

## 基于动态高效潜结构投影的质量相关故障检测

孔祥玉, 王晓兵<sup>†</sup>, 罗家宇, 杨治艳

(火箭军工程大学 导弹工程学院, 陕西 西安 710025)

**摘要:** 高效潜结构投影(EPLS)算法是一种反映过程变量与质量变量相关关系的多变量统计分析方法, 在质量相关故障检测中具有良好的检测效果. 然而EPLS算法是一种静态检测模型, 不能反映实际工业过程或装备测试中的动态特性, 对动态过程中质量相关故障的检测率较低. 为此, 本文提出了一种基于自回归移动平均模型(ARMAX)的动态高效潜结构投影(D-EPLS)检测算法. 该算法首先基于输入时滞值构建增广矩阵, 反映工业以及装备测试过程中的动态特性; 然后将增广矩阵分解为质量相关和质量无关空间分别进行故障检测; 最后通过数值仿真和田纳西伊斯曼过程(TEP)验证算法有效性. 实验结果表明所提算法能够更好的适应动态过程, 并全面提高了质量相关故障的检测率.

**关键词:** 数据驱动; 自回归移动平均模型; 偏最小二乘; 动态系统; 故障检测; 田纳西伊斯曼过程

**引用格式:** 孔祥玉, 王晓兵, 罗家宇, 等. 基于动态高效潜结构投影的质量相关故障检测. 控制理论与应用, 2021, 38(12): 2076 – 2084

DOI: 10.7641/CTA.2021.00586

## Quality-related fault detection based on dynamic efficient projection to latent structures

KONG Xiang-yu, WANG Xiao-bing<sup>†</sup>, LUO Jia-yu, YANG Zhi-yan

(Department of Missile Engineering, Rocket Force University of Engineering, Xi'an Shaanxi 710025, China)

**Abstract:** Efficient projection to latent structures (EPLS) algorithm is a multivariate statistical analysis method to reflect the correlation between process variables and quality variables, which performs well in quality-related fault detection. However, since the EPLS algorithm is a static detection model, it cannot reflect the dynamic characteristics of the actual industrial process or equipment testing, and the detection rate of quality-related faults in the dynamic process is low. Therefore, this paper proposes a dynamic efficient projection to latent structures (D-EPLS) projection algorithm based on the auto-regressive moving average exogenous (ARMAX) model. Firstly, an augmented matrix is constructed based on the input delay value to reflect the dynamic characteristics. Secondly, the augmented matrix is decomposed into quality related and unrelated spaces for fault detection respectively. Finally, numerical simulation and Tennessee Eastman process (TEP) are used to verify the effectiveness of the D-EPLS algorithm. Experimental results show that the proposed algorithm can be better adapted to the dynamic process and improve the detection rate of quality related faults.

**Key words:** data-drive; auto-regressive model; partial least squares; dynamic system; fault detection; Tennessee Eastman process

**Citation:** KONG Xiangyu, WANG Xiaobing, LUO Jiayu, et al. Quality-related fault detection based on dynamic efficient projection to latent structures. *Control Theory & Applications*, 2021, 38(12): 2076 – 2084

### 1 引言

近年来, 随着现代工业流程如化工、制药、发电以及复杂装备系统等逐渐向大型化和复杂化的趋势发展, 使得基于传统物理模型的过程监控方法难以适应现代大型工业过程以及复杂装备测试的需求; 同时伴随着现代先进传感器和物联网技术的不断提高, 采集

到的过程数据也越来越复杂. 因此基于数据驱动的建模方法得到了广泛关注并成功应用于多种复杂工业过程及装备测试监控中<sup>[1-4]</sup>. 其中主成分分析(principal component analysis, PCA)<sup>[5]</sup>、规范变量分析(canonical variable analysis, CVA)<sup>[6]</sup>、独立成分分析(independent component analysis, ICA)<sup>[7]</sup>, 偏最小二乘(partial

收稿日期: 2020-09-02; 录用日期: 2021-03-24.

<sup>†</sup>通信作者. E-mail: ctwangxiaobing@163.com; Tel.: +86 15937822087.

本文责任编辑: 张化光.

国家自然科学基金项目(61673387, 61833016), 陕西省自然科学基金项目(2020JM-356)资助.

Supported by the National Natural Science Foundation of China (61673387, 61833016) and the National Natural Science Foundation of Shaanxi Province (2020JM-356).

least squares, PLS)<sup>[8-9]</sup>等是多元统计过程监控的代表性方法, 它们能够有效地处理高维度且相互耦合的数据.

在多元统计过程监控领域, PLS利用质量变量与过程变量的相关性在数据建模中引导过程变量的投影分解, 所引导的投影空间能够反应过程变量与质量变量相关的变化. 因此, PLS算法在质量相关故障检测中具有明显的优势. 然而标准PLS算法在迭代建模的过程中存在两个缺点<sup>[10]</sup>: 1) PLS提取潜变量的原则是基于 $X$ 和 $Y$ 协方差最大, 并未完全按照 $X$ 的特征信息大小降序提取, 导致残差子空间存在较大变异; 2) 由于对输入 $X$ 采用斜交分解, 导致 $X$ 的主元子空间中含有与输出 $Y$ 正交的信息, 这些信息对预测无用. 针对PLS算法的缺点1, Zhou等<sup>[10]</sup>提出了全潜结构投影(total projection to latent structures, TPLS)算法, 将主元空间和残差空间进一步分为4个子空间. 针对TPLS存在多空间分解问题, Qin等<sup>[11]</sup>提出了并行潜结构投影(concurrent projection to latent structures, CPLS)算法, 该算法将输入数据空间简洁的分解为输入相关和输出相关的部分. 针对缺点2, Yin等<sup>[12]</sup>提出改进的潜结构投影(modified projection to latent structures, MPLS)算法, 采用奇异值分解(singular value decomposition, SVD)构造正交投影算子, 将 $X$ 正交投影到质量相关子空间和质量无关子空间. Peng等<sup>[13]</sup>针对MPLS在推导中协方差的逆矩阵可能导致 $X$ 与 $Y$ 相关信息丢失的问题, 提出了将MPLS中的残差空间进一步主元分析的高效潜结构投影(efficient projection to latent structures, EPLS)算法.

上述方法都只考虑了质量变量和过程变量之间的静态关系, 然而复杂工业及装备系统通常具有随时间变化的动态特性. 对于这一特征, 目前有子空间辨识思想的CVA<sup>[6]</sup>、描述非平稳变量间关系的协整分析(cointegration analysis, CA)<sup>[14]</sup>、建立自回归状态挖掘过程动态特征的动态因变量模型(dynamic latent variable, DLV)<sup>[15]</sup>、通过静态和动态信息联合分析提取数据动静态特征的慢特征分析(slow feature analysis, SFA)<sup>[16]</sup>以及时序拓展<sup>[17]</sup>等多种分析方法用于动态系统的故障检测. 其中时序拓展的思想是利用历史时间序列拟合的数学模型提取各变量之间的互相关及过程的自相关关系, 可以描述系统的动态特征. 基于时序拓展的思想, Lee等<sup>[18]</sup>在2003年最先提出动态偏最小二乘方法(dynamic PLS, D-PLS)用于质量相关故障检测. Li等<sup>[19]</sup>提出一种内外模型一致的动态PLS算法用于动态过程建模, 并扩展到动态TPLS(dynamic inner TPLS, Di-TPLS)算法用于故障检测, 针对MPLS算法对质量相关故障检测时存在的静态模型问题, Jiao等<sup>[20]</sup>提出了一种动态MPLS(dynamic MPLS, D-MPLS)质量相关故障检测算法, Kong等<sup>[21]</sup>利用时滞过程

数据与时延质量数据之间的关系, 建立了在线监控动态潜结构投影(online monitoring dynamic projection to latent structures, OMD-PLS)模型, 并在此基础上提出在线监控并行动态潜结构投影(online monitoring dynamic concurrent projection to latent structures, OMDC-PLS)模型, 实现微小故障的检测.

基于时序拓展的思想已经被应用于多种质量相关故障检测算法中, 但所拓展的动态算法仍存在静态模型本身同样的不足. 例如D-PLS对输入 $X$ 仍采用斜交分解, 导致 $X$ 的主元子空间中含有与输出 $Y$ 正交的信息, 这些信息对预测无用; D-MPLS采用正交分解, 但求解系数过程中仍存在广义逆, 这将导致信息丢失影响质量相关故障的检测性能. 静态EPLS算法的提出在质量相关故障检测时具有空间分解清晰且高效的优势, 保证了模型信息的完备性. 但EPLS算法在建模过程没有考虑实际过程中存在动态特性, 忽略了样本数据受到历史数据的影响, 导致所建立的模型对于动态过程并不适用, 从而降低了模型精度和质量相关故障的检测性能, 因此有必要对该模型进行动态扩展.

通常工业过程中当前时刻的样本值受历史采样样本的影响, 自回归移动平均(auto-regressive moving average exogenous, ARMAX)模型是通过历史样本值对当前样本值进行预测的模型, 所以该模型能够反映工业过程的动态特征. 基于此模型思想, 在EPLS算法的基础上, 本文提出一种基于ARMAX模型的动态高效潜结构投影(dynamic efficient projection to latent structures, D-EPLS)的质量相关故障检测方法. 该方法首先采用ARMAX模型的矩阵形式, 将大量的历史输入及历史输出加入建模样本矩阵中, 然后利用奇异值分解和主成分分析将扩充的样本矩阵分解为质量相关子空间、质量无关子空间和残差子空间, 最后设计相应的指标进行动态系统中的故障检测. 该方法不仅考虑了变量的动态自相关, 同时建立了质量变量与过程变量之间清晰的空间分解模型, 有效减少了质量相关空间中对预测无用的信息, 保证了空间分解的完备性.

本文的主要创新如下:

- 1) 在EPLS算法的基础上, 利用ARMAX模型的时滞性获取变量时间序列的自相关性动态模型, 提出一套基于D-EPLS完整的质量相关故障检测方法.
- 2) D-EPLS在空间分解中采用了SVD分解的方法, 避免了PLS中大量的迭代过程, 并在质量相关故障检测中表现出较好的检测性能, 同时对质量相关故障检测率有了全面提高.

## 2 PLS和EPLS基础

输入矩阵 $X$ 和输出矩阵 $Y$ 是对 $m$ 个过程变量和

$p$ 个质量变量进行 $n$ 次采样得到.

$$X = \begin{bmatrix} x_1^T \\ x_2^T \\ \vdots \\ x_n^T \end{bmatrix} \in \mathbb{R}^{n \times m}, Y = \begin{bmatrix} y_1^T \\ y_2^T \\ \vdots \\ y_n^T \end{bmatrix} \in \mathbb{R}^{n \times p}.$$

PLS是由输入数据矩阵 $X$ 和输出数据矩阵 $Y$ 对潜变量 $t_i$ 和 $u_i$  ( $i = 1, 2, \dots, A$ ) 回归建模的算法,  $A$ 为主元个数. 而潜变量的选取一般满足两个原则<sup>[18]</sup>: 第1,  $t_i$ 和 $u_i$ 尽可能多的携带各自数据矩阵的变异信息; 第2,  $t_i$ 和 $u_i$ 之间的相关程度达到最大. 两个原则可由如下式表示:

$$\begin{cases} \max w_i^T X_i^T Y_i^T c_i, \\ \text{s.t. } \|w_i\| = \|c_i\| = 1, \end{cases} \quad (1)$$

其中 $w_i$ 和 $c_i$ 分别是过程潜变量 $t_i$ 和 $u_i$ 的权向量.

PLS模型参数求解通常有非线性迭代法<sup>[22]</sup>和特征分解法<sup>[23]</sup>. 通过对过程变量 $X$ 和质量变量 $Y$ 分别对潜结构变量 $t_i$ 和 $u_i$ 进行回归建模, 得到如下模型:

$$\begin{cases} X = \hat{X} + \tilde{X} = TP^T + \tilde{X}, \\ Y = \hat{Y} + \tilde{Y} = TQ^T + \tilde{Y}, \end{cases} \quad (2)$$

其中:  $T$ 为得分矩阵,  $P \in \mathbb{R}^{m \times A}$ 和 $Q \in \mathbb{R}^{p \times A}$ 分别为 $X$ 和 $Y$ 的负载矩阵.  $\hat{X}$ 为主元子空间,  $\hat{Y}$ 为可预测空间,  $\tilde{X}$ 和 $\tilde{Y}$ 为输入残差子空间和输出残差子空间.

Yin等<sup>[12]</sup>提出对 $X$ 采取正交分解的MPLS模型, 减少了 $\hat{X}$ 中对预测无用的变化<sup>[24]</sup>. 通过对输入矩阵 $X$ 和输出矩阵 $Y$ 空间分解, 得到MPLS模型.

EPLS算法是在MPLS算法的基础上提出的, 通过对 $X$ 奇异值分解和主成分分析将过程变量分解为3个空间, 有效的解决了工业过程质量相关故障检测的实时性和有效性的问题. 建立过程变量和质量变量关系模型:

$$Y = X\Psi + E, \quad (3)$$

其中:  $\Psi$ 是系数矩阵,  $E$ 为残差矩阵.

为了使输入与残差正交, 需要输入矩阵的列向量与残差矩阵的列向量正交, 即

$$E^T X = 0. \quad (4)$$

因此, 式(3)可以转化为

$$Y^T X = \Psi^T X^T X + E^T X \simeq \Psi^T X^T X. \quad (5)$$

由式(5)可以得到系数矩阵 $\Psi = (X^T X)^{\dagger} X^T Y$ . 根据SVD分解得到两个正交投影空间, 然后将输入矩阵投影到两个正交空间. 对于残差子空间, 利用PCA产生两个子空间, 对影响质量相关的干扰或噪声完全分解. 通过EPLS算法, 得到如下模型:

$$\begin{cases} X = \hat{X} + T_X P_X^T + \tilde{X}_r, \\ Y = \hat{Y} + E_y = X\Psi + E_y, \end{cases} \quad (6)$$

其中:  $T_X$ 和 $P_X$ 分别为 $\tilde{X}_r$ 的得分矩阵和负载矩阵,  $\tilde{X}_r$ 为残差空间.

**注1** PLS模型潜变量的选取是基于潜变量尽可能多的携带数据矩阵的变异信息和输入输出潜变量的相关程度尽可能大两个原则, 这使得模型参数的获取需要大量的迭代过程. 而EPLS模型根据SVD分解和PCA分解得到3个正交投影空间, 即将 $\Psi\Psi^T$ 进行SVD分解, 然后将质量无关空间进一步分解分为两个空间, 该过程有效避免了PLS中大量的迭代过程, 减少了计算量. 文献[13]对EPLS, PLS, MPLS, TPLS, CP-LS等多种算法的计算量进行了详细的对比, 显示出EPLS算法在质量相关故障检测中高效的优点.

### 3 基于D-EPLS的故障检测技术

对于大型工业及复杂装备系统的动态过程, 当前变量值通常受到过去时刻变量值的影响. 为了更好的表征系统中过程变量与质量变量之间的动态关系, 采用ARMAX模型的矩阵形式, 将采样样本进行时序拓展, 构造反应系统动态特性的增广矩阵. 假设采样的时间滞后为 $q$ , 即每个变量的当前样本值 $x(t)$ 利用 $q$ 个历史样本数据值 $x(t-1), x(t-2), \dots, x(t-q)$ 表示, 获取连续样本间动态相关性. 构造过程变量时序拓展矩阵 $X_g = [X_1 \ X_2 \ \dots \ X_q]$ , 其中 $X_i$ 的含义如图1所示. 其中 $x(i)$ 为初始每个采样时刻的样本. 对于质量变量的样本采用相同的方式进行时序拓展.




图1 动态系统中过程变量时序拓展图

Fig. 1 Time series expansion diagram of process variables in dynamic system

每个采样样本包括 $m$ 个过程变量和 $p$ 个质量变量, 根据变量时序拓展形式构造的过程变量和质量变量矩阵, 有如下形式:

$$\begin{cases} X_g = [X_1 \ X_2 \ \dots \ X_q] \in \mathbb{R}^{(n-q+1) \times mq}, \\ Y_g = [Y_1 \ Y_2 \ \dots \ Y_q] \in \mathbb{R}^{(n-q+1) \times pq}, \end{cases} \quad (7)$$

其中 $X_i$ 和 $Y_i$  ( $i = 1, 2, \dots, q$ ) 为每个时滞矩阵, 具体形式如下:

$$X_i = \begin{bmatrix} x_1(i) & \dots & x_m(i) \\ \vdots & \vdots & \vdots \\ x_1(i+n-q) & \dots & x_m(i+n-q) \end{bmatrix}_{(n-q+1) \times m},$$

$$Y_i = \begin{bmatrix} y_1(i) & \dots & y_p(i) \\ \vdots & \vdots & \vdots \\ y_1(i+n-q) & \dots & y_p(i+n-q) \end{bmatrix}_{(n-q+1) \times p}.$$

建立过程变量  $X_g$  与质量变量  $Y_g$  之间的关系模型

$$Y_g = \hat{Y}_g + E_g = X_g M_g + E_g, \quad (8)$$

其中:  $\hat{Y}_g$  为增广矩阵中可预测空间,  $M_g$  为  $X_g$  和  $Y_g$  之间的系数矩阵,  $E_g$  为残差矩阵.

期望  $X_g$  与  $\hat{Y}_g$  相关, 而  $X_g$  与  $E_g$  完全不相干, 即存在  $\text{cov}(e_g, x_g) = 0$  关系, 基于式(8)可以得到如下关系:

$$\frac{1}{n-q+1} Y_g^T X_g = \frac{1}{n-q+1} M_g^T X_g^T X_g + E_g^T X_g \approx M_g^T \frac{X_g^T X_g}{n-q+1}. \quad (9)$$

根据式(9), 可以得到

$$M_g = (X_g^T X_g)^{\dagger} X_g^T Y_g. \quad (10)$$

将  $M_g M_g^T$  进行SVD分解得到  $P_g$  和  $\tilde{P}_g$ , 该过程采用了SVD直接分解的良好特性, 将矩阵直接分为正交的两个空间. 在获取模型参数的过程中有效避免了大量迭代, 减少了计算量.

$$M_g M_g^T = [P_g \ \tilde{P}_g] \begin{bmatrix} M_g & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} P_g^T \\ \tilde{P}_g^T \end{bmatrix}. \quad (11)$$

此时构造两个正交投影矩阵, 即

$$\begin{cases} \Pi_g = P_g P_g^T \in \text{span}\{M\}, \\ \Pi_g^\perp = \tilde{P}_g \tilde{P}_g^T \in \text{span}\{M\}^\perp. \end{cases} \quad (12)$$

将  $X_g$  向  $\text{span}\{M\}$  和  $\text{span}\{M\}^\perp$  投影, 得到两个正交子空间.

$$\begin{cases} \hat{X}_g = X_g \Pi_g, \\ \tilde{X}_g = X_g \Pi_g^\perp. \end{cases} \quad (13)$$

考虑到求解系数矩阵  $M_g$  时存在广义逆, 可能会导致  $X_g$  和  $Y_g$  相关信息的丢失, 在质量无关子空间中变量的变化会影响产品的质量空间, 因此有必要对  $\tilde{X}_g$  进一步主成分分解, 提高质量相关故障检测性能, 即

$$\tilde{X}_g = T_{g-x} P_{g-x}^T + \tilde{X}_{g-r}, \quad (14)$$

其中:  $T_{g-x}$  和  $P_{g-x}$  分别为  $\tilde{X}_g$  的得分矩阵和负载矩阵,  $\tilde{X}_{g-r}$  为残差空间.

结合上述分析, 动态EPLS算法可以得到时滞矩阵间最终关系模型

$$\begin{cases} X_g = \hat{X}_g + T_{g-x} P_{g-x}^T + \tilde{X}_{g-r}, \\ Y_g = \hat{Y}_g + E_{g-r}. \end{cases} \quad (15)$$

在线监测中, 对于新来一组测试样本  $x$ , 通过所建立的模型可以被分为3部分  $\hat{x}$ ,  $\tilde{x}_g$ ,  $x_{g-r}$ . 可以由式(16)计算D-EPLS得分.

$$\begin{cases} t_{\hat{x}} = P_g x^T, \\ t_{\tilde{x}} = P_{g-x} \tilde{x}_g^T. \end{cases} \quad (16)$$

用  $t_{\hat{x}}$  和  $t_{\tilde{x}}$  构造  $T^2$  统计量,  $x_{g-r}$  构造  $Q$  统计量<sup>[13]</sup>, 如下:

$$\hat{T}_{g-x}^2 = t_{\hat{x}}^T \left( \frac{P_g^T X_g^T X_g P_g}{n-q+1} \right)^{-1} t_{\hat{x}}, \quad (17)$$

$$\tilde{T}_{g-x}^2 = t_{\tilde{x}}^T \left( \frac{T_{g-x}^T T_{g-x}}{n-q+1} \right)^{-1} t_{\tilde{x}}, \quad (18)$$

$$Q_{g-r} = \|\tilde{x}_g\|^2 = \tilde{x}_g^T (I - P_{g-x} P_{g-x}^T) \tilde{x}_g, \quad (19)$$

其中:  $\hat{T}_{g-x}^2$  和  $\tilde{T}_{g-x}^2$  统计量服从  $F$  分布,  $Q_{g-r}$  统计量服从  $\chi^2$  分布<sup>[13]</sup>. 设计相应统计量的控制限为

$$J_{\text{th}, \hat{T}_{g-x}^2} = \frac{A(n_g^2 - 1)}{n_g(n_g - A)} F_\alpha(A, n_g - A), \quad (20)$$

$$J_{\text{th}, \tilde{T}_{g-x}^2} = \frac{(m_g - A)(n_g^2 - 1)}{n_g(n_g - m_g - A)} \times F_\alpha(m_g - A, n_g - m_g + A), \quad (21)$$

$$J_{\text{th}, Q} = \hat{g}_r \chi_{\alpha, \tilde{h}_r}^2, \quad \hat{g}_r = \frac{\tilde{S}_r}{2\tilde{\mu}_r}, \quad \tilde{h}_r = \frac{2\tilde{\mu}_r^2}{\tilde{S}_r}, \quad (22)$$

其中:  $n_g$  和  $m_g$  分别为时滞矩阵的样本个数和变量个数,  $\alpha$  为置信区间,  $\tilde{\mu}_r$  和  $\tilde{S}_r$  为  $Q_{g-r}$  统计量对应的均值和方差. D-EPLS质量相关故障检测算法具体步骤如下:

离线建模:

- 步骤 1 标准化数据矩阵  $X$  和  $Y$ ;
- 步骤 2 构造增广矩阵  $X_g$  和  $Y_g$ ;
- 步骤 3 通过式(10)计算系数矩阵  $M_g$ ;
- 步骤 4 将  $M_g M_g^T$  进行SVD分解;
- 步骤 5 构造正交空间  $\text{span}\{M_g\}$  和  $\text{span}\{M_g\}^\perp$ ;
- 步骤 6 将  $X_g$  向正交空间投影得到  $\hat{X}_g$  和  $\tilde{X}_g$ ;
- 步骤 7 对  $\tilde{X}_g$  主元分解得到  $T_{g-x}$  和  $\tilde{X}_{g-r}$ ;
- 步骤 8 计算控制限  $J_{\text{th}, \hat{T}_{g-x}^2}$ ,  $J_{\text{th}, \tilde{T}_{g-x}^2}$ ,  $J_{\text{th}, Q}$ .

在线检测:

- 步骤 9 对新样本  $x$  标准化处理;
- 步骤 10 用式(17)–(19)计算统计量;
- 步骤 11 诊断统计: 若  $\hat{T}_{g-x}^2 > J_{\text{th}, \hat{T}_{g-x}^2}$ , 故障发生

在质量相关空间; 若  $\hat{T}_{g-x}^2 \leq J_{\text{th}, \hat{T}_{g-x}^2}$ ,  $\tilde{T}_{g-x}^2 > J_{\text{th}, \tilde{T}_{g-x}^2}$ ,  $Q_{g-r} > J_{\text{th}, Q}$ , 故障发生在质量无关空间.

#### 4 数值算例和TEP实验

本节将采用两个指标: 故障检测率(fault detection rate, FDR)和故障误报率(false alarm rate, FAR)作为评价指标, 表达式如下:

$$\text{FDR} = \frac{N_{\text{err}}}{N_{\text{tfs}}} \times 100\%, \quad (23)$$

$$\text{FAR} = \frac{N_{\text{eff}}}{N_{\text{tfs}}} \times 100\%, \quad (24)$$

其中:  $N_{\text{eff}}$  和  $N_{\text{err}}$  分别表示有效报警和错误报警的数目,  $N_{\text{tfs}}$  代表故障样本的总数.

在工业过程中, 良好的故障检测效果体现在以下两方面: 1) 当检测数据是质量相关故障时, 质量相关的统计指标FDR高; 2) 当检测数据是质量无关故障

时,质量相关的统计指标FAR低.

4.1 数值仿真

通过式(25)建立初始数值模型<sup>[15]</sup>:

$$\begin{cases} t_k = a_1 t_{k-1} - a_2 t_{k-2} + t_k^*, \\ x_k = P t_k + e_k, \\ y_k = C_1 x_k + C_2 x_{k-1} + \nu_k, \end{cases} \quad (25)$$

其中:

$$a_1 = \begin{bmatrix} 0.4389 & 0.1210 & -0.0862 \\ -0.2966 & -0.0550 & 0.2274 \\ 0.4538 & -0.6573 & 0.4239 \end{bmatrix},$$

$$a_2 = \begin{bmatrix} -0.2998 & -0.1905 & -0.2669 \\ -0.0204 & -0.0550 & 0.2274 \\ 0.4538 & 0.6573 & 0.3749 \end{bmatrix},$$

$$P = \begin{bmatrix} 0.5586 & 0.2042 & 0.6370 \\ 0.2007 & 0.0492 & 0.4429 \\ 0.0874 & 0.6062 & 0.0664 \\ 0.9332 & 0.5463 & 0.3743 \\ 0.2594 & 0.0958 & 0.2491 \end{bmatrix},$$

$$C_1 = \begin{bmatrix} 0.9249 & 0.4350 \\ 0.6295 & 0.9811 \\ 0.8783 & 0.0960 \\ 0.6417 & 0.5275 \\ 0.7984 & 0.5456 \end{bmatrix}^T,$$

$$C_2 = \begin{bmatrix} 1.7198 & -0.3715 \\ 0.5835 & 1.5011 \\ 1.4236 & 0.0960 \\ 0.6417 & 0.5275 \\ 0.7984 & 0.5456 \end{bmatrix}^T, \quad t_k^* \sim N(0, 2^2 I_3),$$

$$e_k \sim N(0, 0.1^2 I_5), \quad \nu_k \sim N(0, 0.1^2 I_2).$$

在正常输入空间加入以下形式故障:

$$x_k = x_k^* + \Xi_x f_x, \quad (26)$$

其中:  $x_k^*$  为式(25)生成的正常数据,  $\Xi_x$  为故障方向,  $f_x$  为故障幅值.

为了验证本文所提算法的有效性,将正常数据中加入质量相关故障和质量无关故障数据.在  $f_x = 0$  的条件下生成500个正常数据用于建立模型,然后生成1000个测试数据用于故障检测,其中前500个数据为正常样本,后500个数据为动态状态下分别加入质量相关与质量无关方向的故障样本.根据预测误差最小化原则<sup>[21]</sup>,确定时滞矩阵个数  $q = 3$ .下面通过两个场景分别检验算法在动态模型中对质量相关数据和质量无关数据的检测性能.

**情景1** 质量相关故障,参考文献[20]设计质量相关故障方向为

$$\Xi_x = [2.0000 \quad 1.0000 \quad -3.0000 \quad 2.0000 \quad -5.0000]^T.$$

图2为对加入质量相关故障数据的仿真结果.红色虚线为统计量控制限,蓝色实线为每个采样时刻的统计量,当统计量超过控制限时表示有故障发生.由图2可知采用D-EPLS检测方法对前500个正常样本检测时,其统计量都在控制限以下,表示样本无故障发生.后500个采样时刻为加入质量相关故障后的样本数据,在质量相关空间检测时,统计量都在控制限以上,表示质量相关故障发生,能够有效报警.由此可以验证所提算法在数值仿真下对质量相关故障检测的可行性.





图2 数值仿真中D-EPLS算法对质量相关故障检测结果

Fig. 2 Quality related fault detection results of D-EPLS algorithm in numerical simulation

**情景2** 质量无关故障,参考文献[20]设计质量无关故障方向:

$$\Xi_x = [0.0054 \quad 0.3145 \quad -0.0432 \quad 0.7516 \quad -0.4440]^T.$$

图3为数值仿真模型加入质量无关故障的仿真结果.由图可知,采用D-EPLS检测方法对前500个正常样本检测时,其统计量都在控制限以下,表示样本无故障发生.当质量无关故障发生时,质量相关空间的  $\tilde{T}^2_{g,x}$  统计量几乎都在控制限以下,有较低的误报率;在质量无关空间  $\tilde{T}^2_{g-x}$  统计量从第501个采样时刻开始均超过控制限,表示能够对质量无关故障有效报警,由此验证了算法对质量无关故障有较低的误报警,并能够在质量无关空间检测到故障发生.






图 3 数值仿真中D-EPLS算法对质量无关故障检测结果

Fig. 3 Quality unrelated fault detection results of D-EPLS algorithm in numerical simulation

### 4.2 TEP实验

TEP是由美国Tennessee Eastman化学公司过程控制部门Downs和Vogel于1993年开发的一个工业过程的基准过程仿真模型<sup>[25]</sup>, 已经广泛用于评估各种过程控制和监控技术. 该过程动态模型主要由5个主要操作单元的动态模型所组成, 包括化学反应器、冷凝

器、压缩机、汽/液分离器和分离器, 具体流程由图4所示. 该过程包括12个操作变量和41个过程变量, 表1-2分别列出了变量在工业过程中的实际物理意义. 本文将选取数据集集中的11个操纵变量XMV(1-11)、22个过程变量XMEAS(1-22)和1个质量变量XMEAS(35)作为建模变量数据集. 根据预测误差最小化原则<sup>[21]</sup>, 确定时滞矩阵个数 $q = 4$ . 建模数据为500个正常样本, 在线测试数据样本数为1300, 其中测试数据前500个为正常数据, 后800个为故障数据. 根据文献[26]引入对故障数据的描述, IDV(1, 2, 5-8, 10, 12, 13)为质量相关故障数据集, IDV(3, 4, 9, 11, 14, 15)为质量无关故障数据集. 为了验证所提算法在实际过程中的检测性能, 对比了D-EPLS, EPLS<sup>[13]</sup>和Di-TPLS<sup>[19]</sup>在质量相关故障发生时的检测率以及质量无关故障发生时的误报率.

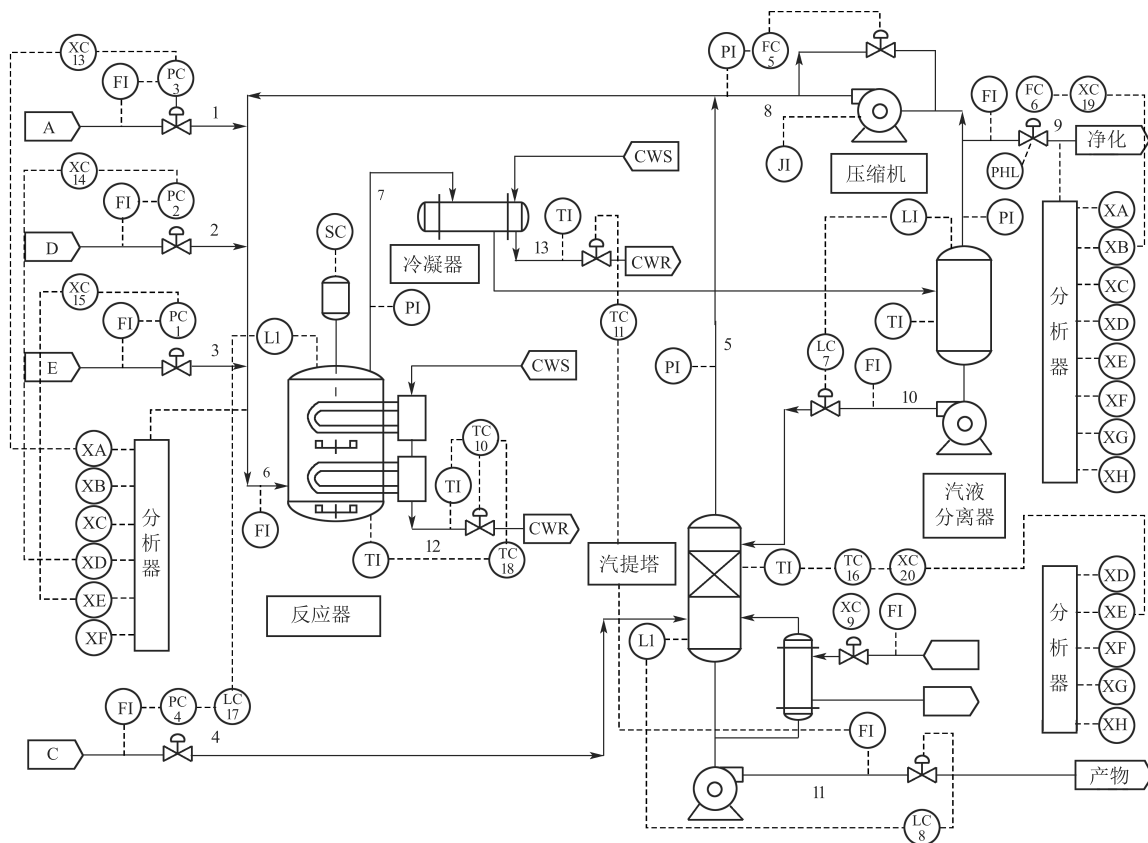


图 4 田纳西伊斯曼过程

Fig. 4 Tennessee eastman process

表 1 12个操作变量(XMV)

Table 1 12 operating variables (XMV)

编号	变量名称	编号	变量名称
1	D进料阀门位置	7	分离器液相阀门位置
2	E进料阀门位置	8	汽提塔液相阀门位置
3	A进料阀门位置	9	汽提塔蒸汽阀门位置
4	A和C蒸汽阀门位置	10	反应器冷凝水流量
5	压缩机循环阀门位置	11	冷凝器冷却水流量
6	排空阀门位置	12	搅拌器速度

为了验证D-EPLS对质量相关故障的检测能力, 给出了EPLS和D-EPLS对质量相关故障IDV(10)的监控结果, 由图5-6显示. IDV(10)是随机扰动下物料温度发生变化的故障, 该故障当前时刻的样本受到前几个时刻的影响. 故障都是在第501个时刻发生, 并一直持续到第1300个采样时刻. 良好的检测算法表现在当故障发生时能够迅速报警, 并能够持续报警, 提醒工程师及操作人员做出及时处理, 避

免重大事故的发生. 图5为EPLS对质量相关故障IDV(10)的检测结果, 由图可知质量相关空间的 $\hat{T}_{g,x}^2$ 统计量在前500个样本均在控制限以下, 但在故障发生后800个样本有较多的故障样本在控制限以下, 存在较高的漏报警, 未能持续报警. 由表3可知EPLS对IDV(10)的检测率只有46.00%, 检测效果并不理想.

表 2 41个过程变量(XMEAS)  
Table 2 41 process variables (XMEAS)

编号	变量名称	编号	变量名称
1	物料A流量	22	冷凝器冷凝水出口温度
2	物料D流量	23	物料6中A的摩尔流量
3	物料E流量	24	物料6中B的摩尔流量
4	物料A和C流量	25	物流6中C的摩尔流量
5	循环流量	26	物料6中D的摩尔流量
6	反应器进料流量	27	物料6中E的摩尔流量
7	反应器压力	28	物料6中F的摩尔流量
8	反应器液位	29	物料9中A的摩尔流量
9	反应器温度	30	物料9中B的摩尔流量
10	排空速率	31	物流9中C的摩尔流量
11	分离器温度	32	物料9中D的摩尔流量
12	分离器液位	33	物料9中E的摩尔流量
13	分离器压力	34	物料9中F的摩尔流量
14	分离器底部流量	35	物料9中G的摩尔流量
15	汽提塔液位	36	物料9中H的摩尔流量
16	汽提塔压力	37	物流11中D的摩尔流量
17	汽提塔底部流量	38	物料11中E的摩尔流量
18	汽提塔温度	39	物料11中H的摩尔流量
19	汽提塔蒸汽流量	40	物流11中G的摩尔流量
20	压缩机功率	41	物料11中H的摩尔流量
21	反应器冷凝水出口温度		




图 5 EPLS算法在TEP中对IDV(10)检测结果

Fig. 5 Detection results of EPLS algorithm to IDV(10) in TEP

图6为D-EPLS对质量相关故障IDV(10)的检测结果. IDV(10)为物料C的温度发生变化, 是典型的随时间变化的故障, 其当前值受之前时刻的影响. D-EPLS考虑了过程中的动态特征, 引入的时滞矩阵能够反映过程中的动态特性, 能够充分考虑变量的自相关性及不同变量间的互相关性. 由图可知在质量相关空间的 $\hat{T}_{g,x}^2$ 统计量在前500个样本均在控制限以下, 表示对正常样本检测时没有误报警, 后800个样本为故障发生时的样本, 通过观测统计量与控制限的比较,  $\hat{T}_{g,x}^2$ 统计量表现出较低的漏报警. 由表3可知D-EPLS算法对IDV(10)的检测率达到95.60%, 相对于静态的EPLS算法提高了49.60%, 能够对该质量相关故障发生时持续报警.




图 6 D-EPLS算法在TEP中对IDV(10)检测结果

Fig. 6 Detection results of D-EPLS algorithm to IDV(10) in TEP

表3列出了3种不同算法对TEP中质量相关故障IDV(1, 2, 5-8, 10, 12, 13)的检测率, 其中加粗数据为3种算法中检测率较高的数据, 即具有较好检测性能的数据. 由表3可知D-EPLS对TEP中质量相关故障的检测率相对于EPLS和Di-TPLS算法均得到了有效提高; 并且除IDV(7)的检测率为92.34%外, 其它质量相关故障的检测率均高于95%, 尤其对质量相关故障IDV(1, 5, 6, 12)的检测率可以达到100%. 综上数据分析, 当动态系统中质量相关故障发生时, 本文所提算法用于故障检测可以效报警.

图7为D-EPLS对TEP中质量无关故障IDV(4)检测效果图. IDV(4)是阶跃下反应器冷凝水入口温度发生变化的故障. 该故障发生时并不会影响产品质量. 工程师及操作人员对工业过程中质量相关故障发生时要求有较高的检测率, 而对质量无关故障发

生时要求有较少的误报警. 本文对提出的算法在质量无关空间的误报警状况进行了检验. 由图可知 D-EPLS 算法对质量相关空间检测时有较少的误报

警, 并由表4知其误报警率为8.91%, 而对质量无关空间检测时可以有效检测到质量无关故障发生, 这将为检验人员提供准确的故障报警信号.

表 3 TEP中质量相关故障的有效报警率(100%)  
Table 3 FDR(100%) of quality-related faults in the TEP

故障编号	已知原因的故障描述	FDR(100%)		
		EPLS	Di-TPLS	D-EPLS
IDV(1)	A/C进料流量比发生变化, 组分B含量保持不变	90.62	<b>100.00</b>	<b>100.00</b>
IDV(2)	组分B含量发生变化, A/C进料流量比保持不变	88.37	98.36	<b>98.74</b>
IDV(5)	冷凝器冷凝水入口温度发生变化	<b>100.00</b>	30.06	<b>100.00</b>
IDV(6)	物料A损失	99.12	<b>100.00</b>	<b>100.00</b>
IDV(7)	物料C压力头损失	41.12	54.09	<b>92.34</b>
IDV(8)	物料A, B和C的组成发生变化	67.87	97.11	<b>99.12</b>
IDV(10)	物料C的温度发生变化	46.00	52.83	<b>95.60</b>
IDV(12)	反应器冷凝水入口温度发生变化	84.12	99.87	<b>100.00</b>
IDV(13)	反应器中的反应程度	90.37	94.84	<b>96.86</b>




图 7 D-EPLS算法在TEP中对IDV(4)检测结果

Fig. 7 Detection results of EPLS algorithm to IDV(4) in TEP

由于质量无关故障发生时并不影响最终产品质量, 工程技术人员可以较少的关注质量无关故障, 因此质量无关故障发生时并不用报警, 这将要求算法对质量无关故障有较低的误报警. 表4列出了不同算法对质量无关故障IDV(3, 4, 9, 11, 14, 15)的误报情况, 其中加粗数据为3种算法中检测较低的数据. 由表4可知, 本文所提出的算法对质量无关故障IDV(3, 4)的误报率相对于EPLS和Di-TPLS算法有所降低, 对IDV(9, 11, 14, 15)的误报率略有提高, 但这并不影响实际工业过程中对质量相关故障的检测性能.

表 4 TEP中质量无关故障的误报警率(100%)  
Table 4 FAR(100%) of quality-unrelated faults in the TEP

故障编号	已知原因的故障描述	FAR(100%)		
		EPLS	Di-TPLS	D-EPLS
IDV(3)	物料D的进料温度发生变化	13.62	10.82	<b>7.53</b>
IDV(4)	反应器冷凝水入口温度发生变化	11.00	<b>5.91</b>	8.91
IDV(9)	物料D温度发生变化	7.50	8.93	<b>7.47</b>
IDV(11)	反应器冷凝水入口温度发生变化	<b>10.24</b>	14.09	18.71
IDV(14)	反应器冷凝水阀门	<b>9.99</b>	10.06	13.69
IDV(15)	压缩机冷凝水阀门	<b>10.50</b>	14.72	12.56

## 5 结论

本文对EPLS检测算法进行动态扩展, 提出一种基于动态高效潜结构投影(D-EPLS)算法的质量相关故障检测方法. 该方法利用ARMAX模型的矩阵形式获取数据间的动态特征, 建立增广矩阵间的关系模型, 实现对动态过程中质量相关故障的检测. 通过数值仿真和TEP实验验证了该算法的有效性; 相对于EPLS, 全面提升了EPLS算法在动态系统中质量相关故障的检测率, 扩大了EPLS算法在实际工业过程中的应用范围. 研究中发现D-EPLS对质量相关故障的检测效果较好, 但对一些质量无关故障的误报率略高, 这将是后续需要解决的难题.



## 参考文献:

- [1] YIN S, LI X, GAO H, et al. Data-based techniques focused on modern industry: an overview. *IEEE Transactions on Industrial Electronics*, 2015, 62(1): 657 – 667.
- [2] LI Yuan, LIU Yadong, ZHANG Cheng, et al. Fault detection of batch process based on diffusion  $k$ -nearest neighbors distance. *Control Theory & Applications*, 2015, 32(12): 1653 – 1659.  
(李元, 刘亚东, 张成, 等. 基于扩散 $k$ 近邻距离的间歇过程故障诊断. 控制理论与应用, 2015, 32(12): 1653 – 1659.)
- [3] CAI B, ZHAN Y, LIU H, et al. A data-driven fault diagnosis methodology in three-phase inverters for PMSM drive systems. *IEEE Transactions on Power Electronics*, 2016, 32(7): 5590 – 5600.
- [4] ZHANG Kai, QI Tianjing, PENG Kaixiang, et al. Performance evaluation for kernel parameter optimizations in fault detection methods. *Control Theory & Applications*, 2019, 36(9): 1520 – 1527.  
(张凯, 齐恬婧, 彭开香, 等. 故障检测中核参数优化方法性能评估. 控制理论与应用, 2019, 36(9): 1520 – 1527.)
- [5] ZHAO S J, ZHANG J, XU Y M. Monitoring of processes with multiple operating modes through multiple principle component analysis models. *Industrial & Engineering Chemistry Research*, 2004, 43(22): 7025 – 7035.
- [6] STUBBS S, ZHANG J, MORRIS J. Fault detection in dynamic processes using a simplified monitoring-specific CVA state space modelling approach. *Computers & Chemical Engineering*, 2012, 41(11): 77 – 87.
- [7] CHEN M, HSU C, MALHOTRA B, et al. An efficient ICA–DW–SVDD fault detection and diagnosis method for non-gaussian processes. *International Journal of Production Research*, 2016, 54(17): 5208 – 5218.
- [8] ZHONG B, WANG J, ZHOU J, et al. Quality-related statistical process monitoring method based on global and local partial least-squares projection. *Industrial & Engineering Chemistry Research*, 2016, 55(6): 1609 – 1622.
- [9] LI Yuan, MA Yuhan, ZHANG Cheng, et al. Fault detection for multimodal batch process based on the local neighborhood standardization partial least squares. *Control Theory & Applications*, 2020, 37(5): 1109 – 1117.  
(李元, 马雨含, 张诚, 等. 局部近邻标准化偏最小二乘的多模态间歇过程故障检测. 控制理论与应用, 2020, 37(5): 1109 – 1117.)
- [10] ZHOU D, LI G, QIN S J. Total projection to latent structures for process monitoring. *AiChE Journal*, 2010, 56(1): 168 – 178.
- [11] QIN S J, ZHENG Y. Quality-relevant and process-relevant fault monitoring with concurrent projection to latent structures. *AICHE Journal*, 2013, 59(2): 496 – 504.
- [12] YIN S, DING S X, ZHANG P, et al. Study on modifications of PLS approach for process monitoring. *IFAC Proceedings Volumes*, 2011, 44(1): 12389 – 12394.
- [13] PENG K X, ZHANG K, YOU B, et al. Quality-relevant fault monitoring based on efficient projection to latent structures with application to hot strip mill process. *IET Control Theory & Applications*, 2015, 9(7): 1135 – 1145.
- [14] ZHAO C H, HUANG B. A full condition monitoring method for non-stationary dynamic chemical processes with cointegration and slow feature analysis. *ALCHE Journal*, 2018, 64(5): 1662 – 1681.
- [15] ZHOU L J, ZHENG J, GE Z, et al. Multimode process monitoring based on switching autoregressive dynamic latent variable model. *IEEE Transactions on Industrial Electronics*, 2018, 65(10): 8184 – 8194.
- [16] ZHAO C H, CHEN J H, JING H. Condition-driven data analytics and monitoring for wide-range nonstationary and transient continuous processes. *IEEE Transactions on Automation Science and Engineering*, 2020, DOI: 10.1109/TASE.2020.3010536.
- [17] KU W, STORER R H, GEORGAKIS C. Disturbance detection and isolation by dynamic principal component analysis. *Chemometrics and Intelligent Laboratory Systems*, 1995, 30(1): 179 – 196.
- [18] LEE G, YOON E S. Multiple-fault diagnosis using dynamic PLS built on qualitative relations. *Computer Aided Chemical Engineering*, 2003, 14(3): 443 – 448.
- [19] LI G, LIU B, QIN S J, et al. Quality relevant data-driven modeling and monitoring of multivariate dynamic processes: The dynamic T-PLS approach. *IEEE Transactions on Neural Networks*, 2011, 22(12): 2262 – 2271.
- [20] JIAO J, YU H, WANG G. A quality-related fault detection approach based on dynamic least squares for process monitoring. *IEEE Transactions on Industrial Electronics*, 2016, 63(4): 2625 – 2632.
- [21] KONG X Y, CAO Z H, AN Q S, et al. Quality-related and process-related fault monitoring with online monitoring dynamic concurrent PLS. *IEEE Access*, 2018, 6(10): 59074 – 59086.
- [22] QIN S J, MCAVOY T J. A data-based process modeling approach and its applications. *Ifac Proceedings Volumes*, 1992, 25(5): 93 – 98.
- [23] KONG Xiangyu, CAO Zehao, AN Qiusheng, et al. Review of partial least squares linear models and their nonlinear dynamic expansion models. *Control and Decision*, 2018, 29(9): 1537 – 1548.  
(孔祥玉, 曹泽豪, 安秋生, 等. 偏最小二乘线性模型及其非线性动态扩展模型综述. 控制与决策, 2018, 29(9): 1537 – 1548.)
- [24] LI G, QIN S J, ZHOU D H. Geometric properties of partial least squares for process monitoring. *Automatica*, 2010, 46(1): 204 – 210.
- [25] LI Jiming, HAN Bing, FENG Shoubo, et al. Fault detection based on block kernel principal component analysis and support vector machine. *Control Theory & Applications*, 2020, 37(4): 847 – 854.  
(李锦冰, 韩冰, 冯守渤, 等. 基于分块核主成分分析和支持向量机的故障检测. 控制理论与应用, 2020, 37(4): 847 – 854.)
- [26] ZHAO C, SUN Y. Multispace total projection to latent structures and its application to online process monitoring. *IEEE Transactions on Control Systems and Technology*, 2014, 22(3): 868 – 883.

## 作者简介:

**孔祥玉** 教授, 博士生导师, 目前研究方向为随机系统分析、非线性系统建模及其应用、复杂系统故障诊断等研究, E-mail: xiangyukong01@163.com;

**王晓兵** 硕士研究生, 目前研究方向为复杂系统特征提取、故障检测与诊断, E-mail: ctwangxiaobing@163.com;

**罗家宇** 博士研究生, 目前研究方向为数据驱动的复杂系统下故障监测与诊断等研究, E-mail: 540629964@qq.com;

**杨治艳** 硕士研究生, 目前研究方向为特征提取和多元统计过程监控, E-mail: 1151212817@qq.com.