

文章编号:1000-582X(2010)06-128-05

在线多尺度滤波多变量统计过程的适时监测

胡友强, 柴毅, 李鹏华

(重庆大学自动化学院, 重庆 400030)

摘要:在详细分析现有 MSPCA 模型不足的基础上,借助在线多尺度滤波(OLMS),提出了一种多变量统计过程的在线监测方法,并将其应用于传感器故障诊断。该方法中,首先在固定窗长的数据窗口内用边缘校正滤波器对信号进行小波分解,然后用小波阈值滤波对分解的小波系数进行消噪,并借助该固定窗长的移动窗口将小波变换和自适应 PCA 结合起来对数据进行在线多尺度建模,从而避免了直接对信号进行消噪所造成的时间浪费,提高了故障诊断率。最后以 6135D 型柴油机在严重漏气下的 8 个振动信号的故障诊断为例进行故障分析,结果表明了所提方法的可行性和实用性。

关键词:快速离散小波变换;在线多尺度滤波;多尺度分析;自适应主元分析

中图分类号: TP277

文献标志码: A

Real-time monitoring for multivariate statistical process with on-line multiscale filtering

HU You-qiang, CHAI Yi, LI Peng-hua

(College of Automation, Chongqing University, Chongqing 400044, P. R. China)

Abstract: By analyzing shortages of current MSPCA model, an on-line multi-variable statistical process monitoring method is proposed, which uses some concepts from online multi-scale filtering and can be applied to sensor fault diagnosis. In the method, wavelet decomposition is employed to the signals using edge correction filter in a fixed-length data window, and then wavelet denoising is conducted with wavelet threshold filtering. Next, an on-line multi-scale model is constructed for data combining wavelet transformation and adaptive PCA in the previous data window. This model avoids time waste in direct signal denoising and reduces time cost in multi-scale data with conventional PCA, which eventually increases accuracy in fault diagnosis. Experiments on eight vibration signals of 6135D diesel engine under severe leak condition prove the practicability and feasibility of the proposed method.

Key words: fast discrete wavelet transformation; online multiscale filtering; multiscale analysis; adaptive PCA

复杂工业系统故障诊断是一个动态过程,该过程由于受到各种事件的干扰和不同时频特征的影响,往往具有复杂的多尺度特性和非线性特性。作为一种成熟的多尺度统计过程监测方法, Bakshi^[1]所提出的多尺度主元分析(MSPCA)对于这种具有

多种变化特征的动态过程具有更强的普适性^[2],近年来:如多尺度主元分析结合滑动中值滤波^[3]及小波包变换^[4-7]的研究;针对多分辨率及不确定性情况的研究^[8-10];结合支持向量机的 MSPCA 研究^[11-12]等一直是国内外学者关注研究的热点。

收稿日期: 2010-02-03

基金项目: 国家自然科学基金资助项目(60974090);教育部博士点基金资助项目(200806110021)

作者简介: 胡友强(1977-),男,重庆大学博士生,主要从事基于数据驱动的故障诊断方向的研究。

柴毅(1962-),男,重庆大学教授,博士生导师,(Tel)023-65106464;(Email)chaiyi@cqu.edu.cn。

工业过程中,信号降噪是不可或缺的一环。传统的线性滤波方法由于其单尺度性,存在保护信号的局部特性与抑制噪声之间的矛盾,而且实际过程中这种滤波方法必须以模型的可知性为前提。小波变换具有对信号进行时频分析、聚焦信号局部特征和时变滤波等特点,因而能有效地解决这一问题^[13]。而当采用小波来消噪,再用 MSPCA 来处理消噪后的信号时,就出现一个实际问题:首先,小波消噪对数据进行了一次小波分解和重构,而其后 MSPCA 又进行了小波分解和重构,这明显是一种步骤上的重叠,造成时间上的浪费。另外,若采用快速 DWT 对信号进行小波分解,然后对分解后的小波系数进行阈值滤波,尽管可以节约时间,但是这不可避免地造成了边缘效应。

为此,提出一种基于在线多尺度滤波的多变量统计过程在线监测方法。通过在线多尺度滤波中的边缘校正滤波器来克服快速 DWT 带来的边缘效应,然后对分解的小波系数进行阈值消噪,并借助固定窗长的移动窗口将小波变换和自适应 PCA 有机结合起来对数据进行在线多尺度建模,从而避免了直接对信号进行消噪所造成的时间浪费,提高了故障诊断效率。

1 信号多尺度分析

1.1 DWT 快速算法

具有多尺度特征的信号可以用小波基函数的加权来表示,任何一个平方可积信号都可分解为一族小波函数和尺度函数。对一个为二进长度 $N=2^{J_0}$ 的离散信号序列 X ,其低频部分可由标准正交的尺度函数来表征,即

$$\Phi_{m,k}(t) = 2^{-m/2} \Phi(2^{-m}t - k)。 \quad (1)$$

X 的高频部分可用标准正交的小波函数来表征,即

$$\Psi_{m,k}(t) = 2^{-m/2} \Psi(2^{-m}t - k)。 \quad (2)$$

式中 m 是扩张参数, k 是平移参数。按照多尺度理论,该信号可表示为

$$x(t) = \sum_{k=1}^{n_2^{-L}} a_{Lk} \Phi_{Lk}(t) + \sum_{m=1}^L \sum_{k=1}^{n_2^{-m}} d_{mk} \Psi_{mk}(t)。 \quad (3)$$

式中 a_{Lk} 是最粗尺度 L 上第 k 个尺度函数 $\Phi_{Lk}(t)$ 的尺度系数, d_{mk} 是第 m 层上第 k 个小波函数 $\Psi_{mk}(t)$ 的小波系数。

以上尺度函数 $\Phi_{Lk}(t)$ 和小波函数 $\Psi_{mk}(t)$ 可通过构造正交滤波器组(H, G)得到,而相应的尺度系数 a_{Lk} 及小波函数系数 d_{mk} 可由信号与相关滤波器的卷积获得,即

$$a_j = H_j X, d_j = G_j X。 \quad (4)$$

其中,各滤波器的传递函数满足 $H_j = \prod_{k=1}^j H^k X$, $G_j = G^j \prod_{k=1}^{j-1} H^k$ 。

1.2 在线多尺度滤波(OLMS)算法

由 R. Bakshi^[13] 教授等人所提出的在线多尺度滤波(OLMS)算法,其核心思想是通过在一个移动的数据窗口内应用小波阈值滤波以达到降低随机噪声水平的目的。与离线小波滤波相比,在线多尺度滤波有 2 个重要特点:即二进长度的滑动窗口和具有因果关系的边缘校正滤波器。从而避免了一般小波滤波器存在的时间迟滞,且消除了滤波过程中存在的边缘效应。OLMS 算法的具体步骤为

- 1) 在长度为 2^n (n 为正整数)的窗口范围内用边缘校正滤波器对测量数据进行小波分解;
- 2) 应用公式 $T = \sigma \sqrt{2 \ln(n)}$ 对小波系数进行阈值处理和并重构信号;
- 3) 保留重构后的最后一个数据点,以备其他在线使用;
- 4) 当接收到新的数据时,移动窗口以包含最新的数据,同时保证是最大的 2^n 长度,当 n 到达要求值时,保持不变。

在线多尺度故障检测是在线多尺度滤波思想的基础上利用边缘校正滤波器对信号进行分解,通过公式 $T = \sigma \sqrt{2 \ln(n)}$ 对小波系数进行消噪,这样既克服了边缘效应又消除了数据的噪声污染。其中,边缘校正滤波器的设计可分别由式(5)与式(6)得到。将式(4)中的矩阵 H_j 和 G_j 行交替放置后,可分别合并成一个右无限的 Toeplitz 矩阵 T_1 与左无限的 Toeplitz 矩阵 T_2

$$T_1 = \begin{bmatrix} A_0 & A_1 & \cdots & \cdots & A_{K-1} & 0 & 0 & \cdots \\ 0 & A_0 & A_1 & \cdots & \cdots & A_{K-1} & 0 & \cdots \\ 0 & 0 & A_0 & A_1 & \cdots & \cdots & A_{K-1} & \cdots \\ \vdots & \ddots \end{bmatrix}。 \quad (5)$$

$$T_2 = \begin{bmatrix} \ddots & \vdots \\ \cdots & A_0 & A_1 & \cdots & \cdots & A_{K-1} & 0 & 0 \\ \cdots & 0 & A_0 & A_1 & \cdots & \cdots & A_{K-1} & 0 \\ \cdots & 0 & 0 & A_0 & A_1 & \cdots & \cdots & A_{K-1} \end{bmatrix}。 \quad (6)$$

其中每个子块

$$A_i = \begin{bmatrix} h_0(2i) & h_0(2i+1) \\ g_0(2i) & g_0(2i+1) \end{bmatrix}, i = 0, 1, \cdots, K-1。$$

是 2×2 阶的,共有 $K=N/2$ 个非零子块, N 为滤波器长度(偶数), h_0 和 g_0 分别为相应的冲击响应。

对于式(5)和式(6),其非零元素取自于完全重构的正交的 2 通道滤波器组^[14-15],当滤波器长度为 $N=2K$,则正交于 T_1 和 T_2 的所有行向量至多在其头 $2K-2$ 个位置上有非零值。为了使 T_1 和 T_2 的行

形成一组基,还需添加 $(N-2)/2$ 个这样的行。这些要添加的行可由 Gram-Schmidt 正交化算法求得。最后得到的矩阵 \mathbf{T}_1 是一个正交矩阵,它的行形成右半无限序列空间的一组正交基。一般称添加的行向量为左边界向量,其非零元素部分称为左边界滤波器。类似的可得到 \mathbf{T}_2 ,其非零元素部分称为右边界滤波器。

2 多尺度故障检测方法

在线多尺度故障检测方法,关键在于每个尺度上都采用递推 PCA 算法并随着模型的更新,更新主元及控制限。本节将从自适应 PCA 算法及主元及控制限的选取说明多尺度故障检测方法。

2.1 自适应 PCA 算法

设原始数据为 $X_k \in \mathbf{R}^{n \times m_k}$,其中 n 为变量个数, m_k 为 n 个变量采样点个数,将 X_k 标准化可得

$$\mathbf{X}_k^1 = [X_k - \overline{X_k} \mathbf{I}_{m_k}] \mathbf{S}_k^{-1}. \quad (7)$$

其中,数据矩阵每一行均值 $\overline{X_k}$ 和数据矩阵标准差 S_k 分别为

$$\overline{X_k} = \frac{1}{m_k} X_k \mathbf{I}_{m_k}^T, \quad (8)$$

$$S_k = \text{diag}(s_{k1}, s_{k2}, \dots, s_{kn}). \quad (9)$$

$$s_{ki} = \sqrt{\frac{1}{m_k} \sum_{k=1}^{m_k} [x_i(k) - \overline{x_k}(i)]^2}, i = 1, 2, \dots, n. \quad (10)$$

$$\mathbf{I}_{m_k} = [1 \cdots 1] \in \mathbf{R}^{m_k}. \quad (11)$$

标准化矩阵的协方差矩阵为

$$\mathbf{C}_k^1 = \frac{1}{m_k - 1} \mathbf{X}_k^1 \mathbf{X}_k^{1T}. \quad (12)$$

当采样到第 $k+1$ 个数据块时,数据矩阵变为

$\mathbf{X}_{k+1} \in \mathbf{R}^{n \times m_{k+1}}$,即是 $\mathbf{X}_{k+1} = \begin{bmatrix} X_k \\ X_{k+1} \end{bmatrix}$ 。标准化的矩阵为

$$\begin{aligned} \mathbf{X}_{k+1}^1 &= [\mathbf{X}_{k+1} - \overline{X_{k+1}} \mathbf{I}_{m_{k+1}}] \mathbf{S}_{k+1}^{-1} = \\ & \begin{bmatrix} X_k - \Delta \overline{X_{k+1}} \cdot \mathbf{I}_{m_k}^T - \overline{X_k} \mathbf{I}_{m_k}^T \\ X_{k+1} - \overline{X_{k+1}} \mathbf{I}_{m_{k+1}}^T \end{bmatrix} \mathbf{S}_{k+1}^{-1} = \\ & \begin{bmatrix} \mathbf{X}_k^1 \mathbf{S}_k \mathbf{S}_{k+1}^{-1} - \Delta \overline{X_{k+1}} \cdot \mathbf{I}_{m_k}^T \mathbf{S}_{k+1}^{-1} \\ \mathbf{X}_{k+1}^1 \end{bmatrix}. \end{aligned} \quad (13)$$

其中

$$\Delta \overline{X_{k+1}} = \overline{X_{k+1}} - \overline{X_k}. \quad (14)$$

$$\overline{X_{k+1}} = \frac{\mathbf{M}_k}{M_{k+1}} \overline{X_k} + \frac{1}{M_{k+1}} \mathbf{I}_{m_{k+1}}^T \mathbf{X}_{n_{k+1}}.$$

$$\mathbf{M}_k = \sum_{j=1}^k m_j. \quad (15)$$

$$S_{k+1} = \text{diag}(s_{j1}, s_{j2}, \dots, s_{jn}), j = k, k+1. \quad (16)$$

$$\mathbf{X}_{n_{k+1}}^1 = (\mathbf{X}_{n_{k+1}} - \overline{X_{k+1}} \mathbf{I}_{n_{k+1}}^T) \mathbf{S}_{k+1}^{-1}. \quad (17)$$

标准化矩阵的协方差矩阵为

$$\mathbf{C}_{k+1}^1 = \frac{k-1}{k} \mathbf{S}_{k+1}^{-1} \mathbf{S}_k^{-1} \mathbf{C}_k^1 \mathbf{S}_k^{-1} \mathbf{S}_{k+1}^{-1} + \quad (18)$$

$$\mathbf{S}_{k+1}^{-1} \Delta \overline{X_{k+1}}^T \Delta \overline{X_{k+1}} \mathbf{S}_{k+1}^{-1} + \frac{1}{k} \mathbf{X}_{k+1}^1 \mathbf{X}_{k+1}^{1T}.$$

假设旧数据对新数据的影响少一点,则可加入

遗忘因子 $\alpha = \frac{\mathbf{M}_k}{\mathbf{M}_{k+1}}$,且协方差矩阵的变化并不剧烈,

那么协方差矩阵可变为

$$\begin{aligned} \mathbf{C}_{k+1}^1 &= \alpha (\mathbf{C}_k^1 + \mathbf{S}_{k+1}^{-1} \Delta \overline{X_{k+1}}^T \Delta \overline{X_{k+1}} \mathbf{S}_{k+1}^{-1}) + \\ & (1 - \alpha) \mathbf{X}_{k+1}^1 \mathbf{X}_{k+1}^{1T}. \end{aligned} \quad (19)$$

2.2 主元及控制限选取

选取主元常用的方法有累积方差百分比 (cumulative percent variance, CPV) 方法、交叉检验 (cross validation) 方法以及能量百分比 (energy percent) 方法等。采用 CPV 方法选取主元。它是通过计算前 n 个主元对数据变化的累积解释程度来作为选择主元的具体依据,即

$$\text{CPV}(n) = \left[\frac{\sum_i^n \lambda_i}{\sum_i^m \lambda_i} \right] \times 100\%. \quad (20)$$

实际仿真过程中,只需 CPV 到达 95% 即可,当数据更新时,相应的主元也更新。

过程监控中,通常采用 T^2 统计量和 SPE 统计量及其相应控制限来判断过程是否发生显著变化。 T^2 统计量的定义为

$$\mathbf{T}_i^2 = \sum_{j=1}^m \frac{t_{ij}^2}{s_{ij}^2}, \quad (21)$$

式中 \mathbf{T}_i^2 是第 i 行的 T^2 统计量, m 是所选得分向量个数, t_{ij} 是得分向量 t_i 第 j 行的值, s_{ij}^2 是 t_i 的估计方差。其控制限可利用 F 分布由式(22)计算

$$\mathbf{T}_{k,n,\alpha}^2 = \frac{k(n-1)}{n-k} F_{k,n-1,\alpha}, \quad (22)$$

式中 n 是主元模型的样本个数, k 是所选主元个数, α 是检验水平, $F_{k,n-1,\alpha}$ 是自由度分别为 k 和 $n-1$ 时 F 分布的临界值。当 $\mathbf{T}_i^2 > \mathbf{T}_{k,n,\alpha}^2$ 时,表示出现了故障。 Q 统计量的定义为

$$\text{SPE} = \sum_{i=1}^m (x_i(k) - \hat{x}_i(k))^2, \quad (23)$$

式中 $x_i(k)$ 为 k 时刻第 i 个变量的测量值, $\hat{x}_i(k)$ 为 k 时刻第 i 个变量的预测值。其控制限可利用正态分布由式(23)式计算

$$Q_\alpha = \theta_1 \left| \frac{C_\alpha \sqrt{2\theta_2 h_0^2}}{\theta_1} + 1 + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1^2} \right|^{\frac{1}{h_0}}, \quad (24)$$

其中 $\theta_j = \sum_{i=k+1}^m \lambda_i^j; j = 1, 2, 3, h_0 = 1 - \frac{2\theta_1 \theta_3}{3\theta_2^2}, \lambda_i$ 为 \mathbf{X} 的协方差矩阵的特征值, C_α 为正态分布在 α 检验水平下的临界值, m 为全部主元个数。 $\text{SPE} > Q_\alpha$ 时,表

示出现故障。

用 MSPCA 对过程进行在线监控时,数据更新导致模型更新,进而造成主元更新,因此,相应的控制限也需要更新。

2.3 基于 OLMS 的在线 MSPCA 方法

基于 OLMS 的线 MSPCA 方法步骤如下

1)在长度为 2^n (n 为正整数)的窗口范围内用边缘校正滤波器对测量数据进行小波分解,并应用公式(2)对各层小波系数进行阈值消噪;

2)对消噪后的小波系数在每一个尺度进行自适应主元分析,APCA 的初始数据块大小应大于或等于测量数据维数,计算小波系数的主元得分和负载向量,选择主元个数,并计算 T^2 统计量和 Q 统计量

的控制限,选取大于等于控制限的小波系数;

3)对所有尺度上侦查到显著事件的尺度进行组合,将保留的系数进行重构,从而建立参考 PCA 模型。

4)计算重构后的数据矩阵的 T^2 和 Q 得分,用 3)中得到的参考 PCA 模型判断是否出现故障,若重构数据矩阵的 T^2 和 Q 得分超过了 PCA 模型的控制限,便发出警报。

5)当接收到新的数据时,移动 1)的数据窗口,且保持窗口长度不变。然后重复 2)、3)、4)步骤。

图 1 详细说明了算法流程,其中 RDWT 代表边缘校正小波分解,WSDN 代表小波阈值消噪, M 代表相应矩阵, \bar{M} 代表处理后的矩阵,APCA 代表自适应 PCA, RDWT 和 IDWT 分别表示小波分解与小波重构。

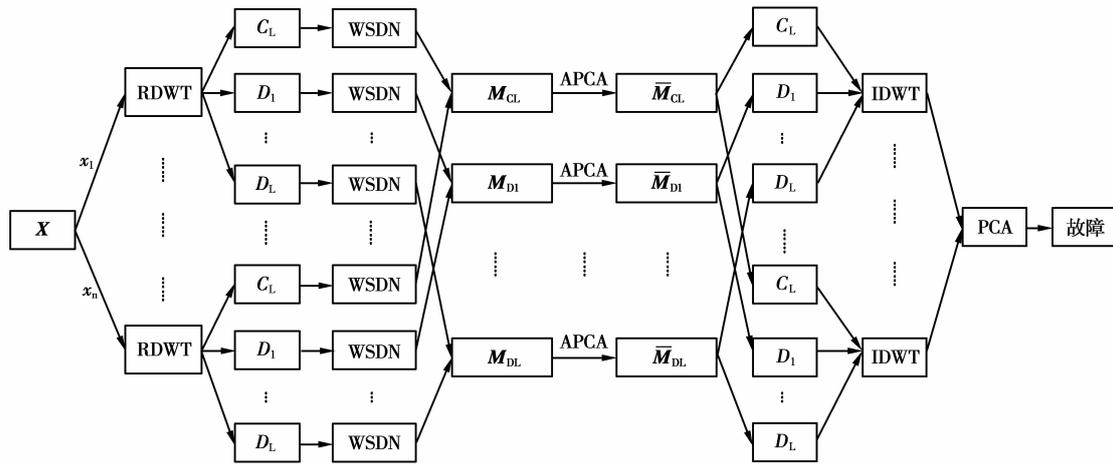


图 1 OLMS-APCA 算法流程图

3 仿真试验

为了验证上述方法的有效性,选取 6135D 型柴油机在严重漏气下的 8 个振动信号构成一个 8 变量过程。这些信号采用加速度传感器在缸盖处进行测量,其采样频率为 25 kHz。柴油机点火顺序为 1-5-3-6-2-4,信号主要对应关系为:最中间的位置为燃烧上止点,其他则为相应的对应,如进气门开、关,排气门开关等。8 个振动信号如图 2 所示:

首先选取大小为 8×256 的正常数据块按照 OLMS-APCA 算法建立主元模型,采用累积方差百分比方法进行主元的选取。其中小波分解的尺度为 $L = \log_2^2 - 5$,滑动窗口的长度为 8,自适应 PCA 选取的初始数据块大小为 8×128 , T^2 控制限和 SPE 控制限均取为 95%。

建立主元模型后,选取大小为 8×1991 的故障数据作为测试样本。下面分别给出用传统离线 MSPCA 算法、直接对小波系数进行阈值滤波的 MSPCA 算法(以下简称改进 MSPCA)和基于在线

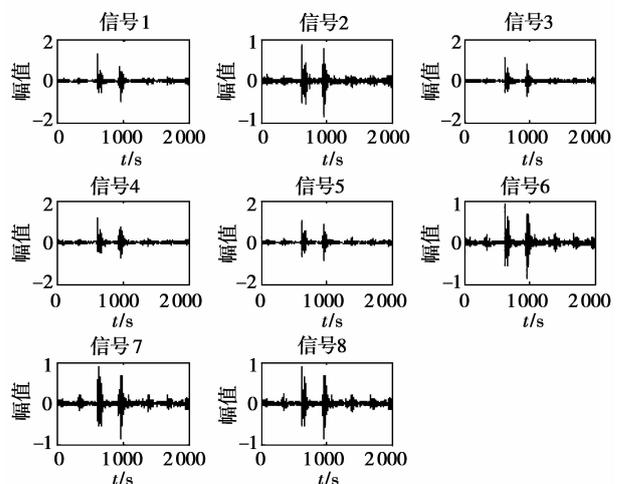


图 2 柴油机振动信号图

多尺度滤波的自适应 MSPCA 算法对 8 个振动信号诊断后得到的 SPE 图及 T^2 图。

从图 3-5 的故障诊断结果可以看出,常规 MSPCA 方法虽然可以判断出故障的发生,但在第

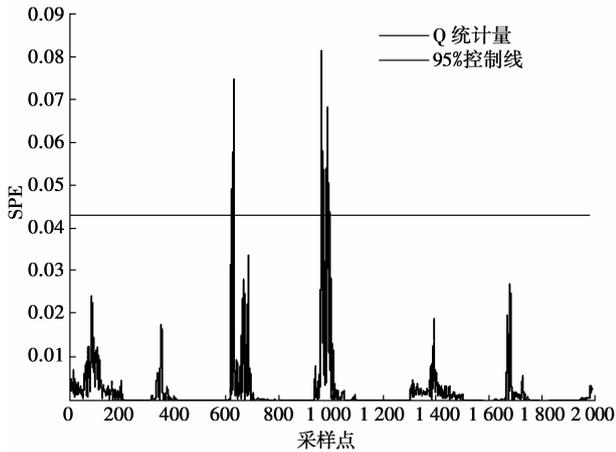


图 3 传统 MSPCA 对样本诊断的 SPE 图

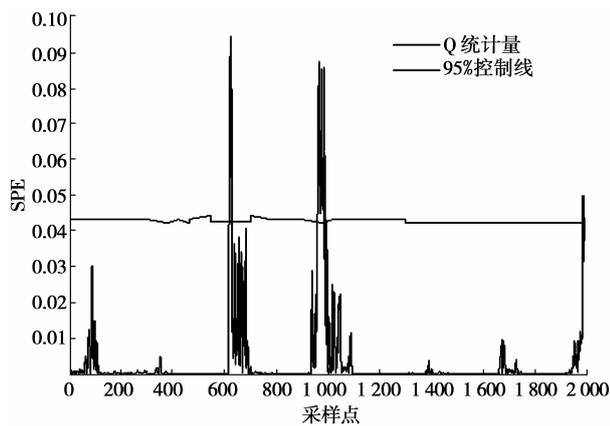


图 4 改进 MSPCA 对样本诊断的 SPE 图

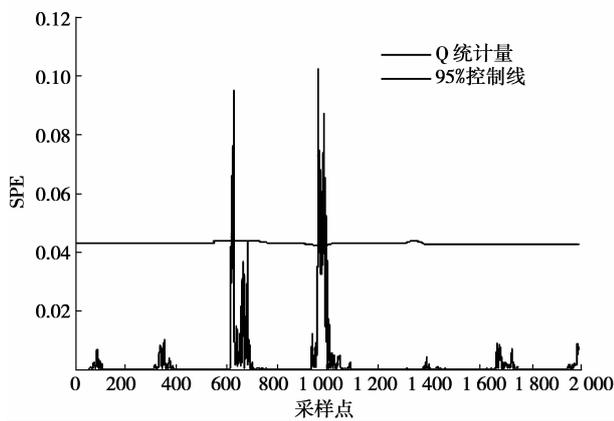
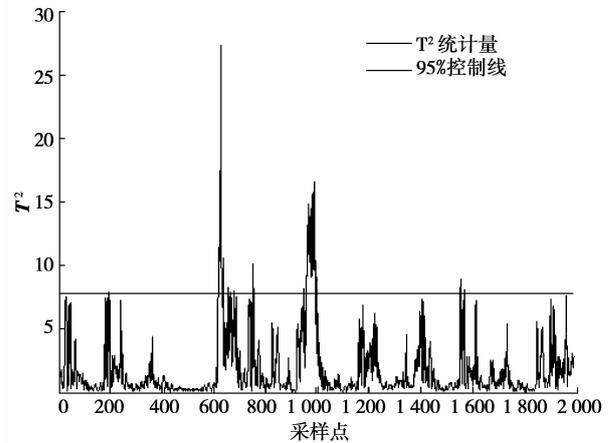
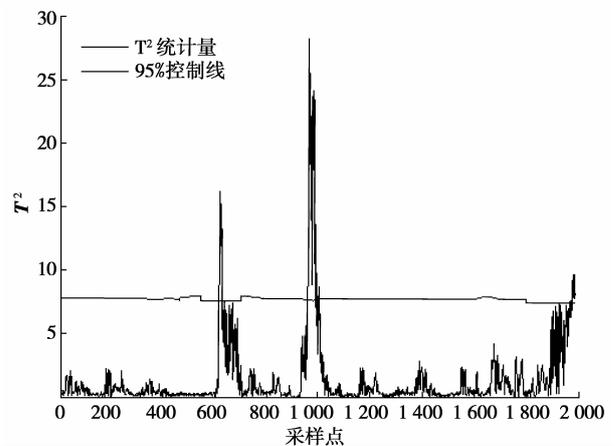
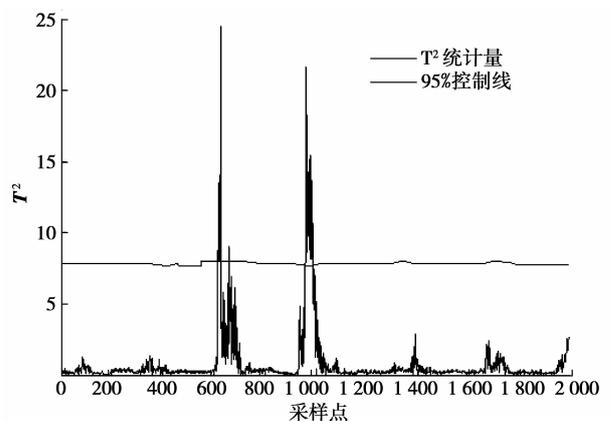


图 5 OLMS-A-MSPCA 对样本诊断的 SPE 图

986 个样本点附近发生了误报。改进的 MSPCA 算法在统计过程的中途部分具有很好的效果,能够准确的诊断出故障发生的位置,但在第 1 900 个样本点附近产生了误报,这也正好说明了边缘效应的影响。较之前 2 种算法,OLMS-A-MSPCA 算法对整个过程的诊断的准确率要高,没有出现误报。另外从整个过程的噪声水平来看,改进的 MSPCA 算法和 OLMS-A-MSPCA 算法较之常规的 MSPCA 算法,

都能很好的消除噪声,但改进的 MSPCA 算法对于处于边缘位置的样本点的去噪效果欠佳,相比之下,OLMS-A-MSPCA 算法能更清晰地监测到整个过程的故障信号。在完成 SPE 统计图后,从 T^2 统计图角度分析了上述 3 种方法对故障的诊断效果。

图 6 传统 MSPCA 对样本诊断的 T^2 图图 7 改进 MSPCA 对样本诊断的 T^2 图图 8 OLMS-A-MSPCA 对样本诊断的 T^2 图

从图 6 可以看出,常规的 MSPCA 算法在进行故障诊断时,含有大量的噪声,并且在第 630 和第

1 580个样本点附近出现了明显的误报。与之相比,图7所显示的改进 MSPCA 算法能更清晰地监测整个过程的故障信号,但是同样在第1 900个样本点附近出现了误报。较之前2种情况,尽管在第689个样本点出现了误报,图8对整个过程的诊断效果要比二者清晰简洁得多。

在比较了3种方法的故障诊断准确率之后,从耗时的角度比较了3种方法的实时性。表1反映了3种算法所消耗的时间。

表1 各种算法耗时 s

方法	Q 统计时间	T^e 统计时间
MSPCA	41.367	41.359
改进 MSPCA	43.283	43.279
OLMS-A-MSPCA	42.458	42.463

从上表可以看出,采用 OLMS-A-MSPCA 算法要比改进的 MSPCA 算法大约快 0.8 s 左右,节约的时间来自于自适应 PCA 算法,因为自适应 PCA 算法固定了初始数据块的大小,在线诊断中,其一次处理的数据量要比改进的 MSPCA 算法小得多,改进的 MSPCA 算法需要等待全部的小波系数阈值去噪完毕才能开始进行计算。另外从3种算法所耗时间来看,在线的算法都要比离线的算法慢 1~2 s,这是由于算法中增加的小波去噪所付出的时间代价造成的。

4 结 论

在实际工业生产过程中,由于人为操作失误、仪表噪声、输入扰动、传感器故障等诸多因素,使得所采集到的过程数据不可避免的受到不确定信息的干扰,从而对数据处理及优化、故障诊断等工作产生影响。若使用小波变换直接对现场数据消噪,再用 MSPCA 进行故障诊断,就会造成2次分解与重构,增加算法的计算量,导致不必要的时间浪费。借助多尺度滤波思想,将小波阈值去噪及自适应 PCA 算法结合起来,使之与 MSPCA 算法成为一个整体,既节约了时间开销,又通过去噪提高了诊断的准确率。尽管整个算法耗时要比离线算法多,但是这种算法可以在线使用,其实时性一般 MSPCA 算法无可比拟的。

参考文献:

[1] BAKSHI B R. Multiscale PCA with application to multivariate statistical process monitoring [J]. American Institute of Chemical Engineering Journal, 1998, 44(7): 1596-1610.
 [2] 刘育明,梁军,胡斌,等.一种基于多尺度分析的多变量统计过程监测方法[J].化工学报,2009,60(4):952-958.
 LIU YU-MING, LIANG JUN, HU BIN, et al. A multivariable statistical process monitoring method based on

multiscale analysis[J]. CIESC Journal, 2009, 60 (4): 952-958.
 [3] 范少荟,文成林.基于滑动中值滤波的多尺度主元分析方法[J].高技术通讯,2008,18(3):271-276.
 FAN SHAO-YUN, WEN CHENG-LIN. MSPCA based on sliding median filter [J]. High Technology Letters, 2008, 18(3):271-276.
 [4] REIS M S, SARAIVA P M. Multiscale statistical process control using wavelet packets [J]. AIChE Journal, 2008, 54(9):2366-2378.
 [5] XU T. Sensor fault diagnosis and data reconstruction based on MSPCA[C]//Proceedings of the 27th Chinese Control Conference, July 16-18, 2008, Kunming, China. [S. l]: IEEE, 2008: 30-33.
 [6] GAO Q, HAN M, HU S L, et al. Design of fault diagnosis system of FPSO production process based on MSPCA[C]// 25th International Conference on Information Assurance and Security, IAS 2009, August 18-20, 2009, Xi'an, China. [S. l]: IEEE, 2009: 729-732.
 [7] 耿卫国,徐涛,王祁.基于 MSPCA 的液体火箭发动机试车台氢供应系统传感器故障诊断方法[J].宇航学报,2006,27(6):1142-1146.
 GENG WEI-GUO, XU TAO, WANG QI. Method of sensor fault diagnosis in liquid rocket engine ground testing bed hydrogen providing system based on MSPCA[J]. Journal of Astronautics, 2006, 27(6): 1142-1146.
 [8] REISM S, SARAIVA P M. Multiscale statistical process control with multiresolution data[J]. AIChE Journal, 2006, 52(6): 2107-2119.
 [9] REISM S, SARAIVA P M. Generalized multiresolution decomposition framework for the analysis of industrial data with uncertainly and missing values [J]. Industrial and Engineering Chemistry Research, 2006, 45(18): 6330-6338.
 [10] 孙美红,孙巍,赵劲松,等.多变量统计方法监测化工过程的缓变故障[J].计算机与应用化学,2009,26(10): 1228-1231.
 SUN MEI-HONG, SUN WEI, ZHAO JIN-SONG, et al. MCUSUM-MSPCA based small shift monitoring in TE process [J]. Computers and Applied Chemistry, 2009, 26(10):1228-1231.
 [11] CHEN W Y. Application of multi-scale principal component analysis and SVM to the motor fault diagnosis[C]// International Forum on Information Technology and Applications, May 15-17, 2009, Chengdu, China. [S. l]: IEEE, 2009:131-134.
 [12] ZHANG G Y ZHANG J. Face recognition using multiscale PCA and support vector machine [C] // Proceedings of the World Congress on Intelligent Control and Automation (WCICA), June 25-27, 2008, Chongqing, China. [S. l]: IEEE, 2008:5906-5910.
 [13] NOUNOU M N, BAKSHI B R. On-line multiscale filtering of random and gross errors without process models[J]. AIChE Journal, 1999, 45(5): 1041-1058.
 [14] COHEN A, DAUBECHIES I, VIAL P. Wavelets on the interval and fast wavelet transforms [J]. Applied and Computational Harmonic Analysis, 1993, 1(1): 54-81.
 [15] HERLEY C, VETTERLI M. Orthogonal time-varying filter banks and wavelet packets[J]. IEEE Transactions on Signal Process, 1994, 42(10):2650-2663.

(编辑 侯湘)