

基于条件扩散隐式模型单幅图像去雨

徐杰, 孙偲远

(江苏科技大学 计算机学院, 江苏 镇江 212100)

摘要:雨水天气会对图像造成干扰并增加图像处理的难度。为消除雨水对图像造成的影响,提出一种基于条件扩散隐式模型的图像去雨方法。该方法采用基于SR3的全卷积网络架构,使用U-Net结构的变体,并用BigGAN的残差块替换了传统的残差块,去掉自注意力机制、位置编码和群组归一化,实现了条件扩散模型支持任意大小图像的输入,且不受图像分辨率的影响。同时,引入确定性加速采样,用子序列时间步来加速生成过程,提高图像恢复速率。通过对图像进行重叠分块处理,将子块分次调入内存处理,减少资源消耗,提高算法的适用性,使用平滑噪声估计引导去噪过程,使生成图像获得更高的保真度。在合成数据集和真实数据集上进行测试,定性和定量结果表明,该方法在峰值信噪比和结构相似性方面均有提升,图像细节信息保留更加完全且去雨后的视觉效果更佳。

关键词:图像去雨;扩散概率模型;卷积网络;图像分块;编码-解码

中图分类号:TP391

文献标识码:A

文章编号:1673-629X(2023)12-0079-06

doi:10.3969/j.issn.1673-629X.2023.12.011

Rain Removal for a Single Image Based on Conditional Diffusion Implicit Models

XU Jie, SUN Si-yuan

(School of Computer Science, Jiangsu University of Science and Technology, Zhenjiang 212100, China)

Abstract: Rainy weather can interfere with images and increase the difficulty of image processing. To eliminate the influence of rain on images, we propose an image rain removal method based on the conditional diffusion implicit model. It adopts a fully convolutional network architecture based on SR3, using a variant of the U-Net structure, and replaces the traditional residual blocks with BigGAN's residual blocks, removing self-attention mechanism, positional encoding, and group normalization. This implementation enables the conditional diffusion model to support input of images of any size, without being affected by the image resolution. In addition, the proposed method introduces deterministic accelerated sampling and uses subsequence time steps to speed up the generation process and improve the image restoration rate. By processing the image in overlapping blocks, the sub-blocks are processed and called into memory in stages, reducing resource consumption and improving the algorithm's applicability. The method uses smooth noise estimation to guide the denoising process, achieving higher image fidelity for the generated images. Tests on synthetic and real datasets show that the proposed method improves the peak signal-to-noise ratio and structural similarity of images, while preserving more complete details and achieving better visual effects after rain removal.

Key words: image rain removal; diffusion probabilistic models; convolutional network; image block; encode-decode

0 引言

降雨是常见的恶劣天气之一,从雨天获取的图像受到雨水的影响,会导致图像内容模糊,从而增加了视觉任务的难度,如目标检测^[1]、语义分割^[2]、场景分析^[3]等等。因此,图像去雨具有重要的研究意义。

目前有大量的去雨算法被提出。其中,传统的图像去雨算法主要是基于先验信息的优化算法,如稀疏编码^[4]、高斯混合模型^[5]和图像分解^[6]等等,这些算

法试图利用纹理特征的先验信息对雨纹进行建模,然后将它们从图像中分离出来。然而,这些方法只能提取图像中的浅层信息,导致低级特征的模型表征能力非常有限,泛化能力和自适应能力相对较弱。因此,此类方法对于那些背景物体复杂且信息丰富的图像会有模型建立复杂、计算量大和去雨效果不理想等问题。

随着神经网络的快速发展,卷积神经网络凭借其强大的特征表示力和计算能力在图像去雨研究上表现

收稿日期:2023-03-09

修回日期:2023-07-11

基金项目:国家自然科学基金资助项目(62261029)

作者简介:徐杰(1997-),男,硕士研究生,通信作者,研究方向为计算机视觉。

优异。Fu 等^[7]首次提出深度卷积网络架构用于图像去雨,这种方法将图像分为基础层和细节层,并通过学习细节层之间的非线性映射关系来去除雨痕,接着将细节层和基础层合并得到去雨图像。Zhang 等^[8]提出了一种基于密度感知的多流密集连接卷积神经网络算法对雨纹进行去除,该算法将雨密度分级,并利用多流密集网络预测出清晰图像,具有适应多种尺度的雨纹的能力。Ren 等^[9]提出了一种渐进循环去雨网络,该网络通过多个阶段的递归运算来实现网络参数共享,以取代复杂模型,从而减少网络参数并提高图像去雨的质量。Zamir 等^[10]将图像去雨分解为多个阶段的子任务,其中编码器网络用于学习特征,最终利用恢复网络完成图像去雨过程。Huang 等^[11]提出了一种面向内存的半监督方法,使网络能够从数据中探索和学习雨纹的特性,并利用自监督的记忆模块来恢复无雨背景。

在图像去雨领域,生成网络建模也受到广泛关注。生成模型通过学习清除图像背景的底层数据分布,从而实现图像去雨。由于其更强的表达能力,生成方法在视觉恢复问题中具有更好的泛化能力。最近,去噪扩散概率模型在各种生成建模任务^[12-14]中取得了显著成功。

基于先进的生成建模方法,该文使用条件扩散概率模型,应用于处理雨天环境下的图像恢复。为使该方法更加高效和灵活,采用基于 SR3^[15]的 U-Net 全卷积网络架构,可支持输入任意大小图像;引入确定性加速采样,用更小的采样步数来加速生成过程,提高图像恢复效率;通过图像重叠分块处理并使用平滑噪声估计来指导采样过程,减少运算的数据量和计算压力,进一步提高算法的适用性。

1 基本理论

1.1 去噪扩散概率模型

去噪扩散概率模型^[16]是一类通过马尔可夫链学习的生成模型,能够将高斯噪声分布执行变分推理转换为模型所训练的数据分布,从而实现去噪和数据恢复的任务。扩散过程由前向扩散过程和逆扩散过程组成。在前向扩散过程中,从一个干净的数据样本 x_0 开始,将预定义的方差表 $\{\beta_1 \cdots \beta_t\}$ 注入高斯噪声, $\beta_t \in (0, \mathbf{I})$,持续 T 个时间步长进行加噪,最终得到一系列数据样本 x_1 到 x_t 。如下所示:

$$q(x_t | x_{t-1}) = \mathcal{N}(x_t; \sqrt{1 - \beta_t} x_{t-1}, \beta_t \mathbf{I}) \quad (1)$$

$$q(x_{1:T} | x_0) = \prod_{t=1}^T q(x_t | x_{t-1}) \quad (2)$$

联合分布 $p_\theta(x_{0:T})$ 称为逆扩散过程,具有学习高斯跃迁的马尔可夫链。从标准高斯分布开始,迭代执

行 T 个时间步来去噪,从而生成与训练分布对应的图像。当时间步数较大且 $\{\beta_t\}$ 的增量较小时,逆分布可以近似为高斯分布。利用已知逆分布 $q(x_t | x_{t-1})$,可以对 $x_t \sim \mathcal{N}(0, \mathbf{I})$ 进行采样,从 $q(x_0)$ 中得到样本,执行逆扩散过程。使用带参数 θ 的神经网络进行近似:

$$p_\theta(x_{0:T}) = p(x_T) \prod_{t=1}^T p_\theta(x_{t-1} | x_t) \quad (3)$$

$$p_\theta(x_{t-1} | x_t) = \mathcal{N}(x_{t-1}; \mu_\theta(x_t, t), \Sigma_\theta(x_t, t)) \quad (4)$$

在这个模型中,使用 $\mu_\theta(x_t, t)$ 和 $\Sigma_\theta(x_t, t)$ 神经网络对逆扩散过程进行参数化。为了获得参数 θ ,通过最小化定义数据分布的负对数似然的变分下界。具体而言,使用优化负数据对数似然的变分界来训练模型。通过这种方式,可以有效地学习到数据分布的结构,提高模型的性能,并更好理解数据的特征。如下所示:

$$L_\theta = E_q \left[\frac{p_\theta(x_{0:T})}{q(x_{1:T} | x_0)} \right] \geq E[-\log(p(x_0))] \quad (5)$$

通过使用随机梯度下降对随机采样的 L_{t-1} 项^[16]进行优化,可以显著降低损失。同时,前向扩散过程允许在给定 x_0 和任意噪声水平 t 下,以封闭形式采样 x_t ,

这里 $\alpha_t = 1 - \beta_t$, $\bar{\alpha}_t = \prod_{i=1}^t \alpha_i$,边缘分布可以表示为:

$$q(x_t | x_0) = \mathcal{N}(x_t; \sqrt{\bar{\alpha}_t} x_0, (1 - \bar{\alpha}_t) \mathbf{I}) \quad (6)$$

$$x_t = \sqrt{\bar{\alpha}_t} x_0 + \sqrt{1 - \bar{\alpha}_t} \epsilon_t \quad (7)$$

利用贝叶斯定理,可以根据 $\tilde{\beta}_t$ 和 $\tilde{\mu}_t(x_t, x_0)$ 计算出后验分布 $q(x_{t-1} | x_t, x_0)$,过程如下:

$$\tilde{\beta}_t = \frac{1 - \bar{\alpha}_{t-1} \beta_t}{1 - \bar{\alpha}_t} \quad (8)$$

$$\tilde{\mu}_t = \frac{1}{\sqrt{\alpha_t}} \left(x_t - \frac{\beta_t}{\sqrt{1 - \bar{\alpha}_t}} \epsilon_t \right) \quad (9)$$

$$q(x_{t-1} | x_t, x_0) = \mathcal{N}(x_{t-1}; \tilde{\mu}_t(x_t, x_0), \tilde{\beta}_t \mathbf{I}) \quad (10)$$

对于简单的训练目标,可以采用固定方差或者采用混合学习^[17]优化 $\Sigma_\theta(x_t, t)$ 。当 $p_\theta(x_{t-1} | x_t) = \mathcal{N}(x_{t-1}; \mu_\theta(x_t, t), \tilde{\beta}_t \mathbf{I})$ 时,训练网络 $\mu_\theta(x_t, t)$ 来预测 $\tilde{\mu}_t$,并在逆扩散过程中对反向步长的均值进行重参数化:

$$\mu_\theta(x_t, t) = \frac{1}{\sqrt{\alpha_t}} \left(x_t - \frac{\beta_t}{\sqrt{1 - \bar{\alpha}_t}} \epsilon_\theta(x_t, t) \right) \quad (11)$$

为了使分布的均值相等,训练目标可以进一步简化为:

$$L_{\text{simple}} = \mathbb{E}_{x_t, \epsilon_t} [\epsilon - \epsilon_\theta(x_t, t)]^2 \quad (12)$$

在该网络中,首先在 t 时刻从 x_t 中预测噪声 ϵ_t ,然后通过逆扩散过程 $p_\theta(x_{t-1} | x_t)$ 采样,最终可以得到目标分布的样本:

$$x_{t-1} = \frac{1}{\sqrt{\alpha_t}} \left(x_t - \frac{\beta_t}{\sqrt{1 - \bar{\alpha}_t}} \epsilon_\theta(x_t, t) \right) + \sqrt{\Sigma_\theta} Z \quad (13)$$

其中, $z \sim \mathcal{N}(0, \mathbf{I})$,这类类似于通过朗之万动力学采样

步骤,从噪声扰动最大的分布中取样,并逐步降低噪声尺度的大小,从数据分布中推导出新的样本,直到达到最小值。

1.2 条件扩散模型

条件扩散模型^[12]展示了最先进的数据编辑和图像合成能力。这些模型基于约束生成图像,并且通过逆扩散过程 $p_\theta(x_{i-1} | x_i, y)$ 学习条件分布,而不修改前向扩散过程 $q(x_{i,T} | x_0)$ 。这种方法可以保证以 y 为条件的数据分布采样的 x 具有高保真度。其过程可以表示为:

$$p_\theta(x_{0:T} | y) = p(x_T) \prod_{i=1}^T p_\theta(x_{i-1} | x_i, y) \quad (14)$$

为了学习条件分布,在所有时间步长 t 均使用图像 y 对神经网络进行约束。训练目标在此处被定义为:

$$L_{\text{simple}} = \mathbb{E}_{t, x_0, \epsilon} [\epsilon - \epsilon_\theta(x_t, y, t)]^2 \quad (15)$$

获得了条件分布之后,该模型就可以用于推理。给定一幅图像 y 后,可以从纯高斯噪声开始,从 T 步的马尔可夫链中采样, $p_\theta(x_{i-1} | x_i, y)$ 的条件分布的对应均值为:

$$\mu_\theta(x_i, t) = \frac{1}{\sqrt{\alpha_t}} (x_i - \frac{\beta_t}{\sqrt{1 - \alpha_t}} \epsilon_\theta(x_i, y, t)) \quad (16)$$

1.3 条件扩散隐式模型

去噪扩散隐式模型^[16]为预训练的扩散模型提供了一种确定性加速采样方法,该方法以牺牲多样性来生成质量更好的图像样本。隐式采样利用了广义的非马尔可夫正向过程公式:

$$q_\lambda(x_{1:T} | x_0) = q_\lambda(x_T | x_0) \prod_{i=2}^T q_\lambda(x_{i-1} | x_i, x_0) \quad (17)$$

将数据分布按照特殊选择的标准差 λ 进行重写:

$$q_\lambda(x_{i-1} | x_i, x_0) = \mathcal{N}(x_{i-1}; \tilde{\mu}_i(x_i, x_0), \lambda_i^2 \mathbf{I}) \quad (18)$$

用方差表示其均值:

$$\tilde{\mu}_i = \sqrt{\alpha_{i-1}} x_0 + \sqrt{1 - \alpha_{i-1} - \lambda_i^2} \cdot \epsilon_i \quad (19)$$

将式 7 代入到 $\tilde{\mu}_i(x_i, x_0)$ 中,并设置 $\lambda_i^2 = \tilde{\mu}_i$, 前向扩散过程就变成了马尔可夫过程,同时恢复了前面描述的原始扩散模型公式。重要的是,训练目标保持不变,而推理仍是基于嵌入式非马尔可夫前向扩散过程。通过将 λ_i^2 设为 0,从边缘噪声分布的初始 x_T 开始进行采样,从而使采样过程具有确定性。如下:

$$x_{i-1} = \sqrt{\alpha_{i-1}} \left(\frac{x_i - \sqrt{1 - \alpha_{i-1}} \cdot \epsilon_\theta(x_i, t)}{\sqrt{\alpha_i}} + \sqrt{1 - \alpha_{i-1}} \cdot \epsilon_\theta(x_i, t) \right) \quad (20)$$

通过加速采样的方式,从完整的 $\{1, 2, \dots, T\}$ 时间步长中抽取出子序列 $\{\tau_1, \tau_2, \dots, \tau_s\}$, τ_1 处于逆扩

散的最后一步,从而大幅度减少采样步骤。

$$\tau_i = (i - 1) \cdot T/S + 1 \quad (21)$$

在与隐式采样保持兼容的同时,将带有条件 y 的逆扩散过程纳入公式:

$$\sqrt{\alpha_{i-1}} \left(\frac{x_i - \sqrt{1 - \alpha_i} \cdot \epsilon_\theta(x_i, y, t)}{\sqrt{\alpha_i}} + \sqrt{1 - \alpha_{i-1}} \cdot \epsilon_\theta(x_i, y, t) \right) \quad (22)$$

从 $x_T \sim \mathcal{N}(0, \mathbf{I})$ 出发,加入条件 y ,沿着一条确定性的反向路径,最终抵达 x_0 。扩散模型过程如图 1 所示。




图 1 扩散模型过程

2 基于分块的条件扩散图像恢复

现有的部分生成式网络模型在进行图像去雨时要求输入指定大小的图片,但是由于数据集的差异,会出现图片大小不统一的问题。虽然可以通过对图片进行 resize 来解决,但这种方法会导致原始信息的丢失和图片精度的损失。相比之下,该文采用基于 SR3^[15] 的全卷积网络架构,它使用了来自文献[16]的 U-Net 结构的变体,并用 BigGAN^[18] 的残差块替换了传统的残差块。为保证模型不受图像分辨率的影响^[19],去掉了自注意力机制、位置编码和群组归一化,使得条件扩散模型能够支持任意图像大小的输入。

该文采用图像重叠分块处理与重构的方法^[20],该方法将图像分成小块进行局部操作,并在优化后将结果合并,如图 2 所示。在图像分块时,保证相邻图像块有一定的重叠,以消除边缝,并在采样过程中对重叠小块之间进行平滑处理。使用图像分块处理不仅可以实现并行处理,而且还可以将整张图像分块处理并调入内存,提高算法的适用性。这种方法可以避免处理过大图像时出现的问题,减少每次运算的数据量和计算压力。

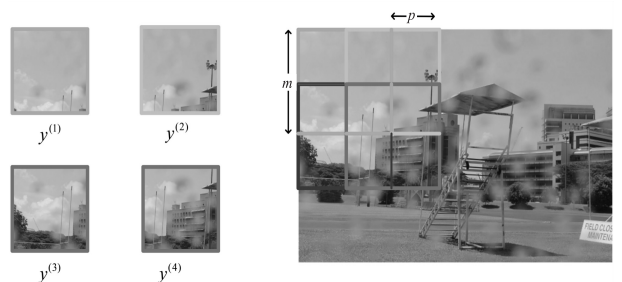


图 2 重叠分块

为了训练模型,该文使用带参数 θ 的神经网络进

行如下近似:

$$p_{\theta}(x_{0:T}^{(k)} | y^{(k)}) = p(x_T^{(k)}) \prod_{t=1}^T p_{\theta}(x_{t-1}^{(k)} | x_t^{(k)}, y^{(k)}) \quad (23)$$

具体来说,首先定义任意大小的无雨图像 x_0 和有雨图像 y 。为了进行结构特征提取,引入了一个二元掩膜 M_k ,它与 x_0 和 y 具有相同的维度,表示图像中第 k 个 $m \times m$ 小块。接着,从训练集中随机选择一对有雨和无雨图像,并根据二元掩膜 M_k 随机采样 $m \times m$ 小块,得到 $x_{0:T}^{(k)}$ 和 $y^{(k)}$ 。然后,从时间步 $\{1, 2, \dots, T\}$ 中均匀选择一个时间步 t ,并从标准正态分布 $\mathcal{N}(0, \mathbf{I})$ 中采样噪声项 ϵ 。最后,执行梯度下降步骤直到收敛,并计算出参数 θ 。

$$\nabla_{\theta} \| \epsilon_t - \epsilon_{\theta}(\sqrt{\alpha_t} x_0^{(k)} + \sqrt{1 - \alpha_t} \epsilon_t, y^{(k)}, t) \|^2 \quad (24)$$

该文使用条件扩散隐式模型进行图像去雨的过程如图 3 所示。首先,通过 $m \times m$ 的小块对有雨图像 y

上进行水平和垂直维度移动 $p(p < m)$ 个步长来分解图像,其中,较小的 p 会增加小块之间的重叠,从而增加平滑度,但也会增加计算负担。定义 N 为所有重叠小块的总数,重叠小块位置 $n \in \{1, 2, \dots, N\}$,重叠小块的噪声估计通过 $\epsilon_{\theta}(x_t^{(n)}, y^{(n)}, t)$ 计算,其中 $t = (i - 1) \cdot T/S + 1$, S 表示隐式采样步数。为了缓解图像的不适性质,并有效地引导反向采样过程以确保获得更高的保真度,在给定的去噪时间步骤 t 中,通过对重叠小块区域中像素的平均噪声估计进行逆采样。

$$\frac{1}{\text{rep}} \sum_{n=1}^{\text{rep}} \epsilon_{\theta}(x_t^{(n)}, y^{(n)}, t) \quad (25)$$

随后将重叠小块的噪声估计累积到矩阵 A_t 中,并使用平滑的全图像噪声估计执行隐式采样更新:

$$x_{t-1} = \sqrt{\alpha_{t-1}} \left(\frac{x_t - \sqrt{1 - \alpha_t} \cdot A_t}{\sqrt{\alpha_t}} \right) + \sqrt{1 - \alpha_{t-1}} \cdot A_t \quad (26)$$

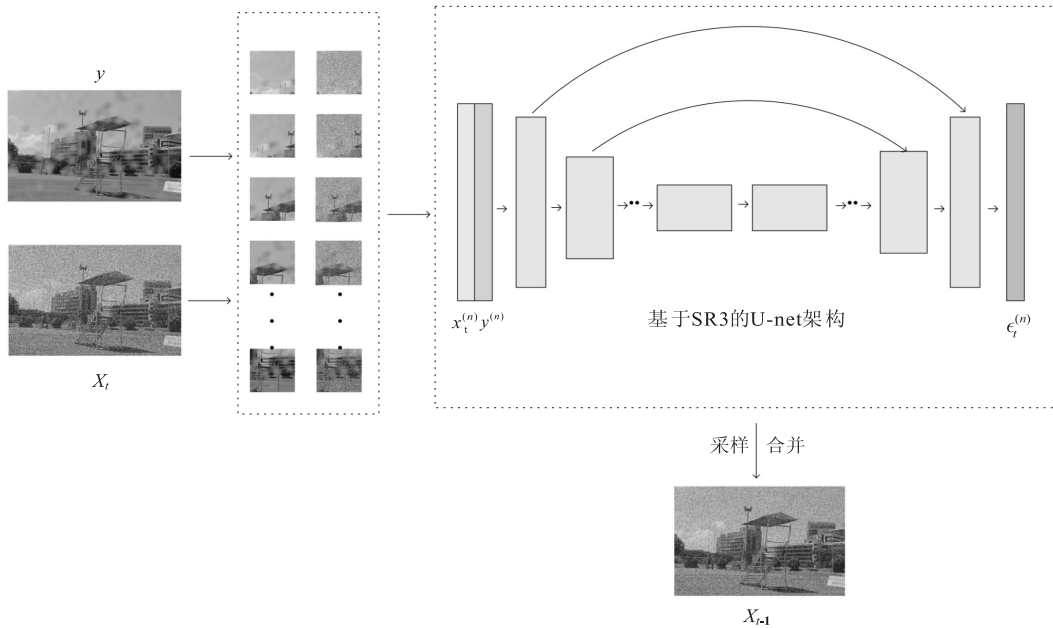


图 3 基于条件扩散隐式模型图像去雨

3 实验结果与分析

3.1 实验设置

实验环境为 ubuntu18.04, 32 GB 内存, 5 vCPU Intel(R) Xeon(R) Silver 4210 CPU @ 2.20 GHz, RTX 3090(24 GB) GPU, Cuda 为 11.1, 使用 Python 3.8 编程语言和 Pytorch 1.8.1 框架进行训练。在训练过程中,模型将图片随机裁剪为 64×64 的小块,并使用 Adam 优化器,学习率固定为 0.000 02,为促进更稳定的学习^[17],参数更新时滑动平均值设置为 0.999。

3.2 数据集与评价指标

在训练和测试的过程中,通常需要大量的数据集,

尤其是成对的有雨和无雨图像。为解决这些问题,该文选用公开的训练集进行训练和测试,包括 Rain14000^[21]和 SPA-Data^[22]。为了评估算法的去雨效果,采用峰值信噪比 (PSNR) 和结构相似性 (SSIM) 两个指标。实验数据集的划分如表 1 所示。

表 1 实验数据集的划分

数据集	Rain14000	SPA-Data
特征	14 种雨纹	雨纹雨雾
面向任务	去雨纹、暴雨	去雨纹、雨雾
训练样本对	10 000	0
测试样本对	4 000	1 000

3.3 合成雨图实验对比

将文中算法与 DID - MDN^[8], PReNet^[9], MPRNet^[10], MOSS^[11] 去雨算法在合成数据集 Rain14000 上进行定量分析,对比结果如表 2 所示。与其他算法相比,文中算法在峰值信噪比和结构相似性方面表现更好。同时,图 4 展示了文中算法在合成数据集上去雨的视觉效果。从图中可以发现,PReNet 在密集雨线下会有明显的雨痕残留,而 DID-MDN 产生了较大的伪影,MPRNet 和 MOSS 丢失了边缘纹理细节较差,与之相比,文中算法可以有效地去除密度较

大、方向不同的雨纹,并保留更多的图像细节和边缘信息,从视觉上得到更令人满意的效果。

表 2 不同算法在合成数据集上的定量对比结果

算法	PSNR/dB	SSIM
DID-MDN	31.47	0.941
PReNet	32.60	0.946
MPRNet	34.98	0.953
MOSS	35.05	0.956
文中算法	35.17	0.961



图 4 不同算法在合成数据集上去雨结果的视觉对比

3.4 真实雨图实验对比

为了进一步验证算法在真实环境下去雨的泛化性能,测试采用了 SPA-Data 数据集,测试结果如图 5 所示。从图中可以发现,对比算法去除雨滴和较粗的雨

纹方面效果并不理想,相比之下,文中算法在雨纹去除和保持图像细节两方面都表现最佳,因此在自然雨图上具有更好的泛化能力。




图 5 不同算法在真实数据集上去雨结果的视觉对比

4 结束语

该文提出一种基于条件扩散隐式模型的图像去雨方法,采用基于SR3^[5]的U-Net全卷积网络架构,支持任意大小的图像输入。引入确定性加速采样来提高图像恢复效率。此外,采用图像重叠分块处理以减少内存压力,提高算法的适用性。由实验分析结果所示,该方法在单图像去雨效果上有更好的性能,但依然存在不足之处。尽管使用了加速确定性采样技术,但相较于其他生成模型,图像恢复时间仍然有待提高,这也是未来需要重点研究的方向。

参考文献:

- [1] 杨坤志,闫潇宁,孙健,等.一种雨雾背景的DeRF-YOLOv3-X目标检测方法[J].传感技术学报,2022,35(9):1222-1229.
- [2] 范润泽,刘宇红,张荣芬,等.基于多尺度注意力机制的道路场景语义分割模型[J].计算机工程,2023,49(2):288-295.
- [3] CHANG C C, JUAN Y H, HUANG C L, et al. Scenario analysis for road following using jetbot[C]//2020 IEEE Eurasia conference on IOT, communication and engineering (ECICE). Taiwan, China; IEEE, 2020:403-406.
- [4] LUO Y, XU Y, JI H. Removing rain from a single image via discriminative sparse coding[C]//Proceedings of the IEEE international conference on computer vision. Santiago de Chile; IEEE, 2015:3397-3405.
- [5] LI Y, TAN R T, GUO X, et al. Rain streak removal using layer priors[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Las Vegas; IEEE, 2016:2736-2744.
- [6] 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, 2011, 21(4):1742-1755.
- [7] FU X, HUANG J, DING X, 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.
- [8] ZHANG H, PATEL V M. Density-aware single image de-raining using a multi-stream dense network[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Salt Lake City; IEEE, 2018:695-704.
- [9] REN D, ZUO W, HU Q, et al. Progressive image deraining networks: a better and simpler baseline[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Long Beach; IEEE, 2019:3937-3946.
- [10] ZAMIR S W, ARORA A, KHAN S, et al. Multi-stage progressive image restoration[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Virtual; IEEE, 2021:14821-14831.
- [11] HUANG H, YU A, HE R. Memory oriented transfer learning for semi-supervised image deraining[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Virtual; IEEE, 2021:7732-7741.
- [12] DHARIWAL P, NICHOL A. Diffusion models beat gans on image synthesis[J]. Advances in Neural Information Processing Systems, 2021, 34:8780-8794.
- [13] ROMBACH R, BLATTMANN A, LORENZ D, et al. High-resolution image synthesis with latent diffusion models[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. New Orleans; IEEE, 2022:10684-10695.
- [14] HO J, SAHARIA C, CHAN W, et al. Cascaded diffusion models for high fidelity image generation[J]. J. Mach. Learn. Res., 2022, 23(47):1-33.
- [15] SAHARIA C, HO J, CHAN W, et al. Image super-resolution via iterative refinement[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 45(4):4713-4726.
- [16] HO J, JAIN A, ABBEEL P. Denoising diffusion probabilistic models[J]. Advances in Neural Information Processing Systems, 2020, 33:6840-6851.
- [17] NICHOL A Q, DHARIWAL P. Improved denoising diffusion probabilistic models[C]//International conference on machine learning. Vienna; PMLR, 2021:8162-8171.
- [18] BROCK A, DONAHUE J, SIMONYAN K. Large scale GAN training for high fidelity natural image synthesis[J]. arXiv:1809.11096, 2018.
- [19] WHANG J, DELBRACIO M, TALEBI H, et al. Deblurring via stochastic refinement[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. New Orleans; IEEE, 2022:16293-16303.
- [20] 张杰,施露露,史振志,等.相差细胞图像的光照均衡与分割计数方法研究[J].电子测量与仪器学报,2022,36(5):136-145.
- [21] FU X, HUANG J, ZENG D, et al. Removing rain from single images via a deep detail network[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Honolulu; IEEE, 2017:3855-3863.
- [22] WANG T, YANG X, XU K, et al. Spatial attentive single-image deraining with a high quality real rain dataset[C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. Long Beach; IEEE, 2019:12270-12279.