

基于 LGSP- Bayes 的故障检测与辨识方法

刘琴, 于春梅

(西南科技大学 信息工程学院, 四川 绵阳 621010)

摘要: 针对主元分析 (Principal component analysis, PCA) 和局部保持投影 (Locality preserving projections, LPP) 方法在降维过程中分别只能保留数据集的整体信息和局部信息, 提出一种基于局部整体结构保持投影的贝叶斯故障检测与辨识方法 (Local and global structure preserving projections and bayes, LGSP- Bayes); 首先, 将正常工况操作下的原始数据通过局部整体结构保持投影方法投影到低维特征空间, 得到高维到低维的数据转换矩阵; 然后通过设计贝叶斯分类器来进行故障检测; 最后当检测到故障后通过计算贝叶斯分类函数的大小来识别故障种类; 将 LGSP- Bayes 方法应用于 TE 过程, 仿真结果表明对故障的检测优于其他方法, 并且可以很好地识别故障种类。

关键词: 主元分析; 局部保持投影; 贝叶斯分类器; 故障检测; 故障辨识

Fault Detection and Identification Method Based on LGSP- Bayes

Liu Qin, Yu Chunmei

(College of Information Engineering, Southwest University of Science and Technology, Mianyang 621010, China)

Abstract: According to the method of principal component analysis (PCA) and locality preserving projections (LPP) can respectively retain the global information and local information of the data set in the process of reducing dimension, a novel method named local and global structure preserving projections and bayes (LGSP- Bayes) was proposed. Firstly, projecting the original data under normal operating conditions onto a low dimensional feature space to get a data transformation matrix from high dimension to low dimension; Then designing bayesian classifier for fault detection; Finally when a fault was detected, identifying which kind of the fault is by calculating bayesian classification functions. Case applying to Tennessee Eastman process illustrates the new method is better than other methods in the detection of fault. Besides, it is also a good way to identify fault types.

Keywords: principal component analysis (PCA); locality preserving projections (LPP); Bayesian classifier; fault detection; fault identification

0 引言

现代工业过程具有规模大、复杂性高、变量多的特点, 及时的进行故障检测与诊断在工业过程中越来越重要。在过去的几十年里, 以主元分析 (principal component analysis, PCA) 为代表的多元统计过程控制 (multivariate statistical process control, MSPC) 方法得到了广泛研究与应用。PCA 及其拓展方法如自适应 PCA、多尺度 PCA、动态 PCA 已经在很多工业过程中得到广泛的研究与应用^[1-5]。尽管 PCA 中提取出的主元能够保留大多数的数据变化, 然而这些主元只能捕获过程数据的整体结构。与 PCA 只考虑了数据的全局结构相比, 局部保持投影 (locality preserving projections, LPP) 能够发现原始高维数据的内在特征或者某些非线性结构^[6]。针对 PCA 和 LPP 都只能考虑到其中一方面, Yu^[7]将 PCA 和 LPP 结合提出了一种局部整体 PCA (local and global PCA, LGPCA) 新算法, 将原始数据投影到具有相似局部结构的低维空间, 同时

保证在低维空间中数据方差最大化, 从而保留整体的结构信息, 结果表明该方法比 PCA 和 LPP 的故障检测效果好。

基于贝叶斯决策理论设计的分类器在故障检测与辨识方面获得了成功应用^[8-9]。贝叶斯分类是模式识别中一种利用概率统计进行分类的算法, 具有方法简单、分类准确率高、速度快的特点。本文在 LGPCA 算法的基础上, 提出了一种基于局部整体结构保持投影的贝叶斯故障检测方法 (LGSP- Bayes)。

1 基于 PCA 和 LPP 的故障检测

设输入 $\mathbf{X} = [x_1, x_2, \dots, x_n]^T \in \mathbf{R}^{n \times m}$, y_i 为映射到低维空间后的样本, $\mathbf{A} \in \mathbf{R}^{m \times l}$ 为线性转换矩阵, 且 $y_i = \mathbf{A}^T x_i$ 。

1.1 基于 PCA 的故障检测

PCA 的基本思想是通过将多变量高维数据空间投影到低维空间, 将数据沿着数据方差最大的方向投影, 使得投影后的数据方差最大化。PCA 的目标函数为式 (1)。

$$J(\mathbf{A})_{PCA} = \max_{\mathbf{A}} \sum_{i=1}^n (y_i - \bar{y})^2 = \max_{\mathbf{A}} \sum_{i=1}^n \mathbf{A}^T (x_i - \bar{x})(x_i - \bar{x})^T \mathbf{A} = \max_{\mathbf{A}} \mathbf{A}^T \mathbf{C} \mathbf{A} \quad (1)$$

其中: $\bar{y} = (1/n) \sum_{i=1}^n y_i$, $\bar{x} = (1/n) \sum_{i=1}^n x_i$, $\mathbf{C} = (1/n) \sum_{i=1}^n (x_i - \bar{x})(x_i - \bar{x})^T$ 为协方差矩阵。负荷矩阵 $\mathbf{A} = [a_1, a_2, \dots, a_l]$ 为与协方差矩阵前 l 个最大特征值对应的特征向量, l 为所选主元个数。

收稿日期: 2014-12-31; 修回日期: 2015-03-24。

基金项目: 特殊环境机器人技术四川省重点实验室开放基金 (13zxtk06); 西南科技大学博士基金; 西南科技大学研究生创新基金 (15ycx118)。

作者简介: 刘琴 (1991-), 女, 山西朔州人, 硕士研究生, 主要从事故障检测与诊断方向的研究。

于春梅 (1970-), 女, 江苏如皋人, 西南科技大学教授, 博士, 主要从事故障诊断、模式识别、机器人控制方向的研究。

建立 T^2 统计量如下:

$$T^2 = x^T A \Lambda^{-1} A^T x \leq \frac{l(n^2 - 1)}{n(n - l)} F_\alpha(l, n - l)$$

其中: $\Lambda = \text{diag}\{\lambda_1, \lambda_2, \dots, \lambda_l\}$, $F_\alpha(l, n - l)$ 是自由度分别为 l 和 $n - l$ 时 F 分布的临界值。当 T^2 统计量超过控制限时, 则说明有故障发生。

主元分析后得到的低维投影空间和原始空间拥有相同的使方差最大化的方向^[10-11], 但是传统主元分析法并没有考虑不同样本间的内在局部信息。

1.2 基于 LPP 的故障检测

局部保持投影能够发现原始高维数据的内在特征或者某些非线性结构, 通过该算法得到的投影子空间保存了原始样本点的局部信息。设 LPP 把高维数据投影到低维子空间的转换矩阵为 \mathbf{A} , 则 \mathbf{A} 可以通过解决以下函数的最小化问题而得到^[12]:

$$J(\mathbf{A})_{LPP} = \min_{\mathbf{A}} \sum_{ij} (y_i - y_j)^2 W_{ij} = \min_{\mathbf{A}} 2 \sum_{i=1}^n y_i D_{ii} y_i^T - 2 \sum_{ij} y_i W_{ij} y_j^T = \min_{\mathbf{A}} \mathbf{A}^T \mathbf{X} \mathbf{L} \mathbf{X}^T \mathbf{A} = \min_{\mathbf{A}} \mathbf{A}^T \mathbf{U} \mathbf{A} \quad (2)$$

其中: $\mathbf{U} = \mathbf{X} \mathbf{L} \mathbf{X}^T$ 称为局部矩阵, $\mathbf{L} = \mathbf{D} - \mathbf{W}$ 称为拉普拉斯矩阵, \mathbf{D} 为对角线矩阵, 对角线元素为矩阵 \mathbf{W} 每一列元素之和, 即 $D_{ii} = \sum_j W_{ij}$ 。矩阵 \mathbf{W} 称为相似性矩阵, 当 x_i 是 x_j 的 k 最近邻或者 x_j 是 x_i 的 k 最近邻时, $W_{ij} = w(x_i, x_j)$, $w(x_i, x_j)$ 表示样本间的相似性, 可以用欧氏距离或者高斯核函数来衡量^[6], 本文采用欧氏距离来衡量样本间的相似性。

通过 LPP 算法求出投影矩阵 \mathbf{A} 并将原样本映射到低维空间后, 参考 PCA 过程监控算法, 构造 T^2 统计量, 通过 T^2 统计量与控制限的比较进行故障检测^[13]。

2 基于 LGSP- Bayes 的故障检测与辨识

2.1 LGSP 算法

为了在映射过程中同时保留与原始数据间相同的整体和局部特征, 可以通过解决如下函数的最小化问题从给定数据中同时提取整体和局部信息^[14]:

$$\min_{\mathbf{A}} J(\mathbf{A}) = \min_{\mathbf{A}} \frac{J(\mathbf{A})_{LPP}}{J(\mathbf{A})_{PCA}} = \min_{\mathbf{A}} \frac{\mathbf{A}^T \mathbf{U} \mathbf{A}}{\mathbf{A}^T \mathbf{C} \mathbf{A}} \quad (3)$$

上述问题转化为如下广义特征值问题:

$$\mathbf{U} \mathbf{A} = \lambda \mathbf{C} \mathbf{A} \quad (4)$$

令 $\mathbf{A} = [a_1, a_2, \dots, a_m]$, 其中 a_i 为上述广义特征值问题的特征向量, 如果只保留 \mathbf{A} 中与前 l 个最大特征值对应的特征向量, 那么原始高维空间中的数据 x 的维数就减少为低维空间数据 $y = \mathbf{A}^T x$ 的维数。

2.2 基于 Bayes 分类器的故障检测与辨识

假设数据服从正态分布, 训练样本的方差阵和均值向量分别为 \mathbf{S}_j 和 \mathbf{m}_j , 观测样本个数为 n_j , 设 δ_j 为故障类 ω_j 的数据集, 即^[8-9]:

$$p(x | \omega_j) \sim N(\mathbf{m}_j, \mathbf{S}_j) \quad (5)$$

$$\mathbf{m}_j = \frac{1}{n_j} \sum_{x \in \delta_j} x \quad (6)$$

$$\mathbf{S}_j = \frac{1}{n_j - 1} \sum_{x \in \delta_j} (x - \mathbf{m}_j)(x - \mathbf{m}_j)^T \quad (7)$$

则观测 x 在故障类 ω_j 条件下的类条件概率密度函数为:

$$p(x | \omega_j) = \frac{1}{(2\pi)^{n/2} (\det(\mathbf{S}_j))^{1/2}} \exp\left[-\frac{1}{2} (x - \mathbf{m}_j)^T \mathbf{S}_j^{-1} (x - \mathbf{m}_j)\right] \quad (8)$$

定义判别函数为:

$$g_j(x) = \ln p(x | \omega_j) + \ln P(\omega_j) = -\frac{1}{2} (x - \mathbf{m}_j)^T \mathbf{S}_j^{-1} \mathbf{S}_j^{-1} (x - \mathbf{m}_j) - \frac{n}{2} \ln 2\pi - \frac{1}{2} + \ln P(\omega_j) \quad (9)$$

利用 LGSP 算法进行降维后得到的投影空间中的样本为 $y = \mathbf{A}^T x$, 则降维后的样本均值向量和样本方差阵为:

$$\mathbf{m}_{fj} = \frac{1}{n_j} \sum_{x \in \delta_j} \mathbf{A}^T x = \mathbf{A}^T \mathbf{m}_j \quad (10)$$

$$\mathbf{S}_{fj} = \frac{1}{n_j - 1} \sum_{x \in \delta_j} (\mathbf{A}^T x - \mathbf{m}_{fj})(\mathbf{A}^T x - \mathbf{m}_{fj})^T = \mathbf{A}^T \mathbf{S}_j \mathbf{A} \quad (11)$$

则 Bayes 判别函数变为:

$$g_{fj}(x) = -\frac{1}{2} (\mathbf{A}^T x - \mathbf{m}_{fj})^T \mathbf{S}_{fj}^{-1} (\mathbf{A}^T x - \mathbf{m}_{fj}) - \frac{1}{2} \ln[\det(\mathbf{S}_{fj})] + \ln P(\omega_j) = -\frac{1}{2} (x - \mathbf{m}_j)^T \mathbf{A} (\mathbf{A}^T \mathbf{S}_j \mathbf{A})^{-1} \mathbf{A}^T (x - \mathbf{m}_j) - \frac{1}{2} \ln[\det(\mathbf{A}^T \mathbf{S}_j \mathbf{A})] + \ln P(\omega_j) \quad (12)$$

令训练样本数据分别为无故障正常操作情况下的样本数据以及故障数据, 对测试样本 x 分别计算判别函数, 设 $g_{f0}(x)$ 为训练样本为正常数据时的判别函数, $g_{fi}(x) (i = 1, \dots, f)$ 为训练样本为第 i 类故障数据时的判别函数, 比较函数值大小, 当 $g_{fi}(x) > g_{f0}(x)$ 时说明测试样本中有故障发生。

利用 Bayes 分类器还可以辨识出故障类别, 设有 C 类训练样本数据, 分别计算对应的 C 个判别函数, 通过比较 C 个判别函数值大小, 将测试样本归于最大判别函数值对应的故障类别, 即 $\max(g_i(x)) = g_k(x)$ 时测试样本故障属于故障 k 。

基于 LGSP- Bayes 算法的故障检测与辨识步骤如下。

- 1) 对训练样本数据进行标准化处理;
- 2) 计算处理后的训练样本 X 的协方差 C ;
- 3) 分别计算相似性矩阵 \mathbf{W} , 对角线矩阵 \mathbf{D} 以及拉普拉斯矩阵 \mathbf{L} ;
- 4) 根据方程 (4) 计算前 m 个最大特征值对应的特征向量 $\mathbf{A} = [a_1, a_2, \dots, a_l] (l \leq m)$;
- 5) 设降维矩阵为 4) 中的矩阵 \mathbf{A} , 计算降维空间的样本均值向量 \mathbf{m}_{fj} 和样本方差阵 \mathbf{S}_{fj} ;
- 6) 计算 Bayes 函数 $g_i(x)$, 在线检测与辨识。

3 仿真研究

Tennessee Eastman 过程是由美国伊斯曼化学品公司提出并创建的, 用来评价过程控制监控方法的有效性。该过程共有 41 个测量变量和 12 个控制变量, 过程仿真包含 21 个可人为预设定的过程故障, 其工艺流程图以及详细仿真过程见文献^[15]。本文采用闭环控制得到仿真数据, 该数据集训练集和测试集均包含 52 个过程变量, 本文选取 33 个变量进行过程监控, 对所选变量的详细介绍见文献^[9], 训练集样本共 500 组, 后面的 480 组样本是 1 h 后引入故障采集的。测试集共采集 960 组数据, 在 160 组数据后引入故障。所有训练集数据在建模之前进行标准化处理, 量化为零均值, 单位标准差, 并且对测试样本数据采用建模样本量化时的均值和方差

进行标准化。在故障检测过程中所有的控制限设定为 99%，所用主元个数均为 9，用来计算相似矩阵的 k 近邻个数设为 10。

为了检验算法检测与辨识的效果，我们对 TEP 数据的故障 1、故障 2、故障 3 进行仿真研究，3 种故障为预设定的故障，分别由 A/C 进料比率、B 成分、D 的进料温度发生阶跃变化引起。对这 3 种故障的检测结果见图 1~3。图 1 表明对于故障 1，LGSP- T^2 在第 171 个样本点检测到故障，而 LGSP-Bayes 在第 164 个样本点就可以检测出故障发生；图 2 表明对于故障 2，LGSP- T^2 在第 182 个样本点检测到故障，LGSP-Bayes 在第 173 个样本点就可以检测出故障发生；对于故障 3，LGSP- T^2 和 LGSP-Bayes 的检测效果都不是很理想，但是 LGSP-Bayes 检测出的故障样本数比 LGSP- T^2 多 173 个。3 种故障的检测正确率见表 1，从表中可以看出对于故障 1，LGSP-Bayes 方法检测正确率分别比 PCA- T^2 、LGSP- T^2 、PCA-Bayes 提高了 0.42%、0.52%、0.42%；对于故障 2，LGSP-Bayes 分别比 PCA- T^2 、LGSP- T^2 、PCA-Bayes 提高了 0.10%、0.73%、0.42%；对于故障 3，LGSP-Bayes 分别比 PCA- T^2 、LGSP- T^2 、PCA-Bayes 提高了 13.95%、13.54%、6.77%。从整体来看，LGSP-Bayes 的平均故障检测正确率分别提高了 4.82%、4.93%、2.54%，说明 LGSP-Bayes 算法比其他方法的检测结果好，对故障检测有一定的改善。

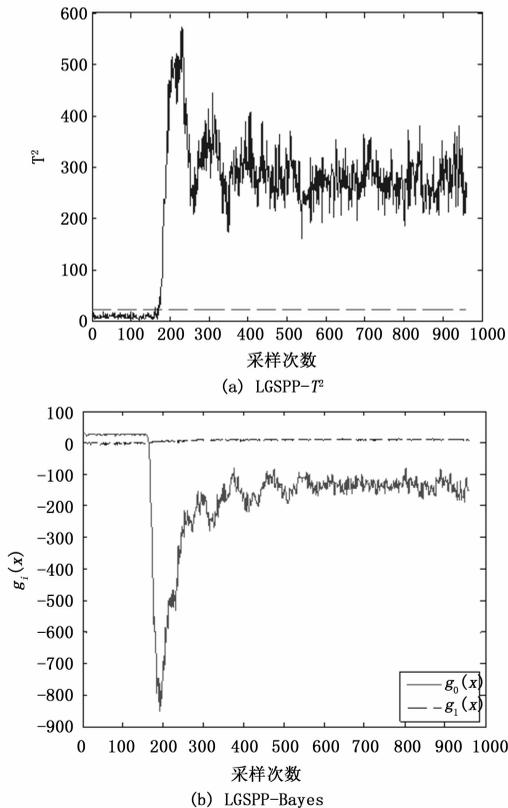


图 1 故障 1 的检测结果

当故障被检测出后，需要识别是何种故障发生，图 4 为 LGSP-Bayes 方法对故障 1、2、3 的识别诊断结果图，图中， $g_i(x) (i = 1, 2, 3)$ 分别代表故障 1、故障 2、故障 3 的

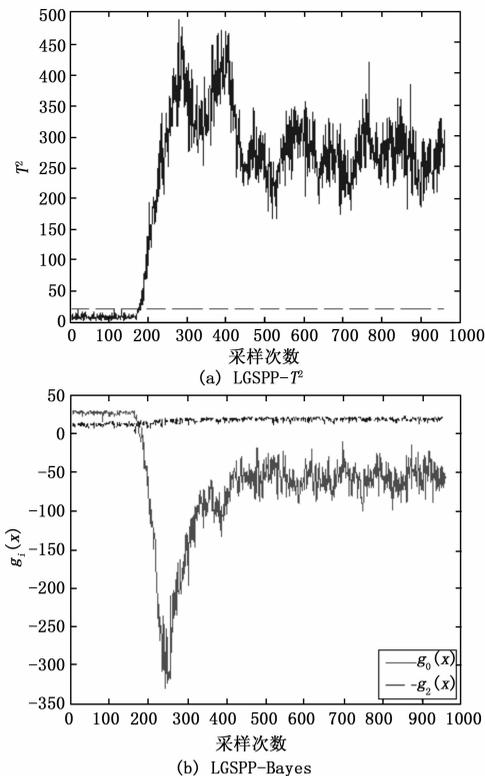


图 2 故障 2 的检测结果

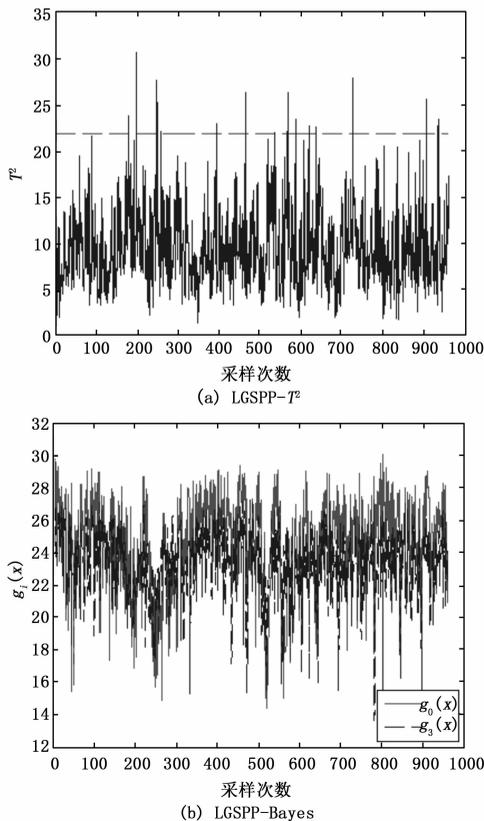


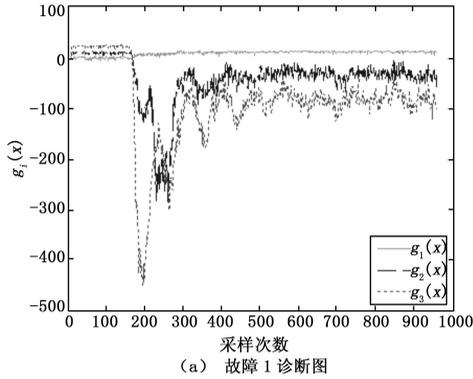
图 3 故障 3 的检测结果

Bayes 决策函数。由图 4 可以看出，从 161 组数据引入故障后，基于 LGSP 的 Bayes 故障识别能力很好，能够将 3 种故障识

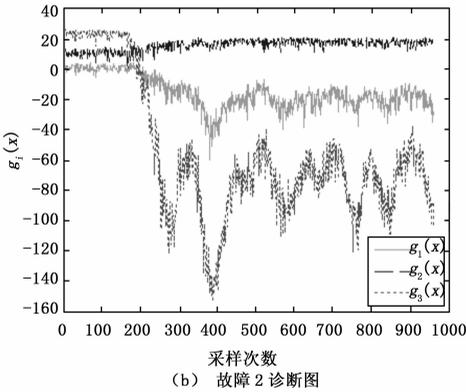
别出来。

表 1 3 种故障的检测正确率

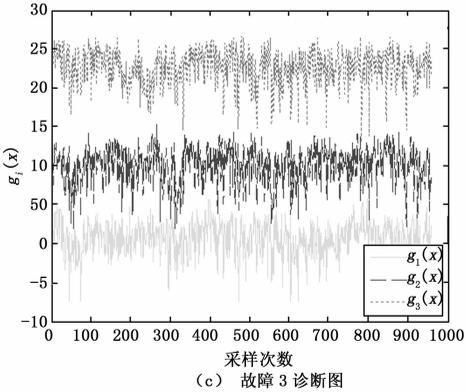
	PCA- T^2	LGSP- T^2	PCA-Bayes	LGSP-Bayes
故障 1	99.27	99.17	99.27	99.69
故障 2	98.65	98.02	98.33	98.75
故障 3	17.92	18.33	25.10	31.87
平均	71.95	71.84	74.23	76.77



(a) 故障 1 诊断图



(b) 故障 2 诊断图



(c) 故障 3 诊断图

图 4 LGSP- Bayes 识别故障图

4 结论

本文提出了一种新的故障检测与诊断的 LGSP- Bayes 方法。该算法综合了传统 PCA 和 LPP 算法的优点, 同时考虑了整体和局部特征的保持, 使得降维后的低维空间包含了更多的

原始数据信息。另外该算法不同于传统采用统计量进行故障检测的方法, 采用 Bayes 分类器对故障进行检测与辨识。针对故障 1、2、3 的仿真结果表明, 与 PCA- T^2 、LGSP- T^2 、PCA-Bayes 方法相比, LGSP- Bayes 的平均故障检测正确率分别提高了 4.82%、4.93%、2.54%, 并且在检测到故障发生后, 可以很好得识别出故障种类。

参考文献:

- [1] Ku W, Storer R H, Georgakis C. Disturbance detection and isolation by dynamic principal component analysis [J]. Chemometrics and Intelligent Laboratory Systems, 1995, 30 (1): 179-196.
- [2] 赵乃卓, 伍江超. 基于 PCA 和信息融合理论的传感器故障诊断 [J]. 计算机测量与控制, 2013, 21 (8): 2033-2035.
- [3] Chen J, Liu K C. On-line batch process monitoring using dynamic PCA and dynamic PLS models [J]. Chemical Engineering Science, 2002, 57 (1): 63-75.
- [4] Li W, Yue H, Valle S, et al. Recursive PCA for adaptive process monitoring [J]. Journal of Process Control, 2000, 10 (5): 471-486.
- [5] Bakshi B R. Multiscale PCA with application to multivariate statistical process monitoring [J]. AIChE Journal, 1998, 44 (7): 1596-1610.
- [6] He X F, Niyogi P. Locality Preserving Projections [A]. Proceedings of the 17th Annual Conference on Neural Information Processing Systems [C]. Cambridge: the MIT Press, 2003.
- [7] Yu J B. Local and global principal component analysis for process monitoring [J]. Journal of Process Control, 2012, 22 (7): 1358-1373.
- [8] 吴 斌, 于春梅, 李 强. 过程工业故障诊断 [M]. 北京: 科学出版社, 2011.
- [9] Yu C M. A novel feature selection method for process fault diagnosis. Applied Mechanics and Materials [J]. 2013, 247-249: 2045-2049.
- [10] Zhang M G, Ge Z Q, Song Z H, et al. Global-local structure analysis model and its application for fault detection and identification [J]. Industrial & Engineering Chemistry Research, 2011, 50 (11): 6387-6388.
- [11] Fu R W, Zhang M G, Song Z H, et al. Global-Local Structure Analysis for Fault Detection [A]. Proceedings of the 49th IEEE Conference on Decision and Control, Hilton Atlanta Hotel, Atlanta [C]. GA, USA, 2010: 15-17.
- [12] He X F, Cai D, Min W L. Statistical and computational analysis of locality preserving projection [A]. Proceedings of the 22nd International Conference on Machine Learning [C]. Bonn, ACM, 2005: 281-288.
- [13] 张沐光, 宋执环. 一种基于 DLPP 的动态过程故障检测方法 [J]. 华中科技大学学报, 2009, 37 (1): 62-65.
- [14] 张沐光, 宋执环. LPMVP 算法及其在故障检测中的应用 [J]. 自动化学报, 2009, 35 (6): 766-772.
- [15] Chiang L H, Russell E L, Braatz R D. Fault detection and diagnosis in industrial systems [M]. London: Spring-Verlag, 2001.