

# The Pre-diagnosis Technology Research on SVM-Based Radar Fault

Yusong Wang

PLA of 91763, Qinhuangdao

Email: yunflyer@163.com

Received: Apr. 27th, 2011; revised: May 9th, 2011; accepted: May 19th, 2011.

**Abstract:** This paper brings Support Vector Machine (SVM) to the pre-diagnosis of radar fault, implementing the advance diagnosis of the latent radar fault. To solve the problems best, such as the process of radar fault diagnosis complexity and long-time diagnosis. This is due to SVM can solve the small sample, nonlinear classification problem, which are the characteristics of the latent radar fault. Finally, the paper through examples fully illustrates that the algorithm has the capacity of excluding the radar latent fault.

**Keywords:** SVM; Radar Fault; Pre-diagnosis

## 基于 SVM 的雷达故障预诊断技术研究

王玉松

海军 91763 部队, 秦皇岛

Email: yunflyer@163.com

收稿日期: 2011 年 4 月 27 日; 修回日期: 2011 年 5 月 9 日; 录用日期: 2011 年 5 月 19 日

**摘要:** 本文将支持向量机(SVM)引入雷达故障预诊断, 实现了雷达进入潜伏性故障时就提前诊断。很好地解决雷达故障诊断流程复杂、诊断时间长等问题。这是由于 SVM 可以很好地解决小样本、非线性分类问题, 而这正是潜伏性雷达故障的特点。本文最后通过实例充分说明了该算法在排除雷达潜伏性故障方面的能力。

**关键词:** SVM; 雷达故障; 预诊断

### 1. 引言

随着新军事变革和军队信息化的发展, 各种新体制雷达不断出现, 其结构复杂、功能强大、数字化程度越来越高。这在大大增强我军信息化力量的同时, 也带来了问题: 雷达故障诊断流程复杂、诊断时间长、维修困难、维修费用高; 更迫切的一点是如何提高雷达在战争或演练中的可靠性<sup>[1]</sup>。本文探讨一种基于支持向量机(support vector machine)的雷达故障预诊断技术, 其基于结构风险最小化原理, 很好地解决雷达故障小样本、非线性的分类和回归问题<sup>[2]</sup>, 最后通过

实例说明该技术对于潜伏性故障的诊断能力。

### 2. 雷达故障预诊断流程

本文将雷达故障预诊断分为系统状态预测和故障预处理两部分, 其工作流程如图 1 示, 当系统状态特征参数数值超过设定阈值, 则进入故障预诊断工作状态<sup>[3]</sup>。

由于雷达故障特征参数的样本数据是在发现系统处于潜伏性异常工作状态时才开始采集, 因而获取的训练数据多数为有限的小样本数据<sup>[4]</sup>。此外, 又因为特征参数数据通常处于非线性的变化状态, 为此本文

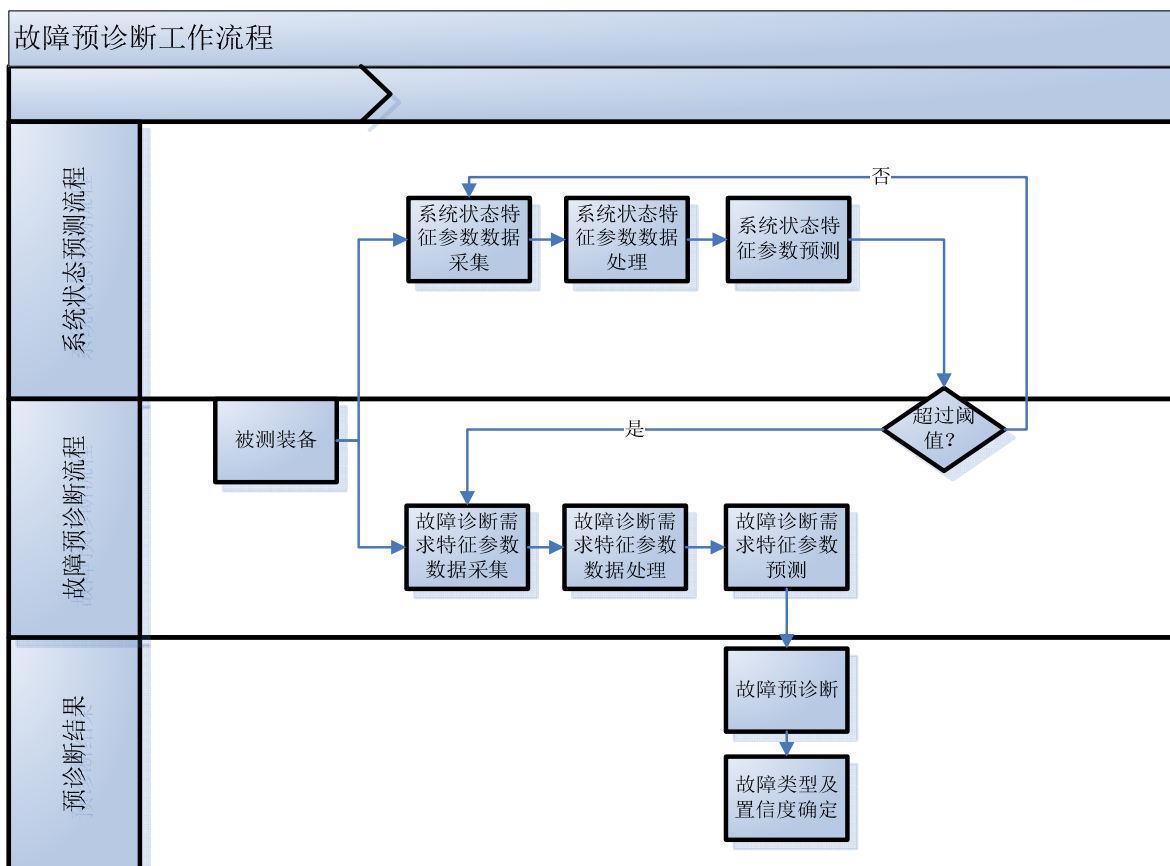


Figure 1. Pretreatment processes Radar Fault  
图 1. 雷达故障预处理工作流程

提出基于 SVM 的雷达故障特征参数的状态预测。

### 3. SVM 回归算法

#### 3.1. SVM 回归算法原理

SVM 回归算法的思想是将原始数据  $X$  非线性映射到高维特征空间, 并在此特征空间解决线性回归问题<sup>[5]</sup>。因而, 给定一组数据集:

$$T = \{(x_1, y_1), \dots, (x_i, y_i), \dots, (x_l, y_l)\} \in (X \times Y)'$$

其中  $\mathbf{X}_i \in \mathbf{Y} = \mathbf{R}^n$  是输入矢量, 是  $\mathbf{Y}_i \in \mathbf{Y} = \mathbf{R}$  相应输出值,  $l$  为训练样本总数, SVM 回归函数[6]:

$$f(x) = [\mathbf{w} \cdot \varphi(x)] + b \quad (1)$$

其中  $\varphi(x)$  为非线性映射函数,  $\mathbf{w}$  为权重矢量,  $b$  为偏差。  $\mathbf{w}$  和  $b$  通过最小化下列泛函进行估计:

$$R(\mathbf{w}) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^l L_\varepsilon(y_i, f(x_i)) \quad (2)$$

其中  $C$  是惩罚参数, 用于实现经验风险与模型平

滑性的折衷。 $\frac{\|\mathbf{w}\|^2}{2}$  为正则项。 $L_\varepsilon(y_i, f(x_i))$  为不敏感损失函数, 被定义为:

$$L_\varepsilon(y_i, f(x_i)) = \begin{cases} |y_i - f(x_i)| - \varepsilon, & |y_i - f(x_i)| \geq \varepsilon \\ 0, & |y_i - f(x_i)| < \varepsilon \end{cases} \quad (3)$$

在公式(3)中, 当预测值的误差在  $\varepsilon$  内, 损失等于 0, 否则损失等于超出  $\varepsilon$  部分。

为了度量  $\varepsilon$  不敏感带外的训练样本偏离程度, 引入非负松弛变量  $\xi$  和  $\xi^*$ 。SVM 优化的目标函数为:

$$\min \varphi(\mathbf{w}, \xi, \xi^*) = \frac{1}{2} \|\mathbf{w}\|^2 + C \sum_{i=1}^l (\xi + \xi^*) \quad (4)$$

$$\text{s.t.} \begin{cases} y_i - [\mathbf{w} \cdot \varphi(x)] - b \leq \varepsilon + \xi_i, \xi_i \geq 0 \\ \mathbf{w} \cdot \varphi(x) + b - y_i \leq \varepsilon + \xi_i^*, \xi_i^* \geq 0 \end{cases}$$

将式(4)最优化问题转化为对偶问题:

$$\begin{aligned} & \max H(\partial, \partial^*) \\ & = -\frac{1}{2} \sum_{i=1}^l \sum_{j=1}^l (\partial - \partial^*) (\partial - \partial^*) K(x_i, x_j) \quad (5) \\ & \quad + \sum_{i=1}^l y_i (\partial - \partial^*) - \varepsilon \sum_{i=1}^l (\partial + \partial^*) \\ & \text{s.t. } \sum_{i=1}^l (\partial_i - \partial_i^*) = 0, \quad \partial_i, \partial_i^* \in [0, C] \end{aligned}$$

其中  $\partial_i, \partial_i^*$  为 Lagrangian 乘子,  $(\partial - \partial^*) \neq 0$  对应的数据点为支持向量。通过  $\partial_i$  和  $\partial_i^*$  计算, 获取回归超平面的优化权重矢量, 即:

$$\mathbf{w}^* = \sum_{i=1}^l (\partial_i - \partial_i^*) K(x_i, x) \quad (6)$$

回归函数为:

$$f(x) = \sum_{i=1}^l (\partial_i - \partial_i^*) K(x_i, x) + b \quad (7)$$

由以上推理可知通过回归函数  $y_s = \sum_{i=1}^{n-m} (\partial_i - \partial_i^*) K(x_i, x_s) + b$ ,  $s=1, 2, \dots, n-m$ , 求得  $\partial_i, \partial_i^*$  和  $b$ , 从而获得 SVM 预测模型。即对 SVM 进行回归训练。

### 3.2. 算法实现

故障特征参数的状态趋势预测是一个时序预测问题, 其最终目的是利用从历史数据中获取的训练样本, 以寻求一个具有良好推广能力的预测模型。基于 SVM 的故障特征参数的状态预测步骤主要包括: (1) 数据预处理; (2) 构建训练集样本; (3) 利用训练的 SVM 进行预测。其中的关键是进行 SVM 样本训练, 它直接关系到对雷达故障预诊断的效果。其流程图如图 2 示。

通过式  $\hat{y}_{n-m+1} = \sum_{i=1}^{n-m} (\partial_i - \partial_i^*) K(x_i, x_{n-m+1}) + b$  对第  $n+1$  点进行预测, 输入矢量  $\mathbf{x}_{n-m+1} = \{a_{n-m+1}, a_{n-m+2}, \dots, a_n\}$ , 得到第  $n+1$  点的预测值  $\hat{y}_{n-m+1} = \{\hat{a}_{n+1}\}$ , 以第  $n+1$  点的预测值  $\hat{a}_{n+1}$  为属性, 构建下一个预测点的输入矢量  $\mathbf{x}_{n-m+2} = \{a_{n-m+2}, a_{n-m+3}, \dots, \hat{a}_{n+1}\}$ , 从而获得第  $n+2$  点的预测值  $\hat{y}_{n-m+2} = \{\hat{a}_{n+2}\}$ , 以此类推, 直到完成所需预测点的数目。利用 MAPE 评价预测精度。

$$\text{MAPE} = \frac{1}{N} \sum_{k=1}^N \frac{|y_k - \hat{y}_k|}{y_k} \times 100\%$$

式中,  $y_k$  和  $\hat{y}_k$  分别为实际和预测值,  $N$  为预测点的数目。

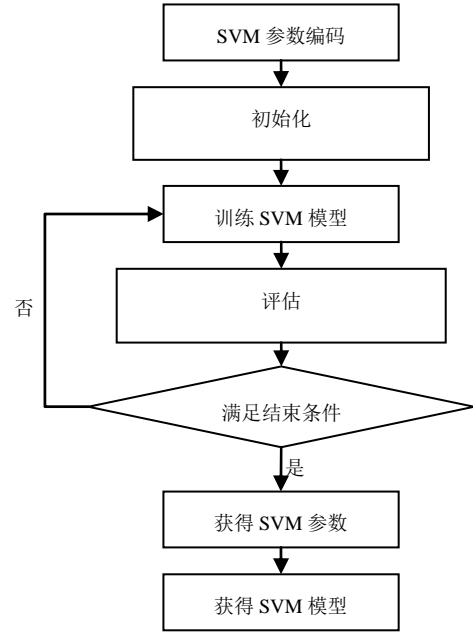


Figure 2. SVM algorithm flow chart  
图 2. SVM 算法实现流程图

### 4. 雷达故障预诊断实例

以某型雷达频率综合器电路为例, 首先建立故障状态样本表。根据电路工作原理和使用过程中的经验, 通过对电路进行仿真, 分析各种故障现象和故障类型, 选择 10 个故障组成故障集。输入为电路板中 8 个关键测试点的波形参数(频率  $F$  和幅度  $V$ )。对该电路在元器件容差范围为 3%、6%、9%、12%、15% 时做 20 次仿真分析, 得到各关键测试点波形频率和幅度在四种容差条件下的容差边界值, 经归一化处理得到各故障状态的测试样本。表 1 为在惩罚因子  $C$  和非负松弛变量  $\xi$  分别取  $2^5$  和  $2^4$  情况下对测试样本的诊断结果。

表 2 为某雷达的频率综合器在实际工作过程中出现异常时的实测样例, 利用本文提出的快速预诊断方法达到了 100% 的诊断正确率。

Table 1. The boundaries of the four characteristics of tolerance diagnosis  
表 1. 对四种容差的边界特征的诊断结果

容差范围	3%	6%	9%	12%	15%
诊断正确率	99%	95%	87%	82%	60%

**Table 2. The boundaries of the four characteristics of tolerance diagnosis**  
**表 2. 某雷达频率综合器故障预诊断实测样例**

样	输入数据															
	A1		A2		A3		A4		A5		A6		A7		A8	
本	F1	V1	F2	V2	F3	V3	F4	V4	F5	V5	F6	V6	F7	V7	F8	V8
1	3.07	4.05	3.07	4.05	3.07	4.05	3.07	22.6	3.07	4.05	3.07	4.05	3.07	4.05	3.07	4.05
2	0.00	0.00	0.00	0.00	0.00	0.00	0.00	0.00	3.50	4.05	3.07	4.05	3.07	4.05	3.07	4.05
3	3.10	4.12	0.03	0.05	0.03	0.05	0.03	0.05	3.10	4.12	3.10	4.12	3.10	4.12	3.10	4.12
4	3.07	4.05	3.07	4.05	0.10	0.20	0.00	3.07	3.07	4.05	3.07	4.05	3.07	4.05	3.10	4.12
5	3.05	4.00	3.10	4.05	3.07	4.05	0.00	0.00	3.05	4.00	3.07	4.05	3.07	4.05	3.07	4.05

### 5. 总结

本文探讨一种雷达故障预诊断技术，很好地解决雷达故障诊断流程复杂、诊断时间长问题，并且实现了雷达进入潜伏性故障时就提前诊断。将 SVM 引入雷达故障预诊断，是由于 SVM 是在小样本学习理论和结构风险最小化理论上发展起来的，具有很强的自学习能力。本文最后通过雷达故障预诊断实例充分说明了该算法在保障雷达正常工作，排除装备潜伏性故障方面，有很好的推广价值。当然，该算法还有需要改进的地方，若通过遗传算法对 SVM 参数进行优化，雷达故障预诊断效果或许会更好。

### 参考文献 (References)

- [1] 虞和济, 陈长征, 张省等. 基于神经网络的智能诊断[M]. 北京: 冶金工业出版社, 2006.
- [2] 时文刚, 戴静君, 杜华军. 基于遗传算法的故障诊断规则提取方法的研究[J]. 航天控制, 2005, 23(5): 79-82.
- [3] 傅连东, 付曙光, 曾良才等. 基于遗传神经网络的故障智能诊断方法及其应用研究[J]. 液压与气动, 2007(4): 65-67.
- [4] 张金泽, 单甘霖. 改进的算法及其在故障诊断中的应用研究[J]. 电光与控制, 2006, 13(6): 97-100.
- [5] 费胜巍. 复杂装备诊断维护系统关键技术研究[D]. 南京理工大学, 2007.
- [6] 张金泽, 段修生. 支持向量机技术的雷达板级电路快速故障诊断[J]. 火力与指挥控制, 2008, 33(2): 86-90.