

# 基于带参考信号独立分量分析的高光谱 图像目标探测

金 硕<sup>1,2</sup>, 王 斌<sup>1,2\*</sup>, 夏 威<sup>3</sup>

(1. 复旦大学 电磁波信息科学教育部重点实验室, 上海 200433;

2. 复旦大学 信息学院智慧网络与系统研究中心, 上海 200433;

3. 中国交通通信信息中心, 北京 100011)

**摘要:**提出了一种用于高光谱图像目标探测的预处理方法,目的是提高目标光谱的准确性,进而提高有监督目标探测算法的精度.该方法将实验室或野外获取的目标光谱作为参考信号,利用带参考信号的独立分量分析方法,从图像中提取出与参考信号相关性最大的独立分量作为新的目标光谱.仿真和实际高光谱数据的实验结果表明,所提出的方法能较大提高目标光谱的准确性,从而较大提高目标探测算法的精度.

**关键词:**高光谱图像;目标探测;带参考信号的独立分量分析;预处理

**中图分类号:**TP751 **文献标识码:**A

## Target detection in hyperspectral imagery based on independent component analysis with references

JIN Shuo<sup>1,2</sup>, WANG Bin<sup>1,2\*</sup>, XIA Wei<sup>3</sup>

(1. Key Laboratory for Information Science of Electromagnetic Waves (Ministry of Education),  
Fudan University, Shanghai 200433, China;

2. Research Center of Smart Networks and Systems, School of Information Science and Technology,  
Fudan University, Shanghai 200433, China;

3. China Transport Telecommunications & Information Center, Beijing 100011, China)

**Abstract:** A new preprocessing method used for target detection in hyperspectral imagery was proposed. This preprocessing method can increase target spectra accuracy, so the performance of the target detection methods can be improved. By using the target spectra gotten from the laboratory and field as references, the proposed method extracts independent components, which are the closest to the references, from the hyperspectral imagery by means of independent component analysis with references (ICA-R). Then, these independent components are used as target spectra in the following supervised target detection methods. Experimental results on both simulated and real hyperspectral data demonstrate that the proposed method can get more accurate target spectra, which obtains much better performance of target detection.

**Key words:** hyperspectral imagery, target detection, independent component analysis with references (ICA-R), preprocessing

**PACS:** 84.40.Xb

## 引言

高光谱遥感的主要特点在于,成像光谱仪在电

磁波谱的紫外、可见光、近红外和中红外区域中的数十至数百个非常窄而且连续的光谱段上同时获取信息,能得到每个像元的完整连续的光谱曲线<sup>[1]</sup>. 因

收稿日期: 2013-12-10, 修回日期: 2015-01-29

Received date: 2013-12-10, revised date: 2015-01-29

基金项目: 国家自然科学基金(41371337), 上海市教育委员会科研创新项目(13ZZ005), 高等学校博士学科点专项科研基金(20110071110018)

Foundation items: Supported by National Natural Science Foundation of China (41371337), the Innovation Program of the Shanghai Municipal Education Commission (13ZZ005), the Research Fund for Doctoral Program of Higher Education of China (20110071110018)

作者简介 (Biography): 金硕 (1989-), 男, 河北邢台人, 硕士研究生, 主要研究领域为高光谱遥感图像的目标探测. E-mail: 12210720030@fudan.edu.cn.

\* 通讯作者 (Corresponding author): E-mail: wangbin@fudan.edu.cn

此,高光谱图像(Hyperspectral imagery, HSI)具有高光谱分辨率和宽波长覆盖范围,能够提供地物详尽的光谱信息.近年来,高光谱遥感技术得到了广泛应用,其中,目标探测是高光谱遥感的重要应用方向之一,涵盖了环境监测、矿物填图和军事侦察等诸多领域.由于空间分辨率的限制,HSI中存在大量的混合像元,待探测目标往往是亚像素级的.传统的基于空间形态信息的方法无法实现对亚像素目标的探测,HSI的目标探测则通常借助于它丰富的光谱信息<sup>[2]</sup>.

在目标地物的光谱先验已知的情况下,通常有四种经典方法进行有监督的目标探测<sup>[3]</sup>,其中包括约束能量最小化(Constrained Energy Minimization, CEM)算法<sup>[4]</sup>、自适应余弦一致性评估器(Adaptive Coherence/Cosine Estimator, ACE)算法<sup>[5]</sup>、自适应匹配滤波器(Adaptive Matched Filter, AMF)算法<sup>[6]</sup>和广义化似然比探测(Generalized Likelihood Ratio Test, GLRT)算法<sup>[7]</sup>.

在实际应用过程中,经典方法普遍存在以下问题:(1)算法中作为先验知识的目标光谱主要来自于实验室光谱数据库,光谱库中的光谱一般采用实验室或野外测量的方式获得,受观测几何、光照、大气、背景环境、仪器噪声等影响,这就使得测量光谱与真实图像光谱之间存在差异;(2)“同物异谱”现象也会导致目标光谱的不确定性<sup>[3]</sup>.然而有监督算法的精度取决于目标光谱的准确性和图像噪声水平<sup>[2]</sup>,当作为先验知识的目标光谱不精确或者图像数据噪声较大时,算法精度显著下降.

为了解决上述问题,提出了一种基于带约束的独立分量分析(Independent Component Analysis with References, ICA-R) HSI 目标探测算法.该方法将 ICA-R 引入 HSI 处理领域中,在传统的有监督目标探测方法之前加入一个预处理过程,以光谱库获得的目标地物光谱作为参考信号,从 HSI 中提取得到与参考信号相关性最大的独立分量作为目标地物光谱,这个提取到的光谱就是预处理之后的目标光谱,然后利用有监督的目标探测算法完成目标探测.因为预处理后得到的目标光谱比光谱库的光谱更加准确,更加接近于实际情况,所以这种方法能使有监督的目标探测算法获得更为准确的结果.仿真和实际数据实验将基于 ICA-R 的算法与传统的算法进行比较,说明了这种方法的有效性.

## 1 ICA-R

ICA 是指在不知道源信号和传输通道参数的情况

下,根据源信号的统计特性,仅由观测信号求得各个独立分量的方法<sup>[8]</sup>.ICA 算法求得的是所有独立分量,然而在实际应用中,许多独立分量并不需要,因此就需要一个附加的筛选过程.而 ICA-R 将提取和筛选这两个过程同时实现,使结果仅含有所需要的独立分量.ICA-R 引入  $k$  维参考信号  $\mathbf{r} = (r_1, r_2, \dots, r_k)^T$ ,其中各分量  $r_i$  的采样长度与观测信号  $x_i$  相同, $k$  为参考信号个数.ICA-R 算法将参考信号以约束条件的形式加入到 ICA 的目标方程中,约束条件是分离出的独立分量与参考信号之间的距离小于某一阈值.这样,分离出的独立分量仅仅是与  $\mathbf{r}$  具有相同特征的一部分,从而避免了附加的筛选过程.ICA-R 算法的目的是经过一系列迭代训练后得到与  $\mathbf{r}$  相关度最大的  $k$  个独立分量<sup>[9]</sup>.

ICA-R 算法的数学描述如下:

根据负熵最大原则,建立最优化目标函数:

$$C(\mathbf{y}) = \sum_{i=1}^k J(y_i) \quad (1)$$

式中, $C(\mathbf{y})$  是输出信号各个分量的负熵的代数和,负熵的计算公式见参考文献[9].

当  $y_i$  完全逼近目标源信号  $c_i$  时,  $E\{(y_i - r_i)^2\}$  具有最小值.设一阈值  $\xi_i$ ,令

$$g_i(\mathbf{w}_i) = E\{(y_i - r_i)^2\} - \xi_i \quad (2)$$

则当  $g_i(\mathbf{w}_i) \leq 0$  时,输出  $y_i$  为所求源信号的估计.令  $g_i(\mathbf{w}_i) \leq 0$  作为式(1)的可行性约束,则 ICA-R 算法可描述为如下约束最优化问题:

$$\text{Maximize: } C(\mathbf{y}) = \sum_{i=1}^k J(y_i)$$

$$\text{Subject to: } \mathbf{g}(\mathbf{W}) \leq 0, \mathbf{h}(\mathbf{W}) = 0 \quad (3)$$

式中,  $y_i = \mathbf{w}_i^T \mathbf{x}$ ,  $\mathbf{g}(\mathbf{W}) = (g_1(w_1), g_2(w_2), \dots, g_k(w_k))^T$ ,  $\mathbf{h}(\mathbf{W}) = (h_{11}(y_1), h_{12}(y_1, y_2), \dots, h_{1k}(y_1, y_k), h_{21}(y_2, y_1), \dots, h_{kk}(y_k))^T$ ,  $h_{ij}(y_i, y_j) = (E(y_i y_j))^2$ .

当式(3)成立时,ICA-R 算法结束, $\mathbf{y} = (y_1, y_2, \dots, y_k)^T$  即为所求的解向量.式(3)最优值求解可以使用拉格朗日函数的方法求解,使用拟牛顿算法对  $\mathbf{W}$  进行迭代,迭代公式详见文献[9].

## 2 ICA-R 用于目标光谱的提取

在有监督的目标探测中,首先需要在所有独立分量中找到所需要的目标光谱,其他物质的光谱并不被需要,所以,为了仅仅提取出目标光谱,将 ICA-R 引入到 HSI 中来提取目标光谱.基于 ICA-R 的目标探测算法流程如图 1 所示.

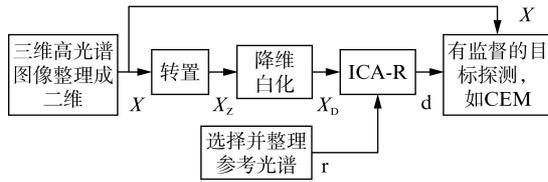


图1 基于 ICA-R 的目标探测流程

Fig. 1 Flowchart of target detection based on ICA-R

ICA-R 算法最初被应用于功能核磁共振图像提取某些特定的生理信号<sup>[9]</sup>, 国内的学者也应用类似方法提取某种特定的脑电信号, 这些信号都是随时间变化的信号, 与 HSI 有所不同. 为了将 ICA-R 算法应用到 HSI 中, 需要结合 HSI 的特点进行相应的改进.

在通常情况下, 端元之间的非线性相互作用可以忽略, 这时可以用线性模型来描述混合像元的形成机理<sup>[10]</sup>. 在线性混合模型中, 像素的观察值等同于各端元的光谱特征按照它们的丰度(物质在像素中所占比例)进行线性组合. 假设观察到  $L$  个波段的 HSI, 它是由  $P$  个端元线性组合而成, 则线性混合模型可被表示为

$$\mathbf{X} = \mathbf{A}\mathbf{S} + \mathbf{E} \quad (4)$$

这里,  $\mathbf{X} \in R^{L \times N}$  为高光谱观测数据矩阵, 其中每一行是一个波段, 每波段有  $N$  个像素,  $\mathbf{A} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_p] \in R^{L \times P}$  被称为端元光谱矩阵,  $\mathbf{a}_j$  对应着第  $j$  个端元的光谱特征,  $\mathbf{S} = [s_1, s_2, \dots, s_p]^T \in R^{P \times N}$  为丰度矩阵, 其中  $s_j = [s_{j1}, s_{j2}, \dots, s_{jN}] \in R^{N \times 1}$  表示第  $j$  个端元在各个像素的丰度,  $\mathbf{E}$  是误差矩阵. 显然  $\mathbf{X}, \mathbf{A}$  和  $\mathbf{S}$  都是非负的.

在将 ICA 方法引入到 HSI 解混中的时候, 首先面临的问题就是选择哪个信号作独立分量. 在现有的研究中, 大部分学者选择了丰度作为独立分量, 先忽略噪声矩阵, 这样在  $\mathbf{X} = \mathbf{A}\mathbf{S}$  中,  $\mathbf{S} = [s_1, s_2, \dots, s_p]^T \in R^{P \times N}$ , 一共有  $P$  个独立分量<sup>[11-12]</sup>, 每个分量都是  $N$  维的, 端元矩阵  $\mathbf{A} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_p] \in R^{L \times P}$  就是  $L \times P$  维的混合矩阵. 虽然大部分学者使用了丰度作为独立分量, 但是在有监督目标探测中, 用 ICA-R 方法作预处理的目的是提取更加准确的目标光谱, 所以应选择端元作为独立分量, 这样就需要对 HSI 数据矩阵  $\mathbf{X} \in R^{L \times N}$  进行转置, 得到

$$\mathbf{X}^T = \mathbf{S}^T \mathbf{A}^T \quad (5)$$

记  $\mathbf{X}_z = \mathbf{X}^T \in R^{N \times L}$ ,  $\mathbf{S}_z = \mathbf{S}^T \in R^{N \times P}$ ,  $\mathbf{A}_z = \mathbf{A}^T \in R^{P \times L}$ , 得到

$$\mathbf{X}_z = \mathbf{S}_z \mathbf{A}_z \quad (6)$$

转置后得到的  $\mathbf{X}_z$  每一行是一个  $L$  维的观察信号,  $\mathbf{A}_z$  每一行是一个  $L$  维的独立分量, 一共  $P$  个独立分量,  $N$  个观察信号, 并且  $P \leq N$ , 满足 ICA 有解的条件,  $\mathbf{S}_z$  就是  $N \times P$  维的混合矩阵.

转置之后, 在像素维上进行降维同时对数据进行白化. 由于观测信号数目是像素点数  $N$ , 往往非常大, 会导致很大的计算量和内存需求, 所以要对转置后的数据进行降维, 降维方法有很多种, 可以选择主成分分析 (Principle Component Analysis, PCA) 方法等. PCA 降维的同时也实现了白化, 达到去相关的目的.

然后, 从光谱库中选择目标的参考光谱并进行一定处理. 根据待探测的物质种类从光谱库选择了光谱后, 要对光谱进行一定的处理, 使参考信号和实际 HSI 的波段数目一致, 且各个波段所对应的波长范围是一致的.

运行 ICA-R 算法, 以光谱库中光谱作为参考信号, 以降维和白化之后的图像作为观测数据, 从图像中分离出与参考信号相关性最大的独立分量, 作为目标实际光谱.

以上完成了预处理的过程, 获得了更加精确的目标光谱. 然后使用经典有监督目标探测方法进行探测, 如 CEM、ACE、AMF 和 GLRT 等, 就能获得更加精确的目标探测结果.

总结所提出的基于 ICA-R 的目标探测的流程为:

步骤 1 将三维的 HSI 整理成二维数据矩阵  $\mathbf{X} \in R^{L \times N}$ ;

步骤 2 对  $\mathbf{X}$  进行转置得到  $\mathbf{X}_z = \mathbf{S}_z \mathbf{A}_z \in R^{N \times L}$ ;

步骤 3 对转置后得到的  $\mathbf{X}_z$  进行 PCA 降维、白化得到  $\mathbf{X}_d$ ;

步骤 4 在实验室光谱库选择合适的参考信号, 并对参考信号进行整理, 将参考光谱记为  $\mathbf{r}$ ;

步骤 5 以  $\mathbf{X}_d$  和  $\mathbf{r}$  作为输入, 利用 ICA-R 方法, 从 HSI 中提取实际目标光谱  $\mathbf{d}$ ;

步骤 6 以  $\mathbf{d}$  和转置之前的数据  $\mathbf{X} \in R^{L \times N}$  作为输入, 使用经典有监督目标探测算法进行探测;

步骤 7 设定阈值, 判断目标在图像中的分布情况.

### 3 实验验证

分别利用仿真和实际数据测试算法的性能. 首先是利用 ICA-R 对目标光谱进行预处理, 然后再利用经典方法进行探测, 在实验中将预处理方法加入

到不同的经典方法中,比较加入前后实验结果的改进,同时证明预处理方法对于经典有监督目标探测算法的有效性和普适性.

仿真和实际数据实验都用到 Cuprite 数据集,该数据集是由机载可见光及红外成像光谱仪(Airborne Visible/Infrared Imaging Spectrometer, AVIRIS)拍摄的美国内华达州 Cuprite 地区的数据(可以从 [http://aviris.jpl.nasa.gov/html/aviris\\_freedata.html](http://aviris.jpl.nasa.gov/html/aviris_freedata.html) 下载),共 224 个波段.区域内主要为裸露的矿物,其中一部分的伪彩色图如图 2 所示.在使用之前,第 1~2,104~113,148~167 以及 221~224 波段由于信噪比过低或者为水吸收波段而被舍弃掉,留下 188 个波段.参考光谱均来自于美国地质调查局(United States Geological Survey, USGS)光谱数据库.

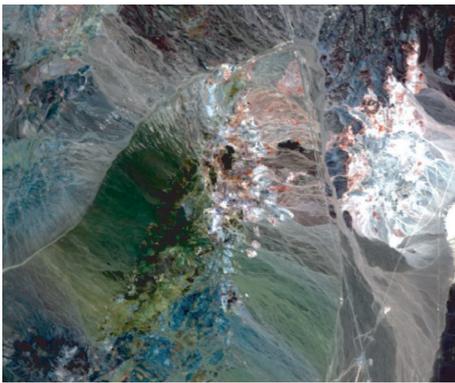


图 2 Cuprite 数据集的 RGB 伪彩色合成图(R、G、B 通道分别为波段 40、20 和 10)<sup>[13]</sup>  
Fig. 2 False-color composite for the Cuprite data set (RGB channels are bands 40, 20, and 10, respectively)<sup>[13]</sup>

可探最低丰度是指可被探测出来的目标点中目标的最低丰度,也即像素中目标丰度低于此值时无法被探测出来.虚警率(False Alarm Rate, FAR)是指所有探测结果标记出的目标点中,非真实目标点所占比例.可探率(Probability of Detection, Pd)是指被正确探测出的目标点占有所有目标点的比例. FAR 和 Pd 的计算公式表示为

$$FAR = \frac{N_{miss}}{N_{td}}, Pd = \frac{N_{hit}}{N_t}, \quad (7)$$

其中  $N_{miss}$  表示被误标记为目标点的背景点数目,  $N_{td}$  表示探测结果标记出的目标点数目,  $N_t$  表示图像中所有目标点的数目,  $N_{hit}$  表示在某一阈值下所有成功探测出的目标点的数目.

仿真实验的结果列出了当 FAR 为 0 时,各个算

法的可探丰度和 Pd,同时也画出了 ROC (Receiver Operating Characteristic) 曲线.在 ROC 曲线中, FAR 相同时, Pd 越高的算法效果越好<sup>[14]</sup>.

所有实验的软硬件环境为 Intel(R) Core™ i7-2600 CPU 3.40 GHz, 16 GB 内存和 Windows 7 及 Matlab R2011b.

### 3.1 仿真数据实验

人工产生仿真数据用于测试算法的性能.在评价算法效果的时候,首先给出目标探测算法的输出结果图,可以直观地从目视上感受算法效果的提升,然后给出量化的评价指标.

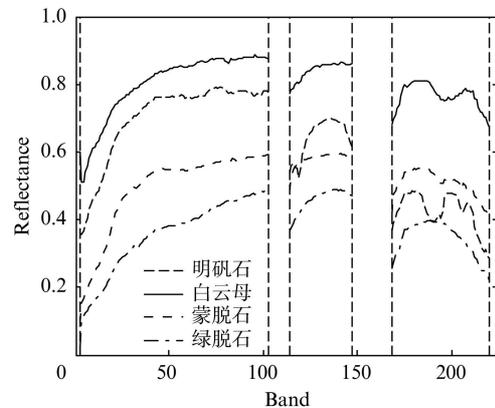


图 3 四种合成仿真数据的端元光谱  
Fig. 3 Four endmember spectra used for synthetic data

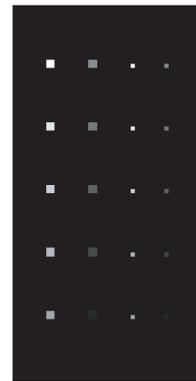


图 4 目标矿物明矾石的丰度图  
Fig. 4 Abundance map of alunite

仿真数据的产生方式:首先,由实际的 Cuprite 数据,通过广泛使用的端元提取算法 VCA<sup>[15]</sup> 提取得到端元光谱,根据已有的对该数据的研究,设置端元数目为 12,选取其中的 4 个作为仿真数据的端元,排列成端元矩阵  $A = [a_1, a_2, a_3, a_4] \in R^{188 \times 4}$ .各端元光谱如图 3 所示;然后,分别设定四种端元在  $90 \times 45$  的图像(总共  $N = 90 \times 45 = 4050$  个像素点)

中每个像素的丰度. 选取其中的明矾石作为探测目标, 其丰度分布如图 4 所示, 左边两排为  $2 \times 2$  的目标, 右边两排为  $1 \times 1$  的目标, 每类目标的丰度值由 1 递减到 0.1, 步长为 0.1. 其余三种矿物作为背景矿物, 它们的丰度用函数随机生成 0 到 1 之间的数字. 然后把这四种矿物在每个像素中的丰度和归一化, 得到丰度矩阵  $S = [s_1, s_2, s_3, s_4]^T \in R^{4 \times 4050}$ ; 最后, 根据指定的信噪比产生高斯白噪声矩阵  $E \in R^{188 \times 4050}$ , 按线型混合模型  $X = AS + E$  得到仿真图像. 实验中信噪比为 30 分贝. 另外, 参考光谱选取自 USGS 矿物光谱库, 同样去除低信噪比和水吸收波段, 保留 188 个波段.

在所有实验中, ICA-R 算法统一的参数设定为权值矩阵  $W$  随机初始化之后归一化; 学习率  $\eta = 0.95$ ; 衡量参考信号与输出信号误差的阈值  $\xi_i = 1.75$ ; 最大迭代次数设置为 200, 迭代误差小于  $10^{-6}$  时停止迭代.

USGS 库中, 同一种矿物在不同的实验条件下测得了多个光谱, 即“同物异谱”. 明矾石有六种不同的光谱, 有的光谱与选定的 HSI 中的实际光谱差异大, 直接用于目标探测时效果就很差; 有的差异小, 用于目标探测时结果就比较准确. 文中所提的预处理方法, 无论从光谱库中选择的光谱与实际差异大或小, 均能在原有精度上有所提高.

### 3.1.1 直观比较加入预处理前后的目标探测效果

目标探测方法选择 CEM. 首先, 参考光谱选择 Alunite\_GDS84, 探测结果见图 5. 可以看出 Alunite\_GDS84 与实际光谱差异较小, 直接用于目标探测结果的精度已经较高. 加入了 ICA-R 的预处理方法后, 精度也有提升, 如图 5(b) 所示, 可以探测出的目标点数目增加.

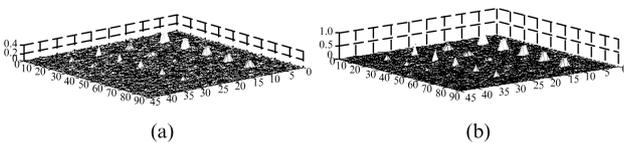


图 5 仿真数据选择明矾石 Alunite\_GDS84 的目标探测结果 (a) CEM, (b) ICA-R + CEM  
Fig. 5 Alunite\_GDS84 target detection results of synthetic data (a) CEM, (b) ICA-R + CEM

然后, 参考光谱选择 Alunite\_SUSTDA, 探测结果见图 6. 可以看出, 由于 Alunite\_SUSTDA 与图像中的明矾石光谱差异过大, 直接用于目标探测时基本无法得出准确的探测结果. 然后, 使用了文中所提的预处理方法, 探测效果明显提升, 仅个别点无法探

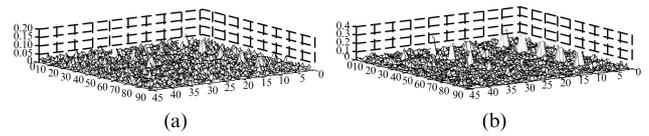


图 6 仿真数据选择明矾石 Alunite\_SUSTDA 的目标探测结果 (a) CEM, (b) ICA-R + CEM  
Fig. 6 Alunite\_SUSTDA target detection results of synthetic data (a) CEM, (b) ICA-R + CEM

测出来, 并且很好地降低了背景噪声的幅度.

综合上面两个实验, 可以看出所提出的预处理方法对于参考光谱的精度具有鲁棒性, 对“同物异谱”的参考信号, 能使目标探测的精度保持稳定.

为了进一步证明, 加入预处理后探测精度的提高是因为预处理得到的目标光谱  $\mathbf{d}$  比参考光谱  $\mathbf{r}$  更加准确, 分别计算了二者与实际目标光谱之间的均方误差和光谱角距离. 均方误差 (Mean Square Error, MSE) 和光谱角距离 (Spectral Angle Distance, SAD) 的计算公式如式 (8) 所示

$$MSE = \frac{\sum_{i=1}^L (a_i - \hat{a}_i)^2}{L}, SAD = \arccos \frac{\mathbf{a}^T \cdot \hat{\mathbf{a}}}{\|\mathbf{a}\| \cdot \|\hat{\mathbf{a}}\|} \quad (8)$$

根据公式得出 MSE 越接近 0 越好, SAD 越接近 1 越好. 计算得到的两组指标如表 1 所示.

表 1 参考光谱与实际光谱、提取光谱与实际光谱的 MSE、SAD 指标

Table 1 MSE and SAD values between reference spectrum and real spectrum and between extracted spectrum and real spectrum

各光谱与实际目标光谱的误差指标	MSE	SAD
参考光谱 Alunite_GDS84	0.006 023	0.997 108
相应提取出的目标光谱	<b>0.005 244</b>	<b>0.997 999</b>
参考光谱 Alunite_SUSTDA	0.030 584	0.995 595
相应提取出的目标光谱	<b>0.028 892</b>	<b>0.997 280</b>

由表中可以看出, 预处理后得到的目标光谱比参考光谱更接近于实际光谱.

### 3.1.2 绘制 ROC 曲线

目标探测方法分别选择 CEM、ACE、AMF 和 GLRT, 参考光谱选择 Alunite\_GDS84. 绘制 ROC 曲线, 如图 7 所示. 可以看出, 加入了 ICA-R 后的目标探测的曲线明显高于经典方法的曲线. 同时, 图 7 说明了提出的预处理方法对于这四种经典的有监督的目标探测算法具有很好的普适性.

### 3.1.3 改变阈值, 研究 FAR = 0 时的最低可探丰度以及 Pd

目标探测方法分别选择 CEM、ACE、AMF 和

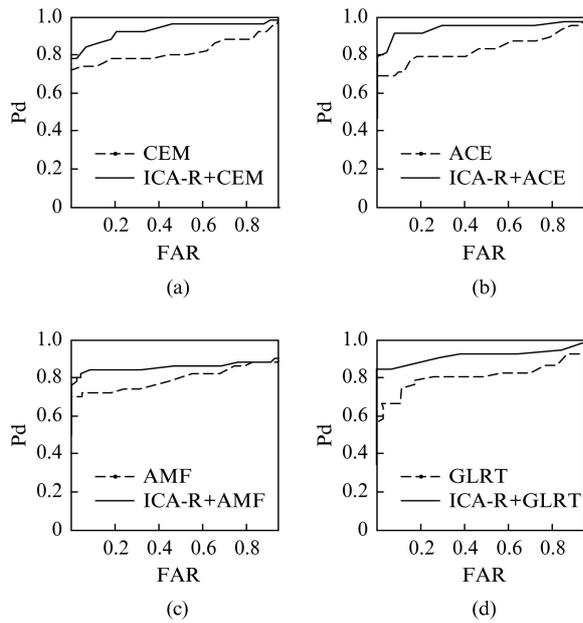


图7 ROC 曲线(a) CEM, (b) ACE, (c) AMF, (d) GLRT  
Fig.7 ROC curves (a) CEM, (b) ACE, (c) AMF, (d) GLRT

GLRT,参考光谱选择 Alunite\_GDS84. 实验中,需要逐步改变阈值,计算 FAR,直到 FAR = 0 时停止,计算最低可探丰度以及 Pd. 为了探索准确的可探丰度,还对数据中目标的丰度值进行了细化,丰度值分别为 0.050、0.100、0.125、0.150、0.175、0.200、0.250、0.275、0.300、0.325、0.350、0.375、0.400、0.450、0.500. 探测结果如表 2 所示. 可以看出,基于 ICA-R 的有监督目标探测算法的 Pd 升高,并且可以探测的最低丰度减小,这都说明了目标探测能力的提高.

表 2 仿真数据实验 FAR = 0 时的 Pd 和可探丰度值  
Table 2 Pds and least abundance values when FAR = 0

算法	CEM	ICA-R + CEM	ACE	ICA-R + ACE	AMF	ICA-R + AMF	GLRT	ICA-R + GLRT
可探丰度	0.175	<b>0.100</b>	0.200	<b>0.150</b>	0.175	<b>0.125</b>	0.175	<b>0.150</b>
可探率	74%	<b>92%</b>	70%	<b>84%</b>	74%	<b>90%</b>	72%	<b>84%</b>

### 3.2 真实数据实验

使用真实 Cuprite 数据对所提出算法的性能进行测试. 测试方法是在实际的数据中某些特定位置埋入目标矿物,使得背景是真实的高光谱数据,目标是背景光谱和目标光谱的混合像素,这样处理易于检验探测结果的正确性. 在 Cuprite 数据集中截取了一块不存在明矾石或者明矾石丰度很低的区域,大小为 90 × 45. 以此作为背景,在图像中埋入 15 个 1 × 1 的目标像素点,明矾石的光谱利用

OBA 端元提取算法从实际 Cuprite 数据集中提取得到,各目标点丰度值如表 3 所示.

表 3 实际 Cuprite 数据中各目标点的丰度值  
Table 3 Abundance values of target pixels in real Cuprite data

目标点丰度值	第一列	第二列	第三列
第一排	0.500	0.325	0.175
第二排	0.450	0.300	0.150
第三排	0.400	0.275	0.125
第四排	0.375	0.250	0.100
第五排	0.350	0.200	0.050

#### 3.2.1 直观比较加入预处理前后的目标探测效果

目标探测方法选择 CEM. 首先,参考光谱选择 Alunite\_GDS84,结果见图 8. 可以看出,未加入预处理时,背景幅度较大,造成较高的 FAR;加入 ICA-R 预处理后,背景被很好地抑制,并且可探测的目标点数多两个,FAR 大大降低.

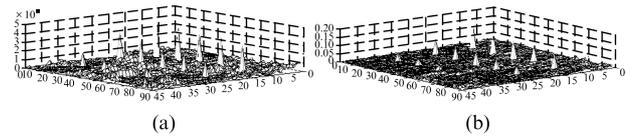


图 8 实际 Cuprite 数据选择明矾石 Alunite\_GDS84 的目标探测结果(a) CEM,(b) ICA-R + CEM  
Fig.8 Alunite\_GDS84 target detection results of real Cuprite data (a) CEM, (b) ICA-R + CEM

然后,参考光谱选择 Alunite\_SUSTDA,结果如图 9 所示. 可以看到,未加入预处理时,可探测出的目标像素点很少,并且背景的干扰非常大;加入 ICA-R 之后,背景被很好地抑制,绝大部分目标像素可以被正确地检测出来.

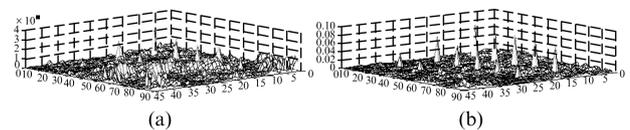


图 9 实际 Cuprite 数据选择明矾石 Alunite\_SUSTDA 的目标探测结果(a) CEM,(b) ICA-R + CEM  
Fig.9 Alunite\_SUSTDA target detection results of real Cuprite data (a) CEM, (b) ICA-R + CEM

为了更加直观地显示目标探测精度的提高,加阈值来说明,如图 10 所示,选取阈值使各种方法下的输出效果最佳. 可以看出,所提出的预处理方法能提高目标探测的精度,并且对目标光谱的精度具有一定的鲁棒性.

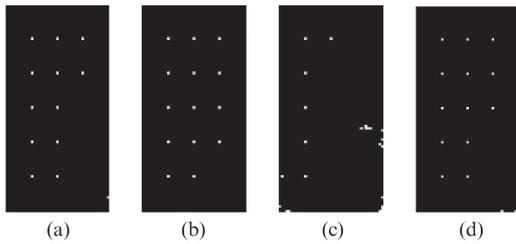


图 10 实际数据实验加阈值后的探测结果 (a) CEM (Alunite\_GDS84), (b) ICA-R + CEM (Alunite\_GDS84), (c) CEM (Alunite\_SUSTDA), (d) ICA-R + CEM (Alunite\_SUSTDA)

Fig. 10 Target detection results with threshold for real Cuprite data, (a) CEM (Alunite\_GDS84), (b) ICA-R + CEM (Alunite\_GDS84), (c) CEM (Alunite\_SUSTDA), (d) ICA-R + CEM (Alunite\_SUSTDA)

### 3.2.2 绘制 ROC 曲线

目标探测方法选择 CEM, 参考光谱选择 Alunite\_GDS84. 采用与仿真数据实验相同的方法, 阈值的变化区间和步长也均相同, 绘制 ROC 曲线, 如图 11 所示. 可以看出, 文中提出的基于 ICA-R 的方法在实际数据中目标探测的精度好于经典的算法.

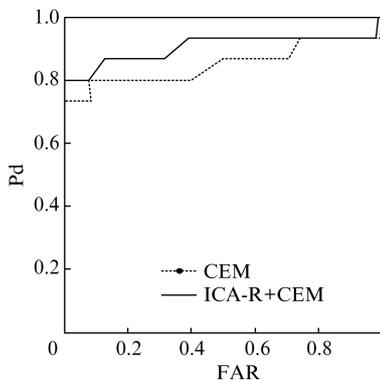


图 11 实际数据实验 ROC 曲线  
Fig. 11 ROC curve of real data test

## 4 结论

提出了一种适用于高光谱图像目标探测的预处理方法. 由于经典的有监督目标探测方法对于目标光谱的准确性非常敏感, 当目标光谱准确性较差时, 无法得出准确的目标探测结果. 针对这一问题, 通过利用实验室得到的目标光谱作为参考信号, 从图像中提取与参考信号最接近的独立分量作为实际的目标光谱, 然后进行有监督的目标探测. 仿真和实际高光谱数据实验表明, 所提出的预处理方法可以适用

于经典的有监督目标探测算法, 如 CEM、ACE、AMF 和 GLRT, 加入这种预处理方法后, 目标探测的精度有较大提高, 并且对目标光谱的精度具有较好的鲁棒性.

## References

- [1] Chang C. -I. *Hyperspectral imaging: techniques for spectral detection and classification* [M]. New York: Plenum, 2003.
- [2] Chang C. -I, Heinz D C, Constrained subpixel target detection for remotely sensed imagery [J]. *IEEE Trans. on Geosci. Remote Sens.*, May 2000, **38**(3): 1144 - 1159.
- [3] Zhang B, Gao L R. *Hyperspectral image classification and target detection* [M]. (张兵, 高连如. 高光谱图像分类与目标探测), Beijing: Science Press. 2011: 245.
- [4] Harsanyi J C. Detection and classification of subpixel spectral signatures in hyperspectral image sequences [R]. Ph. D. dissertation, Dept. Elect. Eng., Univ. Maryland, Baltimore County, 1993.
- [5] Kraut S, Scharf L L. The CFAR adaptive subspace detector is a scale-invariant GLRT [J]. *IEEE Trans. on Signal Processing*, 1999, **47**(9): 2538 - 2541.
- [6] Robey F C, Fuhrmann D R, Kelly E J, et al, A CFAR adaptive matched filter detector [J]. *IEEE Trans. on Aerosp. Electron. Syst.*, 1992, **28**(1): 208 - 216.
- [7] Kelly E J. An detection adaptive algorithm [J]. *IEEE Trans. on Aerosp. Electron. Syst.*, 1986, **AES-22**(1): 115 - 127.
- [8] Hyvarinen A, Oja E, Independent component analysis: algorithms and applications [J]. *Neural Networks*, 2000, **13**: 411 - 430.
- [9] Lu W, Rajapakse J C. Approach and applications of constrained ICA [J]. *IEEE Trans. on Neural Networks*, 2005, **16**(1): 203 - 212.
- [10] Lillesand T M, Kiefer R W. *Remote sensing and image interpretation*, 4<sup>th</sup> ed [M]. New York: John Wiley & Sons, Inc., 2000.
- [11] Tu T M. Unsupervised signature extraction and separation in hyperspectral images: A noise-adjusted fast independent component analysis approach [J]. *Optical Engineering*, 2000, **39**(4): 897 - 906.
- [12] Wang J, Chang C. -I. Applications of independent component analysis in endmember extraction and abundance quantification for hyperspectral imagery [J]. *IEEE Trans. on Geosci. and Remote Sens.*, 2006, **44**(9): 2601 - 2616.
- [13] Heylen R, Burazerovic D, Scheunders P. Fully constrained least squares spectral unmixing by simplex projection [J]. *IEEE Trans. on Geosci. and Remote Sens.*, 2011, **49**(11): 4112 - 4122.
- [14] Wang T, Du B, Zhang L. A kernel-based target-constrained interference-minimized filter for hyperspectral sub-pixel target detection [J]. *IEEE Jour. of Selected Topics in applied earth observations and remote sensing*, 2013, **6**(2): 626 - 637.
- [15] Nascimento J M P, Dias J M B. Vertex component analysis: A fast algorithm to unmix hyperspectral data [J]. *IEEE Trans. on Geosci. and Remote Sens.*, 2005, **43**(4): 898 - 910.