

DOI: 10.20189/j.cnki.CN/61-1527/E.202503010

指数加权慢特征分析的动态故障检测算法

张 晨¹, 孔祥玉¹, 程金勇²

(1. 火箭军工程大学, 陕西 西安 710025;

2. 32204 部队, 陕西 华阴 714200)

摘 要: 针对典型动态过程监视中传统多元统计过程监测 (multivariate statistical process monitoring, MSPM) 方法难以有效提取动态特征的问题, 提出一种基于指数加权慢特征分析 (exponential weighted slow feature analysis, EWSFA) 的动态检测算法。首先, 该算法通过对测试数据执行 2 次奇异值分解, 提取慢特征矩阵; 其次, 借助慢特征的定义优化参数, 确定主要慢特征数量; 然后, 构造监测统计量, 通过指数加权移动平均修正统计量; 最后, 根据置信度计算控制限, 制定动态故障检测策略。基于田纳西-伊士曼过程 (Tennessee Eastman process, TEP) 和电动伺服机构进行算法性能验证。在 TEP 实验中, 所提 EWSFA 算法的故障检测率分别比 DPCA 和 SFA 方法提升 24.19% 和 1.65%; 在电动伺服机构实验中, 所提 EWSFA 算法的故障检测率分别比 DPCA 和 SFA 方法提升 1.66% 和 1.09%。实验结果验证了所提方法在故障检测中的优越性。

关键词: 多元统计过程监测; 慢特征分析; 指数加权; 动态故障检测; 特征提取

中图分类号: TJ410

文献标志码: A

开放科学标识码(OSID):

文章编号: 2097-2741(2025)03-099-08



听语音
与作者互动
聊科研

Exponential Weighted Slow Feature Analysis-Based Dynamic Fault Detection Algorithm

ZHANG Chen¹, KONG Xiangyu¹, CHENG Jinyong²

(1. Rocket Force University of Engineering, Xi'an 710025, China;

2. Troops No.32204, Huayin 714200, China)

ABSTRACT: A dynamic detection algorithm based on exponentially weighted slow feature analysis (EWSFA) was proposed to address the limitations of traditional multivariate statistical process monitoring methods in effectively extracting dynamic features in typical dynamic process monitoring. First, the algorithm extracted a slow feature matrix by performing two singular value decompositions on test data. Second, it employed the definition of slow features to optimize the parameters, thereby determining the number of main slow features. Subsequently, monitoring sta-

收稿日期: 2025-04-11

修回日期: 2025-04-26

录用日期: 2025-04-29

基金项目: 国家自然科学基金 (62273354)

第一作者: 张晨 (1993—), 男, 博士研究生, 主要从事故障诊断与信号处理研究。E-mail: buaa0318@163.com

引用格式: 张晨, 孔祥玉, 程金勇. 指数加权慢特征分析的动态故障检测算法 [J]. 火箭军工程大学学报, 2025, 39 (3): 99-106. ZHANG Chen, KONG Xiangyu, CHENG Jinyong. Exponential weighted slow feature analysis-based dynamic fault detection algorithm [J]. Journal of Rocket Force University of Engineering, 2025, 39 (3): 99-106.

tistics were constructed and adjusted using an exponential weighted moving average. Finally, the control limit was calculated and a dynamic fault detection strategy based on the confidence level was developed. The performance of the algorithm was validated using the Tennessee Eastman process (TEP) and an electric servo mechanism. In the TEP experiment, the fault detection rates of the proposed EWSFA algorithm were improved by 24.19% and 1.65% compared with those of the DPCA and SFA methods, respectively. In the experiment on the electric servo mechanism, the fault detection rates of the proposed EWSFA increased by 1.66% and 1.09%, respectively, compared with the DPCA and SFA methods. The results verified the superiority of the proposed method for fault detection.

KEYWORDS: multivariate statistical process monitoring; slow feature analysis; exponential weighted; dynamic fault detection; feature extraction

复杂装备或者大型系统故障诊断方法主要包括基于解析模型的方法^[1-2]、基于数据驱动的方法^[3-4]以及基于知识的方法^[5-6]。多元统计过程监测 (multivariate statistical process monitoring, MSPM) 是一种被广泛采用的数据驱动方法, 并应用于过程监测和故障检测。该方法通过投影高维过程数据到低维子空间, 来构建统计量并实现过程监测。

传统 MSPM 方法主要包括以下几类: 一是主成分分析 (principal component analysis, PCA)。Yang 等^[7]首先使用 PCA 对每个故障分别建模, 再利用贝叶斯信息准则将多个故障检测模型集成为一个概率模型, 用于最终决策。Li 等^[8]在 PCA 基础上提出一种新的基于重建精度的统计量 SPE-R, 并在冷轧机系统上对所提算法进行了性能评估。Ren 等^[9]提出一种基于数据驱动的生存信息势 PCA 模型, 通过监控过程变量的运行提升了故障检测效率。二是偏最小二乘 (partial least squares, PLS)。Kong 等^[10]提出一种输入输出核偏最小二乘模型, 可以有效地提取输入与输出之间的非线性特征, 并提供全面的监测性能。Yang 等^[11]构造了一种多变量指数加权滑动平均和核主成分分析相结合的混合检测模型, 能够对异常事件进行监测。Hasnen 等^[12]将传统的监督自适应 PLS 方法扩展到包括 PCA 为基础的漂移校正方法, 并用水管锅炉的实际工业数据进行了方法效果验证。三是独立成分分析 (independent component analysis, ICA)。Kong 等^[13]提出一种基于 ICA 的故障重构模型并用于过程在线监测。Yang 等^[14]提出一种基于随机森林和改进 ICA 的光伏故障检测鲁棒智能学习算法。Liu 等^[15]提出一种多模型集成与分布相异度分析的早期故障检测方法, 能够有效地检测

出早期故障。

对于大多数工业过程, 由于夹杂有噪声和干扰的过程变量是自相关和时变的^[16], 使得传统的 MSPM 方法不适合用于监测此类动态过程。为了解决这一问题, Zheng^[17]等扩展了 PCA 方法并提出动态 PCA (dynamic principal component analysis, DPCA)。通过引入时滞来构建增广矩阵, 互相堆叠的观测向量增强了自相关性, 使得传统静态方法可以进一步提取时变动态特征。但对于高维过程, 即使只考虑一阶自相关, 数据的维度也会显著增加^[18]。同时, 在这些动态方法中, 所有变量都以相同的时滞处理, 而动态特性对不同的变量可能有不同的影响。因此, DPCA 等方法不但计算效率低, 而且在动态过程监控中的性能也不够理想^[19]。

此外, 为了从过程数据中提取重要动态信息, 慢特征分析 (slow feature analysis, SFA) 被提出来^[20]。SFA 作为一种无监督特征提取方法, 其核心准则在于: 变化速率越慢的变量, 往往蕴含着数据的关键信息。该方法专注于提取随时间缓慢演变的特征, 而这些特征通常包含数据的重要模式。凭借在捕捉动态特征方面的显著优势, SFA 已在多个领域获得广泛应用。Saafan 等^[21]提出一种基于稀疏 SFA 的模型, 并通过 2 个数据集验证了该方法在故障检测上的优越性。Ji^[22]提出一种基于 SFA 的数据驱动方法, 被成功应用于传感器的故障检测和分类任务中。Zhang 等^[23]通过对慢特征进行稀疏化处理, 有效提升了动态空调系统故障诊断的准确性与有效性。然而, 经典 SFA 在构造统计量时未能考虑外部干扰对测量数据的影响, 导致故障检测精度还有待提高。

在此基础上, 本文提出一种基于指数加权慢

特征分析 (exponentially weighted slow feature analysis, EWSFA) 的动态检测算法。对测试数据执行 2 次奇异值分解, 提取慢特征矩阵; 借助慢特征的定义优化参数, 确定主要慢特征数量; 构造监测统计量, 通过指数加权移动平均修正统计量; 最后, 根据置信度计算控制限, 制定故障检测策略。与现有故障检测方法相比, 本文所提 EWSFA 主要贡献如下: 1) 通过指数加权移动平均将历史样本信息融入当前样本的监测指标构造, 有效提升故障检测效果; 2) 构建一套完备且系统的故障检测策略, 实现对系统动态特性的精准高效监测; 3) 基于田纳西-伊士曼过程 (Tennessee Eastman process, TEP) 和电动伺服机构实验评估算法性能, 促进算法从理论推导向实际应用转化。

1 EWSFA 算法

1.1 慢特征分析

标准 SFA 算法通过寻找合适的输入输出映射函数, 从快速变化的时间序列中提取缓慢变化的特征。

给定 $\mathbf{X} = [x_1, x_2, \dots, x_n] \in R^{n \times m}$ 是测量数据矩阵; n 是样本个数; m 是变量个数。 $\mathbf{S} = [s_1, s_2, \dots, s_n] \in R^{n \times m}$ 是慢特征矩阵, 两者之间关系为

$$\mathbf{S} = \mathbf{W}\mathbf{X} \quad (1)$$

式中: $\mathbf{W} = [w_1, w_2, \dots, w_n] \in R^{n \times m}$ 是映射函数矩阵。SFA 的目标函数为

$$\min E \{ \dot{s}_j^2 \} \quad (2)$$

约束函数为

$$E \{ s_j \} = 0 \quad (3)$$

$$E \{ s_j^2 \} = 1 \quad (4)$$

$$\forall i \neq j: E \{ s_i s_j \} = 0 \quad (5)$$

式中: $\dot{s}_j$ 是慢特征信号 s_j 相对于时间变量 t 的一阶导数。

1.2 目标函数求解

为了求解式 (2), 考虑使用 2 次奇异值分解 (singular value decomposition, SVD)。首先, 对输入的协方差矩阵执行 SVD, 旨在消除变量之间的相关性, 表达式为

$$\langle x(t) x^T(t) \rangle_t = \mathbf{U}\mathbf{\Lambda}\mathbf{U}^T \quad (6)$$

式中: $\mathbf{\Lambda}$ 和 $\mathbf{U}$ 分别为协方差矩阵的特征值矩阵和特征向量。

随后, 对测试数据进行白化转换, 表达式为

$$\mathbf{z}(t) = \mathbf{\Lambda}^{-\frac{1}{2}} \mathbf{U}^T \mathbf{x}(t) \quad (7)$$

定义矩阵 $\mathbf{Q} = \mathbf{\Lambda}^{-\frac{1}{2}} \mathbf{U}^T$ 为白化系数矩阵。在计算 $\mathbf{z}(t)$ 的一阶导数 $\dot{\mathbf{z}}(t)$ 后, 对变量 $\dot{\mathbf{z}}(t)$ 的协方差矩阵执行 SVD, 表达式为

$$\langle \dot{\mathbf{z}}(t) \dot{\mathbf{z}}^T(t) \rangle_t = \mathbf{P}\mathbf{\Omega}\mathbf{P}^T \quad (8)$$

基于 $\mathbf{z}(t) = \mathbf{Q}\mathbf{x}(t)$ 和 $\mathbf{s}(t) = \mathbf{P}\mathbf{z}(t)$, 慢特征的映射函数矩阵 $\mathbf{W}$ 可计算为

$$\mathbf{W} = \mathbf{P}\mathbf{Q} = \mathbf{P}\mathbf{\Lambda}^{-\frac{1}{2}} \mathbf{U}^T \quad (9)$$

1.3 参数优化

基于式 (1), 可得到慢特征 $\mathbf{s}(t)$ 。考虑到慢特征的变化缓慢特性, 需要选择 K 个慢特征作为主要成分, 并将 $\mathbf{s}(t)$ 划分成缓慢变化和快速变化的 2 个部分, 可表示为

$$\mathbf{s}(t) = [\mathbf{s}_d^T \ \mathbf{s}_e^T]^T \quad (10)$$

式中: $\mathbf{s}_d^T = [s_1, s_2, \dots, s_K]$ 代表缓慢变化的特征; $\mathbf{s}_e^T = [s_{K+1}, s_{K+2}, \dots, s_m]$ 代表快速变化的特征。

一方面, 慢特征数量过少可能无法充分反映动态过程的特点; 另一方面, 过多的低频特征会引入噪声, 降低监测效果以及检测精度。鉴于变量变化越慢, 其内在信息就越多, 本文将快速变化的特征定义为时间动态超过所有输入变量的慢特征^[24], 即

$$K_e = \text{card} \{ \mathbf{s}_i | \Delta(\mathbf{s}_i) > \max_q \{ \Delta(\mathbf{x}_j) \} \} \quad (11)$$

式中: $\text{card} \{ \cdot \}$ 为某个集合中的元素个数; $\max_q \{ \Delta(\mathbf{x}_j) \}$ 为集合 $\{ \Delta(\mathbf{x}_j) \}$ 的 q 上分位数。通常, 设置 $q = 0.1$ 。

主要慢特征的数量 K 可表示为

$$K = m - K_e \quad (12)$$

1.4 指数加权修正

指数加权移动平均 (exponentially weighted moving average, EWMA) 法是由加权移动平均法演化而来, 加权移动平均法对已知数据分别赋予不同的权重, 按此权重求得移动平均值, 并以此值为基础, 确定预测值。EWMA 则是指各数的加权系数随时间呈指数递减, 主要优点是不需要保存过去的数值, 只占用极少的内存。邱天等^[25]指出, 对 PCA 加入 EWMA 滤波, 当系统发生故障时, 假如故障发生时间足够长, PCA 算法的 T^2 统计量会被放大, 而其控制限并不改变。因此, EWMA 的引入可以有效提升 PCA 算法的故障检测精度。同理, SFA 的统计量加入 EWMA 滤波可以有效提升故障检测精度。

为了监测慢特征的变化情况, 构造统计量为

$$\hat{T}_d^2 = \mathbf{s}_d^T \mathbf{s}_d \quad (13)$$

复杂装备或工业过程运行中, 环境变化、电磁干扰等因素会导致测量变量产生随机波动。为补偿波动对故障检测结果的影响, 使用 EWMA 对统计量进行修正, 表达式为

$$T_d^2(t) = \varphi \hat{T}_d^2(t) + (1 - \varphi) \hat{T}_d^2(t-1) \quad (14)$$

式中: φ 为遗忘因子, 其值越小表示记忆深度越深; $\hat{T}_d^2(0)$ 使用所有训练样本统计量的均值代替。

给定置信度为 $1 - \alpha$, 针对以上统计量的控制限计算如下:

$$T_{\text{lim}}^2 = \chi_{n_d, \alpha}^2 \quad (15)$$

式中: $\chi_{n_d, \alpha}^2$ 代表显著性水平为 α 下的自由度为 n_d 的 χ^2 分布。

1.5 故障检测策略

基于 EWSFA 的故障检测策略包括离线建模和在线监测 2 个部分, 其流程如图 1 所示, 具体步骤如下。




图 1 基于 EWSFA 的故障检测流程

Fig. 1 EWSFA-based fault detection process

离线建模部分

1) 选取正常工况过程中变量数据 $\mathbf{X}$ 标准化为零的均值和单位方差。

2) 按照式 (6) ~ (9) 求解映射函数矩阵 $\mathbf{W}$ 。

3) 按照式 (11)、(12) 对主要慢特征数量 K 进行优化。

4) 按照式 (14) 对统计量进行指数加权修正并计算监测统计量 T_d^2 。

5) 按照式 (15) 计算控制限 T_{lim}^2 。

在线监测部分

1) 对 t 时刻样本 $\mathbf{X}_{\text{new}}$ 进行标准化处理。

2) 向 EWSFA 模型投影得到新的慢特征。

3) 计算新的统计量 T_{dnew}^2 。

4) 将测试数据的统计量与控制限 T_{lim}^2 进行比较, 如果统计量超出相应的控制限, 则判定过程发生故障; 相反, 则判定测试数据正常。

采用故障检测率 P_{FDR} 和误报率 P_{FAR} 评估算法效果, 表达式分别为

$$P_{\text{FDR}} = \frac{N_{\text{err}}}{N_{\text{ifs}}} \times 100\% \quad (16)$$

$$P_{\text{FAR}} = \frac{N_{\text{eff}}}{N_{\text{its}}} \times 100\% \quad (17)$$


式中: N_{err} 和 N_{ifs} 分别为有效报警数目和故障样本总数; N_{eff} 和 N_{its} 分别为错误报警数目和正常样本总数。

2 实验与分析

为验证所提算法故障检测性能, 使用 TEP 和电动伺服机构开展实验。在故障检测实验中, 选择 DPCA^[17] 和 SFA^[20] 2 种动态故障检测方法作对比。

2.1 田纳西-伊士曼过程

TEP 是一个按照真实工业过程开发的工业基准平台, 包括反应器、冷凝器、压缩机、汽提塔和分离器 5 个主要单元, 其工艺流程如图 2 所示。在此过程中, 4 种气态反应物 A、C、D 和 E 以及输入 B 被送入反应堆。同时, 液体产品 G、H 和副产品 F 形成。详细反应如下:



TEP 是一个典型的动态系统, 已被广泛应用于故障检测效果评估。TEP 包括正常工况和多种故障工况, 本文选用的故障包括 IDV (1, 2, 4, 5, 6, 7, 8, 10)。正常工况包括 500 个正常样本, 作为训练集进行建模。每种故障工况记录 48 h 的仿真数据, 共 960 个样本, 其中前 160 个样本为正常样本, 后 800 个为故障样本。TEP 包含 41 个测量变量和 11 个操纵变量, 分别记作 XMEAS (1-41) 和 XMV (1-11)。仿真实验中, 过程变量矩阵 $\mathbf{X}$ 由 22 个测量变量 XMEAS (1-22) 和 11 个操纵变量 XMV (1-11) 组成。

各类方法对 TEP 的故障检测结果汇总如表 1 所示, 可以看出, EWSFA 的平均 FDR 为 98.96%, 分别比 DPCA 和 SFA 的平均 FDR 提高了 24.19%

和 1.65%; EWSFA 的平均 FAR 为 0.11%, 分别比 DPCA 和 SFA 的平均 FAR 降低 0.83% 和 0.2%。

3 种方法在 IDV (4) 和 IDV (10) 的故障检测结果如图 3 和图 4 所示。可以看出, 在 IDV (4) 和 IDV (10) 的故障检测中, EWSFA 的检测效果明显优于 DPCA 和 SFA。

2.2 电动伺服机构

电动伺服机构主要由伺服控制器、驱动器、机电执行器和电源组成^[26], 如图 5 所示。通过精确控制电机速度、位置和加速度等参数, 电动伺服机构即可实现对机械运动的精确控制。电动伺服机构本质上是一个动态过程, 其运行涉及实时反馈与调节、瞬态响应和外部扰动抑制等多个动态特性。

表 1 TEP 故障检测的 FAR 和 FDR

Table 1 FAR and FDR of TEP fault detection %						
故障 编号	DPCA		SFA		EWSFA	
	FAR	FDR	FAR	FDR	FAR	FDR
IDV 1	0.00	99.13	0.21	99.63	0.00	99.75
IDV 2	1.25	98.13	0.02	98.50	0.00	99.25
IDV 4	1.25	31.13	0.00	94.50	0.00	99.63
IDV 5	1.25	27.75	0.16	99.78	0.00	99.88
IDV 6	0.63	99.25	0.91	99.63	0.79	99.88
IDV 7	1.25	99.87	0.25	99.81	0.04	99.88
IDV 8	0.63	97.25	0.77	97.75	0.01	98.88
IDV 10	1.25	45.63	0.18	88.88	0.00	94.50
平均	0.94	74.77	0.31	97.31	0.11	98.96




图 2 TEP 工艺流程

Fig. 2 Process of TEP




图 3 不同方法对 IDV (4) 故障检测结果

Fig. 3 IDV (4) fault detection results by different methods




图 4 不同方法对 IDV (10) 故障检测结果

Fig. 4 IDV (10) fault detection results by different methods




图 5 电动伺服机构

Fig. 5 Electric servo mechanism

通过分析电动伺服机构的工作原理，其典型故障类型一般可分为 3 类：环境因素故障、机械系统故障和电气系统故障。

在本实验中，某型号电动伺服机构的 21 个变量被采集进行过程监控，包括电压反馈、电流反馈和喷管摆角等，如表 2 所示。最终，收集了 4 组不同的数据集，包括 1 组正常数据集和 3 组与 3 种典型故障类型相对应的故障数据集。采样间隔为 5 ms，正常训练数据集由 1 259 个样本组成。每组故障数据集由 1 140 个样本组成，每组故障数据集的说明如下。

故障集 1：环境因素故障。28 V 电压变量从第 480 个样本突然降至 20 V 左右。

故障集 2：机械系统故障。A 通道作动器位置反馈的 3 个峰值样本 621、820 和 1 022 附近的 100 个样本突然降至原始数值的 50%。

故障集 3：电气系统故障。A 通道速度反馈变量从第 600 个样本开始降低到原始数值的 45%。

在相同的实验数据下，分别采用 DPCA、SFA 和 EWSFA 进行故障检测，结果如表 3 所示。为了直观展示故障检测效果，图 6~8 展示了本文所提 EWSFA 方法对电动伺服机构 3 组故障集的检测结果。

表 3 中，FAR 和 FDR 都是对慢特征变化情况统计量 T_d^2 的统计结果，可以看出，故障 1 和故障 2 都是较为容易检测到的故障，DPCA、SFA 和

EWSFA 3 种方法的 FDR 都在 98% 以上，而 FAR 均低于 1%。故障 3 则是不易被检测到的故障，DPCA 和 SFA 的 FDR 仅有 30.18% 和 31.89%，而本文所提 EWSFA 的 FDR 达到了 35.41%，相对检测效果更好。综合 3 组故障数据来看，EWS-FA 的平均 FAR 为 0.08%，分别比 DPCA 和 SFA 降低了 0.16% 和 0.23%；EWSFA 的平均 FDR 为 77.70%，分别比 DPCA 和 SFA 提高了 1.66% 和 1.09%。实验结果验证了 EWSFA 在故障检测中的优越性。

表 2 电动伺服机构的变量信息

Table 2 Variables of electric servo mechanism

序号	变量描述
1	时标(高字)
2	时标(低字)
3	A 通道作动器位置反馈
4	B 通道作动器位置反馈
5	A 通道速度反馈
6	B 通道速度反馈
7	A 通道 q 轴电流反馈
8	B 通道 q 轴电流反馈
9	A 通道 d 轴电流反馈
10	B 通道 d 轴电流反馈
11	A 通道喷管摆角指令(回传)
12	B 通道喷管摆角指令(回传)
13	A 通道电机转角
14	B 通道电机转角
15	+10 V 供电状态
16	-10 V 供电状态
17	+15 V 供电状态
18	-15 V 供电状态
19	+5 V 供电状态
20	28 V 电压
21	28 V 电流

表 3 电动伺服机构故障检测的 FAR 和 FDR

Table 3 FAR and FDR of fault detection of the electric servo mechanism %

故障 编号	DPCA		SFA		EWSFA	
	FAR	FDR	FAR	FDR	FAR	FDR
1	0.19	98.85	0.59	99.98	0.00	100.00
2	0.52	99.10	0.34	97.96	0.24	97.69
3	0.00	30.18	0.00	31.89	0.00	35.41
平均	0.24	76.04	0.31	76.61	0.08	77.70




图 6 基于EWSFA的故障1检测效果

Fig. 6 EWSFA-based detection effect of fault 1




图 7 基于EWSFA的故障2检测效果

Fig. 7 EWSFA-based detection effect of fault 2




图 8 基于EWSFA的故障3检测效果

Fig. 8 EWSFA-based detection effect of fault 3

3 结论

针对传统多元统计过程监测方法不能有效提取动态特征的问题,提出一种基于指数加权慢特征分析的动态检测算法。基于TEP和电动伺服机构的实验表明,所提算法的故障检测效果明显优

于其他经典故障检测算法。与传统MSPM方法相比,所提EWSFA通过指数加权移动平均将历史样本信息融入当前样本的监测指标构造,在统计量控制限不变的基础上放大了统计量,因此有效提升了故障检测效果。本方法假设过程是线性系统,后续将重点研究如何将该方法拓展到非线性系统中。

参考文献

[1] ZHAO D, LAM H K, LI Y Y, et al. A novel approach to state and unknown input estimation for Takagi sugeno fuzzy models with applications to fault detection[J]. IEEE Transactions on Circuits and Systems I: Regular Papers, 2020, 67 (6) : 2053-2063.

[2] ZOU S C, ZHAO W Z, WANG C Y, et al. Fault detection strategy of vehicle wheel angle signal via long short-term memory network and improved sequential probability ratio test[J]. IEEE Sensors Journal, 2021, 21(15): 17290-17299.

[3] DENG X G, PING Z Y, SUN R. UWB NLOS recognition based on improved convolutional neural network assisted by wavelet analysis and gramian angular field[J]. IEEE Sensors Journal, 2023, 23 (14): 16384-16392.

[4] JI C, MA F Y, WANG J D, et al. Orthogonal projection based statistical feature extraction for continuous process monitoring[J]. Computers & Chemical Engineering, 2024, 183: 108600.

[5] 冯树成, 贺维, 马宁, 等. 基于可扩展置信规则库的工业设备故障诊断方法[J]. 火箭军工程大学学报, 2025, 39 (2): 13-21.

FENG S C, HE W, MA N, et al. Fault diagnosis method for industrial equipment based on extended belief rule base[J]. Journal of Rocket Force University of Engineering, 2025, 39 (2) : 13-21.

[6] 熊子龙, 曹哲. 考虑测试履历影响的惯导系统健康状态评估方法[J]. 火箭军工程大学学报, 2025, 39 (2): 22-28.

XIONG Z L, CAO Z. Health assessment method for inertial navigation systems with consideration of test impact[J]. Journal of Rocket Force University of Engineering, 2025, 39 (2): 22-28.

[7] YANG Y H, CHEN X M, ZHANG Y, et al. A novel decentralized weighted ReliefF-PCA method for fault detection[J]. IEEE Access, 2019, 7: 140478-140487.

- [8] LI H Q, JIA M X, MAO Z Z. Dynamic reconstruction principal component analysis for process monitoring and fault detection in the cold rolling industry[J]. *Journal of Process Control*, 2023, 128: 103010.
- [9] REN M F, LIANG Y, CHEN J H, et al. Fault detection for NO_x emission process in thermal power plants using SIP-PCA[J]. *ISA Transactions*, 2023, 140: 46–54.
- [10] KONG X Y, LUO J Y, FENG X W, et al. A general quality-related nonlinear process monitoring approach based on input-output kernel PLS[J]. *IEEE Transactions on Instrumentation and Measurement*, 2023, 72: 3505712.
- [11] YANG J, WANG J Y, YE Q L, et al. A novel fault detection framework integrated with variable importance analysis for quality-related nonlinear process monitoring[J]. *Control Engineering Practice*, 2023, 141: 105733.
- [12] HASNEN S H, SHAHID M, ZABIRI H, et al. Semi-supervised adaptive PLS soft-sensor with PCA-based drift correction method for online valuation of NO_x emission in industrial water-tube boiler[J]. *Process Safety and Environmental Protection*, 2023, 172: 787–801.
- [13] KONG X Y, YANG Z Y, LUO J Y, et al. Extraction of reduced fault subspace based on KDICA and its application in fault diagnosis[J]. *IEEE Transactions on Instrumentation and Measurement*, 2022, 71: 3505212.
- [14] YANG N C, ISMAIL H. Robust intelligent learning algorithm using random forest and modified-independent component analysis for PV fault detection: in case of imbalanced data[J]. *IEEE Access*, 2022, 10: 41119–41130.
- [15] LIU M Z, KONG X Y, LUO J Y, et al. Incipient fault detection based on ensemble learning and distribution dissimilarity analysis in multi-feature processes[J]. *Measurement Science and Technology*, 2024, 35(4): 045905.
- [16] HUANG J, YAN X F. Dynamic process fault detection and diagnosis based on dynamic principal component analysis, dynamic independent component analysis and Bayesian inference[J]. *Chemometrics and Intelligent Laboratory Systems*, 2015, 148: 115–127.
- [17] ZHENG N N, LUAN X L, SHARDT Y A W, et al. Dynamic-controlled principal component analysis for fault detection and automatic recovery[J]. *Reliability Engineering & System Safety*, 2024, 241: 109608.
- [18] ZHANG C, ZHENG X F, LI Y, et al. A novel fault detection and diagnosis scheme based on independent component analysis statistical characteristics: application on the Tennessee Eastman benchmark process[J]. *Journal of Chemical Engineering Science of Japan*, 2021, 54(6): 304312.
- [19] ODIOWEI P P, CAO Y. State-space independent component analysis for nonlinear dynamic process monitoring[J]. *Chemometrics and Intelligent Laboratory Systems*, 2010, 103(1): 59–65.
- [20] WISKOTT L, SEJNOWSKI T J. Slow feature analysis: unsupervised learning of invariances[J]. *Neural Computation*, 2002, 14(4): 715–770.
- [21] SAAFAN H, ZHU Q Q. Improved manifold sparse slow feature analysis for process monitoring[J]. *Computers & Chemical Engineering*, 2022, 164: 107905.
- [22] JI H Q. Data-driven sensor fault diagnosis under closed-loop control with slow feature analysis[J]. *IEEE Sensors Journal*, 2022, 22(24): 24299–24308.
- [23] ZHANG H Y, LI C D, WEI Q L, et al. Fault detection and diagnosis of the air handling unit via combining the feature sparse representation based dynamic SFA and the LSTM network[J]. *Energy and Buildings*, 2022, 269: 112241.
- [24] SHANG C, YANG F, GAO X Q, et al. Concurrent monitoring of operating condition deviations and process dynamics anomalies with slow feature analysis[J]. *AIChE Journal*, 2015, 61(11): 3666–3682.
- [25] 邱天, 白晓静, 郑茜予, 等. 多元指数加权移动平均主元分析的微小故障检测[J]. *控制理论与应用*, 2014, 31(1): 19–26.
- QIU T, BAI X J, ZHENG X Y, et al. Incipient fault detection of multivariate exponentially weighted moving average principal component analysis[J]. *Control Theory & Applications*, 2014, 31(1): 19–26.
- [26] SHI Z H, XIAO J, JIANG J H, et al. Identifying reliability high-correlated gates of logic circuits with Pearson correlation coefficient[J]. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 2024, 71(4): 2319–2323.

(编辑: 于福兴)