

# 基于非线性故障重构的旋转机械 故障预测方法

马洁<sup>1</sup> 李钢<sup>2</sup> 陈默<sup>1</sup>

**摘要** 对旋转机械的状态进行在线监测和故障预测是一个具有重要应用价值的工程问题。采用基于核主元分析的非线性故障重构技术研究了多变量相关条件下旋转机械的故障估计及预测问题。首先利用核主元分析对旋转机械系统进行离线非线性建模，并进行异常检测。通过对故障程度进行定量描述，用最优化方法求解故障重构意义下的故障估计；然后用多层递阶的方法对估计出的故障幅值的发展趋势进行预测。最后，以中国石化北京燕山分公司的烟气轮机作为实际应用对象，验证了该方法的有效性。

**关键词** 旋转机械，非线性故障重构，核主元分析，多层递阶预测

**引用格式** 马洁，李钢，陈默. 基于非线性故障重构的旋转机械故障预测方法. 自动化学报, 2014, 40(9): 2045–2049

**DOI** 10.3724/SP.J.1004.2014.02045

## Nonlinear Fault Reconstruction Based Fault Prognosis for Rotating Machinery

MA Jie<sup>1</sup> LI Gang<sup>2</sup> CHEN Mo<sup>1</sup>

**Abstract** It is an engineering problem of great application value to monitor the rotating machinery online and perform fault prognosis. A fault prognosis method is proposed for rotating machinery based on kernel principal component analysis and nonlinear fault reconstruction. First, kernel principal component analysis is used to build a model of rotating machinery and perform process monitoring. By describing the fault magnitude quantificationally, an optimal fault estimation is obtained with an optimization method. At last, a multi-layer hierarchical forecasting method is adopted to predict the fault magnitude evolution. The flue gas turbine of Beijing Yanshan Petrochemical Corporation is used to demonstrate the effectiveness of the proposed method.

**Key words** Rotating machinery, nonlinear fault reconstruction, kernel principal component analysis, multi-layer hierarchical forecast

**Citation** Ma Jie, Li Gang, Chen Mo. Nonlinear fault reconstruction based fault prognosis for rotating machinery. Acta Automatica Sinica, 2014, 40(9): 2045–2049

旋转机械是工业上应用最广泛的机械，许多大型旋转机械（如烟气轮机、旋转注水机组等）都是石油化工和电力等行业中的关键设备。旋转机械常常出现各种故障而影响运转，在极端情况下甚至会引发机毁人亡的严重事故，造成重大经济损失。随着科学技术的进步，旋转机械正向高速、重载和自

收稿日期 2013-06-14 收修改稿日期 2014-02-26

Manuscript received June 14, 2013; Accepted February 26, 2014  
国家自然科学基金(61273173), 北京市自然科学基金(4122029)资助  
Supported by National Natural Science Foundation of China (61273173), and Natural Science Foundation of Beijing (4122029)

本文责任编辑 刘德荣

Recommended by Associate Editor LIU De-Rong

1. 北京信息科技大学自动化学院 北京 100192, 中国 2. 美国南加州大学化学系 洛杉矶 90089-0911, 美国

1. Institute of Automation, Beijing Information Science and Technology University, Beijing 100192, China 2. Department of Chemical Engineering, University of California, Los Angeles 90089-0911, USA

动化方向发展，对速度、容量、效率和可靠性等方面有着越来越高的需求<sup>[1]</sup>。目前，尽管在旋转机械的故障检测和诊断研究方面取得了许多成果，但是尚存在一些难点问题有待进一步研究<sup>[2]</sup>，如故障预测问题等<sup>[3–9]</sup>。

现有的旋转机械故障预测方法主要包括基于传统可靠性分析的预测方法、基于实时状态监测的预测方法和两者的混合方法<sup>[3]</sup>。其中，基于传统可靠性分析的预测的方法（如威尔布分布、指数分布等）是利用设备失效时间的随机分布模型，适合于大量同批次零件的维修决策问题，却无法估计和预测某个具体旋转机械的当前健康状态。因此，利用实时状态监测的预测方法越来越得到人们的重视。现有的状态监测模型可以分为基于机理的预测模型和基于数据的预测模型两类<sup>[10]</sup>。其中，基于机理的预测模型包括基于 Paris 原理的裂纹增长模型<sup>[11]</sup>、破裂扩散初始及发展模型<sup>[12]</sup>、基于刚度的破坏模型<sup>[13]</sup>等。由于不同设备的机理模型有明显差异，而且难以中断设备的正常运行来辨识设备的模型，因此基于机理模型的预测方法在大多数工业现场并不实用。相反，基于数据的预测方法由于仅需要设备正常运行时的数据，可以在不干扰设备运行的前提下，对设备进行实时监测和故障预测。常用的基于数据的预测方法包括简单趋势预测、时间序列预测<sup>[14]</sup>、人工神经网络预测、隐马尔科夫预测<sup>[15]</sup>、基于系统辨识的方法等。利用实时的监测数据虽然能够反映设备的当前状态，但无法有效利用设备的退化统计信息，因此无法进行长期预测。结合设备的当前信息和历史统计信息，人们提出了集成当前状态和统计分布的模型，如比例风险模型<sup>[16]</sup>、比例共变量模型<sup>[17]</sup>、随机滤波模型<sup>[18]</sup>、退化扩散模型<sup>[19]</sup>和退化维纳模型<sup>[20]</sup>等。最近，Si 等<sup>[21]</sup>对基于统计数据驱动的剩余寿命预测方法进行了综述，指出了当前的研究热点和难点问题，包括针对多测量变量下的故障预测问题。Wei 等<sup>[22]</sup>针对多个传感器信息，提出了一种基于退化维纳过程的故障预测模型。

上述工作大都假定反映设备退化的变量是直接可测的，或是通过一个简单的观测方程与被测变量联系起来。但是对于一些系统只能观测到一些间接变量，而退化过程是隐含在系统的观测变量中。在假设系统模型已知的前提下，Xu 等<sup>[23]</sup>利用粒子滤波器实现了线性趋势故障的估计和预测。而当系统模型未知时，Li 等<sup>[24]</sup>将线性主元分析 (Principal component analysis, PCA) 模型用于隐含退化过程的故障估计和预测，并取得了一定成果。

由于旋转机械运行时的状态测量具有非线性特性，有必要使用非线性的数据模型。本文以大型旋转机械烟气轮机为研究对象，基于非线性模型和相关的故障重构技术，对一类因性能退化而导致的缓变故障进行初期检测和估计，并对其趋势进行预测。最后，以中国石化北京燕山分公司的实际运行故障数据进行了方法验证。结果表明，提出的方法能够有效地估计出非线性过程的故障幅值，并进行预测。

## 1 基于核主元分析模型的故障检测

### 1.1 核主元分析模型

核函数主元分析模型 (Kernel principal component analysis, KPCA) 是对主元分析模型的非线性扩展，1998 年由 Schölkopf 等<sup>[25]</sup>首次提出，2004 年 Lee 等<sup>[26]</sup>成功地将核主元分析应用于过程监控。核主元分析区别于主元分析是引入了非线性核函数映射，利用核函数把输入数据映射到高维特征空间，然后在高维空间中，按照线性主元分析模型处

理数据. 可见, 通过引入核函数, 就可以将原始测量空间中复杂的非线性问题转化为特征空间中的线性问题.

假设  $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n \in \mathbf{R}^m$  是供核主元分析学习的  $n$  个  $m$  维的列向量样本. 设非线性映射为  $\phi$ , 原始空间  $\mathbf{R}$  通过  $\phi$  映射到高维特征空间  $F^{high}$  中去. 原始数据  $\mathbf{x}_i$  在映射空间  $F^{high}$  中的像为  $\phi(\mathbf{x}_i)$ , 记  $\Phi = [\phi(\mathbf{x}_1), \phi(\mathbf{x}_2), \dots, \phi(\mathbf{x}_n)]^T$ . KPCA 做如下的特征值分解<sup>[21]</sup>:

$$C_\phi \mathbf{v} = \frac{\lambda \mathbf{v}}{n} \quad (1)$$

其中,  $C_\phi = \Phi^T \Phi / n$  为特征空间样本数据  $\phi(\mathbf{x}_i)$  的协方差矩阵.

定义  $K = \Phi \Phi^T$ ,  $\alpha = \Phi^T \mathbf{v}$ , 则有

$$K\alpha = \lambda \alpha \quad (2)$$

其中, 核矩阵  $K = (k_{ij})$  中的元素按如下定义:

$$k_{ij} = k(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j) \quad (3)$$

函数  $k(\cdot)$  即为核函数. 常用的核函数有径向基核函数、多项式核函数、Sigmoid 核函数等. 本文采用的是径向基核函数:

$$k(\mathbf{x}_i, \mathbf{x}_j) = e^{-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{c}} \quad (4)$$

对式 (2) 求解得到特征值和特征向量  $(\lambda_i, \alpha_i)$ , 根据上式可得:

$$\mathbf{v}_i = \lambda^{-1} \Phi^T \alpha_i \quad (5)$$

为了保证  $\mathbf{v}_i$  是单位向量, 需要对  $\alpha_i$  进行归一化处理:

$$\alpha_i = \sqrt{\lambda_i} \alpha_i^o \quad (6)$$

其中,  $\alpha_i^o$  表示式 (2) 中得到的单位长度的特征向量. 令  $P_f = [\mathbf{v}_1, \dots, \mathbf{v}_l]$  即为 KPCA 的载荷矩阵, 其中  $l$  为主元个数, 由累计方差贡献率确定<sup>[27]</sup>. 对于一个新样本  $\mathbf{x}$ , 可以计算其非线性主元如下:

$$\mathbf{t} = P_f^T \phi(\mathbf{x}) = \Lambda^{-\frac{1}{2}} P^T k(\mathbf{x}) \quad (7)$$

其中,  $k(\mathbf{x}) = [k(\mathbf{x}_1, \mathbf{x}), \dots, k(\mathbf{x}_m, \mathbf{x})]^T$ ,  $P = [\alpha_1, \dots, \alpha_l]$ ,  $\Lambda = \text{diag}\{\lambda_1, \dots, \lambda_l\}$ . 式 (7) 全都是可以计算的量, 因此可以用于监测.

## 1.2 基于核主元分析的故障检测指标

故障检测通常使用两种指标判断系统的工况状态, 即 Hotelling  $T^2$  统计量和平方预测误差 (Squared prediction error, SPE). 在 PCA 模型中, Hotelling  $T^2$  统计量衡量变量在主元空间的变化, SPE 指标衡量样本向量在残差子空间的投影变化. 在 KPCA 模型中, 两种检测指标都可以把故障点成功检测出来, 相对于线性 PCA 而言, KPCA 更适合非线性相关的过程监测. 在 KPCA 模型中,  $T^2$ 、SPE 可以分别计算如下<sup>[26]</sup>:

$$T^2 = k(\mathbf{x})^T P \Lambda^{-2} P^T k(\mathbf{x}) \leq T_\alpha^2 \quad (8)$$

$$\text{SPE} = k(\mathbf{x}, \mathbf{x}) - k(\mathbf{x})^T P \Lambda^{-1} P^T k(\mathbf{x}) \leq \delta_\alpha^2 \quad (9)$$

当两种指标分别超过了各自的控制限时, 就证明过程数据中出现了异常; 若在控制限内, 则证明过程数据正常.

## 1.3 归一化核矩阵

上述推导是假设在特征空间  $F$  中  $\sum_{i=1}^n \phi(\mathbf{x}_i) = 0$ , 而实际情况中  $\sum_{i=1}^n \phi(\mathbf{x}_i) \neq 0$ , 故首先需要对  $\phi(\mathbf{x}_i)$  进行均值中心化处理:

$$\begin{cases} \bar{\phi}(\mathbf{x}_i) = \phi(\mathbf{x}_i) - \frac{1}{n} \sum_{i=1}^n \phi(\mathbf{x}_i) \\ \bar{k}_{ij} = \bar{\phi}(\mathbf{x}_i)^T \bar{\phi}(\mathbf{x}_j) \end{cases} \quad (10)$$

则均值中心化后的核矩阵  $\bar{K}$  表示如下:

$$\bar{K} = K - 1_{n \times n} K - K 1_{n \times n} + 1_{n \times n} K 1_{n \times n} \quad (11)$$

式中,  $1_{n \times n}$  为  $n \times n$  矩阵, 矩阵元素为  $1/n$ . 而  $\bar{K}$  中的元素  $\bar{k}_{ij}$  可表达为如下形式:

$$\begin{aligned} \bar{k}(\mathbf{x}_i, \mathbf{x}_j) &= k(\mathbf{x}_i, \mathbf{x}_j) - k(\mathbf{x}_i)^T \mathbf{1}_n - \\ &\quad k(\mathbf{x}_j)^T \mathbf{1}_n + \mathbf{1}_n^T K \mathbf{1}_n \end{aligned} \quad (12)$$

式中,  $\mathbf{1}_n$  为  $n$  列向量, 向量元素为  $1/n$ . 归一化后的  $k(\mathbf{x})$  可以写为:

$$\bar{k}(\mathbf{x}) = (I - 1_{n \times n})(k(\mathbf{x}) - K \mathbf{1}_n) \quad (13)$$

其中,  $I$  为单位矩阵.

## 2 基于非线性故障重构的故障估计

### 2.1 故障重构的基本原理

故障重构就是重新构造去除了故障信息的过程数据, 使故障因素对该数据内正常部分的影响减至最小, 从而构造出正常状态下的数据; 故障估计就是故障重构成功后, 估计出故障的大小. 重构技术已经在故障诊断领域有了一些研究成果<sup>[27-28]</sup>.

假设正常条件下的测量数据用  $\mathbf{x}^*$  表示, 故障下的测量数据用  $\mathbf{x}$  表示,  $\mathbf{f}$  表示故障幅值的大小,  $\Xi$  表示故障的方向. 一般的故障数据可由下式表示<sup>[27]</sup>:

$$\mathbf{x} = \mathbf{x}^* + \Xi \mathbf{f} \quad (14)$$

若取 SPE 作为重构检测指标, 则故障估计的目标是寻找如下目标的最优解<sup>[28]</sup>:

$$\min_{\mathbf{f}} \text{SPE}(\phi(\mathbf{x} - \Xi \mathbf{f})) \quad (15)$$

上式是重构后变量的故障检测指标, 通过最优化方法找到使该目标函数最小化的故障, 估计  $\mathbf{f}$  就可以使重构后样本的检测指标回到正常的控制限内.

### 2.2 故障方向的提取

若故障方向未知, 需要从历史数据中提取故障方向. 令  $X_f = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{nf}]^T$  代表故障方向  $\Xi$  下的故障数据,  $\Xi \in \mathbf{R}^{m \times d}$ . 由于非线性故障数据  $\mathbf{x}_i^*$  是零均值的, 所以采用滑动平均滤波法消除其对  $\mathbf{x}_i$  的影响. 滤波后,

$$X_f^T = \Xi[\mathbf{f}_1, \mathbf{f}_2, \dots, \mathbf{f}_{nf}] \quad (16)$$

对故障数据矩阵进行奇异值分解, 得到<sup>[24]</sup>:

$$X_f^T = U D V^T \quad (17)$$

其中, 将对角阵  $D$  的非零奇异值按照降序排列, 选  $\Xi = U$ . 实际应用中,  $d$  的取值是使得故障样本的重构检测指标处于正常范围的最小值.

### 2.3 非线性故障重构及估计

为取  $\mathbf{f}$  最小值, 需将整体对  $\mathbf{f}^T$  求偏导, 在 0 点处获得极值. 参考文献 [28], 现把重构后的正常数据假设为  $\mathbf{z}$

$$\mathbf{z} = \mathbf{x} - \Xi \mathbf{f} \quad (18)$$

将式 (9) 进一步化简如下:

$$SPE = \bar{k}(\mathbf{z}_i, \mathbf{z}_i) - \bar{k}(\mathbf{z}_i)^T M \bar{k}(\mathbf{z}_i) \quad (19)$$

其中,  $M = P\Lambda^{-1}P^T$ . 将 SPE 对  $\mathbf{f}^T$  求偏导,

$$\frac{\partial SPE}{\partial \mathbf{f}^T} = \frac{\partial \bar{k}(\mathbf{z}, \mathbf{z})}{\partial \mathbf{f}^T} - \frac{\partial [\bar{k}(\mathbf{z})^T M \bar{k}(\mathbf{z})]}{\partial \mathbf{f}^T} \quad (20)$$

其中,  $\bar{k}$  是归一化后的核矩阵元素. 经推导, 式 (20) 等号右边第 1 项可写为:

$$\frac{\partial \bar{k}(\mathbf{z}, \mathbf{z})}{\partial \mathbf{f}^T} = -2 \left[ \mathbf{1}_n^T \frac{\partial k(\mathbf{z})}{\partial \mathbf{f}^T} \right] \quad (21)$$

上式中向量对故障幅值求偏导, 可以计算如下:

$$\frac{\partial k(\mathbf{z})}{\partial \mathbf{f}^T} = \frac{\partial k(\mathbf{z})}{\partial \mathbf{z}^T} \frac{\partial \mathbf{z}}{\partial \mathbf{f}^T} \quad (22)$$

由于选择的核函数是径向基函数, 因此对其求偏导如下:

$$\frac{\partial k(\mathbf{x}_i, \mathbf{z})}{\partial \mathbf{z}^T} = \frac{2}{c} k(\mathbf{x}_i, \mathbf{z}) (-\mathbf{x}_i^T + \mathbf{z}^T) \quad (23)$$

而

$$\frac{\partial \mathbf{z}}{\partial \mathbf{f}^T} = \left[ \frac{\partial \mathbf{z}}{\partial f_1}, \frac{\partial \mathbf{z}}{\partial f_2}, \dots, \frac{\partial \mathbf{z}}{\partial f_d} \right] = -\Xi \quad (24)$$

因此, 式 (22) 可写成

$$\frac{\partial k(\mathbf{z})}{\partial \mathbf{f}^T} = -\frac{2}{c} [B(\mathbf{z})\Xi - k(\mathbf{z})\mathbf{f}^T] \quad (25)$$

其中

$$B(\mathbf{z}) = \begin{bmatrix} k(\mathbf{x}_1, \mathbf{z})(\mathbf{x} - \mathbf{x}_1)^T \\ k(\mathbf{x}_2, \mathbf{z})(\mathbf{x} - \mathbf{x}_2)^T \\ \vdots \\ k(\mathbf{x}_n, \mathbf{z})(\mathbf{x} - \mathbf{x}_n)^T \end{bmatrix} \quad (26)$$

式 (20) 等号右边第 2 项可化简为:

$$\frac{\partial [\bar{k}(\mathbf{z})^T M \bar{k}(\mathbf{z})]}{\partial \mathbf{f}^T} = 2\bar{k}(\mathbf{z})^T M_s \frac{\partial \bar{k}(\mathbf{z})}{\partial \mathbf{f}^T} \quad (27)$$

将式 (27) 代入式 (20) 可得:

$$\begin{aligned} \frac{\partial SPE}{\partial \mathbf{f}^T} &= \frac{4}{c} [\mathbf{1}_n^T + \bar{k}(\mathbf{z})^T M(I - \mathbf{1}_{n \times n})] \times \\ &\quad [B(\mathbf{z})\Xi - k(\mathbf{z})\mathbf{f}^T] \end{aligned} \quad (28)$$

令上式等于零向量, 可求估计的故障幅值为

$$\mathbf{f}^T = \frac{[\mathbf{1}_n^T + \bar{k}(\mathbf{z})^T M(I - \mathbf{1}_{n \times n})]B(\mathbf{z})\Xi}{[\mathbf{1}_n^T + \bar{k}(\mathbf{z})^T M(I - \mathbf{1}_{n \times n})]k(\mathbf{z})} \quad (29)$$

当上式分母不为 0 时, 故障可以被估计; 若分母为 0, 则故障幅值无法被估计.

由式 (29) 可知, 幅值无法直接求取, 需要通过递推的方式确定. 联立式 (18) 和式 (29), 可得递推公式如下:

$$\mathbf{f}^{(j+1)} = \frac{\Xi^T B(\mathbf{z} - \Xi \mathbf{f}^{(j)})^T [\mathbf{1}_n + (I - \mathbf{1}_{n \times n})M\bar{k}(\mathbf{z} - \Xi \mathbf{f}^{(j)})]}{k(\mathbf{z} - \Xi \mathbf{f}^{(j)})^T [\mathbf{1}_n + (I - \mathbf{1}_{n \times n})M\bar{k}(\mathbf{z} - \Xi \mathbf{f}^{(j)})]} \quad (30)$$

其中, 上标括号内的  $j$  代表迭代的次数.

### 3 基于多层递阶的故障预测方法

针对时间序列的多层递阶方法大致分为 2 个步骤: 1) 对多层递阶模型的时变参数进行估计; 2) 对原始的时间序列进行预测. 由于多层递阶方法考虑了系统的时变特性, 因此预报精度有所提升<sup>[29]</sup>.

假设  $\{y(k)\}$  是一维时间序列, 且对其平稳性没有要求. 首先是建立这一时间序列的向前 1 步预测模型

$$y(k) = a_1(k)y(k-1) + \dots + a_p(k)y(k-p) + e(k) \quad (31)$$

式中,  $p$  为模型的阶数,  $e(k)$  为随机噪声. 令

$$\begin{aligned} \varphi(k) &= [y(k-1), y(k-2), \dots, y(k-p)]^T \\ \beta(k) &= [a_1(k), a_2(k), \dots, a_p(k)]^T \end{aligned} \quad (32)$$

则式 (31) 又可以写为:

$$y(k) = \varphi^T(k)\beta(k) + e(k) \quad (33)$$

用递推最小二乘的方法来估计<sup>[30]</sup>:

$$\hat{\beta}(k) = \hat{\beta}_1(k) + \frac{y(k) - \varphi^T(k)\hat{\beta}_1(k-1)}{\|\varphi(k)\|^2} \varphi(k) \quad (34)$$

其中,

$$\begin{aligned} \hat{\beta}_1(k) &= \hat{\beta}_1(k-1) + [y(k) - \varphi^T(k)\hat{\beta}_1(k-1)]M(k) \\ M(k) &= \frac{1}{\lambda + \varphi^T(k)P(k-1)\varphi(k)}P(k-1)\varphi(k) \\ P(k) &= \frac{1}{\lambda}[I - M(k)\varphi^T(k)]P(k-1) \end{aligned} \quad (35)$$

如果随机序列  $\{\beta(k)\}$  是一个多元且平稳的序列, 则  $\beta(k)$  可以写成  $\beta(k) = \beta + V(k)$  的形式. 其中,  $\beta$  是非时变的定常向量,  $\{V(k)\}$  是零均值的平稳随机序列. 此时可以应用多维平稳序列的建模方法, 建立起关于  $\{\beta(k)\}$  所满足的模型, 即自回归滑动平均模型 (Auto-regressive and moving average model, ARMA). 如此可以建立起原时间序列的系数所满足的时间序列模型. 如果  $\{\beta(k)\}$  某个分量不是平稳的, 则按照上述方法建立新的最小二乘估计获得相应的系数序列. 上述建模过程经过若干次迭代, 直到所有序列的建模残差为零均值独立同分布的随机序列; 然后利用各个阶段建立的模型, 从后往前依次预测下一步或多步的时间序列值, 得到的结果作为上一步的系数序列, 最终得到原时间序列的一步或多步预测结果.

### 4 应用研究

本文所使用的验证数据来自中国石化北京燕山分公司烟气轮机机组 4 个通道传感器 (YT-7704A、YT-7704B、YT-7706A、YT-7706B) 采集到的隐含故障过程的振动位移数据.

首先, 这 60 组 4 维振动位移数据要经过计算转换成能够表征振动的敏感因子—振动烈度值; 然后, 再用核主元分析方法对多个相关振动烈度值进行过程监测。

图 1<sup>[30]</sup> 和图 2 分别表示使用 KPCA 和 PCA 模型进行故障检测的结果, 使用 SPE 检测指标来判断故障。从图 1 和图 2 可以看出, 在 KPCA 模型下可以把故障点成功检测出来, 大约在第 31 点位置; 而 PCA 模型虽然也能检测出部分故障点, 但是会有较多的漏报。因此, KPCA 更适合非线性数据的过程监测。基于此后的 30 个故障数据, 使用本文方法进行非线性故障重构, 用以估计故障幅值。根据历史数据提取出来的故障方向向量为:

$$\Xi_{\text{KPCA}} = [-0.4999, -0.5001, -0.5002, -0.4998]^T$$

故障的维数为一维。此一维故障是烟机真正异常运行的原因。检修记录如下: 2006 年 6 月 30 日 21:06 分, 拆下导流罩, 发现一、二级静叶片和一、二级动叶片损坏, 某一根一级动叶片的杆根断裂。由于烟气轮机的高速旋转, 断裂的叶片撞上了其他未断的叶片, 造成数片静叶片受损, 而一级动叶片都出现了向右偏移的情况, 因此机组振动值、轴位移值才会急剧上升, 导致烟气轮机出现故障。而烟机叶片在长期非正常状态旋转下引起了材料的疲劳断裂, 是叶片断裂的主要原因。检修部门更换了所有转子上有裂纹的 19 只一级动叶片, 重新制作二级静叶片, 检修烟气轮机的轴瓦及全部部位, 解体检查其他地方。用 SPE 指标检验 KPCA 模型下重构后的数据, 如图 3 所示, 重构后的 SPE 值都在控制限之下, 说明基于 KPCA 模型下的重构方法能较好地重构出新的正常数据, 故障重构估计出故障幅值是可以接受的。

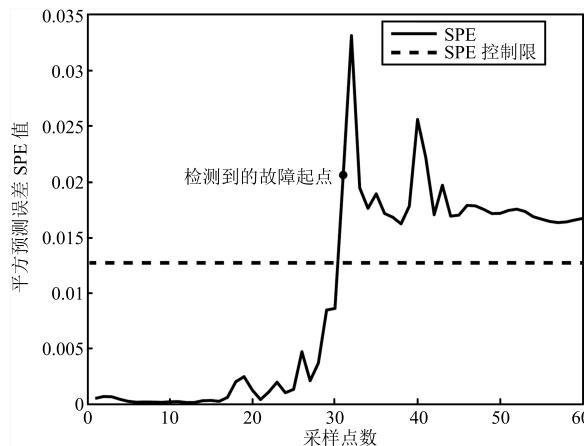


图 1 基于 KPCA 的故障检测结果

Fig. 1 Monitoring results based on KPCA

图 4 是利用非线性重构估计得到的故障幅值。由于本文数据是小样本数据, 故使用多层递阶预报方法对故障幅值的趋势进行预测。如图 4 所示, 仅预测未来 7 天的幅值情况, 预测步数为 1 步, 即提前一天进行故障幅值的预测。从图 4 可以看出, 预测精度较好, 可以符合要求。

## 5 结论

本文针对带有隐含退化故障的非线性过程, 提出了基于核主元分析模型的故障重构及预测算法。该方法建立在一个简单的故障描述上, 利用已有的故障检测框架, 得到相应的故障重构结果, 并准确估计出故障的幅值。由于该故障幅值

是故障对过程的综合影响, 难以获得统计分布, 因此只适合数据驱动的方法进行短期预测。本文利用针对时变过程的多层次递阶方法加以短期预测, 然后以北京燕山石化烟气轮机机组为案例, 验证了提出的重构和预测方法的有效性。

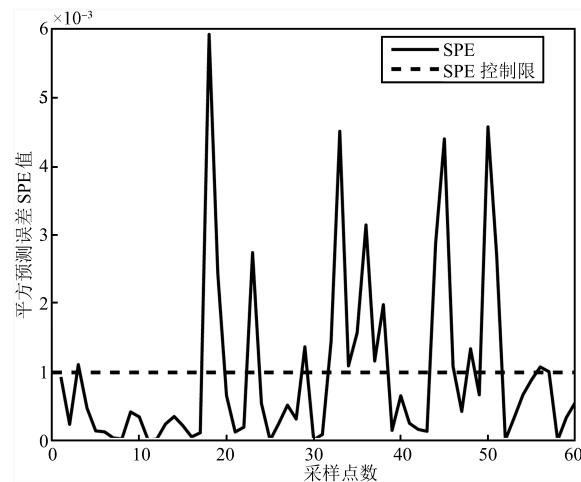


图 2 基于 PCA 模型的故障检测结果

Fig. 2 Monitoring results based on PCA

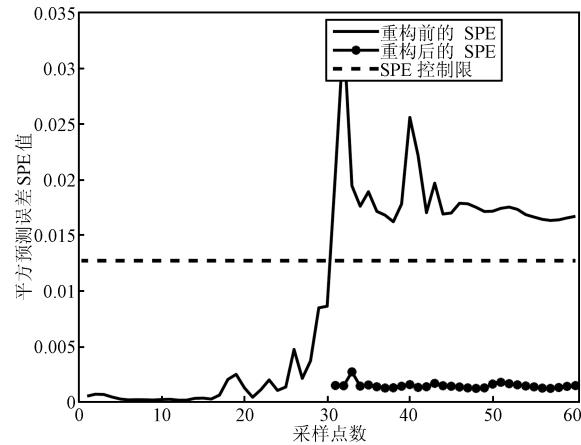


图 3 KPCA 模型下, 故障重构前后的 SPE

Fig. 3 SPE before and after reconstruction based on KPCA

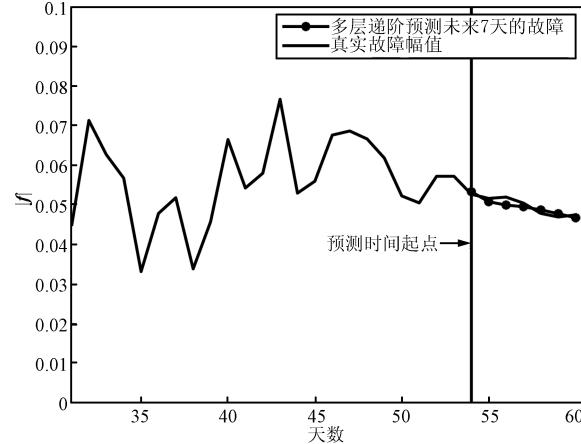


图 4 基于多层次递阶方法的故障幅值的趋势预测

Fig. 4 Fault prediction based on multi-level recursive model

## References

- 1 Wen Bang-Chun, Wu Xin-Hua, Ding Qian, Han Qing-Kai. *Theory and Experiments of Nonlinear Dynamics for Faulty Rotating Machinery*. Beijing: Science Press, 2004.  
(闻邦椿, 武新华, 丁干, 韩清凯. 故障旋转机械非线性动力学的理论与试验. 北京: 科学出版社, 2004.)
- 2 Ma Jie, Xu Xiao-Li, Zhou Dong-Hua. Survey of fault prediction methods for rotating machineries. *Process Automatica Instrumentation*, 2011, **32**(8): 1–3  
(马洁, 徐小力, 周东华. 旋转机械的故障预测方法综述. 自动化仪表, 2011, **32**(8): 1–3)
- 3 Zhou Dong-Hua, Hu Yan-Yan. Fault diagnosis techniques for dynamic systems. *Acta Automatica Sinica*, 2009, **35**(6): 748–758  
(周东华, 胡艳艳. 动态系统的故障诊断技术. 自动化学报, 2009, **35**(6): 748–758)
- 4 Zhou Dong-Hua, Chen Mao-Yin, Xu Zheng-Guo. *The Reliability Prediction and Optimal Maintenance Technology*. Hefei: Press of University of Science and Technology of China, 2013.  
(周东华, 陈茂银, 徐正国. 可靠性预测与最优维护技术. 合肥: 中国科学技术大学出版社, 2013.)
- 5 Fan Ji-Cong, Wang You-Qing, Qin Si-Zhao. Combined indices for ICA and their applications to multi-variate process fault diagnosis. *Acta Automatica Sinica*, 2013, **39**(5): 494–501  
(樊继聰, 王友清, 秦泗钊. 联合指标独立成分分析在多变量过程故障诊断中的应用. 自动化学报, 2013, **39**(5): 494–501)
- 6 Zhou Dong-Hua, Liu Yang, He Xiao. Review on fault diagnosis techniques for closed-loop systems. *Acta Automatica Sinica*, 2013, **39**(11): 1933–1943  
(周东华, 刘洋, 何潇. 闭环系统故障诊断技术综述. 自动化学报, 2013, **39**(11): 1933–1943)
- 7 Zhou Dong-Hua, Shi Jian-Tao, He Xiao. Review of intermittent fault diagnosis techniques for dynamic systems. *Acta Automatica Sinica*, 2014, **40**(2): 161–171  
(周东华, 史建涛, 何潇. 动态系统间歇故障诊断技术综述. 自动化学报, 2014, **40**(2): 161–171)
- 8 Zhou Dong-Hua, Wei Mu-Heng, Si Xiao-Sheng. A survey on anomaly detection, life prediction and maintenance decision for industrial processes. *Acta Automatica Sinica*, 2013, **39**(6): 711–722  
(周东华, 魏慕恒, 司小胜. 工业过程异常检测, 寿命预测与维修决策的研究进展. 自动化学报, 2013, **39**(6): 711–722)
- 9 Si Xiao-Sheng, Hu Chang-Hua, Zhou Dong-Hua. Nonlinear degradation process modeling and remaining useful life estimation subject to measurement error. *Acta Automatica Sinica*, 2013, **39**(5): 530–541  
(司小胜, 胡昌华, 周东华. 带测量误差的非线性退化过程建模与剩余寿命估计. 自动化学报, 2013, **39**(5): 530–541)
- 10 Heng A, Zhang S, Tan A C C, Mathew J. Rotating machinery prognostics: state of the art, challenges and opportunities. *Mechanical Systems and Signal Processing*, 2009, **23**(3): 724–739
- 11 Li C J, Lee H. Gear fatigue crack prognosis using embedded model, gear dynamic model and fracture mechanics. *Mechanical Systems and Signal Processing*, 2005, **19**(4): 836–846
- 12 Kacprzynaki G J, Sarlashkar A, Roemer M J, Hess A, Hardman B. Predicting remaining life by fusing the physics of failure modeling with diagnostics. *Journal of the Minerals Metals and Materials Society*, 2004, **56**(3): 29–35
- 13 Qiu J, Set B B, Liang S Y, Zhang C. Damage mechanics approach for bearing lifetime prognostics. *Mechanical Systems and Signal Processing*, 2002, **16**(5): 817–829
- 14 Wang W. An adaptive predictor for dynamic system forecasting. *Mechanical Systems and Signal Processing*, 2007, **21**(2): 809–823
- 15 Dong M, He D. A segmental hidden semi-Markov model (HSMM)-based diagnostics and prognostics framework and methodology. *Mechanical Systems and Signal Processing*, 2007, **21**(5): 2248–2266
- 16 Jardine A K S, Lin D, Banjevic D. A review on machinery diagnostics and prognostics implementing condition-based maintenance. *Mechanical Systems and Signal Processing*, 2006, **20**(7): 1483–1510
- 17 Sun Y, Ma L, Mathew J, Wang W, Zhang S. Mechanical systems hazard estimation using condition monitoring. *Mechanical Systems and Signal Processing*, 2006, **20**(5): 1189–1201
- 18 Wang W B, Zhang W J. A model to predict the residual life of aircraft engines based upon oil analysis data. *Naval Research Logistics*, 2005, **52**(3): 276–284
- 19 Si X S, Wang W B, Hu C H, Zhou D H, Pecht M G. Remaining useful life estimation based on a nonlinear diffusion degradation process. *IEEE Transactions on Reliability*, 2012, **61**(1): 50–67
- 20 Si X S, Wang W, Hu C H, Chen M Y, Zhou D H. A Wiener-process-based degradation model with a recursive filter algorithm for remaining useful life estimation. *Mechanical Systems and Signal Processing*, 2013, **35**(1–2): 219–237
- 21 Si X S, Wang W, Hu C H, Zhou D H. Remaining useful life estimation—a review on the statistical data driven approaches. *European Journal of Operational Research*, 2011, **213**(1): 1–14
- 22 Wei M H, Chen M Y, Zhou D H. Multi-sensor information based remaining useful life prediction with anticipated performance. *IEEE Transactions on Reliability*, 2013, **62**(1): 183–198
- 23 Xu Z G, Ji Y D, Zhou D H. Real-time reliability prediction for a dynamic system based on the hidden degradation process identification. *IEEE Transactions on Reliability*, 2008, **57**(2): 230–242
- 24 Li G, Qin S J, Ji Y D, Zhou D H. Reconstruction based fault prognosis for continuous processes. *Control Engineering Practice*, 2010, **18**(10): 1211–1219

- 25 Schölkopf B, Smola A, Müller K R. Nonlinear component analysis as a kernel eigenvalue problem. *Neural Computation*, 1998, **10**(5): 1299–1319
- 26 Lee J M, Yoo C K, Choi S W, Vanrolleghem P A, Lee I B. Nonlinear process monitoring using kernel principal component analysis. *Chemical Engineering Science*, 2004, **59**(1): 223–234
- 27 Dunia R, Qin S J. Subspace approach to multi-dimensional fault identification and reconstruction. *AICHE Journal*, 1998, **44**(8): 1813–1831
- 28 Alcalá C F, Qin S J. Reconstruction based contribution for process monitoring with kernel principal component analysis. *Industrial & Engineering Chemistry Research*, 2010, **49**(17): 7849–7857
- 29 Han Zhi-Gang. A new method of dynamic system prediction. *Acta Automatica Sinica*, 1983, **9**(3): 161–168  
(韩志刚. 动态系统预报的一种新方法. 自动化学报, 1983, **9**(3): 161–168)
- 30 Chen Mo, Ma Jie. Nonlinear fault prognosis for stack gas turbine machine based on KPCA-MLR. *Journal of Beijing Information Science and Technology University*, 2013, **28**(1): 30–35  
(陈默, 马洁. 基于 KPCA-MLR 的烟气轮机非线性故障预测. 北京信息科技大学学报, 2013, **28**(1): 30–35)

马洁 北京信息科技大学自动化学院教授. 主要研究方向为数据驱动的过程监控, 故障预测. 本文通信作者. E-mail: mjbeijing@163.com  
(**MA Jie** Professor at the Institute of Automation, Beijing Information Science and Technology University. Her research interest covers data driven process monitoring, and fault prediction. Corresponding author of this paper.)

李钢 美国南加州大学化工系博士后. 主要研究方向为数据驱动的过程建模, 监控, 控制及预测. E-mail: gli816@usc.edu  
(**LI Gang** Postdoctoral at the Mork Family Department of Chemical Engineering, University of Southern California, USA. His research interest covers data driven modeling, monitoring, control and prediction.)

陈默 北京信息科技大学硕士研究生. 主要研究方向为统计过程监测和故障预测. E-mail: 651788@sina.com  
(**CHEM MO** Master student at Beijing Information Science and Technology University. Her research interest covers statistical process monitoring and fault prediction.)