

文章编号: 1007 4619 (2006) 03 0312 07

基于支撑向量回归的高光谱混合像元非线性分解

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: 提出了基于支撑向量回归的高光谱混合像元自动分解。首先利用投影迭代的方法自动寻找到影像的典型地物光谱, 然后利用 Hapke 近似函数模拟出非线性的训练和测试数据。支撑向量回归的混合像元分解方法与基于基函数分解方法的不同点是不需要预先确定非线性的映射形式, 它通过核函数, 把像元矢量从低维空间映射到高维特征空间, 使得在特征空间中构造的线性光谱组合对应着原始空间 (像元空间) 的非线性组合特性, 从而揭示了典型地物光谱之间的高阶性质, 提高了混合像元的分解精度。实验结果证明, 这种方法具有很高的混合像元的分解精度。利用模拟数据作分解精度的评价, 表明 97% 以上的像元分解绝对误差不大于 10%, 而各类总体平均平方根误差均小于 3.5%。

关键词: 光谱分解; 迭代投影; 支撑向量回归; 非线性

中图分类号: TP391.41 **文献标识码:** A

Unmixing Hyperspectral Imagery Based on Support Vector Nonlinear Approximating Regression

WU Bo, ZHANG Liangpei, LI Pingxiang

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

Abstract: Spectral Mixture Analysis (SMA) is a straightforward and efficient approach to the spectral decomposition of hyperspectral remotely sensed scenes. Once a SMA model is developed, land cover proportions can be estimated from pixel values through model inversion. In this paper, we propose to estimate abundances from hyperspectral image using support vector regression (SVR) method. SVR method for abundance estimation can be essentially regarded as function approximation and generalization problem. Differing from other nonlinear regressive approaches which require predefined nonlinear mapping functions, this method transferred each spectral pixel into a high dimension feature space by a kernel function, which will result in a spectral pixel in a feature space consisting of possibly many nonlinear combinations of the spectral bands of the original spectral signature. In this way the higher order relationships between the mixed pixels are exploited in the feature space. Projection iterative method has been used for endmember abstraction from the image, and then simulating nonlinear training and testing data by Hapke's approximation function. Experiment of simulating data and real hyperspectral image (Pushbroom Hyperspectral Image, PHD) are conducted to validate the procedures. The experiments show that the method can provide better result of abundance estimation for hyperspectral image as compared with that of radial basis function neural networks. In our simulating test, over 97% of the total pixels in the image lie within the bound of ± 0.1 , and the RMSE are no more than 3.5%.

Key words: spectral unmixing; iterative projection; support vector regression; nonlinear

收稿日期: 2005 05 16; 修订日期: 2005 09 15

基金项目: 国家自然科学基金 (40523005), 国家 973 研究计划 (2003CB415205), 遥感科学国家重点实验室开放基金。

作者简介: 吴 波 (1975—), 男, 武汉大学摄影测量与遥感专业 2003 级博士生。主要研究图像处理、模式识别、Agent 模型等。E-mail:

wavelet778@sohu.com.

1 引 言

遥感影像中像元很少是由单一均匀的地表覆盖类组成的,一般都是以混合像元的形式存在于影像中。混合像元问题不仅是遥感技术向量化深入发展的重要障碍,而且也严重影响计算机处理的效果或计算机技术在遥感领域中的应用^[1]。针对混合像元分解问题,国内外开展了大量的研究。近年来的研究方向主要体现在新方法与新思路的不断探索中,并提出了各种神经网络模型^[2,3],随机混合模型^[4],非线性逐步回归模型^[5]以及基于优化的搜索模型^[6]等方法。由于理论与实验结果均表明非线性模型要比线性模型计算的结果好,因此利用非线性的混合像元分解模型正逐渐成为研究热点^[2,3,5,6]。然而,很多非线性回归模型需要预先确定非线性的形式,但这种非线性的关系通常却很难知道,而且非线性模型的计算通常比较复杂,因而在实际应用中缺乏普遍的应用意义。

支撑向量回归(SVR)建立在坚实的数学基础上,在高维空间具有良好的学习性能和推广能力,非常适合解决复杂情况下的函数逼近问题^[7]。支撑向量最近已被引入到高光谱遥感分类研究中,并取得了很好的分类效果^[8,9]。但分类与分解是两个相互联系的不同问题,它们分别属于模式识别与回归估计的不同领域,而目前利用支撑向量回归的混合像元分解模型还未见报道。因而,本文提出利用支撑向量回归的理论进行高光谱混合像元分解。这种方法不需要预先确定非线性的映射形式,利用核函数就能够把像元矢量从低维空间映射到高维特征空间,使得在特征空间中构造的线性光谱组合对应着原始空间的非线性组合特性,因而能够揭示典型地物光谱之间的高阶性质^[10]。这种方法的另一特点是并不需要直接对高维特征空间进行分解,而是采用核技术直接在原始空间进行点积运算,并用少量的支撑矢量就能刻画数据的非线性结构,因而训练与推广的计算速度都较快。另外,该方法只需要选择合适的核函数及其参数,就能够在一定程度上解决地物之间的多次散射和阴影与仪器视场的不均匀等原因导致的复杂的非线性效应,因而在混合像元的非线性分解方面具有较大的应用价值。

2 支撑向量回归的原理

设 $x \in R^d$, $y \in R$ 和函数集合 $F = \{f | f: R^d \rightarrow R\}$,

并且已知独立同分布样本数据集 $\{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$, 函数回归就是找到一个合适的函数 $f \in F$, 使得最小化风险泛函

$$R[f] = \int (y - f(x), x) dP(x, y) \quad (1)$$

式中, l 是定义的损失函数, 它是描述如何对 y 与 $f(x)$ 之间的差异进行惩罚的函数, $P(x, y)$ 是联合概率密度函数。由于 $P(x, y)$ 是未知的, 因此 $R[f]$ 通常用经验风险替代:

$$R[f] \approx R_{\text{emp}} = \frac{1}{N} \sum_{i=1}^N l(y_i - f(x_i), x_i) \quad (2)$$

在支撑向量的回归中, 损失函数通常定义为一个 ε 不敏感带函数, 它意味着函数 $f(x)$ 与样本观测值 y_i 最多只有 ε 偏差, 即

$$l = |f(x) - y| \begin{cases} 0, & |f(x) - y| < \varepsilon \\ |f(x) - y| - \varepsilon, & |f(x) - y| \geq \varepsilon \end{cases} \quad (3)$$

支撑向量回归方法通过函数 ϕ 把 x 映射到高维特征空间 $\phi(x)$ 后, 非线性函数 $y = f(x, w)$ 可以用下面的线性组合来表示:

$$y = f(x, w) = \langle w, \phi(x) \rangle + b \quad (4)$$

式中, $w = (w_1, w_2, \dots, w_N, \dots) \in \Theta$, w_i 是权系数, $b \in R$, $\langle \cdot, \cdot \rangle$ 是定义在 Θ 空间中的内积。 $f(x, w)$ 的良好推广能力意味着需要最小化 w 。因为观测数据存在误差, 因而引进了松弛变量 ζ_i 及 ξ_i 来约束那些不在 ε 带的点。因此, f 的估计可以由 (5) 式确定。

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^N (\zeta_i + \xi_i) \quad (5)$$

受限于

$$\begin{cases} y_i - \langle w, \phi(x_i) \rangle - b \leq \varepsilon + \zeta_i \\ \langle w, \phi(x_i) \rangle - b - y_i \leq \varepsilon + \xi_i \\ \zeta_i, \xi_i \geq 0 \end{cases} \quad (6)$$

式中, ε 是指定的逼近容忍误差, C 是惩罚常数。这两个参数取值的意思是 C 越大, ε 越小, 表明训练精度高, 但推广能力差; C 越小, ε 越大, 则能提供较高的推广能力。利用拉格朗日乘数法求解 (5) 式, 对 w , b 及 $\zeta_i^{(\cdot)}$ 求偏导:

$$\sum_{i=1}^N (a_i - \alpha_i) = 0 \quad (7)$$

$$w - \sum_{i=1}^N (\alpha_i - \alpha_i) \phi(x_i) = 0 \quad (8)$$

$$C - \alpha_i^{(\cdot)} - \eta_i^{(\cdot)} = 0 \quad (9)$$

式中, α , $\bar{\alpha}$, $\eta \geq 0$ 为拉格朗日系数, 由此, 式 (5) 转化为其对偶优化问题^[11]:

$$\max W(\alpha, a) = -\varepsilon \sum_{i=1}^N (\alpha_i + a_i) + \sum_{i=1}^N y_i (\alpha_i - a_i) - \sum_{i,j=1}^N (\alpha_i - a_i) (\alpha_j - a_j) k(x_i, x_j) \quad (10)$$

受限于 (11) 式

$$\sum_{i=1}^N (\alpha_i - a_i) = 0, \quad 0 \leq \alpha_i, a_i \leq C \quad (11)$$

式中, $k(x_i, x_j) = \langle (x_i), (x_j) \rangle$ 是希尔伯特空间中两元素的内积, 式 (10) 消除了松弛变量 ζ_i 及 ζ_i , 通过解决式 (10) 和式 (11) 的一个二次优化问题可以确定 α 与 a 的系数, 而常数 b 可用式 (12) 来确定。

$$\begin{cases} b = y_i - \langle w, (x_i) \rangle - \varepsilon, & \alpha_i \in (0, C) \\ b = y_i - \langle w, (x_i) \rangle + \varepsilon, & \alpha_i \in (0, C) \end{cases} \quad (12)$$

最后回归函数可以写为

$$f(x, \alpha, a) = \sum_{i=1}^N (\alpha_i - a_i) k(x_i, x) + b \quad (13)$$

需要说明的是, 上面推导出的 (13) 式每次只能给出一维预测值, 混合像元分解要求对每一个输入的像元矢量 x 能够得到多个端元的组分, 因此 (13) 式并不能直接应用于光谱混合分解。对一个 k 类输出的问题, 本文不考虑 k 类输出之间的相关性, 简单地把它分解为 k 个子问题, 即独立地解决 k 个优化问题, 得到 k 组回归系数, 从而组成 k 个回归方程。

E. Vazquez 等提出了在支撑向量回归中引进多维克里金 (Kriging) 方法, 实现了多类之间的相关输出^[12], 进一步提高了 SVR 模型的预测能力。

3 基于支撑向量回归的混合像元自动分解

利用支撑向量回归原理解混合像元的思想是: 首先设法找到所有的典型地物光谱矢量, 再根据预先确定的核函数 $K(x)$, 把典型地物光谱矢量核化, 混合像元的非线性组合即表示为核化了的典型地物光谱矢量的线性组合。利用二次优化原理确定式 (10) 的权系数, 则对任意的像元输入矢量 x 由式 (13) 确定 $f(x)$ 值, 即混合像元的组比分。

3.1 典型地物光谱自动提取

由于传统手工的方法很难找到正确的典型地物光谱, 本文设计了一种投影迭代分解的方法。每次构造不同投影子空间, 利用迭代的方法, 逐步选取典型地物光谱, 从而能够找出所有的典型地物光谱。

投影迭代求取端元的方法, 根据凸面几何原理, 认为端元应当位于影像“数据云”的角点上, 因此设 Ω 为影像立方体的像元矢量数据集合, 且为凸集。如果有 $d_1 = \arg \max \{\Omega\}$, 则有 d_1 为 Ω 的角点。否则有 $x \in \Omega, y \in \Omega$, 使得 $d_1 = \tau x + (1 - \tau) y, \tau \in (0, 1)^n$, 因而, 在 L_2 范数的意义下, x 与 y 之中必有一个元素大于 d_1 , 这就与 d_1 是 Ω 中最大的元素矛盾。因此, 如果不考虑噪声, 影像立方体中最大的像元矢量 d_1 就是影像中的一个端元矢量, 它在影像中的表现就是亮度最大的地方。通过构造一个与 d_1 正交的投影阵 $P_{d_1}^{\perp}$ 并与 d_1 作用后, 就能够在原影像数据中消除 d_1 的影响。利用迭代的方式, 可以在投影后的数据中再找出最大像元矢量作为另一个端元, 如此反复就能够得到所有的端元。计算步骤如下:

(1) 设定分解误差阈值 ε 。找出遥感影像最大像元矢量 γ , 因最大像元矢量位于多元影像“数据云”的顶点, 所以作为第一个端元 d_1 。则 $P = d_1$ 。

(2) 以 $U = d_1$ 为子空间, 作投影阵 $P_U^{\perp} = I - U(U^T U)^{-1} U^T$, 把 P_U^{\perp} 作用在遥感影像上。

(3) 在投影后的遥感影像中找出最大像元矢量 γ 的位置, 记该位置的像元矢量为 $\gamma(X_i, Y_i)$, 则 γ 为第二个端元, 记为 d_2 。则 $P = [d_1, d_2]$ 。

(4) 以 $U = [d_1, d_2]$ 为子空间, 投影阵 $P_U^{\perp} = I - U(U^T U)^{-1} U^T$ 作用遥感影像后, 求出最大像元矢量作为第三个端元 d_3 。则 $P = [d_1, d_2, d_3]$ 。

(5) 重复这些步骤, 直到分解误差 ε 满足要求或得到预定个数的典型地物光谱。

混合像元分解的目的通常是为了获取典型地物的组分, 而对影像中的小地物及影像光谱异常数据不予考虑。因此, 由上面的方法确定的 γ 只是影像数据的光谱特征点, 它由影像端元、自然信号 (Natural signatures)、影像异常 (Anomalies) 和噪声 (Interferers) 等组成^[13]。若该光谱特征点为典型地物, 则在局部范围内与 γ 相似的像元应当有一定的数目。为此假设端元在空间分布上具有一定的形状和积聚性, 设 γ 的坐标为 (X_i, Y_i) , 则以 (X_i, Y_i) 为中心开一个较大的窗口, 考察在该窗口范围内与最大像元矢量 γ 相似的像元总数, 如果总数大于某个值 x 则认为 γ 为端元光谱, 否则视为其他信息。像元矢量的相似性可以用广义光谱角 θ 度量, 如果 θ 越小, 则相似性越大。采用开窗口的方法, 不但可以避免把小地物当成典型地物, 而且还能够有效避免噪声干扰等的影响。

3.2 数据模拟

获取典型地物光谱后,可以利用组合典型地物的光谱来形成训练样本。由于本文主要解决的是遥感影像的地物光谱非线性合成问题,因此利用 Hapke 近似方程^[14]来模拟非线性的训练样本。通常假设遥感测量的光谱数据具有二向性反射率,因此,可以用如下表达式将二向性反射率近似转化为单一散射反照率 (SSA)。

$$R(i, e) = \frac{wH(\mu)H(\mu_0)}{4(\mu + \mu_0)} \quad (14)$$

式中, $R(i, e)$ 为二向性反射率; w 为均值单一散射反照率, i 为入射角; e 为视角; $\mu = \cos i$; $\mu_0 = \sin i$; $H(\mu)$ 表征地物间多向散射的函数,可以表示为:

$$H(\mu) = \frac{1 + 2\mu}{1 + 2\mu \sqrt{1 - \mu}} \quad (15)$$

假设总共找到了 K 个典型地物光谱,模拟数据合成的基本思路是先将典型地物的光谱反射率转变为反照率 (Adlebo),随机产生混合比,对反照率进行混合后,再转变为像元空间的反射率。步骤如下:

(1) 把 K 个典型地物光谱的 DN 值转化为反射率;

(2) 利用 (14)、(15) 两式把反射率转换为 K 个单一散射反照率 w_i ;

(3) 在 $[0, 1]$ 之间产生 K 个随机数 c_i , 并且使得 $\sum_{i=1}^k c_i = 1$ 。则混合的反照率为:

$$\rho = \sum_{i=1}^k c_i w_i \quad (16)$$

(4) 利用 (14)、(15) 两式把混合的反照率 ρ 转化为混合的反射率 R 。再在 R 附加正态随机噪声,利用下式计算模拟数据 \tilde{R}

$$\tilde{R} = R \left(1 + \frac{N(0, 1)}{SNR} \right) \quad (17)$$

式中, SNR 为信噪比, $N(0, 1)$ 表示 0 均值, 方差为 1 的正态随机矢量。

4 实验分析

用支撑向量回归的方法来自动估计影像混合像元组分的基本步骤为: (1) 用非监督的方法自动提取影像中的全部典型地物光谱; (2) 用模拟的方式组合训练和测试样本,并用互检验 (Cross validation) 的方式确定出支撑向量回归的计算参数; (3) 用训练好的支撑向量回归出影像中各像元的组分值,并

用测试样本对支撑向量回归方法分解混合像元的结果进行精度评价。根据这个思路,作者完成了支撑向量回归的混合像元分解,用模拟的数据与真实的 PHI 高光谱数据试验了该方法的分解效果。

4.1 数据描述

非线性混合现象广泛存在于低矮植被覆盖区,实验数据选用江苏省常州市夏桥的一个农场影像。该影像获取于 1999 年 9 月,传感器为机载推帚式成像光谱仪 (Pushbroom Hyperspectral Imager, PHI, 本次飞行航高为 2000m, 地面空间分辨率 3m; 波长范围在 0.42—0.85 μ m, 光谱分辨率 5nm, 共有 80 个波段数据。实验区的经度为 119° 22' 11", 纬度为 31° 41' 44"。主要地物类型有道路、水体、水稻、菜地等。为减少计算量,从中截取了大小为 200×200 像素的一块区域进行实验。图 1 是该区域的图像立方体 (图示波长: $R = 0.4481, G = 0.5665, B = 0.8187\mu$ m), 已经对图中的主要地物类型做了标示,图中 R 表示道路; C 代表水稻作物; V 是蔬菜等非谷物; W 表示水体等。




图 1 PHI 影像立方体

Fig 1 PHI hyperspectral image cube

4.2 自动提取典型地物光谱

采用投影迭代分解方法,求出了该影像中的典型地物光谱。所用参数用下面的原则确定:最大端元数目设定为 5,它可以从影像 MNF 变换的特征值分布点的转折情况大致确定;容许的分解误差设定为 $\epsilon = 0.5$,这时可以保证本影像的相对误差不超出 5%,这是本文期望控制的分解误差;选择邻域半径与最小相似像元参数时,只须保证两者都不要太小。本次实验邻域半径 $R = 11$, 最小相似像元 $x = 10$, 相似像元光谱角度门限值 $\theta = 1.2$ 。相似像元光谱角

度取值越小,则表示提取的端元越纯。

用投影迭代分解的方法,提取了四种典型地物,分别为道路、水稻作物、蔬菜等旱地作物和水体,取表 1 中每类地物的所有相似像元光谱的平均值作为端元光谱。

表 1 用投影迭代的方法提取典型地物

Table 1 Abstracting endmembers using projective iterative method

端元	道路	菜地	水体	水稻
相似像元数目	11	10	12	10
像元矢量坐标	(110, 2)	(111, 21)	(79, 8)	(138, 39)

4.3 分解结果

由于高斯径向基核函数的分类识别能力不高于阶多项式核函数和 S 型核函数^[15],因此,考虑利用核函数选择高斯函数

$$K(x_i, x_j) = \exp\left\{-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right\} \quad (18)$$

表 2 入射角 i 和信噪比 SNR 取不同值时模拟数据分解的结果 (RMSE)


Table 2 RMSE of unmixing results using simulating data with different angle of incidence (i) and signal to noise ratio (SNR)

i	15		30		45		60		75	
SNR	15:1	30:1	15:1	30:1	15:1	30:1	15:1	30:1	15:1	30:1
水体	0.059	0.032	0.069	0.032	0.057	0.033	0.052	0.044	0.051	0.028
旱地	0.060	0.034	0.075	0.042	0.063	0.042	0.070	0.044	0.067	0.034
道路	0.056	0.026	0.052	0.029	0.047	0.027	0.049	0.031	0.053	0.029
水稻	0.058	0.032	0.088	0.039	0.068	0.045	0.072	0.044	0.069	0.034

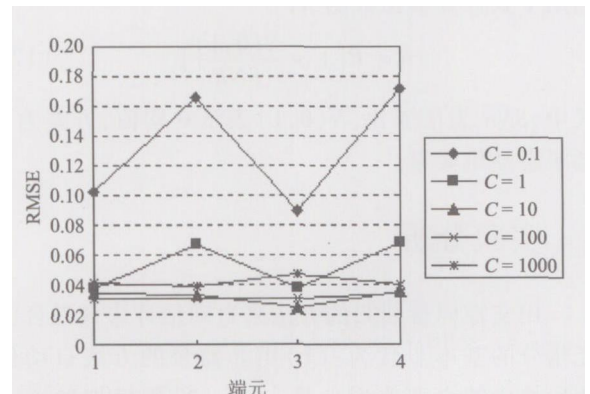
表 2 给出了使用不同入射角 i 和不同信噪比 SNR 产生模拟数据的分解结果。可以看出 SNR 较大时,各地物分解的 RMSE 相对较小,入射角 i 变化对分解结果没有明显的规律,但在各种情况下的分解结果差别都不大。因此,假设在 SNR=30:1,入射角 $i=23^\circ$ 情况下,把影像数据标准化。用 (17) 式产生了 2500 个模拟数据,其中 500 个用来训练 SVR,另外 2000 个数据用来评价分解结果。

分解误差希望控制在 0.1 范围之内,一般来说,计算误差通常需要比分解误差多保留一位有效位数。因此,设定式 (3) 的限定误差参数 $\epsilon=0.01$,核函数的参数 σ 和式 (5) 的惩罚参数 C ,可由互检验的方式确定。即用不同的 (ϵ, σ) 组合来考察分解的平均平方根误差 (RMSE)。由图 2 可知, $C=10, \sigma=2$ 时,分解的效果最好。

完成对支撑向量回归后,再推广到其他像元,推广的本质是一个在空间曲面插值的过程。分解结果如图 3,地物类别从左到右分别为水体、蔬菜等旱地作物、道路和水稻作物。



(a)



(b)

图 2 选择计算参数

Fig 2 Selecting computing parameters




图 3 分解图像

Fig 3 Fractional image

4.4 分解精度分析

由于地面实测混合像元百分比是非常困难的,因此考虑使用模拟数据来评价这种方法的分解误差,本文用 2000 个模拟数据来完成评价分解精度。双变量分布函数 (Bivariate Distribution Function, BDF)与平均平方根误差 (RMSE)来评价真实值与估计值之间的差别。BDF 方法是一种可视化的评

价方法,可以清楚地表明单个地物的分解精度;RMSE 则能够从总体上了解分解的精度。

图 4 是各地物估计值与真实值的分布图。图中横坐标是估计值,纵坐标是真实值;上下两条平行直线是给定的 10% 容忍分解误差边界。经统计,落在 10% 容忍边界内的百分数分别为 98.8%, 97.1%, 99.6% 和 97.0%; 水体、旱地作物、道路与水稻的 RMSE 分别为 0.0346, 0.0324, 0.0248 和 0.0348。




图 4 双变量分布图

Fig 4 bivariate distribution image

4.5 精度比较分析

采用相同的模拟数据,分别用径向基函数神经网络 (RBF)拟合分解及经典最小二乘方法 (LSMA)反演了水体、旱地作物、道路与水稻混合比。其中 RBFNN 的基函数也选择为高斯函数,并且参数取值与 SVR 的一致。

表 3 给出了各种方法产生的 RMSE 情况。从中可以看出, RBFNN 与 SVR 方法产生的结果都比较理想,它们的 RMSE 均不超出 5%, RBFNN 除了对道路的分解结果稍优于 SVR 外,其余地物的分解结果都不如 SVR 方法。而 LSMA 方法与后两者的数值差别非常大,这是由于测试数据是根据 Hapke 近似函数模拟的,非线性效应比较明显。在此情况下,适用于线性的经典最小二乘等方法分解效果很差。而支撑向量自动回归的混合像元光谱分解精度最高。

表 3 3 种方法分解结果的 RMSE 比较

Table 3 Comparison of unmixing RMSE on the LSMA, RBFNN and SVR methods

方法	水体	菜地	道路	水稻	总平均
LSMA	0.226	0.218	0.205	0.215	0.216
RBF	0.0464	0.0457	0.0184	0.0441	0.0386
SVR	0.0346	0.0324	0.0248	0.0348	0.0317

5 结 论

本文提出利用支撑向量自动回归的方法来分解高光谱混合像元问题。引进核函数的方法来逼近地物之间的多次散射、阴影和仪器视场的不均匀等原因产生的非线性效应。这种方法把像元矢量从像元空间 (低维) 映射到特征空间 (高维),使得在特征空

间中的构造的线性光谱组合表现了原始空间的非线性特征。这样既保留了非线性分解精度较高的优点,同时也具备线性分解的直观和简单性。模拟结果表明,这种方法分解误差精度很高,97%以上的混合像元分解误差的绝对值不超过 0.1,而平均平方根误差均不超过 3.5%,对非线性效应比较明显的混合像元分解有很大的优势。

致 谢 本文作者感谢中国科学院遥感应用研究所高光谱遥感室提供 PHI高光谱实验数据。

参 考 文 献 (References)

- [1] Chen S P, Tong Q X, Guo H D. Research on Mechanism of Remote Sensing Information [M]. Science Publishing Company, Beijing, 1998. [陈述彭,童庆禧,郭华东. 遥感信息机理研究 [M]. 北京: 科学出版社, 1998.]
- [2] Zhang Y, Shao M Z. Mixed Image Cell Decomposition on Radial Basis Function Neural Networks [J]. Journal of Remote Sensing, 2002, 4 (4): 285—289. [张彦,邵美珍. 基于径向基函数神经网络的混合像元分解 [J]. 遥感学报, 2002, 4 (4): 285—289.]
- [3] Liu W G, Wu E lanie Y, Sucharita Gopal, et al. ART MMAP: A Neural Network Approach to Subpixel Classification [J]. IEEE Transactions on Geosciences and Remote Sensing, 2004, 42 (9): 1976—1983.
- [4] Chang Chein I, Chiang Shao Shan, James A. Smith. Linear Spectral Random Mixture Analysis for Hyperspectral Imagery [J]. IEEE Transactions on Geosciences and Remote Sensing, 2002, 40 (2): 375—392.
- [5] Huang C, Townshend J. A Stepwise Regression Tree for Nonlinear Approximation: Applications to Estimating Sub pixel Land Cover [J]. International Journal of Remote Sensing, 2003, 24 (1): 75—90.
- [6] Tang S H, Zhu Q J, Yan G J, et al. Effect of GA on the Inversion of Linear and Nonlinear Remote Sensing Models [J]. Journal of Beijing Normal University (Natural Science), 2002, 38 (2): 266—272. [唐世浩,朱启疆,闫广建等. 遗传算法及其在遥感线性、非线性模型反演中的应用效果分析 [J]. 北京师范大学学报 (自然科学版), 2002, 38 (2): 266—272.]
- [7] Vapnik V. Learning Theory and Its Applications [J]. IEEE Transactions on Neural Networks, 1999, 10 (5): 985—987.
- [8] Farid Melgani, Lorenzo Bruzzone. Classification of Hyperspectral Remote Sensing Images with Support Vector Machines [J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42 (8): 1778—1790.
- [9] Gustavo Camps Valls, Luis Gómez Chova, Javier Calpe Maravilla, et al. Robust Support Vector Method for Hyperspectral Data Classification and Knowledge Discovery [J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42 (7): 1530—1542.
- [10] Heesung Kwon, Nasser M. Kemerl RX algorithm: A Nonlinear Anomaly Detector for Hyperspectral Imagery [J]. IEEE Transactions on Geosciences and Remote Sensing, 2005, 43 (2): 388—397.
- [11] Alex J Smola, Bernhard Scholkopf. A Tutorial on Support Vector Regression [R]. Neurocol2 Technical Report Series, October, 1998. [online] available from <http://www.neurocolt.com>.
- [12] Vazquez E, Walter E. Multi output Support Vector Regression [A]. The 13th IFAC Symposium on System Identification [C], Rotterdam, Netherland, 2003, 131—135.
- [13] Chang Chein I, Qian Du. Estimation of Number of Spectrally Distinct Signal Sources in Hyperspectral Imagery [J]. IEEE Transactions on Geosciences and Remote Sensing, 2004, 42 (3): 608—619.
- [14] Hapke B. Bidirectional Reflectance Spectroscopy Theory [J]. Geophysical Research, 1981, 86 (B4): 3039—3054.
- [15] Vapnik V. An Overview of Statistical Learning Theory [J]. IEEE Transactions on Neural Networks, 1999, 10 (5): 988—999.