

# 控制与决策

Control and Decision

## 基于RLANPE的工业过程故障诊断算法

牟淼, 赵小强

引用本文:

牟淼, 赵小强. 基于RLANPE的工业过程故障诊断算法[J]. *控制与决策*, 2025, 40(2): 590–598.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2023.1455>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### [基于广义主成分分析的重构故障子空间建模方法](#)

Reconstructed fault subspace modelling method based on generalized principal component analysis

*控制与决策*. 2021, 36(4): 808–814 <https://doi.org/10.13195/j.kzyjc.2019.0818>

#### [基于交叉熵的改进NPE间歇过程故障检测算法](#)

Improved NPE batch process fault detection algorithm based on cross entropy

*控制与决策*. 2021, 36(2): 411–417 <https://doi.org/10.13195/j.kzyjc.2019.0725>

#### [基于双权重多邻域保持嵌入的间歇过程故障检测](#)

Fault detection of batch process based on double weight and multiple neighborhoods preserving embedding

*控制与决策*. 2021, 36(12): 3023–3030 <https://doi.org/10.13195/j.kzyjc.2020.0659>

#### [基于多尺度特征表示的行人再识别](#)

Multi-scale feature representation for person re-identification

*控制与决策*. 2021, 36(12): 3015–3022 <https://doi.org/10.13195/j.kzyjc.2020.0952>

#### [基于核典型相关性-熵成分分析的工业过程质量监测方法](#)

A quality monitoring method for industrial process based on kernel canonical correlation-entropy component analysis

*控制与决策*. 2021, 36(12): 2999–3006 <https://doi.org/10.13195/j.kzyjc.2020.0548>

# 基于RLANPE的工业过程故障诊断算法

牟淼<sup>1</sup>, 赵小强<sup>1,2,3†</sup>

(1. 兰州理工大学 电气工程与信息工程学院, 兰州 730050; 2. 兰州理工大学 甘肃省工业过程先进控制重点实验室, 兰州 730050; 3. 兰州理工大学 国家级电气与控制工程实验教学中心, 兰州 730050)

**摘要:** 基于邻域保持嵌入(NPE)的故障诊断算法因其能够有效地提取过程数据的局部信息而被广泛应用,但是典型的NPE方法对参数选择和噪声等离群点敏感,同时忽略了过程数据的全局信息,由此提出一种基于鲁棒低秩自适应邻域保持嵌入(RLANPE)的故障诊断算法.该方法将自适应邻域嵌入、投影学习和低秩表示集成到一个框架中,在获得全局最优解的同时能有效提取数据的局部信息;进一步地,为了探索数据的全局信息并减轻异常值的影响,对RLANPE施加低秩表示约束,以增强RLANPE的特征提取能力和鲁棒性;此外,对RLANPE引入基于 $l_{2,1}$ 范数的投影约束,以从复杂的数据中选择最有判别力的特征.通过3个合成数据集验证所提方法的降维效果和结构保持能力,在田纳西伊斯曼过程中的平均故障检测率可达83.72%,相比对比算法可提高近3%.

**关键词:** 工业过程; 故障诊断; 邻域保持嵌入; 低秩表示; 流形学习

中图分类号: TP277

文献标志码: A

DOI: 10.13195/j.kzyjc.2023.1455

引用格式: 牟淼,赵小强. 基于RLANPE的工业过程故障诊断算法[J]. 控制与决策, 2025, 40(2): 590-598.

## Industrial process fault diagnosis algorithm based on RLANPE

MOU Miao<sup>1</sup>, ZHAO Xiao-qiang<sup>1,2,3†</sup>

(1. College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China; 2. Gansu Key Laboratory of Advanced Control for Industrial Processes, Lanzhou University of Technology, Lanzhou 730050, China; 3. National Experimental Teaching Center of Electrical and Control Engineering, Lanzhou University of Technology, Lanzhou 730050, China)

**Abstract:** Fault diagnosis algorithms based on neighborhood preserving embedding (NPE) have been widely used because they can effectively extract the local information of the process. However, the typical NPE method is sensitive to parameter selection and outliers, while ignoring the global information of process data. Therefore, a fault diagnosis algorithm based on robust low-rank adaptive neighborhood preserving embedding (RLANPE) is proposed. This method integrates adaptive neighborhood embedding, projection learning and low-rank representation into a framework, which can effectively extract the local information of data while obtaining global optimal solution. In order to explore the global information of the data and eliminate the influence of outliers, low-rank constraint is imposed on the RLANPE to further enhance the information extraction capability. Meanwhile, the RLANPE introduces projection constraints based on  $l_{2,1}$  norm to select the most discriminative features. The dimension reduction performance and structure preservation capability of the proposed method are verified by three synthetic data sets. The average fault detection rate in Tennessee Eastman can reach 83.72%, which is nearly 3% higher than that of the comparison algorithm.

**Keywords:** industrial process; fault diagnosis; neighborhood preserving embedding; low-rank representation; manifold learning

## 0 引言

随着工业过程的智能化和复杂性的提高,工业过程发生故障的概率越来越高,这可能造成严重的生产

事故和巨大的经济损失.为了保证工业过程的安全和产品质量的可靠性,工业过程故障诊断受到越来越多的关注<sup>[1-3]</sup>.基于多元统计的故障诊断方法因其不

收稿日期: 2023-10-17; 录用日期: 2024-05-09.

基金项目: 国家重点研发计划项目(2020YFB1713600); 国家自然科学基金项目(62263021,62163023); 甘肃省科技计划项目(21JR7RA206,21YF5GA072); 甘肃省工业过程先进控制重点实验室开放基金项目(2022KX07); 甘肃省教育厅产业支撑项目(2021CYZC-02).

责任编辑: 董久祥.

†通讯作者. E-mail: xqzhao@lut.edu.cn.

需要精确的系统模型或过程的先验知识受到了广泛关注,其主要思想是将高维数据投影到低维空间,从而保留反映过程变化的主要信息<sup>[4-5]</sup>.

典型多元统计方法包括主成分分析(PCA)、独立成分分析(ICA)、偏最小二乘法(PLS)等.随着对这些方法的深入研究,基于这些方法的变体在工业过程故障诊断中得到了广泛应用<sup>[6-8]</sup>.Jiang等<sup>[9]</sup>提出了并行主成分分析-核主成分分析(PCA-KPCA)方法,能有效检测具有线性相关和非线性相关变量的过程故障;Li等<sup>[10]</sup>提出了一种集成多个ICA模型的过程监控方法,该方法使用多个具有不同监控性能的ICA模型提高模型的泛化能力.尽管这些方法在故障诊断领域得到了广泛应用,但它们只能捕获过程数据的全局信息,而未发现的局部信息已被证明在识别数据结构中更为重要<sup>[11]</sup>,缺少这些关键信息将导致降维性能大大降低.

为了解决上述问题,学者们提出采用流形学习提取数据的局部信息.典型的流形学习方法包括拉普拉斯特征映射(LE)<sup>[12]</sup>、局部线性嵌入(LLE)<sup>[13]</sup>、邻域保持嵌入(NPE)<sup>[14]</sup>等.这些方法通过探索高维数据的局部拓扑和最近邻关系,将原始空间中的最近邻映射到低维空间中的最近邻.其中,NPE作为LLE的线性近似,因其能够成功识别过程数据的潜在局部几何结构以及出色的局部结构信息保持能力而被广泛应用于故障诊断<sup>[15-17]</sup>.尽管基于NPE的故障诊断方法取得了广泛应用,但其仍存在以下不足:1)NPE需要人工选择近邻数,近邻数太大会导致错误选择其他样本的近邻,近邻数太小会导致信息丢失.2)NPE在求解过程中,首先需要预学习原始空间中的流形信息,然后学习投影矩阵以保留低维空间中的局部信息.这个过程涉及两个优化步骤,可能导致局部最优解的产生.3)NPE对噪声等离群点很敏感,如果选择这些离群点作为近邻,则可能会严重降低降维性能.

作为一种消除异常值的有效方法,低秩表示(LRR)可以通过找到数据的最低秩表示来恢复给定数据的原始空间以提供真实的数据表示<sup>[18-20]</sup>.即使数据被异常值损坏,它仍然对被损坏的数据表现出很强的鲁棒性.此外,LRR可以很好地揭示数据的全局结构信息.近年来,LRR在图像处理等领域得到了广泛的应用<sup>[21-23]</sup>.虽然已经验证了LRR的有效性,但LRR不能直接获取投影空间,此外,LRR也不能获取数据的局部几何信息.

综上所述,本文提出一种基于鲁棒低秩自适应邻域保持嵌入(RLANPE)的工业过程故障诊断方法,主

要贡献如下:

1)与原始的NPE方法相比,RLANPE将自适应邻域图嵌入、投影学习和低秩表示集成到一个框架中,可以解决由于NPE的两步优化过程而无法获得全局最优解的问题.

2)RLANPE引入低秩表示,这不仅能弥补NPE忽略全局结构信息的不足,而且使所提出的方法对异常值更具鲁棒性.同时,通过对投影矩阵施加 $l_{2,1}$ 范数惩罚,可以学习到更加具有判别力的特征.

3)给出RLANPE的迭代求解方法,通过3个合成数据验证所提出方法的出色的结构保持和降维能力,通过田纳西伊斯曼过程验证RLANPE在工业过程故障诊断中的优越性.

## 1 基础算法

### 1.1 邻域保持嵌入算法(NPE)

NPE作为一种典型的流形学习方法,旨在通过投影矩阵在降维过程中保持数据间的局部流形结构不变,挖掘隐藏在流形结构中的局部信息.NPE的求解过程一般包括两个优化步骤,对于数据矩阵 $X = [x_1, x_2, \dots, x_n] \in n \times m$ , $n$ 是样本数, $m$ 是变量数.首先,NPE通过如下最小化等式得到重构误差:

$$\begin{aligned} \Phi(S) &= \sum_{i=1}^n \left\| x_i - \sum_{j=1}^n s_{ij} x_j \right\|_2^2; \\ \text{s.t. } & \sum_{j=1}^n s_{ij} = 1, j = 1, 2, \dots, n. \end{aligned} \quad (1)$$

其中: $x_j$ 表示 $x_i$ 的第 $j$ 个最近邻,最近邻是通过KNN( $K$ -nearest neighbor)方法获得的.得到重构误差后,可以通过对下式最小化来获得投影矩阵:

$$\begin{aligned} \Phi(P) &= \sum_{i=1}^n \left\| P^T x_i - \sum_{j=1}^n s_{ij} P^T x_j \right\|_2^2 = \\ & P^T X (I - S)^T (I - S) X^T P = \\ & P^T X L_S X^T P, \end{aligned} \quad (2)$$

其中 $L_S = (I - S)^T (I - S)$ .式(2)中的投影矩阵 $P$ 可以通过求解广义特征值问题得到.

### 1.2 低秩表示(LRR)

作为一种子空间聚类方法,LRR的主要思想是获取数据的最低秩表示,具体如下:

$$\min_Z \text{rank}(Z); \text{ s.t. } X = XZ. \quad (3)$$

其中 $Z$ 表示低秩系数矩阵.式(3)的优化问题是非凸的,为了简化计算,用核范数代替秩函数,式(3)的优化问题可以写成如下形式:

$$\min_Z \|Z\|_*; \text{ s.t. } X = XZ. \quad (4)$$

其中 $\|\cdot\|_*$ 表示核范数.然而,真实数据通常包含噪声等异常值,因此,式(4)被改写为如下形式:

$$\min_{Z,E} \|Z\|_* + \gamma \|E\|_{2,1}; \quad \text{s.t. } X = XZ + E. \quad (5)$$

其中: $E$ 表示噪声矩阵, $E_{2,1} = \sum_{j=1}^n \left( \sum_{i=1}^m e_{ij}^2 \right)^{1/2}$ .

## 2 RLANPE

### 2.1 RLANPE的目标函数

从1.1节可以看出,NPE通过两次最小化过程依次得到重构误差矩阵和投影矩阵,最终的结果可能会累积两次优化过程的误差,这可能导致NPE无法获得全局最优解.同时,NPE在使用KNN获取最近邻时,需要提前确定近邻数.目前,近邻数的取值往往依赖于人工经验,不恰当的近邻数可能会导致降维性能不佳.为了解决上述问题,首先基于NPE开发如下框架:

$$\min_{P,S} \sum_{i,j=1}^n \|P^T x_i - P^T x_j s_{ij}\|_2^2 + \alpha \|S\|_F^2; \quad \text{s.t. } \xi_i^T s_i = 0. \quad (6)$$

其中: $\xi_i = [0, 0, \dots, 1, 0, \dots, 0]$ 表示第*i*个元素为1,其他元素为0的列向量; $\xi_i^T s_i = 0$ 是为了确保 $s_{ii} = 0$ ;  $S_F = \sum_{i=1}^m \sum_{j=1}^n s_{ij}^2$ .等式(6)可以自适应地学习样本与其邻居之间的重构表示.同时,式(6)将邻域嵌入和投影学习集成到一个框架中,可以寻找NPE的全局最优解.

尽管式(6)可以通过自适应邻域嵌入避免局部信息的丢失和参数选择的困难,但它忽略了数据的全局结构信息.此外,噪声等异常值也会影响其降维性能.为了提取数据的全局结构信息,同时使得低维子空间中的训练样本具有自表达性,表示矩阵是低秩的.因此引入LRR,由式(4)可得

$$\min_{Z,P} \|Z\|_*; \quad \text{s.t. } P^T X = P^T XZ. \quad (7)$$

在实际应用中,数据经常被异常值破坏,因此,引入一个误差矩阵 $P^T X - P^T XZ$ ,等式(7)可以写为

$$\min_{Z,P,E} \|Z\|_* + \gamma \|P^T X - P^T XZ\|_{2,1}; \quad \text{s.t. } P^T X = P^T XZ + E. \quad (8)$$

结合式(6)与(8),可以得到

$$\min_{Z,P,S,E} \sum_{i,j=1}^n \|P^T x_i - P^T x_j s_{ij}\|_2^2 + \alpha \|S\|_F^2 + \beta \|Z\|_* + \gamma \|P^T X - P^T XZ\|_{2,1}; \quad \text{s.t. } \xi_i^T s_i = 0, S \geq 0, P^T X = P^T XZ + E. \quad (9)$$

等式(9)对自适应邻域保持嵌入施加了低秩约束,可以提取数据的局部和全局信息并且对异常值具有鲁棒性.考虑到并非原始数据中的所有特征都是有价值的,因此在投影矩阵 $P$ 上施加一个 $l_{2,1}$ 范数进行特征选择,使得最终得到的投影矩阵更具判别力.最终可以得到RLANPE的目标函数如下:

$$\min_{Z,P,S,E} \sum_{i,j=1}^n \|P^T x_i - P^T x_j s_{ij}\|_2^2 + \alpha \|S\|_F^2 + \beta \|Z\|_* + \gamma \|P^T X - P^T XZ\|_{2,1} + \lambda \|P\|_{2,1}; \quad \text{s.t. } \xi_i^T s_i = 0, S \geq 0, P^T X = P^T XZ + E. \quad (10)$$

### 2.2 RLANPE的求解

由于式(10)的优化问题是非凸的,将其分解为两个子问题进行求解,即:1)固定 $P$ 和 $S$ ,更新 $Z$ 和 $E$ ; 2)固定 $Z$ 和 $E$ ,更新 $P$ 和 $S$ .

#### 2.2.1 固定 $P$ 和 $S$ ,更新 $Z$ 和 $E$

采用增广的拉格朗日乘子法<sup>[24]</sup>对式(10)进行迭代求解.首先引入一个辅助变量 $U$ ,将式(10)写成

$$\min_{Z,P,S,E} \sum_{i,j=1}^n \|P^T x_i - P^T x_j s_{ij}\|_2^2 + \alpha \|S\|_F^2 + \beta \|U\|_* + \gamma \|P^T X - P^T XZ\|_{2,1} + \lambda \|P\|_{2,1}; \quad \text{s.t. } \xi_i^T s_i = 0, S \geq 0, P^T X = P^T XZ + E, Z = U. \quad (11)$$

式(11)可以被写成如下拉格朗日函数:

$$\min_{Z,P,S,E,U} \sum_{i,j=1}^n \|P^T x_i - P^T x_j s_{ij}\|_2^2 + \alpha \|S\|_F^2 + \beta \|U\|_* + \gamma \|E\|_{2,1} + \lambda \|P\|_{2,1} + \frac{\mu}{2} \left( \|P^T X - P^T XZ - E + \frac{C_1}{\mu}\|_F^2 + \left\| Z - U + \frac{C_2}{\mu} \right\|_F^2 \right). \quad (12)$$

其中: $C_1$ 和 $C_2$ 表示拉格朗日乘子, $\mu$ 表示惩罚参数.

然后对式(12)进行迭代求解,当其他变量固定,更新 $U$ 时,式(12)可以写成如下形式:

$$\min_U \beta \|U\|_* + \frac{\mu}{2} \left\| Z - U + \frac{C_2}{\mu} \right\|_F^2. \quad (13)$$

可以得到 $U = \Theta_{(\beta/\mu)} \left( Z + \frac{C_2}{\mu} \right)$ ,其中 $\Theta_{(v)}(A)$ 表示具有阈值 $v$ 的矩阵 $A$ 的奇异值阈值运算<sup>[25]</sup>.

当其他变量固定,更新 $Z$ 时,式(12)可以写成

$$\min_Z \frac{\mu}{2} \left( \left\| P^T X - P^T XZ - E + \frac{C_1}{\mu} \right\|_F^2 + \left\| Z - U + \frac{C_2}{\mu} \right\|_F^2 \right). \quad (14)$$

通过求导可得

$$Z = (X^T P P^T + I)^{-1} \left( X^T P \left( P^T X - \right. \right.$$

$$E + \frac{C_1}{\mu} - \frac{C_2}{\mu} + U). \quad (15)$$

当其他变量固定,更新  $E$  时,式(12)可以写成

$$E = \arg \min \frac{\gamma}{\mu} \|E\|_{2,1} + \frac{1}{2} \|E - (P^T X - P^T X Z + \frac{C_1}{\mu})\|_F^2. \quad (16)$$

式(16)可通过文献[26]中的引理4.1有效求解.

### 2.2.2 固定 $Z$ 和 $E$ ,更新 $P$ 和 $S$

当其他变量固定,更新  $S$  时,式(10)可以写成如下形式:

$$\begin{aligned} \min_S & \|P^T X - P^T X S\|_F^2 + \alpha \|S\|_F^2; \\ \text{s.t. } & \xi_i^T s_i = 0, S \geq 0. \end{aligned} \quad (17)$$

式(17)中描述的问题在不同的  $i$  之间是独立的,因此可以通过将其划分为  $n$  个单独的子问题来解决,即

$$\min_{\xi_i^T s_i} \|P^T x_i - P^T X s_i\|_F^2 + \alpha \|S\|_F^2. \quad (18)$$

通过拉格朗日乘子法,  $s_i$  可以通过下式求得:

$$s_i = W \left( X^T P P^T x_i - \frac{\xi_i^T W X^T P P^T x_i \xi_i}{\xi_i^T W \xi_i} \right), \quad (19)$$

其中  $W = (X^T P P^T X + \alpha I)^{-1}$ . 当其他变量固定,更新  $P$  时,式(10)可以写成如下形式:

$$\begin{aligned} \min_P & \sum_{i,j=1}^n \|P^T x_i - P^T x_j S_{ij}\|_2^2 + \\ & \gamma \|P^T X - P^T X Z\|_{2,1} + \lambda \|P\|_{2,1}. \end{aligned} \quad (20)$$

其中:  $\sum_{i,j=1}^n \|P^T x_i - P^T x_j S_{ij}\|_2^2 = 2\text{Tr}(P^T X L_S X^T P)$ ;  $\|P\|_{2,1} = \text{Tr}(P^T Q P)$ ,  $Q$  表示对角元素为  $Q_{i,i} = 1/\|P_{i,:}\|_2$  的对角矩阵;  $\|P^T X - P^T X Z\|_{2,1} = \text{Tr}(P^T (X - X Z) G (X - X Z)^T P)$ , 这里

$$G_{ii} = \frac{1}{2\| (P^T X - P^T X Z)_i \|_2 + \sigma}. \quad (21)$$

因此,式(20)可以写为

$$\begin{aligned} \min & \text{Tr}(P^T (2X L_S X^T + \\ & \gamma (X - X Z) G (X - X Z)^T + \lambda Q) P). \end{aligned} \quad (22)$$

通过对式(22)进行特征值分解,可以得到矩阵  $(2X L_S X^T + \gamma (X - X Z) G (X - X Z)^T + \lambda Q)$  的  $d$  个最小特征值对应的特征向量组成的投影矩阵  $P$ .

## 3 基于RLANPE的工业过程故障诊断

本节给出基于RLANPE的工业过程故障诊断方法流程,主要包括故障检测和故障诊断两部分.在得到投影矩阵  $P$  后,对于新的测试样本  $x_{\text{new}}$ ,可以得到它的低维表示  $y_{\text{new}} = P^T x_{\text{new}}$ . 基于此,参考NPE构建

监测统计量  $T^2$  和 SPE 的方法,得到基于RLANPE的工业过程故障诊断统计量  $T^2$  和 SPE 如下:

$$T^2 = y_{\text{new}}^T \Lambda^{-1} y_{\text{new}}, \quad (23)$$

$$\text{SPE} = \|(I - P P^T) x_{\text{new}}\|^2. \quad (24)$$

其中:  $\Lambda$  表示  $Y$  的样本协方差矩阵,  $T^2$  和 SPE 的控制限制  $T_{\text{lim}}^2$  和  $\text{SPE}_{\text{lim}}$  通过使用核密度估计求得<sup>[27]</sup>.

当检测到故障后,需要诊断故障变量,为此,采用基于多维重构的贡献(MRBC)<sup>[28]</sup>进行故障诊断.RLANPE的统计量  $T^2$  和 SPE 都具有以下对称形式:

$$\text{Index}(x) = x^T M x = \|x\|_M^2. \quad (25)$$

根据故障重构的思想,重构样本可表示为

$$x_{\text{rec}} = x - \Xi f. \quad (26)$$

其中:  $\Xi$  表示故障方向矩阵,  $f$  表示故障幅值,  $x_{\text{rec}}$  表示重构样本.则MRBC可以推导如下:

$$\begin{aligned} \text{RBC}_{\Xi}^{\text{Index}} &= \text{Index}(\Xi x) = \|\Xi x\|_M^2 = \\ & x^T M \Xi (\Xi^T M \Xi)^+ \Xi^T M x. \end{aligned} \quad (27)$$

因此,沿故障方向重构  $\text{Index}(x_{\text{rec}})$  为

$$\text{Index}(x_{\text{rec}}) = x_{\text{rec}}^T M x_{\text{rec}} = \text{Index}(x) - \text{RBC}_{\Xi}^{\text{Index}}. \quad (28)$$

## 4 仿真实验

本节首先通过3个合成数据集验证RLANPE的降维效果和结构保持能力,随后通过田纳西伊斯曼过程(TEP)验证RLANPE在工业过程故障诊断中的优越性.

### 4.1 合成数据集

本节采用3个合成数据集验证所提方法的降维效果和结构保持能力,3个数据集的三维示意图如图1(a)、图1(e)和图1(i)所示,用不同的颜色区分样本的分布,相邻样本用相似颜色标识.将所提出的RLANPE与典型的等距映射(ISOMAP)和NPE进行比较,选择ISOMAP和NPE的最近邻数为  $k = 6$ . 3种方法的降维效果如图1所示.

从图1可以看出,对于合成数据集,ISOMAP和NPE都可以在一定程度上保持数据的局部结构,即降维后的相邻样本具有相似的颜色标识.但与RLANPE相比,经过NPE降维后的数据很难反映原始数据的全局结构信息.从图1(b)和图1(j)可以看出,ISOMAP作为一种全局流形方法,可以在一定程度上反映数据的全局信息,但是对于合成数据集  $B$ , ISOMAP不能有效反映原始数据的几何信息.从图

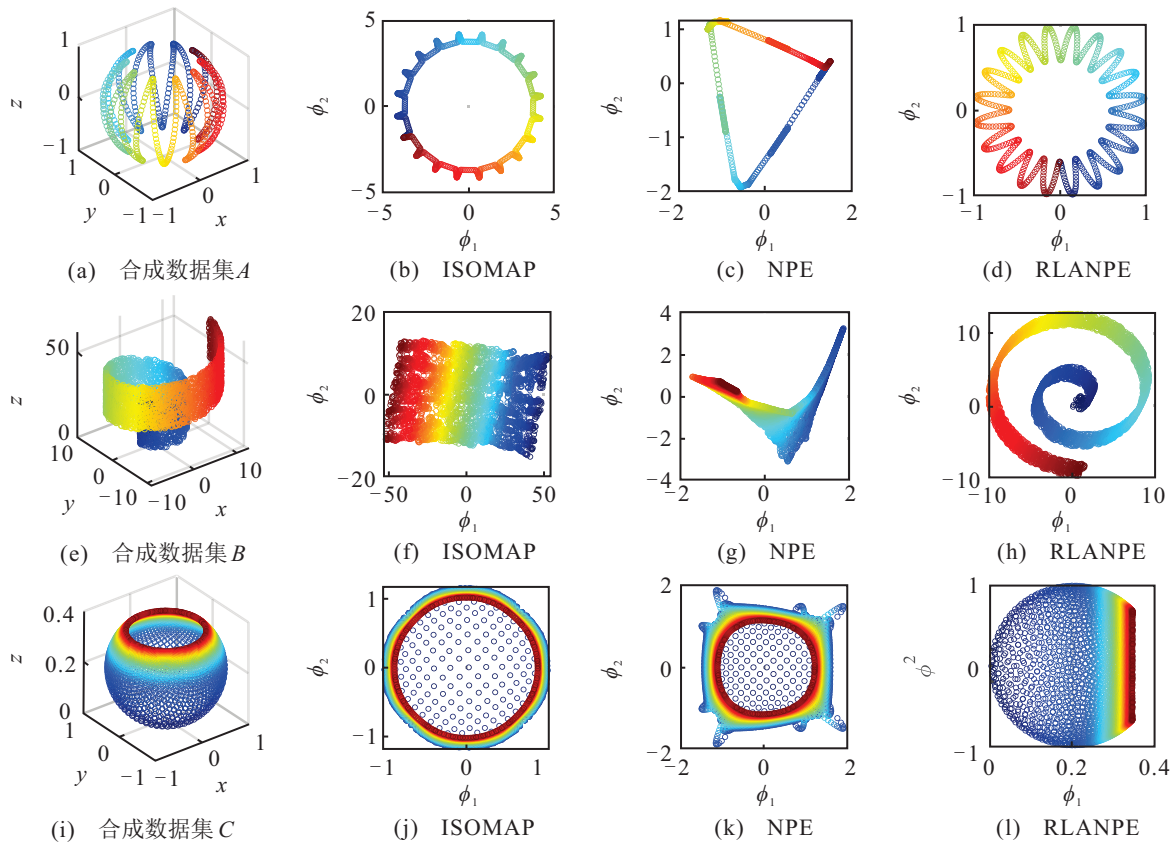


图1 ISOMAP、NPE和RLANPE在3个合成数据集集中的降维效果

1(d)、图1(h)、图1(l)可以看出,RLANPE不仅在很大程度上保持了数据的局部流形结构,而且还反映了降维后原始数据的全局信息.例如,图1(d)可以反映原始数据类似“波峰”和“波谷”的特征,图1(h)反映原始数据类似“瑞士卷”的环绕特征,图1(l)反映了原始数据的截顶球体的特征. RLANPE之所以能够取得良好的降维效果,一方面是因为RLANPE采用了自适应的邻域选择方法,可以避免因邻域选择过大或过小而导致的信息冗余或信息丢失的问题.另一方面,低秩表示的引入可以使RLANPE保持数据的全局结构,从而使降维后的数据能够反映原始数据的全局特征.

#### 4.2 田纳西伊斯曼过程(TEP)

TEP是一个以实际生产过程为背景搭建的仿真平台,作为基准流程在工业过程故障诊断领域得到了广泛应用.该过程共有11个操作变量和41个过程变量,主要包括5个转化单元、4个反应物、2个产物和1个副产物. TEP包含1组正常情况下的训练数据和21组有故障的测试数据,正常数据包含500个样本,故障数据包含960个样本,故障从第160个采样点开始.有关TEP的更多详细信息,请参阅文献[29].

选择PCA、NPE、LRPP\_GRR<sup>[21]</sup>、LRAGE<sup>[22]</sup>、GDAE<sup>[30]</sup>、和DLVM<sup>[31]</sup>六种方法与RLANPE进行比较和验证.其中:PCA是典型的全局信息提取方法,

NPE是典型的基于流形学习的局部信息提取方法,LRPP\_GRR是基于低秩表示的降维方法,GDAE是基于动态图自编码器的方法,LRAGE是基于自适应图的方法,DLVM是基于深度潜变量的方法. PCA根据累计贡献率选择主元数为31.为了使对比结果更加直观,除GDAE外其余6种方法降维后的维数均设置为31,根据经验选取NPE的近邻数为 $k = 12$ ,控制限的置信度为99%.

7种方法对TEP中21个故障的故障检测率(FDR)如表1所示.可以看出,所提出的RLANPE的故障检测能力明显优于其他6种方法.具体而言:对于IDV 16、IDV 20、IDV 21,RLANPE的FDR比其他6种方法高出7%以上;对于IDV 19,RLANPE的FDR比其他6种方法高出4%以上;对于IDV 10,RLANPE比其他6种方法高出10%以上.从表1可以看出:TEP中21个故障的RLANPE的平均FDR比其他6种方法高出3%以上;同时RLANPE的 $T^2$ 统计量的故障检测效果要高于SPE统计量,这是由于 $T^2$ 统计量通常用于检测数据整体的异常性,对全局的故障情况更为敏感,这也说明了所提方法可以有效提取过程数据的全局信息,从而提高故障检测性能.为了进一步说明所提出方法的优越性,给出IDV 16的故障监控图,如图2所示. IDV 16作为未知故障,可以非常有效地测试不同方法的故障检测能力.

表1 7种方法在TEP中的故障检测率

fault No.	PCA		NPE		LRPP_GRR		GDGE		LRAGE		DLVM	RLANPE	
	$T^2$	SPE	$T^2$	SPE	$T^2$	SPE	$T^2$	SPE	$T^2$	SPE	ODBS	$T^2$	SPE
IDV 1	99.37	99.75	100	99.62	99.87	99.75	100	100	100	99.74	99.63	100	99.39
IDV 2	98.25	98.75	98.99	98.12	99.12	98.74	98.99	98.49	99.24	98.24	98.5	99.24	98.37
IDV 3	1	2.75	11.63	4.63	14.26	22.4	6.89	12.78	16.02	15.64	1.2	12.01	16.64
IDV 4	39.5	99.62	13.51	99.74	96.99	59.44	31.82	100	93.49	85.85	99.75	100	44.8
IDV 5	25	25.75	100	27.28	100	36.42	28.44	40.72	35.79	38.79	100	100	34.79
IDV 6	99	100	100	100	100	99.62	100	100	99.74	100	100	100	100
IDV 7	100	100	77.97	100	100	100	100	100	91.99	100	100	100	99.87
IDV 8	97.25	95.12	98.24	96.99	98.24	99.37	97.99	98.99	98.62	96.49	97.63	100	99.12
IDV 9	1.75	3.12	9.7	4.5	13.51	18.52	5.13	9.39	14.64	13.64	1.2	15.43	14.64
IDV 10	39.62	46.37	80.97	29.66	82.85	61.95	48.74	81.57	62.07	52.94	68.63	91.86	56.81
IDV 11	48.87	53.37	28.53	74.59	77.09	63.57	67.66	94.98	71.83	70.08	70.63	75.08	55.94
IDV 12	98.5	96.5	100	98.49	99.87	99.37	97.99	99.62	99.24	99.12	99.75	100	99.24
IDV 13	95.12	95.12	95.61	93.61	95.99	95.49	93.98	96.61	95.74	94.36	95.38	97.74	94.49
IDV 14	100	96.62	93.24	100	100	100	100	100	100	100	99.88	100	100
IDV 15	1.87	5.5	19.14	6	17.39	22.9	11.77	19.28	21.9	15.39	1.75	28.4	20.27
IDV 16	19	43.12	73.59	19.52	87.73	54.81	30.7	81.57	54.19	50.56	72.5	94.24	45.43
IDV 17	78.37	95.5	82.1	93.99	94.99	88.11	79.57	98.37	85.73	96.74	95	98.36	86.85
IDV 18	89.25	90.25	90.36	90.36	91.23	91.48	16.66	91.47	91.23	91.61	90.13	92.23	90.61
IDV 19	6.12	14.87	10.63	22.15	77.97	11.01	27.69	86.59	16.02	52.31	63.87	90.11	8.13
IDV 20	33.87	54.5	80.85	54.19	83.98	63.57	60.52	75.43	65.2	64.33	72.5	91.86	37.29
IDV 21	36.75	51.25	64.08	37.04	55.94	39.79	60.02	47.24	61.57	47.68	53.25	71.46	45.06
平均值	57.54	65.13	68.05	64.3	80.33	67.91	60.21	77.76	70.2	70.64	75.29	83.72	64.17

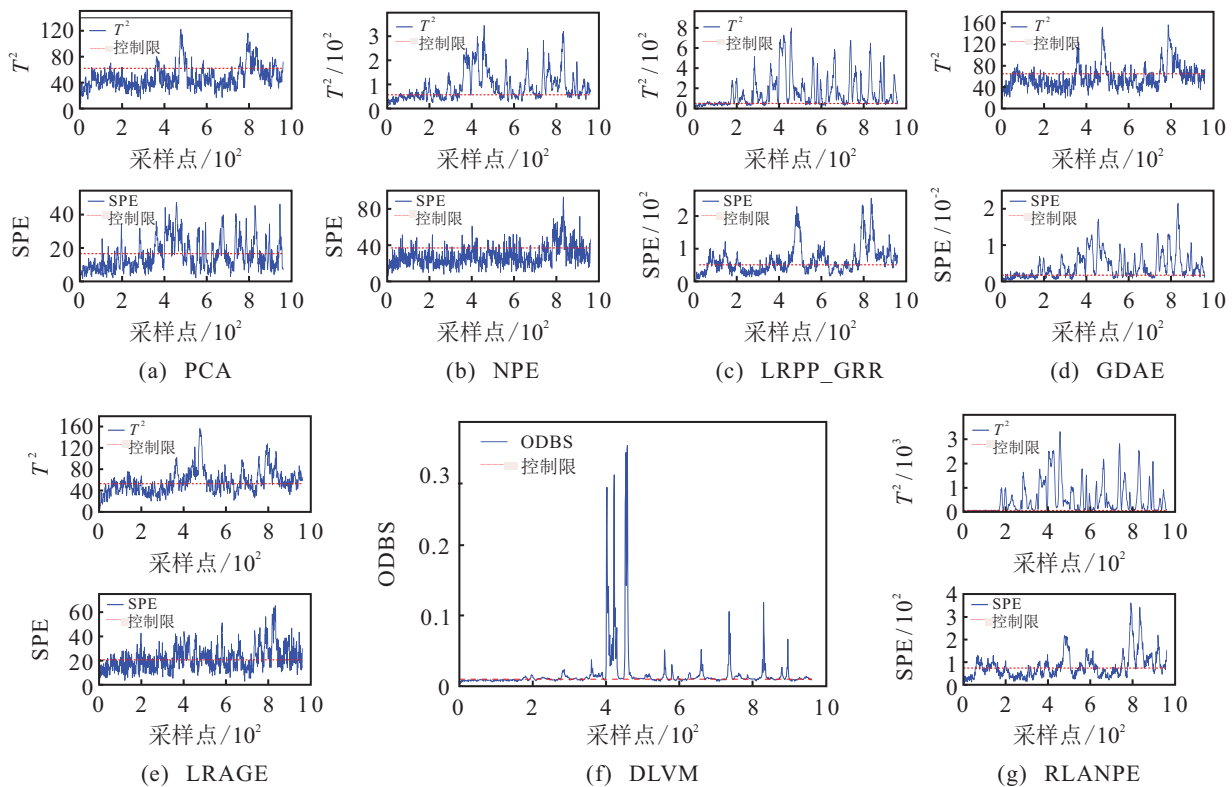


图2 7种方法对IDV 16的故障监控

图2显示了7种方法对IDV16的故障监控. 从图2(a)可以看出:PCA的 $T^2$ 统计量基本不能有效检测

故障的发生, 整个故障阶段只有少量统计量超过控制限;SPE统计量在故障阶段可以检测到部分故障

的发生,但存在大量漏报.从图2(b)可以看出:NPE的 $T^2$ 统计量检测性能优于PCA,但仍存在一定程度的误报和漏报,而SPE统计量检测失效.从图2(c)可以看出:LRPP\_GRR的 $T^2$ 统计量可以检测到故障的发生,但在正常阶段存在大量误报,LRPP\_GRR的SPE统计量同样无法有效检测故障的发生.从图2(d)可以看出:GDAE的SPE统计量检测效果要优于 $T^2$ 统计量,这是由于GDAE是基于重构的模型,SPE在残差空间中检测效果更好,但是其在正常阶段仍存在大量误报.从图2(e)可以看出:LRAGE的 $T^2$ 和SPE统计量基本都不能有效检测出故障.图2(f)为DLVM的故障监控图,采用贝叶斯推断得到的统计量ODBS可以在检测阶段有效检测出故障,但在正常阶段仍存在

大量误报.图2(g)为RLANPE的故障监控图,可以看出:虽然与LRPP\_GRR的SPE统计量类似,不能有效检测故障的发生,但其 $T^2$ 统计量在整个故障阶段基本都在控制限值之上,漏报很少,并且在正常阶段几乎没有误报,与其他6种方法相比,RLANPE的 $T^2$ 统计量具有出色的故障检测性能.

为了验证7种方法的鲁棒性,将TEP的正常训练数据随机选择5%用异常值替换.7种方法对训练样本带有5%异常值的21个故障的故障检测性能如表2所示.从表2可以看出,在训练样本有5%异常值的情况下,所提出的RLANPE仍然具有最高的故障检测率,平均故障检测率达到62.05%,相比其他先进方法高出近2%.

表2 带有5%异常值时7种方法在TEP中的故障检测率

fault No.	PCA		NPE		LRPP_GRR		GDGE		LRAGE		DLVM	RLANPE	
	$T^2$	SPE	$T^2$	SPE	$T^2$	SPE	$T^2$	SPE	$T^2$	SPE	ODBS	$T^2$	SPE
	%												
IDV 1	99.25	99.75	99.49	99.74	99.62	99.62	99.62	99.74	99.37	99.62	99.5	99.74	99.37
IDV 2	97.87	98.62	98.37	97.87	96.75	98.37	98.24	98.37	98.12	98.12	98.13	98.62	96.99
IDV 3	0	0.12	0	0	0	9.51	0	0	0	0	0	0	1.8
IDV 4	9.62	90.25	4.5	73.21	59.82	40.3	0.12	99.87	0	84.98	58.62	27.28	3.87
IDV 5	21.12	11.75	21.27	18.89	19.89	30.16	21.8	19.17	17.39	20.02	98.38	53.31	23.27
IDV 6	99.75	100	99.87	99.62	99.62	99.74	100	100	99.12	100	99.5	100	99.62
IDV 7	100	99.87	100	100	99.87	99.49	99.87	100	86.12	100	100	99.87	92.99
IDV 8	97	89	97.37	94.99	90.48	97.99	97.49	96.49	91.61	95.11	97	94.11	94.49
IDV 9	0	0.12	0	0	0	7.38	0	0	0	0.25	0	0	0.87
IDV 10	21.37	17.75	25.65	19.14	15.01	53.31	25.56	11.02	0.5	22.52	24.62	44.93	38.79
IDV 11	24.37	47	16.89	40.67	7.5	46.43	1.87	46.61	2.3	45.8	27.88	31.66	12.76
IDV 12	97.5	76.5	97.99	95.99	87.23	98.62	96.74	94.36	83.98	95.49	93.88	91.13	97.12
IDV 13	94.12	93.37	94.74	92.49	93.24	94.61	91.47	93.23	92.61	92.86	94.5	94.89	93.49
IDV 14	92.62	100	84.48	100	84.35	99.87	91.35	100	68.71	100	99.63	100	59.57
IDV 15	0	0.12	0.12	0.37	0	1.72	0	0	0	0.12	0	0	5
IDV 16	7.37	19.25	9.63	9.01	35.16	40.55	9.14	3.88	0	19.89	49.75	67.7	19.89
IDV 17	57.75	69.62	58.57	66.7	56.69	71.46	58.27	67.91	53.19	65.58	58.25	63.7	59.57
IDV 18	88.37	89.75	88.36	89.23	88.73	89.73	14.91	89.59	88.48	89.61	89.13	89.48	88.61
IDV 19	0	2.12	0.12	0.12	0	2.7	0	0.12	0	1.75	0	44.3	0
IDV 20	23.62	44.5	39.79	37.92	47.3	21.06	25.68	38.72	22.02	36.54	50.25	65.58	30.16
IDV 21	33.12	38.5	35.79	33.54	26.15	41.3	33.08	36.71	26.15	33.79	39.13	36.79	29.91
平均值	50.7	56.56	51.09	55.69	52.73	59.23	45.96	56.94	44.27	57.24	60.86	62.05	49.91

为了测试所提方法的故障诊断能力,选择已知故障IDV 1进行诊断,故障诊断结果如图3所示.

IDV1是流4中A/C进料流量比的阶跃变化,即反馈控制器增大进料A的流量阀开度(变量44,缩写为V44),这会导致A的流量(V1)增加.V44和V1发生变化,直到达到新的稳定状态.此过程还会影响其他变量以不同方式发生变化,例如变量V4/V18/V50也达到新的稳定值,而变量V7/V16/V38振荡后恢复

到原来的值<sup>[32]</sup>.图3充分描述了整个过程的变化,首先V1和V44发生故障,即图3中V1和V44对应的颜色在采样点161处开始变化,一直持续到整个过程结束.V4/V18/V50也因为故障改变了不同的值,而V7/V16/V38在故障一段时间后又恢复到原来的值,即图3中V7/V16/V38对应的颜色在一段故障后逐渐消失,这表明所提出的方法能够充分诊断过程的故障变化.




图3 IDV 1的故障诊断结果

进一步地,为了说明所提方法是如何通过提取数据的全局和局部信息以及利用低秩表示提高故障检测能力,表3给出所提方法的消融实验. 其中:NPE表示只包含局部信息提取能力的方法,ANPE表示只包含自适应邻域的方法,RLNPE表示只包含低秩表示约束的方法,RLANPE表示同时包含自适应邻域及低秩表示约束的方法,表3给出了4种方法在TEP中对21种故障的平均故障检测率. 可以看出,NPE的平均故障检测率最低,这是由于NPE只关注过程数据的局部信息,其两步优化求解可能会带来误差累积,同时噪声等异常点也会对其故障检测性能造成影响. 相比于NPE,ANPE的故障检测能力有所提升,这是由于其解决了NPE两步优化求解造成的误差累积,但由于忽略了全局信息,ANPE的故障检测能力仍不能达到最优. RLNPE是在NPE的基础上为其目标函数添加了低秩表示约束,低秩表示的低秩特性可以有效提取过程数据的全局信息,进一步提高NPE的故障检测能力. 而所提的RLANPE方法故障检测性能最佳,这是因为RLANPE同时考虑了NPE优化求解中的误差累积、忽略全局信息导致的信息丢失以及噪声等异常点对NPE选取近邻的影响,有效提高了故障检测性能.

表3 所提方法的消融实验

methods	$T^2$	SPE
NPE	68.05	64.3
ANPE	73.2	64.21
RLNPE	80.01	62.28
RLANPE	83.72	64.17

## 5 结论

针对NPE用于工业过程故障诊断时对参数选择和异常值敏感、无法获得全局最优解、无法保持全局结构等问题,本文提出了一种鲁棒低秩自适应邻域保留嵌入(RLANPE)方法. 自适应邻域选择可以有

效避免信息冗余或信息提取不充分的问题,同时,将邻域嵌入和投影学习集成到同一框架中可以确保RLANPE获得全局最优解. 此外,RLANPE中引入了低秩约束,对异常值具有更强的鲁棒性,可以有效提取过程数据的全局信息. 最后,对投影矩阵施加 $l_{2,1}$ 约束,可以确保获得更具辨别力的特征. 3个合成数据集和田纳西伊斯曼过程验证了所提方法的优越性. 虽然RLANPE已被验证具有良好的故障诊断性能,但其平衡参数的选择仍依赖于人工经验,未来如何自适应地选择平衡参数将有待进一步探索.

## 参考文献(References)

- [1] 刘强, 柴天佑, 秦泗钊, 等. 基于数据和知识的工业过程监视及故障诊断综述[J]. 控制与决策, 2010, 25(6): 801-807.  
(Liu Q, Chai T Y, Qin S Z, et al. Progress of data-driven and knowledge-driven process monitoring and fault diagnosis for industry process[J]. Control and Decision, 2010, 25(6): 801-807.)
- [2] 任浩, 屈剑锋, 柴毅, 等. 深度学习在故障诊断领域中的研究现状与挑战[J]. 控制与决策, 2017, 32(8): 1345-1358.  
(Ren H, Qu J F, Chai Y, et al. Deep learning for fault diagnosis: The state of the art and challenge[J]. Control and Decision, 2017, 32(8): 1345-1358.)
- [3] 彭开香, 马亮, 张凯. 复杂工业过程质量相关的故障检测与诊断技术综述[J]. 自动化学报, 2017, 43(3): 349-365.  
(Peng K X, Ma L, Zhang K. Review of quality-related fault detection and diagnosis techniques for complex industrial processes[J]. Acta Automatica Sinica, 2017, 43(3): 349-365.)
- [4] Zhang K, Hao H Y, Chen Z W, et al. A comparison and evaluation of key performance indicator-based multivariate statistics process monitoring approaches[J]. Journal of Process Control, 2015, 33: 112-126.
- [5] Wang Y Q, Si Y B, Huang B, et al. Survey on the theoretical research and engineering applications of multivariate statistics process monitoring algorithms: 2008-2017[J]. The Canadian Journal of Chemical Engineering, 2018, 96(10): 2073-2085.
- [6] Xiao B, Li Y G, Sun B, et al. Decentralized PCA modeling based on relevance and redundancy variable selection and its application to large-scale dynamic process monitoring[J]. Process Safety and Environmental Protection, 2021, 151: 85-100.
- [7] 孔祥玉, 杨治艳, 刘佑民, 等. 基于独立成分分析及其扩展模型的工业过程监测方法综述[J]. 控制与决策, 2022, 37(4): 799-814.

- (Kong X Y, Yang Z Y, Liu Y M, et al. Overview of industrial process monitoring methods based on independent component analysis and its extended model[J]. *Control and Decision*, 2022, 37(4): 799-814.)
- [8] Botre C, Mansouri M, Nounou M, et al. Kernel PLS-based GLRT method for fault detection of chemical processes[J]. *Journal of Loss Prevention in the Process Industries*, 2016, 43: 212-224.
- [9] Jiang Q C, Yan X F. Parallel PCA-KPCA for nonlinear process monitoring[J]. *Control Engineering Practice*, 2018, 80: 17-25.
- [10] Li Z C, Yan X F. Fault-relevant optimal ensemble ICA model for non-Gaussian process monitoring[J]. *IEEE Transactions on Control Systems Technology*, 2020, 28(6): 2581-2590.
- [11] Liu X W, Wang L, Zhang J, et al. Global and local structure preservation for feature selection[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2014, 25(6): 1083-1095.
- [12] Belkin M, Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation[J]. *Neural Computation*, 2003, 15(6): 1373-1396.
- [13] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding[J]. *Science*, 2000, 290(5500): 2323-2326.
- [14] He X F, Cai D, Yan S C, et al. Neighborhood preserving embedding[C]. *Tenth IEEE International Conference on Computer Vision (ICCV'05)*. Beijing, 2005: 1208-1213.
- [15] Tong C D, Lan T, Shi X H, et al. Statistical process monitoring based on nonlocal and multiple neighborhoods preserving embedding model[J]. *Journal of Process Control*, 2018, 65: 34-40.
- [16] Chen X X, Tong C D, Lan T, et al. Dynamic process monitoring based on orthogonal dynamic inner neighborhood preserving embedding model[J]. *Chemometrics and Intelligent Laboratory Systems*, 2019, 193: 103812.
- [17] Yu J B, Zhang C Y. Manifold regularized stacked autoencoders-based feature learning for fault detection in industrial processes[J]. *Journal of Process Control*, 2020, 92: 119-136.
- [18] Liu G, Lin Z, Yan S, et al. Robust recovery of subspace structures by low-rank representation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(1): 171-184.
- [19] Xiao S, Tan M, Xu D, et al. Robust kernel low-rank representation[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2016, 27(11): 2268-2281.
- [20] Mou M, Zhao X Q. Incipient fault detection and diagnosis of nonlinear industrial process with missing data[J]. *Journal of the Taiwan Institute of Chemical Engineers*, 2022, 132: 104115.
- [21] Wen J, Han N, Fang X, et al. Low-rank preserving projection via graph regularized reconstruction[J]. *IEEE Transactions on Cybernetics*, 2019, 49(4): 1279-1291.
- [22] Lu J L, Wang H L, Zhou J, et al. Low-rank adaptive graph embedding for unsupervised feature extraction[J]. *Pattern Recognition*, 2021, 113: 107758.
- [23] Wen J, Fang X Z, Xu Y, et al. Low-rank representation with adaptive graph regularization[J]. *Neural Networks*, 2018, 108: 83-96.
- [24] Lin Z C, Chen M M, Ma Y. The augmented lagrange multiplier method for exact recovery of corrupted low-rank matrices[J/OL]. 2010, arXiv: 1009.5055.
- [25] Cai J F, Candès E J, Shen Z W. A singular value thresholding algorithm for matrix completion[J]. *SIAM Journal on Optimization*, 2010, 20(4): 1956-1982.
- [26] Chen J, Mao H, Sang Y S, et al. Subspace clustering using a symmetric low-rank representation[J]. *Knowledge-Based Systems*, 2017, 127: 46-57.
- [27] Lee J M, Yoo C, Lee I B. Statistical process monitoring with multivariate exponentially weighted moving average and independent component analysis[J]. *Journal of Chemical Engineering of Japan*, 2003, 36(5): 563-577.
- [28] Li G, Qin S J, Yuan T. Data-driven root cause diagnosis of faults in process industries[J]. *Chemometrics and Intelligent Laboratory Systems*, 2016, 159: 1-11.
- [29] Bathelt A, Ricker N L, Jelali M. Revision of the Tennessee Eastman process model[J]. *IFAC-PapersOnLine*, 2015, 48(8): 309-314.
- [30] Liu L, Zhao H T, Hu Z W. Graph dynamic autoencoder for fault detection[J]. *Chemical Engineering Science*, 2022, 254: 117637.
- [31] Kong X Y, Ge Z Q. Deep learning of latent variable models for industrial process monitoring[J]. *IEEE Transactions on Industrial Informatics*, 2022, 18(10): 6778-6788.
- [32] Liu J L, Liu S J, Wong D S H. Process fault diagnosis based on Bayesian inference[M]. *Computer Aided Chemical Engineering*. Amsterdam: Elsevier, 2013: 751-756.

## 作者简介

牟淼(1997-),男,博士生,主要研究方向为工业过程故障检测与诊断、软测量, E-mail: m\_miao7@163.com;

赵小强(1969-),男,教授,博士生导师,主要研究方向为故障诊断、图像处理、数据挖掘, E-mail: qxzhao@lut.edu.cn.