

DOI:10.16356/j.1005-2615.2019.05.001

空间相关性约束联合子空间追踪的高光谱图像稀疏解混

孔繁镛¹ 朱成¹ 徐诚² 周永波¹

(1.南京航空航天大学航天学院,南京,210016; 2.南京航空航天大学无人机研究院,南京,210016)

摘要:通过深入分析高光谱图像空间相邻数据之间的空间相关性,提出一种利用空间相关性进行约束的联合子空间追踪解混(Spatial correlation constrained simultaneous subspace pursuit, SCCSSP)方法。该方法首先基于分块思想将高光谱图像进行分块处理,然后在图像块的端元提取步骤中,结合空间相关性特征对端元的提取进行约束,从而确保当前端元支撑集相对于高光谱图像残差是最优的。在丰度估计中将图像块的端元集合合并作为整幅图像的端元支撑集,通过求解非负性约束的最小二乘法获得丰度重建图像。模拟图像数据实验结果表明,本文方法在同等条件下能够获得更高的信号重构误差,且解混运算时间低于凸优化算法。在实际图像数据实验中,本文方法丰度图像稀疏度最低,取得了仅次于SUnSAL-TV算法的图像重建误差,其所得到的丰度重建图像也取得了更好的视觉效果。实验结果验证了本文方法具有更高的解混精度。

关键词:高光谱图像;高光谱解混;稀疏解混;贪婪算法;多重测量向量

中图分类号:TP751 **文献标志码:**A **文章编号:**1005-2615(2019)05-0577-09

Spatial Correlation Constrained Simultaneous Subspace Pursuit for Sparse Unmixing of Hyperspectral Imagery

KONG Fanqiang¹, ZHU Cheng¹, XU Cheng², ZHOU Yongbo¹

(1. College of Astronautics, Nanjing University of Aeronautics & Astronautics, Nanjing, 210016, China; 2. Research Institute of UAV, Nanjing University of Aeronautics & Astronautics, Nanjing, 210016, China)

Abstract:Based on the analyses of the interpixel correlation in the hyperspectral imagery, a spatial correlation constrained simultaneous subspace pursuit (SCCSSP) method is proposed. The method uses a block-processing strategy to divide the whole hyperspectral imagery into several blocks. In each block, the spatial correlation information is added to improve the accuracy of endmember selection, and ensures that the estimated endmember set is optimal to the current hyperspectral image residuals. The endmembers picked in each block is associated as the endmember sets of the whole hyperspectral imagery. Finally, the abundances are estimated by the nonnegative least squares method with the obtained end member sets. The results of simulated images experiment show that the proposed method can obtain higher signal reconstruction error under the same condition, and the time of unmixing operation is lower than the convex optimization algorithms. In the real images experiment, this method has the lowest sparsity of the abundance images, and is second only to the SUnSAL-TV algorithm in image reconstruction error. In addition, the reconstructed images obtained by this method obtain better visual effects. To sum up, experimental results on both simulated images and real images indicate that the hyperspectral unmixing accuracy of the SCCSSP algorithm

基金项目:国家自然科学基金(61401200)资助项目。

收稿日期:2018-10-16;**修订日期:**2018-11-18

通信作者:孔繁镛,男,副教授,E-mail:kongfq@nuaa.edu.cn。

引用格式:孔繁镛,朱成,徐诚,等.空间相关性约束联合子空间追踪的高光谱图像稀疏解混[J].南京航空航天大学学报,2019,51(5):577-585. KONG Fanqiang, ZHU Cheng, XU Cheng, et al. Spatial Correlation Constrained Simultaneous Subspace Pursuit for Sparse Unmixing of Hyperspectral Imagery[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2019, 51(5): 577-585.

is higher than that of the traditional methods.

Key words: hyperspectral imagery; hyperspectral unmixing; sparse unmixing; greedy algorithm; multiple-measurement vector

相比于多光谱图像和全色图像,高光谱图像不仅可以获得图像上每个点的光谱数据,还可以获得任一个谱段的影像信息,因此可以更有效地对地物进行分析和识别,因此在国土资源利用、地质勘探、海洋资源普查、战场环境侦测以及伪装目标识别等民用和军事领域具有广阔的应用前景。但是由于高光谱相机较低的空间分辨率以及复杂多样的地表环境,高光谱相机的瞬时视场内常包含有多种地物,这导致高光谱遥感图像单个像元往往是由多种地物的反射光混合组成,从而形成了混合像元^[1]。高光谱图像解译、地物识别与分类等工作受到了混合像元较大的干扰。因此,实现混合像元的可靠分解是推广高光谱成像技术应用面临的重大难题。

线性光谱混合模型假定高光谱相机传感器获得的像元光谱向量为多个地物光谱向量的线性组合,是业界学者研究投入最多、成果最丰硕的光谱混合模型。在基于线性混合模型的高光谱混合像元分解中,传统的做法是首先利用N-FINDR^[2]等端元提取算法分辨出混合像元中包含的端元种类,再通过丰度反演来实现高光谱图像解混^[3-6]。近年来,随着对稀疏表示理论研究的日益深入,一些学者开始尝试将稀疏思想引入混合像元分解模型中,用已获得的光谱库代替传统方法中求取的端元集合用于对混合像元进行解混,形成了稀疏解混方法^[7]。

稀疏解混方法目前主要分为凸优化和贪婪算法两类。主流的凸优化算法有SUnSAL^[8],CSUnSAL^[9]、迭代加权 L_1 正则化^[10]、SUnSAL-TV^[11]算法等,这些方法在高光谱混合像元分解中用 L_1 范数代替 L_0 范数。 L_1 范数基本上能够在完成对丰度系数的稀疏性约束,而且将NP-Hard问题转化为了凸优化问题,从而能够快速给出最优解。但是其最大的缺点是计算复杂度较高,不适用于对大尺寸高光谱图像进行解混。另外凸优化算法不能够像贪婪算法那样直接从光谱库中提取端元来控制稀疏解混的稀疏性,而混合像元中端元的数量与光谱库中光谱曲线数相比是非常小的,这使得算法的解混效果受到了某种程度的负面影响。典型的贪婪算法有正交基追踪算法(Orthogonal matching pursuit, OMP)和子空间匹配追踪算法(Subspace matching pursuit, SMP)等^[7],然而在端元选择机制中,由于光谱库中端元具有较强的相关性,SMP及

OMP算法容易进入局部最优的陷阱,对此,文献[12]将多重测量向量(Multiple measurement vector, MMV)模型引入到稀疏解混方法当中,提出了联合正交匹配追踪(Simultaneous orthotrogonal matching pursuit, SOMP)和联合子空间追踪(Simultaneous subspace pursuit, SSP)等联合稀疏解混方法。SOMP算法采用联合稀疏解混模型并结合分块策略来减小局部最优问题的影响,相比OMP和MP算法等算法能更准确得到全局最优解,但在每个分块的端元选择机制上缺少对已入选端元是否满足当前最优条件的检验,即待选端元进入端元支撑候选以后永久添加,而不会遭到去除。这使得提取的端元集合存在较多冗余端元,而这些冗余端元则影响了实际端元的丰度重建精度。SSP算法在端元选择机制上对已入选端元进行检验并能保证新的端元的增加,但SSP算法不能保证当次迭代更新后的残差一定小于前一次残差,即增加或删除端元对残差的影响,从而影响了下一次迭代更新中端元选择的效率和性能。

为了提高高光谱解混的精度,本文提出了一种空间相关性约束联合子空间追踪的高光谱图像解混方法,在端元选择机制中,结合空间相关性特征来约束端元的提取,能更准确地从已知光谱库中提取实际端元,从而进一步提高混合像元分解的精度。实验结果表明,相比SOMP,SMP等稀疏解混算法,本文方法具备更好的解混效果,验证了算法的有效性。

1 联合稀疏解混模型

线性高光谱混合模型假设混合像元是端元经线性组合而成,因此线性光谱混合模型可表示为

$$\mathbf{y} = \mathbf{A}\mathbf{x} + \mathbf{n} \quad (1)$$

式中: $\mathbf{y} \in \mathbf{R}^{L \times 1}$ 为高光谱图像中的单一混合像元; $\mathbf{A} \in \mathbf{R}^{L \times M}$ 为光谱库, M 为光谱库中包含的光谱数量; $\mathbf{x} \in \mathbf{R}^{M \times 1}$ 为端元的丰度向量; $\mathbf{n} \in \mathbf{R}^{L \times 1}$ 为噪声分量。在线性光谱混合模型中,丰度向量 \mathbf{x} 需同时满足非负约束($x_j \geq 0, j = 1, \dots, M$)及和为一约束

$$\left(\sum_{j=1}^M x_j = 1 \right) \text{ 两项约束条件。}$$

由于真实高光谱图像中包含的端元数一般远小于光谱库中的端元数,特定端元出现在某一混合像元中的概率较小,因此由混合像元的丰度系数向量组成的丰度系数矩阵具有行稀疏特性。而且邻

近的混合像元包含的地物种类和丰度较为相似,因此图像具备了空间相关性。因此,针对这些特征,文献[9]提出了联合稀疏解混模型

$$Y = AX + N \quad (2)$$

式中: $Y \in \mathbf{R}^{L \times K}$ 为表示 K 个像元在 L 个波段下的观测值; $X \in \mathbf{R}^{M \times K}$ 为丰度矩阵; N 为噪声矩阵。那么,联合稀疏解混模型可表示为

$$\min_X \|X\|_{\text{row-0}} \quad \text{s.t.} \quad \|Y - AX\|_F \leq \delta, X \geq 0 \quad (3)$$

式中: $\|X\|_{\text{row-0}}$ 代表丰度矩阵 X 中非零元素的行数。

文献[13]论证了如下不等式是式(3)表示的问题在无噪声条件下具有唯一解的充要条件

$$\|X\|_{\text{row-0}} < \frac{[\text{Spark}(A) - 1 + \text{Rank}(Y)]}{2} \quad (4)$$

式中: $\text{Spark}(A)$ 为光谱库 A 中可能线性相关的最小列向量的个数。由于高光谱图像数据的波段数 L 以及高光谱图像中的混合像元的数量 K 远超高光谱图像中包含的地物种类,因此可以认为式(3)表示的问题具有唯一解。

2 基于空间相关性约束联合子空间追踪算法

由于高光谱数据中相邻像素所涉及的物质相似,这些相邻的像素通常包含相同的物质,因而具有空间相关性。现有研究表明,利用高光谱图像空间相邻数据之间的信息进行高光谱图像解混可以有效提高解混性能,如文献[11]把全变差算子作为约束项添加到解混模型中,文献[14]将非局部均值算子作为约束项添加到解混模型中,获得了较好的解混性能。因此,本文将空间相关性作为约束项添加到端元提取步骤中的丰度系数求解模型中,有

$$X \leftarrow \arg \min_{X \in \mathbf{R}^{S \times K}} Q_r(X, S) = \frac{1}{2} \|A_s X - Y\|_F^2 + \frac{\lambda}{2} G(X) \quad (5)$$

式中: A_s 表示 S 个端元的集合; $Q_r(X, S)$ 表示在端元集合 A_s 下残差最小估值; $G(X)$ 为 X 的空间相关性约束项; $\lambda > 0$ 为空间相关性约束的惩罚参数。

通过进一步分析高光谱图像像素的空间相关性,可以发现这种空间相关性往往表现为像素间的平滑性,因此空间相关性约束项可以用梯度模型来表示

$$G(X) = \frac{1}{2} \sum_{i=1}^K \sum_{j \in \Lambda_i} w_{ij} \|x_i - x_j\|_2^2 \quad (6)$$

式中: $j \in \Lambda_i$ 为 x_i 的邻域, w_{ij} 为梯度的权重系数。本文中,像素 x_i 的邻域大小为 3×3 ,如图 1 所示,

将 $\sum_{j=1}^8 w_{ij} \|x_i - x_j\|_2^2$ 作为 x_i 的梯度,其梯度函数及权重系数如下,有

$$G(x_i) = \sum_{j=1}^8 w_{ij} \|x_i - x_j\|_2^2 = \sum_{j=1}^4 \|x_i - x_j\|_2^2 + \frac{1}{\sqrt{2}} \sum_{j=5}^8 \|x_i - x_j\|_2^2 \quad (7)$$




图 1 8邻域梯度估计模型

Fig.1 Eight-neighbour structure used for gradient evaluation

采用文献[15]的方法将式(6)展开,亦可以转化为如下形式

$$G(X) = \frac{1}{2} \sum_{i,j} w_{ij} \|x_i - x_j\|_2^2 = \sum_{i=1}^K x_i^T x_i D_{ii} - \sum_{i,j=1}^K w_{ij} x_i^T x_j = \text{Tr}(XDX^T) - \text{Tr}(XWX^T) = \text{Tr}(XLX^T) \quad (8)$$

式中: $\text{Tr}(\cdot)$ 为矩阵的迹; D 为对角矩阵; $L = D - W$ 为半正定矩阵。将式(8)代入式(5),可以得到

$$X \leftarrow \arg \min_{X \in \mathbf{R}^{S \times K}} Q_r(X, S) = \frac{1}{2} \|A_s X - Y\|_F^2 + \frac{\lambda}{2} G(X) = \frac{1}{2} \|A_s X - Y\|_F^2 + \frac{\lambda}{2} \text{Tr}(XLX^T) \quad (9)$$

针对式(9)的全局优化问题,可对式(9)求导可得

$$\nabla Q_r(X; S) = A_s^T A_s X + \lambda XL - A_s^T Y = 0 \quad (10)$$

式(10)则为 Lyapunov 方程,可以转化为如下紧凑的形式

$$B_1 X + X B_2 = B_3 \quad (11)$$

式中: $B_1 = A_s^T A_s$, $B_2 = \lambda L$ 和 $B_3 = A_s^T Y$ 。采用文献[16]的 Lyapunov 方程求解方法,对矩阵 B_1 和 B_2 进行 QR 分解得到对应的正交矩阵与一个上三角矩阵的积,其中 U 和 V 为正交矩阵

$$R = U^T B_1 U = \begin{bmatrix} R_{11} & & & 0 \\ R_{21} & R_{22} & & \\ \vdots & \vdots & \ddots & \\ R_{p1} & R_{p2} & \dots & R_{pq} \end{bmatrix} \quad (12)$$

$$M = V^T B_2 V = \begin{bmatrix} S_{11} & S_{12} & \dots & S_{1q} \\ & S_{22} & \dots & S_{2q} \\ & & \ddots & \vdots \\ 0 & & & S_{pq} \end{bmatrix} \quad (13)$$

对式(11)左右两边分别乘以 U^T 和 V , 则可以得到

$$(Y^T B_1 U)(U^T X V) + (U^T X V)(V^T B_2 V) = (U^T B_3 V) \quad (14)$$

$$\Rightarrow RZ + ZM = F \quad (15)$$

式中: F 和 Z 分别为

$$F = U^T B_3 V = \begin{bmatrix} F_{11} & \cdots & F_{1q} \\ \vdots & \ddots & \vdots \\ F_{p1} & \cdots & F_{pq} \end{bmatrix} \quad (16)$$

$$Z = U^T X V = \begin{bmatrix} Z_{11} & \cdots & Z_{1q} \\ \vdots & \ddots & \vdots \\ Z_{p1} & \cdots & Z_{pq} \end{bmatrix} \quad (17)$$

由于 R 和 M 为上三角矩阵, 因此对式(14)逐行展开, 则有

$$R_{kk} Z_{kl} + Z_{kl} M_{ll} = F_{kl} - \sum_{j=1}^{k-1} R_{kj} Z_{jl} - \sum_{i=1}^{l-1} Z_{ki} M_{il} \quad (18)$$

式中: $k=1, 2, \dots, p; l=1, 2, \dots, q$ 。通过式(18)可以逐步求出矩阵 Z 的第一行系数 $Z_{11}, Z_{21}, \dots, Z_{p1}$, 然后将 $Z_{11}, Z_{21}, \dots, Z_{p1}$ 作为已知解代入式(18), 则可以得到矩阵 Z 的第二行解 $Z_{12}, Z_{22}, \dots, Z_{p2}$, 依次类推可以得到矩阵 Z 的全部系数。然后将求得的 Z 代入式(17)则可以得到

$$X = UZV^T \quad (19)$$

将求得的 X 代入式(9), 则可以得到残差评估值 $Q_r(X, S)$

$$Q_r(X, S) = \frac{1}{2} \|A_s X - Y\|_F^2 + \frac{\lambda}{2} \text{Tr}(XLX^T) \quad (20)$$

针对 SSP 算法的缺点, 本文结合空间相关性特征来约束端元的剔除, 在选出符合条件的端元加入端元集合之后, 再用结合空间相关性约束的残差最小准则评估所有在端元支撑候选集中的端元, 按照残差最小准则删除端元集合中不符合要求的多余端元, 从而确保当次端元支撑候选集相对于当前的高光谱图像残差始终是最优的。所以, 针对初步筛选后的端元集合 V 中的所有端元, 按照结合空间相关性约束的残差最小准则评估每个端元, 由式(9, 20)可得

$$\begin{cases} c = \arg \min_{c \in V} Q_r(X, V/c) \\ X = \arg \min_{X \in \mathbb{R}^{S(c) \times K}} Q_r(X, V/c) \end{cases} \quad (21)$$

根据式(21)得到残差最小的端元 c 后, 从端元集合 V 中剔除, 则 $V = V/c$ 。

因此, 本文提出了基于空间相关性约束联合子空间追踪算法, 该方法需要将完整的图像分割为多个图像子块。然后针对每个子块, 先通过初步测试吸收恰当的端元加入端元支撑集, 接着利用结合空间相关性约束的残差最小准则又一次筛选入选端

元支撑集中的端元, 剔除里面的冗余端元。对所有图像块完成端元提取后, 将所有图像块的端元支撑集合并作为整幅高光谱图像的端元支撑集, 接着利用非负性约束的最小二乘法进行丰度估计。SCC-SSP 算法的具体步骤如下所示。

(1) 初始化: 将高光谱图像划分为若干大小相同的图像块 $Y = [Y_1, Y_2, \dots, Y_B]$, 端元集 $A_s = \emptyset$ 。

(2) 图像块 b 初始化: 端元子集 $A_{s_b} = \{\text{相应于} \|Y_b^T A_i\|_2 \text{最大的} m \text{个光谱端元}\}$, 残差 $R_b^0 = Y_b - A_{s_b} (A_{s_b}^T A_{s_b})^{-1} A_{s_b}^T Y_b, k=1$ 。

(3) 图像块 b 端元提取:

(a) $V = A_{s_b} \cup \{\text{相应于} \|(R^{k-1})^T A_i\|_2 \text{最大的} m \text{个光谱端元}\}$ 。

(b) $c = \arg \min_{c \in V} Q_r(X, V/c)$ 。

(c) 剔除端元: $V = V/c$ 。

(d) 若端元子集 V 中端元光谱数小于等于 m , 则令 $A_{s_b} = V$, 并执行步骤(e); 否则, 返回步骤(b), 继续剔除端元。

(e) 更新残差: $R_b^k = Y_b - A_{s_b} (A_{s_b}^T A_{s_b})^{-1} A_{s_b}^T Y_b$ 。

(f) 迭代停止判断: $\frac{\| \|R_b^k\|_F - \|R_b^{k-1}\|_F \|}{\|R_b^{k-1}\|_F} \leq \delta$, 迭

代停止, 输出端元子集 A_{s_b} ; 否则, $k \leftarrow k+1$, 返回步骤(a), 继续迭代。

(4) 合并端元子集: $A_s = A_s \cup A_{s_b}$ 。

(5) 丰度估计: 利用提取的端元集合 A_s 进行丰度估计: $X \leftarrow \arg \min_X \|A_s X - Y\|, \text{s.t. } X \geq 0$ 。

3 实验结果与分析

本文实验通过与凸优化算法(SUnSAL, CS-UnSAL, SUnSAL-TV 算法)和贪婪算法(SOMP, SMP, SSP)对混合像元进行解混的结果进行对比, 验证本文算法的性能。在实验中, 各种算法的参数均被调整到最优。本文实验均完成于运行 Windows 7 操作系统的 Intel Core2 Duo E7500@2.93 GHz, 内存 2 GB 的 Dell 微型计算机, Matlab 版本为 2009b。

3.1 模拟图像数据实验

在本实验中, 采用信号重构误差(Signal to reconstruction error, SRE)作为评估算法优劣的依据。定义 $\text{SRE} \equiv E[\|X\|_2^2] / E[\|X - \hat{X}\|_2^2]$, X 为实际的混合像元丰度系数向量, \hat{X} 为通过解混算法求得的丰度系数向量。SRE 用 dB 表示为: $\text{SRE}(\text{dB}) \equiv 10 \log_{10}(\text{SRE})$ 。SRE 越高, 表明算法

的解混精度越高。从美国地质勘探局 USGS splib06^[17]光谱库中选择 498 条光谱组成本实验中采用的光谱库。在模拟数据实验中选取光谱库 A 中 15 个光谱曲线作为实际端元,其中 5 个光谱曲线如

图 2 所示,其余光谱曲线为 Nontronite NG-1.a, Anthophyllite HS286.3B, Spodumene HS210.3B, Wollastonite HS348.3B, Labradorite HS17.3B, Pigeonite HS199.3B 和 Grossular WS484。




图 2 USGS 光谱库中的 5 个光谱曲线

Fig.2 Five spectral signatures from USGS

3.1.1 模拟图像数据 1 实验

模拟图像数据 1 采用文献[12]中的模拟图像数据实验 1 中的数据,模拟图像数据 1 生成 6 组分别对应端元数 5,7,9,11,13 和 15 的具有空间相关性的高光谱模拟图像数据。每组模拟数据都是由 64×64 个混合像元构成。生成模拟数据 1 后,向每组模拟图像数据中分别添加 SNR=20,25,30,35,40,45,50 dB 的高斯噪声,形成 7 幅高光谱模拟图像。

图 3 为 30 dB 高斯噪声下不同端元数时模拟图像数据 1 解混结果对比,从图中可以看出 SUnSAL 在 5~15 端元数时 SRE 最低,SCCSP 和 SMP 算法性能最好,SCCSP 性能要稍高于 SMP 算法,在 30 dB 高斯噪声下平均提高了 0.277 dB。SOMP 算法和 SSP 算法性能相近但都要低于 SCCSP 算法,SCCSP 与 SSP 算法相比,可以看出在不等端元数条件下,SCCSP 算法的 SRE 值都要高于 SSP 算法,在 30 dB 高斯噪声下平均提高了 4.86 dB。图 4 为 20~50 dB SNR 的高斯噪声下 7 端元模拟图像数据 1 解混结果对比,可以看到随着 SNR 的提高,各种算法的信号重构误差 SRE 逐渐提高。

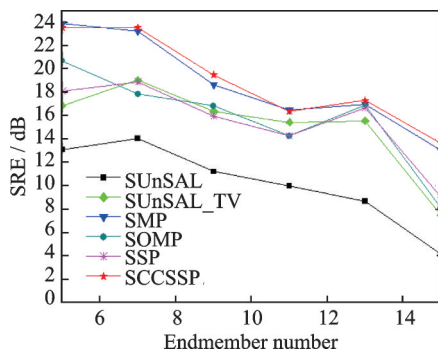


图 3 30 dB 高斯噪声下不同端元数时模拟图像数据 1 解混结果

Fig.3 Results on the simulated data 1 of different endmember number with 30 dB white noise




图 4 7 端元数时不同 SNR 高斯噪声的模拟图像数据 1 解混结果

Fig.4 Results on simulated data 1 with white noise as a function of SNR when the endmember number is 7

由图可知,SCCSP 的 SRE 值在大部分情况下都是最高的。与 SSP 算法相比,SCCSP 算法的 SRE 值均高于 SSP 算法,在 20~50 dB 高斯噪声下平均提高了 5.803 dB。

3.1.2 模拟图像数据 2 实验

模拟图像数据 2 采用文献[11]中的模拟图像数据实验 2 中的数据,由 100×100 个混合像元构成,随机选取给出的 15 个光谱曲线中的 9 个,并经线性组合而成。模拟图像 2 中各端元的原始丰度图像较为平滑,相邻端元间的空间相关性较强,比较接近实际高光谱图像,其中 3 个原始丰度图像如图 5 中原始丰度图像所示。在生成模拟数据 2 后,分别将 SNR=20,25,30,35,40,45,50 dB 的高斯白噪声加入到模拟图像数据 2 中,形成了 7 个模拟高光谱图像。

由图 5 可知,随着信噪比的提高,不同算法的性能也有不同程度的提高。在参与实验的所有算法中,凸优化算法(SUnSAL, SUnSAL-TV)算法表现最差,均不及贪婪算法。SCCSP 的 SRE 值在其中是最高的。与 SSP 算法相比,

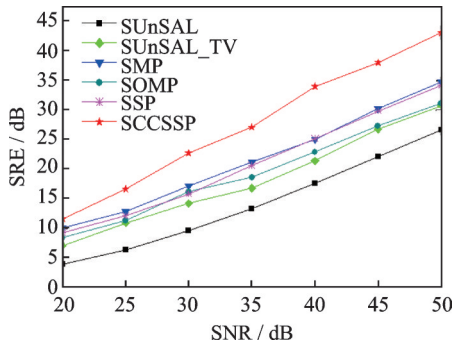


图5 不同SNR高斯噪声的模拟数据2解混结果对比
Fig.5 Results on simulated data 2 with different SNR white noise

SCCSSP算法的SRE值均高于SSP算法,在20~

50 dB高斯噪声下平均提高了6.619 dB。图6为30 dB高斯噪声条件下不同算法的丰度重建图像。从视觉上可以分辨出,在所有的算法中,SUnSAL算法的噪声点最多,SUnSAL-TV算法的丰度重建图像噪声点较少,但其丰度重建图像过于平滑,造成一些细节和边缘没有很好地保留。对比SUnSAL-TV算法,虽然SCCSSP算法的其丰度重建图像有更多的噪声点,但是它的边缘区域有更好的保留。与SOMP、SMP和SSP算法相比,SCCSSP算法的丰度重建图像中噪声点更少,同时更好地保留了边缘区域。综上所述,可以认为SCCSSP算法的丰度重建图像视觉上更加接近真实丰度图像。




图6 30 dB高斯噪声下模拟数据2的丰度重建图

Fig.6 Comparison of estimated abundance maps on simulated data 2 with 30 dB white noise

表1为30 dB高斯噪声下两种模拟数据的各种算法的解混运算时间比较,从表中可以看出,与其他算法相比,SUnSAL-TV算法的解混处理时间最长。由于在端元提取步骤中结合空间相

关性来约束端元的提取,SCCSSP算法与SOMP、SSP和SMP算法相比,运算时间较长,但运算时间远低于SUnSAL和SUnSAL-TV算法。

表1 30 dB高斯噪声的两种模拟数据下各种算法的解混运算时间

Tab.1 Processing time measured after applying the tested methods to the two considered simulated data sets with 30 dB white noise

Data cube	t/s					
	SUnSAL	SUnSAL-TV	SOMP	SMP	SSP	SCCSSP
Simulated data 1 (7 endmembers)	207.5	530.4	5.667	8.822	5.727	14.274
Simulated data 2	523.7	1 173.6	10.514	22.17	14.52	39.61

3.2 实际图像数据实验

本实验中使用的实际高光谱图像是从 AVIRIS Cuprite 数据中选择的 部分高光谱图像, 该部分高光谱图像包含 250×191 个像元, 混合像元的光谱都由 188 个波段组成。本实验采用了与模拟图像实验相同的光谱库。图 7 为利用 Tricorder3.3 software product 软件对 splib06 光谱库进行分析得到的不同矿物的分布图。

在实际图像数据实验中, 采用丰度图像的稀疏度和图像重建误差来作为比较算法优劣的依据。丰度图像的稀疏度定义为每个图像像元中非零值系数的平均个数, 其中定义数值大于 0.001 为非零值。高光谱重建图像的重建误差用均方根误差 (Root mean square error, RMSE)^[17] 来衡量

$$RMSE = \frac{1}{L} \sum_{i=1}^L \sqrt{\frac{1}{K \times \sum_{j=1}^K} (Y_{ij} - \hat{Y}_{ij})^2} \quad (22)$$

式中: Y_{ij} 为原始高光谱图像第 i 个波段第 j 个像元; \hat{Y}_{ij} 为高光谱重建图像第 i 个波段第 j 个像元; K 为图像大小; L 为波段数。

图 8 为各种算法的重建丰度图像和 Tricorder3.3 软件生成的丰度分布图, 从图中可以看出本文算法的重建丰度图像更接近 Tricorder3.3 软件生成的丰度分布图。表 2 为重建丰度图像的稀疏度和高光谱图像重建误差比较, 虽然 SUnSAL-TV




图 7 Cuprite 数据中不同矿物的 USGS 分布图
Fig.7 USGS map showing the distribution of different minerals in the Cuprite scene

具有最低的重建误差, 但 SCCSSP, SOMP, SMP 和 SUnSAL 算法比 SUnSAL-TV 算法的稀疏度要小于 SUnSAL-TV。SCCSSP 算法除了具有较低的重建误差, 而且可以获得最小的稀疏度, 这表明了该算法的有效性。




图 8 各种算法的重建丰度图像和 Tricorder3.3 软件生成的丰度分布

Fig.8 Fractional abundance maps estimated by the tested methods and the distribution maps produced by Tricorder3.3 software for the Cuprite scene

表2 丰度图像稀疏度和高光谱图像重建误差比较

Tab. 2 Comparison of sparsity of the abundance vectors and the reconstruction error of the hyperspectral imagery

Algorithm	重建误差					
	SUnSAL	SUnSAL-TV	SOMP	SMP	SSP	SCCSP
Sparsity	17.563	20.472	13.684	15.102	14.01	13.257
RMSE	0.005 7	0.003 8	0.004 8	0.004 7	0.004 9	0.004 2

4 结 论

在基于贪婪算法的高光谱图像稀疏解混方法中,一般采用以贪婪迭代的方式从已知光谱库中提取端元,由于光谱库中的光谱曲线数远大于实际端元个数且光谱库的光谱曲线通常是高相关性的,端元提取的精确性是个难题。因此,本文提出一种空间相关性约束的联合子空间追踪方法进行高光谱混合像元分解,在端元选择机制中,先通过初步测试选择合适的端元加入端元支撑集,再按照结合空间相关性约束的残差最小准则对已存在于支撑集中的端元进行再次检验,剔除其中的冗余端元。与SSP算法相比,本文算法在端元选择过程中增加了对端元支撑集中端元进行是否满足当前残差最小条件的检验,即检验增加或删除端元对残差的影响,从而更加有效地提取实际端元。模拟图像数据实验和真实图像数据实验表明,对比同类的其他算法,本文算法提取的端元集合更加精确,具有更好的解混精度。

参考文献:

- [1] 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.
- [2] WINTER M E. N-FINDR: An algorithm for fast autonomous spectral endmember determination in hyper spectral data[C]// Proceedings of SPIE—The International Society for Optical Engineering. [S.l.]: Society of Photo-optical Instrumentation Engineers, 1999: 266-276.
- [3] 李二森,徐波,李娜,等.最小体积约束的线性光谱解混算法[J].武汉大学学报:信息科学版,2011,36(6):683-686.
LI Ersen, XU Bo, LI Na, et al. Minimum volume constrained linear spectral unmixing algorithm[J]. Geomatics and Information Science of Wuhan University, 2011, 36(6): 683-686.
- [4] 夏威,王斌,张立明.基于独立分量分析的高光谱遥感图像混合像元盲分解[J].红外与毫米波学报,

2011, 30(2):131-136.

- XIA Wei, WANG Bin, ZHANG Liming. Blind unmixing based on independent component analysis for hyperspectral imagery[J]. Journal of Infrared and Millimeter Waves, 2011, 30(2):131-136.
- [5] ZHOU Guoxu, XIE Shengli, YANG Zuyuan, et al. Minimum-volume-constrained nonnegative matrix factorization: Enhanced ability of learning parts[J]. IEEE Transactions on Neural Networks, 2011, 22(10):1626-1637.
 - [6] WANG Liguu, WEI Fangjie, LIU Danfeng, et al. Fast implementation of maximum simplex volume-based endmember extraction in original hyperspectral data space[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2013, 6(2): 516-521.
 - [7] IORDACHE M D, BIOUCAS-DIAS J M. Sparse unmixing of hyperspectral data[J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(6): 2014-2039.
 - [8] AFONSO M V, BIOUCAS-DIAS J M, FIGUEIREDO M A. An augmented Lagrangian approach to the constrained optimization formulation of imaging inverse problems[J]. IEEE Transactions on Image Process, 2011, 20(3): 681-695.
 - [9] IORDACHE M D, BIOUCAS-DIAS J M, PLAZA A. Collaborative sparse regression for hyperspectral unmixing[J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(1): 341-354.
 - [10] 吴泽彬,韦志辉,孙乐,等.基于迭代加权L1正则化的高光谱混合像元分解[J].南京理工大学学报,2011,35(4):431-435.
WU Zebin, WEI Zhihui, SUN Le, et al. Hyperspectral unmixing based on iterative weighted L1 regularization[J]. Journal of Nanjing University of Science and Technology, 2011, 35(4): 431-435.
 - [11] IORDACHE M D, BIOUCAS-DIAS J M, PLAZA A. Total variation spatial regularization for sparse hyperspectral unmixing[J]. IEEE Transactions on Geoscience and Remote Sensing, 2012, 50(11): 4484-4502.
 - [12] SHI Zhenwei, TANG Wei, DUREN Z, et al. Subspace matching pursuit for sparse unmixing of

- hyperspectral data[J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 52(6): 3256-3274.
- [13] CHEN Jie, HUO Xiaoming. Theoretical results on sparse representations of multiple-measurent vectors[J]. IEEE Transactions on Signal Process, 2006, 54(12): 4634-4643.
- [14] ZHONG Yanfei, FENG Ruyi, ZHANG Liangpei. Non-local sparse unmixing for hyperspectral remote sensing imagery[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2014, 7(6): 1889-1909.
- [15] TANG Wei, SHI Zhenwei, WU Ying. Regularized simultaneous forward-backward greedy algorithm for sparse unmixing of hyperspectral data[J].IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(9): 5271-5288.
- [16] BARTELS R H, STEWART G W. Solution of the Matrix Equation $AX+XB=C$ [J]. Comm of the ACM, 1972, 15(9): 820-826.
- [17] CLARK R N, SWAYZE G A, WISE R, et al. USGS digital spectral library splib06a[EB/OL]. [2017-12-10]. <http://speclab.cr.usgs.gov/spectral.lib06>.

(编辑:孙静)