

## 基于非参数化概率密度估计的雷达目标识别

赵峰<sup>①②</sup> 张军英<sup>①</sup> 刘敬<sup>①</sup> 梁军利<sup>③</sup>

<sup>①</sup>(西安电子科技大学计算机学院 西安 710071)

<sup>②</sup>(济南大学理学院 济南 250012)

<sup>③</sup>(中国科学院声学研究所 北京 100080)

**摘要:** 针对雷达目标识别中, 参数化方法估计高分辨距离像的概率密度存在的“模型失配”问题, 提出一种非参数化方法——基于累计量的随机学习算法, 估计距离像的概率密度。该算法运用多层感知器估计训练样本的分布函数, 然后求导得到概率密度。该算法不仅能全面、精确地估计概率密度, 而且回避了许多其他非参数方法面临的“窗宽”敏感性问题。基于外场实测数据的实验证明了该文方法的有效性。

**关键词:** 雷达目标识别; 高分辨距离像; 密度估计

中图分类号: TN957.51

文献标识码: A

文章编号: 1009-5896(2008)07-1740-04

## Radar Target Recognition Based on Nonparametric Density Estimation

Zhao Feng<sup>①②</sup> Zhang Jun-ying<sup>①</sup> Liu Jing<sup>①</sup> Liang Jun-li<sup>③</sup>

<sup>①</sup>(School of Computer Science and Engineering, Xidian University, Xi'an 710071, China)

<sup>②</sup>(School of Science, Jinan University, Jinan 250012, China)

<sup>③</sup>(Institute of Acoustics, Chinese Academy of Sciences, Beijing 100080, China)

**Abstract:** In order to solve the problem of model mismatch when using parametric approach to estimate the density of High-Resolution Range Profile(HRRP) in radar target recognition, a nonparametric method—Stochastic Learning of the Cumulative(SLC) is presented for the density estimation of HRRP. SLC uses a multiplayer network to estimate the distribution function of the training samples and obtains density by taking derivative. SLC not only describes the density function more comprehensive and accurately, but also avoids the problem of being sensitive to window width that many nonparametric approaches may suffer. Experimental results using outfield real data demonstrate the validity of the proposed learning algorithm.

**Key words:** Radar target recognition; High-Resolution Range Profile (HRRP); Density estimation

### 1 引言

高分辨距离像(High Resolution Range Profile, HRRP)是目标散射点回波在雷达射线上投影的向量和, 提供了目标散射点的强度和位置信息, 反映了目标的形状、结构等特征, 因而成为雷达自动目标识别领域的研究热点<sup>[1-12]</sup>。利用HRRP完成目标识别的研究成果到目前为止已经相当丰硕, 但针对概率密度估计的识别研究较少, 而且局限于采用参数化方法估计HRRP的概率分布<sup>[8-11]</sup>。

参数化方法估计HRRP的概率密度, 不足在于: (1)依据散射点模型理论<sup>[12]</sup>, 不同距离分辨单元所包含的散射点数目以及散射点的强度、位置等是不同的, 其回波幅度的起伏很难用一种甚至几种特定的分布形式来描述, 所以采用参数化方法估计HRRP的概率密度, 可能面临“模型失配”问题, 影响识别效果; (2)目前常用的参数化模型自身也存在一些缺陷。如Gamma模型<sup>[8, 9]</sup>, 一般通过迭代算法估计概率分布的参数, 计算量大, 而且容易陷入局部最优, 影响识别性能;

而Gauss模型<sup>[10, 11]</sup>面临选取合适的幂次问题, 幂次选取不当, 也会影响识别性能。

为此, 本文首次提出采用非参数化方法估计HRRP的密度函数, 以期能够全面、精确地描述各种情况下的HRRP的概率分布。相比参数化方法, 非参数化方法的优点是可以处理任意形式的概率分布, 不存在“模型失配”问题<sup>[13]</sup>。缺点在于: (1)为了得到精确的密度估计, 需要大量的训练样本, 特别是高维的密度估计更是如此。(2)众多非参数化方法面临“窗宽”优化问题, 即非参数化方法本身需要调节的一些参数<sup>[13, 14]</sup>。(3)非参数化方法一般有较高的计算复杂度。因此, 能否采用非参数化方法估计HRRP的密度, 关键看上述问题是否得到解决。

本文分析发现: (1)HRRP的各距离分辨单元的回波幅度近似相互独立, 因此高维HRRP的密度估计问题, 转化为对各个距离单元内一维回波幅度的密度估计, 降低了对训练样本的需求量。(2)本文采用的非参数化方法是基于累计量的随机学习算法(Stochastic Learning of the Cumulative, SLC)<sup>[15]</sup>。该算法不仅可以准确地估计密度函数, 而且不存在“窗宽”调节问题。(3)采用SLC估计概率密度, 运算量

主要集中在离线的训练阶段,并不影响识别时效,而测试阶段的密度计算则同参数化方法相当,只是一般的函数值的计算问题。因此,采用SLC估计HRRP的概率分布符合HRRP的统计规律,同时也回避了常用非参数化方法面临的一些问题。外场实测数据的实验表明,相比目前常用的参数化方法(Gauss模型和Gamma模型),本文方法具有较高的识别率。

## 2 HRRP统计特性分析

估计HRRP的概率密度,必须对其统计特性有所了解,为此,本文先从物理概念出发,基于简单散射点模型<sup>[12]</sup>,对HRRP的统计特性进行定性分析。

基于简单散射点模型理论,HRRP可视为由多个距离分辨单元组成的多维向量,向量的某一元素为相应单元内的所有散射点回波在雷达射线上的投影和。在距离单元内的散射点不发生越距离单元走动(MTRC)<sup>[1]</sup>的小角域内,各距离单元的散射点模型基本不变,距离像峰值的位置比较稳定,所以可以将该角域内的HRRP(即一帧HRRP)视为独立同分布的一组随机取样,估计其概率密度。下面分析单帧HRRP统计特性。

对于单个HRRP而言,它的每个距离分辨单元内驻留的散射点及其分布情况互不相关,可以认为是相互独立的。因此,高维HRRP的密度估计问题,转化为估计各个距离单元内一维回波的密度,为采用非参数方法估计概率密度提供了可能。

对单个距离分辨单元的回波而言,根据距离单元中驻留的散射点不同,其回波幅度大致分为3类<sup>[5]</sup>:(1)距离单元内只包含一个强散射点(称为特显点)和众多相对弱小的散射点,回波幅度的分布可用莱恩分布近似描述。(2)距离单元中包含众多弱散射点,且没有明显的特显点。其回波幅度可用瑞利分布描述。(3)距离单元中包含少数几个,特别是2~3特显点,其余均为弱散射点。一般来说,其回波幅度多为多峰分布,其中双峰分布为主。

上述回波幅度的划分,仅是一种大体概括。事实上,有些距离单元内的回波幅度,用上述3种分布模型,甚至现有的其他概率分布形式,都无法精确描述其分布情况。因此,采用参数化密度估计方法,预先设定分布类型,不可避免地存在“模型失配”问题。特别是对于多峰分布的回波幅度,由于Gauss模型与Gamma模型都是单峰分布,因此很难准确描述这类分布。另外,模型自身也存在一些问题。比如Gauss模型,需要对HRRP进行幂次变换处理<sup>[16]</sup>。其存在的问题是很难找到合适的幂次,使得幂变换后各帧HRRP都变得更具有高斯性,甚至幂次不当,反而减弱某些帧内HRRP的高斯性<sup>[10,11]</sup>;而Gamma模型属于双参模型<sup>[17]</sup>,一般利用极大似然法估计参数,其求解方程不存在解析解,需要运用迭代算法求解,容易陷入局部最优,影响密度估计的准确性<sup>[8,9]</sup>。

## 3 基于累计量的随机学习算法(SLC)

第2节的分析表明:采用非参数化方法估计各个距离单

元的回波幅度的概率密度更符合回波幅度的统计特点。本文选取的具体非参数方法为SLC<sup>[15]</sup>,原因在于:相比其他非参数估计方法,SLC具有下列优势(1)从理论上可以证明该算法的收敛性,而且收敛速度与估计结果优于目前常用的核密度估计方法。(2)不存在许多非参数化方法面临“窗宽”敏感性问题。这里所谓的“窗宽”是指非参数化方法本身需要调节的一些参数。比如 $k_n$ -近邻估计的 $k_n$ 的选取问题<sup>[13]</sup>。基于支撑向量基的密度估计方法需要选取合适的核函数以及核函数的参数问题<sup>[14]</sup>。“窗宽”选取不当直接影响估计结果。(3)SLC主要的时间消耗在训练阶段,而测试阶段的密度估计,同参数化方法一样,只是一般的函数值计算问题。而且训练阶段是离线的,对识别时效并不影响,同时可以通过并行计算提高训练速度。

### 3.1 SLC的理论依据

SLC的理论依据是把一维随机变量 $x$ 的分布函数 $u = F(x)$ 视为随机变量,则 $u$ 服从 $[0,1]$ 上的均匀分布。因此,将 $F(x)$ 的 $n$ 个相互独立的随机采样,按升序排列,记为 $x_1 \leq x_2 \leq \dots \leq x_n$ ,则对应的分布函数值 $u_i = F(x_i)$ ( $i = 1, 2, \dots, n$ )满足 $u_1 \leq u_2 \leq \dots \leq u_n$ 。当 $n$ 充分大时, $u_i$ ( $i = 1, 2, \dots, n$ )应该比较均匀的散布在 $[0,1]$ 上。因此将 $[0,1]$ 区间 $n$ 等分,每个小区间上取一个值,比如 $t_i = i/n$ ( $i = 1, 2, \dots, n$ ),则 $t_i \approx u_i$ 。所以将 $x_i$ 作为多层感知器的输入, $t_i$ 作为期望输出,近似代替 $x_i$ 对应的真实分布函数值 $u_i = F(x_i)$ 。网络训练完毕,则输入测试样本 $x$ ,其网络输出 $H(w,x)$ 即为概率分布函数值,这里 $w$ 表示网络的权重系数。由于多层感知器的激励函数一般都是任意阶可导函数,因此,密度函数 $f(x) = H'(w,x)$ 。

### 3.2 SLC的主要步骤

(1)设未知分布 $F(x)$ 的 $n$ 个独立样本,其升序排列为 $x_1 \leq x_2 \leq \dots \leq x_n$ 。

(2)令 $t = 1$ , $t$ 表示循环数目。设置初始权重 $w(1)$ 。令 $t_i = i/n$ ( $i = 1, 2, \dots, n$ )作为 $x_i$ 的期望输出。

(3)调整权重 $w(t+1) = w(t) + \eta(t)(\partial \varepsilon(w)/\partial w)$ 。其中 $\varepsilon$ 是目标函数,它由输出误差项与“单调惩罚函数”构成,即

$$\varepsilon(w) = \sum_{i=1}^n [H(x_i, w) - t_i]^2 + \lambda \sum_{i=1}^n \theta(H(x_i, w) - H(x_i + \Delta, w)) \quad (1)$$

其中 $\lambda > 0$ , $\Delta > 0$ 且很小, $\theta(x) = \begin{cases} 1, & x > 0 \\ 0, & x \leq 0 \end{cases}$ 用来验证哪些

样本点需要进行单调性修正。

(4)令 $t = t + 1$ ,返回(3)。直到 $\varepsilon(w)$ 小到一个预先设定的阈值。

(5)对输出函数 $H(x,w)$ 求导,得到概率密度函数,即 $f(x) = H'(w,x)$ 。

## 4 运用SLC进行识别的基本步骤

### 4.1 HRRP的预处理

由于HRRP具有方位、平移、幅度敏感性<sup>[1]</sup>。为了消除3

方面敏感性,同Gamma模型与Gauss模型一样,本文采用如下方式对HRRP进行预处理:(1)分角域建模方法,松弛方位敏感性。(2)对于平移敏感性,在训练阶段,对各帧内的HRRP采用滑动相关法对齐;测试阶段的测试样本则带入各个角域,与该角域内的HRRP序列采用同一标准对齐。(3)对于幅度敏感性,不论训练样本还是测试样本,都作幅度归一化处理。

#### 4.2 识别的具体步骤

##### 训练阶段:

(1)将待识别目标  $T_k$  ( $k = 1, 2, \dots, K$ ) 的训练样本按角域分帧,各帧内的HRRP对齐并幅度归一化,记为  $X_l^{(k)} = \{x_{li}^{(k)} | i = 1, 2, \dots, n\}$ 。其中  $l = 1, 2, \dots, L$  表示目标  $T_k$  的第  $l$  帧,  $n$  表示该帧内HRRP数目。

(2)采用SLC估计各类各帧各距离分辨单元的回波幅度的密度函数  $f_{l,t}^{(k)}(x, w) = H'(x, w)$ ,即存储对应的神经网络的权重系数  $w(k, l, t)$ 。其中  $k$  表示第  $k$  类目标,  $l$  表示第  $l$  帧,  $t = 1, 2, \dots, m$  表示距离分辨单元。

##### 测试阶段:

(1)测试样本与帧距离像  $X_l^{(k)} = \{x_{li}^{(k)} | i = 1, 2, \dots, n\}$  距离对齐并幅度归一化,不妨记作  $x = (x(1), x(2), \dots, x(m))^T$ ,其中  $x(t)$  ( $t = 1, 2, \dots, m$ ) 表示第  $t$  个距离单元的回波幅度。将  $x$  代入目标  $T_k$  的第  $l$  帧的概率密度模型中。即

$$p(x|k, l) = \prod_{t=1}^m f_{l,t}^{(k)}(x(t), w) \quad (2)$$

(2)目标  $T_k$  的类条件概率密度为

$$p(x|k) = \max_l p(x|k, l) \quad (3)$$

(3)用Bayes定理估计目标  $T_k$  ( $k = 1, 2, \dots, K$ ) 的类后验概率

$$p(k|x) = \frac{p(x|k)p(k)}{\sum_{k=1}^K p(x|k)p(k)} \quad (4)$$

(4)根据“最大后验概率原则”判别类别归属,若

$$C = \max_k p(k|x) \quad (5)$$

则测试样本  $x$  属于目标  $T_C$ 。

## 5 基于外场实测数据的实验分析

### 5.1 实测数据介绍

本文的雷达数据是某单位的ISAR实验雷达实测飞机数据。该数据是三类飞机目标(an-26、Yark-42、奖状)的一维高分辨距离像(HPPR)。这些数据都是在目标飞行时连续录取的。雷达和飞机的参数以及飞机的飞行轨迹参见文献[3]。为了检验识别算法的推广能力,训练数据和测试数据在不同的数据段内选取,其中,“Yark-42”的2,5段,“An-26”的5,6段,“奖状”的6,7段数据作为训练数据,其他各段作为测试数据。训练数据段基本上基本包含了各种方位角的情况,只是俯仰角有差异。实测HRRP数据为256维,3类目标的训练数据按角域划分为50帧,每帧的角域宽度约

为  $3^\circ$ 。

### 5.2 各种概率密度估计方法的比较

为了比较SLC与Gamma模型与Gauss模型在概率密度估计方面的性能,本文选取相同的距离分辨单元,分别采用3种方法估计该单元内回波幅度的概率密度。其中,SLC所对应的多层感知器只有一个隐层,包含3个神经元<sup>[18]</sup>。其中输入层到隐层的激励函数为  $\tanh(x)$ ,隐层到输出层的激励函数为  $\text{logsig}(x)$ ,而  $\eta(t) = 0.01, \lambda = 1, \Delta = 0.001$ ,符号的具体含义参见3.2节。

图1给出了3种方法对几种典型的距离单元内回波幅度的密度估计。其中矩形表示直方图,实线表示SLC估计的概率密度,长虚线表示Gamma模型估计的概率密度,短虚线表示Gauss模型估计的概率密度。考虑到Gauss模型需要加幂次变换,为了对比幂变换前后Gauss模型的密度估计效果,本文对原始数据以及幂变换后的数据分别采用Gauss模型进行密度估计,图1中第1列表示的是原始数据,而第2列则是对应的幂变换后的数据,试验中的幂次  $\sigma = 0.5$  是该模型的识别效果最优的幂次。

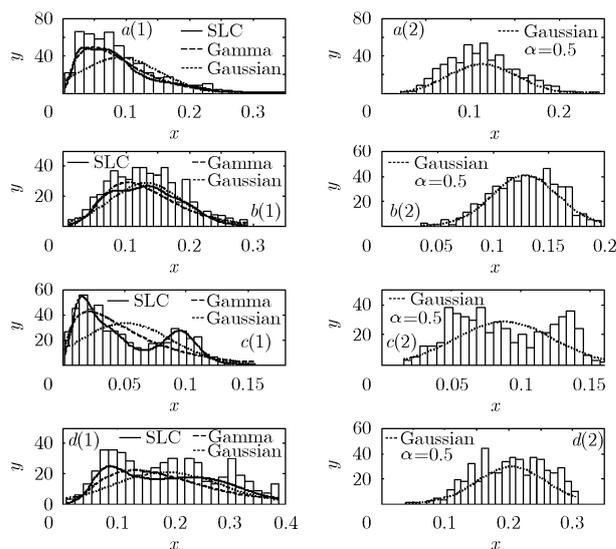


图1 3种方法估计的概率密度曲线

由图1可以看出,(1)对于回波幅度属于单峰分布的情况,如  $a(1)$ ,  $b(1)$ , 3种方法都可以比较准确地描述其分布情况,同时对比  $a(1)$ 与  $a(2)$ ,  $b(1)$ 与  $b(2)$ 不难看出,  $a(2)$ 与  $b(2)$ 密度曲线与直方图更吻合,说明幂次变换后,Gauss模型的密度估计效果更好。(2)对于多峰分布的情况,如  $c(1)$ ,  $c(2)$ ,  $d(1)$ ,  $d(2)$ , Gauss模型与Gamma模型都出现了“模型失配”问题,这与它们的模型本质是单峰分布有关;而SLC则完全不同,SLC直接从训练数据本身出发,估计其分布情况,具有很好的灵活性。因此对于双峰以及多峰分布,仍能比较准确地估计其分布情况。因此采用SLC估计概率密度,更符合回波幅度的统计特性。

### 5.3 SLC, Gamma 模型, Gauss 模型的识别性能比较

表 1 给出了对同样的训练与测试数据, 3 种方法的在测试集上的识别情况。其中  $\sigma = 0.5$  是 Gauss 模型识别效果最优的幂次。从识别率来看, 最优幂次下的 Gauss 模型与 Gamma 模型的识别性能相当, 而本文提出的 SLC 方法识别性能最好, 符合本文的理论分析。

表 1 3 种方法的识别率

|          | SLC   | Gamma | Gauss<br>( $\sigma = 0.5$ ) |
|----------|-------|-------|-----------------------------|
| An-26    | 82    | 78.25 | 79.5                        |
| 奖状       | 93.75 | 87.50 | 91.25                       |
| Yak-42   | 100   | 96.25 | 92.1                        |
| 平均识别率(%) | 92    | 87.33 | 87.7                        |

## 6 结束语

基于简单散射点模型理论, 分析了单个距离单元内回波的概率分布特点, 指出了参数化方法—Gamma 模型与 Gauss 模型无法全面、精确描述不同分布类型的回波幅度。尤其对多峰分布的情况, 由于两个模型都是单峰分布类型, 不可避免的要出现“模型失配”问题。为此, 本文提出采用非参数化方法—SLC, 估计各个距离单元内回波的概率密度, 该方法不受分布类型的限制, 能够全面、精确地描述各种分布类型下的回波幅度, 同时避免了许多其它非参数化存在的“窗宽”敏感性问题。基于实测数据的实验表明, 本文提出的非参数化方法—SLC 具有较好的识别效果。但需要指出的是采用 SLC 估计概率密度, 一是训练过程缓慢, 二是类似 Gamma 模型, 可能陷入“局部最优”问题, 这些都是有待进一步研究的问题。

## 参考文献

- [1] Xing M D, Bao Z, and Pei B N. Properties of high-resolution range profiles [J]. *Optical Engineering*, 2002, 41(2): 493-504.
- [2] Willis C. Aircraft recognition using high-resolution radar range profiles [A]. Proc SPIE Int Soc Opt Eng[C]. Orlando, United States, 2003: 200-209.
- [3] Du L, Liu H W, and Bao Z. Radar HRRP target recognition based on higher order spectra [J]. *IEEE Trans. on Signal Process*, 2005, 53(7): 2359-2368.
- [4] 时宇, 张贤达. 基于局部双谱的高分辨距离像雷达目标识别 [J]. 清华大学学报, 2002, 42(3): 407-410.  
Shi Y and Zhang X D. Local bispectra-based high-resolution radar target recognition with range profiles [J]. *Journal of Tsinghua Univ.*, 2002, 42(3): 407-410.
- [5] 叶炜. 逆合成孔径雷达运动补偿与成像研究[D]. 西安: 西安电子科技大学, 1996.  
Ye W. Study of the inverse synthetic aperture radar imaging and motion compensation [D]. Xi'an: Xidian Univ., 1996.
- [6] 刘宏伟, 杜兰, 袁莉. 雷达高分辨距离像目标识别研究进展[J]. 电子与信息学报, 2005, 27(8): 1328-1334.  
Liu H W, Du L, and Yuan L. Progress in radar automatic target recognition based on high range resolution profile [J]. *Journal of Electronics & Information Technology*, 2005, 27(8): 1328-1334.
- [7] Kim K T, Seo D K, and Kim H T. Efficient radar target recognition using the MUSIC algorithm and invariant features [J]. *IEEE Trans. on Antennas Propagation*, 2002, 50(3): 325-337.
- [8] Webb A R. Gamma mixture models for target recognition [J]. *Pattern Recognition*, 2000, 33(12): 2045-2054.
- [9] Copsey K and Webb A R. Bayesian Gamma mixture model approach to radar target recognition [J]. *IEEE Trans. on Aerospace and Electronic Systems*, 2003, 39(4): 1201-1217.
- [10] Jacobs S P. Automatic target recognition using high-resolution radar range profiles [D]. Washington: Washington University, 1999.
- [11] Heiden R V and Groen F C A. The box-cox metric for nearest neighbor classification improvement [J]. *Pattern Recognition*, 1997, 30(2): 273-279.
- [12] Steinberg B D. Microwave Imaging with Large Antenna Arrays: Radio Camera Principle and Technique [M]. New York: John Wiley and Sons, 1983: 746-852.
- [13] Duda R O, Hart P E, and Stork D G 著. 李宏东, 姚天翔译. 模式分类 [M]. 北京: 机械工业出版社, 2003: 132-163.
- [14] 张昭, 张素, 章琛曦. 基于支撑向量机的概率密度估计方法[J]. 系统仿真学报, 2005, 17(10): 2355-2357.  
Zhang Z, Zhang S, and Zhang C X. Density estimation based on support vector machines [J]. *Journal of System Simulation*, 2005, 17(10): 2355-2357.
- [15] Malik M I and Amir A. Density estimation and random variate generation using Multilayer networks [J]. *IEEE Trans. on Neural Networks*, 2002, 13(3): 497-520.
- [16] Fukunage K. Introduction to Statistic Pattern Recognition [M]. Boston MA: Academic, 1990: 368-424.
- [17] Skolnik M. Introduction to Radar Systems [M]. New York: McGraw-Hill, 1980: 523-614.
- [18] Haykin S 著. 叶世伟, 史忠植译. 神经网络原理 [M]. 北京: 机械工业出版社, 2004: 110-181.

赵峰: 男, 1974年生, 博士生, 主要研究方向为雷达目标识别、智能信息处理等。

张军英: 女, 1961年生, 博士, 教授, 博士生导师, 目前主要从事人工神经网络、智能信息处理、图像处理、分子成像、计算生物信息学、模式识别、优化等方面的研究工作。

刘敬: 女, 1975年生, 博士生, 主要研究方向为雷达目标识别、智能信息处理等。

梁军利: 男, 1978年生, 博士生, 主要研究方向为阵列信号处理、自适应滤波、智能信息处理等。