

SynFSNet: 频域与空间域协同建模的图像去雨网络

李亚敏^{1,2,3}, 向稳^{1,2,3}, 刘钰婷^{1,2,3}, 向尧^{1,4}

(1. 湖北大学计算机学院, 湖北 武汉 430062; 2. 智能感知系统与安全教育部重点实验室, 湖北 武汉 430062;

3. 大数据智能分析与行业应用湖北省重点实验室(湖北大学), 湖北 武汉 430062;

4. 武汉理工大学计算机与人工智能学院, 湖北 武汉 430070)

摘要: 图像去雨旨在从受雨迹干扰的退化图像中恢复高质量的无雨图像, 是提升户外视觉系统鲁棒性的关键技术。现有基于卷积神经网络(CNN)的方法受限于局部感受野, 难以有效建模长程依赖关系; 部分基于Transformer的方法虽增强了全局建模能力, 但对复杂雨迹的多尺度、方向性及局部高频细节恢复仍存在不足; 已有频域增强方法也多将频域作为辅助表示手段, 缺乏针对空间域与频域互补关系的细粒度协同建模。为此, 本文提出了一种频域与空间域协同建模的图像去雨网络(SynFSNet)。不同于现有方法主要将频域作为全局增强工具, 本文从雨迹在频域中的方向性、密度性和尺度变化出发, 通过多尺度傅里叶融合模块(MSFFM)实现由粗到细的渐进式雨迹抑制, 并通过傅里叶形状注意模块(FSAM)中的矩形滤波器注意力(RFA)和方形滤波器注意力(SFA)分别增强方向敏感与局部结构敏感的频域表示。进一步地, 网络通过双域损失函数同时约束空间域结构与频域一致性, 以提升复杂场景下的恢复质量。实验结果表明, SynFSNet 在多个合成数据集和真实场景数据集上均取得了较优性能, 验证了频域与空间域协同建模在复杂图像去雨任务中的有效性。

关键词: 图像去雨; 频域特征; 多尺度傅里叶融合; 滤波器注意力; 傅里叶变换

中图分类号: TP391

文献标志码: A

DOI: 10.19678/j.issn.1000-3428.0253484

SynFSNet: Synergizing Frequency Domain and Spatial Domain Modeling Network for Image Deraining

LI Yamin^{1,2,3}, XIANG Wen^{1,2,3}, LIU Yuting^{1,2,3}, XIANG Yao^{1,4}

(1. School of Computer Science, Hubei University, Wuhan 430062, Hubei, China;

2. Key Laboratory of Intelligent Sensing System and Security, Ministry of Education, Wuhan 430062, Hubei, China;

3. Hubei Key Laboratory of Big Data Intelligent Analysis and Application, Hubei University, Wuhan 430062, Hubei, China;

4. School of Computer Science and Artificial Intelligence, Wuhan University of Technology, Wuhan 430070, Hubei, China)

【Abstract】 Image deraining aims to restore high-quality clean images from rain-degraded inputs and is a key technique for improving the robustness of outdoor vision systems. Existing Convolutional Neural Network (CNN)-based methods are limited by local receptive fields and thus struggle to effectively model long-range dependencies. Although some Transformer-based methods enhance global modeling capability, they show limited ability in handling multi-scale and directional rain streaks as well as recovering local high-frequency details. Moreover, existing frequency-domain enhancement methods often treat the frequency domain merely as an auxiliary representation, which lack fine-grained collaborative modeling of the complementary relationship between the spatial and frequency domains. To address these issues, this study proposes a Synergizing Frequency and Spatial Network (SynFSNet) for image deraining. Unlike existing methods that primarily use the frequency domain as a global enhancement tool, the proposed method uses the directional, density-related, and scale-varying characteristics of rain streaks in the frequency domain. Specifically, a Multi-Scale Fourier Fusion Module (MSFFM) is designed to progressively suppress rain streaks in a coarse-to-fine manner. Additionally, a Fourier Shaped Attention Module (FSAM) is introduced in which Rectangular Filter Attention (RFA) and Square Filter Attention (SFA) are used to enhance direction-sensitive and local-structure-sensitive frequency-domain representations, respectively. Furthermore, a dual-domain loss is employed to jointly constrain spatial structural restoration and frequency-domain consistency, thereby improving restoration quality in complex scenes. Experimental results show that SynFSNet achieves superior performance on multiple synthetic and real-world datasets, verifying the effectiveness of collaborative spatial-frequency domain modeling for complex image deraining tasks.

【Key words】 image deraining; frequency-domain feature; multi-scale Fourier fusion; filter attention; Fourier transform

基金项目: 湖北省自然科学基金面上项目(JCZRYB202501223)。

作者简介: 李亚敏(CCF 专业会员), 女, 副教授、博士, 主研方向为计算机视觉、图像处理; 向稳、刘钰婷, 硕士研究生; 向尧(通信作者), 讲师、博士。

收稿日期: 2025-12-25

修回日期: 2026-05-16

E-mail: hbycxiangyao@163.com

0 引言

在恶劣天气条件下,采集图像的视觉质量往往显著下降,特别是包含雨迹的图像,这对目标检测、图像分割等下游计算机视觉任务会产生不利影响^[1-2]。因此,图像去雨技术已成为自动驾驶、视频监控、遥感等领域中至关重要的图像预处理步骤^[3-5]。传统的单幅图像去雨方法主要包括基于模型的优化方法与手工设计滤波器^[6]。然而,这些方法在处理复杂雨迹形态和非均匀降雨情况时效果较差^[7-8]。此外,它们常依赖于难以准确估计的物理先验参数,例如环境光强度和降雨强度^[9],从而限制了其在不同场景中的泛化能力。

随着深度学习的迅速发展,卷积神经网络(CNN)通过学习从雨迹退化图像到清晰图像的有效映射,显著提升了单幅图像去雨的性能^[10-12]。然而,CNN 的有限感受野及其局部性操作限制了其对长距离依赖关系的建模能力,基于 Transformer 的方法通过建模非局部交互缓解了这一问题^[13-14]。有些基于 Transformer 的图像恢复方法缺乏频域建模,削弱了对细粒度雨纹的去除能力,并且影响了其在复杂场景中的适应性^[15]。部分基于 Transformer 的图像恢复方法已开始引入频域信息,以增强全局建模和频谱表示能力。然而,现有方法多侧重于将频域作为全局增强或辅助表示手段,对于复杂雨迹的多尺度、方向性及局部细节恢复仍存在不足,尤其缺乏针对空间域与频域互补关系的细粒度协同建模。因此,为了克服这些限制,基于傅里叶变换的相关方法逐渐受到关注,这些方法利用频域表征来有效分离图像内容与雨迹引入的噪声^[16-17]。不同类型的雨迹呈现出独特的频率特征,这有助于在空间域与频域中区分雨迹与内容。傅里叶变换能够提取雨迹的方向与密度信息,并通过频谱处理实现内容与噪声的有效分离,同时能够进行长距离依赖建模。因此,基于傅里叶变换的策略被广泛引入 CNN 和 Transformer 中来提升全局特征建模能力,例如快速傅里叶卷积(FFC)^[18]。然而,这类方法仍可能忽略细粒度的空间细节,比如雨迹方向和背景纹理。

为了解决上述问题,本文提出了一种新型高性能图像去雨网络——频域与空间域协同网络(SynFSNet)。通过在频域和空间域的联合建模,SynFSNet 能够有效捕获互补的全局与局部特征,从而去除多样化的雨迹退化。SynFSNet 主要由两个核心模块组成:多尺度傅里叶融合模块(MSFFM)和傅里叶形状注意模块(FSAM)。在

MSFFM 中,本文采用了多分支架构,每个分支首先通过平均池化实现多尺度下采样,再通过卷积提取局部特征。FSAM 被集成到每个分支中来增强频域特征表示能力。随后,将各分支特征进行上采样和融合,最终实现高效的全局-局部联合建模。为有效处理频域中多样化的雨迹,FSAM 引入了矩形滤波器注意力(RFA)和方形滤波器注意力(SFA),它们能够在不同形状和尺度上增强频域特征表示,从而实现雨迹特征更全面的提取。

本文的主要贡献可以总结为以下几点:

1)提出了一种频域与空间域协同建模的图像去雨框架 SynFSNet,其能有效利用双域互补信息的优势,从而显著提升雨迹去除性能。

2)设计了 MSFFM,以此实现空间域与频域的联合建模。该模块通过多分支表示学习和多尺度特征聚合,能够有效捕获全局上下文信息和精细局部细节,这对于高精度去雨至关重要。

3)设计了 FSAM,其中引入了基于多种形状滤波器的注意力机制。该设计能够在频域中自适应地建模不同模式与尺度的雨迹,从而增强频谱特征的学习能力。

1 相关工作

1.1 单幅图像去雨

早期的单幅图像去雨方法主要依赖手工设计的先验,侧重于雨迹特征的提取,但往往忽视了清晰图像中的宝贵信息,这使得优化过程变得复杂^[19]。CNN 方法的出现极大地推动了该领域的发展,它们通过减少图像偏差并提升恢复质量,实现了更高效的去雨处理^[20]。具有代表性的方法包括 MSPFN^[21]和 RCDNet^[22],它们分别引入了多尺度特征融合、强泛化能力以及上下文引导机制。然而,CNN 仍受到有限感受野的制约,无法有效建模长距离的依赖关系。近年来,基于 Transformer 的模型通过自注意力机制展现出了强大的全局建模能力,同时研究者也提出了一些改进方法来进一步提升其性能,如前馈神经网络(FFN)增强或与 CNN 结合^[16,23-24]。尽管如此,其高昂的计算成本仍限制了效率。为应对这些挑战,本文提出了一种新型双域方法,通过协同建模空间特征与频域特征,有效提取全局与局部的雨迹模式,从而显著提升去雨性能。

1.2 基于傅里叶变换的图像去雨方法

傅里叶变换是频域分析中的核心技术,广泛应用于各种领域,能够有效建模信号的全局特性^[25-27]。在图像恢复任务中,傅里叶变换被证明具有特别重

要的价值。例如: FSDGN^[28]展示了傅里叶幅值在捕捉全局雾霾特征方面的能力; FADformer^[16]利用频域特征建模雨迹的密度和方向; SFHformer^[29]通过引入频率特定的位置编码, 进一步增强了频谱特征的表示能力; SFDFormer^[30]利用频率解耦模块建立频域和空间域像素之间的对应关系, 能够直接从原始图像中提取裂缝边缘和区域信息。

尽管傅里叶变换在信号建模中具有巨大的潜力, 但这一潜力仍未得到充分挖掘。与以往的工作不同, 现有频域 Transformer 主要将傅里叶变换或频域分支作为全局建模工具, 本文更关注图像去雨任务中雨迹在频域上的方向性、密度性和尺度变化, 并通过 MSFFM 和 FSAM 构建空间域与频域之间的协同建模机制。其中, MSFFM 采用由粗到细的渐进式多尺度建模策略, FSAM 则通过 RFA 和 SFA 分别增强方向敏感和局部结构敏感的频域表示, 从而提升模型在复杂雨纹场景下的恢复能力。

2 频域与空间域协同的图像去雨网络

本章首先介绍 SynFSNet 的整体架构; 随后, 详细讲解了所提出的 CFFBlock 的核心组件, 包括 MSFFM、FSAM, 以及 FSAM 中的两个子模块: RFA 和 SFA; 最后, 介绍本工作中所采用的双域引导损失函数。

2.1 网络结构

SynFSNet 总体框架如图 1 所示(彩色效果见

《计算机工程》官网 HTML 版, 下同)。该网络采用三阶段的 U 形结构, 具有对称的编码器和解码器组件, 特征从上到下逐层提取, 实现单图像去雨的信息融合。具体来说, 给定一个任意的雨天输入图像 $X \in \mathbb{R}^{H \times W \times 3}$, 编码器首先应用一个卷积核为 3×3 的卷积层进行下采样, 并生成大小为 $\frac{H}{2} \times \frac{W}{2} \times C$ 的浅层特征, 其中, C 表示通道数, $\frac{H}{2} \times \frac{W}{2}$ 表示空间分辨率。随后, 浅层特征通过 3 个 CFFBlock 得到深层表示。每个 CFFBlock 包含多个残差块, 并且 MSFFM 被嵌入到最后一个残差块中。在此过程中, 通道数逐渐增加, 同时空间分辨率逐步减小。此外, MSFFM 集成了多个下采样的特征图, 这些特征图通过 FSAM 模块处理, 以增强多尺度频率特征学习。为了更好地处理形状各异的雨条纹, 在每个尺度中引入了 RFA 和 SFA, 通过由粗到细的方式逐步去除雨条纹。在编码器中, 还采用了 2 个多深度卷积(MDConv)模块, 从不同下采样的退化图像 $X_1 \in \mathbb{R}^{\frac{H}{2} \times \frac{W}{2} \times 3}$ 和 $X_2 \in \mathbb{R}^{\frac{H}{4} \times \frac{W}{4} \times 3}$ 中提取特征, 通过卷积操作逐步增加通道数。解码器的结构和配置与编码器相同。在训练过程中, 解码器采用多输出策略以增强监督学习。此外, 为了减少下采样过程中的信息损失, 在编码器和解码器之间引入了跳跃连接, 有效地弥合了低频特征和高频特征之间的差距, 从而实现更全面的特征融合。




图 1 SynFSNet 总体框架

Fig. 1 Overall framework of SynFSNet

2.2 多尺度傅里叶融合模块

为了实现高效的多尺度特征学习, 设计了一个

单一的 U 形 MSFFM 模块。该模块采用多分支结构, 每个分支通过平均池化获得不同尺度的特征, 然

后通过卷积操作提取局部表示。为了增强频域特征建模能力,FSAM 被集成到每个分支中。在上采样后,各分支的特征空间被对齐至原始分辨率并进行融合。MSFFM 模拟了一个渐进式的多阶段去雨过程。最终各分支的输出通过逐元素求和进行聚合。为了在 SynFSNet 中平衡计算成本与模型参数量,本文采用了 3 个下采样分支,下采样率分别为 2, 4, 8, 记为 $i \in \{1, 2, 3\}$, 此外还保留一个恒等映射分支。MSFFM 的整体公式定义如下:

$$\hat{F}_i = \begin{cases} \text{FSAM}(\text{AP}_{2^i}(\mathbf{F}) + \hat{F}_{i+1} \uparrow_{2^i}), & i < 3 \\ \text{FSAM}(\text{AP}_{2^i}(\mathbf{F})), & i = 3 \end{cases} \quad (1)$$

$$\mathbf{F}_{\text{out}} = \text{add}(\mathbf{F}, \hat{F}_1 \uparrow_2, \hat{F}_2 \uparrow_4, \hat{F}_3 \uparrow_8) \quad (2)$$

式中: $\mathbf{F}$ 表示输入特征; AP_{2^i} 表示下采样率为 2^i 的平均池化; $\uparrow_2$ 表示上采样率为 2 的双线性插值。

2.3 傅里叶形态注意力模块

Transformer 模型在图像去雨任务中已经取得了良好的效果,然而,其自注意力机制所带来的平方级计算复杂度仍然是一个尚未解决的重要限制因素。相反,CNN 在提取局部图像特征方面具有优势,但在捕获全局上下文信息以及处理空间变化显著的雨条纹时存在困难。为克服这些限制,本文提出一种统一框架,协同利用空间域与频域特征,实现对多样化雨条纹特性的全面建模。该双域策略能够有效融合局部与全局特征,有助于提高雨条纹的去除效果。快速傅里叶变换(FFT)具有以下 3 个主要优势。首先,它能够将图像分解为不同的频率成分,而雨条纹通常在频域中表现为显著且相对稳定的特征。其次,FFT 本质上能够作为全局特征提取器,通过对频域成分的计算来捕获整体上下文信息。最后,将 FFT 应用于 MSFFM 各分支中,可促进有效的多尺度全局特征表示学习。因此,本文提出了 FSAM,并将其集成到 MSFFM 的各个分支中,以增强频域特征的建模与精细化处理能力。

2.4 傅里叶频域信息

频域侧重于捕获频率特征,并能够对整个图像进行全局建模。傅里叶变换广泛应用于图像频率特征的分析,下文简要介绍傅里叶频域信息。给定输入图像 $X \in \mathbb{R}^{H \times W \times C}$, FFT 是一种将信号从其原始域(通常是时间或空间)转换为频域表示的数学技术,反之亦然,通过逆快速傅里叶变换(IFFT)实现。对于大小为 $H \times W$ 的单通道图像 X , X 的二维快速傅里叶变换(2D FFT)定义为:

$$\mathcal{F}(\mu, \nu) = \frac{1}{\sqrt{HW}} \sum_{h=0}^{H-1} \sum_{w=0}^{W-1} X(h, w) e^{-j2\pi(\frac{h}{H}\mu + \frac{w}{W}\nu)} \quad (3)$$

式中, μ 和 ν 表示傅里叶空间中的坐标。频域中的每个频率成分与空间域中一组特定的像素紧密相关,因此需要对每个成分进行差异化处理。为了增强在各种退化情况下的频率特征提取,引入了两个关键组件:形态注意力模块(SAM)和动态加权和运算(DWSO)。SAM 集成了 RFA 和 SFA 来增强多形态和多尺度的频率特征表示,从而促进更丰富频率信息的提取。

具体来说,如图 1(e)所示,输入特征 X 首先经过二维快速傅里叶变换 $\mathcal{F}(X)$, 得到复值频域特征。这些特征被分解为实部 $\mathbf{F}_R \in \mathbb{R}^{H \times W \times C}$ 和虚部 $\mathbf{F}_I \in \mathbb{R}^{H \times W \times C}$ 。不独立处理实部和虚部,而是沿通道维度将实部 $\mathbf{F}_R$ 和虚部 $\mathbf{F}_I$ 进行聚合,得到联合频域特征 $\mathbf{F}_S \in \mathbb{R}^{H \times W \times 2C}$ 。随后,应用具有 $2C$ 输出通道的批归一化(BN)对联合频率表示 $\mathbf{F}_S$ 进行归一化,以确保特征分布的稳定性。归一化后的特征随后依次通过 RFA 和 SFA 模块,从而实现频域特征表示的逐步增强。SAM 的具体形式可表示为:

$$\mathbf{F}_{\text{SAM}}(X) = \text{RFA}(\text{BN}(X)) + \text{SFA}(\text{BN}(X)) \quad (4)$$

1) RFA 模块。

为了改善具有多样空间形状特征的表示,提出了 RFA 模块。如图 2 所示,该模块通过结合沿正交轴的方向信息,集成了多形态特征表示,旨在增强具有明确方向性的频域特征,特别是处理条带状、方向性强的雨迹时具有显著效果。然而,固定的矩形滤波器对于倾斜雨迹的响应可能会有所下降,因为倾斜的雨条纹在频域中呈现出非对称的分布,固定的矩形滤波器难以完全捕捉到这些频谱特征。为此,同时利用水平和垂直方向的矩形滤波器,可以有效适应不同倾斜雨迹的情况,能够捕捉更多雨迹方向性特征,减少背景冗余信息的干扰。具体来说,RFA 模块首先使用一个轻量级卷积子网络生成初始的注意力权重。接着,这些权重通过水平和垂直矩形滤波器进行细化,以增强不同形态特征的表示能力。这些经过滤波的权重会自适应地应用于调节输入特征,随后通过卷积操作进行处理,从而实现最终的特征聚合。传统的自注意力机制通常使用 Softmax 函数对注意力权重进行归一化^[31]。然而,这种归一化实际上起到了低通滤波器的作用,从而抑制了高频成分。而这种抑制在图像去雨任务是次优的,因为高频细节对于有效区分雨条纹和底层干净结构至关重要^[32]。

为克服这一限制,提出了注意力权重生成优化策略。首先,将传统的 Softmax 归一化替换为双曲




图 2 矩形滤波器注意力模块

Fig.2 Rectangle filter attention module

正切(tanh)激活函数,这样可以避免低通滤波的约束,并允许注意力权重在 $(-1, 1)$ 范围内变化,从而增强了对无关像素的抑制效果;其次,使用方向性矩形滤波器来增强高频成分。这一设计有助于学习更具辨别性和形态感知的注意力,从而提升图像去雨的效果。形式上,给定输入特征图 $X \in \mathbb{R}^{H \times W \times C}$,注意力权重的生成定义如下:

$$\mathbf{A}^{\text{RFA}} = \sigma(\text{Conv}(\text{BN}(\text{GAP}(X)))) \quad (5)$$

式中: σ 表示 Tanh 激活函数;GAP 表示全局平均池化,BN 表示批归一化。

为了在注意力权重的复杂性和多样性之间实现平衡,对特征图 $\mathbf{A}^{\text{RFA}}$ 应用了分组注意力。具体而言, $\mathbf{A}^{\text{RFA}}$ 被分解为低通和高通频域滤波器。随后,使用可学习的通道级参数对高通滤波器进行重新加权,以突出重要的频率细节。在实验中,低通和高通频率注意力权重是从 $\mathbf{A}^{\text{RFA}}$ 中提取的,具体过程如下:

$$\mathbf{A}_L^{\text{RFA}} = \frac{1}{K^2} \mathbf{E}; \mathbf{A}_H^{\text{RFA}} = \mathbf{A}^{\text{RFA}} - \mathbf{A}_L^{\text{RFA}} \quad (6)$$

$$\tilde{\mathbf{A}}^{\text{RFA}} = \alpha \mathbf{A}_H^{\text{RFA}} + \mathbf{A}_L^{\text{RFA}} \quad (7)$$

式中: $\mathbf{E} \in \mathbb{R}^{C \times H \times W}$ 与 $\mathbf{A}^{\text{RFA}}$ 具有相同的形状,并且所有元素均设置为 1; K^2 表示集成区域的绝对大小; α 表示通过反向传播直接优化的可学习参数; $\tilde{\mathbf{A}}^{\text{RFA}}$ 表示增强的注意力加权特征图。

最后,将获得的注意力权重通过卷积操作应用于输入特征,其中,对输入像素在水平和垂直矩形模式下进行采样,以更好地适应去雨图像中雨条纹形状的变化。水平和垂直方向上加权后的输出特征图计算如下:

$$\hat{X}_V^{\text{RFA}} = \sum_{j=0}^{K-1} X_{g,h,(w-\frac{K}{2}+j)} \tilde{\mathbf{A}}_{g,j}^{\text{RFA}} + X_{g,h,w} \quad (8)$$

$$\hat{X}_H^{\text{RFA}} = \sum_{j=0}^{K-1} X_{g,(h-\frac{K}{2}-j),w} \tilde{\mathbf{A}}_{g,j}^{\text{RFA}} + X_{g,h,w} \quad (9)$$

$$\hat{X}^{\text{RFA}} = \hat{X}_H^{\text{RFA}} + \hat{X}_V^{\text{RFA}} \quad (10)$$

式中: g, h 和 w 分别表示组、行和列; $\tilde{\mathbf{A}}^{\text{RFA}}$ 是注意力

图; $\hat{X}_V^{\text{RFA}}$ 表示垂直方向的注意力; $\hat{X}_H^{\text{RFA}}$ 表示水平方向的注意力; $\hat{X}^{\text{RFA}}$ 表示 RFA 的输出。

2) SFA 模块。

为了增强频域特征的学习能力,并适应图像中雨条纹的多样形状和大小,提出了 SFA 模块。该模块主要用于增强局部尺度敏感的频域特征,对局部变化较大的雨迹具有较强的适应性。它适合处理频谱变化较小、分布较为紧凑的雨纹,能够更好地恢复这些类型的雨条纹。如图 3 所示,SFA 与 RFA 类似,首先使用卷积网络生成初步的注意力权重。随后,通过 SFA 对高通频率滤波器进行重新加权,从而细化这些权重。接着,调整后的注意力权重会自适应地与输入特征对齐,根据输入特征进行自适应匹配,最后通过卷积操作进行特征聚合。输入特征为 $X \in \mathbb{R}^{C \times H \times W}$,SFA 输出的特征图可以按如下方式计算:

$$\hat{X}^{\text{SFA}} = \sum_{i=0}^{K-1} \sum_{j=0}^{K-1} X_{g,(h-\frac{K}{2}+j),(w-\frac{K}{2}+j)} \tilde{\mathbf{A}}_{g,j}^{\text{SFA}} + X_{g,h,w} \quad (11)$$

式中: g, h 和 w 分别表示组、行和列; $\tilde{\mathbf{A}}$ 是注意力图; $\hat{X}^{\text{SFA}}$ 表示 SFA 的输出。




图 3 方形滤波器注意力

Fig.3 Square filter attention

根据上述描述,RFA 主要用于增强方向敏感的频域表示,更适合建模具有条带状结构、方向性较强的雨迹模式。由于雨条纹在频域中通常呈现出沿特定方向分布的能量响应,RFA 通过水平和垂直矩形滤波器对该类方向性频率成分进行选择增强,从而提高网络对方向性雨纹的辨识能力。相比之下,SFA 更侧重于增强局部结构敏感的频域表示,适合补充对局部尺度变化较为明显、分布较为紧凑的雨纹模式的建模能力。两者并非针对某一种固定形状雨迹进行机械划分,而是在频域响应模式上形成互补,RFA 突出方向性建模,SFA 补充局部结构建模,从而共同提升 FSAM 对复杂雨纹的表征能力。

2.5 双域损失函数

考虑到雨条纹图像的空间域和频域特征之间的固有差异,本文融合了两个不同域中的损失函数优势。双域损失函数包括空间域损失函数和频域损失

函数两个主要组成部分,具体如下:

$$L_{\text{spatial}} = \hat{I} - Y_1 \quad (12)$$

$$L_{\text{frequency}} = [R(\hat{I}), I(\hat{I})] - [R(Y), I(Y)]_1 \quad (13)$$

$$L_{\text{total}} = L_{\text{spatial}} + \lambda L_{\text{frequency}} \quad (14)$$

式中: $\hat{I}$ 和 Y 分别表示恢复后的图像和真实值; R 和 I 分别是由 FFT 生成的实部和虚部; λ 被用作平衡因子,以协调双域学习过程。

3 实验结果与分析

3.1 实验参数设置

本文基于 PyTorch 框架实现了 SynFSNet 模型,并在 NVIDIA RTX 4090 GPU 上进行训练。该网络采用三阶段的 U 形架构,结合了对称的编码器-解码器设计,通道维度为 {32, 64, 128, 128, 64, 32}。在训练过程中,使用了 AdamW^[33] 优化器,初始学习率为 1×10^{-4} ,通过余弦退火调度^[34] 将学习率自适应地减少至 1×10^{-5} 。模型总共进行了 30 万次迭代,批量大小为 8。本文中所有对比方法的性能数据通过以下两种途径获取:对于在相同数据集上已有广泛认可结果的方法,直接引用原论文中报告的数值;对于未在目标数据集上报告结果的方法,采用该对比方法在相同的实验参数环境和硬件设备上训练与测试,确保实验条件的一致性与公平性。

3.2 评估指标

模型性能通过两个标准图像质量指标进行定量评估:峰值信噪比 (PSNR)^[35] 和结构相似性指数 (SSIM)^[36]。PSNR 和 SSIM 评价指标的详细描述如下。

1) PSNR。PSNR 是一个常用的指标,在本文中用于评估去雨图像 I_{out} 和真实图像 I_{gt} 之间对应像素的相似性。 $E_{\text{MSE}}(I_{\text{out}}, I_{\text{gt}})$ 表示去雨图像与真实图像之间的均方误差。更高的 PSNR 值表示更好的去雨图像质量。PSNR 数学表达式如下所示:

$$P_{\text{PSNR}}(I_{\text{out}}, I_{\text{gt}}) = 10 \lg \left(\frac{255^2}{E_{\text{MSE}}(I_{\text{out}}, I_{\text{gt}})} \right) \quad (15)$$

2) SSIM。在本文中,SSIM 基于 3 个组成部分:亮度、对比度和结构,用于评估去雨图像 I_{out} 与真实图像 I_{gt} 之间的相似性,其值范围为 0~1,较高的 SSIM 值表示更好的去雨图像质量。SSIM 数学表达式如下所示:

$$S_{\text{SSIM}}(I_{\text{out}}, I_{\text{gt}}) = \frac{(2\mu_{I_{\text{out}}} \mu_{I_{\text{gt}}} + \delta_1)(2\sigma_{I_{\text{out}} I_{\text{gt}}} + \delta_2)}{(\mu_{I_{\text{out}}}^2 + \mu_{I_{\text{gt}}}^2 + \delta_1)(\sigma_{I_{\text{out}}}^2 + \sigma_{I_{\text{gt}}}^2 + \delta_2)} \quad (16)$$

式中: $\mu_{I_{\text{out}}}$ 、 $\mu_{I_{\text{gt}}}$ 、 $\sigma_{I_{\text{out}}}$ 和 $\sigma_{I_{\text{gt}}}$ 分别表示去雨图像和真实图像的均值和标准差; δ_1 和 δ_2 是用于防止除以 0

的常数。

3.3 数据集

本文在多个公开基准数据集上进行了图像去雨实验,包括 Rain200L/H^[37]、DID-Data^[38] 和 DDN-Data^[39]。Rain200L 和 Rain200H 包含 1 800 张合成的雨天图像用于训练,剩余的 200 张用于测试。DID-Data 和 DDN-Data 分别包含 12 000 和 12 600 张具有不同雨条纹方向和密度的合成图像用于训练,剩余的 1 200 张和 1 400 张雨天图像用于测试。此外,还使用了大规模的真实世界数据集 SPA-Data^[40] 来训练 SynFSNet 模型,其中,训练数据集包含 638 492 张成对图像,测试数据集包含 1 000 张成对图像。

3.4 结果分析

1) 在合成数据集上的结果分析。

表 1 前 4 列给出了各方法在 Rain200L、Rain200H、DID-Data 和 DDN-Data 上的定量比较结果,其中,最优数据加粗标示,次优数据以下划线标示,下同。SynFSNet 在 DID-Data 和 DDN-Data 上均取得最优结果。在 DID-Data 上, SynFSNet 的 PSNR 达到 36.32 dB,比次优方法 PW-FNet-L 领先了 0.78 dB, SSIM 达到 0.969 3,同样优于所有对比方法;在 DDN-Data 上, SynFSNet 的 PSNR 达到 35.61 dB, SSIM 达到 0.967 4,均领先所有对比方法。这两个数据集图像包含复杂的空间变化雨纹,而本文方法对复杂非均匀雨纹具有更强的适应能力,这得益于所提出的空间域与频域协同建模机制能够更充分地挖掘多尺度、多方向雨纹特征。在 Rain200L 和 Rain200H 上, SynFSNet 的 PSNR 分别为 42.06 dB 和 32.64 dB,与最优方法 PW-FNet-L 的差距仅为 0.17 dB 和 0.24 dB,性能高度接近,表明 SynFSNet 在相对标准化的合成雨纹场景下同样具备较高的恢复能力。如图 4 所示,不同类型雨迹具有差异化的频率特征,有助于从空间域和频域两个层面对雨迹成分与图像内容进行区分。如图 5 所示, SynFSNet 在 4 个合成数据集上均表现出较强的竞争力,尤其在复杂雨纹场景下优势更加明显。综合 4 个合成数据集的表现可以看出, SynFSNet 并非仅在单一数据集上取得局部优势,而是在不同雨纹复杂度和退化模式下均保持了稳定且优异的性能,体现出较好的鲁棒性与泛化性。

2) 在真实世界数据集上的结果分析。

表 1 的第 5 列给出了各方法在 SPA-Data 上的定量结果比较。SynFSNet 在该数据集上取得了 50.62 dB 的 PSNR 和 0.995 3 的 SSIM,均领先所

表 1 合成数据集和真实世界数据集上的定量结果比较

Table 1 Comparison of quantitative results on synthetic and real-world datasets

Methods	Rain200L		Rain200H		DID-Data		DDN-Data		SPA-Data		Complexity	
	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM	PSNR/dB	SSIM	Params/ 10^6	FLOPs/ 10^9
RESCAN ^[41]	36.09	0.969 7	26.75	0.835 3	31.94	0.934 5	33.38	0.941 7	38.11	0.970 7	0.15	32.12
PReNet ^[42]	37.80	0.981 4	29.04	0.899 1	32.60	0.945 9	33.17	0.948 1	40.16	0.981 6	<u>0.17</u>	66.25
MSPFN ^[21]	38.58	0.982 7	29.36	0.903 4	32.99	0.933 3	33.72	0.955 0	43.43	0.984 3	20.89	595.50
RCDNet ^[22]	39.17	0.988 5	30.24	0.904 8	33.04	0.947 2	34.08	0.953 2	43.36	0.983 1	2.96	194.50
MPRNet ^[43]	39.47	0.982 5	30.67	0.911 0	33.10	0.934 7	33.99	0.959 0	43.64	0.984 4	3.64	548.70
SPDNet ^[44]	40.50	0.987 5	31.28	0.920 7	33.15	0.945 7	34.57	0.956 0	43.20	0.987 1	2.98	96.29
Uformer ^[13]	40.20	0.986 0	30.80	0.910 5	33.95	0.954 5	35.02	0.962 1	46.13	0.991 3	20.60	41.09
Restormer ^[45]	40.99	0.989 0	32.00	0.932 9	34.20	0.957 1	35.29	0.964 1	47.98	0.992 1	26.10	141.00
IDT ^[24]	40.74	0.988 4	32.10	0.934 4	33.84	0.954 9	34.89	0.962 3	47.35	0.993 0	16.39	58.44
HCT-FFN ^[46]	39.70	0.985 0	31.51	0.910 0	33.00	0.950 2	33.96	0.959 2	45.79	0.989 8	0.87	80.25
DRSformer ^[23]	41.23	0.989 4	32.17	0.932 6	34.35	0.958 8	35.35	0.964 6	48.54	0.992 4	33.70	242.90
FADformer ^[16]	41.80	0.990 6	32.48	0.935 9	34.42	0.960 2	<u>35.48</u>	<u>0.965 9</u>	49.21	0.993 4	6.95	48.51
SFHformer ^[29]	41.85	0.990 8	32.33	<u>0.935 1</u>	35.44	0.965 5	35.38	0.965 7	<u>50.11</u>	<u>0.994 2</u>	7.63	50.59
DeRainMamba ^[47]	41.71	0.989 9	32.63	<u>0.939 7</u>	35.52	0.964 2	34.43	0.958 1	—	—	27.79	—
PW-FNet-L ^[48]	42.23	0.991 5	32.88	0.941 3	<u>35.54</u>	<u>0.966 3</u>	34.38	0.960 6	49.79	0.993 6	1.44	<u>33.56</u>
SynFSNet (Ours)	<u>42.06</u>	<u>0.991 2</u>	32.64	0.937 6	36.32	0.969 3	35.61	0.967 4	50.62	0.995 3	16.90	121.65



图 4 频域视角与雨条纹退化现象的分析

Fig. 4 Analysis of frequency-domain perspective and rain streak degradation phenomena

有对比方法。其中,相比次优方法 SFHformer,PSNR 提升了 0.51 dB;相比 FADformer 和 PW-FNet-L, PSNR 分别提升了 1.41 dB 和 0.83 dB。真实场景中的雨纹往往同时伴随背景纹理干扰、照明变化以及非理想成像噪声,因此比合成数据集更能体现模型的实际泛化能力。SynFSNet 在 SPA-Data 上取得显著优势,说明所提出的方法不仅能够处理规则或相对理想的合成雨纹,还能在真实复杂环境下有效分离雨迹与背景结构,具有更强的实际应用潜力。

3) 可视化对比结果分析。

在 Rain200L^[37]、Rain200H^[37] 和 SPA-Data^[40] 3 个具有代表性的图像去雨数据集上比较了 SPDNet^[44]、DRSformer^[23]、FADformer^[16]、PW-FNet-L^[48] 和本文提出的 SynFSNet 方法的图像去雨性能。图 6 和图 7 展示了在不同雨条纹密度和方

向下的定性结果,图 8 则展示了在真实世界数据集 SPA-Data 上的性能。基于傅里叶的方法,如 FADformer,擅长进行全局频率分析,但通常忽略高频的局部细节,如边缘和纹理,导致输出去雨图像存在模糊或缺乏细节。相比之下,SynFSNet 通过 MSFFM 和 FSAM 联合的空间-频率特征建模,能够同时捕捉全局结构和局部细节,使 SynFSNet 网络在复杂的雨天条件下能够生成更清晰、细节更丰富的去雨图像。为了更清晰地展示不同方法之间的差异,本文对关键区域进行了局部放大。可以观察到,部分对比方法在细小雨纹密集区域仍存在残留,在边缘和纹理区域容易出现模糊或过平滑现象。相比之下,SynFSNet 能更有效地抑制残余雨迹,同时较好地保留背景结构边界和低频纹理细节,体现出空间域与频域协同建模在复杂雨迹场景下的优势。




图 5 PSNR 和参数量对比

Fig.5 Comparison of PSNR and parameters




图 6 在 Rain200L 数据集上的定性视觉结果对比

Fig.6 Visual comparisons of denoised results on the Rain200L dataset




图 7 在 Rain200H 数据集上的定性视觉结果对比

Fig.7 Visual comparisons of denoised results on the Rain200H dataset




图 8 在 SPA-Data 真实世界数据集上的定性视觉结果对比

Fig.8 Visual comparisons of derained results on the real-world dataset SPA-Data

值得注意的是,根据表 2 实验数据可知, SynFSNet 在推理速度方面表现优异,达到了 36.64 帧/s,远超其他当前领先的 Transformer 去雨方法和频域去雨方法,如 FADformer (22.60 帧/s) 和 SFHformer (25.54 帧/s)。这一结果表明, SynFSNet 在提供更优恢复性能的同时,能够保持较高的推理效率。

表 2 不同方法的效率对比

Table 2 Efficiency comparison of different methods

Methods	Params/ 10^6	速度/(帧·s ⁻¹)
DRSformer ^[23]	33.70	9.80
FADformer ^[16]	6.95	22.60
SFHformer ^[29]	7.63	25.54
SynFSNet(Ours)	16.90	36.64

3.5 消融实验

通过定量实验验证 SynFSNet 中的关键模块和损失函数的有效性。为了确保快速收敛和稳定的性能,所有实验均在 Rain200H 数据集上进行。

1) 关键模块的消融实验。

本文进行了消融实验并且探讨了关键核心模块对模型性能的影响,结果如表 3 所示,其中,×表示不使用该项,√表示使用该项,下同。基线模型是通过从 SynFSNet 模型中去除 MDConv 和带 FSAM 核心组件的 MSFFM 得到的。单独应用 MDConv 后,基线模型在 PSNR 上提升了 0.26 dB。MDConv 通过多深度卷积从不同下采样的退化图像中提取多尺度特征,增强了对不同尺度雨纹的感知能力。单独应用 MSFFM(不含 MDConv 和 FSAM)使 PSNR 提升了 0.53 dB。这是因为 MSFFM 采用多分支结构,通过不同下采样率的池化获得多尺度特征,实现了由粗到细的渐进式去雨。单独应用 FSAM(不含 MDConv 和 MSFFM)使 PSNR 提升了 0.40 dB。这

是因为 FSAM 通过傅里叶变换将特征映射到频域,频域建模能够有效捕获全局雨迹特征表达,增强网络对复杂雨纹频谱模式的识别能力。当同时使用 MDConv 和 MSFFM(不含 FSAM)时,与基线模型相比在 PSNR 上提升了 1.38 dB,优于两者单独使用,表明 MDConv 提供的多尺度输入先验有助于 MSFFM 进行更充分的跨尺度特征聚合。当同时使用 MDConv 和 FSAM(不含 MSFFM)时,PSNR 提升了 1.16 dB,表明多尺度输入空间先验特征与频域特征之间具有较强互补性。当同时使用 MSFFM 和 FSAM(不含 MDConv)时,PSNR 提升了 1.50 dB,进一步验证了空间域渐进式策略与频域特征增强的协同建模能够有效地提升去雨效果。当 3 个模块同时使用时,基线模型在 PSNR 上提升了 1.79 dB,达到最佳性能,验证了 MDConv、MSFFM 和 FSAM 分别承担多尺度先验特征提取、渐进式跨尺度融合以及频域特征增强的功能,三者协同优化显著提升了图像去雨性能。这些消融实验结果验证了本文提出的 MDConv、FSAM 和 MSFFM 创新模块的有效性。

表 3 关键模块的消融研究

Table 3 Ablation studies of key modules

MDConv	MSFFM (w/o FSAM)	FSAM	PSNR/dB	SSIM
×	×	×	30.85	0.910 7
√	×	×	31.11	0.912 3
×	√	×	31.38	0.915 6
×	×	√	31.25	0.914 2
√	√	×	32.23	0.932 2
√	×	√	32.01	0.928 5
×	√	√	32.35	0.934 7
√	√	√	32.64	0.937 6

2) MSFFM 中分支数量的消融研究。

在 MSFFM 中,分支数量是影响多尺度特征表示有效性的关键因素。为了系统地评估其对性能的影响,进行了不同分支配置的消融实验。如表 4 所示,随着分支数量的增加,模型性能不断提高。具体而言,单分支配置(下采样率为 2)实现了 0.26 dB 的 PSNR 提升,而采用三分支配置则带来了 1.79 dB 的显著提升。随着分支数量增加,模型性能持续提升,但同时模型参数量与计算复杂度也随之增加。引入第 3 个分支后,PSNR 提升开始趋于稳定,而计算开销继续增加。因此,为在恢复性能与计算效率之间取得合理平衡,本文最终采用三分支结构作为 MSFFM 的默认配置。这些结果充分验证了在 MSFFM 中提出的多尺度架构的有效性。

表 4 MSFFM 模块的消融研究

Table 4 Ablation studies of the MSFFM module

2	4	8	PSNR/dB	SSIM	Params/ 10^6	FLOPs/ 10^9
			30.85	0.910 7	12.86	118.95
✓			31.11	0.912 3	14.21	121.00
✓	✓		32.23	0.932 2	15.55	121.52
✓	✓	✓	32.64	0.937 6	16.90	121.65

3) CFFBlock 中残差块数量的消融研究。

残差结构广泛应用于图像恢复任务,因为它们能在缓解梯度消失问题和增强特征传播方面具有有效性。然而,考虑残差块的数量在计算效率和恢复性能之间需要适当权衡,评估 CFFBlock 模块中残差块数量(记作 N)对网络性能的影响,消融实验结果如表 5 所示。当 $N=4$ 时,模型的表现最差,表明特征表示能力不足。将残差块的数量增加到 $N=8$ 时,PSNR 指标增长显著,提升了 0.41 dB,表明更深的残差结构有助于更有效地信息建模。当 $N=16$ 时,模型在恢复质量和计算效率之间达到了最佳平衡,PSNR 进一步提升了 0.53 dB。当残差块数量增加至 $N=32$ 时,PSNR 指标相较于 $N=16$ 时提升非常有限(0.02 dB),但 Params 和 FLOPs 显著增加。进一步增加残差块数量(例如 $N=32$)将带来更高的计算开销,同时可能增加训练难度和过拟合

表 5 CFFBlock 中残差块数量的消融研究

Table 5 Ablation studies of the number of residual blocks in CFFBlock

N	PSNR/dB	SSIM	Params/ 10^6	FLOPs/ 10^9
4	32.11	0.931 5	8.1	40.6
8	32.52	0.936 1	10.9	67.6
16	32.64	0.937 6	16.9	121.6
32	32.66	0.937 9	28.7	229.7

风险。因此,在综合考虑恢复质量与模型复杂度的情况下,本文最终采用 $N=16$ 作为折中配置。

4) FSAM 中的子组件消融研究。

为了进一步评估 FSAM 的有效性,对 RFA 和 SFA 这两个核心组件进行消融实验,分别进行单独和联合评估。如表 6 所示,比较了 4 种配置:不使用完整 FSAM 的基线模型(Experiment I),仅包含 RFA(Experiment II)或仅包含 SFA(Experiment III)的模型,以及使用完整的 FSAM(Experiment IV)。单独使用 RFA 相较于基线模型,PSNR 增加了 0.26 dB,而单独使用 SFA 则提高了 0.21 dB,证明了这两个组件在捕捉方向性雨条纹特征方面的有效性。当 RFA 和 SFA 结合成完整的 FSAM 时,模型达到了最佳性能,相较于基线模型,PSNR 提高了 0.39 dB。表 6 消融实验结果表明,单独引入 RFA 或 SFA 均能够带来性能提升,而两者联合时取得最佳结果,这说明两者在频域特征增强上具有明显的互补性。

表 6 FSAM 模块及其子组件(RFA 和 SFA)的消融研究

Table 6 Ablation studies of the FSAM module and its subcomponents (RFA and SFA)

Experiment	RFA	SFA	PSNR/dB	SSIM
I	×	×	32.25	0.932 9
II	✓	×	32.51	0.936 4
III	×	✓	32.46	0.935 5
IV	✓	✓	32.64	0.937 6

5) 双域损失函数的消融研究。

考虑到雨天图像在空间域和频域特征之间的差异,采用了双域损失函数,旨在利用每个域的损失函数的优势。如表 7 所示,双域损失在性能上优于单一的 L1/FFT 损失。

表 7 双域损失函数的消融研究

Table 7 Ablation studies on dual-domain loss function

Loss function	PSNR/dB	SSIM
L1 Loss	32.32	0.934 9
FFT Loss	32.35	0.935 7
L1+FFT Loss	32.64	0.937 6

6) 空间-频率损失中平衡因子的消融研究。

为了定量评估空间-频率双域损失的贡献,本文通过调节平衡因子 λ 进行消融实验,旨在评估频域监督对雨条纹建模、训练稳定性和图像质量的影响。公式如下:

$$L_{\text{total}} = L_{\text{spatial}} + \lambda L_{\text{frequency}} \quad (17)$$

式中: L_{spatial} 表示空间域损失函数; $L_{\text{frequency}}$ 表示频域损失函数; λ 被用作平衡因子,用于协调双域学习的过程。

如表 8 所示,仅使用空间域损失($\lambda=0$)得到的 PSNR 为 32.32 dB,SSIM 为 0.9349,以此作为稳定的基线;引入小权重的频域损失($\lambda=0.01$ 和 $\lambda=0.05$)可以带来稳定的性能提升。值得注意的是,模型在 $\lambda=0.1$ 时取得最佳的结果,达到最高的 PSNR(32.64 dB)和 SSIM(0.9376),这表明频率信息有效地增强了雨条纹的去除,同时提高了感知质量。

表 8 平衡因子的消融研究

Table 8 Ablation studies of balance factors

λ	PSNR/dB	SSIM
0	32.32	0.9349
0.01	32.41	0.9355
0.05	32.56	0.9369
0.10	32.64	0.9376
0.20	32.54	0.9364
0.50	32.44	0.9357

然而,进一步将 λ 增加到 0.20,尽管 PSNR 相对仅使用空间域损失有所提升,但 SSIM 降低至 0.9364,这表明过度强调频率损失可能会损害结构重建。当 $\lambda=0.50$ 时,也观察到类似的性能下降:PSNR 为 32.44 dB,SSIM 为 0.9357。这些结果表明,频域监督在引导网络方面起到了有益作用,但其影响必须谨慎平衡。最优的 λ 设置为 0.10,突出了空间和频率提示在去雨任务中的互补性,从而提高了图像的保真度和感知质量。

7) 复杂环境下的适应性分析。

为了进一步分析模型在复杂环境下的适应性,图 9 展示了在暗光与雨雪混合真实场景中的定性结果。在此类极端天气条件下,图像退化通常同时包含低照度噪声、雨条纹以及雪粒散射等多种因素,使得雨纹与背景结构在空间域和频域中的区分度显著降低。从图 9 可以观察到,尽管 SynFSNet 能够在一定程度上恢复图像的整体结构并减少部分雨纹干扰,但在低光和雨雪叠加条件下仍可能出现局部细节模糊或纹理丢失现象。其主要原因在于低照度环境会削弱图像的高频信息,而雨雪混合退化会导致频域特征分布更加复杂,从而增加雨迹与背景结构分离的难度。SynFSNet 在图 9 这两种极端场景下仍存在较明显的雨纹残留或结构失真。尽管所提出的方法在复杂天气条件下具有一定鲁棒性,但在极端场景中仍存在提升空间。未来工作将考虑结合低照度增强或多天气联合建模策略,以进一步提升模型在复杂环境中的适应能力。



图 9 暗光与雨雪真实场景中的定性视觉结果

Fig.9 Qualitative results in real-world low-light and rainy-snowy scenes

4 结束语

本文提出了一种频域与空间域协同建模的图像去雨网络 SynFSNet。为了克服 CNN 在长程依赖建模中的局限性以及 Transformer 模型的计算复杂性,在 SynFSNet 中设计了两个关键模块:MSFFM 和 FSAM。MSFFM 通过多分支表示学习和跨尺度特征聚合,能够有效提取全局上下文信息和精细的局部细节。FSAM 集成了 RFA 和 SFA 机制,能够自适应地捕捉不同形状的雨条纹,并提取丰富的频域特征。在合成数据集和真实世界数据集上的广泛实验结果表明,SynFSNet 优于现有先进的图像去雨模型。尽管本文方法在去雨任务中取得了显著的成果,但在极端雨水条件下处理高分辨率图像时,仍然存在一定的计算负担和图像去雨的不足。未来的研究将致力于优化模型的计算效率和扩展 SynFSNet 在其他图像恢复任务中的应用,进一步验证其广泛的实用性和鲁棒性。

参考文献

- [1] WANG K G, WANG T M, QU J C, et al. An end-to-end cascaded image deraining and object detection neural network [J]. IEEE Robotics and Automation Letters, 2022, 7(4): 9541-9548.
- [2] 白邵宙, 张浩, 赵景波, 等. 基于颜色均衡与特征融合的水下图像增强框架[J]. 计算机工程, 2025, 51(10): 336-345. BAI S Z, ZHANG H, ZHAO J B, et al. Underwater image enhancement frame based on color balance and feature fusion [J]. Computer Engineering, 2025, 51(10): 336-345. (in Chinese)
- [3] JIANG Y D, ZHU B, ZHAO X M, et al. Pixel-wise content attention learning for single-image deraining of autonomous vehicles[J]. Expert Systems with Applications, 2023, 224: 119990.
- [4] ALI A M, BENJDIRA B, KOUBAA A, et al. Vision transformers in image restoration: a survey [J]. Sensors,

- 2023, 23(5): 2385-2385.
- [5] LI J H, HU J C, FU P Y, et al. Ultra-fast deraining plugin for vision-based perception of autonomous driving[J]. IEEE Transactions on Intelligent Transportation Systems, 2025, 26(1): 1227-1240.
 - [6] LIANG Z, RUAN R, WANG C J, et al. Single image quality improvement via joint local structure dehazing and local texture enhancement [J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 4210117.
 - [7] TAO W H, SHAO F F, SU L J, et al. An analytical model for simulating the rainfall-interception-infiltration-runoff process with non-uniform rainfall [J]. Journal of Environmental Management, 2023, 344: 118490.
 - [8] LIU R W, LU Y X, GUO Y, et al. AiOENet: all-in-one low-visibility enhancement to improve visual perception for intelligent marine vehicles under severe weather conditions [J]. IEEE Transactions on Intelligent Vehicles, 2024, 9(2): 3811-3826.
 - [9] SU Z P, ZHANG Y X, SHI J H, et al. A survey of single image rain removal based on deep learning [J]. ACM Computing Surveys, 2024, 56(4): 1-35.
 - [10] TAO W Y, YAN X F, WANG Y Z, et al. MFFDNet: single image deraining via dual-channel mixed feature fusion [J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73: 5005813.
 - [11] CHENG D, LI Y, ZHANG D W, et al. Progressive negative enhancing contrastive learning for image dehazing and beyond [J]. IEEE Transactions on Multimedia, 2024, 26: 8783-8798.
 - [12] 杨士钺. 基于卷积神经网络的图像去雨方法研究及应用[D]. 大庆: 东北石油大学, 2024.
YANG S Y. Research and application of image rain removal method based on convolutional neural network[D]. Daqing: Northeast Petroleum University, 2024. (in Chinese)
 - [13] WANG Z D, CUN X D, BAO J M, et al. Uformer: a general U-shaped transformer for image restoration [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New Orleans, USA: IEEE Press, 2022: 17662-17672.
 - [14] 朱凯, 李理, 张彤, 等. 基于 Transformer 的多阶段运动模糊图像修复网络[J]. 计算机工程, 2024, 50(9): 276-285.
ZHU K, LI L, ZHANG T, et al. Multi-stage motion blur image restoration network based on Transformer [J]. Computer Engineering, 2024, 50(9): 276-285. (in Chinese)
 - [15] YANG J K, WANG J Y, LI Y B, et al. Image deraining algorithm based on multi-scale features [J]. Applied Sciences, 2024, 14(13): 5548.
 - [16] GAO N, JIANG X Y, ZHANG X H, et al. Efficient frequency-domain image deraining with contrastive regularization[C] // Proceedings of European Conference on Computer Vision. Berlin, Germany: Springer, 2025: 240-257.
 - [17] 杨佳璇. 基于空频双域特征提取的图像去雨关键技术研究[D]. 天津: 天津工业大学, 2025.
YANG J X. Research on key technologies of image rain removal based on spatial-frequency dual-domain feature extraction [D]. Tianjin: Tianjin Polytechnic University, 2025. (in Chinese)
 - [18] LYU P F, YU X S, YEUNG P H, et al. Deep Fourier-embedded network for RGB and thermal salient object detection[EB/OL]. [2025-11-02]. <https://arxiv.org/abs/2411.18409>.
 - [19] DING X H, CHEN L Q, ZHENG X H, et al. Single image rain and snow removal via guided L0 smoothing filter[J]. Multimedia Tools and Applications, 2016, 75(5): 2697-2712.
 - [20] ZHANG H, PATEL V M. Convolutional sparse and low-rank coding-based rain streak removal[C] // Proceedings of the IEEE Winter Conference on Applications of Computer Vision. Santa Rosa, USA: IEEE Press, 2017: 1259-1267.
 - [21] JIANG K, WANG Z Y, YI P, et al. Multi-scale progressive fusion network for single image deraining[C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE Press, 2020: 8343-8352.
 - [22] WANG H, XIE Q, ZHAO Q, et al. RCDNet: an interpretable rain convolutional dictionary network for single image deraining[J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 35(6): 8668-8682.
 - [23] CHEN X, LI H, LI M Q, et al. Learning a sparse transformer network for effective image deraining [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver, Canada: IEEE Press, 2023: 5896-5905.
 - [24] XIAO J, FU X Y, LIU A P, et al. Image de-raining transformer[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 45(11): 12978-12995.
 - [25] ZHANG T S, LIU P P, ZHAO M, et al. DMFourLLIE: dual-stage and multi-branch Fourier network for low-light image enhancement [C] // Proceedings of the 32nd ACM International Conference on Multimedia. New York, USA: ACM Press, 2024: 7434-7443.
 - [26] ZHOU M, HUANG J, GUO C L, et al. Fourmer: an efficient global modeling paradigm for image restoration[C] // Proceedings of the International Conference on Machine Learning. [S. l.]: PMLR, 2023: 42589-42601.
 - [27] HUANG J, LIU Y J, ZHAO F, et al. Deep Fourier-based exposure correction network with spatial-frequency interaction[C] // Proceedings of European Conference on Computer Vision. Berlin, Germany: Springer, 2022: 163-180.
 - [28] YU H, ZHENG N S, ZHOU M, et al. Frequency and spatial dual guidance for image dehazing[C] // Proceedings of European Conference on Computer Vision. Berlin, Germany: Springer, 2022: 181-198.
 - [29] JIANG X Y, ZHANG X H, GAO N, et al. When fast Fourier transform meets transformer for image restoration [C] // Proceedings of European Conference on Computer Vision. Berlin, Germany: Springer, 2025: 381-402.
 - [30] LI S Y, CAI S Q, TENG S, et al. Weather-robust spatial-frequency decoupling transformer for crack segmentation[J]. IEEE Sensors Journal, 2025, 25(21): 39881-39892.
 - [31] PARK N, KIM S. How do vision transformers work? [EB/OL]. [2025-11-02]. <https://arxiv.org/abs/2202.06709>.
 - [32] CUI Y N, REN W Q, CAO X C, et al. Revitalizing convolutional network for image restoration [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2024, 46(12): 9423-9438.
 - [33] LOSHCILLOV I, HUTTER F. Decoupled weight decay regularization[EB/OL]. [2025-11-02]. <https://arxiv.org/abs/1711.05101>.
 - [34] LOSHCILLOV I, HUTTER F. SGDR: stochastic gradient descent with warm restarts [EB/OL]. [2025-11-02]. <https://arxiv.org/pdf/1608.03983>.
 - [35] HUYNH-THU Q, GHANBARI M. Scope of validity of PSNR in image/video quality assessment [J]. Electronics Letters, 2008, 44(13): 800-801.
 - [36] 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.
 - [37] 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. Honolulu, USA: IEEE Press, 2017: 1685-

- 1694.
- [38] ZHANG H, PATEL V M. Density-aware single image de-raining using a multi-stream dense network[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE Press, 2018: 695-704.
- [39] FU X Y, HUANG J B, ZENG D L, 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, USA: IEEE Press, 2017: 1715-1723.
- [40] 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. Long Beach, USA: IEEE Press, 2020: 12262-12271.
- [41] LI X, WU J L, LIN Z C, et al. Recurrent squeeze-and-excitation context aggregation net for single image deraining [C] // Proceedings of European Conference on Computer Vision. Berlin, Germany: Springer, 2018: 262-277.
- [42] REN D W, ZUO W M, HU Q H, 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, USA: IEEE Press, 2019: 3932-3941.
- [43] 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. Nashville, USA: IEEE Press, 2021: 14821-14831.
- [44] YI Q S, LI J C, DAI Q Y, et al. Structure-preserving deraining with residue channel prior guidance [C] // Proceedings of the IEEE/CVF International Conference on Computer Vision. Montreal, Canada: IEEE Press, 2021: 4218-4227.
- [45] ZAMIR S W, ARORA A, KHAN S, et al. Restormer: efficient transformer for high-resolution image restoration [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. New Orleans, USA: IEEE Press, 2022: 5718-5729.
- [46] CHEN X, PAN J S, LU J Y, et al. Hybrid CNN-transformer feature fusion for single image deraining [J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2023, 37(1): 378-386.
- [47] ZHU Z L, ZENG T, YANG T, et al. DeRainMamba: a frequency-aware state space model with detail enhancement for image deraining [J]. IEEE Signal Processing Letters, 2025, 32: 3869-3873.
- [48] JIANG X Y, GAO N, DOU H K, et al. Global modeling matters: a fast, lightweight, and effective baseline for efficient image restoration[J]. IEEE Transactions on Image Processing, 2026, 35: 2740-2754.

文字编辑 金胡考
栏目编辑 赖玉玲