

控制与决策

Control and Decision

基于倍频卷积和注意力机制的图像去雨

杨青, 于明, 付强, 阎刚

引用本文:

杨青, 于明, 付强, 阎刚. 基于倍频卷积和注意力机制的图像去雨[J]. *控制与决策*, 2023, 38(12): 3372–3380.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2022.0490>

您可能感兴趣的其他文章

Articles you may be interested in

[一种基于多层语义特征的图像理解方法](#)

An image understanding method based on multi-level semantic features

控制与决策. 2021, 36(12): 2881–2890 <https://doi.org/10.13195/j.kzyjc.2020.0927>

[基于协同聚类和权重注意力稀疏自编码网络的变化检测方法](#)

Change detection approach based on cooperative clustering and weighted-attention sparse autoencoder

控制与决策. 2021, 36(10): 2442–2450 <https://doi.org/10.13195/j.kzyjc.2019.1633>

[基于自注意力生成对抗网络的图像超分辨率重建](#)

Image super-resolution reconstruction based on self-attention GAN

控制与决策. 2021, 36(6): 1324–1332 <https://doi.org/10.13195/j.kzyjc.2019.1290>

[复杂背景下全景视频运动小目标检测算法](#)

Panoramic video motion small target detection algorithm in complex background

控制与决策. 2021, 36(1): 249–256 <https://doi.org/10.13195/j.kzyjc.2019.0686>

[基于图像和高程数据的天际线定位匹配](#)

Skyline position matching based on image and elevation data

控制与决策. 2020, 35(11): 2665–2674 <https://doi.org/10.13195/j.kzyjc.2019.0155>

基于倍频卷积和注意力机制的图像去雨

杨青^{1,2}, 于明^{3†}, 付强², 阎刚³

(1. 河北工业大学 电子信息工程学院, 天津 300401; 2. 陆军工程大学石家庄校区
电子与光学工程系, 石家庄 050003; 3. 河北工业大学 人工智能与数据科学学院, 天津 300401)

摘要: 针对机器视觉场景图像中由于雨线影响导致背景信息模糊、损失的问题, 提出一种基于倍频卷积和注意力机制的图像去雨方法. 首先, 建立基于空-频域去雨模型, 设计基于空间尺度变换和倍频卷积的频率特征分解模块, 通过学习得到频率特征和雨线特征的映射关系, 降低低频特征空间冗余, 提高网络运行效率; 其次, 设计多层通道注意力模块映射雨线层权重信息, 增强重要特征, 挖掘雨线层之间的亮度差异, 提高雨线检测性能; 最后, 通过序列操作迭代分解出不同成分的雨线信息, 进而完成场景图像去雨. 实验结果表明, 所提方法对不同方向、形状的雨线和雨滴具有良好的去除性能, 同时对于背景图像的细节与边缘信息也具有较好的保护作用.

关键词: 图像去雨; 去雨模型; 倍频卷积; 分频特征映射; 多层通道注意力; 特征权重

中图分类号: TP183; TP391.41 文献标志码: A

DOI: 10.13195/j.kzyjc.2022.0490

引用格式: 杨青, 于明, 付强, 等. 基于倍频卷积和注意力机制的图像去雨[J]. 控制与决策, 2023, 38(12): 3372-3380.

Image de-raining based on octave convolution and attention mechanism

YANG Qing^{1,2}, YU Ming^{3†}, FU Qiang², YAN Gang³

(1. College of Electronic Information Engineering, Hebei University of Technology, Tianjin 300401, China; 2. Department of Electronic and Optical Engineering, Shijiazhuang Campus of Army Engineering University, Shijiazhuang 050003, China; 3. School of Artificial Intelligence, Hebei University of Technology, Tianjin 300401, China)

Abstract: Aiming at the problem of background information blur and loss caused by rain streaks in machine vision scene images, a method of image de-raining based on octave convolution and attention mechanism is proposed. Firstly, a de-raining model based on spatial-frequency domain is established, and a frequency feature decomposition module is designed based on spatial scale transformation and octave convolution. The mapping relationship between frequency features and rain streaks features is obtained through learning, so as to reduce spatial redundancy of low-frequency features and improve network operation efficiency. Secondly, the multi-layer channel attention module is designed to map the weight information of rain streaks, enhance important features, mine the brightness difference between rain streaks layers, and improve the performance of rain streaks detection. Finally, the rain streaks information of different components is decomposed iteratively through sequence operation, and then the de-raining of scene image is completed. Experimental results show that the proposed method has good removal performance for rain streaks and raindrops with different directions and shapes, and also has good protection for details and edge information of background image.

Keywords: image de-raining; de-raining module; octave convolution; frequency division feature mapping; multi-layer channel attention; feature weight

0 引言

计算机视觉系统非常容易受下雨天气的影响, 导致场景图像质量下降、背景场景变得模糊, 这些图像退化现象将严重影响系统对目标的识别、跟踪等功

能的智能控制. 有效地去除视觉场景中的雨线信息, 可以更好地保留图像细节, 提高场景的清晰度.

单图像去雨由于缺少视频帧之间的时域特征, 去雨更具有难度, 目前单图像去雨主要可分为基于模型

收稿日期: 2022-03-28; 录用日期: 2022-08-09.

基金项目: 国家自然科学基金项目(61806071, 62102129).

责任编委: 张国山.

†通讯作者. E-mail: yuming@hebut.edu.cn.

和数据驱动两大类方法^[1]. 基于模型的去雨方法主要有基于图像分解^[2]、基于稀疏编码^[3]和基于先验的高斯混合模型^[4]. 随着深度卷积神经网络出现并在多个领域证明其有效性后,越来越多的研究者开始聚焦于基于数据驱动的去雨方法,研究方向主要集中在基于深度卷积神经网络^[5-6]、生成对抗网络^[7]和半/无监督方法的单图像去雨^[8-9]. 为了提高网络学习性能,将雨掩模^[10]、背景特征^[11]等约束条件加入到去雨网络中,同时采用循环网络^[10]、递归网络^[12]的体系结构逐层逐步进行去雨,也有一系列方法关注深度特征的层次信息^[13].

目前,基于数据驱动的单图像去雨方法所构建的去雨网络通常学习像素到像素的空域映射关系,进而完成单图像雨线信息的去除,但存在以下不足:

1) 场景特征大多是基于空间域特征建立,频域特征的获取需要人工先验方法,弱化了雨场景图像中空域与频域之间特征的依赖关系;

2) 卷积神经网络生成的特征图在空间映射中既包含图像的高频信息也包含低频信息,在空间维度中造成特征冗余,影响了网络的运行速度;

3) 由于雨线方向、尺度的随机分布,其特征之间的差别不易辨别,导致雨线与背景、细节等信息混淆.

本文在建立频域去雨模型的基础上,提出一种基于倍频卷积和注意力机制的图像去雨方法,结合雨场景中的空间特征与频率特征来表示雨线和无雨场景的空-频域关系;通过尺度空间变换与分频映射分组构建雨线检测网络,降低低频特征空间冗余,提高运算效率;在频率特征分解模块下融合多层通道注意力模块映射雨线层权重信息,增强重要特征,进一步挖掘雨线层之间的亮度差异,获取更可靠的雨线特征表达;最后,通过序列模块迭代分解不同成分的雨线特征,从而实现单图像的去雨,恢复去雨后图像的背景信息.

1 相关工作

基于模型的去雨方法需要建立雨线信息和背景的先验信息,然后构建代价函数并对其进行优化. 文献[3]利用判别式稀疏编码从图像中的高频分量中学习无雨分量,然后与低频分量叠加得到雨线去除后的场景;文献[4]在图像分解的基础上将场景分为背景层和雨线层,通过高斯混合模型构建先验信息,该方法不易求取准确的高斯混合模型参数;文献[14]融合局部和非局部稀疏约束先验,利用降雨方向先验信息

进行单图像去雨.

基于数据驱动的去雨方法利用深度网络自动提取层次特征,构建从雨场景到无雨场景的非线性映射关系. 文献[5-6]首先通过导引滤波将雨场景图像分解为低频段和高频段,然后利用深度残差网络将高频信息映射到雨线层,训练稳定、收敛速度快;文献[10]设计了一种深度循环扩张网络联合检测来去除雨线;文献[7]使用生成对抗网络,捕获超出信号保真度的视觉特性,具有较好的光照、颜色和对对比度分布;文献[12]设计了具有循环层的渐进递归网络,网络结构简单,能有效去除雨线;文献[15]利用注意力机制构建模型雨线的密度和亮度特征,通过循环神经网络分时学习;文献[16]设计了一种新的多阶段卷积神经网络,该网络由几个并行的子网络组成,每个子网络都能感知不同尺度的雨条纹;文献[17]使网络本身能够自动确定雨密度信息,并根据估计的雨密度标签有效地去除相应的雨条纹;文献[18]对于不同位置的相似雨线,采用递归计算来获取全局纹理,通过空间维度上互补和冗余信息来表征雨线.

从上述分析可知,去雨网络通常采用负残差、注意力机制、膨胀卷积学习像素到像素的空域映射关系,忽略空-频域特征间的上下文信息,因此本文提出一种基于倍频卷积和注意力机制的图像去雨方法,关注雨场景中的频率特征与尺度空间变换,进一步提高图像去雨性能.

2 去雨模型

目前,在空间域中,去雨模型最直观表示形式是将有雨场景 \mathbf{X} 线性分解为无雨的同场景背景 \mathbf{Y} 和雨线 \mathbf{R} ,即

$$\mathbf{X} = \mathbf{Y} + \mathbf{R}. \quad (1)$$

在现实中,空气中的雨滴表现形式根据拍摄距离不同、空气中的衰减和散射等因素而形式多样,这就导致了雨线的分布是不规则的,从而进一步增加了雨线亮度的多样性^[15]. 为降低模型的复杂性,同时考虑雨线的亮度变换对背景图像亮度的影响,可将具有相同形状与深度的雨线视为同一雨层 $\mathbf{R}_i (i = 1, 2, \dots, n)$,有雨图像可表示为

$$\mathbf{X} = \mathbf{Y} + \sum_{i=1}^n \mathbf{R}_i, \quad i = 1, 2, \dots, n. \quad (2)$$

在频域中,有雨图像 \mathbf{X} 的频率分布 $\mathcal{F}(\mathbf{X})$ 包含了图像中的高频信息和低频信息,即 $\mathcal{F}(\mathbf{X}) = \{\mathcal{F}^H(\mathbf{X}), \mathcal{F}^L(\mathbf{X})\}$. 将同场景的有雨与无雨图像对

在频域中的频谱图进行对比可以发现,雨图频谱与无雨背景频谱相比,能量由低频部分向四周扩散,雨线的频率信息分布 \mathcal{F}^R 同时存在于频率空间的4个象限中,既有高频信息也有低频信息,如图1所示。

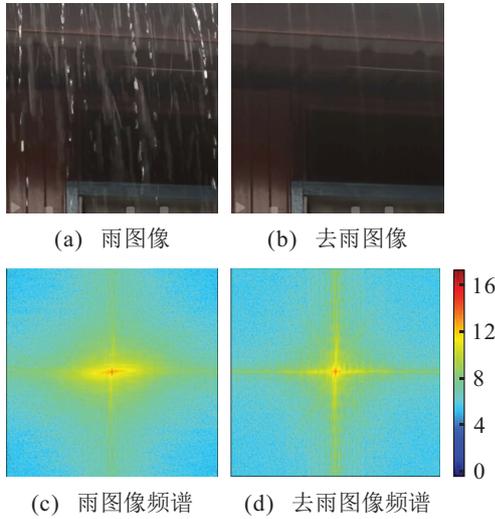


图1 雨图像对的频谱图

雨线的频率信息分布可以表示为

$$\mathcal{F}^R = \mathcal{F}^{H \rightarrow H}(\mathbf{X}) + \mathcal{F}^{L \rightarrow H}(\mathbf{X}). \quad (3)$$

$\mathcal{F}^{H \rightarrow H}$ 为存在于高频信息中的雨线频率, $\mathcal{F}^{L \rightarrow H}$ 为存在于高低频带信息间的雨线频率. 因此, 雨线图像可以表示为

$$\mathbf{R} = \mathcal{F}^{-1}(\mathcal{F}^R) = \mathcal{F}^{-1}[\mathcal{F}^{H \rightarrow H}(\mathbf{X}) + \mathcal{F}^{L \rightarrow H}(\mathbf{X})]. \quad (4)$$

将式(4)代入到(2)中, 有雨图像可以表示为

$$\mathbf{Y} = \mathbf{X} - \sum_{i=1} \mathcal{F}^{-1}[\mathcal{F}^{H \rightarrow H}(\mathbf{X}) + \mathcal{F}^{L \rightarrow H}(\mathbf{X})]. \quad (5)$$

3 去雨算法

传统频域去雨方法是将空域中建立的去雨模型通过傅里叶变换对^[19-20]、小波变换^[21]的方式进行空

域与频域间的转换, 无法主动学习雨线特征在空-频域间的上下文信息. 本文提出一种基于空-频域去雨模型的端到端去雨算法. 网络结构对应式(5)的去雨模型, 将去雨过程分频、分步执行, 迭代分解出具有不同特征的雨线, 提高模型对雨线的识别能力.

3.1 分频特征映射模块

实现式(4)中雨线信息与图像中频率信息之间的映射关系, 本文引入文献[22]的多频特征映射理论, 利用空间尺度变换和倍频卷积(OctCNN)将卷积算子分为低频部分和高频部分, 每组频率特征信息更新的同时实现组间频率信息的交互. 分频特征映射网络结构如图2所示. 输入雨图像 \mathbf{X} 为 $3 \times h \times w$ 的RGB图像, 通过分组卷积操作输出为2组 $24 \times h \times w$ 的特征图, 一组经过 3×3 卷积作为高频特征的输入 $(\mathbf{X}_H)_{in}$, 另一组经过 2×2 平均池化得到降空间分辨率为 $24 \times 0.5h \times 0.5w$ 的低频特征的输入 $(\mathbf{X}_L)_{in}$. 通过OctCNN可得到雨图像的高频特征分量 \mathbf{X}_H 和低频特征分量 \mathbf{X}_L , 分别为

$$\begin{aligned} \mathbf{X}_H &= \mathbf{X}_{H \rightarrow H} + \mathbf{X}_{L \rightarrow H} = \\ & f_{CNN}((\mathbf{X}_H)_{in}, W_{3 \times 3}^{H \rightarrow H}) + \text{upsample}((\mathbf{X}_L)_{in}, 2), \quad (6) \\ \mathbf{X}_L &= \mathbf{X}_{L \rightarrow L} + \mathbf{X}_{H \rightarrow L} = \\ & f_{CNN}((\mathbf{X}_L)_{in}, W_{3 \times 3}^{L \rightarrow L}) + \text{AvgPool}((\mathbf{X}_H)_{in}, 2). \quad (7) \end{aligned}$$

其中: $\mathbf{X}_{H \rightarrow H}$ 和 $\mathbf{X}_{L \rightarrow L}$ 表示频内信息更新, $\mathbf{X}_{L \rightarrow H}$ 和 $\mathbf{X}_{H \rightarrow L}$ 表示频间信息更新, $W_{3 \times 3}^{H \rightarrow H}$ 和 $W_{3 \times 3}^{L \rightarrow L}$ 分别表示高频和低频内 3×3 的卷积核. 低频特征分量 \mathbf{X}_L 的空间分辨率比高频特征分量 \mathbf{X}_H 降低了一半, 使用倍频卷积有效去除了空间冗余, 提高了计算效率; \mathbf{X}_H 作为雨线 R 的学习特征输入具有灵活的存储低频和低频特征的能力, 从而获得更好的学习能力.

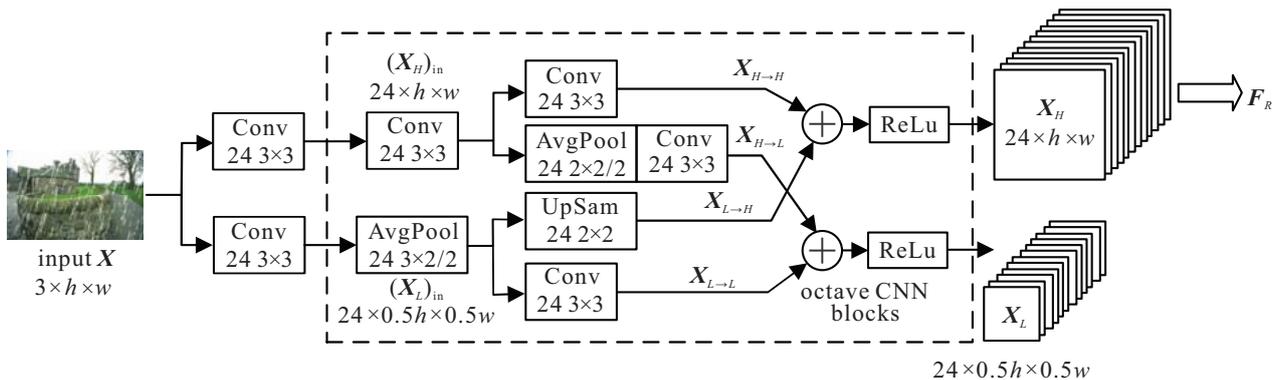


图2 分频特征映射模块结构

3.2 基于多层通道注意力的雨线检测模块

不同方向的雨线层由于镜面反射会导致层之间的亮度差异,因此,本文引入不同方向雨线的亮度权重 α_i ,将雨线进一步表示为 $\mathbf{R} = \sum_{i=1}^n \alpha_i \mathbf{R}_i$,通过多层通道注意力模块^[23]学习每层的权重 α_i ,进一步捕捉不同尺度、方向上的雨线分布的区别特征,提供足够丰富的辨别信息,增强雨线的检测性能。

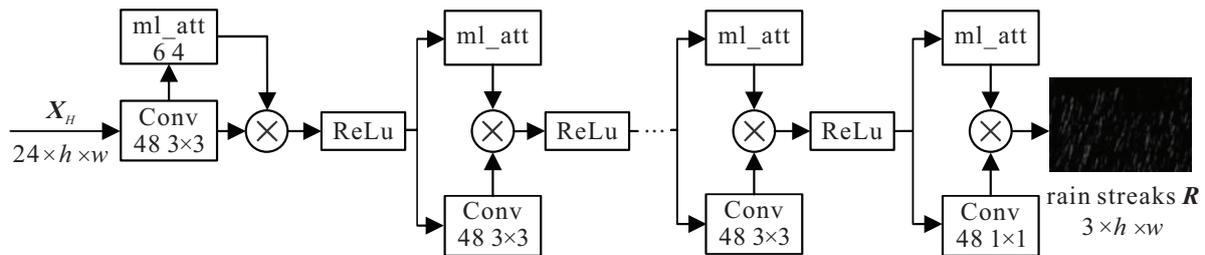


图3 基于多层通道注意力的雨线检测模块结构

多层通道注意力模块第一层的输入特征为高频特征分量 \mathbf{X}_H ,第一层的输出特征为

$$\mathbf{X}_{H'} = \mathbf{X}_H \times s(g(\mathbf{X}_H), \mathbf{W}). \quad (8)$$

其中: $g(\mathbf{X}_H)$ 表示对输入特征进行全局平均池化操作得到每个通道的特征全局信息; $s(g(\mathbf{X}_H), \mathbf{W})$ 表示对每个通道的全局信息特征映射进行权重分配,通过两级全连接层和非线性激活层学习权重 \mathbf{W} ^[24]。

基于多层通道注意力的雨线检测网络采用深度为4的全卷积网络构成,高频特征分量 \mathbf{X}_H 作为输入经 $24 \times 3 \times 3$ 卷积层后送入通道注意力模块ml_att,将其输出的48通道特征与注意模块输出的通道权重相乘后通过非线性激活函数送入下一层,为了复原图像的RGB通道,或者灰度图像的灰度通道,对最后一层采用 1×1 卷积.激活函数选用LeakyReLU,超参数为0.2.网络结构如图3所示。

多层注意力模块每层输出的特征可视化效果如图4所示,为了形象表征特征权重分布,采用cv2中的“COLORMAP_JET”对特征图进行彩色映射.针对雨线检测重要特征和纹理信息,通过注意力模块后赋予更多的权重,增强其特征的显著性;背景特征则赋予较少的权重以降低其显著性.每层对应的权重不同,分别映射雨线层的亮度权重 α_i 。

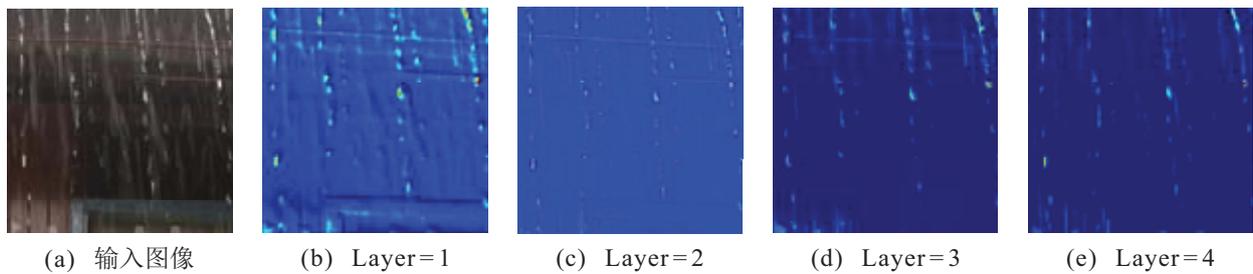


图4 多层注意力模块每层输出特征的可视化效果

3.3 序列去雨网络总体架构

根据式(2),由于雨线相互重叠,去雨过程需要分解成多个阶段,不同阶段的输入图像 $\{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_n\}$ 可看作是去除雨线操作的一系列雨图像的序列,各阶段的输入图像与输出图像之间的关系可以表示为

$$\begin{aligned} \mathbf{X}_n &= \\ \mathbf{X}_{n-1} - f_{\text{MLA}}(\mathbf{X}_{n-1}) &= \\ \mathbf{X}_1 - f_{\text{MLA}}(\mathbf{X}_1) - \dots - f_{\text{MLA}}(\mathbf{X}_{n-1}) &= \end{aligned}$$

$$\mathbf{X}_1 - \sum_{i=1}^{n-1} f_{\text{MLA}}(\mathbf{X}_i) \approx \mathbf{Y}, \quad (9)$$

其中 $f_{\text{MLA}}(\cdot)$ 表示经多层通道注意力模块的输出特征,即雨线频率特征。

序列去雨网络采用分频特征映射模块+多层通道注意力模块作为每个序列的基本结构,网络将前一序列的特征输出作为当前序列特征的输入,通过序列去雨操作,最终得到去雨图像 \mathbf{Y} .由于雨线在方向、颜色和形状上的分布是不同的,整个去雨网络不进行批量标准化处理^[25],从而提高网络训练的稳定性.去雨算法的整体框架如图5所示。

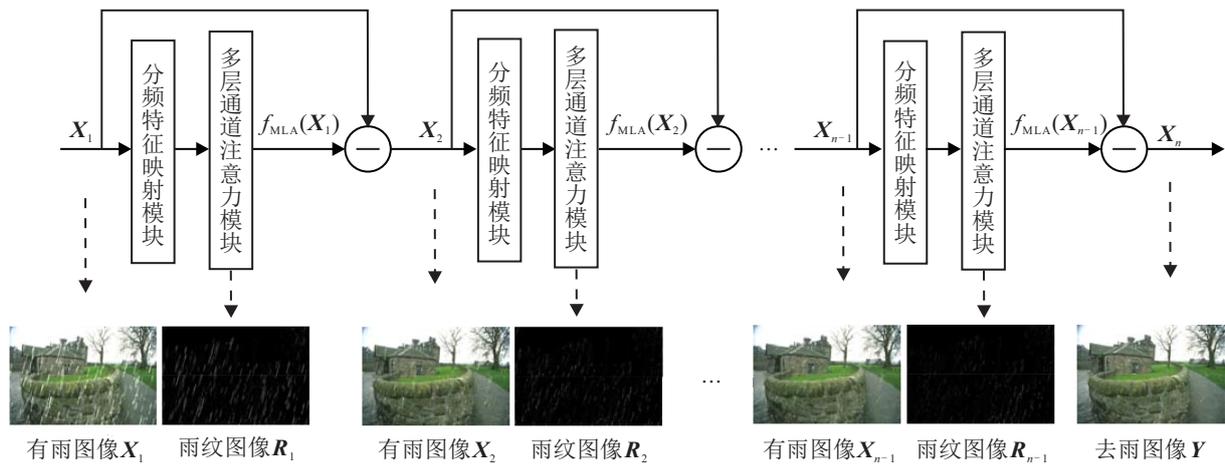


图5 去雨网络整体框架

因为雨线特征相比背景特征更具有稀疏性,所以本算法构建的去雨网络学习的是雨图像 \mathbf{X} 到雨线图像 \mathbf{R} 的映射关系,其损失函数可定义为

$$L(\phi) = \|\mathbf{f}(\mathbf{X}) - \mathbf{R}\|^2 = \sum_{n=1}^n \|\mathbf{f}(\hat{\mathbf{R}}_n) - \mathbf{R}\|^2. \quad (10)$$

4 实验与结果分析

4.1 数据集与评价指标

为验证算法在单图像去雨方面的有效性,分别选取文献[10]、文献[17]提供的合成雨图像对数据集与文献[26]和互联网提供的真实雨图像数据集进行实验. 训练集共包括11 140张图像对,校验集共包括2 540张图像,测试集共包括820张图像.

为了定量衡量算法的去雨效果,采用峰值信噪比 (peak signal noise ratio, PSNR) 和结构相似性 (structural similarity, SSIM) 作为评价指标.

4.2 实验环境与网络设置

利用 Pytorch1.2 搭建网络训练框架,编程语言为 Python 3.7, 计算机配置为 64 G 内存、Inter(R) Xeon(R) Silver 4210 CPU @ 2.2 GHz 2.19 GHz、NVIDIA GeForce RTX 2080Ti GPU. 训练过程中,从每对训练图像中各随机生成100个大小为 64×64 的图像块,

序列个数为4,每个序列中卷积网络深度为7层,其中多频映射模块为2组,每组深度为3层,多层注意力模块深度为4. 为兼顾计算效率和去雨性能,特征映射分配系数 $\beta = 0.5$,分频卷积核大小为 3×3 . 为了抑制梯度方向锯齿问题,激活函数选用 LeakyReLU,超参数为0.2,梯度优化算法选用 ADAM,起始学习率为 5×10^{-3} ,当迭代次数在 15 000 ~ 17 500 之间时,学习率除以10.

4.3 模块及参数对去雨性能的影响

4.3.1 分频特征映射模块

分别对特征频率分解前的卷积层输出特征、分解后的特征高频分量和低频分量的特征图通过二维离散傅里叶变换得到各平均频谱图,如图6所示. 为了形象表征频率分布,采用 cv2 中的“COLORMAP_JET”对频谱图进行彩色映射. 图6(a)为分解前卷积层输出特征频率分布,既包含低频也包含高频信息;图6(b)为分解后的特征高频分量,同时包含低频和高频信息,但是高频信息相比分解前更丰富,说明高频分量具有灵活的存储高频和低频信息的能力,为后续雨线检测提供充分的特征信息;图6(c)为分解后的特征低频分量,能量主要集中在低频部分,降低这部分的空间分辨率可以有效去除冗余.

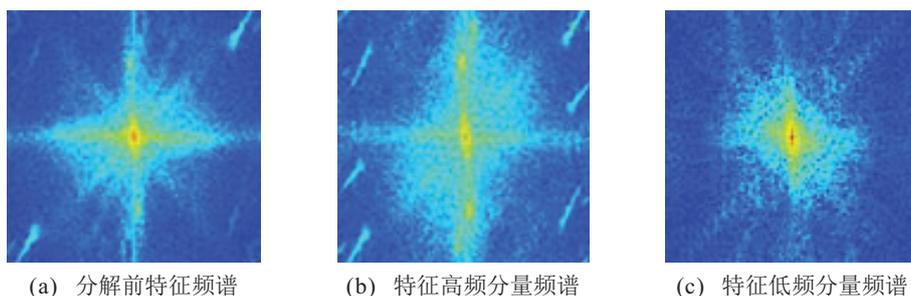


图6 特征频率分解的频谱分析

4.3.2 消融实验

为了验证网络结构中各模块对整个去雨网络的贡献,通过各模块的不同组合方式进行消融实验,结果如表1所示.表1为单独多层注意力模块、分频映射模块以及同时使用两模块(网络序列个数为4)时的实验结果.由去雨性能评价结果可知,不同结构下的SSIM指标比同时采用多层注意力模块和分频特征映射模块时能分别提高约0.022和0.01,表明本算法能保证去雨图像的结构稳定性.对于PSNR指标,

同时采用多层注意力模块和分频特征映射模块时能分别提高约4.436 dB和3.158 dB,验证了本算法结构设计对于提高去雨图像质量的有效性.同时,在GPU下运行算法,运行时间没有受到影响.

多层注意力模块的层数分别在RainTainH和Rain12600两个数据集下进行了对比,两个数据集下的PSNR指标均在层数为4时的指标最佳,虽然层数为5时的指标相近,但综合考虑网络结构的复杂度,算法的注意力模块层数为4.

表1 模块组合消融实验结果

测试图像	分频映射			多层注意力			分频映射+多层注意力		
	PSNR/dB	SSIM	t/s	PSNR/dB	SSIM	t/s	PSNR/dB	SSIM	t/s
图像1	30.51	0.92	0.15	31.56	0.94	0.18	33.17	0.91	0.19
图像2	29.35	0.85	0.18	31.12	0.86	0.18	33.74	0.92	0.18
图像3	28.94	0.91	0.13	29.74	0.92	0.14	30.95	0.93	0.14
图像4	30.04	0.97	0.12	30.26	0.95	0.11	34.2	0.95	0.11
图像5	27.11	0.92	0.15	29.66	0.96	0.17	36.07	0.97	0.15
平均值	29.190	0.914	0.146	30.468	0.926	0.156	33.626	0.936	0.154

4.4 合成雨图的实验对比

将本文算法与DSC^[3]、GMM^[4]、CNN^[5]、DNN^[6]、RESCAN^[15]、DID-MDN^[7]和PRN^[12]等7种典型去雨算法在合成雨图数据集RainTainH和Rain12600上进行定量分析,分析结果如表2所示.实验结果表明,本文算法能够取得较高的峰值信噪比和更好的结构相似性.与其他算法相比,峰值信噪比分别提高了1.28 dB ~ 12.69 dB和0.14 dB ~ 6.64 dB,结构相似度分别提高了0.005 ~ 0.208和0.015 ~ 0.192.

表2 典型去雨算法在Rain12600和RainTainH的定量比较

去雨算法	Rain12600		RainTrainH	
	PSNR/dB	SSIM	PSNR/dB	SSIM
DSC	24.15	0.753	18.68	0.741
GMM	29.48	0.843	22.97	0.789
CNN	23.18	0.874	18.98	0.697
DNN	28.41	0.889	19.22	0.732
RESCAN	32.24	0.942	24.67	0.841
DID-MDN	33.93	0.941	24.31	0.856
PRN	34.59	0.956	25.18	0.874
本文算法	35.87	0.961	25.32	0.889

数据集Rain12600是针对不同雨线方向的合成雨图,数据集RainTainH是雨线密度大、方向多的合

成雨图,如图7所示.DDN、RESCAN和DID-MDN对于密度较大且不同方向的雨线只能去除少量雨线;PRN可以明显去除雨线残留,但是图中一些细节信息由于去雨造成了信息的丢失.与上述算法相比,本文算法对于密度较大且不同方向的雨线去除具有较好的适应能力,在去除雨线的同时可以将图像的细节和边缘信息保留.

4.5 真实雨图的实验对比

真实环境下采集的雨图像来自数据集MPID和互联网雨图像.实验结果如图8所示,对比算法对于较大雨滴和较粗雨线的去除效果都不理想,对于较稀疏的雨线去除效果较好,但是细节信息容易被抑制掉.本文算法对于较大雨滴和较粗雨线的去除均取得了较好的去除效果,对于方向随机的雨滴和雨线、形状较精细的雨线均有较好的去除效果,同时较好地保护了图像中的细节以及纹理信息.本文算法相比其他算法具有较好的鲁棒性.

在相同的计算机硬件配置下,本文算法与对比算法在运行时间上进行了比较,针对分辨率为512×512图像,去雨运行时间比较结果如表3所示,本文算法相比大部分对比算法在运行时间上有优势,进一步验证了本文算法的网络结构节省了计算成本,提高了运行速度.



图7 合成雨图的去雨比较

表3 典型去雨算法的运行时间

算法	DSC	GMM	CNN	DNN
t/s	12.32	10.65	0.64	0.65
算法	RESCAN	DID-MDN	PRN	本文
t/s	0.61	0.5	0.13	0.14

5 结论

为实现面向不同真实雨场景的图像去雨,本文结合图像特征在频域中的特性,提出一种基于倍频卷积和注意力机制的图像去雨,结合雨场景中的空间特征

与频率特征来表示雨线和无雨场景的空-频域关系;通过倍频卷积实现图像从频率特征上的分离,进一步分解雨线与背景特征,降低低频空间分辨率,去除空间冗余特征;设计了融合多层通道注意力模块检测雨线,突出重要特征抑制背景特征,增强雨线和背景的区分度;构建序列去雨网络,有效去除不同成分的雨纹信息.实验表明,算法对不同方向、形状的雨纹和雨滴的去除性能有很大提升,同时对于背景图像的细节与边缘信息也具有较好的保护作用,但是对于密度较大的积累雨去除效果仍需进一步提高.

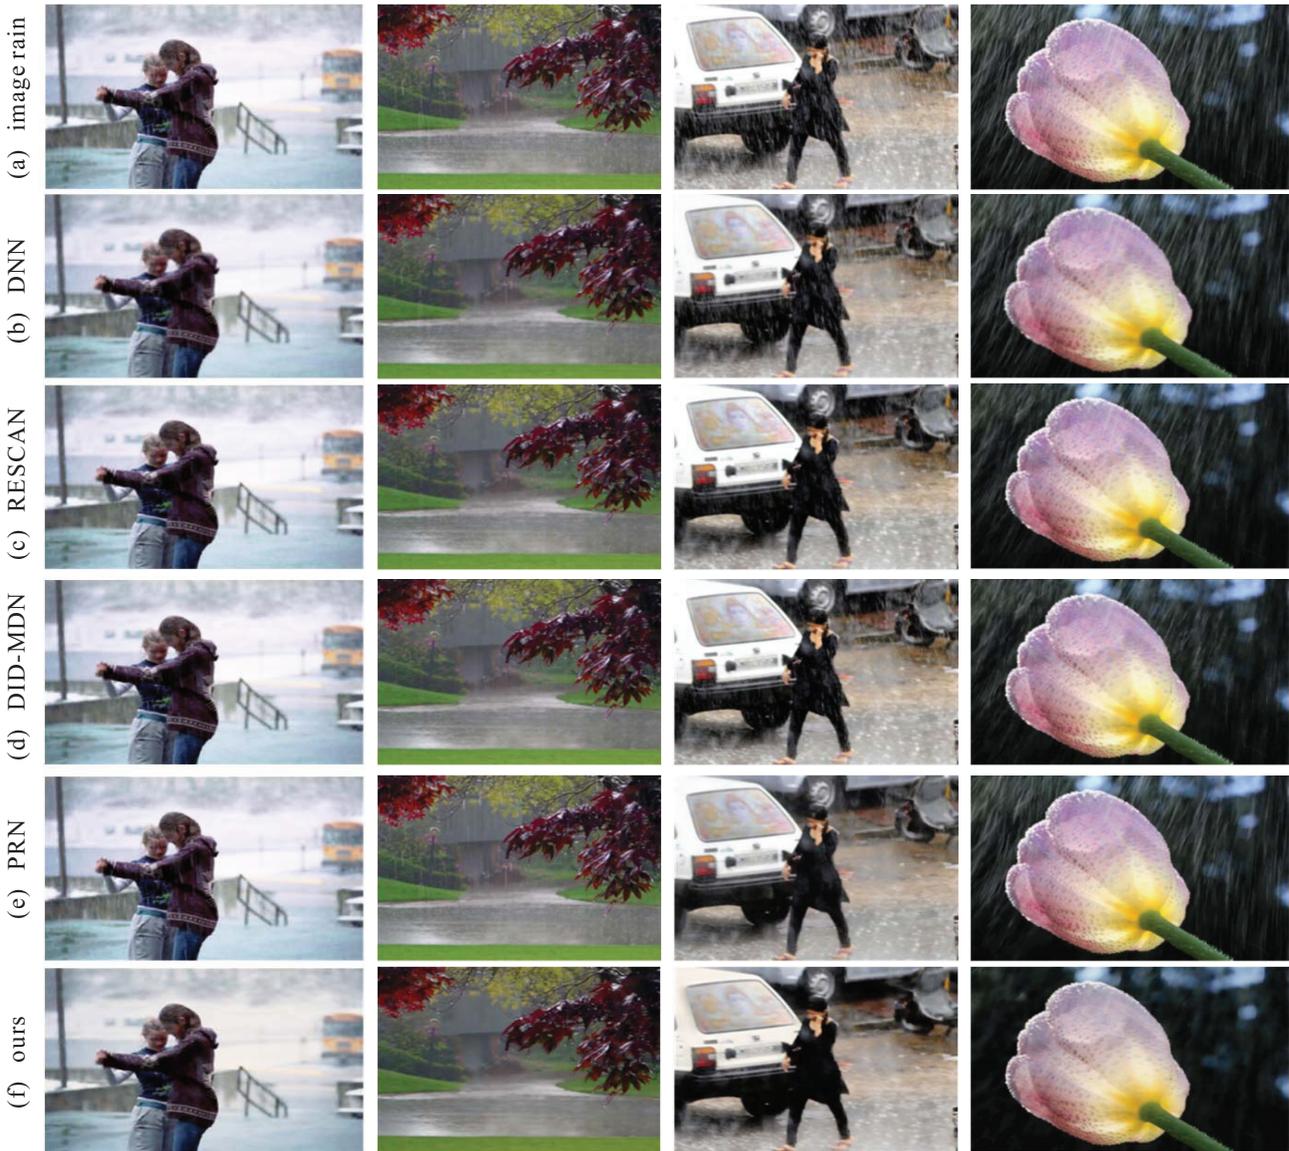


图8 真实雨图的去雨比较

参考文献(References)

- [1] Yang W H, Tan R T, Wang S Q, et al. Single image deraining: From model-based to data-driven and beyond[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2021, 43(11): 4059-4077.
- [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: A Publication of the IEEE Signal Processing Society*, 2012, 21(4): 1742-1755.
- [3] Luo Y, Xu Y, Ji H. Removing rain from a single image via discriminative sparse coding[C]. *2015 IEEE International Conference on Computer Vision*. Santiago, 2015: 3397-3405.
- [4] Li Y, Tan R T, Guo X J, et al. Rain streak removal using layer priors[C]. *2016 IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas, 2016: 2736-2744.
- [5] 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: A Publication of the IEEE Signal Processing Society*, 2017, 26(6): 2944-2956.
- [6] 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*. Honolulu, 2017: 1715-1723.
- [7] Pu J C, Chen X S, Zhang L, et al. Removing rain based on a cycle generative adversarial network[C]. *The 13th IEEE Conference on Industrial Electronics and Applications*. Wuhan, 2018: 621-626.
- [8] Jin X, Chen Z B, Lin J X, et al. Unsupervised single image deraining with self-supervised constraints[C]. *2019 IEEE International Conference on Image Processing*. Taipei, 2019: 2761-2765.

- [9] Li R T, Cheong L F, Tan R T. Heavy rain image restoration: Integrating physics model and conditional adversarial learning[C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach, 2019: 1633-1642.
- [10] Yang W H, Tan R T, Feng J S, et al. Deep joint rain detection and removal from a single image[J/OL]. 2016, arXiv: 1609.07769.
- [11] Fan Z W, Wu H F, Fu X Y, et al. Residual-guide network for single image deraining[C]. MM'18: Proceedings of the 26th ACM international conference on Multimedia. New York, 2018: 1751-1759.
- [12] Ren D W, Zuo W M, Hu Q H, et al. Progressive image deraining networks: A better and simpler baseline[C]. 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach, 2019: 3932-3941.
- [13] Fu X Y, Liang B R, Huang Y, et al. Lightweight pyramid networks for image deraining[J]. IEEE Transactions on Neural Networks and Learning Systems, 2020, 31(6): 1794-1807.
- [14] 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. Venice, 2017: 2545-2553.
- [15] Li X, Wu J L, Lin Z C, et al. Recurrent squeeze-and-excitation context aggregation net for single image deraining[C]. European Conference on Computer Vision. Munich, 2018: 254-269.
- [16] Li R T, Cheong L F, Tan R T. Single image deraining using scale-aware multi-stage recurrent network[J/OL]. 2017, arXiv: 1712.06830.
- [17] 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. Salt Lake City, 2018: 695-704.
- [18] Jiang K, Wang Z Y, Yi P, et al. Multi-scale progressive fusion network for single image deraining[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, 2020: 8343-8352.
- [19] Barnum P, Kanade T, Narasimhan S. Spatio-temporal frequency analysis for removing rain and snow from videos[C]. Proceedings of the First International Workshop on Photometric Analysis for Computer Vision. Rocquencourt, 2007: 1-8.
- [20] Garg K, Nayar S K. Detection and removal of rain from videos[C]. Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition. Washington, 2004: 8161434.
- [21] Zhen C, Jihong S. A new algorithm of rain (snow) removal in video[J]. Journal of Multimedia, 2013, 8(2): 168-174.
- [22] Chen Y P, Fan H Q, Xu B, et al. Drop an octave: Reducing spatial redundancy in convolutional neural networks with octave convolution[C]. 2019 IEEE/CVF International Conference on Computer Vision (ICCV). Seoul, 2019: 3434-3443.
- [23] 于明, 李学博, 郭迎春. 融合注意力机制的域泛化行人再识别[J]. 控制与决策, 2022, 37(7): 1721-1728. (Yu M, Li X B, Guo Y C. Domain generalization person re-identification based on attention mechanism[J]. Control and Decision, 2022, 37(7): 1721-1728.)
- [24] Hu J, Shen L, Sun G. Squeeze-and-excitation networks[C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, 2018: 7132-7141.
- [25] Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]. Proceedings of the 32nd International Conference on International Conference on Machine Learning. Lille, 2015: 448-456.
- [26] Li S Y, Ren W Q, Wang F, et al. A comprehensive benchmark analysis of single image deraining: Current challenges and future perspectives[J]. International Journal of Computer Vision, 2021, 129(4): 1301-1322.

作者简介

杨青(1983—), 女, 讲师, 硕士, 从事数字图像处理与模式识别、计算机视觉等研究, E-mail: yqzd626@163.com;

于明(1964—), 男, 教授, 博士, 从事计算机视觉、人工智能等研究, E-mail: yuming@hebut.edu.cn;

付强(1981—), 男, 讲师, 博士, 从事计算机视觉、目标识别与跟踪等研究, E-mail: 499633087@qq.com;

阎刚(1977—), 男, 副教授, 博士, 从事图像处理与模式识别等研究, E-mail: yangang@hebut.edu.cn.