

基于正交子空间投影的污染气体自适应探测

崔方晓 方勇华

(中国科学院安徽光学精密机械研究所通用光学与定标与表征技术重点实验室, 安徽 合肥 230031)

摘要 超光谱成像遥测污染气体的主要目的是对其进行识别分类,进而获得其空间分布信息,确定污染源位置。实际应用中,目标光谱叠加在强背景辐射之上,此外开放路径中的实测光谱还包含大气等干扰物光谱,这些因素制约了对目标光谱的识别分类。在线性模型基础上,利用正交子空间投影方法有效压缩背景及干扰物信息,并基于广义似然比检验原理构建子空间检测器,对所有像元逐个分类识别。以氨气为目标气体进行了野外实验,数据立方体来自扫描成像傅里叶变换红外(FTIR)光谱仪,子空间向量由奇异值分解(SVD)算法得到。结果表明,子空间检测器对所有像元的识别结果优于光谱角度填图(SAM)算法。

关键词 光谱学;遥感;超光谱成像;正交子空间投影;广义似然比检验

中图分类号 TP722.5 **文献标识码** A **doi**: 10.3788/AOS201434.0730002

Adaptive Detection for Pollutant Gases Based on Orthogonal Subspace Projection

Cui Fangxiao Fang Yonghua

(Key Laboratory of Optical Calibration and Characterization, Anhui Institute of Optics and Fine Mechanics, Chinese Academy of Sciences, Hefei, Anhui 230031, China)

Abstract Identification and classification is the main purpose of hyperspectral imaging remote sensing pollutant gases, then the spatial distribution of the pollutant gases is obtained, as well as the location of the pollutant source. In practical applications, target spectrum is superimposed on intense background radiation, in addition, the spectra measured in open path comprise atmosphere interferences spectra which restrict identification and classification for target spectra. On the basis of linear model, orthogonal subspace projection method is used to effectively suppress the background and interferences' information, and the subspace detector, based on generalized likelihood ratio test principle, is used to classify all pixels one by one. The field experiment is performed with ammonia as target gas, the data cube comes from scanning imaging Fourier transform infrared spectroscopy (FTIR) spectrometer, and the subspace vectors come from singular value decomposition (SVD). The recognition results for all pixels by subspace detector are superior to spectral angle mapper (SAM) algorithm.

Key words spectroscopy; remote sensing; hyperspectral imaging; orthogonal subspace projection; generalized likelihood ratio test

OCIS codes 300.6300; 070.4790; 120.0280

1 引言

工业有害气体排放和突发的气体污染对环境和人类健康具有严重危害,对污染气体的监测是一项长期而重要的任务。近年来,随着技术进步和应用需求发展,出现了超光谱成像遥测技术,其代表的光谱仪有扫描成像光谱仪及焦平面成像光谱仪^[1-2]。

超光谱成像技术不同于传统的点源式、单一视场的光谱遥测技术,而是将光谱遥测技术和成像技术相结合,获取的信息不仅包含随波长分布的光谱辐射信息,还包括二维空间信息,形成所谓的“数据立方体”。丰富的目标光谱信息结合空间影响极大地提高了目标探测的准确性,扩展了传统探测技术的功能。

收稿日期: 2014-01-01; **收到修改稿日期**: 2014-02-19

作者简介: 崔方晓(1985—),男,博士研究生,主要从事光学遥感信号处理方面的研究。E-mail: cfx2010ep@hotmail.com

导师简介: 方勇华(1966—),男,博士生导师,主要从事遥感光电信息技术方面的研究。E-mail: yhfang@aiofm.ac.cn

在实际应用中,目标气体信号叠加在强背景辐射信号之上,但背景辐射信号通常不能通过预先测量得到,且开放路径中实测光谱还包含大气干扰物光谱,制约了对目标气体的检测和识别分类。超光谱成像遥测技术获得的数据立方体同时包含了目标气体的空间信息和光谱信息,大量的实测光谱数据为研究目标识别方法提供了便利。

实际需要检测的目标气体光谱特征是已知的,上述的目标识别分类问题转化为目标信号的检测问题,常用的算法有匹配滤波器等统计检验方法^[3-5]。这些检测算法的基础是假设实测光谱数据服从多维高斯分布,或其他更为复杂分布模型^[6-7]。正交子空间检测方法不需要假设实测数据的分布模型,仅需通过处理算法分析实测数据的结构^[4],用正交投影算子压缩背景和干扰物信息,用探测器对每个像元光谱进行识别分类。正交子空间方法最初由Harsanyi等^[8-9]提出,用于提取地物光谱成像数据的端元,并用正交子空间投影(OSP)探测器对端元分类识别。污染气体红外特征光谱与地物端元光谱具有明显的不同,如污染气体红外特征光谱为辐射亮度光谱,特征峰方向即可能朝上(发射)也可能朝下(吸收),幅值没有限制;地物端元光谱为反射率谱,特征峰方向朝上,且幅值在0~1之间。由于信号模型和约束条件不同,OSP探测器不能直接应用于开放路径遥测污染气体,需要研究特定的目标检测算法。

本文通过理论分析目标光谱与背景特征的线性组合模型,将目标气体检测问题转化为统计检验中二值竞争假设问题,根据广义似然比检验原理构建子空间检测器,对所有像元逐个识别分类。文中数据立方体的正交化采用奇异值分解(SVD)算法,背景子空间向量个数通过背景能量对总能量贡献约束来确定。野外实验以氨气为目标气体,数据来自扫描成像傅里叶变换红外(FTIR)光谱仪,子空间检测器识别结果与光谱角度填图(SAM)算法进行了对比。

2 理论基础

2.1 信号模型

开放路径中污染气体的被动红外遥测模型可以表示为^[10]

$$L(\nu) = L_0(\nu) + [1 - \tau(\nu)][B_1(\nu, T_1) - L_0(\nu)], \quad (1)$$

式中 ν 为波数, $L(\nu)$ 为仪器接收到的辐射亮度, $L_0(\nu)$ 为背景辐射亮度, $\tau(\nu)$ 为污染气体的透射率,

$B_1(\nu)$ 为环境温度 T_1 的黑体辐射亮度。

假设污染气体为单种气体薄云团,它的透射率 τ 近似表达为

$$\tau(\nu) = \exp[-\alpha(\nu)d_{\text{CL}}] \approx 1 - \alpha(\nu)d_{\text{CL}}, \quad (2)$$

式中 $\alpha(\nu)$ 为分子吸收截面, d_{CL} 为浓度程长积值。

背景辐射亮度 $L_0(\nu)$ 近似用背景温度下的黑体辐射亮度代替,那么 $[B_1(\nu) - L_0(\nu)]$ 用其一阶泰勒展开近似表达为

$$[B_1(\nu, T_1) - L_0(\nu)] \approx \left. \frac{\partial B_1(\nu, T)}{\partial T} \right|_{T=T_1} \Delta T_{\text{eff}}, \quad (3)$$

式中 ΔT_{eff} 为背景与环境的温度差。

将(2)、(3)式代入(1)式,可得

$$L(\nu) \approx L_0(\nu) + (d_{\text{CL}}\Delta T_{\text{eff}}) \left[\left. \frac{\partial B(\nu, T)}{\partial T} \right|_{T=T_1} \alpha(\nu) \right] = L_0(\nu) + as(\nu). \quad (4)$$

式中 $s(\nu) = \left. \frac{\partial B(\nu, T)}{\partial T} \right|_{T=T_1} \alpha(\nu)$,表示目标光谱特征; $a = d_{\text{CL}}\Delta T_{\text{eff}}$,表示目标光谱对应的系数。

假设系统测量的光谱维数为 K , (4)式写成向量的表达形式为

$$\mathbf{x} = \mathbf{L}_0 + as, \quad (5)$$

式中 $\mathbf{x}, \mathbf{L}_0, \mathbf{s}$ 分别为 K 维列向量, a 为标量。

根据正交子空间理论,背景辐射 \mathbf{L}_0 认为是若干背景特征的线性组合^[9]:

$$\mathbf{L}_0 = \mathbf{B}\boldsymbol{\beta}, \quad (6)$$

式中 $\mathbf{B} = [\mathbf{B}_1, \mathbf{B}_2, \dots, \mathbf{B}_q]$,表示 q 个背景特征,其中 $\mathbf{B}_i (i=1, 2, \dots, q)$ 分别为 K 维列向量; $\boldsymbol{\beta} = [\beta_1, \beta_2, \dots, \beta_q]^T$,表示 q 个背景特征分别对应的系数,其中 $\beta_i (i=1, 2, \dots, q)$ 分别为标量。 \mathbf{B} 的计算及确定参见2.3节。

由于仪器内部辐射及电子噪声的存在,实测信号总伴随着测量噪声。测量噪声记为 \mathbf{n} (\mathbf{n} 为 K 维列向量),并将(6)式代入(5)式可得

$$\mathbf{x} = \mathbf{B}\boldsymbol{\beta} + as + \mathbf{n}. \quad (7)$$

2.2 目标检测原理

根据(7)式可看到:目标存在时, $a = 0$;目标不存在时, $a \neq 0 (a > 0$ 或 $a < 0)$ 。假设测量噪声 \mathbf{n} 为各个光谱通道独立同分布的高斯白噪声 $\mathbf{n} \sim N(0, \delta^2 \mathbf{I}_K)$,其中 δ^2 为方差, \mathbf{I}_K 为 K 阶单位矩阵, K 为光谱维数。上述目标检测问题可记为二值竞争假设问题^[11],当目标不存在时,

$$H_0: \mathbf{x} = \mathbf{B}\boldsymbol{\beta} + \mathbf{n}, \quad \mathbf{n} \sim N(0, \delta^2 \mathbf{I}_K), \quad (8)$$

当目标存在时,

$$H_1: \mathbf{x} = \mathbf{B}\boldsymbol{\beta} + as + \mathbf{n} = \mathbf{Z}\boldsymbol{\theta} + \mathbf{n}, \quad (9)$$

式中 $\mathbf{Z}=[\mathbf{B} \ \mathbf{s}]=[\mathbf{B}_1, \mathbf{B}_2, \dots, \mathbf{B}_q, \mathbf{s}]$; $\boldsymbol{\theta}=[\boldsymbol{\beta}^T \ a]^T=[\beta_1, \beta_2, \dots, \beta_q, a]^T$ 。

根据广义似然比检验原理^[11], 构建目标检测器。当目标不存在时,

$$H_1: D = \frac{p_{H_1}(\mathbf{x}; \hat{\boldsymbol{\theta}})}{p_{H_0}(\mathbf{x}; \hat{\boldsymbol{\beta}})} < \gamma, \quad (10)$$

当目标存在时,

$$H_0: D = \frac{p_{H_1}(\mathbf{x}; \hat{\boldsymbol{\theta}})}{p_{H_0}(\mathbf{x}; \hat{\boldsymbol{\beta}})} > \gamma, \quad (11)$$

式中 p 为似然函数; $\hat{\boldsymbol{\theta}}$ 为 $\boldsymbol{\theta}$ 的最大似然估计, $\hat{\boldsymbol{\theta}}=(\mathbf{Z}^T \mathbf{Z})^{-1} \mathbf{Z}^T \mathbf{x}$; $\hat{\boldsymbol{\beta}}$ 为 $\boldsymbol{\beta}$ 的最大似然估计, $\hat{\boldsymbol{\beta}}=(\mathbf{B}^T \mathbf{B})^{-1} \times \mathbf{B}^T \mathbf{x}$; γ 为检测门限。

根据正交子空间投影原理, 定义 $\mathbf{P}_B^\perp = \mathbf{I} - \mathbf{B}(\mathbf{B}^T \mathbf{B})^{-1} \mathbf{B}^T$ 和 $\mathbf{P}_Z^\perp = \mathbf{I} - \mathbf{Z}(\mathbf{Z}^T \mathbf{Z})^{-1} \mathbf{Z}^T$, \mathbf{I} 为单位矩阵, 其意义分别为背景子空间和背景信号子空间正交投影算子^[9], 代入(10)、(11)式得到目标检测器^[12-13]。当目标不存在时,

$$H_1: D_{\text{ASD}}(\mathbf{x}) = \frac{\mathbf{x}^T (\mathbf{P}_B^\perp - \mathbf{P}_Z^\perp) \mathbf{x}}{\mathbf{x}^T \mathbf{P}_Z^\perp \mathbf{x}} > \gamma_{\text{ASD}}, \quad (12)$$

当目标存在时,

$$H_0: D_{\text{ASD}}(\mathbf{x}) = \frac{\mathbf{x}^T (\mathbf{P}_B^\perp - \mathbf{P}_Z^\perp) \mathbf{x}}{\mathbf{x}^T \mathbf{P}_Z^\perp \mathbf{x}} < \gamma_{\text{ASD}}, \quad (13)$$

式中 D_{ASD} 被称为自适应子空间检测器^[12-14]; γ_{ASD} 为检测门限。 D_{ASD} 服从 F 分布, 即 $D_{\text{ASD}}(\mathbf{x}) \frac{K-p-q}{p} \sim F_{p, K-p-q}(R_{\text{SIN}})$, p 和 $K-p-q$ 分别为分子、分母自由度, 非中心参数 R_{SIN} 是信噪比, H_0 时 $R_{\text{SIN}} = 0$, H_1 时 $R_{\text{SIN}} > 0$ 。根据 Neyman-Pearson 原理, 设定虚警率 P_{FA} 为固定值, 则检测门限 γ_{ASD} 可根据(14)式确定, 即

$$P_{\text{FA}} = 1 - Q_{p, K-p-q}(\gamma_{\text{ASD}}), \quad (14)$$

式中 $Q_{p, K-p-q}$ 是 $F_{p, K-p-q}$ 分布的累积分布函数。

2.3 背景子空间 \mathbf{B} 的确定

实际应用中, 背景子空间 \mathbf{B} 不可能通过测量得到, 需要从实测数据中估计。背景子空间 $\mathbf{B}=[\mathbf{B}_1, \mathbf{B}_2, \dots, \mathbf{B}_q]$ 包含 q 个背景特征, 如何确定背景子向量个数 q 是目前很多学者在研究的问题^[15-17]。本文利用一种简单的经验准则计算 q , 约束条件为背景对总能量贡献不超过某一设定阈值^[18]。

目前有多种方法可以计算正交子向量, 最常用的一种方法是 SVD 算法。它可以得到平方误差意义下的最优拟合^[19-21]。设定数据立方体的光谱维数为 K , 总像元数为 $M(M > K)$, 所有像元排列成一行, 数据立方体表达为一个二维矩阵 $\mathbf{X}=[\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_M]$, 其中 $\mathbf{x}_j (j=1, 2, \dots, M)$ 是 K 维列向量。总能量表达为 $\mathbf{X} \mathbf{X}^T$, 经 SVD 计算得到

$$\mathbf{X} \mathbf{X}^T = \mathbf{U} \boldsymbol{\Lambda} \mathbf{U}^T, \quad (15)$$

式中 $\mathbf{U}=[\mathbf{U}_1, \mathbf{U}_2, \dots, \mathbf{U}_K]$ 为 K 阶正交矩阵, 其中 $\mathbf{U}_i (i=1, 2, \dots, K)$ 为 K 维列向量; $\boldsymbol{\Lambda} = \text{diag}\{\lambda_1^2, \lambda_2^2, \dots, \lambda_K^2\}$ 为对角矩阵, 其中 $\lambda_i (i=1, 2, \dots, K)$ 为 \mathbf{X} 的特征值。

定义背景对总能量的贡献约束为

$$\eta = \frac{\sum_{i=1}^q \lambda_i^2}{\sum_{i=1}^K \lambda_i^2} \leq \eta_0, \quad (16)$$

式中 η_0 为约束阈值, 可根据经验设定。根据以上约束条件, 计算得到 $q = \text{argmax}\{\eta(q) \leq \eta_0\}$, 背景子空间 $\mathbf{B}=[\mathbf{U}_1, \mathbf{U}_2, \dots, \mathbf{U}_q]$ 。

综上所述, 超光谱成像污染气体的识别算法流程如图 1 所示。




图 1 污染气体的识别算法流程图

Fig. 1 Flow chart of classification algorithm for pollutant gases

3 实验与分析

3.1 实验仪器与数据

以氨气为目标气体进行了野外实验, 实验数据来自 OPAG 33 型 FTIR 扫描成像光谱仪。扫描成像光谱仪参数如表 1 所示, 实验中扫描总点数为

400(20×20), 光谱范围为 1250~750 cm⁻¹, 光谱分辨率为 4 cm⁻¹, 光谱维数为 216。

图 2 为野外实测的 20×20 的扫描区域, 背景包含多类物体, 有天空、土壤、草坪、石块、树木、吊塔和建筑物等。由于自然界大部分物质在长波红外波段的发射率很高, 可以当作黑体来处理。扫描区域按

照背景温度的不同大致可以分为三个区域:地面的背景辐射大致相当于 294 K 的黑体;地平线的背景辐射大致相当于 291 K 的黑体;天空的温度较低,大致相当于 287 K 的黑体。实测光谱除了背景辐射之外,还包含水汽、臭氧、二氧化碳等大气干扰物光谱。

表 1 OPAG 33 型扫描成像光谱仪参数

Table 1 Parameters of OPAG 33 scanning imaging spectrometer

Parameter	Value
Diameter of field of view /cm	18.6
Field of view for a pixel /mrad	7.5
Angular resolution in the horizontal direction /mrad	7.5
Angular resolution in the vertical direction /mrad	3.7
Total pixels	20×20
Spectral range /cm ⁻¹	1250~750
Spectral resolution /cm ⁻¹	4
Spectral dimension	216




图 2 扫描测量区域(网格表示扫描点)

Fig. 2 Scanning area (the grids are scanning points)

在野外实验中,氨水倒在距离扫描光谱仪 5 m 远的地面上,使其自由挥发。扫描光谱仪采用从上到下逐行扫描采集数据,采集到的数据像元点为 400(20×20),图 2 中网格表示扫描点。

3.2 实验结果

根据流程图 1,对采集到的数据立方体 \mathbf{X} 首先用 SVD 计算,得到的正交子向量 \mathbf{U} 如图 3 所示,按照特征值从大到小的次序显示了前 10 个子向量,从图中的光谱特征来看,前 5 个向量为背景及干扰物特征,第 6 个向量包含明显的氨气特征。

背景子空间根据(16)式计算,约束阈值 η_0 需要由经验确定。不失一般性,设定 $\eta_0 = 90\%$,实际的




图 3 计算得到的前 10 个正交子向量(对向量进行了平移以便于区分)

Fig. 3 First 10 quadrature subvectors by calculation (plots are translated for clarity)

选择可略微不同^[18]。计算的背景子空间向量个数 q 如图 4 所示,可以看出,前 3 个子向量对总能量的贡献接近 90%,由此得到 $q=3$,背景子空间 $\mathbf{B}=[\mathbf{U}_1, \mathbf{U}_2, \mathbf{U}_3]$ 。




图 4 前 q 个特征对总能量的贡献(阈值为 90%)

Fig. 4 Contribution of the first q eigen vectors to the total energy (the threshold is 90%)

氨气的光谱特征是已知的,分别计算得到 \mathbf{P}_B^\perp 和 \mathbf{P}_Z^\perp ,代入(12)、(13)式得到检测器 D_{ASD} ,然后对每个像元进行计算。这里 D_{ASD} 的计算结果与 SAM 算法的计算结果进行对比。SAM 是一种常用的目标识别算法,它的意义是计算提取的特征与目标光谱特征夹角的余弦值^[4]。设定 $\mathbf{y} = \mathbf{P}_B^\perp \mathbf{x}$,其意义为压缩背景和干扰物特征后的目标光谱特征,则 SAM 算法的表达式为

$$D_{SAM}(\mathbf{x}) = \frac{\mathbf{s}^T \mathbf{y}}{(\mathbf{s}^T \mathbf{s})^{1/2} (\mathbf{y}^T \mathbf{y})^{1/2}}, \quad (17)$$

式中 \mathbf{s} 为目标光谱特征。 D_{SAM} 大于设定的检测门限时,则判定为目标。根据 SAM 算法的定义, D_{SAM} 越接近于 1,判定为目标的可能性越大。

图 5 为分别采用 D_{ASD} 和 D_{SAM} 对图像所有像素

逐个识别的结果,图中的灰度颜色条代表了识别为氨气的可能性,像元颜色越接近白色,则越有可能判别为氨气。由图中可以看到,在氨气释放源位置的像元颜色最接近白色,这与图 2 中所示的氨气释放位置相符;同时从图 5(a)中可以看到,氨气源左边和右上位置有一些像元也存在氨气,这表明氨气在空气中随风向图像右方扩散。对比图 5 中(a)和(b)




图 5 图像的识别结果。(a) D_{ASD} 的输出结果; (b) D_{SAM} 的输出结果

Fig. 5 Image classification results. (a) Output of D_{ASD} ; (b) output of D_{SAM}

设定虚警率为 $P_{FA} = 5\%$,由于只存在氨气一种目标气体,可知 D_{ASD} 服从分子、分母自由度分别为 1 和 212 的 F 分布。根据(14)式得到检测门限 $\gamma_{ASD} = 1.0183$,图 5(a)的每个像元结果与 γ_{ASD} 比较,大于 γ_{ASD} 的认为是氨气,否则认为无目标存在。而 SAM 算法由于缺少自适应性,检测门限只能设定为一固定值。

4 结 论

研究了超光谱成像被动遥测污染气体的识别分类方法,并以氨气为目标气体进行了野外实验。在线性模型下,目标气体的识别分类问题转化为二值竞争假设问题,通过广义似然比构建子空间检测器对目标进行检测分类。通过约束背景对总能量贡献确定背景子空间向量个数,这是一种半经验性估计方法,但在实际应用中常能得到较好的结果。野外实测数据立方体来自扫描成像 FTIR 光谱仪。实验结果表明,子空间检测器能够识别氨气并得到其空间分布,相比 SAM 方法对目标具有更好的区分能力,且不需要训练分类器及其他先验信息,因而能够应用于污染气体的实时在线检测。

参 考 文 献

1 Vincent Farley, Alexandre Vallières, Martin Chamberland, *et al.*. Performance of the FIRST, a longwave infrared hyperspectral imaging sensor [C]. SPIE, 2006, 6398: 63980T.

的识别结果可以看到,图(b)中存在较多像元可能导致误判,而图(a)中误判的像元较少,这表明 D_{ASD} 对目标的区分结果优于 D_{SAM} 。同时从图中可以看到,污染气体在图像上空间连续性较差,这是由于在扫描测量过程中风速改变缘故,通过图像滤波可以改善气体在空间分布的连续性,减少虚警率。

2 Roland Harig, Peter Rusch, Chris Dyer, *et al.*. Remote measurement of highly toxic vapours by scanning imaging Fourier-transform spectrometry [C]. SPIE, 2005, 5995: 599510.

3 D Manolakis, L G Jairam, D Zhang, *et al.*. Statistical models for LWIR hyperspectral backgrounds and their applications in chemical agent detection [C]. SPIE, 2007, 6565: 656525.

4 Dimitris Manolakis, Gary Shaw. Detection algorithms for hyperspectral imaging applications [J]. IEEE Signal Processing Magazine, 2002, 19(1): 29–43.

5 Dimitris Manolakis, David Marden, Gary A Shaw. Hyperspectral image processing for automatic target detection applications [J]. Lincoln Laboratory Journal, 2003, 14(1): 79–116.

6 Tom Burr, Nicolas Hengartner. Overview of physical models and statistical approaches for weak gaseous plume detection using passive infrared hyperspectral imagery [J]. Sensors, 2006, 6(12): 1721–1750.

7 D Manolakis. Signal processing algorithms for hyperspectral remote sensing of chemical plumes [J]. IEEE Transactions Geoscience and Remote Sensing, 2008, 46: 1857–1860.

8 J C Harsanyi, Chein-I Chang. Hyperspectral image classification and dimensionality reduction: an orthogonal subspace projection approach [J]. IEEE Transactions Geoscience and Remote Sensing, 1994, 32(4): 779–785.

9 Chein-I Chang. Orthogonal subspace projection (OSP) revisited: a comprehensive study and analysis [J]. IEEE Transactions on Geoscience and Remote Sensing, 2005, 43(3): 502–518.

10 Cui Fangxiao, Fang Yonghua. Infrared background compression method based on brightness temperature spectrum [J]. Acta Optica Sinica, 2013, 33(11): 1130001.

崔方晓, 方勇华. 基于亮温光谱的红外背景压缩方法[J]. 光学学报, 2013, 33(11): 1130001.

11 M Kay Steven. Fundamentals of Statistical Signal Processing: Detection Theory [M]. New Jersey: Prentice Hall, 1998.

12 Shawn Kraut, Louis L Scharf, L Todd McWhorter. Adaptive subspace detectors [J]. IEEE Transactions on Signal Processing,

- 2001, 49(1): 1–16.
- 13 Dimitris Manolakis, Francis M D'Amico. A taxonomy of algorithms for chemical vapor detection with hyperspectral imaging spectroscopy [C]. SPIE, 2005, 5795: 125–133.
- 14 Shawn Kraut, Louis L Scharf. The CFAR adaptive subspace detector is a scale-invariant GLRT [J]. IEEE Transactions on Geoscience and Remote Sensing, 1999, 47(9): 2538–2541.
- 15 Chein-I Chang, Qian Du. Estimation of number of spectrally distinct signal sources in hyperspectral imagery [J]. IEEE Transactions on Geoscience and Remote Sensing, 2004, 42(3): 608–619.
- 16 N Acito, M Diani, G Corsini. Hyperspectral signal subspace identification in the presence of rare vectors and signal-dependent noise [J]. IEEE Transactions Geoscience and Remote Sensing, 2013, 51(1): 283–299.
- 17 C M Gittins. Detection and characterization of chemical vapor fugitive emissions by nonlinear optimal estimation; theory and simulation [J]. Appl Opt, 2009, 48(23): 4545–4561.
- 18 Xun Lina, Fang Yonghua, Li Xin. A small target detection approach based on endmember extraction in hyperspectral image [J]. Acta Optica Sinica, 2007, 27(7): 1178–1182.
- 寻丽娜, 方勇华, 李 新. 高光谱图像中基于端元提取的小目标检测算法[J]. 光学学报, 2007, 27(7): 1178–1182.
- 19 Alan Schaum. Methods of hyperspectral detection based on a single signature sample [J]. IEEE Sensors Journal, 2010, 10(3): 518–523.
- 20 Erin M O'Donnell, David W Messinger, Carl Salvaggio, *et al.*. Identification and detection of gaseous effluents from hyperspectral imagery using invariant algorithms [C]. SPIE, 2004, 5425: 573–582.
- 21 Joshua B Broadwater, Thomas S Spisz, Alison K Carr. Detection of gas plumes in cluttered environments using long-wave infrared hyperspectral sensors [J]. SPIE, 2008, 6954: 69540R.

栏目编辑: 王晓琰