

doi:10.3788/gzxb20134210.1224

# 采用主成分量化和密度估计期望最大聚类的高光谱异常目标检测

赵春晖, 李晓慧, 田明华

(哈尔滨工程大学 信息与通信工程学院, 哈尔滨 150001)

**摘要:**针对高光谱图像异常目标检测中图像邻近像元光谱相似易对检测结果产生干扰的现象,将聚类算法引入到异常目标检测领域,提出一种采用主成分量化和密度估计期望最大聚类的高光谱图像异常目标检测算法.在高维空间中,使用期望最大聚类算法对像元光谱向量进行聚类,将邻近像元的空间相关性转化为类内或类间像元的关系,根据异常像元分布在类别边缘的原理,以类为单位检测异常目标,有效地避免异常点的信息被淹没;另外,针对期望最大聚类算法对初始化过程要求敏感的问题,提出了根据图像的第一主成分信息,分别利用向量量化和密度估计的方法对期望最大聚类算法进行初始化,进一步提高算法的检测效果和计算效率.用合成和真实的 AVIRIS 高光谱数据进行仿真实验,仿真结果表明使用基于主成分量化和密度估计期望最大聚类算法的高光谱图像异常目标检测算法明显优于传统的异常检测算法.

**关键词:**高光谱图像;异常检测;主成分量化;密度估计;期望最大聚类

中图分类号:TP751.1

文献标识码:A

文章编号:1004-4213(2013)10-1224-7

## Hyperspectral Imaging Abnormal Target Detection Algorithm Using Principal Component Quantization and Density Estimation on EM Clustering

ZHAO Chun-hui, LI Xiao-hui, TIAN Ming-hua

(College of Information and Communication Engineering, Harbin Engineering University, Harbin 150001, China)

**Abstract:** In order to overcome the problem caused by similar spectrum of the adjacent pixels, the clustering algorithms were introduced into the hyperspectral imagery abnormal target detection. A new algorithm using principal component quantization and density estimation on EM clustering was proposed in this paper. Using EM algorithm to cluster hyperspectral spectrum vectors in the high dimension space, the relations between adjacent pixels in spatial space were be represented by the relations inside or between classes. According to the theory that the abnormal target pixels would spread around the edge of the classes, abnormal target was detected in the unit of class to effectively avoid abnormal point information flooded. And this algorithm achieved good detection effect. For the requirement of EM algorithm initialization is sensitive, in related with the first principal component information of the imagery dataset, EM clustering algorithm was initialized by vector quantization and density estimation method. This can reduce the problems caused by initialization of EM clustering algorithm, and improve the detection effect of the algorithm and computation efficiency. With simulated and real AVIRIS hyperspectral dataset used in simulation experiment, the results show that the proposed anomaly detection algorithm is obviously superior to the traditional detection algorithm.

基金项目:国家自然科学基金(No. 61077079)、教育部博士点计划基金(No. 20102304110013)和黑龙江省自然科学基金重点项目(No. ZD201216)资助

第一作者:赵春晖(1965-),男,教授,主要研究方向为高光谱图像处理、非线性信号处理. Email: zhaochunhui@hrbeu.edu.cn

收稿日期:2013-03-20;录用日期:2013-05-29

**Key words:** Hyperspectral image; Anomaly target detection; Principal component quantization; Density estimation; Expectation maximization clustering

## 0 引言

高光谱遥感成像技术是近年来在多光谱遥感成像技术的基础上发展起来的一种将空间成像技术和光谱技术结合于一体的多维信息获取技术<sup>[1]</sup>. 高光谱图像所携带的信息能够识别地物光谱细微差异, 因而在检测、识别地面目标等方面具有独特的优势, 在环境监测, 安全防卫等领域发挥重要的作用. 地物分类和目标检测是高光谱图像处理技术的两个主要应用. 异常目标检测是指在完全不知道图像的先验信息的条件下, 对图像自身包含的“小目标”进行“盲”检测, 这里的“小目标”是指其光谱数据的异常, 更符合实际的应用条件, 特别是在未知背景和未知目标情况下的异常目标检测, 因而具有重要意义<sup>[2]</sup>.

目前, 比较常用的异常目标检测算法有 RX (Reed, Xiaoli Yu, RX) 算法、正交子空间投影 (Orthogonal Subspace Projection, OSP) 算法、约束能量最小化算法 (Constrained Energy Minimization, CEM)、支持向量数据描述方法 (Support Vector Data Description, SVDD) 等<sup>[3]</sup>. 由 Reed 和 Xiaoli Yu 两人提出的源自多光谱图像的 RX 算法是最为经典的异常检测算法. RX 算法<sup>[4]</sup> 在被认为是背景均一的图像子块上检测异常目标; 但这种背景假设往往与实际情况相差甚远, 算法易受到邻近像元光谱相关性的影响, 参量估计时背景中混入的异常点对 RX 算法的检测结果影响巨大. 此后出现的投影追踪法<sup>[5]</sup>、凸面体投影法<sup>[6]</sup> 等异常检测算法在描述背景时, 与 RX 算法类似, 将高光谱图像看作具有稳定分布的随机场, 用协方差或互相关矩阵来描述背景, 仍然没有考虑复杂背景中异常点对背景模型的影响. OSP 算法<sup>[7-8]</sup> 和 CEM 算法<sup>[9]</sup> 等, 需要已知目标向量的先验信息, 然而这些先验知识在实际应用中很难获取. SVDD 算法<sup>[10-11]</sup> 在检测含有复杂背景干扰的高光谱异常目标时, 检测准确度较低.

高光谱图像异常目标检测可以看作是一种特殊形式的二分类问题: 将图像分为异常目标和背景两类. 据此, 本文引入了聚类分析方法检测异常目标, 旨在挖掘聚类算法在异常目标检测领域的适用性. 将聚类算法引入到高光谱异常目标检测中, 能够有效地抑制图像邻近像元的光谱相似对检测结果产生的影响. 根据异常目标像元分布在各个类的边缘的原理, 将距离作为异常检测算子, 以类为单位检测聚类后的高光谱数据的异常像元, 并针对期望最大

(Expectation Maximization, EM) 聚类算法对初始化方式敏感的问题, 提出利用向量量化和密度估计两种方法对 EM 聚类算法进行初始化, 降低初始化过程对 EM 聚类算法的影响.

## 1 基于聚类算法的异常目标检测

基于聚类算法的异常目标检测算法在不需要先验知识的情况下, 利用聚类算法, 通过分析图像各个像元在背景分布上的归属程度来检测异常目标. 它采用多元高斯混合模型, 假设高光谱图像的背景像元可以被分割成一系列不同的类, 每一类中的像元都服从高斯分布. 聚类算法的作用就是根据像元光谱之间的相似性而将图像中的每个像元划分到其所属的类中. 根据高光谱图像的成像原理, 由于同种物质的光谱具有相似性, 在聚类过程中就会归为同一类; 而不同种物质会彼此分离, 归属于不同类别, 如图 1.

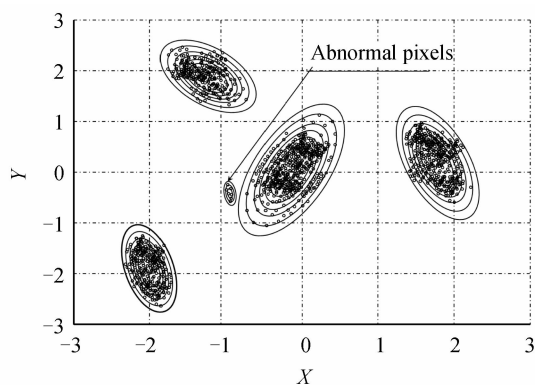


图 1 异常目标示意图

Fig. 1 Abnormal target schematic

由于异常目标通常不可能大量存在于高光谱图像中, 所以这些异常目标通常不能形成单独的类; 事实上这些异常目标的像元分布于与其光谱特性最为相似的背景类中, 但由于其光谱特性与所属的类的特性并不完全相同, 这些异常目标的像元常常会游离于与其光谱特性最为相似的背景类的边缘, 形成外围的依附点. 这样可以根据各个像元在其所归属的类中的位置检测异常目标. 本文中使用像元向量与聚类中心的距离的大小衡量归属感, 从而检测异常目标, 即这些异常像元点距离聚类中心的距离和其归属感成反比.

基于聚类的异常目标检测算法使用多元高斯混合模型. 设包含  $M \times N$  个像元的高光谱图像  $I$ , 它可以分割成为  $K$  个不同的类  $X_k$  ( $1 \leq k \leq K$ ). 在高维空间中, 每一个类中的所有像元点都相互聚集成一个

“云团”式的分布,每一个类内的像元都符合高斯分布.若高光谱图像像元光谱  $x_{i,j}$  ( $1 \leq i \leq M, 1 \leq j \leq N$ ) 归属于第  $k$  个类  $X_k, X_k = \{\mu_k, \Sigma_k\}$ ; 其中,  $\mu_k$  为第  $k$  个类的聚类中心,  $\Sigma_k$  为其协方差矩阵, 这里的  $n_k$  是类  $X_k$  所包含的像元数. 则类  $X_k$  所符合的高斯分布的概率密度函数为

$$f_k(x) = \frac{1}{(2\pi)^{n/2}} \frac{1}{|\Sigma_k|^{1/2}} \exp \left\{ -\frac{1}{2} (x - \mu_k)^T \cdot \Sigma_k^{-1} (x - \mu_k) \right\} \quad (1)$$

式中,  $x$  为属于第  $k$  簇的像元光谱向量,  $\mu_k$  为第  $k$  簇的聚类中心,  $\Sigma_k$  为协方差矩阵.

在进行聚类分析时, 根据图像中各个像元  $x_{i,j}$  ( $1 \leq i \leq M, 1 \leq j \leq N$ ) 归属于各个类的概率密度函数值  $f_k(x_{i,j})$  ( $1 \leq k \leq K$ ) 的大小来判别其最终的归属. 每类中与聚类中心光谱差异越小的像元点距聚类中心越近, 其多元高斯概率密度  $f_k(x)$  越高, 而异常点由于分布在类的边缘, 距聚类中心远, 其归属于各个类的概率密度  $f_k(x)$  较小.

在获得聚类的最终结果后, 根据异常像元点距聚类中心的距离较大原则, 计算每个像元光谱  $x_{i,j}$  ( $1 \leq i \leq M, 1 \leq j \leq N$ ) 与其所归属的类的聚类中心光谱向量的距离, 根据距离值的大小判别该像元是否为异常目标点.

本文使用 EM 聚类算法对高光谱图像进行检测, 用以描述聚类算法在异常目标检测中的作用.

## 2 EM 聚类算法及其初始化

### 2.1 EM 聚类算法原理

EM 聚类算法由 Dempster 等人提出来, 是从不完全数据中求解极大似然估计的一种迭代算法<sup>[12]</sup>. 由于该聚类算法不依赖较多的先验知识, 因而更加适用于高光谱异常目标的“盲”检测问题.

假设高光谱图像数据  $I$  是一个不完整的数据集合  $I = \{x_{i,j} | 1 \leq i \leq M, 1 \leq j \leq N\}$ , 现在构造完整的数据集  $Y = (I, Z)$ , 假设被引入的隐含变量  $Z$  是完整数据集中的缺失数据,  $Z = \{z_{i,j} | 1 \leq i \leq M, 1 \leq j \leq N\}$ ,  $z_{i,j} = \{z_{i,j}^1, z_{i,j}^2, \dots, z_{i,j}^m\}$ ,  $z_{i,j}^k \in \{0, 1\}$ ,  $m$  是给定的有限整数, 由初始化过程给出. EM 算法的基本思想为: 对这一完整的数据集合  $Y$ , 假设这些数据独立同分布于已知参量的某一个模型, 因此可以根据该模型推出属于每个成分的各数据点的概率, 然后修改每个成分的值, 重复该过程直到收敛于结束条件.

对于由高光谱图像数据  $I$  构造的完整待观测数据集  $Y = \{y_{i,j} | 1 \leq i \leq M, 1 \leq j \leq N\}$  中的单个采样  $y_{i,j} = (x_{i,j}, z_{i,j})$ , 其高斯混合模型的概率密度分布函数为

$$F(y_{i,j}) = \sum_{k=1}^m p_k f_k(y_{i,j}) \quad (2)$$

$$p_k = \left( \sum_{i=1}^M \sum_{j=1}^N z_{i,j}^k \right) / (M \times N) \quad (3)$$

EM 算法的每次迭代都由 E-step 和 M-step 两步组成:

M-step: 给定观察样本和当前解条件, 计算完全数据集  $Y$  中每一个像素的所服从的高斯概率密度函数值

$$\mu_k = \left( \sum_{i=1}^M \sum_{j=1}^N z_{i,j}^k x_{i,j} \right) / n_k \quad (4)$$

式中,  $n_k$  是第  $k$  类所包含的像元数目.

E-step: 根据每个像元点的概率密度重新分配其所属的簇

$$z_{i,j}^k = \begin{cases} 1 & \text{if } (k = k_0) \\ 0 & \text{else} \end{cases} \quad (5)$$

$$k_0 = \operatorname{argmax}_k \frac{p_k f_k(y_{i,j})}{F(y_{i,j})} \quad (6)$$

聚类的 EM 算法是在 E-step 和 M-step 之间迭代, 直到聚类的结果收敛为止.

### 2.2 EM 聚类算法的初始化过程

EM 聚类算法是一种通过多次迭代求取最优值的算法. 它的每次迭代都由设定模型的初始参量开始, 算法每迭代一次, 重新计算模型的参量. 迭代直到超过预设的迭代次数或满足收敛条件. 在高斯混合模型的 EM 算法中, EM 聚类算法的初始化参量的设定对最终的聚类结果有较大的影响. 换言之, EM 聚类算法对采用何种初始化方法得到的参量比较敏感. 要取得较好的聚类及异常检测结果, 优化 EM 聚类算法的初始化过程就显得尤为重要.

文中采用根据主成分分析算法 (Principal Component Analysis, PCA) 获取的图像第一主成分信息来初始化 EM 聚类算法. PCA<sup>[13]</sup> 是一种基于变换的方法对高光谱数据进行特征提取, 将高光谱数据从原始的高维空间中映射到一个新的空间; 它在几何意义上相当于进行空间坐标的旋转, 第一主成分是波谱中数据散布最集中的方向.

EM 聚类算法需要采用高效的初始化方法, 才能较好较快地得到异常目标检测结果. 由于高光谱图像的光谱波段多, 单独一个波段所包含的信息过少; 若采用波段组合进行初始化, 计算量过于巨大, 能代表图像大部分信息的波段组合所包含信息量也少于第一主成分所包含的信息量. 故采用高光谱图像第一主成分信息初始化更能有效解决这一问题对聚类结果的影响, 使 EM 迭代算法的效率更高. 在实验仿真时, 第一主成分的贡献率能达到 90% 以上, 能够代表图像的大部分信息, 利用第一主成分信

息可以更有效的初始化 EM 聚类算法。

使用高光谱图像的第一主成分信息初始化 EM 聚类算法时,分别采用向量量化和密度估计的方法进行初始化。

### 2.2.1 向量量化初始化方法

向量量化或称为矢量量化<sup>[14]</sup>.通常在量化过程中是将每个像素的采样值孤立起来,作为一个一维的连续取值的变量进行处理,将其取值范围按某种准则划分成若干段,所有落在同段中的采样值都用同一个代表值代替,由于被量化的采样值是一维变量,所以被称为标量量化.将标量量化的概念推广到多维,就是所谓的向量量化.即指将一组采样值量化为有限个数组状态中的一个。

将图像的第一主成分划分为  $R$  个量化级别,将每一个像元的第一主成分按照如果  $x_r < x < x_{r+1}$ , 则  $x \rightarrow x_r$ , 这样就可以得到一个基本的初始类的标签,完成初始化过程.  $x_r, 0 \leq r \leq R$  的选取要使量化的均方误差  $\epsilon$  最小。

$$\epsilon = \sum_{r=0}^{R-1} \int_{x_r}^{x_{r+1}} (x - x_r)^2 p(x) dx \quad (7)$$

式中,  $p(x)$  为图像第一主成分的幅值  $x$  的概率密度。

### 2.2.2 密度估计初始化方法

根据密度估计进行初始化的方法:根据原始数据集,最好的聚类中心可能就是概率密度函数最稠密的部分.因此,提出了一种使用密度函数的初始化方法.密度函数方法性能计算简单,运算量较小。

所谓密度估计,就是我们根据一定的宽度,将每一维上的整个数据空间分成若干个区域,然后把每个数据的每一维放到对应的区域里面,再计算每一个区域里所含的数据点的个数.含的点数的多的则为概率密度相对大的区域.也就是聚类中心最可能存在的区域。

初始化 EM 的任务就是找到最优聚类中心.通过对图像第一主成分的灰度值进行密度估计,再求取图像的第一主成分后,可以把数据空间在一维上划分成一个个的箱子,再把主成分的值投射到对应的箱子里去.于是,我们可以通过密度估计法来寻找概率密度函数最稠密的部分.概率密度分布曲线的极大值周围的点被认为属于一个类的可能较大,将 2 个极大值中间的极小值点作为分界的门限,对图像的第一主成分按照灰度值进行划分,分别给予类标号,完成初始化过程。

## 3 仿真实验结果及分析

### 3.1 实验数据

为了检验本文提出的异常检测算法的性能,使

用一幅合成数据和一幅真实的 AVIRIS 高光谱图像数据进行仿真实验。

合成数据是根据真实的 Cuprite 高光谱图像数据合成的. Cuprite 高光谱图像数据是 1997 年拍摄于美国内华达州 Cuprite 矿,它包含了 224 个波段的图像数据.在去除水的吸收波段和低信噪比的波段后,保留了 189 个波段(去除波段 1-3, 105-115 和 150-170)的数据参与仿真实验.由于在这幅图像中包含有很多种矿物,而其中只有 5 种矿物的真实分布是已知的(分别为 Alunite, Buddingtonite, Calcite, Kaolinite 和 Muscovite),这 5 种矿物和背景的光谱见图 2。

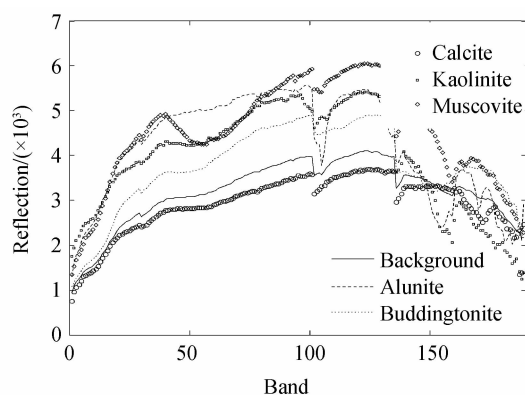


图 2 5 种矿物和背景的光谱

Fig. 2 Five kinds of mining and background spectra

根据这 5 种矿物的光谱构造一幅合成数据来检验本文中所提出算法的性能.合成数据的图像大小为  $100 \times 100$ ,包含了 25 个大小为  $8 \times 8$  的异常目标,其中每一排的 5 个目标属于同一种矿物,其光谱由其真实光谱与随机高斯噪声混合而成,其第 1 个波段以及异常目标的真实分布如图 3。

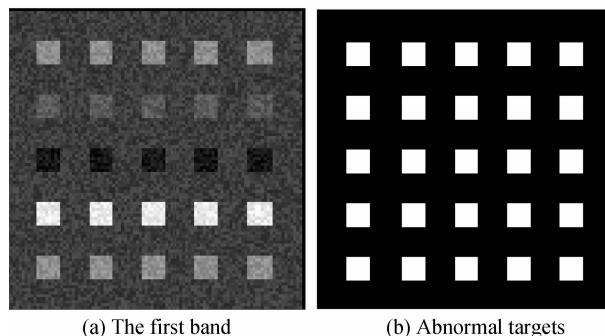


图 3 合成图像数据


Fig. 3 Simulated datasets

实验中使用的另一幅图像数据是真实的 AVIRIS 高光谱图像,它拍摄于美国圣地亚哥机场,光谱范围覆盖了从可见光到近红外,其参量如表 1。

这幅高光谱图像中包含了 38 个待检测的异常目标.所用实验图像的第 1 个波段以及地面异常目标的真实分布如图 4。

表 1 仿真实验所用高光谱图像参量  
Table1 Hyperspectral image parameter list

Sensor	AVIRIS
Wavelength/ $\mu\text{m}$	0.4~1.8
Band	126
Resolution/m	3.5
Size	100×100
Grayscale	0~10 000
Location	Santiago airport



(a) The first band (b) Abnormal targets

图 4 真实的 AVIRIS 高光谱图像  
Fig. 4 Real AVIRIS image

3.2 实验结果及分析

实验中对比较研究的内容为:使用向量量化和密度估计的方法初始化 EM 聚类算法的异常目标检测算法(分别记为 VQ-EM 和 PCA-EM)的检测结果,与采用随机初始化 EM 聚类算法的异常目标检测算法(记为 SJ-EM)的检测结果.为了说明本文中所提出算法的优点,实验中将传统的 RX 算法的检测结果列出,作为对比参考.

对于合成数据,使用向量量化方法初始化 EM 算法时,量化级别为 16,根据第一主成分的值均匀的分为 16 个刻度,据此将合成图像中所有的像元初始化为 16 类,然后执行 EM 聚类算法;而使用密度估计方法初始化时,根据图像的第一主成分的量值统计出其直方图分布,如图 5. 根据图像第一主成分分布,初始化为 6 类.


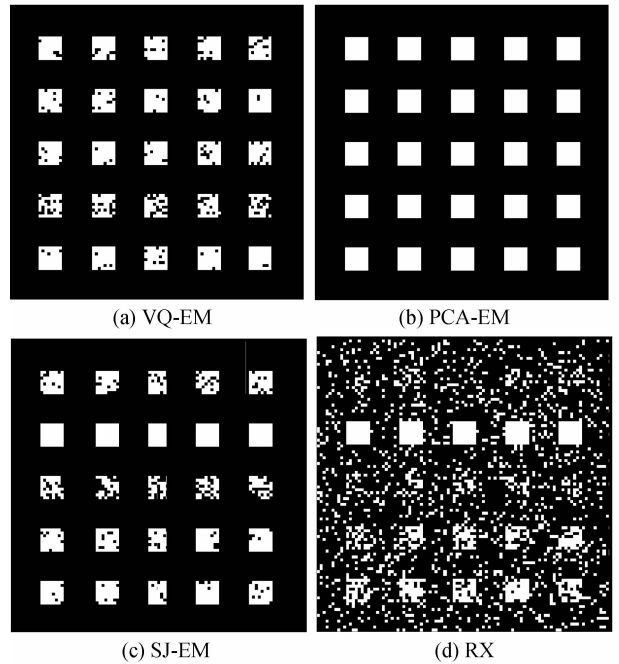


图 5 合成图像数据第一主成分分布直方图  
Fig. 5 Histogram of the first principal component for simulated dataset

四种算法的检测结果如图 6.



(a) VQ-EM (b) PCA-EM  
(c) SJ-EM (d) RX

图 6 模拟数据的检测结果

Fig. 6 Detection results for simulated dataset

同时,本文还对分别采用不同种初始化方法的 EM 聚类检测算法的迭代次数和程序运行时间进行了比较,其比较结果如表 2.

表 2 算法性能比较

Table 2 Algorithm performance comparison

Detection method	Iteration	Time/s
SJ-EM	25	282.74
VQ-EM	6	52.74
PCA-EM	2	14.34

对于真实的 AVIRIS 高光谱图像数据,先画出图像第一主成分灰度值的概率密度曲线,如图 7.




图 7 真实高光谱图像第一主成分的概率分布  
Fig. 7 The probability density of the first principal component

这四种算法的检测结果的二值化图像如图 8. 其中,使用向量量化的方法初始化 EM 算法时,将图像的第一主成分信息均匀划分为 8 个量化级别;而使用密度估计初始化方法时,将相邻的两个密度

极大值之间的极小值作为门限,从而对主成分的灰度值进行划分,完成初始化过程.实验中,使用密度估计的方法将图像的第一主成分信息划分为7个级别.




图8 检测算法在最优检测阈值下的检测结果  
Fig. 8 Detection results under the optimal threshold

从图6和图8的实验结果中可以看出,基于EM聚类算法的异常目标检测算法可检测到更多的异常目标像元,具有较高的目标检测概率,其检测结果要明显地优于传统的RX算法.由于RX算法考虑的是待检测像元点周围的局部空间像元光谱之间的相关性,而EM聚类算法先将各个像元划归到其光谱特性最为相似的类中,考虑在以类为单位检测异常目标像元,通过寻找与聚类中心的距离较远的点进行检测,消除了临近像元对检测结果的影响,因而具有更好的检测性能.同时,对几种不同初始化方法的检测结果比较发现,随机初始化方法虽然操作简单,但是其检测效果也最为不理想,且在实验仿真中发现,选取不同的像元点作为初始化聚类中心的检测结果也有差异,结果并不唯一,具有很大的偶然性;而通过对高光谱图像第一主成分信息的分析,可以较快地找到相对较好的初始化点,从而取得较好的检测效果.而且采用密度估计初始化方法的结果要优于采用向量量化初始化方法.本文提出的两种通过对图像的第一主成分信息来初始化EM聚类算法的检测结果更为理想,充分说明了本文所提出的算法具有优越的性能.

同时,对分别采用不同种初始化方法的EM聚类算法检测算法的迭代次数和程序运行时间进行了

比较,对算法的计算效率进行分析,其比较结果如表3.

表3 算法性能比较

Table 3 Algorithm performance comparison

Detection method	Iteration	Time/s
SJ-EM	37	2 678
VQ-EM	21	583
PCA-EM	16	465

从表2和表3可以看出,采用随机初始化的方法的基于EM聚类算法的异常目标检测算法迭代次数和运行时间都较大,而两种通过对图像的第一主成分信息来初始化的检测算法的迭代次数和运行时间都有很大程度的减小.通过对图像第一主成分信息量化和密度估计来进行初始化可以较快地找到相对较好的初始化点,尤其是密度估计的方法,这也说明了这种初始化方法的有效性.

最后,通过接收机工作特性(Receiver Operating Characteristics, ROC)来分析算法的性能.检测概率 $P_d$ 作为一个以虚警概率 $P_f$ 为自变量的函数,描述了在不同的检测阈值下 $P_d$ 与 $P_f$ 之间的变化关系.ROC曲线为算法检测性能的定量分析提供参考.其中, $P_f$ 定义为检测结果中非异常目标而被确定为异常目标的虚警像元数目与图像包含的全部像元数目的比值; $P_d$ 定义为检测结果中所检测出来的异常目标像元数目与图像中包含的真实的异常目标像元数目的比值.对真实的高光谱图像数据采用上述三种采用不同种初始化方法的检测算法的接收特性曲线如图9.

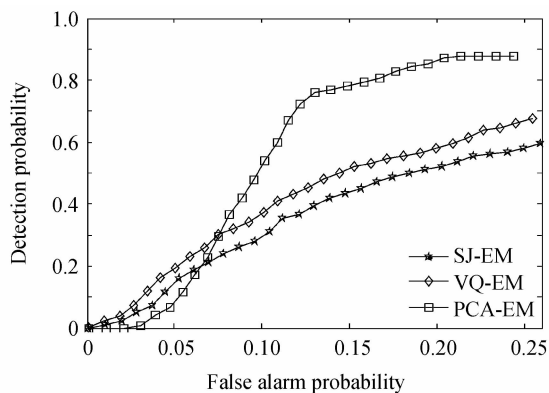


图9 接收机工作特性曲线

Fig. 9 Receiver operating characteristics curve

从图9中接收机工作特性曲线可以看出,对EM聚类算法采用分析图像的第一主成分信息的方法初始化后,检测性能更加理想.采用主成分向量量化的初始化方法特性一直优于采用随机初始化的方法,但优势较小;而采用主成分密度估计的初始化方法在 $P_f$ 大于0.07时,检测性能大幅提升,相比其他的检测算法,其检测效果更加优越.

## 4 结论

提出了一种采用主成分量化和密度估计 EM 聚类算法的高光谱图像异常目标检测算法. 探讨了将聚类算法引入到异常检测领域中, 将邻近像元的空间相关性转化为类内或类间像元的关系, 有效地防止异常点的信息被淹没, 在 EM 聚类算法结果的各个类中进行检测. 针对 EM 聚类算法对初始化过程的敏感性, 通过采用向量量化和密度估计的方法分析图像的第一主成分信息来初始化 EM 聚类算法, 降低了初始化对 EM 聚类算法的影响, 进一步提高算法的检测效果和计算效率, 通过理论分析和真实的高光谱数据的仿真实验, 该方法取得了较好的检测效果.

### 参考文献

- [1] MATTEOLI S, DIANI M, CORSINI G. A tutorial overview of anomaly detection in hyperspectral images[J]. *IEEE A&E Systems Magazine*, 2010, **25**(7): 5-27.
- [2] ZHAO Chun-hui, HU Chun-mei, BAO Yu-gang. A kind of anomaly detection algorithm for hyperspectral image through background error cumulation [J]. *Acta Photonica Sinica*, 2010, **39**(10): 1830-1835.  
赵春晖, 胡春梅, 包玉刚. 一种背景误差累积的高光谱图像异常检测算法[J]. *光子学报*, 2010, **39**(10): 1830-1835.
- [3] MEI Feng, ZHAO Chun-hui, WANG Li-guo, YOU Jia. Support vector data description based on adaptive anomaly detection method in hyperspectral imagery[J]. *Acta Photonica Sinica*, 2009, **38**(11): 2820-2825.  
梅锋, 赵春晖, 王立国, 尤佳. 基于支持向量描述的自适应高光谱异常检测算法[J]. *光子学报*, 2009, **38**(11): 2820-2825.
- [4] REED I S, YU X. Adaptive multi-band CFAR detection of an optical pattern with unknown spectral distribution[J]. *IEEE Transactions on Acoustics Speech and Signal Processing*, 1990, **38**(3): 1760-1770.
- [5] CHIANG S S, CHANG C I, GINSBERG I W. Unsupervised target detection in hyperspectral images using projection pursuit[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2001, **39**(7): 1380-1391.
- [6] ZHANG Bing, CHEN Zheng-chao, ZHENG Fen-lan. Object detection based on feature extraction from hyperspectral imagery and convex cone projection transform[J]. *Journal of Infrared Millimeter and Terahertz Waves*, 2004, **33**(8): 952-955.  
张兵, 陈正超, 郑芬兰. 基于高光谱图像特征提取与凸面几何体投影变换的目标探测[J]. *红外与毫米波学报*, 2004, **23**(6): 441-445.
- [7] CHANG C I. Orthogonal subspace projection (OSP) revisited: a comprehensive study and analysis [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, **43**(3): 502-518.
- [8] ZHAO Chun-hui, HU Chun-mei. Weighted anomaly detection algorithm for hyperspectral imagebased on target orthogonal subspace projection [J]. *Journal of Jilin University (Engineering and Technology Edition)*, 2011, **41**(5): 1468-1474.  
赵春晖, 胡春梅. 基于目标正交子空间投影加权的高光谱图像异常检测算法[J]. *吉林大学学报(工学版)*, 2011, **41**(5): 1468-1474.
- [9] YIN Ji-hao, WANG Yan, WANG Yi-song. A revised multi-target detection approach in hyperspectral image [J]. *Acta Electronica Sinica*, 2010, **38**(9): 1975-1978.  
尹继豪, 王艳, 王义松. 一种改进的高光谱图像中多小目标检测算法[J]. *电子学报*, 2010, **38**(9): 1975-1978.
- [10] KHAZAI S, HOMAYOUNI S, SAFARI A, et al. Anomaly detection in hyperspectral images based on an adaptive support vector method [J]. *IEEE Geoscience and Remote Sensing Letters*, 2011, **8**(4): 646-650.
- [11] CHENG Bao-zhi, ZHAO Chun-hui, WANG Yu-lei. SVDD algorithm with spectral unmixing for anomaly detection in hyperspectral images [J]. *Journal of Applied Sciences-Electronics and Information Engineering*, 2012, **30**(1): 82-88.  
成宝芝, 赵春晖, 王玉磊. 结合光谱解混的高光谱图像异常目标检测 SVDD 算法[J]. *应用科学学报*, 2012, **30**(1): 82-88.
- [12] YANG Zhi-hai, ZHOU Yu-yan, ZHU Yan, et al. Improved EM algorithm for hyperspectral classification [J]. *Journal of Zhengzhou Institute of Surveying and Mapping*, 2006, **23**(1): 36-40.  
杨哲海, 周玉岩, 朱艳, 等. 高光谱影像分类 EM 算法的完善[J]. *测绘科学技术学报*, 2006, **23**(1): 36-40.
- [13] ZHAO Chun-hui, HU Chun-mei, SHI Hong. Anomaly detection for a hyperspectral image by using a selective section principal component analysis algorithm [J]. *Journal of Harbin Engineering University*, 2011, **32**(1): 109-113.  
赵春晖, 胡春梅, 石红. 采用选择性分段 PCA 算法的高光谱图像异常检测[J]. *哈尔滨工程大学学报*, 2011, **32**(1): 109-113.
- [14] WEN Jia, MA Cai-wen, SHUI Peng-lang. An adaptive VQ algorithm used in interferential multi spectral image [J]. *Spectroscopy and Spectral Analysis*, 2011, **31**(4): 1033-1037.  
温佳, 马彩文, 水鹏朗. 改进自适应 LBG 矢量量化算法在干涉高光谱图像压缩中的应用[J]. *光谱学与光谱分析*, 2011, **31**(4): 1033-1037.