

融合频域增强的遥感图像超分辨率重建方法

卢昌婷^{1,2}, 梁玉琦^{1,2*}

¹兰州交通大学, 光电技术与智能控制教育部重点实验室, 甘肃 兰州

²兰州交通大学, 国家绿色镀膜技术与装备工程技术研究中心, 甘肃 兰州

收稿日期: 2026年4月24日; 录用日期: 2026年6月19日; 发布日期: 2026年6月30日

摘要

现有遥感图像超分辨率重建方法在主体结构恢复方面取得了一定效果, 但仍存在高频信息利用不足、边缘易模糊以及复杂纹理区域细节恢复不充分等问题。提出一种融合频域增强的遥感图像超分辨率重建方法(Frequency-Enhanced Prior Reconstruction, FEPR)。该方法以RRDBNet为主干网络, 在深层特征融合阶段引入频域增强模块, 通过统计特征频谱中的高频响应并进行通道自适应重标定, 增强网络对边缘、纹理及局部高频结构的表征能力; 同时结合像素重建损失与频域一致性损失进行联合监督, 以提升重建结果在空间域和频域上的一致性。在NWPU-RESISC45、AID、UC Merced Land Use和WHU-RS19等公开遥感数据集上的实验结果表明, 所提方法在不同数据集和放大倍率条件下均取得了较为稳定的重建效果。其中, 在NWPU-RESISC45数据集×4任务上, FEPR取得25.52 dB的PSNR和0.6345的SSIM, SSIM优于EDSR和RCAN。消融实验表明, 频域增强模块与频域一致性损失对提升重建性能具有一定作用。

关键词

遥感图像超分辨率重建, 频域增强, RRDBNet, 高频信息, 频域一致性损失

Remote Sensing Image Super-Resolution Reconstruction Method Enhanced by Frequency Domain Fusion

Changting Lu^{1,2}, Yuqi Liang^{1,2*}

¹Key Lab of Opt-Technology and Intelligent Control of Ministry of Education, Lanzhou Jiaotong University, Lanzhou Gansu

²National Engineering Research Centre for Green Coating Technology and Equipment, Lanzhou Jiaotong University, Lanzhou Gansu

Received: April 24, 2026; accepted: June 19, 2026; published: June 30, 2026

*通讯作者。

Abstract

Existing remote sensing image super-resolution reconstruction methods have achieved certain effects in the restoration of main structures, but there are still problems such as insufficient utilisation of high-frequency information, edge blurring, and inadequate detail recovery in complex texture areas. A remote sensing image super-resolution reconstruction method with frequency-domain enhancement (Frequency-Enhanced Prior Reconstruction, FEPR) is proposed. This method uses RRDBNet as the backbone network and introduces a frequency-domain enhancement module during the deep feature fusion stage to enhance the network's ability to represent edges, textures, and local high-frequency structures by statistically analysing high-frequency responses in the feature spectrum and performing channel adaptive recalibration. Meanwhile, a combination of pixel reconstruction loss and frequency-domain consistency loss is used for joint supervision to improve the consistency of the reconstruction results in both spatial and frequency domains. Experimental results on publicly available remote sensing datasets such as NWPU-RESISC45, AID, UC Merced Land Use, and WHU-RS19 show that the proposed method achieves relatively stable reconstruction performance under different datasets and scale factors. Notably, in the $\times 4$ task on the NWPU-RESISC45 dataset, FEPR achieved a PSNR of 25.52 dB and an SSIM of 0.6345, with SSIM outperforming EDSR and RCAN. Ablation experiments indicate that the frequency-domain enhancement module and frequency-domain consistency loss play a certain role in improving reconstruction performance.

Keywords

Remote Sensing Image Super-Resolution Reconstruction, Frequency-Domain Enhancement, RRDBNet, High-Frequency Information, Frequency-Domain Consistency Loss

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

遥感图像超分辨率重建旨在由低分辨率观测恢复高分辨率图像,对场景解译、目标识别、资源调查和城市规划等任务具有重要意义[1]。与自然图像相比,遥感图像通常具有场景尺度跨度大、地物类别复杂、边缘分布密集以及纹理重复性强等特点,因此其超分辨率重建在结构保持与细节恢复方面面临更大挑战。尤其在建筑物边界、道路线状结构和复杂纹理区域中,低分辨率成像往往会造成高频信息衰减和局部细节缺失,从而限制后续遥感解译任务的精度和可靠性。

早期图像超分辨率方法主要依赖插值或重建策略,这类方法实现简单,但难以充分恢复图像中的高频纹理与边缘细节,容易产生模糊和失真[2]。随着深度学习的发展,SRCNN [3]、VDSR [4]、EDSR [5]和RCAN [6]等基于卷积神经网络的超分辨率方法显著提升了图像重建性能。其中,EDSR通过移除批归一化层并增强残差学习能力改善了重建效果,RCAN则借助通道注意力机制增强了网络对关键特征的响应能力。此外,SRGAN [7]和ESRGAN [8]等生成式方法在图像感知质量方面取得了较好效果。然而,上述方法大多仍以空间域卷积建模为主,虽然能够较好恢复图像主体结构,但在遥感复杂场景中仍容易出现边缘过渡不清晰、高频纹理恢复不足以及局部细节表达不充分等问题。面向遥感图像超分辨率任务,已有研究从多尺度建模、密集采样、梯度先验、动态多尺度和注意力生成等角度对细节恢复进行了改进[9]-[14]。此外,多尺度残差学习也被证明能够在一定程度上改善超分辨率重建中的特征表达与细节恢复能力[15]。

从信号表示角度来看, 图像边缘、纹理起伏及局部结构变化主要集中于高频分量, 而遥感图像在成像退化和下采样过程中, 高频信息往往更易受到抑制甚至丢失。对于建筑密集区、道路交叉区以及规则重复纹理区域而言, 若网络仅依赖空间域特征学习而缺乏对频域信息的显式利用, 往往难以充分恢复具有判别意义的高频结构。因此在超分辨率重建过程中引入频域建模, 有助于增强网络对边缘与纹理细节的表达能力, 从而提高遥感图像超分辨率重建的整体质量。

针对上述问题, 本文提出一种融合频域增强的遥感图像超分辨率重建方法(Frequency-Enhanced Prior Reconstruction, FEPR)。该方法以 RRDBNet 作为主干网络, 在深层特征提取与融合过程中引入频域增强模块, 通过提取特征频谱中的高频响应并进行通道自适应重标定, 提升模型对边缘、纹理及局部高频结构的关注能力; 同时, 采用像素重建损失与频域一致性损失对网络进行联合优化, 以增强重建结果在空间域和频域上的一致性。本文工作的主要贡献如下: 1) 提出一种面向遥感图像超分辨率重建的频域增强方法。该方法在 RRDBNet 深层融合特征上统计高频响应, 并通过通道自适应重标定增强边缘、纹理和局部结构区域的特征表达能力。2) 构建像素重建损失与频域一致性损失相结合的联合监督策略, 使模型在空间域重建精度和频域高频结构保持之间取得较好平衡。3) 在 NWPU-RESISC45、AID、UC Merced Land Use 和 WHU-RS19 等公开遥感数据集上进行实验, 并补充不同放大倍率和消融实验, 验证所提方法在多数数据集和多尺度条件下的稳定性。

2. 方法

2.1. 总体框架

本文方法以低分辨率遥感图像 I_{LR} 为输入, 其网络框架如图 1 所示, 首先采用残差中残差密集块网络 (Residual in Residual Dense Block Network, RRDBNet) 作为主干网络提取浅层与深层特征; 随后, 在主干特征融合后引入频域增强模块, 对特征中的高频响应进行自适应强化; 最后, 经过上采样与卷积重建得到超分辨率结果 I_{SR} 。与仅依赖空间域卷积的重建方式相比, 该方法在深层特征学习阶段显式引入频率信息建模, 有助于在恢复主体结构的同时增强网络对边缘和纹理细节的响应能力。

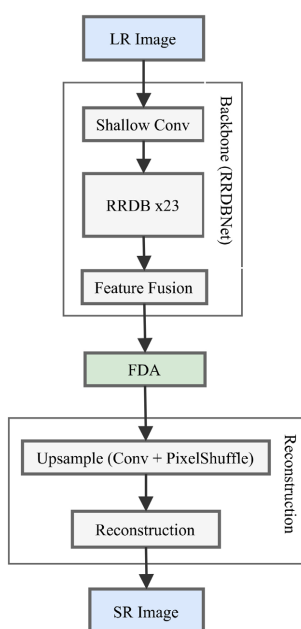


Figure 1. Overall framework diagram
图 1. 总体框架图

2.2. RRDB 主干网络

考虑到 RRDB 结构在图像恢复任务中具有较好的特征复用能力和训练稳定性, 本文采用 RRDBNet 作为主干。对于输入低分辨率图像 I_{LR} , 首先通过首层卷积提取浅层特征:

$$F_0 = H_{head}(I_{LR}) \quad (1)$$

其中, $H_{head}(\cdot)$ 表示浅层卷积映射。随后, 将浅层特征输入由 23 个 RRDB 顺序堆叠构成的 trunk 模块, 得到深层非线性特征表示:

$$F_d = H_{trunk}(F_0) \quad (2)$$

为增强梯度传播并稳定深层训练过程, 在 trunk 末端引入卷积整合与全局残差融合, 得到融合后的主干特征:

$$F_t = H_{conv}(F_d), F = F_0 + F_t \quad (3)$$

其中, $H_{conv}(\cdot)$ 表示 trunk 末端的卷积整合操作。融合特征 F 在保留浅层结构信息的同时, 融入了 RRDB 深层非线性映射得到的高层表示, 为后续频域增强提供了稳定特征基础。在得到频域增强后的特征 F_{enh} 后, 网络进一步通过上采样模块和卷积重建层恢复高分辨率空间表示, 输出重建结果:

$$I_{SR} = H_{rec}(H_{up}(F_{enh})) \quad (4)$$

其中, $H_{up}(\cdot)$ 表示上采样模块, 采用卷积与 Pixel Shuffle 组合实现特征放大[16]; $H_{rec}(\cdot)$ 表示高分辨率重建映射。

2.3. 频域增强模块

遥感图像中的建筑边缘、道路线状结构和纹理变化区域通常对应较强的高频成分。本文在主干特征融合后引入频域增强模块 FDA (Frequency Domain Augmentation), 增强网络对高频结构信息的建模能力[17]。其结构示意图如图 2 所示。

FDA 模块首先对融合后的主干特征为 F 进行二维傅里叶变换, 得到频域表示:

$$F_f = FFT(F) \quad (5)$$

随后取其幅值并进行对数压缩, 以减弱不同频率分量量级差异对训练稳定性的影响:

$$A = \log(1 + |F_f|) \quad (6)$$

为突出高频区域, 先对幅值谱进行中心移位, 使低频分量移动至频谱中心, 然后构造高频掩码 M , 统计各通道在高频区域中的响应强度。具体实现中, 本文采用中心低频区域抑制的高通掩码。设中心移位后的频谱尺寸为 $H \times W$, 频谱中心为 (u_0, v_0) , 高频区域比例参数为 ρ , 则掩码定义为:

$$M(u, v) = \begin{cases} 0, & |u - u_0| < \rho H, |v - v_0| < \rho W \\ 1, & \text{otherwise} \end{cases} \quad (7)$$

其中, $M(u, v) = 0$ 表示中心低频区域, $M(u, v) = 1$ 表示参与统计的高频区域。本文实验中取 $\rho = 0.25$ 。

$$v_c = \frac{1}{|\Omega_h|} \sum_{(u, v) \in \Omega_h} M(u, v) \cdot A_c(u, v) \quad (8)$$

其中, Ω_h 表示由高频掩码 M 确定的高频区域集合, $|\Omega_h|$ 表示高频区域内有效频率位置数量, v_c 表示第 c 个通道的高频响应统计量。随后, 将高频响应向量输入由两层全连接层构成的轻量感知机, 生成通道权重:

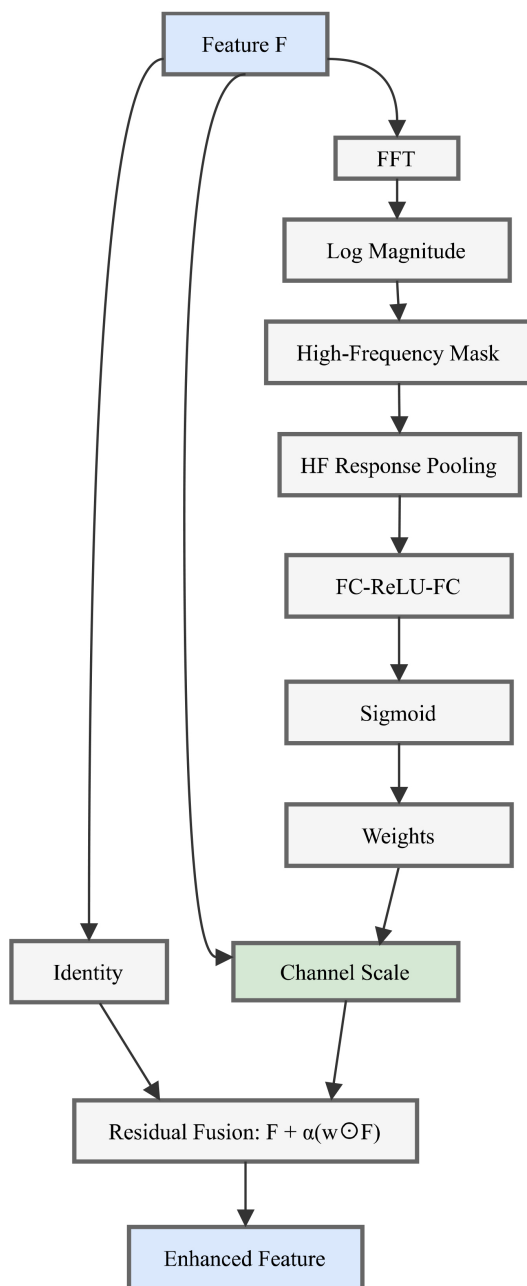


Figure 2. Frequency domain enhancement module
图 2. 频域增强模块

$$w = \sigma(W_2 \delta(W_1 v)) \tag{9}$$

其中, $\delta(\cdot)$ 为 ReLU 激活函数, $\sigma(\cdot)$ 为 Sigmoid 激活函数。最后, 将通道权重作用于原始特征, 并以残差增强方式得到频域增强后的特征表示:

$$F_{enh} = F + \alpha(w \odot F) \tag{10}$$

其中, α 为增强系数, \odot 表示逐通道乘法。本文实验中将 α 设置为 0.1, 用于控制频域增强分支对主干特征的影响强度, 避免过强的通道重标定破坏原有空间特征表达的稳定性。

通过显式利用特征频谱中的高频统计信息, FDA 模块能够引导网络更加关注边缘、纹理和局部结构复杂区域, 从而提升对高频细节的表达能力。

2.4. 损失函数

本文采用像素重建损失与频域一致性损失进行联合监督, 保证重建结果在空间域与频域上均能够较好逼近真实高分辨率图像。像素重建损失定义为:

$$L_{pix} = \|I_{SR} - I_{HR}\|_1 \quad (11)$$

其中, I_{HR} 表示真实高分辨率图像, $\|\cdot\|_1$ 表示 L_1 范数。与 L_2 损失相比, L_1 损失更有利于抑制过度平滑现象, 并保持边缘和纹理细节[18]。引入频域一致性损失, 从频率分布角度进一步约束重建结果:

$$L_{freq} = \left\| \log(1 + |\mathcal{F}(I_{SR})|) - \log(1 + |\mathcal{F}(I_{HR})|) \right\|_1 \quad (12)$$

该损失通过约束重建图像与真实图像在频谱幅值上的差异, 增强模型对高频结构和纹理区域的恢复能力[19]。最终, 总损失函数定义为:

$$L = L_{pix} + \lambda_{freq} L_{freq} \quad (13)$$

其中, λ_{freq} 为频域损失权重。本文实验中将 λ_{freq} 设置为 0.01, 用于平衡像素重建损失与频域一致性损失的影响, 使频域约束作为辅助监督参与训练, 避免其权重过大时干扰主干网络对空间结构的学习。

3. 实验结果与分析

3.1. 实验设置

实验基于 PyTorch 2.1.0 框架实现, 在 Ubuntu 22.04 操作系统下进行, CUDA 版本为 12.1, GPU 为 NVIDIA RTX 4090D 24 GB, CPU 为 Intel Xeon Platinum 8474C, 内存为 80 GB。基础重建模型采用 Adam 优化器进行训练, 参数设置为 $\beta_1 = 0.9$ 、 $\beta_2 = 0.999$, 初始学习率设置为 1×10^{-4} , 权重衰减系数设置为 0。训练过程中采用余弦退火策略调整学习率, 最小学习率为 1×10^{-6} 。训练阶段从高分辨率图像中随机裁剪 96×96 的图像块作为训练样本, 在 $\times 4$ 放大倍率下对应的低分辨率输入尺寸为 24×24 , batch size 设置为 8, 训练轮数设置为 200。统一采用 Bicubic 下采样构造低分辨率输入, 并在 $\times 2$ 、 $\times 3$ 和 $\times 4$ 三种放大倍率下进行评估[20], 其中 $\times 4$ 作为主要分析尺度。

本文选取 NWPU-RESISC45、AID、UC Merced Land Use 和 WHU-RS19 四个公开遥感图像数据集开展实验。NWPU-RESISC45 作为主要训练与测试数据集, 按 8:1:1 的比例划分为训练集、验证集和测试集; AID、UC Merced Land Use 和 WHU-RS19 作为补充测试数据集, 用于验证模型在不同数据分布条件下的泛化性能。评价指标采用峰值信噪比(PSNR)和结构相似性(SSIM)。对比方法包括 Bicubic、EDSR、RCAN 和 ESRGAN。其中, EDSR 和 RCAN 为典型的重建导向方法, 可反映深层残差结构和注意力机制在高保真重建任务中的性能水平; ESRGAN 为典型的感知导向方法, 可用于比较不同重建目标下模型在定量指标和视觉效果上的差异。各方法均采用统一的退化方式与测试流程, 并参考公开实现中的典型配置完成训练与测试, 以保证实验结果的可比性。

3.2. 与主流方法对比

不同方法在 $\times 4$ 放大倍率条件下于 4 个遥感图像数据集上的定量对比结果如表 1 所示。

总体来看, FEPR 在四个数据集上均保持了稳定的竞争性表现, 并在 NWPU-RESISC45、AID 和 WHU-RS19 数据集上取得最优或接近最优结果。其中, 在 NWPU-RESISC45 数据集上, FEPR 的 PSNR 和 SSIM

分别达到 25.52 dB 和 0.6345, 综合性能最佳; 在 AID 和 WHU-RS19 数据集上, FEPR 的 PSNR 均取得最高值, 表明所提方法在复杂场景及规则结构场景下具有较好的泛化能力。在 UC Merced Land Use 数据集上, 各方法差异较小, FEPR 与 EDSR、RCAN 结果接近。该数据集样本规模较小、场景结构相对规整, 模型间性能差距有限。

Table 1. Quantitative comparison results of different methods on four remote sensing datasets

表 1. 不同方法在四个遥感数据集上的定量对比结果

数据集	指标	Bicubic	EDSR	RCAN	ESRGAN	FEPR (Ours)
NWPU-RESISC45	PSNR	25.30	25.51	25.51	24.21	25.52
	SSIM	0.6058	0.6166	0.6177	0.5752	0.6345
AID	PSNR	26.23	26.46	26.47	24.97	26.48
	SSIM	0.6459	0.6647	0.6660	0.6048	0.6654
UC Merced Land Use	PSNR	25.31	25.19	25.21	24.19	25.23
	SSIM	0.6694	0.6653	0.6675	0.6298	0.6664
WHU-RS19	PSNR	26.49	26.68	26.69	24.87	26.70
	SSIM	0.6563	0.6713	0.6725	0.6095	0.6720

EDSR 和 RCAN 作为重建导向方法, 整体表现稳定; ESRGAN 更偏重感知纹理生成, 因此在 PSNR 和 SSIM 指标上低于其他方法。相较于 EDSR 和 RCAN, FEPR 在平均 PSNR 上的提升幅度有限。这表明频域增强策略并非主要提升整体像素误差, 而是更多作用于局部高频细节恢复。在建筑边界、道路线状结构、机场跑道边缘及规则纹理区域, FDA 模块能够通过高频响应建模增强网络对细节信息的表达, 因此在结构保持和视觉质量方面具有一定优势。

3.3. 不同放大倍率下的尺度适应性分析

本文在 NWPU-RESISC45 和 AID 数据集上开展了×2、×3 和×4 三种放大倍率下的对比实验。不同方法在 NWPU-RESISC45 数据集和 AID 数据集上的定量结果分别如表 2 和表 3 所示。整体来看, 随着放大倍率增大, 各方法的 PSNR 和 SSIM 均呈下降趋势, 说明高倍率重建任务更具挑战性, 这与超分辨率任务的一般规律一致。

Table 2. Comparison results of the NWPU-RESISC45 dataset under different magnification levels

表 2. NWPU-RESISC45 数据集不同放大倍率下的对比结果

	指标	Bicubic	EDSR	RCAN	ESRGAN	FEPR
×2	PSNR↑	29.36	29.61	29.63	28.78	29.64
	SSIM↑	0.7812	0.7968	0.7981	0.7486	0.8014
×3	PSNR↑	27.18	27.39	27.40	26.36	27.42
	SSIM↑	0.6915	0.7062	0.7075	0.6518	0.7120
×4	PSNR↑	25.30	25.51	25.51	24.21	25.52
	SSIM↑	0.6058	0.6166	0.6177	0.5752	0.6345

Table 3. Comparison results of the AID dataset at different magnification levels
表 3. AID 数据集不同放大倍率下的对比结果

	指标	Bicubic	EDSR	RCAN	ESRGAN	FEPR
×2	PSNR↑	30.12	30.34	30.35	29.42	30.36
	SSIM↑	0.8126	0.8281	0.8293	0.7815	0.8306
×3	PSNR↑	28.04	28.23	28.24	27.10	28.25
	SSIM↑	0.7248	0.7392	0.7401	0.6887	0.7410
×4	PSNR↑	26.23	26.46	26.47	24.97	26.48
	SSIM↑	0.6459	0.6647	0.6660	0.6048	0.6654

在两组数据集上, FEPR 在×2、×3 和×4 条件下均取得最优或接近最优结果, 表明所提方法并非仅适用于固定×4 任务, 而具有较好的尺度适应能力。尤其在×4 条件下, FEPR 仍保持稳定竞争力, 说明频域增强策略在高倍率重建中能够有效补充边缘与纹理细节, 对复杂遥感场景中的高频信息恢复具有积极作用。

3.4. 消融实验

本文设计 4 组消融实验, 以验证 RRDB 主干网络、频域增强模块(FDA)及频域一致性损失的作用。E1 为仅使用 RRDB 主干; E2 在 E1 基础上加入 FDA 模块; E3 在 E1 基础上加入频域一致性损失; E4 同时引入 FDA 模块与频域损失, 即最终模型 FEPR。结果如表 4 所示。

Table 4. Ablation experiment results
表 4. 消融实验结果

模型	RRDB	FDA	频域损失	PSNR	SSIM
E1	√	×	×	25.49	0.6329
E2	√	√	×	25.50	0.6332
E3	√	×	√	25.45	0.6309
E4 (FEPR, Ours)	√	√	√	25.52	0.6346

与 E1 相比, E2 的 PSNR 和 SSIM 均有所提升, 说明 FDA 模块能够有效增强网络对高频信息的表征能力, 对边缘和纹理细节恢复具有积极作用。E3 结果低于 E1, 表明在缺乏显式频域特征建模的情况下, 仅通过频域损失约束难以带来稳定增益, 甚至可能干扰主干网络优化。E4 取得最优结果(25.52 dB/0.6346), 说明 FDA 模块与频域一致性损失具有较好的互补性: 前者强化高频特征表达, 后者约束频谱一致性, 二者协同提升了遥感图像超分辨率重建性能。

3.5. 可视化分析

本文选取 NWPU-RESISC45 数据集中飞机场、球场、道路和建筑等典型场景进行可视化对比, 结果如图 3 所示。图中上排为整体重建结果, 红框区域为局部关注区域, 下排为对应放大结果。

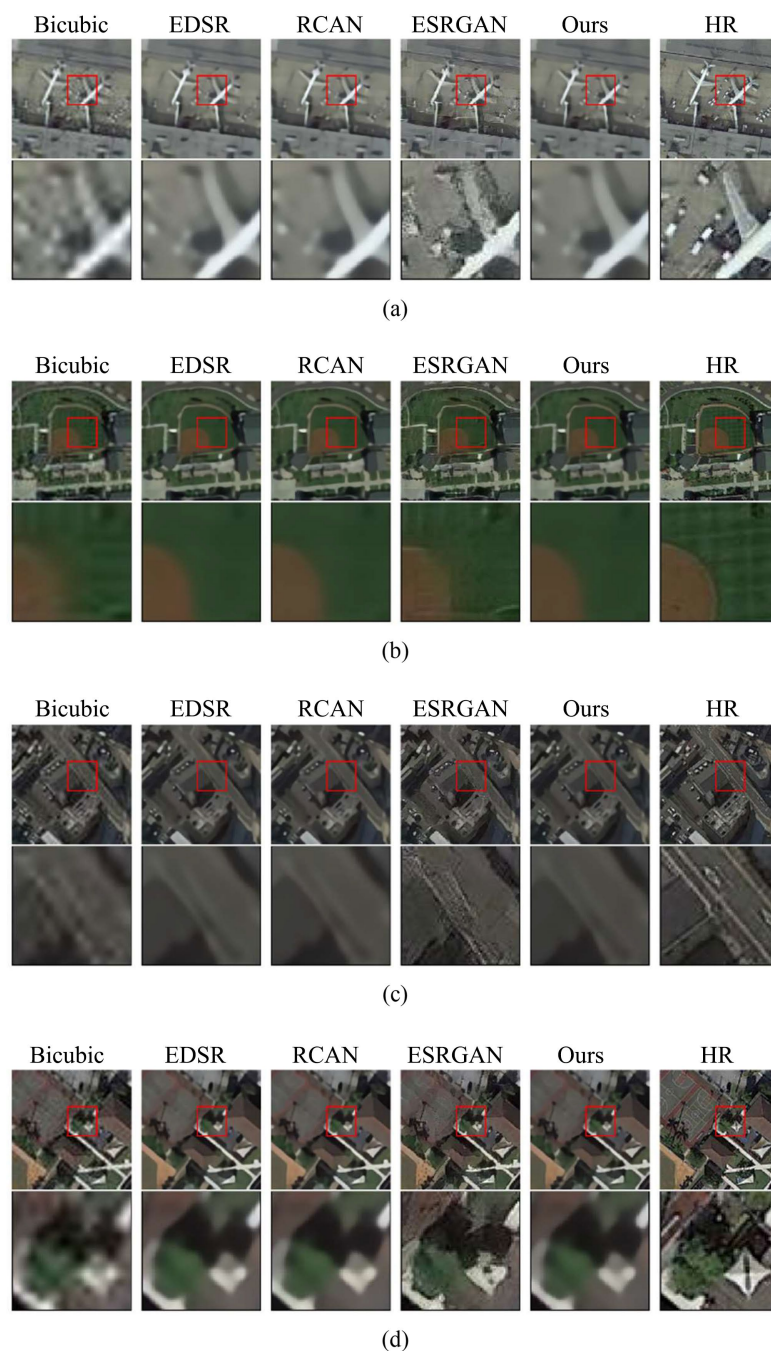


Figure 3. Visual comparison results of different methods in typical remote sensing scenarios. (a) Airport; (b) Court; (c) Road; (d) Architecture

图 3. 不同方法在典型遥感场景中的可视化对比结果。(a) 飞机场; (b) 球场; (c) 道路; (d) 建筑

从图 3 可以看出, Bicubic 方法在边缘过渡和纹理区域存在明显模糊; EDSR 和 RCAN 能够较好恢复主体结构, 但在复杂纹理和局部边缘区域仍存在一定平滑现象; ESRGAN 纹理锐化较强, 但部分区域出现与真实图像不一致的伪纹理。相比之下, FEPR 在高频结构区域表现更优。在飞机场场景中, 机体轮廓边缘更加连续; 在道路场景中, 道路线状结构更加清晰; 在建筑场景中, 建筑边界及块状结构轮廓更稳定; 在球场场景中, 场地区域边界更加明确。

FEPR 的视觉提升主要体现在局部高频细节恢复, 与其定量结果中的稳定小幅增益一致, 说明频域增强策略能够有效改善遥感图像的边缘与纹理表达能力。

4. 结论

本文提出了一种融合频域增强的遥感图像超分辨率重建方法。该方法以 RRDBNet 为主干网络, 在深层特征融合阶段引入频域增强模块, 通过利用特征频谱中的高频响应信息, 提升网络对边缘、纹理及局部结构的表达能力; 同时结合像素重建损失与频域一致性损失进行联合优化, 提高重建结果在空间域与频域上的一致性。在 NWPU-RESISC45、AID、UC Merced Land Use 和 WHU-RS19 四个公开数据集上的实验表明, 所提方法在不同放大倍率下均取得了稳定且具有竞争力的结果。消融实验验证了频域增强模块与频域损失的互补作用, 可视化结果表明该方法在建筑边界、道路结构及复杂纹理区域具有较好的细节恢复能力。

本文方法主要面向高保真重建任务, 其性能增益更多体现在局部高频细节补偿, 因此平均 PSNR 提升幅度相对有限。后续将进一步面向真实遥感退化场景, 研究噪声、压缩及传感器退化条件下的自适应超分辨率重建方法, 以提升实际应用能力。

参考文献

- [1] 成科扬, 荣兰, 蒋森林, 等. 基于深度学习的遥感图像超分辨率重建方法综述[J]. 郑州大学学报(工学版), 2022, 43(5): 8-16.
- [2] Lepcha, D.C., Goyal, B., Dogra, A. and Goyal, V. (2023) Image Super-Resolution: A Comprehensive Review, Recent Trends, Challenges and Applications. *Information Fusion*, **91**, 230-260. <https://doi.org/10.1016/j.inffus.2022.10.007>
- [3] Dong, C., Loy, C.C., He, K. and Tang, X. (2016) Image Super-Resolution Using Deep Convolutional Networks. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, **38**, 295-307. <https://doi.org/10.1109/tpami.2015.2439281>
- [4] Kim, J., Lee, J.K. and Lee, K.M. (2016) Accurate Image Super-Resolution Using Very Deep Convolutional Networks. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27-30 June 2016, 1646-1654. <https://doi.org/10.1109/cvpr.2016.182>
- [5] Lim, B., Son, S., Kim, H., Nah, S. and Lee, K.M. (2017) Enhanced Deep Residual Networks for Single Image Super-resolution. 2017 *IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, Honolulu, 21-26 July 2017, 136-144. <https://doi.org/10.1109/cvprw.2017.151>
- [6] Zhang, Y., Li, K., Li, K., Wang, L., Zhong, B. and Fu, Y. (2018) Image Super-Resolution Using Very Deep Residual Channel Attention Networks. In: Ferrari, V., Hebert, M., Sminchisescu, C. and Weiss, Y., Eds., *Lecture Notes in Computer Science*, Springer International Publishing, 294-310. https://doi.org/10.1007/978-3-030-01234-2_18
- [7] Ledig, C., Theis, L., Huszar, F., Caballero, J., Cunningham, A., Acosta, A., et al. (2017) Photo-Realistic Single Image Super-Resolution Using a Generative Adversarial Network. 2017 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, 21-26 July 2017, 4681-4690. <https://doi.org/10.1109/cvpr.2017.19>
- [8] Wang, X., Yu, K., Wu, S., Gu, J., Liu, Y., Dong, C., et al. (2019) ESRGAN: Enhanced Super-Resolution Generative Adversarial Networks. In: Leal-Taixé, L. and Roth, S., Eds., *Lecture Notes in Computer Science*, Springer International Publishing, 63-79. https://doi.org/10.1007/978-3-030-11021-5_5
- [9] Dong, X., Wang, L., Sun, X., Jia, X., Gao, L. and Zhang, B. (2021) Remote Sensing Image Super-Resolution Using Second-Order Multi-Scale Networks. *IEEE Transactions on Geoscience and Remote Sensing*, **59**, 3473-3485. <https://doi.org/10.1109/tgrs.2020.3019660>
- [10] Dong, X., Sun, X., Jia, X., Xi, Z., Gao, L. and Zhang, B. (2021) Remote Sensing Image Super-Resolution Using Novel Dense-Sampling Networks. *IEEE Transactions on Geoscience and Remote Sensing*, **59**, 1618-1633. <https://doi.org/10.1109/tgrs.2020.2994253>
- [11] Liu, Z., Feng, R., Wang, L., Zhong, Y., Zhang, L. and Zeng, T. (2022) Remote Sensing Image Super-Resolution via Dilated Convolution Network with Gradient Prior. *IGARSS 2022-2022 IEEE International Geoscience and Remote Sensing Symposium*, Kuala Lumpur, 17-22 July 2022, 2402-2405. <https://doi.org/10.1109/igarss46834.2022.9883673>
- [12] Yao, P., He, P., Cheng, S., Fu, L., Guo, Z. and Zhao, J. (2022) Dynamic Multi-Scale Network for Remote Sensing Image Super-Resolution. *IGARSS 2022-2022 IEEE International Geoscience and Remote Sensing Symposium*, Kuala Lumpur, 17-22 July 2022, 3766-3769. <https://doi.org/10.1109/igarss46834.2022.9883063>

-
- [13] Jia, S., Wang, Z., Li, Q., Jia, X. and Xu, M. (2022) Multiattention Generative Adversarial Network for Remote Sensing Image Super-Resolution. *IEEE Transactions on Geoscience and Remote Sensing*, **60**, 1-15. <https://doi.org/10.1109/tgrs.2022.3180068>
- [14] Dong, X., Xi, Z., Sun, X. and Yang, L. (2020) Remote Sensing Image Super-Resolution via Enhanced Back-Projection Networks. *IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium*, Waikoloa, 26 September 2020-2 October 2020, 1480-1483. <https://doi.org/10.1109/igarss39084.2020.9323316>
- [15] Li, J., Fang, F., Mei, K. and Zhang, G. (2018) Multi-Scale Residual Network for Image Super-Resolution. In: Ferrari, V., Hebert, M., Sminchisescu, C. and Weiss, Y., Eds., *Lecture Notes in Computer Science*, Springer International Publishing, 527-542. https://doi.org/10.1007/978-3-030-01237-3_32
- [16] Shi, W., Caballero, J., Huszar, F., Totz, J., Aitken, A.P., Bishop, R., *et al.* (2016) Real-Time Single Image and Video Super-Resolution Using an Efficient Sub-Pixel Convolutional Neural Network. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27-30 June 2016, 1874-1883. <https://doi.org/10.1109/cvpr.2016.207>
- [17] Xu, K., Qin, M., Sun, F., *et al.* (2020) Learning in the Frequency Domain. 2020 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Seattle, 13-19 June 2020, 1740-1749.
- [18] Zhao, H., Gallo, O., Frosio, I. and Kautz, J. (2017) Loss Functions for Image Restoration with Neural Networks. *IEEE Transactions on Computational Imaging*, **3**, 47-57. <https://doi.org/10.1109/tci.2016.2644865>
- [19] Fuoli, D., Van Gool, L. and Timofte, R. (2021) Fourier Space Losses for Efficient Perceptual Image Super-Resolution. 2021 *IEEE/CVF International Conference on Computer Vision (ICCV)*, Montreal, 10-17 October 2021, 2360-2369. <https://doi.org/10.1109/iccv48922.2021.00236>
- [20] Keys, R. (1981) Cubic Convolution Interpolation for Digital Image Processing. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, **29**, 1153-1160. <https://doi.org/10.1109/tassp.1981.1163711>