

文章编号:1000-582X(2012)04-100-07

数据驱动的在线 MW-MSPCA 故障诊断

胡友强,余 嘉,李鹏华

(重庆大学 自动化学院,重庆 400044)

摘要:针对动态非平稳过程数据的时变性和多尺度性导致故障诊断准确率下降及故障准确定位难以实现的不足,引入滑动窗口多尺度主元分析,通过小波阈值消噪解决统计模型偏离与数据相关性降低之间的矛盾,并在各个尺度上利用滑动窗口主元分析实现模型更新,然后借助三维贡献图描述反映过程行为变化的各独立过程变量对统计过程的贡献程度,进而对故障准确定位,最后给出诊断准确性的定量评价机制。在对 6135D 型柴油机进行数值实验中,并通过与传统的多尺度主元分析及自适应多向主元分析比较,实验结果从故障的漏报率、误报率及诊断准确率三方面表明新方法能更好地实现传感器故障诊断。

关键词:数据驱动;多尺度故障诊断;滑动窗口主元分析

中图分类号: TP277

文献标志码: A

Online MW-MSPCA data-driven fault diagnosis

HU You-qiang, YU Jia, LI Peng-hua

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

Abstract: To track the non-stationary dynamics of the process which contains time-varying and multi-scale data, an online moving window multi-scale principal component analysis(MW-MSPCA) data-driven-based fault diagnosis method is proposed. In this data-driven diagnosis technique, wavelet threshold denoising is used to solve the conflict between the statistical model deviation and data correlation decreasing. The statistical models are updated by using moving window principal component analysis in various scales. The contribution of individual process variable to the process behavior change is illustrated in a 3-dimensional contribution chart. A quantitative evaluation mechanism is also given to evaluate the diagnosing accuracy. The numerical experimental results for 6135D diesel demonstrate that the proposed method can diagnose sensor fault better in terms of false rejection, false alarm and diagnosing accuracy for fault diagnosis upon comparing with conventional multi-scale principal component analysis(MSPCA) and adaptive multi-way principal component analysis(AMPCA) modeling.

Key words: data-driven; multi-scale fault diagnosis; moving window principal component

故障检测与定位是工业系统安全运行的重要因素之一,故障的及早发现和可靠辨识能让在线操作人员及时采取补救措施使异常状态重新回到可控范

围内^[1-2]。主元分析(principal component analysis, PCA)广泛应用于工业过程监测和故障诊断,由于其仅限于模型固定的^[3]单尺度建模^[4],而实际采集到

收稿日期:2011-10-20

基金项目:国家自然科学基金资助项目(60974090);中央高校基本科研业务资助(CDJRC 11170001);重庆市攻关项目资助(CSTC,2010AC3055)

作者简介:胡友强(1977-),男,重庆大学博士,副研究员,主要从事基于数据驱动的故障诊断与预测方向的研究,

(Tel)13648401358;(E-mail)yqhu@cqu.edu.cn。

的数据存在着各种噪声和干扰,同时还具有多尺度性和时变性。因此,在基于数过程数据的模型的实际应用中 PCA 的效果并不理想。

为克服传统 PCA 的上述不足,国内外研究者在多元统计理论的基础上发展了不同类型的 PCA。自适应 PCA 能有效处理缓变和突变变量,且对异常值健壮,避免数据的时变效应和设备退化导致的型偏差^[5-7],但没有考虑事件以不同时间、不同频率、不同位置发生所引起的数据多尺度性;多尺度主元分析(MSPCA)能有效处理各种非平稳过程数据,并从不同尺度上解释其累积效应,进而准确监测过程变量^[8-11],却忽略了过程数据的各种统计特性随时间变化的情况,造成故障的缓报或误报。文献[12]提出自适应多向主元分析(adaptive multi-way principal component analysis, AMPCA)对隐藏于时间尺度下的故障进行分析,虽然这种方法能准确诊断出故障发生的时间,但是对于故障准确定位却无能为力。用多分辨分析思想,结合自适应 PCA 算法处理时变过程数据的优势以及小波阈值消噪在处理高频信号方面的长处,设计出一种能有效处理具有多尺度性和时变性的高频过程数据的算法,实现基于数据驱动的在线故障诊断,进一步完善算法性能的定量评价机制,并解决对故障准确定位的问题。

1 在线多尺度故障诊断

为方便讨论,以1个 n 维多元变量产生的初始数据矩阵 \mathbf{X} 作为研究对象,即 $\mathbf{X} \in R^{n \times m}$,其中 n 为变量个数, m 为各分量采样点个数。

1.1 主元分析

主元分析(PCA)的作用是把 n 个相关的变量 x_1, x_2, \dots, x_n 变换成 n 个不相关的变量 t_1, t_2, \dots, t_n 。变换过程由式(1)定义^[13]

$$\begin{bmatrix} t_1 \\ t_2 \\ \vdots \\ t_n \end{bmatrix} = \begin{bmatrix} p_{11} & p_{21} & \cdots & p_{n1} \\ p_{12} & p_{22} & \cdots & p_{n2} \\ \vdots & \vdots & \ddots & \vdots \\ p_{1n} & p_{2n} & \cdots & p_{nn} \end{bmatrix}^T \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}, \quad (1)$$

上式又可简写为

$$\mathbf{T} = \mathbf{P}^T \mathbf{X}. \quad (2)$$

当观测矩阵 \mathbf{X} 中的变量存在一定的线性相关时, \mathbf{X} 的变化将主要体现在最前面的 k 个载荷向量上,而 \mathbf{X} 在最后面的 $n-k$ 个载荷向量投影会很小,它们主要是由测量噪声引起的。从而 \mathbf{X} 具有如下主元分解式

$$\mathbf{X} = \sum_{i=1}^k p_i t_i + \sum_{i=k+1}^n p_i t_i = \sum_{i=1}^k p_i t_i + \mathbf{E}, \quad (3)$$

其中: k 为关键主元的个数, \mathbf{E} 为残差矩阵。将观测

矩阵 \mathbf{X} 归一化为均值为0,方差为1的数据矩阵 $\bar{\mathbf{X}}$,即

$$\bar{\mathbf{X}} = \sum_1^{-1} (\mathbf{X} - \mathbf{b}_n^T \mathbf{I}_m), \quad (4)$$

其中,观测矩阵每一行的均值 \mathbf{b}_n 及其标准差矩阵 \sum_1^{-1} 为

$$\mathbf{b}_n = \frac{1}{m} \mathbf{I}_m \mathbf{X}^T \quad (5)$$

$$\sum_1^{-1} = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_n) \quad (6)$$

此处, $\mathbf{I}_m = [1, 1, \dots, 1] \in R^{1 \times m}$, $\sigma_i = \sqrt{\frac{1}{m} \sum_{j=1}^m (x_{i,j} - b_i)^2}$, $i = 1, 2, \dots, n, j = 1, 2, \dots, m$ 。则观测矩阵 \mathbf{X} 的标准化协方差矩阵为

$$\mathbf{C} = \frac{1}{m-1} \bar{\mathbf{X}} \bar{\mathbf{X}}^T. \quad (7)$$

1.2 滑动窗口主元分析与三维贡图

滑动窗口 PCA 主元分析(moving window muticsale pricipal compony oinaly sy MW-NSPCA MWPCA)是通过丢弃一部分旧的过程数据,并将当前时刻数据加入到模型中得到数据矩阵的矩阵和协方差矩阵。式(8)反映了这种方法的思路,其中 \mathbf{X}_k 表示前 k 时刻所有采样数据构成的数据块,下标 L 表示窗口长度,取值为 2^N , N 为任意整数。

旧数据窗口: $[\mathbf{X}_k \quad \mathbf{X}_{k+1} \quad \cdots \quad \mathbf{X}_{k+L-1}]_{n \times L}$,
 $(b_k \quad \sum_k^{-1} \quad c_k)$

↓

过渡数据窗口: $[\mathbf{X}_{k+1} \quad \cdots \quad \mathbf{X}_{k+L-1}]_{n \times L-1}$,
 $(b_* \quad \sum_*^{-1} \quad c_*)$

↓

新数据窗口: $[\mathbf{X}_{k+1} \quad \mathbf{X}_{k+L-1} \quad \cdots \quad \mathbf{X}_{k+L}]_{n \times L}$.
 $(b_{k+1} \quad \sum_{k+1}^{-1} \quad c_{k+1})$

旧数据窗口的均值 b_k 、标准差矩阵 \sum_k^{-1} 、协方差矩阵 \mathbf{C}_k 可由式(4)~(7)得到。过渡数据窗口的协方差矩阵为

$$\mathbf{C}_* = \mathbf{C}_k - \sum_k^{-1} \Delta \mathbf{b}_k^T \Delta \mathbf{b}_k \sum_k^{-1} - \frac{1}{L-1} \bar{\mathbf{X}}_k^T \bar{\mathbf{X}}_k. \quad (9)$$

那么新数据窗口的协方差矩阵为

$$\mathbf{C}_{k+1} = \sum_{k+1}^{-1} \sum_k^{-1} \mathbf{C}_* \Delta \mathbf{b}_k^T \Delta \mathbf{b}_k \sum_k^{-1} \sum_{k+1}^{-1} + \sum_{k+1}^{-1} \Delta \mathbf{b}_{k+1}^T \Delta \mathbf{b}_{k+1} \sum_{k+1}^{-1} \frac{1}{L-1} \sum_{k+1}^{-1} \bar{\mathbf{X}}_{k+L}^T \bar{\mathbf{X}}_k, \quad (10)$$

其中

$$b_{k+1} = \frac{1}{L} [(L-1)b_* + \mathbf{X}_{k+L}^T], \quad (11)$$

$$\Delta \mathbf{b}_{k+1} = \Delta \mathbf{b}_{k+1} - b_*, \quad (12)$$

$$\sigma_{k+1,i}^2 = \sigma_{k,i}^2 + \Delta \mathbf{b}_{k+1,i}^2 - \Delta \mathbf{b}_{k,i}^2 + \frac{1}{L-1} [(x_{k+L,i} - b_{k+L,i})^2 - (x_{k,i} - b_{k,i})^2], \quad (13)$$

$$\sum_{k+1}^{-1} = \text{diag}(\sigma_{k+1,1}, \sigma_{k+1,2}, \dots, \sigma_{k+1,n}), \quad (14)$$

$$\bar{X}_{k+L} = \sum_{k+L}^{-1} (X_{k+L} - b_{k+1}^T I_{k+L}). \quad (15)$$

故障诊断的主要任务是对系统中出现的故障进行检测、分离和辨识,即判断故障是否发生,定位故障发生的部位和种类,以及确定故障的大小和发生的时间等^[14]。当检测到故障时,传统的 PCA 借助二维贡献图来描述各独立过程变量对统计过程贡献程度,进而确定故障的根源。考虑到自适应 PCA 模型的更新,传统的二维贡献图在确定故障根源方面所提供的信息并不充分。为此,Wang X 等人提出了随模型更新的三维贡献图^[15],解决了二维贡献图在自适应 PCA 算法中的不足。将式(2)改写为

$$X = TP^T + E. \quad (16)$$

则可构造新的投影矩阵 D_k

$$D_k = P_k P_k^T, \quad (17)$$

$$\Delta D_{k+1} = D_{k+1} - D_k. \quad (18)$$

这里载荷矩阵 $P_k \in R^{n \times m}$, n 为多元变量维数, m 为相应主元数。显然, P_k 的第 i 列表示第 i 个主元对统计过程的贡献程度,且当模型更新时, P_k 中的元素也随之更新。此时, ΔD_{k+1} 可以用一个三维贡献图来表示,其中,笛卡尔坐标系 x 轴、 y 轴表示各个过程变量,而 z 轴则表示 ΔD_{k+1} 。

1.3 基于滑动窗口多尺度主元分析的故障诊断

鉴于多尺度主元分析在故障诊断时并不破坏数据相关性^[9],在以上分析的基础上,提出了基于小波阈值消噪的滑动窗口多尺度主元分析算法,在不破

坏数据相关性的前提下,直接对分解的各层小波系数进行小波阈值消噪,实现了批处理过程的在线故障诊断。图 1 描述了算法的具体流程,该流程分为以下 7 步:

- 1) 输入系统的正常数据,设定数据窗口尺度为 2^n , n 为多元变量维数;
- 2) 用离散小波变换(DWT)对 X 的每一行(即多元变量的每一分量)进行尺度均为 M 的分解,阈值消噪各个尺度的小波系数,并将 n 个分量各自在不同尺度下的粗部 A_M 与细部 $D_i (i=1, 2, \dots, M)$ 按尺度顺序组合成相应的 A_M 矩阵和 D_i 矩阵;
- 3) 移动数据窗口,更新计算第②步中的各小波系数矩阵的均值和协方差矩阵,将数据空间分解为相应的残差空间和主元空间,选择主元个数,计算 T^2 和 SPE 统计量的控制限;
- 4) 输入系统的在线监测数据,重复 1)~3)步;
- 5) 用 MWPCA 计算各个尺度数据矩阵的 T^2 和 SPE 统计量,选取大于控制限的小波系数,反之,则根据三维相应的三维贡献图选取对统计过程贡献最大的传感器的小波系数;
- 6) 对所有尺度上监测到显著事件的尺度重新组合,将保留的小波系数进行重构,用 MWPCA 分析重构后的数据矩阵,得到 T^2 和 SPE 统计图和相应的三维贡献图;
- 7) 丢弃旧数据并将新数据载入到的滑动窗口以更新主元模型,重复 4)~6)步。

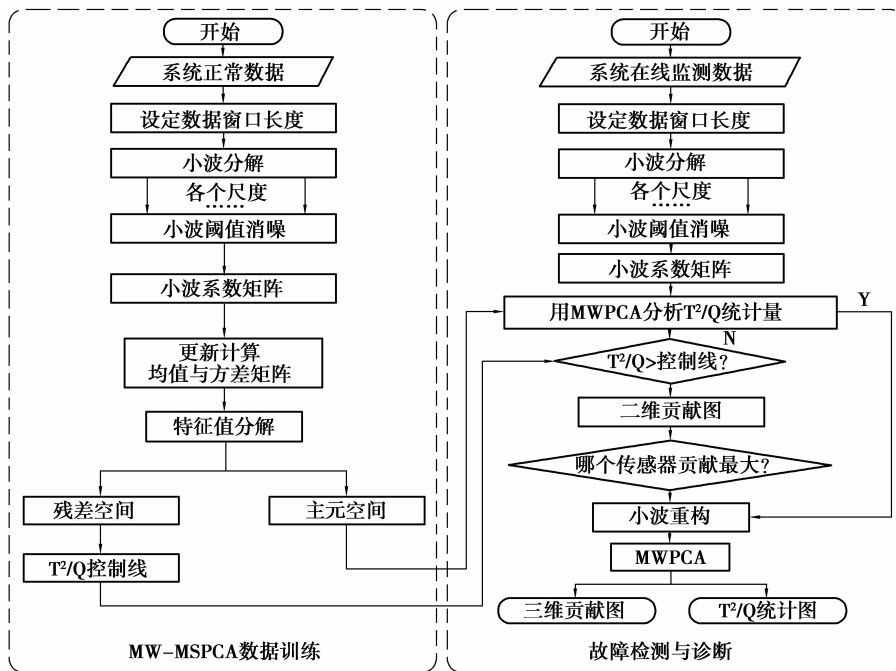


图 1 MW-MSPCA 算法流程图

2 仿真试验与结果分析

为验证所提方法的有效性,对多尺度主元分析(MSPCA)、自适应多向主元分析(AMPCA)、滑动窗口多尺度主元分析(MWMSPCA)3种多元统计方法进行了数值实验,分别从 T^2 和SPE统计图、三维贡献图、故障诊断准确率3方面进行比较。

2.1 数据采集

实验以6135D型柴油机为研究对象,采用8个加速度传感器在缸盖处测量,采样频率为25 KHz,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。采集到的柴油机信号可表示为一个(8×1 990)的数据矩阵,图2描述了8个传感器各自采集到信号,其中故障发生在33~85和612~628这2个样本区间,故障发生的位置为第1个和第2个传感器所在位置,故障类型为新气阀造成的轻微漏气。




图2 柴油机信号展开图

2.2 基于MSPCA的离线模型

多尺度主元分析(MSPCA)与所提算法的不同之处在于:

- 1) 没有对各个尺度的小波系数进行阈值处理;
- 2) 对每个尺度的小波系数矩阵采用传统PCA建模。

显然,此算法只能用于离线数据的故障诊断,因此该算法的主元数与控制限不存在更新,这在多元统计控制图中反映为控制限是一条直线,而不是自适应算法的多元统计控制图中的一条有较小波动的曲线。在完成对系统正常数据的训练后,将系统的故障数据输入MSPCA模型(模型中小波分解尺度为 $M=\log_2 m-5\approx 6$, T^2 统计量与SPE统计量的控制限均取为95%),得到如图3(a)~图3(c)的诊断

结果。从图3(a)可以看出,故障主要发生在38~76、78~91、612~631及646~651这4个样本区间,另外在第689、第987及第1396个样本点也监测到了故障。显然,漏报了33~37与第77样本点的故障,并在89~91、629~631、646~650以及第689、第987和第1396个样本点产生了误报。而用SPE图进行诊断则在64~68与612~617这2个样本区间产生了漏报,但只在第683个样本点造成误报。在诊断出故障发生的时刻后,需进一步对故障进行定位。为此,通过作出如图3(c)所示的三维贡献图来寻找故障根源。但该图并未清晰地显示出故障发生的位置,而是几个贡献程度较大的变量相互纠缠在一起,很难找出监测到故障的传感器。




图3(a) 离线MSPCA的 T^2 图




图3(b) 离线MSPCA的SPE图




图 3(c) 离线 MSPCA 的三维贡献图

2.3 基于 AMPCA 的在线模型

与算法相比,自适应多向主元分析(AMPCA)不同的地方:

- 1) 对各个尺度的小波系数没有进行阈值处理;
- 2) 该算法采用的主元分析模型为递归主元分析(RPCA)。

实验中选取(8×256)的正常数据块作为训练的初始数据矩阵,每当数据块更新一次,模型就更新一次,即当采样到数据重新填满设定好的数据块时,便递推计算数据矩阵的均值与协方差矩阵以及主元个数和相关统计量的控制限,实现模型的更新。通过正常数据训练出 T^2 统计量和 SPE 统计量的控制限后,将在线测量到的系统数据同时输入到 AMPCA 模型进行分析,诊断结果如图 4(a)~图 4(c)所示。

总体来说,由于主元和控制限随采样数据的更新而更新,自适应多向主元分析要比多尺度主元分析更准确地反映过程的变化,因此图 4(a)~图 4(c)对于故障的检测与定位要比图 3(a)~图 3(c)清晰明了。图 4(a)显示故障主要发生在 33~58、62~88 及 618~628 这 4 个样本区间,但是在 59~61 和 612~617 的 2 个样本区间出现了漏报的情况,同时误报了第 105 个样本点与 675~680 的样本区间的故障。在图 4(b)中的 SPE 统计量只是在 56~60 及 612~614 的 2 个样本区间显示了漏报,误报的情况发生在第 680 个样本点。

尽管图 4(c)所示的三维贡献图要比图 3(c)描述各个变量对过程的贡献程度清晰,但是从图中可以明显地看出第 1 个变量与第 4 个变量纠缠在一起,共同为故障作出贡献。为方便讨论,此种情况简记为(1,4)。类似的情况还有(2,5)、(1,6)、(2,7)、

(2,8)。因此无法准确地找出监测到故障的传感器,只能说故障有可能发生在第 1、2、5、6、7、8 个传感器所在位置,其中故障发生在第 1、第 4 个传感器所在位置的概率最大。



图 4(a) 离线 AMSPCA 的 T^2 图

图 4(b) 离线 AMSPCA 的 SPE 图




图 4(c) 离线 AMSPCA 的三维贡献图

2.4 基于 MW-MSPCA 的在线模型

按照所提算法,实际应用中设定数据窗。窗口长度为 256。首先输入正常的系统数据,用离散小波变换对 8 个变量进行尺度均为 6 的分解,并阈值消噪各个尺度的小波系数,组成小波系数矩阵 A_6 和 $D_1 \sim D_6$ 。然后计算各小波系数矩阵的均值和协方差矩阵,将数据空间分解为相应的残差空间和主元空间,选择主元个数,计算 T^2 和 SPE 统计量的控制限。

完成正常数据的训练后,输入系统的在线监测数据用 MWPCA 计算各个尺度数据矩阵的 T^2 与 SPE 统计量,选取大于控制限的小波系数,反之,则根据三维相应的三维贡献图选取对统计过程贡献最大的传感器的小波系数。最后对所有尺度上监测到显著事件的尺度重新组合,将保留的小波系数进行重构,用 MWPCA 分析重构后的数据矩阵,得到 T^2 与 SPE 统计图和相应的三维贡献图。当采样到新数据时,丢弃旧数据并将新数据载入到的滑动窗口以更新主元模型,诊断结果如图 5(a)~图 5(c) 所示。从图 5(a) 可以看出,故障主要发生在 33~49、52~88、612~626 这 3 个样本区间,在第 630 个样本点处发生了误报,漏报了 50~51、627~628 这 4 个样本点的故障。而在图 5(b) 中,没有发生故障的误报,只是在 46~51 和 624~628 这 2 个样本区间发生了漏报。在进行故障定位时,图 5(c) 所示的三维贡献图中清晰的描述了故障发生在第 1 和第 2 个传感器所在位置,与实际故障情况相符。因此,通过消除噪声干扰,MW-MSPCA 算法的诊断效果明显优于前面 2 种算法。




图 5(a) 离线 MW-MSPCA 的 T^2 图




图 5(b) 离线 MW-MSPCA 的 SPE




图 5(c) 离线 MW-MSPCA 的三维贡献图

2.5 诊断效果评估

为定量描述三种算法的故障诊断准确性,定义了算法故障诊断的准确率 A ,即

$$A = \sqrt{\frac{\sigma_{T^2}^2 + \sigma_{SPE}^2}{2}}, \quad (19)$$

此处, σ_{T^2} 和 σ_{SPE} 分别表示了用 T^2 与 SPE 统计监控图进行故障诊断的准确率,即

$$\begin{cases} \sigma_{T^2} = 1 - (\eta_f.T^2 + \eta_o.T^2); \\ \sigma_{SPE} = 1 - (\eta_f.SPE + \eta_o.SPE), \end{cases} \quad (20)$$

其中: $\eta_f = \frac{n}{N}$ 为故障误报率; n 误报的样本点数; N 为发生故障的总样本点数; $\eta_o = \frac{m}{N}$ 为故障漏报率, m 为漏报的样本点数。结合式(19)与式(20)可得到 3 种算法的故障诊断准确率,如表 1 所示。

表 1 诊断准确性比较 %

方法种类	统计量	漏报率	误报率	准确率
MSPCA	T^2	7.35	16.18	53.28
	SPE	13.24	1.47	
AMSPCA	T^2	10.29	8.82	85.41
	SPE	8.82	1.47	
MW-MSPCA	T^2	5.88	1.47	89.75
	SPE	13.24	0	

从表 1 可以看出 MSPCA 算法的准确率最低, 而 MW-MSPCA 算法的准确率最高。造成这种情况的原因可从算法本身找出: MSPCA 属于模型固定数据驱动方法, 固定的模型不能准确反映数据的时变过程。另外, MSPCA 与 AMPCA 都没有进行阈值消噪, 忽略了实际过程中噪声对统计模型造成的偏差, 含有噪声的数据不仅增加对主元选取的复杂度, 而且影响诊断的准确性, 进而造成几个主元相互纠缠致使准确的故障定位难以实现, 这一点可从图 3(c) 和图 4(c) 所示的三维贡献图看出, 同时也从另一个角度解释了为什么 MW-MSPCA 在进行故障定位时要优于前面 2 种算法。

3 结 论

数据驱动的多元统计过程控制(MSPC)的目的在于快速监测并定位过程中发生的异常情况, 以改善对过程的控制。通过对 MSPCA、AMPCA、MW-MSPCA 三种算法进行数值实验分析, 得出 MW-MSPCA 在故障定位及诊断准确性方面要优于另外 2 种算法。借助多分辨分析思想反映了过程数据以不同位置发生所导致的多尺度性; 利用自适应的思路克服了过程数据的各种统计特性随时间变化造成的模型偏差; 同时引入直接对小波系数进行阈值消噪避免了用小波方法对数据进行预处理时导致的二次小波重构, 提高了算法效率。

参考文献:

- [1] CHO H W. Nonlinear feature extraction and classification of multivariate data in kernel feature space [J]. *Expert Systems with Applications*, 2007, 32(2): 534-542.
- [2] CHO H W. An orthogonally filtered tree classifier based on nonlinear kernel-based optimal representation of data [J]. *Expert Systems with Applications*, 2008, 34(2):1028-1037.
- [3] LU B Z, ZHAO Y H, MAO Z H. Fault diagnosis method based on moving window PCA [C] // *Proceedings of the Chinese Control and Decision Conference*, June 17-19, 2009. Shanghai, China: IEEE, 2009:185-188.
- [4] GAO Q, HAN M, HU S L, et al. Design of fault diagnosis system of FPSO production process based on MSPCA [C] // *Proceedings of the 5th International Conference on Information Assurance and Security*, Aug. 18-20, 2009. Xi'an, China: IEEE, 2009, 2: 729-733.
- [5] FACCO P, BEZZO F, BAROLO M. Nearest-neighbor method for the automatic maintenance of multivariate statistical soft sensors in batch processing [J]. *Industrial & Engineering Chemistry Research*, 2010, 49(5): 2336-2347.
- [6] CHENG C Y, HSU C C, CHEN M C. Adaptive kernel principal component analysis (KPCA) for monitoring small disturbances of nonlinear processes [J]. *Industrial & Engineering Chemistry Research*, 2010, 49(5): 2254-2262.
- [7] LEE D S, VANROLLEGHEM P A. Adaptive consensus principal component analysis for on-line batch process monitoring [J]. *Environmental Monitoring and Assessment*, 2004, 92(1-3): 119-135.
- [8] LACHOURI A, BAICHE K, DJEGHADER R, et al. Analyze and fault diagnosis by multi-scale PCA [C] // *Proceedings of the 3rd International Conference on Information and Communication Technologies*, April 7-11, 2008. Umayyad Palace, Damascus, Syria: IEEE, 2008: 1-6.
- [9] CHEN W Y. Application of multi-scale principal component analysis and SVM to the motor fault diagnosis [C] // *Proceedings of the International Forum on Information Technology and Applications*, May 15-17, 2009. Chengdu, China: IEEE, 2009, 3:131-134.

- construction[J]. *Communications in Nonlinear Science and Numerical Simulation*, 2010, 15(5): 1338-1347.
- [10] ZHOU Q, LIAO X F, WONG K W, et al. True random number generator based on mouse movement and chaotic hash function[J]. *Information Sciences*, 2009, 179(19): 3442-3450.
- [11] 王小敏, 张文芳, 张家树. 基于非线性数字滤波器的混沌 Hash 函数设计[J]. *计算机辅助设计与图形学学报*, 2006, 18(6): 870-875.
- WANG XIAO-MIN, ZHANG WEN-FANG, ZHANG JIA-SHU. Design of chaotic hash function based on nonlinear digital filter[J]. *Journal of Computer-aided Design & Computer Graphics*, 2006, 18(6): 870-875.
- [12] US National Institute of Standards and Technology. Announcing request for candidate algorithm nominations for a new cryptographic hash algorithm (SHA-3) family [J]. *Federal Register*, 2007, 72: 62212-62220.
- [13] CHUAN L O, YANG L. Cellular neural networks: theory [J]. *IEEE Transactions on Circuit and Systems*, 1988, 35(10):1257-1272.
- [14] 周庆, 廖晓峰, 胡月. 采用细胞神经网络结构进行图像加密的框架及算法[J]. *计算机辅助设计与图形学学报*, 2009, 21(11): 1676-1681.
- ZHOU QING, LIAO XIAO-FENG, HU YUE. An image encryption framework and an algorithm based on CNN [J]. *Journal of Computer-aided Design & Computer Graphics*, 2009, 21(11):1676-1681.
- [15] RUKHIN A, SOTO J, NECHVATAL J, et al. NIST Special Publication 800-22 A statistical test suite for random and pseudorandom number generators for cryptographic applications[S]. Gaithersburg: National Institute of Standards and Technology, 2001.

(编辑 侯 湘)

~~~~~

(上接第 106 页)

- [10] GENG Z Q, ZHU Q X. Multi-scale nonlinear principal component analysis (NLPCA) and its application for chemical process monitoring [J]. *Industrial & Engineering Chemistry Research*, 2005, 44(10): 3585-3593.
- [11] WANG D, ROMAGNOLI J A. Robust multi-scale principal components analysis with applications to process monitoring [J]. *Journal of Process Control*, 2005, 15(8): 869-882.
- [12] LEE D S, PARK J M, VANROLLEGHEM P A. Adaptive multi-scale principal component analysis for on-line monitoring of a sequencing batch reactor[J]. *Journal of Biotechnology*, 2005, 116(2): 195-210.
- [13] 周福娜, 文成林, 汤天浩, 等. 基于指定元分析的多故障诊断方法[J]. *自动化学报*, 2009, 35(7): 971-982.
- ZHOU FU-NA, WEN CHENG-LIN, TANG TIAN-HAO, et al. DCA based multiple faults diagnosis method[J]. *Acta Automatica Sinica*, 2009, 35(7): 971-982.
- [14] 周东华, 胡艳艳. 动态系统的故障诊断技术[J]. *自动化学报*, 2009, 35(6): 748-758.
- ZHOU DONG-HUA, HU YAN-YAN. Fault diagnosis techniques for dynamic systems [J]. *Acta Automatica Sinica*, 2009, 35(6): 748-758.
- [15] WANG X, KRUGER U, IRWIN G W. Process fault diagnosis using recursive multivariate statistical process control[C/OL] // The 16th IFAC World Congress in Prague, Prague Czech Republic, July 4-8, 2005; impact on <http://www.ifac-papersonline.net/Detailed/29131.html>.

(编辑 侯 湘)