

引用格式: WANG Zhi-wei, TAN Kun, WANG Xue, *et al.* Unsupervised Nearest Regularized Subspace Based on Spectral Space Reconstruction for Hyperspectral Anomaly Detection[J]. *Acta Photonica Sinica*, 2020, **49**(6):0630004

王志威, 谭琨, 王雪, 等. 基于光谱空间重构的非监督最邻近规则子空间的高光谱异常检测[J]. 光子学报, 2020, **49**(6):0630004

基于光谱空间重构的非监督最邻近规则子空间的高光谱异常检测

王志威¹, 谭琨^{1,2}, 王雪^{1,2}, 丁建伟³, 陈宇¹

(1 中国矿业大学 自然资源部国土环境与灾害监测重点实验室, 江苏 徐州 221116)

(2 华东师范大学 地理信息科学教育部重点实验室, 上海 200241)

(3 河北省第二测绘院, 石家庄 050037)

摘要:针对高光谱遥感影像维数高、数据量巨大且地物分布复杂,导致背景与异常难以区分的问题,提出一种基于光谱空间重构的非监督最邻近规则子空间异常探测算法.首先通过基于结构张量的波段选择算法,去除噪声像元,选择更有效的波段.然后,通过光谱空间重构增加背景与异常的绝对光谱距离.最后,为了充分利用背景字典之间的空间相似性信息,将空间距离权重引入到非监督最邻近规则子空间算法中,提高检测精度.为验证所提算法的有效性,用四组真实的高光谱数据进行实验,研究了不同参数对检测结果的影响.结果表明,与其他异常检测算法对比,所提算法具有更好的检测效果.

关键词:高光谱影像;异常探测;波段选择;光谱空间重构;非监督最邻近规则子空间

中图分类号: TP751.1

文献标识码: A

doi: 10.3788/gzxb20204906.0630004

Unsupervised Nearest Regularized Subspace Based on Spectral Space Reconstruction for Hyperspectral Anomaly Detection

WANG Zhi-wei¹, TAN Kun^{1,2}, WANG Xue^{1,2}, DING Jian-wei³, CHEN Yu¹

(1 Key Laboratory of Land, Environment and Disaster Monitoring, Ministry of Natural Resources, China University of Mining and Technology, Xuzhou, Jiangsu 221116, China)

(2 Key Laboratory of Geographic Information Science, Ministry of Education, East China Normal University, Shanghai 200241, China)

(3 The Second Surveying and Mapping Institute of Hebei, Shijiazhuang, 050037, China)

Abstract: The high dimension and huge data volume of hyperspectral remote sensing images and the complexity of surface feature lead to difficulty in distinguishing the anomaly pixel from the background. To solve these problems, an unsupervised nearest regularized subspace anomaly detection algorithm based on spectral space reconstruction is proposed. Firstly, in the process of band selection based on structure tensor, noise pixels are removed to obtain more effective bands. Then, the spectral space reconstruction is utilized to increase the absolute spectral distance between the background and the anomaly. Finally, to take full advantage of the spatial similarity information between background dictionaries, the spatial distance weight is introduced into the unsupervised nearest regularized subspace algorithm to improve the accuracy of linear representation. To validate the effectiveness of the proposed algorithm, experiments on four sets of real hyperspectral data are conducted, and the influence of different parameters on the detection results is studied. Experimental results demonstrate that the

基金项目: 国家自然科学基金(Nos.41871337, 41471356)

第一作者: 王志威(1996—), 男, 硕士研究生, 主要研究方向为高光谱目标探测技术. Email: wangzw1215@163.com

导师(通讯作者): 谭琨(1981—), 男, 教授, 博士, 主要研究方向为高光谱遥感, 环境遥感. Email: tankuncu@126.com

收稿日期: 2019-12-09; 录用日期: 2020-03-02

proposed algorithm has a better detective performance than other anomaly detection algorithms.

Key words: Hyperspectral image; Anomaly detection; Band selection; Spectral spatial reconstruction; Unsupervised nearest regularized subspace

OCIS Codes: 300.6320; 100.4145; 110.4234

0 引言

高光谱遥感影像具有丰富的光谱信息,可以根据不同的光谱特性区分不同的地物,如车辆、舰船等,这些物体通常与自然背景材料具有不同的光谱特征,使高光谱影像目标检测成为区分地物的强有力手段^[1,2].异常目标检测是一种不需要任何先验信息即可检测感兴趣目标的方法,其本质是一个二分类问题,目的是将异常目标从背景中区分出来^[3,4].

高光谱异常检测算法的模型根据理论可分为三类:基于统计模型的检测算法、基于矩阵分解的检测算法和基于几何模型的检测算法^[5].由 REED I S 等提出的异常探测算法(Reed-Xiao li Detection, RXD)^[6]是应用最广泛的一种异常检测方法,它假设背景服从多元正态分布,异常值由待测像元与背景之间的马氏距离来测量.由于高光谱影像背景复杂,很多情况不满足正态分布.DU B 等提出基于随机选择的异常探测(Random Selection based Anomaly Detection, RSAD)算法^[7],通过随机选择背景构建初始背景子集,采用迭代方式更新背景子集,避免了异常像元对背景统计量的污染.基于矩阵分解的检测算法利用高光谱影像的低秩性,用稀疏分量来进行异常检测,进而精确获得目标^[8,9].SONG S 等提出基于卷积神经网络和低秩表示算法^[10],通过 CNN 模型提取丰度图并利用基于密度的聚类算法(Density Based Spatial Clustering of Applications with Noise, DBSCAN)构造字典,能够有效去噪和表示背景,最后利用低秩表示算法检测异常.

基于几何模型的方法认为背景可以由局部背景光谱向量线性表示,而异常目标不能被表示.LI W 等提出非监督最邻近规则子空间(Unsupervised Nearest Regularized Subspace, UNRS)算法^[11]和基于协同表示的异常探测(Collaborative Representation based Detection, CRD)算法^[12]应用于异常探测领域.MA Shi-xin 等^[13]提出利用基于密度的聚类算子对高光谱影像进行空谱预处理,通过平均差的自适应核协同算法有效地提高了协同表示算法的检测精度.TAN K 等^[14-15]提出基于协同表示和反距离权重的局部求和异常检测算法(Local Summation Anomaly Detection based on Collaborative Representation and Inversed Distance Weight, LSADCRIDW),通过采用双窗口滑动求和策略,将反距离权重引入到 CRD 算法中,提高了线性表示的精度,但是由于采用求和策略,运算时间算较长.

高光谱影像具有高维性、冗余性,使得计算代价较高.同时由于地表地物分布的复杂性,异常物体的尺寸小,导致异常像元是混合像元,其光谱与背景光谱特征相似,难以区分背景与异常目标.基于上述研究的不足,本文提出了一种基于光谱空间重构的非监督最邻近规则子空间异常检测算法(Unsupervised Nearest Regularized Subspace based on Spectral Space Reconstruction, UNRS-SSR).首先在基于结构张量的波段选择算法中通过去除噪声像元,选择更加有效的波段.其次,利用基于绝对距离的非负参数对光谱空间进行重构,使异常与背景之间的可分性增强.最后,将空间距离权重引入到非监督最邻近规则子空间算法中,充分利用背景字典之间的空间相似性信息,从而得到更好的检测结果.

1 基于光谱空间重构的非监督最邻近规则子空间算法

1.1 波段选择

由于高光谱影像波段的高维性、冗余性,同时每个波段描述地物的结构特征不同,需要选择结构特征精细的波段.因此,引入一种基于结构张量的波段选择算法^[16].结构张量表示为

$$\mathbf{S}_i^l = \begin{bmatrix} (H_i^l)^2_x & (H_i^l)_x (H_i^l)_y \\ (H_i^l)_y (H_i^l)_x & (H_i^l)^2_y \end{bmatrix} \quad (1)$$

式中, \mathbf{S}_i^l 表示像素 i 在第 l 波段的结构张量. $(H_i^l)_x = \frac{\partial H^l}{\partial x}$ 和 $(H_i^l)_y = \frac{\partial H^l}{\partial y}$ 表示第 l 个波段图像在像素 i 处沿 x 、 y 方向的导数.第 l 波段的结构张量 \mathbf{S}_i^l 可以分解为

$$\mathbf{S}_i^l = [\eta_{1,i}^l \quad \eta_{2,i}^l] \begin{bmatrix} \lambda_{1,i}^l & 0 \\ 0 & \lambda_{2,i}^l \end{bmatrix} \begin{bmatrix} \eta_{1,i}^l \\ \eta_{2,i}^l \end{bmatrix} \quad (2)$$

式中, $\lambda_{1,i}^l$ 和 $\lambda_{2,i}^l$ 表示像素 i 在第 l 波段的非负特征值, $\eta_{1,i}^l$ 和 $\eta_{2,i}^l$ 表示对应的特征向量. 用两个特征值的和可以检测目标的边缘区域. 由于迹等于非负特征值之和, 所以波段的迹可以表示为

$$T_l = \sum_{i=1}^S (\lambda_{1,i}^l + \lambda_{2,i}^l) \quad (3)$$

式中, S 表示高光谱影像中像元个数. T_l 是结构张量在第 l 波段的迹, 称为波段迹.

图 1(a) 为波段迹值曲线, 图 1(b) 为迹值最大的波段对应的单波段影像. 图 1(a)、(b) 表明迹值剧烈变化的波段含有大量噪声, 因此将两个红点之间的第 1~5 波段去除. 图 1(c) 为去除迹值剧烈变化的波段后选取的迹值最大的单波段影像, 所选波段包含的结构特征变化最多, 背景最少. 去除迹值剧烈变化的波段后, 选择的波段为

$$B_k = \operatorname{argmax}\{T_l | l = 1, 2, \dots, L\} \quad (4)$$

式中, L 代表高光谱影像中波段个数. 从所有波段中选择波段迹值最大的前 K 个波段, 波段集由 B_1, B_2, \dots, B_K 组成.





图 1 波段迹曲线与不同波段处的迹值矩阵
Fig.1 Band trace curve and trace value matrix at different bands

在求波段迹的过程中高光谱影像中含有噪声像元造成所选的波段并不准确. 通过在求波段迹的过程中引入噪声像元去除方法^[17], 有效去除噪声像元的迹对波段迹的影响. 基于统计学理论中, 高光谱影像的波段迹值矩阵 $\mathbf{T} \in \mathcal{R}^{S \times L}$ 服从高斯分布的假设, 通过计算所有迹值向量的均值与标准差来定义像元的迹值向量阈值的最大值和最小值, 即

$$\tau_{\max} = \mu + 3 \times \sigma \quad (5)$$

$$\tau_{\min} = \mu - 3 \times \sigma \quad (6)$$

式中, μ 和 σ 分别表示所有像元迹值的均值和标准差, τ_{\max} 和 τ_{\min} 分别代表最大阈值和最小阈值. 阈值之外的像元将会被视为噪声而去除, 从而选择最优波段. 如图 2(a)、(b) 所示, 通过 5 次随机选取 1 000 个像元计算去除噪声前后的波段迹曲线. 可以看到, 经过去除噪声之后, 波段迹值曲线更有规律. 图 2(c) 为噪声像元的位置, 其中噪声像元约占原始像元的 0.5%.





(c) Noise map

图 2 去噪前后波段迹曲线对比与噪声图

Fig.2 Comparison of band trace curve before and after denoising and noise map

1.2 光谱空间重构

由于地表地物分布的复杂性,异常物体的尺寸小,导致异常像是混合像元,而且异常像元的光谱与背景光谱特征相似,难以区分背景与异常目标.因此,对波段选择后的高光谱影像进行光谱空间重构,增加异常与背景之间的绝对光谱距离^[18],绝对光谱距离指的是两个像元光谱差值的绝对值.对于中心像元 $\mathbf{y} \in \mathbb{R}^{K \times 1}$, \mathbf{y} 周围的像元用 \mathbf{a}_i 表示.中心像元 \mathbf{y} 与周围像元 \mathbf{a}_i 之间的绝对光谱距离用 $|\mathbf{y} - \mathbf{a}_i|$ 表示,中心像元与周围像元的关系存在四种情况:

- 1) 如果中心像元 \mathbf{y} 属于背景,它周围的像元也属于背景,绝对光谱距离的和 $\sum |\mathbf{y} - \mathbf{a}_i|$ 趋近于 0;
 - 2) 如果中心像元 \mathbf{y} 属于背景,它周围的像元含有少量异常像元,绝对光谱距离的和 $\sum |\mathbf{y} - \mathbf{a}_i|$ 仍然很小;
 - 3) 如果中心像元 \mathbf{y} 为异常,其周围像元均为背景,绝对光谱距离的和 $\sum |\mathbf{y} - \mathbf{a}_i|$ 较大;
 - 4) 如果中心像元 \mathbf{y} 为异常,其周围像元含有少量背景像元,绝对光谱距离的和 $\sum |\mathbf{y} - \mathbf{a}_i|$ 仍然较大.
- 为了进一步增强绝对光谱距离,引入基于绝对距离的非负参数,定义为

$$\theta_i = 1 - e^{-10|\mathbf{y} - \mathbf{a}_i|} \quad (7)$$

式中,非负参数 θ_i 的范围从 0 到 1.如果 $|\mathbf{y} - \mathbf{a}_i|$ 的值相对较大,参数 θ_i 的值近似为 1.如果 $|\mathbf{y} - \mathbf{a}_i|$ 的值相对较小, θ_i 的值迅速减小.很明显 θ_i 可以保持更大的值,抑制一个较小的值.在第 1) 和 2) 的情况下,参数 θ_i 可以使得 $|\mathbf{y} - \mathbf{a}_i|$ 接近 0.在第 3) 和 4) 的情况下,参数 θ_i 接近 1, $|\mathbf{y} - \mathbf{a}_i|$ 仍然很大.因此,异常与背景之间的可分性通过乘子 θ_i 进一步增强,重构的光谱表示为

$$\mathbf{x}_i = \frac{1}{s} \sum_{i=1}^s \theta_i (\mathbf{y} - \mathbf{a}_i) = \frac{1}{s} \sum_{i=1}^s (1 - e^{-10|\mathbf{y} - \mathbf{a}_i|}) (\mathbf{y} - \mathbf{a}_i) \quad (8)$$

式中, s 表示内外双窗口之间背景像元的个数,即

$$s = \tau_{out} \times \tau_{out} - \tau_{in} \times \tau_{in} \quad (9)$$

式中, τ_{out} 表示外窗口的大小, τ_{in} 表示内窗口的大小.通常情况下异常像元是由几个相邻像元构成,如果仅采用单窗口,异常像元对背景字典造成污染,影响重构光谱的效果.因此采用内外双窗口模型,如图 3 所示.内




图 3 双窗口模型

Fig.3 The model of dual window

窗口的大小应该大于或等于异常目标,有效防止异常进入背景字典.利用外窗口控制中心像元的邻近像元个数,有效地增加异常与背景的绝对光谱距离.

1.3 非监督最邻近规则子空间算法

基于几何模型的异常检测算法认为所有背景像元光谱能够被其周围空间背景字典线性表示,而异常目标则不能被表示.算法建立在滑动双窗口模型的基础上,对于每个待测试像元 $\mathbf{y} \in \mathcal{R}^{K \times 1}$,其中 K 为经过波段选择后的波段个数,假设 $\tilde{\mathbf{y}}$ 可以被其背景字典 $\mathbf{X}_s \in \mathcal{R}^{K \times s}$ 线性表示, $\tilde{\mathbf{y}}$ 的表示形式为

$$\tilde{\mathbf{y}} = \mathbf{X}_s \boldsymbol{\beta} \quad (10)$$

式中, $\boldsymbol{\beta} \in \mathcal{R}^{s \times 1}$ 为每个背景像元的表示系数.只需求出表示系数 $\boldsymbol{\beta}$ 即可求得待测试像元 \mathbf{y} 的近似值 $\tilde{\mathbf{y}}$,因此该问题就转化为求解表示系数 $\boldsymbol{\beta}$ 的问题,即目标函数最小化的问题

$$f(\boldsymbol{\beta}) = \|\mathbf{y} - \mathbf{X}_s \boldsymbol{\beta}\|_2^2 = \left\| \mathbf{y} - \sum_{i=1}^s \beta_i \mathbf{x}_i \right\|_2^2 \quad (11)$$

以中心像元 \mathbf{y} 为中心对原始空间进行“平移”,求解 $f(\boldsymbol{\beta})$ 最小化的问题就转为

$$f(\boldsymbol{\beta}) = \left\| \sum_{i=1}^s \beta_i (\mathbf{x}_i - \mathbf{y}) \right\|_2^2 = \left\| \sum_{i=1}^s \beta_i \mathbf{z}_i \right\|_2^2 = \boldsymbol{\beta}^T \mathbf{Z} \mathbf{Z}^T \boldsymbol{\beta} \quad (12)$$

式中, $\mathbf{z}_i = \mathbf{x}_i - \mathbf{y}$, $\mathbf{Z} \mathbf{Z}^T$ 为对称矩阵,称为 Gram 矩阵,通常用 \mathbf{G} 表示.为了找到更好的系数向量 $\boldsymbol{\beta}$,在式(12)中添加系数向量 $\boldsymbol{\beta}$ 的正则约束项,得到修正代价函数

$$f(\boldsymbol{\beta}, \lambda) = \boldsymbol{\beta}^T \mathbf{G} \boldsymbol{\beta} + \lambda \boldsymbol{\beta}^T \boldsymbol{\beta} \quad (13)$$

式中, λ 为拉格朗日乘子,用于控制目标函数与正则约束项之间的权重.为了求解系数向量 $\boldsymbol{\beta}$,采用拉格朗日法,并在和为一约束条件下,将其转化为求极值问题

$$L(\boldsymbol{\beta}, \lambda_0, \lambda) = \boldsymbol{\beta}^T \mathbf{G} \boldsymbol{\beta} + \lambda \boldsymbol{\beta}^T \boldsymbol{\beta} - \lambda_0 (\mathbf{1}_{s \times 1}^T \boldsymbol{\beta} - 1) \quad (14)$$

式中, $\mathbf{1}_{s \times 1}$ 为 $s \times 1$ 的单位列向量,并且 $\mathbf{1}_{s \times 1}^T \boldsymbol{\beta} = 1$. λ_0 用于调节和为一约束.对式(14)中的 $\boldsymbol{\beta}$ 进行求导,并令导数为零,求得系数向量 $\boldsymbol{\beta}$ 的表达式为

$$\boldsymbol{\beta} = \frac{\lambda_0}{2} (\mathbf{G} + \lambda \mathbf{I})^{-1} \mathbf{l} = \frac{\sum_{j=1}^s (\mathbf{G} + \lambda \mathbf{I})^{-1}}{\sum_{i=1}^s \sum_{j=1}^s (\mathbf{G} + \lambda \mathbf{I})^{-1}} \quad (15)$$

式中, i, j 分别表示矩阵的行和列的索引值.

在高光谱影像中,由于某些背景像元与中心像元的具有光谱相似以及空间相似性,为了自适应调整背景像元所占比重,引入 Tikhonov 正则化矩阵 $\boldsymbol{\Gamma}_y$ ^[19] 和空间距离权重 \mathbf{D} ^[20],权重 \mathbf{W} 表达式为

$$\mathbf{W} = \boldsymbol{\Gamma}_y \times \mathbf{D} \quad (16)$$

Tikhonov 正则化矩阵 $\boldsymbol{\Gamma}_y$ 表达式为

$$\boldsymbol{\Gamma}_y = \begin{bmatrix} \|\mathbf{y} - \mathbf{x}_1\|_2^2 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & \|\mathbf{y} - \mathbf{x}_s\|_2^2 \end{bmatrix} \quad (17)$$

式中, $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_s$ 代表背景像元,矩阵 $\boldsymbol{\Gamma}_y$ 的对角线元素是中心像元与背景像元的欧式距离.

空间距离权重 \mathbf{D} 的表达式为

$$\mathbf{D}(\mathbf{y}, \mathbf{x}_i) = \exp \left[-\frac{1}{2} \left(\frac{d_d(\mathbf{y}, \mathbf{x}_i)}{\sigma_d} \right)^2 \right] \quad (18)$$

式中, σ_d 表示控制空间距离权重的因子, $d_d(\mathbf{y}, \mathbf{x}_i)$ 代表待测像元 $\mathbf{y}(k, l)$ 和背景像元 $\mathbf{x}_i(m, n)$ 向量的几何坐标之间的欧式距离.将式(15)中的单位矩阵 \mathbf{I} 替换为权重 \mathbf{W} ,最终可以得到系数向量 $\boldsymbol{\beta}$ 的解为

$$\boldsymbol{\beta} = \frac{\sum_{j=1}^s (\mathbf{G} + \lambda \mathbf{W}^T \mathbf{W})^{-1}}{\sum_{i=1}^s \sum_{j=1}^s (\mathbf{G} + \lambda \mathbf{W}^T \mathbf{W})^{-1}} \quad (19)$$

根据求得的 $\boldsymbol{\beta}$,最后通过式(20)求得两个向量差值的 l_2 范数,并将其作为最终的探测结果,即

$$r = \|\mathbf{y} - \tilde{\mathbf{y}}\|_2 = \|\mathbf{y} - \mathbf{X}_s \boldsymbol{\beta}\|_2 \quad (20)$$

最后通过设定阈值判定是否为异常像元,若求得的残差 r 大于设定的阈值,则判定该像元为异常,反之,

则判定为背景像元.通过光谱空间重构,如果中心像元为背景像元,那么线性表示的近似值与中心像元的差值很小;反之差值会很大,更容易区分背景与异常目标.

1.4 本文算法步骤

本文提出的 UNRS-SSR 算法是一种基于几何模型的高光谱异常检测算法,图 4 给出了其流程.算法包括四个步骤:1)通过改进的基于结构张量的波段选择算法选取有效波段;2)利用光谱空间重构,增加背景与异常的绝对光谱距离;3)通过加入空间距离权重的非监督最邻近规则子空间算法获得预测背景影像;4)通过两个影像的差值获得检测结果,根据设定的阈值判定像元是否为异常目标.




图 4 算法流程

Fig.4 Framework of the proposed method

2 实验结果与分析

用 4 幅真实高光谱影像对该算法进行验证.为了评估提出的 UNRS-SSR 算法的可靠性和有效性,分别与 Global RX (GRX)、RSAD、CRD、UNRS、LSADCRIDW 算法进行实验对比分析.采用接收者操作特性曲线(Receiver Operating Characteristic, ROC)、ROC 曲线下面积(Area Under Curve, AUC)进行定量的评价.

2.1 实验数据

第一个高光谱影像实验数据是由 AVIRIS 传感器获取的美国 San Diego 飞机场.波长范围为 370~2 510 nm,空间分辨率为 3.5 m,共有 224 个波段.影像大小为 100×100 个像素.去除相应的水汽波段、低信噪比波段,用剩余 189 个可用波段进行实验.影像中异常地物主要为三架飞机,如图 5(a)和(b)分别为实验区的真彩色合成影像和真实异常地物图.




图 5 AVIRIS 数据集
Fig.5 AVIRIS dataset




图 6 ROSIS 数据集
Fig.6 ROSIS dataset

第二个高光谱影像是由 ROSIS 光谱仪采集的 Pavia Centre 数据.波长范围为 430~860 nm,空间分辨率为 1.3 m,包含 115 个波段.去除低信噪比波段和水汽吸收波段,最后可用于实验的波段数为 102 个.实验中截取整幅影像 120×200 的子区域进行分析.影像中的异常地物为桥上的车辆,影像与真实异常地物如图 6 所示.

第三个高光谱影像是由 ProSpecTIR-VS 传感器获取的美国罗契斯特市的 Avon 地区.经过影像预处理,选取的区域大小为 400×480 个像素,如图 7(a)所示.波长范围为 400~2 450 nm,包括 360 个波段,空间分辨率为 1 m.影像中的主要异常地物为人造防水布,真实异常地物如图 7(b)所示.

为了验证算法对低空间分辨率高光谱影像的检测效果,使用的第四个数据集是高分 5 号卫星搭载的超光谱成像仪于 2019 年 5 月获取的中国徐州市的影像.影像获取的波长范围 390~2 500 nm,空间分辨率为 30 m,包含 330 个波段.去除重复波段、低信噪比波段和水汽波段,最后可用于实验的波段数为 275 个.实验区域大小为 100×100 个像素.影像中的主要异常地物为房屋屋顶,实验区域与真实异常地物如图 8 所示.




图 7 Avon 数据集
Fig.7 Avon dataset




图 8 高分 5 号数据集
Fig.8 GF-5 Xuzhou dataset

2.2 参数实验分析

UNRS-SSR 算法有三种类型的参数,包括双窗口的大小、参数 λ 和空间距离权重因子 σ_d .首先分析不同空间距离权重因子 σ_d 对 UNRS-SSR 算法检测性能的影响.设 $w_{out}=5, w_{in}=3, \lambda=1$, 寻找四组实验数据的最优空间距离权重因子 σ_d .表 1 为四组实验数据在不同因子 σ_d 条件下的 AUC 值.对于高分 5 号数据,在 σ_d 为 100 时,AUC 值达到最高,但 σ_d 为 50 时,AUC 值仍然较高.对于其余数据,当 $\sigma_d=50$ 时,这三组数据的 AUC 值达到最高.总体而言,当 $\sigma_d=50$ 时,四组数据都可以达到最佳的检测结果.因此,在本文算法中将空间距离权重因子 σ_d 固定为 50.

表 1 四组数据集在不同参数 σ_d 下的检测结果

σ_d	AVIRIS	ROSI	Avon	GF-5
0.1	0.937 6	0.993 2	0.949 1	0.921 0
1	0.937 6	0.993 2	0.949 1	0.922 7
5	0.939 1	0.993 5	0.950 9	0.927 4
10	0.942 2	0.995 0	0.959 1	0.938 7
50	0.951 2	0.995 4	0.959 1	0.956 5
100	0.943 4	0.995 4	0.959 1	0.961 1

然后利用四组实验数据研究参数 λ 对 UNRS-SSR 算法性能的影响,将双窗口的大小设为 $w_{out}=5, w_{in}=3$,寻找四组实验数据的最优参数 λ 值.表 2 为四组实验数据在不同参数 λ 条件下的 AUC 值.从表 2 可以看出参数 λ 对 AUC 值影响很小.对于 AVIRIS 数据,参数 λ 对 AUC 值都控制在 0.01 以内,当 $\lambda=1$ 时 AUC 值达到最高.对于 ROSIS 数据, λ 对 AUC 值的结果影响很小.对于 Avon 数据和高分 5 号数据,当参数 λ 分别为 0.1 和 0.01 时 AUC 值达到最高.

表 2 四组数据集在不同参数 λ 下的检测结果

λ	AVIRIS	ROSIS	Avon	GF-5
0.01	0.942 7	0.993 5	0.960 4	0.960 5
0.1	0.945 6	0.994 8	0.961 5	0.957 1
1	0.951 2	0.995 4	0.959 1	0.956 5
10	0.950 1	0.993 6	0.945 1	0.959 0
100	0.944 2	0.992 2	0.945 1	0.957 3
1 000	0.942 6	0.991 9	0.943 9	0.956 9

窗口尺寸的选择对各种基于几何模型算法均有很大的影响,因此还需讨论不同窗口尺寸对检测精度的影响.首先,将四组实验数据的参数 λ 分别设定为各自的最优值.图 9 为四组实验数据在不同窗口尺寸下的检测结果.对于 AVIRIS 数据,当双窗口大小为 15/13 时 AUC 值最大,但当内窗口尺寸小于 7 时 AUC 值剧烈下降,这是因为有异常像元落入双窗口内造成背景字典的污染.对于 Avon 数据,当双窗口大小为 9/5 时 AUC 值最大,当外窗口尺寸大于 9 时 AUC 值下降,由于异常像元块距离较近,导致异常像元落入双窗口内造成背景字典的污染.这种现象也存在于 ROSIS 数据和高分 5 号数据的检测结果中,它们的最佳双窗口大小是分别是 15/7 和 15/9.实验结果也表明在基于几何模型算法中需要使用双窗口,并且内部窗口的大小一般大于异常目标.




图 9 四组数据集在不同窗口尺寸下的检测结果

Fig.9 Detection results of four data sets under different window sizes

2.3 异常探测结果

为了突出所提算法在计算量上的优势,将 UNRS、CRD、LSADCRIDW 不同算法的窗口大小设置为与 UNRS-SSR 算法的最优窗口尺寸相同,以保证算法处于相同的窗口条件下,UNRS、CRD、LSADCRIDW 算法的参数 λ 设为各自的最优条件.

AVIRIS 数据实验中各种探测算法的二维探测结果如图 10 所示.图中检测值越亮,显示越偏重于红色,

检测值越低,显示越偏重于蓝色.从中可以看出,GRX、RSAD 并不能够突出飞机异常目标.CRD、UNRS、LSADCRIDW 虽然都可以突出异常目标,但是并不能够很好地抑制背景.而 UNRS-SSR 算法可以很好去除背景的影响,同时在飞机区域显示明显偏亮.




图 10 AVIRIS 数据中不同算法的探测结果

Fig.10 Detection results of various detection algorithms in AVIRIS data

RODIS 数据实验中各种探测算法的二维探测结果如图 11 所示.从中可以看出,GRX、RSAD、CRD 和 LSADCRIDW 算法都可以很好地抑制背景地物,但是异常目标不能够明显检测出来.UNRS 虽然可以很好地突出异常目标,但是去除背景能力较差.UNRS-SSR 算法能够表现出对背景很好的抑制能力,而且能够突出异常目标.




图 11 RODIS 数据中不同算法的探测结果

Fig.11 Detection results of various detection algorithms in RODIS data

Avon 数据实验中各种探测算法的二维探测结果如图 12 所示.从中可以看出,GRX、RSAD 可以很好地抑制背景地物,但是异常目标不能检测出来.CRD、UNRS 虽然可以很好地突出异常目标,但是去除背景能力较差.UNRS-SSR 算法能够表现出对背景很好的抑制能力,而且能够突出异常目标.

高分 5 号数据实验中各种探测算法的二维探测结果如图 13 所示.从中可以看出,UNRS-SSR 算法去除背景的能力明显优于其他五种算法.RSAD 与 UNRS-SSR 算法对异常目标的检测性能明显优于其他算法,但是 RSAD 算法对背景的抑制能力较差.因此 UNRS-SSR 算法表现出良好的检测性能与抑制背景能力,同

时说明了 UNRS-SSR 算法也能较好地应用于低分辨率的高光谱遥感影像中。




图 12 Avon 数据中不同算法的探测结果

Fig.12 Detection results of various detection algorithms in Avon data




图 13 高分 5 号数据中不同算法的探测结果

Fig.13 Detection results of various detection algorithms in GF-5 data

图 14 为四组数据实验中各种探测算法的 ROC 曲线.通过设定不同的阈值,将不同阈值条件虚警率和检测率的坐标点相互连接起来绘制 ROC 曲线,曲线越靠近左上角,探测算法的性能就越好.可以看出,UNRS-SSR 算法明显优于其他算法,具有很强的鲁棒性,且其在虚警率很低的前提下仍然具有较高的检测率,说明该算法在抑制背景信息干扰和提高检测率上具有明显的优势.




图 14 四组数据集的 ROC 曲线
Fig.14 ROC curves of four datasets

表 3 四个真实数据集的 AUC 值和不同方法的运算时间对比

Table 3 Comparison of AUC and execution times of the different methods for four datasets

		GRX	RSAD	CRD	UNRS	LSADCRIDW	UNRS-SSR
AVIRIS	AUC	0.833 4	0.916 5	0.948 5	0.984 3	0.984 6	0.996 2
	Time/s	1.10	15.57	23.26	22.07	980.48	44.03
ROSIG	AUC	0.991 6	0.980 8	0.911 7	0.899 2	0.978 6	0.999 5
	Time/s	1.15	25.52	50.19	47.57	1 480.94	152.65
Avon	AUC	0.925 2	0.953 3	0.959 5	0.977 8	0.9467	0.995 2
	Time/s	8.37	442.21	161.61	171.58	2 194.29	314.34
GF-5	AUC	0.971 0	0.985 6	0.966 7	0.969 6	0.98 02	0.991 0
	Time/s	1.19	22.18	23.73	22.10	993.51	98.31

从表 3 可以看出, UNRS-SSR 算法的检测精度明显优于其他 5 种异常检测算法. UNRS-SSR 与 LSADCRIDW 算法都是在基于几何模型的异常检测算法上进行改进的, LSADCRIDW 算法采用双窗口滑动求和策略使得运算时间增加, 所以 UNRS-SSR 算法在时效性方面要明显优于 LSADCRIDW 法. 同时说明了本文算法也能较好地应用于大尺寸遥感影像和低空间分辨率的高分 5 号卫星数据, 具有良好的通用性. 综上所述, UNRS-SSR 算法能够有效抑制异常目标对背景的干扰, 在异常检测中能够取得很好的效果.

3 结论

针对高光谱影像的数据冗余以及地表地物分布的复杂性所导致的异常目标光谱特征与背景光谱相似, 而难以区分背景与异常的问题, 提出了一种基于光谱数据重构的非监督最邻近规则子空间的异常检测 (UNRS-SSR) 算法. 算法改进了基于结构张量的波段选择算法, 通过对光谱空间重构, 同时非监督最邻近规则子空间的基础上引入了空间距离权重, 提高了异常检测的精度. 光谱空间重构充分利用了空间与光谱信息, 增加了线性表示的近似值与异常像元的差值, 从而更容易区分背景与异常目标. 四组真实数据的实验结

果均表明,UNRS-SSR 算法比其他算法具有更好的鲁棒性和更高的检测精度,且对低空间分辨率的高光谱影像也能够得到更好的检测效果。

同时,本文提出的算法仍然有一些不足,需要不断地探索和改进:1)基于结构张量的波段选择算法仅利用不同单波段的空结构特征,如何将空结构特征精细的波段与信噪比较高的波段结合起来选择最优波段;2)无法根据不同影像数据快速获取最优的窗口尺寸和参数 λ ,如何自适应地确定最优窗口尺寸和参数 λ ;3)在线性表示过程中的背景字典可能存在异常像元,造成对背景字典的污染,如何更加有效地获得纯净的背景字典。

参考文献

- [1] LIU Jia-cheng, WANG Shuang, LIU Wei-hua, *et al.* Saliency weighted RX hyperspectral imagery anomaly detection[J]. *Journal of Remote Sensing* 2019, **23**(3): 418-430.
刘嘉诚,王爽,刘伟华,等.显著性权重 RX 高光谱异常点检测[J].遥感学报,2019,**23**(3):418-430.
- [2] YANG X, WU Z, LI J, *et al.* Anomaly detection in hyperspectral images based on low-rank and sparse representation [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, **54**(4): 1990-2000.
- [3] DU B, ZHAO R, ZHANG L, *et al.* A spectral-spatial based local summation anomaly detection method for hyperspectral images[J]. *Signal Processing*, 2016, **124**:115-131.
- [4] TAGHIPOUR A, GHASSEMIAN H. Hyperspectral anomaly detection using spectral-spatial features based on the human visual system[J]. *International Journal of Remote Sensing*, 2019, **40**(23): 8683-8704.
- [5] ZHANG Yan, HUA Wen-shen, YAN Yang, *et al.* Progress in hyperspectral anomaly target detection[J].*Laser Journal*, 2019, **40**(7):6-9.
张炎,华文深,严阳,等.高光谱异常目标检测算法研究进展[J].激光杂志,2019,**40**(7):6-9.
- [6] 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.
- [7] DU B, ZHANG L. Random-selection-based anomaly detector for hyperspectral imagery [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2011, **49**(5): 1578-1589.
- [8] NIU Y, WANG B. Hyperspectral anomaly detection based on low-rank representation and learned dictionary[J]. *Remote Sensing*, 2016, **8**(4): 289.
- [9] QU Ying, WANG Wei, GUO Rui, *et al.* Hyperspectral anomaly detection through spectral unmixing and dictionary-based low-rank decomposition[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2018, **56**(8):4391-4405.
- [10] SONG S, ZHOU H, YANG Y, *et al.* Hyperspectral anomaly detection via convolutional neural network and low rank with density-based clustering[J].*IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing* 2019, **12**(9):3637-3649.
- [11] LI W, DU Q. Unsupervised nearest regularized subspace for anomaly detection in hyperspectral imagery[C]. 2013 *IEEE International Geoscience and Remote Sensing Symposium-IGARSS, Melbourne, Australia*, 2013: 1055-1058.
- [12] LI W, DU Q. Collaborative representation for hyperspectral anomaly detection [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2015, **53**(3): 1463-1474.
- [13] MA Shi-xin, LIU Hong-cai, LI Hong-cai, *et al.* Improved collaborative algorithm based on spatial-spectral joint clustering for hyperspectral anomaly detection [J].*Acta Photonica Sinica*, 2019, **48**(1):0110003
马世欣,刘春桐,李洪才,等.基于空谱联合聚类的改进核协同高光谱异常检测[J].光子学报,2019,**48**(1): 0110003.
- [14] HOU Zeng-fu. Hyperspectral imagery anomaly detection based on collaborative representation and unsupervised nearest regularized subspace[D].Xuzhou: China University of Mining and Technology,2019.
侯增福. 基于协同表示与非监督最邻近规则子空间的高光谱影像异常探测[D].徐州: 中国矿业大学,2019.
- [15] TAN K, HOU Z, WU F, *et al.* Anomaly detection for hyperspectral imagery based on the regularized subspace method and collaborative representation[J]. *Remote Sensing*, 2019, **11**(11): 1318.
- [16] VAFADAR M, GHASSEMIAN H. Anomaly detection of hyperspectral imagery using modified collaborative representation[J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, **15**(4):577-581.
- [17] XIE W, JIANG T, LI Y, *et al.* Structure tensor and guided filtering-based algorithm for hyperspectral anomaly detection [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, **57**(7): 4218-4230.
- [18] XIE W, LEI J, LIU B, *et al.* Spectral constraint adversarial autoencoders approach to feature representation in hyperspectral anomaly detection [J]. *Neural Networks*, 2019, **119**:222-234.
- [19] PRASAD S, FOWLER J E, LI W, *et al.* Nearest regularized subspace for hyperspectral classification[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2013, **52**(1): 477-489.
- [20] YAO X, ZHAO C. Hyperspectral anomaly detection based on the bilateral filter [J]. *Infrared Physics and Technology*, 2018, **92**:144-153.