

# 基于 TTGNPE 算法的间歇过程监控

赵小强<sup>†</sup>, 惠永永

(兰州理工大学 电气工程与信息工程学院, 兰州 730050)

**摘要:** 针对间歇过程中三维数据展开为二维造成的部分信息丢失以及数据的全局和局部结构可能发生的变化, 提出一种基于张量分解的时序扩展全局局部邻域保持嵌入 (TTGNPE) 算法. 首先利用 TTGNPE 算法直接处理间歇过程中的三维数据, 以避免因展开为二维而造成的信息丢失; 然后, 将近邻流形嵌入并引入数据空间的全局和局部结构保持中, 充分提取数据的局部和全局特征信息; 最后, 结合移动数据窗技术来处理过程的动态时变性, 检测到故障后用贡献图法诊断出故障变量. 通过青霉素发酵过程验证了所提出的算法对间歇过程故障检测与诊断的优越性.

**关键词:** 间歇过程; 过程监控; 张量; 全局和局部邻域保持嵌入; 滑动数据窗

中图分类号: TP277

文献标志码: A

## Batch process monitoring based on TTGNPE algorithm

ZHAO Xiao-qiang<sup>†</sup>, HUI Yong-yong

(College of Electrical Engineering and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China)

**Abstract:** Three-dimension data of batch process unfolded two-dimension data can cause some information loss, and the global and local structures of data may change in the process. Therefore, a temporal extension global-local neighborhood preserving embedding based on tensor factorization (TTGNPE) algorithm is proposed, which can deal directly with three-dimension data to avoid folding information loss. Neighborhood preserving embedding is introduced in the global and local structure preserving of the data space to fully extract global and local feature information of data. By combining moving the data window to handle process dynamic time-variance, the contribution plot method is applied to diagnose fault variables after a failure being detected. The superiority of the proposed algorithm on the penicillin fermentation process is verified for the fault detection and diagnosis of the batch process.

**Keywords:** batch process; process monitoring; tensor; global-local neighborhood preserving embedding; moving data window

## 0 引言

间歇过程被广泛地运用于石油化工、生物制药、发酵、半导体等多品种、高附加值产品的生产中<sup>[1-2]</sup>. 相比于连续过程, 间歇过程最大的区别在于间歇过程所获得的过程数据是由批次、时间和变量构成的三维数据, 而连续过程数据只是由时间和变量构成的二维数据. 间歇过程有着较好的灵活性和快速满足市场变化需求等优点, 随着激烈的竞争, 间歇过程在工业生产中充当着重要的角色. 生产过程的安全和生产质量一直是间歇过程的两个重要目标, 这使得过程监控成为操作过程必不可少的一部分. 过程

监控的主要目标是提前获取可能对生产造成扰动的故障信息, 因此, 找到有效的间歇过程监控方法具有重要的意义.

作为传统的多元统计分析方法, PCA<sup>[3]</sup> 和 PLS<sup>[4]</sup> 可以用来提取高维复杂数据中大部分的信息. 一般来讲, 过程数据的全局和局部结构发生变化都表征着过程的非正常状态. 近年来, 流形学习算法在模式识别和机器学习领域得到广泛的应用, 它能提取原始数据空间中隐藏的低维流形信息, 对局部结构有着较好的保持能力. 自 Roweis 等<sup>[5]</sup> 提出局部线性嵌入 (LLE) 算法以来, 出现了许多新的流形算法, 如等距映

收稿日期: 2016-01-23; 修回日期: 2016-08-09.

基金项目: 国家自然科学基金项目 (61370037); 甘肃省基础研究创新群体基金项目 (1506RJJA031).

作者简介: 赵小强 (1969-), 男, 教授, 博士生导师, 从事故障诊断、生产调度等研究; 惠永永 (1992-), 男, 硕士生, 从事故障诊断的研究.

<sup>†</sup>通讯作者. E-mail: xqzhao@lut.cn

射 (ISOMAP)<sup>[6]</sup>、拉普拉斯特征映射 (LE)<sup>[7]</sup>、局部保持投影 (LPP)<sup>[8]</sup> 和近邻保持嵌入 (NPE)<sup>[9]</sup> 算法等. Hu 等<sup>[10]</sup> 将 LPP 算法用于间歇过程监测并取得了优于 PCA 方法的监测效果, 之后又提出了基于 NPE 的动态间歇过程监测方案<sup>[11]</sup>, 但 NPE 算法只提取了原始数据的局部结构特征, 而忽视了数据的全局结构特征.

在间歇过程的故障诊断中, 通常需将三维数据展开为二维数据. 近年来张量分析 (tensor analysis) 在特征提取、人脸识别<sup>[12]</sup> 和数据挖掘等领域得到了广泛应用. Hu 等<sup>[13]</sup> 提出用张量的方法来处理间歇过程中的三维数据, 为解决间歇过程三维数据提供了新的思路. 张量分析方法并不对三维数据进行二维展开, 而是直接对三维数据进行建模, 这样就不会破坏数据的内在结构, 使更多对监控有利的信息得以保存. 数据空间的全局和局部结构特征都体现了样本空间的重要性, 无论缺失哪一方面都会对过程的检测性能造成影响. Zhang 等<sup>[14]</sup> 提出了一种基于全局-局部结构分析 (GLSA) 算法, 通过对全局结构和局部结构目标函数的加权, 折衷提取过程数据全局-局部结构特征, 但没有进行一个全局的优化, 而且展开为二维数据造成了原始数据信息的损失; Luo 等<sup>[15]</sup> 提出了基于张量的全局局部结构分析算法 (TGLSA), 该算法避免了由于三维数据的展开而造成信息的丢失, 但是没有进行全局优化.

本文提出一种基于张量的时序扩展全局局部邻域保持嵌入 (TTGNPE) 算法, 直接处理三维数据从而避免展开造成的信息丢失, 通过数据空间的全局结构保持子目标中嵌入近邻排列信息, 寻找一个能够折衷考虑原始空间全局和局部结构特征的低维特征子空间. 该算法所定义的全局结构保持目标函数能够考虑到原始样本空间中数据点的密集情况, 局部结构保持目标函数能够考虑到原始样本空间中数据点的动态自相关性, 通过移动数据窗技术能够更好地处理生产过程的时变性以及避免在线监控时对未来数据的预测.

## 1 时序扩展的邻域保持嵌入 (TNPE) 算法

在邻域嵌入 (NPE) 算法的基础上, Miao 等<sup>[16]</sup> 提出了考虑其动态自相关性的时序扩展邻域保持嵌入 (TNPE) 算法, 该算法同时考虑数据的局部空间变化和时间变化特征.

假设原始变量空间数据  $X = (x_1, x_2, \dots, x_n) \in R^D$ , 首先对数据进行归一化处理, 算法如下.

1) 选择近邻点. 针对数据点  $x_i$ , 首先构建其空间

邻域集  $S_i \in \{x_1, x_2, \dots, x_k\}$ , 使用 KNN 方法选择邻接点. 选取其  $2m$  时间序列邻近点集  $P_i \in \{x_{i-m}, \dots, x_{i-1}, x_{i+1}, \dots, x_{i+m}\}$  进行动态建模.

2) 建立目标函数. 为了将原始空间中的样本映射到低维空间后, 数据的局部近邻结构特征可以得到保留, 设目标函数为

$$J(y) = \min(\eta\phi(y)_s) + \min((1-\eta)\phi(y)_p). \quad (1)$$

其中:  $\phi(y)_s = \sum_{i=1}^n \left\| y_i - \sum_{j=1}^k W_{s_{ij}} y_{ij} \right\|^2$  描述了数据的

低维空间几何结构信息;  $\phi(y)_p = \sum_{i=1}^n \left\| y_i - \sum_{j=1}^{2m} W_{p_{ij}} y_{ij} \right\|^2$

描述了数据的时序动态变化信息;  $y_i$  为  $x_i$  的低维信息;  $y_{ij}$  为  $y_i$  的近邻点;  $\eta$  为特征信息的权重系数, 用来平衡数据空间和时间的特征信息, 其取值范围为  $0 \leq \eta \leq 1$ .

## 2 基于张量分解的时序扩展全局局部邻域保持嵌入 (TTGNPE) 算法

本文提出的 TTGNPE 算法利用张量分解, 在不三维数据进行二维展开的情况下直接处理, 能够有效地保持数据内部结构的完整<sup>[13]</sup>; 利用流形学习算法的近邻嵌入能力, 将近邻嵌入同时引入数据空间的全局和局部结构保持中; 通过定义一个不同的全局结构保持目标函数并将其与局部结构保持的目标函数整合为一, 提出了综合考虑全局和局部结构保持的新目标函数.

对于批次数为  $I$ 、变量数为  $J$  和时间为  $K$  的三维的间歇过程数据矩阵  $X(N \times K \times J) = \{X_i | X_i \in R^K \otimes R^J\}$ ,  $i = 1, 2, \dots, N$ , 寻找两个转换矩阵  $U \in R^K \otimes R^{K_1}$  ( $K \geq K_1$ ) 和  $V \in R^J \otimes R^{J_1}$  ( $J \geq J_1$ ), 可得  $Y_i = U^T X_i V$ .

### 2.1 局部结构保持

局部结构保持是通过每个数据点及其近邻点进行重构以挖掘出数据局部结构信息, 其目标函数为

$$J_{T\text{local}}(U, V) = \min \eta \phi(Y)_s + \min((1-\eta)\phi(Y)_p) = \min_{U, V} \eta \sum_i \left\| U^T X_i V - \sum_{j=1}^k W_{s_{ij}} U^T X_i V \right\|^2 + \min_{U, V} (1-\eta) \sum_i \left\| U^T X_i V - \sum_{j=1}^{2m} W_{p_{ij}} U^T X_i V \right\|^2. \quad (2)$$

其中:  $\eta$  为特征信息的权重系数, 用来平衡数据空间和时间的特征信息, 其取值范围为  $0 \leq \eta \leq 1$ ;  $W_{s_{ij}}$ 、 $W_{p_{ij}}$  分别为数据空间和时间的特征信息近邻点的权

重系数,其取值见文献[16].

## 2.2 全局结构保持

在全局结构保持中,同样也嵌入近邻特征以更好地体现数据点分布的密度信息.在此,使用样本 $x_i$ 的局部均值 $\bar{x}_i$ 来代替整体均值 $x$ , $\bar{x}_i$ 定义为样本 $x_i$ 近邻集 $N(x_i, x_j)$ 的均值向量,即

$$\bar{x}_i = \frac{1}{n_i} \sum_{x_j \in N(x_i, x_j)} x_j, \quad i = 1, 2, \dots, n, \quad (3)$$

其中 $n_i$ 是近邻集 $N(x_i, x_j)$ 中的元素个数.因此,全局结构保持的目标是通过求解下式的最优解来求出相应的变换矩阵 $U$ 和 $V$ :

$$J_{T_{\text{global}}}(U, V) = \max_{U, V} \frac{1}{N} \sum_i \|Y_i - \bar{Y}_i\|, \quad (4)$$

$$U^T U = I, \quad V^T V = I.$$

其中: $Y_i = U^T X_i V$ ,  $\bar{X}_i = [\bar{x}_1, \bar{x}_2, \dots, \bar{x}_n]$ 是局部矩阵函数, $\bar{Y}_i = U^T \bar{X}_i V$ ,  $I$ 是单位矩阵,  $N$ 是批次.

## 2.3 TTGNPE算法

如上所述,TTGNPE算法需要同时兼顾局部和全局两个目标函数,这其实是一个相悖的双目标优化问题,很难同时取得最优.为了方便求解,定义如下新的目标函数:

$$J_{\text{TTGNPE}}(U, V) = \frac{\max_i \sum \|Y_i - \bar{Y}_i\|}{\min \eta \phi(Y)_s + \min((1 - \eta) \phi(Y)_p)}. \quad (5)$$

式(5)是受fisher判别分析目标函数的启发而定义的一个新的目标函数.即通过定义如式(5)的判别准则函数,找到使该函数最大化时的变量,通过拉格朗日乘子法进行求解.因为 $\|A\|^2 = \text{tr}(AA^T)$ ,所以式(5)可以改写为

$$J_{\text{TTGNPE}}(U) = \max \frac{\text{tr}(U^T S_V U)}{\text{tr}(U^T W_V U)}. \quad (6)$$

其中

$$S_V = \sum_i (X_i - \bar{X}_i) V V^T (X_i - \bar{X}_i)^T,$$

$$W_V = W_{sV} + W_{pV},$$

$$W_{sV} = \eta \sum_i \left( X_i - \sum_{j=1}^k W_{sij} X_i \right) \times$$

$$V V^T \left( X_i - \sum_{j=1}^k W_{sij} X_i \right)^T,$$

$$W_{pV} = (1 - \eta) \sum_i \left( X_i - \sum_{j=1}^{2m} W_{pij} X_i \right) \times$$

$$V V^T \left( X_i - \sum_{j=1}^{2m} W_{pij} X_i \right)^T,$$

$$V V^T = I.$$

这样就能够找到 $U$ 的最优解.

同理,式(5)可以改为下式:

$$J_{\text{TTGNPE}}(V) = \max \frac{\text{tr}(V^T S_U V)}{\text{tr}(V^T W_U V)}. \quad (7)$$

其中

$$S_U = \sum_i (X_i - \bar{X}_i)^T U U^T (X_i - \bar{X}_i),$$

$$W_U = W_{sU} + W_{pU},$$

$$W_{sU} = \eta \sum_i \left( X_i - \sum_{j=1}^k W_{sij} X_i \right)^T \times$$

$$U U^T \left( X_i - \sum_{j=1}^k W_{sij} X_i \right),$$

$$W_{pU} = (1 - \eta) \sum_i \left( X_i - \sum_{j=1}^{2m} W_{pij} X_i \right)^T \times$$

$$U U^T \left( X_i - \sum_{j=1}^{2m} W_{pij} X_i \right),$$

$$U U^T = I,$$

这样就能求出 $V$ 的最优解.

式(6)和(7)可以转换成如下广义特征值问题:

$$S_V U = \lambda W_V U, \quad (8)$$

$$S_U V = \lambda W_U V. \quad (9)$$

其中: $U = [u_1, u_2, \dots, u_{K_I}]$ 是式(8)的前 $K_I$ 个最大特征值对应的特征向量, $V = [v_1, v_2, \dots, v_{J_I}]$ 是式(9)的前 $J_I$ 个最大特征值对应的特征向量.在本文中, $K_I$ 和 $J_I$ 分别取 $K_I = K$ ,  $J_I = J$ .

## 3 基于TTGNPE算法的过程监控

### 3.1 基于TTGNPE算法的故障检测

通过SPD(squared projection difference)和 $R^2$ 统计量来对过程进行监控<sup>[15]</sup>.SPD统计量用来度量样本 $X_i$ 与特征变量 $Y_i$ 的差异,其具体构造为

$$\text{SPD} = \sum_{jk=1}^{JK} e_{jk}^2 = \sum_{jk=1}^{JK} (x_{jk} - y_{jk})^2. \quad (10)$$

其中: $x_{jk}$ 是变量数为 $j$ 和样本数为 $k$ 的值, $y_{jk}$ 是 $x_{jk}$ 通过TTGNPE算法的投影值.

SPD统计量控制限是由正常工况下的样本近似 $\chi^2$ 分布得到的,其计算式为

$$\text{SPE}_\alpha = g \chi_{h, \alpha}^2, \quad g = \frac{v}{2m}, \quad h = \frac{2m^2}{v}. \quad (11)$$

其中: $g$ 和 $h$ 是 $\chi^2$ 分布的参数, $m$ 和 $v$ 是训练数据集的

均值和方差,  $\alpha$  是显著性水平.

$R^2$  统计量是一种过程监控统计量, 用每个批次的投影到特征空间中心的距离来度量这个批次的偏离程度. 批次  $X_k$  的  $R^2$  统计量的构造式为

$$R^2 = \text{tr}(Y_k Y_k^T) - 2 \sum_i \alpha_i \text{tr}(Y_k Y_i^T) + \sum_{ij} \alpha_i \alpha_j \text{tr}(Y_i Y_j^T), \quad (12)$$

其中  $\alpha_i$  是 STDD 在数据集  $Y(I \times K \times J)$  下的拉格朗日乘子, 具体见文献[17].

$R^2$  统计量控制限也是通过样本近似  $\chi^2$  分布估计得到的, 其构造式为

$$R_\alpha = g \chi_{h, \alpha}^2, \quad g = \frac{v}{2m}, \quad h = \frac{2m^2}{v}, \quad (13)$$

其中  $m$  和  $v$  是训练数据集中所有支持张量和离群值的均值和方差.

检测到故障后需要诊断出故障变量. 本文采用故障贡献图的方法, 把对故障贡献率最大的变量认为是故障变量. 样本时间为  $j$  时变量为  $k$  的 SPD 统计量的贡献率  $e_{kj}^2$  及  $R^2$  统计的贡献率分别为

$$e_{kj}^2 = (x_{kj} - y_{kj}), \quad (14)$$

$$c_{jk} = x_{jk} \text{tr}(u_k^T b_j^T V Y_k^T) - 2 \sum_i x_{kj} \alpha_i \text{tr}(u_k^T b_j^T V Y_i^T). \quad (15)$$

其中:  $u_k$  是变换矩阵  $U$  的第  $k$  行,  $b_j$  是第  $j$  个元素为 1 其他元素都是 0 的列向量.

### 3.2 滑动数据窗

通过结合 TTNPE 与滑动数据窗技术来实现在线监控. 滑动数据窗技术可以提取时变的动态过程, 并且能够避免对未来数据的预测. 设滑动数据窗的宽度为  $d$ , 则第  $I$  批次的窗内数据如下:

$$X_i(d \times J/k) = \begin{bmatrix} x_{k-d+1,1}^i & x_{k-d+1,2}^i & \cdots & x_{k-d+1,J}^i \\ x_{k-d+2,1}^i & x_{k-d+2,2}^i & \cdots & x_{k-d+2,J}^i \\ \vdots & \vdots & \ddots & \vdots \\ x_{k,1}^i & x_{k,1}^i & \cdots & x_{k,1}^i \end{bmatrix}.$$

滑动数据窗技术适用于在线检测, 随着窗口的滑动, 不断地添加新时刻的数据, 去除旧时刻数据, 得到一个新的正常数据模型, 使得算法遵循动态时变的过程.

窗口  $d$  的大小对故障检测的敏感性和准确性有很大的影响. 然而, 选择合适的滑动窗口大小和步长始终是一个难题且没有统一标准, 目前主要凭借经验选择<sup>[18-19]</sup>. 在本文中, 窗口的大小依据检测已知故障的快速性和准确性来选择<sup>[20]</sup>.

### 3.3 监控的具体步骤

#### 1) 离线监控.

1.1) 选择相关批次组成训练模型;

1.2) 选择合适的窗口大小  $d$ ;

1.3) 标准化窗口数据;

1.4) 建立正常情况下的 TTNPE 模型;

1.5) 获取 SPD 和  $R^2$  统计量的控制限.

#### 2) 在线监控.

2.1) 对新批次在采样时刻  $k$  对应的窗口数据进行标准化;

2.2) 将窗口内的数据投影到 TTNPE 模型上, 计算 SPD 与  $R^2$  的统计量;

2.3) 判断统计量是否超限, 如果超限则说明发生故障, 用贡献图法找出故障变量, 否则返回到 2.1), 对  $k+1$  时刻进行监控.

## 4 仿真实验

本文通过 Birol 等<sup>[21]</sup> 提出的 Pensim2.0 青霉素发酵过程的标准仿真平台产生出间歇过程数据. 本文将每批次的反应时间设为 400 h, 采样时间设为 0.1 h, 在初始条件设置不同但都在正常范围内、不引入故障的情况下共产生 50 个批次正常工况下的数据, 从产生的 18 个变量数据中选择 10 个过程变量作为监控变量(见表 1), 构成三维矩阵  $X(50 \times 10 \times 2000)$  作为训练样本.

表 1 过程变量

变量号	变量名称
1	通风速率
2	搅拌速率
3	底物流加速度
4	补料温度
5	基质浓度
6	溶解氧浓度
7	反应器体积
8	排气二氧化碳浓度
9	pH 值
10	发酵罐温度

Pensim2.0 仿真平台不仅可以产生正常工况下的数据, 而且还提供了 3 种故障类型. 本文引入故障类型 2, 即变量 2 的搅拌功率故障, 在采样时间 160~300 h(采样点 1600~3000) 时加入 +10% 的阶跃信号作为故障信号, 所产生的数据作为故障样本以供在线检测. 分别用 TNPE 算法和本文提出的 TTNPE 算法对故障样本进行监控, 得到图 1~图 4 的监控图.




图1 TNPE的SPD监控图




图2 TTGNPE算法的SPD监控图




图3 TNPE算法的R^2监控图




图4 TTGNPE算法的R^2监控图

图1是TNPE算法的SPD监控图,在整个监控过程中多点出现了误报,监控效果不佳.图2是本文TTGNPE算法的SPD监控图,在无故障的情况下没有超出控制限的点,在刚发生故障的时刻(采样点1000)就能够迅速诊断出故障,无漏报现象.这说明TTGNPE算法具有更好的监控效果.图3是TNPE算法的 $R^2$ 监控图,在采样点600以前产生误报,在采样点3800之后出现误报.图4是TTGNPE算法的 $R^2$ 监控图,可以看出只在部分点有跳变,产生误报,但其相对于TNPE算法误报较少.显然,TTGNPE算法具有

更好的监控效果.

检测到过程发生故障后用贡献图法计算出各变量对故障的贡献率,贡献度最大的变量被认为是故障变量,诊断结果如图5~图8所示.




图5 TNPE算法的SPD贡献图




图6 TNPE算法的R^2贡献图




图7 TTGNPE算法的SPD贡献图




图8 TTGNPE算法的R^2贡献图

图5和图6是TNPE算法的SPD和 $R^2$ 的贡献图,两种统计量的贡献图中贡献率最大的都是真实故障变量2,都可以诊断出故障变量;图7和图8是TTGNPE算法的SPD和 $R^2$ 的贡献图,可以看出只有变量2(实际故障变量)的贡献率较大,其他变量的贡献率都较小,这说明TTGNPE算法用贡献图法就能准确地诊断出故障变量.

## 5 结 论

本文提出的TTGNPE算法通过直接处理间歇过程中的三维数据,即可避免因展开所造成的信息丢失;充分提取数据的局部特征信息的同时,还兼顾了数据的全局特征信息.在构建局部空间结构特征的基础上,同时考虑了数据随时间变化的动态特征,使投影得到的低维空间不仅与原始变量空间具有相似的空间局部近邻结构,而且具有相似的时序动态结构;在全局结构中增加了近邻信息,因而包含了更多的特征信息.通过青霉素发酵过程的仿真实验,验证了本文所提出的算法对间歇过程的故障具有较好的监控效果.

### 参考文献(References)

- [1] Nomikos P, MacGregor J F. Multivariate SPC charts for monitoring batch processes[J]. *Technometrics*, 1995, 37(1): 41-59.
- [2] Hu K L, Yuan J Q. Batch process monitoring with tensor factorization[J]. *J of Process Control*, 2009, 19(2): 288-296.
- [3] Jackson J E. A user's guide to principal components[M]. New York: Wiley, 1991.
- [4] Dayal B S, MacGregor J F. Improved PLS algorithms[J]. *J of Chemom*, 1997, 11(1): 73-85.
- [5] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding[J]. *Science*, 2000, 290(5500): 2323-2326.
- [6] Tenenbaum J B, Silva V D, Langford J C. A global geometric framework for nonlinear dimensionality reduction [J]. *Science*, 2000, 290(5500): 2319-2323.
- [7] Belkin M, Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation[J]. *Neural Computation*, 2003, 15(6): 1373-1396.
- [8] He X F, Niyogi P. Locality preserving projection[J]. *Advances in Neural Information Processing Systems*, 2003, 16(1): 153-160.
- [9] He X F, Cai D, Yan S C, et al. Neighborhood preserving embedding[C]. *Proc of the 10th IEEE Int Conf on Computer Vision*. Beijing, 2005: 1208-1213.
- [10] Hu K, Yuan J. Multivariate statistical process control based on multiway locality preserving projections[J]. *J of Process Control*, 2008, 18(7/8): 797-807.
- [11] Hu K, Yuan J. Statistical monitoring of fed-batch process using dynamic multiway neighborhood preserving embedding[J]. *Chemometrics & Intelligent Laboratory Systems*, 2008, 90(2): 195-203.
- [12] Liu S, Ruan Q Q. Orthogonal tensor neighborhood preserving embedding for facial expression recognition[J]. *Pattern Recognition*, 2011, 44(7): 1497-1513.
- [13] Hu K L, Yuan J Q. Batch process monitoring with tensor factorization[J]. *J of Process Control*, 2009, 19(2): 288-296.
- [14] Zhang M G, Ge Z Q, Song Z H, et al. Global-local structure analysis model and its application for fault detection and identification[J]. *Industrial & Engineering Chemistry Research*, 2011, 50(11): 6837-6848.
- [15] Luo L J, Bao S Y, Gao Z L, et al. Batch process monitoring with tensor global-local structure analysis[J]. *Industrial & Engineering Chemistry Research*, 2013, 52(50): 18031-18042.
- [16] Miao Aimin, Ge Zhiqiang, Song Zhihuan, et al. Time neighborhood preserving embedding model and its application for fault detection[J]. *Industrial & Engineering Chemistry Research*, 2013, 52(38): 13717-13729.
- [17] Luo Lijia, Bao Shiyi, Gao Zengliang, et al. Tensor global-local preserving projections for batch process monitoring[J]. *Industrial & Engineering Chemistry Research*, 2014, 53(24): 10166-10176.
- [18] Singhal A, Seborg D E. Pattern matching in multivariate time series databases using a moving-window approach[J]. *Industrial & Engineering Chemistry Research*, 2002, 41(16): 3822-3838.
- [19] Kano M, Hasebe S, Hashimoto I, et al. Statistical process monitoring based on dissimilarity of process data[J]. *AIChE J*, 2002, 48(6): 1231-1239.
- [20] Wang X, Kruger U, Irwin G W. Process monitoring approach using fast moving window PCA[J]. *Industrial & Engineering Chemistry Research*, 2005, 44(15): 5691-5702.
- [21] Birol G, Undey C, Cinar A. A modular simulation package for fed-batch fermentation: Penicillin production[J]. *Computers & Chemical Engineering*, 2002, 26(11): 1553-1565.

(责任编辑:李君玲)