



JOURNAL OF IMAGE AND GRAPHICS

主办: 中国科学院空天信息创新研究院
中国图象图形学学会
北京应用物理与计算数学研究所


中国图象图形学报

2021

08

VOL.26

ISSN1006-8961
CN11-3758/TB



“高光谱图像处理与应用” 专刊

中国图象图形学报

刊名题字：宋健 月刊（1996年创刊）



第26卷第8期（总第304期）
2021年8月16日

中国精品科技期刊
中国国际影响力优秀学术期刊
中国科技核心期刊
中文核心期刊

版权声明

凡向《中国图象图形学报》投稿，均视为同意在本刊网站及CNKI等全文数据库出版，所刊载论文已获得著作权人的授权。本刊所有图片均为非商业目的使用，所有内容，未经许可，不得转载或以其他方式使用。

Copyright

All rights reserved by Journal of Image and Graphics, Institute of Remote Sensing and Digital Earth, CAS. The content (including but not limited text, photo, etc) published in this journal is for non-commercial use.

主管单位 中国科学院
主办单位 中国科学院空天信息创新研究院
中国图象图形学学会
北京应用物理与计算数学研究所

主 编 吴一戎
编辑出版 《中国图象图形学报》编辑出版委员会
通信地址 北京市海淀区北四环西路19号
邮 编 100190
电子信箱 jig@aircas.ac.cn
电 话 010-58887035
网 址 www.cjig.cn

广告发布登记号 京朝工商广登字20170218号
总 发 行 北京报刊发行局
订 购 全国各地邮局
海外发行 中国国际图书贸易集团有限公司
(邮政信箱: 北京399信箱 邮编: 100048)
印刷装订 北京科信印刷有限公司

Journal of Image and Graphics

Title inscription: Song Jian Monthly, Started in 1996


Superintended by Chinese Academy of Sciences
Sponsored by Aerospace Information Research Institute, CAS
China Society of Image and Graphics
Institute of Applied Physics and Computational Mathematics

Editor-in-Chief Wu Yirong
Editor, Publisher Editorial and Publishing Board of Journal of Image and Graphics
Address No. 19, North 4th Ring Road West, Haidian District, Beijing, P. R. China
Zip code 100190
E-mail jig@aircas.ac.cn
Telephone 010-58887035
Website www.cjig.cn

Distributed by Beijing Bureau for Distribution of Newspapers and Journals
Domestic All Local Post Offices in China
Overseas China International Book Trading Corporation
(P.O.Box 399, Beijing 100048, P.R.China)
Printed by Beijing Kexin Printing Co., Ltd.

CN 11-3758/TB
ISSN 1006-8961
CODEN ZTTXFZ

国外发行代号 M1406
国内邮发代号 82-831
国内定价 60.00元



高光谱图像在生物学中的应用(第1764页)



HSRS-SC:面向遥感场景分类的高光谱图像数据集(第1809页)



多尺度超像素分割和奇异谱分析的高光谱影像分类(第1978页)

序言 何明一 I

编者按 II

综述

高光谱图像空谱特征提取综述

叶珍, 白璘, 何明一 1737

高光谱图像在生物学中的应用

李伟, 吕蒙, 陈天虹, 楚照耀, 陶然 1764

高光谱成像技术新进展

近红外高光谱图像数据预测技术

梅少辉, 张博威, 马明阳, 贾森 1786

低成本便携式多光谱成像系统的研发及优化

朱豪男, 胡孟晗, 张健, 李庆利 1796

数据集论文

HSRS-SC:面向遥感场景分类的高光谱图像数据集

徐科杰, 邓培芳, 黄鸿 1809

高光谱医学诊断

膜性肾病诊断的高光谱图像张量嵌入分析

吕蒙, 陈天虹, 李伟, 杨悦, 涂天琪, 李文歌 1823

傅里叶变换通道注意力网络的胆管癌高光谱图像分割

郑少佳, 邱崧, 李庆利, 周梅, 胡孟晗, 于观贞 1836

高光谱图像目标检测与识别

局部梯度轮廓变换的高光谱异常检测

胡静, 张钰婧, 赵明华, 李鹏, 李云松 1847

结合孪生网络和像素配对的高光谱图像异常检测

王德港, 饶伟强, 孙旭, 渠瀛, 刘雪梅, 高连如 1860

粗定位和协同表示的高光谱图像异常检测

胡静, 赵明华, 李鹏, 李云松 1871

高光谱图像深度模糊核聚类的洋底锰结核识别

张启忠, 郑恩迪, 王叶剑, 高发荣 1886

高光谱图像融合与恢复

波段自适应细节注入的高分五号与Sentinel-2遥感影像空谱融合

王海荣, 郭擎, 李安 1896

基于频率加权张量核范数的高光谱图像复原

刘盛, 曾海金, 孔文凤, 张鹏丹 1910

高光谱图像分类

面向高光谱图像分类的内容引导卷积深度网络并行实现

刘启超, 肖亮, 杨劲翔 1926

增强类可分性的高光谱图像分类

方帅, 张坤, 张晶, 曹洋, 石为开 1940

高光谱图像分类的自适应决策融合方法

叶珍, 董睿, 陈浩鑫, 白璘 1952

跨数据集评估的高光谱图像分类

潘尔婷, 马泳, 黄璐, 樊凡, 李隼, 马佳义 1969

多尺度超像素分割和奇异谱分析的高光谱影像分类

付航, 孙根云, 赵云华, 潘兆杰, 胡光, 张爱竹 1978

结合倒置特征金字塔和U-Net的高光谱图像分类

程嵩阳, 熊玉洁, 姚瑶, 李庆利 1994

高光谱图像小样本分类的卷积神经网络方法


吴鸿昊, 王立国, 石瑶 2009

3D卷积自编码器高光谱图像分类模型

石延新, 何进荣, 李照奎, 曾志高 2021

CONTENTS

JOURNAL OF IMAGE AND GRAPHICS



Application of a hyperspectral image in medical field: a review (P1764)



HSRS-SC: a hyperspectral image dataset for remote sensing scene classification (P1809)



Combining multiscale superpixel segmentation and singular spectral analysis for hyperspectral image classification (P1978)

Review

- Review of spatial-spectral feature extraction for hyperspectral image
Ye Zhen, Bai Lin, He Mingyi 1737
- Application of a hyperspectral image in medical field: a review
Li Wei, Lyu Meng, Chen Tianhong, Chu Zhaoyao, Tao Ran 1764

Advances in Hyperspectral Imaging

- Predicting near-infrared hyperspectral images from visible hyperspectral images
Mei Shaohui, Zhang Bowei, Ma Mingyang, Jia Sen 1786
- Development and optimization of a low-cost and portable multispectral imaging system
Zhu Haonan, Hu Menghan, Zhang Jian, Li Qingli 1796

Dataset

- HSRS-SC: a hyperspectral image dataset for remote sensing scene classification
Xu Kejie, Deng Peifang, Huang Hong 1809

Medical Hyperspectral Imagery

- Tensor-based graph embedding for discriminant analysis of membranous nephropathy hyperspectral data
Lyu Meng, Chen Tianhong, Li Wei, Yang Yue, Tu Tianqi, Li Wen'ge 1823
- Fourier transform channel attention network for cholangiocarcinoma hyperspectral image segmentation
Zheng Shaojia, Qiu Song, Li Qingli, Zhou Mei, Hu Menghan, Yu Guanzhen 1836

Hyperspectral Target Detection and Recognition

- Transformation of local gradient profiles for hyperspectral anomaly detection
Hu Jing, Zhang Yujing, Zhao Minghua, Li Peng, Li Yunsong 1847
- Siamese network with pixel-pair for hyperspectral image anomaly detection
Wang Degang, Rao Weiqiang, Sun Xu, Qu Ying, Liu Xuemei, Gao Lianru 1860
- Rough location and collaborative representation for hyperspectral image anomaly detection
Hu Jing, Zhao Minghua, Li Peng, Li Yunsong 1871
- Recognition of ocean floor manganese nodules by deep kernel fuzzy C-means clustering of hyperspectral images
Zhang Qizhong, Zheng Endi, Wang Yejian, Gao Farong 1886

Hyperspectral Image Fusion and Restoration

- Spatial-spectral fusion based on band-adaptive detail injection for GF-5 and Sentinel-2 remote sensing images
Wang Hairong, Guo Qing, Li An 1896
- Hyperspectral image restoration based on frequency-weighted tensor nuclear norm
Liu Sheng, Zeng Haijin, Kong Wenfeng, Zhang Pengdan 1910

Hyperspectral Image Classification

- Parallel implementation of content-guided deep convolutional network for hyperspectral image classification
Liu Qichao, Xiao Liang, Yang Jinxiang 1926
- Hyperspectral image classification with enhanced class separability
Fang Shuai, Zhang Kun, Zhang Jing, Cao Yang, Shi Weikai 1940
- Adjustive decision fusion approaches for hyperspectral image classification
Ye Zhen, Dong Rui, Chen Haoxin, Bai Lin 1952
- Hyperspectral image classification evaluated across different datasets
Pan Erting, Ma Yong, Huang Jun, Fan Fan, Li Hao, Ma Jiayi 1969
- Combining multiscale superpixel segmentation and singular spectral analysis for hyperspectral image classification
Fu Hang, Sun Genyun, Zhao Yunhua, Pan Zhaojie, Hu Guang, Zhang Aizhu 1978
- Hyperspectral image classification using an inverted feature pyramid network with U-Net
Cheng Songyang, Xiong Yujie, Yao Yao, Li Qingli 1994
- Convolution neural network method for small-sample classification of hyperspectral images
Wu Honghao, Wang Liguang, Shi Yao 2009
- Hyperspectral image classification model based on 3D convolutional auto-encoder
Shi Yanxin, He Jinrong, Li Zhaokui, Zeng Zhigao 2021

中图法分类号: TP751.1 文献标识码: A 文章编号: 1006-8961(2021)08-1847-13

论文引用格式: Hu J, Zhang Y J, Zhao M H, Li P and Li Y S. 2021. Transformation of local gradient profiles for hyperspectral anomaly detection. Journal of Image and Graphics, 26(08): 1847-1859 [胡静, 张钰婧, 赵明华, 李鹏, 李云松. 2021. 局部梯度轮廓变换的高光谱异常检测. 中国图象图形学报, 26(08): 1847-1859] [DOI: 10.11834/jig.210148]

局部梯度轮廓变换的高光谱异常检测

胡静¹, 张钰婧¹, 赵明华^{1*}, 李鹏¹, 李云松²

1. 西安理工大学计算机科学与工程学院, 西安 710048;

2. 西安电子科技大学综合业务网及关键技术国家重点实验室, 西安 710071

摘要: 目的 高光谱异常检测由于其重要的应用价值,引起了研究人员的广泛关注,但大部分的检测算法,往往直接利用输入的高光谱遥感影像所携带的光谱信息或者空谱信息进行检测。考虑到由于成像过程的限制,如成像条件的复杂性以及光谱通道众多导致的每个通道光子数量有限等问题,所获取的高光谱遥感影像往往在一定程度上偏离真实场景,而这也制约了异常检测的精度。针对此问题,本文提出了一种局部梯度轮廓变换的高光谱遥感影像异常检测算法。**方法** 为了在不影响算法性能的基础上减少计算复杂度,首先选取部分可能的异常像元,只对这些局部的异常像元可能位置进行梯度轮廓变换。其次,将变换后的梯度轮廓用于指导原始高光谱遥感影像的空域增强。最后,对增强后的高光谱遥感影像进行检测。通过将局部梯度轮廓用于影像的增强,避免了成像过程中由于细节损失而造成检测精度受限的情况。**结果** 实验在来自4个数据集的6幅高光谱遥感影像上进行了性能验证。首先利用经典的Global-RX(Reed Xiaoli)检测算法同时检测本文算法增强后的影像和原始影像,分别取得的平均AUC(area under curve)值为0.9871和0.9336,本文算法带来了0.0535的精度提升;同时,通过与其他3种预处理方法进行比较,证明了本文局部梯度轮廓变换方法的有效性;更进一步,利用基于协同表示CRD(collaborative representation-based detector)的检测器对增强后的影像和原始影像分别进行检测,分别取得的平均AUC值为0.9907和0.9775,检测结果再次验证了本文算法能够有效提升影像的检测精度;通过对比,实验数据表明本文所采用的局部梯度轮廓变换可减少约37.82%的时间复杂度。**结论** 本文算法通过将局部的梯度轮廓进行变换并用于指导原始影像的增强过程,使得影像的空间轮廓信息更为锐利,更为接近真实场景,从而获得异常检测结果的提升。

关键词: 高光谱; 遥感影像; 异常检测; 梯度轮廓; 信息增强

Transformation of local gradient profiles for hyperspectral anomaly detection

Hu Jing¹, Zhang Yujing¹, Zhao Minghua^{1*}, Li Peng¹, Li Yunsong²

1. School of Computer Science and Engineering, Xi'an University of Technology, Xi'an 710048, China;

2. State Key Laboratory of Integrated Services Networks, Xidian University, Xi'an 710071, China

Abstract: **Objective** Anomaly detection is a fundamental problem in hyperspectral remote sensing image processing, and it attracts the interests of several researchers. The anomalies usually refer to the outliers with spectral and spatial signatures

收稿日期: 2021-03-18; 修回日期: 2021-04-26; 预印本日期: 2021-05-03

* 通信作者: 赵明华 zhaominghua@xaut.edu.cn

基金项目: 国家自然科学基金项目(61901362); 教育部春晖计划项目(112-425920021); 陕西省自然科学基金基础研究计划项目(2019JQ-729); 西安理工大学校博士启动项目(112/256081809)

Supported by: National Natural Science Foundation of China (61901362)

that differ from their surroundings. Compared with the background, the anomalies have two main characteristics. First, their spectra are severely different from those of their surroundings, and this phenomenon is called the spectral difference. Meanwhile, the anomalies are usually embedded into the local homogeneous background in a format of several pixels, and this phenomenon is named the spatial difference. Hyperspectral anomaly detection has been widely used in military and civilian applications, such as surveillance, disaster warning, and rescue. In most traditional approaches, anomalies are directly derived from the original hyperspectral image (HSI). However, the HSIs usually deviate from the real scene as limited by the imagery process, such as the complexity of the imagery condition and the limited number of electrons caused by the hundreds of bands. This deviation could reduce the anomaly detection precision. We propose a novel hyperspectral anomaly detection method via the transformation of local gradient profiles to deal with the limitations caused by the low spatial quality. The gradient profile is a 1D profile along the gradient direction of the edge pixel in the image and has been introduced in natural image super resolution. Observations have demonstrated that the shape statistics of the gradient profiles in natural image is quite stable and invariant. In this way, the statistical relationship of the sharpness of the gradient profile between the real scene and the input HSI can be utilized to transform the gradient profiles of the input HSI. Meanwhile, the transformation is applied locally to some probable anomalies to reduce the computational complexity and avoid the disturbance of the background. These transformed gradient profiles are used to provide a constraint on the enhanced HSI.

Method A novel hyperspectral anomaly detection method is proposed in this study. Some probable anomalies are coarsely selected via a threshold to reduce the computational complexity without affecting the detection performance. Specifically, the original HSI is detected via the classical Global-RX (Reed Xiaoli) detector, and the responses in the map are sorted and selected. Meanwhile, the gradient profiles of these coarsely selected anomalies are computed and transformed to obtain the sharper versions. Specifically, the distribution of the gradient profile is fitted by a generalized Gaussian distribution. The transformation from the input gradient profile to the desired one can be computed via a transformation formulation. These transformed gradient profiles are closer to those of the real scene than the original gradient profiles. The original HSI is enhanced with these transformed gradient profiles. Experimental data contain six real HSIs coming from four datasets. The original six HSIs and their enhanced versions are detected via the Global-RX detector. Experimental results demonstrate the necessity of the enhancement. Meanwhile, experimental results on detection accuracy superiority of the proposed method over some other preprocessing techniques, such as the discrete wavelet transformation (DWT-RX), the spectral derivatives (Deriv-RX), and the fractional Fourier entropy (FrFE-RX), further validate the effectiveness of our proposed local gradient profile transformation strategy. We utilize the collaborative representation-based detector (CRD) to detect the enhanced and original HSIs. The enhanced HSIs still achieve higher detection accuracy. **Result** We incorporate six HSIs coming from four datasets, namely, San Diego, AVIRIS (airborne visible/infrared imaging spectrometer) -2, Airport, and Beach, to validate the performance of the proposed method. The quantitative evaluation metrics include the receiver operating curves and the area under the curve (AUC) value. We also exhibit the detection maps of each method for comparison. We validate the necessity of the enhancement. Thus, comparison of detection accuracy is made between the original and enhanced HSIs via the Global-RX detector. AUC values for the six original HSIs are 0.940 2, 0.934 1, 0.840 3, 0.952 5, 0.980 6, and 0.953 8, respectively. The corresponding AUC values for the enhanced HSIs are 0.977 8, 0.984 9, 0.983 5, 0.982 4, 0.998 6, and 0.995 6. Notably, the enhanced HSI always achieves a higher detection accuracy than the original HSI, which proves the necessity of the enhancement. We also compare our proposed method with three other preprocessing techniques, namely, the DWT-RX, Deriv-RX, and the FrFE-RX, which have average AUC values of 0.956 8, 0.957 9, and 0.964 0, respectively. Our proposed method with an average AUC value of 0.987 1 outperforms all the comparison methods. We also utilize the CRD to further validate the effectiveness of our proposed method. The AUC values for the original HSIs detected by the CRD are 0.977 4, 0.985 5, 0.983 6, 0.977 2, 0.991 6, and 0.939 3. The corresponding AUC values for the enhanced HSIs also detected by the CRD are 0.984 0, 0.987 7, 0.990 3, 0.988 8, 0.998 5, and 0.995 0. Notably, enhanced HSIs always outperform the original HSI via the CRD detector. Therefore, the gradient profile transformation is not only effective in promoting the detection accuracy but also outperforms the other preprocessing techniques. Comparing the time required by local and global gradient contour transforms shows that the former can reduce the time complexity by approximately 37.82%. **Conclusion** In this study, we propose a novel hyperspectral anomaly detection

method that incorporates a local gradient profile transformation to enhance the spatial information of the HSIs before detection. The experiment is conducted on six HSIs from four datasets. Experimental results show that our method outperforms several state-of-the-art anomaly detection approaches. The enhanced HSI and original HSI are detected by the Global-RX and the CRD, respectively. The experimental data demonstrate that the enhanced HSI always achieves a superior detection accuracy.

Key words: hyperspectral; remote sensing image; anomaly detection; gradient profiles; information enhancement

0 引言

高光谱成像仪能同时获取目标的空间信息和光谱信息,所获取的高光谱遥感影像(hyperspectral image, HSI)构成 3 维的数据立方体,具有图谱合一、光谱分辨率高以及空间分辨率低等特点(Bioucas-Dias 等,2013)。在光谱维上,高光谱遥感影像可以看做是由成百上千个连续的光谱波段组成,这些光谱波段共同构成其丰富的光谱信息。不同的光谱信息对应着不同的物质属性,即光谱信息能用于反演不同的物质成分(Rasti 等,2020)。因此,高光谱遥感影像在民用和军事等领域均具有广泛的应用价值(王承亮 等,2020),在农作物估产(Zhang 等,2021)、战场搜救(Eken 和 Çetin,2018)等应用中发挥着重要的作用。

高光谱异常检测作为高光谱遥感影像处理的一个重要分支,由于其在众多应用中的重要作用,一直以来受到学者们的持续关注。高光谱遥感影像中的异常主要从两个方面区别于背景像元:首先是光谱差异性,异常目标的光谱与其周围背景像元的光谱之间存在明显差异(Du 和 Zhang,2011);其次是空间差异性,异常目标往往以少数几个像元(甚至是亚像元)的形式嵌在背景之中(Xie 等,2020a)。区别于目标检测中目标信息已知,异常检测中没有异常的任何先验信息(Nasrabadi,2014)。因此,现有的大部分工作均从光谱差异性和空间差异性这两个特征入手,进行高光谱异常检测算法的研究。

经典的 Global-RX(Reed Xiaoli)检测算法(Reed 和 Yu,1990;Chang 和 Chiang,2002)假设所有的背景像元均服从同一分布。通过计算背景的均值和协方差矩阵,构建背景的统计分布。同时利用马氏距离衡量待检测像元与参考背景统计特性之间的偏离程度,得到最终的异常背景响应图。由于检测的有效性和简单性,Global-RX 检测算法已经成为异常检测的基准算法。考虑到背景像元内部也存在一定的

差异性,简单地假设所有背景服从同一分布往往偏离真实场景,因此,在 Global-RX 的基础上又衍生出一些其他的算法,如局部 RX(Molero 等,2013)通过内外滑窗,假设局部背景服从高斯分布,从而得到了检测效果的提升。FrFE-RX(fractional Fourier entropy)检测器则是通过引入一个分数阶傅里叶变换用做数据预处理,获取原始域与其 Fourier 域之间的过渡域特征,从而在去除噪声的同时增强异常像元和背景像元之间的区分度(Tao 等,2019)。考虑到真实的背景往往过于复杂,简单的高斯分布不能很好地拟合背景,核 RX(Zhou 等,2016)将原始高光谱影像通过核映射到高维的特征空间中,对高维特征空间中的数据应用 RX 检测算法,有效解决了背景分布复杂带来的模型不准、虚警率高的问题。这些算法均通过获取背景的统计特性,寻找异于背景的像素位置,并定位为异常。

考虑到原始高光谱影像可以认为是背景和异常的组合,同时有大量的工作通过重构出背景高光谱,并与原始高光谱影像进行比对,从而找到异常像元(Zhang 等,2020)。对于这些方法而言,准确地重构背景高光谱成为检测异常像元的关键(Xie 等,2020b)。基于协同表示的 CRD(collaborative representation-based detector)检测算法通过设计内外窗,认为对每一个待测像元而言,以其为中心,内外窗之间的像元共同构成背景,如果当前像元能由其背景像元线性近似表示,则当前像元为背景,否则为异常(Li 和 Du,2015),该算法取得了不错的检测效果。在背景的重构过程中,低秩和稀疏分解是最常用到的工具。大量工作通过约束背景矩阵的低秩性以及异常矩阵的稀疏性,对目标函数进行优化(Xu 等,2020)。LSMAD(low-rank and sparse-representation with Mahalanobis distance)利用背景统计信息的低秩先验知识来重建背景矩阵,并使用马氏距离做相似性度量(Zhang 等,2016b)。LRASR(low rank and sparse representation)利用一个字典重建策略对稀疏成分进行建模,并使用稀疏噪声的二范数值作为异

常的响应标志 (Xu 等, 2016)。由于用一个单一分布很难对异常和噪声进行区分, LSDM-MoG (low-rank and sparse decomposition model via mixture of Gaussian) 方法则提出通过一个混合的高斯分布来拟合影像中的稀疏成分, 从而获得更精确的检测结果 (Li 等, 2020)。同时, 考虑到高光谱影像的 3 维数据特性, 有研究人员提出了使用三阶张量来表征高光谱影像。基于张量分解的异常检测算法 Tenb (tensor-decomposition based) 通过分别剔除 3 个维度的第 1 主成分, 并对剩余的 3 维数据进行恒虚警率检测, 从而获得异常目标 (Zhang 等, 2016a)。基于张量填充的异常检测算法 TCD (tensor completion-based detector) 则是通过首先选取部分背景点, 并对这些背景点通过 CP (CANDECOMP (canonical decomposition)/PARAFAC (parallel factors)) 分解, 以得到完整的背景张量。通过从原始高光谱影像中去除背景张量, 从而检测异常 (Wang 等, 2021)。

以上这些检测算法均以原始高光谱影像作为处理对象直接进行异常检测。但在实际的影像获取过程中, 由于硬件平台的限制, 每个分光通道上的能量有限, 导致所获取的高光谱影像空间分辨率较低 (Hu 等, 2020), 所包含的空间细节并不是很丰富, 空间维的结构信息往往偏离于真实场景, 限制了异常像元的精确检测。同时, 在高光谱遥感影像的获取过程中, 机载或星载平台上的光谱成像往往受很多因素影响, 成像环境较为复杂。而这将进一步导致影像中的空间结构信息偏离于真实地物 (Chakrabarti 和 Zickler, 2011)。

针对高光谱遥感影像空间分辨率低、细节模糊, 从而导致异常检测精度受限这一问题, 研究者们从空域增强角度提出了各种高光谱异常检测算法。双边滤波器通过显式地构造滤波核函数, 综合考虑与中心像素的距离以及像素值差异从而设置权重, 实现边缘保持的平滑。通过将原始影像与滤波后影像之间的差值进行影像中边缘的保持 (Yao 和 Zhao, 2018)。但因为权重仅由输入图像中邻域像素与中心像素的空间距离决定, 造成图像中边缘和内部像素并不会被区分。引导滤波作为一种有效的保边滤波器, 综合考虑了引导图像和输入图像的结构特点, 在图像细节增强方面取得了广泛应用。基于结构张量和引导滤波的检测方法首先通过利用结构张量选取结构特征最为明显的第 1 波段, 并将其作为引导

图像, 对粗检测的结果图进一步纠正, 从而得到了不错的检测结果 (Xie 等, 2019)。但这类方法在某些弱边缘处不可避免地会产生一些伪晕线效果。与此同时, 有学者创新性地把形态学属性滤波引入高光谱异常检测, 利用不同的属性滤波器对图像进行滤波, 从而得到图像的结构信息, 并利用域变换递归滤波对检测结果进一步优化 (Kang 等, 2017)。其中属性滤波器通过将区域属性值与阈值进行对比, 判断区域被合并或被保留 (Li 等, 2018)。但在实际应用过程中, 随着图像内容的变换, 具体的阈值设置往往也不同。而且, 如果场景中异常区域大小不一, 单一的阈值设定往往不能很好地处理这种情况。

因此, 本文创新性地提出了一种局部梯度轮廓变换的高光谱异常检测算法。由于空间结构细节的损失, 原始高光谱遥感影像中边界处的过渡往往较为平缓, 边界细节模糊, 区别于真实场景。基于此, 首先选取并记录影像中可能的异常像元位置。其次, 通过计算这些可能的异常像元的梯度, 找到边界点, 并对边界点处的梯度轮廓进行变换。变换后的新梯度轮廓用于指导原始高光谱遥感影像的空域增强。最后, 对增强后的高光谱遥感影像进行检测, 以得到最终的异常响应图。与现有工作相比, 本文的创新之处主要有以下几点:

- 1) 首次将梯度轮廓变换用于指导原始高光谱遥感影像的空域增强, 并对增强后的影像进行检测, 以克服成像过程中由于外界环境造成的信息损失, 从而获得检测性能的提升。

- 2) 通过首先定位可能的异常点位置, 并只从所定位的像素中寻找边界点, 进行梯度轮廓变换。这一策略相对于直接对全图进行梯度轮廓变换, 在基本不影响性能的基础上减少了算法复杂度。

- 3) 实验过程中同时采用基于统计的 Global-RX 检测算法和表示类算法 CRD 分别检测增强后影像和原始影像, 两组对比实验均表明增强处理后影像的检测精度获得了提升。同时, 本文算法还和其余 3 组预处理方法进行了对比, 实验结果证明了本文所提出的局部梯度轮廓变换指导影像增强这一策略对于提升检测性能的优越性。

本文算法在来自 4 个数据库上的 6 幅真实高光谱遥感影像上进行了性能验证。相关的实验结果和

数据分析共同证明了算法的有效性。

1 方法

本文提出的局部梯度轮廓变换的高光谱异常检测

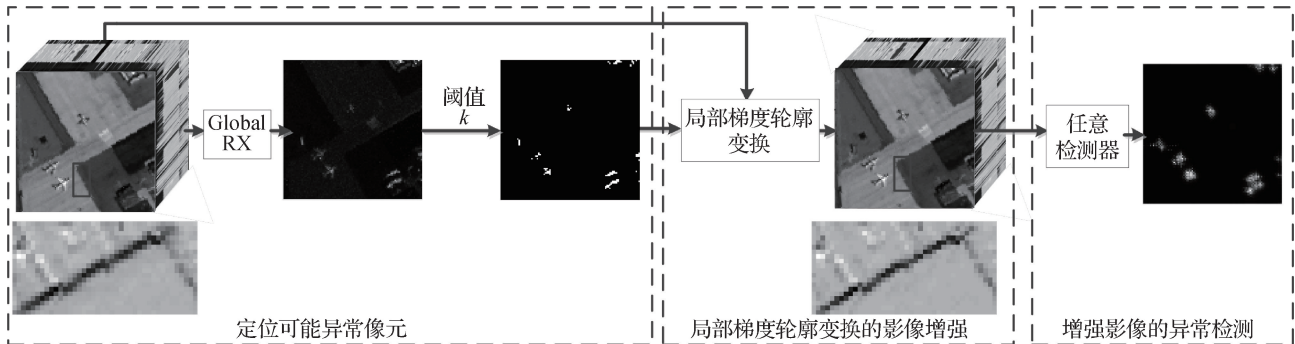


图 1 本文算法框架图

Fig. 1 The architecture of the proposed method

1.1 定位可能的异常像元

在高光谱遥感影像的异常检测过程中,在允许一定程度的虚警情况下,完整检出所有的异常像元并不困难。本文以 San Diego 数据集为例,分别应用 5 种异常检测算法 (global-RX, DWT (discrete wavelet transformation)-RX, Deriv (derivatives)-RX, FrFE (fractional Fourier entropy)-RX 和 CRD) 对其进行检测,对应得到的虚警率—检测率 (ROC) 曲线如图 2 所示。从图 2 可见,不同算法在一定虚警程度下,均能完整地检出异常像元。因此,本文仅对局部可能异常点的梯度轮廓进行变换,以避免全局变换带来的复杂计算量问题。

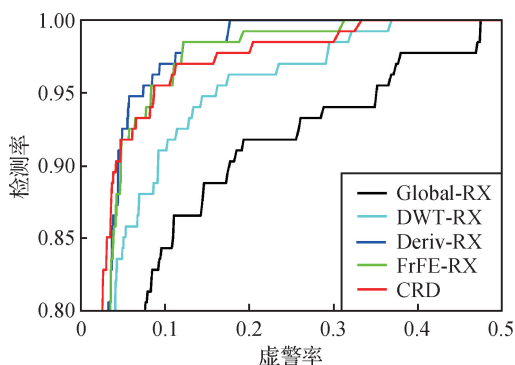


图 2 不同算法对 San Diego 数据检测的虚警率—检测率图

Fig. 2 The ROC curves of different methods for San Diego data

分别用 $H_0 \in \mathbf{R}^{w \times h \times b}$ 和 $H_1 \in \mathbf{R}^{w \times h \times b}$ 表示输入的原始高光谱遥感影像和增强后的目标高光谱遥感影

像,旨在通过局部梯度轮廓变换这一预处理操作,对影像进行细节增强,并对增强后的影像进行异常检测。具体的算法框架如图 1 所示,总共包含 3 部分: 1) 定位可能的异常像元位置; 2) 局部梯度轮廓变换的影像增强; 3) 对增强后的影像进行检测。

像,其中 w, h 和 b 分别表示影像的宽度、高度和波段数。首先利用经典的 Global-RX 检测算法对 H_0 进行检测,得到空间上各个像素位置的响应图 $M \in \mathbf{R}^{w \times h}$,并对 M 中所有响应进行排序,记录响应处于前 $k\%$ 的空间位置。根据记录情况,形成一幅粗定位二值图 $L \in \mathbf{R}^{w \times h}$,如图 1 中第 1 部分定位可能异常像元所示。

1.2 局部梯度轮廓变换的高光谱影像增强

1.2.1 梯度轮廓

梯度轮廓指的是在图像中,一条沿着 x_0 边界点正反梯度方向变化的轮廓曲线,其中 x_0 边界点指的是其梯度幅值处于局部最大的像素点。正反方向变化的终点 x_1 和 x_r 均为梯度幅值不再下降的像素点。本文以经典的 Lena 图为例说明不同空间质量图像对应的梯度轮廓关系,具体如图 3 所示。

图 3 中第 1 行针对原始图像;第 2 行表示的是对原始图像 0.25 倍下采样并 4 倍上采样后的图像,即空间信息差的图像。图 3(a) 分别表示原始图像和 4 倍下采样后图像的视觉展示;图 3(b) 是对图 3(a) 中矩形区域的放大;图 3(c) 是图 3(b) 中区域的梯度;图 3(d) 是对图 3(c) 中的 x_0 至 x_1 和 x_r 路线的描绘,纵轴对应的是梯度的幅值。对比图 3 中的第 1 行和第 2 行可以看出,由于空间信息的损失,图像的边界点处过渡平缓,边界处的结构信息模糊。而理想的图像中,梯度轮廓整体锐利,不同区域之间过渡明显。对于高光谱遥感影像,其一个典型特征




图3 梯度轮廓示意图

Fig. 3 Gradient profile ((a) original images; (b) amplified region; (c) gradient maps; (d) gradient profile of an edge pixel)

就是空间分辨率低,影像结构细节不明显。故本文提出梯度轮廓变换的影像增强,提升细节信息,并进行检测。

为了准确量化梯度轮廓的锐利程度,这里采用标准差 σ 来进行统计。假设边界点为 x_0 ,该点处的梯度轮廓用 $p(x_0)$ 来表示。 $p(x_0)$ 的锐度表示为

$$\sigma(p(x_0)) = \sqrt{\sum_{x \in p(x_0)} m'(x) d^2(x, x_0)} \quad (1)$$

式中, $m'(x) = \frac{m(x)}{\sum_{s \in p(x_0)} m(s)}$ 表示的是当前像素点梯度幅值在总幅值中的占比,即权重; $d(x, x_0)$ 表示的是当前点 x 与边界点 x_0 之间的距离。标准差 σ 越大,则数据整体与其平均值之间差异越大,数据越分散,梯度轮廓越平缓。反之,则数据越集中,梯度轮廓越尖锐。

1.2.2 局部梯度轮廓变换

梯度轮廓的分布通常可以由广义高斯分布进行描述(Varanasi 和 Aazhang, 1989),也就是说,对于边界点 x 而言,其梯度轮廓可以表示为

$$g(x; \sigma, \lambda) = \frac{\lambda \alpha(\lambda)}{2\sigma \Gamma(1/\lambda)} \exp\left\{-\left[\alpha(\lambda) \left|\frac{x}{\sigma}\right|\right]^\lambda\right\} \quad (2)$$

式中, $\Gamma(\cdot)$ 表示伽马函数, $\alpha(\lambda) = \sqrt{\Gamma(\frac{3}{\lambda})/\Gamma(\frac{1}{\lambda})}$ 是用来确保当前广义高斯分布的二阶矩等价于当前梯度轮廓的方差 σ^2 的一个比例系数, λ 是用来控制当前分布整体形状的参数。Sun 等人(2008)研究表明,自然图像的形状参数 λ 与分辨率无关,始终在 1.6 左右;且不同分辨率图像梯度轮廓的锐度指标 σ 之间相互独立。故本文将

原始影像 H_0 中梯度轮廓的形状参数 λ_0 和目标高光谱影像 H_1 中的形状参数 λ_1 分别设置为 1.6 和 1.63。

因此,对于高光谱遥感影像而言,理想梯度轮廓与实际梯度轮廓之间的比例关系可以表示为

$$r(d) = \frac{g(d; \sigma_1, \lambda_1)}{g(d; \sigma_0, \lambda_0)} \quad (3)$$

式中, σ_1, λ_1 分别表示理想梯度轮廓的锐度参数和形状参数; σ_0, λ_0 分别表示输入的原始影像中梯度轮廓的锐度参数和形状参数; σ_1 可由 σ_0 通过分段线性函数映射得到(Sun 等, 2011); d 是梯度轮廓上任意一点到边界点的距离。将式(2)代入式(3)中,可得

$$r(d) = \frac{\lambda_1 \sigma_0 \alpha(\lambda_1) \Gamma(1/\lambda_0)}{\lambda_0 \sigma_1 \alpha(\lambda_0) \Gamma(1/\lambda_1)} \cdot \exp\left\{-\left[\alpha(\lambda_0) \left|\frac{d}{\sigma_0}\right|\right]^{\lambda_0} + \left[\alpha(\lambda_1) \left|\frac{d}{\sigma_1}\right|\right]^{\lambda_1}\right\} \quad (4)$$

1.2.3 局部梯度轮廓变换的高光谱遥感影像增强

根据式(4), 1.1 节定位的可能异常点的梯度轮廓 $\nabla H_0(x)$ (其中 $L(x_{row}, x_{col}) = 1$) 可以变换为理想的梯度轮廓 $\nabla H^T(x)$, 此处 $\nabla H^T(x)$ 表示理想高光谱影像的梯度轮廓, 其中

$$\nabla H^T(x) = r(d(x, x_0)) \cdot \nabla H_0(x) \quad (5)$$

得到理想高光谱影像的梯度轮廓 $\nabla H^T(x)$ 后, 增强后的高光谱遥感影像则可以重建为

$$E(H_1 | H_0, \nabla H^T) = \|\nabla H_1 - \nabla H^T\|^2 \quad (6)$$

s. t. $\nabla H^T = f(\nabla H_0)$

式中, 函数 $f(\cdot)$ 表示式(3)中所描述的梯度轮廓变换关系; ∇H_1 是目标高光谱影像的梯度轮廓。通过梯度下降法, 目标函数式(6)的优化过程可以表示为

$$H_1^{i+1} = H_1^i + \tau \cdot (\nabla^2 H_1^i - \nabla^2 H^T) \quad (7)$$

式中, τ 表示优化过程中的下降步长, i 表示当前的迭代次数。

1.3 增强影像的异常检测

得到增强后的高光谱影像 H_1 后, 可以利用各类已有的检测算法对其进行检测, 从而获得不同于直接对原始输入影像进行检测的精度。需要说明的是, 尽管对于影像的增强是从空间结构信息的引入着手的, 但由于高光谱遥感影像图谱合一的性质, 空间上同一位置在不同波段的响应值构成该点的光谱曲线, 空间信息的增强同样对光谱曲线带来变化。

实验结果表明,增强后的影像无论是利用纯光谱角度出发的 Global-RX 检测算法,还是综合考虑空间信息的协同表示算法 CRD 进行检测,相较于对原始影像进行检测,均能获得精度上的提升。

综上,本文所提出的局部梯度轮廓变换的高光谱异常检测算法步骤为:

输入:原始的高光谱影像 $H_0 \in \mathbf{R}^{w \times h \times b}$ 。

1)对 H_i 利用 Global-RX 检测算法,得到异常响应图 $M \in \mathbf{R}^{w \times h}$;

2)设定阈值 k ,记录 M 中响应处于前 $k\%$ 的像元位置,得到二值图 $L \in \mathbf{R}^{w \times h}$;

3)计算在二值图 $L \in \mathbf{R}^{w \times h}$ 中标记为 1 的像素位置对应的梯度幅值 $Grad_M \in \mathbf{R}^{w \times h}$ 和梯度方向 $Grad_D \in \mathbf{R}^{w \times h}$;

4)找到 $Grad_M$ 中的边界点集,并得到集中所有点的梯度轮廓 $p(x_0)$;

5)通过式(4)对这些梯度轮廓进行变换,得到变换后的梯度轮廓 ∇H^T ;

6)利用式(7),迭代更新,得到最终的增强后高光谱影像 H_1 ;

7)对影像 H_1 分别应用 Global-RX 以及 CRD 检测器进行检测,以验证算法性能。

输出:最终的检测图 $M \in \mathbf{R}^{w \times h}$ 。

2 实验结果

在来自 4 个数据集的 6 个高光谱遥感影像上验证本文方法的检测精度。所有实验均在处理器为 Intel Core i5 2.8 GHz,内存 16 GB 的电脑上进行。

2.1 数据集介绍

本文所使用的 4 个数据库具体情况如下:

San Diego 数据集:该数据集是由 AVIRIS (airborne visible/infrared imaging spectrometer) 传感器 (Green 等,1998) 在美国加利福尼亚州圣地亚哥机场区域所获取的。空间分辨率是 3.5 m。光谱范围从紫外的 370 nm 到近红外的 2 510 nm,总共有 224 个光谱通道。去除其中的噪声波段后,影像的大小为 $100 \times 100 \times 189$ 。场景中的 3 架飞机被标记为异常,总共占 58 个像素。

AVIRIS-2 数据集:该数据集同 San Diego 数据集,是由 AVIRIS 传感器在美国圣地亚哥机场所获取。去除噪声波段后,影像大小为 $100 \times 100 \times 186$ 。

场景中的 3 架飞机被标记为异常,合计 143 个像素 (Wang 等,2020)。

Airport 数据集和 Beach 数据集:这两个数据集中的所有数据均从 AVIRIS 官网上下载得到,同时,通过对下载所得的大幅宽影像进行人工截取,从而得到异常检测中所使用的具体数据 (Kang 等,2017)。这两个数据集中的数据具体描述如表 1 所示。

表 1 Airport 数据集和 Beach 数据集中影像信息

Table 1 Information for the HSIs in Airport and Beach datasets

影像名称	获取地点	空间分辨率/m	传感器	获取时间
airport-1	洛杉矶	7.1	AVIRIS	11/9/2011
airport-2	洛杉矶	7.1	AVIRIS	11/9/2011
airport-3	洛杉矶	7.1	AVIRIS	11/9/2011
airport-4	高尔夫波特	3.4	AVIRIS	7/7/2010
beach-1	卡特岛	17.2	AVIRIS	9/12/2010
beach-2	San Diego	7.5	AVIRIS	11/16/2011
beach-3	Bay-champagne	4.4	AVIRIS	7/4/2010
beach-4	帕维亚	1.3	ROSIS	未知

注:加粗字体表示本文使用对应影像进行性能验证。

在表 1 中可以看出,Airport 数据集中共包含 4 幅影像,其中前 3 幅为同一场景的不同子图,空间分辨率为 7.1 m;第 4 幅是在高尔夫波特所获取的,空间分辨率为 3.4 m。Beach 数据集中同样包含 4 幅影像,其中前 3 幅均由 AVIRIS 传感器所获取,第 4 幅由 ROSIS (reflective optics system imaging spectrometer) 传感器所获取,且第 2 幅影像同 San Diego 数据集和 AVIRIS-2 数据集,均在圣地亚哥所获取。因此,综合考虑实验数据空间分辨率的丰富性和获取平台的多样性,本文采用 Airport 数据集中的第 2 幅和第 4 幅,以及 Beach 数据集中的第 1 幅和第 4 幅影像用做性能验证。

2.2 实验设置

为了验证局部梯度轮廓变换对于影像的空间增强有利于检测性能的提升,本文首先利用 Global-RX 检测算法分别对输入的原始高光谱影像 H_0 和增强后的影像 H_1 进行检测。其次,为了验证梯度轮廓变换这一预处理方式的优越性,本文还与其他同样采

用先预处理后检测的算法进行比较,具体为基于离散小波变换的 DWT-RX 检测算法(Tang 等,2015),光谱导数 Deriv-RX(Liu 和 Han,2017)和基于分数阶傅里叶变换的 FrFE-RX(Tao 等,2019)。所有这些对比算法均采用了其最优参数: DWT-RX 算法中的哈尔小波和一级分解参照 Tao 等人(2019)的研究实现; Deriv-RX 算法中的导数步长设置为 4; FrFE-RX 算法中的最优分数阶自动估计所得,不涉及参数的选取。

本文算法需要确定定位可能异常点时的阈值 $k\%$,具体的设置方式为 k 以 0.1 为间隔,遍历 0.1 ~ 4.5,以找到最佳 k 值。本文中所采用的客观评价指标有接收机操作特性(receiver operating curves, ROC)曲线(Chang 等,2001)以及 ROC 曲线下所覆盖的面积(area under curve, AUC)值(Lobo 等,2008)。为了验证 k 的选取对算法检测性能的影响,对应的 AUC 值曲线如图 4 所示。从图 4 中可以看出,对不同数据而言,AUC 值的变化随着 k 值的变化趋势也不一样。

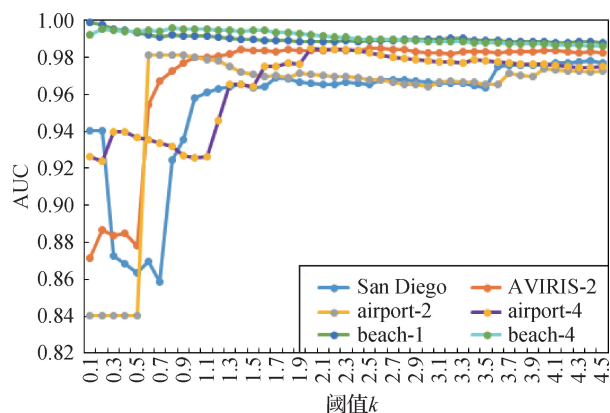


图 4 不同 k 值对应的 AUC 值

Fig. 4 The variations between k and the AUC values

对于 San Diego 数据而言,当阈值 k 为 0.1 和 0.2 时,所选出的区域内容太少,找不到边界点,因此,这时候取得的 AUC 值与原图直接进行检测所取得的 AUC 值一致。但随着 k 值的增加,Global-RX 算法对 San Diego 进行检测时虚警率较高,具体如图 5 所示。

图 5 展示的是针对检测所得的响应图,通过将响应图中最大值与最小值划分成 5 000 等份,并依次将划分间隔设置异常与背景的阈值时,对应得到的虚警率图。其中最左表示所有像素均认为是异

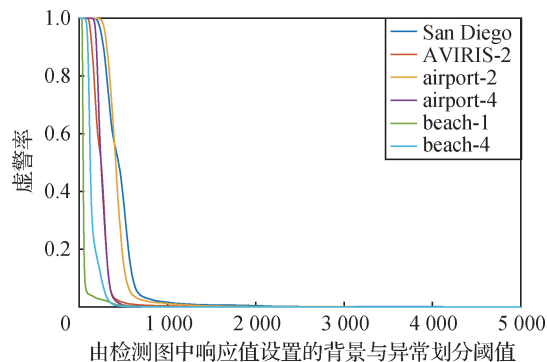


图 5 不同阈值下各数据经 Global-RX 检测所得虚警率曲线

Fig. 5 The false alarm rates with some given thresholds for the detection map achieved by the Global-RX

常,最右表示所有像素均认为是背景。可以看出, San Diego 经 Global-RX 检测后所得虚警率最高,所以随着 k 的增大,此时较多的背景被误判为异常,通过对这些所谓的异常进行局部梯度轮廓变换以增强细节,反而造成 AUC 值的下降。但随着 k 值的进一步增大,更多的真实异常点也参与到局部梯度轮廓变换的过程中,此时 AUC 值逐渐增大。对于 beach-1 数据而言,其图像空间大小为 150×150 像素,合计 22 500 个像素,其中共 19 个像素被标记为异常,异常像素占比很小,且 Global-RX 对该数据的初始检测精度就较高,虚警率低,如图 5 所示。所以对于 beach-1,随着 k 值的增大,越来越多的背景点被加入到局部梯度轮廓变换以增强图像细节的过程,反而造成 AUC 值的下降。从图 5 中可以看出,随着 k 值的增大,beach-1 对应的 AUC 值整体持续下降。对于其他数据来说,airport-2 在 k 取 0.1 ~ 0.5 时,同样找不到边界点,故 AUC 值与原图直接检测一致,但随着 k 的增大,对异常的判定更为宽松,对应图 5 中坐标由右向左,初始时虚警率仍较低,所以这时候异常点梯度轮廓的变换带来的性能提升优于虚警点带来的干扰。但随着 k 的持续增大,性能表现出一定的下降。同理可分析其余数据。因此, k 值的选取不仅与图像本身异常像素占比有关,还与 Global-RX 对图像的初始检测结果密切相关。

另外,在影像的增强过程中,迭代更新的步长 τ 和迭代次数 i 根据经验固定为 0.2 和 30。每个影像所取的最优 $k\%$ 如表 2 所示。

表 2 本文各影像所选用的阈值 k Table 2 The thresholds k for each HSI in the experiment

	San Diego	AVIRIS-2	airport-2	airport-4	beach-1	beach-4
$k/\%$	4.4	2.5	0.5	2.0	0.1	0.9

另外,对于检测器所得的响应图,通过设定不同的阈值,得到一组相应的检测率和虚警率。用横坐标表示虚警率,纵坐标表示检测率,每组检测率和虚警率则对应其中的一个坐标点。若干个坐标点共同构成 ROC 曲线。对于 ROC 曲线来说,越靠近左上角,意味着检测率越高,虚警率越小,说明当前检测器效果越好。AUC 值具体计算为

$$f_{AUC} = \int_0^{+\infty} f_{ROC}(x) dx \quad (8)$$

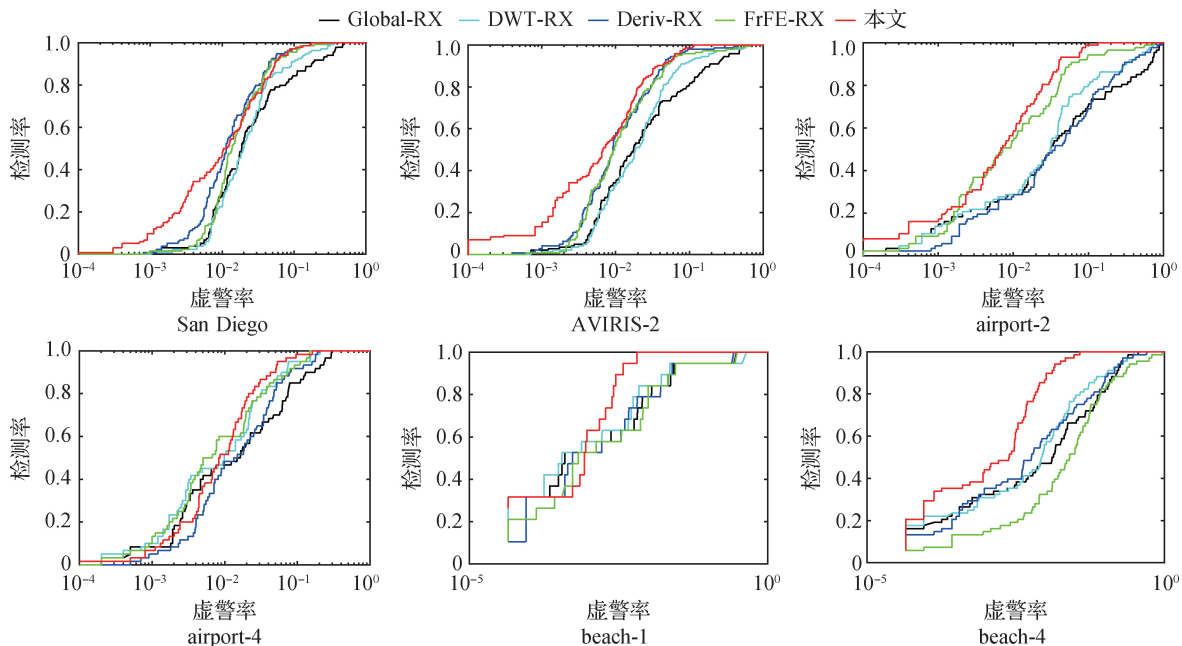


图 6 不同算法最终检测所得 ROC 曲线图

Fig. 6 ROC curves for these HSIs achieved by different methods

从图 7 可以看出,对于 San Diego 数据,由于对影像的梯度轮廓进行约束以增强影像,本文算法能够很好地检出最上方这架飞机,从而避免目标的漏检。但由于阈值 $k\%$ 选取得较大,导致较多的像素位置被认为是可能的异常点,在提高检测精度的同时带来了一定程度的虚警,对应的 ROC 曲线如图 6 中所示。在 AVIRIS-2 数据的检测视觉效果图中可见,尽管各类算法均把右下角的两块平行区域检出较高的响应值,但对于真正异常的 3 架飞机,本文算法的响应是最为明显的。对于 airport-2,对比其他算法仅对异常核心的一小块区域响应明显,本文算

式中, $f_{ROC}(x)$ 表示 ROC 曲线函数。AUC 值的理想上界值为 1。

同时,为了进一步说明实验结果,本文还展示了各算法的异常背景响应目视图,通过观察目视效果图,可以直观地看到不同算法对于影像中背景和异常的区分程度。

2.3 实验结果及数据分析

在来自 4 个数据库的 6 幅高光谱遥感影像上进行了性能验证,对应的 ROC 曲线如图 6 所示。为了清楚展示各算法的性能,图 6 中横坐标采用指数坐标。各类算法的最优检测结果在图 7 中进行了展示。

法由于对边界轮廓区域的增强作用,检出的异常区域面积最为接近真实的异常区域。同样的情况也可以在各个算法对 airport-4 以及 beach-1 检测后的异常区域分布中发现,本文算法检出的区域始终最为接近真实值。对于 beach-4,从图 7 中可以看出,大部分算法只能检出位于影像左中部的异常,且异常区域面积小于真实标记的异常区域,而本文算法不仅能检出最上方两处的异常,且检出的异常区域面积最为接近真实场景。ROC 曲线中的数据进一步表明了本文算法的检测率。综合各影像的视觉检测效果图以及对应的 ROC 曲线,可以证明本文算法的




图7 本文算法和其他检测算法对6幅高光谱遥感影像检测所得视觉效果图

Fig. 7 Comparison results of the proposed method with other algorithms for anomaly detection using the six HSIs
((a) the 100th band of the original HSI; (b) reference detection maps; (c) Global-RX;
(d) DWT-RX; (e) Deriv-RX; (f) FrFE-RX; (g) ours)

有效性。

对应的客观评价指标 AUC 值在表 3 中列出,其中每行的最优参数和次优参数均分别用加粗和下划线进行了标注。通过对比表 3 中的 Global-RX 列和本文算法列可以看出,本文算法的检测精度始终优于直接对原始输入影像进行检测的精度,这表明了对原始影像进行增强处理的有效性。通过对比本文算法列与 DWT-RX、Deriv-RX 和 FrFE-RX 列可以发现,除了 San Diego 这一数据,由于定位可能异常像元时给定了一个较高的阈值 4.4% 导致其虚警率较高,故其 AUC 值略低于 Deriv-RX 算法。对于其他高光谱影像,本文算法均取得最优的检测结果,而这证明了本文所提出的局部梯度轮廓变换这一预处理

策略的优越性。

同时,为了进一步验证本文算法的有效性,还利

表 3 各方法取得的 AUC 值

Table 3 AUC values of different methods

	Global-RX	DWT-RX	Deriv-RX	FrFE-RX	本文
San Diego	0.940 2	0.960 5	0.978 6	0.974 5	<u>0.977 8</u>
AVIRIS-2	0.934 1	0.956 0	<u>0.976 4</u>	0.969 6	0.984 9
airport-2	0.840 3	0.907 7	0.883 9	<u>0.960 2</u>	0.983 5
airport-4	0.952 5	0.975 7	0.967 2	<u>0.976 9</u>	0.982 4
beach-1	0.980 6	0.975 2	<u>0.981 8</u>	0.979 6	0.998 6
beach-4	0.953 8	0.966 0	<u>0.959 4</u>	0.923 2	0.995 6
平均	0.933 6	0.956 8	0.957 9	<u>0.964 0</u>	0.987 1

注:加粗字体为每行最优值,下划线字体为次优值。

用基于空间协同表示的 CRD 检测器分别对增强后的影像和原始影像进行检测。需要说明的是, 由于 CRD 涉及两个参数: 内窗大小 (W_{in}) 和外窗大小 (W_{out}), 在对原始影像进行检测时, 本文参照 Li 和 Du(2015) 所描述的: 将 W_{out} 以 2 为间隔, 遍历 5 ~ 21, 相应的 W_{in} 同样以 2 为间隔, 遍历 3 ~ ($W_{out} - 2$), 以寻找最佳的 W_{out} 和 W_{in} 。同时, 增强后的影像 H_1 采用同样的 W_{out} 和 W_{in} 通过 CRD 检测器进行检测, 以进行性能比对。所得的 AUC 值如表 4 所示。

表 4 CRD 分别对原始影像和增强后影像检测取得的对应 AUC 值

Table 4 AUC values for the original HSI and the enhanced HSI respectively detected by the CRD

	原始影像	本文算法增强后影像
San Diego	0.977 4	0.984 0
AVIRIS-2	0.985 5	0.987 7
airport-2	0.983 6	0.990 3
airport-4	0.977 2	0.988 8
beach-1	0.991 6	0.998 5
beach-4	0.939 3	0.995 0
平均 AUC	0.975 8	0.990 7

注: 加粗字体为每行最优值。

在表 4 中可以看出, 本文中增强后的影像经检测后所取得的平均 AUC 值为 0.990 7, 高于直接对原始影像进行检测的 0.975 8。

综合表 3 和表 4, 可以看出, 本文所提出的局部梯度轮廓变换的高光谱异常检测算法, 通过增强空间信息, 获得细节提升。增强后的影像无论是应用基于光谱统计类的 Global-RX 检测算法, 还是协同表示的 CRD 检测器, 均能取得检测精度的提升。

同时, 为了定量描述局部梯度轮廓变换对于计算复杂度的减少程度, 表 5 中分别列出了本文算法所采用的局部梯度轮廓变换和全局梯度轮廓变换的耗时对比分析。

通过对不同影像进行全局梯度轮廓变换的耗时分析可以看出, 全局梯度变换的耗时与影像大小整体呈线性正相关的关系。对于实验中所用的 6 个数据, 其中最大的是 beach-1, 其大小为 $150 \times 150 \times 188$, 故算法耗时最长。另外, 本文所提出的局部梯度轮廓变换, 相比全局梯度轮廓变换, 整体可以减少

表 5 局部梯度轮廓变换与全局梯度轮廓变换所需时间对比

Table 5 Complexity comparison between the locally gradient transformation and the globally gradient transformation

	局部变换/s	全局变换/s	所减少时间/%
San Diego	177.49	262.94	34.87
AVIRIS-2	172.65	258.91	34.92
airport-2	185.50	284.79	42.68
airport-4	171.69	263.80	41.17
beach-1	357.02	622.80	32.50
beach-4	200.43	340.72	33.32
平均	210.80	338.99	37.82

约 37.82% 的计算量。这是因为尽管梯度轮廓变换的目标是选取的部分像素, 但变换后的梯度轮廓用于指导整幅影像的增强, 且影像增强过程中包含迭代过程, 所以实际减少的计算复杂度小于局部梯度轮廓变换中未被选中的像素比例。

3 结 论

本文从原始高光谱遥感影像由于成像条件的限制, 影像往往偏离于真实场景, 从而导致异常检测算法的精度受限这一客观情况入手, 提出了一种局部梯度轮廓变换的高光谱异常检测算法。首先通过 Global-RX 检测算法, 定位可能的异常点位置。然后, 对这些可能的异常点位置通过梯度的计算与统计, 找到边界点, 并对边界点处的梯度轮廓进行变换。变换后的梯度轮廓用于指导原始高光谱遥感影像的增强。最后, 对增强后的影像进行再次检测。实验所用数据包包含来自 4 个数据库的 6 幅影像, 原始影像和增强后影像分别进行检测所得的精度对比证明了本文算法的有效性。本文算法所得的检测精度与其他 3 种预处理方式所得的实验结果和数据分析则证明了本文算法的优越性。

虽然本文算法在实验中获得了较好的检测效果, 但该工作仍存在很多可以改进的地方。比如, 在定位可能的异常像元位置时, 如何分析最优阈值 $k\%$ 与影像自身之间的关系, 是否能找到两者之间的某种对应关系, 以及能否把更多的先验用于增强原始高光谱遥感影像, 从而获得更好的检测性能。因此, 如何研究高效的高光谱异常检测方法是后续工

作需要重点关注的。

致谢 此次实验的数据主要来自湖南大学康旭东教授和武汉大学智能化遥感数据提取分析与应用(RS-IDEA)研究组,所采用的CRD检测算法来自北京理工大学李伟教授,在此表示衷心感谢!

参考文献 (References)

- Bioucas-Dias J M, Plaza A, Camps-Valls G, Scheunders P, Nasrabadi N and Chanussot J. 2013. Hyperspectral remote sensing data analysis and future challenges. *IEEE Geoscience and Remote Sensing Magazine*, 1(2): 6-36 [DOI: 10.1109/MGRS.2013.2244672]
- Chakrabarti A and Zickler T. 2011. Statistics of real-world hyperspectral images//Proceedings of 2011 Conference on Computer Vision and Pattern Recognition (CVPR). Colorado Springs, USA: IEEE: 193-200 [DOI: 10.1109/CVPR.2011.5995660]
- Chang C I and Chiang S S. 2002. Anomaly detection and classification for hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 40(6): 1314-1325 [DOI: 10.1109/TGRS.2002.800280]
- Chang C I, Chiang S S, Du Q, Ren H and Ifarragaerri A. 2001. An ROC analysis for subpixel detection//IEEE 2001 International Geoscience and Remote Sensing Symposium (Cat. No. 01CH37217). Sydney, Australia: IEEE: 2355-2357 [DOI: 10.1109/IGARSS.2001.978000]
- Du B and Zhang L P. 2011. Random-selection-based anomaly detector for hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 49(5): 1578-1589 [DOI: 10.1109/TGRS.2010.2081677]
- Eken I C and Çetin Y Y. 2018. Underwater target detection with hyperspectral imagery for search and rescue missions//Proceedings of SPIE, Algorithms and Technologies for Multispectral, Hyperspectral, and Ultraspectral Imagery Xxiv. Orlando, USA: SPIE: #106441Z [DOI: 10.1117/12.2304637]
- Green R O, Eastwood M L, Sarture C M, Chrien T G, Aronsson M, Chippendale B J, Faust J A, Pavri B E, Chovit C J, Solis M, Olah M R and Williams O. 1998. Imaging spectroscopy and the airborne visible/infrared imaging spectrometer (AVIRIS). *Remote Sensing of Environment*, 65(3): 227-248 [DOI: 10.1016/S0034-4257(98)00064-9]
- Hu J, Jia X P, Li Y S, He G and Zhao M H. 2020. Hyperspectral image super-resolution via intrafusion network. *IEEE Transactions on Geoscience and Remote Sensing*, 58(10): 7459-7471 [DOI: 10.1109/TGRS.2020.2982940]
- Kang X D, Zhang X P, Li S T, Li K L, Li J and Benediktsson J A. 2017. Hyperspectral anomaly detection with attribute and edge-preserving filters. *IEEE Transactions on Geoscience and Remote Sensing*, 55(10): 5600-5611 [DOI: 10.1109/TGRS.2017.2710145]
- Li L, Li W, Du Q and Tao R. 2020. Low-rank and sparse decomposition with mixture of Gaussian for hyperspectral anomaly detection. *IEEE Transactions on Cybernetics* [EB/OL]. [2020-2-25]. <https://ieeexplore.ieee.org/document/9011733>
- Li S T, Zhang K Z, Hao Q B, Duan P H and Kang X D. 2018. Hyperspectral anomaly detection with multiscale attribute and edge-preserving filters. *IEEE Geoscience and Remote Sensing Letters*, 15(10): 1605-1609 [DOI: 10.1109/LGRS.2018.2853705]
- Li W and Du Q. 2015. Collaborative representation for hyperspectral anomaly detection. *IEEE Transactions on Geoscience and Remote Sensing*, 53(3): 1463-1474 [DOI: 10.1109/TGRS.2014.2343955]
- Liu D L and Han L. 2017. Spectral curve shape matching using derivatives in hyperspectral images. *IEEE Geoscience and Remote Sensing Letters*, 14(4): 504-508 [DOI: 10.1109/LGRS.2017.2651060]
- Lobo J M, Jiménez-Valverde A and Real R. 2008. AUC: a misleading measure of the performance of predictive distribution models. *Global Ecology and Biogeography*, 17(2): 145-151 [DOI: 10.1111/j.1466-8238.2007.00358.x]
- Molero J M, Garzón E M, García I and Plaza A. 2013. Analysis and optimizations of global and local versions of the RX algorithm for anomaly detection in hyperspectral data. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 6(2): 801-814 [DOI: 10.1109/JSTARS.2013.2238609]
- Nasrabadi N M. 2014. Hyperspectral target detection: an overview of current and future challenges. *IEEE Signal Processing Magazine*, 31(1): 34-44 [DOI: 10.1109/msp.2013.2278992]
- Rasti B, Hong D F, Hang R L, Ghamisi P, Kang X D, Chanussot J and Benediktsson J A. 2020. Feature extraction for hyperspectral imagery: the evolution from shallow to deep: overview and toolbox. *IEEE Geoscience and Remote Sensing Magazine*, 8(4): 60-88 [DOI: 10.1109/MGRS.2020.2979764]
- Reed I S and Yu X L. 1990. Adaptive multiple-band CFAR detection of an optical pattern with unknown spectral distribution. *IEEE Transactions on Acoustics, Speech, and Signal Processing*, 38(10): 1760-1770 [DOI: 10.1109/29.60107]
- Sun J, Sun J, Xu Z B and Shum H Y. 2011. Gradient profile prior and its applications in image super-resolution and enhancement. *IEEE Transactions on Image Processing*, 20(6): 1529-1542 [DOI: 10.1109/TIP.2010.2095871]
- Sun J, Xu Z B and Shum H Y. 2008. Image super-resolution using gradient profile prior//Proceedings of 2008 IEEE Conference on Computer Vision and Pattern Recognition. Anchorage, USA: IEEE: 1-8 [DOI: 10.1109/CVPR.2008.4587659]
- Tang Y Y, Lu Y and Yuan H L. 2015. Hyperspectral image classification based on three-dimensional scattering wavelet transform. *IEEE Transactions on Geoscience and Remote Sensing*, 53(5): 2467-2480 [DOI: 10.1109/TGRS.2014.2360672]
- Tao R, Zhao X D, Li W, Li H C and Du Q. 2019. Hyperspectral anom-

- aly detection by fractional Fourier entropy. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 12(12): 4920-4929 [DOI: 10.1109/JSTARS.2019.2940278]
- Varanasi M K and Aazhang B. 1989. Parametric generalized Gaussian density estimation. *The Journal of the Acoustical Society of America*, 86(4): 1404-1415 [DOI: 10.1121/1.398700]
- Wang C K, Zhang Z X, Huang X W, Zou X B, Li Z H and Shi J Y. 2020. Detection of component content changes during tofu formation based on hyperspectral imaging technology. *Spectroscopy and Spectral Analysis*, 40(11): 3549-3555 (王承克, 张泽翔, 黄晓玮, 邹小波, 李志华, 石吉勇. 2020. 基于高光谱成像技术的豆腐形成过程中组分含量变化检测. *光谱学与光谱分析*, 40(11): 3549-3555) [DOI: 10.3964/j.issn.1000-0593(2020)11-00-07]
- Wang J X, Xia Y and Zhang Y N. 2021. Anomaly detection of hyperspectral image via tensor completion. *IEEE Geoscience and Remote Sensing Letters*, 18(6): 1099-1103 [DOI: 10.1109/LGRS.2020.2993214]
- Wang S Y, Wang X Y, Zhong Y F and Zhang L P. 2020. Hyperspectral anomaly detection via locally enhanced low-rank prior. *IEEE Transactions on Geoscience and Remote Sensing*, 58(10): 6995-7009 [DOI: 10.1109/TGRS.2020.2978510]
- Xie W Y, Jiang T, Li Y S, Jia X P and Lei J. 2019. Structure tensor and guided filtering-based algorithm for hyperspectral anomaly detection. *IEEE Transactions on Geoscience and Remote Sensing*, 57(7): 4218-4230 [DOI: 10.1109/TGRS.2018.2890212]
- Xie W Y, Li Y S, Lei J, Yang J, Chang C I and Li Z. 2020a. Hyperspectral band selection for spectral-spatial anomaly detection. *IEEE Transactions on Geoscience and Remote Sensing*, 58(5): 3426-3436 [DOI: 10.1109/TGRS.2019.2956159]
- Xie W Y, Liu B Z, Li Y S, Lei J and Du Q. 2020b. Autoencoder and adversarial-learning-based semi-supervised background estimation for hyperspectral anomaly detection. *IEEE Transactions on Geoscience and Remote Sensing*, 58(8): 5416-5427 [DOI: 10.1109/TGRS.2020.2965995]
- Xu Y, Wu Z B, Li J, Plaza A and Wei Z H. 2016. Anomaly detection in hyperspectral images based on low-rank and sparse representation. *IEEE Transactions on Geoscience and Remote Sensing*, 54(4): 1990-2000 [DOI: 10.1109/TGRS.2015.2493201]
- Xu Y C, Du B, Zhang L P and Chang S Z. 2020. A low-rank and sparse matrix decomposition-based dictionary reconstruction and anomaly extraction framework for hyperspectral anomaly detection. *IEEE Geoscience and Remote Sensing Letters*, 17(7): 1248-1252 [DOI: 10.1109/LGRS.2019.2943861]
- Yao X F and Zhao C H. 2018. Hyperspectral anomaly detection based on the bilateral filter. *Infrared Physics and Technology*, 92: 144-153 [DOI: 10.1016/j.infrared.2018.05.028]
- Zhang J, Dai L M and Cheng F. 2021. Identification of corn seeds with different freezing damage degree based on hyperspectral reflectance imaging and deep learning method. *Food Analytical Methods*, 14(2): 389-400 [DOI: 10.1007/s12161-020-01871-8]
- Zhang X, Wen G J and Dai W. 2016a. A tensor decomposition-based anomaly detection algorithm for hyperspectral image. *IEEE Transactions on Geoscience and Remote Sensing*, 54(10): 5801-5820 [DOI: 10.1109/TGRS.2016.2572400]
- Zhang Y, Fan Y G and Xu M M. 2020. A background-purification-based framework for anomaly target detection in hyperspectral imagery. *IEEE Geoscience and Remote Sensing Letters*, 17(7): 1238-1242 [DOI: 10.1109/LGRS.2019.2941242]
- Zhang Y X, Du B, Zhang L P and Wang S G. 2016b. A low-rank and sparse matrix decomposition-based mahalanobis distance method for hyperspectral anomaly detection. *IEEE Transactions on Geoscience and Remote Sensing*, 54(3): 1376-1389 [DOI: 10.1109/TGRS.2015.2479299]
- Zhou J, Kwan C, Ayhan B and Eismann M T. 2016. A novel cluster kernel RX algorithm for anomaly and change detection using hyperspectral images. *IEEE Transactions on Geoscience and Remote Sensing*, 54(11): 6497-6504 [DOI: 10.1109/TGRS.2016.2585495]

作者简介



胡静, 1992年生, 女, 讲师, 主要研究方向为高光谱遥感影像处理。

E-mail: jinghu@xaut.edu.cn



赵明华, 通信作者, 女, 教授, 主要研究方向为数字图像处理。

E-mail: zhaominghua@xaut.edu.cn

张钰婧, 女, 硕士研究生, 主要研究方向为高光谱异常检测。

E-mail: yu_jingzhang@163.com

李鹏, 男, 副教授, 主要研究方向为图像分类。

E-mail: lip2006@xaut.edu.cn

李云松, 男, 教授, 主要研究方向为图像处理和高性能计算。

E-mail: ysli@mail.xidian.edu.cn