

基于稀疏表示和自适应模型的高光谱目标检测

李非燕, 霍宏涛*, 白杰, 王巍

中国人民公安大学信息技术与网络安全学院, 北京 100038

摘要 影响传统高光谱目标检测精度的因素主要有两个方面:一是高光谱图像固有的光谱畸变造成的图像噪声;另一个是传统方法在处理目标检测和利用空间信息时,会将异质区域与同质区域同等对待,然而异质区域却包含着不同的物质和光谱特征。为了解决以上问题,提出了一种将空间自适应模型与稀疏表示结合起来对高光谱图像目标进行检测的方法。首先,在重建信号时利用噪声的稀疏表示特性,最大限度地提取噪声中包含的有用信息,以确保重建信号的特征更加丰富,并接近源信号;其次,提出了一种空间自适应权重模型,并用它来检测中心像素点同周围邻域不同像素的相似度,最大限度地利用空间邻域像素之间的关系。最终的实验结果表明,所提方法比传统的稀疏表示高光谱目标检测方法更具稳健性。

关键词 遥感; 高光谱图像; 稀疏表示; 空间自适应模型; 目标检测

中图分类号 TP751.1

文献标识码 A

doi: 10.3788/AOS201838.1228004

Hyperspectral Target Detection Based on Sparse Representation and Adaptive Model

Li Feiyan, Huo Hongtao*, Bai Jie, Wang Wei

Information Technology and Cyber Security Academy, People's Public Security University of China, Beijing 100038, China

Abstract There exist two factors influencing the accuracy of conventional hyperspectral target detection. One is the inherent image noises induced by spectral distortion, and the other is the equal contributions of all adjacent pixels in the heterogeneous region. However, in fact the heterogeneity implies that the pixels are composed of different materials and possess different spectral characteristics. To address these problems, we propose a hyperspectral target detection method by the combination of spatially adaptive model and sparse representation. The noise sparse representation is utilized to reconstruct an accurate signal, in which the useful information in noises is extracted as possible to make the reconstructed signal be full of more features and be close to the original signal. In addition, a spatially adaptive weighted model is proposed to detect the similarity between central pixel and neighboring pixels, and to make full use of the relationship among neighboring pixels. The final experimental results show that the proposed method possesses a strong robustness compared with the conventional hyperspectral target detection methods.

Key words remote sensing; hyperspectral image; sparse representation; spatially adaptive model; target detection

OCIS codes 280.4788; 100.4145; 100.5010; 300.6170

1 引 言

高光谱图像(HSI)具有很高的光谱分辨率,通常包含数百个连续波段,从红外线到紫外线进行连续的光谱覆盖,所以高光谱图像与多光谱图像相比在目标检测方面更具优势。当其空间分辨率低至

1 m时,高光谱图像的超高光谱分辨率意味着借助它可以更加精确地确定地面物体的属性,所以在材料分类、地质特征识别和环境监测等^[1-2]方面都具有重要应用。高光谱图像的目标检测问题可以看成是一个二分类问题,传统高光谱图像目标检测精度较低的主要原因有以下几点:一是传感器的性能、光照

收稿日期: 2018-04-23; 修回日期: 2018-07-17; 录用日期: 2018-07-20

基金项目: 高分辨率对地观测系统重大专项(民用部分)项目(01-Y3XXXX-XX01-14/16); 国家重点研发计划(2017YFC0822405); 公安部技术研究计划(2018JSYJA01)

* E-mail: huotony@163.com

等自然条件的影响不可避免;二是高光谱图像具有很高的光谱维度,光谱特征丰富,但冗余度也较高;三是目标像素通常较少,且容易被一些加性噪声破坏,样本目标的数量不足以做出假设性的概率分布^[3]。稀疏表示(SR)可以用少量的训练样本有效地重建信号,已被广泛应用于高光谱图像分类和目标检测领域。

Chen 等^[4]采用稀疏表示模型对高光谱图像进行目标检测,利用目标、背景联级字典对训练样本进行稀疏分解,得到稀疏向量,然后利用稀疏向量和测试样本重建稀疏表示过程,通过比较背景重构误差与目标重构误差来确定测试样本的类别。这种方法利用了相邻高光谱像素的平滑度信息,虽然与传统方法相比提高了检测精度,但没有充分利用空间信息。Zhang 等^[5]提出了基于二元假设的稀疏表示模型(SRBBH),利用背景假设和目标-背景假设得到联合字典,当目标为亚像元或目标像素占整幅图像的比例非常小时,这种方法能够有效提高目标的检测精度,并能在一定程度上解决混合像元的问题,但期望目标的像素分布密集且均匀。宋琳等^[6]提出利用自回归模型和 8 邻域空间模型,以便进一步利用高光谱的空间信息提高分类精度,但是为了简化结果,邻域内各个像素点的权重值相同。Niu 等^[7]提出了基于自完备背景字典(SCBD)的自适应权重学习(AWLM)方法,在该方法中,AWLM 根据目标像素的不同特性,学习与目标像素相关的自适应权重,然后构建 SCBD,用来保证 AWLM 的收敛,这种方法减小了检测模型对背景先验信息的依赖度,但涉及 3 个算法的求解,计算比较复杂,收敛困难。李铁等^[8]和赵春晖等^[9]分别从分层稀疏表示和字典递归更新出发,充分挖掘高光谱图像中隐含的信息,提高了检测精度。

为了充分利用光谱信息和局部空间信息,同时考虑到目标像素领域内光谱特征的相似性(同质性)以及目标周围的像素由不同的地物组成这一情况(异质性),本文将最大相关熵准则注入空间相关信息,并将高维非线性特征空间转换为线性特征空间^[10],这时的线性空间可由给定的二元假设字典进行稀疏分解,通过稀疏重建过程本身具有的区分特性来决定目标像素的类别。这种方法充分考虑了邻域范围内像素之间的空间相关性,通过利用邻域像素与中心像素的相似度确定不同的权重,保证了与中心像素更相似的邻域像素可更大程度地影响检测结果,提高目标检测的精度。

2 基本原理

2.1 稀疏表示模型

由信号处理理论可知,信号可以用基字典的线性组合表示,这在遥感图像领域同样适用^[11]。之所以利用稀疏表示理论对遥感图像进行目标识别,是因为稀疏重建过程具有天然的辨别性。这种辨别性是基于一个潜在的前提,即测试样本理论上能被由其同类训练样本训练得到的字典线性表示^[12]。稀疏表示旨在寻找给定信号的稀疏解:

$$\min \| \mathbf{g} \|_0 \quad \text{s.t.} \quad \mathbf{y} = \mathbf{D} \mathbf{g}, \quad (1)$$

式中: \mathbf{g} 为系数向量表示; l_0 范式 $\| \cdot \|_0$ 为向量中非零原子的个数,也叫做稀疏度; \mathbf{y} 为待观测信号; \mathbf{D} 为字典。由于 l_0 最小化求解问题是非确定性多项式(NP)难问题,而且 l_1 范数为 l_0 范数的最优凸近似^[13],所以(1)式中的求解问题就可以松弛为

$$\min \| \mathbf{g} \|_1 \quad \text{s.t.} \quad \mathbf{y} = \mathbf{D} \mathbf{g}. \quad (2)$$

此时, $\| \mathbf{g} \|_1 = \sum_{i=1}^n |g_i|$, n 为向量中元素的个数。

(2)式可由正交匹配追踪(OMP)算法求解。由于目标检测属于二分类问题,高光谱图像中存在背景和目标两类低维子空间,所以对于一个测试像素向量 \mathbf{y} ,可用背景与目标字典的线性组合表示:

$$\begin{aligned} \mathbf{y} &= \mathbf{d}_1^b \alpha_1 + \mathbf{d}_2^b \alpha_2 + \cdots + \mathbf{d}_{N_b}^b \alpha_{N_b} + \\ &\quad \mathbf{d}_1^t \beta_1 + \mathbf{d}_2^t \beta_2 + \cdots + \mathbf{d}_{N_t}^t \beta_{N_t} = \\ &\quad [\mathbf{d}_1^b \quad \mathbf{d}_2^b \quad \cdots \quad \mathbf{d}_{N_b}^b] [\alpha_1 \quad \alpha_2 \quad \cdots \quad \alpha_{N_b}]^T + \\ &\quad [\mathbf{d}_1^t \quad \mathbf{d}_2^t \quad \cdots \quad \mathbf{d}_{N_t}^t] [\beta_1 \quad \beta_2 \quad \cdots \quad \beta_{N_t}]^T = \\ &\quad \mathbf{D}^b \boldsymbol{\alpha} + \mathbf{D}^t \boldsymbol{\beta} = [\mathbf{D}^b \mathbf{D}^t] \begin{bmatrix} \boldsymbol{\alpha} \\ \boldsymbol{\beta} \end{bmatrix} = \mathbf{D} \mathbf{g}, \end{aligned} \quad (3)$$

式中: N_b 和 N_t 分别为背景训练样本和目标训练样本的数量; \mathbf{D}^b 和 \mathbf{D}^t 分别为背景字典和目标字典,随机地将训练样本中的部分像素点作为初始字典中的基; $\boldsymbol{\alpha}$ 和 $\boldsymbol{\beta}$ 为未知向量,分别为背景字典和目标字典相对应原子的丰度; \mathbf{D} 为由 \mathbf{D}^b 和 \mathbf{D}^t 联级得到的字典。理论上讲,当测试像素 \mathbf{y} 属于背景中的像素时,由(3)式最终求解的 $\boldsymbol{\alpha}$ 是含有少量非零元素的向量,而 $\boldsymbol{\beta}$ 则为元素都是零的向量;相反,当测试像素 \mathbf{y} 属于目标像素时,求解得到 $\boldsymbol{\beta}$ 中有稀疏的非零元素,而 $\boldsymbol{\alpha}$ 为零向量。由于 $\boldsymbol{\alpha}$ 和 $\boldsymbol{\beta}$ 是稀疏向量,因此 \mathbf{g} 也是稀疏的。

使用稀疏表示理论时,噪声 \mathbf{n} 可以有效地处理畸变等问题^[14]。在遥感图像的应用中,受光照和大气的影 响,最后得到的图像光谱会出现不同程度的

畸变,所以在实际应用中,重建信号并不完全等于测试信号,故测试信号 y 的表达式为

$$y = Dg + n, \quad (4)$$

式中: n 为误差(噪声)向量。假设误差向量 n 也可以进行稀疏表示,则向量 g 能求得最稀疏的解为

$$\begin{aligned} \operatorname{argmin}_g \|Dg + n - y\|_2 \quad \text{s.t.} \\ \|g\|_0 \leq K_0 \text{ and } \|n\|_0 \leq K_0, \end{aligned} \quad (5)$$

式中: K_0 为稀疏度。

图 1(a) 是未加入误差向量稀疏表示的原始像素(实线)和稀疏重建像素(虚线)之间的对比图,原始像素包含 170 个波段。图 1(b) 是加入误差向量稀疏表示后的原始像素和重建像素的对比图。图 1(a) 和图 1(b) 重建残差的均方根误差(MSE)分别为 8.11×10^{-4} 和 3.79×10^{-4} 。从图 1 中可以看出,通过对误差向量进行稀疏表示,可以使向量 g 接近更本质的稀疏解,使得重建误差最小。

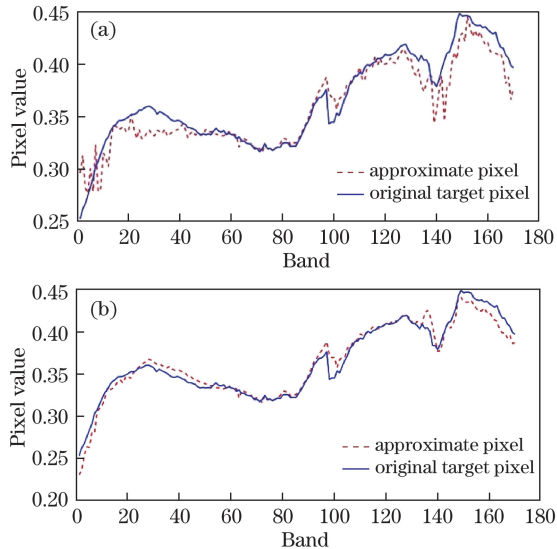


图 1 (a) 未加入误差向量的稀疏表示;
(b) 加入误差向量后的稀疏表示

Fig. 1 (a) Sparse representation without error vector;
(b) sparse representation with error vector

2.2 目标重建与检测

由于目标检测属于二分类问题,所以分别由背景训练样本和目标训练样本分解得到两个稀疏向量 α 和 β , 对应得到的两个重建残差为

$$r_b = \|y - D\alpha\|_2, \quad (6)$$

$$r_t = \|y - D\beta\|_2. \quad (7)$$

通过比较两个重建残差可以最终确定测试样本的类别。比较两个重建残差的表达式为

$$r = r_b - r_t. \quad (8)$$

由于对误差向量进行稀疏表示的目的是使 $g =$

$[\alpha^T \ \beta^T]^T$ 得到最稀疏解,所以重建过程不涉及误差向量的重建。当 $r_b \ll r_t$ 时,测试样本很明显属于背景,所以当 r 小于给定的阈值时,测试样本属于背景;反之,测试样本属于目标。

2.3 基于相关熵的空间自适应模型

文献[14]-[16]在高光谱图像分类中利用了空间信息,而文献[4]在高光谱图像目标的检测中,假设所有邻域范围内的像素的光谱特征是相似的,即同质,但在实际情况中,即使在小的邻域范围内,也存在不同质的像素。如图 2 所示,在第 2 个数据集中 3×3 的邻域像素内随机选取 4 个像素(数据集详见 3.2 节),虽然领域内的大部分像素通常包含相似或相同的光谱特性,如 x_1 、 x_2 和 x_3 ,但是依然存在光谱特性差别很大的像素,如 x_4 。基于此,提出了相关熵空间模型,根据不同的光谱特性对邻域内的像素分配不同的权重,这充分考虑到了相邻像素之间空间信息^[17]的同质性和异质性。




图 2 光谱曲线

Fig. 2 Spectral profiles

相关熵可以用来估计数据的分布,是度量任意两个向量 a 、 b 之间相似度的一种方法^[14],定义如下:

$$f(a, b) = \frac{1}{B} \sum_{i=1}^B k_\sigma(a_{j,k} - b_{l,m}). \quad (9)$$

式中: B 为波段数; $k_\sigma(\cdot)$ 为满足 Mercer 定理的高斯核函数, $k_\sigma(x) = \exp[-\|x\|^2 / (2\sigma^2)]$; $\sigma = 0.05$ 时可同时兼顾同质信息和异质信息; $b_{l,m}$ 为中心像素, $a_{j,k} = [b_{l-1,m-1}, b_{l-1,m}, b_{l-1,m+1}, b_{l,m-1}, b_{l,m+1}, b_{l+1,m-1}, b_{l+1,m}, b_{l+1,m+1}]$, 如图 3 所示; j, k, l, m 分别为像素位置坐标。

用 sigmoid 函数进行归一化处理:

$$S[f(a, b)] = \frac{1}{1 + \exp[-f(a, b)]}. \quad (10)$$

为了提高算法的运行效率,直接丢弃一些权重较小的像素,因为它们对目标检测最终结果的影响




图 3 计算相似度示意图

Fig. 3 Schematic of similarity calculation

较小。考虑到光照、传感器等会使光谱发生轻微畸变,当像素权重高于一定阈值时就认为其与测试样本完全相同。权重的表达式为

$$W = \begin{cases} 0, & \text{if } 0 \leq S(x) < t_1, \\ S(x), & \text{else if } t_1 \leq S(x) < t_2, \\ 1, & \text{else if } t_2 \leq S(x) \leq 1, \end{cases} \quad (11)$$

式中: t_1 和 t_2 为阈值,通过调整阈值的大小可以提高目标检测的精度。实验表明,在大多数情况下,当 $t_1=0.2$ 及 $t_2=0.8$ 时能得到满意的结果。此时自适应权重模型满足:

$$AW = DG + N, \quad (12)$$

$$\operatorname{argmin}_{\mathbf{G}} \|\mathbf{AW} - \mathbf{DG} - \mathbf{N}\|_2 \quad \text{s.t.}$$

$$\|\mathbf{G}\|_{\text{row},0} \leq K_0 \text{ and } \|\mathbf{N}\|_0 \leq K_0, \quad (13)$$

式中: \mathbf{A} 为包含 3×3 领域内所有像素的矩阵; \mathbf{W} 为权重矩阵; \mathbf{D} 为字典; $\mathbf{G} = [\mathbf{g}_1 \ \mathbf{g}_2 \ \cdots \ \mathbf{g}_9]$ 为待重建的稀疏矩阵; $\mathbf{N} = [\mathbf{n}_1 \ \mathbf{n}_2 \ \cdots \ \mathbf{n}_9]$ 为包含邻域内所有误差向量的矩阵。结合(5)式,最终的求解结果为

$$\operatorname{argmin}_{\mathbf{G}} \|\mathbf{DG} + \mathbf{N} - \mathbf{A}\|_2 + \lambda \|\mathbf{DG} + \mathbf{N} - \mathbf{AW}\|_2 \quad \text{s.t.}$$

$$\|\mathbf{G}\|_{\text{row},0} \leq K_0 \text{ and } \|\mathbf{N}\|_0 \leq K_0, \quad (14)$$

其中的 λ 旨在均衡稀疏表示光谱约束与空间约束。基于相关熵的方法可以在空间约束上充分考虑不同像素表现的差异性,对与测试样本同质的像素自适应地赋予更大的权重,以提高检测精度。

综上,整个算法流程如下:

1) 输入背景和训练样本矩阵: $\mathbf{X}_b, \mathbf{X}_t \in \mathbf{R}^{m \times n \times B}$;

2) 迭代。①归一化处理后,用无学习过程求解目标字典 \mathbf{D}_t ,用有学习过程求解背景字典 \mathbf{D}_b ,将两个字典进行联级得到全局字典 \mathbf{D} ;②采用(5)式利用 OMP 算法求解每个像素点对应的稀疏向量 \mathbf{g} ,得到稀疏矩阵 \mathbf{G} ;③将邻域窗口设为 3×3 ,在此窗口范围内逐点检测像素点,采用(9)~(11)式获得像素点的权重;④采用(14)式更新稀疏矩阵 \mathbf{G} ;⑤分别使用目标字典和背景字典计算重建误差,比较重建误差

的大小,确定中心像素的类别。

3 实验结果与分析

实验部分使用真实高光谱图像进行目标检测,将所提出的基于稀疏表示与相关熵自适应空间权重的方法(SR-CSAW),与传统稀疏表示检测模型(SRTD)、基于二元假设的稀疏表示模型(SRBBH)、基于自完备背景字典的自适应权重学习方法(SCBD-AWLM)进行比较,借助 ROC(Receiver operating characteristic)曲线评估算法的性能。

3.1 合成数据集

实验 1 所用的数据高光谱数据^[18]共有 384 个波段,去掉坏波段和吸水带(波段 199~221,272~351,363~372 和 377~384)共 121 个波段后还剩 263 个波段。原始图像中的目标只有 1 个,隐藏在树林中,所以使用目标植入法^[19]合成具有 3 个目标的高光谱图像。图像大小为 100 pixel \times 100 pixel,如图 4(c)所示。




图 4 合成数据集。(a)用于合成的原始目标;

(b)合成后的图像;(c)目标真值图

Fig. 4 Synthetic data set. (a) Original target for synthesis;

(b) synthetic image; (c) target truth map

稀疏度 K_0 分别为 3、5、7、9、11、13、15、17、19、21、23 时的 AUC(area under curve)曲线如图 5(a)所示,可见:AUC 值先随着稀疏度增大而增大,当稀疏度为 15 时,AUC 值达到最大;随着稀疏度继续增大,AUC 值开始减小。在本研究中,不同的稀疏表示方法设置相同的稀疏度: $K_0 = 15$ 。从图 5(b)可以看到,平衡因子 λ 的取值会对检测结果产生影响, $\lambda = 0.6$ 时所提方法的效果最好。

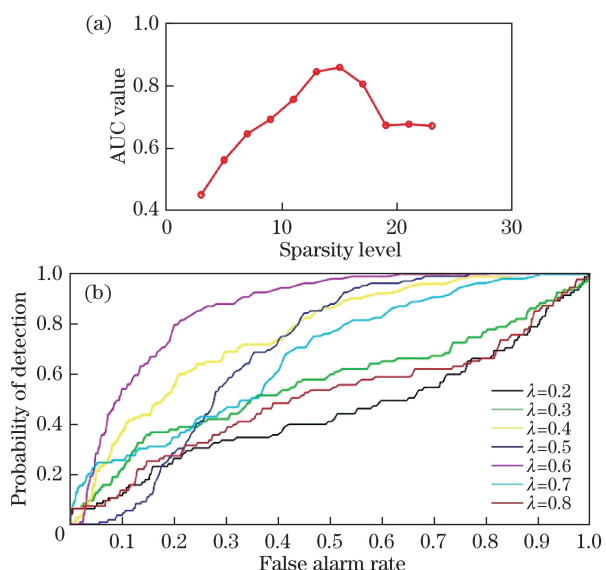


图 5 (a)不同稀疏度对应的 AUC 值;
(b)不同 λ 值对应的 ROC 曲线

Fig. 5 (a) AUC value at different sparsity levels;
(b) ROC curves at different λ

图 6 展示了不同方法的检测结果,可见:SRTD 和 SRBBH 的检测结果稍差,SCBD-AWLM 的检测效果相对较好;由于充分考虑到了空间信息,所提方法的检测效果优于 SCBD-AWLM。通过分析 4 种检测方法的 ROC 曲线可以得到定量的结果,如图 7 所示。在细节上,SCBD-AWLM 检测出了 69.72% 的目标像素,29 个错误像素,但所提方法检测出了大于 82.57% 的目标像素,有 33 个错误像素。总体




图 6 不同方法的检测结果。(a) SRTD;(b) SRBBH;
(c) SCBD-AWLM;(d)所提方法

Fig. 6 Detection results using different methods. (a) SRTD;
(b) SRBBH; (c) SCBD-AWLM; (d) proposed method

来说,SCBD-AWLM 检测的错误像素更少,所提方法检测出的目标像素的比例更大。图 7 中的 ROC 曲线进一步印证了以上结果。




图 7 不同检测方法对应的 ROC 曲线

Fig. 7 ROC curves corresponding to different methods

3.2 实验 2

实验 2 所用数据来自加利福尼亚州圣地亚哥机场的 AVIRIS 高光谱图像的的子图像,共 224 个波段,空间分辨率为 3.5 m。从图 8 中可以看出,测试样本图像大小为 80 pixel \times 80 pixel,3 架飞机(共 57 个像素)被选为目标。去掉吸水带、坏波段和低信噪比的波段,选取波段 36~96,98~116,114~152 共 119 个波段进行实验。




图 8 (a) AVIRIS 数据集和(b)目标真值

Fig. 8 (a) AVIRIS dataset and (b) target truth map

图 9(a)展示了不同稀疏度对应的 AUC 值, $K_0=15$ 时的 AUC 值最大。为了得到更精确的实验结果,这 4 种方法的稀疏度都被设置为 15。图 9(b)表明,除了 $\lambda=0.2$ 之外,大部分的 λ 都能取得稳定的结果。这可能是由于第 1 个实验数据有隐藏的目标,而 AVIRIS 相比第 1 个实验数据的目标结构更为简单。

图 10 展示了 4 种方法的实验结果,可以直观地看出:所提方法检测出的错误像素比其他方法少。图 11 是 4 种方法相应的 ROC 曲线,进一步印证了以上结论。其中,SCBD-AWLM 方法在 ROC 曲线上的表现比 SRBBH 方法差,这是因为 SCBD-AWLM 方法太复杂,收敛太慢。




图 9 (a)不同稀疏度对应的 AUC 值;
(b)不同 λ 值对应的 ROC 曲线

Fig. 9 (a) AUC value at different sparsity levels;
(b) ROC curves at different λ




图 10 AVIRIS 数据集的检测结果。(a) SRTD;
(b) SRBBH;(c) SCBD-AWLM;(d)所提方法

Fig. 10 Detection results for AVIRIS dataset. (a) SRTD;
(b) SRBBH; (c) SCBD-AWLM; (d) proposed method

为了进一步比较 4 种方法的性能,分别计算了两种数据集采用不同方法检测时对应的 AUC 值,如表 1 所示。AVIRIS 数据的 AUC 值比合成数据的结果更高,这是因为合成数据的目标属性更具多样性,包括 2 辆裸露的坦克和隐藏在树林中的坦克,而训练样本仅包含裸露的坦克。对于合成数据集来说,两种基于空间邻域关系的方法优于其他两种方法,也证明了所提方法对隐藏目标的检测具有稳健




图 11 AVIRIS 数据集采用不同检测方法时对应的 ROC 曲线

Fig. 11 ROC curves for AVIRIS dataset using different methods

表 1 不同数据集采用不同方法时对应的 AUC 值

Table 1 AUC value for different methods and datasets

Method	AUC	
	Synthetic	AVIRIS
SRTD	0.5652	0.7695
SRBBH	0.6752	0.9327
SCBD-AWLM	0.8078	0.9119
Proposed method	0.8617	0.9734

性。另外,对于 AVIRIS 数据集来说,所提方法比其他稀疏表示方法的检测结果更好。

4 结 论

本课题组提出了一种将稀疏表示与空间信息联合起来的方法。考虑到高光谱图像存在不同程度的光谱畸变,对噪声进行稀疏分解,以便得到最稀疏解,使重建信号与原始信号的误差更小,提高最终的检测精度。同时,考虑到不同像素对最终检测结果的贡献,为不同的像素分配不同的权重。将所提方法应用在两个高光谱图像数据集中,结果证明所提方法在定量和定性分析上都优于传统的稀疏表示方法。实验结果表明,基于最大相关熵的稀疏表示模型是学习像素之间空间和光谱关系的一种创新方法,在不同的目标检测中都表现出较高的精度。在未来的工作中,本课题组将研究这种方法在纹理、形状特征不明显的弱小目标识别上的应用。

参 考 文 献

[1] Fu L T, Liu C. Novel fast real-time target detection and classification algorithm for hyperspectral imagery[J]. Acta Optica Sinica, 2017, 37(2): 0230002.
付立婷, 刘春. 基于逐行处理的高光谱图像快速实时目标探测与分类方法[J]. 光学学报, 2017, 37(2): 0230002.

- [2] Charles A S, Olshausen B A, Rozell C J. Learning sparse codes for hyperspectral imagery[J]. IEEE Journal of Selected Topics in Signal Processing, 2011, 5(5): 963-978.
- [3] Dimitris M, David M, Gary A S. Hyperspectral image processing for automatic target detection applications[J]. Lincoln Laboratory Journal, 2003, 14(1): 79-116.
- [4] Chen Y, Nasrabadi N M, Tran T D. Sparse representation for target detection in hyperspectral imagery[J]. IEEE Journal of Selected Topics in Signal Processing, 2011, 5(3): 629-640.
- [5] Zhang Y X, Du B, Zhang L P. A sparse representation-based binary hypothesis model for target detection in hyperspectral images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2015, 53(3): 1346-1354.
- [6] Song L, Cheng Y M, Zhao Y Q. Hyper-spectrum classification based on sparse representation model and auto-regressive model [J]. Acta Optica Sinica, 2012, 32(3): 0330003.
宋琳, 程咏梅, 赵永强. 基于稀疏表示模型和自回归模型的高光谱分类 [J]. 光学学报, 2012, 32(3): 0330003.
- [7] Niu Y B, Wang B. Extracting target spectrum for hyperspectral target detection: an adaptive weighted learning method using a self-completed background dictionary[J]. IEEE Transactions on Geoscience and Remote Sensing, 2017, 55(3): 1604-1617.
- [8] Li T, Sun J G, Zhang X J, *et al.* Research of hyperspectral image classification based on hierarchical sparse representation feature learning[J]. Laser & Optoelectronics Progress, 2016, 53(9): 091001.
李铁, 孙劲光, 张新君, 等. 基于分层稀疏表示特征学习的高光谱图像分类研究 [J]. 激光与光电子学进展, 2016, 53(9): 091001.
- [9] Zhao C H, Yao X F, Zhang L L. Target detection sparse algorithm by recursive dictionary updating and GPU implementation[J]. Acta Optica Sinica, 2016, 36(8): 0828002.
赵春晖, 姚渐峰, 张丽丽. 采用字典递归更新的目标检测稀疏算法及 GPU 实现 [J]. 光学学报, 2016, 36(8): 0828002.
- [10] Zhao C H, Li W, Li X H, *et al.* Sparse representation based on stacked kernel for target detection in hyperspectral imagery[J]. Optik-International Journal for Light and Electron Optics, 2015, 126(24): 5633-5640.
- [11] Mallat S. A wavelet tour of signal processing: the sparse way[M]. Dai D Q, Yang L H, Transl. Beijing: China Machine Press, 2012: 1-36.
马拉特. 信号处理的小波导引: 稀疏方法 [M]. 戴道清, 杨力华, 译. 北京: 机械工业出版社, 2012: 1-36.
- [12] Zhang Y M, Du B, Zhang Y X, *et al.* Spatially adaptive sparse representation for target detection in hyperspectral images[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(11): 1923-1927.
- [13] Candes E J, Tao T. Decoding by linear programming[J]. IEEE Transactions on Information Theory, 2005, 51(12): 4203-4215.
- [14] He R, Zheng W S, Hu B G. Maximum correntropy criterion for robust face recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2011, 33(8): 1561-1576.
- [15] Wang P, Xu S, Li Y M, *et al.* Hyperspectral image classification based on joint sparsity model with low-dimensional spectral-spatial features[J]. Journal of Applied Remote Sensing, 2017, 11(1): 015010.
- [16] Dong A G, Li J X, Zhang B, *et al.* Hyperspectral image classification algorithm based on spectral clustering and sparse representation[J]. Acta Optica Sinica, 2017, 37(8): 0828005.
董安国, 李佳逊, 张蓓, 等. 基于谱聚类 and 稀疏表示的高光谱图像分类算法 [J]. 光学学报, 2017, 37(8): 0828005.
- [17] Wang J J, Yang J C, Yu K, *et al.* Locality-constrained linear coding for image classification[C]// IEEE Computer Society Conference on Computer Vision and Pattern Recognition, San Francisco, 2010: 3360-3367.
- [18] Deng S B. ENVI remote sensing image processing method[M]. 2nd ed. Beijing: Higher Education Press, 2014: 372-376.
邓书斌. ENVI 遥感图像处理方法 [M]. 2 版. 北京: 高等教育出版社, 2014: 372-376.
- [19] Marcus S S, John P K. A method for assessing spectral image utility[J]. IEEE Transactions on Geoscience & Remote Sensing, 2009, 47(6): 1698-1706.