

文章编号:1004-4213(2011)06-0835-8

小波包分解支持下的高光谱混合像元盲分解

李熙¹, 陈学泓², 陈晓玲¹, 田礼乔¹, 陈锋锐³

(1 武汉大学 测绘遥感信息工程国家重点实验室, 武汉 430079)

(2 名古屋大学 环境学研究科, 名古屋 464-8601)

(3 中国科学院遥感应用研究所, 北京 100101)

摘要: 提出将小波包辅助下子带分解的独立成分分析用于高光谱混合像元盲分解。利用小波包分解改进独立成分分析技术, 并考虑到高光谱数据的特点提出了高光谱混合像元盲分解方法, 该方法能克服独立成分分析方法要求端元光谱统计独立带来的问题。利用两组合成数据和三组室内实测数据对本算法进行测试, 证明了本算法能较为准确的提取端元光谱波形和端元丰度, 其准确度明显优于独立成分分析方法。该方法为高光谱遥感影像的盲分解提供了一条新的途径。

关键词: 遥感; 小波包分解; 混合像元; 独立成分分析; 线性光谱混合模型

中图分类号:P751.1

文献标识码:A

doi:10.3788/gzxb20114006.0835

0 引言

高光谱影像具有几十到数百个波段, 能充分反映地物的光谱信息, 因此它能够较好的用于遥感影像分类和目标识别^[1-3]。与此同时, 高光谱遥感影像中存在着大量的混合像元, 这些像元的存在阻碍了高光谱遥感影像分类准确度的提高。如果能计算出混合像元中各个地物覆盖类别(端元)所占的面积比例(丰度), 那么混合像元问题产生的分类误差就可以被降低, 这个过程被称为混合像元分解^[2]。高光谱遥感影像具有充分的光谱信息, 为解决混合像元分解问题提供了可行性, 所以高光谱遥感影像的混合像元分解是遥感领域的研究热点。

传统的混合像元分解过程中^[2], 需要获得各类地物的光谱信息并将其作为模型参量, 再将遥感影像输入到模型中, 从而得到混合像元的分解结果。而地物的光谱信息一般通过手工或半自动采集该类地物的纯像元获得^[4]。如果遥感影像中的某些地物全部以亚像元的形式存在, 这使得该影像中没有该类地物的纯像元, 因此无法直接获得该类地物的光谱信息。直接通过混合像元提取端元的光谱曲线和丰度的过程称为混合像元的盲分解。由于高光谱影像拥有充分的光谱信息, 这使得高光谱数据的盲分解成为可能。

近年来, 研究人员对高光谱盲分解做出大量的研究^[5-6], 其中基于独立成分分析(Independent Component Analysis, ICA)法是研究热点之一, 该研究可以分为两类: 第一类是将端元光谱看做源信号, 将端元丰度看做混合矩阵^[7-9], 每次对少量高光谱像元进行盲分解同时获得这些像元的端元光谱和丰度, 这类研究开展的早但研究工作较少; 第二类是将端元丰度看做源信号, 将端元光谱看做混合矩阵^[1, 5, 10], 一次性得到整幅影像的端元光谱和各端元的丰度图, 这类研究开展较多, 但其可靠性却受到了质疑^[5]。

本文基于第一类方法, 利用小波包分解技术解决该类方法存在的瓶颈问题。

1 基于 ICA 的高光谱混合像元盲分解

1.1 独立成分分析

ICA 是指在缺乏先验知识的情况下, 根据非高斯性从混合后的多元信号中寻找独立源信号的方法^[11], 是盲源信号分离研究中的热点。假设观察到随机变量 x_1, x_2, \dots, x_n , 这些变量是由随机变量 s_1, s_2, \dots, s_n 线性组合得来的

$$x_i = a_{i1}s_1 + a_{i2}s_2 + \dots + a_{in}s_n \quad (i=1, \dots, n) \quad (1)$$

用矩阵形式表示为

基金项目: 武汉大学自主科研项目(No. 904275839)、武汉市科技计划项目(No. 200970634267)、国家自然基金委创新研究群体科学基金项目(No. 41021061)和国家重点基础研究发展计划项目(No. 2009CB723905)资助

第一作者: 李熙(1982—), 男, 讲师, 博士, 主要研究方向为遥感影像处理与应用。Email: li_rs@163.com

收稿日期: 2010-12-20; 修回日期: 2011-01-28

$$x = As \quad (2)$$

式中 x_1, \dots, x_n 称为观测变量, 独立成分 s_1, s_2, \dots, s_n 称为隐变量, 混合矩阵 A 是未知的. ICA 是通过 x 的观测值同时估计出混合矩阵 A 和隐变量 s . 关于 ICA 的详细机理可参见文献[11].

1.2 基于 ICA 的高光谱混合像元盲分解

对于 N 个高光谱像元, 假设 N 个像元中包含了 N 个端元成分. 将像元光谱看做观测信号, 那么端元光谱可以看作待估计的源信号, 分别用随机变量 G_1, \dots, G_N 和 R_1, \dots, R_N 表示这两类信号, 根据线性光谱混合模型^[2]可以得到

$$\begin{cases} G_1 = a_{11}R_1 + \dots + a_{1N}R_N \\ \dots \\ G_N = a_{N1}R_1 + \dots + a_{NN}R_N \end{cases} \quad (3)$$

式中 G_i 表示第 i 个像元的光谱变量, R_i 表示第 i 个端元的光谱变量, a_{ij} 表示第 i 个像元中第 j 个端元的丰度值. 可以发现, 上式符合 ICA 中的信号混合表达式, 因此根据 ICA, 通过 G_1, \dots, G_N 的观测值(混合像元的光谱曲线)有可能同时解算出 R_1, \dots, R_N 对应的信号(端元光谱)和混合矩阵(端元丰度). 这就是利用 ICA 进行高光谱混合像元盲分解的基本原理. Bayliss 首次提出这一思路进行高光谱像元的盲分解^[7], 但没有解决丰度归一化和端元光谱幅度不确定的问题. 陶欣利用丰度归一化更正了 ICA 的盲分解结果, 并同时确定了端元光谱幅度, 从而更加准确的对高光谱数据进行了盲分解^[9], 该算法步骤如下: 1) 选出 N 个待分解的像元, 并假设这些像元共包含 N 个端元; 2) 将 N 个像元光谱看做信号并利用 ICA 进行盲分离, 得到 N 个新信号; 3) 根据端元丰度和为 1 的约束条件, 对新的信号进行一定的线性变换, 得到端元光谱及丰度值.

根据 ICA 的应用前提, 隐变量间必须统计独立, 即不同的端元光谱必须统计独立. 然而, 现实中不同物质的光谱往往不服从统计独立, 导致很多情况下该方法失效.

2 基于 WPSDICA 的高光谱混合像元盲分解

2.1 WPSDICA 算法原理

用 ICA 进行信号盲分解的前提是隐变量之间必须统计独立. 然而, 现实中隐变量之间常常不独立, 所以 ICA 技术有时不能准确的分离出隐变量. 为了克服这一弱点, 有学者提出子带分解的独立成分分析(Sub-band Decomposition Independent Component Analysis, SDICA)^[12]. SDICA 技术的出

发点是: 对原始信号进行滤波, 滤波后信号间的独立性可能增强, 所以对滤波后的信号进行 ICA 分解可能生成更准确的混合矩阵, 而理论可以证明滤波不会影响真实的混合矩阵. 但如何选取最优的滤波方式则是一个难点, 直到 Kopriva^[13] 提出利用小波包分解得到最优滤波方式, 从而第一次给出了实现 SDICA 的一般性方案. 该方法称为小波包辅助下子带分解的独立成分分析(Wavelet Package approach to Sub-band Decomposition Independent Component Analysis, WPSDICA). 鉴于小波包技术的良好性能, 已被广泛的用于图像处理等领域^[14].

WPSDICA 算法基本原理为: 对一组观测信号分别进行 N 层小波包分解, 会得到 $2^N - 1$ 组新的观测信号, 每组新信号对应一个小波包节点, 下文用小波包节点来简便表示观测信号在该小波包节点的信号. Kopriva 证明了: 观测信号组在任何一个小波包节点的互信息量与该小波包节点对应的源信号的互信息量成近似正比. 一组信号 (x_1, x_2, \dots, x_N) 的互信息量 I 可用下列公式近似得到

$$I(x_1, x_2, \dots, x_N) \approx \frac{1}{4} \sum_{0 \leq n < l \leq N, n \neq l} \text{cum}^2(x_n^j, x_l^j) + \frac{1}{12} \sum_{0 \leq n < l \leq N, n \neq l} (\text{cum}^2(x_n, x_n, x_l) + \text{cum}^2(x_n, x_l, x_l)) + \frac{1}{48} \sum_{0 \leq n < l \leq N, n \neq l} (\text{cum}^2(x_n, x_n, x_n, x_l) + \text{cum}^2(x_n, x_n, x_l, x_l) + \text{cum}^2(x_n, x_l, x_l, x_l)) \quad (4)$$

式中 $\text{cum}()$ 是互累积量函数^[13], $\text{cum}(x, y)$ 、 $\text{cum}(x, y, z)$ 、 $\text{cum}(x, y, z, v)$ 分别为 2 阶、3 阶、4 阶互累积量函数. 基于这一规律, 即使在源信号不满足统计独立的情况下, 通过下列步骤仍可近似分离出源信号:

- 1) 确定小波包函数和分解层数, 对一组观测信号进行小波包分解, 每个信号经过分解后都得到若干子成分, 不同信号在同一小波包节点构成一个子成分组.
- 2) 选择互信息量最小的子成分组为所需的子成分组.
- 3) 对该子成分组进行独立成分分析, 得到混合矩阵 A .
- 4) 基于公式(2), 通过混合矩阵 A 和观测信号 $x(t)$ 得到源信号.

WPSDICA 算法从理论上解决了源信号间不独立导致的 ICA 失效的问题, 是盲源信号分离领域的最新突破之一.

2.2 基于 WPSDICA 的高光谱混合像元盲分解

因为 WPSDICA 算法能够在源信号间不独立时进行信号盲分离,所以本文尝试用 WPSDICA 来解决高光谱的盲分解问题。利用 WPSDICA 和 ICA 进行高光谱数据盲分解的原理相似,即对输入的混合光谱进行盲分离,将丰度结果归一化并调整对应的端元光谱。但利用 WPSDICA 算法进行高光谱数据盲分解时,应当额外注意两个问题:

1)两个正约束条件:(a) 分离出来后的源信号(光谱曲线)的任意一点不能小于零;(b) 混合矩阵中的任何一个元素不小于零,因为根据物理意义,任何端元的丰度不能为负。

2)数据插值:对待分解的高光谱曲线进行插值,使其共有 2^n 个点,且 n 必须显著大于小波包分解的层数。这是因为常用的小波包分解都是二进小波包分解,必须保证信号长度为2的整数次方。

根据 WPSDICA 算法和以上两点,对于选定的 N 个像元,基于 WPSDICA 的高光谱混合像元盲分解算法为:

1)假设这些像元中包含 N 个端元,设第 i 个像元的光谱为 $x_i(i=1,2,\dots,N)$,确定小波基和小波包分解的层数 k ,对 x_i 进行数据插值使其变为 $x'_i(i=1,2,\dots,N)$ 。

2)对 x'_1,\dots,x'_N 分别进行 k 层小波包分解。对于任意光谱 x'_i ,分解得到 $2^{k+1}-1$ 个节点信号,并将这些节点按照一定的顺序排列,设该光谱在第 j 个节点的信号为 $x'_{i,j}$ 。

3)计算 $(x'_{1,j},\dots,x'_{N,j})$ 的互信息量,因为 $1 \leq j \leq 2^{k+1}-1$,故 $2^{k+1}-1$ 组小波包节点分别对应 $2^{k+1}-1$ 个互信息量值。

4)对信号组 $(x'_{1,j},\dots,x'_{N,j})$ 进行 ICA 分解,由于 $1 \leq j \leq 2^{k+1}-1$,故共对 $1 \leq j \leq 2^{k+1}-1$ 个信号组进行了 ICA 分解。每个节点 j 均产生一组分解信号和混合矩阵,通过丰度归一化方法^[9],得到更正后的混合矩阵(丰度矩阵)。再通过丰度矩阵和像元光谱 x'_1,\dots,x'_N ,基于线性光谱混合模型得到一组端元光谱。

5)根据上一步,每个节点均分解出一组端元光谱(源信号)和端元丰度值(混合矩阵)。通过“两个正约束条件”淘汰不满足要求的节点,可采用如下技巧:将不满足“两个正约束条件”的节点对应的互信息量改为正无穷大。

6)遍历所有节点,找到互信息量最小的一组节点,其对应的端元光谱组和丰度值即像元组的盲分解结果。

本研究中将所有像元光谱插值到1024个点。需要注意的是,本研究在于克服端元光谱不独立导致的盲分解误差,所以本文不涉及如何确定光谱组中端元数量,故后续试验将混合光谱(观测信号)数目设计成端元(源信号)数目以便进行盲分解。当然,如何确定源信号数目也是盲分解中的一个重要话题^[1]。

3 高光谱数据盲分解试验

3.1 盲分解结果的评价指标

光谱盲分解的结果包括端元光谱和端元丰度,因此需要对这两者分别进行评价。

1)端元光谱的评价

因为盲分解得到的端元光谱不包含类别信息,所以在评价结果之前需要将盲分解得到的端元组与真实的端元组进行匹配。

对于两条配对光谱 x,y ,采用相关系数来计算它们的匹配度^[15]

$$r(x,y)=\frac{\sum_{i=1}^n(x_i-\bar{x})(y_i-\bar{y})}{[\sum_{i=1}^n(x_i-\bar{x})^2]^{1/2}[\sum_{i=1}^n(y_i-\bar{y})^2]^{1/2}} \quad (5)$$

式中, $x=(x_1,\dots,x_n)$, $y=(y_1,\dots,y_n)$, $r(x,y)$ 的范围是 $[-1,1]$, r 值越大说明匹配度越高。对于两组光谱曲线 $[x^{(1)},\dots,x^{(m)}]$ 和 $[y^{(1)},\dots,y^{(m)}]$,当已知它们的配对情况时,即 $x^{(i)}$ 对应 $y^{(i)}$ $(i=1,\dots,m)$,本文采用平均相关系数来计算它们的整体匹配度

$$R([x^{(1)},\dots,x^{(m)}],[y^{(1)},\dots,y^{(m)}])=\frac{\sum_{i=1}^mr(x^{(i)},y^{(i)})}{m} \quad (6)$$

事实上,盲分解得到的端元光谱组与真实端元光谱组的配对情况是未知的,这就需要对一组光谱曲线调整顺序以达到两组光谱曲线的最佳配对,为此本文提出了光谱组的盲匹配度(简称为匹配度)

$$R^*([x^{(1)},\dots,x^{(m)}],[y^{(1)},\dots,y^{(m)}])=\max_{\{k_1,\dots,k_m\}=\{1,\dots,m\}}R([x^{(1)},\dots,x^{(m)}],[y^{(k_1)},\dots,y^{(k_m)}]) \quad (7)$$

根据集合的定义,集合的元素没有顺序之分,所以 $\{k_1,\dots,k_m\}=\{1,\dots,m\}$ 等价于 k_1,\dots,k_m 是 $1,\dots,n$ 的一个全排列。将光谱组 $[a^{(1)},\dots,a^{(m)}]$ 视为类别已知的光谱组, $[b^{(1)},\dots,b^{(m)}]$ 为盲分解得到的光谱组(类别未知),当式(8)成立时

$$R([a^{(1)},\dots,a^{(m)}],[b^{(s_1)},\dots,b^{(s_m)}])=R^*([a^{(1)},\dots,a^{(m)}],[b^{(1)},\dots,b^{(m)}]) \quad (8)$$

认为 $[b^{(s_1)},\dots,b^{(s_m)}]$ 是与 $[a^{(1)},\dots,a^{(m)}]$ 具有相同类

别顺序的光谱组。根据这一方法，在结果评价时，将盲分解结果光谱 $[b^{(s_1)}, \dots, b^{(s_m)}]$ 赋予了类别信息。

根据讨论，盲分解结果与真实端元组的光谱匹配度应该在 $[-1, 1]$ 之间，值越大表明盲分解结果越精确。当然，光谱匹配度只能反映光谱波形的接近程度，而不能反映光谱幅度的接近程度。所以，即使在匹配度达到1时，盲分解得到的光谱与真实光谱仍然可能存在幅度上的差别。尽管如此，光谱匹配度仍然是有重要意义的，因为端元光谱波形为判断端元类别提供了直接依据。在本研究中，如果真实端元光谱组与盲分解得到的光谱组的匹配度小于0.6，则认为盲分解失败。

2) 端元丰度的评价

前文通过匹配度指得到了盲分解端元光谱的类别信息，这为评价盲分解的丰度提供了依据。假设端元类别为 c_1, \dots, c_m ，共有 p 个混合像元， a_{ij} 为第*i*个混合像元中类别 c_j 的真实丰度， \hat{a}_{ij} 为第*i*条光谱中类别 c_j 丰度的估计值。本文借鉴测量学中的平均误差指标来度量丰度误差

$$e = \frac{\sum_{i=1}^p \sum_{j=1}^m |a_{ij} - \hat{a}_{ij}|}{pm} \quad (9)$$

该指标反映了一组混合光谱中端元丰度误差的平均值，该指标越大表明盲分解的误差越大。需要注意的是，如果端元光谱曲线提取出现错误，则端元丰度误差也失去了意义。

3.2 合成高光谱试验

本研究中选取4个较常用的小波基sym-3、sym-4、db-3、db-4作为WPSDICA中的小波基。为了比较小波包分解和小波分解的差别，在本节试验和下节试验中将小波分解也作为辅助ICA的方法，实现方式与WPSDICA类似：仅将WPSDICA步骤中的小波包节点换成了小波节点，简称此方法为WSDICA（Wavelet approach to Sub-band Decomposition Independent Component Analysis）。WPSDICA和WSDICA中均进行了3层分解。

本试验从ENVI 4.7软件自带的光谱库中选取JPL2子库中三类物质的光谱，它们分别是ALUNITE SO-4A、NEPHELINE TS-16A、TRIPHYLITE P-4A（图1），三条光谱均有826个波段。以一定的丰度将三种光谱进行线性混合生成混合光谱（混合像元），共生成2组混合光谱，每组混合光谱均有3条混合光谱。丰度矩阵的行表示混合光谱编号，列表示端元编号，例如丰度矩阵的第3行第1列元素表示第3条混合光谱中第1个端元

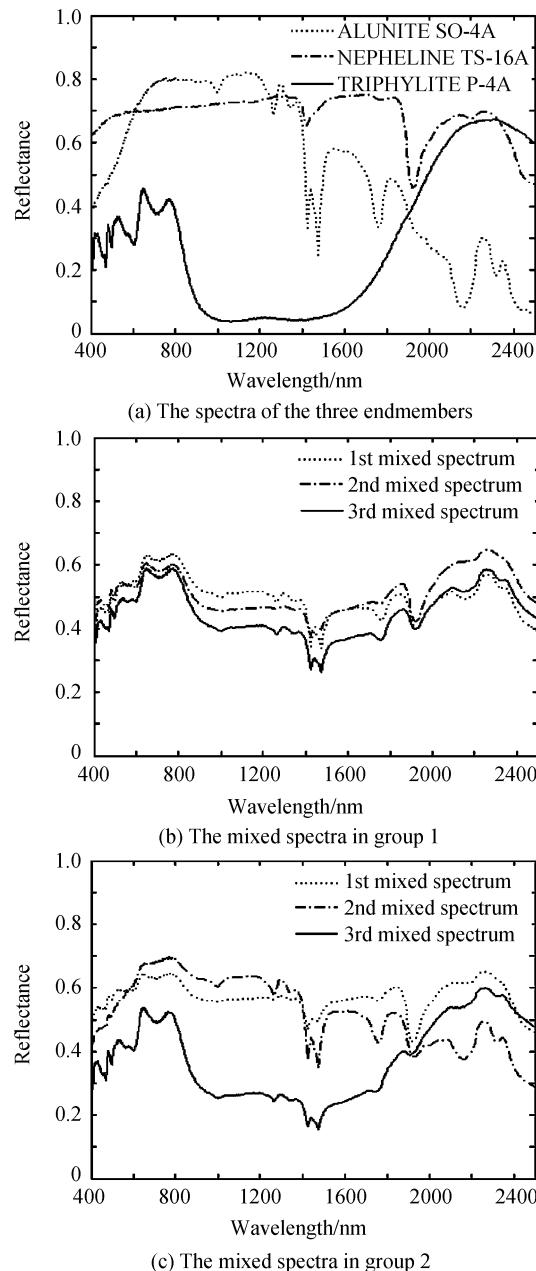


图1 合成光谱试验中的真实端元光谱和两组合成光谱
Fig. 1 Real spectra of the endmembers and two groups of synthetic spectra in the synthetic data based experiment
(ALUNITE SO-4A)的丰度值。两组混合光谱的真实丰度矩阵为

$$\text{丰度矩阵 } 1 = \begin{pmatrix} 0.30 & 0.35 & 0.35 \\ 0.10 & 0.50 & 0.40 \\ 0.25 & 0.25 & 0.50 \end{pmatrix}$$

$$\text{丰度矩阵 } 2 = \begin{pmatrix} 0.10 & 0.65 & 0.25 \\ 0.50 & 0.30 & 0.20 \\ 0.20 & 0.10 & 0.70 \end{pmatrix}$$

采用WPSDICA、WSDICA和ICA三种方法，分别解算出3端元的光谱曲线和丰度值，并通过3.1节中提出的匹配方法，将光谱曲线和丰度赋予类别

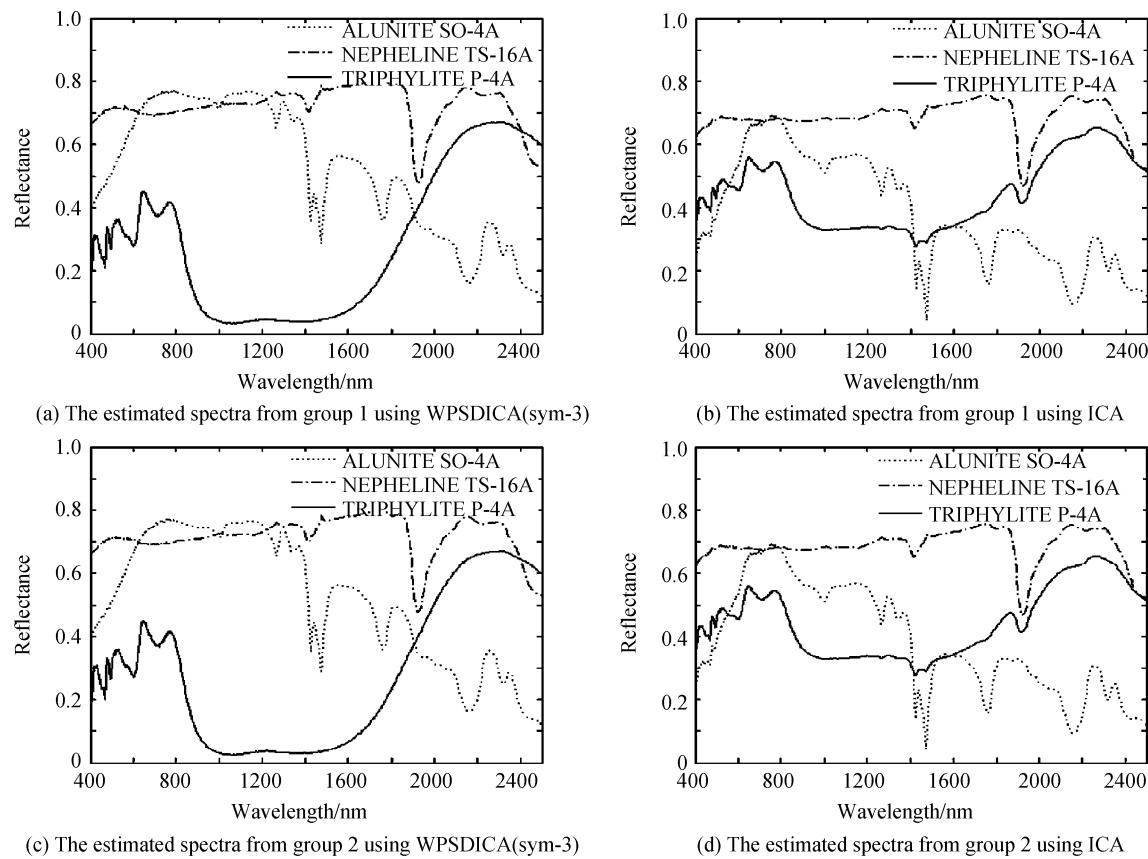


图 2 WPSDICA 和 ICA 分别对两组光谱盲分解得到的端元光谱(合成数据试验)

Fig. 2 The estimated endmember spectra from the two groups using WPSDICA and ICA respectively, in the synthetic data based experiment

表 1 合成光谱试验中 WPSDICA、WSDICA、ICA 方法的结果

Table 1 The results derived from WPSDICA, WSDICA and ICA in the synthetic data based experiment

Method	Group 1		Group 2		
	Spectral matching degree	Abundance error	Spectral matching degree	Abundance error	
WPSDICA	db-3	0.96	0.13	0.95	0.06
	db-4	0.98	0.03	0.98	0.03
	sym-3	0.96	0.06	0.96	0.06
	sym-4	0.97	0.04	0.97	0.05
WSDICA	db-3	0.96	0.13	0.96	0.06
	db-4	0.98	0.03	0.98	0.03
	sym-3	0.96	0.13	0.96	0.32
	sym-4	0.97	0.04	0.97	0.05
ICA	0.92	0.10	0.92	0.18	

(图 2),并基于真实数据对盲分解结果进行评价(表 1). 鉴于大部分情况下 WSDICA 和 WPSDICA 生成的端元光谱类似,所以本试验不列出 WSDICA 的端元光谱曲线. 通过对分解结果观察,可以发现:

1) 两组混合光谱分解得到的端元光谱中,通过 WPSDICA、WSDICA 提取的端元光谱与真实端元光谱波形非常接近,光谱匹配度均不低于 0.95, 均高于 ICA 方法的结果(0.92).

2) 根据第 1 组混合光谱中各方法的丰度误差,WPSDICA 中的 db-4、sym-3、sym-4 得到的结果均明显优于 ICA 方法,但 db-3 得到的结果略逊于 ICA 方法;而 WSDICA 中 db-3 和 sym-3 小波基得到结果逊于 ICA 方法.

3) 根据第 2 组混合光谱中各方法的丰度误差,WPSDICA 优于 WSDICA 和 ICA.

4) 总的来说,WPSDICA 得到的分解结果优于 ICA, WPSDICA 略优于 WSDICA, 其中 db-4、sym-3、sym-4 表现了较为优越的盲分解性能.

5) 需要注意的是,不同方法生成的端元光谱与真实光谱的匹配度相等时,丰度误差可能会有差别,这是因为光谱匹配度没有考虑光谱的幅度.

3.3 室内高光谱试验

考虑到真实遥感影像上存在几何纠正、空间响应、大气效应等问题,本文设计了室内控制实验来模拟遥感影像中的混合像元(图 3),以减少研究中的不确定性. 选取不同地物按一定比例平铺于一个圆柱形容器中,圆柱形容器的内壁和底部均被涂成黑色. 实验光源由两盏卤素灯提供,卤素灯位于容器正上方两侧,互成 45°. 光谱由手提式分光辐射度计(MS-720, EKO Instrument Co. Ltd., Japan)测

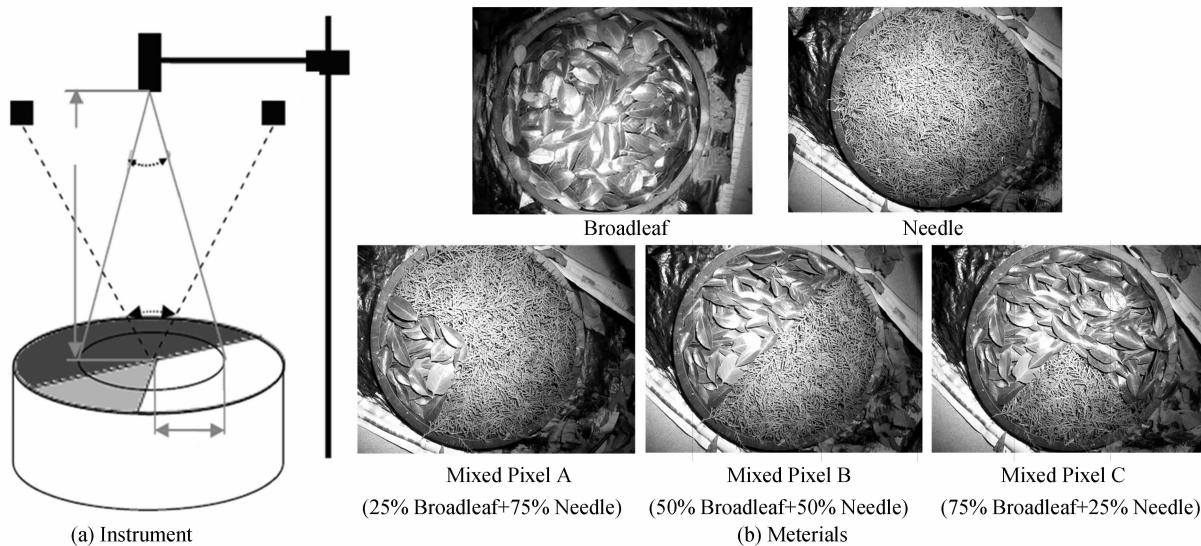


图3 室内试验中的装置和材料

Fig. 3 The instrument and the materials in the indoor experiment

量,波长范围为 $350\sim1050\text{ nm}$,光谱分辨率为 10 nm ,视场角为 25° 。手提式分光辐射计位于容器正上方 56 cm 处。由于光谱质量问题,本实验只采用 $500\sim1000\text{ nm}$ 波段的数据。

本试验采用阔叶和针叶作为研究对象。将阔叶和针叶按照 $25\%+75\%$, $50\%+50\%$, $75\%+25\%$ 三种比例进行混合,分别命名为像元A、像元B、像元C。为了进行试验,我们将这些像元两两组合构成3组像元,第1组像元包含像元A和像元B,第2组像元包含像元A和像元C,第3组像元包含像元B和像元C。这样,每组混合像元都有两个混合像元,且都包含两类端元。

首先测出阔叶和针叶的高光谱(图4),然后测出3个混合像元的高光谱(图4)。利用WPSDICA、WSDICA、ICA方法分别对3组混合像元进行盲分解,得到端元光谱曲线(图5),并对分解结果进行评价(表2)。鉴于大部分情况下WSDICA和

WPSDICA的端元光谱类似,所以本试验不列出WSDICA的端元光谱曲线。

对分解结果(图5和表2)观察,可以发现:

1) WPSDICA方法提取到的端元光谱波形准确,4个小波基得到的端元光谱与真实值的匹配度均达到1.00;ICA方法完全失效,提取的波形错误(与真实值的匹配度均低于0.6);WSDICA方法部分失效(小波基为sym-4时)。

2)考虑到ICA的端元光谱提取已经失效,其对应的丰度误差也失去意义。

3)根据各组混合光谱分解的丰度误差,WPSDICA优于WSDICA,仅在第2组中有两个小波基的结果略逊于WSDICA。

4)总的来说,本试验中WPSDICA方法明显优于ICA方法,并且优于WSDICA方法。其中db-3和sym-3小波基得到的结果一致,且表现了较好的盲分解性能。

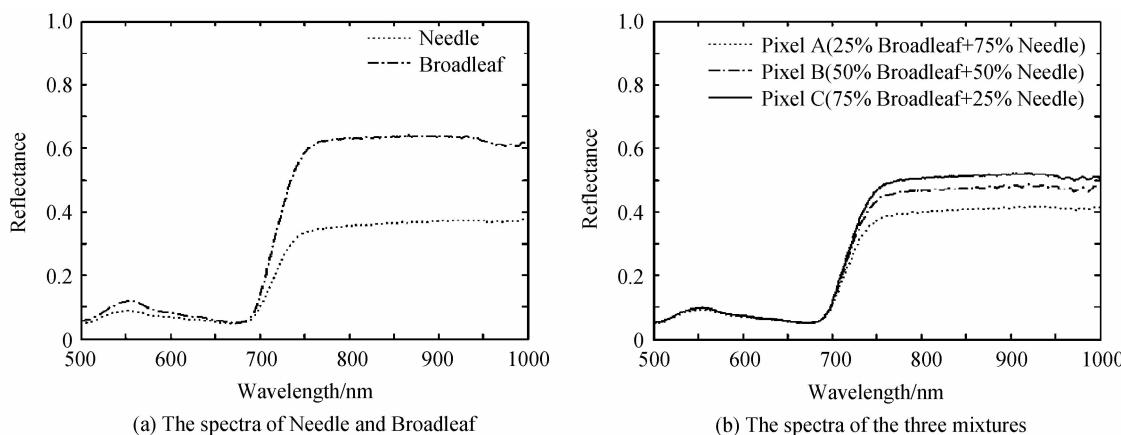


图4 室内试验中真实端元光谱和混合物光谱

Fig. 4 The measured spectra of the real endmembers and the mixtures in the indoor experiment

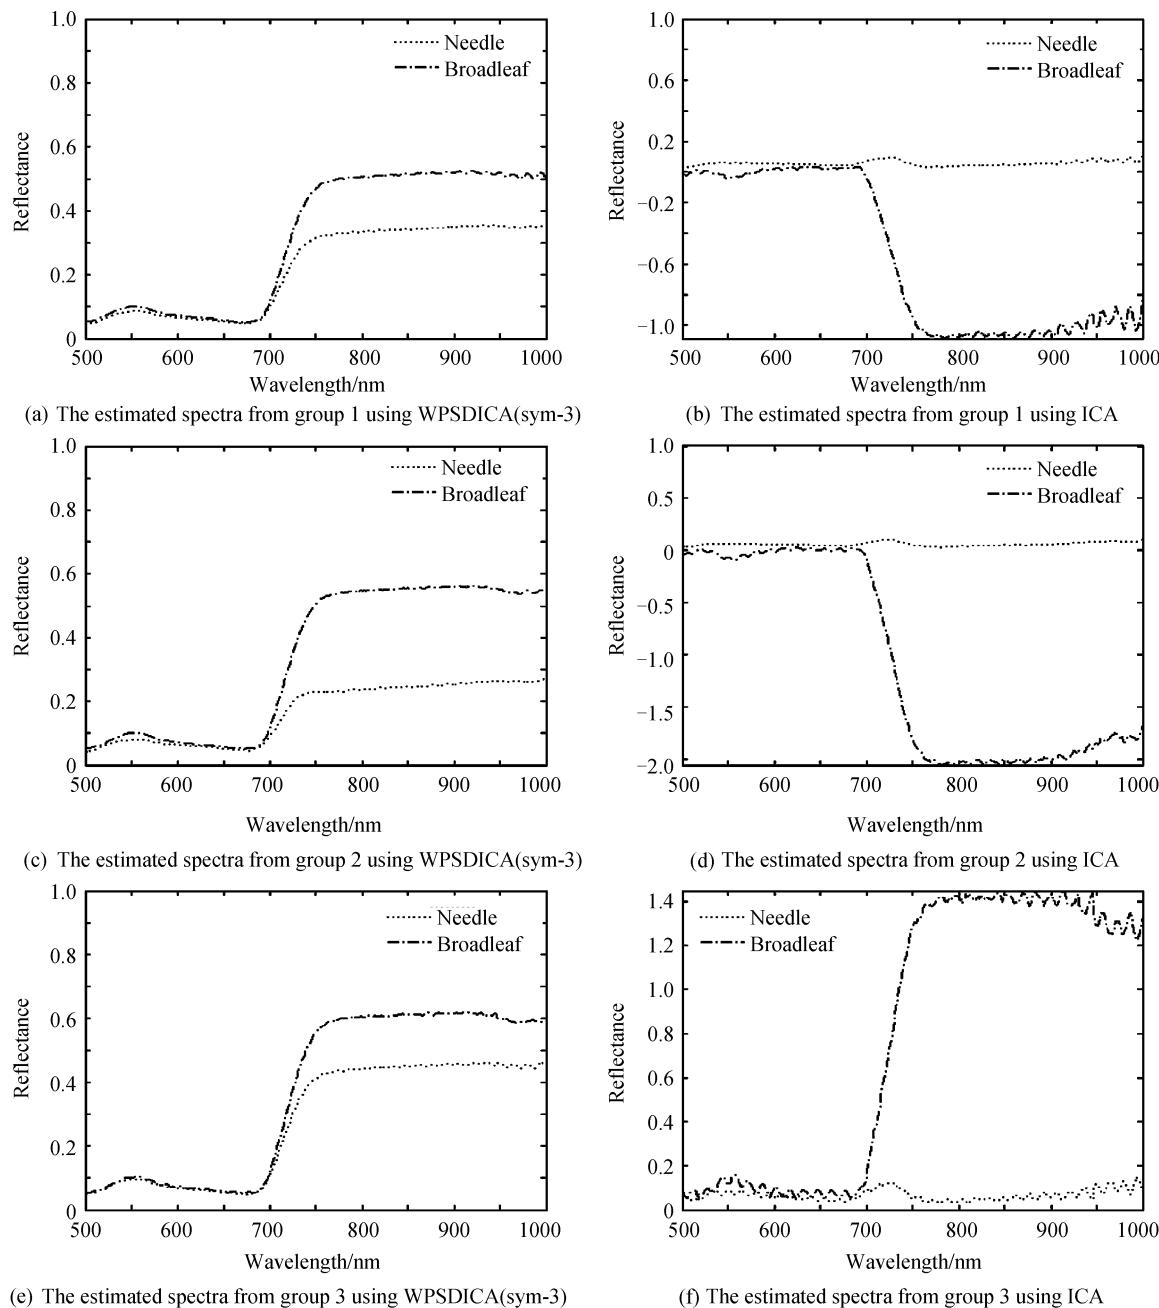


图 5 WPSDICA 和 ICA 分别对三组光谱盲分解得到的端元光谱(室内试验)

Fig. 5 The estimated endmember spectra from the three groups using WPSDICA and ICA respectively, in the indoor experiment

表 2 室内高光谱试验中 WPSDICA、WSDICA、ICA 方法的结果

Table 2 The results derived from WPSDICA, WSDICA and ICA in the synthetic data based experiment

Unmixing method	Group 1		Group 2		Group 3		
	Spectral matching degree	Abundance error	Spectral matching degree	Abundance error	Spectral matching degree	Abundance error	
WPSDICA	db-3	1.00	0.07	1.00	0.19	1.00	0.10
	db-4	1.00	0.36	1.00	0.12	1.00	0.02
	sym-3	1.00	0.07	1.00	0.19	1.00	0.10
	sym-4	1.00	0.17	1.00	0.26	1.00	0.23
WSDICA	db-3	1.00	0.47	1.00	0.18	1.00	0.34
	db-4	1.00	0.36	1.00	0.27	1.00	0.21
	sym-3	1.00	0.47	1.00	0.18	1.00	0.34
	sym-4	-0.43	0.98	1.00	0.26	1.00	0.37
ICA	-0.43	0.98	-0.43	0.70	0.55	0.11	

4 结论

本研究考虑到高光谱数据的实际情况,提出在WPSDICA 算法加入两个约束条件得到了改进后的WPSDICA 算法用于高光谱混合像元的盲分解。模拟数据试验和室内实测数据试验均表明本方法能够得到较好的分解准确度并优于ICA 算法。尤其在端元光谱强烈相关情况下(室内高光谱试验),ICA 算法完全失效,WPSDICA 能够取得较为满意的结果。另外,通过实验可以发现仅通过小波分解(WSDICA 方法)得到的结果逊于小波包分解,所以采用小波包分解是必要的。

今后的研究将会在以下几个方面进行:1) 如何将本文算法推广到遥感影像上;2) 如何根据高光谱数据自适应的选择小波基;3) 如何优化 WPSDICA 算法从而减少计算量。

参考文献

- [1] MOUSSAOUI S, HAUKSDOTTIR H, SCHMIDT F, et al. On the decomposition of Mars hyperspectral data by ICA and Bayesian positive source separation [J]. *Neurocomputing*, 2008, **71**(10-12): 2194-2208.
- [2] KESHAVA N, MUSTARD J F. Spectral unmixing[J]. *IEEE Signal Processing Magazine*, 2002, **19**(1): 44-57.
- [3] LIU Zhi-ming, Hu Bi-ru, WU Wen-jian, et al. Spectral imaging of green coating camouflage under hyperspectral detection[J]. *Acta Photonica Sinica*, 2009, **38**(4): 885-890.
刘志明,胡碧茹,吴文健,等.高光谱探测绿色涂料伪装的光谱成像研究[J].光子学报,2009,**38**(4):885-890.
- [4] NIAN Yong-jian, ZHANG Zhi, WANG Li-bao, et al. Target segmentation for hyperspectral imagery based on FastICA[J]. *Acta Photonica Sinica*, 2010, **39**(6): 1003-1009.
粘永健,张志,王力宝,等.基于FastICA 的高光谱图像目标分割[J].光子学报,2010,**39**(6):1003-1009.
- [5] NASCIMENTO J M P, DIAS J M B. Does independent component analysis play a role in unmixing hyperspectral data [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, **43**(1): 175-187.
- [6] HUCK A, GUILLAUME M, BLANC-TALON J. Minimum dispersion constrained nonnegative matrix factorization to unmix hyperspectral data [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2010, **48**: 2590-2602.
- [7] BAYLISS J, GUALTIERI J, CROMP R. Analyzing hyperspectral data with independent component analysis [C]// 26th Applied Imagery Pattern Recognition Washington, D. C., United States: International Society for Optical Engineering, 1997, **1340**: 133-143.
- [8] FAN Wen-jie, XU Xi-ru. Method for blind unmixing of mixed pixels[J]. *Progrss in Natural Science*, 2005, **18**(5): 993-998.
范闻捷,徐希孺.混合像元组分信息的盲分解方法[J].自然科学发展,2005,**18**(5):993-998.
- [9] TAO Xin, FAN Wen-jie, XU Xi-ru. Blind separation of component information from hyperspectral data [J]. *Acta Scientiarum Naturalium Universitatis Pekinensis*, 2008, **44**(6): 73-78.
陶欣,范闻捷,徐希孺.高光谱数据组分信息的盲分解方法[J].北京大学学报,2008,**44**(6):73-78.
- [10] TU T. Unsupervised signature extraction and separation in hyperspectral images: A noise-adjusted fast independent component analysis approach [J]. *Optical Engineering*, 2000, **39**(4): 897-906.
- [11] HYVARINEN A, OJA E. Independent component analysis: algorithms and applications[J]. *Neural Networks*, 2000, **13**(4-5): 411-430.
- [12] TANAKA T, CICHOCKI A. Subband decomposition independent component analysis and new performance criteria [C]// IEEE International Conference on Acoustics, Speech and Signal Processing. Piscataway, NJ , United States: Institute of Electrical and Electronics Engineers Inc. , 2004 (5): 541-544.
- [13] KOPRIVA I, SERSIC D. Wavelet packets approach to blind separation of statistically dependent sources [J]. *Neurocomputing*, 2008, **71**(7-9): 1642-1655.
- [14] WANG Yong-sheng, FU Yong-qing. Construction of complex contourlet packet transform and its application to image denoising[J]. *Acta Photonica Sinica*, 2010, **39**(9): 1697-1701.
王咏胜,付永庆.复轮廓波包的构造及其图像去噪应用[J].光子学报,2010,**39**(9):1697-1701.
- [15] Van der MEER F, BAKKER W. CCSM: Cross correlogram spectral matching [J]. *International Journal of Remote Sensing*, 1997, **18**(5): 1197-1201.

Blind Unmixing of Hyperspectral Mixed Pixels Assisted by Wavelet Packet Decomposition

LI Xi¹, CHEN Xue-hong², CHEN Xiao-ling¹, TIAN Li-qiao¹, CHEN Feng-rui³

(1 State Key Laboratory of Information Engineering in Surveying, Mapping and Remote Sensing,
Wuhan University, Wuhan 430079, China)

(2 Graduate School of Environmental Studies, Nagoya University, Nagoya, 464-8601, Japan)

(3 Institute of Remote Sensing Applications, Chinese Academy of Sciences, Beijing 100101, China)

Abstract: A method called “wavelet packet approach to sub-band decomposition independent component analysis” was introduced to unmix hyperspectral mixed pixels. Using wavelet packet decomposition technique to improve independent component analysis, a blind unmixing method for hyperspectral data was proposed considering the characteristics of hyperspectral data, and this method could overcome the drawback derived from statistical independence assumption in independent component analysis. Two groups of synthetic data and three groups of indoor data were used to evaluate this method. The experiments show that spectra and fractional abundances of the endmembers can be retrieved precisely using the proposed method, and its accuracy is significantly higher than that of independent component analysis. This approach is useful for blind unmixing of hyperspectral remotely sensed imagery.

Key words: Remote sensing; Wavelet packet decomposition; Mixed pixel; Independent component analysis; Linear spectral mixture model