

# 高光谱图像高维多尺度自回归有监督检测

贺霖<sup>1</sup> 潘泉<sup>2</sup> 邸韦华<sup>3</sup> 李远清<sup>1</sup>

**摘要** 给出一种有监督检测算法以检测高光谱图像中的区域目标. 为利用高光谱图像中的空间尺度维信息, 在高光谱图像多尺度观测不同相连节点之间建立高维多尺度自回归模型, 并利用四叉树节点间的多阶马尔可夫性和高维多尺度回归噪声先验概率密度与高维观测条件概率密度的等价性及其多元  $t$  分布特性, 构造出适用于检测高光谱图像中区域目标的空间多尺度自回归有监督检测算法. 理论分析及实验中的 5 种评价方法的结果均表明该检测器可有效检测出高光谱图像中的目标区域.

**关键词** 高光谱图像, 高维多尺度自回归, 有监督检测, 区域目标  
**中图分类号** TP391.4

## Supervised Detection for Hyperspectral Imagery Based on High-dimensional Multiscale Autoregression

HE Lin<sup>1</sup> PAN Quan<sup>2</sup> DI Wei<sup>3</sup> LI Yuan-Qing<sup>1</sup>

**Abstract** A supervised detection algorithm is presented to detect the target region in hyperspectral imagery. In order to utilize the spatial scale information in hyperspectral data, the multiscale observation of hyperspectral imagery of different connected nodes at different scales are described by a high-dimensional autoregressive model. Then, a high-dimensional multiscale autoregression based detector to detect target region is constructed, utilizing the equality between joint distribution of various multiscale observations and that of the regression noise, and the multivariate  $t$  distribution statistics of the regression noise. Theoretical analysis and the experiment involving five performance indexes show that our detector is effective to detect target region in hyperspectral imagery.

**Key words** Hyperspectral imagery, high-dimensional multiscale autoregression, supervised detection, region target

高光谱图像成像波段密集且连续, 能够进行图谱合一的观测, 可反映观测对象的细微光谱特征<sup>[1-3]</sup>. 以此为基础的高光谱图像目标检测技术自 20 世纪 80 年代末出现后, 引起了许多相关研究机构的重视, 被应用于矿藏探测、农作物估产、伪装隐藏车辆探测、地雷探测和近海潜艇探测等许多方面<sup>[4-7]</sup>. 高光谱图像目标检测方法包括基于光谱信

息的谱检测方法和基于光谱和空间信息的空谱结合检测方法. 谱检测方法包括谱异常检测和谱匹配检测. 高光谱图像谱异常检测不利用背景和目标的先验光谱特征, 此类方法主要包括两种, 一是将不符合背景统计特性的统计异常点判为目标, RXD 算法<sup>[7-9]</sup> 和 UTD 算法<sup>[7]</sup> 等是此方法中的代表性算法, 其余的此类算法包括 He 等构造的一种最大熵和无参估计检测算法<sup>[10]</sup> 和 Di 等构造的一种光谱维噪声子空间融合算法<sup>[11]</sup>; 另一种是在高光谱图像中寻找背景或目标的后验光谱特征, 然后利用子空间投影等匹配的方法进行检测<sup>[7, 9, 12]</sup>, 低概率检测 (Low probability of detection, LPD) 算法<sup>[7]</sup> 是这类算法中的代表性算法. 而谱匹配检测是寻找和已知光谱信号相一致或是类似的光谱信号<sup>[3]</sup>, 子空间投影 (Orthogonal subspace projection, OSP) 算法<sup>[7, 13]</sup> 是此类算法中的典型算法. 除了谱异常检测算法和谱匹配检测方法之外, 还可使用空谱信息结合的方法进行目标检测, 贺霖等利用目标形状子空间的构造, 实现了在高光谱图像中同时检测具有多种形状的多类目标<sup>[14]</sup>; Schweizer 等使用三维高斯马尔可夫随机场对数据进行建模, 以利用高光谱图像的空间相关性信息构造广义似然比检测器进行检测<sup>[15]</sup>; Chang 等利用高光谱图像数据的前几个主成分估计背景信号, 利用正交投影削弱背景信号, 最后根据先

收稿日期 2007-07-09 收修改稿日期 2008-05-06  
Received July 9, 2007; in revised form May 6, 2008  
国家自然科学基金重点项目 (60634030), 国家自然科学基金 (60825306, 60475004), 航空科学基金 (2006ZC53037), 武器装备预研基金 (51401040204HK0359), 教育部新世纪人才基金 (NCET-04-0816), 教育部高等学校博士学科点专项科研基金 (200805611063) 和广东省自然科学基金研究团队资助项目 (04205783) 资助  
Supported by Key Project of National Natural Science Foundation of China (60634030), National Natural Science Foundation of China (60825306, 60475004), Aeronautics Foundation (2006ZC53037), National Defense Foundation (51401040204HK0359), New Century Excellent Talents in University (NCET-04-0816), Specialized Research Foundation for the Doctoral Program of Higher Education of China (200805611063), and Teamwork Projects Funded by Guangdong Natural Science Foundation (04205783)  
1. 华南理工大学自动化科学与工程学院 广州 510640 2. 西北工业大学自动化学院 西安 710072 3. 普度大学西拉法叶校区遥感应用实验室, IN, USA 47907-2045  
1. College of Automation Science and Engineering, South China University of Technology, Guangzhou 510640 2. College of Automation, Northwestern Polytechnical University, Xi'an 710072 3. Laboratory for Applications of Remote Sensing, Purdue University, West Lafayette, IN, USA 47907-2045  
DOI: 10.3724/SP.J.1004.2009.00509

验信息对目标信号进行增强<sup>[7]</sup>; Plaza 等将形态学滤波方法扩展到多维光谱空间, 实现了空间维、光谱维联合目标检测<sup>[16]</sup>.

自然界中的许多现象都具有多尺度特征, 人的观察活动往往也可以在不同尺度上进行. 美国麻省理工学院的 Willsky 等在 20 世纪 90 年代初提出了多尺度自回归模型并进行了深入研究<sup>[17-19]</sup>, 该模型理论的提出标志着多尺度分析理论进入了统计模型化的多尺度随机分析阶段. 现有的高光谱图像目标检测算法大都针对小目标, 一些研究者已尝试利用高光谱图像的光谱维多尺度信息进行小目标检测<sup>[20-22]</sup>, 但这些方法未考虑不同尺度之间特征的相关性. 而在废水废气排放检测、公共场所毒气体、生物战剂检测及海面原油泄漏检测等<sup>[23-26]</sup> 许多应用中, 目标物常会是有一定面积大小的区域目标, 该类目标对数据统计特性会产生明显影响, 谱异常检测不利于检测该类目标, 而如何挖掘其空间尺度信息并将之应用于高光谱图像目标检测是一个值得研究的问题. 本文对利用高光谱图像的空间维信息在目标和背景有监督条件下进行区域目标检测的问题进行了研究. 从综合利用高光谱图像观测数据的光谱维和空间尺度维信息进行目标检测的思路出发, 定义了高光谱图像高维多尺度自回归模型、高光谱图像高维多尺度自回归残差和高光谱图像高维多尺度似然比检验, 以此为基础, 结合随机过程的多阶马尔可夫性、高光谱图像高维多尺度观测与相应高维多尺度回归噪声之间的概率特性等价性、背景最大后验假设及高光谱图像高维多尺度自回归噪声多元  $t$  分布建模, 完整地推导出一种高光谱图像高维多尺度自回归有监督检测器. 理论分析和仿真实验都表明了该检测器对于检测区域目标的有效性.

## 1 高光谱图像高维多尺度检测似然比检验

高光谱图像是三维数据立方体, 可视为一组经过配准的多源图像. 对于空间大小为  $W \times H = N$  个像素、波段数为  $B$  的高光谱图像, 可表示为  $O = [x_{ijk}]_{WHB}$ . 在空间多尺度假设下, 高光谱图

像观测信息来自于原始观测数据及其向更粗尺度空间的投影. 如将  $L$  个尺度的观测数据映射到同态树<sup>[17-19]</sup> 的节点上, 则该点多尺度观测为  $\mathbf{X}_M = [\mathbf{x}^T(s\gamma^{L-1}), \mathbf{x}^T(s\gamma^{L-2}), \dots, \mathbf{x}^T(s\gamma^i), \dots, \mathbf{x}^T(s)]^T$ .

如定义  $\mathbf{R}_M$  为  $B \times L$  维高维多尺度观测空间, 则有  $\mathbf{X}_M \in \mathbf{R}_M$ . 如以  $H_0$  代表背景,  $H_1$  代表目标, 且相应的概率密度似然函数均具有参数化结构, 则可以建立参数化多尺度目标检测假设模型. 对于  $H_0$  和  $H_1$ , 可以把  $B \times L$  维高维多尺度观测空间  $\mathbf{R}_M$  划分为  $\mathbf{R}_{M0}$  和  $\mathbf{R}_{M1}$  两个高维空间. 若对应的两个似然函数也具有参数化结构, 则  $\mathbf{R}_{M0}$  空间和  $\mathbf{R}_{M1}$  空间分别对应于  $\theta_b(X_b)$  和  $\theta_t(X_t)$ . 对于两个假设  $H_0$  和  $H_1$  及与两个观测空间对应的决策  $D_0$  和  $D_1$ , 可以得到判决为虚警和检测到的概率的表达式, 利用 N-P 准则和  $P_D$ 、 $P_{FA}$  的表达式, 可得式 (1) (见本页下方).

要使  $J_{NP}$  取极值, 式 (1) 中积分项在  $\mathbf{R}_{M1}$  空间中的取值应该全部为负值. 因此可得到判别式 (2) (见本页下方), 其中  $\lambda$  为由虚警率  $P(D_1|H_0)$  确定的阈值.

**定义 1.** 当存在高光谱图像空间多尺度观测  $\mathbf{X}_M = [\mathbf{x}^T(s\gamma^{L-1}), \mathbf{x}^T(s\gamma^{L-2}), \dots, \mathbf{x}^T(s\gamma^i), \dots, \mathbf{x}^T(s)]^T$  时, 定义式 (2) 为高光谱图像高维多尺度似然比检验.

## 2 高光谱图像高维多尺度自回归检测器

### 2.1 高光谱图像高维多尺度自回归

对于  $B$  个波段数据, 可建立以下  $P$  阶回归关系:

$$\begin{aligned} \mathbf{x}(s) &= A_1\mathbf{x}(s\gamma) + A_2\mathbf{x}(s\gamma^2) + \dots + A_P\mathbf{x}(s\gamma^P) + \\ &\mathbf{a}_0 + \mathbf{v} = \sum_{i=1}^P A_i\mathbf{x}(s\gamma^i) + \mathbf{a}_0 + \mathbf{v} \end{aligned} \quad (3)$$

其中,  $A_i$  为包含  $i$  波段不同尺度相关系数的对角阵,  $\mathbf{a}_0$  为偏移向量,  $\mathbf{v} = (v_1, v_2, \dots, v_B)^T$  为零均值噪声. 式 (3) 包含了高光谱图像各波段数据尺度间的关系.

$$\begin{aligned} J_{NP} &= 1 - \lambda\alpha + \int \int \dots \int_{\mathbf{R}_{M1}} (\lambda p_{\mathbf{x}(s\gamma^{L-1}), \mathbf{x}(s\gamma^{L-2}), \dots, \mathbf{x}(s\gamma^i), \dots, \mathbf{x}(s)} | H_0(\mathbf{x}(s\gamma^{L-1}), \mathbf{x}(s\gamma^{L-2}), \dots, \\ &\mathbf{x}(s\gamma^i), \dots, \mathbf{x}(s) | H_0) - p_{\mathbf{x}(s\gamma^{L-1}), \mathbf{x}(s\gamma^{L-2}), \dots, \mathbf{x}(s\gamma^i), \dots, \mathbf{x}(s)} | H_1(\mathbf{x}(s\gamma^{L-1}), \mathbf{x}(s\gamma^{L-2}), \dots, \\ &\mathbf{x}(s\gamma^i), \dots, \mathbf{x}(s) | H_1)) d\mathbf{x}(s\gamma^{L-1}) d\mathbf{x}(s\gamma^{L-2}) \dots d\mathbf{x}(s) \end{aligned} \quad (1)$$

$$\begin{aligned} &\frac{p_{\mathbf{x}(s\gamma^{L-1}), \mathbf{x}(s\gamma^{L-2}), \dots, \mathbf{x}(s\gamma^i), \dots, \mathbf{x}(s)} | H_1(\mathbf{x}(s\gamma^{L-1}), \mathbf{x}(s\gamma^{L-2}), \dots, \mathbf{x}(s\gamma^i), \dots, \mathbf{x}(s) | H_1) d\mathbf{x}(s\gamma^{L-1}) d\mathbf{x}(s\gamma^{L-2}) \dots d\mathbf{x}(s)}{p_{\mathbf{x}(s\gamma^{L-1}), \mathbf{x}(s\gamma^{L-2}), \dots, \mathbf{x}(s\gamma^i), \dots, \mathbf{x}(s)} | H_0(\mathbf{x}(s\gamma^{L-1}), \mathbf{x}(s\gamma^{L-2}), \dots, \mathbf{x}(s\gamma^i), \dots, \mathbf{x}(s) | H_0) d\mathbf{x}(s\gamma^{L-1}) d\mathbf{x}(s\gamma^{L-2}) \dots d\mathbf{x}(s)} \\ &\begin{cases} \geq \lambda, & \text{target} \\ < \lambda, & \text{background} \end{cases} \end{aligned} \quad (2)$$

**定义 2.** 当存在高光谱图像空间多尺度观测  $\mathbf{X} = [\mathbf{x}^\top(s\gamma^{L-1}), \mathbf{x}^\top(s\gamma^{L-2}), \dots, \mathbf{x}^\top(s\gamma^i), \dots, \mathbf{x}^\top(s)]^\top$  时, 定义式 (3) 为高光谱图像高维多尺度自回归模型.

高光谱图像高维自回归过程回归指标可使用:

$$J_{BILSE} = \sum_{j=1}^K \left[ \mathbf{x}_j(s) - \sum_{i=1}^P A_i \mathbf{x}_j(s\gamma^i) - \mathbf{a}_0 \right]^\top \times \left[ \mathbf{x}_j(s) - \sum_{i=1}^P A_i \mathbf{x}_j(s\gamma^i) - \mathbf{a}_0 \right] \quad (4)$$

其中  $B$  表示波段数,  $K$  为训练样本个数.

**定义 3.** 当存在高光谱图像空间多尺度观测  $\mathbf{X} = [\mathbf{x}^\top(s\gamma^{L-1}), \mathbf{x}^\top(s\gamma^{L-2}), \dots, \mathbf{x}^\top(s\gamma^i), \dots, \mathbf{x}^\top(s)]^\top$  时, 定义  $J_{BILSE}$  (式 (4)) 为高光谱图像高维多尺度自回归残差和的波段累积.

如以  $J_{BILSE}$  最小为优化准则, 则解式 (3) 为

$$(A_1, A_2, \dots, A_P) = \arg \min J_{BILSE}(A_1, A_2, \dots, A_P) \quad (5)$$

从式 (4) 知求  $J_{BILSE}$  最小等价于求每个残差平方累积项最小, 即每波段数据最小二乘回归.

对于某条件下获取的高光谱图像中的同一类别观测对象, 无论其是由单一纯物质组成还是由多种纯物质混合而成, 其在各个尺度上表现出的光谱特征应该是稳定和不变的.

**性质 1.** 高光谱图像中的同一类别观测对象具有相同的尺度间相关性.

如果使用定义 2 中的高光谱图像高维多尺度自回归模型描述高光谱图像的尺度间相关性, 则高光谱图像中同一类别观测对象对应着同一组回归矩阵和偏移向量, 且相应残差数据样本来自同一分布.

**性质 2.** 高光谱图像中的同一观测对象类别的高维多尺度自回归残差样本来自同一分布.

## 2.2 目标高维多尺度自回归似然

对于  $H_1$  假设, 考虑定义 2 中的模型, 根据概率密度乘法准则及相应马尔可夫性有:

$$\begin{aligned} p(\mathbf{x}(s\gamma^{L-1}), \mathbf{x}(s\gamma^{L-2}), \dots, \mathbf{x}(s)|H_1) = & p(x_1(s\gamma^{L-1})|H_1)p(x_2(s\gamma^{L-1})|x_1(s\gamma^{L-1}), H_1), \dots, \\ & p(x_B(s\gamma^{L-1})|x_{B-1}(s\gamma^{L-1}), \dots, x_1(s\gamma^{L-1}), H_1), \dots, \\ & p(x_1(s\gamma^{L-2})|\mathbf{x}(s\gamma^{L-1}), H_1)p(x_2(s\gamma^{L-2})|x_1(s\gamma^{L-2}), \\ & \mathbf{x}(s\gamma^{L-1}), H_1), \dots, p(x_B(s\gamma^{L-2})|x_{B-1}(s\gamma^{L-2}), \dots, \\ & x_1(s\gamma^{L-2}), \mathbf{x}(s\gamma^{L-1}), H_1)p(x_1(s\gamma^{L-3})|\mathbf{x}(s\gamma^{L-2}), \\ & \mathbf{x}(s\gamma^{L-1}), H_1), \dots, p(x_1(s\gamma^{L-P-1})|\mathbf{x}(s\gamma^{L-P}), \dots, \\ & \mathbf{x}(s\gamma^{L-1}), H_1)p(x_2(s\gamma^{L-P-1})|x_1(s\gamma^{L-P-1}), \\ & \mathbf{x}(s\gamma^{L-P}), \dots, \mathbf{x}(s\gamma^{L-1}), H_1), \dots, \end{aligned}$$

$$\begin{aligned} & p(x_B(s\gamma^{L-P-1})|x_{B-1}(s\gamma^{L-P-1}), \dots, \\ & x_1(s\gamma^{L-P-1}), \mathbf{x}(s\gamma^{L-P}), \dots, \mathbf{x}(s\gamma^{L-1}), H_1), \dots, \\ & p(x_1(s\gamma^{L-P-2})|\mathbf{x}(s\gamma^{L-P-1}), \dots, \\ & \mathbf{x}(s\gamma^{L-1}), H_1)p(x_2(s\gamma^{L-P-2})|x_1(s\gamma^{L-P-2}), \\ & \mathbf{x}(s\gamma^{L-P-1}), \dots, \mathbf{x}(s\gamma^{L-1}), H_1), \dots, \\ & p(x_B(s\gamma^{L-P-2})|x_{B-1}(s\gamma^{L-P-2}), \dots, x_1(s\gamma^{L-P-2}), \\ & \mathbf{x}(s\gamma^{L-P-1}), \dots, \mathbf{x}(s\gamma^{L-1}), H_1), \dots, \\ & p(x_1(s\gamma^{L-1})|\mathbf{x}(s\gamma), \dots, \mathbf{x}(s\gamma^{L-1}), H_1)p(x_2(s\gamma)|x_1(s\gamma), \\ & \mathbf{x}(s\gamma), \dots, \mathbf{x}(s\gamma^{L-1}), H_1), \dots, p(x_B(s\gamma)|x_{B-1}(s\gamma), \dots, \\ & x_1(s\gamma), \mathbf{x}(s\gamma), \dots, \mathbf{x}(s\gamma^{L-1}), H_1) = \\ & p(\mathbf{x}(s\gamma^{L-1})|H_1)p(\mathbf{x}(s\gamma^{L-2})|\mathbf{x}(s\gamma^{L-1}), H_1), \dots, \\ & p(\mathbf{x}(s\gamma^{L-P-1})|\mathbf{x}(s\gamma^{L-P}), \dots, \mathbf{x}(s\gamma^{L-1}), H_1) \times \\ & p(\mathbf{x}(s\gamma^{L-P-2})|\mathbf{x}(s\gamma^{L-P-1}), \mathbf{x}(s\gamma^{L-P}), \dots, \\ & \mathbf{x}(s\gamma^{L-1}), H_1), \dots, p(\mathbf{x}(s)|\mathbf{x}(s\gamma^{L-1}), \\ & \mathbf{x}(s\gamma^{L-2}), \dots, \mathbf{x}(s\gamma)|H_1) = \\ & p(\mathbf{x}(s\gamma^{L-1})|H_1)p(\mathbf{x}(s\gamma^{L-2})|\mathbf{x}(s\gamma^{L-1}), H_1), \dots, \\ & p(\mathbf{x}(s\gamma^{L-P-1})|\mathbf{x}(s\gamma^{L-P}), \dots, \mathbf{x}(s\gamma^{L-1}), H_1) \times \\ & p(\mathbf{x}(s\gamma^{L-P-2})|\mathbf{x}(s\gamma^{L-P-1}), \mathbf{x}(s\gamma^{L-P}), \dots, \\ & \mathbf{x}(s\gamma^{L-2}), H_1), \dots, p(\mathbf{x}(s)|\mathbf{x}(s\gamma^P), \dots, \mathbf{x}(s\gamma)|H_1) \quad (6) \end{aligned}$$

其中  $P$  为与某一尺度高光谱图像观测存在相关性的紧邻更细尺度的尺度数. 可得到

$$\begin{aligned} \mathbf{x}(s) &= \sum_{i=1}^P A_{0i} \mathbf{x}(s\gamma^i) + \mathbf{a}_0 + \mathbf{v}_0 \\ &\dots \\ \mathbf{x}(s\gamma^{L-P-1}) &= \sum_{i=L-P}^{L-1} A_{(L-P-1)i} \mathbf{x}(s\gamma^i) + \\ &\mathbf{a}_{L-P-1} + \mathbf{v}_{L-P-1} \quad (7) \end{aligned}$$

其中,  $A_{0i}$  为包含 0 尺度和  $i$  尺度间相关系数的对角阵. 由式 (7) 知


$$\mathbf{v}_0 = \mathbf{x}(s) - \left( \sum_{i=1}^P A_i \mathbf{x}(s\gamma^i) + \mathbf{a}_0 \right) \quad (8)$$

故  $\mathbf{v}_0$  与  $\mathbf{x}(s)$  间存在一个偏移量, 可得

$$\begin{aligned} p_{\mathbf{v}_0}(\mathbf{v}_0|H_1) &= p_{\mathbf{v}_0} \left( \mathbf{x}(s) - \right. \\ &\left. \left( \sum_{i=1}^P A_i \mathbf{x}(s\gamma^i) + \mathbf{a}_0 \right) \middle| \mathbf{x}(s\gamma), \dots, \mathbf{x}(s\gamma^P), H_1 \right) = \\ &p_{\mathbf{X}} \left( \mathbf{x}(s) - \left( \sum_{i=1}^P A_i \mathbf{x}(s\gamma^i) + \mathbf{a}_0 \right) + \right. \end{aligned}$$

$$\left( \sum_{i=1}^P \mathbf{A}_i \mathbf{x}(s\gamma^i) + \mathbf{a}_0 \right) \left| \mathbf{x}(s\gamma), \dots, \mathbf{x}(s\gamma^P), H_1 \right) = p_{\mathbf{X}}(\mathbf{x}(s) | \mathbf{x}(s\gamma), \dots, \mathbf{x}(s\gamma^P), H_1) \quad (9)$$

如令  $A = \sum_{i=1}^P \mathbf{A}_i \mathbf{x}(s\gamma^i) + \mathbf{a}_0$ , 该过程也可如图 1 所示.



(a) 某节点观测的概率密度

(b) 回归噪声的概率密度

(a) Probability density of the observation of one noise (b) Probability density of corresponding regression noise

图 1 某节点观测与对应的回归噪声间概率密度函数的关系  
Fig. 1 The relationship between the probability density of the observation with the corresponding regression noise

与式 (9) 的证明同理, 可以得到:

$$p_{\mathbf{v}_1}(\mathbf{v}_1 | H_1) = p_{\mathbf{X}}(\mathbf{x}(s\gamma) | \mathbf{x}(s\gamma^{P+1}), \dots, \mathbf{x}(s\gamma^2), H_1) \dots$$

$$p_{\mathbf{v}_{L-P-1}}(\mathbf{v}_{L-P-1} | H_1) = p_{\mathbf{X}}(\mathbf{x}(s\gamma^{L-P-1}) | \mathbf{x}(s\gamma^{L-1}), \dots, \mathbf{x}(s\gamma^{L-P}), H_1) \quad (10)$$

对式 (6) 中  $P-1$  个条件变量数分别为  $P-1, P-2, \dots, 1$  的条件概率密度函数可以分别建立  $P-1$  个回归阶数分别是  $P-1, P-2, \dots, 1$  的高维自回归方程. 并考虑其分别对应的  $P-1, P-2, \dots, 1$  阶马尔可夫性, 利用式 (10) 的证明过程同理可以得到:

$$p_{\mathbf{v}_{L-P}}(\mathbf{v}_{L-P} | H_1) = p_{\mathbf{X}}(\mathbf{x}(s\gamma^{L-P}) | \mathbf{x}(s\gamma^{L-1}), \dots, \mathbf{x}(s\gamma^{L-P+1}), H_1)$$

$$p_{\mathbf{v}_{L-P+1}}(\mathbf{v}_{L-P+1} | H_1) = p_{\mathbf{X}}(\mathbf{x}(s\gamma^{L-P+1}) | \mathbf{x}(s\gamma^{L-1}), \dots, \mathbf{x}(s\gamma^{L-P+2}), H_1) \dots$$

$$p_{\mathbf{v}_{L-2}}(\mathbf{v}_{L-2} | H_1) = p_{\mathbf{X}}(\mathbf{x}(s\gamma^{L-2}) | \mathbf{x}(s\gamma^{L-1}), H_1) \quad (11)$$

$$p(\mathbf{x}(s\gamma^{L-1}), \mathbf{x}(s\gamma^{L-2}), \dots, \mathbf{x}(s) | H_1) = p(\mathbf{x}(s\gamma^{L-1}) | H_1) p(\mathbf{x}(s\gamma^{L-2}) | \mathbf{x}(s\gamma^{L-1}), \phi_{L-2}(X_t), H_1), \dots, p(\mathbf{x}(s\gamma^{L-P-1}) | \mathbf{x}(s\gamma^{L-P}), \dots, \mathbf{x}(s\gamma^{L-1}) \phi_{L-P-1}(X_t), H_1) \times p(\mathbf{x}(s\gamma^{L-P-2}) | \mathbf{x}(s\gamma^{L-P-1}), \mathbf{x}(s\gamma^{L-P}), \dots, \mathbf{x}(s\gamma^{L-1}) \phi_{L-P-2}(X_t), H_1), \dots,$$

$$p(\mathbf{x}(s) | \mathbf{x}(s\gamma^P), \dots, \mathbf{x}(s\gamma), \phi_0(\mathbf{X}_t), H_1) = p(\mathbf{x}(s\gamma^{L-1}) | H_1) p_{\mathbf{v}_1}(\mathbf{v}_1 | \phi_1(X_t), H_1) \times \dots \times p_{\mathbf{v}_{L-P-1}}(\mathbf{v}_{L-P-1} | \phi_{L-P-1}(X_t), H_1) \times p_{\mathbf{v}_{L-P}}(\mathbf{v}_{L-P} | \phi_{L-P}(X_t), H_1) \times p_{\mathbf{v}_{L-P+1}}(\mathbf{v}_{L-P+1} | \phi_{L-P+1}(X_t), H_1) \times \dots \times p_{\mathbf{v}_{L-2}}(\mathbf{v}_{L-2} | H_1) \quad (12)$$

根据性质 1, 通过目标训练样本集  $X_t$  和高维多尺度自回归模型可得到高光谱图像中的目标类别对应的一组回归矩阵和偏移向量, 将这一组参数表示为  $\phi(X_t)(i=0, 1, \dots, L-1)$ , ( $i$  对应于式 (11) 和 (15) 中等式左边的  $s\gamma^i$  角标), 则  $\phi(\mathbf{X}_t)$  所体现出的目标类别尺度间相关性应该是待检测数据样本中的目标数据样本也同样具有的, 再利用式 (6)、(10) 和 (11), 可以得到式 (12) 所示的有监督条件下的目标似然函数.

### 2.3 最大后验背景高维多尺度自回归似然

一般情况下观测场景中的背景组成较为多样, 可将其视为来自于  $C$  个总体. 设不同背景总体相对于多尺度观测数据的后验概率为  $P(U_j | \mathbf{x}(s\gamma^{L-1}), \mathbf{x}(s\gamma^{L-2}), \dots, \mathbf{x}(s))(j=1, 2, \dots, C)$  对于观测数据样本  $\mathbf{x}(s\gamma^{L-1}), \mathbf{x}(s\gamma^{L-2}), \dots, \mathbf{x}(s)$  来自于哪个背景总体的一个合理解释是根据后验概率进行判断, 即:

$$j = \arg \max_{j=1, 2, \dots, C} P(U_j | \mathbf{x}(s\gamma^{L-1}), \mathbf{x}(s\gamma^{L-2}), \dots, \mathbf{x}(s)) \quad \mathbf{x}(s\gamma^{L-1}), \mathbf{x}(s\gamma^{L-2}), \dots, \mathbf{x}(s) \in U_j \quad (13)$$

根据贝叶斯公式有

$$P(U_j | \mathbf{x}(s\gamma^{L-1}), \mathbf{x}(s\gamma^{L-2}), \dots, \mathbf{x}(s)) = \frac{P(U_j) p(\mathbf{x}(s\gamma^{L-1}), \mathbf{x}(s\gamma^{L-2}), \dots, \mathbf{x}(s) | U_j)}{p(\mathbf{x}(s\gamma^{L-1}), \mathbf{x}(s\gamma^{L-2}), \dots, \mathbf{x}(s))} \quad (14)$$

如假设所有背景类别出现的先验概率相同, 即:

$$P(U_1) = P(U_2) = \dots = P(U_C) = \frac{1}{C} \quad (15)$$

又由于所讨论的几个背景类别总体针对相同的样本集进行处理, 因此根据式 (15) 可知, 式 (13) 的判别准则与下式等价:

$$j = \arg \max_{j=1, 2, \dots, C} p(\mathbf{x}(s\gamma^{L-1}), \mathbf{x}(s\gamma^{L-2}), \dots, \mathbf{x}(s) | U_j) \quad \mathbf{x}(s\gamma^{L-1}), \mathbf{x}(s\gamma^{L-2}), \dots, \mathbf{x}(s) \in U_j \quad (16)$$

若在  $H_0$  假设下, 多尺度观测不同尺度间也存在  $P$  阶马尔可夫性, 又考虑多个背景总体, 则有:

$$\begin{aligned} & p(\mathbf{x}(s\gamma^{L-1}), \mathbf{x}(s\gamma^{L-2}), \dots, \mathbf{x}(s)|U_j, H_0) = \\ & p(\mathbf{x}(s\gamma^{L-1})|U_j, H_0)p(\mathbf{x}(s\gamma^{L-2})|\mathbf{x}(s\gamma^{L-1}), \\ & U_j, H_0), \dots, p(\mathbf{x}(s\gamma^{L-P-1})|\mathbf{x}(s\gamma^{L-P}), \dots, \mathbf{x}(s\gamma^{L-1}), \\ & U_j, H_0)p(\mathbf{x}(s\gamma^{L-P-2})|\mathbf{x}(s\gamma^{L-P-1}), \mathbf{x}(s\gamma^{L-P}), \dots, \\ & \mathbf{x}(s\gamma^{L-1}), U_j, H_0), \dots, p(\mathbf{x}(s)|\mathbf{x}(s\gamma^P), \dots, \\ & \mathbf{x}(s\gamma), U_j, H_0) \quad (j = 1, 2, \dots, C) \end{aligned} \quad (17)$$

其中  $j = 1, 2, \dots, C$  表示背景总体类别序号.

在  $H_1$  假设下的推导过程同样适用于  $H_0$  假设. 此时, 对于  $C$  类背景中每一类的存在:

$$\begin{aligned} & p_{\mathbf{v}'_{j_0}}(\mathbf{v}'_{j_0}|H_0) = p_{\mathbf{x}}(\mathbf{x}(s)|\mathbf{x}(s\gamma^P), \dots, \mathbf{x}(s\gamma), U_j, H_0) \\ & \dots \\ & p_{\mathbf{v}'_{j(L-P-1)}}(\mathbf{v}'_{j(L-P-1)}|H_0) = \\ & p_{\mathbf{x}}(\mathbf{x}(s\gamma^{L-P-1})|\mathbf{x}(s\gamma^{L-1}), \dots, \mathbf{x}(s\gamma^{L-P}), U_j, H_0) \end{aligned} \quad (18)$$

对于  $P-1$  个条件变量数分别为  $P-1, P-2, \dots, 1$  的多尺度观测条件概率密度函数及其相应的  $P-1$  个自回归方程, 可得:

$$\begin{aligned} & p_{\mathbf{v}'_{j(L-P)}}(\mathbf{v}'_{j(L-P)}|H_0) = \\ & p_{\mathbf{x}}(\mathbf{x}(s\gamma^{L-P})|\mathbf{x}(s\gamma^{L-1}), \dots, \mathbf{x}(s\gamma^{L-P+1}), U_j, H_0) \\ & p_{\mathbf{v}'_{j(L-P+1)}}(\mathbf{v}'_{j(L-P+1)}|H_0) = \\ & p_{\mathbf{x}}(\mathbf{x}(s\gamma^{L-P+1})|\mathbf{x}(s\gamma^{L-1}), \dots, \mathbf{x}(s\gamma^{L-P+2}), U_j, H_0) \\ & \dots \\ & p_{\mathbf{v}'_{j(L-2)}}(\mathbf{v}'_{j(L-2)}|H_0) = \\ & p_{\mathbf{x}}(\mathbf{x}(s\gamma^{L-2})|\mathbf{x}(s\gamma^{L-1}), U_j, H_0) \end{aligned} \quad (19)$$

与第 2.2 节中的分析类似, 通过某类背景训练样本集  $X_{jb}(j = 0, 1, \dots, C, \text{表示背景类别})$  和高光谱图像高维多尺度自回归模型可得到高光谱图像中的背景类别对应的回归矩阵和偏移向量, 将这一组参数表示为  $\phi_{ji}(X_{jb})(j = 0, 1, \dots, C; i = 0, 1, \dots, L-1)$ , 对应于式 (18) 和 (19) 中的  $\mathbf{v}'_{ji}$  的角标, 则  $\phi_{ji}(X_{jb})$  所体现出的某背景类别尺度间相关性应该是待检测数据样本中的该背景类别数据样本也同样具有的, 再根据式 (16) ~ (19), 可得背景似然函数:

$$\begin{aligned} & p(\mathbf{x}(s\gamma^{L-1}), \mathbf{x}(s\gamma^{L-2}), \dots, \mathbf{x}(s)|H_0) = \\ & \max_{j=1,2,\dots,C} p_{\mathbf{x}}(\mathbf{x}(s\gamma^{L-1})|U_j, H_0) \times \\ & p_{\mathbf{v}'_{j_0}}(\mathbf{v}'_{j_0}|\phi_{j_0}(X_{jb}), H_0)p_{\mathbf{v}'_{j_1}}(\mathbf{v}'_{j_1}|\phi_{j_1}(X_{jb})H_0) \times \dots \times \\ & p_{\mathbf{v}'_{j(L-P-1)}}(\mathbf{v}'_{j(L-P-1)}|\phi_{j(L-P-1)}(X_{jb}), H_0) \times \\ & p_{\mathbf{v}'_{j(L-P)}}(\mathbf{v}'_{j(L-P)}|\phi_{j(L-P)}(X_{jb}), H_0) \times \\ & p_{\mathbf{v}'_{j(L-P+1)}}(\mathbf{v}'_{j(L-P+1)}|\phi_{j(L-P+1)}(X_{jb})H_0) \times \dots \times \\ & p_{\mathbf{v}'_{j(L-2)}}(\mathbf{v}'_{j(L-2)}|\phi_{j(L-2)}(X_{jb}), H_0) \end{aligned} \quad (20)$$

## 2.4 高维多尺度自回归似然比检验

据式 (2)、(12) 和 (20) 可得到多尺度似然比检验的判别式为式 (21) (见本页下方), 其中,  $\lambda_1$  为由虚警率  $\int_{\lambda_1}^{+\infty} f_{\delta_1(\mathbf{X}_M)|H_0}(\delta_1(\mathbf{X}_M)|H_0) d\delta_1(\mathbf{X}_M)$  确定的阈值,  $f_{\delta_1(\mathbf{X}_M)|H_0}$  为检测变换输出对应的概率密度函数. 由于多尺度观测除零尺度外, 其余尺度观测均由零尺度观测分解而来, 因此在最粗尺度的训练样本很少, 可假设最粗尺度上任一待检测位置是目标和背景的先验概率相等, 则式 (21) 化简为式 (22). 其中  $\lambda_2$  为由虚警率  $\int_{\lambda_2}^{+\infty} f_{\delta_2(\mathbf{X}_M)|H_0}(\delta_2(\mathbf{X}_M)|H_0) d\delta_2(\mathbf{X}_M)$  确定的阈值,  $f_{\delta_2(\mathbf{X}_M)|H_0}$  为检测变换输出对应的概率密度函数.

$$\begin{aligned} \delta_1(\mathbf{X}_M) &= \frac{L_t(\mathbf{X}_M)}{L_b(\mathbf{X}_M)} = \\ & \frac{p(\mathbf{x}(s\gamma^{L-1})|H_1)p_{\mathbf{v}_1}(\mathbf{v}_1|\phi_1(\mathbf{X}_t), H_1) \times \dots \times p_{\mathbf{v}_{L-P-1}}(\mathbf{v}_{L-P-1}|\phi_{L-P-1}(\mathbf{X}_t), H_1)}{\max_{j=1,2,\dots,C} p(\mathbf{x}(s\gamma^{L-1})|H_0)p_{\mathbf{v}'_{j_0}}(\mathbf{v}'_{j_0}|\phi_{j_0}(X_{jb}), H_0)p_{\mathbf{v}'_{j_1}}(\mathbf{v}'_{j_1}|\phi_{j_1}(X_{jb}), H_0) \times \dots \times p_{\mathbf{v}'_{j(L-P-1)}}(\mathbf{v}'_{j(L-P-1)}|\phi_{j(L-P-1)}(X_{jb}), H_0)} \times \\ & \frac{p_{\mathbf{v}_{L-P}}(\mathbf{v}_{L-P}|\phi_{L-P}(\mathbf{X}_t), H_1)p_{\mathbf{v}_{L-P+1}}(\mathbf{v}_{L-P+1}|\phi_{L-P+1}(\mathbf{X}_t), H_1) \times \dots \times p_{\mathbf{v}_{L-2}}(\mathbf{v}_{L-2}, H_1)}{p_{\mathbf{v}'_{j(L-P)}}(\mathbf{v}'_{j(L-P)}|\phi_{j(L-P)}(X_{jb}), H_0)p_{\mathbf{v}'_{j(L-P+1)}}(\mathbf{v}'_{j(L-P+1)}|\phi_{j(L-P+1)}(X_{jb}), H_0) \times \dots \times p_{\mathbf{v}'_{j(L-2)}}(\mathbf{v}'_{j(L-2)}|\phi_{j(L-2)}(X_{jb}), H_0)} = \\ & \frac{p(\mathbf{x}(s\gamma^{L-1})|H_1) \prod_{i=0}^{L-2} p_{\mathbf{v}_i}(\mathbf{v}_i|\phi_i(\mathbf{X}_t), H_1)}{\max_{j=1,2,\dots,C} p(\mathbf{x}(s\gamma^{L-1})|H_0) \prod_{i=0}^{L-2} p_{\mathbf{v}'_{ji}}(\mathbf{v}'_{ji}|\phi_{ji}(X_{jb}), H_0)} \begin{cases} \geq \lambda_1, & \text{target} \\ < \lambda_1, & \text{background} \end{cases} \end{aligned} \quad (21)$$

$$\delta_2(\mathbf{X}_M) = \frac{\prod_{i=0}^{L-2} p_{\mathbf{v}_i}(\mathbf{v}_i|\phi_i(X_t), H_1)}{\max_{j=1,2,\dots,C} \prod_{i=0}^{L-2} p_{\mathbf{v}'_{ji}}(\mathbf{v}'_{ji}|\phi_{ji}(X_{jb}), H_0)} \begin{cases} \geq \lambda_2 & \text{target} \\ < \lambda_2 & \text{background} \end{cases} \quad (22)$$

式 (22) 中的回归残差数据是  $B$  维的高维数据, 计算时需预先从训练样本中获取其统计特性. 高斯分布由于其运算简单且可较好描述大样本的统计特性等原因, 而成为最常用的统计模型. Manolakis 等认为高光谱图像观测数据是高维图像数据, 具有较大的复杂性, 难以用多元高斯分布来描述<sup>[27]</sup>. 多元  $t$  分布与多元高斯分布相比, 多了自由度和数据维数参数, 对复杂的高维数据具有更好的适应性, 可更准确描述高维数据的宽尾等特性<sup>[28]</sup>. 因此, 选择多元  $t$  分布来描述高光谱图像高维多尺度自回归残差数据的统计特性, 根据第 2.1 节中的性质 2, 通过某类观测对象的训练样本集  $\mathbf{X}$  ( $\mathbf{X}$  可以是  $X_t$  或是  $X_{jb}$  中的任意一种) 获取的关于多元  $t$  分布的参数化描述可以用来衡量待检测样本与该类观测对象的似然程度. 经高维多尺度自回归处理后的高维回归噪声数据的分布可认为具有零均值和对称性, 再利用式 (22) 可以得到高光谱图像高维多尺度自回归有监督检测器 (23) (见本页下方), 其中,  $\Psi$  为散射矩阵,  $\nu$  为自由度,  $p$  为维数,  $\tau$  为由虚

警率  $\int_{\tau}^{+\infty} f_{\eta(\mathbf{X}_M)|H_0}(\eta(\mathbf{X}_M)|H_0)d\eta(\mathbf{X}_M)$  确定的阈值,  $f_{\eta(\mathbf{X}_M)|H_0}$  为检测变换输出的概率密度函数.

### 3 实验及其分析

实验对象为一套美国 Spectra Vista 公司的机载 EPS-A 成像光谱仪拍摄的高光谱图像数据, 航拍高度为 1500 英尺, 地面空间分辨率为 3.6 米左右, 数据共包含 31 个波段, 图像灰度阶数 16 bits, 包括草皮、阴影、建筑物、公路和泥土等五类地物.

对高光谱图像多尺度观测, 利用训练数据和定义 2 及定义 3 中定义的模型求取五种地物的多尺度观测对应的回归系数和回归噪声, 并估计回归噪声多元  $t$  分布参数, 多尺度观测为 4 个尺度, 训练样本数目为 400, 回归阶数从二阶开始. 以建筑物为待检测目标. 使用上述计算得到的各组参数进行处理. (篇幅所限, 空间各点在 0、1、2 尺度, 在 1、2、3 三个尺度及 2、3 两个尺度观测之间的回归噪声的概率图示略).

图 2(a) (见下页) 是使用式 (23) 高光谱图像高维多尺度自回归有监督检测器和上述中间数据得到的检测变换结果; 图 2(b) 是使用高维多尺度自回归模型且对回归噪声多元正态分布建模得到的结果, 对应算法称为 MMGD (Multiscale multivariate Gaussian distribution) 算法; 图 2(c) 是对原始观测数据使用多元  $t$  分布建模得到的结果, 对应算法称为 MTD (Multivariate- $t$ -distribution) 算法;

$$\eta(\mathbf{X}_M) = \frac{\prod_{i=0}^{L-2} f(\mathbf{v}_i|\mathbf{0}, \Psi_i(X_t), \nu_i(\mathbf{X}_t), \phi_i(X_t))}{\max_{j=1,2,\dots,C} \left( \prod_{i=0}^{L-2} f(\mathbf{v}'_{ji}|\mathbf{0}, \Psi'_{ji}(X_{jb}), \nu'_{ji}(X_{jb}), \phi_{ji}(X_{jb})) \right)} = \frac{\left( \prod_{i=0}^{L-2} |\Psi_i(\mathbf{X}_t)| \right)^{-\frac{1}{2}} \prod_{i=0}^{L-2} \Gamma\left(\frac{\nu_i(X_t) + p}{2}\right)}{\left( \prod_{i=0}^{L-2} \nu_i(\mathbf{X}_t) \right)^{\frac{p}{2}} \prod_{i=0}^{L-2} \Gamma\left(\frac{\nu_i(X_t)}{2}\right) \prod_{i=0}^{L-2} \left[ 1 + \frac{1}{\nu_i} \mathbf{v}_i^T(\mathbf{x}, \phi_i(X_t)) \Psi_i^{-1}(\mathbf{X}_t) \mathbf{v}_i(\mathbf{x}, \phi_i(X_t)) \right]^{\frac{\nu_i(X_t) + p}{2}} \times \min_{j=1,2,\dots,C} \frac{\left( \prod_{i=0}^{L-2} \nu'_{ji}(X_{jb}) \right)^{\frac{p}{2}} \prod_{i=0}^{L-2} \Gamma\left(\frac{\nu_{ji}(\mathbf{X}_{jb})}{2}\right) \prod_{i=0}^{L-2} \left[ 1 + \frac{1}{\nu_{ji}(X_{jb})} \mathbf{v}'_{ji}^T(\mathbf{x}, \phi_{ji}(X_{jb})) \Psi_{ji}^{-1}(X_{jb}) \mathbf{v}_{ji}(\mathbf{x}, \phi_{ji}(\mathbf{X}_{jb})) \right]^{\frac{\nu_{ji}(\mathbf{X}_{jb}) + p}{2}}}{\left( \prod_{i=0}^{L-2} |\Psi'_{ji}(\mathbf{X}_{jb})| \right)^{-\frac{1}{2}} \prod_{i=0}^{L-2} \Gamma\left(\frac{\nu'_{ji}(X_{jb}) + p}{2}\right)} \begin{cases} \geq \tau, & \text{target} \\ < \tau, & \text{background} \end{cases} \quad (23)$$

图 2(d) 是对原始观测数据使用多元正态分布建模得到的结果, 对应算法称为 MGD (Multivariate Gaussian distribution) 算法; 图 2(e) 是先提取高光谱图像的四个主成分并将其视为背景地物光谱特征, 以目标训练样本的均值作为目标光谱特征, 然后使用正交子空间投影方法得到的结果, 对应算法称为 PCM (Principal component matched) 算法; 图 2(f) 是使用三维高斯马尔可夫随机场对高光谱图像数据建模得到的结果, 该算法称为 GMRF (Gaussian Markov random field) 算法. 如果以建筑物目标与背景地物的对比度作为评价检测效果的准则, 那么对比度越强, 目标与背景的分离度越大, 检测效果越好. 在图 2 中目视比较六种算法, 图 2(a) 为本文所给出的算法 1, 检测效果最好; 图 2(e) 和图 2(f) 对应的 PCM 法和 GMRF 法的效果最差; 图 2(a) 和图 2(b) 对应的两种使用多尺度观测的本文算法和 MMGD 法的效果要好于图 2(c) 和图 2(d) 对应的只使用原始观测数据的方法. 图 2(a) 和图 2(c) 对应的使用多元  $t$  分布建模的本文算法和 MTD 的效果分别优于图 2(b) 和图 2(d) 对应的多元正态分

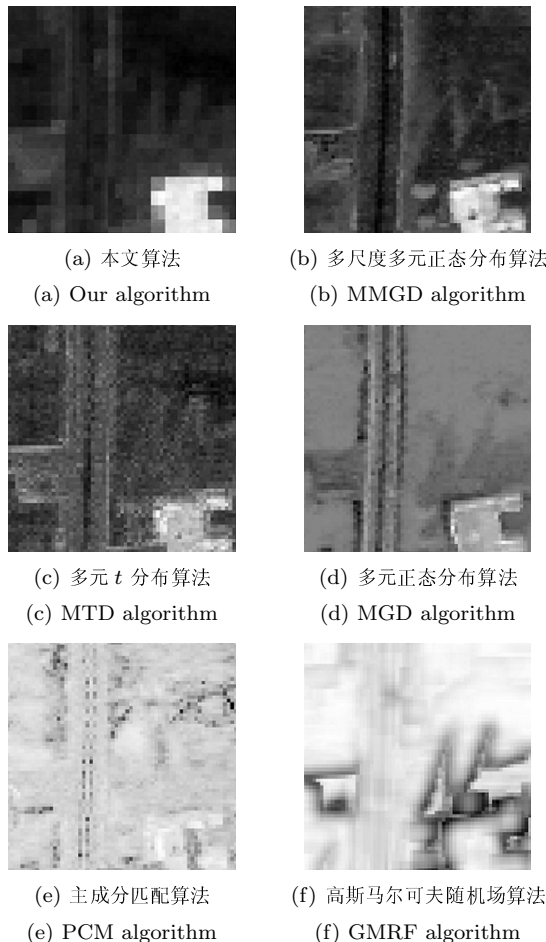


图 2 检测变换结果  
Fig. 2 Detection results

布建模的 MMGD 法和 MGD 法.

图 3 给出了上述六种算法 (依次称为算法 1~6) 的检测变换结果的均值方差分离度示意图 (已规范化到了 0 到 255 之间). 每一种算法对应一个实心棒图, 棒图的纵坐标方向中心位置由目标或背景检测值的均值决定, 其长短由检测值均方差决定, 实心棒图代表背景, 空心棒图代表目标. 从图 3 中得到的六种算法目标和背景分离程度相比较的结果与前述目视判定结果类似. 还可利用其构造 DMSV (Distance between the means relative to the standard variances) 量化评价指标:

$$DMSV = \frac{\alpha_1 |m_b - m_t|}{\alpha_2 (\sigma_b + \sigma_t) + \alpha_3 |\sigma_b + \sigma_t| + 1} \quad (24)$$

其中  $m_b$  和  $m_t$  分别是背景和背景检测值的样本均值;  $\sigma_b$  和  $\sigma_t$  是样本均方差;  $\alpha_1$ 、 $\alpha_2$  和  $\alpha_3$  是均不小于零的权重因子.  $DMSV$  越大, 表明目标和背景分离程度越大, 检测效果越好. 表 1 (见下页) 给出了使用样本均值和样本均方差作为均值和均方差的估计, 六种算法的检测变换值在  $\alpha_1 = 1$ 、 $\alpha_2 = 0$ 、 $\alpha_3 = 0$ ,  $\alpha_1 = 1$ 、 $\alpha_2 = 1$ 、 $\alpha_3 = 1$ ,  $\alpha_1 = 1$ 、 $\alpha_2 = 1$ 、 $\alpha_3 = 0.5$  及  $\alpha_1 = 1$ 、 $\alpha_2 = 0.5$ 、 $\alpha_3 = 1$  条件下的 DSMV 指标值 (分别用  $DSMV1$ 、 $DSMV2$ 、 $DSMV3$  和  $DSMV4$  表示). 通过比较表 1 中的数据可以看出, 在不同权重系数下, 本文算法的  $DSMV$  值都最高; 算法 5 和算法 6 的  $DSMV$  值明显低于其余算法; 算法 2、算法 3、算法 4 的  $DSMV$  值大小顺序随权重系数不同而有一些变化. 从  $DMSV$  看, 本文算法最有效.




图 3 样本均值方差分离度示意图

Fig. 3 Plots of means and standard variances

为更直观准确地比较各算法, 图 4 (见下页) 给出了各算法目标和背景检测变换值的核密度估计曲线 (估计算法使用高斯核和 Rule of thumb 准则). 可以看出, 算法 1 对应的目标和背景概率密度曲线模所在的位置相距最远, 曲线形状较为尖锐且尾部短, 两条曲线尾部没有重合, 说明目标和背景的分

程度非常显著;其他几种算法对应的目标和背景概率密度曲线模所在的位置相距较近,概率密度尾部较宽,两条概率密度曲线的尾部重合较多;尤其是算法 5 和 6 更甚.因此,从图 4 可知本文算法(算法 1)效果最好,算法 2~4 次之,算法 5 和 6 最差.从图 4 也可构造检测评价量化指标.利用概率密度曲线采样并进行积分运算等得到目标和背景检测变换结果均值的估计值  $m'_t$ 、 $m'_b$  和标准方差的估计值  $\sigma'_t$  和  $\sigma'_b$ ,可构造类似于  $DSMV$  的指标  $DSMV'$ :

$$DSMV' = \frac{\alpha_1 |m'_b - m'_t|}{\alpha_2 (\sigma'_b + \sigma'_t) + \alpha_3 |\sigma'_b + \sigma'_t| + 1} \quad (25)$$

表 1 算法的  $DSMV$  指标Table 1  $DSMV$  values of algorithms

算法	$DSMV1$	$DSMV2$	$DSMV3$	$DSMV4$
算法 1	199.5113	0.3640	0.4465	0.5310
算法 2	142.1776	0.0650	0.0769	0.0992
算法 3	115.5711	0.1168	0.1188	0.2259
算法 4	53.1265	0.0807	0.0883	0.1374
算法 5	2.9800	0.0022	0.0024	0.0036
算法 6	6.0717	0.0031	0.0031	0.0061

表 2 给出了图 4 的概率密度函数 (Probability density function, PDF) 曲线对应的  $DSMV'$  值 (使用 10 000 个等间隔采样并估计).与用  $DSMV$  进行的比较类似,从  $DSMV'$  看,本文给出的算法 1 在六种算法中最有效.

从图 2~4,及表 1 和表 2 得出:式 (23) 所示高光谱图像高维多尺度自回归有监督检测器对于区域目标的检测效果优于其余五种对比算法.原因如下:算法 2 利用了高光谱图像中的空间多尺度观测信息,但未能准确描述其统计特性;算法 3 和算法 4 都没有使用高光谱图像中的空间尺度维信息;算法 5 中除未利用高光谱图像空间尺度维信息外,其用作背景光谱特征的主成分信号与实际地物背景无严格的对应关系,且未考虑背景地物光谱特征并不一定满足正交条件;算法 6 没有利用高光谱图像空间尺度维信息且其使用的模型不能很好地描述高光谱图像背景统计特性.本文算法在使用高维多尺度自回归模型对高光谱图像数据进行处理的基础上使用多元  $t$  分布对高维回归噪声数据进行统计性建模,既利用了高光谱图像中的空间尺度维信息,又较为精确地描述了相关高维数据的统计特性,因此取得了比其余几种算法都好的检测效果.

表 2 算法的  $DSMV'$  指标Table 2  $DSMV'$  values of algorithms

算法	$DSMV'1$	$DSMV'2$	$DSMV'3$	$DSMV'4$
算法 1	204.16	5.8013	6.6408	9.0554
算法 2	180.60	2.6970	2.9767	4.4844
算法 3	131.95	2.9053	3.1194	5.0123
算法 4	47.20	1.6277	1.6385	3.1072
算法 5	12.75	0.2298	0.2629	0.3617
算法 6	12.93	0.2411	0.2589	0.4169

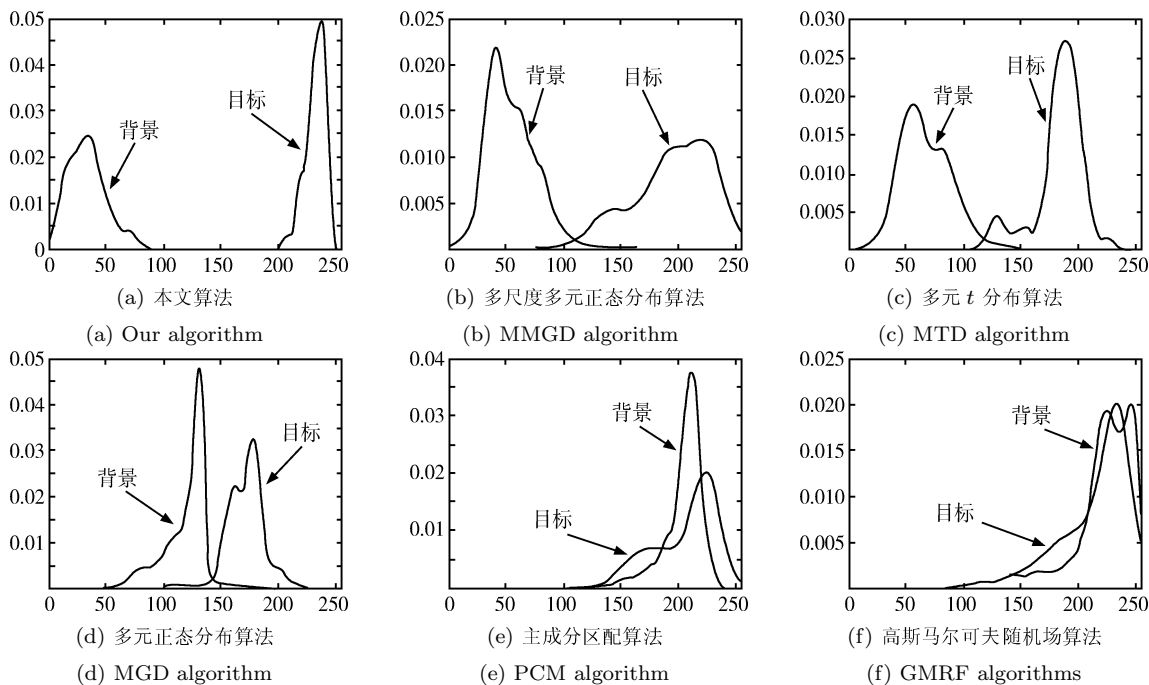


图 4 目标背景概率密度曲线

Fig. 4 Plots of probabilities density of backgrounds and target



## 4 结论和讨论

本文对利用高光谱图像的空间尺度维信息实现目标和背景有监督情况下的区域目标检测问题进行了研究, 给出了高光谱图像高维多尺度自回归有监督检测器. 从实验结果和理论分析看, 该检测器综合利用了高光谱图像的光谱维信息和空间尺度维信息, 可有效检测高光谱图像中的区域目标.

本文方法有一些方面需进一步深入研究. 高光谱图像是高维图像数据, 减小计算复杂度和提高在有限样本或是小样本条件下高维数据的处理精度是推向应用的重要问题, 后者也是模式识别和机器学习理论研究中的经典和难点问题<sup>[29]</sup>. 我们认为可从以下几点入手尝试解决这些问题:

1) 对高维高光谱图像在检测过程中进行原始数据的降维预处理. 高光谱图像光谱空间大部分是空的且样本具有趋向集中于特定区域的特性<sup>[30]</sup>. 故理论上存在着将光谱空间进行降维而保留样本信息的可能. Jia 等使用分段主成分变换进行光谱维降维, 同时保留可分性信息<sup>[31]</sup>; Chiang 等使用了投影寻踪方法<sup>[32]</sup>. 该方面须解决两个问题, 寻找可保留可分性的降维变换及变换后数据统计特性的描述.

2) 在统计性检测框架中引入有效的统计学习过程. 常用小样本统计学习算法包括半监督学习<sup>[33]</sup>和支持向量机<sup>[34]</sup>等. 半监督学习可利用待测试样本的信息以提高学习精度. 支持向量机在高维核空间的期望风险某种程度上与维数无关. Kwon 等构造了一类核变换小目标检测器<sup>[35]</sup>, 但其未讨论小样本的问题.

3) 构造准确的高光谱数据先验统计模型以从数据样本中提取真实信息.

## References

- Landgrebe D. Hyperspectral image data analysis. *IEEE Signal Processing Magazine*, 2002, **19**(1): 17–28
- Manolakis D, Marden D, Shaw G A. Hyperspectral image processing for automatic target detection applications. *Lincoln Laboratory Journal*, 2003, **14**(1): 79–116
- Manolakis D. Taxonomy of detection algorithms for hyperspectral imaging applications. *Optical Engineering*, 2005, **44**(6): 1–11
- Stein D, Schoonmaker J, Coolbaugh E. Hyperspectral Imaging for Intelligence, Surveillance, and Reconnaissance, AD Report A434124, Space and Naval Warfare Systems Center, USA, 2001
- Fay M E. An Analysis of Hyperspectral Imagery Data Collected During Operation Desert Radiance, AD Report A302643, Naval Postgraduate School, USA, 1995
- Nicola P. Detection of landmines using hyperspectral imaging. In: Proceedings of the International Society for Optical Engineering, Kissimmee, USA: SPIE, 2006. 1–9
- Chang C I, Chiang S S. Anomaly detection and classification for hyperspectral imagery. *IEEE Transactions on Geoscience and Remote Sensing*, 2002, **40**(6): 1314–1325
- He Lin, Pan Quan, Zhao Yong-Qiang, Zheng Ji-Wei, Wei Kun. Anomaly detection in hyperspectral imagery based on feature fusion of band subsets. *Acta Photonica Sinica*, 2005, **34**(11): 1752–1755  
(贺霖, 潘泉, 赵永强, 郑纪伟, 魏坤. 基于波段子集特征融合的高光谱图像异常检测. *光子学报*, 2005, **34**(11): 1752–1755)
- He L, Pan Q, Zhao Y Q, Di W. An automatic target detection algorithm for hyperspectral imagery based on feature-level fusion. In: Proceedings of SPIE the International Symposium on Multispectral Image Processing and Pattern Recognition. Wuhan, China: SPIE, 2006. 164–169
- He L, Pan Q, Di W, Li Y Q. Anomaly detection in hyperspectral imagery based on maximum entropy and nonparametric estimation. *Pattern Recognition Letters*, 2008, **29**(9): 1392–1403
- Di W, Pan Q, He L, Cheng Y M. Anomaly detection in hyperspectral imagery by fuzzy integral fusion of band-subsets. *Photogrammetric Engineering and Remote Sensing*, 2008, **74**(2): 201–213
- He Lin, Pan Quan, Zhao Yong-Qiang. Target detection in hyperspectral imagery based on linear mixing model reconstructed from measurements. *Acta Electronica Sinica*, 2007, **35**(1): 23–27  
(贺霖, 潘泉, 赵永强. 量测重构线性混合模型高光谱图像目标检测. *电子学报*, 2007, **35**(1): 23–27)
- He Lin, Pan Quan, Zhao Yong-Qiang, Zheng Ji-Wei. CFAR target detection in unknown background based on subspace projection in aerial hyperspectral imagery. *Acta Aeronautica et Astronautica Sinica*, 2006, **27**(4): 657–662  
(贺霖, 潘泉, 赵永强, 郑纪伟. 基于子空间投影的未知背景航拍高光谱图像恒虚警目标检测. *航空学报*, 2006, **27**(4): 657–662)
- He Lin, Pan Quan, Di Wei. Multicategory targets detection of hyperspectral imagery based on adaptive structured background shape-feature subspace. *Journal of Infrared and Millimeter Waves*, 2007, **26**(5): 353–358  
(贺霖, 潘泉, 邸伟. 基于自适应结构化背景和形状特征子空间的高光谱图像多类目标检测. *红外与毫米波学报*, 2007, **26**(5): 353–358)
- Schweizer S M, Moura M F. Efficient detection in hyperspectral imagery. *IEEE Transactions on Image Processing*, 2001, **10**(4): 584–597
- Plaza A, Martinez P, Plaza J, Perez R. Dimensionality reduction and classification of hyperspectral image data using sequences of extended morphological transformations. *IEEE Transactions on Geoscience and Remote Sensing*, 2005, **43**(3): 466–479
- Benveiste A, Nikoukhah R, Willisky A S. Multiscale system theory. *IEEE Transactions on Circuits and Systems I: Fundamental Theory and Applications*, 1994, **41**(1): 2–15
- Daoudi K, Frakt A B, Willisky A S. Multiscale autoregressive models and wavelets. *IEEE Transactions on Information Theory*, 1999, **45**(3): 828–845
- Irving W W, Novak L M, Willisky A S. A multiresolution approach to discriminating in SAR imagery. *IEEE Transactions on Aerospace and Electronic Systems*, 1997, **33**(4): 1157–1169
- Bruce L M, Li J, Huang Y. Automated detection of subpixel hyperspectral targets with adaptive multichannel discrete wavelet transform. *IEEE Transactions on Geoscience and Remote Sensing*, 2002, **40**(4): 977–980
- Bruce L M, Morgan C, Larsen S. Automated detection of subpixel hyperspectral targets with continuous and discrete wavelet transforms. *IEEE Transactions on Geoscience and Remote Sensing*, 2002, **39**(10): 2217–2226

- 22 Gu Y F, Jia Y H, Zhang Y. Unsupervised hyperspectral target detection based on multiresolution image fusion. In: Proceedings of the 7th International Conference on Signal Processing. Beijing, China: IEEE, 2004. 1076–1079
- 23 Manolakis D, D'Amico F M. Design and evaluation of hyperspectral algorithms for chemical warfare agent detection. In: Proceedings of SPIE International Conference on Chemical and Biological Standoff Detection III. Boston, USA: SPIE, 2005. 1–13
- 24 Gomez R B, Dasgupta S. Use of hyperspectral remote sensing for detection and monitoring of chemical and biological agents – a survey. In: Proceedings of SPIE Conference on Chemical and Biological Standoff Detection II. Philadelphia, USA: SPIE, 2004. 276–285
- 25 Hinrichs M. An infrared hyperspectral tunable filter imaging spectrometer for remote leak detection, chemical speciation and stack/vent analysis applications. In: Proceedings of SPIE Conference on Instrumentation for Air Pollution and Global Atmospheric Monitoring. Boston, USA: SPIE, 2002. 144–152
- 26 Sanchez G, Roper W E, Gomez R B. Detection and monitoring of oil spills using hyperspectral imagery. In: Proceedings of SPIE International Conference on Geo-Spatial and Temporal Image and Data Exploitation III. Orlando, USA: SPIE, 2003. 233–240
- 27 Manolakis D G, Marden D, Kerekes J P, Shaw G A. On the statistics of hyperspectral imaging data. In: Proceedings of SPIE Algorithms for Multispectral, Hyperspectral, and Ultraspectral Imagery VII. Orlando, USA: SPIE, 2001. 308–316
- 28 Liu C. ML estimation of the multivariate  $t$  distribution and the EM algorithm. *Journal of Multivariate Analysis*, 1997, **63**(2): 296–312
- 29 Fukunaga K. *Introduction to Statistical Pattern Recognition*. Boston: Academic Press, 1990
- 30 Jimenez L O, Landgrebe D A. Supervised classification in high-dimensional space: geometrical, statistical, and asymptotical properties of multivariate data. *IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews*, 1998, **28**(1): 39–54
- 31 Jia X P, Richards J A. Segmented principal components transformation for efficient hyperspectral remote-sensing image display and classification. *IEEE Transactions on Geoscience and Remote Sensing*, 1999, **37**(1): 538–542
- 32 Chiang S S, Chang C I, Ginsberg I W. Unsupervised target detection in hyperspectral images using projection pursuit. *IEEE Transactions on Geoscience and Remote Sensing*, 2001, **39**(7): 1380–1391
- 33 Chapelle O, Scholkopf B, Zien A. *Semi-supervised Learning*. Cambridge: The MIT Press, 2006
- 34 Vapnik V. *The Nature of Statistical Learning Theory (Second Edition)*. New York: Springer-Verlag, 2000
- 35 Nasrabadi N M, Kwon H. Kernel matched subspace detectors for hyperspectral target detection. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2006, **28**(2): 178–194



贺霖 华南理工大学自动化科学与工程学院讲师。2007 年获得西北工业大学博士学位。主要研究方向为多元随机信号处理、成像光谱探测、信息融合、脑信号处理。本文通信作者。

E-mail: helin@scut.edu.cn

(HE Lin Lecturer at the College of Automation Science and Engineering, South China University of Technology. He received his Ph.D. degree from Northwestern Polytechnical University in 2007. His research interest covers multivariate stochastic signal processing, imaging spectroscopy detection, information fusion, and brain signal processing. Corresponding author of this paper.)



潘泉 西北工业大学教授。1997 年获得西北工业大学博士学位。主要研究方向为动态系统建模、信息融合、智能监控和多尺度系统。

E-mail: quanpan@nwpu.edu.cn

(PAN Quan Professor at Northwestern Polytechnical University. He received his Ph.D. degree from Northwestern Polytechnical University in 1997. His research interest covers dynamic system modeling, information fusion, intelligent vision surveillance, and multiscale system.)



邸韦华 普度大学西拉法叶校区博士研究生。2008 年获得西北工业大学硕士学位。主要研究方向为多元随机信号处理、成像光谱探测、生物信息识别。

E-mail: vanilladee@gmail.com

(DI Wei Ph.D. candidate at Purdue University, West Lafayette, USA. She received her master degree from Northwestern Polytechnical University in 2008. Her research interest covers multivariate stochastic signal processing, imaging spectroscopy detection, and bio-information identification.)



李远清 华南理工大学教授。1997 年获得华南理工大学博士学位。主要研究方向为信号盲处理、机器学习、脑信号处理。E-mail: auyqli@scut.edu.cn

(LI Yuan-Qing Professor at South China University of Technology. He received his Ph.D. degree from South China University of Technology in 1997.

His research interest covers blind signal processing, machine learning, and brain signal processing.)