

# 一种 RVM 模糊模型辨识方法及在故障预报中的应用

胡昌华<sup>1</sup> 王兆强<sup>1</sup> 周志杰<sup>1</sup> 司小胜<sup>1,2</sup>

**摘要** 对复杂、病态、非线性动态系统进行故障预报的重点和难点是建立系统故障状况的数学模型, 通常难以建立精确的数学模型, 相比之下构建其模糊模型是一个有效途径. 本文研究了相关向量机 (Relevance vector machine, RVM) 与模糊推理系统 (Fuzzy inference system, FIS) 之间的内在联系, 证明了基于 RVM 的 FIS 具有一致逼近性, 并提出了一种基于 RVM 和梯度下降 (Gradient descent, GD) 算法的模糊模型辨识方法. 基于所给出的模糊模型辨识方法提出了一种新的故障预报算法. 仿真结果表明所建立的模糊模型不仅结构更加简单, 而且能达到更高的预测精度, 所提出的故障预报算法能准确地预报系统故障.

**关键词** 故障预报, 模糊模型, 系统辨识, 相关向量机

**DOI** 10.3724/SP.J.1004.2011.00503

## An RVM Fuzzy Model Identification Method and Its Application to Fault Prediction

HU Chang-Hua<sup>1</sup> WANG Zhao-Qiang<sup>1</sup> ZHOU Zhi-Jie<sup>1</sup> SI Xiao-Sheng<sup>1,2</sup>

**Abstract** For a dynamic system with complexity, morbidity and nonlinearity, it is significant and difficult to establish a fault prediction model accurately in general. Instead, to construct a suitable fuzzy model may be an effective alternative. In this paper, the inherent relationship between relevance vector machine (RVM) and fuzzy inference system (FIS) is investigated firstly, then the uniformly approximating capability of FIS based on RVM is proved. Next, a fuzzy model identification method based on RVM and gradient descent (GD) algorithm is presented as well. Finally, a new fault prediction algorithm is given on the basis of the presented fuzzy model identification method. The simulation studies illustrate that the presented fuzzy modeling method can generate a compacter model and achieve higher prediction accuracy as well. Based on the new fault prediction algorithm, the system fault can be predicted correctly.

**Key words** Fault prediction, fuzzy model, system identification, relevance vector machine (RVM)

随着工程实际系统规模的不断扩大, 系统的复杂性、病态和非线性等特性也逐步提高, 因此, 对其安全性和可靠性也提出了更高的要求. 特别是在航空航天、导弹武器系统、核电站等对安全性要求较高的领域, 一旦发生事故, 便会造成巨大的财产损失和人员伤亡. 故障预报是指根据系统过去和现在的监测信息, 预测故障发生的时间或者判断未来某个时刻系统是否会发生故障<sup>[1]</sup>. 由于故障预报技术能在故障发生之前对可能的故障做出判断, 可以有效地防止重大事故的发生, 因而受到了人们的广泛重视<sup>[2]</sup>.

故障预报的前提是根据系统的观测信息建立描

述系统故障状况的数学模型. 然而, 对于大多数系统来说, 往往具有复杂、病态、非线性等特性, 传统的建模方法难以建立精确的数学模型. 模糊系统是由一系列的 “If-Then” 规则组成的, 由于可以同时利用语言信息、数据信息以及现实世界中的模糊不确定性信息, 并且可以方便地选择初始参数以加速辨识算法的收敛, 而被广泛应用于复杂非线性系统建模中, 并取得了很好的效果<sup>[3-4]</sup>. 自 1992 年 Kosko<sup>[5]</sup> 和 Wang 等<sup>[6]</sup> 分别证明了模糊系统具有一致逼近性以来, 模糊建模技术的研究引起了广大科研工作者的兴趣. 通常, 模糊建模主要有两种途径<sup>[7]</sup>: 1) 基于先验知识的方法, 称为 “经验方法”, 基于此方法建立的模糊系统通常称为模糊专家系统; 2) 基于数据的方法, 称为 “数据驱动方法”, 基于此方法建立模糊模型的过程称为模糊模型辨识, 也是最常用的模糊建模方法. 另外, 也有一些学者研究将两者结合的方法<sup>[8]</sup>.

模糊模型辨识可分为参数辨识和结构辨识两部分. 参数辨识主要实现参数的优化学习, 常用的方法主要有梯度下降 (Gradient descent, GD) 算法、最小二乘 (Least square, LS) 方法、反向传播 (Back

收稿日期 2010-08-02 录用日期 2010-11-08  
Manuscript received August 2, 2010; accepted November 8, 2010

国家自然科学基金 (60736026, 61004069), 国家杰出青年基金 (61025014) 资助

Supported by National Natural Science Foundation of China (60736026, 61004069) and National Science Fund for Distinguished Youth Scholars of China (61025014)

1. 第二炮兵工程学院 302 教研室 西安 710025 2. 清华大学自动化系 北京 100084

1. Unit 302, Xi'an Institute of Hi-Tech, Xi'an 710025  
2. Department of Automation, Tsinghua University, Beijing 100084

propagation, BP) 算法以及其他一些智能优化方法(如遗传算法 (Genetic algorithm, GA), 粒子群优化 (Particle swarm optimization, PSO)) 等<sup>[9]</sup>. 相对于参数辨识, 结构辨识是模糊模型辨识的难点和核心<sup>[9]</sup>. 模糊模型结构辨识的主要任务是完成输入输出空间的合理划分. 常见的结构辨识方法主要有: 二叉回归树方法<sup>[10]</sup>、模糊网格方法<sup>[11]</sup>、神经网络方法<sup>[12]</sup>、聚类方法<sup>[13-14]</sup> 以及进化方法<sup>[15]</sup> (如 GA, PSO) 等, 但各自都存在一些缺陷, 在一定程度上模型的泛化能力和精度都不容乐观.

近年来, 将支持向量机 (Support vector machine, SVM) 和核函数思想融合到模糊系统理论中的研究, 大大改进了目前机器学习能力, 提高了模糊模型泛化能力和建模品质, 从而使基于 SVM 和核函数的模糊建模方法成为模糊建模领域的一个新的研究热点<sup>[7, 16]</sup>, 但 SVM 算法存在稀疏性不强、计算量大、核函数必须满足 Mercer 条件等缺点<sup>[17]</sup>. 相关向量机 (Relevance vector machine, RVM) 是由 Tipping<sup>[18]</sup> 提出的一种基于正定核的非线性机器学习算法, 它基于稀疏贝叶斯学习理论, 不仅具有 SVM 避免过学习的优点, 而且在达到与 SVM 相同性能的同时比 SVM 使用更少的核函数, 且核函数不需要满足 Mercer 条件, 具有较好的泛化能力<sup>[19]</sup>. 将相关向量机方法应用于模糊模型辨识是一种新思路, Kim 等<sup>[20]</sup> 最先利用 RVM 方法构造了 T-S 模糊推理系统, 但对 RVM 与模糊推理系统 (Fuzzy inference system, FIS) 的内在联系未作说明, 对所构造的 FIS 的一致逼近性未做理论证明, 以及对如何利用 RVM 方法构建 Mamdani 型模糊推理系统的情况未作研究. 目前利用 RVM 方法进行模糊模型辨识的研究还较少.

针对以上问题, 本文主要研究了以下内容: 首先, 从函数形式上分析了 RVM 和 FIS 之间的相似性, 给出了基于 RVM 的模糊模型的函数形式, 并利用 Stone-weierstrass 定理证明了其一致逼近性; 其次, 提出了一种基于 RVM 和 GD 的模糊模型辨识算法, 先用 RVM 方法提取模糊规则, 获取模型结构和参数的初始值, 再用 GD 算法对模型参数进行优化更新, 实现模糊模型的参数辨识; 进而, 基于所建立的模糊模型及其参数辨识方法提出了一种新的故障预报算法; 最后, 将所提出的模糊模型辨识算法和故障预报算法应用于连续釜式搅拌器 (Continuous stirred tank reactor, CSTR) 的数值仿真实验和某型捷联惯导系统中动调陀螺仪 (Dynamically tuned gyroscope, DTG) 的工程实例之中, 结果表明所建立的模糊模型具有简洁的模型结构和较高的预测精度, 能够对故障情况做出准确的预报.

## 1 问题描述

考虑一个多输入单输出的 Mamdani 型模糊模型, 模糊规则的一般形式是

$$R_j: \text{If } x_1 \text{ is } A_1^j \text{ and } x_2 \text{ is } A_2^j \text{ and } \cdots \text{ and } x_r \text{ is } A_r^j, \\ \text{Then } z \text{ is } B^j \quad (1)$$

在上式中,  $R_j$  ( $j = 1, 2, \dots, M$ ) 表示模糊规则,  $M$  是规则数目;  $x_i$  ( $i = 1, 2, \dots, r$ ) 表示输入,  $r$  是输入维数;  $z$  表示模糊模型的输出;  $A_i^j$  和  $B^j$  分别表示用模糊隶属度函数  $u_{A_i^j}(x_i)$  和  $u_{B^j}(z)$  表征的语言项.

若采用乘积推理机、单值模糊产生器及中心平均模糊消除器, 则整个模糊推理函数可表示为

$$f(\mathbf{x}) = \frac{\sum_{j=1}^M \bar{z}^j \left( \prod_{i=1}^r u_{A_i^j}(x_i) \right)}{\sum_{j=1}^M \left( \prod_{i=1}^r u_{A_i^j}(x_i) \right)} \quad (2)$$

其中,  $f: \mathbf{R}^r \rightarrow \mathbf{R}$ ,  $u_{A_i^j}(x_i)$  选为高斯型隶属函数,  $\bar{z}^j$  是  $u_{B^j}(z)$  在输出空间获得最大值的点.

本文的主要任务是完成如式 (2) 所示模糊模型的辨识, 并将其应用于故障预报领域, 具体可分为以下三部分:

### 1) 结构辨识

主要任务是完成模糊空间的划分, 确定式 (2) 中规则的数目  $M$ ;

### 2) 参数辨识

主要完成式 (2) 中隶属度函数参数 (包括中心和宽度) 以及结论参数  $\bar{z}^j$  等的最优估计;

3) 提出一种新的基于模糊模型的故障预报算法.

下面给出一种利用 RVM 辨识模糊模型的方法. RVM 主要用来从训练数据中抽取模糊规则, 确定模糊模型结构和参数的初始值, 建造初始的模糊模型.

## 2 基于相关向量机的模糊模型

若给定一个多输入单输出的训练样本集  $\{(\mathbf{x}_{k_1}, t_{k_1}), k_1 = 1, \dots, n\}$ ,  $\mathbf{x}_{k_1} \in \mathbf{R}^r$ ,  $t_{k_1} \in \mathbf{R}$ ,  $n$  为训练样本个数, 则 RVM 回归函数可写为

$$f(\mathbf{x}; \tilde{\mathbf{w}}) = \sum_{k_2=1}^N w_{k_2} K(\mathbf{x}, \tilde{\mathbf{x}}_{k_2}) + \tilde{w}_0 = \Phi(\mathbf{x}) \tilde{\mathbf{w}} \quad (3)$$

式中,  $\mathbf{x}$  表示输入向量,  $\tilde{\mathbf{w}} = [\tilde{w}_0, \tilde{w}_1, \dots, \tilde{w}_N]^T$  为非零的权值组成的向量,  $\tilde{\mathbf{x}}_{k_2}$  ( $k_2 = 1, \dots, N$ ) 表示相关向量,  $N$  为相关向量个数,  $K(\mathbf{x}, \tilde{\mathbf{x}}_{k_2})$  表示核函数,  $\Phi(\mathbf{x})$  为  $1 \times (N + 1)$  阶设计矩阵,  $\Phi(\mathbf{x}) =$

$[1, K(\mathbf{x}, \tilde{\mathbf{x}}_1), K(\mathbf{x}, \tilde{\mathbf{x}}_2), \dots, K(\mathbf{x}, \tilde{\mathbf{x}}_N)]$ . 有关 RVM 的基本原理详见文献 [18–21].

定义  $p_j(\mathbf{x}) = \prod_{i=1}^r u_{A_i^j}(\mathbf{x}) / \sum_{j=1}^M (\prod_{i=1}^r u_{A_i^j}(\mathbf{x}))$  为模糊基函数, 则式 (2) 可写为

$$f(\mathbf{x}) = \sum_{j=1}^M p_j(\mathbf{x}) \bar{z}^j = P^T(\mathbf{x}) \bar{Z} \quad (4)$$

式中,  $P(\mathbf{x}) = [p_1(\mathbf{x}), \dots, p_M(\mathbf{x})]^T$  表示模糊基函数矩阵,  $\bar{Z} = [\bar{z}^1, \dots, \bar{z}^M]^T$  表示结论参数矩阵.

比较式 (3) 和式 (4), 可以看出两者除了符号记法上有所不同外, 具有本质的相似性, 即: 都可以看作是一组基函数与其相应权值的乘积形式. 因此, 某些由稀疏贝叶斯理论得到的 RVM 模型可以解释成取加、乘模糊算子得到的 FIS; 同时某些由加、乘模糊算子得到的 FIS 也可以看作由稀疏贝叶斯理论得到的 RVM 模型. 这时, 每个作为相关向量的样本数据对应一条模糊推理规则, 相关向量在核函数中的取值对应模糊推理规则前件的隶属函数值, 从而使得两种机制融为一体, 这为基于样本数据辨识模糊模型提供了一种可行的方法. 下面给出一种利用 RVM 构建模糊模型的方法.

基于 RVM 的模糊模型具有如下函数形式

$$f(\mathbf{x}) = \frac{\sum_{j=1}^M \bar{z}^j K(\mathbf{x}, \tilde{\mathbf{x}}^j)}{\sum_{j=1}^M K(\mathbf{x}, \tilde{\mathbf{x}}^j)} + \tilde{w}_0 \quad (5)$$

式中,  $K(\mathbf{x}, \tilde{\mathbf{x}}^j) = \prod_{i=1}^r \mu_{A_i^j}(x_i)$  ( $j = 1, \dots, M$ ) 表示核函数,  $r$  是输入向量维数,  $M$  是模糊规则数目 (等于相关向量个数  $N$ ),  $\mu_{A_i^j}(x_i) = \exp[-\frac{1}{2}(\frac{x_i - \tilde{x}_i^j}{\sigma_i^j})^2]$  为高斯型隶属函数,  $\tilde{x}_i^j$  和  $\sigma_i^j$  分别表示隶属函数中心和宽度,  $\mathbf{x}$  表示输入向量,  $\tilde{\mathbf{x}}^j = [\tilde{x}_1^j, \dots, \tilde{x}_i^j, \dots, \tilde{x}_r^j]^T$  表示第  $j$  条规则的隶属函数中心向量,  $\bar{z}^j$  表示第  $j$  条规则相应的结论参数,  $\tilde{w}_0$  表示可调参数.

**定义 1**<sup>[22]</sup>. Stone 代数

设  $Z$  是一个定义在紧密论域  $U$  上的连续实函数的集合, 如果  $Z$  满足以下条件, 则称  $Z$  为紧密论域  $U$  上的一个 Stone 代数.

1)  $Z$  为一个代数, 即  $Z$  对加法、乘法和标量乘法是封闭的;

2)  $Z$  能分割  $U$  上的各点, 即对每一个  $\mathbf{x}, \mathbf{y} \in U$ , 若  $\mathbf{x} \neq \mathbf{y}$ , 则必然存在  $f \in Z$ , 使得  $f(\mathbf{x}) \neq f(\mathbf{y})$ ;

3)  $Z$  在  $U$  上任意一点不消失, 即对每一个  $\mathbf{x} \in U$ , 均存在  $f \in Z$ , 使得  $f(\mathbf{x}) \neq 0$ .

**引理 1**<sup>[6, 22]</sup>. Stone-weierstrass 定理

如果定义在紧密论域  $U$  上的连续实函数的集合  $Z$  是一个 Stone 代数, 则  $Z$  在  $U$  上所有连续实函数的集合  $C(U)$  中到处稠密, 即可以用  $Z$  中的元素任意逼近  $U$  上的任意连续函数  $g(\mathbf{x})$ .

基于以上 Stone 代数定义和 Stone-weierstrass 定理, 下面给出基于 RVM 的模糊模型的一致逼近性定理及证明.

**定理 1.** 基于 RVM 的模糊模型一致逼近性定理

若基于相关向量机的模糊模型  $Y$  集合包含式 (5) 所描述函数形式的所有函数, 那么  $Y$  对紧密论域  $U$  上的任意连续函数具有一致逼近性.

**证明.**

根据定义 1 和引理 1, 只需证明  $Y$  为紧密论域  $U$  上的一个 Stone 代数即可.

1) 首先证明  $Y$  为一个代数.

假设  $f_1, f_2 \in Y$ , 可以写成

$$f_1(\mathbf{x}) = \frac{\sum_{j_1=1}^{M_1} \bar{z}^{j_1} K(\mathbf{x}, \tilde{\mathbf{x}}^{j_1})}{\sum_{j_1=1}^{M_1} K(\mathbf{x}, \tilde{\mathbf{x}}^{j_1})} + \tilde{w}_{01}$$

$$f_2(\mathbf{x}) = \frac{\sum_{j_2=1}^{M_2} \bar{z}^{j_2} K(\mathbf{x}, \tilde{\mathbf{x}}^{j_2})}{\sum_{j_2=1}^{M_2} K(\mathbf{x}, \tilde{\mathbf{x}}^{j_2})} + \tilde{w}_{02}$$

a) 加法封闭性

$$f_1(\mathbf{x}) + f_2(\mathbf{x}) = \frac{\sum_{j_1=1}^{M_1} \sum_{j_2=1}^{M_2} (\bar{z}^{j_1} + \bar{z}^{j_2}) K(\mathbf{x}, \tilde{\mathbf{x}}^{j_1}) K(\mathbf{x}, \tilde{\mathbf{x}}^{j_2})}{\sum_{j_1=1}^{M_1} \sum_{j_2=1}^{M_2} K(\mathbf{x}, \tilde{\mathbf{x}}^{j_1}) K(\mathbf{x}, \tilde{\mathbf{x}}^{j_2})} + (\tilde{w}_{01} + \tilde{w}_{02}) \quad (6)$$

b) 乘法封闭性

$$f_1(\mathbf{x}) f_2(\mathbf{x}) = \frac{\sum_{j_1=1}^{M_1} \sum_{j_2=1}^{M_2} (\tilde{w}_{02} \bar{z}^{j_1} + \tilde{w}_{01} \bar{z}^{j_2} + \bar{z}^{j_1} \bar{z}^{j_2}) K(\mathbf{x}, \tilde{\mathbf{x}}^{j_1}) K(\mathbf{x}, \tilde{\mathbf{x}}^{j_2})}{\sum_{j_1=1}^{M_1} \sum_{j_2=1}^{M_2} K(\mathbf{x}, \tilde{\mathbf{x}}^{j_1}) K(\mathbf{x}, \tilde{\mathbf{x}}^{j_2})} + (\tilde{w}_{01} \tilde{w}_{02}) \quad (7)$$

c) 标量乘法封闭性

对任意的  $c \in \mathbf{R}$ , 有

$$cf_1(\mathbf{x}) = \frac{\sum_{j_1=1}^{M_1} (c\bar{z}^{j_1})K(\mathbf{x}, \tilde{\mathbf{x}}^{j_1})}{\sum_{j_1=1}^{M_1} K(\mathbf{x}, \tilde{\mathbf{x}}^{j_1})} + (c\tilde{w}_{01}) \quad (8)$$

由于隶属函数是高斯型隶属函数, 它们的乘积仍是高斯型的, 所以式 (6)~(8) 与式 (5) 具有相同的形式, 即  $f_1(\mathbf{x}) + f_2(\mathbf{x}) \in Y$ ,  $f_1(\mathbf{x})f_2(\mathbf{x}) \in Y$ ,  $cf_1(\mathbf{x}) \in Y$ , 故  $Y$  为一个代数.

2) 其次证明  $Y$  能分割  $U$  上的各点.

在此, 通过构造满足要求的函数来证明  $Y$  能分割  $U$  上的各点.

设任意  $\mathbf{x}^0, \mathbf{y}^0 \in U$ , 若  $\mathbf{x}^0 \neq \mathbf{y}^0$ , 要构造  $f \in Y$ , 使得  $f(\mathbf{x}^0) \neq f(\mathbf{y}^0)$ . 现设计  $f$  只有 2 条规则:

$R_1$ : If  $x_1$  is  $A_1^1$  and  $\dots$  and  $x_r$  is  $A_r^1$ , Then  $z$  is  $\bar{z}^1$

$R_2$ : If  $x_1$  is  $A_1^2$  and  $\dots$  and  $x_r$  is  $A_r^2$ , Then  $z$  is  $\bar{z}^2$

假设  $\mathbf{x}^0 = [x_1^0, x_2^0, \dots, x_r^0]^T$ ,  $\mathbf{y}^0 = [y_1^0, y_2^0, \dots, y_r^0]^T$ , 定义两个模糊集合  $A_i^1, A_i^2$  ( $i = 1, \dots, r$ ), 其相应的隶属函数为

$$\mu_{A_i^1}(x_i) = \exp\left[-\frac{(x_i - x_i^0)^2}{2}\right]$$

$$\mu_{A_i^2}(x_i) = \exp\left[-\frac{(x_i - y_i^0)^2}{2}\right]$$

这样就定义了  $f$  的部分设计参数, 只有  $\bar{z}^1, \bar{z}^2$  及  $w_{x0}, w_{y0}$  待定. 因此

$$f(\mathbf{x}^0) = \frac{\bar{z}^1 + \bar{z}^2 \prod_{i=1}^r \exp\left[\frac{-(x_i^0 - y_i^0)^2}{2}\right]}{1 + \prod_{i=1}^r \exp\left[\frac{-(x_i^0 - y_i^0)^2}{2}\right]} + w_{x0} \quad (9)$$

$$f(\mathbf{y}^0) = \frac{\bar{z}^2 + \bar{z}^1 \prod_{i=1}^r \exp\left[\frac{-(x_i^0 - y_i^0)^2}{2}\right]}{1 + \prod_{i=1}^r \exp\left[\frac{-(x_i^0 - y_i^0)^2}{2}\right]} + w_{y0} \quad (10)$$

因为  $\mathbf{x}^0 \neq \mathbf{y}^0$ , 总有某个  $i$ , 使  $x_i^0 \neq y_i^0$ , 因此, 存在  $\exp[-(x_i^0 - y_i^0)^2/2] \neq 1$ . 此时, 只需选择  $\bar{z}^1 = 0, \bar{z}^2 = 1$  且选取合适的  $w_{x0}, w_{y0}$ , 就可以得到  $f(\mathbf{x}^0) \neq f(\mathbf{y}^0)$ .

3) 最后证明  $Y$  在  $U$  上任意一点不消失.

在式 (5) 中, 只需选择  $\bar{z}^j \geq 0$  ( $j = 1, \dots, M$ ),  $\tilde{w}_0 > 0$ , 即可得

$$f(\mathbf{x}) = \frac{\sum_{j=1}^M \bar{z}^j K(\mathbf{x}, \tilde{\mathbf{x}}^j)}{\sum_{j=1}^M K(\mathbf{x}, \tilde{\mathbf{x}}^j)} + \tilde{w}_0 \geq 0 + \tilde{w}_0 > 0 \quad (11)$$

由上证明过程可知,  $Y$  为紧密论域  $U$  上的一个 Stone 代数. 因此, 可得:

基于 RVM 的模糊模型  $Y$  能以任意精度逼近紧密论域  $U$  上的任意连续实函数, 即对于紧密论域  $U$  上的任意连续实函数  $g(\mathbf{x})$ , 总能找到一个基于 RVM 的模糊模型  $f(\mathbf{x})$ , 使  $f(\mathbf{x})$  一致逼近于  $g(\mathbf{x})$ .  $\square$

**注 1.** 式 (5) 所示的函数形式相对于式 (2) 所表示的模糊推理模型增加了可调参数  $\tilde{w}_0$ , 从而提高了模型可调度, 但对函数类型没有影响, 即式 (5) 仍属于模糊模型.

由定理 1 可知: 利用 RVM 方法构建的如式 (5) 所示的模糊模型能以任意精度逼近任意连续实函数, 其中, 一项重要的工作就是要合理优化模型参数. 基于式 (5) 的函数形式, 下面给出一种基于相关向量机和梯度下降算法的模糊模型辨识方法.

### 3 基于相关向量机和梯度下降方法的模糊模型辨识

#### 3.1 结构辨识

在利用 RVM 方法辨识模糊模型的过程中, RVM 从训练样本中提取相关向量 (Relevance vectors, RVs), 每个相关向量对应一条规则. 可以得到基于 RVM 的模糊模型的结构辨识算法 1, 算法步骤为:

**步骤 1.** 输入输出数据预处理: 确定输入输出变量维数, 生成训练样本和检验样本;

**步骤 2.** 系统初始化: 包括超参数  $\boldsymbol{\alpha} = [\alpha_0, \alpha_1, \dots, \alpha_n]^T$ , 核函数宽度  $\sigma^2$ , 最大循环次数  $k_{\max}$ , 超参数上限  $\alpha_{\max}$ , 选取隶属函数类型为高斯型, 令  $k = 1$ ;

**步骤 3.** 计算超参数矩阵  $A = \text{diag}\{\alpha_0, \alpha_1, \dots, \alpha_n\}$  和设计矩阵  $\Phi$ ;

**步骤 4.** 计算权值的后验统计量  $\Sigma = (\sigma^{-2}\Phi^T\Phi + A)^{-1}$  和  $\boldsymbol{\mu} = \sigma^{-2}\Sigma\Phi^T\mathbf{t}$ ,  $\mathbf{t} = [t_1, \dots, t_n]^T$  为输出向量, 从而得出此时的  $\gamma_{k_3} = 1 - \alpha_{k_3}\Sigma_{(k_3+1)(k_3+1)}$ ,  $\Sigma_{(k_3+1)(k_3+1)}$  为权值后验协方差矩阵  $\Sigma$  的第  $k_3 + 1$  个对角元素,  $k_3 = 0, 1, \dots, n$ ;

**步骤 5.** 通过  $\alpha_{k_3}^{\text{new}} = \gamma_{k_3}/\mu_{(k_3+1)}^2$  和  $(\sigma^2)^{\text{new}} = \|\mathbf{t} - \Phi\boldsymbol{\mu}\|^2/(n - \sum_{k_3=0}^n \gamma_{k_3})$  两式更新超参数和核函数宽度,  $\mu_{(k_3+1)}$  为后验均值  $\boldsymbol{\mu}$  的第  $k_3 + 1$  项;

步骤 6.  $k = k + 1$ , 若  $k = k_{\max}$ , 转步骤 7, 否则返回步骤 3;

步骤 7. 删除超参数中  $\alpha_{k_3} \geq \alpha_{\max}$  的  $\alpha_{k_3}$  所对应的权值及其相应核函数, 设定其余样本为相关向量, 每个相关向量对应一条模糊规则, 相关向量对应的样本数据为  $(\tilde{\mathbf{x}}^j, \bar{z}^j)$  ( $j = 1, \dots, M$ ), 其中,  $M$  是模糊规则数目 (等于相关向量个数),  $\tilde{\mathbf{x}}^j$  为第  $j$  条规则的隶属函数中心向量初值,  $\bar{z}^j$  为相应的结论参数初值, 同时更新后的核函数宽度  $\sigma^2$  和权值  $w_0$  分别作为隶属函数宽度  $\sigma_i^j$  和可调参数  $\tilde{w}_0$  的初值.

### 3.2 参数辨识

下面利用 GD 算法对模型参数进行优化更新, 如果采用高斯型隶属函数, 用  $\theta$  表示所有待估计的参数, 则  $\theta = [\bar{z}^1, \dots, \bar{z}^M, \tilde{x}_1^1, \dots, \tilde{x}_r^M, \sigma_1^1, \dots, \sigma_r^M, \tilde{w}_0]^T$ .

假设获取的任一输入输出数据对为  $(\mathbf{x}_{k_1}, z_{k_1})$ ,  $f(\mathbf{x}_{k_1}; \theta)$  表示基于 RVM 的模糊模型输出,  $z_{k_1}$  表示实际输出,  $e(\theta)$  表示模型输出与实际输出之差,  $k_1 = 1, \dots, n$ ,  $n$  为训练数据个数.

取准则函数为

$$J = \frac{1}{2} \sum_{k_1=1}^n e^2(\theta) = \frac{1}{2} \sum_{k_1=1}^n [f(\mathbf{x}_{k_1}; \theta) - z_{k_1}]^2 \quad (12)$$

采用 GD 算法, 优化  $J$  获得结论参数  $\bar{z}^j$  ( $j = 1, 2, \dots, M$ ), 有

$$\bar{z}^j(\eta + 1) = \bar{z}^j(\eta) - \lambda_1 \left. \frac{\partial J}{\partial \bar{z}^j} \right|_{\theta = \theta(\eta)} \quad (13)$$

若将  $K(\mathbf{x}, \tilde{\mathbf{x}}^j)$  简记作  $K^j$ , 令  $a = \sum_{j=1}^M K^j$ ,  $b = \sum_{j=1}^M \bar{z}^j K^j$ , 则  $z = b/a + \tilde{w}_0$ . 那么

$$\frac{\partial J}{\partial \bar{z}^j} = \frac{\partial J}{\partial z} \frac{\partial z}{\partial b} \frac{\partial b}{\partial \bar{z}^j} = \sum_{k_1=1}^n (f(\mathbf{x}_{k_1}; \theta) - z_{k_1}) \frac{1}{a} K^j \quad (14)$$

将式 (14) 代入式 (13), 得  $\bar{z}^j$  的迭代公式为

$$\bar{z}^j(\eta + 1) = \bar{z}^j(\eta) - \lambda_1 \sum_{k_1=1}^n [(f(\mathbf{x}_{k_1}; \theta(\eta)) - z_{k_1}) \frac{1}{a(\eta)} K^j(\eta)] \quad (15)$$

同理可得,  $\tilde{x}_i^j$ ,  $\sigma_i^j$  ( $i = 1, 2, \dots, r$ ) 和  $\tilde{w}_0$  的迭代公式分别为

$$\tilde{x}_i^j(\eta + 1) = \tilde{x}_i^j(\eta) - \lambda_2 \sum_{k_1=1}^n \left\{ (f(\mathbf{x}_{k_1}; \theta(\eta)) - z_{k_1}) \times \frac{\bar{z}^j(\eta) - f(\mathbf{x}_{k_1}; \theta(\eta))}{a(\eta)} K^j(\eta) \frac{x_i(k_1) - \tilde{x}_i^j(\eta)}{(\sigma_i^j(\eta))^2} \right\} \quad (16)$$

$$\sigma_i^j(\eta + 1) = \sigma_i^j(\eta) - \lambda_3 \sum_{k_1=1}^n \left\{ (f(\mathbf{x}_{k_1}; \theta(\eta)) - z_{k_1}) \times \frac{\bar{z}^j(\eta) - f(\mathbf{x}_{k_1}; \theta(\eta))}{a(\eta)} K^j(\eta) \frac{x_i(k_1) - \tilde{x}_i^j(\eta)}{(\sigma_i^j(\eta))^3} \right\} \quad (17)$$

$$\tilde{w}_0(\eta + 1) = \tilde{w}_0(\eta) - \lambda_4 \sum_{k_1=1}^n [(f(\mathbf{x}_{k_1}; \theta(\eta)) - z_{k_1})] \quad (18)$$

其中,  $x_i(k_1)$  是输入  $\mathbf{x}_{k_1}$  的第  $i$  维,  $\lambda_1 \sim \lambda_4$  代表学习率,  $\eta$  代表迭代步数.

由于利用 RVM 方法进行结构辨识的过程中可以得到较优的参数初始值, 从而加快了运用 GD 算法对参数优化的收敛速度, 使参数得到了进一步优化.

### 3.3 基于相关向量机和梯度下降方法的模糊模型辨识算法

总结以上模糊模型结构辨识和参数辨识的步骤, 可得到基于 RVM 和 GD 的模糊模型辨识算法 2, 算法步骤如下:

步骤 1. 实验数据采集与预处理: 采集实验数据, 并对数据进行预处理, 生成样本数据;

步骤 2. 模型结构辨识: 调用算法 1, 确定模糊模型规则数目和参数初始值;

步骤 3. 模型参数辨识: 利用式 (15) ~ (18) 对参数训练优化, 得到优化的参数模型;

步骤 4. 模型验证: 利用检验样本验证模型的性能, 如果满足要求, 则最终确定模型; 否则, 返回步骤 1 重新学习训练.

## 4 基于相关向量机模糊模型的故障预报

利用基于 RVM 的模糊模型进行故障预报的实质是根据已有观测数据辨识系统模型, 预测表征系统故障情况的特征参数, 从而进行故障预报. 假设系统的输入输出观测数据可以表示为输入输出数据对的形式  $(\mathbf{x}(t), z(t))$ . 其中,  $\mathbf{x}(t)$  表示系统  $t$  时刻的输入向量, 由与系统输出相关的变量组成,  $z(t)$  表示系统  $t$  时刻的输出变量, 是描述系统故障情况的特

征参数. 考虑一步预测情况, 预测函数具有如下形式<sup>[23-24]</sup>:

$$\hat{z}(t) = f(x_{t-1}, x_{t-2}, \dots, x_{t-r}) \quad (19)$$

其中, 预测函数  $f(\cdot)$  由基于 RVM 的模糊模型式 (5) 得到,  $\hat{z}(t)$  为预测输出,  $r$  为与输出相关的向量个数.

基于 RVM 模糊模型的故障预报的基本原理是: 根据  $t$  时刻以前获得的有效信息  $(x_{t-1}, x_{t-2}, \dots, x_{t-r})$ , 利用式 (19) 预测  $t$  时刻的特征参数值  $\hat{z}(t)$ , 从而根据下式判断系统未来的故障情况.

$$\begin{aligned} &\text{The system is normal, If } |\hat{z}(t) - z_a(t)| < \varepsilon_0 \\ &\text{The system is failure, Otherwise} \end{aligned} \quad (20)$$

其中,  $z_a(t)$  为  $t$  时刻正常值,  $\varepsilon_0$  为预先设定的阈值.

基于以上故障预报原理的分析, 可得出基于 RVM 和 GD 的模糊模型的故障预报算法 3, 算法步骤为:

**步骤 1.** 数据采集和预处理: 选取表征系统故障情况的特征参数作为输出  $z(t)$ , 与之相关的变量构成输入向量  $\mathbf{x}(t)$ ;

**步骤 2.** 调用算法 2 中步骤 1 ~ 步骤 3, 辨识系统模型式 (19), 令  $t_k = 1$ ;

**步骤 3.** 选取输入变量  $\mathbf{x}(t_k)$ , 利用得出的模糊模型式 (19) 预测系统未来的故障特征参数  $\hat{z}(t_k + 1)$ ;

**步骤 4.** 选取恰当的阈值  $\varepsilon_0$ , 利用式 (20) 判断系统在  $t_k + 1$  时刻的故障情况;

**步骤 5.** 令  $t_k = t_k + 1$ , 返回步骤 3.

## 5 实验与分析

为验证本文所提出的模糊模型辨识算法及故障预报方法的有效性, 分别进行了 CSTR 的数值仿真实验和某型捷联惯导系统中 DTG 的工程实例研究, 并对实验结果作了分析比较, 得出了相应结论.

### 5.1 数值仿真实验

本节将利用所建立的模糊模型 (RVM-FIS) 对 CSTR 这一非线性系统进行辨识, 辨识精度采用平均绝对百分比误差 (Mean absolute percentage error, MAPE) 和均方根误差 (Root mean square error, RMSE) 来衡量, 将其预测结果与基于 SVM 的模糊模型 (SVM-FIS) 的预测结果作比较. SVM-FIS 借鉴文献 [16] 的建模方式: 先用 SVM 方法进行结构辨识, 再用 GD 算法进行参数辨识, 其中,  $C = 60$ , 不敏感系数  $\varepsilon = 0.5$ , 采用高斯核函数, 且核函数宽度  $\sigma_{svm} = 0.6$ .

CSTR 是一个多变量非线性系统, 反应物在其

内部发生不可逆放热反应, 可以通过控制流经反应器的冷却剂流速使反应物浓度达到生产要求, 其反应过程可由以下方程组来描述:

$$\begin{aligned} \frac{dC_A}{dt} &= \frac{q}{V}(C_{Af} - C_A) - k_0 \exp\left(-\frac{E}{RT}\right)C_A \\ \frac{dT_A}{dt} &= \frac{q}{V}(T_f - T_A) + \frac{-\Delta H}{\rho C_p} k_0 \exp\left(-\frac{E}{RT_A}\right)C_A + \\ &\quad \frac{UA}{V\rho C_p}(T_c - T_A) \end{aligned} \quad (21)$$

其中, 各参数的意义取值参见文献 [25].

对式 (21) 进行欧拉离散化, 并考虑系统噪声, 采样时间  $dt = 0.2 \text{ min}$ , 系统初始状态为:  $C_{A0} = 0.22 \text{ mol/L}$ ,  $T_{A0} = 447 \text{ K}$ . 反应器的控制律采用 PID 控制律<sup>[25]</sup>, 使反应物的浓度保持在  $0.2 \text{ mol/L}$ . 当系统运行 100 步后, 对系统设置一个变化, 使冷却剂流速按此趋势变化:  $q(s) = q(100) - (s - 100) \times 0.2$ . 其中,  $s \geq 100$ , 代表系统运行步数.

假设系统包含两个输入 (输入冷水温度  $T_c$  和冷却剂流速  $q$ ), 一个输出 (反应器温度  $T_A$ ). 取 300 个数据构成样本数据, 利用前 200 个数据进行训练, 后 100 个数据进行检验, 验证模型的辨识精度和有效性. 在训练阶段, 记录 RVM-FIS 和 SVM-FIS 生成模糊规则的条数; 在检验阶段, 用两种模型对反应器温度  $T_A$  进行预测, 完成后统计其预测误差和运行时间. 在主频  $1.91 \text{ GHz}$ , 内存  $1.00 \text{ GB}$  的计算机上进行仿真, 结果如图 1 ~ 4 所示. 两种模糊模型的预测结果定量指标如表 1 所示.




图 1 输入冷水温度和冷却剂流速曲线图  
Fig. 1 Graphs of imported cooling water and refrigerant flow rate

为评价故障预报的准确性, 考虑噪声的随机性,

进行了 100 次 Monte Carlo 仿真实验, 分别在选取故障阈值  $\varepsilon_0$  为 0.03 和 0.05 的情况下, 对系统故障预报的准确率进行了统计, 故障预报的准确率  $\zeta$  通过下式计算.

表 1 两种模糊模型预测结果比较  
Table 1 Comparison of two fuzzy models' predicting results

算法	最终规则数 (条)	MAPE	RMSE	预测时间 (s)
SVM-FIS	163	0.0134	0.1160	80.53
RVM-FIS	30	0.0122	0.1059	1.15

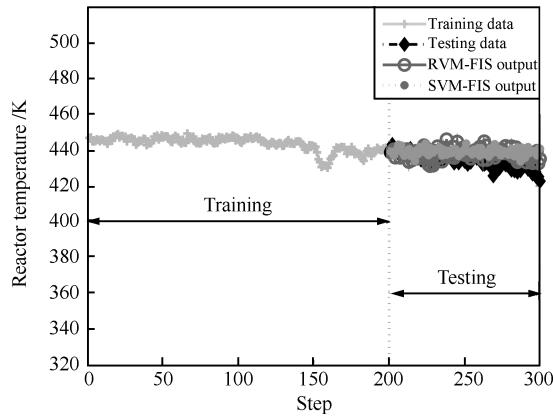


图 2 两种模糊模型的训练、测试曲线图

Fig. 2 Training and testing graph of two fuzzy models




图 3 两种模糊模型的预测曲线图

Fig. 3 Predicting graph of two fuzzy models

$$\zeta = \frac{\sum_{m=1}^{\text{num\_MC}} \frac{\text{num\_a}(m)}{\text{num\_t}}}{\text{num\_MC}} \times 100\% \quad (22)$$

式中, num\_MC 表示进行 Monte Carlo 仿真实验的次数, num\_t 表示每次实验测试点的个数, num\_a(m) 表示第 m 次实验中预测准确的点的个

数. 本实验的统计结果如下:  $\varepsilon_0$  取 0.03 时,  $\zeta = 92\%$ ;  $\varepsilon_0$  取 0.05 时,  $\zeta = 96\%$ .

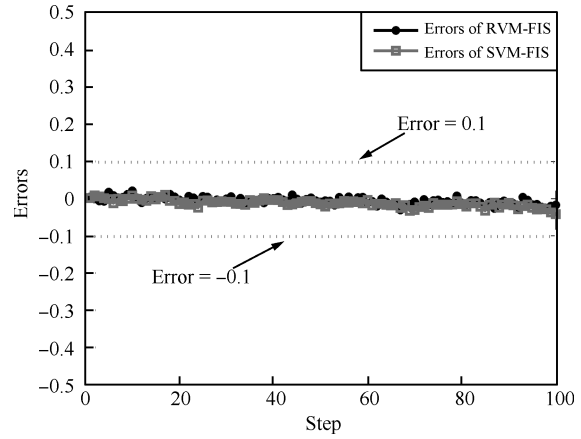


图 4 两种模糊模型的预测误差曲线图

Fig. 4 Predicting error graph of two fuzzy models

从图中可以看出, CSTR 具有较强的非线性, 两种模糊建模方法对其均具有较好的逼近能力, 预测结果与真实数据比较接近, 预测精度较高, 误差较小. 由表 1 的定量比较可以看出, 无论是 MAPE 还是 RMSE, RVM-FIS 的预测误差均比 SVM-FIS 小, 并且 RVM-FIS 只用了 30 条规则, 模型结构更简单, 进行预测的时间也只用到了 1.15 s, 速度比 SVM-FIS 有了大幅提高. 其原因是: RVM 的训练基于稀疏贝叶斯理论, 在训练时通过引入权值的超参数先验分布, 对 RVM 的权值进行了训练, 在训练过程中大部分权值会很快趋于零, 可以得到更少的模糊规则条数, 从而保证了解的稀疏性<sup>[19]</sup>. 也就是说, RVM-FIS 在保持与 SVM-FIS 精度相当的前提下, 模糊模型的结构相对更加简洁, 从而预测时间更短. 由故障预报准确率的统计结果可以看出, 所提出的故障预报算法具有较高的故障预报准确率, 从而得出以下结论:

- 1) 基于 RVM 和 GD 算法的模糊模型辨识方法是可行的, 且具有较高的辨识精度和泛化能力;
- 2) 相对于 SVM-FIS, RVM-FIS 具有下列优点: 模糊模型结构更加简单, 预测时间更快, 原因是 RVM 方法引入了超参数  $\alpha$ , 使模糊规则数更少, 模型稀疏性更强, 并保持了较高的精度; 不需要再计算正规化参数  $C$  和不敏感系数  $\varepsilon$ , 从而减小了计算量; 另外, RVM 核函数不需要满足 Mercer 条件;
- 3) 基于 RVM 模糊模型的故障预报算法具有较好的故障预报能力.

因此, 本文所提出的模糊模型辨识算法和故障预报方法是有效的. 下面将其应用于工程实际领域, 进一步验证其辨识能力和实际应用价值.

## 5.2 工程实例研究

陀螺仪是核心的惯性器件, 它的可靠性直接影响到导弹控制系统的性能, 对于保证整个控制系统的可靠性及安全性具有重要的意义, 其漂移误差是表征陀螺仪故障情况的重要特征参数. 以某型捷联惯导系统中的动调陀螺仪 (DTG) 的 21 个逐日漂移数据作为样本数据, 3 个数据组成一个样本, 其前 2 个值作为输入, 后 1 个值作为期望输出, 构成二维输入一维输出的数据对. 将形成的 19 个样本分成两组, 前 15 个构成训练样本用于学习建模, 后 4 个构成检验样本对该陀螺仪的故障情况进行预报.

对于故障预报问题, 核心是建立描述系统故障的数学模型, 关键是对表征系统故障情况的特征参数进行准确的预测. 为便于比较, 分别用如下三种模糊模型进行建模和预测: 1) RVM-FIS: 本文建模方法; 2) SVM-FIS: 建模方法同 CSTR 例子; 3) FCM-FIS: 借鉴文献 [26] 的建模方式: 先用模糊 C 均值聚类 (Fuzzy C-means, FCM) 进行结构辨识, 再用 GD 算法进行参数辨识, 其中, 模糊指数  $m = 2$ , 聚类个数  $c = 3$ . 陀螺仪漂移曲线如图 5 所示, 定量比较指标如表 2 所示.




图 5 陀螺仪漂移曲线图

Fig. 5 Chart of gyroscopic drift

表 2 三种模糊模型预测结果比较

Table 2 Comparison of three fuzzy models' predicting results

算法	最终规则数 (条)	MAPE	RMSE
SVM-FIS	4	0.0067	0.0165
FCM-FIS	3	0.0080	0.0233
RVM-FIS	3	0.0055	0.0105

若取阈值  $\varepsilon_0 = 0.03$ , 利用基于 RVM 的模糊模型对陀螺仪在第 16~19 天的故障情况进行预报, 预

报结果如图 6 所示.

从图 5 中可以看出, 三种模糊模型都能对陀螺仪的漂移趋势作出较为准确的预测. 但是, 从表 2 的定量指标的比较上, 可以明显看出, RVM-FIS 和 FCM-FIS 都只用了 3 条模糊规则, SVM-FIS 却用了 4 条模糊规则, 显然 RVM-FIS 和 FCM-FIS 的模型结构更加简洁. 然而, 无论是 MAPE 还是 RMSE, RVM-FIS 的预测误差都是最小的, 预测效果最好. 从图 6 中对陀螺仪故障情况的预报可以看出, 陀螺仪在第 16~19 天中处于正常状态.




图 6 第 16~19 天的陀螺仪故障预报结果

Fig. 6 Fault prediction result of gyroscope among the 16th~19th days

通过陀螺仪仿真实验可得出以下结论:

1) 基于 RVM 的模糊模型 (RVM-FIS) 能够对系统的特征参数做出准确的预测, 预测性能优于 SVM-FIS 和 FCM-FIS, 且模型更简洁, 这与 CSTR 例子得出的结果是一致的;

2) 基于 RVM 模糊模型的故障预报算法能准确地预报系统故障情况.

## 6 结论

本文提出了一种利用 RVM 辨识模糊模型的方法, 给出了其函数形式, 并通过 Stone-weierstrass 定理证明了基于 RVM 的模糊模型具有一致逼近性, 进而给出了一种基于 RVM 和 GD 算法的模糊模型辨识方法, 并将其应用于故障预报领域. 通过理论分析和仿真实验, 可以得出以下结论:

1) 基于 RVM 的模糊模型在理论上具有一致逼近性, 而且基于 RVM 的模糊模型可以同时利用定性知识和定量数据两方面的信息, 为将专家经验知识应用于模型辨识和控制提供了基础;

2) 基于 RVM 和 GD 算法的模糊模型辨识方法能够构造简洁的模糊模型, 且辨识精度较高;



3) 基于 RVM 模糊模型的故障预报算法可以对系统的故障情况做出准确的预报。

综上所述, 本文所提出的基于 RVM 的模糊模型及其相关算法具有理论可行性和一定的实际应用潜力, 未来的研究工作主要在于如何实现基于 RVM 的模糊模型的在线结构和参数辨识, 提高算法的精度以及故障预报的实时性等。

## References

- Zhou Dong-Hua, Hu Yan-Yan. Fault diagnosis techniques for dynamic systems. *Acta Automatica Sinica*, 2009, **35**(6): 748–758  
(周东华, 胡艳艳. 动态系统的故障诊断技术. 自动化学报, 2009, **35**(6): 748–758)
- Zhou Zhi-Jie, Hu Chang-Hua, Zhou Dong-Hua. Fault prediction techniques for dynamic systems based on non-analytical mode. *Information and Control*, 2006, **35**(5): 608–613  
(周志杰, 胡昌华, 周东华. 基于非解析模型的动态系统故障预报技术. 信息与控制, 2006, **35**(5): 608–613)
- Wan Feng, Sun You-Xian. Nonlinear discrete-time system identifications based on fuzzy models: algorithms and performance analyses. *Acta Automatica Sinica*, 2004, **30**(6): 844–853  
(万峰, 孙优贤. 基于模糊模型的非线性离散时间系统辨识: 算法与性能分析. 自动化学报, 2004, **30**(6): 844–853)
- Liao Long-Tao, Li Shao-Yuan, Huang Guang-Bin. T-S fuzzy model identification with growing and pruning rules for nonlinear systems. *Acta Automatica Sinica*, 2007, **33**(10): 1097–1100  
(廖龙涛, 李少远, 黄广斌. 规则可生长与修剪的非线性系统 T-S 模糊模型辨识. 自动化学报, 2007, **33**(10): 1097–1100)
- Kosko B. Fuzzy systems as universal approximators. In: *Proceedings of the IEEE International Conference on Fuzzy Systems*. San Diego, USA: IEEE, 1992. 1153–1162
- Wang L X, Mendel J M. Fuzzy basis functions, universal approximation, and orthogonal least-squares learning. *IEEE Transactions on Neural Networks*, 1992, **3**(5): 807–814
- Chen Yong-Yi. Support vector machine and fuzzy systems. *Fuzzy Systems and Mathematics*, 2005, **19**(1): 1–11  
(陈永义. 支持向量机方法与模糊系统. 模糊系统与数学, 2005, **19**(1): 1–11)
- Chen S W, Wang J, Wang D S. Extraction of fuzzy rules by using support vector machines. In: *Proceedings of the 5th International Conference on Fuzzy Systems and Knowledge Discovery*. Washington D. C., USA: IEEE, 2008. 438–442
- Dragan K. Design of adaptive Takagi-Sugeno-Kang fuzzy models. *Applied Soft Computing*, 2002, **2**(2): 89–103
- Sugeno M, Kang G T. Structure identification of fuzzy model. *Fuzzy Sets and Systems*, 1988, **28**(1): 15–33
- Jang J S R. ANFIS: adaptive-network-based fuzzy inference system. *IEEE Transactions on Systems, Man, and Cybernetics*, 1993, **23**(3): 665–685
- Nauck D, Kruse R. Designing fuzzy neural systems networks through backpropagation. *Fuzzy Modeling: Paradigms and Practice*. Boston: Kluwer Academic Publishers, 1996. 203–228
- Chen Jian-Qin, Xi Yu-Geng, Zhang Zhong-Jun. On-line identification of nonlinear systems using fuzzy models. *Acta Automatica Sinica*, 1998, **24**(1): 90–94  
(陈建勤, 席裕庚, 张钟俊. 用模糊模型在线辨识非线性系统. 自动化学报, 1998, **24**(1): 90–94)
- Li Shao-Yuan, Wang Qun-Xian, Li Huan-Zhi, Chen Zeng-Qiang, Yuan Zhu-Zhi. Identification and control based on Sugeno's fuzzy model. *Acta Automatica Sinica*, 1999, **25**(4): 488–492  
(李少远, 王群仙, 李焕芝, 陈增强, 袁著祉. Sugeno 模糊模型的辨识与控制. 自动化学报, 1999, **25**(4): 488–492)
- Chen C C. A PSO-based method for extracting fuzzy rules directly from numerical data. *Cybernetics and Systems*, 2006, **37**(7): 707–723
- Huang X X, Shi F H, Gu W, Chen S B. SVM-based fuzzy rules acquisition system for pulsed GTAW process. *Engineering Applications of Artificial Intelligence*, 2009, **22**(8): 1245–1255
- Xu X M, Mao Y F, Xiong J N, Zhou F L. Classification performance comparison between RVM and SVM. In: *Proceedings of the IEEE International Workshop on Anti-counterfeiting, Security, Identification*. Fujian, China: IEEE, 2007. 208–211
- Tipping M E. The relevance vector machine. In: *Proceedings of the 13th Annual Conference on Neural Information Processing Systems*. Cambridge, USA: The MIT Press, 1999. 652–658
- Tipping M E. Sparse Bayesian learning and the relevance vector machine. *Journal of Machine Learning Research*, 2001, **1**(3): 211–244
- Kim J, Suga Y, Won S. A new approach to fuzzy modeling of nonlinear dynamic systems with noise: relevance vector learning mechanism. *IEEE Transactions on Fuzzy Systems*, 2006, **14**(2): 222–231
- Zhang Xu-Dong, Chen Feng, Gao Jun, Fang Ting-Jian. Sparse Bayesian and its application to time series forecasting. *Control and Decision*, 2006, **21**(5): 585–588  
(张旭东, 陈锋, 高隽, 方廷健. 稀疏贝叶斯及其在时间序列预测中的应用. 控制与决策, 2006, **21**(5): 585–588)
- Jiadeke B K [Author], Shen Xie-Chang, Fang Qi-Qin, Lou Yuan-Ren, Xing Fu-Chong [Translator]. *Introduction to Polynomial Universal Approximation*. Beijing: Beijing University Press, 1989  
(Jiadeke B K [著], 沈燮昌, 方企勤, 娄元仁, 邢富冲 [译]. 多项式一致逼近函数导论. 北京: 北京大学出版社, 1989)

- 23 Si Xiao-Sheng, Hu Chang-Hua, Zhou Zhi-Jie. Fault prediction model based on evidential reasoning approach. *Science China: Information Sciences*, 2010, **53**(10): 2032–2046
- 24 Hu Chang-Hua, Si Xiao-Sheng. Real-time parameters estimation of inertial platform's health condition based on belief rule base. *Acta Aeronautica et Astronautica Sinica*, 2010, **31**(7): 1454–1465  
(胡昌华, 司小胜. 基于信度规则库的惯性平台健康状态参数在线估计. *航空学报*, 2010, **31**(7): 1454–1465)
- 25 Zhou Z J, Hu C H, Xu D L, Chen M Y, Zhou D H. A model for real-time failure prognosis based on hidden Markov model and belief rule base. *European Journal of Operational Research*, 2010, **207**(1): 269–283
- 26 Mitra S, Hayashi Y. Neuro-fuzzy rule generation: survey in soft computing framework. *IEEE Transactions on Neural Networks*, 2000, **11**(3): 748–768




**胡昌华** 第二炮兵工程学院教授. 主要研究方向为控制理论与应用、故障预报、诊断与可靠性工程. 本文通信作者.

E-mail: hch6603@263.net

(**HU Chang-Hua** Professor at Xi'an Institute of Hi-Tech. His research interest covers control theory and applications, fault prediction, fault diagnosis

and reliability engineering. Corresponding author of this paper.)



**王兆强** 第二炮兵工程学院硕士研究生. 主要研究方向为模糊系统与故障预报.

E-mail: zhaoqiangwang@126.com

(**WANG Zhao-Qiang** Master student at Xi'an Institute of Hi-Tech. His research interest covers fuzzy systems and fault prediction.)




**周志杰** 第二炮兵工程学院讲师, 博士. 主要研究方向为系统辨识、故障预测与最优维护.

E-mail: zhouzj04@mails.tsinghua.edu.cn

cn

(**ZHOU Zhi-Jie** Ph.D., lecturer at Xi'an Institute of Hi-Tech. His research interest covers system identifica-

tion, fault prediction and optimal maintenance.)



**司小胜** 第二炮兵工程学院和清华大学博士研究生. 主要研究方向为剩余寿命估计、故障预测、维修与可靠性工程.

E-mail: sxs09@mails.tsinghua.edu.cn

(**SI Xiao-Sheng** Ph.D. candidate at Xi'an Institute of Hi-Tech and Tsinghua University. His research interest covers remaining life estimating, fault

prediction, maintenance and reliability engineering.)