



多阶段渐进处理的图像去雨方法

廉继红,王平,李英,李云红

(西安工程大学 电子信息学院,陕西 西安 710048)

摘要 针对现有图像去雨方法中存在雨纹去除不彻底、纹理信息丢失等问题,提出一种多阶段渐进式处理的图像去雨算法,可以同时将上下阶段的特征融合,使去雨算法的性能有很大的提高。该去雨网络模型由3个阶段构成。前2个阶段采用改进后的U-Net编码器解码器结构学习多尺度上下文特征信息,特征提取部分采用有效通道注意力机制(efficient channel attention network, ECANet),使网络模型参数变小,更加轻量级;第3阶段加入并行注意力机制(parallel attention subnetwork, PASNet),在学习上下文信息和空间细节特征的同时还能生成高分辨率特征,更好地保留图像的输出细节。此外,还引入监督注意力模块(supervised attention module, SAM)以加强特征学习。实验结果表明,在数据集Rain100H上PSNR达到29.37 dB,SSIM为0.88;在Test1200上PSNR达到32.50 dB,SSIM为0.93,验证了所提方法在图像去雨任务上的有效性。

关键词 图像去雨;特征提取;监督注意力;并行注意力机制;空间细节

中图分类号:TP391.4 DOI:10.16152/j.cnki.xdxbr.2025-02-007

The image rain removal method based on multi-stage progressive processing

LIAN Jihong, WANG Ping, LI Ying, LI Yunhong

(School of Electronics and Information, Xi'an Polytechnic University, Xi'an 710048, China)

Abstract Aiming at the problems of incomplete rain pattern removal and texture information loss in the existing image rain removal methods, this paper proposes a multi-stage progressive image rain removal algorithm, which can simultaneously fuse the features of the upper and lower stages and greatly improve the performance of the rain removal algorithm. The rain removal network model consists of three stages. In the first two stages, the improved U-Net coder-decoder structure is used to learn multi-scale context information, and the efficient channel attention network (ECANet) is used for feature extraction, which can reduce the parameters of the network model. In the third stage of becoming lighter, parallel attention subnet (PASNet) is added, which can generate high-resolution features while learning contextual information and spatial details, and can better preserve the output details of images. At the same time, supervised attention module (SAM) is introduced to strengthen feature learning. The experimental results show that the PSNR is 29.37 dB and SSIM is 0.88 on the data set Rain100H; The PSNR is 32.50 dB and SSIM is 0.93 on Test1200, which verifies the effective-

收稿日期:2024-10-25

基金项目:陕西省科技计划项目(2022GY-053);陕西省自然科学基金基础研究重点项目(2022JZ-35)。

第一作者:廉继红,男,副教授,从事工业信号信息处理、计算机控制系统研究,lianjihong@163.com。

ness of the proposed method in the task of image rain removal.

Keywords image deraining; feature extraction; supervise attention; parallel attention mechanism; spatial details

雨天是我们日常生活中常见的天气现象,交通监控、人物识别和跟踪等其他计算机视觉应用系统都需要在这种天气中运行。由于雨线的阻碍,雨天拍摄的图像往往模糊不清,丢失了背景信息,导致无法完成预期目标。大多实际问题中,我们需要有清晰、质量高的图像来处理与分析后续的工作^[1]。作为目前计算机视觉研究领域的重点之一^[2],单幅图像去雨技术的研究和应用对目标检测^[3-4]、目标追踪^[5-6]等具有重要意义。

目前常用的雨图像去除方法主要使用深度学习技术^[7-9],基于深度学习的方法包括卷积神经网络(CNN)^[10]、残差网络(ResNet)、注意力机制(attention)^[11]、生成对抗网络(GAN)^[12]、循环神经网络(RNN)等。基于深度学习的去雨技术通常依赖于大量的图像数据进行训练,以构建有效的去雨模型,从而达到良好的去雨效果。一些研究提出了逐步去雨网络结构^[13],采用残差网络实现图像的雨纹去除任务,并在网络的不同阶段使用长短时记忆模块进行递归连接。尽管可以实现逐步去雨,但由于降雨的多尺度特性,这种方法无法完全去除不同尺度下的雨纹痕迹。另外一些研究提出了多尺度逐步融合去雨网络^[14],通过金字塔结构消除多尺度的雨纹痕迹,但生成的图像背景会变得模糊。随着网络层数的增加,尤其是在图像处理和去雨算法的应用中,计算工作量呈现逐渐增多的趋势。为解决这一难题,学者们推崇轻量级图像去雨网络^[15]的构建,通过借助高斯拉普拉斯金字塔技术实现了轻量级图像雨纹剔除。然而,随着网络深度的减少,去雨效果也明显下降。文献[16]通过缩小输入图像和输出图像之间的映射范围,加入深度置信网络,并利用图像处理中先验知识完成雨水去除任务。尽管这种方法可以有效去除雨图像中大部分雨水痕迹,但同时也会造成图像局部背景细节损失的现象。文献[17]采用一种新颖简洁的循环网络,逐步消除图像中积聚的雨水条纹。文献[18]提出的去雨网络是基于一种多阶段协同处理的图像去雨网络,

该网络利用递归计算的方式完成多阶段协同处理的去雨任务,取得了良好效果。然而,该方法处理完的图像仍然存在雨纹去除不够彻底、图像背景区域模糊的问题。

为了解决上述去雨方法中所面临的问题,本文提出一种多阶段逐步处理的去雨网络算法,网络架构基于 MPRNet 去雨算法进行设计与优化。该网络模型由 3 个阶段逐步完成去雨任务,最初 2 个阶段采用改进后的 U-Net 作为编码器解码器网络,由于编码器结构感受野比较大,可以更全面学习到图像的前后背景信息。在特征提取部分使用 ECANet 网络,使网络模型参数变小,更加轻量级。在网络第 3 阶段引入 PASNet,该模块关注图像的雨纹特性和图像的颜色信息,并且能保留图像的更多输出细节,从而生成高质量的图像。由于在编码器解码器中重复使用上采样和下采样操作,引入 CSFF 模块使网络不易受到信息丢失的影响,并且网络优化过程简化了信息流,从而使整体网络变得更加稳定。通过与 7 种经典的图像去雨方法进行对比实验,验证了本文网络在图像去雨任务上的准确性和有效性。

1 网络模型设计

本文提出的图像去雨网络模型由 3 个阶段构成,图 1 为改进后的 MPRNet 网络总框架图。在该网络每 2 个阶段之间用一个监督注意力模块进行操作,使参考图像的监督效果得到增强。每阶段网络的第 1 部分是相同的,都是先经过卷积层,然后再到 ECANet 模块提取输入图像的初始特征,接着通过改进的 U-Net 编码器解码器提取图像细节特征,再由 SAM 得到该阶段的输出图像。第 3 阶段则采用并行注意力网进行操作,使得最终的输出图像能更好地保留所需的空间细节。本文网络模型第 1 阶段和第 2 阶段的输入信息分别为 4 个图像块和 2 个图像块的特征信息,第 3 阶段输入信息则是原图像。

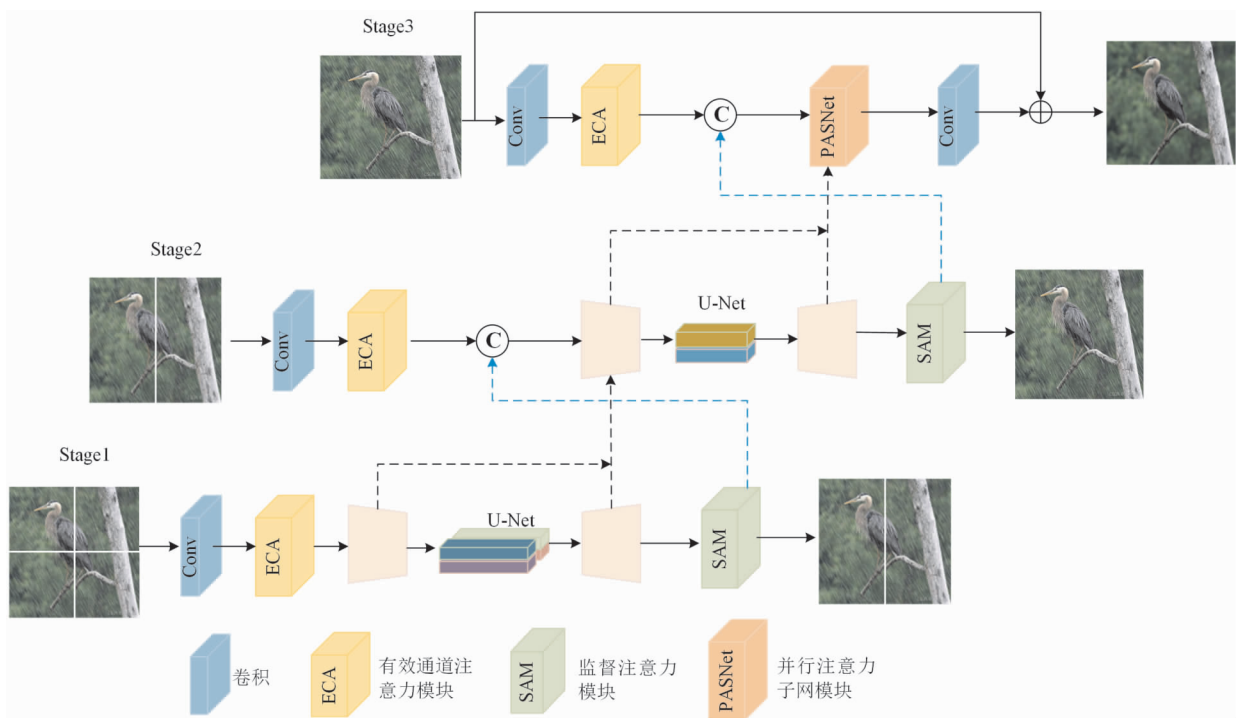


图 1 改进后的 MPRNet 总框架图

Fig. 1 Schematic diagram of the improved MPRNet architecture

1.1 有效通道注意力模块

ECANet 对 SENet 进行了改进,文献[19]对比了这 2 种注意力机制方法,ECANet 通过低模型复杂度实现更优越的性能表现,同时能够减小网络模型的参数规模,从而明显提升特征提取的效果。图 2 为有效通道注意力模块的网络结构, W 、 H 、 C 分别表示特征映射的宽度、高度、通道数;加权特征为 \tilde{U} ,GAP 为全局平均池化运算; K 不仅为部分跨信道之间交互的频率,其卷积核大小也用 K 表示。




图 2 ECANet 结构

Fig. 2 Structure of ECANet

对于输入特征 $U \in \mathbf{R}^{W \times H \times C}$,每个通道空间对应的信息是由 ECANet 模块经过全局平均池化操作来聚集。平均池化计算公式如下,

$$P_{GA}(U) = \frac{1}{W \times H} \sum_{i=1}^W \sum_{j=1}^H U_{i,j} \quad (1)$$

$P_{GA}(U)$ 经过 K 大小的卷积核进行一维卷积操作,使得部分 K 个大小的信息特征关系能被快

速提取。一维卷积通过 Sigmoid 函数计算得到其激活值,由此获得通道特征的 $\omega \in \mathbf{R}^{1 \times 1 \times C}$ 权重值以及部分特征表示关系。

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

$$\omega = \text{Sigmoid}\{C1D_K[P_{GA}(U)]\} \quad (3)$$

式中:C1D 表示一维卷积操作; K 表示卷积核大小。

为了重新进行编码每个 U 中的通道特征信息,将 ω 与 U 进行逐一相乘操作,获得加权特征。赋予有用的特征较大的权值有助于实现增强的效果,赋予不需要的特征较小的权值以利于实现抑制的作用。

1.2 编码解码模块

本文使用经过改进的 U-Net^[20] 网络作为本文编码解码器结构。图 3 展示了在传统 U-Net 网络结构中引入了通道注意力模块,上述模块的作用是从各种尺度中提取特征,并通过通道块关注处理 U-Net 的跳跃连接位置的特征图。相较于普通卷积层,通道块能更有效地关注关键特征信息,显著提升模型的特征提取能力。为了增强解码器特性的空间分辨率,在第 3 步骤中引入双线性上采样,并结合卷积操作,避免使用转置卷积,因为转置卷积操作可能导致输出图像中出现不必要的棋盘状伪影问题。




图 3 U-Net 编码器解码器子网
Fig. 3 U-Net of encoder and decoder

1.3 并行注意力子网模块

本文网络最后阶段引入 PASNet 模块,可以更好保留图像输出时的细节信息,该模块生成的高分辨率特征包含丰富的空间细节,却不需要降采样操作。该模块是多个混合注意力模块(hybrid attention module, HAM)进行串联组成,每个 HAM 模块由 8 个并行注意力模块(parallel attention module, PAM)连接而成,HAM 模块结构如图 4 所示。




图 4 混合注意力模块
Fig. 4 Hybrid attention module

1.3.1 像素注意力块

像素注意力(pixel attention, PA)更关注图像中物体的边缘和纹理,能更好关注像素特征,因此加入像素注意力可以提高去雨后图像的细节恢复性能。如图 5 所示, C 为输出特性的通道数,定义为 64 个。在 PA 模块中,经过 2 层卷积运算学习各像素特征后,会将特征维度由 $C \times H \times W$ 调整为 $1 \times H \times W$ 。将 PA 的输入注意力特征与生成的注意力特征逐像素相乘,为该模块最后的输出。




图 5 像素注意力模块
Fig. 5 Pixel attention module

1.3.2 通道注意力块

通道注意力(channel attention, CA)不仅能够有效地捕捉各通道之间的依赖关系,并能利用独特的位置信息编码增强模型对空间细节的敏感性,做到平衡雨纹信息,实现更精准的视觉识别和分析。如图 6 所示,模块在通过全局平均池化操作后,会将特征信息转变为信道纳入,特征维度的大小将从 $C \times H \times W$ 调整为 $C \times 1 \times 1$;接着,通过 2 个卷积操作学习相应的权值信息;然后,将前面

学习得到的权重值与 CA 输入初始的特征相乘,作为该模块最后的输出。




图 6 通道注意模块
Fig. 6 Channel attention module

PAM 模块的优势是在关注图像雨纹特征的同时,还可以关注图像的颜色特征。如图 7 所示,PAM 模块是由像素注意力块和通道注意力块以并联的方式连接组成。该模块首先通过降采样操作提取简单特征;然后通过 PA 和 CA 并行模块同时学习这些特征信息;随后将学习到的特征相加。为了图像雨纹特征和颜色信息之间的平衡,加入一个卷积层可以很好地解决这个问题。模块最后加入局部残差连接,可以更加关注实际信息。




图 7 并行注意模块
Fig. 7 Parallel attention module

1.4 监督注意力模块

监督注意力模块结构如图 8 所示。 $F_{in} \in \mathbf{R}^{H \times W \times C}$ 为上一阶段的输出特征,经过 SAM 中的 1×1 卷积运算,可以从 SAM 模型中获得残差图像,其中,空间维度用 H 和 W 表示,通道数用 C 表示。去雨图像是残差图像与原始输入图像之和 $X_s \in \mathbf{R}^{H \times W \times 3}$ 。针对已知的 X_s 图像预测,该模块使用预定义的非雨天标签进行监督,接着经过 Sigmoid 函数和 1×1 卷积的处理,生成 X_s 图像并创建逐像素的注意掩码。随后,局部特征 F_{in} 经过这些掩码对其进行重新调整转换,由此生成的特征是经注意力所引导的,SAM 模块最后得到的注意力增强特征 F_{out} 将会传递给下一阶段进行操作处理。




图 8 监督注意力模块
Fig. 8 Supervised attention module

1.5 损失函数

构建出一个良好的算法模型并不只是需要设计出合适的网络架构以及相应的网络模块,选择合适的训练方式和相应的损失函数约束是尤为重要的。在进行网络训练的过程中,不仅要考虑到图像模糊或者过度平滑的视觉现象,还得考虑到可能会存在部分高频纹理信息损失的问题。

为了更好地逼近真实雨线分布 I_{derain} , 在 Charbonnier 惩罚函数指导下,我们采取逐步接近的方法,这种函数具有更强的容错性和训练的收敛性,表达式为

$$L_{\text{char}} = \sqrt{(I_{\text{derain}} - I_{\text{rain}})^2 + \varepsilon^2} \quad (4)$$

式中: L_{char} 为 Charbonnier 损失函数; I_{derain} 为无雨图像(对去雨操作后的预测); I_{rain} 为真实图像中雨纹理分布; ε 为惩罚系数,其值设置为 0.001。

为了在去除雨纹的同时更好保留高频细节信息,本文还采用文献[21]提出的边缘损失来约束参考图像(ground truth image) I_{clean} 和预测的无雨图像 I_{derain} 之间的高频分量。本文的边缘损失定义为

$$L_{\text{edge}} = \sqrt{(\text{Lap}(I_{\text{clean}}) - \text{Lap}(I_{\text{derain}}))^2 + \varepsilon^2} \quad (5)$$

式中: $\text{Lap}(I_{\text{clean}})$ 为经过拉普拉斯算子计算后,从 I_{clean} 中提取出的边缘图;同理, $\text{Lap}(I_{\text{derain}})$ 是经过拉普拉斯算子后,从 I_{derain} 中提取出的边缘图。

本文将边缘损失函数 L_{edge} 与 Charbonnier 损失函数 L_{char} 的和作为本文所使用的总损失函数 L ,表达式为

$$L = L_{\text{char}} + \lambda L_{\text{edge}} \quad (6)$$

式中: λ 为权重的参数,根据经验将 λ 设置为 0.05,能更好地平衡每个损失项。

2 实验结果及分析

2.1 实验设置

本文具体实验平台为 3090Ti GPU * 1,所需搭建环境: CUDA 11.3、CUDNN 8.2、Pytorch 1.11.0,数据集图像尺寸裁剪为 256×256 ,在编码器解码器的每个尺度上使用了 2 个 CAB,下采样用大小为 2×2 的最大池化操作,步长为 2。在最后阶段,使用了 PASNet,其中包含 3 个 HAM,每个 HAM 进一步使用 8 个 PAM。在网络训练过程中,使用 Adam 优化器进行优化,整体实验初始

学习率设置为 2×10^{-4} ,使用余弦退火策略,逐步降低到 1×10^{-6} 。批量处理尺寸(batchsize)设置为 16,训练周期(epoch)为 250。另外,在训练过程中随机利用水平翻转和垂直翻转增强训练数据集。

2.2 数据集

现有去雨算法都没有统一的训练集,所以在训练阶段采用 MSPFN^[22] 中的 13 712 对合成雨图像作为本文训练集。选用 Rain100H^[17]、Test1200^[23] 合成数据集作为本文测试集。Rain100H 数据集中的雨图雨线密集并且包含的雨纹形状最多,雨纹去除是难度最大的,被视为图像去雨问题中最具代表性和挑战性的数据集,所以这种情况更能检验图像去雨算法的性能。Test1200 数据集中包含来自不同方向和不同密度大小的雨纹,其共有 1 498 对测试图像。为了验证本文去雨网络在真实雨图上同样具有出色的去雨效果,选用真实雨图 RealRain300 数据集进行实验。RealRain300 包含 300 张真实雨图像,涵盖了多种现实场景,以及不同形状和大小密度的雨纹。由于是真实雨图数据集,所以没有与其对应的无雨图像。

2.3 评价指标

本文采用峰值信噪比(peak signal to noise ratio, PSNR)和结构相似度(structural similarity index measure, SSIM)衡量去雨后图像的质量,作为去雨后图像的评价指标。

2.3.1 峰值信噪比

峰值信噪比(PSNR)是描述信号最大可能能量和噪声之间关系的指标,通常以分贝(dB)为单位计量,数值范围为 20~40 dB。PSNR 值高于 40 dB 说明去雨后图像非常接近原始图像,去雨效果极好;在 30~40 dB 通常表示去雨图像失真可以察觉,去雨效果相对较好;在 20~30 dB 说明去雨图像有一定失真,去雨效果一般;PSNR 低于 20 dB,去图像严重失真不可接受,去雨图像效果最差。

计算 PSNR 时,首要步骤是计算均方误差(mean square error, MSE),即求取 2 幅图像每个像素值之间的差的平方,然后再对这些平方差值求平均。计算公式如下,

$$\text{MSE} = \frac{1}{MN} \sum_{i=1}^M \sum_{j=1}^N |X(i,j) - Y(i,j)|^2 \quad (7)$$

式中: M 、 N 为雨图像对中有雨图像的高和无雨图像的宽; $X(i,j)$ 、 $Y(i,j)$ 为雨图像的像素值。PSNR 的计算公式如下,

$$PSNR = 10 \times \lg \frac{MAX_1^2}{MSE} \quad (8)$$

式中:MAX₁ 为图像点中像素最大的值,一般地,大多时候用相机采集到的图像中每个像素单通道数值的大小表示用 8 位数据,因此公式中 MAX₁ 的值为 255。

2.3.2 结构相似度

2 幅图像之间存在的相似性即为结构相似度。图像的亮度、对比度和结构 3 方面是 SSIM 评估 2 幅图像之间相似度的指标。

SSIM 能考虑到特征信息,这些特征信息是来自图像的结构邻域,计算公式如下,

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2)} \quad (9)$$

式中: x 为原图像中提取出的像素值; y 则是在去雨后的图像中提取出的像素值; μ_x, μ_y 分别表示 x, y 的平均值; σ_x^2, σ_y^2 分别表示 x, y 的方差; $\sigma_{x,y}$ 为变量 x 和 y 之间的协方差。为了避免公式中出现分母为 0 的情况,在公式中引入常数 c_1 和 c_2 。 $c_1 = (K_1 \times L)^2, c_2 = (K_2 \times L)^2, K_1, K_2$ 的值分别为 0.01、0.03。像素值范围 L 一般取值为 255。结构相

似度 SSIM 的范围为[0,1],SSIM 值越接近 1 时,表示处理后的图像相比原始图像更不失真。

2.4 实验结果分析

2.4.1 定量结果与分析

为了证明本文提出的算法有较好的性能,实验选取了 7 种基于深度学习的单幅图像去雨算法: UMRL^[24]、 DIDMDN^[9]、 RESCAN^[25]、 PReNet^[17]、 MSPFN^[22]、 Uformer-B^[26] 和 MPRNet^[27],用定性和定量的实验结果进行对比,分别在合成数据集 Rain100H、Test1200 上进行对比实验,随后在真实雨图 RealRain300 数据集上观察分析去雨效果。本文研究的训练和测试都使用相同的数据集,以确保实验对比的公正性。

表 1 为对比实验的实验结果,本文算法在合成数据集 Rain100H 上 PSNR 值为 29.37 dB,SSIM 为 0.875;在合成数据集 Test1200 上 PSNR 值为 32.95 dB,SSIM 为 0.930。PSNR 平均值比对比算法中最优的 MPRNet 模型提高了 0.23 dB,SSIM 平均值比对比算法中最优的 Uformer-B 模型提高了 0.002,充分验证了本文提出的模型在去雨任务中具有有良好的性能。

表 1 本文方法与其他方法的对比实验

Tab. 1 Comparison experiment between the proposed method and other methods

Method	Rain100H		Test1200		Average	
	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM
UMRL ^[24]	17.35	0.524	28.13	0.905	22.27	0.715
DIDMDN ^[10]	26.01	0.732	27.99	0.867	23.55	0.799
RESCAN ^[25]	27.43	0.786	31.29	0.904	28.82	0.845
PReNet ^[18]	28.06	0.884	31.75	0.913	29.91	0.898
MSPFN ^[22]	27.67	0.798	32.82	0.927	30.25	0.892
Uformer-B ^[26]	30.31	0.900	29.45	0.903	29.88	0.901
MPRNet ^[27]	29.33	0.878	32.52	0.909	30.93	0.894
Ours	29.37	0.875	32.95	0.930	31.16	0.903

在 Rain100H 数据集上,经本文算法所得 PSNR 值相比对比算法中最优模型 Uformer-B 相差 0.94 dB,SSIM 值相差 0.025;在 Test1200 数据集上,经本文算法所得 PSNR 值均达到最优值,比对比实验中最优模型 MSPFN 算法高出 0.13 dB,比 SSIM 高出 0.003。说明本文算法在雨纹形状复杂、雨线密集的情况下,图像去雨任务仍然能有良好的表现。

为了全面验证本文所提算法在性能上的提升,将其与原始的 MPRNet 网络模型进行对比。该对比主要评估了网络参数量和训练时间 2 个关

键方面,测试数据集使用 Rain100H 和 Test1200。Original 代表原始的 3 阶段 MPRNet 算法,而 Stage1、Stage1&2 和 FullECA 则表示在 3 个阶段中依次加入 ECANet 模块的网络模型。其中,Stage1 指的是仅在第 1 个阶段加入 ECANet 模块的网络,Stage1&2 表示在第 1 个和第 2 个阶段都加入了 ECANet 模块,而 FullECA 则是在 3 个阶段的网络中都加入了 ECANet 后的网络模型。

算法性能对比实验如表 2 所示,Parameters 为在原网络模型和各阶段依次加入 ECANet 后,参数量的对比结果。可以清楚地观察到随着 3 个阶

段依次加入 ECANet 模块,网络整体的参数量逐渐减少,原始网络的参数量值最大,当3个阶段都

加入 ECANet 网络时,参数量值达到最低。

表2 算法性能实验对比

Tab.2 Experimental comparison of algorithm performance

Method	Backbone Models	Parameters/ 10^6	Training Speed/(h · Epoch ⁻¹)
Original	MPRNet	50	2.5
ECA Stage 1	MPRNet	48	2.3
ECA Stage 1&2	MPRNet	45	2.2
Full ECA	MPRNet	40	2.0

Training Speed 为在原网络模型和各阶段依次加入 ECANet 后,训练速度的对比结果。可以清楚地观察到随着3个阶段依次加入 ECANet 模块,网络每轮训练所花费的时间逐渐减少,说明训练速度在逐渐提升。原始网络的训练时间最长,速度最慢,当3个阶段都加入 ECANet 网络时,训练时间值最低,速度达到最快。

在原网络模型加入 ECANet 模块后,有效降低了网络的参数量,使得整体网络框架更加轻量化。且由表1对比实验的结果可知,本文方法在数据集 Rain100H 和 Test1200 上取得较高的 PSNR 和 SSIM 值,更加充分验证本文所提方法的可行性。

2.4.2 定性结果与分析

图9展示了在合成数据集 Rain100H 上不同算法的处理结果。UMRL 算法在处理雨纹密集的有雨图像时,去除雨水的效果有限,导致大量雨纹仍然存在,去雨效果不佳;相比之下,尽管 DID-

MDN 和 RESCAN 算法可以有效减少雨纹数量,但仍然有大量雨纹存在,去雨效果一般;PReNet 算法整体去雨效果较好,但在图像中的标记广告牌区域图像模糊度较高;MSPFN 算法虽能够消除大部分雨纹,但同样在图像中标记的广告牌以及车身数字区域仍存在模糊的问题,对细节的恢复效果较差;Uformer-B 算法有效去除了雨纹,但是图像标记区域的字母以及数字的背景信息仍没得到有效的恢复;MPRNet 算法处理完的图像仍有少数雨纹残留,并且标记区域背景信息也很模糊;经本文的方法处理后,消除雨纹的效果更加完善,同时还能够保留大部分原图的结构和纹理特征,标记区域车身数字背景信息得到较好的恢复,处理后的图像更加接近原始无雨图像。因此,在数据集 Rain100H 上,本文方法不仅在能有效去除复杂雨图所包含的各种形状雨纹的同时,还能更好地保留原图像的色彩信息和细节纹理特征,表明本文算法在除去大雨的能力上表现优异。



图9 Rain100H 数据集上结果实例

Fig.9 Example of results on Rain100H dataset

图 10 展示了在合成数据集 Test1200 上不同算法的处理结果。UMRL 算法生成的无雨图像中仍存在残留的大量雨纹,去雨能力一般;DIDMDN 算法仍有大量雨纹残留,同时生成的图像整体色调过亮;RESCAN 算法处理完雨图中雨纹时,有少量雨纹残留,且图像背景标记区域出现模糊问题;PReNet 算法去雨整体效果较好,但处理完的图像标记区域同样出现了较轻的伪影以及模糊问题;MSPFN 算法在整体上去除了大部分雨水痕迹,但图像对比度有所增强,使得图像视觉效果呈现泛

白现象,从而导致生成的图像质量下降;Uformer-B 算法有效去除了雨纹,但是在去雨后的背景区域能看到明显的白影,图像背景信息没有得到很好的恢复;MPRNet 算法整体去雨效果较好,但处理完的图像丢失了部分细节信息,如图像标记区域的飞机机翼部分。相比在合成数据集 Test1200 中,本文所提算法不仅有效地去除了雨水痕迹,还更好地保留了图像中的边缘纹理以及细节信息。与未处理的雨图相比,本文算法处理后的结果更接近原图像。

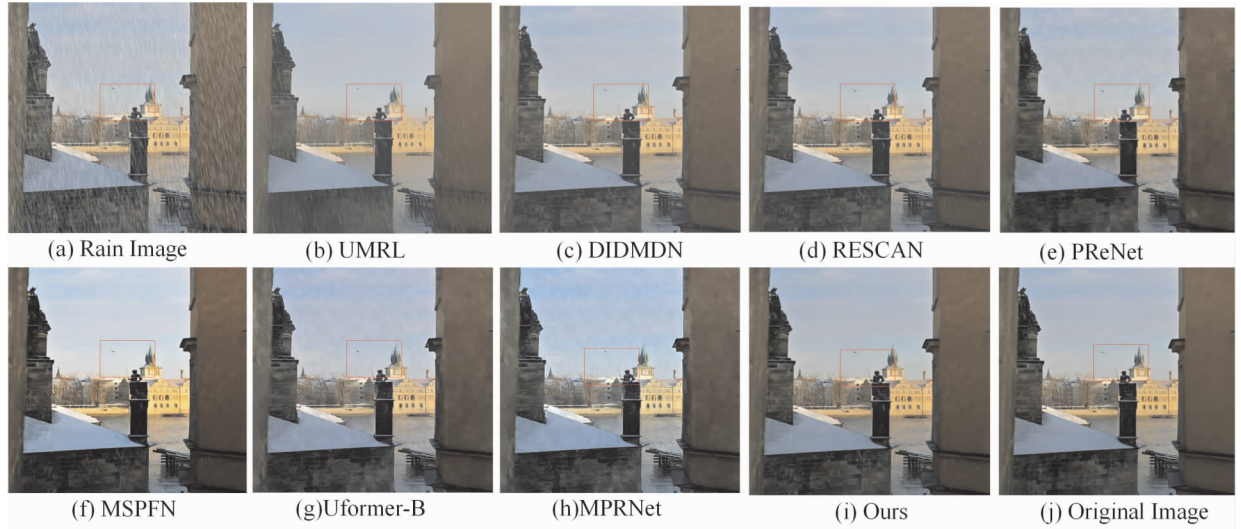


图 10 Test1200 数据集上结果实例

Fig. 10 Example of results on Test1200 dataset

图 11 展示了不同算法在真实雨图 Real-Rain300 数据集上的处理结果。因为拍摄的真实雨图没有与之相对应的无雨图,所以只能对去雨后的无雨图进行视觉观测,通过主观观测分析真实雨图下的对比实验结果。UMRL 和 DIDMDN 算法虽去除了部分雨线,但在 3 幅示例图像标记区域仍存在较多细小的雨线;RESCAN 算法在 3 幅示例图像中同样未能有效去除雨纹,存在少部分雨纹,并且从第 2 幅标记区域看出纹理细节没有很好地恢复;MSPFN 和 PReNet 算法去雨效果相对较好,纹理细节相对有好的恢复,但第 3 幅示例图像左边密集雨线区域雨水残留太多,部分区域产生些许模糊,导致整体质量偏差,视觉效果欠佳;Uformer-B 和 MPRNet 算法处理完的图像,相比前面 5 种算法的去雨能力有很大的提升,但在标记区域仍有背景模糊和雨纹残留的问题。经本

文算法处理过的图像不仅能有效消除密集的雨线,还能很好地保留输出图像的细节信息,说明本文所提算法可以更有效地处理真实环境中的雨纹,图像细节处理效果更出色。

2.5 消融实验

为了更深入地评估本文算法的可靠性以及 ECANet 和 PASNet 模块作为模型组成部分的重要性,进行了消融实验。在模型消融实验中,从 MSPFN 中选取 13 712 组无雨/有雨图像作为训练数据集。而用于测试的数据集为 Rain100H,因为该数据集中包含了不同方向的雨纹、各种形状和大小的密集雨纹,能够展示本研究算法在处理复杂雨线图像时的出色表现和有效性。同时,仍采用 PSNR 和 SSIM 这 2 个指标对去雨结果进行对比分析。



图 11 真实雨图上结果实例

Fig. 11 Example of results on real rain map

2.5.1 定量结果与分析

为了展示 ECANet 和 PASNet 这 2 个关键模块的作用,研究建立了 4 种网络模型,在同一数据

集进行实验,验证本文方法具有合理性和有效性。4 个网络分别为 L1、L2、L3 和 L4,其中 L1 为 MPRNet 去雨网络,L2、L3 为分别使用 ECANet 和

PASNet 模块后的网络,L4 是本文算法网络。表 3 为 4 个网络模型通过消融实验在数据集 Rain100H 上的测试结果。

表 3 本文方法的消融实验

Tab. 3 Ablation experiment of this method

网络	ECANet	PASNet	PSNR/dB	SSIM
L1			29.14	0.863
L2	✓		29.19	0.867
L3		✓	29.16	0.865
L4	✓	✓	29.37	0.875

由表 3 可以看出,相较于 L1 网络,L2 网络加入 ECANet 模块使得网络整体的 PSNR 和 SSIM 值分别提高了 0.05 dB 和 0.04; L3 网络加入 PASNet 模块后,网络整体的 PSNR 和 SSIM 值分别提高了 0.02 dB 和 0.02;然而,只有当这 2 模块均存在时,也就是 L4 网络模型,该网络的 PSNR

和 SSIM 表现达到最佳,分别提高了 0.23 dB 和 0.12。充分说明了本文所提网络模块组合的合理性和有效性。

2.5.2 定性结果与分析

图 12 展示了 4 个网络在 Rain100H 数据集上的处理结果实例图。从图中用红色框标记的区域可以看出,经 L1 网络处理完的图像,在雨纹去除后的区域有背景模糊的问题;L2 网络处理完的图像虽能明显去除掉绝大部分雨纹,但去除雨纹后的图像背景区域恢复较差;L3 网络处理完的图像在标记区域有白影,但在图像色彩和动物身体边缘信息恢复较好;本文提出的 L4 网络去除雨纹效果都更接近原始干净图像,几乎没有雨纹残留,图像细节和纹理信息保留比较完整。再次验证了本文网络模块组合的有效性,展现出本文网络在图像去雨任务上具有较出色的效果。




图 12 消融实验结果实例图

Fig. 12 Example of ablation experiment results

3 结语

本文提出的图像去雨模型采取分阶段逐步处理的策略,融合经过优化的 U-Net 编码解码网络

和并行注意力网络 PASNet。模型不仅能学习到图像空间细节,还可以学习上下文特征信息,并生成高分辨率的特征。特征提取部分使用 ECANet,以更低的模型复杂度获得了更好的性能,模型参数变小,更加轻量级,速度得到很好提升。为使模

型的效果整体提升,在每2个网络阶段之间加入SAM模块。本文提出的网络模型在处理雨纹的同时,也考虑到本身图像质量的优化,以此确保去雨纹后的图像不会丢失重要细节信息。实验结果显示,在Rain100H和Test1200数据集上均达到了高PSNR和SSIM值,在真实的雨天图像处理中也取得了优异的效果。本文所提的去雨算法不仅有效去除了雨纹,还成功保留和恢复了图像的细节纹理信息,泛化性能较好。采用多阶段渐进的去雨网络结构就会导致整体模型规格较大,因此如何在网络模型更轻量化的同时保持去雨效果的稳定是接下来的主要研究方向。

参考文献

- [1] 彭进业,余喆,屈书毅,等. 基于深度学习的图像修复方法研究综述[J]. 西北大学学报(自然科学版), 2023, 53(6): 943-963.
PENG J Y, YU Z, QU S Y, et al. A review of image restoration methods based on deep learning[J]. Journal of Northwest University (Natural Science Edition), 2023, 53(6): 943-963.
- [2] 陈舒曼,陈玮,尹钟. 单幅图像去雨算法研究现状及展望[J]. 计算机应用研究, 2022, 39(1): 9-17.
CHEN S M, CHEN W, YIN Z, Research status and prospect of single image rain removal algorithm [J]. Application Research of Computers, 2022, 39(1): 9-17.
- [3] SUN P Z, ZHANG R F, JIANG Y, et al. Sparse RCNN: End-to-end object detection with learnable proposals[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, TN: IEEE, 2021: 14449-14458.
- [4] CARION N, MASSA F, SYNNAEVE G, et al. End-to-end object detection with transformers[M]//Computer Vision-ECCV 2020. Cham: Springer International Publishing, 2020: 213-229.
- [5] FU Zhihong, FU Zehua, LIU Q J, et al. SparseTT: Visual tracking with sparse transformers [EB/OL]. (2022-05-08) [2024-09-20]. <https://arxiv.org/abs/2205.03776>.
- [6] SONG Z K, YU J Q, CHEN Y P, et al. Transformer tracking with cyclic shifting window attention[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans, LA: IEEE, 2022: 8781-8790.
- [7] YAN W D, TAN R T, YANG W H, et al. Self-aligned video deraining with transmission-depth consistency[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, TN: IEEE, 2021: 11966-11976.
- [8] YUE Z S, XIE J W, ZHAO Q, et al. Semi-supervised video deraining with dynamical rain generator[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, TN: IEEE, 2021: 642-652.
- [9] JIANG T X, HUANG T Z, ZHAO X L, et al. A novel tensor-based video rain streaks removal approach via utilizing discriminatively intrinsic priors [C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI: IEEE, 2017: 2818-2827.
- [10] 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, UT: IEEE, 2018: 695-704.
- [11] QIAN R, TAN R T, YANG W H, 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, UT: IEEE, 2018: 2482-2491.
- [12] WEI Y Y, ZHANG Z, WANG Y, et al. DerainCycleGAN: Rain attentive CycleGAN for single image deraining and rainmaking[J]. IEEE Transactions on Image Processing, 2021, 30: 4788-4801.
- [13] 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 (CVPR). Honolulu, HI: IEEE, 2017: 1715-1723.
- [14] ZHENG X H, LIAO Y H, GUO W, et al. Single-image-based rain and snow removal using multi-guided filter[M]//Neural Information Processing. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013: 258-265.
- [15] 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.
- [16] 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 (CVPR). Honolulu, HI: IEEE, 2017: 1715-1723.
- [17] YANG W H, TAN R T, FENG J S, et al. Deep joint

- rain detection and removal from a single image[C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI: IEEE, 2017: 1685-1694.
- [18] 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, CA: IEEE, 2019: 3937-3946.
- [19] WANG Q L, WU B G, ZHU P F, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks[C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA: IEEE, 2020: 11531-11539.
- [20] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation[EB/OL]. (2015-05-18)[2024-09-20]. <https://arxiv.org/abs/1505.04597>.
- [21] LAI W S, HUANG J B, AHUJA N, et al. Deep Laplacian pyramid networks for fast and accurate super-resolution[C] // 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI: IEEE, 2017: 5835-5843.
- [22] 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, WA: IEEE, 2020: 8343-8352.
- [23] YI Z L, ZHANG H, TAN P, et al. DualGAN: Unsupervised dual learning for image-to-image translation[C] // 2017 IEEE International Conference on Computer Vision (ICCV). Venice: IEEE, 2017: 2868-2876.
- [24] YASARLA R, PATEL V M. Uncertainty guided multi-scale residual learning-using a cycle spinning CNN for single image de-raining[C] // 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach, CA: IEEE, 2019: 8397-8406.
- [25] LI X, WU J L, LIN Z C, et al. Recurrent squeeze-and-excitation context aggregation net for single image deraining[C] // Computer Vision-ECCV 2018. Cham: Springer International Publishing, 2018: 262-277.
- [26] WANG Z D, CUN X D, BAO J M, et al. Uformer: A general U-shaped transformer for image restoration[C] // 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans, LA: IEEE, 2022: 17662-17672.
- [27] ZAMIR S W, ARORA A, KHAN S, et al. Multi-stage progressive image restoration[C] // 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, TN: IEEE, 2021: 14821-14831.

(编辑 李静)