

一种改进的航空发动机剩余寿命预测方法

付旭云¹, 钟诗胜¹, 张慕楠²

(1. 哈尔滨工业大学(威海) 机械工程系, 264209 山东 威海; 2. 中国国际航空股份有限公司 工程技术分公司, 101312 北京)

摘 要: 针对传统的发动机剩余寿命预测方法因为假定机队中所有发动机有相同的性能衰退模式, 导致预测精度不高的问题, 在分析发动机排气温度裕度数据的基础上, 提出基于性能衰退模式的发动机剩余寿命预测方法. 对发动机排气温度裕度粗大误差的处理进行了研究, 定义了排气温度裕度时序数据的距离, 给出了性能衰退模式挖掘步骤, 采用 CFM56-5B 发动机的排气温度裕度时序数据对提出的方法进行了验证. 结果表明, 提出的方法与基于机队 EGTm 平均衰退率的预测方法相比, 平均相对误差减少了 2.5%. 基于性能衰退模式的发动机剩余寿命预测方法可以为发动机拆发期限预测和维修计划制定提供可靠的支持.

关键词: 航空发动机; 剩余寿命; 排气温度裕度; 性能衰退; 聚类

中图分类号: V263.5 **文献标志码:** A **文章编号:** 0367-6234(2013)05-0051-05

An improved method for aeroengine residual life prediction

FU Xuyun¹, ZHONG Shisheng¹, ZHANG Munan²

(1. Department of Mechanical Engineering, Harbin Institute of Technology at Weihai, 264209 Shandong, Weihai, China;

2. Air China Technics, Air China, Beijing 101312, China)

Abstract: The traditional aeroengine residual life prediction method assumes that all aeroengines have the same performance deterioration pattern in a fleet, which leads to a low prediction accuracy. On the basis that the aeroengine exhaust gas temperature margin (EGTM) is analyzed, the aeroengine residual life prediction method based on performance deterioration pattern is proposed. The gross error removal of aeroengine EGTm time series data is studied. The distance measure of aeroengine EGTm time series data is defined, and performance deterioration pattern mining steps are given. Finally, the CFM56-5B aeroengine EGTm time series data is adopted to verify the proposed method. The results show that the average absolute relative error of the proposed method is reduced by 2.5% compared to the method of average EGTm deterioration pattern in a fleet. Thus, the aeroengine residual life prediction method based on performance deterioration pattern can supply reliable support for predicting aeroengine removal deadline and making maintenance plan.

Key words: aeroengine; residual life; exhaust gas temperature margin; performance deterioration; clustering

为了保证发动机的持续适航性, 航空公司必须对发动机进行维护、修理和大修. 发动机拆发期限预测是发动机维修计划制定的前提. 发动机拆发期限预测是根据性能数据、滑油消耗量^[1]、寿

命件、适航指令/服务通告限制等确定发动机的最晚送修时机^[2]. 本文主要研究根据性能数据确定发动机的拆发期限, 也即剩余寿命.

表征发动机健康状态最重要的性能指标是排气温度裕度 (Exhaust Gas Temperature Margin, EGTm). 随着飞行时间的增加, EGTm 会逐渐衰退. 一般在 EGTm 降到 0℃ 前, 发动机就必须送修了. 将发动机的 EGTm 观测值看成时间序列进行预测是一种常用的剩余寿命预测方法. 传统的时间序列预测以回归分析为主^[3-4]. 回归分析方法理论上很成熟, 但精度不高. 人工神经网络具有建

收稿日期: 2012-03-22.

基金项目: 国家高技术研究发展计划资助项目 (2012AA040911); 民航局科技计划项目 (MHRD201122); 哈尔滨工业大学(威海) 校科学研究基金资助项目 (HIT(WH) X201107).

作者简介: 付旭云 (1981—), 男, 博士, 讲师;
钟诗胜 (1964—), 男, 教授, 博士生导师.

通信作者: 付旭云, fuxy_hit@163.com.

模简单且能一致逼近任意连续函数的特点,因此可以将人工神经网络应用于性能参数预测^[5].为了体现性能参数中的时间累积效应,文献[6]采用过程神经网络对性能参数进行了预测.考虑到各种预测模型都具有不同的优点,文献[7]建立了一种基于 ARMA 模型和小波变换的组合预测模型.这些基于单台发动机 EGTM 时序数据的预测方法在短期(几周或1个月以内)具有很大的优势,但若用于长期预测,精度往往不够.

发动机性能衰退是一个长期且缓慢的过程.对一台 EGTM 为 60 °C 的 CFM56-5B 发动机,其衰退到 0 °C 需要花费 2 年或者更长的时间.因此,在根据性能数据预测发动机剩余寿命方面,提高长期预测的精度具有很大意义.文献[2]根据机队 EGTM 平均衰退率进行剩余寿命的预测.文献[8-9]将机队 EGTM 衰退模型看成为一个分段线性函数,通过回归分析获得每段的衰退率,再进行剩余寿命的预测.文献[10]利用贝叶斯更新方

法得到了基于性能衰退的发动机剩余寿命分布,然后利用免疫粒子群优化算法建立了发动机剩余寿命组合预测模型.上述方法都假设机队发动机具有相同的性能衰退模式.实际上,每台发动机的制造、使用和维护过程都有一些差异,因此整个机队中的每台发动机性能衰退模式不一定相同.

本文将从发动机历史性能数据挖掘出发动机性能衰退模式,基于性能衰退模式对发动机剩余寿命进行预测.

1 发动机 EGTM 分析

EGTM 是发动机限制温度与全推力起飞时的排气温度(Exhaust Gas Temperature, EGT)的差值.发动机限制温度是制造商根据关键部件材料所能承受的温度限制确定的,而 EGT 会随着飞行时间的增加逐渐升高,反映到 EGTM,就是逐渐下降.图1是从2007年12月到2010年1月期间5台 CFM56-5B 发动机的 EGTM 数据.




图1 发动机 EGTM 数据

从图1可以看出,EGTM 具有如下特点:

- 1)从短期看,EGTM 波动很大.各相邻采样点的差值大多在 10 °C 以内,最大情况可能达到 20 °C.
- 2)从长期看,EGTM 有明显的下降趋势.如发动机1,在2年的时间里,下降了近 60 °C.
- 3)从单台发动机看,EGTM 下降趋势不是单纯的线性关系.
- 4)从整个机队看,EGTM 下降趋势不尽一致.

如发动机1和发动机4,从2008年6月~2009年2月,发动机4的EGTM下降速度明显高于发动机1的.当然,也有相似的,比如发动机3和发动机4.

根据对 EGTM 的分析,如果能够获得 EGTM 的衰退模式,那么从性能衰退角度进行发动机剩余寿命的预测就变得简单了.不难看出,该问题的关键就是从历史 EGTM 数据中挖掘出性能衰退

模式.

2 基于性能衰退模式的发动机剩余寿命预测方法

2.1 粗大误差的处理

EGT 数据来源于发动机上安装的传感器,经过空地数据链、报文解析程序等步骤进入到性能监控系统.在这个过程中,一般会引入粗大误差. EGT 基于 EGT 计算而来,所以 EGT 数据中必然包含粗大误差.因此,挖掘性能衰退模式,首先必须去掉粗大误差.

常用的粗大误差判别方法,比如拉依达准则、罗曼诺夫准则、狄克松准则等,都要求数据是独立同分布的^[11]. 发动机 EGT 数据是时间序列数据,不满足这个条件.对于时序数据粗大误差的判别,目前主要有两类方法:基于历史采样点的判别和基于过程模型的判别,但都比较复杂.根据对 EGT 的分析,短期内 EGT 数据波动很大,但下降趋势并不明显.因此将 EGT 数据按采样顺序进行分组,每组包含十个采样点,这样每组就可以近似看成是独立同分布的,最后采用狄克松准则进行粗大误差判别.和拉依达准则、罗曼诺夫准则等不同,狄克松准则定义了一个极差比统计量,通过与狄克松检验系数比较进行粗大误差判别,而无需求样本标准偏差.图 2 是图 1 中发动机 1 去掉粗大误差后的数据.可以看出,发动机 EGT 去掉粗大误差后,波动仍然较大.




图 2 去掉粗大误差后的 EGT 数据

2.2 基于时序数据聚类的性能衰退模式挖掘

时序数据聚类目前主要有 3 种方法:基于特征的方法、基于模型的方法和基于原始数据的方法^[12]. 基于原始数据的方法是首先根据具体情况为时序数据定义合适的距离,然后采用静态数据的聚类方法完成聚类.因为静态数据的聚类方法

已经比较成熟,所以本文采用基于原始数据的方法对 EGT 时序数据进行聚类分析.

两个 EGT 时序数据之间的距离度量应该满足:对短期波动不敏感,且能够反映长期趋势的一致性.为此,首先对 EGT 数据进行压缩.将 EGT 数据按照采样顺序以某个固定数 N_c 为一组进行分组,各组均值构成的时序数据就是 EGT 数据的一个压缩. N_c 取得太小,去除短期波动的效果不明显; N_c 取值太大,又会掩盖长期趋势.一般情况下,各个 EGT 时序数据的初值和长度均不相等.通过对 EGT 时序数据的前后双向截取,能够获得初值基本相等、长度也相等的 EGT 时序数据.对于 EGT 时序数据 X_a 和 X_b ,其距离度量 d 定义为

$$d(X_a, X_b) = d(X'_a, X'_b) = \frac{1}{N'_{\text{tsd},a,b}} \sqrt{\sum_{i=1}^{N'_{\text{tsd},a,b}} (x'_{a,i} - x'_{b,i})^2}.$$

式中: X'_a, X'_b 分别为 X_a 和 X_b 前后双向截取后获得的初值基本相等、长度也相等的时序数据; $N'_{\text{tsd},a,b}$ 为 X'_a 和 X'_b 的长度; $x'_{a,i}, x'_{b,i}$ 分别为 X'_a 和 X'_b 的第 i 个采样点.

采用类核法完成 EGT 时序数据的聚类.类核定义为一个类中的典型对象的集合.对于只有 1 个对象或者两个对象的类,类核为类中所有对象的集合.对于拥有对象超过 3 个的类,类核为与类中其他对象的距离之和最小的对象.将 N_{ts} 个时序数据分成 c 类的算法步骤如下.

步骤 1 选择 c 个时序数据作为初始类核: $K_1^{(0)}, K_2^{(0)}, \dots, K_c^{(0)}$, 令 $l = 0$;

步骤 2 将待分类的时序数据按照与类核的最小距离原则分配给 c 类中的某一类,时序数据 X_j 和类核 $K_k^{(l)}$ 的距离定义为

$$d(X_j, K_k^{(l)}) = \frac{1}{N_{\text{ker},k}^{(l)}} \sum_{X_{\text{ker},m} \in K_k^{(l)}} d(X_j, X_{\text{ker},m}).$$

式中: $N_{\text{ker},k}^{(l)}$ 为 $K_k^{(l)}$ 的元素的数量, $X_{\text{ker},m}$ 为 $K_k^{(l)}$ 的第 m 个元素.

步骤 3 按照类核的定义更新各类核 $K_k^{(l+1)}$;

步骤 4 如果类核 $K_k^{(l+1)}$ 保持不变,则算法终止;否则, $l = l + 1$, 转至步骤 2.

需要注意的是,在对 EGT 数据进行聚类时,类别数量 c 是未知的.为了找到合适的 c ,可以对 c 进行遍历,即让 c 分别取 2, 3, $\dots, N_{\text{ts}}$, 然后进行聚类,最后根据准则函数 J 进行选择.准则函数综合考虑类间距离、类内距离和类别数量.类间距离越大,类内距离越小,类别数量越少,聚类越合理.基于此,定义准则函数 J_c 为

$$J_c = \left(\frac{\frac{1}{c} \sum_{C_k \in C} D_1(C_k) - J_{c,1,\min}}{J_{c,1,\max} - J_{c,1,\min}} \right)^2 + \left(\frac{\frac{1}{c} \sum_{C_k \in C} D_2(C_k) - J_{c,2,\min}}{J_{c,2,\max} - J_{c,2,\min}} \right)^2 + \left(\frac{c-2}{N_{ts}-2} \right)^2.$$

式中： C 为聚类结果的类的集合； C_k 为 C 的元素； $D_1(C_k)$ 为 C_k 的类内距离，按照式(1) 进行计算； $D_2(C_k)$ 为 C_k 的类间距离，按照式(2) 进行计算； $J_{c,1,\max}, J_{c,1,\min}$ 为 $c = 2, 3, \cdots, N_{ts}$ 时 $\sum_{C_k \in C} \frac{D_1(C_k)}{c}$ 的最大值和最小值； $J_{c,2,\max}, J_{c,2,\min}$ 为 $c = 2, 3, \cdots, N_{ts}$ 时 $\sum_{C_k \in C} \frac{D_2(C_k)}{c}$ 的最大值和最小值。

$$D_1(C_k) = \sum_{X_j \in C_k} d(X_j, K_k), \tag{1}$$

$$D_2(C_k) = \frac{1}{N_{ker,k} N_{ker,C}} \sum_{X_{ker,m_1} \in K_k, X_{ker,m_2} \in K_C} d(X_{ker,m_1}, X_{ker,m_2}). \tag{2}$$

式中： K_C 表示只分为一组时的类核。

EGTM 数据聚类完成后，可以采用多项式函数对各个类进行拟合，获得的多项式函数就是性能衰退模式。

3 应用案例

2007 年 12 月到 2010 年 1 月期间收集了 17 台 CFM56-5B 发动机的 EGTM 数据，去掉粗大误差和数据压缩(取 $N_c = 20$)后，取其中的 15 台进行聚类。图 3 是类别数量 $c = 2, 3, \cdots, 15$ 时对应的准则函数 J_c 曲线。




图 3 准则函数

从图 3 可以看出，当 $c = 5$ 时， J_c 取到最小值。因此将 15 台发动机的 EGTM 时序数据聚为 5 类。对于每一类，分别采用最小二乘法进行多项式函数拟合。经过试验，发现 6 次多项式函数能够较好地反映 EGTM 的衰退趋势，因此将 6 次多项

式拟合结果作为各类的性能衰退模式，如图 4 所示。






图 4 各个类的性能衰退模式

下面计算没有参与聚类的 2 台发动机的剩余寿命。第 1 台发动机的 EGTM 共采样 540 个点，取前 180 个点(一般情况下，每个航班采样 1 次；按照平均每天执行 2 个航班计算，180 个点约为 3 个月的采样数据)进行匹配，发现和类 1 最接近，如图 5(a) 所示。第 2 台发动机的 EGTM 共采样 570 个点，同样取前 180 个点进行匹配，发现和类 4 最接近，如图 5(b) 所示。



(a) 发动机 1 模式匹配



(b) 发动机 2 模式匹配

图 5 发动机性能衰退模式匹配

从图 5 可以看出，这两台发动机的衰退趋势与类 1、类 4 基本是一致的。CFM56-5B 机队的平均衰退率为每循环 0.041 53 ℃/。分别按照机队平均衰退率和所属性能衰退模式对发动机 1 和发动机 2 的最

后一个采样点进行预测,结果如表 1 所示.

表 1 预测结果比较			
样本编号	实际值	机队平均衰退率 预测结果	性能衰退模式 预测结果
发动机 1	56.316 4	60.732 0	59.261 0
发动机 2	60.695 6	51.211 9	52.667 2

经过计算,基于性能衰退模式的 EGTM 预测与基于机队平均衰退率的 EGTM 预测相比,平均相对误差减少了 2.5%.

一般情况下,当 EGTM 降到 0℃ 时,发动机就必须拆下送修了. 为了保证 EGTM 不超标,设发动机 1 拆下时的 EGTM 为 20℃. 从图 4 可以看出,各个性能衰退模式的最低点不到 30℃. 对于各个性能衰退模式最低点往下的趋势,理论上仍可以按该模式的解析式进行外推. 但外推预测实际上超出了经验归纳的有效范围. 在没有领域知识的支持下,相比线性拟合,高次多项式拟合的风险更大. 因此,对于各个性能衰退模式最低点往下的趋势,采用该模式的平均衰退率进行估计. 以发动机 1 为例,其最新的采样点编号为 780. 根据类 1 的性能衰退模式,到第 15 00 个采样点时,EGTM 为 39.13℃. 而类 1 的平均衰退率为每循环 0.032 76℃. 因此,当到第 2 084 个采样点时,发动机 1 的 EGTM 就衰退到 20℃ 了. 也就是说,如果平均每天执行 2 个航班任务,652 天后发动机 1 就必须拆下送修了.

4 结 论

- 1)发动机 EGTM 波动很大,下降趋势不是简单的线性关系,且不尽一致,存在着多种性能衰退模式.
- 2)和基于机队平均衰退率的方法相比,基于性能衰退模式的发动机剩余寿命预测方法精度更高,可以为发动机拆发期限预测提供可靠的支持.

参考文献

[1] CHUN S M. Simulation of engine life time related with

abnormal oil consumption[J]. Tribology International, 2011, 44(4): 426-436.

[2] 雷达. 计及硬件损伤的航空发动机拆发预测方法及其应用研究[D]. 哈尔滨:哈尔滨工业大学, 2009: 28-37.

[3] CHATFIELD C. The analysis of time series: an introduction[M] sixth edition. [S. l.]: Chapman & Hall/CRC, 2003: 33-54.

[4] WANG J, ZHANG T. A degradation prediction method by use of autoregressive algorithm[C]//2008 IEEE International Conference on Industrial Technology. New Jersey: IEEE, 2008: 1-6.

[5] 侯胜利, 王威, 胡金海, 等. 一种航空发动机性能监控的免疫神经网络模型[J]. 航空动力学报, 2008, 23(9): 1748-1752.

[6] LUAN S G, ZHONG S S, LI Y. Hybrid recurrent process neural network for aero engine condition monitoring[J]. Neural Network World, 2008, 18(2): 133-145.

[7] 李晓白, 崔秀伶, 郎荣玲. 航空发动机性能参数预测方法[J]. 北京航空航天大学学报, 2008, 34(3): 253-256.

[8] RONG X, ZUO H F, CHEN Z X. Civil aero-engine health management integrating with life prediction and maintenance decision-making [C]//Prognostics & System Health Management Conference 2010. New Jersey: IEEE, 2010: 1-6.

[9] 富涛, 许春生. 在翼航空发动机剩余寿命预测[J]. 中国民航飞行学院学报, 2006, 17(3): 18-21.

[10] 任淑红, 左洪福. 基于性能衰退的航空发动机剩余寿命组合预测方法[J]. 机械科学与技术, 2011, 30(1): 23-29.

[11] LIU H C, SHAH S, JIANG W. Accurate identification of biased measurements under serial correlation[J]. Computers and Chemical Engineering, 2004, 28(9): 1635-1647.

[12] LIAO T W. Clustering of time series data: a survey[J]. Pattern Recognition, 2005, 38(11): 1857-1874.

(编辑 杨 波)