

引用格式:陆天驰,吕照民.基于自适应独立成分分析的化工过程监测[J].北京化工大学学报(自然科学版),2019,46(6): 64-71.

LU TianChi, LV ZhaoMin. Chemical process monitoring based on adaptive independent component analysis[J]. Journal of Beijing University of Chemical Technology (Natural Science), 2019, 46(6): 64-71.

# 基于自适应独立成分分析的化工过程监测

陆天驰<sup>1</sup> 吕照民<sup>2\*</sup>

(上海工程技术大学 1. 电子电气工程学院; 2. 轨道交通学院, 上海 200336)

**摘 要:**针对独立成分分析(independent component analysis, ICA)方法应用于过程监测时如何选择独立成分(independent component, IC)的问题,提出了自适应独立成分分析(adaptation independent component analysis, AICA)方法。AICA方法首先利用分离矩阵建立关联矩阵,该关联矩阵表示IC的相似性,同时通过核密度估计选择概率密度最小的IC作为特殊独立成分(particular independent component, PIC),再通过关联矩阵选择与PIC具有相似变异特征的几个普通独立成分(common independent components, CICs),最后将PIC与CICs用于构造监测统计量。将AICA方法应用于田纳西-伊士曼(Tennessee Eastman, TE)仿真过程,测试结果表明所提方法对于过程监测是有效的。

**关键词:**过程监测;独立成分分析;自适应;挑选独立成分;漏报率;误报率

**中图分类号:** TP273 **DOI:** 10.13543/j.bhxbzr.2019.06.010

## 引言

随着近年来工业技术的迅速发展,各类工业生产过程的自动化程度不断提高,工艺过程愈加复杂,对工厂安全 and 产品质量的要求越来越高,进而人们对工业过程监测也越来越重视。此外,自动化控制系统和各类电子仪表已经广泛应用于工业生产过程,生产过程的各项数据都可以很好地予以提取和保存,这给基于数据驱动的过程监测创造了良好的条件。通过对工业过程数据的详细分析,人们可以有效地监测自动化设备和工业流水线的运行状况,并且及时对相关故障进行诊断与排除。

基于数据驱动的过程监测可以分为单变量统计过程控制(univariate statistical process control, USPC)和多变量统计过程控制(multiple statistical process control, MSPC),而主成分分析(principal component analysis, PCA)是MSPC中最基本和最常用的方法。

然而PCA应用于过程监测时需要假设数据服从高斯分布,当数据不满足高斯分布时,PCA的监测方法可能达不到满意的监测效果;且PCA仅利用了数据的二阶统计信息,未使用高阶统计信息<sup>[1]</sup>。在现代工业过程中数据往往不能严格满足高斯分布,由于独立成分分析(independent component analysis, ICA)方法无需数据满足高斯分布的假设,因此可以使用基于ICA的监测方法检测故障信息,同时ICA又可以利用数据的高阶统计量信息<sup>[2]</sup>。ICA概念的提出最初用于处理不同的声音信号源,随着其应用场景在工业领域的不断发展下愈发广泛,该方法在近年来受到越来越多的关注。ICA方法应用于过程监测的原理是从过程数据中提取出独立成分(independent component, IC),以此获得变异特征信息<sup>[3]</sup>。但ICA方法应用于过程监测存在两大问题<sup>[4]</sup>:①ICA的随机初始化过程导致解的不一致;②如何挑选IC是难以确定的。这两个问题使得ICA方法用于过程监测的效果不佳。目前对于如何在ICA方法中挑选IC没有一个普遍接受的标准,但常用的挑选IC的准则有4种,分别为Lee等<sup>[5]</sup>提出的利用分离矩阵行向量的欧几里德范数的标准,Back和Weigend<sup>[6]</sup>提出的根据每个IC的范数的标准,Hyvärinen<sup>[7]</sup>提出的按照非高斯性强弱的标准,

收稿日期:2019-03-07

基金项目:上海市青年科技英才扬帆计划(18YF1409200);上海工程技术大学人才计划项目—展翅计划

第一作者:男,1995年生,硕士生

\*通信联系人

E-mail: zhaomin\_lv@sues.edu.cn

Wang 等<sup>[8]</sup>提出的基于最小均方差进行判断的标准。然而,由于监测过程数据的多样性和复杂性,在没有预知变异特征信息的情况下很难确定哪个准则更有效。为了探究监测过程中不同 IC 的挑选标准,许多学者进行了相关研究,如 Jiang 等<sup>[9]</sup>提出了自适应加权 ICA 的方法,根据各 IC 的重要性设置不同的加权值,并根据 IC 的监测统计量的变化率来进行评估,避免变异特征信息被淹没,以此来降低漏报率。Zhang 等<sup>[10]</sup>提出了基于粒子群的 ICA 监测算法,引入粒子群算法替代常用的牛顿迭代法,根据原始信号的重现情况进行挑选,但该方法增加了运算时间。Wang 等<sup>[11]</sup>提出将多块策略应用于分离矩阵并生成子块,在降低数据复杂度的基础上再利用贝叶斯推理将子块的结果相结合。Ge 等<sup>[12]</sup>提出了一种性能驱动的 IC 选择方法,但该方法需要预先获取异常数据集,在实际应用中较难实现。除了以上方法外,也可以将一些不同的准则通过贝叶斯推理进行组合集成,以此提高监测性能的稳定性。Tong 等<sup>[13]</sup>提出一种改进的 ICA (MSE-ICA) 算法,通过贝叶斯推理将基于 ICA 的 4 种常用的 IC 挑选准则组合成集成模型。之后 Tong 等<sup>[4]</sup>又对该方法作了改进,将基于 modified ICA (MICA) 算法的迭代过程并行执行 3 次再按照 MICA 方法进行建模,获取的一系列 MICA 监测模型通过贝叶斯推理得到双层集成监测模型。最近, Li 等<sup>[14]</sup>提出一种自适应方法,采用分层聚类的手段对随机选择的 IC 生成模型进行聚类,当模型数量充足时从每个模型群中随机选择一个模型,所有保留的模型都用作模型自适应选择的范围;由于这些模型所选择的 IC 具有多样性,它们具有适应各种故障的能力,最后再结合贝叶斯推理求得故障监测指标。该方法虽然具备自适应性,但只利用了离线建模的数据,无法利用在线信息进行监测。

分离矩阵描述了变量和 IC 间的关系,分离向量可以作为 IC 的特征向量,特征向量相似的 IC 具有相似的变异特征,因此将相似的变异特征集中监测可以减少变异特征分散的风险。由于离线选择的 IC 无法确保其具有变异特征信息,因此本文提出利用在线信息来实时选择合适的 IC。针对如何挑选 IC 的问题,提出了一个自适应独立成分分析 (adaptation independent component analysis, AICA) 方法,该方法可利用实时的在线信息自动选择 IC,以实现

自适应的功能。所提方法的优势在于自适应地挑选了 IC,剔除了冗余信息,避免了特征信息被淹没;相似的变异特征集中监测减少了变异特征的分散,因此显著提高了监测性能。田纳西-伊士曼 (TE) 过程的仿真证明了所提方法的有效性。

## 1 ICA 与 KDE 方法简介

### 1.1 ICA 方法

ICA 的目标是计算混合矩阵  $\mathbf{A}$  和独立成分  $\mathbf{S}$ , 以此实现对信号的处理。现有一个变量均值是 0、样本方差是 1 的二维矩阵  $\mathbf{X}(n \times m)$ , 其中变量为  $m$  个, 样本为  $n$  个, 假设有  $m$  个测量变量, 在第  $k$  个样本点时  $\mathbf{X}(k) = [\mathbf{x}_1(k), \mathbf{x}_2(k), \dots, \mathbf{x}_m(k)]$ , 可以由  $r(r < m)$  个未知独立成分  $[\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_r]^T$  来线性表示, 它们之间的关系可以表示为

$$\mathbf{X} = \mathbf{AS} + \mathbf{E} \quad (1)$$

式中,  $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m] \in \mathbf{R}^{m \times n}$  是数据矩阵;  $n$  是样本总数;  $\mathbf{A} = [\mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_r] \in \mathbf{R}^{m \times r}$  是混合矩阵;  $\mathbf{S} = [\mathbf{s}_1, \mathbf{s}_2, \dots, \mathbf{s}_r] \in \mathbf{R}^{r \times m}$  是 IC 矩阵;  $\mathbf{E} \in \mathbf{R}^{m \times n}$  是残差矩阵。

ICA 的基本原理是根据已知的数据矩阵  $\mathbf{X}$  估计出其独立成分  $\mathbf{S}$  和混合矩阵  $\mathbf{A}$ , 所以需要找到一个分离矩阵  $\mathbf{W}$ , 通过分离矩阵使得数据矩阵  $\mathbf{X}$  的估计  $\hat{\mathbf{S}}$  尽量独立, 其关系表示为

$$\hat{\mathbf{S}} = \mathbf{WX} \quad (2)$$

在对 ICA 分解之前, 首先要对数据矩阵  $\mathbf{X}$  进行白化处理, 白化处理最普遍的方法是对特征值分解。可以认为  $\mathbf{X}(k)$  的协方差矩阵是  $\mathbf{R}_x = \mathbf{E}\{\mathbf{x}(k)\mathbf{x}^T(k)\}$ ,  $\mathbf{R}_x$  的特征值分解可以表示为

$$\mathbf{R}_x = \mathbf{U}\mathbf{\Lambda}\mathbf{U}^T \quad (3)$$

白化处理后表示为

$$\mathbf{z}(k) = \mathbf{Q} \cdot \mathbf{x}(k) \quad (4)$$

式中  $\mathbf{Q} = \mathbf{\Lambda}^{-1/2} \mathbf{U}^T$ 。易证  $\mathbf{R}_z = \mathbf{E}\{\mathbf{z}(k)\mathbf{z}^T(k)\}$  是该白化处理后得到的单位矩阵, 所以白化处理后也可以表示为

$$\mathbf{z}(k) = \mathbf{Q} \cdot \mathbf{x}(k) = \mathbf{Q} \cdot \mathbf{A} \cdot \mathbf{s}(k) = \mathbf{B} \cdot \mathbf{s}(k) \quad (5)$$

这里的  $\mathbf{B}$  是一个正交矩阵, 证明过程表示为

$$\mathbf{E}\{\mathbf{z}(k)\mathbf{z}^T(k)\} = \mathbf{B}\mathbf{E}\{\mathbf{s}(k)\mathbf{s}^T(k)\}\mathbf{B}^T = \mathbf{B}\mathbf{B}^T = \mathbf{I} \quad (6)$$

因此, 这里把要找寻满秩矩阵  $\mathbf{A}$  的复杂问题转换为要寻找正交矩阵  $\mathbf{B}$  的简单问题, 该过程可以表示为

$$\hat{\mathbf{s}}(k) = \mathbf{B}^T \mathbf{z}(k) = \mathbf{B}^T \mathbf{Q} \mathbf{x}(k) \quad (7)$$

由公式(7)可得到分离矩阵  $\mathbf{W}$  与正交矩阵  $\mathbf{B}$  的关系

$$\mathbf{W} = \mathbf{B}^T \cdot \mathbf{Q} \quad (8)$$

可以通过观察所提取的 IC 的线性组合来进行 ICA 降维,且必须选择适当数量的 IC,以较少的计算量来获得较高的变化数据。通常,  $\mathbf{L}_2$  的过程变化会随着  $\mathbf{L}_2$  标准假设  $\mathbf{W}$  平方和的增大而变大。 $\mathbf{W}$  中选定的  $b$  行重构了一个低维矩阵  $\mathbf{W}_b$ , 相应地选定  $b$  列重构一个矩阵  $\mathbf{B}_b$ 。类似于 PCA 方法,在样本  $k$  处构造两个统计量即  $\mathbf{I}^2$  统计量和平方预测误差(squared prediction error, SPE),其中  $\mathbf{I}^2$  统计量表示从实时信息中提取的独立成分与过去正常工况下独立成分的偏离程度,平方预测误差表示除了主要独立成分以外的部分信息偏离程度<sup>[15]</sup>,公式为

$$\mathbf{I}^2 = \hat{\mathbf{s}}(k)^T \hat{\mathbf{s}}(k) \quad (9)$$

$$E_{\text{SPE}}(k) = \mathbf{e}(k)^T \mathbf{e}(k) = (\mathbf{x}(k) - \hat{\mathbf{x}}(k))^T (\mathbf{x}(k) - \hat{\mathbf{x}}(k)) \quad (10)$$

式中,  $\hat{\mathbf{s}}(k) = \mathbf{W}_b \mathbf{x}(k)$ , 估计量  $\hat{\mathbf{x}}(k) = \mathbf{Q}^{-1} \mathbf{B}_b \mathbf{W}_b \mathbf{x}(k)$ 。

## 1.2 核密度估计(KDE)方法

由于 ICA 方法数据一般不服从高斯分布,导致  $\mathbf{I}^2$  和 SPE 统计量的控制限不能直接确定,因此要用核密度估计(kernel density estimation, KDE)方法计算 ICA 方法中的  $\mathbf{I}^2$  和 SPE 统计量的控制限。KDE 是概率论中用来估计未知量的密度函数,是一个描述随机变量在某个确定取值点附近出现的可能性的函数,属于非参数检验方法之一。定义具有核函数  $\mathbf{K}$  的单变量核估计量为

$$\hat{f}(x) = \frac{1}{nh} \sum_{i=1}^n \mathbf{K} \left\{ \frac{\mathbf{x} - \mathbf{x}_i}{h} \right\} \quad (11)$$

式中  $\mathbf{x}$  为数据点,  $\mathbf{x}_i$  为数据集的观测值,  $h$  为带宽,  $n$  为观测值。核函数  $\mathbf{K}$  决定函数凸起部分的大小。在实际应用中,高斯核函数运用最为广泛,而核函数的形式本身不是最重要的。高斯核函数以及核密度估计可以表示为

$$\hat{f}(x) = \frac{1}{n} \frac{1}{h \sqrt{2\pi}} \sum_{i=1}^n \exp \left( -\frac{(\mathbf{x} - \mathbf{x}_i)^2}{2h^2} \right) \quad (12)$$

在核密度估计方法中,带宽  $h$  通常情况下对估计的性能有重要影响,带宽  $h$  的最优选择取决于数据点的个数、数据分布及核函数的选择。基于交叉验证的选择方法是较优的,例如最小二乘交叉验证(least squares cross validation, LSCV)和偏置

交叉验证,本文将 LSCV 作为选择  $h$  的方法。为了得到 ICA 方法中的  $\mathbf{I}^2$  和 SPE 统计量的控制限,首先要得到正常运行的  $\mathbf{I}^2$  和 SPE 统计量的数据,然后利用单变量和密度估计来估计正常运行的  $\mathbf{I}^2$  和 SPE 统计量的密度函数,最后将占密度函数区域 99% 的点的值作为正常运行下  $\mathbf{I}^2$  和 SPE 统计量的控制限。

## 2 AICA 方法

### 2.1 方法简介

AICA 方法通过离线建立关联矩阵并在线挑选 IC 的方法对过程进行监测。分离矩阵的向量可以体现出过程变量对 IC 的影响。把分离矩阵的向量定义为 IC 的特征向量,当对 IC 有较大影响的过程变量发生变异时,对应的 IC 也会产生变异,所以特征向量相似的 IC 具有相似的变异特征。在离线建模阶段构造关联矩阵  $\mathbf{R}$  来表示各 IC 特征向量的相似性,具体方法如下。

先假定正常数据矩阵为  $\mathbf{X} \in \mathbf{R}^{n \times m}$ , 其中  $n$  为样本总数,  $m$  为变量个数。首先对数据进行预处理,然后对数据矩阵  $\mathbf{X}$  进行 ICA 分解得到独立成分  $\mathbf{S}$ ,并由式(2)得

$$\mathbf{W} = [\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_m] \quad (13)$$

式中,  $\mathbf{W} \in \mathbf{R}^{m \times k}$  为分离矩阵,  $\mathbf{w}_1, \mathbf{w}_2, \dots, \mathbf{w}_m$  为各 IC 对应的特征向量。之后对于收集到的在线数据进行标准化处理,再转换至 IC 空间。AICA 方法采用核密度估计方法来计算每个在线 IC 对应的概率密度值,计算公式为

$$\hat{f}(s_i) = \frac{1}{n} \frac{1}{h \sqrt{2\pi}} \sum_{k=1}^n \exp \left( -\frac{(s_i - s_{ik})^2}{2h^2} \right) \quad (14)$$

式中,  $\hat{f}(s_i)$  是第  $i$  个 IC 的概率密度估计。概率密度值越低,则 IC 变异性越大。选择变异性最大的 IC 作为 PIC

$$f_i = \hat{f}(s_i) \quad (15)$$

$$f_a = \min(f_1, f_2, \dots, f_m) \Rightarrow P_{\text{PIC}} = S_a \quad (16)$$

再构造相似距离矩阵  $\mathbf{D}$  来表示各 IC 特征向量之间的相似程度,并用 IC 特征向量间的欧氏距离衡量

$$\mathbf{D}_{i,j} = (\mathbf{w}_i - \mathbf{w}_j)^T \cdot (\mathbf{w}_i - \mathbf{w}_j) \quad (17)$$

$$\overline{\mathbf{D}}_i = \frac{\sum_{j=1}^m \mathbf{D}_{i,j}}{m}, i, j = 1, 2, \dots, m \quad (18)$$

式中,  $\mathbf{D}_{i,j}$  为第  $i$  个和第  $j$  个 IC 特征向量间的欧氏距

离,  $\overline{D_i}$  表示第  $i$  个 IC 与其他 IC 相似距离的平均值。

通过 PIC 和 CICs 构造子空间  $H$ , CICs 是与 PIC 相似距离比较近的 IC, 选择相似距离大于平均值的 IC 作为 CICs, 定义一个  $m$  行  $m$  列的关联矩阵  $R$ , 其中第  $i$  个 IC 与第  $j$  个 IC 的相似距离小于平均值, 则关联矩阵  $R$  中的第  $i$  行第  $j$  列的元素为 1, 否则为 0, 公式表示为

$$\frac{D_{i,j}}{\overline{D_i}} < 1 \Rightarrow R_{i,j} = 1, \frac{D_{i,j}}{\overline{D_i}} \geq 1 \Rightarrow R_{i,j} = 0 \quad (19)$$

式中,  $R_{i,j}$  表示第  $i$  个和第  $j$  个载荷向量的相似性,  $R_{i,j} = 1$  时表示相似,  $R_{i,j} = 0$  时表示不相似。

通过 PIC 和关联矩阵  $R$  选择 CICs, 并构造子空间  $H$

$$R_{aj} = 1 \text{ 则 } S_j \in \text{CICs} \quad (20)$$

将变异特征信息集中在  $H$  里显现, 最后再计算当前的  $F^2$  统计量, 以及用核密度估计方法求其控制限, 并最终判断其是否超限。

2.2 基于 AICA 的故障检测方案

- 离线建模步骤如下。
- 1) 获得正常运行下的工况数据并进行预处理, 即用各变量均值和方差对数据进行标准化;
  - 2) 进行 ICA 分解, 解得独立成分  $S$  和分离矩阵  $W$ ;
  - 3) 通过分离矩阵求各 IC 特征向量间的欧氏距离;
  - 4) 构造相似距离矩阵  $D$ ;
  - 5) 利用相似距离矩阵  $D$  求得关联矩阵  $R$ 。

- 在线监测步骤如下。
- 1) 对在线数据的信息进行标准化;
  - 2) 将标准化后的在线数据转换到 IC 空间;
  - 3) 通过核密度估计法选出 PIC;
  - 4) 用关联矩阵  $R$  选出与 PIC 有相似特征向量的 CICs 构成  $H$ ;
  - 5) 求得  $F^2$  统计量和控制限并判断其是否超限。
- 相应的流程图如图 1 所示。

2.3 数值仿真

为了分析 AICA 的监测性能, 进行以下数值仿真过程。

$$V = \begin{bmatrix} v_1 \\ v_2 \\ v_3 \end{bmatrix} = \begin{bmatrix} 1.24 & 2.45 & 1.38 \\ 2.18 & 2.77 & 1.75 \\ 1.96 & 1.39 & 2.83 \end{bmatrix} \begin{bmatrix} \eta_1 \\ \eta_2 \\ \eta_3 \end{bmatrix} + \begin{bmatrix} e_1 \\ e_2 \\ e_3 \end{bmatrix}$$

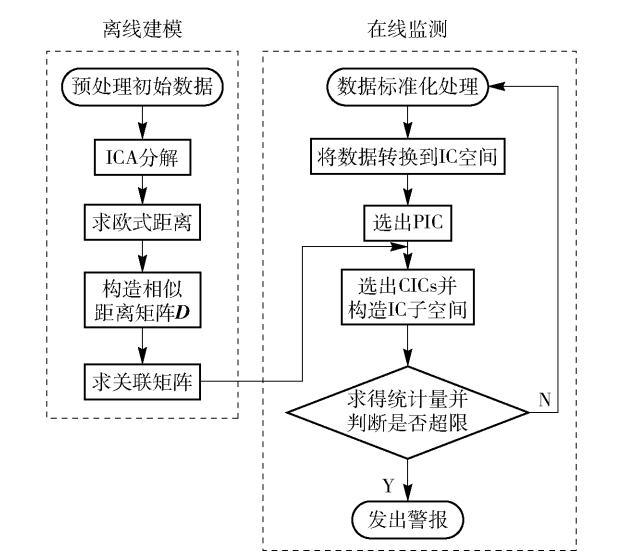


图 1 故障监测流程图  
Fig. 1 The fault detection process

式中,  $\eta, e$  是服从均值为 0、标准差为 1 的噪声信号,  $[x_1, x_2, \dots, x_7]^T = [V^T U^T]$  是 7 个测量变量。生成 200 个正常状态的样本以及 2 个故障, 并以此分析 AICA 方法的监测性能。

故障一 在 201 点时, 将一个 2.6 的阶跃故障引入变量  $x_2$  中, 同时将一个 1.38 的阶跃故障引入变量  $x_6$  中。

故障二 在 201 点时, 将一个大小为 3.5 的阶跃故障引入变量  $x_1$  中, 同时将一个大小为 0.03 ( $i - 200$ ) 的斜坡故障引入变量  $x_5$  中。

基于 ICA 与 AICA 的对于故障一、二的监测统计量效果如图 2、3 所示。由图可知 ICA 模型的  $F^2$




图 2 ICA 与 AICA 对于故障一的监测效果  
Fig. 2 Monitoring renderings of ICA and AICA for fault 1






图3 ICA与AICA对于故障二的监测效果

Fig. 3 Monitoring renderings of ICA and AICA for fault 2

统计量大部分在控制限以下,每个统计量对应的故障漏报率都很高,监测效果很差,而AICA模型在故障发生时能够迅速监测到故障信息,因此AICA的

监测效果相对要好得多。

### 3 田纳西-伊士曼仿真测试

#### 3.1 田纳西-伊士曼仿真平台

田纳西-伊士曼仿真平台简称TE仿真平台,是由美国Tennessee Eastman化学公司开发的具有挑战性和开放性的仿真测试平台,其本质是化工过程的仿真模拟,目前已被广泛应用于过程控制研究领域。TE平台由许多部分组成,包括产品冷凝器、气液分离器、反应器和压缩机等,整个过程中有12个控制变量和41个测量变量,本文选择其中33个变量作为检测变量,22个为测量变量,11个为控制变量。TE过程具体流程图如图4所示,故障说明如表1所示。

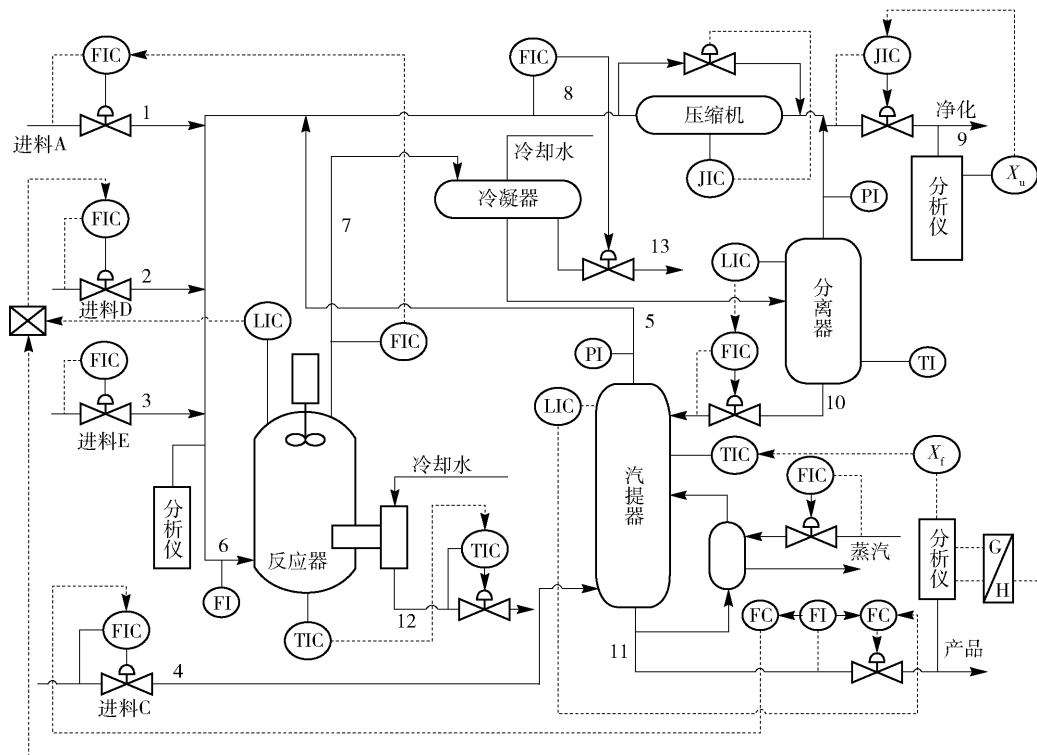


图4 TE工艺流程图

Fig. 4 TE process flow diagram

#### 3.2 TE仿真测试结果

采用正常工况下的960个数据样本建立AICA模型,并同时建立用于对比的ICA、自适应选择集成ICA(ASE-ICA)、集成改进ICA(EMICA)和MSE-ICA模型,其中ASE-ICA选择快速ICA(FastICA)算法保存相应的分离矩阵和ICs,并从中随机选择一些ICs构建模型<sup>[14]</sup>;EMICA利用由PCA模型导出的归一

化主成分作为初始点对ICs进行选择<sup>[16]</sup>;MSE-ICA利用FastICA算法对训练集进行变换,根据不同降维标准选择主要的IC,并将剩余IC作为主IC的附加子集<sup>[13]</sup>。运行后的仿真测试结果如图5、表2所示,其中故障11与故障21的监测结果对比如图6、7所示。

观察图5中AICA、ICA、ASE-ICA、EMICA和

表 1 TE 过程故障说明

Table 1 TE process failure description

编号	描述	变化类型	编号	描述	变化类型
1	A/C 进料比变化,B 组分不变	阶跃	12	冷凝堆冷却水入口温度变化	随机变量
2	B 组分变化,A/C 进料比不变	阶跃	13	反应动力学常数变化	慢漂移
3	D 进料温度变化	阶跃	14	反应堆冷却水阀门	黏滞
4	反应堆冷却水入口温度变化	阶跃	15	冷凝器冷却水阀门	黏滞
5	冷凝堆冷却水入口温度变化	阶跃	16	未知	未知
6	A 进料损失	阶跃	17	未知	未知
7	C 存在压力损失	阶跃	18	未知	未知
8	A、B、C 进料组分变化	随机变量	19	未知	未知
9	D 的温度变化	随机变量	20	未知	未知
10	C 的温度变化	随机变量	21	流 4 的阀门固定在稳态位置	恒定位置
11	反应堆冷却水入口温度变化	随机变量			




图 5 漏报率测试结果折线图

Fig. 5 Plot of missed detection ratios

MSE-ICA 5 种不同监测模型对故障监测得到的结果,对比表 2 中相应的统计量,可以很明显地发现 AICA 方法对故障检测的漏报率要优于其他方法,尤其是对故障 11、21,相较于 ICA 的漏报率 37.125%、47.375%,ASE-ICA 的漏报率 24%、40%,EMICA 的漏报率 20.5%、50.5% 以及 MSE-ICA 的漏报率 43.5%、53.62%,AICA 的漏报率只有 10.975%、30.75%。对比图 6、7,易知 AICA 方法的监测结果要明显好于 ICA 方法。显然,利用 AICA 方法进行过程监测的效果是要优于其他方法的。

表 2 漏报率测试结果

Table 2 Form of missed detection ratios

故障编号	$\hat{P}^{2a}) / \%$	$\hat{P}^{2b}) / \%$	$Q^{b}) / \%$	$\hat{P}^{2c}) / \%$	$\hat{P}^{2d}) / \%$	$Q^{d}) / \%$	$\hat{P}^{2e}) / \%$	$Q^{e}) / \%$
1	0	0.5	0.5	0	0.25	0.13	0.37	0.12
2	1	2	1.98	0.01	1.75	2	0.87	1.75
3	97.35	97.125	96.23	92	98	95	98.12	98.37
4	0	3	2.71	0	3.25	3.5	12.62	41.12
5	0	0	0	0	0	0	0	0
6	0	0	0	0	0	0	0	0
7	0	0	0	0	0	0	0	0
8	0.95	3.38	3.22	2	1.88	2.38	2.62	2.75
9	92.63	98.125	98	93	98.13	96.75	97.87	98.25
10	9.25	19.625	19.12	9	13.75	19.38	24.5	27.5
11	10.975	37.125	32.45	24	37.38	32	43.5	48.12
12	0.13	0.125	0.32	0	0.25	0.25	0.37	0.25
13	4.5	5.425	4.91	4	4.88	5.13	5.5	5.25
14	0	0.125	0.125	0	0.13	0	0	0.12
15	86.83	94.25	93.52	85	95.88	94.88	96.75	96.87
16	14.25	20.875	22.18	7	11.25	17.75	27.75	32.62
17	3.25	6.75	6	4	4.38	7.75	11.12	11.62
18	9.38	10.25	10.17	9	10	10.38	10.37	10.12
19	14.25	27.325	25.3	12	21	35.38	44.62	59
20	11.597	10.125	10.2	9	14.25	21.5	14.62	26.12
21	30.75	47.375	51.74	40	50.5	43.38	53.62	54.87

a—AICA;b—ICA;c—ASE-ICA;d—EMICA;e—MSE-ICA。




图6 故障11的ICA与AICA监测结果对比

Fig.6 Comparison of ICA and AICA monitoring results for fault 11




图7 故障21的ICA与AICA监测结果对比

Fig.7 Comparison of ICA and AICA monitoring results for fault 21

## 4 结论

本文所提出的 AICA 方法可以自适应地挑选变异特征明显的 PIC,再利用关联矩阵和 PIC 求得 CICs 并构造 IC 子空间。相较于其他方法,所提方法进一步集中变异特征信息,剔除冗余信息,减少了变异特征被淹没的风险;AICA 增加了挑选 IC 的稳定性,也使得最后的监测结果更为优良。

## 参考文献:

- [1] 姜庆超. 基于信息富集与特征选择的多元统计化工过程监测研究[D]. 上海: 华东理工大学, 2015.  
JIANG Q C. Some researches on beneficial information concentration and feature selection-based multivariate statistical chemical process monitoring[D]. Shanghai: East China University of Science and Technology, 2015. (in Chinese)
- [2] RASHID M M, YU J. A new dissimilarity method integrating multidimensional mutual information and inde-

pendent component analysis for non-Gaussian dynamic process monitoring[J]. Chemometrics and Intelligent Laboratory Systems, 2012, 115: 44–58.

- [3] 吕照民. 基于数据驱动子空间设计的间歇过程监测[D]. 上海: 华东理工大学, 2017.  
LV Z M. Batch process monitoring based on data-driven subspace design[D]. Shanghai: East China University of Science and Technology, 2017. (in Chinese)
- [4] TONG C D, LAN T, SHI X H. Double-layer ensemble monitoring of non-Gaussian processes using modified independent component analysis[J]. ISA Transactions, 2017, 68: 181–188.
- [5] LEE J M, YOO C K, LEE I B. Statistical process monitoring with independent component analysis[J]. Journal of Process Control, 2004, 14: 467–485.
- [6] BACK A D, WEIGEND A S. A first application of independent component analysis to extracting structure from stock returns[J]. International Journal of Neural Systems, 1997, 8(5): 473–484.
- [7] HYVÄRINEN A. Survey on independent component analysis[J]. Neural Computing Surveys, 1999, 2: 94–128.
- [8] WANG J C, ZHANG Y B, CAO H, et al. Dimension reduction method of independent component analysis for process monitoring based on minimum mean square error[J]. Journal of Process Control, 2012, 22: 477–487.
- [9] JIANG Q C, YAN X F. Non-Gaussian chemical process monitoring with adaptively weighted independent component analysis and its applications[J]. Journal of Process Control, 2013, 23: 1320–1331.
- [10] ZHANG Y W, ZHANG Y. Fault detection of non-Gaussian processes based on modified independent component analysis[J]. Chemical Engineering Science, 2010, 65(16): 4630–4639.
- [11] WANG B, YAN X F, JIANG Q C. Independent component analysis model utilizing de-mixing information for improved non-Gaussian process monitoring[J]. Computers & Industrial Engineering, 2016, 94: 188–200.
- [12] GE Z Q, SONG Z H. Performance-driven ensemble learning ICA model for improved non-Gaussian process monitoring[J]. Chemometric and Intelligent Laboratory Systems, 2013, 123: 1–8.
- [13] TONG C D, PALAZOGLU A, YAN X F. Improved ICA for process monitoring based on ensemble learning and Bayesian inference[J]. Chemometric and Intelligent Laboratory Systems, 2014, 135: 141–149.
- [14] LI Z C, YAN X F. Adaptive selective ensemble-inde-

- pendent component analysis models for process monitoring [J]. Industrial & Engineering Chemistry Research, 2018, 57(24): 8240–8252.
- [15] 祝元春, 于涛, 王建林, 等. 基于核独立成分分析的发酵过程在线监测方法[J]. 北京化工大学学报(自然科学版), 2014, 41(2): 81–86.
- ZHU Y C, YU T, WANG J L, et al. A fermentation process monitoring method based on kernel independent component analysis[J]. Journal of Beijing University of Chemical Technology (Natural Science), 2014, 41(2): 81–86. (in Chinese)
- [16] TONG C D, LAN T, SHI X H. Ensemble modified independent component analysis for enhanced non-Gaussian process monitoring [J]. Control Engineering Practice, 2017, 58: 34–41.

## Chemical process monitoring based on adaptive independent component analysis

LU TianChi<sup>1</sup> LV ZhaoMin<sup>2\*</sup>

(1. Department of Electronic and Electrical Engineering; 2. Department of Rail Transit, Shanghai University of Engineering Science, Shanghai 200336, China)

**Abstract:** In an effort to tackle the problem of how to select independent components (IC) in process monitoring when using independent component analysis (ICA), this paper proposes an adaptation independent component analysis (AICA) method. The AICA method first establishes a correlation matrix by using the separation matrix. The correlation matrix represents the similarities in IC. At the same time, the minimum probability density IC is selected as the particular independent component (PIC) by estimating the nuclear density. Then, by means of the correlation matrix, several common independent components (CICs) with similar variation characteristics to PIC are selected. Finally, PIC and CICs are used to construct monitoring statistics. The AICA method was applied in simulations of the Tennessee Eastman (TE) process. The test results show that the proposed method is an effective means of process monitoring.

**Key words:** process monitoring; independent component analysis; adaptive; select independent components; non-response ratio; false positives ratio

(责任编辑: 吴万玲)