

文章编号 1004-924X(2009)08-2004-07

采用局部正交子空间投影的高光谱图像异常检测

董 超,赵慧洁,王 维,李 娜

(北京航空航天大学 仪器科学与光电工程学院,北京 100191)

摘要:正交子空间投影是一种需要已知待分类目标特征信息监督分类算法。为了扩展该算法的应用,本文提出了局部正交子空间投影算法,并将其成功应用于高光谱图像异常检测中。异常检测常用于自然背景下的人工目标提取,在小范围邻域内地物类型相对单一。基于此,以被检测点作为感兴趣目标,被检测点邻域内样本的均值作为不感兴趣目标,构造局部投影算子。实验结果显示:本算法能够检测出含量高于 30% 的亚像素目标;通过适当增大滑动窗尺寸,可检测像元面积较大的目标且不受 Hughes 效应影响;当波段数为 80 时,运算时间不足 RX 算法的 1/10。得到的数据表明,局部正交子空间投影算法检测精度高、运算速度快,适用于实时高光谱图像异常检测。

关键词:遥感技术;高光谱图像;异常检测;正交子空间投影

中图分类号:TP751.1 **文献标识码:**A

Hyperspectral image anomaly detection based on local orthogonal subspace projection

DONG Chao,ZHAO Hui-jie,WANG Wei,LI Na

(School of Instrumentation Science & Opto-Electronics Engineering,
Beihang University, Beijing 100191, China)

Abstract: The Orthogonal Subspace Projection (OSP) algorithm is a supervised classifier that needs the information of the classified objects. To expand its application, a local OSP (LOSP) is design to apply to detect the hyperspectral image. The anomaly detection algorithms are usually used to extract the isolated man-made objects in the nature background, where the substances in the small local region are usually uniform. Based on the principle, the LOSP is constructed by choosing the detected pixel as the interested object and the mean of its nearby pixels as the suppressed object. The experiments show that the LOSP can detect the sub-pixel targets with a content greater than 30%, and can also detect the targets occupying more pixels by enlarging the window size. In addition, LOSP is proved not to be affected by the Hughes phenomenon, and the computing time is less than 1/10 that by RX detector when the number of wavelengths is 80. LOSP is effective both in precision and in efficiency, and is applicable to the real-time detection of the hyperspectral image.

Key words: remote sensing technology; hyperspectral image; anomaly detection; orthogonal subspace projection

收稿日期:2008-09-24;修订日期:2008-10-24.

基金项目:中国地质调查局科研基金资助项目(No. 1212010816033)

1 引言

Harsanyi 和 Chang 于 1994 年提出了正交子空间投影(OSP)算法^[1],解决了高光谱混合像元的定量化分析问题,并成功应用于分类、目标探测等场合。OSP 算法以线性混合模型为基础,将混合像元各组分分为感兴趣目标和不感兴趣目标,通过增强图像中感兴趣目标的特征、压制不感兴趣目标的特征信息,解决各种应用问题。

OSP 本质上是一种监督分解算法,需要已知各种目标的光谱信息,否则无法实现特征提取。这个条件较为苛刻,在很多应用场合无法满足,因此衍生出已知不同程度目标信息的 OSP 变形算法。对于仅知道感兴趣目标信息的问题,Harsanyi 提出了受限能量最小化(CEM)算法^[2],通过输出能量最小准则成功地提取目标特征信息。Ren 通过目标自动生成(ATGP)算法^[3],设计了仅已知目标光谱时的期望目标探测、分类算法(DTDCA),以及无任何先验信息下的自动目标检测、分类算法(ATDCA)。Chang 把图像相关系数矩阵的逆矩阵作为先验信息,提出了正交子空间异常检测算子(OSPDA)^[4],并通过实验验证其与 RX 算子的相似性。Ren 提出目标受限、干扰最小化算法(TCIMF)^[5],解决了多个感兴趣目标特征的逐个提取问题。吴波使用 ATGP 技术,实现推扫型成像光谱仪(PHI)高光谱数据的端元提取和丰度估计^[6]。

ATGP 和 OSPDA 在一定程度上解决了无先验信息时 OSP 算法的求解问题,但其应用局限性较大。ATGP 算法生成的目标精度较低^[4],因此 DTDCA 和 ATDCA 算法可能无法在有限步内提取出有用信息。与 RX^[7]类似,OSPDA 算法性能受 Hughes 效应^[8]影响,检测精度随谱段数先增后降。另外,由于要计算大量矩阵逆运算,OSPDA 算法运行效率较低,不适合在实时性较强的场合应用,如军事侦查、灾害救援。本文在上述研究的基础上,对 OSP 算法稍作改动,提出了局部正交子空间高光谱图像异常检测算法,成功地解决了无先验信息时异常目标的快速检测问题。

2 OSP 算子

受传感器空间分辨率和地物复杂性的限制,

高光谱图像在很大程度上符合线性混合模型。任意光谱向量 r 满足

$$r = \alpha M + n, \quad (1)$$

其中 r 为 l 维光谱向量, $M = [m_1, m_2, \dots, m_k]^T$ 为 $k \times l$ 维端元光谱矩阵, $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_k]$ 为 k 维混合系数向量, n 为噪声分量。OSP 模型将端元光谱矩阵进一步分解为感兴趣目标 $d = m_1$ 和不感兴趣目标 $U = [m_2, m_3, \dots, m_k]$, 则公式(1)变为公式(2)。

$$r = \alpha_d d + \alpha_U U + n. \quad (2)$$

OSP 将数据投影到 U 的正交补矩阵空间 $P_U^\perp = I - U(U^T U)^{-1} U^T$, 消除图像中不感兴趣目标的特征分量,如式(3)所示:

$$P_U^\perp r = P_U^\perp \alpha_d d + P_U^\perp n. \quad (3)$$

在此基础上,通过最大化信噪比原则得到正交子空间投影算子

$$P_{\text{OSP}} = \kappa d^T P_U^\perp, \quad (4)$$

其中, κ 为归一化常量。

3 局部 OSP 异常检测算子

3.1 构造方法

OSP 算法需要已知目标信息,否则无法构造式(4)的投影算子,局部异常检测(LAD)为 OSP 算法提供了这一问题的解决思路。LAD 通过对局部数据建模,比较中心点和其邻域内像元光谱的差异性,得到被检测点的异常度。如果将被检测点作为感兴趣目标 d , 邻域内样本点的某种统计量作为不感兴趣目标 U , 则可抑制背景、增强被检测点特征,实现异常检测。若被检测点与背景相似,则在抑制背景时,被检测点特征同样被削弱,输出灰度值较低;否则,经 OSP 算子投影后被检测点与背景输出值差异较大,判定为异常。

按以上分析,将公式(2)化简为

$$r = \alpha d + \beta d_\perp, \quad (5)$$

其中, d 表示被检测点光谱向量, d_\perp 为被检测点邻域内、除被检点以外所有样本点的统计量。 d_\perp 应能够反映样本点的整体特征,其选取是否合适对算法性能影响较大,本文采用样本均值向量。局部 OSP(LOSP)算子为:

$$P_{\text{LOSP}} = \kappa d^T [I - d_\perp (d_\perp^T d_\perp)^{-1} d_\perp^T], \quad (6)$$

其中, $d_\perp^T = \sum_{i=1}^m y_i$, y_i 为 d 邻域内样本点。异常

检测常用于自然背景下的人工目标提取,在小范围邻域内地物类型相对单一,因此使用均值表征样本数据特性比较合理。

3.2 量化分析

将被检测点光谱向量乘以投影算子,其异常度为

$$E = \mathbf{P}_{\text{LOSP}} \times \mathbf{r} = \alpha \kappa \mathbf{d}^T [I - \mathbf{d}_{\perp} (\mathbf{d}_{\perp}^T \mathbf{d}_{\perp})^{-1} \mathbf{d}_{\perp}^T] \mathbf{d} = \alpha \kappa \mathbf{d}^T \mathbf{d} - \alpha \kappa \mathbf{d}^T \mathbf{d}_{\perp} (\mathbf{d}_{\perp}^T \mathbf{d}_{\perp})^{-1} \mathbf{d}_{\perp}^T \mathbf{d}. \quad (7)$$

用内积符号表示向量乘法运算,并令系数 $\alpha \kappa = 1$, 上式化简为公式(8):

$$E = \langle \mathbf{d}, \mathbf{d} \rangle - \frac{\langle \mathbf{d}, \mathbf{d}_{\perp} \rangle^2}{\langle \mathbf{d}_{\perp}, \mathbf{d}_{\perp} \rangle}. \quad (8)$$

将 $\langle \mathbf{d}, \mathbf{d}_{\perp} \rangle = \sqrt{\langle \mathbf{d}, \mathbf{d} \rangle \langle \mathbf{d}_{\perp}, \mathbf{d}_{\perp} \rangle} \cos \theta$ (θ 为两向量间夹角) 带入式(8),化简得

$$E = \langle \mathbf{d}, \mathbf{d} \rangle (1 - \cos^2 \theta). \quad (9)$$

由此可以看出,被检测点异常度正比于被检测点与背景均值向量的相似程度。两者相似程度越高,角 θ 越小,经 LOSP 投影后异常度 E 越小;反之, E 越大。由此从原理上证明了 LOSP 异常检测算子的有效性。

被检测点光谱向量 \mathbf{d} 和背景均值向量 \mathbf{d}_{\perp} 间的相似程度主要取决于两方面因素。第一,被检测点为亚像素目标,既包含目标信息,又包含背景信息。在这种情况下,若目标所占比重小于某一数值时将无法被检出。第二,目标在图像中占据多个像素,部分目标信息掺杂在背景之中。当目标面积较大时,背景中包含的目标信息较多,降低异常点与背景的可分性。此时可通过增大邻域面积提高检测精度,但邻域不可过大,否则会因地物种类过多而进一步降低检测精度。

3.3 算法流程


LOSP 是滑动滤波型局部区域异常检测算法。对图像中任意像素,均以其为中心,建立滤波窗进行分析,算法执行流程分为以下 4 步。

- (1) 以被检测点为中心,建立 $n \times n$ 大小的滤波窗,计算窗内背景样本点均值向量 \mathbf{d}_{\perp} ;
- (2) 以被检测点光谱 \mathbf{d} 为感兴趣目标,均值向量 \mathbf{d}_{\perp} 为不感兴趣目标,构造 \mathbf{P}_{LOSP} ;
- (3) 计算被检测点投影到 \mathbf{P}_{LOSP} 上的异常度;
- (4) 将滤波窗口沿图像空间维滑动,计算各像素点的异常度,经直方图分割得到异常点。

4 实验分析

4.1 不同含量下算法的检测精度

本实验定性地验证像元目标含量与检测精度之间的关系。实验采用基于 OMIS 传感器的模拟数据,共 150 行,100 列,90 个波段,图像中共有 49 个异常点,按 7 行 7 列分布,每个异常点占 2 个像元呈上下分布,如图 1(a)所示。图中 49 个异常点均为人工合成目标,背景较为单一,为大面积农田、田间的道路和水渠;感兴趣目标取自同一航带光谱差异性较大的地物。图中前 6 行是混合像元,最后一行为纯像元。其中,头两行目标含量低于 30%,3、4 行目标含量在 35%~65%之间,5、6 行目标含量在 70%~95%之间。图 1(b)为 LOSP 算子的检测结果。可以看出,目标地物含量越低,其奇异性越小;当目标在被检测点含量低于 30% 时,其异常度与背景近似,无法被检出。除 49 个人工目标外,相对于大面积农作物,图像中的道路、水渠也呈现不同的异常性。



(a) 原始数据 (b) 检测结果
(a) Original image (b) Detection result


图 1 不同含量下算法精度测试实验

Fig. 1 Precision test experiment with different contents


4.2 不同大小目标下算法的检测精度

本实验定性地分析目标和滑动滤波窗尺寸与检测精度之间的关系。实验数据基于 OMIS 传感器采集的高光谱图像,共 150 行,100 列,90 个波段。图像中共有 13 个目标,分别占 1×1 、 1×2 、 2×1 、 2×2 、 3×3 、 5×5 、 7×7 个像元,人工目标光谱取自同航带光谱差异较大的地物,如图 2(a)所示。图 2(b)~(d)为分别使用 3×3 、 9×9 和 15×15 滑动滤波窗时,LOSP 算子的检测结果。可

以看出,当滑动滤波窗较小时,小目标被检测出来,同时提取出 5×5 、 7×7 大目标的边界信息;增大窗口大小,大目标特征得到增强;当窗口大小增大到 15×15 时,所有目标都能被检出;此时由于窗口尺寸较大,道路也被作为异常信息凸现出来。应用过程中,根据传感器空间分辨率和感兴趣目标实际尺寸,选择不同大小的滑动窗口,可实现特定大小目标的异常检测。上述两个实验定性验证了目标含量、大小与检测精度之间的关系,与 3.2 分析的结果完全吻合。



(a) 原始数据 (a) Original image (b) 3×3 滤波窗检测结果 (b) Detection result with 3×3 filter window



(c) 9×9 滤波窗检测结果 (c) Detection result with 9×9 filter window (d) 15×15 滤波窗检测结果 (d) Detection result with 15×15 filter window

图 2 不同邻域大小时算子检测结果

Fig. 2 Results under different sizes of the filter window

4.3 与 RX 比较

本实验比较了 RX、LOSP 算法的检测性能和计算效率。该模拟数据包含 20 个纯像元人工目标,每个目标占 4 pixel,模拟采用的基准数据与前 2 个实验相同。RX 算法检测精度受 Hughes 效应的影响,随波段数增加而下降,在检测前需对

数据降维。为保证降维后的图像包含尽量多的异常信息,使用谷延锋提出的基于波段局部异常度的数据降维算法^[9],该方法性能好于基于特征根排序的主成分分析方法。本文对谷的方法稍加修改,直接计算原始图像各波段平均局部峰度值,并将峰度最大的前 N 个波段作为异常性最强的波段,带入 RX 和 LOSP 算子进行检测。

图 3 为 $N=10$ 时,RX 和 LOSP 算法检测结

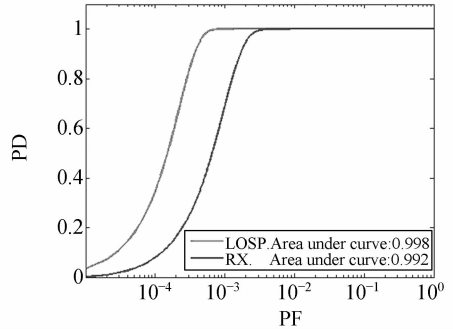




图 3 前 10 个异常成分下 RX、LOSP 的 ROC 曲线
Fig. 3 ROC curves of RX and LOSP with the first ten anomaly bands



(a) $N=10$ (b) $N=20$



(c) $N=40$ (d) $N=80$

图 4 不同数目异常波段 RX 算法检测结果
Fig. 4 Results of RX with different numbers of anomaly bands

果的 ROC 曲线。由于波段数较少,两算法均能在较低虚警率下提取出图像中所有目标,且 LOSP 算法检出所有目标时的虚警率远低于 RX 算法。图 4~5 为两算法使用前 10、20、40 和 80 个异常性最强波段的检测结果,可以看出 RX 算法受 Hughes 效应影响较大,当 N 增加到 20 时,检测精度明显下降,而在后两种情况下无法提取目标信息。而 LOSP 算法不受 Hughes 效应限制,随 N 增加,检测结果中噪声分量略有增加,但仍能提取出所有目标点。

表 1 RX、LOSP 算法计算时间(单位:秒)


Tab. 1 Computing time of the RX and LOSP (Unit: s)

	10	20	40	80
RX	15.235	30.765	91.188	328.547
LOSP	7.062	8.641	13.547	27.361

以上实验结果表明,LOSP 算法不受 Hughes 效应影响,能够充分利用高光谱数据的全波段信息,在精度和计算效率上均优于 RX 异常检测算法,适合实时、高精度异常检测应用。


4.4 真实数据性能测试

本实验使用 PHI 传感器拍摄的方麓茶场地区高光谱图像,验证真实数据下 LOSP 算法的检测性能。去除水汽吸收和低信噪比波段,实验数据有 80 个波段,空间维为 150 行、100 列,图 6(a)



(a) $N=10$

(b) $N=20$



(c) $N=40$

(d) $N=80$

图 5 不同数目异常波段 LOSP 算法检测结果

Fig. 5 Results of LOSP with different numbers of anomaly bands

表 1 为不同 N 值下 RX、LOSP 算法的计算时间。RX 算法计算时间与波段数呈现幂函数关系,当波段数为 80 时,执行时间较长,不适合实时性较强的应用场合。LOSP 算法使用样本均值作为不感兴趣目标,不用计算样本的协方差矩阵,大大缩短了计算时间。当使用 80 个分量时,其计算时间不足 RX 算法的 1/10。



(a) 原始数据

(a) Original image



(b) LOSP 检测结果

(b) Result of LOSP



(c) RX 检测结果

(c) Result of RX

图 6 PHI 方麓茶场地区高光谱数据及检测结果

Fig. 6 Detection results of hyperspectral images of Fang Lu tea plantation collected by PHI

为该区域第 30 波段的图像。图中大部分地物为均一农田,从右上至左下的白色公路是该场景内

的主要异常物质,另外还有少量的田埂、水渠等人工目标。图6(b)、6(c)分别为图像前20个异常性最强波段的LOSP和RX检测结果二值图,两算法采用相同的阈值进行分割。可以看出,LOSP算法能够提取出公路的完整形貌,公路旁的小片白色地物也被检测出来,检测结果虚警率较低。RX算法无法提取公路的完整形貌,且虚警率较高。

5 结 论

本文以待检点为感兴趣目标、待检点邻域内

样本均值作为不感兴趣目标,设计局部正交子空间投影算法,成功地解决了OSP算法在异常检测应用中无先验信息的问题。异常检测应用中,图像在小范围邻域内地物类型单一,因此以待检点样本均值表征数据特性较为合理。实验结果表明:LOSP算子能够检测出含量高于30%的亚像元目标;可通过适当增大滑动窗尺寸,提取大像元尺寸目标;当波段数为80时,运算时间不足RX的1/10。LOSP算法具有检测精度高、计算效率高、不受光谱维数影响等特点,适用于实时高光谱图像异常检测。

参考文献:


- [1] HARSANYI J C, CHANG C I. Hyperspectral image classification and dimensionality reduction: an orthogonal subspace projection approach [J]. *IEEE Trans. Geosci. Remote Sens.*, 1994, 32(4): 779-785.
- [2] HARSANYI J C. *Detection and classification of subpixel spectral signatures in hyperspectral image sequences* [D]. Baltimore: University of Maryland, Baltimore County, 1993.
- [3] REN H, CHANG C I. Automatic spectral target recognition in hyperspectral imagery [J]. *IEEE Trans. Aerospace and Electronic Systems*, 2003, 39(4): 1232-1249.
- [4] CHANG C I. Orthogonal subspace projection (OSP) revisited: a comprehensive study and analysis [J]. *IEEE Trans. Geosci. Remote Sens.*, 2005, 43(3): 502-518.
- [5] REN H, CHANG C I. Target-constrained interference-minimized approach to subpixel target detection for hyperspectral imagery [J]. *Opt. Eng.*, 2000, 39(12): 3138-3145.

- [6] 吴波,张良培,李平湘. 非监督正交子空间投影高光谱混合像元自动分解[J]. *中国图象图形学报*, 2004, 9(11): 1392-1396.
WU B, ZHANG L P, LI P X. Unsupervised orthogonal subspace projection approach to unmix hyperspectral imagery automatically [J]. *Journal of Image and Graphics*, 2004, 9(11): 1392-1396. (in Chinese)
- [7] REED S, YU X. Adaptive multiple-band CFAR detection of an optical pattern with unknown spectral distribution [J]. *IEEE Acoust., Speech, Signal Process*, 1990, 38(10): 1760-1770.
- [8] 杨哲海,冯猛,张燕燕. 高光谱影响处理方法的改进[J]. *海洋测绘*, 2004, 24(4): 13-16.
YANG ZH H, FENG M, ZHANG Y Y. Improvement of technique for hyper-spectral images classification [J]. *Hydrographic Surveying and Charting*, 2004, 24(4): 13-16. (in Chinese)
- [9] GU Y F, LIU Y, ZHANG Y. A selective KPCA algorithm based on high-order statistics for anomaly detection in hyperspectral imagery [J]. *IEEE Geosci. Remote Sens. Lett.*, 2008, 5(1): 43-47.

作者简介:



董超(1982—),男,博士研究生,主要从事图象处理、模式识别、并行计算、高光谱数据快速处理等方面的研究。E-mail: dongchaoxj888@126.com



赵慧洁(1966—),女,教授,博士生导师,主要从事数字图像处理、机器视觉、高光谱应用潜力分析、高光谱成像系统设计等方面的研究。E-mail: hjzhao@buaa.edu.cn



王 维(1984—),男,硕士,主要从事高光谱图像处理、并行计算等方面的研究。E-mail: wangweibh@126.com



李 娜(1978—),女,讲师,主要从事高光谱遥感信息应用处理技术、高光谱应用潜力分析等方面的研究。E-mail: whereln@163.com

● 下期预告

月球探测器软着陆最优控制问题

单永正¹, 段广仁¹, 吕世良²

(1. 哈尔滨工业大学 控制理论与制导技术研究中心, 黑龙江 哈尔滨 150001;

2. 中国科学院 长春光学精密机械与物理研究所, 吉林 长春 130033)

为了减少有限推力作用下月球探测器软着陆所需的燃料消耗, 本文应用一种非线性规划方法来求解该最优控制问题。首先从庞德里亚金极大值原理出发, 将有限推力作用下月球软着陆问题转化为数学上的两点边值问题; 在考虑边界条件及横截条件的前提下, 将该两点边值问题转化为针对共轭变量初值和末时刻的优化问题; 而后应用非线性规划方法求解所形成的参数优化问题, 为了降低共轭变量初值选取的敏感性, 引入共轭变量与控制变量之间的变换, 用控制变量初值代替了共轭变量初值。实验仿真结果表明本文方法能够成功实现月面软着陆, 并且比传统的打靶法减少了 2.1% 的燃料消耗。本文所提设计方法是简单、有效的。