

文章编号: 1000-8055(2008)06-1118-09

基于改进 LS-SVM 的航空发动机传感器故障诊断与自适应重构控制

蔡开龙^{1,2}, 谢寿生¹, 杨 伟¹, 吴 勇¹

(1. 空军工程大学 工程学院, 西安 710038;

2. 空军第一航空学院, 信阳 464000)

摘 要: 提出了一种基于改进 LS-SVM 的航空发动机传感器故障诊断与自适应重构控制方法. 该方法通过给误差变量赋予不同权值因子提高 LS-SVM 的鲁棒性, 采用修剪算法提高 LS-SVM 的稀疏性; 该方法从某涡扇发动机输入输出空间中建立其正常模型, 采用阈值判别法对传感器故障进行实时监视与诊断, 并用模型输出值代替故障传感器测量值反馈回闭环控制系统, 实现对发动机的自适应重构控制. 仿真结果表明, 该方法能及时准确地定位故障, 并进行有效的自适应重构控制.

关 键 词: 航空、航天推进系统; 航空发动机; 改进最小二乘支持向量机 (LS-SVM); 传感器; 故障诊断; 自适应重构控制

中图分类号: V233.7

文献标识码: A

Fault diagnosis and adaptive reconfiguration control for sensors in aeroengine based on improved least squares support vector machine

CAI Kai-long^{1,2}, XIE Shou-sheng¹, YANG Wei¹, WU Yong¹

(1. The Engineering Institute,

Air Force Engineering University, Xi'an 710038, China;

2. The First Aeronautic Institute of the Air Force, Xinyang 464000, China)

Abstract: A method of fault diagnosis and adaptive reconfiguration control based on improved least squares support vector machine (LS-SVM) was presented for sensors in aeroengine control system. LS-SVM robustness was improved by adding weighed values to errors, and its sparseness was improved by clipping algorithm. Some turbofan engine normal models were set up with improved LS-SVM. The threshold discriminance was used to real-time watch and diagnose sensors fault. Adaptive reconfiguration control for aeroengine was realized by model output which is fed back to closed loop control system in replacement of fault sensor measurements. The simulation results show that the proposed method can exactly diagnose sensor faults in time, and also effectively realize adaptive reconfiguration control.

Key words: aerospace propulsion system; aeroengine;

improved least squares support vector machine (LS-SVM); sensors;

fault diagnosis; adaptive reconfiguration control

收稿日期: 2007-05-25; 修订日期: 2007-09-17

基金项目: 军队科研基金; 空军工程大学优秀博士论文创新基金 (BC0502)

作者简介: 蔡开龙 (1979 -), 男, 江西上饶人, 博士生, 讲师, 主要从事航空推进系统控制与状态监控方面研究.




图 1 航空发动机传感器故障诊断原理

Fig. 1 Principle of fault diagnosis for sensors in aeroengine

由于航空发动机工作在高温、高压、大应力的苛刻条件下,而且还经常变换工作状态,承受着大的、变化的载荷,从而导致其传感器故障时有发生。据统计,2001 年以来在某型飞机减小转速信号故障中,传感器故障占了 50 %^[1];在发动机控制系统中,传感器故障占控制系统总故障的 80 % 以上^[2]。因此,很有必要对传感器故障进行研究,以提前发现和减少传感器故障,提高飞行安全性。目前可以采用硬件余度和解析余度两种方法对传感器故障进行诊断。由于硬件余度结构会增加控制系统的重量、体积和研制成本,而解析余度技术不会对控制系统本身产生任何影响,因此,采用解析余度技术取代硬件余度结构是传感器故障诊断与自适应重构控制的发展方向,FADEC 系统的投入使用和分布式控制系统的出现不但使先进复杂的控制理论在航空发动机中的应用成为了可能,而且也为实现控制系统的状态监视和故障诊断提供了平台。

文献[3-4]研究了在离线和系统开环情况下的传感器故障诊断,没有考虑系统的实时性和闭环控制特点,闭环控制系统需要传感器实时的反馈信息,一旦故障传感器信息被反馈给闭环系统的控制器,就可能出现严重后果。文献[1,5]针对线性系统,对单一传感器故障诊断进行了研究,当被检测系统同时有多个传感器故障时显得无能为力。为此,本文提出了一种新的基于改进最小二乘支持向量机(Least squares support vector machine, LS-SVM)的航空发动机传感器故障诊断与自适应重构控制方法。

1 基于改进 LS-SVM 航空发动机传感器故障诊断原理

本文提出的基于改进 LS-SVM 的航空发动

机传感器故障诊断与自适应重构控制方法,其结构原理如图 1 所示。

从图 1 中可以看出,基于改进 LS-SVM 的航空发动机传感器故障诊断与自适应重构控制的基本思想是利用改进 LS-SVM 强大的非线性回归能力,从航空发动机正常的输入输出空间中建立发动机的辨识模型,当传感器故障时,通过对改进的 LS-SVM 模型估计输出值与系统实际输出值的比较,得到残差,通过残差决策逻辑对残差进行决策后,完成对故障传感器的在线监测、诊断与隔离,并用相应的估计输出值代替故障传感器实际输出值,实现对闭环控制系统的自适应重构控制。图中 D 表示延时。

以某涡扇发动机为研究对象,表征该型发动机工作的状态参数主要是低压转子转速 n_l 和高压转子转速 n_h ;控制参数主要是主供油量 m_f 、尾喷管喉部面积 A_e 、低压压气机进口导流叶片角度 α 和高压压气机可调静子叶片角度 α_h 等;扰动参数主要是飞行高度 H 和飞行马赫数 Ma 。因此,某涡扇发动机数学模型可用如下形式表示为

$$\begin{cases} \dot{n}_h = f_1(n_h, n_l, m_f, A_e, \alpha_h, \alpha, H, Ma) \\ \dot{n}_l = f_2(n_h, n_l, m_f, A_e, \alpha_h, \alpha, H, Ma) \\ Y = G(n_h, n_l, m_f, A_e, \alpha_h, \alpha, H, Ma) \end{cases} \quad (1)$$

式中 Y 为发动机的输出向量,本文取 $Y = [n_h, n_l, p_{33}^*, T_{55}^*, \pi_{Tf}]^T$, p_{33}^* , T_{55}^* 和 π_{Tf} 分别为压气机后总压、涡轮后总温和涡轮落压比; $f_1(\cdot)$, $f_2(\cdot)$, $G(\cdot)$ 为发动机的非线性映射关系。本文采用 5 个改进 LS-SVM 辨识模型分别逼近发动机的 5 个非线性映射输出。

2 改进 LS-SVM 原理及算法

LS-SVM 是 Suykens J A K 在 1999 年提出的一种新型支持向量机方法^[6]。LS-SVM 在目标

函数中采用平方和误差损失函数替代传统 SVM 中的不敏感损失函数,用等式型约束替代传统 SVM 中的不等式约束,这样使得 SVM 求解二次规划问题转化为求解一组线性关系式,从而极大地简化了问题,提高了学习速率^[7]. 然而,由于采用了平方和误差损失函数,使得系统鲁棒性和稀疏性下降,因此,本文将误差变量与权系数联系起来,通过给误差变量赋予不同的权值因子使得鲁棒性得到加强,并采用修剪算法提高 LS-SVM 的稀疏性,从而得到改进的 LS-SVM.

对于给定的训练样本集 $D = \{(x_i, y_i) | x_i \in R^n, y_i \in R, i = 1, 2, \dots, N\}$, 其中, x_i 为输入数据, y_i 为输出数据. 则改进 LS-SVM 非线性回归逼近函数为

$$y_{out_i} = w^T \cdot \phi(x_i) + b \quad (2)$$

其非线性回归问题可以描述为求解下面的问题

$$\begin{aligned} \min_{w, e} J(w, e) &= \frac{1}{2} \|w\|^2 + \frac{1}{2} \gamma \sum_i v_i e_i^2 \\ \text{s.t.} \quad y_i &= w^T \phi(x_i) + b + e_i, \\ &(i = 1, 2, \dots, N) \end{aligned} \quad (3)$$

式中 $\phi(x_i) = [\phi_1(x_i), \phi_2(x_i), \dots, \phi_n(x_i)]$ 是一个将输入向量 x_i 映射到一个高维特征空间的非线性函数; $w = [w_1, w_2, \dots, w_n]$ 是确定这个特征空间的权值向量; b 是偏置值; J 为损失函数; e_i 为误差量; γ 为平衡因子; v_i 为误差权系数.

由 SVM 求解二次规划的思想,根据公式(3),定义 Lagrange 函数

$$F(w, b, e, \alpha) = \frac{1}{2} \|w\|^2 + \frac{1}{2} \gamma \sum_i v_i e_i^2 - \sum_i \alpha [w^T \phi(x_i) + b + e_i - y_i] \quad (4)$$

式中 $\alpha \in R$, 为 Lagrange 乘子.

对公式(4)进行优化,即求 Lagrange 函数

$F(\cdot)$ 对 w, b, e_i, α 的偏导数

$$\begin{cases} \frac{\partial F}{\partial w} = 0 & \Rightarrow w = \sum_i \alpha \phi(x_i) \\ \frac{\partial F}{\partial b} = 0 & \Rightarrow \sum_i \alpha = 0 \\ \frac{\partial F}{\partial e_i} = 0 & \Rightarrow \alpha = \gamma v_i e_i \\ \frac{\partial F}{\partial \alpha} = 0 & \Rightarrow w^T \phi(x_i) + b + e_i - y_i = 0 \end{cases} \quad (5)$$

消去变量 w 和 e , 得到如下矩阵方程

$$\begin{bmatrix} 0 & 1_v^T \\ 1_v & \Omega + V_v \end{bmatrix} \begin{bmatrix} b \\ \alpha \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix} \quad (6)$$

式中

$$\begin{aligned} 1_v &= [1, \dots, 1]; \\ V_v &= \text{diag} \left(\frac{1}{v_1}, \frac{1}{v_2}, \dots, \frac{1}{v_N} \right); \\ \alpha &= [\alpha_1, \alpha_2, \dots, \alpha_N]; \quad y = [y_1, y_2, \dots, y_N]; \\ \Omega_{ij} &= \phi(x_i)^T \cdot \phi(x_j), \quad (i, j = 1, 2, \dots, N). \end{aligned}$$

根据 Mercer 条件,存在映射函数 ϕ 和核函数 $K(\cdot, \cdot)$, 使

$$K(x_i, x_j) = \phi(x_i)^T \cdot \phi(x_j) \quad (7)$$

因此,得到改进 LS-SVM 非线性回归逼近函数为

$$y_{out} = \sum_i \alpha_i K(x_i, x) + b \quad (8)$$

式中 α 和 b 由式(5)求得. 核函数 $K(\cdot, \cdot)$ 的选取应当使其为高维特征空间的一个点积,是满足 Mercer 条件的任意对称函数,常用的核函数有线性核函数 $K(x, y) = x \cdot y$, 多项式核函数 $K(x, y) = [(x \cdot y) + 1]^d$ 和 RBF 核函数 $K(x, y) = \exp(-\|x - y\|^2 / 2\sigma^2)$ 等,当采用线性核函数时,即成为线性回归 SVM. 其中径向基核函数的计算复杂度不随参数的变化而变化,在全部参数空间都满足 Mercer 条件,是 SVM 方法中最常用的核函数,本文采用 RBF 核函数.

公式(6)中误差权系数 v_i 的选择采用如下的方法:在式(3)~(6)中不带权系数 v_i 时,得到 LS-SVM 的最优估计参数 α 和 b 以及误差量 e , 则 v_i 为

$$v_i = \begin{cases} 1 & |e_i / \delta| \leq c_1 \\ \frac{c_2 - |e_i / \delta|}{c_2 - c_1} & c_1 < |e_i / \delta| \leq c_2 \\ 10^{-4} & |e_i / \delta| > c_2 \end{cases} \quad (9)$$

式中一般取 $c_1 = 2.5, c_2 = 3$; δ 是 LS-SVM 误差量 e 的鲁棒估计值,通常取以下值

$$\delta = 1.483 \times \text{mid}(e) \quad (10)$$

其中 $\text{mid}(e)$ 为误差量 e 绝对偏差的中值,其值计算为

1) 在公式(3)~(6)中不带权系数 v_i 时,计算得到 $e_i = \alpha / \gamma$;

2) 计算 e_i 的均值 $\bar{e} = \frac{1}{N} \sum_i e_i$;

3) 计算 e_i 绝对偏差的中值

$$\text{mid}(e) = \frac{1}{N} \sum_i (e - \bar{e}).$$

由以上求解过程可知, α 中的所有元素都是不为零的,这使得 LS-SVM 不再具有 SVM 中的支持向量稀疏性,为得到支持向量的稀疏性,可采

用如下的修剪算法:按照 α 绝对值大小决定训练样本集中数据向量(支持向量)的重要程度,并从训练样本集中去掉一小部分最不重要的样本(一般每次为 20 个),用剩下的样本集重新进行函数逼近,直到性能指标下降为止.在修剪过程中可以调整平衡因子 γ 和 RBF 核函数参数 σ ,从而提高函数逼近性能.

从以上的分析可知,对于本文改进 LS-SVM 模型,其参数主要是选择平衡因子 γ 和核函数参数 σ .目前使用的方法主要有最小化 VC 维法、交叉验证法、步步为营法和贝叶斯推断法等.本文采用多层自适应交叉验证法确定 LS-SVM 的模型参数.交叉验证法的基本思想是:①确定参数 γ 和 σ 的取值范围,本文的取值范围可分别确定为 $\gamma \in [10, 10\ 000]$, $\sigma \in [0.01, 10]$.②分别在参数 γ 和 σ 的取值范围内构造一个序列,得到参数向量 $[\gamma, \sigma]$ 的二维网格空间和参数向量组,例如两个参数分别选取 10 个数值,则构成 10×10 的二维网格空间和 100 个参数向量 $[\gamma, \sigma]$.对于在取值范围内构造参数序列有两种方法:第一种是根据所需参数对数进行均匀取值;第二种是根据学习样本的特征和经验确定参数.③输入每个参数向量 $[\gamma, \sigma]$ 到改进的 LS-SVM 中,采用训练样本集进行学习,并输出学习误差,取最小误差对应的参数向量 $[\gamma, \sigma]_{E_{\min}}$ 为最优参数对.④如果学习的精度没有达到所需的要求,则以 $[\gamma, \sigma]_{E_{\min}}$ 为中心构建新二维网格空间,选取数值相近的参数值进一步学习,从而获得更高的学习结果.这个新参数选取过程是自动执行的,经验表明,一般以 $[\gamma, \sigma]_{E_{\min}}$ 的 $0.01 \sim 5$ 倍为一个扩展网格宽度(即参数数值增减幅度),构建新参数向量 $[\gamma, \sigma]$.以此类推,不断优化改进的 LS-SVM 参数,直到满足精度要求.

3 传感器故障决策与自适应重构控制策略

由于基于改进 LS-SVM 的航空发动机传感器故障诊断是通过对传感器的实际输出值与改进 LS-SVM 模型的估计输出值之间产生的残差进行残差决策来判定传感器是否故障,因此,系统残差中包含了传感器可能发生故障的信息.在理想情况下,残差值为零表示改进的 LS-SVM 模型与被检测系统的描述相同,对应传感器无故障;相反,残差值不为零表示被检测系统有传感器发生了故障.然而,由于实际的被检测系统存在测量噪声,使得模型的估计输出与被检测系统的传感器实际

输出之间产生的残差与理想情况有偏差,为此需要进行故障的残差决策.

定义改进 LS-SVM 模型的估计输出值与被检测系统传感器的实际输出值之间产生的残差为

$$e(t) = y(t) - y_{out}(t) \quad (11)$$

式中 y 为被检测系统传感器的实际输出值; y_{out} 为改进 LS-SVM 模型的估计输出值.

本文采用阈值判别法对生成的残差序列进行决策,其基本思想是:首先通过离线建立被检测系统正常情况下的残差阈值范围;然后对在线每一个采样时刻得到的残差进行判定,若得到的残差在阈值范围内,说明系统中没有传感器故障,否则说明系统中有传感器故障.故障判定的阈值范围由系统正常时得到的残差序列的标准方差确定,一般取标准方差的 n 倍.如在系统正常时,得到系统的残差序列的均值为 μ ,标准方差为 σ ,则故障判定的阈值范围为 $[\mu - n\sigma, \mu + n\sigma]$.

在确定了传感器故障判定的阈值范围后,针对航空发动机是一个强非线性、强耦合的闭环系统,采用的传感器故障决策和自适应重构控制策略为:首先,在某涡扇发动机正常工作状态下,对发动机的每一个输出量,利用改进 LS-SVM 非线性回归算法建立一系列并行的改进 LS-SVM 模型,每一个改进 LS-SVM 模型对应于发动机的一个输出量,这样利用改进的 LS-SVM 模型组实现了对发动机输出信息的解耦;然后,将每一个传感器的实际输出值与相应改进的 LS-SVM 模型的估计输出值进行比较,如果得到的残差不在故障判定的阈值范围内,则说明该传感器发生了故障,否则说明该传感器正常;最后,对故障传感器定位后,将此传感器的输出信号断开,用改进的 LS-SVM 模型的估计输出值代替故障传感器的实际输出值,并反馈给闭环控制系统.这样就实现了闭环控制系统的在线故障诊断、隔离与自适应重构控制.

4 仿真实验及结果分析

基于改进 LS-SVM 的航空发动机传感器故障诊断与自适应重构控制闭环仿真系统结构图如图 2 所示.

图 2 中,被检测对象以某涡扇发动机为研究对象,考虑到该型发动机非线性模型的表达过于复杂,且进行动态性能计算时实时性不好,为此,选用某涡扇发动机的稳态点小扰动离散化线性模型进行传感器故障诊断与自适应重构控制性能仿




图 2 航空发动机传感器故障诊断与自适应重构控制闭环仿真系统结构图

Fig. 2 Closed-loop simulation system structure diagram of fault diagnosis and adaptive reconfiguration control for sensors in aeroengine

真研究.某涡扇发动机在高空 ($H=5\text{ km}, Ma=0.5$) 最大状态,控制量为主供油量和尾喷管临界面积,状态量为 n_h 和 n_l 时的相对化离散状态空间模型为

$$\begin{cases} \Delta \bar{x}(k+1) = G\Delta \bar{x}(k) + H\Delta u(k) \\ \Delta y(k) = C\Delta \bar{x}(k) \end{cases} \quad (12)$$

$$G = \begin{bmatrix} 0.962\ 13 & 0.003\ 153\ 8 & 0.012\ 742 & 0.003\ 928\ 5 \\ 0.027\ 037 & 0.952\ 22 & 0.017\ 133 & 0.003\ 530\ 2 \\ 0 & 0 & 0.980\ 2 & 0 \\ 0 & 0 & 0 & 0.980\ 2 \end{bmatrix}$$

$$H = \begin{bmatrix} 1.285\ 7 \times 10^{-4} & 3.965\ 2 \times 10^{-5} \\ 1.727\ 1 \times 10^{-4} & 3.552\ 4 \times 10^{-5} \\ 0.019\ 801 & 0 \\ 0 & 0.019\ 801 \end{bmatrix}$$

$$C = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 1.609\ 6 & -0.456\ 74 & 0.442\ 74 & -0.192\ 65 \\ -1.670 & 0.773\ 2 & 0.425\ 39 & 0.037\ 621 \\ 3.135\ 0 & -1.402\ 7 & 0.378\ 33 & 0.414\ 8 \end{bmatrix}$$

式中 $x = [n_h, n_l, m_{f0}, A_{e0}]^T$, $u = [m_f, A_e]^T$, $y = [n_h, n_l, p_3^*, T_{55}^*, \pi_T]^T$; $\Delta x = x - x_0$, $\Delta u = u - u_0$, $\Delta y = y - y_0$; $n_h, n_l, m_f, A_e, p_3^*, T_{55}^*, \pi_T$ 分别为发动机高压转子转速、低压转子转速、主供油量、尾喷管喉部面积、压气机后总压、涡轮后总温和涡轮落压比; G, H, C 为系数矩阵.

两个控制通道执行机构采用如下离散传递函数

$$G_1(z) = \frac{0.048\ 77 \times z^{-1}}{1 - 0.951\ 23 \times z^{-1}} \quad (13)$$

$$G_2(z) = \frac{0.032\ 46 \times z^{-1}}{1 - 0.967\ 54 \times z^{-1}} \quad (14)$$

由于某涡扇发动机采用双变量控制计划,即用主燃油流量 m_f 调节低压转子转速 n_l 或涡轮后

燃气温度 T_{55}^* ,用尾喷管临界截面积 A_e 调节涡轮落压比 π_T .而实际中是没有落压比传感器的,由于涡轮落压比 π_T 定义为涡轮前总压 p_4^* 与涡轮后总压 p_{55}^* 之比,其值可以通过两个压力传感器输出值之比得到,因此,为仿真方便,假设实际中存在有 π_T 传感器.

图 2 中,闭环控制系统控制器采用如下的离散增量式 PID 控制律

$$\begin{cases} E = E(k) = R(k) - Y1(k) \\ E_1 = E(k-1) \\ E_2 = E(k-2) \\ U1(k) = U1(k-1) + K_p(E - E_1) + \\ \quad K_E + K_i(E - 2 \times E_1 + E_2) \end{cases} \quad (15)$$

式中 $R = [n_0, \pi_0]^T$ 为参考输入向量; $Y_1 = [n, \pi_r]^T$ 为输出反馈向量; $U_1 = [m_r, A_e]^T$ 为控制器输出; E 为跟踪误差; K_p, K_i, K_d 分别为 PID 控制器的比例、积分和微分系数. 本文中, 式(15)的各变量取值分别为 $R = [n_0, \pi_0]^T = [0.1, 0]^T$; $K_p = [0.6, 1.85]$, $K_i = [0.021\ 4, 0.028\ 8]$, $K_d = [0.03, 0.03]$.

在对航空发动机传感器故障诊断与自适应重构控制仿真前, 首先需要对改进 LS-SVM 模型进行离线训练, 以确定合适的平衡因子 γ 和核函数参数 σ , 进而确定改进的 LS-SVM 模型的权值和偏置值. 某涡扇发动机的动态特性可采用如下描述

$$y(k+1) = f[y(k), m_r(k+1), A_e(k+1)] \quad (16)$$

式中 y 分别为 $n_h, n_l, p_{33}^*, T_{55}^*, \pi_r$.

在离线训练时, 将样本集的输入取为 $[-0.5, 0.5]$ 之间均匀分布的白噪声, 并假设系统的测量噪声是幅值为 $0.000\ 2$ 的白噪声, 根据这些条件分别产生出用于训练的 500 个训练样本和用于检验的 100 个检验样本. 以输出 n_h 为例, 得到改进 LS-SVM 模型训练结果和检验结果分别如图 3 (a) (实线是实际值, 虚线是模型值) 和图 3 (b) (实线是实际值, 虚线是模型值) 所示. 从图中可以看出, 经过训练后, 改进 LS-SVM 模型输出与某涡扇发动机的实际输出基本吻合, 说明改进 LS-SVM 模型反映出了某涡扇发动机的输入输出关系. 因此, 经过离线训练后的改进 LS-SVM 模型可以作为某涡扇发动机的数学模型.

采用同样的方法分别建立 $n_l, p_{33}^*, T_{55}^*, \pi_r$ 的改进 LS-SVM 模型, 得到 5 个辨识模型的平衡因子 γ 、核函数参数 σ 和模型偏置值 b 如表 1 所示.


表 1 某涡扇发动机的改进 LS-SVM 模型参数表
Table 1 Parameters table of improved LS-SVM model for some turbofan engine

参数名称	平衡因子 γ	核函数参数 σ	偏置值 b
n_h 模型	3 785.347	0.114 18	- 1.224 17
n_l 模型	4 420.973	0.184 88	- 1.219 40
p_{33}^* 模型	4 145.083	0.148 69	- 1.222 60
T_{55}^* 模型	2 685.490	0.487 95	- 1.237 63
π_r 模型	3 239.838	0.227 83	0.426 88


表 2 系统的故障阈值范围列表

Table 2 Threshold ranges of sensors fault diagnosis

	n_h 模型	n_l 模型	p_{33}^* 模型	T_{55}^* 模型	π_r 模型
阈值范围/ 10^{-3}	$[-1.224, 1.167]$	$[-1.188, 1.175]$	$[-2.102, 1.953]$	$[-1.132, 1.161]$	$[-1.182, 1.225]$



(a) 训练结果



(b) 检验结果

图 3 n_h 的改进 LS-SVM 模型输出估计值与实际值比较
Fig. 3 Compare of improved LS-SVM model output and practical output for n_h

对被检测系统式(12), 其测量信号分为两部分, 即反馈测量信号和输出测量信号. 输出测量信号只用于监测和状态监控, 对闭环控制系统不产生影响; 而反馈测量信号被用来反馈回闭环系统, 产生控制信号, 对闭环系统的控制品质产生直接影响. 因此, 当 n_h 传感器或 π_r 传感器故障时, 需要对系统信息进行自适应重构, 将相应的改进 LS-SVM 模型输出代替故障传感器输出反馈回闭环系统.

假设被检测系统的测量噪声是幅值为 $0.000\ 2$ 的白噪声. 在闭环系统仿真前, 根据带噪声的被检测系统, 得到 5 个模型的故障判定阈值范围如表 2 所示(阈值范围为标准方差的 5 倍).

确定了传感器故障判定的阈值范围后,就可以对闭环控制系统进行仿真实验了.由于仿真时采用的发动机模型是小偏差模型,因此限制控制量 m_f 和 A_e 的相对变化量范围为 $[-0.5, 0.5]$.在仿真实验过程中,若检测到反馈测量信号的传感器发生故障,首先对其进行隔离处理,然后用相应的改进 LS-SVM 模型估计输出值代替故障的反馈测量信号传感器,实现对闭环系统的自适应重构控制.

一般地,常见的传感器故障模式有卡滞、恒增益、恒偏差和完全失效四种.由于完全失效故障可以看作是卡滞故障(完全卡滞)或恒增益故障(增益系数为零)的特例,为此,本文对航空发动机传感器发生卡滞、恒增益和恒偏差故障时的故障诊断与自适应重构控制进行了研究.

闭环系统在 5 s 时, n_1 传感器发生恒增益故障(取恒增益比例系数 1.2),系统残差曲线和自适应重构控制曲线分别如图 4(a) (实线是残差,虚线是阈值界限,下同)和图 4(b) (实线是传感器实际输出曲线,虚线是模型估计输出曲线,下同)所示.

从图 4 和图 5 可知,当反馈输出传感器 (n_1 或 π_T 传感器) 分别在第 5 s 发生故障时,由于改

进的 LS-SVM 模型能较好地反映被检测系统的输入输出非线性关系,所以, n_1 或 π_T 传感器的实际输出值偏离了其对应模型的估计输出值,从而使得产生的残差较大,超出了故障判定的阈值范围,而其它正常传感器的实际输出值与相应的改进 LS-SVM 模型的估计输出值很接近,产生的残差较小,在故障判定的阈值范围内.因此,根据系统 n_1 或 π_T 产生的残差不在故障判定的阈值范围内可以及时诊断出反馈输出传感器发生了故障,同时,由于反馈输出传感器测量值在闭环反馈控制系统中起决定性作用,它们测量值的大小直接影响到闭环系统的控制品质,当系统检测到反馈输出传感器故障时,立刻将其隔离,并用相应的改进 LS-SVM 模型估计输出值代替故障的反馈输出传感器测量值反馈回闭环系统.从图 4~图 5 可以看出,采用本节提出的自适应重构控制技术后,闭环系统在反馈输出传感器发生故障后仍能保持原来良好的控制性能.

闭环系统在 5 s 时, T_{55} 传感器和 p_{33} 传感器同时分别发生恒偏差故障(取恒偏差系数为 0.01)和恒增益故障(取恒增益比例系数 1.2),系统残差曲线和系统响应曲线分别如图 6(a) 和图 6(b) 所示.




图 4 n_1 传感器发生恒增益故障时系统残差和自适应重构控制曲线

Fig. 4 Curves of system error and adaptive reconfiguration control in fixed plus fault of n_1 sensor




图 5 π_T 传感器发生卡滞故障故障时系统残差和自适应重构控制曲线

Fig. 5 Curves of system error and adaptive reconfiguration control in locked fault of π_T sensor




图 6 T_{55} 传感器和 p_{33} 传感器同时分别发生恒偏差和恒增益故障时系统残差曲线和响应曲线

Fig. 6 Curves of system error and response in fixed deflection fault of T_{55} sensor and fixed plus fault of p_{33} sensor

由图6可知,当输出测量信号传感器(n_h 和 T_{55} 传感器)分别在第5s发生故障,传感器的实际输出值偏离了相应模型的估计输出值,从而使产生的残差超出了故障判定的阈值范围,因此,系统在第5s能及时准确地判定出发生故障的传感器.由于输出测量信号传感器没有参与闭环系统的反馈,所以,它们故障对系统闭环反馈不产生影响,只是用于系统故障诊断与状态监视.

综上可知,改进的LS-SVM具有很强的逼近能力和鲁棒性,利用其建立航空发动机的数学模型可以很好地完成闭环控制系统传感器的在线故障诊断、隔离和自适应重构控制,达到了较理想的效果.

5 结 论

通过对基于改进LS-SVM的航空发动机传感器故障诊断与自适应重构控制的闭环仿真实验,得到如下结论:

1) 改进的LS-SVM具有调节参数少,模型结构由算法自动最优生成,不存在局部极小和结构确定无依据的缺点,具有很强的非线性逼近能力,特别适合于复杂、非线性和具有不确定性对象的系统辨识和建模,将其用于辨识航空发动机模型具有较高的精度和较强的泛化能力,为传感器故障诊断与自适应重构控制提供了有利的保障;

2) 对于单个传感器故障和多个传感器同时故障,本文提出的基于改进LS-SVM模型的传感器故障诊断与自适应重构控制方法都能及时准确地诊断出故障传感器和对故障传感器进行隔离,并用相应的改进LS-SVM模型估计输出值代替故障传感器的实际输出值,实现对航空发动机闭环控制系统的自适应重构控制,控制性能与系统正常时的控制性能基本一致,提高了控制系统的安全性和可靠性;

3) 本文虽然以发动机的状态空间模型为例,

研究了改进的LS-SVM算法在航空发动机故障诊断与自适应重构控制中的应用,但提出的方法不仅仅局限于线性系统,通过用非线性系统输入输出空间样本集去训练改进LS-SVM模型,可以将该方法推广到非线性系统.

参考文献:

- [1] 钱坤,谢寿生,胡金海,等.并行鲁棒观测器对发动机减小转速信号的故障分离[J].航空动力学报,2005,20(1):136-141.
QIAN Kun, XIE Shousheng, HU Jinjin, et al. Fault isolation of aeroengine speed decreasing signal based on parallel multiple robust observers[J]. Journal of Aerospace Power, 2005, 20(1): 136-141.
- [2] 何保成,于达仁,史新兴.应用传感器仿真模分析发动机控制系统故障[J].推进技术,2001,22(5):364-367.
HE Baocheng, YU Daren, SHI Xinxing. Application of simulation model of sensors to analysis fault of control system of turbojet engine[J]. Journal of Propulsion Technology, 2001, 22(5): 364-367.
- [3] Boskovic J D, Bergstrom S. Robust integrated flight control design under failures, damage and state-dependent disturbances[J]. Journal of Guidance, Control, and Dynamics, 2005, 28(5): 902-917.
- [4] Duan Zhuohua, Cai Zixing, Yu Jinxia. Unknown fault detection for mobile robots based on particle filters[J]. Proceedings of the 6th World Congress on Intelligent Control and Automation, IEEE, 2006: 5452-5457.
- [5] Koenig D. Unknown input proportional multiple-integral observer design for linear descriptor systems: application to state and fault estimation[J]. Automatic Control, IEEE Transactions on, 2005, 50(2): 212-217.
- [6] Surkens J A K, Vandewalle J. Least squares support vector machine classifiers[J]. Neural Processing Letters, 1999, 9(3): 293-300.
- [7] 朱家元,杨云,张恒喜,等.基于优化最小二乘支持向量机的小样本预测研究[J].航空学报,2004,25(6):565-568.
ZHU Jiayuan, YANG Yun, ZHANG Hengxi, et al. Data prediction with few observations based on optimized least squares support vector machines[J]. Acta Aeronautica et Astronautica Sinica, 2004, 25(6): 565-568.