

基于改进PCA算法的航空发动机 状态诊断模型

姜 健

(中国飞行试验研究院 发动机所, 西安 710089)

摘 要: 针对飞行试验对高效异常诊断手段的迫切需求,利用海量飞行试验数据,在提取表征发动机状态参数的基础上,采用分段线性化的思想改进PCA(主元分析)算法,改善PCA算法在复杂非线性系统建模方面存在的参数估计精度差等问题。根据发动机风扇转子转速对试飞数据(样本数据)进行区间划分,分段建立发动机状态诊断模型。验证结果表明:改进PCA算法建立的诊断模型参数估计精度较好,对参数偏差较为敏感,能正确检测发动机异常的出现并准确定位异常参数,对飞行试验安全监控及发动机异常诊断平台的开发具有一定的参考价值。

关键词: 航空发动机;状态监控;分段线性化;PCA;监视量;估计精度;敏感性;异常定位

中图分类号: V235.1 **文献标识码:** A **文章编号:** 1672-2620 (2017) 02-0032-05

Modeling of aero-engine state diagnosis based on improved PCA algorithm

JIANG Jian

(Engine Flight Test Technology Institute of Chinese Flight Test Establishment, Xi'an 710089, China)

Abstract: In order to meet the urgent demand of high efficiency anomaly diagnosis methods in flight test, on the basis of extracting the state parameters of the engine, a large number of flight test data was used to develop an improved PCA (Principal component analysis) method that applied with piecewise linearization. It can solve the problem that PCA algorithm has poor precision in parameter estimation of complex nonlinear system modeling. According to the rotor speed of the engine fan, the flight test data (sample data) were divided into sections and the engine state diagnosis model was established piecewise. The result shows that the improved PCA algorithm has higher accuracy in parameter estimation and is sensitive to the parameter deviation. The abnormalities of the engine can be detected correctly and the abnormal parameters can be accurately positioned. So it has certain reference value for the flight test safety monitoring and the engine abnormal diagnosis platform establishment.

Key words: aero-engine; status monitoring; piecewise linearization; PCA; comprehensive characterization parameters; estimation accuracy; sensitivity; abnormal localization

1 引言

航空发动机飞行试验具有高风险的突出特点,因此对试验安全性提出了苛刻要求。目前,在我国航空发动机飞行试验或使用飞行中,发动机状态监控主要依靠对地面实时监控系统和飞参系统记录的状态参数进行判读,处理方式局限于参数超限、与控制规律基准线的符合性、滑油光谱分析等,效率低且

需要具备一定技术经验的专业人员进行判读,迫切需要探索高效的发动机异常诊断手段。

异常诊断主要有基于解析模型的方法、基于知识的方法及基于数据驱动的方法等^[1]。其中基于数据驱动的方法是通过采集的数据与利用历史数据建立的统计模型相比较,从而实现异常诊断。由于该方法不需要建立系统的解析模型,在复杂系统异常诊断中得到了广泛应用,而其中又以主元分析(PCA)

收稿日期: 2017-01-17; 修回日期: 2017-03-30

作者简介: 姜 健(1981-),男,陕西勉县人,高级工程师,硕士,主要从事航空发动机飞行试验技术研究。

算法应用较多^[2-6]。PCA算法对建模维数比较高的变量进行主元分析,利用维数比较低的少数几个主元承载原始变量所提供的大多数信息^[2-3]。该算法只需要利用正常的变量样本数据建立主元模型和残差模型,且基于平方预测误差SPE统计量和 Hotelling T^2 统计量建立系统状态监视量,为异常判定阈值的确定提供了理论支持。

文献[7-9]针对PCA算法在航空发动机异常检测和诊断中的应用进行了研究,建立了诸如发动机起飞状态这样的稳态或准稳态过程关键参数的异常诊断模型。但由于PCA算法获得的主元实质为各变量的线性组合,扩展至发动机全工作状态时存在参数估计精度差等问题;而诸如核主元分析(KPCA)等非线性算法则存在优化问题,模型的修正需要反复迭代优化。鉴于以上原因,本文利用海量的飞行试验数据,在提取发动机状态参数的基础上,采用分段线性化的思想改进PCA算法,按发动机转速对试飞数据(样本数据)进行区间划分,分段建立发动机状态诊断模型,并利用飞行试验数据进行验证,获得了较为理想的结果。

2 主元分析算法

2.1 主元模型

设系统 m 个变量的向量 $\mathbf{x}$:

$$\mathbf{x} = (x_1, x_2, \dots, x_m) \quad (1)$$

PCA算法将变量向量 $\mathbf{x}$ 转换到 m 个标准正交基 p_i 组成的新坐标空间 p ,形成 m 个互不相关且正交的主元 t_{i0} 。

$$t_i = \mathbf{p}_i^T \mathbf{x}^T \quad (2)$$

式中: $\mathbf{p}_i = [p_{i1}, p_{i2}, \dots, p_{im}] \in \mathbf{R}^{m \times 1}$ 为第 i 个主元的系数向量。

变量向量 n 次观测形成矩阵 $\mathbf{X} \in \mathbf{R}^{n \times m}$,矩阵 $\mathbf{X}$ 可表示为:

$$\mathbf{X} = \sum_{i=1}^m \mathbf{T}_i \mathbf{p}_i^T \quad (3)$$

式中: $\mathbf{T}_i \in \mathbf{R}^{n \times 1}$ 为第 i 个主元 t_i 的 n 次观测值组成的主元向量。

根据主元的方差贡献率 δ 和前 β 个主元的累计贡献率 η ,保留提供信息量较大的主元^[2-3]。

$$\delta_i = \lambda_i / \sum_{j=1}^m \lambda_j \quad (4)$$

$$\eta_\beta = \sum_{i=1}^a \delta_i \quad (5)$$

主元模型:

$$\hat{\mathbf{X}} = \sum_{i=1}^{\beta} \mathbf{T}_i \mathbf{p}_i^T \quad (6)$$

式中: $\hat{\mathbf{X}}$ 为矩阵 $\mathbf{X}$ 的主元模型估计值。

残差模型:

$$\mathbf{e} = \mathbf{X} - \hat{\mathbf{X}} = \sum_{i=\beta+1}^m \mathbf{T}_i \mathbf{p}_i^T \quad (7)$$

工程上,变量的取值范围差异很大,量纲也不尽相同。因此在建立主元模型和残差模型前,一般将变量观测矩阵标准化,标准化后的变量矩阵记为 $\bar{\mathbf{X}}$ 。

2.2 异常诊断

判断 k 时刻实际测量值是否异常,可通过建立统计量的假设检验。一般基于主元模型建立 Hotelling T^2 统计量,检验主元向量模的波动反映变量的变化情况。基于残差模型建立平方预测误差SPE统计量,检验测量值与估计值的偏离程度^[10-11]。

$$T^2 = \mathbf{x}_k \mathbf{p}_\beta \Lambda_\beta^{-1} \mathbf{p}_\beta^T \mathbf{x}_k^T \quad (8)$$

式中: $\mathbf{p}_\beta$ 为前 β 个主元的系数向量, Λ_β 为前 β 个主元对应的特征值组成的对角矩阵。

$$SPE = \mathbf{x}_k (\mathbf{I} - \mathbf{p}_\beta \mathbf{p}_\beta^T) \mathbf{x}_k^T \quad (9)$$

式中: $\mathbf{I}$ 为单位矩阵。

当检验水平为 α 时, T^2 和SPE的控制限分别为^[10]:

$$T_\alpha^2 = \frac{\beta(n-1)}{n(n-\beta)} F_\alpha(\beta, n-\beta) \quad (10)$$

$$SPE_\alpha = \theta_1 \left[1 + \frac{c_\alpha \sqrt{2\theta_2 h_0^2}}{\theta_1} + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1^2} \right]^{\frac{1}{h_0}} \quad (11)$$

式中: $F_\alpha(\beta, n-\beta)$ 为检验水平为 α 、自由度为 β 和 $n-\beta$ 条件下的 F 分布临界值, $\theta_i = \sum_{j=\beta+1}^m \lambda_j^i (i=1, 2, 3)$, c_α 为标准正态分布在检验水平为 α 下的临界值, $h_0 = 1 - \frac{2\theta_1 \theta_3}{3\theta_2^2}$ 。

当 k 时刻实际测量值 $\mathbf{x}_k$ 的 T^2 和SPE超过控制限(一般以SPE超过控制限为主要判断条件)时,即可认为实际测量值 $\mathbf{x}_k$ 出现异常。

3 改进PCA算法的异常诊断建模

由于PCA算法获得的主元实质为各变量的线性组合,扩展至发动机全工作状态时存在参数估计精度差等问题。因此,采用分段线性化的思想,改进PCA算法,建立航空发动机状态异常诊断模型。具体步骤如下:

(1) 提取表征发动机状态的参数。提取原则为:能够从机载数据和飞参数据中提取该参数,能够表征发动机状态。为此,提取高压转子转速 n_2 、风扇转子转速 n_1 、排气温度 T_6 、风扇进口可调导叶角度 α_1 、

高压压气机进口可调静叶角度 α_2 、尾喷口喉道面积 A_8 、机匣振动 B 、滑油压差 p_m 等8个状态参数作为建模参数,并分别编号1~8。

(2) 选择一定量的飞行试验数据作为建模的样本数据,采用欧式距离等方法筛选剔除冗余数据。

(3) 按照发动机风扇转子转速对样本数据进行区间划分,初步设定风扇转子转速划分点和区间个数。转速划分点的初步设定原则主要有:各区间样本数据量分布均匀;根据发动机控制规律设置划分点,如控制规律的转折点和转换点等。

(4) 对各样本区间数据进行标准化处理,求取各样本区间数据矩阵的协方差矩阵,以及协方差矩阵的特征值和特征向量。

(5) 计算各样本区间的主元,以及各主元的贡献率和累积贡献率,建立各样本区间的主元模型和残差模型。

(6) 给定模型估计精度,分别以样本数据和属于样本集特征的新数据,检验模型的估计精度是否满足要求。如精度不满足要求,则转至第(2)步进行样本数据划分的调整。

(7) 基于各样本区间的主元模型和残差模型,采用 T^2 和 SPE 统计量,作为基于主元模型的监视量和基于残差模型的监视量,计算各监视量的阈值。

发动机状态异常诊断模型诊断过程步骤如下:

(1) 采集新数据,区间判断,然后以建模数据的均值和标准差进行数据的标准化处理。

(2) 计算 SPE 和 T^2 监视量并与阈值进行比较,若小于阈值,当前数据的判读结束,进行下一采集数据的判读。若计算的监视量值大于阈值,以 SPE 的判读为准则, T^2 的判读为辅助。

(3) 计算各建模参数对 SPE 监视量的贡献度,贡献度最大的即为异常参数。

采用某型涡扇发动机的飞行试验数据,按照风扇转子转速划分7个区间,各区间主元模型主元个数、累计贡献率和各区间监视量阈值见表1。为了进行对比验证,采用PCA算法建立异常诊断模型,前4个主元的累积贡献率为89.5%。

4 试验验证

4.1 正常数据检测

图1示出了PCA算法和改进PCA算法建立的诊断模型对高压转子转速的估计。可看出:PCA算法在某些状态估计值与实测值的偏差较大,参数估计精度较低;改进PCA算法的估计值与实测值吻合性

表1 各区间主元个数、累计贡献率及监视量阈值
Table 1 The number of principal components and the cumulative contribution rate of each interval, as well as the threshold value of comprehensive characterization parameter

序号	$n_i/\%$	β	$\eta/\%$	T^2_α	SPE_α	n
1	37~46	4	84.4	13.51	5.46	553
2	46~55	4	88.2	13.59	4.46	419
3	55~65	4	84.5	13.53	5.65	509
4	65~75	4	83.4	13.55	6.15	480
5	75~88	4	85.7	13.47	7.52	687
6	88~95	4	87.6	13.56	4.97	466
7	>95	4	82.8	13.54	6.20	503

注:监视量阈值的置信度为99%。




图1 改进PCA算法诊断模型对高压转子转速的估计
Fig.1 Estimation of high pressure rotor rotation speed by improved PCA method

较好,参数估计精度较高。

4.2 参数偏差敏感性分析

以发动机高压转子转速为例,进行建模参数偏差敏感性分析。在正常数据中分别嵌入存在相对偏差的异常数据,验证监视量对高压转子转速偏差的

敏感性,验证结果如图2、图3所示。由图可知:PCA算法建立的诊断模型监视量对参数偏差的敏感性较差,将不能准确检测参数异常;而改进PCA算法建立的诊断模型监视量对参数偏差的敏感性显著增强,这也将提高诊断模型对参数异常的确诊率。

4.3 异常检测

以高压压气机进口可调静子叶片卡滞(异常模式①)、滑油压差传感器异常(异常模式②)、发动机轴承断裂振动值偏大(异常模式③)等异常模式的试飞数据为验证数据,改进PCA算法建立的诊断模型对异常的检测结果如图4所示。可见,异常模式①~③的SPE值均超出了告警值,异常均被准确检测出。

异常模式下,各建模参数对SPE的贡献度如图5

所示。由图中可知,异常模式①~③下贡献度最大的参数,分别为高压压气机进口可调静叶角度、滑油压差和机匣振动,改进PCA算法建立的诊断模型准确定位了异常参数。

5 结论及展望

利用海量的飞行试验数据,在提取表征发动机状态参数的基础上,采用分段线性化的思想,改进了PCA算法在复杂非线性系统建模方面存在的参数估计精度差等问题。建立了涡扇发动机状态异常诊断模型,并进行了试验验证。主要结论为:

(1) 改进PCA算法建立的诊断模型对建模参




图2 PCA算法建立的诊断模型监视量对高压转子转速偏差的敏感性

Fig.2 Sensitivity of comprehensive characterization parameter to high pressure rotor rotation speed deviation by PCA method




图3 改进PCA算法建立的诊断模型监视量对高压转子转速偏差的敏感性

Fig.3 Sensitivity of comprehensive characterization parameter to high pressure rotor rotation speed deviation by improved PCA method




图4 发动机异常模式验证结果

Fig.4 Validation results of engine abnormal model




图5 异常模式下各建模参数对SPE的贡献度

Fig.5 The contribution rate of each parameter to the SPE value in the abnormal model

数的估计精度较好,对建模参数偏差较为敏感,能够检测到异常并准确定位异常参数。

(2) 后续将在改进PCA算法基础上,开展以下研究:①结合飞行包线分区域建模思想,进一步提高建模参数估计精度。②采用异常特征提取技术,设定SPE时间域的限定条件,当SPE超出阈值持续一段时间才发出告警;时间域初值设置由异常数据提取特征确定,并结合试验修正。③采用递推算法^[12]和滑动窗口算法^[12]提高诊断模型的自适应能力。

参考文献:

- [1] Frank P M. Fault diagnosis in dynamic systems using analytical and knowledge-based redundancy—a survey and some new results[J]. Automatica, 1990, 26(3): 459—474.
- [2] 王桂增,叶 昊. 主元分析与偏最小二乘法[M]. 北京:清华大学出版社,2012.
- [3] 周东华,李 钢,李 元. 数据驱动的工业过程故障诊断技术[M]. 北京:科学出版社,2010.
- [4] 韦 洁. 基于主元分析的电机状态监测方法的研究[D].

北京:北京交通大学,2009.

- [5] 朱孔伟. 基于主元分析的电厂锅炉异常检测与诊断[D]. 南京:东南大学,2006.
- [6] 杜海莲,王占锋,吕 锋,等. 基于主元分析的多传感器异常检测[J]. 南京航空航天大学学报, 2011, 43: 138—141.
- [7] 王英俊,谢寿生. 航空发动机性能趋势监控量化的方法研究[J]. 航空动力学报, 2003, 18(4): 549—553.
- [8] 杨 帆,胡金海,陈 卫,等. 主元分析方法在航空发动机异常检测与诊断中的应用[J]. 机械科学与技术, 2008, 27(3): 330—333.
- [9] 崔建国,郑 蔚,蒋丽英,等. 主元分析在航空发动机关键系统状态识别中的应用[J]. 计算机测量与控制, 2015, 23(11): 3849—3852.
- [10] Jackson J E, Mudhalkar G S. Control procedures for residuals associated with principal component analysis[J]. Technometrics, 1979, 21(3): 341—349.
- [11] Jackson J E. A User's guide to principle components[M]. New York: Wiley, 1991.
- [12] 李应红,尉询楷. 航空发动机的智能诊断、建模与预测方法[M]. 北京:科学出版社,2013.