

引用格式:曹雪,王建林,邱科鹏,等. 基于 PARAFAC2 的多时段间歇过程时段划分[J]. 北京化工大学学报(自然科学版), 2019,46(2):77-82.

CAO Xue, WANG JianLin, QIU KePeng, et al. PARAFAC2-based phase partition of multiphase batch processes[J]. Journal of Beijing University of Chemical Technology (Natural Science), 2019,46(2):77-82.

基于 PARAFAC2 的多时段间歇过程时段划分

曹 雪 王建林* 邱科鹏 刘伟旻 韩 锐

(北京化工大学 信息科学与技术学院, 北京 100029)

摘 要: 针对间歇过程多时段特性,提出一种基于平行因子分解 2(PARAFAC2)的多时段间歇过程时段划分方法。首先对每一个时间片矩阵进行平行因子分解 2(PARAFAC2)建模,得到时间片矩阵的模型控制限,然后从间歇过程初始时刻开始,按照时序依次将每个时间片添加到时间块并进行 PARAFAC2 建模,得到时间块矩阵的模型控制限后,通过评估时间片和时间块模型控制限的差异性来确定初始时段划分点,最后利用时段评价划分指标(PPCI)获取最佳的时段划分结果。通过青霉素发酵过程仿真实验验证了本文方法的有效性。

关键词: 间歇过程; 多时段; 三维数据; 平行因子分解 2(PARAFAC2)

中图分类号: TP391 **DOI:** 10.13543/j.bhxbzr.2019.02.012

引 言

间歇过程因其适应多品种、多规格和高质量的市场要求,近年来被广泛应用于精细化工、生物制药、食品、聚合物反应、金属加工等领域^[1]。间歇过程的一个固有特征是具有多时段性,即在不同时段呈现出不同的过程相关特性。若忽略间歇过程的多时段过程特性,将一次间歇操作的多时段过程看作一个整体进行间歇过程建模,会导致所建立的过程模型难以准确描述间歇过程,直接影响生产过程的安全运行和产品质量,造成生产企业经济损失甚至人员伤亡。因此,进行多时段间歇过程的时段划分,对于提高间歇过程模型精度及产品质量,保障生产过程中的人身、财产安全都具有重要的意义^[2-3]。

目前应用较广泛的间歇过程时段划分方法主要有基于聚类分析^[4-5]和基于模型识别^[6-7]的方法。基于聚类分析的方法通过无监督机器学习,将具有相似特征的过程数据归为一类,从而实现时段划

分^[8-9]。该方法原理简单、计算复杂度较低,但其准确性严重依赖于时段个数的设定和时段初始中心的选取,影响了时段划分结果的精度。基于模型识别的间歇过程时段划分方法不需要设定时段个数和初始时段中心,只需分析间歇过程运行时间顺序的过程特性并建立统计模型,通过评估时段划分对统计模型特性的影响确定合适的时段划分点^[10],但是该方法在处理间歇过程数据时均需将三维过程数据展开为二维数据,从而损失了间歇过程的三维数据特性,直接影响多时段间歇过程的时段划分结果的准确性。

平行因子分解 2(PARAFAC2)^[11]是主成分分析的一种高维推广,因其能够在不对三维数据作二维展开的情况下直接进行主成分分析,可以有效地保持数据内部结构的完整性,在数据挖掘、人脸识别、特征提取等领域得到广泛应用^[12]。Louwerse 等^[13]首次将平行因子法应用于间歇过程的三维过程数据建模,提升了过程模型精度;Maturo 等^[14]利用 PARAFAC2 解决了三维不等长批次过程数据的建模;考虑间歇过程的多时段特性,Luo 等^[15]利用聚类分析方法划分时段并基于 PARAFAC2 建立各个时段的过程模型,相比整体 PARAFAC2 模型,多时段 PARAFAC2 模型具有更高的准确性。以上研究虽然获得了较高精度的过程模型,但均采用基于聚类分析或模型识别方法划分间歇过程的多时段,没

收稿日期: 2018-05-03

基金项目: 国家自然科学基金(61240047);北京市自然科学基金(4152041)

第一作者: 女,1992 年生,硕士生

* 通信联系人

E-mail: wangjl@mail.buct.edu.cn

有充分利用 PARAFAC2 处理三维过程数据所具有的优势划分多时段,仅是利用 PARAFAC2 建立各个时段的过程模型,多时段划分结果的准确性仍然制约着间歇过程模型精度的提升。

针对多时段间歇过程的时段划分问题,本文利用间歇过程三维数据建立三维时变数据集,首先对每个时间片矩阵进行 PARAFAC2 建模,然后从初始时刻开始,将时间片矩阵按照时间顺序依次添加三维的时间块矩阵,并采用 PARAFAC2 建立三维过程数据模型;再分别计算各模型的平方预测误差(square prediction error, SPE)统计量,通过衡量新加入的时间片对时间块模型统计量的影响来判断是否具有相似的过程特性,从而获取时段划分点;然后通过利用时段评价划分指标(PPCI)得到最佳的时段划分结果。最后利用青霉素发酵过程仿真实验验证了所提方法的有效性。

1 平行因子分解 2(PARAFAC2)

给定一个三维过程数据集 $\mathbf{X} = \{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_I\}$, $\mathbf{X}_i \in \mathbf{R}^{K_i \times J}$, $i = 1, 2, \dots, I$, I 为批次个数, J 为变量个数, K_i 为每批次的采样点个数。对矩阵 \mathbf{X} 进行 PARAFAC2 建模可得

$$\mathbf{X}_i = \mathbf{F}_i \mathbf{D}_i \mathbf{A}^T + \mathbf{E}_i \quad (1)$$

式中, \mathbf{F}_i ($K_i \times R$) 为得分矩阵(R 为主元个数), \mathbf{D}_i ($R \times R$) 为加权对角矩阵, \mathbf{A} ($J \times R$) 为负载矩阵, \mathbf{E}_i ($K_i \times J$) 为残差矩阵。三维数据矩阵 \mathbf{X} 的 PARAFAC2 模型如图 1 所示。




图 1 PARAFAC2 模型

Fig. 1 Schematic diagram of the PARAFAC2 model

为了使该模型具有唯一性,需增加约束条件。设 $\mathbf{F}_i^T \mathbf{F}_i$ 为恒定的矩阵,即

$$\mathbf{F}_a^T \mathbf{F}_a = \mathbf{F}_b^T \mathbf{F}_b = \Phi, \quad \forall a, b = 1, 2, \dots, I \quad (2)$$

令 $\mathbf{F}_i = \mathbf{P}_i \mathbf{F}$, 其中 \mathbf{P}_i ($K_i \times R$) 为正交矩阵, \mathbf{F} ($R \times R$) 为定值矩阵。由于

$$\mathbf{F}_i^T \mathbf{F}_i = \mathbf{F}^T \mathbf{P}_i^T \mathbf{P}_i \mathbf{F} = \mathbf{F}^T \mathbf{F}, \quad i = 1, 2, \dots, I \quad (3)$$

因此 PARAFAC2 模型可表示为

$$\mathbf{X}_i = \mathbf{P}_i \mathbf{F} \mathbf{D}_i \mathbf{A}^T + \mathbf{E}_i = \mathbf{T}_i \mathbf{A}^T + \mathbf{E}_i \quad (4)$$

式(4)中 $\mathbf{T}_i = \mathbf{P}_i \mathbf{F} \mathbf{D}_i$ 为组合得分矩阵。

采用直接拟合法^[16]可以得到 \mathbf{P}_i , \mathbf{F} , \mathbf{D}_i 和 \mathbf{A}^T , 其计算式为

$$\sigma(\mathbf{F}, \mathbf{D}_1, \mathbf{D}_2, \dots, \mathbf{D}_I, \mathbf{P}_1, \mathbf{P}_2, \dots, \mathbf{P}_I, \mathbf{A}) = \sum_{i=1}^I \|\mathbf{X}_i - \mathbf{P}_i \mathbf{F} \mathbf{D}_i \mathbf{A}^T\|^2 \quad (5)$$

式中, $\mathbf{P}_i^T \mathbf{P}_i = \mathbf{I}$, \mathbf{D}_i 为对角矩阵。

2 基于 PARAFAC2 的多时段间歇过程时段划分

2.1 三维数据标准化过程

实际间歇过程中采集的数据均为间歇过程中可被测量的状态参数,为消除变量间的量纲关系,需要对间歇过程三维数据 $\mathbf{X} = \{\mathbf{X}_1, \mathbf{X}_2, \dots, \mathbf{X}_I\}$ 进行标准化。首先将间歇过程三维数据 \mathbf{X} 沿采样点时刻方向展开为 K 个二维数据矩阵 $\tilde{\mathbf{X}}(I \times J)$;然后再对每个 $\tilde{\mathbf{X}}(I \times J)$ 进行中心化和归一化处理,得到标准化后的二维数据矩阵 $\hat{\mathbf{X}}(I \times J)$;最后为保证间歇过程三维数据的完整性,还需将 K 个二维数据矩阵 $\hat{\mathbf{X}}(I \times J)$ 按照采样点时刻方向依次叠加,恢复原始的三维结构, $\bar{\mathbf{X}} = \{\bar{\mathbf{X}}_1, \bar{\mathbf{X}}_2, \dots, \bar{\mathbf{X}}_I\}$ 为标准化的间歇过程三维数据。标准化过程的具体流程如图 2 所示。

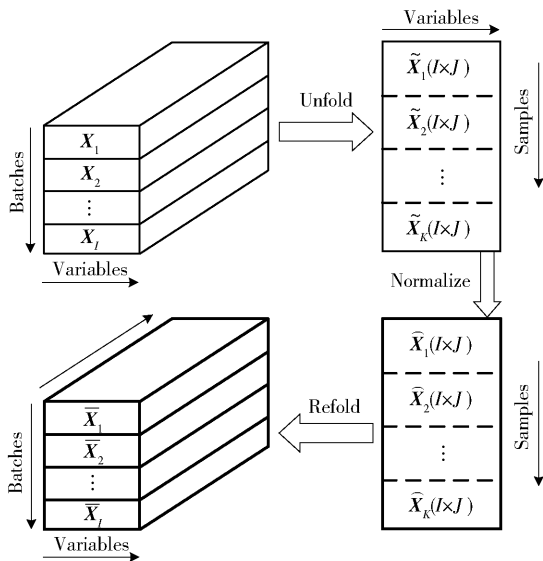


图 2 间歇过程三维数据标准化过程

Fig. 2 Normalization procedure for the three-dimensional batch data set

2.2 时段划分算法

对标准化预处理后的间歇过程数据 $\bar{\mathbf{X}}$ 进行时

段划分,获取基于PARAFAC2的时间片和时间块矩阵模型,并确定时段划分点。

2.2.1 时间片建模

设一个间歇过程具有 K 个采样点和 J 个测量变量,则每个测量批次可获得一个 $K \times J$ 的数据矩阵,重复 I 批次的测量步骤后,得到的数据可以表述为一个三维数据矩阵 $\mathbf{X}(I \times J \times K)$;提取一个批次内的各个采样点上的变量得到二维时间片矩阵 $\mathbf{X}_k(I \times J)$ 。

对每一个时间片矩阵 $\mathbf{X}_k(I \times J)$ 标准化后得到的结果 $\bar{\mathbf{X}}_k$ 进行PARAFAC2分解,建立时间片PARAFAC2模型,其分解过程可表示为

$$\bar{\mathbf{X}}_k = \mathbf{F}_k \mathbf{D}_k \mathbf{A}^T + \bar{\mathbf{E}}_k = \bar{\mathbf{T}}_k \mathbf{A}^T + \bar{\mathbf{E}}_k = \sum_{r=1}^R \bar{\mathbf{T}}_{k,r} \mathbf{A}_r^T + \bar{\mathbf{E}}_k \quad (6)$$

式中, r 表示不同的分解方向。设每个时间片的主元个数为 R_k ,选择出现次数最多的 R_k 值作为所有时间片PARAFAC2模型的主元个数 R 。

2.2.2 时间块建模

从间歇过程初始点开始,依次将每一个时间片按照 k 的方向进行叠加(k 代表当前过程时间),得到三维的时间块矩阵 $\mathbf{X}_k(I \times J \times K)$,其构建过程如图3所示。




图3 时间块构建

Fig.3 Time block matrix modeling

类似地,对每一个时间块矩阵 \mathbf{X}_k 进行PARAFAC2分解,最终建立时间块PARAFAC2模型。

2.2.3 基于模型控制限变化的时段划分

计算每一个时间片矩阵 $\bar{\mathbf{X}}_k$ 、时间块矩阵 \mathbf{X}_k 对应于各个批次的SPE统计量,其计算式为

$$S_{k,i} = \mathbf{e}_{k,i} \mathbf{e}_{k,i}^T \quad (7)$$

式中, i 是批序号, k 是运行时间, $\mathbf{e}_{k,i}$ 是残差矩阵 $\bar{\mathbf{E}}_k$ 对应于 k 时刻第 i 批次的列向量。通过核密度估计方法^[17]分别得出 $\bar{\mathbf{X}}_k$ 、 \mathbf{X}_k 在 k 时刻对应的SPE控制限 CLS_k 、 CLB_k 。

引入动态调节因子 α 来反映时间片模型与时间块模型的精度折中程度。时段划分的步骤为:将时间片控制限 CLS_k 与从初始时刻到 k 时刻的时间

块控制限 CLB_k 进行比较,如果存在连续3个数据满足 $\text{CLB}_k > \alpha \text{CLS}_k$,说明新加入的时间片对该时间块模型的重大影响导致当前时间块模型无法精确表征该时间块内的所有时间片数据,由此判断当前 k 时刻之前的时间块隶属于同一个时段;然后根据所获得的 k 时刻指示信息将该时段数据全部移除,再将余下的间歇过程运行时间作为新的数据起始点,重复进行模型控制限的判断,直到所有的时段划分点被确定。

2.2.4 分段效果评价

通过调节 α 的值可以获取不同时段个数的间歇过程时段划分结果。采用时段划分评价指标(PPCI)^[9]来确定最佳时段个数。首先,对 α 设定一定的范围和步长,利用本文方法依次对间歇过程进行时段划分,得到一组对应不同 α 值的时段划分结果;其次,分别计算每个 α 对应结果的PPCI指标,PPCI指标最小值对应的时段划分结果即为最佳时段分段结果。

基于PARAFAC2的多时段间歇过程时段划分算法流程如图4所示。

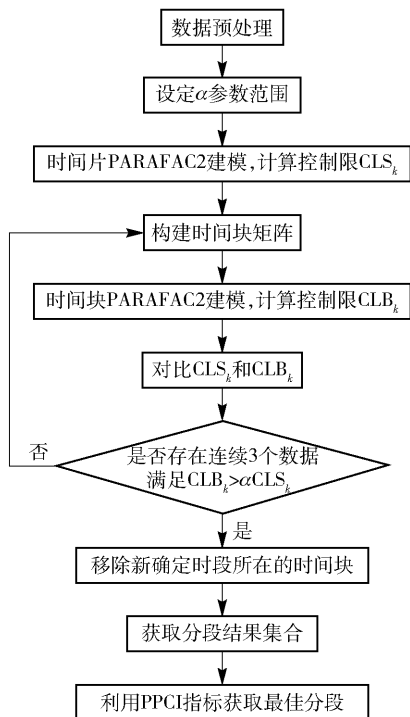


图4 基于PARAFAC2的间歇过程时段划分流程图

Fig.4 Flow diagram of PARAFAC2 based phase partition of multiphase batch processes

3 实验验证及结果分析

为了验证本文方法的有效性,基于青霉素发酵

过程进行了间歇过程的多时段划分实验,并与 K 均值、FCM、WKM、SCFCM 4 种间歇过程时段划分方法进行结果比较。

3.1 实验数据

青霉素是一种临床应用广泛的抗生素,其生产过程是典型的多时段间歇过程。利用 Pensim 仿真平台^[18]为青霉素发酵过程测量数据时段划分提供标准的过程仿真数据,选取如表 1 所示的 6 个时段敏感变量,生成 20 个正常批次数据,采样时间 400 h,采样间隔 1 h,过程数据为 $X(20 \times 6 \times 400)$ 。

表 1 青霉素发酵过程变量

Table 1 Variables for the penicillin fermentation process		
序号	过程变量	单位
1	底物流加速度	L/h
2	底物浓度	g/L
3	溶解氧浓度	nmol/L
4	生物质浓度	g/L
5	产物浓度	g/L
6	反应热	kcal/h

3.2 实验过程

设置 SPE 统计量控制限的置信度为 95%,采用基于 PARAFAC2 模型进行时段划分,通过改变动态调节因子 α 的取值来获取不同的时段划分结果。当 α 的取值范围为 $[2.0, 7.7]$,步长为 0.1 时,对应的时段划分结果如表 2 所示。

表 2 不同 α 对应的时段划分个数

Table 2 Different values of α corresponding to the number of phases		
序号	α	时段个数
1	2.0	10
2	2.1	9
3	2.2~2.3	7
4	2.4~2.8	6
5	2.9~3.8	5
6	3.9~4.9	4
7	5.0~7.7	3

计算不同 α 对应的 PPCI 值如图 5 所示,得出 α 取值为 3.8 时,时段划分结果的 PPCI 值最小。 $\alpha = 3.8$ 的划分结果如图 6 所示,可以看出时段划分点分别为 $p_1 = 28, p_2 = 59, p_3 = 216, p_4 = 369$,划分出 1~28、29~59、60~216、217~369 和 370~400 共 5

个时段。




图 5 不同 α 对应的 PPCI 值
Fig. 5 Different values of α corresponding to the value of PPCI




图 6 $\alpha = 3.8$ 时的分段情况
Fig. 6 Result of phase partition with $\alpha = 3.8$

3.3 方法比较

本文选取 Davies – Bouldin (DB) 指标和 Compactness (CP) 指标^[19]作为比较各种划分方法性能的评价指标。DB 指标计算式为

$$x_{DB} = \frac{1}{L} \sum_{i=1}^L \max_{j \neq i} \left(\frac{b_i + b_j}{\|v_i - v_j\|} \right) \tag{8}$$

式中, L 是时段个数, v_i 和 v_j 分别是时段 i 和时段 j 的中心, b_i 和 b_j 分别为时段 i, j 的平均误差, 计算式为

$$b_i = \frac{1}{N_i} \sum_{x_j \in \Omega_i} \|x_j - v_i\|^2 \tag{9}$$

式中, Ω_i, N_i 分别为时段 i 包含的样本集合和样本个数。DB 指标的值越小, 代表时段内部各个样本越紧凑, 各时段间的距离越大, 时段划分结果的准确性就越高。

CP 指标计算为

$$x_{CP} = \frac{1}{L} \sum_{i=1}^L \frac{1}{N_i} \sum_{x_j \in \Omega_i} \|x_j - v_i\| \tag{10}$$

CP 指标的值越小, 说明类内聚类距离越近, 时段划分结果越准确。

根据 3.2 节得到的最佳时段个数, 分别利用 K 均值、FCM、WKM 和 SCFCM 方法将 3.1 节中青霉素发酵过程测量数据($X(20 \times 6 \times 400)$)划分为 5 个时段, 再代入式(8)~(10)计算时段划分点对应的 DB 和 CP 指标值, 结果如表 3 所示。

表 3 不同方法的 DB 和 CP 指标

Table 3 DB and CP index for different methods

方法	时段划分点	DB 指标	CP 指标
K 均值	31,44,63,153	18.6027	814.9439
FCM	32,45,95,173	17.5374	777.0255
WKM	31,42,58,139	16.1140	745.0541
SCFCM	32,44,80,158	14.8861	765.3641
PARAFAC2	28,59,216,369	10.6867	534.0847

可以看出, 无论从 DB 指标还是 CP 指标来看, 本文方法的时段划分结果均优于其他 4 种方法。原因是基于 K 均值的方法从数据相似性出发实现时段划分, 基于 FCM 的方法利用类间模糊距离约束实现分段, 两种方法均存在时段划分结果依赖初始设定值、时序跳变等情况, 时段划分结果的准确性较低; 基于 WKM 和 SCFCM 的两种算法分别在 K 均值和 FCM 算法基础上增加了时序约束, 但本质上依然受制于聚类方法依赖初始参数和对异常点敏感的缺点, 影响了时段划分结果准确性的提升。本文方法在保证间歇过程数据完整性和结构特性的同时无需设定初始值, 并充分考虑了批次间的时序性, 因此时段划分结果具有更高的准确性。

4 结束语

本文提出一种基于 PARAFAC2 的多时段间歇过程时段划分方法。利用 PARAFAC2 可以对三维数据矩阵进行不展开建模的优势, 在不破坏间歇过程三维数据完整性和结构特征的情况下, 按照时序依次添加时间块矩阵, 保证了时段划分结果的时序性和准确性, 通过识别过程模型时间块矩阵控制限和时段评价划分指标(PPCI)的变化, 获得了最优的时段划分结果。实验结果表明, 与基于 K 均值、FCM、WKM、SCFCM 的间歇过程时段划分方法相比, 本文方法有效地提高了间歇过程时段划分的准确性。

参考文献:

[1] YAN Z B, HUANG B L, YAO Y. Multivariate statistical

process monitoring of batch-to-batch startups[J]. *AIChE Journal*, 2015, 61(11): 3719-3727.

[2] WANG J L, LIU W M, QIU K P, et al. Dynamic hypersphere based support vector data description for batch process monitoring[J]. *Chemometrics and Intelligent Laboratory Systems*, 2018, 172: 17-32.

[3] GE Z Q, SONG Z H, GAO F R. Review of recent research on data-based process monitoring[J]. *Industrial & Engineering Chemistry Research*, 2013, 52(10): 3543-3562.

[4] 王静, 胡益, 侍洪波. 基于 GMM 的间歇过程故障检测[J]. *自动化学报*, 2015, 41(5): 899-905.

WANG J, HU Y, SHI H B. Fault detection for batch processes based on Gaussian mixture model [J]. *Acta Automatica Sinica*, 2015, 41(5): 899-905. (in Chinese)

[5] LIU J X, LIU T, CHEN J H. Sequential local-based Gaussian mixture model for monitoring multiphase batch processes [J]. *Chemical Engineering Science*, 2018, 181: 101-113.

[6] ZHAO C H, SUN Y X. Step-wise sequential phase partition (SSPP) algorithm based statistical modeling and on-line process monitoring[J]. *Chemometrics and Intelligent Laboratory Systems*, 2013, 125(5): 109-120.

[7] 王建林, 马琳钰, 邱科鹏, 等. 基于 SVDD 的多时段间歇过程故障检测[J]. *仪器仪表学报*, 2017, 38(11): 2752-2761.

WANG J L, MA L Y, QIU K P, et al. Multi phase batch processes fault detection based on support vector data description [J]. *Chinese Journal of Scientific Instrument*, 2017, 38(11): 2752-2761. (in Chinese)

[8] 张子羿, 胡益, 侍洪波. 一种基于聚类方法的多阶段间歇过程监控方法[J]. *化工学报*, 2013, 64(12): 4522-4528.

ZHANG Z Y, HU Y, SHI H B. Multi-stage batch process monitoring based on a clustering method[J]. *CI-ESC Journal*, 2013, 64(12): 4522-4528. (in Chinese)

[9] LUO L J, BAO S Y, MAO J F, et al. Fuzzy phase partition and hybrid modeling based quality prediction and process monitoring methods for multiphase batch processes[J]. *Industrial & Engineering Chemistry Research*, 2016, 55(14): 4045-4058.

[10] QIN Y, ZHAO C H, GAO F R. An iterative two-step sequential phase partition (ITSP) method for batch process modeling and online monitoring[J]. *AIChE Journal*, 2016, 62(7): 2358-2373.

[11] SKOV T, BRO R. A new approach for modelling sensor

- based data [J]. *Sensors and Actuators B: Chemical*, 2005, 106(2): 719–729.
- [12] HELWIG N E. Estimating latent trends in multivariate longitudinal data via Parafac2 with functional and structural constraints[J]. *Biometrical Journal*, 2017, 59(4): 783–803.
- [13] LOUWERSE D J, SMILDE A K. Multivariate statistical process control of batch processes based on three-way models [J]. *Chemical Engineering Science*, 2000, 55(7): 1225–1235.
- [14] MATERO S, POUTIAINEN S, LESKINEN J, et al. Monitoring the wetting phase of fluidized bed granulation process using multi-way methods; the separation of successful from unsuccessful batches[J]. *Chemometrics and Intelligent Laboratory Systems*, 2009, 96(1): 88–93.
- [15] LUO L J, BAO S Y, MAO J F, et al. Phase partition and phase-based process monitoring methods for multiphase batch processes with uneven durations[J]. *Industrial & Engineering Chemistry Research*, 2016, 55(7): 2035–2048.
- [16] KIERS H A L, TEN BERGE J M F, BRO R. PARAFAC2-Part I. a direct fitting algorithm for the PARAFAC2 model[J]. *Journal of Chemometrics*, 1999, 13(3/4): 275–294.
- [17] WANG L, SHI H B. Multivariate statistical process monitoring using an improved independent component analysis [J]. *Chemical Engineering Research and Design*, 2010, 88(4): 403–414.
- [18] YAO M, WANG H G. On-line monitoring of batch processes using generalized additive kernel principal component analysis[J]. *Journal of Process Control*, 2015, 28: 56–72.
- [19] HOSSEINI S M S, MALEKI A, GHOLAMIAN M R. Cluster analysis using data mining approach to develop CRM methodology to assess the customer loyalty[J]. *Expert Systems with Applications*, 2010, 37(7): 5259–5264.

PARAFAC2-based phase partition of multiphase batch processes

CAO Xue WANG JianLin* QIU KePeng LIU WeiMin HAN Rui

(College of Information Science and Technology, Beijing University of Chemical Technology, Beijing 100029, China)

Abstract: A method of phase partition of multiphase batch processes based on parallel factor analysis 2 (PARAFAC2) is presented. Firstly, a model of each time-slice matrix was built based on PARAFAC2 and the control limit of each time-slice matrix was calculated. Secondly, starting from the initial time of the batch process, each time slice matrix was sequentially added to the time block matrix and a model based on PARAFAC2 was built, and the control limit of each time block matrix was calculated. Thirdly, the phase partition result was determined by evaluating the difference between the time slice and the time block model control limits. Finally, the optimal phase partition result was chosen according to the phase partition combination index (PPCI). Comparison of the simulation results and experimental data for the penicillin fermentation process verified the effectiveness of the proposed method.

Key words: batch processes; multiphase; three-dimensional data; parallel factor analysis 2 (PARAFAC2)

(责任编辑:汪 琴)