

中文引用格式:袁帅,杨春曦,张秀峰,等. 基于记忆加权核主成分分析的化工过程故障检测[J]. 中国安全科学学报,2026,36(4): 168-175.

英文引用格式:Yuan Shuai, Yang Chunxi, Zhang Xiufeng, et al. Fault detection for chemical process based on memory-weighted kernel principal component analysis[J]. China Safety Science Journal, 2026, 36(4): 168-175.

基于记忆加权核主成分分析的化工 过程故障检测*

袁帅^{1,2}, 杨春曦^{**1,2}教授, 张秀峰^{1,2}, 王娴^{1,2}, 李根根^{1,2}

(1 昆明理工大学 机电工程学院, 云南 昆明 650500;

2 云南省先进装备智能控制及应用国际联合实验室, 云南 昆明 650500)

中图分类号: X937

文献标志码: A

DOI: 10.16265/j.cnki.issn1003-3033.2026.04.1571

基金项目: 国家自然科学基金资助(62463014); 云南省重大科技项目(202202AG050002, 202302AD080005)。

【摘要】 为提高对化工过程中常见故障的检测能力, 保证化工过程平稳可靠运行, 基于历史故障数据信息和核主成分分析法(KPCA), 提出一种利用历史故障数据加权的新型故障检测方法, 即记忆加权核主成分分析法(M-WKPCA)。首先, 根据 KPCA 计算正常数据和历史故障数据的核主成分(KPC), 对比构建的指标选择出能够突出故障信息的 KPC, 并利用求取的加权矩阵突出故障信息, 构建新的统计量, 进而建立基于 M-WKPCA 方法的在线故障检测模型; 然后, 利用 M-WKPCA 方法, 将检测不同常见故障的 M-WKPCA 方法并行处理, 提出一种能够高精度检测常见故障的并行 WKPCA 故障检测策略; 最后, 采用田纳西伊斯曼(TE)化工过程数据仿真验证文中所提方法。结果表明: 所提方法在测试数据中平均准确检测率为 82.25%, 远高于对比方法, 在故障检测上更有优势; 同时, 由于 KPC 的选择引入了故障信息, 检测的故障数据与正常数据在统计量上区分明显。

【关键词】 记忆加权核主成分分析(M-WKPCA); 核主成分分析(KPCA); 化工过程; 核密度估计(KDE); 故障检测

Fault detection for chemical process based on memory-weighted kernel principal component analysis

Yuan Shuai^{1,2}, Yang Chunxi^{1,2}, Zhang Xiufeng^{1,2}, Wang Xian^{1,2}, Li Gengen^{1,2}

(1 Faculty of Mechanical and Electrical Engineering, Kunming University of Science and

Technology, Kunming Yunnan 650500, China; 2 Yunnan International Joint Laboratory of
Intelligent Control and Application of Advanced Equipment, Kunming Yunnan 650500, China)

Abstract: To enhance the detection ability of common faults in the chemical process and ensure the stable and reliable operation, a new fault detection method, termed M-WKPCA, was proposed. The method was based on historical fault data and KPCA, incorporating historical fault data through a weighting mechanism. Initially, kernel principal components(KPC) of normal data and historical fault data were calculated according to KPCA. KPC that can highlight the fault information were selected based on a comparison of the constructed indexes. A weighting matrix was then used to highlight the fault information,

* 文章编号: 1003-3033(2026)04-0168-08; 收稿日期: 2025-11-11; 修稿日期: 2026-02-05

** 通信作者: 杨春曦(1976—), 男, 贵州铜仁人, 博士, 教授, 主要从事复杂机电系统智能控制以及大数据技术研究。E-mail: ycx@kmust.edu.cn。

and a new statistic was constructed to establish an online fault detection model based on M-WKPCA method. Then, the M-WKPCA method was used to detect common faults in parallel. A parallel WKPCA fault detection strategy was proposed to achieve high precision detection of common faults. Finally, the proposed method was verified using simulated data from the Tennessee Eastman (TE) chemical process. The results show that the proposed method achieves an average accurate detection accuracy of 82.25%. This is much higher than that of the comparison methods, demonstrating its superiority in fault detection. At the same time, since fault information is incorporated during the selection of KPC, the detected fault data are significantly different from the normal data in terms of statistics.

Keywords: memory-weighted kernel principal component analysis (M-WKPCA); kernel principal component analysis (KPCA); chemical process; kernel density estimation (KDE); fault detection

0 引言

近年来,随着过程工业的快速发展,各种装备集成化水平不断提高,过程工业装备的维修、检测变得更加困难,并且,由于过程工业体量大,不同工序间的联系密切,任何微小的故障都会对系统产生不可挽回的影响。因此,过程工业的安全性和可靠性理应放在首要位置^[1]。为保证过程工业的稳定运行,提高过程工业故障检测能力就显得尤为重要。目前,故障检测研究可分为3大研究方向:基于数据驱动的故障检测^[2-3]、基于模型的故障检测^[4]和基于知识的故障检测^[5]。随着工业信息化水平和存储技术的提高,获得的工业数据逐渐变多,为基于数据驱动的故障检测方法的研究奠定基础。

多元统计分析方法中最典型的是主成分分析法(Principal Component Analysis, PCA)^[6],该方法利用降维的方式提取数据中的关键信息,主要用于处理线性、静态、高斯分布数据。为弥补PCA方法的不足,学者们在PCA方法基础上改进出一系列方法,如Ku Wenfu等^[7]提出动态PCA法(Dynamic PCA, DPCA),通过增加增广矩阵提高数据的动态特性;Lee等^[8]提出核PCA法(Kernel PCA, KPCA),通过引入核函数将数据投影到更高维空间,将非线性数据转化为线性数据,然后,再利用PCA方法提取数据信息;Raveendran等^[9]提出概率PCA法(Probabilistic PCA, PPCA),解决了工业数据缺失问题。上述方法的应用条件都在逐步接近实际工业数据特点,使故障检测更加准确、快速^[10],但是,现有研究常利用累计百分比方差(Cumulative Percentage Variance, CPV)(又称为累计方差贡献率)来选取数据特征,存在故障信息被覆盖的可能。

过程工业大多是复杂的往复过程,存在一些经

常出现的故障,对应的故障数据也较容易获取^[11],这些数据包含的故障信息可为建立更有针对性的故障检测模型提供参考,达到更精确的故障检测,因此,利用故障数据建立故障检测模型是必要的。近年来,为解决故障信息被覆盖的问题,Jiang Qingchao等^[12]提出加权PCA,根据监测统计量的变化率选取合适的主成分加权,但是没有利用历史故障信息,对异常信息突出能力有限,且主要针对线性过程。为解决非线性问题,Jiang Qingchao等^[13]又提出加权KPCA,求取滑动窗口内在线数据中不同主成分对应的概率密度,将与正常数据概率密度差距大的主成分加权,实现突出故障信息,该方法同样也缺少对故障信息的利用。Tao Yang等^[14]提出一种动态加权PCA(Dynamic Weight PCA, DWPCA),引入历史故障信息,利用故障信息对检测过程加权,提高对线性故障的检测能力,但对非线性过程故障检测能力提高不大。

鉴于此,笔者拟基于KPCA方法,利用历史故障信息,提出一种在线数据故障检测的记忆加权KPCA法(Memory-Weighted KPCA, M-WKPCA);该方法中的新统计量控制限由核密度估计(Kernel Density Estimation, KDE)^[15]求出;然后通过M-WKPCA方法构成的不同故障检测模型并行组合,提出一种并行WKPCA策略;最后,将PCA、KPCA、DWPCA方法和本文提出的方法进行对比,分别应用于田纳西-伊斯曼(Tennessee Eastman Process, TE)化工过程故障检测,以期对化工过程工业故障检测方法的研究提供新思路。

1 KPCA 法

KPCA是一种针对非线性数据的降维方法,该方法主要通过将观测数据投影到高维空间($\phi: \mathbb{R}^p$

$\rightarrow \mathbb{R}^z, y < z, \phi$ 表示高维投影的过程, $\mathbb{R}^y$ 为 y 维空间, $\mathbb{R}^z$ 为 z 维空间), 利用 PCA 方法提取数据中的非线性特征。给定一组正常训练样本 $X_n \in \mathbb{R}^{n \times m}$, 其中, $X_n = [x_1, x_1, \dots, x_n]^T$, n 为样本容量, m 为数据特征量, 将数据投影到高维空间 H 中, 求取投影空间中数据的协方差矩阵 C^H , 公式如下:

$$C^H = \frac{1}{n} \sum_{i=1}^n \phi(x_i) \phi(x_i)^T \quad (1)$$

式中 $\phi(x_i)$ 为映射空间中的第 i 个样本。

通过构造的核函数, 求取数据的核矩阵 K , 计算核矩阵的特征值 $\lambda_i > 0 (i = 1, 2, \dots, n)$ 和特征向量 $\alpha_i (i = 1, 2, \dots, n)$, 核函数采用径向基核函数(核参数常取值为 $r \times m, r$ 为常数^[16]), 将特征值按从大到小排列, 保留前 $k (k \leq n)$ 个特征值 ($\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_k$) 及其对应的特征向量, 计算如下:

$$\sum_{i=1}^k \lambda_i / \sum_{i=1}^n \lambda_i \times 100\% \geq \text{CPV} \quad (2)$$

将特征向量归一化, 即 $\tilde{\alpha}_i = \alpha_i / \sqrt{\lambda_i} (i = 1, 2, \dots, n)$, 在高维空间 H 中将测试数据 x 投影在特征向量上, 得分向量 $t_d (d = 1, 2, \dots, k)$ 计算如下:

$$t_d = \langle \tilde{\nu}_d, \phi(x) \rangle = \sum_{i=1}^n \tilde{\alpha}_i^d \langle \phi(x_i), \phi(x) \rangle = K \tilde{\alpha}_d \quad (3)$$

上述核矩阵 K 需要进行中心化, 中心化计算公式如下:

$$\tilde{K} = K - \frac{1}{n} \nu_n K - \frac{1}{n} K \nu_n + \frac{1}{n^2} \nu_n K \nu_n \quad (4)$$

式中: $\tilde{K}$ 为中心化后的核矩阵; $\nu_n \in \mathbb{R}^{n \times n}$ 表示 n 维元素全为 1 的方阵。

基于 KPCA 方法的故障检测需要建立数据的统计量及其控制限, 常用的统计量有 T^2 统计量和平方预测误差 (Squared Prediction Error, SPE), 也称 Q 统计量, 2 种统计量定义如下:

$$T^2 = [t_1, t_2, \dots, t_k] \Lambda^{-1} [t_1, t_2, \dots, t_k]^T$$

$$\text{SPE} = \|\phi(x_i) - \phi_k(x_i)\| = \sum_{i=1}^n t_i^2 - \sum_{i=1}^k t_i^2 \quad (5)$$

式中 $\Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_k)$ 为保留的特征值组成的矩阵。

上述 2 种统计量的置信限 (控制限) 计算如下:

$$T_\alpha^2 = \frac{k(n^2 - 1)}{n(n - k)} F_\alpha(k, n - k) \quad (6)$$

$$\text{SPE}_\alpha = \alpha^2(h)$$

式中: $h = 2q^2/b, c = b/(2q)$, 其中, q, b 分别为训练数据 SPE 统计量的均值和方差; α 为显著性水平, 取 0.01; $F_\alpha(k, n - k)$ 为自由度为 k 和 $n - k$ 的 f 分布的置信度为 $1 - \alpha$ 的分位点。

2 基于改进方法的故障检测模型

2.1 M-WKPCA

基于 KPCA 的故障检测是根据特征值累计方差贡献率选择核主成分 (Kernel Principal Component, KPC), 可最大程度保留数据信息, 但不能保证包含故障信息最多, 而且过多与故障无关信息可能会掩盖故障信息, 导致准确检测率下降。针对这一问题提出一种基于历史故障数据的 M-WKPCA 方法, 该方法通过提取历史故障数据中的故障信息, 利用这些信息作为参考选取故障信息突出的 KPC, 从而构建更容易突出故障的模型, 提高检测准确率 (Detection Precise Rate, DPR)。

KPCA 方法在选取 KPC 上没有刻意关注故障信息, 而是根据包含数据信息量选择 KPC。事实上, 当出现故障时, 故障数据和正常数据在某些核主成分对应的统计量上表现出较大区别, 因此, 根据统计量上的差异, 选择更有利于突出故障的 KPC。在此考虑下, 提出利用新的权重矩阵 W_f 替代 KPCA 方法中的特征值矩阵 Λ , 实现加权故障。首先根据给定正常数据 $X_n \in \mathbb{R}^{n \times m}$, 故障数据 $X_f \in \mathbb{R}^{n \times m}$, 权重值计算公式如下:

$$\tilde{W}_{a_f} = \frac{\sum_{i=1}^n (|\tilde{T}_{a,i}^2 - T_{a,i}^2|)}{n}$$

$$W_f^a = \frac{\tilde{W}_f^a}{\sum_{i=1}^m \tilde{W}_f^a} \quad (7)$$

式中: $\tilde{W}_f^a$ 为第 a 个核主成分对应的权重值, $W_f^a \in [0, 1]$; $\tilde{T}_{a,i}^2$ 为故障数据中第 i 个样本对应的第 a 个核主成分的 T^2 统计量, $a = 1, 2, \dots, m$; $T_{a,i}^2$ 为正常数据中第 i 个样本对应的第 a 个核主成分的 T^2 统计量, 其中, $T_{a,i}^2 = t_{a,i} \Lambda_{a,i}^{-1} t_{a,i}^T (i = 1, 2, \dots, n)$ 。

$$\frac{\sum_{i=1}^k W_f^i}{\sum_{i=1}^m W_f^i} \times 100\% \geq \varepsilon \quad (8)$$

式中 ε 为权重值累计方差贡献率。

根据权重矩阵 $\mathbf{W}_f$ 构建新的 T_f^2 统计量,具体计算如下:

$$\begin{aligned}\mathbf{W}_f &= \text{diag}(\mathbf{W}_f^1, \mathbf{W}_f^2, \dots, \mathbf{W}_f^k) \\ \boldsymbol{\Psi}_f &= [t_1, t_2, \dots, t_k] \\ T_f^2 &= \boldsymbol{\Psi}_f \mathbf{W}_f^{-1} \boldsymbol{\Psi}_f^T\end{aligned}\quad (9)$$

式中: $\mathbf{W}_f \in \mathbb{R}^{k \times k}$ 为权重矩阵; $\boldsymbol{\Psi}_f \in \mathbb{R}^{n \times k}$ 为得分向量矩阵,该矩阵是根据权重矩阵对得分向量 $t_i (i = 1, 2, \dots, k)$ 重新排列和选择得到; T_f^2 为重新构建的 T^2 统计量。

M-WKPCA 方法的故障检测流程分为离线和在线 2 个阶段,具体流程如图 1 所示,离线阶段主要是离线建模,在线阶段主要是在线检测,接下来详细介绍这 2 部分的具体步骤:

1) 离线阶段。①将获取的正常数据均分为 2 部分,分别为 $X_{n_1} \in \mathbb{R}^{n_1 \times m}$, $X_{n_2} \in \mathbb{R}^{n_2 \times m}$, 历史故障数据 $X_f \in \mathbb{R}^{n_f \times m}$, 其中 n_1, n_2, n_f 分别为样本容量, m 为数据特征量。根据正常数据 X_{n_1} 分别对正常数据和故障数据标准化,即 $\bar{X}_{i,j} = \frac{X_{i,j} - \mu_j}{\sigma_j}$, 其中 $\mu_j =$

$$\frac{1}{n_1} \sum_{i=1}^{n_1} X_{i,j} \text{ 和 } \sigma_j = \sqrt{\frac{1}{n_1 - 1} \sum_{i=1}^{n_1} (X_{i,j} - \mu_j)^2}, X_{i,j} \text{ 表示矩}$$

阵的第 i 行 j 列对应的元素,标准化后的数据为 $\bar{X}_{n_1}$, $\bar{X}_{n_2}$, $\bar{X}_f$; ②根据正常数据 $\bar{X}_{n_1}$ 计算核矩阵 $\mathbf{K}_{n_1}$, 其中

$$K_{i,j} = \exp\left(-\frac{\|x_i - x_j\|^2}{\sigma}\right) \quad (x_i, x_j \text{ 分别为正常数据 } \bar{X}_{n_1} \text{ 中第 } i \text{ 条样本和第 } j \text{ 条样本}), \text{ 对核}$$

矩阵 $\mathbf{K}_{n_1}$ 进行中心化处理可以得到 $\tilde{\mathbf{K}}_{n_1} = \mathbf{K}_{n_1} -$

$$\frac{1}{n_1} \mathbf{v}_{n_1} \mathbf{K}_{n_1} - \frac{1}{n_1} \mathbf{K}_{n_1} \mathbf{v}_{n_1} + \frac{1}{n_1^2} \mathbf{v}_{n_1} \mathbf{K}_{n_1} \mathbf{v}_{n_1}, \text{ 其中, } \mathbf{v}_{n_1} \in \mathbb{R}^{n_1 \times n_1}$$

表示 n_1 维元素全为 1 的方阵。③根据步骤②,求取矩阵 $\frac{1}{n_1} \tilde{\mathbf{K}}_{n_1}$ 的特征值 $\lambda_i (i = 1, 2, \dots, n_1)$ 和特征向量

$\alpha_i (i = 1, 2, \dots, n_1)$, 对特征向量进行归一化处理得到 $\tilde{\alpha}_i = \frac{\alpha_i}{\sqrt{\lambda_i}} (i = 1, 2, \dots, n_1)$; ④根据步骤③和式

(5), 计算正常数据 $\bar{X}_{n_1}$ 对应的统计量 T_a^2 和故障数

据 $\bar{X}_f$ 对应的统计量 $\tilde{T}_a^2$, 根据式(7)计算出权重值 $W_f^a (a = 1, 2, \dots, n_1)$; ⑤根据权重矩阵 $\mathbf{W}_f = \text{diag}(\mathbf{W}_f^1, \mathbf{W}_f^2, \dots, \mathbf{W}_f^{n_1})$ 通过权重值的累计方差贡献率 ε , 求取核主元个数 k ; ⑥通过式(9)计算正常数

据 $\bar{X}_{n_2}$ 的统计量 $\tilde{T}_f^2$, 利用 KDE 方法计算出控制限 $\tilde{T}_{f,\text{lim}}^2$ 。

2) 在线阶段。①在线获得新的观测数据 $x_t \in \mathbb{R}^{1 \times m}$, 根据正常数据 X_{n_1} 的均值和方差对观测数据进行标准化处理, 得到 $\bar{x}_t$; ②计算观测数据 $\bar{x}_t$ 对应的核矩阵 $\mathbf{K}_t$, 并进行中心化处理 $\tilde{\mathbf{K}}_t = \mathbf{K}_t - \frac{1}{n_1} \mathbf{u}_{n_1}^T \mathbf{K}_{n_1} - \frac{1}{n_1} \mathbf{K}_t \mathbf{v}_{n_1} + \frac{1}{n_1^2} \mathbf{u}_{n_1}^T \mathbf{K}_{n_1} \mathbf{v}_{n_1}$, 其中 $\mathbf{u}_{n_1} \in \mathbb{R}^{n_1 \times 1}$ 表示 n_1 维元素全为 1 的列向量, 将观测数据根据建模的特征向量 $\tilde{\alpha}_i (i = 1, 2, \dots, k)$ 进行映射, 计算新的得分向量 $t_t^i = \tilde{\mathbf{K}}_t \tilde{\alpha}_i$; ③根据离线阶段的步骤⑤计算权重矩阵 $\mathbf{W}_f$, 然后依据式(9)计算观测数据 $\bar{X}_t$ 的对应的统计量 $T_t^2 = [t_t^1, t_t^2, \dots, t_t^k] \mathbf{W}_f^{-1} [t_t^1, t_t^2, \dots, t_t^k]^T$, 当 T_t^2 超过控制限 $T_{f,\text{lim}}^2$ 即为故障, 否则为正常数据。




图1 基于 M-WKPCA 故障检测流程

Fig.1 Fault detection process based on M-WKPCA

2.2 并行 WKPCA

根据 M-WKPCA 故障检测方法, 构建基于 M-WKPCA 方法的并行 WKPCA (Parallel WKPCA, P-WKPCA) 故障检测策略。首先, 分别建立已知故障对应的故障加权检测模型; 然后, 将观测数据 $\bar{x}_t$ 分别经过构建的不同故障加权检测模型求出对应的 T_t^i 统计量, 不同的故障检测模型之间关系, 本质上是对特征向量 $\tilde{\alpha}_i$ 重新排序; 最后, 对比不同模型输出的 T_t^i 统计量的 DPR, 选择 DPR 高的 T_t^i 统计量作

为最后输出,流程如图 2 所示(图中 p 为故障种类)。





图 2 基于 P-WKPCA 故障检测策略流程

Fig. 2 Fault detect strategy flow based on P-WKPCA

3 TE 化工过程仿真试验

3.1 TE 化工过程数据

TE 化工过程是根据实际化工厂化工过程搭建的模拟仿真平台^[17],该平台结构包括反应器、冷凝器、气液分离器、压缩机和汽提塔 5 大部分,主要涉及 4 种气体反应物(A、C、D、E)、2 种液体产物(G、H)、1 种惰性组分(B)和 1 种副产物(F)反应过程见下式,详细信息参照文献[18],采用 TE 过程公开数据集验证第 2.1 节所提方法^[19]。



该过程包括 41 个测量变量(19 个成分变量和 22 个过程变量)和 12 个控制变量共 53 个变量,数据集中具有 52 个变量,TE 过程共设置了 21 种故障,包括 16 个已知故障和 5 个未知故障^[20]。采样间隔为 3 min,其中,训练数据包括正常数据样本大小 500×52 ,故障数据样本大小 480×52 ;测试数据包括数据样本大小 960×52 ,故障在 161 个样本(8 h)处加入。参照文献[20],在 41 个测量变量中 19 个成分变量对故障检测的贡献很小,因此,选取 33 个变量包括 22 个过程变量和 11 控制变量验证算法。

3.2 化工过程故障检测结果分析

采用 PCA^[19]、KPCA^[21]、DWPCA^[14]、M-WKPCA 方法和 P-WKPCA 策略分别检测 TE 过程中 21 种故

障,计算步骤参考 2.1 节,上述方法参数的设置原则均参考相应论文,并统计每种方法对这些故障的 DPR, DPR 的计算见下式,其中, KPCA 和 M-WKPCA 方法核函数均选取径向基核函数,参数设置如下:核参数 σ 均为 960×33 ,累计方差贡献率为 95%, ε 为 95%,PCA、DWPCA 方法设置的 CPV 为 95%。

在对比故障检测方法时,DPR 是衡量检测方法优劣的重要指标^[19],DPR 越高代表检测的误报率和漏报率就越低,因此,采用 DPR 作为上述方法的对比指标,计算如下:

$$DPR = \frac{F_p + F_N}{Z} \times 100\% \quad (11)$$

式中: F_p 为判断正确的正常样本数; F_N 为判断正确的故障样本数; Z 为测试样本的总数量。

接下来,通过 TE 过程中故障 5 和故障 10 这 2 种故障为例,类比化工过程中常见阶跃变化和随机变化类型的故障,检测如图 3、图 4 所示。其中故障 5 是冷凝器冷却水的入口温度发生阶跃变化,类比阶跃变化类型故障,故障 10 是物料 C 的进料温度发生随机变化,类比随机变化类型故障。

分析图 3 得到,对于故障 5,KPCA 法只在部分样本处检测到故障,而 DWPCA 和 M-WKPCA 方法则在故障发生后的大部分样本都被检测到,通过分析表 1 中故障 5 的准确检测率可知:M-WKPCA 法的准确检测率比 DWPCA 法更高,说明该方法比 DWPCA 方法检测效果更好。

分析图 4 得到,对于故障 10,KPCA 方法的检测随着过程变化不断波动,存在较多漏检的故障样本检测效果较差,而 DWPCA 和 M-WKPCA 法则都降低故障样本的漏检率,存在较少漏检样本,提高了准确检测率,分析表 1 中故障 10 的 DPR,M-WKPCA 法的检测准确率比 DWPCA 法更高,说明 M-WKPCA 法对于故障检测的提升更明显。综上可知,KPCA 法存在故障信息被覆盖的情况,所以,在故障 5 和故障 10 上的准确检测率都较低;DWPCA 法检测非线性故障能力有限;而 M-WKPCA 法能很好地解决非线性故障信息被覆盖的问题,提高 DPR。

综合考虑不同方法的性能,分别检测 TE 过程中 21 种故障,统计出每种故障的 DPR,见表 1,其中,M-WKPCA 法由于加权的原因每检测一种故障就需要单独建立一个故障检测模型。在 21 种故障中,3、9、15 这 3 种故障尺度较小,且在整个过程表




图 3 不同方法对故障 5 的检测效果

Fig. 3 Detection effect of fault 5 by different methods

现平稳,大部分多元统计方法无法检测,所以,对比方法和本文提出的方法对这 3 种故障的检测效果都较差^[16],对于故障 1、2、6、7、8、12、13、14、18 这些方法 DPR 都较高,方法间的区别并不大,而对于故障 4、5、10、16、17、19、20、21 在 M-WKPCA 法和 P-WKPCA 策略上的 DPR 都要比 PCA、KPCA 和 DWPCA 法高,在故障 11 上 DWPCA、M-WKPCA 法和 P-WKPCA 策略上 DPR 接近。对比不同检测方法的 DPR 平均值 M-WKPCA 法和 P-WKPCA 策略分别为 82.25% 和 83.29%,要远高于其他方法。综合上述分析结果,在 TE 过程 21 种故障上(除 3 种不易检测的故障)M-WKPCA 法和 P-WKPCA 策略要优于 PCA、KPCA 和 DWPCA 故障检测方法,表明:M-WKPCA 方法采用的加权改进和并行策略是有效的,通过利用历史故障数据可有效解决故障信息被覆盖的情况,进一步提高化工过程故障 DPR。




图 4 不同方法对故障 10 的检测效果

Fig. 4 Detection effect of fault 10 by different methods

表 1 TE 过程不同方法的 DPR

Table 1 DPR of different methods in TE process

故障序号	PCA	KPCA	DWPCA	M-WKPCA	P-WKPCA
1	0.992 7	0.993 8	0.994 8	0.996 9	0.999 0
2	0.985 4	0.984 4	0.977 0	0.986 5	0.987 5
3	0.212 5	0.245 8	0.299 6	0.249 0	0.249 0
4	0.760 4	0.852 1	0.991 6	0.997 9	0.997 9
5	0.396 9	0.431 3	0.990 6	0.996 9	0.999 0
6	0.994 8	0.994 8	0.996 9	0.999 0	1
7	0.996 9	0.994 8	0.764 0	1	1
8	0.980 2	0.977 1	0.802 7	0.989 6	0.991 7
9	0.206 3	0.214 8	0.190 0	0.191 7	0.230 2
10	0.530 2	0.581 3	0.793 3	0.868 8	0.868 8
11	0.672 9	0.721 9	0.833 0	0.812 5	0.829 2
12	0.986 5	0.980 2	0.986 4	0.981 3	0.995 8
13	0.954 2	0.955 2	0.838 2	0.962 5	0.962 5
14	0.996 9	0.994 8	0.999 0	0.999 0	0.999 0
15	0.226 0	0.266 7	0.295 4	0.255 2	0.309 4
16	0.386 5	0.455 2	0.788 1	0.909 4	0.909 4

续表 1

故障 序号	PCA	KPCA	DWPCA	M-WKPCA	P-WKPCA
17	0.865 6	0.880 2	0.913 3	0.966 7	0.969 8
18	0.911 5	0.910 4	0.913 3	0.919 8	0.924 0
19	0.307 3	0.388 5	0.181 6	0.750 0	0.766 7
20	0.587 5	0.641 7	0.762 0	0.815 6	0.816 7
21	0.526 0	0.531 3	0.422 8	0.625 0	0.685 4
平均值	0.689 4	0.714 1	0.749 2	0.822 5	0.832 9

4 结 论

1) 提出的 M-WKPCA 故障检测方法,在 TE 过

程 21 种故障上比 PCA、KPCA 和 DWPCA 方法有更高的平均 DPR。文中构建的加权矩阵,可提高主元空间故障信息,降低故障信息被覆盖的情况,使得主元空间故障信息更加突出,为化工过程故障检测提供一种新的多元统计故障检测方法。

2) 建立的并行 M-WKPCA 策略,在故障 DPR 进一步提高,说明提出并行方式的故障检测策略是有效的,可拓展 M-WKPCA 故障检测方法的应用范围。在后续工作中,将继续完善故障诊断的完整流程。文中仅研究了故障检测,没有探究故障发生的原因以及恢复故障等问题,这些都是未来有待研究的内容。

参 考 文 献

[1] 田宇. 基于优化动态核主元分析的复杂工业过程故障诊断研究[D]. 天津: 天津理工大学, 2020.
Tian Yu. Research on fault diagnosis of complex industrial process based on optimized dynamic kernel principal analysis[D]. Tianjin: Tianjin University of Technology, 2020.

[2] 杨余, 杨鑫, 王英, 等. 基于 mini-1D-CNN 模型的 TE 过程故障诊断[J]. 中国安全科学学报, 2023, 33(2): 173-178.
Yang Yu, Yang Xin, Wang Ying, et al. Research on TE process fault diagnosis based on mini-1D-CNN model[J]. China Safety Science Journal, 2023, 33(2): 173-178.

[3] 王斌, 施祖建, 匡蕾. 基于改进 KFDA 和 RW v-SVM 的化工生产系统故障快速诊断[J]. 中国安全科学学报, 2013, 23(8): 84-89.
Wang Bin, Shi Zujian, Kuang Lei. A fast method for diagnosing fault in chemical production system based on improved KFDA and RW v-SVM[J]. China Safety Science Journal, 2013, 23(8): 84-89.

[4] OdendAAL H M, Jones T. Actuator fault detection and isolation: an optimised parity space approach[J]. Control Engineering Practice, 2014, 26: 222-232.

[5] Wang Zun, Han Yongming, Li Chengfei, et al. Input-output networks considering graphlet-based analysis for production optimization: application in ethylene plants[J]. Journal of Cleaner Production, 2021, 278: 1-8.

[6] 张成, 高宪文, 李元. 基于 k 近邻主元得分差分的故障检测策略[J]. 自动化学报, 2020, 46(10): 2 229-2 238.
Zhang Cheng, Gao Xianwen, Li Yuan. Fault detection strategy based on principal component score difference of k nearest neighbors[J]. Acta Automatica Sinica, 2020, 46(10): 2 229-2 238.

[7] Ku Wenfu, Storer R H, Georgakis C. Disturbance detection and isolation by dynamic principal component analysis[J]. Chemometrics and Intelligent Laboratory Systems, 1995, 30(1): 179-196.

[8] Lee J, Yoo C K, Choi S W, et al. Nonlinear process monitoring using kernel principal component analysis[J]. Chemical Engineering Science, 2004, 59(1): 223-234.

[9] Jong M, Qin S J, Lee I B. Fault detection and diagnosis based on modified independent component analysis[J]. Aiche Journal, 2006, 52(10): 3 501-3 514.

[10] 柴天佑. 工业过程控制系统研究现状与发展方向[J]. 中国科学:信息科学, 2016, 46(8): 1 003-1 015.
Chai Tianyou. Industrial process control systems: research status and development direction [J]. Scientia Sinica: Informationis, 2016, 46(8): 1 003-1 015.

[11] Zhao Chunhui, Gao Furong. Fault-relevant principal component analysis (FPCA) method for multivariate statistical modeling and process monitoring[J]. Chemometrics and Intelligent Laboratory Systems, 2014, 133: 1-16.

[12] Jiang Qingchao, Yan Xuefeng. Chemical processes monitoring based on weighted principal component analysis and its application[J]. Chemometrics and Intelligent Laboratory Systems, 2012, 119: 11-20.

[13] Jiang Qingchao, Yan Xuefeng. Weighted kernel principal component analysis based on probability density estimation and

- moving window and its application in nonlinear chemical process monitoring[J]. Chemometrics and Intelligent Laboratory Systems, 2013, 127: 121–131.
- [14] Tao Yang, Shi Hongbo, Song Bing, et al. A novel dynamic weight principal component analysis method and hierarchical monitoring strategy for process fault detection and diagnosis[J]. IEEE Transactions on Industrial Electronics, 2019, 67(9): 7 994–8 004.
- [15] Chen Q, Wynne R J, Goulding P, et al. The application of principal component analysis and kernel density estimation to enhance process monitoring[J]. Control Engineering Practice, 2000, 8(5): 531–543.
- [16] Cheng Chunyuan, Hsu C, Chen Muchen. Adaptive kernel principal component analysis (KPCA) for monitoring small disturbances of nonlinear processes[J]. Industrial & Engineering Chemistry Research, 2010, 49(5): 2 254–2 262.
- [17] Guo Lingling, Wu Ping, Lou Siwei, et al. A multi-feature extraction technique based on principal component analysis for nonlinear dynamic process monitoring[J]. Journal of Process Control, 2020, 85: 159–172.
- [18] Bathelt a, Ricker N, Jelali M. Revision of the Tennessee Eastman process model[J]. IFAC-Papers on Line, 2015, 48(8): 309–314.
- [19] 林扬, 何亚东, 袁壮, 等. 基于 PCA-SVDD 的化工过程异常工况检测[J]. 过程工程学报, 2022, 22(7): 970–978.
- Lin Yang, He Yadong, Yuan Zhuang, et al. Abnormal condition detection in chemical process based on PCA-SVDD[J]. The Chinese Journal of Process Engineering, 2022, 22(7): 970–978.
- [20] Wang Jin, He Q P. Multivariate statistical process monitoring based on statistics pattern analysis[J]. Industrial & Engineering Chemistry Research, 2010, 49(17): 7 858–7 869.
- [21] Samuel R T, Cao Yi. Nonlinear process fault detection and identification using kernel PCA and kernel density estimation[J]. Systems Science & Control Engineering, 2016, 4(1): 165–174.



作者简介: 袁帅 (1998—),男,河南南阳人,硕士研究生,主要研究方向为化工过程故障检测和诊断、数据分析。E-mail:2403091313@qq.com。