

## 基于协峭度张量的高光谱图像异常检测

孟令博 耿修瑞\*

(中国科学院空间信息处理与应用系统技术重点实验室 北京 100190)

(中国科学院电子学研究所 北京 100190)

(中国科学院大学 北京 100049)

**摘要:** 高光谱图像中的异常像素往往具有在图像中出现的概率低和游离于背景数据云团之外的特点, 如何“自动”确定这些异常像素是高光谱遥感图像处理中的一个重要研究方向。经典的高光谱异常检测方法一般从图像的统计特性入手, 广泛应用的RXD异常检测算法通过计算图像的2阶统计特征, 可以直接给出异常点的分布情况, 算法复杂度低, 但缺点是没有考虑到图像的高阶统计信息。基于独立成分分析的异常检测算法虽然考虑了高阶统计量对异常点的敏感性, 但需要反复迭代提取异常成分后, 再对提取后的成分进行异常检测。该文提出一种基于协峭度张量的异常检测算法, 该算法不需要事先提取异常成分, 可以直接对观测像元进行逐一检测, 从而给出异常点的分布情况。基于模拟数据和真实数据的实验结果表明, 该方法能够在检测出异常像元的同时更好地压制背景信息、减小虚警率, 从而提高异常检测精度。

**关键词:** 高光谱图像; 异常检测; 高阶统计; 协峭度张量

中图分类号: TP75

文献标识码: A

文章编号: 1009-5896(2019)01-0150-06

DOI: 10.11999/JEIT180280

## A Hyperspectral Imagery Anomaly Detection Algorithm Based on Cokurtosis Tensor

MENG Lingbo GENG Xiurui

(Key Laboratory of Technology in Geo-spatial Information Processing and Application System, Beijing 100190, China)

(Institute of Electronics, Chinese Academy of Sciences, Beijing 100190, China)

(University of Chinese Academy of Sciences, Beijing 100049, China)

**Abstract:** The abnormal pixels in hyperspectral images are often have the characteristics of low probability and scattered outside the background data cloud. How to automatically detect these abnormal pixels is an important research direction in hyperspectral imagery processing. Classical hyperspectral anomaly detection methods are usually based on statistical perspective. The RXD algorithm which is widely used can give the anomalies distribution directly through the second order statistical feature of the image, but the disadvantage is that it does not take into account the higher order statistics of the image. Anomaly detection algorithm based on Independent Component Analysis (ICA) considers the sensitivity of higher order statistics to outliers, but it needs iteration process to extract abnormal components first. And then the extracted components is used for anomaly detection. A method based on cokurtosis tensor for anomaly detection is proposed. This method does not need to extract anomaly components first. It can directly detect the observed pixels and give the distribution of abnormal pixels. Experiments results on both simulated and real data show that it can detect abnormal pixels while suppressing the background information better. Therefore, it can reduce false alarm rate and improve detection accuracy.

**Key words:** Hyperspectral imagery; Anomaly detection; Higher-order statistical; Cokurtosis tensor

### 1 引言

光谱分辨率的提高是遥感对地观测技术的一个

重要发展趋势, 高光谱遥感将成像技术和光谱技术结合在一起, 实现了图像和光谱的融合。近年来, 高光谱遥感技术获得了越来越广泛的关注和研究<sup>[1-3]</sup>。它被广泛地应用于诸如土地资源使用管理、气候环境监测、广域监视等方面<sup>[4]</sup>。

收稿日期: 2018-03-26; 改回日期: 2018-10-18; 网络出版: 2018-10-24

\*通信作者: 耿修瑞 xrgeng@mail.ie.ac.cn

异常检测是高光谱图像处理的一个重要应用方向。高光谱数据的异常首先是指光谱异常，因而与传统的基于高空间分辨率的遥感影像的异常检测方法不同，它基于异常点与背景地物在光谱上的差别来进行异常检测<sup>[5-9]</sup>。这里的异常不一定对应实际的地物，在更多的情况下往往表现为一种数据的异常<sup>[10]</sup>。高光谱图像异常检测方法有很多<sup>[11-13]</sup>，经典的异常检测方法往往是根据图像的统计特征进行检测。在高光谱图像异常检测领域广泛应用的异常检测方法主要有RX异常检测(RXD)算法、低概率目标检测算法等等，经典的异常检测算法大都是基于图像的1阶和2阶统计特性进行异常检测。但研究发现，在很多情况下，仅仅基于图像的1阶、2阶统计特性很难对图像中的异常目标进行有效检测，因此发展出了基于高阶统计特性的异常检测算法<sup>[14,15]</sup>。例如，基于独立成分分析(Independent Component Analysis, ICA)发展出了一系列高光谱图像高阶统计异常检测算法<sup>[16,17]</sup>，该类算法通常需要从ICA变换后的各个独立成分中先选择出含有异常信息较多的成分，然后再对选择出的成分进行异常检测，如何精确地选择出这些成分这类算法的关键和难点之处。另外，还有基于主成分分析算法的一系列算法<sup>[18-20]</sup>，该类算法基于主成分变换对原始图像进行背景抑制，然后再对背景抑制后的数据进行主成分变换，利用偏度或峭度指标选择出含有异常信息较多的成分进行异常检测。以上这些基于特征空间变换的异常检测算法需要先对数据进行投影，然后再选择异常成分进行异常检测，实现过程需要设置众多参数，算法比较复杂。Geng等人<sup>[21]</sup>提出了一种基于协偏度张量的异常检测算法(COSD)，相比于其它的利用高阶统计特性的异常检测算法，它的实现过程相对简单，且易于实现。COSD算法基于图像的3阶统计张量进行异常检测，可以直接得到异常点的分布图，它能够在保持异常目标的强度的同时更好地压制背景。本文提出了一种基于数据的4阶统计特性的异常检测算法，该算法使用协峭度张量来表示数据整体的4阶统计特性。实验表明，本文方法能够有效地检测出图像中的异常点，且能够很好地压制背景信息。

## 2 背景介绍

本文提出的方法可以和RXD算法、COSD算法看成一个系列的算法，因而首先对这两种算法进行简单的介绍。假设中心化和白化后的高光谱图像数据集为 $\mathbf{R} = \{\mathbf{r}_1, \mathbf{r}_2, \dots, \mathbf{r}_N\}$ ，其中 $\mathbf{r}_i = [\mathbf{r}_{1i}, \mathbf{r}_{2i}, \dots, \mathbf{r}_{Li}]^T$ ， $N$ 为图像像元数目， $L$ 为图像波段数。

对于图像中的任意一个像元 $\mathbf{r}_i$ ，RXD通过式

(1)实现异常检测。

$$\delta_{\text{RXD}}(\mathbf{r}_i) = \mathbf{r}_i^T \mathbf{r}_i \quad (1)$$

需要指出的是，由于数据已经进行过白化操作，而RXD算子利用的是数据和均值的马氏距离(相当于白化后的内积)，所以式(1)的表达形式不同于常用的RXD算子表现形式。现阶段，RXD算法已经成为验证异常检测算法的有效性的标准之一，因此本文的实验部分也使用RXD算法作为比较算法之一。

Geng等人<sup>[22,23]</sup>提出了基于协偏度张量的异常检测算法(COSD)。对于白化后图像中的任意一个像元 $\mathbf{r}_i$ ，COSD算法的检测值为

$$\delta_{\text{COSD}}(\mathbf{r}_i) = \underline{\mathbf{S}} \times_1 \mathbf{r}_i \times_2 \mathbf{r}_i \times_3 \mathbf{r}_i \quad (2)$$

式中， $\underline{\mathbf{S}}$ 代表图像的协偏度张量， $\times_i$ 代表 $i$ -mode乘积算子( $i$ -mode product operator)。该算法利用所有的像元点生成灰度图，图像中比较亮的点(检测值大的点)即是异常点。文献<sup>[22,23]</sup>表明：和RXD算法相比，COSD算法能够更好地检测异常像元。因此实验部分将COSD算法作为比较算法之一，将其与本文方法进行异常检测效果的比较。

另外，本文仿真实验部分还选择了文献<sup>[18]</sup>中的方法进行比较。该算法需要先对数据进行KPCA变换，然后计算变换后的各成分的偏度指数和峭度指数，从而选择特定的成分利用RXD算法进行异常检测，所以本文将之称为KPCA-RXD算法。

## 3 基于协峭度张量的异常检测算法

### 3.1 算法的提出

COSD算法通过计算 $\delta_{\text{COSD}}(\cdot)$ 的值来寻找异常目标，如果图像中存在异常目标，那么 $\delta_{\text{COSD}}(\cdot)$ 的值将会较大。COSD算法表明，图像向异常点所在方向投影时偏度值最大，相应的理论分析可以参考文献<sup>[24]</sup>，这一原理可以用图1形象地表示。图1中红色线条的长度表示图像投影到该方向时的偏度值大小。可以看出异常点所在方向图像的偏度值达到




图1 数据在某个方向的偏度值(红色线条长度)和峭度值(蓝色线条长度)

最大,这正是COSD算法能够有效地检测异常的原因所在。当用4阶统计量(峭度)来描述数据各个方向的异常情况时发现,异常点所在方向图像的峭度值也达到最大,且峭度相对于偏度对异常的存在更为敏感(如图1所示)。受此启发,本文提出了一种基于协峭度张量的异常检测算法,并将之命名为基于协峭度张量的异常检测(COKurtosis Detector, COKD)算法。

### 3.2 算法原理分析

对于图像中的任意一个待检测像元 $\mathbf{r}_i$ , COKD算法通过式(3)得到异常检测值 $\delta_{\text{COKD}}(\mathbf{r}_i)$ :

$$\delta_{\text{COKD}}(\mathbf{r}_i) = \underline{\mathbf{K}} \times_1 \mathbf{r}_i \times_2 \mathbf{r}_i \times_3 \mathbf{r}_i \times_4 \mathbf{r}_i - 3 \|\mathbf{r}_i\|^4 \quad (3)$$

式中, $\underline{\mathbf{K}}$ 代表图像的协峭度张量,假设中心化和白化后的高光谱图像数据集为 $\mathbf{R} = \{\mathbf{r}_1, \mathbf{r}_2, \dots, \mathbf{r}_N\}$ ,协峭度张量计算公式为

$$\underline{\mathbf{K}} = \frac{1}{N} \sum_{i=1}^N \mathbf{r}_i \circ \mathbf{r}_i \circ \mathbf{r}_i \circ \mathbf{r}_i \quad (4)$$

其中, $\circ$ 为外积。COKD算法对图像中的像元进行逐一检测后,得到包含每个像元检测值的灰度图,图像中的异常点的检测值往往较大,在灰度图中显示为较亮的异常点,对这一理论可以进行如下的简单分析。

假设高光谱图像由异常像元 $\mathbf{A} = \{\mathbf{r}_{a_1}, \mathbf{r}_{a_2}, \dots, \mathbf{r}_{a_{N_a}}\}$ 和背景像元 $\mathbf{B} = \{\mathbf{r}_{b_1}, \mathbf{r}_{b_2}, \dots, \mathbf{r}_{b_{N_b}}\}$ 组成,则 $N_a + N_b = N$ ,一般异常像元在图像中出现的概率比较低,因此 $N_a \ll N_b$ 。图像的协峭度张量可以按式(5)进行分解

$$\begin{aligned} \underline{\mathbf{K}} &= \frac{1}{N} \sum_{i=1}^{N_a} \mathbf{r}_{a_i} \circ \mathbf{r}_{a_i} \circ \mathbf{r}_{a_i} \circ \mathbf{r}_{a_i} \\ &+ \frac{1}{N} \sum_{i=1}^{N_b} \mathbf{r}_{b_i} \circ \mathbf{r}_{b_i} \circ \mathbf{r}_{b_i} \circ \mathbf{r}_{b_i} \end{aligned} \quad (5)$$

式中,令

$$\underline{\mathbf{K}}_a = \frac{1}{N} \sum_{i=1}^{N_a} \mathbf{r}_{a_i} \circ \mathbf{r}_{a_i} \circ \mathbf{r}_{a_i} \circ \mathbf{r}_{a_i} \quad (6)$$

$$\underline{\mathbf{K}}_b = \frac{1}{N} \sum_{i=1}^{N_b} \mathbf{r}_{b_i} \circ \mathbf{r}_{b_i} \circ \mathbf{r}_{b_i} \circ \mathbf{r}_{b_i} \quad (7)$$

则

$$\underline{\mathbf{K}} = \underline{\mathbf{K}}_a + \underline{\mathbf{K}}_b \quad (8)$$

如果图像中仅存在一种异常像元,则

$$\underline{\mathbf{K}}_a = \frac{N_a}{N} \mathbf{r}_a \circ \mathbf{r}_a \circ \mathbf{r}_a \circ \mathbf{r}_a \quad (9)$$

对于图像中任一像元的检测值为

$$\begin{aligned} \delta_{\text{COKD}}(\mathbf{r}_i) &= \underline{\mathbf{K}} \times_1 \mathbf{r}_i \times_2 \mathbf{r}_i \times_3 \mathbf{r}_i \times_4 \mathbf{r}_i - 3 \|\mathbf{r}_i\|^4 \\ &= (\underline{\mathbf{K}}_a + \underline{\mathbf{K}}_b) \times_1 \mathbf{r}_i \times_2 \mathbf{r}_i \times_3 \mathbf{r}_i \\ &\quad \times_4 \mathbf{r}_i - 3 \|\mathbf{r}_i\|^4 \\ &= \frac{N_a}{N} (\mathbf{r}_a^\top \mathbf{r}_i)^4 + \underline{\mathbf{K}}_b \times_1 \mathbf{r}_i \times_2 \mathbf{r}_i \\ &\quad \times_3 \mathbf{r}_i \times_4 \mathbf{r}_i - 3 \|\mathbf{r}_i\|^4 \end{aligned} \quad (10)$$

假设背景像元服从多维高斯分布,那么它在任意方向的峭度值均为0,即

$$\underline{\mathbf{K}}_b \times_1 \mathbf{r}_i \times_2 \mathbf{r}_i \times_3 \mathbf{r}_i \times_4 \mathbf{r}_i - 3 \|\mathbf{r}_i\|^4 \approx 0 \quad (11)$$

对任一像元的检测值

$$\delta_{\text{COKD}}(\mathbf{r}_i) \approx \frac{N_a}{N} (\mathbf{r}_a^\top \mathbf{r}_i)^4 = \frac{N_a}{N} \|\mathbf{r}_a\|^4 \|\mathbf{r}_i\|^4 \cos^4 \theta \quad (12)$$

其中, $\theta$ 代表 $\mathbf{r}_i$ 和 $\mathbf{r}_a$ 之间的夹角。通常情况下,异常像元游离于背景像元之外,即 $\|\mathbf{r}_a\| \geq \|\mathbf{r}_i\|$ 。所以,当 $\mathbf{r}_i = \mathbf{r}_a$ 时检测值 $\delta_{\text{COKD}}(\mathbf{r}_i)$ 最大,而当 $\mathbf{r}_i \neq \mathbf{r}_a$ 时,由于 $\cos^4 \theta$ 的存在将会对异常检测值 $\delta_{\text{COKD}}(\mathbf{r}_i)$ 进行压制,这就说明COKD算法能够有效地检测到异常点。相应地,本文把RXD算法和COSD算法重新表达为

$$\delta_{\text{RXD}}(\mathbf{r}_i) = \|\mathbf{r}_i\|^2 \quad (13)$$

$$\delta_{\text{COSD}}(\mathbf{r}_i) \approx \frac{N_a}{N} \|\mathbf{r}_a\|^3 \|\mathbf{r}_i\|^3 \cos^3 \theta \quad (14)$$

可见,RXD算法只考虑了像元在白化空间中的欧氏距离,只有在异常像元远离所有背景像元,且所有背景像元在原点附近时,RXD算法才会获得比较好的异常检测效果。COSD算法和COKD算法不仅考虑了像元在白化空间中的距离,还考虑了异常像元和待检测像元之间的夹角。

综上所述,给出COKD异常检测算法步骤:

(1)首先对高光谱图像数据进行中心化和白化;(2)计算图像的协峭度张量 $\underline{\mathbf{K}}$ ;(3)利用式(3)对白化后的图像像元进行逐一检测,得到相应的检测值。检测值较大的像元即为异常像元。

## 4 仿真实验

为了验证算法的有效性,本文将采用模拟数据和真实数据对RXD算法、COSD算法、KPCA-RXD算法和本文提出的COKD算法进行性能比较。

### 4.1 模拟数据实验

首先生成一幅含有10个波段的模拟数据,图像尺寸为 $100 \times 100$ 像素,在图像中心设置 $9 \times 9$ 的异常像元,该模拟数据的各个波段如图2所示。模拟数据均由MATLAB生成,其中背景像元由多维正




图2 模拟数据各波段灰度图

态随机分布函数mvnrnd生成，异常像元由随机函数rand生成。

图3给出了RXD, COSD, COKD及KPCA-RXD 4种算法生成的异常检测灰度图，从视觉上来

看COKD算法要优于其它3种算法，它能够在保持异常强度的同时更好地压制背景。图4给出了各算法的ROC曲线，表1则列出了各算法的AUC值。综合图4和表1, COKD算法的异常检测性能最好。




图3 异常检测结果灰度图




图4 COSD, RXD, COKD, KPCA-RXD算法的ROC曲线

表1 4种异常检测算法的AUC

算法	AUC
COKD	0.9997
RXD	0.9934
COSD	0.9996
KPCA-RXD	0.9936

## 4.2 真实数据实验

本节实验使用真实的高光谱图像数据测试算法的有效性。

图5(a)是由OMIS-II获取的位于西安的高光谱数据<sup>[24]</sup>，共包含从可见光到热红外的64个波段，空间分辨率约为3.6 m，在可见光到近红外区间(前60个波段)光谱分辨率约为10 nm。图像大小为100×100像素，在图像中存在两个隐藏的人工小目标，位于图像右上部，约占30个像元(图5(a)中用红色方框标记位置)。由于多种异常检测算法，都可以将其作为异常像元标记出来，因此可以将它们看做图像中存在的异常像元。由于该异常像元的位置是已知的，因而常被用来测试异常检测算法<sup>[21]</sup>。在实际进行异常检测时发现，将该图像进行白化后的检测效果较好，且协峭度张量的计算过程中也对数据进行了白化，因而，在异常检测之前首先对数据进行了白化处理，然后再使用本文提出的方法和RXD, COSD, KPCA-RXD算法分别对图像进行异常检测，检测结果的灰度图如图5(b)–图5(e)所示。

从图5可以看出，这4种方法都能检测到该异常像元的存在，但RXD算法和KPCA-RXD算法存在明显的“虚警”像元。图6显示了这4种检测算法的




图5 真实的高光谱图像检测结果

ROC曲线, ROC曲线说明COKD算法明显优于RXD和KPCA-RXD算法, 并且也在一定程度上优于COSD算法, 这和模拟数据的实验结果一致。表2所示的这4种异常检测算法的ROC曲线下面积AUC也进一步验证了COKD算法的优越性。




图6 4种异常检测算法的ROC曲线

表2 4种异常检测算法的AUC

算法	AUC
COKD	0.9832
RXD	0.9779
COSD	0.9830
KPCA-RXD	0.9778

图5(a)中的人工小目标占33个像素, 实验结果表明: COKD算法可以正确地检测出81.82%的异常像元, COSD算法可以正确地检测出78.79%的异常像元, 而RXD算法和KPCA-RXD算法则只能分别正确检测出69.70%和72.73%的异常像元。

## 5 总结

本文提出了一种基于协峭度张量的高光谱图像异常检测算法——COKD算法, 并详细分析了协峭度张量在异常检测中的应用。和传统的基于2阶统计量的异常检测算法相比, 本文算法同时考虑了像元在白化空间中的距离以及异常像元和待检测像元之间的夹角, 从而能够更好地提取出图像中的异常目标。此外, 和基于特征投影的异常检测算法相比, COKD算法不需要进行特征投影, 也不需要特征投影后的成分进行选择, 它可以直接生成关于异常点分布情况的灰度图。基于真实的高光谱图像

数据的仿真实验表明, COKD算法可以成功地将感兴趣异常目标检测出来。大多数情况下COKD和COSD对异常目标的提取效果接近, 但它们之间也存在细微差别。由于COKD的目标函数为4次函数, 而COSD的目标函数为3次, 所以相对于COSD, COKD对背景有更强的压制能力, 但同时也可能对目标本身有所压制。因此, 当异常目标的光谱具有一定变化时, 建议选用COSD甚至RXD。而当异常目标的光谱没有变化或者变化较小时, 用COKD一般会取得更好的结果。

需要指出的是, 当图像波段数非常高时, COKD算法中计算协峭度张量将占有较大内存且耗费较多时间。尽管如此, 协峭度张量的引入对图像的异常检测依然具有重要意义, 如果将COSD算法看做RXD算法从2阶统计量到3阶统计量的自然延伸和过渡, 那么COKD算法则可以看做COSD算法从3阶统计张量到4阶统计张量的自然过渡和延伸。所以, 其它基于2阶统计量或3阶统计量的异常检测方法都可以在COKD算法的基础上扩展为基于4阶统计量的异常检测方法。

## 参考文献

- [1] LÜ Qi, NIU Xin, DOU Yong, *et al.* Classification of hyperspectral remote sensing image using hierarchical local-receptive-field-based extreme learning machine[J]. *IEEE Geoscience and Remote Sensing Letters*, 2016, 13(3): 434–438. doi: 10.1109/LGRS.2016.2517178.
- [2] HEIDEN U, IWASAKI A, MULLER A, *et al.* Foreword to the special issue on hyperspectral remote sensing and imaging spectroscopy[J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2016, 9(9): 3904–3908. doi: 10.1109/JSTARS.2016.2610199.
- [3] LI Wei and DU Qian. A survey on representation-based classification and detection in hyperspectral remote sensing imagery[J]. *Pattern Recognition Letters*, 2016, 83: 115–123. doi: 10.1016/j.patrec.2015.09.010.
- [4] VERACINI T, MATTEOLI S, DIANI M, *et al.* Fully unsupervised learning of Gaussian mixtures for anomaly detection in hyperspectral imagery[C]. Ninth International Conference on Intelligent Systems Design and Applications, Pisa, Italy, 2009: 596–601. doi: 10.1109/ISDA2009220.

- [5] SALEM M B, ETTABAA K S, and BOUHLEL M S. Anomaly detection in hyperspectral images based spatial spectral classification[C]. International Conference on Sciences of Electronics, Technologies of Information and Telecommunications, Hammamet, Tunisia, 2017: 166–170. doi: [10.1109/SETIT.2016.7939860](https://doi.org/10.1109/SETIT.2016.7939860).
- [6] ZHANG Lili and ZHAO Chunhui. Hyperspectral anomaly detection based on spectral-spatial background joint sparse representation[J]. *European Journal of Remote Sensing*, 2017, 50(1): 362–376. doi: [10.1080/22797254.2017.1331697](https://doi.org/10.1080/22797254.2017.1331697).
- [7] THEILER J and ZIEMANN A K. Right spectrum in the wrong place: A framework for local hyperspectral anomaly detection[J]. *Electronic Imaging*, 2016, 2016(19): 1–9. doi: [10.2352/ISSN.2470-1173.2016.19.COIMG-160](https://doi.org/10.2352/ISSN.2470-1173.2016.19.COIMG-160).
- [8] CHIANG S S, CHANG C I, and GINSBERG I W. Unsupervised target detection in hyperspectral images using projection pursuit[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2001, 39(7): 1380–1391. doi: [10.1109/36.934071](https://doi.org/10.1109/36.934071).
- [9] WANG Lijing, GAO Kun, CHENG Xinman, *et al.* A hyperspectral imagery anomaly detection algorithm based on Gauss-Markov model[C]. Fourth International Conference on Computational and Information Sciences (ICCIS), Chongqing, China, 2012: 135–138. doi: [10.1109/ICCIS.2012.21](https://doi.org/10.1109/ICCIS.2012.21).
- [10] 耿修瑞. 高光谱遥感图像目标探测与分类技术研究[D]. [博士学位论文], 中国科学院遥感与数字地球研究所, 2005: 81–91.
- GENG Xiurui. Target detection and classification for hyperspectral imagery[D]. [Ph. D. dissertation], Institute of Remote Sensing and Digital Earth, Chinese Academy of Sciences, 2015: 81–91.
- [11] TAGHIPOUR A and GHASSEMIAN H. Hyperspectral anomaly detection using attribute profiles[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(7): 1136–1140. doi: [10.1109/LGRS.2017.2700329](https://doi.org/10.1109/LGRS.2017.2700329).
- [12] ZHANG Xing, WEN Gongjian, and DAI Wei. A tensor decomposition-based anomaly detection algorithm for hyperspectral image[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(10): 5801–5820. doi: [10.1109/TGRS.2016.2572400](https://doi.org/10.1109/TGRS.2016.2572400).
- [13] TERREAUX E, OVARLEZ J P, and PASCAL F. Anomaly detection and estimation in hyperspectral imaging using random matrix theory tools[C]. IEEE International Workshop on Computational Advances in Multi-Sensor Adaptive Processing, Cancun, Mexico, 2016: 169–172. doi: [10.1109/CAMSAP.2015.7383763](https://doi.org/10.1109/CAMSAP.2015.7383763).
- [14] XUN Lina and FANG Yonghua. Anomaly detection based on high-order statistics in hyperspectral imagery[C]. The Sixth World Congress on IEEE Intelligent Control and Automation, Dalian, China, 2006: 10416–10419. doi: [10.1109/WCICA.2006.1714044](https://doi.org/10.1109/WCICA.2006.1714044).
- [15] REN Hsuan and CHANG Yang Lang. A parallel approach for initialization of high-order statistics anomaly detection in hyperspectral imagery[C]. IEEE International Geosciences and Remote Sensing Symposium, Boston, USA, 2008: 1017–1020. doi: [10.1109/IGARSS.2008.4779170](https://doi.org/10.1109/IGARSS.2008.4779170).
- [16] CARDOSO J F. Eigen-structure of the fourth-order cumulate tensor with application to the blind source separation problem[C]. International Conference on Acoustics, Speech, and Signal Processing, Albuquerque, USA, 1990: 2655–2658. doi: [10.1109/ICASSP.1990.116165](https://doi.org/10.1109/ICASSP.1990.116165).
- [17] OSAKO K, MORI Y, TAKAHASHI Y, *et al.* Fast convergence blind source separation based on frequency subband interpolation by null beamforming[C]. IEEE Workshop on Applications of Signal Processing to Audio and Acoustics, New Paltz, USA, 2007. doi: [10.1109/ASPAA.2007.4392999](https://doi.org/10.1109/ASPAA.2007.4392999).
- [18] GU Yanfeng, LIU Ying, and ZHANG Ye. A selective KPCA algorithm based on high-order statistics for anomaly detection in hyperspectral imagery[J]. *IEEE Geoscience and Remote Sensing Letters*, 2008, 5(1): 43–47. doi: [10.1109/LGRS.2007.907304](https://doi.org/10.1109/LGRS.2007.907304).
- [19] 成宝芝, 赵春晖, 王玉磊. 基于四阶累积量的波段子集高光谱图像异常检测[J]. *光电子·激光*, 2012, 23(8): 1582–1588.
- CHENG Baozhi, ZHAO Chunhui, and WANG Yulei. Abnormal detection of hyperspectral images for band subsets based on fourth order cumulant[J]. *Journal of Optoelectronics-Laser*, 2012, 23(8): 1582–1588.
- [20] 成宝芝. 基于光谱特性的高光谱图像异常目标检测算法研究[D]. [博士学位论文], 哈尔滨工程大学, 2014.
- CHENG Baozhi. Abnormal target detection algorithm for hyperspectral images based on spectral characteristics[D]. [Ph.D. dissertation], Harbin Engineering University, 2014.
- [21] GENG Xiurui, SUN Kang, JI Luyan, *et al.* A high-order statistical tensor based algorithm for anomaly detection in hyperspectral imagery[J]. *Scientific Reports*, 2014, 4: 6869–6869. doi: [10.1038/srep06869](https://doi.org/10.1038/srep06869).
- [22] GENG Xiurui, JI Luyan, and SUN Kang. Principal skewness analysis: Algorithm and its application for multispectral/hyperspectral images indexing[J]. *IEEE Geoscience and Remote Sensing Letters*, 2014, 11(10): 1821–1825. doi: [10.1109/LGRS.2014.2311168](https://doi.org/10.1109/LGRS.2014.2311168).
- [23] GENG Xiurui, JI Luyan, ZHAO Yongchao, *et al.* A small target detection method for the hyperspectral image based on Higher Order Singular Value Decomposition (HOSVD)[J]. *IEEE Geoscience and Remote Sensing Letters*, 2013, 10(6): 1305–1308. doi: [10.1109/LGRS.2013.2238504](https://doi.org/10.1109/LGRS.2013.2238504).
- [24] 孙康. 高光谱图像波段选择技术研究[D]. [博士学位论文], 中国科学院电子学研究所, 2015: 123–160.
- SUN Kang. Research on band selection method for hyperspectral imagery[D]. [Ph.D. dissertation], Institute of Electric, Chinese Academy of Sciences, 2015: 123–160.

孟令博：女，1989年生，博士生，研究方向为高光谱图像特征提取及异常检测。

耿修瑞：男，1965年生，研究员，研究方向为高光谱图像处理技术。