

## 结合 NAPCA 和复小波变换的高光谱遥感图像去噪

徐冬, 孙蕾, 罗建书

(国防科学技术大学理学院, 湖南长沙 410073)

**摘要:** 提出了一种能够良好地保持高光谱遥感图像细节特征的噪声去除方法。该方法首先利用噪声调整的主成分分析(NAPCA)进行特征提取,再利用复小波变换(CWT)对 NAPCA 变换后的低能量成分进行去噪处理。对此低能量成分的每个波段利用二维复小波去噪,此时复小波系数采用 BivaShrink 函数进行收缩。然后对低能量成分的每条光谱进行一维复小波变换,利用邻域阈值函数进行小波系数的收缩。对 AVIRIS 图像贾斯珀桥、月亮湖和盆地进行的仿真实验表明:该方法去噪后的信噪比与 HSSNR 相比提高了 4.3~7.8 dB,与 PCABS 相比提高了 0.8~0.9 dB,验证了该算法的可行性。真实数据 OMIS 图像的实验结果验证了该方法的有效性和适用性。

**关键词:** 高光谱遥感图像; 去噪; 噪声调整的主成分分析; 复小波变换; BivaShrink 函数

**中图分类号:** TP391 **文献标志码:** A **文章编号:** 1007-2276(2015)01-0327-08

## Denoising of hyperspectral remote sensing imagery using NAPCA and complex wavelet transform

Xu Dong, Sun Lei, Luo Jianshu

(College of Sciences, National University of Defense and Technology, Changsha 410073, China)

**Abstract:** A new denoising algorithm was proposed to keep the fine features of hyperspectral remote sensing imagery effectively. Firstly, the noise-adjust principal components analysis (NAPCA) was performed on the hyperspectral datacube. Then output channels of the low-energy NAPCA were transformed into the wavelet domain by 2-D complex wavelet transform(CWT). The BivaShrink function was used to shrink the wavelet coefficients. And then 1-D CWT denoising method was used to remove the noise of the each spectrum of the low-energy NAPCA datacube. The AVIRIS images Jasper Ridge, Lunar Lake and Low Altitude were used for the simulated experiment. Compared with the HSSNR and the PCABS, the signal-to-noise ratio (SNR) is improved by 4.3-7.8 dB and 0.8-0.9 dB via the proposed method in this paper, which shows that the proposed method is feasible. It is shown that the proposed method is correctable and available according to the experimental results of the real datacube OMIS.

**Key words:** hyperspectral imagery; denoising; NAPCA; complex wavelet transform; BivaShrink function

收稿日期:2014-05-07; 修订日期:2014-06-10

基金项目:国家自然科学基金(61101183, 41201363)

作者简介:徐冬(1988-),男,硕士生,主要从事高光谱遥感图像噪声处理方面的研究。Email:xu\_don@163.com

导师简介:罗建书(1956-),男,教授,博士生导师,博士,主要从事小波分析与数据压缩、电磁拓扑与积分方程数值分析方面的研究。  
Email:ljsh3115@sina.com

## 0 引言

高光谱遥感图像可以看成是一维光谱信息和二维空间信息组成的三维数据块。随着高光谱遥感图像技术的迅速发展,高光谱遥感图像能够更全面、更准确地描述地物特征,广泛应用于许多领域,如农业、工业、地质勘探、环境监测、军事侦查等。太阳光照射地面,经过反射穿过大气到达传感器,太阳光在大气中发生散射,高光谱图像的电磁波散射传播途径受到一些复杂因素的影响,会引入大量的噪声,对图像分析带来很多不利影响,因此研究高光谱遥感图像的噪声去除方法非常必要<sup>[1]</sup>。目前,高光谱图像去噪算法主要分为三类:在频谱域的噪声去除,如 Green 等提出的最大噪声分数 (MNF)<sup>[2]</sup>,MNF 是高光谱图像常用的去噪方法,利用信噪比作为指标,得到理论上比较完备的成分分解方法。但该方法的主要缺点是去噪的同时对光谱的峰(比较尖的地方)影响较大,容易破坏光谱曲线特性;在空间域的噪声去除,如 Donoho 和 Johnstone 提出的小波系数收缩方法<sup>[3]</sup>,按波段进行噪声去除时,容易产生“过扼杀”现象,破坏图像细节特征;以及频谱域和空间域结合的噪声去除方法。在这三类方法中,频谱域和空间域去噪结合的方法去噪效果更好。Arkinson 等人提出了一种在空间域利用小波变换和在频谱域利用傅里叶变换的去噪方法<sup>[4]</sup>。Othman 和 Qian 提出了在导数域内空间-谱间混合 (HSSNR)的小波系数收缩的去噪方法<sup>[5]</sup>。但从本质上,并没有改变空间域和频谱域分别去噪,这种方式容易破坏图像的细节光谱曲线特性。为了克服去噪方法在去噪过程中损害图像的细节特征的缺点,常威威等人提出基于 Contourlet 变换和主成分分析 (PCA) 的高光谱遥感图像去噪方法<sup>[6]</sup>,充分利用 Contourlet 变换良好的稀疏特性和 PCA 在高维数据处理中的高效性,取得了较好的去噪结果。吴一全和吴超提出结合具有平移不变性及一定冗余性的非下采样 Contourlet 变换(NSCT)和具有非线性信号处理能力的核主成分分析(KPCA)<sup>[7]</sup>。李婷等人则将经典的二维图像全变差去噪模型推广到三维形式<sup>[8]</sup>,充分利用了原始数据空间域及频谱域的有效信息。依据双正则项及双调整参数构造目标函数,并采用

迭代方法对其进行优化和求解,使得空间域和频谱域的噪声可以同时很好地被去除。Chen 和 Qian 提出了利用 PCA 进行数据降维,保持能量高的主成分,对能量低的主成分进行空间域和频谱域相结合的三维降噪处理<sup>[9]</sup>。该方法简称为 PCABS。为了更好地提取图像特征,克服 PCA 变换主成分分散的问题,文中利用了 NAPCA 变换,该变换根据图像质量排列主成分<sup>[10]</sup>,即主成分按信噪比由大到小依次排列。

对于特征提取后的去噪处理,综合考虑内存消耗和计算时间,文中采用了复小波变换 (CWT)和 BivaShrink 函数。

## 1 噪声调整的主成分分析

PCA 变换是基于信息量的一种正交变换,该变换主要是采用线性投影的方法将数据投影到新的坐标空间,从而使新的成分按信息量分布,然而信息量大的主成分信噪比不一定高,当某个信息量大的主成分包含的噪声的方差大于信号的方差时,会导致主成分分量的图像质量很差,若去噪时作为保留波段将影响去噪结果。NAPCA 变换作为 PCA 变换的一种改进,特征的提取更有效,使得其变换后的主成分能充分保留图像信息,同时抑制噪声。NAPCA 变换基本原理是:首先进行噪声白化处理,使得噪声协方差矩阵为单位矩阵;再进行主成分分析。

这里假设  $X=(x_1, x_2, \dots, x_p)^T$  是  $p \times Q$  维矩阵,行向量组的均值向量  $E(X)=0$ ,协方差矩阵  $\Sigma=D(X)$ ,当均值不为 0 时,可以通过  $Y=X-E(X)$  将行向量组的均值向量变为 0,且  $D(Y)=D(X)=\Sigma$ 。假设  $X=S+N$ ,其中  $S$  和  $N$  指  $X$  中的信号和噪声,且  $S$  和  $N$  不相关,则有  $\Sigma=\Sigma_S+\Sigma_N$ ,  $\Sigma_S$  和  $\Sigma_N$  分别为  $S$  和  $N$  的协方差矩阵。在这里采用多元线性回归得到的残差图像对噪声协方差矩阵  $\Sigma_N$  进行估计。

NAPCA 实现过程主要包括七个步骤,第(3)~(6)步是噪声白化处理,也是 NAPCA 对 PCA 改进的地方,使得噪声协方差矩阵  $\Sigma_N$  变为单位矩阵,从而 NAPCA 具备了 PCA 所没有的两个优点,即不受数值变化影响和主成分按信噪比由大到小排列,对特征提取有更好的结果,有利于去噪过程中细节的保持和噪声的去除。七个步骤如下:

(1) 图像向量化:含有  $p$  个波段的高光谱遥感图像可表示为  $X=(x_1, x_2, \dots, x_p)^T$ , 其中  $x_i$  为一个  $Q$  元列向量, 这里  $Q=m \times n$ , 即将一幅  $m$  行  $n$  列大小的图像按列排列成一个  $Q$  元列向量。

(2) 向量中心化:将向量组中的所有向量减去向量组的均值向量, 即  $Y=X-E(X)$ 。

(3) 计算  $\Sigma_N$  的特征向量矩阵  $E$  和特征值对角矩阵  $\Lambda_N$ , 其中  $E^T \Sigma_N E = \Lambda_N$ ;

(4) 构造矩阵  $F=E\Lambda_N^{-1/2}$ , 从而  $F^T \Sigma_N F=I, F^T F=\Lambda_N^{-1}$ , 这里要求  $\Lambda_N$  存在逆矩阵, 即要求  $\Sigma_N$  非奇异, 正定;

(5) 噪声白化:利用矩阵  $F$  对总协方差矩阵  $\Sigma$  进行变换, 得到噪声调整后的总协方差矩阵  $\Sigma_{adj}$ , 即  $F^T \Sigma_N F = \Sigma_{adj}$ ;

(6) 计算协方差矩阵  $\Sigma_{adj}$  的特征向量矩阵  $G$ , 使得  $G^T \Sigma_{adj} G = \Lambda_{adj}$ , 且  $G^T G = I$ , 其中  $\Lambda_{adj}$  为特征向量矩阵  $G$  对应的特征值对角矩阵;

(7) 进行 NAPCA 变换,  $Z=A^T Y$ , 其中 NAPCA 变换矩阵  $A$  满足  $A=FG$ 。

## 2 复小波变换

因传统小波有良好的时频局部特性, 使得它具有非常有效的算法和稀疏表示, 已经成为信号处理领域强有力的工具, 但是, 仍存在一些缺陷, 如不具有平移不变性、方向能力表示弱、易产生混叠、不能提供相位信息等。因此传统小波在图像处理特别是图像降噪中, 重建图像在边缘处常常出现“振铃”等失真, 使得重建图像视觉效果较差, 阻碍其后续的应用。

通过考虑不具有小波这些问题的 Fourier 变换, 得到复数值的尺度函数和小波, 从而获得 CWT<sup>[11-12]</sup>。实质上, 复小波是传统小波的一种扩展。相对于传统小波, 复小波不仅保持了传统实离散小波变换良好的时频局部化的分析能力, 而且具有近似的平移不变性, 良好的方向分析能力, 有限的冗余度以及满足完全重构条件等优点。这就意味着复小波系数的幅值能够精确表示空间、尺度、方向上的某一特定位置的频谱能量。同时复小波变换也克服了混叠和振荡现象。因此复小波在图像处理中尤其在图像去噪方面取得了良好的效果。

复小波能够更好地应用于图像去噪的另一重要原因是复小波域内的尺度间和尺度内邻域系数的相

关性更强, 因此在复小波域用于基于系数统计模型的去噪算法比在实数小波域内更有效。因此文中选取复小波作为去噪的工具。

## 3 BivaShrink 函数

BivaShrink 函数是由 Sendur 和 Selesinck 提出来的。它是一种高效的和低复杂度的小波系数收缩方法, 充分利用了小波系数之间的统计依赖性<sup>[13]</sup>。

在小波域中, 定义  $y_1=\omega_1+n_1$  和  $y_2=\omega_2+n_2$ ,  $y_1$  和  $y_2$  是含噪信号系数,  $\omega_1$  和  $\omega_2$  是纯净信号系数,  $\omega_2$  是  $\omega_1$  的父小波系数,  $n_1$  和  $n_2$  是噪声系数。BivaShrink 函数公式如下:

$$\omega_1=y_1 \cdot \frac{\left(\sqrt{y_1^2+y_2^2}-\frac{\sqrt{\sigma_n^2}}{3}\right)}{\sqrt{y_1^2+y_2^2}} \quad (1)$$

式中:  $(x)_+=\max(x, 0)$ ; 噪声方差  $\sigma_n^2=\text{Median}(y_{li})/0.6745$ ;  $\{y_{li}\}$  是最高频小波系数。

$$\sigma_n^2=\sqrt{\left(\frac{1}{M} \sum_{x_i \in S} y_{li}^2-\sigma_n^2\right)_+} \quad (2)$$

式中:  $M$  是邻域  $S$  所包含像素点的数量。综合考虑计算量和精度要求, 邻域  $S$  的大小选取为  $7 \times 7$ 。

值得说明的是对于复小波系数, 实部和虚部分开来看并不是位移不变, 但是它们的幅值是位移不变的。因此 BivaShrink 函数应当用于复小波系数的幅值。

## 4 NAPCA 和 CWT 用于高光谱图像去噪

算法流程如图 1 所示。




图 1 文中去噪算法的流程图

Fig.1 Block diagram of proposed method in this paper

(1) 利用噪声调整的主成分分析进行高光谱图像数据(假定共有  $B$  个波段)降维, 得到含有大多数能量的少数波段(假定共有  $l$  个波段)和含有少部分能量的  $B-l$  个波段;

(2) 对含有少部分能量的  $B-l$  个波段进行二维空间去噪, 即按波段进行二维 CWT, 并利用 BivaShrink 函数对小波系数收缩, 再进行二维 CWT 逆变换;

(3) 对含有少部分能量的数据块的每条光谱进行一维 CWT 变换,并用邻域阈值方法进行小波系数收缩,再进行一维 CWT 逆变换;

(4) 利用保留的前  $l$  个波段和重新得到的  $B-l$  个波段重构高光谱图像数据,获得去噪图像。

第 3 步提到的邻域阈值方法<sup>[9]</sup>如下:

$$\hat{d}_{j,k} = d_{j,k} \left( 1 - \frac{\text{thr}^2}{S_{j,k}^2} \right) \quad (3)$$

式中: $\hat{d}_{j,k}$ 为第  $j$  个尺度的第  $k$  个小波系数  $d_{j,k}$  收缩后的值。 $S_{j,k}^2 = (|d_{j,k-1}|^2 + |d_{j,k}|^2 + |d_{j,k+1}|^2) / 3$ ,  $\text{thr} = \sqrt{2\sigma_n^2 \log n}$  是全局阈值, $n$  为所用邻域窗口尺寸大小,即在文中  $n=3$ 。同时噪声方差  $\sigma_n = \text{Median}(|d_{ik}|) / 0.6745$ ,  $\{d_{ik}\}$  是最高频小波系数。

保留前  $l$  个波段不被处理,仅对后面的  $B-l$  个波段去除噪声,这是由于经 PCA 和 NAPCA 变换后,前  $l$  个波段含有大多数能量,不进行去噪处理是为了使得图像细节特征得以保持,即防止图像细节特征被误认为噪声而去除,而后  $B-l$  个波段经过主成分提取后以噪声为主。文中将给出一种  $l$  的选取规则。这样处理不仅高效地去除了大量的噪声,而且防止一些细节特征在去噪过程中被误认为是噪声而去除。又因 NAPCA 是一种完全重构的变换,并不会引入误差,使得去噪结果得到保持。


参考文献中算法 PCABS 是通过肉眼观察主成分,判断噪声污染程度来选取  $l$ ,而在文中给出了一种规则量化选取  $l$ 。该规则是主成分分析过程中协方差矩阵的特征值  $\{\lambda_i\}_{i=1}^B$  按照由大到小排列,依次计算第  $k$  个特征值所占剩余特征值的比例  $T_k$ ,即  $T_k = \lambda_k / \sum_{i=1}^B \lambda_i (1 \leq k \leq B)$ ,当第  $k$  个特征值满足  $T_k \geq 0.2, T_{k+1} < 0.2$  时,此时  $l=k$ 。

文中提出的 NAPCA 得到的主成分不同于 PCA,因此文中算法中 NAPCA 的  $l$  选取规则也不同于 PCA,要分两步进行确定。NAPCA 变换中噪声调整后的总协方差矩阵的特征值  $\{\lambda_i^{\text{adj}}\}_{i=1}^B$  按照由大到小排列,首先依次计算第  $k$  个特征值所占剩余特征值的比例  $T_k^{\text{adj}}$ ,即  $T_k^{\text{adj}} = \lambda_k^{\text{adj}} / \sum_{i=k}^B \lambda_i^{\text{adj}} (1 \leq k \leq B)$ , $k_1$  取最后一个满足  $T_{k_1} \geq 0.7$  特征值的编号,若  $T_{k_1+1} < 0.4$  则停止, $l$  选取  $k_1-1$ ;否则从  $k_1+1$  开始同时计算  $t_j^1 = \lambda_j^{\text{adj}} /$

$\sum_{i=k_1+1}^B \lambda_i^{\text{adj}}$  和  $t_j^2 = \sum_{i=k_1+1}^j \lambda_i^{\text{adj}} / \sum_{i=k_1+1}^B \lambda_i^{\text{adj}} (k_1 < j < B)$ ,则有  $t_j^1$  是随着  $j$  增大而减小, $t_j^2$  随着  $j$  增大而增大,当计算第  $k_2$  步  $t_{k_1+k_2}^1 \geq 0.01, t_{k_1+k_2+1}^1 < 0.01$  或  $t_{k_1+k_2}^2 \geq 0.9$  时,停止计算, $l$  取  $k_1+k_2$ 。为了防止选取程序停止条件不满足时,使得  $l$  的选取过大,可以为  $l$  设定上限。这里的比例阈值 0.2、0.7、0.4、0.01、0.9 是根据经验获得的。

## 5 实验

仿真实验采用由 JPL, NASA 提供的 AVIRIS 图像 Jasper Ridge, Lunar Lake 和 Low Altitude。截取图像大小为  $256 \times 256 \times 224$  (行  $(M) \times$  列  $(N)$  波段  $(B)$ )。图 2 是纯净数据的第 80 波段图像。



(a) 贾斯珀桥  
(a) Jasper ridge

(b) 月亮湖  
(b) Lunar Lake



(c) 盆地  
(c) Low altitude

图 2 第 80 波段的图像  
Fig.2 Band #80 of image

衡量图像质量的一个重要参数是信噪比(SNR)。在文中,信噪比定义如下:

$$\text{SNR} = 10 \log_{10}(P_X / P_N) \quad (4)$$

式中: $P_X$  为纯净信号  $x_{ij}^k$  的能量; $P_N$  为含有噪声的信号  $\tilde{x}_{ij}^k$  中的噪声能量,即

$$SNR=10\log_{10}\left(\frac{\sum_{i=1,j=1,k=1}^{M,N,B} |x_{i,j}^k|^2}{\sum_{i=1,j=1,k=1}^{M,N,B} |x_{i,j}^k - \tilde{x}_{i,j}^k|^2}\right) \quad (5)$$

噪声模型是依据参考文献[5,9],利用高斯白噪声对图像进行加噪。不同于传统的对整个数据块采用固定方差的加性噪声模型,文中采用的噪声模型中噪声方差正比于每个波段的平均幅值,但每个波段噪声仍是加性噪声。文中算法分别与 HSSNR 和 PCABS 进行了比较。根据文中提出的波段选取规则,算法 PCABS 对贾斯珀桥、月亮湖和盆地的  $l$  选取分别为 3、1、3,而文中算法则是 10、2、9。

表 1 列出了实验结果,通过对比分析,三种方法都有效地提高了高光谱图像的信噪比,但文中算法得到的结果更好。与 HSSNR 相比,PCABS 和文中算法获得了更高的信噪比,这是因为 PCABS 和文中算法能够根据图像统计特性对图像细节特征提取。而 HSSNR 在去噪过程中,首先利用频谱导数域提升噪声级,然后利用缺少方向性信息的实数小波变换对空间进行降噪处理后再进行谱间去噪,当进行图像细节轮廓处理和平滑光谱曲线时,使得很多图像细节特征和光谱峰值被误认为噪声进行去除。与 PCABS 相比,文中算法获得更高信噪比,是因为 NAPCA 能够更好地对图像进行特征提取。相对于 PCA 变换后的主成分,NAPCA 的主成分能量更加集中。并且信噪比相对于信号方差更能反映图像质量,因此对数据块进行 PCA 或 NAPCA 变换后保留的主成分所包含的信号能量和噪声能量有很大不同。PCA 变换噪声的能量没有得到有效的抑制,使得某些主成分的噪声能量甚至大于信号能量。而 NAPCA 的主成分按信噪比排列,其主成分更加纯净。

表 1 HSSNR, PCABS 和文中算法 AVIRIS 图像的 SNR 比较结果(单位: dB)

Tab.1 SNR of AVIRIS images by HSSNR, PCABS and proposed algorithm(Units: dB)

	Jasper ridge	Lunar lake	Low altitude
Original SNR	27.781 5	27.781 5	27.781 5
HSSNR	33.724 5	34.499 7	33.006 4
PCABS	38.046 6	41.541 8	36.536 1
Algorithm in paper	38.863 5	42.391 5	37.384 7

高光谱遥感图像的特性决定了光谱去噪的必要性。因为高光谱遥感图像也可看作是若干光谱曲线的集合。而空间去噪并没有使得频谱域的噪声得到充分去除,因此利用光谱特性进一步进行光谱去噪以获得更好的去噪结果。表 2 列出了文中算法有无光谱去噪的 SNR 对比结果,从结果可以看出,一维光谱去噪是有必要的。

表 2 无一维光谱去噪和有一维光谱去噪的文中算法 AVIRIS 图像的 SNR 比较结果(单位: dB)

Tab.2 SNR of AVIRIS images by proposed algorithm without 1-D spectral denoising and proposed method with 1-D spectral denoising (Units: dB)

	Jasper ridge	Lunar lake	Low altitude
Original SNR	27.781 5	27.781 5	27.781 5
Without one-dimensional spectrum denoising	38.699 2	41.819 3	37.297 3
With one-dimensional spectra denoising	38.863 5	42.391 5	37.384 7

文中算法的实现是通过 Matlab7.8 编程实现的,在系统为 Windows XP SP3、硬件为 Dual-Core CPU E5400@2.7GHz、1G 内存下运行。表 3 列出了 HSSNR, PCABS 和文中算法运算时间的比较结果。文中算法运算时间要长于 HSSNR, PCABS。在计算时间上,并不占有优势。与去噪结果相结合来看,文中算法可以看成是用时间换取了信噪比的提高。但这种置换是有意义的,信噪比的提高有利于高光谱遥感图像的应用。

表 3 HSSNR、PCABS 和文中算法 AVIRIS 图像的运算时间的比较结果(单位: s)

Tab.3 Computational time of AVIRIS images by HSSNR, PCABS and proposed algorithm(Units: s)

	Jasper ridge	Lunar lake	Low altitude
HSSNR	161.98	154.01	161.68
PCABS	180.74	183.58	185.48
Algorithm in paper	356.49	362.96	358.75

为了验证文中算法的有效性和适用性,选取实用型模块化成像光谱仪(OMIS)数据进行真实数据实验。OMIS 是中国科学院上海技术物理研究所研制的新型航空遥感仪器。它在可见光/近红外/短波红外/热红外  $0.46\sim 12.15\ \mu\text{m}$  的波长范围内设置了 128 个光谱波段<sup>[4]</sup>。原始图像大小为  $512\times 536$ ,截取其中  $256\times$

256 的部分进行实验,其多数波段受到了不同程度的噪声干扰,主要是条纹噪声和随机噪声干扰<sup>[6]</sup>。PCABS 根据提出的规则选取的主成分数量为  $l=5$ ,文中算法根据规则选取的主成分数量为  $l=9$ 。图 3 分别为第 30,第 60 和第 90 波段去噪前后的图像,而图 4 分别为原始图像和相应算法所得去除噪声图像


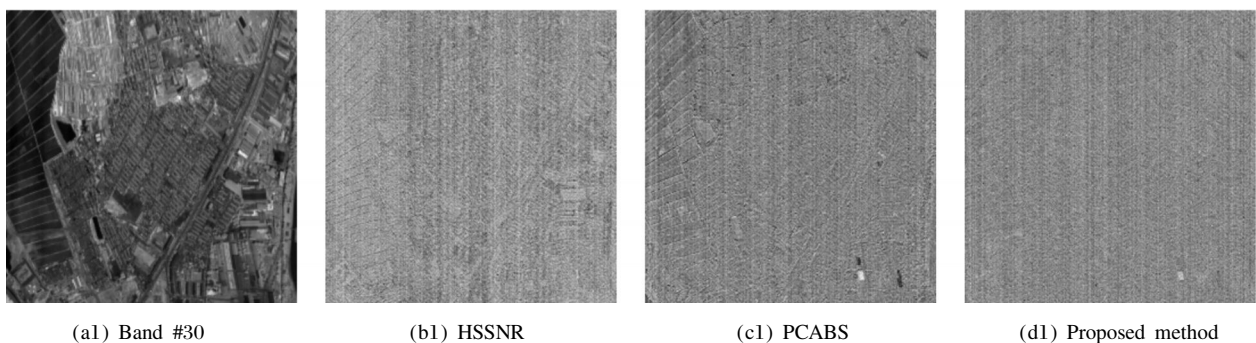


图 3 去噪前后第 30,第 60 和第 90 波段图像

Fig.3 Band #30, #60 and #90 of the OMIS datacube before and after denoising



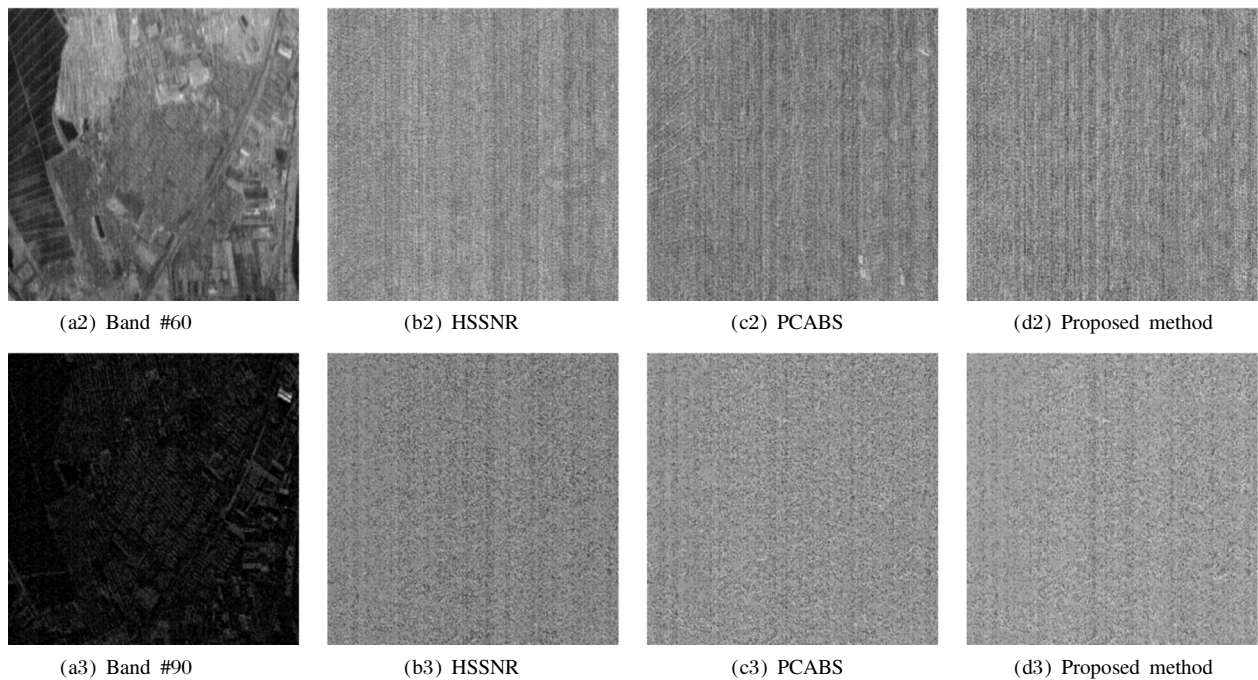


图 4 去噪前后第 30, 第 60 和第 90 波段图像与原图像的差别

Fig.4 Difference of OMIS datacube before and after denoising for band #30, #60 and #90

之差, 其差值图像被认为是通过算法移除的噪声图像。由这两幅图可知第 30 波段噪声污染程度十分微小, 肉眼很难分辨, 第 60 波段主要受到条带噪声污染, 附加少量的随机噪声污染, 而第 90 波段则主要受到随机噪声污染, 附加少量的条带噪声。通过这三个波段去噪结果的比较, 从图 4 中的(b)和(c)可以看到原图像的部分边缘和轮廓, 说明这些去噪算法在去噪的同时, 损失了原图的细节信息, 而文中算法这种现象不明显。因此对于这三种算法, 文中算法更好的保持了图像地纹理细节特征。

## 6 结 论

传统的去噪方法进行去噪的同时, 破坏了图像细节特征。文中通过结合 NAPCA 和 CWT 的方法, 在去噪处理的过程中, 能更好地保持图像的细节特征。通过仿真实验, 与其他方法对比表明: 文中算法能够有效地移除噪声, 提高图像信噪比。通过真实数据实验表明了文中算法的有效性和适用性, 能够很好地去掉图像的点状噪声和条带噪声。文中是从 SNR 的角度判别高光谱遥感图像的去噪效果, 而如何从实际应用的角度进行判别是值得在未来的工作中探讨和研究的, 如分类精度、目标识别准确度。

## 参 考 文 献:

- [1] Xu Xiaohui, Zhang An, Duanmu Jingshun, et al. Remote sensing target recognition based on particle swarm classifier [J]. *Infrared and Laser Engineering*, 2007, 36(4): 551-554. (in Chinese)  
徐小慧, 张安, 端木京顺, 等. 基于粒子群分类器的遥感图像目标识别[J]. *红外与激光工程*, 2007, 36(4): 551-554.
- [2] Ding Ling, Tang Ping, Li Hongyi. Dimensionality reduction and classification for hyperspectral remote sensing data using ISOMAP[J]. *Infrared and Laser Engineering*, 2013, 42(10): 2707-2711. (in Chinese)  
丁玲, 唐婷, 李宏益. 基于 ISOMAP 的高光谱遥感数据的降维与分类[J]. *红外与激光工程*, 2013, 42(10): 2707-2711.
- [3] Donoho D L, Johnstone I M. Ideal spatial adaptation by wavelet shrinkage [J]. *Biometrika*, 1994, 81(3): 425-455.
- [4] Atkinson I, Kamalabadi F, Jones D L. Wavelet-based hyperspectral image estimation [J]. *International Geoscience and Remote Sensing Symposium*, 2003, 2: 743-745.
- [5] Othman H, Qian S E. Noise reduction of hyperspectral imagery using hybrid spatial-spectral derivative-domain wavelet shrinkage [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2006, 44(2): 397-408.
- [6] Chang Weiwei, Guo Lei, Liu Kun, et al. Denoising of

- hyperspectral data based on contourlet transform and principal component analysis [J]. *Journal of Electronics & Information Technol*og, 2009, 31(12): 2892–2896. (in Chinese)  
常威威, 郭雷, 刘坤, 等. 基于 Contourlet 变换和主成分分析的高光谱数据噪声消除方法[J]. 电子与信息学报, 2009, 31(12): 2892–2896.
- [7] Wu Yiquan, Wu Chao. Denoising of hyperspectral remote sensing images using NSCT and KPCA [J]. *Journal of Remote Sensing*, 2012, 16(3): 539–554. (in Chinese)  
吴一全, 吴超. 结合 NSCT 和 KPCA 的高光谱遥感图像去噪[J]. 遥感学报, 2012, 16(3): 539–554.
- [8] Li Ting, Chen Xiaomei, Chen Gang, et al. A noise reduction algorithm of hyperspectral imagery using double-regularizing terms total variation [J]. *Spectroscopy and Spectral Analysis*, 2011, 31(1): 16–20. (in Chinese)  
李婷, 陈小梅, 陈刚, 等. 一种双正则项全变差高光谱图像去噪算法[J]. 光谱学与光谱分析, 2011, 31(1): 16–20.
- [9] Chen G Y, Qian S E. Denoising of hyperspectral imagery using principal component analysis and wavelet shrinkage [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, 49(3): 973–980.
- [10] Lee J B, Woodyatt A S, Berman M. Enhancement of high spectral resolution remote-sensing data by a noise-adjusted principal components transform [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1990, 28(3): 295–304.
- [11] Bioucas-Dias J M, Nascimento J M P. Hyperspectral subspace identification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2008, 46(8): 2435–2445.
- [12] Selesnick I W, Baraniuk R G, Kingsbury N G. The dual-tree complex wavelet transform[J]. *IEEE Transactions on Signal Processing*, 2005, 22(6): 123–151.
- [13] Sendur L, Selesnick I W. Bivariate shrinkage functions for wavelet-based denoising exploiting interscale dependency [J]. *IEEE Transactions on Signal Processing*, 2002, 50 (11): 2744–2756.
- [14] Liu Yinnian, Xue Yongqi, Wang Jianyu, et al. Operational modular imaging spectrometer [J]. *Journal of Infrared and Millimeter Waves*, 2002, 21(1): 9–13. (in Chinese)  
刘银年, 薛永祺, 王建宇, 等. 实用型模块化成像光谱仪. 红外与毫米波学报, 2002, 21(1): 9–13.