

文章编号: 1000-8055(2009)07-1649-05

航空发动机部件性能故障融合诊断方法研究

鲁 峰¹, 黄金泉¹, 陈 煜^{1,2}

(1. 南京航空航天大学 能源与动力学院, 南京 210016;

2. 贵州黎阳航空发动机公司, 贵阳 561102)

摘 要: 提出一种对航空发动机部件性能蜕化进行融合诊断的模糊决策融合机制, 以改善单独采用基于模型和基于数据的部件性能故障诊断的漏诊与误诊的问题. 传感器测量值同时输入到基于自适应模型的和基于数据的诊断模块中, 分别利用卡尔曼滤波算法和最小二乘支持向量机 (LSSVM) 对主要部件故障性能参数估计, 再利用模糊逻辑调整决策权重以进行 D-S (Dempster Shafer) 证据理论的决策融合诊断. 以某型涡扇发动机为对象进行单部件和双部件蜕化仿真研究表明, 与单独使用基于模型和基于数据的诊断方法相比, 采用决策融合机制有效地提高了部件故障诊断精度.

关 键 词: 航空发动机; 融合诊断; 自适应模型; 最小二乘支持向量机 (LSSVM); 模糊逻辑; D-S (Dempster Shafer) 证据理论

中图分类号: V233.7

文献标识码: A

Research on performance fault fusion diagnosis of aero-engine component

LU Feng¹, HUANG Jinqun¹, CHEN Yu^{1,2}

(1. College of Energy and Power Engineering,

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

2. Guizhou Liyang Aero Engine Corporation, Guiyang 561102, China)

Abstract: A method of engine component fault diagnosis based on fuzzy decision fusion was proposed to improve the accuracy of component fault diagnosis, and reduce the probability of false alarming and missing detection. By using Kalman filter algorithm and least square support vector machine (LSSVM), the sensor outputs were both sent to two different modules — self-tuning model and data-based diagnostic module — to estimate the health parameters. Fuzzy algorithm was operated to adjust the weights of two modules, and then the fault fusion decision was made by D-S (Dempster-Shafer) theory. Simulation on a turbofan engine shows that, as compared to these two modules, this method has better accuracy of fault diagnosis.

Key words: aero-engine; fusion diagnosis; self-tuning model; least square support vector machine (LSSVM); fuzzy logic; D-S (Dempster Shafer) theory

航空发动机结构复杂, 工作环境恶劣, 装配的传感器数量有限, 根据有限的传感器测量信息诊断发动机部件性能是研究的难点^[1]. 近年来, 发动

机健康管理系统 (EHM) 成为当前研究的热点^[2], 在 EHM 系统中进行部件故障诊断主要采用以下三种方法: 基于物理模型的方法^[3] (如卡尔曼滤波

收稿日期: 2008-06-30; 修订日期: 2008-12-16

作者简介: 鲁峰 (1981-), 男, 浙江长兴人, 博士生, 主要从事航空发动机故障诊断融合方法的研究.

算法)、基于数据的方法^[4-5] (如人工神经网络、模糊逻辑、粗糙集和决策树等) 和基于知识的方法. 基于模型的方法需要有具体发动机型号的准确部件特性. 物理模型的精度决定了诊断的准确度, 然而由于发动机安装制造公差及建模误差使得基于模型的故障诊断产生误诊和漏诊; 基于数据的方法以发动机测量数据作为部件故障诊断的依据, 最小二乘支持向量机(LSSVM) 是一种基于数据的方法并逐步应用于故障诊断中^[6], 它以结构风险最小化作为优化目标, 利用有限的小样本实现目标方程全局最优, 但测量噪声和各种智能算法的缺陷都会对诊断精度影响很大; 基于知识的方法则过于依据以往的专家经验以及各种先验知识, 针对各种具体的工作状况及新类型故障不能作出准确诊断.

目前, 出现了以各种智能算法为基础进行信息融合^[7], 这些智能融合算法主要集中在以基于数据的方法进行诊断的基础上提出的, 如各种不同类型的神经网络之间的融合^[8], 神经网络与模糊算法的融合^[9], 以及粗糙集与神经网络融合等, 这类融合能在一定程度上解决单一智能算法存在的缺陷, 但是没有考虑到不同发动机的物理特性, 片面的从数据出发, 一旦发动机的部件特性发生轻微变化或出现新的故障类型时, 都会严重影响部件的诊断精度^[10].

本文提出的自调整信息和决策融合算法将以机载自适应模型的卡尔曼滤波估计算法与 LSSVM 估计得到的两个部件健康状况证据体信息结合起来, 通过对性能参数的模糊化处理自动调整已有的各个特征参数的概率权重, 再利用 D-S (Dempster Shafer) 证据理论对两个诊断子系统的决策进行融合, 获得发动机故障综合诊断结果. 该方法使两种算法取长补短, 有效地提高部件性能的故障诊断精度, 避免了单独使用两种算法的各自缺陷, 通过对各个部件不同程度的单故障、多故障仿真实验, 验证了该方法的有效性.

1 故障决策融合诊断机制

涡扇发动机的风扇、压气机、高压涡轮和低压涡轮部件属于故障多发部件, 发动机部件故障导致发动机工作参数偏离正常值, 引起发动机性能下降; 另外, 随着使用时间增加, 部件磨损、气流通道变形、脏污以及调节机构参数的误差增大, 发动机性能蜕化导致工作参数也会逐渐偏离正常值. 因此, 可根据发动机工作状态参数的变化情况, 确

定发动机的部件故障状况, 将部件故障模式分为无故障、异常警告和故障三类. 测量参数随发动机实际情况而异, 本文选取 8 个传感器作为故障诊断系统的输入量: 风扇转速 N_1 , 压气机转速 N_h , 风扇出口总压 p_{22} , 总温 T_{22} , 压气机出口总压 p_3 , 总温 T_3 , 低压涡轮出口总压 p_6 , 总温 T_6 .

航空发动机部件故障决策融合诊断系统如图 1 所示, 由基于模型的诊断模块、基于 LSSVM 的诊断模块、性能特征模糊化模块和 D-S 证据融合决策模块 4 个模块组成. 以传感器测量参数作为故障决策融合诊断系统的输入量, 同时输入至机载自适应模型和 LSSVM 数据挖掘诊断子系统中, 以核心部件的效率蜕化量作为性能参数 $\Delta\eta=[\Delta\eta_{h1}, \Delta\eta_{h2}, \Delta\eta_{h3}, \Delta\eta_{h4}]$, 分别采用卡尔曼滤波算法和 LSSVM 的回归算法估计出各部件的性能参数 $\Delta\eta_1$ 和 $\Delta\eta_2$. 在部件特性模糊化模块中同时对两个子系统的性能参数进行模糊化处理, 将连续的部件性能参数转化成离散的故障模式指示值并得到相应的基本概率函数. 利用 D-S 证据融合决策模块融合基于模型和基于数据两个证据体的信息, 以在整个蜕化空间得到发动机部件故障模式.




图 1 基于平方根 UKF 的发动机气路部件故障诊断系统

Fig. 1 Aero engine gas path component diagnostics system

2 故障诊断系统算法

在输入指令与进口条件确定的情况下, 部件健康参数是影响发动机输出的主要因素, 因此, 发动机气路部件故障诊断问题可以转化为部件健康参数的非线性辨识估计问题. 设计健康参数平方根 UKF 滤波估计算法如下:

- 1) 基于机载自适应模型的性能参数估计
- 机载自适应模型是从发动机部件级模型中通过小扰动法得到的线化模型, 在机载线化模型中将部件的性能参数扩展至状态变量中, 运用卡尔曼滤波算法可以对部件性能参数 $\Delta\eta_0$ 实时估计^[11-12]. 机载自适应模型的表达式如下:

$$\begin{aligned}\dot{\Delta \mathbf{x}} &= \mathbf{A} \Delta \mathbf{x} + \mathbf{B} \Delta \mathbf{u} + \mathbf{L} \Delta \eta_1 \\ \Delta \mathbf{y} &= \mathbf{C} \Delta \mathbf{x} + \mathbf{D} \Delta \mathbf{u} + \mathbf{M} \Delta \eta_1\end{aligned}\tag{1}$$

扩展状态变量的机载自适应模型的卡尔曼滤波估计方程如下:

$$\begin{aligned}\dot{\Delta \hat{\mathbf{x}}} &= \begin{bmatrix} \mathbf{A} & \mathbf{L} \\ \mathbf{0} & \mathbf{0} \end{bmatrix} \Delta \hat{\mathbf{x}} + \begin{bmatrix} \mathbf{B} \\ \mathbf{0} \end{bmatrix} \Delta \mathbf{u} + \\ &\mathbf{K}[\Delta \mathbf{y} - [\mathbf{C} \ \mathbf{M}] \Delta \hat{\mathbf{x}}] \\ \Delta \hat{\mathbf{y}} &= [\mathbf{C} \ \mathbf{M}] \Delta \hat{\mathbf{x}} + \mathbf{D} \Delta \mathbf{u}\end{aligned}\tag{2}$$

式中机载自适应模型输入量 $\mathbf{u} = [WFB, A8]^T$, 输出量 $\mathbf{y} = [N_1, N_h, p_{22}, T_{22}, p_3, T_3, p_6, T_6]^T$, 扩展的状态量 $\mathbf{x} = [N_1, N_h, \eta_{nl}, \eta_{nh}, \eta_{hl}, \eta_h]^T$, $\Delta \mathbf{u} = \mathbf{u} - \mathbf{u}_b$, $\Delta \mathbf{y} = \mathbf{y} - \mathbf{y}_b$, $\Delta \mathbf{x} = \mathbf{x} - \mathbf{x}_b$, 分别表示相对于发动机稳态工作点的输入增量、输出增量和状态增量。

2) 基于 LSSVM 的性能参数估计

LSSVM 性能评估模型的基本思想是通过一个非线性映射 ϕ 将数据 y_j 映射到高维的特征空间, 并在该空间进行回归估计。本文利用 LSSVM 回归算法, 根据发动机传感器测量参数, 对发动机出现的性能蜕化量进行辨识, 以评估各个部件的性能蜕化量及失效程度。给定 l 个样本数据 $\{y_1, \Delta \eta_{b1}, \dots, y_l, \Delta \eta_{bl}\}$, 其中 y_j 为部件正常和不同蜕化程度下的 8 个传感器测量值, $\Delta \eta_{bj}$ 为相应的 4 个部件蜕化量。8 输入 4 输出的 LSSVM 估计模型如下:

$$\Delta \eta_b(\mathbf{y}) = \sum_{j=1}^l \alpha_j K(\mathbf{y}, \mathbf{y}_j) + \mathbf{b}\tag{3}$$

式中 $\alpha_j, \mathbf{b}$ 表示回归因子, $K(\cdot, \cdot)$ 称为核函数, 它是对称的正实数函数, 本文选用高斯核函数 $K(\mathbf{y}, \mathbf{y}_j) = \exp\left\{-\frac{\|\mathbf{y} - \mathbf{y}_j\|^2}{\sigma^2}\right\}$ 。训练时, LSSVM 的输入为发动机在每个部件整个的蜕化范围内若干典型点的传感器测量信号, 输出为相应的性能量。在性能评估时, LSSVM 的输出即为各个部件的性能估计量。


3) 部件特征模糊化

将每个部件分为无故障、故障警告和故障三类故障等级, 因此针对风扇、压气机、高压涡轮和低压涡轮 4 个核心部件共有 8 种单故障模式和 24 种双故障模式。定义故障等级空间 $\{0, 1, 2\}$, 其中, 0 代表无故障, 1 代表警告, 2 代表故障, 如压气机发出故障警告, 则相应的故障模式为 $q = [0, 1, 0, 0]$ 。从连续的性能蜕化空间提取特征信息, 将其转换至离散的部件故障模式空间, 最简单的特征提取的实现方法是直接根据专家知识和经验来


确定, 但该方法过度依赖专家经验。部件特征模糊化模块就是通过对部件性能参数进行模糊化处理, 直接将连续的性能蜕化参数转化为部件故障程度及其相应的概率函数, 其关键是选择一个合适的特征概率函数。该函数主要由蜕化参数的工作特性而定, 飞行小时数的增加决定了部件性能蜕化, 并且蜕化速度也变得越来越快, 蜕化量越大部件相对来说出现故障的可能性就会变大。选取高斯分布函数作为转换概率函数, 则 j 部件属于故障模式 k 的概率函数如下:

$$p_k(j) = \exp\{-[1 - \Delta \eta(j)] - \mu_k\}^2 / 2\sigma_k^2\}\tag{4}$$

式中 μ_k, σ_k 分别为故障模式 k 下的均值和方差。根据某型涡扇发动机允许蜕化范围实际宽度, 以 1% 和 5% 为故障程度的平稳过渡点, 部件在无故障、警告、故障三种故障模式下的性能蜕化区间分别为 $[0, 1\%), [1\%, 5\%), [5\%, +\infty)$, 所以选取三种故障程度的均值分别为 0, 0.03 和 0.06, 相应的故障方差分别为 0.5, 1 和 0.5。因此, 发动机部件性能参数模糊转换如图 2 所示。



(a) 部件性能蜕化趋势图



(b) 性能参数模糊化

图 2 发动机部件性能参数模糊化示意图
Figure.2 Component health parameter processed by fuzzy algorithm

4) D-S 决策融合

使用 D-S 决策融合机制对经过部件特征模糊化处理的两个子系统证据体的诊断结果进行融合. D-S 证据理论融合是为了同时利用来自相互独立的两个不同信息源的两组或多组子证据体, 提高对事件的置信程度而提出的一种对信息组合法则. D-S 证据理论推理规则: 先计算各个证据体的基本概率赋值函数, 然后采用 D-S 合成规则计算所有证据体作用下的联合基本概率赋值函数, 最后根据一定的决策规则, 选择联合作用下支持最大的假设. 设 Ω 为所有可能的故障模式的集合, $\Omega = \{q | q = [a_1, a_2, a_3, a_4], a_i = 0, 1, 2\}$, a_i 分别表示 4 个核心部件, 其不同的取值表示该部件不同的故障模式, 本文根据发动机实际可能的故障类型设定 4 个部件不同故障程度的单、双两种故障形式以及无故障模式总共 33 个故障模式. 对任意一个属于 Ω 的命题 q , 对应一个数 $m_i \in [0, 1]$, 且满足

$$\sum_{\Omega} m_i(q) = 1 \quad m_i(\phi) = 0 \quad (5)$$

式中 m_i 为第 i 个证据体的基本概率分配. D-S 证据理论中没有给出确定各证据 m_i 函数的方法, 本文根据发动机故障诊断的特点和研究经验, 采用前述的高斯转换函数方法构建 m_i 函数. 利用基于机载自适应模型诊断结果 m_1 和基于 LSSVM 诊断结果 m_2 作为子证据体的合成表达式如下:

$$m(A) = \sum_{A_1 \cap A_2 = A} m_1(A_1) m_2(A_2) \times \left[1 - \sum_{A_1 \cap A_2 = \phi} m_1(A_1) m_2(A_2) \right] \quad (6)$$

式中 $\sum_{A_1 \cap A_2 = \phi} m_1(A_1) m_2(A_2)$ 反映了两个证据体具有的知识和观察实物的角度差异对同一命题之间的差异, 当对故障模式的分量判断全部相左则无法融合.

3 仿真结果

本文以某型涡扇发动机部件级模型为对象, 研究了风扇、压气机、高压涡轮和低压涡轮 4 个核心旋转部件中单部件性能蜕化和两个部件故障同时性能蜕化的类型. 这 4 个部件的性能量的蜕化范围 $[0, 0.06]$. 在地面工作状态 $H = 0 \text{ km}$, $Ma = 0$, 供油量 $W_{FB} = 1.0$, 尾喷口面积 $A_8 = 0.28$ 的稳态条件下模拟发动机部件蜕化, 选取的传感器输出信号为发动机蜕化后的稳定值, 但由于测量噪声的存在, 采用均值滤波对稳态测量数据进行

消噪处理. 该型涡扇发动机部件级模型的 4 个部件蜕化典型点作为故障样本空间, 分别模拟蜕化量从 1% 至 5% 的变化, 得到 20 组发生单故障时的 8 个传感器测量数据. 再模拟两个部件同时发生蜕化, 同时蜕化 1% 至 5%, 分别蜕化 1% 和 3%, 蜕化 1% 和 5% 以及蜕化 3% 和 5%, 得到 66 组两个部件性能参数同时发生蜕化的传感器测量数据. 加上 1 组无故障的传感器测量数据, 共 87 组数据作为 LSSVM 的训练样本, 构建 LSSVM 部件性能评估子系统. 其中 LSSVM 的惩罚因子 $\gamma = 10$, 高斯核参数 $\sigma = 0.2$. 为了验证融合诊断机制的有效性, 对部件性能发生单故障和多故障时进行仿真.

1) 单部件性能蜕化

在此针对每一种单部件故障模式在蜕化空间中选取 5 个测试样本进行仿真试验. 表 1 以统计形式给出了单部件故障诊断正确的样本数、误诊样本数和每个系统的诊断精度. 子系统 I 表示自适应模型诊断结果, 子系统 II 表示 LSSVM 数据挖掘算法诊断输出, 系统 III 表示经过模糊化决策融合后的诊断输出. 表中的每个单元格左右两个数字分别表示正确诊断和误诊的样本个数.

表 1 单部件故障诊断
Table 1 One component fault diagnosis

故障描述	故障模式	子系统 I	子系统 II	系统 III
无故障	[0, 0, 0, 0]	5/0	5/0	5/0
风扇警报	[1, 0, 0, 0]	5/0	5/0	5/0
风扇故障	[2, 0, 0, 0]	4/1	4/1	5/0
压气机警报	[0, 1, 0, 0]	4/1	5/0	5/0
压气机故障	[0, 2, 0, 0]	4/1	4/1	5/0
高压涡轮警报	[0, 0, 1, 0]	4/1	4/1	5/0
高压涡轮故障	[0, 0, 2, 0]	4/1	3/2	4/1
低压涡轮警报	[0, 0, 0, 1]	5/0	5/0	5/0
低压涡轮故障	[0, 0, 0, 2]	5/0	4/1	5/0
准确率/%		88.8	86.6	97.7

从表 1 可知, 经过 D-S 决策融合后, 发动机单部件故障的诊断精度比单独使用自适应模型的 Kalman 滤波诊断和 LSSVM 的数据挖掘方法诊断得到有效提高.

2) 双部件性能蜕化

发动机作为一个复杂气动热力系统, 各个部件之间的性能量密切联系, 一个部件蜕化会影响另一个部件的工作特性发生变化, 需要及时地对

双部件性能蜕化作出准确的诊断, 避免造成不可逆转的故障后果. 由于两个部件同时发生故障的故障模式较多, 本文只针对在 LSSVM 训练空间的 66 种双故障模式进行验证实验, 在每种双部件故障模式选取 1 个测试样本. 表 2 给出了两个部件发生故障时每个系统对部件的诊断结果.

表 2 双部件故障诊断

Table 2 Double component fault diagnosis

	子系统I	子系统II	系统III
双故障模式	52/ 14	57/ 9	61/ 5
准确率%	78. 8	86. 3	92. 4

5 结 论

本文以机载自适应模型的卡尔曼滤波算法对部件健康参数估计为基础, 并行地构建了基于 LSSVM 性能回归预测系统对健康参数进行评估, 采用了部件蜕化参数模糊化的 D-S 理论对两个子系统的诊断结果进行融合, 得到系统的故障模式. 避免了单独使用两种算法各自存在的建模误差和噪声、样本量的限制引起的数据样本的不可靠性的缺陷. 通过对发动机单部件故障、双部件故障仿真, 验证了所提出的部件故障诊断系统的有效性, 具有较高的诊断精度.

参考文献:

[1] Esteban A M. Aircraft applications of fault detection and isolation techniques [D]. Minnesota, USA: The University of Minnesota, 2004

[2] James A L, Elias G M, David P P. Functional aspects of, and trade considerations for, an application optimized engine health management system (EHMS) [C] // 41st AIAA/ ASME/ SAE/ ASEE Joint Propulsion Conference and Exhibit. Tucson, Arizona: The American Institute of Aeronautics and Astronautics, AIAA- 2005- 3719

[3] LU Feng, HUANG Jinquan. Application of intelligent compensation to engine health management system [C] // Proceedings of Computing, Communication, Control, and Management. Florida, USA: IEEE Computer Society,

2008, (1): 485- 489

[4] 黄向华, 丁毅. 基于几何模式识别的发动机传感器故障诊断 [J]. 航空学报, 2006, 27 (6): 1018- 1022
HUANG Xianghua, DING Yi. Engine sensor fault diagnosis based on geometric pattern recognition [J]. Acta Aeronautica et Astronautica Sinica, 2006, 27 (6): 1018- 1022 (in Chinese)

[5] 陈恬, 孙健国. 粗糙集与神经网络在航空发动机气路故障诊断中的应用 [J]. 航空动力学报, 2006, 21 (1): 207- 212
CHEN Tian, SUN Jianguo. Aeroengine gas path fault diagnosis using rough sets and neural networks [J]. Journal of Aerospace Power, 2006, 21 (1): 207- 212 (in Chinese)

[6] Yang Q S. Model based and data driven fault diagnosis methods with applications to process monitoring [D]. Cleveland, USA: Electrical Engineering and Computer Sciences, Case Western Reserve University, 2004

[7] Feng Z G, Shida K, Wang Q. Sensor fault detection and data recovery based on LS-SVM predictor [J]. Chinese Journal of Scientific Instrument, 2007, 28 (2): 193- 197

[8] 陈恬, 孙健国, 郝英. 基于神经网络和证据融合理论的航空发动机气路故障诊断 [J]. 航空学报, 2006, 27 (6): 1014- 1017
CHEN Tian, SUN Jianguo, HAO Ying. Neural network and dempster shafter theory based fault diagnosis for aero engine gas path [J]. Acta Aeronautica et Astronautica Sinica, 2006, 27 (6): 1014- 1017 (in Chinese)

[9] 赵世荣, 黄向华. 应用神经网络信息融合诊断航空发动机故 [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)

[10] Brotherton T, Grabill P, Wroblewski D, et al. A testbed for data fusion for diagnostics and prognostics [C] // Proceedings of the 2002 IEEE Aerospace Conference. Big Sky MT: IEEE, 2002

[11] 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): 580- 584
HUANG Weibin, HUANG Jinquan. On board self tuning model for aero engine fault diagnostics [J]. Journal of Aerospace Power, 2008, 23 (3): 580- 584 (in Chinese)

[12] LU Feng, HUANG Jinquan. The dynamic compensation to complex system based on LS-SVM [C] // Proceedings of First International Conference of Modelling and Simulation. Liverpool, UK: World Academic Union, 2008, (5): 87- 91