

减少防撞雷达虚假目标的信号处理研究

孙艳敏, 周长林, 常青美, 高 辉

(解放军信息工程大学 理学院, 河南 郑州 450001)

摘要: 从信号处理的角度分析了防撞雷达虚报警率、漏报警率偏高的原因, 采用 AR 模型功率谱估计的 Burg 算法代替传统的 FFT 算法, 并将粗神经网络应用于防撞雷达目标识别。仿真结果表明, 此方法提高了雷达信号处理的准确度和目标识别率, 能有效地降低漏报警、虚报警率。

关键词: 防撞雷达; 虚假目标; 功率谱估计; 粗神经网络

中图分类号: TP391

文献标识码: A

文章编号: 1674-7720(2011)18-0046-03

Signal processing study on reducing false targets for anti-collision radar

Sun Yanmin, Zhou Changlin, Chang Qingmei, Gao Hui

(Institute of Science, Information Engineering University, Zhengzhou 450001, China)

Abstract: This article analyzes the reasons for the high rate of leakage alarm and false alarm of the anti-collision radar from the point of the signal processing, using the Burg algorithm of AR models power spectrum estimation instead of the traditional FFT algorithm, and use the rough neural network for anti-collision radar target identification. Simulation results show that this method improves the accuracy of radar signal processing and target recognition rate, which can effectively reduce the leakage alarm and false alarm rate.

Key words: anti-collision radar; false target; power spectrum estimation; rough neural network

在智能交通系统中, 汽车防撞雷达通常采用线性调频连续波体制, 而多目标检测能力较低、大量的遗漏目标、虚假目标是制约其应用和普及的关键问题。如何获得较低的虚警率和漏警率是汽车防撞雷达研究的重点和难点。

在雷达接收机产生的雷达中频信号中, 不但含有目标的中频频率, 还含有雷达噪声信号和干扰信号, 如邻近车道上的车辆、车道间的护栏、路旁的树木以及空中和远处的建筑物等, 这些都会对雷达系统形成干扰, 导致雷达做出错误判断。减少防撞雷达的漏报警、虚报警, 要求信号处理有较高的分辨率和准确性, 并且有较好的目标检测和识别方法^[1]。

本文讨论了传统雷达信号处理存在的不足之处, 分析了导致防撞雷达漏报警、虚报警的主要原因, 提出采用 AR 参数模型功率谱估计的 BURG 算法求取雷达数据的频域信息, 用粗集理论和神经网络构造相结合的粗神经网络进行防撞雷达目标数据融合, 实现防撞雷达目标识别, 取得了较好的仿真效果。

1 雷达测量的工作原理

线性调频连续波体制(LFMCW)雷达根据多普勒频

移原理, 利用发射信号和回波信号之间的差频来确定目标的距离和速度。其测量原理如图 1 所示。

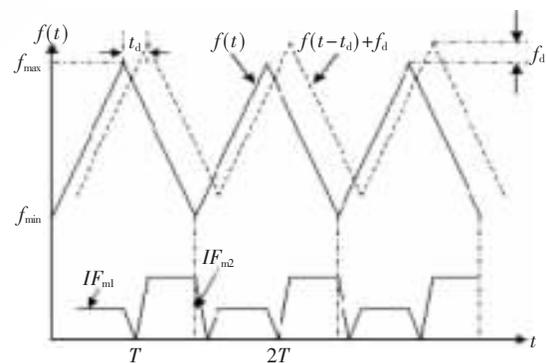


图 1 LFMCW 雷达信号示意图

图 1 中, $f(t)$ 为发射信号频率, $f(t-t_d)$ 为接收信号频率, IF_{m1} 和 IF_{m2} 分别为中频信号上下扫频频率。中频频率为发射信号与接收信号的频率之差, 它包含着前方目标的距离和速度的信息。中频频率由频率调制规律 f 、回波时间延迟 t_d 以及多普勒频移 f_d 共同决定。由理论推导可得出目标的距离和速度的计算公式:

《微型机与应用》2011 年 第 30 卷 第 18 期

网络与通信

Network and Communication

$$R = \frac{CT(IF_{m2} - IF_{m1})}{4B} \quad (1)$$

$$v = \frac{\lambda(IF_{m1} + IF_{m2})}{4} \quad (2)$$

式中, C 为光速, T 为调制周期, B 为调制频带宽度, λ 为发射信号波长。由此求出雷达中频信号上下扫频频率, 即可求出目标的距离和相对速度。

在传统防撞雷达信号处理方法中, 常采用对中频信号进行傅里叶变换得到信号的频谱信息, 然后寻找中频频谱的峰值谱线, 以其作为目标的中频频率, 来计算目标的距离和相对速度。

然而雷达接收端得到的是随机信号, 不能通过一个确切的数学公式来描述, 对其作傅里叶变换求出的频谱不能有效地抑制噪声信号, 会导致很多虚假目标的产生。并且在 N 点 FFT 的过程中, 事实上认为 N 点以外的数据均为 0, 这相当于给信号加了一个 N 点的窗函数, 在频域中引入了一个与之卷积的 sinc 函数, 结果必然造成失真。如何从被目标物反射回来的受到严重干扰的微弱回波信号中提取发送的有用信号, 并通过计算回波到达时间和频率偏移进而确定目标的方位和运动速度? 在随机过程理论上, 从统计观点出发, 采用功率谱估计是一种更好的解决方法, 且功率谱估计可以避免窗函数的影响, 从而提高信号处理的分辨率和准确度^[2]。

以中频频谱的峰值谱线作为目标的中频频率来计算目标数据, 这种目标识别方法虽简单易行, 但是很容易把干扰和噪声的峰值谱识别为目标谱线, 从而造成大量的虚假目标, 导致雷达虚警率高。采用神经网络处理复杂问题, 进行目标识别时显示了强大的功能^[3], 但传统的神经网络其输入输出信息是定量的。将粗集理论融入神经网络可以大大改善网络的性能, 使之不仅能处理传统的定量输入, 而且能处理定性或混合性的输入信息, 解决多传感器不同种类信息的融合问题, 可以大大提高雷达目标的识别率^[4]。

2 Burg 算法在防撞雷达信号处理中的应用

2.1 AR 参数模型及 AR 模型系数的 Burg 算法

参数模型法的思路: (1) 假定所研究的过程 $x(n)$ 是由一个输入序列 $u(n)$ 激励一个线性系统 $H(z)$ 的输出; (2) 由已知的 $x(n)$ 或自相关函数 $r_x(n)$ 来估计 $H(z)$ 的参数; (3) 由 $H(z)$ 的参数来估计 $x(n)$ 的功率谱。

假定 $u(n)$ 、 $x(n)$ 均为实平稳的随机信号, $u(n)$ 为方差为 σ^2 的白噪声, AR 参数模型的输入 $u(n)$ 和输出 $x(n)$ 的关系为:

$$x(n) = -\sum_{k=1}^p a_k x(n-k) + u(n) \quad (3)$$

记数据前向预测值 $\hat{x}^f(n)$ 与真实值 $x(n)$ 之间的误差为 $e^f(n)$, 误差功率为 ρ^f ; 后向预测值 $\hat{x}^b(n)$ 与真实值之

间的误差为 $e^b(n)$, 误差功率为 ρ^b 。AR 模型系数的 Burg 算法基本思想:

(1) 令前后向预测误差功率之和, 即 ρ^b 为最小;

(2) ρ^f 和 ρ^b 的求和范围为 $p \sim N-1$, 等效于 $e^f(n)$ 、 $e^b(n)$ 前后都不加窗;

(3) 当阶次 m 由 1 至 p 时, 令 ρ^b 对 k_m 为最小, 即可估计出反射系数:

$$\hat{k}_m = \frac{-2 \sum_{n=m}^{N-1} e_{m-1}^f(n) e_{m-1}^{b*}(n-1)}{\sum_{n=m}^{N-1} |e_{m-1}^f(n)|^2 + \sum_{n=m}^{N-1} |e_{m-1}^b(n-1)|^2} \quad m=1, 2, \dots, p \quad (4)$$

(4) 按上式求出 \hat{k}_m 后, 阶次为 m 时的 AR 模型系数由 Levinson 算法递推出, 即:

$$\begin{cases} \hat{a}_m(k) = \hat{a}_{m-1}(k) + \hat{k}_m \hat{a}_{m-1}^*(m-k) & k=1, 2, \dots, m-1 \\ \hat{a}_m(m) = \hat{k}_m \end{cases} \quad (5)$$

2.2 雷达中频信号的 AR 模型功率谱估计

利用 AR 功率谱估计的 Burg 算法对得到的仿真数据进行处理, 该数据由雷达中频信号、雷达噪声信号、杂波信号叠加而成。图 2 是 AR 模型功率谱估计的 Burg 算法分别对数据进行 40、45、50 节次的 2 048 点功率谱估计所得到的结果。

由图 2 可以看出, 在 $P=40$ 时, 尚不能完全分辨出两运动目标的上下扫频, 目标数据尚未拉开, 不利于目标识别; $P=45$ 和 $P=50$ 时上下扫频数据已完全分开, 能明

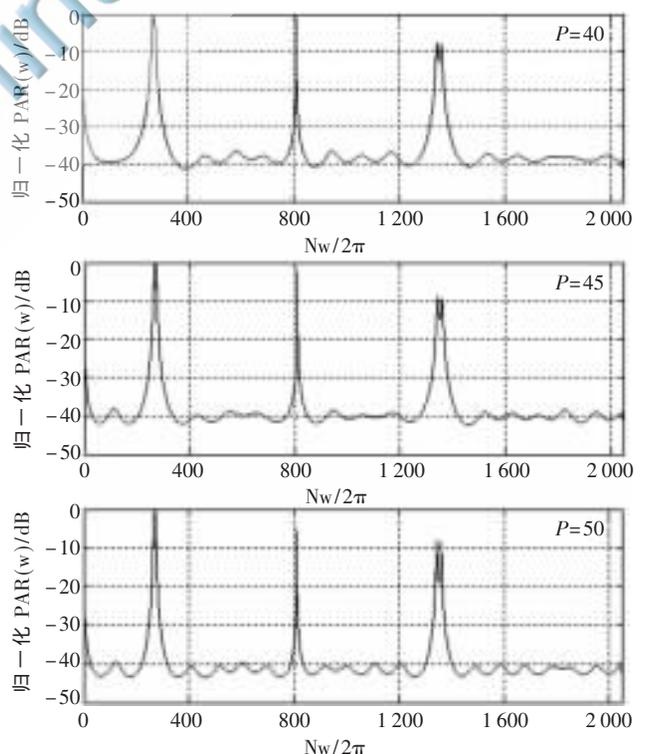


图 2 各节次功率谱估计

网络与通信

Network and Communication

确分辨目标信息。由于节次越高,算法越复杂,因此可以选择 AR 模型 45 节次的谱估计。

3 粗神经网络在防撞雷达目标识别中的应用

3.1 粗集理论及粗神经网络

给定一有限的非空集合 U, R 为 U 上的一组等效关系, 设 X 为 U 的一个子集, a 为 U 的一个对象, $[a]_R$ 表示所有与 a 不可分辨的对象所组成的集合。称 $R_-(X) = \{a \in U: [a]_R \subseteq X\}$ 为集合 X 的下近似集; 称 $R^-(X) = \{a \in U: [a]_R \cap X \neq \emptyset\}$ 为集合 X 的上近似集; 称集合 $BN_R(X) = R^-(X) - R_-(X)$ 为 X 的 R 边界域; 称 $POS_R(X) = R_-(X)$ 为 X 的 R 正域; 称 $NEGR(X) = U - R_-(X)$ 为 X 的 R 负域。

由以上可知, 下近似 $R_-(X)$ 是由必定属于 X 的对象组成的集合; 而上近似 $R^-(X)$ 是由可能属于 X 的对象组成的集合; $NEGR(X)$ 则表示一定不属于 X 的对象组成的集合。当 $BN_R(X) = \emptyset$ 时, 即 $R^-(X) = R_-(X)$, 称 X 是 R 的精确集; 当 $BN_R(X) \neq \emptyset$ 时, 即 $R^-(X) \neq R_-(X)$, 称 X 是 R 的粗糙集^[5]。

根据粗集的概念, 把神经元分成上下两层, 分别代表粗糙集合的上下近似组成粗神经元。 U, L 分别表示上、下近似, 两个粗神经元之间有 4 种基本的连接方式, 如图 3 所示, 其组合连接方式如图 3(e) 所示。

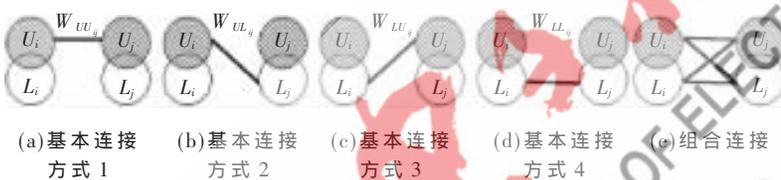


图 3 神经元连接方式

$$\text{Input } U_j = \sum_i (W_{U_i U_j} \times \text{Output } U_i + W_{L_i U_j} \times \text{Output } L_i) \quad (6)$$

$$\text{Input } L_j = \sum_i (W_{U_i L_j} \times \text{Output } U_i + W_{L_i L_j} \times \text{Output } L_i) \quad (7)$$

式中 i 是和 j 相连的神经元, $W_{U_i U_j}, W_{U_i L_j}, W_{L_i U_j}, W_{L_i L_j}$ 分别为 i 的上下神经元与 j 的上下神经元之间的权。粗神经网络 j 的输出可计算为:

$$\text{Output } U_j = \max\{f_U(\text{Input } U_j - \theta_{U_j}), f_L(\text{Input } L_j - \theta_{L_j})\} \quad (8)$$

$$\text{Output } L_j = \min\{f_U(\text{Input } U_j - \theta_{U_j}), f_L(\text{Input } L_j - \theta_{L_j})\}$$

式中, θ_{U_j} 和 θ_{L_j} 分别为粗神经网络 j 的上下两神经元的阈值; f_U 和 f_L 为上下两层的传递函数。可通过设定权值和连接情况, 得到多种不同的神经网络结构。

定义粗神经网络的误差传递函数:

$$E = \frac{1}{2} \sum_{p=1}^N [(O_{U_p} - Q_{U_p}) - (O_{L_p} - Q_{L_p})]^2 \quad (9)$$

式中, O_{U_p} 为神经元 P 上层的实际输出, Q_{U_p} 为神经元 P 上层的理想输出, O_{L_p} 为神经元 P 下层的实际输出, Q_{L_p} 为神经元 P 下层的理想输出, 定义 $O_{U_p} - O_{L_p} = O_p, Q_{U_p} - Q_{L_p} = Q_p$ 则有:

$$E = \frac{1}{2} \sum_{p=1}^N (O_p - Q_p)^2 \quad (10)$$

经过上述处理, 粗神经网络的学习算法完全可以借用传统的 BP 神经网络的学习算法。

3.2 基于粗神经网络的雷达目标识别

BP 网络具有逼近任意连续函数和非线性映射的能力^[6], 能模拟任意的非线性输入输出关系。网络的各层维数越大, 其收敛速度越慢, 因此要对输入数据进行预处理来减小信号冗余度, 从而降低 BP 网络的神经元数, 并适当提取信号的特征量作为 BP 网络的输入, 以提高识别率。

本文对功率谱估计数据进行以下处理: 首先进行门限判决, 判定门限值以下的数据为噪音信号并舍弃, 然后对目标数据根据幅值进行上下扫频配对, 最后分别以每个目标的上下扫频谱峰值为中心各取 20 个数据, 作为粗神经网络的输入。将处理后的数据形成控制规则映射到 BP 神经网络进行训练, 直到满足均方差要求为止。

本文所采用的神经网络输出层为 4, 输出矢量为 $Y = \{y_1, y_2, y_3, y_4\}$, 分别以行人、自行车、汽车和卡车作为识别对象输出。识别判定标准: 输出节点中各分量值大于 0.8 判定为 1, 小于 0.2 判定为 0。本文分别用 10 个隐

节点和 20 个隐节点的神经网络对两组数据进行处理, 第一组数据是用传统方法对雷达数据直接进行 FFT 变换后的频谱数据, 第二组数据是利用本文所介绍的方法, 首先对雷达数据进行功率谱估计, 然后对谱估计数据进行预处理所得到的数据。处理结果如表 1 所示。

表 1 粗神经网络目标识别结果

目标	数据 1/%		数据 2/%	
	10 个隐节点	20 个隐节点	10 个隐节点	20 个隐节点
行人	57.7	66.9	89.1	93.1
自行车	59.3	70.5	93.6	97.3
汽车	60.4	69.7	90.2	96.7
卡车	51.5	59.3	86.4	92.6

由表 1 可知, 直接用雷达回波数据作识别的传感器数据, 识别效果相对较差, 其原因是网络对其分类能力较差, 且目标之间的特征差别不明显。而将数据进行功率谱估计, 在经过门限判决和频域配对后, 其特征更显著, 20 个隐节点的网络结构识别率可达 90% 以上, 取得了较好的识别效果。

虚报警、漏报警率高是制约线性调频连续波雷达发展的重要因素, 本文从信号处理的角度出发, 采用 AR 参数模型功率谱估计以提高雷达数据的分辨率和准确度, 并将粗神经网络用于目标识别。仿真结果表明, 该方法可以减少防撞雷达的虚假目标。并且, 随着数字信号处理器件的发展, 基于 DSP 的汽车防撞雷达完全可以做

到实时处理各种复杂的信号处理算法,使开发者摆脱复杂算法和实时处理不能兼顾的困扰。

解决防撞雷达虚假目标的问题,还可通过其他途径,例如使雷达具备测角能力,通过目标的方位角信息可助于排除虚假目标;还可设计易于产生,抗干扰性能强的复杂雷达发射信号,配合以实时高效的信号处理和目标检测算法。对于防撞雷达虚假目标的问题,作者还将做进一步的研究实践。

参考文献

- [1] 王晓丹,王积勤.雷达目标识别技术综述[J].现代雷达,2003,25(5):21-26.
- [2] 张浩,薛伟,余稳,等.一种应用于毫米波车流量检测雷达的背景功率谱识别方法[J].毫米与红外波学报,2008,12

(27):438-441.

- [3] 杜小丹,杜雨.一种人工神经网络算法在汽车防撞雷达中的应用[J].计算机应用研究,2005,22(11):154-156.
- [4] 雷景生.基于混合神经网络的模糊辨识方法[J].复旦学报,2004,43(5):880-883.
- [5] 张东波,王耀南,黄辉先.基于模糊粗糙模型的粗神经网络建模方法研究[J].自动化学报,2008,34(8):1016-1023.
- [6] 巩华,郑链,宋承天.粗神经网络在雷达目标识别中的应用[J].电光与控制,2005,12(1):80-82.

(收稿日期:2011-03-26)

作者简介:

孙艳敏,女,1982年生,工学硕士,助教,主要研究方向:数字信号处理技术、嵌入式系统。

