

基于 Fv-SVM 的机械故障诊断方法

吴 奇^{1,2}, 武书彦³, 刘 静⁴

(1. 东南大学 江苏省微纳生物医疗器械设计与制造重点实验室, 南京 211189; 2. 东南大学 复杂工程系统测量与控制教育部重点实验室, 南京 210096; 3. 郑州牧业工程高等专科学校, 郑州 450011; 4. 上海海事大学 信息工程学院, 上海 200135)

摘 要 针对机械故障诊断中存在的小样本、模糊、不确定性特征数据等问题, 将改进三角模糊理论与支持向量分类机 (SVM) 方法相结合, 提出一种 Fv-SVM 模型, 给出相应的机械故障诊断方法. 最后进行了复杂设备故障诊断的实例分析, 结果表明基于 Fv-SVM 的机械故障诊断方法是有效和可行的.

关键词 机械故障诊断; 支持向量分类机; 三角模糊数; 粒子群

Mechanical fault diagnoses approach based on Fv-SVM

WU Qi^{1,2}, WU Shu-yan³, LIU Jing⁴

(1. Jiangsu Key Laboratory for Design and Manufacture of Micro-Nano Biomedical Instruments, Southeast University, Nanjing 211189, China; 2. Key Laboratory of Measurement and Control of Complex Systems of Engineering, Ministry of Education, Southeast University, Nanjing 210096, China; 3. Zhengzhou College of Animal Husbandry, Zhengzhou 450011, China; 4. College of Information Engineering, Shanghai Maritime University, Shanghai 200135, China)

Abstract Aiming at the problems of small samples and uncertainty data in mechanical fault diagnoses, improved triangular fuzzy theory is combined with support vector classifier machine, and a kind of fuzzy support vector classifier machine named Fv-SVM is proposed. And then, a mechanical fault diagnoses method are put forward. The results of application in complex equipment show that the fault diagnoses method based on Fv-SVM is feasible and effective.

Keywords mechanical fault diagnoses; support vector classifier machine; triangular fuzzy number; particle swarm optimization

1 绪论

机电设备的在线状态监测及诊断是一个复杂动态过程, 其持续模式受很多因素的影响, 这些因素可分为确定性信息和不确定性信息, 而不确定信息大多呈现随机性、模糊性等特点. 这些因素之间有着复杂的非线性关系, 很难用一种确定性的方法来表达^[1-3]. 通常使用模糊神经网络模型来诊断和预示这些模式, 但神经网络本身是大样本分析方法, 泛化能力较差, 而且由于涉及的输入变量较多而使得模糊神经网络模型面临“维数灾难”问题.

由于各种原因, 在实际中很难得到大量的样本. 统计学理论专门研究小样本情况下机器学习的规律, 它根据有限的样本信息在模型的复杂性和学习能力之间寻求最佳折衷, 以获得最好的推广能力. 支持向量机 (Support vector machine, SVM)^[4] 是基于统计学理论的一种新的学习方法, 具有很好的泛化能力, 其得到的解是全局最优解, 而且能较好地解决小样本、非线性、高维数等实际问题, 目前已成为机器学习领域的研究热点^[5-12]. SVM 是针对模式识别问题提出来的, 然而对于很多带有模糊不确定性数据的特征模式问题, 标

收稿日期: 2009-04-07

资助项目: 国家自然科学基金 (60904043); 中国博士后科学基金 (20090451152); 江苏省博士后科研资助计划项目 (0901023C); 上海市教育发展基金会晨光计划 (2008CG55); 东南大学博士后重点科研 A 类资助

作者简介: 吴奇 (1978-), 男, 安徽肥东人, 博士后, 研究方向: 复杂系统诊断与预测、计算机视觉、生物计算、模式识别; 武书彦 (1975-), 河南人, 讲师, 研究方向: 计算机网络; 刘静 (1979-), 女, 安徽人, 讲师, 研究方向: 故障诊断、进化计算.

准 SVM 分类方法不能很好地处理. 针对这个问题, 本文将三角模糊理论与标准 SVM 进行组合, 从而形成一种新的模糊 SVM, 它可以有效处理这类具有模糊不确定性输入与输出的故障诊断问题.

由此, 本文首先提出一种新的分类型模糊支持向量机: Fv-SVM (Fuzzy v -support vector machine), 并将这种模型与复杂机械设备故障诊断的特点相结合, 从而得到一种智能故障诊断方法.

2 Fv-SVM 模型

一些学者对模糊支持向量机 (FSVM) 作了初步探索. 针对分类问题, Lin 和 Wang^[13] 提出的 FSVM 方法通过对每个输入样本增加一个模糊隶属度, 使得重要性不同的变量其错分程度也有不同的衡量要求, 但这种样本点隶属度的含义很模糊. 在回归估计问题上, Sun 和 Sun^[14] 将模糊化和模糊推理过程加入到最小二乘支持向量机 (LS-SVM) 之前, 对输入数据进行模糊预处理, 这种方法训练的是模糊规则. 在分析线性和非线性模糊回归理论的基础上, Hong 和 Hwang^[15] 首次提出了基于支持向量机的模糊回归模型, 但模型的推导不够严密.

通常观测到数据具有不确定性、模糊性, 利用三角模糊数可以较精确地描述这种模式. 为此我们将三角模糊数理论和 v -SVM 方法相融合, 发挥各自特长, 从而形成一种新的模糊支持向量分类机模型, 称之为 Fv-SVM.

2.1 三角模糊理论

在很多实际问题中, 部分或全部观测值往往用语言或不确定数据表达, 机械故障诊断的一些不确定性特征信息就属于这类问题, 由此建立的模型, 其输入和输出为三角模糊数, 参数为实数. 由于标准三角模糊数不便于基于模糊数幅度的支持向量机建模, 本文提出一种扩展三角模糊数, 可以建立基于模糊数幅度的模糊支持向量机模型, 具体如下:

设标准三角模糊数可以表示为 $M = (\alpha_M, r_M, \beta_M)$, $r_M \in R$ 是中心, $\alpha_M \in R$ 是左边界, $\beta_M \in R$ 是右边界^[16]. 为便于对三角模糊支持机建模, 本文提出一种扩展三角模糊数表示方法, 即: $M = (r_M, \Delta r_M, \overline{\Delta r_M})$, 其中 $\Delta r_M = r_M - \alpha_M$, $\overline{\Delta r_M} = \beta_M - r_M$.

设 $T(R)$ 和 $T(R)^d$ 分别表示 1 维和 d 维三角模糊数空间. A, B 为 $T(R)$ 上两模糊数, $A = (r_A, \Delta r_A, \overline{\Delta r_A})$, $B = (r_B, \Delta r_B, \overline{\Delta r_B})$, $r, \Delta r, \overline{\Delta r}$ 分别表示模糊数的中心和左右模糊幅度. $T(R)$ 上的线性运算定义为: $A+B = (r_A+r_B, \max(\Delta r_A, \Delta r_B), \max(\overline{\Delta r_A}, \overline{\Delta r_B}))$, $k \geq 0$ 时 $kA = (kr_A, \Delta r_A, \overline{\Delta r_A})$, $k < 0$ 时 $kA = (kr_A, \overline{\Delta r_A}, \Delta r_A)$, $A-B = (r_A-r_B, \max(\Delta r_A, \overline{\Delta r_B}), \max(\overline{\Delta r_A}, \Delta r_B))$. 记 A 的 λ 截集为 $A_\lambda = [\underline{A}(\lambda), \overline{A}(\lambda)]$, $\underline{A}(\lambda)$ 和 $\overline{A}(\lambda)$ 分别表示 λ 截集的左右端点, 则根据 Hausdorff 度量, 可定义 $T(R)$ 上的距离:

$$\begin{aligned} D(A, B) &= \sup_{\lambda} \max\{|\underline{A}(\lambda) - \underline{B}(\lambda)|, |\overline{A}(\lambda) - \overline{B}(\lambda)|\} \\ &= \max\{|(r_A - \Delta r_A) - (r_B - \Delta r_B)|, |r_A - r_B|, |(r_A + \overline{\Delta r_A}) - (r_B + \overline{\Delta r_B})|\} \end{aligned} \quad (1)$$




图 1 二个三角模糊数的 λ 截集

图 1 给出三角模糊数 A 和 B 的 λ 截集. 选择 l 个样本构成模糊训练集 $\{(x_i, y_i)\}_{i=1}^l$, $x_i \in T(R)^d$, $y_i = (r_i, \Delta r_i, \overline{\Delta r_i})$. 简单起见, 这里采用对称三角模糊数形式, $x_i = (r_{x_i}, \Delta r_{x_i})$, $y_i = (r_{y_i}, \Delta r_{y_i})$, 其中 $r_{x_i} = \Delta r_{x_i}$, $r_{y_i} = \Delta r_{y_i}$.

构造决策分类函数: $f(x) = \text{sgn}(w \cdot \varphi(x) + b)$, 其中 $w = (w^1, w^2, \dots, w^d)$, $w \cdot \varphi(x)$ 表示向量 w 与 $\varphi(x)$ 的内积. 在 $T(R)$ 上, $f(x)$ 可表示为:

$$f(x) = \text{sgn}(w \cdot \varphi(r_x) + b, \varphi(r_x)), \text{ 其中 } \varphi(\Delta r_x) = \max(\Delta r_x^1, \Delta r_x^2, \dots, \Delta r_x^d) \quad (2)$$

2.2 三角模糊支持向量分类机

对于线性或者非线性问题, 可以通过线性或者非线性变换 $r_x \rightarrow \varphi(r_x)$, 将原问题映射到某个高维线性特征空间, 然后在特征空间中构造分类决策函数. 在高维特征空间中, 线性问题中的内积运算可用核函数来代替, 即 $K(r_x, r_{x'}) = \varphi(r_x) \cdot \varphi(r_{x'})$.

根据 ν -SVM 用于分类的基本思想, 为了得到 $T(R)$ 上具有较好泛化能力的分类决策函数, 可通过如下的优化问题求解:

$$\begin{aligned} \min_{w, \xi, \rho, b} \quad & \tau(w, \xi^{(*)}, \varepsilon) = \frac{1}{2} \|w\|^2 - \nu\rho + \frac{1}{l} \sum_{k=1}^2 \sum_{i=1}^l \xi_{ki} \\ \text{s.t.} \quad & \begin{cases} (r_{y_i} + \Delta r_{y_i}) - (w \cdot \varphi(r_{x_i}) + b + \varphi(\Delta r_{x_i})) \geq \rho - \xi_{1i} \\ (r_{y_i} - \Delta r_{y_i}) - (w \cdot \varphi(r_{x_i}) + b - \varphi(\Delta r_{x_i})) \leq \rho - \xi_{2i} \\ \xi_{ki} \geq 0, \quad \rho \geq 0, \quad k = 1, 2 \end{cases} \end{aligned} \quad (3)$$

式中, $\rho > 0$; $\nu \in (0, 1]$ 为 ε 管道大小的控制参数 (图 2 给出 F ν -SVM 的 ε 不敏感管道); ξ_{ki} ($k = 1, 2; i = 1, 2, \dots, l$) 为松弛变量, 保证了约束的满足.




图 2 F ν -SVM 的 ε 不敏感管道

对上述问题定义 Lagrange 函数. Lagrange 函数对于参数 w, b, ρ, ξ 的偏导数都应等于零, 得到 (3) 式的对偶优化问题:

$$\begin{aligned} \max_a \quad & W(a) = -\frac{1}{2} \sum_{k=1}^2 \sum_{i=1}^l \sum_{j=1}^l y_i y_j a_{ki} a_{kj} K(r_{x_i} * r_{x_j}) \\ \text{s.t.} \quad & \sum_{k=1}^2 \sum_{i=1}^l y_i \alpha_{ki} = 0, \quad 0 \leq \alpha_{ki} \leq \frac{1}{l}, \quad \sum_{k=1}^2 \sum_{i=1}^l \alpha_{ki} \geq \nu \end{aligned} \quad (4)$$

其中, $\alpha_{ki} \geq 0$ ($k = 1, 2; i = 1, 2, \dots, l$) 为 Lagrange 乘子, $w = \sum_{k=1}^2 \sum_{i=1}^l (\alpha_{ki} - \alpha_{ki}^*) \varphi(r_{x_i})$.

根据 Karush-Kuhn-Tucker (KKT) 条件, 在最优解处, 有:

$$\begin{cases} \alpha_{1i}(r_{y_i} + \Delta r_{y_i} - w \cdot \varphi(r_{x_i}) - b - \varphi(\Delta r_{x_i}) - \rho + \xi_{1i}) = 0 \\ \alpha_{2i}(r_{y_i} - \Delta r_{y_i} - w \cdot \varphi(r_{x_i}) - b + \varphi(\Delta r_{x_i}) - \rho + \xi_{2i}) = 0 \\ (1/l - \alpha_{ki}) \xi_{ki} = 0 \\ \left[\nu - \sum_{k=1}^2 \sum_{i=1}^l \alpha_{ki} \right] \rho = 0 \end{cases} \quad (5)$$

由此可知, 最优化计算得到的 α_{ki} 必须满足: $\alpha_{ki} = 0$. 对于 $k = 1$ 和 $k = 2$ 两种情况来说, 在 ε_k 管道内, $\alpha_{ki} = 0$; 在管道之外的点为边界支持向量, $\alpha_{ki} = 1/l$ 或 0 ; 在管道边界上的点为标准支持向量, 此时 $\alpha_{ki} \in (0, 1/l)$ 或等于 0 , 而且满足:

$$b = r_{y_i} + \Delta r_{y_i} - w \cdot \varphi(r_{x_i}) - \varphi(\Delta r_{x_i}) - \rho, \quad \alpha_{1i} \in (0, 1/l) \quad (6)$$

或

$$b = r_{y_i} - \Delta r_{y_i} - w \cdot \varphi(r_{x_i}) + \varphi(\Delta r_{x_i}) - \rho, \quad \alpha_{2i} \in (0, 1/l) \quad (6')$$

从而可确定 b , 为计算可靠, 一般取平均值. (6) 和 (6') 两种情况实际上是等效的, 即分别求得平均值 b_1 和 b_2 满足: $b_1 = b_2 = b$. 二个等式对应的标准支持向量数分别记为 $n_{NSV1}^{(*)}$, $n_{NSV2}^{(*)}$, 若 $n_{NSV1}^{(*)} \neq 0$, 则 b 的计算式为:

$$b = \frac{\sum_{i \in n_{NSV1}} (r_{y_i} + \Delta r_{y_i} - w \cdot \varphi(r_{x_i}) - \varphi(\Delta r_{x_i}))}{2n_{NSV1}} + \frac{\sum_{j \in n_{NSV1}^{(*)}} (r_{y_j} + \Delta r_{y_j} - w \cdot \varphi(r_{x_j}) - \varphi(\Delta r_{x_j}))}{2n_{NSV1}^{(*)}} \quad (7)$$

确定 b 值后, 可得到决策分类函数 (2). 由式 (5) 最后一项推断, 式 (4) 中的不等式约束一般可写成等式约束. 进一步分析可知, lv 分别为边界支持向量数 (对应于间隙误差) 的上界和支持向量数的下界.

Fv-SVM 中的 v 的意义由下面的定理 1 给出:

定理 1 设已知训练集 $T = \{x_i, y_i\}_{i=1}^l$, 其中 $x_i \in T(R)^d$, $y_i \in T(R)$. 采用 Fv-SVM 进行分类, 若所得到的 ρ^* 值非零, 则:

- 1) 若记间隔错误样本点的个数为 p , 则 $v \geq p/l$, 即 v 是间隔错误样本的个数与样本容量之比的上界.
- 2) 若记支持向量的个数为 q , 则 $v \leq q/l$, 即 v 是支持向量的个数与样本容量之比的下界.

证明 1) 由 KKT 条件, 若 $\rho^* > 0$, 则对应约束 $\sum_{k=1}^2 \sum_{i=1}^l \alpha_{ki} \geq v$ 的乘子 $\delta = 0$, 约束 $\sum_{k=1}^2 \sum_{i=1}^l \alpha_{ki} \geq v$ 成为等式. 另一方面, 由于间隔错误样本点所对应的 $\xi_{ki} > 0$, 则 $\alpha_{ki} = \frac{1}{l}$, 因此 $v = \sum_{k=1}^2 \sum_{i=1}^l \alpha_{ki} \geq \frac{p}{l}$.

- 2) 由于支持向量所对应的 $\alpha_{ki} > 0$, 又由 $v = \sum_{k=1}^2 \sum_{i=1}^l \alpha_{ki} \leq \frac{q}{l}$.

由于可见, 在一定条件下, 当样本点个数 $l \rightarrow \infty$ 时, v 以 1 的概率渐近于支持向量个数和样本点个数之比.

3 基于 Fv-SVM 的故障诊断方法

3.1 模式影响因素的确定

复杂设备故障诊断在本质上属于非线性分类问题, 作为输入变量的影响因素种类较多, 可分为外界因素 (如设备工作环境) 和设备零部件内在故障因素这二个方面. 因此本文仅考察若干外在工作环境因素和若干关键零部件故障因素.

故障特征因素中, 有些不能用数值直接表示, 只能用语言描述. 对于语言型因素, 一般可以划分为若干个程度等级, 然后用 0-1 之间的数值表示. 实际收集到的数据往往具有不确定性, 采用模糊数的表示形式更能体现数据原貌.

3.2 分类算法

基于 Fv-SVM 模型, 对机械故障进行诊断的步骤为:

- Step 1** 对数据进行归一化和模糊化处理, 形成训练样本集;
- Step 2** 选择核函数 $K(x, x')$, 建立形如 (3) 式的优化目标函数;
- Step 3** 求解优化问题并判断 KKT 条件, 得到参数 α_{ki} , 由式 (7) 计算 b ;
- Step 4** 对新的输入 x , 根据式 (2) 计算决策值.

归一化处理将量纲不同的数据都表示为 0-1 之间的值. 模糊化处理时, 用观测值表示对称三角模糊数的中心, 模糊幅度取为观测值的函数, 这里取 $\Delta r_{x_i} = 0.1 \times r_{x_i}$.

对于一个 SVM 分类器来说, 决定其分类性能的关键因素是它的核函数, 选择了一个特定的核函数也就选择了它从样本空间到特征空间的特定映射情况. 但是不同核函数有不同的特点, 由它们所构成的 SVM 的性能也会有所差别. 目前用于 SVM 的核函数分为 2 大类: 全局核函数和局部核函数. 全局核函数 (例如线性核函数) 具有全局特性, 允许相距很远的的数据点都可以对核函数的值有影响; 而局部核函数 (如高斯核函数) 具有局部性, 只允许相距很近的数据点对核函数的值有影响. 当选择了一种核函数后, 也就选定了一种学习模型, 而一个学习模型性能的好坏是由学习能力和推广能力 (对未知样本的预测能力) 两方面决定的, 所以如何得到一个既有较好的学习能力, 又具有较好的推广能力就是我们很关心的问题. 鉴于故障模式样本数据间隔比较近, 而且很多应用经验也表明径向基核函数具有良好的学习能力, 故本文选择高斯径向基函数作为核函数.

4 应用实例

以某家电工厂注塑车间的注塑机故障诊断为例, 影响注塑机正常工作的因素有很多, 有些是数值型变量

(某些部件的振动频率), 有些是语言型变量 (如车间温度, 液压油的浓度, 原材料的含水浓度等). 利用 Matlab 语言编制相应的模型训练和分类诊断程序, 运行环境为 Core (TM)2 CPU 1.80GHz、内存 1.00G 的微机.

用训练好的模型对测试样本进行分类, 诊断结果如表 1 所示. 表中, 实际模式的原值是通过专家对该注塑机的故障模式进行评价所得到, 将诊断得到的值与实际模式的原值作比较更加合理. 从表 1 中可看出, 最大诊断误差为 28.6% (第 3 组), 最小诊断误差为 0.51% (第 12 组), 平均诊断误差为 5.68%. 实验结果也表明 Fv -SVM 能够将测试样本正确分开. 考虑到工厂机械设备运转的现实状况, 数据的收集和估计不可避免地存在着偏差, 因此诊断所得结果是满意的, 这也说明了 Fv -SVM 诊断方法是可行而且有效的.

表 1 测试样本的诊断结果

序号	特征模式						实际模式		Fv -SVM 诊断模式	
	A	B	C	D	E	F	原值	模式	诊断值	模式
1	0.9	0.0222	0.0037	1	0.0579	4	2.3	1	2.58	1
2	0.7	0.0614	0.0221	1	0.0329	14	-5.7	-1	-5.27	-1
3	0.9	0.0721	0.0329	1	0.0132	9	-1.5	-1	-1.93	-1
4	0.7	0.0534	0.0134	1	0.0099	7	6.7	1	7.50	1
5	0.5	0.0292	0.0228	2	0.0389	2	-3.8	-1	-3.73	-1
6	0.7	0.0858	0.0496	2	0.0028	3	6.4	1	6.35	1
7	0.1	0.0358	0.0722	4	0.0987	8	5.7	1	5.58	1
8	0.3	0.0802	0.0688	2	0.0038	2	-2.7	-1	-2.76	-1
9	0.5	0.0534	0.0557	1	0.0722	5	1.8	1	1.83	1
10	0.7	0.0567	0.0049	1	0.0988	9	5.2	1	5.16	1
11	0.3	0.0983	0.0553	8	0.0153	6	-4.6	-1	-4.55	-1
12	0.3	0.0344	0.0948	10	0.0468	4	3.9	1	3.92	1
13	0.5	0.0625	0.0861	1	0.0451	7	2.8	1	2.73	1

注: A 表示车间温度 (语言型变量); B 表示传动机构 (数值型变量); C 表示螺杆传动 (数值型变量); D 表示液压油浓度 (语言型变量); E 表示传动部分的传动轴 (数值型变量); F 表示原材料的含水浓度 (语言型变量).

表 2 故障诊断精度分析

Model	误诊率	漏诊率
v -SVM	23%	9%
Fv -SVM	7%	0%

为了便于对 Fv -SVM 模型的诊断精度进行分析, 标准 v -SVM 模型 (样本集由三角模糊数的中心组成) 也被用于训练上述故障模式. 表 2 给出了基于误诊率 (以百分比表示同类故障诊断错误次数与总诊断次数之比) 和漏诊率 (以百分比表示同类故障诊断遗漏次数与总诊断次数之比) 的分类效果分析. 可以明显看出, 对于本算例的故障模式, 本文给出的 Fv -SVM 的分类指标值均好于标准 v -SVM 模型的分类指标值. 这说明了基于 Fv -SVM 模型的诊断方法极具理论意义, 是可行而且有效的, 易于在工程实际中推广应用.

5 结论

复杂机电设备的故障模式受很多因素的影响, 大多故障诊断方法只考虑某些关键零部件的振动频率作为输入样本, 而忽略一些外界影响因素, 恰恰正是这些外界因素可能造成设备的非正常工作. 对于这些具有不确定性特征的外界影响因素, 标准支持向量机处理效果不好. 考虑到三角模糊技术能够刻画不确定故障知识的原貌, 并且将这些不确定性故障知识纳入支持向量机的最优化问题, 建立诊断模型, 从而整体上提高了系统的诊断能力.

由此可见, 本文所建立的基于 Fv -SVM 故障诊断模型, 解决了分布在广域范围内的故障知识的获取问题, 有利于解决专家系统中知识获取的瓶颈和降低复杂问题的求解难度, 能够为复杂机电设备故障诊断提供方便有效的诊断服务, 对于设备的技术保障具有重要的现实意义.

参考文献

- [1] 柴天佑, 丁进良, 王宏, 等. 复杂工业过程运行的混合智能优化控制方法 [J]. 自动化学报, 2008, 34(5): 505-515.

- Chai T Y, Ding J L, Wang H, et al. Hybrid intelligent optimal control method for operation of complex industrial processes[J]. *Acta Automatica Sinica*, 2008, 34(5): 505–515.
- [2] 陈茂银, 周东华. 一类非线性系统的故障诊断 [J]. *自动化学报*, 2004, 30(6): 1011–1016.
Chen M Y, Zhou D H. Fault detection and isolation in a class of nonlinear systems[J]. *Acta Automatica Sinica*, 2004, 30(6): 1011–1016.
- [3] 吕琛, 王桂增, 张泽宇. PWM 型 VLSI 神经网络在故障诊断中的应用 [J]. *自动化学报*, 2005, 31(2): 195–201.
Lü C, Wang G Z, Zhang Z Y. PWM VLSI neural network for fault diagnosis[J]. *Acta Automatica Sinica*, 2005, 31(2): 195–201.
- [4] Vapnik V. *The Nature of Statistical Learning*[M]. New York: Springer, 1995.
- [5] 张莉, 席裕庚. 基于支持向量机的可分离非线性动态系统辨识 [J]. *自动化学报*, 2005, 31(6): 965–969.
Zhang L, Xi Y G. Identification of separable variable nonlinear dynamical system based on SVMs[J]. *Acta Automatica Sinica*, 2005, 31(6): 965–969.
- [6] 程军圣, 于德介, 杨宇. 基于内禀模态奇异值分解和支持向量机的故障诊断方法 [J]. *自动化学报*, 2006, 32(3): 475–480.
Cheng J S, Yu D J, Yang Y. Fault diagnosis approach based on intrinsic mode singular value decomposition and support vector machines[J]. *Acta Automatica Sinica*, 2006, 32(3): 475–480.
- [7] 夏国恩, 金炜东. 基于支持向量机的客户流失预测模型 [J]. *系统工程理论与实践*, 2008, 28(1): 71–77.
Xia G E, Jin W D. Model of customer churn prediction on support vector machine[J]. *Systems Engineering — Theory & Practice*, 2008, 28(1): 71–77.
- [8] 于德介, 陈森峰, 程军圣, 等. 基于 AR 模型和支持向量机的转子系统故障诊断方法 [J]. *系统工程理论与实践*, 2007, 27(5): 152–157.
Yu D J, Chen M F, Cheng J S, et al. Fault diagnosis approach for rotor systems based on AR Model and support vector machine[J]. *Systems Engineering — Theory & Practice*, 2007, 27(5): 152–157.
- [9] 于滨, 杨忠振, 林剑艺. 应用支持向量机预测公交车运行时间 [J]. *系统工程理论与实践*, 2007, 27(4): 160–164.
Yu B, Yang Z Z, Lin J Y. Bus arrival time prediction using support vector machines[J]. *Systems Engineering — Theory & Practice*, 2007, 27(4): 160–164.
- [10] 董华, 杨世元, 吴德会. 基于模糊支持向量机的小批量生产质量智能预测方法 [J]. *系统工程理论与实践*, 2007, 27(3): 98–104.
Dong H, Yang S Y, Wu D H. Intelligent prediction method for small batch producing quality based on fuzzy least square SVM[J]. *Systems Engineering — Theory & Practice*, 2007, 27(3): 98–104.
- [11] 肖文兵, 费奇. 基于支持向量机的个人信用评估模型及最优参数选择研究 [J]. *系统工程理论与实践*, 2006, 26(10): 73–79.
Xiao W B, Fei Q. A study of personal credit scoring models on support vector machine with optimal choice of kernel function parameters[J]. *Systems Engineering — Theory & Practice*, 2006, 26(10): 73–79.
- [12] 蒋铁军, 李积源. 基于支持向量机的武器系统费用预测分析 [J]. *系统工程理论与实践*, 2004, 24(9): 121–130.
Jiang T J, Li J Y. Forecast analysis on weapon system fee based on support vector machine[J]. *Systems Engineering — Theory & Practice*, 2004, 24(9): 121–130.
- [13] Lin C F, Wang S D. Fuzzy support vector machines[J]. *IEEE Transactions on Neural Networks*, 2002, 13(2): 464–471.
- [14] Sun Z H, Sun Y X. Fuzzy support vector machine for regression estimation[J]. *IEEE International Conference on Systems, Man and Cybernetics*, 2003, 4: 3336–3341.
- [15] Hong D H, Hwang C. Support vector fuzzy regression machines[J]. *Fuzzy Sets and Systems*, 2003, 138(2): 271–281.
- [16] Dubois D, Prade H. *Fuzzy Sets and Systems: Theory and Applications*[M]. New York: Academic Press, 1980.