

基于递推规范变量残差和核主元分析的微小故障检测

秦玉峰[†], 史贤俊

(海军航空大学 岸防兵学院, 山东 烟台 264001)

摘要: 微小故障由于故障征兆不明显从而很难在故障发生早期对其进行检测. 针对该问题, 本文提出了一种基于递推规范变量残差和核主元分析(RCVD-KPCA)的微小故障检测方法. 首先构造规范变量残差, 从中提取数据的线性特征. 利用指数加权滑动平均法对规范变量残差进行递推滤波处理, 提高规范变量残差对微小故障的敏感程度; 然后使用KPCA提取规范变量残差中的非线性主成分作为非线性特征, 根据提取的特征提出了两个新的故障检测统计量; 此外, 利用核密度估计确定故障检测统计量的控制限. 由于同时提取了过程数据的线性特征和非线性特征, 有效地提高了非线性动态过程中微小故障的可检测性. 以闭环连续搅拌釜式反应器过程为例进行了仿真分析, 仿真结果表明本文所提方法具有较好的故障检测性能.

关键词: 故障检测; 规范变量残差; 核主元分析; 微小故障; 指数加权滑动平均; 核密度估计

引用格式: 秦玉峰, 史贤俊. 基于递推规范变量残差和核主元分析的微小故障检测. 控制理论与应用, 2022, 39(9): 1716 – 1724

DOI: 10.7641/CTA.2022.10613

Incipient fault detection based on recursive canonical variate dissimilarity and kernel principal component analysis

QIN Yu-feng[†], Shi Xian-jun

(College of Coast Guard, Naval Aviation University, Yantai Shandong 264001, China)

Abstract: Incipient faults are difficult to be detected in the early stage because the symptoms are not obvious. In response to this problem, this paper proposes an incipient fault detection method based on the recursive canonical variate dissimilarity and the kernel principal component analysis (RCVD-KPCA). First, the canonical variate dissimilarity is constructed, and the linear features are extracted from the canonical variate dissimilarity. The exponentially weighted moving average method is used to recurse and filter the canonical variate dissimilarity to improve the sensitivity of canonical variate dissimilarity to incipient faults. Then, the KPCA is used to extract the nonlinear principal components in the canonical variate dissimilarity as nonlinear features. According to the extracted features, two new fault detection statistics are proposed. Furthermore, the kernel density estimation is used to determine the control limits of statistics. The method extracts the linear and nonlinear features of the process data at the same time, the detectability of incipient fault in the nonlinear dynamic process is improved. The process of a closed-loop continuous stirred tank reactor is taken as an example for simulation analysis, and the simulation results show that the proposed method has good performance in the incipient fault detection.

Key words: fault detection; canonical variate dissimilarity; kernel principal component analysis; incipient fault; exponentially weighted moving average; kernel density estimation

Citation: QIN Yufeng, SHI Xianjun. Incipient fault detection based on recursive canonical variate dissimilarity and kernel principal component analysis. *Control Theory & Applications*, 2022, 39(9): 1716 – 1724

1 引言

随着系统日益大型化和复杂化, 故障诊断技术已成为保证系统安全运行的一种重要手段^[1]. 按照故障引起的征兆大小, 可分为显著故障和微小故障. 微小故障在早期的主要特征是发展变化缓慢, 故障征兆不明显, 容易被噪声所淹没^[2]; 随着时间累积, 故障幅值缓慢增加进而发展成为显著故障^[3], 如果不及早发现,

可能会导致系统失效从而引发严重后果.

微小故障的特点导致了在早期检测到微小故障的发生是非常困难的. 现有的微小故障诊断方法主要包括基于知识的故障诊断方法、基于解析模型的故障诊断方法以及基于数据驱动的故障诊断方法. 考虑到系统结构组成及功能的复杂性, 基于知识和基于解析模型的故障诊断方法往往难以实施^[4-5]. 因此, 基于数据

驱动的微小故障诊断方法成为了研究热点^[6]. 其优点在于不需要完备的结构功能等先验知识, 也不需要构建精确的物理模型. 大量多元统计分析技术被用于微小故障检测领域^[7-11]. 如: Harmouche等^[12-13]针对传统主成分分析(principal component analysis, PCA)方法的 T^2 统计量存在对微小故障不敏感的问题, 提出了一种基于KL散度(Kullback-Leibler divergence, KLD)的微小故障检测方法; Zhang等^[14]将PCA和KLD相结合, 并对PCA所得到的投影向量进行优化, 使得投影向量对于KLD故障检测方法是局部最优的; Chen等^[15]基于KLD对非高斯电驱动系统的早期微小故障进行了检测, 并分析了该方法在较宽信噪比范围内的鲁棒性能; Cai等^[16]考虑到核主元分析模型不能敏感地检测微小故障初期的变化, 引入KLD来度量核主成分的变化程度, 提出了一种基于KLD-KPCA的微小故障诊断方法; 陶松兵等^[17]建立了基于协方差矩阵特征值变化与KLD变化的微小故障幅值估计模型; Gautam等^[18]利用扩展卡尔曼滤波器建立故障检测指标和故障特征, 然后基于KLD设计了故障决策统计量. 与KLD类似, Zhang等^[19]基于JS散度(Jensen-Shannon divergence, JSD)对早期微小故障进行检测和估计. 上述文献利用概率密度函数对微小故障较为敏感的特点, 通过衡量故障发生前后检测数据概率密度函数之间的差异, 实现对微小故障的检测. 这类方法通常需要假设检测数据服从正态分布, 但是实际系统可能不满足该要求, 因此应用范围受到一定限制.

另一类方法旨在提高残差对微小故障的灵敏度. 如: Ruiz-Cárcel等^[20]提出了基于规范变量分析(canonical variate analysis, CVA)的微小故障检测方法, 并验证了该方法的故障检测效果优于传统的PCA方法; Wu等^[21]将深度神经网络引入CVA中, 利用贝叶斯推理分类器对故障进行分类; 商亮亮等^[22-23]在CVA中引入了一阶干扰理论, 显著降低了计算负荷; 此外, Pilario等^[24-25]根据过去和未来规范变量之间的差异, 构造规范变量残差, 通过规范变量残差分析(canonical variate dissimilarity analysis, CVDA)来处理早期微小故障检测问题; Shang等^[26]基于CVDA提出了一种加权平均统计量, 提高了故障检测率; Li等^[27]基于CVDA提出了一个新的故障检测统计量, 对微小故障的发展变化更敏感, 同时仍然保持低的虚警率, 并改进了传统的贡献图方法, 提高了故障可识别性; Chen和Luo^[28]提出了一种新的多变量 q -sigma规则来监测规范变量残差, 并为每个变量都设置控制限, 降低了检测延时和虚警率; 肖妹君^[29]将CVDA推广到非线性过程, 提出了一种基于核规范变量残差分析(kernel canonical variate dissimilarity analysis, KCVDA)的故障检测方法; Pilario等^[30]将不同的核函数进行组合, 提出了一种基于混合KCVDA的非线性动态过程早期微小故障方法.

虽然CVDA以及KCVDA在微小故障检测方面具有一定的有效性, 但单一采用一种模型并不是最佳选择: CVDA仅提取数据中的线性特征, 无法提取数据的非线性特征, 这些非线性特征通常出现在线性模型的残差空间中^[31]; KCVDA将原始数据映射到高维空间, 从而忽略了原有空间的信息. 因此, 若仅用线性或非线性模型进行故障检测, 微小故障的可检测性是相对较低的. 针对上述问题, 本文提出了一种基于RCVD-KPCA的微小故障检测方法. 其主要贡献在于: 提出了一种混合统计建模方法, 同时提取过程数据的线性和非线性特征, 改进了非线性动态过程的早期微小故障检测性能, 提高了微小故障的可检测性.

2 基于CVDA的规范变量残差构建

作为一种线性降维技术, CVA能够最大程度地关联过去和未来数据集^[24-25]. 因此, 可以根据过去数据集对未来数据集的预测程度检测出数据变化. CVDA在CVA的基础上, 利用过去和未来规范变量之间的差异构造出规范变量残差, 通过规范变量残差检测数据变化. 下面介绍CVDA的具体实现方法.

设 $Y^0 = [y_1^0 \ \cdots \ y_n^0]^T \in \mathbb{R}^{n \times m}$ 为原始检测数据, 其中: $y_i^0 = [y_{1i}^0 \ \cdots \ y_{mi}^0]^T$, $i = 1, \dots, n$, n 为样本个数, m 为变量个数, $y_k^0 \in \mathbb{R}^m$ 为第 k 个样本. 对原始检测数据进行标准化处理

$$y_{ij} = \frac{y_{ij}^0 - \bar{y}_j}{s_j}, \quad (1)$$

式中: \bar{y}_j 为第 j 个变量的均值, s_j 为第 j 个变量的标准差, $j = 1, \dots, m$. 此时矩阵 Y^0 转化为: $Y = [y_1 \ \cdots \ y_n]^T$. 对于第 k 个检测样本, 其过去观测向量 $y_p(k)$ 和未来观测向量 $y_f(k)$ 可以用下式来表示:

$$y_p(k) = \begin{bmatrix} y_{k-1} \\ y_{k-2} \\ \vdots \\ y_{k-p} \end{bmatrix} \in \mathbb{R}^{mp}, \quad (2)$$

$$y_f(k) = \begin{bmatrix} y_k \\ y_{k+1} \\ \vdots \\ y_{k+f-1} \end{bmatrix} \in \mathbb{R}^{mf}, \quad (3)$$

式中 p 和 f 分别表示过去观测向量和未来观测向量的窗口长度. 定义过去和未来观测矩阵 $Y_p \in \mathbb{R}^{mp \times N}$ 和 $Y_f \in \mathbb{R}^{mf \times N}$

$$Y_p = [y_p(p+1) \ y_p(p+2) \ \cdots \ y_p(p+N)], \quad (4)$$

$$Y_f = [y_f(p+1) \ y_f(p+2) \ \cdots \ y_f(p+N)], \quad (5)$$

其中 $N = n - f - p + 1$. Y_p 和 Y_f 的协方差和互协方差可以用以下公式计算:

$$\Sigma_{pp} = \frac{1}{N-1} Y_p Y_p^T, \quad (6)$$

$$\Sigma_{ff} = \frac{1}{N-1} Y_f Y_f^T, \quad (7)$$

$$\Sigma_{fp} = \frac{1}{N-1} Y_f Y_p^T. \quad (8)$$

注1 为了避免 Σ_{pp} 和 Σ_{ff} 是奇异的, 参数 p 和 f 需要满足: $\{mp, mf\} < N$.

CVA的目标是找到投影矩阵 J 和 L , 使得 $JY_p(k)$ 和 $LY_f(k)$ 之间的相关性最大化, 其中 $JY_p(k)$ 和 $LY_f(k)$ 称为规范变量. 投影矩阵 J 和 L 一般可以通过奇异值分解计算

$$H = \Sigma_{ff}^{-1/2} \Sigma_{fp} \Sigma_{pp}^{-1/2} = USV^T, \quad (9)$$

式中: U 和 V 分别是由左右奇异向量组成的矩阵. 对角矩阵 S 由有序奇异值组成, $S = \text{diag}\{\Sigma_1, \dots, \Sigma_\gamma, 0, \dots, 0\}$, γ 为矩阵 H 的秩. 由于只有 q ($q < mp$)个主导奇异值描述系统的动态特性^[24,30], 因此取 U 和 V 具有最大相关性的前 q 列, 得到降维后的矩阵 U_q 和 V_q . 投影矩阵 J 和 L 分别为

$$J = V_q^T \Sigma_{pp}^{-1/2} \in \mathbb{R}^{q \times mp}, \quad (10)$$

$$L = U_q^T \Sigma_{ff}^{-1/2} \in \mathbb{R}^{q \times mf}. \quad (11)$$

对于第 k 个检测样本, 其状态向量 $x(k)$ 和残差向量 $e(k)$ 定义为

$$x(k) = JY_p(k), \quad (12)$$

$$e(k) = (I - V_q V_q^T) \Sigma_{pp}^{-1/2} Y_p(k), \quad (13)$$

式中 I 为适维单位阵. 利用 $x(k)$ 和 $e(k)$ 构造如下故障检测统计量:

$$T^2(k) = x^T(k)x(k), \quad (14)$$

$$Q(k) = e^T(k)e(k), \quad (15)$$

其中: $T^2(k)$ 统计量来度量状态向量 $x(k)$ 的变化; $Q(k)$ 统计量度量残差向量 $e(k)$ 的变化.

值得注意的是, 过去观测向量对未来观测向量的可预测性可以有效地检测数据的微小变化^[32]. 因此第 k 个检测样本的规范变量残差 $d(k)$ 可以表示为

$$d(k) = Ly_f(k) - S_q Jy_p(k), \quad (16)$$

式中: $S_q = \text{diag}\{\Sigma_1, \dots, \Sigma_q\}$. 记所有样本的规范变量残差组成的矩阵为 Y_d , 其协方差矩阵为

$$\Sigma_{dd} = I - S_q S_q^T. \quad (17)$$

基于马氏距离的相关定义构造故障检测统计量 D

$$D(k) = d^T(k) \Sigma_{dd}^{-1} d(k). \quad (18)$$

文献[24]证明了统计量 $D(k)$ 对微小故障检测的有效性, 但它只能评估过程数据中线性特征的变化. 由于线性模型的残差通常具有非线性特征, 其影响不能与其他不确定性相分离^[31], 使得模型具有更高的控制限, 从而降低了微小故障的可检测性. 为了提高故障

可检测性, 有必要进一步提取规范变量残差 d 中的非线性特征. 考虑到目前核方法技术成熟, 因此本文应用KPCA方法实现非线性特征提取.

3 基于RCVD-KPCA的故障检测

为了提高规范变量残差 d 对数据变化的敏感程度, 首先采用指数加权滑动平均法(exponentially weighted moving average, EWMA)对 d 进行滤波处理. EWMA是工程系统过程测量中一种常用的数据处理方法^[33], 其求解过程实际上是一个递推过程. 滤波后的数据 \hat{d} 可以用下式进行表示:

$$\begin{cases} \hat{d}(k) = d(k), & k = 1, \\ \hat{d}(k) = \varphi d(k) + (1 - \varphi) \hat{d}(k-1), & k > 1, \end{cases} \quad (19)$$

式中: φ ($0 \leq \varphi \leq 1$)为权重因子, φ 取值越大, \hat{d} 越能反应实际数据信息; φ 取值越小, \hat{d} 对数据的微小变化越敏感.

然后采用KPCA算法进一步提取 \hat{d} 中的非线性特征. 假设 \hat{d} 通过非线性函数 $\phi(\hat{d}) : \mathbb{R}^q \rightarrow \mathcal{F}$ 隐式映射到高维特征空间 \mathcal{F} , 且 $\sum_{i=1}^N \phi(\hat{d}(i)) = 0$. 然后求解样本协方差矩阵的特征值问题

$$C = \frac{1}{N} \sum_{i=1}^N \phi(\hat{d}(i)) \phi(\hat{d}(i))^T, \quad (20)$$

$$C\xi = \lambda\xi, \quad (21)$$

式中: C 为空间 \mathcal{F} 中的样本协方差矩阵, λ 为特征值, ξ 为特征向量. 由于 $\phi(\hat{d}(i))$ 无法显式表示, 因此式(21)不能够直接进行求解. 考虑到 ξ 被包含于 $\phi(\hat{d}(j))$, $j = 1, \dots, N$ 所张成的子空间中, 因此存在向量 $\eta = [\eta_1 \dots \eta_N]^T$, 使得 ξ 被表示为 $\phi(\hat{d}(j))$ 的线性组合

$$\xi = \sum_{j=1}^N \eta_j \phi(\hat{d}(j)). \quad (22)$$

式(21)可以改写为

$$\langle \phi(\hat{d}(k)), C\xi \rangle = \lambda \langle \phi(\hat{d}(k)), \xi \rangle, \quad (23)$$

式中 $\langle \cdot, \cdot \rangle$ 表示内积. 将式(20)(22)代入到式(23)中可得

$$\begin{aligned} & \lambda \sum_{j=1}^N \eta_j \langle \phi(\hat{d}(k)), \phi(\hat{d}(j)) \rangle = \\ & \frac{1}{N} \sum_{j=1}^N \eta_j \langle \phi(\hat{d}(k)), \sum_{i=1}^N \phi(\hat{d}(i)) \rangle \times \\ & \langle \phi(\hat{d}(i)), \phi(\hat{d}(j)) \rangle. \end{aligned} \quad (24)$$

定义核矩阵 $K \in \mathbb{R}^{N \times N}$, K 中元素满足

$$K_{ij} = \langle \phi(\hat{d}(i)), \phi(\hat{d}(j)) \rangle = \kappa(\hat{d}(i), \hat{d}(j)). \quad (25)$$

式中 $\kappa(\cdot, \cdot)$ 为核函数, $i, j = 1, \dots, N$. 本文选取高斯径向基函数作为核函数

$$\kappa(\hat{d}(i), \hat{d}(j)) = e^{-\|\hat{d}(i) - \hat{d}(j)\|^2/h}, \quad (26)$$

式中 h 为核宽度. 因此, 式(24)可以改写为

$$\lambda \sum_{j=1}^N \eta_j K_{kj} = \frac{1}{N} \sum_{j=1}^N \eta_j \sum_{i=1}^N K_{ki} K_{ij}, \quad (27)$$

即

$$\lambda N \eta = K \eta. \quad (28)$$

根据式(28)即可确定特征向量 η_1, \dots, η_N , 及其对应的特征值 $\lambda_1, \dots, \lambda_N$. 另外, 在计算前需要对矩阵 K 进行均值中心化

$$\bar{K} = K - I_N K - K I_N + I_N K I_N, \quad (29)$$

式中 $I_N \in \mathbb{R}^{N \times N}$ 且其中每个元素都为 $1/N$.

取累积方差贡献率前95%的 r 个特征值 $\lambda_1, \dots, \lambda_r$ 和其对应的特征向量 η_1, \dots, η_r , 对于第 k 个规范变量残差 $\hat{d}(k)$, 通过以下投影获得其主元得分向量 $\hat{t}_r(k)$:

$$\hat{t}_r(k) = [t_1(k) \ \dots \ t_r(k)], \quad (30)$$

$$t_i(k) = \sum_{j=1}^N \bar{K}_{kj} \eta_i^j, \quad (31)$$

式中: η_i^j 为特征向量 η_i 中的第 j 个元素, $i = 1, \dots, r$. 构造故障检测统计量 T_{ck}^2 和 Q_{ck} , 即

$$T_{ck}^2(k) = \hat{t}_r(k) \Lambda^{-1} \hat{t}_r^T(k), \quad (32)$$

$$Q_{ck}(k) = \hat{t}_N(k) \hat{t}_N^T(k) - \hat{t}_r(k) \hat{t}_r^T(k), \quad (33)$$

式中: $\Lambda = \text{diag}\{\lambda_1, \dots, \lambda_r\}$, $\hat{t}_N(k) = [t_1(k) \ \dots \ t_N(k)]$.

4 基于核密度估计的控制限设计

核密度估计(kernel density estimation, KDE)是一种确定控制上限的常用方法^[34], 尤其适用于非线性或非高斯分布过程数据. 考虑到实际检测数据不一定服从正态分布, 本文利用KDE确定故障检测统计量的控制限.

假设 x 为一个随机变量, $p(x)$ 为 x 的概率密度函数. 则

$$P(x < \varepsilon) = \int_{-\infty}^{\varepsilon} p(x) dx. \quad (34)$$

KDE中广泛使用的核函数是高斯核函数

$$k(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}. \quad (35)$$

通过高斯核函数估计 x 的概率密度函数

$$\hat{p}(x) = \frac{1}{N\psi} \sum_{i=1}^N k\left(\frac{x-x(i)}{\psi}\right). \quad (36)$$

式中: ψ 为带宽, $x(i), i = 1, 2, \dots, N$ 为 x 中第 i 个样本. 设某一故障检测统计量为 J , 其控制限为 J_{UCL} . 给定一个显著性水平 α , 则可以通过解决以下问题来计算 J_{UCL} :

$$P(J < J_{UCL}) = \int_{-\infty}^{J_{UCL}} \frac{1}{N\psi} \sum_{i=1}^N k\left(\frac{J-J(i)}{\psi}\right) dJ = \alpha. \quad (37)$$

若 $J \leq J_{UCL}$, 则认为没有发生故障发生; 若 $J > J_{UCL}$, 认为检测到故障.

总结本文所提方法, 其总体流程图如图1所示. 具体步骤如下.

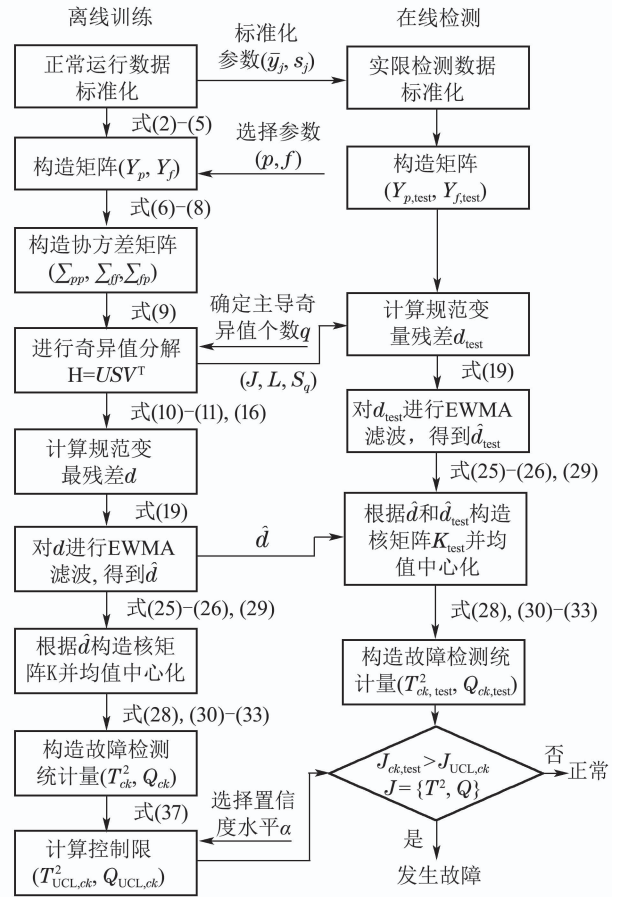


图1 RCVD-KPCA算法流程图
Fig. 1 Flow chart of RCVD-KPCA algorithm

离线训练:

- 步骤 1** 获取正常运行状态下的检测数据 Y^0 , 并对其进行标准化, 得到标准化后的检测数据 Y ;
- 步骤 2** 构造过去观测矩阵 Y_p 和未来观测矩阵 Y_f ;
- 步骤 3** 分别计算 Y_p 和 Y_f 的协方差和互协方差矩阵;
- 步骤 4** 对矩阵 H 执行奇异值分解, 并确定主导奇异值个数 q ;
- 步骤 5** 根据式(16)计算规范变量残差 d ;
- 步骤 6** 根据式(19)对 d 进行EWMA滤波, 得到滤波后的规范变量残差 \hat{d} ;
- 步骤 7** 构造核矩阵 K 并均值中心化, 求解其特征值和特征向量;
- 步骤 8** 根据式(30)–(31)计算主元得分向量 \hat{t}_r ;

步骤9 根据式(32)–(33)计算故障检测统计量 T_{ck}^2 和 Q_{ck} ;

步骤10 根据式(37)计算对应的控制限 $T_{UCL,ck}^2$ 和 $Q_{UCL,ck}$.

在线检测:

步骤1 获取实际检测数据, 并使用 Y^0 的均值和协方差对其进行标准化, 得到标准化后的检测数据 Y_{test} ;

步骤2 构造过去观测矩阵 $Y_{p,test}$ 和未来观测矩阵 $Y_{f,test}$;

步骤3 根据式(16)计算规范变量残差 d_{test} ;

步骤4 根据式(19)对 d_{test} 进行EWMA滤波, 得到滤波后的规范变量残差 \hat{d}_{test} ;

步骤5 利用 \hat{d} 和 \hat{d}_{test} 构造核矩阵 K_{test} 并均值中心化, 求解其特征值和特征向量;

步骤6 根据式(30)–(31)计算主元得分向量 $\hat{t}_{r,test}$;

步骤7 根据式(32)–(33)计算故障检测统计量 $T_{ck,test}^2$ 和 $Q_{ck,test}$;

步骤8 若 $T_{ck,test}^2 > T_{UCL,ck}^2$ 或 $Q_{ck,test} > Q_{UCL,ck}$, 则检测到故障发生.

5 仿真分析

使用闭环CSTR过程来验证本文所提出方法的有效性. 该过程的数据由以下非线性状态空间模型模拟获得

$$\begin{cases} \frac{dC}{dt} = \frac{Q}{V}(C_i - C) - a\tau C + \nu_1, \\ \frac{dT}{dt} = \frac{Q}{V}(T_i - T) - a\frac{(\Delta H_r)\tau C}{\rho C_p} - b\frac{UA}{\rho C_p V}(T - T_c) + \nu_2, \\ \frac{dT_c}{dt} = \frac{Q_c}{V_c}(T_{ci} - T_c) + b\frac{UA}{\rho_c C_{pc} V_c}(T - T_c) + \nu_3, \end{cases} \quad (38)$$

其中: 输入 $u = [C_i \ T_i \ T_{ci}]^T$, C_i 为反应物进料浓度, T_i 和 T_{ci} 分别为反应物进料温度和冷却剂进料温度. 输出 $y = [C \ T \ T_c \ Q_c]^T$, C 为反应器中反应物浓度, T 为反应器温度, T_c 为冷却剂温度, Q_c 为冷却剂流速. ν_1, ν_2, ν_3 为过程噪声, 噪声功率为 10^{-4} dB. τ 为速率常数, 满足 $\tau = \tau_0 e^{-E/RT}$, a 与 b 的标准值为1, 输出测量过程中存在均值为0, 方差为0.05的高斯白噪声. CSTR过程的原理图如图2所示.

CSTR过程通过控制冷却剂流速 Q_c 来维持反应器温度 T , 控制器设置为饱和度低于10 L/min和高于200 L/min. 表1给出了方程中其他参数的物理意义及

取值.

选取CSTR过程中的2个早期微小故障对本文所提方法进行验证, 故障的具体形式如表2所示.




图2 CSTR过程原理图

Fig. 2 Schematic of the CSTR

表1 CSTR过程参数物理意义及取值

Table 1 Parameters meanings and values in CSTR

参数	物理意义	取值
Q	入口流速	100 L/min
V	储罐容积	150 L
V_c	套管容积	10 L
ΔH_r	反应热	-2.0×10^5 cal/min
UA	传热系数	7.0×10^5 cal/(min · K ⁻¹)
τ_0	常数因子	7.2×10^{10} min ⁻¹
E/R	活化能	1.0×10^4 K
ρ, ρ_c	流体密度	1000 g/L
C_p, C_{pc}	流体热容	1.0 cal/(g · K ⁻¹)

表2 CSTR过程中的微小故障

Table 2 Incipient fault in CSTR

故障序号	故障名称	数学描述	δ
f_1	传感器漂移	$T_c = T_{c,0} + \delta t$	0.05
f_2	冷却套管结垢	$b = b_0 e^{-\delta t}$	0.001

其中下标0表示标准值.

由系统状态空间模型(38)及原理图可知, 当发生传感器漂移故障 f_1 时, 系统的过程参数不发生变化, 仅输出信号中 T_c 的测量值发生改变, 测量值随着系统运行逐渐增大; 当发生冷却套管结垢故障 f_2 时, b 逐渐减小, 直接对 T_c, T 产生影响, 进而导致 τ, C, Q_c 也发生变化.

仿真模拟运行时间为1200 min, 所有变量的采样间隔为1 min, 同时每隔60 min通过在输入 u 的标称值附近注入随机扰动 w 来改变操作状态, 其中: $w = [w_1 \ w_2 \ w_3]^T$, $w_1 \sim N(0, 0.002)$, $w_2, w_3 \sim N(0, 2)$. 带有随机扰动的输入会导致系统动态发生变化, 使得该过程非线性并且所得检测数据是非高斯分布的. 在故障数据集中, 正常运行200 min后引入故障. 所有故障检测指标的控制限显著性水平 α 设定为0.99. 选择 $p = f = 3$, $\varphi = 0.6$, $h = 60$. 为了评价算法的故障检测性能,

比较不同算法下故障检测延迟(detection delay, DD)、虚警率(false alarm rate, FAR)、漏检率(missed detection rate, MDR)等参考指标. 由于故障类型为缓变的早期微小故障, 因此故障检测统计量可能会在控制限的附近波动. 为了明确检测到故障时间, 本文定义检测到故障的时间为首次连续报警5次时的时间点. 定义检测延迟为故障发生到检测到故障所经历的时间. 虚警率和漏检率的计算方法如下:

$$\begin{cases} \text{FAR} = \frac{N_{\text{FA}}}{N_{\text{No Fault}}} \times 100\%, \\ \text{MDR} = \frac{N_{\text{MD}}}{N_{\text{Fault}}} \times 100\%. \end{cases}$$

式中: N_{FA} 为无故障发生时, $J > J_{\text{UCL}}$ 的样本数; $N_{\text{No Fault}}$ 为无故障发生的样本数; N_{MD} 为故障发生后, $J < J_{\text{UCL}}$ 的样本数; N_{Fault} 为存在故障的样本数. 为了体现本文方法的优越性, 与CVDA和KCVDA方法进行对比, 设CVDA方法中故障检测统计量分别为 T^2, Q, D , KCVDA方法中故障检测统计量分别为 T_k^2, Q_k, D_k , 所有方法的 p, f 和 h 与本文相同, 且控制限均通过KDE计算所得.

对于故障 f_1 , 其前200 min是正常数据, 在第200 min引入了冷却剂温度传感器漂移故障. 所得到的统计量监测图如图3-5所示.




图 3 CVDA故障1统计量监测图

Fig. 3 Statistical monitoring diagram of f_1 by CVDA

故障检测性能对比如表3所示.

根据实验结果可得: 在DD和MDR方面, 故障检测统计量 T_k^2, Q_k 相比 T^2, Q 都有所降低, 但是 T_k^2, Q_k, D_k 引发的虚警相比 T^2, Q, D 和 T_{ck}^2, Q_{ck} 明显增加. 在本案例中, Q_{ck} 的DD和MDR最低: Q_{ck} 在故障发生后的第13 min即检测到故障, 且MDR仅有1.2%. 说明 Q_{ck} 对数据的微小变化更加敏感, 采用本文方法能够

更快地检测出微小故障的发生. 另外, 虽然 T_{ck}^2 和 Q_{ck} 的虚警率不是最低的, 但是仍与 T^2, Q, D 保持在同一水平, 因此综合3个指标分析, T_{ck}^2 和 Q_{ck} 的故障检测效果更好.

表 3 发生故障 f_1 时的故障检测性能对比

Table 3 Comparison of fault detection performance when f_1 occurs

	CVDA			KCVDA			RCVD-KPCA	
	T^2	Q	D	T_k^2	Q_k	D_k	T_{ck}^2	Q_{ck}
DD/min	25	220	47	21	109	70	22	13
FAR/%	8.5	1.0	3.0	27.5	9.0	17.0	5.0	4.5
MDR/%	1.8	19.6	3.8	1.3	8.8	4.8	1.3	1.2

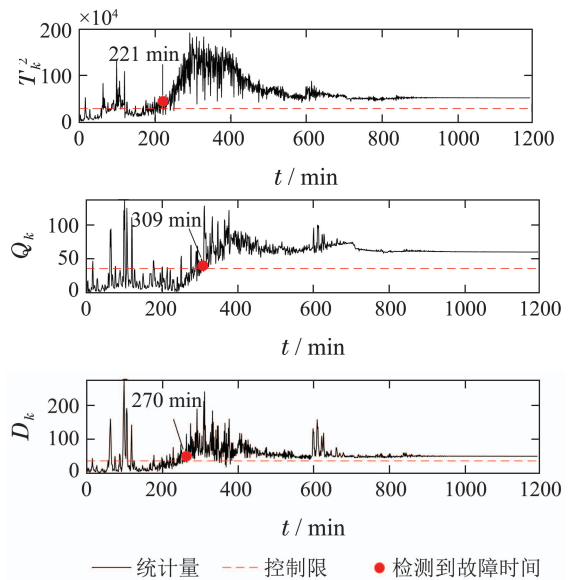


图 4 KCVDA故障1统计量监测图

Fig. 4 Statistical monitoring diagram of f_1 by KCVDA




图 5 RCVD-KPCA故障1统计量监测图

Fig. 5 Statistical monitoring diagram of f_1 by RCVD-KPCA

对于故障 f_2 ,其前200 min是正常数据,在第200 min采样点引入了冷却套管结垢故障. 所得到的统计量监测图如图6-8所示. 故障检测性能对比如表4所示.

在本案例中,故障检测统计量 T_k^2 具有最低的故障检测延迟,但是其虚警率FAR明显高于其他统计量,因此 T_k^2 在实践中是不可靠的. 故障检测统计量 T_{ck}^2 和 Q_{ck} 的故障检测延迟与 T_k^2 几乎相同,且 T_{ck}^2 和 Q_{ck} 的FAR和MDR分别为0%,7.3%和0%,5.9%,在所有的故障检测统计量中最低,说明 T_{ck}^2 和 Q_{ck} 的故障检测效果更好.

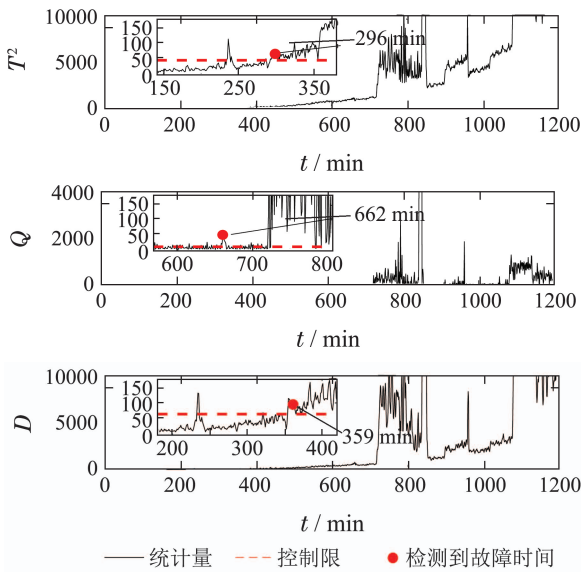


图6 CVDA故障2统计量监测图
Fig. 6 Statistical monitoring diagram of f_2 by CVDA

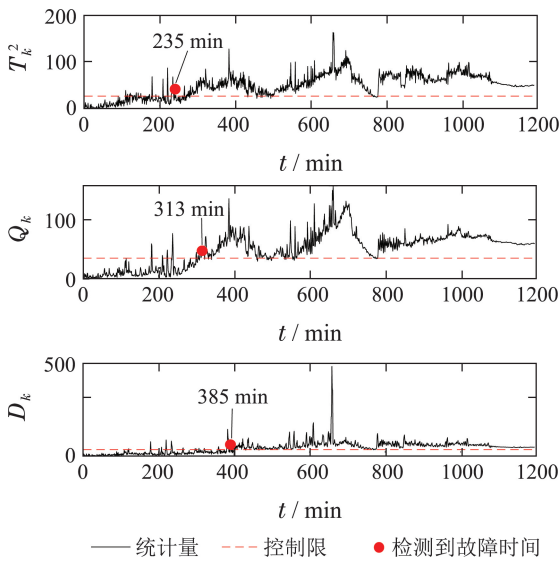


图7 KCVDA故障2统计量监测图
Fig. 7 Statistical monitoring diagram of f_2 by KCVDA

为了检验本文所提方法的鲁棒性,为故障 f_1 和 f_2 分别生成15个测试数据集,每个测试数据集中过程噪声和测量噪声的强度与前文一致. 所有测试数据集的

前200 min都是正常运行数据,在第200 min注入故障. 在得到所有的测试数据集后,测试CVDA, KCVDA, RCVD-KPCA的故障检测性能,结果如图9所示. 图9(a)-(b)分别为故障 f_1 和 f_2 的故障检测性能箱线图,其中每一行箱线图分别对应DD, FAR和MDR结果. 为了排除个别极端数据值的影响,选择15次故障检测结果的中位数表示故障检测性能的整体水平,如表5所示.

表4 发生故障 f_2 时的故障检测性能对比
Table 4 Comparison of fault detection performance when f_2 occurs

	CVDA			KCVDA			RCVD-KPCA	
	T^2	Q	D	T_k^2	Q_k	D_k	T_{ck}^2	Q_{ck}
DD/min	96	462	159	35	113	185	37	36
FAR/%	0	0	0	12.5	1.0	1.0	0	0
MDR/%	8.3	53.2	15.0	7.8	12.8	18.2	7.3	5.9


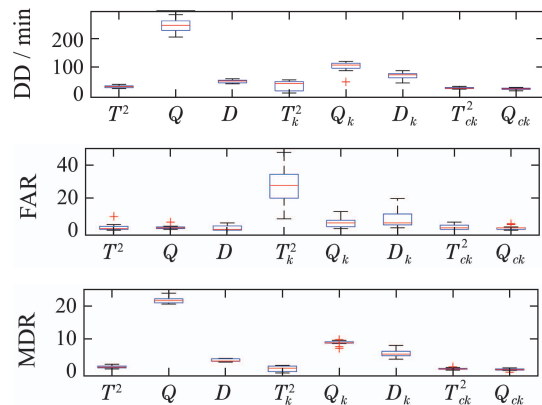

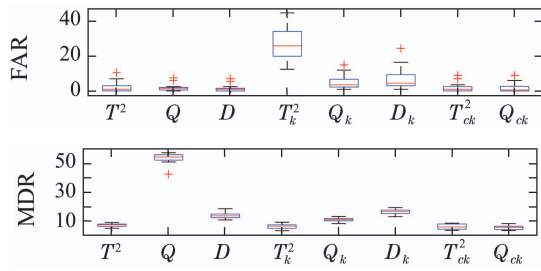


图8 RCVD-KPCA故障2统计量监测图
Fig. 8 Statistical monitoring diagram of f_2 by RCVD-KPCA



(a) f_1 故障检测性能箱线图





(b) f_2 故障检测性能箱线图

图 9 故障检测性能箱线图

Fig. 9 Fault detection performance boxplot

表 5 故障检测性能箱线图中位数

Table 5 Median of fault detection performance boxplot

	CVDA			KCVDA			RCVD-KPCA	
	T^2	Q	D	T_k^2	Q_k	D_k	T_{ck}^2	Q_{ck}
DD/min								
f_1	28	247	48	39	105	70	22	20
f_2	81	464	143	71	105	101	62	52
FAR/%								
f_1	1.0	1.5	0.5	27.5	4.5	4.5	1.5	1.5
f_2	1.0	1.5	1.0	26.0	3.5	4.5	1.0	0.5
MDR/%								
f_1	2.1	20.5	3.8	1.8	8.8	5.7	1.6	1.4
f_2	7.8	54.4	14.0	6.8	11.5	16.8	6.3	5.9

在检测早期微小故障时, 更早地检测到故障意味着延长了可用于处理故障的时间范围. 在这一时间段内, 可以根据故障的状态进行故障预测和基于状态的维护等活动. 因此, 及时检测到微小故障可以避免显著故障的发生. 一般来说, 一个好的故障检测指标必须具有较低的DD, FAR和MDR. 综合15次实验结果来看, 除了故障 f_1 情况下的 T^2 , T_k^2 和 D , D_k 以外, T_k^2 , Q_k , D_k 相比 T^2 , Q , D 在DD和MDR方面有所提升, 但是提升效果不明显, 且鲁棒性较差, 同时KCVDA引发的虚警数是最多的.

在两种故障场景下, 本文所提方法得到的故障检测统计量 T_{ck}^2 , Q_{ck} 与 T^2 , Q , D 相比, FAR具有相同水平, 但是具有更小的DD和MDR; 与 T_k^2 , Q_k , D_k 相比, T_{ck}^2 , Q_{ck} 的3个指标都优于 T_k^2 , Q_k , D_k . 与 Q 相比, Q_{ck} 在检测时间上的改进幅度最大, 也具有更好的鲁棒性. 此外, T_{ck}^2 和 Q_{ck} 在有效降低DD和MDR的情况下, 虚警率没有显著提高, 分别只有(f_1 : 1.5%, f_2 : 1.0%)和(f_1 : 1.5%, f_2 : 0.5%), 因此 T_{ck}^2 , Q_{ck} 是故障检测效果更好的统计量. 由于CSTR过程同时包含线性和非线性关系, 相比于传统的CVDA或KCVDA方法仅使用线性或非线形模型, RCVD-KPCA由于使用了线性-非

线性混合模型, 故障检测效果更好, 上述实验结果验证了本文所提方法的有效性. 综上所述, 本文所提方法的优点如下: 1) 利用EWMA对规范变量残差进行滤波, 提高了规范变量残差对数据变化的敏感程度; 2) 通过串联模型结构将CVDA和KPCA相结合, 利用非线性主元对规范变量残差数据中的非线性变化进行准确捕捉, 提高了故障检测效果.

6 结论

本文提出了一种基于递推规范变量残差和核主元分析的微小故障检测方法. 仿真结果表明, 与传统的CVDA和KCVDA方法相比, 本文方法所得到的故障检测统计量不仅能够更快地检测到微小故障, 而且虚警率和漏检率较低, 验证了本文方法具有较好的故障检测性能. 进行故障检测的根本目的是为了诊断故障并给出解决方案, 现有的基于规范变量残差的故障诊断方法绝大多数都是仅单独使用线性或非线形模型, 这些方法无法用于本文所提出的线性-非线形混合模型, 因此下一步工作将在此基础上进一步研究适用于本文所提模型的微小故障诊断方法.

参考文献:

- [1] WEN Chenglin, LÜ Feiya, BAO Zhejing, et al. A review of data driven-based incipient fault diagnosis. *Acta Automatica Sinica*, 2016, 42(9): 1285 – 1299. (文成林, 吕菲亚, 包哲静, 等. 基于数据驱动的微小故障诊断方法综述. *自动化学报*, 2016, 42(9): 1285 – 1299.)
- [2] ZHANG X X, DELPHA C, DIALLO D. Incipient fault detection and estimation based on Jensen-Shannon divergence in a data-driven approach. *Signal Processing*, 2020, 169: 107410.
- [3] LI Juan, ZHOU Donghua, SI Xiaosheng, et al. Review of incipient fault diagnosis methods. *Control Theory & Applications*, 2012, 29(12): 1517 – 1529. (李娟, 周东华, 司小胜, 等. 微小故障诊断方法综述. *控制理论与应用*, 2012, 29(12): 1517 – 1529.)
- [4] DENG X G, DENG J W. Incipient fault detection for chemical processes using two-dimensional weighted SLKPCA. *Industrial & Engineering Chemistry Research*, 2019, 58(6): 2280 – 2295.
- [5] WEN Chenglin, HU Yucheng. Fault diagnosis based on information incremental matrix. *Acta Automatica Sinica*, 2012, 38(5): 832 – 840. (文成林, 胡玉成. 基于信息增量矩阵的故障诊断方法. *自动化学报*, 2012, 38(5): 832 – 840.)
- [6] LI Jinbing, HAN Bing, FENG Shoubo, et al. Fault detection based on block kernel principal component analysis and support vector machine. *Control Theory & Applications*, 2020, 37(4): 847 – 854. (李锦冰, 韩冰, 冯守渤, 等. 基于分块核主成分分析和支持向量机的故障检测. *控制理论与应用*, 2020, 37(4): 847 – 854.)
- [7] CHEN H T, JIANG B, LU N Y, et al. Deep PCA based real-time incipient fault detection and diagnosis methodology for electrical drive in high-speed trains. *IEEE Transactions on Vehicular Technology*, 2018, 67(6): 4819 – 4830.
- [8] ZHANG C, GAO X W, XU T, et al. Fault detection and diagnosis strategy based on a weighted and combined index in the residual subspace associated with PCA. *Journal of Chemometrics*, 2018, 32(11): e2981.

- [9] JI H Q, HE X, SHANG J, et al. Incipient fault detection with smoothing techniques in statistical process monitoring. *Control Engineering Practice*, 2017, 62: 11 – 21.
- [10] ZHANG Y W, ZHOU H, QIN S J. Decentralized fault diagnosis of large-scale processes using multiblock kernel principal component analysis. *Acta Automatica Sinica*, 2010, 36(4): 593 – 597.
- [11] ZHANG Caixia, WANG Zihan, WEN Chenglin, et al. Sample space based on multi-level high dimensional feature representation micro-fault diagnosis. *Acta Electronica Sinica*, 2020, 48(8): 1647 – 1654. (张彩霞, 王子涵, 文成林, 等. 样本空间基于多级高维特征表示的微小故障诊断. *电子学报*, 2020, 48(8): 1647 – 1654.)
- [12] HARMOUCHE J, DELPHA C, DIALLO D. Incipient fault detection and diagnosis based on Kullback–Leibler divergence using principal component analysis: Part I. *Signal Processing*, 2014, 94: 278 – 287.
- [13] HARMOUCHE J, DELPHA C, DIALLO D. Incipient fault detection and diagnosis based on Kullback–Leibler divergence using principal component analysis: Part II. *Signal Processing*, 2015, 109: 334 – 344.
- [14] ZHANG G, YANG Q, LI G T, et al. A satellite incipient fault detection method based on local optimum projection vector and Kullback–Leibler divergence. *Applied Sciences*, 2021, 11(2): 797.
- [15] CHEN H T, JIANG B, LU N Y. An improved incipient fault detection method based on Kullback–Leibler divergence. *ISA Transactions*, 2018, 79: 127 – 136.
- [16] CAI P P, DENG X G, CAO Y P. Incipient fault diagnosis of sucker rod pumping system using Kullback–Leibler divergence based improved kernel principal component analysis. *Proceedings of CAA Symposium on Fault Detection, Supervision and Safety for Technical Processes*. Xiamen, China: IEEE, 2019: 761 – 766.
- [17] TAO Songbing, CHAI Yi, WANG Yiming, et al. Incipient fault diagnosis of sensors in the closed-loop system utilizing Kullback–Leibler divergence. *Control Theory & Applications*, 2019, 36(6): 909 – 914. (陶松兵, 柴毅, 王一鸣, 等. 基于Kullback–Leibler距离的闭环系统传感器微小故障诊断. *控制理论与应用*, 2019, 36(6): 909 – 914.)
- [18] GUATAM S, TAMBOLI P K, ROY K, et al. Sensors incipient fault detection and isolation of nuclear power plant using extended Kalman filter and Kullback–Leibler divergence. *ISA Transactions*, 2019, 92: 180 – 190.
- [19] ZHANG X X, DELPHA C, DIALLO D. Performance of Jensen Shannon divergence in incipient fault detection and estimation. *Proceedings of IEEE International Conference on Acoustics, Speech and Signal Processing*. Brighton, United Kingdom: IEEE, 2019: 2742 – 2746.
- [20] RUIZ-CÁRCEL C, CAO Y, MBA D, et al. Statistical process monitoring of a multiphase flow facility. *Control Engineering Practice*, 2015, 42: 74 – 88.
- [21] WU P, LOU S W, ZHANG X J, et al. Data-driven fault diagnosis using deep canonical variate analysis and fisher discriminant analysis. *IEEE Transactions on Industrial Informatics*, 2021, 17(5): 3324 – 3334.
- [22] SHANG Liangliang, LIU Jianchang, TAN Shubin, et al. Recursive canonical variate analysis for fault detection of time-varying processes. *Journal of Northeastern University (Natural Science)*, 2016, 37(12): 1673 – 1676. (商亮亮, 刘建昌, 谭树彬, 等. 基于递推规范变量分析的时变过程故障检测. *东北大学学报(自然科学版)*, 2016, 37(12): 1673 – 1676.)
- [23] SHANG Liangliang, LIU Jianchang, TAN Shubin, et al. Soft sensor modeling for multimode process based on adaptive efficient recursive canonical variate analysis. *Control Theory & Applications*, 2016, 33(3): 380 – 386. (商亮亮, 刘建昌, 谭树彬, 等. 基于自适应高效递推规范变量分析的多模过程软传感器建模. *控制理论与应用*, 2016, 33(3): 380 – 386.)
- [24] PILARIO K E S, CAO Y. Canonical variate dissimilarity analysis for process incipient fault detection. *IEEE Transactions on Industrial Informatics*, 2018, 14(12): 5308 – 5315.
- [25] PILARIO K E S, CAO Y, SHAFIEE M. Incipient fault detection, diagnosis, and prognosis using canonical variate dissimilarity analysis. *Proceedings of the 29th European Symposium on Computer Aided Process Engineering*. Eindhoven, The Netherlands: IEEE, 2019, 46: 1195 – 1200.
- [26] SHANG L L, YAN Z, LI J H, et al. Canonical residual based incipient fault detection method for industrial process. *Proceedings of Chinese Control and Decision Conference*. Hefei, China: IEEE, 2020: 987 – 992.
- [27] LI X C, YANG X Y, YANG Y J, et al. Canonical variate residuals-based contribution map for slowly evolving faults. *Journal of Process Control*, 2019, 76: 87 – 97.
- [28] CHEN B, LUO X L. Novel multivariate q -sigma rule focusing on process variation for incipient fault detection in dynamic processes. *Chemometrics and Intelligent Laboratory Systems*, 2020, 206: 104149.
- [29] XIAO Shujun. *Research on fault detection method based on kernel canonical variate analysis*. Beijing: Beijing University of Chemical Technology, 2019. (肖姝君. 基于核规范变量分析的故障检测方法研究. 北京: 北京化工大学, 2019.)
- [30] PILARIO K E S, CAO Y, SHAFIEE M. Mixed kernel canonical variate dissimilarity analysis for incipient fault monitoring in nonlinear dynamic processes. *Computers & Chemical Engineering*, 2019, 123: 143 – 154.
- [31] DENG X G, TIAN X M, CHEN S, et al. Nonlinear process fault diagnosis based on serial principal component analysis. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 29(3): 560 – 572.
- [32] LARIMORE W E. Optimal reduced rank modeling, prediction, monitoring and control using canonical variate analysis. *IFAC Proceedings Volumes*, 1997, 30(9): 61 – 66.
- [33] LIU J Y, LI G N, CHEN H X, et al. A robust online refrigerant charge fault diagnosis strategy for VRF systems based on virtual sensor technique and PCA–EWMA method. *Applied Thermal Engineering*, 2017, 119: 233 – 243.
- [34] ODIOWEI P E P, CAO Y. Nonlinear dynamic process monitoring using canonical variate analysis and kernel density estimations. *IEEE Transactions on Industrial Informatics*, 2010, 6(1): 36 – 45.

作者简介:

秦玉峰 博士研究生, 目前研究方向为故障可诊断性评价与设计,

E-mail: Hy-qyf082@163.com;

史贤俊 教授, 博士生导师, 目前研究方向为飞行器智能检测与故

障诊断、测试性设计与评估等, E-mail: sxjaa@sina.com.