

文章编号: 1001-0920(2013)10-1473-06

基于多块 KPCA 和 SDG 的故障诊断方法

王雅琳, 何 巍, 桂卫华, 阳春华

(中南大学 信息科学与工程学院, 长沙 410083)

摘 要: 针对大规模复杂工业过程, 提出一种基于多块核主元分析 (MBKPCA) 和符号有向图 (SDG) 的故障诊断方法. 首先, 提出基于 SDG 和优先级的分块策略, 以强连接元 SCC 为最高优先级、多入/出度节点群为次高优先级、节点链为最低优先级对过程进行分块; 在此基础上, 采用 MBKPCA 进行过程监控, 对于检测到的故障, 先确定故障发生在哪一个数据块, 再触发 SDG 在故障块内完成故障定位. 所提出方法克服了多块 KPCA 故障隔离不完全和 SDG 推理过程中组合爆炸的缺点, 可以提高复杂工业过程故障诊断的准确度和速度. 基于 Tennessee Eastman 过程的仿真研究表明了所提出故障诊断方法的有效性.

关键词: 符号有向图; 多块核主元分析; 过程监控; 故障定位

中图分类号: TP273

文献标志码: A

Fault diagnosis method based on MBKPCA and SDG

WANG Ya-lin, HE wei, GUI Wei-hua, YANG Chun-hua

(School of Information Science and Engineering, Central South University, Changsha 410083, China. Correspondent: WANG Ya-lin, E-mail: ylwang@csu.edu.cn)

Abstract: Aiming at the large-scale complex industrial process, a fault diagnosis method based on multiblock kernel principal component analysis (MBKPCA) and signed directed graph (SDG) is proposed. Firstly, by proposing a partition strategy based on SDG and priority, the process is divided into multiple blocks according to the strong connected component as the highest priority, the multiple input or output degree node group as the second priority and the node chain as the lowest priority. On that basis, MBKPCA is used for the process monitoring. If the fault is detected, MBKPCA will determine which block the fault occurs in, then SDG is triggered to complete the fault location in the fault block. The proposed method can improve the accuracy and rapid of the fault diagnosis for the complex industrial process by overcoming the disadvantage of the incomplete fault isolation of MBKPCA and combination explosion in SDG reasoning process. The simulation research on Tennessee Eastman process is performed to show the effectiveness of the proposed method.

Key words: signed directed graph; multiblock kernel principal component analysis; process monitoring; fault location

0 引 言

现代流程工业系统日益复杂, 因此及早准确地进行故障检测和诊断十分关键. 在过去的几十年中有大量致力于此方面的研究, 总体上分为 3 类: 基于定量模型、基于定性模型和基于过程历史数据的方法. 对于流程工业, 数据驱动的故障诊断方法成为主流, 其主要优点是可以利用丰富的过程测量数据而不需要过程的分析模型^[1].

基于主元分析 (PCA) 的多元统计方法广泛地应用于复杂过程的过程监控^[2-3]. 这些方法在处理高维的、含噪声的、高度相关的过程数据上具有优越性,

但线性 PCA 方法在非线性过程的过程监控上表现得不尽如人意^[4-6]. 为了克服这一缺陷, Schölkopf 等^[7]提出了核主元分析法 (KPCA), Choi 等^[8]证明了 KPCA 在故障检测上的应用要优于其他线性 PCA.

一旦故障被统计监控方法检测到, 如何进行故障定位十分重要. KPCA 作为一种数据驱动方法在故障检测上表现良好, 但是难以准确可靠地定位故障^[9], 尤其是大规模复杂过程存在着故障极易传播的问题. 另一方面, MacGregor 等^[10]提出采用多块偏最小二乘 (multiblock partial least squares) 来进行过程监控和故障诊断, 先将过程分成几个子块, 然后对每个子

收稿日期: 2012-07-01; 修回日期: 2012-10-04.

基金项目: 国家自然科学基金项目(61273187, 61134006, 61074117); 国家科技支撑计划项目(2012BAF03B05); 湖南省科技计划项目(2012CK4018).

作者简介: 王雅琳(1973-), 女, 教授, 博士, 从事复杂工业过程建模、优化控制等研究; 何巍(1988-), 男, 硕士生, 从事复杂工业过程故障诊断的研究.

块进行监控, 可以将故障准确地定位到一个子块. 多块核主元分析 (MBKPCA)^[11]也采用了这种对复杂过程进行分块的思想, 但是存在隔离不完全的缺点.

符号有向图 (SDG) 是一种描述大规模复杂系统的有效方式, 节点和有向支路分别表示系统变量和变量之间的因果关系. Iri 等^[12]首先将 SDG 的概念和方法应用于故障诊断. 基于定性 SDG 模型的故障诊断方法具有较好的故障定位能力, 而且具有不要求系统精确数学模型的特点. 但 SDG 方法需要时刻监控所有过程变量是否处于正常状态, 应用在过程监控上较为繁琐. Vedam 等^[13]将 PCA 与 SDG 结合进行过程监控和故障诊断, 但是作为两者间桥梁的贡献图存在不准确的问题, 而且 PCA 对于非线性过程的过程监控效果不理想.

鉴于此, 针对复杂工业过程具有规模大、非线性、故障检测定位难的特点, 本文提出一种基于多块核主元分析和符号有向图的故障诊断方法. 首先建立过程的 SDG 模型, 以 SDG 强连接元 (SCC) 为最高优先级、多入/出度节点群为次高优先级、节点链为最低优先级对过程按优先级顺序进行分块; 然后利用多块 KPCA 进行故障检测并确定故障发生在哪一个数据块, 同时触发 SDG 在故障块内完成故障定位. 以 Tennessee Eastman 过程仿真系统为例进行仿真实验, 结果表明了所提出方法的有效性.

1 MBKPCA 方法

1.1 KPCA 算法

KPCA 方法最早由 Schölkopf 等^[7]提出. 设 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N \in R^M$ 为 KPCA 模型的训练样本, 考虑到特征空间的维数是任意的, 采用非线性映射 $\Phi: R^M \rightarrow F$ 将输入空间的值扩展到高维特征空间. 特征空间 F 中的协方差矩阵为

$$\bar{C} = \frac{1}{N} \sum_{j=1}^N \Phi(\mathbf{x}_j) \Phi(\mathbf{x}_j)^T. \quad (1)$$

\bar{C} 的特征向量 \mathbf{v} 由下式计算:

$$\lambda \mathbf{v} = \bar{C} \mathbf{v}. \quad (2)$$

其中: $\lambda = [\lambda_1, \lambda_2, \dots, \lambda_N]$ 为 \bar{C} 的特征值, 且 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_N$. 式 (2) 两边均乘以 $\Phi(\mathbf{x}_k)$, 得到

$$\lambda (\Phi(\mathbf{x}_k) \mathbf{v}) = \Phi(\mathbf{x}_k) \bar{C} \mathbf{v}. \quad (3)$$

对于 $\lambda \neq 0$ 的所有特征向量 \mathbf{v} , 有

$$\mathbf{v} = \sum_{j=1}^N \alpha_j \Phi(\mathbf{x}_j). \quad (4)$$

引入核函数 $K_{jk} = K(x_j, x_k) = \Phi(x_j) \Phi(x_k)$, 则求特征值问题可以简化为

$$\lambda \alpha = (1/N) \mathbf{K} \alpha. \quad (5)$$

其中: $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_N]^T$ 为核矩阵 \mathbf{K} 的特征向量, $\mathbf{K} \in R^{N \times N}$.

上述推导在假设 $\sum_{k=1}^N \Phi(\mathbf{x}_k) = 0$ 的条件下得到, 实际情况不一定成立, 为此需要对 \mathbf{K} 进行中心化, 即将式 (5) 中的 \mathbf{K} 用 $\bar{\mathbf{K}}$ 代替, 有

$$\bar{\mathbf{K}} = \mathbf{K} - \mathbf{K} \mathbf{E} - \mathbf{E} \mathbf{K} + \mathbf{E} \mathbf{K} \mathbf{E}. \quad (6)$$

依据下式的累积方差贡献率准则确定主元个数 p :

$$\sum_{k=1}^p \lambda_k / \sum_{k=1}^N \lambda_k > C, \quad (7)$$

其中 C 的取值通常大于 85%, 本文取 90%.

确定 p 后, 对原始样本提取的最终特征将是一个 p 维的向量

$$\mathbf{y} = \left[\frac{1}{\sqrt{\lambda_1}} \sum_{j=1}^N \alpha_j^1 k(x_j, x), \frac{1}{\sqrt{\lambda_2}} \sum_{j=1}^N \alpha_j^2 k(x_j, x), \dots, \frac{1}{\sqrt{\lambda_p}} \sum_{j=1}^N \alpha_j^p k(x_j, x) \right]^T. \quad (8)$$

对于新观测样本 \mathbf{x}_{new} , 其得分向量为

$$\mathbf{t}_{\text{new}} = [t_{\text{new},1}, t_{\text{new},2}, \dots, t_{\text{new},p}]^T, \quad (9)$$

$$t_{\text{new},l} = v_l \bar{\Phi}(\mathbf{x}_{\text{new}}) = \sum_{j=1}^N \alpha_j^l (\bar{\Phi}(\mathbf{x}_j) \bar{\Phi}(\mathbf{x}_{\text{new}})). \quad (10)$$

其中: $l = 1, 2, \dots, p$; $\bar{\Phi}(\mathbf{x}_j)$ 为中心化的特征向量, 满足 $\sum_{j=1}^N \bar{\Phi}(\mathbf{x}_j) = 0$. 由此, 可根据下式计算新观测样本 \mathbf{x}_{new} 的两个监控统计量 T_{new}^2 和 SPE_{new} 进行过程监控:

$$T_{\text{new}}^2 = \mathbf{t}_{\text{new}}^T \mathbf{A}^{-1} \mathbf{t}_{\text{new}}, \quad (11)$$

$$\text{SPE}_{\text{new}} = k(\mathbf{x}_{\text{new}}, \mathbf{x}_{\text{new}}) - \mathbf{t}_{\text{new}}^T \mathbf{t}_{\text{new}}, \quad (12)$$

其中 \mathbf{A} 为 p 个主元对应特征值构成的对角矩阵.

1.2 MBKPCA 算法

对于复杂大型过程, 全局 KPCA 需要同时考虑所有过程变量, 忽视了大型过程子系统内部的固有联系. 同时, 当过程变量数目急剧膨胀时, 降低了过程监控和故障诊断的效率. 多块 KPCA 能降低过程分析的复杂度并且提供一种分散的过程监控和故障诊断方式, 其进行故障诊断^[11]的基本思想如下: 给定一个训练数据集 $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N \in R^M$, 将 \mathbf{x}_k ($k = 1, 2, \dots, N$) 分割成 B 块, 若选择径向基函数来构建核矩阵 \mathbf{K} , 则元素为

$$K_{i,j} = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2/c). \quad (13)$$

根据 $\|\mathbf{x}_i - \mathbf{x}_j\|^2 = \sum_{b=1}^B \|x_{b,i} - x_{b,j}\|^2$ 可得

$$K_{i,j} = \prod_{b=1}^B \exp\left(\frac{-\|x_{b,i} - x_{b,j}\|^2}{c}\right) = \prod_{b=1}^B K_{i,j}^b. \quad (14)$$

因此, 可以将训练数据集 X 分成 B 块, 计算每块的核矩阵 $K_b = \{K_{i,j}^b\}$, 其中每块的核矩阵都应该被中心化, 即

$$\bar{K}_b = K_b - EK_b - K_bE + EK_bE. \quad (15)$$

对于给定的一个测试样本, 若用 MBKPCA 进行故障诊断, 则首先将测试样本分割成与训练数据块相对应的 B 块^[14], 再分别通过 KPCA 分析得到各块的监控统计量 T^2 和 SPE, 将两个监控变量最先出现突变且增幅最大的块判断为故障块.

2 基于 SDG 模型的故障诊断方法

SDG 提供了一种描述过程变量间因果关系的简单图形表示方式, 广泛应用于众多领域. 在标准的 SDG 中, 过程变量表示为图形节点, 因果关系表示为有向弧. SDG 中的节点状态可以是 (0), (+) 和 (-). 其中: (0) 为正常稳定状态值, (+) 和 (-) 分别为高于和低于正常稳定状态值. 有向弧从原因节点指向结果节点, 弧的符号可以是 (+) 或 (-), 分别表示两个节点之间是正相关或负相关, 正影响用实线表示, 负影响用虚线表示, 如图 1 所示. 节点 B ~ 节点 E 构成一个强连接元 (SCC). SCC 是指定向图的一个子集, 每个节点之间彼此可达.




图 1 SDG 示意图

由于故障只能在相容路径上传播, 基于 SDG 模型的故障诊断主要在 SDG 模型中搜索报警节点可能的故障原因相容通路, 为故障诊断提供清晰的故障传播路径, 保证故障诊断的完备性和准确性. 相容通路满足 $\text{sign}(\text{支路的起始节点}) \bullet \text{sign}(\text{支路}) \bullet \text{sign}(\text{支路的终止节点}) = "+"$ 的条件, 具体情况如图 2 所示.




图 2 SDG 相容通路

SDG 模型上的推理实际上是搜索相容通路的过程. 推理机制包括前向推理和逆向推理: 前向推理是指搜索从原因节点到所有结果节点的相容通路, 逆向推理则考虑结果节点到所有可能原因节点的相容通路. 通常采用逆向推理与基于相容通路宽度优先算法的前向推理相结合的推理机制进行故障定位.

3 基于多块 KPCA 和 SDG 的故障诊断方法

由于过程对象的具体情况不同, 测量变量数目庞大且表现形式不同, 多块 KPCA 存在多种分块方法和机理, 既可以将测量变量按性质不同分为温度变量块、压力变量块和流量变量块等, 也可以按不同工段和设备对测量变量进行分块, 还可以将测量变量按物理和化学性质不同分为物理变量块和化学变量块. 本文提出以 SCC 为最高优先级、多入/出度节点群为次高优先级、节点链为最低优先级的分块策略, 按一定优先顺序对过程进行分块. 由于 SDG 是对过程知识的深层表达, 且能反映出故障在整个过程中的传播, 根据 SDG 进行分块是合理的. 基于 SDG 和优先级的分块方法具体步骤如下.

Step 1: 根据 Tarjan^[15] 提出的基于深度优先搜索的算法获取 SDG 中的 SCC, 每个 SCC 作为一个块, 若已经覆盖所有节点, 则分块完毕, 否则转至 Step 2.

Step 2: 搜索入度或出度大于等于 2 的节点并作为多入/出度节点群的中心节点, 再在邻接矩阵中确定中心节点的邻接节点, 从而得到多入/出度节点群, 将每个多入/出度节点群作为一个块, 若已经覆盖所有节点, 则分块完毕, 否则转至 Step 3.

Step 3: 搜索入度或出度等于 1 的节点, 成对验证它们之间的路径得到节点链, 每条节点链作为一个块, 若已经覆盖所有节点, 则分块完毕, 否则转至 Step 4.

Step 4: 合并受到同一 SCC 影响的块和节点, 若已经覆盖所有节点, 则分块完毕, 否则转至 Step 5.

Step 5: 将孤立节点并入相邻的块, 完成分块.

在进行上述步骤时, 上一优先级的节点不再出现在下一优先级的搜索范围内, 分块过程如图 3 所示, 图 3 中的虚线框表示对块进行合并.




图 3 基于 SDG 和优先级的分块方法

MBKPCA 可以对一个复杂的大规模工业系统进行分块监控, 但难以对块内故障进行定位, 因此提出基于 MBKPCA 和 SDG 的故障诊断方法, 步骤如下.

Step 1: 利用过程经验知识和过程数据对过程进行 SDG 建模, 获得过程对象的 SDG 模型.

Step 2: 根据过程的 SDG 模型, 按照上述基于 SDG 和优先级的分块方法对过程进行分块.




Step 3: 利用正常工作状态下的过程变量数据建立 MBKPCA 模型, 以 SPE 和 T^2 值作为监控统计量进行在线监控, 若任意块的两个监控统计量发生突变, 则检测到故障并确定故障块.

Step 4: 触发 SDG 在故障块内进行逆向推理故障定位, 得到故障根源.

Step 5: 以逆向推理得到的故障根源为起点进行前向推理验证, 如果所有异常节点到故障根源都存在相容通路, 则验证成功, 否则, 进行全局 SDG 逆向推理故障定位, 得到多个故障根源.

4 TE 过程仿真

TE 过程是由 Downs 等^[16]根据 Eastman 化学公司的实际工艺流程作少许修改后于 1993 年提出的. 整个 TE 过程有 4 种反应物 (A, C, D, E)、2 种产物 (G, H)、1 种恒量组分 B 和副产物 F. 系统中存在的化学反应如下:



TE 过程包括 5 个主要操作单元: 反应器、冷凝器、气/液分离器、循环压缩机和 1 个产品解析塔. 该过程包含 41 个可供监控的测量变量和 12 个操作变量, 其中 41 个测量变量又包括 22 个连续过程测

量变量(如表 1 所示)和 19 个成分测量值. 该过程共有 20 种扰动, 其中 15 种扰动是已知扰动. 根据 TE 过程的过程知识和历史数据进行 SDG 建模, 得到过程的 SDG 如图 4 所示.




图 4 基于 SDG 和优先级的分块方法

图 4 中有两个 SCC, 分别为: 1) $F_1, F_2, F_3, F_5, P_7, L_8, L_{12}, F_{14}, L_{15}, F_{17}$; 2) T_9, T_{21} . 根据基于 SDG 和优先级的分块原则进行分块, 结果如下: 1) (块 1) $F_1, F_2, F_3, F_5, P_7, L_8, L_{12}, F_{14}, L_{15}, F_{17}$; 2) (块 2) $F_6, T_9, P_{r10}, T_{11}, P_{13}, P_{16}, T_{18}, F_{19}, C_{20}, T_{21}, T_{22}$. 其中: 数据块 1 包含第 1 个 SCC; 数据块 2 包含第 2 个 SCC、节点链 T_{11}, T_{18}, T_{19} 、多入度节点群中心节点 F_6 、孤立节点 T_{22} , 这些节点均受第 1 个 SCC 的影响, 所以合并为数据块 2.

根据变量性质和所处的位置或装置, 得到另一种分块结果^[17]: 1) (块 1 原料块) F_1, F_2, F_3, F_4 ; 2) (块 2 反应器块) $F_6, P_7, L_8, T_9, T_{21}$; 3) (块 3 分离器块) $T_{11}, L_{12}, P_{13}, F_{14}$; 4) (块 4 解吸塔块) $L_{15}, P_{16}, F_{17}, T_{18}, F_{19}$; 5) (块 5 压缩机块) $F_5, P_{r10}, C_{20}, T_{22}$. 为了方便比较, 将其称为传统分块方法.

故障 1 发生时, 在物料流 4 中的 A/C 进料比引入一个阶跃变化, 导致物料流 4 中 C 的进料增加, A 的进料减少. 从第 1001 个采样点开始引入故障, 传统分块方法的仿真结果如图 5 所示. 图 5 中数据块 1 的 SPE 和 T^2 值在第 1001 个采样点的发生突变, 得到各个数据块在第 1001 个采样点的 SPE 和 T^2 值如图 6 所示. 由图 6 可见, 数据块 1 的 SPE 和 T^2 值最大, 其次是数据块 4, 其他 3 个数据块的 SPE 和 T^2 值均相对较小. 基于 SDG 和优先级分块方法的仿真结果如图 7 所示, 各个数据块在第 1001 个采样点的 SPE 和 T^2 值如图 8 所示.

由图 8 可见, 数据块 1 的 SPE 和 T^2 值最大, 其次是数据块 2. 从两种分块方法的故障 1 仿真结果看, 它们都能正确判断故障发生在哪一个数据块. 然而, 传统分块方法需要操作员根据经验判断故障块中的哪

表 1 Tennessee Eastman 的 22 个测量变量

变量名	变量含义
F_1	物料 A 流量
F_2	物料 D 流量
F_3	物料 E 流量
F_4	物料 A 和 C 流量
F_5	循环流量
F_6	反应器进料流量
P_7	反应器压力
L_8	反应器液位
T_9	反应器温度
P_{r10}	放空速率
T_{11}	分离器温度
L_{12}	分离器液位
P_{13}	分离器压力
F_{14}	分离器底部流量
L_{15}	解吸塔液位
P_{16}	解吸塔压力
F_{17}	解吸塔底部流量
T_{18}	解吸塔温度
F_{19}	解吸塔上部蒸汽流量
C_{20}	压缩机功率
T_{21}	反应器冷却水出口温度
T_{22}	冷凝器冷却水出口温度

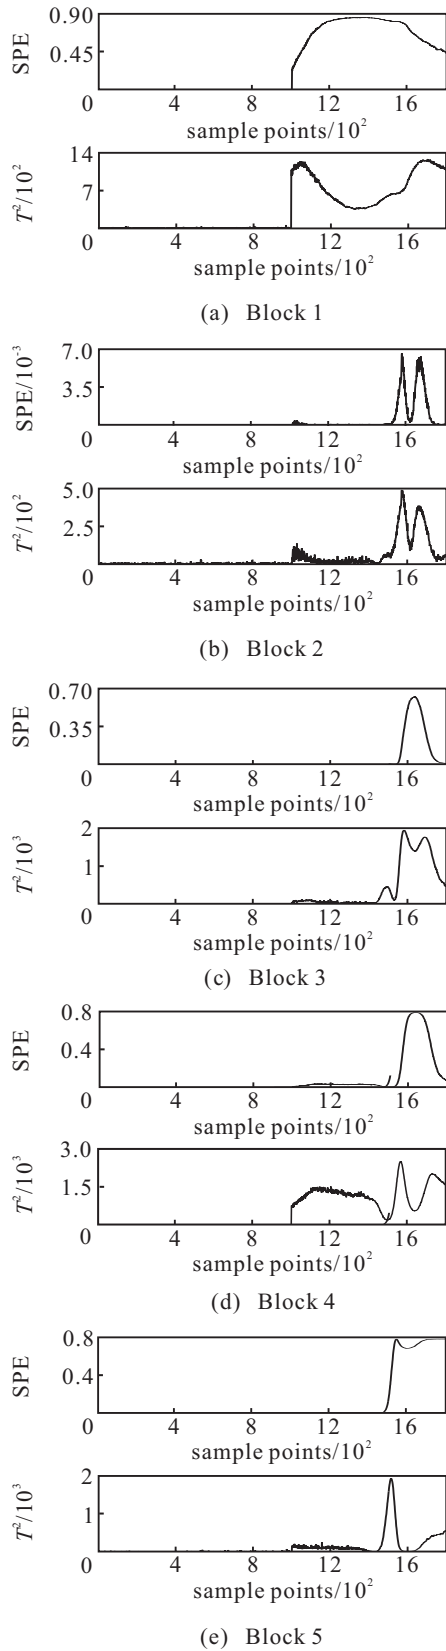


图 5 传统分块方法的故障 1 仿真结果

一个变量是故障根源. 就发生故障 1 而言, 采用传统分块方法的多块 KPCA 判断出数据块 1 (原料块) 为故障块的可能性最大, 其次是数据块 4 (解吸塔块). 这时操作员根据经验, 即可知道原料块中与解吸塔块关系最密切的是 F_4 物料 A 和 C 流量, 所以判断 F_4 为故障

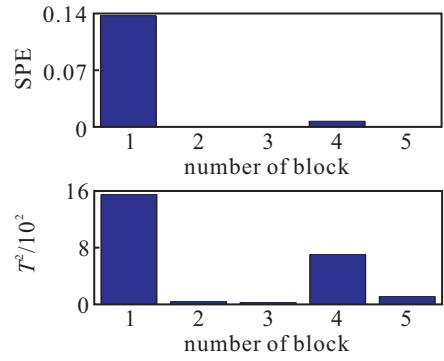


图 6 传统分块方法 SPE 和 T^2 值

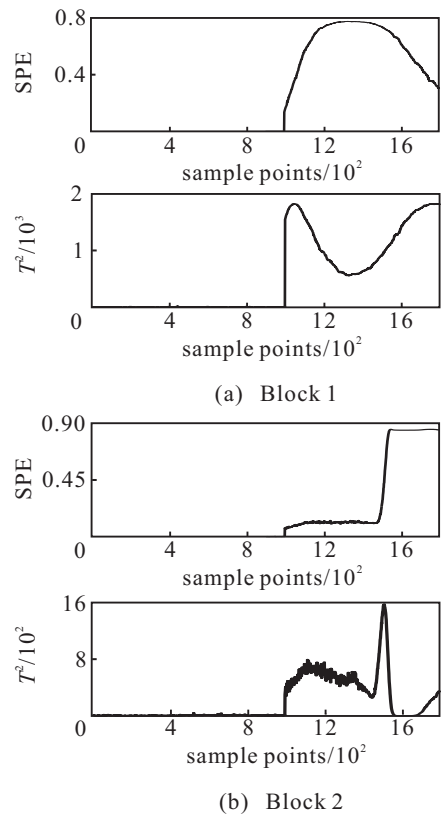


图 7 基于 SDG 和优先级的分块方法的故障 1 仿真结果




图 8 基于 SDG 和优先级的分块方法 SPE 和 T^2 值

变量, 这种诊断方法的主观性太强并且不是对所有情况均有效. 以 SCC 为最高优先级、多入/出度节点群为次高优先级、节点链为最低优先级的分块方法会更有利于进一步 SDG 故障定位, 从而避免错误经验导致误判. 当过程规模和复杂性大幅增加, 过程变量数目

急剧膨胀时, 块内 SDG 定位相对于全局 SDG 定位的高效性和快速性会更加明显. 故障 1 的块内 SDG 定位如图 9 所示.




图 9 故障 1 的块内逆向推理 SDG 定位

通过在 SDG 中逆向推理可以得到如下相容通路:

$$\begin{aligned}
 &F_5(+)\leftarrow L_8(-)\leftarrow F_1(+)\leftarrow P_7(+)\leftarrow F_4(+)\leftarrow \text{IDV}(1), \\
 &F_5(+)\leftarrow L_8(-)\leftarrow F_3(+)\leftarrow P_7(+)\leftarrow F_4(+)\leftarrow \text{IDV}(1), \\
 &F_2(+)\leftarrow L_8(-)\leftarrow F_1(+)\leftarrow P_7(+)\leftarrow F_4(+)\leftarrow \text{IDV}(1), \\
 &F_2(+)\leftarrow L_8(-)\leftarrow F_3(+)\leftarrow P_7(+)\leftarrow F_4(+)\leftarrow \text{IDV}(1), \\
 &F_{17}(+)\leftarrow L_{15}(+)\leftarrow F_{14}(+)\leftarrow L_{12}(+)\leftarrow L_8(-)\leftarrow \\
 &F_1(+)\leftarrow P_7(+)\leftarrow F_4(+)\leftarrow \text{IDV}(1), \\
 &F_{17}(+)\leftarrow L_{15}(+)\leftarrow F_{14}(+)\leftarrow L_{12}(+)\leftarrow L_8(-)\leftarrow \\
 &F_3(+)\leftarrow P_7(+)\leftarrow F_4(+)\leftarrow \text{IDV}(1), \\
 &F_{17}(+)\leftarrow F_4(+)\leftarrow \text{IDV}(1). \tag{20}
 \end{aligned}$$

式 (20) 中的 IDV(1) 表示故障 1, 所有相容通路都指向 IDV(1), 此故障发生在 F_4 , 通过块内 SDG 成功定位了故障变量 F_4 . 然后进行基于相容通路宽度优先算法的前向推理验证, 如果所有异常节点到故障根源都存在相容通路, 则验证成功. 全局 SDG 前向推理如图 10 所示.




图 10 故障 1 的全局 SDG 前向推理

5 结 论

为了提高大规模复杂工业过程故障诊断的可靠性和及时性, 本文提出了一种基于多块 KPCA 和 SDG 的故障诊断方法. 该方法基于 SDG, 按 SCC 为最高优先级、多入/出度节点群为次高优先级、节点链

为最低优先级的优先顺序对过程进行分块, 用多块 KPCA 进行过程监控, 以正常工况下的数据建立多块 KPCA 模型, 从而保证了监测的准确度. 一旦检测到故障, 确定故障块同时触发 SDG 在故障块内完成故障定位.

以 TE 过程为例, 验证了基于 MBKPCA 和 SDG 的故障诊断方法的有效性, 比较了两种不同的分块方法. 仿真结果表明, 基于 SDG 和优先级的分块方法优于传统分块方法, 前者作为连接 MBKPCA 和 SDG 桥梁构成了进行块内 SDG 故障定位的前提条件. 本文提出的方法克服了 MBKPCA 故障隔离不完全的缺点, 同时有效避免了 SDG 推理过程中的组合爆炸. MBKPCA 和 SDG 的故障诊断方法可以为大规模复杂工业过程提供分散故障诊断, 降低设备维护和故障诊断的成本, 具有广泛的推广价值和应用意义.

参考文献(References)

- [1] Venkatasubramanian V, Rengaswamy R, Yin K. A review of process fault detection and diagnosis, Part I: Quantitative model-based methods[J]. *Computers and Chemical Engineering*, 2003, 27: 293-311.
- [2] Zhao C H, Wang F L, Lu N Y. Stage-based soft-transition multiple PCA modeling and on-line monitoring strategy for batch processes[J]. *J of Process Control*, 2007, 17(9): 728-741.
- [3] Aguado D, Rosen C. Multivariate statistical monitoring of continuous wastewater treatment plants[J]. *Engineering Application of Artificial Intelligence*, 2008, 21(7): 1080-1091.
- [4] Dong D, McAvoy T. Nonlinear principal component analysis based on principal curves and neural networks[J]. *Computers and Chemical Engineering*, 1996, 20: 65-78.
- [5] Jia F, Martin E, Morris A. Nonlinear principal components analysis with application to process fault detection[J]. *Int J of Systems Science*, 2001, 31: 1473-1487.
- [6] Cho J, Lee J. Fault identification for process monitoring using kernel principal component analysis[J]. *Chemical Engineering Science*, 2005, 60: 279-288.
- [7] Schölkopf B, Smola A, Müller K. Nonlinear component analysis as a kernel eigenvalue problem[J]. *Neural Computation*, 1998, 10(5): 1299-1319.
- [8] Choi S, Lee C, Lee J. Fault detection and identification of nonlinear processes based on kernel PCA[J]. *Chemometrics and Intelligent Laboratory Systems*, 2005, 75(1): 55-67.
- [9] Ni J, Zhang C, Yang S. An adaptive approach based on KPCA and SVM for real-time fault diagnosis of HVCBs[J]. *IEEE Trans on Power Delivery*, 2011, 26(3): 1960-1971.

(下转第 1484 页)