

文章编号: 1674-8085(2016)01-0069-06

# 分块噪声自适应高光谱图像去噪算法研究

孔祥阳<sup>1,2</sup>

(1. 四川工程职业技术学院基础教学部, 四川, 德阳 618000; 2. 西北工业大学自动化学院, 陕西, 西安 710072)

**摘要:** 高光谱图像在获取过程中容易产生噪音, 从而影响了地物空间信息的识别。噪声去除是高光谱图像处理十分必要的步骤。结合低秩矩阵分解理论, 在传统奇异值阈值方法的基础上提出基于分块的噪声自适应遥感去噪方法。实验结果证明, 该方法运算速度快, 并能够有效去除缺失值造成的死线噪声以及高斯噪声, 在平均峰值信噪比 (MPSNR) 和平均结构相似性 (MSSIM) 上优于 Godec 算法。

**关键词:** 高光谱图像; 低秩矩阵; 奇异值分解; 去噪

中图分类号: TP751

文献标识码: A

DOI:10.3969/j.issn.1674-8085.2016.01.014

## RESEARCH ON THE ALGORITHM OF NOISE-ADAPTIVE HYPER SPECTRAL IMAGE DENOISING BASED ON BLOCK

KONG Xiang-yang<sup>1,2</sup>

(1. Ministry of Basic Education, Sichuan Engineering Technical College, Deyang, Sichuan 618000, China;

2. School of Automation, Northwestern Polytechnical University, Shanxi, Xi'an 710072, China)

**Abstract:** Hyperspectral images carry abundant spectral information and the spatial information which can be used to identify the objects on the land, so they have a great use in many areas. However, the hyperspectral images are often affected by the noise in the obtaining process, which is not conducive to the subsequent application. Therefore, noise removal is a very necessary step in the processing of hyperspectral image. The clean hyperspectral image data matrix is low rank. Combining with low rank matrix decomposition theory, based on the traditional singular value threshold method, a method of adaptive noise reduction based on block is proposed. Experimental results show that the computing speed of this method is fast, and can effectively remove missing values caused by the deadline noise and Gaussian noise, the results which are compared with Godec algorithm in average peak signal to noise ratio (MPSNR) and mean structure similarity (MSSIM) are better.

**Key words:** hyperspectral image; low rank matrix; singular value decomposition; denoising

## 0 引言

由于高光谱图像所携带的丰富的光谱信息, 以及能够用来识别地物的空间信息, 所以在许多领域中都有很大的用途。比如城市规划, 测绘, 农业, 林业, 及监测<sup>[1-4]</sup>。然而, 通过多路探测器得到的高光谱图像 (HSI) 往往受到不同类型噪声的污染,

从而使图像质量严重退化, 而这将限制图像后续处理的精度, 其中包括—分类<sup>[5-7]</sup>, 分割<sup>[8]</sup>, 解混合<sup>[9-10]</sup>和目标检测<sup>[11]-[13]</sup>。因此, 降低高光谱图像的噪声并最大限度地保持图像细节信息显得十分重要。

无论是对普通图像的去噪研究还是对高光谱图像的去噪研究已有很多<sup>[14]-[18]</sup>。然而, 不管是结合 NAPCA 和复小波变换<sup>[14]</sup>, 还是基于 RTF<sup>[15]</sup>的方法, 以及基于主成分分析<sup>[16]</sup>的方法, 虽然它们的去

收稿日期: 2015-07-04; 修改日期: 2015-12-28

作者简介: 孔祥阳(1985-), 男, 四川德阳人, 讲师, 博士生, 主要从事图像处理及图论研究(E-mail:kongxy@scetc.edu.cn).

噪效果较好,但是它们对高光谱图像所受噪声的影响只假设为高斯噪声。但是,实际中图像退化通常是受多种噪声的影响,因此,只研究一种噪声的影响不够全面。目前所知的高光谱图像混合噪声去除的文献是[19]。因此,本文主要与文献[19]的结果进行对比。

本文在传统奇异值阈值方法的基础上提出基于分块的噪声自适应遥感去噪方法。实验结果证明,该方法能够有效去除缺失值造成的死线噪声以及高斯噪声。

为了下面讨论的方便,我们首先一些符号的定义。

设矩阵  $X = (x_{ij})_{n_1 \times n_2} \in R^{n_1 \times n_2}$ , 则  $X$  的 Frobenius 范数以及核范数的定义为:

$$\|X\|_F = \left( \sum_{i=1}^{n_1} \sum_{j=1}^{n_2} |x_{ij}|^2 \right)^{\frac{1}{2}}, \|X\|_* = \sum_i |\sigma_i(X)|.$$

其中  $\sigma_i(X)$  表示  $X$  的第  $i$  个奇异值。

## 1 低秩矩阵恢复 (LRMR) 模型

LRMR模型首先是由Wright等人提出的。假设低秩数据矩阵  $X \in R^{m \times n}$  受任意幅度的稀疏噪声  $N \in R^{m \times n}$  的破坏,则观测到的数据矩阵  $Y \in R^{m \times n}$  可以分解为低秩矩阵  $X$  和稀疏矩阵  $N$  之和,即  $Y = X + N$ , 这也可以看作鲁棒主成分分析问题。Candes已经证明,当  $L$  的秩和稀疏度以及  $S$  的分布满足一定条件时,可以极大可能地恢复出低秩矩阵  $L$  和稀疏矩阵  $S$ 。即核范数最小化逼近问题。其优化模型如下:

$$\min_X \text{rank}(X) \quad \text{s.t.} \quad \Phi(X) = Y \quad (1)$$

其中  $\Phi(\bullet)$  表示线性算子。

然而,上述优化问题是NP问题的,所以将其转化为下列可解的凸优化问题:

$$\min_X \|X\|_* \quad \text{s.t.} \quad \Phi(X) = Y \quad (2)$$

一方面,Candes和Recht<sup>[20]</sup>证实大多数低秩矩阵可以通过求解一个核范数最小化问题完全恢复;另一方面,Cai et al.<sup>[21]</sup>证明带有数据保真度项的基于核范数最小化的低秩矩阵范数逼近问题可以很容易地通过对观测矩阵的奇异值进行软阈值操作来解决。因此如上所述,如果  $Y = \Phi(X) = X + N$ , 则

优化问题(2)可以转化为

$$\hat{X} = \arg \min_X \|Y - X\|_F^2 + \lambda \|X\|_* \quad (\lambda > 0) \quad (3)$$

进行求解。并且其解为  $\hat{X} = U S_\lambda(\Sigma) V^T$ , 其中  $Y = U \Sigma V^T$  是  $Y$  的奇异值分解 (SVD),  $S_\lambda(\Sigma)$  是带有参数  $\lambda$  的秩为  $r$  的对角矩阵  $\Sigma = \text{diag}(\Sigma_1, \Sigma_2, \dots, \Sigma_r)$  的软阈值函数,  $U$  和  $V$  分别称为左、右奇异矩阵。对  $\Sigma$  里的任一对角元素  $\Sigma_{ii}$ , 有

$$S_\lambda(\Sigma)_{ii} = \max(\Sigma_{ii} - \lambda, 0) \quad (4)$$

## 2 基于低秩恢复的高光谱图像去噪

### 2.1 高光谱图像的低秩性分析

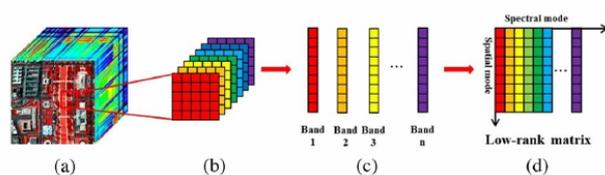


图1 高光谱图像数据的低秩矩阵表示<sup>[19]</sup>

Fig.1 Low rank matrix representation for hyperspectral image data

高光谱图像的低秩性可以从线性光谱混合模型的角度解释。由于光谱特征之间存在很高的相关性,因此每个光谱特征可以用少量的纯光谱端元的线性组合来表示,即线性光谱混合模型。将高光谱图像数据的每一波段展开成一个向量,那么所有波段放在一起就构成一个矩阵  $X$ 。如果高光谱图像的纯光谱端元最多有  $R$  个,则  $X$  可以分解为  $X = MP^T$ , 其中  $M$  是丰度矩阵,矩阵  $P$  的列由光谱端元构成。作为端元数量的上界  $R$  通常比较小,即  $X$  的秩是有界的,即  $\text{rank}(X) \leq R$ , 从而说明矩阵  $X$  是低秩的。

### 2.2 基于核范数最小化的分块自适应遥感图像去噪

假设观测到的高光谱图像数据  $Y$  受到高斯噪声、坏像素或直线等混合噪声污染。高光谱图像的退化模型可以写为

$$Y = X + N \quad (5)$$

其中  $Y$  是观测到的含噪高光谱图像,  $X$  是无噪的高光谱图像,  $N$  是死线噪声和高斯噪声,且  $Y, X, N \in R^{m \times n \times b}$ 。

将  $Y, X$  和  $N$  的每一波段按列展开以后排在一起构成矩阵分别为  $\bar{Y}, \bar{X}, \bar{N}$ , 从而上述模型改写为

$\bar{Y} = \bar{X} + \bar{N}$ 。由此得本文的优化模型为:

$$\hat{X} = \arg \min_x \|\bar{Y} - \bar{X}\|_F^2 + \|\bar{X}\|^w \quad (6)$$

其中 $\|\bar{X}\|^w$ 表示对图像进行分块去噪。

基于分块的去噪算法是将图像分成一个一个小块进行去噪,并且由于每个图像块的噪声水平不一样,所以去噪的阈值选取也有所不同。在去噪过程中,由于噪声主要对应较小的奇异值。因此,奇异值越大,在奇异值收缩时缩小的应该越少。因此,对于 $\bar{Y}$ 的一个图像块 $\bar{Y}_j$ 的估计 $\bar{X}_j$ 的第*i*个奇异值 $\sigma_i(\bar{X}_j)$ 的权重应该与 $\sigma_i(\bar{X}_j)$ 成反比。这里根据交叉验证可以令

$$\omega_i = \frac{c(\sigma'_i)}{\sigma_i(\bar{X}_j) + \varepsilon} \quad (7)$$

其中 $c(\sigma'_i) > 0$ 是一个与 $\bar{X}_j$ 的最大的奇异值 $\sigma'_j$ 有关的常数,取 $\varepsilon = 10^{-16}$ 以避免分母为0。然而,奇异值 $\sigma_i(\bar{X}_j)$ 不可用。所以假设的噪声能量均匀地分布在由左右奇异矩阵张成的每个子空间,并且奇异值 $\sigma_i(\bar{X}_j)$ 可以估计为:

$$\hat{\sigma}_i(\bar{X}_j) = \sqrt{\max(\sigma_i^2(\bar{Y}_j) - n\sigma_n^2, 0)} \quad (8)$$

其中 $\sigma_i(\bar{Y}_j)$ 是 $Y_j$ 的第*i*个奇异值。从而得到 $\bar{Y}_j$ 的估计 $\hat{X}_j = \arg \min_{X_j} \frac{1}{\sigma_n^2} \|\bar{Y}_j - \bar{X}_j\|_F^2 + \|\bar{X}_j\|^w$ 。注意到既然 $\hat{\sigma}_i(\bar{X}_j)$ 通常是按非升序排列的,权重是按非降序排列。通过在每个块上应用上面的程序,最后联合所有的块就得到重构的图像X。

### 3 实验结果比较与分析

#### 3.1 评价指标

峰值信噪比(PSNR)指数是用来对模拟实验从灰度相似性方面结果的定量评估<sup>[22]</sup>。最近,一些图像质量评价指标,基于人类视觉系统已被提出,如结构相似度(SSIM)指标<sup>[23]</sup>。对于高光谱图像,我们计算每一个清晰带噪声的频段之间的PSNR和SSIM值,然后取平均数得到平均PSNR(MPSNR)和平均SSIM(MSSIM)。这些评价指标的定义如下:

$$PSNR = 10 \log_{10} \left( \frac{MN}{\|\hat{u} - u\|^2} \right) \quad (9)$$

$$SSIM = \frac{(2\mu_u \mu_{\hat{u}} + C_1)(2\sigma_{u\hat{u}} + C_2)}{(\mu_u^2 + \mu_{\hat{u}}^2 + C_1)(\sigma_u^2 + \sigma_{\hat{u}}^2 + C_2)} \quad (10)$$

$$MPSNR = \frac{1}{B} \sum_{i=1}^B PSNR_i \quad (11)$$

$$MSSIM = \frac{1}{B} \sum_{i=1}^B SSIM_i \quad (12)$$

在高光谱图像的一个波段中, $MN$ 是一个波段的总像素数, $B$ 是高光谱图像的波段数。 $u$ 和 $\hat{u}$ 代表原清晰图像与去噪后的图像, $\mu_u$ 和 $\mu_{\hat{u}}$ 分别代表原来的清晰图像和去噪后的图像平均灰度值。 $\sigma_u$ 和 $\sigma_{\hat{u}}$ 分别代表原始清晰图像和去噪后的图像的方差。 $\sigma_{u\hat{u}}$ 代表原始图像清晰与去噪后的图像之间的协方差。 $C_1$ 和 $C_2$ 是常数,防止不稳定的结果。

#### 3.2 结果对比与分析

目前已知的可以去除混合噪声的算法是文[19]中提出的Godec算法,所以这里提出的方法与Godec方法进行对比。

模拟实验采用由高光谱遥感数字图像采集实验(HYDICE)收集的三个数据集。整个数据包含191个波段1208×307像素的图像。由于有些波段受污染太严重,所以选取一个大小为256×256×68的数据用于我们的实验。

去噪的视觉效果如下图2-图4表所示。从图中不难看出,两种算法对高斯噪声和死线噪声的去噪效果都较好,而本文提出的方法在图像细节和边缘的保持上更好。

去噪的性能比较如下表1-表3所示,其中表中的MPSNR\_N、MPSNR\_G和MPSNR\_C分别表示含噪图像、Godec算法去噪图像以及本文算法得到的PSNR值,单位为分贝(db),MSSIM\_N、MSSIM\_G和MSSIM\_C分别表示含噪图像、Godec算法去噪图像以及本文算法得到的MSSIM指数值。从比较不难发现,在高光谱数据1和2的PSNR值上,本文算法平均比Godec算法高出约7db,在数据3上高出约2db,而在数据1和2的结构相似性指数上,当噪声方差较小时本文算法优于Godec算法,而在噪声方差较大时,与Godec算法相比略有下降,但是从视觉效果上看,两者去噪结果差别不大。



图2 高光谱数据1噪声方差为10时去噪效果对比

Fig.2 Comparison of the denoising effect of hyperspectral data 1 when noise variance is 10

表1 高光谱数据1去噪结果对比

Table 1 Comparison of the denoising results of hyperspectral data 1

MPSNR(db)与 MSSIM	噪声方差	Sigma=5	Sigma=10	Sigma=15	Sigma=20	Sigma=25
	MPSNR_N		23.3624	22.1339	20.2163	18.0845
MPSNR_G		30.7899	28.7557	29.5566	25.5467	27.3688
MPSNR_C		35.3509	32.0386	29.6633	27.1197	24.9370
MSSIM_N		0.8856	0.7648	0.6288	0.5051	0.4011
MSSIM_G		0.9644	0.9279	0.9253	0.8519	0.8585
MSSIM_C		0.9747	0.9374	0.9040	0.8458	0.7818



图3 高光谱数据2噪声方差为10时去噪效果对比

Fig.3 Comparison of the denoising effect of hyperspectral data 2 when noise variance is 10

表2 高光谱数据2去噪结果对比

Table 2 Comparison of the denoising results of hyperspectral data 2

MPSNR(db)与 MSSIM	噪声方差	Sigma=5	Sigma=10	Sigma=15	Sigma=20	Sigma=25
	MPSNR_N		22.7781	21.6864	19.9233	17.9028
MPSNR_G		19.7836	22.1251	20.7930	23.2832	22.6989
MPSNR_C		34.6319	31.4785	28.9512	26.2908	24.0191
MSSIM_N		0.8975	0.7905	0.6662	0.5510	0.4513
MSSIM_G		0.8970	0.9095	0.8795	0.8876	0.8547
MSSIM_C		0.9779	0.9442	0.9085	0.8486	0.7822



图4 高光谱数据3噪声方差为10时去噪效果对比

Fig.4 Comparison of the denoising effect of hyperspectral data 3 when noise variance is 10

表3 高光谱数据3去噪结果对比

Table 3 Comparison of the denoising results of hyperspectral data 3

MPSNR(db)与 MSSIM	噪声方差	Sigma=5	Sigma=10	Sigma=15	Sigma=20	Sigma=25
	MPSNR_N		21.0267	20.2759	18.9514	17.2796
MPSNR_G		28.4748	26.5922	26.6739	25.4145	15.4127
MPSNR_C		34.5514	31.2994	28.9309	26.5186	24.4325
MSSIM_N		0.8547	0.7380	0.6034	0.4825	0.3833
MSSIM_G		0.9354	0.8773	0.8615	0.8077	0.4661
MSSIM_C		0.9672	0.9267	0.8884	0.8263	0.7580

## 4 结论

本文在低秩矩阵恢复理论的基础上结合光谱数据的低秩特性提出了一种基于分块的奇异值收缩的高光谱图像去噪方法。其主要优点为：(1) 算法理论简单，运算速度快；(2)能够去除混合噪声的影响；(3)无论在平均峰值信噪比还是在平均结构相似性等评价指标上，以及视觉效果上，去噪效果优于Godec去噪方法，在光谱分析中具有广阔的应用前景。

### 参考文献：

[1] Zhong P, Wang R. Multiple-spectral-band CRFs for denoising junk bands of hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 51(4): 2260-2275.

[2] Qian Y, Ye M. Hyperspectral imagery restoration using nonlocal spectral-spatial structured sparse representation with noise estimation[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2013, 6(2): 499-515.

[3] 岳学军,全东平,洪添胜,等. 不同生长期柑橘叶片磷含量

的高光谱预测模型[J]. 农业工程学报, 2015(8):207-213.

[4] 马维维,巩彩兰,胡勇,等. 牧草品质的高光谱遥感监测模型研究[J]. 光谱学与光谱分析,2015(10):2851-2855.

[5] Li J, Zhang H, Huang Y, et al. Hyperspectral image classification by nonlocal joint collaborative representation with a locally adaptive dictionary[J]. IEEE Transactions on Geoscience and Remote Sensing,2014, 52(6): 3707-3719.

[6] Plaza A, Martinez P, Plaza J, et al. Dimensionality reduction and classification of hyperspectral image data using sequences of extended morphological transformations[J]. IEEE Transactions on Geoscience and Remote Sensing,2005, 43(3): 466-479.

[7] Zhang H, Li J, Huang Y, et al. A nonlocal weighted joint sparse representation classification method for hyperspectral imagery[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(6): 2056-2065.

[8] Li J, Bioucas-Dias J M, Plaza A. Semisupervised hyperspectral image segmentation using multinomial logistic regression with active learning[J]. IEEE Transactions on Geoscience and Remote Sensing, 2010,

- 48(11): 4085-4098.
- [9] Bioucas-Dias J M, Plaza A, Dobigeon N, et al. Hyperspectral unmixing overview: Geometrical, statistical, and sparse regression-based approaches[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2012, 5(2): 354-379.
- [10] Iordache M D, Bioucas-Dias J M, Plaza A. Sparse unmixing of hyperspectral data[J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(6): 2014-2039.
- [11] Stein D W J, Beaven S G, Hoff L E, et al. Anomaly detection from hyperspectral imagery[J]. Signal Processing Magazine, IEEE, 2002, 19(1): 58-69.
- [12] Zhang L, Zhang L, Tao D, et al. Sparse transfer manifold embedding for hyperspectral target detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(2): 1030-1043.
- [13] Buades A, Coll B, Morel J M. A non-local algorithm for image denoising[C]. IEEE Computer Society Conference on Computer Vision and Pattern Recognition. IEEE, 2005, 2: 60-65.
- [14] 徐冬,孙蕾,罗建书. 结合NAPCA和复小波变换的高光谱遥感图像去噪[J]. 红外与激光工程, 2015(1):327-334.
- [15] 阳雄耀,钟平,王润生. 基于RTF的高光谱图像去噪方法[J]. 现代电子技术,2015(21):1-5,10.
- [16] 印佳,杜战战. 基于主成分分析的高光谱遥感图像非局部去噪[J]. 现代电子技术, 2015(11):70-72.
- [17] Acito N, Diani M, Corsini G. Subspace-based striping noise reduction in hyperspectral images[J]. IEEE Transactions on Geoscience and Remote Sensing,2011, 49(4): 1325-1342.
- [18] Rasti B, Sveinsson J R, Ulfarsson M O, et al. Hyperspectral image denoising using first order spectral roughness penalty in wavelet domain[J]. Selected Topics in Applied Earth Observations and Remote Sensing, IEEE Journal of, 2014, 7(6): 2458-2467.
- [19] Zhang H, He W, Zhang L, et al. Hyperspectral image restoration using low-rank matrix recovery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(8): 4729-4743.
- [20] Candès E J, Recht B. Exact matrix completion via convex optimization[J]. Foundations of Computational mathematics, 2009, 9(6): 717-772.
- [21] Cai J F, Candès E J, Shen Z. A singular value thresholding algorithm for matrix completion[J]. SIAM Journal on Optimization, 2010, 20(4): 1956-1982.
- [22] 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.
- [23] Wang Z, Bovik A C. Mean squared error: love it or leave it? A new look at signal fidelity measures[J]. Signal Processing Magazine, IEEE, 2009, 26(1): 98-117.

(上接第 68 页)

- [4] 史少锋,刘宴兵. 基于动态规划的云计算任务调度研究[J]. 重庆邮电大学学报:自然科学版,2012,24(6): 687-692.
- [5] 李建锋,彭舰. 云计算环境下基于改进遗传算法的任务调度算法[J]. 计算机应用, 2011, 31(1): 184-187.
- [6] 封良良,张陶,贾振红,等. 云计算环境下基于改进粒子群的任务调度算法[J]. 计算机工程, 2013, 39(5): 183-188.
- [7] 叶菁,陈国龙,阮一文. 异构环境下相关任务调度免疫遗传算法的研究[J]. 小型微型计算机系统, 2011, 32(10): 2124-2129.
- [8] 董丽丽,黄贲,介军. 云计算中基于差分进化算法的任务调度研究[J]. 计算机工程与应用,2014,50(5): 90-95.
- [9] 孙凌宇,冷明,朱平等. 云计算环境下基于禁忌搜索的负载均衡任务调度优化算法[J]. 小型微型计算机系统, 2015, 36 (9): 1948-1952.