



计算机科学

COMPUTER SCIENCE

面向高光谱图像去噪的超像素级图特征学习方法

吴颖, 叶海良, 曹飞龙

引用本文

吴颖, 叶海良, 曹飞龙. 面向高光谱图像去噪的超像素级图特征学习方法[J]. 计算机科学, 2025, 52(12): 189-199.

WU Ying, YE Hailiang, CAO Feilong. [Superpixel-level Graph Feature Learning Method for Hyperspectral Image Denoising](#) [J]. Computer Science, 2025, 52(12): 189-199.

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)

[基于改进ModernTCN的光伏发电中短期预测](#)

Prediction of Short-and-Medium Term Photovoltaic Power Generation Based on Improved ModernTCN
计算机科学, 2025, 52(11A): 241000164-7. <https://doi.org/10.11896/jsjcx.241000164>

[基于知识图谱嵌入的异构图欺诈用户检测](#)

Fraud User Detection Based on Heterogeneous Information Network with Knowledge Graph
Eembedding

计算机科学, 2025, 52(11A): 250400085-7. <https://doi.org/10.11896/jsjcx.250400085>

[基于多层级图表征增强的加密应用流量识别方法](#)

Classification of Encrypted Application Traffic Enhanced by Multi-level GraphRepresentation
计算机科学, 2025, 52(11A): 241200126-7. <https://doi.org/10.11896/jsjcx.241200126>

[基于消除语义特征的图像篡改定位模型对抗攻击](#)

Attacking Image Manipulation Localization Model by Eliminating Semantic Features
计算机科学, 2025, 52(11A): 241100104-7. <https://doi.org/10.11896/jsjcx.241100104>

[面向图垂直联邦学习的对抗攻击方法](#)

Adversarial Attack on Vertical Graph Federated Learning

计算机科学, 2025, 52(11A): 241200220-10. <https://doi.org/10.11896/jsjcx.241200220>

面向高光谱图像去噪的超像素级图特征学习方法

吴颖¹ 叶海良¹ 曹飞龙²

1 中国计量大学理学院 杭州 310018

2 浙江师范大学数学科学学院 浙江 金华 321014

(wuying991105@163.com)

摘要 基于传统深度学习的高光谱图像去噪方法通常难以捕捉空间位置的长程相关性和全局不规则局部块的相似性,导致去噪后细节信息丢失和结构完整性不足。为此,提出一种新的面向高光谱图像去噪的超像素级图特征学习方法,旨在利用图神经网络提取空谱特征,捕捉不规则局部块空间位置的长程相关性,以保留纹理细节和结构信息。首先,设计了门控注意力模块来抑制噪声并增强光谱相关性,为后续的超像素分割奠定基础。然后,设计了超像素级图聚合模块,将高光谱图像按空间维分割成多个空间相连的超像素,并使用共享线性层学习超像素中像素的加权值。接着,使用图卷积更新节点信息,从而有效地保持高光谱图像结构的完整性和内部细节的清晰度。最后,利用高光谱图像的低秩性,在训练过程中引入核范数正则化进行约束,提出了低秩-空谱损失,以关注结构信息的保留。实验结果表明,所提方法在性能上优于当前先进方法。

关键词 高光谱图像去噪;图神经网络;深度学习;空谱特征;核范数

中图分类号 TP751

Superpixel-level Graph Feature Learning Method for Hyperspectral Image Denoising

WU Ying¹, YE Hailiang¹ and CAO Feilong²

1 School of Sciences, China Jiliang University, Hangzhou 310018, China

2 School of Mathematical Sciences, Zhejiang Normal University, Jinhua, Zhejiang 321014, China

Abstract Hyperspectral image denoising methods based on traditional deep learning usually have difficulty capturing the long-range correlation of spatial positions and the similarity of global irregular local blocks, resulting in loss of detailed information and insufficient structural integrity after denoising. To this end, this paper proposes a new superpixel-level graph feature learning method for hyperspectral image denoising, which aims to use graph neural networks to extract spatial-spectral features and capture the long-range correlation of spatial positions of irregular local blocks to preserve texture details and structural information. Firstly, a gated attention module is designed to suppress noise and enhance spectral correlation, laying the foundation for subsequent superpixel segmentation. Then, a superpixel-level graph aggregation module is designed, which effectively maintains the structural integrity and clarity of internal details of the hyperspectral image by segmenting the hyperspectral image into multiple spatially connected superpixels according to the spatial dimensions and using a shared linear layer to learn the weighted values of pixels in the superpixel. Then, graph convolution is used to update the node information. Finally, nuclear norm regularization is introduced in the training process for constraint by taking advantage of the low rank of hyperspectral images, and a low-rank-spatial spectral denoising loss is proposed to focus on preserving structural information. Experimental results show that the proposed method outperforms the current advanced methods in performance.

Keywords Hyperspectral image denoising, Graph neural networks, Deep learning, Spatial-spectral features, Nuclear norm

1 引言

高光谱图像(Hyperspectral Images, HSI)蕴含丰富的光谱信息,成为了目标检测^[1]、环境监测^[2]和城市规划^[3]等领域的关键载体。然而,成像设备的内在缺陷或周围大气条件引

起的噪声,如高斯噪声、条纹状噪声及脉冲式噪声等^[4],严重破坏了HSI空谱结构的完整性,降低了分析结果的精确度。因此,探索有效的HSI去噪方法,对于提升高光谱图像应用的整体性能,具有重要的理论价值和实际意义。

现有的HSI去噪技术主要分为基于模型驱动的方法和

到稿日期:2025-01-13 返修日期:2025-04-23

基金项目:国家自然科学基金面上项目(62176244,62536006)

This work was supported by the National Natural Science Foundation of China(62176244,62536006).

通信作者:曹飞龙(caofeilong88@zjnu.edu.cn)

基于数据驱动的方法^[5]。前者主要基于对噪声特性的先验假设,通过建立优化模型并采用迭代技术达到去噪目的^[6]。该方法通常利用 HSI 的非局部自相似性^[7-8]、平滑性^[9-10]、稀疏性^[11-12]以及低秩性^[13-14]等内在特性,提供了良好的理论基础,但往往需要复杂的迭代计算和精细的参数调整。因此,在实际应用中,基于模型驱动的方法常面临计算成本高和处理时间长等问题,难以有效应对 HSI 复杂多变的噪声干扰。

随着基于数据驱动的深度学习方法快速发展,基于深度学习的 HSI 去噪方法,尤其是卷积神经网络(Convolutional Neural Network, CNN)已展现出强大潜力。2017 年, Xie 等^[15]首次将深度级联 CNN 应用于 HSI 去噪任务,显著提升了去噪性能,开创了深度学习方法在该领域的先河。Yuan 等^[16]利用多尺度二维卷积构建了空谱深度残差 CNN,用于提取多尺度特征。Dong 等^[17]则提出了基于三维 U 型递归神经网络的空谱表示学习方法,以处理 HSI 的三维空谱结构。为应对三维 CNN 参数量大、训练困难的问题, Ma 等^[18]结合二维与三维 CNN,设计了增强型非局部级联注意力网络。Kan 等^[19]通过引入三维可分离卷积进一步减少了参数量,并开发了基于注意力机制的密集网络。针对复杂噪声环境, Torun 等^[20]提出了光谱自调节残差模块,并通过多模型融合增强了网络的适应能力。Pan 等^[21]则通过挖掘 HSI 噪声的内在特性来估计光谱噪声分布,并以此为基础设计了一种引导机制,实现了更为精细的去噪效果。尽管基于 CNN 的方法在去除空间和光谱噪声方面表现出一定的有效性,但其依赖滑动窗口的操作机制限制了提取空间位置长程相关性的能力,如图 1(a)所示。这种局限性导致其在全局一致性、细节保留以及计算效率等方面仍存在明显不足。




图 1 CNN 和超像素级的 GNN 在信息处理方面的差异
(电子版为彩图)

Fig. 1 Differences in information processing between CNN and superpixel-level GNN

为此,近期部分研究者将 Transformer^[22]引入 HSI 去噪任务。通过自注意力机制建模空间位置上任意两个像素间的相关性,Transformer 能够捕捉全局空谱信息,减少细节丢失。Li 等^[23]分别在 HSI 的空间和光谱维度上使用 Transformer,构造了一种空谱 Transformer。Lai 等^[24]则将 CNN 的高效性与 Transformer 捕捉全局空谱相关性的优势结合,提出了一种混合光谱去噪 Transformer。然而,真实 HSI 中像素间的相关性通常是稀疏的,而非全局相关的。Transformer 全连接的建模方式,导致这些方法仅关注像素级别的上下文信息,难以有效捕捉全局范围内不规则局部相似块之间的纹理细节和

结构特征,且往往具有较高的计算复杂度。这种局限性使得在处理 HSI 时,局部细节信息容易丢失,结构边缘变得模糊,从而影响图像的清晰度。

此外,传统损失函数未能有效约束 HSI 的空谱结构特性,导致去噪结果在空间细节保留和光谱连续性上存在显著偏差。针对这一问题, Zhang 等^[25]提出了一种空谱梯度损失,以减少光谱失真。Wang 等^[26]则设计了一种基于全变分损失的空谱 Transformer,以保持 HSI 的平滑结构。然而,这些方法忽略了干净 HSI 在空间维度上的低秩先验,导致去噪结果的空间结构一致性不足。

综上所述,现有的 HSI 去噪方法尽管已取得一些成果,但仍存在以下关键问题亟需优化。

1)全局与局部特征的平衡:现有方法难以同时有效捕捉 HSI 全局空间位置的长程相关性和局部细节信息,导致去噪结果难以兼顾全局一致性与细节保留。

2)不规则局部相似块的长程建模:对 HSI 中不规则局部相似块的长程相关性捕捉不足,导致结构完整性难以保持,边缘模糊或纹理失真问题突出。

3)空谱结构的有效约束:去噪后, HSI 的光谱连续性和空间连贯性缺乏有效约束,易出现光谱失真或空间结构退化,影响后续分析与解释。

为解决这些问题,将图神经网络(Graph Neural Networks, GNNs)引入 HSI 去噪任务。GNNs 在处理图结构数据和建模复杂关系方面表现出色,被广泛应用于推荐系统^[27]、医学图像分割^[28]和 HSI 分类^[29]等任务。HSI 同类地表物质常聚成不规则局部块,分散于多个区域,且局部块内像素光谱特征相关性^[30]。如图 1(b)所示,黄色与灰色超像素呈现相似植被分布的不规则地表,黑线表示超像素质心(节点)之间的连接。因此,基于超像素级的 GNN 能有效捕捉全局不规则相似块的空间相关性,较传统方法保留了更多的边缘细节等结构信息。而在 HSI 去噪任务中,噪声干扰超像素分割的准确性,利用 GNN 联合空谱特征解决边缘结构丢失的问题尚未得到充分探索。本文旨在确保超像素分割准确的基础上,充分挖掘超像素级构图潜力,以提取超像素级特征,保证去噪后 HSI 结构完整,提升网络去噪性能。

为此,本文提出了一种新的面向 HSI 去噪的超像素级图特征学习方法(Superpixel-Level Graph Feature Learning Method for Hyperspectral Image Denoising, SGFL)。它主要由门控光谱注意力模块和卷积增强的超像素级特征提取模块组合而成,是自适应学习噪声特征的 HSI 去噪模型。门控光谱注意力模块通过融合通道注意力和门控机制的优势,提升光谱相关性,在网络前部抑制噪声。而卷积增强的超像素级特征提取模块先使用超像素级的图聚合模块进行超像素级特征提取,通过建模不规则局部块的空间长程相关性,有效整合全局空谱信息,在去噪时恢复边缘结构并保留细节纹理;再使用混合空洞卷积^[31]和门控光谱注意力模块增强其空间和光谱维信息。此外,本文引入核范数正则化和光谱差分约束,促进空间结构学习并保持光谱连续性,进而恢复真实完整的 HSI。总之,SGFL 框架巧妙地结合了 HSI 的低秩性、不规则

局部块的全局自相似性、全局光谱强相关性以及空谱结构,旨在保留更多的细节和结构信息,显著提升了 HSI 去噪性能。

本文主要贡献如下:

1) 设计了门控光谱注意力模块,用于捕捉全局背景信息与局部显著特征之间的互补性,以此自适应地区分噪声和有效信息,增强了光谱相关性,确保超像素分割的准确性。

2) 设计了超像素级图聚合模块。通过分割 HSI 为超像素,并利用共享线性层学习超像素的加权系数,有效地保持了边缘结构完整性和局部纹理清晰度。

3) 设计了均方差损失、空间维矩阵的核范数正则化以及光谱差分约束相融合的低秩-空谱损失,确保了空间维度的

低秩特性,并增强了光谱连续性。

2 超像素级图特征学习方法

假设 $\mathbf{Y} \in \mathbb{R}^{H \times W \times B}$ 是有噪声的 HSI, H 和 W 是空间分辨率, B 是光谱波段的数量。HSI 噪声退化模型描述为:

$$\mathbf{Y} = \mathbf{X} + \mathbf{N} \quad (1)$$

其中, $\mathbf{X} \in \mathbb{R}^{H \times W \times B}$ 是无噪声的 HSI, $\mathbf{N} \in \mathbb{R}^{H \times W \times B}$ 是噪声,如高斯噪声、条纹噪声、脉冲噪声、Deadline 噪声及其混合噪声。为从 \mathbf{Y} 中有效恢复 \mathbf{X} , 本文提出超像素级图特征学习方法,去噪后的 HSI 表示为 $\hat{\mathbf{X}} \in \mathbb{R}^{H \times W \times B}$ 。网络整体框架如图 2 所示。




图 2 网络整体框架示意图

Fig. 2 Schematic diagram of the overall network framework

首先,为使后续超像素级的图聚合模块能够精准地使用简单线性迭代聚类算法^[32],使用三维卷积、动态卷积^[33]和二维卷积对含噪声的 HSI \mathbf{Y} 进行预处理,而后采用门控光谱注意力模块强化光谱相关性。经过处理,光谱维度从 B 降至 C ,且 C 远小于 B 。上述操作能够以函数 $f(\cdot)$ 予以表征,所得结果记为 $\mathbf{P}_0 \in \mathbb{R}^{H \times W \times C}$, 即:

$$\mathbf{P}_0 = f(\mathbf{Y}) \quad (2)$$

然后,为保持结构完整性并增强网络的表示能力,本文构建了卷积增强的超像素级特征提取模块。该模块在网络中连续堆叠 n 层,通过跳跃连接将每层输出直接传递到后续所有层,直至第 n 层,强化特征传输和融合。对于第 i 层输出 $\mathbf{P}_i \in \mathbb{R}^{H \times W \times C}$, 有:

$$\mathbf{P}_i = \sum_{k=0}^{i-1} \mathbf{P}_k + \text{CSFE}(\mathbf{P}_{i-1}), i=1, 2, \dots, n \quad (3)$$

其中, $\text{CSFE}(\cdot)$ 表示卷积增强的超像素级特征提取模块,由超像素级的图聚合模块、混合空洞卷积^[31]以及门控光谱注意力模块搭建而成。超像素级的图聚合模块专注于提取超像素级特征。混合空洞卷积膨胀率为 $[1, 3, 5, 1, 3, 5]$,通过提取空间维度上的多尺度特征,增强局部细节和结构信息。门控光谱注意力模块进一步增强光谱相关性,以便更好地学习复杂噪声特征。这些模块相互协同,有效提取和融合了多层次特征。




图 3 门控光谱注意力模块示意图

Fig. 3 Schematic diagram of the gated spectral attention module

接着,利用 Transformer 作为特征增强模块,对第 n 层的输出特征表示 \mathbf{P}_n 进行全局信息增强,以提升特征表示的全面性和准确性。若用 $\mathbf{E} \in \mathbb{R}^{H \times W \times C}$ 表示网络学习到的噪声,则去噪后的特征表示 $\mathbf{R} \in \mathbb{R}^{H \times W \times C}$ 可由式(4)得到:

$$\mathbf{R} = \mathbf{F} - \mathbf{E} \quad (4)$$

最后, \mathbf{R} 被传入一个三维卷积 $\text{Rec}(\cdot)$ 重构,以学习和恢复潜在干净的 HSI $\hat{\mathbf{X}} \in \mathbb{R}^{H \times W \times B}$, 即:

$$\hat{\mathbf{X}} = \text{Rec}(\mathbf{R}) \quad (5)$$

下面介绍网络的关键模块:门控光谱注意力模块和超像素级的图聚合模块。

2.1 门控光谱注意力模块

网络预处理操作会在一定程度上降低光谱相关性。因此,本文结合门控机制与文献^[34]的通道注意力模块,设计了门控光谱注意力模块。如图 3 所示,根据通道注意力机制生成注意力图 $\mathbf{a} \in \mathbb{R}^{1 \times 1 \times C}$:

$$\mathbf{a} = \rho(\text{MLP}(\text{Max}(\mathbf{F}_{in})) + \text{MLP}(\text{Avg}(\mathbf{F}_{in}))) \quad (6)$$

其中, $\mathbf{F}_{in} \in \mathbb{R}^{H \times W \times C}$ 是输入特征图, $\text{Max}(\cdot)$ 和 $\text{Avg}(\cdot)$ 分别表示平均和最大池化层, $\text{MLP}(\cdot)$ 是共享的多层感知器, $\rho(\cdot)$ 为 Sigmoid 函数。

其次,将注意力图 \mathbf{a} 乘 \mathbf{F}_{in} , 得到光谱注意力特征图 $\mathbf{F}_{att} \in \mathbb{R}^{H \times W \times C}$:

$$\mathbf{F}_{att} = \mathbf{F}_{in} \otimes \mathbf{a} \quad (7)$$

其中, \otimes 表示逐元素相乘。

之后,通过门控机制进一步增强特征图,其经过一个 1×1 卷积层 $Conv(\cdot)$, 并通过 Sigmoid 函数生成门控信号。

最后,将门控信号与 \mathbf{F}_{in} 逐元素相乘,进行信息传递,得到增强后的特征图 $\mathbf{F}_{out} \in \mathbb{R}^{H \times W \times C}$:

$$\mathbf{F}_{out} = \mathbf{F}_{in} \otimes \rho(Convl([\mathbf{F}_{in}, \mathbf{F}_{att}])) \quad (8)$$

其中, $[\cdot, \cdot]$ 表示按通道维拼接。

上述模块通过捕捉全局背景信息和局部显著特征的互补性,自适应地区分光谱维噪声和有效信息。之后通过门控机制增强光谱间的相关性,为后续特征提取提供更好的基础。

2.2 超像素级的图聚合模块

传统图像的超像素通常采用简单线性迭代聚类算法进行分割^[35]。该算法作为前向传播中的非参数化预处理模块,不包含可学习参数,因此不参与网络的训练过程。然后,求超像素内所有像素的平均值,并将其作为超像素的质心,以此构建 GNN 的节点。该方法生成的关联矩阵值为 0 或 1,表示像素与超像素之间的对应关系。然而,这种简单的连接方式在从 HSI 的图表示恢复到网格表示的过程中,会导致严重的过平滑问题,影响网络对噪声的学习和对细节信息的修复。为克服此问题,设计超像素级的图聚合模块,如图 4 所示。

1) 图编码器。图编码器是关键组件,其核心是生成关联矩阵,细节如图 5 所示。首先,采用简单线性迭代聚类算法将输入特征图 $\mathbf{F} \in \mathbb{R}^{H \times W \times C}$ 划分为 S 个空间相连且光谱相似的超像素集 $\mathbf{S}_i = \{z_1^i, z_2^i, \dots, z_{P_i}^i\}$, $i = 1, 2, \dots, S$ 。其中, $z_{P_i}^i$ 表示在 \mathbf{S}_i 中的第 P_i 个像素, P_i 表示第 i 个超像素 \mathbf{S}_i 中包含的像素总数 ($\mathbf{S}_i \cap \mathbf{S}_j = \emptyset, \forall i \neq j$, 且 $H \times W = \sum_{i=1}^S P_i$)。接着,通过设

置共享线性层来学习超像素 \mathbf{S}_i 中各像素的权值系数 $\theta_i \in \mathbb{R}^{1 \times P_i}$, $i = 1, 2, \dots, S$ 。最后,对 \mathbf{S}_i 加权求和,得到超像素加权质心 $\mathbf{v}_i \in \mathbb{R}^{1 \times C}$, $i = 1, 2, \dots, S$:

$$\mathbf{v}_i = \theta_i * \mathbf{S}_i \quad (9)$$

其中, $*$ 表示矩阵乘法。由于超像素中所包含像素数量不同,无法将上述分割方法直接集成到超像素级图聚合模块中。受文献[36]启发,通过应用数据转换,允许特征在像素和超像素之间传播,如图 5 所示。具体地,设 $\mathbf{Q} \in \mathbb{R}^{N \times S}$ 是像素与超像素之间的关联矩阵,其中 S 表示超像素数量, N 表示输入特征图 \mathbf{F} 的所有像素数量,则有:

$$\mathbf{Q}_{i,j} = \begin{cases} \theta_i, & \text{if } z_i \in \mathbf{S}_j \\ 0, & \text{if } z_i \notin \mathbf{S}_j \end{cases}, \mathbf{Z} = Flatten(\mathbf{F}) \quad (10)$$

其中, $Flatten(\cdot)$ 表示按空间维度展平 HSI 数据, z_i 表示 $\mathbf{Z} \in \mathbb{R}^{N \times C}$ 中的第 i 个像素, \mathbf{S}_j 是第 j 个超像素, $\mathbf{Q}_{i,j}$ 表示在位置 (i, j) 处 \mathbf{Q} 的值。然后,使用式(11)表示图编码器:

$$\mathbf{V} = \hat{\mathbf{Q}}^T Flatten(\mathbf{F}) \quad (11)$$

其中, $\mathbf{V} = (\mathbf{v}_i)_{S \times C}$ 是节点特征矩阵, $\hat{\mathbf{Q}} \in \mathbb{R}^{N \times S}$ 表示按列归一化的 \mathbf{Q} , 即 $\hat{\mathbf{Q}}_{i,j} = \mathbf{Q}_{i,j} / \sum_k \mathbf{Q}_{k,j}$ 。而后,构建一个节点数为 S 且节点特征维度为 C 的图 $\mathbf{G} = (\mathbf{V}, \mathbf{A})$, 其中 $\mathbf{A} = (a_{ij})_{S \times S}$ 是邻接矩阵, a_{ij} 是节点 i 和节点 j 之间的边权值。




图 4 超像素级图聚合模块示意图

Fig. 4 Schematic diagram of the superpixel-level graph aggregation module

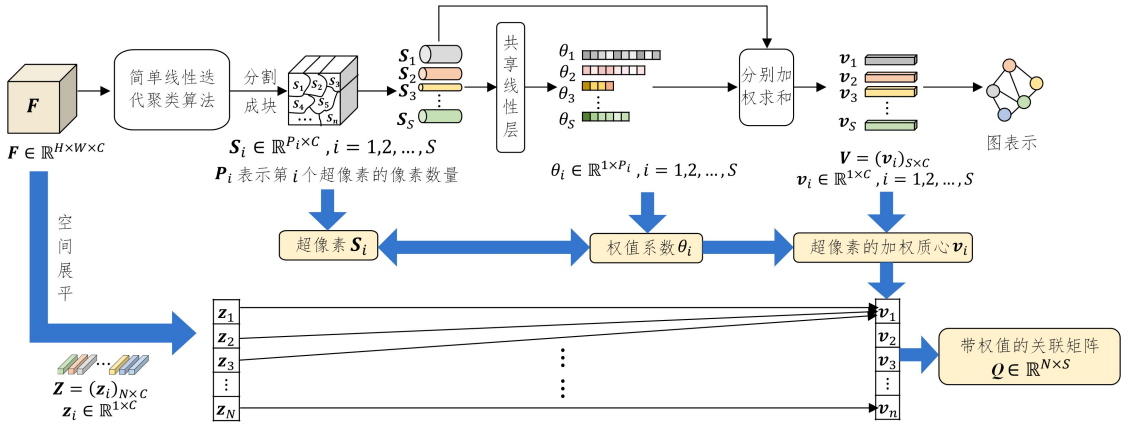


图 5 图编码器的示意图

Fig. 5 Schematic diagram of the graph encoder

2) 图聚合。通过式(11),可以快速将 HSI 编码为图节点。下面利用 GNN 进行处理,构建包含空谱信息的图结构,有效揭示 HSI 的空间特征。首先,计算图 \mathbf{G} 中节点特征间的余弦相似度。第 i 个节点特征 \mathbf{v}_i 和第 j 个节点特征 \mathbf{v}_j 之间的余弦相似度 m_{ij} 为:

$$m_{ij} = \frac{\mathbf{v}_i^T \mathbf{v}_j}{\|\mathbf{v}_i\|_2 \|\mathbf{v}_j\|_2}, j \neq i \quad (12)$$

其中, $\|\cdot\|$ 是欧几里德范数。对于第 i 个节点,选择 K 个相似度最高的节点作为邻居, \mathcal{N}_i 是其邻居节点集合。因此,图 \mathbf{G} 的邻接矩阵 $\mathbf{A} = (a_{ij})_{S \times S}$ 满足:

$$a_{ij} = \begin{cases} m_{ij}, & \text{if } j \in \mathcal{N}_i \\ 0, & \text{if } j \notin \mathcal{N}_i \end{cases} \quad (13)$$

最后,对于第 i 个节点,更新后的特征向量 $\mathbf{v}'_i \in \mathbb{R}^{1 \times C}$ 是其所有邻居特征的加权和:

$$\mathbf{v}_i' = \varphi\left(\sum_{j \in \mathcal{N}_i} a_{ij} \mathbf{v}_j \mathbf{W}\right) \quad (14)$$

其中, $\mathbf{W} \in \mathbb{R}^{C \times C}$ 是参数矩阵, $\varphi(\cdot)$ 是 LeakyReLU 激活函数。完成全局相似节点的特征聚合后,更新节点特征,记为 $\mathbf{v}' = (\mathbf{v}_i')_{S \times C}$ 。

3) 图解码器。为将节点特征传播到像素,利用关联矩阵 \mathbf{Q} 定义图解码器,通过将图特征投影回图像空间,形成三维立方体特征图,记作 $\mathbf{S} \in \mathbb{R}^{H \times W \times C}$:

$$\mathbf{S} = \text{Reshape}(\mathbf{Q}\mathbf{V}') \quad (15)$$

综上,超像素级的图聚合模块在捕捉不规则局部块的空间长程相关性和保持清晰度方面表现出色。此外,超像素的聚合方式允许模型在更大范围内考虑相似特征,更全面地提取了空谱特征,增强了模型对复杂噪声的适应性。

2.3 低秩-空谱损失

传统的均方误差损失 $\mathcal{L}_{\text{spatial}}$ 能较好恢复 HSI 的空间信息:

$$\mathcal{L}_{\text{spatial}} = \|\hat{\mathbf{X}} - \mathbf{X}\|_2^2 \quad (16)$$

其中, $\hat{\mathbf{X}}, \mathbf{X} \in \mathbb{R}^{H \times W \times B}$ 分别是去噪后和干净的 HSI。HSI 去噪不能仅关注空间信息,还需重视结构特征。由于干净 HSI 在空间上通常具有低秩性,为有效抑制噪声并保持图像空间结构,本文引入 $\hat{\mathbf{X}}$ 的空间维度矩阵 $\hat{\mathbf{X}}_{\text{flatten}} \in \mathbb{R}^{N \times C}$ (N 是空间像素总数, C 是光谱通道数)的核范数正则化 $\mathcal{L}_{\text{nuclear}}$:

$$\mathcal{L}_{\text{nuclear}} = \|\hat{\mathbf{X}}_{\text{flatten}}\|_* \quad (17)$$

其中, $\|\cdot\|_*$ 表示矩阵的核范数。 $\mathcal{L}_{\text{nuclear}}$ 促使去噪后 HSI 在空间维度上保持低秩特性,从而保留图像的结构信息。

此外,为了抑制光谱失真,本文还引入了文献[25]的光谱差分约束 $\mathcal{L}_{\text{spectral}}$:

$$\begin{cases} \mathcal{L}_{\text{spectral}} = \|\hat{\mathbf{D}} - \mathbf{D}\|_2^2 \\ \hat{\mathbf{D}}_{:,i} = \text{Flatten}(\hat{\mathbf{X}}_{:,i+1} - \mathbf{X}_{:,i+1}), i=1, \dots, C-1 \\ \mathbf{D}_{:,i} = \text{Flatten}(\mathbf{X}_{:,i+1} - \mathbf{X}_{:,i}) \end{cases} \quad (18)$$

其中, $\hat{\mathbf{X}}_{:,i}, \mathbf{X}_{:,i} \in \mathbb{R}^{H \times W}$ 表示 $\hat{\mathbf{X}}$ 和 \mathbf{X} 的第 i 个波段的二维图像矩阵; $\hat{\mathbf{D}}, \mathbf{D} \in \mathbb{R}^{N \times (C-1)}$ 表示 $\hat{\mathbf{X}}$ 和 \mathbf{X} 的光谱差分矩阵; $\hat{\mathbf{D}}_{:,i}, \mathbf{D}_{:,i} \in \mathbb{R}^{N \times 1}$ 表示 $\hat{\mathbf{D}}$ 和 \mathbf{D} 的第 i 列向量。去噪后 HSI $\hat{\mathbf{X}}$ 光谱恢复越好, $\hat{\mathbf{D}}$ 与 \mathbf{D} 差异就越小。

综上,本文构造的低秩-空谱损失 \mathcal{L} 为:

$$\mathcal{L} = \mathcal{L}_{\text{spatial}} + \lambda_1 \cdot \mathcal{L}_{\text{nuclear}} + \lambda_2 \cdot \mathcal{L}_{\text{spectral}} \quad (19)$$

其中, λ_1 和 λ_2 为超参数。

3 实验及结果分析

3.1 数据集

本文使用 3 个 HSI 数据集¹⁾来评估 SGFL 模型的有效性: Washington DC Mall(WDC), Urban 和 Indian Pines(IP)。WDC 数据集被用于模拟数据实验, Urban 和 IP 数据集则被用于真实数据实验。

1) WDC。该数据集通过 HYDICE 机载传感器采集

而来,其空间分辨率为 1208×303 , 包含 191 个波段。首先,将该数据集划分为 $1080 \times 303 \times 191$ 的训练数据集和 $200 \times 200 \times 191$ 的测试数据。然后,向 WDC 数据集中添加合成噪声。最后,对数据进行裁剪,并将采样步长设定为 34,以生成 $64 \times 64 \times 191$ 的立方体样本。为了高效训练 HSI 去噪模型,对训练样本进行多角度图像旋转以及多尺度大小调整,与文献[19]一致。同时,为全面评估不同 HSI 去噪方法在各种噪声下的表现,在 WDC 数据集上合成两类常见噪声,即高斯噪声和混合噪声,进行模拟实验。

(1) 高斯噪声。与文献[16]一致,对 WDC 数据集分别加入不同噪声水平 $\sigma = [50 \ 75 \ 100]$ 的高斯噪声。

(2) 混合噪声。采用文献[20]中的复杂混合噪声模型。每个波段都受到噪声水平为 $10 \sim 70$ 的随机变化的高斯噪声的影响,增加了噪声的不确定性。此外,每个波段还受到一种或多种特定类型噪声的污染,包括条纹噪声、Deadline 和脉冲噪声。条纹和 Deadline 通过在波段的随机行或列中选择 $5\% \sim 15\%$ 的位置添加,以模拟现实中条纹和竖线的干扰。在每个受脉冲噪声影响的波段随机分配值为 $10\% \sim 70\%$ 的噪声强度,以模拟现实中的突发干扰。

2) Urban。该数据集也由 HYDICE 获取,共 307×307 个空间像素,其中每个像素表示 $2\text{m} \times 2\text{m}$ 的地表面积,共有 210 个波段。

3) IP。该数据集由机载可见光红外成像光谱仪采集,包含 145×145 空间像素以及 224 个光谱波段。

为了将 SGFL 应用于真实 HSI 数据集(Urban 和 IP)的去噪,对这两个数据集进行了处理。以 Urban 数据集为例,首先对其进行数据归一化处理。然后,按照空间维度进行裁剪,裁剪后的尺寸与训练集的一致,均为 64×64 ,采样步长设定为 27,生成 $64 \times 64 \times 210$ 的立方体样本。将处理好的 Urban 数据集输入在 WDC 数据集上训练好的去噪模型中进行泛化实验(混合噪声情形)。最后,对去噪后的立方体样本进行复原,重叠部分采用取平均策略进行处理。

3.2 实验设置

1) 实现细节。所有实验均在一台配备 NVIDIA GeForce RTX 2080 Ti GPU(11GB 显存)的 Windows 服务器上完成。实验配置如下:操作系统为 Microsoft Windows,编程语言使用 Python v3.8.18,深度学习框架为 PyTorch v1.9.0,并集成 CUDA 10.2 加速库以支持 GPU 计算。SGFL 网络参数通过 Xavier 初始化器^[37]进行初始化,并使用 Adam 优化器^[38]进行更新。初始学习率为 0.0002,批量大小设为 4。模型经过 600 轮训练,每 60 轮后学习率按 0.5 的因子衰减。对每个噪声水平进行 10 次重复实验,以确保评估结果的准确性和稳定性。预处理阶段, C 设置为 64。网络中,使用 $n=2$ 层卷积增强的超像素级特征提取模块(Convolution-Enhanced Superpixel Feature Extraction Module, CSFEM)提取细节与结构信息。为确保超像素级的图聚合模块(Superpixel-Level Graph Aggregation Module, SGAM)中邻接矩阵 \mathbf{A} 的稀疏性,将 K 值和 S 值分别经验性地设定为 20 和 64。同时, λ_1 和 λ_2 也经

¹⁾ <https://rslab.ut.ac.ir/data>

验性地设置为 0.01。关于超参数 n 和 S 的影响分析详见第 3.6 节。SGFL 的详细设置如表 1 所列,其中 GSAM(Gated Spectral Attention Module)表示门控光谱注意力模块。

表 1 SGFL 的网络设置

Table 1 Networks setting of SGFL

	操作	输入大小	输出大小
预处理	$191 \times 3 \times 3$ Conv	$H \times W \times B$	$H \times W \times C$
	3×3 动态卷积 ^[33]	$H \times W \times C$	$H \times W \times C$
	3×3 Conv	$H \times W \times C$	$H \times W \times C$
	GSAM	$H \times W \times C$	$H \times W \times C$
CSFEM $\times 2$	SGAM	$H \times W \times C$	$H \times W \times C$
	混合空洞卷积 ^[31]	$H \times W \times C$	$H \times W \times C$
	GSAM	$H \times W \times C$	$H \times W \times C$
	Transformer ^[22]	$H \times W \times C$	$H \times W \times C$
重构	$191 \times 1 \times 1$ Conv	$H \times W \times C$	$H \times W \times B$

2) 度量指标。在模拟实验中,使用 4 个度量指标来评估去噪效果:平均峰值信噪比(Mean Peak Signal-to-Noise Ratio, MPSNR)、平均结构相似度(Mean Structure Similarity, MSSIM)、平均特征相似度(Mean Feature Similarity, MFSIM)和平均光谱角(Mean Spectral Angle, MSA)。通常,较高的 MPSNR, MSSIM 和 MFSIM 值,及较低的 MSA 值,表明去噪效果更佳。对于没有参考 HSI 的真实 HSI 数据集的泛化实验,本文采用无参考评估指标 Q-metric^[46]来评估去噪后其空间信息的保持情况。Q-metric 值越高,表示去噪后的 HSI 质量越好,且图像在视觉上具有更明显的几何特征,尤其

是清晰度和对比度得到了增强。

3) 对比方法。在模拟和真实数据集实验中,将 SGFL 与多种先进的数据驱动 HSI 去噪方法进行比较,包括 HSI-CNN (Spatial-Spectral Deep Convolutional Neural Network)^[16], ENCAM (Enhanced Non-Local Cascade Network with Attention Mechanism)^[18], AODN (Attention-Based Octave Dense Network)^[19], MACNet (Model-Assisted Non-Local Neural Network)^[39], HSDT (Hybrid Spectral Denoising Transformer)^[24], SST (Spatial-Spectral Transformer)^[23] 以及 SM-CNN (Self-Modulating Convolutional Neural Network)^[20]。

3.3 模拟的 WDC 实验

1) 定量评估。表 2 列出了各项指标的平均值和标准差,其中最优结果以粗体显示,次优结果则用下划线突出。首先,在 Gaussian 噪声情形下,SGFL 方法取得了最高的 MPSNR, MSSIM 和 MFSIM 值,同时达到了最低的 MSA 值。这些指标表明,SGFL 在应对高斯噪声时,能够有效降低空间噪声,显著提高图像清晰度和视觉效果。其次,在混合噪声情形下,SGFL 在 MSSIM, MFSIM 和 MSA 这 3 个度量指标上同样优于其他方法。这意味着,SGFL 能够更好地恢复和增强 HSI 的对比度,特别是在 MSA 值上表现尤为突出,直观展示了其在去噪过程中对 HSI 的光谱信息破坏较少,从而更好地保留了 HSI 的真实信息。

表 2 WDC 数据集的定量比较

Table 2 Quantitative comparisons of WDC dataset

对比方法	噪声水平为 $\sigma=50$ 的高斯噪声				噪声水平为 $\sigma=75$ 的高斯噪声			
	MPSNR \uparrow	MSSIM \uparrow	MFSIM \uparrow	MSA \downarrow	MPSNR \uparrow	MSSIM \uparrow	MFSIM \uparrow	MSA \downarrow
HSID-CNN ^[16]	28.6502 \pm 0.0043	0.9478 \pm 0.0001	0.8801 \pm 0.0001	0.1179 \pm 0.0001	26.3544 \pm 0.0115	0.9160 \pm 0.0003	0.8567 \pm 0.0003	0.1384 \pm 0.0002
ENCAM ^[18]	29.7549 \pm 0.0035	0.9581 \pm 0.0001	0.9016 \pm 0.0001	0.1016 \pm 0.0001	27.5642 \pm 0.0870	0.9237 \pm 0.0012	0.8683 \pm 0.0027	0.1532 \pm 0.0019
AODN ^[19]	30.6724 \pm 0.0096	0.9690 \pm 0.0001	0.9063 \pm 0.0001	0.0831 \pm 0.0001	28.0635 \pm 0.0227	0.9474 \pm 0.0003	0.8829 \pm 0.0003	0.1039 \pm 0.0003
MAC-Net ^[39]	30.1608 \pm 0.0189	0.9721 \pm 0.0001	0.9076 \pm 0.0001	0.0855 \pm 0.0001	28.0223 \pm 0.0234	0.9444 \pm 0.0004	0.8621 \pm 0.0005	0.1132 \pm 0.0002
HSDT ^[24]	32.0582 \pm 0.0097	0.9771 \pm 0.0001	0.9218 \pm 0.0001	0.0672 \pm 0.0001	30.2002 \pm 0.0138	0.9656 \pm 0.0001	0.9071 \pm 0.0002	0.0761 \pm 0.0001
SST ^[23]	33.0079 \pm 0.0001	0.9810 \pm 0.0001	0.9281 \pm 0.0001	0.0626 \pm 0.0001	31.0904 \pm 0.0155	0.9727 \pm 0.0002	0.9116 \pm 0.0003	0.0750 \pm 0.0002
SM-CNN ^[20]	29.1821 \pm 0.0025	0.9524 \pm 0.0001	0.8956 \pm 0.0001	0.1088 \pm 0.0001	26.8611 \pm 0.0039	0.9232 \pm 0.0001	0.8728 \pm 0.0001	0.1330 \pm 0.0001
SGFL(Ours)	33.3734\pm0.0098	0.9827\pm0.0001	0.9293\pm0.0001	0.0620\pm0.0001	31.2882\pm0.0118	0.9738\pm0.0001	0.9152\pm0.0002	0.0711\pm0.0002
对比方法	噪声水平为 $\sigma=100$ 的高斯噪声				混合噪声			
	MPSNR \uparrow	MSSIM \uparrow	MFSIM \uparrow	MSA \downarrow	MPSNR \uparrow	MSSIM \uparrow	MFSIM \uparrow	MSA \downarrow
HSID-CNN ^[16]	24.1608 \pm 0.9124	0.8708 \pm 0.0082	0.7530 \pm 0.0480	0.1820 \pm 0.0144	26.6068 \pm 0.0278	0.9156 \pm 0.0003	0.8540 \pm 0.0003	0.1439 \pm 0.0002
ENCAM ^[18]	25.3713 \pm 0.7315	0.8749 \pm 0.0543	0.8392 \pm 0.0400	0.1927 \pm 0.0002	29.0527 \pm 0.0942	0.9516 \pm 0.0006	0.8949 \pm 0.0009	0.1114 \pm 0.0010
AODN ^[19]	25.2115 \pm 0.0172	0.9026 \pm 0.0006	0.8486 \pm 0.0002	0.1411 \pm 0.0002	29.4036 \pm 0.0560	0.9616 \pm 0.0006	0.8830 \pm 0.0007	0.0957 \pm 0.0007
MAC-Net ^[39]	26.6667 \pm 0.0414	0.9229 \pm 0.0004	0.8546 \pm 0.0005	0.0901 \pm 0.0003	30.0374 \pm 0.3007	0.9735 \pm 0.0012	0.8935 \pm 0.0023	0.1007 \pm 0.0024
HSDT ^[24]	29.3138 \pm 0.0153	0.9590 \pm 0.0001	0.8959 \pm 0.0003	0.0826 \pm 0.0001	32.6205\pm0.2653	0.9796 \pm 0.0007	0.9088 \pm 0.0011	0.0705 \pm 0.0019
SST ^[23]	29.5101 \pm 0.0162	0.9621 \pm 0.0001	0.8983 \pm 0.0003	0.0845 \pm 0.0002	32.0577 \pm 0.2687	0.9786 \pm 0.0009	0.9177 \pm 0.0019	0.0735 \pm 0.0021
SM-CNN ^[20]	25.4446 \pm 0.0027	0.8985 \pm 0.0001	0.8579 \pm 0.0001	0.1482 \pm 0.0002	29.4028 \pm 0.2864	0.9551 \pm 0.0025	0.8992 \pm 0.0021	0.1050 \pm 0.0027
SGFL(Ours)	29.7076\pm0.0175	0.9640\pm0.0001	0.9031\pm0.0002	0.0791\pm0.0002	32.3963 \pm 0.2069	0.9803\pm0.0008	0.9241\pm0.0015	0.0654\pm0.0013

2) 可视化比较。为直观展示实际效果,本文精心挑选两个代表性案例进行视觉比较。图 6 和图 7 分别比较了不同方法在噪声水平为 $\sigma=100$ 的高斯噪声以及混合噪声下去噪的结果,其中选择 WDC 数据的第 17、第 94 和第 184 波段组合成伪彩色图像进行可视化。通过放大细节区域可以观察到,与其他方法相比,SGFL 在去噪图像中保留了更多的建筑物屋顶边缘信息,图像清晰度更高。具体而言,在图 6 中噪声水平为 $\sigma=100$ 的高噪声强度条件下,HSID-CNN, AODN 和 HSDT 方法的去噪结果表现出边缘模糊和过度平滑,导致一

些细节丢失。相比之下,ENCAM, MAC-Net, SST 和 SM-CNN 方法的去噪效果较好,但图像中仍残留可见的噪声点。同样,图 7 展示的混合噪声去除场景中,这些方法也遇到了类似的问题,要么平滑了边缘信息,要么噪声去除不完全。进一步观察可视化图像中植被区域的去噪效果可以判断,SGFL 的处理结果更接近原始干净图像,特别是在植被分布和植被与道路之间清晰的边界方面。这些分析表明,SGFL 在保留结构信息、内部细节以及图像清晰度方面表现良好,在 HSI 去噪中表现出色。




图 6 在(17,94,184)3个波段下,噪声水平为 $\sigma=100$ 时 WDC 的去噪结果可视化

Fig. 6 Denoising result visualization for WDC with a noise level of 100 in the case of bands (17,94,184)





图 7 在(17,94,184)3个波段下,WDC对混合噪声的去噪结果可视化

Fig. 7 Denoising result visualization for WDC with mixture noise in the case of bands (17,94,184)

3)光谱特征差异。为评估各种 HSI 去噪方法在处理带高噪声水平 $\sigma=100$ 的 WDC 数据集时的实际性能,在光谱维度上绘制了不同方法对应的光谱特征差异曲线,如图 8 所示。图的纵轴表示去噪后 HSI 与无噪声 HSI 之间的数值(Digital Number, DN)差异,(1)到(9)分别表示噪声图像以及经 HSID-CNN, ENCAM, AODN, MAC-Net, HSDT, SST, SM-

CNN 和 SGFL 方法去噪后的光谱差异曲线;横轴表示光谱波段数量。这些曲线表示在 WDC 的空间维度上像素(2,100)和(78,159)处无噪声光谱与去噪后光谱之间的差异值。在这两个像素中,与其他方法相比,SGFL 显示的光谱差异曲线更平滑,其差值更接近于零。这充分表明,SGFL 在保留噪声 HSI 的原始光谱特征方面具有更高的可靠性和准确性。



(a) 像素(2,100)的光谱差异图

(b) 像素(78,159)的光谱差异图

图 8 各方法去噪后 HSI 在(2,100)和(78,159)两像素光谱与无噪声光谱间的差异

Fig. 8 Difference between the two-pixel spectral of HSI at (2,100) and (78,159) after denoising by each method and the noise-free spectrum

3.4 真实数据集实验

本节在真实 HSI Urban 和 IP 数据集上进行泛化实验。

使用带混合噪声的 WDC 数据集上训练好的模型对 Urban 和 IP 数据集进行测试,以验证其在去除真实混合噪声方面的去

噪性能和泛化能力。

表 3 列出了所有方法在 Urban 和 IP 数据集上去噪后的定量评估结果,最优和次优结果以粗体和下划线标记。SGFL 在 Urban 和 IP 数据集中均实现了最高的 Q-metric,表明其在图像视觉清晰度和色彩对比度方面表现最佳。

图 9 和图 10 给出了伪彩色图像可视化结果,图 9 中伪彩色图像通过组合 1108 和 208 波段生成,图 10 中伪彩色图像通过组合 2,3 和 203 波段生成。为了展示去噪质量,每个结果都包含局部细节的放大视图。在图 9 中,HSID-CNN, AODN 和 MAC-Net 方法在 Urban 中去除密集和条纹状噪声方面仍显不足;同时,ENCAM, HSDT, SST 和 SM-CNN 方法

在部分区域出现了不同程度的局部模糊。在图 10 中,MAC-Net 和 SST 方法在抑制噪声和保持色彩对比度方面表现良好。这些方法尽管在去噪方面效果显著,但去噪结果中仍然可见残留的密集和条纹状噪声,如图 9(e)和图 9(g)所示。进一步观察放大区域的去噪可视化效果发现,ENCAM 和 HSID-CNN 方法在处理图像边缘时存在模糊现象。此外,HSID-CNN, AODN 和 SM-CNN 方法在去噪过程中过度平滑,导致部分图像细节丢失,整体清晰度降低。相反,SGFL 方法能够保留更多的纹理细节和结构信息,同时增强图像清晰度和色彩对比度。这不仅提升了两个数据集的图像质量,还为后续分析任务提供了更加丰富和清晰的数据支持。

表 3 真实数据集下的 Q-metric

Table 3 Q-metric in real datasets

数据集	带噪声 HSI	HSID-CNN	ENCAM	AODN	MAC-Net	HSDT	SST	SM-CNN	SGFL(Ours)
Urban	0.0633	0.1818	0.1819	<u>0.2243</u>	0.1618	0.1863	0.1842	0.2015	0.30887
IP	0.0271	0.1834	0.2246	0.1941	<u>0.3190</u>	0.2329	0.3164	0.1576	0.32756

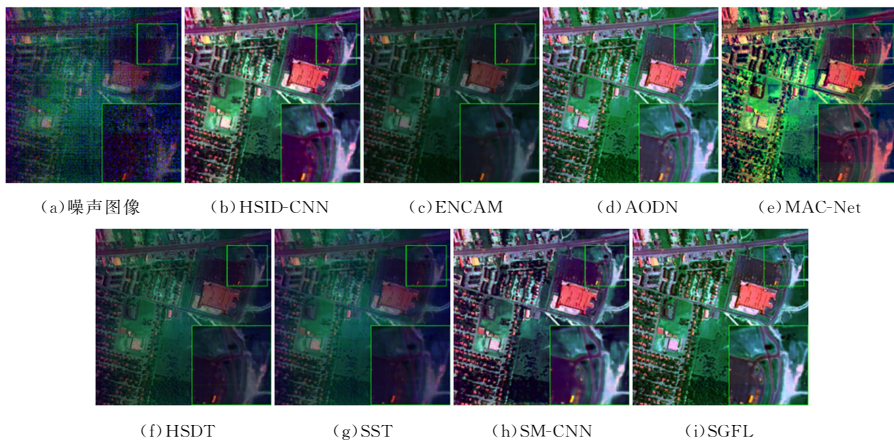


图 9 真实数据集 Urban 上的去噪结果

Fig. 9 Denoised results on real-world Urban dataset

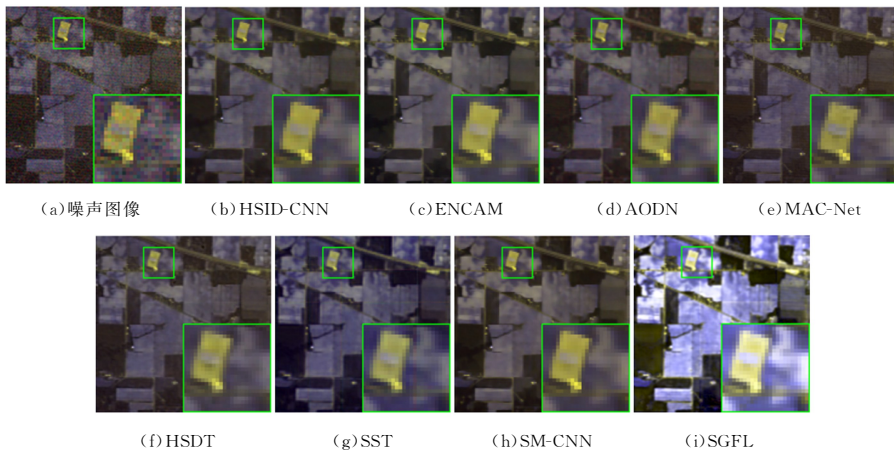


图 10 真实数据集 IP 上的去噪结果

Fig. 10 Denoised results on real-world IP dataset

3.5 消融实验

本节通过消融实验来验证 SGFL 方法的有效性,重点关注 SGAM, GSAM 和 $\mathcal{L}_{\text{nuclear}}$ 对模型性能的影响。此外,还评估了使用 Transformer 和混合空洞卷积的有效性。具体设计了以下模型:“模型 1”“模型 2”“模型 4”和“模型 5”分别用 3×3

卷积替换 SGFL 中所有的 SGAM, GSAM, Transformer 和混合空洞卷积,同时保持其他组件与 SGFL 一致;“模型 3”在设置的低秩-空谱损失中删除 $\mathcal{L}_{\text{nuclear}}$,模型设置与 SGFL 一致。上述模型均在噪声水平为 100 的高斯噪声以及混合噪声条件下进行评估,实验结果如表 4 和表 5 所列。

所有实验均在 WDC 数据集上进行。通过比较“模型 1”“模型 2”“模型 3”和 SGFL 得到,SGAM 通过提取不规则局部块的全局相似特征来保留结构完整性,相对于未考虑该特征的模型,有效提升了网络的去噪性能。GSAM 网络初期抑噪和增强光谱相关性效果显著。 $\mathcal{L}_{\text{nuclear}}$ 通过约束 HSI 在空间维保持低秩性,有效地进行去噪,使 HSI 恢复得更加真实。此外,“模型 4”“模型 5”和

SGFL 之间的比较,验证了 Transformer 在全局上下文信息增强以及混合空洞卷积在提取多尺度特征强化局部细节和结构信息方面的有效性。这些技术的应用使 SGFL 在处理复杂多变的噪声时表现出色,显著提升了去噪后 HSI 的图像质量。

总之,对 SGFL 模块的消融研究充分验证了所提出的模块在改善 HSI 去噪效果方面的有效性。

表 4 噪声水平为 $\sigma=100$ 时的消融实验

Table 4 Ablation experiment with the noise level of 100

模型	SGAM	GSAM	$\mathcal{L}_{\text{nuclear}}$	特征增强 模块	混合空洞 卷积	MPSNR \uparrow	MSSIM \uparrow	MFSIM \uparrow	MSA \downarrow
1		✓	✓	✓	✓	29.4075±0.0237	0.9626±0.0001	0.9020±0.0002	0.0811±0.0002
2	✓		✓	✓	✓	29.5118±0.0178	0.9629±0.0001	0.9009±0.0002	0.0806±0.0002
3	✓	✓		✓	✓	29.3086±0.0150	0.9617±0.0001	0.9007±0.0002	0.0806±0.0001
4	✓	✓			✓	28.9166±0.0152	0.9575±0.0001	0.8951±0.0002	0.0841±0.0002
5	✓	✓	✓	✓		29.5960±0.0181	0.9636±0.0001	0.9022±0.0003	0.0803±0.0002
SGFL	✓	✓	✓	✓	✓	29.7076±0.0175	0.9640±0.0001	0.9031±0.0002	0.0791±0.0002

表 5 混合噪声下的消融实验

Table 5 Ablation experiment under mixture noise

模型	SGAM	GSAM	$\mathcal{L}_{\text{nuclear}}$	特征增强 模块	混合空洞 卷积	MPSNR \uparrow	MSSIM \uparrow	MFSIM \uparrow	MSA \downarrow
1		✓	✓	✓	✓	32.0689±0.2321	0.9786±0.0010	0.9221±0.0021	0.0676±0.0014
2	✓		✓	✓	✓	31.8393±0.1889	0.9776±0.0009	0.9181±0.0017	0.0691±0.0013
3	✓	✓		✓	✓	31.5182±0.1242	0.9771±0.0008	0.9173±0.0013	0.0696±0.0011
4	✓	✓			✓	31.2436±0.1543	0.9752±0.0009	0.9138±0.0018	0.0738±0.0015
5	✓	✓	✓	✓		31.6482±0.1563	0.9770±0.0008	0.9175±0.0015	0.0692±0.0014
SGFL	✓	✓	✓	✓	✓	32.3963±0.2069	0.9803±0.0008	0.9241±0.0015	0.0654±0.0013

3.6 超参数讨论

本节研究了 SGFL 中的两个关键超参数对模型性能的影响,分别是 CSFEM 的层数 n 和简单线性迭代聚类算法划分的超

像素个数 S 。实验基于 WDC 数据集展开,通过分析不同噪声条件下网络的去噪性能,探讨了超参数 $n(n=1,2,3,4)$ 和 $S(S=32,64,128)$ 型性能的影响。具体实验结果如表 6 和表 7 所列。

表 6 n 的影响Table 6 Impact of n

指标	n				
	1	2	3	4	
$\sigma=100$	MPSNR \uparrow	29.5297±0.0161	29.7076±0.0175	29.5564±0.0185	29.5888±0.0208
	MSSIM \uparrow	0.9642±0.0001	0.9640±0.0001	0.9633±0.0002	0.9637±0.0001
	MFSIM \uparrow	0.9031±0.0001	0.9031±0.0002	0.9021±0.0002	0.9028±0.0002
	MSA \downarrow	0.0798±0.0002	0.0791±0.0002	0.0802±0.0002	0.0801±0.0002
混合噪声	MPSNR \uparrow	31.9955±0.1732	32.3963±0.2069	31.7642±0.1165	31.7954±0.1487
	MSSIM \uparrow	0.9793±0.0009	0.9803±0.0008	0.9778±0.0007	0.9778±0.0008
	MFSIM \uparrow	0.9215±0.0019	0.9241±0.0015	0.9179±0.0013	0.9188±0.0015
	MSA \downarrow	0.0674±0.0013	0.0654±0.0013	0.0698±0.0012	0.0694±0.0012

表 7 S 的影响Table 7 Impact of S

指标	S			
	32	64	128	
$\sigma=100$	MPSNR \uparrow	29.4873±0.0186	29.7076±0.0175	29.5198±0.0232
	MSSIM \uparrow	0.9629±0.0001	0.9640±0.0001	0.9637±0.0001
	MFSIM \uparrow	0.9011±0.0002	0.9031±0.0002	0.9016±0.0002
	MSA \downarrow	0.0806±0.0002	0.0791±0.0002	0.0811±0.0002
混合噪声	MPSNR \uparrow	31.9391±0.2117	32.3963±0.2069	31.5684±0.1303
	MSSIM \uparrow	0.9787±0.0009	0.9803±0.0008	0.9775±0.0007
	MFSIM \uparrow	0.9203±0.0016	0.9241±0.0015	0.9183±0.0012
	MSA \downarrow	0.0677±0.0013	0.0654±0.0013	0.0702±0.0011

根据表 6 的结果,当 n 值从 1 增加到 2 时,在噪声水平为 $\sigma=100$ 的高斯噪声和混合噪声条件下,网络的去噪性能逐渐

提高;然而,当 n 值进一步增加到 3 时,去噪性能反而下降。这表明,在 $n=2$ 时,网络的去噪效果达到最佳,此时的特征增

强效果最为显著,而 n 值的进一步增加可能导致特征表示的冗余。因此,基于实验结果,经验性地选择 $n=2$ 来构建 SGFL。

由表 7 可知,当 S 值为 64 时,在噪声水平为 $\sigma=100$ 的高斯噪声和混合噪声条件下,网络的去噪性能达到最优。这可能是因为当 S 值过小时,超像素无法有效覆盖复杂结构;而当 S 值过大时,计算复杂度会显著增加,并且容易引入噪声干扰。经过在 WDC 数据集上的验证,经验性地选择 $S=64$,并在其他数据集上保持一致,以确保模型的泛化能力。

3.7 模型复杂度分析

表 8 对比了不同方法的计算复杂度(包括浮点运算次数和参数量)以及单张图像的推理时间。实验结果表明,本文方法在维持较低计算开销的同时,实现了高效的推理。结合前文分析,本文方法在所有 HSI 数据集上均取得了最优性能。综上,SGFL 在计算效率与去噪性能之间实现了更优的平衡。

表 8 模型复杂度与推理时间的对比

Table 8 Comparison of model complexity and inference time

方法	运算量/ GB	参数量/ MB	推理时间/ (s/img)
HSID-CNN ^[16]	1.5028	0.3353	0.0140
ENCAM ^[18]	10.7855	2.8213	0.5113
AODN ^[19]	3.7272	1.1273	0.0219
MAC-Net ^[39]	2.8452	0.0982	0.6842
HSDT ^[24]	72.5397	0.5844	3.7566
SST ^[23]	92.7876	22.6363	1.7260
SM-CNN ^[20]	9.8306	0.2486	0.0519
SGFL(Ours)	12.2830	0.6913	0.3969

结束语 本文提出了一种面向 HSI 去噪的超像素级图特征学习方法。该模型创新性地设计了使用共享线性层学习超像素中像素加权值的超像素级图特征聚合模块,通过捕获全局不规则局部块的相似性,不仅保证了 HSI 结构的完整性,还提高了 HSI 的清晰度。为实现初始噪声抑制并增强光谱相关性,设计了门控光谱注意力模块。此外,还设计了一个低秩-空谱损失,通过引入核范数正则化,约束 HSI 空间维的低秩性,以保留更多的空间结构信息。实验结果表明,本文方法在 HSI 去噪上优于其他方法。尽管本文方法在复杂噪声条件下能够有效保持图像结构的完整性和光谱的连续性,但其缺乏对像素级空间位置长程相关性的建模,这可能导致超像素内部细节提取不够充分。未来的研究将重点探索自适应稀疏邻接矩阵的构建方法,以进一步优化模型,增强其对细节信息的保留能力,从而实现更精确、高效的混合噪声去噪。

参考文献

[1] SUN S, LIU J, LI W. Spatial Invariant Tensor Self-Representation Model for Hyperspectral Anomaly Detection [J]. IEEE Transactions on Cybernetics, 2024, 54(5): 3120-3131.

[2] LYU Z Y, ZHANG M, SUN W W, et al. Spatial-Contextual Information Utilization Framework for Land Cover Change Detection with Hyperspectral Remote Sensed Images [J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 4411-4419.

[3] BEGLIOMINI F N, BARBOSA C C F, MARTINS V S, et al. Machine Learning for Cyanobacteria Mapping on Tropical Ur-

ban Reservoirs Using PRISMA Hyperspectral Data [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2023, 204: 378-396.

[4] ZHUANG L, NG M K. FastHyMix: Fast and Parameter-Free Hyperspectral Image Mixed Noise Removal [J]. IEEE Transactions on Neural Networks and Learning Systems, 2023, 34(8): 4702-4716.

[5] ZHANG Q, ZHENG Y M, YUAN Q Q, et al. Hyperspectral Image Denoising: From Model-Driven, Data-Driven, to Model-Data-Driven [J]. IEEE Transactions on Neural Networks and Learning Systems, 2024, 35(10): 13143-13163.

[6] CHEN Y R, ZHANG H, WANG Y N, et al. Flex-DLD: Deep Low-Rank Decomposition Model with Flexible Priors for Hyperspectral Image Denoising and Restoration [J]. IEEE Transactions on Image Processing, 2024, 33: 1211-1226.

[7] ZHENG J W, HUANG J J, QIN M J, et al. Hyperspectral Image Denoising Based on Non-Local Similarity and Weighted-Truncated Nuclearnorm [J]. Computer Science, 2021, 48(9): 160-167.

[8] HE W, YAO Q M, LI C, et al. Non-Local Meets Global: An Iterative Paradigm for Hyperspectral Image Restoration [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(4): 2089-2107.

[9] ZHANG L H, YE J. Hyperspectral Image Denoising Based on Group Sparse and Constraint Smooth Rank Approximation [J]. Computer Science, 2023, 50(6): 209-215.

[10] SU X, ZHANG Z, YANG F. Fast Hyperspectral Image Denoising and Destriping Method Based on Graph Laplacian Regularization [J]. IEEE Transactions on Geoscience Remote Sensing, 2023, 61: 5511-5514.

[11] SI W N, YE J, JIANG B. Hyperspectral Image Denoising Combining Group Sparse and Representative Coefficient Bidirectional Spatial Spectral Total Variation [J]. Computer Science, 2024, 51(12): 199-208.

[12] ZHA Z Y, WEN B H, YUAN X, et al. Nonlocal Structured Sparsity Regularization Modeling for Hyperspectral Image Denoising [J]. IEEE Transactions on Geoscience and Remote Sensing, 2023, 61: 5510-5516.

[13] YE H L, LI H, YANG B, et al. A Novel Rank Approximation Method for Mixture Noise Removal of Hyperspectral Images [J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(7): 4457-4469.

[14] ZHANG F, ZHANG K, WAN W B, et al. 3D Geometrical Total Variation Regularized Low-Rank Matrix Factorization for Hyperspectral Image Denoising [J]. Signal Processing, 2023, 207: 108942.

[15] XIE W Y, LI Y S. Hyperspectral Imagery Denoising by Deep Learning with Trainable Nonlinearity Function [J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(11): 1963-1967.

[16] YUAN Q Q, ZHANG Q, LI J, et al. Hyperspectral Image Denoising Employing a Spatial-Spectral Deep Residual Convolutional Neural Network [J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(2): 1205-1218.

[17] DONG W S, WANG H, WU F F, et al. Deep Spatial-Spectral

- Representation Learning for Hyperspectral Image Denoising [J]. *IEEE Transactions on Computational Imaging*, 2019, 5(4): 635-648.
- [18] MA H W, LIU G C, YUAN Y. Enhanced Non-Local Cascading Network with Attention Mechanism for Hyperspectral Image Denoising [C]// *Proceedings of the IEEE International Conference on Acoustics, Speech and Signal Processing*. IEEE, 2020: 2448-2452.
- [19] KAN Z W, LI S H, HOU M Z, et al. Attention-Based Octave Network for Hyperspectral Image Denoising [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2022, 15: 1089-1102.
- [20] TORUN O, YUKSEL S E, ERDEM E, et al. Hyperspectral Image Denoising via Self-Modulating Convolutional Neural Networks [J]. *Signal Processing*, 2024, 214: 109248.
- [21] PAN E T, MA Y, MEI X G, et al. Hyperspectral Image Denoising via Spectral Noise Distribution Bootstrap [J]. *Pattern Recognition*, 2023, 142: 109699.
- [22] VASWANI A, SHAZEER N, PARMAR N, et al. Attention Is All You Need [C]// *Advances in Neural Information Processing Systems*. MIT, 2017: 5998-6008.
- [23] LI M Y, FU Y, ZHANG Y L. Spatial-Spectral Transformer for Hyperspectral Image Denoising [C]// *Proceedings of the AAAI Conference on Artificial Intelligence*. AAAI, 2023: 1368-1376.
- [24] LAI Z Q, YAN C G, FU Y. Hybrid Spectral Denoising Transformer with Guided Attention [C]// *Proceedings of the IEEE/CVF International Conference on Computer Vision*. IEEE, 2023: 13065-13075.
- [25] ZHANG Q, YUAN Q Q, LI J, et al. Hybrid Noise Removal in Hyperspectral Imagery with a Spatial-Spectral Gradient Network [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(10): 7317-7329.
- [26] WANG M Y, HE W, ZHANG S H Y. A Spatial-Spectral Transformer Network with Total Variation Loss for Hyperspectral Image Denoising [J]. *IEEE Geoscience and Remote Sensing Letters*, 2023, 20: 5503105.
- [27] LI M, ZHANG L, CUI L X, et al. BLoG: Bootstrapped Graph Representation Learning with Local and Global Regularization for Recommendation [J]. *Pattern Recognition*, 2023, 144: 109874.
- [28] JIANG Q T, YE H L, YANG B, et al. Label-Decoupled Medical Image Segmentation with Spatial-Channel Graph Convolution and Dual Attention Enhancement [J]. *IEEE Journal of Biomedical and Health Informatics*, 2024, 28(5): 2830-2841.
- [29] DONG Y N, LIU Q W, DU B, et al. Weighted Feature Fusion of Convolutional Neural Network and Graph Attention Network for Hyperspectral Image Classification [J]. *IEEE Transactions on Image Processing*, 2022, 31: 1559-1572.
- [30] YANG F, CHEN X, ZHANG Z, et al. Denoising and Destriping Hyperspectral Images Using Double Graph Laplacian Regularizers [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2023, 16: 10406-10419.
- [31] WANG P Q, CHEN P F, YUAN Y, et al. Understanding Convolution for Semantic Segmentation [C]// *Proceedings of the IEEE Winter Conference on Applications of Computer Vision*. IEEE, 2018: 1451-1460.
- [32] ACHANTA R, SHAJI A, SMITH K, et al. SLIC Superpixels Compared to State-of-the-Art Superpixel Methods [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, 34(11): 2274-2282.
- [33] CHEN Y P, DAI X Y, LIU M C, et al. Dynamic Convolution: Attention over Convolution Kernels [C]// *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. IEEE, 2020: 11030-11039.
- [34] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional Block Attention Module [C]// *Proceedings of the European Conference on Computer Vision*. Springer, 2018: 3-19.
- [35] VERMA S, SHARMA A, SHESHADRI R, et al. GraphFill: Deep Image Inpainting Using Graphs [C]// *Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision*. IEEE, 2024: 4996-5006.
- [36] JAMPANI V, SUN D, LIU M Y, et al. Superpixel Sampling Networks [C]// *Proceedings of the European Conference on Computer Vision*. Springer, 2018: 352-368.
- [37] GLOROT X, BENGIO Y. Understanding the Difficulty of Training Deep Feedforward Neural Networks [C]// *Proceedings of the International Conference on Artificial Intelligence and Statistics*. 2010: 249-256.
- [38] KINGMA D P, BA L J. Adam: A Method for Stochastic Optimization [C]// *International Conference on Learning Representations*. San Diego, USA: ArXiv, 2015.
- [39] XIONG F C, ZHOU J, ZHAO Q L, et al. MAC-Net: Model-Aided Nonlocal Neural Network for Hyperspectral Image Denoising [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2022, 60: 5519414.
- [40] ZHU X, MILANFAR P. Automatic Parameter Selection for Denoising Algorithms Using a No-Reference Measure of Image Content [J]. *IEEE Transactions on Image Processing*, 2010, 19(12): 3116-3132.



WU Ying, born in 1999, master. Her main research interests include deep learning and hyperspectral image denoising.



CAO Feilong, born in 1965, Ph.D, professor, Ph.D supervisor. His main research interests include deep learning and image processing.