

# 基于指定元分析的多故障诊断方法

周福娜<sup>1,2</sup> 文成林<sup>3</sup> 汤天浩<sup>1</sup> 陈志国<sup>2</sup>

**摘要** 为了克服传统主元分析 (Principal component analysis, PCA) 因模式复合现象而无法进行多故障诊断和诊断结果难以解释的不足, 本文引入指定元分析 (Designated component analysis, DCA) 的思想, 建立 DCA 多故障诊断理论的空间投影框架, 从而把异常检测问题转化为将观测数据向故障子空间投影后投影能量的显著性检测问题. 在确定系统存在异常的情况下, 再将观测数据向故障子空间中各故障模式方向分别进行投影, 根据投影能量的显著性进行多故障诊断. 并利用正交补空间构造法证明了基于非正交模式指定元分解形式的可行性和收敛性, 建立了一种逐步 DCA 多故障诊断方法以解决指定模式非正交情况下的多故障诊断问题. 包含 5 种共存故障的观测数据的仿真研究验证了新方法的有效性.

**关键词** 投影框架, 非正交模式, 多故障诊断, 指定元分析, 主元分析  
**中图分类号** TP273.5

## DCA Based Multiple Faults Diagnosis Method

ZHOU Fu-Na<sup>1,2</sup> WEN Cheng-Lin<sup>3</sup> TANG Tian-Hao<sup>1</sup> CHEN Zhi-Guo<sup>2</sup>

**Abstract** As it can avoid pattern compounding problem of principal component analysis (PCA), designated component analysis (DCA) is introduced to implement multiple faults diagnosis of a multivariate system. A projection frame, which is the theory foundation for DCA based multiple faults diagnosis, is established in this paper. Under the DCA projection frame, anomaly detection and fault diagnosis problem is transformed into the significance detection problem for projection energy of the observation data projected to fault subspace spanned by fault patterns defined in advance. Then, for the case when designated patterns are not orthogonal to each other, a progressive DCA diagnosis method is developed by grouping the designated patterns into several orthogonal subgroups to the observation data or the residual of the previous DCA process. Simulation for data involved 5 faults shows the efficiency of the progressive DCA method for multiple faults diagnosis.

**Key words** Projection frame, non-orthogonal variation pattern, multiple faults diagnosis, designated component analysis (DCA), principal component analysis (PCA)

大型自动化系统的结构越来越复杂, 自动化程度越来越高, 一处故障可能导致停机停产, 甚至会造成机毁人亡的灾难性事件. 因此, 故障诊断方法的研究吸引了工程和学术领域众多专家的广泛关注<sup>[1-2]</sup>.

现有的故障诊断方法大体上可以分为 3 类: 基于定量模型的方法<sup>[1,3-5]</sup>, 基于定性模型的方法<sup>[1,6]</sup> 和基于过程历史的方法 (也称数据驱动的方法)<sup>[2,7-11]</sup>. 数据驱动的方法基于数据提取系统状态的有用信息进行异常监控, 无需系统或故障的准

确机理模型, 从而可以有效解决现代大型系统面临的数据丰富、信息匮乏问题<sup>[2]</sup>.

常用的数据驱动故障诊断方法包括专家系统 (Expert system, ES) 法、人工神经网络 (Artificial neural network, ANN) 法和基于统计的方法等<sup>[1-2]</sup>. ES 法缺少学习机制, 推理的效率比较低, 而且处理问题的能力至多是知识库中知识的总和, 限制了其在实际运用中的灵活性. ANN 法具有大规模并行处理和自适应学习能力, 但 ANN 是一种黑箱建模方法, 推理诊断过程不透明<sup>[10]</sup>.

数据驱动的异常监控算法中, 研究和应用最多的是多变量统计方法. 其中的主流方法是主元分析 (Principal component analysis, PCA) 和部分最小二乘. 主元分析及其有关改进和扩展的方法, 包括动态主元分析、自适应主元分析、多尺度主元分析、分块主元分析、相对主元分析和非线性主元分析等都已成功应用到异常监控和故障诊断中<sup>[1,7-9,11-12]</sup>.

文献 [13] 将统计建模与系统实际运行经验相结合, 提出了指定元分析 (Designated component analysis, DCA) 的思想. 不同于 PCA 中将观测数据向载荷向量上投影的方法, DCA 将观测数据投影

收稿日期 2008-09-08 收修改稿日期 2008-11-26  
Received September 8, 2008; in revised form November 26, 2008  
国家自然科学基金 (60804026, 60572051), 浙江省国际合作重点项目 (2006C24G2040012), 上海市教委重点学科 (J50602) 资助  
Supported by National Natural Science Foundation of China (60804026, 60572051), International Cooperation Project of Zhejiang (2006C24G2040012), and Key Disciplines of Shanghai Municipality (J50602)  
1. 上海海事大学电气自动化系 上海 200135 2. 河南大学先进控制与智能信息处理研究所 开封 475004 3. 杭州电子科技大学信息与控制研究所 杭州 310018  
1. Department of Electrical Automation, Shanghai Maritime University, Shanghai 200135 2. Institute of Advanced Control and Intelligent Information Processing, Henan University, Kaifeng 475004 3. Institute of Information and Control, Hangzhou Dianzi University, Hangzhou 310018  
DOI: 10.3724/SP.J.1004.2009.00971

到有明确物理意义的指定模式上得到指定元. 从而可以克服 PCA 的模式复合效应, 解决故障模式的物理意义不明确且不能进行多故障诊断的不足<sup>[13]</sup>. 但是现有的 DCA 故障诊断方法假设各指定模式相互正交, 且 DCA 理论的基础研究也需进一步开展. 本文旨在建立 DCA 的空间投影框架, 进一步完善 DCA 故障诊断理论, 给出有关推证过程, 并解决非正交指定模式的 DCA 诊断问题.

本文内容安排如下: 第 1 节和第 2 节分别介绍基于 PCA 和 DCA 的故障诊断思想及各自的优缺点; 第 3 节建立多变量系统的 DCA 空间投影框架, 并给出有关推证; 第 4 节针对非正交指定模式的处理问题, 证明了基于非正交指定模式 DCA 分解的可行性和收敛性, 并在此基础上给出了一种逐步 DCA 多故障诊断方法; 第 5 节对包含 5 种共存故障的观测数据, 给出了逐步 DCA 多故障诊断方法的仿真结果; 第 6 节是本文的结论和展望.

### 1 基于 PCA 的故障诊断

#### 1.1 基于 PCA 的异常检测

PCA 的目的是把  $p$  个相关的观测变量  $y_1, y_2, \dots, y_p$  变换成  $p$  个不相关的变量  $v_1, v_2, \dots, v_p$ , 变换过程由下式定义<sup>[14-15]</sup>

$$\begin{bmatrix} v_1 \\ v_2 \\ \vdots \\ v_p \end{bmatrix} = \begin{bmatrix} b_{11} & b_{21} & \cdots & b_{p1} \\ b_{12} & b_{22} & \cdots & b_{p2} \\ \vdots & \vdots & \ddots & \vdots \\ b_{1p} & b_{2p} & \cdots & b_{pp} \end{bmatrix}^T \begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_p \end{bmatrix} \quad (1)$$

主元  $v_i$  是多元变量  $\mathbf{y}$  在载荷向量  $\mathbf{b}_i$  上的投影, 即

$$v_i = \mathbf{b}_i^T \mathbf{y} \quad (2)$$

其中,  $\mathbf{b}_i = [b_{i1} \ b_{i2} \ \cdots \ b_{ip}]^T$  为多维随机变量  $\mathbf{y}$  的协方差矩阵  $\Sigma_Y$  的标准化特征向量. 式 (2) 取  $n$  个采样后的形式为

$$[v_{i1}, v_{i2}, \dots, v_{in}] = [b_{i1}, b_{i2}, \dots, b_{ip}] \begin{bmatrix} y_{11} & y_{12} & \cdots & y_{1n} \\ y_{21} & y_{22} & \cdots & y_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ y_{p1} & y_{p2} & \cdots & y_{pn} \end{bmatrix} \quad (3)$$

对所有  $i = 1, 2, \dots, p$ , 式 (3) 可简写为

$$V = B^T Y \quad (4)$$

其中,  $Y = [\mathbf{y}(1) \ \mathbf{y}(2) \ \cdots \ \mathbf{y}(n)] \in \mathbf{R}^{p \times n}$ ,  $\mathbf{y}(j)$  ( $j = 1, 2, \dots, n$ ) 是  $p$  维随机变量  $\mathbf{y} = [y_1 \ y_2 \ \cdots \ y_p]^T$

$\in \mathbf{R}^{p \times 1}$  的  $n$  次观测样本;  $V \in \mathbf{R}^{p \times n}$  是主元变量  $\mathbf{v} = [v_1 \ v_2 \ \cdots \ v_p]^T \in \mathbf{R}^{p \times 1}$  的  $n$  次观测样本.

由  $B$  是标准正交矩阵知

$$Y = BV \quad (5)$$

从而观测矩阵  $Y$  具有如下主元分解式

$$Y = \sum_{i=1}^p \mathbf{b}_i \mathbf{v}_i = \sum_{i=1}^k \mathbf{b}_i \mathbf{v}_i + E \quad (6)$$

其中

$$E = \sum_{i=k+1}^p \mathbf{b}_i \mathbf{v}_i \quad (7)$$

是分解的残差矩阵,  $k$  是关键主元的个数.

**定理 1.** 观测数据阵基于主元的分解式 (6) 中, 当  $k \rightarrow p$  时, 残差阵  $E \rightarrow 0$ .

**证明.** 由于矩阵各范数之间是等价的, 不失一般性, 采用 Frobenius 范数<sup>[16]</sup>

$$\|E\|_F^2 = \sum_{i=1}^p \sum_{j=1}^n |e_{ij}|^2 \quad (8)$$

由  $B$  是标准正交矩阵知

$$\mathbf{b}_i^T \mathbf{b}_q = \begin{cases} 1, & i = q \\ 0, & i \neq q \end{cases}$$

$$\sum_{i=1}^p \mathbf{b}_i \mathbf{b}_i^T = I \quad (9)$$

$$\mathbf{b}_i \mathbf{b}_i^T \leq I \quad (10)$$

$$EE^T = \sum_{i=k+1}^p \mathbf{b}_i \mathbf{v}_i \left( \sum_{i=k+1}^p \mathbf{b}_i \mathbf{v}_i \right)^T = \sum_{i=k+1}^p \text{var}(v_i) \mathbf{b}_i \mathbf{b}_i^T \leq \sum_{i=k+1}^p \lambda_i I \quad (11)$$

所以

$$\|E\|_F^2 = \text{tr}(EE^T) \leq \text{tr} \left( \sum_{i=k+1}^p \lambda_i I \right) = (p - k) \sum_{i=k+1}^p \lambda_i \quad (12)$$

主元分析将观测数据的协方差按从大到小顺序排列, 除非  $\Sigma_Y$  具有  $p$  个相同特征值, 否则第  $k$  项之后  $\sum_{i=k+1}^p \lambda_i$  非常小, 其中  $k$  为关键主元的个数<sup>[14]</sup>. 当  $k \rightarrow p$  时,  $\sum_{i=k+1}^p \lambda_i \rightarrow 0$ , 从而  $\|E\|_F \rightarrow 0$ , 这就证明了在矩阵 F-范数意义下,  $E \rightarrow 0$ .  $\square$

针对主元模型 (6), 可以用多元统计控制量进行故障检测与诊断的分析, 常用的统计量有 2 个, 即 Hotelling  $T^2$  统计量和平方预测误差 (Squared prediction error, SPE) 统计量. PCA 通过检测  $T^2$  或  $SPE$  统计量的取值是否超过其相应的控制限, 确定过程是否处于正常工况<sup>[15, 17]</sup>.

## 1.2 基于 PCA 的故障诊断

进行工况的异常检测之后, 还要进一步做基于 PCA 的故障模式辨识. 常用的方法有单变量 Shewhart 图法、SPE-Score 图法、基于特征方向的故障诊断法、基于统计距离和角度的故障诊断法等<sup>[14]</sup>.

上述方法多是基于观测数据 PCA 分析的第一个载荷向量, 因此, 当系统中同时包含多种故障时, 它们都无法很好地诊断.

贡献图法虽然可以确定对系统异常贡献较大的变量, 但是无法保证发生故障的传感器对应变量的贡献一定大<sup>[12]</sup>.

主元方差刻画了观测数据在载荷向量方向的覆盖程度, 各载荷向量对系统变化的贡献率可以用下式计算

$$P_i \% = \frac{\text{var}(v_i)}{\sum_{i=1}^p \text{var}(v_i)} \quad (13)$$

由于载荷矩阵  $B$  是标准正交阵, 故<sup>[17]</sup>

$$\text{var}(v_i) = \lambda_i \quad (14)$$

$$\text{tr}(\Sigma_Y) = \sum_{i=1}^p \text{var}(v_i) \quad (15)$$

$$P_i \% = \frac{\text{var}(v_i)}{\sum_{i=1}^p \text{var}(v_i)} = \frac{\lambda_i}{\text{tr}(\Sigma_Y)} \quad (16)$$

根据贡献率的大小可确定过程的变化主要是由哪些载荷向量所表示的变化模式引起的. 但 PCA 的模式复合效应使得载荷向量没有明确物理意义, 从而无法指明故障根源<sup>[13]</sup>. 所以 PCA 只能做异常检测, 而无法很好地进行故障模式辨识.

## 2 指定元分析

本节引入一种将统计建模和工程物理建模相结合的多变量统计特征提取方法, 即指定元分析法. 其基本思想是: 类似于 PCA 中的特征向量  $\mathbf{b}_i$ , 首先根据设备运行中常见的故障和征兆之间的关系, 定义正常或故障变化模式  $\mathbf{d}_i$

$$\mathbf{d}_i = [d_{i1}, d_{i2}, \dots, d_{ip}]^T, \quad i = 1, 2, \dots, p \quad (17)$$

然后, 将观测变量  $\mathbf{y}$  在指定模式  $\mathbf{d}_i$  所表示方向上做投影, 即可得到相应的指定元  $w_i$ , 即

$$w_i = \mathbf{d}_i^T \mathbf{y} \quad (18)$$

在做  $n$  次采样的情况下, 得到如下方程

$$[w_{i1}, w_{i2}, \dots, w_{in}] = [d_{i1}, d_{i2}, \dots, d_{ip}] \begin{bmatrix} y_{11} & y_{12} & \dots & y_{1n} \\ y_{21} & y_{22} & \dots & y_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ y_{p1} & y_{p2} & \dots & y_{pn} \end{bmatrix} \quad (19)$$

对所有  $i = 1, 2, \dots, p$ , 可用矩阵形式表示为

$$W = D^T Y \quad (20)$$

其中,  $D \in \mathbf{R}^{p \times p}$  是由标准正交指定模  $\mathbf{d}_i \in \mathbf{R}^{p \times 1}$ ,  $i = 1, 2, \dots, p$  构成的矩阵, 满足  $D^T D = I$ .  $W \in \mathbf{R}^{p \times n}$  为指定元  $\mathbf{w} = [w_1 \ w_2 \ \dots \ w_p]^T \in \mathbf{R}^{p \times 1}$  的  $n$  次采样矩阵. 所以

$$Y = DW \quad (21)$$

从而观测数据矩阵具有基于指定元的分解式<sup>[12]</sup>

$$Y = \sum_{i=1}^p \mathbf{d}_i w_i \quad (22)$$

并可以基于各指定元的显著性信息或其 Shewhart 图进行故障诊断.

与主元方差类似, 指定元的方差也刻画了观测数据阵在相应指定模式方向上的覆盖程度, 各指定模式对系统变化的贡献率可以用下式计算

$$D_i \% = \frac{\text{var}(w_i)}{\text{tr}(\Sigma_Y)} \quad (23)$$

由于指定模式是有明确物理意义的变化模式, 根据各指定模式贡献率的大小, 可以快速确定系统的变化是由哪些故障模式引起的<sup>[13]</sup>.

DCA 需要先定义一组相互正交的变化模式, 这在有些情况下比较困难. 为此, 本文首先建立 DCA 的空间投影框架, 进一步完善 DCA 故障诊断理论, 将异常检测和诊断问题转化为观测数据向相应子空间投影能量的显著性检测问题, 并在此基础上开展非正交指定模式 DCA 诊断方法研究.

## 3 DCA 的空间投影框架

### 3.1 指定模式的定义

为了对大型自动化系统进行监控, 往往需要安装不同类型的传感器, 系统的故障现象、故障原因之



$$\mathbf{d}_\alpha^T \sum_{i=1}^l c_i \mathbf{d}_i = 0 \quad (31)$$

$$\sum_{i=1}^l c_i \mathbf{d}_\alpha^T \mathbf{d}_i = 0 \quad (32)$$

所以

$$c_\alpha = 0 \quad (33)$$

对所有  $\alpha$  成立, 从而  $\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_l$  线性无关.

设  $\mathbf{d}_i$  ( $i = 1, 2, \dots, l$ ) 是观测空间中定义的  $l$  ( $l > p$ ) 个正交模式, 则  $\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_l$  线性无关. 另一方面, 由线性代数知识知  $p$  维空间中线性无关向量的个数不超过  $p$ , 与  $l > p$  矛盾. 所以正交指定模式的数目  $l \leq p$ .  $\square$

本节以下部分分别讨论  $l = p$  和  $l < p$  时的 DCA 故障诊断理论.

### 3.2.1 正交指定模式数目等于 $p$

记多变量系统观测空间  $S \equiv \mathbf{R}^{p \times 1}$ , 观测变量  $y$  的采样样本  $\mathbf{y}(j)$  ( $j = 1, 2, \dots, n$ ) 是  $S$  中的元素. 若按式 (25) 定义的  $p$  个指定模式  $\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_p$  是相互正交的, 由线性代数知识知  $\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_p$  是观测空间  $S$  的一组基.  $S$  可看作  $\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_p$  的张成空间

$$S = \text{span}\{\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_p\} \quad (34)$$

**定理 3.** 观测空间  $S$  可分解为正常子空间和故障子空间的直和

$$S = S_N \oplus S_F \quad (35)$$

其中, 故障子空间  $S_F$  由故障模式张成

$$S_F = \text{span}\{\mathbf{d}_{F_1}, \mathbf{d}_{F_2}, \dots, \mathbf{d}_{F_{l_F}}\} \quad (36)$$

正常子空间  $S_N$  由正常随机变化模式张成

$$S_N = \text{span}\{\mathbf{d}_{N_1}, \mathbf{d}_{N_2}, \dots, \mathbf{d}_{N_{l_N}}\} \quad (37)$$

$\mathbf{d}_{F_t}, \mathbf{d}_{N_s} \in \{\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_p\}$ ,  $t = 1, 2, \dots, l_F$ ,  $s = 1, 2, \dots, l_N$ ,  $l_F + l_N = p$ .

### 3.2.2 正交指定模式数目小于 $p$

正交指定模式数目小于观测空间维数时, 可通过构造由指定模式张成子空间的正交补空间的方法给出观测数据阵基于指定元的分解式.

**定理 4.** 若指定了  $l$  ( $l < p$ ) 个正交变化模式  $\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_l$ , 则可通过 Schmidt 正交化法构造指定模式张成空间  $S_1 = \text{span}\{\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_l\}$  的正交补空间  $S_E$ , 从而观测数据阵可以有如下分解形式

$$Y = \sum_{i=1}^l \mathbf{d}_i \mathbf{w}_i + E \quad (38)$$

**证明.** 由线性代数知识知  $\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_l$  是  $\mathbf{R}^{p \times 1}$  中的一组线性无关向量, 且  $D = [\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_l]$  是一个列满秩矩阵  $\text{rank}(D) = l$ . 所以存在  $H \in \mathbf{R}^{p \times (p-l)}$ , 使得

$$\bar{D} = [D \quad H] \quad (39)$$

是一个列满秩矩阵  $\text{rank}(\bar{D}) = p$ . 再对  $\bar{D}$  的列向量做 Schmidt 正交化, 并做归一化处理可得一标准正交矩阵  $\tilde{D}$ , 其中  $\tilde{D}$  的前  $l$  列是  $D$ , 即

$$\tilde{D} = [D \quad \hat{H}] \quad (40)$$

由  $\tilde{D}$  的列定义的模式是一组正交模式. 做观测数据阵  $Y$  关于  $\tilde{D}$  的指定元分析可得

$$\tilde{W} = \tilde{D}^T Y \quad (41)$$

$$Y = \tilde{D} \tilde{W} = \sum_{i=1}^p \tilde{\mathbf{d}}_i \tilde{\mathbf{w}}_i = \sum_{i=1}^l \mathbf{d}_i \tilde{\mathbf{w}}_i + \sum_{i=l+1}^p \tilde{\mathbf{d}}_i \tilde{\mathbf{w}}_i = DW + \hat{H} \hat{W} \quad (42)$$

其中

$$W = [\tilde{\mathbf{w}}_1, \tilde{\mathbf{w}}_2, \dots, \tilde{\mathbf{w}}_l]^T \quad (43)$$

$$\hat{W} = [\tilde{\mathbf{w}}_{l+1}, \tilde{\mathbf{w}}_{l+2}, \dots, \tilde{\mathbf{w}}_p]^T \quad (44)$$

由于  $D$  和  $\hat{H}$  中各列正交, 所以  $S_E = \text{span}\{\hat{\mathbf{h}}_1, \hat{\mathbf{h}}_2, \dots, \hat{\mathbf{h}}_{p-l}\}$  是  $S_1 = \text{span}\{\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_l\}$  的正交补空间

$$S = S_1 \oplus S_E \quad (45)$$

且观测数据阵有关于指定元的分解式

$$Y = \mathbf{d}_1 \mathbf{w}_1 + \mathbf{d}_2 \mathbf{w}_2 + \dots + \mathbf{d}_l \mathbf{w}_l + E = DW + E \quad (46)$$

其中分解的残差阵为

$$E = \hat{H} \hat{W} \quad (47)$$

$\square$

**推论 1.** 由定理 3 知  $S_1 = \text{span}\{\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_l\}$  可分解为正常子空间和故障子空间的直和

$$S_1 = S_N \oplus S_F \quad (48)$$

由式 (45) 和式 (48) 可得定理 5.

**定理 5.** 观测空间  $S$  可分解为正常子空间、故障子空间和残差子空间的直和

$$S = S_N \oplus S_F \oplus S_E \quad (49)$$

其中故障子空间  $S_F$  由故障模式张成

$$S_F = \text{span}\{\mathbf{d}_{F_1}, \mathbf{d}_{F_2}, \dots, \mathbf{d}_{F_{l_F}}\} \quad (50)$$

正常子空间  $S_N$  由正常随机变化模式张成

$$S_N = \text{span}\{\mathbf{d}_{N_1}, \mathbf{d}_{N_2}, \dots, \mathbf{d}_{N_{l_N}}\} \quad (51)$$

$\mathbf{d}_{F_t}, \mathbf{d}_{N_s} \in \{\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_l\}$ ,  $t = 1, 2, \dots, l_F$ ,  $s = 1, 2, \dots, l_N$ ,  $l_F + l_N = l$ . 残差子空间

$$S_E = \text{span}\{\tilde{\mathbf{d}}_{l+1}, \tilde{\mathbf{d}}_{l+2}, \dots, \tilde{\mathbf{d}}_p\} \quad (52)$$

### 3.3 基于空间投影能量的异常检测

**定义 1.** 将空间的基看作坐标轴, 向量向子空间投影的能量定义为它在子空间的各坐标轴上投影的平方和.

将时刻  $j$  采集到的观测值  $\mathbf{y}(j) \in \mathbf{R}^{p \times 1}$  看作是观测输出空间  $S$  中的一个向量,  $\mathbf{y}(j)$  向故障信号子空间  $S_F$ 、正常信号子空间  $S_N$  和残差子空间  $S_E$  投影的能量可以用下式定义

$$e_{F_j} = \sum_{i=1}^{l_F} |\mathbf{d}_{F_i}^T \mathbf{y}(j)|^2 \quad (53)$$

$$e_{N_j} = \sum_{i=1}^{l_N} |\mathbf{d}_{N_i}^T \mathbf{y}(j)|^2 \quad (54)$$

$$e_{E_j} = \sum_{i=l+1}^p |\tilde{\mathbf{d}}_i^T \mathbf{y}(j)|^2 \quad (55)$$

则多变量系统在时刻  $j$  的能量可定义为

$$e_{S_j} = \|\mathbf{y}(j)\|^2 = \sum_{i=1}^p |y_{ij}|^2 \quad (56)$$

易知时刻  $j$  多变量系统的能量等于  $\mathbf{y}(j)$  在式 (49) 所示的三个子空间上投影能量的和

$$e_{S_j} = e_{F_j} + e_{N_j} + e_{E_j} \quad (57)$$

**定义 2.** 若  $\mathbf{y}(j)$  在故障空间投影的能量  $e_{F_j}$  较大, 则系统发生异常, 否则认为系统正常运作.

**注 1.** 指定模式选取合理的情况下, 观测  $\mathbf{y}(j)$  在残差空间投影的能量  $e_{E_j}$  很小. 若  $e_{E_j}$  较大, 则说明模式选取不合适. 这个结论可用于故障诊断初期用试错法选取指定模式的过程.

### 3.4 基于空间投影能量的故障诊断

系统发生异常情况下, 为了方便及时进行故障维修, 还需进一步判断究竟发生了什么故障, 找出引起故障的根源. 为此, 在故障子空间中, 将时刻  $j$  的观测  $\mathbf{y}(j)$  向各指定的故障模式方向投影, 计算投影的能量为

$$e_{d_{ij}} = |\mathbf{d}_i^T \mathbf{y}(j)|^2 \quad (58)$$

由式 (18) 知

$$e_{d_{ij}} = |w_{ij}|^2 \quad (59)$$

并据此定义多变量系统的采样数据阵  $Y$  在  $\mathbf{d}_i$  方向投影的能量

$$e_{d_i} = \sum_{j=1}^n |\mathbf{d}_i^T \mathbf{y}(j)|^2 = \sum_{j=1}^n |w_{ij}|^2 \quad (60)$$

若观测变量  $\mathbf{y} = [y_1, y_2, \dots, y_p]^T$  是零均值的随机向量, 则各分量的线性组合  $w_i = \mathbf{d}_i^T \mathbf{y}$  是一个零均值的随机变量, 所以指定元各次采样的平方和即是其方差的  $n$  倍

$$\sum_{j=1}^n |w_{ij}|^2 = n \text{var}(w_i), \quad i = 1, 2, \dots, p \quad (61)$$

从而

$$e_{d_i} = n \text{var}(w_i) \quad (62)$$

由于多变量系统的能量可以用观测数据阵的范数表示

$$\|Y\|_F^2 = \text{tr}(YY^T) = n \text{tr}(\Sigma_Y) \quad (63)$$

所以有如下定义:

**定义 3.** 观测数据阵对各指定模式的显著性定义为

$$D_i \% = \frac{e_{d_i}}{\|Y\|_F^2} = \frac{\text{var}(w_i)}{\text{tr}(\Sigma_Y)} \quad (64)$$

事实上, 式 (64) 刻画了第  $i$  种指定模式  $\mathbf{d}_i$  对系统变化的贡献率,  $D_i \%$  取值较大说明系统的变化可能是由这个模式引起的. DCA 根据式 (64) 所得显著性的大小, 判断相应的故障是否发生.

综合第 3.3 节和第 3.4 节的研究, 在 DCA 空间投影框架下, 异常检测问题转化为观测数据  $\mathbf{y}(j)$  在故障子空间  $S_F = \text{span}\{\mathbf{d}_{F_1}, \mathbf{d}_{F_2}, \dots, \mathbf{d}_{F_{l_F}}\}$  中投影能量的显著性检测问题, 而故障诊断问题则转化为观测数据阵  $Y$  在空间  $S_{F_i} = \text{span}\{\mathbf{d}_{F_i}\}$  上投影能量的显著性检测问题. 第 4 节根据观测数据向相应子空间投影能量的显著性进行非正交模式 DCA 故障诊断研究.

## 4 逐步 DCA 多故障诊断方法

在基于 DCA 的故障诊断中, 首先需要定义一组相互正交的变化模式, 然而, 在大型自动化系统的运作过程中, 由征兆定义的变化模式并非彼此正交. 本节基于模式分组的思想给出非正交指定模式逐步 DCA 多故障诊断方法.

首先, 根据实际运行经验和理论分析, 按照式 (25) 的方式定义  $l$  种变化模式  $\mathbf{d}_i$  ( $i = 1, 2, \dots, l$ ), 并将其分为  $M$  组组内正交的变化模式集

$$D^m = [\mathbf{d}_1^m, \mathbf{d}_2^m, \dots, \mathbf{d}_{l_m}^m] \in \mathbf{R}^{p \times l_m} \quad (65)$$

满足

$$D^{m^T} D^m = I \quad (66)$$

$$\sum_{m=1}^M l_m = l \quad (67)$$

先将观测数据阵  $Y$  关于第一组正交模式  $D^1$  做指定元分析, 将第一组指定模式从观测数据中移除之后, 得到残差数据阵  $Y^2$ , 将  $Y^2$  向故障子空间  $S_F$  投影, 根据能量显著性判断是否仍包含其他故障. 确实包含其他故障情况下, 再将  $Y^2$  关于第二组指定模式  $D^2$  做指定元分析, 依此类推, 直到对全部故障模式都完成分析. 即

$$Y^1 = Y \quad (68)$$

$$W^1 = D^{1^T} Y^1 \quad (69)$$

$$Y^2 = Y^1 - D^1 W^1 \quad (70)$$

$$W^2 = D^{2^T} Y^2 \quad (71)$$

$$Y^3 = Y^2 - D^2 W^2 \quad (72)$$

⋮

$$W^M = D^{M^T} Y^M \quad (73)$$

$$E = Y^{M-1} - D^M W^M \quad (74)$$

分别计算每步 DCA 过程中各指定元的显著性

$$D_i^m \% = \frac{\text{var}(w_i^m)}{\text{tr}(\Sigma_{Y^i})}, \quad i = 1, 2, \dots, l_m \quad (75)$$

据此判断相应的故障有否发生.

上述逐步 (Progressive) DCA 诊断过程可用图 1 表示.

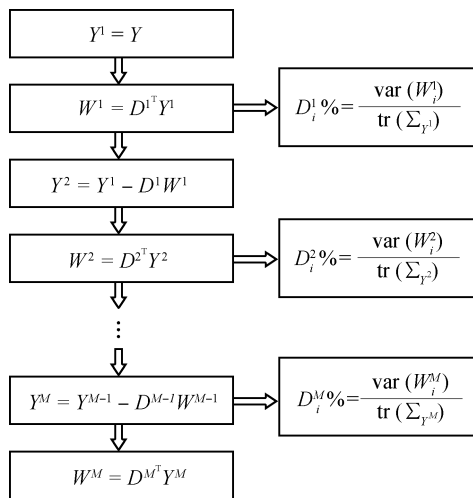


图 1 逐步 DCA 多故障诊断算法

Fig. 1 Progressive DCA for multiple faults diagnosis

**定理 6.** 上述逐步 DCA 过程事实上是将观测数据矩阵表示成由非完全正交模式定义的指定元的

和.

$$Y = D^1 W^1 + D^2 W^2 + \dots + D^M W^M + E \quad (76)$$

**证明.** 设  $\text{rank}(D^1)$  表示指定模式矩阵  $D^1$  的列秩.

1) 若  $\text{rank}(D^1) = p$

即找到了  $p$  个正交的变化模式, 根据第 3 节指定元分析的定义, 可以将观测数据阵  $Y \in \mathbf{R}^{p \times n}$  关于指定元进行完全分解

$$Y = D^1 W^1 \quad (77)$$

此时残差阵  $E = 0$ .

2) 若  $\text{rank}(D^1) < p$

由  $D^1$  的定义知  $d_1^1, d_2^1, \dots, d_{l_1}^1 \in \mathbf{R}^{p \times 1}$  是一组正交的  $p$  维向量, 由线性代数知识知它们线性无关, 且  $D^1$  是一个列满秩矩阵. 同定理 4 的证明, 利用构造各列张成空间的正交补空间的方法构造标准正交矩阵

$$\tilde{D}^1 = [D^1 \quad \tilde{H}^1] \quad (78)$$

将观测数据阵  $Y$  关于  $\tilde{D}^1$  做指定元分析

$$\tilde{W}^1 = \tilde{D}^{1^T} Y = \begin{bmatrix} D^{1^T} \\ \tilde{H}^{1^T} \end{bmatrix} Y = \begin{bmatrix} D^{1^T} Y \\ \tilde{H}^{1^T} Y \end{bmatrix} \equiv \begin{bmatrix} W^1 \\ \hat{W}^1 \end{bmatrix} \quad (79)$$

从而观测数据阵  $Y$  有如下分解式

$$Y = \tilde{D}^1 \tilde{W}^1 = D^1 W^1 + \tilde{H}^1 \hat{W}^1 \quad (80)$$

令

$$Y^2 = Y - D^1 W^1 \quad (81)$$

同前述过程, 对  $D^2 = [D_{1_2}^2, D_{2_2}^2, \dots, D_{l_2_2}^2] \in \mathbf{R}^{p \times l_2}$  经过扩维和正交化处理之后, 可得一标准正交矩阵

$$\tilde{D}^2 = [D^2 \quad \tilde{H}^2] \quad (82)$$

对移除第一组指定模式后的观测数据  $Y^2$  做关于  $\tilde{D}^2$  的指定元分析, 可得

$$\tilde{W}^2 = \tilde{D}^{2^T} Y^2 \quad (83)$$

且有  $Y^2$  关于指定元的分解式

$$Y^2 = \tilde{D}^2 \tilde{W}^2 = D^2 W^2 + \tilde{H}^2 \hat{W}^2 \quad (84)$$

由式 (81) 知

$$Y = D^1 W^1 + Y^2 = D^1 W^1 + D^2 W^2 + \tilde{H}^2 \hat{W}^2 \quad (85)$$

重复此过程直到

$$Y^M = Y^{M-1} - D^{M-1} W^{M-1} \quad (86)$$

即可得

$$Y = D^1 W^1 + D^2 W^2 + \dots + D^M W^M + E \quad (87)$$

其中

$$E = \tilde{H}^M \hat{W}^M \tag{88}$$

□

**定理 7.** 在观测数据阵基于指定元的分解式 (76) 中, 适当选取指定模式的情况下, 当指定模式数目  $l \rightarrow p$  时, 残差阵  $E \rightarrow 0$ .

**证明.** 1) 若  $\text{rank}(D^1) = p$ , 由定理 6 的证明知,  $E = 0$ , 结论显然成立.

2) 若  $\text{rank}(D^1) < p$ , 由定理 6 的证明知

$$E = \tilde{H}^M \hat{W}^M \tag{89}$$

由  $\tilde{H}^M$  的定义知,  $\tilde{H}^M \in \mathbf{R}^{p \times (p-l_M)}$ , 不妨设

$$\tilde{H}^M = [\tilde{\mathbf{h}}_{l_M+1}^M \quad \tilde{\mathbf{h}}_{l_M+2}^M \quad \cdots \quad \tilde{\mathbf{h}}_p^M] \tag{90}$$

$$\hat{W}^M = [\hat{\mathbf{w}}_{l_M+1}^M \quad \hat{\mathbf{w}}_{l_M+2}^M \quad \cdots \quad \hat{\mathbf{w}}_p^M]^T \tag{91}$$

由  $\tilde{D}^M = [D^M \quad \tilde{H}^M]$  是标准正交矩阵知

$$\tilde{D}^M \tilde{D}^{M^T} = I = D^M D^{M^T} + \tilde{H}^M \tilde{H}^{M^T} \tag{92}$$

从而

$$\tilde{H}^M \tilde{H}^{M^T} \leq I \tag{93}$$

即

$$\sum_{i=l_M+1}^p \tilde{\mathbf{h}}_i^M \tilde{\mathbf{h}}_i^{M^T} \leq I \tag{94}$$

所以

$$\tilde{\mathbf{h}}_i^M \tilde{\mathbf{h}}_i^{M^T} \leq I \tag{95}$$

$$\begin{aligned} EE^T &= (\tilde{H}^M \hat{W}^M)(\tilde{H}^M \hat{W}^M)^T = \\ &= \left( \sum_{i=l_M+1}^p \tilde{\mathbf{h}}_i^M \hat{\mathbf{w}}_i^M \right) \left( \sum_{i=l_M+1}^p \tilde{\mathbf{h}}_i^M \hat{\mathbf{w}}_i^M \right)^T = \\ &= \sum_{i=l_M+1}^p \text{var}(\hat{\mathbf{w}}_i^M) \tilde{\mathbf{h}}_i^M \tilde{\mathbf{h}}_i^{M^T} \leq \sum_{i=l_M+1}^p \text{var}(\hat{\mathbf{w}}_i^M) I \end{aligned} \tag{96}$$

$$\begin{aligned} \|E\|_F^2 &= \text{tr}(EE^T) \leq \text{tr} \left( \sum_{i=l_M+1}^p \text{var}(\hat{\mathbf{w}}_i^M) I \right) = \\ &= (p-l_M) \sum_{i=l_M+1}^p \text{var}(\hat{\mathbf{w}}_i^M) \end{aligned} \tag{97}$$

由式 (87) 可知, 对  $M$  组正交指定模式子集做逐步 DCA 分析后, 已把全部  $l = \sum_{m=1}^M l_m$  种指定模式都从观测数据中移除, 所得残差

$$E = Y - \sum_{m=1}^M D^m W^{m^T} \tag{98}$$

中包含的未指定模式  $\tilde{\mathbf{h}}_i^M$  的指定元方差  $\text{var}(\hat{\mathbf{w}}_i^M)$  都很小. 当指定模式数目  $l \rightarrow p$  时,  $\sum_{i=l_M+1}^p \text{var}(\hat{\mathbf{w}}_i^M) \rightarrow 0$ , 所以

$$\|E\|_F \rightarrow 0 \tag{99}$$

□

事实上, 由注 1 和式 (62) 知, 未指定模式相应指定元的方差都很小. 若未指定模式的方差较大, 则说明模式选取不成功, 应该回到诊断初期, 进一步利用系统或设备的运行状态信息正确选取指定模式.

### 5 仿真研究

本节给出逐步 DCA 多故障诊断方法的仿真结果, 仿真中取  $p = 15$ , 即用 15 中征兆表示变化模式, 并取  $n = 1000$  个采样点. 设观测数据由 15 种共存的变化模式复合而成

$$Y = \sum_{i=1}^{15} \mathbf{d}_i \bar{\mathbf{w}}_i \tag{100}$$

受各模式影响程度如图 2 所示.  $\mathbf{d}_i (i = 1, 2, \dots, 15)$  由式 (25) 定义.




图 2 仿真用指定元方差

Fig. 2 DC value for generating observation

选定  $l = 10$  个指定模式  $\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_{10}$ , 其中  $\mathbf{d}_1, \mathbf{d}_3, \mathbf{d}_5, \mathbf{d}_8, \mathbf{d}_{10}$  为仿真故障模式,  $\mathbf{d}_2, \mathbf{d}_4, \mathbf{d}_6, \mathbf{d}_7, \mathbf{d}_9$  为正常随机变化模式. 其他表示非显著的随机变化模式. 在 10 种指定模式中,  $D^1 = [\mathbf{d}_1, \mathbf{d}_2, \dots, \mathbf{d}_6]$  是一组组内正交指定模式构成的矩阵,  $D^2 = [\mathbf{d}_7, \mathbf{d}_8, \mathbf{d}_9, \mathbf{d}_{10}]$  是另一组组内正交指定模式构成的矩阵.  $\bar{\mathbf{w}}_i$  是仿真用指定元样本, 假设仿真指定元是零均值的正态分布随机变量, 可通过 Matlab 中的 randn 及简单线性运算产生 15 组相关的随机样本  $\bar{\mathbf{w}}_i (i = 1, 2, \dots, 15)$ .



### 5.1 基于 PCA 的故障诊断

图 3 给出了用 PCA 对观测数据做监控的 SPE 图, 从图 3 可以看出从 801 个采样点开始系统发生了明显的故障. 但 SPE 图只能发出系统异常状况报警, 无法判定究竟哪些故障发生了. 为此, 直接对观测数据  $Y$  本身做主元分析, 提取其中变化最大的方向, 并与已知故障方向相比较, 采用基于 PCA 的特征方向法进行故障模式识别.

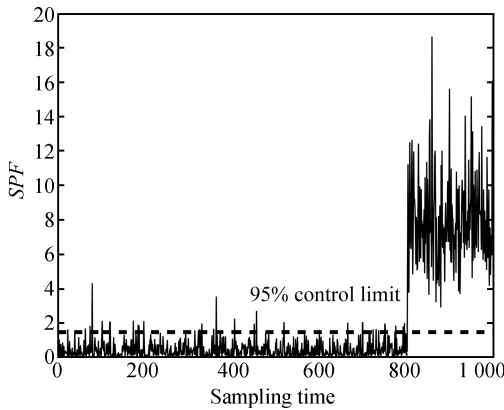


图 3 PCA 的 SPE 图  
Fig. 3 SPE chart for PCA

定义两个标准化向量的方向相似性

$$s = 1 - \frac{c\theta}{90} \quad (101)$$

其中,  $\theta$  是向量  $\mathbf{a}$  与  $\mathbf{b}$  的夹角,  $c = 57.3$  表示弧度与度的转换系数,  $1/90$  为归一化系数. 表 2 给出了对  $Y$  直接做主元分析的第一载荷向量  $\mathbf{b}_1$  与已知故障模式  $\mathbf{d}_i$  ( $i = 1, 3, 5, 8, 10$ ) 的相似性.

表 2  $\mathbf{b}_1$  与已知故障模式的相似性  
Table 2 Similarity between  $\mathbf{b}_1$  and the simulated fault pattern

	$\mathbf{d}_1$	$\mathbf{d}_3$	$\mathbf{d}_5$	$\mathbf{d}_8$	$\mathbf{d}_{10}$
$\mathbf{b}_1$	0.3108	0.2537	0.2694	0.1924	0.1566

从表 2 可以看出, 当系统中包含多种故障时, 主元分析的第一载荷向量与故障库中故障的相似性都不超过 0.35, 因此基于 PCA 特征方向法的故障诊断结果是不可靠的.

### 5.2 基于逐步 DCA 的多故障诊断

先将观测数据关于  $D^1$  中的变化模式做 DCA 分析, 绘制观测数据向故障子空间  $S_F = \text{span}\{\mathbf{d}_1, \mathbf{d}_3, \mathbf{d}_5, \mathbf{d}_8, \mathbf{d}_{10}\}$  投影的能量曲线如图 4 所示. 其中实线和虚线分别表示正常和故障数据向  $S_F$  投影的能量随时间变化曲线.

从图 4 可以看出, 801 点开始观测数据向故障子空间  $S_F$  投影的能量较大, 据此判断系统发生了异常. 也可通过确定投影能量阈值的方法进行系统异常检测, 阈值可由多次实验结果或经验确定.

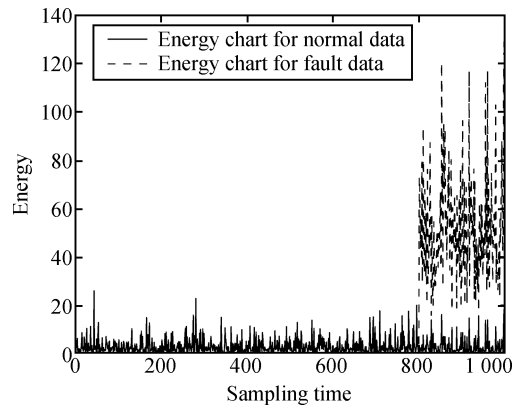


图 4 观测数据向故障子空间投影能量曲线  
Fig. 4 Projection energy of original observation

根据 DCA 分析的结果, 计算  $D^1$  中各变化模式的显著性如表 3 所示. 从表 3 可以看出, 观测数据关于故障模式  $\mathbf{d}_1, \mathbf{d}_3, \mathbf{d}_5$  的显著性较大, 据此判断观测数据中包含这三种故障. 图 5 (见下页) 给出了关于  $D^1$  中的指定模式做指定元分析所得 6 个指定元的 Shewhart 图. 图 5 中, UCL (Upper control limit) 和 LCL (Lower control limit) 分别表示控制上限和控制下限. 不难看出图 5 的结果进一步验证了基于表 3 进行多故障诊断结果的可靠性.

表 3  $D^1$  中各指定模式的显著性  
Table 3 Significance of the designated pattern in  $D^1$

	$\mathbf{d}_1$	$\mathbf{d}_2$	$\mathbf{d}_3$	$\mathbf{d}_4$	$\mathbf{d}_5$	$\mathbf{d}_6$
$D_i$ %	0.3204	0.0143	0.2338	0.0099	0.3039	0.0073

移除第一组变化模式  $D^1$  后得到残差数据阵  $Y^2$ , 将其向故障子空间  $S_F$  投影, 并绘制其投影能量曲线如图 6 (见第 981 页) 所示. 其中实线和虚线分别表示正常和故障观测数据向  $S_F$  投影的能量曲线.

从图 6 可以看出, 移除了第一组变化模式  $D^1$  后, 系统中仍然可能包含其他故障. 为找出这些故障, 将残差数据阵关于第二组变化模式  $D^2$  再做指定元分析, 计算各变化模式的显著性, 结果如表 4 (见下页) 所示. 从表 4 可以看出  $\mathbf{d}_8, \mathbf{d}_{10}$  对系统变化的贡献较大, 据此可以判断系统中发生了这两种故障.

图 7 (见第 981 页) 给出了各指定元的 Shewhart 图, 从图 7 可以看到  $\mathbf{d}_8, \mathbf{d}_{10}$  相应指定元的 Shewhart 图在 801 个采样点以后超出了控制限, 其余指定元的 Shewhart 图基本都在控制限内, 这进一步证实除

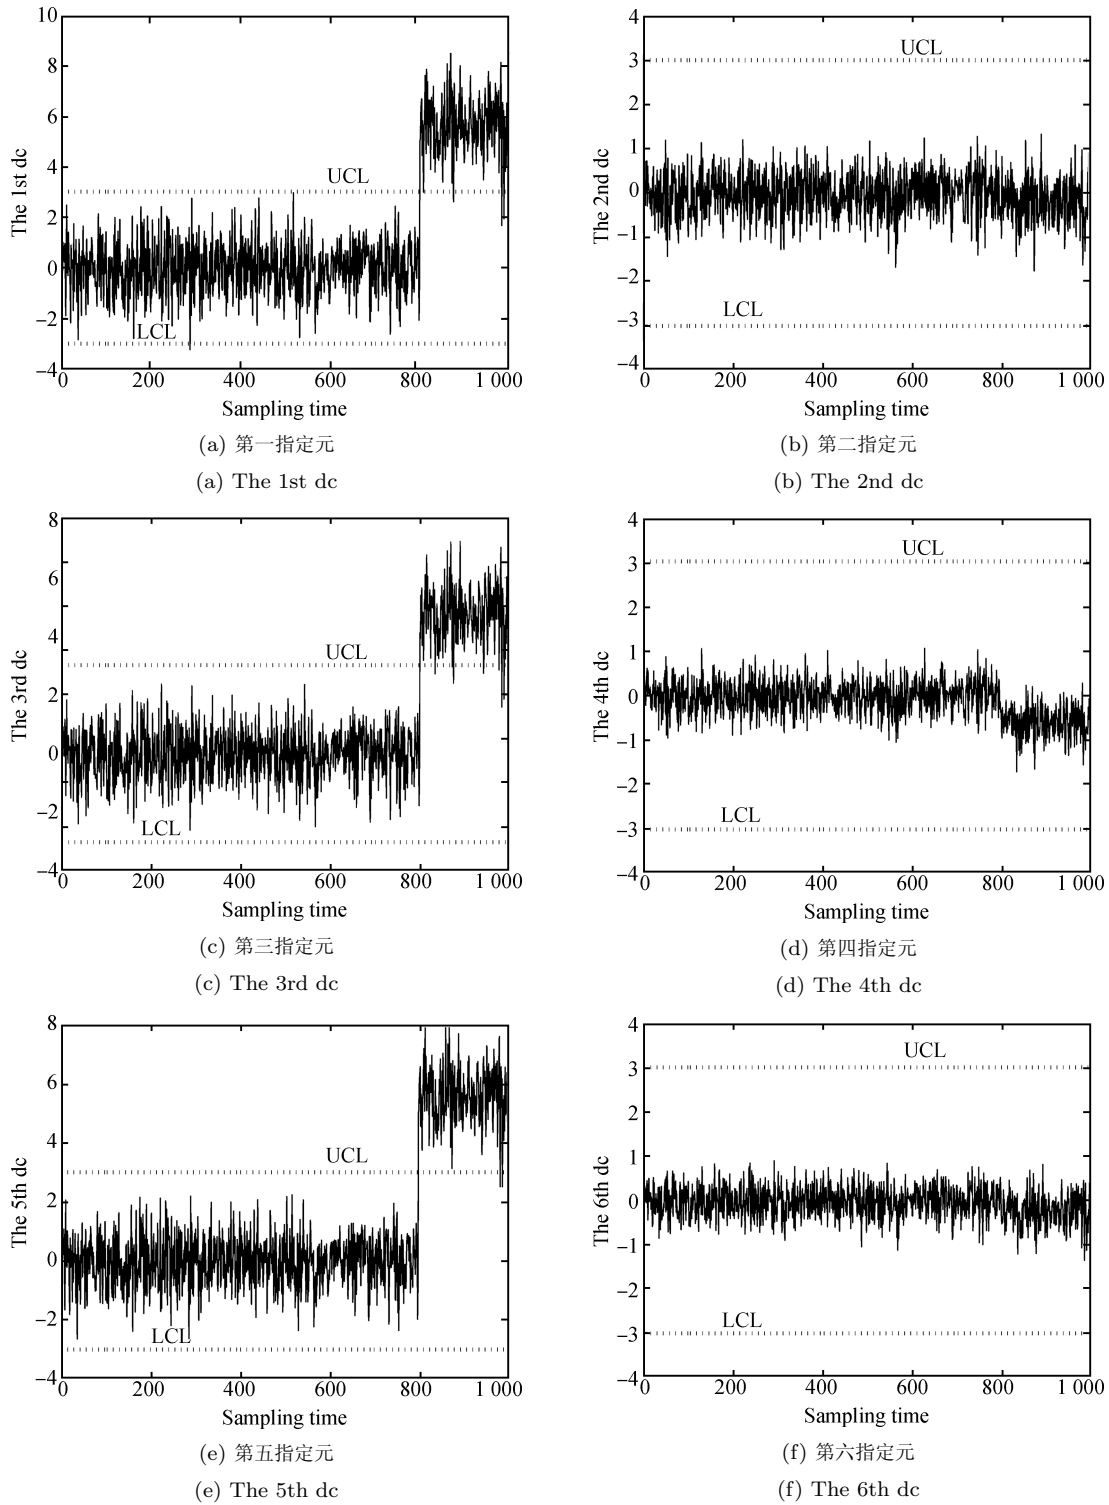


图 5  $D^1$  中各指定元的 Shewhart 图  
Fig. 5 Shewhart chart for dc in  $D^1$

了已诊断出的  $d_1, d_3, d_5$  外, 系统中还发生了  $d_8, d_{10}$  两种故障。

综合本节的仿真研究可知, 用逐步 DCA 方法可以诊断出系统中包含  $d_1, d_3, d_5, d_8, d_{10}$  等 5 种故障, 与仿真产生  $Y$  的方式相同。

表 4  $D^2$  中各指定模式的显著性

Table 4 Significance of the designated pattern in  $D^2$

	$d_7$	$d_8$	$d_9$	$d_{10}$
$D_i\%$	0.0315	0.4277	0.0082	0.2283

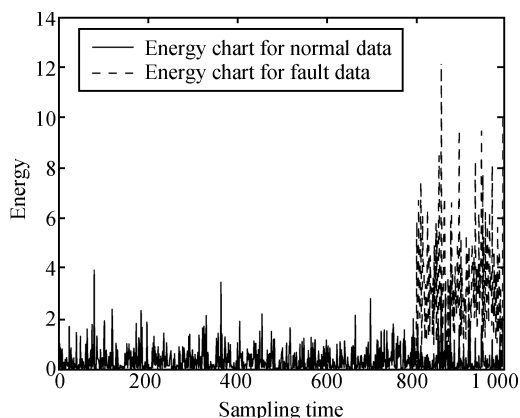


图 6 残差数据向故障子空间投影能量曲线


Fig. 6 Projection energy of residual

### 6 结论和展望


结合多变量统计建模与物理建模的 DCA 可以克服 PCA 模式复合的不足, 除了可以进行异常检测外, 还可以有效地进行故障的识别和多故障的诊断.

本文首先建立多变量系统的观测空间  $S$ , 并将其分解为正常子空间  $S_N$  和故障子空间  $S_F$  的直和, 然后将观测数据分别向故障子空间和正常子空间投影, 建立 DCA 的空间投影框架. 从而将异常检测问题转化为观测数据  $y(j)$  在故障子空间  $S_F$  中投影能量的显著性检测问题, 而故障诊断问题则转化为观测数据阵  $Y$  在子空间  $S_{F_i} \equiv \text{span}\{d_{F_i}\}$  上投影能量的显著性检测问题. 以此为理论基础, 开展了非正交指定模式 DCA 多故障诊断问题研究, 提出了一种逐步 DCA 多故障诊断方法, 并证明了非正交模式逐步 DCA 分析的可行性和收敛性.


利用标架 (Frame) 的相关理论也是解决非正交指定模式 DCA 诊断问题的途径之一. 但是用标架表示相应空间的信息时所产生的冗余性, 使得非正交模式的标架投影 DCA 方法研究过程中, 将会遇到因分解形式的不唯一性而带来的新问题. 解决这些关键理论问题可以给出更完善的 DCA 理论框架, 同时有助于增强算法的实用性.




(a) 第七指定元  
(a) The 7th dc



(b) 第八指定元  
(b) The 8th dc



(c) 第九指定元  
(c) The 9th dc



(d) 第十指定元  
(d) The 10th dc

图 7  $D^2$  中各指定元的 Shewhart 图

Fig. 7 Shewhart charts for dcs in  $D^2$

## References

- 1 Venkatasubramanian V, Rengaswamy R, Yin K, Kavuri S N. A review of process fault detection and diagnosis part I: quantitative model-based methods. *Computers and Chemical Engineering*, 2003, **27**(3): 293–311
- 2 Guo Ming. Research on Data-Based Performance Monitoring and Fault Diagnosis for Process Industry [Ph. D. dissertation], Zhejiang University, China, 2004  
(郭明. 基于数据驱动的流程工业性能监控与故障诊断研究 [博士学位论文], 浙江大学, 中国, 2004)
- 3 Mao Z H, Jiang B, Shi P, Cocquemot V. High gain observer-based fault estimation for nonlinear networked control systems. In: Proceedings of the American Control Conference. Washington D. C., USA: IEEE, 2008. 3058–3063
- 4 Odgaard P F, Lin B, Jorgensen S B. Observer and data-driven-model-based fault detection in power plant coal mills. *IEEE Transactions on Energy Conversion*, 2008, **23**(2): 659–668
- 5 Wang Y Q, Zhou D H, Gao F R. Robust fault-tolerant control of a class of non-minimum phase nonlinear processes. *Journal of Process Control*, 2007, **17**(6): 523–537
- 6 Simani S, Patton R J. Fault diagnosis of an industrial gas turbine prototype using a system identification approach. *Control Engineering Practice*, 2008, **16**(7): 769–786
- 7 Peng D Z, Zhang Y. Dynamics of generalized PCA and MCA learning algorithms. *IEEE Transactions on Neural Networks*, 2007, **18**(6): 1777–1784
- 8 Ge Zhi-Qiang, Liu Yi, Song Zhi-Huan, Wang Hai-Qing. Local model based monitoring for nonlinear multiple mode process. *Acta Automatica Sinica*, 2008, **34**(7): 792–797  
(葛志强, 刘毅, 宋执环, 王海清. 一种基于局部模型的非线性多工况过程监测方法. *自动化学报*, 2008, **34**(7): 792–797)
- 9 Wen Cheng-Lin, Hu Jing, Wang Tian-Zhen, Chen Zhi-Guo. Relative PCA with applications of data compression and fault diagnosis. *Acta Automatica Sinica*, 2008, **34**(9): 1128–1139  
(文成林, 胡静, 王天真, 陈志国. 相对主元分析及其在数据压缩和故障诊断中的应用. *自动化学报*, 2008, **34**(9): 1128–1139)
- 10 Li Gang, Zhou Dong-Hua. SPM-based online fault prediction approach for multivariate continuous processes. *Journal of Chemical Industry and Engineering*, 2008, **59**(7): 1829–1833  
(李钢, 周东华. 基于 SPM 的多变量连续过程在线故障预测方法. *化工学报*, 2008, **59**(7): 1829–1833)
- 11 Verde C, Mina J. Principal components structured models for fault isolation. In: Proceedings of the 17th World Congress of the International Federation of Automatic Control. Seoul, Korea: Elsevier, 2008. 795–808
- 12 Cherry G, Qin S J. Reconstruction-based contribution for process monitoring. In: Proceedings of the 17th World Congress of the International Federation of Automatic Control. Seoul, Korea: Elsevier, 2008. 7889–7894
- 13 Liu Y G. Statistical Control of Multivariate Processes with Applications to Automobile Body Assembly [Ph. D. dissertation], University of Michigan, USA, 2002
- 14 Jackson J E. *A User's Guide to Principal Components*. New York: Wiley-Interscience, 1991
- 15 Zhang Jie, Yang Xian-Hui. *Multivariate Statistical Process Control*. Beijing: Publishing House of Chemical Industry and Engineering, 2000  
(张杰, 阳宪惠. *多变量统计过程控制*. 北京: 化学工业出版社, 2000)
- 16 Cao Zhi-Hao. *Numerical Linear Algebra*. Shanghai: Publishing House of Fudan University, 1996  
(曹志浩. *数值线性代数*. 上海: 复旦大学出版社, 1996)
- 17 Johnson R A, Wicheren D W. *Applied Multivariate Statistical Analysis (Sixth Edition)*. New Jersey: Prentice Hall, 2008
- 18 Zhou Shou-Xi, Li Zhu-Guo, Yang Hui, Huo Hua, Chen Shi-Wei. Application of fuzzy theory in large air compressor condition monitoring. *Lubrication Engineering*, 2004, **166**(6): 94–96  
(周守西, 李柱国, 杨慧, 霍华, 陈士玮. 模糊理论在大型空气压缩机故障诊断中的应用. *润滑与密封*, 2004, **166**(6): 94–96)



**周福娜** 上海海事大学博士研究生. 2004 年获得河南大学计算机学院硕士学位. 主要研究方向为故障诊断和数据融合. E-mail: zhoufn2002@163.com  
(**ZHOU Fu-Na** Ph. D. candidate at Shanghai Maritime University. She received her master degree from Henan University in 2004. Her research interest covers fault diagnosis and information fusion.)



**文成林** 博士后, 教授. 主要研究方向为多尺度估计理论及其应用、信号处理与数据融合技术及应用、动态系统建模理论及其应用. 本文通信作者.  
E-mail: wenc1@hdu.edu.cn

(**WEN Cheng-Lin** Postdoctor, professor. His research interest covers multiscale estimation theory and its applications, signal processing, data fusion technology and its applications, and dynamic system modeling theory and its application technology. Corresponding author of this paper.)



**汤天浩** 博士, 教授. 1998 年获上海大学控制理论与控制工程专业博士学位. 主要研究方向为智能信息处理、智能控制理论及其应用.

E-mail: thtang@cen.shmtu.edu.cn  
(**TANG Tian-Hao** Ph. D., professor. He received his Ph. D. degree from Shanghai University in 1998. His research interest covers intelligent information processing, intelligent control theory and its application.)



**陈志国** 教授. 主要研究方向为计算机网络技术与信号处理.

E-mail: chenzg@henu.edu.cn  
(**CHEN Zhi-Guo** Professor. His research interest covers computer network technology and signal processing.)