

# 量测重构线性混合模型高光谱图像目标检测

贺霖, 潘泉, 赵永强

(西北工业大学自动化学院, 陕西西安, 710072)

**摘要:** 针对高光谱图像中无背景和目标先验信息情况下的目标检测问题, 给出了一种基于量测重构光谱混合模型的目标检测算法. 通过构造投影算子削弱背景干扰, 提高自动搜索目标光谱特征的准确性; 对光谱空间进行估计后, 构造量测重构光谱混合模型; 以此量测重构混合光谱模型为基础, 使用投影抑制背景并提高信噪比以改善检测效果. 同时给出了目标信号与局部杂乱背景之间的均方根误差 SLCR 及目标信号峰值与局部杂乱背景均值的比例 PSLCMR 两个检测评价指标的定义. 利用可见光/近红外波段高光谱图像进行了实验, 实验结果和理论分析表明了算法的有效性.

**关键词:** 高光谱图像; 目标检测; 量测重构; 光谱混合模型

**中图分类号:** TP39114 **文献标识码:** A **文章编号:** 0372-2112 (2007) 02-0023-05

## Target Detection in Hyperspectral Imagery Based on Linear Mixing Model Reconstructed from Measurements

HE Lin, PAN Quan, ZHAO Yongqiang

(College of Automation, Northwestern Polytechnical University, Xi'an, Shaanxi 710072, China)

**Abstract:** There presents a detection algorithm based on spectral mixing model reconstructed from measurement in this paper in order to detect unknown targets in unknown environment. Firstly, we project the hyperspectral imagery to suppress the background interference in order to search target spectral more accurately. Then, we estimate the spectral subspace and construct a spectral mixing model reconstructed from measurements. And based on the proposed spectral mixing modeling, we project the hyperspectral imagery, which suppress spectral signatures of background and improve the SNR, in order to increase the detection power. Finally, the Signal to Local Clutter RMSE (SLCR) and Peak Signal to Local Clutter Mean Ratio (PSLCMR), which is proposed, are used to evaluate the detection. Theoretic analysis and the results of experiment on visible/near infrared hyperspectral imagery verify the effectiveness of the algorithm.

**Key words:** hyperspectral imagery; target detection; reconstructing from measurement; spectral mixing model

### 1 引言

高光谱图像目标检测和识别技术以光谱信号分析为基础, 是基于物质光谱特征的信息获取和处理领域的一项前沿技术. 由于高光谱成像具有光谱分辨率高、光谱波段连续等特点, 高光谱图像包含了大量光谱信息, 为有效提高探测能力提供了可能, 尤其在对伪装目标和低空间分辨率目标进行检测、识别方面具有很大潜力. 但正是由于高光谱成像所拥有的强大的光谱信息探测能力, 在其获取目标物信息的同时也会引入大量干扰, 这给高光谱图像信息的后处理过程带来了很大困难. 对于未知环境下异常目标的自动检测, 除了高光谱图像体现出的量测信息, 没有先验光谱信息可用, 实际上只能较粗略地找到可能的目标物. Chang<sup>[1]</sup>用基于正交投影的自动目标

搜寻方法来搜索场景中可能的目标物, 通过预先设定阈值或给定目标物的种类来使算法终止, 然后采用基于正交投影的分类器对可能的目标物进行检测与识别, Harsanyi<sup>[2,3]</sup>用基于正交投影和光谱匹配滤波的低概率检测方法来寻找目标. Yu<sup>[4,5]</sup>以多元正态分布为基础将不符合场景统计特性的点判为目标; Brumbley<sup>[6]</sup>用基于向量量子化空间投影的方法寻找地物光谱特征以检测目标.

本文从抑制背景和噪声信号的角度出发, 给出一种利用量测重构线性混合模型进行高光谱图像自动目标检测的算法, 该算法不需背景地物和目标的先验光谱特征, 可有效检测目标. 首先, 利用无监督聚类和搜索方法估计光谱子空间; 然后, 将从量测中估计得到的光谱子空间和光谱成分系数结合建立量测线性混合模型; 最后, 以量测重构线性混合模型为基

收稿日期: 2005-08-23; 修回日期: 2006-07-28

基金项目: 国家自然科学基金(No. 60172037); 航空科学基金(No. 03D53032); 武器装备预研基金(No. 51401040204HK0359); 西北工业大学科技创新基金

础进行投影及求模运算获取检测结果. 量测重构线性混合模型利用了已有的量测信息, 以此模型为基础的运算不需背景和目标的先验信息, 且增强了对背景干扰物和噪声的抑制, 从而提高了检测效果.

## 2 线性光谱混合模型和光谱子空间

高光谱图像是一个图像立方体, 可视为一组经过配准的多源图像. 对于空间大小为  $W@H$ 、波段数为  $M$  的高光谱图像, 若  $W@H = N$ , 则其可用矩阵形式表示为:  $R = [r(1), r(2), \dots, r(k), \dots, r(N)]$ , 其中为:  $r(k) = [r_1(k), r_2(k), \dots, r_M(k)]^T$ ,  $r_1(k), r_2(k), \dots, r_M(k)$ , 分别为第  $k$  个像素位置在第  $1, 2, \dots, M$  波段的灰度值. 如果将图像中的灰度值视为不同背景和目標光谱特征的线性混合, 可对高光谱图像建立线性光谱混合模型<sup>[3]</sup>:

$$r(k) = Su(k) + v(k) = [B, T] \begin{bmatrix} A(k) \\ B(k) \end{bmatrix} + v(k) \quad (1)$$

其中  $S = [B, T] = [b_1, b_2, \dots, b_p, t_1, t_2, \dots, t_Q]$ ,  $B = [b_1, b_2, \dots, b_p]$  表示  $P$  种背景物的光谱特征,  $T = [t_1, t_2, \dots, t_Q]$  表示  $Q$  种目标的光谱特征,  $u(k) = \begin{bmatrix} A(k) \\ B(k) \end{bmatrix} = [A_1(k), A_2(k), \dots, A_P(k), B_1(k), B_2(k), \dots, B_Q(k)]^T$  表示  $P+Q$  种地物 ( $P$  种背景,  $Q$  种目标) 的光谱成分系数,  $v(k)$  为协方差阵为  $R^2 I$  的零均值白噪声.

定义  $X = \text{span}(S)$  为光谱子空间<sup>[7]</sup>, 本文中简要地以矩阵  $S$  表示光谱子空间.

## 3 估计光谱子空间

如果没有背景和目標光谱特征先验知识, 要使用线性光谱混合模型, 必须估计光谱子空间  $S$ , 估计  $S$  包括估计背景的光谱特征和目標的光谱特征.

Harsanyi<sup>[3]</sup> 利用高光谱图像谱间样本相关矩阵的特征向量来描述背景特征, 由于这些特征向量的分量会存在负值, 所以不能满足背景光谱特征的非负性约束. Ifarraguerri<sup>[8]</sup> 使用了凸锥分析的方法来满足这种非负性约束, 但该方法较为繁琐, 计算量大. 本文采用 ISODATA 动态聚类方法获取背景特征, 对高光谱图像数据聚类完毕后, 将类内元素视为同种背景地物, 以类内元素均值作为该类背景地物的光谱信号. 对于小的人造物目标, 聚类过程中止时, 由于目标的低概率特性, 目标会被归为某一背景地物类别, 但也正是由于目标的低概率特性, 所以目标错归类为背景时, 对该类别背景光谱特征的影响很小. 通过运用以上聚类方法, 获取了背景中各类主要地物的光谱特征  $B = [b_1, b_2, \dots, b_p]$ . 该方法具有获取背景地物光谱特征较为准确, 不用指定地物类别数的优点.

和寻找背景光谱特征相比, 寻找目标光谱特征较为困难, 主要是因为目标的空间分辨率低, 光谱能量弱. Chang<sup>[9]</sup> 提出了一种利用投影光谱空间中最大模值为判据的自动搜寻目标光谱特征的算法. 由于存在光谱混合及背景光谱向量的模值也可能较大等因素, 该种寻找目标光谱特征的方法易受背景干扰物影响. 如果在检测目标之前能够抑制背景信号, 则可有效

提高搜索目标光谱特征的效果. 抑制背景信号需要的背景光谱特征可使用已得到的背景估计  $B$ , 则抑制背景信号的算子为<sup>[10]</sup>:

$$P_b^{\perp} = I - B(B^T B)^{-1} B^T \quad (2)$$

其中  $I$  为  $M@M$  单位矩阵. 对于经过背景信息抑制后的数据, 利用正交投影和匹配滤波的方法找出可能的目标物. 由于没有目标的先验知识, 匹配信号取均匀分布的形式, 即  $u_M = [1, 1, \dots, 1]^T$ , 其中  $u_M$  维数为  $M$ . 经过投影后的数据包含负值, 光谱信号匹配前将数据取绝对值.

目标光谱特征的搜索过程<sup>[9]</sup>如下:

1 使用(3)式中的投影算子抑制背景干扰物, 得到数据  $Rc = P_b^{\perp} R$ .

2 取  $u_M R c$  中最大值所在位置对应于  $Rc$  的列向量为初始目标光谱特征  $t_1$ . 其中矩阵  $R c$  为  $Rc$  中所有元素取绝对值后的矩阵.

3 取  $u_M R \hat{c}$  中最大值所在位置对应于  $Rc$  的列向量为新增目标光谱特征. 其中  $R \hat{c}$  为矩阵  $P_b^{\perp} Rc$  中所有元素取绝对值后的矩阵,  $P_b^{\perp}$  为向目标子空间的正交补空间进行投影的算子, 该目标子空间由所有已搜索到的目标光谱特征张成.

4 如果未找到特定数目的光谱特征或  $t_i^T P_b^{\perp} t_i < E$ , 则执行 2; 否则, 结束搜索过程. 其中  $E$  为阈值.

上述搜索过程完成后, 即得到目标光谱特征的估计  $T = [t_1, t_2, \dots, t_Q]$ .

经过对背景光谱特征和目標光谱特征的估计, 获取了包含背景和目標光谱特征的光谱信号空间的估计:

$$S = [B, T] = [b_1, b_2, \dots, b_p, t_1, t_2, \dots, t_Q] \quad (3)$$

## 4 量测重构线性混合模型目标检测

### 4.1 量测重构线性混合模型

通过对光谱空间的估计获取了关于背景和目標光谱特征的后验知识, 还可进一步利用量测数据来建立完整的量测重构光谱混合模型, 以增强检测过程中对于噪声的抑制, 获取光谱空间的估计  $S$  后, 将式(1)中的  $Su(k)$  项围绕  $S$  展开, 则式(1)所示的光谱混合模型可表示为以下形式:

$$\begin{aligned} r(k) &= Su(k) + (S - S)u(k) + v(k) \\ &= Su(k) + S S u(k) + v(k) \end{aligned} \quad (4)$$

其中  $S S$  是式(3)中的光谱特征估计值,  $S S = S - S$ . 根据式(4), 在最小二乘准则下, 从高光谱图像量测  $R$  中获取  $u(k)$  的最优估计的投影算子为<sup>[11]</sup>:

$$P_u = ((S + S S)^T (S + S S))^{-1} (S + S S)^T \quad (5)$$

则最小二乘意义下从量测  $R$  中获取光谱信号最优估计的投影算子为:

$$P_s = (S + S S)((S + S S)^T (S + S S))^{-1} (S + S S)^T \quad (6)$$

则式(4)可表示为:

$$r(k) = P_s r(k) + v_s(k) = (S + S S)[(S + S S)^T (S + S S)]^{-1} (S + S S)^T r(k) + v_s(k) \quad (7)$$

其中  $v_s(k) = r(k) - (S + S S)[(S + S S)^T (S + S S)]^{-1} (S + S S)^T r(k)$ . 若估计量  $S$  足够准确, 则式(7)可化简为:

$$r(k) = S\hat{u}(k) + v_{GS}(k) = [B, T] \begin{bmatrix} A(k) \\ B(k) \end{bmatrix} + v_{GS}(k) \quad (8)$$

其中  $\hat{u}(k) = (S^T S)^{-1} S^T r(k)$ ,  $v_{GS}(k) = r(k) - S(S^T S)^{-1} S^T r(k)$ . 由于噪声项  $v_{GS}$  与光谱子空间的估计  $S$  正交<sup>[11]</sup>, 所以在最小平方误差准则下, 量测  $r(k)$  经过正交投影后, 噪声项  $v_{GS}$  被抑制(图 1 所示). 如将式(8)视为某种光谱混合模型, 由于该式中所示的各量(包括光谱特征和光谱成分系数)均来自于量测, 所以据(8)式可定义量测重构线性混合模型.




图 1 噪声项与光谱子空间的关系

**定义:** 若  $S = [B, T]$  是对光谱子空间  $S$  的估计, 则将表达式  $r(k) = [B, T] \begin{bmatrix} A(k) \\ B(k) \end{bmatrix} + v_{GS}(k)$  ((8)式) 定义为量测重构线性混合模型, 其中  $v_{GS}(k) = r(k) - S(S^T S)^{-1} S^T r(k)$ ;  $B, T$  分别为背景和地物光谱特征的估计;  $\begin{bmatrix} A(k) \\ B(k) \end{bmatrix} = \hat{u} = S(S^T S)^{-1} S^T r(k)$ .

以上述定义的量测重构线性混合模型为基础进行目标检测不要求背景和目标的先验信息, 且可在有效抑制后, 再进行有关检测的其它处理, 这样可获得较好的抑制噪声的效果.

#### 4.1.2 背景和噪声信号抑制

以量测重构线性混合模型为基础, 可利用正交投影方法来检测目标.

抑制量测重构线性混合模型中的噪声项的投影算子为<sup>[11]</sup>:

$$P_G = S(S^T S)^{-1} S^T \quad (9)$$

$P_G$  即为最小二乘意义下获取光谱信号最优估计的投影算子, 而(8)式中的  $S\hat{u}(k)$  项为最小二乘意义下光谱信号的最优估计, 所以为抑制量测重构线性混合模型(9)式中的噪声项, 将高光谱图像向  $P_G$  投影, 可得:

$$\begin{aligned} r_1(k) &= P_G r(k) = S\hat{u}(k) = S[u(k) + S[\hat{u}(k) - u(k)]] \\ &= [B, T] \begin{bmatrix} A(k) \\ B(k) \end{bmatrix} + S[\hat{u}(k) - u(k)] \end{aligned} \quad (10)$$

$r_1(k)$  是建立在量测重构光谱混合模型基础上的对  $r(k)$  的后验估计, 估计量  $S$  足够准确时, 由可知  $r_1(k)$  的信噪比是  $r(k)$  信噪比的  $\frac{M}{P+Q}$  倍<sup>[11]</sup>, 由于高光谱图像的波段数  $M$  一般总是大于光谱空间维数  $P+Q$  ( $P$  种背景,  $Q$  种目标), 所以利用量测重构光谱混合模型获取的  $r_1(k)$  与原数据相比, 信噪比得到提高.

$r_1(k)$  中仍有背景和噪声信号, 利用(2)式中的投影算子  $P_b^T$  抑制背景:

$$\begin{aligned} r_2(k) &= P_b^T r_1(k) = P_b^T [B, T] \begin{bmatrix} A(k) \\ B(k) \end{bmatrix} + P_b^T S[\hat{u}(k) - u(k)] \\ &= P_b^T TB(k) + P_b^T S\hat{u}(k) - P_b^T S u(k) \end{aligned}$$

$$\begin{aligned} &= P_b^T TB(k) + P_b^T S(S^T S)^{-1} S^T [r(k) - S\hat{u}(k)] \\ &= P_b^T TB(k) + P_b^T P_G v(k) \end{aligned} \quad (11)$$

对于投影算子  $P_s$  有:

$$P_s P_s^T = P_s P_s = S(S^T S)^{-1} S^T [S(S^T S)^{-1} S^T]^T = P_s \quad (12)$$

由式(12)可知  $P_s$  具有对称性和幂等性. 同理, 可知  $P_b^T$  也具有对称性和幂等性.

由(11)式及  $P_s, P_b^T$  的对称性和幂等性可得  $r_2(k) \sim N(P_b^T TB(k), R^2 P_b^T P_G)$ , 所以将  $r_2(k)$  向  $t_k$  投影进行匹配滤波, 则数据信噪能量比  $SNER = \frac{R^2 t_k^T P_b^T P_G t_k}{t_k^T P_b^T TB(k) B^T(k) T^T (P_b^T)^T t_k}$  最大<sup>[2]</sup>. 对于寻找到的多个目标光谱特征, 可将  $T^T$  作为投影算子, 得到:

$$r_3(k) = T^T r_2(k) = T^T P_b^T TB(k) + T^T P_b^T P_G v(k) \quad (13)$$

式(13)的处理结果可表示为  $Q$  幅灰度图像, 原高光谱图像数据中的背景和噪声信号得到抑制, 目标信号能量被突出. 因此, 使用  $r_3(k)$  的模值  $y(k)$  作为该点是否为目标的检验函数, 则对于  $y(k)$  有:

$$\begin{aligned} y(k) &= \sqrt{r_3^T(k) r_3(k)} \\ &= \sqrt{r^T(k) (P_G)^T (P_b^T)^T T^T T^T P_b^T P_G r(k)} \end{aligned} \quad (14)$$

#### 4.3 检测评价准则

对于式(14)所示的高光谱图像目标检测器, 一方面, 其概率密度特性难以使用解析形式表达, 另一方面, 该检测器是以光谱解混<sup>[12]</sup>中使用的投影变换为基础进行推导的, 未直接使用零假设和备择假设前提. 因此, 式(14)所示检测器无法使用经典的包含检测概率、虚警概率和信噪比指标的评价方法对检测器的理论性能进行评价. 可将式(14)运算得到的灰度图像作为检测结果进行判读, 考虑到目标的判读受目标周围虚警分布情况的影响较大, 所以可定义针对具体数据的局部检测效果评价准则. 均方根误差 RMSE(Root Mean Square Error) 可衡量变量之间的差异性, 故定义目标信号与局部杂乱背景之间的均方根误差 SLCR(Signal to Local Clutter RMSE):

$$SLCR = \sqrt{\frac{\sum_{j=1}^V \sum_{i=1}^U (a_i - b_j)^2}{UV}} \quad (15)$$

其中  $a_i$  是目标像素的灰度值,  $b_j$  是目标的某一空间邻域的像素的灰度值. 同时, 还可定义目标信号峰值与局部杂乱背景均值的比例 PSLCMR(Peak Signal to Local Clutter Mean Ratio):

$$PSLCMR = \sqrt{\frac{[\max(a_i)]^2}{\frac{1}{V} \sum_{j=1}^V b_j^2}} \quad (16)$$

两种评价指标 SLCR 和 PSLCMR 的值越大, 说明在检测算法获取的图像中目标与背景的对比特度越大.

### 5 实验及其分析

实验对象为一套机载 HYDICE 航拍高光谱图像数据(数据来自于美国地形学工程中心), 共包含 210 个波段, 大小为, 成像波段范围 0.4μm~2.1μm, 处于可见光和近红外波段, 灰度阶数 16bits. 图 2 是对应于该高光谱图像数据的快视图, 其中的白色圆圈标示出了高光谱图像中实际存在的低空间分辨

率小目标的位置. HYDICE 图像不同波段成像情况不同(如图 3 所示), 考虑到大气吸收波段及传感器噪声波段的影响(如图 3(c)、3(d)所示), 对此高光谱图像数据进行处理时, 在全部 210 个波段的数据中去掉第 101 波段到 110 波段、第 136 波段到第 155 波段、第 201 波段到第 210 波段的数据, 只对剩余 170 个波段的数据进行运算.




图 2 目标的位置




图 3 不同波段成像情况

对高光谱图像数据利用 Yu 的 RX 算法<sup>[4,5]</sup>、Harsanyi 的低概率检测(LPD)算法<sup>[2,3]</sup>, 结果如图 4(a)、4(b)所示;用本文中基于量测重构混合光谱模型的(13)式进行处理, 结果如图 4(c)所示, 其中聚类过程得到 8 类背景地物, 目标光谱特征搜索设定为 20 个目标特征. 由于采用阈值分割图 4 中的图像来检测目标可能会产生不在目标周围的成片虚警, 难以处理. 所以本文并不对图 4 中的图像直接进行阈值分割来评价检测结果. 而分别采用 SLCR 和 PSLCMR 这两种局部检测效果评价准则对图 3 中的检测图进行运算, 计算结果在表 1 和表 2 中.



图 4 不同算法结果

分析表 1 中的 SLCR 数据可知, 本文算法的 SLCR 值均大于 RX 算法, 而在目标  $t_2$ 、 $t_4$  和  $t_7$  (尤其是  $t_2$ 、 $t_4$ ) 处, 其 SLCR 值小于 LPD 算法;分析表 2 中的 PSLCMR 数据可知, 本文算法的 PSLCMR 值均大于 LPD 算法, 而在目标  $t_1$ 、 $t_6$  和  $t_7$  处, 其 PSLCMR 值小于 RX 算法. 从评价指标 SLCR 来看, 本文算法的检测结果明显优于 RX 算法, 而优于 LPD 算法的程度相对较小;从评价指标 PSLCMR 来看, 本文算法的检测结果明显优于 LPD 算法, 与 RX 算法相比没有明显优势. 可以看出, 两种评价指标的结果存在一些差异性, 考虑到 SLCR 和 PSLCMR 两个指标都只是分别从某一个具体角度来衡量检测效果, 可将两个指标进行全面综合分析, 则本文算法是不但优于 LPD 算法

也优于 RX 算法的. 另外, 若直接对图 4 中的三幅检测图进行目视判读, 可以看出图 4(b) 中道路和大块地物等的边缘处灰度值明显较大, 且背景和目标的对比度较小, 大地物的边缘处灰度值较大说明容易产生与小目标混淆的小块虚警, 背景和目标的对比度较小说明容易在小目标周围产生淹没目标的成片虚警;在图 4(c) 中, 道路及一些大块地物灰度值都很低, 有 5 个目标物灰度值较高, 与局部背景形成的对比度较强(用白色箭头标出), 很容易辨别, 另有 2 个目标物  $t_2$  和  $t_4$  灰度值低, 无法辨别. 在图 4(a) 中, 除  $t_6$  外, 其余目标物与局部背景形成的对比没有图 4(c) 强.

观察表 1 和表 2 中本文算法对应的数据可发现, 对于目标  $t_2$  和  $t_4$ , 本文算法的 SLCR 和 PSLCMR 值比其余的 5 个目标明显偏小, 这意味着  $t_2$  和  $t_4$  容易漏检(从 4(c) 中可发现  $t_2$  和  $t_4$  难以直接目视判别出来). 这是由于估计出的光谱子空间与理想子空间之间存在误差(如图 1 所示), 没有包含  $t_2$  和  $t_4$  的光谱特征, 使得通过量测重构出的线性混合模型未包含  $t_2$  和  $t_4$  的信息, 导致以量测重构线性混合模型为基础的本文算法在检测  $t_2$  和  $t_4$  时失效. 如果排除  $t_2$  和  $t_4$ , 从 SLCR 指标来看, 本文算法的性能相对于 RX 算法和 LPD 算法还会得到提高.

表 1 不同算法的 SLCR 值

目标代号	本文算法	RX 算法	LPD 算法
$t_1$	175.9	107.4	41.4
$t_2$	6.7	1.8	37.6
$t_3$	119.2	16.2	84.3
$t_4$	3.6	1.2	48.4
$t_5$	126.3	12.8	65.4
$t_6$	213.4	167.2	129.1
$t_7$	66.0	63.5	92.6

表 2 不同算法的 PSLCMR 值

目标代号	本文算法	RX 算法	LPD 算法
$t_1$	14.3	59.7	1.5
$t_2$	1.7	1.6	1.2
$t_3$	2.2	0.3	1.4
$t_4$	1.3	1.3	1.3
$t_5$	12.3	0.2	1.3
$t_6$	8.8	22.9	1.9
$t_7$	5.3	23.0	1.7

通过以上实验对比, 可知本文的基于量测重构线性混合模型的检测方法可以有效增强目标和背景的对比度, 利于目视判读, 但其检测性能在某种程度上要依赖于对光谱子空间进行估计的准确性.

## 6 结论

本文针对无背景和先验光谱特征条件下的高光谱图像目标检测问题进行了研究, 利用高光谱图像量测信息建立量测重构线性混合模型, 并在此模型的基础上利用投影变换检测目标, 由于利用量测重构光谱混合模型可在投影抑制背景和噪声之前先对数据进行一次降噪, 因此以量测重构光谱


混合模型为基础的运算增强了对背景干扰物和噪声的抑制, 从实验效果也可看出算法有效增强了目标和背景的对比值, 表明了算法的有效性. 同时, 由式(7)和式(8)知, 量测重构线性混合模型是建立在对光谱空间进行准确估计的基础上, 背景地物由于面积大, 能量强, 其光谱特征的估计包含了加权过程, 不易受较大野值影响; 而对于低概率小目标, 由于其能量很弱, 易受较大野值的干扰, 可能难以估计和搜索出所有的目标光谱特征, 导致其后的检测过程可能使得某些目标难以检测出来. 所以需要寻找更有效的提高光谱子空间特别是目标光谱特征估计准确度的方法, 以使量测重构线性混合模型中包含尽量多的目标光谱信息, 从而进一步提高算法检测效果. 另外, 由于 SLCR 和 PSLCMR 两种评价指标对于不同的算法, 其效果不完全一致且具有一定的互补性, 因此还可将此两种单因素指标进行融合, 构造其特性更直观的综合评价指标.

#### 参考文献:

- [1] H Ren, C I Chang. Automatic spectral target recognition in hyperspectral imagery[J]. IEEE Transactions on Aerospace Electronic Systems, 2003, 39(4): 1232- 1249.
- [2] J C Harsanyi, C I Chang. Hyperspectral image classification and dimensionality reduction: an orthogonal subspace projection approach[J]. IEEE Transactions on Geoscience and Remote Sensing, 1994, 32(7): 779- 785.
- [3] C I Chang, S S Chiang. Anomaly detection and classification for hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing, 2002, 40(6): 1314- 1325.
- [4] X Yu, I S Reed, A D Stocker. Comparative performance analysis of adaptive multispectral detectors[J]. IEEE Transactions on Signal Processing, 41(8), 1993: 2639- 2656.
- [5] X Yu, L E Hoff, I S Reed, et al. Automatic target detection and recognition in multispectral imagery: A Unified ML Detection and Estimation Approach[J]. IEEE Transactions on Image Processing, 1997, 6(1): 143- 156.
- [6] C Brumbley, C I Chang. An unsupervised vector quantization based target subspace projection approach to mixed pixel detection and classification in unknown background for remotely sensed imagery[J]. Pattern recognition, 1999, 32(7): 1161- 1174.
- [7] T M Tu, C H Chen, C I Chang. A posteriori least squares orthogonal subspace projection approach to desired signature[J]. IEEE Transactions on Geoscience and Remote Sensing, 1997, 35(1): 127- 139.

- [8] A Ifarraguerri, C I Chang. Multispectral and hyperspectral image analysis with convex cones[J]. IEEE Transactions on Geoscience and Remote Sensing, 1999, 37(2): 756- 770.
- [9] H Ren, C I Chang. A generalized orthogonal subspace projection approach to unsupervised multispectral image classification[J]. IEEE Transactions on Geoscience and Remote Sensing, 2000, 38(6): 2515- 2528.
- [10] S Haykin. Adaptive Filter Theory[M]. New Jersey: Prentice Hall, 2002.
- [11] L L Scharf. Statistical Signal Processing: Detection, Estimation, and Time Series Analysis[M]. New York: Addison-Wesley, 1991: 377- 381.
- [12] N Keshava, J F Mustard. Spectral Unmixing[J]. IEEE Signal Processing Magazine, 2002, 19(1): 44- 57.

#### 作者简介:




贺霖 男, 1973 年出生于新疆省石河子市, 现为西北工业大学模式识别与智能系统专业博士生, 目前主要研究方向: 信息融合、图像模式识别、多元信号处理.

E-mail: helin@mail.nwpu.edu.cn



潘泉 男, 1961 年出生于上海, 工学博士, 西北工业大学自动化学院教授, 博士生导师, 复杂系统综合自动化研究所所长、总装备部飞机机载电子综合和火力控制专业组专家委员、全国控制工程领域研究生培养协作组组长、中国自动化学会理事、国际信息融合协会(ISIF)会员, 已发表论文近 200 余篇, 获国家和省部级科技奖 7 项. 目前主要研究方向: 动态系统建模、多目标跟踪与识别、信息融合、智能

监控、C<sub>T</sub> 技术、多尺度系统理论等. E-mail: quanpan@nwpu.edu.cn



赵永强 男, 1976 年出生于甘肃临洮, 工学博士, 西北工业大学自动化学院讲师. 目前主要研究方向: 多源图像融合、偏振图像分析以及目标识别. E-mail: zyqxy@nwpu.edu.cn