

# LPMVP 算法及其在故障检测中的应用

张沐光<sup>1</sup> 宋执环<sup>1</sup>

**摘要** 针对数据信息的特征提取和降维问题, 提出一种局部保持最大方差投影 (Locality preserving maximum variance projections, LPMVP) 新算法。该算法综合考虑了主元分析 (Principal component analysis, PCA) 和局部保持投影 (Locality preserving projections, LPP) 算法的优点和不足, 提出了新的优化目标, 使投影得到的低维空间不仅和原始变量空间有相似的局部近邻结构, 而且有相似的整体结构, 因而可以包含更多的特征信息。在此基础上, 本文使用 LPMVP 算法把原始变量空间划分为特征空间和残差空间, 分别构造了  $T^2$  和 SPE 统计量对过程进行监测, 建立了一种新的故障检测方法。通过数值例子以及 TE 过程的仿真研究, 表明了 LPMVP 算法可以有效地提取数据信息, 同时也体现了较强的故障检测能力。

**关键词** 主元分析, 局部保持投影, 流形学习, 故障检测

中图分类号 TP277

## LPMVP Algorithm and Its Application to Fault Detection

ZHANG Mu-Guang<sup>1</sup> SONG Zhi-Huan<sup>1</sup>

**Abstract** In order to handle the feature extraction and dimensionality reduction problem, a new method named as locality preserving maximum variance projections (LPMVP) is developed. This algorithm can be considered as a linear approach with a new optimizing target, which takes the excellence and limitation of principal component analysis (PCA) and locality preserving projections (LPP) into account. Comparing to original variable space, this low-dimension projection space enjoys similar locality neighborhood structure and global one. As a result, more feature information can be extracted. Moreover, a new fault detection method is also proposed. The LPMVP algorithm is used to divide the original variable space into two parts: feature space and residual space. Then,  $T^2$  and SPE statistics can be built to monitor the process. Case studies of a numerical example and Tennessee-Eastman (TE) process illustrate the efficiency of the LPMVP algorithm on information extraction. Besides, the new method also shows its fault detection ability.

**Key words** Principal component analysis (PCA), locality preserving projections (LPP), manifold learning, fault detection

由于现代工业过程的复杂化、大型化, 以及分布式控制系统 (Distributed control system, DCS) 的广泛使用, 使得操作人员往往要面对成千上百维的复杂数据, 因此, 需要使用有效的特征提取和降维的方法及相应的过程监控算法, 以帮助操作员更好地了解过程的运行状态。传统的主元分析 (Principal component analysis, PCA) 降维算法在工业过程中已经有了非常广泛的应用<sup>[1-3]</sup>, 但是 PCA 算法本身只考虑了数据的全局结构, 对其他特征信息的提取并不充分<sup>[4]</sup>。流形学习 (Manifold learning) 近年来受到了模式识别和机器学习领域的密切关注, 与传统学习算法相比, 流形学习算法的优化目标是寻找原始变量空间中隐藏的低维流形信

息, 对于局部结构有较好的保持能力。流形学习的主要方法有等度规映射法 (Isometric mapping, ISOMAP)<sup>[5]</sup>, 局部线性嵌套法 (Locally linear embedding, LLE)<sup>[6]</sup>, 拉普拉斯特征映射法 (Laplacian eigenmap, LE)<sup>[7]</sup>, 局部保持投影法 (Locality preserving projections, LPP)<sup>[4]</sup> 等, 这些方法在人脸识别、手写数字识别<sup>[4-7]</sup> 等方面都已经有了成功的应用。其中局部保持投影法作为一种新的降维方法, 具有线性、局部流形保持等优点, 因而常被用于高维数据的特征提取<sup>[8-9]</sup>。但是其本身是基于局部特征保持的, 对于全局结构特征的保持没有给出明确的约束。

本文在 PCA 和 LPP 算法的基础上, 提出一种面向数据降维和特征提取的局部保持最大方差投影 (Locality preserving maximum variance projections, LPMVP) 新算法, 其基本思想是把原始变量空间投影到一个具有相似局部近邻结构的低维空间, 同时保证低维空间的方差最大化, 以保留整体的结构特征。由于综合了 PCA 保持全局结构和 LPP 保持局部特征的特点, LPMVP 算法可以从原始变量空间提取更多信息, 使投影得到的低维空间具有

收稿日期 2008-12-08 收修改稿日期 2009-02-24

Received December 8, 2008; in revised form February 24, 2009  
国家自然科学基金(60774067, 60736021)资助

Supported by National Natural Science Foundation of China  
(60774067, 60736021)

1. 浙江大学工业控制研究所工业控制技术国家重点实验室, 杭州  
310027

1. State Key Laboratory of Industrial Control Technology,  
Institute of Industrial Process Control, Zhejiang University,  
Hangzhou 310027

DOI: 10.3724/SP.J.1004.2009.00766

更好的表现能力。同时, 基于 LPMVP 较好的信息提取能力, 本文将其应用于过程监控领域, 提出了一种基于该算法的故障检测方法: 首先确定计算相似矩阵  $S$  的策略 ( $k$  最近邻法或  $\varepsilon$ -ball 法), 为参数  $k$  或  $\varepsilon$  选取合适的值, 采用 LPMVP 算法把原始变量投影到低维的特征空间, 然后通过特征空间和原始变量空间之间的关系, 计算出残差空间, 最后在特征空间和残差空间里, 分别构造合适的统计量对过程进行监测, 进而实现故障检测。

## 1 LPMVP 算法

作为特征提取和降维的经典方法, PCA 的基本思想是把数据投影到方差最大的方向, 使得重建误差最小。但是 PCA 仅仅考虑了全局结构, 忽略了局部流形特征, 因而对原始变量空间的信息利用得不够充分。另一方面, LPP 算法着眼于局部结构的保持<sup>[10]</sup>, 是利用局部结构来描述整体, 其本身并没有考虑全局的结构特征。受 PCA 和 LPP 算法的启发, 我们把保持局部流形和保存全局结构的思想结合起来, 在降维的过程中同时考虑局部和全局特征, 提出了一种 LPMVP 新算法, 目的是获取更多的信息, 提高建模效果。假设原始变量空间为  $X = [\mathbf{x}_i]_{i=1}^n \in \mathbf{R}^M$ , LPMVP 算法的基本思想是寻找一个投影矩阵  $A \in \mathbf{R}^{M \times d}$ , 使得低维空间  $Y = [\mathbf{y}_i]_{i=1}^n \in \mathbf{R}^d$  (其中  $\mathbf{y}_i = A^T \mathbf{x}_i$ ) 和  $X = [\mathbf{x}_i]_{i=1}^n \in \mathbf{R}^M$  具有相似的局部近邻结构, 同时实现低维空间的方差最大化, 以保留整体的结构特征。设  $\mathbf{a}_k \in \mathbf{R}^{M \times 1}$  为投影向量,  $y_i^k = \mathbf{a}_k^T \mathbf{x}_i$ ,  $k = 0, 1, 2, \dots, d-1$ , 投影矩阵  $A = [\mathbf{a}_0, \mathbf{a}_1, \mathbf{a}_2, \dots, \mathbf{a}_{d-1}]$  可以通过依次求解  $d$  个投影向量来构造。

因此, LPMVP 算法的优化目标可以通过以下 2 个目标方程来表示, 方程  $J(\mathbf{a}_k)_{\text{global}}$  的约束保持了整体结构特征:

$$J(\mathbf{a}_k)_{\text{global}} = \max_{\mathbf{a}_k} \sum_{i=1}^n (y_i^k - \mu_y^k)^2 \quad (1)$$

其中,  $\mu_y^k = (\sum_{i=1}^n y_i^k)/n$ , 而局部近邻结构的保持可以通过以下的目标函数  $J(\mathbf{a}_k)_{\text{local}}$  来实现<sup>[7]</sup>:

$$J(\mathbf{a}_k)_{\text{local}} = \min_{\mathbf{a}_k} \sum_{ij} (y_i^k - y_j^k)^2 S_{ij} \quad (2)$$

其中,  $S_{ij}$  随着  $\mathbf{x}_i, \mathbf{x}_j$  之间距离的缩小而增大, 因此, 最小化目标函数  $J(\mathbf{a}_k)_{\text{local}}$ , 就可以保证在原始变量空间里相近的  $\mathbf{x}_i, \mathbf{x}_j$ , 其所对应的低维空间里的  $y_i^k, y_j^k$  依然是相近的。

### 1.1 整体结构特征保持

假设过程变量为  $\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n$ ,  $J(\mathbf{a}_k)_{\text{global}}$  的

目标是寻找  $d$  个投影向量  $\mathbf{a}_0, \mathbf{a}_1, \dots, \mathbf{a}_{d-1}$ , 构成投影矩阵  $A$ , 使得  $\mathbf{y}_i = A^T \mathbf{x}_i$  满足方差最大化的要求。易知, 这正是 PCA 算法<sup>[11]</sup> 的优化目标, 因此, 式(1)可以改写为

$$\begin{aligned} J(\mathbf{a}_k)_{\text{global}} &= J(\mathbf{a}_k)_{\text{PCA}} = \max_{\mathbf{a}_k} \sum_{i=1}^n (y_i^k - \mu_y^k)^2 = \\ &\max_{\mathbf{a}_k} \sum_{i=1}^n \mathbf{a}_k^T (\mathbf{x}_i - \boldsymbol{\mu}_x) (\mathbf{x}_i - \boldsymbol{\mu}_x)^T \mathbf{a}_k = \\ &\max_{\mathbf{a}_k} \mathbf{a}_k^T C \mathbf{a}_k \end{aligned} \quad (3)$$

其中,  $C = (\sum_{i=1}^n (\mathbf{x}_i - \boldsymbol{\mu}_x)(\mathbf{x}_i - \boldsymbol{\mu}_x)^T)/n$ ,  $\boldsymbol{\mu}_x = (\sum_{i=1}^n \mathbf{x}_i)/n$ 。可以看出, PCA 寻找出的投影空间最好地保留了原始变量空间的方差信息, 因此也保存了全局结构特征。但是另一方面, PCA 算法没有考虑到样本点之间的近邻关系, 在低维的投影空间里, 样本点之间的几何关系被打乱, 从而有可能导致过程信息的丢失。

### 1.2 局部流形特征保持

假设原始变量空间为  $X = [\mathbf{x}_i]_{i=1}^n \in \mathbf{R}^M$ ,  $J(\mathbf{a}_k)_{\text{local}}$  的优化目标是寻找  $d$  个投影向量  $\mathbf{a}_0, \mathbf{a}_1, \dots, \mathbf{a}_{d-1}$ , 构成投影矩阵  $A$ , 使得低维空间  $Y = [\mathbf{y}_i]_{i=1}^n \in \mathbf{R}^d$  和  $X = [\mathbf{x}_i]_{i=1}^n \in \mathbf{R}^M$  有相似的局部近邻结构, 其中  $\mathbf{y}_i = A^T \mathbf{x}_i$ ,  $d << M$ 。易知, 这和局部保持投影<sup>[4]</sup> 的基本思想是一致的, 参照局部保持投影的算法, 这个优化目标可以进一步写为

$$\begin{aligned} J(\mathbf{a}_k)_{\text{local}} &= \min_{\mathbf{a}_k} \sum_{ij} (y_i^k - y_j^k)^2 S_{ij} = J(\mathbf{a}_k)_{\text{LPP}} = \\ &\min_{\mathbf{a}_k} \sum_{ij} (y_i^k - y_j^k)(y_i^k - y_j^k)^T S_{ij} = \\ &\min_{\mathbf{a}_k} 2 \sum_{i=1}^n y_i^k D_{ii} (y_i^k)^T - \\ &2 \sum_{ij} y_i^k S_{ij} (y_j^k)^T = \\ &\min_{\mathbf{a}_k} Y_k (D - S) Y_k^T = \\ &\min_{\mathbf{a}_k} \mathbf{a}_k^T X (D - S) X^T \mathbf{a}_k \end{aligned} \quad (4)$$

其中,  $D$  是  $n \times n$  阶的对角阵, 对角线元素  $D_{ii} = \sum_j S_{ij}$ ,  $S$  为相似矩阵, 其中的每一个元素  $S_{ij}$  表示点  $\mathbf{x}_i$  与  $\mathbf{x}_j$  之间的近邻关系, 可以用  $k$  ( $k \in \mathbf{R}$ ) 最近邻法 (式(5)) 或  $\varepsilon$ -ball ( $\varepsilon \in \mathbf{R}$ ) 法 (式(6)) 来定义。

$$S_{i,j} = \begin{cases} e^{-(\|\mathbf{x}_i - \mathbf{x}_j\|^2)/t}, & \text{若 } \mathbf{x}_i \text{ 和 } \mathbf{x}_j \text{ 为 } k \text{ 近邻} \\ 0, & \text{否则} \end{cases}$$

s.t.  $1 \leq i \leq n, 1 \leq j \leq n$  (5)

$$S_{i,j} = \begin{cases} e^{-(\|\mathbf{x}_i - \mathbf{x}_j\|^2)/t}, & \text{若 } (\|\mathbf{x}_i - \mathbf{x}_j\|^2) < \varepsilon \\ 0, & \text{否则} \end{cases}$$

s.t.  $1 \leq i \leq n, 1 \leq j \leq n$  (6)

其中  $t \in \mathbf{R}$  为参数, 用于调整  $S_{ij}$  的大小. 可以看出, LPP 算法投影得到的低维空间里, 样本点之间的几何关系被保持得很好, 但是 LPP 寻找子空间时仅仅关注样本点之间的局部关系, 因而对全局的特征没有直接体现. 关于 LPP 更详细的算法描述参见文献 [4, 10].

### 1.3 LPMVP 算法描述

优化目标  $J(\mathbf{a}_k)_{\text{global}}$  和  $J(\mathbf{a}_k)_{\text{local}}$  可以进一步重写为

$$J(\mathbf{a}_k)_{\text{global}} = \max_{\mathbf{a}_k} \mathbf{a}_k^T C \mathbf{a}_k \quad (7)$$

$$J(\mathbf{a}_k)_{\text{local}} = \min_{\mathbf{a}_k} \mathbf{a}_k^T X(D - S)X^T \mathbf{a}_k \quad (8)$$

为了在提取特征时既考虑全局结构, 又考虑局部特征, 重新构造 LPMVP 算法的优化目标如下

$$J(\mathbf{a}_k)_{\text{LPMVP}} = \frac{\max_{\mathbf{a}_k} \mathbf{a}_k^T C \mathbf{a}_k}{\min_{\mathbf{a}_k} \mathbf{a}_k^T X(D - S)X^T \mathbf{a}_k} = \frac{\max_{\mathbf{a}_k} \frac{\mathbf{a}_k^T C \mathbf{a}_k}{\mathbf{a}_k^T X(D - S)X^T \mathbf{a}_k}}{\min_{\mathbf{a}_k} \frac{\mathbf{a}_k^T X(D - S)X^T \mathbf{a}_k}{\mathbf{a}_k^T X(D - S)X^T \mathbf{a}_k}} \quad (9)$$

式 (9) 可以通过拉格朗日乘子法求解, 首先构造拉格朗日方程如下

$$J_L(\mathbf{a}_k)_{\text{LPMVP}} = \max_{\mathbf{a}_k} \{ \mathbf{a}_k^T C \mathbf{a}_k - \lambda (\mathbf{a}_k^T X(D - S)X^T \mathbf{a}_k - 1) \} \quad (10)$$

对拉格朗日方程求导

$$\frac{\delta J_L(\mathbf{a}_k)_{\text{LPMVP}}}{\delta \mathbf{a}_k} = C \mathbf{a}_k - \lambda X(D - S)X^T \mathbf{a}_k = 0$$

(11)

因此 LPMVP 算法转化为求解如下广义特征值问题

$$C \mathbf{a}_k = \lambda X(D - S)X^T \mathbf{a}_k \quad (12)$$

其中, 最大的  $d$  个特征值  $[\lambda_0, \lambda_1, \lambda_2, \dots, \lambda_{d-1}]$  ( $\lambda_0 > \lambda_1 > \lambda_2 > \dots > \lambda_{d-1}$ ) 所对应的特征向量构成了投影矩阵  $A = [\mathbf{a}_0, \mathbf{a}_1, \dots, \mathbf{a}_{d-1}]$ .

### 1.4 算法分析

LPMVP 算法作为一种新的降维算法, 其优化目标更全面地考虑了数据集的结构特征, 提高了信息提取能力, 使得降维后的空间可以更好地表征原始数据集. 相比其他特征提取算法, LPMVP 算法具有以下的优良性质:

1) LPMVP 算法保留了 LPP 算法的特点, 在降维的过程中, 保持样本之间的近邻关系不变, 因此, 和 LPP 算法一样, LPMVP 算法可以保存原始变量空间的本征几何结构, 体现了局部流形信息.

2) LPMVP 算法也保留了 PCA 算法的特点, 通过把数据投影到方差最大的方向, 保存了全局结构特征.

3) LPMVP 算法是一个线性算法, 计算量小, 有利于实时进行在线监测计算.

4) LPMVP 算法明确地给出了原始变量空间和投影空间之间的映射关系, 方便我们对新样本进行处理, 相比非线性算法如 LLE<sup>[6]</sup> 和 LE<sup>[7]</sup>, LPMVP 算法不仅适合于建模, 也适合应用于过程监控领域.

其中性质 1) 和 2) 说明了 LPMVP 算法可以更有效、全面地提取特征信息, 因此适合在数据分析、模式分类等领域中应用. 相比 PCA 和 LPP, LPMVP 算法可以获得更满意的降维结果. 性质 3) 和 4) 分析了将 LPMVP 算法应用于过程监控领域的可行性. 作为一种和 PCA 类似的线性投影算法, LPMVP 算法可以方便地构造出统计量来实现故障监测的目的; 同时, 其更好的信息提取能力也保证了监测结果的有效性.

## 2 基于 LPMVP 的故障检测方法

### 2.1 $T^2$ 和 $SPE$ 统计量构造

假设原始变量空间为  $X = [\mathbf{x}_i]_{i=1}^n \in \mathbf{R}^M$ , 通过 LPMVP 算法, 该空间可以被低维空间  $Y = [\mathbf{y}_i]_{i=1}^n \in \mathbf{R}^d$  所表示, 其中  $\mathbf{y}_i = A^T \mathbf{x}_i$ ,  $d \ll M$ . 那么空间  $X, Y$  存在如下关系<sup>[12]</sup>

$$X = BY + E \quad (13)$$

$$Y = (B^T B)^{-1} B^T X \quad (14)$$

$$E = X - BY \quad (15)$$

因此, 原始变量空间可以分解为

$$X = \hat{X} + \tilde{X} = BY + E \quad (16)$$

其中  $A^T = (B^T B)^{-1} B^T$ .  $Y$  可以被认为是特征空间, 它和原始变量空间有相似的局部和全局结构特征,  $\tilde{X}$  即为残差空间. 为了使用 LPMVP 算法进行过程监控, 参考传统的 PCA 过程监控算法<sup>[1]</sup>, 分别

对  $Y, \tilde{X}$  建立  $T^2$  统计量和  $SPE$  统计量. 其中对  $Y$  建立 Hotelling's  $T^2$  统计量如下

$$\begin{aligned} T^2 &= \mathbf{y}^\top \tilde{\mathbf{S}}^{-1} \mathbf{y} \leq \frac{d(n-1)}{n-d} F_{d,(n-d),\alpha} \\ \tilde{\mathbf{S}} &= \frac{\mathbf{Y} \mathbf{Y}^\top}{n-1} \end{aligned} \quad (17)$$

其中  $F_{d,(n-d),\alpha}$  表示  $F$  分布  $F_{d,(n-d)}$  的上侧  $\alpha$  分位数, 同样, 针对残差  $\tilde{X}$ , 建立统计量  $SPE$  如下

$$SPE = \mathbf{e}^\top \mathbf{e} \leq SPE_\alpha \quad (18)$$

$SPE_\alpha$  表示  $SPE$  统计量的  $1 - \alpha$  置信限<sup>[1]</sup>,  $\mathbf{y}$  和  $\mathbf{e}$  分别为  $Y$  和  $E$  空间中的向量.

## 2.2 故障检测算法

使用 LPMVP 算法把原始变量空间划分为特征空间和残差空间后, 通过计算  $T^2$  和  $SPE$  统计量的值以及相应的统计置信限, 即可对过程进行故障检测. 具体算法可以归纳如下, 其中步骤 1~3 是离线建模过程, 步骤 4~6 是在线检测过程:

**步骤 1.** 获取正常工况下的数据, 并进行归一化处理.

**步骤 2.** 确定计算相似矩阵  $S$  的策略 ( $k$  最近邻法或  $\varepsilon - ball$  法), 为参数  $k$  或  $\varepsilon$  选取合适的值, 使用 LPMVP 算法对数据进行特征提取, 获得投影矩阵.

**步骤 3.** 分别计算各个采样点的  $T^2$  和  $SPE$  统计量的值, 并通过式 (17) 和 (18) 计算出控制限.

**步骤 4.** 获取当前监控样本的值, 并进行归一化处理.

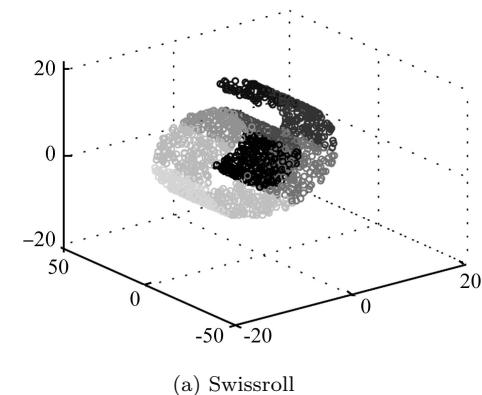
**步骤 5.** 使用步骤 2 获得的投影矩阵把监控样本投影到特征空间, 并计算该样本的  $T^2$  和  $SPE$  统计量的值.

**步骤 6.** 观察统计量是否超过各自的统计限.

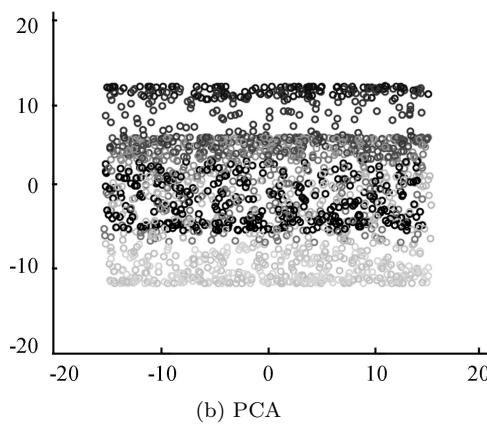
## 3 仿真

### 3.1 数值仿真例子

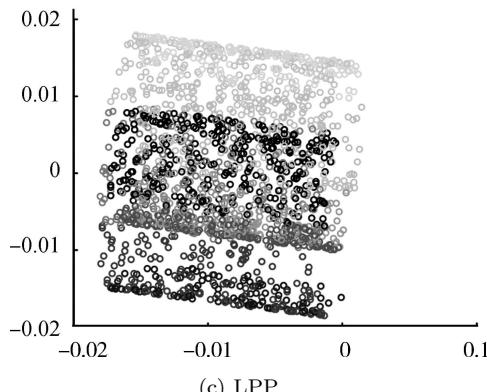
本文使用被广泛应用的 Swissroll<sup>[13-14]</sup> 和 3d-clusters 数据集检验 LPMVP 算法信息提取的效果. 图 1 显示了分别使用 PCA、LPP 和 LPMVP 三种方法在 Swissroll 数据集上的降维结果. 可以看出, PCA 和 LPP 方法对 Swissroll 的降维结果并不好, 数据点出现了比较明显的重叠, 这个结果和文献 [13] 是相符合的; 而 LPMVP 算法的结果较好地将 Swissroll 在 2 维空间上表现了出来, 其原本 3 维空间的几何结构也体现得比较好. 图 2 (见下页) 显示了分别使用 PCA、LPP 和 LPMVP 三种方法



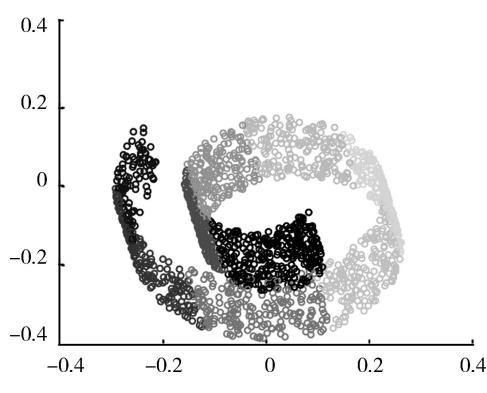
(a) Swissroll



(b) PCA



(c) LPP



(d) LPMVP

图 1 三种方法在 Swissroll 上的投影结果

Fig. 1 Projection results of three methods on Swissroll

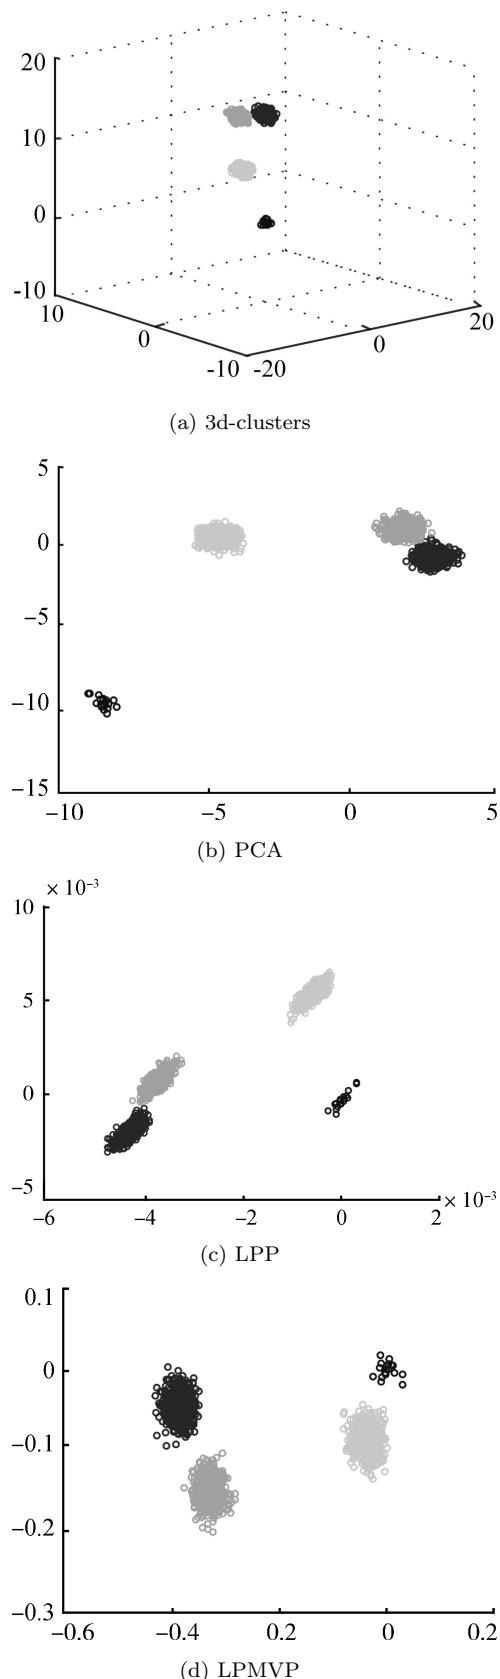


图2 三种方法在3d-clusters上的投影结果

Fig.2 Projection results of three methods on 3d-clusters

在 3d-clusters 数据集上的降维结果。可以发现, PCA 将 3d-clusters 投影到 2 维后, 有 2 类数据点出现了重叠; LPP 的效果比 PCA 有所改善, 但对于 PCA 中出现重叠的 2 类样本, 区分还不是很明显; 而 LPMVP 算法的结果较好地将 3 维空间的点在 2 维空间上分开。由上述两个例子可以看出, 相比 PCA 和 LPP, LPMVP 算法由于综合考虑了局部和全局的特征, 因此可以更好地提取信息, 在 Swissroll 和 3d-clusters 数据集上均取得了明显的改进效果。

### 3.2 TE过程故障检测

Tennessee-Eastman (TE) 过程是由 Downs 和 Vogel 根据 Eastman 化学公司的工艺流程建立的一个标准测试平台, TE 模型源于真实的化工过程, 包含了 30 个微分方程和 148 个代数方程, 其数据具有非线性、强耦合、时变等特点, 是典型的复杂工业过程<sup>[1]</sup>。该过程有 12 个操作变量和 41 个测量变量, 并且人工设定了 21 种故障工况<sup>[15]</sup>。本文选取 33 个变量作为过程监测变量。采集正常工况下的 960 个样本作为训练集, 500 个样本作为测试集, 采集故障数据时, 先让系统运行在正常状态, 故障在第 160 个采样点加入, 每个故障采集 960 个样本作为测试集。建立的 PCA 模型选取的主元数目为 9 个, 作为对照, 建立 LPMVP 故障检测模型时, 选取低维空间的维度也为 9, 所取的置信限都是 95%, 另外, 在 LPMVP 模型中, 我们采取  $k$  最近邻法来计算相似矩阵  $S$ , 其中  $k = 4$ , 参数  $t = 1$ 。首先我们对正常工况数据进行处理, 监测结果如图 3 和图 4 (见下页) 所示。传统的 PCA 算法和 LPMVP 算法都得到了较好的效果, 可见本文算法没有牺牲对于正常工况的监测性能。为了检验使用 LPMVP 算法进行故障

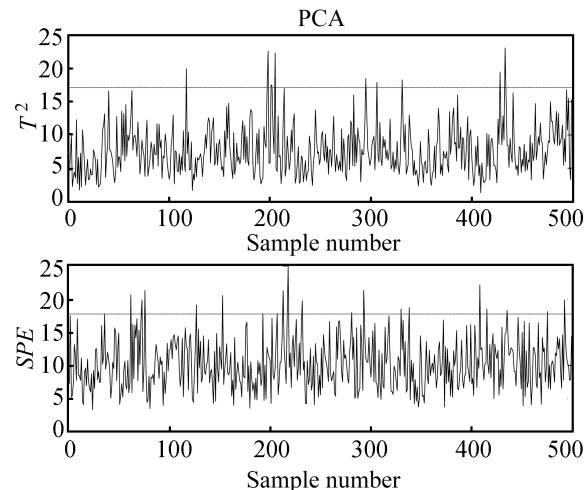


图3 PCA 方法在正常工况下的仿真结果

Fig.3 Simulation of normal operating mode by PCA

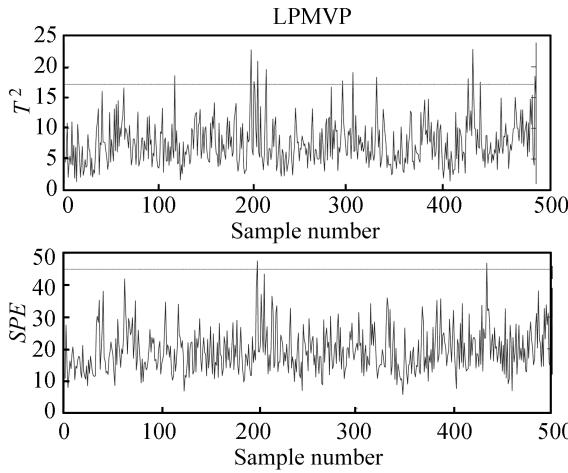


图 4 LPMVP 方法在正常工况下的仿真结果

Fig. 4 Simulation of normal operating mode by LPMVP

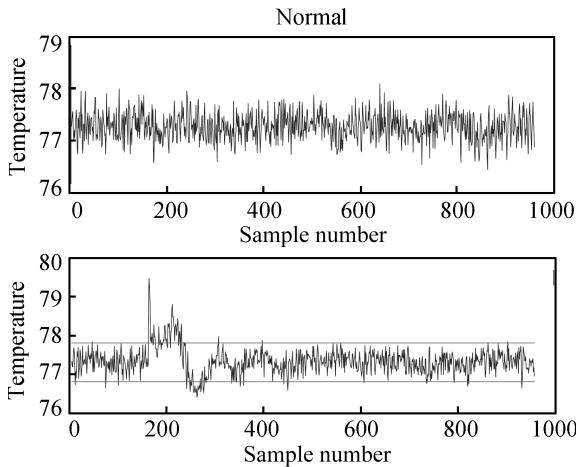


图 5 正常工况和故障工况 5 下的分离器水出口温度

Fig. 5 Separator cooling water outlet temperatures for normal operating mode and fault five mode

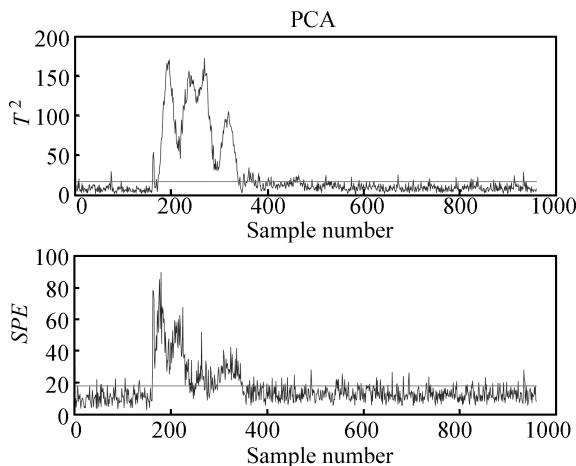


图 6 PCA 方法在故障工况 5 下的仿真结果

Fig. 6 Simulation of fault five mode by PCA

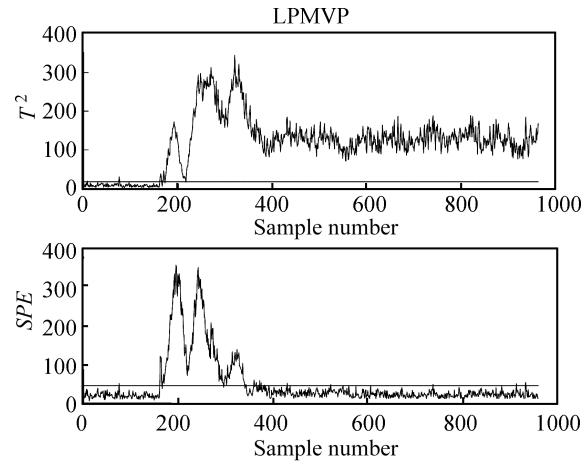


图 7 LPMVP 方法在故障工况 5 下的仿真结果

Fig. 7 Simulation of fault five mode by LPMVP

检测的效果, 我们对典型故障 5 (冷凝器冷却水入口温度阶跃变化) 进行仿真研究。由 TE 的机理模型和文献 [1] 知, 该故障发生时, 会引起冷凝器出口到气液分离器流速的增加, 从而导致了气液分离器自身温度及其冷却水出口温度的变化。值得注意的是, 由于控制回路可以补偿这个故障引起的变化, 在一段时间后, 分离器水出口温度会回到正常的工作点(如图 5, 分离器水出口温度在 350 个采样点以后已基本回到正常范围), 为检测该故障带来了困难。

图 6 显示了 PCA 方法的故障检测结果, 可以发现, PCA 方法的检测率比较低, 原因是当分离器水出口温度回到正常的工作点后(约 350 个采样点以后), PCA 模型建立的统计量  $T^2$  和  $SPE$  也回到了控制限之下, 给出了系统工作正常的结论。可以认为, PCA 方法不能“持续”地检测出故障。而在实际中, 对于故障检测的“持续性”要求是相当重要的<sup>[12]</sup>, 因为操作员往往要同时监控很多的变量或者工业过程, 对于各种故障的处理也需要一定的间隔时间, 如果算法检测出故障的持续时间比较短, 操作员往往来不及处理, 统计量就已经恢复了正常, 从而使操作员产生故障已经不存在的错觉, 因此往往会导致比较严重的后果。图 7 显示了基于 LPMVP 算法的故障检测结果, 可以发现, 特征空间上的  $T^2$  统计量对故障具有很好的检测能力。和传统 PCA 算法相比, 在 350 个采样点后,  $T^2$  统计量依然远超控制限, 符合“持续性”的故障检测要求。该结果也表明了 LPMVP 算法投影得到的特征空间包含了更多的有效信息。当监测样本的全局结构特征恢复正常后, PCA 算法认为过程已经无故障存在, 而 LPMVP 算法不仅监测了样本的全局结构信息, 还监测了样本的局部结构信息, 因而对过程的工况给出了正确的判断。

## 4 结论

本文提出了一种用于数据降维和特征提取的LPMVP新算法,不同于传统的PCA和LPP方法,该算法的优化目标综合考虑了全局和局部特征的保持,使得降维后的特征空间包含更多的信息,因此对原始变量空间有了更好的体现。同时,考虑到LPMVP方法特征提取的能力及其线性的优点,本文还给了一种基于该算法的故障检测方法。通过在Swissroll, 3d-clusters数据集以及Tennessee-Eastman(TE)模型上的仿真研究,表明了该算法的优越性以及在过程故障检测上的有效性。

## References

- 1 Chiang L H, Russell E L, Braatz R D. *Fault Detection and Diagnosis in Industry System*. London: Springer-Verlag, 2001
- 2 Sharmin R, Shah S L, Sundararaj U. A PCA based fault detection scheme for an industrial high pressure polyethylene reactor. *Macromolecular Reaction Engineering*, 2008, **2**(1): 12–30
- 3 Liu X Q, Xie L, Kruger U, Littler T, Wang S Q. Statistical-based monitoring of multivariate non-Gaussian systems. *American Institute Chemical Engineers Journal*, 2008, **54**(9): 2379–2391
- 4 He X F, Niyogi P. Locality preserving projections. In: *Proceedings of the 17th Annual Conference on Neural Information Processing Systems*. Cambridge, USA: The MIT Press, 2003. 1–8
- 5 Tenenbaum J B, de Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction. *Science*, 2000, **290**(5500): 2319–2323
- 6 Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding. *Science*, 2000, **290**(5500): 2323–2326
- 7 Belkin M, Niyogi P. Laplacian eigenmaps and spectral techniques for embedding and clustering. *Advances in Neural Information Processing Systems*, 2002, **14**(1): 585–591
- 8 Pan X, Ruan Q Q. Palmprint recognition with improved two-dimensional locality preserving projections. *Image and Vision Computing*, 2008, **26**(9): 1261–1268
- 9 Li J B, Pan J S, Chu S C. Kernel class-wise locality preserving projection. *Information Sciences*, 2008, **178**(7): 1825–1835
- 10 He X F, Cai D, Min W L. Statistical and computational analysis of locality preserving projection. In: *Proceedings of the 22nd International Conference on Machine Learning*. Bonn, Germany: ACM, 2005. 281–288
- 11 Hotelling H. Analysis of a complex of statistical variables into principal components. *Journal of Educational Psychology*, 1933, **24**(7): 498–520
- 12 Westerhuis J A, Gurden S P, Smilde A K. Generalized contribution plots in multivariate statistical process monitoring. *Chemometrics and Intelligent Laboratory Systems*, 2000, **51**(1): 95–114
- 13 Zhang T H, Yang J, Zhao D L, Ge X L. Linear local tangent space alignment and application to face recognition. *Neurocomputing*, 2007, **70**(7–9): 1547–1553
- 14 Chang H, Yeung D Y. Robust locally linear embedding. *Pattern Recognition*, 2006, **39**(6): 1053–1065
- 15 Downs J J, Vogel E F. A plant-wide industrial process control problem. *Computers and Chemical Engineering*, 1993, **17**(3): 245–255



**张沐光** 浙江大学工业控制研究所博士研究生。主要研究方向为过程监测与故障诊断技术。

E-mail: mgzhang@iipc.zju.edu.cn

**ZHANG Mu-Guang** Ph. D. candidate at the Institute of Industrial Process Control, Zhejiang University. His research interest covers process monitoring and fault diagnosis.)



**宋执环** 浙江大学工业控制研究所教授。主要研究方向为基于数据驱动技术的复杂工业过程建模、控制与故障诊断。本文通信作者。

E-mail: zhsong@iipc.zju.edu.cn

**SONG Zhi-Huan** Professor at the Institute of Industrial Process Control, Zhejiang University. His research interest covers data-driven based techniques for complex process modeling, control and fault diagnosis. Corresponding author of this paper.)