基于训练特征空间分布的雷达地面目标鉴别器设计

李龙 刘峥*

(西安电子科技大学雷达信号处理国家重点实验室 西安 710071)

摘 要: 该文对雷达地面目标高分辨1维距离像目标识别中的库外目标鉴别问题,提出一种基于训练特征空间分布 的雷达地面目标鉴别器。在训练阶段利用基于相关系数预处理的 K-Means 聚类方法对库内目标样本特征空间进行 区域划分,并采用基于空间分布的支撑向量域描述方法确定样本特征空间的边界与支撑向量,利用样本特征空间边 界与加权 K 近邻原则对目标类别进行判决。该方法解决了库内目标与库外目标的鉴别问题,提高了目标识别系统 的总体性能。针对多种不同姿态下目标特征空间非均匀聚合的特点,对训练样本特征空间进行区域划分,减小模板 匹配搜索运算规模,保证目标鉴别所需的实时性工作要求。最后通过仿真和实测数据验证了该方法具备优良的鉴别 性能与良好的实时处理能力。

关键词:目标鉴别;高分辨距离像;K-Means聚类;支撑向量域描述;K近邻分类器
 中图分类号:TN957
 文献标识码:A
 文章编号:1009-5896(2016)04-0950-08
 DOI: 10.11999/JEIT150786

Identifier for Radar Ground Target Based on Distribution of Space of Training Features

LI Long LIU Zheng

(National Laboratory of Radar Signal Processing, Xidian University, Xi'an 710071, China)

Abstract: To identify the out-of-database targets in the process of radar ground target recognition with High Resolution Range Profile (HRRP), this paper proposes an improved radar ground target identifier based on the distribution of the space of training features. In the training phase, a K-Means clustering strategy based on the pre-process of correlation coefficient is utilized to divide the space of training dataset. Then each sub-space boundary is determined by Support Vector Domain Description (SVDD) based on the distribution of the sample space. Finally, it can decide the category of target with the sub-space boundary and the weighted K-neighbors principle. This method can work without the template of out-of-database samples, which improves the effectiveness of target identification. Due to the fact that the feature space of different targets has the characteristic of non-uniform aggregation under different attitudes, a procedure of region partition is applied to training dataset. Thus computational load is relieved with a decrease in search operation of template matching. The requirement of real-time processing can be satisfied. Finally, the experiments against both simulation and real data verify its excellent performance of identification and real-time processing capability.

Key words: Target identification; High Resolution Range Profile (HRRP); K-Means clustering; Support Vector Domain Description (SVDD); K Nearest Neighbors (KNN) classifier

1 引言

弹载雷达地面目标识别系统主要面临的问题是 复杂环境下对特定目标的实时鉴别。针对弹载雷达 应用背景,采用合成宽带雷达体制生成雷达地面目 标 1 维高分辨距离像(High Resolution Range Profile, HRRP)用于检测与识别。目标 HRRP 反映 了目标散射点在雷达视线方向的几何结构信息,相 对于 2 维雷达成像,其易于工程实现且实时性强,

因此在雷达目标识别系统中得到了广泛的应用[1]。

弹载雷达系统对地面场景进行探测时,场景中 包括待攻击目标与假目标干扰(如铁塔、民用车辆、 路牌等),该类假目标散射特性与待攻击目标类似, 利用目标检测技术无法进行区分,需采用目标鉴别 技术进行辨别与剔除。在实际应用中,由于假目标 种类繁多,几何尺寸与物理形状各异,无法通过实 际测量与建模仿真的方式建立相应的模板库。针对 该训练样本集非完备问题,常规最大相关系数分类 器与支撑向量机分类器均基于二分类构架设计,由 于严重的样本规模不均衡,生成的分类边界无法准

收稿日期: 2015-06-29; 改回日期: 2015-12-25; 网络出版: 2016-02-26 *通信作者: 刘峥 lz@xidian.edu.cn

确对样本空间进行划分¹²。模式识别理论中,针对仅 有部分训练样本的不完备样本库的目标分类问题,

常采用单类分类器 (One-Class Classification, OCC)^[3],如支撑向量域描述(Support Vector Domain Description, SVDD)分类器与 K 近邻(K Nearest Neighbors, KNN)分类器。SVDD 是一种典 型的 OCC 分类器,通过寻找支撑向量确定样本特 征区域边界,利用边界与待测样本距离进行类别判 决[4]。当样本特征空间分布为中心聚合时,该分类器 具有良好的性能^{6]}。但弹载雷达地面目标鉴别问题 中,通过建模仿真或实际测量获得目标样本特征空 间,由于目标 HRRP 的方位敏感性,造成不同角域 下样本特征空间分布的非均匀多区域聚合性,在这 种情况下 SVDD 算法所确定的分类边界将包含大片 非样本目标特征空间区域,导致性能的严重下降⁶。 而针对 KNN 分类器,由于训练样本分布复杂,无 法确定准确的距离边界阈值,且该分类器基于模板 匹配构架,需要遍历所有库内样本,计算复杂度高, 无法保证实时处理[7]。

为解决以上存在的问题,本文首先对库内目标 样本特征空间分布特性进行分析,在此基础上综合 考虑鉴别器性能指标与弹载雷达背景下的工程可实 现性,提出一种改进的雷达地面目标鉴别器。在训 练阶段利用基于相关系数预处理的 K-Means 聚类方 法对库内目标样本特征空间进行区域划分,并采用 基于空间分布的支撑向量域描述方法确定样本特征 空间的边界与支撑向量,利用样本特征空间边界进 行第1次判决,并利用加权K近邻原则,计算测试 样本与各个特征分布区域支撑向量的距离,从而得 到最终判决结果。最后利用实测数据进行对比实验, 通过接收机特性(Receiver Operating Characteristic, ROC)曲线与训练样本数-时间曲线^[7],验证了本文所 提出的鉴别器应用于雷达地面目标鉴别时,相较于 现有鉴别器性能上有明显优势,且通过特征区域预 划分,有效地减小运算量,使得实时处理的能力得 到保证。

2 特征空间分布特性分析

针对弹载雷达目标识别系统存储空间与时间资 源有限的特点,采用合成宽带雷达体制生成目标 HRRP 作为识别对象。在实际应用中,非合作目标 的类型、距离具有不确定性,且目标雷达散射截面 积(Radar Cross Section, RCS)受雷达发射功率、目 标与雷达径向距离、气象环境衰减等因素的影响, 体现在目标 HRRP 上为姿态敏感性、平移敏感性与 幅度敏感性^{8]}。目标 HRRP 的 3 类敏感性对目标识 别系统性能影响较大,需对目标 HRRP 进行平移校 准与幅度归一化等预处理。

目标特征提取是指从雷达采集到的数据中获得 表征目标本质特性的数值或向量,并实现对原有数 据的降维^[9-12]。目标识别系统中的目标鉴别问题, 需要实时对多个未知目标进行判断,以确定该目标 为库内目标或库外目标。针对该应用背景进行特征 选择时,在保证库内目标特征与库外目标特征具有 强可分性的基础上,应选取不同类型库内目标具有 共性的特征,以保证库内目标特征空间的稳定性与 聚合性;另外需要目标特征易于提取且具有低维度 的特点,以便应用于工程实现。

通过对典型库内目标(如坦克目标与雷达站目 标)与库外目标(如角反射器、铁塔、民用车辆等)大 量实测数据进行特征可分性分析,针对目标鉴别的 特定问题,本文选取目标长度特征、目标波形熵特 征与目标去尺度结构特征组成特征向量,3 类特征 互不相关,且与库外目标具有较强的可分性。目标 长度特征工程实现灵活且具有良好的可分性, 但是 易受到杂波与噪声影响,需要与其不相关特征联合 构成特征向量;目标波形熵与目标 HRRP 的概率分 布有关,与单个散射点的具体取值无关,可有效地 避免杂波与噪声的干扰,具有较强的可分性且易于 工程实现;目标 HRRP 去尺度结构特征只与波形内 部的结构有关,而与目标 HRRP 的尺度变化(俯仰 角度变化)无关,当目标 HRRP 呈现单峰情况时值 较小,呈现多峰情况时值较大,该特征在较低信杂 比下可以保持识别性能稳定,具有良好的可分性并 易于工程实现。

在建立训练样本库时,需要不同类型的库内目标特征具有空间聚合性,即具有近似的均值与较小的方差。但在保证库内目标特征与库外目标特征具有较好可分性的基础上,这种聚合性是不易达到的,本文利用多项式变换的方法对目标特征进行预处理,以这种处理后的目标特征空间建立训练样本库。由于不同类型库内目标 HRRP 的姿态敏感性,变换后的目标特征空间无法呈现理想的单一区域聚合特性,其体现出一种非均匀多区域聚合性的分布特性,如图 1 所示。

图 1 为坦克目标与雷达站目标实测数据的 HRRP 归一化特征空间分布图,由于目标姿态角的 变化,同类目标特征呈现出多区域分布特性,而不 同类型目标特征会在区域中相互交错。针对目标识 别中的目标鉴别问题,仅需要区分库内目标与库外 目标,对不同类型的目标看作一个整体进行边界划 分。由于库内目标的特征空间呈现多区域聚合性分



图1 坦克目标与雷达站目标全角度特征空间分布

布,利用单一边界确定的库内目标特征区域会造成 大量库外目标特征区域被包括,造成库内目标特征 空间扩大,从而影响鉴别器性能。针对该问题,本 文利用基于相关系数预处理的K-Means聚类算法进 行特征空间区域划分,并通过基于空间分布的 SVDD 算法确定特征空间中的各个子区域的边界与 支撑向量,得出准确的目标特征空间描述,以此为 基础进行目标类别的判断。

3 基于相关系数预处理的 K-Means 聚类算法

目标特征空间呈现非均匀多区域聚合性分布, 各个特征空间子区域呈现中心聚合性分布,采用聚 类算法对目标特征空间进行空间区域划分。以各个 特征空间子区域为一个特征集合,鉴于其中心聚合 性特点,利用聚类中心作为其标志特征。当需要对 样本特征空间进行遍历搜索时,该层次结构可以大 大降低算法循环次数,加快运算速度。

由于目标特征空间呈现不定数目的多区域性分 布,需要聚类算法对初始类中心选择不敏感^[13],本 文提出一种基于相关系数预处理的K-Means聚类算 法,该算法的基本思想是首先进行基于相关性的预 处理以确定初始中心与类别数目,然后运用 K-Means 算法进行细化,最后得到质量较高的聚类 结果。

基于相关系数预处理的K-Means聚类算法的实现过程具体分为2个阶段。在第1阶段,通过相关系数预处理获得初始中心与类别数目,具体算法描述如下:

(1)训练样本特征向量 **X**_i(*i* = 1,2,…,*n*),其描述 *n* 个待聚类的特征向量。

(2)根据最大相关系数准则,计算特征向量之间 的相关性 ρ_{ij} ,其中 $\rho_{ij} = \frac{\boldsymbol{X}_i^{\mathrm{T}} \boldsymbol{X}_j}{\|\boldsymbol{X}_i\|\|\boldsymbol{X}_j\|}$,设定阈值 τ 对所 分特征区域数目进行控制,对 $\rho_{ij} \geq \tau$ 的特征向量进 行逐层合并,并计算其所得的均值向量 ψ_i ,循环该步骤直至所有 ρ_{ii} 小于 τ 为止。

(3)确定特征区域数目 P,以及其对应的均值向 量 $\psi_i(i = 1, 2, \dots, P)$,将其作为进行 K-Means 算法的 初始类中心点。

第2阶段,通过 K-Means 聚类算法细化初始结 果,具体算法如下:

(4)对目标特征空间中的特征向量进行考察,计 算 该特 征 向 量 与 各 个 特 征 区 域 的 均 值 向 量 $\psi_i(i = 1, 2, \dots, P)$ 的距离,将该特征向量赋予其距离 最小的特征区域。

(5)重新计算各个特征区域的均值向量和特征 区域中特征向量的个数,更新特征区域的聚类特征。

(6)重复步骤(4)和步骤(5),直到特征区域中的 特征向量不发生变化。

(7)最后得到描述各个特征区域的聚类特征 $F_p = (\eta, O_p)$,其中 η 表示该特征区域中的特征向量 序号, O_p 表示该特征区域的均值向量。

图2为图1中的特征向量进行基于相关系数预处 理的K-Means聚类算法后的特征区域描述,可以看 出通过聚类算法处理,特征空间被分为3块特征区 域,各个区域呈现单一区域聚合特性。在算法具体 实现中,需要对阈值 τ 进行合理标定,其主要功能 是控制类别数目,当 τ 值过大时,造成特征区域过 多,且各特征区域中样本特征向量数目过少,无法 体现特征空间的区域聚合性,且加大运算量;当 τ 值 过小时,造成仅有一个特征区域,特征边界中会包 含大片库外目标区域,从而影响鉴别器性能。阈值 τ 的选取是一类工程实践问题,经过对实测数据的分 析,针对目标HRRP特征提取后对特征进行归一化 处理后所得的特征空间,通过计算聚合区域样本特 征向量之间的相关性,本文中选取0.8作为阈值 τ 。

4 基于空间分布的 SVDD 算法

SVDD 算法由 TAX D 和 DUIN R 最早提出,



图 2 坦克目标与雷达站目标特征向量聚类后的特征区域划分

随后二人对 SVDD 算法进行了详细的论述,提出 SVDD 是一种典型的 OCC 分类器,可实现对库外 目标的有效鉴别。常规 SVDD 算法在训练阶段仅考 虑样本间的距离关系,而未考虑样本空间的分布情 况^[14]。文献[15]中提出一种基于样本密度的 SVDD 算法,但其仅考虑了样本密度而未关注不同密度区 域的样本空间整体分布关系。在实际问题中,样本 分布的密度与样本偏离特征空间中心的程度对于描 述数据同样重要。本文根据样本特征向量分布密度 与样本特征向量空间位置偏离设计权值,对传统 SVDD 算法进行改进,使其可以更准确地对训练样 本特征空间进行描述。

目标特征空间经聚类处理后,各个子区域呈现 出中心聚合性分布的特点。针对每个特征子区域, 根据其样本空间分布情况寻找一个包含该特征区域 全部样本半径为R的超球体,同时使半径R最小, 以期望获取可以准确描述特征区域全部样本分布的 一个紧凑的超球边界。其数学表示形式为

$$\begin{array}{c|c} \min R^2 + C \sum_{i}^{n_p} \rho(\boldsymbol{X}_i) \boldsymbol{\xi}_i \\ \text{s.t.} \quad \delta(\boldsymbol{X}_i) \cdot \| \boldsymbol{X}_i - \boldsymbol{a} \|^2 \le R^2 + \boldsymbol{\xi}_i, \ \boldsymbol{\xi}_i \ge 0, \ \forall i \end{array}$$
 (1)

其中, X_i ($i = 1, 2, ..., n_p$)为第p个特征子区域的特征 向量, n_p 为第p个特征区域的特征向量数目, 其中R为 SVDD 半径, C 表示权重因子, ξ_i 表示松弛向量, a 表示超球体球心, $\rho(X_i)$ 为特征空间密度中心偏离 权值, $\delta(X_i)$ 为样本特征空间区域密度权值, 其具体 定义如下:

$$\rho(\boldsymbol{X}_{i}) = \sum_{k=1}^{K} \frac{d(\boldsymbol{X}_{i}, \boldsymbol{X}_{k})}{d(\boldsymbol{X}_{i}, \boldsymbol{O}_{p})} / K$$
(2)

$$\delta(\boldsymbol{X}_{i}) = 1 - \frac{1}{K} \cdot \sum_{k=1}^{K} d(\boldsymbol{X}_{i}, \boldsymbol{X}_{k}) / \left[\frac{1}{N} \cdot \sum_{n=1}^{N} d(\boldsymbol{X}_{i}, \boldsymbol{X}_{n})\right] (3)$$

其中,

$$d^{2}\left(\boldsymbol{X}_{i}, \boldsymbol{X}_{k}\right) = \left\|\boldsymbol{X}_{i}, \boldsymbol{X}_{k}\right\|_{1}^{2}$$
(4)

 $d(\cdot)$ 表示 L1 范数距离, $d(\mathbf{X}_i, \mathbf{X}_k)$ 表示在特征向

量 X_i 与其近邻向量的距离, $d(X_i, O_p)$ 表示在特征向 量 X_i 与该特征区域均值向量的距离, $\rho(X_i)$ 由 $d(X_i, X_k)$ 与 $d(X_i, O_p)$ 的比值求和后归一化获得,表 示该特征向量与区域中心的位置关系,若该特征向 量位于特征区域外边界,则 $\rho(X_i)$ 较小,对应式(1) 中可以看出,此时 $C\sum_i^{n_p} \rho(X_i)\xi_i$ 项较小,描述边界 紧缩;反之当特征向量位于特征空间中心位置时, 特征区域的特征边界膨胀。 $\delta(X_i)$ 由特征向量 X_i 与 其近邻向量之间的平均距离与特征向量 X_i 与小于 $d(X_i, O_p)$ 范围内的所有向量的平均距离表示。 $\delta(X_i)$ 表示特征向量 X_i 周围的样本密度,当密度较大时, 较大的 $\delta(X_i)$ 值保证了特征边界可以在高密度区域 包含更多特征向量;反之,特征边界松弛,忽略某 些距离中心较远的离群特征向量。

利用拉格朗日算子求解式(1)的凸二次规划问题^[12]:

$$L(R, \boldsymbol{a}, \boldsymbol{\alpha}_{i}, \boldsymbol{\gamma}_{i}, \boldsymbol{\xi}_{i})$$

$$= R^{2} + C \sum_{i}^{n_{p}} \rho(\boldsymbol{X}_{i}) \boldsymbol{\xi}_{i}$$

$$- \sum_{i}^{n_{p}} \boldsymbol{\alpha}_{i} \left\{ R^{2} + \boldsymbol{\xi}_{i} - \delta(\boldsymbol{X}_{i}) \cdot \|\boldsymbol{X}_{i} - \boldsymbol{a}\|^{2} \right\}$$

$$- \sum_{i}^{n_{p}} \boldsymbol{\gamma}_{i} \boldsymbol{\xi}_{i}$$
(5)

利用对偶原理构成新的等式:

$$\max \sum_{i=1}^{n_p} \rho(\boldsymbol{X}_i) \boldsymbol{\alpha}_i K(\boldsymbol{X}_i, \boldsymbol{X}_i) \\ - \sum_{i,j=1}^{n_p} \rho(\boldsymbol{X}_i) \rho(\boldsymbol{X}_j) \boldsymbol{\alpha}_i \boldsymbol{\alpha}_j K(\boldsymbol{X}_i, \boldsymbol{X}_j) \\ \text{s.t.} \quad 0 \le \boldsymbol{\alpha}_i \le \rho(\boldsymbol{X}_i) C, \ i = 1, 2, \cdots, n_p \\ \sum_{i=1}^{n_p} \boldsymbol{\alpha}_i = 1, \ \sum_{i=1}^{n_p} \boldsymbol{\alpha}_i \cdot \rho(\boldsymbol{X}_i) = T \end{bmatrix}$$
(6)

利用各个特征区域边界与支撑向量对测试样本 进行判决,数学表达式为 (7)

$$\begin{split} K(\boldsymbol{Z}, \boldsymbol{Z}) &- 2 \sum_{i=1}^{M_p} \rho\left(\boldsymbol{X}_{i,p}^{'}\right) \boldsymbol{\alpha}_{i,p} \cdot K\left(\boldsymbol{Z}, \boldsymbol{X}_{i,p}^{'}\right) \\ &+ \sum_{i,j=1}^{M_p} \rho\left(\boldsymbol{X}_{i,p}^{'}\right) \rho\left(\boldsymbol{X}_{j,p}^{'}\right) \boldsymbol{\alpha}_{i,p} \boldsymbol{\alpha}_{j,p} \\ &\cdot K\left(\boldsymbol{X}_{i,p}^{'}, \boldsymbol{X}_{j,p}^{'}\right) \leq R^2 \end{split}$$

其中,Z表示测试样本特征向量, M_p 表示该特征空间支撑向量 $X'_{i,p}$ 的数目。

图 3 为图 2 利用基于空间分布的 SVDD 算法后的结果,可以看出各个特征边界紧密地包裹住特征向量区域。利用基于空间分布的 SVDD 算法对特征 空间子区域进行描述,特征子区域根据本身的分布 特点进行描述,各个特征子区域仅利用支撑向量、 特征边界与特征区域的统计均值向量即可表示,大 大减小了实际工程实现中的存储压力。但由于对特 征空间子区域进行相对收紧的描述,造成部分支撑 向量位于特征边界之外,所以仅用式(7)判别测试样 本是否为库内样本存在较大的误差,本文在此基础 上,利用改进的加权 KNN 分类器对位于特征边界 外的测试样本进行二次判决。



图 3 各特征区域的 SVDD 特征边界与其对应的支撑向量

5 改进的加权 KNN 分类器

目标特征空间经聚类算法与 SVDD 算法后,特 征空间已可简化由支撑向量 **X**[']_{i,p}、特征区域半径 **R**_p 与特征区域的统计均值向量 **O**_p表示。由于部分支撑 向量为特征区域外的离群向量,仅利用 SVDD 边界 判决会造成靠近离群支撑向量的测试样本特征向量 被判定为库外目标,使得目标鉴别系统性能下降。

本文采用 KNN 原则为基本框架,利用其高自 由度的特点^[16],通过对测试向量与支撑向量之间的 加权距离关系,得到基于测试样本 K 近邻的加权平 均向量,利用其与测试样本特征向量的 L1 范数距 离^[17-19],对样本进行判定。算法具体步骤如下:

(1)对测试样本 HRRP 进行特征提取,得到特征 向量为 Z。

(2)计算支撑向量与其对应的特征区域的均值

向量的距离 $d(\mathbf{X}'_{i,p}, \mathbf{O}_p)$,计算该距离与各个特征区域的特征区域半径的差的绝对值 $|R_p - d(\mathbf{X}'_{i,p}, \mathbf{O}_p)|$ 。

(3) 计算支撑向量与测试向量之间的距离 $d(\mathbf{X}'_{i,p}, \mathbf{Z})$ 并进行排序,选择较小的 K 个距离组成向 量 $\mathbf{D} = [d(\mathbf{X}'_{1,p}, \mathbf{Z}) d(\mathbf{X}'_{2,p}, \mathbf{Z}) \cdots d(\mathbf{X}'_{K,p}, \mathbf{Z})]$ 。

(4)计算D中各个支撑向量所对应的权值:

$$v_{i,p} = \frac{1}{\exp\left[d\left(\boldsymbol{X}_{i,p}, \boldsymbol{Z}\right) \cdot \left|R_p - d(\boldsymbol{X}_{i,p}, \boldsymbol{O}_p)\right|\right]}$$
(8)

该权值表示支撑向量与各个特征子区域的距离 以及与测试样本之间的距离,以此来确定支撑向量 与测试样本的相似性,权值越大越能代表其与测试 样本较相似。

(5)在此基础上计算测试样本的 K 近邻特征向量的均值向量:

$$\boldsymbol{X}_{\text{mean}} = \sum_{i=1}^{K} w_{i,p} \cdot \boldsymbol{X}_{i,p}' / \sum_{i=1}^{K} w_{i,p}$$
(9)

计算 X_{mean} 与测试样本之间的 L1 范数距离

$$d^{2}\left(\boldsymbol{Z}, \boldsymbol{X}_{\text{mean}}\right) = \left\|\boldsymbol{Z} - \boldsymbol{X}_{\text{mean}}\right\|_{1}^{2}$$
(10)

设定阈值 ζ ,当 $d^2(\mathbf{Z}, \mathbf{X}_{\text{mean}}) \ge \zeta$ 时测试样本为 库外目标,当 $d^2(\mathbf{Z}, \mathbf{X}_{\text{mean}}) < \zeta$ 时测试样本为库内目标。

6 实验结果

为检验本文所提出的鉴别器的有效性,利用课题组现有设备进行外场实验获取数据,利用实测数据与仿真数据进行实验,具体实验流程如图 4 所示。结合现有设备参数进行参数设置:采用步进频率体制雷达,跳频步长为 128 步,跳频频率为 $\Delta f =$ 4 MHz,所得合成带宽为 B = 512 MHz,目标 HRRP 距离分辨率为 $\Delta r = 0.293$ m。

6.1 实测数据验证

利用课题组现有实验设备进行试验,获得不同 目标不同状态下的 HRRP 回波。通过对实测库内目 标电磁散射特性分析,利用高频电磁散射计算方法 生成坦克与雷达站的全角度 HRRP 数据作为目标识 别系统的训练样本库,训练样本库包含坦克与雷达 站两类目标各 360 个 HRRP,该方法易于实现且与 实测数据具有较高的相似性。库内测试数据采用静 止坦克数据、静止雷达车数据、迎面运动坦克数据; 库外测试数据采用径向距离 1.5 m 双角反数据、静 止铁塔数据与运动卡车数据。对各个目标回波进行 IFFT 与像拼接处理生成目标 HRRP,如图 5 所示。

为检验本文提出的鉴别器性能,选取坦克目标 (库内目标)与运动卡车目标(库外目标)数据进行对



图 5 实测数据目标 HRRP

比试验。第1组实验测试数据为400组运动卡车 HRRP, 第 2 组实验测试数据为 300 组静止坦克 HRRP 与 100 组运动坦克 HRRP。图 6 为对运动卡 车(库外目标)进行鉴别的结果,图中原点表示被拒 判的库外目标,其拒判率为 89.25%。图 7 为对某次 外场实验中的静止坦克与运动坦克(库内目标)目标 进行鉴别的结果,其正确判决率为83.25%。

弹载下视地面场景构成复杂且干扰较多,鉴别 器性能易受到地杂波影响,现讨论本文所提出的鉴 别器在不同信杂比下的性能变化。测试数据均采用 实测数据,库内目标测试数据包括 400 组坦克目标 数据(运动状态与静止状态)与 400 组雷达车目标数 据(不同姿态静止状态); 库外目标测试数据包括 400

组运动卡车目标数据, 200 组双角反目标数据, 与 200 组静止铁塔目标数据。对各组数据加入不同信 杂比的韦布尔分布杂波,对不同信杂比下的回波数 据进行鉴别,得到的鉴别结果如图 8 所示。可以看 出当信杂比大于15dB时,鉴别器可达到80%以上 的判决率,可以认为在该信杂比下鉴别器具有可接 受的性能,但随着信杂比的下降,鉴别器性能迅速 恶化,当信杂比过小时鉴别器失效。经分析在杂波 条件下影响鉴别器性能的主要原因是特征提取阶段 中杂波与目标的混叠,所以稳健的特征提取以及信 号处理阶段的杂波抑制是解决杂波影响目标鉴别器 性能的关键。



6.2 实验性能评估

鉴别器性能根据接收机工作特性(Receiver Operating Characteristic, ROC)曲线进行评估。 ROC 曲线最初是用来评估接收机检测性能的,其横 轴为虚警率,纵轴为检测率。把库内样本视为正样 本,把库外样本视为负样本,则 ROC 曲线的横轴 表示负样本被错分为正目标的比率,用 P_{f+} 表示; 纵轴表示正样本被正确分为正目标的比率,用 P_{t+} 表示^[20]。

对鉴别器进行性能评估可通过调整鉴别器参数 阈值 ζ 来得到不同的工作点,即得到不同 P_{f+} 下的 P_{t+} ,由此得鉴别器的 ROC 曲线^[21]。鉴别器 ROC 曲线下方积分面积越大性能越好,通常利用其面积 大小作为准则来定量评估分类器的鉴别性能的优 劣。

利用 6.1 节中的训练数据与测试数据进行仿真 实验生成各类典型鉴别器的 ROC 曲线。图 9 为常 用多种目标鉴别器 ROC 曲线比较。由图中可得常 规目标鉴别器,如 MCC 鉴别器、K-NN 鉴别器、 SVDD 鉴别器,在 P_{f+} 小于 0.1 时, P_{t+} 均小于 0.7, 在实际应用中会造成大量的漏警,极大地影响目标 鉴别器性能;改进型的目标鉴别器,如加权 K-NN 鉴别器、基于密度的 SVDD 鉴别器,在 P_{f+} 小于 0.1 时, P_{t+} 迅速下降,说明该鉴别器当 P_{f+} 较低时性能 稳定性不足;本文所提出的改进的地面目标鉴别器,



图9 不同类别鉴别器ROC曲线对比

当 P_{f+} 为 0.1 时, P_{t+} 为 0.9, 且当 P_{f+} 小于 0.1 时, P_{t+} 仍能保持 0.7 以上, ROC 曲线下面积大且曲线变化 平缓,说明识别器性能较对比的目标鉴别器优越且 稳定。

图 10 显示了本文所提出的鉴别器在实时性能 上的优势,实际应用中,由于战场环境复杂,需要 多类目标建立训练样本库,当训练样本库具有较大 规模时,MCC鉴别器与KNN类鉴别器由于需要对 各个样本进行遍历,判决所用的时间将会大幅上升; 本文所提出的鉴别器与SVDD类鉴别器均利用支撑 向量边界进行判决,均具有较好的实时性能。

7 结束语

本文提出一种改进的雷达地面目标鉴别器,其 基于目标特征空间分布进行设计,利用 K-Means 聚 类,对目标特征空间进行区域划分,在此基础上采 用 SVDD 算法进行更为准确的子区域的边界描述, 通过子区域边界与支撑向量对测试特征向量进行判 决。通过实测数据实验对比,本文所提出的鉴别器 具有良好的性能,并且由于对目标特征空间进行划 分,有效地减少了训练样本库规模,同时采用二级 处理的方式,逐层进行判断,有效地减少冗余的计 算量,满足弹载雷达要求的实时处理能力。在下一 步工作研究中,将进一步对鉴别器在低信杂比下的 性能提高进行研究。



图10 不同类别鉴别器实时性能曲线对比

参考文献

李

- KHAN N, KSANTINI R, AHMAD I, et al. Covarianceguided one-class support vector machine[J]. Pattern Recognition, 2014, 47(6): 2165–2177.
- [2] CABRAL G and OLIVEIRA A. One-class classification based on searching for the problem features limits[J]. Expert Systems with Applications, 2014, 41(11): 7182–7199.
- [3] HE X, MOUROT G, MAQUIN D, et al. Multi-task learning with one-class SVM[J]. Neurocomputing, 2014, 133(6): 416-426.
- [4] ZHANG H, CAO L, and GAO S. A locality correlation preserving support vector machine[J]. *Pattern Recognition*, 2014, 47(9): 3168–3178.
- [5] DAGEFU F and SARABANDI K. High-resolution subsurface imaging of deeply submerged targets based on distributed near-ground sensors[J]. *IEEE Transactions on Geoscience* and Remote Sensing, 2014, 52(2): 1089–1098.
- [6] CHAI Jing, LIU Hongwei, CHEN Bo, et al. Large margin nearest local mean classifier[J]. Signal Processing, 2010, 90(1): 236–248.
- [7] TOHME M and LENGELLE R. Maximum margin one class support vector machines for multiclass problems[J]. Pattern Recognition Letters, 2011, 32(10): 1652–1658.
- [8] 丁军,刘宏伟,王英华.基于非负稀疏表示的 SAR 图像目标 识别方法[J].电子与信息学报,2014,36(9):2194-2200.doi: 10.3724/SP.J.1146.2013.01451.

DING Jun, LIU Hongwei, and WANG Yinghua. SAR image target recognition based on non-negative sparse representation[J]. Journal of Electronics & Information Technology, 2014, 36(9): 2194–2200. doi: 10.3724/SP.J.1146. 2013.01451.

 [9] 王军,赵宜楠,乔晓林.基于压缩感知的雷达前视向稀疏目标 分辨[J].电子与信息学报,2014,36(8):1978-1984.doi:10. 3724/SP.J.1146.2013.01936.
 WANG Jun, ZHAO Yinan, and QIAO Xiaolin. A sparse

target-scenario determination strategy based on compressive sensing for active radar in the line of sight[J]. *Journal of Electronics & Information Technology*, 2014, 36(8): 1978–1984. doi: 10.3724/SP.J.1146.2013.01936.

- [10] 刘艳红,薛安荣,史习云. K-means 聚类与 SVDD 结合的新的 分类算法[J]. 计算机应用研究, 2010, 27(3): 883-886.
 LIU Yanhong, XUE Anrong, and SHI Xiyun. New classification algorithm K-means clustering combined with SVDD[J]. Application Research of Computers, 2010, 27(3): 883-886.
- [11] KEMMLER M, RODNER E, WACKER E, et al. One-class classification with gaussian processes[J]. Pattern Recognition, 2013, 46(12): 3507–3518.
- [12] BOYD Stephen. Convex Optimization[M]. Cambridge:

Cambridge University Press, 2004: 325–337.

- [13] 柴晶,刘宏伟,保铮.加权 KNN 分类器在 HRRP 库外目标拒 判中的应用[J].系统工程与电子技术,2010,32(4):718-723. CHAI Jing, LIU Hongwei, and BAO Zheng. Application of a weighted KNN classifier for HRRP out-of-database target rejection[J]. Systems Engineering and Electronics, 2010, 32(4): 718-723.
- [14] TOYAMA J, KUDO M, and IMAI H. Probably correct k-nearest neighbor search in high dimensions[J]. Pattern Recognition, 2010, 43(4): 1361–1372.
- [15] CHA M, KIM S, and BAEK J. Density weighted support vector data description[J]. *Expert Systems with Applications*, 2014, 41(6): 3343–3350.
- [16] DJOUADI A and BOUKTACHE E. A fast algorithm for the nearest-neighbor classifier[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1997, 19(3): 277–282.
- [17] XIAO Y, WANG H, XU W, et al. L1 norm based KPCA for novelty detection[J]. Pattern Recognition, 2013, 46(1): 389–396.
- [18] 陈思宝,陈道然,罗斌. 基于 L1-范数的二维线性判别分析[J]. 电子与信息学报, 2015, 37(6): 1372-1377. doi: 10.11999/ JEIT141093.
 CHEN Sibao, CHEN Daoran, and LUO Bin. L1-norm based two-dimensional linear discriminant analysis[J]. Journal of Electronics & Information Technology, 2015, 37(6): 1372-1377. doi: 10.11999/JEIT141093.
 [19] SAMET H. K-nearest neighbor finding using
- [19] SAMET H. K-nearest neighbor finding using MaxNearestDist[J]. *IEEE Transactions on Pattern Analysis* and Machine Intelligence, 2008, 30(2): 243–252.
- [20] 刘家辰,苗启广,曹莹,等.基于混合多样性生成与修剪的集成单类分类算法[J].电子与信息学报,2015,37(2):386-393. doi: 10.11999/JEIT140161.

LIU Jiachen, MIAO Qiguang, CAO Ying, et al. Ensemble one-class classifiers based on hybrid diversity generation and pruning[J]. Journal of Electronics & Information Technology, 2015, 37(2): 386–393. doi: 10.11999/JEIT140161.

- [21] 冯博,陈渤,王鹏辉,等.基于稳健深层网络的雷达高分辨距 离像目标特征提取算法[J].电子与信息学报,2014,36(12): 2949-2955. doi: 10.3724/SP.J.1146.2014.00808.
 FENG Bo, CHEN Bo, WANG Penghui, et al. Feature extraction method for radar high resolution range profile targets based on robust deep networks[J]. Journal of Electronics & Information Technology, 2014, 36(12): 2949-2955. doi: 10.3724/SP.J.1146.2014.00808.
- 李 龙: 男, 1988年生, 博士生, 研究方向为雷达目标识别技术.
- 刘 峥: 男,1964年生,教授,博士生导师,研究方向为雷达信号处理的理论与系统设计、雷达精确制导技术、多传感器信息融合等.