

一种基于模糊逻辑的非线性系统故障检测与定位的方法*

刘志言 沈毅 刘宜平

(哈尔滨工业大学控制科学与工程系, 哈尔滨, 150001)

摘要: 针对一般非线性系统, 提出了一种带故障标志的系统故障模糊模型, 基于此模型给出了一种非线性系统故障检测与定位的新方法. 它采用模糊聚类算法提取故障系统的模糊规则, 进而完成系统故障的检测与定位. 该方法对噪声污染具有较强的抑制作用, 对模型误差亦无较高的要求. 仿真结果表明所提方法对非线性系统的故障可以及时准确地完成检测与定位.

关键词: 非线性系统; 故障诊断; 模糊聚类分析; 模糊模型

文献标识码: A

An Approach to Fault Detection and Isolation in Nonlinear System Based on Fuzzy Logic

LIU Zhiyan, SHEN Yi and LIU Yiping

(Department of Control Science and Engineering, Harbin Institute of Technology, Harbin, 150001, P. R. China)

Abstract: A new fuzzy model with symbols for faults in system is proposed. Further, based on this model, a new method for fault detection and location in nonlinear systems is developed. The method extracts fuzzy rules by fuzzy cluster algorithms to perform fault diagnosis. It can be still efficient when there exist noise and model error. Finally, the simulation results demonstrate the effectiveness and feasibility of the proposed method.

Key words: nonlinear systems; fault diagnosis; fuzzy cluster analysis; fuzzy model

1 引言(Introduction)

非线性系统因其结构的复杂性、强烈的非线性使得对其故障诊断研究一直进展不大, 文献[1]分别针对一些特殊类型的非线性系统给出了一些故障检测的方法, 但仅限于检测, 未给出有效的故障定位方法; 而文献[2]的方法可以对非线性系统进行故障检测与定位, 且具有较强的抗干扰能力, 但缺乏一般性, 算法效果易受到各类参数初值选取的影响, 且需要噪声的统计特性, 算法对被诊断系统的要求比较严格.

事实上, 在实际系统运作时, 操作人员可以较容易从系统的各种症状来判断系统是处于正常状态还是系统的某一部分出现异常. 本文正是基于这种思想, 试图在这方面做些工作: 系统的各种症状可以看作是某种意义上的系统模糊模型, 而系统的各个模糊模型可以从系统大量的输入、输出样本中提取得到. 本文采用的是一种基于 Fuzzy C-Means(FCM)思想的自学习聚类算法来建立模糊模型, 它可以有效地从大量数据样本中提取所需模糊规则. 但是建立

系统的各个模糊模型后, 并不意味着可以将系统的故障准确无误的检测出来. 为此, 本文提出一种有别于传统模糊模型的带输出标志的模糊模型. 标志 Z 这里所起的作用就是标识系统的故障状态. 从而可以仅通过对 Z 曲线的实时监测即可准确地判定系统的状态, 完成系统的故障检测与定位.

2 模糊聚类算法与模糊模型的建立(Fuzzy cluster algorithm and fuzzy modeling)

2.1 模糊聚类算法(Fuzzy cluster algorithm)

FCM 聚类算法是一种迭代优化算法, 它的指标

函数为: $J = \sum_{k=1}^n \sum_{i=1}^c u_{ik}^m \|x_k - v_i\|^2$, 其中, m 是权值

指数, $1 \leq m \leq \infty$; v_i 为数据的第 i 个聚类中心;

$$\mu_{ik} = \frac{\left(\frac{\|x_k - v_i\|}{\|x_k - v_j\|} \right)^{-2/(m-1)}}{\sum_{j=1}^c \left(\frac{\|x_k - v_i\|}{\|x_k - v_j\|} \right)^{-2/(m-1)}}$$
 为数据 x_k 对第 i 个聚

类中心 v_i 的隶属函数. 但是和大多数非线性优化问题一样, FCM 法对数据聚类效果的优劣, 很大程度上依赖于初值(如聚类数 C 、初始聚类中心点等)的选择. Stephen L. Chiu 部分解决了此初值选择的问

* 基金项目: 国家自然科学基金(69904004)资助项目.

收稿日期: 1999-02-02; 收修改稿日期: 2000-03-21.

题^[3].其算法描述如下:

1) 初值选取:每一个数据点作为一个潜在的聚类中心点.

2) 对每个数据点 x_i 定义测度

$$P_i = \sum_{j=1}^n e^{-\alpha} \|x_i - x_j\|^2,$$

其中, $\alpha = 4/r_a^2$, r_a 是正常数. P_i 是 x_i 到其他任一数据点距离的函数. 计算各 P_i 值, 选择对应 P_i 值最高的点 x_i 作为第一个聚类中心 x_1^* .

3) 计算决定下一个聚类中心点

$$P_i = P_i - P_1^* e^{-\beta \|x_i - x_1^*\|^2},$$

其中, $\beta = 4/r_b^2$, $r_b = 1.5r_a$. 距 x_1^* 越近的数据点, 其相应的 P_i 就越小, 故而成为下一个聚类中心点的可能性就越小. 接下来计算第三个、第四个……聚类中心点. 经过 K 次聚类后,

$$P_i = P_i - P_k^* e^{-\beta \|x_i - x_k^*\|^2},$$

直到 $P_k^* < \epsilon P_1^*$ 为止. 这里 ϵ 是一个很小的数.

2.2 对此算法的几点讨论与改进 (Discussion and improvement of the algorithm)

1) 对 ϵ 选择的讨论.

采用如下三值逻辑判别标准: 如果 $P_k^* > \bar{\epsilon} P_1^*$ 则将接受 x_k^* 作为一个新聚类中心点. 这里 $\bar{\epsilon}$ 是接受 x_k^* 作为聚类中心点的阈值. 否则, 若 $P_k^* < \underline{\epsilon} P_1^*$ 则拒绝 x_k^* 作为聚类中心点, 结束整个聚类处理. 这里 $\underline{\epsilon}$ 是拒绝 x_k^* 作为聚类中心的阈值. 如果 $\underline{\epsilon} P_1^* < P_k^* < \bar{\epsilon} P_1^*$ 则进一步判断: $d_{\min}/(cr_a) + p_k^*/p_1^* \geq 1$ 就接受 x_k^* 作为一个聚类中心, 这里, $d_{\min}$ 是 x_k^* 到前面所有 $(K-1)$ 个聚类中心点的最短距离, c 为常系数. 否则拒绝 x_k^* 作为聚类中心点, 并同时将此 x_k^* 值置为 0, 并选择下一个最高的 P_i 值作为新的 x_k^* 重新测试.

2) 对聚类中心“振荡”现象的预防.

在实际的运用中, 我们发现原算法很容易出现两个聚类中心 x_1, x_2 交替连续出现的循环情况, 也即形成聚类点为 $x_1, x_2, x_1, x_2, \dots$. 解决的办法是把已经成为聚类中心的点从形成下一个聚类中心的候选数据点中删除掉.

3) 对数据假聚类现象的克服.

原算法采用的判断下一个聚类中心点的标准是距离第 i 个聚类中心 x_i 最大的数据点具有最高的聚类候选值. 这样就易在形成聚类时产生聚类中心点不符合聚类要求的假聚类现象, 也即假设对 x_1 来

说, x_2 是符合要求的由 x_1 产生的聚类中心, 它应该距离 x_1 是最远的. 但在由 x_2 产生下一个聚类中心 x_3 时, x_3 就很可能出现距离 x_2 很远, 但同时距离 x_1 却很近. 显然这种在 x_1 点附近形成的新聚类中心, 从整体上是符合数据聚类要求的. 对此, 我们采用到所有已经产生的聚类中心点最短距离中最大的数据点具有最高的聚类候选值的标准来进行聚类. 也即: $x_{i+1} = d^{-1}(\max\{\min\{d_{ml}\}\})$, 其中, d^{-1} 为求取 $d(x)$ 对应的数据点 x ; m 为候选数据点; $l = 1, \dots, i$.

2.3 模糊模型的建立 (Fuzzy modeling)

当我们应用聚类估计方法来对输入、输出数据进行分类时, 每个聚类中心点是体现系统特性的重要数据. 因此, 依据每个聚类中心点可构成各条描述系统特性的模糊规则.

设在 M 维空间中考虑聚类中心点集 $\{x_1^*, x_2^*, \dots, x_c^*\}$. 令前 N 维分量与输入变量相对应, 而剩下的 $M-N$ 维分量则与系统的输出相对应. 这样就将向量 x_k^* 分解成两个向量 u_k^* 和 y_k^* , 即: $x_k^* = [x_{k1}^*, x_{k2}^*, x_{k3}^*, \dots, x_{kN}^*, \dots, x_{kM}^*] = [u_k^*, y_k^*]$. 于是可以将每一个聚类中心点 x_k^* 转换为描述系统特性的一条模糊规则. 给定输入向量 u , 其对第 i 条模糊规则的隶属函数定义为:

$$\mu_i = e^{-\alpha \|u - u_i^*\|^2}, \quad (1)$$

所对应的输出向量 y 由式(2)计算:

$$y = \sum_{i=1}^c \mu_i y_i^* / \sum_{i=1}^c \mu_i. \quad (2)$$

从而第 i 条模糊规则具有如下的形式:

$$\begin{aligned} &\text{if } u_1 \text{ is } A_{i1} \ \& \ u_2 \text{ is } A_{i2} \ \& \ \dots \\ &\text{then } y_1 \text{ is } B_{i1} \ \& \ y_2 \text{ is } B_{i2} \ \& \ \dots \end{aligned}$$

这里 u_j 是输入向量 u 的第 j 个输入变量; y_j 是输出向量 y 的第 j 个输出变量; A_{ij} 是具有指数隶属函数的模糊集; B_{ij} 是单值模糊集; 对于由聚类中心 x_k^* 所表示的规则, A_{ij} 和 B_{ij} 分别由下式给出:

$$\begin{cases} A_{ij}(q) = e^{-\alpha(q - u_{ij}^*)^2}, \\ B_{ij} = y_{ij}^*, \end{cases}$$

这里 u_{ij}^* 是 u_i^* 的第 j 个分量元素; y_{ij}^* 是 y_i^* 的第 j 个分量元素.

方程(1)和(2)提供了一种直接将模糊聚类中心集转变为模糊推理系统的方法. 并且如果将方程(2)中的 y_i^* 以简单的线性函数 $y_i^* = C_i u + h_i$ 来替代, 这里 C_i 为 $(M-N) \times N$ 的常数阵, h_i 是 $(M-N) \times 1$ 的常数列向量, 规则就转化为 Tokogi-Sugero 类

型,则系统的建模精度将会得到显著的提高^[3].

3 故障诊断策略的实现(Strategy of diagnosis)

3.1 用作故障诊断的模糊模型(Fuzzy model for diagnosis)

为了适应故障诊断的要求,我们提出了一种特殊的带系统状态标志的模糊模型.具体阐述如下:假设系统处于模型 P 下,经过对样本数据的聚类处理形成 C_p 条规则,它们即是在模型 P 下的系统模糊模型.为表示系统所处状态,在各条规则的结论部分,加入标志项,常值 z^p .也即形成如下用于故障诊断的规则:

if u_1 is A_{11}^p u_2 is $A_{12}^p \cdots u_N$ is A_{1N}^p
 then y_1 is B_{11}^p y_2 is $B_{12}^p \cdots y_{(M-N)}$ is $B_{1(M-N)}^p$ z is z^p ,
 $\vdots$
 if u_1 is A_{i1}^p u_2 is $A_{i2}^p \cdots u_N$ is A_{iN}^p
 then y_1 is B_{i1}^p y_2 is $B_{i2}^p \cdots y_{(M-N)}$ is $B_{i(M-N)}^p$ z is z^p ,
 $\vdots$
 if u_1 is $A_{C_p1}^p$ u_2 is $A_{C_p2}^p \cdots u_N$ is $A_{C_pN}^p$
 then y_1 is $B_{C_p1}^p$ y_2 is $B_{C_p2}^p \cdots y_{(M-N)}$ is $B_{C_p(M-N)}^p$ z is z^p .

且对同一模糊模型,其包含的所有模糊规则 z 的取值均为 z^p .显然,因为 z 的取值与系统的输入、输出无任何耦合关系,故而加入此 z 标志项对原系统的模糊规则没有任何影响,它仅起到指示系统在当前输入、输出条件下处于何种状态模式的作用.

对任意输入、输出数据对 $x = (u, y)$,它对模型 P 中的第 i 条规则的隶属度可按式计算: $\mu_i^p = e^{-\alpha \|x - x_i^*\|^2}$, 这里, $i = 1, 2, \cdots, C_p$, C_p 为第 p 模型所含的规则数; $p = 1, 2, \cdots, S$, S 为系统已经辨识出的状态模型总数; x_i^* 为系统的第 p 模型中第 i 条规则所代表的聚类中心.将此 S 种系统状态的所有规则形成一个整体规则基,共计有 $Q = \sum_{p=1}^S C_p$ 条规则.则输入、输出数据对 $x = (u, y)$ 对此规则基的第 l 条规则的隶属度就可以按下式计算: $\mu_l = e^{-\alpha \|x - x_l^*\|^2}$, 这里, x_l^* 为规则基中第 l 条规则所对应的聚类中心.于是可定义:

$$z' = \sum_{i=1}^Q \mu_i z_i^p / \sum_{i=1}^Q \mu_i, \quad (3)$$

这里, z_i^p 为 μ_i 相对应规则中的 z^p .可以通过数学推导证明 z' 的值能够正确反映系统当前所处的状态.证明推导从略.

本法是建立在精确模糊建模基础之上的,但是本法对模型的适配性并没有非常严格的要求,只要

所建立的模糊模型能够正确表示出系统的不同状态模型即可.而非线性系统的模糊建模是能够满足这一要求的^[4].一定程度的建模误差可以接受,对诊断结果的正确性并没有显著影响,这是因为该法并不是建立在传统残差分析基础上,因而对模型误差并不敏感;另外,依据模糊聚类的性质,它对数据的噪声污染应有较好的滤波抑制作用,且并不需要知道噪声的统计特性.这也是我们选用模糊聚类算法的重要原因之一.

3.2 系统故障诊断的步骤(Steps of diagnosis)

离线部分:

1) 给定系统的各状态模式下的输入、输出样本集,采用模糊聚类算法分别对系统各状态模型下样本进行训练;

2) 将训练好的各状态模式下的聚类中心集,转化为相应的模糊规则,并指定状态标志 z^p , 将所有的模糊规则合成整体规则基.

在线部分:

1) 实测系统的输入、输出值,计算它们对规则集中每条规则的隶属度;

2) 计算相应的 z' 值;

3) 通过监测 z' 曲线,判断系统所处状态,完成系统故障检测与定位.

4 仿真(Simulation)

为演示该故障检测和定位方法的性能,以某二级水箱系统的故障检测与分离进行仿真,该系统由连通道互连的两个单水箱所组成,是典型的多变量非线性系统.相应的数学模型为:

$$\begin{aligned} A \cdot \frac{dh_1(t)}{dt} &= Q_1(t) - C(h_1(t) - h_2(t)) \cdot \\ &\quad \sqrt{2g | h_1(t) - h_2(t) |} + Q_3(t), \\ A \cdot \frac{dh_2(t)}{dt} &= Q_2(t) - C \operatorname{sgn}(h_1(t) - h_2(t)) \cdot \\ &\quad \sqrt{2g | h_1(t) - h_2(t) |} + Q_2(t), \end{aligned}$$

其中, A, C 为常系数; $Q_1(t), Q_2(t)$ 为水箱的进水量; $h_1(t), h_2(t)$ 分别为两个单水箱的液位高度; $Q_3, Q_2(t)$ 为因渗漏而引起的额外流量,系统正常对应为零值.仿真中,针对水箱常见的三种故障模式经过离线训练对系统的四种状态模式进行模糊建模分别得到 45 条、51 条、49 条、53 条模糊规则所构成的模糊模型.我们指定在系统处于状态 1(正常状态)时 $z^p = 0$; 在系统处于状态 2(故障 1 状态,单水箱 1 发生渗漏故障)时 $z^p = 1$; 在系统处于状态 3(故障 2

状态,单水箱2发生渗漏故障)时 $z^p = 2$;在系统处于状态4(故障3状态,单水箱间连通管道发生阻塞故障)时 $z^p = 3$.并假设系统在第16,53,90采样时刻分别发生故障1、故障2、故障3,在第30,68采样时刻又恢复到正常状态.仿真结果如图1所示.从图中可以看出通过对 Z 曲线进行监测,可以满足对系统实时诊断的要求.




图1 水箱系统故障诊断 Z 值监测曲线

Fig. 1 The supervision curve of Z in a liquid level system

为了检验本法在系统输入、输出数据受到噪声污染情况下的效果,我们引入幅值为0.2的量测白噪声,仿真结果如图2所示.从图中可以看出,由于采用了聚类算法对噪声污染确有较好的抑制效果.




图2 系统数据含噪声污染的 Z 值曲线

Fig. 2 The supervision curve of Z under system noise




图3 存在系统模型误差 Z 值曲线

Fig. 3 The supervision curve of Z under model error

减少规则数目,将会导致相应的模糊模型建模误差的增加.为了检验本法在有模型误差时的效果,人为地从已经建好的规则基中抽掉若干模糊规则,

进行仿真,仿真结果如图3所示.从图中可以看出,虽然存在模型误差,但诊断效果也基本较好.

5 结论(Conclusion)

本文针对非线性系统,在故障模糊模型的基础上,提出一种利用模糊聚类方法进行故障检测与定位的新方法.此方法的核心是系统故障模糊模型的建立.它在线检测算法简单,故障检测与定位同时完成,能够满足系统实时诊断的要求;它的适用范围较广,对可重复性故障,理论上均可达到较好的诊断效果;从仿真结果可以看出,在数据有噪声污染时,它能较好地抑制噪声,对系统故障作出准确的诊断;它对模型误差具有一定的容忍能力,在有一定模型误差的情况下,诊断效果也较好.

参考文献(References)

- [1] Zhou Donghua and Sun Youxian. Failure Detection and Diagnosis Technique for Control Systems [M]. Beijing: Tsinghua University Press, 1994 (in Chinese)
- [2] Zhou Donghua, Sun Youxian, Xi Yugeng and Zhang Zhongjun. Real-time detection and diagnosis of parameter bias faults for nonlinear systems [J]. Acta Automatic Sinica, 1993, 19(2): 184-189 (in Chinese)
- [3] Stephen L C. A cluster estimation method with extension to fuzzy model identification [A]. Proceedings of the 3rd IEEE Conference on Fuzzy Systems [C]. Orlando, 1994, 1240-1245
- [4] Zhang Pingan and Li Renhou. Fuzzy identification based on fuzzy cluster and Kalman filter [J]. Control Theory and Applications, 1996, 13(5): 639-643 (in Chinese)

本文作者简介

刘志言 1936年生.现为哈尔滨工业大学控制科学与控制工程系教授,博士生导师.已发表论文50余篇.主要研究领域为工业过程控制,故障诊断,检测技术与信号处理.

沈毅 1965年生.1995年于哈尔滨工业大学获博士学位.现为哈尔滨工业大学控制科学与控制工程系教授,博士生导师,国家863专题专家.已发表论文80余篇.主要研究领域为飞行器制导与控制,数字信号处理与传感器理论,故障诊断与容错技术.

刘宜平 1974年生.2000年获哈尔滨工业大学控制科学与控制工程系博士学位.现在华为公司工作.研究领域为信号处理,模糊理论,控制系统的故障诊断.