

光谱角匹配加权核特征空间分离变换 高光谱异常检测算法

韩 静, 岳 江, 张 毅, 柏连发*, 陈 钱

(南京理工大学 江苏省光谱成像与智能感知重点实验室, 江苏 南京 210094)

摘要:提出了一种光谱角匹配(SAM)加权核特征空间分离变换(KEST)高光谱异常检测算法.在基于核的特征空间分离变换(KEST)算法基础上,利用光谱角匹配(SAM)测度对高维特征空间中检测点邻域差异相关矩阵(DCOR)中的每个样本引入权重因子,各样本权重因子取决于该样本光谱向量与检测窗口数据中心向量夹角,从而抑制检测窗口中的病态数据,突出主成分数据的贡献,使得 DCOR 矩阵能够更好地描述目标、背景数据分布差异.通过理论分析和对模拟、实际数据实验比较,证明该算法较传统异常检测算法和 KEST 算法具有更高的检测率.

关键词:高光谱;异常检测;光谱角匹配;特征空间分离变换;SAM 加权 KEST

中图分类号:TP751.1 文献标识码:A

SAM weighted KEST algorithm for anomaly detection in hyperspectral imagery

HAN Jing, YUE Jiang, ZHANG Yi, BAI Lian-Fa*, CHEN Qian

(Jiangsu Key Laboratory of Spectral Imaging and Intelligent Sense,

Nanjing University of Science and Technology, Nanjing 210094, China)

Abstract: A SAM weighted KEST algorithm based on kernel eigenspace separation transform (KEST) was proposed for anomaly detection in hyperspectral imaging. Weights are introduced for each sample in the difference correlation matrix (DCOR), and the input pixel neighbor surroundings. All samples were weighted according to the angle between the sample spectral vector and the centered vector in detection window to minimize the influence of anomalous data and outstand the contribution of principle component. In this way, DCOR represented the difference between target and background distribution much better. Experimental results indicate that the proposed method shows superior performance over the conventional anomaly detection algorithms and KEST.

Key words: hyperspectral imagery; anomaly detection; spectral angle mapper (SAM); kernel eigenspace separation transform (KEST); SAM weighted KEST (SKEST)

PACS: 07. 05. Pj

引言

在高光谱目标检测中,由于实际应用需求,近年来提出了许多无需目标先验光谱知识的异常检测算法.这些算法充分利用异常点与其邻域点的光谱特性不同,计算局部区域的统计特性以实现目标检测.

目前,常用的异常检测算法主要包括 RX 异常

检测法和子空间投影法(包括主成分分析(PCA)、特征空间分离变换(EST)等).Reed 等人提出了 RX 检测算法^[1],根据背景样本点的光谱向量均值和协方差矩阵,计算检测点光谱向量和背景样本的马氏距离,实现异常点检测;Kown 等人提出基于核的 RX 算法(KRX)^[2-4],该算法将高光谱数据映射到高维特征空间后,利用核函数的性质进行异常点的检测,

收稿日期:2012-02-27,修回日期:2012-10-29

基金项目:国家自然科学基金(61231014, 61071147);

Foundation items: Supported by National Natural Science Foundation of China (61231014, 61071147)

作者简介(Biography):韩静(1987-),女,江苏扬州人,博士生,主要研究领域为多光谱图像理解、目标探测等. E-mail: njusthanjing@163.com

* 通讯作者(Corresponding author): E-mail: mrblf@163.com

Received date: 2012-02-27, revised date: 2012-10-29

较好地利用了高光谱图像波段间的非线性统计特性. 在 PCA 方法研究基础上, Yanfeng G 等人引入核 PCA 算法 (KPCA) 进行异常检测^[5-7], 该算法在高维特征空间中计算样本数据协方差矩阵的特征向量, 并将检测点的光谱向量在较大特征值的主分量上进行投影分析, 实现异常点检测; S. Susan Young 等人将 EST 方法引入到红外目标检测中^[8-9], 该算法计算目标和背景的差异相关矩阵 (DCOR) 的特征向量, 并将检测点的光谱向量在选定的特征分量上进行投影分析, 实现异常检测; Goldberg H 等人在此基础上提出核 EST 算法 (KEST)^[10].

RX 算法要求数据服从高斯分布, 该条件对真实场景很难满足, 因此子空间投影法更加适应于真实应用情况. 而比较 PCA 算法, EST 法计算特征分量时兼顾了目标和背景的光谱差异, 对应的 KEST 法能够更有效的提取和利用数据的非线性特征. 但 KEST 法也存在一定的缺陷, 即若实际背景数据为病态分布、背景数据中异常目标点数目或目标数据中背景点数目较多时, DCOR 矩阵不能完全描述目标和背景数据的差异. 因此本文提出了一种光谱角匹配 (SAM) 加权 KEST 高光谱异常检测算法 (SK-EST).

1 EST 算法

采用双矩形窗作为局域检测窗口^[8,11]. 该方法以检测点为中心, 以两个内外嵌套的矩形, 将该检测点及其邻域分为内窗和外窗两个区域, 假设目标分布于内窗, 背景分布于外窗, 对内外窗中的光谱向量分别进行统计分析, 比较两者差异实现目标检测.

EST 算法以检测点为中心, 计算目标和背景数据的 DCOR 矩阵. 设高光谱数据波段数为 P , 定义 $P \times N_t$ 矩阵 $\mathbf{X} = [x_1, x_2 \cdots x_{N_t}]$ 表示目标数据, 样本 x_i 为 P 维光谱向量 $x_i = [x_{i1}, x_{i2} \cdots x_{ip}]^T, i = 1, 2, \dots, N_t$; $P \times N_b$ 矩阵 $\mathbf{Y} = [y_1, y_2 \cdots y_{N_b}]$ 表示背景数据, 样本 y_j 为 P 维光谱向量 $y_j = [y_{j1}, y_{j2} \cdots y_{jp}]^T, j = 1, 2, \dots, N_b$. DCOR 矩阵 \mathbf{C}_{dcor} 定义为目标和背景样本相关矩阵 $\mathbf{C}_X, \mathbf{C}_Y$ 的差值^[12]:

$$\begin{aligned} \mathbf{C}_{\text{dcor}} &= \mathbf{C}_X - \mathbf{C}_Y = \frac{1}{N_t} \sum_{i=1}^{N_t} \mathbf{x}_i \mathbf{x}_i^T - \frac{1}{N_b} \sum_{j=1}^{N_b} \mathbf{y}_j \mathbf{y}_j^T \\ &= \frac{1}{N_t} \mathbf{X} \mathbf{X}^T - \frac{1}{N_b} \mathbf{Y} \mathbf{Y}^T = \mathbf{V} \mathbf{\Lambda} \mathbf{V}^T \\ &= [\mathbf{V}_+, \mathbf{V}_-] \begin{bmatrix} \mathbf{\Lambda}_+ & 0 \\ 0 & \mathbf{\Lambda}_- \end{bmatrix} \begin{bmatrix} \mathbf{V}_+^T \\ \mathbf{V}_-^T \end{bmatrix}, \quad (1) \end{aligned}$$

其中 \mathbf{V} 为 \mathbf{C}_{dcor} 非零特征值 $\mathbf{\Lambda}$ 对应的特征向量, \mathbf{V}_+

为正特征值 $\mathbf{\Lambda}_+$ 对应的特征向量, \mathbf{V}_- 为负特征值 $\mathbf{\Lambda}_-$ 对应的特征向量.

计算 $(\mathbf{V}_+, \mathbf{r})$ 、 $(\mathbf{V}_-, \mathbf{r})$, \mathbf{r} 为检测点光谱向量, 即将检测点的光谱数据分别在正负特征向量上进行投影分析, 进行异常检测. 并建立二值假设: H_1 代表目标存在, H_0 代表目标不存在. $H_0: \mathbf{s} = \mathbf{n}; H_1: \mathbf{s} = \alpha \mathbf{x} + \mathbf{n}$, H_0 成立时 $\alpha = 0$, H_1 成立时 $\alpha > 0$, \mathbf{n} 表示背景噪声向量, \mathbf{x} 为目标光谱向量. η 为决策阈值, EST 算法判决表达式为:

$$(\mathbf{V}_+, \mathbf{r}) \text{ 或 } (\mathbf{V}_-, \mathbf{r}) \begin{cases} \geq \eta & H_1 \text{ 成立} \\ < \eta & H_0 \text{ 成立} \end{cases}$$

从文献[8]可见, EST 比 PCA 具有更好的降维和分类效果.

2 SAM 加权 KEST 算法 (SKEST)

虽然 EST 算法能够在一定程度上区分目标和背景, 但是没有很好地利用各光谱波段间的相关性, 因此采用 KEST 算法, 将线性空间光谱信号映射到高维特征空间中进行异常点检测, 可以挖掘各光谱波段间的非线性信息, 提取目标和背景的高维特征, 从而更好地区分目标和背景.

2.1 KEST 算法

利用非线性映射函数 ϕ 将 X, Y 映射到高维特征空间后, EST 算法表示为计算 \mathbf{C}_ϕ 的正负特征向量 $\mathbf{V}_{+\phi}, \mathbf{V}_{-\phi}$, 及在高维特征空间中检测点光谱向量 $\phi(\mathbf{r})$ 在 $\mathbf{V}_{+\phi}, \mathbf{V}_{-\phi}$ 上的投影 $(\mathbf{V}_{+\phi}, \phi(\mathbf{r}))$ 、 $(\mathbf{V}_{-\phi}, \phi(\mathbf{r}))$ ^[10].

$$\begin{aligned} \mathbf{C}_\phi &= \mathbf{C}_{X\phi} - \mathbf{C}_{Y\phi} = \frac{1}{N_t} \phi(\mathbf{X}) \phi(\mathbf{X})^T - \frac{1}{N_b} \phi(\mathbf{Y}) \phi(\mathbf{Y})^T \\ &= [\mathbf{V}_{+\phi}, \mathbf{V}_{-\phi}] \begin{bmatrix} \mathbf{\Lambda}_{+\phi} & 0 \\ 0 & \mathbf{\Lambda}_{-\phi} \end{bmatrix} \begin{bmatrix} \mathbf{V}_{+\phi}^T \\ \mathbf{V}_{-\phi}^T \end{bmatrix}. \quad (2) \end{aligned}$$

由式(2)可看出: 目标、背景相关矩阵 $\mathbf{C}_{X\phi}, \mathbf{C}_{Y\phi}$ 中各像素的权重相等, 但若背景数据为病态分布、背景数据中异常目标点数目或目标数据中背景点数目较多, $\mathbf{C}_{X\phi}, \mathbf{C}_{Y\phi}$ 就不能完全描述目标、背景数据的分布, 目标检测率低^[4].

图 1 是以两个真实目标为中心的双矩形窗放大图 (内窗 3×3 为真实异常目标, 外窗 11×11 为背景), 及其中各像素光谱向量与检测窗口 (内、外窗) 数据中心向量夹角 (SAM) 的三维图. 从图 1 可以看出, 在内外窗中心的像素 SAM 值较大 (红色), 而内外窗交界处像素的 SAM 值较小 (蓝色). 这主要是因为内窗中心均属目标像素、外窗中心均属背景像素, 它们的光谱向量与各自的检测窗口数据中心向

量相似,其 SAM 值就较大;而交界处存在目标像素在背景窗口(图 1(a)目标 1 图内窗左上角外侧)或背景像素在目标窗口(图 1(b)目标 2 图内窗右下角内侧)的情况,它们的光谱向量与各自的检测窗口数据中心向量不相似,其 SAM 值就较小.

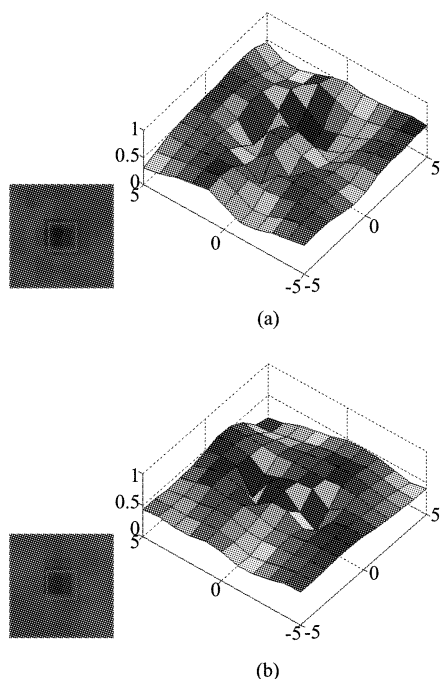


图 1 以真实目标为中心的双矩形窗图及其中各像素光谱向量与检测窗口数据中心向量夹角三维图

Fig. 1 The 3D map of vector angle between spectral vector and detecting window data center vector

所以高维特征空间检测点邻域的目标、背景相关矩阵 $C_{X\phi}$ 、 $C_{Y\phi}$ 中各像素均需引入权重因子,这样就能有效抑制或降低目标数据中的背景点或病态点对 $C_{X\phi}$ 的影响,以及背景数据中的目标点或病态点对 $C_{Y\phi}$ 的影响, $C_{X\phi}$ 、 $C_{Y\phi}$ 就能更准确地描述目标、背景数据的分布.

由此本文提出 SAM 加权 KEST 算法,该方法以 $C_{X\phi}$ 、 $C_{Y\phi}$ 中各像素光谱向量与数据中心向量的光谱角匹配(SAM)为准则^[13],对 $C_{X\phi}$ 、 $C_{Y\phi}$ 中各像素光谱向量引入对应的权重因子.若像素光谱向量与数据中心向量的夹角较小,表示两者光谱信息相似,则该像素获得较大权值,反之亦然,如此去除或降低 $C_{X\phi}$ 、 $C_{Y\phi}$ 中的异常数据.高维特征空间中 SAM 加权相关矩阵表达式为:

$$C_{\phi w} = \frac{1}{N_t} \sum_{i=1}^{N_t} w_{x_i} \phi(x_i) \phi(x_i)^T / \sum_{i=1}^{N_t} w_{x_i} - \frac{1}{N_b} \sum_{j=1}^{N_b} w_{y_j} \phi(y_j) \phi(y_j)^T / \sum_{j=1}^{N_b} w_{y_j}, \quad (3)$$

式中 $\{w_{x_1}, w_{x_2}, \dots, w_{x_{N_t}}; w_{y_1}, w_{y_2}, \dots, w_{y_{N_b}}\}$ 为各像素光谱向量权重因子:

$$w_{x_i} = \cos(\phi(x_i), \mu_X) = \frac{\phi^T(x_i) \mu_X}{\|\phi^T(x_i)\| \|\mu_X\|} = \frac{\frac{1}{N_t} \sum_{m=1}^{N_t} k(x_i, x_m)}{\sqrt{k(x_i, x_i)} \sqrt{\frac{1}{N_t^2} \sum_{m=1}^{N_t} \sum_{n=1}^{N_t} k(x_m, x_n)}} \\ w_{y_j} = \cos(\phi(y_j), \mu_Y) = \frac{\phi^T(y_j) \mu_Y}{\|\phi^T(y_j)\| \|\mu_Y\|} = \frac{\frac{1}{N_b} \sum_{m=1}^{N_b} k(y_j, y_m)}{\sqrt{k(y_j, y_j)} \sqrt{\frac{1}{N_b^2} \sum_{m=1}^{N_b} \sum_{n=1}^{N_b} k(y_m, y_n)}}, \quad (4)$$

$$i = 1, \dots, N_t, j = 1, \dots, N_b, \mu_X = \frac{1}{N_t} \sum_{m=1}^{N_t} \phi(x_m), \mu_Y = \frac{1}{N_b} \sum_{n=1}^{N_b} \phi(y_n), \text{其中利用了核函数性质: } k(x, y) = (\phi(x), \phi(y)) \text{ [14].}$$

SAM 加权 KEST 算法即计算高维特征空间中 $C_{\phi w}$ 的正、负特征向量 $V_{+\phi w}$ 、 $V_{-\phi w}$, 及检测点光谱向量 $\phi(r)$ 在 $V_{+\phi w}$ 、 $V_{-\phi w}$ 上的投影 ($V_{+\phi w}$ 、 $\phi(r)$)、($V_{-\phi w}$ 、 $\phi(r)$).

采用 SAM 函数能够表征光谱曲线的形状差异,再选用径向基核函数 $k(x, y) = \exp[-\|x - y\|^2 / 2\sigma^2]$ ^[14],能够表征信号的光谱能量差异,如此 SK-EST 算法既考虑了像元间光谱能量差异,也考虑了像元间光谱曲线形状差异,更全面地描述了高光谱数据特性.

2.2 SAM 加权 KEST 算法

定义 $\sum_{i=1}^{N_t} w_{x_i} = w_X$, $\sum_{j=1}^{N_b} w_{y_j} = w_Y$, 高维特征空间加权数据 $\{\phi_w(X) \phi_w(Y)\}$: $\phi_w(X) = [\phi_w(x_1) \phi_w(x_2) \dots \phi_w(x_{N_t})]$, $\{\phi_w(x_i) = \sqrt{w_{x_i}} \phi(x_i)\}_{i=1}^{N_t}$, $\phi_w(Y) = [\phi_w(y_1) \phi_w(y_2) \dots \phi_w(y_{N_b})]$, $\{\phi_w(y_j) = \sqrt{w_{y_j}} \phi(y_j)\}_{j=1}^{N_b}$, 由式(3)可推出:

$$C_{\phi w} = \frac{1}{N_t w_X} \sum_{i=1}^{N_t} \phi_w(x_i) \phi_w(x_i)^T - \frac{1}{N_b w_Y} \sum_{j=1}^{N_b} \phi_w(y_j) \phi_w(y_j)^T \\ = [\phi_w(X), \phi_w(Y)] \begin{bmatrix} \phi_w(X)^T / N_t w_X \\ \phi_w(Y)^T / N_b w_Y \end{bmatrix} = V_{\phi w} \Lambda_{\phi w} V_{\phi w}^T \\ = [V_{+\phi w}, V_{-\phi w}] \begin{bmatrix} \Lambda_{+\phi w} & 0 \\ 0 & \Lambda_{-\phi w} \end{bmatrix} \begin{bmatrix} V_{+\phi w}^T \\ V_{-\phi w}^T \end{bmatrix}, \quad (5)$$

其中, Λ_{ϕ_w} 为高维特征空间加权相关矩阵 \mathbf{C}_{ϕ_w} 的所有非零特征值, 及其对应的特征向量 \mathbf{V}_{ϕ_w} , $\Lambda_{+\phi_w} = \text{diag}([\lambda_{1w}, \lambda_{2w} \cdots \lambda_{N_+w}])$, $\Lambda_{-\phi_w} = \text{diag}([\lambda'_{1w}, \lambda'_{2w} \cdots \lambda'_{N_-w}])$ 为 \mathbf{C}_{ϕ_w} 的 N_+ 、 N_- 个非零特征值构成的对角矩阵, $\mathbf{V}_{+\phi_w}$ 、 $\mathbf{V}_{-\phi_w}$ 分别为正、负特征值对应的特征向量。

由(5)式可知, 每个特征向量 $\mathbf{V}_{\phi_w}^k$ 都在 $\{\phi_w(\mathbf{X})\}$ 的度量空间内, 因此 $\mathbf{V}_{\phi_w}^k$ 可以表示成 $\{\phi_w(\mathbf{X})\}$ 的线性组合^[15]:

$$\begin{aligned} \mathbf{V}_{\phi_w}^k &= \frac{1}{\sqrt{w_X N_t}} \sum_{i=1}^{N_t} \alpha_i^k \phi_w(\mathbf{x}_i) \lambda_i^{\frac{1}{2}} - \frac{1}{\sqrt{w_Y N_b}} \sum_{j=1}^{N_b} \beta_j^k \phi_w(\mathbf{y}_j) \lambda_j^{\frac{1}{2}} \\ &= \frac{1}{\sqrt{w_X N_t}} \phi_w(\mathbf{X}) \boldsymbol{\alpha}^k \Lambda_{+\phi_w}^{-\frac{1}{2}} - \frac{1}{\sqrt{w_Y N_b}} \phi_w(\mathbf{Y}) \boldsymbol{\beta}^k \Lambda_{-\phi_w}^{-\frac{1}{2}}, \quad (6) \end{aligned}$$

其中 $k=1, 2, \dots, N$, $N=N_t+N_b$, 系数 $\boldsymbol{\alpha}^k = [\alpha_1^k, \alpha_2^k \cdots \alpha_{N_t}^k]^T$, $\boldsymbol{\beta}^k = [\beta_1^k, \beta_2^k \cdots \beta_{N_b}^k]^T$. 因此高维特征空间加权特征向量 \mathbf{V}_{ϕ_w} 可表示为:

$$\begin{aligned} \mathbf{V}_{\phi_w} &= [\mathbf{V}_{\phi_w}^1 \mathbf{V}_{\phi_w}^2 \cdots \mathbf{V}_{\phi_w}^N] \\ &= \phi_w(\mathbf{X}) \mathbf{A}_w \Lambda_{+\phi_w}^{-\frac{1}{2}} - \phi_w(\mathbf{Y}) \mathbf{B}_w \Lambda_{-\phi_w}^{-\frac{1}{2}} \\ &= [\phi_w(\mathbf{X}), -\phi_w(\mathbf{Y})] \begin{bmatrix} \mathbf{A}_w & \mathbf{0} \\ \mathbf{0} & \Lambda_{-\phi_w}^{-\frac{1}{2}} \end{bmatrix} \\ &= [\phi_w(\mathbf{X}), -\phi_w(\mathbf{Y})] \mathbf{D}_w, \quad (7) \end{aligned}$$

$$\text{其中, } \mathbf{A}_w = \begin{bmatrix} \frac{\alpha^1}{\sqrt{w_X N_t}} & \frac{\alpha^2}{\sqrt{w_X N_t}} & \cdots & \frac{\alpha^N}{\sqrt{w_X N_t}} \end{bmatrix},$$

$$\mathbf{B}_w = \begin{bmatrix} \frac{\beta^1}{\sqrt{w_Y N_b}} & \frac{\beta^2}{\sqrt{w_Y N_b}} & \cdots & \frac{\beta^N}{\sqrt{w_Y N_b}} \end{bmatrix},$$

$$\begin{aligned} \mathbf{D}_w &= \begin{bmatrix} \mathbf{A}_w & \mathbf{0} \\ \mathbf{0} & \Lambda_{-\phi_w}^{-\frac{1}{2}} \end{bmatrix} \\ &= \begin{bmatrix} \frac{\alpha^1}{\sqrt{w_X N_t}} & \frac{\alpha^2}{\sqrt{w_X N_t}} & \cdots & \frac{\alpha^N}{\sqrt{w_X N_t}} \\ \frac{\beta^1}{\sqrt{w_Y N_b}} & \frac{\beta^2}{\sqrt{w_Y N_b}} & \cdots & \frac{\beta^N}{\sqrt{w_Y N_b}} \end{bmatrix} \Lambda_{\phi_w}^{-\frac{1}{2}} \end{aligned}$$

将式(7)和式(5)代入 $\mathbf{V}_{\phi_w} = \mathbf{C}_{\phi_w}$ 可得:

$$\begin{aligned} &[\phi_w(\mathbf{X}), \phi_w(\mathbf{Y})] \mathbf{D}_w \Lambda_{\phi_w} \\ &= [\phi_w(\mathbf{X}), \phi_w(\mathbf{Y})] \begin{bmatrix} \phi_w(\mathbf{X})^T / N_t w_X \\ \phi_w(\mathbf{Y})^T / N_b w_Y \end{bmatrix} \\ &= [\phi_w(\mathbf{X}), \phi_w(\mathbf{Y})] \mathbf{D}_w. \quad (8) \end{aligned}$$

利用核函数性质将(8)式简化为:

$$\begin{aligned} &[\phi_w(\mathbf{X}), -\phi_w(\mathbf{Y})] \mathbf{D}_w \Lambda_{\phi_w} = [\phi_w(\mathbf{X}), -\phi_w(\mathbf{Y})] \\ &\begin{bmatrix} \frac{k_{wXX}}{N_t w_X} & -\frac{k_{wXY}}{N_t w_X} \\ \frac{k_{wYX}}{N_b w_Y} & -\frac{k_{wYY}}{N_b w_Y} \end{bmatrix} \mathbf{D}_w, \quad (9) \end{aligned}$$

$$\begin{aligned} \text{其中, } k_{wXX} &= \phi_w(\mathbf{X})^T \phi_w(\mathbf{X}) = [\sqrt{w_{x_1}} \phi(\mathbf{x}_1), \dots, \\ &\sqrt{w_{x_{N_t}}} \phi(\mathbf{x}_{N_t})]^T [\sqrt{w_{x_1}} \phi(\mathbf{x}_1), \dots, \sqrt{w_{x_{N_t}}} \phi(\mathbf{x}_{N_t})] \\ &= [\sqrt{w_{x_i} w_{x_j}} \phi^T(\mathbf{x}_i) \phi(\mathbf{x}_j)] = [\sqrt{w_{x_i} w_{x_j}} k(\mathbf{x}_i, \\ &\mathbf{x}_j)]_{N_t \times N_t} \quad i, j=1, \dots, N_t \end{aligned}$$

$$\text{同理 } k_{wYY} = [\sqrt{w_{y_i} w_{y_j}} k(\mathbf{y}_i, \mathbf{y}_j)]_{N_b \times N_b} \quad i, j=1, \dots, N_b,$$

$$k_{wXY} = [\sqrt{w_{x_i} w_{y_j}} k(\mathbf{x}_i, \mathbf{y}_j)]_{N_t \times N_b} \quad i=1, \dots, N_t; j=1, \dots, N_b,$$

$$k_{wYX} = [\sqrt{w_{y_j} w_{x_i}} k(\mathbf{y}_j, \mathbf{x}_i)]_{N_b \times N_t} \quad j=1, \dots, N_b; i=1, \dots, N_t.$$

将式(9)两边左乘 $\begin{bmatrix} \phi_w(\mathbf{X})^T / N_t w_X \\ \phi_w(\mathbf{Y})^T / N_b w_Y \end{bmatrix}$ 可得

$k_{wEST} \mathbf{D}_w \Lambda_{\phi_w} = k_{wEST}^2 \mathbf{D}_w$, 即 $\mathbf{D}_w \Lambda_{\phi_w} = k_{wEST} \mathbf{D}_w$, 则 \mathbf{D}_w 为 k_{wEST} 的特征向量, 且 k_{wEST} 与 \mathbf{C}_{ϕ_w} 具有相同特征值 Λ_{ϕ_w} .

$$k_{wEST} = \begin{bmatrix} \frac{k_{wXX}}{N_t w_X} & -\frac{k_{wXY}}{N_t w_X} \\ \frac{k_{wYX}}{N_b w_Y} & -\frac{k_{wYY}}{N_b w_Y} \end{bmatrix} = \mathbf{D}_w \Lambda_{\phi_w} \mathbf{D}_w^T. \quad (10)$$

由式(7)可得, 检测点光谱向量 $\phi(\mathbf{r})$ 在高维特征空间加权特征向量 \mathbf{V}_{ϕ_w} 上的投影为:

$$\begin{aligned} \langle \mathbf{V}_{\phi_w}, \phi(\mathbf{r}) \rangle &= \mathbf{D}_w^T [\phi_w(\mathbf{X}), -\phi_w(\mathbf{Y})]^T \phi(\mathbf{r}) \\ &= \mathbf{D}_w^T [\sqrt{w_{x_1}} \phi(\mathbf{x}_1), \dots, \sqrt{w_{x_{N_t}}} \phi(\mathbf{x}_{N_t}), \\ &\quad -\sqrt{w_{y_1}} \phi(\mathbf{y}_1), \dots, -\sqrt{w_{y_{N_b}}} \phi(\mathbf{y}_{N_b})]^T \phi(\mathbf{r}) \\ &= \mathbf{D}_w^T [\sqrt{w_{x_1}} k(\mathbf{x}_1, \mathbf{r}), \dots, \sqrt{w_{x_{N_t}}} k(\mathbf{x}_{N_t}, \mathbf{r}), \\ &\quad -\sqrt{w_{y_1}} k(\mathbf{y}_1, \mathbf{r}), \dots, -\sqrt{w_{y_{N_b}}} k(\mathbf{y}_{N_b}, \mathbf{r})]^T \\ &= \mathbf{D}_w^T k_w(\mathbf{Z}, \mathbf{r}) \quad \mathbf{Z} = \mathbf{X} \cup \mathbf{Y} \quad (11) \end{aligned}$$

因此选择合适的核函数 k 构造正定的核矩阵 k_{wEST} , 计算其特征向量 \mathbf{D}_w , 即可得出高维特征空间中检测点光谱向量 $\phi(\mathbf{r})$ 在加权特征向量 \mathbf{V}_{ϕ_w} 上的投影 $\langle \mathbf{V}_{\phi_w}, \phi(\mathbf{R}) \rangle$, 实现异常检测。

3 实验与结果分析

分别针对模拟数据和真实高光谱图像数据, 测试比较了 RX、PCA、EST、KRX、KPCA、KEST、SKEST 这 7 种算法. 通过多次实验对所有算法均选用径向基核函数, 且实验中 $2\sigma^2$ 取 40.

对所有检测点, 计算其在双矩形窗邻域内的统计特性, 特征空间投影等式^[10]为:

$$\delta = (\mathbf{r} - \boldsymbol{\mu}_{\text{out}})^T \mathbf{v} \mathbf{v}^T (\mathbf{r} - \boldsymbol{\mu}_{\text{out}}), \quad (12)$$

式中 \mathbf{r} 为检测点光谱向量, $\boldsymbol{\mu}_{\text{out}}$ 为外窗样本的均值向量, \mathbf{v} 为采用不同算法 (PCA、EST、RX 除外) 选定的特征向量。

对 KPCA、KEST、SKEST 算法高维特征空间投影等式^[10]为:

$$\delta^k = (k(\mathbf{Z}, \mathbf{r}) - k(\mathbf{Z}, \boldsymbol{\mu}_{\text{out}}))^T \mathbf{w} \mathbf{w}^T (k(\mathbf{Z}, \mathbf{r}) - k(\mathbf{Z}, \boldsymbol{\mu}_{\text{out}})) \quad (13)$$

式中 $k(\mathbf{Z}, \mathbf{r}) = (k(x_1, \mathbf{r}), \dots, k(x_{N_t}, \mathbf{r}), -k(y_1, \mathbf{r}), \dots, -k(y_{N_b}, \mathbf{r}))^T$, $k(\mathbf{Z}, \boldsymbol{\mu}_{\text{out}}) = \sum_{j=1}^{N_b} k(\mathbf{Z}, y_j) / N_b$, \mathbf{w} 为采用不同算法 (KPCA、KEST、SKEST、KRX 除外) 选定的核矩阵的特征向量. 其中 SKEST 算法采用式 (10) 计算 \mathbf{w} , 并且以 $k_w(\mathbf{Z}, \mathbf{r})$ 、 $k_w(\mathbf{Z}, \boldsymbol{\mu}_{\text{out}})$ 代替式 (13) 中 $k(\mathbf{Z}, \mathbf{r})$ 、 $k(\mathbf{Z}, \boldsymbol{\mu}_{\text{out}})$.

两个高斯分布数据下 7 种算法给出的等高线图见图 2 (表示不同阈值下的分类情况). 双矩形窗结构中设置背景检测窗口大小 11×11 , 目标检测窗口 5×5 . 比较 (b) ~ (k) 可以看出, 线性空间变换 (RX、PCA、EST) 只能产生线性决策边界, 无法区分非线性数据; 高维空间变换 (KRX、KPCA、KEST) 虽然能够产生非线性决策边界, 但是仍无法分类出两个高斯数据; SKEST 方法可以有效的将两类高斯数据完全区分开.

还对真实 AVIRIS (Airborne Visible Infrared Imaging Spectrometer) 传感器获取的美国加州圣地亚哥市海军飞机场的高光谱数据进行了实验, 图 3 为 AVIRIS 圣地亚哥机场高光谱数据场景图, 从中选取两组场景进行仿真 (下图线框). 该高光谱影像作用距离 20 km, 成像波段 370 ~ 2500 nm, 带宽 10 nm, 含 224 个谱段, 去掉受噪声和水汽吸收较明显的谱段, 选取了 130 个波段. 仿真环境: Matlab, CPU 2.41 GHz、内存 2 G. 本文算法针对小目标异常检测, 不限定目标类型, 本文检测的目标视场占 30 个像素以内.

两个场景第 1 波段图像及目标分布图 4 (a₁)、(b₁), (a₂)、(b₂) 所示. 双矩形窗结构中设置背景检测窗口大小 11×11 , 目标检测窗口 3×3 . (c₁) (d₁)、(c₂) (d₂) 为 RX (决策阈值 2×10^5)、KRX (决策阈值 0.8) 算法检测结果, (e₁) (f₁)、(e₂) (f₂) 为 PCA (决策阈值 1.5×10^6)、KPCA (决策阈值 4.0) 算法取前 6 个最大特征向量的检测结果, (g₁) (h₁) (i₁)、(g₂) (h₂) (i₂) 为 EST (决策阈值 1.5×10^5)、KEST (决策阈值 0.3)、SKEST (决策阈值 2.5) 算法取前 4 个最大正特征向量的检测结果.

两个场景采用 7 种算法的接收操作特性 (ROC) 曲线的比较见图 5. ROC 描述检测概率 P_d 与虚警概率 F_r 之间的变化关系, 能够提供算法检测性能的定量分析. 检测概率 P_d 为检测到的真实目标像素数目 N_{det} 与地面真实目标像素数目 N_{target} 的比值;





图 2 各算法对高斯数据的分类等高线 (a) 二维混合高斯数据, (b) RX, (c) KRX, (d) PCA, (e) KPCA, (f) EST+, (g) EST-, (h) KEST+, (i) KEST-, (j) SKEST+, (k) SKEST-

Fig. 2 Contour and surface plots of results on points in different algorithms (a) Two-dimensional nonlinearly mapped toy data set, (b) RX, (c) KRX, (d) PCA, (e) KPCA, (f) EST+, (g) EST-, (h) KEST+, (i) KEST-, (j) SKEST+, (k) SKEST-




图3 AVIRIS 圣地亚哥机场高光谱数据的场景图
Fig. 3 Scene picture of the San Diego airport hyperspectral data

虚警概率 F_r 为检测到的虚警像素数目 N_{false} 与整幅图像像素数目总和 N_{total} 的比值.

$$P_d = \frac{N_{det}}{N_{target}} \quad F_r = \frac{N_{false}}{N_{total}} \quad (14)$$

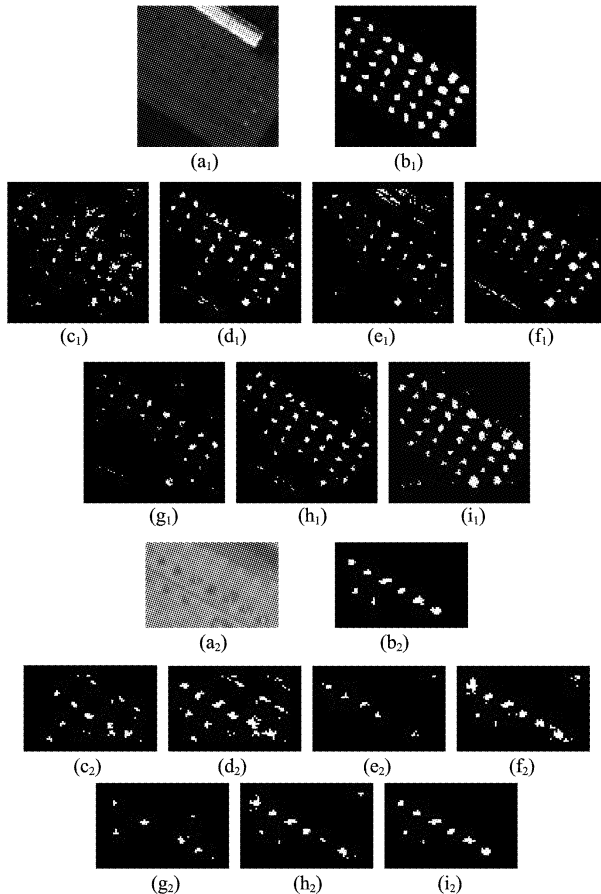


图4 不同方法下的 AVIRIS 影像异常检测阈值分割结果图
Fig. 4 Thresholding of anomaly detection results for AVIRIS image using different algorithms: (a) first band of AVIRIS image, (b) distribution of targets, (c) RX, (d) KRX, (e) PCA, (f) KPCA, (g) EST, (h) KEST, (i) SKEST

从图 4 (c) ~ (i) 和图 5 可以看出, 高维空间变换 (KRX、KPCA、KEST) 比其对应的线性空间变换 (RX、PCA、EST) 具有更高的检测率, 但是仍无法检测出所有目标, 且虚警率高; SKEST 方法由于有效抑制目标、背景窗口中的病态数据, 突出主成分数据的贡献, 明显提高了检测率, 且可以更有效地区分目标和背景, 降低虚警率.

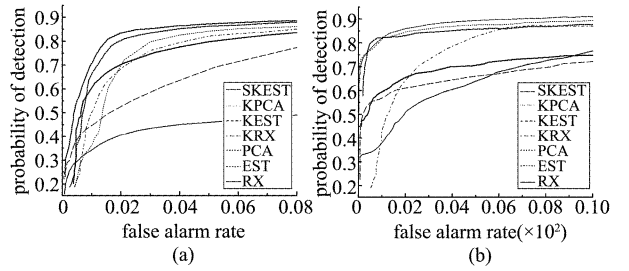


图5 ROC 曲线 (a) 场景 1, (b) 场景 2
Fig. 5 ROC curves for AVIRIS image: (a) Scene 1, (b) Scene 2


4 结论

提出了一种 SAM 加权 KEST 高光谱异常检测算法, 并推导其计算过程, 实现高维特征空间加权运算到低维输入空间核函数计算的转化. 通过理论分析说明高维特征空间检测点邻域的目标、背景相关矩阵中各像素引入权重因子的必要性, 使得 SKEST 算法较 EST、KEST 方法能够更好表针目标、背景差异; 同时由于结合 SAM 测度加权和径向基核函数, 使得 SKEST 算法既考虑了像元间光谱能量差异, 也考虑了其光谱曲线形状差异, 更全面地描述了高光谱数据特性. 通过模拟、实际数据实验比较, 证明 SKEST 算法比常用的线性 (PCA、EST、RX)、非线性 (KRX、KPCA、KEST) 异常检测方法能够更完全地检测出异常目标, 同时在相同虚警率情况下具有更高检测率, 以及在相同检测率情况下具有更低虚警率. 今后的工作将致力于多种数据下的 SKEST 方法测试, 论证其实用性、进一步提高其检测率.

REFERENCES

[1] Reed I S, Yu X. Adaptive multiple-band CFAR detection of an optical pattern with unknown spectral distribution [J]. *IEEE Trans. Acoust., Speech, Signal Process.*, 1990, **38** (10): 1760 - 1770.
[2] 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.

- [3] LI Jie, ZHAO Chun-Hui, MEI Feng. Detection hyperspectral anomaly by using background residual error data [J]. *Journal Infrared Millimeter Waves* (李杰, 赵春晖, 梅峰. 利用背景残差数据检测高光谱图像异常. *红外与毫米波学报*), 2010, **29**(2): 150 - 155.
- [4] ZHAO Chun-Hui, LI Jie, MEI Feng. A kernel weighted RX algorithm for anomaly detection in hyperspectral imagery [J]. *Journal Infrared Millimeter Waves* (赵春晖, 李杰, 梅峰. 核加权 RX 高光谱图像异常检测算法. *红外与毫米波学报*), 2010, **29**(5): 378 - 382.
- [5] Shawe-Taylor J, Cristianini N. *Kernel methods for pattern analysis* [M]. Cambridge: Cambridge University Press, 2004: 112 - 287.
- [6] Kwon H, Nasrabadi N M. Kernel spectral matched filter for hyperspectral imagery [J]. *International Journal of Computer Vision*, 2007, **71**(2): 127 - 141.
- [7] Gu Y F, Liu Y, Zhang Y. A selective KPCA algorithm based on high-order statistics for anomaly detection in hyperspectral imagery [J]. *IEEE Geoscience and Remote Sensing Letters*, 2008, **5**(1): 43-47.
- [8] Kwon H, Der S Z, Nasrabadi N M. Adaptive anomaly detection using subspace separation for hyperspectral imagery [J]. *Optical Engineering*, 2003, **42**(11): 3342 - 3351.
- [9] Young S S, Kwon H, Der S Z, et al. Adaptive target detection in forward-looking infrared imagery using the eigenspace separation transform and principal component analysis [J]. *Optical Engineering*, 2004, **43**(8): 1767 - 1776.
- [10] Goldberg H, Kwon H, Nasrabadi N M. Kernel eigenspace separation transform for subspace anomaly detection in hyperspectral imagery [J]. *IEEE Geoscience and Remote Sensing Letters*, 2007, **4**(4): 581 - 585.
- [11] Ranney K I, Soumekh M. Hyperspectral anomaly detection within the signal subspace [J]. *IEEE Geoscience and Remote Sensing Letter*, 2006, **3**(3): 312 - 316.
- [12] Goldberg H R. A performance characterization of kernel-based algorithms for anomaly detection in hyperspectral imagery [D]. Washington: University of Maryland, 2007.
- [13] LI Qing-Bo, LI Xiang, ZHANG Guang-Jun. A hyperspectral small target detection method based on outlier detection [J]. *Spectroscopy and Spectral Analysis* (李庆波, 李响, 张广军. 一种基于光谱奇异值检测的高光谱遥感小目标探测方法. *光谱学与光谱分析*), 2008, **28**(8): 1832 - 1836.
- [14] Kwon H, Nasrabadi N M. Kernel matched subspace detectors for hyperspectral target detection [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2006, **28**(2): 178 - 194.
- [15] Strang G. *Linear algebra and its applications* [M]. New York: Academic Press, 1988: 63 - 131.



(上接 356 页)

- negative weights [J]. *Systems Engineering Theory Methodology Applications* (唐小我, 曾勇, 曹长修. 非负权重最优组合预测的迭代算法研究. *系统工程理论方法应用*), 1994, **3**(4): 48 - 52.
- [25] Horler D N H, Dockray M, Barber J. The red edge of plant leaf reflectance [J]. *Int J Remote Sens*, 1983, **4**: 273 - 288.
- [26] Miller J R, Hare E W, Wu J. Quantitative characterization of the vegetation red edge reflectance model [J]. *Int J Remote Sens*, 1990, **11**: 1755 - 1773.
- [27] TANG Xiao-Wo. Study of combination forecasting error information matrix [J]. *Journal of UEST of China* (唐小我. 组合预测误差信息矩阵研究. *电子科技大学学报*), 1992, **21**(4): 448 - 454.
- [28] Botha E J, Zebarth B J, Leblon, B. Non-destructive estimation of potato leaf chlorophyll and protein contents from hyperspectral measurements using the PROSPECT radiative transfer model [J]. *Can J Plant Sci*, 2006, **86**: 279 - 291.
- [29] Haboudane D, Miller J R, Pattey E, et al. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture [J]. *Remote Sens Environ*, 2004, **90**: 337 - 352.
- [30] CHEN Peng-Fei, SUN Jiu-Lin, WANG Ji-Hua, et al. Using remote sensing technology for crop nitrogen diagnosis: status and trends [J]. *Scientia Sinica Informationis* (陈鹏飞, 孙九林, 王纪华, 等. 基于遥感的作物氮素营养诊断技术: 现状与趋势. *中国科学: 信息科学*), 2010, **40** (增刊): 21 - 37.
- [31] PAN Rui-Chi. *Plant physiology (5th edition)* [M]. Beijing: Higher Education Press (潘瑞炽. *植物生理学* (第五版). 北京: 高等教育出版社), 2004: 64.
- [32] Reyniers M, Walvoort D J J, De Baardemaaker J. A linear model to predict with a multi-spectral radiometer the amount of nitrogen in winter wheat [J]. *Int J Remote Sens*, 2006, **27**: 4159 - 4179.