

一类设备故障过程的故障趋势预测方法研究

李 钢, 周东华

(清华大学 自动化系, 北京 100084)

摘要:研究了一类带有指数故障过程的故障趋势预测问题。在测量变量受到平稳噪声干扰的情况下,首先依据对测量数据的统计检验判断出故障过程,然后根据对故障过程的先验知识,利用强跟踪滤波器辨识指数趋势项的参数,同时对建模误差进行 ARMA 时序分析,最后结合趋势项和时序预测给出故障趋势的总体预测。仿真实验结果验证了该方法的有效性。

关键词:故障过程; 趋势预测; 非平稳 ARMA 过程; 强跟踪滤波

中图分类号: TP273 **文献标识码:**A **文章编号:**1009-3516(2007)04-0005-04

机器设备的故障过程检测和故障趋势分析是对现代设备实行动态管理的关键技术,用该技术可以对机器整体和特定部件的故障进行预测,提早做好预防措施^[1]。设备的故障预测常常采用特征参数跟踪法,即根据所监测的特征参数的历史和当前数据,推断未来某时刻的特征参数值,并确定设备发生故障的可能性,此方法适合在线预报^[2]。

预测实质上是对动态数据进行建模的过程,所建立的模型称为预测模型。用预测模型描述机械设备的发展趋势推知设备将来行为,在此基础上根据事先制定的停机阈值,能确定设备安全运行的时间,估算设备使用寿命^[2]。预测的一个关键问题是建立符合实际的预测模型,目前常用的模型有曲线拟合,时间序列模型,滤波模型,灰色模型,神经网络模型,模糊模型,支持向量机等。

预测的另一个关键问题是检测故障过程的发生以及对预测模型做相应调整。由于发生故障后系统模型发生变化,预测模型也需要进行相应的改变。而上述的绝大多数方法都是假设故障已经发生,并且用大量故障过程的数据来建模,回避了故障发生前期快速建立新的故障预测模型的需求,因此在实际应用中实时性不强。

1 问题描述

本文考虑的设备特殊监测参数是一个非平稳的时间序列。可由时间序列的经典分解式表示^[3-4]:

$$y_t = m_t + s_t + x_t \quad (1)$$

式中: m_t 是缓慢变化的趋势项; s_t 是已知周期为 d 的周期项; x_t 为平稳随机项。特别地,本文中考虑的 m_t 为指数规律趋势项,周期项为 0。考虑到故障过程发生的时间未知,因此用到的故障预测模型如下式表示:

$$y(t) = \begin{cases} c + x_1(t), & t \leq \tau \\ c + m(t) + x_2(t), & t > \tau \end{cases} \quad (2)$$

式中: $x_1(t)$ 和 $x_2(t)$ 为故障发生前后两个不同的平稳 ARMA 过程, τ 是故障过程开始的时间。 $m(t)$ 为指数趋势项 $m(t) = \theta_1 e^{\theta_2 t}$, c 为常数。

收稿日期:2007-03-29

基金项目:国家自然科学基金资助项目(60574084)

作者简介:李 钢(1983-),男,江西南昌人,博士生,主要从事基于数据的故障趋势预测研究;

周东华(1963-),男,江苏江阴人,教授,博士生导师,主要从事系统辨识、故障诊断与容错控制、智能维护系统等研究。

2 指数故障过程趋势预测方法

2.1 ARMA 模型预测

对于一个剔除了趋势项的零均值平稳时间序列,我们可以用如下 ARMA 模型来建模:

$$\gamma_t + \phi_1 \gamma_{t-1} + \cdots + \phi_p \gamma_{t-p} = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \cdots + \theta_q \varepsilon_{t-q} \quad (3)$$

式中: p 和 q 分别是自回归部分和滑移平均部分的阶数; $\phi_i (i=1,2,\dots,p), \theta_j (j=1,2,\dots,q)$ 分别是自回归系数和滑移平均系数; ε_t 为零均值、方差为 σ^2 的独立同分布白噪声序列^[4]。完整的 ARMA 模型求解包括模型定阶,确定 p 和 q 使得拟合优度度量 AICC 最小;其次用极大似然估计或者最小二乘法估计相应的系数和白噪声的方差。

由于 ARMA(p,q)模型定阶比较复杂,计算时间长,不便于在线计算。理论研究表明任何一个 ARMA (p,q)模型都可以用一个无穷阶的 AR 或 MA 模型来表示。因此在容许的误差之内,所求的 ARMA 模型可以由一个高阶 AR(p)模型拟合。本文采用递推最小二乘法来估计一个高阶的 AR(p)模型^[5]。

2.2 强跟踪滤波器(STF)

根据问题描述,检测到故障过程需要估计趋势项的参数 θ 。相应的非线性系统方程如下:

$$\begin{cases} \theta(k+1) = \theta(k) \\ y(k) = h(\theta, k) + x(k) \end{cases} \quad (4)$$

式中: $\theta(k)$ 为趋势项参数,在这里为滤波器要估计的状态; $y(k)$ 为观测值, $x(k)$ 为平稳随机噪声。 $h(\theta, k) = \theta_1 \exp(\theta_2 k)$ 是趋势项,是 θ 和 k 的非线性函数。

上述系统的状态估计可以用著名的扩展卡尔曼滤波器来解决(EKF):

$$\hat{\theta}(k+1|k+1) = \hat{\theta}(k+1|k) + K(k+1) \gamma(k+1) \quad (5)$$

式中: $\hat{\theta}(k+1|k) = \hat{\theta}(k|k)$ 为状态一步预报值。增益阵:

$$\begin{aligned} K(k+1) &= P(k+1|k) H^T(k+1, \hat{\theta}(k+1|k)) [H(k+1, \hat{\theta}(k+1|k)) P(k+1|k) H^T(k+1, \hat{\theta}(k+1|k)) + \\ &R(k+1)]^{-1} \end{aligned} \quad (6)$$

预报误差协方差阵:

$$P(k+1|k) = F(\hat{\theta}(k|k)) P(k|k) F^T(\hat{\theta}(k|k)) \quad (7)$$

误差序列:

$$\gamma(k+1) = y(k+1) - \hat{y}(k+1) = y(k+1) - h(k+1, \hat{\theta}(k+1|k)) \quad (8)$$

式(6)中:

$$H(k+1, \hat{\theta}(k+1|k)) = \frac{\partial h(k+1, \theta(k+1))}{\partial \theta} \Big|_{\theta(k+1) = \hat{\theta}(k+1|k)} \quad (9)$$

式(7)中:

$$F(\hat{\theta}(k|k)) = \frac{\partial \theta}{\partial \theta} \Big|_{\theta = \hat{\theta}(k|k)} = [1, 1]' \quad (10)$$

如果状态估计的初值比较合适的话,上述的 EKF 能够给出比较准确的估计 $\theta(k|k)$ 。但是由于趋势项的参数初值是未知的,并且需要短时间内快速估计出来。采用强跟踪滤波器可以解决这一问题。

将残差序列强制保持相互正交,可以使得滤波器保持对状态的突变跟踪。为此,修改上面 EKF 中的式(7)为

$$P(k+1|k) = \lambda(k+1) F(\hat{\theta}(k|k)) P(k|k) F^T(\hat{\theta}(k|k)) \quad (11)$$

其中 $\lambda(k+1)$ 为次优渐消因子,可由下式近似得到:

$$\lambda_0 = \frac{\text{tr}[N(k+1)]}{\text{tr}[M(k+1)]} \quad (12)$$

$$N(k+1) = V_0(k+1) - \beta R(k+1) \quad (13)$$

$$M(k+1) = H(k+1, \hat{\theta}(k+1|k)) F(\hat{\theta}(k|k)) P(k|k) F^T(\hat{\theta}(k|k)) H^T(k+1, \hat{\theta}(k+1|k)) \quad (14)$$

$$V_0(k+1) = \frac{\gamma(1)\gamma^T(1)}{[\rho V_0(k) + \gamma(k+1)\gamma^T(k+1)]} \quad (15)$$

式中: ρ 为遗忘因子,通常取 0.95; β 为事先给定的弱化因子,在 0 到 1 之间。

2.3 故障过程检测算法

由问题描述可知,故障过程发生前,特征参数序列是一个平稳时间序列;而故障发生之后,特征参数序列是一个非平稳时间序列。因此只要检测时间序列的各阶统计量即可。通常检测序列的均值或者方差,如果变化则可以启动故障趋势预测过程。用 $\hat{\mu}$ 表示均值,则 $\hat{\mu}(k) = \frac{1}{l} \sum_{i=k-l}^k y(i)$, 其中 l 为统计长度,用 $\hat{\mu}(k)$ 和标称值比较,当差值超过给定的阈值(由序列的方差给定)时,断定检测到故障过程。对于评价预测的精度,采用如下的误差计算公式: $\frac{1}{n} \sum_{i=k}^n |\frac{y_i - y_i^*}{y_i}|$, 其中 k 为故障过程发生的时刻, y_i, y_i^* 分别表示真值和预测值。

2.4 一步预报和多步预报

根据 ARMA 模型预测和滤波器的滤波结果可以获得一步预报和多步预报值。 $\hat{y}(k+p|k) = \hat{\theta}_1(k|k) \exp(\hat{\theta}_2(k|k) \times (k+p)) + \hat{x}_2(k+p|k)$, 其中 p 为预报步数。 $\hat{x}_2(k+p|k)$ 为第二个 ARMA 模型的多步预报结果。当 $p=1$ 时是一步预报, $p>1$ 时为多步预报。

3 仿真

为了验证上述故障趋势预测方法的有效性,本文做了下面的仿真实验:

仿真实系统如式(2)所确定,其中 $x_1(t) = 0.2x_1(t-1) + 0.63x_1(t-2) + e(t)$, $x_2(t) = 0.8x_2(t-1) - 0.15x_2(t-1) + e(t)$, $e(t)$ 为零均值,方差为 $1/12$ 的均匀分布白噪声序列。 $m(t) = a(\exp(b(t-\tau)) - 1)$, 其中 $a=5, b=1/100, \tau=150$ s, $c=100$; 仿真时间为 350 s。

先用未发生故障的数据估计 c ,用递推最小二乘法估计 AR(p)模型,同时检测均值的变化。检测到故障过程后,用 STF 算法估计趋势项的参数,同时对建模残差用递推最小二乘法估计改变后的 AR(p)模型。最后,结合趋势项的预报值和 AR(p)模型的预报值可以获得故障趋势的一步和多步预报。

仿真实结果由图 1-3 显示。图 1 显示了该方法所求得的预报值。采用上述的误差计算方式,一步预测的预测误差为 1.6%, 20 步预测的预测误差为 5.59%。这个结果说明该方法增加预测步数对预测精度造成的损失不大,提高了预测的实时性。图 2 ARMA 模型参数的估计曲线。由图可见,参数估计基本上收敛。图 3 是对建模残差的 ARMA 模型拟合程度的检验,当绝大多数点位于置信区间内,表示 ARMA 模型的拟合是可靠的。

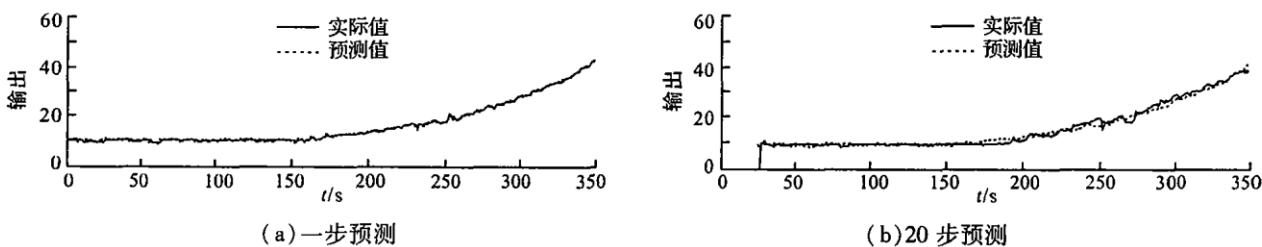


图 1 一步预测与多步预报

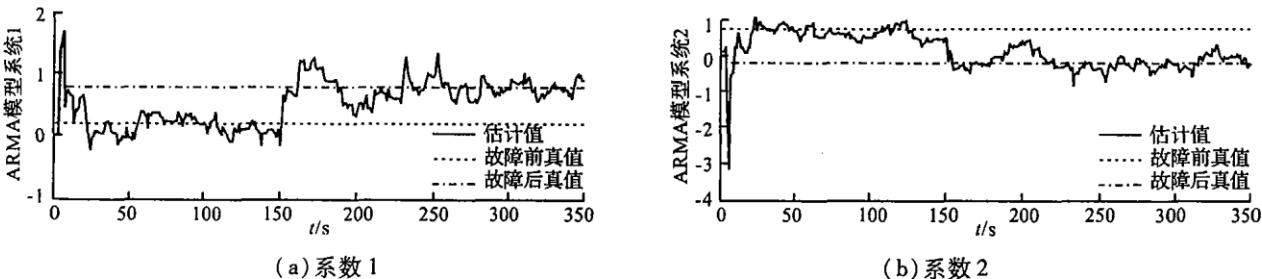


图 2 ARMA 模型参数估计结果

4 结论

本文针对一类指数增长故障过程,研究了在线的故障趋势预测方法。本文提出的方法基于 ARMA 时序分析和强跟踪滤波方法,在检测到故障过程后,迅速估计出趋势项的参数,并对建模残差进行时序分析,结合两者的预报值可以获得最终的预报结果。计算机仿真结果验证了本文方法的有效性。

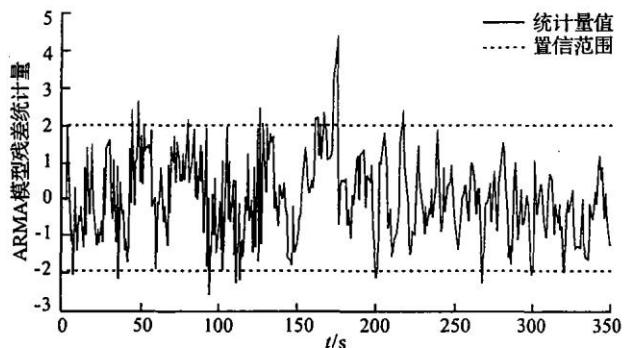


图 3 ARMA 模型拟合程度检验

参考文献:

- [1] 徐小力,徐勇,王信义.机器状态趋势分析及在注水机组上的应用[J].北京理工大学学报,1998,18(4): 441 - 443.
- [2] 薛子云,杨江天,朱衡君.机械故障预测模型综述[J].机械强度,2006,28(s):60 - 65.
- [3] 吴庚申,梁平,龙新峰.基于 ARMA 的汽轮机转子振动故障序列的预测[J].华南理工大学学报,2005,33(7): 67 - 73.
- [4] BrockWell Peter J, Davis Richard A. Time Series: Theory and Methods [M]. Second Edition. Heidelberg: Springer, 2001.
- [5] 邓自立.自校正滤波理论及其应用[M].哈尔滨:哈尔滨工业大学出版社.
- [6] 周东华,叶银忠.现代故障诊断与容错控制[M].北京:清华大学出版社, 2000.

(编辑:姚树峰)

Study on a Fault Trend Prediction Method for a Class of Device Fault Processes

LI Gang, ZHOU Dong-hua

(Department of Automation, Tsinghua University, Beijing 100084, China)

Abstract: A fault trend prediction problem for a class of exponential fault process is studied. Under the condition that the measure variable is disturbed by a stationary noise, the fault process is detected by statistical analysis of the measurement firstly. According to the model assumption, the parameters of the fault trend process can be obtained by using STF (strong tracing filter). After the extraction of trend component, the modeling error series becomes a stationary series, which can be used for normal ARMA time series analysis. Finally, the whole prediction can be acquired by combining trend prediction and time series analysis. Computer simulations validate the effectiveness of the proposed method.

Key words: fault process; trend prediction; non - stationary ARMA process; STF