

基于GMM的多模态过程模态识别与过程监测

谭帅^{1,2}, 常玉清¹, 王福利¹, 王姝¹

(1. 东北大学 流程工业综合自动化国家重点实验室, 沈阳 110004;

2. 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)

摘要: 多模态复杂过程的多变量、多工序、变量时变性以及模态转换时间不确定等多种原因, 导致面向多模态生产过程的监测问题十分复杂. 对此, 基于高斯混合模型的监测方法, 结合定性知识和定量知识, 解决了多模态过程监测中离线数据模态划分、稳定模态和过渡模态的监测模型建立以及在线数据的模态识别等关键问题, 最终实现了对多模态过程的监测.

关键词: 多模态过程; 过程监测; 模态识别; 连续退火机组

中图分类号: TP391.9

文献标志码: A

Mode identification and process monitoring for multiple mode processes based on GMM

TAN Shuai^{1,2}, CHANG Yu-qing¹, WANG Fu-li¹, WANG Shu¹

(1. Stat Key Laboratory of Integrated Automation of Process Industry Technology, Northeastern University, Shenyang 110004, China; 2. Key Laboratory of Advanced Control and Optimization for Chemical Processes of Ministry of Education, East China University of Science and Technology, Shanghai 200237, China. Correspondent: TAN Shuai, E-mail: tanshuai@ise.neu.edu.cn)

Abstract: Considering the process high dimensionality, multi-operation, time-variant characteristics, and unknown mode duration, it is challenging to conduct the statistical analysis and online monitoring for multi-mode processes. The process monitoring model based on the Gaussian mixture model(GMM) combining quantitative with qualitative information solves several key points, such as mode classification of offline data, model building for stable modes and transitional modes, and mode identification of online data. Process monitoring for multi-mode processes is realized by using the proposed method.

Keywords: multiple mode processes; process monitoring; mode identification; continuous annealing

0 引言

随着生产水平的不断提高以及自动控制技术的不断发展, 为了保证生产的安全、稳定以及更高的经济效益, 生产过程监测及故障诊断技术受到了学术界和工业界的广泛重视. 产品多样化、生产多工序、过程多模态已逐渐成为现代工业界的主导生产模式, 因而多模态过程监测技术也逐渐受到学术界和工业界的广泛重视^[1-2].

总结近几年国内相关研究, 针对具有多模态特性的复杂工业过程监测方法大体可以分为以下几种^[3]: 1) 整体建模思路, 即把不同模态的数据特征用一个模型来描述; 2) 多模型建模思路, 建立多个局部模型来

描述不同模态的过程特性; 3) 自适应建模思路, 根据模态的转变自动更新模型以适应过程特性的改变; 4) 鲁棒建模思路, 分析不同模态数据所蕴含的过程特性, 建立鲁棒模型来描述不同模态之间所蕴含的共性. 其中: 整体建模思路是针对多模态过程建立统一模型, 所建立的模型无法准确刻画每一种运行模态的特性, 对于大部分的多模态过程, 这种解决方案会导致较大的漏报率; 自适应建模思路和鲁棒建模思路都是局部学习方法, 前者关注的是最新过程特性, 后者只对不同的操作模式共享的信息进行分析; 相对而言, 多模型建模思路虽然繁琐, 但可以完整地对待差异明显的多个运行模态进行描述. 因此, 本文沿用多模型的监测

收稿日期: 2013-11-14; 修回日期: 2014-02-26.

基金项目: 国家自然科学基金项目(61403072, 61374146, 61174130); 国家863计划项目(2011AA060204); 中央高校基本科研专项资金项目(N120304004); 中国博士后科学基金项目(2013M530937).

作者简介: 谭帅(1983—), 女, 博士后, 从事复杂工业过程监测及故障诊断的研究; 王福利(1957—), 男, 教授, 博士生导师, 从事复杂工业过程建模、优化、监测及故障诊断等研究.

思路,对多模态过程进行建模分析.

基于有限高斯混合模型是利用贝叶斯推理的概率方法解决各种模式下的故障监测,近几年引起了人们的关注^[4-9].每个单独操作模式的正常过程数据被假定为一个多变量的高斯分布,每一个操作模式对应一个高斯分量,基于马氏距离对后验概率整合进而对所有的高斯超椭圆进行度量,实现对不同的操作区域的过程故障监测.但是该方法仅适合每个单独的操作模式对应一个多变量高斯分布,这种假设对于实际过程是否满足很难判断.

本文针对模态识别、多模态特性提取等关键问题,提出一种较完整的基于高斯混合模型的多模态过程监测方法.结合聚类结果和多模态过程机理知识,识别出稳定模态和过渡模态的离线数据;建立多个高斯混合模型,分别描述稳定模态和过渡模态的特性;利用联合密度识别在线数据的模态种类,调用所对应的监测模型对当前样本进行监测.最后以连续退火过程为背景,利用本文的多模态在线监测方法进行了仿真研究,所得结果表明了本文方法的有效性.

1 高斯混合模型

高斯混合模型(GMM)是一种用以描述混合密度分布的模型,用有限多个单一高斯概率密度函数的加权形式来逼近任意的连续分布.基于高斯混合的监测模型可以不局限于建模数据的密度函数,而且模型的复杂度与建模样本的集合大小无关.

假设 $x \in R^d$ 是一个来自多工况过程的 d 维样本,它的高斯混合模型下的概率密度函数为

$$p(x|\theta) = \sum_{i=1}^K \omega_i g(x|\theta_i), \quad (1)$$

$$g(x|\theta_i) = \frac{\exp\left[-\frac{1}{2}(x - \mu_i)^T \Sigma_i^{-1}(x - \mu_i)\right]}{\sqrt{(2\pi)^d |\Sigma_i|}}. \quad (2)$$

其中: K 为 GMM 中高斯分量的数目; $g(x|\theta_i)$ 为第 i 个分量 C_i 的高斯密度函数; ω_i 为第 i 个分量 C_i 的权重,可以理解为样本点来自第 i 个高斯分量 C_i 的先验概率,满足 $\sum_{i=1}^K \omega_i = 1$; $\theta_i = \{\mu_i, \Sigma_i\}$ 为第 i 个高斯子模型的参数集, μ_i 和 Σ_i 分别为第 i 个分量的均值向量和协方差矩阵; $\theta = \{\theta_1, \dots, \theta_K\} = \{\mu_1, \Sigma_1, \dots, \mu_K, \Sigma_K\}$ 表示 K 个高斯子模型参数组成的全局参数集.

期望最大化(EM)算法被用来估计未知参数 μ 、 Σ 和权值 ω . 利用 Figueiredo 等^[10]提出的非监督学习方法(F-J算法),采用最小信息长度(MML)准则确定高斯分量个数 K .

2 基于高斯混合模型的多模态过程监测

2.1 离线模态识别

数据模态识别是对没有模态指示信息的数据进行模态类别划分.离线建模时,需要对冗繁的历史数据进行处理,区分出不同模态所对应的建模数据.模态识别可以通过分析模态变量相关性的特点来实现,本文通过分析采样点对应高斯混合模型的子模型的后验概率来实现模态识别.离线数据 $X \in R^{d \times N}$. 其中: d 为变量维数, N 为样本数目.建立高斯混合模型描述整体离线数据的联合密度.可以分别求取 N 个采样点对应 K 个高斯分量的后验概率,即

$$\begin{bmatrix} p(C_1|x_1) & p(C_2|x_1) & \cdots & p(C_K|x_1) \\ p(C_1|x_2) & p(C_2|x_2) & \cdots & p(C_K|x_2) \\ \vdots & \vdots & \ddots & \vdots \\ p(C_1|x_N) & p(C_2|x_N) & \cdots & p(C_K|x_N) \end{bmatrix}, \quad (3)$$

$$p(C_i|x_n) = \frac{\omega_i g(x_n|\theta_i)}{\sum_{i=1}^K \omega_i g(x_n|\theta_i)}. \quad (4)$$

矩阵中的每一行代表第 n 个样本 x_n 对于 K 个高斯分量的后验概率向量,反映的是 x_n 属于每个高斯分量的概率密度.如果两个样本点的密度向量一样,则说明这两个样本点的密度分布特性完全一致,可以用相同的子分量来描述.

对 N 个采样点的后验概率向量进行聚类(本文采用减聚类算法),将聚类后的数据按照采样时间在时间轴上排列开.将数据分成 C 类,聚类后得到的数据形式为 $X = (X_1, X_2, \dots, X_C)$, 其中 $X_c \in R^{d \times N_c}$, $c = 1, 2, \dots, C$.

因为过渡模态具有复杂的过程特性,过渡模态的聚类结果可能包含多段子模态,而产生生产价值的稳定模态往往特性稳定且能维持一段时间,所以选择历史最短的稳定模态长度 h 为稳定模态阈值.将聚类后 $N_c \geq h$ 的时间段定义为“稳定模态”,同时可知,两个相邻稳态间的模态(满足 $N_c < h$)有两种可能:过渡模态或者噪声.为便于描述,定义 $N_c < h$ 的时间段为“非稳态模态”.这里采用如下两个步骤,进一步去除非稳态模态中的稳定模态噪声和过渡模态噪声,同时可以区分出过渡模态和噪声.

1) 去除稳定模态噪声.由于过渡模态是从一个稳定模态到另一个稳定模态的过程,对于某一非稳态模态,如果前后相邻的两个稳定模态聚类结果为相同的模态,则将两个相同稳定模态间的数据视为扰动数据,并将其从建模数据中剔除.

2) 去除过渡模态噪声. 由于过渡模态的变量呈现出一种动态的渐变趋势, 如果某一变量在短时间内变化剧烈, 则将过渡模态数据中的这种数据视为扰动数据, 将其从建模数据中剔除. 对于不同稳定模态之间所夹的一段或多段非稳态模态数据 $X^* \in R^{d \times N^*}$, 计算相邻两个样本点数据的差值模 Δx , 如果 Δx_n 和 Δx_{n+1} 同时大于阈值 $\Delta x_{\max}$, 则认为样本点 x_n 为过渡模态中的噪声点. Δx_n 的计算公式如下:

$$\Delta x_n = \|x_n - x_{n-1}\|, n = 2, 3, \dots, N^*. \quad (5)$$

2.2 离线建模

2.2.1 稳定模态

以往基于高斯混合模型的监测方法是对过程建立一个整体高斯混合模型, 这种建模思想通过计算样本对每一个高斯子模型的后验概率判断样本所属的模态类别, 比较适用于每一种稳定模态都服从单高斯分布的多模态生产过程. 但是, 这种建模方法会引入较大的漏报率, 而且对于稳定模态无法服从单高斯分布的多模态过程, 在识别样本的模态种类时, 整体建模思路也存在着较大的局限性.

在实际生产过程中, 很难保证每一稳定模态的多维变量数据都服从高斯分布, 并且稳定模态和过渡模态的数据也具有不同的特性. 为了准确描述不同模态的过程特性, 本文采用多模型思想, 对不同的稳定模态分别建立高斯混合模型; 对不同的过渡模态重点分析过渡数据动态特性, 并分别建立高斯混合模型以描述不同过渡模态数据特性.

假设多模态生产过程中存在 M 个稳定模态的种类, 则需要建立 M 个稳定模态 (即 M 个 GMM 模型), GMM 代表每一个稳定模态所对应的高斯混合模型. 通过 F-J 算法和 E-M 步骤求取每个高斯混合模型的高斯分量, 最终得到 M 个稳定模态模型, 即

$$p^{(m)}(x|\theta^{(m)}) = \sum_{i=1}^{K^{(m)}} \omega_i^{(m)} g(x|\theta_i^{(m)}), \quad (6)$$

$$g(x|\theta_i^{(m)}) = \frac{\exp\left[-\frac{1}{2}(x - \mu_i^{(m)})^T \Sigma_i^{(m)-1}(x - \mu_i^{(m)})\right]}{\sqrt{(2\pi)^d |\Sigma_i^{(m)}|}}. \quad (7)$$

其中: $K^{(m)}$ ($m = 1, 2, \dots, M$) 为第 m 个稳态的子模态个数; $\omega_i^{(m)}$ 为第 m 个稳态中第 i 个分量的权重, 可以理解为第 m 个稳态中样本点来自第 i 个高斯分量 $C_i^{(m)}$ 的先验概率; $\mu_i^{(m)}$ 和 $\Sigma_i^{(m)}$ 分别为第 m 个稳态中第 i 个高斯分量 $C_i^{(m)}$ 的均值向量和协方差矩阵; $i = 1, 2, \dots, K^{(m)}$.

2.2.2 过渡模态

与稳定模态建模不同, 过渡模态的过程特性具有较强的时变特性, 如果按照稳定生产模态建模思路, 则很难提取过渡模态变量相关关系的时变特性, 而这恰恰是过渡生产模态区别于稳定生产模态的根本所在. 通过深入研究发现, 在过渡模态下, 尽管变量的运行特性会随时间变化, 但是在忽略随机干扰的前提下, 变量在一定步长下的相对变化还是有规律可循的.

以某一稳定模态 M_a 向另一稳定模态 M_b 的过渡为例, 每次过渡时, 都希望生产工序尽量按照过渡设定曲线 (即最佳过渡轨迹) 运行, 所以可以认为相同的过渡模态数据具有重复性. 对于某一种过渡模态, 累积多次 (I 次) 正常过渡的生产数据, 就可以得到某一过渡模态的建模数据矩阵 $X_{tr}(I \times d \times N)$. 其中: I 为过渡次数, d 为变量个数, N 为一次过渡过程的样本个数. 对于 I 次过渡, 样本个数 N 可能不完全相同, 在此, 利用简单的拉伸或压缩处理, 将 I 次过渡数据处理成等长向量.

为了提取过渡周期内不同样本之间的时间关联特性, 对三维数据 X_{tr} 沿时间采样方向进行垂直分割, 得到 N 个二维数据矩阵. 对于采样时间间隔为 ΔN 的两个数据矩阵进行差分处理, 得到过渡变量在这段时间差内的变化幅度, 如果固定差分步长, 则可以得到数据 X_{tr} 在整个过渡模态下的相对变化率. 以第 n 个时间的时间片 $X_n(I \times d)$ 为例, 对应的差分矩阵为 $X_n^* = X_n - X_{n-\Delta N}$, 是通过第 n 个时刻的时间片, 与第 $n - \Delta N$ 时刻的时间片差分获得的. 差分后的三维矩阵为 $X_{tr}^*(I \times d \times (N - \Delta N - 1))$, 展开后的二维矩阵为 $X_{tr}^*(I(N - \Delta N - 1) \times d)$.

假设过程具有 M 个稳定模态, 则过渡模态的种类为 $M(M - 1)$. 对每一种过渡模态的差分二维矩阵 X_{tr}^* 建立高斯混合模型, 有

$$p^{*(m)}(x|\theta^{*(m)}) = \sum_{i=1}^{K^{*(m)}} \omega_i^{*(m)} g(x|\theta_i^{*(m)}), \quad (8)$$

$$g(x|\theta_i^{*(m)}) = \frac{1}{\sqrt{(2\pi)^d |\Sigma_i^{*(m)}|}} \times \exp\left[-\frac{1}{2}(x - \mu_i^{*(m)})^T \Sigma_i^{*(m)-1}(x - \mu_i^{*(m)})\right]. \quad (9)$$

其中: $\omega^{*(m)}, \mu^{*(m)}, \Sigma^{*(m)}, K^{*(m)}$ 为第 m 类过渡模态对应的参数; m 的最大值为 $M(M - 1)$.

2.3 在线模态识别及过程监测

在线监测时, 如果当前样本数据的模态类型未知, 则为了调用正确的模型进行监测, 首先必须识别出当前样本所对应的模态类别. 同一种模态正常数据

的运行特性应与离线建模数据的特性一致,所以,可以通过计算当前样本与各个模态离线建模数据运行特性的相似度来识别当前运行模态。

1) 如果当前运行在稳定模态下,则下一时刻的运行模态存在以下 3 种情况:

- ① 继续保持前一时刻的运行模态;
- ② 进入过渡模态;
- ③ 故障模态或未知新模态。

在线运行时,沿用前一时刻的稳定模态模型进行监测:

① 如果过程运行正常,则说明模态没有发生改变也没有故障。

② 如果过程运行非正常,则人为假设过程进入过渡模态,按照概率最大的原则,从以当前稳定模态为起始模态的过渡模态中选择对应的模型进行过程监测:若监测结果正常,则说明过程模态发生改变,进入过渡模态;若监测结果不正常,则说明过程是故障模态或未知新模态。

2) 如果当前过程运行在过渡模态下,则通过比较在线数据联合概率密度值来确定具体的过渡模态类型,同时可以获得过渡结束时进入的稳定模态类型。当过渡模态过程运行非正常时,人为假设过程进入对应的稳定模态,调用对应的稳定模态监测模型进行过程监测:若监测结果正常,则说明过程模态发生改变,进入稳定模态;若监测结果不正常,则说明过程是故障模态或未知新模态。

所谓未知新模态是历史数据中从未出现的模态类型,本文算法对于这种情况会产生误判。当这种情况多次出现时,就说明算法建立的模型不准确,有一部分正常特性没有包含进来,这时需要对模型进行修正。结合专家知识判断新模态数据后,对新模态模型进行补充。

为了提高监测系统的鲁棒性能,尽量避免模态误判断,采用一段时间内的过程数据信息实现对当前运行模态的识别。累计 10 个采样点的在线数据的联合密度,这里假设 10 个采样点相互独立,可以得到 x_{ten} 对离线第 m 种稳定模态模型的联合概率密度为

$$p^{(m)}(x_{\text{ten}}|\theta^{(m)}) = p^{(m)}(x_1|\theta^{(m)})p^{(m)}(x_2|\theta^{(m)}) \cdots p^{(m)}(x_{10}|\theta^{(m)}), \quad (10)$$

$$p^{(m)}(x|\theta^{(m)}) = \sum_{i=1}^{K^{(m)}} \omega_i^{(m)} g(x|\theta_i^{(m)}). \quad (11)$$

运行数据 x_{ten} 所对应最大联合密度值的模型对应于具有最大可能的模态,因此选择对应最大可能性的稳定模态 m 进行监测。同理,判断过渡模态类别

时,分别计算 x_{ten} 与 $(M-1)$ 种可能过渡模态的联合概率密度,选择对应最大联合密度值的过渡模态(以每一种稳定模态为起始状态的过渡模态种类最多可能有 $(M-1)$ 种)。

为了实现过程监测,必须进一步得到所有正常工作区域的置信界,而混合分布的多模态特性使得人们难以得到在某一置信水平下的密度函数的解析界限。因此,这里定义一个基于贝叶斯推理的概率指标(BIP)作为监测目标。监测样本 x_{on} 的 BIP 指标可由下式求得:

$$\text{BIP} = \sum_{i=1}^K p(C_i|x_{\text{on}})p_L^{(i)}(x_{\text{on}}), \quad (12)$$

$$p(C_i|x_{\text{on}}) = \frac{\omega_i g(x_{\text{on}}|\theta_i)}{\sum_{i=1}^K \omega_i g(x_{\text{on}}|\theta_i)}. \quad (13)$$

其中: $p(C_i|x_{\text{on}})$ 为样本 x_{on} 属于第 i 个高斯子分量的后验概率; $p_L^{(i)}(x_{\text{on}})$ 为基于马氏距离的样本 x_{on} 属于第 i 个高斯子分量局部概率指标,其计算公式如下:

$$p_L^{(i)}(x_{\text{on}}) = \Pr\{D_r((x, C_i)|x \in C_i) \leq D_r((x_{\text{on}}, C_i)|x_{\text{on}} \in C_i)\}, \quad (14)$$

$$D_r((x, C_i)|x \in C_i) = (x - \mu_i)^T \Sigma_i^{-1} (x - \mu_i), \quad (15)$$

$$D_r \sim \chi_d^2, \quad (16)$$

D_r 是 x 到第 i 个高斯子分量中心的马氏距离且服从 χ_d^2 分布, d 是自由度。

在一个事先给定的置信水平 $(1 - \alpha)100\%$ 下,如果 $\text{BIP} \leq 1 - \alpha$,则认为过程处于正常工作状态,否则认为过程出现了故障。

3 连续退火过程仿真研究

退火的目的是改善带钢的性能。带钢连续退火传统的生产工艺是:酸洗、冷轧、清洗、罩式退火、平整、检查和精整。在连续退火机组内,经过冷变形的钢被加热到再结晶温度以上,通过回复、再结晶、晶粒长大 3 个阶段,使因冷轧而产生加工硬化的带钢进行再结晶,完善微观组织。

在连续退火生产线中,退火炉的中央段可以分为:加热段 HF,均热段 SF,慢冷段 SCF,一冷段 1C,再加热段 RH,一过时效段 10A,二过时效段 20A,二冷段 2C,水冷段 WQ 等几个炉段,如图 1 所示。

根据不同的带钢调质度要求,退火生产线需要设置不同的工作模态处理带钢,以便获得不同硬度和延伸率的带钢成品。本文以调质度为 T-4CA 和 T-3CA 两种带钢为例,采集的建模数据中包含以下变量:退火机组均热温度,慢冷、1 冷、2 冷的降温速率,10A、20A(过时效)的温度,中央段速度等所有可以获得的过程信息,如表 1 所示。




图 1 连续退火机组示意图

表 1 连续退火机组建模变量表

序号	变量名称	序号	变量名称
1	HF 加热炉带钢温度	13	SCF4 区炉温
2	HF1 区炉温	14	RH 再加热炉带钢温度
3	HF2 区炉温	15	FCF 快冷炉带钢温度
4	HF3 区炉温	16	IOA-1 1 区炉温
5	HF4 区炉温	17	IOA-1 2 区炉温
6	HF5 区炉温	18	IOA-1 1 区过时效炉带钢温度
7	SF 炉温	19	IOA-2 2 区过时效炉带钢温度
8	SF 均热炉带钢温度	20	2OA-1 1 区炉温
9	SCF 缓冷炉带钢温度	21	2OA-1 2 区炉温
10	SCF1 区炉温	22	2OA-2 1 区炉温
11	SCF2 区炉温	23	2OA-2 2 区炉温
12	SCF3 区炉温		

现场变量的采集频率为 10 s/次, 仿真所用的温度数据每个样本包括 23 个变量. 根据现场工人操作记录(例如: 根据给料工序段换带钢的类型的操作记录, 可以推断出退火时过渡起始时间; 根据后续化验工序段的质量检测记录, 可以推断出退火的过渡结束时间), 搜集前后相关生产工序的操作记录, 并请教有经验的现场技师, 分析得到连续退火机组真实数据对应的各模态转换时段数据大小.

首先生产过程历经 7.6 h 的 T-4CA 稳定生产, 采集获得 T-4CA 模态的数据 X_{T4} ($2\,736 \times 23$); 根据生产调度的要求, 此时过程开始转为 T-3CA 生产模态, 在经过 1.4 h 的过渡后, 获得过渡数据 X_{T4-T3} (504×23); 过程在 T-3CA 模态下稳定生产 14.5 h, 累积 T-3CA 稳定模态的数据 X_{T3} ($5\,220 \times 23$); 根据要求过程再次回到 T-4CA 模态下, 在经过 1.5 h 的过渡后, 获得过渡数据 X_{T3-T4} (542×23); 在 T-4CA 模态下持续稳定生产, 采集 5.2 h 的数据 X_{T4} ($1\,872 \times 23$).

离线数据模态识别结果如图 2 所示. 其中: 模态 1 (1~2 740) 和模态 1 (9 016~10 874) 是识别出的 T-4CA 稳定模态; 模态 5 (3 261~8 460) 是识别出的 T-3CA 稳定模态; 时段 (2 741~3 260) 和时段 (8 461~9 015) 分别是位于不同稳定模态之间的过渡模态. 对

比离线建模数据可知, 算法的误差最多为 20 个采样点 (3.3 min). 现场过渡模态大部分需要经历一个多小时, 稳定模态的生产时间则更久, 经常会持续几天的时间, 因此离线数据模态识别的误差为 3~4 min, 对比整个生产时间的误差率小于 5%, 在可接受的范围内.




图 2 离线模态识别结果

对两种稳定模态和两种过渡模态分别建立监测模型, 得到参数如表 2 所示(每种模态模型的均值参数是 K 个 23×1 的向量, 协方差参数是 K 个 23×23 的矩阵, 在此不一一列出).


表 2 模型参数表

模态类型	高斯子模型个数 K	权重向量 ω
T-3CA	2	(0.64, 0.36)
T-4CA	2	(0.72, 0.28)
T-4CA 向 T-3CA 过渡	3	(0.51, 0.39, 0.10)
T-3CA 向 T-4CA 过渡	4	(0.47, 0.28, 0.14, 0.11)


在线应用时, 重新获取 8 460 个在线采样数据, 数据包含建模时的两种模态 T-4CA 和 T-3CA. 已知样本 1~1 727 为 T-4CA 的生产数据; 2 250~5 939 为 T-3CA 的生产数据; 6 500~8 460 为 T-4CA 的生产数据. 在第 7 000 s 时人为引入故障, 此时, 过程运行在 T-4CA 模态下, 人为引入的故障特性与 T-3CA 模态特性相似. 同时为了验证本文算法对于提高监测鲁棒性能

的效果,在第3000~4000s随机加入持续时间小于10s的间断性干扰信号。

图3中的实线是在线统计量,虚线是控制限。在线数据的BIP统计量趋势如图3(a)所示,识别结果如下:1~1741为模态T-4CA;2224~5950为模态T-3CA;6481~8460为模态T-4CA。由调质度T-4CA向T-3CA转变的起始时刻为1742;由调质度T-3CA向T-4CA转变的起始时刻为5951。对比结果可以发现,模态识别的转变开始时间与实际情况相比略有延迟,但最大误差不超过2min,在实际生产中这种精度完全可以满足要求。此外,如图3(a)所示,算法在第7012s监测出故障发生。为了验证本文算法对于提高监测鲁棒性能的效果,本文另作一次仿真验证,在线监测时没有累计10个采样点的在线数据的联合密度,而是只用1个采样点的在线数据密度进行监测,监测效果如图3(b)所示。对比两图结果可以发现,在第3000~4000s时间段内,图3(a)的方法比图3(b)的误报率明显降低,表明本文算法的抗干扰能力较好。



(a) 利用在线数据监测的结果



(b) 未利用在线数据监测的结果

图3 联合密度监测结果

4 结论

本文深入分析了多模态过程的特性,在建立多模态稳定模态和过渡模态监测模型的同时,充分考虑到生产中数据模态未知的普遍问题,补充了关于模态数

据离线识别、在线识别的算法,完善了复杂工业过程监测的框架。本文还以实际工业生产数据为依托,对所提出的方法和技术进行了验证,所得结论表明了本文方法的有效性,为进一步推广到实际应用提供了可能,体现了算法的工业应用价值。

参考文献(References)

- [1] Bhagwat A, Srinivasan R, Krishnaswamy P R. Multi-linear model based fault detection during process transitions[J]. Chemical Engineering Science, 2003, 58(9): 1649-1670.
- [2] Yew Seng Ng, Rajagopalan Srinivasan. An adjoined multi-model approach for monitoring batch and transient operations[J]. Computers and Chemical Engineering, 2009, 33(4): 887-902.
- [3] Chunhui Zhao, Yuan Yao, Furong Gao, et al. Statistical analysis and online monitoring for multimode processes with between mode transitions[J]. Chemical Engineering Science, 2010, 65(22): 5961-5975.
- [4] Choi S W, Park J H, Lee I B. Process monitoring using a Gaussian mixture model via principal component analysis and discriminate analysis[J]. Computers and Chemical Engineering, 2004, 28(8): 1377-1387.
- [5] Yoo C K, Villez K, Lee I B, et al. Multimodel statistical process monitoring and diagnosis of a sequencing batch reactor[J]. Biotechnol Bioeng, 2007, 96(4): 687-701.
- [6] Thissen U, Swierenga H, de Weijer A P, et al. Multivariate statistical process control using mixture modeling[J]. Chemom, 2005, 19(1): 23-31.
- [7] Yew Seng Ng, Rajagopalan Srinivasan. An adjoined multi-model approach for monitoring batch and transient operations[J]. Computers and Chemical Engineering, 2009, 33(4): 887-902.
- [8] Jie Yu, S Joe Qin. Multimode process monitoring with Bayesian inference-based finite Gaussian mixture models[J]. AIChE, 2008, 54(7): 1811-1829.
- [9] Carlos F Alcala, S Joe Qin. Reconstruction-based contribution for process monitoring[J]. Automatica, 2009, 45(7): 1593-1600.
- [10] Figueiredo M A F, Jain A K. Unsupervised learning of finite mixture models[J]. IEEE Trans on Pattern Analysis and Machine Intelligence, 2002, 24(3): 381-396.

(责任编辑:李君玲)