一种基于局部模型的非线性多工况过程监测方法

葛志强 [1] 刘 毅 [1] 宋执环 [1] 王海清 [1]

摘 要 针对复杂工业过程中的非线性、非高斯特性以及多工况问题, 提出了一种基于局部模型的在线统计监测新方法. 首先利用局部最小二乘支持向量机回归 (Least square support vector regression, LSSVR) 模型对过程输出进行预测, 与真实的输出相比较构成残差序列. 然后利用 ICA-PCA 两步特征提取策略, 完整地提取残差的高斯和非高斯信息, 最后用三个统计量 (I^2、T^2 和 SPE) 对过程进行监测, 建立了一种具有非线性、非高斯特性的多工况过程在线监测算法. 通过对 TE (Tennessee Eastman) 过程的仿真研究, 验证提出的方法是可行、有效的, 并显示出了一定的故障检测能力.

关键词 多工况, 非高斯, 非线性, 局部模型, 最小二乘支持向量机回归 (LSSVR), ICA-PCA
中图分类号 TP277

Local Model Based Monitoring for Nonlinear Multiple Mode Process

GE Zhi-Qiang[1] LIU Yi[1] SONG Zhi-Huan[1] WANG Hai-Qing[1]

Abstract In order to handle the multiple operating mode problem and the widely existing non-Gaussian information of nonlinear processes, a new online local model based process monitoring method is proposed. First, least square support vector regression (LSSVR) local model is used to predict process outputs. Residuals are made between real outputs and predicted outputs. Then a two step ICA-PCA information extraction is carried out in order to extract both Gaussian and non-Gaussian information from the residuals. Finally, three statistic quantities are built to monitor the process. An online monitoring algorithm for nonlinear multiple mode processes with non-Gaussian information is also developed. Simulation of TE process shows the feasibility and efficiency of the new method. Besides, the new method also shows fault detection ability.

Key words Multiple modes, non-Gaussian, nonlinear, local model, least square support vector regression (LSSVR), ICA-PCA

以主元分析 (PCA) 和偏最小二乘 (PLS) 为代表的多元统计过程性能监控和故障诊断技术在化工生产过程中得到了成功应用[1], 但这类方法局限于服从高斯分布的线性测量数据的假定条件, 而且测量数据来自单一的稳定工况. 事实上, 大部分化工过程都是非线性的, 而且过程变量也不完全服从高斯分布, 实际的过程信息是高斯信息和非高斯信息的混合体. 另外, 大部分工业过程都不是运行在单一的工况下, 工况的频繁变化在现代化工过程中普遍存在. 在这种情况下, 用传统的多变量统计过程技术 (如 PCA) 对过程进行监测, 势必会导致过程性能分析不准确和监测的误报、漏报. 因此, 如何处理过程的非线性、非高斯信息和多工况问题成为目前过程监测领域研究的热点之一. 传统的非线性过程监测方法主要有基于模型的方法和各种非线性多变量统计方法等. 文献 [2] 提出了一种基于模型的 PCA 方法, 用于乙烯压缩机运行过程监测, 取得了较好的效果. 但是, 该方法在描述过程中使用的是传统的机理模型, 这在实际中是很难获得的, 而且一旦过程工况变化, 原来的机理模型也要随之改变. 因此, 从某种意义上说, 该机理模型缺乏可行性和灵活性. 文献 [3] 提出了用神经网络描述过程的非线性, 建立了基于神经网络模型的 PCA 方法, 但是神经网络容易陷入局部极小点, 而且训练费时, 一旦工况改变就要重新训练和确定网络的拓扑结构. 支持向量机回归 (Support vector regression, SVR) 是基于统计学习理论的新方法[4], 它依据结构风险最小化原则, 避免了神经网络存在的几大问题, 因此 SVR 有着更好的推广性能. 最小二乘支持向量机回归 (Least squares SVR, LSSVR)[5] 将 SVR 的不等式约束改为等式约束, 使得求解相对简单, 更适于在线建模. 为了处理多工况问题, 引入局部建模的概念, 使得模型能够实时地反映过程工况的变化. 独立成分分析 (Independent component analysis, ICA) 作为近年来发展起来的一种新的非高斯统计信号处理方法, 已在多个领域获得了成功应用[6], 但在化工过程性能监控方面的应用还很少. 国外学者 Kano[7] 等把 ICA 方法引入到化工过程监控领域, 国内很多学者也在这一领域做了很多工作. 本文针对非线性、非高斯过程的多工况问题, 提出了一种基于局部模

收稿日期 2007-02-05 收修改稿日期 2007-05-20
Received February 5, 2007; in revised form May 20, 2007
国家自然科学基金 (20576116) 资助
Supported by National Natural Science Foundation of China (20576116)
1. 浙江大学工业控制研究所工业控制技术国家重点实验室 杭州 310027
1. State Key Laboratory of Industrial Control Technology, Institute of Industrial Process Control, Zhejiang University, Hangzhou 310027
DOI: 10.3724/SP.J.1004.2008.00792

型的 ICA-PCA 过程监测新方法. 首先建立 LSSVR 局部模型, 得到的输出预测值和当前输出测量值相比较构成残差序列, 然后利用 ICA-PCA 两步信息提取方法对该残差序列进行处理, 利用 ICA 提取非高斯信息, 构造 I^2 统计量, 并用核密度估计方法获得概率密度函数以及确定相应的统计限, 然后对其中的高斯信息进行 PCA 分析, 并构造相应的 T^2 和 SPE 统计量对过程进行监测.

1　LSSVR 局部在线建模方法

工况的变化在绝大部分工业过程中普遍存在, 传统的处理办法是采用迭代的方法或者对各个工况分别建模[8−11]. 迭代的方法虽然能反映工况的变化, 但是具有一定的盲目性, 一般只对缓慢变化的过程比较有效; 而多模型的方法虽然能对多个工况进行监测, 但只能离线建模, 不能实时地反映过程的变化. 本文采用局部建模方法, 针对当前的输入测量值, 首先从数据库里搜寻与该输入相匹配的历史数据, 选取一定数量匹配程度较高的数据建立 LSSVR 模型, 然后利用建立的局部模型对当前的输入进行回归, 得到当前时刻的输出预测值.

对于当前测量输入 $\boldsymbol{u}_t$, 局部回归模型的目标是基于历史数据库预测当前时刻的输出 $\hat{y}_t = f(\boldsymbol{u}_t)$. 第一步是获得局部回归模型的建模数据, 本文采用以下距离因子作为两个输入之间相似程度的衡量标准

$$\begin{aligned} &S_i = \sqrt{\mathrm{e}^{-d^2(\boldsymbol{u}_t,\boldsymbol{u}_i)}} \\ &d(\boldsymbol{u}_t,\boldsymbol{u}_i) = \|\boldsymbol{u}_t - \boldsymbol{u}_i\|,\ \ i = 1,2,\cdots,N \end{aligned} \tag{1}$$

其中 $\boldsymbol{u}_i$ 为历史数据库中的第 i 个数据点, 得到一系列的相似数据后, 按照 S_i 的大小对数据进行排列, 选取匹配程度较高的前 N_{neig} 个数据作为局部回归模型的建模数据.

LSSVR 具有快速学习能力, 计算相对简单, 特别适合在线建模. 对于一组输入样本, LSSVR 利用非线性映射将训练数据集非线性地映射到一个高维特征空间, 从而使非线性函数估计问题转化为高维特征空间中的线性函数估计问题. 设回归函数为 $y = f(\boldsymbol{u}) = <\boldsymbol{w}, \Phi(\boldsymbol{u})> + b$, 其中 $<\cdot,\cdot>$ 为内积运算, LSSVR 在回归估计中, 优化目标和约束条件分别为

$$\min J(\boldsymbol{w}, b, \boldsymbol{e}) = \|\boldsymbol{w}\|^2 + \frac{C}{2}\sum_{i=1}^{N_{neig}} e_i^2 \tag{2}$$

$$\begin{aligned} &\text{s.t. } y_i = <\boldsymbol{w}, \Phi(\boldsymbol{u}_i)> + b + e_i \\ &\qquad i = 1,2,\cdots,N_{neig} \end{aligned} \tag{3}$$

其中, $\boldsymbol{e} = [e_1,\cdots,e_{N_{neig}}]^{\mathrm{T}}$ 为误差向量, C 为 (正的) 惩罚系数, 其值越大表示对误差的惩罚力度越强. 采用拉格朗日乘子法求解上述优化问题即可得到如下方程组

$$\begin{bmatrix} 0 & \mathbf{1}_{N_{neig}}^{\mathrm{T}} \\ \mathbf{1}_{N_{neig}} & \Omega + \frac{1}{C}I \end{bmatrix} \begin{bmatrix} b \\ \boldsymbol{\alpha} \end{bmatrix} = \begin{bmatrix} 0 \\ \boldsymbol{y} \end{bmatrix} \tag{4}$$

$$\begin{aligned} &\mathbf{1}_{N_{neig}} = [1\ \cdots\ 1]^{\mathrm{T}} \in \mathbf{R}^{N_{neig}} \\ &\boldsymbol{\alpha} = [\alpha_1\ \cdots\ \alpha_{N_{neig}}]^{\mathrm{T}} \in \mathbf{R}^{N_{neig}} \\ &\boldsymbol{y} = [y_1\ \cdots\ y_{N_{neig}}]^{\mathrm{T}} \in \mathbf{R}^{N_{neig}} \\ &I \in \mathbf{R}^{N_{neig}\times N_{neig}} \\ &\Omega_{ij} = K(\boldsymbol{u}_i,\boldsymbol{u}_j) = <\Phi(\boldsymbol{u}_i), \Phi(\boldsymbol{u}_j)> \\ &\forall\, i,j = 1,\cdots,N_{neig} \end{aligned} \tag{5}$$

求解出式 (4) 的 $\boldsymbol{\alpha}$ 和 b, 最终可得到回归函数为

$$f(\boldsymbol{u}) = <\boldsymbol{w}, \Phi(\boldsymbol{u})> + b = \sum_{i=1}^{N_{neig}} \alpha_i K(\boldsymbol{u}_i, \boldsymbol{u}) + b \tag{6}$$

本文采用较常用的 Gaussian 核[4, 9]: $K(\boldsymbol{u}_i,\boldsymbol{u}_j) = \exp((-\|\boldsymbol{u}_i - \boldsymbol{u}_j\|^2)/\sigma^2)$, 参数 σ 为核宽度. 这样就可以得到当前时刻的预测值 $\hat{y}_t$, 假设当前时刻的输出测量值为 y_t, 则当前时刻的残差为

$$er(t) = y_t - \hat{y}_t \tag{7}$$

得到正常工况下所有输出变量的残差后, 组成残差序列 ER, 下一步将对 ER 建立统计监测模型.

2　基于 ICA-PCA 的过程监测方法

由于大部分工业过程都具有非高斯特性, 第 1 节得到的过程残差信息序列通常是高斯信息和非高斯信息的混合体. 因此, 在提取完过程的非高斯信息后, 有必要对剩下的高斯信息进行分析. 本文采用 ICA-PCA 两步信息提取策略对预测残差信息进行处理. 由第 1 节可知, 过程的监测数据矩阵为 ER, 首先通过 ICA 提取出一定数量的独立成分 (由非高斯性度量决定)

$$ER = A \cdot \hat{S} + E \tag{8}$$

本文采用负熵的方法评价这种信号分离的非高斯性. 限于篇幅, ICA 算法的详细描述可参考文献 [6], 另外, 在提取独立成分的方法上, 本文采用 Hyvcarinen 提出的定点快速 ICA 算法[12]. 提取完非高斯信息后, 由各个变量剩余信息的负熵值可知[6], 剩下的过程信息数据矩阵 E 近似服从高斯分布, 因此可以用 PCA[5] 对它进行主成分的提取

$$E = T \cdot P^{\mathrm{T}} + F \tag{9}$$

其中 F 为残差数据矩阵, 综合以上两步信息提取过程, 原始数据矩阵 ER 可以分解为

$$ER = A \cdot \hat{S} + T \cdot P^{\mathrm{T}} + F \tag{10}$$

提取出过程的各种信息之后, 下一步是建立统计量以及相应的统计限对过程进行监测, 假定提取出来的独立成分个数为 r, 即 $\boldsymbol{S} = [s_1, s_2, \cdots, s_r]$, 构造 I^2 统计量为

$$I^2 = \boldsymbol{S}^{\mathrm{T}}\boldsymbol{S} \tag{11}$$

在得到正常工况下各个采样点的 I^2 值后, 可以利用核密度估计的方法[13] 获得其概率密度分布函数, 进而确定其统计置信限: 令 $K(\boldsymbol{x})$ 为核函数, n 个 p 维的数据构成样本集 $S_0 = \boldsymbol{x}_1, \boldsymbol{x}_2, \cdots, \boldsymbol{x}_n$, 则其概率密度分布函数可以表示为

$$\hat{f}(\boldsymbol{x}, H) = \frac{1}{n}\sum_{i=1}^{n} K(H^{-1/2}(\boldsymbol{x} - \boldsymbol{x}_i)) \tag{12}$$

其中 $\boldsymbol{x}_i \in \mathbf{R}^p$ 为第 i 个数据向量, H 为相应核函数的带宽参数矩阵, 这里我们选取核函数为高斯函数 $K(\boldsymbol{x}) = (2\pi)^{-p/2}\exp(-\boldsymbol{x}^{\mathrm{T}}\boldsymbol{x}/2)$, 带宽参数矩阵选为 $H = \mathrm{diag}(h_1^2, h_2^2, \cdots, h_p^2)$. 对于复杂的多变量系统, 考虑到核函数密度估计的困难性和计算量的问题, 在具体实施的时候, 很多文献也采用了较为简化的方法[7], 即在获得正常工况下各个采样点的 I^2 值后, 直接利用各个数据点的分布情况确定相应的统计限 (95%), 使得处于统计限之外的样本个数比例为 5%. 对过程的高斯信息部分, 建立 T^2 和 SPE 统计量, 其中 T^2 统计量定义为[1]

$$T^2 = \sum_{i=1}^{k}\frac{\boldsymbol{t}_i^2}{\lambda_i} \le \frac{k(n-1)}{n-k}F_{k,(n-k),\alpha} \tag{13}$$

其中 $\boldsymbol{t}_i^{1\times k} \in T$, $F_{k,(n-k),\alpha}$ 表示 F 分布 $F_{k,(n-k)}$ 的上侧 α 分位数. 另外, 用于残差监测的 SPE 统计量定义为

$$SPE = \boldsymbol{f} \cdot \boldsymbol{f} = \boldsymbol{e}(I - PP^{\mathrm{T}})\boldsymbol{e}^{\mathrm{T}} \le SPE_\alpha \tag{14}$$

其中 $\boldsymbol{f} \in F$, SPE_α 为 SPE 统计量的 $1-\alpha$ 置信限[1].

3 基于局部模型的 ICA-PCA 算法

建立过程的统计监测模型 (ICA-PCA) 之后, 就可以利用该模型对过程进行在线监测了. 由于 LSSVR 模型很好地描述了过程的非线性, 局部模型匹配了当前的工况状态, 而且统计监测模型是建立在预测残差的基础上, 因此, 新的方法很好地克服了传统监测方法线性和单一工况的局限性. 另外, 采用 ICA 提取过程的非高斯信息, 给过程监测提供了更好的信息基础. 基于局部 LSSVR 模型的 ICA-PCA 算法如图 1 所示, 其中 y_p 为输出的预测值.

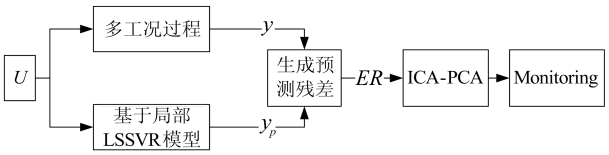

图 1 基于局部模型的 ICA-PCA 算法

Fig. 1 Flowsheet of ICA-PCA algorithm based on local model

基于局部 LSSVR 模型的 ICA-PCA 离线建模主要实施步骤为:

Step 1. 收集正常工况下的历史数据构成建模数据库;

Step 2. 采集正常工况下的数据集作为建模数据, 建立局部 LSSVR 模型, 预测各个输出变量, 构造残差序列;

Step 3. 提取残差序列的独立元和主元, 并计算各采样点 I^2 统计量的值, 由核密度估计方法估计 I^2 统计量的密度函数并确定其统计限 (简单起见也可以采用简化的方法);

Step 4. 由式 (13) 和 (14) 确定 T^2 和 SPE 统计量的统计限值.

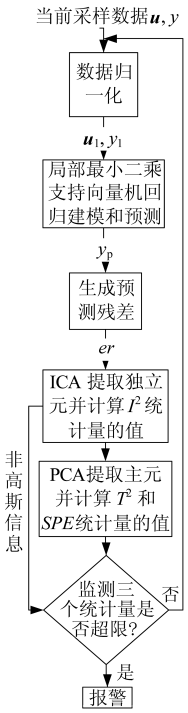

图 2 在线监测过程示意图

Fig. 2 Sketch of online monitoring process

基于局部 LSSVR 模型的 ICA-PCA 在线监测主要实施步骤为:

Step 1. 采集当前时刻数据测量值并进行归一化处理;

Step 2. 将当前输入值和历史数据库进行匹配, 提取匹配程度最高的 N_{neig} 个数据样本, 建立局部 LSSVR 模型, 并对当前时刻的输出进行预测 $\hat{y}_t = f(\boldsymbol{u}_t)$;

Step 3. 生成残差 $er = y_t - \hat{y}_t$, 对 er 进行独立元和主元提取;

Step 4. 计算三个统计量的值: I_t^2、T_t^2 和 SPE_t;

Step 5. 监测各个统计量是否超过各自的统计限.

整个过程的示意图如图 2 (见上页) 所示.

4　TE 过程仿真研究

1993 年美国 Eastman 化学公司的 Downs 和 Vogel 根据该公司一个实际的化工联合反应过程, 开发了 Tennessee Eastman (TE) 测试 (Benchmark) 仿真平台. 该平台是一个开放的、具有挑战性的化工模型仿真平台, 由连续搅拌式反应器、冷凝器、气液分离器、解析塔、再沸器和离心式压缩机等多个操作单元组成[14]. TE 过程的流程示意图如图 3 所示.

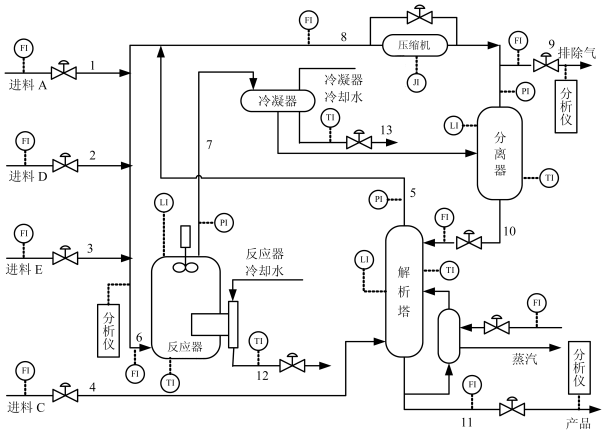

图 3　TE 过程流程图

Fig. 3　Flowsheet of TE process

TE 过程共有 41 个测量变量 (其中包括 22 个连续过程测量变量和 19 个组分变量) 和 12 个操控变量, 过程一共有 6 个操作模式 (工况), 并人为地设定了 21 种故障工况, 详细资料参见文献 [14]. 本文根据文献 [15] 选取其中 7 个变量作为过程输入, 10 个变量作为过程输出, 如表 1 所示. 模拟正常工况时, 采集过程平稳运行时的 2 000 个样本, 其中 1 000 个作为训练样本, 另外 1 000 个作为测试样本. 为了模拟多工况过程, 将 TE 过程切换到第 3 种工况下, 并采集相应数目的样本. 此外, 为了测试算法的故障检测能力, 引入第 5 种过程故障, 并采集相应数目的样本. 训练样本和检测样本的采样间隔均设定为 3 min.

表 1　TE 过程输入输出变量列表

Table 1　List of input and output variables of TE process

输入变量	变量名称	输出变量	变量名称
1	A 进料流量	1	循环流流率
2	D 进料流量	2	反应器进料流率
3	C 进料流量	3	反应器压力
4	净化流流率	4	反应器温度
5	反应器冷却水出口温度	5	产品分离器温度
6	循环压缩机阀门开度	6	产品分离器压力
7	冷凝器冷却水流率	7	解析塔压力
		8	解析塔温度
		9	压缩机功率
		10	分离器冷却水出口温度

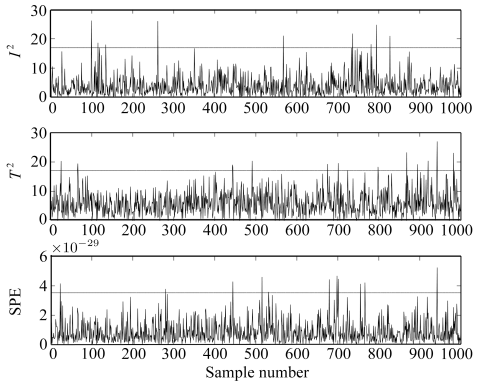

(a) 基于局部模型的 ICA-PCA 方法

(a) ICA-PCA method based on local model

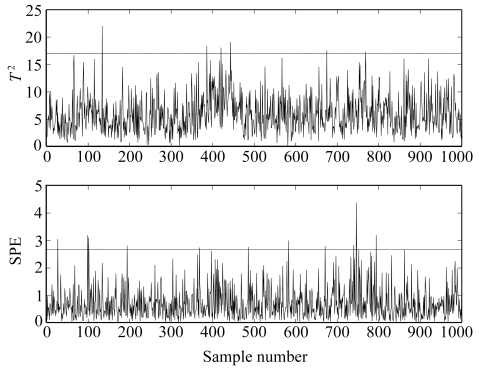

(b) PCA 方法

(b) PCA method

图 4　单一工况仿真结果

Fig. 4　Single mode simulation results

建立基于局部模型的 ICA-PCA 统计监测模型时, 选取的独立元和主元个数分别为 4 和 6, 基本的 PCA 统计监测模型选取的主元个数也为 6 个, 所有统计限的置信度均为 95%. 另外, 在建立局部模型时, 选取的近邻建模样本数为 50 个, SVM 正则化参数选为 50, 高斯核函数宽度选为 0.1. 图 4 是对初始

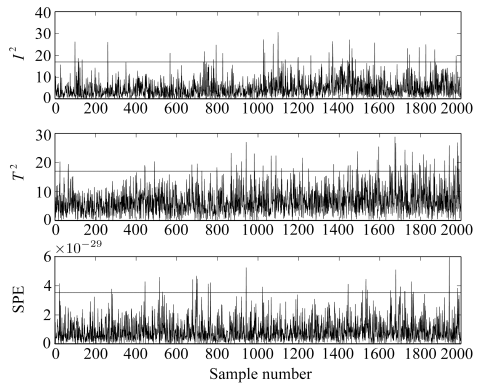

(a) 基于局部模型的 ICA-PCA 方法

(a) ICA-PCA method based on local model

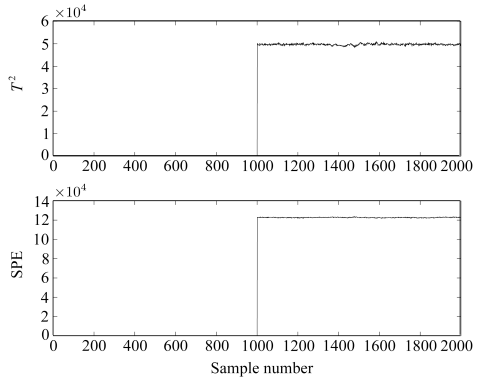

(b) PCA 方法

(b) PCA method

图 5 工况变化仿真结果

Fig. 5 Mode change simulation results

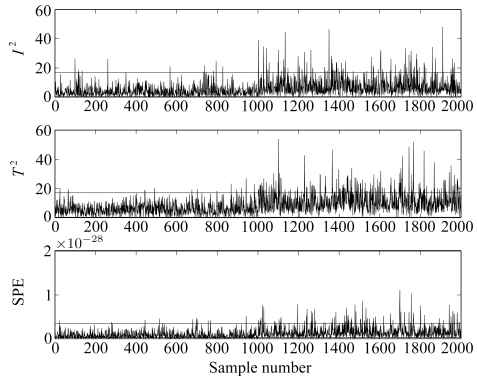

(a) 基于局部模型的 ICA-PCA 方法

(a) ICA-PCA method based on local model

工况的监测结果, 基于局部模型的 ICA-PCA 方法和传统的 PCA 方法都能给出较好的结果, 这说明新的方法并没有牺牲系统对单一工况的监测性能. 当过程的工况发生变化时, 监测结果如图 5 所示. 其中基于局部模型的 ICA-PCA 方法 (图 5 (a)) 给出了较满意的监测结果; 而图 5 (b) 给出的传统 PCA 的监测结果, 说明传统的 PCA 方法只能处理单一工况下的监测问题, 对工况的变化则无法作出响应. 另外,

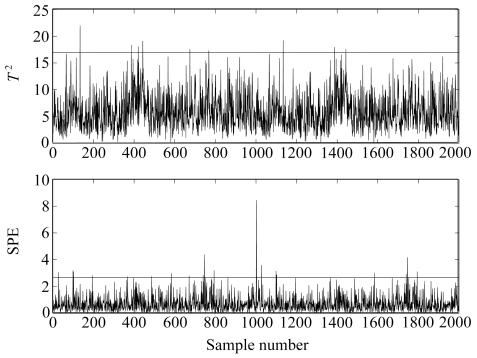

(b) PCA 方法

(b) PCA method

图 6 正常工况和故障工况 5 仿真结果

Fig. 6 Normal and fault mode 5 simulation results

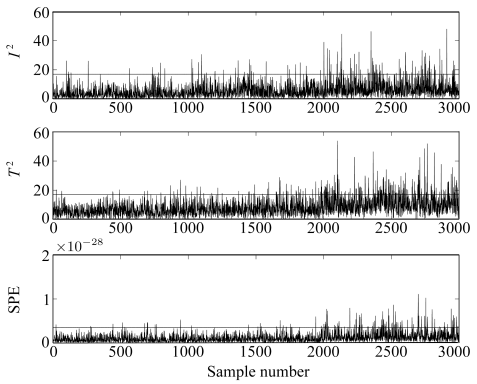

(a) 基于局部模型的 ICA-PCA 方法

(a) ICA-PCA method based on local model

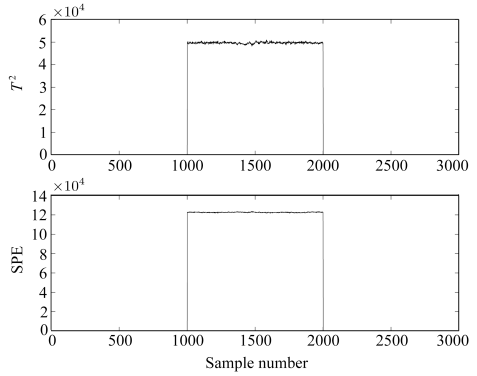

(b) PCA 方法

(b) PCA method

图 7 工况变化和故障工况 5 仿真结果

Fig. 7 Fault mode change and fault mode 5 simulation results

为了测试新方法的故障检测性能, 对典型的过程故障工况 5 进行了仿真研究, 故障 5 包含冷凝器冷却水入口温度的一个阶跃变化, 这个故障的显著影响是会引起冷凝器冷却水流量的阶跃变化, 当故障发生时, 从冷凝器出口到分离器的流速也增加, 这导致分离器的温度增加, 并且分离器冷却水温度也会增加. 从正常工况到故障工况变化的仿真结果如图 6

所示, 其中新方法的三个统计量均处于报警状态, 说明新方法可以检测到该过程故障, 而 PCA 方法则无法检测出过程的故障信息. 另外, 图 7 给出了正常工况、工况变化和故障工况的综合仿真结果, 相比普通 PCA 方法, 新的方法不但能适应过程工况的变化, 而且具有一定的故障检测能力.

5 结论

本文提出了一种新的基于局部模型的 ICA-PCA 过程在线监测方法, 针对过程的非线性、非高斯特性以及普遍存在的多工况现象, 该方法首先通过局部 LSSVR 模型对过程的输出进行预测, 然后和真实测量值相比较构成残差序列, 建立 ICA-PCA 统计分析模型对其进行监测. 由于过程大多是非高斯和高斯信息的混合体, 采用 ICA-PCA 两步信息提取策略能更有效地提取过程的信息, 为监测提供更好的信息基础. 通过对 TE 过程仿真研究, 说明本文提出的方法可以有效地解决过程的非线性、多工况和非高斯监测问题, 并显示出了一定的故障检测能力.

References

1 Chiang L H, Russell E L, Braatz R D. *Fault Detection and Diagnosis in Industrial Systems*. London: Springer-Verlag, 2001

2 Rotem Y, Wachs A, Lewin D R. Ethylene compressor monitoring using model-based PCA. *American Institute of Chemical Engineers Journal*, 2000, **46**(9): 1825−1836

3 Rattan S S P, Hsieh W W. Complex-valued neural networks for nonlinear complex principal component analysis. *Neural Networks*, 2005, **18**(1): 61−69

4 Vapnik V N. *The Nature of Statistical Learning Theory*. New York: Springer-Verlag, 1995

5 Suykens J A K, Gestel T V, Brabanter J D, Moor B D, Vandewalle J. *Least Squares Support Vector Machines*. Singapore: World Scientific, 2002

6 Hyvarinen A, Oja E. Independent component analysis: algorithms and applications. *Neural Network*, 2000, **13**(4-5): 411−430

7 Kano M, Tanaka S, Hasebe S, Hashimoto I, Ohno H. Monitoring independent components for fault detection. *American Institute of Chemical Engineers Journal*, 2003, **49**(9): 969−976

8 Voegtlin T. Recursive principal component analysis. *Neural Networks*, 2005, **18**(8): 1051−1063

9 Choi S W, Martin E B, Morris A J, Lee I B. Adaptive multivariate statistical process control for monitoring time-varying processes. *Industrial and Engineering Chemistry Research*, 2006, **45**(9): 3108−3118

10 Jin H D, Lee Y H, Lee G, Han C H. Robust recursive principal component analysis modeling for adaptive monitoring. *Industrial and Engineering Chemistry Research*, 2006, **45**(2): 696−703

11 Lee Y H, Jin H D, Han C H. Online process state classification for adaptive monitoring. *Industrial and Engineering Chemistry Research*, 2006, **45**(9): 3095−3107

12 Hyvarinen A, Oja E. A fast fixed-point algorithm for independent component analysis. *Neural Computation*, 1997, **9**(7): 1483−1492

13 Chen Q, Wynne R J, Goulding P, Sandoz D. The application of principal component analysis and kernel density estimation to enhance process monitoring. *Control Engineering Practice*, 2000, **8**(5): 531−543

14 Downs J J, Vogel E F. A plant-wide industrial process control problem. *Computers and Chemical Engineering*, 1993, **17**(3): 245−255

15 Juricek B C, Seborg D E, Larimore W E. Identification of the Tennessee Eastman challenge process with subspace methods. *Control Engineering Practice*, 2001, **9**(12): 1337−1351

葛志强 浙江大学工业控制研究所博士研究生. 主要研究方向为过程监测与故障诊断技术.
E-mail: zqge@iipc.zju.edu.cn
(**GE Zhi-Qiang** Ph. D. candidate at Institute of Industrial Process Control, Zhejiang University. His research interest covers process monitoring and fault diagnosis.)

刘 毅 浙江大学工业控制研究所博士研究生. 主要研究方向为核学习建模与控制. E-mail: yliu@iipc.zju.edu.cn
(**LIU Yi** Ph. D. candidate at Institute of Industrial Process Control, Zhejiang University. His research interest covers kernel learning based modeling and control.)

宋执环 浙江大学工业控制研究所教授. 主要研究方向为基于数据驱动技术的复杂工业过程建模、控制与故障诊断. 本文通信作者.
E-mail: zhsong@iipc.zju.edu.cn
(**SONG Zhi-Huan** Professor at Institute of Industrial Process Control, Zhejiang University. His research interest covers data-driven based techniques for complex process modeling, control and fault diagnosis. Corresponding author of this paper.)

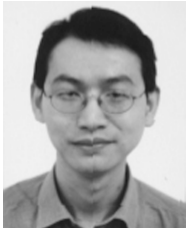

王海清 浙江大学工业控制研究所副教授. 主要研究方向为统计学习建模、监测与控制.
E-mail: hqwang@iipc.zju.edu.cn
(**WANG Hai-Qing** Associate professor at Institute of Industrial Process Control, Zhejiang University. His research interest covers statistical learning theory for process modeling, monitoring and control.)