

# 基于新型光谱相似度量核的高光谱异常检测算法\*

梅锋, 赵春晖, 孙岩, 王立国

(哈尔滨工程大学 信息与通信工程学院, 哈尔滨 150001)

**摘要:**提出一种新型光谱相似度量核函数,并应用于高光谱异常检测.由于高斯径向基核函数是基于光谱向量间欧式距离的度量,其对于光谱向量间距离变化的适应性较强,而对于因光照强度变化,阴影和遮挡等引起的同种地物光谱变化的适应性较弱,使得基于高斯径向基核的高光谱异常检测算法性能下降.为解决该问题,从光谱曲线形状描述出发,基于光谱相似度量提出了光谱相似度量核函数.通过理论分析和真实高光谱数据异常检测实验检验,实验结果说明相对于高斯径向基核函数,光谱相似度量核函数具有一定的优越性,能改善基于核方法的高光谱异常检测算法的性能.

**关键词:**高光谱;异常检测;光谱相似度量;核方法;RX

中图分类号:TP751.1

文献标识码:A

文章编号:1004-4213(2009)12-3165-6

## 0 引言

利用高光谱图像进行目标检测与识别是遥感图像处理领域的研究热点之一.传统的目标检测算法一般是在假设数据服从某种统计或几何模型的基础上构造检测算子,并根据先验信息估计算子中的统计参量,如光谱匹配算法<sup>[1]</sup>、正交子空间投影算法<sup>[2]</sup>等.然而,在实际应用中,由于缺少完备的光谱数据库和准确的反射率反演算法使得目标的先验光谱信息的获得变得非常困难,因此,不需目标先验信息的异常检测算法更符合实际需求,逐渐成为了研究的热点<sup>[3-7]</sup>.其中比较典型的就有 Reed 和 Yu 提出的 RX 方法<sup>[3]</sup>,该算法建立在多元正态分布基础上,通过计算检查点数据与背景数据的马氏距离来查找异常点.实际中地物分布是复杂多变的,这使得高光谱数据的多元正态分布很难满足;同时由于只利用了高光谱数据的低阶统计特性,而忽视了高光谱数据几百个波段中所含有的丰富的非线性信息,影响了 RX 算法的最终检测效果.

近年来,一些学者通过将线性异常检测算法与核机器学习理论结合,形成了许多基于核的异常检测算法.包括核 RX 算法<sup>[4]</sup>,核主成分分析算法,核 Fisher 分离算法,核特征空间分离算法等<sup>[5]</sup>.这些算法通过引入核方法,将原始高光谱数据映射到高维特征空间后进行异常点的检测,挖掘了高光谱图像波段间的非线性统计特性,提高了检测性能,取得了

较好的效果.在这些基于核方法的异常检测算法中,核函数的选取是一个关键的因素.而高斯径向基核函数(Radial Basis Function, RBF)是大多数算法所采用的核函数<sup>[4-5]</sup>,由于高斯径向基核函数是基于光谱向量间欧式距离的度量,其对于光谱向量间距的变化比较敏感,而对于由于光谱曲线的细微变化的区分能力不强,而且对于由光照强度变化,阴影等引起的同种地面覆盖物质光谱向量间距增大的情况容易引起误判.本文提出基于光谱相似度量的核函数,并将其应用于高光谱异常检测算法.通过理论推导和试验验证,结果说明光谱相似度量核函数具有很好的光谱曲线非线性分辨能力,能有效的改善高光谱异常检测的性能.

## 1 光谱相似度量核函数

核函数是支撑向量机(Support Vector Machine, SVM)在解决原始样本空间中线性不可分问题时引入的一种非线性变换<sup>[8]</sup>.而核函数的非线性特性使得其广泛应用于非线性分类,检测,识别等领域.核函数及核方法的研究是 SVM 以及其他非线性统计学习理论与方法研究中极为重要的一个分支.

在已知的核函数中,应用最为广泛的(尤其是在高光谱异常检测领域)是高斯径向基核函数,其表达式为

$$k_r(\mathbf{x}, \mathbf{y}) = \exp\left(\frac{-\|\mathbf{x} - \mathbf{y}\|^2}{c}\right) \quad (1)$$

式中,参量  $c$  为径向基核函数的宽度.由于 RBF 核是平移不变核,只依赖于向量  $\mathbf{x}$  和  $\mathbf{y}$  之间的变化量  $\mathbf{x} - \mathbf{y}$ ,而与各光谱向量的绝对位置无关<sup>[9]</sup>,因而很适合应用在在高光谱异常检测上.

高斯径向基核基于两光谱向量的欧氏距离,对

\*国家自然科学基金(60802059)、高等学校博士学科点基金(20060217021)和黑龙江省自然科学基金重点基金(ZJG0606-01)资助

Tel:0451-82569810

Email:meifeng12@163.com

收稿日期:2009-02-23

修回日期:2009-04-13

于具有  $J$  个波段的两光谱向量  $\mathbf{x}, \mathbf{y}$  来说,其间距可以表示为

$$d = \mathbf{x} - \mathbf{y} = \sqrt{\sum_{i=1}^J (x_i - y_i)^2} \quad (2)$$

因此高斯径向基核对于光谱向量间距的变化十分敏感,但对于由于光照强度变化、阴影、遮挡等原因引起的同种地物光谱间距的变化,高斯径向基核则会增大误判。

光谱相似度量方法对于光谱形状相似性的描述使得其广泛应用于高光谱地物分类,光谱解混等<sup>[10-11]</sup>,但由于其线性特性使得分辨能力不理想,本文采用光谱相似度量构造新型核函数,并将之应用到高光谱异常检测中。

互相关系数被广泛用来描述两个向量之间的相似程度.光谱向量  $\mathbf{x}, \mathbf{y}$  的互相关系数其表示为

$$\rho = \frac{(\mathbf{x} - \mu_x)^T (\mathbf{y} - \mu_y)}{[(\mathbf{x} - \mu_x)^T (\mathbf{x} - \mu_x) (\mathbf{y} - \mu_y)^T (\mathbf{y} - \mu_y)]^{1/2}} \quad (3)$$

式中  $\mu_x, \mu_y$  分别为光谱向量  $\mathbf{x}, \mathbf{y}$  的平均值.  $\rho \in [-1, 1]$ ,  $\rho$  越接近 1 则两光谱向量的线性相关度越高,也可以说两光谱向量的形状越相似。

利用互相关系数,定义光谱相似核  $k_s$  为

$$k_s = \begin{cases} \exp\left(\frac{-\cot\left[\frac{\pi(\rho+1)}{4}\right]}{\theta}\right) & \rho \in (-1, 1] \\ 0 & \rho = -1 \end{cases} \quad (4)$$

式中  $\cot$  为三角余切函数,  $\theta$  定义为光谱相似度量核的相似临界因子. 证明式(4)是一个核函数. Gram 矩阵和半正定矩阵的定义是一个函数作为核函数的充分必要条件<sup>[12]</sup>.

定义 1 给定一个函数  $k: X^2 \rightarrow K (K = R \text{ 或 } C, R \text{ 为实数集}, C \text{ 为复数集})$ , 以及样本  $\mathbf{x}_1, \dots, \mathbf{x}_m \in X$ , 那么,大小为  $m \times m$  的矩阵  $\mathbf{K}$

$$\mathbf{K}_{i,j} := k(\mathbf{x}_i, \mathbf{x}_j)$$

称为函数  $k$  关于  $\mathbf{x}_1, \dots, \mathbf{x}_m$  的 Gram 矩阵。

定义 2 对于  $m \times m$  的复矩阵  $\mathbf{K}$ , 若对于任意  $c_i \in C$  都有  $\sum_{i,j} c_i c_j \mathbf{K} \geq 0$  成立, 则称该矩阵  $\mathbf{K}$  为正定矩阵<sup>[12]</sup>.

定义 3 令  $X$  为一非空集合, 一个定义在  $X \times X$  上的函数  $k$ , 如果满足对所有的  $m \in N (N \text{ 为自然数集})$  和  $\mathbf{x}_1, \dots, \mathbf{x}_m \in X$  都产生一个正定的 Gram 矩阵, 则称  $k$  为正定核, 简称为核。

命题 1  $k_s$  是对称函数。

证明: 由  $k_s$  的定义可以得到对于任意的向量  $\mathbf{x}, \mathbf{y}$  来说  $\rho(\mathbf{x}, \mathbf{y}) = \rho(\mathbf{y}, \mathbf{x})$ , 所以有  $k_s(\mathbf{x}, \mathbf{y}) = k_s(\mathbf{y}, \mathbf{x})$  成立。

因此,  $k_s$  是对称函数。

命题 2 由函数  $k_s$  生成的矩阵  $\mathbf{K}_{i,j} := k_s(\mathbf{x}_i, \mathbf{x}_j)$

是正定矩阵。

证明: 由命题 1 可以得知,  $k_s(\mathbf{x}, \mathbf{y})$  是对称函数. 则有  $\mathbf{K}_{i,j} = \mathbf{K}_{j,i}$ , 所以矩阵  $\mathbf{K}$  是对称的。

由于  $k_s \in R$  且  $k_s(\mathbf{x}, \mathbf{y}) \geq 0$ , 因此  $\mathbf{K}$  是一个实对称阵, 所以矩阵  $\mathbf{K}$  是正定的。

根据定义 3, 可以确定  $k_s$  为正定核, 称之为光谱相似度量核 (Spectral Similarity Measurement kernel, SSM)。

为了说明高斯径向基核与本文提出的光谱相似度量核的特点, 采用真实高光谱数据的光谱向量曲线进行试验. 如图 1, 简便起见在两个区域选取三条光谱向量曲线, 分别简记为光谱  $\mathbf{a}_1$ , 光谱  $\mathbf{a}_2$  和光谱  $\mathbf{b}$ . 其中  $\mathbf{a}_1$  与  $\mathbf{a}_2$  属于同一地物类型 A, 但  $\mathbf{a}_2$  由于受到阴影影响而使得其绝对值要低于  $\mathbf{a}_1$ , 但从光谱曲线形状上来看还是可以很明显的看出二者的相似性的; 而光谱  $\mathbf{b}$  则取自另一地物 B. 分别计算光谱  $\mathbf{a}_1$  与  $\mathbf{b}$ ,  $\mathbf{a}_2$  与  $\mathbf{b}$ ,  $\mathbf{a}_1$  与  $\mathbf{a}_2$  在高斯径向基核以及光谱相似度量核下的取值, RBF 中  $c$  取值为 40, 而 SSM 中  $\theta$  取为 0.1, 结果如表 1。

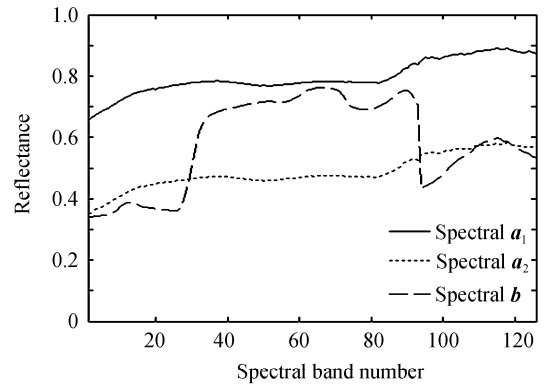


图 1 光谱曲线示意图

Fig. 1 Demonstration of three spectrum curves

表 1 高斯径向基核与光谱相似度量核对比

	$(\mathbf{a}_1, \mathbf{b})$	$(\mathbf{a}_2, \mathbf{b})$	$(\mathbf{a}_1, \mathbf{a}_2)$
$k_r$	0.761 6	0.880 1	0.669 1
$k_s$	0.000 8	0.000 9	0.995 4

两向量的高斯径向基核取值或光谱相似度量核取值都是越接近于 1 表明二者的相似程度越高, 二者被归为一类的可能性越大. 从表 1 的结果可以看出, 向量  $\mathbf{a}_1, \mathbf{a}_2$  与  $\mathbf{b}$  的 RBF 核 ( $k_r$ ) 计算结果要大于  $\mathbf{a}_1, \mathbf{a}_2$  之间的 RBF 核计算结果, 若以光谱向量  $\mathbf{a}_1$  为参考对象, 该计算结果说明光谱向量  $\mathbf{b}$  要比光谱向量  $\mathbf{a}_2$  更有可能判断为  $\mathbf{a}_1$  的同类, 但实际情况并不是如此. 相反 SSM 核 ( $k_s$ ) 的计算结果则认为  $\mathbf{a}_1$  与  $\mathbf{a}_2$  的相似程度更高, 且  $\mathbf{a}_1, \mathbf{a}_2$  与  $\mathbf{b}$  不是同一类地物. 尽管从表 1 中可以看见同一向量对的 SSM 核 ( $k_s$ ) 计算结果相对于 RBF 核 ( $k_r$ ) 的计算结果要更

接近于实际情况,但由于二者的参量并未纳入一个统一的框架下,所以我们不做同一向量条件下  $k_r$  与  $k_l$  的横向比较。

光谱相似度量核对于因光照强度变化、阴影、遮挡等原因引起的同种地物光谱变化的适应性要好于高斯径向基核。

## 2 核 RX 异常检测算法

Reed 与 Yu 提出的 RX 异常检测算法<sup>[3]</sup>通过比较检测点与背景光谱的差异来进行检测.其局部检测模型如图 2,检测背景分布于外窗,而检测点位于内窗,内窗中其它部分则作为缓冲区域。




图 2 高光谱异常检测同心双窗模型

Fig. 2 Dual concentric windows model for hyperspectral imagery anomaly detection

RX 检测算子表示为

$$RX(\mathbf{r}) = (\mathbf{r} - \hat{\boldsymbol{\mu}}_b)^T \hat{\mathbf{C}}_b^{-1} (\mathbf{r} - \hat{\boldsymbol{\mu}}_b) \quad (5)$$

式中  $\mathbf{r}$  表示当前检测向量,  $\hat{\boldsymbol{\mu}}_b$  为背景光谱向量平均值的估计,  $\hat{\mathbf{C}}_b$  为背景光谱向量的协方差估计。

Kwon 等人提出的基于核的 RX 算法<sup>[4]</sup>,通过非线性函数  $\Phi$  将原始输入空间光谱信号非线性映射到高维特征空间中,使得在原始输入空间中线性不可分的成分经过非线性映射到高维特征空间成为线性可分,在高维特征空间实现 RX 检测,检测算法表示为

$$KRX(\Phi(\mathbf{r})) = (\Phi(\mathbf{r}) - \hat{\boldsymbol{\mu}}_{\Phi})^T \hat{\mathbf{C}}_{\Phi}^{-1} (\Phi(\mathbf{r}) - \hat{\boldsymbol{\mu}}_{\Phi}) \quad (6)$$

式中  $\Phi(\mathbf{r})$  为非线性映射到高维特征空间的检测向量,  $\hat{\boldsymbol{\mu}}_{\Phi}$  与  $\hat{\mathbf{C}}_{\Phi}$  分别为特征空间的背景均值和协方差估计。

由于特征空间的维数很高(甚至可能趋于无穷),同时由于非线性映射函数未知,这使得直接在特征空间进行计算变得很困难甚至于不可能实现.核方法将特征空间的点积转化为输入空间数据的核函数来实现<sup>[9]</sup>,从而巧妙的避开了在高维的特征空间计算点积.特征空间的点积的核表达式为

$$k(\mathbf{x}_i, \mathbf{x}_j) = \langle \Phi(\mathbf{x}_i), \Phi(\mathbf{x}_j) \rangle = \Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j) \quad (7)$$

因此不需要知道具体的非线性映射函数  $\Phi$ ,也不需

要在高维的特征空间进行相应的点积运算,通过核函数将高维特征空间的点积转换为低维输入空间的核函数表示能够简单的进行核 RX 检测。

## 3 试验与结果分析

为了检验光谱相似度量核的有效性,利用真实空中可见光/红外成像分光计(Airborne Visible/Infrared Imaging Spectrometer, AVIRIS) 高光谱数据(HSI)进行了仿真实验.该图像是美国圣地亚哥机场的一部分,去掉噪音污染严重及水汽吸收较明显的波段,选取剩余 126 个波段作为研究对象.截取的图像大小为  $100 \times 100 \text{ pixel}^2$ ,含有 38 个待检测目标.其第 1 波段图像及定位后的目标分布如图 3.为了比较,选用核 RX(简记为 KRX)算法作为高光谱异常检测算子,分别采用高斯径向基核与本文所提出的光谱相似度量核进行异常目标检测,同时为了对比基于核方法的非线性检测算法与经典线性检测算法的差异,本文将 RX 算法也作为比较对象进行试验。




图 3 光谱第 1 波段图像及相应的目标分布

Fig. 3 First band image and real targets distribution

局部检测模型的背景检测外窗尺寸设为  $13 \times 13 \text{ pixel}^2$ ,内窗尺寸设为  $5 \times 5 \text{ pixel}^2$ .外窗的选择要保证有足够的背景向量来描述当前检测点所处的环境,而内窗则要避免异常点混入检测背景中。

高斯径向基核函数的宽度  $c$  的选择至关重要,参量选择得当可以使数据的所有变化都体现在核函数中.通过多次实验,将高斯径向基核函数宽度  $c$  定为 40.利用高斯径向基核函数的 KRX 算法记为 RBF-KRX.

通过试验比较,将光谱相似度量核的相似临界因子  $\theta$  设定为 0.08,详细的相似临界因子讨论在后文给出.利用光谱相似度量核函数的 KRX 算法记为 SSM-KRX.

三种方法检测结果如图 4.从检测结果可以看出,由于对高光谱波段间的非线性信息不能充分利用,经典 RX 算法的检测效果不是很理想.而利用核方法挖掘高光谱波段间的非线性信息后,核 RX 算

法的检测效果有了很大改善. 由于高斯径向基核是基于光谱向量间距离的, 因此, 对于光谱形状的细微差别不能有效的区分, 这使得在受阴影影响区域(如图3(a)中左侧中部区域)的目标检测效果下降. 而基于光谱相似度量核的 KRX 算法的检测效果由于光谱形状分辨能力的提高, 使得其检测结果较 RBF-KRX 要好.




图4 RX、RBF-KRX 和 SSM-KRX 算法检测结果三维示意图

Fig. 4 3-D plot of detection results using RX, RBF-KRX and SSM-KRX

接收机操作特性曲线(ROC)用于描述检测概率  $P_d$  与虚警概率  $P_f$  之间的变化关系, 能够提供算法检测性能的定量分析. 根据地面目标真实分布图可以获得每个目标所包含的像素区域坐标, 通过考察检测到的异常点是否落入真实目标分布区域可以来判定检测到的是真实目标还是虚警. 将检测概率

( $P_d$ ) 定义为检测到的真实目标像素数目  $N_{hit}$  与地面真实目标像素数目  $N_{target}$  的比值; 虚警概率( $P_f$ ) 定义为检测到的虚警像素数目  $N_{miss}$  同整幅图像像素数目总和  $N_{total}$  的比值.

$$P_d = N_{hit} / N_{target}, P_f = N_{miss} / N_{total} \quad (8)$$

将检测结果通过不同的阈值分割得到不同条件下的虚警概率和检测概率数据. 图5给出了RX算法、RBF-KRX算法和本文提出的SSM-KRX算法应用到真实高光谱数据上得到的ROC比较. 可以看出, 由于核函数的引入使得RBF-KRX和SSM-KRX算法能够挖掘高光谱波段间的非线性统计特性, 具有很好的非线性检测能力, 因而检测性能明显优于传统RX算法; 由于光谱相似度量核很强的光谱形状分辨能力, 使得SSM-KRX的检测概率随着虚警概率的上升而超越了RBF-KRX算法; 但不可否认的是正是由于光谱相似度量核对光谱形状的高度敏感性使得其虚警概率也较高, 尤其是在低虚警概率情况下( $P_f < 0.012$ ) SSM-KRX的检测概率要低于RBF-KRX. 如果我们以不同分割阈值条件下得到的检测目标个数( $N_{dt}$ )与虚警概率( $P_f$ )作为标准比较, 能得到如表2所示的结果.

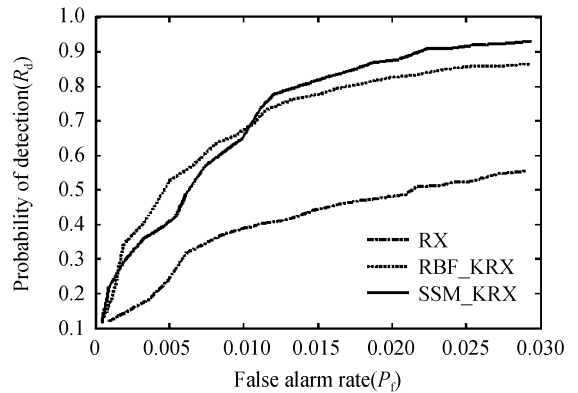


图5 三种检测算法 ROC 示意图

Fig. 5 ROC curves obtained by RX, RBF-KRX and SSM-KRX

表2 SSM-KRX 与 RBF-KRX 检测性能对比

阈值	0.5	0.4	0.3	0.2	0.1	
RBF	$N_{dt}$	23	24	26	28	31
	$P_f(\%)$	0.63	0.97	1.11	1.48	2.21
SSM-KRX	$N_{dt}$	28	32	35	36	38
	$P_f(\%)$	0.99	1.12	1.71	2.07	2.34

从表2的结果可以看出, SSM-KRX能检测出所有38个潜在目标, 而相同条件下RBF-KRX算法检测出来的目标个数要明显少于SSM-KRX. 这也说明了光谱相似度量核在高光谱异常目标检测上的优越性. 值得注意的是, 尽管在检测概率上来讲, 如图5, RBF-KRX算法和SSM-KRX算法在虚警概率为1%左右情况下的探测概率应当差不多(或

RBF-KRX 要稍好于 SSM-KRX), 但由于 SSM-KRX 算法在目标数目上较多, 如表 2 中, RBF-KRX 在  $P_f$  为 0.97% 时  $N_{dt}$  为 24 个, 而 SSM-KRX 在  $P_f$  为 0.99% 时  $N_{dt}$  为 28 个, 多出来的这几个目标(高光谱图像左侧)多为亚像素目标, 因而在检测概率上来讲并没有比 RBF-KRX 算法高。

为了对光谱相似度量核函数的参量相似临界因子  $\theta$  进行初步探讨, 将  $\theta$  分别取值为 1.0、0.5、0.1、0.01, 对高光谱数据进行异常检测, 分别得到各自的接收机操作特性曲线, 结果如图 6。




图 6 不同  $\theta$  条件下 SSM-KRX 的检测 ROC

Fig. 6 ROC curves obtained by SSM-KRX using different  $\theta$

从图 6 的结果可以看出, 相似临界因子  $\theta$  的取值对基于光谱相似度量核函数的检测算法的性能有着十分重要的影响. 随着  $\theta$  的变化, 其检测性能有着较大的起伏, 但也有一定的规律可循. 当  $\theta$  较大时 (本文中  $\theta \geq 1$ ), 光谱形似度量核的光谱分辨能力下降, 其表现在检测结果上就是漏检概率的上升, 使得最终检测到的目标数目下降; 而随着  $\theta$  的降低, SSM-KRX 的检测性能也随之上升, 但也不是一直如此, 当  $\theta$  过小 (本文中  $\theta \leq 0.01$ ) 时, 则光谱相似度量核对于光谱形状间差异过于敏感, 使得同类地物被判为异类的概率上升, 表现在最终的检测结果上为得到相同的检测概率则要付出很大虚警概率的代价, 而这在某些情况下是不允许的. 因而, 从目前的试验结果来看, 本文认为要取得较好的检测结果, 相似临界因子的取值一般来讲不能超过 1, 但也不能太小. 即  $\theta \in (0, 1)$ , 试验中的具体取值要根据检测性能对于虚警概率和检测概率的要求进行设定。

## 4 结论

本文提出了一种基于光谱相似度量核的高光谱异常检测算法, 对光谱相似度量核的构造进行了阐述并对其核函数的充要性进行了证明. 通过与常用的高斯径向基核函数在理论上和试验中的对比, 发现光谱相似度量核对于光谱曲线形状的分能力要

强于高斯径向基核, 因而对于由于遮挡, 阴影等引起的同种地物光谱变化的适应性更强. 在高光谱异常检测中, 基于光谱相似度量核的 KRX 算法的检测性能优于基于高斯径向基核的 KRX 算法. 文中对影响光谱相似度量核性能的相似临界因子的设定进行了简要探讨. 对于进一步改善光谱相似度量核的性能, 对其应用进行推广, 以及其参量优化等都是进一步研究的内容。

## 参考文献

- [1] SCHAUM A. Spectral subspace matched filtering [C]. *Proceedings of the SPIE-The International Society for Optical Engineering*, 2001, **4381**:1-17.
- [2] HARSANYI J C, CHANG C I. Hyperspectral image classification and dimensionality reduction: An orthogonal subspace projection approach [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 1994, **32**(4):779-785.
- [3] REED I S, YU X. Adaptive multiple-band CFAR detection of an optical pattern with unknown spectral distribution [J]. *IEEE Transactions on Acoustics, Speech and Signal Processing*, 1990, **38**(10):1760-1770.
- [4] HEESUNG K, NASRABADI N M. Kernel RX-algorithm: a nonlinear anomaly detector for hyperspectral imagery [J]. *Geoscience and Remote Sensing, IEEE Transactions on*, 2005, **43**(2):388-397.
- [5] GOLDBERG H, NASRABADI N M. A comparative study of linear and nonlinear anomaly detectors for hyperspectral imagery [C]. *SPIE*, 2007, 656504.
- [6] DI Wei, PAN Quan, HE Lin, et al. Anomaly Detection in Multi-Band Spectral Imagery Based on Multiple-Detector Maximum Entropy Fusion [J]. *Acta Photonica Sinica*, 2007, **36**(7):1338-1344.  
邸韡, 潘泉, 贺霖, 等. 基于多检测器最大熵融合的多通道光谱图像异常检测 [J]. *光子学报*, 2007, **36**(7):1338-1344.
- [7] HE Lin, PAN Quan, ZHAO Yong-qiang, et al. Anomaly Detection in Hyperspectral Imagery Based on Feature Fusion of Band Subsets [J]. *Acta Photonica Sinica*, 2005, **34**(11):1752-1755.  
贺霖, 潘泉, 赵永强, 等. 基于波段子集特征融合的高光谱图像异常检测 [J]. *光子学报*, 2005, **34**(11):1752-1755.
- [8] NAPNICK V N. *Statistical Learning Theory* [M]. New York: Wiley, 1998.
- [9] SCHOLKOPF B, SMOLA A J, MULLER K. Kernel principal component analysis [C]. *Proceedings of the 1997 7th International Conference on Artificial Neural Networks*, 1997, **1327**:583.
- [10] LIU Wei-min, CHANG Chein I. Sample spectral correlation-based measures for subpixels and mixed pixels in real hyperspectral imagery [C]. *SPIE*, 2006, **6233**:62330J.
- [11] WANG Zhi-ping, YANG Jian-feng, XUE Bin, et al. Using Hyperspectral Data for Land Cover Identification and Classification [J]. *Acta Photonica Sinica*, 2008, **37**(3):561-565.  
王志平, 杨建峰, 薛彬, 等. 利用高光谱数据进行地物识别分类

研究[J]. 光子学报, 2008, 37(3): 561-565.

Cambridge: The MIT Press, 2002.

[12] SCHOLKOPF B, SMOLA A J. Learning with Kernels[M].

## A Novel Spectral Similarity Measurement Kernel Based Anomaly Detection Method in Hyperspectral Imagery

MEI Feng, ZHAO Chun-hui, SUN Yan, WANG Li-guo

(College of Information & Communication Engineering, Harbin Engineering University, Harbin 150001, China)

**Abstract:** A novel spectral similarity measurement kernel function is proposed and applied to anomaly detection in hyperspectral imagery. As the Gaussian Radial Basis Function (RBF) is based on the Euclidean distance of two spectral vectors, it is sensitive for distance variations of two spectral vectors, but not for spectral curve variation coming from radiation intensity variation, shadow, and shading etc. When the spectral curves of a material are variety, the detection performance of the RBF based anomaly detectors degenerate. In order to solve the spectral curves variation problems for the same materials, a spectral similarity measurement kernel function is proposed according to the spectral curves similarity description. A theoretical analysis is expounded and numerical experiments are conducted on real hyperspectral imagery. The detection result comparison of Gaussian Radial Basis Function based and Spectral Similarity Measurement Kernel based anomaly detector shows the Spectral Similarity Measurement kernel can improve the performance of kernel base anomaly detection methods in hyperspectral imagery.

**Key words:** Hyperspectral imagery; Anomaly detection; Spectral similarity measure; Kernel-based method; RX



**MEI Feng** was born in 1983. He is currently pursuing the Ph. D. degree at College of Information and Communication Engineering, Harbin Engineering University. His research interests focus on signal and image processing, pattern recognition, and hyperspectral image analysis.