

基于非局部相似联合低秩表示的高光谱图像去噪

张显 叶军

南京邮电大学理学院 南京 210023

(zx10186574@163.com)



摘要 高光谱图像(Hyperspectral Images, HSI)在采集过程中常受到多种类型的噪声干扰,会直接影响其在后续应用中的精度,因此 HSI 的去噪是一项十分重要的预处理过程。低秩表示(Low-Rank Representation, LRR)模型能很好地满足 HSI 的光谱性质,但该框架下字典的选择尤为为重要,在当下仍是一个开放性的问题。同时,典型去噪方法仅考虑了图像的局部相关性,不能满足去噪要求,非局部相似性在图像中也是不可忽略的。基于 LRR,文中提出了一种新的 HSI 去噪算法。首先,综合考虑噪声的类型,选取具有更全面的噪声判别能力的字典;其次,在对图像分块处理的前提下,通过聚类的方式引入非局部相似信息,将相似的图像块联合起来进行低秩表示。在模拟 Indian Pines 数据集以及 EO-1 Hyperion 真实数据集上的实验结果均表明,相较于目前主流的 HSI 去噪方法,无论是在图像的视觉效果还是在模拟数据集的定量评价指标下,所提方法均有显著提升。

关键词: 高光谱图像;去噪;低秩表示;字典选取;非局部相似

中图法分类号 TP751

Hyperspectral Images Denoising Based on Non-local Similarity Joint Low-rank Representation

ZHANG Xian and YE Jun

School of Science, Nanjing University of Posts and Telecommunications, Nanjing 210023, China

Abstract The acquisition of hyperspectral images (HSI) is often interfered by multiple types of noise, which will directly affect accuracy in the subsequent applications. Therefore, HSI denoising is a very important pretreatment process. The low-rank representation (LRR) model can well satisfy the spectral properties of HSI. However, the choice of dictionary under this framework is particularly significant, which is still an open question at present. Meanwhile, the typical method can't satisfy the requirement well by only considering the local correlation of the image, and the non-local similarity is equally of significance. Based on LRR, a new method of HSI denoising was proposed. Firstly, the type of noise is considered comprehensively and the dictionary with more comprehensive discrimination ability is selected. Secondly, on the premise of block processing, non-local similar information is introduced through clustering, and similar blocks are combined for LRR framework. The experimental results on the simulated Indian Pines and real EO-1 Hyperion data set show that the proposed method performs better than the state-of-art HSI denoising methods both in the visual effect of the image and the quantitative evaluation index of the simulated data set.

Keywords Hyperspectral images (HSI), Denoising, Low-rank representation (LRR), Dictionary selection, Non-local similarity

1 引言

高光谱图像(HSI)作为一种特殊的遥感图像,因含有丰富的光谱信息,在农业、林业、地质矿产乃至城市规划等领域有着十分广泛的应用^[1]。但实际采集到的 HSI 常含有较复杂的混合噪声,包括高斯噪声、椒盐噪声以及坏死的线条等其他类型的噪声,这不仅影响图像的视觉效果,而且会对其后续应用产生很大的影响^[2-4]。因此,HSI 的去噪是一项十分重要的预处理过程。

HSI 的去噪领域一直十分活跃,简单来说,HSI 可以看作

许多二维图像的叠加,每一幅二维图像对应一个波段。传统的 HSI 去噪方法就是将每个波段的图像看作一幅独立的二维图像,然后利用现阶段比较成熟的二维图像去噪方法逐一进行去噪,如基于全变分(Total Variation, TV)的方法^[5]、三维块匹配(Block-Matching and 3D filtering, BM3D)算法^[6],以及基于小波的方法^[7]。但这种去噪思路忽略了 HSI 各个波段间的相关性,使得对于受到强烈噪声干扰的波段的去噪效果明显较差。综合考虑空间信息与光谱信息的 HSI 去噪方法受到了广大学者的关注,Zhang^[8]提出了一种基于分段光滑的全变分正则约束项来提升去噪效果;而 Yuan 等^[9]则在

收到日期:2018-12-17 返修日期:2019-04-25

本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国家自然科学基金项目(61771250)

This work was supported by the National Natural Science Foundation of China (61771250).

通信作者:叶军(yj8422092@163.com)

在此基础上对该正则约束项进行了改进,提出了一种光谱空间自适应的TV模型,在这个模型中综合考虑了空间信息的差异性以及光谱信息的差异性;视频三维块匹配(Video Block-Matching and 3D filtering, VBM3D)算法^[10]是BM3D算法的进一步改进,将处理对象扩展到三维图像上;此外,基于张量分解的方法^[11]也被提出,这种方法把数据看作一个多维的数据立方体,然后利用线性代数对HSI张量直接进行分析。

与自然图像相比,HSI中存在着其特有的低秩先验信息,这既表现在光谱通道间的强相关性,又表现在临近像素间的空间相关性。因此,低秩特性可以作为一个很好的正则化条件来建立HSI的去噪模型^[12-14],鲁棒主成分分析(Robust Principal Component Analysis, RPCA)^[15]框架则很好地满足了这一约束。在RPCA的基础上,Zhang等^[16]提出了基于低秩矩阵恢复(Low-Rank Matrix Recovery, LRMR)的HSI去噪方法,较为成功地去除了HSI中的混合噪声。但RPCA框架没有对HSI光谱空间的内部结构进行约束,当噪声量级较大时,去噪效果会有所下降。事实上,根据地物种类,HSI的光谱空间可以看成是多个低秩子空间的联合,而不是一个单一的低秩空间。为了恢复数据的联合结构,低秩表示(LRR)框架^[17]提供了一种有力的工具。Liu等^[17]指出,给定一个字典,LRR就可以从低秩子空间中稳定重建出数据的联合结构。但是,对字典的选择在当下仍是一个开放性的问题。传统的方法是直接选取受污染的原始数据作为字典,但这种字典往往不能很好地反映真实数据的内在结构,去噪能力十分有限。与此同时,在对HSI进行去噪时,通常采用分块处理的方式,既减小了运算负担,又保留了图像在空间上的局部相关性。但这种思路无疑忽略了图像中的非局部相似信息,而这些信息往往是普遍存在的。Wang等^[18]在LRMR方法的基础上,通过分组的方式来引入非局部相似信息,进一步提升了去噪效果。

总的来说,采用低秩约束信息对HSI进行去噪时,需要考虑两方面的问题:1)数据表达模型的选择;2)图像本身信息的充分利用。针对上述两方面的问题,本文提出了一种基于非局部相似联合低秩表示(Non-local Similarity Joint Low-rank Representation, NLSJLRR)的HSI去噪方法,该方法主要包括LRR框架的字典选取以及非局部相似信息的引入两部分。本文的具体贡献如下:

1)字典的选取会直接影响LRR框架下的去噪效果。综合考虑各噪声类型,通过初步去噪得到更接近真实数据的HSI数据,并将其作为字典。与原始数据相比,该字典无疑更加接近真实数据的光谱结构。

2)在对HSI数据分块进行处理的同时,通过半监督聚类的方式引入真实图像数据中普遍存在的非局部相似信息,以进一步提升去噪效果。

2 低秩表示模型

矩阵的秩是一种具有非常强的全局约束能力的正则化算子,在三维立体视觉领域中随处可见。受近年来取得巨大成功的压缩感知和稀疏表示理论的推动,低秩模型逐渐发展成

为新的理论。目前,基于低秩模型的算法可以划分为两种类型:一类只考虑了一个低维子空间条件,如RPCA,目标是从原始数据中寻找低秩结构;另一类考虑了多个低维子空间条件,如LRR,即通过对数据矩阵增加低秩约束来挖掘数据潜在的结构信息。

对于一个给定的数据矩阵 \mathbf{W} ,LRR的目标函数为:

$$\begin{aligned} \min_Z \text{rank}(\mathbf{Z}) \\ \text{s. t. } \mathbf{W} = \mathbf{DZ} \end{aligned} \quad (1)$$

式(1)的解 \mathbf{Z}^* 被称为 \mathbf{W} 在字典 \mathbf{D} 下的最低秩表示。而在实际问题中,由于原始数据一般会受到噪声的影响,因此增加了噪声模型,其LRR目标函数为:

$$\begin{aligned} \min_{Z,E} \text{rank}(\mathbf{Z}) + \lambda \|\mathbf{E}\|_{2,1} \\ \text{s. t. } \mathbf{W} = \mathbf{DZ} + \mathbf{E} \end{aligned} \quad (2)$$

其中, \mathbf{E} 表示噪声矩阵, $\lambda > 0$ 为平衡参数。矩阵的求秩运算是非凸函数,无法直接进行计算,一般将其凸松弛为核范数,凸松弛后的LRR模型为:

$$\begin{aligned} \min_{Z,E} \text{rank}(\mathbf{Z}) + \lambda \|\mathbf{E}\|_{2,1} \\ \text{s. t. } \mathbf{W} = \mathbf{DZ} + \mathbf{E} \end{aligned} \quad (3)$$

研究表明,矩阵核范数是矩阵秩函数的最优凸近似,则上述问题也是一个凸优化问题,可以采用增广拉格朗日算法进行求解^[17]。设 \mathbf{Z}^* 是式(3)的最优解,则 \mathbf{DZ}^* 即为从原始数据矩阵 \mathbf{W} 中恢复的干净数据。

根据地物类别,HSI的光谱空间可以看成是多个低秩子空间的联合 $\bigcup_i s_i$ (s_i 代表低秩子空间),而RPCA模型假设光谱空间来源于一个单一的低秩空间,此时 $\bigcup_i s_i$ 就会退化成 $\sum_i s_i$ 。而 $\sum_i s_i$ 包含 $\bigcup_i s_i$,也就是说相较于RPCA模型,LRR模型的求解精度会进一步提升。

3 基于非局部相似联合低秩表示的高光谱图像去噪

低秩约束条件下,LRR框架更能满足HSI的光谱空间性质,但该框架下字典的选取尤为重要;与此同时,现阶段单独考虑图像的空间局部相关性已不能满足去噪要求,必须引入更多的信息。

3.1 字典的选取

本节通过对含噪HSI进行初步的去噪处理,来选取后续LRR模型中的字典。假设受污染的HSI数据立方体为 $\Gamma \in \mathbb{R}^{m \times n \times p}$,其中 $m \times n$ 表示数据的二维空间信息, p 代表波段数。按照列优先的方式将每个波段的数据都拉成一个列向量,那么 Γ 就可以表示成一个空-谱联合的二维矩阵,记为 $\mathbf{X} = [\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_p] \in \mathbb{R}^{mn \times p}$,该矩阵的每一列代表一个波段,每一行代表一个像素的波段信息。利用上述方法将HSI数据转换为二维矩阵,则含噪的HSI矩阵模型可以表示为:

$$\mathbf{X} = \mathbf{L} + \mathbf{S} + \mathbf{N} \quad (4)$$

其中, \mathbf{L} 为低秩矩阵,表示去噪后的数据; \mathbf{S} 为稀噪声矩阵; \mathbf{N} 为添加的高斯噪声判别项。上述模型的优化问题为:

$$\begin{aligned} \min_{L,S} \|\mathbf{L}\|_* + \mu \|\mathbf{S}\|_1 \\ \text{s. t. } \|\mathbf{X} - \mathbf{L} - \mathbf{S}\|_F \leq \sigma \end{aligned} \quad (5)$$

其中, μ 为折中因子, σ 为与高斯噪声标准差有关的常数。为方便求解, Zhou 等^[19]提出了一种等价模型:

$$\begin{aligned} \min_{L, S} & \|X - L - S\|_F^2 \\ \text{s. t.} & \text{rank}(L) \leq r, \text{card}(S) \leq k \end{aligned} \quad (6)$$

其中, r 和 k 为可调节参数, 分别用来约束 L 的秩以及 S 的基数。文献[19]同样提供了一种 GoDec 算法, 用于求解上述模型。将求解得到的 L 进行重构即可得到初步的无噪 HSI 数据, 记为 Δ 。

选取 Δ 作为后续 LRR 模型中的字典, 相较原始数据 Γ , Δ 更加接近真实数据的光谱结构, 并且在模型中十分全面地考虑了各种类型噪声的存在, 使得字典具备更全面的噪声判别能力。

3.2 非局部相似块的联合

将整体图像数据进行分块处理时, 对存在局部大噪声数据的去噪效果会很不理想。HSI 中普遍存在非局部相似块, 它们具有相同的地物类型, 对应的光谱信息也十分相似, 因此, 当这些三维图像块转换为二维数据矩阵时就具有近似的低秩特征。将这些二维矩阵联合起来利用 LRR 进行求解, 既提升了低秩表示的样本容量, 又提升了局部大噪声的去除效果。

但是, 当受到较大量级噪声的影响时, 图像数据将受到严重破坏, 直接对含有噪声的图像块进行聚类或是分组的操作^[18,20], 常常使得联合结果不能很好地代表真实数据中图像块之间的非局部相似信息。针对这一问题, 我们采用 3.1 节中得到的 Δ 作为相似块选取的依据, 利用 K-means 聚类算法进行分组。具体操作如下: 首先采用相同的规则利用滑动窗口对 Γ 以及 Δ 进行取块, 两个图像块集合记为 \mathcal{X} 和 \mathcal{L} ; 然后以给定的 K 值对 \mathcal{L} 利用 K-means 算法进行聚类, 将聚类结果对应到 \mathcal{X} , 这样就得到了 \mathcal{X} 中图像块的类别信息; 最后, 对于 \mathcal{X} 中的每个图像块, 选取与它属于同一类别的 q 个图像块, 采取 3.1 节中 HSI 的矩阵表示方法将选到的图像块展开为二维矩阵并进行联合, 作为 LRR 模型中输入的原始数据矩阵。需要说明的是, 这里并没有对相似图像块的选取规则加以限定, 而是采取随机选取的方式, 目的是尽可能地引入非局部相似信息。

3.3 NLSJLRR 方法

若假设滑动窗口的大小为 $M \times M$, 则每个图像块对应的二维矩阵大小为 $M^2 \times p$, 联合后作为输入的原始数据矩阵记为 $\{G_i\}_{i=1}^N$ (N 为图像块总数), 有 $G_i \in \mathcal{R}^{(q+1)M^2 \times p}$, 与此同时, 在

$$SSIM_i = \frac{(2\mu(x^i)\mu(\hat{x}^i) + C_1)(2\sigma(x^i)\sigma(\hat{x}^i) + C_2)(\sigma(x^i, \hat{x}^i) + C_3)}{(\mu^2(x^i) + \mu^2(\hat{x}^i) + C_1)(\sigma^2(x^i) + \sigma^2(\hat{x}^i) + C_2)(\sigma(x^i)\sigma(\hat{x}^i) + C_3)} \quad (8)$$

$$MPSNR = \frac{1}{p} \sum_{i=1}^p PSNR_i \quad (9)$$

$$MSSIM = \frac{1}{p} \sum_{i=1}^p SSIM_i \quad (10)$$

其中, x^i 和 \hat{x}^i 分别代表第 i 个波段的无噪图像和去噪后图像; $\mu(x^i)$ 和 $\mu(\hat{x}^i)$ 代表对应的均值, $\sigma(x^i)$ 和 $\sigma(\hat{x}^i)$ 代表对应的方差, $\sigma(x^i, \hat{x}^i)$ 则代表协方差。总的来说, PSNR 值和 SSIM 值越大, 去噪效果就越好。

\mathcal{L} 中选取对应的图像块, 展开并联合得到作为 LRR 模型的输入的字典矩阵, 记为 $H_i \in \mathcal{R}^{(q+1)M^2 \times p}$ 。基于非局部相似联合 LRR 的 HSI 去噪方法的具体流程如算法 1 所示。

算法 1 NLSJLRR 去噪算法

输入: 含噪 HSI 数据 Γ

输出: 去噪后的数据

Step1 通过 3.1 节得到 Δ ;

Step2 通过 3.2 节得到 G_i 和 $H_i, i=1, 2, \dots, N$;

Step3 for $i=1:N$

$W=G_i, D=H_i$, 代入式(3)进行求解

end

Step4 二维数据矩阵重构回图像块;

Step5 对图像块中重复选取的像素值取平均, 还原得到去噪后的数据立方体。

4 数值实验与结果分析

为了验证所提方法的有效性, 本节分别使用模拟 HSI 数据集和真实 HSI 数据集进行数值实验, 分别选取经典的 VBM3D 方法、LRMR 方法以及最新的 LLRSSTV (Local Low-rank and Global Spatial-Spectral Total Variation)^[14] 方法作为对比方法, 并对实验结果进行分析。其中, LLRSSTV 方法是在对图像块利用 RPCA 框架约束的前提下, 引入空间-光谱全变分正则项 (SSTV) 来进一步提升去噪效果。

4.1 模拟数据实验

采用 Indian Pines 作为模拟无噪 HSI 数据集, 该数据集由真实的地物类别 Indian Pines 数据集和美国数字光谱实验室提供的光谱数据库 splib06a 人工合成得到, 整个高光谱数据集共有 224 个波段, 像元数为 145×145 。模拟实验中, 对每个波段均添加 $\sigma=0.03$ 的高斯噪声, 以模拟实际中的热噪声; 选取 3, 15, 27, 54, 76, 98, 110 共 7 个波段添加 20% 的椒盐噪声, 并添加 3 条死线噪声, 以模拟实际中的像元坏死以及传感器故障。

本文采用两个定量评价指标 (峰值信噪比 (Peak Signal-to-Noise, PSNR) 和结构相似度 (Structural Similarity, SSIM)^[21]) 来对实验结果进行定量评价。对各方法的去噪结果图像逐波段计算出 PSNR 值和 SSIM 值, 然后取结果的平均值得到平均 PSNR (Mean PSNR, MPSNR) 和平均 SSIM (Mean SSIM, MSSIM) 值。各指标定义如下:

$$PSNR_i = 10 \lg \frac{m \times n}{\sum_{a=1}^m \sum_{b=1}^n |x_{ab}^i - \hat{x}_{ab}^i|^2} \quad (7)$$

模拟数据实验中, 在 28 波段中仅添加了高斯噪声。从图 1 中可以看出, VBM3D 方法基本去除了高斯噪声, 但在部分边缘存在过度擦除的现象; LRMR 方法对于高斯噪声的去除则比较成功, 但对于图像的细节恢复效果不够理想; LLRSSTV 方法由于引入了 TV 项, 对于高斯噪声的去除效果十分显著, 并且图像边缘信息保留得也十分完整; 本文所提的 NLSJLRR 方法也十分成功地去除了高斯噪声, 并且由于非局部相似信息的引入, 较好地保留了图像的边缘信息。




图1 模拟 Indian Pines 数据集第 28 波段的实验结果对比

Fig.1 Comparison of experimental results at 28th band of simulated dataset Indian Pines

在第 110 波段添加了多种类型的混合噪声,实验结果如图 2 所示。可以看出,VBM3D 方法的表现更加糟糕,当图像中存在较强烈的稀疏噪声时,该方法对于图像质量的改善十分有限。LRMR 方法基本去除了混合噪声,但在死线噪声的去除以及图像细节的还原上仍有不足。针对 LLRSSTV 方法,从去噪结果图可以明显地看出,其对死线噪声的去除效果十分一般。实际上,该方法十分依赖于图像块的秩约束,当该约束很小时可以达到去除死线噪声的目的,但也会造成图像整体质量的急剧下降,而放松该约束以提升整体图像质量的同时,就会出现图中死线噪声去除不理想的现象。在同等情况下,本文所提 NLSJLRR 方法则在保证整体图像质量的前提下,成功去除了比如死线噪声的强烈稀疏噪声。

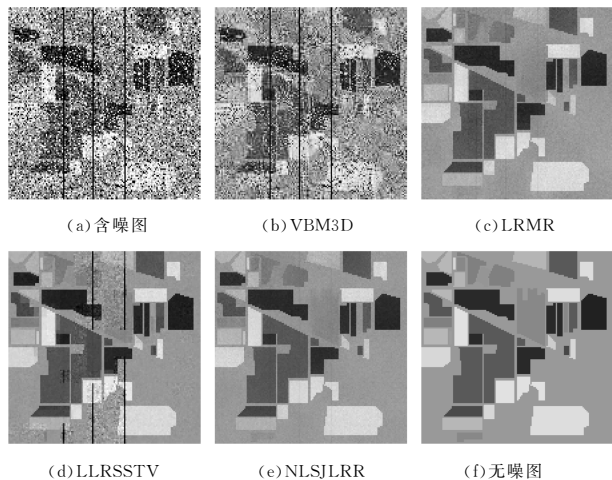


图2 模拟 Indian Pines 数据集第 110 波段的实验结果对比

Fig.2 Comparison of experimental results at 110th band of simulated dataset Indian Pines

从图 3 中可以看出,在具有强烈稀疏噪声干扰的波段,LLRSSTV 方法去噪结果的 PSNR 值以及 SSIM 值均有明显下降,NLSJLRR 方法的整体去噪效果则十分理想,尤其是在含有多种类型噪声的第 3,15,27,54,76,98,110 波段处,该方法的去噪效果取得了更大的改善。




图3 不同方法去噪结果的 PSNR 以及 SSIM 值对比

Fig.3 Comparison of PSNR and SSIM values of different methods

为了更直观地进行对比,表 1 列出了所有波段下不同方法去噪结果的 MPSNR 值以及 MSSIM 值。

表1 不同方法去噪结果的 MPSNR 值和 MSSIM 值

Table 1 MPSNR and MSSIM values of different methods

	noisy	VBM3D	LRMR	LLRSSTV	NLSJLRR
MPSNR/dB	15.53	28.84	31.55	32.56	33.09
MSSIM	0.23	0.80	0.84	0.89	0.90

4.2 真实数据实验

本文的真实数据实验选取 EO-1 Hyperion 图像作为数据集,该数据集大小为 $400 \times 1000 \times 242$,选取 $200 \times 200 \times 166$ 的子数据集,该数据集中很多波段存在死线以及条纹噪声。图 4 给出了第 165 波段的图像。





图4 真实数据集 EO-1 Hyperion 第 165 波段示意图

Fig.4 Schematic diagram at 165th band of real dataset EO-1 Hyperion

图 5 给出了不同方法在上述波段的去噪结果,可以看出 VBM3D 方法存在十分明显的过度擦除现象,图像恢复效果十分一般;LRMR 方法同样存在图像细节恢复效果不理想的问题,在去噪结果图中可以明显看出,该方法存在条带噪声去除不完全的问题;LLRSSTV 方法以及本文提出的 NLSJLRR 方法则十分成功地去除了图像中的混合噪声,并且十分完整地保留了图像细节。



(a) VBM3D (b) LRM (c) LLRSSTV (d) NLSJLRR

图5 真实数据集 EO-1 Hyperion 第 165 波段的去噪结果对比

Fig.5 Denoising results at 165th band of real dataset EO-1 Hyperion

为了进一步分析对比 LLRSSTV 方法与 NLSJLRR 方法的

去噪效果,图6给出了不同去噪方法在该数据集第165波段去噪效果的垂直平均灰度剖面图。从图中可以看出,LLRSSTV方法很好地保留了图像的局部光滑信息,而这正体现了引入




图6 真实数据集EO-1 Hyperion第165波段的垂直平均剖面

Fig. 6 Vertical mean profiles of 165th band in real dataset EO-1 Hyperion

4.3 参数分析

模拟数据实验中,VBM3D方法以及LRMR方法中涉及的参数分别根据对应的参考文献选取,而LRR方法与本文提出的NLSJLRR方法主要涉及如下参数:

1)式(3)所示的LRR模型中的正则化参数,该参数的选取参见文献[17]。

2)进行低秩表示的样本个数,本文中对应的是输入数据矩阵的行数,记为 m 。在LRR方法中, m 即为取块窗口大小的平方;而在NLSJLRR方法中, $m=(q+1) \times M^2$ 。为了方便分析,图7给出了以3.1节选取的字典,不进行相似块联合的操作而直接代入LRR模型进行求解时,不同 m 对MPSNR的影响。




图7 低秩表示样本数对MPSNR值的影响情况

Fig. 7 Influence on MPSNR value of number of low-rank representation sample

从图7可以看出,当进行LRR的样本数为255时,去噪效果达到最佳,据此,实验中NLSJLRR方法的取块窗口大小 M 设置为11,相似块联合的个数 q 设置为1。

3)NLSJLRR方法中,聚类的个数为 K 。图8给出了MPSNR值随着 K 值的变化情况。




图8 聚类个数对MPSNR值的影响

Fig. 8 Influence on MPSNR values of clustering number

实际上,选取进行模拟实验的数据集中共有17种不同的地物类别,而从图中可以看出,当类别数大于或等于真实地物类别数目时,MPSNR值的变化逐渐趋于稳定,但类别数目过

多可能会导致某一类别只含有一个图像块,从而无法进行联合。依据图8,实验中选取 $K=31$ 。

4.4 收敛性分析

针对所提方法的收敛性,本文采取实验的方式进行分析。图9给出了在模拟Indians Pines数据集上的实验过程中,MPSNR值以及MSSIM值随着对图像块进行低秩表示的迭代次数的变化情况。




图9 MPSNR和MSSIM随迭代次数的变化

Fig. 9 MPSNR and MSSIM values versus the number of iterations

可以看出,随着迭代次数的增加,MPSNR以及MSSIM数值的提升十分明显,并且当迭代次数超过120后,该数值变化趋于稳定,表明了本文所提方法具有良好的收敛性。

结束语 本文提出了一种基于非局部相似联合低秩表示的高光谱图像去噪方法(NLSJLRR)。该方法主要分为两部分,首先综合考虑了高光谱图像中存在的噪声类型,以获取具备更全面噪声判别能力的字典;然后采用分块处理的方式,并联合非局部相似块,既保留了图像的局部相似信息,又引入了普遍存在的非局部相似信息。更进一步地,该方法采用低秩表示框架,满足了高光谱图像的光谱空间特性,提升了去噪效果。实验结果表明,无论是在目视效果还是定量评价指标上,该方法对图像质量的提升效果都十分明显,这对于受到噪声污染的高光谱图像的后续利用具有重要的现实意义。与此同时,通过与LLRSSTV方法的对比实验可以发现,改进的TV项在HSI的去噪领域有其特殊优势,如何将更符合HSI光谱空间的LRR模型以及TV项相结合,以进一步提升去噪效果,将是未来的研究重点。

参考文献

- [1] LV F, HAN M, QIU T. Remote sensing image classification based on ensemble extreme learning machine with stacked autoencoder[J]. IEEE Access, 2017, 5: 9021-9031.
- [2] LIU H C, LI S T, FANG L Y. Robust object tracking based on

- principal component analysis and local sparse resenatation[J]. *IEEE Transactions on Instrumentaiton & Measurement*, 2015, 64(11):2863-2875.
- [3] BO C, LU H C, WANG D. Weighted generalized nearest neighbor for hyperspectral image classification [J]. *IEEE Access*, 2017, 5: 1496-1509.
- [4] YANG W, HOU K, LIU B, et al. Two-stage clustering technique based on the neighboring union histogram for hyperspectral remote sensing images [J]. *IEEE Access*, 2017, 5: 5640-5647.
- [5] WEN Y W, MICHAEL K, HUANG Y M. Efficient total variation minimization methods for color image restoration [J]. *IEEE Transactions on Image Processing*, 2008, 17(11):2081-2088.
- [6] 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.
- [7] KOPSINIS Y, MCLAUGHLIN S. Development of EMD-based denoising methods inspired by wavelet thresholding [J]. *IEEE Transactions on Signal Processing*, 2009, 57(4):1351-1362.
- [8] ZHANG H Y. Hyperspectral image denoising with cubic total variation model [J]. *ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences*, 2012, 1(7):95-98.
- [9] YUAN Q Q, ZHANG L P, SHEN H F. Hyperspectral image denoising employing a spectral-spatial adaptive total variation model [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2012, 50(10):3660-3677.
- [10] DABOV K, FOI A, EGIAZARIAN K. Video denoising by sparse 3D transform-domain collaborative filtering [C] // 15th European Signal Processing Conference. Poznan, Poland, 2007:145-149.
- [11] LIN T, BOURENNANE S. Survey of hyperspectral image denoising methods based on tensor decompositions [J]. *Eurasip Journal on Advances in Sibnal Processing*, 2013, 2013(1):1-11.
- [12] ZHAO Y Q, YANG J X. Hyperspectral image denoising via sparse representation and low-rank constraint [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 53(1):296-308.
- [13] CHANG Y, YAN L, ZHONG S. Hyperspectral image denoising via spectral and spatial low-rank approximation [C] // IEEE International Geoscience and Remote Sensing Symposium, Fort Worth, USA; IEEE, 2017:4193-4195.
- [14] HE W, ZAHNG H Y, SHEN H F, et al. Hyperspectral image denoising using local low-rank matrix recovery and global spacial-spectral total variation [J]. *IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing*, 2018, 11(3):713-729.
- [15] CANDES E J, LI X D, MA Y, et al. Robust principal component analysis? [J]. *Journal of the ACM*, 2011, 58(3):1-37.
- [16] ZHANG H, HE W, ZHANG L P, et al. Hyperspectral image restoration using low-rank matrix recovery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2014, 52(8):4729-4743.
- [17] LIU G C, LIN Z C, YAN S C, et al. Robust recovery of subspace structures by low-rank representation [J]. *IEEE Transactions on Pattern Analysis and Machine Inteligence*, 2013, 35(1):171-184.
- [18] WANG M D, YU J, XUE J H, et al. Denoising of hyperspectral images using group low-rank representation [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, 9(9):4420-4427.
- [19] ZHOU T Y, TAO D C. GoDec: Randomized low-rank & sparse matrix decomposition in noisy case [C] // Proceedings of the 28th International Conference on Machine Learning. WA, USA, 2011:33-40.
- [20] HUANG Z H, LI S T, FANG L Y, et al. Hyperspectral image denoising with group sparse and low-rank tensor decomposition [J]. *IEEE Access*, 2017, 6:1380-1390.
- [21] WANG Z, BOVIK A C, SHEIKH H R, et al. Image quality assessment: From error visibility to structural similarity [J]. *IEEE Transactions on Image Processing*, 2004, 13(4):600-612.



ZHANG Xian, born in 1994, postgraduate. His main research interests include pattern recognition, remote sensing image processing, and machine learning.



YE Jun, born in 1981, Ph.D, associate Professor. His main interestes include pattern recognition, machine learning, and image processing.