

一种基于小波网络的故障检测方法

吕柏权 李天铎

(清华大学热能工程系·北京, 100084)

摘要: 本文针对突变故障给出了一种基于小波网络的检测方法。故障检测方法一般分为两种: 一种是基于信号分析; 而另一种是基于过程的数学模型。本文给出了一种基于小波网络的故障检测方法。它具有信号分析, 数学模型两者优点, 从而更准确地检测出突变故障。

关键词: 诊断故障; 小波网络; 数学模型

1 引言

近年来, 小波分析以及可以逼近任意函数的神经网络和小波网络的出现给故障诊断技术带来了新方法。基于信号分析的故障诊断技术由于小波分析具有变时域—频域窗而更受关注, 它将代替传统的 FFT 分析广泛地应用于机械及医学等领域, 而基于工业过程机理来诊断故障方法即数学模型方法是非常有前途的, 但当工业过程比较复杂时一般很难得到精确的数学模型, 通常通过辨识方法得到其近似数学模型。神经网络虽然从理论上解决了非线性辨识问题, 但由于神经网络在线学习比较慢, 对网络的输入比较敏感, 从而影响其泛化能力, 尽管出现了各种改进学习方法, 但能应用于实际中去还有一定距离。小波网络则学习比较快, 对网络的输入不太敏感, 可望能应用于实际中去。本文就是利用小波网络来辨识非线性对象, 然后, 利用信号在小波变换的多尺度刻划下表现行为不同的特点来检测出突变的故障信号。通过仿真表明此方法是可行的。

2 诊断算法

小波网络是一种连续的非线性映射。当非线性对象没有突变时小波网络的输出与辨识非线性对象的输出的差比较小; 当非线性对象有突变时由于小波网络是连续的映射, 故小波网络的输出与辨识非线性对象的输出的差比较大, 因为非线性对象的参数变化了, 则必须通过一段学习来辨识新的非线性对象的参数。据此可以利用方差检测出故障, 但当非线性系统的输出有噪声, 且非线性系统的参数的突变较小时, 方差检测此参数变化不明显, 为此本文利用信号在小波变换的多尺度刻划下表现行为不同的特点来检测。

2.1 非线性系统的对象辨识

定义一些运算:

$$\begin{aligned}\langle f, g \rangle &= \int_R f(x) \overline{g(x)} dx, \\ \|f\| &= \langle f, f \rangle^{1/2}, \quad \Psi^{(a,b)}(x) = \frac{1}{\sqrt{a}} \Psi\left(\frac{x-b}{a}\right), \\ T(a,b) &= \langle f, \Psi^{(a,b)} \rangle.\end{aligned}$$

Ψ 为母小波且

$$C_\Psi = \int_{-\infty}^{\infty} |\Psi(\omega)|^2 \omega^{-1} d\omega < \infty. \quad (1)$$

定义 函数 $f(x) \in L^2(\mathbb{R})$ 空间的连续小波变换 $T(a, b) = \langle f, \Psi^{(a, b)} \rangle$.

其反变换为

$$f(x) = \frac{1}{C_\Psi} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} T(a, b) \Psi^{(a, b)}(x) \frac{da db}{a^2}.$$

当 $a = 2^j, b = kb_0 2^j (j, k \in \mathbb{Z})$ 时反变换离散为:

$$f(x) = \sum_{j, k \in \mathbb{Z}} \langle f, \Psi_{j, k} \rangle \Psi_{j, k}(x) = \sum_{j, k \in \mathbb{Z}} \langle f, \Psi^{j, k} \rangle \Psi_{j, k}(x), \quad (2)$$

$\Psi_{j, k}$ 是 $\Psi^{j, k}$ 的共轭基.

$$\Psi^{j, k}(x) = \Psi^{(2^j, kb_0 2^j)}(x) = 2^{-j/2} \Psi(2^{-j}x - kb_0).$$

为了能再现 $f(x)$ 还必须满足如下条件:

$$A \|f\|^2 \leq \sum_{j, k \in \mathbb{Z}} |\langle f, \Psi_{j, k} \rangle|^2 \leq B \|f\|^2, \quad (3)$$

A, B 为常数且满足 $0 \leq A \leq B < \infty$.

应用时(1)式用下式近似:

$$\hat{f}(x) = \sum_{k=1}^n c_k \Psi(a_k^T X - b_k), \quad (4)$$

其中 a_k^T 为行向量, X 为列向量, 因(4)式可以逼近任意连续函数, 即用可以辨识任意连续非线性对象. 利用学习方法可以得到 c_k, a_k^T, b_k .

2.2 多尺度分析的突变信号检测

信号 $f(x)$ 在任意尺度 s 和位置 x 的小波变换定义为:

$$W_s f(x) = f^* \Psi_s(x) = \int_R f(t) \Psi_s(x-t) dt,$$

其中 $\Psi_s(x) = \frac{1}{s} \Psi\left(\frac{x}{s}\right), s \neq 0$, 称作小波, 且 $\int_{-\infty}^{+\infty} \Psi(x) dx = 0$.

可选取小波 $\Psi(x)$ 为函数 $\theta(x)$ 的一阶导数:

$$\Psi(x) = \frac{d\theta(x)}{dx}, \quad \theta(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left(-\frac{x^2}{2\sigma^2}\right), \quad \sigma = 1. \quad (5)$$

$\theta(x)$ 称作平滑函数.

由(5)式得:

$$W_s f(x) = f^* \left(s \frac{d\theta_s}{dx} \right)(x) = s \frac{d}{dx} (f^* \theta_s)(x), \quad \theta_s(x) = \frac{1}{s} \theta\left(\frac{x}{s}\right).$$

因为 $f^* \theta_s(x)$ 可看成 $f(x)$ 用 $\theta(x)$ 函数按尺度 s 进行光滑化的结果. 当 s 很小时, 用 $\theta_s(x)$ 对 $f(x)$ 的突变部分的位置与形态影响不大. 当 s 较大时则此光滑过程会将 $f(x)$ 的一些细小的突变消去而剩下大尺寸的突变. $W_s f(x)$ 是在尺度 s 下光滑后函数 $f(x)$ 的一阶导数. 由此可见, 与 $W_s f(x)$ 的零点或极值点相对应的是 $f^* \theta_s(x)$ 的极值点或拐点. 又因为噪声和突变信号在不同的尺度下所表现的行为不同, 从而将此信号特征从噪声中分离出来^[1].

3 仿真结果

本文以 $y'' = \sin(y') - (1 + 1.5y')^* y^2 + (1 + 0.2y)u$ 为例用四阶龙格库塔法进行仿真. u 为输入, y 为输出, 实际输出 $y = y + \alpha, \alpha$ 为 $[-0.01, 0.01]$ 的均匀分布, y' 为时间的导数. 仿真步长为 $h = 0.02$ s. 每 5 倍 h 作为一个学习点, 共 200 点, 每 200 点作为一个学习周期重新开始学习. $u = 1.0$. 其权初值为 $(-0.01, 0.01)$ 的均匀分布. $X = \{y(n-1), y(n-2), u(n)\}$ 为

网络的输入,中间结点数选为 200,用激励函数 $\Psi(x) = \frac{1}{\sqrt{2\pi}}(1-x^2)e^{-x^2/2}$ 进行参数辨识的,

很易验证 $\Psi(x)$ 满足(3)式. 误差函数为 $E_1 = \sum_{i=1}^{200} |(y(i) - \hat{y}(i))|^2$. 当学习 801 个周期(此时 $E_1 = 0.216986$) 的第 110 个学习点(学习速率 $\eta = 0.07$) 非线性对象的系数 0.2 突变为 0.6 时, 用尺度 $s = 3$ 的小波检测参数突变信号, 其结果如图 1 所示.

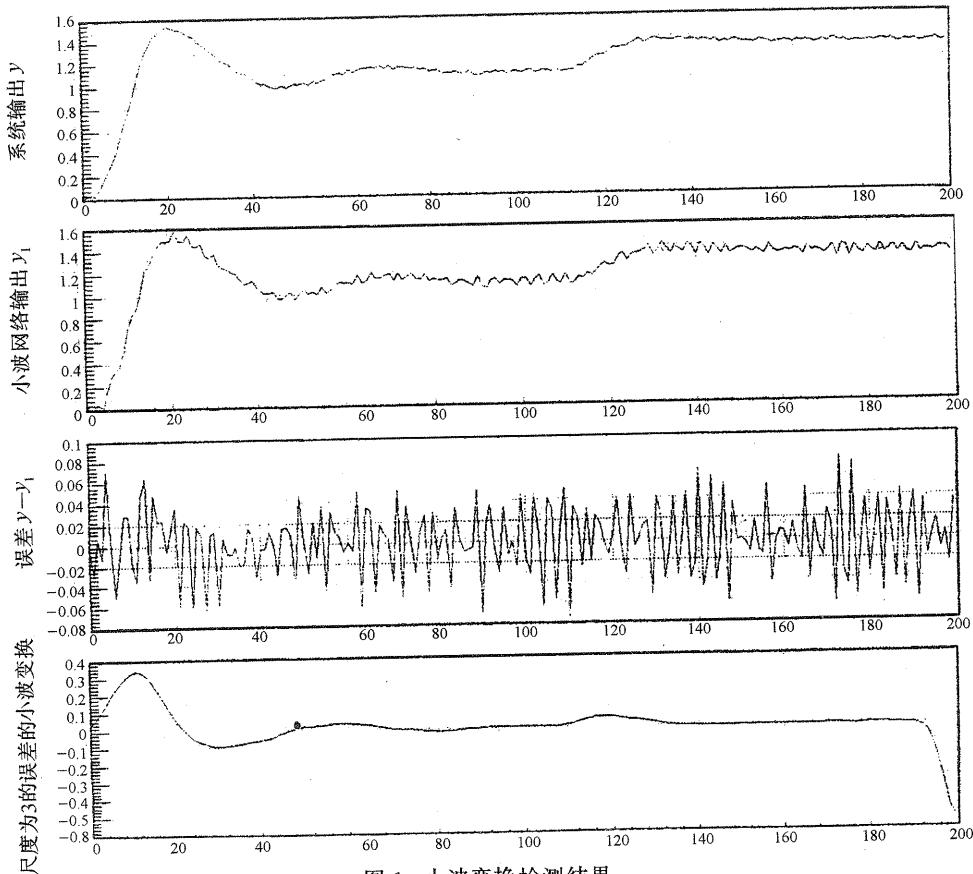


图 1 小波变换检测结果

从图 1 可以看出 $0.1 \times 80 = 8$ 秒过渡过程基本完成, 小波变换曲线在第 110 个采样点以后有明显的突变, 可见效果明显(在第 190~200 采样点小波变换曲线向下弯, 是因为数据取为 200 点, 200 以后按零处理而产生的. 只要每处理一次数据时叠加一些上次数据即可). 误差函数非常杂乱, 用方差方法很难提取出故障信息, 因为在故障信息比较弱时, 方差方法的判别标准即阀值比较难确定. 若取大则漏掉故障信息; 若取小则误判故障. 另外用方差方法也不能给出故障发生的比较准确时间. 而用小波变换则方便地得到故障信息及故障发生时间(横轴表示采样点, 换算成时间秒为 $0.1 \times$ 采样数).

4 结 论

本文针对非线性对象, 给出了一种基于小波网络的故障检测方法. 其特点它具有信号分析, 数学模型两者优点. 从而有效地检测出故障信息. 尚存在的问题有: 小波网络虽然相对于神经网络对输入扰动不敏感, 但当系统参数变化与输入扰动同时发生时完全区分此还有待于进一步研究. 因为输入一般是可测的.

参 考 文 献

- 1 Stephane Mallat and Wen Liang Huang. Singularity detection and processing with wavelets. IEEE Trans. Information Theory, 1992, 38(2): 617—643
- 2 周东华,席裕庚,张钟俊.一类非线性系统参数突变故障的检测与诊断.控制理论与应用,1991,8(3):302—307
- 3 秦前清,杨宗凯.实用小波分析.西安:西安电子科技大学出版社,1994
- 4 倪先锋,陈宗基,周绥平.基于神经网络的非线性学习控制研究自动化学报,1993,19(3):307—314
- 5 Zhang Qinghua and Albert Beveniste. Wavelet networks. IEEE Trans. Neural Networks, 1992, 3(6):889—898

An Approach of Fault Detection Based on Wavelet Network

LU Baiquan and LI Tianduo

(Department of Thermal Engineering, Tsinghua University • Beijing, 100084, PRC)

Abstract: This paper presents a detection approach based on wavelet network for fault of parameter jump. Generally, there are two kinds of fault detection approaches. One is based on signal processing. The other is based on the mathematical model of process, the approach presented here is a combination of the two approaches. It has both the advantages of signal processing and mathematical model, and has increased the precision of fault detection.

Key words: fault diagnosis; wavelet network; mathematical model

本文作者简介

吕柏权 1963年生。1986年,1988年,1996年分别于齐齐哈尔轻工业学院、哈尔滨工业大学、清华大学获学士、硕士、博士学位。现在日本九州大学大学院电气电子系统情报科学研究院留学。研究兴趣:图像处理,自适应控制,系统辨识,小波分析,神经网络,分形等。

李天铎 1928年生。1950年毕业清华大学机械系,一直在清华大学从事科研教育工作,研究方向为热能工程,热工自动化,电站仿真。发表论文数十篇,1984年获原水电部一等奖,1985年获国家科技进步一等奖。