

文章编号:1001-9014(2011)02-0131-07

# 基于独立分量分析的高光谱遥感图像混合像元盲分解

夏威<sup>1</sup>, 王斌<sup>1,2\*</sup>, 张立明<sup>1</sup>

(1. 复旦大学 电子工程系, 上海 200433;

2. 复旦大学 波散射与遥感信息教育部重点实验室, 上海 200433)

**摘要:**传统的独立分量分析并不适用于高光谱遥感图像的混合像元解混, 因为图像中各端元的分布不是相互独立的. 针对这一问题, 提出了一种有约束的独立分量分析方法, 来实现遥感图像混合像元的盲分解. 通过在独立分量分析的目标函数中引入丰度非负约束与丰度和为一约束, 改变了传统的独立性假设. 同时, 为了更好地适用于遥感数据分析, 还提出了一种自适应的丰度建模方法来描述数据的概率分布, 对各种不同的遥感数据进行建模. 仿真数据和真实高光谱数据的实验结果表明, 作为一种无需光谱先验信息的算法, 具有更高的分解精度, 为高光谱遥感图像混合像元的盲分解提供了一种有效的解决手段.

**关键词:**高光谱解混; 独立分量分析; 丰度非负约束; 丰度和为一约束

**中图分类号:**TP751 **文献标识码:**A

## Blind unmixing based on independent component analysis for hyperspectral imagery

XIA Wei<sup>1</sup>, WANG Bin<sup>1,2\*</sup>, ZHANG Li-Ming<sup>1</sup>

(1. Department of Electronic Engineering, Fudan University, Shanghai 200433, China;

2. The Key Laboratory of Wave Scattering and Remote Sensing Information (Ministry of Education), Fudan University, Shanghai 200433, China)

**Abstract:** In hyperspectral unmixing, endmember signals are not independent with each other, which compromise the application of independent component analysis (ICA) algorithm. This paper presented a novel approach based on constrained ICA for hyperspectral unmixing to overcome this problem. By introducing the constraints of abundance nonnegative and abundance sum-to-one, the purpose of our algorithm was not to find independent components as decomposition results anymore. In order to accord with the condition of hyperspectral imagery, we developed an abundance modeling technique to describe the statistical distribution of the data. The modeling approach is capable of self-adaptation, and can be applied to hyperspectral images with different characteristics. Experimental results on both simulated and real hyperspectral data demonstrated that the proposed approach can obtain more accurate results than the other state-of-the-art approaches. As an algorithm with no need of spectral prior knowledge, our method provided an effective technique for the blind unmixing of hyperspectral imagery.

**Key words:** hyperspectral unmixing; independent component analysis (ICA); abundance nonnegative constraint (ANC); abundance sum-to-one constraint (ASC)

**PACS:** 84.40.Xb

## 引言

高光谱遥感技术是一种新型的对地观测技术, 其光谱仪可以提供数十至数百个波段的光谱信息, 光谱分辨率达纳米数量级. 但是由于空间分辨率的限制, 图像中的一个像元可能包含多种地物类型, 形

成了“混合像元”. 从混合像元中提取典型地物(端元)的光谱, 并且求出这些地物所占的比例(丰度), 在实际应用中有着重要意义, 已成为遥感领域的一个研究热点<sup>[1]</sup>. 当前的大部分混合像元分解方法都是基于线性混合模型的, 其像元分解过程可分为两个步骤: 端元提取和丰度解混. 端元提取是指从遥感

收稿日期: 2010-06-27, 修回日期: 2010-10-06

Received date: 2010-06-27, revised date: 2010-10-06

基金项目: 863 国家高技术研究计划(2009AA12Z115); 国家自然科学基金(61071134, 60672116)

作者简介: 夏威(1986-), 男, 山东济宁人, 博士研究生, 主要从事遥感图像处理的研究, E-mail: 081021016@fudan.edu.cn.

\* 通讯作者: wangbin@fudan.edu.cn.

数据中求取端元光谱. 多数端元提取算法需要假设图像中各种地物都存在“纯像元”, 这类方法有 N-FINDR<sup>[2]</sup>, Vertex Component Analysis (VCA)<sup>[3]</sup>, 以及 Simplex Growing Algorithm (SGA)<sup>[4]</sup>等. 但是由于环境的复杂性, 很多情况下纯像元假设并不成立. 丰度解混是指确定各个端元在混合像元中所占的比例. 比较有效的算法有 Fully constrained least squares (FCLS)<sup>[5]</sup>, 该算法通过求约束最小二乘解, 得出地物的丰度. 有些算法可以同时完成端元提取和丰度解混, 如独立分量分析 (Independent Component Analysis, ICA)<sup>[6]</sup>. 该方法把混合像元分解视为一种盲分离问题, 无需光谱先验信息就可以进行分解. 缺点是: ICA 的独立性假设与线性混合模型中的和为一约束相矛盾, 导致结果出现负值, 违反了高光谱数据的非负性<sup>[7]</sup>. 另一个缺点是, ICA 除观测值以外没有其它先验知识, 只能假设数据的统计分布是一定的, 然而自然图像却是各不相同, 这种统计不变性问题进一步影响了算法的性能.

为解决 ICA 存在的上述问题, 提出了一种有约束的独立分量分析 (Constrained Independent Component Analysis, CICA) 方法. 该方法与传统 ICA 算法的不同之处主要在于: 根据高光谱遥感图像混合像元分解问题的特点, 将丰度非负约束、和为一约束引入到 ICA 中, 使解混结果在满足约束条件的同时, 尽可能减小它们之间的互信息. 我们不是要求分离结果各分量之间彼此独立, 而是希望其相关性尽量小, 从而将不同地物分离开来. 本算法中包含了一种自适应的丰度建模方法, 可以根据观测数据的概率分布自动地对模型进行调节, 从而对各种统计分布的数据都能有良好的适用性.

## 1 基于线性混合模型的光谱解混

线性混合模型是高光谱遥感图像研究中的一种常用模型. 设高光谱图像中共有  $L$  个波段,  $P$  个端元, 则某一个像素的观察值  $\mathbf{x}$  可被表示为

$$\mathbf{x} = \mathbf{A}\mathbf{s} + \mathbf{e} \quad (1)$$

这里,  $\mathbf{x} = [x_1, x_2, \dots, x_L]^T$ ;  $\mathbf{A} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_p]$  是端元光谱矩阵, 其中  $\mathbf{a}_i$  代表第  $i$  个端元的光谱向量;  $\mathbf{s} = [s_1, s_2, \dots, s_p]^T$  是丰度向量, 代表该像素中各端元所占的比例;  $\mathbf{e}$  是误差项. 其中,  $\mathbf{s}$  应满足丰度非负约束 (Abundance Nonnegative Constraint, ANC) 与丰度和为一约束 (Abundance Sum-to-one Constraint, ASC)

$$0 \leq s_i, \quad \sum_{i=1}^P s_i = 1, \quad (i = 1, 2, \dots, P) \quad (2)$$

在线性模型下, 混合像元分解就是从观察值  $\mathbf{x}$  中分离出  $\mathbf{A}$  和  $\mathbf{s}$ , 因而可以应用线性分离算法 ICA 来实现. ICA 寻找一种线性变换, 使分离出的源信号彼此相互独立. 具体地, 可以将式 (1) 中的  $\mathbf{x}$ ,  $\mathbf{A}$ ,  $\mathbf{s}$  分别视为观测信号、混合矩阵、源信号, 求出一个解混矩阵  $\mathbf{W}$ , 使得

$$\mathbf{y} = \mathbf{W}\mathbf{x} = \mathbf{U}\mathbf{s} \quad (3)$$

这里,  $\mathbf{y} = [y_1, y_2, \dots, y_p]^T$  是  $\mathbf{s}$  的估计值, ICA 通常把  $y_i$  视为随机变量;  $\mathbf{U}$  是每行每列只有一个非 0 元素的矩阵. 互信息可以用于衡量独立性的强弱, 通过最小化  $\mathbf{y}$  的各分量间的互信息, 可得出  $\mathbf{W}$  的迭代公式为<sup>[8]</sup>

$$\mathbf{W} \leftarrow \mathbf{W} + \eta \Delta \mathbf{W} \quad (4)$$

$$\Delta \mathbf{W} = (\mathbf{I} - \mathbf{f}(\mathbf{y})\mathbf{y}^T) \mathbf{W} \quad (5)$$

其中,

$$\mathbf{f}(\mathbf{y}) = [-p'(y_1)/p(y_1), -p'(y_2)/p(y_2), \dots, -p'(y_p)/p(y_p)]^T \quad (6)$$

$p(\mathbf{y})$  是  $\mathbf{y} = [y_1, y_2, \dots, y_p]^T$  的联合概率密度函数,  $p(y_i)$  是  $y_i$  的概率密度函数,  $p'(y_i)$  是  $p(y_i)$  的导函数,  $\eta$  是步长因子,  $\mathbf{I}$  是单位阵.

由式 (5) 和式 (6) 可知, 求解  $\mathbf{W}$  需要已知  $p(y_i)$ . 理论上应取真实值, 但在实际中  $p(y_i)$  难以获取, 导致解混精度下降. 另外, 根据式 (3) 可知, ICA 不能保证结果的幅值和源信号的幅值相同, 这将严重影响分解结果. 针对以上问题, 提出完整的解决方案.

## 2 算法描述

### 2.1 自适应丰度建模

采用 Pearson 混合模型近似  $p(y_i)$  为

$$p(y_i) = (1 - \alpha_i)N(\mu_{1(i)}, \sigma_i^2) + \alpha_i N(\mu_{2(i)}, \sigma_i^2) \quad (7)$$

其中,  $\alpha_i$  是权重因子,  $0 < \alpha_i < 1$ ,  $N(\mu, \sigma^2)$  代表均值为  $\mu$  方差为  $\sigma^2$  的正态分布函数,  $\alpha_i, \sigma_i, \mu_{1(i)}$  和  $\mu_{2(i)}$  都是待定参数. 经典的 ICA 算法<sup>[8]</sup>通过事先指定所有参数的值来确定  $p(y_i)$ , 这种预定义的  $p(y_i)$  往往不同于真实的地物分布情况, 导致分解结果有较大偏差. AAM 方法可以克服这一问题, 下面介绍 AAM 的参数调整规则.

(1) 参数  $\mu_{2(i)}$ . 在遥感图像中, 各端元都有各自的分布区域, 不会充满整幅图像, 这种性质称为丰度分布的稀疏性. 具体表现为: 丰度信号中出现较多的 0 值或接近于 0 的值. 该性质可视为  $y_i$  在 0 附近的概

率取峰值,因此,我们令 $\mu_{2(i)}=0, (i=1, \dots, P)$ .

(2) 参数 $\alpha_i$ . 首先, 设 $\kappa_n(y_i)$ 是 $y_i$ 的第 $n$ 阶累积量, 并令

$$\beta_i = \kappa_4(y_i) / [\kappa_1(y_i)\kappa_3(y_i)] \quad (8)$$

对于概率分布为式(7), 且 $\mu_{2(i)}=0$ 的信号 $y_i$ , 求出高阶累积量 $\kappa_n(y_i)$ 并带入式(8), 可得

$$6\alpha_i^2 - 6\alpha_i + 1 = \beta_i(2\alpha_i - 1)(1 - \alpha_i) \quad (9)$$

视式(9)中的 $\alpha_i$ 为一元二次方程的未知数, 则该方程有 2 个根:  $\text{root1}(\beta_i)$  和  $\text{root2}(\beta_i)$ , 分别为

$$\text{root1}(\beta_i) = \begin{cases} \frac{3\beta_i + 6 + \sqrt{\beta_i^2 + 4\beta_i + 12}}{12 + 4\beta_i}, & \text{if } \beta_i \neq -3 \\ \frac{2}{3}, & \text{otherwise} \end{cases},$$

$$\text{root2}(\beta_i) = \begin{cases} \frac{3\beta_i + 6 - \sqrt{\beta_i^2 + 4\beta_i + 12}}{12 + 4\beta_i}, & \text{if } \beta_i \neq -3 \\ \frac{2}{3}, & \text{otherwise} \end{cases} \quad (10)$$

当 $\beta_i \rightarrow -3$ 时, 这两个根的左右极限分别是

$$\lim_{\beta_i \rightarrow -3^+} \text{root1}(\beta_i) = \frac{2}{3}, \quad \text{and} \quad \lim_{\beta_i \rightarrow -3^-} \text{root1}(\beta_i) = \frac{2}{3} \quad (11)$$

$$\lim_{\beta_i \rightarrow -3^+} \text{root2}(\beta_i) = -\infty, \quad \text{and} \quad \lim_{\beta_i \rightarrow -3^-} \text{root2}(\beta_i) = \infty \quad (12)$$

(3) 参数 $\mu_{1(i)}$ . 对于概率分布为式(7), 且满足 $\mu_{2(i)}=0$ 的信号 $y_i$ , 可求出其均值为 $\text{mean}(y_i) = (1 - \alpha_i)\mu_{1(i)}$ . 因此可给出参数 $\mu_{1(i)}$ 的调整规则如下: 每次迭代中, 计算 $\text{mean}(y_i)$ , 然后令

$$\mu_{1(i)} = \text{mean}(y_i) / (1 - \alpha_i) \quad (13)$$

(4) 参数 $\sigma_i$ .  $\sigma_i$ 是文中算法的辅助性参数, 其精确与否不会对结果带来决定性的影响. 对于高光谱遥感数据, 直接给出 $\sigma_i$ 的经验值为 $\sigma_i = 1/3$ .

将上述 AAM 的参数 $\alpha_i, \sigma_i, \mu_{1(i)}$ 和 $\mu_{2(i)}$ 代入式(7)与式(5), 并以符号 $\Delta W_{\text{AMM}}$ 代替 $\Delta W$ , 可得

$$\Delta W_{\text{AAM}} = (\mathbf{I} + d\mathbf{y}^T - 9\mathbf{y}\mathbf{y}^T)\mathbf{W} \quad (14)$$

其中,  $d = 9\mu_1 \cdot / [\mathbf{1} - \alpha \cdot / (\alpha - \mathbf{1}) \cdot * \exp(-9\mu_1 \cdot * \mathbf{y} + 4.5\mu_1 \cdot * \mu_1)]$ ,  $\mu_1 = [\mu_{1(1)}, \mu_{1(2)}, \dots, \mu_{1(P)}]^T$ ,  $\mathbf{1} = [1, 1, \dots, 1]^T$ ,  $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_P]^T$ . 上式中的“ $\cdot *$ ”和“ $\cdot /$ ”表示矩阵元素对应相乘和相除.

以上针对单个像素给出了 ICA 的迭代公式. 但是在实际处理高光谱遥感图像问题时, 都是采用矩阵形式. 设每个波段的高光谱图像都有 $N$ 个像素点, 则式(1)所示的单像素观测矢量可以排列成矩阵形式

$$\mathbf{X} = \mathbf{A}\mathbf{S} + \mathbf{E} \quad (15)$$

这里,  $\mathbf{X}$ 是多通道遥感图像的观测矩阵, 每一列代表单一像元的观测光谱矢量;  $\mathbf{S}$ 是丰度矩阵, 每一行代表一个端元的丰度;  $\mathbf{E}$ 是误差矩阵. 相应的 ICA 解混公式见式(3), 表示为 $\mathbf{Y} = \mathbf{W}\mathbf{X}$ , 其中矩阵 $\mathbf{Y} \in R^{P \times N}$ 的第 $i$ 列定义为 $\mathbf{y}_i = [y_{1i}, y_{2i}, \dots, y_{Pi}]^T \in R^{P \times 1}$ . 类似地还可推出 $\mathbf{W}$ 的更新式(14)的矩阵形式为

$$\Delta \mathbf{W}_{\text{AAM}} = (\mathbf{I}\mathbf{N} + \mathbf{D}\mathbf{Y}^T - 9\mathbf{Y}\mathbf{Y}^T)\mathbf{W}/N \quad (16)$$

其中

$$\mathbf{D} = 9\tilde{\mu}_1 \cdot / [\tilde{\mathbf{1}} - \tilde{\alpha} \cdot / (\tilde{\alpha} - \tilde{\mathbf{1}}) \cdot * \exp(-9\tilde{\mu}_1 \cdot * \mathbf{Y} + 4.5\tilde{\mu}_1 \cdot * \tilde{\mu}_1)] \quad (17)$$

$$\tilde{\mu}_1 = \mu_1 \times \mathbf{1}^T, \quad \tilde{\alpha} = \alpha \times \mathbf{1}^T,$$

$$\tilde{\mathbf{1}} = \mathbf{1} \times \mathbf{1}^T, \quad \mathbf{1}^T = [1, 1, \dots, 1] \in R^{1 \times L} \quad (18)$$

## 2.2 约束条件

(1) 丰度非负约束 线性混合模型的 ANC 条件要求: 丰度信号必须在 $[0, 1]$ 范围内取值. 通过在算法中引入非负约束项来使结果满足 ANC. 设计原则是, 当结果满足 ANC 时, 约束项等于 0; 否则, 大于 0. 提出的非负约束目标函数如下

$$J_{\text{ANC}}(\mathbf{Y}) = \sum_{j=1}^N \sum_{i=1}^P [f(y_{ij}) + |f(y_{ij})|] / 2 \quad (19)$$

其中,  $f(y_{ij})$ 是任意一种可以满足以下条件的函数

$$f(y_{ij}) \begin{cases} = 0, & y_{ij} \in [0, 1] \\ > 0, & y_{ij} \notin [0, 1] \end{cases} \quad (20)$$

取 $f(y_{ij}) = ((y_{ij} - 0.5)^{2b} - 0.5^{2b}) / 2b$ , ( $b \in R_+$ ). 这时, 当矩阵 $\mathbf{Y}$ 中负分量的绝对值越大时,  $J_{\text{ANC}}(\mathbf{Y})$ 的值就越大. 这一特性有助于加快算法的收敛速度. 以符号 $\Delta \mathbf{W}_{\text{ANC}}$ 表示 $J_{\text{ANC}}(\mathbf{Y})$ 对 $\mathbf{W}$ 的负自然梯度, 并取正整数 $b$ 为 1, 可得

$$\Delta \mathbf{W}_{\text{ANC}} = -\frac{\partial J_{\text{ANC}}(\mathbf{Y})}{\partial \mathbf{W}} \mathbf{W}^T \mathbf{W} = -\mathbf{G}\mathbf{X}^T \mathbf{W}^T \mathbf{W} \quad (21)$$

其中, 矩阵 $\mathbf{G}$ 的第 $i$ 行第 $j$ 列位置处的元素为

$$g_{ij} = \begin{cases} y_{ij} - 0.5, & y_{ij} \notin [0, 1] \\ 0, & y_{ij} \in [0, 1] \end{cases} \quad (22)$$

(2) 丰度和为一约束 线性混合模型的 ASC 条件要求: 对于任意像素点, 所有端元地物在该点的丰度之和必须为 1. 定义 ASC 目标函数为

$$J_{\text{ASC}}(\mathbf{Y}) = \sum_{j=1}^N \left( \sum_{i=1}^P y_{ij} - 1 \right)^{2c} / 2c \quad (23)$$

这里 $c \in R_+$ . 当 $\mathbf{Y}$ 满足 ASC 时,  $J_{\text{ASC}}(\mathbf{Y}) = 0$ ; 否则 $J_{\text{ASC}}(\mathbf{Y}) > 0$ . 取 $c = 1$ , 并令 $J_{\text{ASC}}(\mathbf{Y})$ 对 $\mathbf{W}$ 求负自然梯度, 可得

$$\Delta \mathbf{W}_{ASC} = -\frac{\partial J_{ASC}(\mathbf{Y})}{\partial \mathbf{W}} \mathbf{W}^T \mathbf{W} = -\mathbf{H} \mathbf{X}^T \mathbf{W}^T \mathbf{W}, \quad (24)$$

其中,矩阵  $\mathbf{H}$  的第  $i$  行第  $j$  列位置处的元素为

$$h_{ij} = \left( \sum_{i=1}^p y_{ij} - 1 \right). \quad (25)$$

### 2.3 CICA 算法迭代公式

综合考虑互信息、丰度非负约束以及丰度和为一约束,CICA 问题可以被总结为

$$\text{Minimize } J(\mathbf{Y}) = I(\mathbf{Y}) + \eta_1 J_{ANC}(\mathbf{Y}) + \eta_2 J_{ASC}(\mathbf{Y}),$$

其中  $\mathbf{Y} = \mathbf{W}\mathbf{X}$ .

其中参数  $\eta_1, \eta_2$  用于控制约束条件的权重.  $J(\mathbf{Y})$  就是 CICA 算法的总目标函数,根据梯度下降法,可以得到  $\mathbf{W}$  的迭代公式为

$$\mathbf{W} \leftarrow \mathbf{W} + \eta \Delta \mathbf{W},$$

$$\Delta \mathbf{W} = \Delta \mathbf{W}_{AAM} + \eta_1 \Delta \mathbf{W}_{ANC} + \eta_2 \Delta \mathbf{W}_{ASC}, \quad (26)$$

这里,  $\Delta \mathbf{W}_{AAM}, \Delta \mathbf{W}_{ANC}$ , 以及  $\Delta \mathbf{W}_{ASC}$  均已在前面作过说明.

如果要获取端元矩阵  $\mathbf{A}$  的值,可以在求出丰度矩阵  $\mathbf{Y}$  后,通过解非负最小二乘问题来实现.也可以使用  $NMF^{[9]}$  来实现,即以  $\mathbf{Y}$  作为 NMF 的初始值,进行迭代求解.

## 3 实验结果与讨论

### 3.1 仿真数据实验

采用仿真数据测试算法的性能. CICA 方法与 VCA<sup>[3]</sup>, HOS-ICPA<sup>[7]</sup>, 以及 MVCNMF<sup>[10]</sup> 这 3 种算法进行对比. 其中 VCA 只能得到端元光谱矩阵,因此在得到端元光谱后用 FCLS<sup>[5]</sup> 求出丰度矩阵,将这种方法记为 VCA-FCLS. 光谱角距离 (Spectral Angle Distance, SAD) 和均方根误差 (Root Mean Square Error, RMSE) 两个指标被用于衡量所有算法的结果和真实参考值之间的差异.

在进行实验测试时,以所有端元的平均 SAD 和平均 RMSE 作为评价标准. 实验使用的仿真数据含有五个端元,其光谱取自美国地质勘测局 (USGS) 公布的矿物光谱库 (Available at <http://speclab.cr.usgs.gov/spectral.lib04/lib04-AVIRIS.html>), 具有 224 个波段. 丰度数据则按照以下方法产生: 为 5 种端元分别产生 5 幅大小为  $r \times r$  像素的丰度图,图上各点的灰度值代表该点的丰度,其取值范围是  $[0, 1]$ . 每幅图上各选一个点作为“中心点”,该点的值设为数据的纯度. 中心点以外的点,其值逐渐递减. 最后把所有端元的丰度信号之和归一化以满足

ASC. 通过四个实验评估几种方法的性能,实验中 CICA 算法的参数统一设置为:  $\eta = 0.01 \times P, \eta_1 = 5/N, \eta_2 = 1/N$ .

**实验 1 抗噪声干扰性能.** 按照式(1)将高斯白噪声加入仿真数据,然后测试不同算法的解混结果. 一般,在真实遥感图像中并非所有地物都存在纯像元,为了让仿真数据近似这种情况,在实验中指定三个端元的纯度为 0.7 (无纯像元),其余两个端元的纯度为 1 (有纯像元). 图 1(a) 和图 1(b) 分别给出了在不同的信噪比下,各算法的 RMSE 和 SAD 的变化情况. 可见,随着信噪比的降低,所有算法的整体效果均逐渐变差. CICA 算法的效果始终是最好的,其次是 VCA-FCLS.

**实验 2 算法性能与像素个数的关系.** 改变仿真图像的大小,以此比较像素个数对各算法的影响. 图 2(a) 和图 2(b) 分别给出了在不同的像元个数下,各算法的 RMSE 和 SAD 的变化情况. 可见,随着像元个数的增加,所有方法的性能都有小幅改善. VCA 是基于单形体的方法,像素数的增加有利于对单形体顶点的寻找; CICA 和 HOS-ICPA 是基于统计的方法,样本数的增加意味着能够获取更多的统计信息; MVCNMF 是基于 NMF 方法,像素个数的增加可以提供更多统计信息. 但是 NMF 算法具有局部极小,所以图中也出现了随着像素个数提高而效果




图 1 不同信噪比下算法的结果 (a) RMSE (b) SAD  
Fig. 1 Results of the algorithms with different noise levels (a) RMSE (b) SAD

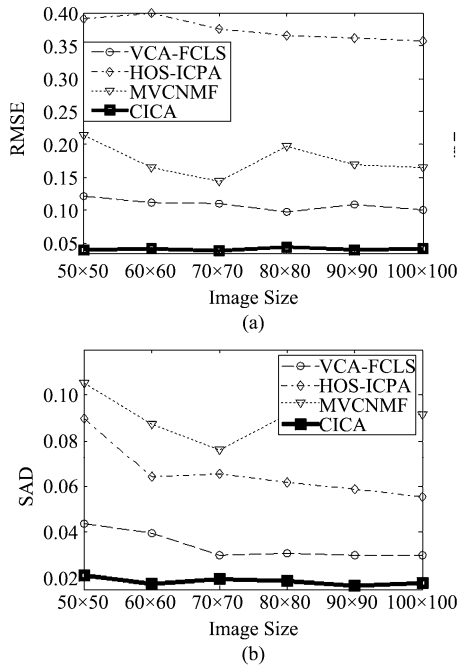


图 2 不同像素数下算法的结果 (a)RMSE (b)SAD  
Fig.2 Results of the algorithms with different data sizes (a) RMSE (b)SAD

下降的情况,这在一定程度上反应了该方法的不稳定性.

实验 3 纯像元缺失情况下的适应性. 让纯度从 1 改变到 0.5, 比较各算法对纯像元缺失情况的适应性. 图 3(a) 和图 3(b) 分别给出了在不同的纯像元缺失程度下, 各算法的 RMSE 和 SAD 的变化情况. 可见, 随着像元纯度的降低, CICA 和 VCA-FCLS 的性能都在逐渐变差, 但是 CICA 在效果上始终优于 VCA-FCLS, 其次则是 MVCNMF 和 HOS-ICPA.

实验 4 抗端元数估计误差的性能. 现有的混合像元解混算法必须精确已知图像中存在的端元的个数  $P$ , 这就需要根据先验知识或者使用专门的算法来进行端元数估计. 但是, 由于数据集本身的复杂性, 端元个数的估计一般是不准确的. 事实上, 对于同样的实际遥感数据, 不同的端元数估计算法求出的端元个数一般是不同的, 同一种估计算法在不同的参数下给出的端元个数也是不同的. 因此, 能否在不准确的端元数估计下依然给出正确的结果, 在实际应用中具有重要意义.

仿真数据的真实端元数  $P = 5$ , 假设端元数被错误地估计为一个大于 5 的数  $P'$ . 例如  $P' = 8$ , 设纯度为 1, 这时所提议算法的解混结果如图 4 所示. 可见, 其中 5 个丰度图 4(a) ~ (e) 各对应一个真实的端元丰度, 多估计的端元丰度被算法以近似为 0 的




图 3 不同混合度下算法的结果 (a)RMSE (b)SAD  
Fig.3 Results of the algorithms with different mixing degrees (a) RMSE (b)SAD




图 4  $P' = 8$  时解出的丰度图  
Fig.4 Estimated abundance maps when  $P' = 8$

形式由图 4(f) ~ (h) 给出. 进一步, 令  $P'$  从 5 ~ 10 变化, 以此模拟不同程度的端元数估计误差. 比较各种算法的解混结果和理想结果间的 RMSE 和 SAD, 如图 5 所示. 这里没有放上 VCA-FCLS 的结果, 因为  $P > 5$  时, 它的 RMSE 太大, 与其他方法不具有可比性. 可见, 随着端元数估计误差的增大, CICA 几乎没有受到影响, 总是能得出正确的结果, 而其它几种方法的都没能得出正确解. 实验说明, 在端元数估计偏大的情况下, CICA 不但能正确求出实际存在的端元, 同时还以近似为 0 的形式给出被错误地多估计的端元的丰度, 从而指出了正确的端元个数. 这一优

点是其它算法所不具备的。

### 3.2 实际遥感数据实验

实验采用了美国印第安纳州西拉斐特 (West Lafayette) 地区的高光谱遥感数据 (Available at <http://cobweb.ecn.purdue.edu/~biehl/MultiSpec/>). 该数据由机载可见光及红外成像光谱仪 (Airborne Visible/Infrared Imaging Spectrometer, AVIRIS) 拍摄于 1992 年 6 月, 成像区域是 Purdue 大学的一块遥感试验田, 图像大小为  $145 \times 145$ , 波长范围从  $0.4 \sim 2.5 \mu\text{m}$ , 光谱分辨率为  $10\text{nm}$ , 空间分辨率为  $17\text{m}$ , 共 224 个波段. 由实地勘测报告<sup>[11]</sup>可知, 该地区的地表主要由各种农作物和人工建筑所覆盖, 典型地物包括玉米、大豆、干草、树林、草地、公路、石塔以及一些房屋。

数据的第 1~4, 78~82, 103~115, 148~166 以及 211~220 波段由于为水吸收波段或信噪比太低而被移除, 剩下的 169 个波段被用于实验. 为定量衡量算法的性能, 根据地物真实报告所提供的分布情况对端元进行手动提取, 在图像中为各地物分别选择多个较纯像元, 求出每类像元观测值的平均值作为各端元的参考光谱. 总共提取了六个端元光谱, 分别对应人工建筑、玉米、大豆、草地、树林和干草堆。

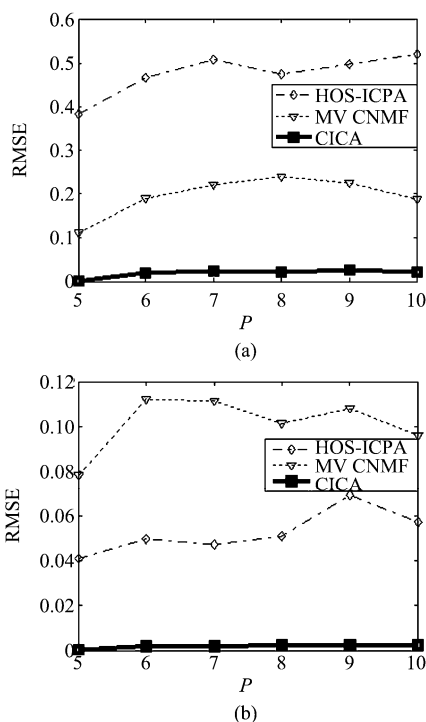


图 5 不同端元数估计误差下算法的结果 (a) RMSE (b) SAD

Fig. 5 Results of the algorithms with incorrect estimation of endmember number (a) RMSE (b) SAD

CICA 的丰度解混结果如图 6 所示. 通过比较可以发现, 分解结果与真实分布非常吻合. 为定量衡量算法性能, 将所有算法解出的光谱与手动选取的参考光谱进行比较, 求出其光谱角, 结果如表 1 所示. 可见, 文中方法取得了最好的效果。

表 1 Indiana 数据的光谱角比较

Table 1 The comparison of SAD values for Indiana dataset

	CICA	VCA	HOS-ICPA	MVCNMF
玉米	<b>0.1355</b>	0.6508	0.1403	0.1878
草地	<b>0.1109</b>	0.8342	1.2941	0.6123
树林	<b>0.1483</b>	0.4039	1.3765	0.9807
人工建筑	<b>0.1104</b>	0.3592	0.7361	0.6366
干草堆	0.1029	0.6602	0.2020	0.7595
大豆	0.0894	0.1302	0.7379	0.2911

## 4 结论

提出了一种基于有约束 ICA 的高光谱遥感图像的混合像元分解算法. 传统 ICA 在应用到高光谱解混时会面临独立性假设问题和概率分布统计不变问题, 通过提出自适应丰度建模 (AAM) 方法, 并向 ICA 算法中引入约束条件, 较好地解决了上述问题. AAM 的学习规则根据高光谱遥感图像的物理特性设计, 可按照遥感数据的特点进行自动调整, 提高了算法的适用性. 另外, 引入了 ANC 与 ASC 约束条件, 它们具有明确的物理意义且易于计算. 仿真实验结果表明, 所提出的算法克服了传统 ICA 的问题, 能得出更优的解, 对纯像元缺失和受到干扰的数据, 都表现出了良好的鲁棒性. 此外, 在端元数估计错误




图 6 Indiana 数据的分解结果 (a) 干草堆 (b) 大豆 (c) 草地 (d) 玉米 (e) 树林 (f) 人工建筑

Fig. 6 The unmixing results of Indiana dataset (a) hay (b) soybean (c) grass (d) corn (e) woods (f) man-made structures

(下转 155 页)

分的窄带探测技术能够更好的挖掘目标的光谱信息,仿真结果表明所提出的基于广义似然比检验的红外多光谱弱小运动目标检测算法正确可行,能够进一步提高对低信噪比条件下弱小运动目标的检测能力. 下一步的工作可以利用当前的检测结果并结合目标的光谱先验知识确定其温度和组成成分,从而有效区分目标.

## REFERENCES

- [1] Theodore A P. Explanation of why the sensor in the exoatmospheric kill vehicle (EKV) cannot reliably discriminate decoys from warheads [R/OL]. [http://fas.org/spp/starwars/program/news00/postol\\_atta.pdf](http://fas.org/spp/starwars/program/news00/postol_atta.pdf).
- [2] Theodore A P. Technical discussion of the misinterpreted results of the IFT-1A experiment due to tampering with the data and analysis and errors in the interpretation of the data [R/OL]. [http://fas.org/spp/starwars/program/news00/postol\\_attrb.pdf](http://fas.org/spp/starwars/program/news00/postol_attrb.pdf).
- [3] CAO Le-Lin, WU Chun-Feng, HOU Qing-Yu, et al. Survey of target recognition technology based on spectrum imaging[J]. *Optical Technique*(操乐林,武春风,侯晴宇,等. 基于光谱成像的目标识别技术综述. *光学技术*), 2010, **36**(1):145—150.
- [4] HUANG Shi-Ke, ZHANG Tian-Xu, LI Li-Juan, et al. IR guiding technology based on multispectral imaging for air to air missile[J]. *Infrared and Laser Engineering*(黄士科,张天序,李丽娟,等. 空空导弹多光谱红外成像制导技术研

究. *红外与激光工程*), 2006, **35**(1):16—20.

- [5] Stein D W J, Beaven S G, Hoff L E, et al. Anomaly detection from hyperspectral imagery[J]. *IEEE Signal Processing Magazine*, 2002, **19**(1):58—69.
- [6] Yu X L, Hoff L E, Reed I S, et al. Automatic target detection and recognition in multiband imagery: a unified ML detection and estimation approach[J]. *IEEE Trans. on Image Processing*, 1997, **6**(1):143—156.
- [7] Rallier G, Descombes X, Falzon F, et al. Texture feature analysis using a Gauss-Markov model in hyperspectral image classification[J]. *IEEE Trans. on Geoscience and Remote Sensing*, 2004, **42**(7):1543—1551.
- [8] Chang C I. *Hyperspectral imaging: techniques for spectral detection and classification*[M]. Kluwer Academic/Plenum Publishers, 2003, 13—102.
- [9] Li N, Du P, Zhao H J. Independent component analysis based on improved quantum genetic algorithm: application in hyperspectral images[J]. *International Geoscience and Remote Sensing Symposium (IGARSS)*, 2005, **6**: 4323—4326.
- [10] XUN Li-Na, FANG Yong-Hua, LI Xin. A small target detection approach based on endmember extraction in hyperspectral image[J]. *Acta Optica Sinica*(寻丽娜,方勇华,李新. 高光谱图像中基于端元提取的小目标检测算法. *光学学报*), 2007, **27**(7):1178—1182.
- [11] HE Lin, PAN Quan, DI Wei, et al. A small-target detector based on single likelihood test for hyperspectral imagery[J]. *Acta Optica Sinica*(贺霖,潘泉,邸韡,等. 一种基于单似然检验的高光谱图像小目标检测器. *光学学报*), 2007, **27**(12):2155—2162.

(上接 136 页)

的情况下仍能得到正确结果,对于实际应用有较为重要的意义. 对于实际高光谱遥感数据实验,也得到了理想的结果,进一步证实了算法的有效性和对于各种不同数据的适用性.

## REFERENCES

- [1] Chang C I. *Hyperspectral imaging: techniques for spectral detection and classification* [M]. New York: Plenum, 2003.
- [2] Winter M E. N-findr: an algorithm for fast autonomous spectral endmember determination in hyperspectral data [J]. *Proc. of the SPIE imaging spectrometry V*, 1999, **3753**:266—275.
- [3] Nascimento J, Bioucas-Dias J. Vertex component analysis: a fast algorithm to unmix hyperspectral data [J]. *IEEE Trans. Geosci. Remote Sens.*, 2002, **43**(4):898—910.
- [4] Chang C I, Wu C C, Liu W, et al. A new growing method for simplex-based endmember extraction algorithm [J]. *IEEE Trans. Geosci. Remote Sens.*, 2006, **44**(10):2804—2819.
- [5] Heinz D C, Chang C I. Fully constrained least squares line-

ar spectral mixture analysis method for material quantification in hyperspectral imagery[J]. *IEEE Trans. Geosci. Remote Sens.*, 2001, **39**(3):529—545.

- [6] Hyvarinen A, Karhunen J, Oja E, *Independent Component Analysis*[M]. New York: Wiley, 2001.
- [7] Chang C I, Wang J. Applications of independent component analysis in endmember extraction and abundance quantification for hyperspectral imagery [J]. *IEEE Trans. Geosci. Remote Sens.*, 2006, **44**(9):2601—2616.
- [8] Lee T, Girolami M, Sejnowski T. Independent component analysis using an extended infomax algorithm for mixed subgaussian and supergaussian sources [J]. *Neural Computation*, 1999, **11**(2):417—441.
- [9] Lee D D, Seung H S. Learning the parts of objects by non-negative matrix factorization [J]. *Nature*, 1999, **401**:788—791.
- [10] Miao L, Qi H. Endmember extraction from highly mixed data using minimum volume constrained nonnegative matrix factorization [J]. *IEEE Trans. Geosci. Remote Sens.*, 2007, **45**(3):765—777.
- [11] Landgrebe D. *Multispectral data analysis: A signal theory perspective*[R]. West Lafayette: School of Electrical & Computer Engineering, Purdue University, 1998.