

基于凸锥分析的低概率检测方法研究

李智勇, 匡纲要, 郁文贤

(国防科技大学电子科学与工程学院, 湖南长沙 410073)

摘要: 低概率检测(LPD)方法利用图像互相关矩阵的特征向量,在已知目标先验信息的情况下检测图像中小概率目标.但是,由于噪声的影响以及特征向量之间正交约束性,使其检测效果不理想.本文提出了利用凸锥分析(CCA)来改善LPD的方法;它避免由特征向量的正交性约束导致的虚警率较高的不良结果,同时消除图像中的条带噪声的影响.最后,结合OMIS数据分析了这种方法检测小目标的效果.

关键词: 超光谱; 低概率检测; 凸锥分析

中图分类号: TN958 **文献标识码:** A **文章编号:** 0372-2112(2001)12A-1856-04

Research of Low Probability Detection Based on Convex Cone Analysis

LI Zhi yong, KUANG Gang-yao, YU Wen xian

(Department of Electronic Engineering, National University of Defence Technology, Changsha, Hunan 410073, China)

Abstract: Low probability detection (LPD) is an approach for hyperspectral imagery analysis; it use the eigenvectors of the imagery's correlation matrix in detecting small targets. Unfortunately, because of noise and the orthogonality constraints among the eigenvectors, the results of detection are non ideal. In this paper, we use the method of Convex Cone Analysis (CCA) to improve the detectability of LPD and to eliminate the stripe noise. The experimental results are given by applying the method to the data from Operative Modular Imaging Spectrometer (OMIS) system.

Key words: hyperspectral; low probability detection; convex cone analysis

1 引言

随着传感器技术的发展,遥感技术也出现了飞跃;表现在由成像光谱仪产生的超光谱(Hyperspectral)图像的出现.超光谱数据是一种高维数据,通常对超光谱图像的处理是建立在线性空间变换理论上.主成份分析(PCA)就是一种在高维数据空间中找到一个较低维的子空间,使得每个数据在这个子空间的投影与其本身的差距最小^[2]的方法;另一类方法是子空间投影技术,其中有代表性的是由马里兰大学的 Cheir I Chang 提出的正交子空间投影(OSP方法),它是一种利用先验信息,通过把光谱向量投影到背景向量所形成空间的正交子空间中,从而抑制背景^[3-5].基于正交子空间投影的思想,出现了一种低概率检测(LPD)的方法,它使用图像特性向量来代替背景的光谱曲线进行正交子空间投影.其主要优点就是不需要背景的先验知识,非常具有实用性^[6].但是由于特征向量之间的正交约束性,使得它的效果不理想. Agustin 在文献[6]中引入凸锥分析(CCA)对图像的特征向量进行线组合,组合结果包含在一个凸锥中,计算它的边界点,并以边界点作为目标向量来对图像较大面积地物进行光谱匹配处理,取得了较好的结果;但是由于特征向量不能反映小目标的光谱特性,致使这种方法对检测小目标不太理想.

本文将给出一种基于凸锥分析的LPD算法.由于LPD算法受到特征向量的正交约束,自然想到组合特征向量来替代背景向量.由于利用CCA的方法可以得到与背景相量较低的组合向量,所以,考虑结合这两种方法对小目标进行检测.文中首先介绍LPD算法和凸锥分析的原理,然后阐述算法的实现与实际中产生的问题;在第4节将利用OMIS系统生成的可见光\近红外64波段图像来检验算法的效果.

2 LPD方法和CCA原理

LPD方法来源于OSP(正交子空间投影)方法,类似OSP方法LPD也使用线性混合点信号模型:

$$r = d \cdot a_p + U \cdot \gamma + n \quad (1)$$

其中: r 代表 $b \times 1$ 维像素向量, b 为波段数, U 是由图像中 p 个不相关的背景地物的光谱以列向量形式排列起来构成的 $b \times p$ 维矩阵,可表示为 $U = [u_1, \dots, u_i, \dots, u_{p-1}]$,其中 u_i 是背景地物的光谱; d 为目标光谱; u_i, d 都是 $b \times 1$ 维; n 代表 $b \times 1$ 维噪声向量, a_p, γ 均为权向量.

OSP方法就是构造一个算子来消除 U 矩阵代表的干扰对 d 的影响;方法就是将 r 投影到由 U 的列向量构成的空间的正交子空间中.利用最小均方准则,这个算子可表示为一个 $b \times b$ 的矩阵 P :

$$P = (I - UU^\#) \quad (2)$$

其中: $U^\# = (U^T U)^{-1} U^T$ 为 U 的伪逆. 这个算子作用于式(2), 得到:

$$P \cdot r = P \cdot d \cdot a_p + P \cdot n \quad (3)$$

可见, 算子 P 在将背景光谱的影响降到了零, 从而起到了消除背景、突出目标的作用.

在 OSP 方法中要构造投影算子需要知道感兴趣目标的光谱和背景的光谱, 这在实际应用中不方便. 在没有很多先验知识的情况下, 如何构造投影算子正是 LPD 所解决的内容. LPD 算法是基于这样的假设: 目标在图像中所占的区域非常小. 从整个图像看来, 目标出现的概率非常小, 可视为不存在. 在这种情况下, 图像中的观测值是由 p 个背景光谱的线性组合构成的. 我们知道, 图像互相关矩阵的前 p 个特征向量可以代表大部分图像信息, 所以, LPD 方法就是利用这 p 个特征向量构成矩阵来代替式(2)中的 U 矩阵, 构造投影算子, 如式(4)所示:

$$\tilde{E} = \begin{bmatrix} \uparrow & & \uparrow \\ e_1 & \dots & e_p \\ \downarrow & & \downarrow \end{bmatrix} = U \quad (4)$$

利用特征向量来代替背景光谱构造投影算子是 LPD 算法的关键, 这样就不需要知道背景光谱的先验信息; 实用性较好. 但是, 它还存在问题: 众所周知, 由于光辐射强度的非负性, 地物光谱向量也是非负的. 所以由其构成的互相关矩阵就是非负的, 则它的第一特征向量一定是非负的. 同时由于特征向量之间的正交约束, 其他特征向量都要与第一特征向量正交, 则这些特征向量一定包含负值, 这样, 他们将不能有效代表地物光谱, 用他们构造的投影算子将不能有效地抑制背景的干扰. 由此, 我们考虑到使用特征向量的线性组合来代替特征向量本身构造投影算子.

把图像的互相关矩阵的前几个特征向量进行线性组合, 由其中的非负向量组成的集合将构成一个凸锥; 即集合中任意向量的正值加权的线性组合都属于这个集合, 且原点是其顶点^[7]. 根据主成分分析的定义, 一般的




图 1 三维空间中的凸锥

图像互相关矩阵的第一特征向量波形可以代表图像中大面积地物的光谱向量波形^[2]. 用前几个特征向量组合而成的凸锥集合是以第一特征向量为中心的. 图 1 显示了在三维空间中的凸锥形状.

超光谱图像的光谱都是非负向量, 理论上说, 由前几个特征向量组合而成的集合只能包含大部分的背景地物光谱. 所以, 怎样组合前几个特征向量, 使其能有效代表图像中的背景光谱正是凸锥分析所解决的内容. 一般情况下凸锥的边界与凸锥的中心角度较大, 在实际中, 代表不同地物的光谱, 凸锥的内点是这些边界向量与中心向量的组合. 因此, 我们将计算凸锥边界点, 并以边界点的光谱代表背景光谱. 值得一提的是, 前几个特征向量可以代表数据大部分信息, 所以用于组合

的特征向量的数目越大, 其组合形成的集合就能越完善地代表图像的光谱向量. 但是, 特征向量的数目不能太大, 因为这样会给边界点的计算带来麻烦.

下面介绍计算凸锥边界的方法: 设图像数据为 b 维, 所以它有 b 个 b 维特征向量, 我们选择其中的前 c ($c < b$) 个来组合. 组合的条件就是, 对任意的权值向量 $\{a_i\}$, $i = 1, \dots, c-1$ 满足:

$$X = [e_1 \quad \dots \quad e_c] \begin{bmatrix} 1 \\ a_1 \\ \vdots \\ a_{c-1} \end{bmatrix} \geq 0 \quad (5)$$

其中 e_i 是特征向量, a_i 为权值, 则边界点的条件满足下式:

$$e_{j1} + a_1 e_{j2} + \dots + a_{c-1} e_{jc} = 0, \quad j \in 1 \dots b \quad (6)$$

式(6)是求解 $c-1$ 个变量 $(a_1 \dots a_{c-1})$ 的线性方程组, 但总共的方程数目为 b , 且 $b > c$; 即要从 b 个方程中选出 c 个来求解. 所以要计算凸锥的所有边界点就必须要求解 $\binom{b}{c-1}$ 个线性方程组. 因此, 如果参与组合的特征向量选择太多; 即 c 的数目较大, 将带来求解方程组的数量的迅速增加. 例如, 假设 $b = 64$, $c = 3$, 则要求解 $64 \times 63 = 4032$ 个方程组, 如果 $c = 4$, 则要求解 $64 \times 63 \times 62 = 249984$ 个方程组. 图 2 是计算凸锥边界点的算法流程图, 其中最主要的步骤是解方程组.

3 算法的实现

在计算出组合向量后, 就可以用它们构成 LPD 算法的投影算子 P 中的 U 矩阵, 如式(7):

$$U = [x_1, \dots, x_p] = [e_1, \dots, e_c] \begin{bmatrix} 1 & 1 & \dots & 1 \\ a_{11} & a_{21} & \dots & a_{p1} \\ \vdots & \vdots & \dots & \vdots \\ a_{1c-1} & a_{2c-1} & \dots & a_{pc-1} \end{bmatrix} = \tilde{E}A \quad (7)$$

其中 $[x_1 \quad \dots \quad x_p]$ 为 p 个组合向量 x 以列向量排列在一起构成的 $b \times p$ 维的矩阵, A 为一个 $c \times p$ 维的权值矩阵, c 是参与凸锥分析的特征向量个数, p 为参与构造 LPD 算法中投影算子的背景光谱向量的个数. 得到 U 矩阵后, 求其伪逆来构造算子 P , 如上一节的式(3), 就可以利用 LPD 算法对图像进行处理.

在实际中, 运用组合向量作为背景光谱进行 LPD 运算中, 需要注意一个问题: 进行线性组合的特征向量个数 c 与 LPD 算法中背景向量的个数 p 不能相等. 我们首先来看 LPD 算法的投影算子 P 的建立方法; 如式(3)所示; 其中 $U^\#$ 是 U 矩阵的伪逆,

$$U^\# = (U^T U)^{-1} U^T \quad (8)$$

将式(8)代入式(3)得:

$$P = (I - U(U^T U)^{-1} U^T) \quad (9)$$

如果进行线性组合的特征向量个数 c 与 LPD 算法中背景向量的个数 p 相等, 假设都为 c , 则进行 LPD 变换的矩阵 U 可写为:

$$U = [e_1 \ \dots \ e_c] \begin{bmatrix} 1 & 1 & \dots & 1 \\ a_{11} & a_{21} & \dots & a_{c1} \\ \vdots & \vdots & \dots & \vdots \\ a_{1c-1} & a_{2c-1} & \dots & a_{cc-1} \end{bmatrix} = \tilde{E}A \quad (10)$$

其中, A 是 $c \times c$ 维的方阵, 这样:

$$\begin{aligned} P &= (I - U(U^T U)^{-1} U^T) = (I - \tilde{E}A(A^T \tilde{E}^T \tilde{E}A)^{-1} A^T \tilde{E}^T) \\ &= (I - \tilde{E}A A^{-1} (\tilde{E}^T \tilde{E})^{-1} A^T (A^T)^{-1} \tilde{E}^T) \\ &= (I - \tilde{E} (\tilde{E}^T \tilde{E})^{-1} \tilde{E}^T) \end{aligned} \quad (11)$$

可见, 其结果与直接用特征向量构造的算子相同, 失去的凸锥分析的意义. 所以, 一般选择进行线性组合的特征向量数目 c 大于参与 LPD 计算的背景向量数目 p .

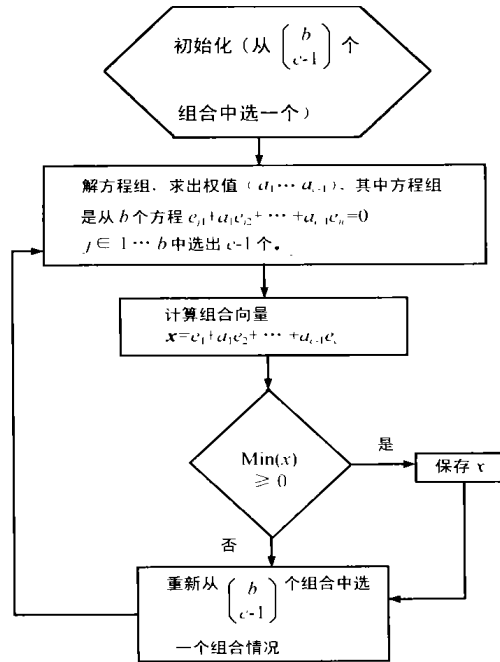


图 2 凸锥边界点的算法流程图

4 实验分析

我们将分析的结果对 OMIS 系统生成的可见光超光图像进行了处理. OMIS 系统由上海技术物理研究所开发研制的新一代成像光谱仪 OMIS 系统(实用性模块化成像光谱仪); 它是一套高性能机载可见光、近红外、短波红外、热红外成像光谱仪, 能在可见光和红外 (0.4~12.5μm) 的光谱段内划分成 128 个波段成像; 具有国际先进水平^[1]. 它所生成的图像在可见光\近红外波段(0.4~1.1μm)分成 64 波段, 光谱分辨率为 10nm, 式数据处理的主要波段. 由于探测器响应的变化, 在图像中出现了某些像素特别亮或综合特别暗. 其整体表现是图像中有一些亮纹和暗纹, 形成条带噪声. 图 3 是原始的第 13 波段、第 19 波段和第 33 波段的图像, 图像大小为 170×170.

原始图像中主要的背景地物有三种: 泥土地面、水泥地面、绿色植被. 要检测的目标在图像中央: 如图 3 中的 33 波段图像, 方框中黑点为感兴趣的目标(车辆). 另外, 图 3 的 11 波段的图像有条带噪声. 实际上, 图像数据中出现噪声的波段是比较多的, 所以在 LPD 处理的结果中也有明显的条带噪声.

但是如果利用凸锥分析对特征向量进行组合后, 将消除条带噪声的影响, 并提高检测效果. 图 4 是前三个特征向量和三个组合向量以及三种背景地物的光谱向量曲线.



图 3 原始的图像

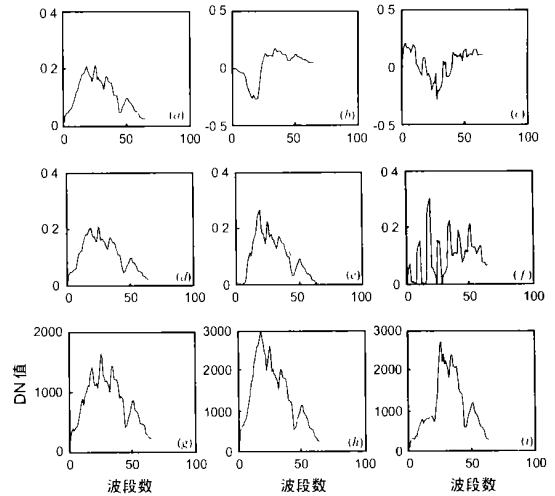


图 4 特征向量、组合后向量、地物光谱曲线图((a)、(b)、(c) 第 1、2、3 特征向量; (d)、(e)、(f) 为组合后所选择的 3 个向量, 其中(d)就是第一特征向量; (g)、(h)、(i) 为从图像上直接提取的三种主要地物波谱)

由图 4 的结果可以看出: 经过组合后向量的波形(图 4 中的(d)、(e)、(f))比特征向量的波形(图 4 中的(a)、(b)、(c))更接近背景地物光谱的波形(图 4 中的(g)、(h)、(i)); 这样, 在构造投影算子后进行 LPD 处理, 就更能消除这些背景地物影响. 特别的, (f) 的锯齿状波形, 正是条带噪声的特点, 正是它的作用消除了条带噪声的影响.

图 5 是用前 3 个特向向量作 LPD 运算和选择组合的向量作 LPD 运算的结果图; 由前所述, LPD 算法需已知目标光谱向量; 图 5(a) 中方框套住的白点的光谱就是已知的目标向量, 是一辆裸露车辆. 从图像上看, (b) 图的结果要明显好于 (a)




图 5 (a)原始 LPD 算法; (b)改进 LPD 算法 ((b) 图中亮框中是要检测的小目标——裸露车辆)

的结果, 图 5(b) 不仅消除了图 5(a) 的大量噪声, 还增强了目标与背景的可区分度; 实际上是消除了大量的虚警. 而在图 5(a) 中, 除了已知目标外可区分度较高外, 其它小目标基本湮没在条带噪声中. 可见, 利用凸锥分析改进的 LPD 算法大大提高了检测小目标的能力.

5 结论与问题

从对 OMIS 系统数据处理结果看, 这种基于凸锥分析的 LPD 算法, 对图像处理的效果是比较好的, 不仅消除了条带噪声的影响, 还突出了感兴趣的小目标, 大大改善了 LPD 方法检测结果, 不失为一种较好的检测小目标的处理方法. 但是, 此方法还存在两个不足之处: (1) 以凸锥的边界点作为背景向量, 但实际中, 背景的光谱向量不一定都在凸锥边界上, 也就是说, 计算的边界点可能不能代表某种背景地物的光谱. (2) 如前所述, 如果参与组合的特征向量数目 c 值较大, 计算将比较麻烦, 需要找到简化的算法.

参考文献:

- [1] 薛永祺, 王建宇. 实用型模块化机载成像光谱仪 [M]. 信息获取与处理技术, 1999: 43- 46.
- [2] 胡国定, 张润楚. 多元数据分析 [M]. 南开大学出版社, 1990.
- [3] Marcus Stavros Stefanou, Richard C Olsen, Herschel H Loomis. Signal perspectives of hyperspectral imagery analysis techniques [R]. 1998,

AD A333: 254.

- [4] Joseph C Harsanyi, Cheir I Chang. Hyperspectral image classification and dimensionality reduction: an orthogonal subspace projection approach [J]. IEEE Trans. on Geoscience and Remote Sensing, 1994: 779 - 785.
- [5] Agustin Farraguerni, Cheir I Chang. Multispectral and hyperspectral image analysis with convex cones [J]. IEEE Trans. on Geoscience and Remote Sensing, 1999: 756- 770.
- [6] TeMing Tu, ChirHsing Chen. A noise subspace projection approach to target signature detection and extraction in an unknown background for hyperspectral images [J]. IEEE Trans. on Geoscience and Remote Sensing, 1998: 171- 181.
- [7] 寇述舜. 凸分析与凸二次规划 [M]. 天津大学出版社, 1994.

作者简介:

李智勇 男. 1975 年生. 博士生, 主要从事遥感信息处理、超光谱图像目标检测与识别等方面的研究工作.

匡纲要 男. 1966 年生. 博士, 副教授, 主要从事雷达信号处理、SAR 图像判读、多光谱图像目标识别、雷达目标特性分析等领域的研究工作. 在国内外学术刊物上发表 30 余篇学术论文.

郁文贤 男. 1964 年生. 博士、教授、博士生导师, 主要从事雷达目标识别、信息融合、神经网络等方面的研究. 在国内外学术刊物上发表 50 余篇学术论文.