

文章编号:1000-8055(2011)05-1178-07

涡轴发动机自适应混合诊断模型 高斯加权聚类方法

余云峰, 黄金泉, 鲁 峰

(南京航空航天大学 能源与动力学院, 南京 210016)

摘 要: 针对整个飞行包线内涡轴发动机健康参数估计问题, 提出基于高斯加权聚类的机载自适应混合模型建立方法. 机载自适应混合模型由卡尔曼滤波器和神经网络组成, 由于飞行数据样本庞大, 采用高斯加权模型对涡轴发动机飞行数据进行实时聚类, 利用聚类数据更新神经网络权重, 并实现自适应混合模型工作范围的自动扩展. 仿真结果表明了该方法的有效性, 采用高斯加权聚类的自适应混合模型提高了全包线内性能跟踪的精度.

关 键 词: 涡轴发动机; 高斯加权模型; 机载自适应混合模型; 性能参数估计; 卡尔曼滤波; 神经网络
中图分类号: V233.7 **文献标志码:** A

Gaussian weighted sum clustering method of adaptive hybrid diagnostic model for turbo-shaft engine

SHE Yun-feng, HUANG Jin-quan, LU Feng

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

Abstract: A Gaussian weighted sum clustering method of on-board adaptive hybrid model was proposed for health parameter estimation of turbo-shaft engine in the full flight envelope. The on-board adaptive hybrid model was composed of Kalman filter and neural network. Gaussian weighted sum model was used to cluster a huge amount of flight data in real-time and update the neural network weighting. The working range of adaptive hybrid model was increased automatically with this method. The simulation results show the validity of the proposed method. Adaptive hybrid model based on Gaussian weighted sum clustering increases the accuracy for turbo-shaft engine performance tracking in the full flight envelope.

Key words: turbo-shaft engine; Gaussian weighted sum model;
on-board adaptive hybrid model; performance parameter estimation;
Kalman filter; neural network

涡轴发动机工作条件十分恶劣, 通常工作在近地面、近海面高度, 这样往往会吸入大量的沙尘和含盐的海水蒸汽, 发动机部件经常受到污垢的腐蚀. 随着使用时间增加, 发动机将会发

生性能蜕化或者故障. 为了保证发动机能够安全高效地完成任务, 视情维修成为发展趋势, 因此, 对涡轴发动机性能蜕化或者故障现象的识别非常重要. 由于发动机性能蜕化或者故障现

收稿日期: 2010-04-26; 修订日期: 2010-07-04

作者简介: 余云峰(1986-), 男, 江苏南通人, 硕士生, 主要从事航空发动机控制与故障诊断方面的研究.

象经常反应在部件的效率和流量的变化量上,因此,发动机气路分析是常见且有效的方法,部件的效率和流量的变化量也称为发动机的性能健康参数.对健康参数的估计通常在发动机进入准稳态情况下进行.

传统的气路故障分析法始于1972年Urban提出的故障影响系数矩阵.随着30多年的不断发展,气路分析法已成为发动机故障诊断的重要方法,如模糊逻辑^[1]、人工神经网络^[2]、贝叶斯网络^[3]、遗传算法^[4]、数据融合^[5]以及基于物理模型的方法^[6-7].其中基于物理模型的故障诊断方法由于其能够深入系统本质的动态性质和实时诊断的能力,因此该方法已在F119和F135发动机工程研究中得到应用.

利用卡尔曼滤波器模型来估计发动机性能参数的方法在很多文献中已经提到,但其估计精度受模型误差影响很大^[8-11].为此,提出了由加入经验模型的神经网络模型与基于物理模型的卡尔曼滤波器一起构成混合模型的方法,通过神经网络消除建模误差,从而提高卡尔曼滤波器的估计精度^[12].传统的方法是将包线中的飞行数据全部采集后进行神经网络离线训练,但此方法需要专门的飞行试验,数据量庞大,容易引起神经网络训练饱和现象.

本文在混合模型中采用高斯加权聚类方法对飞行数据进行实时数据聚类,并利用新增的聚类数据有针对性地训练神经网络,从而实现自适应混合模型在全包线中的性能估计.

1 自适应混合模型的建立

自适应混合模型由基于物理模型的卡尔曼滤波器与基于经验模型的神经网络模型构成.其结构如图1所示.

在发动机准稳态工况下,混合模型工作在如下两个模式.

1) 训练模式.将发动机控制量 u 转换为相似参数 u_c 输入到状态变量模型,其输出 y_s 与发动机相似转换输出 y_c 比较得到误差 $r = y_c - y_s$,将 u_c 作为神经网络训练输入, r 作为输出,训练神经网络,得到映射关系 $r = f(u_c)$.

2) 估计模式.采用训练好的神经网络对发动机状态变量模型进行修正,采用卡尔曼滤波器对健康参数进行估计.

卡尔曼滤波器增广状态变量方程为




图1 混合模型结构

Fig. 1 Structure of hybrid model

$$\begin{bmatrix} \Delta \dot{x} \\ \Delta \dot{\eta} \end{bmatrix} = \begin{bmatrix} A & L \\ 0 & 0 \end{bmatrix} \begin{bmatrix} \Delta x \\ \Delta \eta \end{bmatrix} + \begin{bmatrix} B \\ 0 \end{bmatrix} \Delta u + \omega$$

$$\Delta y = \begin{bmatrix} C & M \end{bmatrix} \begin{bmatrix} \Delta x \\ \Delta \eta \end{bmatrix} + D \Delta u + v \quad (1)$$

式中 $\Delta \eta = [\Delta \eta_c \quad \Delta W_c \quad \Delta \eta_g \quad \Delta W_g \quad \Delta \eta_p]^T$, 分别为压气机效率和流量,燃气涡轮效率和流量和动力涡轮效率的蜕化量. $\Delta x = [\Delta n_g \quad \Delta n_p]^T$, $\Delta y = [\Delta n_g \quad \Delta n_p \quad \Delta T_3 \quad \Delta p_3 \quad \Delta T_{45}]^T$,分别为燃气涡轮转速、动力涡轮转速、压气机出口温度、压气机出口压力和动力涡轮进口温度对基准点的偏差量,这些测量数据均经过标准大气换算和归一化. A, B, C, D, L, M 均是常值矩阵, ω 和 v 分别为系统噪声和测量噪声.

飞行包线内状态变量模型系数矩阵以及卡尔曼滤波增益采用分段计算方法,选取基准工作点建立标准大气状况下的状态变量模型、计算卡尔曼滤波增益.对其他工作点,利用动力涡轮转速 n_p 和总距角 α 作为索引插值得到.

为了提高训练精度,采用一组5个神经网络(图2).输入层节点为高度 H 、马赫数 Ma 和总距角 α ,每个神经网络有20个隐含节点.神经网络采用Levenberg-Marquardt法训练.




图2 神经网络结构图

Fig. 2 Structure of neural network

由于输入节点相对较少,为防止一组神经网络无法完成全包线中所有数据的映射,本文以马赫数为0.1、高度为1000 m的间隔将飞行包线划分成12个子区域,每个区域的中心为该区域的基准点,这些基准点可以用来判断当前飞行子区域。在每个子区域内建立一组神经网络子模块(5个),因此整个飞行包线共需要12组神经网络子模块(共60个神经网络),这12组神经网络子模块共同组成一个神经网络数据库。这种区域划分方法可以根据需要针对性地对飞行数据所在区域进行相应神经网络子模块训练,而不需要将全包线区域中神经网络全部训练,提高了神经网络训练的效率。

2 高斯加权聚类方法

对于神经网络模型而言,传统的方法是将包线中的飞行数据全部采集、记录后进行离线训练。由于一、两次飞行无法得到全包线所有数据,而且飞行数据过于庞大,神经网络训练极为耗时,容易引起神经网络训练饱和现象。事实上在飞行过程中,准稳态的飞行数据在一段时间内一般都趋于相同,这些数据具有可压缩性。因此本文采用如下

方法:在每次飞行过程中,如果工作区域的神经网络已得到训练,则进入估计模式,利用自适应混合模型在线实时估计性能健康参数。否则,采用高斯加权聚类对数据进行压缩。飞行结束后,将聚类后的特征数据增加到神经网络训练样本集中,待飞行结束后进行离线神经网络更新。这样,在下次飞行过程中,参数估计的工作区域不断增多。当发动机在某些工作区域估计出健康参数有蜕化,在新的工作区域聚类时,需要将训练样本中的蜕化信息进行分离,得到无蜕化的神经网络训练样本。

2.1 高斯加权聚类

设 n 个观测时刻样本集合为

$$\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$$

$$\mathbf{x}_i = [\mathbf{u}_i^T, \mathbf{r}_i^T]^T, \quad i = 1, 2, \dots, n$$

其中

$$\mathbf{u}_i = [\mathbf{u}_i(1), \mathbf{u}_i(2), \mathbf{u}_i(3)]^T = [H, Ma, \alpha]^T$$

$$\mathbf{r}_i = [\mathbf{r}_i(1), \mathbf{r}_i(2), \dots, \mathbf{r}_i(5)]^T$$

$\mathbf{r}_i$ 为第1节中5个测量参数误差,一个具有 K 阶的高斯加权模型由 K 个高斯分量的加权和来表示

$$P(\mathbf{x}) = \sum_{k=1}^K w_k g_k(\mathbf{x}; \bar{\mathbf{x}}_k, \boldsymbol{\Sigma}_k) \quad (2)$$

式中 w_k 是第 k 个高斯分布的权重, $\sum_{k=1}^K w_k = 1$, $\bar{\mathbf{x}}_k = [\bar{\mathbf{u}}_k, \bar{\mathbf{r}}_k]^T$, $\boldsymbol{\Sigma}_k = [\boldsymbol{\Sigma}_k^{(u)}, \boldsymbol{\Sigma}_k^{(r)}]^T$ 分别是第 k 个高斯分布的均值向量和协方差矩阵, g_k 是第 k 个高斯分布的概率密度函数

$$g_k(\mathbf{x}_i; \bar{\mathbf{x}}_k, \boldsymbol{\Sigma}_k) = \frac{1}{\sqrt{(2\pi)^d |\boldsymbol{\Sigma}_k|}} \cdot \exp\left[-\frac{1}{2}(\mathbf{x}_i - \bar{\mathbf{x}}_k)^T \boldsymbol{\Sigma}_k^{-1} (\mathbf{x}_i - \bar{\mathbf{x}}_k)\right] \quad (3)$$

由式(3)可以看出,只要算出一个类中的均值向量和协方差矩阵即可表示该类。为了节约存储空间和简化计算,本文将协方差矩阵 $\boldsymbol{\Sigma}_k$ 简化成对角阵,均值和标准差计算公式为

$$\bar{\mathbf{u}}_{k,i}(j) = \frac{i-1}{i} \bar{\mathbf{u}}_{k,i-1}(j) + \frac{1}{i} \mathbf{u}_{k,i}(j)$$

$$\sigma_{k,i}^{(u)}(j) = \sqrt{\frac{i-2}{i-1} [\sigma_{k,i-1}^{(u)}(j)]^2 + [\bar{\mathbf{u}}_{k,i-1}(j)]^2 - \frac{i}{i-1} [\bar{\mathbf{u}}_{k,i}(j)]^2 + \frac{1}{i-1} [\mathbf{u}_{k,i}(j)]^2}$$

$$\forall j = 1, 2, 3 \quad (4)$$

$$\bar{\mathbf{r}}_{k,i}(j) = \frac{i-1}{i} \bar{\mathbf{r}}_{k,i-1}(j) + \frac{1}{i} \mathbf{r}_{k,i}(j)$$

$$\sigma_{k,i}^{(r)}(j) = \sqrt{\frac{i-2}{i-1} [\sigma_{k,i-1}^{(r)}(j)]^2 + [\bar{\mathbf{r}}_{k,i-1}(j)]^2 - \frac{i}{i-1} [\bar{\mathbf{r}}_{k,i}(j)]^2 + \frac{1}{i-1} [\mathbf{r}_{k,i}(j)]^2}$$

$$\forall j = 1, 2, \dots, 5 \quad (5)$$

式中 $\bar{\mathbf{u}}_{k,i}(j)$ 和 $\sigma_{k,i}^{(u)}(j)$ 分别表示第 k 个类中采集到 i 个数据后第 j 个输入均值和标准差, $\bar{\mathbf{r}}_{k,i}(j)$ 和 $\sigma_{k,i}^{(r)}(j)$ 分别表示相应输出误差的均值和标准差。

在聚类过程中,需要确定一个聚类数据的最小个数 $i_{\min}$, 当聚类的数据 $i = i_{\min}$ 时,可以认为一个高斯分布(第 k 个)产生,此时迭代出的输入均值向量和标准差向量(初始均值向量和标准差向量,记作 $\mathbf{u}_{k,0}, \sigma_{k,0}$) 保存在临时数据库中,后面采集的数据 $\mathbf{u}_i (i > i_{\min})$ 与此数据进行比较,判断出新采集的点 $\mathbf{u}_i$ 是否处于该类中,判断依据为

$$|\mathbf{u}_i(j) - \mathbf{u}_{k,0}(j)| \leq a(j) \sigma_{k,0}(j) \quad \forall j = 1, 2, 3 \quad (6)$$

式中 $a(j)$ 表示第 j 个输入参数的阈值系数. 如果飞行数据满足不等式(6),则认为该数据属于此类,利用式(4)和式(5)继续更新该类的均值向量和标准差向量;如果不满足不等式(6),则当前聚类结束,将此时的输入均值向量与标准差向量($\bar{\mathbf{u}}_k, \sigma_k^{(u)}$)、输出误差的均值向量($\bar{\mathbf{r}}_k$)以及聚类样本数据数目 i_k 存入临时数据库中,开始一个新类创建,高斯加权模型增加一阶。

2.2 高斯加权聚类的自适应混合模型建立流程

1) 初始化参数,加载健康参数估计结果,加载神经网络数据库,将飞行区域初始设置为上次飞行后区域,加载该区域内的神经网络模块。

2) 采集飞行数据,进行相似折算和归一化,判断是否进入准稳态. 如果进入准稳态,利用当前高度、马赫数确定发动机的工作区域,这里通过计

算采集数据点与区域基准点之间的欧式距离来判断

$$R = \arg \min_{i=1,2,\dots,N_c} \{\sqrt{(H_i - H)^2 + (Ma_i - Ma)^2}\} \quad (7)$$

式中 N_c 是飞行区域的存储点数目, $N_c = 12$ 。

3) 如果工作区域发生变化,则从神经网络数据库中加载相应区域的神经网络模块,判断当前采集的飞行数据点是否已经通过神经网络建模。

4) 如果此点已经通过神经网络建模,则进行卡尔曼滤波器估计. 判断一个点是否已经通过神经建模的依据为

$$|\mathbf{u}_i(j) - \bar{\mathbf{u}}_l(j)| \leq a(j) \sigma_l(j) \quad \forall l = 1, 2, \dots, n \quad j = 1, 2, 3 \quad (8)$$

式中 n 是当前飞行区域内神经网络模块中训练样本的个数. 如果当前飞行点不满足式(8),关闭卡尔曼滤波器功能,估计结果作为状态变量模型输入,进行高斯混合模型聚类. 在飞行阶段,重复2),3),4)步骤。

5) 飞行结束后,遍历临时数据库,根据式(6)可知,一个聚类很容易被一个驻点所干扰而结束,因此很有可能同一个工作状态下得到了多个相似的类,因此需要处理重复类. 如果第 m 个类与第 n 个类满足

$$|\bar{\mathbf{u}}_m(j) - \bar{\mathbf{u}}_n(j)| \leq \min\{\sigma_m^{(u)}(j), \sigma_n^{(u)}(j)\} \quad \forall j = 1, 2, 3 \quad (9)$$

则可以合并成同一个类 mn , 且有

$$\bar{\mathbf{u}}_{mn} = \frac{\bar{\mathbf{u}}_m i_m + \bar{\mathbf{u}}_n i_n}{i_m + i_n}, \quad i_{mn} = i_m + i_n$$

$$\sigma_{mn} = \sqrt{\frac{1}{i_{mn}-1}[(i_m-1)\sigma_m^2 + i_m \bar{\mathbf{u}}_m^2 + (i_n-1)\sigma_n^2 + i_n \bar{\mathbf{u}}_n^2] - \frac{i_{mn}}{i_{mn}-1} \bar{\mathbf{u}}_{mn}^2} \quad (10)$$

重复类合并结束后,将这些类的特征数据增加到对应区域的神经网络训练样本中,利用输入数据的聚类均值作为神经网络样本输入,输出误差的聚类均值作为神经网络样本输出更新该区域的神经网络模块。

6) 经过更新后的神经网络模块添加到神经网络数据库中。

3 仿真结果

为了验证数据聚类能力以及基于自适应混合模型对性能健康参数估计效果,本文利用涡轴发

动机非线性模型模拟准稳态飞行状态进行仿真。

3.1 未蜕化情况仿真

图3~图5分别是高度、马赫数和总矩角随时间变化曲线. 图6是未加神经网络模块时健康参数估计结果. 由图6可以看出,在发动机没有发生蜕化时,由于状态变量模型与真实发动机的输出存在建模误差,使得估计参数产生较大偏差,产生误报。

采用高斯加权模型对这些数据进行聚类,本文选取 $i_{\min} = 200$; $\mathbf{a} = [3, 3, 3]$ 飞行结束后,临时数据库中飞行子区域1内94个类,子区域7内




图3 第一次飞行高度随时间变化曲线

Fig. 3 Variation curve of altitude with time in the first flight




图4 第一次飞行马赫数随时间变化曲线

Fig. 4 Variation curve of Mach number with time in the first flight




图5 第一次飞行总距角随时间变化曲线

Fig. 5 Variation curve of torque angle with time in the first flight

3个类,经过重复类合并后区域1内57个类,区域7内2个类,图7是子区域1内57个类的高度与马赫数分布情况。

待飞行结束后,将增加的数据进行神经网络训练,这里采集的数据均属于飞行子区域1和7内,因此利用类统计数据进行了子区域1和7内的神经网络子模块训练(不需要训练其他区域内




图6 卡尔曼滤波器估计结果(无神经网络)

Fig. 6 Kalman filter (KF)'s estimation without neural network




图7 第一次飞行数据聚类

Fig. 7 Clusters in the first flight

的神经网络,从而可以减少计算量)。待神经网络训练完成后让发动机在同样的工作状态下运行,图8是加入神经网络模块后卡尔曼滤波器估计结果。由此可以看出,通过聚类飞行数据得到了有效的压缩,(压缩前、后数据点个数分别为29534,59),利用压缩数据进行神经网络训练后同样能够大大提高卡尔曼滤波估计精度。




图8 卡尔曼滤波器估计结果(加神经网络补偿)

Fig. 8 KF's estimation with neural network

3.2 蜕化情况仿真

假设发动机在上面的工作状态下压气机效率下降 5%, 同时增加新的飞行数据. 图 9~图 10 分别显示了第二次飞行中总矩角随时间的变化以及高度与马赫数分布图. 为了便于说明, 在图 10 中将飞行数据按时间顺序用号码标记: ① 0~170 s; ② 170~335 s; ③ 335~425 s; ④ 425~500 s; ⑤ 500~650 s 分别代表不同的阶段, 每个阶段在图 10 中近似于一条直线. ①, ②, ⑤ 阶段的数据已经在上一次飞行中完成了神经网络建模任务, 因此发动机工作在上述状态时进入估计模式, 卡尔曼滤波器在这些点进行估计, 不同的是②和⑤阶段压气机效率发生 5% 蜕化. ③和④阶段的工作状态由于还没有神经网络建模, 此时进入聚类模式, 健康参数保持为②阶段时的估计结果不变, 将其作为状态变量模型输入, 同时开始实时高斯聚类. 飞行结束后, 临时数据库中飞行子区域 1 中新增 21 个类, 经过重复类合并后得到 15 个类, 图 11 显示了这 15 个新增的类.




图 9 第二次飞行总矩角随时间变化曲线

Fig. 9 Variation curve of torque angle with time in the second flight




图 10 第二次飞行高度与马赫数分布图

Fig. 10 Flight data points of altitude and Mach number in the second flight




图 11 第二次飞行的新增聚类

Fig. 11 New-added clusters in the second flight

一旦飞行结束后, 飞行子区域 1 内的神经网络子模块训练样本将加上此次新增聚类特征数据 (共 72 个中心样本) 重新训练, 更新该区域内的神经网络. 完成神经网络训练后, 这些工作状态在以后的飞行中就可以通过卡尔曼滤波器加上神经网络补偿模块估计出来. 图 12 是在完成神经网络建模后重复第二次飞行工作状态下的卡尔曼滤波器估计效果.




图 12 压气机效率下降 5% 时卡尔曼滤波器估计

Fig. 12 KF's estimation with 5% degraded in compressor efficiency

4 结 论

本文在卡尔曼滤波器与神经网络所组成的自适应混合模型基础上, 采用高斯加权聚类方法对飞行包线中未经神经网络建模的飞行点进行实时机载聚类, 在聚类过程中, 保持卡尔曼滤波器的健康参数估计结果不变, 排除发动机蜕化因素对输出误差的影响. 待到飞行结束后, 将聚类的特征数据增加到神经网络数据样本中重新训练更新得到新的神经网络数据库. 经过更新后的神经网络模型使得卡尔曼滤波器工作范围不断扩展. 随着飞行次数和飞行工况的不断增加, 可实现自适应混

合模型在整个包线中对发动机健康情况进行实时诊断的目标. 这种方法不需要专门的飞行试验, 经过压缩后的数据以及区域划分均提高了神经网络训练效率, 具有很强的实用价值.

参考文献:

- [1] Ganguli R. Application of fuzzy logic for fault isolation of jet engines[R]. ASME 2001-GT-13, 2001.
- [2] 赵世荣, 黄向华. 应用神经网络信息融合诊断航空发动机故障[J]. 航空动力学报, 2008, 23(1): 163-168.
ZHAO Shirong, HUANG Xianghua. Fault diagnosis for aeroengine gas path components based on neural network multisensor data fusion[J]. Journal of Aerospace Power, 2008, 23(1): 163-168. (in Chinese)
- [3] Jensen F V. Bayesian networks and decision graphs[M]. New York: Springer-Verlag, 2001.
- [4] 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 Power, 2009, 24(4): 880-885. (in Chinese)
- [5] 鲁峰, 黄金泉. 航空发动机部件性能故障融合诊断方法研究[J]. 航空动力学报, 2009, 24(7): 1649-1653.
LU Feng, HUANG Jinquan. Research on performance fault fusion diagnosis of aero-engine component[J]. Journal of Aerospace Power, 2009, 24(7): 1649-1653. (in Chinese)
- [6] Volponi A J, Brotherton T. A bootstrap data methodology is for sequential hybrid engine model building[R]. Big Sky, MT: IEEE Aerospace Conference Proceedings, 2005.
- [7] Volponi A J. Enhanced self tuning on-board real-time model (eSTORM) for aircraft engine performance health tracking[R]. NASA/CR-2008-215272, 2008.
- [8] Luppold R, Brotherton T, Volponi A. Adaptive on-wing gas turbine engine performance estimation[R]. Big Sky, MT: IEEE Aerospace Conference Proceeding, 2007.
- [9] Frith P, Karvounis G. Model-based decision support tools for T700 engine health monitoring[R]. Melbourne, Australia: DSTO International Conference on Health and Usage Monitoring, 2001.
- [10] Litt J S, Simon D L. Toward a real-time measurement-based system for estimation of helicopter engine degradation due to compressor erosion [R]. NASA/TM-2007-214843, 2007.
- [11] Volponi A J, De Pold 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 Turbine and Power, 2003, 125(10): 917-924.
- [12] 黄伟斌, 黄金泉. 航空发动机故障诊断的机载自适应模型[J]. 航空动力学报, 2008, 23(3): 581-584.
HUANG Weibin, HUANG Jinquan. On board self-tuning model for aero-engine fault diagnostics[J]. Journal of Aerospace Power, 2008, 23(3): 581-584. (in Chinese)