

## 涡扇发动机气路健康的简约卡尔曼滤波估计

鲁 峰, 黄金泉

(南京航空航天大学 能源与动力学院, 江苏 南京 210016)

**摘要:** 由于航空发动机气路中传感器的数目有限, 令气路健康参数的估计结果带有不确定性, 为此, 我们提出基于简约卡尔曼滤波器的机载自适应模型. 该模型通过矩阵变换降低健康参数矩阵的维数, 把简约卡尔曼滤波器的估计偏差和方差的加权和作为最小化的目标, 采用自适应遗传算法构造出一个较准确, 能反映发动机性能的健康参数子集. 从理论上进一步论证了简约卡尔曼滤波器的估计方法. 对某型涡扇发动机气路部件进行性能估计作数值仿真, 结果表明, 基于简约卡尔曼滤波器的机载自适应模型方法适用于在包线内传感器个数少于健康参数条件下, 有效估计出发动机气路健康性能.

**关键词:** 航空发动机; 气路分析; 卡尔曼滤波器; 自适应遗传算法; 变换矩阵

**中图分类号:** V233.7      **文献标识码:** A

## Contracted Kalman filter estimation for turbofan engine gas-path health

LU Feng, HUANG Jin-quan

(College of Energy and Power Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing Jiangsu 210016, China)

**Abstract:** Because of the limited number of sensors, the health estimation results for the gas-path in a turbo-fan engine are uncertain. Based on the contracted Kalman filter, a self tuning on-board model is proposed. By using a matrix transformation, we reduce the dimensions of the health parameter matrix. The weighted sum of the estimation bias and the variance of the contracted Kalman filter is employed as the object of optimization; and a subset of precise health parameters reflecting the engine performance in operations is obtained by using the adaptive genetic algorithm. The self tuning on-board model based on contracted Kalman filter is further proved theoretically. The simulation of a turbo-fan engine shows that the method of contracted Kalman filter with self tuning on-board model effectively estimates the health parameters when the sensor number is less than the health parameter number in the operation range.

**Key words:** aero-engine; gas-path analysis; Kalman filter; adaptive genetic algorithms; transformation matrix

### 1 引言(Introduction)

发动机健康管理(engine health management, EHM)是利用发动机传感器、维护记录、部件模型等数据资源,对发动机故障进行诊断,对健康状态进行预报,从而增加飞行的安全性、可靠性和发动机性能<sup>[1]</sup>.考虑到气路部件故障约占发动机总体故障的90%.因此基于气路分析的故障诊断在发动机健康管理中至关重要<sup>[2]</sup>.典型的气路分析法包括基于模型的、数据驱动的和基于规则的方法<sup>[3]</sup>,为了最大程度地利用传感器和发动机部件特性信息,基于模型的发动机气路故障诊断成为最有效的手段.目前,基于模型的方法主要有基于部件级非线性模型和基于机载自适应模型,基于部件级模型的方法是在发动机部件级模型基础上采用扩展Kalman滤波器(extended Kalman filter, EKF)、无味Kalman滤波

器(unscented Kalman filter, UKF)算法实现健康参数估计<sup>[4-7]</sup>,但是由于机载资源和计算能力的限制,发动机部件级模型计算的实时性较难保证,而以线性模型为基础的自适应模型能满足机载要求<sup>[8]</sup>.

基于机载自适应模型的气路健康估计<sup>[9]</sup>主要有卡尔曼滤波器和实时机载模型,利用卡尔曼滤波器对发动机不可测的效率和流量等健康参数估计,卡尔曼滤波算法要求测量参数大于待估的健康参数,然而航空发动机可用传感器个数一般都比健康参数个数少,这就给估计带来了问题<sup>[10-11]</sup>.目前,为了使基于机载自适应模型的气路健康估计可行<sup>[12]</sup>,主要采用直接假设健康参数不大于测量参数或者根据经验选取健康参数子集,这就使得所选健康参数不能全面反映发动机健康状况,降低了诊断精度.

本文提出一种简约的卡尔曼滤波方法,对涡扇发

动机气路健康进行评价. 其基本原理为: 通过引入变换矩阵对健康参数向量降维, 使健康参数个数不大于测量参数, 以稳定工作状态下降维后的卡尔曼滤波估计误差和方差最小为目标, 采用自适应遗传算法对变换矩阵寻优, 最后得到一组能反映发动机健康状况的适维健康参数. 该方法扩展经典卡尔曼滤波算法应用范围, 解决了有限传感器的估计健康参数不确定性问题, 有效地提高发动机气路部件性能估计精度.

## 2 卡尔曼滤波的气路健康估计方法(Kalman filter gas-path health estimate method)

### 2.1 状态变量模型(State variable model)

以某型涡扇发动机部件级模型为对象, 采用混合求解法建立状态变量模型如下:

$$\begin{aligned} x_{k+1} &= Ax_k + Bu_k + Lh_k + \omega_k, \\ y_k &= Cx_k + Du_k + Mh_k + \nu_k, \end{aligned} \quad (1)$$

式中:  $A, B, C, D, L, M$ 均为发动机线性模型系数矩阵, 下标 $k$ 表示第 $k$ 个时刻点,  $u, x, y$ 分别是发动机稳态工作点的输入量、状态量和输出量,  $h$ 是健康参数,

$$\begin{aligned} u &= [PWFB \ PA_8]^T, \quad x = [PN_f \ PN_c]^T, \\ y &= [PN_f \ PN_c \ PT_{22} \ PP_{22} \ PT_3 \\ &\quad PP_4 \ PT_{45} \ PP_{45}]^T, \\ h &= [\eta_f \ W_f \ \eta_c \ W_c \ \eta_{ht} \ W_{ht} \ \eta_{lt} \ W_{lt}]^T. \end{aligned}$$

表1给出了发动机状态变量模型中各变量的物理意义.  $\omega$ 和 $\nu$ 分别为系统噪声阵和测量噪声阵, 其协方差阵分别为 $Q$ 和 $R$ .

表1 发动机状态变量模型变量表

Table 1 Variables of engine state variable model

变量	表述	变量	表述
$WFB$	燃油流量	$T_{22}$	风扇出口总温
$A_8$	尾喷口面积	$P_{22}$	风扇出口总压
$N_f$	低压转子转速	$T_3$	压气机出口总温
$N_c$	高压转子转速	$P_4$	燃烧室出口总压
$T_{45}$	高压涡轮出口总温	$P_{45}$	高压涡轮出口总压
$\eta_f$	风扇效率	$W_f$	风扇流量
$\eta_c$	压气机效率	$W_c$	压气机流量
$\eta_{ht}$	高压涡轮效率	$W_{ht}$	高压涡轮流量
$\eta_{lt}$	低压涡轮效率	$W_{lt}$	低压涡轮流量

为了使状态方程的系数矩阵能适用于全包线范围, 且避免物理量数量级的差别引起系数矩阵元素数量级相差很大, 以标况设计点相似参数作归一化处理.

### 2.2 基于自适应遗传算法的变换矩阵寻优 (Adaptive genetic algorithm (AGA) transformation matrix optimization method)

健康参数降维的机载自适应模型能部分地反映

发动机健康状况, 由式(14)和式(18)可以看出, 发动机健康降维估计精度由变换矩阵 $V$ 决定. 由于自适应遗传算法不需要考虑目标函数的解析性质<sup>[13]</sup>, 就能对任何形式的目标进行优化, 本文采用自适应遗传算法对变换矩阵 $V$ 寻优, 使卡尔曼滤波估计的健康参数误差最小. 将式(19)的目标函数的倒数作为自适应遗传算法的适应度函数. 遗传算法的遗传行为和性能由设置的交叉概率 $P_c$ 和变异概率 $P_m$ 决定, 且影响算法的收敛性. 作为遗传算法的改进自适应遗传算法根据个体的适应度值 $f$ 自动调整 $P_c, P_m$ , 对于性能较好、适应度高于平均适应度 $f_{avg}$ 的个体, 采用较小的 $f_{avg}$ , 反之亦然.  $P_c, P_m$ 的表达式如下:

$$\left\{ \begin{aligned} PN_f &= \left( \frac{N_f}{\sqrt{T_2}} \right) / \left( \frac{N_f}{\sqrt{T_2}} \right)_{ds} \times 100\%, \\ PN_c &= \left( \frac{N_c}{\sqrt{T_2}} \right) / \left( \frac{N_c}{\sqrt{T_2}} \right)_{ds} \times 100\%, \\ PP_{22} &= \left( \frac{P_{22}}{P_2} \right) / \left( \frac{P_{22}}{P_2} \right)_{ds} \times 100\%, \\ PT_{22} &= \left( \frac{T_{22}}{T_2} \right) / \left( \frac{T_{22}}{T_2} \right)_{ds} \times 100\%, \\ PT_3 &= \left( \frac{T_3}{T_2} \right) / \left( \frac{T_3}{T_2} \right)_{ds} \times 100\%, \\ PP_4 &= \left( \frac{P_4}{P_2} \right) / \left( \frac{P_4}{P_2} \right)_{ds} \times 100\%, \\ PT_{43} &= \left( \frac{T_{43}}{T_2} \right) / \left( \frac{T_{43}}{T_2} \right)_{ds} \times 100\%, \\ PP_{43} &= \left( \frac{P_{43}}{P_2} \right) / \left( \frac{P_{43}}{P_2} \right)_{ds} \times 100\%, \\ PWFB &= \left( \frac{WFB}{P_2\sqrt{T_2}} \right) / \left( \frac{WFB}{P_2\sqrt{T_2}} \right)_{ds} \times 100\%, \\ PA_8 &= \frac{A_8}{A_{8ds}} \times 100\%, \end{aligned} \right. \quad (2)$$

式中下标 $ds$ 表示设计点参数.

考虑采用卡尔曼滤波算法估计健康参数, 式(1)可等价转换为式(3)的发动机增广状态变量模型

$$\left\{ \begin{aligned} \begin{pmatrix} x_{k+1} \\ h_{k+1} \end{pmatrix} &= \underbrace{\begin{pmatrix} A & L \\ 0 & I \end{pmatrix}}_{A_{xh}} \underbrace{\begin{pmatrix} x_k \\ h_k \end{pmatrix}}_{x_{xh,k}} + \underbrace{\begin{pmatrix} B \\ 0 \end{pmatrix}}_{B_{xh}} u_k + \omega_{xh,k} = \\ &\quad A_{xh}x_{xh,k} + B_{xh}u_k + \omega_{xh,k}, \\ y_k &= \underbrace{\begin{pmatrix} C & M \end{pmatrix}}_{C_{xh}} \underbrace{\begin{pmatrix} x_k \\ h_k \end{pmatrix}}_{x_{xh,k}} + Du_k + \nu_k = \\ &\quad C_{xh}x_{xh,k} + Du_k + \nu_k. \end{aligned} \right. \quad (3)$$

### 2.3 降阶的状态方程(Reduced-order state equation)

降阶健康参数 $q$ 是所有健康参数 $h$ 的线性组合,

定义为

$$q = Vh, \quad (4)$$

式中:  $q \in \mathbb{R}^m$ ,  $h \in \mathbb{R}^p$ ,  $m < p$ ,  $V$  是秩为  $m$  的变换矩阵. 原健康参数  $h$  的估计值可表示为  $h = V^{-1}q$ .  $V^{-1}$  是变换矩阵  $V$  的伪逆, 把式(4)代入式(3)中, 就可以得到如下的降维状态变量模型:

$$\begin{cases} \begin{pmatrix} x_{k+1} \\ q_{k+1} \end{pmatrix} = \underbrace{\begin{pmatrix} A & LV^{-1} \\ 0 & I \end{pmatrix}}_{A_{xq}} \underbrace{\begin{pmatrix} x_k \\ q_k \end{pmatrix}}_{x_{xq,k}} + \underbrace{\begin{pmatrix} B \\ 0 \end{pmatrix}}_{B_{xq}} u_k + \omega_{xq,k} = \\ A_{xq}x_{xq,k} + B_{xq}u_k + \omega_{xq,k}, \\ y_k = \underbrace{\begin{pmatrix} C & MV^{-1} \end{pmatrix}}_{C_{xh}} \underbrace{\begin{pmatrix} x_k \\ q_k \end{pmatrix}}_{x_{xq}} + Du_k + \nu_k = \\ C_{xq}x_{xq,k} + Du_k + \nu_k. \end{cases} \quad (5)$$

噪声  $\omega_{xq}$  及其协方差  $Q_{xq}$  按如下方法计算:

$$\begin{cases} \omega_{xq} = \begin{pmatrix} I & 0 \\ 0 & V \end{pmatrix} \omega_{xh}, \\ Q_{xq} = \begin{pmatrix} I & 0 \\ 0 & V \end{pmatrix} Q_{xh} \begin{pmatrix} I & 0 \\ 0 & V \end{pmatrix}^T. \end{cases} \quad (6)$$

### 2.4 卡尔曼滤波器估计(Kalman filter estimate)

为了在白噪声环境下应用线性状态观测器, 采用卡尔曼滤波器<sup>[14]</sup>作为发动机状态估计器, 估计发动机健康状况. 卡尔曼滤波状态估计方程如下:

$$\hat{x}_{xq,k} = A_{xq}\hat{x}_{xq,k-1} + K_{\infty}(y_k - C_{xq}A_{xq}\hat{x}_{xq,k-1}), \quad (7)$$

式中卡尔曼滤波增益矩阵

$$K_{\infty} = P_{\infty}C_{xq}^T(C_{xq}P_{\infty}C_{xq}^T + R)^{-1}.$$

由于研究发动机稳态性能, 故发动机系统方程为常系数矩阵,  $P_{\infty}$  可以通过 Riccati 方程来计算:

$$A_{xq}P_{\infty}A_{xq}^T - A_{xq}P_{\infty}C_{xq}^T(C_{xq}P_{\infty}C_{xq}^T + R)^{-1}C_{xq}P_{\infty}A_{xq}^T + Q_{xq} = P_{\infty}, \quad (8)$$

则未降阶的增广状态变量模型的状态估计方程如下:

$$\begin{aligned} \hat{h}_k = V^{-1}\hat{q}_k \Rightarrow \\ \begin{bmatrix} \hat{x}_k \\ \hat{h}_k \end{bmatrix} = \begin{pmatrix} I & 0 \\ 0 & V^{-1} \end{pmatrix} \begin{bmatrix} \hat{x}_k \\ \hat{q}_k \end{bmatrix} \Rightarrow \hat{x}_{xh,k} = \\ \begin{pmatrix} I & 0 \\ 0 & V^{-1} \end{pmatrix} \hat{x}_{xq,k}. \end{aligned} \quad (9)$$

## 3 简约卡尔曼滤波的气路健康估计方法 (Contracted Kalman filter gas-path health estimation method)

### 3.1 构建目标函数(Object function design)

由于原系统的测量参数个数少于待估的健康参数个数, 区分信息不足, 不能通过降阶后的健康参数  $q$  将所有的蜕化信息都还原到  $h$ , 因此卡尔曼滤波估计存在误差, 该估计误差由估计偏差和估计方差两部分组成.

假设在某一稳定状态下, 发动机模型各参数满足以下统计特性:

$$\begin{cases} E[x_k] = E[x_{k+1}] = x_{ss}, \\ E[u_k] = 0, \\ E[h_k] = h, \\ E[y_k] = y_{ss}, \\ E[\omega_k] = E[\nu_k] = 0, \\ E[\hat{x}_{xq,k}] = E[\hat{x}_{xq,k-1}] = \bar{\hat{x}}_{xq,ss}, \\ E[\hat{x}_{xh,k}] = \bar{\hat{x}}_{xh,ss}, \end{cases} \quad (10)$$

式中下标  $ss$  代表稳态. 通过对式(3)取期望,  $x_{ss}, y_{ss}$  可以表示为原健康参数  $h$  的函数.

$$\begin{cases} E[x_{k+1}] = A \cdot E[x_k] + B \cdot E[u_k] + \\ L \cdot E[h_k] + E[\omega_k], \\ x_{ss} = Ax_{ss} + Lh, \\ x_{ss} = (I - A)^{-1}Lh, \\ E[y_k] = C \cdot E[x_k] + D \cdot E[u_k] + \\ M \cdot E[h_k] + E[\nu_k], \\ y_{ss} = Cx_{ss} + Mh, \\ y_{ss} = (C(I - A)^{-1}L + M)h. \end{cases} \quad (11)$$

取式(7)两边的期望,  $\hat{x}_{xq,k}$  的期望可以表示为  $y_{ss}$  的函数:

$$\begin{cases} E[\hat{x}_{xq,k}] = \\ A_{xq} \cdot E[\hat{x}_{xq,k-1}] + K_{\infty}(E[y_k] - \\ C_{xq}A_{xq} \cdot E[\hat{x}_{xq,k-1}]), \\ \bar{\hat{x}}_{xq,ss} = \\ A_{xq}\bar{\hat{x}}_{xq,ss} + K_{\infty}(y_{ss} - C_{xq}A_{xq}\bar{\hat{x}}_{xq,ss}) = \\ (I - A_{xq} + K_{\infty}C_{xq}A_{xq})^{-1}K_{\infty}y_{ss} = \\ (I - A_{xq} + K_{\infty}C_{xq}A_{xq})^{-1} \times \\ K_{\infty}(C(I - A)^{-1}L + M)h. \end{cases} \quad (12)$$

稳定状态下的增广状态变量估计偏差如下:

$$\bar{\hat{x}}_{xh,ss} = E[\hat{x}_{xh,k} - x_{xh,k}] = \bar{\hat{x}}_{xh,ss} - x_{xh,ss}. \quad (13)$$

联立式(9)(11)-(12)能得到如下稳定状态下的增广状态的估计偏差, 它包含原始状态量  $\bar{\hat{x}}_{ss}$  和健康参

数 $\tilde{h}_{ss}$ 的偏差信息:

$$\begin{cases} \tilde{x}_{xh,ss} = \begin{bmatrix} \tilde{x}_{ss} \\ \tilde{h}_{ss} \end{bmatrix} = \begin{bmatrix} I & 0 \\ 0 & V^{*-1} \end{bmatrix} \tilde{x}_{xq,ss} - x_{xh,ss}, \\ \tilde{x}_{xh,ss} = \\ \left( \begin{pmatrix} I & 0 \\ 0 & V^{*-1} \end{pmatrix} (I - A_{xq} + K_{\infty} C_{xq} A_{xq})^{-1} \times \dots \times \right. \\ \left. K_{\infty} (C(I - A)^{-1} L + M) - \begin{pmatrix} (I - A)^{-1} L \\ I \end{pmatrix} \right) = \\ G_{xh} h. \end{cases} \quad (14)$$

估计方差矩阵 $P_{\hat{x}q,k}$ 按下式定义:

$$P_{\hat{x}q,k} = E[\underbrace{(\hat{x}_{xq,k} - E[\hat{x}_{xq,k}])}_{\varepsilon_{xq,k}} (\hat{x}_{xq,k} - E[\hat{x}_{xq,k}])^T]. \quad (15)$$

由于 $E[\hat{x}_{xq,k}] = \tilde{x}_{xq,ss}$ , 且测量噪声 $v_k = y_k - y_{ss}$ , 联立式(7)(12)得

$$P_{\hat{x}q,k} = (A_{xq} - K_{\infty} C_{xq} A_{xq}) P_{\hat{x}q,k-1} (A_{xq} - K_{\infty} C_{xq} A_{xq})^T + K_{\infty} R K_{\infty}^T. \quad (16)$$

由于假设用于发动机稳定状态估计, 故 $P_{\hat{x}q,k} = P_{\hat{x}q,k-1}$ , 则式(16)可转化为如下 Ricatti 方程求解 $P_{\hat{x}q,k}$ , 并可求出 $P_{\hat{x}h,k}$ :

$$P_{\hat{x}q,k} = (A_{xq} - K_{\infty} C_{xq} A_{xq}) P_{\hat{x}q,k} (A_{xq} - K_{\infty} C_{xq} A_{xq})^T + K_{\infty} R K_{\infty}^T, \quad (17)$$

$$P_{\hat{x}h,k} = \begin{pmatrix} I & 0 \\ 0 & V^{*-1} \end{pmatrix} P_{\hat{x}q,k} \begin{pmatrix} I & 0 \\ 0 & V^{*-1} \end{pmatrix}^T. \quad (18)$$

以发动机健康参数估计误差平方和作为目标函数, 联立式(14)和式(18)可得估计误差平方和

$$\begin{aligned} SSE(\hat{x}_{xh}) &= \tilde{x}_{xh,ss}^2 + \text{tr}\{P_{\hat{x}h,k}\} = \\ &\text{tr}\{G_{xh} \cdot E[hh^T] G_{xh}^T\} + \text{tr}\{P_{\hat{x}h,k}\} = \\ &\text{tr}\{G_{xh} P_h G_{xh}^T + P_{\hat{x}h,k}\}. \end{aligned} \quad (19)$$

### 3.2 基于自适应遗传算法的变换矩阵寻优(AGA transformation matrix optimization method)

健康参数降维的机载自适应模型能部分地反映发动机健康状况, 由式(14)和式(18)可以看出, 发动机健康降维估计精度由变换矩阵 $V$ 决定. 由于自适应遗传算法不需要考虑目标函数的解析性质<sup>[13]</sup>, 就能对任何形式的目标进行优化, 本文采用自适应遗传算法对变换矩阵 $V$ 寻优, 使卡尔曼滤波估计的健康参数误差最小. 将式(19)的目标函数的倒数作为自适应遗传算法的适应度函数.

遗传算法的遗传行为和性能由设置的交叉概率 $P_c$ 和变异概率 $P_m$ 决定, 且影响算法的收敛性. 作为遗传算法的改进自适应遗传算法根据个体的适应度值 $f$ 自动调整 $P_c, P_m$ , 对于性能较好、适应度高于平均适应度 $f_{avg}$ 的个体, 采用较小的 $P_c, P_m$ , 反之亦然.  $P_c, P_m$ 的表达式如下:

$$\begin{cases} P_c = \begin{cases} P_{c1} - \frac{(P_{c1} - P_{c2})(f - f_{avg})}{f_{max} - f_{avg}}, & f \geq f_{avg}, \\ P_{c1}, & f < f_{avg}, \end{cases} \\ P_m = \begin{cases} P_{m1} - \frac{(P_{m1} - P_{m2})(f - f_{avg})}{f_{max} - f_{avg}}, & f \geq f_{avg}, \\ P_{m1}, & f < f_{avg}. \end{cases} \end{cases} \quad (20)$$

基于自适应遗传算法的发动机健康参数变换矩阵寻优算法如图1所示.

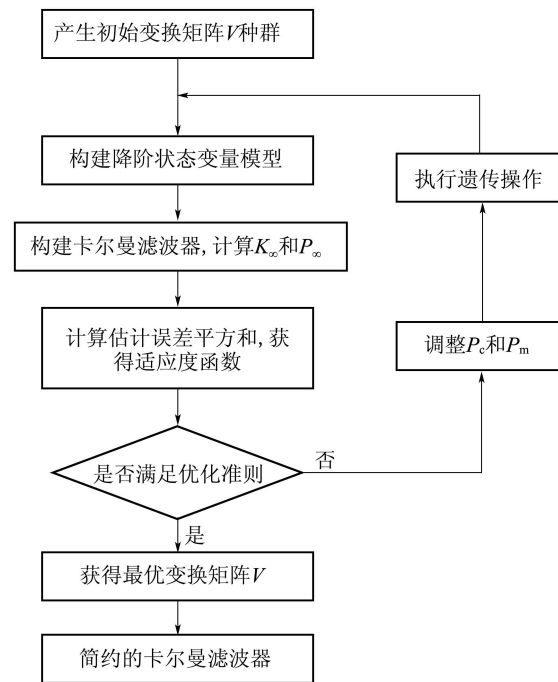


图1 基于自适应遗传算法求解变换矩阵  
Fig. 1 Transformation matrix optimized by AGA

### 4 仿真分析(Simulation analysis)

本文以某型涡扇发动机为研究对象, 研究了在地面标况和非标况的不同燃油流量条件下, 发动机发生单故障和双故障时, 基于简约的机载自适应模型方法对气路部件健康参数的估计能力. 涡扇发动机气路健康参数为风扇、压气机、高低压涡轮4个旋转部件的效率和流量共8个参数, 蜕化值参考NASA的航空推进系统仿真模块(modular aero-propulsion system simulations, MAPSS)仿真平台中完成一定工作循环的涡扇发动机主要气路部件健康参数变化情况统计数据, 这里考虑的是最大蜕化量. 依发动机传

传感器的相关性分析, 选取未降阶的机载自适应模型的测量参数子集  $y^* = [N_f \ N_c \ T_{22} \ P_{22} \ T_3 \ P_4 \ T_{45}]^T$ .

在稳态工作条件 ( $H = 0, Ma = 0, W_{fb} = 2.48 \text{ kg/s}, A_8 = 0.26$ ) 下, 采用混合求解法获得机载自适应模型:

$$A = \begin{bmatrix} -5.047 & 6.3937 \\ 0.3151 & -4.7638 \end{bmatrix}, B = \begin{bmatrix} 0.9562 & 1.8349 \\ 0.6220 & 0.1644 \end{bmatrix},$$

$$C = \begin{bmatrix} 1.0000 & 0 \\ 0 & 1.0000 \\ 0.4191 & -0.0761 \\ 1.0847 & -0.2019 \\ 0.1991 & 0.5137 \\ 0.4785 & 1.3075 \\ -0.2944 & -0.6147 \\ 0.5170 & 1.2772 \end{bmatrix}, D = \begin{bmatrix} 0 & 0 \\ 0 & 0 \\ 0.0786 & -0.2770 \\ 0.2210 & -0.9990 \\ 0.0977 & -0.0987 \\ 0.3503 & -0.4866 \\ 0.5224 & 0.3017 \\ 0.3331 & -0.5468 \end{bmatrix},$$

$$L = \begin{bmatrix} 3.5475 & -3.3393 & -0.5336 & 3.5954 & -0.5047 & 0.3949 & 2.2619 & -2.9836 \\ -0.9320 & -0.0029 & 2.1125 & -2.1718 & 2.2137 & -0.7905 & -0.2081 & 1.2965 \end{bmatrix},$$

$$M = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ -0.4373 & 0.2258 & -0.0278 & -0.0535 & -0.0324 & 0.0033 & -0.0291 & 0.0218 \\ -0.1619 & 0.8950 & -0.0836 & -0.1495 & -0.1097 & 0.0164 & -0.0912 & 0.0616 \\ -0.2694 & 0.0883 & -0.4857 & 0.2338 & -0.0046 & -0.2528 & -0.0269 & 0.0364 \\ 0.2267 & 0.4921 & -0.0630 & 0.7513 & 0.0194 & -0.9639 & -0.0845 & 0.0696 \\ -0.2574 & -0.3423 & -0.2479 & -0.4175 & -0.2273 & 0.0173 & 0.0849 & -0.1597 \\ 0.2323 & 0.5180 & -0.0901 & 0.7167 & -0.1009 & 0.0783 & -0.0605 & -0.9252 \end{bmatrix}.$$

在基于自适应遗传算法的变换矩阵  $V$  寻优中, 选取初始种群数为 100, 遗传代数为 400, 初始变换矩阵  $V$  满足  $\|V\|_F = 1$ , 设它们的染色体长度均为 10, 交叉概率  $P_{c1} = 0.7, P_{c2} = 0.5$ , 变异概率  $P_{m1} = 0.05, P_{m2} = 0.002$ . 在机载自适应模型中, 系统噪声  $Q$  和测量噪声  $R$  的协方差阵分别为

$$Q = \text{diag}\{0.005^2, 0.005^2, 0.005^2, 0.005^2, 0.005^2, 0.005^2, 0.005^2, 0.005^2\},$$

$$R = \text{diag}\{0.0015^2, 0.0015^2, 0.0015^2, 0.0015^2\}.$$

$$V = \begin{bmatrix} 0.1377 & 0.3063 & 0.0659 & 0.0306 & 0.0734 & 0.0488 & 0.1795 & 0.1281 \\ 0.0826 & 0.0085 & 0.2282 & 0.1882 & 0.1624 & 0.2220 & 0.0815 & 0.0260 \\ 0.0921 & 0.1059 & 0.1017 & 0.0334 & 0.088 & 0.0446 & -0.0299 & 0.2273 \\ 0.0039 & 0.0993 & 0.2025 & 0.0280 & 0.1773 & 0.1748 & 0.0646 & -0.0021 \\ 0.0185 & 0.1207 & 0.0446 & 0.2075 & 0.2601 & 0.2523 & 0.1007 & 0.2201 \\ 0.0468 & 0.0722 & -0.0038 & -0.0001 & 0.0313 & 0.0874 & -0.0115 & 0.1154 \\ 0.2423 & 0.1271 & 0.0519 & 0.1144 & 0.1312 & 0.0240 & 0.1008 & 0.1972 \end{bmatrix}.$$

模拟发动机在 2 s 时分别发生风扇流量下降 4%, 压气机流量下降 10% 的单故障情况. 对于双重故障, 模拟 2 s 时分别使风扇效率下降 4% 且低压涡轮效率下降 9%, 低压涡轮效率下降 2% 且低压涡轮流量增大 2%. 图 2、图 3 为发动机在地面标况下的单、双故障仿真效果, 图中的纵坐标为发动机健康参数蜕化量.

从图 2-3 可看出, 简约卡尔曼滤波器能有效地

$0.0015^2, 0.0015^2, 0.0015^2, 0.0015^2\}$ .

#### 4.1 地面标况仿真 (Simulations on standard ground conditions)

发动机在稳态工作条件 ( $H = 0, Ma = 0, W_{fb} = 2.48 \text{ kg/s}$ ) 下, 采用自适应遗传算法对变换矩阵寻优, 构建简约的机载自适应模型. 在原机载自适应模型中删除对应的行与列, 采用自适应遗传算法寻优获得的变换矩阵, 构建该传感器故障下的简约卡尔曼滤波器, 其中变换矩阵为

估计发动机单故障和双重故障, 由图 2(a) 可看出发动机在 2 s 时, 风扇流量曲线开始下降, 最终稳定至  $-0.04$  左右, 故可判断风扇流量蜕化 4%, 与发动机实际工作状态相符, 但部分其他部件健康参数有不大于 0.5% 的偏差, 可推断可用传感器信息量的减少对个别健康参数的估计存在微小偏差. 由图 3(a) 可得发动机在 2 s 时有两个气路参数发生蜕化, 分别为风扇效率下降 4% 且低压涡轮效率下降 2%.




图2 地面标况下的发动机单故障仿真效果

Fig. 2 Health estimation of simple fault mode under standard condition




图3 地面标况下的发动机双故障仿真效果

Fig. 3 Health estimation of double fault mode under standard condition

### 4.2 非标况仿真(Simulations on nonstandard conditions)

为了验证基于简约卡尔曼滤波器的机载自适应模型方法的健康估计鲁棒性,在飞行包线内取一非标况稳态( $H = 11000\text{ m}$ ,  $Ma = 0.8$ ,  $W_{fb} = 2.48\text{ kg/s}$ )进行仿真验证,采用自适应遗传算法算得变换矩阵 $V$ :

$$V^* = \begin{bmatrix} 0.1637 & 0.1421 & 0.1841 & 0.0546 & 0.0314 & 0.1798 & 0.1105 & 0.1249 \\ 0.0706 & 0.0800 & 0.0958 & 0.1101 & 0.1523 & 0.1141 & 0.1952 & 0.1945 \\ 0.0421 & 0.0046 & 0.2087 & 0.2080 & 0.1636 & 0.1662 & 0.1658 & 0.1297 \\ 0.0437 & 0.1243 & 0.0417 & 0.1009 & 0.0084 & 0.1584 & 0.2029 & 0.1325 \\ 0.0661 & 0.1589 & 0.0001 & 0.1985 & 0.1197 & 0.0329 & 0.2022 & 0.0760 \\ 0.2280 & 0.1221 & 0.1570 & 0.1753 & 0.0647 & 0.0941 & 0.0556 & 0.1173 \\ -0.0075 & 0.1878 & 0.0593 & 0.0144 & 0.0918 & 0.1339 & 0.1966 & 0.1494 \end{bmatrix}.$$

模拟发动机在2s时分别发生风扇效率下降4%,压气机流量下降10%的单故障情况.对于双重故障,模拟2s时分别使风扇效率下降2%且流量下降1%,风扇效率下降3%且压气机流量下降6%.图4、图5为发动机在非标况下的单、双故障仿真效果.

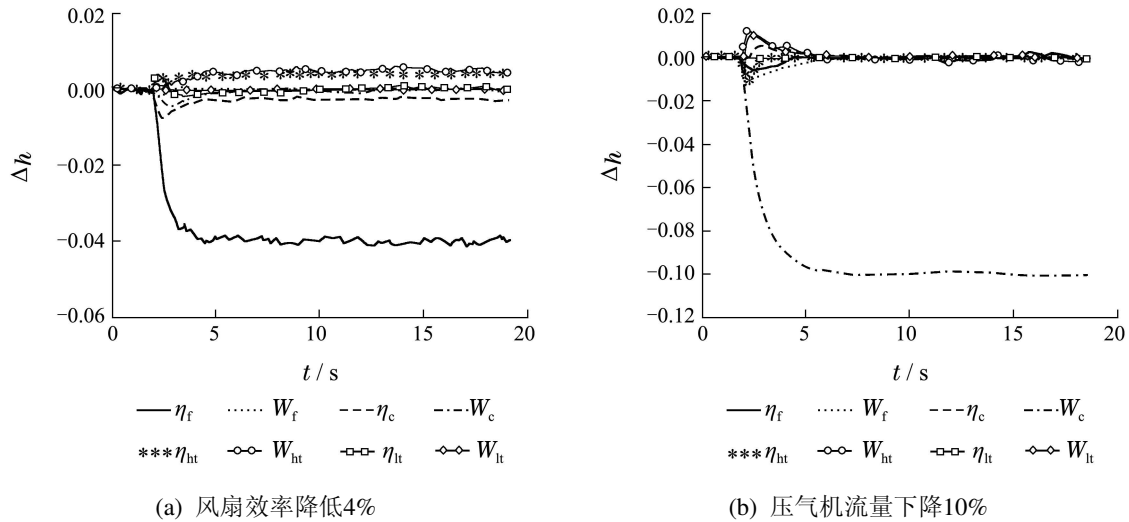


图 4 非标况下的发动机单故障仿真效果

Fig. 4 Health estimation of simple fault mode under nonstandard condition

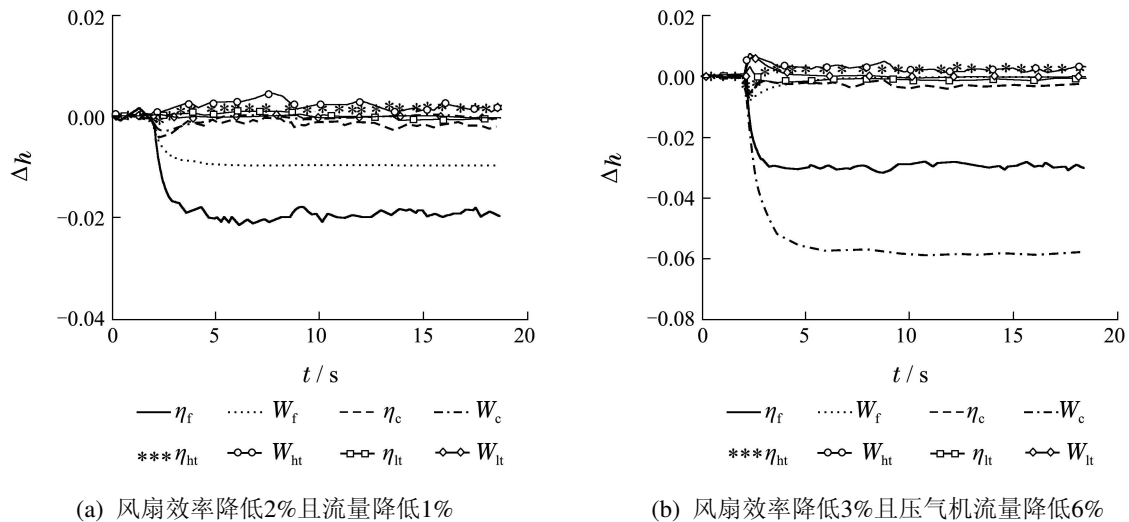


图 5 非标况下的发动机双故障仿真效果

Fig. 3 Health estimation of double fault mode under unstandard condition

从图4-5可以看出, 简约卡尔曼滤波器能有效地估计发动机单故障和双重故障, 表明该设计方法具有一定的鲁棒性, 能适用于非标况下的传感器参数少于健康参数个数的健康估计。

### 4.3 实验分析(Experimental analysis)

简约卡尔曼滤波器不仅能解决所需的测量参数个数小于待估的气路健康参数个数的问题, 而且能保证发动机气路健康参数估计对精度的要求。表2给出了在地面标况下的4种故障模式, 其中:  $\eta_f$  蜕化-4%,  $W_c$  蜕化-10%,  $\eta_f$  蜕化-4%同时 $\eta_{ht}$  蜕化-2%,  $\eta_{ht}$  蜕化-2%同时 $W_{ht}$  蜕化2%。表3给出了在非标况下的4种故障模式, 其中:  $\eta_f$  蜕化-4%,  $W_c$  蜕化-10%,  $\eta_f$  蜕化-2%同时 $W_f$  蜕化-1%,  $\eta_f$  蜕化-3%同

时 $W_c$ 蜕化-6%, 分别采用常规卡尔曼滤波器、按经验未优化的降价卡尔曼滤波器和简约卡尔曼滤波器方法获得的健康参数估计误差。

常规的卡尔曼滤波器估计器所用的测量信息为

$$y^* = [N_f \ N_c \ T_{22} \ P_{22} \ T_3 \ P_4 \ T_{45} \ P_{45}]^T,$$

与降价卡尔曼滤波器和简约卡尔曼滤波器相比, 多一个传感器信息 $P_{45}$ , 降价卡尔曼滤波器是直接利用初始经验获得变换矩阵 $V$ , 简约卡尔曼滤波器以估计误差的统计分析优化获得变换矩阵 $V$ 。由表2和表3可知, 简约卡尔曼滤波器在降低测量输入的维数的同时保证了健康参数的估计精度, 适用于发动机健康参数的不确定性估计。

表2 地面标况下健康参数估计误差  
Table 2 Health estimated errors under standard condition

	$\eta_f$ (-4%)	$W_c$ (-10%)	$\eta_f(-4\%),$ $\eta_t(-2\%)$	$\eta_t(-2%),$ $W_t(2\%)$
KF	0.002	0.0039	0.0037	0.0437
降阶KF	0.0629	0.0401	0.0441	0.0775
简约KF	0.0051	0.0059	0.0027	0.0412

表3 非标况下健康参数估计误差  
Table 3 Health estimated errors under nonstandard condition

	$\eta_f$ (-4%)	$W_c$ (-10%)	$\eta_f(-2%),$ $W_f(-1\%)$	$\eta_f(-3%),$ $W_c(-6\%)$
KF	0.0035	0.003	0.0033	0.025
降阶KF	0.0701	0.1192	0.0133	0.0383
简约KF	0.0126	0.0025	0.0068	0.0298

## 5 结论(Conclusions)

1) 基于自适应遗传算法的变换矩阵寻优是构建降阶的机载自适应模型的有效途径。

2) 基于简约卡尔曼滤波器的机载自适应模型能够避免实际工程中可用传感器信息有限, 解决了卡尔曼滤波估计中测量参数少于健康参数的参数估计问题。

3) 通过地面标况和非标况的单故障、双重故障的气路健康估计仿真验证, 表明该方法具有一定的鲁棒性, 能适用于飞行包线内不同工作点。

4) 为进一步探讨在卡尔曼滤波算法中, 不同故障模式下测量参数与健康参数的关系, 更少测量参数估计健康参数的适用范围提供必要的理论基础。

## 参考文献(References):

- [1] GARG S. *Controls and health management technologies for intelligent aerospace propulsion systems*, NASA/TM-2004-212915 [R]. Washington: National Aeronautics Space Administrator, 2004.
- [2] MICHAEL P, RUBYCA J. A prognostics and health management roadmap for information and electronics-rich systems [J]. *Microelectronics Reliability*, 2010, (50): 317 - 323.
- [3] SIMON D. A comparison of filtering approaches for aircraft engine health estimation [J]. *Aerospace Science and Technology*, 2008, 12(4): 276 - 284.
- [4] BORGUET S, DEWALLEF P, LEONARD O. *On-line transient engine diagnostics in a Kalman filtering framework*, ASME Turbo Expo 2005: Power for Land, Sea, and Air, GT2005-68013 [R]. Atlanta, Georgia, USA: ASME, 2005.
- [5] DEWALLEF P, LEONARD O. *On-line performance monitoring and engine diagnostic using robust Kalman filtering techniques*, GT2003-38379 [R]. Atlanta, Georgia, USA: ASME, 2003.
- [6] SIMON D, SIMON D L. *Aircraft turbofan engine health estimation using constrained Kalman filtering*, NASA/TM-2003-212528 [R]. Atlanta, Georgia, USA: ASME, 2003.
- [7] DONALD L, SANJAY G. *A systematic approach for model-based aircraft engine performance estimation*, NASA/TM-2010-216077 [R]. Washington: National Aeronautics Space Administrator, 2010.
- [8] VOLPONI A. *Enhanced self tuning on-board real-time model (eSTORM) for aircraft engine performance health tracking*, NASA/CR-2008-215272 [R]. Atlanta, Georgia, USA: ASME, 2008.
- [9] 李秋红, 孙健国, 王前宇. 航空发动机推力估计新方法 [J]. *控制理论与应用*, 2011, 28(2): 185 - 191.  
(LI Qiu hong, SUN Jianguo, WANG Qianyu. A new method for estimating the thrust of aircraft engines [J]. *Control Theory & Applications*, 2011, 28(2): 185 - 191.)
- [10] OGAI S, SAMPATH S, SINGH R, et al. Parameter selection for diagnosing a gas-turbine's performance deterioration [J]. *Applied Energy*, 2002, 73(1): 25 - 46.
- [11] JULIER S, UHLMANN J K. A new method for the nonlinear transformation of means and covariances in filters and estimators [J]. *IEEE Transactions on Automatic Control*, 2000, 45(3): 477 - 482.
- [12] SIMON D L, GARG S. *Optimal tuner selection for Kalman filter-based aircraft engine performance estimation*, NASA/TM-2010-216076 [R]. Atlanta, Georgia, USA: ASME, 2010.
- [13] 鲁峰, 黄金泉. 基于遗传算法的航空发动机机载模型支持向量机修正方法 [J]. *航空动力学报*, 2009, 24(4): 880 - 885.  
(LU Feng, HUANG Jinquan. AGA-LSSVR compensation for on-board self tuning model of aero-engine model [J]. *Journal of Aerospace*, 2009, 24(4): 880 - 885.)
- [14] RAN C J, DENG Z L. Self-tuning weighted measurement fusion Kalman filter and its convergence [J]. *Journal of Control Theory and Application*, 2010, 8(4): 435 - 440.

## 作者简介:

鲁峰 (1981-), 男, 博士, 讲师, 硕士生导师, 主要研究方向为航空发动机预测健康管理、建模仿真、信息融合, E-mail: lufengnuaa@126.com;

黄金泉 (1963-), 男, 博士, 教授, 博士生导师, 主要研究方向为航空发动机建模、控制与故障诊断等, E-mail: E-mail: jhuang@nuaa.edu.cn.