无雨真实图像，就可以采用两种客观评价图像质量方法来客观地比较不同算法的去雨效果，分别为峰值信噪比(Peak Signal to Noise Ratio, PSNR)^[17]和结构相似性(Structural SIMilarity index, SSIM)^[18]，两个指标都是值越高，代表复原图像的质量越好。表1、表2中分别显示了图6中图像的PSNR和SSIM和在测试集中随机选取的300张模拟有雨图像的均值结果。可以看出，通过本文算法得到的复原图像的图像质量优于其他算法的处理结果。

上述所采用的图像样本均使用的是在真实无雨场景中添加雨线构成的模拟有雨图像，为了证明本文的算法在真实的有雨图像上仍然适用，于是对真实的雨天图像也做了同样的测试。实验结果如图7所示，图7(a)为真实的雨天图像，图7(b)–图7(e)分别是文献^[8]、文献^[12]、文献^[13]和本文算法的处理结果，观察发现，本文算法相比于其他算法依然具有较好的视觉效果。

3.3 多尺度与单尺度卷积性能比较

本文提出了利用空洞卷积构造的多通道多尺度卷积神经网络对图像提取不同尺度的特征图，使得提取的特征信息更为丰富，提高了有雨图像到无雨图像之间映射关系估计的准确性。为了进一步展示所提多尺度特征提取的有效性，对提取多尺度与单尺度特征信息的网络性能做了对比测试，将分别提




图6 模拟雨图去雨效果对比

表1 PSNR对比结果

图像	文献[8]	文献[12]	文献[13]	本文方法
第1幅	20.157	21.233	21.779	23.128
第2幅	21.530	24.783	25.637	26.821
第3幅	27.006	30.252	31.553	34.460
300张平均	22.537	24.838	26.096	27.794

表2 SSIM对比结果

图像	文献[8]	文献[12]	文献[13]	本文方法
第1幅	0.9012	0.9048	0.9133	0.9236
第2幅	0.8937	0.9156	0.9248	0.9420
第3幅	0.8830	0.9364	0.9430	0.9448
300张平均	0.8963	0.9246	0.9398	0.9434

取低频图像与更高频图像特征的通道①和通道②中的第1层,也就是将Covn11, Covn12, Covn21, Covn22用一个卷积层替换,由于Covn11, Covn12

提取的特征图像的感受野大小为 5×5 , Covn21和Covn22提取的特征图像的感受野大小为 7×7 ,所以用于替换的单尺度卷积层其卷积核大小为 5×5 或 7×7 ,输出特征维数为256。对单尺度的网络进行训练,训练后利用同样的300张模拟雨图对单尺度卷积神经网络进行测试,单尺度与多尺度网络的测试对比结果如表3所示。

对比表1和表2中的实验结果可以看出,由于提取多尺度特征图包含的图像特征信息更为丰富,所以提取多尺度特征图的卷积神经网络的处理结果要优于提取单一尺度特征图的卷积神经网络得到的结果。选择对雨图像提取多尺度特征图有利于后面对雨图像和无雨图像的非线性映射估计,提升网络模型的去雨能力。

4 结论

本文针对雨天图像分解之后的低频背景图像残留了大量雨痕,高频雨线图像容易出现背景与雨线



图7 真实雨图去雨效果对比

表3 图像质量指标对比

图像	指标	单尺度卷积	单尺度卷积	多尺度卷积
		5 × 5	7 × 7	
第1幅	PSNR	21.253	20.197	23.128
	SSIM	0.9109	0.9114	0.9236
第2幅	PSNR	25.017	25.714	26.821
	SSIM	0.9211	0.9237	0.9420
第3幅	PSNR	31.581	30.336	34.460
	SSIM	0.9382	0.9369	0.9448
300张平均	PSNR	25.973	25.285	27.794
	SSIM	0.9350	0.9337	0.9434

具有相同纹理时导致背景误判,使得最终图像去雨效果不理想的问题,提出了一种多通道多尺度卷积神经网络的单幅图像去雨方法,一方面将有雨图像通过小波阈值去噪引导的双边滤波得到细节保持度高的低频背景图像和减弱背景信息增强雨痕信息的更高频雨线图像,有雨的低频背景图像和更高频雨线图像同时送入到卷积神经网络中进行雨线特征学习后向无雨图像映射,使得网络最终输出的图像中雨线去除更彻底,同时提高了去雨图像的质量。另一方面选择利用空洞卷积对图像提取不同尺度的特征图,使得提取的图像特征信息更为丰富,更加贴合图像去雨的目标。分别在模拟雨天图像和真实雨天图像上进行实验并与其他经典的图像去雨算法相比较,结果表明本文提出的方法能够更好地去除图像中的雨线,极大地改善了图像的视觉效果。

参考文献

- [1] 郭智, 宋萍, 张义, 等. 基于深度卷积神经网络的遥感图像飞机目标检测方法[J]. 电子与信息学报, 2018, 40(11): 2684–2690. doi: [10.11999/JEIT180117](https://doi.org/10.11999/JEIT180117).
GUO Zhi, SONG Ping, ZHANG Yi, et al. Aircraft detection method based on deep convolutional neural network for remote sensing images[J]. *Journal of Electronics & Information Technology*, 2018, 40(11): 2684–2690. doi: [10.11999/JEIT180117](https://doi.org/10.11999/JEIT180117).
- [2] 孙彦景, 石韞开, 云霄, 等. 基于多层卷积特征的自适应决策融合目标跟踪算法[J]. 电子与信息学报, 2019, 41(10): 2464–2470. doi: [10.11999/JEIT180971](https://doi.org/10.11999/JEIT180971).
SUN Yanjing, SHI Yunkai, YUN Xiao, et al. Adaptive strategy fusion target tracking based on multi-layer convolutional features[J]. *Journal of Electronics & Information Technology*, 2019, 41(10): 2464–2470. doi: [10.11999/JEIT180971](https://doi.org/10.11999/JEIT180971).
- [3] GARG K and NAYAR S K. Detection and removal of rain from videos[C]. 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, Washington DC, USA, 2004. doi: [10.1109/CVPR.2004.1315077](https://doi.org/10.1109/CVPR.2004.1315077).
- [4] BARNUM P C, NARASIMHAN S, and KANADE T. Analysis of rain and snow in frequency space[J]. *International Journal of Computer Vision*, 2010, 86(2): 256–274. doi: [10.1007/s11263-008-0200-2](https://doi.org/10.1007/s11263-008-0200-2).
- [5] LIU Jiaying, YANG Wenhan, YANG Shuai, et al. Erase or fill? Deep joint recurrent rain removal and reconstruction in videos[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA, 2018: 3233–3242. doi: [10.1109/CVPR.2018.00341](https://doi.org/10.1109/CVPR.2018.00341).
- [6] CHEN Jie, TAN C H, HOU Junhui, et al. Robust video content alignment and compensation for rain removal in a CNN framework[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA, 2018: 6286–6295. doi: [10.1109/CVPR.2018.00658](https://doi.org/10.1109/CVPR.2018.00658).
- [7] KIM J H, LEE C, SIM J Y, et al. Single-image deraining using an adaptive nonlocal means filter[C]. 2013 IEEE International Conference on Image Processing, Melbourne, Australia, 2013: 914–917. doi: [10.1109/ICIP.2013.6738189](https://doi.org/10.1109/ICIP.2013.6738189).
- [8] HUANG Dean, KANG Liwei, WANG Y C F, et al. Self-learning based image decomposition with applications to single image denoising[J]. *IEEE Transactions on Multimedia*, 2014, 16(1): 83–93. doi: [10.1109/TMM.2013.2284759](https://doi.org/10.1109/TMM.2013.2284759).
- [9] LUO Yu, XU Yong, and JI Hui. Removing rain from a single image via discriminative sparse coding[C]. 2015 IEEE International Conference on Computer Vision, Santiago, Chile, 2015: 3397–3405. doi: [10.1109/ICCV.2015.388](https://doi.org/10.1109/ICCV.2015.388).
- [10] KANG Liwei, LIN C W, and FU Y H. Automatic single-image-based rain streaks removal via image decomposition[J]. *IEEE Transactions on Image Processing*, 2012, 21(4): 1742–1755. doi: [10.1109/TIP.2011.2179057](https://doi.org/10.1109/TIP.2011.2179057).
- [11] QIAN Rui, TAN R T, YANG Wenhan, et al. Attentive generative adversarial network for raindrop removal from a single image[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA, 2018: 2482–2491. doi: [10.1109/CVPR.2018.00263](https://doi.org/10.1109/CVPR.2018.00263).
- [12] HE Zhang and PATEL V M. Density-aware single image de-raining using a multi-stream dense network[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Salt Lake City, USA, 2018: 695–704. doi: [10.1109/CVPR.2018.00079](https://doi.org/10.1109/CVPR.2018.00079).
- [13] FU Xueyang, HUANG Jiabin, DING Xinghao, et al. Clearing the skies: A deep network architecture for single-image rain removal[J]. *IEEE Transactions on Image Processing*, 2017, 26(6): 2944–2956. doi: [10.1109/TIP.2017.2691802](https://doi.org/10.1109/TIP.2017.2691802).
- [14] 肖进胜, 李文昊, 姜红, 等. 基于双域滤波的三维块匹配视频去噪算法[J]. 通信学报, 2015, 36(9): 91–97. doi: [10.11959/](https://doi.org/10.11959/)

- [j.issn.1000-436x.2015245](https://doi.org/10.11959/j.issn.1000-436x.2015245).
- XIAO Jinsheng, LI Wenhao, JIANG Hong, *et al.* Three dimensional block-matching video denoising algorithm based on dual-domain filtering[J]. *Journal on Communications*, 2015, 36(9): 91–97. doi: [10.11959/j.issn.1000-436x.2015245](https://doi.org/10.11959/j.issn.1000-436x.2015245).
- [15] XIAO Jinsheng, LI Wenhao, LIU Guoxiong, *et al.* Hierarchical tone mapping based on image colour appearance model[J]. *IET Computer Vision*, 2014, 8(4): 358–364. doi: [10.1049/iet-cvi.2013.0230](https://doi.org/10.1049/iet-cvi.2013.0230).
- [16] YU Hancheng, LI Zhao, and WANG Haixian. Image denoising using trivariate shrinkage filter in the wavelet domain and joint bilateral filter in the Spatial Domain[J]. *IEEE Transactions on Image Processing*, 2009, 18(10): 2364–2369. doi: [10.1109/TIP.2009.2026685](https://doi.org/10.1109/TIP.2009.2026685).
- [17] HUYNH-THU Q and GHANBARI M. Scope of validity of PSNR in image/video quality assessment[J]. *Electronics Letters*, 2008, 44(13): 800–801. doi: [10.1049/el:20080522](https://doi.org/10.1049/el:20080522).
- [18] WANG Zhou, BOVIK A C, SHEIKH H R, *et al.* Image quality assessment: From error visibility to structural similarity[J]. *IEEE Transactions on Image Processing*, 2004, 13(4): 600–612. doi: [10.1109/TIP.2003.819861](https://doi.org/10.1109/TIP.2003.819861).
- 柳长源: 男, 1970年生, 副教授, 工学博士, 硕士生导师, 研究方向为模式识别与图像处理, 机器学习与优化方法.
- 王 琪: 女, 1996年生, 硕士生, 研究方向为模式识别与图像处理.
- 毕晓君: 女, 1964年生, 教授, 博士生导师, 研究方向为数字图像处理、信息智能处理技术及通信信息处理技术.

责任编辑: 马秀强