

电力设备基于小波神经网络故障检测方法的仿真研究^{**}

余 勇 万德钧 程启明

(东南大学仪器科学与工程系,江苏 南京 210096 盐城工学院计算机系,江苏 盐城 224003)

摘 要 提出了一种基于小波神经网络非线性观测器的故障检测方法。它是将规范正交的小波函数作为基函数网络中的基函数,得到小波神经网络。通过小波的去噪和神经网络的自学习功能,获取系统输入输出的非线性动力学特性,进而实时计算出残差并进行逻辑判决,可提高故障检测的速度和准确率。对同步交流电机的结构损伤故障进行了仿真,结果表明了该方法的有效性。

关键词 小波神经网络; 故障检测; 非线性观测器

分类号 TP273 **文献标识码** A **文章编号** 1008-5092(2000)02-0005-05

为了保持电力系统的可靠、稳定、安全运行,电力设备的故障检测就显得十分重要。用于电力设备故障检测的方法较多,如模糊辨识方法、遗传算法等,但在某种程度上,这些方法都依赖于工程技术人员分析经验,同时电力设备的故障中存在着大量不确定因素。因此,有必要寻求一种新的有效的办法来检测系统的故障。

近年来,神经网络理论引起了故障检测及应用学术界的关注。这是因为神经网络具有固有的学习能力、泛化能力、自适应能力及非线性映射能力。因此,可以利用神经网络法来检测电力设备的故障^[1,2]。小波分析是一种全新的时-频两维分析技术,其对高频突变信号和低频缓变信号的分析有着独特的优点,它具有带通滤波、消除噪声等功能。

小波神经网络是小波分析和神经网络相结合的一种网络,其优点是:(1)小波神经元及整个网络结构的确定有可靠的理论依据,可避免BP网络等结构设计上的盲目性;(2)网络权系数线性分布和学习目标函数的凸性,使网络的训练过程从根本上避免了局部最优等非线性优化问题;(3)网络的学习比较快,对网络的输入不太敏感,这就有可能应用于实际中去。本文提出了基于小波神经

网络的非线性观测器的故障检测方法,通过计算机仿真证实了该方法的有效性。

1 小波神经网络

为简便起见,只考虑单输入(一维)情形。

设 $f(t)$ 是 $L^2 \in R$ 上任意一个函数,神经网络的函数学习问题就是对于给定的训练数据集 $T_N = \{t_i, f(t_i)\}_{i=1}^N$, 寻求 $f(t)$ 的一个估计,它能够充分逼近函数 $f(t)$ 。从小波理论可知,对于足够大的 M , 可以任意精度逼近函数 $f(\cdot)$:

$$f(t) \approx \sum_k \langle f, \varphi_{M,k} \rangle \varphi_{M,k}(t) \quad (1)$$

式中 $\langle \cdot, \cdot \rangle$ 表示内积; $\varphi_{M,k}(t)$ 是通过尺度函数 $\varphi(t)$ (父函数) 伸缩和平移而得到的, 即 $\varphi_{M,k}(t) = 2^{\frac{M}{2}} \varphi(2^M t - k)$ 。尺度函数 $\varphi(t)$ 与小波 $\psi(t)$ (母函数) 的关系为:

$$\varphi(t) = \sqrt{2} \sum_k h_k \varphi(2t - k) \quad (2)$$

$$\psi(t) = \sqrt{2} \sum_k g_k \varphi(2t - k) \quad (3)$$

式中, $\{h_k\}$ 和 $\{g_k\}$ 是一对离散正交镜像滤波器(低通和高通), 它们的关系为:

$$g_k = (-1)^{k-1} h_{-(k-1)} \quad (4)$$

对于小波神经网络, 可用如图 1 所示的 3 层

* 收稿日期:1999-05-05

** 本课题得到国家教育部博士点基金资助(编号 97J40.5.2)

第一作者简介:余 勇(1971-),男,四川省广安县人,博士研究生。

神经网络来实现^[3,4]。特别地,输入层为直通节点,即对输入 t 输出也为 t ;隐层包括可数个节点,以 k 来标识, k 可为任意整数,隐层节点的权值和非线性函数分别为 2^M 和 $\varphi(\cdot)$,隐层节点的阈值互不相同,第 k 个节点的阈值为 k ;输出层是线性节点,其阈值为 0。对于理想情况,节点的权值就是式(1)的系数。在实际应用中,函数 $f(t)$ 只包含有限支撑,因此隐层可以只包含有限个数的节点,这对 $\varphi(t)$ 为紧支函数时也成立,如 Daubechies 小波^[5];当 $\varphi(t)$ 非紧支但迅速减少时,我们也可近似认为其成立,如 Lemarie-Meyer 尺度函数^[6]。因此,不失一般性,假设隐节点数为 $2K + 1$,其范围为 $(-k \sim k)$ 。

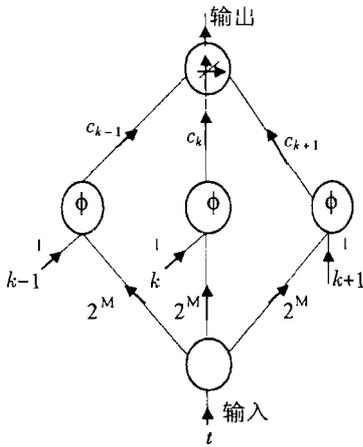


图 1 三层小波神经网络结构图
Fig.1 The frame figure of three-layered wavelet neural networks

对于给定的 M 和 K ,以上所述的小波神经网络实现了函数 $g(t)$:

$$g(t) = \sum_{k=-K}^K c_k \varphi_{M,k}(t) \quad (5)$$

通过适当选取权值 c_k ,上式可作为函数 $f(t)$ 的逼近。当训练数据集 T_N 已知时,权值 c_k 可通过最小化均方(训练)误差 $e_N(f, g)$ 来得到,即

$$(\hat{c}_{-K}, \dots, \hat{c}_K) = \arg \min_{(c_{-K}, \dots, c_K)} e_N(f, g) \quad (6)$$

式中 $e_N(f, g) = \frac{1}{N} \sum_{i=1}^N [f(t_i) - g(t_i)]^2 \quad (7)$

$e_N(f, g)$ 中的下标 N 强调与训练数据的依赖性。式(6)可由下式求得:

$$\frac{\partial e_N(f, g)}{\partial c_k} = 0 \quad (8)$$

由于尺度函数是正交的,只要取足够大的 N ,通常式(8)都有唯一解。然而,当 K 很大时,直接求解它需要求一个 $(2K + 1) \times (2K - 1)$ 维矩阵的逆,

计算量很大。为了减少运算量,一种方法是采用迭代梯度下降法:

$$\hat{c}_k^{(p)} = \hat{c}_k^{(p-1)} - \lambda \frac{\partial e_N(f, g)}{\partial c_k} |_{c_k = \hat{c}_k^{(p-1)}} \quad (9)$$

式中 λ 为训练步长。若考虑到尺度函数的局部性质,式(9)的计算量还可减少。这是因为:式(9)的偏导包含对 $\varphi_{M,k}(t_i)$ 项求和,当 $\varphi(t)$ 有紧支而且 t_i 在 $[-\frac{1}{2}, +\frac{1}{2}]$ 上近似均匀分布时,对一个给定的 k ,这些项大都为零而不必求和。

另外一种确定小波神经网络权值的简单方法是,令

$$\hat{c}_k = \frac{1}{N} \sum_{i=1}^N f(t_i) \varphi_{M,k}(t_i) \quad (10)$$

上式是对 $\langle f(t), \varphi_{M,k}(t) \rangle$ 很好的近似。如果训练数据是均匀的,例如 t_i 是均匀分布于 $[-\frac{1}{2}, +\frac{1}{2}]$ 上的独立同分布随机变量。一般地,对一特定的训练样本集合,用式(10)产生的均方误差比用式(6)产生的均方误差要大。

在实际应用小波神经网络时,要注意以下两个问题:

第一个实际问题是怎样确定隐层节点的个数。对于一个给定的整数 M , $\varphi_{M,k}(t)$ 的中心大约有 $2^M + 1$ 个在 $[-\frac{1}{2}, +\frac{1}{2}]$ 内。这是因为:尺度为 2^M 的尺度函数是由 $\varphi(2^M t)$ 平移而得到的,平移量为 2^{-M} 的整数倍。由于小波神经网络所用的尺度函数具有紧支撑或快速衰减的性质,所有的实际目的是,需要覆盖 $[-\frac{1}{2}, +\frac{1}{2}]$ 或逼近任一支撑为 $[-\frac{1}{2}, +\frac{1}{2}]$ 的 L^2 函数尺度为 2^M 的尺度函数的个数不超过 $2^M + p$,其中 $p \geq 1$ 是一个小的整数。通常 p 选为大于 1 是为了具有一定的冗余性,如图 2 所示。

为了确定恰当的 M ,可以使用下面的简单方案:

- (1) 从一个小的 M 开始且用上面的上限 $2^M + p$ 来确定隐层节点的个数。
- (2) 用式(6)或式(10)来获得输出层的权值,所得到的小波神经网络可记为 $\hat{f}_{M,N}$,下标 M , N 表示其依赖于尺度和训练数据。

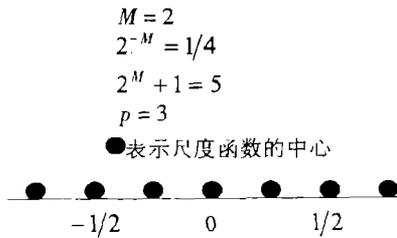


图2 尺度为 2^M 的尺度函数的位置解释

Fig.2 The place explanation of scale function with 2^M scale

(3) 计算均方误差 $e_N(f, \hat{f}_{M,N})$ 。

(4) 如果均方误差小于某一个阈值,就停止。否则,用 $M + 1$ 代替 M 并返回到第一步。

第二个实际问题是训练数据通常在所考虑函数的支撑集 $([-\frac{1}{2}, +\frac{1}{2}])$ 上不是均匀的。而且它们是以簇的形式出现的,对于多输入(高维)情形时尤其如此。在这种情形下,通过尺度函数来覆盖整个 $[-\frac{1}{2}, +\frac{1}{2}]$ 是十分浪费计算资源的。

一种较好的方法是在 $[-\frac{1}{2}, +\frac{1}{2}]$ 上识别出包含充分多训练数据的非空区域,这些区域中的训练数据可认为是近似均匀分布的,并且对每个区域构造一个子小波神经网络,所考虑的函数可近似认为是由这些小波网络合成的。

以上的结果可以直接推广到多维的情形,从而形成了多输入-多输出小波神经网络。

2 基于小波神经网络非线性观测器的故障检测

故障检测与隔离由残差产生和残差判决两部分组成。系统在无故障时,残差仅由未建模噪声和扰动引起,且其幅值接近于零;当故障发生时,输出残差按一定规律偏离零,而且其变化的性质取决于故障类型,如突发性故障,残差呈阶跃变化,根据其变化特征和相应的决策规则以及函数可进行故障分类与定位。

由于电力系统是一个复杂的非线性系统,通常的用于线性系统的故障检测方法不适用于电力系统。为此,笔者提出了一种基于小波神经网络的非线性观测器的故障检测方法。小波神经网络非线性观测器的故障检测的结构如图3所示。小波神经网络观测器类似于传统的状态估计器,其实质是被用来建立非线性动态系统的输入-输出

模型。经过充分训练的小波神经网络观测器可以给出系统正常情况下输出的估计值,然后利用估计输出与实际输出之差作为残差来检测故障,当残差的幅值超过预定门限值时,则可判定系统发生故障。

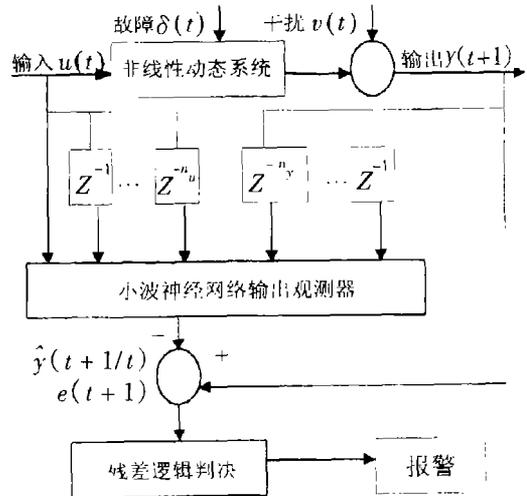


图3 小波神经网络的故障检测原理图

Fig.3 The principle figure of fault detection of wavelet neural networks

考虑如下非线性动态系统:

$$y(t) = f(y(t-1), \dots, y(t-n_y), \dots, u(t-1), \dots, u(t-n_u)) + \delta(t) + v(t) \tag{11}$$

式中 $y(t) \in R^m$ 和 $u(t) \in R^r$ 分别为系统的输出和输入; $\delta(t) \in R^m$ 和 $v(t) \in R^r$ 分别为故障向量和噪声向量; n_y, n_u 分别为系统输出和输入的延迟; $f(\cdot)$ 为非线性函数。构造非线性观测器的实质就是利用小波神经网络来逼近系统的动力学特性 $f(\cdot)$ 。利用神经网络的自学习功能和选取不同的小波变换尺度来调整权值,使得观测器的估计输出 $\hat{y}(t+1/t)$ 与系统实际输出 $y(t+1)$ 之间的误差极小化,这样可获得系统的非线性函数。

基于小波神经网络的观测器可在线给出 t 时刻系统输出的一步超前预报值 $\hat{y}(t+1/t)$, 定义残差: $e(t+1) = y(t+1) - \hat{y}(t+1/t)$, 且 $e(t+1) = [e_1(t+1), \dots, e_m(t+1)]^T$ 。根据小波神经网络输出观测器的预报残差序列, 确定如下的残差评估准则:

$$H_1: |e_i(t+1)| > \epsilon \quad H_0: |e_i(t+1)| < \epsilon \tag{12}$$

$i = 1, 2, \dots, m$

式中, H_0 表示系统无故障, H_1 表示系统发生故障, ϵ 为预先设定的故障检测阈值。

一般来说,非线性系统越复杂,小波神经网络

的隐层就需要更多的神经元。由于训练样本很难覆盖系统运行的所有工况,因此实际应用中,常常是将网络的离线学习和在线学习结合起来,首先利用非线性系统的历史运行信息离线学习,同时考虑到样本空间的局限性和系统参数的时变性,实时采集系统运行时的输入输出测量值作为训练数据,以便在线更新权值,且学习在动态系统运行过程中进行。这种在线学习方式既能节约计算机内存、提高运算速度,且能提高对系统参数变化的适应性。

$$\begin{bmatrix} \dot{x}_1 \\ \dot{x}_2 \\ \dot{x}_3 \end{bmatrix} = \begin{bmatrix} x_2 \\ -0.34x_2 - 12.49x_3 \sin x_1 + 24.98 \sin(2x_1) + 37.25u_1 \\ -0.43x_3 + 18 \cos x_1 + u_2 \end{bmatrix},$$

$$\begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \end{bmatrix} \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix} + \begin{bmatrix} \delta_1 \\ \delta_2 \end{bmatrix} \begin{bmatrix} v_1 \\ v_2 \end{bmatrix},$$

式中 u_1, u_2 为输入, y_1, y_2 为输出, $\delta = [\delta_1, \delta_2]^T$ 为故障向量, $v = [v_1, v_2]^T$ 为白噪声干扰向量。小波神经网络观测器的结构选为 4-21-2, 输入节点为 4, 对应输入向量为 $X = [y_1(t-1), y_2(t-1), u_1(t-1), u_2(t-1)]^T$; 隐层节点为 21, 是根据第二部分隐层节点的确定程序来选定的; 输出 2 个节点分别对应 $[y_1(t), y_2(t)]^T$; 小波基函数选为:

$$\varphi(X) = \cos(1.75X) \exp\left(-\frac{\|X\|^2}{2}\right), \text{ 其中, } \|X\|^2 = X^T X.$$

在本文中,小波神经网络的权值由式(6)训练得到。为了加快网络的收敛速度,首先对训练样本作了规范化,并且采用了变步长技术,得到了较好的效果。

在 $t = 150$ 时设置系统发生突发性结构故障,使系统的结构参数变化 20%, 采样时间为 0.05 s, 启动小波神经网络观测器进行输出预报并计算输出残差,其响应曲线如图 4 所示。从图中看出第 1 个输出量的残差 $e_1(t)$ 的幅值在 $t = 158$ 时超过门限($\epsilon = 0.1$), 而第 2 个输出量的残差 $e_2(t)$ 变化

在实际应用中,要注意小波神经网络训练数据量的选择。一方面,神经网络的训练需要较大的数据量,这样训练出的权值才是较优的;另一方面,若数据量太大,小波变换的时间就较长,故障检测的实时性就较差。

3 计算机仿真结果

考虑如下非线性同步交流电机的动态数学模型:

速度快,其幅值在 $t = 152$ 时就超过门限而发出故障报警。

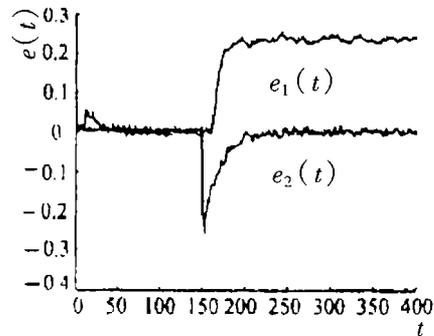


图 4 残差 $e(t)$ 的响应曲线
Fig.4 The response curve of residual error $e(t)$

4 结束语

本文提出了一种基于小波神经网络非线性观测器的故障检测方法。该法充分利用了小波和神经网络各自的优点,即小波变换或分解所表现出良好的时频局部化特性,以及多尺度、去噪等功能和神经网络具有的自学习、自适应、非线性映射等功能。计算机仿真结果表明了该法的有效性。

参 考 文 献

- 1 Ding X, Liu Y. Predicting Power Transformer Resonant Frequencies Using ANN[J]. NAPS, 1993, 18(2): 15 ~ 20.
- 2 Bhattacharyya S K, Smith R E, Haakew T A. A Neural Network Approach to Transformer Fault Diagnosis Using Dissolved Gas Analysis Data[J]. NAPS, 1993, 18(2): 121 ~ 132.
- 3 Jun Zhang G G, Walter Y M and Wan N W L. Wavelet Neural Networks for Function Learning[J]. IEEE Trans. On Signal Processing, 1995, 43(6): 1485 ~ 1497.

- 4 Qinghua Zhang. Using Wavelet Network in Nonparametric Estimation[J]. IEEE Trans. On Neural Network, 1997, 8(2): 227 ~ 236.
- 5 Mallat G A. Theory for Multiresolution Signal Decomposition: The Wavelet Representation[J]. IEEE Trans. On Pattern Analysis and Machine Intelligence, 1989, 11(7): 674 ~ 693.
- 6 Daubechies I. Ten Lectures on Wavelets[M]. Philadelphia, PA: SIAM Press, 1992.

Simulation Research on a Fault Detection Method Using Wavelet Neural Networks for Power Equipment

Yu Yong¹⁾ Wan Dejun¹⁾ Cheng Qiming²⁾

(1) Southeast University, Jiangsu Nanjing 210096, PRC
(2) Department of Computers Engineering of Yancheng
Institute of Technology, Jiangsu Yancheng, 224003, PRC

Abstract In this paper, a method of fault detection based on nonlinear observer using wavelet neural networks is presented. In the method, wavelet is used as the basic of the basis neural networks, which is called wavelet neural networks. By the denoising function of wavelet and the learning itself function of neural network, the input and output nonlinear dynamic characteristic of system is obtained. The output prediction error, generated from the real output and wavelet neural networks estimated output, is used as a residual error to execute logical judge. and this approach can improve the speed and accuracy rate of fault detection. Simulation for structural damage faults of nonlinear synchronous motors show that the fault detection approach is effective.

Keywords wavelet neural networks; fault detection; nonlinear observe