

文章编号: 1000-8055(2008)03-0580-05

航空发动机故障诊断的机载自适应模型

黄伟斌, 黄金泉

(南京航空航天大学 能源与动力学院, 南京 210016)

摘 要: 提出了复合拟合法建立状态变量模型, 该方法应用于建立高维状态变量模型时, 具有较高的精度. 将健康参数作为增广的状态变量, 设计了卡尔曼滤波器, 从而可以根据可测参数的偏离量估计得到健康参数. 为了减少自适应模型与真实发动机之间的建模误差, 在自适应模型中加入神经网络对稳态基点模型进行修正, 从而提高了故障诊断系统的置信度.

关 键 词: 航空/航天推进系统; 航空发动机故障诊断; 健康参数; 机载自适应模型; 状态变量模型; 卡尔曼滤波器; 神经网络

中图分类号: V233.7

文献标识码: A

On board self-tuning model for aero-engine fault diagnostics

HUANG Wei bin, HUANG Jin quan

(College of Energy and Power Engineering,

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

Abstract: The composite least square method was proposed for establishing the state variable model. The method was also applied to develop high dimension state variable model with high accuracy. By taking health parameters as augmented state variables, a Kalman filter was then designed to predict the health parameters from the deviation of measurable parameters. To minimize the modeling errors between the self tuning model and real engine, a neural network was built to modify the steady-state modeling errors, thus improving the confidence level of fault diagnosis system.

Key words: aerospace propulsion system; aero-engine fault diagnostics; health parameters; on board self tuning model; state variable model; Kalman filter; neural network

故障诊断系统是航空发动机健康管理的一个重要组成部分. 故障诊断的目的在于估计发动机各个部件的变化情况, 通过分析沿发动机气路的各个传感器的测量值, 隔离发动机故障, 估计发动机性能变化. 气路故障诊断的核心内容是健康参数的估计, 主要方法有基于人工神经网络的方法和基于卡尔曼滤波的方法^[1].

上世纪 80 年代末, Luppold R H 等人首先建立了基于卡尔曼滤波的自适应模型^[2], 从而可以

根据可测参数的偏离量得到健康参数的估计值. 利用神经网络建立不可测健康参数和可测参数的偏离量之间的非线性关系, 从而可以根据可测参数的偏离量来估计健康参数^[3].

自适应模型是在部件级模型的基础上获得的. 由于真实发动机与部件级模型之间总是存在着建模误差. 因此, 自适应模型与真实发动机之间总是存在着建模误差. 当自适应模型用于故障诊断时, 这一建模误差会产生误诊. 从工程实际出

收稿日期: 2007-01-30; 修订日期: 2007-11-02

作者简介: 黄伟斌(1982), 男, 福建泉州人, 硕士生, 主要从事航空发动机建模与故障诊断方面的研究.

发, 只有消除建模误差, 才能对健康参数进行准确估计, 从而提高故障诊断系统的置信度。

1 状态变量模型

为了能够利用可测输出偏离量估计健康参数, 在状态变量模型中需要包含健康参数与输出量关系的信息。因此, 状态变量模型的表达式如下:

$$\begin{aligned}\Delta \dot{\mathbf{x}} &= \mathbf{A} \Delta \mathbf{x} + \mathbf{B} \Delta \mathbf{u} + \mathbf{L} \Delta \boldsymbol{\eta} \\ \Delta \mathbf{y} &= \mathbf{C} \Delta \mathbf{x} + \mathbf{D} \Delta \mathbf{u} + \mathbf{M} \Delta \boldsymbol{\eta}\end{aligned}\quad (1)$$

其中, $\Delta \mathbf{x} = \mathbf{x} - \mathbf{x}^b$, $\Delta \mathbf{y} = \mathbf{y} - \mathbf{y}^b$, $\Delta \mathbf{u} = \mathbf{u} - \mathbf{u}^b$, 分别表示状态增量、输出增量和控制增量。下标 b 表示状态变量模型的发动机稳态工作点, 也称稳态基点模型。令 $\mathbf{x} = [N_L \quad N_H \quad T_4]^T$, N_L 为风扇转速, N_H 为压气机转速, T_4 为高压涡轮进口温度; 令 $\mathbf{y} = [N_L \quad N_H \quad p_4 \quad T_{45}]^T$, p_4 为燃烧室出口压力, T_{45} 为低压涡轮进口温度; 令 $\mathbf{u} = [W_{FB} \quad A_8]^T$, W_{FB} 为燃油量, A_8 为尾喷口面积。令 $\Delta \boldsymbol{\eta} = [\Delta \eta_{\text{fan}} \quad \Delta \eta_{\text{comp}} \quad \Delta \eta_{\text{ht}} \quad \Delta \eta_{\text{lt}}]^T$ 为健康参数, $\Delta \eta_{\text{fan}}$ 表示风扇效率的变化量, $\Delta \eta_{\text{comp}}$ 表示压气机效率的变化量, $\Delta \eta_{\text{ht}}$ 表示高压涡轮效率的变化量, $\Delta \eta_{\text{lt}}$ 表示低压涡轮效率的变化量。

状态变量模型中系数矩阵的求取, 可采用拟合法^[4]或改进拟合法^[5]。拟合法的优点是状态方程的系数矩阵和输出方程的系数矩阵是分开求取的, 且输出方程的系数矩阵可以针对输出量单独求取。但是, 拟合法需要求解状态变量模型的动态响应解析式, 而求解状态量三维以上模型的动态响应解析式比较复杂, 因此对于本文中以 N_L , N_H , T_4 为状态量的状态变量模型来说, 拟合法并不适用。改进拟合法的优点是避免三维以上的状态变量模型动态响应解析式的求解, 但是所有矩阵需要同时进行拟合, 当输出量多维时采用改进拟合法会降低拟合的精度。本文结合改进拟合法和拟合法的各自优点, 提出了复合拟合法。复合拟合法的具体求取步骤如下:

(1) 采用改进拟合法求解 $\mathbf{A}$, $\mathbf{B}$, $\mathbf{L}$ 矩阵。将三个状态量 N_L , N_H , T_4 作为输出量, 此时 $\mathbf{A}$, $\mathbf{B}$, $\mathbf{L}$ 矩阵未知, $\mathbf{C}$ 为单位矩阵, $\mathbf{D}$, $\mathbf{W}$ 为零矩阵。根据改进拟合法的矛盾方程组, 求得在最小二乘意义下的 $\mathbf{A}$, $\mathbf{B}$, $\mathbf{L}$ 矩阵。

(2) 采用拟合法求解 $\mathbf{C}$, $\mathbf{D}$ 矩阵。此时 $\mathbf{A}$, $\mathbf{B}$, $\mathbf{L}$ 矩阵已经由改进拟合法求得, $\mathbf{C}$, $\mathbf{D}$, $\mathbf{M}$ 矩阵未知。采用拟合法一一求得 p_4 和 T_{45} 所对应的矩阵系数, 从而得到最小二乘意义下的 $\mathbf{C}$, $\mathbf{D}$, $\mathbf{M}$ 矩阵。

复合拟合法利用改进拟合法求解状态方程的系数矩阵, 从而避免了高维动态响应解析式的求解, 利用拟合法求解输出方程的系数矩阵, 在多维输出的情况下, 可以提高建模的精度。

2 卡尔曼滤波器设计

发动机实际工作中会受到各种噪声的污染, 如振动噪声、热噪声、测量噪声等, 而建模时所做的各种假设如忽略高频特性和线性化近似。所以, 要表示发动机真实系统的特性, 需要考虑系统误差和测量误差。因此, 发动机模型应表示为

$$\begin{aligned}\Delta \dot{\mathbf{x}} &= \mathbf{A} \Delta \mathbf{x} + \mathbf{B} \Delta \mathbf{u} + \mathbf{L} \Delta \boldsymbol{\eta} + \mathbf{w} \\ \Delta \mathbf{y} &= \mathbf{C} \Delta \mathbf{x} + \mathbf{D} \Delta \mathbf{u} + \mathbf{M} \Delta \boldsymbol{\eta} + \mathbf{v}\end{aligned}\quad (2)$$

式中, $\mathbf{w}$ 和 $\mathbf{v}$ 分别为系统噪声阵和测量噪声阵, 其协方差阵分别为 $\mathbf{Q}$ 和 $\mathbf{R}$ 。对于一般的工程问题, 系统噪声和测量噪声均为不相关正态分布的高斯白噪声, 即 $\mathbf{Q}$ 和 $\mathbf{R}$ 为对角阵。

卡尔曼滤波器通过含有测量噪声的可测输出偏离量 $\Delta \mathbf{y}$ 估计健康参数的变化量 $\Delta \boldsymbol{\eta}$ 。因此, 需要将健康参数增广为状态量, 然后在增广的状态变量模型的基础上设计卡尔曼滤波器。

对于发动机来说, 如果不考虑外物突然撞击造成的损伤, 那么健康参数的退化是一个比较缓慢的过程, 因此可以假设 $\Delta \dot{\boldsymbol{\eta}} = 0$ 。增广的状态变量模型为

$$\begin{aligned}\begin{bmatrix} \Delta \dot{\mathbf{x}} \\ \Delta \dot{\boldsymbol{\eta}} \end{bmatrix} &= \begin{bmatrix} \mathbf{A} & \mathbf{L} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \begin{bmatrix} \Delta \mathbf{x} \\ \Delta \boldsymbol{\eta} \end{bmatrix} + \begin{bmatrix} \mathbf{B} \\ \mathbf{0} \end{bmatrix} \Delta \mathbf{u} + \begin{bmatrix} \mathbf{w} \\ \mathbf{0} \end{bmatrix} \\ \Delta \mathbf{y} &= [\mathbf{C} \quad \mathbf{M}] \begin{bmatrix} \Delta \mathbf{x} \\ \Delta \boldsymbol{\eta} \end{bmatrix} + \mathbf{D} \Delta \mathbf{u} + \mathbf{v}\end{aligned}\quad (3)$$

因此, 卡尔曼滤波器的表达式为

$$\begin{aligned}\begin{bmatrix} \Delta \hat{\mathbf{x}} \\ \Delta \hat{\boldsymbol{\eta}} \end{bmatrix} &= \begin{bmatrix} \mathbf{A} & \mathbf{L} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \begin{bmatrix} \Delta \hat{\mathbf{x}} \\ \Delta \hat{\boldsymbol{\eta}} \end{bmatrix} + \begin{bmatrix} \mathbf{B} \\ \mathbf{0} \end{bmatrix} \Delta \mathbf{u} + \\ &\quad \mathbf{K} [\Delta \mathbf{B} - [\mathbf{C} \quad \mathbf{M}] \begin{bmatrix} \Delta \hat{\mathbf{x}} \\ \Delta \hat{\boldsymbol{\eta}} \end{bmatrix}] \\ \Delta \mathbf{y} &= [\mathbf{C} \quad \mathbf{M}] \begin{bmatrix} \Delta \hat{\mathbf{x}} \\ \Delta \hat{\boldsymbol{\eta}} \end{bmatrix} + \mathbf{D} \Delta \mathbf{u}\end{aligned}\quad (4)$$

式中, $\mathbf{K} = \begin{bmatrix} \mathbf{K}_x \\ \mathbf{K}_\eta \end{bmatrix} = \mathbf{B} \mathbf{H}^T \mathbf{R}^{-1}$, $\mathbf{P} > 0$ 为如下 Riccati 方程的解

$$\begin{aligned}\begin{bmatrix} \mathbf{A} & \mathbf{L} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \mathbf{P} + \mathbf{P} \begin{bmatrix} \mathbf{A} & \mathbf{L} \\ \mathbf{0} & \mathbf{0} \end{bmatrix}^T + \mathbf{Q} - \\ \mathbf{P} [\mathbf{C} \quad \mathbf{M}]^T \mathbf{R}^{-1} [\mathbf{C} \quad \mathbf{M}] \mathbf{P} = 0\end{aligned}$$

由状态变量模型和卡尔曼滤波器组成自适应模型(图1)。

4 数字仿真

以某型涡扇发动机为研究对象, W_{FB} 取 1% 的阶跃, 健康参数的变化量分别取 1% 的下降, 采用复合拟合合法得到状态变量模型. 给状态变量模型阶跃输入, 得到阶跃响应曲线. 图 4 给出了设计点($H=0\text{ km}$, $Ma=0$, 风扇换算转速为 0.93) 状态变量模型和部件级模型的阶跃响应仿真结果. 限于篇幅, 图中仅给出压气机转速在燃油量阶跃作用下, 以及涡轮前温度在高压涡轮效率阶跃作用下的响应, 两者的误差小于 2%.




图 4 N_L 和 T_4 的阶跃响应
Fig. 4 Responses of N_L and T_4

选择 BP 网络的 Levenberg-Marquardt 算法训练神经网络. 经过仿真试验研究, 当式(6)中的 $q=2$, 网络的隐含层单元个数为 15 时, 网络的训练输出与状态变量模型输出相加后的输出与真实发动机的输出接近.

为了检验神经网络的泛化能力, 从最大状态经过 935 s 的缓慢减速到达慢车状态, 然后在慢车状态保持 330 s, 最后从慢车状态再经过 935 s 的缓慢加速回到最大状态. 将这一过程的燃油量变化规律作为测试信号输入到神经网络中, 将网络的测试输出与状态变量模型输出相加后的输出与真实发动机的输出进行比较, 如图 5 所示. 设 $e_k = (y_k - \hat{y}_k)/y_{d,k} \times 100\%$, $k=1, 2, 3, 4$ 分别表示 4 个输出量 N_L, N_H, p_4, p_6 的误差, $y_{d,k}$ 为相应输出的设计点值. 从图中可以看出, 两者非常接近, 误差小于 1%.

为了检验神经网络对建模误差修正的效果, 在某一稳态点($H=0\text{ km}$, $Ma=0$, 风扇换算转速




图 5 修正后状态变量模型和实际发动机的输出
Fig. 5 Outputs of revised state variable model and real engine

$N_{Lcor}=0.5$), 选取一定的 Q 和 R , 设计卡尔曼滤波器. 其中, $Q=\text{diag}\{0.002^2\ 0.002^2\ 0.002^2\ 0.0006^2\ 0.0006^2\ 0.0006^2\ 0.0006^2\}$, $R=\text{diag}\{0.002^2\ 0.002^2\ 0.002^2\ 0.002^2\}$. 此时真

实发动机没有退化,即健康参数变化量为零.在无神经网络修正时,卡尔曼滤波器估计得到健康参数如图 6 中(a)所示,健康参数估计存在较大的估计误差.增加神经网络的修正功能,估计得到健康参数如图 6 中(b)所示,估计误差大大减少.




图 6 真实发动机的健康参数估计结果
Fig.6 Health parameters estimation results
of non degradation engine




图 7 退化发动机的健康参数估计结果
Fig.7 Health parameters estimation results
of degradation engine

当压气机退化 3% 时,无神经网络的修正时,卡尔曼滤波器估计得到健康参数的变化量如图 7 (a)所示.有神经网络修正功能时,估计得到健康参数的变化量如图 7 (b)所示.

从图 6 和图 7 中可以看出,不管是在发动机没有退化还是发动机退化的情况下,具有神经网络修正功能的自适应模型都能较准确地估计发动机的健康参数,从而提高了发动机故障诊断系统的置信度.另外,从图中也可以看出,当建模误差消除后,所建立的卡尔曼滤波器能较准确地估计健康参数.

5 结 论

- (1) 提出了复合拟合建立包含健康参数的状态变量模型.该方法应用于建立高维的状态变量模型时,具有较高的精度.
- (2) 设计了卡尔曼滤波器,数字仿真表明,设计的卡尔曼滤波器能准确估计发动机的健康参数.
- (3) 考虑到模型与真实发动机之间的建模误差,在自适应模型中引入了神经网络的修正机制,提高了自适应模型的精度,从而提高了发动机故障诊断系统的置信度.

参考文献:

[1] Volponi A J, DePold H, Ganguli R. The use of Kalman filter and neural network methodologies in gas turbine performance diagnostics: a comparative study[J]. Journal of Engineering for Gas Turbines and Power, 2003, 125(11): 917-924.

[2] Luppold R H, Gallops G W, Kerr L J, et al. Estimating in-flight engine performance variations using kalman filter concepts[R]. AIAA-89-2584, 1989.

[3] 王信德, 孙健国, 李松林, 等. 神经网络在发动机自适应建模中的应用研究[J]. 航空动力学报, 2003, 18(6): 845-849.

WANG Xinde, SUN Jianguo, LI Songlin, et al. Application of neural networks to aeroengine adaptive modeling [J]. Journal of Aerospace Power, 2003, 18(6): 845-849.

[4] 冯正平, 孙健国, 黄金泉, 等. 一种建立航空发动机状态变量模型的新方法[J]. 航空动力学报, 1998, 13(4): 435-438.

FENG Zhengping, SUN Jianguo, Huang Jinquan, et al. A new method for establishing a state variable model of aeroengine[J]. Journal of Aerospace Power, 1998, 13 (4): 435-438.

[5] 冯正平. 航空发动机多变量鲁棒控制[D]. 南京: 南京航空航天大学, 1999.