

文章编号: 1000-8055(2009)08-1856-10

基于 SPSO-SVR 的融合航空发动机 传感器故障诊断

鲁 峰¹, 黄金泉¹, 陈 煜^{1,2}, 宋云峰¹

(1. 南京航空航天大学 能源与动力学院, 南京 210016;

2. 贵州黎阳航空发动机公司, 贵阳 561102)

摘 要: 针对航空发动机常见的传感器故障问题, 提出了一种利用改进的粒子群算法训练支持向量回归机, 并利用融合机制将其应用于传感器故障诊断. 论述了用一簇支持向量回归机 (SVR) 预测器对传感器进行实时检测, 通过逻辑判断机制隔离故障传感器, 并且依据剩余的无故障传感器信息实现信号重构. 以某型航空发动机传感器在其整个工作范围内受到的冲击、偏置和漂移故障为例, 验证了基于自协调粒子群优化支持向量回归机 (SPSO-SVR) 算法的融合诊断机制对传感器单一故障和多重故障具有较高的精度和计算效率.

关 键 词: 航空发动机; 传感器故障检测、隔离、重构; 自协调粒子群优化; 支持向量回归机;

小波分析

中图分类号: V233.7

文献标识码: A

Research on sensor fault diagnosis of aero-engine based on data fusion of SPSO-SVR

LU Feng¹, HUANG Jin-quan¹, CHEN Yu^{1,2}, SONG Yun-feng¹

(1. College of Energy and Power Engineering,

Nanjing University of Aeronautics and Astronautics, Nanjing 210016, China;

2. Guzhou Liyang Aero Engine Corporation, Guiyang 561102, China)

Abstract: In consideration of the common sensor faults in aero-engine, a new algorithm was proposed based on support vector regression (SVR) trained by improved particle swarm optimization (PSO), and was used for sensor fault diagnosis system based on data fusion. A bank of SVR was applied to sensor fault detection, isolation and validation. This fault diagnosis system would isolate the fault sensor relying on the isolation mechanisms, and select the validation module for signal recovery when some fault sensors were detected. According to the simulation experiment of aero-engine sensor faults (impact fault, offset fault and drift fault), the results show that this sensor fault diagnosis system has high level of precision and is an effective way to sensor fault diagnosis under the conditions of both one and multiple sensor faults.

Key words: aero-engine; sensor fault detection, isolation, validation;
self-tuning particle swarm optimization (SPSO);
support vector regression (SVR); wavelet analysis

收稿日期: 2008-07-22; 修订日期: 2008-12-19

作者简介: 鲁峰 (1981 -), 男, 浙江长兴人, 博士生, 主要从事航空发动机控制与故障诊断方面的研究.

现代航空发动机控制系统日趋复杂,随着控制变量数目增加所需的传感器数目也越来越多,而航空发动机传感器工作在高温强振动的恶劣环境中,是整个系统中易发故障元件之一。因此,对传感器故障的实时诊断并运用冗余技术进行传感器信号重构是提高发动机控制系统可靠性,保证发动机状态监控与故障诊断精度的关键^[1-2]。80 年代中期开始,NASA Lewis 研究中心开展的 ADIA 计划提出了通过一组卡尔曼滤波器对传感器故障进行诊断,并将该计划投入到 F100 等发动机上验证^[3-4]。随后,Kobayashi 等人^[5-6]围绕发动机可能出现的传感器故障和执行机构故障对该诊断方法进行了扩展研究^[7-8]。90 年代以来,随着机器学习算法的不断发展,神经网络、专家系统和支持向量机等新颖算法^[8]也开始应用到传感器的故障诊断中。

支持向量回归机(SVR)^[9]是通过改变样本空间维度把非线性回归问题转换成线性回归问题,与传统的学习算法相比,具有较好的泛化性能,算法的效率和精度都比较高。但由于 SVR 是以二次规划来求解支持向量,在求解二次规划问题时涉及高阶矩阵的计算,随着矩阵阶的增大矩阵的存储和计算将耗费大量的机器内存和运算时间,因此 SVR 具有一定局限性。

粒子群优化(PSO)算法^[10]是由 Kennedy 和 Eberhart 于 1995 年首次提出,与遗传算法不同的是 PSO 通过个体及个体之间的信息共享来寻找最优解,它的概念更简单、效率更高、更易实现,目前已广泛应用于函数优化、模式分类、神经网络训练等领域。一些学者利用 PSO 实现对支持向量机(SVM)的核参数 α 、惩罚因子 C 等特征参数寻优,以误差最小化为目标避免特征参数按经验选取^[11]。本文对现有的 PSO 改进设计出自协调粒子群优化(SPSO)寻优,并提出用 SPSO 构造 SVR 最优超平面的自协调粒子群优化支持向量回归机(SPSO-SVR),把问题直接转化为超平面支持参数寻优,避免了二次规划问题 Lagrange 方法涉及的高阶矩阵的计算,以减小内存消耗和运算时间。将 SPSO-SVR 设计的传感器故障诊断系统应用于某型航空发动机传感器故障诊断中,通过三层模块之间的数据融合实现故障检测、隔离和重构,以实现提高传感器故障诊断、计算的效能及单、双重故障的诊断能力。

1 航空发动机传感器故障诊断系统

SPSO-SVR 传感器故障诊断系统首先对所

有传感器输出可测参数利用小波消噪算法消去高频噪声,然后通过 SPSO-SVR 进行信号检测,如果传感器信号出现异常则经过相应的逻辑判断选择 SPSO-SVR 重构单元,利用剩余无故障传感器测量值重构实现对单、双重传感器故障信号的恢复。

1.1 故障模式与信号预处理

发动机传感器作为整个航空发动机健康管理系统的前端元件,其健康状况密切影响对发动机的诊断效果。发动机测试信号较多,有温度、压力、流量、转速和振动信号等等,一般以下传感器较容易发生故障,分别是风扇相对转速 N_1 、高压转子相对转速 N_h 、燃烧室相对出口压力 p_4 、低压涡轮相对进口温度 T_{45} 、低压涡轮相对出口压力 p_6 。传感器的故障通常包括硬故障和软故障,硬故障指结构损坏导致信号幅值变化较大,软故障则是幅值较小且变化缓慢的信号,而冲击故障、偏置故障和漂移故障这三类典型故障较能反映出发动机传感器的故障模式,在仿真中这三类故障分别通过对原始信号加脉冲信号、恒定偏置信号和以某一速率偏移的信号来实现。

航空发动机传感器工作环境恶劣,在采集到的测试信号中,不可避免的混有噪声或者干扰信号,为了更有效地获取发动机工作状态信息并进行正确的传感器故障诊断,需要抑制干扰或噪声以提取出有用的测试信号。由于传感器输出量包含了温度、压力、转速等不同的物理量,它们的数量级相差很大,利用各物理量设计点值来对相应的参数进行归一化处理。一般地,传感器输出信号中的噪声是高斯白噪声信号,利用小波阈值消噪方法^[12]对信号进行预处理具有较好的消噪效果。图 1 为发动机由慢车到最大状态的经过小波阈值消噪前后的 5 组传感器输出量

$$U = [N_1, N_h, p_4, T_{45}, p_6]^T$$

1.2 传感器故障检测、隔离、重构模型

在航空发动机整个工作范围内实现对传感器的故障检测、隔离和信号重构,以 SPSO-SVR 预测算法作为该传感器故障诊断的核心,设计三层传感器故障诊断模型,如图 2 所示。传感器故障诊断模型结构如图 2(a)所示。具体实现方法如下:

1) 故障监视,构建 5 个 h 输入单输出 SPSO-SVR 自回归预测单元,分别对应于每个传感器测量信号。每个预测单元利用当前时刻 k 之前

的 h 个该测量信号对当前时刻 k 该测量信号进行预测,利用预测值与实际值之差实现故障监视^[13].

以风扇转速为例,构建基于 SPSO-SVR 的 N_1 传感器故障检测单元. 风扇转速无故障的时间序列 $\{[N_1(k-h), \cdots, N_1(k-1)], N_1(k)\} \in \mathbf{R}^h \times \mathbf{R}$ 作为 h 阶 SPSO-SVR 自回归预测器的训练样本,风扇转速训练样本来自整个飞行包线内慢车到最大状态的数据,动态训练得到 SPSO-

SVR 预测器.

2) 故障决策隔离,SPSO-SVR 预测器的输出与测量输出值的之差和该传感器故障门限值相比较,若超过该传感器的门限值则输出为 1,否则为 0,以该二进制串 z 输出作为传感器故障与否的指示信号,如风扇转速传感器和燃烧室出口压力传感器同时发生故障则 $z = [1, 0, 1, 0, 0]$. 将决策模块输出的故障指示信号 z 作为信号隔离的依据,按照隔离指示位隔离故障传感器信号.




图 1 小波阈值消噪信号效果图
Fig. 1 Signal filtered by wavelet




图 2 传感器故障诊断模型
Fig. 2 Sensor fault diagnosis model

3) 故障传感器信号重构,对传感器测量信号进行相关性分析,利用与故障传感器具有强相关的无故障传感器信号作为重构单元训练输入,故障传感器无故障时的测量信号作为该单元的训练输出,以构建 SPSO-SVR 重构单元.由于 3 个或 3 个以上的传感器同时发生故障的概率极低,而对于 5 个输出量共有 $C_5^3 + C_5^2 = 15$ 种一个传感器发生故障和两个传感器发生故障的情况组合,因此在重构模块 SPSO-SVR 簇中需构建 15 个 SPSO-SVR 传感器故障信号重构单元.信号重构 SPSO-SVR 簇如图 2(b)所示,该簇包含了 15 个 SPSO-SVR 重构单元,第 i 个 SPSO-SVR 重构单元利用与第 i 种故障类型相对应的无故障传感器的测量信号 V^i ,以恢复该种故障类型下的其余故障传感器信号 V_R^i ,图 2(b)中的信号选择是利用故障指示信号 Z 选择需要重构的故障传感器信号,SPSO-SVR 簇的重构模块输出 U 则包含了无故障传感器的测量信号和故障传感器的重构信号.

以风扇转速传感器和高压涡轮出口压力传感器同时发生故障为例,构建该传感器故障类型下的 SPSO-SVR 传感器故障信号重构单元.此时以高压转子转速、低压涡轮进口温度和低压涡轮出口压力的测量信号作为 SPSO-SVR 的训练输入,无故障时的风扇转速传感器和高压涡轮出口压力作为 SPSO-SVR 的训练输出,对应这种情况训练得到三输入二输出的 SPSO-SVR 故障信号重构单元.

2 SPSO-SVR 算法

2.1 自协调粒子群算法 (SPSO)

PSO 是基于群体智能理论的优化算法,群体中的粒子在每次迭代搜索过程中,通过跟踪粒子群的 2 个极值:粒子个体最优解 P_b 和粒子群最优解 G_b 来动态调整粒子位置 P_o 以实现寻优.速度更新 v_e 和位置更新 P_o 如下:

$$v_e(t+1) = \varepsilon v_e(t) + c_1 a_1 [P_b(t) - P_o(t)] + c_2 a_2 [G_b(t) - P_o(t)] \quad (1)$$

$$P_o(t+1) = P_o(t) + v_e(t+1) \quad (2)$$

式中学习因子 c_1, c_2 , 惯性权重 ε 均为常数,加速度系数 a_1 和 a_2 服从 $[0, 1]$ 区间的均匀分布.

1) 学习因子 c_1, c_2 自协调

学习因子 c_1, c_2 影响粒子速度的更新,为了增加 PSO 在寻优初期的全局搜索能力,学习因子在迭代初期的值应较小;而为了增强 PSO 的局部搜索能力,学习因子也应随着迭代次数的增加而增加.利用粒子本身与粒子之间的交互信息,动态调整学习因子

$$c_i = (1 + t/T)/2 \quad (i = 1, 2) \quad (3)$$

式中 t 为当前迭代次数, T 为 SPSO 最大迭代次数.

2) 粒子速度 v_e 自协调

为了避免陷入局部最优,引入变异因子 P_m .在进化初期粒子群很快地收敛到粒子群最优解 G_b 附近,以后由于各粒子基本趋于一致,粒子的速度矢量趋近于 0, PSO 算法收敛很慢甚至陷入停滞不前的状态,因此引入速度变异因子 P_m 实现更新速度.具体的变异方法为:根据粒子的适应度值 f 自动改变 P_m ,当适应度值低于平均适应度 f_{avg} 时,说明该粒子是性能不优,对它就采用较大的变异概率,相应地当适应度高于平均适应度时,说明该粒子性能优良,对它就根据适应度取相应较小的变异概率.

$$P_m = \begin{cases} P_{m1} - \frac{(P_{m1} - P_{m2})(f - f_{avg})}{f_{max} - f_{avg}} & f \geq f_{avg} \\ P_{m1} & f < f_{avg} \end{cases} \quad (4)$$

$$P_o(t+1) = P_o(t) + P_m v_e(t+1) \quad (5)$$

3) 粒子位置 P_o 自协调

在粒子群寻优过程中,粒子位置是以一定的更新速度不断更新,当粒子位置的更新量过大则会超出粒子的寻优空间,因此引入粒子位置限定域,对粒子位置更新施加约束限定其变化范围能解决避免在解空间以外寻得最优解.

$$P_o(t+1) = \begin{cases} P_{omin} & P_o(t+1) < P_{omin} \\ P_{omax} & P_o(t+1) > P_{omax} \\ P_o(t+1) & \text{else} \end{cases} \quad (6)$$

式中 P_{omax}, P_{omin} 分别为粒子位置的极值.

2.2 SPSO 训练支持向量回归机

设构建 SVR 的样本空间 $(x_1, y_1), \cdots, (x_l, y_l) \in \mathbb{R}^m \times \mathbb{R}^n$, 本文的传感器故障检测模块中利用单输出 SVR 构造了传感器测试信号预测器^[14], 其中 $m = h, n = 1$; 而在重构模块中使用多输出 SVR 对传感器故障信号进行恢复, 其中 m 为无故障传感器输入信号数, n 为重构的故障传感器数, 满足 $m + n = 5$. 以下 SVR 算法是针对多输入多输出的一种算法, 特殊地当 $n = 1$ 时, 则为单输出最小二乘支撑向量回归机 (LSSVR). 高维特征空间的回归函数如下:

$$y(x) = W^T \cdot \phi(x) + b =$$
$$\begin{bmatrix} w_1^T \cdot \phi(x) + b_1 \\ \vdots \\ w_n^T \cdot \phi(x) + b_n \end{bmatrix}$$

(7)

其中 $W \in \mathbb{R}^{n \times m}$, $\phi(\cdot)$ 表示输入空间至高维特征空间的非线性映射.

SVR 训练算法是为了求解权向量 w_i 和偏置向量 b , 以此求得支持向量以在高维特征空间确定最优超平面. 本文以回归系数 w_i, b 为待寻最优解 G_b , 利用 SPSO 直接训练 SVR, 从而避免利用 Lagrange 对偶原理求解凸二次规划问题. 在 SVR 中适应度函数如下:

$$f = F - \sum_i^n K(w_i, w_i) + C \sum_k^l \zeta_{ik}$$

(8)

式中 $K(\cdot, \cdot)$ 为高斯核函数, C 为惩罚因子, ζ_{ik} 为容错因子, F 为常数, 分别满足如下关系:

$$\zeta_{ik} =$$
$$\begin{cases} 0 & |K(w_i, x_k) - b_i - y_{ik}| < \varepsilon \\ |K(w_i, x_k) - b_i - y_{ik}| - \varepsilon & \text{else} \end{cases}$$

(9)

$$F > \max \left\{ \sum_i^n K(w_i, w_i) + C \sum_k^l \zeta_{ik} \right\}$$

(10)

式中 ε 为超平面分类宽带

采用 SPSO 训练 SVR 的流程图如图 3 所示.




图 3 SPSO-SVR 流程图
Fig. 3 Program of SPSO-SVR

3 仿真试验与分析

以某型航空发动机部件级模型作为仿真验证模型. 在高度 $H = 0 \text{ km}$, 马赫数 $Ma = 0$, 从慢车到最大工作状态这个动态工作范围内, 利用 N_1, N_h, p_4, T_{45} 和 p_6 这 5 个传感器测量参数对这 5 个传感器进行故障诊断. 各传感器的故障门限值根据不同类型传感器的精度不同而确定, 设定转速传感器的精度为 $\pm 0.1\%$, 压力传感器的精度为 $\pm 0.5\%$, 温度传感器的精度为 $\pm 1\%$, 根据经验分别令转速、压力和温度传感器的门限值为

$\pm 0.5\%$, $\pm 1\%$ 和 $\pm 2\%$.

在地面工作状态下,针对 5 个传感器改变供油量 W_f 得到这 5 个传感器的整个动态变化范围内的 5 组测量值,每个传感器各有 10000 组数据,每 100 个数据中随机选取 1 个数据,这样每个传感器共选取 100 组数据作为训练样本,利用该训练样本构建 SPSO-SVR 预测单元、重构单元,其中参数选取如下:初始粒子群规模为 200,迭代次数为 $T=500$,最优超平面参数 w_i , b 中元素的寻优区间分别为 $(1 \times 10^{-5}, 10]$, $[-1, 1]$, 变异概率 $P_{m1}=0.05$, $P_{m2}=0.002$, 预测单元的阶数 $h=5$, SVR 的 $\varepsilon=0.05$, 高斯核参数 $\sigma=0.2$, 惩罚因子 $C=10$. 本文分别以传感器单一、双重故障来验证该发动机传感器故障诊断模型对于传感器故障诊断的有效性.

3.1 单一传感器故障

在航空发动机传感器发生单一故障时,以高压压气机相对转速 N_h 为例,分别对传感器的冲击故障、偏置故障和漂移故障进行仿真实验,在 $t=700\text{ s}$ 时,其中冲击故障为 -5% 的瞬时脉冲,偏置故障为 -3% 的偏置量,漂移故障以每秒 -0.001% 与当前时刻 N_h 的乘积的变化量发生漂移. 传感器单一故障的检测和重构如图 4 所示.

通过 N_h 信号 SPSO-SVR 预测器与传感器输出实际值的残差 $\Delta N_h = \hat{N}_h - N_h$ 和 N_h 故障门限值相比较,从图 4(a)、图 4(b)、图 4(c) 可以发现在 $t=700\text{ s}$ 时高压压气机转速传感器预测残差分别超过了其传感器的故障门限值,经过故障决策隔离模块产生故障指示信号 $W=[0, 1, 0, 0, 0]$, 得出高压压气机传感器发生故障,再根据故障指示信号隔离故障的 N_h 传感器,通过剩余无故障传感器输出值重构的冲击故障、偏置故障和漂移故障的 N_h 如图 4(d)、图 4(e)、图 4(f) 所示,该信号在故障时还能很好地跟踪上原始的无故障信号 N_{h0} .

3.2 传感器双重故障

在航空发动机传感器中多个故障同时发生的概率随着传感器的个数急速减小,为了验证此诊断模型的有效性,本文还对两个传感器同时发生

冲击、偏置和漂移三类故障进行诊断. 以低压涡轮相对进口温度 T_{45} 和低压涡轮相对出口压力 p_6 为例,在 $t=700\text{ s}$ 时,对 T_{45} 分别施以幅值为 -5% 的冲击故障, -1.5% 的偏置故障和变化率为 0.001% 的漂移故障;对 p_6 分别加入幅值为 -10% 的冲击故障, -3% 的偏置故障和变化率为 0.001% 的漂移故障. 传感器双重同步故障的检测和重构如图 5 所示.

从图 5(a)、图 5(b)、图 5(c) 可以发现在 $t=700\text{ s}$ 时, T_{45} 和 p_6 传感器预测残差分别超过了其传感器的故障门限值,经过故障决策隔离模块产生故障指示信号 $W=[0, 0, 0, 1, 1]$, 得出低压涡轮进口温度传感器和低压涡轮出口传感器发生了故障,此时再隔离故障的传感器 T_{45} 和 p_6 输出值,通过剩余无故障传感器重构的冲击故障、偏置故障和漂移故障的 T_{45} , p_6 信号如图 5(d)、图 5(e)、图 5(f) 所示,该信号在故障时还能很好地跟踪上原始的无故障信号 T_{450} 和 p_{60} .

两个传感器发生故障的较为普遍的形式是在不同时刻发生了故障,同样以低压涡轮进口温度 T_{45} 和低压涡轮出口压力 p_6 为例,对 T_{45} 和 p_6 这两个传感器输出分别在 500 s 和 700 s 时模拟如上冲击、偏置故障,在 700 s 和 800 s 时模拟漂移故障. 传感器双重异步故障的检测和重构如图 6 所示.

由图 6(a)、图 6(b) 可以发现在 $t=500\text{ s}$ 冲击、偏置故障仿真时, T_{45} 传感器预测残差超过了其传感器的故障门限值,经过故障决策隔离模块产生故障指示信号 $W=[0, 0, 0, 1, 0]$, 此时诊断出低压涡轮进口温度传感器发生故障,再隔离故障的传感器 T_{45} , 通过剩余无故障传感器输出值重构 T_{45} ; 在 $t=700\text{ s}$ 时, p_6 的预测残差也超过了压力门限值,此时故障指示信号 $W=[0, 0, 0, 1, 1]$, 重构模块再隔离 p_6 , 依据剩余的信号重构 T_{45} 和 p_6 . 如图 6(d)、图 6(e) 所示,该信号在故障时还能很好地跟踪上原始的无故障信号 T_{450} 和 p_{60} . 同理,由图 6(c)、图 6(f) 可知两个传感器在不同时刻分别发生漂移后也有很好的故障检测和恢复效果.




图 4 单一传感器故障检测和重构效果图

Fig.4 Signal detection and recovery under single sensor fault




图 5 传感器同步双重故障检测和重构效果图

Fig. 5 Signal detection and recovery under double sensor fault synchronously




图 6 传感器异步双重故障检测和重构效果图

Fig. 6 Signal detection and recovery under double sensor fault asynchronously

4 结 论

1) 在现有粒子群算法的基础上提出了自协

调粒子群算法 (SPSO), 通过对粒子速度和位置同时自协调更新, 提高了全局搜索能力, 加快了收敛速度;

2) 将现有建立 SVR 模型的 Lagrange 对偶原理求解二次规划问题转化为利用 SPSO 寻最优回归参数问题, 直接利用 SPSO 训练 SVR 以构建 SPSO-SVR 回归模型, 使得问题更直接、简化。

3) 将 SPSO-SVR 应用于航空发动机传感器单一故障和多重故障的诊断。经小波消噪的传感器信号通过 SPSO-SVR 预测器簇对传感器测试信号进行故障监测, 隔离, 产生相应的故障模式并实现对故障传感器信号的恢复。通过仿真可以验证该传感器故障诊断模型能对由于冲击、偏置和漂移引起的单一传感器故障、多传感器故障都能进行有效诊断, 该方法对常见的传感器故障具有较强的诊断能力、较高的重构精度。

参考文献:

- [1] Delaat J C, Merrill W C. Advanced detection isolation and accommodation of sensor failures in turbofan engine [R]. NASA-1990-2925.
- [2] Sanjay G. Controls and health management technologies for intelligent aerospace propulsion systems [R]. AIAA-2004-0949.
- [3] Alag G, Gilyard G. A proposed kalman filter algorithm for estimation of unmeasured output variables for an F100 turbofan engine [R]. AIAA-1990-1920.
- [4] Caliskan F, Hajiyeve C M. Aircraft sensor fault diagnosis based on kalman filter innovation sequence [C]// Proceedings of the 37th IEEE Conference on Decision and Control. Florida U. S. A. : IEEE, 1998.
- [5] Kobayashi T, Simon D L. Application of a bank of kalman filters for aircraft engine fault diagnostics [R]. NASA/TM-2003-212526.
- [6] Kobayashi T, Simon D L. Evaluation of an enhanced bank of kalman filters for in-flight aircraft engine sensor fault diagnostics [J]. Engineering for Gas Turbines and Power, 2005, 127: 497-504.
- [7] 张鹏, 黄金泉. 航空发动机气路故障诊断的平方根 UKF 方法研究[J]. 航空动力学报, 2008, 23(1): 169-173.
- ZHANG Peng, HUANG Jinquan. SRUKF research on aeroengines for gas path component fault diagnostics[J]. Journal of Aerospace Power, 2008, 23(1): 169-173. (in Chinese)
- [8] 陈毅, 黄金泉, 张鹏. 航空发动机控制系统传感器 FDIA 系统仿真[J]. 航空动力学报, 2008, 23(2): 396-400.
- CHEN Yi, HUANG Jinquan, ZHANG Peng. FDIA simulation of aero-engine control system sensor FDIA system [J]. Journal of Aerospace Power, 2008, 23(2): 396-400. (in Chinese)
- [9] Clarke S M, Gribsch J H, Simpson T W. Analysis of support vector regression for approximation of complex engineering analyses [J]. Journal of Mechanical Design, 2005, 127: 1077-1087.
- [10] Kennedy J, Eberhart R. Particle swarm optimization [C]// Proc. of IEEE Int. Conf on Neural Networks. Perth, Australia: IEEE, 1995: 1942-1948.
- [11] 张东方, 李应红, 陈东林. 基于 PSO 算法的航空发动机启动燃油控制[J]. 航空动力学报, 2007, 22(6): 923-927.
- ZHANG Dongfang, LI Yinghong, CHEN Donglin. A new method to control fuel flow of aircraft engine's starting process based on PSO algorithm[J]. Journal of Aerospace Power, 2007, 22(6): 923-927. (in Chinese)
- [12] 赵治栋, 陈裕泉. 广义小波收缩消噪阈值选择及应用研究[J]. 传感技术学报, 2007, 20(3): 601-605.
- ZHAO Zhidong, CHEN Yuquan. Research of threshold value selections and application for generalized threshold functions [J]. Chinese Journal of Sensors and Actuators, 2007, 20(3): 601-605. (in Chinese)
- [13] FENG Zhigang, Katsunori S, WANG Qi. Sensor fault detection and data recovery based on LS-SVM predictor[J]. Chinese Journal of Scientific Instrument, 2007, 28(2): 193-197.
- [14] Ruxandra S, Dumitrescu D, Mike P, et al. Evolutionary support vector regression machines [C]// Proceedings of the Eighth International Symposium on Symbolic and Numeric Algorithms for Scientific Computing. Timisoara, Romania: IEEE Computer Society, 2006.