

doi: 10. 6046/gtzyyg. 2014. 03. 01
引用格式: 成宝芝. 高光谱图像异常目标检测算法研究与进展[J]. 国土资源遥感, 2014, 26(3): 1-7. (Cheng B Z. Study and progress of anomaly target detection in hyperspectral imagery[J]. Remote Sensing for Land and esources, 2014, 26(3): 1-7.)

高光谱图像异常目标检测算法研究与进展

成宝芝

(大庆师范学院物理与电气信息工程学院, 大庆 163712)

摘要: 高光谱图像是一种新型的具有“图谱合一”特性的遥感图像,其连续的光谱曲线可更好地表达地表物质间的细微差异,在地表物质的分类、解混和目标探测等方面得到了广泛应用。随着高光谱遥感技术的深入发展,对不需要先验信息的异常目标检测的研究成为最活跃的方向之一,许多研究者提出了具有较好效果的异常检测算法。基于对国内外已有算法的综合归纳和分析,系统地论述了高光谱异常检测的研究现状和最新进展。阐述了高光谱异常目标检测的实质和基本理论;从算法思想、关键技术和优缺点等方面重点分析总结了较有代表性的异常目标检测算法,并对其进行了概括和阐述;最后对异常检测算法的未来研究方向进行了展望,力图为高光谱异常目标检测算法研究找到新的突破点。

关键词: 高光谱图像; 异常目标检测; 核函数; 支持向量数据描述

中图法分类号: TP 751.1 **文献标志码:** A **文章编号:** 1001-070X(2014)03-0001-07

0 引言

从 20 世纪 60 年代开始,遥感技术得到了迅速的发展。到了 20 世纪 80 年代,由于成像光谱仪的研制成功和广泛应用,出现了具有较高光谱分辨率的高光谱图像。近年来,国内外研究人员在充分理解高光谱图像光谱特性和空间特性的基础上,在地物分类(material classification)、光谱解混(spectral unmixing)和目标检测(target detection)等方面进行了深入研究,取得了许多成果,其中,对实用性较强的高光谱异常目标检测(anomaly target detection)算法的研究和应用得到了特别的关注,已成为高光谱图像研究的热点之一。异常目标检测的突出特点在于不需要对要检测的感兴趣目标的光谱提供任何先验信息,在这种近似“盲状态”的情况下,通过异常检测可以在高光谱图像中发现一些相对于所在背景来说是“异常”的目标。

高光谱图像异常检测的实质是一个二值假设检验问题,通过衡量被检测点与所选择的背景光谱样本间的差异判决其属于目标还是背景。检测似然比(likelihood ratio, LR)的构造是检测过程最主要的环节,LR 是异常目标检测的理论基础。给定一个观测光谱,二值的 LR 检测利用条件概率密度函数判定像元是背景像元还是目标像元,但在实际情况中,条

件概率密度函数所依赖的未知目标和背景参数很难得到。所以,一般用最大似然估计来代替检测 LR 中的未知参数,即广义 LR 检测(generalized likelihood ratio test, GLRT)^[1]。这样,就可以对预识别像元进行处理,设置一定的阈值,得到异常检测结果。

现有的异常目标检测算法主要从高光谱图像的背景信息分布模型、像元混合情况和非线性特性等几个角度展开的。本文从 RX 异常检测、混合像元异常检测和非线性异常检测等几个方面进行了研究,其中典型的算法有传统的 RX 算法^[2-3]、核 RX(kernel RX, KRX)算法^[4]、支持向量数据描述(support vector data description, SVDD)算法^[5]、基于光谱解译的 RX 算法^[6]、基于背景残差数据的 KRX 异常检测算法^[7]、基于聚类的异常检测算法^[8]和混合像元条件下的异常检测算法^[1,9]等。以期对这些方法进行概括和阐述,并对其发展方向进行展望,为高光谱异常目标检测算法研究找到新的突破点。

1 异常检测算法研究与进展

1.1 RX 异常检测

传统的 RX 异常算法最初是由 Reed 和 Yu 等从多光谱图像的检测算法发展而来的,在本质上可被看作主成分分析(principal component analysis, PCA)的逆过程。该算法将不符合背景统计特性的异常点

判为目标,是一种基于广义 LR 检验的恒虚警率异常检测 (constant false - alarm rate, CFAR) 算法^[10-12]。在 RX 算法^[13]中,一般假设背景模型符合高斯分布统计特性,虽然真实高光谱图像的背景分布可能与高斯分布有差异,但是这种假设在统计特性上具有合理性。

在局部正态模型的基础上,RX 算法在被检测像元的局部近邻中,采用双窗口模式(包括同心嵌套的背景窗和目标窗)估计协方差和均值等参数。一般情况下,背景窗口是外窗,目标窗口是内窗,且外窗要比内窗大很多,窗口的边长一般都取奇数值。

RX 算法实现的详细过程如下:定义 $\mathbf{X}_B$ 为包含

$$RX(r) = (r - \hat{\mu}_b)^T \left[\frac{M}{M+1} \hat{\mathbf{C}}_b + \frac{1}{M+1} (r - \hat{\mu}_b)(r - \hat{\mu}_b)^T \right]^{-1} (r - \hat{\mu}_b) \underset{H_0}{\overset{H_1}{>}} \eta, \quad (3)$$

式中: η 为判决阈值,其值大小与信噪比和虚警概率有关; $\hat{\mu}_b$ 与 $\hat{\mathbf{C}}_b$ 分别为背景均值和协方差矩阵的估计值,即

$$\hat{\mu}_b = \frac{1}{M} \sum_{i=1}^M x_i, \quad (4)$$

$$\hat{\mathbf{C}}_b = \frac{1}{M} \sum_{i=1}^M (x_i - \hat{\mu}_b)(x_i - \hat{\mu}_b)^T. \quad (5)$$

在真实数据中, $M \rightarrow \infty$, 则 RX 算子简化为

$$RX(r) = (r - \hat{\mu}_b)^T \hat{\mathbf{C}}_b^{-1} (r - \hat{\mu}_b) \underset{H_0}{\overset{H_1}{>}} \eta. \quad (6)$$

式(6)为 RX 算子的一般形式,在实际应用中大多采用此式。

传统的 RX 算法应用于高光谱异常检测也已取得了较好的效果,而且该算法原理简单,运行速度相对较快。但由于高光谱图像具有高维性、非线性等特点,而 RX 算法对这类图像本身存在的问题处理的效果不好,进而影响到异常目标检测精度的进一步提高,故许多研究者对传统 RX 算法进行了改进和完善。Matteoli 等^[14-15]提出了基于最小协方差行列式的 RX 算法 (minimum covariance determinant RX, MCD - RX),该算法从解决原始高光谱图像局部背景分布不完全符合均一高斯模型的情况出发,利用最小协方差行列式改善背景分布中小样本数据的影响,提高了传统 RX 算法的检测性能;但 MCD - RX 算法在整个数据空间中都需要估计鲁棒性的协方差,导致计算复杂度增加,故 Matteoli 又对 MCD - RX 算法进行完善,提出了峰度驱动的最小协方差行列式的 RX (kurtosis driven MCD - RX, KMCD - RX) 算法;该算法首先对原始像元应用基于峰度的二值假设检验快速确定像元的邻域是否存在异常

M 个像元的 $l \times M$ 背景矩阵,每个被观测的光谱像元都可以表示为一个列向量 $\mathbf{X}_B$,即

$$\mathbf{X}_B = [x_1, x_2, \dots, x_p]. \quad (1)$$

RX 算法区分目标的二值假设定义为

$$\begin{cases} H_0: x = \mathbf{n} & \text{目标不存在} \\ H_1: x = a\mathbf{s} + \mathbf{n} & \text{目标存在} \end{cases}, \quad (2)$$

式中: $a=0$ 时 H_0 成立, $a>0$ 时 H_1 成立; $\mathbf{n}$ 为背景噪声向量; $\mathbf{s} = [s_1, s_2, \dots, s_l]^T$ 为目标光谱向量(未知量)。

设 r 为观测数据, RX 算法的判决表达式为

目标,进而决定是否进行协方差的估计,从而降低了计算复杂度。Molero^[16]等则提出基于聚类的并行快速 RX 算法,该算法从缩短异常检测时间出发,通过聚类把具有相同特性的像元归为一类,然后并行执行 RX 异常检测算子,从而提高了 RX 异常检测的速度。Chang 等^[10]也从提高异常检测的时效性方面对传统 RX 检测算法提出了改进,引入了目标区别测量的概念,通过该方法利用聚类把不同的异常目标归到不同的目标类,有效地提高了异常检测的性能。Ren 等^[17]基于样本数据中如果异常像元数量过多会使得样本协方差矩阵不能再代表背景分布的问题,提出了一个加权的 RX 异常检测算法,提高了传统 RX 算法的性能。Riley 等^[18]从区分背景数据是噪声还是真正的异常目标出发,对 RX 异常检测算子进行重新构建,利用噪声协方差阵对传统的欧氏矩阵加以改进,构造成加权欧氏距离,将其通过拉格朗日乘法与 RX 异常检测器进行联合,形成新的异常检测器;该异常检测器在有效抑制噪声干扰的同时,改善了传统 RX 异常检测器的性能。

近年来, Rossi 等^[19]为了提高 RX 算法异常检测的实时性,提出了一个基于逐行处理更新策略架构的 RX 算法,该算法依据线性代数策略更新高光谱图像像元对应的逆矩阵的计算,降低了计算复杂度,提高了实时处理能力。Du 等^[20]对现有异常算法检测性能一方面易受检测窗或图像尺寸影响、另一方面对背景统计特性需要估计合适的窗口尺寸等问题进行研究,提出了基于背景像元随机选择的异常检测算法,在得到背景像元子集的基础上,利用马氏距离完成异常检测;相比于传统的 RX 等算法,检测性能有很大改善。

1.2 混合像元异常检测

由于成像光谱仪空间分辨率的限制和地物分布的复杂性,高光谱图像中的像元可能会由不同地表物质构成的多个端元组成(即出现混合像元情况)。从混合像元角度出发分析高光谱数据分布情况,可以得到更精确的异常目标检测结果。Stein^[11]首先利用丰度估计的直方图特征识别相似目标的端元,然后在丰度空间使用匹配滤波器检测存在的每一个目标端元,从线性混合模型角度得到最终的异常检测结果,通过仿真分析可以看出该算法具有较高的检测性能。李杰等^[7]提出了基于背景残差数据的KRX异常检测算法,通过提取背景端元抑制了背景干扰,突出了异常目标信息;在此基础上,将残差数据非线性映射到高维特征空间,再利用KRX算子完成目标检测,降低了虚警率、提高了异常目标检测性能。成宝芝等^[9]将光谱解混技术引入到支持向量数据描述的异常检测问题中,实现了高光谱图像复杂背景信息和目标信息的分离,使解混后的误差数据含有丰富的目标信息,抑制了背景干扰,同样取得了较好的检测结果。在考虑了高光谱图像的物理信息和统计信息的基础上,Broadwater等^[21]在对高光谱图像进行异常检测时构造了线性混合模型,并使用了多种检测器联合的方法检测子像元目标,取得了较好的效果。

1.3 非线性异常检测

前文阐述的RX异常检测算法把目标和背景信息之间的关系设定为线性关系,但是在有些情况下,由于异常目标和背景信息的分离需要一个复杂的决策边界,背景数据分布并不是总为高斯分布或者其他单峰状态的分布,导致基于线性的异常检测方法性能变差;另外,高光谱图像波段间也存在着非线性的强相关性。近年来,随着统计学习理论的快速发展和逐步完善,使用非线性的核机器学习进行异常检测成为一个研究热点;这类算法通过将原始高光谱数据非线性映射到高维的特征空间,充分挖掘其隐含的非线性信息。通过核技巧将高维特征空间的内积运算转化为低维输入空间的核函数计算,使得算法的处理过程变得简单^[22]。这里主要介绍具有代表性的KRX,SVDD及据其改进的非线性异常检测算法。

1.3.1 KRX及其改进算法

经典的核RX算法(KRX)是Kwon等^[4]在传统RX算法的基础上发展来的,是一种非线性的RX算法^[23-25]。KRX算法将原始数据 $\mathbf{X}_B$ 通过非线性函数 Φ 映射到高维特征空间,即

$$\Phi(\mathbf{X}_B) = [\Phi(x_1), \Phi(x_2), \dots, \Phi(x_M)] \quad (7)$$

式中: $\mathbf{X}_B$ 含有 M 个样本背景像元,即 $\mathbf{X}_B = [x_1, x_2, \dots, x_M]$ 。

$\Phi(\mathbf{X}_B)$ 是由两个高斯分布组成的,建立特征空间中的二值假设,即

$$\begin{cases} H_{0\phi}: \Phi(x) = \mathbf{n}_\phi & \text{目标不存在} \\ H_{1\phi}: \Phi(x) = \beta\Phi(s) + \mathbf{n}_\phi & \text{目标存在} \end{cases} \quad (8)$$

式中: $\beta=0$ 时 $H_{0\phi}$ 成立, $\beta>0$ 时 $H_{1\phi}$ 时成立; $\mathbf{n}_\phi$ 为特征空间内的背景噪声向量; $\Phi(s)$ 为目标光谱向量。

KRX算法的算子可以表示为

$$KRX[\Phi(r)] = [\Phi(r) - \hat{\mu}_{B\phi}]^T \hat{\mathbf{C}}_{B\phi}^{-1} [\Phi(r) - \hat{\mu}_{B\phi}] \quad (12)$$

式中: $\hat{\mu}_{B\phi}$ 和 $\hat{\mathbf{C}}_{B\phi}$ 分别为特征空间中的均值向量和背景协方差矩阵的估计值; $\hat{\mathbf{C}}_{B\phi}$ 为对称阵,利用特征值分解可表示为

$$\hat{\mathbf{C}}_{B\phi} = \mathbf{V}_\phi \mathbf{\Lambda}_\phi \mathbf{V}_\phi^T \quad (10)$$

式中: $\mathbf{\Lambda}_\phi = \text{diag}([\lambda_1, \lambda_2, \dots, \lambda_M])$ 为 $\hat{\mathbf{C}}_{B\phi}$ 的 M 个非零特征值构成的对角阵; $\mathbf{V}_\phi = [v_\phi^1, v_\phi^2, \dots, v_\phi^M]$ 是 $\hat{\mathbf{C}}_{B\phi}$ 的 M 个特征值对应的特征向量的列矩阵。

通过式(9),不需要具体的映射函数,也不需要高维的特征空间进行相应的点积运算,只需要寻找一个合适的核函数来产生一个正定的Gram核矩阵,就可以对原始高光谱数据进行KRX异常检测。

KRX算法充分利用了高光谱图像的非线性特性,但也存在一些问题:①计算复杂度高,因为需要计算高阶的Gram矩阵及其逆矩阵;②没有成熟的理论原则可以确定如何选择核函数及其参数。目前,普遍采用的是高斯径向基(Gaussian radial basis function, Gaussian-RBF, RBF)核函数,该核函数适合应用在异常目标检测问题中,也能得到较好的检测结果;但公式中涉及的参数的选择比较复杂,需要经多次实验验证才能确定。因此,研究人员又提出了很多基于KRX的改进算法。赵春晖等^[26]提出了核加权RX高光谱图像异常检测算法,该算法从协方差矩阵准确表征背景数据分布出发,通过加权的方法使协方差矩阵可以更好地符合背景数据分布,从而提高背景分布的均一性,改善了异常检测结果。胡春梅等^[27]提出了基于背景误差累积的高光谱图像异常检测算法,该算法首先构造一个背景子空间,然后把各像元投影到该子空间,使得背景得到有效抑制并突出了异常目标信息,更好地降低了虚警率、提高了检测性能。梅峰等^[28]提出了基于空域滤波的KRX异常检测算法,该算法从改善背景信息分布特性出发,首先把需要检测的高光谱图像利用中值滤波进行处理,然后利用KRX进行异常检测,

在一定程度上改善了经典 KRX 算法的性能。胡春梅等^[29]提出了基于目标正交子空间投影加权(target orthogonal subspace projection weighted, TOSPW)异常检测算法,该算法从子空间角度出发,首先估算背景协方差矩阵,然后将每个像元投影到目标的正交子空间中,并自适应地赋予每个像元合适的权值,以减小背景特性估计受目标信息的影响,从而检测到更多的异常目标、降低了虚警率。

史振威等^[30]为了提高 KRX 算法在高光谱图像异常检测中的稳定性,从规范背景协方差矩阵角度出发,将核矩阵正则化,提出了正则化的 KRX 算法。该算法同时考虑了原始线性空间和高维特征空间的异常检测结果,使异常检测效果更加稳定。

1.3.2 SVDD 及其改进算法

Banerjee 等^[5]最先提出了利用支持向量数据描述(SVDD)的高光谱图像异常检测算法。SVDD 是一类分类器,该算法通过发现一个含有训练数据的最小超球面估计支持区的训练数据,寻找最小封闭超球包围具有共同特性的一类样本,并用判别准则使这一类与其他类样本分开^[31],实现异常检测。

SVDD 算法作为一种数据驱动算法,不存在假设模型与数据实际分布特点不符的问题;该算法将光谱信号映射到高维特征空间后,利用核函数的性质进行异常点的检测,较好地利用了高光谱图像波段间的非线性统计特性。但该算法在时效性差、计算复杂和核参数的选择复杂等方面存在不足,为进一步提高其检测性能,许多研究者对该算法进行了改进。Khazai 等^[32]从核参数的选择角度出发,提出了自适应的 SVDD 异常检测算法,该算法基于核函数的参数选择对性能的提高有重要的作用,而又不容易确定的实际情况,使用了一种自适应的几何解释的方法估计核参数的值,提高了异常检测的性能。谌德荣^[33]等为了解决 SVDD 对于局部异常目标检测精度不高的问题,通过空间邻域聚类获取潜在的异常目标,并根据检测的异常目标特点选择背景窗收集样本,获取背景光谱的参数,得到了结合空间邻域聚类分割的局部异常检测算法,提高了传统 SVDD 算法的异常检测精度。梅峰等^[34]为了更好地确定核参数,提出了基于支持向量描述的自适应高光谱异常检测算法,该算法通过局部背景分波段二阶分布统计,对局部背景总体标准差与核参数的变化关系进行了分析,构造了一个新的局部检测核参数——随检测背景不同而变化的核参数,这种参数设定方法克服了传统的 SVDD 算法由于采用固定核参数带来的检测性能下降的问题。Gurram 等^[35]从核函数选择角度出发,提出了一个基于稀疏核的

SVDD 高光谱图像异常检测算法,该算法是从基于稀疏核的集成学习(sparse kernel - based ensemble learning, SKEL)发展来的。SKEL 算法把给定的一个多元数据集表示的常态特征随机二次抽样到特征子空间,在各个特征子空间重建的再生核希尔伯特空间(reproducing kernel Hilbert space, RKHS)中,定义了一个支持常态数据的封闭的超球面,该算法相比于传统的 SVDD 算法提高了检测性能。针对传统 SVDD 算法计算时间较长的缺点, Khazai 等^[36]提出了一个快速自适应 SVDD 异常检测算法,该算法包括聚类、背景模型化和自动异常检测 3 个过程,与全局性的 SVDD 异常算法相比,检测性能和计算复杂度方面都有很大提高。另外,谌德荣等^[37]针对基于 SVDD 异常检测算法存在计算量巨大等问题,提出了基于样本分割的快速高光谱图像异常检测 SVDD 方法,通过样本分割降低 SVDD 用于局部异常检测的计算量,也取得了较好的异常检测效果。

1.3.3 采用核方法的其他非线性算法

近年来,还有一些研究者提出了新的采用核函数的非线性异常检测算法。例如: Zhao 等^[38]提出的利用核独立成分分析(kernel independent component analysis, KICA)进行特征提取的高光谱异常检测算法; Goldberg 等^[39]提出的在高维特征空间利用特征值分解方法实现小目标的异常检测。总的来说,利用非线性方法特别是核方法进行异常目标检测,还有很多问题需要研究。无论是发现新的核方法,或者是把已有的线性方法“核化”,都是值得研究的方向。

1.4 其他异常检测算法

1.4.1 高斯马尔科夫随机场模型

RX 算法存在的基础是建立在背景信息分布属于局部正态分布模型(local normal model, LNM)。由于真实高光谱数据分布的复杂性,存在背景信息分布不一致的问题;另外,算法中涉及的高阶协方差矩阵及其逆矩阵求解的计算复杂度高,影响了算法的实时性。因此, Schweizer 等^[40-41]在 RX 算法基础上,提出了基于 LNM 的利用高斯马尔可夫随机场(Gaussian Markov random field, GMRF)对高光谱数据进行建模,求解异常目标问题。该算法考虑了高光谱图像的空间相关性,使用 1 个三维的一阶马尔可夫随机场(Markov random field, MRF)对背景信号建模。该算法相对于 RX 算法的优点在于可直接得到波段协方差阵逆阵的估计,避免高阶矩阵求逆过程的困难。GMRF 协方差的逆矩阵仅用 4 个参数就可以描述,使用小尺寸的估计窗就可以得到可靠的逆矩阵估计,因而减少了估计窗中的背景分布不一

致的可能。

1.4.2 子空间技术

子空间算法首先在高光谱图像中寻找背景的光谱特征,然后利用子空间投影等方法进行异常检测。低概率检测(low probability detection,LPD)^[42]异常目标算法是其中最重要的方法之一,它通过构建正交子空间,并投影原始高光谱数据于其上,达到抑制背景信息、突出异常目标,最终利用背景与目标之间的对比度增大达到检测出异常目标的目的。王玉磊等^[43]也从子空间分割角度出发,利用基于特征融合的 LPD 算法进行异常目标检测,取得了较好的异常检测结果。

1.4.3 概率密度估计

He 等^[44]对于异常检测中背景分布模型非均匀一致的问题进行分析,提出了基于最大熵和非参数估计的高光谱异常检测算法。该算法通过高光谱数据样本得到数据的统计信息,而不需要知道数据的统计模型,通过仿真得到的异常目标检测结果优于传统的 RX 算法。

2 异常检测算法性能评价

对异常检测算法性能进行评价的一个重要指标是接收机操作特性(receiver operating characteristic,ROC)曲线。ROC 用于描述检测概率与虚警概率之间的变化关系^[45]。根据地面目标真实分布图可以获得每个目标所包含的像元区域坐标,异常目标和虚警的区分通过分析检测到的异常点是否处于真实图的目标区域之内来判断,如落入其内,则认定为异常目标,反之则为虚警。将检测概率 P_d 定义为检测到的真实目标像元数目 N_{hit} 与地面真实目标像元数目 N_{target} 的比值,虚警概率 P_f 定义为检测到的虚警像元数目 N_{false} 同整幅图像像元数目总和 N_{total} 的比值^[1,34],即

$$P_d = N_{hit} / N_{target} \quad , \quad (11)$$

$$P_f = N_{false} / N_{total} \quad \circ \quad (12)$$

通过比较各算法的 ROC 曲线,就能对各算法的异常目标检测性能进行评估。另外,异常目标检测算法能检测到的目标个数、目标所占像元数和虚警所占像元数等 3 个统计结果,也是对各算法性能进行评价的重要指标。

3 结论与展望

随着遥感科学技术的不断发展,高光谱图像处

理技术已经得到广泛重视和深入研究。由于地表物质的多样性和光谱分布的复杂性,尽管异常目标检测技术有了快速的发展,但是仍存在许多问题。从未来研究的角度来看,高光谱异常检测技术需要关注和解决的问题有:

1)现有的算法在光谱特性方面研究的比较深入。但是,随着成像光谱仪硬件技术和核心软件的不断进步,高光谱图像在空间分辨率方面也有了很大提高,如何更好地结合高光谱图像的光谱特性和空间特性进行异常目标检测值得关注。

2)在异常目标检测中,非线性核方法的引入取得了很好的效果,许多研究者也在不断对原来非核的异常检测算法进行核化,并也都很好地改善了原有算法的异常检测性能。目前,核方法中的核函数普遍采用的是 RBF 核函数,该函数用于异常检测在一定程度上也具有优良的性能。但是通过对高光谱图像光谱和空间特性的分析,在充分理解其复杂性的基础上,是否能找到一个更好的核函数(或者合理设定 RBF 核函数的参数)用于异常目标检测,提高算法的性能,也是一个需要深入研究的难点。

3)高光谱图像波段多,在带来丰富的地物信息的同时,也给异常检测算法引入了“维数灾难”问题。所以,寻找更好的特征提取和降维技术是一件有重要意义的事情。

参考文献 (References) :

[1] 梅 峰. 基于核机器学习的高光谱异常目标检测算法研究 [D]. 哈尔滨:哈尔滨工程大学,2009.
Mei F. Research on kernel machine learning based anomaly detection algorithms in hyperspectral imagery [D]. Harbin: Harbin Engineering University, 2009.

[2] Reed I S, Yu X L. 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.

[3] Yu X L, Hoff L E, Reed I S, et al. Automatic target detection and recognition in multiband imagery: A unified ML detection and estimation approach [J]. IEEE Transactions on Image Processing, 1997, 6(1): 143 - 156.

[4] Kwon H, Nasrabadi N M. Kernel RX - algorithm: A nonlinear anomaly detector for hyperspectral imagery [J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(2): 388 - 397.

[5] Banerjee A, Burlina P, Diehl C. A support vector method for anomaly detection in hyperspectral imagery [J]. IEEE Transactions on Geoscience and Remote Sensing, 2006, 44(8): 2282 - 2291.

[6] 谷延锋, 刘 颖, 贾友华, 等. 基于光谱解译的高光谱图像奇异检测算法 [J]. 红外与毫米波学报, 2006, 25(6): 473 - 477.
Gu Y F, Liu Y, Jia Y H, et al. Anomaly detection algorithm of hyperspectral images based on spectral analyses [J]. Journal of Infrared and Millimeter Waves, 2006, 25(6): 473 - 477.

- [7] 李杰,赵春晖,梅锋. 利用背景残差数据检测高光谱图异常[J]. 红外与毫米波学报,2010,29(2):150-155.
Li J,Zhao C H,Mei F. Detecting hyperspectral anomaly by using background residual error data[J]. Journal of Infrared and Millimeter Waves,2010,29(2):150-155.
- [8] Carlotto M J. A cluster-based approach for detecting man-made objects and changes in imagery[J]. IEEE Transactions on Geoscience and Remote Sensing,2005,43(2):374-387.
- [9] 成宝芝,赵春晖,王玉磊. 结合光谱解混的高光谱图像异常目标检测 SVDD 算法[J]. 应用科学学报,2012,30(1):82-88.
Cheng B Z,Zhao C H,Wang Y L. SVDD algorithm with spectral unmixing for anomaly detection in hyperspectral images[J]. Journal of Applied Sciences,2012,30(1):82-88.
- [10] Chang C I,Chiang S S. Anomaly detection and classification for hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing,2002,40(6):1314-1325.
- [11] Stein D W J,Beaven S G,Hoff L E,et al. Anomaly detection from hyperspectral imagery[J]. IEEE Signal Processing Magazine,2002,19(1):58-69.
- [12] Stein D W J. Stochastic compositional models applied to subpixel analysis of hyperspectral imagery[J]. Proceedings of SPIE,2002,4480:49-56.
- [13] Fowler J E,Du Q. Anomaly detection and reconstruction from random projections[J]. IEEE Transactions on Image Processing,2012,21(1):184-195.
- [14] Matteoli S,Diani M,Corsini G. Improved estimation of local background covariance matrix for anomaly detection in hyperspectral images[J]. Optical Engineering,2010,49(4):046201-1-046201-6.
- [15] Matteoli S,Diani M,Corsini G. Hyperspectral anomaly detection with kurtosis-driven local covariance matrix corruption mitigation[J]. IEEE Geoscience and Remote Sensing Letters,2011,8(3):532-536.
- [16] Molero J M,Paz A,Garzón E M,et al. Fast anomaly detection in hyperspectral images with RX method on heterogeneous clusters[J]. The Journal of Supercomputing,2011,58(3):411-419.
- [17] Ren H,Chen C W,Chen H T. Weighted anomaly detection for hyperspectral remotely sensed images[C]//Proc. SPIE The International Society for Optical Engineering,2005,5995:599501-599507.
- [18] Riley R A,Newsom R K,Andrews A K. Anomaly detection in noisy hyperspectral imagery[C]//USA: SPIE - Int. Soc. Opt. Eng,2004,5546:159-170.
- [19] Rossi A,Acito N,Diani M,et al. RX architectures for real-time anomaly detection in hyperspectral images[J]. Journal of Real-Time Image Processing,2012,11:12-26.
- [20] Du B,Zhang L P. Random-selection-based anomaly detector for hyperspectral imagery[J]. IEEE Transactions on Geoscience and Remote Sensing,2011,49(5):1578-1589.
- [21] Broadwater J,Chellappa R. Hybrid detectors for subpixel targets[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence,2007,29(11):1891-1903.
- [22] Scholkopf B,Smola A J. Learning with kernels:Support vector machines regularization, optimization and beyond[M]. Cambridge, MA:MIT Press,2001.
- [23] Kwon H,Nasrabadi N M. A comparative study of kernel spectral matched signal detectors for hyper-spectral target detection[C]//The International Society for Optical Engineering. USA: SPIE,2005,5806:827-838.
- [24] Kwon H,Nasrabadi N M. Kernel adaptive subspace detector for hyperspectral target detection[C]//International Conference on Acoustics,Speech, and Signal Processing. USA: IEEE,2005,4:681-684.
- [25] Kwon H,Nasrabadi N M. Kernel-based subpixel target detection in hyperspectral images[C]//International Joint Conference on Neural Networks. USA: IEEE,2004,1:717-721.
- [26] 赵春晖,李杰,梅锋. 核加权 RX 高光谱图像异常检测算法[J]. 红外与毫米波学报,2010,29(5):378-382.
Zhao C H,Li J,Mei F. A kernel weighted RX algorithm for anomaly detection in hyperspectral imagery[J]. Journal of Infrared and Millimeter Waves,2010,29(5):378-382.
- [27] 赵春晖,胡春梅,包玉刚. 一种背景误差累积的高光谱图像异常检测算法[J]. 光子学报,2010,39(10):1830-1835.
Zhao C H,Hu C M,Bao Y G. A kind of anomaly detection algorithm for hyperspectral image through background error cumulation[J]. Acta Photonica Sinica,2010,39(10):1830-1835.
- [28] 梅锋,赵春晖. 基于空域滤波的核 RX 高光谱图像异常检测算法[J]. 哈尔滨工程大学学报,2009(6):697-702.
Mei F,Zhao C H. Spatial filter based anomaly detection algorithm for hyperspectral imagery kernel RX detectors[J]. Journal of Harbin Engineering University,2009(6):697-702.
- [29] 赵春晖,胡春梅. 基于目标正交子空间投影加权的高光谱图像异常检测算法[J]. 吉林大学学报:工学版,2011,41(5):1468-1474.
Zhao C H,Hu C M. Weighted anomaly detection algorithm for hyperspectral image based on target orthogonal subspace projection[J]. Journal of Jilin University:Engineering and Technology Edition,2011,41(5):1468-1474.
- [30] 史振威,吴俊,杨硕,等. RX 及其变种在高光谱图像中的异常检测[J]. 红外与激光工程,2012,41(3):796-802.
Shi Z W,Wu J,Yang S,et al. RX and its variants for anomaly detection in hyperspectral images[J]. Infrared and Laser Engineering,2012,41(3):796-802.
- [31] 湛德荣,宫久路,何光林,等. 高光谱图像全局异常检测 RFS-SVDD 算法[J]. 宇航学报,2010,31(1):228-232.
Chen D R,Gong J L,He G L,et al. A RFS-SVDD algorithm for hyperspectral global anomaly detection[J]. Journal of Astronautics,2010,31(1):228-232.
- [32] Khazai S,Homayouni S,Safari A. Anomaly detection in hyperspectral images based on an adaptive support vector method[J]. IEEE Geoscience and Remote Sensing Letters,2011,8(4):646-650.
- [33] 湛德荣,张立燕,陶鹏,等. 结合邻域聚类分割的高光谱图像异常检测支持向量数据描述方法[J]. 宇航学报,2007,28(3):767-771.
Chen D R,Zhang L Y,Tao P,et al. Support vector data description for anomaly detection in hyperspectral imagery combined with neighbor-ring clustering segmentation[J]. Journal of Astronautics,2007,28(3):767-771.
- [34] 梅锋,赵春晖,王立国,等. 基于支持向量描述的自适应高光谱异常检测算法[J]. 光子学报,2009,38(11):2820-2825.
Mei F,Zhao C H,Wang L G,et al. Support vector data description

based on adaptive anomaly detection method in hyperspectral imagery[J]. Acta Photonica Sinica,2009,38(11):2820–2825.

[35] Gurram P,Kwon H,Han T. Sparse kernel – based hyperspectral anomaly detection[J]. IEEE Geoscience and Remote Sensing Letters,2012,9(5):943–947.

[36] Khazai S,Safari A,Mojaradi B,et al. A fast – adaptive support vector method for full – pixel anomaly detection in hyperspectral images[C]//IEEE International Geoscience and Remote Sensing Symposium. Vancouver,BC,Canada;IEEE,2011;1763–1767.

[37] 谌德荣,宫久路,陈 乾,等. 基于样本分割的快速高光谱图像异常检测支持向量数据描述方法[J]. 兵工学报,2008,29(9):1049–1053.

Cheng D R,Gong J L,Chen Q,et al. Support vector data description for fast anomaly detection in hyperspectral imagery based on sample segmentation[J]. Acta Armamentarii,2008,29(9):1049–1053.

[38] Zhao C H,Wang Y L,Mei F. Kernel ICA feature extraction for anomaly detection in hyperspectral imagery[J]. Chinese Journal of Electronics,2012,21(2):265–269.

[39] Goldberg H,Kwon H,Nasrabadi N M. Kernel eigenspace separation transform for subspace anomaly detection in hyperspectral imagery [J]. IEEE Geoscience and Remote Sensing Letters,2007,4(4):581–585.

[40] Schweizer S M,Moura J M F. Hyperspectral imagery: Clutter adaptation in anomaly detection[J]. IEEE Transactions on Information Theory,2000,46(5):1855–1871.

[41] Schweizer S M,Moura J M F. Efficient detection in hyperspectral imagery[J].IEEE Transactions on Image Processing,2001,10(4):584–597.

[42] 张立燕,谌德荣,李世义,等. 基于低概率检测的高光谱图像有损压缩方法研究[J]. 弹箭与制导学报,2008,28(1):307–310.

Zhang L Y,Cheng D R,Li S Y,et al. Research on hyperspectral imagery loss compression method based on low probability detection [J]. Journal of Projectiles,Rockets, Missiles and Guidance,2008,28(1):307–310.

[43] 王玉磊,赵春晖,王江洪. 基于低概率检测的高光谱异常目标检测算法研究[J]. 黑龙江大学自然科学学报,2010,27(3):411–416.

Wang Y L,Zhao C H,Wang J H. Anomaly detection based on low probability detection for hyperspectral image[J]. Journal of Natural Science of Heilongjiang University,2010,27(3):411–416.

[44] He L,Pan Q,Di W,et al. Anomaly detection in hyperspectral imagery based on maximum entropy and nonparametric estimation [J]. Pattern Recognition Letters,2008,29(9):1392–1403.

[45] Gao G. A parzen – window – kernel – based CFAR algorithm for ship detection in SAR images[J]. IEEE Geoscience and Remote Sensing Letters,2011,8(3):557–561.

Study and progress of anomaly target detection in hyperspectral imagery

CHENG Baozhi

(College of Physics and Electrical Information Engineering , Daqing Normal University , Daqing 163712 , China)

Abstract: Hyperspectral image is a new kind of remote sensing images with the feature of “combining mapping and spectra into one”, thus better expressing the subtle differences on the surface of the material through the continuous spectral curve. Hyperspectral images have a wide range of applications in such aspects as classification, unmixing and target detection. With the continuous development of hyperspectral remote sensing technology, anomaly target detection has become one of the most active direction of research because it doesn’t need a priori information. Many anomaly target detection algorithms have been proposed. Based on data available both in China and abroad, this paper summarized the research situation and new progress in anomaly detection algorithms. The author first expounded the essence of hyperspectral anomaly target detection and used the basic theory and then analyzed and summed up some representative anomaly detection algorithms in such aspects as the ideas of algorithm, key technology, advantages and disadvantages. On such a basis, the author summarized and described the evaluation method of anomaly detection and discussed the future development trend of anomaly target detection algorithm, with the purpose of finding new breakthroughs in the study of the algorithm of hyperspectral anomaly target detection.

Key words: hyperspectral image; anomaly target detection; kernel function; support vector data description (SVDD)

作者简介: 成宝芝(1976 –),男,博士,讲师,主要从事高光谱图像处理研究。Email: chengbaozhigy@163.com。

(责任编辑: 李 瑜)