

文章编号: 1000-5013(2012)06-0621-06

# 基于改进动态等距离映射的非线性动态故障诊断方法

张妮, 田学民, 蔡连芳

(中国石油大学(华东) 信息与控制工程学院, 山东 青岛 266580)

**摘要:** 分析动态等距离映射算法, 针对数据稀疏分布造成短路边的缺点, 运用主成分分析法进行可视化一维主元提取, 近似确定高维采样点的分布情况, 自适应获取采样点的近邻参数. 其次, 采用流形距离量度代替欧氏距离进一步得到测地线距离, 提取训练样本的子流形特征, 并运用标准化监控统计量实施过程监控和故障检测. 最后, 设立子流形综合相似度指标, 对故障数据进行模式匹配. TE(Tennessee Eastman)过程的仿真结果表明: 所提出的方法可以更为有效地检测到故障发生, 并进一步对发生的故障进行识别.

**关键词:** 动态等距离映射; 子流形; 非线性过程; 故障诊断; 主成分分析法

**中图分类号:** TP 277

**文献标志码:** A

以主成分分析(PCA)、独立分量分析(ICA)等为代表的多元统计方法, 通过提取采集数据的特征构造监控统计量并进行过程状态监控<sup>[1]</sup>. 然而, 化工过程数据关系复杂, 变量间的相关性较强, 简单的 PCA 等方法难以有效地获取高维数据的非线性特征. 流形学习是模式识别领域新兴的研究热点, 可以在保存数据结构的同时对高维数据进行特征提取<sup>[2]</sup>. Shao 等<sup>[3]</sup>采用最大方差展开(MVU)进行非线性过程故障诊断的研究. Zhang 等<sup>[4]</sup>从全局和局部数据结构特征保持分析考虑, 有效地提取了数据的低维子流形特征. Wong 等<sup>[5]</sup>提出两种基于监督最优局部保持投影和标准化拉普拉斯监督最优局部保持投影的特征提取算法, 并用于故障分类. 张妮等<sup>[6]</sup>运用动态等距离映射(ISOMAP)算法, 以典型化工 TE(Tennessee Eastman)过程为研究背景进行算法的仿真验证. 本文为了充分挖掘高维采样数据的结构信息, 提出一种基于改进动态等距离映射(IDSOMAP)流形学习的非线性故障诊断模型.

## 1 动态等距离映射算法

动态等距离映射(ISOMAP)算法是一种基于流形学习的非线性维数约减算法, 多维尺度变换(MDS)算法只对线性结构的数据集有效. 作为 MDS 算法的重要改进, Tenenbaum 等<sup>[7]</sup>在 ISOMAP 算法中引入了“测地距离”代替欧氏距离, 使得映射前后数据点对之间的测地距离保持不变.

设高维数据  $\mathbf{X} = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n)^T$ ,  $\mathbf{x}_i \in \mathbf{R}^m$ , 降维后坐标为  $\mathbf{Y} = (\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_n)^T$ ,  $\mathbf{y}_i \in \mathbf{R}^d$ . 动态等距离映射算法有如下 3 个主要的步骤:

- 1) 计算近邻域关系图  $G(V, E)$ ;
- 2) 确定  $G$  中数据点对间的最短路径, 即测地线距离  $d_M(\mathbf{x}_i, \mathbf{x}_j)$ ;
- 3) 将测地线距离矩阵带入 MDS 算法计算低维嵌入. 即有

$$\mathbf{B} = -\frac{1}{2}(\mathbf{I} - \frac{1}{n}\mathbf{l} \cdot \mathbf{l}^T)\mathbf{D}_M(\mathbf{I} - \frac{1}{n}\mathbf{l} \cdot \mathbf{l}^T). \quad (1)$$

**收稿日期:** 2012-06-15

**通信作者:** 田学民(1956-), 男, 教授, 主要从事过程控制及优化, 故障检测与故障诊断的研究. E-mail: tianxm@upc.edu.cn.

**基金项目:** 山东省自然科学基金资助项目(ZR2011FM014); 中央高校基本科研业务费专项资金资助项目(10CX04046A)

式(1)中: $\mathbf{I}$  为  $n$  阶单位阵; $\mathbf{l}$  为元素为 1 的  $n$  维列向量.

设  $\lambda_1 \geq \lambda_2 \geq \cdots \lambda_d$  对应矩阵  $\mathbf{B}$  最大的  $d$  个特征值,  $\mathbf{A}$  对应特征值构成的对角阵,  $\mathbf{a}_1, \mathbf{a}_2, \cdots, \mathbf{a}_d$  为特征向量, 观测数据的  $d$  维输出为

$$\mathbf{Y} = \sqrt{\mathbf{A}}\mathbf{a}. \tag{2}$$

## 2 改进的动态等距离映射算法

欧氏距离是常用的距离度量, 但在数据集不具有全局线性结构时, 欧氏距离不是一种合适的距离量度. 引入流形距离<sup>[8]</sup>, 即

$$d_g(\mathbf{x}_i, \mathbf{x}_j) = \exp\left(\frac{d_E(\mathbf{x}_i, \mathbf{x}_j)}{\sigma}\right) - 1. \tag{3}$$

式(3)中:  $d_E(\mathbf{x}_i, \mathbf{x}_j)$  为  $(\mathbf{x}_i, \mathbf{x}_j)$  之间的欧氏距离;  $\sigma$  为可变参数.

由此, 测地距离可以进一步表示为

$$d_M(\mathbf{x}_i, \mathbf{x}_j) = \min\{d_g(\mathbf{x}_i, \mathbf{x}_j), d_g(\mathbf{x}_i, \mathbf{x}_p) + d_g(\mathbf{x}_p, \mathbf{x}_j)\}. \tag{4}$$

采样数据稀疏时, 分布在相同大小区域的样本点相对减少, 导致近邻点搜索范围相对扩大, 可能出现不属于同一流形区域的点包含在同一邻域图中. 不同流形区域的点相互连接, 出现短路边, 不能反映流形整体的拓扑结构, 需要根据数据的实际分布确定近邻域参数.

高维数据的稀疏分布不易确定, 因此将高维数据通过 PCA 算法进行可视化一维预处理, 判断降维后一维主元分布状况, 邻域参数  $k$  根据一维得分的分布自适应获取.

PCA 借助于一个正交变换, 对过程采样协方差矩阵进行分解, 把原有相关的随机变量通过线性组合转化为不相关的主元变量. 低维空间的投影为

$$\mathbf{T} = (\mathbf{X}\mathbf{P})^T.$$

根据主元得分近似确定高维数据点的分布, 进一步确定近邻参数, 在样本点分布较稠密的地方, 近邻点的个数较多, 在分布比较稀少的地方, 近邻点的个数相对较少.

## 3 基于改进动态等距离映射的故障检测算法

ISOMAP 算法不能提供高维采样空间和低维嵌入空间的合理映射, 无法在线处理观测数据. 因此, 采用线性投影映射近似输入输出数据之间的关系, 即

$$\mathbf{Y} = \mathbf{X}\mathbf{A}.$$

通过线性最小二乘回归解方程获得基向量  $\mathbf{a}_j (j=1, 2, \cdots, d)$ , 当  $\mathbf{X}$  满秩时, 有

$$\mathbf{a}_j = (\mathbf{X}^T \cdot \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}^j. \tag{5}$$

采用改进的动态等距离映射方法进行数据非线性特征提取后, 在降维子流形空间及残差空间分别构造监控统计量, 采用标准化  $T^2$  监控统计量监控降维空间的变化, 即

$$T^2 = \mathbf{y}^T (\mathbf{Y}^T \mathbf{Y})^{-1} \mathbf{y}. \tag{6}$$

残差空间运用  $Q$  统计量测量 (也称为 SPE 统计量, 反应数据在残差子空间中偏离主元模型的程度) 其变化, 即有

$$Q = (\mathbf{x} - \hat{\mathbf{x}})^T \{(\mathbf{X} - \hat{\mathbf{X}})^T (\mathbf{X} - \hat{\mathbf{X}})\}^{-1} (\mathbf{x} - \hat{\mathbf{x}}). \tag{7}$$

式(7)中:  $\hat{\mathbf{x}}$  为  $\mathbf{x}$  的重构向量,  $\hat{\mathbf{x}} = \mathbf{A}\mathbf{A}^T \mathbf{x}$ ,  $\hat{\mathbf{X}} = \mathbf{A}\mathbf{A}^T \mathbf{X}^T$ .

改进动态等距离映射算法的故障检测分为离线建模和在线监测两个阶段.

1) 离线建模. 采集过程正常运行数据, 首先考虑滞后阶次的影响对观测向量  $\mathbf{x}$  增广化处理, 即

$$\mathbf{X}_t(p) = [\mathbf{X}(t) \mathbf{X}(t-1) \cdots \mathbf{X}(t-p)]. \tag{8}$$

式(8)中:  $p$  为滞后阶次. 扩展后的向量包含当前时刻的测量向量及  $t$  时刻之前的测量向量<sup>[9]</sup>.

标准化预处理后运用改进的动态等距离映射方法进行特征提取, 并确定采样空间和子流形空间的映射关系. 随后以降维特征信息构造监控统计量, 通过核密度估计确定监控量的控制限.

2) 在线监控. 在线采集过程数据, 标准化预处理后运用文中算法进行特征提取和残差计算, 并计算

出相应的监控统计量;如果统计量超出控制限,则表明监控过程可能有故障发生.

## 4 基于相似度模式匹配的故障诊断

当前故障是通过相似度匹配确定的. 首先运用改进动态等距离映射算法获取各类故障的子流形特征,对各类不同故障的特征构建故障模式库. 新的测试点通过文中算法获得降维子流形信息,并计算新增信息与更新后故障库信息之间的相似度测度判断故障类别. 两个子流形空间向量之间的几何角距离相似度定义为

$$S_1(Y_i, Y_{j, n_h}) = \frac{1}{n_h} \sum_{j=1}^{n_h} \cos^2 \theta_{i,j}, \quad (9)$$

$$\cos \theta_{i,j} = \frac{Y_i^T Y_{j, n_h}}{\|Y_i\|_2 \|Y_{j, n_h}\|_2}. \quad (10)$$

式(9),(10)中:  $Y_i$  为当前观测数据点的坐标;  $Y_{j, n_h}$  为历史数据库中故障  $j$  对应的故障点;  $n_h$  为故障库中每一种故障类型的训练点数;  $\theta_{i,j}$  是两个子流形空间中向量间的夹角.

进一步考虑流形距离相似度测度函数,对不同故障进行判别,则有

$$S_2(Y_i, Y_{j, n_h}) = \sqrt{\exp\left(\frac{Eu(Y_i, Y_{j, n_h})}{\sigma}\right) - 1}, \quad j = 1, 2, \dots, L. \quad (11)$$

式(11)中:  $Eu$  为两点之间的欧氏距离量度;  $L$  为故障类别数;  $\sigma$  为调节参数.

同一故障的数据相距较近,不同故障的数据之间距离相对较大,以此为准则判断故障所属类型,进而构造相似度匹配函数为

$$S = \max S_1, \text{ and, } \min S_2.$$

## 5 实例仿真结果分析

TE 过程<sup>[10]</sup>包含 5 个主要的操作单元,42 个测量变量和 12 个操作变量,除去反应器的搅拌速度,故障诊断采用的数据为 52 维,所有过程测量值均包含高斯噪声. 数据的采样时间为 3 min,仿真由无故障开始,故障在运行 8 h 后引入,每一次运行产生 960 个样本. 模拟 21 种人为设置的不同类型的故障,包含阶跃、斜坡、随机故障等.

选取正常工况的 960 个样本作为训练数据,对所有的变量预先进行均值与方差标准化,本征维数估计将 52 维数据降至 13 维,去除噪声的同时降低了计算的复杂度. 参数  $\sigma$  对故障检测率有一定的影响,交叉验证近似确定  $\sigma$  取值为 100. 邻域参数  $k$  取值对结果影响比较敏感,数据经过 PCA 算法预处理之后得到一维主元分布;然后,根据该分布可以近似确定参数  $k$  的取值. 文中监控置信限设为 95%,在仿真图图 1 中用点画线标出.

以 TE 过程的典型故障 4 为例,分析算法的故障检测仿真结果. 典型故障 4 涉及反应器冷却水入口温度的一个阶跃变化,该故障与正常运行条件下相比,每个变量的均值和标准差的变化很小,故障检测的任务更加具有挑战性. 动态等距离映射 (ISOMAP) 及其 3 种改进方法的监控图,如图 1 所示. 其中: IDISOMAP1 为在 ISOMAP 基础上对欧氏距离加以改进; IDISOMAP2 为在 IDISOMAP1 的基础上判断数据的稀疏; IDISOMAP(文中提出的基于改进动态等距离映射故障检测方法) 为在 IDISOMAP2 的基础上构造标准化监控统计量.

由图 1 可见:故障发生时, IDISOMAP 的  $Q$  监控统计量在故障发生之初就可以一直有效地检测到故障,其检测效果相对于原始的基于动态等距离映射的故障诊断方法有了很大的改善;  $T^2$  统计量有较大的漏检率,但是相比其他故障检测方法,  $T^2$  监测统计量的故障检测率也有较大程度的提高;其他几种方法的仿真结果中皆有很多数据点位于控制限之上,无法提供准确的工况反映图示.

在 TE 过程不同类型的代表故障下,4 种故障检测方法的监控统计量的故障检测率,如表 1 所示. 由表 1 可见:文中提出的基于改进动态等距离映射故障检测方法可以有效地检测到故障发生,故障检测率相对动态等距离映射方法<sup>[6]</sup>有了一定的改善和提高,一定程度上降低了过程运行的安全隐患.

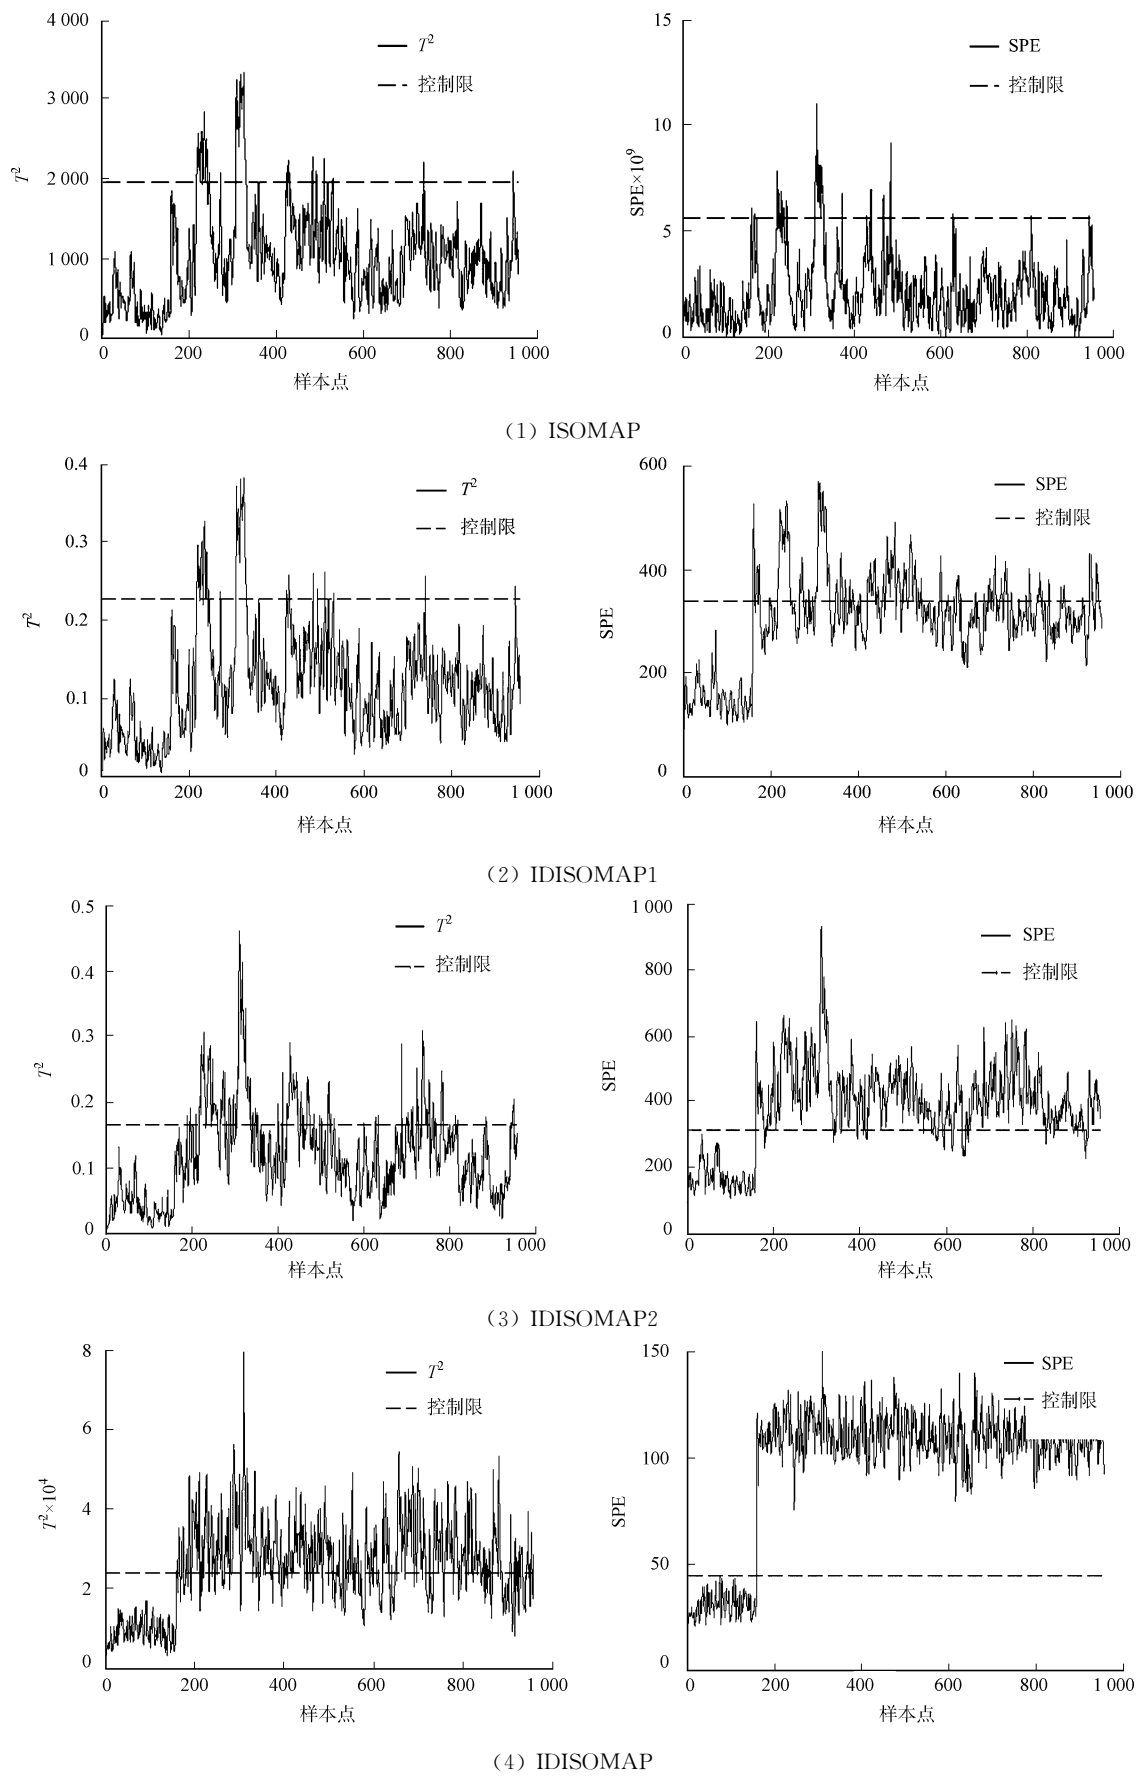


图 1 TE 过程故障检测监控图比较

Fig.1 Fault detection monitoring chart of TE process

表 1 TE 过程故障检测结果对比  
Tab.1 Fault detection results of TE process

故障	ISOMAP		IDISOMAP1		IDISOMAP2		IDISOMAP	
	Q	$T^2$	Q	$T^2$	Q	$T^2$	Q	$T^2$
IDV(4)	0.055 0	0.075 0	0.383 8	0.075 0	0.913 8	0.266 3	0.998 8	0.695 0
IDV(7)	0.792 5	0.606 3	0.998 8	0.603 8	0.998 8	0.817 5	0.998 8	0.972 5
IDV(10)	0.707 5	0.800 0	0.678 8	0.798 8	0.877 5	0.8850	0.930 0	0.895 0
IDV(11)	0.057 5	0.217 5	0.517 5	0.213 8	0.672 5	0.367 5	0.878 8	0.538 8
IDV(16)	0.615 0	0.722 5	0.508 8	0.723 8	0.860 0	0.881 3	0.956 3	0.888 8
IDV(17)	0.663 8	0.736 3	0.853 8	0.735 0	0.916 3	0.877 5	0.976 3	0.893 8
IDV(19)	0.017 5	0.001 3	0.003 8	0.001 3	0.107 5	0.111 3	0.992 5	0.363 8
IDV(20)	0.438 8	0.511 3	0.497 5	0.508 8	0.700 0	0.747 5	0.917 5	0.883 8

如果统计量  $T^2$  或  $Q$  超出控制限,则表明有故障发生,随后运用相似度匹配方法进行故障类型识别.取正常工况数据  $f_0$  和 8 种故障模式数据( $f_1, f_2, f_4, f_5, f_{10}, f_{16}, f_{18}, f_{21}$ ),对其进行子流形特征提取后建立故障模式库.以  $f_1$ (进料比率发生阶跃变化)为例,当前故障与历史故障模式库的两相似度指标分别如图 2 所示.

由图 2 可以看出:当前故障与故障库中的  $f_1$  几何角距离相似度  $S_1$  最大,其纵坐标表示当前故障与故障模式库中 9 种不同类型数据之间的距离.进一步可以看出,当前故障与参考故障库中的  $f_1$  距离最近,相似性最大,可以判断当前发生故障为  $f_1$ .说明所提出的改进的动态等距离映射算法对于非线性数据具有很好的特征提取能力,对多种故障具有较好的区分度.

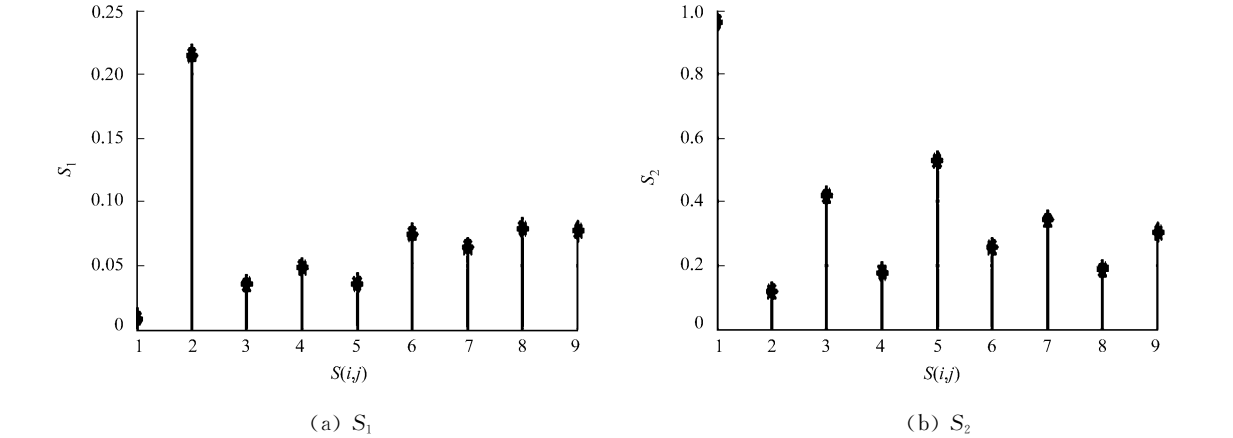


图 2 相似度匹配图  
Fig.2 Similarity matching diagram

6 结论

文中所提出的方法通过高维数据的可视化低维投影,获得数据的近似稀疏分布并确定采样点的近邻域参数,这在一定程度上降低了短路边对数据流形结构的影响,同时运用流形距离代替传统的欧氏距离,进一步得到测地距离阵.

在保留数据结构的前提下,对系统进行非线性特征的提取,深入挖掘过程的非线性动态信息;然后,在主流形空间和残差空间分别构造标准化监控统计量实施故障检测.

相对于原有的基于动态等距离映射方法的故障检测方法,该方法更具灵敏性,故障检测率有一定程度的提高.故障检测后,采用子流形相似度匹配的故障诊断方法对故障类型进行模式匹配,可以获得较好的诊断结果,给工作人员提供决策指导.

参考文献:

[1] VENKATASUBRAMANIAN V,RENGASWAMY R,KAVURI S N,et al. A review of process fault detection and

diagnosis: Part III : Process history based methods[J]. Computers and Chemical Engineering,2003,27(3):327-346.

[2] VAN DER MAATEN L J P,POSTMA E O,VAN DEN HERIK H J. Dimensionality reduction: A comparative review[J]. Computer and Information Science,2008,71(1):2596-2603.

[3] SHAO Ji-dong,RONG Gang. Nonlinear process monitoring based on maximum variance unfolding projections[J]. Expert Systems with Applications,2009,36(8):11332-11340.

[4] ZHANG Mu-guang,GE Zhi-qiang,SONG Zhi-huan,et al. Global-local structure analysis model and its application for fault detection and identification[J]. Industrial & Engineering Chemistry Research,2011,50(11):6837-6848.

[5] WONG W K,ZHAO H T. Supervised optimal locality preserving projection[J]. Pattern Recognition,2012,45(1):186-197.

[6] 张妮,田学民. 基于等距离映射的非线性动态故障检测方法[J]. 上海交通大学学报:自然科学版,2011,45(8):1202-1206.

[7] TENENBAUM J B,DE SILVA V,LANDFORD J C. A global geometric framework of nonlinear dimensionality reduction[J]. Science,2000,290(5500):2319-2323.

[8] BELKIN M,NIYOGI P,SINDHWANI V. Manifold regularization: A geometric framework for learning from labeled and unlabeled examples[J]. Journal of Machine Learning Research,2006,7:2399-2434.

[9] KU W,STORER R H,GERGAKIS C. Disturbance detection and isolation by dynamic principal component analysis [J]. Chemometrics and Intelligent Laboratory Systems,1995,30(1):179-196.

[10] DOWNS J J,VOGEL E F. A plant-wide industrial process control problem[J]. Computers and Chemical Engineering,1993,17(3):245-255.

Nonlinear Dynamic Fault Diagnosis Method Based  
on Improved Isometric Mapping

ZHANG Ni, TIAN Xue-min, CAI Lian-fang

(College of Information and Control Engineering, China University of Petroleum (East China), Qingdao 266580, China)

**Abstract:** DISOMAP (dynamic isometric mapping) algorithm is analyzed in this paper. According to the shortcomings of short edge caused by data sparse distribution, PCA (principal component analysis) algorithm was used to extract one-dimensional visualization principal component, determining the distribution of sampling points approximately, acquiring the neighbor parameter of sampling point adaptively. Secondly, manifold distance instead of euclidean distance was defined to calculate geodesic distance furtherly. So the submanifold character could be extracted from the training sample. Standardized monitoring statistics were used in process monitoring application and fault detection. Finally, the similarity index was used for pattern matching in the sub-manifold fault database. Simulation results of TE (Tennessee Eastman) process show that improved dynamic isometric mapping (IDISOMAP)-based method is more effective for fault detection and fault identification.

**Keywords:** dynamic isometric mapping; sub manifold; non-linear process; fault diagnosis; principal component analysis

(责任编辑: 黄晓楠      英文审校: 杨建红)