

高光谱端元自动提取的迭代分解方法

吴 波, 张良培, 李平湘

(武汉大学 测绘遥感信息工程国家重点实验室, 湖北 武汉 430079)

摘 要:混合像元线性分解技术是进行高光谱影像处理的常用方法,应用这种方法的一个主要问题是难以有效、自动地确定影像的端元光谱。利用非监督的方法快速自动提取高光谱遥感图像的端元光谱是解决这个问题的主要技术手段。根据迭代误差分析思路,通过对线性混合像元模型分解的误差传播分析后,得到了端元选择的约束条件。结合端元存在的空间信息,自动提取出端元光谱并进行了混合像元分解。利用不同地区、不同传感器的高光谱数据实例测试了该文的方法,分析和讨论了选择迭代初始值与参数阈值的敏感性问题。研究结果表明此方法可以自动提取端元光谱,并且精度较高。

关键词: 端元自动提取;混合像元;迭代分解

中图分类号: TP732 **文献标识码:** A

1 引 言

由于传感器的空间分辨率以及地面的复杂多样性,混合像元普遍存在于遥感图像中。利用成像光谱仪进行定量遥感应用的一个突出问题就是混合像元的分解问题,如何有效地解译混合像元是高光谱遥感应用的关键问题之一^[1]。混合像元分解方法是以端元光谱(endmember)为条件建立的,首先必须以监督或非监督的方法找到所谓的端元光谱。传统的方法以监督的手段,利用人机交互选取端元光谱^[2],很难获取完整的地物端元光谱,且不利于遥感影像的快速处理。遥感学者更重视从数据本身挖掘出端元光谱,提出了一系列非监督的技术方法自动寻找端元光谱。目前比较成功的方法有投影追踪法^[3](PP)、模拟退火算法^[4](SAA)、凸锥分析方法^[5]CCA和N-FINDR^[6]等等。这些方法都有成功应用的一面,但由于端元光谱的不确定性,目前还没有普适的方法。文献[7]研究、评价了一些典型的方法,并认为联合空间信息有助于提高分解效果。

近年来,一些研究者利用迭代误差的思路来自动选取端元光谱^[8,9]。这种方法的本质是根据分块

矩阵的原理,对影像进行线性分解后的残存误差来定位端元光谱的位置,并依据阈值来指导选择端元光谱。它们共同缺点是没有考虑端元存在的空间关系。事实上,端元在空间分布上应当有一定的形状和积聚性,充分利用这个特点就相应增加了信息量,将有助于改善像元的分解结果。另一方面,如果选择端元时考虑了端元彼此间的独立关系,就有可能获得更好的分解矩阵。因此,作者认为除了利用误差信息来定位端元光谱的位置外,还应从端元的空间分布和彼此间的关系方面加上相应的约束条件。

2 端元选择的约束条件

对混合像元,利用线性混合模型描述为:

$$\rho = P f_0 + \epsilon_0 \quad (1)$$

式中 ρ 为混合像元在 n 个光谱通道上测量的反射率所组成的 n 维列矢量, P 是 n 行 m 列的矩阵,它的列是 m 个像元组分光谱矢量, f_0 是像元组分比, ϵ_0 为 n 维误差项。

由最小二乘法,可以得到 f_0 的估计值 f_{LS} :

$$f_{LS} = (P^T P)^{-1} P^T \rho \quad (2)$$

估计值与真实值之差记为 $\Delta f = f_{LS} - f_0$, 并把

收稿日期:2004-03-03;修订日期:2004-04-27

基金项目:国家自然科学基金(40471088),国家973研究计划(2003CB415205),遥感科学与技术国家重点实验室开放基金资助。

作者简介:吴波(1975—),男,武汉大学摄影测量与遥感专业博士生。主要研究领域图像处理、模式识别、Agent模型等。

(1)代入(2)得到:

$$\Delta f = (P^T P)^{-1} P^T \epsilon_0 \quad (3)$$

记 $R = (P^T P)$, $\alpha = R^{-1}$, 并假设 $\Sigma_{\epsilon_0} = \sigma^2 I$, 则有:

$$\Delta f^2 = \sigma^2 Tr(\alpha) \quad (4)$$

其中 $Tr(\alpha)$ 表示对 α 矩阵求迹。如果选取端元光谱存在误差时, 等于在 P 基础上加相应的一个微小变量 Δp , 则

$$\rho = (P + \Delta p)f_0 = Pf_0 + \Delta pf_0 \quad (5)$$

假使 ϵ_0 是因为选取端元光谱存在误差引起的, 比较(1)和(5)两式得:

$$\epsilon_0 = \Delta pf_0 \quad (6)$$

其中 Δp 中各列为 $\delta_i = [\delta_{i1}, \delta_{i2}, \dots, \delta_{im}]$, 进一步假设 σ_{δ_j} 有相同的方差 δ_i^2 , 且 Δp 中各列相互独立, 即 $E[\delta_i \delta_j] = 0$, $R_i = E[\delta_i \delta_i^T] = \sigma_i^2 I$; 则可以得到:

$$\sigma^2 = \sum_{i=1}^m \sigma_i^2 f_{i0} \quad (7)$$

其中 σ_i^2 表示端元光谱矢量内的方差, f_{i0} 是实际像元组分比, n 为光谱通道数。把(7)式代入(4)式得:

$$\Delta f^2 = Tr(\alpha) \sum_{i=1}^m \sigma_i^2 f_{i0}^2 \quad (8)$$

式(8)中, m 和 f_{i0} 是确定的, 所以要减少 Δf , 需减小 σ_i^2 和 $Tr(\alpha)$ 的值。减小端元光谱内矢量间的差别就减小了 σ_i^2 , 而减小 $Tr(\alpha)$ 的值, 也就是需增大端元光谱矢量间的差别。文献[10]对两个端元情况下像元分解的误差传播分析, 得到 Δf 与这两个端元光谱矢量间的欧几里得距离和光谱角度有关, 且有成反比的规律。

下面讨论方程解的稳定性。因 R 是实正定对称矩阵, 存在正交矩阵 Q , 使得 $Q^T \Lambda Q = R$, 代入(4)得:

$$\Delta f^2 = \sigma^2 \sum_{i=1}^m \frac{1}{\lambda_i} \quad (\lambda_i > 0) \quad (9)$$

由(9)知, 如果 Λ^* 矩阵的对角元素中有很小的 λ_i , 则有较大的分解误差, 这时称 R 为病态矩阵, 避免这种情况的办法是使 $CN(R)$ 值较小。如果 R 为对称矩阵, 则 $CN(R)$ 定义为:

$$CN(R) = \frac{\lambda_{\max}}{\lambda_{\min}} \quad (10)$$

为减小 $CN(R)$ 值, 在选择端元光谱时, 尽量使它们相互独立, 即增大不同端元光谱之间的差距。

3 端元光谱提取的算法

现在讨论选择端元光谱矢量。假设 $P(k) =$

$[P_1, P_2, \dots, P_k]$ 为已选定的端元光谱矢量, 首先利用这些端元对图像分解, 设法找到最大误差的位置 (x_i, y_i) , 其像元矢量记为 P_{k+1} , 现在需要确定第 P_{k+1} 种光谱矢量是否为端元光谱矢量的问题。

(a) 空间分布信息。如果 P_{k+1} 是端元, 则以该点为中心的一定范围内且与 P_{k+1} 相似的光谱矢量数目 S 需要大于某个门限值 Ψ 。因为较大的 Ψ 值可以减少噪声的干扰, 所以此处需要考察一个较大的邻域, 即开一个较大的窗口。光谱矢量的相似性可以用其广义角 θ 度量。如果 θ 越小, 则相似性越大。

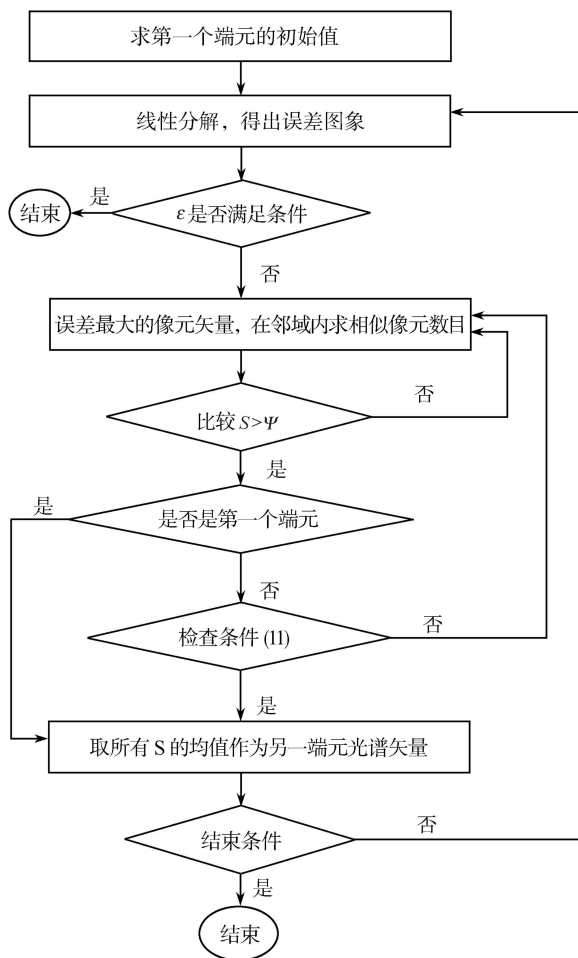


图1 计算流程图

Fig.1 Flow chat of the proposed algorithm

(b) 模型解的可靠性。如果选择 P_{k+1} 为端元, $P = [p_1, p_2, \dots, p_k]$, 那么为保证不同端元之间的差别, P_{k+1} 投影到 $P(k)$ 上应当大于一定的值^[11]。即:

$$\frac{\|P_{k+1} p_m\|}{\|P_{k+1}\| \cdot \|p_m\|} \geq \varphi, \quad m = 1, 2, \dots, k \quad (11)$$

* Λ 为对角矩阵的标示符。

式(8)中得到要减少 Δf , 通过选择光谱矢量, 以增大端元矢量之间的欧几里得距离(10)式的条件也在于选择 P 矩阵, 而(10)式可以保证选择的光谱矢量有较大的差别。所以 P_{k+1} 如果 P_{k+1} 通过了(a)和(b)这两个限制条件的检验, 则认为它是端元, 用它与矩阵 P 一起构成新矩阵 $P(k+1)$ 后, 再分解计算误差图像; 否则对 (x_i, y_i) 位置作标记, 对另外的最大误差位置的矢量进行相同的考察。

结束条件是分解误差 ϵ 直接满足要求, 或得到了指定个数的端元。实际上, 如果 $|\epsilon(k+1) - \epsilon(k)| < \eta$, 则可终止计算。 η 为一很小的正数, 其计算流程如图 1。

4 混合像元分解

理论与实验结果都证实了限制性分解较非限制性方法精度高^[12]。本文也采用限制性分解的模型计算, 虽然上面推导得到的约束条件是在非限制性模型下得到的, 但仍然认为适用于限制性分解模型。在(1)式的基础上增加限制性条件:

$$\sum_{i=1}^m f_i = 1 \text{ 且 } f_i \geq 0 \quad (12)$$

采用迭代公式计算^[12]:

$$f_{cls}^{(k+1)} = f_{ls}^{(k)} - \alpha (\lambda_1^k I + \lambda_2^k \text{sgn}(f_{cls}^{(k)})) \quad (13)$$

其中 $f_{cls}^{(k)}$ 为第 k 次迭代限制性求解的像元比, $f_{ls}^{(k)}$ 是第 k 次非限制性求解的结果, λ_1^k 与 λ_2^k 是第 k 次拉格朗日乘数的系数, $\alpha = (P^T P)^{-1}$ 。如果有 $f_{cls}^{(k+1)}(i)$, ($i=1, 2, \dots, m$) 小于零, 用(13)式继续迭代, 直到 $\sum_{i=1}^m |f_i| - \zeta < 1$ 时结束, 其中 $\zeta=0.01$, 为一很小的正数。

5 实验分析

根据算法描述, 作者在 VC6.0 下实现了端元自动提取与混合像元分解的功能。为考察该方法的有效性, 从以下 4 个方面进行了测试。①考察选择不同的初始值时, 对端元提取与混合像元分解的影响; ②进一步讨论算法中的一些阈值灵敏性问题; ③美国内华达州 Cuprite 地区的 AVIRIS 数据的分解实验; ④中国常州地区的 PHI 数据的分解实验。

图 2(波长: $R=2.10\mu\text{m}$, $G=2.20$, $B=2.34\mu\text{m}$) 是一幅 ENVI 软件自带的 AVIRIS 示例数据。成像于

1995 年。其大小为 400×350 , 波长范围是 $1.99 - 2.48\mu\text{m}$, 共有 172-221 波段间的 50 个波段数据。




图 2 Cuprite 地区的 AVIRIS 数据
Fig.2 AVIRIS image data in cuprite region




图 3 MNF 变化后的特征值
Fig.3 The eigenvalues after MNF transform

由于高光谱数据相邻波段间的相关系数较大, 信息冗余大。同时兼顾计算时间, 本文考虑了特征波段选择。关键问题是确定选取特征波段的数目。特征波段的选择数目首先不能少于端元数目, 否则会出现不可分的问题。影像中的端元数目可以从影像 MNF 变化后的特征值分布转折点的情况大致确定^[13]。为此在 ENVI 平台下对原始数据进行了 MNF 处理, 得到了其特征值, 如图 3。从图 3 中可知大致有 8-10 个独立成分, 故选取特征波段的数目不得小于 10。因第 10 个特征值为 1.5, 故以特征值 1.0 作为阈值来选取波段的数目, 本例只有 15 个特征值大于 1.0, 故根据波段间相关系数的大小, 从中选择了 15 个波段进行后面的实验(波段数目可以大于端元数目, 实验结果表明直接利用 PCA 或 MNF 变换后的影像效果并不好, 因而采用直接方法抽取波段)。

5.1 实验 1: 用 AVIRIS 测试初始值对端元提取与混合像元分解的影响

由于该方法是逐步求取端元, 前面端元的选取

对后面端元的选择可能会有重大的影响,本实验的目的在于验证不同初试值对端元提取与混合像元分解的影响。考虑了以下3种方法的初始迭代像元矢量。(1)波段平均值。(2)波段最大值。(3)任意值,选择了(100,200)为代表。表1、表2、表3是计算得出的结果。 $(R=11, \Psi=50, \theta=1.2, \varphi=2.5)$ 从表中数据可以看出不同初始值对结果几乎没有影响,只是颠倒了第一与第二个端元的顺序。因第三个端元以后所有指标都是相同的,故第三个以后的端元结果没有列在表上。

表1 初始值为平均值的情况下的结果

Table 1 The results of using average pixel value

端元	图像坐标	相似像元	最大误差	平均误差
1	(170, 325)	50	255.5	27.0
2	(49, 385)	50	308.9	201.0
3	(273, 26)	64	42.8	17.4

表2 初始值为最大值的情况下的结果

Table 2 The results of using maximum pixel value

端元	图像坐标	相似像元	最大误差	平均误差
1	(49, 385)	50	484.4	376.8
2	(170, 325)	50	319.2	68.3
3	(273, 26)	64	42.8	17.4

表4 取不同 θ 参数值时的计算结果

Table 4 The computing results by using different θ value

θ	端元1	端元2	端元3	端元4	端元5	端元6	端元7	端元8	端元9	端元10
0.8	376.3	57.1	15.9	7.1	4.5	3.4	3.0	2.5	2.1	1.8
0.9	376.6	60.9	16.2	7.8	4.8	3.5	3.0	2.6	2.4	2.0
1.0	376.8	40.5	16.7	7.9	5.0	4.4	3.5	2.9	2.6	2.1
1.1	376.8	41.0	16.6	7.6	4.8	4.4	3.6	3.1	2.7	2.2
1.2	376.8	68.3	17.4	8.2	5.2	4.5	3.6	3.2	2.7	2.2

(b)参数 Ψ 在区间[10,50]内变化,步长每次增加10,结果表明 EMS 只在前5个端元间变动,且变动幅度很小。同样让 R 在区间[7,11]内变化,步长每次增加1,得出类似的结果。参数 φ 是描述端元光谱之间差距的阈值,而 θ 是端元光谱内的阈值,可设定 φ 为2-3倍的 θ 值,实验表明 $\varphi \in [2, 3]$ 分解效果都较好。实验2说明阈值的选择并没有严格的要求。

5.3 实验3: AVIRIS 数据的分解实验

实验数据说明同上,在参数取值为 $R=11, \theta=0.8, S=50$,设定端元最大数目为10的条件下计算

表3 初始值为随机值的情况下的结果

Table 3 The results of using random pixel value

端元	图像坐标	相似像元	最大误差	平均误差
1	(170, 325)	50	241.0	33.2
2	(49, 385)	50	308.9	201.0
3	(273, 26)	64	42.8	17.4

5.2 实验2: 阈值灵敏性的讨论

本文使用了一些阈值控制端元的选择,主要有邻域搜索半径 R ,最小相似像元数目 Ψ ,描述端元内的光谱角 θ 。不同端元间阈值 φ 。实验2的目的在于说明这些参数一定程度上的鲁棒性。方法是保持其它参数不动,每次只变动一个参数。

(a)保持 $R=11, \Psi=50$ 与 $\varphi=2.5$ 不变,光谱角度 θ 在[0.8, 1.2]区间取值,步长每次增加0.1。以平均分解误差 RMS 为指标说明 θ 取值的鲁棒性。表4是得到的一些计算结果。从表4中可以看出选出的10个端元分解后的 RMS 基本上都相同。并且有 θ 越小,分解结果更好的趋势。这是因为 θ 越小,选取端元越纯。但考虑到其它的约束条件, θ 也不是越小越好。

的结果, $RMS=1.8$ 。

图4表示的是分解误差随选择端元数目增加而不断减小的规律,从中可以看出只有前5个端元时误差减小的非常快,用这5种端元光谱分解后误差就已经很小了,此时误差为 $RMS=4.5$ 。此后误差随端元数目增加而减小的过程则逐渐趋于平缓,但总体还是慢慢在减小,这说明该图像主要由5种独立地物构成,且用该方法逐步提取出的端元光谱对图像的构成贡献有从大到小的特点。图5是分解后的误差图象,从分解效果来看,误差图像除了中间还有一小亮斑,似乎还有些信息没有提取出来外,其它基本上为噪声图像。小亮斑出现的原因,与分解的

最大端元数目选择有关,本实验最大端元数目设定为10,如果设定最大端元数目为15,则可以得到最终的 $RMS = 0.34$ 。但提取的端元基本上为噪声图像。

况,经与美国地质调查局(USGS)调查结果比较^[14](图7)。确认出各端元分别为(a)山体、阴影;(b)黄钾铁矾;(c)针铁矿;(d)明矾;(e)白云母;(f)玉髓;(g)高岭石;(h)方解石;(i)没有找到对应的物质,认为是噪声图像;(j)钠蒙脱石。

图6是按照端元提取的顺序排列的端元分布情况




图4 误差随端元增加而减小的曲线

Fig.4 The diminishing error curve with increasing endmember number




图5 误差图像

Fig.5 Error image




图6 端元的空间分布

Fig.6 The distribution of endmember in spatial




图7 美国地质调查局资料(Cuprite, Nevada, 1995)

Fig.7 The thematic imagery mapped by USGS in 1995 (Cuprite, Nevada)




图8 夏桥的 PHI 数据

Fig.8 PHI image data in Xiaqiao area

5.4 实验 4:PHI 高光谱数据的分解实验

该实验所用数据成像光谱仪(PHI)影像位于江苏省常州市夏桥,获取于1999年9月。经度 $119^{\circ}22'11''$,纬度是 $31^{\circ}41'44''$ 。主要的地物类型有道路、水体、水稻、土壤等。对数据作了几何精纠正和辐射纠正,经定标转换为反射率的遥感影像。共有80个波段,波长范围在 $0.42-0.85\mu\text{m}$ 。从中选取了一块大小为 200×200 的区域进行实验。图8(波长: $R=0.4481\mu\text{m}$, $G=0.5665\mu\text{m}$, $B=0.8187\mu\text{m}$)是该区域的RGB图像,已经对图中的主要地物类型作了标示,图中R表示道路;C代表水稻作物;V是蔬菜等非谷物;W表示水体;S是土壤、稀疏草地等。

由图9可知该影像有5-6个独立地物,故设定最大端元数目为6。最后分解后 $RMS=0.30$,分解出的6个图像中,经与实际地面数据比较辨认,认为




图 10 分解结果

Fig.10 The result of unmixing

从中看出分离出的五个端元(图中色度亮的地方)分别为道路、水体、菜地、稻田和稀疏草地。其分布情况与实地调查一致(见图8图示)。图11为这五种端元对应的光谱 z 剖面曲线,光谱曲线表明菜地、稀疏草地(土壤)与水稻表现出植被的光谱曲线特征,但本文的方法还是把它们区分出来了。分解后由前3个像元组分比重新合成的图像如图12。图13是获得的误差图像。图中基本上为噪声图像。




图 11 端元光谱曲线

Fig.11 Endmember spectral profile

共有5个端元。这5个端元由图10中前5个子图像表示((a)道路;(b)水体;(c)菜地;(d)稻田;(e)土壤、稀疏草地)。




图 9 MNF 变化的特征值

Fig.9 The eigenvalue after MNF transform




图 12 前三个组分的 RGB 图像

Fig.12 RGB image combined by the first three abundances




图 13 误差图像

Fig.13 Error image

6 结 论

本文通过对混合像元线性模型分析后,提出了基于空间信息的误差迭代分解方法。讨论了用不同初始迭代值求解的问题与阈值的灵敏性问题,并用不同地区,不同传感器的影像对该方法进行了实验测试。得出以下结论:

(1)在选取端元光谱时需要考虑(a)减小相同端元光谱矢量间的差别;同时增加不同端元光谱矢量间的差别。(b)减小 $CN(R)$ 的值;

(2)利用端元在空间分布上具有一定的形状和积聚性的特点,有助于提取更纯的端元,能够在处理信噪比较低的图像中减少误把噪声当作端元的机会;

(3)实验分解效果和误差图像的结果证明可以用这种方法自动提取端元,并且可以获知图像主要独立地物的端元及其数目;

(4)计算时间与端元数目、门限值的选择有关;

(5)进一步研究表明,用小波系数特征的影像分解的效果更好,目前正在整理、总结这方面的成果。

参考文献 (References)

[1] Chen S P, Tong Q X, Guo H D. Research on Mechanism of Remote Sensing Information [M]. Science Press, Beijing, 1998. [陈述彭, 童庆喜, 郭华东. 遥感信息机理研究 [M]. 北京·科学出版社, 1998.]

[2] Bateson C. A, Curtiss B. A Tool for Manual Endmember Selection and Spectral Unmixing [A]. in Summaries of the V JPL Airborne Earth Science Workshop [C]. Pasadena, CA, 1993.

[3] Ifarraguerri A, Chein-I Chang. Unsupervised Hyperspectral Image Analysis with Projection Pursuit [J]. *IEEE Trans. Geoscience and*

Remote Sensing, 2000, **38**(6); 2529—2538.

[4] Penn B. S. Using Simulated Annealing to Obtain Optimal Linear Endmember Mixtures of Hyperspectral Data [J]. *Computers & Geosciences*, 2002, **28**: 809—817.

[5] Ifarraguerri A, Chang C I. Multispectral and hyperspectral Image Analysis with Convex Cones [J]. *IEEE Trans. Geoscience and remote sensing*, 1999, **37**(5); 756—770.

[6] Winter M E. N-FINDR: An Algorithm for Fast Autonomous Spectral Endmember Determination in Hyper Spectral Data [A]. Proc. SPIE Imaging Spectrometry [C]. 1999, 266—275.

[7] Plaza A, Martínez P, Pérez R. A Quantitative and Comparative Analysis of Endmember Extraction Algorithms From Hyperspectral Data [J]. *IEEE Trans. Geoscience and Remote Sensing*. 2004, **42**(3); 650—663.

[8] Neville R A, Szeredi T, Lefebvre J. Automatic Endmember Extraction from Hyperspectral data for Mineral Exploration [A]. Proc. 21st Can. Symp. Remote Sensing [C]. Ottawa, Canada, 1999.

[9] Daniel C Heinz, Chein-I Chang. Real-Time Processing of an Unsupervised Constrained Linear Spectral Unmixing Algorithm [A]. IGARSS 01. Geoscience and Remote Sensing Symposium [C]. 2002, 372—374.

[10] Sharp M H. Analysis of Error Propagation in Spectral Unmixing [A]. IGARSS01, Geoscience and Remote Sensing Symposium [C]. 2001, 2376—2378.

[11] Hsuan Ren, Qian Du, James Jensen. Constrained Weighted Least Squares Approaches for Target Detection and Classification in Hyperspectral Imagery [A]. IGARSS02. Geoscience and Remote Sensing Symposium [C]. 2002, 6; 3426—3428.

[12] Acito N, Corsini G, M. Diani. An Unsupervised Algorithm for the Selection of Endmember in Hyperspectral Imagery [A]. IGARSS02. Geoscience and Remote Sensing Symposium [C]. 2002, (3); 1673—1675.

[13] Tu T M, Huang P S, Chen P Y. Blind Separation of Spectral Signatures in Hyperspectral Imagery [A]. IEE Proc. -Vis. Image Signal Process [C]. 2001, **148**(4); 217—225.

[14] <http://speclab.cr.usgs.gov>

Automatic Extraction of Endmember from Hyperspectral Imagery by Iterative Unmixing

WU Bo, ZHANG Liang-pei, LI Ping-xiang

(State Key Lab of Information Engineering in Surveying, Mapping & Remote Sensing, Wuhan University, Wuhan 430079, China)

Abstract: Linear pixel unmixing is a straightforward and efficient approach to the spectral decomposition of multi-channel & hyperspectral remotely sensed scenes. A main drawback to its utilization in operational cases is that the endmember of spectral components can not be retrieved correctly and automatically. Developing unsupervised methods to automatically abstract endmember is a difficult but significant job. The authors presented an iterative error analysis algorithm to retrieve endmembers and unmixing hyperspectral imagery automatically after obtaining some constraint conditions of selecting endmembers by analyzing error propagation in linear spectral unmixing model, and combined with the property of endmember which is cohesive in spatial. The experimental results show the algorithm is robust by testing various thresholds and initial iterative value. Other experiments for test efficiency and accuracy of the algorithm by employing AVIRIS and PHI hyperspectral data were also done.

Key words: automated endmember extraction; mixing pixels; iterative unmixing