

改进的空间信息约束非负矩阵分解的高光谱 图像解混算法

李登刚, 王忠美*

湖南工业大学交通工程学院, 湖南 株洲 412007

摘要 传统的高光谱混合像元分解方法仅考虑高光谱图像的几何特性或者丰度的稀疏性, 而忽略高光谱数据的光谱空间特性。当原图像中不存在纯净像元时, 分解精度将严重下降。为了解决这些问题, 提出一种改进的空间信息约束非负矩阵分解的解混算法, 该方法充分利用高光谱图像的空间信息和稀疏性, 提高了传统非负矩阵分解算法的性能。合成的模拟图像和真实的高光谱图像实验表明, 该方法克服了传统方法对噪声的敏感性以及对纯像元的依赖性。

关键词 图像处理; 高光谱混合像元分解方法; 非负矩阵分解; 光谱空间信息; 稀疏性

中图分类号 TP751

文献标识码 A

doi: 10.3788/LOP56.111006

Improved Spatial Information Constrained Nonnegative Matrix Factorization Method for Hyperspectral Unmixing

Li Denggang, Wang Zhongmei*

College of Traffic Engineering, Hunan University of Technology, Zhuzhou, Hunan 412007, China

Abstract The traditional hyperspectral unmixing methods only consider the geological properties of hyperspectral images or the sparse properties of abundance and neglect the spectral spatial information of hyperspectral data. Thus when the pure pixels are missing, the unmixing accuracy is significantly reduced. In order to overcome these limitations, an improved spatial information constrained nonnegative matrix factorization method for unmixing is proposed. This method fully uses the spatial information and the sparse properties of hyperspectral images, and thus the properties of the traditional nonnegative matrix factorization methods are improved. Both the synthetic simulation images and the experimental results show that the proposed method has overcome the noise-sensitivity and the dependence on pure pixels of the traditional methods.

Key words imaging processing; hyperspectral unmixing method; nonnegative matrix factorization; spectral spatial information; sparseness

OCIS codes 100.4145; 300.6320; 300.6170

1 引言

高光谱图像拥有较高的光谱分辨率, 近年来在遥感领域得到了广泛应用^[1-3]。空间分辨率的限制导致高光谱图像中广泛存在混合像元, 混合像元是指单个像素所包含的实际地物往往不止一种, 而是多种地物的混合。混合像元严重影响高光谱图像的后续分析和处理。高光谱图像混合像元分解旨在将

混合的像元分解为各种地物(端元), 及对应所占有的组分(丰度)^[4]。

为了解决混合像元分解问题, 近年来学者们提出了诸多算法。这些算法可以分两步法(TSM)和一步法(SSM)两类。其中两步法从混合像元中提取各个物质的端元, 然后利用端元反演得到丰度组分。典型的两步法包括顶点成分分析法^[5](VCA)、N-FINDR^[6]、纯像素指数法^[7](PPI)、基于变量分裂与

收稿日期: 2018-11-23; 修回日期: 2018-12-21; 录用日期: 2019-01-02

基金项目: 湖南省教育厅科学研究项目(18C0513)

* E-mail: ldwangzm2008@163.com

增广拉格朗日的单形体识别法^[8] (SISAL)等,得到端元后,采用全约束最小二乘法^[9] (FCLS)计算丰度组分。一步法可以同时得到端元和丰度,常见的一步法有独立成分分析法^[10] (ICA)和非负矩阵分解^[11-19] (NMF)等,一步法可以避免两步法中提取端元时所产生的累积误差。

高光谱图像中是否存在纯净像元是未知的,因此,已有的以纯像元存在为前提的端元提取算法(VCA、PPI等)不能准确提取端元。NMF不需要原图像中存在纯净像元,近年来得到广泛关注。但NMF算法的解非唯一,为了使NMF具有唯一解,需在NMF的目标函数中加入约束项,在目标函数中加入端元约束项的方法相继出现,如最小体积约束非负矩阵分解^[11] (MVCNMF)、端元相异性约束非负矩阵分解^[12] (EDCNMF)和最小距离约束非负矩阵分解^[15] (MDCNMF)等;同时,考虑丰度的稀疏性,在目标函数中加入稀疏约束项的方法也受到关注,如稀疏和平滑性约束非负矩阵分解(NMFSSC)^[16]、S方法约束非负矩阵分解(SMCNMF)^[17]以及L1/2稀疏约束非负矩阵分解(L1/2NMF)^[18]等。

上述方法虽有效利用端元和丰度的相关特性,但忽略了高光谱图像的空间信息。基于图论约束的非负矩阵分解^[19] (GLNMF)充分利用高光谱图像的空间信息,但忽略了端元和丰度的自然特性。本文以GLNMF为基本框架,同时将端元和丰度的自然特性加入目标函数进行研究。

2 空间信息约束的非负矩阵分解

2.1 基于图论的非负矩阵分解

在进行混合像元分解时,为了提高分解的精度,需要充分利用高光谱图像的内在流形结构信息^[20]。传统的混合像元分解算法仅考虑全局信息,忽略了数据局部几何结构信息。而原始图像与不同端元的丰度图之间存在紧密联系,这些局部信息非常重要。以 $\mathbf{X}=[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n] \in \mathbf{R}^{m \times n}$ 表示原始高光谱图像矩阵, m 和 n 分别为矩阵 \mathbf{X} 的行和列的数量,端元矩阵为 $\mathbf{A}=[\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_l] \in \mathbf{R}^{m \times l}$, m 和 l 分别为矩阵 \mathbf{A} 的行和列的数量,丰度矩阵为 $\mathbf{S}=[\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_n] \in \mathbf{R}^{l \times n}$, l 和 n 分别为矩阵 \mathbf{S} 的行和列的数量,则线性混合模型的表达式为

$$\mathbf{x}_i = \mathbf{A}\mathbf{s}_i, \quad (1)$$

式中: $\mathbf{x}_i \in \mathbf{R}^m$, $\mathbf{s}_i \in \mathbf{R}^l$, \mathbf{s}_i 为矩阵 \mathbf{S} 的任一列向量, s_i

可视作 \mathbf{x}_i 在新的 l 维空间的表示。矩阵 \mathbf{A} 的列向量构成新空间的基向量,其在原始图像和不同端元丰度图像(\mathbf{x}_i 与 \mathbf{s}_i)之间建立了联系。如果原始图像中的两个像素点非常相似,那么这两个点在新基向量所构成的空间中也将会非常相似。对于混合像元分解问题,如果 m 维空间中的任意两列数据 \mathbf{x}_i 和 \mathbf{x}_j (i, j 为列序号)非常相似,则其丰度 \mathbf{s}_i 和 \mathbf{s}_j 也非常相似,该假设称之为流形假设,已在高光谱图像分类^[21]领域得到了广泛应用。

NMF由Lee等^[22]提出,最初应用在数据降维等领域。给定一个非负矩阵 $\mathbf{Y} \in \mathbf{R}^{n \times m}$ 及一个正常数 $r, r < \min(n, m)$,NMF旨在寻找2个低秩矩阵 $\mathbf{G} \in \mathbf{R}^{n \times r}$ 和 $\mathbf{H} \in \mathbf{R}^{r \times m}$,使得 \mathbf{Y} 和 \mathbf{GH} 之间的误差最小,即目标函数为

$$\min f(\mathbf{G}, \mathbf{H}) = \|\mathbf{Y} - \mathbf{GH}\|^2 / 2, \text{ s.t. } \mathbf{G}, \mathbf{H} \geq 0. \quad (2)$$

假设高光谱图像为 $\mathbf{X}=[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n] \in \mathbf{R}^{m \times n}$,其每一列 $\{\mathbf{x}_i\}_{i=1}^n$ 可视作 m 维空间中的一个数据点。为了描述数据的内在几何结构,考虑分散数据点的最近邻图,假设 \mathbf{x}_i 为 \mathbf{x}_j 的一个近邻,采用热核^[20]构造出图的权重矩阵 \mathbf{W} ,得到权重矩阵元

$$W_{ij} = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / \sigma), \quad (3)$$

式中: σ 为热核参数。从(3)式可以看出,当 \mathbf{x}_i 与 \mathbf{x}_j 距离较近时, W_{ij} 相对较大。如果原始图像中 \mathbf{x}_i 与 \mathbf{x}_j 相距很近,则新空间中 \mathbf{s}_i 和 \mathbf{s}_j 也相近。根据上述分析,将 W_{ij} 加入关于丰度向量 \mathbf{s}_i 与 \mathbf{s}_j 的误差约束项中,可得

$$\frac{1}{2} \sum_{i,j=1}^n W_{ij} \|\mathbf{s}_i - \mathbf{s}_j\|^2 =$$

$$\sum_{i=1}^n D_{ii} \mathbf{s}_i^T \mathbf{s}_i - \sum_{i,j=1}^n W_{ij} \mathbf{s}_i^T \mathbf{s}_j =$$

$$\text{Tr}(\mathbf{SDS}^T) - \text{Tr}(\mathbf{SWS}^T) = \text{Tr}(\mathbf{SLS}^T), \quad (4)$$

式中: $\text{Tr}(\cdot)$ 表示矩阵的迹; \mathbf{D} 为对角矩阵,对角的值为矩阵 \mathbf{W} 各列的和,即满足 $D_{ii} = \sum_j W_{ij}$, $\mathbf{L} = \mathbf{D} - \mathbf{W}$,显然 \mathbf{L} 为一个对称矩阵。(4)式即为流形约束项,最小化(4)式,可以使权重矩阵相对较大的两个像元 \mathbf{x}_i 与 \mathbf{x}_j 所对应的 $\|\mathbf{s}_i - \mathbf{s}_j\|^2$ 误差较小。至此,实现了原始图像非常相近的两个像元在解混后的丰度图像中也非常相近。因此,将(4)式作为约束项加入原NMF的目标函数中,可得基于图论非负矩阵分解算法的目标函数

$$\min f(\mathbf{A}, \mathbf{S}) = \|\mathbf{X} - \mathbf{AS}\|^2 / 2 + \alpha \cdot \text{Tr}(\mathbf{SLS}^T) / 2, \quad (5)$$

式中: $\alpha > 0$ 为流形约束正则化参数。

2.2 基于图论稀疏约束的非负矩阵分解

根据高光谱图像的几何知识^[5],端元分布在图像空间的部分区域,不会充满整个图像空间,对应的丰度存在很多0值,丰度的分布通常具有一定的稀疏性。目前 L1/2NMF^[18]等稀疏约束非负矩阵分解方法在解混领域得到了较好的应用,但在选择不同的初始值时,该算法结果的差异很大,且对噪声非常敏感。近年来,Lu等^[19]在 L1/2NMF的基础上,将流形约束加入到了目标函数中,提出了 GLNMF,该算法既考虑丰度分布的稀疏性,同时充分利用高光谱数据的内在几何结构信息,其目标函数为

$$\min f(\mathbf{A}, \mathbf{S}) = \|\mathbf{X} - \mathbf{AS}\|^2/2 + \lambda \cdot \|\mathbf{S}\|_{1/2} + \mu \cdot \text{Tr}(\mathbf{SLS}^T)/2, \text{ s.t. } \mathbf{A} \geq 0, \mathbf{S} \geq 0, \mathbf{1}_l^T \mathbf{S} = \mathbf{1}_n^T, \quad (6)$$

式中: λ 为稀疏系数,其值取决于各种端元物质丰度的稀疏度; μ 为流形约束的正则化参数,主要控制平滑度。通过梯度下降法迭代求解端元矩阵 \mathbf{A} 和丰度矩阵 \mathbf{S} ,则有

$$\mathbf{A} \leftarrow \mathbf{A} \cdot \mathbf{XS}^T ./ \mathbf{ASS}^T \mathbf{S} \leftarrow \mathbf{S} \cdot (\mathbf{A}^T \mathbf{X} + \mu \cdot \mathbf{SW}) ./ (\mathbf{A}^T \mathbf{AS} + \lambda \cdot \mathbf{S}^{-1/2}/2 + \mu \cdot \mathbf{SD}), \quad (7)$$

式中: \cdot 和 $./$ 分别表示矩阵按元素相乘和相除; $\cdot^{-1/2}$ 表示矩阵按元素取开方后求倒数。

3 改进的空间光谱信息约束的非负矩阵分解

正如文献^[19]所述,利用 L1/2 范数作为目标函数的稀疏性约束项时,存在算法对噪声敏感、结果对初始值的依赖性较大等问题。为了解决这些问题,充分利用丰度的稀疏特性,改进丰度的稀疏性约束项,提出一种改进的空间信息约束的非负矩阵分解算法。

首先,考查二次稀疏约束函数

$$f(s_{ij}) = \sigma (s_{ij} - 1/r)^2, \quad (8)$$

式中:参数 $\sigma > 0$ 控制稀疏的收敛速度; s_{ij} 为丰度向量元素,其每一列应满足和为1的约束,即 $\sum_i s_{ij} = 1, 0 < s_{ij} < 1$; r 为端元的个数。对于该约束函数,显然当 $s_{ij} = 1/r$ 时,约束函数取得最小值0。为了使问题形象化,这里假设 $\sigma = 4, r = 2$,并给出二次函数的图形,结果如图1所示。

从图1可以看出, $0 \leq s_{ij} \leq 1$ 内,当 $\mathbf{S} = (0.5, 0.5)^T$ 时,二次函数取得最小值,稀疏性最低;而当 $\mathbf{S} = (0, 1)^T$ 或者 $\mathbf{S} = (1, 0)^T$ 时,二次函数取得




图1 二次函数抛物线($\sigma=4, r=2$)

Fig. 1 Quadratic parabola ($\sigma=4, r=2$)

最大值,稀疏性最高。离中心对称轴越远,稀疏性越高;而离中心对称轴越近时,稀疏性越低。所以当 r 增大时,抛物线的对称轴将向左移动,此时,丰度将在 $\mathbf{S} = (1, 0)$ 处稀疏性最高。根据上述理论分析,对 $f(\mathbf{S})$ 进行累加操作,从而得到稀疏约束函数

$$J(\mathbf{S}) = \sum_{i=1}^l \sum_{j=1}^n f(s_{ij}) = \sum_{i=1}^l \sum_{j=1}^n \sigma (s_{ij} - 1/r)^2. \quad (9)$$

结合(5)式所示的基于图论的非负矩阵分解算法与(9)式所示的稀疏约束函数,提出改进的空间信息约束的非负矩阵分解算法(ASSNMF),其目标函数为

$$\min f(\mathbf{A}, \mathbf{S}) = \|\mathbf{X} - \mathbf{AS}\|^2/2 + \alpha \cdot \text{Tr}(\mathbf{SLS}^T)/2 - \frac{\beta}{2} \sum_{i=1}^l \sum_{j=1}^n (s_{ij} - 1/r)^2, \text{ s.t. } \mathbf{A} \geq 0, \mathbf{S} \geq 0, \mathbf{1}_l^T \mathbf{S} = \mathbf{1}_n^T, \quad (10)$$

式中: α 和 β 分别为流形约束和稀疏约束的正则化参数。目标函数关于矩阵 \mathbf{A} 和 \mathbf{S} 是非凸的,无法直接对其求取全局最优解,因此本文通过迭代求解法求解全局最优解。根据梯度下降法,得到端元矩阵 \mathbf{A} 和 \mathbf{S} 的更新法则

$$\mathbf{A} \leftarrow \mathbf{A} \cdot \mathbf{XS} ./ \mathbf{ASS}^T + \lambda \mathbf{S} \leftarrow \mathbf{S} \cdot (\mathbf{A}^T \mathbf{X} + \alpha \mathbf{SW} + \beta \mathbf{S}) ./ (\mathbf{A}^T \mathbf{X} + \alpha \mathbf{SD} + \beta/r + \lambda), \quad (11)$$

式中: \mathbf{W} 为(3)式所表示的权重矩阵; λ 为一个极小的正常数,作用是使迭代过程中分母不为0。显然(11)式仅存在乘法和加法运算,保证了结果的非负性。与此同时,考虑到丰度的和为1约束,在矩阵迭代运算前进行扩展,即

$$\bar{\mathbf{X}} = [\mathbf{X} \ \delta \mathbf{1}^T]^T, \bar{\mathbf{A}} = [\mathbf{A} \ \delta \mathbf{1}^T]^T, \quad (12)$$

式中: $\mathbf{1}^T$ 为元素全为1的向量; δ 为控制和为1约束的常数。在每次迭代更新之前,分别用 $\bar{\mathbf{X}}$ 和 $\bar{\mathbf{A}}$ 代替 \mathbf{X} 和 \mathbf{A} ,并在每次迭代求解完成之后,从 $\bar{\mathbf{X}}$ 和 $\bar{\mathbf{A}}$ 中取出原来的 \mathbf{X} 和 \mathbf{A} ,再利用(12)式所示的扩展进行下一次迭代,或者达到停止条件时,停止迭代,输出最终结果。

总结算法的步骤为

Input: 非负图像矩阵 \mathbf{X} 和端元个数 r 。

Output: 端元矩阵 \mathbf{A} 和丰度矩阵 \mathbf{S} 。

- 1) 初始化端元 \mathbf{A} 和丰度矩阵 \mathbf{S} , 设置最近邻阶数 k , 权重参数 α, β , 参数 δ, λ 和 σ ;
- 2) 规范化丰度矩阵 \mathbf{S} , 使其满足列和为 1 约束, 按照(12)式变换矩阵 \mathbf{X} 为 $\bar{\mathbf{X}}$, \mathbf{A} 为 $\bar{\mathbf{A}}$;
- 3) 按照(11)式迭代计算矩阵 \mathbf{A} 和 \mathbf{S} ;
- 4) 达到停止条件时, 停止迭代, 输出结果。

4 实验分析

通过真实的高光谱数据和实验合成的数据验证所提出方法的有效性, 并比较改进的 ASSNMF 与原始的 GLNMF 算法^[19]、VCA-FCLS^[5,9]和 L1/2NMF^[18]等方法。采用光谱角距离(SAD)和方均根误差(RMSE)评价算法性能。评价指标的定义为

$$R_{\text{SAD}} = (180/\pi) \cdot \arccos(\mathbf{a}^T \hat{\mathbf{a}} / \|\mathbf{a}\|_2 \|\hat{\mathbf{a}}\|_2), \quad (13)$$

$$R_{\text{RMSE}} = \left[\sum_{j=1}^N (s_j - \hat{s}_j)^2 / N \right]^{1/2}, \quad (14)$$

式中: R_{SAD} 衡量估计端元和真实端元之间的相似性, \mathbf{a} 与 $\hat{\mathbf{a}}$ 分别为真实的端元向量和估计的端元向量; R_{RMSE} 为评价丰度相似性的指标; \mathbf{s} 与 $\hat{\mathbf{s}}$ 分别为真实丰度向量和估计丰度向量; N 为丰度图像像素的个数。 R_{SAD} 和 R_{RMSE} 越小, 说明估计值和真实值越相近, 误差越小, 分解效果越好。

4.1 模拟高光谱图像

为了测试算法性能, 从美国地质勘探局(USGS)的光谱库中随机选取了 P 种矿物光谱。所选取的光谱包含 224 个波段, 波长范围为 $0.38 \sim 2.5 \mu\text{m}$, 光谱分辨率为 10 nm 。利用胺基黄钾铁矾(Ammonio-Jarosite)、叶蛇纹石(Antigorite)、斧石(Axinite)和光卤石(Carnallite)等 4 种物质生成高光谱图像, 即 $r=4$, 各物质的端元光谱曲线如图 2 所示。参照文献[14]中的方法, 按照如下步骤合成高光谱图像:

- 1) 将大小为 64×64 的模拟图像平分成 8×8 的小块;
- 2) 从光谱库中随机选取某种端元填补各个小块, 使得每个小块中的像素均为纯像元;
- 3) 使用一个 9×9 的低通滤波器生成混合图像, 从而获得每个像素的丰度部分;
- 4) 为了进一步移除纯像元, 并控制丰度的稀疏度, 对于丰度大于某个预设参数 η 的像素, 由全

部的 c 种端元均匀组成的像素所替代, 该混合像素中各种端元的丰度均为 $1/c$; 为了更进一步模拟真实高光谱图像, 并测试所提方法对噪声的敏感性, 充分考虑可能出现的噪声和误差, 因此向图像添加不同信噪比(SNR)的零均值高斯噪声, SNR 定义为

$$R_{\text{SNR}} = 10 \lg[E(\mathbf{x}^T \mathbf{x}) / E(\mathbf{e}^T \mathbf{e})], \quad (15)$$

式中: \mathbf{x} 和 \mathbf{e} 分别为像素的观测向量和噪声向量; $E(\cdot)$ 表示期望。




图 2 从 USGS 光谱库中选取的端元
Fig. 2 Endmembers selected from USGS spectral library

为了确定 ASSNMF 算法中各个参数的最优值, 使用上述模拟数据完成测试。首先, 向模拟数据中添加 $R_{\text{SNR}} = 20 \text{ dB}$ 的零均值高斯噪声, $\eta = 0.8$; 同时, 为了消除端元和丰度矩阵初始化对结果的影响, 采用 VCA-FCLS^[5,9] 作为端元矩阵和丰度矩阵的初始化方法, 并在对比实验中保持初始值不变; 为了与 GLNMF 算法保持一致, 将容许误差和最大迭代次数作为迭代停止条件, 容许误差和最大迭代次数分别设为 10^{-4} 和 3000。

参考 GLNMF^[19] 相关的参数设置, 设定 $\delta = 15$ 、 $\lambda = 10^{-9}$, 确定流形约束和丰度约束的正则化参数 α 和 β 。固定权重矩阵 \mathbf{W} 的参数为 $k = 5$, $\sigma = 1$, 流形约束 $\alpha = 0.1$, 设置 β 为 $0.008 \sim 0.1$ 。在不同的 β 值下, 利用所提 ASSNMF 算法求取 R_{SAD} 和 R_{RMSE} , 结果如图 3 所示。从图 3(a) 可以看出, 当 $\beta < 0.01$ 时, R_{SAD} 随 β 的增加而减小; 而当 $\beta > 0.01$ 时, R_{SAD} 随 β 的增加而增加, 因此, R_{SAD} 在 $\beta = 0.01$ 时取得最小值。从图 3(b) 同样可以看出, 在 $\beta < 0.03$ 时, R_{RMSE} 基本趋于平稳; 而当 $\beta > 0.03$ 时, R_{RMSE} 显著增加。所以综合 R_{SAD} 和 R_{RMSE} 的变化情况, 选择参数 β 的最优值为 0.01。

采取同样的方法, 固定稀疏约束参数 $\beta = 0.01$, 设置 α 为 $0.01 \sim 0.15$ 。图 4(a) 和图 4(b) 分别给出了不同 α 下所提 ASSNMF 算法的 R_{SAD} 和 R_{RMSE} 变

化情况。从图 4 可以看出, R_{SAD} 随着 α 的增大而逐渐增加; 而 R_{RMSE} 随着 α 的增大而缓慢减小。为此,

对 α 选择一个折中值, 让 R_{SAD} 和 R_{RMSE} 都尽可能小, 最终选择参数 α 的最优值为 0.05。




图 3 R_{SAD} 和 R_{RMSE} 随 β 的变化情况。(a) R_{SAD} ; (b) R_{RMSE}
Fig. 3 R_{SAD} and R_{RMSE} versus β . (a) R_{SAD} ; (b) R_{RMSE}




图 4 R_{SAD} 和 R_{RMSE} 随 α 的变化情况。(a) R_{SAD} ; (b) R_{RMSE}
Fig. 4 R_{SAD} and R_{RMSE} versus α . (a) R_{SAD} ; (b) R_{RMSE}

上述实验确定了流形约束和稀疏性约束的参数分别为 $\alpha=0.05, \beta=0.01$ 。接着确定权重矩阵 \mathbf{W} 的参数 k 和 σ 。采用类似的方法, 首先固定 σ , 改变近邻数 k 。所提 ASSNMF 算法在不同近邻数 k 下

R_{SAD} 和 R_{RMSE} 的变化情况如图 5 所示。由图 5 可知, $3 < k < 10$ 时, R_{SAD} 随着 k 的增大而增加, 而 R_{RMSE} 随着 k 的增大而平稳小幅下降。因此, 为了使 R_{SAD} 和 R_{RMSE} 尽可能达到最优, 选择 $k=5$ 为最佳参数值。




图 5 R_{SAD} 和 R_{RMSE} 随 k 的变化情况。(a) R_{SAD} ; (b) R_{RMSE}
Fig. 5 R_{SAD} and R_{RMSE} versus k . (a) R_{SAD} ; (b) R_{RMSE}

然后, 固定 $k=5$, 改变参数 σ 。所提 ASSNMF 算法在不同的 σ 下的 R_{SAD} 和 R_{RMSE} 变化情况如图 6 所示。由图 6 可以看出, 当 σ 增大到 0.1 后, R_{SAD} 和 R_{RMSE} 基本趋于稳定, R_{SAD} 小幅增加, R_{RMSE} 小幅减小; σ 足够大时, 热核加权矩阵更近似于 $0 \sim 1$ 加权。

因此, 综合考虑 R_{SAD} 和 R_{RMSE} 曲线的变化情况, 最终选择 $\sigma=1$, 以使端元和丰度都能达到一个稳定的状态。

上述实验最终确定的各个参数的最优值为 $\alpha=0.05, \beta=0.01, k=5, \sigma=1$ 。




图 6 R_{SAD} 和 R_{RMSE} 随 σ 的变化情况。(a) R_{SAD} ; (b) R_{RMSE}

Fig. 6 R_{SAD} and R_{RMSE} versus σ . (a) R_{SAD} ; (b) R_{RMSE}

传统混合像元分解方法对噪声非常敏感,并且高度依赖原始图像中的纯净像元。这里通过 2 个合成数据验证所提出方法的有效性。图 7 给出了不同噪声水平下,原始 GLNMF 方法和所提 ASSNMF 方法、VCA-FCLS 方法以及 L1/2 NMF 等方法进行混合像元分解的效果比较。从

图 7 可以看出,随着噪声的减少(R_{SNR} 增加),上述 4 种方法的分解效果均有所提升。但所提 ASSNMF 算法的分解效果优于原来的 GLNMF 及其他几种方法,对于 R_{RMSE} 效果更明显,这也说明所提出的稀疏约束项可以克服原方法对噪声敏感的问题。

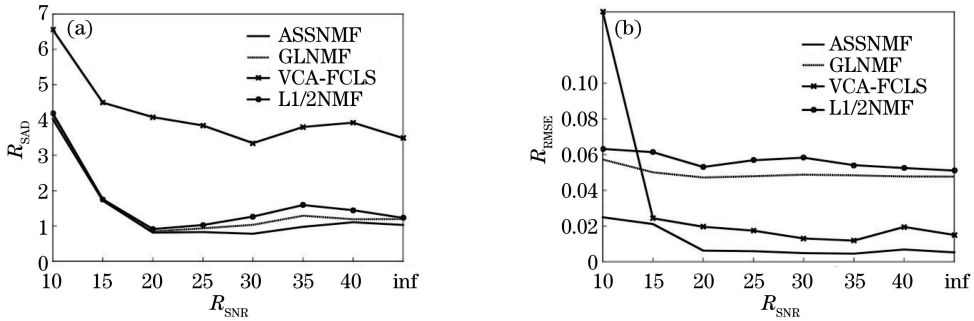


图 7 不同信噪比 R_{SNR} 下的 R_{SAD} 和 R_{RMSE} 。(a) R_{SAD} ; (b) R_{RMSE}

Fig. 7 R_{SAD} and R_{RMSE} versus R_{SNR} . (a) R_{SAD} ; (b) R_{RMSE}

在真实的高光谱图像中,纯净像元存在与否是未知的。从算法的全面性考虑,既要考虑纯净像元存在的情况,也要考虑图像中不存在纯净像元的情况。表 1 和表 2 分别给出了模拟图像中存在纯净像元和不存在纯净像元两种情况下,不同方法所获得的 R_{SAD} 和 R_{RMSE} ,表中粗体表示相应的误差最小。从表 1 和表 2 的结果可以看出,无论是在纯净像元存在的情况,还是在纯净像元不存在的情况,所提 ASSNMF 算法的解混性能均优于原来的 GLNMF 方法以及 VCA-FCLS、L1/2NMF 算法,对于丰度向量效果更明显。结果也进一步说明,所提方法对复杂的地物分布场景具有更强的适应性,并且不需要图像中存在纯净像元。

4.2 真实高光谱图像实验

将所提方法应用于真实的高光谱图像,测试算法在实际高光谱场景中的性能。采用超光谱数字图像光谱仪(HYDICE)收集的城市高光谱图像数

表 1 有无纯净像元下 R_{SAD} 的比较

Table 1 R_{SAD} with and without pure pixels

Algorithm	Without pure pixels	With pure pixels
GLNMF	1.6908	0.3282
ASSNMF	1.6274	0.3138
VCA-FCLS	8.1653	1.1300
L1/2NMF	1.8258	0.3895

表 2 有无纯净像元下 R_{RMSE} 的比较

Table 2 R_{RMSE} with and without pure pixels

Algorithm	Without pure pixels	With pure pixels
GLNMF	0.0472	0.0776
ASSNMF	0.0062	6.9604×10^{-4}
VCA-FCLS	0.0195	8.6333×10^{-4}
L1/2NMF	0.0531	0.0851

据。该图像共有 210 个波段,图像大小为 $307 \text{ pixel} \times 307 \text{ pixel}$ 。为了提高算法的有效性和运算效率,实验去除了信噪比过低以及被水蒸气吸收的那些波段,留下 162 个波段进行后续处理。根据已有的知识及对

该地区的分析可知^[23],该区域共包含屋顶、树木、草地、沥青 4 种物质及其混合。同时选取坐标分别为 (213,124),(31,274),(87,134),(197,62) 的 4 个点的光谱作为上述 4 种物质的参考光谱。

图 8 和表 3 分别给出了所提 ASSNMF 算法分解得到的丰度分布图以及各算法求得的端元光谱与光谱库中参考光谱的 R_{SAD} 值。表 3 中粗体表示相




图 8 ASSNMF 算法解混的丰度图。(a)屋顶;(b)树木;(c)草地;(d)沥青

Fig. 8 Abundance maps after unmixing by ASSNMF method. (a) Roof; (b) tree; (c) meadow; (d) pitch

表 3 各算法提取端元光谱和真实光谱 R_{SAD} 的比较

Table 3 R_{SAD} of real spectra and endmember spectra extracted by each algorithm

Material types	GLNMF	ASSNMF	VCA-FCLS	L1/2NMF
Roof	15.2564	15.1564	22.3564	18.7451
Tree	2.2147	1.8547	3.7852	2.6122
Meadow	8.7893	6.6389	11.2873	8.9657
Pitch	10.7556	10.2568	15.6238	12.3285
Mean	9.2540	8.4767	13.2632	10.6229

5 结 论

分析了传统非负矩阵分解中忽略的空间信息等问题,针对传统空间信息约束非负矩阵分解方法存在的对端元和丰度初始值依赖性大、噪声敏感性差等缺点,对目标函数中光谱结构信息的约束项进行了改进,并提出了一种改进的空间信息约束非负矩阵分解的高光谱图像解混算法。合成的模拟图像和真实高光谱图像实验结果表明,所提算法在解混性能上较原 GLNMF 算法具有一定程度的提高。

参 考 文 献

[1] Zhao C H, Deng W W, Yao X F. Hyperspectral real-time anomaly target detection based on progressive line processing[J]. Acta Optica Sinica, 2017, 37(1): 0128002.

赵春晖, 邓伟伟, 姚浙峰. 基于逐行处理的高光谱实时异常目标检测[J]. 光学学报, 2017, 37(1): 0128002.

应的误差最小,从表 3 可以看出,所提 ASSNMF 方法较原 GLNMF 方法、VCA-FCLS 方法以及 L1/2NMF 方法的解混效果具有明显提高。真实高光谱图像实验也进一步说明,改进的稀疏约束项对复杂的地物分布具有更强的适应性,克服了真实高光谱图像场景中噪声敏感性及对纯净像元的依赖性的问题,实验结果得到明显的提高。

[2] Liao J S, Wang L G. Hyperspectral image classification method based on fusion with two kinds of spatial information[J]. Laser & Optoelectronics Progress, 2017, 54(8): 081002.

廖建尚, 王立国. 两类空间信息融合的高光谱图像分类方法[J]. 激光与光电子学进展, 2017, 54(8): 081002

[3] Dong A G, Li J X, Zhang B, *et al.* Hyperspectral image classification algorithm based on spectral clustering and sparse representation[J]. Acta Optica Sinica, 2017, 37(8): 0828005.

董安国, 李佳逊, 张蓓, 等. 基于谱聚类和稀疏表示的高光谱图像分类算法[J]. 光学学报, 2017, 37(8): 0828005.

[4] Zhang B, Gao L R. Hyperspectral image classification and target detection [M]. Beijing: Science Press, 2011:15-23.

张兵, 高连如. 高光谱图像分类与目标探测[M]. 北京: 科学出版社, 2011: 15-23.

[5] Nascimento J M P, Dias J M B. Vertex component analysis: a fast algorithm to unmix hyperspectral data [J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(4): 898-910.

[6] Winter M E. N-FINDR: an algorithm for fast autonomous spectral end-member determination in hyperspectral data[J]. Proceedings of SPIE, 1999, 3753: 266-275.

[7] Boardman J W, Kruse F A, Green R O. Mapping target signatures via partial unmixing of AVIRIS data [C]//Proceedings of Summaries of the Fifth Annual

- JPL Airborne Earth Science Workshop, January 23-26, 1995, Pasadena, USA. Pasadena: AVIRIS Workshop, 1995: 23-26.
- [8] Bioucas-Dias J M. A variable splitting augmented Lagrangian approach to linear spectral unmixing[C]// 2009 First Workshop on Hyperspectral Image and Signal Processing: Evolution in Remote Sensing, August 26-28, 2009, Grenoble, France. New York: IEEE, 2009: 5289072.
- [9] Heinz D C, Chein-I-Chang. Fully constrained least squares linear spectral mixture analysis method for material quantification in hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2001, 39(3): 529-545.
- [10] Wang J, Chang C I. Applications of independent component analysis in endmember extraction and abundance quantification for hyperspectral imagery [J]. IEEE Transactions on Geoscience and Remote Sensing, 2006, 44(9): 2601-2616.
- [11] Miao L D, Qi H R. Endmember extraction from highly mixed data using minimum volume constrained nonnegative matrix factorization [J]. IEEE Transactions on Geoscience and Remote Sensing, 2007, 45(3): 765-777.
- [12] Wang N, Du B, Zhang L P. An endmember dissimilarity constrained non-negative matrix factorization method for hyperspectral unmixing[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2013, 6(2): 554-569.
- [13] Rajabi R, Ghassemian H. Spectral unmixing of hyperspectral imagery using multilayer NMF [J]. IEEE Geoscience and Remote Sensing Letters, 2015, 12(1): 38-42.
- [14] Li D G, Li S T, Li H L. Hyperspectral image unmixing based on sparse and minimum volume constrained nonnegative matrix factorization [C] // Proceedings of 6th Chinese Conference on Pattern Recognition, November 17-19, Changsha, China. Heidelberg: Springer, 2014: 44-52.
- [15] Yu Y, Guo S, Sun W D. Minimum distance constrained nonnegative matrix factorization for the endmember extraction of hyperspectral images [J]. Proceedings of SPIE, 2007, 6790: 151-159.
- [16] Wu C Y, Shen C M. Spectral unmixing using sparse and smooth nonnegative matrix factorization [C] // 2013 21st International Conference on Geoinformatics, June 20-22, 2013, Kaifeng, China. New York: IEEE, 2013: 6626115.
- [17] Yang Z Y, Zhou G X, Xie S L, *et al.* Blind spectral unmixing based on sparse nonnegative matrix factorization [J]. IEEE Transactions on Image Processing, 2011, 20(4): 1112-1125.
- [18] Qian Y T, Jia S, Zhou J, *et al.* Hyperspectral unmixing via $L_{1/2}$ sparsity constrained nonnegative matrix factorization [J]. IEEE Transactions on Geoscience and Remote Sensing, 2011, 49(11): 4282-4297.
- [19] Lu X Q, Wu H, Yuan Y, *et al.* Manifold regularized sparse NMF for hyperspectral unmixing [J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 51(5): 2815-2826.
- [20] M, Niyogi P. Laplacian eigenmaps and spectral techniques for embedding and clustering [C] // Advances in Neural Information Processing systems, December 03-08, Vancouver, British Columbia, Canada. USA: MIT Press, 2002: 585-591.
- [21] Wang Q, Lin J Z, Yuan Y. Salient band selection for hyperspectral image classification via manifold ranking[J]. IEEE Transactions on Neural Networks and Learning Systems, 2016, 27(6): 1279-1289.
- [22] Lee D D, Seung H S. Learning the parts of objects by non-negative matrix factorization [J]. Nature, 1999, 401(6755): 788-791.
- [23] Lü Y L. Hyperspectral unmixing theory and techniques based on nonnegative matrix factorization [D]. Hangzhou: Hangzhou Dianzi University, 2009: 32-33.
- 吕亚丽. 基于非负矩阵分解的高光谱图像解混技术研究 [D]. 杭州: 杭州电子科技大学, 2009: 32-33.