

基于非局部信息的双重加权协同稀疏解混方法

李勇新¹ 王凤丽¹ 岳思雯¹

LI Yongxin WANG Fengli YUE Siwen

摘要

针对传统基于协同稀疏的半监督解混方法中存在的丰度结果过度平滑、高光谱空间上下文信息利用不足、丰度矩阵稀疏程度较低等问题,提出一种基于非局部高阶空间信息的双重加权协同稀疏解混方法。所提出的方法以协同稀疏解混模型为基础,一方面通过结合自适应权重因子以提高估计结果的稀疏性,另一方面通过挖掘高光谱数据较为丰富的非局部空间信息,形成空间权重矩阵以提高对高光谱图像空间信息的利用率,同时对行稀疏约束带来的过度平滑问题加以限制。算法选择结合交替方向乘子法对模型进行迭代求解,求解过程中采用了内外双循环结构以便于优化算法结果。在模拟和真实高光谱数据集上的实验结果表明了所提出方法的有效性。

关键词

高光谱解混; 权值矩阵; 非局部空间信息; 稀疏约束; 半监督

doi: 10.3969/j.issn.1672-9528.2024.03.013

0 引言

高光谱图像解混,作为高光谱图像研究领域的一个重要方向,在土地资源调查、能源环保、气象水利等领域具有重要作用^[1]。高光谱图像由于地物分布的复杂性和图像本身的空间分辨率问题,导致其本身表现出多种地物的混合特征^[2]。如以像元为单位对图像进行处理,则会受到混合地物信息的影响,降低图像处理精度^[3]。为此,高光谱解混逐渐成为高光谱图像研究的热门领域之一。

高光谱图像可分为两部分,即端元与丰度^[4]。其中端元指的是构成高光谱图像的基本地物,丰度则表示了每个像元中不同地物的混合程度^[5]。半监督的解混方法采用大型光谱库数据集来解决地物混合问题,由于一幅高光谱图像通常仅由少数地物组成,其对应的丰度矩阵实际应为一个稀疏矩阵,所以半监督解混方法又被称为稀疏解混方法^[6]。

稀疏解混中通常采用稀疏约束来求解地物的分布问题, L0 范数被首先考虑,但 L0 范数存在非凸问题使得求解难度大大增加^[7]。为了解决该问题, Candes 等人提出在稀疏解混中当所用光谱库满足条件时,可用 L1 范数替代 L0 范数进行求解^[8]。 Bioucas-Dias 等人通过交替方向乘子法来对稀疏解混模型进行求解,并提出了基于 L1 范数的解混方法 SUnSAL,通过对丰度的稀疏约束来提高解混精度^[9]。 Iordache 等人考虑到丰度矩阵中的行稀疏性,提出了基于 L2,1 范数的稀疏解混方法 CLSUnSAL,通过削弱光谱库中各地物光谱的相似性来提高解混精度^[10]。吴泽彬等人引入迭代加权的 L1

范数,通过权值矩阵来提高 L1 范数的稀疏性,从而提高解混效果^[11]。 Zheng 等人通过最小化加权 L1 范数来约束丰度矩阵中的非零项,也取得了较好的解混效果^[12]。

高光谱图像具有较多的光谱信息,许多研究人员对此进行了相关研究并取得了一定成果,但却忽略了高光谱图像中丰富的空间特征信息^[13]。 Iordache 等人关注到这一问题,在 SUnSAL 的模型基础之上添加了全变分正则化约束,以此来使用图像中的空间邻域信息^[14]。 Zhang 等人将邻域信息与 L2,1 范数结合,提出一种局部协同稀疏解混方法 LCSU,进一步优化了解混效果^[15]。 Zhong 等人将非局部正则化引入稀疏解混中,提出一种非局部正则化稀疏解混方法 NLSU^[16]。

综上,加权稀疏模型在稀疏解混领域具有较高的研究价值,但目前来说,对于非局部信息这种高阶空间信息的使用仍有一定的探索空间。因此,为了更好地使用高光谱图像中的高阶空间信息,本文提出一种基于非局部信息的双重加权协同稀疏解混方法 NLSDWSU,通过计算非局部空间信息矩阵作为权重矩阵,来对协同稀疏解混模型进行稀疏约束,并添加光谱权重矩阵来进行双重约束,以达成更好的解混效果。

1 相关工作

1.1 稀疏模型

光谱混合模型目前可分为线性混合模型与非线性混合模型^[17]。其中线性混合模型将高光谱图像中的混合地物假设为端元光谱与对应丰度的线性组合,矩阵形式可表示为:

$$Y = AX + N \quad (1)$$

式中: Y 表示高光谱数据, A 为测得的光谱向量矩阵, X 为

光谱库中所有端元所对应的丰度矩阵, N 为误差项。对于某一混合像元中各端元所对应的丰度来说, 通常需要满足丰度非负 (abundance non-negative constraint, ANC) 与和为一 (abundance sum-to-one constraint, ASC) 两种约束, 但由于真实的高光谱数据中的端元光谱存在变异性, 所以 ASC 约束实际上并不完全适用于稀疏解混场景^[18]。而有研究表明, ANC 实际上隐式地施加了一个广义的 ASC 约束, 所以通常不会显式地添加 ASC 约束。此外, 由于混合像元通常只由少量几种端元构成, 所以丰度矩阵 X 常为一个稀疏矩阵, 可以通过稀疏正则化器对丰度加以约束:

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

式中: $\|\cdot\|_F$ 表示 F 范数, 用于比较模拟数据与真实数据之间的相似性。 $\|\cdot\|_0$ 表示 L_0 范数, 用于进行稀疏约束。 λ 为正约束参数。为了便于求解, 通常采用 L_1 范数来代替 L_0 范数:

$$\min_X \frac{1}{2} \|AX - Y\|_F^2 + \lambda \|X\|_1 \quad \text{s.t. } X \geq 0 \quad (3)$$

因此, 原本难以求解的非凸问题就被转化为凸优化问题进行求解。

1.2 协同稀疏解混模型

正如之前所述, 由于高光谱图像仅由少量端元组成, 所以丰度矩阵 X 表现出一种行稀疏特性, 即每行仅存在少量非零值^[19]。由此, CLSUnSAL 选择采用行稀疏约束来限制丰度矩阵:

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

式中: $\|\cdot\|_{2,1}$ 表示行稀疏约束项, $\|X\|_{2,1}$ 实际可表示为 $\sum_{i=1}^M \|X^i\|_2$, i 为第 i 个端元光谱的丰度。

1.3 加权稀疏解混模型

虽然使用 L_1 范数来近似 L_0 范数是稀疏解混中的通用做法, 但 L_1 范数由于其自身特点, 导致对于较大值的惩罚较为严重, 为了解决此问题, 可采用权值矩阵对于 L_1 范数加以调整, 使结果更贴合 L_0 范数。加权稀疏解混模型为:

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

式中: W 表示权值矩阵, $d=1$ 时模型为 L_1 范数的加权稀疏模型, $d=2$ 时为 L_2 范数的加权稀疏模型。

2 本文模型及求解方法

2.1 模型介绍

由上述内容可知, 以加权形式来促进稀疏约束是可行的, 由此, 本文结合加权 L_2 范数模型与高光谱图像的非局部高阶空间信息, 提出一种基于非局部相似性的双重加权稀疏解

混算法 NLSDWSU, 该算法模型为:

$$\min_X \frac{1}{2} \|AX - Y\|_F^2 + \lambda \| (w_1 \odot w_2) \odot X \|_{2,1} \quad \text{s.t. } X \geq 0 \quad (6)$$

式中: 引入了两个不同的加权项, W_1 为光谱加权项:

$$W_1^{t+1} = \frac{1}{|x_{ij}^t| + \varepsilon} \quad (7)$$

以图像的光谱信息为基础, 形成加约束矩阵。 W_2 为空间约束项:

$$W_{2,ij}^{t+1} = \frac{1}{N(x_{ij}^t) + \varepsilon} \quad (8)$$

式中: $N(x_{ij}^t) = \sum_{q=1}^Q w(x_{ij}, x_{ij}^q) x_{ij}^q$ 表示在足够大的窗口内寻找与像元相似的 Q 个像元, 然后用其加权平均来表示 x_{ij} 。

$W(\cdot) = \exp\{-\|x_i - x_j^q\|_2^2\}$ 考虑在 24 连通区域内寻找相似块, 窗口大小为 8 连通。

2.2 模型求解

对于加权模型的求解, 通常选择结合交替方向乘法 (alternating direction method of multipliers, ADMM)^[20]。本模型使用内外双循环结构结合 ADMM 进行求解, 将两个权重矩阵放在外部循环中进行迭代更新, 将丰度矩阵 X 及拉格朗日乘子相关内容放在内部循环中反复迭代以取得较好的解混效果, 具体如下所述。

式 (6) 可转换为无约束等效形式:

$$\min_{U, V_1, V_2, V_3} \frac{1}{2} \|V_1 - Y\|_F^2 + \lambda \| (w_1 \odot w_2) \odot V_2 \|_{2,1} + t_{R+}(V_3) \quad (9)$$

式 (9) 可以写为以下简约形式:

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

式中:

$$V = (V_1, V_2, V_3) \quad (11)$$

$$g(V) = \frac{1}{2} \|V_1 - Y\|_F^2 + \lambda \| (w_1 \odot w_2) \odot V_2 \|_{2,1} + t_{R+}(V_3) \quad (12)$$

$$G = \begin{bmatrix} A \\ I \\ I \end{bmatrix}, B = \begin{bmatrix} -I & 0 & 0 \\ 0 & -I & 0 \\ 0 & 0 & -I \end{bmatrix} \quad (13)$$

式 (10) 可用 ADMM 求解, 迭代流程如算法 1 所示。

算法 1 NLSDWSU 迭代流程

输入: 设 $k, t=0, \lambda, \mu, \varepsilon > 0, U^0, V_1^0, V_2^0, V_3^0, D_1^0, D_2^0, D_3^0$

输出: U

(1) 循环

$$(2) W_1^{t+1} = \frac{1}{|x_{ij}^t| + \varepsilon}$$

$$(3) W_{2,ij}^{t+1} = \frac{1}{N(x_{ij}^t) + \varepsilon}$$

(4) 循环

$$(5) U^{t+1} \leftarrow (A^T A + 2I)^{-1} (A^T (V_1^t + D_1^t) + (V_2^t + D_2^t) + (V_3^t + D_3^t))$$

$$(6) \quad V_1^{t+1} \leftarrow \frac{1}{1+\mu} [Y + \mu(AU^t + D_1^t)]$$

$$(7) \quad V_2^{t+1} \leftarrow \text{vect} - \text{soft}(U^{t+1} - D_2^t, \frac{\lambda}{\mu} W_1^k W_2^k)$$

$$(8) \quad V_3^{t+1} \leftarrow \max(U^{t+1} - D_3^t, 0)$$

$$(9) \quad D_1^{t+1} \leftarrow D_1^t - AU^{t+1} + V_1^{t+1}$$

$$(10) \quad D_2^{t+1} \leftarrow D_2^t - U^{t+1} + V_2^{t+1}$$

$$(11) \quad D_3^{t+1} \leftarrow D_3^t - U^{t+1} + V_3^{t+1}$$

(12) 更新迭代次数:

$$(13) \quad t \leftarrow t + 1$$

$$(14) \quad k \leftarrow k + 1$$

(15) 直到满足迭代条件

3 实验评估

为了验证 NLSDWSU 的可行性, 分别在模拟和真实数据集上进行了实验验证。

3.1 模拟数据集

3.1.1 数据集介绍

半监督解混方法通常需要使用光谱库, 本文选择使用由美国地质调查局 USGS 公开的光谱库中部分光谱组成的子库 A_1 , 其中包含了 240 种不同的物质类型, 具有 224 个光谱波段。本次模拟实验中所用到的数据集是由 A_1 中随机选择的 9 个端元光谱组成的, 并在数据集中添加了独立同分布的高斯噪声。模拟数据的像素大小为 100×100 , 224 波段, 9 种端元的真实丰度分布图如图 1 所示。




图 1 端元的真实丰度分布

可以看出, 不同的端元具有不同的分布形状, 且均有一定的差异性, 这有助于测试算法的空间表现。

3.1.2 评价指标介绍

为更好地对比几种算法之间的优缺点, 本文中 choice 使用 $RMSE$ 、 P_s 、 $Sparsity$ 三项指标来对在 $SNR=30$ 的情况下各算法的表现情况进行评价。现对三项指标的计算方式及评估项目分别进行介绍。

(1) 均方根误差 $RMSE$

$$RMSE = \sqrt{\frac{1}{mn} \sum_{i=1}^m \sum_{j=1}^n (x_{ij} - \hat{x}_{ij})^2} \quad (14)$$

式中: x_{ij} 和 $\hat{x}_{ij}$ 分别为参考丰度矩阵和估计丰度矩阵中的值, mn 为估计丰度矩阵中总元素数目, $RMSE$ 指标用于比较估计丰度与参考丰度矩阵之间的差值, 其数值越小, 意味着所测算法的精度越高。

(2) 成功概率 P_s

$$P_s = P\left(\frac{\|X - \hat{X}\|^2}{\|X\|^2} \leq \text{threshold}\right) \quad (15)$$

成功概率 P_s 可有效反映出算法的稳定性。本文参考了文献 [14] 中对于 threshold 的设置, 即当比值小于 5 dB (3.16) 时, 丰度矩阵的重构成功率为 100%。

(3) 稀疏性 $Sparsity$

$$Sparsity = \frac{s}{mn} \quad (16)$$

稀疏性 $Sparsity$ 被用来测试矩阵的稀疏程度。 s 表示估计丰度矩阵中大于 0.005 的数值数目。 $Sparsity$ 越小, 意味着估计结果的稀疏性越高。

3.1.3 实验结果及分析

在模拟数据集上对 SUnSAL、CLSunSAL、SUnSAL-TV 和 NLSDWSU 四种算法进行了对比实验, 各个算法的指标评价情况如表 1 所示, 对于四种算法的评价指标来说, 从 $RMSE$ 表示出的误差情况来看, NLSDWSU 的误差较小, 具有相对较高的估计精度。从四种算法的成功概率来看, NLSDWSU 具有较高的稳定性, 其次是添加了邻域信息的 SUnSAL-TV 算法, 说明空间信息对于提升算法的稳定性具有一定帮助。从稀疏性指标反馈出的情况来看, 受到行稀疏约束及邻域信息的影响, CLSunSAL 和 SUnSAL-TV 反而包含较多噪点, 这一问题也可从丰度结果的对比图中看出。而在四种算法中 NLSDWSU 的估计结果中稀疏程度相对较高, 也反映出通过加权形式来加强 L2 范数的约束效果, 能够在一定程度上缓解行稀疏约束带来的平滑问题。

表 1 评价结果

算法	$RMSE$	P_s	$Sparsity$
SUnSAL	0.362 0	0.600 1	0.045 6
CLSunSAL	0.298 3	0.774 5	0.074 2
SUnSAL-TV	0.246 8	0.809 1	0.067 2
NLSDWSU	0.144 7	0.945 9	0.032 0

结果对比如图 2 所示, 其中展示了四种算法对于端元 1、3、7 的估计丰度图及真实丰度图之间的对比。从丰度图的对比情况来看, SUnSAL 对于端元 3 和端元 7 的估计结果不够理想, CLSunSAL 对于端元 1 和端元 3 的估计结果与真实丰度分布之间存在较大差异, SUnSAL-TV 从估计的丰度图来

看出现了较为明显的平滑现象，这与其采用的局部空间信息策略有较大关联。NLSDWSU 表现出更好的细节处理能力，但对端元 7 中一些分布较少的地方测试结果存在误差。




图2 丰度结果图对比

综上所述，NLSDWSU 在模拟数据集上具有相对较好的表现，说明算法在端元分布较为复杂的情况下也能取得不错的估计结果。

3.2 真实数据集

3.2.1 数据集介绍

Cuprite 数据集是光谱解混工作中较为常用的数据集之一，实验中所用数据集是其中的一个子块，像素大小为 250×191 ，波段数为 188 个，如图 3 所示。其原始数据来自美国内华达州拉斯维加斯的 Cuprite 矿区，其矿产分布图如图 4 所示。




图3 Cuprite 数据集的图像立方体




图4 内华达州铜矿区矿产分布图

3.2.2 实验结果及分析

在 Cuprite 数据集子集上对 SUnSAL、CLSUnSAL、SUnSAL-TV 和 NLSDWSU 几种算法进行实际测试，取明矾石、水铍长石和玉髓的丰度图进行对照，结果如图 5 所示（从左到右依次为明矾石、水铍长石和玉髓）。




图5 算法的丰度估计结果对比

从图 5 中结果可以看出，若仅查看明矾石的丰度结果图，四种算法基本都取得了较好的解混效果，但对于其中丰度分布较为密集的区域，四种算法的解混结果具有一定的差别。对于水铍长石的丰度结果图来说，SUnSAL 算法整体来看与其余三种算法存在一定的差别，CLSUnSAL 算法结果图中的细致程度不够，对于水铍长石分布较为密集的区域存

在一定的模糊情况,应当是协同稀疏的约束所导致的误差,NLSDWSU在加权稀疏项的约束之下,对于丰度图中过度的平滑效果进行了抑制,从而取得了相对较好的结果。而对于玉髓的丰度结果图来说,CLSunSAL和SUnSAL-TV两种算法均表现出较强的模糊化效果,说明协同稀疏项与局部空间信息的约束对于算法本身产生了较大的影响,相对来说,SUnSAL与NLSDWSU对于玉髓的整体分布能给出更为详细的结果。综合来看,NLSDWSU算法具有一定的抗噪声能力,且对于行稀疏约束所导致的过度平滑问题,能有效解决。

4 结论

本文提出了一种基于非局部信息的双重加权协同稀疏解混算法,该算法在协同稀疏解混模型的基础之上,引入了非局部的空间信息作为约束矩阵来解决协同稀疏项所导致的过度平滑问题,就模拟和真实数据集的验证情况来看,NLSDWSU算法具有较好的解混表现。

参考文献:

- [1] 张兵. 当代遥感科技发展的现状与未来展望[J]. 中国科学院院刊, 2017, 32(7): 774-784.
- [2] BIOUCAS-DIAS J M, PLAZA A, CAMPS-VALLS G, et al. Hyperspectral remote sensing data analysis and future challenges[J]. IEEE geoscience and remote sensing magazine, 2013, 1(2): 26-36.
- [3] MARTIN G, PLAZA A. Region-based spatial preprocessing for endmember extraction and spectral unmixing[J]. IEEE journal of selected topics in applied earth observations and remote sensing, 2011, 8(4): 745-749.
- [4] MOUSSAOUI S, HAUKSDÓTTIR H, SCHMIDT F, et al. On the decomposition of mars hyperspectral data by ica and bayesian positive source separation [J]. Neurocomputing, 2007, 71(10): 2194-2208.
- [5] MARTIN G. Spatial-spectral preprocessing prior to endmember identification and unmixing of remotely sensed hyperspectral data[J]. IEEE journal of selected topics in applied earth observations and remote sensing, 2012, 5(2): 380-395.
- [6] KESHAVA N, MUSTARD J F. Spectral unmixing[J]. IEEE signal processing magazine, 2002, 19(1): 44-57.
- [7] SUN L, WU Z, 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.
- [8] CANDES E J, TAO T. Decoding by linear programming[J]. IEEE transactions on information theory, 2005, 51(12): 4203-4215.
- [9] BIOUCAS-DIAS J M, FIGUEIREDO M A. Alternating direction algorithms for constrained sparse regression: Application to hyperspectral unmixing[C]//2010 2nd Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing. Piscataway: IEEE, 2010: 1-4.
- [10] IORDACHE M D, BIOUCAS-DIAS J, PLAZA A. Collaborative sparse regression for hyperspectral unmixing[J]. IEEE transactions on geoscience and remote sensing, 2013, 52(1): 341-354.
- [11] 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.
- [12] ZHENG C Y, LI H, WANG Q, et al. Reweighted sparse regression for hyperspectral unmixing[J]. IEEE transactions on geoscience and remote sensing, 2015, 54 (1): 479-488.
- [13] ZHANG S, LI J, LI H C, et al. Spectral-spatial weighted sparse regression for hyperspectral image unmixing[J]. IEEE transactions on geoscience and remote sensing, 2018, 56(6): 3265-3276.
- [14] 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.
- [15] ZHANG S, 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.
- [16] ZHONG Y, FENG R, ZHANG L. 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.
- [17] TANG M, QU Y, QI H. Hyperspectral nonlinear unmixing via generative adversarial network[C]//IGARSS 2020-2020 IEEE International Geoscience and Remote Sensing Symposium. Piscataway: IEEE, 2020: 2404-2407.
- [18] BIOUCAS-DIAS J M, ANTONIO P, NICOLAS D, 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.
- [19] 冯如意, 王力哲, 曾铁勇. 高光谱遥感图像亚像元信息提取方法综述 [J]. 测绘学报, 2023, 52(7): 1187-1201.
- [20] 黄伟, 伍飞扬, 孙乐. 基于局部加权低秩先验的高光谱稀疏解混方法 [J]. 应用科学学报, 2020, 38(6): 890-905.

【作者简介】

李勇新(1997—), 男, 河南安阳人, 硕士, 研究方向: 图形图像与智能信息处理。

(收稿日期: 2023-12-28)