

基于超像素块聚类与低秩特性的高光谱图像降噪

张明华¹, 武玄¹, 宋巍¹, 梅海彬¹, 贺琪¹, 苏诚²

(1. 上海海洋大学信息学院, 上海 201306; 2. 自然资源部东海预报中心, 上海 200136)

摘要: 高光谱图像通常受到高斯噪声、脉冲噪声、死线和条纹等干扰, 因此去噪必不可少。现有基于低秩特性的降噪方法通过引入空间信息改善了降噪效果, 但由于其只利用了局部相似性或非局部自相似性, 而对在光谱维度存在一定结构信息的稀疏噪声去除效果较差。本文提出了基于超像素块聚类与低秩特性的高光谱图像降噪方法, 实现了分块的自适应划分与聚类, 在较好地保留了局部细节的同时又充分利用了非局部空间自相似性, 且实验表明聚类后的超像素块组成的同物分块具有良好的空-谱双重低秩属性。该方法首先对高光谱图像进行超像素分割, 再对超像素块进行聚类, 得到同物分块; 然后对其建立低秩矩阵恢复模型并求解, 最终得到降噪后图像。本文分别在模拟数据和真实数据上进行实验, 并与其他基于低秩特性的方法进行比较, 结果表明: 本文方法对混合噪声, 尤其是具有一定结构信息的稀疏噪声具有较好的降噪性能。

关键词: 高光谱图像处理; 降噪; 低秩矩阵恢复; 超像素分割; 聚类

中图分类号: TP751 **文献标志码:** A

Hyperspectral Image Denoising Based on Superpixel Block Clustering and Low-Rank Characteristics

ZHANG Minghua¹, WU Xuan¹, SONG Wei¹, MEI Haibin¹, HE Qi¹, SU Cheng²

(1. College of Information Technology, Shanghai Ocean University, Shanghai 201306, China; 2. East China Sea Forecast Center, Ministry of Natural Resources, Shanghai 200136, China)

Abstract: Hyperspectral images are usually contaminated by Gaussian noise, impulse noise, dead lines and stripes. So, denoising is an essential step. The existing denoising methods based on low-rank characteristics introduce spatial information to improve the noise reduction effect. But because they often only use local similarity or non-local self-similarity, it has poor removal effect of sparse noise with structural information in the spectral dimension. Therefore, we propose a hyperspectral image denoising method based on superpixel block clustering and low-rank characteristics. The method realizes the adaptive partition and clustering of blocks, and makes full use of the non-local spatial self-similarity while retaining the local details. The experiments show that the same object block composed of clustered superpixel blocks has a good spatial-spectral dual low-rank attributes. Firstly, a superpixel segmentation method is applied to hyperspectral images, and the superpixel blocks are clustered to obtain the same object blocks. Secondly, the low-rank matrix restoration model is established and solved, and finally the denoised image is obtained.

基金项目: 国家重点研发计划(2021YFC3101601); 国家自然科学基金面上项目(61972240, 41906179); 上海市科委地方能力建设项目(20050501900)。

收稿日期: 2022-05-04; **修订日期:** 2022-09-15

We conduct experiments on simulated data and real data respectively, and compare with other methods based on low-rank characteristics. The results show that this method has better denoising performance for mixed noise, especially sparse noise with structural information.

Key words: hyperspectral image processing; denoising; low-rank matrix restoration; superpixel segmentation; clustering

引言

近年来,得益于成像光谱技术的发展与成熟,高光谱遥感领域得到了快速发展^[1]。高光谱图像(Hyperspectral image, HSI)最大特点就是每幅图像都包含了数百个连续窄波段,这为高光谱图像在农业、医疗、遥感和军事等领域的应用提供了大量重要信息。但由于各种内外部因素的影响,如电磁干扰、仪器故障等,引起了不正常的斑点和条纹,导致高光谱图像质量的严重下降,为后续的应用带来了影响。因此,高光谱图像降噪工作通常作为其他高光谱图像处理与分析操作的预处理步骤,其重要性不言而喻。

高光谱图像是一个三维数据立方,由两个空间维度和一个光谱维度组成。在高光谱图像降噪研究之初,研究者们就想利用已有的图像降噪方法来实现降噪,即将一幅高光谱图像看作是若干个灰度图的组合,依次对每一幅图像进行降噪处理,一些经典方法^[2-3]被用在了逐波段的高光谱图像降噪方法中,并取得了一定的效果。但是,这完全忽略了高光谱图像波段间的高相关性,使得许多被噪声严重污染的波段无法通过相邻波段的信息进行恢复。自然地,研究者们开始结合光谱维度信息来降噪。一般图像中存在着大量冗余,使得其具有低秩属性。2009年Wright等^[4]考虑了从损坏的矩阵中恢复出低秩矩阵的问题,提出低秩矩阵恢复(Low-rank matrix restoration, LRMR)模型,证明了大多数这样的低秩矩阵能够通过求解一个简单的凸函数获得。该方法被广泛应用在了图像去噪领域,随后研究者们也很快发现在高光谱图像丰富的光谱信息中也具有这种低秩属性。因为,来自同一局部区域的像素更有可能是相同材料,相同材料光谱特征更有可能是相似的,这也启发了研究者们探索高光谱图像的局部低秩属性,分析高光谱图像以空间局部块方式而不是全局方式。2013年Zhang等^[5]较早地将低秩理论应用到了高光谱图像降噪领域并取得了相较于传统方法较大的提升效果,其将高光谱图像划分为了若干个相互重叠的正方形局部块,并将该局部块内所有波段像素值重新排列成二维矩阵,发现了该二维矩阵的低秩属性,以此建立低秩矩阵恢复模型并求解。但该方法只考虑了光谱维度信息,忽略了空间信息。2018年He等^[6]在文献[5]的基础上,提出了一种空-谱结合的降噪方法,同时考虑了局部低秩特性和全局空-谱全变差(Spatial-spectral total variation, SSTV)正则化模型,利用SSTV较好地保留边缘信息及空-谱分段平滑性。

随后,研究者们开始更多地考虑空-谱结合的降噪方法。一种常见的做法就是对高光谱图像进行超像素分割,随后对超像素块建立低秩模型^[7-8]。此类方法利用了空间局部相似性,依据位置、颜色与纹理将像素组成形状自适应的均匀区域,但其忽略了更为重要的非局部空间自相似性。于是,Zeng等^[9]在2020年提出了结合局部低秩和非局部自相似性的降噪方法,对高光谱图像进行分块处理,再对分块进行分组,将每组作为一个整体处理以获取非局部空间自相似性。Liu等^[10]则进一步加入更复杂的四维块匹配(Block matching 4D filtering, BM4D)模型以此充分利用非局部空间自相似性。Zeng等与Liu等都实现了局部低秩与非局部自相似性地结合,但对空间的局部相似性利用得不够充分,使得降噪后图像缺乏纹理细节,且分块尺寸也较难确定,较大则分块之间相似性下降,较小则噪声影响增大。此外,他们都无法有效去除光谱维度上具有一定结构信息的稀疏噪声,例如稀疏噪声出现在某些波段甚至全

部波段的相同位置。2020年Huang等^[11]提出结合地物类别和低秩特性的高光谱图像降噪算法,引入了地物类别的强先验信息,充分利用了高光谱图像的空间低秩特性。但算法所需的地物类别的强先验信息不易获取,其是通过官方数据得来的,而实际情况中大部分数据都未经过此类处理,这就使该算法的通用性和易用性具有一定限制。

本文综合考虑了局部相似性和非局部自相似性,将超像素分割同局部分块聚类相结合,提出了一种新的基于超像素块聚类与低秩特性(Superpixel block clustering and low-rank, SCLR)的高光谱图像降噪方法,有效地克服了上述缺点,实现了分块的自适应划分与聚类,避免了对强先验信息的依赖,在较好地保留局部细节的同时又充分利用非局部空间自相似性,且聚类后的超像素块组成的同物分块不仅具有了良好的空间低秩属性,也具有更好的光谱低秩属性。该方法首先使用简单线性迭代聚类算法(Simple linear iterative clustering, SLIC)^[12]进行超像素分割,捕获局部相似性,再使用K-means算法对超像素块聚类,以此更为充分地利用非局部空间自相似性。再将同物块展开为二维矩阵,使用SSTV重建这些低秩的同物分块矩阵,进一步去除高斯噪声。在模拟数据和真实数据上的实验结果表明,本文方法能有效去除混合噪声,尤其是具有一定结构信息的稀疏噪声,与其他基于低秩特性的方法相比,在平均峰值信噪比(Mean peak signal to noise ratio, MPSNR)上分别提升1.12 dB和1.05 dB,在平均结构相似性(Mean structural similarity index measure, MSSIM)上分别提升0.046和0.038。

1 基于低秩的高光谱图像降噪模型

高光谱图像往往受到高斯噪声、脉冲噪声、死线和条纹等混合噪声的干扰,因此高光谱图像的退化模型可表示为

$$Y = L + S + N \quad (1)$$

式中: $Y, L, S, N \in \mathbb{R}^{w \times h \times b}$; Y 表示观察到的高光谱图像; L 表示干净的高光谱图像; S 表示稀疏噪声; N 表示高斯噪声。高光谱图像的尺寸为 $w \times h \times b$ 。

将LRMR模型应用到高光谱图像降噪中,核心就是构建包含低秩信息的矩阵 D 。由于高光谱图像波段间具有高相关性,这意味着可以很容易根据这些相关性构造出所需的矩阵。文献[5]给出了一种简单而有效的构造方法,其将高光谱图像 Y 划分为若干个相互覆盖、大小相同的局部块 $p_{i,j} \in \mathbb{R}^{q \times q \times b}$,即以 i 行 j 列像素为中心覆盖全波段的一个子数据立方。再将局部块每一个波段的数据按先后列顺序展开为一个大小为 $q^2 \times 1$ 的矩阵,接着按波段顺序拼接起来,得到二维矩阵 $P_{i,j} \in \mathbb{R}^{q^2 \times b}$ 。可以证明,矩阵 $P_{i,j}$ 可分解为一个低秩矩阵和一个稀疏矩阵,即具有低秩属性。对矩阵 $P_{i,j}$ 建立LRMR模型

$$\min_{X, S} \|X\|_* + \lambda \|S\|_1 \quad \text{s.t.} \quad \left\| D - X - S \right\|_F^2 \leq \delta, \text{rank}(X) \leq r \quad (2)$$

式中: X 为低秩矩阵; λ 为平衡两者的正则化参数; $\|\cdot\|_*$ 为矩阵的核范数,即矩阵的奇异值之和; $\|\cdot\|_1$ 为矩阵 L_1 范数,即矩阵中的每个元素绝对值之和; $\|\cdot\|_F^2$ 为矩阵的F范数的平方,即矩阵的各个元素平方之和; δ 是高斯噪声方差; $D = P_{i,j}$; $\text{rank}(A)$ 为矩阵 A 的秩; r 表示矩阵 A 秩的上限。

因此,对于上述方式构造的完整模型可表示为

$$\arg \min_{X_{i,j}, S_{i,j}} \left(\|X_{i,j}\|_* + \lambda \|S_{i,j}\|_1 \right) \quad \text{s.t.} \quad \|Y_{i,j} - X_{i,j} - S_{i,j}\|_F^2 \leq \delta, \text{rank}(X_{i,j}) \leq r \quad (3)$$

式中 $Y_{i,j}$ 为按上述方法构造出来的二维矩阵。

研究者们提出了许多式(3)的求解算法^[13-15],本文所使用的是非精确增广拉格朗日乘子法(Inexact

augmented Lagrange multipliers, IALM)^[16],它在传统ALM算法的基础上进行改进,是目前比较主流的求解算法之一。

2 本文方法

图1是本文方法的总体流程图。首先,依据信息熵选取质量最高的波段,利用SLIC算法进行超像素分割,再对这些超像素块应用K-means算法进行聚类,并将结果应用于所有波段,从而实现局部块的自适应划分以及非局部块的联合,将同物分块展开后的二维矩阵通过秩约束分离出其中的低秩部分,随后,使用SSTV来重建这些低秩的同物块矩阵,最终得到降噪后的高光谱图像。

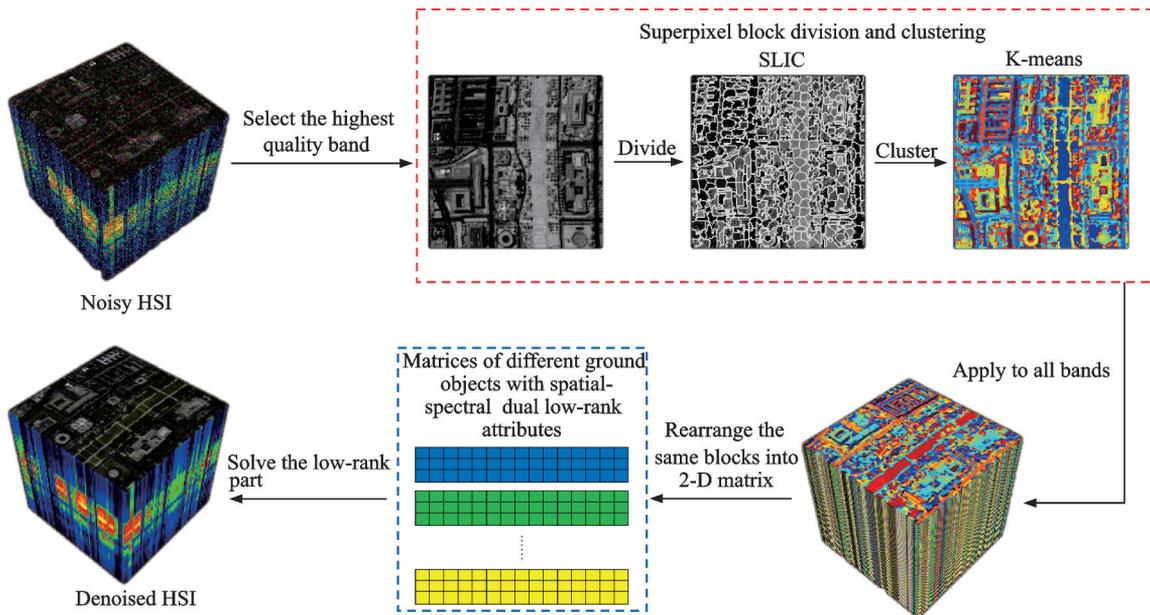


图1 本文方法总体流程图

Fig.1 Flowchart of the proposed method

2.1 高光谱图像超像素块划分与聚类

空间上的物体总是连续的,因此图像通常具有局部相似性。同时,图像空间中也存在着大量相似矢量,因此存在许多相似的非局部块,它们往往包含相同的地物,从而具有相似的光谱信息。有效利用这些先验信息有助于提高降噪效果。本文通过将两种算法相结合,实现了局部相似块的自适应划分与非局部相似块的联合,因此有效地提取了高光谱图像的局部相似性与非局部自相似性。

首先,计算各波段图像的信息熵,公式为

$$H(I) = - \sum_{i=1}^m p_i \log_2(p_i) \quad (4)$$

式中: I 表示灰度图; m 为灰度级; p_i 为各个灰度级的出现概率。信息熵可以在一定程度上反应图像受到高斯噪声和稀疏噪声污染的程度,信息熵越大,图像质量越高,包含噪声越少,且在模拟数据和真实数据上均可应用。根据信息熵选取质量最高的波段用于SLIC算法的超像素分割,SLIC算法是目前比较流行的超像素分割算法,使用此算法可以得到边界划分清晰的超像素块。得到超像素块后,用超像素块内像素值的均值作为代表,再次利用信息熵选取图像质量较好的 n 个波段,这样每个超像素块就是一个 n 维向量,第 i 个超像素块构成的向量可表示为

$$s_i = (\bar{x}_{i1}, \bar{x}_{i2}, \dots, \bar{x}_{in}) \tag{5}$$

式中 x_{ij} 为第 i 个超像素块的第 j 个波段的像素均值。以此作为 K-means 聚类的一个点,先从中随机选取 k 个数据作为初始的簇中心,依据距离公式

$$d = \sqrt{(\bar{x}_{i1} - \bar{x}_1)^2 + (\bar{x}_{i2} - \bar{x}_2)^2 + \dots + (\bar{x}_{in} - \bar{x}_n)^2} \tag{6}$$

将每个超像素块分配到距离其自身最近的簇中心所在的簇,然后再计算新的簇中心,迭代更新每个超像素块所属的簇,无超像素块更新所属簇之后,说明算法已收敛。通过上述过程即可实现高光谱图像非局部自相似块的联合,该过程简单且有效,既较好地保留了 SLIC 提取的边缘信息,又实现了全局上的聚合,同时得到的同物分块具有良好的空-谱双重低秩属性。

为了验证同物分块的有效性,绘制了高光谱图像局部分块和同物分块两种方式的奇异值(Singular value, SV)曲线对比图^[11],如图2所示。两条曲线都急剧衰减的趋势表明,同物分块方式与局部分块方式一样具有较强的行列间相关性。文献[17]给出了一种定量分析低秩属性的公式,采用前 k 个奇异值累积能量,定义为

$$\text{AccEgyR} = \frac{\sum_i^k \sigma_i}{\sum_i^n \sigma_i} \tag{7}$$

式中: σ_i 代表第 i 个 SV; n 为所有 SV 矩阵的总个数。图2为 HSI 低秩特性图。图2(a) 中标出的两个值分别为是 0.952 2 和 0.990 3; 图2(b) 中标出的两个值分别为 0.952 0 和 0.990 2。这些定量值也表明,同物分块具有良好的空间低秩属性。对同物分块构建低秩矩阵恢复模型,可以充分地利用高光谱图像空间低秩特性,从而使得光谱维度上具有一定结构信息的噪声依旧能在构造出的矩阵中表现出稀疏属性,进而很好地去除掉这些噪声。

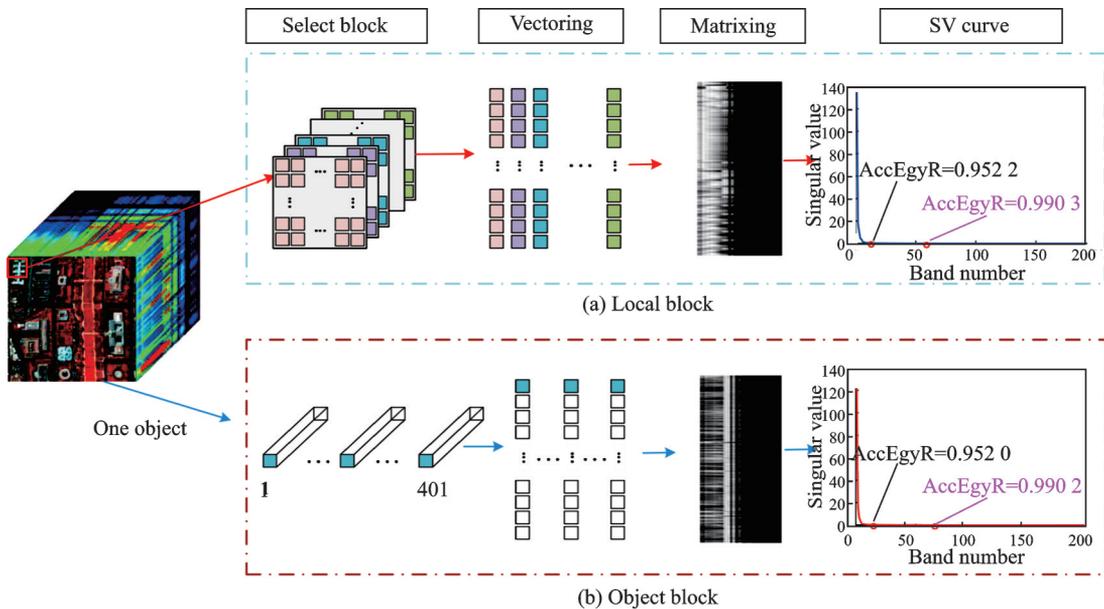


图2 HSI 低秩特性

Fig.2 Illustration of HSI low-rank characteristic

图3是 Washington DC Mall 的第85波段图像和根据上述算法所得的非局部块联合后的图像,可以看到算法将地物大致分成了10类左右,道路、建筑和阴影等部分都较为清晰地被分割出来,较好地获取了全局空间信息。

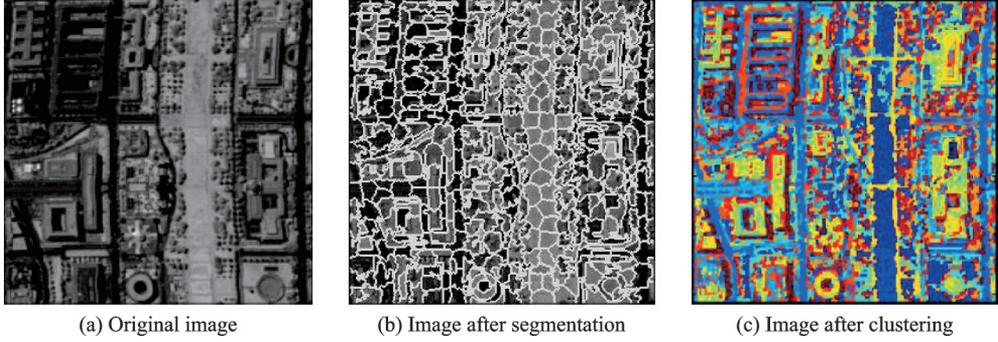


图3 Washington DC Mall 第85波段超像素分割和聚类后图像

Fig.3 Image after superpixel segmentation and clustering in band 85 of Washington DC Mall

2.2 结合超像素块聚类的低秩降噪模型

假设经过超像素分割和聚类后的同物分块个数为 k ,则引入了该方法后的LRMR模型可改写为

$$\min_{X,S} \sum_{i=1}^k (\|X^{(i)}\|_* + \lambda \|S^{(i)}\|_1) + \tau \|X\|_{\text{SSTV}} \quad \text{s.t.} \quad \|Y^{(i)} - X^{(i)} - S^{(i)}\|_F^2 \leq \delta, \text{rank}(X^{(i)}) \leq r_i \quad (8)$$

式中: τ 为正则化参数; $Y^{(i)}, X^{(i)}, S^{(i)} \in \mathbf{R}^{\text{num}(i) \times b}$ 为第 i 个地物类别块按字典序展开成的二维矩阵; $\tau \|X\|_{\text{SSTV}}$ 为SSTV正则化,其能够有效地保留边缘信息,为去除高斯噪声提供帮助,表达式为

$$\|u\|_{\text{SSTV}} = \tau_x \|D_x u\|_1 + \tau_y \|D_y u\|_1 + \tau_z \|D_z u\|_1 \quad (9)$$

式中 D_x, D_y, D_z 为空间和光谱维度上的一阶正向有限差分算子,其定义为

$$\begin{cases} D_x u(x, y, z) = u(x+1, y, z) - u(x, y, z) \\ D_y u(x, y, z) = u(x, y+1, z) - u(x, y, z) \\ D_z u(x, y, z) = u(x, y, z+1) - u(x, y, z) \end{cases} \quad (10)$$

使用IALM算法求解式(10)时,首先需要增加3个辅助变量: $J, A \in \mathbf{R}^{w \times h \times b}$ 和 $U \in \mathbf{R}^{w \times h \times b \times 3}$,且有

$$\begin{cases} J = X \\ A = J \\ U = D \otimes A \end{cases} \quad (11)$$

式中

$$D = [\tau_x D_x, \tau_y D_y, \tau_z D_z] \quad (12)$$

2.3 优化算法

式(8)可用拉格朗日乘法求解

$$\begin{aligned} \arg \min_{X,S,J,A,U} L(X,S,J,A,U) = & \arg \min_{X,S,J,A,U} \sum_{i=1}^k (\|X^{(i)}\|_* + \lambda \|S^{(i)}\|_1 + \\ & \langle Y_O^{(i)}, Y^{(i)} - X^{(i)} - S^{(i)} \rangle + \frac{\mu}{2} \|Y^{(i)} - X^{(i)} - S^{(i)}\|_F^2 + \langle Y_L^{(i)}, X^{(i)} - J^{(i)} \rangle + \\ & \frac{\mu}{2} \|X^{(i)} - J^{(i)}\|_F^2) + \tau \|U\|_1 + \langle y, U - DA \rangle + \langle Y_A, J - A \rangle + \frac{\mu}{2} (\|U - DA\|_2^2 + \|J - A\|_2^2) \end{aligned} \quad (13)$$

式中: Y_O, Y_L, y, Y_A 为拉格朗日乘子; μ 为惩罚因子; $\langle \cdot, \cdot \rangle$ 为矩阵内积,即两个大小相同的矩阵元素

一一对应相乘并相加。

式(13)的求解,通常是固定其余参数,一次只更新一个变量,对于第 $n+1$ 次迭代,可以将更新分为以下两个子问题

$$(\mathbf{X}^{n+1}, \mathbf{S}^{n+1}) = \arg \min_{\mathbf{X}, \mathbf{S}} L(\mathbf{X}, \mathbf{S}, \mathbf{J}^n) \quad \text{s.t. rank}(\mathbf{X}) \leq r \quad (14)$$

$$(\mathbf{J}^{n+1}, \mathbf{A}^{n+1}, \mathbf{U}^{n+1}) = \arg \min_{\mathbf{J}, \mathbf{A}, \mathbf{U}} L(\mathbf{X}^{n+1}, \mathbf{J}, \mathbf{A}, \mathbf{U}) \quad (15)$$

上述两个子问题需要通过式(14)求解出全部类别块矩阵的低秩部分,再利用式(15)的SSTV正则化重建高光谱图像。

首先求解式(14),逐一更新变量 \mathbf{X} 和 \mathbf{S} 。固定其余变量,更新 \mathbf{X} ,对关于 $\mathbf{X}^{(i)}$ 的函数化简可得

$$(\mathbf{X}^{(i)})^{n+1} = \arg \min_{\mathbf{X}^{(i)}} \left\| \mathbf{X}^{(i)} \right\|_* + \frac{1}{2} \times 2\mu \times \left\| \mathbf{X}^{(i)} - ((\mathbf{Y}^{(i)} - \mathbf{S}^{(i)} + \mathbf{J}^{(i)})/2 + (\mathbf{Y}_O^{(i)} - \mathbf{Y}_L^{(i)})/(2\mu)) \right\|_F^2 \quad (16)$$

式(16)可通过奇异值分解求得

$$(\mathbf{U}, \mathbf{S}, \mathbf{V}) = \text{svd}((\mathbf{Y}^{(i)} - \mathbf{S}^{(i)} + \mathbf{J}^{(i)})/2 + (\mathbf{Y}_O^{(i)} - \mathbf{Y}_L^{(i)})/(2 \times \mu)) \quad (17)$$

式中svd函数内的参数均为第 n 次迭代的结果,则

$$(\mathbf{X}^{(i)})^{n+1} = \mathbf{U} \mathbf{T}_{1/(2\mu)}(\mathbf{S}) \mathbf{V}^T \quad (18)$$

式中: \mathbf{V}^T 为矩阵 \mathbf{V} 的转置矩阵; $\mathbf{T}_\varepsilon(x)$ 为软阈值运算符, ε 为阈值,即 $x > \varepsilon$ 时,运算结果为 $x - \varepsilon$, $x < -\varepsilon$ 时,结果为 $x + \varepsilon$,其余情况则为0。

同样地,对于式(14)固定其余变量,更新 \mathbf{S} ,对关于 $\mathbf{S}^{(i)}$ 的函数化简可得

$$(\mathbf{S}^{(i)})^{n+1} = \arg \min_{\mathbf{S}^{(i)}} \lambda \left\| \mathbf{S}^{(i)} \right\|_1 + \frac{\mu}{2} \left\| \mathbf{Y}^{(i)} - \mathbf{X}^{(i)} - \mathbf{S}^{(i)} + \mathbf{Y}_O^{(i)}/\mu \right\|_F^2 = \mathbf{T}_{\lambda/\mu}(\mathbf{Y}^{(i)} - (\mathbf{X}^{(i)})^{n+1} + \mathbf{Y}_O^{(i)}/\mu) \quad (19)$$

对于第 $n+1$ 次迭代得到 \mathbf{X} 和 \mathbf{S} 之后,即求解式(15)。同样地,逐一更新变量 \mathbf{J} 、 \mathbf{A} 和 \mathbf{U} 。固定其余变量,更新 \mathbf{J} ,对关于 \mathbf{J} 的函数化简可得

$$\mathbf{J}^{n+1} = \arg \min_{\mathbf{J}} \frac{\mu}{2} \left\| \mathbf{J} - \mathbf{A} + \mathbf{Y}_X/\mu \right\|_2^2 + \left(\frac{\mu}{2} \left\| \mathbf{X}^{(i)} - \mathbf{J}^{(i)} + \mathbf{Y}_L^{(i)}/\mu \right\|_F^2 \right) = ((\mathbf{X} + \mathbf{Y}_L/\mu) + (\mathbf{A} - \mathbf{Y}_X/\mu))/2 \quad (20)$$

固定其余变量,更新 \mathbf{A} ,对关于 \mathbf{A} 的函数化简可得

$$\mathbf{A}^{n+1} = \arg \min_{\mathbf{A}} \frac{\mu}{2} \left\| \mathbf{U} - \mathbf{D}\mathbf{A} + \mathbf{y}/\mu \right\|_2^2 + \frac{\mu}{2} \left\| \mathbf{J} - \mathbf{A} + \mathbf{Y}_X/\mu \right\|_2^2 \quad (21)$$

式(21)可通过式(22)求解

$$(\mathbf{D}^* \mathbf{D} + 1)\mathbf{A} = \mathbf{D}^*(\mathbf{U} + \mathbf{y}/\mu) + (\mathbf{J} + \mathbf{Y}_X/\mu) \quad (22)$$

式中 \mathbf{D}^* 为 \mathbf{D} 的伴随运算符,采用快速傅里叶变换求解式(22),得

$$\mathbf{A}^{n+1} = \mathbf{F}^{-1} \left[\frac{\mathbf{F}((\mathbf{J} + \mathbf{Y}_X/\mu) + \mathbf{D}^*(\mathbf{U} + \mathbf{y}/\mu))}{1 + (\mathbf{F}(\tau_x \mathbf{D}_x))^2 + (\mathbf{F}(\tau_y \mathbf{D}_y))^2 + (\mathbf{F}(\tau_z \mathbf{D}_z))^2} \right] \quad (23)$$

式中: $\mathbf{F}[\cdot]$ 为快速傅里叶变换; $\mathbf{F}^{-1}[\cdot]$ 为其逆变换。固定其余变量,更新 \mathbf{U} ,对关于 \mathbf{U} 的函数化简可得

$$\mathbf{U}^{n+1} = \arg \min_{\mathbf{U}} \tau \left\| \mathbf{U} \right\|_1 + \frac{\mu}{2} \left\| \mathbf{U} - \mathbf{D}\mathbf{A} + \mathbf{y}/\mu \right\|_2^2 \quad (24)$$

进而有

$$\begin{cases} \mathbf{U}_1 = \mathbf{T}_{\tau/\mu}(\tau_x \mathbf{D}_x \mathbf{A} - \mathbf{y}_1/\mu) \\ \mathbf{U}_2 = \mathbf{T}_{\tau/\mu}(\tau_y \mathbf{D}_y \mathbf{A} - \mathbf{y}_2/\mu) \\ \mathbf{U}_3 = \mathbf{T}_{\tau/\mu}(\tau_z \mathbf{D}_z \mathbf{A} - \mathbf{y}_3/\mu) \end{cases} \quad (25)$$

最后更新 \mathbf{Y}_O 、 \mathbf{Y}_L 、 \mathbf{y} 、 \mathbf{Y}_X 和 μ ,即

$$\begin{cases} Y_O = Y_O + \mu(Y - X - S) \\ Y_L = Y_L + \mu(X - J) \\ \mathbf{y} = \mathbf{y} + \mu(U - DA) \\ Y_X = Y_X + \mu(J - A) \\ \mu = \rho\mu \end{cases} \quad (26)$$

综上所述,本文方法主要步骤如算法1所示,所用参数值为: $k=12\ 000$, $c=30$, $\lambda=1.2$, $\tau=0.005$, $r=2$, $\text{maxiter}=50$ 。

算法1 利用SCLR算法进行高光谱图像降噪

输入:待降噪图像 $Y \in \mathbb{R}^{w \times h \times b}$,超像素块个数 k ,K-means聚类簇数 c 和参数 λ 、 τ 、 r ,最大迭代次数 maxiter ;
输出:降噪后图像 $J \in \mathbb{R}^{w \times h \times b}$;

- (1) 初始化: X 为符合正态分布的 $w \times h \times b$ 矩阵, $J=X$, $A=J$, $S=Y_O$, Y_L , \mathbf{y} , Y_X 均为 $w \times h \times b$ 的零矩阵;
- (2) 利用2.1节所提方法对 Y 进行划分聚类,获得各个像素点的类别矩阵 $C \in \mathbb{R}^{w \times h}$,和类别数 kinds ;
- (3) for iter=1 to maxiter do
- (4) for $n=1$ to kinds do
- (5) 根据式(18)更新 X^{n+1} ;
- (6) end for
- (7) 根据式(19)更新 S^{n+1} ;
- (8) 根据式(20)更新 J^{n+1} ;
- (9) 根据式(23)更新 A^{n+1} ;
- (10) 根据式(24)更新 U^{n+1} ;
- (11) 根据式(26)更新 Y_O 、 Y_L 、 \mathbf{y} 、 Y_X 和 μ ;
- (12) end for

3 实验结果及分析

为了验证本文所提方法的有效性,在模拟数据和真实数据上进行了实验,并与5种降噪方法进行了比较,分别为BM4D^[18]、LRMR^[5]、局部低秩矩阵恢复和全局空-谱全变差方法(Local low-rank and global spatial-spectral total variation, LLRSSTV)^[6]、平滑波段超像素分割降噪方法(Superpixel segmentation of smooth band, SSSB)^[8]、结合非局部自相似性和局部低秩正则化降噪方法(Spatial non-local and local rank-constrained low-rank regularized plug-and-play, NLRpNp)^[9],其中BM4D是十分经典的一种方法,而LRMR和LLRSSTV则是基于低秩特性降噪方法的代表,SSSB利用空间局部相似性,NLRpNp则利用了非局部自相似性。所使用的对比方法的相关参数均参照所在文献给出的最优参数进行模拟和仿真。具体参数如下:

- (1) BM4D:立方块尺寸 $L=4$,组尺寸 $M=32$,步长 $N_{\text{step}}=3$,搜索块尺寸 $N_s=11$,相似度阈值 $\tau_{\text{match}}=0.4$ 。
- (2) LRMR:局部块尺寸 $q=20$,步长 $\text{step}=4$,低秩矩阵秩上限 $r=7$,稀疏矩阵基数 $k=4\ 000$ 。
- (3) LLRSSTV:局部块尺寸 $q=20$,正则化参数 $\lambda=0.2$ 、 $\tau=0.005$ 、 $\tau_b=0.5$ 。
- (4) SSSB:超像素个数 $K=45$,正则化参数根据超像素块尺寸自适应确定。
- (5) NLRpNp:局部块尺寸 $q=20$,步长 $\text{step}=10$,正则化参数 $\lambda=0.2$ 、 $\tau=0.005$,低秩矩阵秩上限 $r=2$ 。

3.1 模拟数据实验

模拟实验使用经典的Washington DC Mall数据集(<https://engineering.purdue.edu/biehl/Multi-Spec/hyperspectral.html/>),由于原图过大,为方便实验与展示进行了裁剪,得到256像素 \times 256像素 \times

191的数据立方,即长宽均为256像素,含有191个波段。

本实验为模拟真实的含噪图像,添加了混合噪声,包括高斯噪声、脉冲噪声和死线等,通过PSNR^[19]、SSIM^[20]、特征相似性(Feature similarity index measure,FSIM)^[21]及它们在所有波段上的均值MPSNR、MSSIM、MFSIM作为评价指标。具体添加噪声情况如下:

(1) 噪声情况1。为每个波段添加相同强度的高斯噪声(G)和脉冲噪声(P),高斯噪声方差分别取 $G=0.025$ 、 $G=0.075$,脉冲噪声强度分别取 $P=0.05$ 、 $P=0.15$ 。

(2) 噪声情况2。为每个波段添加不同强度的高斯噪声和脉冲噪声,高斯噪声方差范围为 $0\sim 0.1$,脉冲噪声强度范围为 $0\sim 0.2$ 。

(3) 噪声情况3。在情况2的基础上,在 Washington DC Mall的60~110波段添加死线,死线数目在3~12之间随机变化,宽度在2~6之间随机变化。

(4) 噪声情况4。在情况3的基础上,在 Washington DC Mall的80~95波段的固定位置添加大小为20像素 \times 20像素的斑块噪声。

本文首先做了算法自身对比实验。图4~6分别为SLIC算法形成的超像素块个数 k 、K-means聚类簇数 c 和参数 λ 的变化对MPSNR的影响。图中结果表明,模拟数据实验中 k 值达到12 000之后MPSNR逐渐平稳,也就是高光谱图像单波段像素总数的5%左右,能够较好地处理图像边界问题,基本能够将相同地物划分到同一个超像素块内。 c 值在图5(a,b)两个情况下与实际地物类别个数相接近或略大时,效果较好,在图5(c)情况下则无明显规律属于特殊情况,本文模拟数据实验中真实地物类别数为15。正则化参数 λ 则在0.3之后变化趋于稳定,其代表了稀疏噪声的权重。

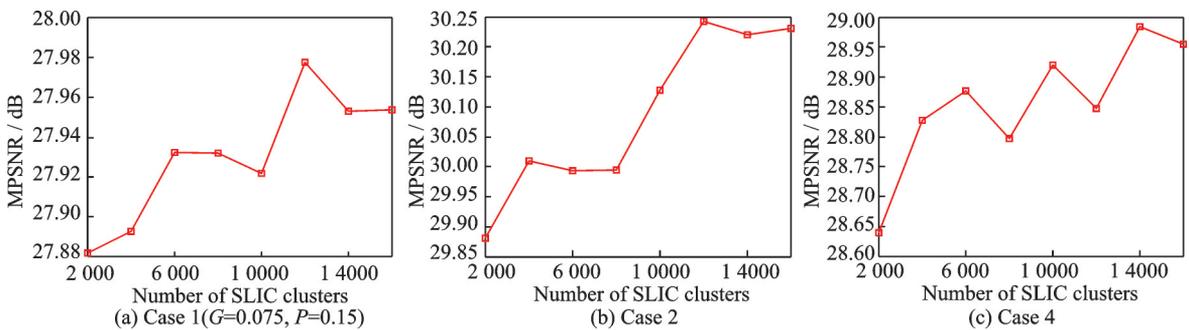


图4 SLIC形成超像素块个数对MPSNR的影响

Fig.4 Influence of the number of superpixel blocks formed by SLIC on MPSNR

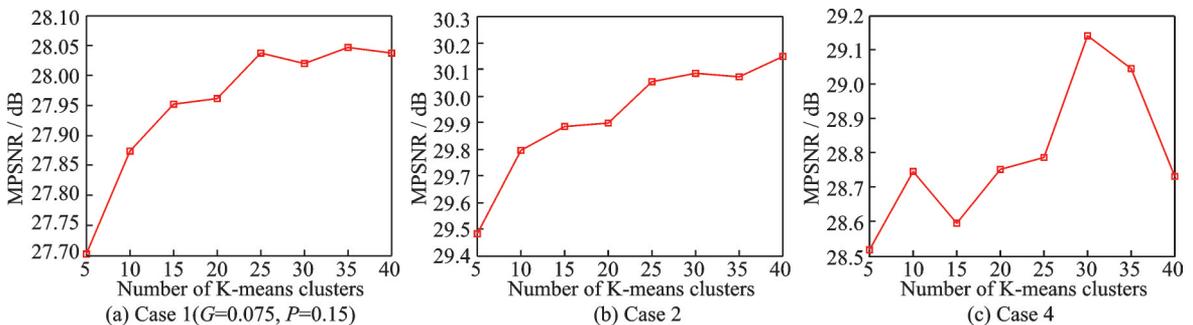


图5 K-means聚类个数对MPSNR的影响

Fig.5 Influence of the number of K-means clusters on MPSNR

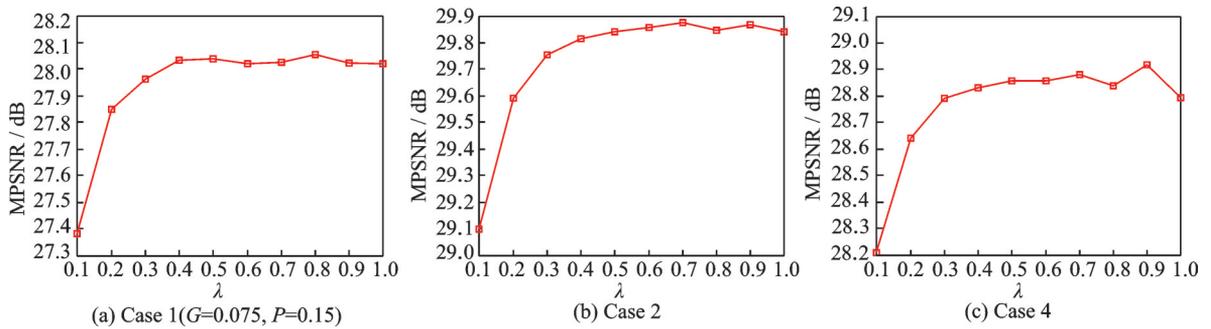


图6 参数λ对MPSNR的影响

Fig.6 Influence of the parameter λ on MPSNR

图7为4种不同方法去噪后各波段PSNR值。图中4种方法分别为只使用LRMR、使用LRMR加SSTV约束、使用SLIC加LRMR以及本文方法。其MPSNR分别为25.59、25.67、24.82、26.41 dB。使用LRMR可以较好地去除稀疏噪声,加上SSTV约束则进一步去除了高斯噪声,利用SLIC构建低秩矩阵则与LRMR接近,而对SLIC划分结果进行K-means聚类则能够构建出具有良好空-谱双重低秩属性的矩阵,使得低秩矩阵恢复模型的降噪结果进一步提升。对高光谱图像进行SLIC超像素分割,只需要提供一个波段信息,这就需要对数据降维或选择。图8给出了3种波段选取方法对PSNR的影响,图中Ysmooth为平滑波段即取全波段的平均值,PCA为主成分分析法,Entropy则为本文所使用的信息熵。因为SLIC是依据空间信息划分,各个波段的不同地物都会表现出差异,所以选择一个噪声较少的波段即可获得较好的分割结果。图8结果表明3种方法的效果相差不大。

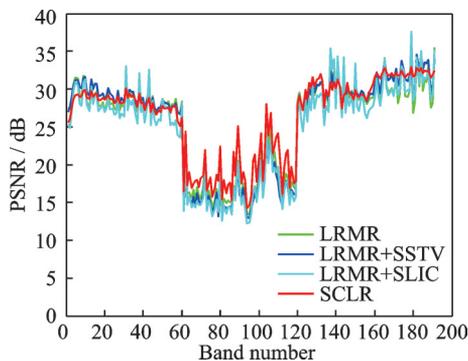


图7 4种不同方法去噪后各波段的PSNR值

Fig.7 PSNR of each band after denoising using four different methods

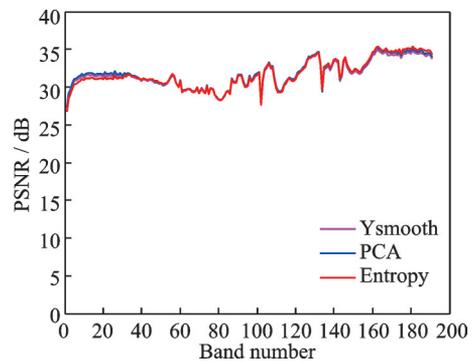


图8 不同波段选取方法对PSNR的影响

Fig.8 Influence of different band selection methods on PSNR

图9是噪声情况3和4下各降噪方法去噪结果的PSNR和SSIM对比图,表1给出了各噪声情况定量评价结果。可以看出本文方法随着高斯噪声强度的增加,降噪能力逐渐弱于LLRSSTV算法;但对于稀疏噪声强烈的混合噪声,如大量的死线和大面积连续波段数据缺失的情况,本文方法表现优异,在MPSNR、MSSIM和MFSIM等定量指标上,相较于其他方法都有较大的提升。

图10、11是 Washington DC Mall第85波段在噪声情况3、4下各降噪方法去噪前后对比图。图11显示了在严重混合噪声影响下,原图基本难以分辨出,并且还有一块连续多波段的大面积像素丢失,为降噪工作带来了较大困难。从降噪结果上可以看出,BM4D无法去除死线和斑块,其余几种方法较好

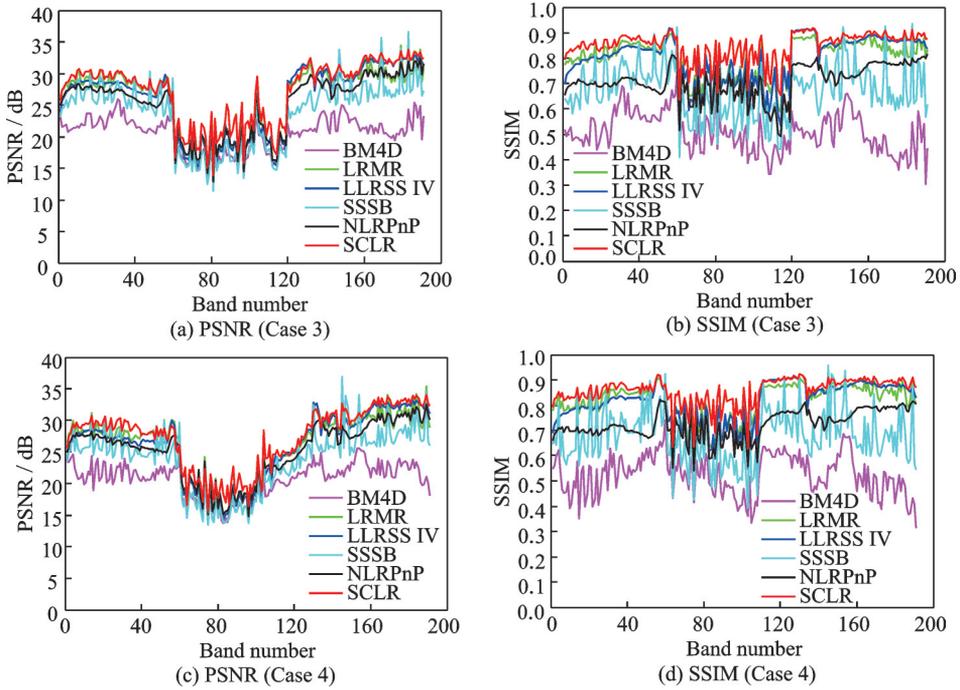


图9 不同方法在噪声情况3、4下降噪后的图像PSNR和SSIM对比图

Fig.9 Comparison of PSNR and SSIM with different methods after denoising in noise cases 3 and 4

表1 模拟实验中的定量评价结果

Table 1 Quantitative evaluation results in simulation experiments

Noise case	Level	Evaluation index	BM4D	LRMR	LLRSSTV	SSSB	NLRPnP	SCLR
Case 1	$G=0.025$ $P=0.05$	MPSNR/dB	24.675 0	31.117 0	31.747 6	27.708 1	27.837 7	31.929 7
		MSSIM	0.655 4	0.902 8	0.925 4	0.794 3	0.805 5	0.927 6
		MFSIM	0.857 5	0.949 4	0.954 6	0.950 3	0.896 5	0.955 4
	$G=0.075$ $P=0.15$	MPSNR/dB	19.712 3	27.022 0	29.081 3	23.138 1	27.530 9	28.085 2
		MSSIM	0.485 7	0.795 5	0.860 2	0.593 7	0.799 1	0.838 9
		MFSIM	0.769 7	0.903 6	0.925 0	0.821 0	0.899 1	0.912 7
Case 2	Gaussian+Im- pulse	MPSNR/dB	22.262 5	29.264 4	29.836 1	26.421 9	27.095 4	30.826 0
		MSSIM	0.581 5	0.866 8	0.879 2	0.744 0	0.783 8	0.914 8
		MFSIM	0.819 8	0.939 6	0.930 3	0.882 5	0.885 0	0.949 1
Case 3	Gaussian+Im- pulse+ Deadline	MPSNR/dB	20.451 6	26.178 2	26.016 3	23.679 3	25.187 8	27.296 7
		MSSIM	0.507 2	0.801 1	0.802 6	0.669 7	0.708 6	0.848 5
		MFSIM	0.777 7	0.888 2	0.894 3	0.844 2	0.836 2	0.916 8
Case 4	Gaussian+Im- pulse+ Deadline+Block	MPSNR/dB	20.634 0	26.287 1	26.091 7	23.852 7	25.291 1	27.334 6
		MSSIM	0.524 1	0.818 6	0.814 3	0.677 7	0.724 0	0.856 9
		MFSIM	0.783 2	0.901 0	0.894 6	0.847 0	0.844 9	0.919 6

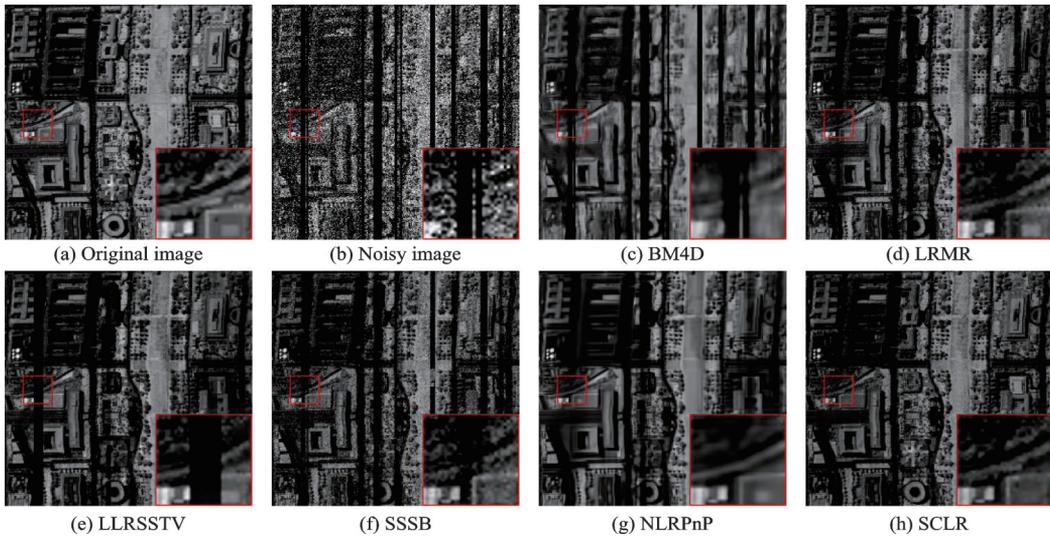


图 10 模拟实验噪声情况 3 下 Washington DC Mall 数据第 85 波段的降噪结果

Fig.10 Denoising results of the 85th band of Washington DC Mall in simulated noise case 3

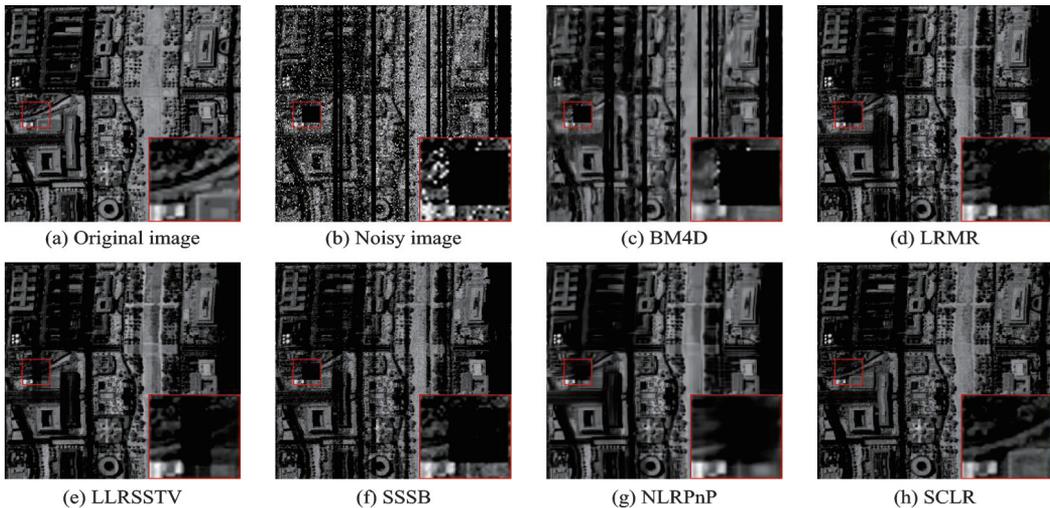


图 11 模拟实验噪声情况 4 下 Washington DC Mall 数据第 85 波段的降噪结果

Fig.11 Denoising results of the 85th band of Washington DC Mall in simulated noise case 4

地去除了高斯噪声、脉冲噪声和宽度较短的 deadline,但也无法去除较宽的 deadline 和斑块噪声。本文方法通过引入空间相似性的先验知识,对非局部块构建 LRMR 模型,充分地利用了高光谱图像空间低秩特性,从而使得光谱维度上具有一定结构信息的噪声依旧能在构造出的矩阵中表现出稀疏属性,进而能够较好地恢复出斑块内损失的数据。

在模拟噪声情况 1 下的各算法运行时间对比如表 2 所示,其余噪声情况与之接近不再列出。其中, BM4D 需要经过硬阈值化和维纳滤波两个阶段,包括了大量复杂运算,耗时较高。其余基于低秩的方法运行时间则主要取决于需要求解低秩矩阵的局部块的个数及大小, LRMR 与 LLRSSTV 接近, NLRnP 则因为引入了 BM4D 导致运行时间较长,本文由于局部块大小较大且需要进行超像素块划分与聚类,运行时间较 LRMR 和 LLRSSTV 要长。

表 2 噪声情况 1 下的各降噪方法运行时间
Table 2 Running time of each noise reduction method in noise case 1

方法	BM4D	LRMR	LLRSSTV	SSSB	NLRpNp	SCLR
运行时间/s	543.28	236.80	123.21	45.18	1 052.7	431.23

3.2 真实数据实验

真实数据实验同样使用经典的 Indian Pines 数据,它是由机载可见红外成像光谱仪 AVIRIS 采集而得。该图像大小为 145 像素 \times 145 像素和 220 个波段,一些波段被混合高斯噪声和脉冲噪声严重污染,而其他一些波段质量较高。本文对 Indian Pines 的第 1、2 和 103 波段分别使用上述几种降噪方法,降噪结果如图 12~14 所示。本文方法在视觉上,相比于其余 5 种方法均有所提升。

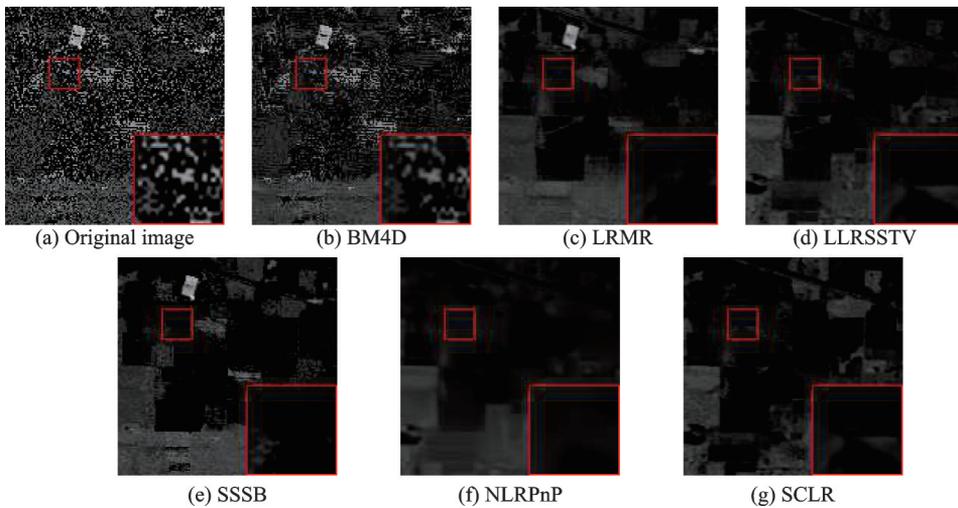


图 12 Indian Pines 图像在波段 1 的降噪结果

Fig.12 Denoising results of Indian Pines image in band 1

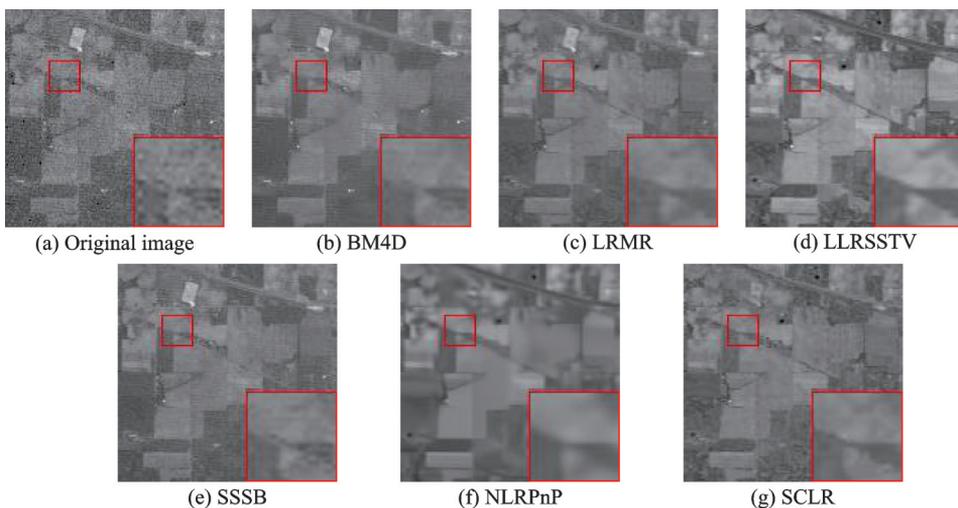


图 13 Indian Pines 图像在波段 2 的降噪结果

Fig.13 Denoising results of Indian Pines image in band 2

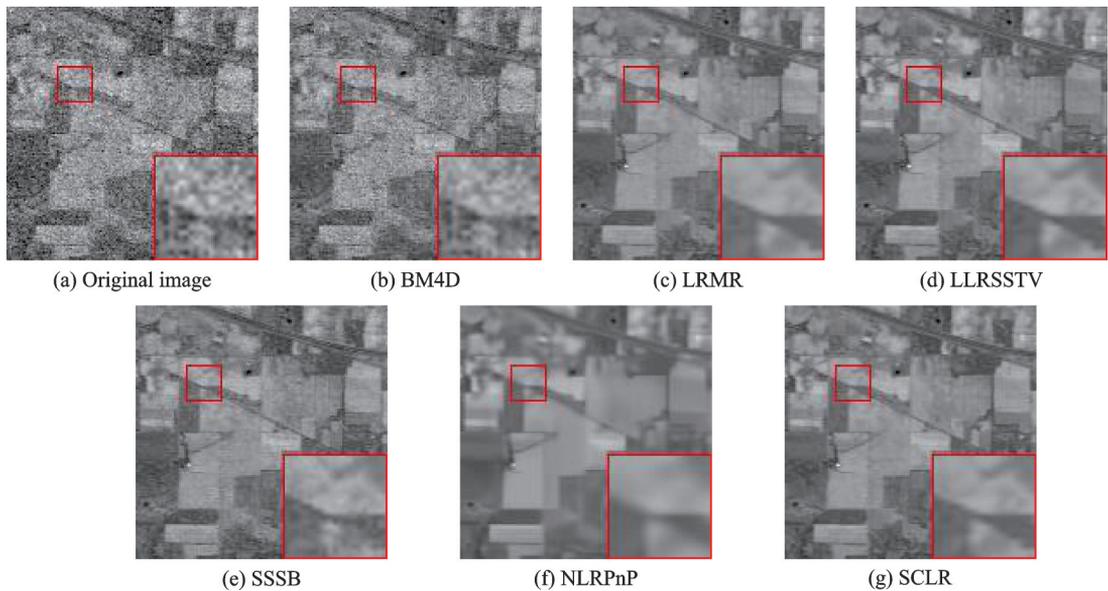


图 14 Indian Pines 图像在波段 103 的降噪结果

Fig.14 Denoising results of Indian Pines image in band 103

在定量评价方面,图 15、16 是 Indian Pines 第 103 个波段的垂直均值剖面图和水平均值剖面图,该剖面图波动越小图像质量越高^[22]。可以看到,降噪方法对波动有一定程度的抑制,且本文方法相比于其他方法更加平滑,这表明噪声得到了更有效的去除。真实数据实验的各降噪算法运行时间对比如表 3 所示。运行时间相对关系与表 2 基本相同,由于该图像大小仅为 145 像素 \times 145 像素,基于低秩方法生成的局部块个数减少,而本文方法生成的局部块尺寸也有所减小,这都使得运行时间进一步减少。

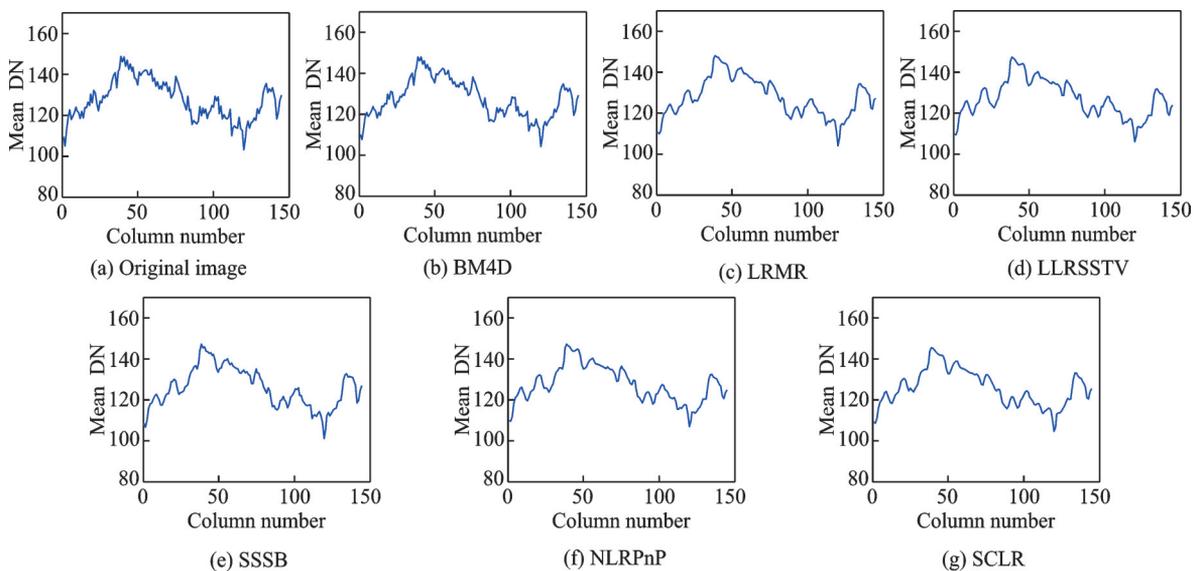


图 15 Indian Pines 图像在第 103 波段的垂直均值剖面图

Fig.15 Vertical mean profiles of band 103 of Indian Pines image

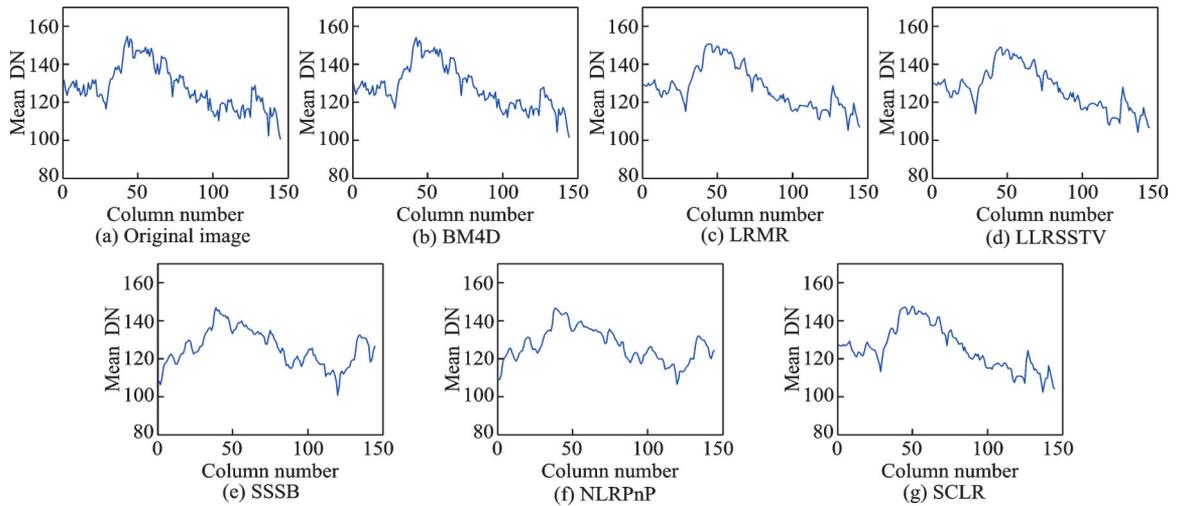


图 16 Indian Pines 图像在第 103 波段的水平均值剖面图

Fig.16 Horizontal mean profiles of band 103 of Indian Pines image

表 3 Indian Pines 图像上各降噪方法运行时间

Table 3 Running time of each denoising method on Indian Pines image

方法	BM4D	LRMR	LLRSSTV	SSSB	NLRpNp	SCLR
运行时间/s	174.51	75.15	78.70	31.35	963.34	108.30

4 结束语

为了充分利用空间局部相似与非局部自相似性,以有效去除光谱维度上具有一定结构信息的稀疏噪声,本文提出了一种基于超像素块聚类与低秩特性的高光谱图像降噪方法。通过超像素分割与聚类相结合,构造出具有良好空-谱双重低秩特性的矩阵。在模拟数据集和真实数据集上进行实验,结果表明,相较于其他基于低秩特性的方法,本文方法在去除混合噪声能力上有一定提升,尤其对于稀疏噪声强烈和存在具有一定结构信息稀疏噪声的情况,对比 LLRSSTV 算法在 MPSNR 指标上分别提升了 1.12 dB 和 1.05 dB。

参考文献:

[1] 张兵. 高光谱图像处理与信息提取前沿[J]. 遥感学报, 2016, 20(5): 1062-1090.
ZHANG Bing. Advancement of hyperspectral image processing and information extraction[J]. Journal of Remote Sensing, 2016, 20(5): 1062-1090.

[2] DABOV K, FOI A, KATKOVNIK V, et al. Image denoising by sparse 3-D transform-domain collaborative filtering[J]. IEEE Transactions on Image Processing, 2007, 16(8): 2080-2095.

[3] ELAD M, AHARON M. Image denoising via sparse and redundant representations over learned dictionaries[J]. IEEE Transactions on Image Processing, 2006, 15(12): 3736-3745.

[4] WRIGHT J, GANESH A, RAO S, et al. Robust principal component analysis: Exact recovery of corrupted low-rank matrices via convex optimization[C]// Proceedings of the 23rd Annual Conference on Neural Information Processing Systems. Vancouver, British Columbia, Canada: Curran Associates Inc, 2009: 1-9.

[5] ZHANG Hongyan, HE Wei, ZHANG Liangpei, et al. Hyperspectral image restoration using low-rank matrix recovery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 52(8): 4729-4743.

[6] HE Wei, ZHANG Hongyan, SHEN Huanfeng, et al. Hyperspectral image denoising using local low-rank matrix recovery and global spatial-spectral total variation[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2018, 11(3): 713-729.

- [7] SUN Le, JEON B, SOOMRO B N, et al. Fast superpixel based subspace low rank learning method for hyperspectral denoising [J]. *IEEE Access*, 2018, 6: 12031-12043.
- [8] FAN Y R, HUANG T Z. Hyperspectral image restoration via superpixel segmentation of smooth band[J]. *Neurocomputing*, 2021, 455: 340-352.
- [9] ZENG Haijin, XIE Xiaozhen, KONG Wenfeng, et al. Hyperspectral image denoising via combined non-local self-similarity and local low-rank regularization[J]. *IEEE Access*, 2020, 8: 50190-50208.
- [10] LIU Wei, HE Chengxun, SUN Le. Spectral-smoothness and non-local self-similarity regularized subspace low-rank learning method for hyperspectral mixed denoising[J]. *Remote Sensing*, 2021, 13(16): 3196:1-3196:20.
- [11] 黄冬梅,李永兰,张明华,等. 结合地物类别和低秩特性的高光谱图像降噪[J].*激光与光电子学进展*, 2020, 57(12): 278-286.
HUANG Dongmei, LI Yonglan, ZHANG Minghua, et al. Hyperspectral image denoising by combining ground object features with low-rank characteristics[J]. *Laser & Optoelectronics Progress*, 2020, 57(12): 278-286.
- [12] 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.
- [13] 史加荣,郑秀云,魏宗田,等. 低秩矩阵恢复算法综述[J].*计算机应用研究*, 2013, 30(6): 1601-1605.
SHI Jiarong, ZHENG Xiuyun, WEI Zongtian, et al. Survey on algorithms of low-rank matrix recovery[J]. *Application Research of Computers*, 2013, 30(6): 1601-1605.
- [14] SHEN N, JIN Z, WANG Q. Nested alternating direction method of multipliers to low-rank and sparse-column matrices recovery[J]. *Chinese Quarterly Journal of Mathematics*, 2021, 36(1): 90-110.
- [15] 闫喜红,王川龙,李超,等. 求解低秩矩阵恢复问题的非单调交替梯度方向法[J].*中国科学:数学*, 2021, 51(4): 549-560.
YAN Xihong, WANG Chuanlong, LI Chao, et al. A non-monotone alternating directional method for matrix recovery problem[J]. *Sci Sin Math*, 2021, 51(4): 549-560.
- [16] LIN Zhouchen, LIU Risheng, SU Zhixun. Linearized alternating direction method with adaptive penalty for low rank representation[J]. *Advances in Neural Information Processing Systems*, 2011, 24: 612-620.
- [17] XUE Jize, ZHAO Yongqiang, LIAO Wenzhi, et al. Joint spatial and spectral low-rank regularization for hyperspectral image denoising[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 56(4): 1940-1958.
- [18] MAGGIONI M, KATKOVNIK V, EGIAZARIAN K, et al. Nonlocal transform-domain filter for volumetric data denoising and reconstruction[J]. *IEEE Transactions on Image Processing*, 2012, 22(1): 119-133.
- [19] HUYNH-THU Q, GHANBARI M. Scope of validity of PSNR in image/video quality assessment[J]. *Electronics Letters*, 2008, 44(13): 800-801.
- [20] WANG Zhou, 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.
- [21] ZHANG Lin, ZHANG Lei, MOU Xuanqin, et al. FSIM: A feature similarity index for image quality assessment[J]. *IEEE Transactions on Image Processing*, 2011, 20(8): 2378-2386.
- [22] YANG Jingxiang, ZHAO Yongqiang, YI Chen, et al. No-reference hyperspectral image quality assessment via quality-sensitive features learning[J]. *Remote Sensing*, 2017, 9(4): 305:1-305:24.

作者简介:



张明华(1977-),女,副教授,研究方向:遥感图像处理、海洋信息技术,E-mail: mhzhang@shou.edu.cn。



武云(1997-),男,硕士研究生,研究方向:高光谱图像降噪。



宋巍(1977-),通信作者,女,教授,研究方向:计算机视觉、海洋信息智能处理,E-mail: wsong@shou.edu.cn。



梅海彬(1973-),男,副教授,研究方向:海洋大数据智能分析。



贺琪(1979-),女,教授,研究方向:海洋大数据存储、工作流与业务流程管理、服务计算、云计算。



苏诚(1962-),男,教授级高工,研究方向:大型海洋信息化系统构建、海洋工程勘察与数值计算。