

# 基于扩展 LLE 方法的非线性系统故障诊断研究

张 伟,周维佳,刘晓源

(中国科学院沈阳自动化研究所机器人学国家重点实验室,辽宁沈阳 110016)

**摘 要:** 针对非线性系统故障诊断难以解决的问题,提出了一种基于扩展局部线性嵌入映射(Locally Linear Embedding, LLE)的故障诊断方法.通过引入切空间距离代替欧氏距离,可以更加科学的满足算法近邻点局部线性的要求,从而可以更好的保留原始数据的局部流形特征.另外,将故障状态与高维空间分布结合起来,通过确定数据点在空间超球内的分布完成故障的检测,在这个过程中将超球的确定与 LLE 算法中基于核函数的样本外数据扩展相结合,减少了计算量,提高了算法的实时性,从而为复杂非线性系统的故障诊断提供了一种新的有效的方法.

**关键词:** 故障诊断;局部线性嵌入映射;切空间距离

**中图分类号:** TP206      **文献标识码:** A      **文章编号:** 0372-2112 (2015)09-1810-06

**电子学报 URL:** <http://www.ejournal.org.cn>      **DOI:** 10.3969/j.issn.0372-2112.2015.09.020

## An Improved LLE-Based Approach to Fault Diagnosis of Nonlinear System

ZHANG Wei, ZHOU Wei-jia, LIU Xiao-yuan

(National Robotics Laboratory, Shenyang Institute of Automation Chinese Academy of Sciences, Shenyang, Liaoning 110016, China)

**Abstract:** It is quite a difficult problem of fault detection in nonlinear system. In this paper, a new method based on LLE is proposed to solve the problem. Firstly, tangent space distance is introduced to LLE(Locally Linear Embedding) algorithm, which can satisfy the hypothesis of locally linear patch of LLE, and so it can preserve the local manifold features of the original data better. And then, fault state is combined with special distribution to complete the fault detection. Out of sample extension is also considered, and combined with fault detection algorithm, which can reduce computation obviously and improves real time capability of the Thereby algorithm. provides a new effective method for the fault diagnosis of complicated nonlinear system.

**Key words:** fault diagnosis; locally linear embedding; tangent space distance

## 1 引言

当今社会工业系统智能化程度越来越高,发生故障的概率也相应增大.为了提高系统可靠性,系统的故障诊断引起了越来越高的重视.工业系统数据的显著特点为:高数据量、高维数、高数据增长率、非结构化.目前,特征提取最重要的手段之一是主成分分析法(Principal Component Analysis, PCA),这个方法是 1901 年 Pearson 在研究回归分析时附带提出,其数学基础是 1933 年由 Hotelling 奠定<sup>[1]</sup>,随着模式识别、机器学习的兴起和发展,又成了这些领域的重要研究对象之一<sup>[2]</sup>.但是它针对的是线性系统,如果将 PCA 应用于非线性系统时,较小的主元并不表示不重要的方差,反而可能包含重要的系统信息,这将引起主元模型的误差增大.1998 年, Scholkopf 提出了一种新型的非线性 PCA 算法(核主元分析, KPCA)<sup>[3]</sup>. KPCA(Kernel Principal Component Analysis)

的基本特点是利用内积和核函数实现其非线性,并在非线性高维特征空间中有效地获得主元<sup>[4,5]</sup>.但是,虽然 KPCA 是对 PCA 的一种非线性扩展,不过由于自身原因,核函数的选择没有一个定量的指导方法,同时对数据结构本身描述不足,使得它的应用受到很大的限制.

2000 年, Roweis 和 Lawrence 提出了基于流形的局部线性嵌入映射方法(Locally Linear Embedding, LLE)<sup>[6]</sup>,奠定了流形学习的基础.随后,由于其优秀的特征提取性能,及可以有效揭示数据固有的几何特征,流形算法也被应用到故障诊断领域<sup>[7]</sup>.与传统方法相比, LLE 处理高维大规模数据的低维嵌入具有更强的能力,不仅具有较低的时间和空间复杂度,而且得到全局的低维系统,有利于数据的结构和相关分析,已经广泛应用于图像聚类、识别等各个领域<sup>[8]</sup>.

但是,由于算法自身原因和应用到故障诊断领域的需求, LLE 算法还存在一定缺陷.算法的前提是假设每

个数据点及其近邻是局部线性,如果近邻点选择不当就会改变其固有流形,影响数据的重构效果;另外,LLE 虽然可以在训练示例上建立从高维样本空间向低维特征空间的非线性映射模型,但是由于这些投影涉及对距离矩阵或者权值矩阵的特征分解,不能像 PCA 那样生成变换矩阵,因而处理实时数据时,要把新数据与训练集重新全部计算一次距离和权值矩阵,然后再重新投影到低维特征空间,计算量会相当大。

本文主要针对这些问题做了相应的研究,在原有 LLE 算法的基础上引入了切空间距离,给出了基于扩展 LLE 的故障检测算法和基于 TE 数据的试验结果。

## 2 扩展 LLE 算法

### 2.1 LLE 算法

局部线性嵌入映射(LLE)算法是 Roweis 和 Lawrence 在 2000 年提出的一种非线性降维方法,其基本思想是在样本点和它的邻域点之间构造一个重构权向量,并在低维空间中保持每个邻域中的权值不变,即假设嵌入映射在局部是线性的条件下,来最小化重构误差。LLE 并不仅仅是纯粹的降维,在某种意义上也是一种新的特征提取方式。它并非是从高维特征向量中选取部分分量而组成新的特征向量,而是高维特征向量在低维空间的一个映射。通过这样一个映射,我们得到新的低维的特征向量,既能保持原有数据的拓扑结构和局部关联性,而且新的向量的维数可以足够的低。LLE 算法可以归结为三步:

- (1) 找到原始数据集中每个数据的近邻点;
- (2) 在重构误差最小的条件下,计算每个数据用近邻重构的权值,得到权值矩阵;
- (3) 在特征空间中,用权值矩阵计算出数据点的映射值,得到降维数据。

算法步骤如图 1 所示。

### 2.2 扩展 LLE 算法

从上面 LLE 的直观描述可以知道,近邻必须满足与数据点是局部线性的条件,当前算法中都是用欧氏距离计算出近邻,然后直接求出数据之间的相关性。但是有时候欧氏距离短的近邻点并不意味着能够最好的体现局部线性的要求,如图 2 中 Swiss 曲面所示,其中,  $X_0$  为 Swiss 曲面上的一个样本点,  $X_1, X_2$  为其近邻点,  $d_1, d_2$  分别为  $X_1$  和  $X_2$  到样本点  $X_0$  的距离,从 LLE 的定义可以知道,  $d$  越小则越能满足样本点与近邻点为局部线性的要求。

从图 2 中对比  $X_1$  和  $X_2$  可以看到,  $X_2$  在欧氏距离下更满足样本点  $X_0$  的近邻要求 ( $d_2 < d_1$ ),但是在这种情况下,如果按照欧式距离完成 LLE 投影的话,将会完

全改变 Swiss 曲面的内在流形结构,从而导致投影失败。为避免这种情况,必须找到能够更好的表示样本点局部线性的近邻点,而非寻找欧式距离意义下最近的点。

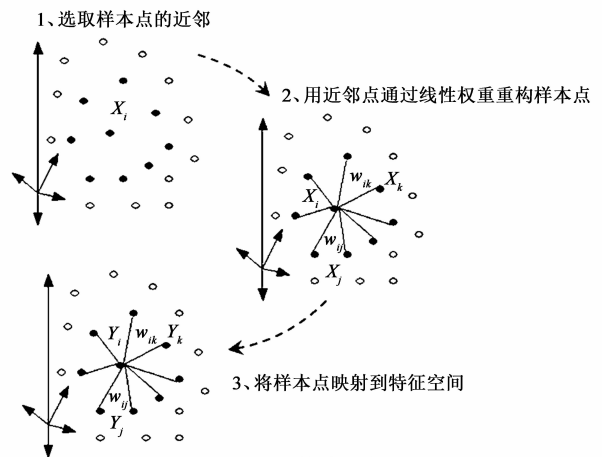


图1 LLE算法示意图




图2 近邻点到样本点的欧式距离及切空间距离

重新考虑 LLE 算法的基本思想:假设数据局部是线性的条件下,最小化重构误差。因此在寻找样本点近邻的时候,首先要保证样本点和近邻点是局部线性的,也就是处于同一平面上。考虑到这一点,我们将切空间的概念引入到 LLE 算法中来,首先确定出各个样本点的切空间,然后通过计算周围数据到样本点的切空间距离来确定其近邻,这样可以更好的满足算法关于局部线性的要求。

要计算切空间,必须知道显式函数的微分,但在实际的问题中,原始数据并没有一个显式的函数表达式,仅是流形上的一些离散样本点。因此采用局部切空间排列方法中的一个步骤来解决这个问题,对于高维空间上的每个样本点邻域,可以通过局部 PCA 得到其近似切空间,或者说切空间上的一组正交基。

假设存在一个  $d$  维流形,其是通过一个未知函数  $f(\tau), \tau \in \mathbf{R}^d$ , 映射到  $m$  维空间,已有的样本点集  $\mathbf{X} = (x_1, x_2, \dots, x_n), x_i \in \mathbf{R}^m$ , 是该未知函数的像,  $x_i = f(\tau_i), i$

$= 1, 2, \dots, n$ . 要得到流形在  $x_i$  处的切空间, 即相当于要知道向量函数  $f(\tau)$  在  $\tau_i$  处的微分. 于是, 我们假设流形是足够光滑的, 在固定的某个  $\tau$  处利用一阶 Taylor 展开得到,

$$f(\bar{\tau}) = f(\tau) + J_f(\tau) \cdot (\bar{\tau} - \tau) + O(\|\bar{\tau} - \tau\|_2^2) \quad (1)$$

其中,  $J_f(\tau) \in \mathbf{R}^{m \times d}$  是  $f$  在  $\tau$  处的 Jacobi 矩阵. 记  $f(\tau) =$

$$\begin{pmatrix} f_1(\tau) \\ \vdots \\ f_m(\tau) \end{pmatrix}, \text{ 则 } J_f(\tau) = \begin{pmatrix} \frac{\partial f_1}{\partial \tau_1} & \dots & \frac{\partial f_1}{\partial \tau_d} \\ \vdots & \vdots & \vdots \\ \frac{\partial f_m}{\partial \tau_1} & \dots & \frac{\partial f_m}{\partial \tau_d} \end{pmatrix}, \text{ 于是 } f \text{ 在 } \tau \text{ 处的}$$

切空间  $\Gamma_\tau$  由  $J_f(\tau)$  的  $d$  个列向量张成:  $\Gamma_\tau = \text{span}(J_f(\tau))$ . 由于不知道函数  $f$ , 无法直接求出  $J_f(\tau)$ , 但确定是  $d$  维空间, 假设知道  $J_f(\tau)$  上的一组正交基  $Q_\tau \in \mathbf{R}^{m \times d}$ , 则

$$J_f(\tau) \times (\bar{\tau} - \tau) = Q_\tau \theta_\tau^* \quad (2)$$

其中  $\theta_\tau^*$  是  $\bar{\tau} - \tau$  在切空间  $\Gamma_\tau$  上对应于  $Q_\tau$  的坐标, 又因为  $f(\bar{\tau}) - f(\tau) \approx J_f(\tau) \cdot (\bar{\tau} - \tau)$ , 上式可写成  $f(\bar{\tau}) - f(\tau) \approx Q_\tau \theta_\tau^*$ , 即

$$f(\bar{\tau}) \approx Q_\tau \theta_\tau^* + f(\tau) \quad (3)$$

对于某个样本点  $x_i$ , 其邻域点  $x_{ij} \approx x_i + Q_i \theta_i$ . 建立如下的最优化过程,

$$\begin{aligned} & \min_{x_i^*, Q_i, \theta_i} \sum_{j=1}^k \|x_{ij} - (x_i^* + Q_i \theta_i)\|_2^2 \\ & = \min_{x_i^*, Q_i, \theta_i} \|X_i - (x_i^* e^T + Q_i \Theta_i)\|_F^2 \end{aligned} \quad (4)$$

其中,  $X_i = (x_{i1}, x_{i2}, \dots, x_{ik})$ ,  $Q_i \in \mathbf{R}^{m \times d}$ ,  $\Theta_i = (\theta_{i1}, \theta_{i2}, \dots, \theta_{ik}) \in \mathbf{R}^{d \times k}$ , 由此得到的  $Q_i$  可作为流形在  $x_i$  处切空间的  $d$

个近似正交基, 此问题的求解可对  $X_i(I - \frac{1}{k}ee^T)$  进行 SVD 分解得到,  $Q_i$  为  $X_i(I - \frac{1}{k}ee^T)$  对应最大  $d$  个特征值的特征向量, 这组特征向量可作为空间的一组正交基. 近邻点在此正交基张成空间中的坐标为  $(x_1, \dots, x_d)$ , 到切空间距离为点剩下  $(m-d)$  维正交基坐标的均方根, 可表示为  $\sqrt{x_{d+1}^2 + x_{d+2}^2 + \dots + x_m^2}$ , 从而确定出切空间距离意义的近邻.

### 3 基于扩展 LLE 的故障检测方法

虽然 LLE 可以在训练集建立从高维样本空间向低维特征空间的非线性映射模型, 但是由于这些投影涉及对距离矩阵或者权值矩阵的特征分解, 不存在一个显式的投影函数, 因此原始 LLE 方法是不可扩展的, 即当有新数据需要处理时, 要把新数据与训练集重新全部计算一次距离和权值矩阵, 然后再重新投影到低维特征空间.

为提高算法实时性, 在 Yoshua Bengio<sup>[9]</sup> 研究基础上采用核函数方法对新数据进行扩展, 并结合异常检测算法, 在实现数据迭代的同时, 完成故障数据检测.

设初始数据集为  $\{x_1, \dots, x_n\}$ ,  $x_i \in \mathbf{R}^D$ , 低维空间中的投影为  $\{y_1, \dots, y_n\}$ ,  $y_i \in \mathbf{R}^d$ , 其中  $d \ll D$ . 对于新数据  $x$ , 首先计算其训练集中的  $k$  个近邻  $(x^1, \dots, x^k)$ , 计算各个近邻的权重, 得到  $(w^1, \dots, w^k)$ . 通过核函数对新数据进行扩展, 需要核函数  $K(x, y)$  产生矩阵  $M$ , 其中  $M$  的元素为  $M_{ij} = K(x_i, x_j)$ , 由 LLE 算法可得  $M = (I - W)'(I - W)$ , 其元素为  $M_{ij} = \delta_{ij} - w_{ij} - w_{ji} + \sum_{k=1}^n w_{ik}w_{kj}$ .

LLE 算法中需要取最小的特征值对应的特征向量, 所以, 对  $M$  进行修改, 令  $\tilde{M} = I - M$ , 这样可以保证特征向量不变而  $\tilde{M}$  中的特征值可以取最大. 令

$$\tilde{K}(x_i, x_j) = \tilde{M}_{ij} = w_{ij} + w_{ji} - \sum_{k=1}^n w_{ik}w_{kj} \quad (5)$$

给定有限输入空间  $X = \{x_1, x_2, \dots, x_n\}$ , 设  $k(x, z)$  是在  $X$  上的对称函数, 令  $K = (k(x_i, x_j))_{i,j=1}^n$ , 则样本外数据的投影数据为

$$y_k(x) = \frac{1}{\lambda_k} \sum_{i=1}^n v_{ik} k(x, x_i) = \frac{1}{\lambda_k} K(x) V_k \quad (6)$$

其中,  $K(x)$  为向量  $(k(x, x_1), k(x, x_2), \dots, k(x, x_n))$ ,  $V_k$  为核函数矩阵的第  $k$  个特征向量.

完成新数据到特征空间的投影后, 需要对数据进行故障检测. 假定一组数据服从同一个分布, 那么在空间可以看作是一个超球体, 其圆心可以看作数据质心, 只要确定出超球体半径, 则可以检测出新数据点是否服从同样的分布, 从而确定数据是否有故障. 对于一个给定系统来说, 当系统正常运行时, 其输出可以看作是服从同一分布下的数据, 因此可以近似看作是一个超球体, 其超球体的半径是距离质心最远的数据点到质心的距离. 但是, 如果训练集数据中有一个不够好的数据点, 其半径将比实际需求大的多, 这样将大大增加故障检测的漏报率. 因此, 需要找到一个最小的超球体, 保证除了几个极端的数据点外, 包含其他所有的训练集数据.

假定训练集数据  $S = \{x_1, x_2, \dots, x_l\}$  到特征空间的映射为  $\phi$ , 相关联核函数为  $k(x, z) = \langle \phi(x), \phi(z) \rangle$ . 包含  $S$  的最小超球体的中心是使到最远的数据点的距离  $r$  最小化的点  $c$ , 即  $c = \arg \min_c \max_{1 \leq i \leq l} \|\phi(x_i) - c\|$ .

最小封闭超球体: 给定  $S = \{x_1, x_2, \dots, x_l\}$ , 解决最优化问题,

$$\min_{c, r} r^2 \quad (7)$$

$$\text{s.t. } \|\phi(x_i) - c\|^2 = (\phi(x_i) - c)'(\phi(x_i) - c) \leq r^2$$

其超球体  $(c, r)$  是具有最小半径  $r$  的包含  $S$  的超球体.

可以通过定义对于每一个约束条件都有一个拉格朗日乘子  $\alpha_i \geq 0$  和它对应的拉格朗日函数

$$L(c, r, \alpha) = r^2 + \sum_{i=1}^l \alpha_i [\|\varphi(x_i) - c\|^2 - r^2] \quad (8)$$

来解决这个最优化问题。

对  $c, r$  分别求偏导并使其为零,

$$\frac{\partial L(c, r, \alpha)}{\partial c} = 2 \sum_{i=1}^l \alpha_i (\varphi(x_i) - c) = 0 \quad (9)$$

$$\frac{\partial L(c, r, \alpha)}{\partial r} = 2r(1 - \sum_{i=1}^l \alpha_i) = 0 \quad (10)$$

得,  $\sum_{i=1}^l \alpha_i = 1$ , 并且  $c = \sum_{i=1}^l \alpha_i \varphi(x_i)$ .

代入到拉格朗日函数, 得到

$$\begin{aligned} L(c, r, \alpha) &= r^2 + \sum_{i=1}^l \alpha_i [\|\varphi(x_i) - c\|^2 - r^2] \\ &= r^2 + \sum_{i=1}^l \alpha_i \|\varphi(x_i) - c\|^2 - \sum_{i=1}^l \alpha_i r^2 \\ &= \sum_{i=1}^l \alpha_i [(\varphi(x_i) - c), (\varphi(x_i) - c)] \\ &= \sum_{i=1}^l \alpha_i [k(x_i, x_i) + \sum_{j,k=1}^l \alpha_j \alpha_k k(x_j, x_k) - 2 \sum_{j=1}^l \alpha_j k(x_i, x_j)] \\ &= \sum_{i=1}^l \alpha_i k(x_i, x_i) + \sum_{j,k=1}^l \alpha_j \alpha_k k(x_j, x_k) - 2 \sum_{i,j=1}^l \alpha_i \alpha_j k(x_i, x_j) \\ &= \sum_{i=1}^l \alpha_i k(x_i, x_i) - \sum_{j,k=1}^l \alpha_j \alpha_k k(x_j, x_k) \quad (11) \end{aligned}$$

拉格朗日函数已经全部根据拉格朗日参数来表示, 原问题转化为求取  $\alpha_i$  的最优解,

$$W(\alpha) = \sum_{i=1}^l \alpha_i k(x_i, x_i) - \sum_{j,k=1}^l \alpha_j \alpha_k k(x_j, x_k) \quad (12)$$

其中,  $\sum_{i=1}^l \alpha_i = 1, \alpha_i \geq 0$ . 求得最优解  $\alpha^*$ , 从而得到包含训练集数据的最小体积的超球体, 超球体的中心为  $c^*$

$$= \sum_{i=1}^l \alpha_i^* \varphi(x_i), \text{半径为 } r^* = \sqrt{W(\alpha^*)}.$$

得到最小超球体的球心和半径后, 即可计算新数据在特征空间中与训练集数据的关系, 若在超球体之中则数据正常, 否则系统就是出现故障. 在实际的计算中, 可以根据核函数的性质直接计算新数据与超球体球心的距离进行故障检测而不需要计算新数据在特征空间投影的具体值, 从而提高算法的实时性.

设初始数据集为  $X = \{x_1, \dots, x_n\}$ , 存在核函数  $k(x, z)$  和映射  $\phi$ , 满足  $k(x, z) = \langle \varphi(x), \varphi(z) \rangle$ . 令  $\phi(X) = \{\varphi(x_1), \dots, \varphi(x_n)\}$  是  $X$  在映射  $\phi$  下的映像.  $\phi(X)$  所组成的超球体的质心为  $c^*$ , 半径为  $r^*$ . 假设有新数据  $\hat{x}$ , 在特征空间的投影为  $\varphi(\hat{x})$ , 则判别规则为,

$$\Delta = \|\varphi(\hat{x}) - c^*\| - r^* \quad (13)$$

其中,  $\|\varphi(\hat{x}) - c^*\| = \langle \varphi(\hat{x}) - c^*, \varphi(\hat{x}) - c^* \rangle$   
 $= \langle \varphi(\hat{x}), \varphi(\hat{x}) \rangle + \langle c^*, c^* \rangle - 2 \langle \varphi(\hat{x}), c^* \rangle$

已知,  $c^* = \sum_{i=1}^l \alpha_i^* \varphi(x_i)$ , 代入(13)式, 得,

$$\begin{aligned} k(\hat{x}, \hat{x}) + \langle c^*, c^* \rangle - 2 \langle \varphi(\hat{x}), \sum_{i=1}^n \alpha_i^* \varphi(x_i) \rangle \\ = k(\hat{x}, \hat{x}) + \langle c^*, c^* \rangle - 2 \sum_{i=1}^n \alpha_i^* k(\hat{x}, x_i) \quad (14) \end{aligned}$$

从上式可以看出, 计算过程中不需要计算新数据在特征空间投影的具体值  $\varphi(\hat{x})$ , 只需要计算新数据点与训练集数据在核矩阵中的内积即可, 从而简化了故障检测算法的计算量.

## 4 仿真试验

田纳西-伊斯曼(TE)过程是由 Downs 和 Vogel 提出的一个标准测试过程, 大量文献引用它作为数据源, 来进行控制、优化、过程监控、故障诊断等研究. TE 过程的原型是一个真实的化工过程, 一共 52 维数据. TE 数据分为 20 类故障, 每次运行时间是 48 小时, 采样时间间隔为 3 分钟, 因此每次运行所产生的观测样本总数为 960, 系统一共有 52 个传感器, 所以每组数据是  $52 \times 960$  维的矩阵. 仿真在无故障情况下开始, 故障在仿真时间 8 小时的时候引入, 即第 161 个数据.

不失一般性, 选取第 4 个故障(阶跃)、第 10 个故障(随机)以及第 16 个故障(未知)来测试算法有效性, 分别用 PCA 算法、KPCA 算法以及基于切空间距离的扩展 LLE 算法(Tangent space LLE, TLLE)进行检测.

其中, PCA 算法选取的主元数为 3 个; KPCA 算法的核函数采用径向基核函数.

$$k(x, y) = \exp\left[-\frac{\|x - y\|^2}{2\sigma^2}\right], \text{其中, } 2\sigma^2 = 10.$$

图 3~图 5 每个图的第一行是 PCA 算法的  $Q$  统计量结果, 第二行是 KPCA 算法的  $Q$  统计量结果, 第三行是本文提出的基于 TLLE 算法的检测结果, 检测标准采用 3Sigma 原则.

表 1 给出了这三种故障基于 PCA 算法、KPCA 算法以及 TLLE 算法下的故障诊断结果. 主要从误报率(false positive-FP)及漏报率(false negative-FN)来评价算法的故障检测率.

从图 3 中可以看出, 对于阶跃故障 4, 由于其故障特征比较明显, 因此, 三种方法在故障发生时都能够比较准确、及时的检测出故障, 但是对于故障误报率和漏报率指标, PCA 算法要比 KPCA 以及 TLLE 算法差, 尤其是漏报率几乎达到 80%; KPCA 算法效果要优于 PCA, 但是从图上也可以看出, 漏报率也比较高, 而 TLLE 算法则在误报率和漏报率方面都有比较好的表现. 定量分析三种算法对故障 4 的检测率, PCA 算法的检测率为

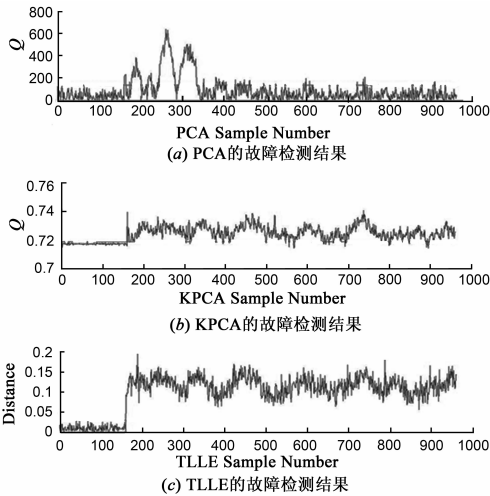


图3 故障4的三种算法检测结果

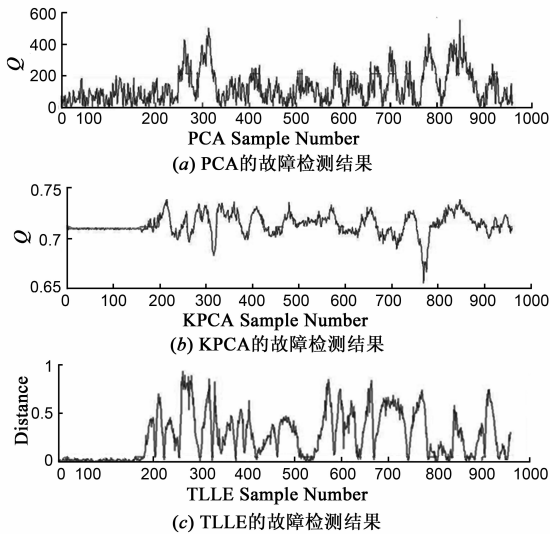


图4 故障10的三种算法检测结果

21.63%, KPCA 算法的检测率为 95.25%, 而 TLLE 算法的检测率为 100%。

对于图 4 和图 5 的随机故障和未知故障, 由于故障特征不是很明显, 因此, PCA 算法基本不能完成故障检测任务, KPCA 算法在故障发生时能够比较好的检测出故障, 但是漏报率都很高, 而 TLLE 算法则在故障诊断实时性、误报率和漏报率方面都有很好的表现。

上述故障基于三种算法的误报率和漏报率的详细结果如表 1 所示

从表中可以看出, PCA 算法误报率数据比较好, 主要是因为其对故障不敏感, 并不是算法的性能好; KPCA 算法在故障误报率的表现不错, 但是在故障漏报率上对于故障特征不明显的故障效果很差; TLLE 算法在误报率方面稍高于 KPCA, 主要由于其对于故障敏感度比较高, 而漏报率则远优于 PCA 和 KPCA 算法。

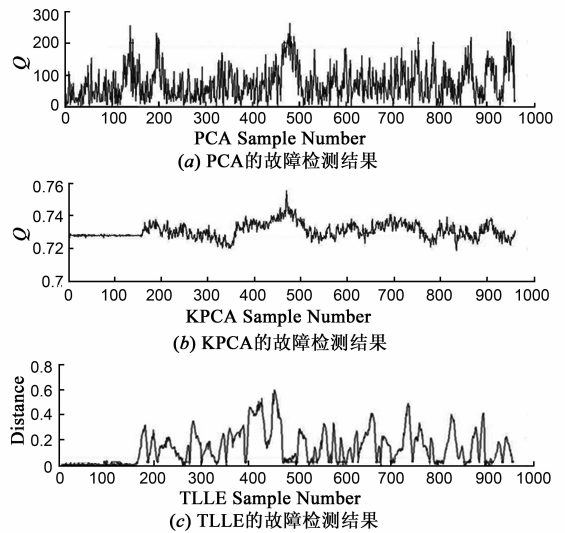


图5 故障16的三种算法检测结果

表 1 故障 4、10 和 16 的误报率及漏报率

		FP	FN
故障 4	PCA	0	79.37%
	KPCA	0.63%	4.75%
	TLLE	8.75%	0
故障 10	PCA	0	77.12%
	KPCA	0	38.37%
	TLLE	7.5%	7.75%
故障 16	PCA	1.25%	97.5%
	KPCA	0	36.88%
	TLLE	5.63%	7.62%

为了测试 TLLE 算法故障检测的通用性能, 对 TE 数据的 20 组故障数据分别进行故障诊断, 其故障检测率如表 2 所示。

表 2 基于 TLLE 算法的 TE 数据故障检测率

故障	检测率	故障	检测率	故障	检测率
1	99.87%	8	88.97%	15	73.25%
2	98.37%	9	29.5%	16	92.38%
3	84.25%	10	92.25%	17	97.74%
4	100%	11	71.75%	18	94.88%
5	100%	12	95.25%	19	96.75%
6	99.75%	13	88.97%	20	90.5%
7	98.5%	14	81.75%		

从表 2 中可看出, 在所有 20 类故障中, 故障 9 为进料 2 温度随机变化故障, 由于其故障特征不明显, 检测率较低, 其他 19 类故障都具有较高检测率, 其中 12 类

故障的检测率超过 90%,说明其在非线性系统故障诊断方面具有较高性能,同时也具有较好的通用性.

## 5 结论

本文在 LLE 的基础上,引入切空间距离,提出扩展 LLE 算法,可以更加科学的满足近邻点局部线性的要求,更好的保留原始数据的局部流形特征.同时,对样本外扩展数据进行迭代,根据核函数的性质与故障检测算法相结合,简化了原算法的计算量,提高了算法的工业应用价值.最后通过与 PCA 算法和 KPCA 算法的试验结果比较表明,本文提出的方法可以很好的完成非线性数据的故障检测,从而为传感器故障诊断提供了一种新的方法.

## 参考文献

- [1] H Hotelling. Analysis of a complex of statistical variables into principal components[J]. The Journal of Educational Psychology, 1933, 24(6): 498 - 520.
- [2] 周福娜,文成林,陈志国.基于指定元分析的多级相对微小故障诊断方法[J].电子学报,2010,38(8):1874 - 1879.  
Zhou Funa, Wen Chenglin, Chen Zhiguo. DCA based multi-level small fault diagnosis method[J]. Acta Electronic Sinica, 2010, 38(8): 1874 - 1879. (in Chinese)
- [3] Scholkopf B, Smola A J, Muller K. Nonlinear component analysis as a kernel eigenvalue problem[J]. Neural computation, 1998, 10(5): 1299 - 1319.
- [4] 薛建中,闫相国,郑崇勋.用核学习算法的意识任务特征提取与分类[J].电子学报,2004,32(10):1749 - 1753.  
Xue Jianzhong, Yan Xiangguo, Zheng Chongxun. Classifications of EEG during mental tasks by kernel learning algorithms [J]. Acta Electronic Sinica, 2004, 32(10): 1749 - 1753. (in Chinese)
- [5] Yoshikazu W. Adaptive subset kernel principal component analysis for time-varying patterns[J]. IEEE Transactions on Neural Networks and Learning Systems, 2012, 23(12): 1961 - 1973.
- [6] Roweis S, Saul L. Nonlinear dimensionality reduction by locally linear embedding [J]. Science, 2000, 290(22): 2323 - 2326.
- [7] 蒋全胜,李华荣,黄鹏.一种基于非线性流形学习的故障特征提取模型[J].振动与冲击,2012,31(23):132 - 137.  
Jiang Quansheng, Li Huarong, Huang Peng. A fault feature extraction model based on nonlinear manifold learning[J]. Journal of Vibration and Shock, 2012, 31(23): 132 - 137. (in Chinese)
- [8] Zhan Shenglin, Zhu Shan-an. Face recognition by LLE dimensionality reduction[A]. 2011 Fourth International Conference on Intelligent Computation Technology and Automation[C]. Shenzhen, China: IEEE, 2011. 121 - 123.
- [9] Bengio Y, Paiement J F, Vincent P. Out-of-sample extensions for lle, isomap, mds, eigenmaps, and spectral clustering[J]. Advances in Neural Information Processing Systems, 2004, 16: 177 - 184.

## 作者简介



张 伟 男,1979 年生于山东烟台,博士,中国科学院沈阳自动化研究所副研究员,主要从事模式识别、系统及传感器的故障检测与诊断研究.

E-mail: zhangwei@sia.cn



周维佳 男,1957 年生于上海,中国科学院沈阳自动化研究所研究员,博导,主要从事空间机器人及智能控制体系研究.

E-mail: zwj@sia.cn