

KL 散度多模块滑动窗口慢特征分析的故障诊断方法*

郭昕刚, 霍金花, 程超, 许连杰

(长春工业大学 计算机科学与工程学院, 吉林 长春 130012)

摘要:针对传统分块方法根据经验划分子块导致变量特征信息无法充分利用,其单一的建模方式忽略局部信息以及离线模型无法适应时变特性的问题,提出了一种 KL (Kullback-Leibler) 散度多模块滑动窗口慢特征分析方法。在正常工况数据集中,利用 KL 散度来度量变量间的距离,同时引入最小误差平方和准则进行聚类,分成两个距离最小的子模块;在此基础上利用慢特征分析方法对每个子模块进行建模,结合滑动窗口对每次采样的数据进行更新,得到最优模型,分别计算监测统计信息,利用支持向量数据描述对故障监测结果进行融合,实现故障诊断。并将该方法应用于田纳西伊斯曼过程的监控中,得到了较高的故障检测率和较低的虚警率,验证了该方法的可行性和有效性。

关键词:KL 散度;滑动窗口;慢特征分析;故障诊断

中图分类号:TP277 **文献标志码:**A **文章编号:**1001-2486(2023)06-165-09

KL divergence multi-block moving window slow feature analysis method for fault diagnosis

GUO Xingang, HUO Jinhua, CHENG Chao, XU Lianjie

(School of Computer Science and Engineering, Changchun University of Technology, Changchun 130012, China)

Abstract: A KL (Kullback-Leibler) divergence multi-block moving window slow feature analysis method was proposed to solve the problems that the variable feature information cannot be fully utilized by the traditional block segmentation method based on experience, the local information is ignored by a single modeling method, and the off-line model cannot adapt to the time-varying characteristics. KL divergence was used to measure the distance between variables in the normal working condition data set, and the minimum error sum criterion was introduced to cluster, which was divided into two sub-blocks with the minimum distance. On this basis, the slow feature analysis method was utilized to model each sub-block, and the optimal model was obtained by updating the sampled data with moving window. Monitoring statistics were calculated respectively, and the fault monitoring results were fused with support vector data description to achieve fault diagnosis. The proposed method was applied to the monitoring of Tennessee Eastman process, and higher fault detection rate and lower false alarm rate are obtained, verify the feasibility and effectiveness of this method.

Keywords: KL divergence; moving window; slow feature analysis; fault diagnosis

随着现代工业的发展,数据驱动方法在过程监控中发挥着重要作用^[1-2]。在主流方法中,多元统计过程监控(multivariate statistical process monitoring, MSMP)被用于监控多元复杂工业过程中的故障^[3]。传统的多元统计监控主要包括主成分分析法(principal component analysis, PCA)、偏最小二乘法(partial least square, PLS)和独立成分分析^[4](independent component analysis, ICA)。

工业过程的复杂性和未知的动态特性使得静态过程的监测效果较差。传统的 MSMP 方法是静态过程监控方法,即当前时间的样本与过去的

样本没有关联,样本数据相互独立,忽略了动态特性。Li 等提出了一种部分动态主成分分析(dynamic principal component analysis, DPCA)来提高动态过程监测能力^[5]。针对过程动力学和数据非高斯统计的特点,动态独立成分分析(dynamic independent component analysis, DICA)也相继被提出^[6-7]。上述方法以消除动力学为目标,往往假设所有变量具有相同的动态特性,然后对原始数据进行扩展,与传统方法相比提高了性能,但产生了大量的冗余信息,处理动态特性较强的变量时性能较差。慢特征分析^[8](slow feature

* 收稿日期:2021-09-14

基金项目:国家自然科学基金联合基金重点资助项目(U20A20186)

作者简介:郭昕刚(1979—),男,吉林长春人,副教授,硕士,硕士生导师,E-mail:6889068@qq.com;

程超(通信作者),男,吉林长春人,副教授,博士,博士生导师,E-mail:125725673@qq.com

analysis, SFA) 可以从时间序列中提取缓慢变化的特征, 表征变量变化的快慢程度, 是一种有效的无监督算法。Shang 等提出了基于 SFA 的动态监控, 实现了运行和控制性能的监控^[9]。上述方法虽然克服了动态缺陷, 但只建立单一模型却忽略了局部信息, 导致大规模工业过程的诊断性能较差。

多模块算法最早由 Macgregor 等提出, 有效利用局部信息改进过程分析将整个模型分为多个子模型^[10]。Ge 等根据主成分分析的不同方向对原始数据进行划分, 将线性变量分配到同一个块中, 分块过程中存在缺失和重叠的问题^[11]。Tong 等分别分析了变量与主元子空间和残差空间的相关性, 再将变量分配到相应的子空间中实现分块^[12]。这些方法都以先验知识作为前提, 极大程度限制了该方法的应用。KL (Kullback-Leibler) 散度作为一种新的概率测度, 可以测量两个统计变量之间的差值, 用来解决故障诊断问题^[13-14]。Wang 等利用 KL 散度将具有类似统计特征的变量划分为一块, 在每个低维子空间中建立 PCA 模型, 使用贝叶斯策略进行融合^[15]。周伟等在 DPCA 建模的基础上, 利用 KL 散度量化模型得到分量概率分布之间的相似度, 从而建立多块模型实现对微小故障的诊断^[16]。

在实际的工业生产过程中, 大多数缓慢变化的过程数据也具有非线性时变的特性, 其使正常数据出现偏移, 导致出现误警现象。柯亮等提出了基于滑动窗 PCA 的微小故障检测方法, 利用滑动窗口的策略对数据实时更新, 使得故障数据与非故障数据分化明显, 实现了对微小故障的放大, 提高了模型的自适应能力^[17]。

综合以上问题, 提出一种基于 KL 散度的多模块滑动窗口慢特征分析故障诊断方法, 利用 KL 散度的统计特性, 建立多块模型, 在每个块中应用 SFA 来提取过程数据的不同动态, 利用滑动窗口得到最优模型, 克服依据先验知识分块的策略、单一模型不稳定等问题。在田纳西伊斯曼 (Tennessee Eastman, TE) 过程监控中取得了较好的诊断效果。

1 理论基础

1.1 KL 散度

KL 散度通常用来测量两个概率密度分布的差异, 广泛应用于模型的选择^[18]。两个连续变量 $v_1(x)$ 和 $v_2(x)$ 的 KL 散度 $D_{KL}(v_1 \| v_2)$ 表示为

$$D_{KL}(v_1 \| v_2) = \int v_1(x) \ln \frac{v_1(x)}{v_2(x)} dx \quad (1)$$

由于 KL 散度的定义具有不对称性, 不能作用于距离的度量。在实际的应用中, 人们将其改进为对称形式

$$D_{KL}(v_1 \| v_2) = \int v_1(x) \ln \frac{v_1(x)}{v_2(x)} dx + \int v_2(x) \ln \frac{v_2(x)}{v_1(x)} dx \quad (2)$$

式(2)可得到对称的距离度量结果, 具有非负性, $v_1(x)$ 和 $v_2(x)$ 相似性越大, $D_{KL}(v_1 \| v_2)$ 值越接近于 0, 反之, $D_{KL}(v_1 \| v_2)$ 值越大, 相似性越小。

1.2 慢特征分析

假设存在 m 维时间序列输入信号 $\mathbf{x}(t) = [x_1(t), x_2(t), \dots, x_m(t)]^T$, SFA 的目标是找到一组特征函数 $\mathbf{g}(t) = [g_1(t), g_2(t), \dots, g_m(t)]^T$, 使得特征 $\mathbf{s}(t) = \mathbf{g}(\mathbf{x}(t))$ 缓慢变化^[2]。 $\mathbf{s}(t) = [s_1(t), s_2(t), \dots, s_m(t)]^T$ 用来表示缓慢变化的特征, SFA 的优化问题表示如下

$$\Delta(s_i) = \min_{g_i(\cdot)} \langle \dot{s}_i^2 \rangle_t \quad (3)$$

约束条件为

$$\langle s_i \rangle_t = 0 \quad (4)$$

$$\langle s_i^2 \rangle_t = 0 \quad (5)$$

$$\forall i \neq j, \langle s_i s_j \rangle_t = 0 \quad (6)$$

其中, $\langle \cdot \rangle_t$ 和 \dot{s} 分别表示均值和 s 对时间的导数。上述约束条件既排除了常数解, 又保证所有解独立。

线性 SFA 中, 每个缓慢变化的特征 (slow features, SFs) 是所有输入数据的线性组合

$$\mathbf{s} = \mathbf{W}\mathbf{x} \quad (7)$$

式中, $\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_m]^T$ 是权重矩阵。

$$\mathbf{R} = \langle \mathbf{x}(t)\mathbf{x}(t)^T \rangle_t = \mathbf{U}\mathbf{\Lambda}\mathbf{U}^T \quad (8)$$

式中, \mathbf{U} 是 \mathbf{R} 的特征值, $\mathbf{\Lambda}$ 是由特征值组成的对角矩阵。白化矩阵可表示为 $\mathbf{Q} = \mathbf{\Lambda}^{-1/2}\mathbf{U}^T$, 白化过程为

$$\mathbf{z} = \mathbf{\Lambda}^{-1/2}\mathbf{U}^T\mathbf{x} = \mathbf{Q}\mathbf{x} \quad (9)$$

结合式(7)和式(9), SFs 进一步表示为

$$\mathbf{s} = \mathbf{W}\mathbf{x} = \mathbf{W}\mathbf{Q}^{-1}\mathbf{z} = \mathbf{P}\mathbf{z} \quad (10)$$

式中, $\mathbf{P} = \mathbf{W}\mathbf{Q}^{-1}$, $\langle \mathbf{z}\mathbf{z}^T \rangle_t = \mathbf{Q}\langle \mathbf{x}\mathbf{x}^T \rangle\mathbf{Q}^T = \mathbf{I}$, $\langle \mathbf{z} \rangle_t = 0$ 。优化问题(3)和约束条件进一步表示为

$$\Delta(s_i) = \min_{g_i(\cdot)} \langle \dot{s}_i^2 \rangle_t = \min \langle \mathbf{p}_i^T \langle \dot{\mathbf{z}}\dot{\mathbf{z}}^T \rangle \mathbf{p}_i \rangle \quad (11)$$

$$\langle s_i \rangle_t = \mathbf{p}_i^T \langle \mathbf{z} \rangle_t = 0 \quad (12)$$

$$\langle s_i^2 \rangle_t = \mathbf{p}_i^T \langle \mathbf{z}\mathbf{z}^T \rangle \mathbf{p}_i = \mathbf{p}_i^T \mathbf{p}_i = 0 \quad (13)$$

$$\forall i \neq j, \langle s_i s_j \rangle_t = \mathbf{p}_i^T \langle \mathbf{z}\mathbf{z}^T \rangle \mathbf{p}_j = \mathbf{p}_i^T \mathbf{p}_j = 0 \quad (14)$$

为了满足式(11)~(14), 优化问题再次转化为求解正交矩阵 \mathbf{P} 。

$$\langle \dot{\mathbf{z}}\dot{\mathbf{z}}^T \rangle = \mathbf{P}^T \mathbf{\Omega} \mathbf{P} \quad (15)$$

式中, $\mathbf{P} = [\mathbf{p}_1, \mathbf{p}_2, \dots, \mathbf{p}_m]$ 是正交特征向量矩阵, 对应的特征值为 $\mathbf{\Omega} = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_m)$, 且 $\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_m$ 。

权重 \mathbf{W} 表示为

$$\mathbf{W} = \mathbf{P}\mathbf{Q} = \mathbf{P}\mathbf{A}^{-1/2}\mathbf{U}^T \quad (16)$$

最后, 得到 m 个缓慢程度由大到小排列的 SFs。

$$\mathbf{s} = \mathbf{W}\mathbf{x} = \mathbf{P}\mathbf{Q}\mathbf{x} = \mathbf{P}\mathbf{A}^{-1/2}\mathbf{U}^T\mathbf{x} \quad (17)$$

$$\Delta(s_i) = \min_{g_i(\cdot)} \langle \dot{s}_i^2 \rangle = \min \langle \mathbf{p}_i^T \langle \dot{\mathbf{z}}\dot{\mathbf{z}}^T \rangle \mathbf{p}_i \rangle = \lambda_i \quad (18)$$

2 基于 KL 散度多模块滑动窗口慢特征分析方法及过程监测

2.1 KL 散度分块策略

使用 KL 散度度量任意两个变量间的相关性, 并进一步构造 KL 散度分量, 作为分块的基础。

对于训练数据 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m]^T \in \mathbf{R}^{n \times m}$, m 和 n 表示变量数和样本个数。取任意两个变量 \mathbf{x}_i 和 \mathbf{x}_j , 且 $\mathbf{x}_i \in \mathbf{X}, \mathbf{x}_j \in \mathbf{X}$, 在正态分布的条件下, KL 散度分量表示为

$$d_{i,j}^{\text{KL}}(x) = \frac{1}{2} \left[\frac{\sigma_i}{\sigma_j} + \frac{\sigma_j}{\sigma_i} + (\mu_i - \mu_j)^2 \left(\frac{1}{\sigma_i} + \frac{1}{\sigma_j} \right) - 2 \right] \quad (19)$$

式中, $\mu_i = \frac{1}{m} \sum_{m=1}^i x(i), \sigma_i = \frac{1}{m} \sum_{m=1}^i (x(i) - \mu_i)^2$ 。

得到度量变量的对称矩阵 $\mathbf{d}^{\text{KL}} \in \mathbf{R}^{m \times m}$, 该对称矩阵为变量的相关性矩阵。随机选取两类数值 $c_1, c_2 \in \mathbf{d}^{\text{KL}}$ 作为初始中心, 分别计算对称矩阵到每个初始中心的欧氏距离, 将离初始中心最近的类确定为新的初始中心, 其他类也被重新分配, 依次迭代进行, 直到满足式(20)时, 分块结果收敛。

$$J(c, i) = \sum_{i=1}^2 \sum_{c_i \in \mathbf{d}^{\text{KL}}} |d^{\text{KL}} - c_i|^2 \quad (20)$$

最后将训练数据分成两个子模块 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m]^T = [\mathbf{X}_1, \mathbf{X}_2]^T$ 。

2.2 多模块滑动窗口慢特征分析方法

根据工业过程的动态特性, 将子模块 $\mathbf{X} = [\mathbf{X}_1, \mathbf{X}_2]^T$ 扩展 d 个时延, 使当前样本与过去样本相关联, 得到增强的过程矩阵, 在 SFA 建模过程中扩展了动态特性, 矩阵增强过程如式(21)所示。

$$\mathbf{X}_i = \begin{bmatrix} \mathbf{x}(t)^T & \mathbf{x}(t-1)^T & \dots & \mathbf{x}(t-d)^T \\ \mathbf{x}(t+1)^T & \mathbf{x}(t)^T & \dots & \mathbf{x}(t+1-d)^T \\ \vdots & \vdots & & \vdots \\ \mathbf{x}(t+n-1)^T & \mathbf{x}(t+n-2)^T & \dots & \mathbf{x}(t+n-d-1)^T \end{bmatrix} \quad (21)$$

式中, i 是子模块数量, n 是过程变量的样本量。

随后进行 SFA 离线建模, 局部建模过程中使用滑动窗口算法训练最优的离线模型, 如算法 1 所示。

算法 1 滑动窗口训练最优模型

Alg. 1 Moving window trains the optimal model

输入: 过程矩阵 $\mathbf{X} = [\mathbf{X}_1, \mathbf{X}_2]^T$

输出: 权重矩阵 $\mathbf{W}_1, \mathbf{W}_2$

1. 计算训练数据与测试数据的欧氏距离, 对距离结果升序排列
2. 设置窗口大小为 w , 第 L 个时刻的矩阵 \mathbf{X}_L 为 $\mathbf{X}_L = [\mathbf{x}_{L-w+1}, \mathbf{x}_{L-w+2}, \dots, \mathbf{x}_L]^T$, \mathbf{X}_L 和 \mathbf{X}_{L+1} 的中间矩阵 $\mathbf{X}_{\text{mid}} = [\mathbf{x}_{L-w+2}, \mathbf{x}_{L-w+3}, \dots, \mathbf{x}_L]^T$

3. 利用 SFA 建模, 协方差矩阵 \mathbf{R}_{mid} 为

$$\mathbf{R}_{\text{mid}} = \frac{w-1}{w-2} \left[\mathbf{R}_L - \frac{1}{w-1} \mathbf{x}_{L-w+1}^T \mathbf{x}_{L-w+1} - \sum_L^1 (\bar{\mathbf{X}}_L - \bar{\mathbf{X}}_{\text{mid}}) (\bar{\mathbf{X}}_L - \bar{\mathbf{X}}_{\text{mid}})^T \sum_L^1 1 \right]$$

4. 第 $L+1$ 个时刻的协方差矩阵为

$$\mathbf{R}_{L+1} = \mathbf{R}_L - \frac{1}{w-1} \mathbf{x}_{L-w+1}^T \mathbf{x}_{L-w+1} - \sum_L^1 \Delta \bar{\mathbf{X}}_L \Delta \bar{\mathbf{X}}_L^T \sum_L^1 1 + \sum_{L+1}^1 \Delta \bar{\mathbf{X}}_{L+1} \Delta \bar{\mathbf{X}}_{L+1}^T \sum_{L+1}^1 1 + \frac{1}{w-1} \mathbf{x}_{L+1}^T \mathbf{x}_{L+1}$$

其中 $\Delta \bar{\mathbf{X}}_L = \bar{\mathbf{X}}_L - \bar{\mathbf{X}}_{\text{mid}}$

以上模型通过将样本数据根据欧氏距离升序排列, 使用滑动窗口算法对样本进行筛选, 得到最优的局部模型及相应的权重矩阵 $\mathbf{W}_1, \mathbf{W}_2$, 提高了模型的自适应能力。

为了实现对故障的检测, 分别构造 T^2 和 S^2 统计量对故障进行在线监测, T^2 表示统计量在慢特征空间中的静态变化, S^2 表示过程统计量的动态变化分布。 T^2 统计量定义为

$$T_1^2 = \mathbf{s}_1^T \mathbf{s}_1 \quad (22)$$

$$T_2^2 = \mathbf{s}_2^T \mathbf{s}_2 \quad (23)$$

其中, 子块的 SFs 为 $\mathbf{s}_i = \mathbf{W}_i \mathbf{x}_i, i = 1, 2$ 。 S^2 统计量定义为

$$S_1^2 = \mathbf{s}_1^T \langle \dot{\mathbf{s}}_1 \dot{\mathbf{s}}_1^T \rangle_i^{-1} \dot{\mathbf{s}}_1 \quad (24)$$

$$S_2^2 = \mathbf{s}_2^T \langle \dot{\mathbf{s}}_2 \dot{\mathbf{s}}_2^T \rangle_i^{-1} \dot{\mathbf{s}}_2 \quad (25)$$

根据定义式分别得到子块对应的阈值和测试样本, 由于多个统计量很难同时被监测, 利用支持向量数据描述 (support vector data description, SVDD) 集成策略将子块结果转换为更加直观的监测指标。将阈值 $\mathbf{Y} = [T_1^2, T_2^2, S_1^2, S_2^2]$ 作为输入, 建立 SVDD 模型, 如算法 2 所示,

进行融合。

算法 2 SVDD 建模及监测

Alg.2 SVDD modeling and monitoring

输入: $Y = [T_1^2, T_2^2, S_1^2, S_2^2]$

输出: D

1. 训练 SVDD 超球体, 获得超球体的阈值、支持向量等参数
2. 对于在线测试数据 x_{test} , SVDD 模型的测试向量为 $Y_i = [T_{i1}^2, T_{i2}^2, S_{i1}^2, S_{i2}^2]$, 计算测试向量到超球体半径中心的距离 D_R , 表达式为 $D_R^2 = \|y_i - a\|^2 = K(y_i, y_i) - 2 \sum_{i=1}^n a_i K(y_i, y_i) + \sum_{i=1}^n \sum_{j=1}^n a_i a_j K(y_i, y_j)$, 式中, $K(y_i, y_j)$ 为核函数, a 是球体中心

3. 监测统计量 D 被定义为 $D = \frac{D_R^2}{R^2}$

监测结果融合后, 得到阈值控制限 $D_l = 1$ 和半径中心 D_R 。当 $D \geq D_l$ 时, 检测出故障, 反之 $D < D_l$, 正常工作。该方法通过增强过程数据, 实现对故障的动态监测, 局部建模的方式避免了全局建模中忽略局部信息的问题, 通过 KL 散度量变量相似性, 迭代实现无监督分块, 得到两个相关性更高的样本数据, 监测过程中有效解决了单一模型不稳定的问题。

2.3 KL-MWSFA 过程监测

基于 KL 散度的多模块滑动窗口慢特征分析方法 (multi-block moving window slow feature analysis method based on KL divergence, KL-MWSFA) 的过程监测详细步骤如下。

离线训练:

步骤 1: 对训练数据 X 标准化, 计算变量间的 KL 散度量 d^{KL} 。

步骤 2: 随机取 d^{KL} 中的两个值作为中心, 根据损失函数依次迭代更新中心数值, 直到收敛, 划分为两个子块 $X = [X_1, X_2]^T$ 。

步骤 3: 将子块进行 d 个时延扩展为动态矩阵, 计算与测试数据的欧氏距离, 将其升序排列。

步骤 4: 利用滑动窗口对每个子块进行 SFA 离线建模, 分别计算 T^2, S^2 的阈值。

在线监测:

步骤 5: 对故障数据标准化, 扩展 d 个时延, 然后分块。

步骤 6: 使用 SFA 进行训练, 得到 T^2, S^2 的阈值, 作为 SVDD 的输入 Y 。

步骤 7: 建立 SVDD 模型, 计算测试向量 Y_i 到超球半径的距离, 得到 D_R 。

步骤 8: 控制限 $D_l = 1$, 当 $D \geq D_l$ 时, 发生故障, 反之正常。

3 TE 过程仿真实验

3.1 TE 过程简要介绍

TE 过程是美国化工公司在大量实际工程经验的基础上, 由 Downs 和 Vogel^[19] 提出的一个化工过程模型, 其产生的数据具有时变性、强耦合性以及非线性, 广泛应用于过程控制、监测和故障诊断研究, 工艺流程如图 1 所示。主要由反应器、冷凝器、压缩机、气液分离器以及汽提塔 5 个操作控制部分构成。其共有 33 个变量, 正常情况

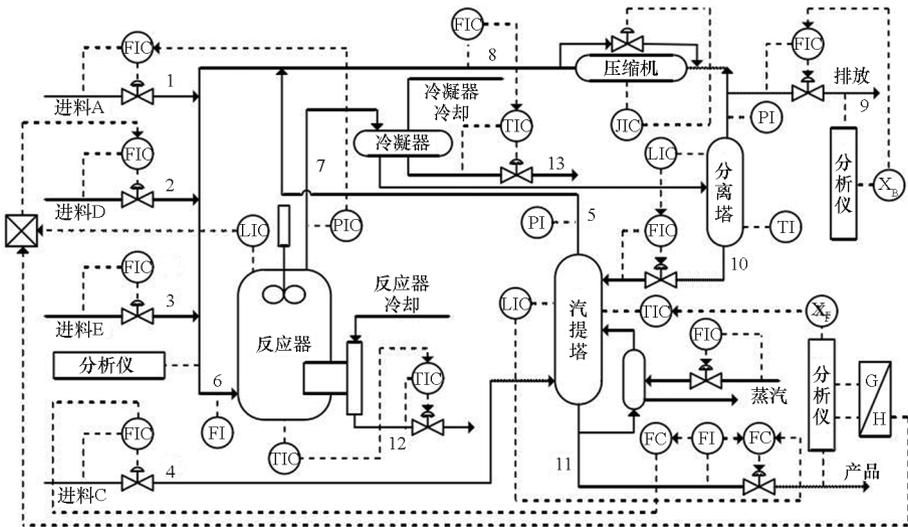


图 1 TE 过程流程图

Fig. 1 TE process flow chart

下的基准数据集包含 500 个样本。故障数据共有 960 个样本,前 160 个是正常数据,第 161 到 960 个样本为故障数据。本实验选择 22 个过程变量和 11 个操作变量作为输入,用 500 个正常样本建立模型。仿真共有 21 个故障类型,其中 16 种是已知故障,剩余 5 种是未知故障,实际的建模和监测过程中,一般不包括由搅拌速度引起的故障 21,故采用 15 种已知故障进行测试,具体描述如表 1 所示。

表 1 TE 过程故障类型表
Tab.1 TE process fault type table

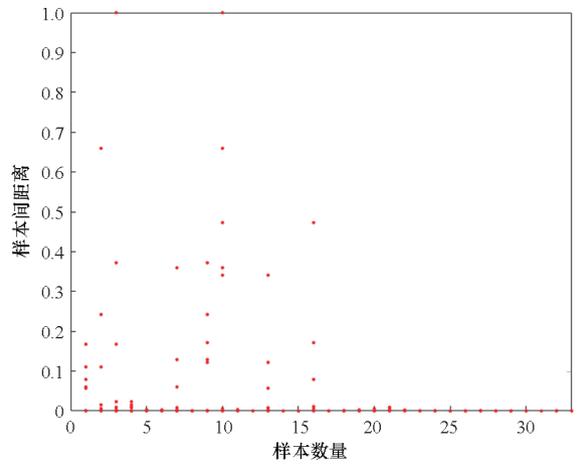
编号	扰动	故障类型
1	A/D 进料比变化,B 含量不变	阶跃
2	B 组分含量变化,A/C 进料比不变	阶跃
3	物料 D 的温度发生变化	阶跃
4	反应器冷却入口温度发生变化	阶跃
5	冷凝器冷却水入口温度发生变化	阶跃
6	物料 A 损失	阶跃
7	物料 C 压力存在压力损失	阶跃
8	物料 A、B、C 组分发生变化	随机变化
9	物料 D 的温度变化	随机变化
10	物料 C 的温度变化	随机变化
11	反应器冷却水入口温度发生变化	随机变化
12	冷凝器冷却水入口温度发生变化	随机变化
13	反应动力学常数变化	慢漂移
14	反应器冷却水阀门	黏滞
15	冷凝器冷却水阀门	黏滞
16~20	未知	未知
21	流 4 的阀门固定在稳定位置	恒定位置

3.2 分块

随机选取两个变量作为初始中心,计算 KL 散度量构成的对称矩阵到初始中心的欧氏距离,离初始中心最近的变量重新确定为新的中心,依次迭代,最后收敛时将变量自动分成两个子块。具体分块策略见第 2.1 节,变量间的分布如图 2 所示,分块结果如表 2 所示。

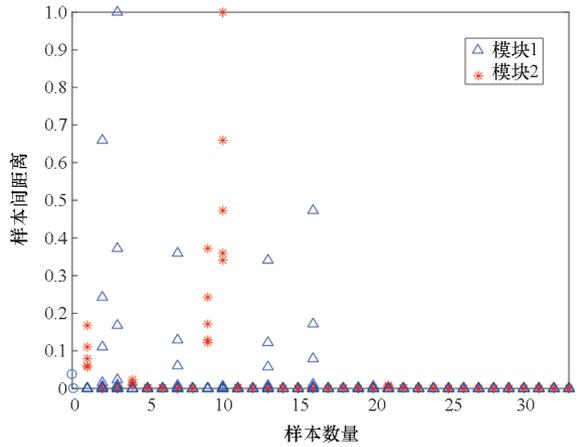
3.3 TE 仿真实验结果分析

将 KL-MWSFA 和核主成分分析(kernel



(a) 聚类前的变量分布

(a) Distribution of variables before clustering



(b) 聚类后的变量分布

(b) Distribution of variables after clustering

图 2 变量的分布

Fig.2 Distribution of sub-blocks

表 2 分块结果

Tab.2 Block the results

模块数	变量
1	$x_2, x_3, x_7, x_{13}, x_{16}$
2	$x_1, x_4 \sim x_6, x_8 \sim x_{12}, x_{14} \sim x_{15}, x_{17} \sim x_{33}$

principal component analysis, KPCA), ICA, SVDD 进行对比分析,故障检测率如表 3 所示,可以看出,对于故障 1,2,4,5,6,7,8,9,10,11,12,13, KL-MWSFA 方法都能有效检测到这些故障。由于故障 3,9,15 的震级非常小,几乎所有的方法都无法检测到故障。但对于故障 5,10,12,该方法具有较好的检测性能。

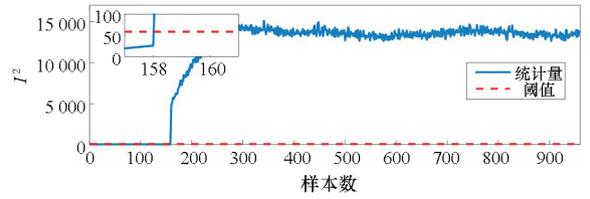
故障 5 是冷凝器冷却水入口温度的阶跃变化,导致冷凝器温度发生变化^[20]。故障 5 的监测图如图 3 所示,图 3(a)在第 300 个采样点以后,

表 3 KPCA, DICA, SVDD 和 KL-MWSFA 的故障检测率

Tab.3 Fault detection rate of KPCA, DICA, SVDD and KL-MWSFA

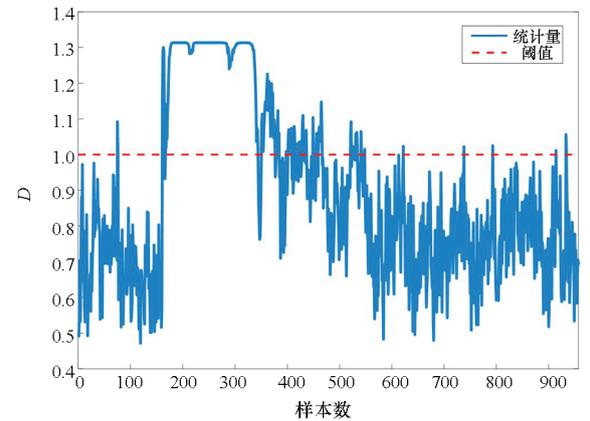
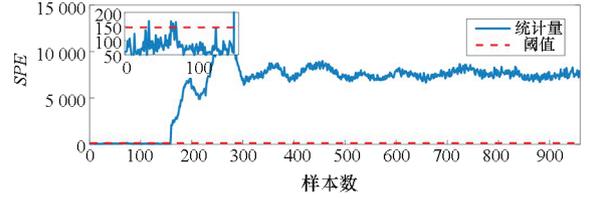
故障序列	KPCA		DICA		SVDD	KL-MWSFA
	T^2	SPE	I^2	SPE	D	D
1	0.26	0.99	1.00	1.00	0.99	1.00
2	0.03	0.98	0.98	0.97	0.98	0.98
3	0	0.03	0.01	0.09	0.15	0.12
4	0.20	1.00	1.00	1.00	0.94	1.00
5	0.08	0.26	1.00	1.00	0.32	1.00
6	0	1.00	1.00	1.00	1.00	1.00
7	0.80	0.99	1.00	1.00	1.00	1.00
8	0.46	0.98	0.97	0.98	0.98	0.98
9	0.01	0.01	0.01	0.12	0.06	0.14
10	0.07	0.43	0.88	0.88	0.55	0.90
11	0.42	0.74	0.82	0.83	0.58	0.85
12	0.40	0.98	1.00	1.00	0.98	1.00
13	0.26	0.95	0.95	0.95	0.94	0.95
14	0.60	0.99	1.00	1.00	1.00	0.93
15	0	0.07	0.20	0.19	0.23	0.04

无法检测出故障。图 3(b) I^2 统计量在第 161 个采样点之前发生虚警现象,图 3(c)在故障正常检测一段时间后,大部分统计量向控制限下方波动,检测效果一般。图 3(d)在第 161 个采样点检测到故障后,一直持续到最后一个样本,检测效果较好。



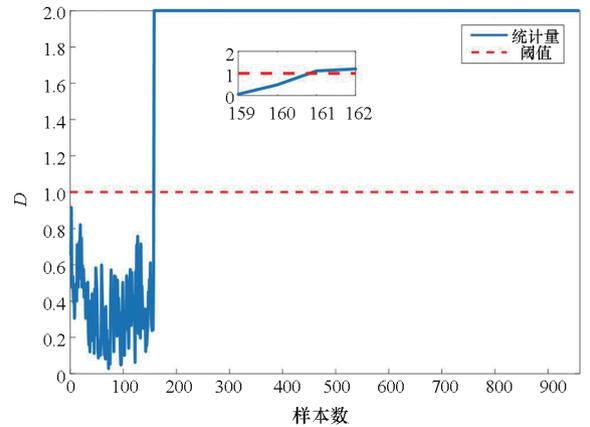
(b) DICA 监测结果

(b) Monitoring results of DICA



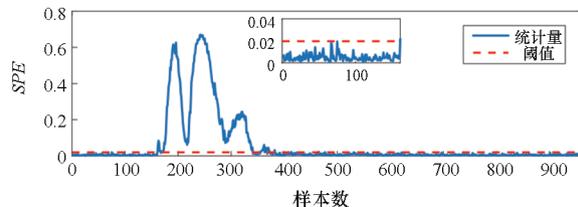
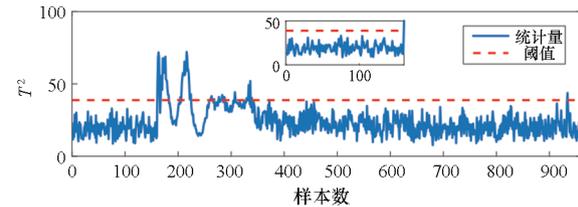
(c) SVDD 监测结果

(c) Monitoring results of SVDD



(d) KL-MWSFA 监测结果

(d) Monitoring results of KL-MWSFA



(a) KPCA 监测结果

(a) Monitoring results of KPCA

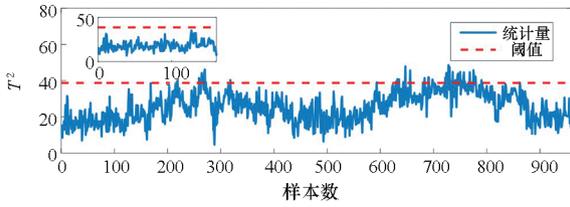
图 3 故障 5 监测结果

Fig.3 Monitoring results for fault 5

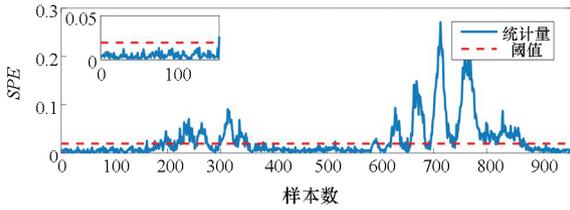
故障 10 是 C 进料温度的随机变化,主要影响汽提塔压力^[21]。图 4 为 KPCA, DICA, SVDD 和 KL-MWSFA 的监测图,图 4(a)的 T^2 统计样本大部分在控制限下面,检测效果不佳,图 4(c)的监控数据在控制限附近波动,也无法清楚地检测到

故障的发生,由表 3 可见 DICA 和 KL-MWSFA 检测效果较好,但在图 4(b)的子图中,我们可以看到个别正常样本出现虚警,只有图 4(d)在检测故障的同时没有发生虚警状况。

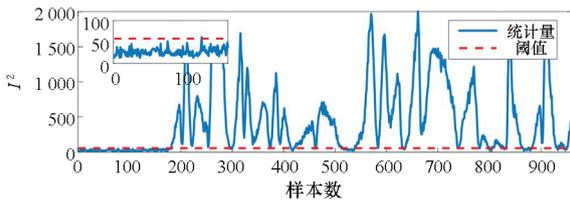
故障 12 是冷凝器冷却水入口温度的随机变化^[22]。由图 5(a)可知, T^2 监测性能不好且在阈值附近上下波动,图 5(b)虽然可以检测到故障,



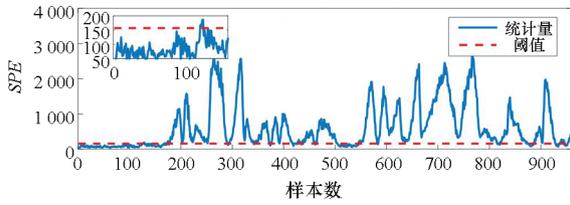
(a) KPCA 监测结果
(a) Monitoring results of KPCA



(b) DICA 监测结果
(b) Monitoring results of DICA



(c) SVDD 监测结果
(c) Monitoring results of SVDD



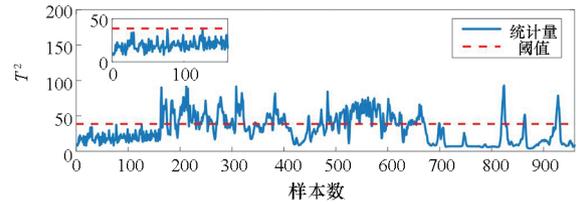
(d) KL-MWSFA 监测结果

(d) Monitoring results of KL-MWSFA

图 4 故障 10 监测结果

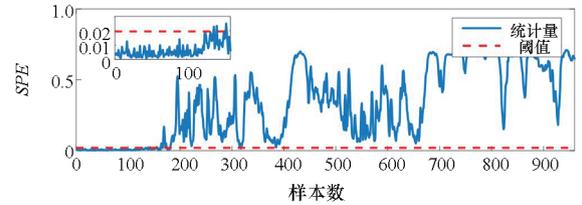
Fig. 4 Monitoring results for fault 10

但在正常工况时发生虚警,图 5(c)在发生虚警的同时监测效果没有图 5(b)的效果好,而图 5(d)的监测性能在检测中均得到改善,没有虚警并检测到所有故障。



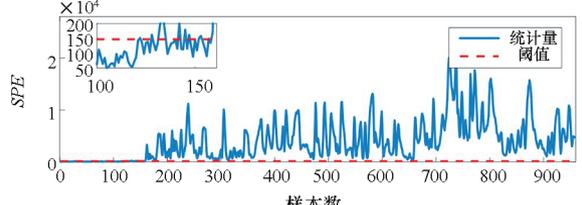
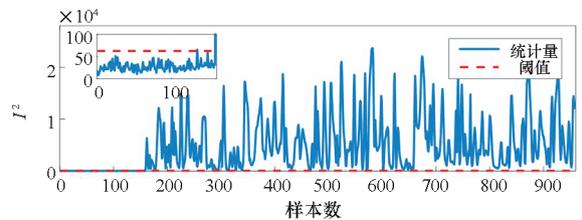
(a) KPCA 监测结果

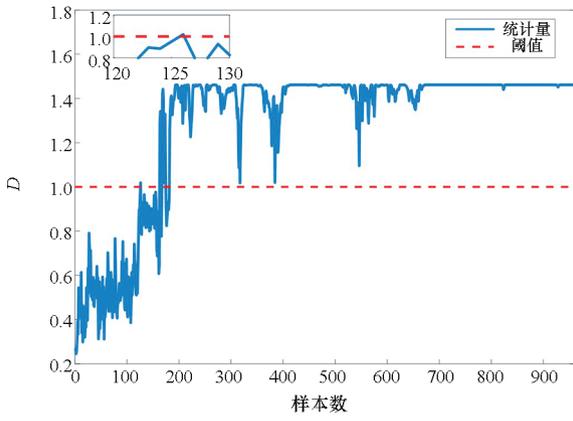
(a) Monitoring results of KPCA



(b) DICA 监测结果

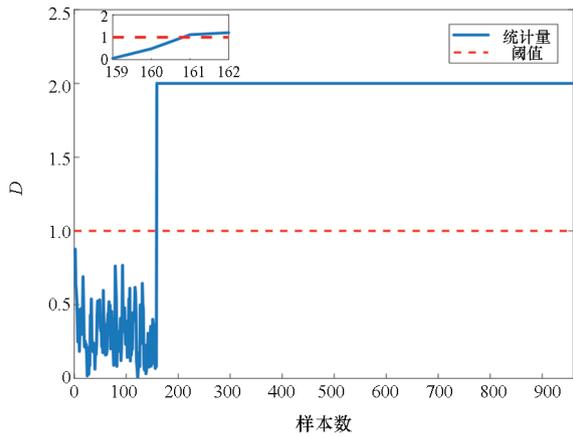
(b) Monitoring results of DICA





(c) SVDD 监测结果

(c) Monitoring results of SVDD



(d) KL-MWSFA 监测结果

(d) Monitoring results of KL-MWSFA

图 5 故障 12 监测结果

Fig. 5 Monitoring results for fault 12

4 结论

本文提出了一种基于 KL 散度的多模块滑动窗口慢特征分析方法,该方法使用 KL 散度算法度量每两个变量间的相似度,利用最小误差平方和准则对变量间的距离依次迭代,实现了对样本的无监督分块,并在每个子块中建立 SFA 监测模型,解决了单一模块的不稳定性问题,同时引入滑动窗口建立最优子模型,利用 SVDD 将子块监测结果融合。并将所提方法应用于 TE 过程,验证了该方法的有效性。

参考文献 (References)

[1] LI Z C, YAN X F. Complex dynamic process monitoring method based on slow feature analysis model of multi-subspace partitioning[J]. ISA Transactions, 2019, 95: 68 – 81.
 [2] HUANG J, ERSOY O K, YAN X F. Fault detection in dynamic plant-wide process by multi-block slow feature analysis and support vector data description [J]. ISA

Transactions, 2019, 85: 119 – 128.
 [3] JIANG Q C, GAO F R, YI H, et al. Multivariate statistical monitoring of key operation units of batch processes based on time-slice CCA [J]. IEEE Transactions on Control Systems Technology, 2019, 27(3): 1368 – 1375.
 [4] LI S, ZHOU X F, PAN F C, et al. Correlated and weakly correlated fault detection based on variable division and ICA[J]. Computers & Industrial Engineering, 2017, 112: 320 – 335.
 [5] LI R Y, RONG G. Fault isolation by partial dynamic principal component analysis in dynamic process[J]. Chinese Journal of Chemical Engineering, 2006, 14(4): 486 – 493.
 [6] LEE J M, YOO C Y, LEE I B. Statistical monitoring of dynamic processes based on dynamic independent component analysis[J]. Chemical Engineering Science, 2004, 59(14): 2995 – 3006.
 [7] WISKOTT L, SEJNOWSKI T J. Slow feature analysis: unsupervised learning of invariances [J]. Neural Computation, 2002, 14(4): 715 – 770.
 [8] LI R F, WANG X Z. Dimension reduction of process dynamic trends using independent component analysis[J]. Computers & Chemical Engineering, 2002, 26(3): 467 – 473.
 [9] SHANG C, HUANG B, YANG F, et al. Slow feature analysis for monitoring and diagnosis of control performance [J]. Journal of Process Control, 2016, 39: 21 – 34.
 [10] MACGREGOR J F, JAECKLE C, KIPARISSIDES C, et al. Process monitoring and diagnosis by multiblock PLS methods[J]. AIChE Journal, 1994, 40(5): 826 – 838.
 [11] GE Z Q, SONG Z H. Distributed PCA model for plant-wide process monitoring [J]. Industrial & Engineering Chemistry Research, 2013, 52(5): 1947 – 1957.
 [12] TONG C D, SONG Y, YAN X F. Distributed statistical process monitoring based on four-subspace construction and Bayesian inference [J]. Industrial & Engineering Chemistry Research, 2013, 52(29): 9897 – 9907.
 [13] CONTRERAS-REYES J E, ARELLANO-VALLE R B. Kullback-Leibler divergence measure for multivariate skew-normal distributions [J]. Entropy, 2012, 14(9): 1606 – 1626.
 [14] YOUSSEF A, DELPHA C, DIALLO D. Enhancement of incipient fault detection and estimation using the multivariate Kullback-Leibler Divergence [C]//Proceedings of 24th European Signal Processing Conference (EUSIPCO), 2016.
 [15] WANG B, JIANG Q C, YAN X F. Fault detection and identification using a Kullback-Leibler divergence based multi-block principal component analysis and Bayesian inference [J]. Korean Journal of Chemical Engineering, 2014, 31(6): 930 – 943.
 [16] 周伟, 潘海鹏, 吴平, 等. 基于 DPCA 和 KL 散度的微小故障检测方法 [J]. 传感器与微系统, 2020, 39(3): 135 – 138.
 ZHOU W, PAN H P, WU P, et al. Tiny fault detection

- method based on DPCA and KL divergence [J]. *Transducer and Microsystem Technologies*, 2020, 39(3): 135 – 138. (in Chinese)
- [17] 柯亮, 熊伟丽, 徐保国. 基于滑动窗 PCA 的微小故障检测[J]. *小型微型计算机系统*, 2016, 37(6): 1360 – 1364.
- KE L, XIONG W L, XU B G. Small fault detection based on moving window PCA [J]. *Journal of Chinese Computer Systems*, 2016, 37(6): 1360 – 1364. (in Chinese)
- [18] SEGHOUANE A K, AMARI S I. The AIC criterion and symmetrizing the Kullback-Leibler divergence [J]. *IEEE Transactions on Neural Networks*, 2007, 18(1): 97 – 106.
- [19] DOWNS J J, VOGEL E F. A plant-wide industrial process control problem [J]. *Computers & Chemical Engineering*, 1993, 17(3): 245 – 255.
- [20] YIN J, YAN X F. Mutual information-dynamic stacked sparse autoencoders for fault detection [J]. *Industrial & Engineering Chemistry Research*, 2019, 58(47): 21614 – 21624.
- [21] LI Z C, YAN X F. Complex dynamic process monitoring method based on slow feature analysis model of multi-subspace partitioning [J]. *ISA Transactions*, 2019, 95: 68 – 81.
- [22] LI Z C, YAN X F. Fault-relevant optimal ensemble ICA model for non-Gaussian process monitoring [J]. *IEEE Transactions on Control Systems Technology*, 2020, 28(6): 2581 – 2590.