

基于主成分分析和字典学习的高光谱遥感图像去噪方法

霍雷刚* 冯象初

(西安电子科技大学数学与统计学院 西安 710126)

摘要: 高光谱图像变换域各波段图像噪声强度不同,并具有独特的结构。针对这些特点,本文提出一种基于主成分分析(Principal Component Analysis, PCA)和字典学习的高光谱遥感图像去噪新方法。首先,对高光谱数据进行PCA变换得到一组主成分图像;然后,对信息量较小的主成分图像分别采用基于自适应字典的稀疏表示方法和对偶树复小波变换方法去除空间维和光谱维的噪声;最后,通过PCA逆变换得出去噪后的数据。结合主成分分析和字典学习的优势,该方法相对于传统方法对高光谱图像具有更好的自适应性,在细节得到保留的同时有效地抑制了斑块效应。对模拟和实际高光谱遥感图像的实验结果验证了该方法的有效性。

关键词: 图像处理; 高光谱图像; 去噪; 主成分分析; 稀疏表示; 字典学习

中图分类号: TP751

文献标识码: A

文章编号: 1009-5896(2014)11-2723-07

DOI: 10.3724/SP.J.1146.2013.01840

Denoising of Hyperspectral Remote Sensing Image Based on Principal Component Analysis and Dictionary Learning

Huo Lei-gang Feng Xiang-chu

(School of Mathematics and Statistics, Xidian University, Xi'an 710126, China)

Abstract: To reflect different intensities of noises among the different bands in the transform domain and the intrinsic structures of the transformed data, a new approach for denoising the hyperspectral images is proposed based on Principal Component Analysis (PCA) and dictionary learning. At first, a group of the principle component images are achieved by using the PCA transform. Then, these noises which exist in the spatial- and the spectral- domain of the components with low energy are denoised by an adaptively learned dictionary based sparse representation method and the dual-tree complex wavelet transform, respectively. Finally, the denoised data is obtained using the inverse PCA transform. By taking advantages of principal component analysis and dictionary learning, the proposed approach is superior to the traditional ones in preserving the details and alleviating the blocking artifacts. The experiment results on the synthetic and real hyperspectral remote sensing images demonstrate the effectiveness of the proposed approach.

Key words: Image processing; Hyperspectral image; Denoising; Principal Component Analysis (PCA); Sparse representation; Dictionary learning

1 引言

近年来,高光谱遥感图像受到广泛关注,并成功应用到地质勘探、考古发现、森林火灾检测、军事作战等多个领域。然而,由于在获取、传输过程中受到各种因素的影响,高光谱遥感图像的噪声比较严重。这些噪声对后续的解混^[1]、分类^[2]和识别^[3]等造成严重影响,制约了高光谱图像的广泛应用。因此,图像去噪技术是高光谱遥感应应用中非常重要的关键技术之一,也是遥感科学和信息科学的研究热点。

与全色图像、多光谱图像相比,高光谱图像的

噪声更加复杂。一方面,高光谱图像的波段数较多,各波段图像受噪声影响的程度不同;另一方面,由于光谱分辨率较高(单个波段的光谱频率范围较窄),各波段之间的相关性较强。上述特点使得传统的全色图像、彩色图像和多光谱图像去噪方法不能很好地用于去除高光谱图像中的噪声。因此,有必要针对高光谱图像的特点,设计更加合理的去噪方法。根据是否对高光谱数据进行光谱维变换,传统的高光谱图像去噪方法基本上可以分为两大类:(1)直接对获取的高光谱数据在空间维和光谱维建立去噪模型。例如:文献[4]把高光谱图像看作超立方体,研究了基于3维各向异性扩散的高光谱图像增强方法;文献[5]提出光谱-空间维自适应的总变差模型;文献[6]在最大后验估计框架下提出空间-光谱维混

2013-11-22收到,2014-03-13改回

国家自然科学基金(61271294, 60872138)资助课题

*通信作者: 霍雷刚 leiganghuo@163.com

合先验模型等；(2)先将高光谱数据进行光谱维变换，在变换后的空间维和光谱维进行去噪，然后进行逆变换得到去噪后的数据。例如：文献[7]提出在光谱微分域采用小波阈值收缩方法去噪；文献[8]提出在光谱微分域采用 BayesShrink 算法和 Savitzky-Golay 滤波进行去噪；文献[9]提出一种基于主成分分析和小波阈值收缩的高光谱图像去噪方法等。

以上方法考虑了高光谱图像的特点，但没有充分利用高光谱数据本身的特性。例如，文献[9]对主成分图像采用对偶树复小波变换，这些事先定义的、固定的解析字典没有充分考虑数据本身的属性，使得去噪方法对每个主成分图像去噪的自适应性受到限制。

针对上述缺陷，本文提出一种基于主成分分析和字典学习的高光谱图像去噪新方法。一方面，新方法充分利用 PCA 变换的优点，前几个主成分图像携带的主要信息得以有效保留；另一方面，新方法根据当前数据自适应地学习字典，结合稀疏表示方法对每个噪声成分图像进行去噪。由于字典是自适应学习的，更加全面地反映了数据的特殊性。

本文的结构安排为：第2节详细叙述了本文提出的方法；第3节是对实验结果的分析；结论在第4节给出。

2 基于主成分分析和字典学习的高光谱图像去噪方法

如前所述，本文方法的基本原理是综合利用光谱维变换和字典学习的优点来解决高光谱图像去噪的问题。不失一般性，本文结合经典的主成分分析^[10]和基于 K-奇异值分解 (K-Singular Value Decomposition, K-SVD) 算法^[11]的图像去噪模型^[12]给出一种新的高光谱图像去噪方法。

本文的方法主要包括如下4个步骤：

步骤1 光谱维 PCA 变换。假设含噪声的高光谱图像空间维大小为 $M \times N$ ，波段个数为 P ，将其表示为 P 行 $M \times N$ 列的矩阵 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_P]^T$ ，其中， $\mathbf{x}_p, p = 1, 2, \dots, P$ 表示将第 i 个波段图像按先后行(或者先后列)顺序重新排列的 $MN \times 1$ 维的列向量；对 \mathbf{X} 进行 PCA 变换得到变换后的数据 \mathbf{Y} 。

步骤2 PCA 域空间维去噪。保留前 k 个主成分分量(即 \mathbf{Y} 的前 k 行)不变，将其余的每个主成分分量采用如下方式进行去噪：将主成分分量转化为大小是 $M \times N$ 的 2 维图像(主成分图像)；采用文献[13]提出的鲁棒中值估计法估计噪声的标准差；利用 K-SVD 去噪模型^[12]去除该主成分图像中的噪声。

步骤3 PCA 域光谱维去噪。在 PCA 域，依次对变换后的每个像元采用如下方式进行去噪：保

留变换后的光谱维前 k 个分量不变，采用文献[14]的方法对剩余的 $P - k$ 维的分量进行去噪。

步骤4 数据重构。对经过以上方法处理的所有主成分分量进行 PCA 逆变换，并将得到的数据重新排列为大小为 $M \times N \times P$ 的矩阵，即去噪后的高光谱数据。

下面对其中的关键算法——主成分分析和 K-SVD 算法进行叙述。

2.1 主成分分析

主成分分析^[10]是一种最基本的数据降维方法，主要是通过对数据的协方差矩阵进行特征值分解，特征值分解后的特征向量对应数据的主成分，特征值对应数据在各个主成分上的权重。因此，PCA 变换是一种线性变换，变换后各主成分分量彼此不相关，且随着主成分编号的增加该分量包含的信息量减小。同其他基于光谱维变换的高光谱图像去噪方法一样，本文的方法主要是利用 PCA 变换去除高光谱图像波段间的相关性，去除冗余信息。对高光谱图像进行 PCA 变换后，大部分信息集中在前几个主成分分量中，其他的主成分分量以噪声为主，本文称之为噪声成分分量。通常可以只取前几个信息量大的主成分分量而丢掉信息量小的噪声成分分量。值得注意的是，噪声成分分量仍包含一些有用信息，如果丢弃噪声成分分量，重构的高光谱图像将会有信息损失。针对以上情况，文献[9]提出保留信息量大的前几个主成分分量，对噪声成分分量进行去噪，然后取处理后的所有主成分分量进行 PCA 逆变换。本文也采用这种方式。

2.2 基于 K-SVD 模型的噪声成分图像去噪

小波变换由于具有良好的时频特性，在信号和图像处理领域应用广泛。传统的基于阈值收缩的小波去噪方法考虑了小波系数的大小但忽略了小波系数的结构信息，很多学者对其进行改进，如采用双变量收缩的方法^[15]，结合稀疏表示的方法^[16]等。根据信号的先验知识，可以设计出合适的字典。进一步，考虑信号样本，可以优化这些字典^[17]。近年来，稀疏表示理论和字典学习算法的研究取得了很大的进展。字典学习的方法因其对不同图像的自适应性获得了比采用固定字典方法更好的效果，已被成功地用于图像去噪^[12,18]、Bayer 格式图像彩色恢复^[19]、高光谱遥感图像分类^[20]等。其中，K-SVD 算法^[11]是目前最具代表性的字典学习方法之一。

假设 $\mathbf{f} = \mathbf{u} + \mathbf{v}$ ，其中，噪声成分图像 \mathbf{f} 的大小为 M 行 N 列， \mathbf{u} 是待恢复图像， \mathbf{v} 是均值为 0、标准差为 σ 的高斯白噪声。基于 K-SVD 字典学习算法的图像去噪模型对应的能量形式为^[12]

$$\begin{aligned} \{\hat{\alpha}_{ij}, \hat{D}, \hat{u}\} = \arg \min_{\{\alpha_{ij}, D, u\}} & \lambda \|f - u\|_2^2 \\ & + \sum_{ij} \|R_{ij}u - D\alpha_{ij}\|_2^2 + \sum_{ij} \mu_{ij} \|\alpha_{ij}\|_0 \end{aligned} \quad (1)$$

其中, $R_{ij}u$ 表示以图像 u 的按先列后行(或者先行后列)顺序排列的第 $ij, ij = 1, 2, \dots, IJ$ 个元素为左上角位置抽取 $\sqrt{n} \times \sqrt{n}$ 大小的图像块并把它转化为大小为 $n \times 1$ 的列向量的二值化算子, $IJ = (M - \sqrt{n} + 1) \cdot (N - \sqrt{n} + 1)$ 为图像块的个数; $D \in \mathbb{R}^{n \times K}$ 表示字典, n 是图像块中的像素点个数, K 是字典原子的个数, $\hat{\alpha}_{ij}$ 是 $R_{ij}u$ 在字典 D 上的稀疏表示系数向量。 $\{\hat{\alpha}_{ij}, \hat{D}, \hat{u}\}$ 分别表示所有图像块对应的稀疏表示系数向量组、待学习的字典和去噪后的图像。 λ 是估计的图像和含噪声图像之间保真度的权重, 与噪声强度有关, 噪声较大时, λ 应取较小的值。 μ_{ij} 对应系数 α_{ij} 稀疏度的权重。 $\|\alpha\|_0$ 表示向量 α 中的非零元素的个数。

经过适当地初始化, 上述优化问题中的待求变量可以采用交替迭代的方法按如下步骤求解^[12]:

步骤 1 稀疏编码: 固定 \hat{D} , 求解: $\hat{\alpha}_{ij} = \arg \min_{\alpha} \|R_{ij}u - D\alpha\|_2^2 + \mu_{ij} \|\alpha\|_0$;

步骤 2 字典更新: 固定 $\{\hat{\alpha}_{ij}\}$, 求解: $\hat{D} = \arg \min_D \sum_{ij} \|R_{ij}u - D\hat{\alpha}_{ij}\|_2^2$ 。

经过适当转换, 稀疏编码可以通过正交匹配追踪(Orthogonal Matching Pursuit, OMP)算法^[21]求解。根据矩阵范数的性质 $\sum_{ij} \|R_{ij}u - D\hat{\alpha}_{ij}\|_2^2 = \|Y - DA\|_F^2$, 其中, $A = [\alpha_1, \alpha_2, \dots, \alpha_{IJ}] \in \mathbb{R}^{K \times IJ}$ 。对字典原子采用逐个更新的方式, 步骤 2 对应的能量泛函可以转换为^[11]

$$\begin{aligned} \{D_{k_i}, A_{k_i}^T\} &= \arg \min_{D_{k_i}, A_{k_i}^T} \left\| Y - \sum_{k \neq k_i} D_k A_k^T - D_{k_i} A_{k_i}^T \right\|_F^2 \\ &= \arg \min_{D_{k_i}, A_{k_i}^T} \|E_{k_i} - D_{k_i} A_{k_i}^T\|_F^2 \end{aligned} \quad (2)$$

其中, $A_{k_i}^T$ 表示矩阵 A 的第 k_i 行。式(2)中, 由于 D_{k_i} 和 $A_{k_i}^T$ 分别是列向量和行向量, E_{k_i} 可以看作两个秩 1 的矩阵 D_{k_i} 和 $A_{k_i}^T$ 的乘积。根据误差矩阵的奇异值分解 $E_{k_i} = U\Delta V^T$, 对 E_{k_i} 做秩 1 逼近, 求出新的字典原子 $D_{k_i} = U_1$ 和对应系数 $A_{k_i}^T = \Delta[1, 1] \times V_1$ (对 $A_{k_i}^T$ 的更新可以加快算法的收敛速度)。

步骤 1 和步骤 2 交替迭代进行, 直到满足停止条件(达到指定最大迭代次数或误差)。

按以上步骤得到稀疏编码和字典之后, 取式(1)中与 u 相关的项, 并对 u 求导, 容易得到^[12]

$$\hat{u} = \left(\lambda I + \sum_{ij} R_{ij}^T R_{ij} \right)^{-1} \left(\lambda f + \sum_{ij} R_{ij}^T D \hat{\alpha}_{ij} \right) \quad (3)$$

其中, I 表示单位方阵。式(3)实际上表示 \hat{u} 的每一像素点处的值由含噪声图像和去噪后图像中包含该像素点的所有图像块对应该像素点位置的像素值加权平均得到。

3 实验结果

为了验证本文方法的有效性, 本节给出一个模拟数据和一个真实数据上的实验结果。本文算法同以下 3 种相关方法进行比较: (1)原始数据每个波段分别采用基于双变量收缩模型的 2 维对偶树复小波变换域阈值收缩方法去噪^[15](BandBishr2D); (2)原始数据每个波段分别采用基于字典学习的稀疏表示方法(本文采用 K-SVD 去噪模型^[12](BandK-SVD2D)); (3)在 PCA 变换域, 除了前 k 个以外的每个主成分图像采用基于双变量收缩模型的 2 维对偶树复小波变换域阈值收缩方法去噪, 该方法简记为 PCABishr2D 方法^[9]。为方便起见, 本文方法简记为 PCAK-SVD2D 方法。实验中, 以上 4 种方法又分别考虑了两种情况: (1)在光谱维不进行处理; (2)在光谱维采用文献[14]的方法抑制光谱维噪声。

3.1 模拟数据实验结果

模拟数据的生成参考 Indian Pines 数据集的真实地物类别数据^[22,23]和美国地质调查局数字光谱实验室(USGS digital spectral library)提供的光谱数据库 splib06a^[24]进行合成。Indian Pines 数据集覆盖了 16 类确定类别的地物^[22]。本文采用文献[25]的方法从光谱数据库“splib06a”中找出与 16 类地物和未标注类别的地物相似的光谱数据。按照如下方式构造不含噪声的模拟高光谱图像: 首先, 分别为每一类地物按选定的相似光谱数据赋值; 然后, 从赋值完成后的数据中选取所有像素值均不小于零的波段; 最后, 将整个数据的数值范围线性拉伸到 $[0, 255]$, 得到大小为 $145 \times 145 \times 151$ 的模拟数据。

假定噪声为零均值加性高斯白噪声, 对于模拟数据, 本文分别考虑了以下 3 种情况: (1)所有波段噪声强度相同, 噪声标准差分别为 $\sigma = \{5, 10, 15, 20, 25\}$; (2)每个波段的噪声强度随机从 $[2, 10]$ 之间均匀采样; (3)每个波段噪声强度取为该波段最大像素值的 3%。

除了视觉效果以外, 本文还利用信噪比(Signal-to-Noise Ratio, SNR)和峰值信噪比(Peak Signal-to-Noise Ratio, PSNR)两个客观定量指标对不同方法的性能进行比较。对于大小为 $M \times N \times P$ 的高光谱图像, 上述指标定义为

$$\text{SNR} = \frac{\sum_{i,j,p} \mathbf{A}(i,j,p)^2}{\sum_{i,j,p} [\mathbf{B}(i,j,p) - \mathbf{A}(i,j,p)]^2} \quad (4)$$

$$\text{PSNR} = 10 \lg \left(\frac{255^2}{\sum_{i,j,p} \frac{[\mathbf{B}(i,j,p) - \mathbf{A}(i,j,p)]^2}{M \times N \times P}} \right) \quad (5)$$

其中, $i = 1, 2, \dots, M; j = 1, 2, \dots, N; p = 1, 2, \dots, P$; \mathbf{B} 表示含噪声的数据或者去噪后的数据, \mathbf{A} 表示不含噪声的参考数据。这 3 个指标都是值越大, 对应去噪效果越好。

表 1 和表 2 分别列出了 3 种噪声情况下含噪声高光谱图像及采用不同方法去噪后的高光谱图像的两个客观评价指标。对比表中数据, 可以得出: (1) 光谱维去噪有助于提升高光谱图像的整体去噪效果。例如, 在所有波段噪声强度相同情况下(见表 1), 对于在原始数据空间去噪的 BandBishr2D 方法和 BandK-SVD2D 方法, 添加光谱维去噪后大部分情况(BandK-SVD2D 方法中, 当 $\sigma = \{15, 20\}$ 时例外), 去噪效果略有提升; 而对于在 PCA 变换域去噪的 PCABishr2D 和本文方法, 添加变换域光谱维去噪后, 去噪效果提升明显。(2) 相同算法框架下, 采用自适应字典的方法优于采用固定对偶树复小波基的方法。该结论可通过对比直接对原始数据分波段处理的 BandBishr2D 方法和 BandK-SVD2D 方法, 或者 PCA 变换域的 PCABishr2D 方法和本文方法得出。光谱维不做处理或者去噪后都可得出此结论。(3) 基于 PCA 变换的 PCABishr2D 方法和本文方法在光谱维不做处理和去噪两种情况下, 都要优于直接对原始数据处理的 BandBishr2D 方法和 BandK-SVD2D 方法。(4) 本文提出的基于自适应字典

去噪的 PCAK-SVD2D 方法优于基于固定对偶树复小波基去噪的 PCABishr2D 方法。例如, 当 $\sigma = 20$ 时, 光谱维去噪前本文方法与 PCABishr2D 方法去噪后数据的信噪比相对噪声数据的信噪比的比值为: 11.66 和 28.72, 光谱维去噪后, 该比值为 25.28 和 38.45。

为了进一步说明本文方法的有效性, 图 1 展示了模拟数据、含噪声数据($\sigma = 20$)和光谱维去噪后数据中随机选取的 2 个波段图像。图中第 1 行, 第 2 行分别对应模拟数据的第 10 和第 54 波段。图 1(c) 列显示了 BandBishr2D 的方法去噪后的结果, 可以看出, 噪声没有很好地去掉, 还引入了斑块效应, 尤其第 10 个波段的图像, 很多细节信息丢失。图 1(d) 列显示的是 BandK-SVD2D 方法去噪后的图像, 相对 BandBishr2D 方法, 斑块效应得到有效抑制, 但去噪后的图像被过分平滑, 边缘模糊和小细节丢失。PCABishr2D 方法(图 1(e)列)由于保留了 PCA 变换的前几个主成分, 一些细节信息得到保留, 但仍有较弱的斑块效应存在。图 1(f) 列中, 本文方法去除噪声的同时, 有效地保留了细节信息, 抑制了斑块效应。

由于噪声强度随波长变化, 为进一步比较不同方法在每个波段上的去噪性能, 图 2 显示了第(2)种情况和第(3)种情况下(即噪声强度随波段变化的情况)每隔 5 个波段含噪声数据和不同去噪方法去噪后数据在各个波段上的信噪比之差(峰值信噪比之差的比较与此类似), 其他未显示的波段的比较结果与此类似。从中可以看出, BandBishr2D 方法去噪的性能偏低, BandK-SVD2D 方法较 BandBishr2D 方法效果有所提升, 部分波段达到甚至超过了 4 种方法在该波段达到的最高信噪比(例如第 1 个波段)。PCABishr2D 方法和本文方法在所有波段都取得

表 1 模拟数据上 4 种方法去噪性能比较(所有波段的噪声强度都相同的情况)

σ	评价指标	噪声图像	BandBishr2D		BandK-SVD2D		PCABishr2D		PCAK-SVD2D	
			(a)	(b)	(a)	(b)	(a)	(b)	(a)	(b)
5	SNR	386.57	971.67	972.19	2409.04	2413.55	4311.91	8632.82	8430.01	10177.39
	PSNR(dB)	34.17	38.17	38.18	42.12	42.13	44.65	47.66	47.56	48.38
10	SNR	98.44	334.59	334.89	773.49	789.30	1171.62	2496.78	2818.73	2913.52
	PSNR(dB)	28.23	33.54	33.55	37.18	37.27	38.99	42.27	42.80	42.94
15	SNR	44.90	185.93	186.13	399.88	399.38	531.84	1163.64	1373.88	1852.71
	PSNR(dB)	24.82	30.99	31.00	34.32	34.31	35.56	38.96	39.68	40.98
20	SNR	25.94	123.55	123.73	229.05	206.17	302.45	655.73	744.96	997.47
	PSNR(dB)	22.44	29.22	29.22	31.90	31.44	33.11	36.47	37.02	38.29
25	SNR	17.10	90.59	90.74	150.01	163.33	194.90	418.28	401.88	546.36
	PSNR(dB)	20.63	27.87	27.88	30.06	30.43	31.20	34.51	34.34	35.67

注: (a)列为光谱维不进行处理时的结果; (b)列为光谱维去噪后的结果。

表 2 模拟数据上 4 种方法的去噪性能比较(噪声强度随波段变化的情况)

σ	评价指标	噪声图像	BandBishr2D		BandK-SVD2D		PCABishr2D		PCAK-SVD2D	
			(a)	(b)	(a)	(b)	(a)	(b)	(a)	(b)
$\sigma_i \sim U[2, 10]$	SNR	217.18	643.52	643.88	1576.89	1584.15	2474.08	4563.18	5912.81	6938.06
	PSNR(dB)	31.64	36.38	36.39	40.28	40.30	42.23	44.89	46.02	46.71
$\sigma_i = 3\% \times \text{MAX}_i$	SNR	361.69	874.83	875.48	2235.00	2202.48	3870.56	6720.26	8979.13	9776.35
	PSNR(dB)	33.88	37.72	37.72	41.79	41.73	44.18	46.57	47.83	48.20

注：(a)列为光谱维不做处理时的结果；(b)列为光谱维去噪后的结果。 σ_i, MAX_i 分别表示第 i 个波段添加的噪声的标准差和该波段的最大像素值。

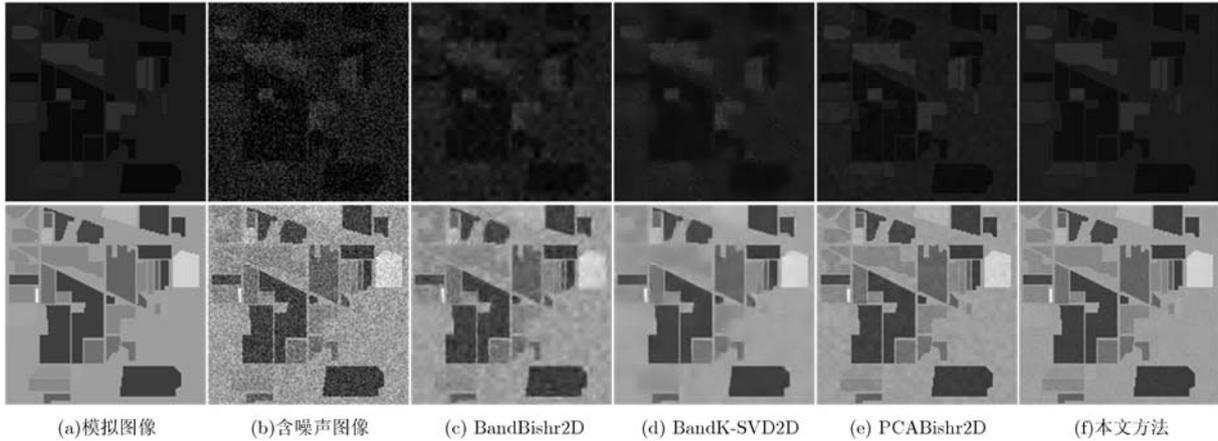


图 1 模拟数据上不同算法去噪后图像的视觉效果比较

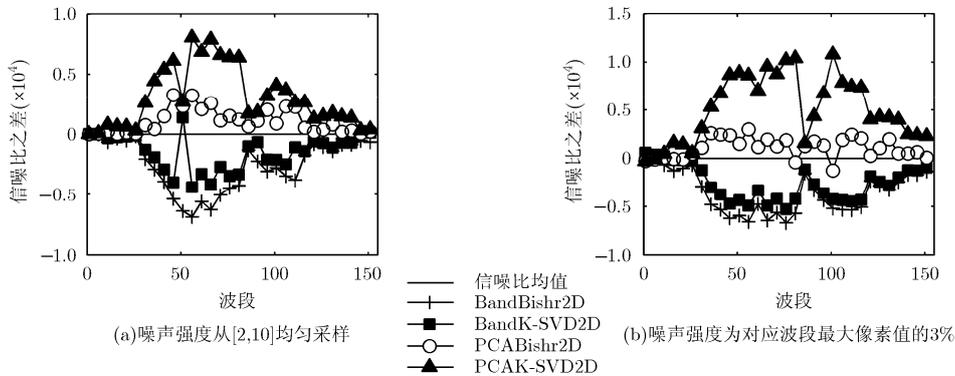


图 2 模拟数据上不同去噪方法去噪后数据和含噪声数据的信噪比差值比较

了很好的去噪效果，整体比较稳定且大多数波段高于前两种方法。其中，本文方法去噪效果较 PCABishr2D 方法又有所提升，并且对大部分波段提升效果明显。

3.2 真实数据实验结果

Pavia Center^[22]是由高光谱传感器 ROSIS 在意大利西北部的帕维亚采集，包含 102 个波段，光谱分辨率约为 4 nm，本文选取大小为 $128 \times 128 \times 102$ 的数据验证不同方法对受噪声影响的真实高光谱数据的去噪性能。去噪前将所有数值线性拉伸到 $[0, 255]$ 。该数据前 10 个波段含有较强的噪声。

为了说明本文方法的有效性，图 3 显示了含噪声数据和不同方法去噪后数据的第 1(第 1 行)和第 3 波段(第 2 行)图像。本文还计算了含噪声数据和去噪后数据每个波段的各向异性质量指标 (Anisotropic Quality Index, AQI)^[26]和所有波段的 AQI 指标的平均值(MAQI)。AQI 指标可以在没有不含噪声的参考图像的情况下评价图像的质量，其值越大，图像质量越好。为了便于比较，图 4 中的曲线分别展示了不同方法去噪后数据与含噪声数据每隔 5 个波段的 AQI 指标的差值，其他未显示的波段的比较结果与此类似。表 3 列出了含噪声数据和

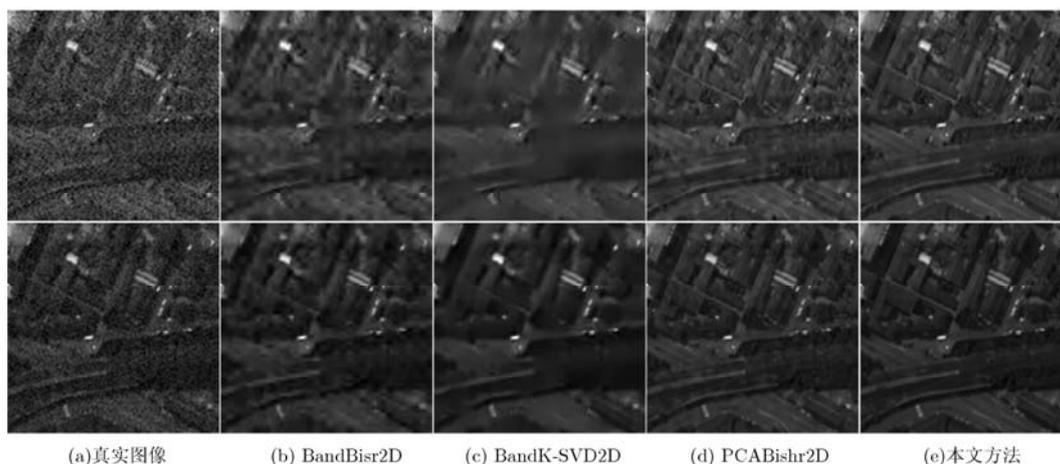


图 3 真实数据上不同算法的去噪结果比较

表 3 真实数据和不同方法去噪后数据的 MAQI 指标

方法	真实数据	BandBisr2D	BandK-SVD2D	PCABisr2D	PCAK-SVD2D
MAQI	0.0164	0.0167	0.0168	0.0166	0.0177

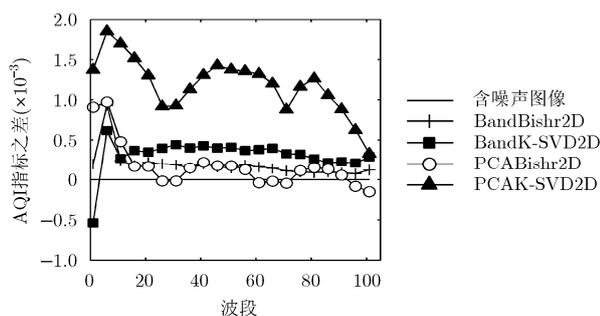


图 4 采用不同方法去噪后数据和真实数据各波段的 AQI 指标差值比较

不同方法去噪后数据的 MAQI 指标。结合图 3, 图 4 和表 3 可以看出: BandBisr2D 方法去噪后图像斑块效应明显, BandK-SVD2D 方法去噪后图像视觉效果有所提升, 但图像被过分平滑(尤其第 1 个波段), 造成细节丢失和边缘模糊。PCABisr2D 方法和本文方法能够很好地保留边缘和细节信息, 这主要是由于 PCA 变换后保留了主要的前 k 个主成分。但前一种方法仍然有明显的斑块效应。边缘模糊, 特别是斑块效应严重影响了图像的视觉效果, 导致了较小的 AQI 和 MAQI 指标。本文提出的方法通过采用自适应字典对除前 k 个以外的每个主成分图像进行去噪, 保留了细节的同时, 更有效地抑制了斑块效应, 得到了较好的视觉效果、较大的 AQI 和 MAQI 指标。

4 结束语

高光谱图像变换域各波段噪声强度不同, 为利

用各波段图像的独特结构并提高去噪性能, 本文提出了一种基于主成分分析和字典学习的高光谱遥感图像去噪新方法。该方法根据当前数据学习自适应字典, 利用稀疏表示方法对噪声成分图像去噪。由于字典反应了图像本身的结构, 本文方法在保留细节的同时有效抑制了斑块效应。该方法可以推广到采用其他光谱维变换和字典学习的方法, 也可以将本文方法加以改进, 针对非高斯噪声的情况设计合理的去噪模型或算法。

参考文献

- [1] Eches O, Benediktsson J A, Dobigeon N, *et al.*. Adaptive markov random fields for joint unmixing and segmentation of hyperspectral images[J]. *IEEE Transactions on Image Processing*, 2013, 22(1): 5-16.
- [2] Bai Jun, Xiang Shi-ming, and Pan Chun-hong. A graph-based classification method for hyperspectral images[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, 51(2): 803-817.
- [3] Li Qing-ting, Lu Lin-lin, Zhang Bing, *et al.*. The recognition of altered rock based on spectral modeling and matching using hyperspectral data[C]. *Proceedings of 2nd IEEE International Conference on Remote Sensing, Environment and Transportation Engineering*, Nanjing, 2012: 1-4.
- [4] Martín-Herrero J. Anisotropic diffusion in the hypercube[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2007, 45(5): 1386-1398.
- [5] Yuan Qiang-qiang, Zhang Liang-pei, and Shen Huan-feng. Hyperspectral image denoising employing a spectral-spatial adaptive total variation model[J]. *IEEE Transactions on*

- Geoscience and Remote Sensing*, 2012, 50(10): 3660-3677.
- [6] Chen Shao-lin, Hu Xi-yuan, and Peng Si-long. Hyperspectral imagery denoising using a spatial-spectral domain mixing prior[J]. *Journal of Computer Science and Technology*, 2012, 27(4): 851-861.
- [7] Othman H and Qian Shen-en. 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.
- [8] 孙蕾, 罗建书. 高光谱遥感图像微分域三维混合去噪方法[J]. *光谱学与光谱分析*, 2009, 29(10): 2717-2720.
- Sun Lei and Luo Jian-shu. Three-dimensional hybrid denoising algorithm in derivative domain for hyperspectral remote sensing imagery[J]. *Spectroscopy and Spectral Analysis*, 2009, 29(10): 2717-2720.
- [9] Chen Guang-yi and Qian Shen-en. 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] Jolliffe I T. Principal Component Analysis[M]. Second Edition, New York: Springer, 2002: 1-6.
- [11] Aharon M, Elad M, and Bruckstein A. K-SVD: an algorithm for designing overcomplete dictionaries for sparse representation[J]. *IEEE Transactions on Signal Processing*, 2006, 54(11): 4311-4322.
- [12] Elad M and Aharon M. Image denoising via sparse and redundant representations over learned dictionaries[J]. *IEEE Transactions on Image Processing*, 2006, 15(12): 3736-3745.
- [13] Donoho D L and Johnstone I M. Ideal spatial adaptation by wavelet shrinkage[J]. *Biometrika*, 1994, 81(3): 425-455.
- [14] Chen Guang-yi and Zhu Wei-ping. Signal denoising using neighbouring dual-tree complex wavelet coefficients[C]. Proceedings of 22nd Canadian Conference on Electrical and Computer Engineering, St Johns, NL, 2009: 565-568.
- [15] Sendur L and Selesnick I W. Bivariate shrinkage with local variance estimation[J]. *IEEE Signal Processing Letters*, 2002, 9(12): 438-441.
- [16] Zhao Rui-zhen, Liu Xiao-yu, Li Ching-chung, et al.. Wavelet denoising via sparse representation[J]. *Science in China Series F: Information Sciences*, 2009, 52(8): 1371-1377.
- [17] Mallat S. A Wavelet Tour of Signal Processing: The Sparse Way[M]. Third Edition, San Diego: Academic Press, 2008: 693-695.
- [18] Hao Yan, Feng Xiang-chu, and Xu Jian-lou. Multiplicative noise removal via sparse and redundant representations over learned dictionaries and total variation[J]. *Signal Processing*, 2012, 92(6): 1536-1549.
- [19] 朱波, 汶德胜, 王飞, 等. 应用字典学习算法改善 Bayer 格式图像彩色恢复效果[J]. *电子与信息学报*, 2013, 35(4): 812-819.
- Zhu Bo, Wen De-sheng, Wang Fei, et al.. Improvement of Bayer-pattern demosaicking with dictionary learning algorithm[J]. *Journal of Electronics & Information Technology*, 2013, 35(4): 812-819.
- [20] 宋相法, 焦李成. 基于稀疏表示及光谱信息的高光谱遥感图像分类[J]. *电子与信息学报*, 2013, 34(2): 268-272.
- Song Xiang-fa and Jiao Li-cheng. Classification of hyperspectral remote sensing image based on sparse representation and spectral information[J]. *Journal of Electronics & Information Technology*, 2013, 34(2): 268-272.
- [21] Pati Y C, Rezaiifar R, and Krishnaprasad P S. Orthogonal matching pursuit: recursive function approximation with applications to wavelet decomposition[C]. Proceedings of 27th Asilomar Conference on Signals, Systems and Computers, Pacific Grove, 1993: 40-44.
- [22] Hyperspectral Remote Sensing Scenes[OL]. http://www.ehu.es/ccwintco/index.php/Hyperspectral_Remote_Sensing_Scenes, 2013. 10.
- [23] Landgrebe D and Biehl L. MultiSpec[OL]. <https://engineering.purdue.edu/~biehl/MultiSpec/>, 2013.10.
- [24] Clark R N, Swayze G A, Wise R, et al.. USGS digital spectral library splib06a, 2007[OL]. <http://speclab.cr.usgs.gov/spectral.lib06/>, 2013. 10.
- [25] Qian Yun-tao and Ye Min-chao. 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.
- [26] Gabarba S and Cristobal G. Blind image quality assessment through anisotropy[J]. *Journal of the Optical Society of America A: Optics, Image Science & Vision*, 2007, 24(12): 42-51.
- 霍雷刚: 男, 1986 年生, 博士生, 研究方向为高光谱图像去噪模型和算法。
- 冯象初: 男, 1962 年生, 教授, 研究方向为小波理论及应用、数值分析、图像处理等。