



基于空间加权协同稀疏的高光谱解混算法研究

摘要

针对传统稀疏解混算法因空间信息利用不足带来的丰度图像空间分布连续性差的问题,本文提出了一种基于空间加权协同稀疏的解混方法.该方法利用协同稀疏正则项刻画丰度系数的行稀疏性;同时,在协同稀疏框架下,引入空间加权因子挖掘高光谱图像邻域像元间的空间相关性.本模型采用交替方向乘子法求解,通过交替迭代,对空间权重和丰度系数进行优化.模拟和真实高光谱数据实验结果表明本文方法能够比现有同类方法获得更精确的解混结果.

关键词

高光谱图像;稀疏解混;空间加权;协同稀疏回归

中图分类号 TP391.41

文献标志码 A

0 引言

高光谱遥感影像是成像光谱仪对待测地物进行二维空间成像,同时将每个高光谱像元的光谱分成上百个波段进行连续的光谱覆盖,形成二维空间特征信息与一维光谱特征信息,体现出高光谱遥感影像图谱合一的特性,在包含大量的空间信息的同时,还具有丰富的地物光谱信息^[1-2].然而,由于受到传感器空间分辨率的限制以及自然界地物复杂多样性的影响,高光谱遥感影像中的一个像元所包含的地物可能并不单一,导致一个像元对应的光谱曲线可能由多种不同物质的光谱曲线混合而成,使得高光谱遥感影像中存在大量的混合像元^[3].混合像元的存在往往会造成“同质异谱”和“同谱异质”的现象,严重影响了地物的识别和分类精度^[4].如何从混合像元广泛存在的高光谱影像中准确地提取出典型地物(端元)的光谱,并有效地进行混合像元分解,以得到它们之间混合的比例(丰度),是保证高光谱遥感技术量化发展的前提.

总的来说,混合像元分解主要基于以下2种模型:线性光谱混合模型和非线性光谱混合模型^[5].线性光谱混合模型假定像元光谱是各端元光谱的线性组合,而非线性光谱混合模型则认为像元光谱是各端元光谱按某种非线性关系综合而成的.由于线性光谱混合模型简单、效率高、物理含义明确,并且在一般情况下能够得到满意的效果,是当前混合像元分解研究的主流.基于此,本文的研究将基于线性光谱混合模型展开.

近年来,随着稀疏表示^[6]理论的飞速发展,以及随着各大光谱库的普及,Iordache等^[7]用已知光谱库替代从图像中选取的端元集合,创新性地将稀疏性约束加入到混合像元分解之中,提出了稀疏解混方法.由于混合像元的端元丰度是稀疏的,而已知光谱库中光谱曲线数可能大于甚至远远大于实际构成混合像元的端元数目,因此混合像元中端元在已知光谱库下的丰度系数具有一定的稀疏性,于是形成了基于稀疏性的线性高光谱混合像元分解.稀疏解混避免了传统端元提取算法的2个弊病^[5]:第一不需要假设纯端元的存在;第二不需要估计端元数目.可以同时实现端元的选取和端元组分比例的估计,达到解混的目的.而且随着光谱库(即字典)的丰富,几乎所有物质的光谱曲线都被收录到光谱库中,从而避免了传统端元提取算法得到的端元光谱可能没有实际物理意义的情况.鉴于稀疏解混方法所具有的这些优点,该方法一经提

收稿日期 2017-10-26

资助项目 国家自然科学基金(61771496,61371165);广东省自然科学基金(2016A030313254)

作者简介

朱昌宇,男,硕士生,主要研究遥感图像处理、机器学习等.zhuchy8@mail2.sysu.edu.cn

李军(通信作者),女,教授,博士,博士生导师,主要研究方向为高光谱分类、混合像元分解、信号处理等.lijun48@mail.sysu.edu.cn

1 中山大学 地理科学与规划学院,广州,510275

2 西南交通大学 信息科学与技术学院,成都,610031

出,就受到国内外学者的高度关注,成为混合像元分解领域新的研究热点^[8-10].

稀疏解混的基本模型是一个非凸的组合优化问题,由于非平滑项 l_0 范数的存在,使得稀疏解混模型的求解过程极其复杂和困难.Iordache 等^[7]对 l_0 和 l_1 约束的高光谱数据稀疏解混问题进行了研究,在此基础上,先后用 OMP (Orthogonal Matching Pursuit)、ISMA (Iterative Spectral Mixture Analysis)、TwIST (Two-step Iterative Shrinkage/Thresholding algorithm) 以及 SUnSAL (Sparse Unmixing by variable Splitting and Augmented Lagrangian) 等算法进行稀疏性高光光谱混合像元分解,并比较和分析了各求解算法的性能.从 Iordache 等^[7]比较分析出的结果来看,为便于求解,在稀疏解混模型中一般采用 l_1 范数代替 l_0 范数,但会存在 l_1 正则化稀疏性和稳健性不好的新问题.针对该问题,学者们展开了广泛的研究,可以概括为 2 个方向.一方面,通过引入新的稀疏正则项来更好地表征像元丰度系数的稀疏性.如 Iordache 等^[11]提出了基于协同稀疏的解混算法 CLSUnSAL (Collaborative SUnSAL),利用丰度系数表现出的行稀疏特性,施加协同稀疏,减弱光谱库谱特征高相关性对解混精度的影响,提高解混效果.Sun 等^[12]采用 $l_{1/2}$ 正则化方法进行高光光谱混合像元分解,获得了更好的性能.Chen 等^[13]采用 l_p ($0 < p < 1$) 稀疏,提出 $l_p - l_2$ 约束的高光谱解混,获得了更稀疏的解及取得了更高的分解精度.另一方面,随着迭代加权的 l_1 正则化方法^[14]在图像处理各领域取得的成功,一些方法通过引入加权因子来约束稀疏解的非零系数.如吴泽彬等^[15]采用一种迭代加权的 l_1 正则化方法进行稀疏性混合像元分解,能较好地刻画混合像元丰度系数的稀疏性.Zheng 等^[16]在协同稀疏的基础上引入迭代加权因子,进一步增强解的稀疏性.Wang 等^[17]采用双重加权同时约束端元光谱库和丰度系数的稀疏性,获得了较好的性能.但是上述方法仅考虑像元丰度的独立性,并没有考虑它们之间的空间相关性,其结果无法保证丰度图像空间分布的连续性,存在一定的局限.考虑到高光光谱图像存在极强的空间相关性,因此结合这些空间信息来提高分解的精确性变得尤为关键^[18].

基于此,Iordache 等^[19]率先将各向同性全变差 (Total Variation, TV) 模型引入到稀疏性约束的解混问题,用来促进同质区域光滑性,但此类空间一阶邻域方法会加剧空间过平滑现象,丢失丰度图像本身

的纹理结构.Zhong 等^[20]在全变差模型的基础上,由局部邻域扩展到非局部邻域,提出非局部邻域正则化稀疏解混方法 (NLSU).Feng 等^[21]为了克服非局部正则化稀疏解混中参数的选择问题,提出自适应的非局部稀疏解混方法.然而,虽然这些方法能利用空间高阶结构信息,也能取得较好的结果,但其高昂的计算代价制约了实际应用潜力^[22].尽管考虑了高光光谱空间信息的方法已经取得了一定的进展,但仍然存在很多问题.因此,提出有效且实用的稀疏解混方法具有重要的研究价值.

综上,受迭代加权和协同稀疏解混算法在刻画丰度系数的稀疏性方面所拥有的优势的启发,以及考虑到高光光谱图像的空间连续特性,本文提出了一种基于空间加权协同稀疏的解混算法,称为 SW-CLSUnSAL 方法.本文提出的 SW-CLSUnSAL 方法,一方面基于协同稀疏解混的框架,利用丰度系数表现出的行稀疏特性,施加协同稀疏;另一方面,引入基于邻域系统的空间加权,考虑图像间的空间相关性,促进解的稀疏,进而提高分解的精确性.本模型采用交替方向乘子法 (Alternating Direction Method of Multipliers, ADMM)^[23]进行求解.

1 稀疏解混

假定高光光谱遥感使用了 L 个光谱波段,将稀疏解混模型写成如下形式:

$$\mathbf{Y} = \mathbf{A}\mathbf{X} + \mathbf{N} \quad \text{s.t.} \quad \mathbf{X} \geq 0, \quad (1)$$

其中, $\mathbf{Y} = [\mathbf{y}_1, \dots, \mathbf{y}_n] \in \mathbf{R}^{L \times n}$ 表示高光光谱图像, L 为波段数, n 为图像中的像元个数, $\mathbf{A} \in \mathbf{R}^{L \times m}$ 表示光谱库, m 表示光谱库中端元光谱数目, $\mathbf{X} = [\mathbf{x}_1, \dots, \mathbf{x}_n]$ 表示丰度矩阵, $\mathbf{N} \in \mathbf{R}^{L \times n}$ 表示系统噪声.根据丰度的物理意义,丰度系数满足“非负性”约束 (ANC, 即 $\mathbf{X} \geq 0$) 和“和为 1”约束 (ASC, 既 $\mathbf{1}_m^T \mathbf{X} = \mathbf{1}_n^T$).由于光谱库 $\mathbf{A}$ 的选择具有一定的随机性,不一定能涵盖目标高光光谱图像中所有的端元谱线,因此“和为 1”约束对于稀疏解混往往并不适用^[7].根据高光光谱混合像元分解的机理,光谱库 $\mathbf{A}$ 中的端元数目远大于一个混合像元中的端元个数,这样丰度矩阵 $\mathbf{X}$ 就具有“稀疏性”.这种稀疏性能够提高混合像元分解模型的精度和解的稳定性.基于稀疏性的混合像元分解模型可以表示为

$$\min_{\mathbf{X}} \frac{1}{2} \|\mathbf{A}\mathbf{X} - \mathbf{Y}\|_F^2 + \lambda \|\mathbf{X}\|_0 \quad \text{s.t.} \quad \mathbf{X} \geq 0, \quad (2)$$

其中 $\|\cdot\|_F$ 表示 Frobenius 范数, λ 是正则化参数,

$\|X\|_0$ 表示 X 的 l_0 范数. 根据压缩感知和稀疏表示理论, l_0 范数能较好地刻画稀疏性, 但是 l_0 最小化问题是非凸的, 求解困难. 2006 年 Candès 和 Tao^[24-25] 一起合作证明了在 RIP (Restricted Isometric Property) 条件下, l_0 范数优化问题与 l_1 范数优化问题具有相同的解, 且 l_1 范数最优化问题是凸的, 使得求解变得容易. 于是利用 l_1 范数代替 l_0 范数, 则基于 l_1 范数的最优化问题的解混模型为

$$\min_X \frac{1}{2} \|AX - Y\|_F^2 + \lambda \|X\|_{1,1} \quad \text{s.t.} \quad X \geq 0, \quad (3)$$

其中 $\|X\|_{1,1} = \sum_{j=1}^n \|x_j\|_1$, x_j 表示丰度矩阵 X 的第 j 列. 该模型可以利用基于交替迭代的 SUnSAL (Sparse Unmixing by variable Splitting and Augmented Lagrangian) 算法进行求解^[23]. 然而, 如前所述, l_1 范数对信号稀疏性的刻画不够充分, 一定程度上影响了分解的精度.

考虑到一般情况下, 光谱数据只是由光谱库中少量端元的线性组合, 那么, 光谱数据对应的丰度矩阵是行稀疏矩阵. 基于此, Iordache 等^[11] 采用 $l_{2,1}$ 混合范数, 提出了基于协同稀疏的解混算法:

$$\min_X \frac{1}{2} \|AX - Y\|_F^2 + \lambda \sum_{k=1}^m \|x^k\|_2 \quad \text{s.t.} \quad X \geq 0, \quad (4)$$

其中 x^k 表示丰度矩阵 X ($k = 1, 2, \dots, m$) 的第 k 行, $\sum_{k=1}^m \|x^k\|_2$ 则表示为 $l_{2,1}$ 混合范数. CLSUnSAL 算法^[11] 与 SUnSAL 算法的区别是用 $l_{2,1}$ 混合范数代替 l_1 范数, 其利用丰度系数表现出的行稀疏特性, 施加协同稀疏.

Candès 等^[14] 在稀疏约束下, 证明了 l_0 范数和 l_1 范数最小化约束模型在信号的稀疏重构中表现出对信号中的大小系数的不同惩罚, 并据此提出了更加逼近 l_0 范数的加权 l_1 范数模型, 将其应用于稀疏解混^[15-16], 所得模型如下:

$$\min_X \frac{1}{2} \|AX - Y\|_F^2 + \lambda \|W \odot X\|_{1,1} \quad \text{s.t.} \quad X \geq 0, \quad (5)$$

其中 $\odot$ 表示 2 个变量的点乘, 光谱权值 W 依据前一步的迭代结果计算出来, 权值 W 与 X 成反比, 设 t 表示迭代次数, 其更新公式如下:

$$W^{t+1} = \frac{1}{\|X\|^t + \varepsilon}, \quad (6)$$

其中 ε 为矫正参数, 取值很小^[26]. 当丰度矩阵中对应的丰度系数值较小时, 所对应的权值则较大, 相

应的在下一次的迭代过程中对该分量进行了更大的约束, 反之, 丰度系数值较大的时候, 相应的权值则较小, 施加的约束也较小. 因此, 该方法能够较好地刻画混合像元丰度系数的稀疏性. 然而, 如前所述, 这种加权 l_1 正则化方法与 l_1 正则化方法类似, 在保持丰度图像空间分布连续性上存在较强的局限.

2 本文提出的稀疏解混方法

2.1 基于空间加权协同稀疏的解混模型

受加权 l_1 优化所展现出优势的启发, 此外, 根据高光谱图像端元丰度分布在大部分地方都保持连贯性和均匀性的特点, 本文提出了一种基于空间加权协同稀疏的解混方法, 其模型如下:

$$\min_X \frac{1}{2} \|AX - Y\|_F^2 + \lambda \|W_{\text{spa}} \odot X\|_{2,1} \quad \text{s.t.} \quad X \geq 0, \quad (7)$$

其中 W_{spa} 为空间加权因子, $w_{\text{spa},ij}^{(t+1)}$ 表示矩阵 W_{spa} 中第 i 行 ($i = 1, \dots, m$)、第 j 列 ($j = 1, \dots, n$) 的元素, t 表示迭代次数, 其可以表示为

$$w_{\text{spa},ij}^{(t+1)} = \frac{1}{\left| \sum_{h \in N(j)} x_{ih} \right| + \varepsilon}, \quad (8)$$

其中, x_{ij} 表示丰度矩阵 X 中第 i 行、第 j 列的元素, $N(j)$ 表示第 i 幅丰度图像中第 j 个像元 (即元素 x_{ij}) 的邻域. 在这里, 我们选择的是一个 8-连接邻域, 也就是 3×3 的邻域窗口来挖掘空间信息. 综上, 则 $W_{\text{spa}}^{(t)}$ 表示为

$$W_{\text{spa}}^{(t)} = \begin{bmatrix} w_{\text{spa},11}^{(t)} & \cdots & w_{\text{spa},1n}^{(t)} \\ \vdots & & \vdots \\ w_{\text{spa},m1}^{(t)} & \cdots & w_{\text{spa},mn}^{(t)} \end{bmatrix}. \quad (9)$$

如式 (7) 所示, 在协同稀疏的框架下, 通过 W_{spa} 挖掘丰度系数间的空间相关性, 进而进一步刻画混合像元丰度系数的稀疏性, 以及减弱光谱库谱特征高相关性对解混精度的影响, 达到提高解混结果的目的.

2.2 模型求解

如前所述, 尽管加权 l_1 问题通过 ADMM 优化取得较好的结果, 但是在优化过程中权值的变更会给算法的收敛性带来困难, 本文利用内外循环迭代方案来处理这个问题. 下面将详细介绍求解流程:

扩展的拉格朗日 $(U, V, D) \equiv g(U, V) +$

$$\frac{\mu}{2} \|GU + BV - D\|_F^2 \text{ 表示如下:}$$

$$\min_{U,V} (V) \quad \text{s.t.} \quad GU + BV = 0, \quad (10)$$

其中, $\mu > 0$ 是一个常数, 设 $U = X, D = (D_1, D_2, D_3)$ 表示在 $GU + BV = 0$ 约束下的拉格朗日乘子, $V = (V_1, V_2, V_3), G = [A, I, I]^T, B = \text{diag}(-I)$, 目标函数 $g(V) \equiv \frac{1}{2} \|V_1 - Y\|_F^2 + \lambda \|W_{\text{spa}} \odot V_2\|_{2,1} + \iota_{R^+}(V_3)$ 的优化问题如下所示:

$$\min_{U,V_1,V_2,V_3} \frac{1}{2} \|V_1 - Y\|_F^2 + \lambda \|W_{\text{spa}} \odot V_2\|_{2,1} + \iota_{R^+}(V_3) \\ \text{s.t.} \quad V_1 = AU, \quad V_2 = U, \quad V_3 = U, \quad (11)$$

其中, $\iota_{R^+}(X) = \sum_{i=1}^n \iota_{R^+}(x_i)$ 表示“非负性”约束的示范函数, 当 $x_i \geq 0$ 时, $\iota_{R^+}(x_i) = 0$, 当 $x_i < 0$ 时, $\iota_{R^+}(x_i) = \infty$. 利用 ADMM 方法求解 SW-CLSunSAL 中的优化问题, 流程如算法 1 所示, 其中 vect-soft 表示行软阈值法, 如 $\text{vect-soft}(y, \tau) = y(\max\{\|y\|_2 - \tau, 0\} / (\max\{\|y\|_2 - \tau, 0\} + \tau))$, u 和 d_2 分别表示矩阵 U 和 D_2 中的像元. 在算法 1 的外循环中, 步骤 4 用来更新空间权重, 在内部循环中, 拉格朗日乘子则通过 ADMM 更新. 此外, 根据经验分析, 算法中的内部和外部循环的迭代次数 k 和 t 分别设置 5 和 200, 能够保证算法的收敛. 因此, 后续的实验也参照此设置.

算法 1 基于空间加权协同稀疏的解混算法

1. 初始化;
2. 设 $k, t = 0$, 令 $\mu, \lambda, \varepsilon > 0, U^{(0)}, V_1^{(0)}, V_2^{(0)}, V_3^{(0)}, D_1^{(0)}, D_2^{(0)}, D_3^{(0)}$;
3. 循环;
4. $W_{\text{spa}}^{(t)} \leftarrow \begin{bmatrix} w_{\text{spa},11}^{(t)} & \cdots & w_{\text{spa},1n}^{(t)} \\ \vdots & & \vdots \\ w_{\text{spa},m1}^{(t)} & \cdots & w_{\text{spa},mn}^{(t)} \end{bmatrix}$;
5. 其中 $w_{\text{spa},ij}^{(t)} = \frac{1}{\left| \sum_{h \in N(j)} (u_{ih}^{(t)} - d_{2ih}^{(t)}) \right| + \varepsilon}$;
6. 循环;
7. $U^{(k+1)} \leftarrow (A^T A + 2I)^{-1} (A^T (V_1^{(k)} + D_1^{(k)}) + V_2^{(k)} + D_2^{(k)} + V_3^{(k)} + D_3^{(k)})$;
8. $V_1^{(k+1)} \leftarrow \frac{1}{1 + \mu} [Y + \mu(AU^{(k+1)} - D_1^{(k)})]$;
9. $V_2^{(k+1)} \leftarrow \text{vect-soft}\left(U^{(k+1)} - D_2^{(k)}, \frac{\lambda}{\mu} W_{\text{spa}}^{(t)}\right)$;
10. $V_3^{(k+1)} \leftarrow \max(U^{(k+1)} - D_3^{(k)}, 0)$;
11. 更新拉格朗日乘子;
12. $D_1^{(k+1)} \leftarrow D_1^{(k)} - AU^{(k+1)} + V_1^{(k+1)}$;
13. $D_2^{(k+1)} \leftarrow D_2^{(k)} - U^{(k+1)} + V_2^{(k+1)}$;
14. $D_3^{(k+1)} \leftarrow D_3^{(k)} - U^{(k+1)} + V_3^{(k+1)}$;
15. 更新迭代次数: $k \leftarrow k + 1$;
16. $U^{(t+1)} \leftarrow U^{(k+1)}$;
17. $D_2^{(t+1)} \leftarrow D_2^{(k+1)}$;
18. 更新迭代次数: $t \leftarrow t + 1$;
19. 直到满足终止条件.

3 实验与分析

3.1 模拟数据实验

在本节中, 我们采用模拟数据测试算法的性能. 本文提出的算法 SW-CLSunSAL 将与 SunSAL^[7]、CLSunSAL^[11]、RW-CLSunSAL^[16] 和 SunSAL-TV^[19] 进行比较. 在实验中使用信号重构误差 SRE (量值记为 E_{SR} , 单位为 dB) 来衡量混合像元分解的精度, 这个评价标准已在其他高光谱混合像元分解算法研究的文献中得到广泛应用. 它被定义为

$$E_{\text{SR}} = 10 \cdot \log_{10}(E(\|x\|_2^2) / E(\|x - \hat{x}\|_2^2)), \quad (12)$$

其中 $E(\cdot)$ 表示期望函数, x 是实际的混合像元丰度系数向量, $\hat{x}$ 是估计的丰度系数向量. 此外, 我们也利用丰度重构正确率 (p_s) 验证各算法得到结果的精度. 定义如下:

$$p_s = P(\|\hat{x} - x\|^2 / \|x\|^2 \leq y_{\text{th}}), \quad (13)$$

其中, 假设定义阈值 $y_{\text{th}} = 10$ 且重构正确率 $p_s = 1$, 这就意味着所有丰度估计的误差绝对值与真实丰度估计的比值小于 1/10. 从这也能看出丰度估计的准确性从 SRE 中是无法精确判断的, 因为 SRE 是计算出的平均值. 文献[7]中对于阈值的确定给出了说明: 当丰度估计的误差与真实值的比值小于 5 dB 时, 丰度系数的重构正确率是 100%, 即 $\|\hat{x} - x\|^2 / \|x\|^2 \leq 3.16$. 通常来说, SRE 和 p_s 的值越大, 说明混合像元分解的精度越高, 性能更好. 此外, 本文对估计的丰度矩阵 $\hat{x}$ 中系数值大于 0.005 的像元数目进行统计, 将得到的数目与丰度矩阵中所有像元个数的比例定义为稀疏度 (sparsity), 稀疏度越小, 表明得到的解越稀疏.

3.1.1 模拟数据集

在该实验中, 光谱库是由美国地质勘探局 USGS 的矿物光谱库 splib06 的部分光谱构成 (<http://speclab.cr.usgs.gov/spectral.lib06>), 其中物质种类数目为 222 作为光谱库, 即 $A \in \mathbf{R}^{221 \times 222}$, 光谱波段数 $L = 221$, 反射值大小范围为 0.4 ~ 2.5 μm . 模拟数据集由从光谱库 A 中随机选取的 9 个光谱特征作为端元线性生成大小为 100×100 的像元, 其丰度图像满足“非负”约束 (ANC) 且“和为 1”约束 (ASC). 此外, 该数据具有非常良好的空间均匀性, 能较好地适用于不同解混算法提取局部特征. 图 1 给出了该图像中 9 个端元的原始丰度. 在模拟数据集中加入 3 种等级不同的高斯白噪声进行干扰, 信噪比 (SNR) 分别设为 30、40 和 50 dB.




图 1 模拟数据中 9 个端元的真实丰度

Fig. 1 Real fractional abundances in the simulated dataset

3.1.2 实验结果与分析

在白噪声的情况下,本文采取 5 种稀疏解混方法对模拟数据集进行解混,通过计算其 SRE 和 p_s 比较各方法的解混精度,以及比较稀疏度 sparsity.表 1 显示了在不同信噪比 (SNR) 下, SUnSAL、CLSUnSAL、SUnSAL-TV、RW-CLSUnSAL 和 SW-CLSUnSAL 这 5 种算法得到的 SRE、 p_s 和 sparsity 值.在这里,对 SUnSAL-TV 采用非各向同性 (non-isotropic) 全变差.此外,表 1 中给出了各方法取得最优值的参数值.

从表 1 中可以得出以下几个结论:第一,在 3 种不同信噪比的情况下,本文提出的 SW-CLSUnSAL 算法都获得了最好的 SRE,相较于 SUnSAL、CLSUnSAL、SUnSAL-TV 得到的结果,无论哪种情况

本文算法都展现出巨大的优势,且在低信噪比情况下,考虑了空间信息的 SW-CLSUnSAL 算法得到的结果比 RW-CLSUnSAL 得到的结果有明显的提升;第二,在低信噪比的情况下,本文算法比其他算法获得了更好的 p_s 值,表明考虑了空间信息的 SW-CLSUnSAL 算法具有更好的鲁棒性;第三,在所有情况下,本文算法可以比 SUnSAL、CLSUnSAL、SUnSAL-TV 和 RW-CLSUnSAL 获得更稀疏的解,这表明加入空间信息可以进一步增强解的稀疏性.因此可以得出结论,基于空间加权策略在提高混合像元分解的性能上展现出了巨大的潜力.

为了进一步验证所提出算法的有效性,图 2 直观地展示了 SUnSAL、CLSUnSAL、SUnSAL-TV、RW-CLSUnSAL 和 SW-CLSUnSAL 算法在信噪比为 30 dB

表 1 各算法对模拟数据集解混得到的 SRE(dB) , p_s 和 sparsity 值(括号中给出了获得最优结果的参数)
Table 1 SRE(dB) , p_s and sparsity scores achieved after applying different unmixing methods to the simulated data cube
(The optimal parameters for which the reported values were achieved are indicated in the parentheses)

算法	SNR=30 dB			SNR=40 dB			SNR=50 dB		
	SRE/dB	p_s	稀疏度	SRE/dB	p_s	稀疏度	SRE/dB	p_s	稀疏度
SUnSAL	6.425 9	0.632 7 ($\lambda=8e-3$)	0.065 3	11.583 3	0.887 7 ($\lambda=2e-3$)	0.060 5	18.998 7	0.999 2 ($\lambda=3e-4$)	0.044 4
CLSunSAL	6.555 6	0.723 4 ($\lambda=3e-1$)	0.093 3	14.840 1	0.999 7 ($\lambda=2e-2$)	0.073 5	26.594 5	1 ($\lambda=7e-3$)	0.023 6
SUnSAL-TV	9.037 1	0.782 9 ($\lambda=4e-3$; $\lambda_{TV}=2e-3$)	0.078 8	15.451 4	0.986 6 ($\lambda=6e-5$; $\lambda_{TV}=9e-4$)	0.041 5	25.355 7	1 ($\lambda=5e-5$; $\lambda_{TV}=9e-5$)	0.028 0
RW-CLSunSAL	13.963 3	0.977 5 ($\lambda=4e-2$)	0.047 0	25.491 2	1 ($\lambda=3e-2$)	0.023 6	34.251 2	1 ($\lambda=6e-3$)	0.021 5
SW-CLSunSAL	18.758 2	0.996 3 ($\lambda=4e-1$)	0.031 5	27.704 5	1 ($\lambda=1e-1$)	0.022 1	35.672 5	1 ($\lambda=6e-3$)	0.020 5




图 2 在信噪比为 30 dB 时,各算法对第 9 个端元丰度的结果比较

Fig. 2 The obtained results for the ninth endmember from simulated data under signal-to-noise ratio of 30 dB

时,估算出的第 9 个端元的丰度(如选择其他端元丰度图也是一样的结果),同时展示了真实丰度图和各算法估计丰度图的差值.从图 2 中可以看出,SUnSAL 和 CLSunSAL 得到的结果不精确且噪声很多,加入空间信息的 SUnSAL-TV 提升了解混效果,但是获得的丰度图存在过平滑现象.RW-CLSunSAL 和 SW-CLSunSAL 获得的结果更加接近真实的丰度图,表明了加权策略的有效性.从差值图中可以看出,与 RW-CLSunSAL 相比,SW-CLSunSAL 获得了更好的丰度估计,估计的丰度图中表现出更多的细节,保留

了丰度图像精细的结构和纹理,进一步表明空间加权策略的有效性.

3.2 真实数据实验

对于真实数据实验,本文采用著名的 Airborne Visible Infrared Imaging Spectrometer (AVIRIS) 成像光谱仪采集的美国内华达州 Cuprite 地区高光谱数据(<http://aviris.jpl.nasa.gov/html/aviris.freedata.html>),该图像近年来被广泛应用于验证高光谱图像解混算法的性能.该图地表主要是裸露的矿物,基本没

有植物覆盖,此外,该地区矿物间的混合现象很普遍.本节采用的 Cuprite 高光谱遥感图像的大小为 350×350 ,光谱包含了 188 个波段,波长范围为 $0.4 \sim 2.5 \mu\text{m}$,光谱分辨率为 10 nm .实验中,使用的 USGS 矿物光谱库 $A_2 \in \mathbf{R}^{188 \times 240}$.需要注意的是这里剔除了低信噪比和水蒸气的吸收波段 ($1 \sim 2$ 、 $105 \sim 115$ 、 $150 \sim 170$ 和 $223 \sim 224$),最终剩下 188 个波段进行后续的处理.为了便于分析,如前面实验一样,图 3 显示了 1995 年通过 USGS 拍摄得到的矿物图,用 Tricorder3.3 软件勘察矿区中不同的矿物^[27],得到各个矿物的分布.在实验中,用图 3 作为定性分析的参考,用它来测试不同混合像元分解算法的性能.为了确保算法的收敛和提高解混精度,使用最大迭代次数来终止运算.

如图 4 所示,对于明矾石 (Alunite)、铵长石 (Buddingtonite) 和玉髓 (Chalcedony) 3 种矿物,将 SUnSAL、CLSunSAL、SUnSAL-TV、RW-CLSunSAL 和 SW-CLSunSAL 这 5 种算法分解得到 3 种端元的丰度图与 Tricorder 算法得到的分类图进行定性比较,

其中 SUnSAL、CLSunSAL、RW-CLSunSAL 和 SW-CLSunSAL 这 5 种算法的正则化参数分别设置为 $\lambda = 0.001$, $\lambda = 0.01$, $\lambda = 0.06$, $\lambda = 0.5$, 相应的 SUnSAL-TV 算法的 2 个正则化参数设置为 $\lambda = 0.001$, $\lambda_{\text{TV}} = 0.001$.从图 4 中可以看出,5 种算法分解出来的效果与 Tricorder 算法的结果都较相似,表明了稀疏解混算法的有效性.然而,从图 4 中可以看出,由 SUnSAL 和 CLSunSAL 估计的一些丰度图 (例如 Buddingtonite) 看起来噪声多, SUnSAL-TV 获得的结果表现出过平滑现象.此外, RW-CLSunSAL 得到的丰度图,没有展现出良好的空间一致性 (例如, Chalcedony). 另外,与 RW-CLSunSAL 算法相比, SW-CLSunSAL 算法估计的丰度图更接近于真实的参照图.最后, SUnSAL, CLSunSAL, SUnSAL-TV, RW-CLSunSAL 和 SW-CLSunSAL 获得的稀疏度分别为 0.068 2、0.073 9、0.074 3、0.054 5 和 0.052 5.由这些小的差异可以得出结论,本文所提出的方法可以使用较少数量的像元来表达数据,从而实现更高的稀疏性.总的来说,通过真实数据实验得出的定性结




图 3 USGS 获得的内华达州赤铜矿区不同矿物所在的位置

Fig. 3 USGS map showing the location of different minerals in the Cuprite mining district in NV




图 4 在真实数据实验下 5 种算法分别得到的矿物丰度

Fig. 4 Fractional abundance maps estimated by five algorithms for AVIRIS Cuprite scene

果表明,新提出的 SW-CLSunSAL 算法能提高混合像元分解的精度。

4 结论

本文提出了一种新的基于空间加权协同稀疏的解混算法,用来加强对高光谱数据的分析.提出的 SW-CLSunSAL 在协同稀疏框架下,通过空间加权挖掘高光谱图像的空间信息,一方面增强了解的稀疏性,另一方面提高了丰度图像分布的空间连续性.实验结果表明,提出的 SW-CLSunSAL 与 SUnSAL、CLSunSAL、SUnSAL-TV、RW-CLSunSAL 算法相比,具有更好的解混效果且展现出较大的优势,验证了本文提出算法的精确性和有效性.鉴于此,本文提出的方法为以后的空谱联合稀疏性解混方法提供了新思路。

参考文献

References

- [1] Landgrebe D. Hyperspectral image data analysis [J]. IEEE Signal Processing Magazine, 2002, 19(1) : 17-28
- [2] 童庆禧,张兵,郑兰芬.高光谱遥感:原理、技术与应用 [M].北京:高等教育出版社,2006
TONG Qingxi, ZHANG Bing, ZHENG Lanfen. Hyperspectral remote sensing: Theory, technology, and applications [M]. Beijing: Higher Education Press, 2006
- [3] Keshava N, Mustard J F. Spectral unmixing [J]. IEEE Signal Processing Magazine, 2002, 19(1) : 44-57
- [4] 张良培,张立福.高光谱遥感 [M].武汉:武汉大学出版社,2005
ZHANG Liangpei, ZHANG Lifu. Hyperspectral remote sensing [M]. Wuhan: Wuhan University Press, 2005
- [5] 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
- [6] Elad M, Figueiredo M A T, Ma Y. On the role of sparse and redundant representation in image processing [J]. Proceedings of the IEEE, 2010, 98(6) : 972-982
- [7] 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
- [8] Shi Z W, Tang W, Duren Z, et al. Subspace matching pursuit for sparse unmixing of hyperspectral data [J]. IEEE Transactions on Geoscience and Remote Sensing, 2014, 52(6) : 3256-3274
- [9] Zhao X L, Wang F, Huang T Z, et al. Deblurring and sparse unmixing for hyperspectral images [J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 51(7) : 4045-4058
- [10] Zhang S Q, Li J, Liu K, et al. Hyperspectral unmixing based on local collaborative sparse regression [J]. IEEE Geoscience and Remote Sensing Letters, 2016, 13(5) : 631-635
- [11] 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
- [12] Sun L, Wu Z B, Xiao L, et al. A novel $L1/2$ sparse regression method for hyperspectral unmixing [J]. International Journal of Remote Sensing, 2013, 34(20) : 6983-7001
- [13] Chen F, Zhang Y. Sparse hyperspectral unmixing based on constrained l_p - l_2 optimization [J]. IEEE Geoscience and Remote Sensing Letters, 2013, 10(5) : 1142-1146
- [14] Candès E J, Wakin M B, Boyd S P. Enhancing sparsity by reweighted l_1 minimization [J]. Journal of Fourier Analysis & Applications, 2008, 14(5) : 877-905
- [15] 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
- [16] Zheng C Y, Li H, Wang Q, et al. Reweighted sparse regression for hyperspectral unmixing [J]. IEEE Transactions on Geoscience and Remote Sensing, 2016, 54(1) : 479-488
- [17] Wang R, Li H C, Liao W Z, et al. Double reweighted sparse regression for hyperspectral unmixing [C]. // IEEE International Geoscience and Remote Sensing Symposium, 2016: 6986-6989
- [18] Shi C, Wang L. Incorporating spatial information in spectral unmixing: A review [J]. Remote Sensing of Environment, 2014, 149: 70-87
- [19] 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
- [20] Zhong Y F, Feng R Y, Zhang L P. 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
- [21] Feng R Y, Zhong Y F, Zhang L P. Adaptive non-local Euclidean medians sparse unmixing for hyperspectral imagery [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2014, 97: 9-24
- [22] 张良培,李家艺.高光谱图像稀疏信息处理综述与展望 [J]. 遥感学报, 2016, 20(5) : 1091-1101
ZHANG Liangpei, LI Jiayi. Development and prospect of sparse representation-based hyperspectral image processing and analysis [J]. Journal of Remote Sensing, 2016, 20(5) : 1091-1101
- [23] Bioucas-Dias J M, Figueiredo M A T. Alternating direction algorithms for constrained sparse regression: Application to hyperspectral unmixing [C]. // Proceedings of the 2nd IEEE GRSS Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, 2010: 1-4

- [24] Candès E J, Tao T. Decoding by linear programming [J]. IEEE Transactions on Information Theory, 2005, 51 (12): 4203-4215
- [25] Candès E J, Tao T. Near-optimal signal recovery from random projections: Universal encoding strategies [J]. IEEE Transactions on Information Theory, 2006, 52 (12): 5406-5425
- [26] 王立国, 谭健. 一种改进的加权 L_1 正则化稀疏光谱解混算法[J]. 黑龙江大学自然科学学报, 2013, 30(5): 671-676
- WANG Ligu, TAN Jian. An improved sparse spectral unmixing algorithm based on weighted L_1 regularization [J]. Journal of Natural Science of Heilongjiang University, 2013, 30(5): 671-676
- [27] Clark R N, Swayze G A, Livo K E, et al. Imaging spectroscopy: Earth and planetary remote sensing with the USGS Tetracorder and expert systems [J]. Journal of Geophysical Research Atmospheres, 2003, 108 (12): 5131-5135

Spatially weighted collaborative sparse unmixing for hyperspectral images

ZHU Changyu¹ ZHANG Shaoquan¹ LI Jun¹ LI Hengchao²

1 School of Geography and Planning, Sun Yat-Sen University, Guangzhou 510275

2 School of Information Science and Technology, Southwest Jiaotong University, Chengdu 610031

Abstract In this paper, we propose a spatially weighted collaborative sparse unmixing method aiming at fully exploiting the spatial information in the hyperspectral images, in which a collaborative sparse regularizer is used to describe the row sparsity of the abundance, while on the top of the collaborative regularizer, a spatial weighting factor introducing the spatial correlations is incorporated. The proposed model is optimized by the well known alternating direction method of multiplier. Our experimental results, conducted using both simulated and real hyperspectral data sets, illustrate the good potential of the proposed algorithm which can greatly improve the abundance estimation results when compared with other advanced sparse unmixing methods.

Key words hyperspectral imaging; sparse unmixing; spatially weighted; collaborative sparse regression