文章编号:1000-8152(2010)03-0296-07

一种基于独立元贡献度的子空间故障检测方法

张沐光, 宋执环

(浙江大学工业控制研究所工业控制技术国家重点实验室,浙江杭州 310027)

摘要: 针对工业过程故障检测问题,本文定义了独立元贡献度和贡献度矩阵,提出一种改进的子空间检测算法. 首先,利用独立元分析(independent component analysis, ICA)算法提取过程变量的独立元信息,通过计算各个独立元 在过程变量上的贡献度,构造贡献度矩阵;然后根据贡献度的大小,挑选出对应的变量组成反映不同"源"信息的 子空间,并在这些子空间上建立故障检测模型;最后综合以上的多个检测模型,根据实际的需求或者故障的传播特 征,确定集成策略,对工业过程进行故障检测.通过在TE(Tennessee Eastman)过程上对21种故障工况和1种正常工况 的仿真研究,说明提出的改进算法是有效的.

关键词: 独立元分析; 子空间; 故障检测; 独立元贡献度 中图分类号: TP277 文献标识码: A

Subspace fault detection method based on independent component contribution

ZHANG Mu-guang, SONG Zhi-huan

(State Key Laboratory of Industrial Control Technology, Institute of Industrial Process Control, Zhejiang University, Hangzhou Zhejiang 310027, China)

Abstract: In order to handle the problem of fault detection for industrial processes, an improved subspace method is proposed based on the definitions of the independent component (IC) contribution and the contribution matrix. First, the appropriate independent components are extracted by independent component analysis(ICA), and then, the contributions of different independent components on the process variables are calculated to construct the contribution matrix. According to the contribution, a set of suitable subspaces, which can reflect different root causes, are constructed by corresponding variables. The fault detection models are established on these subspaces. Finally, combining all the above fault detection models and choosing the proper ensemble strategy based on the actual requirement or the spread characteristic of the faults, we make the ensemble decision for the fault detection of industrial processes. A case study on the Tennessee Eastman(TE) process for each mode (1 normal and 21 faulty) illustrates the effectiveness of the proposed method.

Key words: ICA; subspace; fault detection; IC contribution

1 引言(Introduction)

基于多元统计理论的过程监控和故障诊断技术 在工业界已经有了广泛的应用^[1~3],但是这些传统 的多元统计方法,如PCA,PLS都是假设测量数据服 从高斯分布,而实际的工业过程往往是不符合这一 假设的,其过程信息一般体现出非高斯信息和高斯 信息混合.因此,仅仅使用高斯信息来对过程进行 监控,往往不能有效地涵盖过程的重要信息,造成漏 报、误报等情况.

独立元分析(ICA)近年来受到了学术界的广泛 关注,由于利用了非高斯信息和高阶统计量,ICA方 法在信号处理^[4]、医学图像处理^[5]、人脸识别^[6]等领 域都已经得到成功应用.考虑到ICA的优良特性, 国外学者Kano^[7]等将ICA方法应用于化工过程监测 领域,取得了较好的效果.其他学者如Lee^[8,9]、葛志强^[10]等也提出了很多改进方法,但是现有的方法^[7~10]都是建立单个模型进行过程监测.考虑到统计量对于各个变量的解释程度不尽相同,对全部变量建立的统一控制限只能描述过程的整体特征,对于局部的刻画并不清楚,因此在某种程度上放宽了监测的控制限,导致了故障检测能力的下降;另一方面,受实际工业设备制约,故障往往主要体现在和故障源关联紧密的少数变量上,对于其他变量的影响比较微弱,因而具有"局部性"的特征.单模型方法是一种全局方法,仅关注变量的整体结构,对故障可能发生的方向没有更进一步的考察,实质上是丢失了细节信息.

本文在文献[8]的基础上,考虑监控过程的不同

收稿日期: 2009-01-18; 收修改稿日期: 2009-06-12.

基金项目:国家自然科学基金资助项目(60774067,60736021).

方向,提出一种基于独立元贡献度的子空间故障检测算法,并给出了构造子空间的准则.通过在子空间上检测故障,克服了普通ICA算法在整个变量空间上建模容易掩盖微小异常信息的弱点,体现了过程的局部特征,使得监测模型可以包含更多的细节信息,构造更紧凑的控制限,从而对过程给出了更精确的描述.同时,本文也给出了一种灵活的集成策略,可以根据实际的需求或者故障的传播特征选择合适的策略,提高故障检测的性能.

2 基于IC贡献度的子空间构造(Subspace construction based on IC contribution)

对于实际工业过程, 原始过程变量矩阵 $X = [\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \cdots, \mathbf{x}_n]^{\mathrm{T}}$ 是通过工业设备中不同位置的 传感器记录得到的, 而这些数据可以被认为是由某 些与工业过程所对应的内在成分 $\mathbf{s}_1, \mathbf{s}_2, \mathbf{s}_3, \cdots, \mathbf{s}_m$ 混合产生的. 对这些内在成分做进一步的考察和 分析,可以帮助笔者更好地了解过程的内在变化, 及时的发现故障. 因此,与普通ICA在整个变量空 间 ψ 上建模不同,笔者考虑在 ψ 的基础上,针对过 程的内在成分,构造与其一一对应的若干个子空 间 $\Phi_1, \Phi_2, \Phi_3, \cdots, \Phi_m$,通过在子空间上观察过程,笔 者可以了解各个内在成分的表现,从而可以对整个 过程有更细致的刻画. 如图1所示,其中 $\hat{\psi}$ 和 $\hat{\psi}$ 分别代 表全局模型上的独立元空间和残差空间, $\hat{\Phi}_j$ 代表局 部模型上的独立元空间. 在整个变量空间上建立的 模型因为要考虑变量的各个方向,给出的控制限实 际上是较为宽松的;而在各个子空间上建立的模型 对局部的描述显然比整体模型更加细致. 通过这种 局部、多模型的方法,笔者增加了对过程的了解,从 而提高了监测效果.



图 1 单模型方法和子空间方法的比较 Fig. 1 Comparison of single model method and subspace method

要建立合理的子空间检测模型,关键是保证构造出来的子空间的差异性和有效性,差异性要求各个子空间之间的差别要大,这样才能更好的反映不同方面的信息,减少冗余;有效性要求各个子空间要包含足够的信息,才可以保证子空间检测模型能够反映各个内在成分的特征和变化.

独立元(IC)是过程的内在成分,反映了过程的 非高斯特征,整个过程信息可以看作是独立元的 线性组合.同时,独立元彼此之间又是统计独立的. 基于独立元的这些特性,我们考虑构造一个指标 量,用来衡量独立元在各个变量上的贡献度,并以 此作为构造子空间的依据,可以较好的保证子空 间的差异性和有效性.

2.1 ICA监测算法(ICA monitoring method)

假设过程变量 $X = [x_1, x_2, x_3, \cdots, x_n]^T$ 含有 $m(m \leq n)$ 个独立成份 $s_1, s_2, s_3, \cdots, s_m$,那么该过 程变量矩阵可以表示为

$$X = AS + E. \tag{1}$$

其中: A是混合矩阵, $S = [s_1, s_2, s_3, \cdots, s_m]^T$ 代表 了过程的独立元信息, E是残差矩阵.本文采用 的是快速不动点ICA算法(详细算法参见文献[11]). 提取出合适的独立元之后,针对S和E,根据文 献[8]分别建立 I^2 , SPE统计量,并通过核密度估计 的方法^[12]确定其对应的置信限,就可以对过程进 行监测.

2.2 IC贡献度和贡献度矩阵(IC contribution and contribution matrix)

定义1 设混合矩阵
$$A = \begin{pmatrix} a_{11} \cdots a_{1m} \\ \vdots & \vdots \\ a_{n1} \cdots & a_{nm} \end{pmatrix}$$
, 并且变量 \boldsymbol{x}_i 可以表示为

$$\boldsymbol{x}_{i} = a_{i1} \times \boldsymbol{s}_{1} + a_{i2} \times \boldsymbol{s}_{2} + a_{i3} \times \boldsymbol{s}_{3} + \cdots + a_{im} \times \boldsymbol{s}_{m}, \ i = 1, \cdots, n,$$
(2)

则定义独立元 s_i 在变量 x_i 上的贡献度为

$$\begin{cases} \eta_{ij} = \frac{|a_{ij}|}{|a_{i1}| + |a_{i2}| + \dots + |a_{im}|}, \\ \text{s.t. } 0 \leqslant \eta_{ij} \leqslant 1, \\ i = 1, \dots, n, \ j = 1, \dots, m. \end{cases}$$
(3)

定义 2 由定义1,对于整个过程变量 $x_1, x_2, x_3, \dots, x_n,$ 定义贡献度矩阵如下:

$$\boldsymbol{\eta} = \begin{pmatrix} \eta_{11} \cdots \eta_{1m} \\ \vdots & \vdots \\ \eta_{n1} \cdots \eta_{nm} \end{pmatrix}.$$
 (4)

 η_{ij} 越大,说明独立元 s_j 对变量 x_i 的贡献越大,则该变量可以更好的体现独立元 s_j 的特征信息.显然,使用这样的变量 x_i 用于建模,会更好的体现内在成分 s_j 的变化,使笔者可以有针对性的了解过程的局部变化,提高检测效果.同时, η 矩阵也为挑选子空间变量确定了很好的标准.如前文所述,构造子空间的原则是要保证子空间的差异性和有效性,由独立元的性质可知, $s_1, s_2, s_3, \dots, s_m$ 彼此是独立的,他们彼此之间的差别最大;同时,独立元是整个过程的"源"信息,过程变量是独立元

的线性组合.因此,在构造子空间的时候,应该让 不同的子空间尽可能体现出不同独立元的特征, 这样不仅可以实现各个子空间上较大的差异性, 而且可以保证每个子空间的有效性.

2.3 子空间构造算法(Subspace construction algorithm)

由以上分析,构造子空间*Φ*_i如下:

 $设\eta_{1j}, \eta_{2j}, \eta_{3j}, \dots, \eta_{nj}, j = 1, \dots, m$ 是贡献 度矩阵 η 中的一列, 可知这一列反映了第j个独 立元 s_j 在所有变量 $x_1, x_2, x_3, \dots, x_n$ 上的贡献, 根 据 η_{ij} 值的大小, 找出最大的K个元素. 设为

$$\eta_{h_1j} > \eta_{h_2j} > \eta_{h_3j} \cdots \eta_{h_Kj},$$

s.t. $j = 1, \cdots, m, h_K \subset 1, 2, \cdots, n.$ (5)

则使用变量 $\boldsymbol{x}_{h_1}, \boldsymbol{x}_{h_2}, \boldsymbol{x}_{h_3}, \cdots, \boldsymbol{x}_{h_K}$ 建立第j个子空间模型 $\boldsymbol{\Phi}_j$.

具体的算法流程图参见图2, 通过以上的算法, 把原始的变量空间, 构造成为m个子空间 $\phi_1, \phi_2, \phi_3, \dots, \phi_m$. 通过上述方法构造的子空间, 分别对 应过程的各个内在成分. 由于这些内在成分(IC)是 相互独立的, 因此子空间 $\phi_1, \phi_2, \phi_3, \dots, \phi_m$ 之间 也具有较好的差异性, 减少了冗余; 同时, 每一个 子空间都针对内在成分而构建, 因此包含有足够 的信息, 可以体现过程的内在变化, 保证了检测模 型的有效性.



Fig. 2 Subspace construction algorithm

3 子空间故障检测算法(Subspace fault detection method)

常见的工业过程故障检测方法,如PCA, KPCA^[13], ICA^[7,8], KICA^[9], 以及一些相关的改进 算法^[10], 都是使用全部过程变量,建立单个模型 来进行检测, 然而,考虑到一些微小故障,可能只 是表现在部分过程变量上,使用全部样本建模会 "淹没"这些单个变量上的异常信息,导致较低 的检测率.本文提出的子空间检测算法,在不同的 变量空间上,建立多个模型,共同检测工业过程, 体现了局部变量上的变化,提高了检测效果.可以 认为,传统的ICA方法是一种全局的、单模型的检 测方法,考虑故障在整个变量空间上的表现;而本 文提出的方法是一种局部的、多模型的检测方法, 考虑故障在各个独立元空间上的不同表现.

3.1 集成策略的设计(Ensemble strategy design)

由第2节可知, 把原始的变量空间构造为m个 子空间, 在m个空间上, 使用第2节介绍的ICA 过 程检测方法, 分别建立m个ICA检测模型. 设1代 表正常工况, -1代表异常工况, 得到m组检测结 果 $y_1, y_2, y_3, \dots, y_m, y_i \in (1, -1), 1 \leq i \leq m.$

容易理解,对于某些明显的故障,其故障信息 在独立元上的表现应该会比较明显,而且可能会 影响多个独立元,而那些比较微小的故障,可能 只影响少数甚至单个独立元,而且其表现也并不 明显.因此,在构建的m个子空间模型上,明显的 故障会被多个子空间模型检测到,同时其统计量 超过得置信限的幅度会比较明显;而微小的故障 只能被少数的子空间模型检测到,同时其统计量 超限的幅度会比较小.基于以上考虑,为了集成 这m个检测结果,确定集成策略如下,即

$$\varphi(x) = \begin{cases}
-1, \ \text{ym} \ \mathbb{R}(\text{find}(Y) = -1) \ge l, \\
1, \ \text{zte.} \\
\text{s.t.} \ Y = [y_1, y_2, y_3 \cdots y_m], \ y_i \subset (1, -1), \\
1 \le i \le m, \ 1 \le l \le m.
\end{cases}$$
(6)

其中*l*是人为设定值,上述策略表明,当有*l*,1 ≤ *l* ≤ *m*个子空间模型检测到故障发生,就认为故障发生.通过选取不同的*l*值,就可以使集成策略从激进变化到平衡,再到保守,这种变化的集成策略具有较好的灵活性和适应性.

3.2 集成策略的选取(Ensemble strategy selection)

在实际的工业过程监测中,可以根据实际的需 求,选取不同的策略.比如强调故障的检测率时, 可以使用激进策略,这样会对故障比较敏感;如 果希望达到各方面的平衡,可以使用平衡策略,如 果仅仅希望检测大的故障,可以使用保守策略.同 时,策略的选取还应该考虑实际故障的传播特征. 由于故障的传播是受实际工业设备所限制的,一 般来说,随着故障的传播,其表现会慢慢降低,因 此远离故障源的传感器节点上,故障的表现会比 较微弱.因此,即使是很明显的故障,也可能只在 少数几个子空间上有明显的表现.所以,选取过 大的/值会导致检测性能的急剧恶化,也不符合实 际的工业背景.整个检测算法的步骤可以归结为 以下的几步,其中Step 1到Step 4是离线建模过程, Step 5到Step 8是在线检测过程:

Step 1 通过正常工况数据,提取合适的独立 元成分.

Step 2 根据提取的独立元成分,求出贡献度 矩阵,选择合适的子空间样本数目*K*,构造子空间.

Step 3 在每个子空间上,建立ICA检测模型,构造*I*²、SPE统计量,并确定合适的置信限.

Step 4 根据实际要求,选取合适的集成策略.

Step 5 收集实时过程检测数据并进行归一 化处理.

Step 6 在不同的子空间上,提取实时检测数据的独立成分和残差计算出其统计量的数值.

Step 7 检测各个子空间上,统计量有没有超过各自得置信限.

Step 8 根据选取得集成策略,集成检测结果.

3.3 算法实时性分析(Method real-time performance analysis)

工业实际要求故障检测方法要尽可能快速的 发现故障,因此对算法的实时性提出了较高的要 求.本文提出的基于IC贡献度的子空间故障检测 方法,主要由离线建模过程和在线检测过程两个 步骤组成,其中建模过程由于是离线的,因此对检 测算法的实时性没有影响,本文算法的实时性主 要由在线检测部分的时间复杂度决定.假设采样 点为 $x \in \mathbb{R}^{n \times 1}$,提取出的独立元个数为m,则分离 矩阵为 $W_{ICA} \in \mathbb{R}^{m \times n}$,设 $n/m = \alpha$,对于每个待检 测样本,普通ICA方法在线检测部分所需的操作次 数为

 $OT_{ICA} = nm + n + m = \alpha m^2 + \alpha m + m, \quad (7)$

则其时间复杂度为

$$T_{\rm ICA} = \mathcal{O}(\alpha m^2). \tag{8}$$

第27卷

假设每个子空间包含p个变量,提取出的独立元 个数为q,则子空间上的分离矩阵为 $W_{\text{IC-subspace}} \in \mathbb{R}^{q \times p}$,设 $p/q = \beta$,本文方法在线检测部分所需的操作次数为

$$OT_{\text{IC-subspace}} = m(pq + p + q) = m(\beta q^2 + \beta q + q),$$
(9)

则时间复杂度为

$$T_{\rm IC-subspace} = O(m\beta q^2).$$
 (10)

比较两种算法的时间复杂度,可以得到

$$\lambda = \frac{T_{\text{IC-subspace}}}{T_{\text{ICA}}} = \frac{\mathcal{O}(m\beta q^2)}{\mathcal{O}(\alpha m^2)} = \frac{\beta}{\alpha} \times \frac{q^2}{m}.$$
 (11)

其中: α , β 分别表示了ICA算法在整个变量空间和 各个子空间上的降维程度, 它们的值一般是比较 接近的. 易知, 当 $\lambda < 1$ 时, 本文算法的实时性要好 于普通ICA算法. 同时, 由于q代表p个变量中的独 立元个数, 且有 $q \leq p$. 因此, 通过选择适当的子空 间维数, 可以控制q的大小, 从而有效的提高算法 的实时性, 并使其优于普通ICA算法; 另一方面, 由 于构造子空间的变量是根据IC贡献度挑选的, 贡 献度高的变量会被优先挑选, 因此即使减少了子 空间维数, 重要的变量依然会被包括, 从而保证了 子空间的有效性和差异性.

4 仿真(Simulation)

Tennessee Eastman(TE)过程是由Downs和Vogel 在1993年根据Eastman化学公司的一个实际化工 联合反应过程建立的一个标准测试平台, TE模型 包含了30个微分方程,148个代数方程,其数据具 有非线性,强耦合,时变等特点,是典型的复杂工 业过程^[1]. TE模型具有6种操作模式, 12个操作变 量和41个测量变量,并且可以人工设定21种故障 工况,本文采用的数据来源于Washington大学提供 的操作模式3,选取33个变量作为过程检测变量. 采集正常工况下的960个样本作为训练集,960个 样本作为测试集,采集故障数据时,先让系统运行 在正常状态,故障在第160个采样点加入,每个故 障采集960个样本作为测试集. 首先对正常工况 数据进行处理,提取独立元个数为9个,选取贡献 度最大的10个变量,建立9个子空间检测模型,子 空间上提取独立元个数为3个.所取得置信限都 是99%. 通过上文的分析可知, 此时 $\beta/\alpha = 10/11$, $q^2/m = 1, \lambda < 1.$ 因此本文算法的实时性要好于 普通ICA算法. 首先对一些故障进行测试, 以确定 合适的集成策略.

通过图3可以看出,对于TE过程,随着l值的增 大,故障的检测效果在不断恶化.同时,注意到,对 于不同的故障,都有一个临界值,一旦l值超过该 临界值,检测效果就会出现了急剧的恶化.如故 障5,7,当选取l = 3时,检测率有一个很明显的下 降;这说明该故障只在2个独立元子空间上有明显 的表现.同时,对于正常工况,l的变化对其结果 影响很小,当l = 1时,其检测效果已经相当满意; 当l = 2时,检测效果已经达到100%.基于以上的 结果,选取l = 1的激进策略作为集成方法,对21 种故障工况和1种正常工况进行检测.表1列出了 对故障工况的检测结果(对故障工况的检测率), 表2列出了对正常工况的检测结果(对正常工况的 误报率).





Fig. 3 Detection rates of different strategy in the TE process

可以从表1看到,本文方法对几乎所有故障的 检测率都有了比较明显的提高,对于故障3,9,15, 普通ICA方法可以说几乎检测不到故障,但是本文 方法均有10%左右的检测率,检测率仍然不高,说 明该故障在所有的独立元子空间上表象都不明显, 因此即使在子空间上观察故障,仍然不能得到满 意的效果.对于一些较难检测的故障,如故障11, 19,21,本文方法相对普通ICA,有了很大的提高, 说明这些故障只在某些独立元子空间有明显表现, 因此,通过在各个独立元子空间上观察,可以更明 显的发现故障;对于一些比较容易检测的故障,如 故障2,7,8,普通ICA已经可以达到比较高的检测 率,说明这个故障在整个变量空间上都有很明显 的表现,但是在各个独立元子空间上观察故障,还 是可以对检测率作进一步的提高.

表1	TE过程上ICA算法和独立元子空间算法
	的检测率

Table 1Fault detection rates(%) of ICA method
and that of IC-subspace method
in the TE process

	IC	CA	独立元子空间算法			
议障 上优	I^2	SPE	I^2	SPE		
1	99.75	99.50	99.75	99.88		
2	96.88	98.00	98.50	98.75		
3	0	4.75	8.62	7.75		
4	17.50	95.50	100	99.88		
5	100	100	100	100		
6	100	100	100	100		
7	96.38	100	100	100		
8	92.00	97.62	98.12	98.25		
9	0	6.75	10.25	12.25		
10	73.88	76.50	85.75	84.25		
11	38.00	60.88	86.88	79.13		
12	99.75	99.75	99.88	99.75		
13	94.75	94.37	95.63	95.37		
14	99.88	100	100	100		
15	0.13	6.75	12.75	15.75		
16	73.75	73.25	88.62	86.50		
17	88.38	91.87	97.00	96.13		
18	89.38	90.87	90.87	91.75		
19	15.13	39.50	74.88	87.50		
20	65.87	76.75	89.00	77.75		
21	36.00	45.00	61.75	54.63		

表2说明了本文方法在采取的激进策略时,并 没有牺牲对正常工况的监测性能.其误报率略有 提高的原因是:和普通ICA方法相比,本文方法更 好的描述了细节,因此对"正常工况"提出了更 高的要求,即采样数据不仅要在整体上表现正常, 在各个独立元子空间上也要表现正常.而在实际 过程中,正常工况的采样数据中往往也包含一些 小的波动,这些小的波动在整个变量空间上没有 什么反映,但是却会表现在某些独立元子空间上, 并被本文方法检测到.

图4显示了普通ICA对故障4的检测效果,可以 发现统计量对故障的检测效果很差,统计量也存 在少数漏报的情况.图5~8显示了本文方法中第4, 7,5,9个独立元子空间对故障4的检测效果,可以发 现,在第4和第7个独立元子空间上,故障4的表现 非常明显,而在第5和第9个独立元子空间上,故 障4几乎检测不到.表3列出了所有独立元子空间 对故障4的检测效果,通过该表,可以发现,正如我 们前面叙述的那样,故障4只在某些独立元子空间 (如4,7)上有明显的表现,而在其他独立元子空 间(如5,9)上几乎没有表现,因此,普通ICA方法使 用全部变量空间建模,以至于那些对故障4没有表现的子空间影响了有效的子空间,掩盖了异常信息,导致了较差的检测效果(*I*²统计量检测效果的急剧恶化和SPE统计量检测效果的下降).

- 表 2 正常工况下ICA算法和独立元子空间 算法的误报率
- Table 2False alarm rates(%) of ICA method and
that of IC-subspace method on normal
operating mode



表 3 各个独立元子空间对故障4的检测率 Table 3 Fault detection rates(%) of each IC-subspace for fault 4

IC-subspace for fault 4										
(子)1 日	子空间索引									
统计重	1	2	3	4	5	6	7	8	9	
I^2	1.375	0.25	2.875	100	0	80.25	100	0.125	0.25	
SPE	1.375	1.375	2.00	96.75	1.875	99.25	98.12	1.25	0.75	
SPE I^2	$ \begin{array}{c} 150 \\ 100 \\ 50 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ $			1 400 1 400 400 **		o :	800 800	1000 1000		
	11.45.84									

图 5 故障4在独立元子空间4上的仿真结果 Fig. 5 Simulation of fault 4 in IC-subspace 4





5 结论(Conclusion)

本文提出一种基于IC贡献度的子空间算法,用 于过程检测,针对普通ICA检测方法仅在整个变 量空间上检测故障的弱点,本文方法定义了IC贡 献度指标,通过衡量原始变量空间不同独立元在 不同变量上的贡献度,从原始的变量空间,构造出 若干个独立元子空间.通过在各个独立元子空间 上观察故障,可以更细致的刻画整个过程,体现 故障发生时过程内在成分的变化,从而提高检测效果.同时,本文也给出了一种灵活的集成策略, 用来得到最终的检测结果.通过在Tennessee Eastman(TE)模型上对21种故障和正常工况的仿真研 究,说明了本文算法的有效性.同时,本文算法并 不局限于故障识别,还可以用于故障分类和故障 隔离.

参考文献(References):

- CHIANG L H, RUSSELL E L, BRAATZ R D. Fault Detection and Diagnosis in Industry System[M]. London: Springer-Verlag, 2001.
- [2] RUMANA S, SIRISH L S, UTTANDARAMAN S. A PCA based fault detection scheme for an industrial high pressure polyethylene reactor[J]. *Macromolecular Reaction Engineering*, 2008, 2(1): 12 – 30.
- [3] LIU X Q, XIE L, KRUGER U, et al. Statistical-based monitoring of multivariate non-Gaussian systems[J]. AIChE Journal, 2008, 54(9): 2379 – 2391.
- [4] HERAULT J, JUTTEN J. Space or time adaptive signal processing by neural network models[C] //Proceedings of Neural Networks for Computing: AIP Conference. Woodbury, NY, USA: American Institute of Physics Inc, 1986: 206 – 211.
- [5] MCKEOWN M J, SEJNOWSKI T J. Independent component analysis of FMRI data: examining the assumptions[J]. *Human Brain Mapping*, 1998, 6(5/6): 368 – 372.
- [6] BARTLETT M S, LADES H M, SEJNOWSKI T J. Face recognition by independent component analysis[J]. *Neural Networks*, 2002, 13(6): 1450 – 1464.
- [7] KANO M, TANAKA S, HASHIMOTO I, et al. Monitoring independent component for fault detection[J]. *AIChE Journal*, 2003, 49(4): 969 – 976.
- [8] 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.
- [9] LEE J M, QIN S J, LEE I B. Fault detection of non-linear processes using kernel independent component analysis[J]. *The Canadian Journal of Chemical Engineering*, 2007, 85(8): 526 – 536.
- [10] GE Z Q, SONG Z H. Process monitoring based on independent component analysis-principal component analysis (ICA-PCA) and similarity factors[J]. *Industrial & Engineering Chemistry Research*, 2007, 46(7): 2054 – 2063.
- [11] HYVARIEN A, OJA E. Independent component analysis: algorithms and application[J]. *Neural Network*, 2000, 13(4/5): 411 – 430.
- [12] CHEN Q, WYNNE R J, GOULDING P, et al. The application of principal component analysis and kernel density estimation to enhance process monitoring[J]. *Control Engineering Practice*, 2000, 8(5): 531 – 543.
- [13] CHOI S W, LEE C, LEE J M, et al. Fault detection and identification of nonlinear processes based on KPCA[J]. *Chemometrics and Intelligent Laboratory Systems*, 2005, 75(1): 55 – 67.

作者简介:

张沐光 (1983—), 男, 博士研究生, 目前研究方向为过程监测

与故障诊断技术, E-mail: mgzhang@iipc.zju.edu.cn;

宋执环 (1962—), 男, 教授, 目前研究方向为基于数据驱动技 术的复杂工业过程建模、控制与故障诊断, E-mail: zhsong@iipc.zju. edu.cn.