



计算机科学

COMPUTER SCIENCE

基于联合注意力机制与多阶段特征提取的图像去雨

林祖凯, 侯国家, 王国栋, 潘振宽

引用本文

林祖凯, 侯国家, 王国栋, 潘振宽. 基于联合注意力机制与多阶段特征提取的图像去雨[J]. 计算机科学, 2025, 52(11): 206-212.

LIN Zukai, HOU Guojia, WANG Guodong, PAN Zhenkuan. [Image Deraining Based on Union Attention Mechanism and Multi-stage Feature Extraction](#) [J]. Computer Science, 2025, 52(11): 206-212.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[基于多尺度层次网络的人体重建神经辐射场](#)

Neural Radiance Field for Human Reconstruction Based on Multi-scale Hierarchical Network
计算机科学, 2025, 52(11): 175-183. <https://doi.org/10.11896/jsjcx.240900141>

[基于神经辐射场的即时高保真人脸生成算法](#)

Immediate Generation Algorithm of High-fidelity Head Avatars Based on NeRF
计算机科学, 2025, 52(10): 159-167. <https://doi.org/10.11896/jsjcx.241000066>

[MTFuse:基于Mamba和Transformer的红外与可见光图像融合网络](#)

MTFuse:An Infrared and Visible Image Fusion Network Based on Mamba and Transformer
计算机科学, 2025, 52(8): 188-194. <https://doi.org/10.11896/jsjcx.240600106>

[基于改进SOM网络的聚类算法](#)

Clustering Algorithm Based on Improved SOM Model
计算机科学, 2025, 52(8): 162-170. <https://doi.org/10.11896/jsjcx.240700017>

[基于双分支小波卷积自编码器和数据增强的深度聚类方法](#)

Deep Clustering Method Based on Dual-branch Wavelet Convolutional Autoencoder and DataAugmentation
计算机科学, 2025, 52(4): 129-137. <https://doi.org/10.11896/jsjcx.240100111>

基于联合注意力机制与多阶段特征提取的图像去雨

林祖凯 侯国家 王国栋 潘振宽

青岛大学计算机科学技术学院 山东 青岛 266071

(linzukai@qdu.edu.cn)

摘要 现有的图像去雨网络主要依赖大量合成配对数据进行训练,忽视了合成数据与真实数据在空间分布特征和通道重要性上的差异,导致在真实数据上的去雨效果存在纹理细节模糊和泛化性差等问题。为此,提出了一种基于联合注意力机制与多阶段特征提取的无监督图像去雨网络。首先,为了适应雨纹的空间位置局部性,设计了结合空间和通道注意力机制的雨纹特征感知模块,并通过扩张卷积增大雨纹特征提取感受野。其次,引入循环神经网络渐进地分阶段提取雨纹特征,并在循环中保留前一阶段的有用信息,以增强对雨纹特征的提取能力。为了进一步提升对局部微观细节和全局纹理结构特征的鉴别能力,设计了一个多尺度鉴别器,分别在3个不同尺度上对生成图像进行判别,以指导生成器生成更高质量的图像。在合成和真实数据集上进行了定性和定量实验,通过PSNR,SSIM和NIQE客观评价指标对比表明,所提出方法的结果优于对比的监督、半监督和无监督方法,验证了其有效性和泛化性。

关键词: 图像处理; 图像去雨; 联合注意力机制; 多阶段特征提取; 无监督学习

中图分类号 TP391

Image Deraining Based on Union Attention Mechanism and Multi-stage Feature Extraction

LIN Zukai, HOU Guojia, WANG Guodong and PAN Zhenkuan

College of Computer Science & Technology, Qingdao University, Qingdao, Shandong 266071, China

Abstract Existing image deraining networks predominantly rely on the large-scale synthetic paired datasets for training, ignoring the difference in spatial distribution characteristics and the difference in channel importance between synthetic and real data, resulting in blurred texture details and diminished generalization performance. To address these issues, this paper develops an unsupervised network model for image deraining based on a union attention mechanism with multi-stage feature extraction. To adapt to the spatial locality of rain streaks, the feature-aware module is initially designed to extract rain streaks through the combination of spatial and channel attention mechanisms, while dilation convolution is used to enhance the sensory field of rain feature extraction. In addition, a recurrent neural network is introduced to extract the rain stripe features gradually, and the useful information of the previous stage is retained in the cycle to improve the rain stripe feature extraction ability. To further enhance the discrimination of local micro-details and global texture structure features, it designs a multi-scale discriminator for distinguishing images at three different scales and guideings the generator to produce higher quality images. Qualitative and quantitative experiments on synthetic and real datasets show that the proposed method is superior to some supervised, semi-supervised and unsupervised methods on PSNR, SSIM and NIQE metrics, which verifies its effectiveness and generalization.

Keywords Image processing, Image deraining, Multi-attention mechanism, Multi-stage feature extraction, Unsupervised learning

1 引言

在雨天场景下拍摄的图像由于雨条纹的干扰,常常存在背景信息模糊和能见度下降等质量退化问题,会直接影响目标检测^[1]、图像识别^[2]和视觉跟踪^[3]等后续计算机视觉下游任务的准确性。因此,设计有效的雨纹去除方法以恢复图像

信息极具现实意义。

目前,图像去雨方法大致可分为模型驱动的传统方法^[4]和数据驱动的深度学习方法^[5-7]两大类。早期,诸多研究主要采用模型驱动的方法,通过手工设计的先验知识来表征图像中的雨纹和背景属性,进而构建和优化去雨模型以去除雨纹。虽然模型驱动方法在一定程度上取得了效果,但其对先验知

到稿日期:2024-09-02 返修日期:2024-11-26

基金项目:山东省自然科学基金(ZR2024MF125);青岛市自然科学基金(24-4-4-zrjj-122-jch);国家自然科学基金(61901240)

This work was supported by the Natural Science Foundation of Shandong Province(ZR2024MF125), Natural Science Foundation of Qingdao Municipality(24-4-4-zrjj-122-jch) and National Natural Science Foundation of China(61901240).

通信作者:侯国家(guojiahou@qdu.edu.cn)

识的高度依赖,导致此类方法在处理具有较密集且复杂雨纹信息的图像时能力有限。相比之下,得益于强大的特征挖掘和表达能力,数据驱动方法在图像去雨方面表现出了显著的性能提升。大多数现有的数据驱动方法依赖于配对数据标签,通过监督学习进行训练。然而,获取成对的真实训练数据十分困难,此类方法往往依赖合成数据集,导致在处理真实雨天图像时性能较差。因此,采用非配对图像进行雨图清晰化,切合图像去雨技术实际的应用需求,具有重要意义。文献[8]设计了一种同时关注雨图和清晰图的无监督降雨信息检测器,虽然在一定程度上缓解了配对数据难题,但其忽略了雨纹的空间位置局部性,导致对雨纹的特征提取不足,无法在去雨过程中完全保留原始图像中的细微纹理细节。相比之下,文献[9]关注了雨纹的位置特性,但其由于使用了单尺度鉴别器,未能有效地融合局部和全局信息,缺乏对图像整体特征和局部细节的全面考虑。

针对配对数据获取困难、忽略雨纹空间位置局部性以及未能有效融合局部和全局信息等问题,本文提出了一种基于联合注意力机制与多阶段特征提取的无监督图像去雨网络。将联合注意力机制嵌入卷积神经网络中,设计了一个注意力雨纹特征感知模块,该模块能够逐阶段捕获全局不同位置的相似雨纹特征,并结合门控循环单元记忆前一阶段的有效信息,来增强雨纹特征的提取能力,弥补了无监督去雨网络对雨纹特征提取不足的缺陷。此外,为了全面感知雨纹特征,在该模块中使用扩张卷积来增大雨纹特征提取的感受野。为了从局部到全局对生成图像进行鉴别,进一步设计了一个多尺度鉴别器分别在3个不同尺度(70×70 , 142×142 和 286×286)上对生成图像进行判别,3个不同尺度的判别网络协同工作能更有效地引导生成器生成更清晰的图像。

2 相关工作

2.1 基于模型的方法

基于模型的方法通过分析和建模雨纹在图像中的成像过程,并反演这一过程来提取背景层。此类方法最早可以追溯到Kang等^[10]的工作,他们使用形态成分分析进行图像分解以去除雨纹,通过字典学习和稀疏编码将最初提取的雨图像高频分量进一步分解为雨和非雨分量。但该方法在去除雨纹的同时,会导致图像模糊。随着图像去雨研究的快速发展,Du等^[11]提出了一种基于梯度域的新框架,利用背景与雨纹在梯度域中的低相关性构建无雨方向模型。该模型结合全变分、低秩约束和去相关项,显式提取与无雨方向垂直的梯度分量,并利用泊松方程生成无雨图像。然而,该方法对雨纹方向的依赖、局部处理的一致性问题以及梯度域和总变分法的局限性,导致其在复杂场景中的泛化能力较差。Wang等^[12]提出了基于卷积字典学习机制的图像去雨模型,并利用近端梯度下降技术进行求解。该模型通过端到端训练,可以自动提取雨纹和简单算子,更好地表征雨层和背景层的特征,表现出更好的去雨性能。综上所述,尽管基于模型的方法在去除雨纹方面取得了一定进展,但这些方法对图像特征的提取和表达仍留在较低层次,适用场景有限且泛化性差。

2.2 基于深度学习的方法

基于深度学习的方法因具有卓越的特征提取和表达能力,在处理复杂雨纹结构方面表现突出,被广泛应用于图像去雨任务。Hsu等^[13]设计了一种循环小波结构,其通过保留残差网络保留了每个级别的低频子图像,并被引入低频去雨子网络中。低频结构信息通过块连接共享给高频子网络,并使用图像加权混合模块消除雨纹,从而在细节保留和去雨性能之间实现了平衡。Chen等^[14]提出了一种多尺度Transformer模型,通过综合不同尺度的特征和双向反馈机制来提升图像去雨效果。该方法引入了闭环设计和尺度间的双向反馈,以更好地处理空间变化的雨条纹退化。尽管监督学习方法取得了一定的成效,但它们普遍依赖配对的合成数据集进行训练,在真实雨天场景中的去雨效果往往不佳,主要原因在于合成图像和真实图像之间存在显著的域差距。

为了弥补合成图像和真实图像之间的域差距,进一步提高去雨算法的泛化能力,一些半监督^[15-16]和无监督方法^[17]相继被提出。Qiu等^[15]为提高去雨模型对真实雨天图像的去雨效果,提出在模型训练过程中同时使用合成雨图和真实雨图,并最小化特征向量的一阶信息和二阶统计信息差异,使两者特征分布一致。该方法虽然在特征分布一致性上有所改善,但在处理复杂雨纹时不够有效。Yasarla等^[18]进一步构建了一种基于高斯过程的半监督学习框架,该框架使网络可利用合成数据集进行学习,同时使用未配对的真实降雨图像以提高网络的泛化性,但其对高斯过程的依赖限制了其在不同降雨场景下的适应性。Jiang等^[16]设计了包含一个监督分支和一个无监督分支的半监督框架,通过级联子网络逐步消除复杂的雨条纹,并采用递归学习策略来减少模型参数。但其递归学习策略增加了模型的复杂度,使得效率降低。为了进一步减少对合成数据的依赖,Ye等^[19]提出了一种非局部对比学习方法用于无监督图像去雨,该方法利用了样本内部固有的自相似性和不同层之间的互斥性,更有效地将雨纹层和清晰图像区分开。文献[9,17]分别通过深度特征空间中的双重对比学习方式和互补的注意力融合模块,来更有效地学习判别特征,提升去雨效果。然而,这两种方法在特征提取的全面性和效率上仍有较大提升空间。最近,Wen等^[20]提出了一种新颖的神经Schrödinger桥方法,该方法通过随机微分方程捕捉雨天和清晰图像之间的映射,并利用对比语言-图像预训练模型进行优化。然而,此方法对随机微分方程的参数选择依赖性较强,限制了其在不同场景下的泛化能力。

3 本文方法

本文提出了一种基于联合注意力机制与多阶段特征提取的无监督图像去雨方法。与现有的无监督去雨模型不同,本文方法以雨纹特征为导向,学习非配对数据之间的映射关系,更好地实现了清晰图像与雨天图像之间的转化。本文所提去雨网络由3部分构成,即注意力雨纹特征感知模块(RPIE)、两个生成器 G_n 和 G_r 、两个多尺度鉴别器 D_n 和 D_r ,它们构成了有雨图像和清晰图像之间的两条转换路径,其流程框架如图1所示。

相匹配,在雨天图像到清晰图像的转换中,将退化图像和雨纹特征输入生成器 G_n 生成清晰图像,并利用鉴别器 D_n 判断生成图像的真实性。该转换过程的对抗性损失 $\mathcal{L}_{adv}(G_n, D_n)$ 表示为:

$$\mathcal{L}_{adv}(G_n, D_n) = \mathbb{E}_{n \sim P_{\text{data}}(n)} [\log D_n(n)] + \mathbb{E}_{r \sim P_{\text{data}}(r)} [\log(1 - D_n(G_n(\mathcal{U}(r), r)))] \quad (4)$$

其中, $P_{\text{data}}(n)$ 和 $P_{\text{data}}(r)$ 分别是真实无雨图像和雨天图像的数据分布, D_n 最大化目标函数可以区分生成的无雨图像和真实图像, G_n 最小化损失使生成的无雨图像更加真实。类似地,清晰图像到雨天图像转换的对抗性损失 $\mathcal{L}_{adv}(G_r, D_r)$ 表示为:

$$\mathcal{L}_{adv}(G_r, D_r) = \mathbb{E}_{r \sim P_{\text{data}}(r)} [\log D_r(r)] + \mathbb{E}_{n \sim P_{\text{data}}(n)} [\log(1 - D_r(G_r(\mathcal{U}(n), n)))] \quad (5)$$

在模型训练过程中,为了保持生成图像与原始输入图像的内容一致性,引入循环一致性损失 \mathcal{L}_{cyc} 来约束生成图像的解空间。

$$\mathcal{L}_{cyc} = \mathbb{E}_{n \sim P_{\text{data}}(n)} [\|G_n(\mathcal{U}(r), \hat{r}) - n\|_1] + \mathbb{E}_{r \sim P_{\text{data}}(r)} [\|G_r(\mathcal{U}(\hat{n}), \hat{n}) - r\|_1] \quad (6)$$

其中, \hat{r} 为 $G_r(\mathcal{U}(n), n)$, \hat{n} 为 $G_n(\mathcal{U}(r), r)$ 。

预训练的深度网络中提取的特征包含丰富的语义信息,本文引入感知损失 \mathcal{L}_p 提取图像中的多层次特征,保持图像的语义信息感知相似度。感知损失 \mathcal{L}_p 表示为:

$$\mathcal{L}_p = \|\phi_l(G_n(\mathcal{U}(r), r)) - \phi_l(n)\|_2^2 \quad (7)$$

其中, $\phi_l(\cdot)$ 是在 ImageNet 上预训练的 VGG16 网络中第二个和第三个卷积块中的卷积层。

另外,当目标域的图像作为生成器的输入时,本文引入恒等映射损失 $\mathcal{L}_{identity}$ 以促使其映射到自身。该损失表示为:

$$\mathcal{L}_{identity} = \mathbb{E}_{r \sim P_{\text{data}}(r)} [\|G_r(\mathcal{U}(r), r) - r\|_1] + \mathbb{E}_{n \sim P_{\text{data}}(n)} [\|G_n(\mathcal{U}(n), n) - n\|_1] \quad (7)$$

综上,本文网络的总损失为:

$$\mathcal{L} = \lambda_1 \mathcal{L}_{adv1} + \lambda_2 \mathcal{L}_{adv2} + \lambda_3 \mathcal{L}_{cyc} + \lambda_4 \mathcal{L}_p + \lambda_5 \mathcal{L}_{identity} \quad (8)$$

其中, λ 为各个损失的权重,在本文中 $\lambda_1 = 1, \lambda_2 = 1, \lambda_3 = 10, \lambda_4 = 0.01, \lambda_5 = 5$ 。

4 实验

4.1 实验设置

本文基于 PyTorch 框架来构建网络,并在 Ubuntu 环境

下使用配备 24 GB 内存的 NVIDIA GeForce RTX 3090 GPU 进行训练。在训练过程中,设置训练轮次为 400, BatchSize 为 1, 动量参数设置为 0.9, 注意力雨纹特征感知模块中设置迭代次数为 6, 并将训练图像(或其水平翻转)随机裁剪成大小为 256×256 的图像块。采用 Adam 优化器更新模型参数, 初始学习率为 1×10^{-4} , 并在 200 个 epoch 后线性衰减至零。

4.2 数据集和评价指标

在定性和定量对比实验中, 选用 Rain100L^[21], Rain12^[24], SPA-Data^[25] 和 LHP-Rain^[26] 这 4 个数据集对所提方法进行评估, 其中, Rain100L 和 Rain12 为合成数据集, SPA-Data 和 LHP-Rain 为真实雨天图像数据集。Rain100L 数据集包含 300 对图像, 其中 200 对用于训练, 100 对用于测试; Rain12 数据集仅包含 12 对测试图像; SPA-Data 和 LHP-Rain 分别包含 1000 对测试图像。

本文采用峰值信噪比 (Peak Signal to Noise Ratio, PSNR)、结构相似度 (Structural Similarity Index Metric, SSIM) 和自然图像质量评价指标 (Natural Image Quality Evaluator, NIQE), 将所提方法与现有的图像去雨算法进行定量对比。其中, PSNR 能够反映恢复图像与原始图像之间像素值的差异; SSIM 能够体现恢复图像与原始图像的亮度、对比度和结构信息之间的相似性; NIQE 通过结合图像的梯度信息、对比度和饱和度等信息来量化图像的自然性, 它更加关注图像的感知质量。PSNR 和 SSIM 指标评价价值较高时, 代表生成图像与原始图像具有更高的相似度, 图像质量更高; NIQE 指标相反, 值越低, 代表图像更加自然、真实, 图像质量也相对较高。

4.3 合成雨天实验对比

为了验证本文方法的有效性, 本实验选用了 5 个主流的去雨算法进行定性和定量的去雨结果对比, 包括: 1 个监督学习的方法 DTCN^[27], 1 个半监督学习的方法 Syn2Real^[18], 以及 3 个无监督学习的方法 CycleGAN^[28], DerainCycleGAN^[8] 和 DCD-GAN^[17]。表 1 列出了不同方法在合成数据集上的 PSNR, SSIM 和 NIQE 值的对比结果。从表 1 可以看出: 相对于其他无监督去雨方法, 所提方法在 PSNR, SSIM 和 NIQE 指标上的评价价值均更优, 这表明本文方法生成的图像具有更佳的质量、更好的相似性和更高的自然度; 尽管监督方法 DTCN 和半监督学习方法 Syn2Real 能够利用一些标记数据提供更多信息, 但其去雨效果仍不如本文所提的无监督方法。

表 1 不同方法在 Rain100L 和 Rain12 数据集上的定量比较

Table 1 Quantitative evaluations via using different methods on Rain100L and Rain12 datasets

方法	Supervision	Rain100L			Rain12		
		PSNR \uparrow	SSIM \uparrow	NIQE \downarrow	PSNR \uparrow	SSIM \uparrow	NIQE \downarrow
DTCN ^[27]	F	28.70	0.942	3.3361	32.64	0.953	3.8526
Syn2Real ^[18]	S	32.14	0.934	3.6641	32.78	0.926	4.1018
CycleGAN ^[28]	U	24.33	0.832	4.5658	21.56	0.857	4.1682
DerainCycleGAN ^[8]	U	31.49	0.936	3.2883	34.44	0.952	3.7239
DCD-GAN ^[17]	U	23.90	0.831	4.1583	22.14	0.835	4.6059
Ours	U	32.80	0.948	3.2846	35.43	0.955	3.6936

图 3 给出了不同方法在 Rain100L 和 Rain12 数据集上的视觉对比。可以观察到, CycleGAN 和 DCD-GAN 存在明显的雨纹残留, 并且还会导致去雨图像颜色的失真; DTCN 和 Syn2Real 能够去除较多的雨纹, 但难以保持图像的纹理细节;

DerainCycleGAN 去除了大部分雨纹, 但单尺度鉴别器导致其映射能力较弱, 生成的图像中出现较宽的雨纹残留。本文方法能更有效地去除图像中的雨纹, 并且在此过程中最大程度地保持图像的清晰度和色彩信息, 从而展现出更佳的去雨视觉效果。

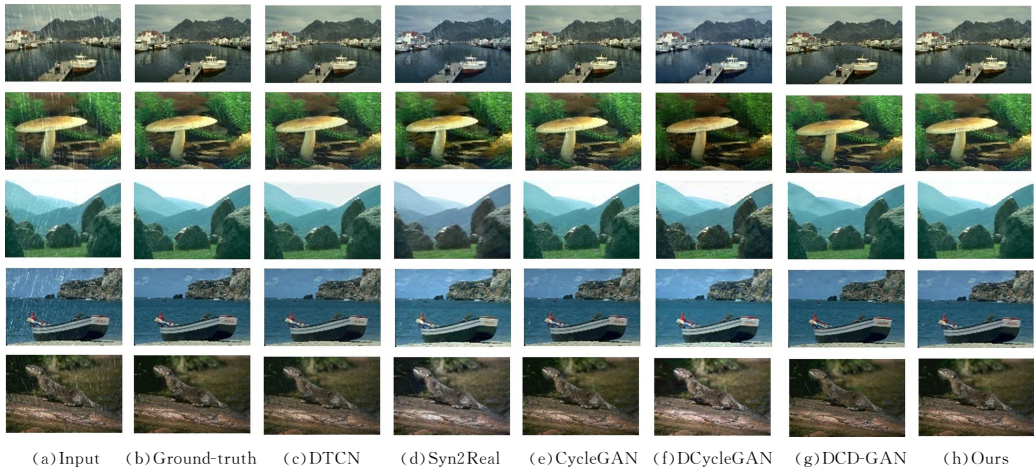


图3 不同方法在 Rain100L 和 Rain12 数据集上的去雨结果

Fig. 3 Comparison of deraining effects of different methods on Rain100L and Rain12 datasets

4.4 真实雨天实验对比

为了验证本文算法的普适性,进一步选取了 100 幅真实雨天图像(Real100)对方法进行对比测试,并对去雨结果进行图像质量的量化评估。表 2 列出了所有方法在真实雨天图像数据集 SPA-Data, LHP-Rain 和 Real100 上的 PSNR, SSIM 和 NIQE 值的对比结果。可以看出,本文方法的 PSNR 和 NIQE 值均取得最优,在 SPA-Data 数据集上的 SSIM 值略低。这种差异主要是因为 Sy2Real 不仅利用了未配对数据,还结合了

大量配对数据进行训练来增强模型的学习能力,使其在结构保真度和细节重建上具有一定优势;而 DerainCycleGAN 在去雨过程中投入了更多的计算资源和时间,其优化过程使得在 SSIM 指标上表现相对较好。综合对比来看,本文方法尽管在 SSIM 指标上略逊于 Sy2Real 和 DerainCycleGAN,但在 PSNR 和 NIQE 指标上表现出色,同时具备较高的时间效率。实验结果表明,本文方法在实现高质量去雨效果的同时,可以更好地平衡性能指标和时间效率。

表 2 不同方法在真实数据集上的定量比较

Table 2 Quantitative evaluations via using different methods on real-world datasets

方法	Supervision	Rain100L			Rain12			Real100
		PSNR \uparrow	SSIM \uparrow	NIQE \downarrow	PSNR \uparrow	SSIM \uparrow	NIQE \downarrow	NIQE \downarrow
DTCN ^[27]	F	31.31	0.927	4.8606	26.46	0.868	4.7277	3.8177
Syn2Real ^[18]	S	34.13	0.945	4.7079	31.23	0.912	4.7902	4.1671
CycleGAN ^[28]	U	22.49	0.851	5.6793	22.20	0.841	5.1021	4.4733
DerainCycleGAN ^[8]	U	34.12	0.950	4.8436	31.31	0.917	4.8476	3.8143
DCD-GAN ^[17]	U	22.87	0.874	4.8937	21.45	0.785	5.4459	4.1583
Ours	U	34.82	0.940	4.1140	32.59	0.943	4.0866	3.5663

图 4 给出了本文方法与其他方法在真实雨天数据集上的去雨结果视觉对比。为了更加直观地对比各个方法,对实验结果的局部细节信息进行了放大处理。可以观察到,DTCN 与 Syn2Real 能够去除部分雨纹,但是在图像中仍然存在一些

残留的雨纹;CycleGAN 和 DCD-GAN 的去雨效果较差,仍存在大量雨纹残留,并且二者会导致图像颜色失真和模糊;相较于其他方法,本文方法处理得到的图像更加清晰,细节恢复表现更优,体现了其优越性和普适性。




图 4 不同方法在真实雨天数据集上的去雨结果

Fig. 4 Comparison of different deraining methods on real-world rainy images datasets

4.5 时间效率与模型大小对比

为了评估模型在图像去雨任务中的时间效率与模型规模大小,分别选取了1000幅 256×256 和 512×512 的雨天图像进行测试,所有测试均在GPU上进行。本文记录了每种方法的平均运行时间,同时统计了模型的参数量,结果如表3所列。

表3 不同方法的模型大小与时间效率的比较

Table 3 Comparison of model size and time efficiency of different methods

方法	平均时间/s	参数量
DTCN ^[27]	0.021/0.073	2.538×10^7
Syn2Real ^[18]	0.044/0.150	2.261×10^7
CycleGAN ^[28]	0.012/0.025	2.275×10^7
DCycleGAN ^[8]	0.015/0.029	4.358×10^7
DCD-GAN ^[17]	0.016/0.029	2.276×10^7
Ours	0.014/0.026	1.927×10^7

可以看出,本文方法在运行时间方面相较于监督和半监督学习的方法具有明显的优势。在无监督学习方法中,本文方法虽然略次于CycleGAN,但优于大多数对比方法。尽管CycleGAN在运行时间上稍占优势,但本文方法在性能表现上明显更优,这主要归因于本文对模型网络结构的优化,使得其在图像去雨时能够取得更好的效果。此外,本文方法的参数量在对比方法中是最少的,这意味着模型不仅更易于训练和部署,还能降低计算资源需求,提升计算效率。总之,本文

方法在保证较高性能的同时,具备较小的模型参数量,能更好地权衡时间效率。

4.6 消融实验

为了验证本文网络模型中各模块的有效性和优越性,在Rain100L数据集上进行了消融实验。图5给出了不同模型的视觉效果对比,其中,Model-A为将注意力雨纹特征感知模块从本文方法中移除,即直接将输入图像送入生成器,并使用单尺度鉴别器替换多尺度鉴别器;Model-B为仅将注意力雨纹特征感知模块从本文模型中移除;Model-C为将所提网络中的多尺度鉴别器替换为单尺度鉴别器;Model-D为将雨纹特征感知模块中的联合注意力机制移除,模型中的多尺度鉴别器保持不变;Model-E为在Model-D的基础上将多尺度鉴别器替换为单尺度鉴别器。为了公平比较,所有模型测试均保持相同的训练设置。对比不同模型的去雨结果可以观察到,在缺少注意力雨纹特征感知模块的情况下,模型无法精确定位雨纹,从而无法准确地将其去除;使用单尺度鉴别器只能在单一尺度上进行特征的提取和评估,无法同时捕获输入数据的全局和局部特征,导致生成图像对细微的局部纹理和小尺度细节的处理不佳,生成图像的真实感下降;移除注意力雨纹特征感知模块中的联合注意力机制后,去雨图像中存在对雨纹提取不充分和图像细节丢失等问题,导致去雨效果不佳。

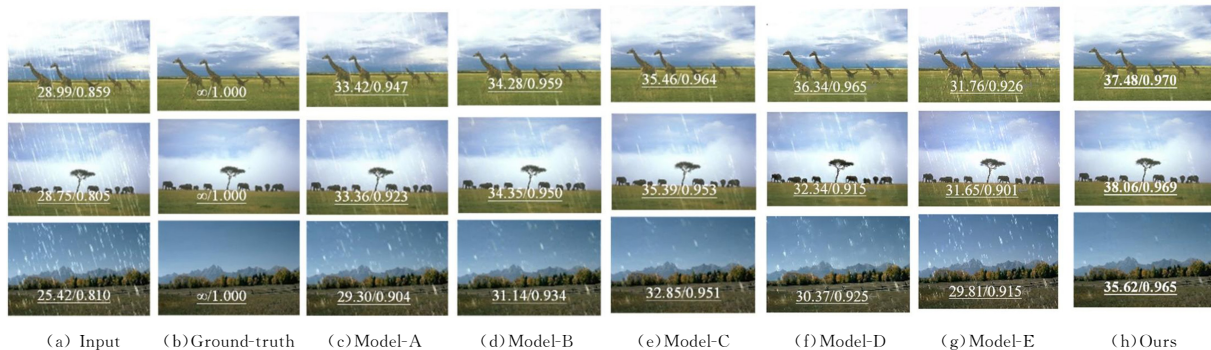


图5 在Rain100L数据集上进行消融实验的去雨结果

Fig. 5 Comparison of deraining results of ablation experiments on Rain100L dataset

不同模型的PSNR,SSIM和NIQE性能指标对比结果如表4所列。可以看出,注意力雨纹特征感知模块和多尺度鉴别器均有助于提升模型的性能指标,缺少其中任何一个模块都会导致模型性能的下降。注意力雨纹特征感知模块中的联合注意力机制显著提升了模型的去雨效果,而在去除注意力雨纹特征感知模块中的联合注意力机制后,模型的性能表现明显下降,证明了联合注意力机制嵌入网络对于提升网络对雨纹特征的感知能力的重要性。

表4 在Rain100L上进行消融实验的定量比较

Table 4 Quantitative evaluations of the ablation study on

Rain100L dataset			
模型	PSNR \uparrow	SSIM \uparrow	NIQE \downarrow
Model-A	29.63	0.906	3.6454
Model-B	30.40	0.926	3.4035
Model-C	31.37	0.936	3.4352
Model-D	31.97	0.941	3.3276
Model-E	30.89	0.935	3.5014
Ours	32.80	0.948	3.2846

提取的图像去雨方法由注意力雨纹特征感知模块、生成器和多尺度鉴别器组成。注意力雨纹特征感知模块分多阶段地提取雨天图像中不同通道和空间位置上的雨纹特征,并将感知到的特征融合后反馈到生成器去除图像中的雨纹;多尺度鉴别器可以在小、中、大3个尺度上对生成图像的全局纹理特征和局部微观细节进行判别,以指导生成器生成更清晰的图像,提升模型的去雨效果。在合成数据集和真实数据集上的实验结果表明,本文方法能够更有效地去除图像中的雨纹并保留图像的细节和结构信息。尽管在对比方法中,本文方法的参数量是最少的,但其与真正的轻量化模型相比仍存在一定差距。本文方法适用于具备一定计算资源的图像去雨任务,难以直接应用在实时性要求高和资源受限的场景中。因此,未来将继续探索模型的压缩优化方案,以实现模型的轻量化,提升其在复杂场景下的适用性和灵活性。

参考文献

[1] ZHAO Z Q,ZHENG P,XU S T,et al.Object detection with

结束语 本文提出的基于联合注意力机制与多阶段特征

- deep learning: A review[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2019, 30(11): 3212-3232.
- [2] YU J, TAN M, ZHANG H Y, et al. Hierarchical deep click feature prediction for fine-grained image recognition [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2022, 44(2): 563-578.
- [3] MARVASTI-ZADEH S M, CHENG L, GHANEI-YAKHDAN H, et al. Deep learning for visual tracking: A comprehensive survey[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(5): 3943-3968.
- [4] 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.
- [5] ZHANG Z, WEI Y Y, ZHANG H J, et al. Data-driven single image deraining: A comprehensive review and new perspectives [J]. *Pattern Recognition*, 2023, 143: 109740.
- [6] MENG X Y, XUE X H, LI W L, et al. Motion-estimation based space-temporal feature aggregation network for multi-frames rain removal[J]. *Computer Science*, 2021, 48(5): 170-176.
- [7] XIE Q Q, ZHANG H, GAI S. Multi-resolution context aggregation network for single image rain removal[J]. *Journal of Computer-Aided Design & Computer Graphics*, 2022, 34(2): 232-244.
- [8] 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.
- [9] CHEN M M, WANG P, SHANG D H, et al. Cycle-attention-derain: Unsupervised rain removal with CycleGAN[J]. *The Visual Computer*, 2023, 39(8): 3727-3739.
- [10] 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.
- [11] DU S L, LIU Y G, YE M, et al. Single image deraining via decorrelating the rain streaks and background scene in gradient domain[J]. *Pattern Recognition*, 2018, 79: 303-317.
- [12] WANG H, XIE Q, ZHAO Q, et al. A Model-Driven Deep Neural Network for Single Image Rain Removal [C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2020: 3103-3112.
- [13] HSU W Y, CHANG W C. Recurrent wavelet structure-preserving residual network for single image deraining [J]. *Pattern Recognition*, 2023, 137: 109294.
- [14] CHEN X, PAN J H, DONG J. Bidirectional Multi-Scale Implicit Neural Representations for Image Deraining [C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2024: 25627-25636.
- [15] QIU Y R, YAO G L, FENG J, et al. Single image de-raining algorithm based on semi-supervised learning[J]. *Journal of Computer Applications*, 2022, 42(5): 1577-1582.
- [16] JIANG N F, LUO J W, LIN J H, et al. Lightweight semi-supervised network for single image rain removal[J]. *Pattern Recognition*, 2023, 137: 109277.
- [17] CHEN X, PAN J S, JIANG K, et al. Unpaired Deep Image Deraining Using Dual Contrastive Learning [C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2022: 2017-2026.
- [18] YASARLA R, SINDAGI V A, PATEL V M. Syn2real Transfer Learning for Image Deraining Using Gaussian Processes [C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2020: 2726-2736.
- [19] YE Y T, YU C F, CHANG Y, et al. Unsupervised Deraining: Where Contrastive Learning Meets Self-Similarity [C] // *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2022: 5821-5830.
- [20] WEN Y B, GAO T, CHEN T. Neural schrödinger bridge for unpaired real-world image deraining [J]. *Information Sciences*, 2024, 682: 121199.
- [21] YANG W H, TAN R T, FENG J S, et al. Deep Joint Rain Detection and Removal from a Single Image [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2017: 1357-1366.
- [22] HU J, SHEN L, SUN G. Squeeze-and-Excitation Networks [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2018: 7132-7141.
- [23] JADERBERG M, SIMONYAN K, ZISSERMAN A, et al. Spatial transformer networks [C] // *Proceedings of the 29th International Conference on Neural Information Processing Systems*. 2015: 2017-2025.
- [24] LI Y, TAN R T, GUO X J, et al. Rain Streak Removal Using Layer Priors [C] // *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2016: 2736-2744.
- [25] WANG T Y, 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*. 2019: 12270-12279.
- [26] GUO Y, XIAO X Y, CHANG Y, et al. From Sky to the Ground: A Large-Scale Benchmark and Simple Baseline Towards Real Rain Removal [C] // *Proceedings of the IEEE/CVF International Conference on Computer Vision*. 2023: 12097-12107.
- [27] ZHANG H, JIA D L, HAN Z X. Dual-task complementary networks for single-image deraining [J]. *Signal, Image and Video Processing*, 2023, 17(8): 4171-4179.
- [28] ZHU J Y, PARK T, ISOLA P, et al. Unpaired Image-to-Image Translation Using Cycle-Consistent Adversarial Networks [C] // *Proceedings of the IEEE International Conference on Computer Vision*. 2017: 2223-2232.



LIN Zukai, born in 2000, postgraduate, is a member of CCF (No. U6520G). His main research interest is image processing.



HOU Guojia, born in 1986, Ph.D, associate professor, master supervisor, is a member of CCF (No. 76713M). His main research interests include image processing and pattern recognition.