

2-15-2024

## Fault Detection Based on Sliding Window and Multiblock Convolutional Autoencoders

Jianpeng Mou

*School of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China, 1121059781@qq.com*

Weili Xiong

*School of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China; Key Laboratory of Advanced Process Control for Industry (Ministry of Education), 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. For more information, please contact [xtfzxb@126.com](mailto:xtfzxb@126.com).

---

# Fault Detection Based on Sliding Window and Multiblock Convolutional Autoencoders

## Abstract

**Abstract:** In order to further improve the fault detection performance and fully mine the timing and hidden feature information, a fault detection method based on convolutional auto encoder is proposed. On the basis of modeling the original information set, the modeling of cumulative information and rate of change information is added to enhance the mining of implicit information; The three reconstructed information sets are sampled by sliding windows, and time series feature extraction and modeling are performed based on convolutional auto encoders. Bayesian fusion of the decision results of the convolutional auto encoder is performed to obtain the statistics, and the control limit is determined by the method of kernel density estimation for fault detection. The method is numerically simulated and applied in TE process, and the simulation results confirm the effectiveness and detection performance.

## Keywords

fault detection, convolutional autoencoder, multiblock modeling, sliding window, Bayesian fusion

## Recommended Citation

Mou Jianpeng, Xiong Weili. Fault Detection Based on Sliding Window and Multiblock Convolutional Autoencoders[J]. Journal of System Simulation, 2024, 36(2): 423-435.

## 基于滑动窗和多块卷积自编码器的故障检测

牟建鹏<sup>1</sup>, 熊伟丽<sup>1,2</sup>

(1. 江南大学 物联网工程学院, 江苏 无锡 214122; 2. 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)

**摘要:** 为了进一步提升故障检测性能, 充分挖掘时序和隐含特征信息, 提出一种基于卷积自编码器的故障检测方法。在对原始信息集进行建模的基础上增加了对累计信息与变化率信息的建模, 以增强对隐含信息的挖掘; 对重构的3个信息集进行滑动窗采样, 基于卷积自编码器进行时序特征提取和建模; 将卷积自编码器的决策结果进行贝叶斯融合得到统计量, 并用核密度估计的方法确定控制限从而进行故障检测。将该方法进行数值仿真并应用于TE过程, 仿真结果验证了所提方法的有效性和检测性能。

**关键词:** 故障检测; 卷积自编码器; 多块建模; 滑动窗; 贝叶斯融合

中图分类号: TP277

文献标志码: A

文章编号: 1004-731X(2024)02-0423-13

DOI: 10.16182/j.issn1004731x.joss.22-1059

**引用格式:** 牟建鹏, 熊伟丽. 基于滑动窗和多块卷积自编码器的故障检测[J]. 系统仿真学报, 2024, 36(2): 423-435.

**Reference format:** Mou Jianpeng, Xiong Weili. Fault Detection Based on Sliding Window and Multiblock Convolutional Autoencoders[J]. Journal of System Simulation, 2024, 36(2): 423-435.

## Fault Detection Based on Sliding Window and Multiblock Convolutional Autoencoders

Mou Jianpeng<sup>1</sup>, Xiong Weili<sup>1,2</sup>

(1. School of Internet of Things Engineering, Jiangnan University, Wuxi 214122, China;

2. Key Laboratory of Advanced Process Control for Industry (Ministry of Education), Jiangnan University, Wuxi 214122, China)

**Abstract:** In order to further improve the fault detection performance and fully mine the timing and hidden feature information, a fault detection method based on convolutional auto encoder is proposed. On the basis of modeling the original information set, the modeling of cumulative information and rate of change information is added to enhance the mining of implicit information; The three reconstructed information sets are sampled by sliding windows, and time series feature extraction and modeling are performed based on convolutional auto encoders. Bayesian fusion of the decision results of the convolutional auto encoder is performed to obtain the statistics, and the control limit is determined by the method of kernel density estimation for fault detection. The method is numerically simulated and applied in TE process, and the simulation results confirm the effectiveness and detection performance.

**Keywords:** fault detection; convolutional autoencoder; multiblock modeling; sliding window; Bayesian fusion

## 0 引言

随着科学技术的发展, 工业过程日益复杂, 实施高效的故障检测能够及时报警, 保证工业过

程与设备稳定运行, 减少财产损失与人员伤亡<sup>[1-2]</sup>。目前常用的故障检测方法分为基于机理模型、基于知识和基于数据驱动的方法等<sup>[3]</sup>。

复杂工业过程的机理模型难以精确建立, 基

收稿日期: 2022-09-08

修回日期: 2022-11-15

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)

第一作者: 牟建鹏(1998-), 男, 硕士生, 研究方向为过程监测。E-mail: 1121059781@qq.com

于知识的方法需要大量的故障样本, 获取难且成本高, 基于数据驱动的故障检测方法可以仅用正常的样本建立模型, 因此, 基于数据驱动的故障检测方法得到了许多学者的关注<sup>[4]</sup>。深度学习与其他传统的数据驱动方法相比, 能够通过多层非线性映射, 从数据中提取更深层的抽象特征, 具有强大的数据建模能力<sup>[5-6]</sup>。常用的深度学习故障检测方法有卷积神经网络<sup>[7]</sup>、长短时记忆网络<sup>[8]</sup>、生成对抗网络<sup>[9]</sup>和卷积自编码器<sup>[10]</sup>(convolutional autoencoder, CAE)等。其中, CAE不需要对原有数据的分布进行假设, 适用于非线性特征的提取<sup>[11]</sup>。然而, 传统的 CAE 在数据样本不平衡时, 难以获得较好的检测效果。为提高 CAE 的精度与效率, 学者们提出了许多改进的 CAE 以更好地实现故障检测。Chen 等<sup>[12]</sup>提出的卷积稀疏自编码器能够自动从数据集中提取特征, 并创建故障检测与分类的框架。Yu 等<sup>[13]</sup>提出了一种卷积长短时自编码器, 用卷积长短时记忆网络来刻画过程数据的分布, 学习时间序列数据的有效特征, 增强了故障检测的能力。孙海蓉等<sup>[14]</sup>提出了一种深度卷积自编码器网络, 能够自动学习小样本中的有效特征。但这些方法对于具有微小偏差的故障不够敏感, 不利于对微小故障的检测。赵小强等<sup>[15]</sup>针对过程数据的时变性, 通过滑动窗(sliding window, SW)<sup>[16]</sup>更新数据, 实时更新模型与监测统计量。陈含智等<sup>[17]</sup>利用滑动窗内的历史信息实时估计观测噪声方差矩阵, 进而构建故障检测量与识别量, 对故障进行检测与识别。这些基于 CAE 的方法通过对网络结构的改进有效地提升了故障检测效率, 但随着工业数据维数升高, 全局建模的故障检测方法不利于故障检测精度的提高<sup>[18]</sup>。

针对复杂的工业过程, 通常采用多块建模的策略提取信息低复杂性。Ge 等<sup>[19]</sup>通过主成分分析方法(principal component analysis, PCA)构造子块,

划分特征空间, 构造了多块分布式主成分分析模型, 既能反映局部特征, 又能够提高检测能力。何永建<sup>[20]</sup>将高维数据划分成多个子块单元, 并对各子块单元用偏最小二乘法处理。朱家桢等<sup>[21]</sup>提出多块 CAE 的故障检测方法, 采取局部提取和全局整合的特征提取策略对过程数据中的特征进行提取。这些方法能够分离出具体的故障单元, 再从具体的单元分析具体的故障原因<sup>[22-23]</sup>。Ge 等<sup>[24]</sup>基于 PCA 分解方法构造线性子空间, 将各子空间的决策结果进行融合。但这些多块建模方法对数据的隐含信息挖掘不足。郭大权等<sup>[25]</sup>提出了多块信息(multi-block information, MBI)提取的 PCA 故障检测方法, 构造相关性信息子块、变化率信息子块和累计误差信息子块以提取隐含特征, 最后用贝叶斯融合进行故障检测<sup>[24]</sup>, 但该方法受数据的高斯分布假设以及变量线性相关性约束, 不利于在非高斯非线性情况下进行故障检测。

综上所述, 本文提出一种基于滑动窗和多块卷积自编码器(sliding window and multi-block information convolutional autoencoder, SW-MBI-CAE)的故障检测方法。一方面, 基于原始数据构建变化率信息子块与累计信息子块, 分别训练 3 个子块对应的卷积自编码器, 融合各子块的决策结果, 对原始子块的隐含信息进行挖掘。另一方面, 使用滑动窗进行样本采样, 用基于滑动窗的卷积自编码器方法, 在提取样本时序信息的同时, 扩大了样本维度, 实现了误差的累计, 提升了算法对微小故障的检测能力。

## 1 基于卷积自编码器的故障检测原理

自编码器是一种无监督的网络模型, 由编码器与解码器构成, 在数据压缩与特征提取方面效果显著。在自编码器中可以加入卷积层或者长短时记忆网络层以加强网络学习特征的能力。本文采用的卷积自编码器结构如图 1 所示。

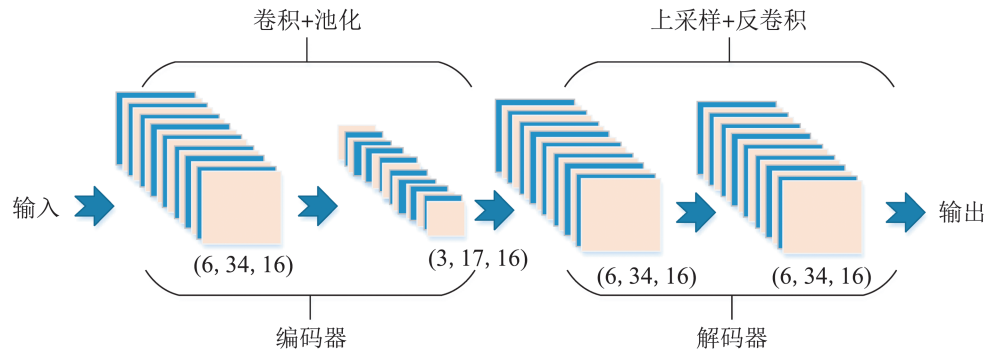


图1 卷积自编码器结构  
Fig. 1 Convolutional autoencoder architecture

用正常样本训练卷积自编码器得到故障检测模型, 将正常样本与重构样本之间的欧氏距离作为统计量, 用核密度估计的方法求得控制限, 核密度函数的计算公式为

$$\hat{f}_h(\mathbf{x}) = \frac{1}{n} \sum_{i=1}^n K_h(\mathbf{x} - \mathbf{x}_i) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{\mathbf{x} - \mathbf{x}_i}{h}\right) \quad (1)$$

式中:  $\mathbf{x}_i$  为独立同分布的样本点;  $n$  为独立同分布样本点的数量;  $K(\cdot)$  为核函数;  $K_h(\mathbf{x})$  为缩放核函数;  $h$  为带宽。卷积自编码器模型无法较好地重构异常样本, 因而得到的统计量较大。将测试样本的统计量与控制限比较, 若测试样本的统计量超过控制限, 则认为样本异常; 反之, 样本正常。卷积定义为

$$y_{i,j} = \sum_{u=1}^U \sum_{v=1}^V \mathbf{K}_{u,v} \mathbf{I}_{i-u+1,j-v+1} \quad (2)$$

式中:  $\mathbf{I}$  为给定输入样本; 卷积核  $\mathbf{K}$  的大小为  $U \times V$ ;  $y$  为输出。不同的卷积核可以提取不同的特征, 卷积操作实现了局部感知与参数共享, 极大地减少了计算量, 加快了运算速度<sup>[26]</sup>。

自编码器包含输入层、输出层和隐含层, 输出数据是对输入的重构, 用正常的样本进行训练, 尽量减少代价函数的值, 代价函数定义为

$$J_{\text{MSE}}(\mathbf{x}, \hat{\mathbf{x}}) = \frac{1}{m} \sum_{i=1}^m \left( \frac{1}{2} \|\mathbf{x}^{(i)} - \hat{\mathbf{x}}^{(i)}\|^2 \right) \quad (3)$$

式中:  $\|\mathbf{x}^{(i)} - \hat{\mathbf{x}}^{(i)}\|^2$  为输入与重构之间的欧氏距离。优化器使用 adam, 激活函数为 ReLU 函数, 卷积

操作为填充卷积, 池化采用最大池化。欧氏距离能够表征 2 个样本间的相似程度, 欧氏距离越小, 样本相似程度越大; 欧氏距离越大, 样本间的相似程度越小。

## 2 基于滑动窗和多块卷积自编码器的故障检测方法

### 2.1 基于滑动窗的 CAE 故障检测方法

滑动窗是对原有样本进行重新采集的一种方式, 对于给定的样本数据集  $D = \{\mathbf{z}_i | \mathbf{z}_i \in \mathbb{R}^{m \times 1}, i = 1, 2, \dots, n\}$ ,  $m$  为变量个数, 经过滑动窗采样后形成新的样本集

$$W_i = \{\mathbf{z}_i, \mathbf{z}_{i+1}, \dots, \mathbf{z}_{i+L_x-1}\}, i \leq n - L_x + 1 \quad (4)$$

式中:  $L_x$  为滑动窗的宽度;  $n$  为样本数量。经过滑动窗采样后, 样本的数目会损失  $(L_x - 1)$  个。

采用正常工况数据训练卷积自编码器, 通过对特征的学习, 能够近似地还原正常样本, 使正常样本与其重构数据之间的欧氏距离在一定的阈值范围内。而对于异常样本, 卷积自编码器并不能很好地还原异常样本的数据分布, 导致异常样本与其重构数据间的欧氏距离相较于正常样本会偏大。因此, 利用滑动窗技术, 对重构后的样本集进行重采样, 使样本数据量增大的同时, 异常样本与其重构间的相似度相较于正常样本更小, 提升了故障检测性能。滑动窗原理图如图 2 所示。




图2 滑动窗原理图  
Fig. 2 Sliding window schematic

算法 SW-CAE伪代码

1. 训练数据  $Z$  归一化为  $Z_1$
2. 用滑动窗采样  $Z_1$  得到数据集  $W$
3. 用卷积自编码器对数据集  $W$  进行训练，得到重构  $W_1$ ，计算  $W$  与  $W_1$  之间的欧氏距离得到统计量，利用核密度估计的方法得到控制限  $D_l$

4. 在线检测：

测试样本  $Z_i$  归一化得到  $Z_{i'}$

用滑动窗采样得到数据集  $W_2$

计算  $W_2$  与重构  $W_3$  之间的欧氏距离  
得到统计量  $D_\mu$ ，将  $D_\mu$  与  $D_l$  比较

若  $D_\mu \leq D_l$ ，样本正常

若  $D_\mu > D_l$ ，样本异常

## 2.2 多块建模策略

在现代工业中过程变量大多来自不同的操作单元，全局建模策略有统计量计算成本高、不易解释等问题。为充分挖掘原始数据集的隐含信息，

本文增加对累计信息和变化率信息的提取，构建累计信息子块和变化率信息子块，然后基于滑动窗的CAE故障检测方法，分别对3个子块进行建模，多块建模策略如图3所示。

累计信息是指一定时间段内数据的累加和，当数据出现微小偏移时，通过累加作用，可以将偏移进行放大，从而增强对微小偏移故障的检测。累计信息的计算方式为

$$M_i = \sum_{i=1}^{i+T} z_i \quad (5)$$

假设标准化后的原始数据集为  $D = \{z_i | z_i \in \mathbb{R}^{m \times 1}, i = 1, 2, \dots, n\}$ ，则累计信息集为  $D_1 = \{M_i | M_i \in \mathbb{R}^{m \times 1}, i = 1, 2, \dots, n - T\}$ 。

变化率信息是指后一时刻样本与前一时刻样本之间的差，变化率信息反映了样本数据变化的程度。利用变化率信息建模能够增强模型对振荡类型故障的检测能力。由于累计信息丢失了  $T$  个样本，为了统一数据集的规模大小， $D_2 = \{N_i | N_i \in \mathbb{R}^{m \times 1}, i = 1, 2, \dots, n - T\}$  为得到的变化率信息集。变化率信息计算方式为

$$N_i = z_{i+T} - z_{i+T-1} \quad (6)$$

综上，在原始信息集的基础上，构建变化率信息集与累计信息集，实现对隐含信息的挖掘。原始信息集使最终的误报率保持在较低水平；通过提取累计信息可以放大故障变量的偏移和缓变；提取变化率信息可以提高振荡类型故障的检测。

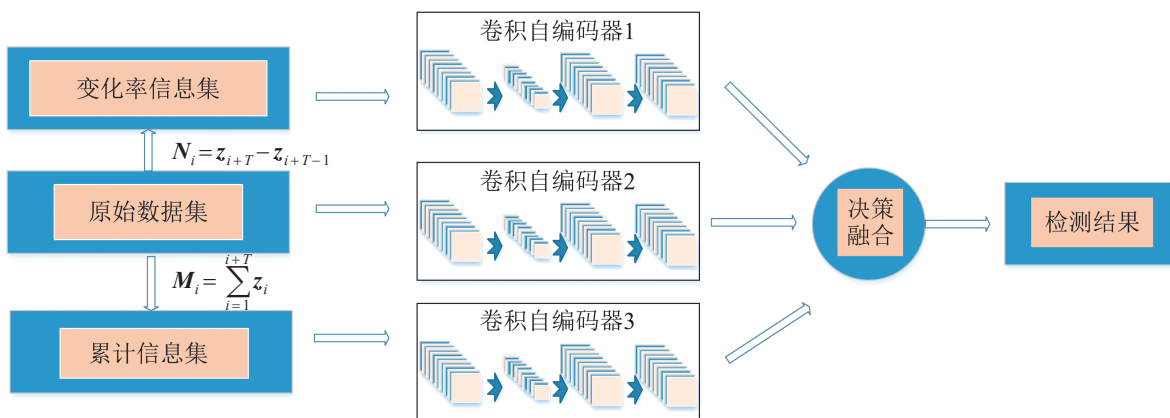


图3 多块建模策略  
Fig. 3 Multiblock modeling strategies

## 2.3 基于滑动窗和多块卷积自编码器的故障检测

CAE故障检测方法采用样本重构误差统计量, 用核密度估计的方法得到控制限。由于3个子块对同一个待测样本计算所得统计量与控制限均不一致, 因此, 各子块模型对于待测样本是否故障的决策也不一致, 不利于检测。在求取3个子块的统计量与控制限后, 对其采用贝叶斯融合, 根据融合后的统计量与控制限进行最终决策。

给定  $\mathbf{z}_\mu \in \mathbf{Z}_{\text{test}}$  为一待测样本,  $\mathbf{z}_\mu^{(1)}$ 、 $\mathbf{z}_\mu^{(2)}$ 、 $\mathbf{z}_\mu^{(3)}$  分别为原始数据子块、变化率信息子块和累计信息子块。根据子块  $i$  的统计量  $D_\mu$  以及控制限  $D_i$  计算子块  $i$  中待测样本故障的概率:

$$P_{D^2}(F|\mathbf{z}_\mu^{(i)}) = \frac{P_{D^2}(\mathbf{z}_\mu^{(i)}|F)P_{D^2}(F)}{P_{D^2}(\mathbf{z}_\mu^{(i)}|F)P_{D^2}(F) + P_{D^2}(\mathbf{z}_\mu^{(i)}|N)P_{D^2}(N)} \quad (7)$$

式中:  $P_{D^2}(F)$  为样本故障的先验概率, 其值为  $1-\gamma$ ;  $P_{D^2}(N)$  为样本正常的先验概率, 其值为  $\gamma$ ;  $P_{D^2}(\mathbf{z}_\mu^{(i)}|F)$ 、 $P_{D^2}(\mathbf{z}_\mu^{(i)}|N)$  分别为样本异常与正常的似然函数。似然函数定义如下:

$$P_{D^2}(\mathbf{z}_{\text{test}}^{(i)}|N) = e^{-D_{i,\mu}^2/D_{i,N}^2} \quad (8)$$

$$P_{D^2}(\mathbf{z}_{\text{test}}^{(i)}|F) = e^{-D_{i,\mu}^2/D_{i,F}^2}$$

以各子块样本异常的似然函数作为权值, 加权计算各个子块待测样本  $\mathbf{z}_\mu$  为故障的概率, 最终得到贝叶斯融合后的统计量, 即样本故障的概率:

$$B_{D^2}(\mathbf{z}_\mu) = \sum_{i=1}^3 \left( \frac{P_{D^2}(\mathbf{z}_\mu^{(i)}|F)P_{D^2}(F|\mathbf{z}_\mu^{(i)})}{\sum_{j=1}^3 P_{D^2}(\mathbf{z}_\mu^{(j)}|F)} \right) \quad (9)$$

融合后控制限为  $1-\gamma$ ,  $\gamma$  为置信度, 当  $B_{D^2} > 1-\gamma$ , 样本异常; 否则, 样本正常。

基于滑动窗和多块卷积自编码器的故障检测流程如图4, 具体步骤如下。

step 1: 对原始数据集归一化操作并进行信息提取, 得到原始信息集、累计信息集以及变化率信息集3个子块。

step 2: 对得到的变化率信息集和累计信息集进行归一化操作, 方便后期训练。

step 3: 对3个子块分别用滑动窗采样, 得到送入卷积自编码器进行训练的样本。

step 4: 用自编码器对3个子块进行训练, 求得训练样本与其重构样本间的欧氏距离作为统计量, 用核密度函数方法获得3个子块控制限。

step 5: 采用贝叶斯融合方法, 将各个子块统计量进行融合得到融合后的统计量, 根据置信度  $\gamma$  得到控制限, 对于测试样本, 如果统计量大于控制限, 则样本异常; 统计量  $\leq$  控制限, 则样本正常。

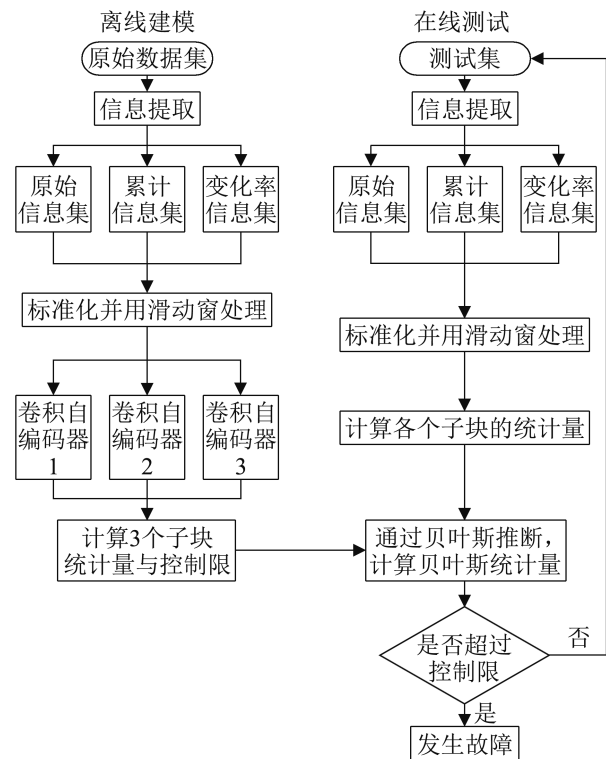


图4 SW-MBI-CAE故障检测流程图  
Fig. 4 SW-MBI-CAE fault detection flow chart

## 3 仿真实验

### 3.1 数值仿真

采用一个数值仿真<sup>[27]</sup>验证所提方法对微小偏移及振荡类型故障的检测效果, 其结构为

$$\begin{aligned}
 z_1 &= 0.5768x_1 + 0.3766x_2 + e_1 \\
 z_2 &= 0.3982x_1 + 0.3566x_2 + e_2 \\
 z_3 &= 0.829x_1 + 0.401x_2 + 0.243x_3 + 0.852x_4 + e_3 \\
 z_4 &= 0.358x_2 + 1.768x_3 + 0.852x_4 + e_4 \\
 z_5 &= 1.393x_3 + 0.804x_4 + e_5
 \end{aligned}
 \tag{10}$$

式中： $z_i$ 为因变量； $x_i$ 为自变量，服从[0,0.5]上的均匀分布； $e_i$ 为干扰变量，服从正态分布，均值为0，方差为0.01。

仿真共产生800组正常样本作为训练集，测试集同样为800个样本，前400个为正常样本，后400个为故障样本，故障设置如下。

故障1：从第401个样本开始，加入幅值为0.01的斜坡信号，直至第600个样本结束。

故障2：从第601个样本开始，加入幅值为0.9的脉冲信号，直至第800个样本结束。

仿真实验分为2组进行：基于多块卷积自编码器的数值仿真；基于滑动窗和多块卷积自编码器的数值仿真。通过网格选取的方式，确定累计信息集参数 $T=5$ ，滑动窗宽度 $L_x=6$ 。表1中CAE方法滑动窗宽度是1，报警率为66.25%；SW-CAE方法滑动窗宽度为6，报警率为89.5%。通过报警率的对比，可以体现滑动窗宽度对实验结果影响显著。

表1 微小偏移及振荡类型故障误报率与报警率  
Table 1 False alarm rate and alarm rate of minor deviation and oscillation type faults

方法	误报率	报警率
CAE	0.005 0	0.662 5
SW-CAE	0.010 1	0.895 0
MBI-CAE	0.002 5	0.852 5
SW-MBI-CAE	0.005 1	0.942 5

图5~6为MBI-CAE和SW-MBI-CAE方法检测效果图。通过图5~6中的子块2与子块1对比可以看出，累计信息集对微弱的斜坡信号进行了累计，从而能够加强对微弱的斜坡信号的检测效果，但对于微弱的振荡信号效果变差；子块3与子块1的对比可以看出，变化率信息能够对微弱的振荡信号进行放大，但是对斜坡信号几乎没有作用。最终融合效果，综合了各个信息集的优点，增强了

对微弱的振荡信号以及斜坡信号的检测。实际工业过程尤其是化工过程的数据采集涉及大量仪表，仪表故障通常有偏差阶跃、冲击、漂移，以及周期振荡等4种，所提算法能够放大故障变量的偏移和变化并提高振荡类型故障的检测，对实际工业过程具有一定的应用价值。

滑动窗的使用，将累计信息集与变化率信息集的作用加强，使得故障样本与正常样本的差距进一步增大，更加容易区分正常样本与故障样本。尽管从子块2来看，滑动窗的效果不是很明显，但通过3个子块的融合，最终效果有了明显提升。

表1中给出了4种方法的检测结果，CAE方法与MBI-CAE方法相比，多子块的使用具有明显的效果，大幅提升报警率的同时，误报率也有所降低；MBI-CAE方法与SW-MBI-CAE方法两者误报率相差无几，后者的报警率有较大程度的提高。滑动窗与多块信息相结合，使得多块信息的优点进一步放大，对于微小偏移及振荡类型故障能够更加有效地检测。

### 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，旨在对化工过程的过程控制以及检测方法进行评价<sup>[9]</sup>。整个过程包含22个数据集，其中，1个是全部为正常样本的数据集，另外21个均包含故障样本。每个数据集采集历时2 d，每经过3 min采集一次数据，对于包含故障样本的数据集，在第8小时开始加入故障，每个包含故障样本的数据集有160个正常样本，800个异常样本。通过网格选取的方法， $T$ 取5，滑动窗的宽度 $L_x$ 取6，会损失掉前10个正常样本，故数值仿真的故障从151个样本开始。采用TE过程的11个操纵变量、22个测量变量和一个系数为0的伪变量作为样本，用于故障检测。表2给出了采用MBI-CAE和SW-MBI-CAE方法得到的各个子块的报警率以及平均误报率。

TE过程采用的卷积自编码器结构如图7所示。



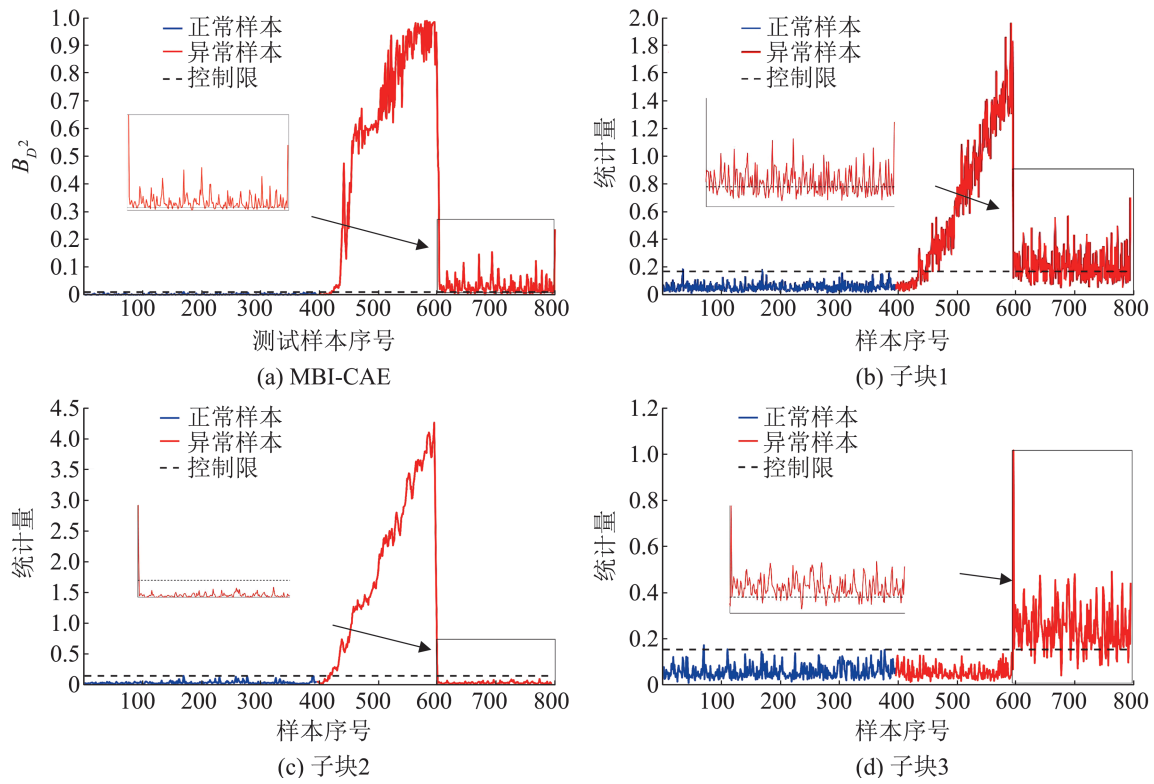


图 5 MBI-CAE 及其各子块检测效果  
Fig. 5 Detection effect of MBI-CAE and its sub-blocks

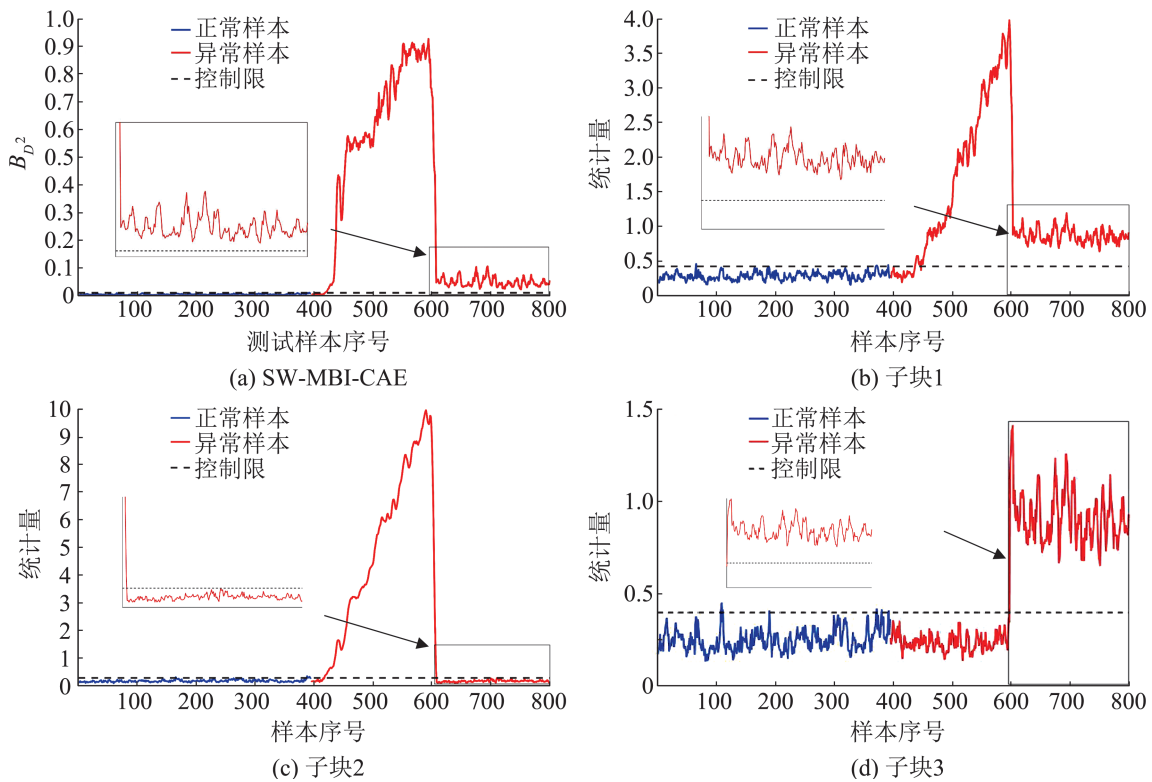


图 6 SW-MBI-CAE 及其各子块检测效果  
Fig. 6 SW-MBI-CAE and its sub-block detection effect

表 2 MBI-CAE 与 SW-MBI-CAE 故障检测结果对比  
Table 2 Comparison of fault detection results between MBI-CAE and SW-MBI-CAE

故障编码	MBI-CAE				SW-MBI-CAE			
	子块 1	子块 2	子块 3	BIC	子块 1	子块 2	子块 3	BIC
1	0.996 2	0.995 0	0.077 5	0.995 0	0.998 7	0.998 7	0.122 0	0.992 5
2	0.985 0	0.983 8	0.013 8	0.985 0	0.998 7	0.998 7	0.018 9	0.982 5
3	0.042 5	0.102 5	0.007 5	0.0737	0.035 2	0.135 8	0.007 5	0.041 3
4	0.972 5	1	0.018 7	1	1	1	0.020 1	1
5	0.255 0	0.882 5	0.071 2	0.828 7	0.254 1	0.932 1	0.084 3	0.833 7
6	1	0.998 8	0.051 2	1	1	1	0.054 1	1
7	1	0.998 8	0.187 5	1	1	1	0.236 5	1
8	0.975 0	0.978 8	0.423 8	0.977 5	0.978 6	0.986 2	0.636 5	0.977 5
9	0.035 0	0.072 5	0.025 0	0.063 8	0.055 3	0.117 0	0.039 0	0.055 0
10	0.450 0	0.600 0	0.095 0	0.611 2	0.508 2	0.667 9	0.150 9	0.625 0
11	0.683 7	0.920 0	0.077 5	<b>0.938 7</b>	0.836 5	0.988 7	0.168 6	<b>0.975 0</b>
12	0.985 0	0.996 2	0.783 7	0.995 0	0.997 5	1	0.953 5	1
13	0.947 5	0.953 7	0.561 3	0.950 0	0.950 9	0.957 1	0.704 4	0.947 5
14	1	0.778 3	0.998 8	1	1	1	1	0.998 8
15	0.071 2	0.170 0	0.015 0	<b>0.135 0</b>	0.088 1	0.223 9	0.039 0	<b>0.165 0</b>
16	0.253 7	0.440 0	0.106 2	0.430 0	0.281 8	0.517 0	0.140 9	0.452 5
17	0.900 0	0.976 2	0.287 5	0.976 2	0.947 2	0.979 9	0.359 7	0.975 0
18	0.9900 0	0.911 3	0.178 7	0.903 8	0.906 9	0.917 0	0.188 7	0.900 0
19	0.155 0	0.112 5	0.418 8	<b>0.463 8</b>	0.654 1	0.293 1	0.903 1	<b>0.856 2</b>
20	0.470 0	0.632 5	0.127 5	<b>0.598 8</b>	0.545 9	0.734 6	0.240 3	<b>0.640 0</b>
21	0.383 7	0.601 2	0.008 8	0.570 0	0.410 1	0.639 0	0.020 1	0.575 0
平均报警率	0.641 0	0.719 2	0.215 9	<b>0.737 9</b>	0.688 0	0.766 0	0.289 9	<b>0.761 5</b>
平均误报率	0.024 4	0.052 5	0.008 0	0.040 8	0.023 9	0.080 0	0.013 9	0.034 2

注：子块 1 是原始数据集；子块 2 是累计信息集；子块 3 是变化率信息集；BIC 是贝叶斯融合后的结果。




图 7 TE 过程卷积自编码器结构图

Fig. 7 TE process convolutional autoencoder structure diagram

通过表2可知, 子块2对子块1的故障信息进行了放大, 使报警率得到了提升, 有助于融合后的报警率提升; 子块3平均报警率较差, 但是对于一些故障, 例如, 故障19的报警率要优于子块1, 并且子块3的平均误报率较低, 对于融合后报警率的提高以及误报率的降低都有重要作用。分析 MBI-CAE 和 SW-MBI-CAE 方法得到的数据可以看出, 采用滑动窗后, 综合考虑了更多数据, 某些故障信息进一步放大, 例如, 故障11、15、19和20, 相较于子块1, 在报警率得到了一定程度提升的同时, 误报率有所降低。

图8~12为故障11、15、19、20使用 MBI-CAE 和 SW-MBI-CAE 方法的效果图。故障11为反

应器冷却水入口温度发生变化, 故障15为冷凝器冷却水阀门, 故障19与20为未知故障, 故障19更为明显。未使用滑动窗之前, 报警率为0.4638, 大量数据位于控制限以下; 使用滑动窗后, 报警率为0.8562, 异常样本与正常样本相对距离拉大, 更易于区分。

表3给出了5种方法的比较结果, 相较于 LNSPPCAST、KECA、CAE、MBI-CAE 方法, SW-MBI-CAE 在误报率相差不大的情况下, 平均报警率分别提升了0.1705、0.0787、0.0849、0.0282。SW-MBI-CAE 方法在故障5、11、12、19、21的检测上均优于前4种方法, 在平均报警率上也有较大优势。




图8 故障11两种方法检测结果  
Fig. 8 Fault 11 test results of two methods




图9 故障15两种方法检测结果  
Fig. 9 Fault 15 test results of two methods




图 10 故障 19 两种方法检测结果  
Fig. 10 Fault 19 test results of two methods




图 11 故障 20 两种方法检测结果  
Fig. 11 Fault 20 test results of two methods




图 12 故障 20 两种方法局部检测结果  
Fig. 12 Fault 20 local detection results of two methods

表3 5种方法在TE过程中的检测结果  
Table 3 Detection results of 5 methods in TE process

故障编码	LNSPPCAST <sup>[28]</sup>	KECA <sup>[29]</sup>	CAE	MBI-CAE	SW-MBI-CAE
1	0.996 9	<b>0.997 5</b>	0.992 5	0.995 0	0.992 5
2	<b>0.988 1</b>	0.981 3	0.982 5	0.985 0	0.982 5
4	0.068 1	<b>1</b>	<b>1</b>	<b>1</b>	<b>1</b>
5	0.513 1	0.246 3	0.258 7	0.828 7	<b>0.833 7</b>
6	0.981 3	<b>1</b>	<b>1</b>	<b>1</b>	<b>1</b>
7	0.251 9	<b>1</b>	<b>1</b>	<b>1</b>	<b>1</b>
8	<b>0.981 2</b>	0.973 8	0.972 5	0.9775	0.977 5
10	<b>0.892 5</b>	0.691 3	0.505 0	0.611 2	0.625 0
11	0.916 3	0.742 5	0.831 2	0.938 7	<b>0.975 0</b>
12	0.670 6	0.991 3	0.995 0	0.995 0	<b>1</b>
13	<b>0.951 9</b>	0.951 3	0.945 0	0.950 0	0.947 5
14	0.986 3	<b>1</b>	0.998 7	<b>1</b>	0.998 8
16	0.063 1	<b>0.858 5</b>	0.280 0	0.430 0	0.452 5
17	0.936 3	0.928 8	0.942 5	<b>0.976 2</b>	0.975 0
18	0.845 0	0.896 3	0.901 2	<b>0.903 8</b>	0.900 0
19	0.619 4	0.157 5	0.650 0	0.463 8	<b>0.856 2</b>
20	<b>0.941 3</b>	0.473 8	0.542 5	0.598 8	0.640 0
21	0.059 4	0.425 0	0.407 5	0.570 0	<b>0.575 0</b>
平均报警率	0.703 5	0.795 3	0.789 1	0.845 8	<b>0.874 0</b>

## 4 结论

本文方法基于卷积自编码器对滑动窗采样的数据进行时序特征提取, 提升了模型的故障检测能力; 使用滑动窗实现误差累计, 能够提高对微小故障的检测效果。通过提取变化率信息与累计信息, 挖掘了数据集中易被忽略的隐含信息, 提升了模型对于微小偏移及振荡类型故障的检测效果。与LNSPPCAST、KECA、CAE、MBI-CAE进行对比分析, 在数值例子和TE应用仿真中保证低误报率的同时取得了较高的报警率, 验证了该方法的有效性。但是在仿真中也发现相邻过程变量关联性比较差, 如何提高变量间的局部相关性, 是未来需要进一步研究的问题。

## 参考文献:

- [1] 李俨, 杨晨. 基于相对输出信息的多智能体系统分布式故障检测[J]. 控制与决策, 2023, 38(7): 1901-1908.  
Li Yan, Yang Chen. Distributed Fault Detection of Multi-

agent System Based on Relative Output Information[J]. Control and Decision, 2023, 38(7): 1901-1908.

- [2] 周东华, 刘洋, 何潇. 闭环系统故障诊断技术综述[J]. 自动化学报, 2013, 39(11): 1933-1943.  
Zhou Donghua, Liu Yang, He Xiao. Review on Fault Diagnosis Techniques for Closed-loop Systems[J]. Acta Automatica Sinica, 2013, 39(11): 1933-1943.
- [3] 高学金, 程琨, 韩华云, 等. 基于中心损失的条件生成式对抗网络的冷水机组故障诊断[J]. 化工学报, 2022, 73(9): 3950-3962.  
Gao Xuejin, Cheng Kun, Han Huayun, et al. Fault Diagnosis of Chillers Using Central Loss Conditional Generative Adversarial Network[J]. CIESC Journal, 2022, 73(9): 3950-3962.
- [4] Ge Zhiqiang, Song Zhihuan, Gao Furong. Review of Recent Research on Data-based Process Monitoring[J]. Industrial & Engineering Chemistry Research, 2013, 52(10): 3543-3562.
- [5] 魏贇, 李栋. 结合改进卷积神经网络与自编码器的表情识别[J]. 小型微型计算机系统, 2022, 43(2): 387-392.  
Wei Yun, Li Dong. Expression Recognition Based on Improved Convolutional Neural Networks and Self-encoder[J]. Journal of Chinese Computer Systems, 2022,

- 43(2): 387-392.
- [6] 刘家瑞, 杨国田, 王孝伟. 基于孪生深度神经网络的风电机组故障诊断方法[J]. 系统仿真学报, 2022, 34(11): 2348-2358.
- Liu Jiarui, Yang Guotian, Wang Xiaowei. A Wind Turbine Fault Diagnosis Method Based on Siamese Deep Neural Network[J]. Journal of System Simulation, 2022, 34(11): 2348-2358.
- [7] 杜先君, 巩彬, 余萍, 等. 基于CBAM-CNN的模拟电路故障诊断[J]. 控制与决策, 2022, 37(10): 2609-2618.
- Du Xianjun, Gong Bin, Yu Ping, et al. CBAM-CNN Based Analog Circuit Fault Diagnosis[J]. Control and Decision, 2022, 37(10): 2609-2618.
- [8] 张鹏, 束小曼, 厉雪衣, 等. 基于LSTM的交流电机系统故障诊断方法研究[J]. 电机与控制学报, 2022, 26(3): 109-116.
- Zhang Peng, Shu Xiaoman, Li Xueyi, et al. LSTM-based Fault Diagnosis of AC Electric Machine System[J]. Electric Machines and Control, 2022, 26(3): 109-116.
- [9] 徐林, 郑晓彤, 付博, 等. 基于改进GAN算法的电机轴承故障诊断方法[J]. 东北大学学报(自然科学版), 2019, 40(12): 1679-1684.
- Xu Lin, Zheng Xiaotong, Fu Bo, et al. Fault Diagnosis Method of Motor Bearing Based on Improved GAN Algorithm[J]. Journal of Northeastern University(Natural Science), 2019, 40(12): 1679-1684.
- [10] 刘兴, 余建波. 注意力卷积GRU自编码器及其在工业过程监控的应用[J]. 浙江大学学报(工学版), 2021, 55(9): 1643-1651, 1659.
- Liu Xing, Yu Jianbo. Attention Convolutional GRU-based Autoencoder and Its Application in Industrial Process Monitoring[J]. Journal of Zhejiang University (Engineering Science), 2021, 55(9): 1643-1651, 1659.
- [11] Khushwant Rai, Farnam Hojatpanah, Firouz Badrkhani Ajaei, et al. Deep Learning for High-impedance Fault Detection: Convolutional Autoencoders[J]. Energies, 2021, 14(12): 3623.
- [12] Chen Kunjin, Hu Jun, He Jinliang. Detection and Classification of Transmission Line Faults Based on Unsupervised Feature Learning and Convolutional Sparse Autoencoder[J]. IEEE Transactions on Smart Grid, 2018, 9(3): 1748-1758.
- [13] Yu Jianbo, Liu Xing, Ye L. Convolutional Long Short-term Memory Autoencoder-based Feature Learning for Fault Detection in Industrial Processes[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-15.
- [14] 孙海蓉, 潘子杰, 晏勇. 基于深度卷积自编码网络的小样本光伏热斑识别与定位[J]. 华北电力大学学报(自然科学版), 2021, 48(4): 91-98.
- Sun Hairong, Pan Zijie, Yan Yong. Identification and Location of Photovoltaic Hot Spots with Small Samples Based on Deep Convolutional Autoencoder Network[J]. Journal of North China Electric Power University (Natural Science Edition), 2021, 48(4): 91-98.
- [15] 赵小强, 张潇潇. 基于滑动窗的CVA故障诊断算法[J]. 兰州理工大学学报, 2015, 41(3): 91-95.
- Zhao Xiaoqiang, Zhang Xiaoxiao. CVA Algorithm for Fault Diagnosis Based on Moving Window[J]. Journal of Lanzhou University of Technology, 2015, 41(3): 91-95.
- [16] 肖雄, 王健翔, 张勇军, 等. 一种用于轴承故障诊断的二维卷积神经网络优化方法[J]. 中国电机工程学报, 2019, 39(15): 4558-4567.
- Xiao Xiong, Wang Jianxiang, Zhang Yongjun, et al. A Two-dimensional Convolutional Neural Network Optimization Method for Bearing Fault Diagnosis[J]. Proceedings of the CSEE, 2019, 39(15): 4558-4567.
- [17] 陈含智, 孙蕊, 邱明, 等. 基于自适应噪声方差的卫星定位故障检测法[J]. 北京航空航天大学学报, 2023, 49(2): 406-421.
- Chen Hanzhi, Sun Rui, Qiu Ming, et al. An Adaptive Noise Variance Based Fault Detection Algorithm for GNSS Positioning[J]. Journal of Beijing University of Aeronautics and Astronautics, 2023, 49(2): 406-421.
- [18] 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): 736-749.
- Gu Bingbin, Xiong Weili. Fault Diagnosis Based on PCA Method with Multi-block Information Extraction[J]. CIESC Journal, 2019, 70(2): 736-749.
- [19] Ge Zhiqiang, Song Zhihuan. Distributed PCA Model for Plant-wide Process Monitoring[J]. Industrial & Engineering Chemistry Research, 2013, 52(5): 1947-1957.
- [20] 何永建. 基于多块PLS的故障检测方法研究[D]. 沈阳: 东北大学, 2014.
- He Yongjian. Research on Fault Detection Method Based on Multiblock PLS[D]. Shenyang: Northeastern University, 2014.
- [21] 朱家桢, 何雨旻, 侍洪波. 基于多块卷积自编码器的故障检测方法[C]//第32届中国过程控制会议(CPCC2021)论文集. 太原: 中国自动化学会, 2021: 1777.
- [22] 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.
- 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.
- [23] 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.
- [24] Ge Zhiqiang, Zhang Muguang, Song Zhihuan. Nonlinear Process Monitoring Based on Linear Subspace and Bayesian Inference[J]. *Journal of Process Control*, 2010, 20(5): 676-688.
- [25] 郭大权, 杨宗圣, 周晓锋, 等. 基于多块信息提取的AUV资源勘查系统故障检测[J]. *控制与决策*, 2021, 36(4): 790-800.  
Guo Daquan, Yang Zongsheng, Zhou Xiaofeng, et al. Fault Detection of AUV Resource Exploration System Based on Multi-block Information Extraction[J]. *Control and Decision*, 2021, 36(4): 790-800.
- [26] 赵杭天. 基于卷积自编码网络的故障在线检测研究[D]. 上海: 中国科学院上海应用物理研究所, 2021.  
Zhao Hangtian. Research on Online Fault Detection Based on Convolutional Auto-encoder Network[D]. Shanghai: Shanghai Institute of Applied Physics, Chinese Academy of Sciences, 2021.
- [27] Ge Zhiqiang, Song Zhihuan. Multimode Process Monitoring Based on Bayesian Method[J]. *Journal of Chemometrics*, 2009, 23(12): 636-650.
- [28] 李元, 张昊展, 唐晓初. 基于多模态数据全信息的概率主成分分析故障检测研究[J]. *仪器仪表学报*, 2021, 42(2): 75-85.  
Li Yuan, Zhang Haozhan, Tang Xiaochu. Study on Probabilistic Principal Component Analysis Fault Detection Based on Full Information of Multimodal Data[J]. *Chinese Journal of Scientific Instrument*, 2021, 42(2): 75-85.
- [29] 邓明月, 刘建昌, 许鹏, 等. 基于KECA的非线性工业过程故障检测与诊断新方法[J]. *化工学报*, 2020, 71(5): 2151-2163.  
Deng Mingyue, Liu Jianchang, Xu Peng, et al. New Fault Detection and Diagnosis Strategy for Nonlinear Industrial Process Based on KECA[J]. *CIESC Journal*, 2020, 71(5): 2151-2163.