

# 基于自适应参数支持向量机的高光谱遥感图像小目标检测

吴一全<sup>1,2</sup> 周 杨<sup>1</sup> 龙云淋<sup>1</sup>

<sup>1</sup>南京航空航天大学电子信息工程学院,江苏 南京 210016

<sup>2</sup>中国科学院西安光学精密机械研究所中国科学院光谱成像技术重点实验室,陕西 西安 710000

**摘要** 针对高光谱遥感图像的小目标检测问题,提出了一种基于自适应参数支持向量机(SVM)的检测方法。采用主成分分析(PCA)法对高光谱遥感图像进行降维,降低数据冗余度;之后通过无监督检测方法对小目标进行快速、粗糙定位,并将该定位结果作为后验信息输入到SVM中;依据后验信息与核空间散度准则自适应确定SVM中核函数的参数,并使用SVM在核空间中寻找分离目标和背景的最佳超平面;利用该超平面将像元重新分类为背景和目标,并且迭代上述操作,得到精确且稳定的目标检测结果。大量实验结果表明,与经典RX方法、核RX方法、支持向量数据描述(SVDD)方法相比,该方法可以更有效、精确地检测出高光谱遥感图像中的小目标。

**关键词** 遥感; 高光谱图像; 小目标检测; 自适应参数; 支持向量机

中图分类号 TP751

文献标识码 A

doi: 10.3788/AOS201535.0928001

## Small Target Detection in Hyperspectral Remote Sensing Image Based on Adaptive Parameter SVM

Wu Yiquan<sup>1,2</sup> Zhou Yang<sup>1</sup> Long Yunlin<sup>1</sup>

<sup>1</sup>College of Electronic and Information Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing, Jiangsu 210016, China

<sup>2</sup>Key Laboratory of Spectral Imaging Technology Chinese Academy of Science, Xi'an Institute of Optics and Precision Mechanics, Chinese Academy of Science, Xi'an, Shaanxi 710000, China

**Abstract** As for the problem of small target detection in hyperspectral remote sensing image, a detection method based on adaptive parameter support vector machine (SVM) is proposed. The low dimensional information of the hyperspectral image is obtained using the method of principal component analysis (PCA) and the redundancy of data is reduced. Then, small targets are positioned fast and roughly by an unsupervised detection method, and the posterior information of SVM is got by the position result. The kernel parameter of SVM is determined adaptively based on the posterior information and the criteria of divergence in the kernel space. The best hyperplane in the kernel space for the segmentation of targets and background is found by the SVM. Pixels are separated to targets and background by the best hyperplane. The accurate and stable target detection result is obtained by iteration. A large number of experimental results show that, compared to the existing methods such as RX method, kernel RX method and support vector data description (SVDD) method, the proposed method is more effective to detect small targets accurately in the hyperspectral remote sensing image.

**Key words** remote sensing; hyperspectral image; small target detection; adaptive parameter; support vector machine

**OCIS codes** 280.4788; 110.4234; 040.1880; 100.4999

收稿日期: 2015-04-14; 收到修改稿日期: 2015-05-28

**基金项目:** 国家自然科学基金(60872065)、中国科学院光谱成像重点实验室开放基金项目(LSIT201401)、江苏高校优势学科建设工程

**作者简介:** 吴一全(1963—),男,博士,教授,主要从事遥感图像处理与理解、红外目标检测与识别、视觉检测与图像测量、数字全息等方面的研究。E-mail: nuaaimage@163.com

## 1 引 言

在 20 世纪后半叶,伴随着光谱成像仪而产生的高光谱成像技术是遥感领域的一个进步,其最大特点是融合成像技术与光谱探测技术,可以同时获得区域的图像信息与光谱特征,为目标检测开辟了新的途径<sup>[1-2]</sup>。高光谱遥感图像目标检测是根据图像中的信息分布提取出具有不同光谱特征的小概率目标<sup>[3-4]</sup>。该技术在目标检测方面具有较大的优势与较强的实用性,近年来被广泛应用于军事目标识别、矿藏探测、环境检测、城市规划等多个领域,并且取得了一定的成果<sup>[4-5]</sup>。

高光谱遥感图像小目标检测的方法众多,主要分为两类:有监督检测和无监督检测。有监督检测方法一般是建立在有先验信息的基础上,虽然具有较高的检测精度,但是其先验信息的获取受到光谱库、反射率和光谱混合现象的限制<sup>[6-8]</sup>,制约了该方法在实际中的应用,因此高光谱无监督检测方法成为该领域的研究重点。高光谱无监督检测方法无需目标的先验信息,主要根据数据的统计特性,从全局或局部块中选取出现概率较小的点作为目标。由 Reed 等<sup>[9-11]</sup>提出的基于广义似然比检验的 RX 方法是经典的无监督检测方法,用于在具有高斯统计性质的背景下检测光谱特征未知的目标,但该方法对图像信噪比要求较高,易将噪声点检测为小目标,且计算量较大。随着统计学习研究的深入,核方法逐渐被运用到高光谱遥感图像处理中。Kwon<sup>[12]</sup>使用核函数对传统的 RX 方法进行了改进,先利用核函数将原始空间中的光谱信号映射到核空间中,再使用 RX 方法进行目标的检测,降低了 RX 方法的虚警率。但是,核 RX 方法中协方差矩阵的运算量较大,且核函数的参数需要人为选择,限制了其通用性。之后, Banerjee 等<sup>[13-14]</sup>提出了一种基于支持向量数据描述(SVDD)的异常目标检测方法。SVDD 由支持向量机(SVM)发展而来,是一种描述单类数据的方法。其主要思想是:在尽可能接受像元的前提下,通过寻找包含一组像元的最小超球体边界对目标和背景进行分类。该方法避免了核 RX 方法中协方差矩阵的求逆运算,加快了运算速度,但是其检测性能亦受核参数的影响,需要通过实验不断地尝试确定核参数,对不同图像的适应性较差。上述无监督检测方法虽然简单易行,但由于无先验信息的指导,往往会出现虚警率较高或检测率较低的情况。

基于上述分析,本文提出了一种融合无监督检测和自适应参数支持向量机<sup>[15]</sup>的高光谱小目标检测方法。针对单一无监督检测方法无先验信息指导的弊端,在忽略虚警率的情况下,使用简单的无监督检测对小目标进行快速、模糊定位,并将该定位结果作为指导后续检测的后验信息,缩小检测范围,提高检测效率;针对线性空间中无监督检测方法无法精确检测非线性目标的弊端,根据目标和背景在核空间中具有类间可分与类内聚集的特点,使用非线性支持向量机在核空间中分离目标和背景;针对核方法中参数选择困难、适应性较差的弊端,在基于后验信息的基础上,将欧式空间中衡量数据可分性的类内类间散度准则<sup>[16]</sup>拓展到核空间中,并且根据该准则提出了核参数的自适应确定方法。给出了基于该方法的高光谱小目标检测结果,并将该方法与 RX 方法、核 RX 方法、SVDD 方法进行了比较。

## 2 高光谱遥感图像的小目标检测方法

将无监督检测方法与支持向量机结合运用于高光谱遥感图像的小目标检测中,并给出一种基于后验信息与核空间散度准则的支持向量机核参数自适应确定方法。该方法主要包括高光谱遥感图像的降维、小目标的后验信息获取、基于核空间散度准则的 SVM 核函数参数自适应确定、基于 SVM 的目标与背景分类四个部分,其流程图如图 1 所示。

### 2.1 高光谱遥感图像的降维和后验信息的获取

虽然高光谱遥感图像具有多波段可以提供丰富的光谱信息,但是相邻光谱之间具有较高的相关性,势必导致信息的冗余和计算量的递增,因此有必要对高光谱遥感图像进行降维<sup>[17]</sup>。由于主成分分析法(PCA)可以将高维数据映射到少数含有主要信息的低维矢量上,具有计算量少、压缩程度大等优点<sup>[18-19]</sup>,因此首先使用主成分分析法对原始高光谱数据进行降维。

在降维的基础上,使用无监督检测方法对小目标进行初步模糊定位,其作用是后续的精确定检测提供初始化的后验信息,目的是缩小检测范围、提高检测效率。由于本文方法对后验信息的精确度要求较低,因此可以采用简单易行、运算速度快的无监督检测方法进行后验信息的提取,如 RX 方法<sup>[9-11]</sup>、投影寻踪方法<sup>[20]</sup>和独立分量分析方法<sup>[21]</sup>等。

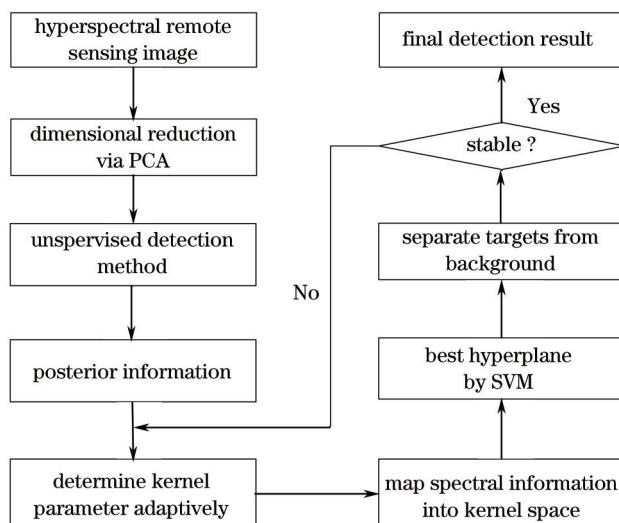


图 1 高光谱遥感图像小目标检测方法的流程图

Fig. 1 Flowchart of detection method for small target in hyperspectral remote sensing image

## 2.2 基于核空间散度准则的 SVM 核函数参数自适应确定

通过引入核方法而构造的高光谱目标非线性检测方法,在充分挖掘高光谱数据间存在的非线性信息基础上,大大提高了原线性方法的检测性能。在基于支持向量机的高光谱目标检测方法中,支持向量机的核函数选择了高斯径向基函数,这是由于该函数具有良好的通用性以及转移不变性。类似众多的核检测方法,核函数参数是决定该方法性能的重要因素,然而,该参数大多通过大量实验的方式进行人为选择,其适用性收到了限制<sup>[13-14]</sup>。为了克服该缺点,本文通过构造高斯径向基核函数的参数估计模型,自适应地确定核参数。

由于支持向量机能否快速地找到分类超平面取决于核空间中数据的可分性,而数据的可分性往往与核函数的参数有关,核参数的微小变动将会导致支持向量机无法找到合适的超平面,因此可以通过最大化数据可分性优化核参数。人们已经提出了一些有效的判据来衡量数据的可分性,如:基于类内类间散度准则的判据、基于熵函数及基于概率分布的判据<sup>[16]</sup>。与后两种判据相比较,基于类内类间散度准则的判据具有概念清晰、计算简便等特点,其主要思想为:当类间距离越大、类内距离越小时,数据的可分性越明显。本文将该判据拓展到核空间中,通过最大核空间中的类内类间距离差或距离比优化核函数的参数,并给出相应的快速迭代公式。

记初检结果中的像元类别数为  $C$ ,第  $t$  类像元的总数为  $N_t$  ( $t=1,2,\dots,C$  且  $\sum_{t=1}^C N_t=N$ ),降维后的高光谱遥感图像可表示为  $X=(x_1, x_2, \dots, x_i, \dots, x_c)$ ,其中  $x_i=(x_{i1}, x_{i2}, \dots, x_{in_i}, \dots, x_{in_i})$  表示第  $t$  类的像元集合,  $x_i$  表示第  $t$  类中第  $i$  个像元的降维光谱信息,其映射至核空间的像元为  $\Phi(x_i)$ ,核函数为  $\text{Ker}$ ,待优化的参数为  $e$ ,核矩阵为  $K$ ,任意两像元  $\Phi(x_i)$  和  $\Phi(x_j)$  在核空间中的内积可由核函数间接表示为

$$\Phi(x_i)^T \cdot \Phi(x_j) = \langle \Phi(x_i), \Phi(x_j) \rangle = \text{Ker}(x_i, x_j) = K_{i,j} = \exp\left(-\frac{1}{2e} \|x_i - x_j\|_2\right). \quad (1)$$

核空间中某类像元的中心像元  $\overline{\Phi(x_i)}$  与所有像元的中心像元  $\overline{\Phi(x)}$  的计算公式为

$$\overline{\Phi(x_i)} = \frac{1}{N_t} \sum_{i=1}^{N_t} \Phi(x_i), \quad \overline{\Phi(x)} = \frac{1}{N} \sum_{t=1}^C \sum_{i=1}^{N_t} \Phi(x_i). \quad (2)$$

核空间中类内散度  $S_w$  的计算公式为

$$\begin{aligned} S_w &= \sum_{i=1}^C \left\{ \frac{N_t}{N} \sum_{i=1}^{N_t} \frac{1}{N_t} \left\{ [\Phi(x_i) - \overline{\Phi(x_i)}]^T \cdot [\Phi(x_i) - \overline{\Phi(x_i)}] \right\} \right\} = \sum_{i=1}^C \sum_{i=1}^{N_t} \left\{ \frac{1}{N} \left[ \Phi(x_i) - \frac{1}{N_t} \sum_{z=1}^{N_t} \Phi(x_z) \right]^T \cdot \left[ \Phi(x_i) - \frac{1}{N_t} \sum_{z=1}^{N_t} \Phi(x_z) \right] \right\} = \\ &= \frac{1}{N} \sum_{i=1}^C \sum_{i=1}^{N_t} \left[ \Phi(x_i)^T \Phi(x_i) - \frac{1}{N_t} \sum_{z=1}^{N_t} \Phi(x_i)^T \Phi(x_z) - \frac{1}{N_t} \sum_{l=1}^{N_t} \Phi(x_l)^T \Phi(x_i) + \frac{1}{N_t^2} \sum_{z=1}^{N_t} \sum_{l=1}^{N_t} \Phi(x_z)^T \Phi(x_l) \right] = \\ &= \frac{1}{N} \sum_{i=1}^C \sum_{i=1}^{N_t} \left( K_{i,i} - \frac{1}{N_t} \sum_{z=1}^{N_t} K_{i,z} - \frac{1}{N_t} \sum_{l=1}^{N_t} K_{l,i} + \frac{1}{N_t^2} \sum_{z=1}^{N_t} \sum_{l=1}^{N_t} K_{z,l} \right) = \frac{1}{N} \sum_{i=1}^C \sum_{i=1}^{N_t} \overline{K_{i,i}} \end{aligned} \quad (3)$$

式中  $\overline{K_{t_i}}$  表示类内中心化核矩阵的第  $(t_i, t_i)$  个元素。

类比于  $S_w$  的推导方法, 可得核空间中类间散度  $S_b$  的计算公式为

$$S_b = \sum_{i=1}^C \left\{ \frac{N_i}{N} \sum_{i=1}^{N_i} \left[ (\overline{\Phi(x_i)} - \overline{\Phi(x)})^T \cdot [\overline{\Phi(x_i)} - \overline{\Phi(x)}] \right] \right\} \approx \frac{1}{N} \sum_{i=1}^C \sum_{i=1}^{N_i} \left\{ [\Phi(x_i) - \overline{\Phi(x)}]^T \cdot [\Phi(x_i) - \overline{\Phi(x)}] \right\} =$$

$$\frac{1}{N} \sum_{i=1}^C \sum_{i=1}^{N_i} \left[ K_{t_i} - \frac{1}{N} \sum_{p=1}^C \sum_{z=1}^{N_p} K_{p_z} - \frac{1}{N} \sum_{q=1}^C \sum_{l=1}^{N_q} K_{l_q} + \frac{1}{N^2} \sum_{p=1}^C \sum_{z=1}^{N_p} \left( \sum_{q=1}^C \sum_{l=1}^{N_q} K_{p_z q_l} \right) \right] = \frac{1}{N} \sum_{i=1}^C \sum_{i=1}^{N_i} (\overline{K_{t_i}})' \quad (4)$$

式中  $N_q$  为第  $q$  类像元的总数, 其中  $q = 1, 2, \dots, C$ , 且  $\sum_{q=1}^C N_q = N$ ,  $N_p$  为第  $p$  类像元的总数, 其中  $p = 1, 2, \dots, C$ ,

且  $\sum_{p=1}^C N_p = N$ ,  $(\overline{K_{t_i}})'$  表示类间中心化核矩阵的第  $(t_i, t_i)$  个元素。

两种散度指标  $S$ , 分别为散度差  $S_1 = S_b - S_w$  和散度比  $S_2 = \frac{S_b}{S_w}$ 。由于使用随机步长最陡下降法更新高斯核函数的参数  $e$ , 因此需要计算散度指标  $S$  的导数  $\nabla S$  (散度差导数  $\nabla S_1$  或散度比导数  $\nabla S_2$ )。记核矩阵  $\mathbf{K}$  的导数为  $\nabla \mathbf{K}$ , 其第  $(t_i, t_j)$  个元素为  $\nabla K_{t_i t_j}$ , 对应的类内、类间核矩阵导数中心化后的元素分别为  $\overline{\nabla K_{t_i t_j}}$  和  $(\overline{\nabla K_{t_i t_j}})'$ 。由于高斯核函数的导数仍具有核函数的性质, 因此  $\nabla S_1$  和  $\nabla S_2$  的计算公式为

$$\left\{ \begin{array}{l} \nabla K_{t_i t_j} = \exp\left(-\frac{1}{2e} \|x_{t_i} - x_{t_j}\|_2\right) \cdot \frac{1}{2e^2} \|x_{t_i} - x_{t_j}\|_2 \\ \overline{\nabla K_{t_i t_i}} = \nabla K_{t_i t_i} - \frac{1}{N} \sum_{z=1}^{N_i} \nabla K_{t_i z} - \frac{1}{N} \sum_{l=1}^{N_i} \nabla K_{l t_i} + \frac{1}{N^2} \sum_{z=1}^{N_i} \sum_{l=1}^{N_i} \nabla K_{t_i z l} \\ (\overline{\nabla K_{t_i t_i}})' = \nabla K_{t_i t_i} - \frac{1}{N} \sum_{p=1}^C \sum_{z=1}^{N_p} \nabla K_{p_z t_i} - \frac{1}{N} \sum_{q=1}^C \sum_{l=1}^{N_q} \nabla K_{t_i q_l} + \frac{1}{N^2} \sum_{p=1}^C \sum_{z=1}^{N_p} \left( \sum_{q=1}^C \sum_{l=1}^{N_q} \nabla K_{p_z q_l} \right) \\ \nabla S_1 = \sum_{i=1}^C \sum_{i=1}^{N_i} \frac{1}{N} \cdot (\overline{\nabla K_{t_i t_i}})' - \sum_{i=1}^C \sum_{i=1}^{N_i} \frac{1}{N} \cdot \overline{\nabla K_{t_i t_i}} \\ \nabla S_2 = \frac{S_w \cdot \left[ \sum_{i=1}^C \sum_{i=1}^{N_i} \frac{1}{N} \cdot (\overline{\nabla K_{t_i t_i}})' \right] - S_b \cdot \left[ \sum_{i=1}^C \sum_{i=1}^{N_i} \frac{1}{N} \cdot \overline{\nabla K_{t_i t_i}} \right]}{S_w^2} \end{array} \right. \quad (5)$$

则核参数  $e$  的迭代公式为

$$e_{\text{update}} = e_{\text{before}} + \lambda \cdot \text{rand} \cdot \text{sign}(\nabla S) \cdot e_{\text{before}}, \quad (6)$$

式中  $\text{rand}$  为 0~1 之间的随机数,  $\text{sign}(\cdot)$  为符号函数,  $\lambda$  为迭代步长,  $e_{\text{before}}$  为迭代前的  $e$  值,  $e_{\text{update}}$  为迭代后的  $e$  值。

综上所述, SVM 核参数自适应确定方法的具体步骤为

Step1: 初始化: 参数  $e = 1$ ; 最佳散度指标  $S_0 = 0$  与其对应的参数  $e_0 = 0$ ; 迭代次数  $n_i = 0$  和最佳值滞留次数  $n_d = 0$ ; 迭代步长  $\lambda = 0.5$ ; 由于当散度指标在某个值的滞留次数达到阈值时, 则说明该散度指标已收敛到最佳值, 需要停止迭代, 因此设最佳值的最大滞留次数  $n_{\text{delay}} = 10$ ; 若散度指标在某个值附近徘徊, 无法收敛时, 则需要设置迭代次数阈值, 使该迭代过程停止, 因此设最大迭代次数  $n_{\text{max}} = 50$ ;

Step2: 由(1)式和(5)式计算参数  $e$  决定的核矩阵  $\mathbf{K}$  和其导数矩阵  $\nabla \mathbf{K}$ , 并且将矩阵  $\mathbf{K}$ 、 $\nabla \mathbf{K}$  分别进行类内和类间中心化;

Step3: 由(3)~(5)式计算散度指标  $S$  和其导数  $\nabla S$ , 使用随机步长最陡下降法, 按照(6)式更新  $e_{\text{before}}$ , 得到  $e_{\text{update}}$ ;

Step4: 令  $n_i = n_i + 1$ , 若  $S \leq S_0$ , 则  $n_d = n_d + 1$ ,  $S = S_0$ ,  $e_{\text{update}} = e_0$ ,  $e_{\text{before}} = e_{\text{update}}$ ,  $\lambda = 0.1$ ; 若  $S > S_0$ , 则  $n_d = 0$ ,  $S_0 = S$ ,  $e_0 = e_{\text{update}}$ ,  $e_{\text{before}} = e_{\text{update}}$ ,  $\lambda = 0.5$ ;

Step5: 判断 Step4 是否满足截止条件, 若  $n_i > n_{\text{max}}$  或  $n_d > n_{\text{delay}}$ , 则迭代结束, 输出  $e_0$ ; 否则, 重复 Step2~Step4 的操作, 继续更新  $e$ 。

### 2.3 基于 SVM 的目标、背景分类

高光谱小目标的检测类似于二分类问题。鉴于目标和背景具有类内聚集和类间分离的分布特点,可以使用分类器分离目标和背景,达到检测目标的目的。由于后验信息是粗糙的(含有较多的错分样本),而支持向量机具有较好的泛化性能,因此使用支持向量机对小目标进行精确检测。

支持向量机依据结构风险最小化准则构造而成,其基本原理是:在数据线性可分的情况下,寻找一个最优的分类超平面,该平面不仅能够将数据进行分类,而且能够使超平面和支持向量之间的距离最大化;若被分类的数据是线性不可分的,则通过引入核函数,将低维空间的数据映射至核空间,使之线性可分,再在核空间寻找超平面<sup>[15]</sup>。

在有后验信息的基础上,使用支持向量机检测小目标的基本步骤如下:

Step1:使用核函数将像元的光谱信息映射至核空间,使目标和背景具有类间线性可分的特点;

Step2:根据后验信息初始化支持向量机的分类超平面;

Step3:在误差系数的允许范围内,自动调整超平面,使该超平面两边的数据具有最大的类间距离;

Step4:使用该超平面将所有像元重新分类为目标或背景;

Step5:根据目标和背景的分类结果,更新核函数的参数与后验信息;

Step6:判断该分类结果是否满足停止迭代的条件,若本次与上次的分类结果不同,则继续迭代检测,重复Step1~Step5的操作;若本次与上次的分类结果相同,则停止迭代,并将该次分类结果作为小目标的最终检测结果。

现以图2(a)所在的某军事基地高光谱遥感图像为例说明该方法的实验过程,其真实目标分布如图2(b)所示,图2(c)为虚警率较高的后验信息,图2(d)~(h)分别为本文方法的迭代检测过程。




图2 本文方法的目标检测过程。(a)波段图像;(b)真实小目标;(c)初检结果;  
(d)1次迭代;(e)2次迭代;(f)3次迭代;(g)4次迭代;(h)5次迭代

Fig. 2 Target detection process of the proposed method. (a) Band image; (b) real small targets; (c) preliminary detection result;  
(d) first iteration; (e) second iteration; (f) third iteration; (g) fourth iteration; (h) fifth iteration

从图2可以看出,后验信息的质量较差,不仅含有较多的背景误检点,而且其小目标的定位较粗糙。以后验信息作为SVM的训练样本并确定其最佳参数,使用该SVM对降维图像中的像元第1次分类后,可以得到图2(d)的检测结果,相对于图2(c),大部分误检点可以被正确分类,只剩余2个误检块;然后,以图2(d)的检测结果作为新的后验信息,重复上述步骤,对像元进行第2次分类得到图2(e)的检测结果,只剩1个误检块,且目标的绝大部分邻域也被正确分类;经过第3次分类后,已经不存在背景误分块,且目标被进一步提纯;第4次的分类结果相对于第3次来说,只调整了一个像元点;第5次分类结果与第4次相同,说明检测结果已经收敛,可以停止分类,得到最终的小目标检测结果。

### 3 实验结果与分析

为了测试所提出的基于自适应参数支持向量机的高光谱小目标检测方法的有效性,进行了大量的小目标检测实验,并与基于经典RX的高光谱小目标检测方法(方法1)、基于核RX的高光谱小目标检测方法(方法2)、基于SVDD的高光谱小目标检测方法(方法3)进行了比较。实验是在AMD Radeon IIN660 Dual-Core Process 3.00 GHz CPU、2 G内存的计算机,Matlab7.0的环境中进行的。方法1和方法2皆使用直方图分割法从参数图像中提取小目标。根据高光谱遥感图像的特点,对4种方法的参数设置为:RX与核RX方法的背景窗口大小为 $11 \times 11$ ,目标窗口大小为 $5 \times 5$ ,直方图分割的参数 $d=2$ ;核RX与SVDD方法的核函数为高斯径向基函数,核参数 $e=1$ ,SVDD方法的误差系数 $\epsilon=1$ ;本文方法的无监督检测方法采用RX方法,其窗口、直方图分割参数、核函数及误差系数均与上述对比方法一致,并交叉使用核空间的散度比和散度差自适应地确定核参数。首先将本文方法与3种对比方法的检测结果进行了比较,以验证本文方法的优越性;然后,针对误检点较多的初检结果做实验,以验证本文方法对后验信息不敏感。由于所涉及的核矩阵计算受到硬件设备的限制,因此采用的实验图像大小均为 $70 \text{ pixel} \times 70 \text{ pixel}$ 。现以图像的形式直观地给出不同方法的检测结果,并定义检测率 $P_d$ 和虚警率 $P_f$ 对检测结果进行定量分析。

$$P_d = \frac{N_{\text{hit}}}{N_{\text{target}}}, P_f = \frac{N_{\text{false}}}{N_{\text{total}}}, \quad (7)$$

式中 $N_{\text{hit}}$ 为检测到的真实目标像元数目, $N_{\text{target}}$ 为真实目标像元总数目,虚警率 $N_{\text{false}}$ 为检测到的虚警像元数目, $N_{\text{total}}$ 为整幅图像像元总数目。

#### 3.1 不同目标检测方法的实验结果比较

以该方法进行了大量实验,以图3~5所在的高光谱遥感图像为例加以说明。图3和图4为某军事基地的高光谱遥感图像,图5为采用机载可见红外成像光谱仪AVIRIS提供的高空高光谱遥感图像。图3~5中(a)和(b)分别为波段图像和真实小目标图像,图3~5中(c)~(f)分别为4种不同方法的检测结果,表1为4种不同方法的结果分析,表2为4种不同方法的检测时间。




图3 不同方法的小目标检测结果。(a) 波段图像;(b) 真实小目标;(c) RX方法;  
(d) 核RX方法;(e) SVDD方法;(f) 本文方法

Fig. 3 Small target detection results by different methods. (a) Band image; (b) real small targets; (c) RX method; (d) kernel RX method; (e) SVDD method; (f) proposed method

从图3可以看出,RX方法得到的小目标检测结果中不但有较多的背景误检点,图像的边缘易被误认为小目标,而且部分目标的成分被漏检;核RX方法相对于RX方法具有较少的误检点,但相对于其他方法而言,该方法的误检情况仍较严重;SVDD方法虽然具有较少的虚警点,但是检测到的目标失真度较大,且会出现目标成分被漏检(图3和图5)或目标邻域被误检测(图4)的情况,因此该方法的检测结果不稳定,其原因为:不同的图像适应于不同的核函数参数;相对于3种对比方法,本文方法不仅可以较全面地检测出小目标,还可以减少误检点,且目标的失真度较小。

从表1可以看出,RX方法虽然具有较高的检测率,但是其虚警率也较高;核RX方法的虚警率比RX方法低,但是其检测率没有RX方法高;SVDD方法具有更低的虚警率,但是其检测率也低,且性能不稳定;相对于3种对比方法,本文方法具有最低的虚警率与较高的检测率,综合检测效果优于3种对比方法。综合以上分

析,本文方法的目标检测性能优于以上3种对比方法。




图4 不同方法的小目标检测结果。(a) 波段图像;(b) 真实小目标;(c) RX方法;  
(d) 核RX方法;(e) SVDD方法;(f) 本文方法

Fig. 4 Small target detection results by different methods. (a) Band image; (b) real small targets; (c) RX method; (d) kernel RX method;  
(e) SVDD method; (f) proposed method




图5 不同方法的小目标检测结果。(a) 波段图像;(b) 真实小目标;(c) RX方法;  
(d) 核RX方法;(e) SVDD方法;(f) 本文方法

Fig. 5 Small target detection results by different methods. (a) Band image; (b) real small targets; (c) RX method; (d) kernel RX method;  
(e) SVDD method; (f) proposed method

表1 不同方法的结果分析

Table 1 Result analysis of different methods

		RX method	Kernel RX method	SVDD method	Proposed method
Fig.3	Detection rate /%	92.49	89.02	58.96	92.49
	False alarm rate /%	3.33	1.71	0.33	0.22
Fig.4	Detection rate /%	96.30	92.59	88.89	93.52
	False alarm rate /%	3.00	1.71	0.78	0.12
Fig.5	Detection rate /%	93.75	87.50	81.25	93.75
	False alarm rate /%	1.71	0.76	0.22	0.12

表 2 不同方法的检测时间

Table 2 Detection time of different methods

		RX	Kernel RX	SVDD	Proposed
		method	method	method	method
Fig.3	Detection time /s	393	410	48	42
Fig.4	Detection time /s	377	415	46	41
Fig.5	Detection time /s	401	408	46	28

从表 2 可以看出,由于 RX 方法与核 RX 方法都需要计算矩阵的逆,因此这两种方法的检测时间较长;相对于前两种方法,SVDD 方法不需要计算矩阵的逆,其检测时间较短;虽然,相对于 SVDD 方法,本文方法的核函数参数自适应确定这一步骤涉及大矩阵的运算,花费的时间较多,但是该方法的总体检测时间略少于 SVDD 方法。这是由于采用无监督检测方法进行小目标的快速、粗糙定位,为 SVM 提供了后验信息,大大缩小了检测范围,加快了检测效率。另外,相对于图 3 和图 4,图 5 的检测时间较短,这是由于图 5 中的目标较少,迭代检测过程中连续两次的检测结果变化较小,迭代收敛较快。

综上所述,相对于 3 种对比方法,本文方法的检测时间较短,检测效率较高。在本文方法中,核函数参数自适应确定步骤占用了 76% 的时间,而无监督检测和支持向量机分类分别只占了 8% 与 16% 的时间,因此后期可以研究快速的核参数确定方法,进一步缩短小目标的检测时间。

### 3.2 本文方法的稳健性分析

在本文方法中,作为后验信息的初检结果不仅受无监督检测方法的影响,还随其参数的调整而改变,因此该初检结果是不确定的。为了使本文方法对于不同的后验信息都有较好的稳健性,采用自适应参数支持向量机对小目标进行迭代检测。为了验证本文方法的稳健性,以图 6(a)所在的高光谱遥感图像的实验结果加以说明,其真实目标分布如图 6(b)所示,图 6(c)~(f)为采用不同的无监督检测方法和参数得到的后验信息,图 6(g)~(j)为不同后验信息对应的最终检测结果。

对比方法的参数设置如下:图 6(c)~(f)都采用直方图分割法<sup>[20]</sup>从参数图像或投影图像中分割出小目标。其中,图 6(c)采用的是 RX 算法,内窗和外窗的直径分别为 7 和 13,直方图的分割参数为 2;图 6(d)采用的是 RX 算法,内窗和外窗的直径分别为 7 和 13,直方图的分割参数为 2;图 6(e)采用的是独立分量分析方法,分




图 6 不同后验信息的最终检测结果。(a) 波段图像;(b) 真实小目标;(c) 初检结果 1;(d) 初检结果 2;(e) 初检结果 3;(f) 初检结果 4;(g) 最终检测结果 1;(h) 最终检测结果 2;(i) 最终检测结果 3;(j) 最终检测结果 4

Fig. 4 Final detection results of different posteriori informations. (a) Band image; (b) real small targets; (c) preliminary detection result 1; (d) preliminary detection result 2; (e) preliminary detection result 3; (f) preliminary detection result 4; (g) final detection result 1; (h) final detection result 2; (i) final detection result 3; (j) final detection result 4



量指标为峰度,选择分量图像的峰度阈值选择 15,直方图的分割参数为 1;图 6(f)采用的是投影寻踪方法,投影指标为偏度,选择投影图像的偏度阈值为 5,直方图的分割参数为 1。

虽然,从图 6(c)~(f)中可以看出,采用不同的无监督检测方法和参数,可以得到不同的后验信息。然而,从图 6(g)~(j)中可以看出,经过自适应参数 SVM 方法迭代检测后,可以得到相似的检测结果(或者只相差几个像素)。因此,对于一幅高光谱小目标图像,本文方法会得到一个固定的小目标检测结果,并且其结果不随无监督检测方法的种类和参数改变,具有较高的稳健性。

## 4 结 论

提出了一种基于自适应参数支持向量机的高光谱小目标检测方法,该方法主要包括主成分分析降维、使用无监督检测方法快速提取后验信息、依据散度准则自适应确定核参数、以及采用支持向量机分类目标和背景四个部分。实验结果表明,与 RX 方法、核 RX 方法、SVDD 方法相比,在检测效果方面:该方法不但有较高的检测率与较低的虚警率,而且检测到的目标失真度较小;在算法稳健性方面:本文方法适用于不同的场景,且目标检测效果不易受无监督检测方法的种类与参数的影响。此外,该方法是一种不需要先验光谱信息的非监督目标检测方法,具有自动检测、精确度较高以及对参数不敏感等特点。

## 参 考 文 献

- 1 Xue Qingsheng. Optical system design of multi-model hyperspectral imager for spaced-based atmospheric remote sensing[J]. *Acta Optica Sinica*, 2014, 34(8): 0822005.  
薛庆生. 空间大气遥感高光谱成像仪光学系统设计[J]. *光学学报*, 2014, 34(8): 0822005.
- 2 Zhao Chunhui, Li Xiaohui, Wang Yulei. Research advance on anomaly detection for hyperspectral imagery[J]. *Journal of Electronic Measurement and Instrumentation*, 2014, 28(8): 803-811.  
赵春晖, 李晓慧, 王玉磊. 高光谱图像异常目标检测研究进展[J]. *电子测量与仪器学报*, 2014, 28(8): 803-811.
- 3 Mei Feng, Zhao Chunhui, Wang Ligu, *et al.*. Support vector data description based on adaptive anomaly detection method in hyperspectral imagery[J]. *Acta Photonica Sinica*, 2009, 38(11): 2820-2825.  
梅 锋, 赵春晖, 王立国, 等. 基于支持向量描述的自适应高光谱异常检测算法[J]. *光子学报*, 2009, 38(11): 2820-2825.
- 4 Zhang L, Zhang L, Tao D, *et al.*. Hyperspectral remote sensing image subpixel target detection based on supervised metric learning [J]. *Geoscience and Remote Sensing, IEEE Transactions on*, 2014, 52(8): 4955-4965.
- 5 Liu Xiaogang, Zhao Huijie, Li Na. Feature extraction based on multifractal spectrum for hyperspectral data[J]. *Acta Optica Sinica*, 2009, 29(3): 844-848.  
刘小刚, 赵慧洁, 李 娜. 基于多重分形谱的高光谱数据特征提取[J]. *光学学报*, 2009, 29(3): 844-848.
- 6 Han Qijin, Pan Zhiqiang, Zhang Xuwen, *et al.*. Tge cross\_calibration of GF- 1 WFV and SJ- 9A PMS sensors based on homogeneous land surface targets[J]. *Acta Optica Sinica*, 2014, 34(11): 0628003.  
韩启金, 潘志强, 张学文, 等. 基于均匀目标的 GF-1WFV 与 SJ-9A PMS 相机交叉定标[J]. *光学学报*, 2014, 34(11): 06281003.
- 7 Huang Z, Shi Z, Yang S. Nonlocal similarity regularized sparsity model for hyperspectral target detection[J]. *Geoscience and Remote Sensing, IEEE Transactions on*, 2013, 10(6): 1532-1536.
- 8 Song Yigang, Wu Zebin, Sun Le, *et al.*. A novel spectral- spatial sparse method for hyperspectral target detection[J]. *Acta Armementarii*, 2014, 35(6): 834-841.  
宋义刚, 吴泽彬, 孙 乐, 等. 一种新的空谱联合稀疏高光谱目标检测方法[J]. *兵工学报*, 2014, 35(6): 834-841.
- 9 Reed I S, Yu L X. Adaptive multiple-band CFAR detection of an optical pattern with unknown spectral distribution[J]. *Acoustics, Speech and Signal Processing, IEEE Transactions on*, 1990, 38(10): 1760-1770.
- 10 He Lin, Pan Quan, Di Wei, *et al.*. A small-target detector based on single likelihood test for hyperspectral imagery[J]. *Acta Optica Sinica*, 2007, 27(12): 2155-2162.  
贺 霖, 潘 泉, 邸 韡, 等. 一种基于单似然检验的高光谱图像小目标检测器[J]. *光学学报*, 2007, 27(12): 2155-2162.
- 11 Matteoli S, Diani M, Corsini G. A tutorial overview of anomaly detection in hyperspectral images[J]. *Aerospace and Electronic Systems Magazine, IEEE*, 2010, 25(7): 5-28.
- 12 Kwon H, 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.

- 13 Banerjee A, Burlina P, Diehl C. A support vector method for anomaly detection in hyperspectral imagery[J]. *Geoscience and Remote Sensing, IEEE Transactions on*, 2006, 44(8): 2282–2291.
- 14 Mei Feng, Zhao Chunhui, Wang Liguo, *et al.*. Support vector data description based on adaptive anomaly detection method in hyperspectral imagery[J]. *Acta Photonica Sinica*, 2009, 38(11): 2820–2825.  
梅 锋, 赵春晖, 王立国, 等. 基于支持向量描述的自适应高光谱异常检测算法[J]. *光子学报*, 2009, 38(11): 2820–2825.
- 15 Liu Nannan, Xu Shuyan, Hu Jun, *et al.*. Hyper accuracy star location algorithm based on nonsubsampled Contourlet transform and mapped least squares support vector machine[J]. *Acta Optica Sinica*, 2013, 33(5): 0512001.  
刘南南, 徐抒岩, 胡 君, 等. 基于非下采样 Contourlet 变换和映射最小二乘支持向量机的高精度星点定位方法[J]. *光学学报*, 2013, 33(5): 0512001.
- 16 Song Fengxi, Zang Dapeng, Yang Jingyu, *et al.*. Adaptive classification algorithm based on maximum scatter difference discriminant criterion[J]. *Acta Automatica Sinica*, 2006, 32(4): 541–549.  
宋枫溪, 张大鹏, 杨静宇, 等. 基于最大散度差鉴别准则的自适应分类算法[J]. *自动化学报*, 2006, 32(4): 541–549.
- 17 Zhang Jingjing, Zhou Xiaoyong, Liu Qi. Improved dimensionality reduction algorithm of large-scale hyperspectral scenes using manifold[J]. *Acta Optica Sinica*, 2013, 33(11): 1120001.  
张晶晶, 周晓勇, 刘 奇. 一种改进的大尺度高光谱流形降维算法[J]. *光学学报*, 2013, 33(11): 1120001.
- 18 Chen Yang, Zhang Taining, Guo Peng, *et al.*. Quantitative analysis for nonlinear fluorescent spectra based on principle component analysis[J]. *Acta Optica Sinica*, 2009, 29(5): 1285–1291.  
陈 扬, 张太宇, 郭 澎, 等. 给予主成分分析的复杂光谱定量分析方法的研究[J]. *光学学报*, 2009, 29(5): 1285–1291.
- 19 He Songhua, Liu Zhen, Chen Qiao. Research of spectral dimension reduction method based on matrix  $\tilde{R}$  theory[J]. *Acta Optica Sinica*, 2014, 34(2): 0233001.  
何颂华, 刘 真, 陈 桥. 基于矩阵  $\tilde{R}$  理论的光谱降维方法研究[J]. *光学学报*, 2014, 34(2): 0233001.
- 20 Wu Chao, Wu Yiquan. Target detection in hyperspectral image using projection pursuit based on chaotic particle swarm optimization [J]. *Acta Optica Sinica*, 2011, 31(12): 1211003.  
吴 超, 吴一全. 基于混沌粒子群优化投影寻踪的高光谱图像目标检测[J]. *光学学报*, 2011, 31(12): 1211003.
- 21 Lu Wei, Yu Xuchu, Ma Yonggang, *et al.*. Research of sea fleet targets detection approach in hyperspectral image [J]. *Hydrographic Surveying and Charting*, 2005, 25(4): 8–12.  
路 威, 余旭初, 马永刚, 等. 高光谱遥感影像海上舰船目标检测方法的研究[J]. *海洋测绘*, 2005, 25(4): 8–12.

栏目编辑: 苏 芬