

文章编号:1001-9014(2017)04-0471-10

DOI:10.11972/j.issn.1001-9014.2017.04.016

一种新的用于高光谱图像小目标探测的 目标光谱学习算法

钮宇斌^{1,2}, 王斌^{1,2*}

(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)

摘要:提出一种用于高光谱图像小目标探测的目标光谱学习算法,目的是从图像中学习得到一条更为准确的目标光谱,从而提高有监督目标探测的效果.该算法由基于自适应权重的目标光谱学习算法和自完备字典两部分组成.前一部分内容是在已有完备的背景字典的情况下,通过稀疏编码和梯度下降算法来优化学习目标光谱;后一部分内容通过背景字典的不断扩充来确保该字典的完备性,从而保证了学习算法的准确性.仿真和实际高光谱数据的实验结果表明,所提出的方法能有效地提取出准确的目标光谱,从而显著提高目标探测算法的精度.

关 键 词:高光谱图像;目标探测;稀疏编码;光谱多样性;混合光谱

中图分类号:TP751 文献标识码: A

A novel target spectrum learning algorithm for small target detection in hyperspectral imagery

NIU Yu-Bin^{1,2}, WANG Bin^{1,2*}

(1. Key Laboratory for Information Science of Electromagnetic Waves (MoE), Fudan University, Shanghai 200433, China;
2. Research Center of Smart Networks and Systems, School of Information Science and Technology,
Fudan University, Shanghai 200433, China)

Abstract: A novel target spectrum learning method for small target detection in hyperspectral imagery is proposed to obtain a more accurate target spectrum for better supervised target detection. This method is composed of two components: adaptive weighted learning method and self-completed background dictionary. Given a complete background dictionary, the former component refines the target spectrum through sparse coding and gradient descent algorithm. The latter component guarantees the background dictionary completeness by gradually size enlarging. Both experimental results on simulated and real hyperspectral data show that the proposed method has an advantage in extracting the accurate target spectrum, which enables better detection results.

Key words: hyperspectral imagery, target detection, sparse coding, spectral variability, mixed spectrum

PACS: 84.40. Xb

引言

高光谱遥感图像具有较高的光谱分辨率,其观测波长覆盖了电磁波谱的紫外、可见光、近红外和中

红外区域,图像中的每一个像元都是一条由数百个波段构成的连续光谱曲线,包含了详尽的地物光谱信息.而每一种类的地物都有着与之对应的光谱特征曲线,因此高光谱遥感图像在地物目标探测领域

收稿日期:2016-08-09,修回日期:2016-12-13

Received date: 2016-08-09, revised date: 2016-12-13

基金项目:国家自然科学基金(61572133);北京师范大学地表过程与资源生态国家重点实验室开放基金(2015-KF-01)

Foundation items: Supported by National Natural Science Foundation of China (61572133), Research Fund for the State Key Laboratory of Earth Surface Processes and Resource Ecology (2015-KF-01)

作者简介(Biography): 钮宇斌(1990-),男,浙江湖州人,博士研究生.主要从事高光谱遥感图像目标探测的研究. E-mail: 12110720009@fudan.edu.cn

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

有着独特的优势,近年来受到了研究者们的广泛重视^[1].

传统的目标探测算法包括约束能量最小化(Constrained Energy Minimization, CEM)算法^[2]、自适应余弦一致性评估器(Adaptive Coherence/Cosine Estimator, ACE)算法^[3]、自适应匹配滤波器(Adaptive Matched Filter, AMF)算法^[4]等,这些算法都是基于统计学的原理,有着广泛的应用. 近些年来,一些改进算法,比如多层CEM(hierarchical CEM, hCEM)算法^[5],和一些基于稀疏理论的目标探测算法^[6-7]也先后被研究者们提出,具有较好的探测效果.

然而,以上方法的探测效果与先验的目标光谱的准确性极为相关. 当先验目标光谱不准确时,以上算法无法取得令人满意的效果. 目前通常有以下三种方法来获得目标地物的光谱信息:(1)实验室光谱数据库;(2)高光谱图像中的像素点或者多个像素点的均值^[8];(3)端元提取算法^[9]. 然而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、仪器噪声等影响,使得测量光谱与真实图像中的光谱之间存在差异^[10]. 与此同时,“同物异谱”现象使得同一种地物有着多条与之对应的实验室光谱. 另外由于高光谱遥感图像的空间分辨率较低,图像中存在大量的混合像元,通常情况下很难保证图像上的某些像素点属于纯目标像元,进行仔细的判定又需要比较大的人工成本. 而端元提取算法需要图像中存在纯目标像元,同时要求所探测的目标具有较高的出现概率,当以上条件不满足时,端元提取算法也难以获取准确的目标光谱.

综上所述,先验目标光谱的准确性在实际情况中很难被保证,对目标探测的效果有着较大的影响. 近期,针对这一问题,T. Wang, et al 提出了一种迭代自适应定权的ACE(reweighted ACE, rACE)算法^[11],该算法通过多层ACE算法来优化目标光谱,从而获得更优的结果. 然而该算法无法应对相对复杂的背景情况^[5]. S. Yang, et al 提出了一种鲁棒的CEM(CEM using a inequality constrain, CEM-IC)算法^[12],用一个不等约束替换掉CEM中的等式约束,使得所探测的目标是先验目标光谱附近构成的一个包络. 然而该方法在提升探测率的情况下也同时增大了虚警率,另外参数的选择也比较困难.

为了解决先验目标光谱不准确的问题,我们提出一种目标光谱学习算法,该算法是由基于自适应权重的目标光谱学习算法(adaptive weighted learn-

ing method, AWLM)和自完备背景字典(self-completed background dictionary, SCBD)两部分组成,简称AWLM_SCBD. AWLM的思路来源于字典学习算法^[13],与之不同的是,AWLM假设已有一个完备的背景字典,通过稀疏编码和梯度下降算法优化学习目标光谱,同时学习过程中添加一个与目标分量相关的自适应权重来优化学习结果. 然而当AWLM过程中的背景字典不完备时,所学习到的结果可能是某一背景光谱. 利用目标的特性来判断AWLM的学习结果,当该结果为背景时,将学习得到的光谱添加到背景字典中,开始新的AWLM循环,直到准确的目标光谱被学习获得. 因此整个过程中背景字典是不断扩充的,该字典可以被称为自完备背景字典(SCBD). 仿真和实际数据实验结果说明,AWLM_SCBD能够有效地提取出准确的目标光谱,即使结合传统的有监督目标探测算法也能获得令人满意的探测效果.

1 稀疏编码和字典学习

基于稀疏表示模型,已有字典矩阵 $\mathbf{D} = [\mathbf{D}_b, \mathbf{D}_t] \in \mathbf{R}^{L \times (N_b + N_t)}$, 其中 $\mathbf{D}_b \in \mathbf{R}^{L \times N_b}$ 表示有 N_b 个原子的背景字典, $\mathbf{D}_t \in \mathbf{R}^{L \times N_t}$ 表示有 N_t 个原子的目标字典, 图像上的每一个像元 $\mathbf{x}_i \in \mathbf{R}^{L \times 1}$, 可以表示为:

$$\mathbf{x}_i = \mathbf{D}\boldsymbol{\gamma}_i + \boldsymbol{\nu}, \quad (1)$$

其中 $\boldsymbol{\gamma}_i = [\boldsymbol{\alpha}_i^T, \boldsymbol{\beta}_i^T]^T$, $\boldsymbol{\alpha}_i$ 和 $\boldsymbol{\beta}_i$ 为背景字典和目标字典对应的稀疏向量, $\boldsymbol{\nu}$ 是误差项.

稀疏向量 $\boldsymbol{\gamma}_i$ 可以通过求解以下优化问题得到:

$$\boldsymbol{\gamma}_i = \arg \min_{\boldsymbol{\gamma}_i} \|\mathbf{x}_i - \mathbf{D}\boldsymbol{\gamma}_i\|_2^2 \text{ s. t. } \|\boldsymbol{\gamma}_i\|_0 \leq K_0, \quad (2)$$

其中 $\|\bullet\|_0$ 表示 l_0 范数, 指矩阵中非零元素的个数, K_0 表示 $\boldsymbol{\gamma}_i$ 的稀疏度. 然而问题(2)是一个非凸问题,通常松弛到 l_1 范数进行求解:

$$\boldsymbol{\gamma}_i = \arg \min_{\boldsymbol{\gamma}_i} \|\mathbf{x}_i - \mathbf{D}\boldsymbol{\gamma}_i\|_2^2 + \lambda \|\boldsymbol{\gamma}_i\|_1, \quad (3)$$

其中 $\|\bullet\|_1$ 表示 l_1 范数, 表示矩阵中各元素绝对值之和, λ 是权衡因子. 求解问题(3)的过程被称为稀疏编码, 该问题是一个凸问题, 可以通过最小角回归(Least angle regression, LARS)算法^[14]求解.

当字典矩阵 \mathbf{D} 未知的时候, 字典学习的问题可以表示为:

$$\{\mathbf{D}, \{\boldsymbol{\gamma}_i\}\} = \arg \min_{\mathbf{D}, \{\boldsymbol{\gamma}_i\}} \sum_{i=1}^N (\|\mathbf{x}_i - \mathbf{D}\boldsymbol{\gamma}_i\|_2^2 + \lambda \|\boldsymbol{\gamma}_i\|_1), \quad (4)$$

其中 N 为样本个数. 可以通过一个循环迭代以下两个步骤来优化获得学习字典: 1) 求解问题(3)中的

稀疏向量;2)通过下式梯度更新字典矩阵:

$$\mathbf{D}^{(n+1)} = \mathbf{D}^{(n)} - \mu \sum_{i=1}^N (\mathbf{D}^{(n)} \gamma_i - \mathbf{x}_i) \gamma_i^T, \quad (5)$$

其中 μ 为更新步长.

2 算法描述

2.1 基于自适应权重的目标光谱学习算法(AWLM)

目标光谱学习算法的思路源自字典学习算法^[13],与之不同的是,假设已经获得一个完备的背景字典 \mathbf{D}_b 和初始的先验目标光谱 \mathbf{d} ,固定背景字典 \mathbf{D}_b ,准确的目标光谱 \mathbf{d}_t 可以通过求解以下优化问题获得:

$$\begin{aligned} & \{\mathbf{d}_t, \{\alpha_i\}, \{\beta_i\}\} \\ &= \arg \min_{\mathbf{d}_t, \|\alpha_i\|, \|\beta_i\|} \sum_{i=1}^N \left(\left\| \mathbf{x}_i - [\mathbf{D}_b, \mathbf{d}_t] \times \begin{bmatrix} \alpha_i \\ \beta_i \end{bmatrix} \right\|_2^2 + \lambda \left\| \begin{bmatrix} \alpha_i \\ \beta_i \end{bmatrix} \right\|_1 \right) \\ &= \arg \min_{\mathbf{d}_t, \|\alpha_i\|, \|\beta_i\|} \sum_{i=1}^N \left(\left\| \mathbf{x}_i - \mathbf{D}_b \alpha_i - \beta_i \mathbf{d}_t \right\|_2^2 + \lambda \left\| \begin{bmatrix} \alpha_i \\ \beta_i \end{bmatrix} \right\|_1 \right) \\ & \quad \text{s. t. } \mathbf{d}_t^0 = \mathbf{d}, \quad (6) \end{aligned}$$

其中 \mathbf{d}_t^0 表示 \mathbf{d}_t 的初始设置.值得注意的是,所提出算法的目的是从高光谱图像中学习获得准确的目标光谱,因此对该目标光谱的稀疏系数 β_i 是一个标量.首先通过稀疏编码算法求解稀疏向量,然后, \mathbf{d}_t 可以通过梯度下降算法进行优化,其更新公式如下:

$$\mathbf{d}_t^{k+1} = \mathbf{d}_t^k + \mu \sum_{i=1}^N \beta_i \mathbf{x}_t^i, \quad \mathbf{x}_t^i = \mathbf{x}_i - \mathbf{D}_b \alpha_i, \quad (7)$$

其中 \mathbf{x}_t^i 可以看作是循环过程中像素 \mathbf{x}_i 去除背景分量后的目标残差.通过不断循环以上两步可以求解优化问题(6).如同字典学习算法,在每次更新 \mathbf{d}_t 之后,应对其进行二范数归一化操作.

然而上述优化方法的准确性极大地依赖初始背景字典的准确性,而准确的背景字典通常难以获得.同时根据优化问题(6),所有的像素有着同样的权重,然而在实际情况中,目标样本的出现概率很小,给予所有的像素相同的权重并不合理.因此所提出算法引入自适应权重,通过对各像素赋予不同的权重来克服以上问题.从理论上说,各个像素所对应的权重应该与该像素中目标的占比相关,目标占比越大的像素的权重更大,反之,则权重较小.在迭代优化过程中,像素 \mathbf{x}_i 中目标的占比由下式表示:

$$t_i = \frac{\|\beta_i \mathbf{d}_t\|_2}{\|\mathbf{x}_i\|_2} = \frac{\beta_i}{\|\mathbf{x}_i\|_2}, \quad (8)$$

其中 \mathbf{d}_t 的二范数固定为 1.然后采用以下函数获得各个像素的权重:

$$g(t_i) = \frac{1}{1 + e^{-\kappa^*(t_i - \tau)}}, \quad (9)$$

其中 κ 和 τ 是控制 $g(t)$ 的两个参数,分别固定为 30 和 0.5.具体的函数形状见图 1.可以看出,目标占比大于 τ 的像素有着较大的权重.然后用下式归一化各权重:

$$\omega_i = \frac{g(t_i)}{\sum_{i=1}^N g(t_i)}. \quad (10)$$

引入自适应权重后,优化问题(6)变为:

$$\begin{aligned} & \{\mathbf{d}_t, \{\alpha_i\}, \{\beta_i\}\} \\ &= \arg \min_{\mathbf{d}_t, \|\alpha_i\|, \|\beta_i\|} \sum_{i=1}^N \omega_i \left(\left\| \mathbf{x}_i - [\mathbf{D}_b, \mathbf{d}_t] \times \begin{bmatrix} \alpha_i \\ \beta_i \end{bmatrix} \right\|_2^2 + \lambda \left\| \begin{bmatrix} \alpha_i \\ \beta_i \end{bmatrix} \right\|_1 \right) \\ &= \arg \min_{\mathbf{d}_t, \|\alpha_i\|, \|\beta_i\|} \sum_{i=1}^N \omega_i \left(\left\| \mathbf{x}_i - \mathbf{D}_b \alpha_i - \beta_i \mathbf{d}_t \right\|_2^2 + \lambda \left\| \begin{bmatrix} \alpha_i \\ \beta_i \end{bmatrix} \right\|_1 \right) \\ & \quad \text{s. t. } \mathbf{d}_t^0 = \mathbf{d}. \quad (11) \end{aligned}$$

相应地, \mathbf{d}_t 的梯度迭代公式为:

$$\mathbf{d}_t^{k+1} = \mathbf{d}_t^k + \mu \sum_{i=1}^N \omega_i \beta_i \mathbf{x}_t^i, \quad \mathbf{x}_t^i = \mathbf{x}_i - \mathbf{D}_b \alpha_i \quad . \quad (12)$$

值得注意的是,由于自适应权重 ω_i 与 β_i 相关,优化问题(11)是一个非凸问题,可能会有局部最优的问题,然而之后的实验结果表明,该算法仍然可以收敛并获得预期的结果.

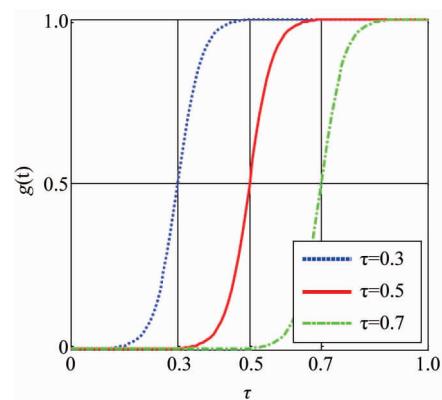


图 1 参数 κ 取 30, 在不同 τ 值对应的函数 $g(t)$ 的形状

Fig. 1 Shapes of the function $g(t)$ with different choices of τ when κ is settled at 30

2.2 自完备背景字典(SCBD)

AWLM 算法通过引入自适应权重解决了背景字典 \mathbf{D}_b 不准确所带来的问题,从一定程度上保证算法收敛到实际的目标光谱.然而当 \mathbf{D}_b 不够完备时,算法的有效性依旧存在问题.考虑一种最糟糕的

情况,即 \mathbf{D}_b 是一个空集,此时迭代公式(12)中的目标残差 \mathbf{x}_t^i 的值就是像素光谱向量本身。根据公式(12), \mathbf{d}_t 会收敛到图像中占比最大的某个地物端元光谱。因此可以得出以下结论:当 \mathbf{D}_b 不完备时,AWLM 收敛的结果可能是某条背景光谱。针对这一问题,这里我们提出一种背景字典构建方案,使得在 AWLM 收敛到某条光谱向量后,先对该光谱向量进行判定:如果判定为背景光谱,则使之成为 \mathbf{D}_b 的一个新原子,然后重新开始一轮 AWLM 学习算法;如果判定为目标,则该光谱即为所需要的准确目标光谱。在这样一个过程中, \mathbf{D}_b 不断扩充完备直到准备目标光谱被学习获得,因此该字典被称为自完备背景字典。

所提出算法利用目标的两个特征来判定 AWLM 的收敛结果 \mathbf{d}_t 是否属于目标:(1)其光谱与先验的目标光谱 \mathbf{d} 之间的距离在一定范围内;(2)目标的出现概率低。 \mathbf{d} 的信息可能不够准确,但也会具有一定的目标信息,当 \mathbf{d}_t 与 \mathbf{d} 距离过大,可以认为学习结果是一条背景光谱。由于 \mathbf{d}_t 和 \mathbf{d} 均已进行二范数归一化,可以利用简单的欧式距离来衡量两者之间的距离,当 $\|\mathbf{d}_t - \mathbf{d}\|_2 \leq \eta$, \mathbf{d}_t 可能为目标光谱,反之则是背景光谱。 η 是判定阈值,固定为 0.2。在一般情况下,目标像素在整个高光谱图像中的占比很低,其阈值设定为 0.5%。在 AWLM 过程中,目标占比大于 τ 的像素有着较大的权重,利用较大权重像素的个数,记作 $\text{sum}(\mathbf{t}_i \geq \tau)$,来衡量 \mathbf{d}_t 的出现概率。

当 \mathbf{d}_t 同时满足 $\|\mathbf{d}_t - \mathbf{d}\|_2 \leq \eta$ 和 $\text{sum}(\mathbf{t}_i \geq \tau) \leq 0.005 N$ 两个条件时, \mathbf{d}_t 被判定为实际的目标光谱,否则判定为背景光谱,作为一个新的背景字典原子开始新的 AWLM 循环。

2.3 算法小结

所提出算法由 AWLM 和 SCBD 两部分构成,简称 AWLM_SCBD。其中 AWLM 可以看作所提出算法的内循环,而 SCBD 的构造过程可以看作所提出算法的外循环。AWLM_SCBD 算法流程图如图 2 表示,具体算法过程如下:

算法:AWLM_SCBD

输入:初始数据矩阵 $X \in \mathbb{R}^{b \times N}$,先验的目标光谱 $\mathbf{d} \in \mathbb{R}^{b \times 1}$

输出:准确的目标光谱 $\mathbf{d} \in \mathbb{R}^{b \times 1}$

初始化设置: $\lambda = 0.5, \eta = 0.2, \kappa = 30, \tau = 0.5, \mu = 0.1, \varepsilon = 10^{-5}, \mathbf{d}_t^0 = \mathbf{d}, \mathbf{D}_b = []$

步骤 1. 初始化内循环次数: $k = 0$;

步骤 2. 执行以下循环(AWLM):

2a) $\mathbf{D} = [\mathbf{D}_b, \mathbf{d}_t^k]$;

2b) 利用式(3)求解稀疏向量;

2c) 利用式(8)、(9)和(10)计算各像素权重;

2d) 用式(12)更新迭代 \mathbf{d}_t^{k+1} ;

2e) 二范数归一化 \mathbf{d}_t^{k+1} ;

2f) 当满足 $\|\mathbf{d}_t^{k+1} - \mathbf{d}_t^k\|_2 \leq \varepsilon$ 时,跳出循环,AWLM 输出 $\mathbf{d}_t = \mathbf{d}_t^{k+1}$;

步骤 3. 当满足 $\|\mathbf{d}_t - \mathbf{d}\|_2 \leq \eta$ 和 $\text{sum}(\mathbf{t}_i \geq \tau) \leq 0.005 N$ 两个条件时,结束 AWLM_SCBD 算法,输出 \mathbf{d}_t ;否则, $\mathbf{D}_b = [\mathbf{D}_b, \mathbf{d}_t]$ 并返回步骤 1.

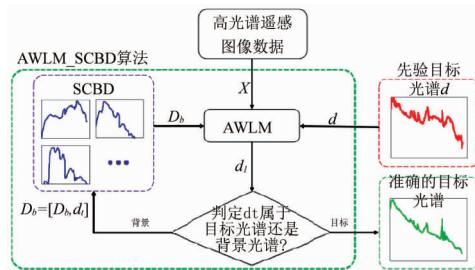


图 2 AWLM_SCBD 算法流程图

Fig. 2 Flowchart of AWLM_SCBD algorithm

3 实验结果与讨论

在本节中,分别采用仿真数据实验和真实数据实验来验证所提出方法的有效性。首先通过 AWLM_SCBD 算法学习获得准确的目标光谱,然后利用该目标光谱通过传统的 CEM 算法和 ACE 算法获得探测结果,将该结果与直接利用 CEM 算法、ACE 算法和最新提出的 hCEM 算法^[5]、rACE 算法^[11] 和 CEM-IC 算法^[12] 的探测结果进行比较,来验证 AWLM_SCBD 算法在提取准确目标光谱方面的有效性。具体的算法在软件 matlab(版本为 R2013a) 上实现并运行。

直观的二维探测结果图、接收者操作特性曲线(Receiver operating characteristic, ROC)与 ROC 曲线下面积(Area under ROC curve, AUC)用作实验中探测性能的评价标准。

3.1 仿真数据实验

图 3 是美国地质调查局(United States Geological Survey, USGS)光谱数据库^[15]中白云母的光谱曲线,一共包括 10 条光谱曲线,从这里可以看出同物异谱现象广泛存在于高光谱图像数据中。当采用 USGS 中白云母的光谱曲线作为先验目标光谱时,其光谱很有可能与实际图像中白云母的光谱曲线不

同,对各类目标算法的探测结果有着较大的影响.因而通过 AWLM_SCBD 算法提取出实际的目标光谱,然后再利用其它目标探测算法可以获得令人满意的效果.为了验证 AWLM_SCBD 算法的有效性,采用了埋点的方式来构造仿真数据.仿真实验用到了 Cuprite 数据集¹,Cuprite 数据集是由机载可见光及红外成像光谱仪 (Airborne Visible/Infrared Imaging Spectrometer, AVIRIS) 拍摄于 1997 年 6 月 19 日的美国内华达州 Cuprite 地区的数据,该数据有 224 个波段,图像尺寸为 250×191 ,其伪彩色图如图 4(a) 所示.在使用之前,第 1 ~ 3, 104 ~ 115 和 150 ~ 170 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 个波段进行进一步的处理.埋入目标点的像素光谱 z 由下式计算得到:

$$z = f \cdot t + (1 - f) \cdot b \quad , \quad (13)$$

其中 f 为标的丰度, t 为目标光谱, b 为当前像元的光谱.埋入的位置如图 4(b) 所示,其中前面两列是大小为 2×2 的目标样本,后两列为单一目标像素点,各自的丰度 f 如表 1 所示.以图 3 中编号为 Muscovite_GD111 的光谱作为埋入的目标光谱 t ,同时添加强度为 30 dB 的高斯噪声.

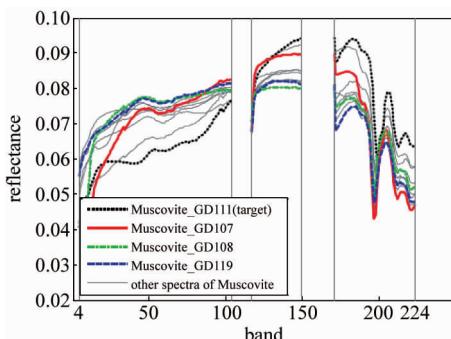


图 3 USGS 库中白云母的光谱曲线
Fig. 3 Spectra of Muscovite in USGS library

表 1 埋入目标的丰度值

Table 1 Fraction values of implanted targets

目标点 丰度值	第一列 (2×2)	第二列 (2×2)	第三列 (1×1)	第四列 (1×1)
第一排	1.00	0.50	0.95	0.45
第二排	0.90	0.40	0.85	0.35
第三排	0.80	0.30	0.75	0.25
第四排	0.70	0.20	0.65	0.15
第五排	0.60	0.10	0.55	0.05

首先以编号为 Muscovite_107 的白云母光谱作为先验输入光谱来进行仿真实验,图 5 描绘了整个目标光谱的学习过程,其中一共经历了 5 个 AWLM

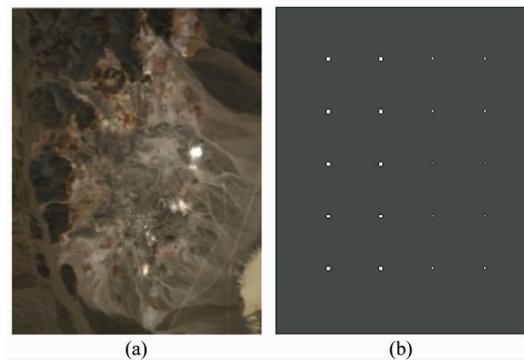


图 4 Cuprite 数据集,(a) Cuprite 伪彩色图(波段 40, 20 和 10 分别对应 RGB 通道),(b) 地物真实

Fig. 4 Cuprite dataset. (a) Band 40, 20 and 10 for RGB, (b) ground truth

内循环.左图表示每个内循环过程中光谱的变化过程,其中红色实线为先验输入光谱,在每个 AWLM 循环中作为初始目标光谱,灰色实线为 AWLM 中每次迭代更新的目标光谱,蓝色实线表示每个 AWLM 循环满足终止迭代条件时的结果.前 4 个 AWLM 的迭代结果不满足 2.2 节中判定为实际目标光谱的两个条件,故而用作第 5 个 AWLM 循环中的背景字典.第 5 个 AWLM 的学习结果被判定为实际的目标光谱,得到整个目标光谱提取算法的输出.右图表示每个 AWLM 停止迭代时目标光谱所对应的归一化自适应权重,可以看出,在第 5 个 AWLM 循环中,埋入目标比例较大的像素点有着很高的权重,而其他点的权重很小,从而说明学习算法的有效性.值得一提的是,所采用的 Cuprite 数据集本身含有一定的白云母成分,其中图像中的白云母成分在第 4 个 AWLM 中被探测获得,然而由于高光谱图像数据的光谱多样性特点,图像中原本的白云母光谱与所埋入的编号为 Muscovite_GD111 的光谱有着一定的差别,同时其在图像中的占比很大,故而被判定为了一条背景光谱.

为了进一步说明所提出算法在不同的先验目标光谱条件下的算法稳定性,利用白云母在光谱库中的 10 条光谱分别作为先验目标光谱,用 AWLM_SCBD 算法提取目标光谱.图 6 是基于 Cuprite 数据集的目标光谱学习结果,其中图 6(a) 是以其中三条光谱作为先验目标光谱的学习结果,而虚线为学习得到的光谱结果,图 6(b) 则综合了全部 10 条光谱作为先验目标光谱的学习结果.图中 AWLM_SCBD (Muscovite_GD107) 表示以编号为 Muscovite_GD107 的光谱作为先验目标光谱,然后利用 AWLM_SCBD

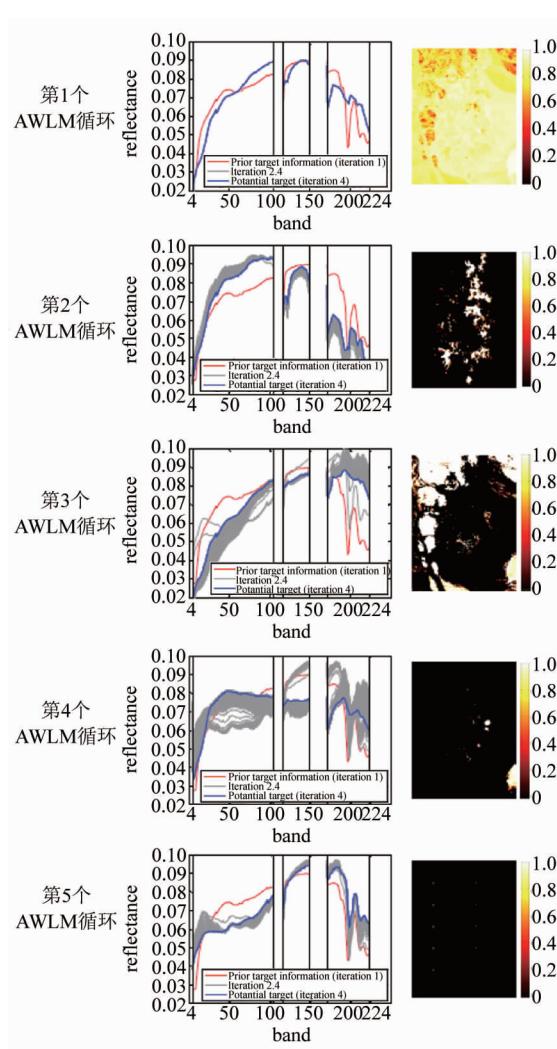


图 5 基于 Cuprite 数据集的目标光谱学习过程
Fig. 5 Target spectrum learning process on Cuprite dataset

算法提取得到准确的目标光谱曲线。可以看出，提取得到的结果与实际埋入的光谱曲线十分接近，近乎重合，说明 AWLM_SCBD 能够有效地提取出实际的目标光谱。

图 7 是以编号为 Muscovite_GD108 的白云母光谱作为先验目标光谱时，各个方法的直观的二维探测结果图。图 8 是以其中三条不同的白云母光谱作为先验目标光谱时，各个方法所对应的 ROC 曲线。表 2 是各方法所对应的 AUC 面积。结果显示，其他各类方法，包括传统的 CEM 算法、ACE 算法和新提出的 rACE 算法、hCEM 算法和 CEM-IC 算法均受到目标光谱不准确的影响。而首先通过 AWLM_SCBD

表 2 Cuprite 数据集上各类算法的 AUC 面积(%)

Table 2 AUC (mean \pm std) on Cuprite dataset (%)

各算法	CEM	ACE	hCEM	rACE	CEM - IC	AWLM_SCBD + CEM	AWLM_SCBD + ACE
AUC	98.16 \pm 1.89	97.42 \pm 3.15	98.50 \pm 2.11	98.82 \pm 0.29	96.01 \pm 2.83	99.24 \pm 0.00	99.38 \pm 0.01

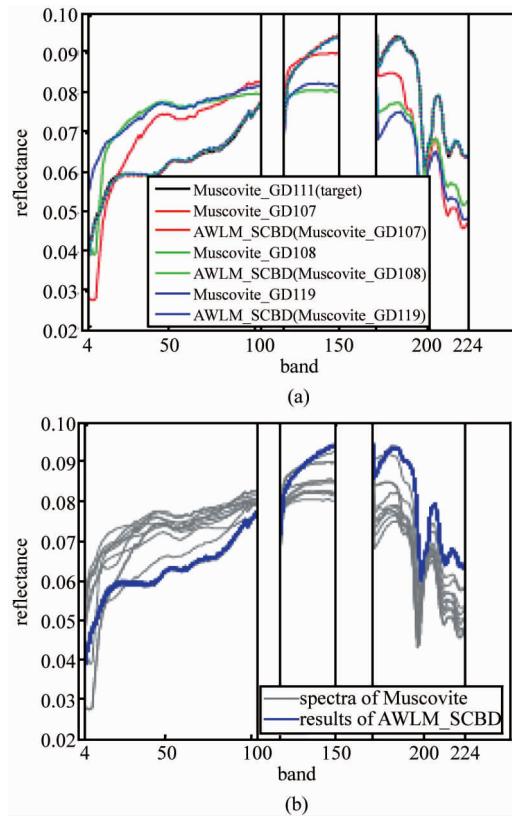


图 6 基于 Cuprite 数据集的目标光谱学习结果,(a)以其中三条光谱作为先验目标光谱的学习结果;(b)综合全部 10 条光谱作为先验目标光谱的学习结果
Fig. 6 Target spectrum learning results on Cuprite dataset, (a) results of using three spectra of Muscovite as an example, (b) results of all references

算法提取出准确的目标光谱之后，利用传统的 CEM 和 ACE 方法能获得更好而且更为稳定的探测结果。

3.2 真实数据实验

真实数据实验用到了一幅由 AVIRIS 机载高光谱成像光谱仪在美国加利福尼亚州圣地亚哥机场上方拍摄高光谱遥感图像数据，如图 9(a)所示，该图像尺寸为 180×180 ，在使用之前，第 1 ~ 6、33 ~ 35、97、107 ~ 113、153 ~ 166 和 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 189 个波段进行进一步的处理。图中一共有三架飞机，包含了 73 个飞机目标像素，其光谱如图 9(b)所示。

真实数据实验以这 73 条飞机光谱分别作为先验目标光谱进行实验。AWLM_SCBD 算法学习的目标光谱结果如图 10 所示。图 10(a)以图像中三个位置的像元光谱作为目标光谱学习的例子，具体位置

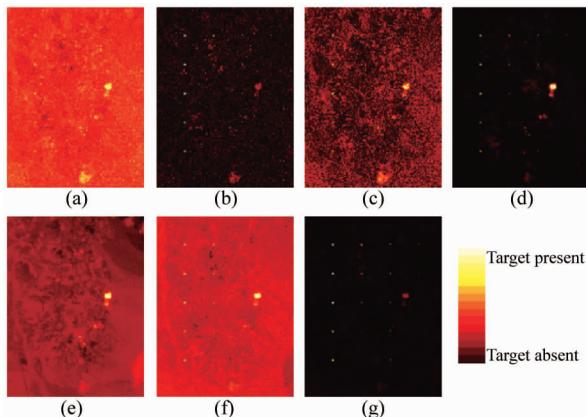


图 7 以编号为 Muscovite_GD108 的光谱曲线作为先验目标光谱时各方法的二维探测结果, (a) CEM, (b) ACE, (c) hCEM, (d) rACE, (e) CEM-IC, (f) AWLM_SCBD + CEM, (g) AWLM_SCBD + ACE

Fig. 7 2-D plots of the detection results on the Cuprite dataset using Muscovite_GD108 as the target spectrum of reference. (a) CEM, (b) ACE, (c) hCEM, (d) rACE, (e) CEM-IC, (f) AWLM_SCBD + CEM, (g) AWLM_SCBD + ACE

如图 9(a)所示. 图 10(b)综合了 73 条目标光谱学习的结果. 图 11 以位置(35, 53)上的像素光谱作为先验目标光谱时各方法的二维探测结果. 图 12 是以三个位置的像元光谱作为先验目标光谱时, 各方法对应的 ROC 曲线. 表 3 是各方法对应的 AUC 面积. 相比于仿真数据实验, 真实数据实验结果相对来说更为发散一些, 这是因为真实图像数据更为复杂. 值得注意的是, 其中有 3 条飞机光谱通过 AWLM_SCBD 算法学习得到的是图中某一类屋顶的光谱, 图 10(b)中已标出. 这是因为这 3 条飞机光谱实际上都是飞机与地面的混合光谱, 其光谱曲线与那一类屋顶的光谱十分近似, 这可能是因为此类屋顶的材料与飞机材料有着相似之处. 与此同时, 此类屋顶光谱满足 2.2 节中描述的两个判定条件, 因此所提出算法在学习获得屋顶光谱时终止了迭代. 然而从整体来说, AWLM_SCBD 所提取的目标光谱对于探测结果有着显著的提升.

3.3 所提出算法相关特性

3.3.1 受噪声的影响

在 Cuprite 数据集上, 通过添加不同强度的噪声来分析噪声对所提出算法的影响. 图 13 是以编号 Muscovite_GD108 的光谱曲线作为先验目标光谱, 在不同噪声下的目标光谱学习结果. 结果显示, 学习得

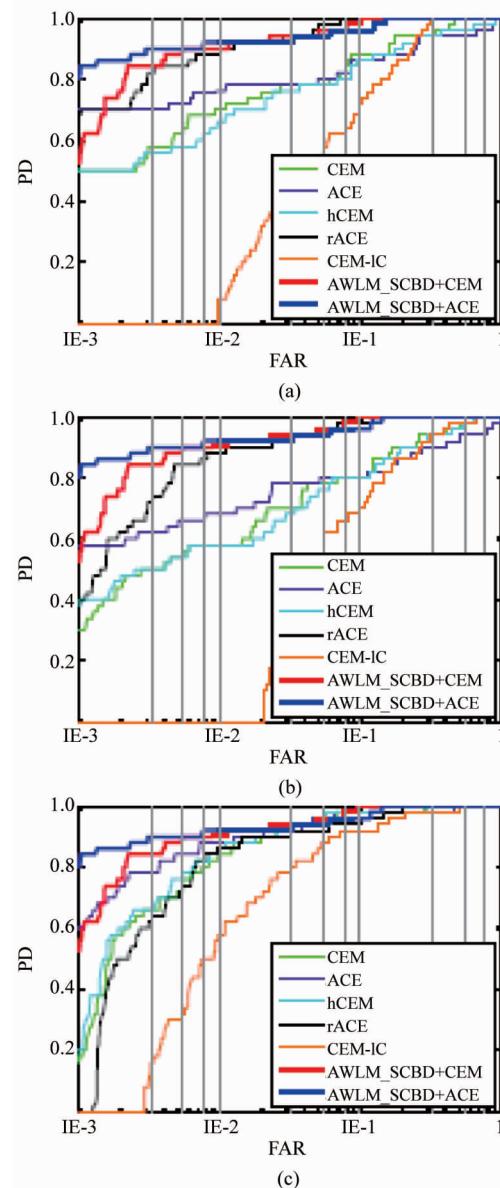


图 8 基于 Cuprite 数据集, 利用不同先验目标光谱下的各方法的 ROC 曲线, (a) Muscovite_GD107, (b) Muscovite_GD108, (c) Muscovite_GD119

Fig. 8 ROC curves on the Cuprite dataset using different target spectra of reference, (a) Muscovite_GD107, (b) Muscovite_GD108, (c) Muscovite_GD119

到的目标光谱曲线与实际埋入的光谱曲线相接近, 其中在 20 dB 和 30 dB 情况下与实际光谱曲线基本吻合. 在噪声较大的情况下(10 dB), 学习结果相对毛糙些, 这主要因为图像中目标样本的数目较少. 但总的来说, 所提出算法对噪声较为鲁棒, 可以有效提

表 3 机场数据集上各类算法的 AUC 面积(%)

Table 3 AUC (mean \pm std) on Cuprite dataset (%)

各算法	CEM	ACE	hCEM	rACE	CEM-IC	AWLM_SCBD + CEM	AWLM_SCBD + ACE
AUC	94.08 \pm 5.95	91.34 \pm 6.94	94.09 \pm 6.07	96.62 \pm 6.18	92.19 \pm 9.11	99.56 \pm 1.35	99.37 \pm 2.31

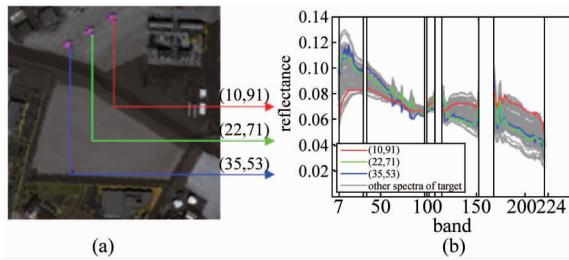


图9 机场数据集. (a) 伪彩色图(波段 53, 3 和 19 分别对应 RGB 通道),(b)所有飞机目标光谱曲线

Fig. 9 Airport dataset. (a) Channels 53, 33 and 19 for RGB, (b) spectra of airplane pixels

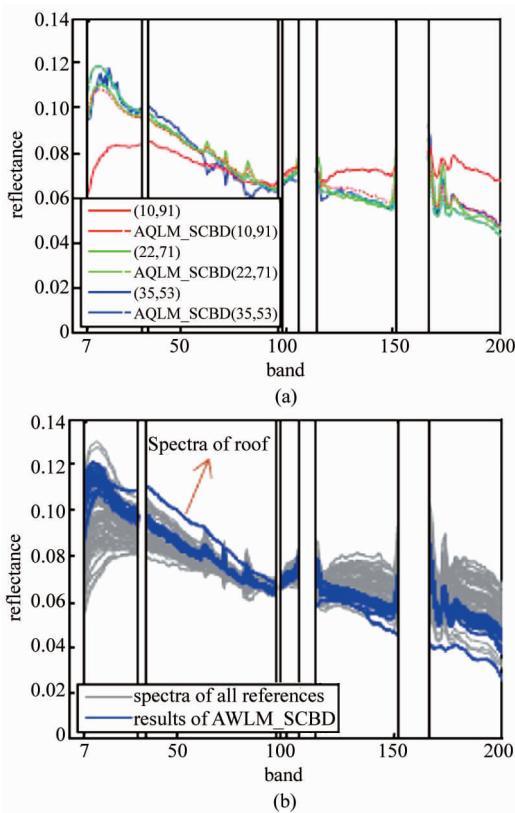


图10 基于机场数据集的目标光谱学习结果. (a)以其中三条飞机光谱作为先验目标光谱的学习结果,(b)综合全部 73 条光谱作为先验目标光谱的学习结果

Fig. 10 Target spectrum learning results on airport dataset. (a) Results of using spectra of three target pixels as an example, (b) results of all references

取准确的目标光谱.

3.3.2 收敛特性与运算开销

自适应权重的引入使得优化问题(11)变成一个非凸问题,因而收敛结果可能存在局部极小问题,但实验中均表明,所提出算法均能很好地收敛. 图14是机场数据集上一不同位置的像元光谱作为先验目标光谱时,AWLM_SCBD 的收敛性曲线. 其中纵轴为,当该值小于 10^{-5} 时,一组 AWLM 内循环收敛,

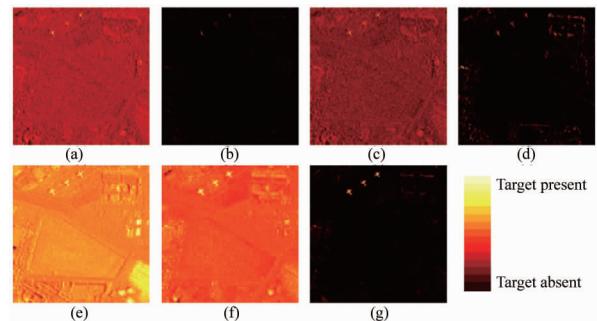


图11 以位置为(35, 53)上的像素光谱作为先验目标光谱时各方法的二维探测结果. (a) CEM, (b) ACE, (c) hCEM, (d) rACE, (e) CEM-IC, (f) AWLM_SCBD + CEM, (g) AWLM_SCBD + ACE

Fig. 11 2-D plots of the detection results on the airport dataset using spectrum of target pixel on the location of (35, 53) as the target spectrum of reference. (a) CEM, (b) ACE, (c) hCEM, (d) rACE, (e) CEM-IC, (f) AWLM_SCBD + CEM, (g) AWLM_SCBD + ACE

然后判断 AWLM 的结果是否属于目标,当该结果被判定为背景光谱时,作为背景字典的新原子开始下一轮 AWLM 内循环. 图中下方横轴表示总的迭代次数,上方横轴表示背景字典中原子的个数. 图 14(a) 表示该目标光谱学习过程共经历了 11 个 AWLM 循环,而图 14(b) 与 (c) 只经历了 6 个 AWLM 循环,这是因为位置为(10, 91)上的像元光谱与实际的飞机光谱差距较大,这一点可以从图 9 中看出,因此需要更为完备的背景字典才能将实际的目标光谱学出. 从这里也可以看出,所提出的自完备背景字典并非传统意义上的完备字典,实际上是指一个能够学出所需要的目标光谱的背景字典.

具体的运算时间与迭代次数相关,从图 14 可知,迭代次数与数据情况和先验的目标光谱的准确性相关. 每次迭代过程中的计算开销是求解每个像素对应字典的稀疏向量,与之相比,自适应权重的计算和目标光谱的梯度更新过程可以忽略不计. 该稀疏向量的求解利用网络上公开的 matlab 工具包 spams^[16],该工具包利用 LARS 算法,使得求解稀疏向量的运算量接近一个最小二乘回归的过程^[14].

4 总论

一般的高光谱图像目标探测算法对先验目标光谱较为敏感,而当先验目标光谱不准确时,导致目标探测结果较差. 针对这一问题,提出了一种新型的目标光谱学习算法,该方法通过基于自适应权重的目标光谱学习算法从实际图像中提取出目标光谱,并

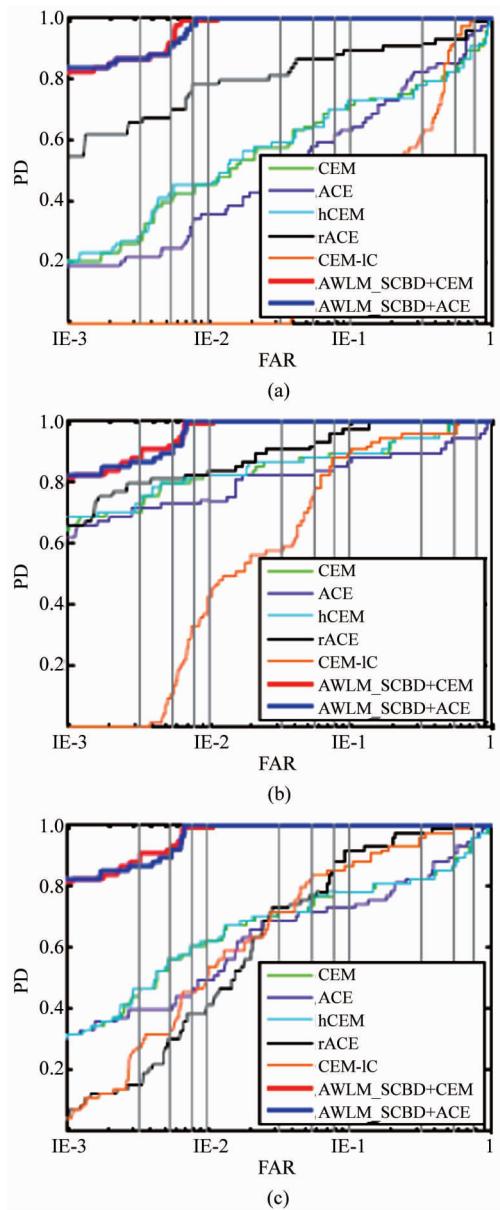


图 12 基于机场数据集,利用不同位置的先验目标光谱下的各方法的 ROC 曲线. (a) 位置为 (10, 91),(b) 位置为 (22, 71),(c) 位置为 (35, 53)

Fig. 12 ROC curves on the airport dataset using different target spectra on the location of (a) (10, 91), (b) (22, 71), and (c) (35, 53), as references

且通过构造自完备背景字典来保证学习算法的准确性. 仿真和真实高光谱图像的实验结果表明,所提出方法能够有效地提取目标光谱,同时对噪声有着较好的鲁棒性,也无须额外调整各个参数,对各类数据有着一定的普适性,可以作为一种有效的高光谱图像目标探测的预处理方法. 然而由于高光谱图像的光谱多样性现象,以单一的目标光谱作为先验输入并不完全合理,如何获得更为准确并且丰富的目标信息是将来的研究工作之一.

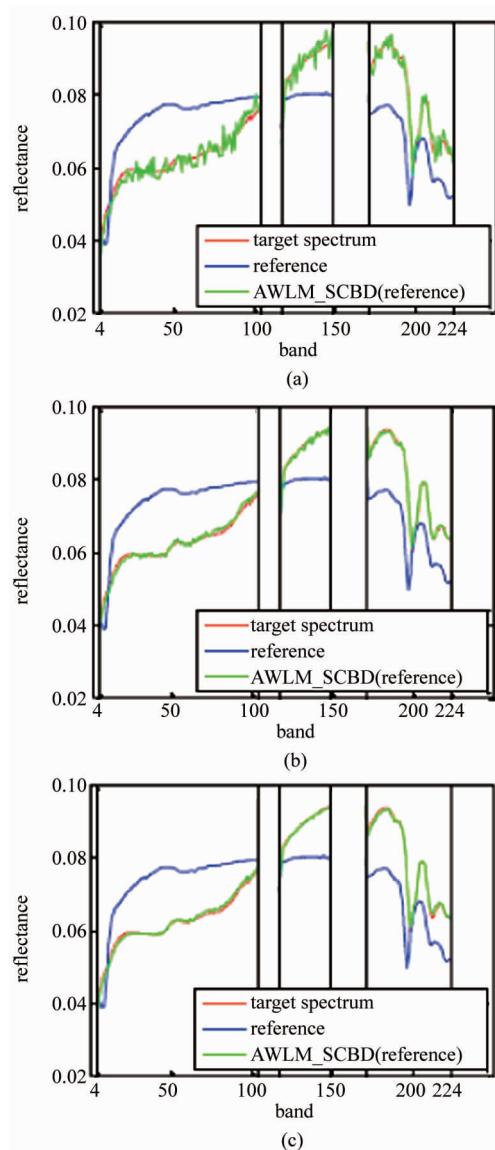


图 13 不同噪声下的目标光谱学习结果. (a) 10dB,(b)20dB,(c)30dB

Fig. 13 Target spectrum learning results with added Gaussian noise of different SNR. (a) 10 dB, (b) 20 dB, (c) 30 dB

References

- [1] Nasrabadi N M. Hyperspectral target detection: an overview of current and future challenges [J]. *IEEE Signal Process. Mag.*, 2014, **31**(1): 34–44.
- [2] Farrand W H, Harsanyi J C. Mapping the distribution of mine tailings in the Coeur d' Alene River Valley, Idaho, through the use of a constrained energy minimization technique [J]. *Remote Sens. Environ.*, 1997, **59**(1): 64–76.
- [3] Kraut S, Scharf L L, McWhorter L T. Adaptive subspace detectors [J]. *IEEE Trans. Signal Process.*, 2001, **49**(1): 1–16.

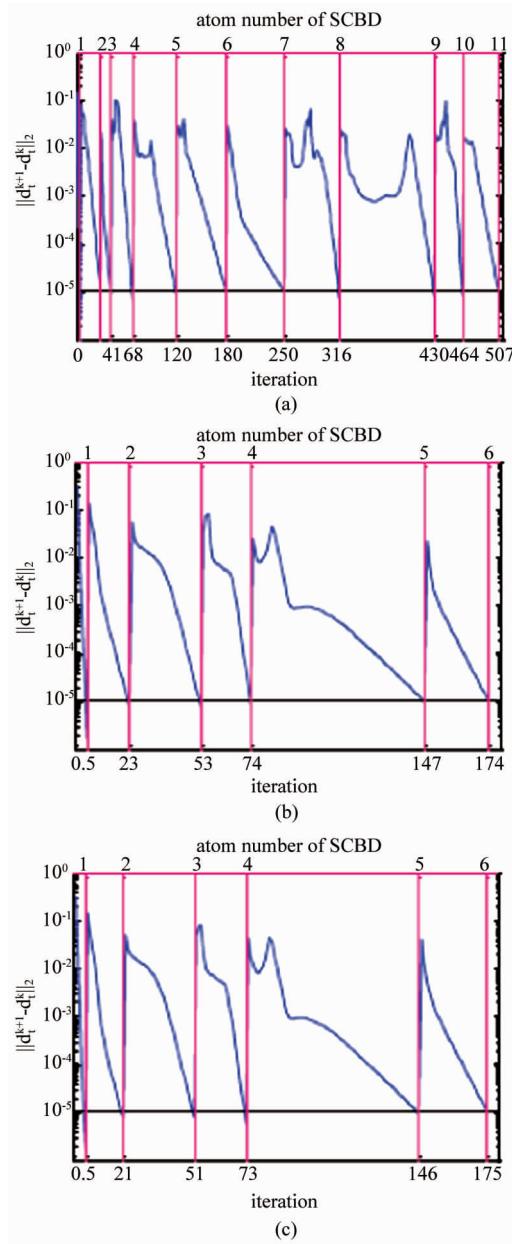


图 14 机场数据集上以不同位置上的像元光谱作为先验目标光谱时, AWLM_SCBD 的收敛曲线. (a) 位置为(10, 91), (b) 位置为(22, 71), (c) 位置为(35, 53)

Fig. 14 Convergence curves of the proposed method for the San Diego dataset using target pixels on different locations of (a) (10, 91), (b) (22, 71), and (c) (35, 53), as references

- [4] Robey F C, Fuhrmann D R, Kelly E J, et al. A CFAR adaptive matched filter detector [J]. *IEEE Trans. Aerosp. Electron. Syst.*, 1992, **28**(1): 208–216.
- [5] Zou Z X, Shi Z W. Hierarchical suppression method for hyperspectral target detection [J]. *IEEE Trans. Geosci. Remote Sens.*, 2016, **54**(1): 330–342.
- [6] Chen Y, Nasrabadi N M, Tran T D. Sparse representation for target detection in hyperspectral imagery [J]. *IEEE J. Sel. Topics Signal Process.*, 2011, **5**(3): 629–640.
- [7] Zhang Y X, Du B, Zhang L P. A sparse representation-based binary hypothesis model for target detection in hyperspectral images [J]. *IEEE Trans. Geosci. Remote Sens.*, 2015, **53**(3): 1346–1354.
- [8] Zhang L F, Zhang L P, Tao D C, et al. Sparse transfer manifold embedding for hyperspectral target detection, [J]. *IEEE Trans. Geosci. Remote Sens.*, 2014, **52**(2): 1030–1043.
- [9] Winter M E. N-FINDR: an algorithm for fast autonomous spectral endmember determination in hyperspectral data [C]. In *Proc. SPIE*, 1999, **3753**: 266–275.
- [10] Shaw G A, Burke H H. Spectral imaging for remote sensing [J]. *Lincoln Lab. J.*, 2003, **14**(1): 3–28.
- [11] Wang T, Du B, Zhang L P. An automatic robust iteratively reweighted unstructured detector for hyperspectral imagery [J]. *IEEE J. Sel. Topics Appl. Earth Observ. Remote Sens.*, 2014, **7**(6): 2367–2382.
- [12] Yang S, Shi Z W, Tang W. Robust hyperspectral image target detection using an inequality constraint [J]. *IEEE Trans. Geosci. Remote Sens.*, 2015, **53**(6): 3389–3404.
- [13] Aharon M, Elad M, Bruckstein A. K-SVD: an algorithm for designing overcomplete dictionaries for sparse representation [J]. *IEEE Trans. Signal Process.*, 2006, **54**(11): 4311–4322.
- [14] Zou H, Hastie T, Tibshirani R. Sparse principal component analysis [J]. *J. Comp. Graph. Statist.*, 2006, **15**(2): 265–286.
- [15] Clark R N, Swayze G A, Gallagher A J, et al. The U.S. geological survey digital spectral library: Version 1: 0.2 to 3.0 μm [C]. U. S. Geol. Surv., Denver, CO, USA, Open File Rep. 1993, 93–592.
- [16] Mairal J, Bach F, Ponce J, et al. Online learning for matrix factorization and sparse coding [J]. *J. Mach. Learn. Res.*, 2010, vol. **11**(1): 19–60.