

基于多块MICA-PCA的全流程过程监控方法

王振雷^{1†}, 江伟¹, 王昕²

(1. 华东理工大学 化工过程先进控制和优化技术教育部重点实验室, 上海 200237;
2. 上海交通大学 电工与电子技术中心, 上海 200240)

摘要: 多块策略广泛应用于全流程过程监控领域,以解决变量关系复杂性较高的问题,但传统分块方法得到的子块数据存在高斯与非高斯混合分布问题,影响过程监控的效果.为此,提出一种基于多块MICA-PCA的过程监控方法.首先采用Jarque-Bera(J-B)检测方法对原始数据进行高斯与非高斯分块;然后利用Hellinger距离(HD)方法获得高斯与非高斯子块,通过对高斯与非高斯子块采用不同的建模和诊断方法,提高监控效果;最后将该方法应用于田纳西-伊斯曼(TE)过程的监控中,以验证所提出方法的有效性.

关键词: 多块; 全流程; 主元分析; 非高斯

中图分类号: TP273 **文献标志码:** A

Plant-wide process monitoring based on multiblock MICA-PCA

WANG Zhen-lei^{1†}, JIANG Wei¹, WANG Xin²

(1. Key Laboratory of Advanced Control and Optimization for Chemical Processes, East China University of Science and Technology, Shanghai 200237, China; 2. Center of Electrical & Electronic Technology, Shanghai Jiaotong University, Shanghai 200240, China)

Abstract: The multiblock strategy is widely used for plant-wide process monitoring, to capture the relations between complex process variables of the plant-wide process, however, the sub-block data obtained from the traditional multiblock method still has the problem of non-Gaussian and Gaussian mixture distribution, which influences the performance of process monitoring. Therefore, a plant-wide process monitoring method based on multiblock MICA-PCA is proposed to improve the process monitoring performance. Firstly, the measured variables are automatically divided into non-Gaussian block and Gaussian block through the Jarque-Bera(J-B) test method, the non-Gaussian block and Gaussian block are divided into non-Gaussian sub-blocks and Gaussian sub-blocks through the Hellinger Distance(HD) method. By using different modeling and diagnosis methods for non-Gaussian sub-blocks and Gaussian sub-blocks, the monitoring effect is improved. Finally, the proposed method is applied to monitor the Tennessee-Eastman(TE) process, which shows its effectiveness.

Keywords: multiblock; plant-wide process; principal component analysis; non-Gaussian

0 引言

随着现代工业生产过程对产品质量和安全性的要求日益提高,过程监控得到了更高的重视^[1].近年来,基于数据驱动,特别是基于多变量统计过程监控(MSPM)的方法在过程监控领域获得了迅速发展^[2].其中,主元分析(PCA)是一种得到广泛运用的MSPM方法,它能对已获取的数据进行降维,消除变量之间的相关性,获得较好的监控效果^[3],但该方法仅对高斯信息有效.因此,为了解决PCA方法不能提

取过程数据非高斯信息的问题,人们提出了一种基于独立成分分析(ICA)的过程监控方法^[4].ICA方法不仅能够提取过程数据的非高斯信息,还能提取过程数据的高阶统计量信息.同时,为了进一步提高过程监控的效果,一些改进的PCA和ICA方法也被陆续提出^[5-6].

另一方面,全流程过程的过程监控方法已经成为热门的研究领域.全流程过程通常是具有多个操作单元、大量过程变量、变量关系复杂等特点的工业过

收稿日期: 2016-09-25; 修回日期: 2017-03-12.

基金项目: 国家自然科学基金重点项目(61134007); 国家自然科学基金青年项目(61403141); 上海市“科技创新行动计划”研发平台建设项目(13DZ2295300); 上海市自然科学基金项目(14ZR1421800); 流程工业综合自动化国家重点实验室开放课题基金项目(PAL-N201404).

作者简介: 王振雷(1975-),男,教授,博士生导师,从事故障诊断等研究;江伟(1991-),男,硕士生,从事故障诊断的研究.

†通讯作者. E-mail: wangzhen_1@ecust.edu.cn

程. 为了克服全流程过程变量关系复杂性较高的问题, 并提取全流程过程数据的局部变量信息, 人们提出了分块方法^[7]. Ge等^[8]提出了基于两阶段多块统计的全流程监控方法, 利用过程知识划分子块. 但该方法无法满足子块自动划分的要求, 为此, Ge等^[9]又提出了一种基于分布式PCA的全流程过程监控方法, 利用各过程变量在主元方向上的贡献度进行自动划分子块, 将在同一主元方向上贡献度高的变量划分在同一子块中. 然而, 基于PCA的分块方法只考虑了过程变量的均值及方差信息, 忽视了变量的其他概率分布信息, 影响了子块的监控效果. 为此, Jiang等^[10]提出了一种基于分块ICA结合Hellinger距离(HD)与贝叶斯推理的全流程过程监控方法, 将相互之间HD较小的变量划分在一个子块中, 该方法不仅考虑了变量的概率分布信息, 还同时采用ICA方法提取过程数据的非高斯以及高阶信息, 提高了子块的监控效果. 同时, 文献[11-12]提出了一种基于变量之间互相关信息(MI)进行分块的办法, 考虑了变量数据的高阶统计信息, 将MI较大的变量划分在一个子块中, 同时采用改进的建模方法, 取得了较好的监控效果. 但是, 按照以上方法进行分块, 得到的子块数据会存在高斯与非高斯混合分布的问题, 这会影响故障检测的效果. 传统的故障诊断方法都采用基于主元方向贡献度的方法, 该方法不能有效提取变量数据的非高斯信息, 从而造成故障诊断的效果不佳.

本文提出一种基于多块MICA-PCA的全流程过程监控方法. 该方法首先利用Jarque-Bera(J-B)检测方法进行变量的高斯与非高斯分块, 利用变量之间的HD对高斯与非高斯分块进行进一步分块, 获得高斯与非高斯分块的子块; 然后对非高斯与高斯子块分别采用改进的ICA(MICA)与MICA-PCA方法进行建模, 获得每个子块的统计量, 并对每个子块的统计量进行加权得到总的联合指标实现对实际工业过程的在线监控. 当进行故障诊断时, 对于非高斯子块, 本文采用基于独立成分方向贡献度的方法, 以解决基于主元方向贡献度方法对过程数据非高斯信息提取不足的问题. 本文方法的主要贡献在于: 1) 提出了一种新的分块方法, 有效地解决了子块数据存在的高斯与非高斯混合分布的问题; 2) 对高斯与非高斯子块采用不同的建模方法, 并通过联合指标的方法提高了监测效果; 3) 对高斯与非高斯子块采用不同的诊断方法, 提高了故障诊断的效果. 最后, 通过TE过程的仿真实验表明所提出方法的有效性.

1 分块方法

在实际的工业过程中, 变量大多是高斯与非高斯混合分布的, 传统的PCA与ICA方法只能提取数据中的高斯或非高斯信息, 因此对变量进行高斯与非高斯分块可以提高各自信息的提取能力. 另外, 采用PCA与ICA方法提取过程信息时, 都假设各变量是线性相关的. 若两个变量的概率分布不同, 则这两个变量很难线性相关或是由相同的信号源线性组合生成. 因此对高斯与非高斯分块进行分块, 将概率分布相近的变量划分到一个子块中, 不仅可以降低全流程过程的复杂性, 还能解决过程变量之间存在的非线性关系问题, 更有利于过程监控效果的提高. 本文分别采用J-B检测与HD方法进行高斯与非高斯子块的划分.

1.1 基于J-B检测的高斯与非高斯分块方法

J-B检测主要通过一个变量数据的峰度和偏度进行高斯与非高斯检测, 对于一个具有 n 个样本的随机变量 X , 可以表示成 x_1, x_1, \dots, x_n , 则随机变量的样本偏度和峰度分别为

$$\sqrt{b_1} = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^3}{\left[\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right]^{\frac{3}{2}}}, \quad (1)$$

$$b_2 = \frac{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^4}{\left[\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2 \right]^2}, \quad (2)$$

其中 $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$. 因此, J-B检测的指标值为

$$JB = \frac{n}{6} \left[b_1 + \frac{(b_2 - 3)^2}{4} \right]. \quad (3)$$

设判断变量数据是否符合高斯分布的JB指标的阈值为 JB_α , JB_α 由重要性水平 α 和采样个数 n 决定^[13]. 当 $JB < JB_\alpha$ 时, 认为该变量是属于高斯分布的变量, 放入高斯分块, 反之则放入非高斯分块. 因此, 对于给定的数据集 X , 可以分块为

$$X = [X_{\text{Gaussian}}, X_{\text{nonGaussian}}]. \quad (4)$$

1.2 基于HD的子块划分方法

本文采用Hellinger距离方法进行子块的划分, 具体两个变量之间的HD值为

$$H(x_r, x_q) = \frac{1}{\sqrt{2}} \sqrt{\sum_{i=1}^k (\sqrt{p(x_r)_i} - \sqrt{p(x_q)_i})^2}, \quad (5)$$

其中 $p(x_r)$ 、 $p(x_q)$ 分别为变量 x_r 、 x_q 的概率密度函

数. 当两变量之间的HD小于阈值 β 时, 可以将两个变量划分到一个子块中. 如果高斯分块被分为 b 个子块, 非高斯分块被分为 c 个子块, 则数据集可以进一步表示为

$$X = [X_{G1}, \dots, X_{Gb}, X_{N1}, \dots, X_{Nc}]. \quad (6)$$

2 建模方法

过程变量的分块完成后, 需对每个子块进行建模以获得相应的统计量和统计监控限, 从而实现对整个子块的在线监控. 为了简化过程监控的步骤, 实现对高斯与非高斯信息都能有效地提取, 本文通过对子块统计量进行加权得到总的联合指标, 并获得相应的统计监控限, 以实现对整个工业过程的在线监控. 因为ICA方法能够提取变量数据的非高斯与高阶统计信息, 本文首先采用ICA方法对各子块进行建模, 以提取非高斯子块的非高斯信息与高阶统计信息, 同时可以提取高斯子块的高阶统计信息. 而PCA方法只能提取变量数据的高斯信息, 因此本文只对高斯子块ICA建模后得到的残差进行PCA建模, 以解决ICA方法不能提取高斯子块的高斯信息的问题.

2.1 基于MICA的非高斯子块的建模方法

传统的ICA统计指标并不够完善, 所以本文采用MICA方法^[14]对非高斯子块进行建模.

首先对非高斯子块进行ICA统计建模, 将数据矩阵 X_{NK} 作如下组合分解:

$$X_{NK} = AS + E. \quad (7)$$

其中: $X_{NK} \in R^{m_{NK} \times n}$ 为第 K 个非高斯子块的数据集, $S \in R^{p \times n}$ 为独立成分矩阵, $A \in R^{m_{NK} \times p}$ 为混合矩阵, m_{NK} 、 n 、 p 分别为第 K 个非高斯子块的变量个数、样本个数和独立成分个数. ICA通过求取分离矩阵 W 重构 S , 即

$$S = WX_{NK}. \quad (8)$$

这里采用FastICA算法^[15]求得分离矩阵 W , $W \in R^{p \times m_{NK}}$.

MICA方法对传统ICA的统计指标 I^2 进行了改进, 传统的 $I^2(i)$ 由 p 个指标 $(I_1^2(i), \dots, I_p^2(i))$ 加权得到, 每个指标的权重为1. MICA根据第 k 个指标 $I_k^2(i)$ 在一段时间的平均值占 $I^2(i)$ 的平均值比重与监控效果具有正相关性这一性质, 在分离矩阵 W 前乘以一个加权矩阵 Y ($Y = \text{diag}(y_1, y_2, \dots, y_p)$) 得到第 K 个非高斯子块新的统计指标 $I_{NK}^2(i)$, 即

$$\begin{aligned} I_{NK}^2(i) &= s(i)^T s(i) = \\ & x_{NK}(i)^T W^T Y^T Y W x_{NK}(i), \end{aligned} \quad (9)$$

$$Y = \begin{bmatrix} y_1 & \cdots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \cdots & y_p \end{bmatrix}, \quad (10)$$

$$y_k(i) = \left(\frac{\bar{I}_k^2(l)}{\bar{I}^2(l)} \right)^h, \quad (11)$$

$$\bar{I}_k^2(l) = \frac{1}{r} \sum_{i=r(l+1)}^{r(l+r)} I_k^2(i), \quad (12)$$

$$\bar{I}^2(l) = \frac{1}{r} \sum_{i=r(l+1)}^{r(l+r)} I^2(i), \quad (13)$$

$$l = [i/r] - 1, \quad (14)$$

其中 $[i/r]$ 表示对 i/r 的取整. 通过核密度估计(KDE)方法^[16], 可以得到第 K 个非高斯子块的统计监控限 $l_{I_{NK}^2}$.

2.2 基于MICA-PCA的高斯子块的建模方法

本文采用MICA-PCA方法对高斯子块进行建模, $X_{GK} \in R^{m_{GK} \times n}$ 为第 K 个高斯子块的数据集. 首先对该数据集进行MICA建模, 得到相应的统计指标 $I_{GK}^2(i)$ 和统计监控限 $l_{I_{GK}^2}$; 然后, 对MICA建模后得到残差 E 进行PCA建模, 根据文献^[17]将残差分析后的两个统计量 T^2 和SPE两个指标合二为一得到新的PCA监控指标, 即

$$P_{GK}^2 = 1/l_{T^2} \times T^2 + 1/l_{\text{SPE}} \times \text{SPE}, \quad (15)$$

其中 l_{T^2} 和 l_{SPE} 为相应的统计量 T^2 和SPE的统计监控限, 具体公式详见文献^[18], 通过KDE方法可以得到相应的统计监控限 $l_{P_{GK}^2}$. 根据文献^[14]的加权公式对MICA统计量 I_{GK}^2 和PCA统计量 P_{GK}^2 进行加权得到新的统计量 D_{GK}^2 , 通过KDE方法可得相应的统计监控限 $l_{D_{GK}^2}$, 即

$$D_{GK}^2 = 1/l_{I_{GK}^2} \times I_{GK}^2 + 1/l_{D_{GK}^2} \times D_{GK}^2. \quad (16)$$

2.3 总的联合指标的建立

本文使用一个总的联合指标进行过程监控, 定义该指标 D^2 为

$$D^2 = \sum_{K=1}^c (1/l_{I_{NK}^2} \times I_{NK}^2) + \sum_{K=1}^b (1/l_{D_{GK}^2} \times D_{GK}^2). \quad (17)$$

通过对正常工况数据得到的总的联合指标 D^2 进行核密度估计, 即可求得总的统计监控限 l_{D^2} .

3 故障检测与诊断步骤

3.1 故障检测步骤

本文的监控方法可分为离线建模和在线监控. 离线建模主要为了获得非高斯与高斯子块的统计监控限和总的联合指标的统计监控限, 而在线监控主要

是为了在线监控系统的运行状态. 具体步骤如下.

Step 1: 离线建模.

Step 1.1: 首先对正常工况下数据集 $X \in R^{m \times n}$ 进行均值中心化等预处理;

Step 1.2: 利用J-B检测方法对标准化后的数据集进行高斯与非高斯分块,然后利用HD方法得到相应的高斯与非高斯子块;

Step 1.3: 利用MICA与MICA-PCA方法分别对非高斯与高斯子块进行建模,得到相应的监控统计量 I_{NK}^2 和 D_{GK}^2 ,并计算出非高斯与高斯子块的统计监控限 l_{NK}^2 、 l_{GK}^2 ;

Step 1.4: 对非高斯和高斯子块的统计量进行加权得到总的联合指标 D^2 ,联合指标的统计监控限 l_{D^2} .

Step 2: 在线监控.

Step 2.1: 对在线获取的实时数据进行数据预处理;

Step 2.2: 根据离线建模子块的划分结果,进行高斯与非高斯子块的划分;

Step 2.3: 计算出各子块的统计指标,计算出总的联合指标,判断是否在正常工况下.

3.2 故障诊断步骤

传统的故障诊断方法是当过程监控的统计指标超过统计监控限以后,便认为发生了故障,再根据每个变量在主元方向的贡献度之和的值进行判别,贡献度较高的几个变量认为是造成故障或受到故障影响的变量.但全流程过程变量数目众多,变量之间的关系复杂,因此传统的故障诊断方法的诊断效果不佳.

在本文方法中,当故障发生后,各子块将被分为两类:监控效果较好的子块和监控效果较差的子块.因为存在故障相关变量的子块能够提取更多的故障信息,如高斯与非高斯信息及高阶统计信息等,所以与故障相关的变量在监控效果较好的子块中的概率比在监控效果较差的子块中的概率要高.因此可以基于监控效果较好的子块进行故障诊断,该子块中贡献度最高的几个变量即为引起故障或受故障影响的变量.

如果检测出了故障的子块是高斯子块,则对该子块进行PCA建模.该子块的第 j 个变量 $x_{j,G}$ 对第 i 个主元 $t(i)$ 的贡献度为

$$\text{cont}_{i,j} = \frac{t(i)}{\lambda(i)} p_{i,j} x_{j,G}. \quad (18)$$

其中: $\lambda(i)$ 为第 i 个特征值, $p_{i,j}$ 为负荷矩阵 P 的一个元素.如果有 d 个失控状态,则第 j 个变量总的贡献度

之和为

$$\text{cont}_j = \sum_{i=1}^d \text{cont}_{i,j}. \quad (19)$$

如果检测出了故障的子块是非高斯子块,则对该子块进行ICA建模.如果有 r 个失控状态,则该子块的第 j 个变量 $x_{j,N}$ 对第 i 个独立成分 $s(i)$ 的总的贡献度之和为

$$\text{cont}_j = \sum_{i=1}^r s(i) x_{i,N}. \quad (20)$$

4 TE过程仿真实验

4.1 TE模型

TE模型是评价过程控制和监控方法的一个现实的工业过程,其包括41个测量变量(22个连续测量变量和19个成分测量值)和12个控制变量,TE过程的详细描述可参考文献[19].

4.2 基于分块MICA-PCA的TE过程仿真

TE过程变量数目众多,变量之间关系较为复杂,而且变量还存在着高斯与非高斯混合分布以及非线性相关的问题.因此在仿真实验中,首先选取52维的960组正常工况数据进行标准化处理,再利用J-B检测方法进行高斯与非高斯分块,将值小于 JB_α 的变量划分到高斯分块中,反之放入非高斯分块中.其中, α 值设为0.05,相应的 JB_α 值为5.991,具体的分块结果如表1所示.将高斯与非高斯分布相同的变量划分到一个分块中,可以有效解决传统方法无法同时提取高斯与非高斯信息的问题.为了进一步降低TE过程的复杂性并解决变量之间的非线性相关问题,利用HD方法对高斯与非高斯分块进行进一步的分块,得到了相应的高斯与非高斯子块,具体的分块结果如表2所示.将概率分布信息相近的变量划分到一个子块中,不仅可以有效解决变量之间的非线性相关问题,有利于故障信息的提取,而且概率分布信息相近的变量往往在工艺上也具有较强的相关关系,如高斯第1子块中的变量1、44都与A进料相关,非高斯第1子块变量大多与流9相关.当故障发生时,由于子块中各变量关系相近,更有利于过程监控效果的提高.因此,利用本文的方法可以得到高斯与非高斯子块相应的统计量与统计监控限,再运用加权方法计算得到总的联合指标并估计出总的统计监控限,用来进行TE过程

表1 TE过程的高斯与非高斯分块结果

Block	Gaussian block	Non-Gaussian block
Variable no.	1 4 5 6 8 9 11 12 14 15 17 20 21	2 3 7 10 13 16 18
	22 23 24 25 26 27 29 30 35 36 37	19 28 31 32 33 34
	38 40 42 43 44 45 48 49 51 52	39 41 46 47 50

表2 TE过程的高斯与非高斯子块的分块结果

Block	G block1	G block2	G block3	G block4	N block1	N block2
Variable no.	1 17 26 29 36 44 52	4 6 8 9 12 22 27 30 35 42 45 48 51	5 15 25 37 40 49	11 14 20 21 23 24 38 43	2 13 28 31 33 34 41 47	3 7 10 16 18 19 32 39 46 50

的故障检测。

在线监控时,采取本文方法得到总的联合指标,并与统计监控限比较,判断其是否超限.经多次实验,得到的检测率与其他方法进行对比,结果如表3所示.由表3可见,本文的方法对于这几类故障都有较好的监控效果.

表6 TE过程故障的检测率对比 %

Fault model	PCA		ICA	LTSA-MICA-PCA	本文方法
	T^2	SPE	T^2	D^2_{MICA}	D^2
fault 2	97.7	97.1	97.6	98.1	99.4
fault 4	81.2	100	100	100	100
fault 5	40.4	31.5	100	100	100
fault 11	70.6	67.5	45.4	95.5	96.5
fault 13	89.4	90	90.6	95.8	96.4
fault 18	91.8	90.8	90.7	92.1	93.6
fault 19	41.1	16.3	44.1	97	98.3
fault 20	54.9	54.8	77.9	92.9	92.9

故障11是反应器冷却水入口温度发生故障,并引起了反应器冷却水流速与反应器温度(变量9)的

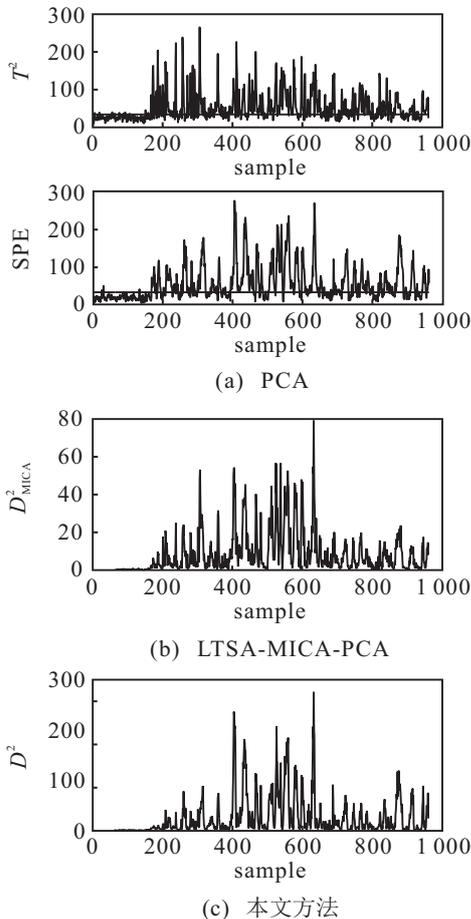


图1 TE过程故障11的监控图对比

波动.由表3和图1可见,本文的故障检测效果比PCA方法有了较大的提高,比文献[14]中的方法也有一定的提高.图2给出了故障11部分子块的监控图,除了高斯分块的第2子块的监控效果较好,其他子块的监控效果与图2(a)和图2(b)类似,因此对该子块进行故障诊断,其他子块的变量的贡献度设为0,得出的结果如图3(a)所示,发现变量9、52与故障相关,并且变量9的贡献度高于变量52,因此该诊断方法是有效的.图3(b)给出的是传统方法的诊断结果,虽然也发现了变量9的贡献度较高,但是变量48(分离器罐液流量)的贡献度比变量9更高,因此诊断效果不如本文方法.分布式PCA与基于MI的方法的诊断结果同样存在诊断出变量9的贡献度不是最高的问题,因此本文方法对故障11的诊断效果更好.

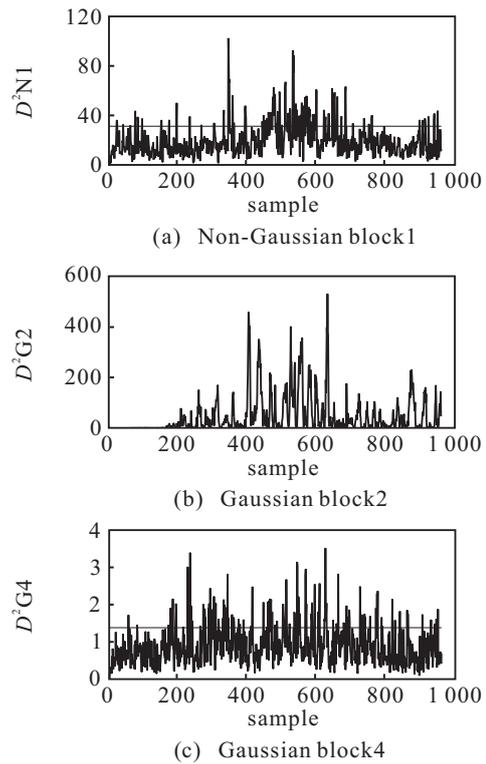


图2 TE过程故障11部分子块的监控图对比

通过TE平台的仿真实验可见,本文提出的基于多块MICA-PCA的方法,在故障检测的效果上不仅优于传统的PCA与ICA方法,而且与文献[14]中方法的检测效果相比也略有提高.更重要的是,本文提出的方法在一些故障中定位故障变量的精确度上要优于传统的方法与其他分块方法,因此本文提出的方法对于TE过程可以实现较好的监测和诊断.

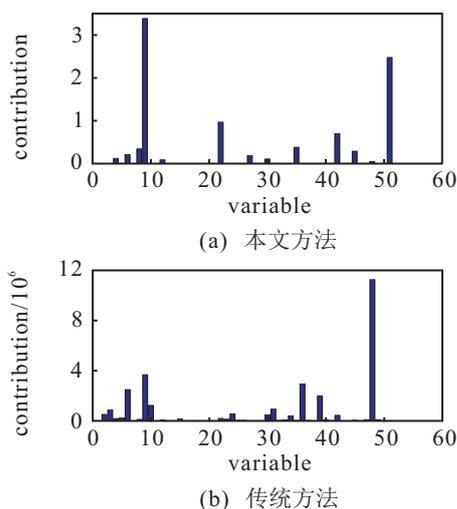


图3 TE过程故障11的贡献图

5 结论

本文提出了一种基于多块MICA-PCA的全流程故障检测与诊断方法,有效地降低了全流程过程的复杂性.该方法通过J-B检测和HD方法对原始数据集进行高斯与非高斯分块,得到高斯与非高斯子块的分块方法,有效地解决了传统分块方法中子块数据存在高斯与非高斯混合分布从而影响过程监控效果的问题.通过对高斯与非高斯子块采用不同的建模和诊断方法,提高了故障检测和诊断效果.最后通过TE平台的仿真实验表明了所提出方法的有效性.

参考文献(References)

- [1] Wang T, Wu H, Ni M, et al. An adaptive confidence limit for periodic non-steady conditions fault detection[J]. *Mechanical Systems and Signal Processing*, 2016, 72: 328-345.
- [2] Luo L, Bao S, Mao J, et al. Nonlinear process monitoring based on kernel global-local preserving projections[J]. *J of Process Control*, 2016, 38: 11-21.
- [3] Li W, Yue H H, Valle-Cervantes S, et al. Recursive PCA for adaptive process monitoring[J]. *J of Process Control*, 2000, 10(5): 471-486.
- [4] Hrv A, Oja E. Independent component analysis: Algorithms and applications[J]. *Neural Networks*, 2000, 13(4): 411-430.
- [5] Cai L, Tian X, Zhang N. A kernel time structure independent component analysis method for nonlinear process monitoring[J]. *Chinese J of Chemical Engineering*, 2014, 22(11): 1243-1253.
- [6] Huang J, Yan X. Related and independent variable fault detection based on KPCA and SVDD[J]. *J of Process Control*, 2016, 39: 88-99.
- [7] Wang B, Jiang Q, Yan X. Fault detection and identification using a Kullback-Leibler divergence based multi-block principal component analysis and bayesian inference[J]. *Korean J of Chemical Engineering*, 2014, 31(6): 930-943.
- [8] Ge Z, Song Z. Two-level multiblock statistical monitoring for plant-wide processes[J]. *Korean J of Chemical Engineering*, 2009, 26(6): 1467-1475.
- [9] Ge Z, Song Z. Distributed PCA model for plant-wide process monitoring[J]. *Industrial & Engineering Chemistry Research*, 2013, 52(5): 1947-1957.
- [10] Jiang Q, Wang B, Yan X. Multiblock independent component analysis integrated with hellinger distance and bayesian inference for non-Gaussian plant-wide process monitoring[J]. *Industrial & Engineering Chemistry Research*, 2015, 54(9): 2497-2508.
- [11] Jiang Q, Yan X. Plant-wide process monitoring based on mutual information-multiblock principal component analysis[J]. *ISA Trans*, 2014, 53(5): 1516-1527.
- [12] Jiang Q, Yan X. Nonlinear plant-wide process monitoring using MI-spectral clustering and Bayesian inference-based multiblock KPCA[J]. *J of Process Control*, 2015, 32: 38-50.
- [13] Huang J, Yan X F. Dynamic process fault detection and diagnosis based on dynamic principal component analysis, dynamic independent component analysis and Bayesian inference[J]. *Chemometrics and Intelligent Laboratory Systems*, 2015, 148: 115-127.
- [14] 江伟, 王昕, 王振雷. 基于LTSA和MICA与PCA联合指标的过程监控方法及应用[J]. *化工学报*, 2015, 66(12): 4895-4903.
(Jiang W, Wang X, Wang Z L. LTSA and combined index based MICA and PCA process monitoring and application[J]. *CIESC J*, 2015, 66(12): 4895-4903.)
- [15] 葛志强. 复杂工况过程统计监测方法研究[D]. 杭州: 浙江大学控制科学与工程学院, 2009.
(Ge Z Q. Statistical process monitoring research of complex states[D]. Hangzhou: School of Control Science and Engineering, Zhejiang University, 2009.)
- [16] Li X, Yang Y, Zhang W. Statistical process monitoring via generalized non-negative matrix projection[J]. *Chemometrics and Intelligent Laboratory Systems*, 2013, 121: 15-25.
- [17] 杨正永, 王昕, 王振雷. 基于LTSA和联合指标的非高斯过程监控方法及应用[J]. *化工学报*, 2014, 66(4): 1370-1377.
(Yang Z Y, Wang X, Wang Z L. LTSA and combined index based non-Gaussian process monitoring and application[J]. *CIESC J*, 2014, 66(4): 1370-1377.)
- [18] Yue H H, Qin S J. Reconstruction-based fault identification using a combined index[J]. *Industrial and Engineering Chemistry Research*, 2001, 40(20): 4403-4414.
- [19] Chiang L H, Russell E L, Braatz R D. *Fault detection and diagnosis in industrial systems*[M]. London: Springer, 2001: 103.

(责任编辑: 郑晓蕾)