

动态广义主成分分析及其在故障子空间建模中的应用

冯晓伟, 许剑锋, 何川

(火箭军工程大学, 陕西 西安 710025)

摘 要: 针对传统故障子空间建模方法未考虑故障数据中同时包含正常工况信息和故障工况信息的实际情况, 或未考虑故障数据中的动态因素而导致的对故障子空间提取不够准确的问题, 提出了一种动态广义主成分分析方法。通过将带延迟的输入数据进行空间重组, 采用广义主成分分析方法提取正常工况和各故障工况之间的动态特征信息, 实现对故障子空间的准确建模, 并进一步建立故障库实现故障诊断。仿真结果表明, 所提方法能够准确提取动态过程的故障子空间, 并可用于动态工业过程的故障诊断。

关键词: 动态广义主成分分析; 故障子空间; 故障重构; 故障诊断

中图分类号: TP277

文献标志码: A

DOI: 10.11959/j.issn.1000-436x.2022091

Dynamic generalized principal component analysis with applications to fault subspace modeling

FENG Xiaofeng, XU Jianfeng, HE Chuan

The Rocket Force University of Engineering, Xi'an 710025, China

Abstract: In order to solve the problem of inaccurate modeling of fault subspace, traditional fault subspace modeling method did not consider the fact that fault data contain both normal and fault condition information, or did not consider the dynamic factors in the fault data, these flaws may lead to the case that the fault subspace cannot be extracted accurately, a dynamic generalized principal component analysis (DGPCA) method was proposed. By reorganizing the lagged input data, the dynamic characteristics between normal and fault data were extracted by the proposed DGPCA method, and then the fault subspaces could be modeled for further fault diagnosis. Finally, simulation results confirm the availability of the proposed method for fault subspace modeling and fault diagnosis.

Keywords: dynamic generalized principal component analysis, fault subspace, fault reconstruction, fault diagnosis

0 引言

大型工业设备在运行过程中的突发性故障容易造成经济损失甚至危及生命财产安全。在现代工业技术高速发展的今天, 日趋复杂的系统结构使系统的安全性和可靠性面临着前所未有的挑战, 也促使在线工业过程监控和故障诊断方法越来越受到

重视^[1-2]。

目前, 学者们针对工业过程的故障诊断技术做了大量研究, 提出了多种不同的在线故障诊断方案。基于人工神经网络的方法^[3-4]采用历史数据训练神经网络模型来实现故障定位。以主成分分析 (PCA, principal component analysis)^[5-6]和偏最小二乘 (PLS, partial least square)^[7-8]为典型代表的多元统计分析

收稿日期: 2022-01-05; 修回日期: 2022-03-27

基金项目: 国家自然科学基金资助项目 (No.61903375, No.61773389); 中国博士后科学基金资助项目 (No.2019M663635); 陕西省自然科学基金资助项目 (No.2020JQ-298); 陕西省青年科技新星基金资助项目 (No.2021KJXX-22)

Foundation Items: The National Natural Science Foundation of China (No.61903375, No.61773389), China Postdoctoral Science Foundation Project (No.2019M663635), The Natural Science Foundation of Shaanxi Province (No.2020JQ-298), The Young Science and Technology Nova of Shaanxi Province (No.2021KJXX-22)

方法通过历史数据建立主子空间和残差子空间,并在两类子空间中分别构建 T^2 和平方预测误差 (SPE, squared prediction error) 统计量来实现过程监控。在此基础上,学者们又发展了核 PCA (KPCA, kernel PCA) [9-10] 和核 PLS (KPLS, kernel PLS) [11] 等方法将数据映射到高维空间来实现非线性工业过程监控。传统方法将工业过程视为静态过程,但实际工业过程往往具有动态特性,即系统当前状态与历史状态密切相关。因此,传统静态监控方法在处理动态过程数据时容易出现较高的漏报率或误报率。许多动态多元统计方法,如递归 PCA (RPCA, recursive PCA) [12]、动态 PCA (DPCA, dynamic PCA) [13-14] 以及动态 PLS (DPLS, dynamic PLS) [15-16] 等方法相继提出,提升了动态工业过程的监测准确度。

上述方法只考虑对系统状态进行监测,即确定系统是否发生了故障。在监测到系统发生故障后,为了进一步确定故障发生的位置、类型和时间,一些故障诊断方法被相继提出。其中,故障重构方法通过分离故障数据的正常工况和故障工况实现故障诊断,在实际工业过程监控中得到了广泛应用。基于重构的贡献图法 [17] 通过分析各变量的重构贡献图,可以定位到发生故障的传感器,在较严重的故障拖尾效应下仍能表现出很好的性能。文献 [18] 提出通过对标准化的故障数据直接做奇异值分解来提取故障子空间。基于阈值的故障子空间提取方法 [19] 在系统含有加性噪声时比奇异值分解方法具有更小的重构误差。文献 [20] 通过相对变化分析来寻找故障方向,可实现多重故障重构。

基于奇异值分解的故障子空间提取方法直接针对包含正常工况和故障工况的原始数据进行分解,其不足之处是对数据特征分解不够充分,难以得到精确的故障子空间。针对传统故障子空间提取方法的不足,文献 [21] 提出了一种基于广义主成分分析 (GPCA, generalized PCA) 的故障子空间提取方法,通过剔除正常建模数据和故障建模数据之间的公共关系得到了更精确的故障子空间。针对动态工业过程的故障诊断问题,文献 [22] 提出将数据进行时移并重组到更高维度来提取动态主成分,取得了良好效果。在此研究基础上,本文提出一种动态广义主成分分析 (DGPCA, dynamic GPCA) 方法并将其运用到故障子空间建模与故障诊断中。首先,分别将正常数据和故障数据重组到高维空间,并采用 DGPCA 方法提取正常数据和故障数据之间的共

性部分,实现对原始数据动态广义主成分信息的提取;然后,剔除该共性部分得到纯故障数据,并使用该纯故障数据实现精确故障子空间提取和故障重构;最后,针对不同故障提取相应故障子空间建立故障子空间库,并基于该故障子空间库实现了在线故障诊断。所提方法实现了故障子空间提取流程的简化和精度的提升,且直接构造故障子空间库的方法降低了故障诊断的计算复杂度。

1 基于 PCA 的故障子空间重构方法

令 $X \in \mathbf{R}^{m \times l}$ 为正常工况下的采样数据集,其中 m 为变量个数, l 为样本长度。假设 X 已经过标准化处理,即 X 各维数据均值为 0,方差为 1 [23]。通过对 X 进行主成分分析,可得如下模型

$$\begin{cases} T = P^T X \\ E = X - PT = (I - PP^T)X \end{cases} \quad (1)$$

其中, $P \in \mathbf{R}^{m \times r}$ 、 $T \in \mathbf{R}^{r \times l}$ 分别为数据在主子空间的负载矩阵和得分矩阵, $I \in \mathbf{R}^{m \times m}$ 为单位矩阵, $E \in \mathbf{R}^{(m-r) \times l}$ 为数据在残差子空间的得分矩阵, r 为主子空间维数。

当获取新的采样数据 x 后,将 x 在主/次子空间内进行分解可得

$$x = \hat{x} + \tilde{x} \quad (2)$$

其中,

$$\hat{x} = PP^T x \quad (3)$$

$$\tilde{x} = (I - PP^T)x \quad (4)$$

进而可以获得相应统计量

$$T^2 = x^T P \Lambda^{-1} (x^T P)^T \quad (5)$$

$$\text{SPE} = \tilde{x}^T \tilde{x} = x^T (I - PP^T)x \quad (6)$$

其中, $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_r)$, 其对角元素由主子空间特征值 $\lambda_i (i=1, 2, \dots, r)$ 组成。显然,统计量 T^2 和 SPE 分别用于监控主子空间和残差子空间的工况。如果满足

$$T^2 \leq \chi_i^2 \quad (7)$$

$$\text{SPE} \leq \delta^2 \quad (8)$$

则认为当前工况处于正常状态,其中控制限 χ_i^2 和 δ^2 的计算方法可参考文献 [24]。

在实际工业生产过程中,可能会发生多种不同的故障,而不同故障之间存在互不相同的特征信息。通过对故障数据的深入分析,区分不同故障的

特征信息，可以实现故障诊断，即定位到具体故障及故障发生的时间。故障重构^[18,20]是一种可实现故障定位与诊断的有效手段。该方法的核心思想是，当故障发生时，将故障数据分解为正常工况部分 \mathbf{x}^* 和纯故障工况部分 \mathbf{x}^- 。显然，如果能够估计出纯故障工况部分，则可以得到正常工况数据，进而实现故障重构，即

$$\mathbf{x}^* = \mathbf{x} - \mathbf{x}^- = \mathbf{x} - \mathbf{E}\mathbf{f} \quad (9)$$

其中， \mathbf{E} 是由正交向量组成的故障子空间代表故障方向； \mathbf{f} 代表故障幅度。

如果故障子空间 \mathbf{E} 已知，那么故障重构的关键就是通过故障数据估计故障幅度 \mathbf{f} 。在主子空间，要最大限度地消除 \mathbf{x} 中故障信息的影响，故障幅度 \mathbf{f}_T 应满足^[25]

$$\begin{aligned} \mathbf{f}_T &= \arg \min \|\Lambda^{\frac{1}{2}} \mathbf{P}^T \mathbf{x}^*\|^2 = \\ & \arg \min \|\Lambda^{\frac{1}{2}} \mathbf{P}^T (\mathbf{x} - \mathbf{E}\mathbf{f})\|^2 = \\ & \arg \min \|\mathbf{P}^T (\mathbf{x} - \mathbf{E}\mathbf{f})\|^2 = \\ & (\mathbf{E}^T \mathbf{P} \mathbf{P}^T \mathbf{E})^{-1} \mathbf{E}^T \mathbf{P} \mathbf{P}^T \mathbf{x} = \\ & (\hat{\mathbf{E}}^T \hat{\mathbf{E}})^{-1} \hat{\mathbf{E}}^T \mathbf{x} \end{aligned} \quad (10)$$

其中， $\hat{\mathbf{E}} = \mathbf{P} \mathbf{P}^T \mathbf{E}$ 代表故障子空间在主子空间的投影。同理，在残差子空间，故障幅度 \mathbf{f}_S 应满足

$$\begin{aligned} \mathbf{f}_S &= \arg \min \|\tilde{\Omega} \mathbf{x}^*\|^2 = \\ & \arg \min \|\tilde{\Omega} (\mathbf{x} - \mathbf{E}\mathbf{f})\|^2 = \\ & \arg \min \|\tilde{\mathbf{x}} - \tilde{\mathbf{E}}\mathbf{f}\|^2 = \\ & (\tilde{\mathbf{E}}^T \tilde{\mathbf{E}})^{-1} \tilde{\mathbf{E}}^T \tilde{\mathbf{x}} = \\ & (\tilde{\mathbf{E}}^T \tilde{\mathbf{E}})^{-1} \tilde{\mathbf{E}}^T \mathbf{x} \end{aligned} \quad (11)$$

其中， $\tilde{\Omega} = \mathbf{I} - \mathbf{P}(\mathbf{P}^T \mathbf{P})^{-1} \mathbf{P}^T = \mathbf{I} - \mathbf{P} \mathbf{P}^T$ 为残差子空间， $\tilde{\mathbf{E}} = \tilde{\Omega} \mathbf{E}$ 为故障子空间在残差子空间的投影。

在进行故障重构后，使用重构数据重新计算 2 个统计量。如果数据被正确地重构，那么重新计算的统计量应处于控制限以下。

假设工业过程中共有 n 类故障，且故障 j ($j=1,2,\dots,n$) 的故障子空间为 \mathbf{E}_j 。已获得标准化的故障 j 的故障数据集 \mathbf{X}_j ， $\mathbf{x}(k)$ 为 \mathbf{X}_j 中第 k 个样本，即

$$\mathbf{X}_j = [\mathbf{x}(1), \mathbf{x}(2), \dots, \mathbf{x}(k)] \quad (12)$$

由式(9)可知

$$\mathbf{x}(k) = \mathbf{x}^*(k) + \mathbf{E}_j \mathbf{f}(k) \quad (13)$$

因为 $\mathbf{x}^*(k)$ 为零均值数列，如果故障幅度 $\mathbf{f}(k)$

足够大，则可以近似认为^[18]

$$\mathbf{x}(k) \approx \mathbf{E}_j \mathbf{f}(k) \quad (14)$$

从而有

$$\mathbf{X}_j = \mathbf{E}_j [\mathbf{f}(1), \mathbf{f}(2), \dots, \mathbf{f}(k)] \quad (15)$$

式(15)表明， \mathbf{E}_j 具有与 \mathbf{X}_j 相同的列空间^[18]。

于是，对数据列 \mathbf{X}_j 做奇异值分解，得

$$\mathbf{X}_j = \mathbf{U}_j \mathbf{D}_j \mathbf{V}_j^T \quad (16)$$

其中，当确定故障子空间维度 l_j 后， $\mathbf{E}_j = \mathbf{U}_j(:, 1:l_j)$ 即故障 j 的故障子空间。

2 动态广义主成分分析方法

传统静态方法在包含动态因素的工业过程监控中容易出现漏报或误报的情况，而基于 PCA 的故障重构方法因对故障分离不充分而未能对故障子空间精确建模。为此，本文提出了一种可在动态因素提取的基础上实现精确故障子空间建模的 DGPCA 方法。

假设 $\mathbf{X} \in \mathbf{R}^{m \times l}$ ， $\mathbf{Y}^{(j)} \in \mathbf{R}^{m \times l}$ 分别代表用于训练的正常样本集和故障样本集，其中 $\mathbf{Y}^{(j)}$ 代表第 j ($j=1,2,\dots,n$) 类故障的样本集。令 $\mathbf{x}_k \in \mathbf{R}^m$ ， $\mathbf{y}_k^{(j)} \in \mathbf{R}^m$ 分别代表 \mathbf{X} 和 $\mathbf{Y}^{(j)}$ 中第 k 个样本数据。为了提取样本数据中的动态信息，对样本数据重组如下^[22,26]

$$\mathbf{X}_k = \begin{bmatrix} \mathbf{x}_{k+s} & \mathbf{x}_{k+s+1} & \cdots & \mathbf{x}_{k+q+s-1} \\ \mathbf{x}_{k+s-1} & \mathbf{x}_{k+s} & \cdots & \mathbf{x}_{k+q+s-2} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{x}_{k+1} & \mathbf{x}_{k+2} & \cdots & \mathbf{x}_{k+q} \end{bmatrix} \quad (17)$$

$$\mathbf{Y}_k^{(j)} = \begin{bmatrix} \mathbf{y}_{k+s}^{(j)} & \mathbf{y}_{k+s+1}^{(j)} & \cdots & \mathbf{y}_{k+q+s-1}^{(j)} \\ \mathbf{y}_{k+s-1}^{(j)} & \mathbf{y}_{k+s}^{(j)} & \cdots & \mathbf{y}_{k+q+s-2}^{(j)} \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{y}_{k+1}^{(j)} & \mathbf{y}_{k+2}^{(j)} & \cdots & \mathbf{y}_{k+q}^{(j)} \end{bmatrix} \quad (18)$$

其中， s 为延迟量， q 为建模数据长度。

根据前面的分析，故障样本应由两部分组成，即正常工况部分和纯故障工况部分。其中，正常工况部分的特征子空间应与正常样本的特征子空间相关性最大。寻找该相关性，即寻找故障样本集 $\mathbf{Y}_0^{(j)}$ 在正常样本集 \mathbf{X}_0 中的最大投影。因此，提出如下目标函数

$$\max_{\mathbf{w}} \frac{\mathbf{w}^T \mathbf{Y}_0^{(j)} (\mathbf{Y}_0^{(j)})^T \mathbf{w}}{\mathbf{w}^T \mathbf{X}_0 \mathbf{X}_0^T \mathbf{w}} \quad (19)$$

令 $\mathbf{R}_y^{(j)} = \mathbf{Y}_0^{(j)}(\mathbf{Y}_0^{(j)})^T$, $\mathbf{R}_x = \mathbf{X}_0\mathbf{X}_0^T$, 从而式(19)可以改写为

$$\begin{aligned} & \max_{\mathbf{w}} \mathbf{w}^T \mathbf{R}_y^{(j)} \mathbf{w} \\ & \text{s.t. } \mathbf{w}^T \mathbf{R}_x \mathbf{w} = 1 \end{aligned} \quad (20)$$

为了求解目标函数的最大值, 定义拉格朗日函数

$$J = \mathbf{w}^T \mathbf{R}_y^{(j)} \mathbf{w} + \lambda(1 - \mathbf{w}^T \mathbf{R}_x \mathbf{w}) \quad (21)$$

将式(21)对 \mathbf{w} 求偏导, 并令其为 0, 得

$$\frac{\partial J}{\partial \mathbf{w}} = 2(\mathbf{R}_y^{(j)} \mathbf{w} - \lambda \mathbf{R}_x \mathbf{w}) = 0 \quad (22)$$

进而可得

$$\mathbf{R}_y^{(j)} \mathbf{w} = \lambda \mathbf{R}_x \mathbf{w} \quad (23)$$

对式(23)左乘 \mathbf{w}^T , 可得

$$J_{\max} = \lambda \quad (24)$$

上述分析表明, 要寻找的特征向量 \mathbf{w} 本质上是对应矩阵束 $(\mathbf{R}_y^{(j)}, \mathbf{R}_x)$ 最大广义特征值的广义特征向量。

进一步, 对 $(\mathbf{R}_y^{(j)}, \mathbf{R}_x)$ 做广义特征分解

$$[\mathbf{W}^{(j)}, \mathbf{A}^{(j)}] = \text{eig}(\mathbf{R}_y^{(j)}, \mathbf{R}_x) \quad (25)$$

其中, eig 表示求矩阵束 $(\mathbf{R}_y^{(j)}, \mathbf{R}_x)$ 的广义特征分解; $\mathbf{W}^{(j)}$ 表示广义特征空间, 满足

$$\begin{cases} (\mathbf{W}^{(j)})^T \mathbf{R}_y^{(j)} \mathbf{W}^{(j)} = \mathbf{A}^{(j)} \\ (\mathbf{W}^{(j)})^T \mathbf{R}_x \mathbf{W}^{(j)} = \mathbf{I}_{ms} \end{cases} \quad (26)$$

其中, $\mathbf{I}_{ms} \in \mathbf{R}^{ms \times ms}$ 为 $ms \times ms$ 单位矩阵; $\mathbf{A}^{(j)}$ 为对角阵, 其对角元素为矩阵束 $(\mathbf{R}_y^{(j)}, \mathbf{R}_x)$ 按降序排列的广义特征值。当选定主子空间维度 d_s 后, $\mathbf{W}^{(j)}$ 的前 d_s 列构成的广义主子空间 $\hat{\mathbf{W}}^{(j)}$ 代表了 \mathbf{X} 和 $\mathbf{Y}^{(j)}$ 线性关系最强的方向, 即两者的共性部分。

故障数据和正常数据的共性部分代表了故障数据中隐含的正常工况, 是影响故障子空间建模精度的直接因素。DGPCA 方法实现了动态工业过程中对故障数据和正常数据共性部分的提取, 为故障子空间的精确提取奠定了基础条件。

3 基于动态广义主成分分析的故障子空间建模

3.1 故障子空间提取

由于广义主子空间 $\hat{\mathbf{W}}^{(j)}$ 代表了 \mathbf{X} 和 $\mathbf{Y}^{(j)}$ 线性关系最强的方向, 因此, 故障数据 $\mathbf{Y}^{(j)}$ 在子空间 $\hat{\mathbf{W}}^{(j)}$ 中的投影即故障数据 $\mathbf{Y}^{(j)}$ 中所包含的正常工

况部分。利用广义主子空间将故障数据 $\mathbf{Y}^{(j)}$ 中的正常工况部分剔除, 即可得到纯故障数据 $\tilde{\mathbf{Y}}_0^{(j)}$, 即

$$\begin{aligned} \tilde{\mathbf{Y}}_0^{(j)} &= \mathbf{Y}_0^{(j)} - \hat{\mathbf{W}}^{(j)}(\hat{\mathbf{W}}^{(j)})^T \mathbf{Y}_0^{(j)} = \\ & (\mathbf{I}_{ms} - \hat{\mathbf{W}}^{(j)}(\hat{\mathbf{W}}^{(j)})^T) \mathbf{Y}_0^{(j)} \end{aligned} \quad (27)$$

显然, 对纯故障数据进行奇异值分解, 即可得到更加准确的故障子空间。对 $\tilde{\mathbf{Y}}_0^{(j)}$ 做奇异值分解, 有

$$\tilde{\mathbf{Y}}_0^{(j)} = \mathbf{U}^{(j)} \mathbf{D}^{(j)} (\mathbf{V}^{(j)})^T \quad (28)$$

当确定故障空间维度 d_d 后, $\mathbf{U}^{(j)}$ 前 d_d 个故障方向 $\mathbf{U}^{(j)}(1:d_d)$ 即故障 j 的故障子空间 $\mathbf{E}^{(j)}$ 。

在基于重构的故障诊断方法中, 精确的故障重构是有效实现故障诊断的基础。基于 DGPCA 方法实现了对故障子空间的精确提取, 为后续精确故障重构的实现提供了条件支持。

3.2 故障重构

为了判定故障重构效果, 对正常工况数据集 \mathbf{X}_0 的期望矩阵 $\mathbf{R}_0 = \mathbf{E}\{\mathbf{X}_0^T \mathbf{X}_0\}$ 做特征分解, 构建直接 DPCA 监测模型^[26], 即

$$\mathbf{R}_0 = \mathbf{U}_0 \mathbf{A}_0 \mathbf{U}_0^T \quad (29)$$

取 \mathbf{U}_0 的前 d_0 列构成主子空间 \mathbf{P}_0 , 其余部分构成次子空间, 并分别求 $\mathbf{Y}^{(j)}$ 在主/次子空间的统计量为

$$\begin{cases} (T^{(j)})^2(k) = (\mathbf{Y}_0^{(j)}(k))^T \mathbf{P}_0 \mathbf{A}_0^{-1} \mathbf{P}_0^T \mathbf{Y}_0^{(j)}(k) \\ \text{SPE}^{(j)}(k) = (\mathbf{Y}_0^{(j)}(k))^T (\mathbf{I}_{ms} - \mathbf{P}_0 \mathbf{P}_0^T) \mathbf{Y}_0^{(j)}(k) \end{cases} \quad (30)$$

相应控制限为

$$(T^{(j)})^2 \leq \chi_t^2 \quad (31)$$

$$\text{SPE}^{(j)} \leq \delta^2 \quad (32)$$

注意, 由于数据维度的扩展, 此处的 χ_t^2 和 δ^2 仍沿用式(7)和式(8)的符号, 其具体数值应不一样, 但计算方法一致。

文献[21,25]都是通过将故障数据分别投影到主子空间和残差子空间来求故障幅度, 然后分别进行故障重构。本文采用文献[18]的联合指标构建模式来计算统计量和控制限。联合统计量计算方式为

$$\begin{aligned} \phi^{(j)}(k) &= \frac{(T^{(j)})^2(k)}{\chi_t^2} + \frac{\text{SPE}^{(j)}(k)}{\delta^2} = \\ & (\mathbf{Y}_0^{(j)})^T \Phi \mathbf{Y}_0^{(j)}(k) \end{aligned} \quad (33)$$

其中, Φ 为对称正定矩阵, 有

$$\Phi = \frac{P_0 A_0^{-1} P_0^T}{\chi_i^2} + \frac{I_{ms} - P_0 P_0^T}{\delta^2} \quad (34)$$

依据文献[18]可知, 正常工业过程的联合统计量应满足

$$\varphi^{(j)}(k) \leq g \chi^2(h) \quad (35)$$

其中,

$$g = \frac{\sum v_i \lambda_i^2}{\sum v_i \lambda_i} = \frac{\text{tr}(R_0 \Phi)^2}{\text{tr}(R_0 \Phi)} \quad (36)$$

$$h = \frac{(\sum v_i \lambda_i^2)^2}{\sum v_i \lambda_i^2} = \frac{[\text{tr}(R_0 \Phi)]^2}{\text{tr}(R_0 \Phi)^2} \quad (37)$$

其中, λ_i 为矩阵 $R_0 \Phi$ 的第 i 个特征值, 其重数为 v_i 。

当获取新的待监测采样数据 \mathbf{y} 后, 根据延迟量, 联合历史数据采用式(18)将其扩展为高维数据 $\tilde{\mathbf{y}}$ 。在联合指标限定下, 其故障幅度计算式为

$$\mathbf{f}^{(j)} = ((\mathcal{E}^{(j)})^T \Phi \mathcal{E}^{(j)})^{-1} (\mathcal{E}^{(j)})^T \Phi \tilde{\mathbf{y}} = \Theta^{(j)} \tilde{\mathbf{y}} \quad (38)$$

其中,

$$\Theta^{(j)} = ((\mathcal{E}^{(j)})^T \Phi \mathcal{E}^{(j)})^{-1} (\mathcal{E}^{(j)})^T \Phi$$

进而实现故障重构

$$\tilde{\mathbf{y}}^* = \tilde{\mathbf{y}} - \mathcal{E}^{(j)} \mathbf{f}^{(j)} \quad (39)$$

显然, 如果故障数据只包含单个故障 j , 则基于故障子空间 $\mathcal{E}^{(j)}$ 采用式(39)重构后的数据, 其统计量应当处于控制限式(35)以下。反之, 则不能将故障数据重构在控制限以下。

不同类型的故障的其故障子空间互不相同, 因此可将其作为相应故障的特征信息。显然, 当且仅当故障类型与故障子空间相对应时才能成功将该故障数据重构到控制限以下。因此, 基于故障子空间的故障重构方法为故障诊断提供了决策依据。

3.3 故障重构参数的确定

只有合理选择上述延迟量 s 和几种子空间维数 d_0 、 d_s 和 d_d 等参数才能对故障子空间进行准确的提取。本节讨论几种维度参数的选择方法。

延迟量 s 代表工业过程中的动态阶数, d_0 代表工业过程中变量的非线性关系数量。两者可通过文献[22]提出的互相关分析法来确定, 如图1所示。

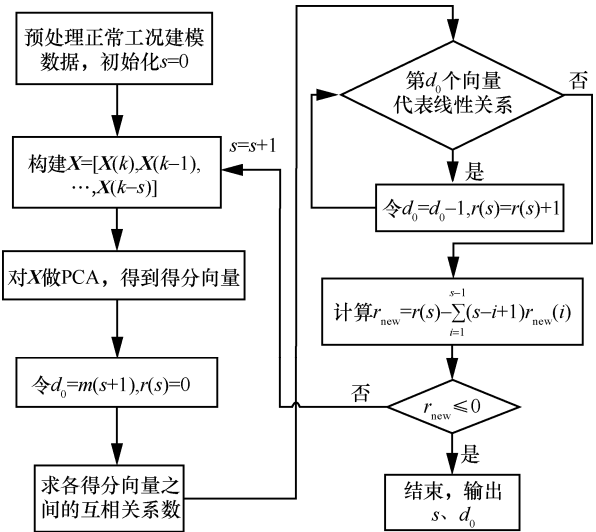


图1 s 和 d_0 计算流程

参数 d_s 为 $\hat{\mathbf{W}}^{(j)}$ 的维度, 代表故障建模数据和正常建模数据之间相关维度, 令

$$\hat{\mathbf{Y}}_0^{(j)} = \hat{\mathbf{W}}_r^{(j)} (\hat{\mathbf{W}}_r^{(j)})^T \mathbf{Y}_0^{(j)} \quad (40)$$

其中, $\hat{\mathbf{W}}^{(j)}$ 由 $\mathbf{W}(j)$ 中前 r 个列向量组成。显然, 当 $r < d_s$ 时, $\hat{\mathbf{Y}}_0^{(j)}$ 中包含部分正常工况; 当 $r > d_s$ 时, $\hat{\mathbf{Y}}_0^{(j)}$ 中包含全部正常工况和部分异常工况; 当且仅当 $r = d_s$ 时, $\hat{\mathbf{Y}}_0^{(j)}$ 包含全部正常工况而不包含异常工况。采用式(33)计算 $\hat{\mathbf{Y}}_0^{(j)}$ 的统计量, 令 ζ 为统计量超出控制限的样本数量与总样本数量的比率, 取满足 $\zeta \leq 0.5\%$ 的最大 r 为 d_s 。

为了确定故障子空间的维度, 定义 $\eta_r^{(j)}$ 为故障 j 在故障子空间维度 r 下的故障重构率, 即采用 r 维故障子空间对故障 j 重构后, 统计量低于控制限的样本数量与总样本数量的比率。取满足 $\eta_r^{(j)} \geq 99.5\%$ 的最小 r 值为故障 j 的故障子空间维度 d_d 。

4 基于动态广义主成分分析的故障诊断

在实际工业过程中, 可能发生的故障种类是多种多样的, 在检测到系统故障后, 需要进一步对故障进行定位, 即故障诊断。本文故障诊断的基本思想为, 首先通过 DGPCA 方法对所有已知故障进行故障子空间提取, 建立故障子空间库; 当发生故障后, 尝试采用故障子空间库对该故障进行重构, 通过对比重构前后统计量的变化, 即可判断出故障类型。根据同时发生的故障数量, 可将故障诊断分为单故障诊断和多故障诊断。

4.1 单故障工业过程的故障诊断

在已知的 n 类故障中，对于每一类故障，都可以基于历史故障数据提取其故障子空间，得到 $\mathcal{E}^{(1)}$, $\mathcal{E}^{(2)}$, \dots , $\mathcal{E}^{(n)}$ 。定义矩阵

$$\mathcal{E} = \begin{bmatrix} \mathcal{E}^{(1)} & & & \\ & \mathcal{E}^{(2)} & & \\ & & \ddots & \\ & & & \mathcal{E}^{(n)} \end{bmatrix} \quad (41)$$

代表 n 类故障组成的故障子空间库。当获取新的待监测采样数据 y 后，基于式(38)，采用式(18)将其扩展为高维数据 \tilde{y} ，并在故障子空间库中求其在

$$\tilde{Y}^* = \begin{bmatrix} (\tilde{y}^{(1)})^* & & & \\ & (\tilde{y}^{(2)})^* & & \\ & & \ddots & \\ & & & (\tilde{y}^{(n)})^* \end{bmatrix} = \begin{bmatrix} \tilde{y} - \mathcal{E}^{(1)}\Theta^{(1)}\tilde{y} & & & \\ & \tilde{y} - \mathcal{E}^{(2)}\Theta^{(2)}\tilde{y} & & \\ & & \ddots & \\ & & & \tilde{y} - \mathcal{E}^{(n)}\Theta^{(n)}\tilde{y} \end{bmatrix} = (\mathbf{I}_n \otimes \tilde{y}) - \mathcal{E}(\mathcal{E}^T(\mathbf{I}_n \otimes \Phi)\mathcal{E})^{-1}\mathcal{E}^T(\mathbf{I}_n \otimes \Phi\tilde{y}) \quad (43)$$

进一步可求得由故障数据在各故障子空间重构后的统计量组成的统计量向量为

$$\boldsymbol{\psi} = [\varphi^{(1)} \quad \varphi^{(2)} \quad \dots \quad \varphi^{(n)}] = \text{diag} \left[\begin{array}{c} ((\tilde{y}^{(1)})^*)^T \Phi (\tilde{y}^{(1)})^* \\ ((\tilde{y}^{(2)})^*)^T \Phi (\tilde{y}^{(2)})^* \\ \vdots \\ ((\tilde{y}^{(n)})^*)^T \Phi (\tilde{y}^{(n)})^* \end{array} \right] = \text{diag}((\tilde{Y}^*)^T(\mathbf{I}_n \otimes \Phi)\tilde{Y}^*) \quad (44)$$

其中， $\text{diag}(\cdot)$ 代表将矩阵的对角元素组合成向量。显然，如果待检测过程数据 \tilde{y} 只含有第 j 类故障，则在重构后只有 $(\tilde{y}^{(j)})^*$ 的统计量能恢复到控制限以下，而在其他故障子空间的故障重构则不能显著改变统计量，即

$$\begin{cases} \varphi^{(i)} \leq g\chi^2(h), & i = j \\ \varphi^{(i)} > g\chi^2(h), & i \neq j \end{cases} \quad (45)$$

因此，定义如下统计量变异向量

$$\boldsymbol{\psi}_c = [\varphi_c^{(1)} \quad \varphi_c^{(2)} \quad \dots \quad \varphi_c^{(n)}] = [\varphi_s - \varphi^{(1)} \quad \varphi_s - \varphi^{(2)} \quad \dots \quad \varphi_s - \varphi^{(n)}] = \mathbf{1}_n \varphi_s - \boldsymbol{\psi} \quad (46)$$

其中， $\mathbf{1}_n$ 为所有元素均为 1 的 n 维行向量， φ_s 代表故障样本数据在重构前基于式(33)求得的统计量， $\boldsymbol{\psi} = [\varphi^{(1)} \quad \varphi^{(2)} \quad \dots \quad \varphi^{(n)}]$ 。显然，只有在正确的故障子空间进行故障重构，由于重构前后的统计量的显

每一类故障中的故障幅度为

$$\mathbf{f} = \begin{bmatrix} f^{(1)} & & & \\ & f^{(2)} & & \\ & & \ddots & \\ & & & f^{(n)} \end{bmatrix} = \begin{bmatrix} \Theta^{(1)}\tilde{y} & & & \\ & \Theta^{(2)}\tilde{y} & & \\ & & \ddots & \\ & & & \Theta^{(n)}\tilde{y} \end{bmatrix} = (\mathcal{E}^T(\mathbf{I}_n \otimes \Phi)\mathcal{E})^{-1}\mathcal{E}^T(\mathbf{I}_n \otimes \Phi\tilde{y}) \quad (42)$$

然后，在故障子空间库中对 \tilde{y} 进行故障重构

著变化才能导致 $\varphi_c^{(j)}$ 显著增加，而在其他故障子空间重构的数据由于其统计量变化不显著，导致 $\varphi_c^{(j)}$ 的值近似为 0。因此，在实际故障诊断过程中，可以将 $\boldsymbol{\psi}_c$ 的各个元素作为故障指标单独绘图，实现故障诊断。 $\boldsymbol{\psi}_c$ 中对应位置的指标指示对应的故障信息。

如果系统同时发生多种故障，那么故障数据在任意单一故障子空间中都不能实现完全重构，因此重构数据的统计量不能降低到控制限以下。然而，由于在非故障子空间重构时的统计量变化较小，而在所有包含故障的子空间中重构的统计量变化仍然较显著，此时 $\boldsymbol{\psi}_c$ 中将会有多个指标出现显著变化。因此，采用指标 $\boldsymbol{\psi}_c$ 可实现多故障诊断。

讨论 1 工业过程故障诊断总体可以分为离线建模和在线监测两部分，而在线监测算法的计算复杂度因其涉及硬件执行效率而成为关注点之一。假设式(41)中矩阵 \mathcal{E} 的总列数为 p ，则式(42)的故障幅

度的计算复杂度为 $p(msn)^2 + (p+n)msnp + (ms)^2 + (n+1)p^2$; 在式(42)计算结果的基础上, 式(43)的故障重构计算复杂度为 $msnp^2$, 而式(44)的统计量向量计算复杂度为 $(ms+1)msn^3$ 。综上, 在忽略较小项后, 算法的总计算复杂度约为 $(p+n)(msn)^2$ 。

4.2 多故障工业过程的故障诊断

上述过程是针对单故障诊断分析的, 在实际工业过程中, 可能同时发生几类故障。文献[25]指出, 在发生多故障情况时, 将过程数据投影到任何一个单一故障子空间都不能实现完全重构, 而应同时投影到由相应故障类型的故障子空间组合成的联合故障子空间来进行故障重构。不难发现, 虽然此时过程数据不能在单一故障子空间完全重构, 但是只要在过程数据中所包含的故障类型的故障子空间重构时, 重构数据的统计量都会有较显著的减小, 其减小幅度相对于在非对应故障类型的故障子空间重构时的微弱减小幅度而言十分明显。因此, 可以通过式(46)所求指标向量 ψ_c 中各元素的幅度来判断过程数据所包含的故障类型, 进而在这些故障类型的联合故障子空间中进行故障重构。

假设所提取的 k 类故障的故障子空间分别为 $\mathcal{E}_1 \sim \mathcal{E}_k$, 定义如下矩阵

$$\mathcal{E}_c = [\mathcal{E}_1, \mathcal{E}_2, \dots, \mathcal{E}_k] \quad (47)$$

为当前故障的联合故障子空间, 注意此处 \mathcal{E}_c 不一定是列满秩的。为了消除各故障子空间之间的线性关系, 对 \mathcal{E}_c 做奇异值分解, 得到

$$\mathcal{E}_c = U_c \Lambda_c V_c^T \quad (48)$$

则取 U_c 的前 r 列 $U_c(:, 1:r)$ 为联合故障子空间, 仍记为 \mathcal{E}_c , 此处 r 为 Λ_c 对角线中非零元素的个数。当获取联合故障子空间后, 即可在联合故障子空间中对数据进行故障重构

$$f_c = (\mathcal{E}_c^T \Phi \mathcal{E}_c)^{-1} \mathcal{E}_c \Phi \bar{y} \quad (49)$$

$$\bar{y}^* = \bar{y} - \mathcal{E}_c f_c \quad (50)$$

另一方面, 指标 $\varphi_{c,1}, \varphi_{c,2}, \dots, \varphi_{c,k}$ 也同时用于多故障工业工程中的故障诊断。

讨论 2 已有故障库需基于已知类型故障建立, 且建立的故障库只能对已知类型的故障进行区分。在实际工业过程中, 由于实际工况的复杂性, 可能会发生未知类型的新故障。根据前面的分析

可知, 在发生新故障后, 由于未对该故障建模, 因此系统只能监测到该故障而无法区分其故障类型。针对此类情况, 可以在监测到未知类型故障后, 先给出故障报警信号并对故障数据进行采集, 在获得足够的故障数据集后, 对其进行建模并更新故障库, 即可在后续监控过程中实现对该故障的识别。

5 数值仿真实验

本节通过数值仿真实验来验证本文所提方法在故障子空间建模和故障诊断的性能。实验中对比了文献[21]所提静态广义主成分分析算法在动态工业过程中的故障重构能力。

数值仿真模型为

$$\begin{aligned} u_k &= G t_k + e_k \\ x_k &= C_1 u_k + C_2 u_{k-1} + v_k \end{aligned} \quad (51)$$

其中, $t_k \in \mathbf{R}^{2 \times 100}$ 、 $u_k \in \mathbf{R}^{5 \times 100}$ 为中间变量, t_k 代表 2 个独立的随机变量, 且服从标准正态分布; $x_k \in \mathbf{R}^{5 \times 100}$ 为传感器输出的数据点; $G \in \mathbf{R}^{5 \times 2}$ 、 $C_1, C_2 \in \mathbf{R}^{5 \times 5}$ 为建立过程状态与传感器测量的测量矩阵; $e, v \in \mathbf{R}^{5 \times 100}$ 均代表 5 个独立的高斯噪声, 均值为 0, 方差为 0.01。测量矩阵 G 、 C_1 、 C_2 均随机产生, 在本文实验中, 其值分别为

$$G = \begin{bmatrix} -0.3713 & -0.6370 \\ -0.0167 & -0.7573 \\ -0.8733 & -0.3534 \\ 0.7285 & -0.5849 \\ 0.6225 & -0.2722 \end{bmatrix} \quad (52)$$

$$C_1 = \begin{bmatrix} 1.4056 & -0.1221 & -0.4992 & -1.1096 & -1.5319 \\ 1.9434 & -0.5479 & 1.4946 & 0.1247 & 0.4570 \\ 0.6932 & -0.6965 & 0.9392 & -0.7634 & 1.1402 \\ -0.4683 & -0.4088 & -0.0111 & -0.7585 & 0.0469 \\ 0.2829 & 0.9053 & -1.3510 & 0.9974 & 2.8239 \end{bmatrix} \quad (53)$$

$$C_2 = \begin{bmatrix} -0.5875 & -0.3392 & -0.4420 & -0.3776 & -1.0502 \\ -1.3725 & 0.6965 & 0.2339 & -1.3905 & -0.8213 \\ 0.0442 & 0.5718 & -0.2925 & -0.0791 & -0.6569 \\ 1.2117 & -1.1299 & -1.5921 & 0.7259 & 0.8548 \\ 0.9808 & 0.2781 & -0.6802 & -1.2084 & 0.0175 \end{bmatrix} \quad (54)$$

对于建模的故障数据，共设置 5 种故障，分别发生在 5 个变量上，故障幅度均为 5，即

$$\mathbf{x}_k = \mathbf{x}_k^* + \mathbf{E} \mathbf{f}_k \quad (55)$$

5 种故障的故障子空间设置如表 1 所示。

表 1 建模故障数据的故障子空间设置

故障编号	故障子空间
故障 1	$\mathbf{E} = [1\ 0\ 0\ 0\ 0]^T$
故障 2	$\mathbf{E} = [0\ 1\ 0\ 0\ 0]^T$
故障 3	$\mathbf{E} = [0\ 0\ 1\ 0\ 0]^T$
故障 4	$\mathbf{E} = [0\ 0\ 0\ 1\ 0]^T$
故障 5	$\mathbf{E} = [0\ 0\ 0\ 0\ 1]^T$

对于测试的单故障数据，设置为在 30 采样点以后发生故障 2，故障幅度为 7；对于测试的多故障数据，设置为在 30 个采样点以后同时发生故障 2 和故障 5，故障幅度分别为 6、9。在本文实验中，延迟量 $s=1$ ， $d_0=2$ ，5 个故障的 d_s 均为 4，故障子空间维度 d_d 分别为 2、1、2、1、1。

故障 2 在重构前后的统计量变化如图 2 所示。图 2 中包括重构前的统计量，以及分别采用故障 2 和故障 3 的故障子空间对故障 2 进行重构的结果。仿真结果表明，重构前的数据在 30 个采样点以后统计量明显超出控制限，并在控制限以上振荡，表明系统在 30 个采样点以后出现故障。采用故障 2 的故障子空间对故障数据进行重构后，重构数据的统计量都在控制限以下，说明重构后的数据已不再包含故障信息。然而，采用故障 3 的故障子空间对故障 2 的故障数据进行重构，由于故障子空间和发生的故障类型不一致，因此重构对于数据的统计量未产生明显影响。




图 2 故障 2 在重构前后的统计量变化

图 3 所示为针对包含故障 2 和故障 5 的多故障数据在重构前后的统计量变化，图 3 中包括重构前的统计量，分别采用故障 2 和故障 5 的故障子空间以及故障 2 和故障 5 的联合故障子空间对故障数据重构的结果。仿真结果表明，对于包含故障 2 和故障 5 的多故障数据，采用故障 2 和故障 5 的故障子空间均能有效降低故障数据的统计量，但都不能将数据重构到控制限以下，采用故障 2 和故障 5 的联合故障子空间则可以有效将故障重构数据重构到控制限以下。




图 3 多故障数据（故障 2 和故障 5）数据在重构前后的统计量变化

采用文献[21]提出的广义主成分分析方法对故障 2 进行过程监控的 T^2 统计量和 SPE 统计量结果分别如图 4 和图 5 所示。通过结果可以发现，由于没有考虑动态因素的提取，传统静态广义主成分分析方法得到的统计量均处于控制限以下，即不能实现动态过程下的过程监控。显然，基于式(17)和式(18)将数据重组到高维空间后，再采用该方法即可实现动态因素的提取。在采取动态因素提取的方式后，再采用GPCA方法重新计算相应统计量，如图 6 所示。此时可以发现，重新计算的 SPE 统计量可实现对故障 2 的监测。




图 4 GPCA 算法中故障 2 的 T^2 统计量




图 5 GPCA 算法中故障 2 的 SPE 统计量




图 6 动态因素提取后, GPCA 算法中故障 2 的 SPE 统计量

采用本文方法对故障 2 的故障诊断结果如图 7 所示。从图 7 中可以看到, 在 30 个采样点后, 统计量超过控制限, 意味着此时系统发生了故障, 而故障 2 的统计量变化指标的明显增大意味着此时发生的故障为故障 2。




图 7 单故障过程 (故障 2) 的故障诊断结果

采用本文方法对包含故障 2 和故障 5 的多故障过程故障诊断结果如图 8 所示。从图 8 中可以看到, 在 30 个采样点后, 统计量超过控制限, 指示当前过程已发生故障。进一步, 故障 2 和故障 5 的统计量变化指标明显增大, 表明此时系统同时发生的是故障 2 和故障 5, 与故障预设情况一致。




图 8 多故障过程 (故障 2 和故障 5) 的故障诊断结果

6 结束语

通过动态广义主成分分析方法, 可以提取动态工业过程中正常数据和故障数据之间的公共部分, 即故障数据中的正常工况信息, 从而实现故障数据中正常工况和故障工况的分离。对获得的只包含纯故障信息的故障数据, 采用奇异值分解方法可准确提取故障子空间, 提高了故障子空间的建模精度。在实际工业过程监控中, 采用提取的故障子空间可对故障数据进行有效故障重构。进一步, 可采用已知故障数据库建立故障子空间库, 从而实现故障诊断。

参考文献:

- [1] PRAKASH O, SAMANTARAY A K, BHATTACHARYYA R. Model-based multi-component adaptive prognosis for hybrid dynamical systems[J]. Control Engineering Practice, 2018, 72: 1-18.
- [2] 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.
- [3] CHEN J, LIAO C M. Dynamic process fault monitoring based on neural network and PCA[J]. Journal of Process Control, 2002, 12(2): 277-289.
- [4] LIU L, WANG Z S, ZHANG H G. Adaptive fault-tolerant tracking control for MIMO discrete-time systems via reinforcement learning algorithm with less learning parameters[J]. IEEE Transactions on Automation Science and Engineering, 2017, 14(1): 299-313.

- [5] RATO T, REIS M, SCHMITT E, et al. A systematic comparison of PCA-based statistical process monitoring methods for high-dimensional, time-dependent processes[J]. *AIChE Journal*, 2016, 62(5): 1478-1493.
- [6] KETELAERE B D, HUBERT M, SCHMITT E. Overview of PCA-based statistical process-monitoring methods for time-dependent, high-dimensional data[J]. *Journal of Quality Technology*, 2015, 47(4): 318-335.
- [7] WANG G, YIN S. Quality-related fault detection approach based on orthogonal signal correction and modified PLS[J]. *IEEE Transactions on Industrial Informatics*, 2015, 11(2): 398-405.
- [8] 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[J]. *IET Control Theory & Applications*, 2015, 9(7): 1135-1145.
- [9] CHENG C Y, HSU C C, CHEN M C. Adaptive kernel principal component analysis (KPCA) for monitoring small disturbances of nonlinear processes[J]. *Industrial & Engineering Chemistry Research*, 2010, 49(5): 2254-2262.
- [10] JAFFEL I, TAOUALI O, HARKAT M F, et al. Kernel principal component analysis with reduced complexity for nonlinear dynamic process monitoring[J]. *The International Journal of Advanced Manufacturing Technology*, 2017, 88: 3265-3279.
- [11] MANSOURI M, NOUNOU M N, NOUNOU H N. Multiscale kernel PLS-based exponentially weighted-GLRT and its application to fault detection[J]. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2019, 3(1): 49-58.
- [12] JENG J C. Adaptive process monitoring using efficient recursive PCA and moving window PCA algorithms[J]. *Journal of the Taiwan Institute of Chemical Engineers*, 2010, 41(4): 475-481.
- [13] DONG Y N, QIN S J. A novel dynamic PCA algorithm for dynamic data modeling and process monitoring[J]. *Journal of Process Control*, 2018, 67: 1-11.
- [14] DONG Y N, QIN S J. New dynamic predictive monitoring schemes based on dynamic latent variable models[J]. *Industrial & Engineering Chemistry Research*, 2020, 59(6): 2353-2365.
- [15] DONG Y N, QIN S J. Dynamic-inner partial least squares for dynamic data modeling[J]. *IFAC-PapersOnLine*, 2015, 48(8): 117-122.
- [16] DONG Y N, QIN S J. Regression on dynamic PLS structures for supervised learning of dynamic data[J]. *Journal of Process Control*, 2018, 68: 64-72.
- [17] ALCALA C F, QIN S J. Reconstruction-based contribution for process monitoring[J]. *Automatica*, 2009, 45(7): 1593-1600.
- [18] YUE H H, QIN S J. Reconstruction-based fault identification using a combined index[J]. *Industrial & Engineering Chemistry Research*, 2001, 40(20): 4403-4414.
- [19] 宁超, 陈茂银, 周东华. 基于阈值故障子空间提取算法的多重故障重构[J]. *上海交通大学学报*, 2015, 49(6): 780-785.
NING C, CHEN M Y, ZHOU D H. Fault reconstruction for multiple failure modes based on threshold fault subspace extraction algorithm[J]. *Journal of Shanghai Jiao Tong University*, 2015, 49(6): 780-785.
- [20] ZHAO C H, GAO F R. Fault subspace selection approach combined with analysis of relative changes for reconstruction modeling and multifault diagnosis[J]. *IEEE Transactions on Control Systems Technology*, 2016, 24(3): 928-939.
- [21] 杜柏阳, 孔祥玉, 冯晓伟. 基于广义主成分分析的重构故障子空间建模方法[J]. *控制与决策*, 2021, 36(4): 808-814.
DU B Y, KONG X Y, FENG X W. Reconstructed fault subspace modelling method based on generalized principal component analysis[J]. *Control and Decision*, 2021, 36(4): 808-814.
- [22] KU W F, STORER R H, GEORGAKIS C. Disturbance detection and isolation by dynamic principal component analysis[J]. *Chemometrics and Intelligent Laboratory Systems*, 1995, 30(1): 179-196.
- [23] JACKSON J E. *A user's guide to principal components*[M]. Hoboken: John Wiley & Sons, Inc., 1991.
- [24] MACGREGOR J F, KOURTI T. Statistical process control of multivariate processes[J]. *Control Engineering Practice*, 1995, 3(3): 403-414.
- [25] ZHAO C H, GAO F R. Fault subspace selection approach combined with analysis of relative changes for reconstruction modeling and multifault diagnosis[J]. *IEEE Transactions on Control Systems Technology*, 2016, 24(3): 928-939.
- [26] LI G, QIN S J, ZHOU D H. A new method of dynamic latent-variable modeling for process monitoring[J]. *IEEE Transactions on Industrial Electronics*, 2014, 61(11): 6438-6445.


[作者简介]



冯晓伟(1986-),男,四川绵阳人,博士,火箭军工程大学讲师,主要研究方向为随机信号处理、工业过程监控技术等。



许剑锋(1977-),男,河北石家庄人,博士,火箭军工程大学副教授、硕士生导师,主要研究方向为雷达信号处理技术。



何川(1985-),男,山东莱芜人,博士,火箭军工程大学副教授、博士生导师,主要研究方向为信号处理技术。