

# 基于数据变化率和重构贡献图的微小故障诊断方法

赵凯阳, 张家良

(西安工业大学 电子信息工程学院, 西安 710021)

**摘要:** 针对复杂工业过程的微小故障诊断问题, 提出一种数据预处理与重构贡献图相结合的故障诊断方法; 为了克服非高斯分布数据对故障检测准确性的影响, 通过基于数据变化率的方法对样本原始数据进行预处理后, 可以有效地检测过程变量的微小故障, 以此建立故障诊断主元分析模型; 检测出系统故障后, 为了提高故障辨识准确度, 采用一种平均残差差值重构贡献图的方法对故障进行辨识; 通过正常样本数据和故障数据在残差子空间中的投影, 获取两个数值的残差差值向量, 计算重构贡献值来确定故障变量; 以田纳西-伊斯曼 (TE) 过程为对象进行了故障诊断仿真实验, 并与传统贡献图和重构贡献图方法的辨识准确率相比较, 结果表明所提方法具有良好的故障诊断性能。

**关键词:** 主元分析; 故障诊断; 贡献图; 田纳西-伊斯曼过程; 数据变化率

## Incipient Fault Diagnosis Method Based on Data Change Rate and Reconstruction Contribution Map

ZHAO Kaiyang, ZHANG Jialiang

(School of Electronic Information Engineering, Xi'an Technological University, Xi'an 710021, China)

**Abstract:** A fault diagnosis method is proposed for tiny faults in complex industrial processes, which combines data preprocessing with reconstruction contribution mapping. In order to overcome the impact of non-Gaussian distribution data on fault detection accuracy, the original data of process variables is effectively detected by preprocessing the samples based on data change rate, thus establishing a fault diagnosis principal component analysis model. In order to improve the accuracy of fault identification after the system fault detection, a method of reconstructing contribution mapping of average residual difference is used to identify the fault. Two residual difference value values are obtained by projecting the normal sample data and fault data in the residual subspace, and the reconstruction contribution value is calculated to determine the fault variable. Fault diagnosis simulation experiments are conducted by taking the Tennessee Eastman (TE) process as a object, and the identification accuracy is compared with traditional contribution mapping and reconstruction contribution mapping methods. The results show that the proposed method has a good fault diagnosis performance.

**Keywords:** principal component analysis; fault diagnosis; contribution plot; Tennessee Eastman process; data change rate

## 0 引言

随着科学技术飞速发展, 工业系统的复杂性和现代化水平日渐提高, 过程监控和故障诊断在增强系统稳定性和保障系统正常运行等方面显得越来越重要。现有的故障诊断方法分为定性分析和定量分析两大类型。定量分析故障诊断方法主要包括基于解析模型的方法和数据驱动方法。由于集散控制系统 (DCS, distributed control system) 在工业过程中的广泛使用, 使得基于数据驱动的主元分析故障诊断方法成为故障诊断领域的研究热点<sup>[1-2]</sup>, 微小故障较显著性故障相比更难被检测到, 微小故障具有幅值波动低、故障特征不明显、容易被噪声和扰动覆盖等特点<sup>[3-4]</sup>, 故障长期小幅度的偏离正常运行状态, 经长时间积累, 最终危

机系统的安全运行, 因此及时检测出系统存在的微小故障对工业生产至关重要, 本文针对微小故障诊断难的问题, 提出一种基于数据变化率和重构贡献图的微小故障检测方法。

主元分析 (PCA, principal component analysis) 是一种广泛应用于过程监控和故障诊断领域的的数据驱动方法。PCA 方法对过程变量进行线性变换, 将原数据空间分解为主元子空间和残差子空间, 分别使用和 SPE 统计量在两个子空间中对样本进行过程监测<sup>[5]</sup>。文献 [6] 利用主元分析的故障诊断方法, 对核电站的冷却系统进行故障检测, 通过与实际的数据进行分析, 证明了方法的可用性。文献 [7] 利用主元分析方法对压水堆进行故障检测, 利用 T<sup>2</sup>

收稿日期: 2023-01-19; 修回日期: 2023-02-28。

基金项目: 陕西省自然科学基金基础研究计划项目 (2023-JC-YB-579)。

作者简介: 赵凯阳 (1998-), 男, 硕士研究生。

通讯作者: 张家良 (1982-), 男, 博士, 讲师, 硕士生导师。

引用格式: 赵凯阳, 张家良. 基于数据变化率和重构贡献图的微小故障诊断方法[J]. 计算机测量与控制, 2023, 31(12): 14-20.

和 SPE 两个统计量通过判断是否超出阈值来检测系统状态, 根据故障特征实现对不同故障的辨识, 证明了方法的有效性。文献 [8] 利用 SPE 均值和 SPE 贡献均值作为故障检测的指标, 通过对变压器运行时产生故障进行检测, 可以准确的识别出变电所发生的异常故障。文献 [9] 利用主元分析法对水下机器人进行故障检测, 通过对系统变量的协方差矩阵进行特征值分解来进行故障检测, 实验结果验证了该方法的可行性和有效性。文献 [10] 使用基于主元分析的 SPE 统计量作为故障检测的指标, 通过工程和实验数据对方法进行验证, 结果表明该方法可以有效地预测出故障检测结果。文献 [11] 将主元分析法用于高炉故障检测, 通过现场的历史数据与方法结果进行对比, 该方法的故障报警时间早于故障发生时间, 证明了方法的可行性。传统 PCA 对数据进行预处理的方法仅在数据样本测量变量符合或近似符合高斯分布时选取的主元才具有代表性, 否则会导致错误选取主元或因为主元选取不合理降低方法结果的准确性。为解决这一问题, 一些学者提出了一些改进方法。文献 [12] 通过 Gap 度量的预处理方法, 对数据集进行转换, 反映出不同变量在高维空间的关联性。文献 [13] 提出一种基于数据自适应分区的方法, 将特征空间分解为几个子特征空间, 提高了故障检测的效果。文献 [14] 通过定义一种新的故障敏感系数来作为选取主元的排序准则, 通过分块的思想选择出每个变量方向上最敏感的主元, 并利用贝叶斯准则对结果进行融合, 提高故障检测的准确性。文献 [15] 提出一种变量加权型算法, 使得处理后的数据能够充分体现变量间相关性的差异, 通过贝叶斯准则将多组结果融合为一组概率指标进行故障检测。文献 [16] 提出利用加权差分的主元分析方法消除原始数据的多模态和非线性特征, 降低计算的复杂度。文献 [17] 利用故障检测覆盖率的概念提出了新的故障检测指标和故障识别指标, 覆盖率最大时对应的主元个数确定为最优主元个数。文献 [18] 针对传统 PCA 方法故障检测率较低的问题, 提出了一种基于 K 近邻 (KNN, k-nearest-neighbor) 的主元差分故障检测方法, 利用数据样本的 K 近邻向量得到的得分矩阵与原数据集的得分矩阵之间的差值构造新的得分矩阵, 提高故障检测的准确性。文献 [19] 将深度学习思想与主元分析思想相结合, 将数据先扩维后降维, 使原本数据空间的信息充分表达。文献 [20] 提出一种主元子空间富信息重构的方法, 通过计算各主元方向上  $T^2$  统计量的变化率, 选取变化较为明显的主元重构主元子空间。文献 [21] 提出了一种基于数据变化率的主元分析故障检测方法, 可以有效检测系统故障, 但文中只对故障检测问题进行了研究, 未涉及到如何解决故障辨识的问题。

检测出故障后, 还需要对系统进行故障辨识, 以确定系统发生何种故障。故障辨识方法的准确性对实际工业生产至关重要。文献 [22] 对 5 种辨识方法进行分析和概括, 总结出通用方法, 并提出一种新的相对贡献形式的故障辨

识方法。文献 [23] 通过随机分配故障传感器和故障量级, 提出了一种基于数据关联的故障辨识方法。文献 [24] 通过断层重建方法估计断层的大小, 提出一种通过故障方向来提高识别精度的故障隔离方法。文献 [25] 基于潜在结构的总投影模型用于检测输出相关的故障, 提出一种广义的重构贡献辨识方法。文献 [26] 定义了一种平均残差差值重构贡献图, 用于检测早期故障, 解决了传统贡献图方法对早期故障的不敏感问题, 并且减小了传统贡献图方法的故障模糊效应问题。

针对工业过程的微小故障诊断问题, 提出一种基于数据预处理方法与平均残差差值重构贡献图相结合的主元分析故障诊断方法。采用一种以训练样本各变量均值为中心的基于数据变化率的方法对原始数据进行预处理。通过正常的工业过程数据, 建立故障诊断主元分析模型。当检测出故障后, 根据正常状态和故障状态下在残差空间中的向量, 计算出残差差值向量, 利用平均残差差值重构贡献图方法对故障进行辨识。为了验证提出方法的有效性, 使用 TE 过程进行故障诊断仿真实验。

## 1 数据变化率的预处理方法

对于实际的工业系统, 假设  $x(k) \in R^m$ ,  $k=1, 2, 3, \dots$ ,  $n$  表示系统中第  $k$  个传感器的  $m$  个独立采样值。 $\mathbf{X}$  表示包含了  $n$  个传感器的测量样本, 每个传感器各含有  $m$  个独立采样值的数据矩阵空间, 其中矩阵的行向量代表一个样本, 列向量代表传感器的观测变量, 则多维数据矩阵空间  $\mathbf{X} \in R^{m \times n}$  如式 (1) 所示:

$$\mathbf{X} = \begin{bmatrix} x_1(1) & x_1(2) & \cdots & x_1(n) \\ x_2(1) & x_2(2) & \cdots & x_2(n) \\ x_3(1) & x_3(2) & \cdots & x_3(n) \\ \vdots & \vdots & \ddots & \vdots \\ x_m(1) & x_m(2) & \cdots & x_m(n) \end{bmatrix} \quad (1)$$

传统的 PCA 诊断过程对数据进行预处理的方法是将  $\mathbf{X}$  的每一列减去对应变量的均值并除以对应变量的标准差, 处理之后  $\mathbf{X}$  的各列变为均值为零, 单位方差的变量。但是该方法具有一定的局限性, 只有当原始数据的分布符合或近似符合高斯分布时, 经过标准化处理的数据才能得到较为理想的故障诊断结果, 否则会导致选取的系统主元难以具有代表性, 进而影响故障的诊断结果, 由数据变化率的方向看待变量数值  $1 \sim 2$  与  $100 \sim 101$  的变化, 虽然变化数值相同, 但是相对变化率相差 100 倍, 因此在微小故障检测中, 将数据变化率作为检测指标是很有必要的。

针对上述微小故障检测难的问题, 本文采用以变量样本的均值为中心的基于数据变化率 (ROC, rate of change) 的预处理方法, 处理过程表达出每个原始数据偏离数据中心的程度, 数据处理的变化方法如式 (2) 所示:

$$x^*(k) = \frac{x_i(k) - \mu(k)}{\mu(k)} \quad (2)$$

其中:  $x^*(k)$  为处理后的矩阵数值,  $\mu(k) =$

$\frac{\sum_{i=1}^m x_i(k)}{m}$  为数据矩阵中第  $k$  列的均值。对系统正常运行

状态下得到的数据矩阵  $\mathbf{X}$  进行预处理可得：

$$\mathbf{X}^* = \begin{bmatrix} x_1(1)^* & x_1(2)^* & \cdots & x_1(n)^* \\ x_2(1)^* & x_2(2)^* & \cdots & x_2(n)^* \\ x_3(1)^* & x_3(2)^* & \cdots & x_3(n)^* \\ \vdots & \vdots & \ddots & \vdots \\ x_m(1)^* & x_m(2)^* & \cdots & x_m(n)^* \end{bmatrix} \quad (3)$$

## 2 基于平均残差差值贡献图的故障辨识

数据经过预处理后，可以通过式 (4) 求得样本  $\mathbf{X}$  的协方差矩阵  $\mathbf{S}$ ：

$$\mathbf{S} = cov(x) \approx \frac{1}{n-1} \mathbf{X}^T \mathbf{X} \quad (4)$$

对  $\mathbf{S}$  进行特征值分解，得到矩阵的特征值  $\lambda_i$  和特征向量，将特征值由大到小排序组成特征值对角矩阵，由主元累计贡献率  $CPV$  确定主元的数目。

$$CPV = \frac{\sum_{i=1}^A \lambda_i}{\sum_{i=1}^n \lambda_i} \quad (5)$$

$CPV$  达到 85% 以上时，就认为当前的主元个数  $A$  已经包含了原始数据中足够多的信息。主元数目  $A$  确定后，即可确定负载矩阵  $\mathbf{P} \in R^{m \times A}$ ，由  $\mathbf{S}$  的前  $A$  个特征向量构成，以及得分矩阵  $\mathbf{T} \in R^{m \times A}$ ，可以由式 (6) 求解得到：

$$\mathbf{T} = \mathbf{X}\mathbf{P} \quad (6)$$

故障检测使用平方预测误差  $SPE$  统计量来检测过程是否发生异常。 $SPE$  指标衡量样本向量在残差空间投影的变化

$$SPE = |(\mathbf{I} - \mathbf{P}\mathbf{P}^T)x| \leq \delta_\alpha^2 \quad (7)$$

其中： $\delta_\alpha^2$  表示置信水平为  $\alpha$  时的控制限。当  $SPE$  位于控制限内时，认为过程处于正常状态。控制限的计算公式为

$$\delta_\alpha^2 = \theta_1 \left( \frac{c_\alpha \sqrt{2\theta_2 h_0^2}}{\theta_1} + 1 + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1^2} \right)^{1/h_0} \quad (8)$$

其中： $\theta_1$  和  $h_0$  分别由式 (9) 和式 (10) 确定：

$$\theta_1 = \sum_{j=A+1}^m \lambda_j^i \quad (i = 1, 2, 3) \quad (9)$$

$$h_0 = 1 - 2\theta_1 \theta_3 / 3\theta_2^2 \quad (10)$$

系统运行检测到故障后，找出故障发生的根源所在对于工业过程来说显得尤为重要，样本数据  $x$  经过 PCA 分解后可以分别投影到主元子空间和残差子空间中，投影到残差子空间的表达式为：

$$\tilde{x} = (\mathbf{I} - \mathbf{P}\mathbf{P}^T)x = \tilde{\mathbf{C}}x \quad (11)$$

其中： $\mathbf{I}$  单位矩阵， $\mathbf{P}$  为训练集数据的负载矩阵， $\tilde{\mathbf{C}}$  为投影到残差子空间的投影矩阵。

$$\tilde{\mathbf{C}} = \begin{bmatrix} \tilde{c}_{11} & \cdots & \tilde{c}_{1n} \\ \vdots & \ddots & \vdots \\ \tilde{c}_{n1} & \cdots & \tilde{c}_{nm} \end{bmatrix} \quad (12)$$

基于  $SPE$  的贡献图定义如下：

$$SPE = \|\tilde{\mathbf{C}}x\|^2 = \sum_{i=1}^m Cont_i^{SPE} \quad (13)$$

其中： $Cont_i^{SPE} = (\xi_i^T \tilde{\mathbf{C}}x)^2$ ，表示每个变量对  $SPE$  统计量的贡献值， $\xi_i$  表示单位矩阵  $\mathbf{I}$  的第  $i$  列，当系统发生故障时，故障样本数据  $x_f$  可以表示为：

$$x_f = x_n + f_i \xi_i \quad (14)$$

其中： $x_n$  表示正常数据， $f_i$  表示在  $\xi_i$  方向的故障幅值。

传统贡献图方法能够顺利检测出故障发生所处的传感器位置，必须满足所有可能的正常值必须小于  $SPE$  统计量的控制限，否则在故障诊断的过程中，许多系统发生的微小故障有可能发生漏检、错检的情况。为克服传统贡献图方法对微小故障辨识难的问题，并且降低传感器偏移故障对诊断结果的影响，本文采用平均残差差值重构贡献图法进行故障辨识，该方法利用残差空间中正常数据与故障数据求解差值向量，通过差值向量产生新的贡献图，通过采样时间内贡献值的均值减少随机噪声对辨识结果的影响，因此针对微小故障可以有效提高辨识微小故障的性能。平均残差差值重构贡献图方法中的贡献值计算公式为：

$$\|\tilde{x}_n - \tilde{x}_f\|^2 = \sum_{i=1}^n \Delta x \tilde{x}_i^2 = \sum_{i=1}^n z_i \quad (15)$$

其中： $\tilde{x}_n$  和  $\tilde{x}_f$  分别为  $x_n$  和  $x_f$  在残差子空间中的投影， $z_i$  为  $x_f$  时刻第  $i$  个变量的贡献值，为消除噪声对故障识别的干扰，取采样时间段内贡献值的均值，

$$\bar{z}_i = \frac{1}{l} \sum_{j=1}^l z_{i,j} \quad (16)$$

$$\bar{c}_i = \frac{\bar{z}_i}{c_{ii}} \quad (17)$$

$z_{i,j}$  为第  $j$  采样时的第  $i$  个变量的贡献值， $l$  是采样窗口的时间大小， $\bar{c}_{ii}$  为残差子空间投影矩阵  $\tilde{\mathbf{C}}$  的主对角线元素的数值， $\bar{c}_i$  为第  $i$  个变量的最终平均残差贡献值。

## 3 基于数据变化和贡献图的故障诊断步骤

基于主元分析的故障诊断分为模型建立和在线故障诊断两个部分。模型建立过程中，首先通过数据预处理方法对正常情况下的训练集数据进行处理，对处理后的数据矩阵通过 PCA 变换和特征值分解得到训练集的负载矩阵和得分矩阵，通过累计方差贡献率方法确定主元数目，在残差子空间中计算数据的  $SPE$  统计量和控制限。模型建立流程如图 1 所示。

主元分析故障诊断模型建立步骤为：

- 1) 导入系统正常运行状态下得到的训练数据。
- 2) 应用式 (2) 通过数据变化率的方法对训练集数据  $\mathbf{X}$  进行预处理得到变化后的数据矩阵  $\mathbf{X}^*$ 。
- 3) 对数据矩阵  $\mathbf{X}^*$  进行 PCA 变换，根据式 (4) 计算协方差矩阵，对其进行特征值分解，并按照特征值从大到小的顺序排列。
- 4) 由式 (5) 使用累计方差贡献率方法计算出系统的主元数目  $A$ 。
- 5) 由步骤 4) 得到的主元数目  $A$ ，根据特征向量即可



为避免故障辨识结果的偶然性，本实验过程采用 160 组正常数据建立主元分析故障诊断模型，计算使系统稳定运行的控制限，对每种故障分别采用 800 组故障数据进行故障诊断测试，通过与控制限的比较来判定系统是否出现故障。

在故障识别过程中，分别使用 PCA 方法、KNN-PCA 方法和本文方法（ROC 方法）对故障进行辨识。在 ROC 方法检测出故障发生的基础上，分别使用传统贡献图法、重构贡献图法和平均残差差值重构贡献图法进行故障识别，故障 1~3 的检测及辨识结果如图 4~9 所示。

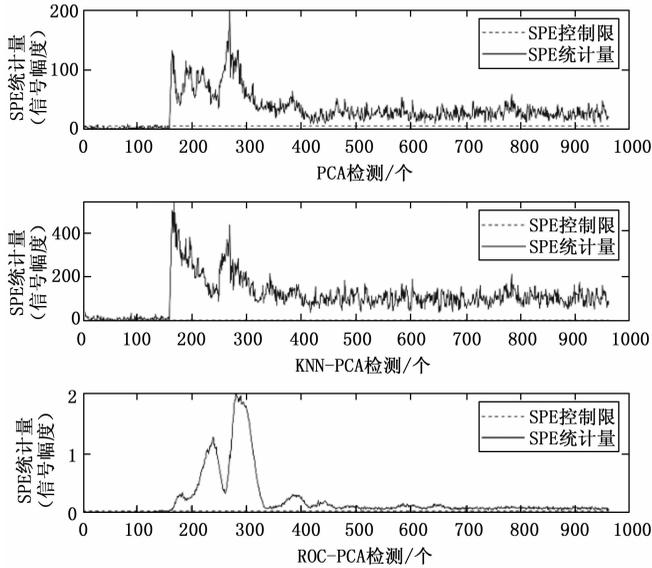


图 4 故障 1 检测结果

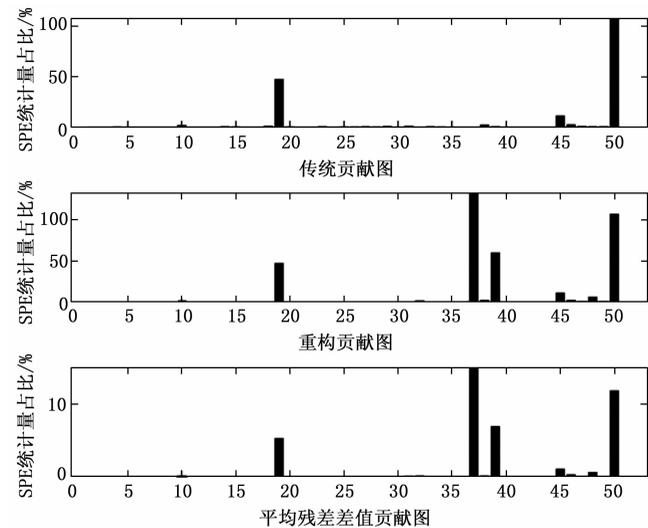


图 5 故障 1 辨识结果

故障点在第 161 组数据后引入，通过图 4、图 6 和图 8 得出，对正常故障 1 进行检测时，三种方法检测准确率都较好，但当系统发生微小故障时，传统 PCA 方法和 KNN 方法对正常数据进行检测时出现了误判情况，在检测故障 2

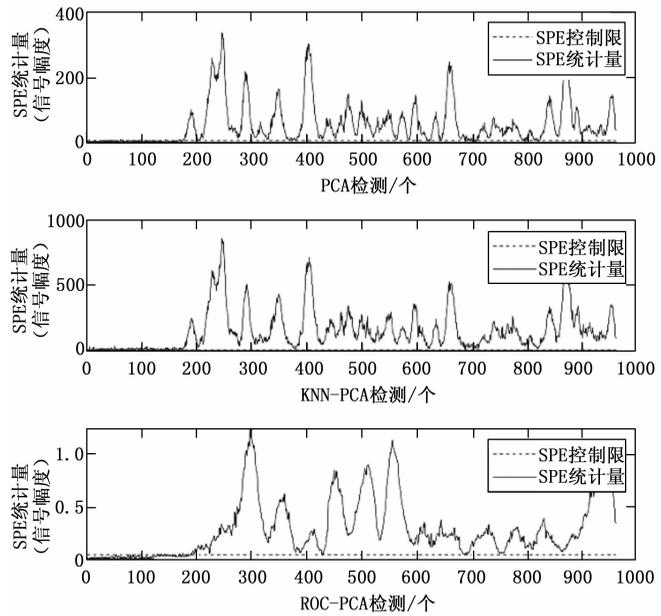


图 6 故障 2 检测结果

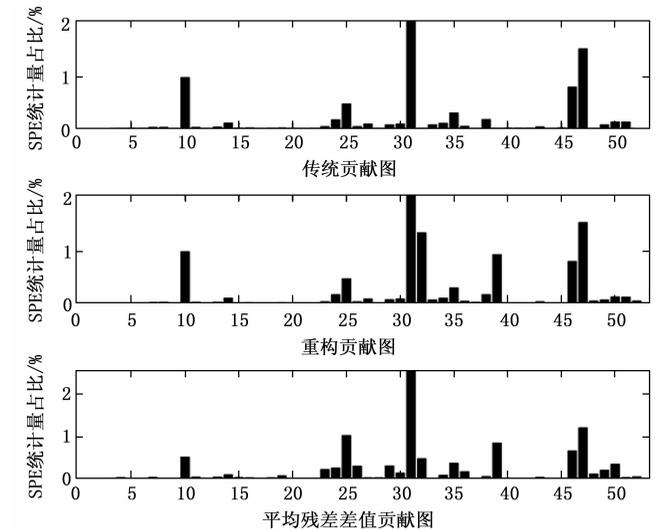


图 7 故障 2 辨识结果

和故障 3 时，KNN 方法甚至对正常数据的计算都超过了 SPE 控制限，容易引起无故障而报警的情况，而本文方法可以对微小故障做出较为精准的故障检测，对故障 3 进行检测时，通过故障检测图可以明显得出，PCA 方法和 KNN 方法对微小故障检测的准确率达不到 75%，难以达到工业安全的要求，而 ROC 方法可以精准地检测出系统运行中发生的微小故障。由图 5、图 7 和图 9 得出，平均残差差值重构贡献图法可以准确地辨识出故障发生的位置。

为证明仿真实验结果的有效性，在 Matlab 中，对故障 1~3 分别使用两种方法与本文方法进行对比实验，每种方法对 3 种故障各进行 1 000 次仿真验证，测取实验结果的平均准确率进行验证比较。故障检测准确率如表 2 所示。

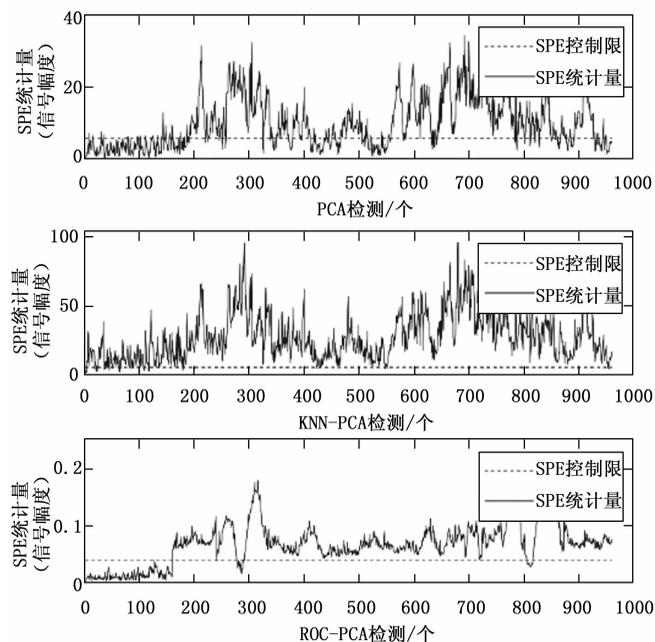


图 8 故障 3 检测结果

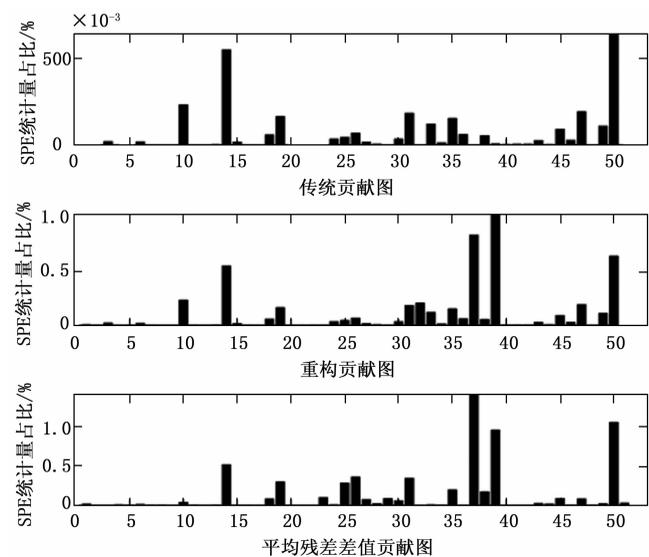


图 9 故障 3 辨识结果

表 2 故障检测准确率 %

方法	故障 1	故障 2	故障 3
PCA	87.2	86.3	74.3
KnnPCA	83.1	85.4	76.2
ROC-PCA	93.2	91.4	90.4

根据表 2 和以上故障检测结果图可以得出, ROC-PCA 方法可以非常有效地检测识别出实验中的三种故障, 检测准确率在 90% 左右, 并且基本高于原始 PCA 方法和 K 近邻 PCA 方法, 由故障检测图看可以出, 当故障为多模态且幅值变化较小的异常数据时, 以上两种方法在正常数据范围

内的检测会出现错判、误判的情况, 本文通过数据预处理, 采用以训练样本各变量均值为中心的基于数据变化率的方法对原始数据进行预处理, 能够精准地检测到系统发生的微小故障, 减少检测过程中错判、误判问题的发生, 且由图 8 可以看出故障检测准确率明显高于进行对比的两种方法。

在 ROC-PCA 方法检测到产生微小故障后, 使用平均残差差值重构贡献图法与传统贡献图和重构贡献图通过 MATLAB 仿真进行故障辨识对比实验, 故障辨识准确率如表 3 所示。

表 3 故障辨识准确率 %

方法	故障 1	故障 2	故障 3
贡献图	84.6	89.8	76.4
重构贡献图	89.3	91.2	78.7
平均残差差值贡献图	91.5	92.3	89.8

由表 3 和以上故障识别结果图可以看出, 基于平均残差差值重构贡献图的故障诊断方法在本实验中要优于基本贡献图法和重构贡献图法, 在都能正确识别出故障原因的情况下还能很大程度上减少其他变量对辨识结果的影响, 并且在故障 3 的识别诊断中识别准确率明显高于另外两种方法, 证明了该方法的有效性。

## 5 结束语

为了更好地解决工业过程中微小故障诊断难的问题, 本文提出一种数据变化率与平均残差差值重构贡献图相结合的故障诊断方法, 该方法对于相对变化较大的故障数据通过预处理后可以使数据的有效信息充分表达, 对微小且关键的数据变化也能够做到有效的检测与识别, 解决了传统贡献图对早期故障不敏感和重构贡献图减小了传统贡献图故障模糊效应的问题。通过 TE 过程的仿真实验, 证明了该方法具有良好的故障诊断性能。

数据预处理方法的选择要根据样本的数据类型为依据, 不同的数据类型应该灵活的选择不同的数据预处理方法。本文方法也具有其使用的局限性, 当故障样本数据的绝对变化量大, 但其相对变化量较小时, 该方法在对正常数据进行处理时可能将其误判为异常数据, 降低故障检测的准确性, 如何解决该问题是以后的研究方向。

## 参考文献:

- [1] JOE Q S. Statistical process monitoring: basics and beyond [J]. Journal of Chemometrics, 2003, 17: 8-9.
- [2] BERSIMIS S, PSARAKIS S, PANARETOS J. Multivariate statistical process control [J]. Quality & Reliability Engineering International, 2007, 23 (5): 517-543.
- [3] 文成林, 吕菲亚, 包哲静, 等. 基于数据驱动的微小故障诊断方法综述 [J]. 自动化学报, 2016, 42 (9): 1285-1299.
- [4] REN L, XU Z Y, YAN X Q. Single-sensor incipient fault detection [J]. IEEE Sensors Journal, 2011, 11 (9): 2102-2107.
- [5] 黄欣研, 李玲, 辛云宏. WPCA-LDA: 一种数据分类新方法

- [J]. 计算机应用研究, 2017, 34 (6): 1650-1653.
- [6] 冯俊婷, 王桂增, 徐 铄. 基于主元分析的核电站主冷却剂泵故障诊断 [J]. 原子能科学技术, 2003 (5): 395-399.
- [7] 曹桦松, 孙培伟. 基于主元分析的小型压水堆故障检测和辨识方法研究 [J]. 核动力工程, 2022, 43 (1): 148-155.
- [8] 李朝阳, 杨健维, 王 玘, 等. 基于主元分析的牵引变电所互感器二次量异常故障在线识别方法 [J]. 电力自动化设备, 2015, 35 (8): 103-109.
- [9] 王玉甲, 张铭钧, 郭 勇. 基于 PCA 的水下机器人故障诊断与数据重构 [J]. 华中科技大学学报 (自然科学版), 2009, 37 (S1): 135-139.
- [10] 胡云鹏. 基于主元分析的传感器故障检测盲区预测 [J]. 化工学报, 2017, 68 (4): 1509-1515.
- [11] 窦克勤, 叶 昊, 张海峰, 等. 基于主元分析的高炉异常炉况检测 [J]. 上海交通大学学报, 2015, 49 (12): 1862-1867.
- [12] WANG Z, WEN C, XU X, et al. Fault diagnosis method based on gap metric data preprocessing and principal component analysis [J]. Journal of Control Science and Engineering, 2018 (1): 1-9.
- [13] LIU K, XIN J, FEI Z, et al. Adaptive partitioning PCA model for improving fault detection and isolation [J]. Chinese Journal of Chemical Engineering, 2015, 23 (6): 981-991.
- [14] 顾炳斌, 熊伟丽, 史旭东. 基于故障敏感主元的多块 PCA 故障监测方法 [J]. 高校化学工程学报, 2019, 33 (6): 1499-1508.
- [15] 蓝 艇, 童楚东, 史旭华. 变量加权型主元分析算法及其在故障检测中的应用 [J]. 化工学报, 2017, 68 (8): 3177-3182.
- [16] GUO J Y, WANG X, LI Y, et al. Fault detection based on weighted difference principal component analysis [J]. Journal of Chemometrics, 2017, 31 (11): e2926.
- [17] XUAN J, XU Z, SUN Y. Selecting the number of principal components on the basis of performance optimization of fault detection and identification [J]. Industrial & Engineering Chemistry Research, 2015, 54 (12): 3145-3153.
- [18] ZHANG C, GUO Q, LI Y. Fault detection in the Tennessee eastman benchmark process using principal component difference based on K-nearest neighbors [J]. IEEE Access, 2020 (99): 1.
- [19] 张彩霞, 王子涵, 文成林, 等. 样本空间基于多级高维特征表示的微小故障诊断 [J]. 电子学报, 2020, 48 (8): 1647-1654.
- [20] 仓文涛, 杨慧中. 基于主元子空间富信息重构的过程监测方法 [J]. 化工学报, 2018, 69 (3): 1114-1120.
- [21] 鲍中新, 文成林, 马 雪. 一种基于数据变化率的预处理及主元分析故障诊断方法 [J]. 电子学报, 2021, 49 (11): 2234-2240.
- [22] ALCALA C F, QIN S J. Analysis and generalization of fault diagnosis methods for process monitoring [J]. Journal of Process Control, 2011, 21 (3): 322-330.
- [23] ALCALA C F, QIN S J. Reconstruction-based contribution for process monitoring [J]. Automatica, 2009, 45 (7): 1593-1600.
- [24] ZHANG Y, YANG Z, CHANG L. Fault magnitude estimation for processes [J]. Chemical Engineering Science, 2011, 66 (18): 4261-4267.
- [25] GANG L, ALCALA C F, QIN S J, et al. Generalized reconstruction-based contributions for output-relevant fault diagnosis with application to the Tennessee Eastman process [J]. IEEE Transactions on Control Systems Technology, 2011, 19 (5): 1114-1127.
- [26] XUAN J, XU Z, SUN Y. Incipient sensor fault diagnosis based on average residual-difference reconstruction contribution plot [J]. Industrial & Engineering Chemistry Research, 2014, 53 (18): 7706-7713.
- [7] 刘高辉, 刘 军. 基于扩展粒子滤波算法的单载波通信信号载波跟踪方法研究 [J]. 微电子学与计算机, 2021, 38 (12): 61-68.
- [8] 孙 颢, 石潇竹, 刘海颖, 等. 基于 GNSS 的地基增强系统信号质量监测阈值设计 [J]. 大地测量与地球动力学, 2021, 41 (7): 690-694.
- [9] 王 艳, 王 阳, 赵洪山, 等. 中压配电网电力线载波通信信道建模 [J]. 电力系统保护与控制, 2021, 49 (8): 50-57.
- [10] 金 鑫, 肖 勇, 曾勇刚, 等. 低压电力线宽带载波通信信道建模及误差补偿 [J]. 中国电机工程学报, 2020, 40 (9): 2800-2809.
- [11] 张家田, 万景涛, 张庆彬. 电潜泵采油井下电力线载波通信系统设计 [J]. 仪表技术与传感器, 2022 (2): 70-74.
- [12] 贺利芳, 吴雪霜, 张天骥. 正交多载波降噪差分混沌键控通信系统 [J]. 电子与信息学报, 2021, 43 (4): 1120-1128.
- [13] 杨 挺, 侯昱丞, 赵黎媛, 等. 基于时-频域混合特征的变电站通信网异常流量检测方法 [J]. 电力系统自动化, 2020, components on the basis of performance optimization of fault detection and identification [J]. Industrial & Engineering Chemistry Research, 2015, 54 (12): 3145-3153.
- [18] ZHANG C, GUO Q, LI Y. Fault detection in the Tennessee eastman benchmark process using principal component difference based on K-nearest neighbors [J]. IEEE Access, 2020 (99): 1.
- [19] 张彩霞, 王子涵, 文成林, 等. 样本空间基于多级高维特征表示的微小故障诊断 [J]. 电子学报, 2020, 48 (8): 1647-1654.
- [20] 仓文涛, 杨慧中. 基于主元子空间富信息重构的过程监测方法 [J]. 化工学报, 2018, 69 (3): 1114-1120.
- [21] 鲍中新, 文成林, 马 雪. 一种基于数据变化率的预处理及主元分析故障诊断方法 [J]. 电子学报, 2021, 49 (11): 2234-2240.
- [22] ALCALA C F, QIN S J. Analysis and generalization of fault diagnosis methods for process monitoring [J]. Journal of Process Control, 2011, 21 (3): 322-330.
- [23] ALCALA C F, QIN S J. Reconstruction-based contribution for process monitoring [J]. Automatica, 2009, 45 (7): 1593-1600.
- [24] ZHANG Y, YANG Z, CHANG L. Fault magnitude estimation for processes [J]. Chemical Engineering Science, 2011, 66 (18): 4261-4267.
- [25] GANG L, ALCALA C F, QIN S J, et al. Generalized reconstruction-based contributions for output-relevant fault diagnosis with application to the Tennessee Eastman process [J]. IEEE Transactions on Control Systems Technology, 2011, 19 (5): 1114-1127.
- [26] XUAN J, XU Z, SUN Y. Incipient sensor fault diagnosis based on average residual-difference reconstruction contribution plot [J]. Industrial & Engineering Chemistry Research, 2014, 53 (18): 7706-7713.
- [14] 吴 斌, 贺 云, 冯晓芳, 等. 基于 LFM-OTDR 的超长跨距光纤电力通信链路监测 [J]. 光通信技术, 2021, 45 (2): 55-59.
- [15] 王晓湘, 刘洞天, 刘南江, 等. 基于 LSTM 的震后通信数据异常检测分析 [J]. 中国地震, 2022, 38 (2): 270-279.
- [16] 李红映, 张天荣. 移动无线传感网络通信异常行为识别方法研究 [J]. 传感技术学报, 2022, 35 (2): 240-245.
- [17] 朱雨男, 王 彪, 张 岑. 基于深度神经网络的水声 FBMC 通信信号检测方法 [J]. 声学技术, 2021, 40 (2): 199-204.
- [18] 孙学波, 李志福, 王元杰, 等. 基于 5G 通信网络的高精度无线微震监测技术研究 [J]. 矿业安全与环保, 2022, 49 (2): 83-90.
- [19] 陈建国, 黄 宇, 严 南. 基于频谱修正的通信噪声信号峰值检测系统 [J]. 科技通报, 2021, 37 (4): 33-36.
- [20] 马莉莉, 刘江平. 基于数据挖掘的光纤通信网络异常数据检测研究 [J]. 应用光学, 2020, 41 (6): 1305-1310.