

基于 1 类 SVM 的高分辨雷达真假目标识别

廖东平

(国防科技大学电子科学与工程学院空间电子信息技术研究所, 长沙 410073)

摘要: 本文将高分辨雷达目标检测问题等效为真假目标识别问题, 并针对现有的高分辨雷达目标检测算法的缺陷, 借鉴处理异常值问题的思想, 首次将 1 类 SVM 引入高分辨雷达目标检测之中, 为解决高分辨雷达目标检测问题提供了一条崭新的思路。同时针对现有的 1 类 SVM 对数据域描述的不足, 结合高分辨雷达目标数据分布的特点, 提出了一种聚类式的 1 类 SVM 模型, 通过对训练的正类样本的聚类分组, 用多个小的超球来代替原来的 1 个大的超球, 从而更准确的实现了对数据域的描述。最后针对存在多类真目标的情况, 提出了对每一类真目标分别进行处理的方法, 以满足后续真目标类型识别的需要。雷达实测数据实验结果表明本文算法是有效的。

关键词: 高分辨雷达目标检测; 真假目标识别; 1 类 SVM; 数据域描述

中图分类号: TN959 **文献标识码:** A **文章编号:** 1003-0530(2010)05-0746-07

True-False Target Recognition In High Resolution Radar Based on One-Class SVM

LIAO Dong-ping

(Research Institute of Space Electronics Information technology, National University of Defense Technology, Changsha 410073)

Abstract: The problem of high resolution radar target detection is taken as the problem of true-false target recognition in this paper. In allusion to the shortcoming of the existing high resolution radar target detection algorithm, and by borrowing ideas from the dealing with novelty problem, one-class SVM is introduced to high resolution radar target detection for the first time. That can provide a new idea for solving high resolution radar target detection problem. At the same time, in allusion to the incompleteness of one-class SVM in describing data domain, and combing the data distribution characteristics of the high resolution radar object, a cluster one-class SVM model is proposed. It conducts training positive kind based on clustering, uses several small spheres instead of previously one big sphere, and gives more accurate description of the data domain. At last, in allusion to the condition of the existing several kinds of true targets, a method that deals with every single kind of true target separately is proposed to satisfy with the need of the succeeding true target type identifying. Experiments with radar raw data show the validity of this algorithm.

Key words: High resolution radar target detection; True-false target recognition; One-class SVM, Data domain description

1 引言

对于毫米波高分辨雷达(MW-HRR)来说,目标回波为多散射点形成的一维距离像[1,2],而雷达杂波的幅度分布明显偏离通常的瑞利分布[3,4],特别是像丘陵、水坑等不规则杂波源,它们的回波幅度分布更复杂,很难用统一的参数模型来拟合这些不规则的杂波统计特性分布,即使能给出它们的分布模型,其对应的

模型参数也需要进行实时自适应估计。对于要求处理速度苛刻的实时处理问题(机载毫米波雷达对地探测等),显然是不能满足要求的。因此,一般考虑用非参数模型的方法来检测隐藏在杂波背景中的目标信号。

雷达目标检测中恒虚警(CFAR)处理的一个主要目的就是防止干扰和杂波使显示器画面或数据处理机过载,但是由于 CFAR 处理总存在恒虚警损失,在信杂比(S/C)较高的情况下,CFAR 处理没有必要存在[5]。

因此,对于高分辨雷达目标检测问题,直接基于雷达目标或杂波等假目标的一维距离像信息,就足够用以检测出感兴趣的目标信号[6]。

基于以上考虑,文献[7,8]提出了一种基于目标散射点位置相关的高分辨雷达目标检测算法。该算法对于存在杂乱脉冲干扰(由丘陵、水坑、毁坏的人工目标等形成)的情况,能够辨别出假目标,将感兴趣的真目标完好地检测出来。但该算法的使用,是以感兴趣的人工真目标(如车辆、坦克等)的尺寸大于杂波等假目标的尺寸为前提的,而事实上,这一前提并不一定成立,因此会造成大量虚警的存在。

从本质上讲,目标检测问题实际上是一个两类目标的分类问题,在高分辨雷达目标检测中即为对真目标和杂波等假目标进行区分的真假目标识别问题。但是高分辨雷达目标检测领域中能够获得的数据往往呈现出小样本性和高维性,这样的数据对于这些传统的分类方法而言是很大的难题。基于统计学习理论(Statistical learning theory,简称SLT)的支持向量机(Support vector machine,简称SVM),是由Vapnik等人提出的一种全新的机器学习方法[9]。它建立在结构风险最小化原则基础之上,具有很强的学习能力和泛化性能,能够较好地解决小样本、高维数、非线性、局部极小等问题[10]。

标准的SVM主要处理两类目标的分类问题,并且具有相当好的结果。但是,根据高分辨雷达目标检测中数据的特点,真假两类目标的所获样本分布往往呈现出不平衡性,而这种不平衡将严重影响分类性能[11]。1类SVM[12-15]是SVM的一种扩展,它是针对异常值检测问题提出的,将异常值检测视为一类分类问题[16-18]。由于只是对正常值数据构建分类面,而不需要关心异常值数据的分布情况,从而克服了由于样本不平衡带来的问题,并取得了好的效果。

本文借鉴处理异常值检测问题的思想,首次将1类SVM引入高分辨雷达目标检测之中,有效地解决了由于无法获得完整的假目标数据而带来的分类误差问题,为解决高分辨雷达目标检测问题提供了一条崭新的思路。

2 SVM 算法简介

标准的SVM的核心思想是:对于输入空间中非线性可分的情形,选择一个适当的非线性映射,将输入空间中的样本点映射到一个高维的特征空间,使得对应的样本点在该特征空间中是线性可分的。SVM算法对于两类目标的分类问题,有许多成功的应用实例[9]。

本文将杂波等假目标数据规定为负样本,而将感兴趣的人工真目标数据规定为正样本。根据SVM理论,2类SVM分类器的分类超平面由靠近分类超平面的支持向量(Support vector,简称SV)决定,而在实际操作中,只需要选用比较靠近分类面的样本点即可。但是,由于高分辨雷达所处环境的复杂性,对真目标构成干扰的假目标的数量和种类是非常多的,这也意味着很难获得完整的假目标的信息,因而与所获正样本数据情况不同的是,通常所能获得的负样本数据与实际中的负样本数据相比,比例是非常少的,而这种不足会严重影响分类器的泛化性能,并将直接导致分类器的错误率太高。这是因为SVM在各类别样本数差异较大时,会明显倾向于样本数多的大类别,样本数少的类别的训练误差和预测误差较大,而样本数多的类别的训练误差和预测误差较小[11]。

尽管已有一些办法来补偿这种倾向性造成的影响,比如采用对样本差异或类别差异进行加权的办法[19-20],权值的计算主要是基于两类样本的数量差异。但是在高分辨雷达目标检测中,两类样本的差异并不一定表现在数量上的差异,当两类样本的数量相差无几时,这种补偿作用就显得不够明显了。因此,SVM至今仍没有应用到高分辨雷达目标检测这一重要的领域。本文将讨论用一种基于1类SVM的方法,构造一种可应用于高分辨雷达目标检测的SVM方法。

3 1类SVM 算法简介

1类SVM的实现方法有两条途径,一条是根据构造超球面的方法来实现[12,13],另一条是通过构造与原点分离的超平面来实现[14,15],两种方法在选择高斯核函数的情况下是等价的[15]。无论采用哪一种途径,目的都是对正类样本进行数据域描述,以拒绝来自负类样本的数据。在本文中采用第一种方法,选择高斯核函数: $K(x,y) = \exp(-|x-y|^2/2s^2)$, s 为核宽参数。关于该方法的详细介绍见上述文献。

在具体应用时,需要进一步确定的参数有惩罚因子 C 和核宽参数 s ,这两个参数共同决定了SV的个数以及超球面的形状。下面以 s 为例说明不同参数对超球面形状的影响:

利用1类SVM对一个简单样本集(2维)进行分类,该样本集有45个正样本和20个负样本。图1给出了在 s 取不同值时(0.05,0.12,1)所得到的分类轮廓面,其中“+”代表正样本,“x”代表负样本,“O”代表正样本的SV。

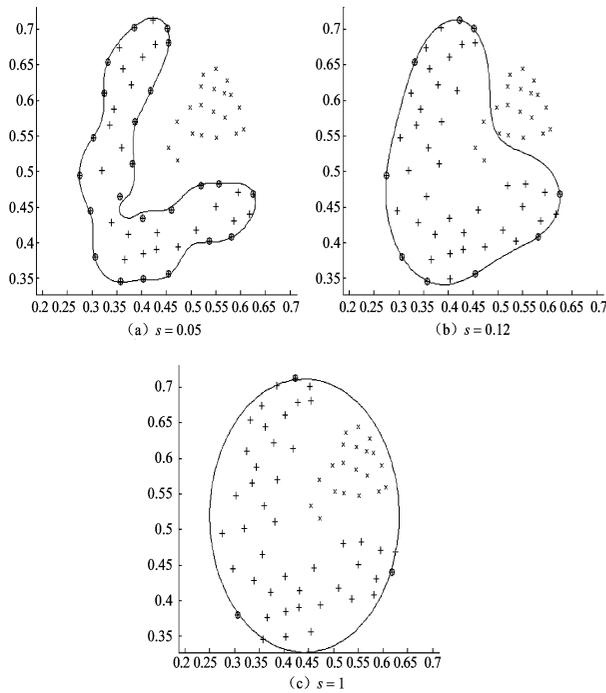


图1 核宽参数 s 对 1 类 SVM 的影响 ($C = 1$)

由图 1 可以看出,当 s 取值较小时 ($s = 0.05$),能很好的将两类样本分开,但是对正类样本的数据域描述是比较紧的,其分类轮廓面是比较复杂的,并且 SV 的个数 (23 个) 也是比较多的,可能会影响正类样本分类的推广能力。这是因为根据 SVM 理论[9],在训练样本个数一定的情况下,分类器的推广能力只与 SV 的个数有关:

$$E[P(\text{error})] = \frac{\#SV}{N} \quad (1)$$

其中 $\#SV$ 为 SV 的个数,SV 越多,表明对测试样本分类错误的期望越大。图 1(a) 给出的正类样本分类错误期望为 51.11%。

因此,当 SV 的个数较多的时候,应该增大 s 的值,以获得一个较好地正类样本分类的推广能力。图 1(b) 和图 1(c) 给出了 s 分别在 0.12 和 1 的情况下的分类轮廓面,其 SV 的个数分别为 9 个和 3 个,相应的正类样本分类错误期望分别为 20% 和 6.67%,并且其数据域进一步扩大,分类轮廓面也逐渐趋于光滑。因此,通过设定正类样本分类错误期望,就可实现对参数 C 和 s 的优化选择。

但是由图 1 还可以看出,在增大 s 的同时,不但增大了正类样本的数据域,提高了对正类样本的分类精度,也增大了负类样本落入该区域的可能性,牺牲了对负类样本的分类精度。如何选择 C 和 s 以达到两类分类精度的平衡,需要在实际应用中根据经验来调整。

4 构造适用于高分辨雷达目标检测的 1 类 SVM 分类器

应该指出,现有的 1 类 SVM 算法是以牺牲负类样本的分类精度来提高正类样本的分类精度的,这在异常值检测问题中是适用的,因为异常值数量相对正常值数量来讲比例是非常少的,并且这二者所处的地位是不同的。但是对于高分辨雷达目标检测问题来讲,杂波等假目标的数量反倒比真目标数量要大的多,而且这二者的地位是对等的,因此直接将现有的 1 类 SVM 引入进来可能会带来一些问题。

事实上,1 类 SVM 的思想就在于对训练类样本的一种数据域描述,如果这种数据域的描述是准确的,不但对于训练类的分类能达到一定的精度,对于异类的分类也应该能达到一定的精度。文献[12,13]提出的数据域描述方法,是以构造超球面的方式来实现的。如果一个类的样本分布符合超球状分布,那么这种描述就是准确的,也能够取得比较好的结果,后面的仿真实验将说明这一点。但如果一个类的样本分布不符合超球状分布,此时利用超球面来描述该类样本,显然是不合适的。因此,在无法获知样本空间分布的情况下,能否构造准确的对正类样本的数据域描述,将是 1 类 SVM 能否应用于高分辨雷达目标检测的关键。

本文对此进行了研究,在结合高分辨雷达目标数据分布特点的基础上,提出了一种聚类式的 1 类 SVM 算法。首先利用 K -均值算法对训练的正类样本进行分组,然后对每一个分组分别进行训练以获得多个子 1 类 SVM,最后测试时对每一个子 1 类 SVM 的输出结果进行综合处理以获得最后的结果。该算法的主要思想是用多个小的超球来代替原来的 1 个大的超球,从而能够更准确的实现对数据域的描述,在保证正类样本分类精度的同时,提高负类样本的分类精度。

4.1 K -均值算法简介[21]

K -均值算法是一种动态聚类方法,从初始聚类开始,运用迭代算法动态地改变样本的类别和聚类的中心使准则函数取得极值或设定的参数达到设计要求时停止。在本文中,用以下方法来解决动态聚类方法的 3 个要点:(1)选择欧氏距离度量作为样本间的相似性度量;(2)确定误差平方和准则作为确定评价聚类结果质量的准则函数;(3)用密度法(具体见文献[21])选择代表点作为初始分类中心,然后用迭代算法找出使准则函数取得极值的最好聚类结果。

采用 K -均值算法首先要确定类别数 K 。显然准

则函数值是随着 K 的增加而单调减少的,因而 K 越大,聚类的效果应该就越好。但是,大的 K 将增加后期处理的运算量,并且当 K 增加到某一个值时,准则函数值虽有所减少,但减少的速度将比较缓慢。因而对于 K 的确定,要根据实际情况来综合考虑。

4.2 用于高分辨雷达目标检测的聚类式的1类SVM

文献[12,13]提出的数据域描述方法,是以构造超球面的方式实现的,这在某类样本分布符合超球状分布时能够取得比较好的结果,但在其它情况下,其结果不是很理想。因此,在应用1类SVM时,应该根据实际情况构造适合的数据域描述。

高分辨雷达目标检测是根据雷达目标的一维距离像信息来实现对目标是否真假目标的判断,一维距离像反映了目标的几何形状和结构特征。但一维距离像敏感于目标姿态角的变化,在不同的目标姿态角下,同一目标的一维距离像可以完全不同。这说明,只采用一个样本均值作为一个类的代表点是无法反映整个样本在空间的分布的,这也可以理解为,雷达目标的一维距离像在一般情况下是不满足超球状分布的。

既然只用一个样本均值不能够反映整个样本的空间分布,一种直观的解决办法是采用多个样本均值来作为类的代表点,采用 K -均值算法对样本进行分组的方式来实现。这相当于在对样本分布进行描述时,用多个小的超球代替了原来的一个大的超球,这样就能够更好的贴近样本本来的空间分布,实现对数据域的准确描述。

设训练的正类样本集为 $\{x_i, i = 1, \dots, N\}, x_i \in R^l$, 根据上述的 K -均值算法将样本分成 K 组,各组分开写成 $\{x_1^{(s)}, \dots, x_{N_s}^{(s)}, s = 1, \dots, K\}$, 其中 $\{x_i^{(s)}, i = 1, \dots, N_s\}$ 表示第 s 组训练的正类样本, $N_1 + \dots + N_K = N$ 。分别对每一组样本实行上述的1类SVM处理,从而获得 K 个子1类SVM,以及超球体中心 $a_s, s = 1, \dots, K$ 和半径 $R_s, s = 1, \dots, K$ 。

给定待识别样本 x , 分别计算在 K 个子1类SVM下的输出结果 $\{y_s, s = 1, \dots, K\}, y_s \in \{+1, -1\}$, 则最后的结果应该是 K 个子1类SVM判决结果的综合,判决函数如下:

$$f(x) = \begin{cases} +1, & \sum_{s=1}^K y_s \neq -K \\ -1, & \sum_{s=1}^K y_s = -K \end{cases} \quad (2)$$

若 $f(x) = +1$, 则可判定其为正样本, 否则判定为负样本。

4.3 多类真目标情况下的处理

在实际的高分辨雷达目标检测中,感兴趣的真目标种类有可能不止一种,这将为目标检测带来困难。幸运的是,本文在上一小节中构造的可用于高分辨雷达目标检测的聚类式的1类SVM,所针对的对象不仅仅只是一类真目标,在存在多类真目标的情况下,该方法也是适用的。因此,直接将多类真目标数据混合在一块进行处理,也能够得到比较好的结果。

但是在实际中需要考虑更高层次的问题,即对于真目标的处理,不仅仅只是将其从存在杂波等假目标的环境中检测出来,还需要考虑对所检测出来的真目标进行进一步识别的问题。因此,在对目标检测的过程中,若能将其真目标的类型识别出来,将是非常理想的。退一步讲,就算不能很准确的将真目标的类型识别出来,但如果能够为后续识别过程提供一定的信息,也是比较让人满意的。因此,针对存在多类真目标的情况,对每一类真目标分别进行处理,将是一种比较合适的处理方法。

对于存在 $M (M \geq 2)$ 类真目标的高分辨雷达目标检测问题,设经过训练后得到 M 个判决函数,则第 m 个判决函数为

$$f_m(x) = \begin{cases} +1, & \sum_{s=1}^{K_m} y_s \neq -K_m \\ -1, & \sum_{s=1}^{K_m} y_s = -K_m \end{cases} \quad (3)$$

式中 K_m 表示第 m 类真目标按照上述 K -均值算法所得到的分组数。最后的结果应该是 M 个判决函数的综合,最终判决函数如下:

$$f(x) = \begin{cases} +1, & \sum_{m=1}^M f_m(x) \neq -M \\ -1, & \sum_{m=1}^M f_m(x) = -M \end{cases} \quad (4)$$

对于检测出来的真目标,还可以进一步对其类型进行识别。显然,如果真目标 x 唯一地满足

$$f_m(x) = +1 \quad (5)$$

则可以判定 x 属于第 m 类真目标。但是如果真目标 x 满足多个 $f_m(x) = +1$, 则可以通过下面的方法进行处理。

假设有 L 个 $f_l(x) = +1, l = 1, \dots, L$, 则对于第 l 类真目标,实行上述的1类SVM处理,获得 K_l 个子1类SVM,以及超球体中心 $a_s, s = 1, \dots, K_l$ 和半径 $R_s, s = 1, \dots, K_l$ 。计算真目标 x 到各个中心点的归一化距离如下:

$$\lambda_s = \frac{(\phi(x) - a_s)^T (\phi(x) - a_s)}{R_s}$$

$$= \left[1 - 2 \sum_{i=1}^{N_s} \alpha_i^{(s)} K(x, x_i^{(s)}) + \sum_{i=1}^{N_s} \sum_{j=1}^{N_s} \alpha_i^{(s)} \alpha_j^{(s)} K(x_i^{(s)}, x_j^{(s)}) \right] / R_s$$

$$s = 1, \dots, K_l \quad (6)$$

对 λ_s 进行归一化处理的目的是为了消除由于不同的子 1 类 SVM 参数对距离计算的影响,即 λ_s 是识别样本 x 到各个中心点的相对距离,并取 λ_s 的最小值作为 x 到第 l 类真目标的相对距离:

$$\lambda_l = \min \lambda_s, s = 1, \dots, K_l \quad (7)$$

重复以上过程,可分别得到真目标 x 相对 L 类真目标的相对距离 $\lambda_l, l = 1, \dots, L$ 。

从一定意义上讲, λ_l 的大小反映了真目标 x 归属第 l 类真目标的程度, λ_l 越小,表明真目标 x 离第 l 类真目标越近,亦即 x 越可能是第 l 类真目标,反之亦然。因此根据 λ_l 的值,选择使 λ_l 值最小所对应的两类,即可确定 x 的类别范围。最后再利用 2 类 SVM 对其进行进一步识别。

因此,针对多类真目标情况下的处理,采用对每一类真目标分别进行处理的方法,不但可实现对每一类真目标优化处理的并行操作,提高程序的运行速度,而且可以为后续的识别提供一定的信息,甚至能直接将真目标的类型识别出来。

5 实验结果

实验数据来自某机载雷达实测一维距离像数据集,样本类型共 4 种,分别为卡车、轮式装甲车、坦克和杂波等假目标,样本维数为 32(不包括分类属性)。数据采集时,卡车、轮式装甲车和坦克等目标分别以一定速度绕小圈行驶,雷达架在高处对其进行照射,实验场地的地杂波后向散射系数 $\gamma = 0.15$ 。将卡车、轮式装甲车和坦克数据作为正样本,杂波等假目标数据作为负样本,实验数据组成如表 1 所示。

表 1 实验数据组成

个数		卡车实验	轮式装甲车实验	坦克实验	三类真目标实验
训练样本	正样本	286	286	286	858
	负样本	286	286	286	858
	全体训练样本	572	572	572	1716
测试样本	正样本	1192	1749	1369	4310
	负样本	9000	9000	9000	9000
	全体测试样本	10192	10749	10369	13310

分别对上面提出的算法进行实验,其中:算法一为基于目标散射点位置相关的高分辨雷达目标检测算法;算法二为 2 类 SVM 算法;算法三为现有的 1 类 SVM 算法;算法四为本文提出的聚类式的 1 类 SVM 算法,实验结果分别如表 2-5 所示。实验中参数的设置为:算法一的第一参数为 0.27,第二参数为 5;算法二的实验参数 $C = 100, s = 0.5$;算法三和四的实验参数 C 和 s 的选择以满足测试样本分类错误期望(见式(1))低于 10% 为准则,算法四的 K -均值聚类组数为 5。

由表 2-5 可以看出,本文提出的聚类式的 1 类 SVM 算法性能要明显优于基于目标散射点位置相关的高分辨雷达目标检测算法性能,同时由于实现了比较准确的对数据域的描述,克服了由于训练负类样本的不足而带来的分类误差问题,因此相比较 2 类 SVM 算法和现有的 1 类 SVM 算法,性能也有较明显的优势。

表 2 卡车的实验结果

分类精度		算法一	算法二	算法三	算法四
训练样本	正样本	96.853%	100%	92.657%	96.154%
	负样本	94.406%	100%	66.434%	98.951%
	全体训练样本	95.629%	100%	79.545%	97.552%
测试样本	正样本	96.309%	92.953%	89.849%	88.758%
	负样本	59.956%	64.578%	38.178%	88.267%
	全体测试样本	64.207%	67.896%	44.221%	88.324%

表 3 轮式装甲车的实验结果

分类精度		算法一	算法二	算法三	算法四
训练样本	正样本	91.608%	100%	93.007%	96.503%
	负样本	84.266%	100%	90.909%	91.608%
	全体训练样本	87.937%	100%	91.958%	94.056%
测试样本	正样本	86.735%	90.966%	90.738%	88.565%
	负样本	50.033%	73.233%	81.089%	90.844%
	全体测试样本	56.005%	76.119%	82.659%	89.705%

表 4 坦克的实验结果

分类精度		算法一	算法二	算法三	算法四
训练样本	正样本	86.364%	100%	100%	94.056%
	负样本	84.266%	100%	67.832%	94.056%
	全体训练样本	85.315%	100%	83.916%	94.056%
测试样本	正样本	85.756%	89.993%	89.189%	84.149%
	负样本	37.556%	74.178%	75.089%	86.844%
	全体测试样本	43.919%	76.266%	76.951%	86.489%

表 5 三类真目标的实验结果

分类精度		算法一	算法二	算法三	算法四
训练样本	正样本	88.462%	100%	86.364%	96.154%
	负样本	87.762%	100%	41.142%	82.984%
	全体训练样本	88.112%	100%	63.753%	89.569%
测试样本	正样本	85.870%	91.879%	86.845%	90.186%
	负样本	52.322%	69.200%	33.356%	75.044%
	全体测试样本	63.186%	76.544%	50.676%	79.947%

单独分析现有的 1 类 SVM 算法的实验结果可以看出,在三类真目标的分类精度相差无几的情况下(分别为 89.849%、90.738% 和 89.189%),当真目标为轮式装甲车时的负类样本的分类精度最高,达到了 81.089%,这说明现有的 1 类 SVM 的使用,并不一定会严重影响负类样本的分类精度。但是当真目标分别为坦克和卡车时,其负类样本的分类精度下降为 75.089% 和 38.178%。此结果从一定意义上反映了三类真目标数据的空间分布,验证了上文中的分析,同时也说明了现有的 1 类 SVM 算局局限性。

表 6-8 给出了对于存在多类真目标的情况,采用本文提出的聚类式的 1 类 SVM 算法时,对真目标类型识别的初步结果。由表 6-8 可以看出,对于三类真目标的初步识别,分别有 1003 个卡车数据,480 个轮式装甲车数据和 895 个坦克数据被直接识别出来,分别占其总数的 84.144%、27.444% 和 65.376%,需要进一步识别的卡车数据为 54 个,轮式装甲车数据为 1065 个,坦克数据为 257 个,仅有 1 个卡车数据和 4 个轮式装甲车数据被识别为其它的真目标类型。这说明,对于存在多类真目标的情况,采用分别对每一类真目标分别进行处理的方法,能够为后续的真目标的类型识别提供一定的信息,甚至能直接将真目标识别出来。

表 6 三类真目标情况下卡车的识别结果

识别结果 个数 真目标	卡车	卡车/ 轮式装甲车	卡车/ 坦克	轮式装甲车/ 坦克	假目标
	卡车	1003	51	3	1

表 7 三类真目标情况下轮式装甲车的识别结果

识别结果 个数 真目标	轮式 装甲车	轮式装甲车/ 卡车	轮式装甲车/ 坦克	卡车/ 坦克	假目标
	轮式装甲车	480	151	914	4

表 8 三类真目标情况下坦克的识别结果

识别结果 个数 真目标	坦克	坦克/ 卡车	坦克/ 轮式装甲车	卡车/ 轮式装甲车	假目标
	坦克	895	62	195	0

6 结束语

本文首次将 1 类 SVM 引入高分辨雷达目标检测之中,为解决高分辨雷达目标检测问题提供了一条崭新的思路。同时针对现有的 1 类 SVM 对数据域描述的不足,结合高分辨雷达目标数据分布的特点,提出了一种聚类式的 1 类 SVM 模型,通过对训练的正类样本的聚类分组,用多个小的超球来代替原来的 1 个大的超球,从而更准确的实现了对数据域的描述。最后针对存在多类真目标的情况,提出了对每一类真目标分别进行处理的方法,以满足后续真目标类型识别的需要。雷达实测数据实验结果表明本文算法是有效的。

参考文献

- [1] Wehner D. R, High Resolution Radar[M], Boston: Artech House, 1987.
- [2] Mensa D. L, High Resolution Radar Imaging[M], Boston: Artech House, 1981.
- [3] Eaves J. L, Reedy E. K, Principles of Modern Radar [M], New York: Van Nostrand Reinhold Company New York, 1987.
- [4] Currie N. C, Hayes R. D, Trebits R. N, Millimeter-Wave Radar Clutter [M], Boston, London: Artech House, 1992.
- [5] Barkat M, Himonas S. D, Varshney P. K, CFAR Detection for Multiple Situation[J], IEE Proceedings F, 1989, 136(5): 193-209.
- [6] 黄德双,高分辨雷达智能信号处理技术[M],北京:机械工业出版社,2001.
- [7] 黄德双,韩月秋,基于位置相关的高分辨雷达目标检测方法研究[J],电子科学学刊,1997,19(5):584-590.
- [8] Huang D. S, Han Y. Q, A Detection Method of High Resolution Radar Targets Based on Position Correlation [J], Journal of Electronics, 1998, 15(2): 107-115.
- [9] Vapnik V. N, The Nature of Statistical Learning Theory [M], New York: Springer, 1995.
- [10] Burges C. J. C, A Tutorial on Support Vector Machines for Pattern Recognition [M], Boston: Kluwer Academic Publishers, 1998.

- [11] Hong-Gunn Chew, Crisp D. J, Bogner R. E, Target Detection in Radar Imagery Using Support Vector Machine with Training Size[A], Proceedings of the Sixth International Conference on Control, Automation, Robotics and Vision[C], Singapore, 2000.
- [12] Tax D. M. J, Duin R. P. W, Data Domain Description Using Support Vectors[A], In: Verleysen M, Edits, Proceedings of the European Symposium on Artificial Neural Networks[C], Brussels, Belgium: Facto D Press, 1999: 251-256.
- [13] Tax D. M. J, Duin R. P. W, Support Vector Data Domain Description[J], Pattern Recognition Letters, 1999, 20:1191-1199.
- [14] Scholkopf B, Williamson R. C, Smola A. J, Taylor J. S, Platt J. C, Estimating the Support of a High-Dimensional Distribution[A], Technical Report MSR-TR-99-87, Microsoft Research, Redmond, WA, 1999.
- [15] Scholkopf B, Platt J. C, Taylor J. S, Smola A. J, Williamson R. C, Estimating the Support of a High-Dimensional Distribution[J], Neural Computation, 2001, 13(7): 1443-1471.
- [16] Kunlun Li, Houkuan Huang, Shengfeng Tian, Wei Xu, Improving One-Class SVM for Anomaly Detection[C], Proceedings of the Second International Conference on Machine Learning and Cybernetic, Xi'an, 2003(4): 3077-3081.
- [17] 李辉,管晓鸿,咎鑫,韩崇昭,基于支持向量机的网络入侵检测[J],计算机研究与发展,2003,40(6):799-807.
- [18] Yanxin Wang, Johnny Wong, Andrew Miner, Anomaly Intrusion Detection Using One Class SVM[C], Information Assurance Workshop, Proceedings from the Fifth Annual IEEE SMC, 2004: 358-364.
- [19] Hong-Gunn Chew, Bogner R. E, Cheng-Chew Lim, Dual ν -Support Vector Machine with Error Rate and Training Size Biasing[A], Proceedings of the 26th IEEE International Conference on Acoustics, Speech, and Signal Processing[C], Salt Lake City, UT, USA, 2001: 1269-1272.
- [20] 范昕炜,杜新树,吴铁军,可补偿类别差异的加权支持向量机算法[J],中国图像图形学报,2003,8(9):1037-1042.
- [21] 边肇祺,张学工,模式识别(第二版)[M],北京:清华大学出版社,2000.

作者简介



廖东平(1977-),男,湖南邵阳人,博士,讲师。主要从事雷达目标识别,支持向量机等研究。获军队科技进步一等奖1项,军队科技进步二等奖1项。在国内外核心期刊和会议上共发表学术论文20余篇。E-mail:ldpcho@tom.com