

1-18-2023

## kNN Fault Detection Based on Reconstruction Error and Multi-block Modeling Strategy

Jing Zheng

*1.China Key Laboratory of Advanced Process Control for Light Industry Ministry of Education, Jiangnan University, Wuxi 214122, China;2.School of the Internet of Things Engineering, Jiangnan University, Wuxi 214122, China; zhengjing7928@163.com*

Weili Xiong

*1.China Key Laboratory of Advanced Process Control for Light Industry Ministry of Education, Jiangnan University, Wuxi 214122, China;2.School of the Internet of Things Engineering, Jiangnan University, Wuxi 214122, China; greenpre@163.com*

Xiaodong Wu

*1.China Key Laboratory of Advanced Process Control for Light Industry Ministry of Education, Jiangnan University, Wuxi 214122, China;2.School of the Internet of Things Engineering, Jiangnan University, Wuxi 214122, China;*

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the [Artificial Intelligence and Robotics Commons](#), [Computer Engineering Commons](#), [Numerical Analysis and Scientific Computing Commons](#), [Operations Research](#), [Systems Engineering and Industrial Engineering Commons](#), and the [Systems Science Commons](#)

---

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

---

# kNN Fault Detection Based on Reconstruction Error and Multi-block Modeling Strategy

## Abstract

**Abstract:** For the fault monitoring algorithm based on k-nearest neighbor (kNN), the abnormal information that caused the fault is easy to be overwhelmed by the normal operating condition information, which leads to the problem of untimely fault detection and low alarm rate. A kNN fault monitoring method based on reconstruction error is proposed using auto-encoder and multi-block modeling strategy. *The method uses the normal working condition data set to train the auto-encoder model, and extracts the reconstruction error based on the model to solve the problem that abnormal information is easy to be overwhelmed. Further considering the fault characteristics such as micro-offset and oscillation, a multi-block modeling strategy is adopted to calculate statistics for each sub-block and merge the detection.* Through a numerical example and Tennessee-Eastman (Tennessee-Eastman, TE) process simulation and analysis, the results verify the effectiveness of the proposed method and the improvement of monitoring performance.

## Keywords

k-nearest neighbor(kNN), reconstruction error, fault detection, information extraction, multi-block modeling

## Recommended Citation

Jing Zheng, Weili Xiong, Xiaodong Wu. kNN Fault Detection Based on Reconstruction Error and Multi-block Modeling Strategy[J]. Journal of System Simulation, 2023, 35(1): 95-109.

# 基于重构误差和多块建模策略的 kNN 故障监测

郑静<sup>1,2</sup>, 熊伟丽<sup>1,2\*</sup>, 吴晓东<sup>1,2</sup>

(1. 江南大学 轻工过程先进控制教育部重点实验室, 江苏 无锡 214122; 2. 江南大学 物联网工程学院, 江苏 无锡 214122)

**摘要:** 针对基于 k 近邻(k-nearest neighbor, kNN)的故障监测算法中, 引发故障的异常信息易被正常信息淹没, 导致故障检测不及时和报警率低的问题, 利用自编码器和多块建模策略提出一种基于重构误差的 kNN 故障监测方法。该方法利用正常工况数据集训练自编码器模型, 基于该模型进行重构误差提取以解决异常信息易被淹没的问题。进一步考虑微小偏移和振荡等故障特征, 采用多块建模策略, 对各子块分别计算统计量并融合检测。通过一个数值例子与田纳西-伊斯曼(Tennessee-Eastman, TE)过程进行仿真与分析, 结果验证了所提方法的有效性与监测性能的提升。

**关键词:** k 近邻; 重构误差; 故障监测; 信息提取; 多块建模

中图分类号: TP 277

文献标志码: A

文章编号: 1004-731X(2023)01-0095-15

DOI: 10.16182/j.issn1004731x.joss.21-0689

**引用格式:** 郑静, 熊伟丽, 吴晓东. 基于重构误差和多块建模策略的 kNN 故障监测[J]. 系统仿真学报, 2023, 35(1): 95-109.

**Reference format:** Zheng Jing, Xiong Weili, Wu Xiaodong. kNN Fault Detection Based on Reconstruction Error and Multi-block Modeling Strategy[J]. Journal of System Simulation, 2023, 35(1): 95-109.

## kNN Fault Detection Based on Reconstruction Error and Multi-block Modeling Strategy

Zheng Jing<sup>1,2</sup>, Xiong Weili<sup>1,2\*</sup>, Wu Xiaodong<sup>1,2</sup>

(1. China Key Laboratory of Advanced Process Control for Light Industry Ministry of Education, Jiangnan University, Wuxi 214122, China;

2. School of the Internet of Things Engineering, Jiangnan University, Wuxi 214122, China)

**Abstract:** For the fault monitoring algorithm based on k-nearest neighbor (kNN), the abnormal information that caused the fault is easy to be overwhelmed by the normal operating condition information, which leads to the problem of untimely fault detection and low alarm rate. A kNN fault monitoring method based on reconstruction error is proposed using auto-encoder and multi-block modeling strategy. *The method uses the normal working condition data set to train the auto-encoder model, and extracts the reconstruction error based on the model to solve the problem that abnormal information is easy to be overwhelmed. Further considering the fault characteristics such as micro-offset and oscillation, a multi-block modeling strategy is adopted to calculate statistics for each sub-block and merge the detection.* Through a numerical example and Tennessee-Eastman (Tennessee-Eastman, TE) process simulation and analysis, the results verify the effectiveness of the proposed method and the improvement of monitoring performance.

**Keywords:** k-nearest neighbor(kNN); reconstruction error; fault detection; information extraction; multi-block modeling

收稿日期: 2021-07-15

修回日期: 2021-10-02

基金项目: 国家自然科学基金(61773182); 国家重点研发计划子课题(2018YFC1603705-03); 广东省科技专项资金(2020ST010)

第一作者: 郑静(1996-), 女, 硕士生, 研究方向为故障监测。E-mail: zhengjing7928@163.com

通讯作者: 熊伟丽(1978-), 女, 教授, 博导, 博士, 研究方向为复杂工业过程建模与优化, 智能软测量技术。

E-mail: greenpre@163.com

## 0 引言

现代工业生产过程日趋复杂, 故障类别日益增多, 一旦发生故障, 不仅影响生产效率, 还可能造成严重的安全事故。故障监测技术可以有效地监测过程运行状态, 提高复杂系统的可靠性和安全性, 因此已成为工业过程控制领域的研究热点<sup>[1-2]</sup>。随着分布式控制系统的广泛使用和大量过程数据的采集存储, 基于数据的过程监控方法受到了广泛关注<sup>[3-5]</sup>, 其中主元分析法(principal component analysis, PCA)<sup>[6]</sup>、偏最小二乘(partial least squares, PLS)<sup>[7]</sup>、基于 k 近邻(k-nearest neighbor, kNN)<sup>[8]</sup>的故障监测方法是常用的多元统计过程监控方法。

传统的故障监测方法大多采用全局建模策略, 但是由于现代工业过程具有多个操作单元、变量之间关系复杂等特点, 使局部、多块等建模策略的优势得到了充分发挥。Macgrego 等<sup>[9]</sup>提出基于多块建模策略的监测方法, 通过将过程分解成若干个子块进行监测并决策融合, 有效提高了复杂过程的监测效果。Ge 等<sup>[10]</sup>利用过程变量在主元方向上的贡献度划分子块, 提出一种分布式 PCA 监测方法; 同时又提出了一种基于线性子空间与贝叶斯决策的故障监测方法<sup>[11]</sup>, 利用 PCA 分解构造线性子空间, 并通过贝叶斯方法融合各子块监测结果。Jiang 等<sup>[12]</sup>根据 Hellinger 距离将概率分布相似的变量划分在一个子块中, 然后用独立主成分分析方法对每个子块建立故障监测模型。文献[13]考虑到变量的不同特性, 将原始数据进行高斯与非高斯分块, 然后采用不同的建模方法对相应子块进行监控。上述多块监测方法大多在原始数据集的基础上, 通过分析变量之间的相关关系构建子块。然而只利用过程变量的观测数据进行建模, 容易忽略数据中隐含的其他有效信息。文献[14]根据原始数据定义累计误差和变化率信息, 并结合实际观测信息建立 3 个子块进行故障监测, 实现了对微小偏移和振荡等故障的监测。这些多块监

测方法的监测效果已经在数值仿真及实际工业过程应用中得到了证实, 然而目前子块建模多选用的 PCA 方法无法同时对非线性和非高斯特性的过程数据进行有效监测。He 等<sup>[15]</sup>提出的基于 kNN 的故障监测算法, 使用局部近邻距离度量样本间的相似度, 通过对比数据的近邻距离差异来实现故障监测, 对非线性、非高斯和多模态过程有很好的监测效果。

为提高 kNN 故障监测方法的效率和精度, 并针对传统的 kNN 故障监测算法计算量比较大, 近邻样本 k 值不容易确定等问题, 学者们提出了许多改进的 kNN 故障监测算法。文献[16]利用局部保持投影方法将高维数据投影到低维空间, 然后根据样本的近邻权重计算权重统计量实现故障检测, 不仅提高了检测率还降低了计算复杂度。文献[17]针对多模态数据的方差差异, 运用局部相对概率密度对数据进行预处理, 实现了 kNN 方法对多模态数据的有效监测。文献[18]通过深层网络结构将原始数据空间转换为特征空间和残差空间, 并在两个数据空间中分别建立 kNN 模型, 解决了 kNN 模型难以有效利用高阶数据信息的问题。此外, 部分学者也尝试针对统计量计算过程中故障变量信息易被淹没的问题进行改进研究, 比如文献[19]通过对数据应用 ICA 方法获得独立元矩阵, 然后在独立元矩阵建立 kNN 监测模型, 解决了潜在变量在统计量计算过程中被淹没而导致报警率低的问题。文献[20]利用近邻距离之差将样本映射到距离空间, 通过捕捉样本之间的差异性来解决故障样本信息易被其他样本掩盖的问题。

基于以上分析, 本文在多块建模策略框架下, 提出一种基于自编码器重构误差的 kNN 故障监测方法。为了解决统计量计算过程中异常信息易被淹没的问题, 先基于自编码器模型进行正常工况数据的重构还原, 再基于该模型求取异常工况数据的重构误差, 抽离出异常信息数据; 并将该重构误差作为观测信息, 进一步提取累计信息和变化率信息构建 3 个信息子块, 对每个信息子块建

立相应的kNN模型。再利用核密度估计方法确定各子块中的控制限,最后将待测样本在各个子块上的监测结果通过贝叶斯融合进行故障监测。将所提方法进行数值仿真并应用于田纳西-伊斯曼(Tennessee-Eastman, TE)过程的故障监测,取得了较好的监测效果,验证了本文方法的性能。

## 1 相关算法基本原理

### 1.1 基于kNN的故障检测原理

kNN算法是一种惰性学习算法,其核心思想是待分类样本的类别由其近邻的 $k$ 个样本投票决定,已广泛应用于数据挖掘和数据分类中<sup>[21-22]</sup>。基于kNN的故障监测算法以异常工况样本相较于正常工况样本会产生偏移量为根据,通过比较正常样本与故障样本在训练集中的前 $k$ 个最近邻样本距离平方和判断是否发生故障。kNN故障监测算法由模型建立和故障检测2部分组成。

(1) 模型建立。首先在训练集中确定每个样本的 $k$ 个最近邻样本,然后计算每个样本到 $k$ 个最近邻样本的欧式距离平方和作为统计量。第 $i$ 个样本与 $k$ 个近邻的欧式距离平方和如式(1)定义,其中 $d_{ij}^2$ 表示第 $i$ 个样本与它第 $j$ 个近邻的欧式距离平方。最后通过核密度估计方法和置信度 $\alpha$ 确定控制限 $D_\alpha^2$ 。

$$D_i^2 = \sum_{j=1}^k d_{ij}^2 \quad (1)$$

(2) 故障检测。首先在训练集中寻找待测样本 $x$ 的前 $k$ 个近邻,然后运用式(1)计算 $x$ 与 $k$ 个近邻样本的欧式距离平方和 $D_x^2$ ,最后将 $D_x^2$ 与 $D_\alpha^2$ 进行比较,若 $D_x^2 \geq D_\alpha^2$ ,则样本 $x$ 为故障样本,否则为正常样本。

### 1.2 自编码器

自编码器是一种3层架构的无监督学习模型,由编码器和解码器组成。通过将输入数据进行编码和解码得到重构项,然后以最小化重构项与原始输入间的误差为目标更新模型参数,输出与输

入之间的一致性标反映了该模型对输入信号的还原能力<sup>[23]</sup>。自编码器模型的预测输出称为重构输出(reconstruction output, RO),故模型输入与其重构输出的差值可称为重构误差。

从结构上看,自编码器非常类似于多层感知器,包括输入层、隐含层和输出层<sup>[24]</sup>。由于自编码器目标在于提取隐变量空间或对输入进行降噪重构,而不是根据给定输入 $X$ 进行传统分类或回归任务,因此自编码器中的输出层与其输入层具有相同数量的节点,其结构如图1所示。

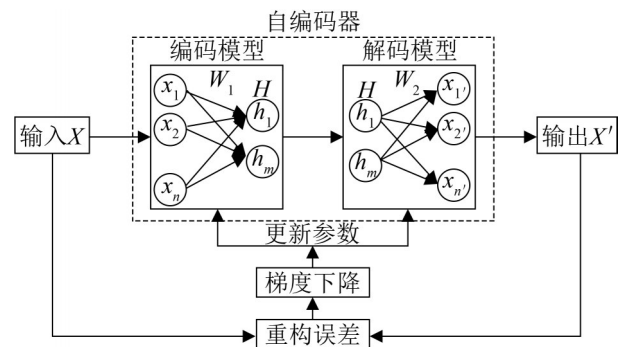


图1 自编码器结构图  
Fig. 1 Auto-encoder structure

自编码器将输入 $X \in R^{n \times 1}$ 通过函数 $f$ 映射得到新特征输出 $H \in R^{m \times 1}$ (通常 $m < n$ ),去除输入中冗余信息的同时,最大程度地保留对输入数据解释性最好的信息。编码函数为

$$H(X) = f(W_1 * X + b_1) \quad (2)$$

式中: $H$ 为输入的新特征表示; $f(\cdot)$ 通常为非线性激活函数,本文选用sigmoid函数,即 $f(x) = \frac{1}{1 + e^{-x}}$ ;  $W_1$ 和 $b_1$ 分别为编码器的权重矩阵和偏差向量。

解码器通过非线性激活函数 $g$ 将 $H$ 映射回原始数据空间,得到 $X' \in R^{n \times 1}$ 。解码函数为

$$X' = g(W_2 * H + b_2) \quad (3)$$

式中: $X'$ 为输入的重构表示; $g(\cdot)$ 为sigmoid激活函数; $W_2$ 和 $b_2$ 分别为解码器的权值矩阵和偏差向量。

参数集 $\theta = \{W_1, b_1, W_2, b_2\}$ 以最小化重构误差

$L(X, X')$ 为目标进行参数更新, 从而使得输出尽可能接近输入, 故优化目标为

$$\begin{aligned} \theta^* &= \underset{\theta}{\operatorname{argmin}} L(X, X') \\ \text{s. t. } &X \approx X' \end{aligned} \quad (4)$$

本文以重构输出与输入的欧式距离平方为指标计算重构误差, 误差函数为

$$L(X, X') = \|X - X'\|_2^2 = \|X - g(W_2 * H + b_2)\|_2^2 = \|X - g(W_2 * f(W_1 * X + b_1) + b_2)\|_2^2 \quad (5)$$

## 2 一种基于自编码器重构误差的kNN故障监测方法

### 2.1 基于重构误差的kNN故障监测

测试集样本数据实际上可以看做正常信息数据加异常信息数据的和集:

$$X_{\text{test}} = X_{\text{test}}^n + X_{\text{test}}^u \quad (6)$$

式中:  $X_{\text{test}}^n$  为正常信息数据;  $X_{\text{test}}^u$  为异常信息数据。

本文构建的自编码器模型以  $X_{\text{train}}$  作为训练集,  $X_{\text{train}}$  为正常工况下记录得到的数据, 因此  $X_{\text{train}}$  也称为正常信息数据, 其重构输出  $\hat{X}_{\text{train}}$  为

$$\hat{X}_{\text{train}} = g(\omega * H_{\text{train}} + b) \quad (7)$$

式中:  $H_{\text{train}}$  为  $X_{\text{train}}$  经过编码后提取出的潜隐变量, 假设  $X_{\text{train}}$  服从  $D$  分布, 则  $H_{\text{train}}$  服从  $D'$  分布,  $\hat{X}_{\text{train}}$  服从  $D''$  分布。

自编码器的损失函数为重构误差即  $X_{\text{train}} - \hat{X}_{\text{train}}$ , 当训练过程结束时, 损失函数近似为 0, 可以得出  $\hat{X}_{\text{train}} \approx X_{\text{train}}$ 。

测试集  $X_{\text{test}}$  基于该自编码器的重构输出为

$$\begin{aligned} \hat{X}_{\text{test}} &= g(\omega * (H_{\text{test}}^n + H_{\text{test}}^u) + b) = \\ &g(\omega * H_{\text{test}}^n + b) + g(\omega * H_{\text{test}}^u + b) = \\ &\hat{X}_{\text{test}}^n + \hat{X}_{\text{test}}^u \end{aligned} \quad (8)$$

式中:  $H_{\text{test}}^n$  为  $X_{\text{test}}$  中正常信息数据的潜隐变量, 则其服从  $D'$  分布,  $\hat{X}_{\text{test}}^n$  服从  $D''$  分布, 结合  $X_{\text{train}}$  服从  $D$  分布,  $\hat{X}_{\text{train}}$  服从  $D''$  分布可以推断出  $\hat{X}_{\text{test}}^n \approx X_{\text{test}}^n$ 。

将测试集与其在该自编码器模型的重构输出做差, 由式(6)和(8)可得重构误差为

$$X_{\text{test}} - \hat{X}_{\text{test}} \approx X_{\text{test}}^u - \hat{X}_{\text{test}}^u \quad (9)$$

可以发现重构误差仅与异常信息数据有关, 基于重构误差建立故障监测模型, 避免了统计量计算过程中由于正常信息数据量级远超异常信息数据而淹没异常信息数据的问题, 提升了故障监测的效果。图2给出了基于重构误差的kNN故障监测方法 (kNN fault detection based on reconstruction error, RE\_kNN)与基于传统kNN的监测方法对比图。

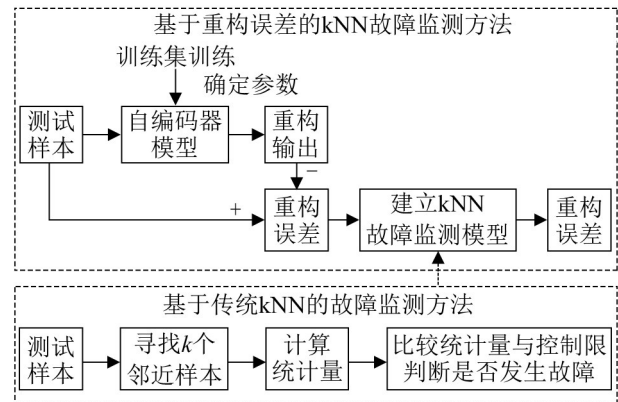


图2 RE\_kNN与传统kNN对比  
Fig. 2 Comparison of RE\_kNN and traditional kNN

### 2.2 多块建模策略

传统多块建模方法根据不同的变量选取准则将过程划分成若干子块, 本文将自编码器重构误差作为观测信息, 提取出累计信息和变化率信息构成3个信息子块, 进行分块监测。

累计信息是指累加计算一段时间内的观测值而得到的数据信息。通过提取累计信息可以放大故障变量的微小偏移和缓变, 从而提高故障的检出率。

假设标准化后的变量数据集为  $X \in R^{n \times m}$ , 由于构造新特征应用了数据集前  $T$  个时刻的样本,

因此得到的累计信息数据集会损失  $T$  个样本, 即  $X_1 \in R^{(n-T) \times m}$ 。第  $t$  时刻的累计信息为

$$x_1(t) = \sum_{l=0}^T (x(t-l)); x_1(t) \subset X_1 \quad (10)$$

式中:  $x(t)$  为  $t$  时刻的观测数据样本。

变化率信息反映变量的变化速率, 当故障的类型表现为振荡而非单一的偏移, 传统的监测方法难以检测。但利用其变化速率超过正常工况范围, 可达到监测此类故障的目的。

令标准化后的变量数据集为  $X \in R^{n \times m}$ , 由于累计信息数据集丢失前  $T$  个样本, 为了保证各子块数据集大小一致, 变化率信息提取出的数据集为  $X_D \in R^{(n-T) \times m}$ 。第  $t$  时刻的变化率信息为

$$x_D(t) = x(t) - x(t-1); x_D(t) \in X_D \quad (11)$$

式中:  $x(t)$  为  $t$  时刻的观测数据样本。

将数据集经自编码器得到的重构误差作为原始观测值信息  $X$ , 对  $X$  提取累计信息和变化率信息, 分别得到信息子块  $X_1$  和  $X_D$ , 从而得到 3 个信息子块。本文所采用的基于自编码器重构误差的多块建模方法如图 3 所示。

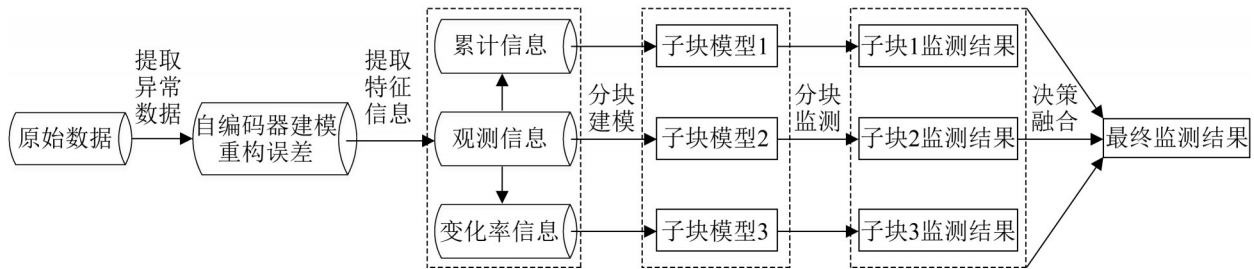


图3 基于自编码器重构误差的多块建模方法

Fig. 3 Multi-block modeling method based on reconstruction error of auto-encoder

### 2.3 故障监测

在划分好子块的基础上, 对各子块建立 kNN 故障监测模型, 得到相应的统计量与控制限。再进一步采用贝叶斯融合策略<sup>[25]</sup>, 对所有子块的监测结果进行融合, 得到一个最终的监测指标。

假设测试样本  $x_{test} \in X_{test}$ , 根据第  $i$  个子块的  $D^2$  统计量和控制限可得该样本在第  $i$  个子块中的故障条件概率为

$$P_{D^2}(F|x_{test}, i) = \frac{P_{D^2}(x_{test}, i|F)P_{D^2}(F)}{P_{D^2}(x_{test}, i|N)P_{D^2}(N) + P_{D^2}(x_{test}, i|F)P_{D^2}(F)} \quad (12)$$

式中:  $x_{test, i}$  为第  $i$  个子块中的测试样本;  $P_{D^2}(N)$  和  $P_{D^2}(F)$  分别为正常样本和故障样本的先验概率, 置信度为  $\alpha$  和  $1-\alpha$ 。条件概率  $P_{D^2}(x_{test}, i|N)$  和  $P_{D^2}(x_{test}, i|F)$  定义为

$$P_{D^2}(x_{test}, i|N) = e^{-D_{i, new}^2 / D_{i, lim}^2} \quad (13)$$

$$P_{D^2}(x_{test}, i|F) = e^{-D_{i, lim}^2 / D_{i, new}^2}$$

式中:  $D_{i, new}^2$  为新样本在第  $i$  个子块中的统计量;

$D_{i, lim}^2$  为第  $i$  个子块中由核密度估计方法得到的控制限。最终, 以条件概率  $P_{D^2}(x_{test}, i|N)$  和  $P_{D^2}(x_{test}, i|F)$  为权重, 加权计算各子块中待测样本  $x_{test}$  为故障样本的概率。融合后的  $BIC_{D^2}$  统计量即为待测样本  $x_{test}$  发生故障的概率:

$$BIC_{D^2} = \sum_{i=1}^3 \left\{ \frac{P_{D^2}(x_{test}, i|F)P_{D^2}(F|x_{test}, i)}{\sum_{j=1}^3 P_{D^2}(x_{test}, j|F)} \right\} \quad (14)$$

融合后的统计量控制限为  $1-\alpha$ , 其中,  $\alpha$  为先验知识, 即生产过程中正常样本的先验概率,  $1-\alpha$  为异常样本的先验概率, 本文取  $1-\alpha$  为 0.01。当  $BIC_{D^2}$  大于  $1-\alpha$  时, 则判断待测样本为故障样本, 否则为正常样本。

### 2.4 算法流程描述

基于重构误差和多块建模策略的 kNN 故障监测算法(kNN fault detection based on reconstruction error and multi-block modeling strategy, RE\_MBIkNN)的流程如图 4 所示, 具体描述如下。

step 1: 基于标准化后的正常工况数据集  $X$ , 训练自编码器模型, 得到重构误差  $R_e$ ;

step 2: 将重构误差作为观测信息, 进一步提取累计信息和变化率信息, 构成3个信息子块  $R_e$ 、 $R_e^I$ 、 $R_e^D$ ;

step 3: 对每个子块分别建立kNN模型, 利用核密度估计方法确定各自的故障控制限;

step 4: 对于新来的标准化测试样本  $x_{\text{test}}$ , 在训练好的自编码器模型上得到重构项并求取重构误差, 按step 2提取特征信息, 得到信息子块;

step 5: 对step 4中的各子块建立kNN故障监测模型;

step 6: 采用贝叶斯融合方法, 将各子块的统计量组合成一个新的  $BIC$  统计量, 并根据置信度确定控制限, 当  $BIC$  统计量超过控制限时则判断发生了故障, 反之正常。

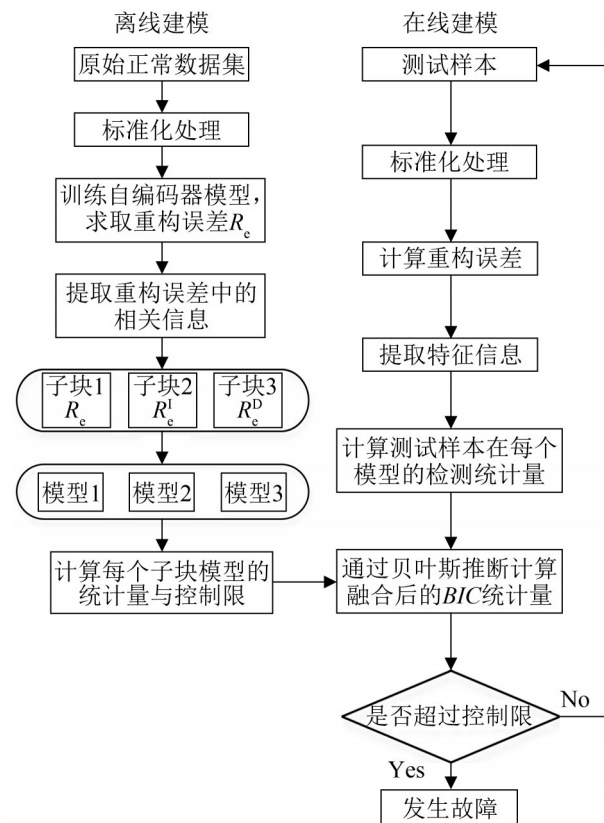


图4 基于重构误差和多块建模策略的kNN故障监测流程  
Fig. 4 Flow chart of kNN fault detection based on reconstruction error and multi-block modeling strategy

## 3 仿真研究

### 3.1 数值仿真

采用文献[11]中的数值例子进行仿真验证, 其具体结构为

$$\begin{cases} x_1 = y + e_1, \\ x_2 = y^2 - 3y + e_2, \\ x_3 = -y^3 + 3y^2 + e_3, \\ x_4 = y^4 - 4y^3 + 2y + e_4, \\ x_5 = -2y^5 + 6y^4 - 3y^3 + y + e_5 \end{cases} \quad (15)$$

式中:  $x_i (i=1, 2, 3, 4, 5)$  为变量;  $y$  为服从  $[0.01, 2]$  上均匀分布的源变量;  $e_j (j=1, 2, 3, 4, 5)$  为噪声变量,  $e_j \sim N(0, 0.01^2) (j=1, 2, 3, 4, 5)$ 。

该数值例子共产生300个训练样本, 故障设置如下:

故障1: 在第100~200处样本给变量  $x_3$  加入幅值为0.2的振荡信号;

故障2: 在第201~300处样本给变量  $x_5$  加入幅值为0.005的斜坡信号。

为了验证本文的方法, 图5给出了数值样本及处理后数值样本的变量曲线图。其中图5(a)、5(b)、5(c)分别为数值样本、重构误差样本及对重构误差样本提取变化率信息后样本在变量  $x_3$  上的曲线图, 图5(d)、5(e)、5(f)分别为数值样本、重构误差样本及对重构误差样本提取累计信息后样本在变量  $x_5$  上的曲线图。由于累计信息宽度  $T$  取值为5, 因此在监测中会损失前5个样本点。从图5中可以看出, 对于数值仿真中设计的2种特殊类型故障, 故障样本曲线与正常样本的变量曲线差异性不大(图5(a)、5(d)), 而重构误差的变量曲线图很好地还原了故障信息特征(图5(b)、5(e)), 可以明显地区分正常样本与异常样本。为进一步深入分析, 在曲线图中用“■”表示变量  $x_3$  的第108、117、136、164、185个样本, 用“▲”表示变量  $x_5$  的第210、226、236、264、285个样本。原始数据中由于上述几个故障样本点在变量  $x_3$  上的值位于正常工况样本变量值域内而漏报,



当经过重构误差后, 变量值均明显偏离了正常工况样本的变量值域, 因此被准确地监测出来。

由图5(c)、5(f)可以看出, 合适的信息提取方式可以显著地提高故障的检出率, 比如, 对于变量 $x_3$ 的振荡类型故障, 由于提取了变化率信息, 使得故障发生前后的差异更加明显; 对于变量 $x_5$ , 提取的累计信息将异常数据的微小偏移放大, 使故障可以及时地被监测出来。

基于kNN, RE\_kNN, RE\_MBIkNN 3种方法进行仿真与对比, 采用网格搜索方法确定近邻个数 $k$ 为19, 并采用加权贡献图<sup>[14]</sup>进行故障诊断。监测结果如图6和表1所示。由图6可知, 传统kNN方法无法有效监测到故障的发生, 报警率仅有9%。而基于重构误差的kNN可以有效提高报警率, 报警率达87%。对比图6(b)、6(c)可以发现, 通过提取累计信息将异常信息的微小偏移再次放大, 提升了子块2对微小偏移类型故障的监测效果。子块3通过提取异常信息的变化率, 使得对

振荡类型的故障更为敏感。最后融合的监测结果融合了子块2和子块3的优势, 对这2种不易检出的特殊故障类型都做到了很好的监测, 最终报警率达到98%。图7给出了故障的诊断结果, 可以看出变量 $x_3$ 和 $x_5$ 是引发故障的源变量。

为更好地说明本文方法的有效性, 对提取重构误差后的样本绘制变量 $x_3$ 和 $x_5$ 的曲线图, 图7(b)第100~200个样本处变量曲线呈现出了与数值仿真设置的故障1类型一致的振荡信号, 图7(c)第200~300个样本处变量曲线呈现出了与仿真设置故障2类型一致的斜坡信号。由于数据经过了预处理故重构误差提取的异常信息与实际设置的故障信号幅值并不相等, 但变量变化趋势和数据分布都大致相同, 可见通过求取自编码器重构误差确实有效地从正常工况数据中抽离出了异常信息数据, 解决了异常信息易被淹没的问题, 提升了监测效果。

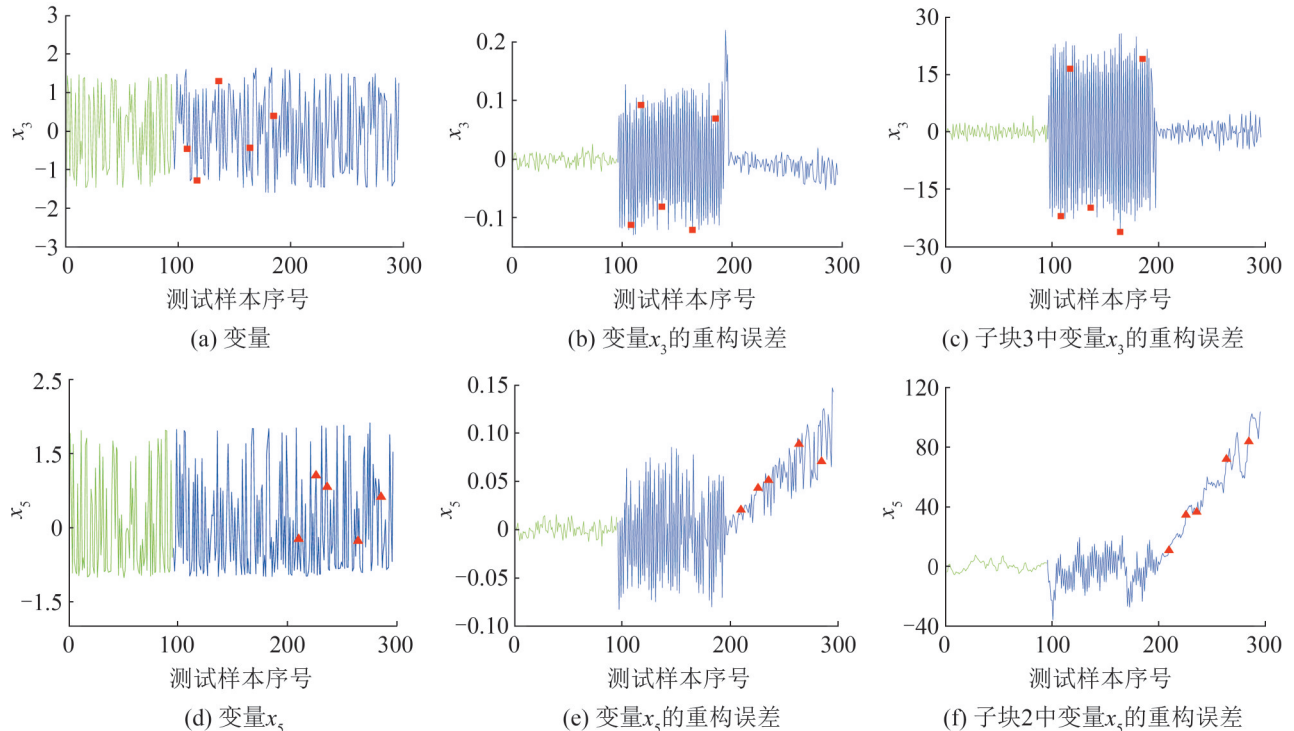


图5 数值样本变量曲线图

Fig. 5 Variable curve of numerical sample

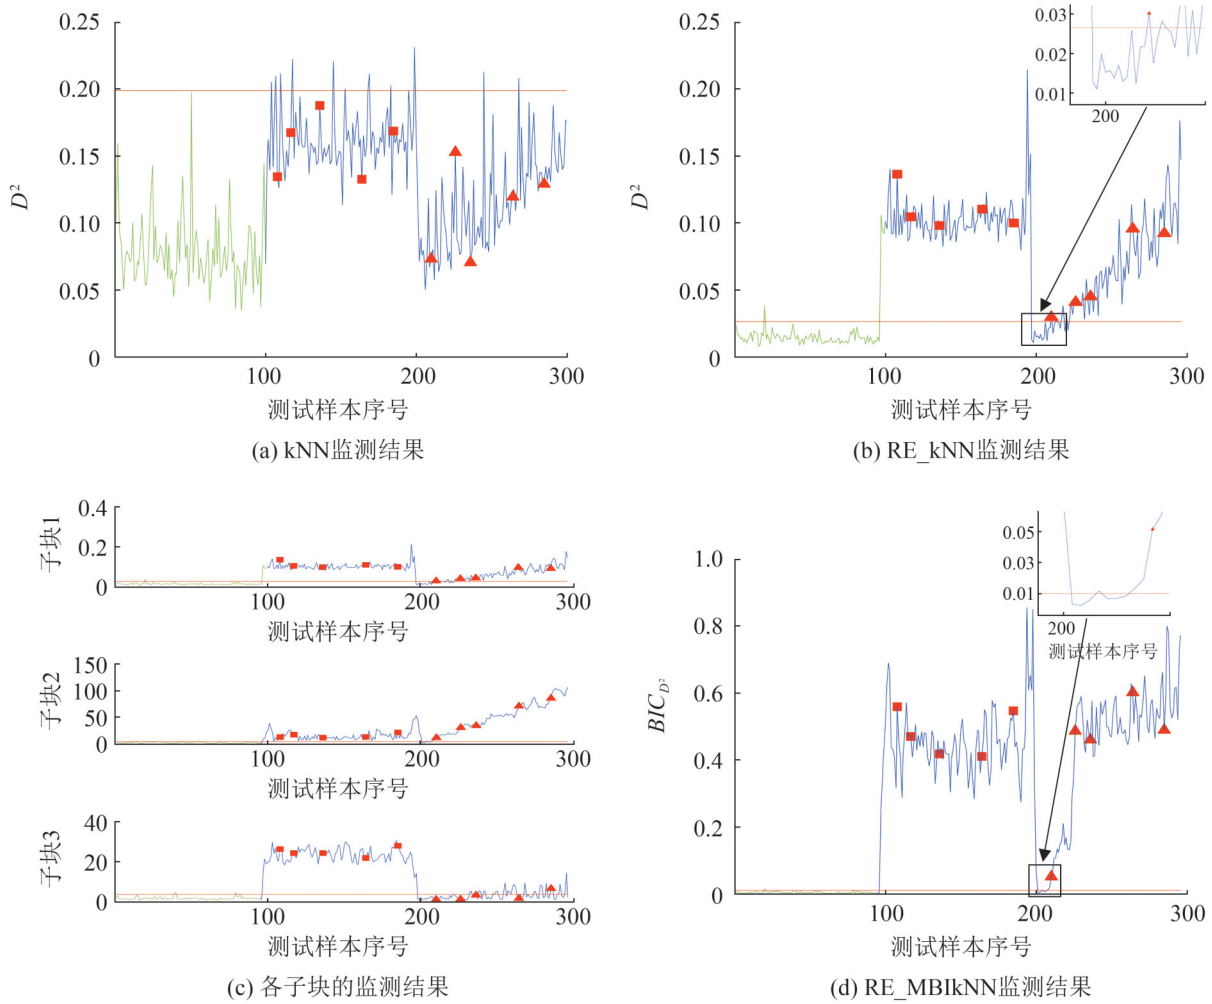


图 6 kNN、RE\_kNN 和 RE\_MBIkNN 的监测结果  
Fig. 6 Monitoring results of kNN, RE\_kNN and RE\_MBIkNN

表 1 数值仿真故障报警率及误报率比较  
Table 1 Comparison of alarm rate and false alarm rate in numerical simulation

方法	报警率	误报率
kNN	0.090	0
RE_kNN	0.872	0.04
RE_MBIkNN	0.981	0




图 7 数值仿真故障 1、2 的诊断结果  
Fig. 7 Diagnosis results of fault 1 and 2 in numerical simulation

### 3.2 TE过程

TE过程是一个基于实际化工过程的仿真模拟系统, 它包括5个主体部分: 冷凝器、汽提塔、压缩机、反应器以及分离器<sup>[26-27]</sup>。整个过程包含19个成分变量, 22个测量变量, 12个操作变量以及21种预设定的故障类型, TE过程的详细描述见文献[28]。本文选取测量变量和操作变量(除去搅拌速度)共33个变量用于监测方法建模与测试。分别采用正常工况下和21种故障工况下的960个样本作为训练集和测试集, 故障均从第161个样本点引入。由于本文在信息提取时累计信息宽度取值5, 因此会损失前5个样本, 在监控图中表现为故障样本中的故障从第156个点开始。

表2给出了各子块分别以原始数据为观测信

息和以重构误差为观测信息时对21种故障的报警率和平均误报率。对比各子块的报警率, 其中以重构误差为观测信息时的报警率要高于以原始数据为观测信息时的报警率, 可见通过重构误差提取异常信息改善了传统kNN故障监测方法中故障源信息易被正常信息淹没导致监测效果不理想的问题。此外, 由于子块2提取了累计信息, 放大故障信号也放大了噪声干扰信息, 使得子块2在多数情况下的监测结果优于其他两个子块的同时, 误报率也较高。子块3虽然报警率低, 但是对于某些故障(如故障19)检出率高且对降低融合后的误报率起着重要的作用。从对21种故障的监测结果来看, 融合后的监测性能有了明显的提高, 整体上优于3个子块。

表2 以原始数据、重构误差为观测信息时TE过程监测结果对比

Table 2 Comparison of TE process monitoring results when using original data and reconstruction error as observation information

故障编码	以原始数据为观测信息				以重构误差为观测信息			
	子块1	子块2	子块3	BIC	子块1	子块2	子块3	BIC
1	0.996	0.998	0.001	0.995	0.996	0.995	0.976	0.995
2	0.983	0.988	0.000	0.984	0.986	0.989	0.978	0.984
3	0.013	0.326	0.001	0.054	0.092	0.195	0.119	0.150
4	0.975	0.999	0.005	0.999	0.999	0.999	0.117	0.999
5	0.260	0.809	0.002	0.381	0.999	0.999	0.336	0.999
6	1	0.999	0.004	0.999	0.999	0.999	0.911	0.999
7	1	0.999	0.007	0.999	0.999	0.999	0.554	0.999
8	0.976	0.993	0.006	0.979	0.979	0.984	0.969	0.976
9	0.020	0.290	0.005	0.051	0.084	0.162	0.135	0.132
10	0.418	0.815	0.000	0.618	0.737	0.860	0.393	0.848
11	0.683	0.941	0.047	0.868	0.758	0.930	0.553	0.913
12	0.989	1.000	0.199	0.993	0.995	1.000	0.980	1.000
13	0.946	0.963	0.031	0.951	0.950	0.958	0.944	0.953
14	1	0.878	0.998	0.998	0.999	0.998	0.999	0.999
15	0.029	0.326	0.004	0.105	0.101	0.220	0.119	0.181
16	0.289	0.820	0.002	0.549	0.729	0.886	0.291	0.893
17	0.919	0.974	0.149	0.966	0.946	0.975	0.864	0.976
18	0.896	0.940	0.041	0.899	0.906	0.914	0.898	0.913
19	0.099	0.412	0.114	0.135	0.669	0.644	0.697	0.779
20	0.495	0.848	0.039	0.642	0.669	0.843	0.452	0.810
21	0.425	0.699	0.001	0.566	0.576	0.664	0.583	0.639
平均报警率	0.639	0.810	0.079	0.701	0.770	0.820	0.613	0.816
平均误报率	0.006	0.159	0.003	0.015	0.046	0.079	0.067	0.059

图8展示了故障10的监测结果，故障10是TE过程中流2(C进料)中温度的随机变化，从图8可以看出，传统的kNN方法只能在第700~800样本间较好地监测到故障，基于重构误差的kNN已经可以在故障初期和故障后期做到大范围的报警，而采用信息提取和多块建模策略融合监测后，报警率进一步提升，实现了更准确及时的报警。从图9(a)中可以看出引发故障10的源变量为变量 $x_{18}$ 、 $x_{19}$ 和 $x_{31}$ 。故障的主要原因是故障变量

在第300和800样本点附近发生了过大的波动，而提取的重构误差放大了正常与故障样本之间的差异性，使得RE\_kNN可以很好地监测到由于变量不正常波动产生的故障。但是变量 $x_{19}$ 在第400~600样本点之间有一个幅值较小的偏移，由于该偏移较小，kNN和RE\_kNN方法均难以监测到。而本文方法在求取重构误差的基础上进行信息提取，将该偏移再次放大，因此能够很好地监测到该故障。

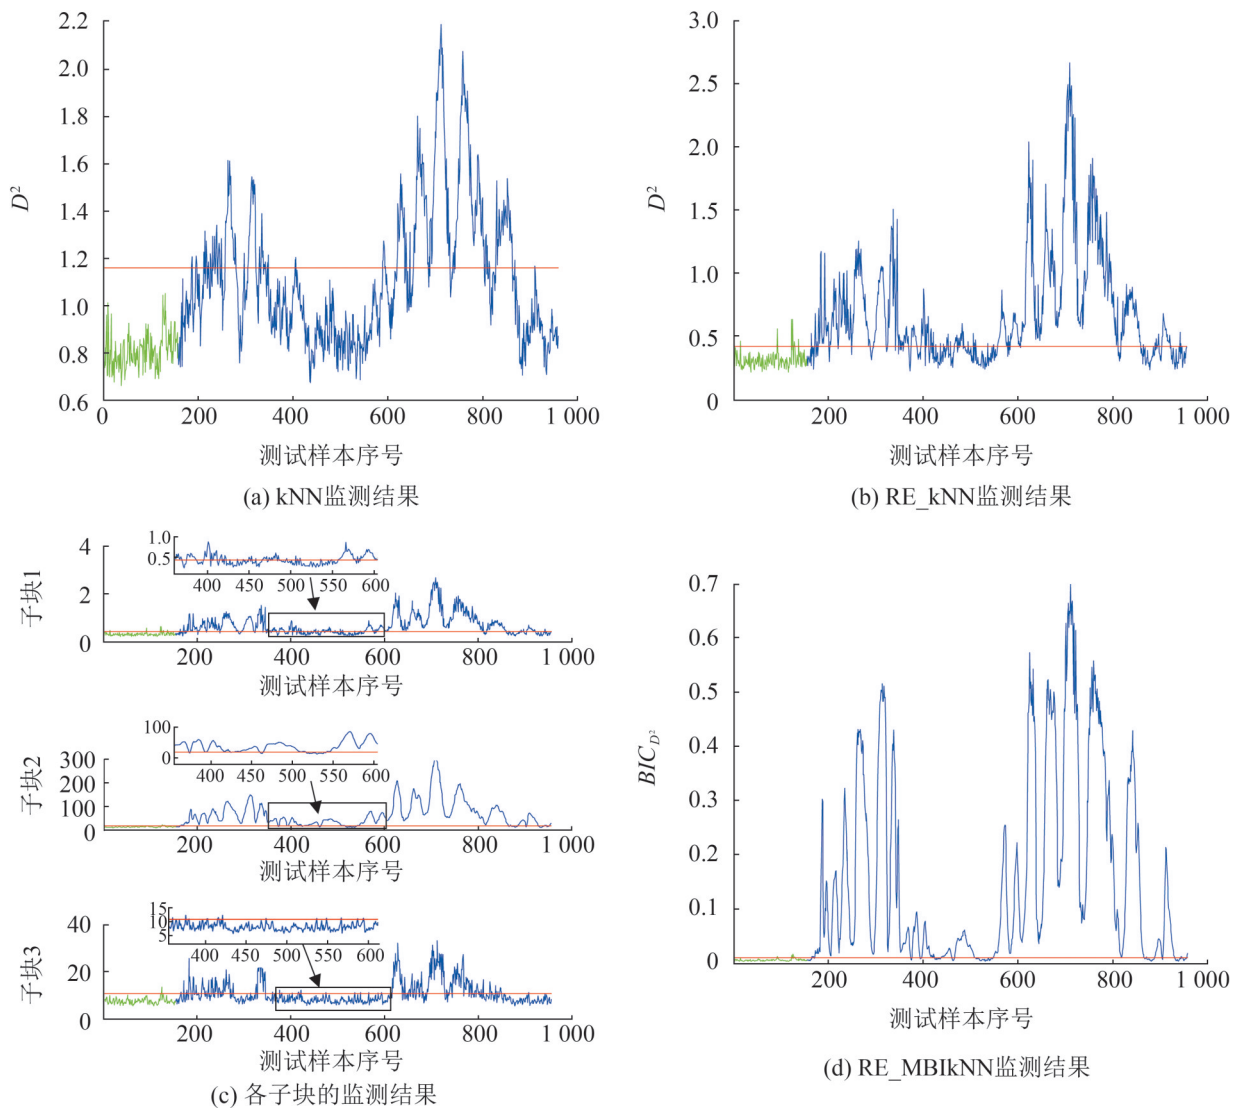


图8 kNN、RE\_kNN及RE\_MBIkNN对故障10的监测结果  
Fig. 8 kNN, RE\_kNN and RE\_MBIkNN monitoring results of fault 10

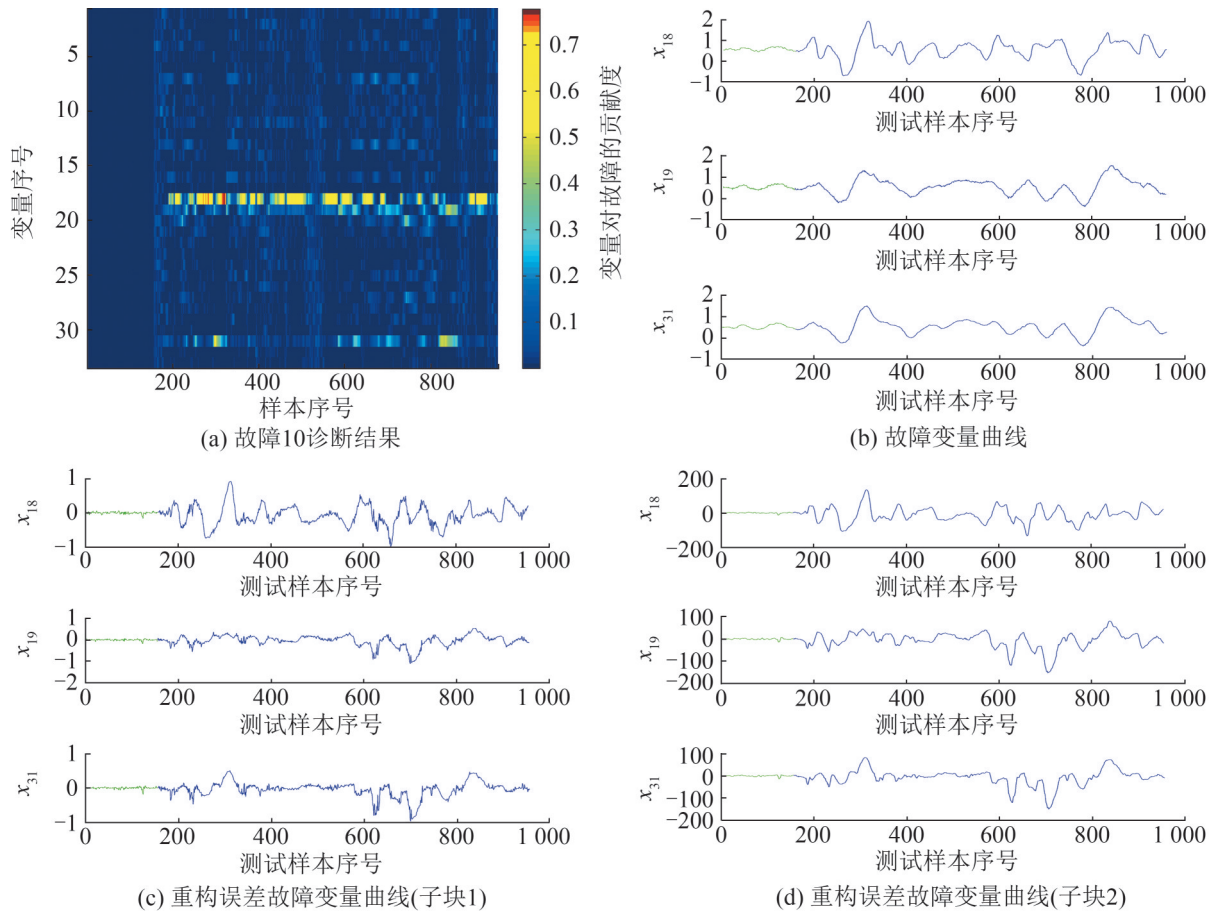


图9 故障10诊断结果和故障变量曲线图

Fig. 9 Fault 10 diagnosis results and fault variable curve diagram

传统的kNN方法对故障11的报警率只有68%，而本文所提方法从故障引入点处开始就能做到大范围的持续报警，报警率达91.3%，具体监测结果如图10所示。图11(a)对故障提供了清晰的诊断结果，即引发该故障的源变量为变量 $x_9$ 与 $x_{32}$ 。在原始TE数据集、重构误差数据集及重构误差数据集提取累计信息后数据集上分别对变量 $x_9$ 与 $x_{32}$ 绘制变量曲线图，如图11(b)、11(c)、11(d)所示，可以看出引发该故障的故障变量相较于重构误差的故障变量，有更多的故障样本变量值处于正常工况样本的变量值域内，这些样本点计算所得统计量与正常工况样本统计量相差不大，因此以重构误差为统计量计算时的监测效果要优于传统的kNN监测方法。对比图11(c)和图11(d)可以看出提取累计信息后，放大了变量之间的差异，

使得子块2表现了良好的监测性能，最终提升了整体的监测结果。

表3给出了6种不同监测方法对TE过程21种故障的报警率和平均误报率，包括PCA、SVDD、kNN、MBikNN、RE\_kNN和RE\_MBikNN，其中各方法控制限均采用核密度估计方法确定，阈值设置为99%，通过网格搜索算法，取近邻个数 $k$ 为19，核宽系数为0.5，累计信息宽度 $T$ 为5。可以看出，RE\_kNN相比于传统监测方法，报警率有了一定的提升。而引入多块建模策略后，在部分传统方法及RE\_kNN不易检出的故障类型上，报警率获得了显著的提升。本文所提方法综合了MBikNN和RE\_kNN的优势，在大多数故障下报警率最高，平均报警率达81.6%，进一步验证了本文所提方法的监测性能。

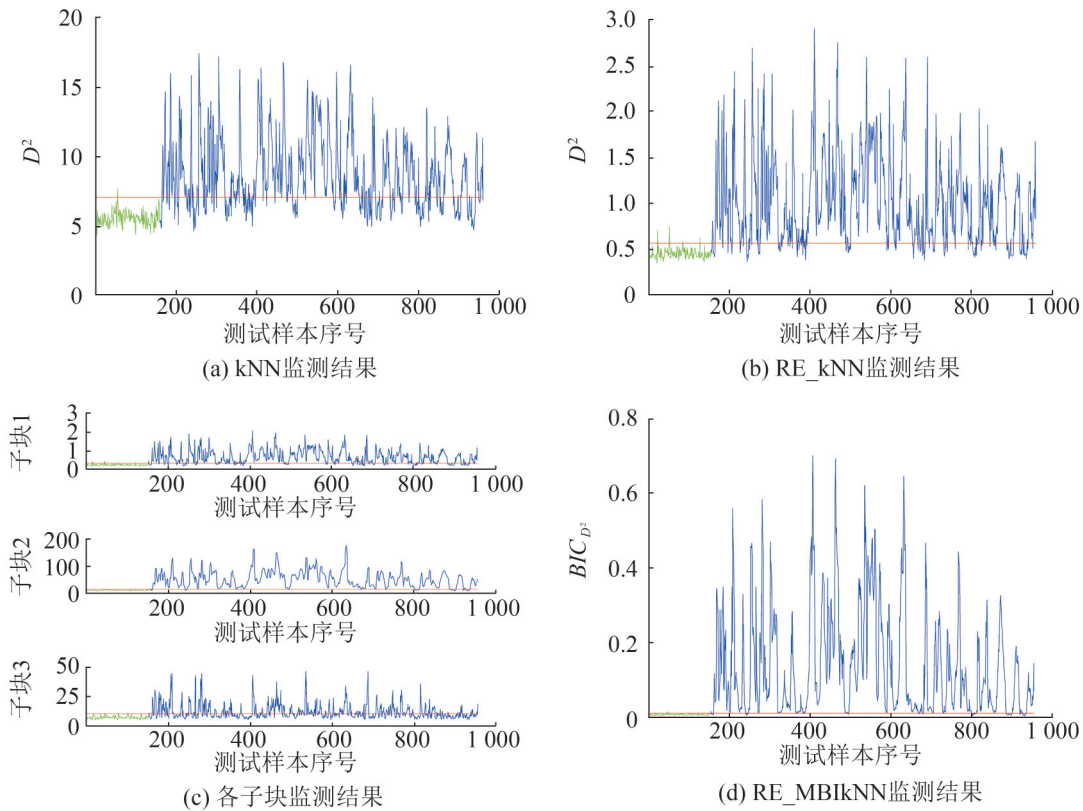


图 10 kNN、RE\_kNN 及 RE\_MBIkNN 对故障 11 的监测结果  
Fig. 10 kNN, RE\_kNN and RE\_MBIkNN monitoring results of fault 11

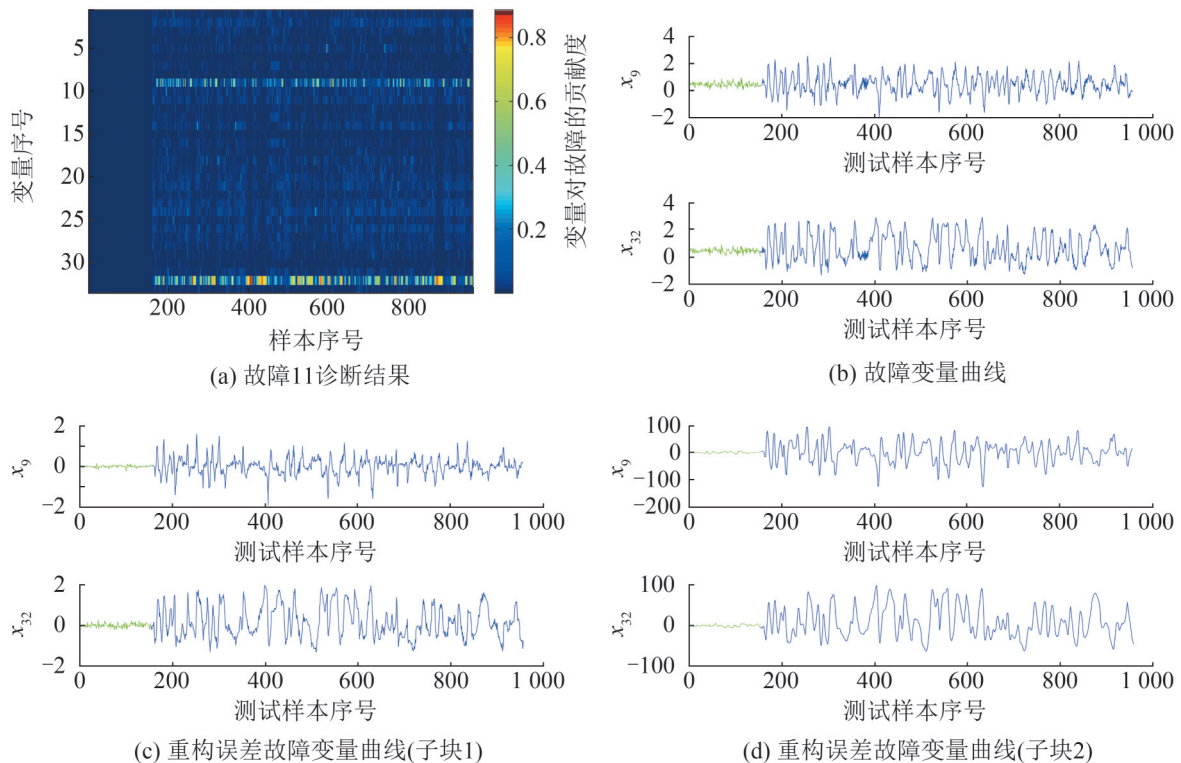


图 11 故障 11 诊断结果和故障变量曲线图  
Fig. 11 Fault 11 diagnosis results and fault variable curve diagram

表3 PCA、SVDD、kNN、MBikNN、RE\_kNN和RE\_MBikNN的TE过程监测结果  
Table 3 TE process monitoring results of PCA, SVDD, kNN, MBikNN, RE\_kNN and RE\_MBikNN

故障编码	报警率					
	PCA	SVDD	kNN	MBikNN	RE_kNN	RE_MBikNN
1	<b>0.999</b>	0.993	0.995	0.995	0.996	0.995
2	0.985	0.983	0.983	0.984	<b>0.986</b>	0.984
3	0.032	0.035	0.013	0.054	0.092	<b>0.150</b>
4	<b>1</b>	0.790	0.974	0.999	0.999	0.999
5	0.253	0.275	0.260	0.381	<b>0.999</b>	<b>0.999</b>
6	<b>1</b>	<b>1</b>	<b>1</b>	0.999	0.999	0.999
7	<b>1</b>	<b>1</b>	<b>1</b>	0.999	0.999	0.999
8	0.976	0.975	0.977	0.979	<b>0.979</b>	0.976
9	0.058	0.029	0.021	0.051	0.084	<b>0.132</b>
10	0.299	0.446	0.418	0.618	0.737	<b>0.848</b>
11	0.754	0.598	0.683	0.868	0.758	<b>0.913</b>
12	0.984	0.987	0.988	0.993	0.995	<b>1</b>
13	<b>0.953</b>	0.944	0.946	0.951	0.950	<b>0.953</b>
14	<b>1</b>	<b>1</b>	<b>1</b>	0.998	0.999	0.999
15	0.037	0.063	0.029	0.105	0.101	<b>0.181</b>
16	0.274	0.284	0.279	0.549	0.729	<b>0.893</b>
17	0.952	0.876	0.919	0.966	0.946	<b>0.976</b>
18	0.901	0.898	0.898	0.899	0.906	<b>0.913</b>
19	0.225	0.045	0.089	0.135	0.669	<b>0.779</b>
20	0.498	0.458	0.485	0.642	0.669	<b>0.810</b>
21	0.513	0.421	0.426	0.566	0.576	<b>0.639</b>
平均报警率	<b>0.652</b>	<b>0.624</b>	<b>0.637</b>	<b>0.701</b>	<b>0.770</b>	<b>0.816</b>
平均误报率	<b>0.004</b>	<b>1.756</b>	<b>0.006</b>	<b>0.015</b>	<b>0.046</b>	<b>0.059</b>

## 4 结论

本文提出了一种基于重构误差和多块建模策略的kNN故障监测方法,通过求取自编码器的重构误差解决异常信息数据易被正常工况数据淹没的问题,再对该重构误差提取观测、累计和变化率信息,建立3个信息子块进行多块建模,最终采用贝叶斯方法融合各子块结果做出决策。所提方法与PCA、SVDD、kNN、MBikNN等故障监测方法相比,在数值仿真和TE过程故障监测中具有更好的监测效果,表明了方法的有效性。但在仿真中发现,自编码器训练的时候存在一定的过拟合问题,如何有效改进自编码器结构使其更好地应用于kNN故障监测,是今后需要考虑和研究

的问题。

## 参考文献:

- [1] 刘强,卓洁,郎自强,等.数据驱动的工业过程运行监控与自优化研究展望[J].自动化学报,2018,44(11):1944-1956. Liu Qiang, Zhuo Jie, Lang Ziqiang, et al. Perspectives on Data-driven Operation Monitoring and Self-optimization of Industrial Processes[J]. Acta Automatica Sinica, 2018, 44(11): 1944-1956.
- [2] Ge Z, Song Z. Review of Recent Research on Data-based Process Monitoring[J]. Industrial & Engineering Chemistry Research (S0888-5885), 2013, 52(10): 3534-3562.
- [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 Kaixiang, Ma Liang, Zhang Kai. Review of Quality-related Fault Detection and Diagnosis Techniques for Complex Industrial Processes[J]. Acta Automatica Sinica, 2017, 43(3): 349-365.

- [4] Jiang Q, Yan X, Zhao W. Fault Detection and Diagnosis in Chemical Processes Using Sensitive Principal Component Analysis[J]. *Industrial & Engineering Chemistry Research* (S0888-5885), 2013, 52(4): 1635-1644.
- [5] Yin S, Xie X, Sun W. A Nonlinear Process Monitoring Approach with Locally Weighted Learning of Available Data[J]. *IEEE Transactions on Industrial Electronics* (S0278-0046), 2016, 64(2): 1507-1516.
- [6] 王文标, 田志远, 汪思源, 等. 交叉分段PCA在锅炉故障诊断中的应用[J]. *信息与控制*, 2020, 49(4): 507-512.  
Wang Wenbiao, Tian Zhiyuan, Wang Siyuan, et al. Optimal Operation Method Based on Cross and Piecewise PCA for Industrial Boilers[J]. *Information and Control*, 2020, 49(4): 507-512.
- [7] Wang Y, Si Y, 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* (S0008-4034), 2018, 96(10): 2073-2085.
- [8] Zhou Z, Wen C, Yang C. Fault Detection using Random Projections and k-nearest Neighbor Nule for Semiconductor Manufacturing Processes[J]. *IEEE Transactions on Semiconductor Manufacturing* (S0894-6507), 2014, 28(1): 70-79.
- [9] MacGregor J F, Jaeckle C, Kiparissides C, et al. Process Monitoring and Diagnosis by Multiblock PLS Methods [J]. *AIChE Journal* (S0001-1541), 1994, 40(5): 826-838.
- [10] Ge Z, Song Z. Distributed PCA Model for Plant-wide Process Monitoring[J]. *Industrial & Engineering Chemistry Research* (S0888-5885), 2013, 52(5): 1947-1957.
- [11] Ge Z, Zhang M, Song Z. Nonlinear Process Monitoring Based on Linear Subspace and Bayesian Inference[J]. *Journal of Process Control* (S0959-1524), 2010, 20(5): 676-688.
- [12] Jiang Q, Wang B, Yan X. Multiblock Independent Component Analysis Integrated with Hellinger Distance and Bayesian Inference for Non-Gaussian Plant-wide Process Monitoring[J]. *Industrial & Engineering Chemistry Research* (S0888-5885), 2015, 54(9): 2497-2508.
- [13] 王振雷, 江伟, 王昕. 基于多块MICA-PCA的全流程过程监控方法[J]. *控制与决策*, 2018, 33(2): 269-274.  
Wang Zhenlei, Jiang Wei, Wang Xin. Plant-wide Process Monitoring Based on Multiblock MICA-PCA[J]. *Control and Decision*, 2018, 33(2): 269-274.
- [14] 顾炳斌, 熊伟丽. 基于多块信息提取的PCA故障诊断方法[J]. *化工学报*, 2019, 70(2): 316-329.  
Gu Bingbin, Xiong Weili. Fault Diagnosis Based on PCA Method with Multi-block Information Extraction[J]. *CIESC Journal*, 2019, 70(2): 316-329.
- [15] He P Q, Wang J. Fault Detection Using the k-nearest Neighbor Rule for Semiconductor Manufacturing Processes[J]. *IEEE Transactions on Semiconductor Manufacturing* (S0894-6507), 2007, 20(4): 345-354.
- [16] 张成, 郭青秀, 冯立伟, 等. 基于局部保持投影-加权k近邻规则的多模态间歇过程故障检测策略[J]. *控制理论与应用*, 2019, 36(10): 1682-1689.  
Zhang Chen, Guo Qingxiu, Feng Liwei, et al. Fault Detection Strategy Based on Locality Preserving Projections-weighted k Nearest Neighbors in Multimodal Batch Processes[J]. *Control Theory & Applications*, 2019, 36(10): 1682-1689.
- [17] 郭金玉, 刘玉超, 李元. 基于局部相对概率密度kNN的多模态过程故障检测[J]. *高校化学工程学报*, 2019, 33(1): 159-166.  
Guo Jinyu, Liu Yuchao, Li Yuan. Multimodal Process Fault Detection Based on Local Relative Probability Density kNN[J]. *Journal of Chemical Engineering of Chinese Universities*, 2019, 33(1): 159-166.
- [18] 刘腾飞. 基于深层自编码器的发酵过程故障监测[D]. 北京: 北京工业大学, 2020: 54-64.  
Liu Tengfei. Fault Monitoring of Fermentation Process Based on Deep Auto-encoder[D]. Beijing: Beijing University of Technology, 2020: 54-64.
- [19] 张成, 高宪文, 徐涛, 等. 基于独立元的k近邻故障检测策略[J]. *控制理论与应用*, 2018, 35(6): 805-812.  
Zhang Chen, Gao Xianwen, Xu Tao, et al. Fault Detection Strategy of Independent Component-Based k Nearest Neighbor Rule[J]. *Control Theory & Applications*, 2018, 35(6): 805-812.
- [20] 马贺贺, 胡益, 侍洪波. 基于距离空间统计量分析的多模态过程无监督故障检测[J]. *化工学报*, 2012, 63(3): 873-880.  
Ma Hehe, Hu Yi, Shi Hongbo. Unsupervised Fault Detection for Multimode Processes using Distance Space Statistics Analysis[J]. *CIESC Journal*, 2012, 63(3): 873-880.
- [21] Zhu W, Sun W, Romagnoli J. Adaptive k-Nearest-Neighbor Method for Process Monitoring[J]. *Industrial & Engineering Chemistry Research* (S0888-5885), 2018, 57(7): 2574-2586.
- [22] Zhou Z, Wen C, Yang C. Fault Isolation Based on k-Nearest Neighbor Rule for Industrial Processes[J]. *IEEE Transactions on Industrial Electronics* (S0278-0046), 2016, 63(4): 2578-2586.
- [23] Shen B, Ge Z. Supervised Nonlinear Dynamic System for Soft Sensor Application Aided by Variational Auto-encoder[J]. *IEEE Transactions on Instrumentation and Measurement* (S0018-9456), 2020, 69(9): 6132-6142.



- [24] Chen Z, Li W. Multisensor Feature Fusion for Bearing Fault Diagnosis Using Sparse Autoencoder and Deep Belief Network[J]. IEEE Transactions on Instrumentation and Measurement (S0018-9456), 2017, 66(7): 1693-1702.
- [25] Ge Z, Song Z. Multimode Process Monitoring Based on Bayesian Method[J]. Journal of Chemometrics (S0886-9383), 2009, 23(12): 636-650.
- [26] Yin S, Ding S X, Haghani A, et al. A Comparison Study of Basic Data-driven Fault Diagnosis and Process Monitoring Methods on the Benchmark Tennessee Eastman Process [J]. Journal of Process Control (S0959-1524), 2012, 22(9): 1567-1581.
- [27] 郭金玉, 王鑫, 李元. 基于集成核局部保持投影算法的故障检测[J]. 信息与控制, 2018, 47(2): 191-199.  
Guo Jinyu, Wang Xin, Li Yuan. Fault Detection Based on Ensemble Kernel Locality Preserving Projections[J]. Information and Control, 2018, 47(2): 191-199.
- [28] Li N, Yang Y. Ensemble Kernel Principal Component Analysis for Improved Nonlinear Process Monitoring [J]. Industrial & Engineering Chemistry Research (S0888-5885), 2015, 54(1): 318-329.