

基于信息增量矩阵的故障诊断方法

文成林¹ 胡玉成¹

摘要 主元分析 (Principal component analysis, PCA) 是一种常用的故障检测方法, 由于特征提取不准确, 在用于故障诊断时常存在误报率和漏报率较高的现象. 为此, 本文首先介绍了基于全局的协方差矩阵的信息增量矩阵的故障诊断方法, 虽然相比 PCA 方法它能有效减少误报率和漏报率, 但随着采样样本的增加, 会因计算得到的阈值越来越不具代表性和计算量较大等原因而影响该方法的性能. 然后, 建立了基于局部数据的移动窗口协方差矩阵的信息增量矩阵的故障诊断方法, 以克服上述方法中存在的不足. 该方法主要通过定义局部协方差矩阵、局部信息增量矩阵、局部信息增量均值、局部动态阈值、异常检测与判定等过程完成. 最后, 通过两个数值仿真例子来验证 PCA 方法、基于全局的协方差矩阵的信息增量矩阵方法以及本文方法在故障误报和漏报方面的检测效能. 实验结果表明, 本文方法具有最好的检测性能.

关键词 故障诊断, 协方差矩阵, 主元分析, 信息增量矩阵

引用格式 文成林, 胡玉成. 基于信息增量矩阵的故障诊断方法. 自动化学报, 2012, 38(5): 832–840

DOI 10.3724/SP.J.1004.2012.00832

Fault Diagnosis Based on Information Incremental Matrix

WEN Cheng-Lin¹ HU Yu-Cheng¹

Abstract Principal component analysis (PCA) is a kind of commonly used fault detection method, but because of the uncorrected feature extraction, there are higher rates of false and missed alarm by using it in fault diagnosis. Thus, this paper firstly introduces the method of fault diagnosis based on the information incremental matrix obtained by the global covariance matrix. It can effectively reduce the rate of false and missed alarm as compared to PCA. But when the number of samples increases, the calculated threshold value is more unrepresentative and a much larger amount of calculation is required, they influence the performance of this method. Then, in order to overcome these shortcoming of the above method, one new fault diagnosis method is proposed by the local information incremental matrix obtained by the covariance matrix of moving the window, which comprises partial samples. This new method is mainly composed of defining the local covariance matrix, calculating local information incremental matrix, local information incremental mean, local dynamic threshold, and detecting abnormality and diagnosing fault, and so on. Finally, through two examples of numerical simulation to verify the detection efficiency of three fault diagnosis methods, i.e., PCA method, the method of fault diagnosis based on the information incremental matrix obtained by the global covariance matrix, and the proposed method, in false and missed alarm. The results show that the new method possesses the best detection performance.

Key words Fault diagnosis, covariance matrix, principal component analysis (PCA), information incremental matrix

Citation Wen Cheng-Lin, Hu Yu-Cheng. Fault diagnosis based on information incremental matrix. *Acta Automatica Sinica*, 2012, 38(5): 832–840

复杂工业过程中, 设备和系统的故障对生产安全、产品质量或效率产生不良影响, 甚至造成人身伤亡和对环境的污染. 随着控制系统日益复杂以及对产品质量要求不断提高, 人们对设备的安全性和可靠性要求也越来越高, 因而故障诊断技术越来越受到重视^[1–2]. 故障诊断的核心是诊断方法, 现有的故

障诊断方法主要可以分为基于解析模型的方法、基于知识的方法和基于数据驱动的方法^[3]. 基于解析模型方法有状态估计法、等价空间法、扩展卡尔曼滤波器 (Extended Kalman filter, EKF) 等, 但需要精确的数学模型, 而实际工业系统过程不确定性因素多而且复杂, 难以建立精确的数学模型; 基于知识的方法主要有神经网络、模糊推理和专家系统等^[4], 虽然这类方法不需精确的数学模型, 但常存在学习和自适应能力差、推理效率低、对奇异的模式判断能力差等问题; 基于数据驱动的方法是在对象难以建立精确的数学模型的情况下^[5], 通过将过程运行数据从测量空间变换到特征空间后再进行分析, 从而实现对该系统的故障诊断, 是目前研究的热点方向之一. 而多元统计方法是这类方法的代表^[5–7], 其中最

收稿日期 2011-09-07 录用日期 2011-12-20
Manuscript received September 7, 2011; accepted December 20, 2011

国家自然科学基金 (60934009, 61034006) 资助
Supported by National Natural Science Foundation of China (60934009, 61034006)

本文责任编辑 钟麦英
Recommended by Associate Editor ZHONG Mai-Ying

1. 杭州电子科技大学信息与控制研究所 杭州 310018
1. Institute of Information and Control, Hangzhou Dianzi University, Hangzhou 310018

常用的有主元分析 (Principal component analysis, PCA)、相对主元分析 (Relative PCA)^[8]、指定元分析 (Designated component analysis, DCA) 方法^[9]。

PCA 方法一般首先要基于一定采样数据计算出协方差矩阵, 进而求解出该矩阵对应的特征值和特征向量, 并根据特征值的大小确定主元数和载荷矩阵, 从而实现从高维数据降维的目的。传统 PCA 方法忽视量纲对系统的影响, 从而使选取的主元难以具有代表性; 而在进行量纲标准化后, 得到的特征值常常是近似相等而无法进行有效的主元提取。针对这些问题, 文献 [8] 引入相对主元分析方法, 该方法先对系统各分量进行量纲标准化; 再根据系统的先验信息分析和确定各分量的重要程度; 赋予系统各分量相应的权值; 建立相对主元模型, 但这一方法根据系统的先验信息选取比重因子, 实际过程中难以确定^[8]。PCA 用于故障诊断时, 先用历史数据建立正常工况下的主元模型, 然后再检测新的观测数据相对于主元模型的偏离程度, 并据此判断系统是否有异常发生^[10]。由于是将过程运行数据从测量空间线性变换到特征空间后再进行分析, 因此存在严重的模式复合效应, 所以 PCA 选取的主元没有明确的物理意义, 难以解释故障由哪个变量引起。针对此问题, 文献 [9] 给出了 DCA 方法, 根据设备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的载荷矩阵, 类似 PCA 的方法进行故障诊断, 可以有效避免 PCA 的模式复合效应, 但是在选择投影框架 (载荷矩阵) 时比较困难^[9-10]。另外, 它是用固定的模型来检测时变系统的数据, 这既不可靠也不具有自适应性; 同时, 该方法还要求采样数据服从正态分布, 而这在实际工业系统中通常是难以满足的。

针对上述问题, Yang 给出了基于全局协方差矩阵的信息增量矩阵方法^[11], 这是一种既没有采样数据服从正态分布的限制, 同时也不需要离线建模的故障诊断方法。该方法首先基于当前时刻及之前的采样数据定义并计算协方差矩阵, 待有新的观测数据到来后再更新协方差矩阵; 然后将相邻的两个协方差矩阵做差运算, 从而得到信息增量矩阵; 再后, 基于信息增量矩阵计算出各元素对总体变化的贡献率和计算动态阈值; 最后, 通过确定各变量对故障的影响程度, 从而实现故障诊断与识别。

然而, 随着采样数据的增多, 距当前时刻较前的数据却仍然在继续使用, 这些数据不仅已不具有代表性或代表性已经很弱, 而且还会造成更新协方差矩阵时所获取的阈值不能及时代表系统当前的状况, 更新阈值时计算量增大, 从而增加了误报率。针对这一问题, 本文给出了基于局部数据的移动窗口协方差矩阵的信息增量矩阵的故障诊断方法, 该方法选

择具有固定大小的采样数据窗口以及固定的阈值窗口, 不仅使更新协方差矩阵时数据有效减少, 而且也因所获取的动态阈值基于靠近当前时刻的数据计算出来, 所以更具有代表性, 从而有望降低系统的误报率。

1 基于协方差矩阵的信息增量矩阵的故障诊断方法

1.1 基于全局协方差矩阵的信息增量矩阵的故障诊断方法 (算法 1^[11])

传统的主元分析方法利用正常的历史数据建立模型, 首先计算协方差矩阵的特征值和特征向量, 按特征值从大到小排列, 并选取主元数和确定相应的载荷矩阵, 然后确定控制限, 最后对在线的数据进行异常检测。信息增量矩阵的方法不要求出协方差矩阵的特征值和特征向量, 也不需要历史数据进行离线建模, 而是用实时更新的协方差矩阵与之前的做差, 得到实时变化的信息增量矩阵并计算信息增量均值, 因此能够做到对系统异常情况的实时检测^[9]。

记多变量前 n 时刻的数据观测矩阵为

$$X_n = \begin{bmatrix} x_1(1) & x_1(2) & \cdots & x_1(n) \\ x_2(1) & x_2(2) & \cdots & x_2(n) \\ \vdots & \vdots & \ddots & \vdots \\ x_p(1) & x_p(2) & \cdots & x_p(n) \end{bmatrix} \in \mathbf{R}^{p \times n} \quad (1)$$

其中, $\mathbf{x}(k) = [x_1(k), x_2(k), \dots, x_p(k)]^T$ 是系统变量在 k 时刻的观测, $k = 1, 2, \dots, n, \dots, p$ 为系统状态变量的数目, n 是系统变量的采样数目。首先对数据阵进行预处理, X_n 的均值向量为

$$\mathbf{b}_n = \frac{1}{n} X_n \mathbf{l}_n \quad (2)$$

其中, $\mathbf{l}_n = [1, 1, \dots, 1]^T \in \mathbf{R}^{n \times 1}$ 。将原始数据进行预处理:

$$X_n^1 = X_n - \mathbf{b}_n \mathbf{l}_n^T \quad (3)$$

则数据矩阵 X_n^1 的协方差矩阵为

$$R_n = \frac{1}{n-1} X_n^1 (X_n^1)^T \quad (4)$$

R_n 是一个对称矩阵, 其对角线上的元素反映各分量的方差, 非对角线上的元素反映各变量的协方差, 为了简化式 (4) 的计算, 令

$$K_n = X_n X_n^T \quad (5)$$

则重写式 (4), 得到全体采样数据的全局协方差矩阵为

$$R_n = \frac{K_n}{n-1} - \mathbf{b}_n \mathbf{b}_n^T \frac{n}{n-1} \quad (6)$$

当新的观测值 $\mathbf{x}(n+1)$ 到来时, 则有:

$$K_{n+1} = K_n + \mathbf{x}(n+1)\mathbf{x}(n+1)^T \quad (7)$$

类似式 (6), 可计算得:

$$R_{n+1} = \frac{K_{n+1}}{n} - \mathbf{b}_{n+1} \mathbf{b}_{n+1}^T \frac{n+1}{n} \quad (8)$$

将式 (6) 和式 (7) 代入式 (8) 计算得:

$$R_{n+1} = \frac{(n-1)R_n}{n} + \frac{[\mathbf{b}_n - \mathbf{x}(n+1)][\mathbf{b}_n - \mathbf{x}(n+1)]^T}{n+1} \quad (9)$$

基于全体采样数据信息的信息增量矩阵为

$$D_{n+1} = R_{n+1} - R_n = \frac{[\mathbf{b}_n - \mathbf{x}(n+1)][\mathbf{b}_n - \mathbf{x}(n+1)]^T}{n+1} - \frac{R_n}{n} \quad (10)$$

基于全体采样数据信息的信息增量均值为

$$\gamma_{n+1} = \frac{\sum_{i=1}^p \sum_{j=1}^p |D_{n+1}[i, j]|}{p^2} \quad (11)$$

是否有故障发生的判定过程如下:

1) 若系统的动态阈值为 σ_{n+1} , 当 $\gamma_{n+1} \geq 3\sigma_{n+1}$ 时, 则表示系统已有故障发生。

此时, 记 γ_{n+1} 为 γ_{n+1}^* . 由于该 $n+1$ 时刻发生了故障, 也就是表示已发生的故障存在于数据 $\mathbf{x}(n+1)$ 中, 为了继续检测与更新, 在下一步计算信息增量均值 γ_{n+1} 时, 不应再包含已发生故障的信息, 需去除 $\mathbf{x}(n+1)$. 同时, 应当对相关参数进行重新更新标记, $X_{n+1} = X_n$, $K_{n+1} = K_n$, $R_{n+1} = R_n$.

记发生故障时刻的信息增量均值 γ^* 下标全体集合为 $\Omega(n+1) = \{l|\gamma_l^*\}$, $|\Omega|$ 为该集合中元素的数目. 记全体 γ^* 为

$$\{\gamma_{j_1}^*, \gamma_{j_2}^*, \dots, \gamma_{j_k}^*, \dots, \gamma_{j_{m'}}^*\} \quad (12)$$

且满足 $\{j_1, j_2, \dots, j_k, \dots, j_{m'}\} \subseteq \{1, 2, \dots, n+1\}$. 记未发生故障时刻的全体信息增量均值 γ 为

$$\{\gamma_{i_1}, \gamma_{i_2}, \dots, \gamma_{i_k}, \dots, \gamma_{i_{n'}}\} \quad (13)$$

且满足 $\{i_1, i_2, \dots, i_k, \dots, i_{n'}\} \subseteq \{1, 2, \dots, n+1\}$. 式 (12) 和式 (13) 中的下标满足

$$\{i_1, i_2, \dots, i_k, \dots, i_{n'}\} \cup \{j_1, j_2, \dots, j_k, \dots, j_{m'}\} = \{1, 2, \dots, n+1\} \quad (14)$$

计算基于全体正常采样数据动态阈值:

$$\sigma_{n+1} = \frac{2}{n+1} \sum_{k=n'-\lceil \frac{n+1}{2} \rceil+1}^{n'} \gamma_{i_k} \quad (15)$$

其中, $\lceil \cdot \rceil$ 表示向上取整数。

2) 当 $\gamma_{n+1} < 3\sigma_{n+1}$ 时, 则表示系统没有故障发生, 继续采样后, 再利用步骤 1) 进行检测。

注 1. 从式 (5) 和式 (7) 可知, 矩阵 K_n 和 K_{n+1} 均基于全采样数据定义. 再由式 (6) 和式 (8) 分别表示的协方差矩阵 R_n 和 R_{n+1} 是基于全体采样数据得到的; 这样, 基于式 (10) 定义的信息增量矩阵 D_{n+1} 自然也是由全体采样信息得到的; 从而最终得到的用于呈现当前时刻的采样数据 $\mathbf{x}(n+1)$ 是否包含有故障的信息增量均值 γ_{n+1} 是基于全体采样信息得到的, 而基于信息增量均值 γ_{n+1} 用来判定当前时刻故障是否已发生的动态阈值 σ_{n+1} 也基于全体采样数据信息计算得到 (易知, 虽然 σ_{n+1} 用部分 γ 得到, 但每个信息增量均值 γ 却又是基于全体信息得到的)。

注 2. 基于注 1 的分析, 基于全局协方差矩阵的信息增量矩阵的故障诊断方法存在以下问题: 1) 计算出的信息增量均值 γ_{n+1} 和动态阈值 σ_{n+1} 代表性不强, 这是因为两者均基于全体采样信息得到 (分析见注 1). 2) 由于计算出的信息增量均值 γ_{n+1} 和动态阈值 σ_{n+1} 代表性不强, 且计算动态阈值时计算量大, 因此在实际应用中会因产生较高的误报率而影响其应用效果, 这将在第 2 节的仿真中进行验证。

1.2 基于局部数据的移动窗口协方差矩阵的信息增量矩阵故障诊断方法 (算法 2)

为了解决第 1.1 节所述的基于全局协方差矩阵的信息增量矩阵故障诊断方法存在的阈值计算大, 尤其是计算出的信息增量均值 γ 和动态阈值 σ 代表性不强等原因, 从而影响其在实际应用效果不佳等问题, 本节给出一种基于局部数据的移动窗口协方差矩阵的信息增量矩阵故障诊断方法, 具体思想如下。

假设当前时刻为 n , 记包含有故障的采样数据全体为 $\{\mathbf{x}^*(j_1), \mathbf{x}^*(j_2), \dots, \mathbf{x}^*(j_{m'})\}$, 记正常采样数据 (不包含故障) 全体为 $\{\mathbf{x}(i_1), \mathbf{x}(i_2), \dots, \mathbf{x}(i_{n'})\}$, 且满足

$$\{i_1, i_2, \dots, i_k, \dots, i_{n'}\} \cup \{j_1, j_2, \dots, j_k, \dots, j_{m'}\} = \{1, 2, \dots, n\} \quad (16)$$

对于已获取的 n 个采样数据, 从正常采样数据集 $\{\mathbf{x}(i_1), \mathbf{x}(i_2), \dots, \mathbf{x}(i_{n'})\}$ 中连续选取固定窗口长

度为 L 的采样数据, 并形成相应的局部数据矩阵:

$$X_n^L = [\mathbf{x}(i_{n'-L+1}), \mathbf{x}(i_{n'-L+2}), \dots, \mathbf{x}(i_{n'})] \quad (17)$$

对于当前时刻 $n+1$, 在采样数据 $\mathbf{x}(n+1)$ 到来后, 形成的相应局部数据矩阵为

$$X_{n+1}^L = [\mathbf{x}(i_{n'-L+2}), \mathbf{x}(i_{n'-L+3}), \dots, \mathbf{x}(i_{n'}), \mathbf{x}(n+1)] \quad (18)$$

通过观察 X_n^L 和 X_{n+1}^L 可知, 由它们具有公共部分采样数据形成的局部数据矩阵为

$$Y_{n,n+1}^L = [\mathbf{x}(i_{n'-L+2}), \mathbf{x}(i_{n'-L+3}), \dots, \mathbf{x}(i_{n'})] \quad (19)$$

式 (17) 可写为 $X_n^L = [\mathbf{x}(i_{n'-L+1}), Y_{n,n+1}^L]$, 式 (18) 可写为 $X_{n+1}^L = [Y_{n,n+1}^L, \mathbf{x}(n+1)]$. 由式 (19) 所示矩阵 $Y_{n,n+1}^L$ 中各个采样数据得到的均值向量为

$$\mathbf{y}_{n,n+1}^L = \frac{1}{L-1} Y_{n,n+1}^L \mathbf{i}_n \quad (20)$$

其中, $\mathbf{i}_n = [1, 1, \dots, 1]^T \in \mathbf{R}^{(L-1) \times 1}$. 若记

$$K_n^L = X_n^L (X_n^L)^T = \mathbf{x}(i_{n'-L+1}) \mathbf{x}(i_{n'-L+1})^T + Y_{n,n+1}^L (Y_{n,n+1}^L)^T \quad (21)$$

则 n 时刻的局部协方差矩阵为

$$R_n^L = \frac{K_n^L}{L-1} - \frac{L \mathbf{b}_n^L (\mathbf{b}_n^L)^T}{L-1} \quad (22)$$

其中, \mathbf{b}_n^L 为 n 时刻的均值向量, 有:

$$\mathbf{b}_n^L = \frac{(L-1) \mathbf{y}_{n,n+1}^L + \mathbf{x}(i_{n'-L+1})}{L} \quad (23)$$

类似地, 若记 $K_{n+1}^L = X_{n+1}^L (X_{n+1}^L)^T$, \mathbf{b}_{n+1}^L 为式 (18) 所示矩阵 X_{n+1}^L 中各个采样数据得到的均值向量, 则 $n+1$ 时刻的局部协方差矩阵为

$$R_{n+1}^L = \frac{K_{n+1}^L}{L-1} - \frac{L \mathbf{b}_{n+1}^L (\mathbf{b}_{n+1}^L)^T}{L-1} \quad (24)$$

其中, 矩阵 K_{n+1}^L 和向量 \mathbf{b}_{n+1}^L 可分别表示为

$$K_{n+1}^L = Y_{n,n+1}^L (Y_{n,n+1}^L)^T + \mathbf{x}(n+1) \mathbf{x}(n+1)^T = K_n^L + \mathbf{x}(n+1) \mathbf{x}(n+1)^T - \mathbf{x}(i_{n'-L+1}) \mathbf{x}(i_{n'-L+1})^T \quad (25)$$

$$\mathbf{b}_{n+1}^L = \frac{(L-1) \mathbf{y}_{n,n+1}^L + \mathbf{x}(n+1)}{L} = \mathbf{b}_n^L + \frac{\mathbf{x}(n+1) - \mathbf{x}(i_{n'-L+1})}{L} \quad (26)$$

将式 (22)、式 (25)、式 (26) 代入式 (24) 可得:

$$R_{n+1}^L = R_n^L + \frac{[\mathbf{Lb}_n^L - \mathbf{x}(n+1)] [\mathbf{Lb}_n^L - \mathbf{x}(n+1)]^T}{L(L-1)} - \frac{[\mathbf{Lb}_n^L - \mathbf{x}(i_{n'-L+1})] [\mathbf{Lb}_n^L - \mathbf{x}(i_{n'-L+1})]^T}{L(L-1)} + \frac{\mathbf{x}(n+1) \mathbf{x}(n+1)^T - \mathbf{x}(i_{n'-L+1}) \mathbf{x}(i_{n'-L+1})^T}{L} - \frac{[\mathbf{x}(n+1) - \mathbf{x}(i_{n'-L+1})] [\mathbf{x}(n+1) - \mathbf{x}(i_{n'-L+1})]^T}{L(L-1)} \quad (27)$$

基于局部采样数据信息的局部信息增量矩阵为

$$D_{n+1}^L = R_{n+1}^L - R_n^L = \frac{[\mathbf{Lb}_n^L - \mathbf{x}(n+1)] [\mathbf{Lb}_n^L - \mathbf{x}(n+1)]^T}{L(L-1)} - \frac{[\mathbf{Lb}_n^L - \mathbf{x}(i_{n'-L+1})] [\mathbf{Lb}_n^L - \mathbf{x}(i_{n'-L+1})]^T}{L(L-1)} + \frac{\mathbf{x}(n+1) \mathbf{x}(n+1)^T - \mathbf{x}(i_{n'-L+1}) \mathbf{x}(i_{n'-L+1})^T}{L} - \frac{[\mathbf{x}(n+1) - \mathbf{x}(i_{n'-L+1})] [\mathbf{x}(n+1) - \mathbf{x}(i_{n'-L+1})]^T}{L(L-1)} \quad (28)$$

基于局部采样数据信息的局部信息增量均值为

$$\gamma_{n+1}^L = \frac{\sum_{i=1}^p \sum_{j=1}^p |D_{n+1}^L [i, j]|}{p^2} \quad (29)$$

是否有故障发生的判定过程如下:

1) 若系统的动态阈值为 σ_{n+1}^L , 当 $\gamma_{n+1}^L \geq 3\sigma_{n+1}^L$ 时, 则表示系统已有故障发生.

此时, 记 γ_{n+1}^L 为 $^* \gamma_{n+1}^L$. 由于该 $n+1$ 时刻发生了故障, 也就是表示已发生的故障存在于数据 $\mathbf{x}(n+1)$ 中, 记 $\mathbf{x}(n+1)$ 为 $\mathbf{x}^*(j_{m'+1})$. 为了继续检测与更新, 在下一步计算局部信息增量均值 γ_{n+1}^L 时, 不应再包含已发生故障的采样数据 $\mathbf{x}^*(j_{m'+1})$, 需将 $\mathbf{x}(n+1)$ 从 X_{n+1}^L 中去除. 同时, 应当对相关参数进行重新更新标记, 如 $X_{n+1}^L = X_n^L$, $K_{n+1}^L = K_n^L$, $R_{n+1}^L = R_n^L$. 特别要指出的是, 在 $n+1$ 时刻发生故障的情况下, 在 $n+2$ 时刻的采样数据 $\mathbf{x}(n+2)$ 到

来后,形成的相应局部数据矩阵为

$$X_{n+2}^L = [\mathbf{x}(i_{n'-L+2}), \mathbf{x}(i_{n'-L+3}), \dots, \mathbf{x}(i_{n'}), \mathbf{x}(n+2)] \quad (30)$$

记发生故障时刻的局部信息增量均值 $^*\gamma^L$ 下标全体集合为 $\Omega(n+1) = \{l | ^*\gamma_l^L\}$, $|\Omega|$ 为该集合中元素的数目. 记发生故障时刻的局部信息增量均值全体为 $\{^*\gamma_{j_1}^L, \dots, ^*\gamma_{j_k}^L, \dots, ^*\gamma_{j_{m'+1}}^L\}$, 且下标满足 $\{j_1, \dots, j_k, \dots, j_{m'+1}\} \subseteq \{1, 2, \dots, n+1\}$. 记未发生故障时刻的局部信息增量均值为 $\{\gamma_{i_1}^L, \dots, \gamma_{i_k}^L, \dots, \gamma_{i_{n'}}^L\}$, 且满足 $\{i_1, i_2, \dots, i_k, \dots, i_{n'}\} \subseteq \{1, 2, \dots, n+1\}$.

$$\{i_1, i_2, \dots, i_k, \dots, i_{n'}\} \cup \{j_1, j_2, \dots, j_k, \dots, j_{m'+1}\} = \{1, 2, \dots, n+1\} \quad (31)$$

基于固定窗口的长度为 L 的局部正常采样数据动态阈值为

$$\sigma_{n+1}^L = \frac{1.5}{L} \sum_{k=n'-L+1}^{n'} \gamma_{i_k}^L \quad (32)$$

2) 当 $\gamma_{n+1} < 3\sigma_{n+1}$ 时, 则表示系统没有故障发生, 继续采样后, 再利用步骤 1) 进行检测.

注 3. 算法 1 和算法 2 的初始值选择或初始若干步算法执行如下:

1) 算法 1 中, 要求采样 $n > 3$, 且前 3 个时刻采样数据正常. 对于前 3 个时刻数据的 R 、 D 和 γ 的计算为由 $[\mathbf{x}(1), \mathbf{x}(2)]$ 和 $[\mathbf{x}(1), \mathbf{x}(2), \mathbf{x}(3)]$ 分别求出协方差矩阵 R_2 和 R_3 , 从而计算出 D_3 和 γ_3 . 因此可得前 3 个时刻 $\gamma \{\gamma_1, \gamma_2, \gamma_3\}$, 其中 $\gamma_1 = \gamma_2 = 0$. 在计算阈值 σ_{n+1} 时, n' 指 n 时刻的非正常数据的标号. 若异常的数据较多使得 $n' - \left\lfloor \frac{n+1}{2} - 1 \right\rfloor + 1 < 0$ 时, 在计算动态阈值时则用所有正常状态下的 γ .

2) 算法 2 中, 要求采样数目为 $n (n > L + 2)$, 且假设前 $L + 2$ 个时刻采样数据为正常. 对于前 $L + 2$ 个时刻数据的 R^L 、 D 和 γ 的计算为由 $[\mathbf{x}(1), \mathbf{x}(2)]$ 和 $[\mathbf{x}(1), \mathbf{x}(2), \mathbf{x}(3)]$ 分别求出协方差矩阵 R_2^L 和 R_3^L , 从而求出 D_3^L 和 γ_3^L . 同理可由 $[\mathbf{x}(1), \mathbf{x}(2), \mathbf{x}(3)]$ 和 $[\mathbf{x}(1), \mathbf{x}(2), \mathbf{x}(3), \mathbf{x}(4)]$ 求出协方差矩阵 R_3^L 和 R_4^L , 从而求出 D_4^L 和 γ_4^L . 依此类推, 可以计算出 γ_5^L 至 γ_{L+2}^L . 从而可得前 $L + 2$ 个时刻的 $\gamma^L \{\gamma_1^L, \gamma_2^L, \gamma_3^L, \dots, \gamma_{L+2}^L\}$, 其中 $\gamma_1^L = \gamma_2^L = 0$, 这样保证正常的 γ^L 的个数为 L , 同时也保证了正常采样数据的长度为 L . 在选取动态阈值时, σ_{n+1}^L 中的 n' 指 n 时刻的非正常数据的标号. 当 n 不大于 $L + 2$ 且正常 γ^L 的个数小于 L 时, 计算阈值时使用小于 L 的所有正常状态下的 γ^L .

注 4. 基于局部数据的移动窗口协方差矩阵的信息增量矩阵故障诊断方法具有固定大小的采样数据窗口以及固定的阈值窗口, 不仅使更新协方差矩阵时数据有效减小, 而且也因所获取的动态阈值是基于靠近当前时刻的数据计算出来的, 所以更具代表性, 从而有望降低系统的误报率. 因此, 无论是使用第 1.1 节介绍的基于全局协方差矩阵的信息增量矩阵故障诊断方法^[11], 还是使用第 1.2 节建立的基于局部数据的移动窗口协方差矩阵的信息增量矩阵故障诊断方法, 都可以对被采样的系统是否发生故障进行判定. 但当已判定被采样系统发生故障后, 如何能判定故障源于哪一个变量或哪几个变量, 本节提供的两种方法都不具备这样的能力. 下一节引入的基于贡献率的故障诊断方法将弥补本节提供的两种方法的不足.

1.3 新息贡献率

为解决第 1.1 节和第 1.2 节提供的两种方法虽然具有能判定被采样系统是否发生了故障的能力, 但仍然存在不能进一步判定源于具体变量的不足, 我们先引入新息贡献率的概念. 无论是第 1.1 节定义的信息增量矩阵 D_{n+1} , 还是第 1.2 节引入的局部信息增量矩阵 D_{n+1}^L , 它们反映的都是当新的采样数据 $\mathbf{x}(n+1)$ 到来后, 相对由 $\mathbf{x}(n)$ 及其以前的全部或部分采样数据形成的数据 R_n 或者 R_n^L , 又提供了哪些新的信息; 因此也可以称信息增量矩阵 D_{n+1} 和局部信息增量矩阵 D_{n+1}^L 为新息矩阵. 根据这种思想, 基于新息增量矩阵 D_{n+1} 和局部信息增量矩阵 D_{n+1}^L 分别定义相应的新息贡献率如下:

$$P(i) = \frac{\left| \sum_{j=1}^p D[i, j] \right|}{\sum_{j=1}^p \sum_{k=1}^p |D[j, k]|} \quad (33)$$

$$P^L(i) = \frac{\left| \sum_{j=1}^p D^L[i, j] \right|}{\sum_{j=1}^p \sum_{k=1}^p |D^L[j, k]|} \quad (34)$$

通过式 (33) 和式 (34) 分别判断算法 1 和算法 2 中各变量对总体的贡献率, 从而识别引起故障的变量. 但在某些情况下, 由于变量之间的相关性, 会同时出现几个 $P(i)$ 或 $P^L(i)$ 较大, 对于这种情况, 可以对其进行进一步的检测:

$$P(i, j) = \frac{|D[i, j]|}{\left| \sum_{j=1}^p D[i, j] \right|} \quad (35)$$

可以判断出由哪几个变量共同作用, 从而更好地识别故障.

注 5. 在本文介绍的方法中, 一方面, 基于全局协方差矩阵的信息增量矩阵故障诊断方法和基于局部数据的移动窗口协方差的信息增量矩阵故障诊断方法都可以用来检测系统是否发生故障, 完成传统 PCA 的检测功能. 另一方面, 在检测系统已发生故障的情况下, 基于本节介绍的新息贡献率方法, 判定已发生的故障源于原始系统中的哪个或哪几个变量. 从而克服了传统 PCA 只能用于检测系统是否已发生故障, 却不能判定已发生故障源于原始系统中的哪个或哪几个变量的不足.

2 仿真

为了验证上述方法的有效性, 考虑随机变量及其线性组合构建 6 个系统变量如下:

$$\begin{cases} \mathbf{x}_1 = 0.1 \times \text{randn}(1, n) \\ \mathbf{x}_2 = 0.2 \times \text{randn}(1, n) \\ \mathbf{x}_3 = 0.3 \times \text{randn}(1, n) \\ \mathbf{x}_4 = -1.3\mathbf{x}_1 + 0.2\mathbf{x}_2 + 0.8\mathbf{x}_3 \\ \mathbf{x}_5 = \mathbf{x}_2 - 0.3\mathbf{x}_3 \\ \mathbf{x}_6 = \mathbf{x}_1 + \mathbf{x}_3 \end{cases} \quad (36)$$

其中, $\text{randn}(1, n)$ 是用 Matlab 产生的 1 行 n 列的随机数. 对于 PCA, 选取 1000 个正常数据建立主元模型; 再选取 1000 个样本作为测试数据, 对测试数据中的变量 \mathbf{x}_6 后 200 个样本点引入幅值为 3.2 的恒偏差故障, 分别用模型进行检测. 以平方预测误差 (Squared prediction error, SPE) 和 T^2 为指标衡量 PCA 的误报和漏报个数, 算法 1 与算法 2 直接用 PCA 引入偏差后的数据进行建模及检测, 取固定窗口长度 $L = 30$.


经过 10 次仿真统计得到 PCA 和算法 1^[11] 以及算法 2 的平均误报和漏报次数, 如表 1 所示.

表 1 检测结果
Table 1 Detection result


	PCA 的 SPE	PCA 的 T^2	算法 1 ^[11]	算法 2
误报个数	46	37	16	7
漏报个数	0	18	0	0

检测时, 1~800 时刻超过控制限时为误报, 801~1000 时刻低于控制限时则为漏报. 由图 1 和表 1 可知, 用 PCA 方法存在大量的误报和漏报的现象, 图 1(c) 是用 PCA 方法得到的各变量的贡献率, 由图可知是由变量 6 引起的异常, 图 2(a) 是算法 1 检测结果图, 误报和漏报的个数较少. 图 2(b)


是算法 1 中各变量的贡献率, 从图中可以看出变量 6 引起异常, 算法 1 也能够很好地诊断出故障. 图 3 是本文方法的故障检测图和贡献率图, 可知误报的个数相对算法 1 减少. 算法 1 出现误报数目较多, 是因为随着采样数据的长度增大, 在计算阈值时正常状态下的 γ 值数目也会增多, 而很靠前的 γ 对系统影响不是太大, 所以误报数目较多.



(a) PCA 的 SPE 图
(a) SPE chart for PCA




(b) PCA 的 T^2 图
(b) T^2 chart for PCA

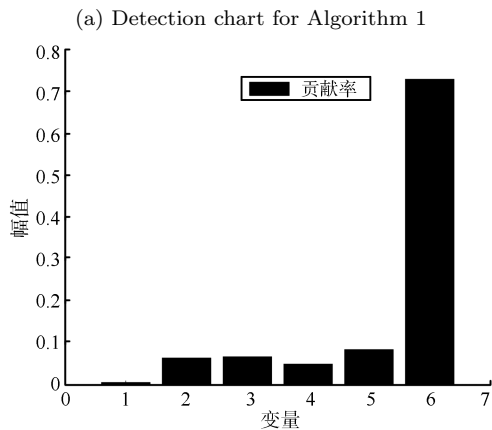


(c) PCA 的贡献率图
(c) Contribution chart for PCA

图 1 PCA 方法在 801~1000 时刻加故障检测图
Fig. 1 Detection chart with fault added at time 801~1000 using PCA method



(a) 算法 1 的检测图



(b) 算法 1 的贡献率图

(b) Contribution chart for Algorithm 1

图 2 算法 1 在 801~1000 时刻加故障诊断图

Fig. 2 Diagnosis chart with fault added at time 801~1000 using Algorithm 1

现考虑系统中在某段时间内发生异常, 然后又恢复正常的情况下, 验证该方法是否能有效检测异常. 仿真数据用式 (36) 的随机变量及其线性组合构建 6 个变量, 对于 PCA 选取 1000 个正常数据建立主元模型; 再选取 1000 个样本作为测试数据, 对测试数据的变量 x_6 的 801~900 时刻的样本点引入幅值为 3.2 的恒偏差故障, 分别用模型进行检测. 算法 1 与算法 2 直接用 PCA 引入偏移后的数据进行建模及检测. 取固定窗口长度 $L = 30$.

经过 10 次仿真统计得到 PCA、算法 1 和算法 2 的故障诊断的平均误报和漏报次数, 如表 2 所示.


表 2 检测结果

Table 2 Detection results


	PCA 的 SPE	PCA 的 T^2	算法 1 ^[11]	算法 2
误报个数	45	43	15	8
漏报个数	0	6	0	0

由图 4 和表 2 可知, PCA 的 SPE 图存在大量

的误报现象, T^2 图存在大量的误报和漏报现象, 由图 5 (a) 和表 2 可知, 算法 1 方法较 PCA 存在较少的误报和漏报现象. 图 5 (b) 是算法 1 的各变量贡献率的大小, 可知变量 6 引起异常, 与实际给定相符合. 图 6 是本文方法的故障检测图和诊断图. 由表 2 可知误报的个数相对算法 1 减少. 综上, 两个仿真实验表明, 本文方法较算法 1 以及 PCA 方法误报数较少, 这是因为本文方法在更新协方差时所用采样数据较算法 1 靠近当前数据较多, 去除那些距离当前数据较远的的数据; 在计算阈值时用固定窗口的长度, 更具有代表性, 从而减少了误报数目.



(a) 算法 2 的检测图



(b) 算法 2 的贡献率图

(b) Contribution chart for Algorithm 2


图 3 算法 2 在 801~1000 时刻加故障诊断图

Fig. 3 Diagnosis chart with fault added at time 801~1000 using Algorithm 2


3 结论

PCA 方法在故障诊断中存在着严重模式复合的作用, 且采样数据要服从正态分布, 存在大量的误报漏报现象. 针对此问题, 文献 [11] 给出了基于全局数据的协方差矩阵的信息增量矩阵方法, 不仅没有对采样数据服从正态分布的要求, 而且还能较好地实现故障识别以及降低误报率. 但是随着采样数据


的增多, 前面数据不具有代表性, 影响阈值的更新以及计算阈值方法的计算量大, 也影响着误报率. 针对这一问题, 本文给出了基于局部数据的移动窗口协方差矩阵的信息增量矩阵方法, 在更新协方差矩阵时所用数据的长度固定, 计算阈值时窗口固定, 使数据更具有代表性, 同时也使得阈值的计算量减小, 从而减少了误报率. 通过仿真验证了该方法的有效性.



(a) SPE chart for PCA




(b) T² chart for PCA




(c) Contribution chart for PCA

图 4 PCA 方法在 801~900 时刻加故障检测图
Fig. 4 Detection chart with fault added at time 801~900 using PCA method

但是当系统变量维数较大时, 本文方法同样会遇到大矩阵运算的困难. 因而, 如何能有效地将 PCA 方法在高维数据降维方面的功能与本文引入并新建的方法在检测方法的优势有效地结合起来, 将是一个有意义的研究课题.




(a) Detection chart for Algorithm 1

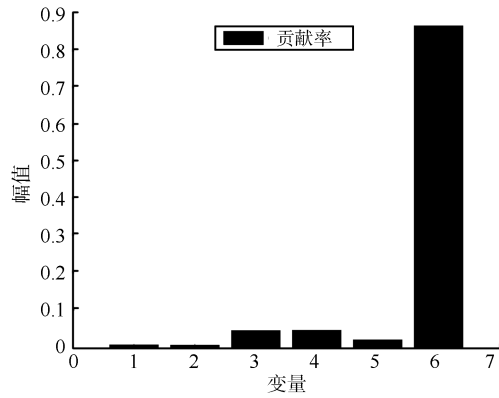


(b) Contribution chart for Algorithm 1

图 5 算法 1 在 801~900 时刻加故障诊断图
Fig. 5 Diagnosis chart with fault added at time 801~900 using Algorithm 1



(a) Detection chart for Algorithm 2



(b) 算法 2 的贡献率图

(b) Contribution chart for Algorithm 2

图 6 算法 2 在 801~900 时刻加故障诊断图

Fig. 6 Diagnosis chart with fault added at time 801~900 using Algorithm 2

References

- 1 Kano M, Nakagawa Y. Data-based process monitoring, process control, and quality improvement: Recent developments and applications in steel industry. *Computers and Chemical Engineering*, 2008, **32**(1-2): 12-24
- 2 Zhang Ping, Wang Gui-Zeng, Zhou Dong-Hua. Fault diagnosis methods for dynamic systems. *Control Theory and Applications*, 2000, **17**(2): 153-158
(张萍, 王桂增, 周东华. 动态系统的故障诊断方法. 控制理论与应用, 2000, **17**(2): 153-158)
- 3 Zhou Dong-Hua, Hu Yan-Yan. Fault diagnosis techniques for dynamic systems. *Acta Automatica Sinica*, 2009, **35**(6): 748-758
(周东华, 胡艳艳. 动态系统的故障诊断技术. 自动化学报, 2009, **35**(6): 748-758)
- 4 Venkatasubramanian V, Rengaswamy R, Kavuri S N. A review of process fault detection and diagnosis: part II: qualitative models and search strategies. *Computers and Chemical Engineering*, 2003, **27**(3): 313-326
- 5 Li Han, Xiao De-Yun. Survey on data driven fault diagnosis methods. *Control and Decision*, 2011, **26**(1): 1-9
(李晗, 萧德云. 基于数据驱动的故障诊断方法综述. 控制与决策, 2011, **26**(1): 1-9)
- 6 Liu Qiang, Chai Tian-You, Qin Si-Zhao, Zhao Li-Jie. Progress of data-driven and knowledge-driven process monitoring and fault diagnosis for industry process. *Control and Decision*, 2010, **25**(6): 801-807


(刘强, 柴天佑, 秦泗钊, 赵立杰. 基于数据和知识的工业过程监视及故障诊断综述. 控制与决策, 2010, **25**(6): 801-807)

- 7 Alcalá C F, Qin S J. Analysis and generalization of fault diagnosis methods for process monitoring. *Journal of Process Control*, 2011, **21**(3): 322-330
- 8 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研究. 自动化学报, 2008, **34**(9): 1128-1139)
- 9 Zhou Fu-Na, Wen Cheng-Lin, Tang Tian-Hao, Chen Zhi-Guo. DCA based multiple faults diagnosis method. *Acta Automatica Sinica*, 2009, **35**(7): 971-982
(周福娜, 文成林, 汤天浩, 陈志国. 基于指定元分析的多故障诊断方法. 自动化学报, 2009, **35**(7): 971-982)
- 10 Zhou Fu-Na, Wen Cheng-Lin, Chen Zhi-Guo, Leng Yuan-Bao. DCA based multi-level small fault diagnosis method. *Acta Electronica Sinica*, 2010, **38**(8): 1874-1879
(周福娜, 文成林, 陈志国, 冷元宝. 基于指定元分析的多级相对微小故障诊断方法. 电子学报, 2010, **38**(8): 1874-1879)
- 11 Yang H Y. Advanced Prognosis and Health Management of Aircraft and Spacecraft Subsystems [Master dissertation], Massachusetts Institute of Technology, Massachusetts, 2000



文成林 博士, 杭州电子科技大学教授. 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** Ph.D., professor at Hangzhou Dianzi University. 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. Corresponding author of this paper.)



胡玉成 杭州电子科技大学硕士研究生. 主要研究方向为故障诊断.

E-mail: huyucheng2009@163.com

(**HU Yu-Cheng** Master student at Hangzhou Dianzi University. His main research interest is fault diagnosis.)