

文章编号: 1000-8055(2008)06-1111-07

基于卡尔曼滤波器及神经网络的 发动机故障诊断

姚 华^{1,2}, 单贵平¹, 孙健国¹

(1. 南京航空航天大学 能源与动力学院, 南京 210016;

2. 中国航空工业第一集团公司 航空动力控制系统研究所, 无锡 214063)

摘 要: 提出了一种基于卡尔曼滤波器及神经网络的航空燃气涡轮发动机气路故障诊断的方法. 该方法用卡尔曼滤波器来估计发动机可测参数的变化量, 再由神经网络来映射发动机性能参数的变化量, 并据此进行发动机气路故障诊断. 数字仿真表明, 该方法是可行的, 有效的.

关 键 词: 航空、航天推进系统; 航空发动机; 故障诊断; 卡尔曼滤波器; 神经网络

中图分类号: V231

文献标识码: A

Fault diagnosis for gas turbine engines based on Kalman filter and neural networks

YAO Hua^{1,2}, SHAN Gui-ping¹, SUN Jian-guo¹

(1. College of Energy and Power Engineering,

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

2. Aviation Motor Control System Research Institute,

China Aviation Industry Corporation I, Wuxi 214063, China)

Abstract: A method for gas path fault diagnosis of gas turbine engines based on Kalman filter and neural networks was proposed. For the fault diagnosis, the Kalman filter was used to estimate the variations of measurable parameters, while neural network was applied for mapping the variations of performance parameters of gas turbine engines. Digital simulations show that the proposed method is feasible and effective.

Key words: aerospace propulsion system; gas turbine engine; fault diagnosis; Kalman filter; neural networks

传统的发动机故障诊断只能在地面进行, 在地面通过对发动机的检测来诊断发动机的故障, 不能在飞行中对发动机进行实时故障诊断, 这显然影响了对故障的及时诊断及排除, 影响了发动机的安全工作及飞行安全. 发动机数控技术的应用, 为发动机故障诊断技术的提高及应用奠定了基

础^[1]. 利用数字计算机强大的计算能力及逻辑判断功能, 可以实现控制与故障诊断的一体化设计, 以及发动机实时健康监控、故障诊断、故障预报.

当发动机的气路部件由于疲劳、磨损等原因发生故障时, 会导致这些部件的(一个或几个)特性参数发生变化. 所有能比较直接反映发动机部

收稿日期: 2007-05-30; 修订日期: 2007-08-20

基金项目: 航空科学基金(04C52019)

作者简介: 姚华(1961 -), 男, 湖北武汉人, 中国一航动力控制系统研究所总设计师, 博士, 从事航空发动机控制技术研究及系统研制.




图1 故障诊断的结构原理图

Fig.1 Fault diagnosis for gas turbine engines based on Kalman filter and neural networks

件工作状态变化及故障特性的参数,如效率、流通能力等称为部件性能参数。但一般情况下,这些部件性能参数都难以测量或根本无法测量,而容易被测量到的参数是发动机各截面的温度、压力、转子转速和燃油流量等,这些参数称为测量参数。在发动机工作条件不变的情况下,部件性能参数的变化将会引起测量参数的变化,所以测量参数也能反映发动机性能的变化,但是不同的部件性能参数变化有可能引起相似的测量参数的变化。因此难以用测量参数的变化来直接反映部件性能参数的变化以及发动机是否发生故障。另一方面测量参数与部件性能参数之间存在着严格的气动热力学关系。因此应该可以找到一种方法,通过对测量参数的变化进行分析,推断出相应的部件性能参数变化,进而达到故障诊断的目的。本文提出一种利用卡尔曼滤波器及神经网络相结合,对发动机进行实时故障诊断的方法,其软件可嵌入在发动机数控计算机中,为实现控制与故障诊断的一体化打下基础。

1 基本思路

当发动机发生气路故障时,部件性能参数的改变将会引起可测量参数的变化,因而可以用这些可测参数的变化量(可测参数偏离量)来反映发动机部件性能参数的变化以及发动机发生故障的情况。为了得到这些可测参数的变化量,将它们视为增广的状态变量,设计卡尔曼滤波器对其进行最优估计,将可测参数偏离量来修正部件级模型的输出,再用修正的可测参数通过BP神经网络建立起来的可测参数和发动机部件性能参数之间的映射关系映射出性能参数,通过故障诊断模块进行故障诊断。故障诊断的原理如图1所示。

2 故障诊断原理

2.1 建立故障诊断模型

发动机部件级模型根据发动机的气动热力特性及典型实验特性数据按部件法建立,能准确反映发动机设计额定工况。

卡尔曼滤波器是针对线性系统的滤波理论,要把它推广用于航空发动机这样的非线性系统,首先需要建立发动机分段线性化的状态变量模型(SVM),对于SVM中A、B、C、D系数矩阵的求取方法很多^[2]。常用的是“偏导数法”^[3],该方法的缺点在于拟合精度低,存在较大误差。因此,本文采用拟合精度较高的“拟合法”求取系数矩阵^[4]。

选择 N_1 和 N_2 为SVM的状态变量,5个可测量参数 N_1, N_2, p_3, p_6, T_y 为SVM的输出变量, W_{fb} 和 A_8 为输入变量。状态变量模型的形式为

$$\Delta X = A \cdot \Delta X + B \cdot \Delta Y \quad (1)$$

$$\Delta Y = C \cdot \Delta X + D \cdot \Delta U \quad (2)$$

发动机状态变量模型SVM,是按发动机的额定工作特性来建立的,因而该模型只能反映发动机的额定工况。实际工作的发动机由于受到制造安装公差以及使用寿命期内性能蜕化的影响而往往工作在非额定工作状态。发动机的非额定工作必然导致其输出参数的变化,使得按正常特性建立的模型输出和真实发动机输出不一致,产生输出偏离量。我们必须获得这些输出偏离量,并用来校正模型输出,使模型输出反映发动机的真实工况。

由于实际工作的发动机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简化假设如忽略高频特性和线性化假设,会给模型带来系统误差。所以,要表示发动机真实系统

的特性,还需要考虑系统误差和测量误差。

因此,描述真实发动机系统的动态模型应表示为

$$\dot{\Delta X} = A \cdot \Delta X + B \cdot \Delta U + W \quad (3)$$

$$\Delta Y = C \cdot \Delta X + D \cdot \Delta U + Y_b + V \quad (4)$$

其中 Y_b 表示输出偏离量, $Y_b = [PN_{1b} \quad PN_{2b} \quad Pp_{3b} \quad Pp_{6b} \quad PT_{yb}]^T$ (各输出偏离量是在参数名后加字母 b 表示,符号 P 表示百分比,即对于额定值的相对量), W 为系统噪声矩阵, V 为测量噪声矩阵。由于噪声作用使 Y_b 不能直接获得,只能通过估计方法得到。为了能够用估计方法得到 Y_b ,我们将它们作为增广的状态变量扩充至状态方程中,于是得到

$$\dot{\Delta Z} = A_I \cdot \Delta Z + B_I \cdot \Delta U + G \cdot W \quad (5)$$

$$\Delta Y = C_I \cdot \Delta Z + D_I \cdot \Delta U + V \quad (6)$$

公式(5)和(6)两式表示的模型被称为增广状态变量模型(ASVM)。其中

增广状态向量

$$Z \triangleq \begin{bmatrix} PN_1 \\ PN_2 \\ PN_{1b} \\ PN_{2b} \\ Pp_{3b} \\ Pp_{6b} \\ PT_{yb} \end{bmatrix} \quad 7 \times 1$$

输出向量

$$Y \triangleq \begin{bmatrix} PN_1 \\ PN_2 \\ Pp_3 \\ Pp_6 \\ PT_{yb} \end{bmatrix} \quad 5 \times 1$$

控制向量

$$U \triangleq \begin{bmatrix} PW_{fb} \\ PA_8 \end{bmatrix} \quad 2 \times 1$$

2.2 设计卡尔曼滤波器^[5-6]

设系统噪声矩阵 W , 测量噪声矩阵 V 均为不相关的正态分布的零均值白噪声,其协方差阵分别为 Q, R 。

则对噪声环境下的增广系统(5)和(6),卡尔曼滤波器最优状态估计为

$$\begin{aligned} \hat{\Delta Z} &= A_I \cdot \hat{\Delta Z} + B_I \cdot \Delta U + P \cdot C_I^T \cdot \\ &R^{-1} \cdot (\Delta Y - C_I \cdot \hat{\Delta Z} - D_I \cdot \Delta U) \end{aligned} \quad (7)$$

其中 P 为如下 Riccati 方程的解

$$\begin{aligned} A_I \cdot P + P \cdot A_I^T + G \cdot Q \cdot G^T - \\ P \cdot C_I^T \cdot R^{-1} \cdot C_I \cdot P = 0 \end{aligned} \quad (8)$$

令 $K = P \cdot C_I^T \cdot R^{-1}$, 称为滤波增益阵,于是可以得到卡尔曼滤波器的表示式为

$$\begin{aligned} \dot{\hat{\Delta Z}} &= (A_I - K \cdot C_I) \cdot \hat{\Delta Z} + (B_I - K \cdot D_I) \cdot \\ &\Delta U + K \cdot \Delta Y \end{aligned} \quad (9)$$

$$\hat{\Delta Y} = C_I \cdot \hat{\Delta Z} + D_I \cdot \Delta U \quad (10)$$

公式(9)和(10)两式构成了常值增益的卡尔曼滤波器。可以看出,卡尔曼滤波器的设计取决于两方面,一方面是建立足够好的系统模型(SVM),另一方面是确定系统噪声和测量噪声水平,即确定 Q, R 值。系统噪声协方差阵 Q 是模型(SVM)误差的量度,测量噪声协方差阵 R 是发动机传感器测量精度的量度。

2.3 神经网络映射

如上所述,故障诊断是要知道部件性能量蜕化了多少。这些部件性能量的偏离量不能像可测参数偏离量那样通过设计卡尔曼滤波器的方法获得。但从前文可知,通过卡尔曼滤波器获得的可测参数偏离量中包含了发动机的非额定工作信息及故障信息,我们可以充分利用这部分非额定工作信息,通过可测参数偏离量映射出部件性能量的偏离量。并且,我们将卡尔曼滤波器获得的可测参数偏离量来修正部件级模型的输出量,并建立起偏离的实际可测量参数与偏离的实际部件性能量之间的映射关系。

文献[7]中提出可采用线性映射来建立可测参数偏离量和不可测参数偏离量之间的关系。但文献[8]的研究表明,如果采用线性映射,在不同的蜕化程度下,线性映射系数矩阵相差很大,而发动机的实际蜕化程度我们是无法事先知道的,且在使用过程中,蜕化程度也是在不断变化的,因此这种方法有一定的局限性。有一种解决思路是,认为发动机的性能蜕化表现为部件效率的下降,通过可测参数的偏离量来得出部件效率的具体下降量,通过设计部件跟踪滤波器来解决模型和发动机输出间的失配。但是这种方法的计算量大,实时性差,对于机载实时故障诊断显然是不合适的。

考虑到以上两方面,同时考虑到前向神经网络能以任意精度逼近任意连续非线性函数和它突出的泛化能力。最终我们采用神经网络来映射经修正的可测参数偏离量与不可测的蜕化部件性能偏离量之间的关系。

表 1 神经网络输入及输出参数
Table 1 Inputs and outputs of neural networks

输入参数	符号	输出参数	符号
低压转子转速	N_1	低压效率、相似换算流量	$\eta_{\text{L}}, W_{\text{Ax2C}}$
高压转子转速	N_2	高压压气机效率、相似换算流量	$\eta_{\text{CH}}, W_{\text{Ax5C}}$
燃烧室出口总压	p_4	主燃烧室效率	η_{b}
低压涡轮进口总温	T_{45}	高压涡轮效率、相似换算流量	$\eta_{\text{TH}}, W_{\text{G4C}}$
加力燃烧室进口总压	p_7	低压涡轮效率、相似换算流量	$\eta_{\text{TL}}, W_{\text{GyC}}$

本文采用如图 2 所示的三层前向神经网络结构.网络输入为经过修正后的 5 个可测参数,输出为需要诊断的发动机性能参数,输入及输出参数见表 1.经反复调试,中间隐含层采用 30 个神经元.




图 2 神经网络结构示意图
Fig. 2 Neural networks

为了使网络具备映射可测参数和不可测部件性能量之间关系的能力,需要将各种蜕化状态下的发动机可测参数与不可测部件性能量分别作为输入样本和输出样本离线训练神经网络.在本文中,考虑了发动机 5 个部件中单个部件蜕化的情况,并用蜕化部件效率和流通能力的下降来模拟发动机的蜕化,每个蜕化部件的效率和流通能力以 0.5 % 为间隔在 0 %~4 % 之间变化,这样在每个稳态点处进行蜕化,形成 40 个蜕化模型.用部件级模型可计算出每种蜕化模型下的可测参数和部件性能参数(均在地面状态 $H=0, Ma=0$),将他们分别作为输入样本和输出样本来训练神经网络.

网络的学习方法采用 BP 算法.神经网络的精度和泛化能力分别由训练误差和测试误差两个指标来反映.训练误差反映的是网络对于训练集中的样本的映射精度,而测试精度是指经训练后

的神经网络对于未在训练集中出现的样本的映射精度,它反映了网络的泛化能力.如果把学习过程看作一个曲线拟合过程,泛化则相当于非线性内插.网络的训练次数直接影响网络的精度和网络的泛化能力.在网络隐层结点数确定的情况下,存在一个最佳训练次数问题.训练次数过大会出现“过训练”现象,即随着训练次数的增加,训练误差虽然减小,而测试误差反而增大,泛化能力变差.

为有效防止“过训练”,除了训练样本外,还需要测试样本.提取测试样本的方法与提取训练样本的方法相同,但具体蜕化量不同,提取测试样本时使部件的效率和流量以 0.5 % 为间隔在 0.25 %~3.25 % 之间变化,在每个稳态点处形成 35 个蜕化模型.用部件级模型计算出每种蜕化模型的可测参数偏离量与不可测参数偏离量以及性能偏离量,构成测试样本.在训练过程中,每当训练一定次数后,就暂停训练,用测试样本检测其测试误差,当发现测试误差开始上升时,网络达到最佳训练次数,停止训练.

下面给出在稳态点 $A_8=0.2888\text{ m}^2, W_{\text{fb}}=0.616\text{ kg/s}; A_8=0.2888\text{ m}^2, W_{\text{fb}}=0.91\text{ kg/s}$ 和 $A_8=0.2888\text{ m}^2, W_{\text{fb}}=1.204\text{ kg/s}$ 三处的神经网络训练误差(图 3)和测试误差(图 4).其中纵坐标为误差,各符号含义见表 1,横坐标为样本的组数,每幅图均表示了一个部件的两个性能参数的误差.

从图上可以看出,训练误差均在 0.02 % 以内,测试误差在 0.05 % 以内.

3 诊断实例

下面给出一个用上述方法进行发动机气路故障诊断的实例.我们以发动机部件的性能蜕化来模拟发动机故障.先在稳态点 $A_8=0.2888\text{ m}^2$,




图 3 神经网络训练误差图 ($A_8 = 0.288\ 8\ \text{m}^2$, $W_{fb} = 1.204\ \text{kg/s}$)
Fig. 3 Neural networks training ($A_8 = 0.288\ 8\ \text{m}^2$, $W_{fb} = 1.204\ \text{kg/s}$)




图 4 神经网络测试误差图 ($A_8 = 0.288\ 8\ \text{m}^2$, $W_{fb} = 1.204\ \text{kg/s}$)
Fig. 4 Neural networks tests ($A_8 = 0.288\ 8\ \text{m}^2$, $W_{fb} = 1.204\ \text{kg/s}$)

$W_{fb} = 1.204\ \text{kg/s}$ ($H = 0, Ma = 0$) 进行仿真,在 2 s 使故障模型高压压气机的 η_{CH} 和 $W_{A \times 5C}$ 同时下降 2.1 % 来模拟高压压气机发生故障,记录 5 个可测参数的输出.在故障模型的 5 个可测输出中混入测量噪声来模拟传感器测量参数,各测量噪声均为互不相关正态分布白噪声,图 5 给出混入

测量噪声的测量参数.
将带噪声的测量参数通过卡尔曼滤波器,得到滤波后的测量参数,如图 6 所示.
我们只关心故障模型达到新的稳定时的参数,将新稳定点的滤波后的参数通过已经训练好的神经网络映射模块,映射出 9 个性能量,图 7 显





图 5 模拟的传感器测量参数
Fig. 5 Simulated sensor parameters



(—卡尔曼滤波后参数; ·····故障模型的参数)
图 6 卡尔曼滤波后的可测参数
Fig. 6 Mesurable parameters tuned by Kalman filter

示了映射出的 9 个性能量的变化.横坐标自左向右依次为: η_{CL} , W_{Ax2C} , η_{CH} , W_{Ax5C} , η_B , η_{TH} , W_{G4C} , η_{TL} , W_{GyC} , 纵坐标均为相对量.

从图 7 所示的 9 个性能量的变化可见,第 3 和第 4 个性能量明显下降,他们分别是高压压气机的效率和流量,因此,可以判断是高压压气机

发生故障,这与我们前面设定的故障是一致的.

对发动机其他部件的故障可得到同样的故障诊断效果,限于篇幅,不再一一给出仿真结果.要说明的是,在上述工作中,卡尔曼滤波器设计及神经网络的训练均在离线进行,使实时计算的工作量很小,可满足实时性要求.

4 结 论

本文提出了利用卡尔曼滤波器估计发动机可测参数的变化量,再用修正的可测参数通过 BP 神经网络建立起来的可测参数和发动机部件性能参数之间的映射关系映射出性能参数的变化量,通过故障诊断模块进行故障诊断.该故障诊断方法通过实例仿真表明是可行的,可以作为实现发动机实时健康监控、故障诊断的基础.




图 7 神经网络映射的性能量的变化
Fig. 7 Performance parameters outputted by neural networks

参考文献:

- [1] Rajagopalan R, Wood B C, Schryver M. Evolution of propulsion controls and health monitoring at pratt and whitney[R]. Dayton, Ohio: AIAA/ ICAS International Air and Space Symposium and Exposition: The Next 100 Y, 14-17 July 2003, AIAA 2003-2645.
- [2] Sugiyama N. Derivation of ABCD system matrices from nonlinear dynamic simulation of jet engines[R]. AIAA 92-3319.
- [3] 樊思齐, 徐芸, 等. 航空推进系统控制[M]. 西安: 西北工业大学出版社, 1995.
- [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] Kobayashi T, Simon D L. Application of a bank of Kalman filters for aircraft engine fault diagnostics [R]. NASA/ TM-2003-212526.
- [6] Simon D, Simon D L. Aircraft turbofan engine health estimation using constrained Kalman filtering [R]. Atlanta, Georgia, USA: Proceeding of GT '03, 2003 ASME/ IGTI Turbo Expo, June 16-19, 2003.
- [7] 李松林, 孙健国, 李健民. 涡扇发动机机载自适应建模技术研究[J]. 航空动力学报, 1997, 13 (3) : 315-318.
LI Songlin, SUN Jianguo, HUANG Jinquan. An in-flight adaptive model of turbofan[J]. Journal of Aerospace Power, 1997, 13 (3) : 315-318.
- [8] 王信德, 孙健国, 李松林. 神经网络在航空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. Application of neural networks to aeroengine adaptive modeling[J]. Journal of Aerospace Power, 2003, 18 (6) : 845-849.