

文章编号: 1001-0920(2009)03-0477-04

基于 SVM 和 Kalman 预测的非线性系统故障预报

曹玉苹, 田学民

(中国石油大学(华东)信息与控制工程学院, 山东 东营 257061)

摘要: 针对 Kalman 预测在非线性系统故障预报中预测误差较大的问题, 提出一种基于支持向量机预测新息的 Kalman 预测方法. 根据未知非线性系统的典型变量分析子空间模型进行 Kalman 预测, 采用支持向量机时间序列预测算法预测未来时刻的新息, 利用新息进行 Kalman 单步和多步预报. 在连续搅拌反应器上的仿真研究表明: 所提出方法能准确地预测较长时间段内故障过程的劣化趋势, 预知可能发生的故障, 使操作人员有时间采取必要措施消除故障隐患.

关键词: 非线性系统; 故障预报; Kalman 预测; 支持向量机

中图分类号: TP273

文献标识码: A

Nonlinear system fault prognosis based on SVM and Kalman predictor

CAO Yurping, TIAN Xue-min

(College of Information and Control Engineering, China University of Petroleum (East China), Dongying 257061, China. Correspondent: TIAN Xue-min, E-mail: tianxm@hdpu.edu.cn)

Abstract: For Kalman predictor performing worse in nonlinear system fault prognosis, a Kalman predictor with innovation predicted by support vector machine is presented. Kalman predictor is conducted with canonical variate analysis subspace model. Time series support vector machine is trained to predict future innovation. Then, one step ahead and multi-step ahead fault prognosis are implemented by Kalman predictor with future innovation. The simulation results on CSTR indicate that the proposed method can predict the deterioration trend of fault process accurately, prognose possible fault, and gain maintenance time for operators.

Key words: Nonlinear system; Fault prognosis; Kalman prediction; Support vector machine

1 引言

在工业生产过程中,故障会带来长期的扰动,破坏生产设备甚至导致停工.一些灾难性的故障会污染环境,造成巨额经济损失,甚至对人的生命形成威胁.大部分故障在造成严重影响之前存在一个缓变的过程,即故障发生后,过程按一定的趋势轨迹缓慢变化到达一个新的稳定状态,或逐渐恶化直至崩溃.故障预报技术预测过程的劣化趋势,提前预知过程的状态,对即将发生的故障进行报警,使得操作人员有时间采取必要的措施避免事故的发生.因此,故障预报技术对于增强系统故障早期的发现能力,提高过程的安全性和可靠性具有重要意义.

Saeks 等早在 1979 年就开始故障预报方面的

研究,直到 20 世纪 90 年代中期才发表了多篇故障预报的文献,主要集中在基于状态的机械预测维修领域.2000 年以后,故障预报技术成为国内的研究热点之一^[1-5].传统的非线性预测主要采用扩展卡尔曼滤波(EKF),但线性化导致精度下降,并且计算复杂.近年来,UKF(Unscented Kalman Filter)在非线性的估计领域得到广泛应用^[6],该方法有效地解决了上述问题.EKF 和 UKF 均要求系统模型已知,并且非线性系统建模费力费时.

本文采用典型变量分析子空间辨识,获得未知非线性系统的局部线性化模型.针对故障信息以及预测新息未知引起的预测误差较大的问题,提出一种基于新息预测的改进 Kalman 预测方法.

收稿日期: 2008-01-25; 修回日期: 2008-06-18.

基金项目: 国家 863 计划项目(2007AA04Z193); 山东省自然科学基金项目(Y2007G49).

作者简介: 曹玉苹(1982—),女,山东单县人,博士生,从事化工过程故障检测与诊断的研究; 田学民(1955—),男,山东文登人,教授,博士生导师,从事过程动态模拟、先进控制与优化等研究.

2 基本 Kalman 预测

Kalman 滤波器广泛应用于状态估计及相关领域. 选取相应的时间设置可得到预测器^[7]. 本文首先基于典型变量分析子空间辨识方法, 建立未知系统的状态空间模型及噪声的统计特性.

2.1 典型变量分析子空间辨识

子空间辨识方法是近年来新兴的一种模型辨识方法. 该方法计算简单, 适用于多变量系统^[8]. 典型变量分析 (CVA) 子空间辨识算法是其中的一种, 该方法利用 CVA 提取状态变量, 通过最小二乘法估计模型矩阵^[9]. CVA 子空间辨识方法可根据测量数据自动获得非线性系统的局部线性化模型

$$\begin{cases} x(k+1) = Ax(k) + Bu(k) + w(k), \\ y(k) = Cx(k) + Du(k) + v(k). \end{cases} \quad (1)$$

其中: $w(k) \sim N(0, Q)$, $v(k) \sim N(0, R)$.

2.2 基本 Kalman 预测在故障预报中存在的问题

假设非线性系统模型为

$$\begin{cases} x(k+1) = f(x(k), u(k), (k)), \\ y(k) = h(x(k), u(k)). \end{cases} \quad (2)$$

其中 (k) 为未知故障, 正常情况下 $(k) = 0$. 将式 (2) 在 $x = x_0$ 附近展开, 得

$$\begin{cases} x(k+1) = Ax(k) + Bu(k) + (k), \\ y(k) = Cx(k) + Du(k) + (k). \end{cases} \quad (3)$$

其中: (k) 表示状态方程中的故障项和高次项, (k) 表示输出方程中的故障项和高次项, 输出

$$y(k) = y_0(k) + y_{N+F}(k). \quad (4)$$

式中: $y_0(k) = Cx(k) + Du(k)$ 表示输出的局部线性化部分, $y_{N+F}(k) = (k)$ 表示输出的非线性部分和故障的影响. 假设输入序列已知, 对线性化模型进行 Kalman 预测, 有

$$\begin{cases} \hat{x}(k+1) = A\hat{x}(k) + Bu(k), \\ \hat{y}(k+1) = C\hat{x}(k+1) + Du(k+1), \\ (k+1) = y(k+1) - \hat{y}(k+1), \\ \hat{x}(k+1) = \\ \hat{x}(k+1) + K(k+1)(k+1). \end{cases} \quad (5)$$

其中预测新息 (k) 对应于非线性部分和故障的影响 $y_{N+F}(k)$. 在单步和多步预测中, 由于未来时刻的输出未知, 取新息 $(k) = 0$ ^[4]. 因此 Kalman 预测失去修正功能退化为基本的迭代, 导致较大的预测误差.

3 基于 SVM 新息预测的 Kalman 预测

针对基本 Kalman 预测在故障预报中存在的问题, 本文提出利用支持向量机时间序列模型预测未来时刻的新息, 综合运用 Kalman 预测方法和支持向量机时间序列模型预测方法估计故障过程的劣化趋势.

3.1 基于支持向量机的时间序列预测

支持向量机 (SVM) 是一种基于统计学习理论的机器学习算法. SVM 不但能较好地解决小样本、过学习、高维数、局部最优等实际难题, 而且具有很强的泛化能力^[10].

利用支持向量机进行时间序列预测的关键是拟合测量变量的时序关系. 将过去时刻的测量值 $x(k) = [x(k), x(k-1), \dots, x(k-p+1)]$ 作为输入, 未来时刻的测量值 $x(k+1)$ 作为输出, 基于支持向量机回归建立 $x(k+1)$ 关于 $x(k)$ 的时间序列映射关系 $f: R^p \rightarrow R$, 其中 p 为嵌入维数. 根据 n 个测量数据构造支持向量机的输入输出学习样本

$$X = \begin{bmatrix} x(p) \\ x(p+1) \\ \dots \\ x(n-1) \end{bmatrix} = \begin{bmatrix} x(p) & x(p-1) & \dots & x(1) \\ x(p+1) & x(p) & \dots & x(2) \\ \dots & \dots & \ddots & \dots \\ x(n-1) & x(n-2) & \dots & x(n-p) \end{bmatrix},$$

$$Y = \begin{bmatrix} x(p+1) \\ x(p+2) \\ \dots \\ x(n) \end{bmatrix}.$$

通过训练得到预测函数

$$x(k) = f(x(k-1)) = \sum_{i=p}^{n-1} (i - i^*) K(x(i), x(k-1)) + b, \quad (6)$$

根据预测函数计算单步预测值

$$\hat{x}(k+1) = f(x(k)) = \sum_{i=p}^{n-1} (i - i^*) K(x(i), x(k)) + b. \quad (7)$$

将预测值 $\hat{x}(k+1)$ 作为下一步预测的已知条件, 构造输入

$$x(k+1) = [\hat{x}(k+1), x(k), \dots, x(k-p+2)],$$

套用预测函数 (6) 可得未来 2 步的预测值 $\hat{x}(k+2)$. 后续各步预测依此类推.

3.2 故障预报

基于改进 Kalman 预测器的故障预报思路是: 首先利用故障初期的过程数据建立新息的 SVM 时间序列模型; 然后将 CVA 子空间模型的 Kalman 预测与 SVM 新息预测相结合, 预测非线性故障过程的劣化趋势. 系统的单步预测分为如下预测和修正两个步骤:

1) 预测: 根据 CVA 子空间模型预测未来时刻的状态和输出

$$\begin{cases} \hat{x}^-(k+1) = A\hat{x}^-(k) + Bu(k), \\ \hat{y}^-(k+1) = C\hat{x}^-(k+1) + Du(k+1). \end{cases} \quad (8)$$

根据 SVM 时间序列模型预测未来时刻的新息

$$\hat{y}^-(k+1) = f(k, (k-1), \dots, (k-p+1)). \quad (9)$$

2) 修正:利用新息修正输出和状态

$$\hat{y}(k+1) = \hat{y}^-(k+1) + \hat{y}^-(k+1), \quad (10)$$

$$\hat{x}(k+1) = \hat{x}^-(k+1) + K\hat{y}^-(k+1). \quad (11)$$

式(11)利用 SVM 时间序列预测的新息值 $\hat{y}^-(k+1)$ 作为未来时刻的 Kalman 预测新息,使得 Kalman 预测具备修正功能.未来 N 步预测按照单步预测进行迭代即可.

4 仿真研究

选取连续搅拌反应器(CSTR)作为研究对象,运用本文提出的方法进行故障预报.CSTR 可用下述一阶非线性微分方程组描述:

$$\frac{dC_A}{dt} = -k_0 e^{-E/RT} C_A + \frac{F(C_F - C_A)}{V}, \quad (12)$$

$$\frac{dT}{dt} = \frac{(-H)k_0 e^{-E/RT} C_A}{C_p} + \frac{F(T_F - T)}{V} + \frac{UA(T_J - T)}{V C_p}. \quad (13)$$

其中: T 为输出, T_J 和 F 为输入,采样周期为0.1 min.反应器参数参见文献[4].

根据表 1 模拟 4 种缓慢变化型故障.温度阈值设定为 384 ± 10 K,当 T 在阈值范围内波动时认为系统正常,超出时认为系统发生故障.

表 1 故障模式

故障 1	进料浓度斜坡上升	$C_F + 0.01(\text{mol/l})/\text{min}, k > 101$
故障 2	进料温度斜坡上升	$T_F + 1 \text{ K}/\text{min}, k > 101$
故障 3	催化剂活性降低	$E/R + 3 \text{ K}/\text{min}, k > 101$
故障 4	热交换器结垢	$UA-125(\text{J}/(\text{min} \cdot \text{K}))/\text{min}, k > 101$

定义在 k 时刻进行的 N 步预测的误差

$$\tilde{y}(k+N/k) = |y(k+N) - \hat{y}(k+N/k)|, N = 1, 2, \dots;$$

最大预测步长

$$N_{\max} = \max\{N / \tilde{y}(k+N/k) \mid 1 \text{ K}, N = 1, 2, \dots\}.$$

使用 UKF 方法预测故障过程的变化趋势.以故障 1 为例,UKF 预测效果如图 1 所示.其中: $k < 201$ 时刻为单步预测值, $k > 201$ 时刻为未来多步预报值.由于缺少新息项的修正,预测值回落到稳态工作点附近,无法实现故障预报.

根据 CVA 子空间辨识方法确定系统滞后阶次为 6,状态阶次为 2.选取 SVM 预测参数 $p = 6$,利用 101 ~ 200 时刻的测量数据进行 SVM 时间序列建




图 1 故障 1 的 UKF 预测曲线

模,按照 3.2 节的步骤进行故障预报.系统的 1 步和 5 步预测曲线分别如图 2 和图 3 所示.




图 2 故障 1 的 1 步预测结果




图 3 故障 1 的 5 步预测结果

在图 2 中,预测曲线和实际曲线均在 $k = 218$ 时刻超出阈值,提前 1 步预报故障.在图 3 中,预测曲线在 $k = 219$ 时刻超出阈值,提前 4 步预报故障.

在 $k = 201$ 时刻进行多步预报,预测误差如图 4 所示.可见预测误差随预测步长的增加而增大,最大预测步长为 $N_{\max} = 112$.




图 4 故障 1 在 $k = 201$ 时刻的多步预测误差

故障 1 ~ 故障 4 的最大预测步长如表 2 所示.结果表明,该方法能较准确地预测故障过程的变化趋势,提前预知将要发生的故障,使得操作人员有时间

表 2 故障情况下的最大预测步长

步 长	故障 1	故障 2	故障 3	故障 4
$N_{\max}/$ 步	112	117	102	86

采取必要措施消除故障隐患.

分别对系统正常情况和故障情况进行 40 次仿真,以检验故障预测的漏报率和误报率.故障 1 的漏报率和误报率如表 3 所示.表中的未来 N 步预报是在 $k = 201$ 时刻进行的,其中 $N = 23$ 使预测时域包含实际故障超限的时刻.结果表明,随着预测步数的增大,漏报率下降.

表 3 多步预报的漏报率和误报率

N 步预报	漏报率 / %	误报率 / %
23	5	0
24	0	0
25	0	0

5 结 论

本文针对未知非线性系统的故障预报问题,提出一种基于 SVM 预测新息的 Kalman 预测方法.该方法首先利用 SVM 模型拟合 Kalman 预测新息,然后利用 SVM 预测的新息改进 Kalman 单步和多步预测.对 CSTR 斜坡型故障的仿真结果表明,该方法能准确地预测较长时间段内故障过程的变化趋势,提前预知将要发生的故障.

参考文献(References)

- [1] 陈敏泽,周东华. 动态系统的故障预报技术[J]. 控制理论与应用, 2003, 20(6): 819-824.
(Chen M Z, Zhou D H. Fault prediction techniques for dynamic systems[J]. Control Theory & Applications, 2003, 20(6): 819-824.)
- [2] 周志杰,胡昌华,周东华. 基于非解析模型的动态系统故障预报技术[J]. 信息与控制, 2006, 35(5): 608-613.
(Zhou Z J, Hu C H, Zhou D H. Fault prediction techniques for dynamic systems based on non-analytical

model[J]. Information and Controls, 2006, 35(5): 608-613.)

- [3] Andrew K S Jardine, Daming Lin, Dragan Banjevic. A review on machinery diagnostics and prognostics implementing condition-based maintenance [J]. Mechanical Systems and Signal Processing, 2006, 20(7): 1483-1510.
- [4] Ben C Juricek, Dale E Seborg, Wallace E Larimore. Predictive monitoring for abnormal situation management[J]. J of Process Control, 2001, 11(2): 111-128.
- [5] 胡寿松,张正道. 基于神经网络的非线性时间序列故障预报[J]. 自动化学报, 2007, 33(7): 744-748.
(Hu S S, Zhang Z D. Fault prediction for nonlinear time series based on neural network [J]. Acta Automatica Sinica, 2007, 33(7): 744-748.)
- [6] Xiong K, Zhang H Y, Chan C W. Performance evaluation of UKF-based nonlinear filtering [J]. Automatica, 2006, 42(2): 261-270.
- [7] Mohinder S Grewal, Angus P Andrews. Kalman filtering: Theory and practice using Matlab[M]. New York: John Wiley & Sons, 2001.
- [8] Van Overschee Peter, De Moor Bart. An unifying theorem for three subspace system identification algorithms[J]. Automatica, 1995, 31(12): 1853-1864.
- [9] Ben C Juricek, Dale E Seborg, Wallace E Larimore. Identification of the tennessee eastman challenge process with subspace methods [J]. Control Engineering Practice, 2001, 9(12): 1337-1351.
- [10] 张军峰,胡寿松. 基于聚类和支持向量机的非线性时间序列故障预报[J]. 控制理论与应用, 2007, 24(1): 64-68.
(Zhang J F, Hu S S. Nonlinear time series fault prediction based on clustering and support vector machine[J]. Control Theory & Applications, 2007, 24(1): 64-68.)