

中图分类号: TP751.1 文献标志码: A 文章编号: 1006-8961(2011)09-1632-05

论文索引信息: 蒲晓丰, 雷武虎, 张林虎, 周峰. 基于改进 RX 算法的高光谱异常检测 [J]. 中国图象图形学报, 2011, 16(9): 1632-1636

基于改进 RX 算法的高光谱异常检测

蒲晓丰^{1),2)}, 雷武虎^{1),2)}, 张林虎^{1),2)}, 周峰²⁾

¹⁾(电子工程学院脉冲功率激光技术国家重点实验室, 合肥 230037)

²⁾(电子工程学院, 合肥 230037)

摘要:针对 RX 算法中局部背景协方差矩阵估计的局限性, 提出一种改进的 RX (I-RX) 异常检测算法。基于奇异值分解 (SVD), 将高光谱图像投影到背景的正交子空间上, 获得仅包含噪声和异常的残留图像。在此基础上, 通过计算各样本的空间秩深度将残留图像划分为噪声背景和潜在异常两个样本集, 利用噪声背景集估计整幅图像的背景协方差矩阵, 并将潜在异常集作为测试样本进行异常检测。对模拟数据和真实高光谱数据进行了实验仿真, ROC 曲线表明, 在相同的虚警概率下, I-RX 算法的检测概率相较于 RX 平均提高了 2 倍左右。

关键词: 异常检测; 奇异值分解; 背景正交子空间; 空间秩深度; 高光谱图像

Anomaly detection based on improved RX algorithm in hyperspectral imagery

Pu Xiaofeng^{1),2)}, Lei Wuhu^{1),2)}, Zhang Linhu^{1),2)}, Zhou Feng²⁾

¹⁾(Electronic Engineering Institute, State Key Laboratory of Pulsed Power Laser Technology, Hefei 230037 China)

²⁾(Electronic Engineering Institute, Hefei 230037 China)

Abstract: Aiming to reduce the limitation in local background covariance matrix estimation of RX algorithm, an improved RX (I-RX) algorithm is proposed for anomaly detection in hyperspectral imagery. Based on a singular value decomposition (SVD), We firstly project the hyperspectral imagery onto the background orthogonal subspace to obtain the remaining imagery which only consists of noisy background and anomaly. On this basis, by calculating the spatial rank depth value of every sample, the remaining imagery can be divided into two sample sets: noise background set and potential anomaly set. Using the noise background set to estimate the background covariance matrix of the whole imagery and the potential anomaly set as test examples to be detected whether has anomaly or not. Numerical experiments are performed on simulated data and real hyperspectral data. The ROC curves demonstrate that the detection probability of I-RX algorithm is about 2 times than RX algorithm at the same false alarm rates.

Keywords: anomaly detection; singular value decomposition (SVD); background orthogonal subspace; spatial rank depth; hyperspectral imagery

0 引言

目前, 高光谱图像的目标检测技术是遥感数据

处理领域比较活跃的研究方向^[1-6]。按照目标光谱使用层次的不同, 目标检测可以分为光谱匹配检测和光谱异常检测。光谱匹配检测需要使用目标光谱特征的先验知识, 这在实际应用中受到了诸多限

收稿日期: 2010-06-29; 修回日期: 2010-11-17

基金项目: 安徽省自然科学基金(070415217)。

第一作者简介: 蒲晓丰(1984—), 男。电子工程学院光电工程专业硕士研究生, 主要研究方向为高光谱图像目标检测技术。

E-mail: pxf_555@sina.com。

制^[3],而在缺少目标和背景先验知识的条件下,检测处与背景存在明显光谱差异的小目标的异常检测技术成为了高光谱图像目标检测研究的重点。通常,异常检测算法首先是为背景进行建模,并将图像中不满足背景模型的像元认为是异常目标^[4],其中,最具代表性的就是 Reed 和 u 提出的 RX 算法^[5],它假设局部背景服从多元正态分布,通过估计局部背景的协方差矩阵来描述背景模型。但是,在实际应用过程中,局部背景中用于估计协方差矩阵的样本个数不足、样本的非单一性以及易受到异常数据的“污染”^[6]等因素都会严重影响背景协方差矩阵的估计,使得估计的协方差矩阵不能够准确描述背景模型,从而导致 RX 算法的检测性能下降。为解决上述问题,提出一种改进的 RX 异常检测算法(I-RX),利用线性子空间模型为背景建模,将高光谱图像投影到该子空间的正交子空间上,使得到的残留图像可以看做是由单一噪声背景数据和异常构成,通过对噪声数据和潜在异常数据进行分离,利用噪声数据估计整幅残留图像的协方差矩阵,计算潜在异常数据在全局背景下的马氏距离来检测异常。利用模拟数据和真实高光谱图像进行仿真验证了该算法的有效性。

1 线性子空间模型

设高光谱图像用矩阵 $X = [x_1, x_2, \dots, x_N]$ 表示,其中 x_i 为 L 维光谱列向量, N 为图像中像元的个数,通常 $N > L$ 。基于线性子空间模型^[7-8],认为高光谱图像可以在一个低维的子空间中描述, X 可以写为

$$X = BA + W \tag{1}$$

式中, $B = [u_1, u_2, \dots, u_D]$ 可以看做是背景子空间, u_i 为 L 维列向量, $D (D < L)$ 为背景子空间的维数, A 为线性系数, W 为误差矩阵(包含异常目标和噪声)。

B 的获取可以基于奇异值分解(SVD)实现,高光谱图像 X 可以分解为 3 个矩阵的乘积,即

$$X = U\Lambda V^T = \sum_{i=1}^D \sigma_i u_i v_i^T \tag{2}$$

式中, $U = [u_1, u_2, \dots, u_L]$ 为 $L \times L$ 的正交单位矩阵, $V = [v_1, v_2, \dots, v_L]$ 为 $N \times L$ 的正交单位矩阵, Λ 为 $L \times L$ 的对角阵,即 $\Lambda = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_D, \sigma_{D+1}, \dots, \sigma_L)$, σ_i 为 X 的奇异值,且 $\sigma_i \approx 0, i = D +$

$1, D + 2, \dots, L$ 。背景子空间维数 D 满足

$$\frac{\sum_{i=1}^D \sigma_i^2}{\sum_{i=1}^L \sigma_i^2} \times 100\% \geq \text{percent} \tag{3}$$

选择 $\text{percent} = 99.8\%$, U 的前 D 个列向量就构成了背景子空间 $B = [u_1, u_2, \dots, u_D]$ 。

2 I-RX 异常检测算法

利用正交子空间投影算法(OSP),将高光谱图像 X 投影到背景子空间 B 的正交子空间上,去除背景的影响^[9]

$$Y = P^T X \tag{4}$$

$$P = I - B(B^T B)^{-1} B^T$$

式中, I 为 $L \times L$ 维单位矩阵, Y 为高光谱图像去除背景后的残留图像,且只含有噪声和少量的异常信息。在 L 维空间中,残留图像的噪声数据服从数据“云团”式的分布,少量的异常则“游离”于数据云团之外,如图 1 所示。




图1 AVIRIS 数据去除背景后第 1,2,3 波段的散点图
Fig. 1 Scatter-plots of 1,2,3 band of AVIRIS data after removing backgrounds

这样,基于残留图像,建立二值假设

$$\begin{cases} H_0 : y_i = n & \text{异常存在} \\ H_1 : y_i = at + n & \text{异常不存在} \end{cases} \tag{5}$$

式中, $y_i \in Y$, n 为噪声向量, t 为异常向量, a 为系数。假设噪声和少量异常的分布具有相同的协方差和不同的均值,分别服从 L 维多元正态分布 $N(u_b, C_b)$ 和 $N(u_i, C_b)$,其中 u_b 和 u_i 分别为整个残留图像中噪声背景的均值和异常目标的均值, C_b 为整个残留图像噪声背景的协方差矩阵。I-RX 算法

的检测函数及相应的判别式为

$$IRX(r) = (r - \hat{u}_b)^T \hat{C}_b (r - \hat{u}_b) \begin{cases} > \eta & H_1 \\ \leq \eta & H_0 \end{cases} \quad (6)$$

式中, $r \in Y$ 为残留图像的 L 维测试数据, η 为判决阈值, \hat{u}_b 和 \hat{C}_b 分别是噪声背景的均值和协方差矩阵的估计值

$$\hat{u}_b = \frac{1}{M} \sum_{i=1}^M y_i \quad (7)$$

$$\hat{C}_b = \frac{1}{M} \sum_{i=1}^M (y_i - \hat{u}_b)(y_i - \hat{u}_b)^T \quad (8)$$

式中, M 为用于背景估计的样本个数。

3 分离背景和异常数据

为有效分离背景和潜在的异常数据,根据残留图像中噪声和异常在 L 维空间的分布情况,引入空间秩深度^[10]的概念来度量每个样本数据相对整个数据云团的空间位置,并将深度值较大的数据作为背景样本用于估计噪声背景的协方差矩阵,而深度值较小的数据则看做潜在的异常数据,用于异常

检测。

3.1 空间秩深度

文献[10]基于空间秩给出了一个数据深度,设 x 是 L 维的样本点 ($x \in R^d$),其相对于服从 L 维 P_n 分布的数据云团 $Y = [y_1, y_2, \dots, y_N]$, $x \in R^d$ ($x \notin Y$) 的空间秩深度可以写为

$$D(x, P_n) = 1 - \left[\frac{1}{N} \sum_{i=1}^N \frac{x - y_i}{x - y_i} \right]^2 \quad (9)$$

式中, y_i 是数据云团 Y 中第 i 个样本, N 是数据云团包含的样本个数。其主要具有如下性质^[8]:

- 1) 偏离云团无穷远处深度为 0;
- 2) 单调性。数据越靠近数据云团的表面,深度越小,这保证了异常数据具有较小的深度值。

为检验空间秩深度探测异常数据的能力,随机产生 510 个 2 维数据点作为数据集,其中,正常数据共 500 个,服从 $N((0,0), I)$ 分布,异常数据共 10 个,服从 $N((3,3), I)$ 分布,其分布如图 2(a) 所示。根据式(9)计算每个数据点相对整个数据云团的深度,不同深度的数据分布如图 2(b) 所示。

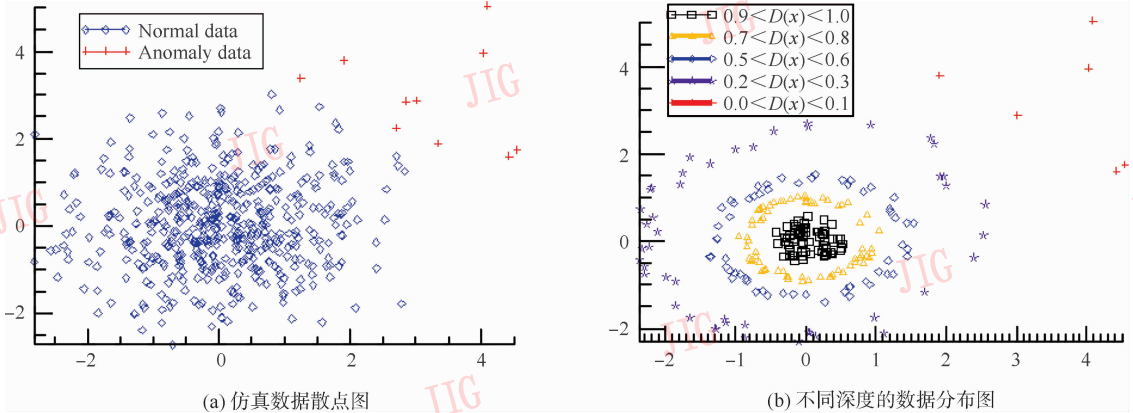


图 2 仿真数据及实验结果

Fig. 2 Simulated data and experimental results

从图 2(b) 中可以看出,空间秩深度能够很好的反映每个数据相对整个数据云团的位置,深度越大,越靠近云团的中心,反之亦然,异常数据“游离”于整个数据云团之外。同时,深度等高线在一定程度上也可以反映出数据云团的实际形状分布。

3.2 分离背景和异常数据

在残留图像中,异常存在两种形式:即全局异常和局部异常,为兼顾局部异常和全局异常的检测,同时考虑到计算空间秩深度的时间和空间的复杂度,

将残留图像划分为 N 个等面积的矩形块 $S = [S_1, S_2, \dots, S_N]$, 计算 S_j ($S_j \in S$) 中每个数据点 y_i ($y_i \in S_j, i = 1, 2, \dots, n$) 相对于其他 $n - 1$ 个数据点构成的数据云团的空间秩深度。将深度值小于预先设定的阈值 D_{cut} 的 K_j 个样本点 $Y_j^a = [y_1^a, y_2^a, \dots, y_{K_j}^a]$ 看做是潜在的异常数据;将深度值大于预先设定的阈值 D_{cut} 的 M_j 个样本点 $Y_j^b = [y_1^b, y_2^b, \dots, y_{M_j}^b]$ 看做是噪声背景样本。将所有矩形块中的噪声背景样本和潜在的异常数据分别进行合并,从而实现了对背景和异常数据的分离。其中, $Y^b = [Y_1^b, Y_2^b, \dots, Y_j^b, \dots, Y_N^b]$

作为背景的训练样本用于对噪声背景协方差矩阵的估计, $\mathbf{Y}' = [Y'_1, Y'_2, \dots, Y'_j, \dots, Y'_N]$ 作为测试数据用于式(6)进行异常检测。

4 实验分析

为检测算法的有效性,利用真实 AVIRIS 高光谱数据进行了仿真。实验中对原始图像选取 169 个波段并进行了截取,选取其中包含异常目标的一部分检测区域 (100×100),受实验条件的限制(异常目标分布的随机性),无法获得图像拍摄时场景中全部真实异常目标信息,实验只针对多边形内的区域,通过人为多波段观察和比较该区域内的像元的光谱曲线,确定共含有 38 个待检测的异常目标,其分布情况如图 3 所示。分别利用 RX 和 I-RX 算法进行仿真,其中, RX 算法中嵌套窗口的的外窗尺寸为 25×25 ,内窗尺寸为 5×5 ;在 I-RX 算法中,图像被分割为 $N = 25$ 个等面积的矩形块,空间秩深度阈值 $D_{\text{cut}} = 0.3$, $\text{percent} = 99.8\%$ 。RX 和 I-RX 算法的检测效果如图 4 所示。




图 3 高光谱数据

Fig. 3 Hyperspectral data

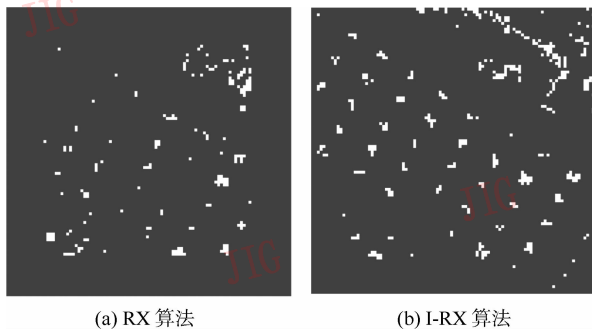


图 4 检测结果

Fig. 4 Detection results

利用接收机特性曲线(ROC)描述两个算法的检测概率 P_d 和虚警概率 P_f 之间的变化关系,对算法的检测性能进行定量分析。通过考察检测出的异常是否落入异常目标的分布区域来判断检测出的是真实目标还是虚警,将检测概率 P_d 定义为检测到真实目标像素个数 N_d 与实际目标像素个数 N_t 的比值;虚警概率 P_f 定义为检测的虚警像素个数 N_f 与目标区域内像素总数 N_{total} 的比值。

$$P_d = N_d/N_t \quad P_f = N_f/N_{\text{total}} \quad (10)$$

利用不同的阈值分割检测结果得到不同条件下的 P_d 和 P_f ,图 5 给出了 RX 算法和 I-RX 算法的 ROC 曲线的比较。可以看出,I-RX 算法通过将高光谱图像投影到背景的正交子空间上,有效抑制了背景地物的复杂性,利用空间秩深度将残留图像划分为噪声背景集和潜在异常集,以噪声背景集估计全局背景的协方差矩阵,克服了 RX 算法中背景估计的样本个数不足和背景易受异常“污染”的问题,因此具有更高的检测概率和较低的虚警概率。通过比较,在相同的虚警概率的条件下,I-RX 算法的检测概率相较于 RX 平均提高了 2 倍左右。

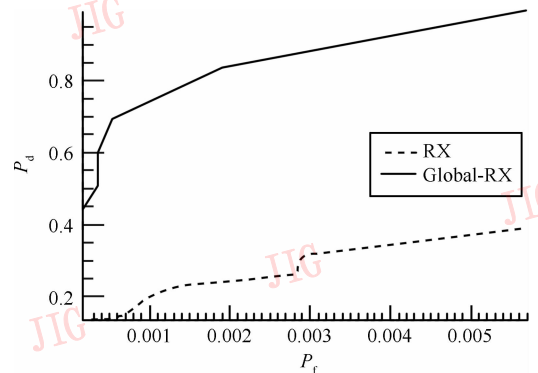


图 5 RX 和 I-RX 算法的 ROC 曲线

Fig. 5 ROC curves for RX and I-RX algorithms

其他参数不变,矩形块个数 N 对 I-RX 算法检测性能的影响,如图 6 所示。可以看出,当 $N = 25$ 时,算法的检测性能最好;当 $N = 4$, $N = 100$ 时,检测性能次之;当 $N = 400$ 时,检测性能最差。这是因为,当 N 值较大时,异常数据在各矩形块中占有较大的面积,使得部分异常数据被划分为噪声背景样本,用于背景协方差矩阵估计,导致异常被淹没在背景中,检测概率下降,在这种情况下可适当增大空间秩深度阈值以提高检测概率;当 N 值较大时,图像中的局部异常数据被划分为背景样本集中,导致算法能较好地检测出全局异常,而对局部异常数据出




图6 不同 N 值下I-RX算法的ROC曲线

Fig. 6 ROC curves for I-RX algorithm with different values of N

现漏警现象。在实际应用中,参数 N 和 D_{cut} 的选择一般是根据在各矩形块中估计的潜在异常数据占总样本的5%~9%左右来确定的。

本实验基于IDL7.1工具编程实现,在主频为2.66 GHz,内存为3 GB的计算机上运行,在各参数设置不变的情况下,RX算法需要的计算时间为194.687 s,I-RX算法(包括向背景正交子空间投影和计算空间秩深度)所需时间为166.516 s,体现出I-RX算法具有更好的时间效率。

5 结论

提出一种改进的RX算法(I-RX)用于高光谱图像异常检测,该算法将去除背景后的残留图像划分为噪声背景集和潜在异常集,利用噪声背景集估计背景的协方差矩阵,潜在异常集作为测试样本进行异常检测。通过理论分析以及仿真实验,结果表明,该算法中背景协方差矩阵的估计能准确反映残留图像的背景分布,避免出现RX算法中背景估计存在的问题,使得其检测性能明显优于RX算法。

下一步的工作将进一步研究参数 N 和 D_{cut} 之间的关系,以及对空间秩深度阈值 D_{cut} 进行自适应选择。

参考文献 (References)

- [1] Zhang L, Du B, Zhong Y. Hybrid detectors based on selective endmembers[J]. IEEE Transactions on Geoscience and Remote Sensing, 2010, 48(6): 2633-2646.
- [2] Du Bo, Zhang Liangpei, Li Pingxiang, et al. A constrained energy minimization method in sub-pixel target detection based on minimization noise fraction[J]. Journal of Image and Graphics, 2009, 14(9): 1850-1857. [杜博, 张良培, 李平湘, 等. 基于最小噪声分离的约束能量最小化亚像元目标探测方法[J]. 中国图象图形学报, 2009, 14(9): 1850-1857.]
- [3] Stein D W J, Beaven S G, Hoff L E, et al. Anomaly detection from hyperspectral imagery [J]. IEEE Signal Processing Magazine, 2002, 19: 58-69.
- [4] Madar E, Kuybeda O, Malah D, et al. Local-global background modeling for anomaly detection in hyperspectral images [C]// IEEE First Workshop on Hyperspectral Imagery and Signal Processing: Evolution in Remote Sensing. Grenoble, France: IEEE, 2009, 1-4.
- [5] Reed I S, Yu X. Adaptive multiple-band CFAR detection of an optical pattern with unknown spectral distribution [J]. IEEE Transactions on Acoustics, Speech and Signal Processing, 1990, 38(10): 1760-1770.
- [6] Matteoli S, Diani M, Corsini G. Improved covariance matrix estimation; interpretation and experimental analysis of different approaches for anomaly detection application [C]// Proceedings of SPIE conference on Image and Signal Processing for Remote Sensing XV. Berlin, DEU: SPIE, 2009, 7477: 74770K. 1-74770K. 9.
- [7] Healey G, Slater D. Models and methods for automated material identification in hyperspectral imagery acquired under unknown illumination and atmospheric conditions [J]. IEEE Transactions on Geoscience and Remote Sensing, 1999, 37(6): 2706-2717.
- [8] Thai B, Healey G. Invariant subpixel material detection in hyperspectral imagery [J]. IEEE Transactions on Geoscience and Remote Sensing, 2002, 40(3): 599-608.
- [9] Carolina P O, Miguel V R. Comparison of basis-vector methods for structural modeling of hyperspectral imagery [C]// Proceedings of SPIE conference on Imaging Spectrometry XIV. San Diego, USA: SPIE, 2009, 7457: 74570C. 1-74570C. 10.
- [10] Gao Yonghong. Data depth based on spatial rank [J]. Statistics & Probability Letters, 2003, 65(3): 217-225.