

# 面向目标检测基于稀疏表示的波段选择方法

唐意东, 黄树彩, 薛爱军

(空军工程大学防空反导学院, 陕西西安 710051)

**摘要:** 随着高光谱成像技术的发展, 日益提高的光谱分辨率在提高目标检测和识别能力的同时, 其较高的数据维度和较大的数据量也为数据分析和处理带来了很大的挑战. 波段选择作为一种有效提高处理效率的技术受到广泛关注, 但却鲜有专门针对目标检测设计的方法. 针对上述问题, 本文在分析约束能量最小化(CEM)检测算法特点的基础上, 提出了一种面向目标检测, 基于稀疏表示的波段选择方法. 该方法首先基于数据的对称 KL 散度分布情况, 将原始高光谱数据划分为若干波段子空间. 然后在各子空间内稀疏重构检测结果, 利用选择波段与稀疏向量非零项的一一对应关系, 通过求解最优化问题实现波段选择. 实验结果验证了该方法的有效性.

**关键词:** 波段选择; 高光谱图像; 稀疏表示; 目标检测; 子空间划分

**中图分类号:** TP751.1      **文献标识码:** A      **文章编号:** 0372-2112 (2017)10-2368-07

**电子学报 URL:** <http://www.ejournal.org.cn>      **DOI:** 10.3969/j.issn.0372-2112.2017.10.009

## Sparse Representation Based Band Selection for Hyperspectral Imagery Target Detection

TANG Yi-dong, HUANG Shu-cai, XUE Ai-jun

(Air and Missile Defense College, Air Force Engineering University, Xi'an, Shaanxi 710051, China)

**Abstract:** With the development of hyperspectral imaging technology, the raising spectral resolution improves the ability of target detection and classification. But its great data size and high data dimension also bring challenge to analysis and processing. As a dimensionality reduction technology, band selection (BS) plays an important role in the pre-processing of hyperspectral imagery (HSI). However, few BS algorithms are specially designed for target detection. In this paper, based on analyzing the character of constrained energy minimization (CEM) algorithm, a sparse representation based band selection method (TD-SRBBS) is proposed for HSI target detection. The symmetric Kullback-Leibler divergence is defined for subspatial partition, which makes the original HSI dataset some subset. Sparse reconstruct the detection result in each subset, and then band selection can be implemented based on the one-to-one correspondence between selected bands and nonzero elements of sparse vector. The experiments on real hyperspectral data demonstrate the effectiveness of TD-SRBBS.

**Key words:** band selection; hyperspectral imagery; sparse representation; target detection; subspatial partition

### 1 引言

高光谱图像能够提供上百个波段信息, 具有光谱连续, 分辨率高的特点<sup>[1]</sup>, 其数据结构如图 1 所示. 高分辨率在提高探测能力的同时, 也带来了一系列问题. 首先, 高分辨率导致数据维数高且相邻波段相关性高, 存在大量信息冗余. 另外, 高分辨率带来的庞大数据量为其分析和处理带来了极大挑战<sup>[2]</sup>. 因此, 降维成为高光

谱图像处理的重要步骤, 常用的降维方法包括波段选择和基于变换的方法两类<sup>[2,3]</sup>.

近年来, 波段选择作为一种有效的降维方法受到广泛关注. 与基于变换的降维方法相比, 波段选择最大的优点是其直接从原始数据中选择波段子集, 能够保留数据的光谱信息和物理意义. 基于稀疏表示的分类方法的关键在于利用训练样本近似线性表示待测像元的光谱, 因此保留数据的光谱信息显得尤为重要. 事实

上,高光谱图像的意义不仅在于具备丰富的波段信息,更重要的是其提供了构造大量不同波段子集的可能性.这使得当缺乏特征波段和目标分布等先验信息时,针对不同数据集总能选出相应的波段子集以保证其应用精度,也正是这种性质保证了波段选择的可行性.




图1 高光谱数据结构

波段选择旨在不明显降低应用精度的同时,去除高光谱图像中的冗余波段,具体可分为有/无监督两种.有监督方法需要事先采集地物数据作为训练样本<sup>[4]</sup>,通过训练学习进行波段选择. BSUMI<sup>[5,6]</sup>计算各波段与参考图的互信息,选择其中数值较大的波段.此时,无论参考图是事先给定还是估计得到,都需要大量先验信息.无监督方法一般基于波段自身信息量和波段间相关性实现波段选择<sup>[2,7-9]</sup>,选出信息量较大,且相关性弱的波段子集. BandClust<sup>[10]</sup>采用贪婪算法计算每一种聚类结果的互信息,基于最小化互信息选择可分性强的波段子集,计算量较大.文献[11]提出两种基于层次聚类的波段选择方法, WaLuMI 和 WaLuDi,分别以互信息和 KL 散度作为波段相异性度量,在光谱维上进行层次聚类,选择与其余各波段相关性最强的波段作为各聚类的代表性波段.聚类方法目的是选择尽可能不同的波段,关注的是波段间的相异性,忽略了波段本身的信息量大小.文献[7]以波段对整个数据集的信息量贡献为评价准则,逐个剔除贡献小的波段,但由于评价指标相对波段的连续性,使得最终选择的波段可能集中在某些连续子空间. LPPBS<sup>[12]</sup>利用已选波段预测余下波段,选择预测误差最大的波段,最后得到波段相似度最低的波段子集,其投影矩阵规模很大,不利于全局处理.因此只能随机选择部分像元进行波段相似性度量,而这势必会影响波段选择的结果. SpaBS<sup>[13]</sup>基于稀疏表示和 K-SVD 算法将光谱数据分解为字典矩阵和系数矩阵,通过系数矩阵直方图分析进行波段选择.

上述波段选择方法,不管是有监督还是无监督,多是针对分类提出的,目的是将高光谱图像中的各类物质一一区分开.监督方法将与分类相关的准则融入到波段选择<sup>[14-16]</sup>,而无监督方法则直接利用分类准确性

来衡量波段选择的好坏<sup>[11,12,17]</sup>.尽管目标检测和分类都是高光谱图像重要的应用方向,针对目标检测设计的波段选择方法却相对较少<sup>[18]</sup>.文献[19~21]仅机械地将检测性能的评判纳入波段选择过程,其循环过程使得运算变得十分冗杂.本文在波段子空间划分的基础上,提出了一种面向目标检测基于稀疏表示的波段选择方法 TD-SRBBS.其理论基础在于,从能量输出的角度看,波段越多,CEM 算子的能量输出目标函数越小,检测效果越好<sup>[22]</sup>.TD-SRBBS 将 CEM 检测结果看作各波段图像的线性组合,通过对全波段检测结果的稀疏重构实现波段选择,将波段选择和目标检测有机关联,在数据降维的同时保证检测性能.

## 2 面向目标检测的 TD-SRBBS

### 2.1 波段子空间划分

高光谱图像各波段间存在较强的相关性,特别是相邻波段,且这种谱间相关性比空间相关性要强得多<sup>[23]</sup>.在许多基于信息量的无监督波段选择方法中,由于评价指标相对波段的连续性,容易导致选择的波段集中在少数连续子空间,造成信息的重复使用.只有选择的波段本身信息量大,相互间的相关性弱,才能获得更大的累积信息量.另外,由于高光谱图像数据在光谱空间的全局统计特性与局部特性存在差异,在全空间进行波段选择并非最佳.因此,需要在波段选择前对高光谱数据进行波段子空间划分.

张焯<sup>[23]</sup>等提出了一种自适应子空间分解方法,通过设定相关系数阈值将原始数据划分为若干具有不同维度的波段子空间,使得各子空间内的波段具有强相关性,但其并没有明确设定阈值的原则. KL 散度是一种在信息论中广泛应用的信号相似性度量,物理意义为两个信号的信息量之差,其值越大说明两信号越不相似,因此可将其理解为概率意义上的距离.本文采用对称 KL 散度作为波段相似性度量,将其用于波段子空间划分可以有效去除高光谱数据的冗余信息.在空间  $\Omega$  中定义两个随机变量  $B_i$  和  $B_j$ ,分别代表高光谱图像波段  $i$  和波段  $j$  的图像信息,假设  $p_i(b)$  和  $p_j(b)$  分别为  $B_i$  和  $B_j$  的概率密度函数,则两个随机变量的对称 KL 散度定义为:

$$D_{KL}(B_i, B_j) = \sum_{b \in \Omega} p_i(b) \log \frac{p_i(b)}{p_j(b)} + \sum_{b \in \Omega} p_j(b) \log \frac{p_j(b)}{p_i(b)} \quad (1)$$

实际上,本文将单波段像素值平均划分为 32 个区间,采用直方图估计的方法计算概率密度函数.得到对称 KL 散度分布之后,计算其梯度,以梯度变化剧烈的波段为节点,将高光谱数据划分为若干波段子空间.波

段子空间划分完成后,波段选择将在各子空间内完成.各子空间内的波段信息量相近,且一般维数不同,按照一定比例在各子空间内选择波段,并保证在每个子空间内至少选出一个波段.

## 2.2 TD-SRBBS 模型

CEM 是一种应用广泛的目标检测方法,从能量输出角度看,高光谱数据波段越多,其检测性能越好<sup>[22]</sup>.也就是说,全波段的检测效果最好,去除任何波段都会增大 CEM 算子的能量输出. TD-SRBBS 就是研究如何选择波段子集,使得该波段子集下的检测结果与全波段检测结果之间的差异最小. TD-SRBBS 并不是简单地重复波段选择—检测—波段选择<sup>[20]</sup>的过程,而是在 CEM 检测框架下,通过对全波段检测结果的稀疏重构实现波段选择,在数据降维的同时保证检测性能.

给定一个  $L$  波段包含  $N$  个像元的高光谱数据  $\mathbf{X}_{N \times L} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_L]$ , 其中  $\mathbf{x}_j$  代表波段  $j$ . CEM 检测的目的是设计一个线性滤波器,在抑制背景输出的同时保证目标能量输出. 假设目标光谱向量为  $\mathbf{d}$ , 则 CEM 的检测输出为:

$$\mathbf{y}_{N \times 1} = \mathbf{X}\mathbf{w} = \mathbf{X} \left( \frac{\mathbf{R}^{-1}\mathbf{d}}{\mathbf{d}^T \mathbf{R}^{-1}\mathbf{d}} \right) \quad (2)$$

其中,  $\mathbf{w} = \frac{\mathbf{R}^{-1}\mathbf{d}}{\mathbf{d}^T \mathbf{R}^{-1}\mathbf{d}}$  称为 CEM 检测算子,  $\mathbf{R} = (1/N) \mathbf{X}^T \mathbf{X}$  为高光谱数据的自相关矩阵.

由式(2)知,可将 CEM 的检测结果看作高光谱图像各波段的线性组合,而 CEM 检测算子则为该线性组合的系数向量. 假设从全部  $L$  个波段中选择  $n$  个波段,波段序列记作  $S = \{s_1, s_2, \dots, s_n\}$ , 对应的数据子集为  $\hat{\mathbf{X}}_{N \times n}$ . 此时,CEM 检测结果为:

$$\hat{\mathbf{y}}_{N \times 1} = \hat{\mathbf{X}}\hat{\mathbf{w}} = \sum_{j=1}^n \hat{\omega}_j \mathbf{x}_{s_j} \quad (3)$$

其中,  $\hat{\mathbf{w}} = (\hat{\omega}_1, \hat{\omega}_2, \dots, \hat{\omega}_n)$  为相应的 CEM 检测算子. TD-SRBBS 研究的是如何选择波段子集,使得其检测结果与全波段检测结果相近. 定义两者检测结果的差异为:

$$f(\hat{\mathbf{w}}) = \|\mathbf{y} - \hat{\mathbf{y}}\|_2^2 = \|\mathbf{y} - \sum_{j=1}^n \hat{\omega}_j \mathbf{x}_{s_j}\|_2^2 \quad (4)$$

其中,  $\mathbf{y}$  和  $\hat{\mathbf{y}}$  分别为全波段和波段选择后的 CEM 检测结果.

由式(3)知,波段选择后的检测结果为波段子集  $B = \{s_1, s_2, \dots, s_n\}$  的线性组合. 但仍可将其看作全波段的线性组合,只是除  $\{s_1, s_2, \dots, s_n\}$  以外的  $L - n$  个波段对应的系数为 0. 因此,式(4)可以改写为:

$$\begin{aligned} f(\hat{\mathbf{w}}) &= \|\mathbf{y} - \hat{\mathbf{y}}\|_2^2 = \|\mathbf{y} - \sum_{j=1}^L \omega_j \mathbf{x}_j\|_2^2, \\ \text{s. t. } \quad &\|\mathbf{w}\|_0 = n \end{aligned} \quad (5)$$

当选择波段数  $n$  确定后,波段选择问题可以描述为稀疏度约束下的近似误差最小化问题.

$$\mathbf{w} = \operatorname{argmin} \|\mathbf{y} - \mathbf{X}\mathbf{w}\|_2^2, \quad \text{s. t. } w_0 \leq n \quad (6)$$

其中,  $\|\mathbf{w}\|_0$  为  $\mathbf{w}$  的  $L_0$  范数,表示系数向量中非零元素的个数,即选择波段数,而  $\mathbf{w}$  的非零项序号则对应所选波段序列.

## 2.3 模型求解

直接求解最优化问题(6),需要筛选出向量  $\mathbf{w}$  中所有可能的非零元素,是一个 NP 难问题. 可以利用  $L_1$  范数代替  $L_0$  范数,将其转变为凸松弛的  $L_1$  范数最优化问题,也可以利用贪婪算法 (greedy algorithm, GA) 近似求解. OMP 算法是一种最常用的 GA,其在每一步迭代中选择一原子,直到满足终止条件. 由于 TD-SRBBS 选出的波段与  $\mathbf{w}$  的非零元素一一对应,因此采用 OMP 方法求解最优化问题(6)能够将波段选择问题直观地转变为稀疏向量  $\mathbf{w}$  的求解. 采用 OMP 算法的另一好处是,可以通过设置稀疏度直接控制选择波段数目,OMP 算法的流程如表 1 所示. 随后,在选择的波段子集上进行 CEM 检测,以评价波段选择方法的性能.

表 1 OMP 算法流程

输入	矩阵 $\mathbf{X}$ , 向量 $\mathbf{y}$ , 稀疏度 $n$ .
初始化	$k=0, \mathbf{w}^0 = \mathbf{0}, \mathbf{r}^0 = \mathbf{y} - \mathbf{X}\mathbf{w}^0 = \mathbf{y}$ , 支撑集 $\mathbf{I}^0 = \operatorname{Support}\{\mathbf{w}^0\} = \emptyset$
循环	while $k \leq n$ , 令 $k \leftarrow k + 1$ , do
步骤 1	更新支撑集 $\mathbf{I}^k$ 求矩阵 $\hat{\mathbf{X}}$ 中与残差 $\mathbf{r}^{k-1}$ 最强相关列 $j_k \in \operatorname{argmax}_j  \langle \mathbf{r}^{k-1}, \mathbf{x}_j \rangle $ , $\mathbf{I}^k = \mathbf{I}^{k-1} \cup \{j_k\}$
步骤 2	估计 $\mathbf{w}^k$ 求解最小化问题 $\min_{\mathbf{w}^k} \ \mathbf{y} - \mathbf{X}_{\mathbf{I}^k} \mathbf{w}^k\ _2$ , 其中 $\mathbf{X}_{\mathbf{I}^k} = [\mathbf{x}_{\tau^1}, \dots, \mathbf{x}_{\tau^k}], \tau^1, \dots, \tau^k \in \mathbf{I}^k$ .
步骤 3	更新残差 $\mathbf{r}^k = \mathbf{y} - \mathbf{X}_{\mathbf{I}^k} \mathbf{w}^k$
end	
输出	$\mathbf{w}(i) = \begin{cases} \mathbf{w}^k(i), & i \in \mathbf{I}^k \\ 0, & \text{其他} \end{cases}$

## 3 实验分析

本文将 TD-SRBBS 应用到两组真实的高光谱数据上,并与 LPPBS, BandClust, WaLuMI 和 BSUMI 等方法进行比较,以验证算法的有效性. ROC (Receiver Operating Characteristic) 曲线常用于描述检测概率和虚警概率的关系,能够提供检测性能的定量分析. 尽管 TD-SRBBS 的理论基础并非从 ROC 性能角度得出,但其服务于目标检测,因此本文采用 ROC 曲线下面积 (Area Under Curve, AUC) 作为评价指标以定量比较上述波段选择方法.

### 3.1 实验 1

实验数据为 AVIRIS Indiana Pines, 大小为  $145 \times 145$ , 空间分辨率为 20m, 波长范围为  $0.2 \sim 2.4 \mu\text{m}$ , 共包含 220 个波段,其假彩色图如图 2(a) 所示. 标定的地物真实共 16 类,包括玉米、大豆、小麦等农作物,草地、树

木等天然植被和一个无线电发射塔. 其中无线电发射塔所占像素数相对较少, 光谱与其余各类地物差异较大, 因此将其作为待检测目标, 其真实分布如图 2(b) 所示. 去掉信噪比低和受水汽吸收影响较大的 20 个波段 (104 ~ 108, 150 ~ 163, 220), 最终得到 200 个波段的高光谱图像.




图2 高光谱数据结构

Indiana Pines 的对称 KL 散度分布如图 3 所示, 根据其梯度变化情况将原始数据划分为 5 个波段子空间





图3 Indiana Pines 对称 KL 散度分布

用上述方法分别选择 9, 15, 21, 40, 60 个波段用于目标检测, 检测结果如图 5 所示. 可以看出, 随着波段数的增加, 各方法获得的检测效果都得到改善; 当选择波段数足够大时, 各种方法都能比较明显地将目标区分出来. 总的看来, TD-SRBBS 的检测效果更加理想可靠, 仅在图像顶部存在少量虚警 (同为钢制品的铁路). LaWuMI 能够获得与 TD-SRBBS 相近的检测效果, 而另外三种方法的检测效果则有限. 特别是当选择波段数较少时, 如当  $n=9$  时, TD-SRBBS 选择的波段能够有效地区分目标和背景, LPPBS 区分效果不明显且存在大量虚警, 而 BandClust 和 BSUMI 甚至完全不能分辨出目标.

### 3.2 实验 2

实验数据为 University of Pavia, 空间分辨率为 1.3m, 共 115 个波段, 波长范围为  $0.43 \sim 0.86 \mu\text{m}$ . 从中截取大小为  $300 \times 200$  的图像, 去掉信噪比较低的 12 个波段, 得到 103 个波段的高光谱图像, 其假彩色图如图 6(a) 所示. 地面真实包含树木、草地和沥青路面等 9 种

(1 ~ 35, 36 ~ 75, 76 ~ 105, 106 ~ 145, 146 ~ 200). 给定不同选择波段数, 结合子空间划分情况, 分别运用 LPPBS, BandClust, WaLuMI, BSUMI 和 TD-SRBBS 方法进行波段选择. 其中, LPPBS 随机选择 10% 的像元进行波段相似性度量, BSUMI 利用波段 151 ~ 191 的均值图像作为参考图像. 在波段选择的基础上进行 CEM 检测, AUC 值与选择波段数的关系如图 4(a) 所示, 可以看出, 当波段数少 ( $n < 30$ ) 时, 各种波段选择方法获得的检测性能都随波段数增加而明显改善; 而当波段数达到一定值后, 各种方法的 AUC 值均保持相对稳定的水平. 同时可以看出, 绝大多数情况下, TD-SRBBS 都能获得较其它方法更好的检测效果, 特别是波段数较少时, 这种优势更加明显. 当波段数为 11 时, 各种波段选择方法对应的 ROC 曲线如图 4(b) 所示, 可以看出, BandClust 和 BSUMI 的检测效果较差. 当虚警概率一定时, TD-SRBBS 几乎总能够获得较其它方法更高的检测概率, 仅在 0.0006 ~ 0.016 区间内逊色于 LPPBS.



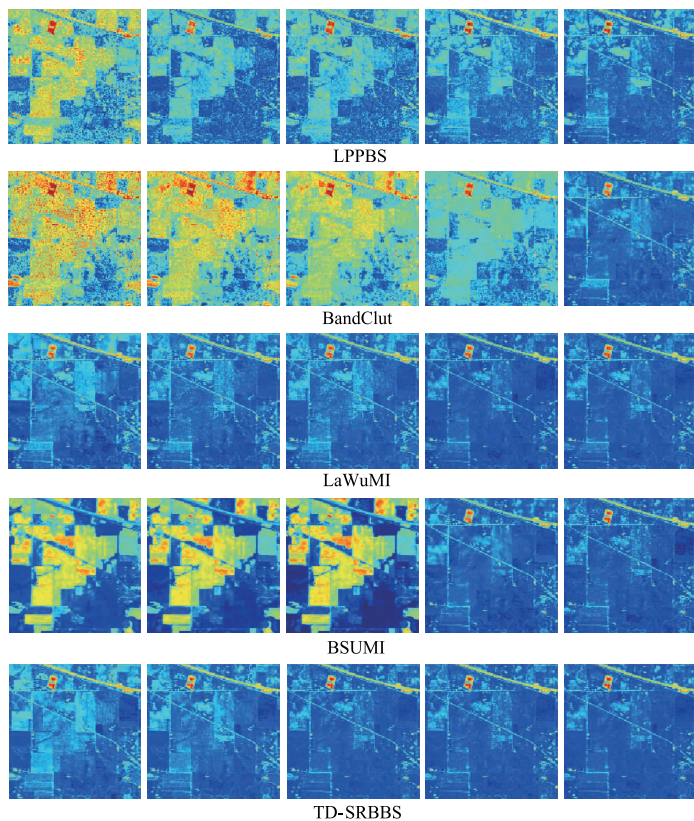

(a) AUC 值与波段数关系曲线

(b) 选择波段数为 11 时 ROC 曲线

图4 波段选择检测性能分析

地物, 其中 Metal Sheets 与其它各类光谱差异明显, 因此将其作为待检测目标, 其真实分布如图 6(b) 所示.

University of Pavia 的对称 KL 散度分布如图 7 所示, 同样, 根据其梯度变化情况将数据划分为 4 个子空间 (1 ~ 4, 5 ~ 69, 70 ~ 76, 77 ~ 103), 随即给定一组选择波段数, 结合子空间划分情况进行波段选择. 为保证投影矩阵的规模可行, LPPBS 随机选择 5% 的像元进行波段相似性度量, BSUMI 利用波段 51 ~ 91 的均值图像作为参考图像. 得到检测 AUC 值随波段数变化的关系如图 8(a) 所示, 可以看出, 随着波段数增大, BandClust 和 BSUMI 检测性能都先上升后下降, 然后保持相对稳定水平. 这印证了“波段越多, CEM 检测性能越好”这一结论是从能量输出的角度得到的, 波段越多并不一定意味着 ROC 性能更好, 只有增加数据中的有效波段才能改善 CEM 的 ROC 性能. BSUMI 的检测性能波动较大, 且绝大多数情况下不如 TD-SRBBS. 当  $18 < n < 45$  时, BandClust 的检测性能优于 TD-SRBBS, 但其和 BSUMI 类似, 检测性能总体波动幅度较大. 相较于 BandClust

图5 不同选择波段数时(从左到右 $n=9, 15, 21, 40, 60$ ) Indiana Pines检测结果

(a) 假彩色图 (b) 地物真实

图6 University of Pavia


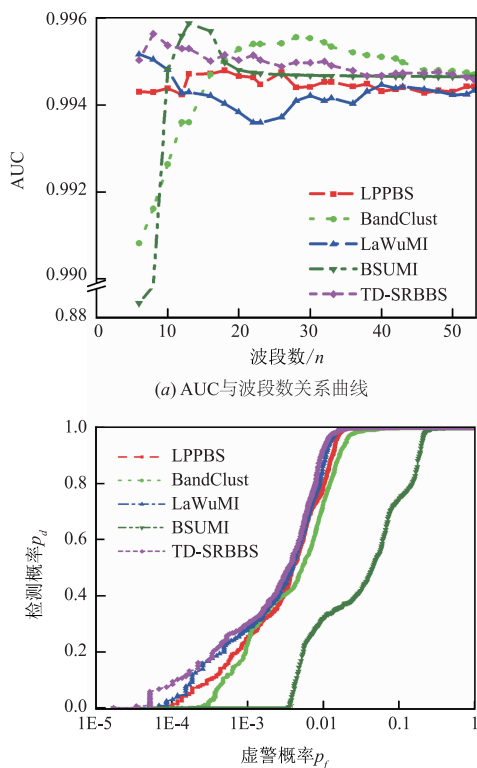


图7 University of Pavia对称KL散度分布

(a) AUC与波段数关系曲线  
(b) 选择波段数为8时ROC曲线  
图8 波段选择检测性能分析

和 BSUMI, LaWuMI 和 LPPBS 的检测效果波动较小,但其检测性能几乎总是低于 TD-SRBBS. 总的说来,尽管当  $n > 8$  时, TD-SRBBS 的检测性能呈下降趋势,但其波动较小且 AUC 值始终较大(0.995 左右),检测性能总是处于最优或次优水平,能获得更可靠的检测性能. 当  $n = 8$  时,各种波段选择方法对应的 ROC 曲线如图 8(b) 所示,可以看出, TD-SRBBS 能够获得更好的检测性能,当虚警概率一定时,其检测概率高于其它方法.

用上述 5 种方法分别选择 6, 10, 16, 22, 46 个波段用于目标检测,检测结果如图 9 所示. 可以看出, TD-SRBBS 能够比较明显的区分目标,当选择波段数增加到 46 时,其检测性能出现下降. BandClust 在  $n = 22$  时效果较好,当  $n$  增大到 46 时其检测性能也出现下滑; LaWuMI 比较稳定,但其检测效果不如 TD-SRBBS; 而 BSUMI 则表现不佳,特别是当  $n$  极小时,其完全不能分辨目标. 不同于实验 1, 此时 LPPBS 能够获得比较稳定且接近 TD-SRBBS 的检测效果. 对比实验 1 和实验 2 发现,针对不同的数据集,随着选择波段数的变化, LPPBS, BandClust, LaWuMI 和 BSUMI 等方法的检测性能表现出不同的变化形态和相对关系. 而 TD-SRBBS 虽然并非总是最好,但却始终能够获得良好且稳定可靠的检测性能,应用范围更广.

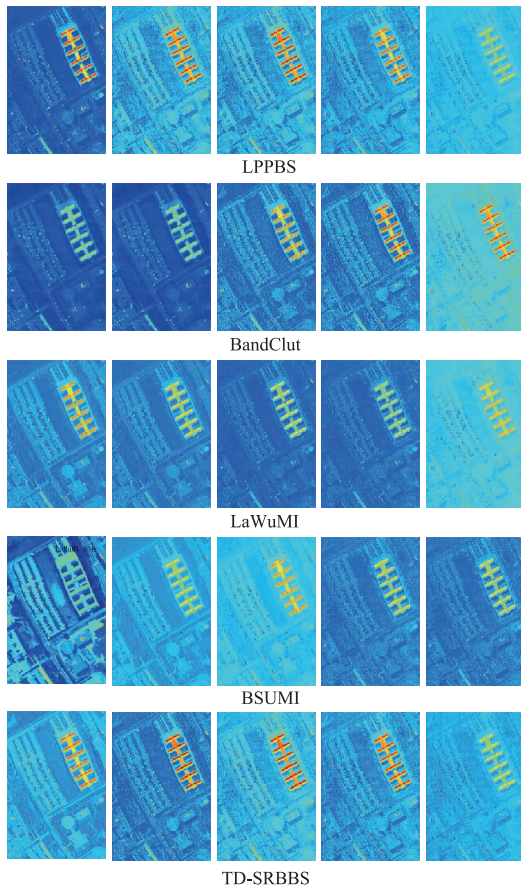


图9 不同选择波段数时(从左到右: 6, 10, 16, 22, 46) University of Pavia检测结果

#### 4 结论

本文在分析 CEM 检测算子特点的基础上,提出了一种面向目标检测基于稀疏表示的波段选择方法 TD-SRBBS. 该方法将波段选择问题转变为  $L_0$  范数最优化问题,利用选择波段和稀疏向量非零项的对应关系进行波段选择. 由于在 CEM 检测框架下建立模型,该波段选择方法将目标信息和背景信息融入到波段选择问题,实验结果验证了该方法的有效性和优越性.

#### 参考文献

- [1] Chen Y, Nasrabadi N M, Tran T D. Hyperspectral image classification via kernel sparse representation [J]. IEEE Trans. Geosci. Remote Sens. 2013, 51(1): 217 - 231.
- [2] Sellami A, Ettabaï K S, Farah I R, et al. Interpretation of hyperspectral imagery based on hybrid dimensionality reduction methods [A]. International Image Processing Application and Systems Conference [C]. New York: IEEE. 2014. 1 - 6.
- [3] 葛亮, 王斌, 张立明. 基于波段聚类的高光谱图像波段选择 [J]. 计算机辅助设计与图形学学报, 2012, 24(11): 1447 - 1454.
- Ge L, Wang B, Zhang L M. Band selection based on band clustering for hyperspectral imagery [J]. Journal of Computer-Aided Design and Computer Graphics, 2012, 24(11): 1447 - 1454. (in Chinese)
- [4] Imani M, Ghassemian H. Band clustering based feature extraction for classification of hyperspectral images using limited training samples [J]. IEEE Geosci. Remote Sens. Lett., 2014, 11(8): 1325 - 1329.
- [5] Guo B F, Gunu S R, Damper R I, et al. Band selection for hyperspectral image classification using mutual information [J]. IEEE Geosci. Remote Sens. Lett., 2006, 3(4): 522 - 526.
- [6] Sarhrouni E, Hammouch A, Aboutajdine D. Band selection and classification of HSI by minimizing normalized mutual information [EB/OL]. <http://arxiv.org/abs/1211.0613>, 2012 - 12 - 01.
- [7] 刘雪松, 葛亮, 王斌, 等. 基于最大信息量的高光谱遥感图像无监督波段选择方法 [J]. 红外与毫米波学报, 2012, 31(2): 166 - 170.
- Liu X S, Ge L, Wang B, et al. An unsupervised band selection algorithm for hyperspectral imagery based on maximal information [J]. Journal Infrared Millim. Waves, 2012, 31(2): 166 - 170. (in Chinese)
- [8] Chang C I, Wang S. Constrained band selection for hyperspectral imagery [J]. IEEE Trans. Geosci. Remote Sens., 2006, 44(6): 1575 - 1585.
- [9] Li-chien Lee, Yen-Chieh Ouyang, Shih-yu Chen, et al. An information theoretical approach to multiple-band selection for hyperspectral imagery [A]. International Geoscience & Remote Sensing Symposium [C]. New York: IEEE 2016. 2773 - 2776.
- [10] Cariou C, Chehdi K, Moan S L. BandClust: an unsupervised band reduction method for hyperspectral remote sensing [J]. IEEE Geosci. Remote Sens. Lett. 2011, 8(3): 565 - 569.
- [11] Adolfo Martínez-Usó, Pla F., José Martínez Sotoca, et al. Clustering-based hyperspectral band selection using information measures [J]. IEEE Trans. Geosci. Remote Sens. 2007, 45(12): 4158-4171.
- [12] Du Q, Yang H. Similarity based unsupervised band selection for hyperspectral image analysis [J]. IEEE Geosci. Remote Sens. Lett. 2008, 5(4): 564 - 568.
- [13] Li S J, Qi H R. Sparse representation based band selection for hyperspectral images [A]. International Conference on Image Processing [C]. New York: IEEE 2011. 2693 - 2696.
- [14] Kuo B C, Ho H H, Li C H, et al. A kernel based feature selection method for SVM with RBF kernel for hyperspec-

- tral image classification [J]. IEEE Journal of Selected Topics in Applied Earth Observation and Remote Sensing, 2014, 7(2): 317–326.
- [15] Keshava N. Distance metrics and band selection in hyperspectral processing with applications to material identification and spectral libraries [J]. IEEE Trans. Geosci. Remote Sens., 2004, 42(7): 1552–1565.
- [16] Su H, Du Q. Hyperspectral band clustering and band selection for urban land cover classification [J]. Geocarto Int., 2012, 27(5): 395–411.
- [17] Jia S, Ji Z, Qian Y, et al. Unsupervised band selection for hyperspectral imagery classification without manual band removal [J]. IEEE Journal of Selected Topics in Applied Earth Observation and Remote Sensing, 2012, 5(2): 531–543.
- [18] S Sharifi Hashjin, A Darvishi, S Khazal, F Hatami, et al. A band selection method for sub-pixel target detection in hyperspectral images based on laboratory and field reflectance spectral comparison [J]. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, 2016, XLI–b7: 117–120.
- [19] 王艺婷, 黄世奇, 刘代志, 等. 一种新的基于目标检测的波段选择方法 [J]. 红外与激光工程, 2013, 42(8): 2294–2298.
- Wang Y T, Huang S Q, Liu D Z, et al. Novel band selection method based on target detection [J]. Infrared and Laser Engineering, 2013, 42(8): 2294–2298. (in Chinese)
- [20] 何元磊, 刘代志, 易世华, 等. 面向目标检测的高光谱图像层次聚类波段选择 [J]. 仪器仪表学报, 2011, 32(4): 825–830.
- He Y L, Liu D Z, Yi S H, et al. Band selection based on hierarchical clustering for hyperspectral target detection [J]. Chinese Journal of Scientific Instrument, 2011, 32(4): 825–830. (in Chinese)
- [21] Diani M, Acito N, Gario M, et al. A new band selection strategy for target detection in hyperspectral images [J]. Lecture Notes in Computer Science. 2008, 5179: 424–431.
- [22] Geng X R, Ji L Y, Sun K, et al. CEM: more bands, better performance [J]. IEEE Geosci. Remote Sens. Lett., 2014, 11(11): 1876–1880.
- [23] Gu Y F, Zhang Y. Unsupervised subspace linear spectral mixture analysis for hyperspectral images [A]. Proc. of International Conference on Image Processing [C]. New York: IEEE, 2003. 801–804.

#### 作者简介



唐意东 (通信作者) 男, 四川富顺人, 1989 年出生, 博士生, 主要研究方向为红外/高光谱图像目标检测与识别。  
E-mail: 18109267859@163.com



黄树彩 男, 陕西西安人, 1967 年出生, 教授, 博士生导师, 主要研究方向为模式识别与智能信息处理。  
E-mail: hsc1967@126.com