

文章编号:1000-8055(2011)03-0675-05

民用发动机状态混沌预测算法

宋云雪, 彭 朋, 史永胜

(中国民航大学 航空工程学院, 天津 300300)

摘 要: 首先应用 Haar 小波和 DB16 小波对航空发动机排气温度的原始数据序列进行去噪处理, 并且证明了处理后的数据序列具有混沌特征. 其次应用混沌理论建立发动机状态预测算法, 实现对排气温度的预测. 通过检验排气温度预测值是否超过所规定的红线, 以及该曲线是否平稳, 从而进行发动机的健康状态排查. 作为验证实例, 使用一组某机型发动机实际飞行数据对预测算法进行了验证, 并与加权一阶局域算法和自回归滑动平均模型算法进行了对比. 结果表明, 该组合模型算法精度优于加权一阶局域算法和自回归滑动平均模型算法, 该方法可以为这种机型发动机故障预测提供决策依据.

关 键 词: 航空发动机; 小波变换; 排气温度; 预测算法; 加权一阶局域算法

中图分类号: V23

文献标识码: A

Chaos arithmetic for civil aero-engine forecasting

SONG Yun-xue, PENG Peng, SHI Yong-sheng

(College of Aeronautical Engineering,

Civil Aviation University of China, Tianjin 300300, China)

Abstract: Firstly, using Haar wavelet and DB16 wavelet, the original exhaust gas temperature data series were denoised. Further analysis on the denoised data series indicates the existence of a chaos feature. Then, by using chaos theory, chaotic forecasting arithmetic was established to forecast the exhaust gas temperature data series. Finally, by testing the stable level of data series and comparing the series with the red line, the condition of aero-engine was defined. The proposed arithmetic was verified through some types of aircraft aero-engine exhaust gas temperature data series obtained from actual flight, and then compared with adding-weight one-rank local-region arithmetic and auto-regressive and moving average (ARMA) arithmetic. The result shows that the proposed arithmetic has a better forecasting accuracy. It can be used as a supporting model in the decision-making of aero-engine fault forecasting.

Key words: aero-engine; wavelet transformation; exhaust gas temperature; forecasting arithmetic; adding-weight one-rank local-region arithmetic

保证飞机安全、可靠、高效、经济地运行是航空公司追求的目标. 发动机作为飞机的心脏, 是飞机预防重大事故时应考虑的重要因素之一, 近年来与其相关的故障预测及健康管理技术^[1]成为关

注的热点, 状态监控和视情维修^[2]日益受到重视. 在巡航状态下, 发动机性能参数的变化趋势能够客观反映发动机性能衰退情况, 对发动机性能参数进行预测, 有助于制定最优的发动机换发和维

收稿日期: 2010-01-30; 修订日期: 2010-06-13

基金项目: 国家自然科学基金委员会与中国民用航空总局联合资助(60879017); 天津市自然科学基金(08JCYBJC11600)

作者简介: 宋云雪(1968—), 女, 辽宁鞍山人, 高级工程师, 硕士, 研究方向: 民航发动机故障诊断与预测.

修计划,这对于航空公司在竞争环境下的生存和发展有着深远意义^[3].

航空发动机经常在高温高压的恶劣环境中工作,因此传感器采集到的原始数据容易受到噪声的影响.经过多年的研究,人们在去噪领域已取得大量成果.主要包括滤波器去噪法、影子定理法、主分量的奇异谱法、基于数据自适应的小波去噪法^[4-5]和基于冗余基集的小波去噪法^[6-7]等.在发动机性能参数预测算法的研究上,主要集中在利用自回归模型预测航空发动机滑油系统^[8],利用神经网络和多元线性回归对航空发动机排气温度进行预测^[9].但是,自回归模型的预测精度不高,神经网络存在学习和训练不稳定的问题.

因此本文尝试采用小波去噪和混沌理论的组合预测来对发动机的重要性能参数进行短期预测,提高了预测精度,并以此为基础提出一种发动机异常状态预测模型.

1 基于小波变换的航空发动机排气温度数据序列噪声平滑方法

1.1 去噪问题的数学定义

设长度为 N 的信号被噪声 e_n 所污染,所测得含噪数据为

$$X_n = f_n + e_n \quad (1)$$

去噪的目标是从含噪数据 X 中得到信号 f 的一个逼近信号 $\hat{f}$,使得在某种误差估计下 $\hat{f}$ 是 f 的最优逼近.去噪的主要任务是最大程度地将实际信号从含噪信号中分离出来,去除噪声信号,达到去噪的目的.

1.2 基于正交小波变换模型

函数线性空间为

$$L^2(R) = \left\{ f(t) \left| \int_R |f(t)|^2 dt < +\infty \right. \right\} \quad (2)$$

设 $f(t) \in L^2(R)$,若函数 $\phi(t)$ 的傅里叶变换 $\phi(\omega)$ 满足条件

$$\int_R \frac{|\phi(\omega)|^2}{\omega} d\omega < +\infty \quad (3)$$

称 $\phi(t)$ 为基小波,则 $f(t)$ 的连续小波变换为

$$W_f(a, b) = \frac{1}{\sqrt{a}} \int_R f(t) \bar{\psi}\left(\frac{t-b}{a}\right) dt, \quad a > 0 \quad (4)$$

式中 $\bar{\psi}(t)$ 是 $\phi(t)$ 的复共轭函数; $W_f(a, b)$ 为由基小波 $\phi(t)$ 进行伸缩和平移变换得到的系数; a 为尺度因子; b 为平移因子.

一般时间序列是离散的,则式(4)的离散形式为

$$W_f(a, b) = \frac{1}{\sqrt{a}} \Delta t \sum_{k=1}^{N_1} f(k\Delta t) \bar{\psi}\left(\frac{k\Delta t - b}{a}\right) \quad (5)$$

式中 N_1 为离散点数; Δt 为抽样时间间隔.

从公式(4),(5)中可见,小波具有自适应变化的时频窗口.当 a 较大时,窗口呈“瘦窄”状,符合高频信号的局部时频特征;当 a 较小时,窗口呈“扁平状”,符合低频信号的局部时频特征,从而实现了函数或信号序列的多尺度细化分析.

1.3 阈值收缩去噪算法

根据不同尺度下小波信号的信噪比选取阈值,细化小波分解信号,基本步骤如下^[10]:

1) 根据所处理数据的实际情况,对数据进行 J 尺度小波分解,得到平滑近似信号 a_j 和细节信号 $d_j, j=1, \dots, J; J \leq m\tau$,且小于轨道平均周期.其中 m 为嵌入维数, τ 为延迟时间(一般取 1).

2) 保持近似信号 a_j 不变,分别对各细节信号 d_j 进行小波噪声平滑,根据不同层次上信号的信噪比不同,各层的阈值如下式所示:

$$\lambda_j = \begin{cases} M_j \sqrt{2 \ln N} & j = 1 \\ M_j \sqrt{2 \ln N / \ln(j+1)} & j = 2, 3, \dots, J-1 \\ M_j \sqrt{2 \ln N / \sqrt{j}} & j = J \end{cases} \quad (6)$$

式中 λ_j 代表各细节信号的阈值, M_j 为各个层次上的绝对偏差中值, N 为信号的长度.

3) 使用 Mallat 的小波重构算法得到重构信号,细节信号 d_j 的重构信号为 $d_{jj}, j=1, \dots, J$.

4) 最终噪声平滑后的信号为

$$\hat{s} = a_J + \sum_{j=1}^J d_{jj} \quad (7)$$

2 加权一阶局域算法预测模型

2.1 定义

设中心点 Y_k 的邻近点位 $Y_{ki}, i=1, 2, \dots, q$ (q 是一个整数,它依赖于指定的邻近距离的大小),并且到 Y_k 的距离为 d_i ,设 $d_{\min}$ 是 d_i 中的最小值,定义点 Y_{ki} 的权值为

$$P_i = \frac{\exp[-a(d_i - d_{\min})]}{\sum_{i=1}^q \exp[-a(d_i - d_{\min})]} \quad (8)$$

式中一般取参数 $a=1$,则一阶局域线性拟合为

$$Y_{k(i+1)} = ae + bY_{ki}, \quad i = 1, 2, \dots, q \quad (9)$$

其中 $e=(1,1,\dots,1)^T$, 写成向量的形式为

$$\begin{bmatrix} Y_{k(1+1)} \\ Y_{k(2+1)} \\ \vdots \\ Y_{k(q+1)} \end{bmatrix} = \begin{bmatrix} e & Y_{k1} \\ e & Y_{k2} \\ \vdots & \vdots \\ e & Y_{kq} \end{bmatrix} \begin{bmatrix} a \\ b \end{bmatrix} \quad (10)$$

其中 $e=[1 \ 1 \ \dots \ 1]_m^T$.

就维数 $m=1$ 时的情况讨论, $m>1$ 的情况类似, 即

$$\begin{bmatrix} x_{k(1+1)} \\ x_{k(2+1)} \\ \vdots \\ x_{k(q+1)} \end{bmatrix} = \begin{bmatrix} e & x_{k1} \\ e & x_{k2} \\ \vdots & \vdots \\ e & x_{kq} \end{bmatrix} \begin{bmatrix} a \\ b \end{bmatrix} \quad (11)$$

应用加权最小二乘法有

$$\sum_{i=1}^q P_i (x_{k(i+1)} - a - bx_{ki})^2 = \min \quad (12)$$

将式(12)看成是关于未知数 a, b 的二元函数, 两边求偏导, 化简得到关于未知数 a, b 方程组

$$\begin{cases} a \sum_{i=1}^q P_i x_{ki} + b \sum_{i=1}^q P_i x_{ki}^2 = \sum_{i=1}^q P_i x_{ki} x_{k(i+1)} \\ a + b \sum_{i=1}^q P_i x_{ki} = \sum_{i=1}^q P_i x_{k(i+1)} \end{cases} \quad (13)$$

解方程组得到 a, b , 然后代入式(10)得到预测公式. 根据预测公式, $Y_{ki} (i=1, 2, \dots, q)$ 的一步预测为 $Y_{k(i+1)} (i=1, 2, \dots, q)$.

2.2 发动机混沌预测算法

1) 重构相空间. 计算时间序列的延迟时间 τ . 根据 Grassberger-Procaccia (G-P) 算法计算出时间序列的关联维数 d , 再由 Takens 定理选取嵌入维数 m , 得到重构相空间.

2) 寻找邻近点. 在相空间中计算各点到中心点的参考向量, 并计算各点与中心点之间的距离.

3) 进行预测. 应用加权最小二乘法, 求出未知参数 a, b , 分离出预测值.

4) 根据预测公式进行预测.

3 发动机异常状态的预测

排气温度(exhaust gas temperature, 用 t_{eg} 表示)是表征发动机健康状况核心的指标之一, 发动机的异常状态可以通过预测的 t_{eg} 数据得到反映.

t_{eg} 的异常状态可从以下两个方面来判断:

- 1) t_{eg} 超过了设定的红线温度;
- 2) t_{eg} 在某一个时间段内出现整体性的波动趋势.

发动机异常状态的预测过程可描述为: 首先将采集到的 t_{eg} 原始数据去噪, 然后把处理过的数据导入到混沌预测模块中, 求出预测数列. 将预测值和 t_{eg} 的红线值作比较. 如果有预测值高过红线, 则立即报警. 如果都在正常范围内, 继续下一步的平稳性检验.

将预测得到的数据和最近的一段实际数据组成检测样本, 测试它的平稳程度, 如果平稳, 则表示该系统延续正常状态; 如果不平稳, 则表明数据序列有整体变化的趋势, 系统可能进入异常状态, 需要严密监测 t_{eg} 的后续发展. 预测流程如图1所示.




图1 异常状态预测流程图

Fig. 1 Flowchart of abnormal condition forecasting

4 实例分析

发动机的绝大部分工作时间是处于巡航阶段. 因此, 对巡航状态下的 t_{eg} 的预测可以为判断发动机是否进入异常提供数据支持. 本文的数据来自中国国际航空公司某波音 777 客机 PW4077 发动机近一年的巡航飞行数据.

对图2所显示的 t_{eg} 数据值进行 ADF (augmented Dickey-Fuller) 检验, ADF 检验的 t 统计




图2 t_{eg} 数据序列

Fig. 2 t_{eg} data series

量为-6.476 560,而且概率值非常小.检验水平为 1%,5%,10%的 t 统计量临界值如表 1 所示.

表 1 稳定性检验
Table 1 Stability test

检验水平/%	t 统计量临界值
1	-3.436 722
5	-2.864 242
10	-2.568 261

检验结果显示,ADF 检验的 t 统计量小于检验水平为 1%,5%,10%的 t 统计量临界值,该 t_{eg} 序列是平稳的.

选取该发动机前 1 000 次测得的 t_{eg} 数据.利用本文第 1 节的方法对原始数据进行去噪.分解尺度选为 3,用 DB16 小波函数为小波基函数,噪声平滑后的噪声部分进行自相关函数^[11]分析.通过分析得到去除的噪声部分的自相关性很弱,具有不可预测性,表现出与随机噪声相似的特性.

同时,计算噪声平滑后的 t_{eg} 时间序列的特征参数,求得延迟时间为 3,嵌入维数为 8,最大 Lyapunov^[12]指数为 0.02.利用加权一阶局域算法对去噪前后的两组数据分别进行 10 步预测,并与 Harr 小波和 DB16 小波去噪预测,ARMA(自回归滑动平均模型)预测进行了对比.原始值和预测值如表 2 所示.预测的相对误差如表 3 所示.

表 2 t_{eg} 原始值和预测值

Table 2 Actual data and forecasting result of t_{eg}

序号	原始值	加权一阶局域预测	Haar 去噪预测	DB16 去噪预测	ARMA 预测
1	383.5	386.6	384.3	384.7	375.9
2	396.9	382.7	389.2	388.0	374.2
3	396.2	386.8	392.1	386.8	375.9
4	393.5	385.1	392.7	387.6	374.2
5	389.3	384.0	385.5	385.4	375.9
6	380.4	389.3	394.6	383.5	374.2
7	383.1	388.5	387.6	381.5	375.9
8	401.1	381.9	382.9	381.8	374.2
9	397.2	386.0	391.7	385.4	375.9
10	380.0	385.6	393.6	383.6	374.2

从图 3 可以看出加权一阶局域算法的预测精度要比 ARMA 算法更高.

表 3 t_{eg} 原始相对预测误差和去噪后的相对预测误差
Table 3 Relative error of t_{eg} forecasting result

序号	加权一阶局域预测 相对误差/%	Haar 去噪 预测相对 误差/%	DB16 去噪 预测相对 误差/%	ARMA 预测相对 误差/%
1	0.80	0.22	0.31	-1.98
2	-3.59	-1.93	-2.24	-5.73
3	-2.38	-1.04	-2.38	-5.12
4	-2.14	-0.21	-1.51	-4.91
5	-1.36	-0.98	-1.00	-3.44
6	2.33	3.73	0.82	-1.63
7	1.42	1.16	-0.41	-1.88
8	-4.79	-4.53	-4.80	-6.71
9	-2.82	-1.39	-2.98	-5.36
10	1.46	3.58	0.94	-1.53




图 3 t_{eg} 预测相对误差(加权一阶 vs ARMA)
Fig. 3 Relative error of t_{eg} forecasting result with adding-weight one-rank local-region arithmetic and ARMA arithmetic

图 4 和图 5 分别显示了使用 Haar 小波和 DB16 小波去噪为预测精度带来的影响.从图中可以看出,原始数据经过小波去噪后,预测精度又有了一个提高.




图 4 t_{eg} 预测相对误差(不去噪 vs Haar 小波去噪)
Fig. 4 Relative error of t_{eg} forecasting result (non-denoising vs Haar wavelet denoising)

从表 3、图 4 和图 5 中可以看出 t_{eg} 数据经过去噪后,大约有 70% 的数据预测误差得到降低,而且经过 Haar 小波和 DB16 小波去噪后有 60%~




图5 t_{eg} 预测相对误差(不去噪 vs DB16 小波去噪)

Fig. 5 Relative error of t_{eg} forecasting result
(non-denoising vs DB16 wavelet denoising)

70%的相对误差控制在2%之内,相比去噪前,预测精度有一个不小的提高。

5 结 论

通过仿真实验表明:

1) 发动机排气温度时间序列具有混沌性.因此利用混沌时间序列的相关预测方法是可行的。

2) 原始的排气温度 t_{eg} 采集数据经过去噪后,能够获得比以前更好的预测结果.实验显示用Haar小波去噪后能够把近一半的预测值的误差率降到1%左右.用DB16小波去噪后有60%的预测误差率控制在2%以内,两者都优于去噪前约3%的误差率。

参考文献:

- [1] Banks J, Reichard K, Crow E, et al. How engineers can conduct cost-benefit analysis for PHM systems[J]. IEEE Aerospace and Electronic Systems Magazine, 2009, 24(3): 22-30.
- [2] Van der Weide J A M, Pandey M D, Van Noortwijk J M. Discounted cost model for condition based maintenance optimization[J]. Reliability Engineering and System Safety, 2010, 95(3): 236-246.
- [3] 张海军, 左洪福, 梁剑. 航空发动机多指标模糊信息熵的性能排序研究[J]. 应用科学学报, 2006, 24(3): 288-292.
- [4] ZHANG Haijun, ZUO Hongfu, LIANG Jian. Multi-parameter performance ranking of aeroengines based on fuzzy information entropy method[J]. Journal of Applied Science, 2006, 24(3): 288-292. (in Chinese)
- [5] Cinquemani E, Pilonetto G. Wavelet estimation by Bayesian thresholding and model selection[J]. Automatic, 2008, 44(9): 2288-2297.
- [6] Cai T, Zhou H. A data-driven block thresholding approach to wavelet estimation[J]. Annals of Statistics, 2009, 37(2): 569-595.
- [7] Zhang B, Fadili J M, Starck J L. Wavelets, ridgelets and curvelets for Poisson noise removal[J]. IEEE Transactions Image Processing, 2008, 17(7): 1093-1108.
- [8] Ma J, Plonka G. Combined curvelet shrinkage and non-linear anisotropic diffusion[J]. IEEE Transactions Image Processing, 2007, 16(9): 2198-2206.
- [9] 胡金海, 谢寿生. 基于AR模型对润滑油中金属元素含量的预测[J]. 燃气涡轮试验与研究, 2003, 16(1): 32-36.
- [10] HU Jinhai, XIE Shousheng. AR model-based prediction of metal content in lubricating oil[J]. Gas Turbine Experiment and Research, 2003, 16(1): 32-36. (in Chinese)
- [11] 宋云雪, 张科星, 史永胜. 基于多元线性回归的发动机性能参数预测研究[J]. 航空动力学报, 2009, 24(2): 427-431.
- [12] SONG Yunxue, ZHANG Kexing, SHI Yongsheng. Research on aeroengine performance parameters forecast based on multiple linear regression forecasting method[J]. Journal of Aerospace Power, 2009, 24(2): 427-431. (in Chinese)
- [13] Medina C A, Alcaim A, Apolinario J A. Wavelet denoising of speech using neural networks for threshold selection[J]. Electronics Letters, 2003, 39(25): 1869-1871.
- [14] Barabanov N E, Prokhorov D V. Stability analysis of discrete-time recurrent neural networks[J]. IEEE Transactions on Neural Networks, 2002, 13(2): 292-303.
- [15] Vallejos R O, Anteneodo C. Theoretical estimates for the largest Lyapunov exponent of many-particle systems[J]. Physical Review E, 2002, 66(2): 1203-1218.