

融合频域调制的多尺度高光谱图像去噪网络

李家祥

内蒙古大学数理科学学院, 内蒙古 呼和浩特

收稿日期: 2026年6月3日; 录用日期: 2026年6月25日; 发布日期: 2026年7月7日

摘要

高光谱图像(Hyperspectral Image, HSI)在遥感解译、目标识别和精细分类等任务中具有重要应用价值。然而,受传感器噪声和复杂成像环境影响,高光谱图像易受到高斯噪声干扰导致结构退化和光谱失真。针对现有方法在细节恢复与光谱一致性保持方面的不足,本文提出一种融合频域先验引导与特征调制机制的高光谱图像去噪网络。该方法构建多尺度特征提取网络,将频域统计信息嵌入特征调制过程,并设计三参数调制模块,实现对不同尺度特征响应的自适应调控。同时,引入轻量化通道增强模块和弱高频残差增强模块,以提升边缘纹理恢复能力;并在损失函数中加入光谱角约束,以增强光谱一致性。ICVL数据集上的实验结果表明,本文方法在PSNR、SSIM和SAM等指标上均取得较优性能,可视化结果进一步验证了其在边缘结构恢复与细节重建方面的有效性。

关键词

高光谱图像去噪, 多尺度特征融合, 频域先验, 参数调制

Multi-Scale Hyperspectral Image Denoising Network with Frequency-Prior Guided Modulation

Jiexiang Li

School of Mathematical Sciences, Inner Mongolia University, Hohhot Inner Mongolia

Received: June 3, 2026; accepted: June 25, 2026; published: July 7, 2026

Abstract

Hyperspectral images (HSIs) play an important role in remote sensing interpretation, target recognition, and fine-grained classification. However, due to sensor noise and complex imaging conditions, HSIs are often contaminated by Gaussian noise, stripe noise, and mixed noise, resulting in spatial structure degradation and spectral distortion. To address the limitations of existing methods in

detail restoration and spectral consistency preservation, this paper proposes a hyperspectral image denoising method that integrates frequency-prior guidance and feature modulation. The proposed method constructs a multi-scale feature extraction network, embeds frequency-domain statistical information into the feature modulation process, and designs a triple-parameter modulation module to adaptively regulate feature responses at different scales. Meanwhile, a lightweight channel enhancement module and a weak high-frequency residual enhancement module are introduced to improve edge and texture restoration. In addition, a spectral-angle constraint is incorporated into the loss function to enhance spectral consistency. Experimental results on the ICVL dataset show that the proposed method achieves superior performance in terms of PSNR, SSIM, and SAM. Visual results further verify its effectiveness in edge structure recovery and detail reconstruction.

Keywords

Hyperspectral Image Denoising, Multiscale Feature Fusion, Frequency Do-Main Prior, Parameter Modulation

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

高光谱图像能够在连续窄波段上获取丰富的光谱信息，在遥感解译、目标识别及精细分类等任务中具有重要应用价值。然而，受传感器噪声及复杂成像环境影响，高光谱图像[1]在采集过程中容易受到高斯噪声干扰，从而导致空间结构退化与光谱失真。因此，在保持空间结构信息与光谱一致性的前提下实现高效去噪，成为高光谱图像处理领域的重要研究问题。传统高光谱图像去噪方法主要基于滤波、稀疏表示以及低秩约束等模型驱动思想。这类方法在特定场景下能够取得一定效果，但对于复杂混合噪声的适应能力有限，同时优化求解过程通常具有较高计算开销。近年来，深度学习[2]方法在高光谱图像去噪任务[3]中取得了显著进展。卷积神经网络[4]能够通过数据驱动方式学习复杂的非线性映射关系，在空间信息与光谱信息联合建模方面表现出较强优势。尤其是多尺度特征[5]融合结构，通过不同分辨率下的特征交互增强网络的上下文建模能力，已成为当前研究的重要方向。同时，频域信息由于能够从全局角度刻画图像中的低频结构与高频细节，也逐渐被引入图像复原任务[6]中。近年来，Fourier Convolution、MWCNN等方法通过将可学习频域操作嵌入深度网络，显著提升了模型对纹理与全局依赖关系的建模能力。然而，现有高光谱图像去噪方法[7]-[9]在频域信息利用与跨尺度特征交互方面仍存在一定不足。一方面，频域信息[10]往往仅作为辅助特征引入，与空间域特征之间缺乏深度耦合，难以充分发挥其对高频结构恢复的指导作用；另一方面，现有特征调制机制大多采用固定或弱自适应方式，缺乏针对不同噪声类型与结构复杂度的动态调节能力，在细节恢复与噪声抑制之间难以取得理想平衡。此外，高光谱图像中相邻波段之间具有较强相关性，仅依赖空间域建模容易导致光谱曲线出现局部震荡与偏移，从而影响光谱一致性。

针对上述问题，本文提出一种融合频域先验引导与三参数特征调制机制的高光谱图像去噪方法。首先，在多尺度特征提取过程中引入频域统计信息，通过频域分解获取高频响应与全局频率分布特征，从而增强模型对真实结构与噪声成分的区分能力。随后，设计三参数特征调制模块，通过特征缩放、归一化调制以及偏置校正实现对不同尺度特征响应的自适应调节，以提升模型对复杂噪声场景的建模能力。在特征融合阶段，引入轻量化通道增强模块，对关键通道特征进行选择性强化的，从而在保证计算效率的

同时提升特征表达能力。此外，在输出阶段构建弱高频残差增强模块，通过对高频细节进行受控补偿，在避免噪声放大的同时进一步提升边缘纹理恢复效果。在 ICVL 高光谱数据集上的实验结果表明，本文方法在峰值信噪比(PSNR)、结构相似性(SSIM)以及光谱角映射(SAM)等指标上均优于多种对比方法。图 1 是提出的网络模型架构，图中重要操作为 3×3 卷积以及特征融合。

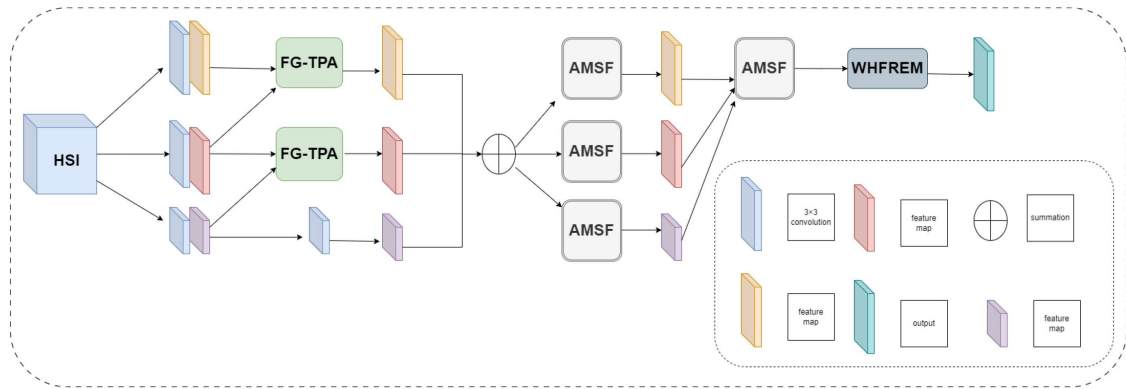


Figure 1. Proposed network architecture

图 1. 所提出的网络模型整体架构




Figure 2. Schematic diagram of key architectures for the proposed modules: FG-TPA, AMSF and WHFREEM.

图 2. 所提出的模块 FG-TPA AMSF WHFREEM 关键架构示意图

2. 模型架构

针对现有高光谱图像去噪方法在跨尺度特征交互与频域信息利用方面的不足，提出一种融合频域先验引导与三参数调制机制的多尺度高光谱图像去噪网络。如图 1 所示网络主要由初始特征提取模块、频域先验引导三参数调制模块(FG-TPA)、自适应多尺度融合模块(AMSF)以及弱高频残差增强模块(WHFREM)组成。给定输入高光谱图像，网络首先构建三个尺度的特征分支，以提取不同尺度下的局部纹理与结构信息。随后，通过频域先验引导的跨尺度调制机制实现多尺度特征交互，并利用自适应融合模块进一步增强特征表达能力。最后，在输出阶段引入弱高频残差增强模块，以补偿去噪过程中丢失的高频细节。如图 2 所示 FG-TPA AMSF WHFREEM 关键架构示意图，关于 FG-TPA 模块，传统调制方法通常仅利用缩放与偏置参数对归一化特征进行调节，难以同时兼顾原始特征响应与统计特征表达。为此，本文一种频域先验引导的三参数调制机制，通过联合建模原始特征、归一化特征及偏置补偿，实现更加灵活的特征调制，输入特征为 X ，其调制过程表示为：

$$Y = X + d_{\alpha} X + d_{\gamma} \hat{X} + d_{\beta},$$

其中 X 表示归一化特征， d_{α} 、 d_{γ} 与 d_{β} 分别表示原始特征调制项、归一化特征调制项与偏置补偿项。频域先验对引导特征首先对其进行二维快速傅里叶变换，并提取其对数幅度谱，以获得频域响应表示。随

后，利用径向频率掩码将幅度谱划分为高频区域与低频区域，并分别计算其全局统计描述，从而表征细节纹理信息与整体结构信息。同时，为保留原始空间域的全局上下文特征，进行全局平均池化，得到空间统计信息。最后，将空间域统计信息、低频统计信息和高频统计信息进行拼接，并通过卷积映射生成频域先验。该先验能够为后续调制参数的生成提供频率感知引导，使网络根据不同噪声退化特征自适应调整特征响应，从而提升结构保持与细节恢复能力。

$$P = \phi\left(\left[D_{sp}, D_{lf}, D_{hf} \right]\right),$$

其中 D_{sp} 、 D_{lf} 和 D_{hf} 分别表示空间域、低频域与高频域统计描述， $\phi(\cdot)$ 表示特征映射函数。最终，将频域先验与引导特征融合共同用于生成调制参数，从而实现空频联合引导的跨尺度特征调制。关于 AMSF 模块，该模块以三个尺度的特征 Y_1, Y_2, Y_3 为输入，首先通过通道拼接与全局平均池化获得跨尺度通道描述，并利用轻量非线性映射生成不同尺度的注意权重，实现多尺度特征的自适应加权融合。随后，引入自校准增强机制，通过通道变换分支与空间感知分支的协同作用，对融合特征中的结构信息和上下文关系进行进一步建模，从而增强特征表达能力。在此基础上，采用轻量通道门控机制对通道响应进行重标定，抑制冗余信息并突出关键特征。最终，模块通过残差连接保留原始融合信息，以提高训练稳定性和特征传递效率。整体而言，AMSF 能够在较低计算开销下实现跨尺度信息交互、结构校准与通道自适应增强，有助于提升复杂噪声条件下的细节恢复与结构保持能力。设三个尺度特征分别为 Y_1 、 Y_2 和 Y_3 。

其融合过程可表示为：

$$F_m = a_1 \odot Y_1 + a_2 \odot Y_2 + a_3 \odot Y_3,$$

其中 a_1, a_2, a_3 ，表示不同尺度对应的注意力权重。关于 WHFREM 模块，该模块首先对输入特征进行傅里叶变换，获得其幅值谱与相位信息，并利用高频掩码提取频域中的高频成分。随后，仅对高频幅值进行轻量化调制，在保持相位不变的条件下重建增强后的频域特征，从而尽量保留原始空间结构关系。为避免直接高频增强导致噪声被同步放大，模块采用残差补偿方式将增强结果弱注入原始特征中，使网络能够在细节恢复与噪声抑制之间取得平衡。其增强过程可表示为：

$$Y = X + \lambda(X_f - X),$$

其中， X_f 表示高频增强后的特征， λ 为残差缩放系数。该模块能够在保持整体稳定性的同时增强边缘与纹理细节恢复能力。同时由重建损失、梯度损失以及光谱余弦损失组成联合优化目标：

$$L_{total} = L_{denoise} + \lambda_{grad} L_{grad} + \lambda_{cos} L_{cos},$$

其中 $L_{denoise}$ 用于约束像素级重建误差， $\lambda_{grad} L_{grad}$ 用于增强边缘与结构信息恢复能力， $\lambda_{cos} L_{cos}$ 用于保持光谱一致性。联合损失能够同时兼顾空间结构恢复与光谱信息保持，从而提升整体去噪性能。

3. 数值实验

3.1. 实验设置

为验证所提方法的有效性，本文在公开高光谱图像数据集 ICVL 上开展实验，并从定量指标、可视化结果及消融实验等方面对模型性能进行评估。同时，在真实场景数据集 Indian Pines 上进行可视化分析，以进一步验证模型的实际去噪能力。

本文方法基于 PyTorch 实现，并在 NVIDIA GPU 平台上完成训练与测试。优化器采用 Adam，初始学习率设置为 0.0002，并结合阶段式学习率衰减策略进行优化。模型总训练轮数设置为 150 轮。输入样本尺寸为 $31 \times 128 \times 128$ ，其中 31 表示光谱维度。损失函数采用联合优化形式。

3.2. 实验结果

表 1 与图 3 给出了不同方法在 ICVL 数据集上、不同高斯噪声强度下的定量比较结果与视觉效果。可以看出, 传统方法在噪声增强时性能下降较为明显, 而深度学习方法整体表现优于传统模型。本文方法在三种噪声强度下均取得了较优的 PSNR 与 SSIM 结果, 说明所提出的频域先验引导调制与高频补偿机制在空间重建质量方面具有较强的有效性。进一步地, 从 SAM 指标可以看出, 本文方法在光谱一致性方面同样保持了较稳定的表现。尤其是在较强噪声场景下, 模型仍能获得较高的结构保持能力与较低的光谱角误差, 这说明频域先验引导的调制机制能够在复杂退化条件下提供更有针对性的结构增强, 而弱高频残差补偿则有助于减轻高噪声条件下的细节损失。

Table 1. Quantitative comparison results of different methods on the ICVL dataset under Gaussian noise with varying noise levels

表 1. 不同高斯噪声强度下各方法在 ICVL 数据集上的定量对比结果

Case	Index	Noisy	LRMR	BM4D	LRTV	MemNet	HSID-CNN	QRNN3D	Ours
$\sigma = 30$	PSNR	18.58	31.73	36.72	34.79	40.17	41.14	43.46	43.83
	SSIM	0.107	0.679	0.865	0.769	0.962	0.957	0.973	0.975
	SAM	0.703	0.179	0.143	0.157	0.074	0.096	0.038	0.036
$\sigma = 50$	PSNR	14.15	29.56	34.92	32.75	37.68	37.21	41.93	42.72
	SSIM	0.043	0.634	0.769	0.646	0.941	0.932	0.957	0.967
	SAM	0.890	0.214	0.192	0.194	0.093	0.124	0.040	0.039
$\sigma = 70$	PSNR	11.22	26.44	31.78	29.13	35.83	35.46	39.73	41.15
	SSIM	0.023	0.576	0.601	0.598	0.897	0.896	0.945	0.955
	SAM	1.013	0.282	0.231	0.252	0.097	0.148	0.051	0.041

从表 2 以看出, 随着频域先验引导三参数调制模块(FG-TPA)、自适应多尺度融合模块(AMSF)以及弱高频残差增强模块(WHFREM)逐步引入多尺度基础模型 B0, 网络模型性能持续提升。其中, 频域先验引导三参数调制能够有效增强结构与纹理表达, 多尺度融合进一步提升空间恢复能力, 而弱高频残差增强则有效补偿高频细节并改善光谱一致性。

Table 2. Ablation results of structural odules

表 2. 结构模块消融实验结果

Case	Index	B0	B1	B2	B3
$\sigma = 30$	PSNR	42.12	42.96	43.23	43.87
	SSIM	0.971	0.973	0.974	0.976
	SAM	0.041	0.037	0.035	0.032
$\sigma = 50$	PSNR	41.98	42.83	42.91	43.21
	SSIM	0.964	0.966	0.967	0.969
	SAM	0.054	0.049	0.047	0.039
$\sigma = 70$	PSNR	40.55	40.98	41.05	41.26
	SSIM	0.950	0.952	0.953	0.954
	SAM	0.064	0.058	0.056	0.042




Figure 3. Visual comparison under different Gaussian noise levels
图 3. 不同高斯噪声水平下的去噪结果对比




Figure 4. Visual comparison of real-scene false-color images under different band combinations.
图 4. 不同波段组合下真实场景假彩色可视化结果对比

在真实图像数据集 Indian Pines 上的实验效果如图 4 所示，可以看出在真实场景高光谱图像上的各方法存在差异。真实遥感场景中同时包含复杂纹理区域、边缘结构以及大面积平坦区域，因此该实验能够更直观地反映不同方法在空间结构恢复与光谱一致性保持方面的能力。对比的方法虽然能够有效降低部分随机噪声，但其恢复结果存在一定程度的过平滑现象，部分区域纹理细节被削弱，边缘结构清晰度下降，在复杂区域仍存在颜色偏移与局部伪影问题，部分区域出现较明显的条纹状结构。

相比之下，本文方法在不同波段组合下均能够较好地保持空间结构连续性与边缘清晰度。在局部放大区域中，本文方法恢复出的地物边界更加清晰，纹理过渡更加自然，同时能够有效抑制复杂噪声带来的伪影干扰。此外，在不同假彩色波段组合下，本文方法均表现出较好的光谱稳定性，整体颜色分布更加协调，说明所提出的频域引导三参数调制机制能够有效增强模型对高频纹理与光谱结构的联合建模能力，从而提升真实场景下的高光谱图像去噪效果。

可视化结果图 5 表明，空间高频能量主要集中于结构边界与纹理区域，调制参数 d_γ 在对应区域同样具有较强响应，二者 Pearson 相关系数为 0.3026，说明频域先验能够有效参与特征调制。同时 d_α 负责全局调节， d_γ 更关注高频结构， d_β 于局部细节补偿。综上，本文提出的方法能够通过频域先验引导特征调制，实现对结构细节与复杂噪声的有效建模，并在 PSNR、SSIM 与 SAM 等指标上取得较优性能。

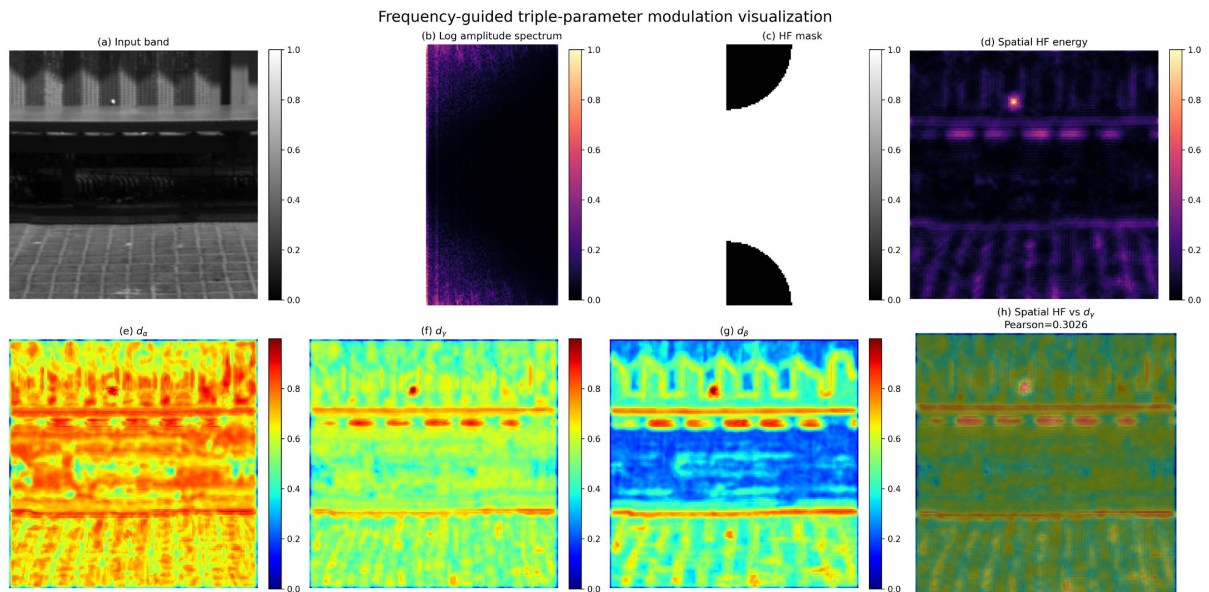


Figure 5. Visualization of frequency-guided parameter modulation

图 5. 频域先验引导的三参数调制可视化结果

4. 结论

本文提出一种融合频域先验引导与参数特征调制的高光谱图像去噪网络，通过引入频域先验信息，引导特征调制过程，实现对结构细节与复杂噪声的自适应建模。同时，结合多尺度特征融合与高频残差增强机制，进一步提升了模型对边缘纹理与光谱信息的恢复能力。实验结果表明，该方法在 PSNR、SSIM 与 SAM 等指标上均取得了较优性能，验证了所提方法的有效性与鲁棒性。

参考文献

- [1] Zhuang, L., Ng, M.K., Gao, L. and Wang, Z. (2024) Eigen-CNN: Eigenimages plus Eigennoise Level Maps Guided Network for Hyperspectral Image Denoising. *IEEE Transactions on Geoscience and Remote Sensing*, **62**, 1-18.

-
- <https://doi.org/10.1109/tgrs.2024.3379199>
- [2] Liang, H., Ke, C. and Li, K. (2025) Hybrid Spatial-Spectral Neural Network for Hyperspectral Image Denoising. In: Del Bue, A., *et al.*, Eds., *European Conference on Computer Vision*, Springer, 278-294. https://doi.org/10.1007/978-3-031-91838-4_17
- [3] Ma, R., Zhang, Y., Zhang, B., Fang, L., Huang, D. and Qi, L. (2024) Learning Attention in the Frequency Domain for Flexible Real Photograph Denoising. *IEEE Transactions on Image Processing*, **33**, 3707-3721. <https://doi.org/10.1109/tip.2024.3404253>
- [4] Li, M., Liu, J., Fu, Y., Zhang, Y. and Dou, D. (2023). Spectral Enhanced Rectangle Transformer for Hyperspectral Image Denoising. 2023 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Vancouver, 18-22 June 2023, 5805-5814. <https://doi.org/10.1109/cvpr52729.2023.00562>
- [5] Pan, H., Gao, F., Dong, J. and Du, Q. (2023) Multiscale Adaptive Fusion Network for Hyperspectral Image Denoising. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, **16**, 3045-3059. <https://doi.org/10.1109/jstars.2023.3257051>
- [6] Liu, N., Li, W., Wang, Y., Tao, R., Du, Q. and Chanussot, J. (2023) A Survey on Hyperspectral Image Restoration: From the View of Low-Rank Tensor Approximation. *Science China Information Sciences*, **66**, Article ID: 121301. <https://doi.org/10.1007/s11432-022-3609-4>
- [7] Lu, Y., Zheng, X., Xin, H., Tang, H., Wang, R. and Nie, F. (2023) Ensemble and Random Collaborative Representation-Based Anomaly Detector for Hyperspectral Imagery. *Signal Processing*, **204**, Article ID: 108835. <https://doi.org/10.1016/j.sigpro.2022.108835>
- [8] Wang, Z., Shao, Z., Huang, X., Wang, J. and Lu, T. (2022) SSCAN: A Spatial-Spectral Cross Attention Network for Hyperspectral Image Denoising. *IEEE Geoscience and Remote Sensing Letters*, **19**, 1-5. <https://doi.org/10.1109/lgrs.2021.3112038>
- [9] Chen, H., Yang, G. and Zhang, H. (2024) Hider: A Hyperspectral Image Denoising Transformer with Spatial-Spectral Constraints for Hybrid Noise Removal. *IEEE Transactions on Neural Networks and Learning Systems*, **35**, 8797-8811. <https://doi.org/10.1109/tnnls.2022.3215751>
- [10] Pan, E., Ma, Y., Mei, X., Huang, J., Fan, F. and Ma, J. (2023) D2Net: Deep Denoising Network in Frequency Domain for Hyperspectral Image. *IEEE/CAA Journal of Automatica Sinica*, **10**, 813-815. <https://doi.org/10.1109/jas.2022.106019>