

基于加权核独立成分分析的故障检测方法

韩敏, 张占奎

(大连理工大学 控制科学与工程学院, 辽宁 大连 116024)

摘要: 针对核独立成分分析故障检测时忽略各独立成分分量对系统故障贡献度的差异, 提出一种基于加权核独立成分分析的故障检测方法. 使用核独立成分分析提取过程变量的独立成分, 根据核密度估计衡量各独立成分分量对系统故障的贡献度, 对各独立成分分量赋予不同权重, 突出包含有用信息的独立成分分量, 引入局部离群因子在特征空间构造统计量进行故障检测. 基于数值仿真和 Tennessee Eastman 数据集的仿真结果表明了所提出方法的优越性.

关键词: 加权核独立成分分析; 核密度估计; 贡献度; 局部离群因子; 故障检测

中图分类号: TP273

文献标志码: A

Fault detection method based on weighted kernel independent component analysis

HAN Min, ZHANG Zhan-kui

(School of Control Science and Engineering, Dalian University of Technology, Dalian 116024, China.

Correspondent: HAN Min, E-mail: minhan@dlut.edu.cn)

Abstract: To solve the problem of missing different contribution of each kernel independent component for the system fault by using the kernel independent component analysis fault detection method, a weighted kernel independent component analysis is proposed for fault detection. The kernel independent component analysis is performed to extract the kernel independent components. Kernel density estimation is used to evaluate the contribution of each kernel independent component. According to the contribution, different weighting values are set up to highlight the kernel independent components with more useful information. Finally, the local outlier factor is used to establish the monitoring statistic in the feature space. The advantages of the proposed method are demonstrated by the results based on a numerical and the Tennessee Eastman process simulation.

Keywords: weighted kernel independent component analysis; kernel density estimation; contribution; local outlier factor; fault detection

0 引言

对于工业生产而言, 只有实现了安全、稳定的运行, 才能获得最大的经济效益, 因此, 及时检测过程是否发生故障并合理处理, 具有重要的理论意义和工程应用价值. 由于工业生产系统的复杂性, 过程数据的维数非常高, 且变量之间具有高度相关性, 从而形成了基于数据驱动的多元统计过程故障检测方法^[1-2].

目前, 广泛使用的多元统计方法主要有主成分分析(PCA)^[3-4]、独立成分分析(ICA)^[5-6]和费舍尔判别分析(FDA)^[7-8], 其中主成分分析利用数据的均值和方差实现降维处理^[9], 其优势是处理高斯分布问题. 作为主成分分析的进一步发展, 独立成分分析能够有效

利用数据的高阶统计特性提取出独立成分信息, 在非高斯过程中体现出巨大的优势^[10-12]. 为提取过程数据的非线性特征, 核独立成分分析(KICA)^[13]被用于故障检测中. 传统核独立成分分析进行故障检测时, 直接在特征空间中利用提取的独立成分建立监控统计量. 然而当故障发生时, 只有与故障源关联紧密的独立成分分量才能反映出系统的变化. 如果不能捕捉到这些包含有用信息的独立成分分量, 则有限的反映故障的信息可能会被大量的无用信息淹没, 影响故障检测的性能. 此外, I^2 和 SPE 监控统计量^[14]采用椭圆形控制限边界来区分正常和故障数据, 提高了故障检测误差, 且采用两个指标会分散故障对过程变量的影响.

收稿日期: 2014-12-15; 修回日期: 2015-03-11.

基金项目: 国家自然科学基金委科学仪器基础研究专项项目(51327004); 国家自然科学基金项目(61374154).

作者简介: 韩敏(1959-), 女, 教授, 博士生导师, 从事复杂系统建模与预测等研究; 张占奎(1988-), 男, 硕士生, 从事故障诊断、机器学习的研究.

局部离群因子(LOF)^[15]用来计算测试数据集偏离正常训练数据集中的幅度,与 I^2 和SPE统计量相比,通过局部离群因子构造的统计量^[16-18]可以准确地确定正常和故障工况的非线性控制限边界,提高故障检测率.

针对核独立成分分析进行故障检测时忽略独立成分分量对系统故障贡献度的差异性,本文提出基于加权核独立成分分析(WKICA)的故障检测方法.WKICA通过核密度估计衡量各独立成分分量偏离正常状态的程度,确定各独立成分分量对故障的贡献度,为各独立成分分量赋予不同的权重,突出对系统变化影响较大的独立成分分量.在特征空间中计算各样本的局部离群因子值,使用核密度估计确定其控制限.最后基于数值仿真和Tennessee Eastman数据集的仿真结果表明了所提出方法的优越性.

1 基于核独立成分分析的故障检测方法

核独立成分分析(KICA)^[13]通过非线性函数将数据从原始空间映射到高维空间再运用线性独立成分分析技术,实现了非高斯特征信息的提取.假设正常工况下测量数据集

$$X = [x_1, x_2, \dots, x_n] \in \mathbf{R}^{m \times n},$$

m 表示系统变量数目, n 表示系统采样数目,利用非线性函数 $\phi(\cdot)$ 将 X 映射到高维空间得到

$$\Phi(\cdot) = [\phi(x_1), \phi(x_2), \dots, \phi(x_n)],$$

借助核函数完成变换,通过下式计算核矩阵 $K \in \mathbf{R}^{n \times n}$:

$$K = [k_1, k_2, \dots, k_n]^T = \begin{bmatrix} k_{11} & k_{12} & \dots & k_{1n} \\ k_{21} & k_{22} & \dots & k_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ k_{n1} & k_{n2} & \dots & k_{nn} \end{bmatrix}. \quad (1)$$

其中: $k_i = [k_{i1}, k_{i2}, \dots, k_{ij}]$, k_{ij} 由核函数 $k(x_i, x_j)$ 计算,即

$$k_{ij} = k(x_i, x_j) = \phi(x_i)^T \phi(x_j), \\ i, j = 1, 2, \dots, n.$$

对数据 Φ 进行白化预处理得到数据矩阵 Z ,有

$$Z = \sqrt{n}\Lambda^{-1}H^T\Phi^T\Phi = \sqrt{n}\Lambda^{-1}H^TK. \quad (2)$$

其中: Λ 为核矩阵 K 前 d 个最大特征值组成的对角矩阵, H 为核矩阵 K 前 d 个最大特征值对应的特征向量组成的矩阵.

基于白化数据矩阵 Z ,采用FastICA算法得到正交分离矩阵 $W = [w_1, w_2, \dots, w_m]^T$ 和独立成分数据矩阵 $S = WZ$.根据 W 中行向量的二范数选择独立成分个数,较大的 d 行作为 W_d .得到当前第 t 时刻采样点 x_t 的白化数据 z_t ,有

$$z_t = \sqrt{n}\Lambda^{-1}H^T\Phi^T\phi(x_t) = \sqrt{n}\Lambda^{-1}H^Tk_t. \quad (3)$$

其中

$$k_t = [k_{t1}, k_{t2}, \dots, k_{tm}], \quad k_{ti} = k(x_t, x_i), \\ i = 1, 2, \dots, m.$$

采样点 x_t 的独立成分 s_t 估计为

$$s_t = W_d z_t. \quad (4)$$

采用如下 I^2 和SPE统计量进行监控:

$$I^2 = s_t^T s_t, \quad (5)$$

$$\text{SPE} = (z_t - W_d^T W_d z_t)^T (z_t - W_d^T W_d z_t). \quad (6)$$

2 基于加权核独立成分分析的故障检测方法

传统核独立成分分析进行故障检测时直接在特征空间建模,没有考虑各独立成分分量对系统故障不同的贡献度.针对这一问题,本文提出基于加权核独立成分分析(WKICA)的故障检测方法.

2.1 加权核独立成分分析

假设给定权重矩阵 Y ,特征空间中第 t 时刻采样点 x_t 加权后的独立成分 $s_t(w)$ 可以表示为

$$s_t(w) = Y \begin{bmatrix} \hat{s}_1(i) \\ \vdots \\ \hat{s}_d(i) \end{bmatrix} = Y \begin{bmatrix} w_1 \\ \vdots \\ w_d \end{bmatrix} z_t. \quad (7)$$

加权矩阵 Y 为对角矩阵,即

$$Y = \text{diag}(y_1, y_2, \dots, y_d),$$

式(7)变为

$$s_t(w) = \begin{bmatrix} y_1 & 0 & 0 \\ \vdots & \ddots & \vdots \\ 0 & 0 & y_d \end{bmatrix} \begin{bmatrix} w_1 \\ \vdots \\ w_d \end{bmatrix} z_t = \begin{bmatrix} y_1 w_1 \\ \vdots \\ y_d w_d \end{bmatrix} z_t. \quad (8)$$

当故障发生时,各独立成分分量对系统变化的贡献度是不同的.独立成分分量变化幅度越大,对故障的贡献度就越大;反之,变化幅度越小,对故障的贡献度就越小.引入加权矩阵 Y 为各独立成分分量赋予不同的权重,突出对系统故障的贡献度较大的包含有用信息的独立成分分量.使用当前时刻采样点的各独立成分分量偏离相应正常状态独立成分分量的程度来衡量当前时刻采样点各独立成分分量对故障的贡献度.偏离程度越大,对系统故障的贡献度就越大,赋予该独立成分分量较大权重,加大与其他独立成分分量的差异,突出其对故障的贡献度;反之,偏离程度越小,表明当前时刻采样点对系统故障的影响越小.

核密度估计^[19]方法能有效估计复杂数据的概率密度,首先,估计正常状态下训练数据集特征空间中

各独立成分分量的密度函数;然后,利用估计的密度函数计算新采样点各独立成分分量的密度值,该值用来衡量各独立成分分量对系统故障的贡献度.密度值越小,偏离程度越大,贡献度就越大;反之,密度值越大,偏离程度越小,贡献度就越小,以此对各独立成分分量实施不同的权重策略.在核密度估计中,一般情况下核函数采用高斯核函数的形式,密度函数可以估计为

$$p(x) = \frac{1}{nh\sqrt{2\pi}} \sum_{i=1}^n \exp\left(-\frac{(x-x_i)^2}{2(h)^2}\right). \quad (9)$$

其中: h 为平滑参数, n 为采样数目, x 为待估计的随机变量, x_i 为随机变量的第 i 个采样点.

已知提取正常工况下的独立成分矩阵 $S = [s_1, s_2, \dots, s_n]$,使用核密度估计方法分别求得各独立成分分量 s_i 的密度函数, $i = 1, 2, \dots, n$.然后,提取新样本 x_{new} 的独立成分 $s^{\text{new}} = [s_1^{\text{new}}, s_2^{\text{new}}, \dots, s_n^{\text{new}}]$,估计各独立成分分量 s_i^{new} 的密度值,其权值 y_i^{new} 可由下式确定:

$$y_i^{\text{new}} = \begin{cases} 1, & p(s_i^{\text{new}}) \geq \alpha; \\ \beta, & p(s_i^{\text{new}}) < \alpha. \end{cases} \quad (10)$$

其中: $i = 1, 2, \dots, n$, α 为核密度估计的阈值, β 为权重参数.当 $p(s_i^{\text{new}}) \geq \alpha$ 时,新样本 x_{new} 的第 i 个独立成分分量 s_i^{new} 未偏离正常状态,将权值 y_i^{new} 设置为1;当 $p(s_i^{\text{new}}) < \alpha$ 时,新样本 x_{new} 的第 i 个独立成分分量 s_i^{new} 偏离了正常状态,该独立成分分量对系统故障的贡献度就越大,将权值设置为 β .定义独立成分 s_i^{new} 的变化率为

$$RI_i^2(\text{new}) = \frac{I_i^2(\text{new})}{\overline{I^2(\text{new})}}. \quad (11)$$

其中: $I_i^2(\text{new})$ 为第 i 个独立成分分量 s_i^{new} 的 I^2 统计, $\overline{I^2(\text{new})}$ 为独立成分 s^{new} 的 I^2 统计的均值.令

$$\beta = \exp\left(\frac{RI_i^2(\text{new}) - 1}{\sigma}\right),$$

其中 $\sigma > 0$ 为可调参数. $RI_i^2(\text{new})$ 越大,当前采样点第 i 个独立成分分量偏离正常状态的程度越大,加权参数 β 越大.当采样点的各独立成分分量被赋予不同的权值后,各采样点独立成分之间的差别就越大.故障检测将正常样本和故障样本区分开,当数据集之间的差异性越大时,所建立的监控统计量越有效.

2.2 局部离群因子

作为一种基于密度的离群点检测方法,局部离群因子(LOF)方法认为样本集中的离群点将比正常样本有更大的局部离群因子值,用于寻找多维数据矩阵中的离群点.对于数据集 $X = [x_1, x_2, \dots, x_n] \in \mathbf{R}^{m \times n}$ 中的样本 x_i ,其局部离群因子值按以下步骤计算.首先,根据样本间的欧氏距离在数据矩阵 X 中

为 x_i 寻找 l 个近邻, $i = 1, 2, \dots, n$.定义样本 x_i 的局部邻域 $N(x_i)$ 由 x_i 的 l 个近邻组成,令

$$N(x_i) = (x_i^1, \dots, x_i^f, \dots, x_i^l), \quad f = 1, 2, \dots, l.$$

样本 x_i 与其邻域集合 $N(x_i)$ 中的第 l 个近邻之间的欧氏距离 $d(x_i, x_i^l)$ 为样本 x_i 的邻域半径 $l\text{-dist}(x_i)$,则样本 x_i 与其邻域集合 $N(x_i)$ 中任一近邻 x_i^f 之间的可达距离为

$$\text{reach_dist}(x_i, x_i^f) = \max(l\text{-dist}(x_i^f), d(x_i, x_i^f)), \quad (12)$$

样本 x_i 的局部可达密度计算为

$$\text{lrd}(x_i) = \frac{l}{\sum_{f=1}^l \text{reach_dist}(x_i, x_i^f)}, \quad (13)$$

得到样本 x_i 的局部离群因子值为

$$\text{lof}(x_i) = \frac{\sum_{f=1}^l \text{lrd}(x_i^f)}{l \text{lrd}(x_i)}. \quad (14)$$

其中: l 为样本 x_i 的近邻个数, $\text{lrd}(x_i)$ 为样本 x_i 的局部可达密度, $\text{lrd}(x_i^f)$ 为邻域集合 $N(x_i)$ 中 x_i 的近邻 x_i^f 的局部可达密度.

2.3 基于加权核独立成分分析的故障检测方法

基于加权核独立成分分析方法的故障检测步骤如下.

Step 1: 收集正常工况下过程变量数据集 X ,作归一化处理.

Step 2: 使用KICA提取正常数据集的独立成分矩阵 S_{normal} .

Step 3: 使用核密度估计方法确定正常工况独立成分矩阵 S_{normal} 的各独立成分分量的密度分布函数.

Step 4: 将独立成分矩阵 S_{normal} 作为LOF的输入建立监控模型,确定控制限 $\text{lof}_{\text{limit}}$.

Step 5: 对新样本 x_{new} 归一化处理后提取独立成分 s^{new} ,将 s^{new} 中各独立成分分量分别代入相应的密度函数中,确定各独立成分分量的权值,得到加权后的独立成分 $s_{\text{new}}(w)$.

Step 6: 为加权后的独立成分 $s_{\text{new}}(w)$ 在独立成分矩阵 S_{normal} 中寻找 l 个近邻,计算局部离群因子值 $\text{lof}(x_{\text{new}})$,与控制限 $\text{lof}_{\text{limit}}$ 进行比较,当 $\text{lof}(x_{\text{new}}) > \text{lof}_{\text{limit}}$ 时,判断有故障发生.

3 仿真实验

为了验证本文所提出方法的优越性,将基于加权核独立成分分析的故障检测方法应用于数值仿真和Tennessee Eastman过程仿真.核函数选择高斯核函数,其中核参数 $h = 20n$, n 为过程变量的维数,统计量置信限均为99%.

3.1 数值仿真

Lee 等^[20]提出的数值仿真例子广泛应用在过程监控中, 具体结构如下:

$$\begin{aligned} r(i) &= A \times r(i-1) + B \times u(i-1), \\ u(i) &= C \times u(i-1) + D \times h(i-1), \\ g(i) &= r(i) + v(i). \end{aligned} \quad (15)$$

其中

$$A = \begin{bmatrix} 0.018 & -0.191 & 0.287 \\ 0.847 & 0.264 & 0.943 \\ -0.333 & 0.514 & -0.217 \end{bmatrix},$$

$$B = \begin{bmatrix} 1 & 2 \\ 3 & -4 \\ -2 & 1 \end{bmatrix}, C = \begin{bmatrix} 0.811 & -0.226 \\ 0.477 & 0.415 \end{bmatrix},$$

$$D = \begin{bmatrix} 0.193 & 0.689 \\ -0.320 & -0.749 \end{bmatrix}.$$

h 为均匀分布于 $(-2, 2)$ 的随机向量, v 为均值为 0、方差为 0.1 的噪声向量, i 为采样时刻. 训练数据集 X 包括 200 个正常采样点, 其中 $x(i) = [g^T(i) \quad u^T(i)]$, 测试数据集也包括 200 个采样点, 设定如下两种故障:

- 1) 故障 1, 系统从第 51 个样本起变量 h_1 发生幅度为 3.5 的阶跃故障;
- 2) 故障 2, 系统从第 51 个样本起变量 h_2 发生 $0.06(i-50)$ 的慢偏移故障, i 为采样时刻.




图 1 不同方法对数值例子中故障 1 检测结果

图 1 为不同方法对故障 1 的检测结果, 图中实线表示监控统计量, 虚线表示控制限. 图 1(a) 和图 1(b) 为基于 I^2 和 SPE 统计量的 KICA 方法检测结果, 两种统计量基本检测到故障发生, 但效果较差, 出现明显的漏报现象. 图 1(c) 为 KICA 方法采用 lof 统计量的检测结果, 可以看出效果要好于基于 I^2 和 SPE 统计量的 KICA 方法. 如图 1(d) 所示, 本文方法从第 51 时刻其监控统计量马上超过了控制限, 而且能持续地检测出故障, 没有发生误报和漏报.

故障 2 是一个缓慢漂移型的故障, 随着时间增加, 故障幅度较大时, 图 2(a) 和图 2(b) 显示基于 I^2 和 SPE 统计量的 KICA 方法也能够检测出故障发生, 而在故障发生初期, 漏报较多, 稳定性差. 图 2(c) 中, KICA 方法采用 lof 统计量时虽然能在第 61 时刻检测出故障, 但其监控统计量在检测出故障发生之后仍在控制限附近波动. 如图 2(d) 所示, 本文方法在第 58 时刻检测出故障, 且之后与控制限完全分离.

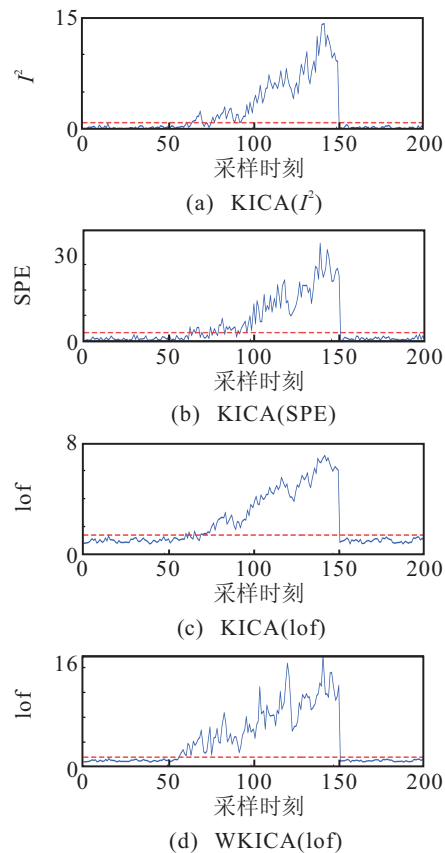


图 2 不同方法对数值例子中故障 2 检测结果

以故障 1 为例, 给出各独立分量在整个过程的变化情况. 定义采样点 x_t 独立成分 s_t 第 m 个独立成分分量的 I^2 为

$$I_t^2(m) = x_t^T W_m^T W_m x_t, \quad (16)$$

其中 W_m 为分离矩阵 W 的第 m 行. 由图 3 可见, 从第 51 时刻开始, 第 5 个独立成分分量 $s(5)$ 的统计量 $I^2(5)$ 发生了很大变化, 而其他独立成分分量的 I^2 统

计量变化较小. 因此, 可以认为 $s(5)$ 包含了绝大多数故障信息, 对故障的贡献度最大, 而当所有的独立成分分量平等地作为局部离群因子方法的输入建立监控模型时, 可能导致有用信息被淹没, 影响故障检测的性能. 因此, 突出能够反映故障信息的独立成分分量是十分重要的.

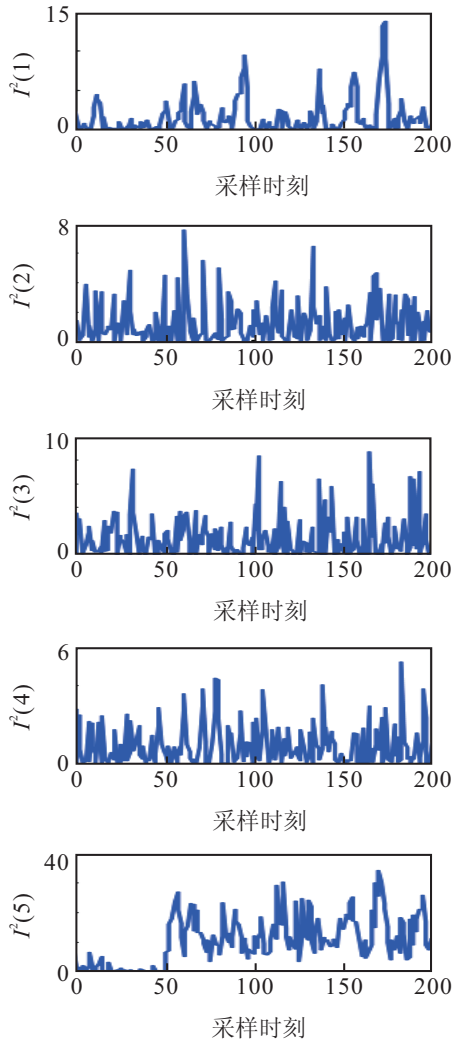


图 3 故障 1 工况下各独立成分分量的 I^2 统计

图 4 为故障 1 各独立成分分量的核密度估计结果, 可以看出当故障发生时, 各独立成分分量核密度估计的数值变化是不一样的. 前 4 个独立成分分量的密度分布自始至终变化很小, 而第 5 个独立成分分量 $s(5)$ 从第 51 时刻起发生了较大变化, 包含了较为丰富的信息, 应该赋予其较大权重. 图 5 为各独立成分分量加权的权值, 由图 5 可见, 测试样本前 50 个采样时刻各独立成分分量的权值基本都为 1, 在第 51~200 采样时刻之间, 只有 $s(5)$ 赋予了较大的权值, 其他 4 个独立成分分量的权值基本保持不变. 各独立成分分量赋予不同的权重因子后, 测试样本中采样点加权后的独立成分与正常样本的独立成分的差异性越大, 该采样点在数据矩阵中的局部离群因子值越大, 那么该采样点被认为是异常点.

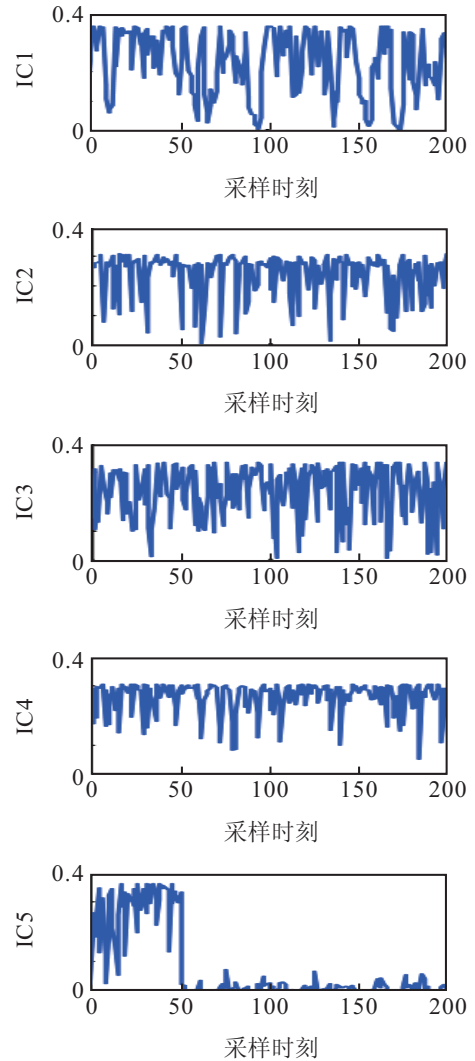


图 4 故障 1 各独立成分分量核密度估计结果




图 5 数值例子中故障 1 独立成分加权权值

3.2 Tennessee Eastman 过程仿真

为进一步验证所提出加权核独立成分分析方法的优越性, 采用 Tennessee Eastman (TE)^[1] 检测数据集进行仿真实验. TE 过程作为一个评价过程监控方法性能的真实工业过程的仿真平台, 广泛应用在基于多元统计方法的故障检测研究领域. 该过程有 12 个操作变量和 41 个测量变量, 包含了正常状态和 21 种不同状态的故障, 每种状态包括训练数据集和测试数据集, 每一种故障从第 161 个数据点引入, 到第 960 个数据点结束.

选取故障 19 进行验证性仿真实验, 仿真结果如图 6 所示. 图 6(a) 和图 6(b) 显示了基于 KICA 方法,

I^2 和 SPE 统计量对故障 19 的检测结果, 两种统计量无法对故障 19 实现完全检测. 图 6(c) 表示 KICA 方法采用 lof 作为统计量时检测效果得到了一定的改善, 这是因为基于密度的局部离群因子可以较准确地确定正常和故障工况的非线性控制限边界. 本文方法对故障 19 的检测结果如图 6(d) 所示, 在第 161 时刻, 监控统计量立刻超出了控制限, 且能持续将故障一直显示到过程结束, 这是因为本文方法根据测试样本中采样点偏离正常样本的程度, 对测试样本实施不同的权重策略, 当将测试样本中的采样点作为局部离群因子的输入计算其在正常样本中的 lof 值时, 加权策略能够加大测试样本中采样点与正常样本的独立成分的差异性, 从而得到较大的 lof 值, 提高了故障检测精度.

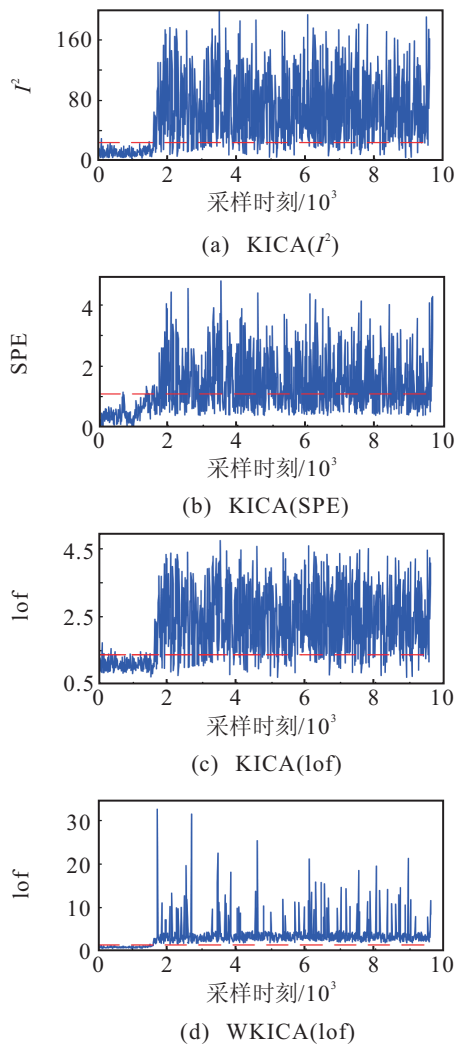


图 6 不同方法对 TE 过程故障 19 检测结果

表 1 为不同方法在 TE 过程故障测试数据集上的故障检测率. 由表 1 可见, 本文方法在测试数据集中均取得了最优结果, 表明所提出方法具有更高的检测精度. lof 统计量的检测率要高于传统的 I^2 和 SPE 统计量, 在使用相同的 lof 统计量时, 加权核独立成分分析方法的检测率要高于传统的核独立成分分析方法, 表明了所提出加权策略的有效性.

表 1 故障检测率测试结果

方法	测试数据集								
	04	10	11	13	16	17	18	19	20
KICA(I^2)	93	86	77	94	88	94	95	87	77
KICA(SPE)	98	78	68	94	82	94	90	72	70
KICA(lof)	100	92	80	98	92	97	95	91	80
WKICA(lof)	100	98	86	100	97	99	98	100	85

与传统 I^2 和 SPE 统计量相比, 在计算 lof 统计量时有一个新的参数 l , 它表示测试数据集的样本在训练集正常样本数据矩阵中的近邻个数. 为了考察参数 l 对本文方法产生的影响, 在不同参数 l 下对比分析了 4 种方法的检测效果, 图 7 给出了不同方法随着参数 l 变化时的平均漏报率. 由于传统 KICA 方法采用的 I^2 和 SPE 统计量中并不包括参数 l , 采用 I^2 和 SPE 统计量时其平均漏报率并不随着 l 的变化而变化, 是与 l 无关的一条直线. 而 lof 统计量在 l 大于 30 后, 其平均漏报率基本保持不变, 同时低于 I^2 和 SPE 统计量. 由图 7 可见, 参数 l 对本文方法的检测性能影响不大.




图 7 不同方法在不同 l 时的平均漏报率

4 结 论

本文针对核独立成分分析故障检测提取独立成分时忽略各独立成分分量对系统异常贡献度的差异, 提出了基于加权核独立成分分析的故障检测方法. 该方法采用核独立成分分析提取过程数据的独立成分信息, 根据各独立成分分量偏离正常状态的程度对其实施不同的权重, 最后采用局部离群因子建立统计量, 充分考虑了故障发生时不同独立成分分量对系统变化的影响, 并且采用的统计量能较准确地确定正常和故障工况的非线性控制限边界, 提高了故障检测精度. 基于数值仿真和 Tennessee Eastman 过程故障检测数据集的仿真结果, 表明了所提出方法的优势.

参考文献(References)

[1] Yin S, Ding S X, Haghani A, et al. A comparison study of basic data-driven fault diagnosis and process monitoring methods on the benchmark tennessee eastman process[J]. J of Process Control, 2012, 22(9): 1567-1581.
 [2] 李晗, 萧德云. 基于数据驱动的故障诊断方法综述[J]. 控制与决策, 2011, 26(1): 1-9.

- (Li H, Xiao D Y. Survey on data driven fault diagnosis methods[J]. *Control and Decision*, 2011, 26(1): 1-9.)
- [3] 王健, 冯健, 韩志艳. 基于流形学习的局部保持PCA算法在故障检测中的应用[J]. *控制与决策*, 2013, 28(5): 683-687.
(Wang J, Feng J, Han Z Y. Locally preserving PCA method based on manifold learning and its application in fault detection[J]. *Control and Decision*, 2013, 28(5): 683-687.)
- [4] 赵珍, 王福利, 贾明兴, 等. 缓变故障的概率故障预测方法研究[J]. *控制与决策*, 2010, 25(4): 572-576.
(Zhao Z, Wang F L, Jia M X, et al. Research on probabilistic fault prediction of incipient fault[J]. *Control and Decision*, 2010, 25(4): 572-576.)
- [5] Jiang Q, Yan X, Tong C. Double-weighted independent component analysis for non-Gaussian chemical process monitoring[J]. *Industrial & Engineering Chemistry Research*, 2013, 52(40): 14396-14405.
- [6] 杨英华, 李召, 陈永禄, 等. 基于CVA-ICA与CSM的故障诊断方法[J]. *东北大学学报: 自然科学版*, 2012, 33(12): 1685-1689.
(Yang Y H, Li Z, Chen Y L, et al. Fault diagnosis based on CVA-ICA and CSM[J]. *J of Northeastern University: Natural Science*, 2012, 33(12): 1685-1689.)
- [7] 石怀涛, 刘建昌, 谭帅, 等. 基于混合KPLS-FDA的过程监控和质量预报方法[J]. *控制与决策*, 2013, 28(1): 141-146.
(Shi H T, Liu J C, Tan S, et al. Process monitoring and quality prediction method based on hybrid KPLS-FDA[J]. *Control and Decision*, 2013, 28(1): 141-146.)
- [8] 王姝, 赵珍, 常玉清, 等. 基于故障特征时段识别的间歇过程故障诊断方法[J]. *东北大学学报: 自然科学版*, 2013, 34(6): 761-765.
(Wang S, Zhao Z, Chang Y Q, et al. Fault diagnosis method for batch process based on identification of fault feature phases[J]. *J of Northeastern University: Natural Science*, 2013, 34(6): 761-765.)
- [9] 范雪莉, 冯海泓, 原猛. 基于互信息的主成分分析特征选择算法[J]. *控制与决策*, 2013, 28(6): 915-919.
(Fan X L, Feng H H, Yuan M. PCA based on mutual information for feature selection[J]. *Control and Decision*, 2013, 28(6): 915-919.)
- [10] Zhang Y, Zhang Y. Fault detection of non-Gaussian processes based on modified independent component analysis[J]. *Chemical Engineering Science*, 2010, 65(16): 4630-4639.
- [11] Stefatos G, Ben Hamza A. Dynamic independent component analysis approach for fault detection and diagnosis[J]. *Expert Systems with Applications*, 2010, 37(12): 8606-8617.
- [12] Rashid M M, Yu J. A new dissimilarity method integrating multidimensional mutual information and independent component analysis for non-Gaussian dynamic process monitoring[J]. *Chemometrics and Intelligent Laboratory Systems*, 2012, 115: 44-58.
- [13] Lee J M, Qin S J, Lee I B. Fault detection of nonlinear processes using kernel independent component analysis[J]. *Canadian J of Chemical Engineering*, 2007, 85(4): 526-536.
- [14] Fan J, Wang Y. Fault detection and diagnosis of non-linear non-Gaussian dynamic processes using kernel dynamic independent component analysis[J]. *Information Sciences*, 2014, 259: 369-379.
- [15] Breunig M M, Kriegel H P, Ng R T, et al. LOF: Identifying density-based local outliers[J]. *Sigmod Record ACM*, 2000, 29(2): 93-104.
- [16] Lee J, Kang B, Kang S H. Integrating independent component analysis and local outlier factor for plant-wide process monitoring[J]. *J of Process Control*, 2011, 21(7): 1011-1021.
- [17] Ma H, Hu Y, Shi H. Fault detection and identification based on the neighborhood standardized local outlier factor method[J]. *Industrial & Engineering Chemistry Research*, 2013, 52(6): 2389-2402.
- [18] Ma Y, Shi H, Ma H, et al. Dynamic process monitoring using adaptive local outlier factor[J]. *Chemometrics and Intelligent Laboratory Systems*, 2013, 127: 89-101.
- [19] Martin E B, Morris A J. Non-parametric confidence bounds for process performance monitoring charts[J]. *J of Process Control*, 1996, 6(6): 349-358.
- [20] Jiang Q, Yan X. Probabilistic monitoring of chemical processes using adaptively weighted factor analysis and its application[J]. *Chemical Engineering Research and Design*, 2014, 92(1): 127-138.

(责任编辑: 郑晓蕾)