

文章编号: 1001-0920(2003)02-0229-04

一种基于输入训练神经网络的 非线性 PCA 故障诊断方法

李尔国, 俞金寿

(华东理工大学 自动化研究所, 上海 200237)

摘 要: 简要讨论了线性 PCA 故障诊断方法存在的问题, 提出一种基于输入训练神经网络的非线性 PCA 故障诊断方法。该方法首先利用输入训练神经网络和 BP 网络双网络机制, 实现非线性主元的识别, 并采用统计方法进行故障检测与故障分离。对 CSTR 的仿真研究结果表明, 该方法能够克服线性 PCA 方法在提取过程变量的非线性特征方面存在的不足, 并能够准确地进行故障检测和分离。

关键词: PCA; 神经网络; 故障诊断

中图分类号: TP273 **文献标识码:** A

Input-training neural network-based nonlinear principal component analysis approach for fault diagnosis

LI Er-guo, YU Jin-shou

(Research Institute of Automation, East China University of Science & Technology, Shanghai 200237, China)

Abstract: Some problems existing in the linear principal component analysis methodology are discussed briefly. A nonlinear principal component analysis methodology based on input-training neural network is presented for fault diagnosis. Input-training neural network and BP neural network are used to estimate the nonlinear principal component scores. Fault detection and diagnosis are performed by means of statistical methods. The simulation research to continuous stirred tank reactor (CSTR) is performed to show its advantages in extracting the nonlinear features compared with the linear principal component analysis methodology.

Key words: PCA; Neural network; Fault diagnosis

1 引 言

主元分析方法 PCA 是一种利用统计原理建立描述系统的低维模型的方法^[1]。由于未考虑过程动态模型, 因此 PCA 方法不能进行复杂的故障检测与诊断, 而且它对故障的检测和诊断仅局限于测量变量, 从而无法对其他故障进行诊断^[2]。此外, 由于常规的 PCA 方法是一种线性方法, 对于复杂非线性系统, 可能会丢失系统所包含的重要非线性信息^[3]。所以, 目前许多学者考虑将 PCA 方法和系统动态模型

结合起来, 建立基于模型的 PCA 故障诊断方法^[1,4], 或将 PCA 方法与人工神经网络方法相结合^[5-8], 建立非线性 PCA 方法。但从总体上看, 目前非线性 PCA 故障诊断方法的研究仍处于探索阶段。

本文提出一种基于输入神经网络的非线性 PCA 故障诊断方法, 该方法首先利用双网络(输入神经网络和 BP 网络)机制实现非线性主元的识别, 并采用统计的方法进行故障检测与故障分离。将该方法用于一连续搅拌的釜式反应器(CSTR)中, 其

收稿日期: 2001-11-05; 修回日期: 2002-05-27。

作者简介: 李尔国(1975—), 男, 安徽天长人, 博士生, 从事基于知识的故障诊断及应用的研究; 俞金寿(1939—), 男, 浙江海宁人, 教授, 博士生导师, 从事化工过程控制、过程建模与控制等研究。

仿真研究结果表明,该方法可以克服线性 PCA 方法在提取过程变量非线性特征方面存在的不足,并能够准确地进行故障检测和分离。

2 基于输入训练神经网络的非线性 PCA 故障诊断方法

2.1 线性 PCA 和非线性 PCA

设过程正常工况下的历史测量数据集为 $X = [X_1, X_2, \dots, X_M] \in R^{N \times M}$ 。如果过程的各测量变量之间存在冗余,那么理论上利用 A ($A < M$) 个主元就可反映出过程的主要信息。利用线性主元计算方法可得到主元矩阵 $T_L = [t_1, t_2, \dots, t_A] \in R^{N \times A}$ 和负荷向量矩阵 $P = [p_1, p_2, \dots, p_A] \in R^{M \times A}$, 设 \hat{X} 为 X 的估计, E 为残差矩阵, 则原测量数据集可表示为

$$X = \hat{X} + E = T_L P^T + E = \sum_{i=1}^A t_i p_i^T + E \quad (1)$$

非线性 PCA 是线性 PCA 的扩展。线性 PCA 是为了提取过程变量中的线性信息, 而非线性 PCA 不仅提取过程变量中的线性信息, 而且同时提取了非线性信息, 这一点可从

$$X = \hat{X} + E = F(T_N) + E \quad (2)$$

看出。式中: $T_N = [t_1, t_2, \dots, t_K]$ 为非线性主元得分矩阵, $F(\bullet)$ 为一非线性函数, E 为残差矩阵。

现在的问题是如何从历史数据集中提取非线性特征, 即求出 T_N , 同时寻找出合适的非线性函数 $F(\bullet)$, 使它们满足式 (2)。为此, Tan 等人提出了 IT (Input-training) 神经网络, 并证明单输入的 IT 网络方法与主曲线方法是等价的^[9]。IT 网络在训练时, 网络输入不是固定不变的, 而是随着网络内部连接参数的调整作自适应调整。当网络训练完时, 根据网络的最终输入便可得到 T_N , 而 IT 网络则逼近了函数 $F(\bullet)$ 。本文采用多层 IT 网络, 其结构如图 1 所示。

采用快速梯度下降法调整网络间连接权值和




图 1 多层输入训练神经网络结构

阈值, 目标函数为

$$J = \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^M (X_{ij} - \hat{X}_{ij})^2 = \frac{1}{2} \sum_{j=1}^M e_j^2 \quad (3)$$

为减小学习过程中的振荡, 提高网络的收敛性, 对算法引入动量项及动量因子。

2.2 基于输入训练神经网络的非线性 PCA 故障诊断方法

本文提出的基于输入训练神经网络的非线性 PCA 方法的故障诊断原理如图 2 所示。




图 2 故障诊断原理

在实际问题中, 不同的变量具有不同的量纲, 为消除由于量纲不同可能带来的一些不合理影响, 通常应对测量数据进行标准化处理, 转化成标准数据集 X^* , 即

$$X_i^* = \frac{X_i - E(X_i)}{\sqrt{\text{Var}(X_i)}}, \quad i = 1, 2, \dots, M \quad (4)$$

这样原数据集 X 就被变换为均值为 0, 方差为 1 的标准数据集 X^* 。

根据式 (1), 利用线性 PCA 方法进行线性变换, 将数据集 X^* 表示成一组新的互不相关的线性主元, 为保留原始数据中的非线性关系, 提取最大线性相关信息时应保留足够大的方差; 然后使用多层输入训练神经网络提取数据非线性结构, 即识别非线性主元得分矩阵。在输入训练神经网络结构中, 将非线性主元得分矩阵 T_N 作为网络输入, 数据集 X^* 作为网络输出, T_N 的初始值从理论上可任意选取, 但经验表明 T_N 的初始值取为 T_L 将有助于网络的快速收敛。因此, 基于输入训练神经网络的 PCA 模型可表示为

$$X^* = G(T_N) \cdot P^T + E \quad (5)$$

式中: $T_N = [t_1, t_2, \dots, t_K]$ 为非线性主元得分矩阵, 可通过输入训练神经网络最终得到; P 为线性主元载荷向量; $G(\bullet)$ 为一非线性函数, 即输入训练神经网络所表示的函数; E 为残差矩阵。

由于计算一个新数据的非线性主元得分矩阵涉及到非线性优化算法, 该算法需要很长的运算时间, 这将难以满足在线过程监测和故障诊断的要求。为了能够快速识别新数据的非线性主元, 这里采用

另一前馈神经网络 BP 网络来实现过程数据与非线性主元得分矩阵之间的映射。网络的输入可采用数据集的线性主元得分矩阵 T_L 来代替数据集 X^* , 网络的输出则为经过输入训练神经网络得到的 T_N , 因此非线性主元得分矩阵可表示为

$$T_N = H(T_L) = H(X^* \cdot P) \quad (6)$$

式中 $H(\cdot)$ 为一非线性函数, 即 BP 网络所逼近的函数。

分别训练 IT 网络和 BP 网络, 使得式 (5) 和 (6) 得以实现, 这样就建立了非线性 PCA 模型。该模型可以很方便地用于在线过程监视和故障检测。对于一新数据 X_{new} , 首先利用 BP 网络在线识别其非线性主元得分矩阵 T_{new} , 再运用 IT 网络在线计算出估计值 X_{new} , 最后计算残差 E_{new} 。利用 T_{new} , X_{new} 和 E_{new} 可进行统计假设检验, 常用的统计有 Hotelling T^2 统计和 Q 统计^[2]。根据统计假设检验结果, 可检测有无异常发生。

当检测出故障后, 就要对故障进行分离。对于线性 PCA 模型, 贡献图方法是一种简单有效的故障诊断方法, 它根据各测量变量的变化对系统统计模型稳定性的影响大小实现故障分离。对于 Q 统计方法, 可根据各变量的估计残差对 SPE 的贡献值大小进行故障分离; 对于 Hotelling T^2 统计方法, 可根据每个变量对线性主元的贡献大小进行故障诊断, 具体方法可参见文献 [2]。在非线性 PCA 故障诊断方法中, 仍可继续采用 Q 统计方法进行故障分离, 但对于 T^2 统计方法, 由于过程变量与主元之间存在非线性关系, 必须重新计算贡献率。由于 $H(\cdot)$ 的一阶偏导数表示变量的变化对该函数影响的大小, 因此对于某一数据点 X_0 , 它对 T_N 的贡献率为

$$X \Big|_{X=X_0} \cdot \frac{\partial T_N}{\partial X} \Big|_{T_N=T_k, X=X_0} \quad (7)$$

式中 $\partial T_N / \partial X$ 为 T_N 和 X 之间的一阶偏导数, T_N 和 X 满足式 (6)。显然, 在线性 PCA 中, $\partial T_N / \partial X$ 为一常量, 即线性主元载荷向量 P 。根据各变量对主元的贡献率大小, 可找出引发过程异常的主次要原因, 从而实现故障分离。

3 仿真研究

考虑一个连续搅拌的釜式反应器, 该反应过程的仿真模型为

$$\frac{dC_A}{dt} = \frac{q}{V} (C_{Af} - C_A) - k_0 \exp\left(-\frac{E}{RT}\right) C_A \quad (8)$$

$$\frac{dT}{dt} = \frac{q}{V} (T_f - T) + \frac{-\Delta H}{\rho C_p} k_0 \exp\left(-\frac{E}{RT}\right) C_A +$$

$$\frac{UA}{V \rho C_p} (T_c - T) \quad (9)$$

式中: C_A 为反应浓度; q 为反应物进料流速; V 为反应体积; C_{Af} 为进料浓度; k_0 为预指数因子; E 为活化能; T_f 为进料温度; T 为反应温度; ΔH 为反应热; C_p 为热容量; T_c 为冷却剂的温度。标准状态下, 系统的参数为 $q = 100 \text{ L/min}$, $-\Delta H = 17\,835.82 \text{ J/mol}$, $T = 446 \text{ K}$, $C_{Af} = 1 \text{ mol/L}$, $\rho = 1\,000 \text{ g/L}$, $E/R = 5\,360 \text{ K}$, $V = 100 \text{ L}$, $UA = 11\,950 \text{ J/(min} \cdot \text{K)}$, $C_A = 0.2 \text{ mol/L}$, $T_c = 419 \text{ K}$, $k_0 = \exp 13.4 \text{ min}^{-1}$, $T_f = 400 \text{ K}$, $C_p = 0.239 \text{ J/(g} \cdot \text{K)}$ 。

系统以 T_c 作为输入量, 进行反应浓度设定点的控制。根据仿真模型采集正常工况下的 100 组数据构成历史数据集 $X = [q, T, C_A, T_c, C_{Af}, T_f] \text{ R}^{100 \times 6}$, 采样间隔 $dt = 0.2 \text{ min}$, 为模拟实际过程的测量数据, 仿真时对各变量加上零均值的高斯白噪声, 并将 X 按式 (4) 进行标准化处理。

假设在 $k = 101$ 时, 系统发生异常, CSTR 反应出口浓度的传感器发生故障 $\Delta C_A = 0.05 \text{ mol/L}$ 。根据文献 [2] 的研究结果可知, 运用线性 PCA 方法, SPE 图和 T^2 图都可以较缓慢地检测出该故障, 但利用 SPE 和 T^2 贡献图无法对故障进行分离, 并会出现误报。现采用非线性 PCA 方法来进行故障监测与分离。按照 2.2 节所述方法建立非线性 PCA 模型, 非线性主元数取为 2, 主元对原数据集的方差表示为 97%, IT 神经网络的结构为 2-11-5-6, BP 神经网络的结构为 5-11-2。将训练好的双网络用于系统故障检测与故障分离。图 3 为基于 T^2 的非线性 PCA 主元监视图, 图中“ \circ ”和“ ∇ ”分别表示正常工况历史数据集和故障数据集, 图中内部椭圆线表示 95% 置信限, 外部表示 99% 置信限。由图可见, 非线性 PCA 已识别出过程中的异常。图 4(a) 和 (b) 分别为线性和非线性 PCA 方法的 SPE 贡献图, 图中“ \circ ”, “ ∇ ”, “ \cdot ”, “ \times ”分别表示变量 q, T, C_A, T_c, C_{Af} 和 T_f 。






图 3 基于 T^2 的非线性 PCA 主元监视图



(a) 基于线性 PCA 方法



(b) 基于非线性 PCA 方法

图4 基于 SPE 贡献图的故障分离结果

图4(a)中各变量对SPE贡献都较大,因此无法对故障进行分离,甚至出现误报。而在图4(b)中,反应浓度 C_A 对出现的异常贡献最大,因此可以认为反应浓度 C_A 值出现了异常,从而找出了故障源。可见,由于非线性PCA更全面地描述了系统特征,因此更适合过程监视和故障诊断。

4 结 论

本文改进了输入训练神经网络学习算法,并提出了基于输入训练神经网络的非线性PCA故障诊断方法。对CSTR的仿真研究结果表明,该方法可以克服线性PCA方法在提取过程变量非线性特征

方面的不足,并能够准确地进行故障检测和分离。由于采用双网络(输入神经网络和BP网络)机制实现非线性主元的识别,因此该方法可用于在线过程监测和故障诊断。非线性PCA方法同时提取了历史数据集中的线性信息和非线性信息,同线性PCA相比,它能更全面准确地描述系统,因此非线性PCA故障诊断方法必将成为故障诊断领域的研究热点。

参考文献(References):

- [1] Seongkyu Yoon, MacGregor John F. Statistical and causal model-based approaches to fault detection and isolation[J]. *A IChE J*, 2000, 46(9): 1813-1824
- [2] 李尔国,俞金寿. PCA在过程故障检测与诊断中的应用[J]. *华东理工大学学报*, 2001, 27(5): 572-576
- [3] Dong D, Thomas J. Batch tracking via nonlinear principal component analysis[J]. *A IChE J*, 1996, 42(8): 2199-2208
- [4] Roten Y, Wachs A, Lewin D R. Ethylene compressor monitoring using model-based PCA[J]. *A IChE J*, 2000, 46(9): 1825-1836
- [5] Patton R J, Chen J, Benkhedda H. A study on neuro-fuzzy systems for fault diagnosis[J]. *Int J of System Science*, 2000, 31(11): 1441-1448
- [6] Jia F, Martin E B, Morris A J. Non-linear principal components analysis with application to process fault detection[J]. *Int J of System Science*, 2000, 31(11): 1473-1487
- [7] Kramer M A. Non-linear principal component analysis using autoassociative neural networks[J]. *A IChE J*, 1991, 37(2): 233-243
- [8] Malhotra E C. Limitations of non-linear PCA as performed with generic neural networks[J]. *IEEE Trans on Neural Networks*, 1998, 9(1): 165-173
- [9] Tan S, Mavrouniotis M L. Reducing data dimensionality through optimizing neural network inputs[J]. *A IChE J*, 1995, 41(6): 1471-1480

(上接第228页)

- [2] Schei T S. A finite-difference method for linearization in nonlinear estimation algorithms[J]. *Automatica*, 1997, 33(11): 2051-2058
- [3] Norgaard M, Poulsen N K, Ravn O. Easy and accurate state estimation for nonlinear systems[A]. *14th IFA C World Conf [C]*. Beijing, 1999. 343-348
- [4] Julier S J, Uhlmann J K, Durrant W F. A new

approach for filtering nonlinear systems[A]. *Proc 1995 American Control Conf [C]*. Seattle, 1995. 1628-1632

- [5] Zhang Y M, Dai G Z, Zhang H C, et al. A SVD-based extended Kalman filter and application to flight state and parameter estimation of aircraft[J]. *Control Theory Appl*, 1996, 13(1): 106-114