

# 一种基于多工况识别的过程在线监测方法

熊伟丽<sup>1,2†</sup>, 郭校根<sup>2</sup>

(1. 江南大学 轻工过程先进控制教育部重点实验室, 江苏 无锡 214122;

2. 江南大学 物联网工程学院, 江苏 无锡 214122)

**摘 要:** 在包含多个工况的工业生产过程中, 各个稳态工况之间存在着一定的过渡过程, 虽然过渡时间较短, 但其复杂的动态特性使得传统的过程监测方法难以获得满意的效果, 为此提出一种基于多工况识别的过程监测方法. 首先, 通过窗口切割对基本稳态工况进行识别; 然后, 采用滑动窗技术确定过渡过程的起始和结束时间, 并进一步基于差分分段技术对过渡过程的子阶段进行分类, 考虑到各阶段数据的不同分布特性, 利用独立成分分析和主元分析分别提取各阶段数据的非高斯和高斯信息; 最后根据贝叶斯推断将 3 个统计量进行重构, 实现多工况过程的在线监测. 通过 TE 过程的仿真研究, 验证了所提出方法的可行性和有效性.

**关键词:** 多工况识别; 稳态工况; 过渡过程; 过程监测

中图分类号: TP273

文献标志码: A

## A process on-line monitoring method based on multi-mode identification

XIONG Wei-li<sup>1,2†</sup>, GUO Xiao-gen<sup>2</sup>

(1. China Key Laboratory of Advanced Process Control for Light Industry Ministry of Education, Jiangnan University, Wuxi 214122, China; 2. School of the Internet of Things Engineering, Jiangnan University, Wuxi 214122, China)

**Abstract:** In the industrial production process containing a number of different modes, there is a certain transition process between every two steady modes. Although the transition period is rather short, its the complex dynamic behavior makes traditional process monitoring methods difficult to obtain satisfactory results. Therefore, a process monitoring method based on multi-mode identification is proposed. Firstly, the identification of the basic steady modes is realized through a window cutting method. Then, the accurate time boundaries of transitional modes are determined by using a moving window strategy, and a differential segmentation technique is performed on the sub-modes of the transitional process for classification. Considering different distribution characteristics of each data segment, independent component analysis and principal component analysis are carried out to deal with the non-Gaussian and Gaussian information. Finally, according to the Bayesian inference, three statistics are reconstructed to realize the multi-mode process monitoring. The feasibility and effectiveness of the proposed method are later demonstrated through a simulated Tennessee Eastman(TE) process.

**Keywords:** multi-mode identification; steady mode; transition mode; process monitoring

## 0 引 言

由于产品的制造需要经过复杂的加工过程, 生产方案的改动或者多个目标产品的需求, 使得生产过程呈现多种不同的过程特性, 即多种工况. 多工况过程包含多个稳定的工作状态, 每个稳态工况运行数据的均值和方差等特征信息会有明显的差异. 不同稳态工况之间一般由相对短暂的过程衔接, 一般认为过渡过程, 此过程数据包含了比较复杂的动态特性. 对

于这种包含多工况以及过渡过程的复杂生产过程, 其建模和过程监测问题一直是研究的热点. Ma 等<sup>[1]</sup>采用一种局部邻域标准化(LNS)预处理策略与 PCA 相结合的方法成功地将多工况数据处理为一个全局模型, 使得在线监测时不需要关注当前过程的运行状态, 这种基于全局模型的方法一般适用于各个工况非常接近的情形. Teppola 等<sup>[2]</sup>利用自适应模糊 C 均值聚类, 根据均值判断工况的改变更新模型, 解决了

收稿日期: 2017-01-09; 修回日期: 2017-05-15.

基金项目: 国家自然科学基金项目(61773182, 21206053); 江苏省“六大人才高峰”计划项目(2013-DZXX-043).

责任编委: 姜斌.

作者简介: 熊伟丽(1978—), 女, 教授, 博士, 从事复杂工业过程建模及优化、智能优化算法及应用等研究; 郭校根(1991—), 男, 硕士生, 从事工业过程监控的研究.

†通讯作者. E-mail: greenpre@163.com

过程漂移引起的均值变化问题. Ge等<sup>[3]</sup>将即时学习(JITL)思想与局部最小二乘支持向量回归(LSSVR)相结合更新局部模型来处理多工况监测问题,但此类方法的模型更新时机和规则难以确定. 根据多工况数据的时变、动态和非线性等特征,目前研究较多的是基于多模型的监测方法. 该方法的基本思想是将不同阶段分别建立不同的模型进行监测,每个模型都能更加准确地对该阶段数据进行描述,从而能够获得更好的监测性能. 对于多阶段、多工况过程的监测问题,Zhao等<sup>[4-6]</sup>做了很多相关研究,包括通过分析载荷矩阵的变化实现过渡过程的软划分、采用ICA-PCA两步提取策略直接分析批次间的相对变化和交叉模式进行分析监测等,都成功地应用到了多阶段批次过程和多工况连续过程中. 另外,孙贤昌等<sup>[7]</sup>利用高斯混合模型(GMM)描述多工况数据,用不同的高斯成分表征不同的工况. Xie等<sup>[8]</sup>将高斯混合模型和邻近保留投影方法相结合,能够得到最优的聚类数目,进一步改善了监测性能. 周福娜等<sup>[9]</sup>采用微分几何特征抽取的方式提取过渡阶段的动态特征,进而完成在线监测. 谭帅等<sup>[10]</sup>考虑到过渡阶段数据的动态特性,分别对稳态工况和过渡阶段建立高斯混合模型,弥补了整体高斯混合模型的缺陷. 但在多工况生产过程中,不同工况的过程变量不一定服从同一种分布,在这种情况下用传统的多元统计方法对过程进行监测势必会导致监测结果的不准确.

综合以上分析,考虑多个稳态工况、过渡阶段的识别和工业数据服从不同分布等特点,采用窗口划分、滑动窗技术、独立成分分析(ICA)和主成分分析(PCA)等方法对多工况过程进行过程监测. 该方法按照样本数据采集的时间顺序使用等长窗口对完整历史数据进行切割,以对稳态工况进行初步识别;采取滑动窗技术跟踪不确定时段数据的变化特征,在窗口内所有数据偏离原有特征的情况下,捕捉到过渡阶段的起始和结束位置,从而确定过渡过程;利用差分分类的思想对过渡过程进行划分,使得每一个阶段能较好地刻画过渡数据的时变特性;对每个阶段的数据利用ICA-PCA方法从非高斯和高斯分布的角度分析数据建立模型,并应用贝叶斯推断重构统计量,从而完成多工况过程的故障监测.

## 1 多工况过程的离线工况识别

### 1.1 稳态工况的识别

给定多工况过程正常运行数据集  $\mathbf{X} \in \mathbf{R}^{m \times n}$ , 其中  $m$  是过程变量的维数,  $n$  是样本的个数. 假设从初始稳态工况开始采集,根据经验定义最小稳态过程

运行时间长度为  $T_m$ , 过渡过程的时间小于  $T_m$ .

首先,进行窗口切割. 选取长度为  $H$  的窗口对历史数据集  $\mathbf{X}$  沿着采样方向进行等长切割,将  $n$  个样本数据分割成  $K$  个窗口. 当  $n$  是  $H$  的整数倍时,  $n$  可以表示为  $n = K \times H$ ; 否则,  $n = (K - 1) \times H + d$  ( $0 < d < H$ ). 求取每个窗口矩阵的均值向量,记为  $\bar{\mathbf{x}}_i$ ,  $i = 0, 1, \dots, K$ , 这些均值向量代表了每个窗口的特征信息,利用这些特征信息对窗口进行初始类别划分,并进行各个稳态工况识别. 以第1个窗口  $\mathbf{X}_1$  作为稳态工况  $A$  的基准窗口  $\mathbf{X}_{\text{base}}$ ,按照相似度计算公式

$$\gamma_{i,j} = \exp\left(-\frac{\|\bar{\mathbf{x}}_i - \bar{\mathbf{x}}_j\|}{2m}\right), \quad i, j = 1, 2, \dots, K, \quad (1)$$

依次计算  $\mathbf{X}_{\text{base}}$  后面的窗口和其相似度,并设定相似度阈值  $\alpha$ . 如果  $\mathbf{X}_2$  和  $\mathbf{X}_{\text{base}}$  的相似度大于阈值  $\alpha$ ,则认为  $\mathbf{X}_2$  也属于稳态工况  $A$ ,然后继续计算下一个窗口和  $\mathbf{X}_{\text{base}}$  的相似度;否则,认为  $\mathbf{X}_2$  属于下一个阶段,并令  $\mathbf{X}_{\text{base}} = \mathbf{X}_2$ ,按上述步骤继续进行. 稳态工况识别过程如图1所示.

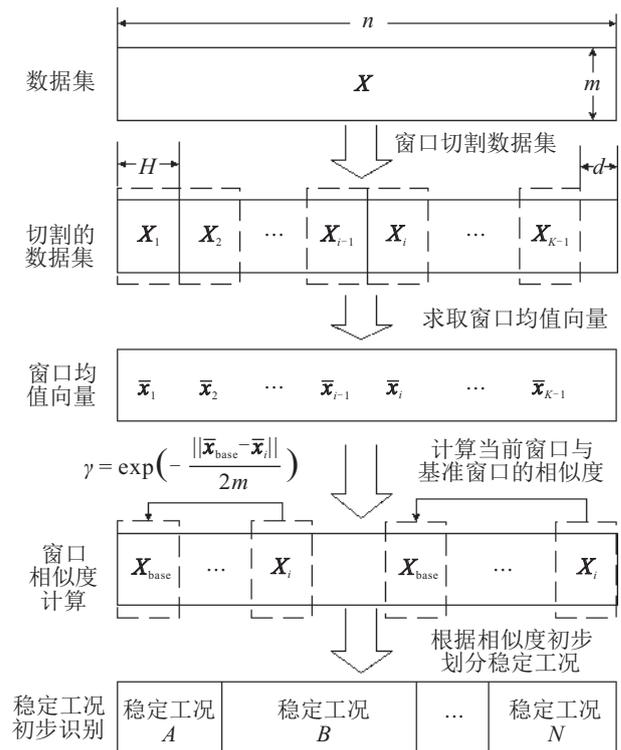


图1 基于窗口切割的稳态工况识别流程

窗口长度  $H$  和相似度阈值  $\alpha$  的选取都会直接影响到稳态工况的识别效果. 首先  $H$  的时间长度不能小于  $T_m$ , 因为  $H$  过小会使得过渡过程被切割成多份, 容易造成部分过渡过程数据融入到稳态工况中, 且会使噪声等扰动的影响扩大, 不利于后续过渡阶段的精确确定;  $H$  过大可以增强抗干扰能力, 但是各稳态工况的识别长度会放宽; 由于数据库中包含稳态和过

渡过程数据,数据复杂程度高,需要根据实际情况选择窗口长度,一般可以选取时间长度为 $T_m$ 的样本数作为窗口长度.其次,相似度阈值 $\alpha$ 也需要根据实际情况试凑,若 $\alpha$ 选取过大,则要求每一个窗口和基准窗口的相似程度较高,可能会使原本的稳态数据被划分到过渡过程中;反之,相似度要求较宽松,会导致原本的过渡过程数据划分到稳态过程中,从而影响工况的识别效果.

## 1.2 过渡阶段的确定与子阶段分类

在识别出稳态工况后,需要在相邻稳态工况之间进一步确定过渡阶段,即确定过渡阶段的起始和结束位置.由于过渡阶段时间长度不会大于 $T_m$ ,过渡过程的位置存在两种情形:

1) 相邻稳态工况差异较大,即过渡过程变化较大时,其起始位置肯定在工况发生改变的两个相邻窗口之间,这两个相邻窗口是既包含稳态过程数据又包含过渡阶段数据的不确定时段.

2) 相邻稳态工况差异较小,即过渡过程相对平缓时,过渡过程的起始和结束位置都在同一个窗口内.

如图2所示,假设稳态工况A和B之间发生工况改变的窗口为第 $k_1$ 个,则过渡过程起始位置存在两种状态:第1种状态是起始点在第 $k_1 - 1$ 个窗口的后半段,而窗口大部分数据属于稳态工况A,因此第 $k_1 - 1$ 个窗口和稳态A的相似度较高,被划分到稳态工况A中;第2种状态是起始点发生在第 $k_1$ 个窗口的前半段,窗口只有较少的数据和稳态A相似,因此被划分到稳态工况B中;同理,第3种和第4种状态是平缓过渡过程的两种状态.

基于以上分析,在进行过渡过程起始和结束位置确定时,可以采取滑动窗来捕捉数据特征发生变化的位置.选取长度为 $L(L < H/2)$ 的窗口,以步长 $h$ 按采样时间顺序从第 $k_1 - 1$ 个窗口由前向后滑动,设定相似度阈值为 $\beta$ .为了提高识别效果的稳健性,减小噪声等扰动的影响,通过比较滑动窗内每一个样本与稳态工况A的相似度确定过渡过程的起始时刻,只有窗口内每1个样本点与稳态工况A的相似度超过阈值 $\beta$ 时,才认为该滑动窗的第一个样本点为过渡过程起始点.同理,确定过渡过程结束点时,从第 $k_1 + 1$ 个窗口将滑动窗口按采样时间顺序由后向前滑动,通过比较每个窗口内样本与稳态工况B的相似度确定过渡过程的结束时刻.假如过渡起始和结束位置之间的时长超过 $T_m$ ,则按起始时刻开始经过 $T_m$ 后过渡过程结束处理.

为了提高过渡起始、结束位置的识别精度,滑动

窗宽度 $L$ 一般取得比较小,但是过小会放大噪声的影响,过大又可能受到奇异点的影响,导致识别精度下降;滑动步长 $h$ 一般也取较小的值,甚至可以取1,取得过大会加快运算速度,但是识别精度会下降;相似度阈值 $\beta$ 可以利用滑动窗 $L$ 在确定的稳态工况中滑动,并求得一系列滑动窗内数据与该稳态工况的相似度值,应用核密度估计来计算合理的阈值.

由于过渡过程的数据特征会随时间发生较大变化,使用单一模型往往得不到良好的监测效果.为了更加准确地描述过渡阶段的数据特性,本文应用多模型的思想进行监测.如果按上述窗口划分方法直接对过渡数据进行划分建模,则几乎每一个窗口都需要建立一个子模型,模型过多会使得用来建模的样本数很少,模型描述反而不准确,引入较大的误报率.尽管过渡过程数据在运行时会发生变化,但是正常过渡过程数据在变化的同时存在某种固有的规律.而差分技术可以直观地将数据变化的趋势展现出来,根据数据变化的趋势对过渡阶段数据进行分类,建立适当数量的子模型,提高多工况过程的监测效果.假设一个完整批次中的某个过渡过程数据集为 $\mathbf{X}_t = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n] \in \mathbf{R}^{m \times n}$ .按照下式对数据集进行差分,实现过渡数据集的重构:

$$\mathbf{d}_i = \mathbf{x}_{i+1} - \mathbf{x}_i, i = 1, 2, \dots, n - 1, \quad (2)$$

得到差分矩阵 $\mathbf{D} = [\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_{n-1}] \in \mathbf{R}^{m \times (n-1)}$ .假如直接应用建模方法对获得的差分矩阵建模,将不会获得有效的监测效果.因为当故障发生后,运行数据会发生偏移,其变化趋势并不一定会发生特别大的变化,而且过渡过程结束后,由于正常稳态工况变量相对变化小使得不能确定何时进入稳态工况.根据差分矩阵可以反映该过渡过程变化趋势的特点,可以对差分矩阵进行分类,即按照稳态工况识别的窗口切割方法对 $\mathbf{D}$ 进行划分分类,然后按照 $\mathbf{D}$ 的划分结果将过渡数据划分为相同的类别,即将变化趋势相近的过渡数据分为同一类,最后对每一类数据分别进行建模和监测.

## 2 多工况过程的在线监测

### 2.1 ICA-PCA-BI监测方法

在多工况工业生产过程中,很难保证来自所有工况的数据都服从高斯分布.因此,采用ICA-PCA方法从非高斯空间和高斯空间分析对应的工况,并结合贝叶斯推断将多个统计量组合成一个监测统计量,实现多工况过程的在线监测,本文将此方法简称为ICA-PCA-BI方法.假设 $\mathbf{X} \in \mathbf{R}^{m \times n}$ 为包含 $m$ 个过程变量

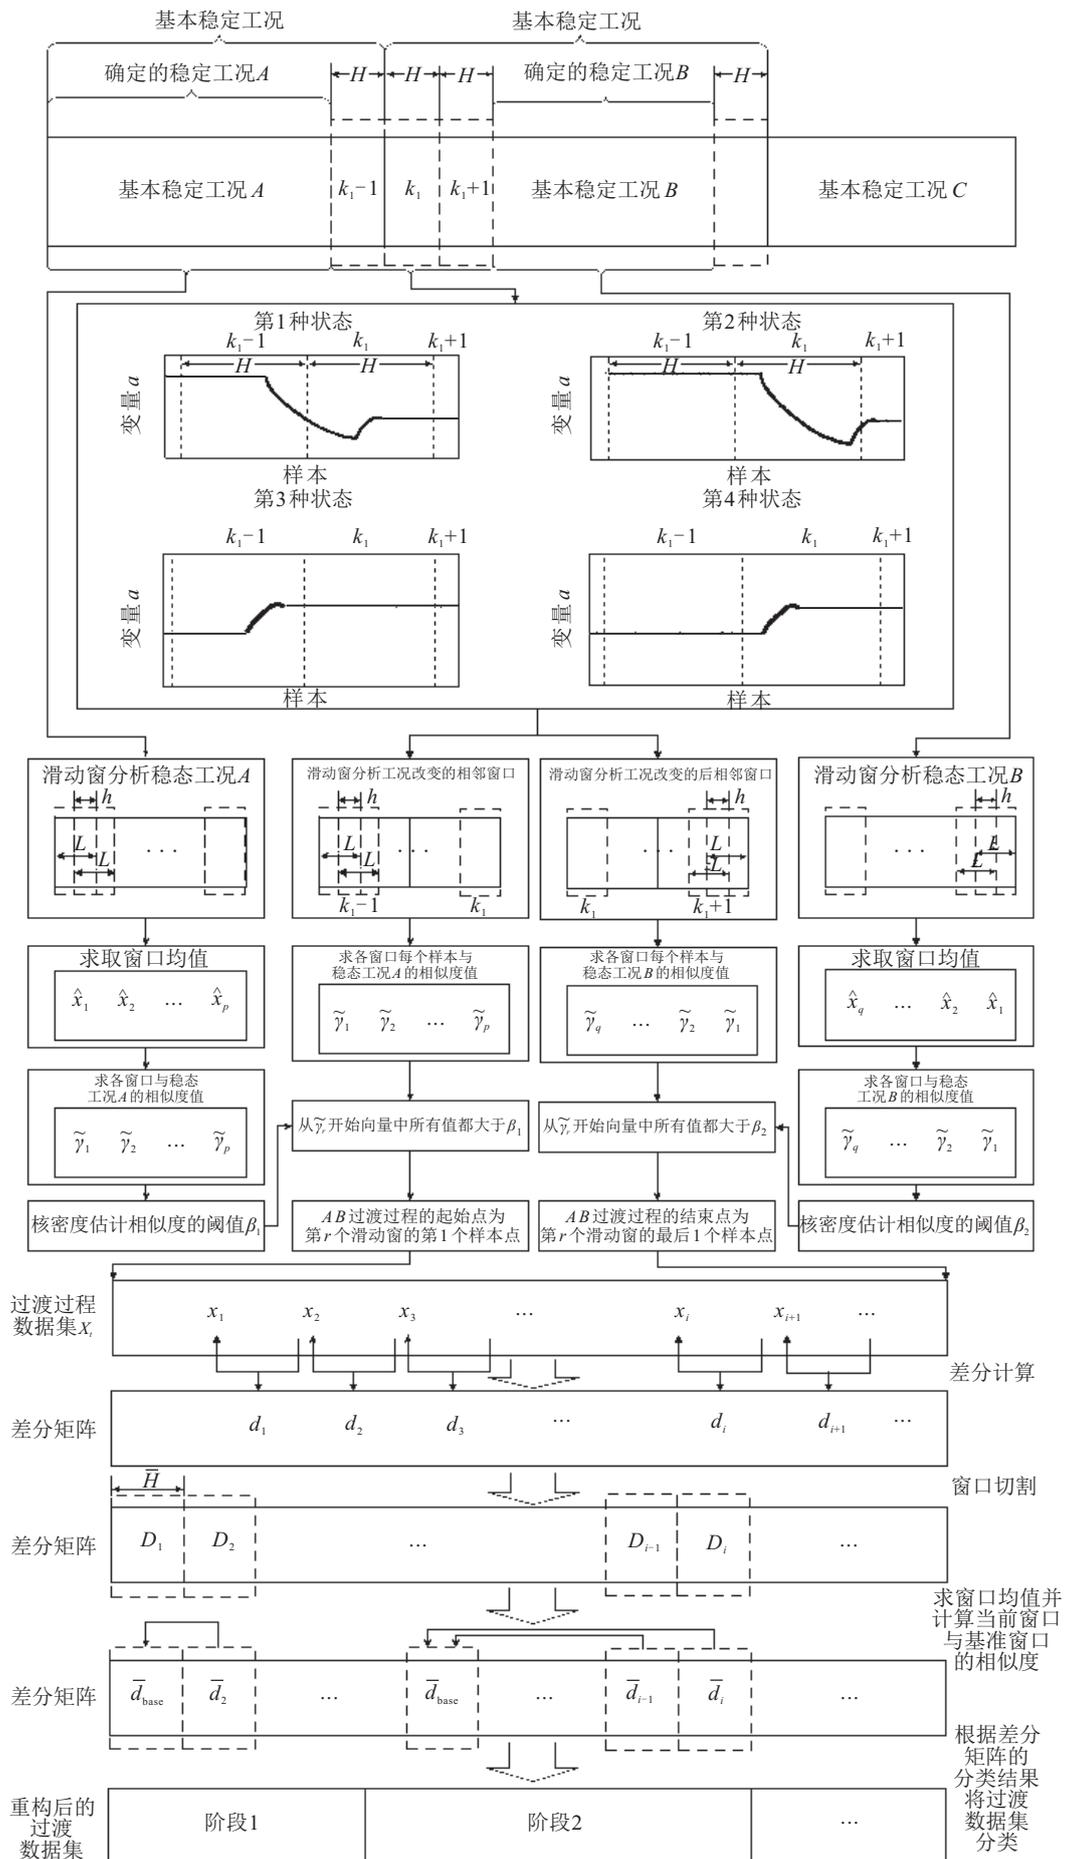


图2 多工况准确识别和过渡子阶段划分流程

和  $n$  个样本点的正常运行数据集,进行独立主元分析可得

$$\mathbf{X} = \mathbf{AS} + \mathbf{E}_{ICA}. \quad (3)$$

数据集  $\mathbf{X}$  可以看作是  $r (r \leq m)$  个独立成分  $\mathbf{S} = [\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_r]^T \in \mathbf{R}^{r \times n}$  的线性组合,  $\mathbf{A} \in \mathbf{R}^{m \times r}$  为混合系数矩阵,  $\mathbf{E}_{ICA} \in \mathbf{R}^{m \times n}$  为残差矩阵. 对于新数据样本  $\mathbf{x}_{new} \in \mathbf{R}^m$ ,  $I^2$  统计量可以计算为

$$I_{new}^2 = \hat{\mathbf{s}}^T(k) \hat{\mathbf{s}}(k) \leq I_{lim}^2. \quad (4)$$

其中:  $\hat{\mathbf{s}}(k) \in \mathbf{R}^r$  为新样本的独立主元估计,  $I_{lim}^2$  为应用核密度估计出的控制限. 对残差矩阵  $\mathbf{E}_{ICA}$  应用 PCA 处理分析, 有

$$\mathbf{E}_{ICA} = \mathbf{TP}^T + \mathbf{E}_{PCA}. \quad (5)$$

其中:  $\mathbf{T} \in \mathbf{R}^{n \times q}$  和  $\mathbf{P} \in \mathbf{T}^{m \times q}$  分别为主元空间的得分矩阵和载荷矩阵,  $\mathbf{E}_{PCA}$  为残差矩阵.  $T^2$  统计量和 SPE 统计量可以分别计算为

$$T_{new}^2 = \mathbf{x}_{new} \mathbf{P} \mathbf{A}^{-1} \mathbf{P}^T \mathbf{x}_{new} = \mathbf{t} \mathbf{A}^{-1} \mathbf{t}^T \leq T_{\alpha}^2, \quad (6)$$

$$\text{SPE}_{new} = \mathbf{x}_{new}^T (\mathbf{I} - \mathbf{P} \mathbf{P}^T) \mathbf{x}_{new} \leq \delta_{\alpha}^2. \quad (7)$$

其中:  $\mathbf{t}$  为主元得分向量,  $\mathbf{A}$  为前  $q$  个主元所对应的特征值组成的对角矩阵,  $T_{\alpha}^2$  和  $\delta_{\alpha}^2$  分别为显著水平是  $\alpha$  的  $T^2$  和 SPE 统计量的控制限. 由于经过 ICA-PCA 分析处理后将产生 3 个统计量, 各个控制限也不一致, 易造成观察的不便. 因此, 应用贝叶斯推断从概率角度上将上述统计量组合重构, 获得单一统计量, 方便操作人员观察, 提高过程监测效率. 非高斯空间  $\mathbf{X}_{ICA}$  发生故障的概率为

$$P_{I^2(F|\mathbf{X}_{ICA})} = \frac{P_{I^2(\mathbf{X}_{ICA}|F)} P_{I^2 F}}{P_{I^2 \mathbf{X}_{ICA}}}. \quad (8)$$

其中

$$P_{I^2 \mathbf{X}_{ICA}} = P_{I^2(\mathbf{X}_{ICA}|N)} P_{I^2 N} + P_{I^2(\mathbf{X}_{ICA}|F)} P_{I^2 F},$$

$\mathbf{X}_{ICA}$  为当前样本  $\mathbf{X}$  的非高斯空间,  $F$  为故障情形,  $N$  为正常情形,  $P_{I^2 N}$  和  $P_{I^2 F}$  分别设置为  $\omega$  和  $1 - \omega$ ,  $\omega$  为置信水平,  $P_{I^2(\mathbf{X}_{ICA}|N)}$  和  $P_{I^2(\mathbf{X}_{ICA}|F)}$  计算为

$$P_{I^2(\mathbf{X}_{ICA}|N)} = \exp\left(-\frac{I_{new}^2}{I_{lim}^2}\right), \quad (9)$$

$$P_{I^2(\mathbf{X}_{ICA}|F)} = \exp\left(-\frac{I_{lim}^2}{I_{new}^2}\right). \quad (10)$$

同理,  $P_{T^2(F|\mathbf{X}_{PCA})}$  和  $P_{\text{SPE}(F|\mathbf{X}_{PCA})}$  也可以计算获得. 最后根据贝叶斯推断计算统计量

$$\text{BIC} = \frac{P_{I^2(F|\mathbf{X}_{ICA})}^2 + P_{T^2(F|\mathbf{X}_{PCA})}^2 + P_{\text{SPE}(F|\mathbf{X}_{PCA})}^2}{P_{I^2(F|\mathbf{X}_{ICA})} + P_{T^2(F|\mathbf{X}_{PCA})} + P_{\text{SPE}(F|\mathbf{X}_{PCA})}}. \quad (11)$$

BIC 的控制限为  $1 - \omega$ , 当 BIC 的值大于  $1 - \omega$  时, 认为发生故障, 否则认为过程运行正常.

## 2.2 离线建模与在线监测

本文的过程监测流程如图 3 所示, 包括离线的稳态工况和过渡过程的识别、离线的统计建模和在线监测 3 个主要部分. 在基于窗口划分的离线工况识别后, 稳态工况和过渡阶段的各个子阶段被划分开来. 由于在复杂工业生产过程中, 很难保证每个工况数据都服从高斯分布, 并且稳态工况和过渡过程数据也存在着较大的差异, 采用 ICA-PCA-BI 的建模方法从数据的非高斯空间和高斯空间角度分别对相应工况阶段进行分析处理, 最终只有一个监测变量, 既提高了效率又简化了监测过程.

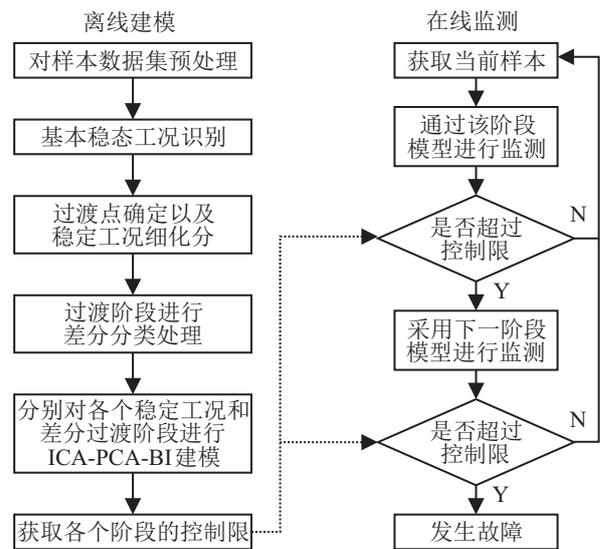


图 3 基于多工况识别的过程监测方法

在线监测时, 第 1 个监测样本需要知道当前处于的具体阶段位置, 利用对应的模型进行监测, 假设系统运行于稳态工况  $A$ , 下一个稳态工况为  $B$ , 当前采样点监测值没有超过控制限时, 表明运行状态正常. 为了提高监测过程的稳健性, 当连续  $R$  个采样点超过控制限时, 认为可能出现两种情况: 生产过程开始进入  $AB$  过渡阶段或系统出现故障. 针对上述两种情况进一步排除检验, 根据生产运行状态不可能发生突变, 首先认为系统进入过渡阶段, 利用  $AB$  过渡阶段的第 1 个子模型进行监测, 假如没有超过控制限, 则说明系统进入过渡阶段, 接下来的样本点采用该模型继续监测; 否则, 认为发生故障.

## 3 仿真实验

### 3.1 基于 TE 过程的仿真实验设计

TE 过程是一个典型的化工过程, 此仿真平台目前已广泛应用于多变量统计建模分析领域. 系统由反应器、冷凝器、循环压缩机、解吸塔和气液分离器等 5 个单元组成. 过程共包含 41 个测量变量和 12 个操作变量. 研究表明, TE 过程的反应器压力在不同

的设定值情况下就是一个典型的多工况过程<sup>[11]</sup>. 本文根据反应器压力值设计两种不同的稳态工况,并选取15个过程连续测量变量作为被监控变量,如表1所示.

表1 TE过程变量表

序号	变量名称	序号	变量名称
1	A进料量(流1)	9	分离器温度
2	D进料量(流2)	10	分离器压力
3	E进料量(流3)	11	分离器塔底流量(流10)
4	A、C混合物进料量	12	汽提塔压力
5	再循环流量(流8)	13	汽提塔温度
6	反应器进料速度(流6)	14	反应器冷却水出口温度
7	反应器温度	15	分离器冷却水出口温度
8	排放速度(流9)		

实验模拟140h的仿真过程,采样频率为每小时100次,最短稳态运行时间为25h,其中改变2次反应器压力的设定值,从而得到3种稳态运行工况. 初始反应器压力设置为2800kPa,命名为稳态工况A. 当运行至40h时,将反应器压力设置为2500kPa,过程开始进入过渡阶段1,在57.8h时,过渡结束,过程进入稳态工况B. 在稳态工况B运行至90h时,将反应器压力设置为2600kPa,过程开始进入过渡阶段2. 在94.7h时,过渡结束,过程进入稳态工况C. 用于仿真的采样数据共14000个.

### 3.2 稳态工况的初步识别

初始稳态工况识别时,首先需要对本数据集进行标准化处理,去掉不同量纲带来的影响. 为比较不

同窗口宽度 $H$ 和相似度阈值 $\alpha$ 的取值不同所带来的影响,针对 $H$ 的3种取值( $H = 100$ ,  $H = 2500$ 和 $H = 6000$ )和 $\alpha$ 的3种取值( $\alpha = 0.85$ ,  $\alpha = 0.9$ 和 $\alpha = 0.95$ )进行讨论分析.

如图4所示,当 $H = 100$ 时样本数据集被切割成140个窗口,由于窗口宽度太小,放大了扰动的影响,不同窗口数据之间差异增大,导致划分出的类别比较多,且大部分类别的数据都不满足运行时长大于最小稳态时间的条件. 随着 $\alpha$ 的减小,可以减少类别的个数,但是 $\alpha$ 过小可能会使得部分过渡过程划分到稳态过程中,容易得到错误的结论. 当 $H = 6000$ 时样本数据集被切割成3个窗口,由于窗口宽度过大,在提高对噪声、奇异点冗余能力的同时导致过渡过程完全被包含在稳态工况内,3个稳态工况间数据差异性减小,因此出现了1种稳态工况的情形,将 $\alpha$ 的值提高到0.95时,仍然只能划分出2个稳态工况;当 $H = 2500$ 时,样本集被切割成6个窗口,在 $\alpha = 0.9$ 时能够识别出3种稳态工况,但是需要注意的是,连续3个窗口属于不同稳态工况的情况下,根据 $T_m$ 选择的是最小稳态过程运行时间,即同一个窗口中不可能包含2段过渡过程,即该情况下只包含一个过渡过程,发生这种情况是过渡过程的信号幅值变化较大引起的,因此,可以通过提高 $\alpha$ 值进行解决,当 $\alpha = 0.95$ 时,可以获得2个过渡过程、3个稳态工况的结果. 综合上述分析,本文选取 $H = 2500$ ,  $\alpha = 0.95$ .

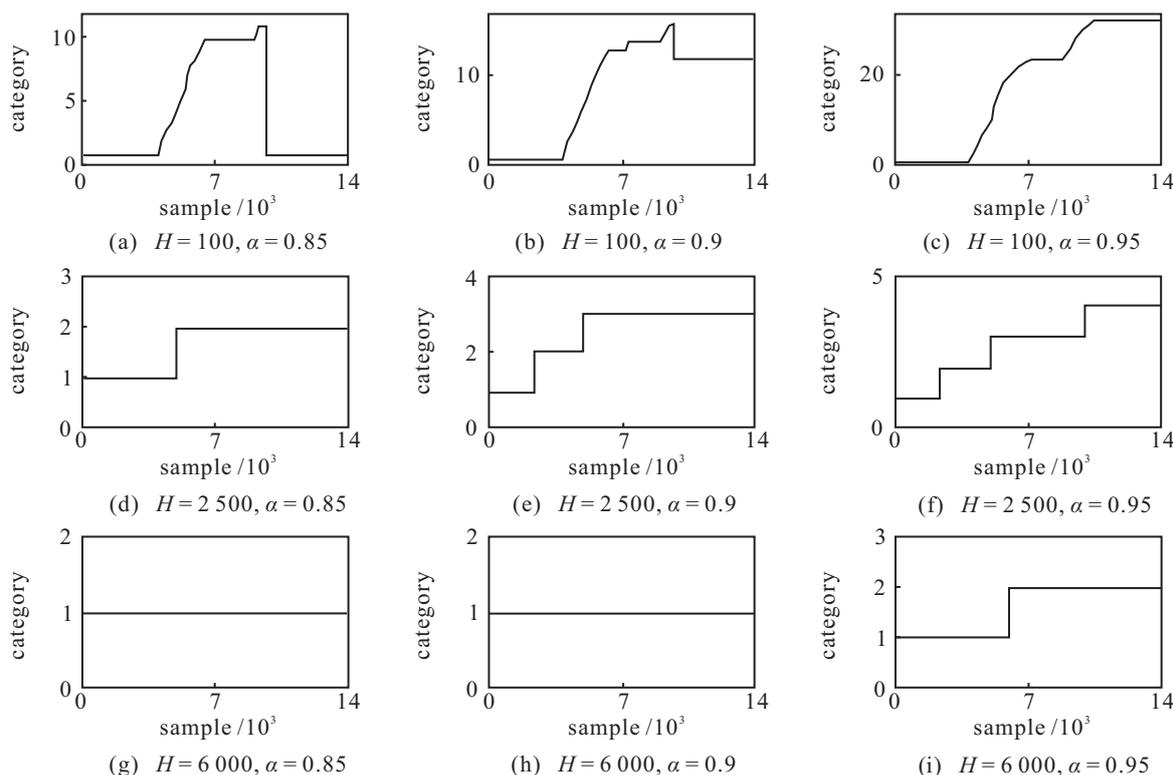


图4 不同窗口宽度和相似度阈值划分结果

### 3.3 过渡阶段确定与稳态工况的细划分

基本稳态工况确定后,需要在相邻稳态工况之间寻找出过渡阶段.根据过渡阶段的动态特性,利用滑动窗口技术可以有效跟踪过渡数据的变化特性.为了分析滑动窗口 $L$ 和滑动步长 $h$ 的影响,对 $L = 1$ 和 $L = 200$ 分别在 $h = 1$ 和 $h = 10$ 的情况下进行仿真,过渡过程1和过渡过程2的识别结果分别如表2和表3所示.当窗口宽度 $L = 1$ ,即通过单一样本比较时,没有窗口对样本数据进行限制,导致过渡过程受噪声、奇异点的影响特别明显,无论步长大小,都容易得到错误的过渡位置.当窗口宽度 $L = 200$ 时,通过比较可以发现,设置滑动窗口后明显提高了抗干扰能力,当 $h = 10$ 时,窗口滑动速度较快,在一定程度上能够提高运算速度,但是太快的速度可能导致真正的起始、结束位置被错过.而减小滑动速度可以提高识别精确性,可以看出,当 $h = 1$ 时,平缓的滑动速度能更好地把握数据变化的细节,识别效果明显.找到确定的过渡阶段起始和结束位置后,将分析窗口中剩余的非过渡阶段数据分别规划到对应的稳态工

况中,完成稳态工况的最终确定.完整离线数据经过上述处理获得的稳态工况和过渡阶段结果如图5所示,系统从稳态工况A开始运行,经过40.03h后开始进入过渡阶段1,随后经过18.03h后在58.06h进入稳态工况B,接着又在90.31h时进入过渡阶段2,然后经过3.96h后在94.27h进入稳态工况C并持续运行.实验设计表明,本文算法可以有效地进行多工况识别.

表2 过渡过程1的识别结果和误差

滑动窗宽度 $L$	滑动步长 $h$	识别位置 (开始-结束)	总识别误差 (样本数)
1	1	326-2434	7020
1	10	2211-7249	3258
200	1	4003-5806	29
200	10	4011-5800	31

表3 过渡过程2的识别结果和误差

滑动窗宽度 $L$	滑动步长 $h$	识别位置 (开始-结束)	总识别误差 (样本数)
1	1	7508-12459	4481
1	10	7601-12470	4399
200	1	9031-9427	74
200	10	9031-9420	81

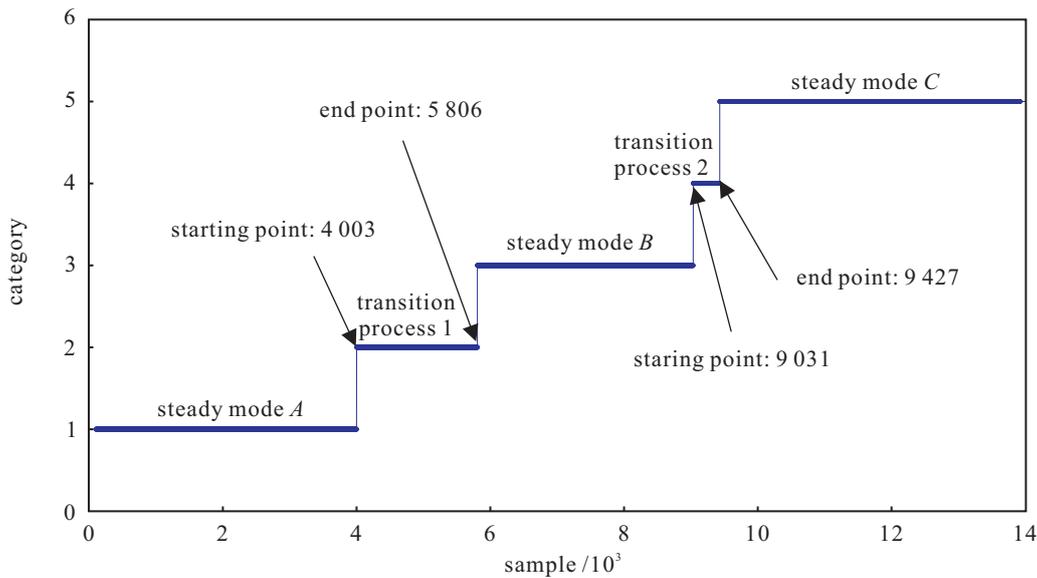


图5 稳态工况与过渡阶段识别结果

### 3.4 过渡子阶段划分及过程监测

考虑到过渡过程数据包含着复杂的动态特性,直接对其建模会带来较高的漏报率,但基于过渡阶段数据划分进行建模,建模复杂且建模样本数太少,也会影响模型准确性.考虑采用差分分类技术,将过渡数据集进行重构,获取的差分矩阵描述了整个过渡过程的变化趋势.过渡初期由于压力设定值的突然改变导致变量的变化较大,随着过渡的继续进行,工况逐渐向下一个稳定状态靠近,变量的变化趋势逐渐变小.按照过渡过程变量的变化趋势分段,将变化趋势

相近的归为一类,可以有效地控制模型数量,提高模型的稳定性.

根据式(2)对第3.3节划分出的过渡阶段数据进行差分,获得的差分矩阵按 $H = 50$ 、 $\alpha = 0.9$ 进行分类,样本数据的所有变量划分结果如图6和图7所示,横坐标为样本,纵坐标为各变量值.过渡阶段1数据被分成5个子模型:子阶段1(40.03h~41.52h)、子阶段2(41.53h~49.52h)、子阶段3(49.53h~50.52h)、子阶段4(50.53h~53.52h)和子阶段5(53.53h~58.06h).由各子阶段数据的特点可以看出,从稳态

工况 A 开始进入过渡阶段时系统变化较快,经过一小段时间的调整后从子阶段 1 进入子阶段 2,系统变化较为平缓,当到达一定条件后,在子阶段 3 运行数据趋势发生改变,从子阶段 4 开始逐渐向稳态工

况 B 趋近,在子阶段 5 调整后结束过渡阶段,进入稳态工况 B. 由于过渡阶段 2 变化趋势较为平稳,被分为 2 个子模型:子阶段 1(90.31 h~92.80 h)和子阶段 2 (92.81 h~94.27 h).

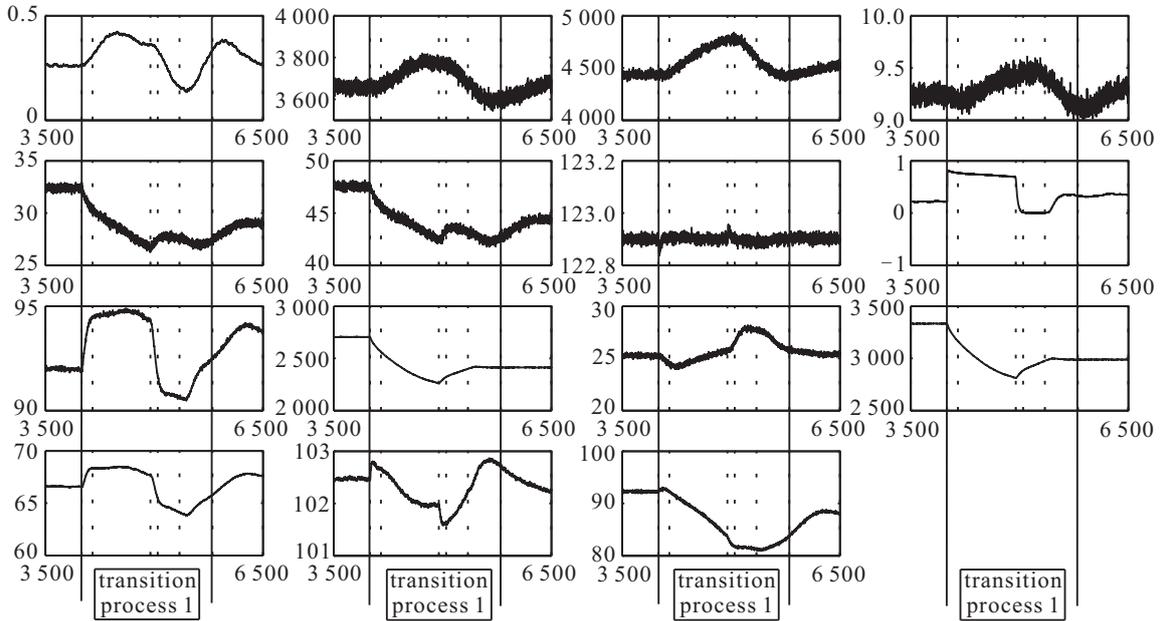


图 6 过渡阶段 1 划分结果

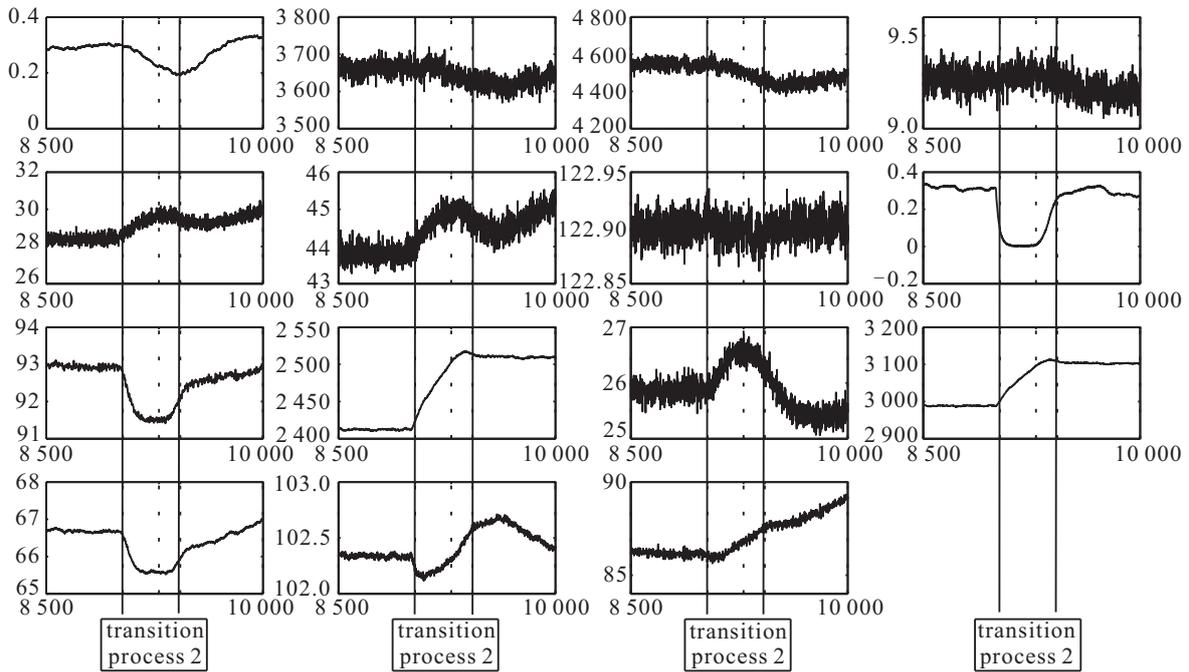


图 7 过渡阶段 2 划分结果

为比较过渡阶段直接建模和本文方法的有效性,分别在系统运行至 44 h 和 91 h 时,保持 A/C 进料流量比不变,使组分 B 含量发生一个阶跃变化故障.在获取在线数据后,应用 ICA-PCA-BI 和 PCA 方法在对过渡阶段直接建模和分段建模 2 种情况下进行对比分析,本文取  $R = 3$ ,即连续 3 个样本点超过控制限即认为发生故障.由图 8 可知,对过渡阶段直接建模时,PCA 几乎监测不到故障,ICA-PCA-BI 具有一定的

监测效果,但是滞后 1.24 h 后才报警,精度不是很理想;而对过渡阶段分段建模后,PCA 恢复了监测能力,但还是在  $T = 44.98$  h 时才报警,而 ICA-PCA-BI 仅在 0.14 h 后便超过控制限.由图 9 可见,同样的建模方法在分段建模时能够获得更好的监测效果.通过对比发现,本文方法的监测性能在 PCA 的基础上有一定的提升,而对过渡阶段分段建模比直接建模具有更高的准确性和鲁棒性.

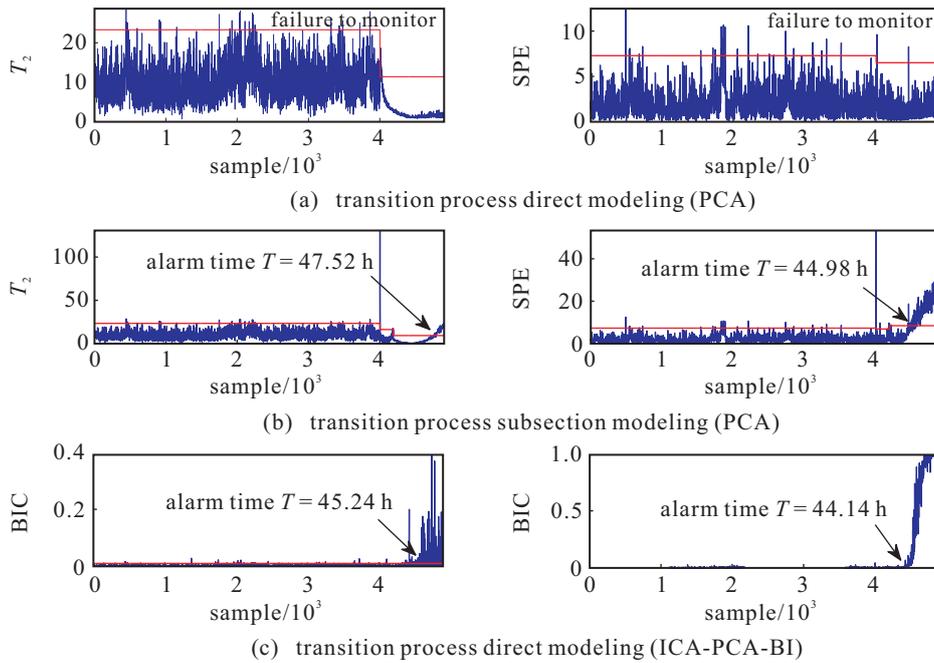


图8 过渡阶段1故障监测对比

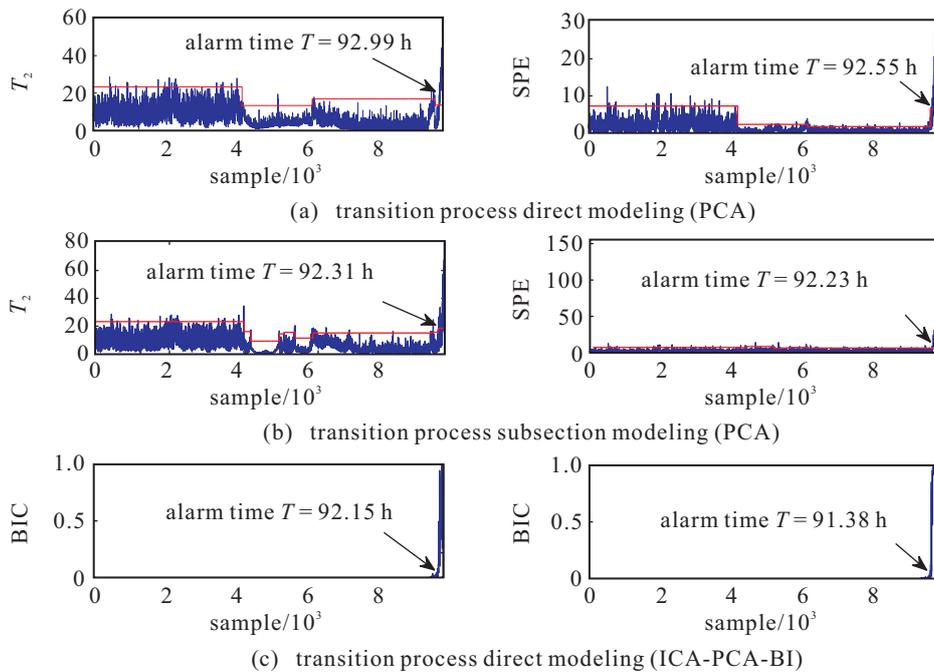


图9 过渡阶段2故障监测对比

### 4 结论

本文针对多工况过程监测问题,不仅考虑过程的多个稳态工况,同时捕捉过渡过程的数据特征,提出了一种基于多工况识别的故障监测方法.该方法通过大小窗口识别工况,确定稳态工况和过渡阶段的界限.利用窗口差分技术对过渡阶段进行分类,结合多模型思想提高过渡阶段监测的准确性.采用ICA-PCA-BI方法从数据不同分布的角度提取过程信息,实现一个统计变量和控制限监测的方案,简化监测过程,提高效率.最后,通过TE仿真平台实验验证了所

提出方法能够实现稳态工况和过渡过程的识别,以及对过程故障的准确监测.

### 参考文献(References)

[1] Ma H H, Hu Y, Shi H B. A novel local neighborhood standardization strategy and its application in fault detection of multimode processes[J]. *Chemometrics and Intelligent Laboratory Systems*, 2012, 118(7): 287-300.  
 [2] Teppola P, Mujunen S P, Minkkinen P. Adaptive fuzzy C-means clustering in process monitoring[J]. *Chemometrics and Intelligent Laboratory Systems*, 1999, 45(1): 23-38.

- [3] Ge Z Q, Song Z H. Online monitoring of nonlinear multiple mode processes based on adaptive local model approach[J]. *Control Engineering Practice*, 2008, 16(12): 1427-1437.
- [4] Zhao C H, Wang F L, Lu N Y, et al. Stage-based soft-transition multiple PCA modeling and on-line monitoring strategy for batch processes[J]. *J of Process Control*, 2007, 17(9): 728-741.
- [5] Zhao C H, Wang F L, Gao F R, et al. Enhanced process comprehension and statistical analysis for slow-varying batch processes[J]. *Industrial & Engineering Chemistry Research*, 2008, 47(24): 9996-10008.
- [6] Zhao C H, Yao Y, Gao F R, et al. Statistical analysis and online monitoring for multimode processes with between-mode transitions[J]. *Chemical Engineering Science*, 2010, 65(22): 5961-5975.
- [7] 孙贤昌, 田学民, 张妮. 一种基于GMM的多工况过程故障诊断方法[J]. *计算机与应用化学*, 2014, 31(1): 33-39.  
(Sun X C, Tian X M, Zhang N. Multi-mode process fault diagnosis method based on GMM[J]. *Computers and Applied Chemistry*, 2014, 31(1): 33-39.)
- [8] Xie X, Shi H B. Dynamic multimode process modeling and monitoring using adaptive Gaussian mixture models[J]. *Industrial and Engineering Chemistry Research*, 2012, 51(15): 5497-5505.
- [9] 周福娜, 杨书娜, 张玉. 基于数据特征抽取技术的多模态异常监测[J]. *自动化与仪器仪表*, 2014, 4: 135-136.  
(Zhou F N, Yang S N, Zhang Y. Feature extraction technique based on multi-modal data anomaly detection[J]. *Automation & Instrumentation*, 2014, 4: 135-136.)
- [10] 谭帅, 常玉清, 王福利, 等. 基于GMM的多模态过程模态识别与过程监测[J]. *控制与决策*, 2015, 30(1): 53-58.  
(Tan S, Chang Y Q, Wang F L, et al. Mode identification and process monitoring for multiple mode processes based on GMM[J]. *Control and Decision*, 2015, 30(1): 53-58.)
- [11] 谢彦红, 孙呈敖, 李元. 基于滑动窗口SVDD的间歇过程故障监测[J]. *信息与控制*, 2015, 44(5): 531-537.  
(Xie Y H, Sun C A, Li Y. Fault monitoring of batch process based on moving window SVDD[J]. *Information and Control*, 2015, 44(5): 531-537.)
- [12] 郭金玉, 齐蕾蕾, 李元. 基于DMOLPP的间歇过程在线故障检测[J]. *仪器仪表学报*, 2015, 36(1): 134-142.  
(Guo J Y, Qi L L, Li Y. On-line fault detection of batch process based on DMOLPP[J]. *Chinese J of Scientific Instrument*, 2015, 36(1): 134-142.)
- [13] Qin J S. Survey on data-driven industrial process monitoring and diagnosis[J]. *Annual Reviews in Control*, 2012, 36(2): 220-234.
- [14] Wang G Z, Liu J C, Zhang Y W. A novel multi-mode data processing method and its application in industrial process monitoring[J]. *J of Chemo Metrics*, 2014, 29(2): 126-138.
- [15] 张淑美, 王福利, 谭帅, 等. 多模态过程的全自动离线模态识别方法[J]. *自动化学报*, 2016, 42(1): 60-80.  
(Zhang S M, Wang F L, Tan S, et al. A fully automatic offline mode identification method for multi-mode process[J]. *Acta Automatica Sinica*, 2016, 42(1): 60-80.)
- [16] 雷琪, 蔡伟, 吴敏, 等. 基于多子系统信息熵的焦炉加热燃烧过程工况识别[J]. *信息与控制*, 2014, 43(3): 361-367.  
(Lei Q, Cai W, Wu M, et al. Operating-state identification for coke ovens combustion process based on multi-subsystem-entropy[J]. *Information and Control*, 2014, 43(3): 361-367.)
- [17] Ren S J, Song Z H, Yang M Y, et al. A novel multimode process monitoring method integrating LCGMM with modified LFDA[J]. *Chinese J of Chemical Engineering*, 2015, 23(12): 1970-1980.
- [18] Lv Z M, Yan X F, Jiang Q C. Batch process monitoring based on just-in-time learning and multiple-subspace principal component analysis[J]. *Chemometrics and Intelligent Laboratory Systems*, 2014, 137(20): 128-139.
- [19] 于涛, 李和平, 王建林, 等. 基于滑动时间窗口加权MPCA的间歇过程监测方法[J]. *北京化工大学学报: 自然科学版*, 2015, 42(4): 112-119.  
(Yu T, Li H P, Wang J L, et al. A method of batch process monitoring based on sliding-time-window weighted MPCA[J]. *J of Beijing University of Chemical Technology: Natural Science*, 2015, 42(4): 112-119.)
- [20] 韩敏, 张占奎. 基于改进核主成分分析的故障检测与诊断方法[J]. *化工学报*, 2015, 66(6): 2139-2148.  
(Han M, Zhang Z K. Fault detection and diagnosis method based modified kernel principal component analysis[J]. *CIESC J*, 2015, 66(6): 2139-2148.)
- [21] Chen J, Liu J. On-line batch process monitoring using dynamic PCA and dynamic PLS models[J]. *Chemical Engineering Science*, 2002, 57(1): 63-75.
- [22] Ge Z Q, Song Z H. Multimode process monitoring based on Bayesian method[J]. *J of Chemo Metrics*, 2009, 23(12): 636-650.
- [23] Zhou F, Park J H, Liu Y. Differential feature based hierarchical PCA fault detection method for dynamic fault[J]. *Neurocomputing*, 2016, 202: 27-35.
- [24] Hwang D H, Han C H. Real-time monitoring for a process with multiple operating modes[J]. *Control Engineering Practice*, 1999, 7(7): 891-902.

(责任编辑: 郑晓蕾)