

基于局部保持投影-加权 k 近邻规则的 多模态间歇过程故障检测策略

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: 针对多模态间歇过程故障检测问题, 本文提出一种基于局部保持投影-加权 k 近邻规则(LPP-WkNN)的故障检测策略。首先, 应用局部保持投影(LPP)方法将原始数据投影到低维主元子空间; 接下来, 在主元子空间中, 应用样本第 k 近邻的局部近邻集确定每个样本的权重并计算权重统计量 D_w ; 最后, 应用核密度估计方法确定 D_w 控制限并进行故障检测。本文方法应用LPP对过程数据进行维数约减, 既能够降低训练过程中离群点对模型的影响, 又能够降低在线故障检测的计算复杂度。同时, 加权 k 近邻规则(WkNN)方法通过引入权重规则能够使得过程故障检测统计量分布具有单模态结构。相比传统的 k NN统计量, 本文引入的权重统计量具有更高的故障检测性能。通过数值例子和半导体蚀刻过程的仿真实验, 并与主元分析(PCA), k NN, WkNN, LPP- k NN等方法进行比较, 实验结果验证了本文方法的有效性。

关键词: 局部保持投影; 权重 k 近邻规则; 间歇过程; 故障检测

引用格式: 张成, 郭青秀, 冯立伟, 等. 基于局部保持投影-加权 k 近邻规则的多模态间歇过程故障检测策略. 控制理论与应用, 2019, 36(10): 1682–1689

DOI: 10.7641/CTA.2019.80858

Fault detection strategy based on locality preserving projections-weighted k nearest neighbors in multimodal batch processes

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 fault detection in multimodal batch process, fault detection strategy based on locality preserving projections-weighted k nearest neighbors (LPP-WkNN) in multimodal batch processes is proposed in this paper. First, raw data are projected into low dimensional principal component subspace using locality preserving projections (LPP). Then, apply the local nearest neighbor set of the k -th nearest neighbor of the samples to determine the weight of samples and construct the weighted statistics D_w . Finally, apply kernel density estimation to determine control limits of D_w to detect faults. Dimensionality reduction using LPP is capable of not only eliminating the influence of outliers on the model, but also reducing the computational complexity of fault detection. At the same time, the weighted k nearest neighbors (WkNN) method can make the statistics of samples have a single model structure by introducing weight rules. Compared with the traditional k NN statistics, the weight statistics introduced in this paper have higher fault detection performance. The efficiency of the proposed strategy is implemented in a numerical case and in the semiconductor etching process. The experimental results indicate that the proposed method outperforms principal component analysis (PCA), LPP, k NN, WkNN and LPP- k NN.

Key words: locality preserving projections; weight k nearest neighbor rule; batch process; fault detection

Citation: ZHANG Cheng, GUO Qingxiu, FENG Liwei, et al. Fault detection strategy based on locality preserving projections-weighted k nearest neighbors in multimodal batch processes. *Control Theory & Applications*, 2019, 36(10): 1682–1689

收稿日期: 2018-11-02; 录用日期: 2019-03-13.

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

本文责任编辑: 陈增强.

国家自然科学基金项目(61490701, 61573088, 61673279), 辽宁省教育厅项目(LZ2015059), 辽宁省自然科学基金项目(2015020164)资助.
Supported by the National Natural Science Foundation of China (61490701, 61573088, 61673279), the Education Department Research Project of
Liaoning Province (LZ2015059) and the National Natural Science Foundation of Liaoning (2015020164).

1 引言

随着工业自动化技术的稳态发展, 生产过程的可靠性及安全性已成为控制领域的研究热点。数据驱动的过程监控方法只需对过程数据分析, 无需确定系统解析模型, 因此该方法在过程故障检测领域已经得到了广泛关注^[1]。

主元分析(principal component analysis, PCA)是一种典型的基于数据驱动的无监督线性降维算法^[2-3]。PCA将原始高维空间分解为主元子空间(principal component subspace, PCS)和残差子空间(residual subspace, RS), 其中PCS包含原始数据变化的主要信息, 而RS包含过程的随机噪声。通常在PCS和RS中, 分别应用Hotelling's T^2 和平方预测误差(square predicted error, SPE)来监控样本状态。由于在确定 T^2 和SPE控制限时需要假设数据服从多元高斯分布, 而非线性过程数据通常不服从多元高斯分布。因此, PCA方法在非线性过程故障检测中通常具有较低的故障检测率^[4-5]。针对PCA的上述缺陷, 基于核理论的PCA(kernel PCA, KPCA)被提出^[6]。Cheng等提出了自适应核PCA, 该方法解决了非线性过程中核PCA对微弱故障敏感度低的问题^[7]。考虑到过程的动态性, Ku等通过增广矩阵将样本序列相关性纳入其中, 提出了动态PCA(dynamic principal component analysis, DPCA)^[8]。童等考虑到不同测量变量间序列相关性差异, 提出了基于互信息的分散式DPCA故障检测方法^[9]。值得注意的是, PCA及其衍生方法都在寻找全局数据变化最大的方向作为投影方向, 但是此类方法并不能降低训练数据离群点的影响, 这将影响正常数据建模的准确性。

为了保持降维后数据的局部结构, He等提出了局部保持投影(locality preserving projections, LPP)数据降维方法。LPP是通过在拉普拉斯特征映射算法(Laplacian eigenmaps, LE)的基础上引入线性变换得到^[10]。作为典型的线性降维方法, LPP与PCA的区别在于降维后保持了数据的几何特性^[11]。由于LPP非正交基函数对数据局部结构保持产生影响, Cai等利用正交基函数提出了正交LPP(orthogonal LPP, OLPP)^[12]。Luo等为了保持数据集的全局和局部结构, 利用双目标函数提出了全局LPP(global LPP, GLPP)^[13]。然而, 上述提到的基于PCA和LPP的方法适用于单模态故障检测, 当数据具有多模态结构时, 故障检测能力下降。

针对多模态过程, He等提出了 k 近邻(k nearest neighbors, k NN)规则^[14]。 k NN通过计算样本与其近邻的距离来衡量测试样本是否偏离训练样本的轨迹, 因此该方法降低了多模态结构对故障检测的影响。但当模态间方差差异较大时, 统计量波动随之增大且统计量存在较强的自相关性, 这将引起严重的故障漏报^[15]。许多学者对 k NN进行改进以提高其故障检测率^[16-18], 但这些方法都存在计算量高且内存开销大的

问题。

针对多模态间歇过程故障检测问题, 本文提出一种基于局部保持投影—加权 k 近邻规则(locality preserving projections-weighted k nearest neighbors, LPP-WkNN)的故障检测策略。首先, 利用LPP将高维数据投影到低维空间; 接下来, 在得到的低维子空间中, 计算每个样本的近邻权重; 最后, 利用每个样本的权值距离进行故障检测。本文方法既能够继承LPP数据维数约减的优势, 又能够有效完成非线性和多模态过程的故障检测。通过模拟例子和实际间歇过程的仿真实验, 结果进一步证明了本文方法的有效性。

2 基本算法

2.1 局部保持投影

假设 $\mathbf{X}_{m \times n}$ 为数据集, 其中: m 为样本数, n 为变量数。LPP通过寻找投影矩阵 \mathbf{A} , 将 m 个高维样本点映射到低维空间, 即 $\mathbf{Y} = \mathbf{X}\mathbf{A}$, 其中 \mathbf{A} 的大小为 $n \times l$ 。LPP方法使得投影数据与原始数据的近邻结构得到保持。其具体过程如下:

首先构造目标函数, 使局部近邻结构在投影前后相似, 如式(1):

$$\min \frac{1}{2} \sum_{ij} (\mathbf{y}_i - \mathbf{y}_j)^2 W_{ij}, \quad (1)$$

其中: \mathbf{y}_i 为 \mathbf{x}_i 所对应的低维样本点, 即 $\mathbf{y}_i = \mathbf{x}_i\mathbf{a}$; \mathbf{W} 为权值矩阵, W_{ij} 表示顶点 \mathbf{x}_i 与 \mathbf{x}_j 路径的权重, 计算方法为 $W_{ij} = e^{-\frac{\|\mathbf{x}_i - \mathbf{x}_j\|^2}{t}}$ 。式(1)可化为

$$\begin{aligned} & \frac{1}{2} \min \sum_{ij} (\mathbf{y}_i - \mathbf{y}_j)^2 W_{ij} = \\ & \frac{1}{2} \min \sum_{ij} (\mathbf{x}_i\mathbf{a} - \mathbf{x}_j\mathbf{a})^T (\mathbf{x}_i\mathbf{a} - \mathbf{x}_j\mathbf{a}) W_{ij} = \\ & \frac{1}{2} \min \mathbf{a}^T \mathbf{X}^T (2\mathbf{D} - 2\mathbf{W}) \mathbf{X} \mathbf{a} = \\ & \min \mathbf{a}^T \mathbf{X}^T \mathbf{L} \mathbf{X} \mathbf{a}, \end{aligned}$$

其中: $\mathbf{L} = \mathbf{D} - \mathbf{W}$ 为拉普拉斯矩阵, \mathbf{D} 为对角矩阵且 $D_{ii} = \sum_j W_{ij}$ 。

为了保证投影向量的解唯一, 加入约束条件 $\mathbf{a}^T \mathbf{X}^T \mathbf{D} \mathbf{X} \mathbf{a} = 1$ 。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(2):

$$\mathbf{X}^T \mathbf{L} \mathbf{X} \mathbf{a} = \lambda \mathbf{X}^T \mathbf{D} \mathbf{X} \mathbf{a}. \quad (2)$$

式(2)的 p 个最小特征值所对应的特征向量构成投影矩阵 \mathbf{A} , 即 $\mathbf{A} = (\mathbf{a}_1 \ \mathbf{a}_2 \ \cdots \ \mathbf{a}_p)$ 。对于新样本 \mathbf{x}_* , 投影后可表示为

$$\mathbf{y}_* = \mathbf{x}_* \mathbf{A}. \quad (3)$$

LPP与PCA采用相同的统计指标 T^2 来监控主元子空间的变化,

$$T^2 = \mathbf{x} \mathbf{A} \mathbf{C}^{-1} \mathbf{A}^T \mathbf{x}^T, \quad (4)$$

其中 \mathbf{C} 为数据集 \mathbf{Y} 的协方差矩阵。 T^2 的控制限可由式

(5)确定:

$$T_{\text{UCL}}^2 = \frac{p(m-p)(m+1)}{m(m-r)} F_{p,m-p,\alpha}, \quad (5)$$

其中: T^2 近似服从自由度为 p 和 $m-p$ 的 F 分布, m 是样本个数, α 为置信水平, 通常选取为0.95或0.99^[1].

2.2 k 近邻规则

k NN的基本思想是正常样本的轨迹与训练样本的轨迹相似, 而故障样本的轨迹与训练样本的轨迹会呈现一定的偏移. k NN首先在训练数据集中找出每个样本的前 k 个近邻样本. 其次利用样本与其 k 近邻样本的距离累计和 D^2 作为统计指标进行故障检测, 如式(6):

$$D^2 = \sum_{j=1}^k d_j^2, \quad (6)$$

其中 d_j 表示样本与其第 j 近邻的距离. 由非中心卡方分布可以确定控制限 D_α^2 并进行故障检测. 为了方便, 控制限 D_α^2 也可根据核密度估计法(kernel density estimation, KDE)进行确定^[14].

3 基于局部保持投影-加权 k 近邻的故障检测策略

3.1 加权 k 近邻规则

LPP将高维数据投影到低维空间后, 数据的局部结构得到保持, 并且离群点敏感度降低, 在一定程度上减少了样本序列的自相关性^[19-20]. 但在确定 T^2 控制限时需要假设数据服从多元高斯分布. 在工业过程中, 数据具有非线性、多中心、时序相关、分散程度不同等特征, 这些特征使得上述假设条件难以满足. 针对 T^2 统计量上述的局限性, 本节引入WkNN方法来提高对过程的监控能力. 样本 \mathbf{x} 的加权 k NN统计量定义如式(7)所示:

$$D_w = \sum_{i=1}^k \frac{1}{\frac{1}{K} \sum_{j=1}^K d_{ji}^2} d_{ji}, \quad (7)$$

其中: d_{ji} 为样本 \mathbf{x} 与其第 i 近邻 $\bar{\mathbf{x}}_i$ 的距离, K 为 $\bar{\mathbf{x}}_i$ 的近邻个数, d_{ji}^2 为样本 $\bar{\mathbf{x}}_i$ 与其第 j 近邻的距离. 由式(6)可知 k NN统计量只考虑样本与其 k 近邻的欧式距离. 当数据集呈现多模态特征且各模态离散程度差异较大时, 稀疏模态中的样本点对统计量的贡献远大于密集模态中样本点对统计量的贡献. 而式(7)中WkNN通过对样本赋予权值将每个模态的离散程度调整到同一尺度, 使得控制限更合理的被各个模态共同确定, 消除了 k NN在多模态故障检测中的局限性.

3.2 局部保持投影-加权 k 近邻

本节针对多模态故障检测问题, 提出了基于局部保持投影-加权 k 近邻的故障检测策略. 其故障检测过程由两部分构成: 离线建模和在线检测.

3.2.1 离线建模

给定原始数据 \mathbf{X} .

a) 对原始数据利用式(8)进行Z-SCORE标准化:

$$\hat{\mathbf{X}} = \frac{\mathbf{X} - \mu}{\sigma}, \quad (8)$$

其中: μ 为 \mathbf{X} 的均值向量, σ 为 \mathbf{X} 的标准差对角矩阵.

b) 由式(2)求解得投影矩阵 \mathbf{A} , 由式(3)得到 \mathbf{X} 降维后样本集 \mathbf{Y} .

c) 在LPP主元子空间中, 由式(7)计算样本 \mathbf{y}_i 的加权 k NN统计值 D_w^i .

d) 由核密度估计法确定控制限 $D_{w\alpha}$.

3.2.2 在线检测

a) 对于测试样本 \mathbf{x}_* , 利用式(8)中的 μ 与 σ 进行标准化.

b) 由式(3), 通过投影矩阵 \mathbf{A} 将 \mathbf{x}_* 投影到与训练样本同维的低维子空间中, 得到 \mathbf{y}_* .

c) 由式(7)计算 \mathbf{y}_* 的加权 k NN统计值 D_w^* .

d) 比较 D_w^* 与 $D_{w\alpha}$ 的大小, 若 $D_w^* < D_{w\alpha}$, 则 \mathbf{x}_* 为正常样本; 否则, \mathbf{x}_* 被判断为故障样本.

4 数值模拟

本节引用文献[21]中的一个多模态数值例子来验证本文方法的有效性. 数据集包含4个变量, 其中前两个变量为主要变量, 其余变量为随机噪声. 具体模型如下:

$$\text{Mode 1 : } \begin{cases} x = t + e, \\ y = 2t + e, \end{cases} \quad t \sim U(-1, 1),$$

$$\text{Mode 2 : } \begin{cases} x = t + e, \\ y = 50 + 2t + e, \end{cases} \quad t \sim U(-5, 13).$$

每个模态各生成200个训练数据与50个校验数据. 通过对模态1中的变量 y 增加扰动, 生成100个故障数据. 数据散点图如图1所示. 由于故障尺度较小, 因此图1中模态1和故障样本均做了局部放大处理.

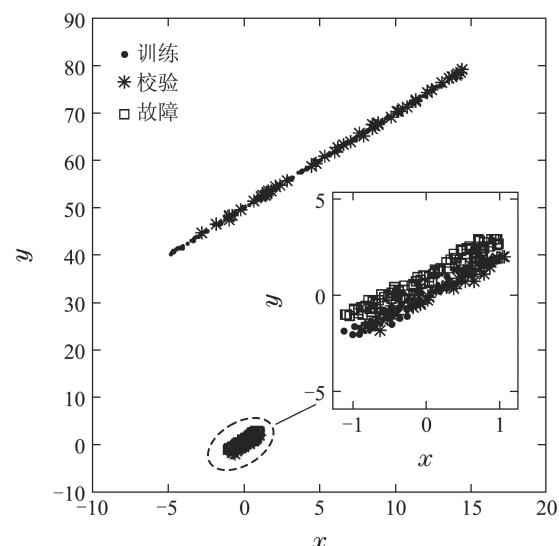


图1 数据散点图

Fig. 1 Scatter plots of samples

在本节中,本文方法及其他传统方法对该例进行了测试,具体参数设置如表1所示。主元数根据累计贡献率^[22]达到85%进行确定。近邻数k太大时增加计算量,太小时易受噪声影响,经验法一般定在3到5之间^[17~18]。 K 根据训练数据统计量自相关性^[19]与k交叉验证确定。如图2所示,当k=5时,LPP-WkNN中使训练数据统计量无自相关性的K取值范围为6~14,而WkNN中满足同样条件的K取值范围为8~11。图3给出在k=5的条件下,不同K值与LPP-WkNN统计量自相关性之间的关系。由图可知,当k取值固定时,统计量自相关性随着K值的增加而增大。

表1 参数确定

Table 1 Parameter determination

方法	PCs	k	K
LPP	2	—	—
kNN	—	5	—
WkNN	—	5	11
LPP-kNN	2	5	—
LPP-WkNN	2	5	8

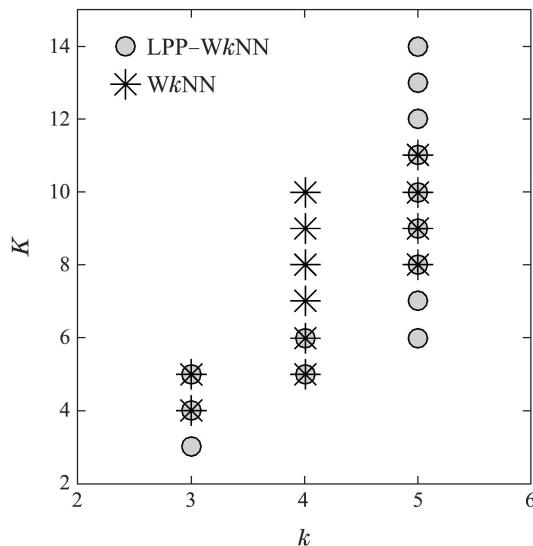


图2 k与K和统计量自相关性交叉验证

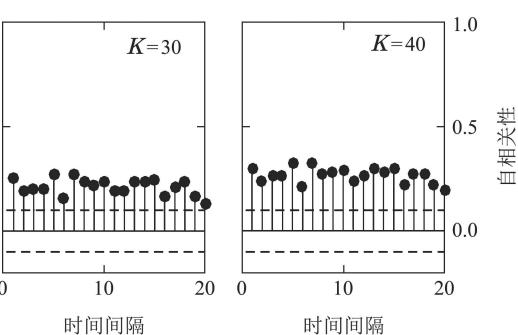
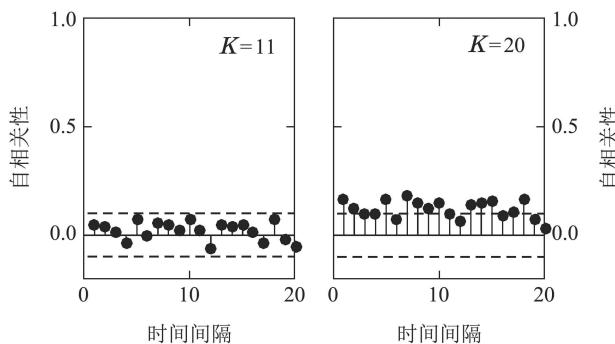
Fig. 2 Cross-validation of k , K and statistic autocorrelation

图3 不同K值的LPP-WkNN统计量自相关性

Fig. 3 Statistical autocorrelation of different K values in LPP-WkNN

图4给出LPP-T²的故障检测结果。由图可知, T^2 检测率为0, 主要原因是数据经过LPP处理后依旧保持原始分布特征, 即多模态结构, 如图5所示。由图5可知经过LPP降维后的数据并不服从多元高斯分布, 因此LPP-T²在本例中具有较低的故障检测率, 如图4所示。

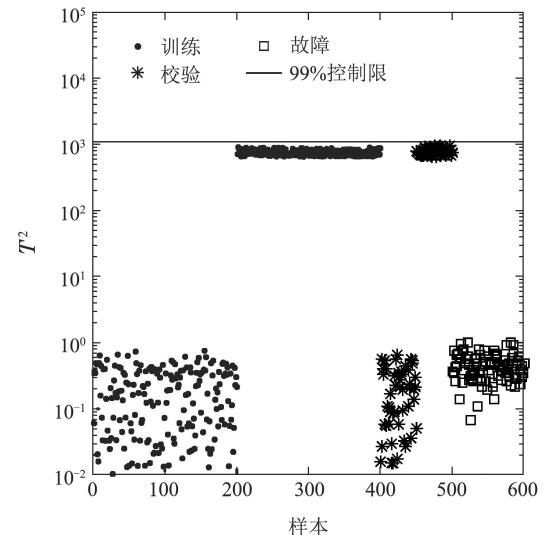


图4 LPP检测结果

Fig. 4 Fault detection results using LPP

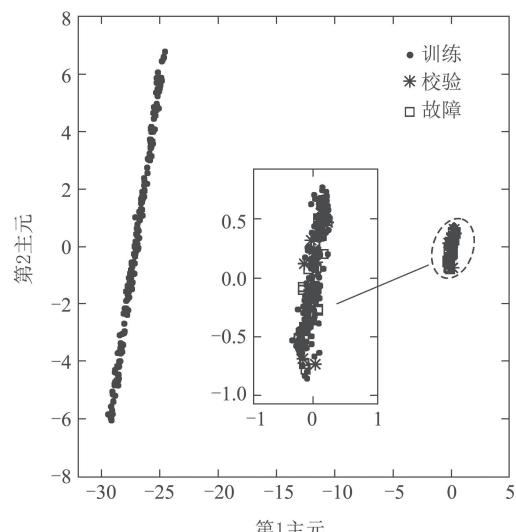


图5 LPP主元子空间散点图

Fig. 5 Scatter plots of samples in PCS using LPP

考虑到LPP主元子空间数据的分布特征,接下来在该空间中引用kNN方法进行故障检测。LPP-kNN是在kNN前利用LPP对数据进行降维,以降低kNN计算量。LPP降维后虽然数据保持了局部结构,但不同模态间的疏密程度同样被保留。由于kNN对密集模态小尺度故障不敏感,因此LPP-kNN检测率为68%,结果如图6所示。

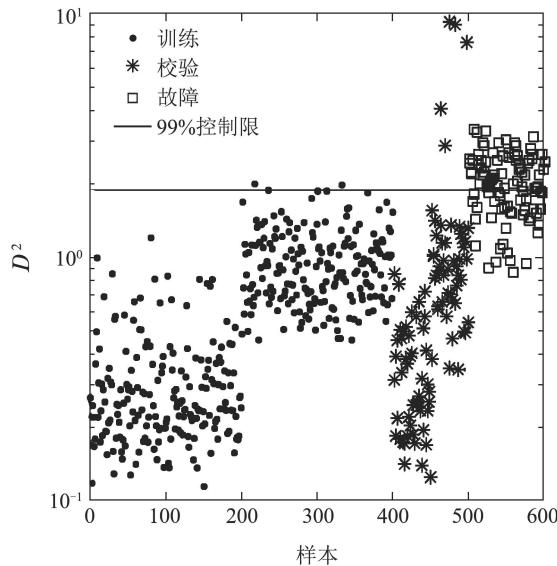


图6 LPP-kNN检测结果

Fig. 6 Fault detection results using LPP-kNN

图7为LPP-WkNN检测结果,其检测率为94%。LPP-WkNN具有较高的故障检测率的原因是WkNN通过对每个样本引入权值将模态方差差异消除,将不同模态间样本的统计值更新到同一尺度,消除模态间统计值波动。

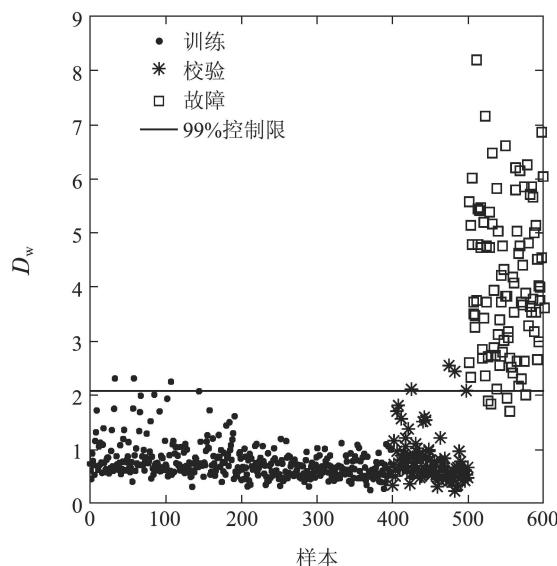


图7 LPP-WkNN检测结果

Fig. 7 Fault detection results using LPP-WkNN

除此之外,本节还利用WkNN进行试验,WkNN对该数值例子的检测率为92%。但如图8所示,LPP-

WkNN的故障检测累计耗时要远小于WkNN,且故障检测及时性要优于WkNN。在实际工业生产中,除故障检测率外,故障检测及时性也是衡量监控有效性的主要指标。

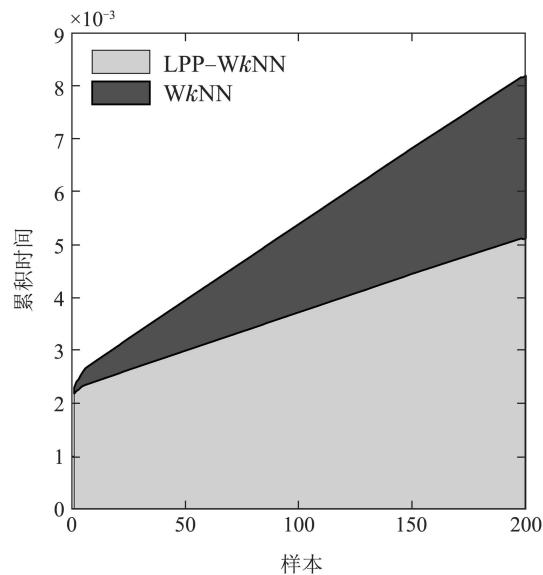


图8 WkNN与LPP-WkNN检测累计耗时

Fig. 8 Cumulative time of detection using WkNN and LPP-WkNN

5 半导体蚀刻工艺

本节数据集源于德克萨斯州仪器公司的半导体蚀刻过程^[23]。过程共包含6步:1)气体流动;2)压力稳定;3)短暂的等离子点火阶段;4)Al蚀刻;5)底层锡和氧化物的过度腐蚀;6)通风。在理想情况下,蚀刻过程是平稳的,即数据的均值与协方差不随着时间的变化而波动。但蚀刻过程的测量是不稳定的,造成过程漂移的主要原因如下:1)在机器日常维护周期间,反应器内残留物的积累导致设备老化;2)上游工序发生变化导致材料的差异;3)过程监控传感器的漂移;4)过程维护可能导致均值突然变化。以上特点对故障检测带来了一定的困难^[24]。

数据集采集自1996年二月、三月和四月进行的3个实验,分别命名为实验29、实验31、实验33。实验共生产129个晶片,其中108个正常晶片、21个故障晶片。21个故障类型如表2,其中故障1~9属于实验29,故障10~15属于实验31,故障16~21属于实验33^[25]。由于第56正常晶片和第12故障晶片数据丢失,因此检测阶段只采用107个正常晶片用于建模和20个故障晶片用于测试。

由于每个晶片包含时间和变量信息,因此原始数据被存储在一个三维矩阵中(批次×变量×时间)。传统批次展开方法通过截取批次数据使不等长批次成为等长批次,由于多元统计分析方法不能直接运用于三维矩阵,因此根据批次展开得到二维矩阵(批次×变

量), 再利用PCA进行监控. 数据展开过程中的批次截取会造成信息丢失, 并且监控变量(变量 \times 时间)的数目会随着采样时间的增加而增长. 本节利用文献[26]提出的统计模量(statistical pattern analysis, SPA)方法进行数据预处理. SPA利用各批次变量的统计值来代替样本, 如图9所示, 常用的统计值有均值、方差、偏度、峭度等. SPA展开不仅保留了过程数据的信息, 而且降低了数据维度. 考虑到检测效果以及计算量, 实验中采用变量的均值和方差代替样本信息.

表2 故障类型
Table 2 Type of faults

故障名称	故障类型	故障名称	故障类型
F1	TCP+50	F12	RF+8
F2	RF-12	F13	BC13-5
F3	RF+10	F14	Pr+2
F4	Pr+3	F15	TCP-20
F5	TCP+10	F16	TCP-15
F6	BC13+5	F17	C12-10
F7	Pr-2	F18	RF-12
F8	C12-5	F19	BC13+10
F9	He Chuck	F20	Pr+1
F10	TCP+30	F21	TCP+20
F11	C12+5		

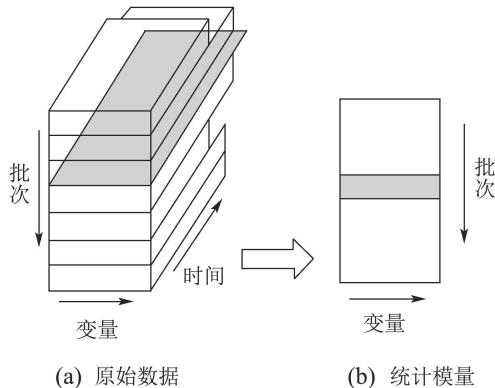


图9 统计模量框架

Fig. 9 SPA framework

本节运用LPP-WkNN进行故障检测, 并与PCA, LPP, kNN, WkNN及LPP-kNN进行对比分析, 各方法具体参数设置如表3.

表3 参数确定

Table 3 Parameter determination

方法	PCs	k	K
PCA	3	—	—
LPP	3	—	—
kNN	—	5	—
WkNN	—	5	8
LPP-kNN	3	5	—
LPP-WkNN	3	5	15

根据累计贡献率, LPP及PCA主元数设置为3, k根据文献[18]设定为5, K根据训练数据统计量自相关性与k交叉验证得k=5时, WkNN中K取值范围为2到8, LPP-WkNN中K取值范围为5到24, 如图10所示.

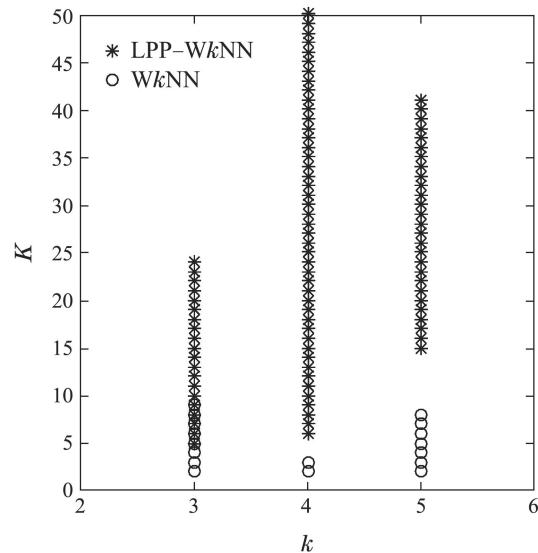


图10 k与K和统计量自相关性交叉验证

Fig. 10 Cross-validation of k , K and statistic autocorrelation

上述提及方法对半导体蚀刻过程检测率见表4所示. 由于PCA和LPP适用于单模态故障检测, 而半导体数据具有多模态特征, 因此这两种方法并未检测出全部故障. kNN在半导体过程中的故障检测率为80%, 主要原因是 D^2 的控制限被方差较大的模态 D^2 值拉高, 导致部分故障批次被淹没. 针对kNN的上述缺陷, 利用WkNN对该过程进行检测. WkNN通过引入权值将各模态离散程度调整到同一尺度, 消除了模态间离散程度不同对故障检测的影响. 但kNN与WkNN搜索近邻时需要遍历全部样本, 计算量较大.

表4 故障检测率

Table 4 Fault detection rate

方法	故障检测率/%
PCA- T^2	0.15
PCA-SPE	0.80
LPP- T^2	0.40
LPP-SPE	0.75
kNN	0.80
WkNN	0.75
LPP-kNN	0.65
LPP-WkNN	1.00

基于计算量的考虑, LPP-kNN也被用于测试. 利用LPP进行维数约减从而减少了计算量, 但并未改变其主元子空间的多模态结构, 因此LPP-kNN的检测率仅为65%.

针对上述方法在进行故障检测时的缺陷,运用LPP-WkNN进行验证。LPP降维不仅降低了离群点的影响,还减少了故障检测阶段的计算量,如图11所示。值得注意的是,LPP降维后主元子空间仍然保持多模态结构。运用WkNN将各模态离散程度调整到同一尺度再进行故障检测,因此LPP-WkNN在本文中检测率达到100%,如图12和表4所示。

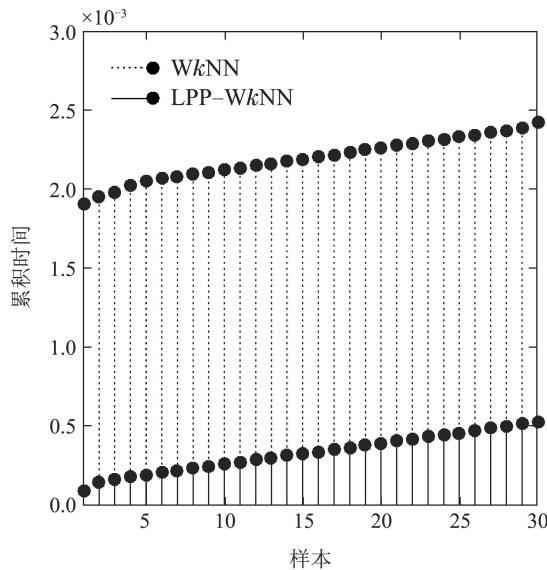


图 11 WkNN与LPP-WkNN 检测累计耗时

Fig. 11 Cumulative time of detection using WkNN and LPP-WkNN

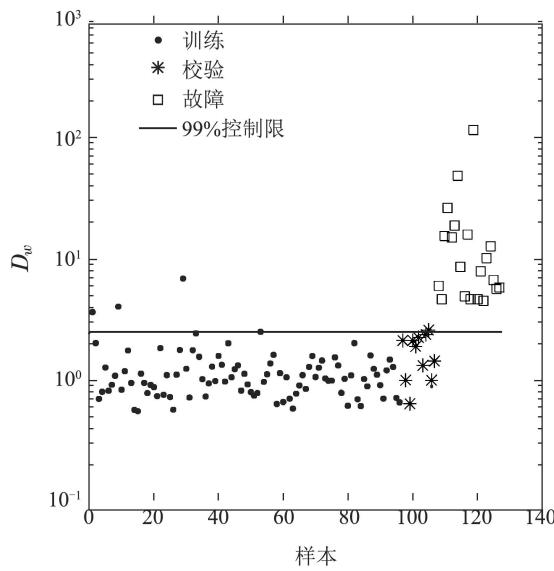


图 12 LPP-WkNN检测结果

Fig. 12 Fault detection results using LPP-WkNN

6 结论

传统LPP在故障检测时利用 T^2 作为统计量。当数据具有多模态结构时,传统LPP具有较低的故障检测率。为了提高LPP在多模态过程中的故障检测能力,本文提出一种基于LPP-WkNN的多模态间歇过程故障

检测策略。LPP-WkNN不仅降低了检测过程的计算复杂度,还通过权重规则使统计量具有单模态结构,从而提高故障检测率。通过数值例子和半导体蚀刻过程的仿真实验,结果验证了本文方法的有效性。但文中只研究了针对多模态结构的故障检测策略,因此,故障诊断与分离为下一步的研究方向。

参考文献:

- [1] ZHOU Donghua, LI Gang, LI Yuan. *Data Driven Based Process Fault Detection and Diagnosis Technology*. Beijing: Science, 2011. (周东华, 李钢, 李元. 数据驱动的工业过程故障诊断技术. 北京: 科学出版社, 2011.)
- [2] ZHAO F Z, SONG B, SHI H B. Multi-mode process monitoring based on a novel weighted local standardization strategy and support vector data description. *Journal of Central South University*, 2016, 23(11): 2896 – 2905.
- [3] ZHANG Y W, WANG C, LU R Q. Modeling and monitoring of multimode process based on subspace separation. *Chemical Engineering Research & Design*, 2013, 91(5): 831 – 842.
- [4] QIN S J. Statistical process monitoring: basics and beyond. *Journal of Chemometrics*, 2003, 17(8/9): 480 – 502.
- [5] TAMURA M, TSUJITA S. A study on the number of principal components and sensitivity of fault detection using PCA. *Computers & Chemical Engineering*, 2007, 31(9): 1035 – 1046.
- [6] LEE J M, YOO C K, SANG W C, et al. Nonlinear process monitoring using kernel principal component analysis. *Chemical Engineering Science*, 2004, 59(1): 223 – 234.
- [7] CHENG C Y, HSU C C, CHEN M C. Adaptive kernel principal component analysis (KPCA) for monitoring small disturbances of nonlinear processes. *Industrial & Engineering Chemistry Research*, 2011, 49(5): 2254 – 2262.
- [8] KU W, STOREY R H, GEORGAKIS C. Disturbance detection and isolation by dynamic principal component analysis. *Chemometrics & Intelligent Laboratory Systems*, 1995, 30(1): 179 – 196.
- [9] TONG Chudong, LAN Ting, SHI Xuhua. Fault detection by decentralized dynamic PCA algorithm on mutual information. *Journal of Chemical Industry and Engineering (China)*, 2016, 67(10): 4317 – 4323. (童楚东, 蓝艇, 史旭华. 基于互信息的分散式动态PCA故障检测方法. 化工学报, 2016, 67(10) : 4317 – 4323.)
- [10] HE X F, NIYOGI P. Locality preserving projections. *The 17th Annual Conference on Neural Information Processing Systems*. Vancouver, BC, Canada: Neural Information Processing Systems Foundation, 2003, 16: 153 – 160.
- [11] HE X, YAN S, HU Y, et al. Face recognition using laplacianfaces. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2005, 27(3): 328 – 340.
- [12] CAI D, HE X F, HAN J W, et al. Orthogonal laplacianfaces for face recognition. *IEEE Transactions on Image Process*, 2006, 15(11): 3608 – 3614.
- [13] 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.
- [14] 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.
- [15] 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.)

- [16] VERDIER G, FERREIRA A. Adaptive mahalanobis distance and nearest neighbor rule for fault detection in semiconductor manufacturing. *IEEE Transactions on Semiconductor Manufacturing*, 2011, 24(1): 59 – 68.
- [17] ZHANG C, GAO X, LI Y, et al. Fault detection strategy based on weighted distance of k nearest neighbors for semiconductor manufacturing processes. *IEEE Transactions on Semiconductor Manufacturing*, 2018, 32(1): 75 – 81.
- [18] HE Q P, WANG J. Large-scale semiconductor process fault detection using a fast pattern recognition-based method. *IEEE Transactions on Semiconductor Manufacturing*, 2010, 23(2): 194 – 200.
- [19] RATO T J, REIS M S. Fault detection in the Tennessee Eastman benchmark process using dynamic principal components analysis based on decorrelated residuals (DPCA-DR). *Chemometrics & Intelligent Laboratory Systems*, 2013, 125(7): 101 – 108.
- [20] RATO T J, REIS M S. Advantage of using decorrelated residuals in dynamic principal component analysis for monitoring large-scale systems. *Industrial & Engineering Chemistry Research*, 2013, 52(38): 13685 – 13698.
- [21] 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*, 2019, 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*, 2019, 36(5): 774 – 782.)
- [22] 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): 653 – 658.
- [23] WISE B M, GALLAGHER N B, BUTLER S W, et al. A comparison of principal component analysis, multiway principal component analysis, trilinear decomposition and parallel factor analysis for fault detection in a semiconductor etch process. *Journal of Chemometrics*, 2015, 13(3/4): 379 – 396.
- [24] 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. *Proceeding of the Safeprocess*, 1997, 30(9): 79 – 84.
- [25] NOMIKOS P, MACGREGOR J F. Monitoring batch processes using multiway principal component analysis. *Aiche Journal*, 2010, 40(8): 1361 – 1375.
- [26] 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@syt.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: 505087396@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.