

基于自适应滑窗递归稀疏主成分分析的 工业过程故障监测

刘金平¹, 王 杰¹, 唐朝晖², 贺俊宾^{1,4}, 谢永芳², 马天雨^{1,3}

(1. 湖南师范大学智能计算与语言信息处理湖南省重点实验室, 湖南长沙 410081;
2. 中南大学自动化学院, 湖南长沙 410083; 3. 湖南师范大学物理与电子科学学院, 湖南长沙 410081;
4. 湖南省计量检测研究院, 湖南长沙 410014)

摘 要: 本文提出一种自适应滑窗递归稀疏主成分分析方法,用于时变工业过程的在线故障监测. 首先,通过滑窗提取正常过程数据空间的特征信息,并对当前窗口数据块矩阵进行稀疏主成分分析,构建稀疏主成分分析故障监测模型;然后,根据相邻窗口的相似度实时调整遗忘因子以自适应更新滑窗大小,使得所建立的稀疏主成分故障监测模型可以有效追踪复杂的时变过程;最后,通过递归更新滑窗稀疏载荷矩阵来动态更新故障监测模型. 非线性数值仿真系统与田纳西-伊斯曼过程的故障监测结果表明,所提方法可以有效提高故障检测的准确率,适应于长流程时变工业过程在线故障监测.

关键词: 时变工业过程; 故障监测; 滑动窗口; 递归稀疏主成分分析

中图分类号: TP273 **文献标识码:** A **文章编号:** 0372-2112 (2020)09-1795-09

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2020.09.018

Industrial Process Fault Monitoring Based on Adaptive Sliding Window-Recursive Sparse Principal Component Analysis

LIU Jin-ping¹, WANG Jie¹, TANG Zhao-hui², HE Jun-bin¹, XIE Yong-fang², MA Tian-yu³

(1. Hunan Provincial Key Laboratory of Intelligent Computing and Language Information Processing, Hunan Normal University, Changsha, Hunan 410081, China;
2. School of Automation, Central South University, Changsha, Hunan 410083, China;
3. School of Physics and Electronics, Hunan Normal University, Changsha, Hunan 410081, China;
4. Hunan Institute of Metrology and Test, Changsha, Hunan 410014, China)

Abstract: This paper presents an adaptive sliding window recursive sparse principal component analysis method for the on-line fault monitoring of time-varying industrial processes. Firstly, feature information of normal process data space is extracted by the sliding window, and the sparse principal component analysis is applied to the current window block matrix to construct the sparse principal component analysis-based process fault monitoring model. Then, the forgetting factor is adjusted in real time according to the similarities of adjacent windows to update the sliding window size adaptively, so that the sparse principal component fault monitoring model can effectively track the time-varying process. Finally, the sparse load matrix of the sliding window is renewed recursively to update the fault monitoring model dynamically. Fault monitoring results of the nonlinear numerical simulation system and the Tennessee-Eastman process show that the proposed method can effectively improve the fault detection accuracy and adapt to the on-line fault monitoring of long process industries with time-varying processes.

Key words: time-varying industrial processes; fault monitoring; sliding window; recursive sparse principal component analysis (RSPCA)

收稿日期: 2019-07-25; 修回日期: 2019-10-24; 责任编辑: 梅志强

基金项目: 国家自然科学基金项目 (No. 61971188, No. 61771492, No. U1701261, No. 61725306); 湖南省自然科学基金项目 (No. 2018JJ3349); 湖南省知识产权战略推进专项项目 (No. 2019F011K); 湖南省研究生科研创新项目 (No. CX2018B31, No. CX20190415)

1 引言

工业过程监测,特别是工业过程异常监测或者故障在线监测,是保证生产安全、减少或避免工况异常产生、提高产品质量和经济效益的关键^[1,2].主成分分析(Principle Component Analysis, PCA)作为工业过程监控领域常见的多元统计过程监测方法(Multivariate Statistical Process Monitoring, MSPM)被广泛应用于多种连续工业过程监控中. PCA 通过线性变换将工业过程监测中的原始高维过程数据投影到低维线性空间,得到互不相关的主成分信息以表征原始数据空间的结构信息,进而在新的低维空间进行过程监测^[3].然而,PCA 所得到的主成分是原变量的线性组合且线性变换系数通常是非零值,使得 PCA 在实际应用中存在可解释性差、灵敏度不高和计算量大等问题^[4].

因而,一些研究学者提出一些改进方法来进行复杂工业过程监测. Zou 等人^[5]提出一种稀疏主成分分析方法(Sparse PCA, SPCA),采用 Lasso 和 Ridge 结合的弹性回归网进行主成分稀疏化求解,获得较好的故障监测效果;Scholkopf 等人^[6]基于非线性映射函数将测量变量投影到高维特征空间,提出基于核主成分分析(Kernel PCA, KPCA)的过程监测方法,克服了传统 PCA 方法受限于线性过程的缺点;Lee 等人^[7]提出一种基于独立主成分分析(Independent Component Analysis, ICA)的过程监测方法,克服了复杂工业过程数据的非高斯分布问题.

上述 MSPM 方法都是面向稳定工况进行的,然而,现代工业过程普遍具有非线性、非高斯、非稳态的时变特性^[8],这些传统的 MSPM 方法因难以适应于现代工业过程的时变特性,在进行故障监测时极易造成虚警率高,或因计算复杂度高未能对故障及时报警,难以对复杂工业过程进行长时间在线监测^[9].

针对复杂工业过程工况状态的时变特性,一些学者提出了基于滑窗模型的过程故障监测方法.随着窗口的移动,窗口不断纳入新的数据并丢弃旧的数据,从而动态更新过程监测数据的标准差、均值和协方差等统计信息以及及时更新过程监测模型^[10],从而提高过程监测模型的自适应能力和更新效率.

然而,传统的滑窗过程监测仍面临以下两大难题:

(1) 滑窗长度的选取问题.窗口过大对过程故障检测迟钝,窗口过小则会造成所建立的局部模型的稳定性较差,严重时极易造成误报和漏报^[11].

(2) 历史数据的舍取问题.在窗口滑动过程中,传统的过程监测方法直接舍弃历史数据或者采用某种加权遗忘因子以降低历史数据的影响,历史数据的取舍受经验性的限制.

鉴于传统滑窗 MSPM 模型中存在的问题,本文提出一种自适应滑窗递归稀疏主成分分析(Adaptive Sliding Window-Recursive SPCA, ASW-RSPCA)方法,用于复杂工业过程的在线故障监测.首先基于窗口数据块建立初始的 SPCA 故障监测模型,再通过滑窗扫描正常工况数据集,根据相邻窗口相似度实时调整遗忘因子以自适应遗忘部分历史数据,获得与工况相适应的滑窗数据块用于过程监测模型更新,然后递归更新滑窗数据块稀疏载荷矩阵,从而动态更新故障监测模型,保证过程监测模型的实时监测能力.非线性数值仿真系统和田纳西-伊斯曼(TE)过程的实验结果表明,相比于其他方法,该方法具有计算复杂度低、可有效提高故障监测准确率,适应于长流程时变工业过程的在线故障监测.

2 稀疏主成分分析(SPCA)

考虑观测数据矩阵 $\mathbf{X} = [\mathbf{x}_1^T, \mathbf{x}_2^T, \dots, \mathbf{x}_n^T]^T \in \mathbf{R}^{n \times m}$, m 为变量维数, n 为采样数.不失一般性, \mathbf{X} 为标准化处理后的矩阵.

首先,将 PCA 问题转化为 Ridge 回归问题:

$$(\hat{\mathbf{A}}, \hat{\mathbf{B}}) = \operatorname{argmin} \sum_{i=1}^n \|\mathbf{x}_i - \mathbf{x}_i \mathbf{B} \mathbf{A}^T\|_2^2 + \lambda_2 \sum_{j=1}^p \|\mathbf{B}_j\|_2^2 \quad (1)$$

式中, \mathbf{A} 表示主成分载荷矩阵, \mathbf{B} 表示稀疏载荷矩阵, λ_2 为惩罚系数, p 为主成分的个数.

然后,引入 Lasso 惩罚项对主成分稀疏化,获得 SPCA 模型^[12]如下:

$$(\hat{\mathbf{A}}, \hat{\mathbf{B}}) = \operatorname{argmin}_{\mathbf{A}, \mathbf{B}} \left\{ \sum_{i=1}^n \|\mathbf{x}_i - \mathbf{x}_i \mathbf{B} \mathbf{A}^T\|_2^2 + \lambda_{1,j} \sum_{j=1}^p \|\mathbf{B}_j\|_1 + \lambda_2 \sum_{j=1}^p \|\mathbf{B}_j\|_2^2 \right\} \quad (2)$$

式中, $\lambda_{1,j}$ 为稀疏惩罚系数.

3 自适应递归稀疏主成分分析(ASW-RSPCA)

本节详细分析了 ASW-RSPCA 算法的核心思路.

3.1 滑动窗口模型

滑动窗口模型为观测样本顺序排列的动态数据块矩阵,第 k 个数据窗口表示为:

$$\mathbf{X}_k^0 = [\mathbf{x}_{k+1}^T, \mathbf{x}_{k+2}^T, \dots, \mathbf{x}_{k+L}^T]^T \quad (3)$$

式中 L 为窗口的大小.窗口的统计特征由均值 m_k 、标准差矩阵 $\boldsymbol{\Sigma}_k$ 和 Gram 矩阵 \mathbf{G}_k 进行描述,定义为,

$$\boldsymbol{\Sigma}_k = \operatorname{Diag}(\sigma_k^1, \sigma_k^2, \dots, \sigma_k^m) \quad (4)$$

$$\mathbf{G}_k = \mathbf{X}_k^T \mathbf{X}_k \quad (5)$$

式中, $\sigma_k^i = \sqrt{(x_{ij} - m_j)^2 / L}$, $i = 1, 2, \dots, L, j = 1, 2, \dots, m$, \mathbf{X}_k 为标准化后的数据块矩阵.

当窗口滑动后,第 $k+1$ 个数据窗口表示为:

$$\mathbf{X}_{k+1}^0 = [\mathbf{x}_{k+\ell+1}^T, \mathbf{x}_{k+\ell+2}^T, \dots, \mathbf{x}_{k+L+H}^T]^T \quad (6)$$

式中, H 为滑动步长, ℓ 为自适应丢弃样本的数量.

随着窗口的滑动,描述窗口的统计量也会发生变化,新窗口的 Gram 矩阵更新为:

$$\mathbf{G}_{k+1} = \mathbf{G}_k + \mathbf{G}_H - \mathbf{G}_\ell + (L - \ell)(\boldsymbol{\varphi} - \boldsymbol{\psi}) \quad (7)$$

式中, $\boldsymbol{\varphi} = \boldsymbol{\Sigma}_{k+1}^T \Delta \mathbf{m}_{k+1} \Delta \mathbf{m}_{k+1}^T \boldsymbol{\Sigma}_{k+1}^{-1}$, $\boldsymbol{\psi} = \boldsymbol{\Sigma}_k^T \Delta \mathbf{m}_k \Delta \mathbf{m}_k^T \boldsymbol{\Sigma}_k^{-1}$, $\Delta \mathbf{m}_{k+1} = \mathbf{m}_{k+1} - \mathbf{m}_*$, $\Delta \mathbf{m}_k = \mathbf{m}_k - \mathbf{m}_*$, \mathbf{m}_* 为过渡数据窗口 $[\mathbf{x}_{k+\ell+1}^T, \mathbf{x}_{k+\ell+2}^T, \dots, \mathbf{x}_{k+L}^T]$ 的均值向量, \mathbf{G}_H 为新增数据块 $[\mathbf{x}_{k+L+1}^T, \mathbf{x}_{k+L+2}^T, \dots, \mathbf{x}_{k+L+H}^T]$ 的 Gram 矩阵, \mathbf{G}_ℓ 为丢弃数据块 $[\mathbf{x}_{k+1}^T, \mathbf{x}_{k+2}^T, \dots, \mathbf{x}_{k+\ell}^T]^T$ 的 Gram 矩阵.

3.2 滑窗大小自适应选择

为反映新窗口相对于旧窗口特征信息的变化情况,基于新旧窗口相似度信息建立可量化的窗口遗忘指标来自适应更新窗口大小.

定义新增数据窗口和旧窗口的混和 Gram 矩阵:

$$\mathbf{G}_\Omega = \begin{bmatrix} \mathbf{G}_k \\ \mathbf{G}_H \end{bmatrix} \quad (8)$$

对 \mathbf{G}_Ω 进行特征值分解,其特征值对角阵和特征向量分别表示为 \mathbf{A}_Ω 和 \mathbf{P}_Ω . 定义转换矩阵:

$$\mathbf{P}_0 = \mathbf{P}_\Omega \mathbf{A}_\Omega^{-\frac{1}{2}} \quad (9)$$

通过转换矩阵 \mathbf{P}_0 对 \mathbf{G}_k 和 \mathbf{G}_H 进行变换,可得:

$$\begin{cases} \mathbf{G}'_k = \mathbf{P}_0^T \mathbf{G}_k \mathbf{P}_0 \\ \mathbf{G}'_H = \mathbf{P}_0^T \mathbf{G}_H \mathbf{P}_0 \end{cases} \quad (10)$$

由式(9)和式(10)可推导出转换后的矩阵满足:

$$\mathbf{P}_0^T \mathbf{G}_\Omega \mathbf{P}_0 = \mathbf{G}'_k + \mathbf{G}'_H = \mathbf{I} \quad (11)$$

对转换后的 \mathbf{G}'_k 和 \mathbf{G}'_H 进行特征值分解得到 Y_i^k 和 Y_i^H , $i = 1, 2, \dots, m$, m 为特征值的个数,由式(11)分析可知:

$$Y_i^k + Y_i^H = 1 \quad (12)$$

因此,特征值 Y_i^k 和 Y_i^H 关于 0.5 对称, Y_i^k 越接近 0.5, \mathbf{G}_k 和 \mathbf{G}_H 的相似度越高. 文献[13]指出可以采用如下指标判别不同时段两个过程数据的相似度,

$$\mu = 1 - \frac{4 \sum_{i=1}^m (Y_i^k - 0.5)}{m} \quad (13)$$

本文选用 μ 作为旧窗口的遗忘因子,对旧数据进行自适应丢弃. 设置遗忘个数 $\ell = \mu L$, 将其代入公式可得,

$$\mathbf{G}_{k+1} = \mathbf{G}_k + \mathbf{G}_H - \mathbf{G}_\ell + L(1 - \mu)(\boldsymbol{\varphi} - \boldsymbol{\psi}) \quad (14)$$

3.3 载荷矩阵和特征值矩阵递归更新

在进行特征值分解时,常规的 SVD 方法计算量大. 为降低算法计算量,本文采用 Lanczos 算法^[14]对 \mathbf{G}_{k+1} 的分解因式递归计算 SVD, 获得 \mathbf{G}_{k+1} 的低秩逼近,实现对载荷矩阵和特征值矩阵的递归更新.

由式(14)可知 \mathbf{G}_{k+1} 为实对称矩阵,对 \mathbf{G}_{k+1} 作正交

变换,可得:

$$\mathbf{G}_{k+1} = \boldsymbol{\Phi} \mathbf{T} \boldsymbol{\Phi}^T \quad (15)$$

式中, \mathbf{T} 矩阵为稀疏三角阵,其特征值分解计算复杂度低,表示如下:

$$\mathbf{T} = \begin{bmatrix} a_0 & b_1 & 0 & 0 & \dots \\ b_1 & a_1 & b_2 & 0 & \dots \\ 0 & b_2 & a_2 & b_3 & \dots \\ \dots & \dots & \dots & \dots & \dots \end{bmatrix} \quad (16)$$

采用分治法快速进行特征值分解,将 \mathbf{T} 分为两个部分分别求解特征值:

$$\begin{cases} \mathbf{T}_1 = \mathbf{Q}_1 \mathbf{D}_1 \mathbf{Q}_1^T \\ \mathbf{T}_2 = \mathbf{Q}_2 \mathbf{D}_2 \mathbf{Q}_2^T \end{cases} \quad (17)$$

将 \mathbf{T}_1 和 \mathbf{T}_2 合并,表示如下:

$$\mathbf{T} = \begin{pmatrix} \mathbf{Q}_1 & \\ & \mathbf{Q}_2 \end{pmatrix} (\mathbf{D} + \boldsymbol{\eta} \boldsymbol{\zeta} \boldsymbol{\zeta}^T) \begin{pmatrix} \mathbf{Q}_1^T \\ & \mathbf{Q}_2^T \end{pmatrix} \quad (18)$$

式中, $\mathbf{D} = \begin{pmatrix} \mathbf{D}_1 & \\ & \mathbf{D}_2 \end{pmatrix}$, $\boldsymbol{\zeta}^T = (\mathbf{q}_1^T, \mathbf{q}_2^T)$, \mathbf{q}_1^T 为 \mathbf{Q}_1 的最后一行, \mathbf{q}_2^T 为 \mathbf{Q}_2 的第一行. $\mathbf{D} + \boldsymbol{\eta} \boldsymbol{\zeta} \boldsymbol{\zeta}^T$ 的特征值求解问题转化为求解 Secular 方程的根,

$$1 + \boldsymbol{\eta} \boldsymbol{\zeta}^T (\mathbf{D} - h\mathbf{I})^{-1} \boldsymbol{\zeta} = 0 \quad (19)$$

文献[15]给出了 Secular 方程的解法,得到特征值为 $\mathbf{A} = [h_1, h_2, \dots, h_m]$, 由式(19)可得 $(\mathbf{D} - h\mathbf{I})^{-1} \boldsymbol{\zeta}$ 为对应特征向量,其所组成的矩阵为 $\boldsymbol{\Psi} = [\boldsymbol{\Psi}_1, \boldsymbol{\Psi}_2, \dots, \boldsymbol{\Psi}_m]$.

因此, $\mathbf{D} + \boldsymbol{\eta} \boldsymbol{\zeta} \boldsymbol{\zeta}^T$ 可分解为 $\mathbf{D} + \boldsymbol{\eta} \boldsymbol{\zeta} \boldsymbol{\zeta}^T = \boldsymbol{\Psi} \mathbf{A} \boldsymbol{\Psi}^T$, 令

$$\mathbf{Q} = \begin{pmatrix} \mathbf{Q}_1 & \\ & \mathbf{Q}_2 \end{pmatrix} \boldsymbol{\Psi} \quad (20)$$

将式(20)代入至式(18),可知

$$\mathbf{T} = \mathbf{Q} \mathbf{A} \mathbf{Q}^T \quad (21)$$

进而得新数据窗口的 Gram 矩阵递归分解为:

$$\mathbf{G}_{k+1} = \boldsymbol{\Phi} \mathbf{Q} \mathbf{A} (\boldsymbol{\Phi} \mathbf{Q})^T \quad (22)$$

通过 \mathbf{G}_{k+1} 进行稀疏主成分的递归求解时,对式(2)中给出的 SPCA 优化问题,采用交替方向乘子算法 (Alternating Direction Method of Multipliers, ADMM)^[16] 进行求解.

不失一般性,定义 l_1 约束的最小二乘问题的增广拉格朗日函数为:

$$\begin{aligned} J(\boldsymbol{\theta}, \mathbf{w}, \boldsymbol{\rho}) = & \| \mathbf{y} - \mathbf{A} \boldsymbol{\theta} \|_2^2 + \lambda \| \mathbf{w} \|_1 + \\ & \boldsymbol{\rho}^T (\boldsymbol{\theta} - \mathbf{w}) + \frac{1}{2} \| \boldsymbol{\theta} - \mathbf{w} \|_2^2 \end{aligned} \quad (23)$$

式中 $\boldsymbol{\rho}, \boldsymbol{\theta}, \mathbf{w}$ 为更新参数. 将 ADMM 算法推广至 $l_1 + l_2$ 约束的最小二乘求解,并结合式(14),得到递推稀疏载荷矩阵的更新方程为:

$$\mathbf{B}_{k+1} = [\mathbf{G}_{k+1} + (\boldsymbol{\rho} + l_\rho) \mathbf{I}_\rho]^{-1} (\mathbf{G}_{k+1} + \mathbf{w} - \boldsymbol{\rho}) \mathbf{A}_{k+1} \quad (24)$$

式中 \mathbf{I}_p 为单位向量, \mathbf{I}_p 为单位矩阵.

至此,总结 ASW-RSPCA 算法流程如算法 1 所示.

算法 1 ASW-RSPCA

输入: 数据矩阵 \mathbf{X} , 初始窗口大小 L , 滑动步长 H .

输出: 稀疏主成分载荷矩阵 \mathbf{B}_{k+1} .

步骤 1 初始化数据窗口 \mathbf{X}_1 , 采用式(5)计算 Gram 矩阵 $\mathbf{G}_1 = \mathbf{X}_1^T \mathbf{X}_1$, 流程计数 $k = 1$.

步骤 2 遗忘因子的自适应选择: 采用式(13)计算 \mathbf{G}_1 和新增数据块的 Gram 矩阵 \mathbf{G}_H 的相似度 μ , 作为窗口 \mathbf{X}_1 的遗忘数据量的百分比.

步骤 3 求取递归 Gram 矩阵: 根据 $\mathbf{G}_1, \mathbf{G}_H$ 和 μ 采用式(14)递归计算新窗口的 Gram 矩阵 \mathbf{G}_2 .

步骤 4 特征值分解: 采用式(22)对递归的 Gram 矩阵 \mathbf{G}_2 进行快速的特征值分解.

步骤 5 迭代更新递归稀疏载荷矩阵: 采用 ADMM 迭代算法求解稀疏载荷矩阵(更新方程为式(24)), 直到更新程序收敛得到最优解 \mathbf{B}_{k+1} 停止迭代.

步骤 6 $k = k + 1$, 执行下一次循环.

4 基于 ASW-RSPCA 的工业过程故障监测

本节主要介绍基于 ASW-RSPCA 的工业过程故障监测统计量的计算和工业过程在线监测的主要步骤.

4.1 故障监测统计量的计算

在工业过程故障在线监测中, 新测试样本 $\mathbf{x}_{\text{new}}, k + 1$ 时刻统计监测指标计算如下:

$$\begin{cases} T_{k+1}^2 = \mathbf{x}_{\text{new}} \mathbf{B}_{k+1} \mathbf{R}_{k+1}^{-1} \mathbf{B}_{k+1}^T \mathbf{x}_{\text{new}}^T \\ Q_{k+1} = \|\mathbf{x}_{\text{new}} (\mathbf{I} - \mathbf{B}_{k+1} \mathbf{A}_{k+1}^T)\|_2^2 \end{cases} \quad (25)$$

式中, \mathbf{B}_{k+1} 为稀疏载荷矩阵, \mathbf{A}_{k+1} 为主成分载荷矩阵, \mathbf{R}_{k+1} 为协方差矩阵, 可由 \mathbf{G}_{k+1} 计算得知.

第 $k + 1$ 时刻数据窗口的 T^2 和 Q 控制限计算如下:

$$\begin{cases} T_{\text{threshold}}^2(k+1) = g_{T_{k+1}}^2 \chi_{h_{T_{k+1}}, \alpha}^2 \\ Q_{\text{threshold}}(k+1) = g_{Q_{k+1}}^2 \chi_{h_{Q_{k+1}}, \alpha}^2 \end{cases} \quad (26)$$

式中, $g = v/(2m)$, $h = 2m^2/v$, v 和 m 分别代表数据窗口的方差和均值, α 为自由度.

4.2 工业过程在线故障监测步骤

基于 ASW-RSPCA 的工业过程在线故障监测的主要步骤如下:

步骤 1 收集正常工况下的样本数据集, 设定数据窗口大小为 L , 滑动步长为 H , 初始计数器 $k = 0$.

步骤 2 对窗口进行标准化处理, 根据贡献率理论确定保留主元的个数, 提取窗口数据的主成分.

步骤 3 采用 SPCA 算法稀疏化窗口数据的主成分, 建立初始的工业过程故障监测模型, 确定窗口过程监测统计量 T^2 和 SPE 的过程控制限.

步骤 4 在线采集工业过程数据 x_i , 采用步骤 2 中

计算的均值和方差对 x_i 进行标准化处理, 根据当前的模型信息, 计算 x_i 监测统计量 T^2 和 SPE 的值. 如果统计量超出过程控制限, 则表明 x_i 为故障样本, 转至步骤 7; 否则, x_i 为正常样本, 执行累加操作 $k = k + 1$.

步骤 5 如果计数器 $k = H$, 则更新窗口数据, 窗口向前滑动 H 个步长, 比较 H 个步长的数据块与当前窗口的相似度, 对当前窗口进行自适应遗忘, 产生新数据窗口, 并把 H 个监测样本加入至正常的训练集中, 置 $k = 0$, 转至步骤 6; 如果 $k < H$, 窗口不移动, 模型不更新, 转至步骤 7.

步骤 6 根据更新后的窗口, 递归更新稀疏主成分分析的故障监测模型, 同时更新 T^2 和 SPE 的过程监测控制限, 转至步骤 7.

步骤 7 $i = i + 1$, 转至步骤 4.

5 实验验证

为验证本文方法的有效性, 采用典型的非线性数值仿真系统和 TE 过程进行故障监测实验.

5.1 数值仿真系统

5.1.1 模型介绍

考虑如下非线性系统模型:

$$\begin{cases} y_1 = 3s_1 + 2s_2 + \varepsilon \\ y_2 = s_1 + \sin(s_2) + \varepsilon \\ y_3 = 5\cos(s_1) + 3s_2 + \varepsilon \\ y_4 = s_1 + s_2^2 + \varepsilon \\ y_5 = \exp(s_1) + s_2^2 + \varepsilon \end{cases} \quad (27)$$

式中 y_1, y_2, y_3, y_4, y_5 代表模型的 5 个观测变量, s_1 和 s_2 为潜变量, ε 为高斯噪声. 式(28)和(29)给出时变过程发生前后两种数据分布, 过程数据 1 和过程数据 2 分别产生 200 组样本和 300 组样本作为初始训练数据 $\mathbf{X}_{500 \times 5}$.

$$\text{model1} = \begin{cases} s_1: \text{Uniform}(1, 2) \\ s_2: \text{Normal}(5, 1) \\ \varepsilon: \text{Normal}(0, 0.1) \end{cases} \quad (28)$$

$$\text{model2} = \begin{cases} s_1: \text{Uniform}(0, 1) \\ s_2: \text{Normal}(0, 0.5) \\ \varepsilon: \text{Normal}(0, 0.1) \end{cases} \quad (29)$$

引入阶跃信号构造仿真故障数据, 定义如下:

$$\mathbf{X}_f = \mathbf{X} + \mathbf{f} \boldsymbol{\varepsilon}_p \quad (30)$$

式中, p 为可能发生故障的变量, $\boldsymbol{\varepsilon}_p = [0, 0, \dots, 1, \dots, 0]$ 为故障方向向量, \mathbf{f} 为故障信号. 在工况 2 中, 从 201 个样本到第 300 个样本, 在变量 y_4 中引入幅值为 15 的阶跃信号作为故障数据. 即第 200 组到 300 组为带有故障的样本, 其他为正常样本数据, 构成测试集.

5.1.2 过程监测

将 ASW-RSPCA 方法应用到上述数值仿真过程, 并

与 PCA, PLS, KPCA 和 SPCA 方法进行比较,其故障监测如图 1(a)~(d)所示. 实验中,各种对比方法的参数设置如下:本数值案例所有方法主元数均通过 85% 方差累计贡献率确定;PLS 方法选取变量 y_4 作为质量变量;KPCA 方法中,核函数取核半径为 20 的高斯核函数;SPCA 方法中,Lasso 惩罚系数、迭代次数和收敛条件分别为 300 和 1×10^{-5} ;自适应滑动窗口递归 SPCA 方法中,窗口大小 $L = 50$,滑动步长 $H = 50$,其它的参数设置与 SPCA 方法设置相同. 所有方法控制限的置信度设置为 99%.

从图 1(a)~(d)可以看出,对于引入的故障信号(即第 200 个到第 300 个采样点),PCA、PLS、KPCA 和 SPCA 方法均没有监测到,或者监测效果极差. 其中,KPCA 方法的 SPE 统计量故障引入点检测出极少的故障点. 对于第 0 到 200 个采样点,KPCA 方法出现大量的误报. PLS 和 SPCA 方法的 SPE 统计量故障信号呈现报警的趋势,但由于整体控制限保持较高的水平,使得统计量并没有超出控制限,产生大量漏报. ASW-RSPCA 故障监测结果如图 1(e)所示,其中在第 1 到 200 个采样点上,过程数据统计特性保持不变,控制限发生微调. 在故障信号引入时,ASW-SPCA 方法的控制限发生了相应调整,保证了监测的灵敏度和准确性. 基于 ASW-RSPCA 的故障监测方法随着过程工况状态的变化能动态调整历史数据的贡献比例,获得不同的遗忘因子,保证了故障监测模型自适应能力.

5.2 TE 仿真系统

TE 过程较好地模拟了实际复杂工业过程控制系统的许多典型特征,常被作为仿真例子来评价故障诊断方法的可行性^[17].

5.2.1 数据介绍

TE 过程数据包含了正常状态和 21 种不同的故障状态,即 IDV1~IDV21. 其中,IDV1~IDV7 的故障类型为阶跃变化;IDV8~IDV12 为随机变化故障类型;IDV13 的故障类型为缓慢漂移;IDV14、IDV15 和 IDV21 表示阀门卡死;其余的故障类型未知. 除了搅拌器的搅拌速度以外,每种状态共有 52 个变量,按采样顺序构成监测矩阵,并分为训练集和测试集. 训练集为 500 个正常样本数据. 测试集前 160 个样本为正常样本,后 800 个样本为带有故障的样本.

5.2.2 实验设计与性能评价指标

为了充分验证本文所提出方法的有效性,首先对算法的性能进行测试,然后使用本文所提方法对 21 种类型的故障数据进行监测,并与 PCA、PLS、KPCA、SPCA 进行比较,各方法主元数均通过贡献率理论确定,各方法详细参数设置如表 1 所示.

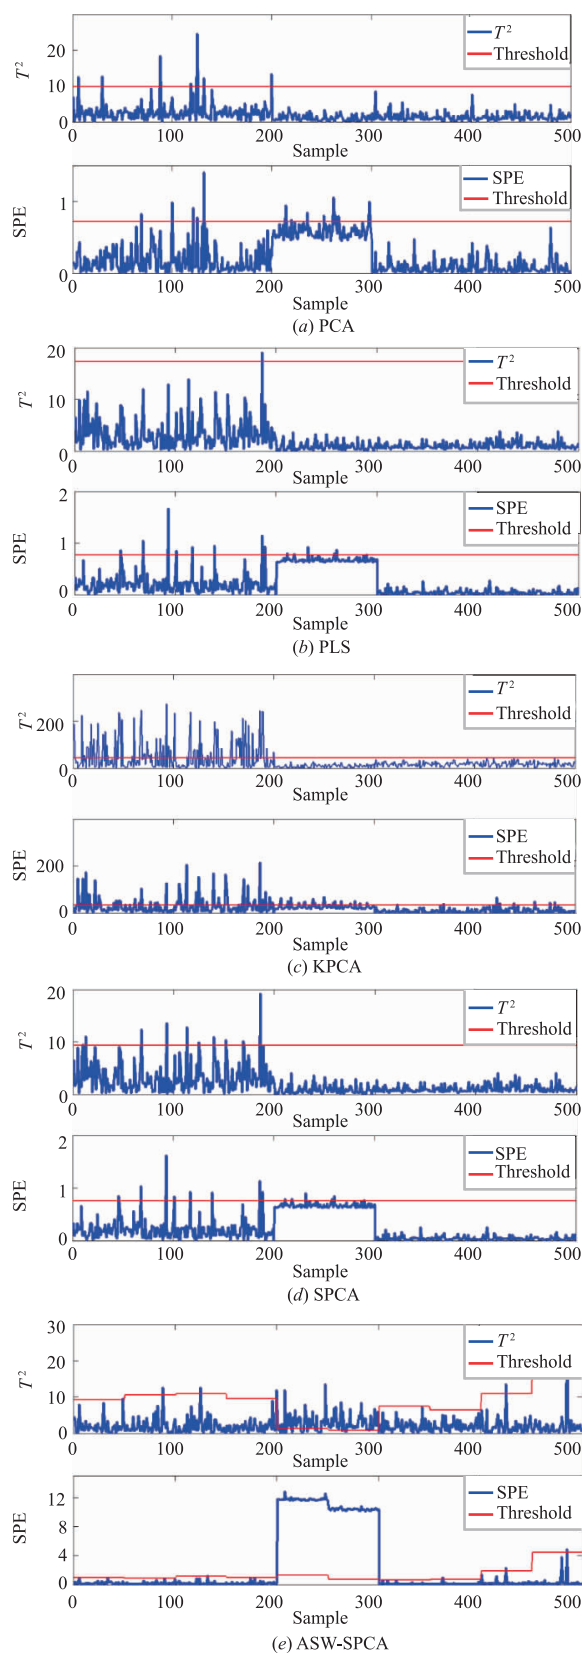


图1 数值仿真系统故障监测结果对比

表 1 各方法的参数设置

方法	CPV	α	核函数	惩罚项	窗口参数
PCA	90%	0.01	—	—	—
PLS	90%	0.01	—	—	—
KPCA	90%	0.01	$\sigma = 20$	—	—
SPCA	90%	0.01	—	$\lambda_1 = 0.5$	—
ASW-RSPCA	90%	0.01	—	$\lambda_1 = 0.5$	$H = 100 L = 100$

实验选用故障检测的误报率 (FAR)、漏检率 (MDR) 和准确率 (ACC) 对模型检测能力进行评估, 定义如下:

$$FAR = \frac{FN}{FN + TP} \quad (31)$$

$$MDR = \frac{FP}{TN + FP} \quad (32)$$

$$ACC = \frac{TP + TN}{TN + FP + FN + TP} \quad (33)$$

式中, TN、FP、FN、TP 为分类问题中混淆矩阵中的元素, 如表 2 所示. 误报率和漏报率越低, 准确率越高, 故障监测的性能越好.

表 2 混淆矩阵

	预测为故障样本	预测为正常样本
实际为故障样本	TN	FP
实际为正常样本	FN	TP

5.2.3 实验结果分析

5.2.3.1 验证性实验

图 2 ~ 图 8 分别代表 ASW-RSPCA 故障监测方法在故障 5、7、8、13、16、17 和 21 的故障监测图. 图中红色曲线代表置信度为 99% 的控制限, 蓝色曲线为各样本点 T^2 和 SPE 统计量的值, 当 T^2 和 SPE 统计量超过过程控制限, 则认为是故障样本, 否则认为是正常样本.




图 2 故障 5 监测结果




图 3 故障 7 监测结果




图 4 故障 8 监测结果




图 5 故障 13 监测结果




图 6 故障 16 监测结果




图 7 故障 17 监测结果




图 8 故障 21 监测结果

从图 2 和图 3 可以看出, 故障 5 和 7 均能在故障引入点 (即第 161 个样本) 点附近检测出故障. 随着时间的推移, 故障检测统计量的值逐渐趋于稳定, 验证了故

障为阶跃类型.图 5 到图 7 表现为相应故障发生后,故障监测统计量的值并未趋向稳定,而是发生随机变化,故障类型为随机变化类型.故障 5、13 和 16 的监测图显示,ASW-RSPCA 方法的过程控制限能够适应窗口数据的变化情况,避免由于离线建模丧失对缓变数据或动态数据的追踪能力,实现过程数据统计量异常的准确报警.而故障 21 则是在第 600 个样本点才监测出故障,为未知类型故障.上述监测结果表明,所提出的 ASW-RSPCA 方法具有一定的灵敏性,能够适应于不同类型的故障监测.

5.2.3.2 对比性实验

为了进一步验证所提方法故障监测的有效性,实验对 TE 过程不同类型的故障分别进行故障监测,并以 MDR、FDR 和 ACC 作为评价指标,量化比较本文方法与 PCA、PLS、KPCA、SPCA 方法.图 9 和图 10 分别为不同方法对不同类型故障监测的误报率和漏报率.表 3 为不同方法在故障 IDV1-IDV21 的故障检测准确率.

从图 9 和图 10 中可以看出,SPCA 方法相对于传统的 PCA 方法和 PLS 方法,漏报率和误报率有所下降;KPCA 方法通过引入核函数,提高了对非线性数据的检测能力,漏报率和误报率与 SPCA 方法相当;而所提方法在 SPCA 方法的基础上,增加了滑动窗口和递归更新策略,相对于其他方法,其漏报率和误报率明显下降,故障监测能力显著提升.




图9 故障漏报率对比图




图10 故障漏报率对比图

从表 3 的对比性结果可以看出,所提方法在多故障检测的准确率方面均高于其他方法:对故障 1、2、6 和 7 等的检测率达到 100%,对于过程数据的均值和方差与正常数据相差不多的故障 3、4、9 和 15 等,使得统计量与过程控制限较为接近,为较难检测的故障类型,而所提方法其检测率有所提高;但从另外 17 种故障的准确

率和平均值来看,ASW-RSPCA 方法的故障检测率具有较大的优势.

表 3 不同方法的检测准确率对比 (%)

FaultNo	PCA	PLS	KPCA	SPCA	ASW-RSPCA
IDV1	99.20	99.25	99.14	99.13	100
IDV2	98.03	97.36	98.75	98.38	100
IDV3	1.50	5.00	6.38	6.23	15.71
IDV4	4.57	6.33	4.00	3.25	8.21
IDV5	22.50	23.25	24.12	30.75	36.45
IDV6	99.00	99.63	99.47	99.13	100
IDV7	91.37	100	100	100	100
IDV8	96.32	97.50	97.50	95.44	98.28
IDV9	1.05	3.00	3.00	0.88	3.88
IDV10	23.55	26.63	29.88	31.93	43.13
IDV11	21.16	22.36	31.50	29.12	39.82
IDV12	98.45	97.99	98.25	91.78	99.64
IDV13	94.83	92.51	96.87	93.00	95.83
IDV14	83.96	86.18	84.36	91.32	95.70
IDV15	1.81	1.63	1.77	1.38	2.51
IDV16	20.63	20.59	23.91	25.96	37.21
IDV17	75.36	77.25	75.86	80.14	98.62
IDV18	89.37	89.48	89.34	89.25	94.10
IDV19	10.40	11.64	15.79	9.36	17.65
IDV20	30.63	32.00	31.64	34.39	42.26
IDV21	40.32	39.65	42.94	39.88	54.16
MACC	52.57	53.77	54.97	54.79	61.10

6 结论

为提高流程工业过程故障监测的可靠性和自适应能力,本文在传统 SPCA 故障监测模型基础上,结合滑动窗口和递归协方差矩阵实时更新模型的思想,提出了一种基于 ASW-RSPCA 的在线故障监测方法.使得过程监测模型可以跟踪工况的时变过程,克服了传统的主成分模型在监测动态非平稳数据时误报警和漏报警高并存在延时报警的缺点.数值仿真系统和 TE 过程的验证性实验表明,本文所提出的方法收敛快,具有一定的稳定性、灵敏性.在故障的检测率、误报率和漏报率方面要优于其他方法.所提出的 ASW-RSPCA 故障监测方法可以为大规模复杂工业过程长时间监测提供一种新的思路.同时,如何将所提方法有效应用到实际的分布式复杂回路工业过程的故障监测中,进一步实现自适应滑动窗口步长选取,获得易混淆的过渡过程以及回路过程中的微小故障的在线检测、诊断与溯因结果是

下一步亟待解决的问题。

参考文献

- [1] 郑近德,潘海洋,戚晓利,等. 基于改进经验小波变换的时频分析方法及其在滚动轴承故障诊断中的应用[J]. 电子学报,2018,46(2):358-364.
Zheng J, Pan H, Qi X, et al. Enhanced empirical wavelet transform based time-frequency analysis and its application to rolling bearing fault diagnosis[J]. Acta Electronica Sinica,2018,46(2):358-364. (in Chinese)
- [2] 张丹威,王晓东,黄国勇. 相关系数 SVD 增强随机共振的单向阀故障诊断[J]. 电子学报,2018,46(11):2696-2704.
Zhang D, Wang X, Huang G. Check valve fault diagnosis with correlation coefficient SVD enhanced stochastic resonance[J]. Acta Electronica Sinica,2018,46(11):2696-2704. (in Chinese)
- [3] Li W, Peng M, Wang Q. Fault detectability analysis in PCA method during condition monitoring of sensors in a nuclear power plant[J]. Annals of Nuclear Energy,2018,119(9):342-351.
- [4] Ait-Izem T, Harkat M F, Djeghaba M, et al. On the application of interval PCA to process monitoring: A robust strategy for sensor FDI with new efficient control statistics[J]. Journal of Process Control,2018,63(1):29-46.
- [5] Zou H, Hastie T, Tibshirani R. Sparse principal component analysis[J]. Journal of Computational & Graphical Statistics,2006,15(2):265-286.
- [6] Sch Lkopf B, Smola A, M LLER K-R. Nonlinear component analysis as a kernel eigenvalue problem[J]. Neural Computation,1998,10(5):1299-1319.
- [7] Lee J M, Yoo C K, Lee I B. Statistical process monitoring with independent component analysis [J]. Journal of Process Control,2004,14(5):467-485.
- [8] Qui Ones-Grueiro M, Prieto-Moreno A, Verde C, et al. Data-driven monitoring of multimode continuous processes: A review[J]. Chemometrics and Intelligent Laboratory Systems,2019,189(1):56-71.
- [9] WANG B, LI H X. A sliding window based dynamic spatiotemporal modeling for distributed parameter systems with time-dependent boundary conditions[J]. IEEE Transactions on Industrial Informatics,2019,15(4):2044-2053.
- [10] Liu X, Kruger, Uwe, et al. Moving window kernel PCA for adaptive monitoring of nonlinear processes [J]. Chemometrics & Intelligent Laboratory Systems,2009,96(2):132-143.
- [11] Wang Y, Sun K, Yuan X, et al. A novel sliding window PCA-IPF based steady-state detection framework and its industrial application [J]. IEEE Access,2018,6(99):20995-21004.
- [12] Gajjar S, Kulahci M, Palazoglu A. Real-time fault detection and diagnosis using sparse principal component analysis [J]. Journal of Process Control,2018,67(7):112-128.
- [13] Kano M, Hasebe S, Hashimoto L, et al. Statistical process monitoring based on dissimilarity of process data [J]. Aiche Journal,2002,48(6):1231-1240.
- [14] ILIĆ M, TURNER I W, SIMPSON D P. A restarted Lanczos approximation to functions of a symmetric matrix[J]. IMA Journal of Numerical Analysis,2010,30(4):1044-1061.
- [15] Hastie T, Mazumder R, Zadeh R, et al. Matrix completion and low-rank SVD via fast alternating least squares[J]. Journal of Machine Learning Research,2015,16(1):3367-3402.
- [16] WEI S, LING Q, YUAN K, et al. On the linear convergence of the ADMM in decentralized consensus optimization[J]. IEEE Transactions on Signal Processing,2014,62(7):1750-1761.
- [17] Hajhosseini P, Anzehae M M, Behnam B. Fault detection and isolation in the challenging Tennessee Eastman process by using image processing techniques [J]. ISA Transactions,2018,79(8):137-146.

作者简介



刘金平 男,1983 年生于湖南省洞口县. 湖南师范大学信息科学与工程学院副教授. 研究方向为智能信息处理.
E-mail:ljp202518@163.com



王杰 男,1995 年生于湖北随州. 目前在湖南师范大学信息科学与工程学院攻读硕士学位,研究方向为智能信息处理、工业过程故障诊断.
E-mail:wangjie_hunnu@163.com



唐朝晖 男,1965 年出生于湖南省长沙市.中南大学自动化学院教授.研究方向为复杂工业系统的建模与优化控制、复杂工业系统的建模与优化控制.

E-mail: zhtang@csu.edu.cn



贺俊宾 男,1989 年生于湖南常德.目前在湖南师范大学信息科学与工程学院攻读硕士学位,研究方向为智能信息处理.

E-mail: 341078304@qq.com



谢永芳 男,1972 年出生于河南省郸城县.中南大学自动化学院教授.研究方向为复杂工业系统的建模与优化控制、分散鲁棒控制、工业过程故障诊断.

E-mail: yfxie@csu.edu.cn



马天雨(通信作者) 男,1978 年生于甘肃白银,博士,湖南师范大学物理与电子学院讲师.研究方向为复杂工业过程建模与优化控制.

E-mail: mty@hunnu.edu.cn