基于密度标准误差的局部保持投影故障检测策略

张 成, 郭青秀, 冯立伟, 李 元[†]

(沈阳化工大学 技术过程故障诊断与安全性研究中心, 辽宁 沈阳 110142)

摘要:针对协方差结构具有显著差异的多模态过程故障检测问题,本文提出一种基于密度标准误差的局部保持 投影故障检测策略(LPP-DSE).首先,根据样本距离矩阵确定样本截止距离;接下来,应用截止距离计算每个样本的 本质密度及其前k近邻样本的估计密度;最后,通过样本的密度误差及其k近邻密度的标准差构建统计量并完成过 程监控.本文方法通过应用局部保持投影(LPP)对过程数据进行维数约减可以保证过程监控的及时性;同时,通过设 计密度标准误差(DSE)统计量可以有效提高多模态过程的故障检测率.此外,本文给出基于贡献图的诊断方法能够 准确识别故障发生的原因.通过数值例子和半导体工业实例测试,并与主元分析、邻域保持嵌入、局部保持投影、 k近邻故障检测等方法比较,实验结果进一步验证了LPP-DSE方法的有效性.

关键词:局部保持投影; k近邻; 多模态过程; 主元分析; 故障检测

引用格式: 张成, 郭青秀, 冯立伟, 等. 基于密度标准误差的局部保持投影故障检测策略. 控制理论与应用, 2020, 37(8): 1757 – 1765

DOI: 10.7641/CTA.2020.90406

Fault detection strategy based on density standard error associated with locality preserving projections

ZHANG Cheng, GUO Qing-xiu, FENG Li-wei, LI Yuan[†]

(Research Center for Technical Process Fault Diagnosis and Safety, Shenyang University of Chemical Technology,

Shenyang Liaoning 110142, China)

Abstract: Aiming at the fault detection of multimodal processes with significant variation in covariance of each mode, a fault detection strategy based on density standard error associated with locality preserving projections (LPP–DSE) is proposed in this paper. Firstly, calculate the cutoff distance according to sample distance matrix. Secondly, calculate respectively the intrinsic density and the estimated density of a sample through cutoff distance. Finally, build a new statistic to accomplish process monitoring. In LPP–DSE, the timeliness of process monitoring is guaranteed by using locality preserving projections (LPP); meanwhile, the fault detection rate of a multimode process is improved through using density standard error (DSE) statistic. Moreover, the proposed fault diagnosis method based on contribution chart is able to identify accurately the abnormal variables. Compared with principal component analysis, neighborhood preserving embedding, LPP, k nearest neighbor rule and other methods, the effectiveness of LPP–DSE is verified by a numerical case and semiconductor etching process.

Key words: locality preserving projections; k nearest neighbor; multimodal process; principal component analysis; fault detection

Citation: ZHANG Cheng, GUO Qingxiu, FENG Liwei, et al. Fault detection strategy based on density standard error associated with locality preserving projections. *Control Theory & Applications*, 2020, 37(8): 1757 – 1765

1 引言

随着自动化技术的快速发展,通过传感器采集的 大量工业数据被应用于不同领域.工业过程数据由于 生产系统的规模性与复杂性,通常具有大样本、非线 性、多模态、强相关等特征,例如半导体蚀刻过程具有 多中心、协方差结构不同等特点.为了获取过程数据 的有效信息,基于数据驱动的多元统计过程分析 (multivariate statistical process analysis, MSPA)方法被

收稿日期: 2019-05-30; 录用日期: 2020-03-28.

[†]通信作者. E-mail: li-yuan@mail.tsinghua.edu.cn; Tel.: +86 13082424115.

本文责任编委: 宗群.

国家自然科学基金项目(61490701, 61573088, 61673279), 辽宁省自然科学基金项目(2019–MS–262), 辽宁省教育厅基金项目(LJ2019013)资助. Supported by the National Natural Science Foundation of China (61490701, 61573088, 61673279), the Liaoning Natural Science Fund Project (2019–MS–262) and the Liaoning Provincial Department of Education Fund Project (LJ2019013).

引入工业领域[1-3].

以主元分析(principal component analysis, PCA)为 基础的各类算法作为经典的MSPA方法得到广泛应 用^[4-7].近年来,针对过程数据的不同特征,许多学者 提出了PCA的改进算法,如谭等考虑到模态过渡时变 量间相关关系的变化,提出了基于差分分段PCA的多 模态过程故障监测算法^[8].张等通过得分差分以及构 建新的监控统计量提出了基于主元分析得分重构差 分的故障检测策略,解决了PCA对于多模态过程的监 控缺陷^[9].但是上述基于PCA的方法在降维时均将数 据变化最大的方向作为降维方向,没有考虑到降维后 数据的近邻结构是否保持.

为了更好的描述低维空间中数据的结构,流形学 习被提出. 流形学习假设高维数据可以由低维空间中 的流形结构表示且该结构揭示了高维数据的内部信 息^[10]. 初期具有代表性的流形学习算法包括基于图框 架理论的局部线性嵌入算法(locally linear embedding, LLE)和拉普拉斯特征映射(laplacian eigenmaps, LE) 算法[11-12]. 随后, t-分布随机邻域嵌入(t-distribution stochastic neighbor embedding, *t*-SNE) 被 提 出^[13]. LE, LLE以及t-SNE等典型的流形学习算法在人脸识 别领域得到广泛发展,但它们均为非线性降维方法, 无法处理新的观测数据.因此,He等通过在LE,LLE 上引入线性变换提出了局部保持投影算法 (locality preserving projections, LPP)和邻域保持嵌入算法 (neighborhood preserving embedding, NPE)^[14-15]. 基 于流形学习算法的优点,它被专家广泛的应用于各个 领域[16-17]. 故障检测领域中的流形学习算法同样得 到快速发展. 马等将LLE与支持向量数据描述(support vector data description, SVDD)相结合对化工过程进 行有效监控^[18]. Jia等提出参数t-SNE(parametric t-SNE)方法,在监控较少特征的前提下,该方法能准确 识别非高斯、非线性工业过程故障数据^[19]. Hu等考虑 到LPP降维能够保持数据近邻结构的特点,将LPP引 入故障检测领域[20]. 郑等考虑到过程动态性提出了动 态稀疏局部保持投影[21].

值得注意的是,上述基于PCA以及LPP算法在对 过程进行监控时均使用Hotelling's T²统计量.具有多 模态结构的数据不满足T²统计量的假设条件,即假设 数据服从多元高斯分布,因此基于PCA以及LPP的算 法对多模态过程故障检测有一定的不足^[22].

针对多模态过程故障检测,He等提出了k近邻故 障检测(k nearest neighbor rule, kNN)算法^[23]. kNN算 法利用样本的前k近邻距离之和作为统计量来判断样 本状态,能够有效的识别过程故障.但是,当各个模态 的离散程度显著不同且故障发生在密集模态时,kNN 算法会出现故障漏报的情况.近年来许多学者对kNN 进行改进以提高疏密程度不同的多模态过程故障检 测率(fault detection rate, FDR)^[24-25]. 然而上述基于 *k*NN的算法有一个共同的缺陷,即计算量大. 通常,除 了故障检测的准确性、及时性,计算复杂度同样是评 价过程监控方法的重要指标.

针对疏密程度不同的多模态过程故障检测问题, 本文提出一种基于密度标准误差的局部保持投影故 障检测策略 (fault detection strategy based on density standard error associated with locality preserving projections, LPP–DSE). 首先,根据截止距离 (cutoff distance, dc)确定每个样本的密度与其前k近邻的均值密 度;其次,将上述两种密度作差得到密度误差;最后, 将样本的密度误差与前k近邻的密度标准差的比值作 为新的统计指标,即密度标准误差.当待测样本被判 定为故障样本后,本文提出了基于贡献图的密度标准 误差诊断策略.本文余下章节安排如下:第2节简要描 述LPP算法;第3节详细介绍LPP–DSE故障检测及诊 断策略;第4节通过数值例子和半导体工业实例来验 证算法的有效性;第5节为结论.

2 局部保持投影

LPP通过寻找投影矩阵A将输入数据 $X_{m \times n}$ 投影 到低维特征空间 $Y_{m \times l}$ ($l \leq n$), 即Y = XA, m为样 本数, n为原始数据变量数, l为特征空间维数.

LPP通过优化下式目标函数求解投影矩阵A:

$$\begin{cases} \min \frac{1}{2} \sum_{ij} (\boldsymbol{y}_i - \boldsymbol{y}_j)^2 W_{ij}, \\ \text{s.t. } \boldsymbol{a}^{\mathrm{T}} \boldsymbol{X}^{\mathrm{T}} \boldsymbol{D} \boldsymbol{X} \boldsymbol{a} = 1, \end{cases}$$
(1)

其中: **W**为权重矩阵, **D**是对角矩阵且 $D_{ii} = \sum_{j} W_{ij}$. 本节中 W_{ij} 的计算采取热核法, 即 $W_{ij} = e^{-\frac{\|\boldsymbol{w}_i - \boldsymbol{w}_j\|^2}{t}}$, 其中t为热核参数^[14], 更多的 W_{ij} 计算方式可见文献

[26].

通过简单的代数运算,式(1)可转化为式(2):

$$\begin{cases} \min \boldsymbol{a}^{\mathrm{T}} \boldsymbol{X}^{\mathrm{T}} \boldsymbol{L} \boldsymbol{X} \boldsymbol{a}, \\ \text{s.t. } \boldsymbol{a}^{\mathrm{T}} \boldsymbol{X}^{\mathrm{T}} \boldsymbol{D} \boldsymbol{X} \boldsymbol{a} = 1, \end{cases}$$
(2)

其中*L* = *D* - *W*为拉普拉斯矩阵.通过拉格朗日 函数法可将最优化求解问题转化为广义特征值问题, 如式(3)所示:

$$\boldsymbol{X}^{\mathrm{T}}\boldsymbol{L}\boldsymbol{X}\boldsymbol{a} = \lambda \boldsymbol{X}^{\mathrm{T}}\boldsymbol{D}\boldsymbol{X}\boldsymbol{a}.$$
 (3)

由式(3)求出的前l个最小的特征值所对应的特征向量 构成的矩阵即为投影矩阵A,即 $A = (a_1, a_2, \cdots, a_l)$.

与PCA相同, LPP同样采用T²统计量对特征空间 进行监控^[20], 如式(4)所示:

$$T^2 = \boldsymbol{y}\boldsymbol{\Lambda}^{-1}\boldsymbol{y}^{\mathrm{T}},\tag{4}$$

其中**A**为数据集**Y**的协方差矩阵.**T**²统计了特征空间 中样本点到原点的马氏距离,其控制限可由核密度估 计法(kernel density estimation, KDE)确定^[27].

3 基于密度标准误差的局部保持投影故障 检测策略

基于LPP降维可以保持数据局部结构的优点以及 过程监控对于降低计算量的需求,LPP被广泛应用于 故障检测领域.传统LPP使用T²作为统计指标对特征 空间进行故障检测,T²控制限在二维和三维空间分别 为椭圆和椭球^[22].当变量服从多元高斯分布时,T²控 制图可以准确识别故障.当变量具有非线性结构或多 模态结构时,T²控制图的故障检测能力明显下降.针 对LPP在检测多模态过程时T²统计量的不足,本节提 出一种密度标准误差统计量来代替T²对多模态过程 进行监控.

假设 y_i 与 y_j 为LPP降维后特征空间的样本点.两点间欧式距离如式(5)所示:

$$s(y_i, y_j) = \|y_i - y_j\|^2.$$
 (5)

 y_i 的密度如式(6)所示:

$$\rho_i = \operatorname{num}(\odot \boldsymbol{y}_i, dc), \tag{6}$$

其中 ρ_i 表示以 \boldsymbol{y}_i 为圆心、以截止距离dc为半径所形成 的圆内包含样本点的个数. 当 \boldsymbol{y}_i 位于稀疏模态时, ρ_i 较小; 当 \boldsymbol{y}_i 位于密集模态时, ρ_i 较大. 截止距离dc计算 方法如式(7)–(8)所示:

$$dc = D_{r-\text{th}},\tag{7}$$

$$r-\text{th} = \text{round}(\varsigma \times \text{num}(D)),$$
 (8)

其中D_{r-th}为D中第r个元素的值,D由步骤①至④求 解可得:

① 由式(5)得到样本距离矩阵S;

② 将**S**下三角区域元素赋值为0, **S**上三角区域保 留原始数值;

③ 将S矩阵按行排列得到行向量;

④ 去除行向量中0元素并升序排列.

num(D)表示集合D中元素的个数; round为四舍 五入取整函数; ς为可选参数, 由式(6)-(8)可知, ς的取 值对ρ_i具有决定性作用. 通过与样本密度交叉验证确 定ς的值, 当各模态密度差异最大时确定最优的ς. 截 止距离dc是衡量样本密度的重要参数. dc本质上代表 圆的半径, 直接决定了样本密度值. 当dc较大时, ρ_i可 能出现跨模态情况; 当dc较小时, ρ_i可能为0. 密度在 一定程度上反应出样本的离散程度. 同一模态中样本 的密度应位于同一尺度, 因此, 离散程度不同的多模 态过程中样本密度也呈现典型的多模态特征.

定义 y_i 监控指标密度标准误差 ρ_{e-i} 如式(9)所示:

$$\rho_{e-i} = \frac{e_i}{\sigma_i},\tag{9}$$

其中: $e_i = |\rho_i - \rho_i^m|$, $\rho_i^m \supset y_i$ 的前k近邻样本 y_i^k 的密 度均值; $\sigma_i \supset y_i$ 的前k近邻样本 y_i^k 的密度标准差. ρ_i^m 代表样本近邻的平均疏密程度, e衡量了样本 y_i 与其 前k近邻样本 y_i^k 的密度误差. e较大时代表 y_i^k 与其近 邻疏密程度差异较大,则可判定该点为离群点或故障 点. 前k近邻样本标准差可将样本统计值调整到较平 稳的状态, k取值规则见注释.

注1 由于计算样本前k近邻的密度标准差涉及到参数 k,因此k的值经过重复实验选取.k太小导致近邻少,则容易 出现近邻密度相同.k 太大会导致近邻跨模态.因此参数k的 合理选取可以避免近邻密度标准差为0.

注2 当密度误差为0时,代表当前样本密度与其前k近 邻样本均值相同,即表示当前样本处于正常样本中,间接验证 了当前样本为正常样本.然而密度误差为0会对控制限造成 影响,因此需要调整参数k避免该情况.

LPP-DSE故障检测方法共分为两步:离线建模与 在线检测.图1为LPP-DSE故障检测流程图.



图 1 LPP-DSE故障检测流程图

Fig. 1 Flow chart of fault detection method using LPP-DSE

1) 离线建模.

① 利用Z-SCORE标准化对原始数据X进行预处理.

② 将预处理后的数据经由LPP投影到特征空间, 投影后数据记为**Y**.

③ 由式(5)计算Y的上三角距离矩阵S.

④ 根据式(7)-(8)确定截止距离dc.

⑤ 由式(9)计算样本 y_i 的密度标准误差 ρ_{e-i} .

⑥ 根据KDE确定控制限 $\rho_{e-\text{UCL}}$.

2) 在线检测.

对于测试样本x*:

① 利用离线建模阶段的均值与标准差对*x**进行标准化.

② 将预处理后的*x**经由LPP投影到特征空间,投影后数据记为*y**.

③ 根据式(9)计算y*的密度标准误差 ρ_e^* .

④ 比较 ρ_{e}^{*} 与 $\rho_{e-\text{UCL}}$. 若 $\rho_{e}^{*} > \rho_{e-\text{UCL}}$,则 x^{*} 为故 障样本; 否则 x^{*} 为正常样本.

样本被判定为故障样本后,准确的诊断程序有利于识别异常变量以便保证工序正常运行.接下来对LPP-DSE算法诊断部分进行说明.

由于某些变量的异常变化,故障样本的密度值小于正常样本的密度值,即故障样本偏离正常样本的分布区域.本质上,故障样本与其近邻中心的距离大于 正常样本与其近邻中心的距离.

诊断过程包含如下两个部分:特征空间与原始空 间.

1) 特征空间.

对于特征空间中的样本**y**,**y**与其近邻中心**m**的距 离如式(10)所示:

$$\kappa = \boldsymbol{\xi} \boldsymbol{\xi}^{\mathrm{T}}, \qquad (10)$$

其中 $\xi_i = y_i - m_i$ ($i = 1, 2, \dots, l$). 变量 y_i 对样本y与 其近邻中心距离的贡献如式(11)所示:

$$\operatorname{con}_{-}y_{i} = \boldsymbol{\xi} \boldsymbol{Z} \boldsymbol{Z}^{\mathrm{T}} \boldsymbol{\xi}^{\mathrm{T}}, \qquad (11)$$

其中Z为l阶零方阵且Z(i,i) = 1.

2) 原始空间.

假设特征空间中的第*i*个得分对故障样本与其近 邻中心的距离贡献较大,即原始样本*x*向第*i*个特征方 向投影时对上述距离贡献较大,则样本*x*的第*j*个变量 对故障样本与其近邻中心的距离贡献如式(12)所示:

$$\operatorname{con}_{x_j} = x_j \times \boldsymbol{I}_j \times \boldsymbol{\Psi}, \tag{12}$$

其中: $\Psi = P_i P_i^{\mathrm{T}} x$, I_j 为n阶单位阵的第*j*行.

根据以上论述, LPP-DSE算法总结如下:

① 由于LPP能够在特征空间保持原始数据的近 邻结构,因此数据能够被有效投影到特征空间从而降 低了过程监控的复杂度.除此之外,LPP降维可以消除 数据离群点对模型建立的影响.

② DSE通过密度误差与近邻密度标准差将多模态结构调整为单模态结构,即DSE消除了多模态数据的多中心、离散程度不同等特征,从而提高多模态过程故障检测率.

③ 待测样本被检测为故障样本后,基于贡献图的 诊断策略被提出.通过监控样本各变量对故障的贡献 确定故障样本的失控变量.

4 仿真实验

4.1 数值仿真

通过一个数值例子对LPP-DSE进行验证并与其 他传统方法进行比较,其具体模型如下:

$$\boldsymbol{X} = \begin{bmatrix} t & s \end{bmatrix} \cdot \boldsymbol{\Phi},\tag{13}$$

其中: t = s为驱动变量, 模态1中 $t \sim U(1,2)$, 模态2中 $t \sim U(-11,2)$, 两个模态中 $s \sim U(0,10)$. 变换矩阵 **\Phi**如式(14)所示:

$$\boldsymbol{\Phi} = \begin{pmatrix} 5 & 0 & 0.5 \\ 0 & 5 & 0.5 \end{pmatrix}. \tag{14}$$

每个模态各生成400个训练数据用于训练模型. 各 模态生成10个样本用于校验模型有效性. 将模态2中 驱动变量t设置为t ~ U(0.5,0.7), 由此生成10个故障 样本. 并在密集模态生成少量离群点. 其数据散点图 如图2所示. 由图可知, 原始数据呈现出典型的疏密程 度不同的多模态特征, 其中故障由密集模态产生.



图 2 数据散点图 Fig. 2 Scatter plots of samples

接下来利用LPP-DSE对该例进行检测. LPP降维 后保留了原始数据的局部结构, 如图3所示.





由图可知, LPP在特征空间中保持了原始数据的 多模态特征, 且故障样本依旧偏离正常样本. 此外, LPP还减少了训练数据离群点对模型建立的影响, 如 图4所示.



Fig. 4 Boxplots

原始空间中变量3存在少量离群点,而LPP降维后的特征空间中变量无离群点.多模态数据的密度也呈现典型的多模态特征,如图5(a)所示.当密集模态发生小尺度故障时,故障的密度位于两个模态训练数据的密度之间,因此故障难以被分离.通过计算样本的密度标准误差,两个模态样本密度的中心以及离散程度近似相同.由此可见,DSE消除了多模态数据的多中心结构并将不同模态的密度调整到同一尺度,如图5(b)所示.



Fig. 5 Density analysis

由于LPP-DSE结合了LPP降维的优势以及DSE能够调整模态结构的特点,因此LPP-DSE检测出全部故障,如图6所示.为了验证参数k对检测结果的影响, 表1列出不同k值对应的FDR.当k太小时,密度误差为 0导致控制限制定不合理,因此FDR为0.随着k的逐渐 增大,FDR也随之增高.考虑到计算量的问题,当FDR 为100%时,最小k值被认为最优,本例为k = 11.



Fig. 6 Fault detection results using LPP–DSE

表1 不同k值的故障检测率

Table 1 FDR of different k values								
k	3	4	5	6	7	8	9	10
FDR/%	0	0	80	90	90	90	90	90

为了验证LPP-DSE的有效性,本节还利用PCA, LPP, NPE, kNN, DSE进行了实验. PCA中主元数根据 累计贡献率^[28]达到90%确定. 各方法参数设置及FDR 如表2所示.

表 2 各方法参数确定及故障检测率

Table 2 Parameter determination and FDR of method

方法	r	k	t	ς	FDR/%
PCA	2	_		_	0
LPP	2		0.5	_	0
NPE	2		_	—	0
kNN		3	_	—	0
LPP-kNN	2	3	0.5	—	0
DSE		11	_	0.05	90
LPP-DSE	2	11	0.5	0.05	100

PCA, LPP和NPE的FDR均为0. 作为典型的线性 降维算法, 它们可以将数据根据不同规则映射到低维 空间. 对多模态过程进行监控时, T²被作为监控统计

量,而低维空间中的多模态数据不符合统计量的分布 假设,因此PCA,LPP和NPE检测故障失效.考虑到数 据的多模态特征,*k*NN被用于测试该例.*k*NN故障检 测率为0的原因是不同模态疏密程度差异较大,控制 限完全根据稀疏模态确定,因此密集模态的小尺度故 障被检测为正常.LPP-*k*NN算法虽然降低了检测过 程的计算量,但降维后数据模态疏密程度依旧差异较 大,因此LPP-*k*NN检测率为0.针对疏密程度不同的 多模态过程,DSE被用来进行检测.DSE利用样本与 其近邻的标准误差来判定样本状态为正常还是故障. 但当原始数据中变量存在异常值时会影响DSE统计 量的稳定性,如图4(a)所示,这会导致控制限确定不合 理从而造成故障漏报现象,因此其故障检测率为90%.

根据LPP-DSE对该例的检测结果,本节对已检测 出的故障进行诊断,如图7所示.由图7(a)可知,特征 空间中的变量1对故障的贡献较大.根据式(11)对异常 变量进行回溯,原始空间中的变量1被诊断为异常变 量,如图7(b)所示.除此之外,原始空间变量3由0.5t + 0.5s构成,当驱动变量t发生偏移时,变量3理应偏离 正常区域,然而图7(b)并未诊断出变量3的异常.未诊 断出变量3是因为变量3的分布范围远远小于变量1与 变量2的分布范围,因此当变量3发生微小偏移时,偏 移幅值被变量1的偏移幅值淹没.





为了验证诊断方法的有效性,将数值例子的故障 设置为由驱动变量*s*的异常变化引起.数据在特征空 间的散点图如图8所示,诊断结果如图9所示.





由图9(a)可知,在特征空间中,变量2被诊断为异常变量.由图8可知,特征空间中故障样本的变量2偏离正常区域,两图所反映事实互相吻合.由图9(b)可知,原始空间中的变量2被诊断为异常变量,诊断结果符合故障设置,证明诊断策略有效.

4.2 半导体蚀刻过程

本节数据源自于美国德州的半导体生产中铝蚀刻 工艺过程^[29].数据集共包含3组实验的108个正常晶 片数据与21个故障晶片数据.由于第56个正常晶片存 在数据缺失,因此本节只采用107个正常晶片用于建 模和校验^[3].由于半导体数据为批次数据,因此过程 监控前需要将三维数据展开为二维数据.本节利用统 计模量分析(statistics pattern analysis, SPA)方法展开数据^[30]. SPA将每个批次中各变量的均值、方差、偏度与峭度等规则排列为一行作为监控样本. 原始半导体数据共有20个变量, 通过SPA展开后变量数为80, 即过程共包含80个变量.

本节利用PCA, LPP, NPE, kNN, DSE和LPP-DSE 对半导体蚀刻过程进行监控, 各方法参数设置如表3 所示.

表 3 各方法参数确定

Table 3 Parameter determination of methods

方法	r	k	t	ς
PCA	34	_	_	_
LPP	34	—	11	—
NPE	35		—	—
kNN	—	5	—	—
DSE	—	10	—	0.37
LPP-DSE	34	5	11	0.34

由于PCA, LPP和NPE均利用T²作为统计量, 因此 半导体数据的多中心特征导致这类方法未能检测出 全部故障, 检测率如表4所示.由于半导体过程中3个 模态的中心与疏密程度不同, 如图10所示, 因此kNN 检测率仅为38.1%. DSE虽然融合了半导体过程的多 中心结构, 但对于训练样本的边缘点较为敏感, 导致 控制限被边缘点影响, 因此DSE检测率为33.3%. LPP –DSE检测结果如图11所示. LPP将原始80维数据投 影到34维特征空间, 在保持数据局部结构的前提下不 仅降低了计算复杂度, 还降低了离群点的影响. DSE 通过密度标准误差将3个模态融合为疏密程度近似相 同的单模态结构, 从而成功检测出21个故障, 如图11 和表4所示.







图 11 LPP-DSE检测结果

Fig. 11 Fault detection results using LPP-DSE

表4 故障检测率

方法	检测率/%
$PCA-T^2$	57.1
$LPP-T^2$	61.9
NPE $-T^2$	76.2
k NN– D^2	38.1
$\text{DSE-}\rho_e$	33.3
LPP–DSE– ρ_e	100

接下来,本节对检测出的故障进行诊断分析.以故障1为例,特征空间中故障1的变量2对统计值的贡献 最大,如图12所示.





图13为原始空间中变量对统计值的贡献,由图13 以及SPA展开时变量的排列可知,故障1中变量13对 统计值 ρ_e 的贡献最大.根据文献[30]可知,故障1的类 型为TCP+50,变量13对应TCP impedance.





图14为训练数据与故障数据变量13轨迹图,进一步验证了故障样本的变量13发生偏移,从而证实了诊断策略的有效性.故障2与故障3的诊断结果分别在图 15与图16给出.由诊断结果分析可知,故障2与故障3 分别由变量12(RF impedance)与变量11(RF power)异 常变化引起,符合故障设置^[30].







Fig. 16 Contribution plots of fault 3 in raw space

5 结论

本文提出了一种基于密度标准误差的局部保持投 影故障检测策略以提高多模态过程的故障检测率.该 方法既继承了LPP降维后保持数据结构的优点,又降 低了过程监控的复杂度;DSE通过计算降维后样本的 密度标准误差将各模态的离散程度调整到同一尺度. 通过仿真实验以及结果分析验证了LPP-DSE的有效 性.

由于本文中参数ς对于样本的密度影响较大,因此 下一步研究方向为减少参数ς对于检测结果的影响.

参考文献:

- WESTERHUIS J A, GURDEN S P, SMIIDE A K. Generalized contribution plots in multivariate statistical process monitoring. *Chemometrics & Intelligent Laboratory Systems*, 2000, 51(1): 95 – 114.
- [2] BAKSHI B R. Multiscale PCA with application to multivariate statistical process monitoring. *Aiche Journal*, 2010, 44(7): 1596 – 1610.
- [3] GALLAGHER N B, WISE B M, BUTLER S W, et al. Development and benchmarking of multivariate statistical process control tools for a semiconductor etch process: improving robustness through model updating. *IFAC Proceedings Volumes*, 1997, 30(9): 79 – 84.
- [4] SHAMS M A B, BUDMAN H M, DUEVER T A. Fault detection, identification and diagnosis using CUSUM based PCA. *Chemical Engineering Science*, 2011, 66(20): 4488 – 4498.
- [5] KU W, STORER R H, GEORGAKIS C. Disturbance detection and isolation by dynamic principal component analysis. *Chemometrics & Intelligent Laboratory Systems*, 1995, 30(1): 179 – 196.
- [6] LEE J M, YOO C K, CHOI S W, et al. Nonlinear process monitoring using kernel principal component analysis. *Chemical Engineering Science*, 2004, 59(1): 223 – 234.
- [7] KANO M, HASEBE S, HASHIMOTO I, et al. A new multivariate statistical process monitoring method using principal component analysis. *Computers & Chemical Engineering*, 2001, 25(7/8): 1103 – 1113.
- [8] TAN Shuai, WANG Fuli, CHANG Yuqing, et al. Fault detection of multi-mode process using segmented PCA based on differential transform. *Acta Automatica Sinica*, 2010, 36(11): 1626-1636. (谭帅, 王福利, 常玉清, 等. 基于差分分段PCA的多模态过程故障监 测. 自动化学报, 2010, 36(11): 1626-1636.)

[9] ZHANG Cheng, GUO Qingxiu, LI Yuan, et al. Fault detection strategy based on difference of score reconstruction associated with principal component analysis. *Control Theory & Applications*, 2018, 36(5): 774 – 782.

(张成,郭青秀,李元,等.基于主元分析得分重构差分的故障检测策略.控制理论与应用,2018,36(5):774-782.)

- [10] WANG J, ZHONG B, ZHOU J. Quality-felevant fault monitoringbased on locality preserving partial least squares statistical models. *Industrial & Engineering Chemistry Research*, 2017, 56(24): 7009 – 7020.
- [11] ROWEIS S T. Nonlinear dimensionality reduction by locally linear embedding. *Science*, 2000, 290(5500): 2323 – 2326.
- [12] BELKIN M, NIYOGI P. Laplacian eigenmaps for dimensionality reduction and data representation. *Neural Computation*, 2003, 15(6): 1373 – 1396.
- [13] LAURENS V D M. Accelerating t–SNE using tree-based algorithms. *Journal of Machine Learning Research*, 2014, 15(1): 3221 – 3245.
- [14] HE X F, NIYOGI P. Locality preserving projections. *The 17th Annu*al Conference on Neural Information Processing Systems. Vancouver, BC, Canada: Neural Information Processing Systems Foundation, 2003, 16: 153 – 160.
- [15] HE X, DENG C, YAN S, et al. Neighborhood preserving embedding. *The 10th IEEE International Conference on Computer Vision*. Piscateway, NJ, USA: IEEE, 2005: 1208 – 1213.
- [16] ZHOU J L, REN Y W, WANG J. Quality-relevant fault monitoring based on locally linear embedding orthogonal projection to latent structure. *Industrial & Engineering Chemistry Research*, 2019, 58(3): 1262 – 1272.
- [17] LUO L, BAO S, GAO Z, et al. Tensor global-local preserving projections for batch process monitoring. *Industrial & Engineering Chemistry Research*, 2014, 53(24): 10166 – 10176.
- [18] MA Yuxin, WANG Mengling, SHI Hongbo. Fault detection for chemical process based on locally linear embedding. *CIESC Journal*, 2012, 63(7): 2121 2127.
 (马玉鑫, 王梦灵, 侍洪波. 基于局部线性嵌入算法的化工过程故障 检测. 化工学报, 2012, 63(7): 2121 2127.)
- [19] JIA R X, WANG J, ZHOU J L. Fault diagnosis of industrial process based on the optimal parametric t-distributed stochastic neighbor embedding. *Science China (Information Sciences)*, 2019, doi: 10.1007/ s11432-018-9807-7.
- [20] HU K, YUAN J. Multivariate statistical process control based on multiway locality preserving projections. *Journal of Process Control*, 2008, 18(7/8): 797 – 807.
- [21] ZHENG Xin, TIAN Xuemin, ZHANG Hanyuan. Fault detection method based on dynamic sparse locality preserving projections. *CI-ESC Journal*, 2016, 67(3): 833 – 838.

(郑鑫,田学民,张汉元.基于动态稀疏保局投影的故障检测方法.化工学报,2016,67(3):833-838.)

- [22] MASON R L, CHOU Y M, YOUNG J C. Applying Hotelling's T² statistic to batch processes. *Journal of Quality Technology*, 2001, 33(4): 466 – 479.
- [23] HE Q P, WANG J. Fault detection using the k-nearest neighbor rule for semiconductor manufacturing processes. *IEEE Transactions on Semiconductor Manufacturing*, 2007, 20(4): 345 – 354.
- [24] ZHANG Cheng, GAO Xianwen, XU Tao, et al. Fault detection strategy of independent component-based k nearest neighbor rule. Control Theory & Applications, 2018, 35(6): 805 812.
 (张成,高宪文,徐涛,等.基于独立元的k近邻故障检测策略. 控制理 论与应用, 2018, 35(6): 805 812.)
- [25] MA H, HU Y, SHI H. A novel local neighborhood standardization strategy and its application in fault detection of multimode processes. *Chemometrics & Intelligent Laboratory Systems*, 2012, 118(7): 287 – 300.
- [26] CAI D, HE X, HAN J. Document clustering using locality preserving indexing. *IEEE Transactions on Knowledge and Data Engineering*, 2005, 17(12): 1624 – 1637.
- [27] TERRELL G R, SCOTT D W. Variable kernel density estimation. Annals of Statistics, 1992, 20(3): 1236 – 1265.
- [28] VALLE S, LI W, QIN S J. Selection of the number of principal components: the variance of the reconstruction error criterion with a comparison to other methods. *Industrial & Engineering Chemistry Research*, 1999, 38(11): 4389 – 4401.
- [29] YANG J G, ZHANG J, YANG J X, et al. A principal component analysis based fault detection method in etch process of semiconductor manufacturing. *Key Engineering Materials*, 2012, 522(8): 793 – 798.
- [30] HE Q P, WANG J. Statistics pattern analysis: a new process monitoring framework and its application to semiconductor batch processes. *Aiche Journal*, 2015, 57(1): 107 – 121.

作者简介:

张 成 副教授,博士研究生,目前研究方向为复杂工业过程故障 诊断, E-mail: zhangcheng@syuct.edu.cn;

郭青秀 硕士研究生,目前研究方向为复杂工业生产过程智能建 模等,E-mail: 505087396@qq.com;

冯立伟 讲师,硕士,目前研究方向为复杂工业生产过程故障检测 等,E-mail: 470348733@qq.com;

李元 教授,博士生导师,目前研究方向为复杂工业过程故障诊断,E-mail: li-yuan@mail.tsinghua.edu.cn.