

# 基于多流扩张残差稠密网络的图像去雨算法

王薇薇<sup>1</sup>, 翟亚宇<sup>2</sup>, 陈平<sup>1\*</sup>, 曹凤才<sup>1</sup>

<sup>1</sup> 中北大学信息与通信工程学院, 山西 太原 030051;

<sup>2</sup> 中国船舶工业综合技术经济研究院, 北京 100081

**摘要** 针对传统图像去雨算法未考虑多尺度雨条纹及图像去雨后细节信息丢失的问题, 提出一种基于多流扩张残差稠密网络的图像去雨算法, 利用导向滤波器将图像分解为基础层和细节层。通过直接学习含雨图像细节层和无雨图像细节层的残差来训练网络, 缩小映射范围。采用 3 条带有不同扩张因子的扩张卷积对细节层进行多尺度特征提取, 获得更多上下文信息, 提取复杂多向的雨线特征; 同时, 将扩张残差密集块作为网络的参数层, 加强特征传播, 扩大接受域。在合成图片和真实图片上的实验结果表明, 所提算法能有效去除不同密度的雨条纹, 并较好地恢复图像细节信息。通过对比其他算法, 证明了所提算法在主观效果和客观指标上都有提升。

**关键词** 图像处理; 图像去雨; 图像增强; 多流扩张残差稠密网络; 卷积神经网络

中图分类号 TP391

文献标志码 A

doi: 10.3788/LOP202158.0410024

## Image Deraining Algorithm via Multiflow Expansion Residual Dense Network

Wang Weiwei<sup>1</sup>, Zhai Yayu<sup>2</sup>, Chen Ping<sup>1\*</sup>, Cao Fengcai<sup>1</sup>

<sup>1</sup> School of Information and Communication Engineering, North University of China, Taiyuan, Shanxi 030051, China;

<sup>2</sup> China Institute of Marine Technology & Economy, Beijing 100081, China

**Abstract** The traditional image rain removal algorithms do not consider multiscale rain streaks and often result in loss of detailed information after the image is derained. To solve these problems, an image rain removal algorithm based on a multiflow expansion residual dense network is proposed in this study. In this algorithm, a guided filter is used for decomposing an image into a base layer and a detail layer. The mapping range can be considerably reduced by training the network with the residuals present between the rain and rainless image detail layers. Three dilated convolutions with different expansion factors are used to perform multiscale feature extraction on the detail layer to obtain more context information and extract complex and multidirectional rainline features. Further, the expanded residual dense block, which is the parameter layer of the network, is applied to enhance the propagation of features and expand the acceptance domain. The experiments conducted on synthetic and real pictures show that the proposed algorithm can effectively remove rain streaks with different densities and restore the detailed information present in an image. When compared with other algorithms, the proposed algorithm is better in terms of subjective effects and objective indicators.

**Key words** image processing; image rain removal; image enhancement; multiflow expansion residual dense network; convolutional neural network

**OCIS codes** 100.3020; 100.2860; 100.2980

收稿日期: 2020-09-25; 修回日期: 2020-10-02; 录用日期: 2020-10-14

基金项目: 国家自然科学基金(61871351, 61971381)、山西省自然科学基金(201901D111158)

\* E-mail: pc0912@163.com

## 1 引言

在雨天情况下,拍摄的图像和视频的能见度降低,从而改变了图像的内容和色彩,影响人的主观视觉感受,并且也对计算机视觉系统任务造成严重干扰,如目标检测<sup>[1]</sup>、视频监控及自动驾驶等。例如,由于雨水遮挡住图像中的目标,目标检测和定位的准确性降低。因此,有效去除图像中的雨条纹,恢复图像细节信息,具有实际的应用价值。

图像去雨算法主要分为两类:基于视频的去雨算法和基于单幅图像的去雨算法。视频去雨算法可以利用丰富的时间知识,而单幅图像去雨算法无时域信息可以利用,且雨的随机分布特征使雨像素点的位置不好确定,因此单幅图像去雨一直是一个极具挑战性的问题。同时,单幅图像去雨算法不仅可以处理单幅图像,也可以处理视频帧图像,因此,单幅图像的去雨算法具有重要的研究意义和广泛的应用前景。

传统的图像去雨算法主要有基于纯粹物理模型和数学推导的去雨模型方法、基于图像处理知识的去雨方法、基于稀疏编码字典学习和分类器的去雨方法。传统图像去雨算法建模复杂、计算量大,去雨效果不理想。近些年来,深度学习逐渐被应用到图像去雨领域。基于深度学习的图像去雨方法直接学习含雨图像到无雨图像的端到端映射,在某些情况下取得了良好的性能。但仍然忽视了一些重要问题:首先,雨条纹大小和方向的多样性往往被忽略,导致图像去雨效果不好,图像的细节信息丢失;其次,大多数方法都有一个受限的接受域,增加接受域以获得更多周围信息的潜力仍需讨论。本文提出一种基于多流扩张残差稠密网络的图像去雨算法来解决上述问题,该算法受图像分解去雨算法中图像分解和深度细节去雨算法中负映射操作的启发。首先,将含雨图像分解为包含雨条纹和轮廓信息的细节层和包含背景信息的基础层,直接学习含雨图像细节层和无雨图像细节层之间的残差,减小映射范围,提高网络训练速度。然后,采用带有不同扩张因子(DF)的扩张卷积层提取细节层中复杂多向的雨条纹特征,通过扩张残差稠密连接网络去除提取的雨条纹信息。扩张残差稠密网络结构便于充分利用图像中的多尺度冗余,随着扩张卷积中扩张因子的增大,网络以更快的速度扩大感受野,从而获得更多的上下文信息。最后,对去雨后的细节层与基础层进行叠加获得无雨的图像。

## 2 相关工作

传统的图像去雨方法探索了关于雨条纹特征的某些先验信息,将含雨图像看作是由干净的背景图像层和雨条纹层组成的,因此图像去雨问题可以作为一个分层的问题。Kang 等<sup>[2]</sup>最早提出了一种基于图像分解的单图像去雨方法,该方法首先利用双边滤波器把含雨图像分解为低频和高频两个部分,然后通过稀疏编码和字典学习算法检测和消除高频部分的雨痕。Kim 等<sup>[3]</sup>利用核回归方法检测雨痕区域,然后利用自适应非局部均值滤波器去除检测到的雨痕。Chen 等<sup>[4]</sup>提出一个广义的低秩外观模型,该模型可以去除单个图像或视频中的雨痕。Lou 等<sup>[5]</sup>提出了一种判别稀疏编码的方法,将互斥性考虑到优化框架中,通过将雨层系数向量稀疏化来达到去除图像中雨条纹的目的。Li 等<sup>[6]</sup>通过建立高斯混合模型获取背景层图像块和雨层图像块的先验信息,从含雨图像中分离出雨条纹,并去除分离出的雨条纹。Zhu 等<sup>[7]</sup>提出一种基于联合双层优化的图像去雨方法,该方法通过三项先验迭代分离雨层和背景层,并采用最小二乘法来优化问题,达到图像去雨的目的。

近些年来,深度学习由于强大的特征表示能力和端到端的数据表达能力,被广泛应用于图像去雨任务中。Fu 等<sup>[8]</sup>最先将卷积神经网络引入到图像去雨领域,首先将含雨图像分解为基础层和细节层,然后用三层卷积网络去除含雨图像细节层中的雨条纹,最后将去雨后的细节层与基础层相加得到无雨图像。随后,Fu 等<sup>[9]</sup>将残差网络<sup>[10]</sup>作为图像去雨的主干网络并引入负残差映射思想,减小映射范围,提高了计算效率。Yang 等<sup>[11]</sup>提出了一种联合雨水检测和去除的循环卷积神经网络,该网络采用膨胀卷积和循环结构处理雨条纹信息,并且为了有效去除大气中的烟雾,在网络中嵌入了去雾网络。Zhang 等<sup>[12]</sup>提出了一种基于条件生成对抗网络的去雨方法,该方法通过引入一个感知损失函数来提高训练的稳定性并减少生成对抗网络引入的伪影。Zhang 等<sup>[13]</sup>提出了一种密度感知的多流密集连接的卷积神经网络,该网络由一个感知雨密度的分类器和一个雨水去除网络组成,用于联合估计雨密度和去除雨条纹。此外,Fu 等<sup>[14]</sup>还提出一种基于轻量级金字塔网络的图像去雨框架,拉普拉斯网络框架的应用减少了计算参数量,提高了计算效率,但代价是去雨质量明显下降。

### 3 图像去雨增强算法

采用如图 1 所示的多流扩张残差稠密连接网络 (MERDN) 去除图像中的雨条纹, 网络结构如图 2 所示。为减小映射范围, 消除背景干扰, MERDN 直接学习含雨图像和无雨图像细节层之间的残差。针对雨条纹大小和方向的不一致性, 采用 3 条带有不

同扩张因子的扩张卷积提取不同尺度的雨条纹特征。受到密集神经网络 (Desnet)<sup>[15]</sup> 的启发, 在去雨网络中引入稠密连接的思想, 稠密连接结构可以加强特征在网络中的传播, 解决深层网络在训练过程中的梯度消失问题。并且为了减少计算量和扩大感受野, 在每一个稠密连接的小块中, 都采用  $1 \times 1$  卷积和扩张卷积的结构。

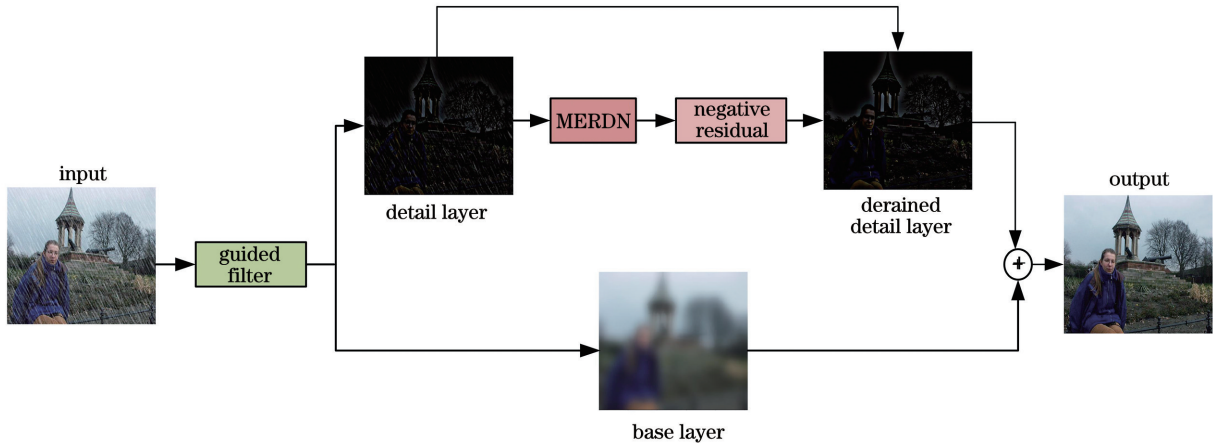


图 1 图像去雨算法的整体框架

Fig. 1 Overall framework of image rain removal algorithm

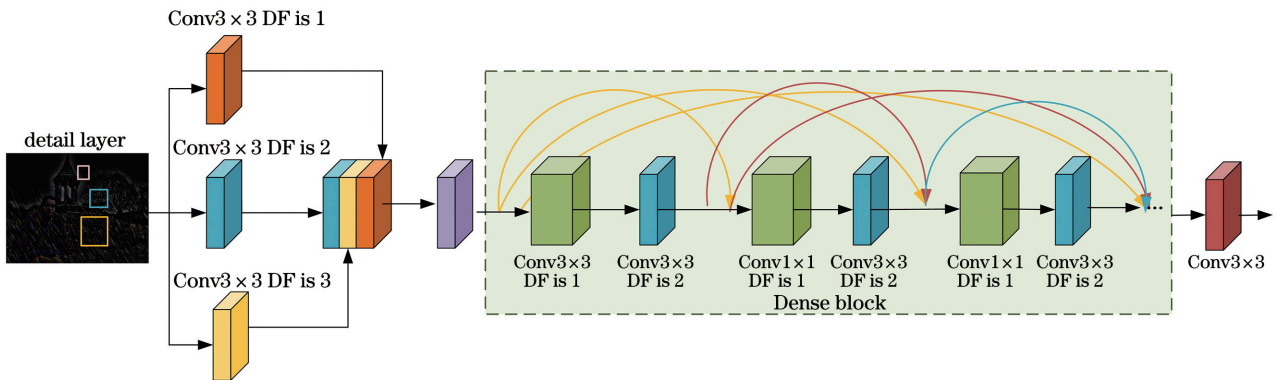


图 2 多流扩张残差稠密网络

Fig. 2 Multiflow expansion residual dense network

#### 3.1 细节层

直接在图像域训练含雨图像到无雨图像之间的映射, 映射范围覆盖所有可能的像素值, 这很难很好地学习回归函数, 并且随着网络深度的加深可能会出现梯度消失现象。考虑到雨条纹信息几乎存在于高频部分, 将含雨图像和无雨图像分别通过导向滤波器分解为低频 (基础层) 和高频 (细节层) 两部分, 表达式分别为

$$\mathbf{X} = \mathbf{X}_{\text{base}} + \mathbf{X}_{\text{detail}}, \quad (1)$$

$$\mathbf{Y} = \mathbf{Y}_{\text{base}} + \mathbf{Y}_{\text{detail}}, \quad (2)$$

式中:  $\mathbf{X}$  为含雨图像;  $\mathbf{Y}$  为无雨图像; base 代表基础层, detail 代表细节层。相比传统双边滤波器, 导向

滤波器对图像进行分解时具有计算效率高、边缘保护强等特性。在滤波效果上, 导向滤波器对细节的处理更加细腻。

如图 3 所示, 细节层保留图像的边缘信息和雨条纹信息, 基础层保留图像的背景信息, 几乎没有雨水存在, 含雨图像和无雨图像的基础层相似。图 4 为含雨图像基础层和无雨图像基础层的平均颜色曲线对比, 表明两者在颜色分布上接近。因此, 为使图像去雨问题更加简单, 并且减小映射范围, 在保持图像背景信息不变的前提下, 仅在细节层上训练网络, 然后对网络预测的无雨细节层和包含背景层信息的基础层进行叠加, 便可得到无雨图像。






图 3 图像分解示例。(a)含雨图像;(b)含雨图像基础层;(c)无雨图像基础层;(d)含雨图像细节层

Fig. 3 Examples of image decomposition. (a) Rainy image; (b) base layer of rainy image; (c) base layer of rainless image; (d) detail layer of rainy image




图 4 基础层颜色曲线图。(a)无雨图像;(b)含雨图像

Fig. 4 Color curves of base layer. (a) Rainless image; (b) rainy image

### 3.2 负残差映射

为进一步缩小映射范围,优化映射空间,引入残差思想到网络中。无雨图像和含雨图像之间的残差显著稀疏,建立无雨图像和含雨图像之间的负残差映射可以降低网络训练的难度,有助于学习映射。

无雨图像、含雨图像以及两者之间的残差如图 5 所示,雨水一般都是以白色条纹的形式出现在图像中,其像素的灰度值接近于 255,因此,无雨图像与含雨图像之间的残差大多都为负值,所以无雨图像减含雨图像的残差称为负残差映射。




图 5 残差图示例。(a)无雨图像;(b)含雨图像;(c)残差图像

Fig. 5 Example of residual image. (a) Rainless image; (b) rainy image; (c) residual image

### 3.3 多尺度特征提取网络

考虑到雨条纹的多样性,如有的含雨图像中雨点小,有的含雨图像中雨点大,小雨点对应小的感受野,大雨点对应大的感受野。为提取多尺度、多方向的雨条纹特征,将这些特征聚合起来。采用 3 条带有不同扩张因子的扩张卷积对含雨图像细节层进行特征提取,3 条支路分别采用扩张因子为 1,2,3 的扩张卷积来提取特征,该结构可以聚合更多尺度上下文空间信息。其效果类似于使用不同大小的卷积

核,但相比直接使用不同大小的卷积提取特征,使用扩张卷积进行多尺度特征提取具有参数量更少、训练更容易、效果更好的优点<sup>[16]</sup>。

### 3.4 改进的密集连接块

为了加强特征的传递,更有效地利用特征,使用密集连接块(Dense block)结构,Dense block 前面每一层的输出都会通过短连接的方式输入到后面的每一层中,处于网络后面的卷积层也能够利用前面卷积层所提取到的特征<sup>[17]</sup>。为了减少网络参数计



算量,密集块中的卷积部分使用  $1 \times 1$  的卷积,为了扩大感受野,密集块中的另一部分卷积使用扩张卷积。Dense block 结构如图 2 所示,其输出来自具有不同接收场的层,从而在不同尺度上提取有用的密集特征,加强信息的传播,缓解了网络训练中的梯度消失现象。

### 3.5 目标函数及网络的具体设置

对于含雨图像  $\mathbf{X}$  和无雨图像  $\mathbf{Y}$ ,定义目标函数为

$$L = \frac{1}{N} \sum_{i=1}^N \left\| f(\mathbf{X}_{i,\text{detail}}, \mathbf{W}, \mathbf{b}) + \mathbf{X}_{i,\text{detail}} - \mathbf{Y}_{i,\text{detail}} \right\|_F^2, \quad (3)$$

式中: $N$  为训练图像数目; $f(\cdot)$  为扩张残差密集网络; $\mathbf{W}$  为权重; $\mathbf{b}$  为偏移量; $\mathbf{X}_{\text{detail}}$  和  $\mathbf{Y}_{\text{detail}}$  分别为含雨图像的细节层和无雨图像的细节层; $\|\cdot\|_F$  为弗罗贝尼乌斯范数。

基本网络结构可以表示为

$$\begin{cases} \mathbf{X}_{\text{detail}} = \mathbf{X} - \mathbf{X}_{\text{base}} \\ \mathbf{X}_{\text{detail}}^{01} = \sigma(\mathbf{W}^{01} * \mathbf{X}_{\text{detail}} + \mathbf{b}^{01}) \\ \mathbf{X}_{\text{detail}}^{02} = \sigma(\mathbf{W}^{02} * \mathbf{X}_{\text{detail}} + \mathbf{b}^{02}) \\ \mathbf{X}_{\text{detail}}^{03} = \sigma(\mathbf{W}^{03} * \mathbf{X}_{\text{detail}} + \mathbf{b}^{03}) \\ \mathbf{X}_{\text{detail}}^1 = \sigma(\mathbf{W}^1 * C[\mathbf{X}_{\text{detail}}^{01}, \mathbf{X}_{\text{detail}}^{02}, \mathbf{X}_{\text{detail}}^{03}] + \mathbf{b}^1) \\ \mathbf{X}_{\text{detail}}^{2l} = \sigma(\mathbf{W}^{2l} * C[\mathbf{X}_{\text{detail}}^1, \mathbf{X}_{\text{detail}}^3, \mathbf{X}_{\text{detail}}^5, \dots, \mathbf{X}_{\text{detail}}^{2l-1}] + \mathbf{b}^{2l}) \\ \mathbf{X}_{\text{detail}}^{2l+1} = \mathbf{W}^{2l+1} * \mathbf{X}_{\text{detail}}^{2l} + \mathbf{b}^{2l+1} \\ \mathbf{X}_{\text{derained detail}} = \mathbf{W}^L * C[\mathbf{X}_{\text{detail}}^1, \mathbf{X}_{\text{detail}}^3, \mathbf{X}_{\text{detail}}^5, \dots, \mathbf{X}_{\text{detail}}^{L-1}] + \mathbf{b}^L + \mathbf{X}_{\text{detail}} \end{cases}, \quad (4)$$

式中:网络层数  $l=1,2,\dots,(L-2)/2$ ;  $*$  为卷积操作符号; $\sigma$  为线性矫正单元; $C[\cdot]$  为特征图级联合并。最终去雨图像可以表示为已去雨的细节层和基础层的叠加,即预测的无雨图像表示为

$$\mathbf{Y}_{\text{approx}} = \mathbf{X}_{\text{derained detail}} + \mathbf{X}_{\text{base}}. \quad (5)$$

网络参数设置如表 1 所示。首先,采用 3 条分支网络提取复杂多向的雨线特征,各分支网络分别由扩张因子为 1,2,3 的  $3 \times 3$  大小的扩张卷积构成。然后,将提取到的特征聚集起来并通过 18 层的扩张残差密集网络,每个稠密连接的小块中都包含 2 个卷积层。第一层采用  $1 \times 1$  卷积, $1 \times 1$  卷积利于促进特征融合并减少网络参数量,第二层采用扩张因子为 2, $3 \times 3$  大小的扩张卷积,扩大感受野。最后,采用  $3 \times 3$  大小的卷积层作为网络最后一层。

表 1 参数层的详细设置

Table 1 Detailed setting of parameter layer

Layer	Filter size	Dilated factor	Number of filters
Convolution $\times 1$	$3 \times 3$	1	32
Convolution $\times 1$	$3 \times 3$	2	32
Convolution $\times 1$	$3 \times 3$	3	32
Dense block $\times 9$	$1 \times 1$	1	64
Dense block $\times 9$	$3 \times 3$	2	32
Convolution $\times 1$	$3 \times 3$	1	3

## 4 实验及结果分析

### 4.1 数据集

采用 3 种数据集训练和测试 MERDN 图像去雨算法。数据集 1:来源于文献[5],包含 1000 张无雨图片和 14000 张合成带雨图片,14000 张带雨图像由 1000 张无雨图像通过 Photoshop 操作添加 14 个不同方向和尺度的雨条纹制作而成,选取 900 对图像作为训练集,从剩下的图像中随机选择 100 对图像作为测试集。数据集 2:来源于文献[7],训练集包括 200 对不同环境下拍摄的图像,测试集包括 100 对不同环境下拍摄的图片。数据集 3:来源于文献[3],包含 12 对不同环境下拍摄的测试图像对。

### 4.2 参数设置

实验环境为 Windows 10,处理器为 Intel(R) Core(TM) i7-6700 CPU @ 3.4 GHz,内存 32 G,显卡为 GTX1080,编程环境为 Python3.7,开发工具为 PyCharm 2018,使用 TensorFlow 框架进行网络训练和测试。使用权重衰减为  $10^{-10}$  的 Adam 优化器来迭代更新网络参数,批次大小为 20,学习率初始化为  $10^{-3}$ ,并在 100000 次迭代后除以 10,在 200000 次迭代后终止训练。

### 4.3 基本方法

对 MERDN 算法和几个经典且去雨效果较好

的算法进行比较,包括基于高斯混合滤波器的去雨算法(GMM)、基于判别稀疏编码的去雨算法(DSC)、基于图像分解的去雨算法(DCN)、基于条件生成对抗网络的去雨算法(ID-CGAN)、基于多流密集网络的密度感知的去雨算法(DID-MDN)。前两种是传统的去雨方法,后几种是最新的基于深度学习的去雨方法。

#### 4.4 合成图片结果

对于合成图片,采用峰值信噪比(PSNR)<sup>[18]</sup>和结构相似性指数(SSIM)<sup>[19]</sup>这两个评价指标。各种图像去雨算法的 PSNR 和 SSIM 如表 2、3 所示。

表 2 不同算法的 PSNR

Table 2 PSNR of different algorithms unit: dB			
Algorithm	Dataset 1	Dataset 2	Dataset 3
GMM	23.75	28.36	30.70
DSC	22.03	24.16	30.02
DCN	21.97	28.17	29.42
ID-CGAN	23.81	23.39	20.78
DID-MDN	26.17	28.27	28.90
MERDN	26.46	28.81	31.90

表 3 不同算法的 SSIM

Table 3 SSIM of different algorithms			
Algorithm	Dataset 1	Dataset 2	Dataset 3
GMM	0.7844	0.8712	0.8928
DSC	0.7985	0.8679	0.8679
DCN	0.8333	0.9134	0.9033
ID-CGAN	0.8072	0.8275	0.8519
DID-MDN	0.8409	0.8625	0.8762
MERDN	0.8841	0.9173	0.9381

从表 2、3 可以发现:与其他算法相比,在不同数据集上,MERDN 算法得到的去雨结果都具有更高的 PSNR 和 SSIM 值;在数据集 1 上,MERDN 算法的平均 PSNR 值比 GMM 算法、DSC 算法、DCN 算法、ID-CGAN 算法及 DID-MDN 算法分别高 2.71 dB、4.43 dB、4.49 dB、2.65 dB、0.29 dB;MERDN 算法的平均 SSIM 值比 GMM 算法、DSC 算法、DCN 算法、ID-CGAN 算法及 DID-MDN 算法分别高 0.0997、0.0856、0.0508、0.0769、0.0432。由此可见,MERDN 算法使图像去雨的性能得到大幅度提高,具有较好的去雨表现。

为了直观地显示出所提算法与其他对比算法在

图像去雨视觉效果上的不同,在两张合成图像上对所提算法与其他算法的去雨效果进行比较,实验结果如图 6 所示,为了观察图像部分区域的细节,对图片中部分区域进行细节放大处理。



图 6 不同算法在合成雨水图像上的视觉比较。(a1)(a2) 含雨图像;(b1)(b2) GMM 算法;(c1)(c2) DSC 算法;(d1)(d2) DCN 算法;(e1)(e2) DID-MDN 算法;(f1)(f2) MERDN 算法

Fig. 6 Visual comparison of different algorithms on composite rainy images. (a1)(a2) Rainy image; (b1)(b2) GMM algorithm; (c1)(c2) DSC algorithm; (d1)(d2) DCN algorithm; (e1)(e2) DID-MDN algorithm; (f1)(f2) MERDN algorithm



从图 6 可以观察到:GMM 算法处理的结果比较模糊,包含雨迹伪影;DSC 算法留下明显的雨痕;DCN 算法去除了大部分雨痕,但仍保留了一些雨痕,特别是去除大雨条纹效果不理想;DID-MDN 算法的去雨效果较好,但由于很难划分输入雨图像的雨密度类别,因此该方法容易模糊图像细节,导致细节部分信息丢失;对比其他算法,MERDN 算法能够

有效去除复杂多向的雨条纹并较好地保留背景图像中的细节信息,去雨后图像具有更清晰的视觉效果。

#### 4.5 真实图片结果

由于真实拍摄的雨天图像没有相对应的标签图像,因此无法对算法进行关于 PSNR 和 SSIM 的比较,只能从主观视觉效果上比较各种算法的去雨效果。图 7 为两幅真实图像的定性比较结果。




图 7 不同算法在真实雨水图像上的视觉比较。(a1)(a2)含雨图像;(b1)(b2) GMM 算法;(c1)(c2) DSC 算法;  
(d1)(d2) DCN 算法;(e1)(e2) DID-MDN 算法;(f1)(f2) MERDN 算法

Fig. 7 Visual comparison of different algorithms on real rainy images. (a1)(a2) Rainy image; (b1)(b2) GMM algorithm;  
(c1)(c2) DSC algorithm; (d1)(d2) DCN algorithm; (e1)(e2) DID-MDN algorithm; (f1)(f2) MERDN algorithm



观察图 7 可以发现:GMM 算法的图像去雨结果中仍然存在伪影;DSC 算法留下明显的雨痕,去雨效果不好;DCN 算法无法彻底去除雨痕,有细小雨条纹残留;DID-MDN 算法在去除一些含雨图像细节信息的同时模糊图像;与其他图像去雨算法相比,MERDN 算法可以更有效地去除雨痕并且保留细节信息,提供了更好的视觉性能。

#### 4.6 算法效率比较

表 4 为 MERDN 算法和其他去雨算法在算法效率上的比较,该时间为数据集 3 中 12 张图像集测试的平均运算时间。可以观察到:GMM 算法结构复杂、计算量大,需要大量时间;DCN 算法和 DID-MDN 算法虽然相较 GMM 算法更省时,但也需要 10 s 以上的时间;对比其他算法,MERDN 算法计算量小、耗时更少,运算速度更快,效率更高。

表 4 不同算法的效率比较

Table 4 Efficiency comparison of different algorithms

Algorithm	GMM	DCN	DID-MDN	MERDN
Time /s	897	29	11	5

## 5 结 论

针对图像去雨后图像中的残留部分雨条纹、图像细节模糊等问题,提出了一种基于多流扩张残差稠密网络的图像去雨算法,实现了图像去雨增强。首先,构造多流多尺度特征提取网络,对带有图像雨条纹信息的细节层进行特征提取,提取多尺度雨条纹信息。然后,采用残差密集块结构对提取的信息进行处理,残差密集块结构可以在保持网络深度的同时缓解梯度消失现象,加强特征利用。最后,对去雨后的细节层与带有背景信息的基础层进行叠加,得到无雨图像。实验证明,无论是在去雨图像的主观视觉效果上,还是在 PSNR 和 SSIM 客观评价指标上,所提算法均具有一定的优势。从而说明所提算法能够有效克服传统图像去雨算法中未考虑多尺度雨条纹的问题,较好地恢复图像细节信息,得到了细节清晰的无雨图像,图像去雨质量得到了提升。

#### 参 考 文 献

- [1] Ou P, Zhang Z, Lu K, et al. Object detection of remote sensing images based on convolutional neural networks [J]. *Laser & Optoelectronics Progress*, 2019, 56(5): 051002.  
欧攀, 张正, 路奎, 等. 基于卷积神经网络的遥感图像目标检测 [J]. *激光与光电子学进展*, 2019, 56(5): 051002.
- [2] 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*, 2012, 21(4): 1742-1755.
- [3] Kim J H, Lee C, Sim J Y, et al. Single-image deraining using an adaptive nonlocal means filter [C] // 2013 IEEE Transactions on Image Processing, September 15-18, 2013, Melbourne, VIC, Australia. New York: IEEE Press, 2013: 914-917.
- [4] Chen Y L, Hsu C T. A generalized low-rank appearance model for spatial-temporally correlated rain streaks [C] // 2013 IEEE International Conference on Computer Vision, December 1-8, 2013, Sydney, NSW, Australia. New York: IEEE Press, 2013: 1968-1975.
- [5] Lou Y, Xu Y, Ji H. Removing rain from a single image via discriminative sparse coding [C] // 2015 IEEE International Conference on Computer Vision, December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 3397-3405.
- [6] Li Y, Tan R T, Guo X, et al. Rain streak removal using layer priors [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition, June 26-July 1, 2016, Las Vegas, NV. New York: IEEE Press, 2016: 2736-2744.
- [7] Zhu L, Fu C W, Lischinski D, et al. Joint bi-layer optimization for single-image rain streak removal [C] // 2017 IEEE International Conference on Computer Vision, October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 2526-2534.
- [8] Fu X Y, Huang J B, Ding X H, 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.
- [9] Fu X Y, Huang J B, Zeng D L, et al. Removing rain from single images via a deep detail network [C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 1715-1723.
- [10] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [11] Yang W H, Tan R T, Feng J S, et al. Deep joint rain detection and removal from a single image [EB/OL]. (2017-03-13) [2020-09-24]. <https://arxiv.org/abs/1609.07769>.
- [12] Zhang H, Sindagi V, Patel V M. Image de-raining using a conditional generative adversarial network [J].

- IEEE Transactions on Circuits and Systems for Video Technology, 2019.
- [13] Zhang H, 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, June 18-23, 2018, Salt Lake, UT, USA. New York: IEEE Press, 2018: 695-704.
- [14] Fu X, Liang B, Huang Y, et al. Lightweight pyramid networks for image deraining [J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(6): 1794-1807.
- [15] Huang G, Liu Z, Maaten L V D, et al. Densely connected convolutional networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [16] Chen Y, Guo H G, Ai Y P. Single image dehazing method based on multi-scale convolution neural network [J]. Acta Optica Sinica, 2019, 39(10): 1010001.
- 陈永, 郭红光, 艾亚鹏. 基于多尺度卷积神经网络的单幅图像去雾方法 [J]. 光学学报, 2019, 39(10): 1010001.
- [17] Huang S, Li F F, Chen Q. Computed tomography image classification algorithm based on improved deep residual network [J]. Acta Optica Sinica, 2020, 40(3): 0310002.
- 黄盛, 李菲菲, 陈虬. 基于改进深度残差网络的计算断层扫描图像分类算法 [J]. 光学学报, 2020, 40(3): 0310002.
- [18] Huynh-Thu Q, Ghanbari M. Scope of validity of PSNR in image/video quality assessment [J]. Electronics Letters, 2008, 44(13): 800-801.
- [19] Wang Z, 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.