

文章编号 1004-924X(2007)10-1609-07

# 一种稳健的高光谱图像压缩方法

苏令华<sup>1,2</sup>, 李 纲<sup>1</sup>, 衣同胜<sup>3</sup>, 万建伟<sup>1</sup>

(1. 国防科技大学 电子科学与工程学院, 湖南 长沙 410073; 2. 空军大连通信士官学校 大连 116600;  
3. 92941 部队, 辽宁 葫芦岛 125000)

**摘要:**提出了一种稳健的高光谱图像压缩技术。估计原始数据的虚拟维数, 继而采用一种非监督的正交子空间投影技术提取端元矢量, 构成矩阵作为快速独立分量分析的初始化混合矩阵, 进行 ICA 变换。对变换后的独立分量图, 采用二维分层树集合分裂进一步压缩编码。计算机仿真结果表明, 该压缩算法在取得 40 : 1 压缩比的同时, 能有效地保持数据, 尤其是小目标和异常的谱向特征, 是一种高效的三维数据压缩方法, 可有效地应用在小目标检测及异常检测中。

**关键词:**图像压缩; 高光谱图像; 独立分量分析; 初始化

**中图分类号:** TP751.1; TN919.81 **文献标识码:** A

## A robust hyperspectral image compression method

SU Ling-hua<sup>1,2</sup>, LI Gang<sup>1</sup>, YI Tong-sheng<sup>3</sup>, WAN Jian-wei<sup>1</sup>

(1. College of Electronic Science and Engineering, National University of Defense Technology, Changsha 410073, China; 2. Dalian Sergeant School of Communication of Air Force, Dalian, 116600; 3. 92941 Unit of PLA, Huludao 125000, China)

**Abstract:** A robust hyperspectral image compression method is proposed for the detection of small target and abnormality. The virtual dimensionality of original data is estimated, then the endmember vectors are extracted using an unsupervised orthogonal subspace projection method. Fast-ICA transformation is performed with the endmember vectors as initialization matrix, and the IC images are coded by 2D Set Partitioning in Hierarchical Trees (SPIHT). The experiment results show that the algorithm has a high compression ratio (40 : 1), while the spectral characteristics are preserved. This algorithm is an efficient 3D compression method for the detection of small target and abnormality.

**Key words:** image compression; hyperspectral image; independent component analysis; initialization

## 1 引言

高光谱遥感技术是 20 世纪 80 年代出现的新型对地观测技术<sup>[1]</sup>。从诞生之日起, 就被广泛应

用于农业生产、环境监测、军事侦察等领域。由于其数据量庞大, 卫星数据链路信道容量有限, 海量数据的有损压缩成为研究的热点。目前, 高光谱数据应用主要可以归结为高维空间的目标检测与分类技术, 并且小目标, 甚至亚像元目标的检测成

为难点。同时,数据的 3 维特点又决定了其应用主要依靠其算法的自动完成,而非人眼的直观感知。因此,数据压缩技术必须与分类、检测等结合起来考虑。

独立分量分析(Independent Component Analysis, ICA)<sup>[2]</sup>作为信号处理领域的一种新方法,与高光谱数据特点紧密结合,几年来已先后被应用到高光谱数据的目标分类、异常检测等领域,并取得了不错的效果。相对于主成分分析(Principal Component Analysis, PCA),ICA 以互信息为标准,能更有效地保持数据细节特征。

本文提出一种基于 Fast\_ICA 的高光谱数据压缩方法。首先采用 HFC(Harsanyi Farrand and Chang)算法估计原始数据的虚拟维数(Virtual Dimensionality, VD)<sup>[3]</sup>,继而采用一种非监督的正交子空间投影技术(Unsupervised Orthogonal Subspace Projection, UOSP)<sup>[4]</sup>提取端元矢量,对 Fast\_ICA 进行有效的初始化,最后采用 SPIHT(Set Partitioning in Hierarchical Trees)对独立分量图进行二维压缩,完成整个编码过程。对 224 波段 AVIRIS 数据及构造了小目标的合成数据进行了仿真实验,采用一种改进的约束最小能量(Constrained Energy Minimum, CEM)<sup>[5]</sup>算子进行目标检测和异常检测,并与 PCA 算法进行了比较。

## 2 ICA 简介

独立分量分析已经被广泛应用于信号处理、模式识别等领域,如盲源分离、信道均衡、特征提取等。其基本模型介绍如下:

设观测到  $m$  个随机变量  $\mathbf{x} = (x_1, x_2, \dots, x_m)^T$ , 并假定它们是由  $n$  个具有零均值、且相互统计独立的成分  $\mathbf{s} = (s_1, s_2, \dots, s_n)^T$  线性组合而成。这种线性关系可以用矩阵形式表示为:

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

式中  $\mathbf{A}$  为未知的  $m \times n$  维满秩混合矩阵。ICA 所要解决的问题就是利用观测到的数据  $\mathbf{x}$ , 在式(1)所描述的模型前提下求解  $\mathbf{A}$  与  $\mathbf{s}$ 。文献[1]中指出  $\mathbf{s}$  中至多只能有一个高斯源,这是因为多个高斯源的线性组合依然是一个高斯源而无法分离。同时,各独立元的能量、符号及其先后顺序也无法估计。因此,对各独立分量  $\mathbf{s}$  乘以一个常数都可以通过对混合矩阵  $\mathbf{A}$  除以相同的常数来对消,而

式右侧的求和顺序可以通过置换矩阵来任意改变。为了理论推导的方便,常规定独立分量具有单位能量(即单位方差),这使得非高斯独立成分在不考虑顺序和符号的情况下是唯一的。

## 3 压缩算法

针对小目标和异常检测的应用需求,本节介绍所提出的压缩算法。算法结合了虚拟维数估计、端元提取、独立分量分析和 SPIHT 编码。关于 SPIHT 此处不再赘述<sup>[6]</sup>,基于 UOSP 初始化 ICA 的高光谱图像压缩流程如图 1 所示。




图 1 压缩编码流程图

Fig. 1 Flow chart of proposed compression and coding method

以下对虚拟维数及其估计以及端元提取方案分别介绍。

### 3.1 虚拟维数及其估计

使用 ICA 实现高光谱数据压缩,其基本思想在于使用少量的独立分量来表征数据的有效信息,也就是谱向的维数压缩。主分量分析是最常用的降维方法,以二阶统计量作为标准,采用计算特征值累积的方法确定它们占总能量的百分比以决定维数。在此基础上,ANDREW A. GREEN 等人提出的最小噪声分离(Minimum Noise Fraction, MNF)变换被应用于确定高光谱数据的内在维数<sup>[7]</sup>,并得到了应用软件 ENVI 等的支持。然而,这个过程存在的问题就是一些小目标对信噪比或者主分量贡献甚微,但却对图像理解有至关重要的影响。ICA 以互信息作为标准,其性能要优于基于二阶统计量的方法,可以保护二阶统计量降维容易丢失的数据特征。

由于高光谱数据具有很高的谱间分辨率,许多尚未定性的未知信号出现在数据中,这些信号的谱向特征都无法用已经确知的特征来定义。同时,干扰信号出现的概率大大提高,给数据维数的确定带来很大困难。Chang 提出了一个虚拟维数的概念<sup>[3]</sup>,完全依据数据中的可分谱向特征数目

对数据维数进行界定。而 Harsanyi、Farrand 和 Chang 提出的基于奈曼-皮尔逊检测理论特征分析方法 HFC 成为一种有效的 VD 估计方法,其原理简介如下:

首先计算取样的相关阵和方差阵,分别记为  $\mathbf{R}$  和  $\mathbf{K}$ 。对  $\mathbf{R}$  和  $\mathbf{K}$  做特征值分解,特征值分别记为相关特征值  $\{\hat{\lambda}_1 \geq \hat{\lambda}_2 \geq \dots \geq \hat{\lambda}_L\}$  和方差特征值  $\{\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_L\}$ 。假定信号源是未知正常数,噪声是均值为零的白噪声,VD 问题转化为二元假设问题:

$$H_0: z_l = \hat{\lambda}_l - \lambda_l = 0, \quad l=1, 2, \dots, L, \quad (2)$$

$$H_1: z_l = \hat{\lambda}_l - \lambda_l > 0,$$

若  $H_1$  为真,则认为存在一个端元对相关特征值做出了贡献,反之则认为仅有噪声成分,在该二元假设下,可以将每一对特征值  $\hat{\lambda}_l, \lambda_l$  看成服从以下条件概率密度的随机变量:

$$p_0(z_l) = p(z_l | H_0) \cong N(0, \sigma_{z_l}^2), \quad l=1, 2, \dots, L, \quad (3)$$

$$p_1(z_l) = p(z_l | H_1) \cong N(\mu_l, \sigma_{z_l}^2), \quad l=1, 2, \dots, L, \quad (4)$$

其中,

$$\sigma_{z_l}^2 = \text{Var}[\hat{\lambda}_l - \lambda_l] = \text{Var}[\hat{\lambda}_l] + \text{Var}[\lambda_l] - 2\text{Cov}(\hat{\lambda}_l, \lambda_l). \quad (5)$$

根据式(3)~(5),可以定义检测概率和虚警概率:

$$P_D = \int_{\tau_l}^{\infty} p_1(z) dz, \quad (6)$$

$$P_F = \int_{\tau_l}^{\infty} p_0(z) dz. \quad (7)$$

在给一个虚警概率的情况下,  $\tau_l$  被确定, 既而若  $\hat{\lambda}_l - \lambda_l > \tau_l$ , 则判定有一个信号能量对该特征值做出贡献。对  $l=1, 2, \dots, L$  分别确定  $\tau_l$ , 最终确定虚拟维数 VD。

### 3.2 端元提取与 ICA 的初始化

维数确定以后,使用 Fast\_ICA 成功提取出最重要的  $p$  个独立分量,则这些独立分量可以有效地保护原始数据的谱向特征。但是,在 Fast\_ICA 应用中一个难解的问题就是其独立分量排序的不确定性。各个独立分量统计独立,并不像 PCA 那样,第一个主成分对应于最大特征值,第二主成分对应于第二大特征值,依次类推,相反,其产生顺序是随机的,正如第 2 节介绍的那样。

Bharath Ramchrishna 采用高阶统计量为标

准<sup>[8]</sup>, 选取出最优先的  $p$  个独立分量。不难发现, Fast\_ICA 生成独立分量的随机排序问题源于在算法的初始化过程中,采用了随机的单位投影矢量。对混合矩阵  $\mathbf{A}$  进行有效的初始化,可以解决“随机排序”问题。由于 ICA 还是一个线性混合模型,矩阵  $\mathbf{A}$  与地物谱矢量间存在某种对应关系。通过对高光谱数据进行端元提取,得到  $p$  个端元谱矢量作为初始矢量,应该是合理的。

通常的情况下,无法获得高光谱数据足够的先验信息,而只能采用无监督的端元提取算法。吴波等人在混合像元分解研究过程中<sup>[4]</sup>,以凸面几何学分析为基础,提出了一种无监督的正交子空间投影方法(UOSP)进行有效的端元提取。相对于纯净像元指数(Purity Pixel Index, PPI)等端元提取算法,该方法实现简单,并且取得了较好的效果,此处采用该方法对 Fast\_ICA 进行初始化。提取算法简介如下:

(1) 3 维图像数据几何是一个凸集。从高光谱图像中找到最大像元矢量,记为  $\mathbf{e}_1$ ,可以证明该矢量位于数据集的一个顶点,以其作为第一个端元矢量。

(2) 以  $\mathbf{U} = \mathbf{e}_1$  作为子空间,做投影阵  $\hat{\mathbf{P}}_{\mathbf{U}} = \mathbf{I} - \mathbf{U}(\mathbf{U}^T \mathbf{U})^{-1} \mathbf{U}^T$ , 并将其作用到高光谱数据上,形成“新”的数据。式中,  $\mathbf{I}$  为单位阵。

(3) 在第(2)步生成的“新”数据中,搜索最大像元矢量对应的空间位置,记原数据中该位置像元矢量为  $\mathbf{e}_2$ , 作为第 2 端元。

(4) 以  $\mathbf{U} = [\mathbf{e}_1 \quad \mathbf{e}_2]$  作为子空间,做投影阵  $\hat{\mathbf{P}}_{\mathbf{U}} = \mathbf{I} - \mathbf{U}(\mathbf{U}^T \mathbf{U})^{-1} \mathbf{U}^T$ , 将其作用到原始高光谱数据,形成“新”数据,仿照第(3)步方法,可以得到第 3 个端元,记为  $\mathbf{e}_3$ , 而  $\mathbf{U} = [\mathbf{e}_1 \quad \mathbf{e}_2 \quad \mathbf{e}_3]$  成为新的子空间。

(5) 重复这个步骤,直至获得  $p$  个端元矢量。

## 4 仿真与分析

根据本文提出的压缩方案,使用 Matlab6.5, 对 224 波段 AVIRIS 飞行数据进行了仿真实验。机载航空可见光/红外光成像光谱仪(Airborne Visible/Infrared Imaging Spectrometer, AVIRIS)是首次测量全部太阳辐射覆盖波长范围(400~2500 nm)的成像光谱仪,一般搭载于美 U2 飞机。实验数据成像区域为某机场,空间分辨率为 3.5

m, 每像素存为两个字节。限于 PC 机计算能力, 从原图像中截取  $128 \text{ pixel} \times 128 \text{ pixel}$  大小的区域进行实验。去除强噪声及水吸收波段, 从原数据 220 波段中选取 180 个波段作为实验对象。图 2 给出了该区域第 30 波段图。



图 2 某机场实验区局部第 30 波段  
Fig. 2 Local airfield of waveband 30

使用 3.1 节介绍的 HFC 方法, 进行 VD 的估计。图 3 给出了在虚警概率  $P_F = 10^{-4}$  情况下的特征值差分与阈值曲线, 其中实心点表示特征值差分, 实线表示阈值。表 1 给出了在不同虚警概率下, 这幅图像的 VD 估计表。




图 3 虚拟维数估计图 ( $P_F = 10^{-4}$ )

Fig. 3 Estimation of VD ( $P_F = 10^{-4}$ )

表 1 AVIRIS 图像 2 虚拟维数估计与虚警概率关系表  
Tab. 1 Relation between VD estimations and formalism probabilities

虚警概率	虚拟维数 VD
$P_F = 10^{-1}$	22
$P_F = 10^{-2}$	13
$P_F = 10^{-3}$	11
$P_F = 10^{-4}$	10
$P_F = 10^{-5}$	8

经过 VD 估计以后, 使用第 3.2 节介绍的非监督正交子空间投影端元提取方法, 进行端元提取, 得到 10 个端元矢量, 图 4 给出了提取结果。可以看出, 大的目标比如飞机 (第 6 个端元矢量), 以及一些异常信号 (第 4 端元矢量) 得到了很好的提取。使用这些矢量构成的  $180 \times 10$  矩阵作为混合矩阵  $\mathbf{A}$  的初始化矩阵, 应用 Fast\_ICA<sup>[9]</sup> 生成 10 个独立分量, 然后对各独立分量进行 2 维 SPIHT 压缩编码。表 2 给出了在不同压缩率下, 信噪比的变化情况。




图 4 UOSP 端元提取结果图

Fig. 4 Result of end member extraction using UOSP

表 2 不同压缩率下的压缩图像信噪比对照表  
Tab. 2 SNR for different CRs

压缩率 CR	信噪比 (dB)
5:1	51.04
10:1	42.03
15:1	37.96
20:1	32.84
40:1	27.33

为了检测压缩对数据后续应用的影响, 使用约束最小能量算子 (Constrained Energy Minimization, CEM) 对原始数据及独立分量图序列分别进行了仿真, 此处采用 UOSP 提取出的端元矢量作为待检测的目标 (ENVI 中给出了飞机目标的先验位置信息, 而 UOSP 准确地提取出了该目标端元)。耿修瑞博士于文献 [10] 对 CEM 进行了很好的改进, 推出了基于加权样本相关矩阵的目标探测算法, 解决了大目标探测问题与原 CEM 算法的不稳定问题。本文的仿真使用这种改进的 CEM 探测算法。设  $\mathbf{r}$  为图像中任一像元矢量,  $\mathbf{e}$  为待检测的模式矢量, 文献 [10] 提出了几种加权


方式,如欧几里德距离加权、波谱角度加权等。基于正交子空间投影的加权样本相关矩阵方法(OWCEM)得到了相对最优的目标检测结果。此处采用这种加权方式,即:

$$\mathbf{R}^* = \frac{1}{N} \sum_{i=1}^N \mathbf{r}_i^T \mathbf{P} \mathbf{r}_i \mathbf{r}_i \mathbf{r}_i^T, \quad (8)$$

其中,  $\mathbf{R}^*$  为加权自相关阵。设  $\mathbf{d}$  为感兴趣的目标矢量,则  $\mathbf{P} = \mathbf{I} - \mathbf{d}\mathbf{d}^+$ , 其中  $\mathbf{d}^+ = (\mathbf{d}^T \mathbf{d})^{-1} \mathbf{d}^T$  为  $\mathbf{d}$  的广义逆。


对原始 180 波段数据及 10 个独立分量图序列,分别使用 OWCEM 进行目标探测,其中 2 维 SPIHT 选择 10 倍压缩率。图 5 给出了部分结果图,分别为第 1、2、6、7 端元对应目标的检测结果。

通过图 5(a)与图 5(b)的比较,可以发现在使用本文方法进行数据压缩之后,极大降低数据量的同时,目标检测几乎没有受到什么影响。压缩前后,背景以及一些干扰分量均得到了很好的抑制。



(a)原始数据 OWCEM 检测结果

(a)Panel detection results of original data



(b)采用独立特征分量图 OWCEM 检测结果

(b)Panel detection results of ICs

图 5 CEM 检测结果图

Fig. 5 Detection results of CEM algorithm

主成分分析经常被应用于高光谱数据的压缩处理。这里对 PCA + SPIHT 方案与 ICA + SPIHT 方案在目标检测性能上做一番比较。仍使用该高光谱数据,对该数据做谱向主成分分析,取出前 10 个主成分特征图,各特征图经过 SPIHT 进行 10 倍压缩编码。使用前述 OWCEM 算子进行目标检测,对应图 5 的 4 个目标,检测结果如图 6 所示。

将图 6 与图 5 比较可以发现,经过 PCA 变

换,相当于将原数据矢量投影到多元正态分布下等密度椭圆面的主轴上,尽管具备了最优的能量汇聚功能,但是不能与高维数据特征吻合,因此,从模式识别的角度讲,变换过程破坏了原数据的“可分性”,无法抑制背景和噪声,造成了部分目标的混叠,从而检测失败。





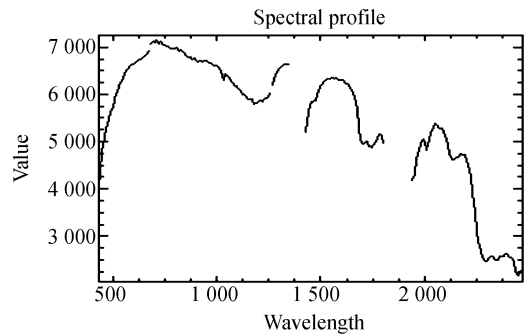
图 6 主分量特征图 OWCEM 检测结果

Fig. 6 Panel detection results of PCs



(a)目标 1

(a)Target 1



(b)目标 2

(b)Target 2

图 7 构造目标光谱曲线

Fig. 7 Spectrum curves of constructed targets

为了进一步分析 UOSP + Fast\_ICA + SPIHT 压缩方案对小目标,尤其是一些异常特征的保留性能,采用了与文献[10]类似的方法,构造小目标,研究压缩前后数据的异常检测功能。其中,目标 1、2 分别为如图 7 所示的光谱曲线,并将它们分别放置于坐标(60,30)和(120,60)处,目标

周围 4 个邻点分别采用 1/2 混合方式,即:

$$\begin{aligned}\hat{r}(60,29) &= 0.5 \times r(60,29) + 0.5 \times \mathbf{abnorm}(1) \\ \hat{r}(60,31) &= 0.5 \times r(60,31) + 0.5 \times \mathbf{abnorm}(1) \\ \hat{r}(59,30) &= 0.5 \times r(59,30) + 0.5 \times \mathbf{abnorm}(1) \\ \hat{r}(61,30) &= 0.5 \times r(61,30) + 0.5 \times \mathbf{abnorm}(1),\end{aligned}\quad (9)$$

其中,  $\hat{r}(g, g)$  和  $r(g, g)$  分别表示合成像元矢量和原像元矢量,  $\mathbf{abnorm}(1)$  表示第 1 个构造目标矢量, 坐标(120,60)周围点情况可以仿照写出。

经过图 1 所示的数据处理流程( $P_F = 10^{-2}$  情况下, UOSP 完全提取到两个构造目标), 同样使用 OWCEM 检测, 并将此结果与原始数据和主成分特征图检测比较, 结果如图 8 所示。

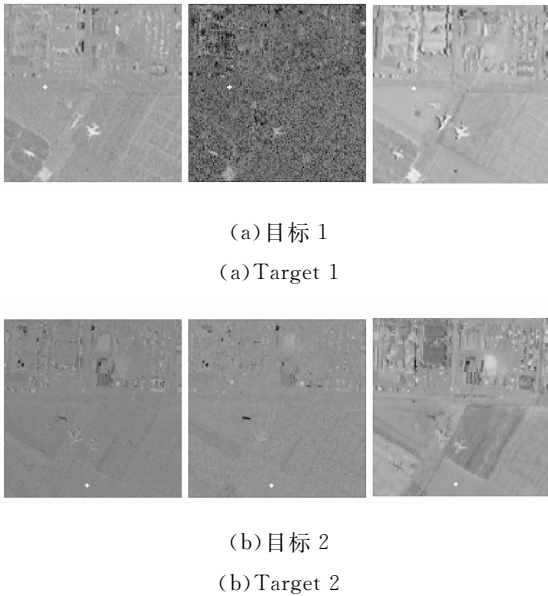


图 8 构造目标检测结果(从左到右分别为原始数据检测、IC 图检测、主特征图检测)

Fig. 8 Detection results of constructed targets(from left to right: original data, ICs, PCs)

通过图 8 可以看出, 相对于原始数据检测和主成分特征图检测, 基于 IC 图检测的方法更好地抑制了周围背景和其他目标, 检测效果最好, 是一种稳健的有损压缩方案。原始数据对目标 2 效果较好, 但对于目标 1 出现了一定程度的干扰信号, 而主成分特征图检测对目标 1、2 都没能很好的抑制背景和其它信号。

## 5 结 论

针对小目标和异常检测的特殊应用, 本文提出了使用非监督正交子空间投影方法(UOSP)提取端元矢量, 初始化 Fast\_ICA 混合矩阵的方法, 进行高光谱图像的压缩, 并采用了 ICA+SPIHT 的压缩框架。首先, 估计原始数据的虚拟维数, 继而采用 UOSP 提取出端元矢量, 并以这些矢量构成的矩阵作为初始化矩阵, 对高光谱数据做 ICA 变换, 对 IC 图, 使用 2 维 SPIHT 压缩编码。通过对 224 波段 AVIRIS 数据仿真实验证明, 该压缩方案在取得较高压缩率的同时, 很好地保留了数据的谱向特性, 压缩数据在目标检测尤其是小目标和异常的检测上, 与基于 PCA 的压缩算法相比, 具有独特的优势, 是一种行之有效的三维数据压缩方法。

进一步的研究可以针对完全基于 IC 图的非监督“端元”提取, 同时, 在小目标检测环境下, 端元提取方法以及虚警概率的选定标准需要进一步探讨。

## 参考文献:

- [1] 肖功海, 舒嵘, 薛永琦. 显微高光谱成像系统的设计[J]. 光学 精密工程, 2004, 12(4):367-372.  
XIAO G H, SHU R, XUE Y Q. Design of microscopic hyperspectral imaging system[J]. *Opt. Precision Eng.*, 2004, 12(4): 367-372. (in Chinese)
- [2] HYVÄRINEN A, KARHUNEN J, OJA E. *Independent Component Analysis*[M]. New York: Wiley, 2001.
- [3] CHEIN I C, QIAN D. Estimation of number of spectrally distinct signal sources in hyperspectral imagery[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2004, 42(3):608-619.

- [4] 吴波,张良培,李平湘. 非监督正交子空间投影的高光谱混合像元自动分解[J]. 中国图像图形学报,2004,9(11):1392-1396.  
WU B, ZHANG L P, LI P X. Unsupervised orthogonal subspace projection approach to unmix hyperspectral imagery automatically[J]. *Journal of Image and Graphics*, 2004,9(11):1392-1396. (in Chinese)
- [5] JOSEPH C H. *Detection and classification of subpixel spectral signatures in hyperspectral image sequences*[D]. Maryland:University of Maryland, 1993.
- [6] AMIR S, WILLIAM A P. A new, fast, and efficient image codec based on set partitioning in hierarchical trees[J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 1996, 6(3):243-250.
- [7] GREEN A A, BERMAN M, SWITZER P, *et al.*. A transformation for ordering multispectral data in terms of image quality with implications for noise removal[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1988,26(1):65-74.
- [8] RAMAKRISHNA B, WANG J, CHEIN I C. Spectral/spatial hyperspectral image compression in conjunction with virtual dimensionality[J]. *SPIE*, 2005, 5806:772-781.
- [9] <http://www.cis.hut.fi/projects/ica/>[Z].
- [10] 耿修瑞. 高光谱遥感图像目标检测与分类技术研究[D]. 北京:中国科学院遥感应用研究所, 2005.  
GENG X R. *Target detection and classification for hyperspectral imagery* [D]. Beijing: Institute of Remote Sensing Applications, Chinese Academy of Sciences, 2005. (in Chinese)

**作者简介:**苏令华(1979—),男,山东枣庄人,国防科技大学博士生,主要从事遥感图像处理、雷达信号处理等方面的研究;E-mail:sulinghua79@sina.com.

万建伟(1964—),男,江西南昌人,主要从事雷达信号处理,现代信号处理,遥感图像处理等方面的研究。E-mail:kermittwan@hnmcc.com