

引文格式:黄远程,薛园园,李朋飞.高光谱影像子空间分析孤立森林异常目标探测方法[J].测绘学报,2021,50(3):416-425. DOI:10.11947/j.AGCS.2021.20200036.
HUANG Yuancheng, XUE Yuanyuan, LI Pengfei. Subspace analysis isolation forest for hyperspectral anomaly detection[J]. Acta Geodaetica et Cartographica Sinica, 2021, 50(3): 416-425. DOI: 10.11947/j.AGCS.2021.20200036.

高光谱影像子空间分析孤立森林异常目标探测方法

黄远程, 薛园园, 李朋飞

西安科技大学测绘科学与技术学院, 西安 710054

Subspace analysis isolation forest for hyperspectral anomaly detection

HUANG Yuancheng, XUE Yuanyuan, LI Pengfei

College of Geomatics, Xi'an University of Science and Technology, Xi'an 710054, China

Abstract: Since the anomalies are usually “rare and different” in the hyperspectral image scene, they tend to be more easily isolated from the background pixels by appropriate splitting criterion. In view of this, we propose a hyperspectral anomaly detection method based isolation forest (*iForest*) with subspace analysis. Firstly, orthogonal subspace background suppression and dimension reduction techniques were used to improve the reliability of the isolation tree-splitting criterion. Secondly, the *iForest*-based detection may produce a number of false alarms since the forest is constructed using the randomly selected pixels in the whole scene. In order to solve this problem, the initial anomaly detection map was refined by local *iForest* processing. Compared with original *iForest* method, our approach can not only handle high dimensional problem, but also make full use of the local information. The experiments demonstrate the AUC score have been significantly improved in our approach.

Key words: hyperspectral imagery; anomaly detection; isolation forest; orthogonal subspace; principal component analysis

Foundation support: The National Natural Science Foundation of China (No. 41977059); Ministry of Public Security Key Laboratory of Forensic Marks Open Foundation (No. 2020FMKFKT07)

摘要:复杂的背景信息和高维冗余波段是影响高光谱遥感影像异常目标检测精度的重要因素。本文针对高光谱影像异常目标提取提出了一种子空间分析孤立森林探测方法。该方法不对背景做高斯分布假设,通过正交子空间分析增强输入特征影像中潜在异常目标与背景之间的对比度,通过主成分分析法降维来降低孤立森林算法带来的不确定性,运用了全局和局部结合的思想实现异常目标检测。在停机坪、海滩、港口和草地4个不同场景的高光谱影像上的试验结果表明,本方法的异常目标提取精度较经典方法取得了更好的结果。该方法不仅有效地处理了高光谱遥感影像的复杂背景和高维问题,还有效地利用了空间信息。

关键词:高光谱影像;异常目标检测;孤立森林;正交子空间;主成分分析

中图分类号:P237

文献标识码:A

文章编号:1001-1595(2021)03-0416-10

基金项目:国家自然科学基金(41977059);痕迹科学与技术公安部重点实验室开放基金(2020FMKFKT07)

遥感中的异常信息通常以低概率的形式出现在地表环境中,且与周围环境存在光谱或空间属性上明显差异^[1-2]。异常目标检测被认为是一个二分类问题,它将待测像素分为异常类或背景类^[3],它的特点是在背景和异常目标无先验知识的情况下识别出感兴趣目标^[4-5]。而高光谱图像


具有数百个光谱波段,为每个像素提供了丰富的光谱信息,这一优势使其成为异常目标检测最有价值的遥感手段^[6-7],比如利用高光谱影像检测海洋环境背景下的船舶溢油^[8]和机场的飞机,发现地表的矿物^[9]等。

异常目标检测有两类代表性的方法:①基于


统计模型的异常检测,这类方法假设背景服从特定的概率分布,而背离该概率分布的样本则为异常。其中,应用最为广泛的是RX算子^[10-11],它建立在背景服从高斯分布假设的基础上,通过计算待探测像素与背景的马氏距离来判断像素点是否属于异常目标。但由于背景并不一定简单地服从单一的高斯分布,故而产生较高的虚警率。局部RX算子则在背景的协方差与均值估计时容易受潜在的异常信号影响。②基于误差重建的异常检测,这类方法不对背景的概率分布做一般假设,而是采用构建背景字典来对待检测像元进行重构^[12-13],以重构误差来反映异常。但该方法多以线性稀疏表达为主,无法有效地处理线性不可分问题;此外字典构建是关键,全局字典依赖于非监督学习算法获得,局部字典则由局部邻域像素构成,局部构建的字典也易受可能的异常像元影响^[14]。

与上述方法不同,孤立森林(isolation forest, *iForest*)异常检测定义异常样本为分布稀疏且易被孤立的离群点^[15],如图1(b)点 x_0 。*iForest*在子采样的基础上使用随机超平面切割特征空间来

构建孤立树(isolation tree, *iTree*),如图1(a)中正常的样本点 x_i 需多次切割到达更深的树叶节点上才能被孤立;图1(b)中异常点 x_0 只需较少的切割次数就能够被孤立,它靠近孤立树的根部,有较短的路径长度。 t 个*iTrees*组成*iForest*,然后用生成的*iForest*来评估测试数据,*iForest*中具有短的平均路径长度的点被识别为异常,而这个异常度值是通过将森林里的所有树用集成的方法计算得到的。它为解决异常检测问题提供了一个新的视角,即不需要对背景概率分布做出假设,且具有集成多种不同特征的优势。但孤立树的构建将决定着*iForest*模型异常检测的性能。特别的,若将*iForest*直接应用于高维高光谱遥感影像进行异常检测,则容易出现两个主要的问题:①遥感影像中地物复杂,对输入特征进行随机阈值剖分时不易有效的区分背景与目标;②仍有重要的光谱特征易在建完树后没被使用^[16-17]。这是因为高光谱影像波段众多且相邻波段之间相关性大,*iTrees*的每一个结点对应的特征均采用随机的方式定义,无法有效地保证具有区别能力的关键特征被选中。



(a) Isolation x_i (一个正常的数据点被孤立需要12个随机分区)



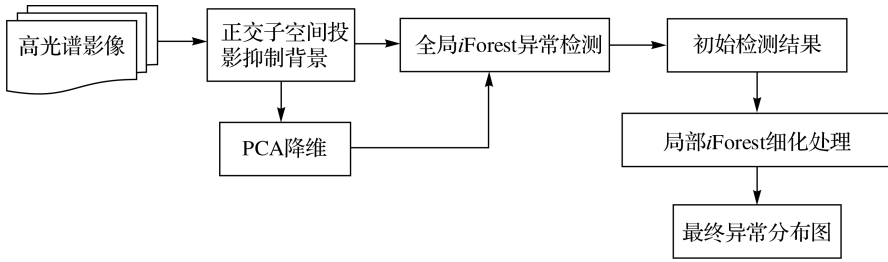
(b) Isolation x_0 (一个异常的数据点被孤立仅需要4个随机分区就能被隔离)

图1 孤立森林对特征空间中数据点切割

Fig.1 Schematic diagram of data point cutting in feature space

为了利用*iForest*求解异常目标问题的优势,同时克服其直接应用于高光谱影像分析的困难,本文提出了一种子空间分析孤立森林异常目标探测方法,其总体流程如图2所示。针对问题①,采用正交子空间分析^[18]技术增强输入特征影像中潜在异常目标与背景之间的对比度,以减少背景的干扰;针对问题②,对增强的目标特征影像

利用主成分分析方法将其投影到一个低维子空间进行降维^[19],从而降低维数过高给*iForest*算法带来的不确定性;在此基础上,采用在整幅图像中随机采样的方式来构建孤立森林获得初步检测结果,称之为全局*iForest*异常检测;最后利用滑动窗口进行局部的*iForest*异常检测来细化初始异常检测结果,得到最终的异常分布。

图2 基于子空间分析的 *iForest* 异常目标检测流程Fig.2 *iForest* anomaly detection flowchart with subspace analysis and global-local processing

1 本文方法

1.1 正交子空间抑制背景类信息

假设 $r \in \mathbb{R}^{L \times 1}$ 为 L 维高光谱图像的任意像元,根据正交子空间分析理论,假设目标子空间为 $S \in \mathbb{R}^{L \times c}$,背景子空间 $U \in \mathbb{R}^{L \times k}$,它们构成了影像的特征空间,则图像的每个像元可由目标子空间 S 和背景子空间 U 进行线性表达,其中 c 和 k 分别是目标子空间和背景子空间的大小。如式(1)所示

$$r = S\alpha + U\gamma + \varepsilon \quad (1)$$

式中,第1项用 S 及其对应系数 α 的乘积表示感兴趣目标信息;第2项由 U 及其对应系数 γ 表示背景信息,公式中的 $\varepsilon \in \mathbb{R}^{L \times 1}$ 为模型误差。若记 P_U^\perp 为 U 的正交子空间,如式(2)的定义

$$P_U^\perp = I - U(U^T U)^{-1} U^T \quad (2)$$

然后将其乘以每一个像元矢量如式(3)

$$P_U^\perp r = P_U^\perp S\alpha + P_U^\perp \varepsilon \quad (3)$$

即像元向量投影于背景的正交子空间中,这样消除了式(1)的第2项,使得与 U 相关的背景信息被抑制后只剩下目标相关的信息。这一思想称为高光谱影像正交子空间投影(OSP)的分析^[20]。

本文采用两种方法定义式(1)的 U ,分别为主成分特征子空间法和典型类判别特征子空间法。这两类方法定义的背景子空间和目标相关子空间符合式(1)的线性模型。

(1) 主成分特征子空间法:假设 $[U_1, U_2, \dots, U_L]$ 为高光谱影像的主成分特征向量,其对应的特征值由大到小排列^[21]。由于异常目标在影像中分布稀少,其信息主要表现在较小特征值对应的特征中,故可定义背景子空间为最大的 k 个特征值对应的特征向量组成,即 $U = [U_1, U_2, \dots, U_k]$ 。

(2) 典型类判别特征子空间法:首先对高光谱图像进行 k -means 聚类^[22],统计聚类后的每一

类像元数的占比,并定义预估异常像元占比 δ ,将像元数量占比大于这个值的类视为正常类或称背景类。接着采用 Fisher 判别分析^[23],最小化类内散度和最大化类间散度,对所有的 k 个背景类样本进行判别分析计算,得到的判别特征向量组成背景子空间 $U = [U_1, U_2, \dots, U_{k-1}]$ 。

1.2 背景正交子空间增强变换的孤立森林异常检测

结合正交子空间分析的特点和经典的 *iForest* 算法提出如下计算方法。首先采用主成分特征子空间法或典型类判别特征子空间法估计得到的背景子空间对输入图像进行正交子空间投影,从而抑制背景,增强目标,使主要的信息与异常相关;为降低因高光谱影像维数过高给算法带来的风险,接着对输入的特征继续采用主成分分析进行降维处理,使主要的异常信息集中在几个主成分中。在此基础上利用 *iForest* 对主成分特征影像进行训练和对待检测样本进行测试。具体的训练和测试方法如下。

(1) 训练阶段是建立孤立森林。假设孤立树 *iTree* 的数目为 t ,由 t 棵 *iTree* 构成孤立森林 *iForest*。*iTree* 的建立是通过递归分割来建立的,递归分割结束的标志是所有的样本被孤立,或者树达到了指定的高度。假设树的高度限制为 l , l 与子样本数量 n 的关系为 $l = \text{ceiling}(\log_2(n))$,近似等于树的平均高度。以下为树的构造过程。

Step1:从被背景子空间抑制后的高光谱影像中随机选择 n 个样本作为子样本集, $X = \{x_1, x_2, \dots, x_n\}$,样本的特征维数 d 是主成分分析降维后的特征维数。

Step2:为了构建一棵孤立树,需要从 d 个特征中随机选择一个特征 q 及其分割值 p , p 值介于该特征的最小值和最大值之间,与经典的

iForest 不同在于 p 对输入特征的随机剖分能更容易区分背景与目标像元。

Step3:假设 T 是孤立树的一个节点,它要么是没有子节点的叶子节点,要么是只有两个子节点(T_l, T_r)的内部节点,每一步分割,都包含特征 q 和分割值 p ,对特征 q 的任一样本 q_i ,若其满足 $q_i < p$,则将其分到 T_l ,若满足 $q_i \geq p$,则分到 T_r 。

Step4:子节点递归的重复 Step2 和 Step3,直到树的高度达到了限制值 l 或节点上的样本都相同。

(2) 测试阶段计算待检测样本的异常值。每一个测试样本 $x (x \in \mathbb{R}^{d \times 1})$ 的异常值由期望路径长度 $E(h(x))$ 表达得到,树的路径长度 $h(x)$ 表示样本 x 从 i Tree 的根节点到叶节点过程中经过的边的数目。为了便于评价异常值,对 $E(h(x))$ 采用归一化处理(4)来定义最终的异常分值

$$S(x) = 2^{-E(h(x))/C(n)} \quad (4)$$

式中, $C(n)$ 是 n 个样本构建二叉树的平均路径长度,定义如式(5)

$$C(n) = 2H(n-1) - (2(n-1)/n) \quad (5)$$

式中, $H(\cdot)$ 为调和函数,用 $\ln(\cdot) + 0.577\ 215\ 664\ 9$ (欧拉常数)估算。对高光谱影像中的每一个像元均进行上述步骤,得到异常检测结果图 $D \in \mathbb{R}^{h \times w}$, h 和 w 分别为影像的行数和列数。

异常值 $0 < S(x) \leq 1$,如果异常值接近 1,则认为它为异常,如果远远小于 0.5,则其可以归到普通样本,当异常值接近 0.5 时,则不能判读是否为异常。

1.3 局部化 i Forest 细化处理

影像中亮度值比较大的像元具有离群的特点,易被误检为异常。这类地物与感兴趣的异常目标不同在于它们往往成面状或线状。为了消除其对异常的影响,采用二次 i Forest 计算,称之为局部 i Forest 细化处理,其实质是在局部范围内再进行一次 i Forest 异常检测,并将 1.2 节的处理结果称为初始异常检测结果。具体步骤如下。

(1) 二值化:将初始的异常检测结果图 D 转换为二值化图像 $B \in \mathbb{R}^{h \times w}$

$$B_i = \begin{cases} 1 & \text{if } D_i > s \\ 0 & \text{otherwise} \end{cases} \quad (6)$$

式中,阈值 s 由 Otsu^[24] 算法确定; B_i 和 D_i 分别为 B 和 D 对应的像元。

(2) 基于分块分析的 i Forest 异常检测:对二值图像进行形状分析,找出二值图像 B 的所有连

通分量,并计算连通分量内的像元数。接着对图像进行分块,相邻块之间设置一定的重叠度。评估每一个块内最大的连通分量的像元数与块内像元总数的比值 θ ,如果该值大于给定的阈值,则在块内构造一个局部 i Forest 来重新定义该窗口中像素的异常分数,并以此值代替全局值。不失一般性,本文设置的图像块的大小为 20×20 ,块间重叠度为 4 个像素,比值 θ 的阈值设置为 0.3。若相邻块均有局部操作,则重叠区域的异常分数取相邻块的异常分数的平均值。

2 试验验证与分析

2.1 试验数据集说明

利用 5 组高光谱数据集来验证本文方法的性能,如图 3(a)、(b)、(c)和(d)为 4 幅分别命名为 airport1、airport2、beach、harbor 的 AVIRIS 高光谱传感器获取的影像^[25],4 幅影像进行目标检测前去掉了水吸收波段和信噪比比低的波段;图 3(e)是用具有 46 个波段的 CRI 高光谱成像仪^[26]获取的真实高光谱数据影像(grassland),图 3 中的二值图像为影像中对应的目标分布的参考图。各数据的场景特点和目标空间分布相关信息描述如表 1,比如图 3(a)为机场环境下有 13 架飞机目标,异常像元个数为 144 个。

2.2 试验的实现与对比

根据采用的背景子空间估计方式的差异,以及是否进行主成分分析降维处理,对异常检测方法有不同形式的实现。主成分背景子空间变换 i Forest 异常检测,记为(PCA subspace i Forest detector, PSF),即背景子空间由主成分特征子空间法构造,影像经正交子空间背景抑制后,各像元的异常值的计算由全局 i Forest 计算得到;局部细化的 PSF,记为(locally refined PSF, LPSF),即利用局部 i Forest 对 PSF 得到的结果检测结果图再进行细化;聚类判别背景子空间变换 i Forest 异常检测,记为(cluster discriminant subspace i Forest detector, CDSF),与 PSF 不同的在于背景子空间由典型类别判别特征子空间法得到;局部细化的 CDSF,记为(locally refined CDSF, LCDSF);主成分降维的局部细化主成分背景子空间变换 i Forest 异常检测,记为(dimension reduced LPSF, DLPSF),即对高光谱影像进行正交子空间背景抑制处理后用 PCA 主成分分析降维,之后各像元的异常值的计算与 LPSF 的计算方式相同。

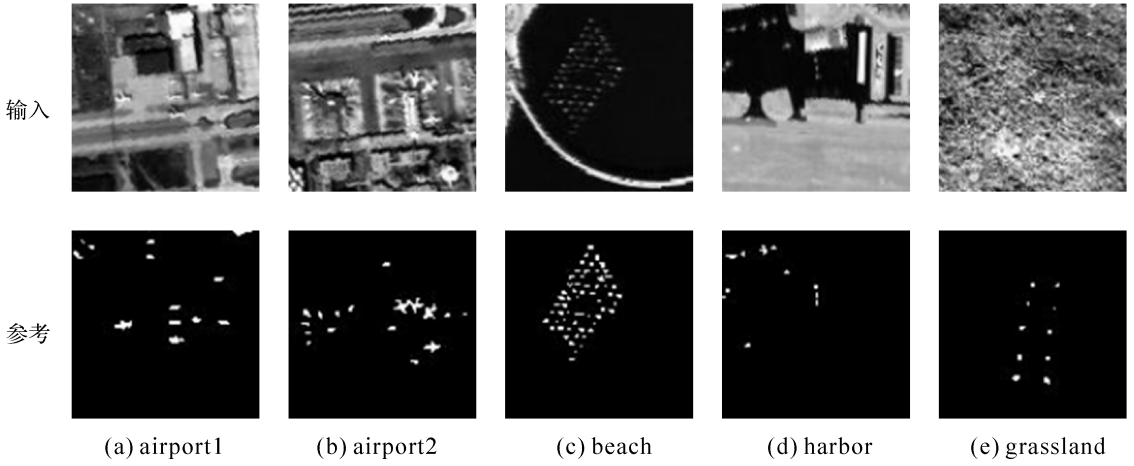


图3 高光谱影像及其对应的异常目标参考

Fig.3 Hyperspectral images and their target reference images

表1 试验数据描述及其试验参数设置

Tab.1 Experimental data description and experimental parameter settings

参数	airport1	airport2	beach	harbor	grassland
场景特点	机场-飞机	机场-飞机	海滩-养殖排	港口-船只	草地-塑料薄片
目标数/像元数	13/144	16/170	58/196	13/144	10/47
PCA子空间数目 k	10	1	6	9	2
影像的聚类数 k	7	6	7	7	6
预估异常像元占比 δ	0.02	0.03	0.03	0.02	0.02


为便于分析,将本文方法处理结果与其他全局化异常检测方法的结果对比。包括不做任何预处理的全局 i Forest,全局 RX(Global RX-GRX),和经正交子空间背景抑制后的 GRX,分别是主成分背景子空间变换 GRX 异常检测(PCA background subspace GRX,Ps-GRX)和聚类判别背景子空间变换 GRX 异常检测(cluster discriminant background subspace GRX,Cs-GRX)。

2.2.1 试验的参数设置

本文所有基于 i Forest 的算法中树的数目 t 统一设置为 100,样本随机采样大小 n 为 256。背景子空间参数设置方面。

主成分特征向量背景子空间参数 k 则通过 AUC(area under the curve)^[27] 评价方法生成每一个试验数据用不同值时 PSF 异常目标检测结果。图 4 结果展示的点线图反映 5 幅影像采用的主成分个数与 AUC 值之间的关系,根据图 4 试验结果设置每一个试验数据的最优参数见表 1 中“PCA 子空间数目 k ”。CDSF 方法中背景子空间的确定涉及两个参数,分别为聚类数目和异常像元占影像面积的比例^[28]。根据本文所用数据的特点,并进行多次试验后选择了效果最好的参数,

各场景的上述两参数设置见表 1 最后两行。

图4 PCA子空间参数 k 的确定Fig.4 Determination of PCA subspace parameter k

2.2.2 试验对比分析

2.2.2.1 背景正交子空间增强结果对比

基于表 1 给定的参数,图 5 展示了 9 种不同异常检测方法在 5 个高光谱数据上进行处理后异常目标响应强度的灰度图。其中基于 i Forest 的方法异常值根据式(4)的定义将小于 0.5 的像元全部设为 0。

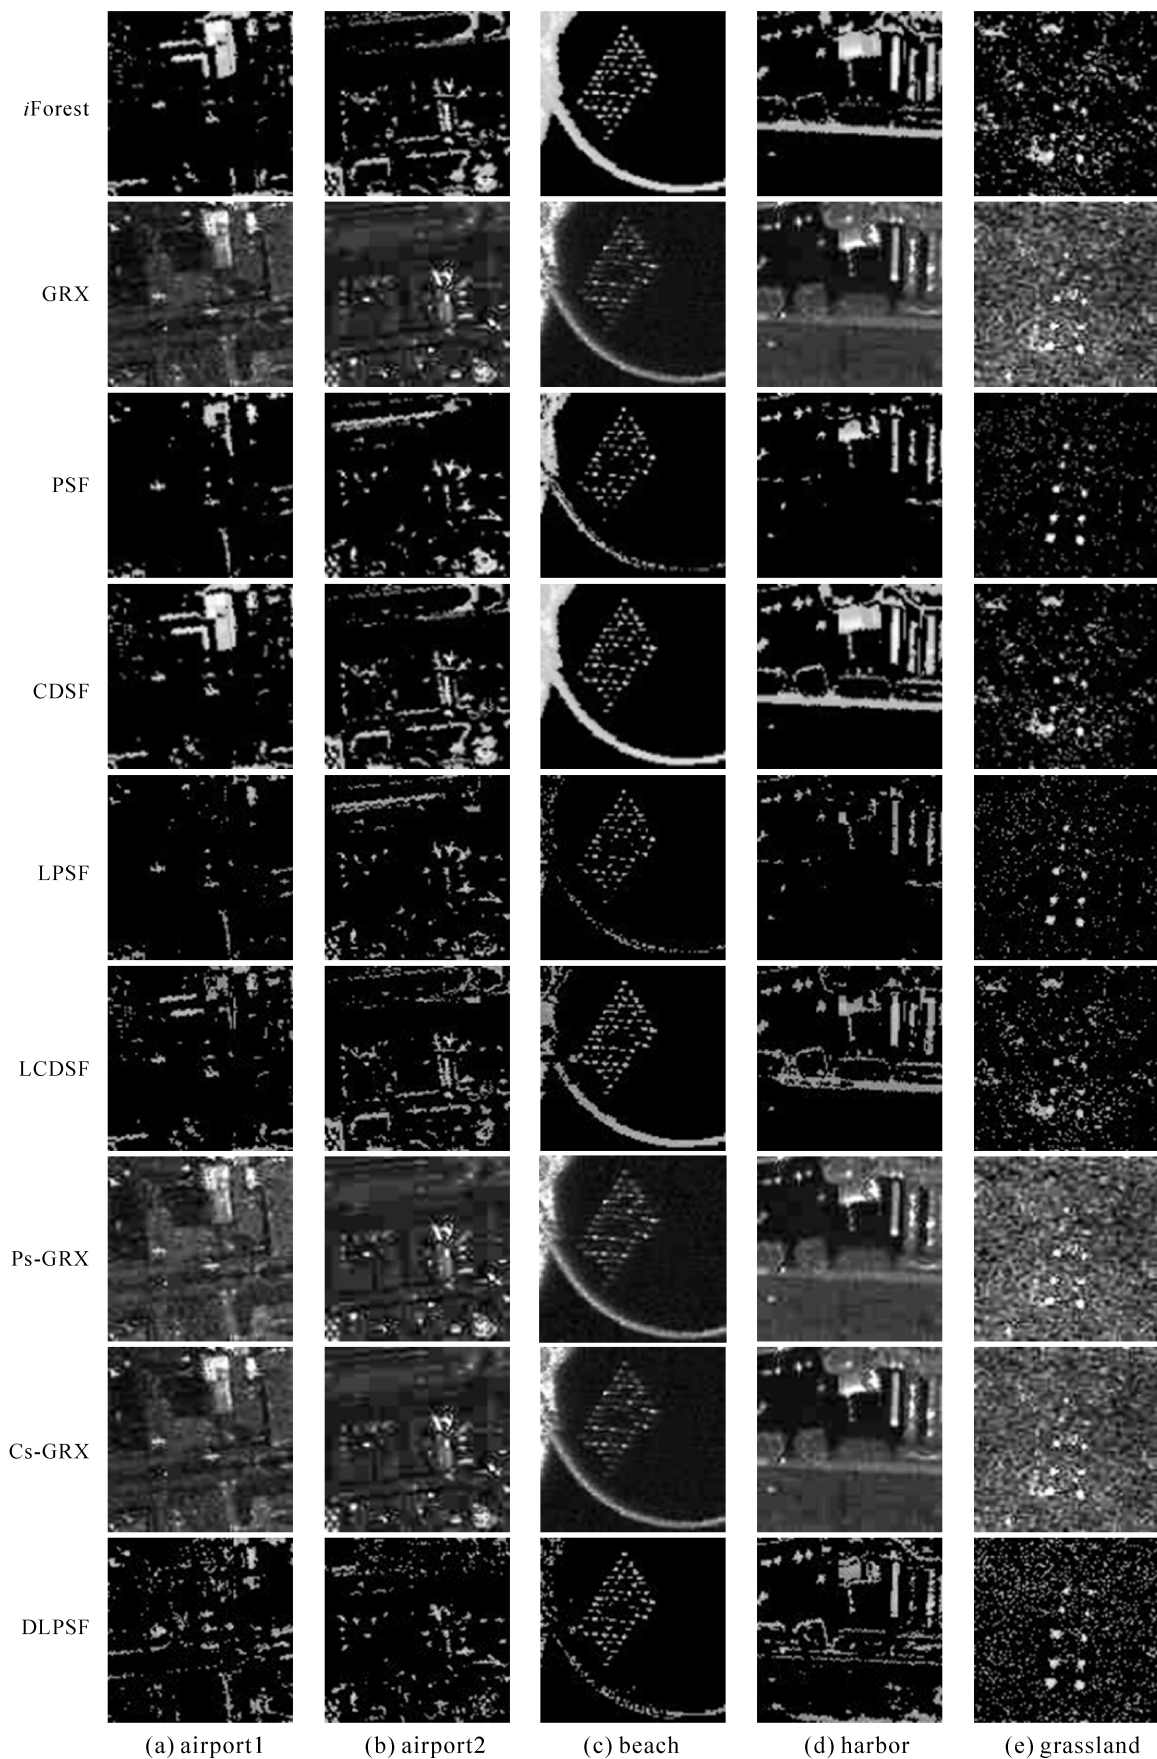


图 5 异常目标检测结果

Fig.5 Detection maps for anomaly targets

对照目标参考图计算目标与背景分离的箱状表达图^[29](图 6),箱状图表现了异常检测特征图像中背景和背景响应值的分散情况,红色和蓝色分别代表异常目标与背景检测值的主体分布,距离越远,则说明算法的性能越好。在计算 GRX 的箱状图之前先将其检测得到的特征图进行归一化。由图 6 中可以看出 *iForest* 相对于 GRX 在 harbor 和 grassland 两幅图像的目标响应值的数

字范围总体上好于 GRX,但与 GRX 相同的是目标的响应最大值比背景的小;在 airport2 中 GRX 结果明显优于 *iForest*;从 Ps-GRX 和 Cs-GRX 的分离图中可以看出正交子空间投影对 GRX 的数值动态变化范围影响甚微,甚至结果不如 GRX;两种类型的子空间增强方法中 PSF 在各试验数据的背景与目标的分离性比 CDSF 好,也比其他方法的分离性好。

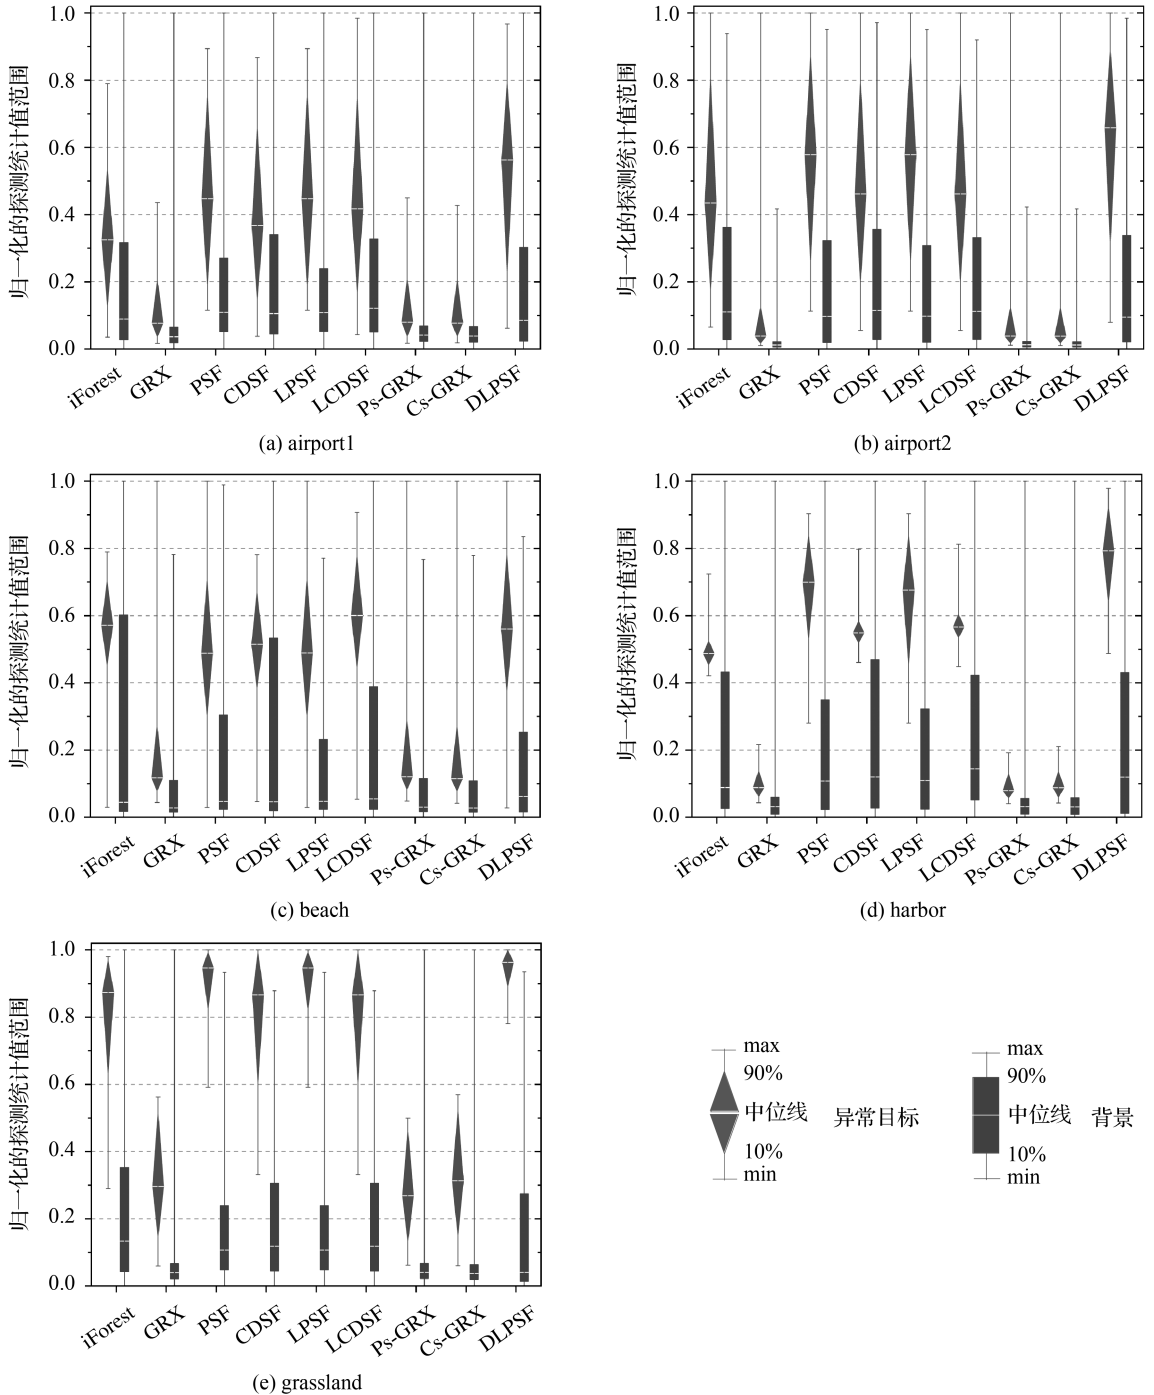


图 6 目标与背景分离

Fig.6 Separability maps of target and background

表 2 计算了图 5 各结果的 AUC(area under curve)值,AUC 越接近 1.0,检测方法可靠性越高。采用子空间分析的 *iForest* 的 AUC 值比 GRX,以及同样采用子空间分析的 Ps-GRX 和 Cs-GRX 的都高,也比经典 *iForest* 高。以 airport1 为例,PSF 的 AUC 值相对于经典

iForest,GRX、Ps-GRX 和 Cs-GRX 分别提高了 9.38%、12.8%、14.52%和 13.22%;而 CDSF 则分别提高了 0.65%、3.8%、5.4%和 4.2%。精度提高非常明显说明经子空间背景抑制处理后异常目标检测变得更容易。同时也注意到子空间分析并没有提高经典 GRX 的结果。

表 2 算法的 AUC 分数
Tab.2 AUC score of the algorithm

方法	airport1	airport2	beach	harbor	grassland
<i>iForest</i>	0.847 8	0.884 6	0.900 6	0.955 4	0.991 9
GRX	0.822 1	0.928 8	0.910 6	0.951 3	0.995 2
PSF	0.927 3	0.947 9	0.946 6	0.980 0	0.999 8
CDSF	0.853 3	0.889 8	0.903 1	0.957 8	0.996 7
LPSF	0.940 6	0.953 3	0.977 8	0.981 5	0.999 8
LCDSF	0.877 4	0.900 4	0.961 5	0.974 4	0.996 2
Ps-GRX	0.809 7	0.928 2	0.910 7	0.950 8	0.995 8
Cs-GRX	0.819 0	0.928 3	0.910 6	0.951 6	0.996 2
DLPSF	0.944 2	0.958 8	0.979 1	0.987 9	0.999 8

2.2.2.2 局部 *iForest* 对异常检测结果的影响

由图 5 检测图可以明显地看到全局与局部相结合的异常检测算法的误检减少更为明显。结合表 2,以 airport1 为例,LPSF 相对于 PSF 的 AUC 值得到了提高 1.43%;LCDSF 相对于 CDSF 的 AUC 值得到了提高 2.82%。这说明局部处理进一步提高了精度。

2.2.2.3 主成分分析特征降维对 *iForest* 异常检测算法的影响

用不同维数的特征对不同数据进行异常检测的 AUC 统计值如图 7 所示,airport1、airport2、beach、harbor 和 grassland 5 个场景分别在保留 2、4、6、2、1 个特征时取得最大值。可以看出背景抑制后的影像在有限个主成分特征上获得了更好的检测结果,目标的形状更为完整。其对应的 AUC 值见表 2,以 airport1 为例,DLPSF 相对于 LPSF 的 AUC 值提高了 0.38%。

2.2.2.4 时间效率对比

在 CPU 为 3.60 GHz、内存为 8 GB 配置的计算机上比较了异常检测算法的运行时间。所有算法都在 Matlab 软件上实现,表 3 给出每种方法在每个数据上的运行时间,可以看出 *iForest* 需要耗费比 GRX 更长的时间,时间消耗的主要原因是孤立树建立和测试过程;正交子空间投影简化了建树过程,因而其消耗时间比经典 *iForest* 少,主成分分析定义的比聚类判别分析的耗费时间更

短。局部细化计算需要额外的时间,降维能使耗费时间进一步减少。




图 7 AUC 分数随保留特征维数的变化

Fig.7 Changes of AUC scores with retained feature dimensions

3 结 论

不同于经典高光谱图像异常目标检测方法偏向于正常背景样本的描述,本文采用 *iForest* 异常检测思想着重于孤立异常点。但并不是直接将 *iForest* 算法应用高光谱图像,而是提出了在基于特征子空间正交分析的背景抑制和主成分降维处理后,将图像全局 *iForest* 异常值计算初步结果

和局部分块计算结果结合。综合试验分析与讨论得出如下结论:①以主成分特征子空间分析为基础的 LPSF 的异常特征值与背景具有更好的可分性,其能够获得更高目标计算精度和计算效率;②全局和局部结合的 *i*Forest 异常目标检测更灵

活地检测出了感兴趣的目标,并获得了良好的检测精度,丰富了算法的内涵;③主成分特征降维使得 *i*Forest 算法较好地适用于高光谱图像分析。但从图 6 中可以看到检测结果图中存在一定的噪声,这是论文未来需要解决的问题。

表 3 试验数据集的算法运行时间

Tab.3 Running time (second) of the algorithms for the experimental data sets

方法	airport1	airport2	beach	harbor	grassland
<i>i</i> Forest	12.071 7	11.965 0	10.027 5	12.073 5	12.207 1
GRX	0.610 4	0.616 4	0.606 2	0.624 6	0.606 4
PSF	10.220 3	10.303 6	9.073 8	9.742 3	10.800 3
CDSF	12.366 8	12.969 8	10.551 4	13.592 5	12.301 9
LPSF	24.551 8	42.266 2	41.495 8	23.742 0	11.172 8
LCDSF	35.542 6	22.115 0	59.124 6	90.014 5	12.546 5
Ps-GRX	0.886 6	0.741 5	0.685 5	0.746 8	0.656 9
Cs-GRX	1.164 0	1.405 8	1.382 6	1.007 6	1.046 0
DLPSF	26.404 8	33.097 4	35.640 3	17.994 5	12.268 9

参考文献:

- [1] MATTEOLI S, DIANI M, CORSINI G. A tutorial overview of anomaly detection in hyperspectral images[J]. IEEE Aerospace and Electronic Systems Magazine, 2010, 25(7): 5-28.
- [2] ZHANG Yun. Smart photogrammetric and remote sensing image processing for very high resolution optical images—examples from the CRC-AGIP lab at UNB[J]. Journal of Geodesy and Geoinformation Science, 2019, 2(2): 17-26. DOI: 10.11947/j.JGGS.2019.0203.
- [3] XIE Weiyang, JIANG Tao, LI Yunsong, 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.
- [4] DAI Yuchao, ZHANG Jing, HE Mingyi, et al. Salient object detection from multi-spectral remote sensing images with deep residual network[J]. Journal of Geodesy and Geoinformation Science, 2019, 2(2): 101-110. DOI: 10.11947/j.JGGS.2019.0211.
- [5] HUYAN Ning, ZHANG Xiangrong, ZHOU Huiyu, et al. Hyperspectral anomaly detection via background and potential anomaly dictionaries construction[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(4): 2263-2276.
- [6] 李敏, 朱国康, 张学武, 等. 基于多孔径映射的高光谱异常检测算法[J]. 测绘学报, 2016, 45(10): 1222-1230. DOI: 10.11947/j.AGCS.2016.20160119.
- LI Min, ZHU Guokang, ZHANG Xuewu, et al. An anomaly detector based on multi-aperture mapping for hyperspectral data[J]. Acta Geodaetica et Cartographica Sinica, 2016, 45(10): 1222-1230. DOI: 10.11947/j.AGCS.2016.20160119.
- [7] LU Xiaoqiang, WANG Yulong, YUAN Yuan. Graph-regularized low-rank representation for destriping of hyperspectral images[J]. IEEE Transactions on Geoscience and Remote Sensing, 2013, 51(7): 4009-4018.
- [8] KRUSE F A, BOARDMAN J W, HUNTINGTON J F. Comparison of airborne hyperspectral data and EO-1 Hyperion for mineral mapping[J]. IEEE Transactions on Geoscience and Remote Sensing, 2003, 41(6): 1388-1400.
- [9] EISMANN M T, STOCKER A D, NASRABADI N M. Automated hyperspectral cueing for civilian search and rescue[J]. Proceedings of the IEEE, 2009, 97(6): 1031-1055.
- [10] IMANI M. RX anomaly detector with rectified background[J]. IEEE Geoscience and Remote Sensing Letters, 2017, 14(8): 1313-1317.
- [11] 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.
- [12] LING Qiang, GUO Yulan, LIN Zaiping, et al. A constrained sparse representation model for hyperspectral anomaly detection[J]. IEEE Transactions on Geoscience and Remote Sensing, 2019, 57(4): 2358-2371.
- [13] SU Hongjun, WU Zhaoyue, DU Qian, et al. Hyperspectral anomaly detection using collaborative representation with outlier removal[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2018, 11(12): 5029-5038.
- [14] YUAN Yuan, MA Dandan, WANG Qi. Hyperspectral anomaly detection via sparse dictionary learning method of capped norm[J]. IEEE Access, 2019, 7: 16132-16144. DOI: 10.1109/ACCESS.2019.2894590.

- [15] LIU F T, TING Kaiming, ZHOU Zhihua. Isolation forest [C]//Proceedings of 2008 IEEE International Conference on Data Mining. Pisa: IEEE, 2009: 413-422.
- [16] LIU F T, TING Kaiming, ZHOU Zhihua. Isolation-based anomaly detection[J]. *Acm Transactions on Knowledge Discovery from Data*, 2012, 6(1): 1-39.
- [17] BANDARAGODA T R, TING Kaiming, ALBRECHT D, et al. Efficient anomaly detection by isolation using nearest neighbour ensemble[C]//2014 IEEE International Conference on Data Mining Workshop (ICDMW). Shenzhen: IEEE, 2014: 698-705.
- [18] ZHAO Rui, DU Bo, ZHANG Liangpei, et al. Beyond background feature extraction: an anomaly detection algorithm inspired by slowly varying signal analysis[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2016, 54(3): 1757-1774.
- [19] 黄鸿, 石光耀, 段宇乐, 等. 加权空-谱联合保持嵌入的高光谱遥感影像降维方法[J]. *测绘学报*, 2019, 48(8): 1014-1024. DOI: 10.11947/j.AGCS.2019.20180229. HUANG Hong, SHI Guangyao, DUAN Yule, et al. Dimensionality reduction method for hyperspectral images based on weighted spatial-spectral combined preserving embedding[J]. *Acta Geodaetica et Cartographica Sinica*, 2019, 48(8): 1014-1024. DOI: 10.11947/j.AGCS.2019.20180229.
- [20] HARSANYI J C, CHANG C I. Hyperspectral image classification and dimensionality reduction: an orthogonal subspace projection approach[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1994, 32(4): 779-785.
- [21] 张兵. 高光谱图像处理与信息提取前沿[J]. *遥感学报*, 2016, 20(5): 1062-1090. ZHANG Bing. Advancement of hyperspectral image processing and information extraction[J]. *Journal of Remote Sensing*, 2016, 20(5): 1062-1090.
- [22] KHOUJ Y, DAWSON J, COAD J, et al. Hyperspectral imaging and k-means classification for histologic evaluation of ductal carcinoma *in situ* [J]. *Frontiers in Oncology*, 2018, 8: 17. DOI: 10.3389/fonc.2018.00017.
- [23] BELHUMEUR P N, HESPANHA J P, KRIEGMAN D J. Eigenfaces vs. fisherfaces: recognition using class specific linear projection [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1997, 19(7): 711-720.
- [24] OTSU N. A threshold selection method from gray-level histograms[J]. *IEEE Transactions on Systems, Man, and Cybernetics*, 1979, 9(1): 62-66.
- [25] KANG Xudong, ZHANG Xiangping, LI Shutao, et al. Hyperspectral anomaly detection with attribute and edge-preserving filters[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2017, 55(10): 5600-5611.
- [26] 黄远程, 钟燕飞, 赵野鹤, 等. 联合盲分解与稀疏表达的高光谱图像异常目标检测[J]. *武汉大学学报(信息科学版)*, 2015, 40(9): 1144-1150. HUANG Yuancheng, ZHONG Yanfei, ZHAO Yehe, et al. Joint blind unmixing and sparse representation for anomaly detection in hyperspectral image[J]. *Geomatics and Information Science of Wuhan University*, 2015, 40(9): 1144-1150.
- [27] WU Yuanfeng, LÓPEZ S, ZHANG Bing, et al. Approximate computing for onboard anomaly detection from hyperspectral images[J]. *Journal of Real-Time Image Processing*, 2019, 16(1): 99-114.
- [28] 马春笑, 黄远程, 胡荣明, 等. 多窗口融合判别子空间的高光谱图像异常检测[J]. *应用科学学报*, 2019, 37(1): 64-72. MA Chunxiao, HUANG Yuancheng, HU Rongming, et al. Discriminant subspace and multi-window fusion RX algorithm for hyperspectral image anomaly detection[J]. *Journal of Applied Sciences*, 2019, 37(1): 64-72.
- [29] ZHANG Yuxiang, KE Wu, DU Bo, et al. Independent encoding joint sparse representation and multitask learning for hyperspectral target detection[J]. *IEEE Geoscience and Remote Sensing Letters*, 2017, 14(11): 1933-1937.

(责任编辑:张艳玲)

收稿日期: 2020-02-03

修回日期: 2021-01-23

第一作者简介: 黄远程(1983—),男,博士,讲师,研究方向为高光谱图像处理与模式识别。

First author: HUANG Yuancheng (1983—), male, PhD, lecturer, majors in hyperspectral image processing and pattern recognition.

E-mail: yuanchenghuang@xust.edu.cn

通信作者: 薛园园

Corresponding author: XUE Yuanyuan

E-mail: xueyuan815@foxmail.com