

基于小波神经网络的蒸汽发生器动态过程辨识

周刚, 张大发, 彭威

(海军工程大学 核能科学与工程系, 湖北 武汉 430033)

摘要: 在核动力蒸汽发生器(SG)运行过程中, 其逆动力学效应使其动态特性难以辨识。为提高蒸汽发生器动态特性辨识的效果, 提出了基于小波神经网络的蒸汽发生器动态过程辨识的新方法。辨识模型采用串-并联型辨识结构, 网络训练采用 Levenberg-Marquardt 学习算法(LMBP)。对蒸汽发生器典型运行工况的辨识结果表明, 所提出的方法能够正确地辨识蒸汽发生器的动态特性且具有较高的辨识精度。

关键词: 核动力; 蒸汽发生器; 小波神经网络; 动态过程; 辨识

中图分类号: TL362 文献标识码: A 文章编号: 1000-6931(2006)S0-0001-04

Dynamic Process Identification for Steam Generator Based on Wavelet Neural Network

ZHOU Gang, ZHANG Da-fa, PENG Wei

(Department of Nuclear Energy Science and Engineering,
Naval University of Engineering, Wuhan 430033, China)

Abstract: In the operation of nuclear steam generator (SG), the reverse thermal-dynamic effects make its dynamics characteristic difficult to identify. In order to improve the effect of identification, a new method based on wavelet neural network (WNN) was proposed in this paper. The identification model employs series-parallel model and the train algorithm for the WNN adopts the back propagation algorithm of Levenberg-Marquardt type (LMBP). The identification on steam generator typical operation modes was implemented. The results show that employing WNN can identify steam generator dynamic process correctly and has adequate precision.

Key words: nuclear power; steam generator; wavelet neural network; dynamic process; identification

核动力蒸汽发生器(以下简称 SG)是压水堆核动力装置中把一回路冷却剂从反应堆堆芯带出的热量传递给二回路水的关键性设备。在

SG 运行过程中, 为对其进行有效的控制, 必须正确掌握 SG 的动态特性。由于 SG 是一个高度复杂的非线性、时变的非最小相位系统, 其运

行过程中的“收缩”与“膨胀”现象引起的逆动力学效应和低功率运行工况下测量误差等因素,使其动态特性难以辨识^[1]。以往对 SG 动态过程辨识一般采用传统的方法。但传统的辨识方法是建立在线性系统理论基础之上的。对于复杂非线性系统的辨识问题一直未能很好地解决。1992 年, A. G. Palos 等^[2] 采用递归神经网络对 SG 动态过程进行辨识,取得了优于传统辨识方法的效果。为进一步提高 SG 动态特性辨识效果,本文提出基于小波神经网络(WNN)的 SG 动态特性辨识方法,并对基于小波神经网络的辨识结构、算法进行研究。

1 基于 WNN 的 SG 动态辨识模型

在基于 WNN 的 SG 动态过程辨识中,为保证辨识结果的收敛性和稳定性,辨识模型采用串-并联型辨识结构(图 1)。在图 1 中, $u(k)$ 、 $y(k)$ 与 $v(k)$ 分别为被辨识系统 SG 输入、输出和干扰信号; $\hat{y}(k)$ 为小波神经网络辨识器 WNNI (Wavelet Neural Network Identifier) 的输出; TDL 为按拍延迟环节; $e(k)$ 为被辨识系统 SG 的输出与 WNNI 的输出之差。被辨识的参数为 SG 的水位 $y(k)$ 和压力 $p(k)$ 。

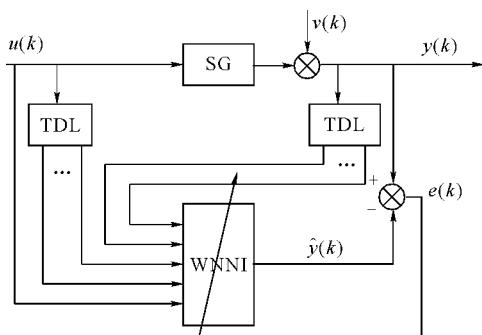


图 1 基于 WNN 的 SG 动态辨识结构框图

Fig. 1 Block diagram of dynamic identification based on WNN for SG

2 小波神经网络及其学习算法

2.1 用于辨识的小波神经网络结构

从目前小波神经网络研究的结果看,小波神经网络可分为 3 种类型,即分别为基于连续小波变换、基于正交小波变换以及基于小波框架的小波神经网络,它们具有不同的函数逼近

性能和特点^[3-8]。

H. H. Szu 等^[8] 提出了自适应小波网络。自适应小波网络由叠加小波(Superposition Wavelet)构成。其基本思想是通过选取小波基进行线性叠加来拟合函数 $f(t)$ 。由自适应小波的线性组合而构成的叠加小波,其本身也可以被看成一普通小波。在叠加小波中,其尺度会在信号处理过程中改变,即小波基本形状可以适应特定的应用,而不是仅对固定形状小波的参数。其小波网络结构如下:

$$f(t) = \sum_{m=1}^M w_m \psi\left(\frac{t-b_m}{a_m}\right) \quad (1)$$

式中: w_m 、 a_m 、 b_m 分别为权值、小波基的尺度参数和位移参数; m 为小波基的个数。

自适应小波网络结构中的尺寸参数和平移参数不是固定的,它没有小波系数作为权值,而是直接采用类似神经网络的权值 w_k 。除中间层与输出层之间的权值外,自适应小波结构中的尺寸参数和平移参数都可以通过相应的学习算法来调节。自适应小波网络与径向基网络非常类似,但与径向基网络相比有其明显的优点。径向基网络中径向基函数的中心参数和宽度参数的选择主要是靠经验,而自适应小波网络中的尺度参数和位移参数的选择则可以根据小波的时频局部化特性来设置。

本文在 SG 动态过程辨识中,神经网络辨识器采用 1 个 3 层自适应小波网络,其结构示于图 2。图 2 中, w_{ji} 为网络输入层节点 i 与隐含层节点 j 之间的连接权; w_{kj} 为网络隐含层节点 j 与输出层节点 k 之间的连接权。隐含层激励函数采用 Mexican Hat 小波函数,即 $f_1(x) = (1-x^2)e^{-\frac{x^2}{2}}$, 输出层激励函数采用线性函数 $f_2(x) = x$ 。

2.2 学习算法

设小波神经网络输入层节点数为 I , 隐层节点数为 J , 输出层节点数为 K , 网络样本数为 N , 网络的输入向量为 X_n , 输出向量为 Y_n 。 X_n 与 Y_n 分别表示为:

$$X_n = [x_{1n}, x_{2n}, \dots, x_{In}]^T \quad (2)$$

$$Y_n = [y_{1n}, y_{2n}, \dots, y_{Kn}]^T$$

输入第 n 个样本时的期望输出为:

$$yd_n = [yd_{1n}, yd_{2n}, \dots, yd_{Kn}]^T \quad (3)$$

网络输入层到隐层的连接权矩阵向量为 $W_{J \times I}^1$,

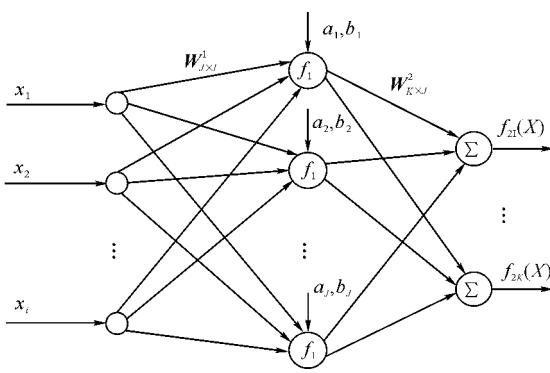


图 2 小波神经网络的结构

Fig. 2 Architecture of wavelet neural network

尺度因子向量为 $a_{j \times 1}^1$, 平移因子向量为 $b_{j \times 1}^1$, 隐层到输出层的连接权矩阵向量为 $W_{K \times j}^2$ 。

定义样本误差向量为:

$$\mathbf{e}_n = \mathbf{y}_d T \mathbf{W}_n - \mathbf{y}_n = [e_{1n}, e_{2n}, \dots, e_{Kn}]^T \quad (4)$$

目标函数定义为所有样本的总体平均平方误差, 即:

$$E = \sum_{n=1}^N E_n = \sum_{n=1}^N \mathbf{e}_n^T \mathbf{e}_n,$$

$$E_n = \frac{1}{2} \sum_{k=1}^K (\mathbf{y}_d_{kn} - \mathbf{y}_{kn})^2 \quad (5)$$

输入第 n 个样本时, 隐层第 j 个节点状态为:

$$\text{net}_{jn}^1 = \frac{\sum_{i=1}^I w_{ji}^1 x_{jn} - b_j}{a_j} \quad (6)$$

隐层第 j 个节点输出为

$$y_{jn}^h = f_1(\text{net}_{jn}^1) \quad (7)$$

输入第 n 个样本时的输出层第 k 个节点状态为:

$$\text{net}_{kn}^2 = \sum_{j=1}^J w_{kj}^2 y_{jn}^h \quad (8)$$

输出层第 k 个节点输出为:

$$y_{kn} = f_2(\text{net}_{kn}^2) = \text{net}_{kn}^2 \quad (9)$$

小波神经网络训练采用 Levenberg-Marquardt BP 算法^[9]。根据网络训练需要构造误差向量 \mathbf{e} 和参数向量 \mathbf{V} 如下:

$$\mathbf{e} = [e_{11}, e_{21}, \dots, e_{K1}, e_{12}, e_{22}, \dots, e_{K2}, \dots, e_{1N}, \dots, e_{KN}]^T \quad (10)$$

$$\mathbf{V} = [w_{11}^1, w_{21}^1, \dots, w_{j1}^1, w_{1i}^1, w_{2i}^1, \dots, w_{ji}^1, w_{11}^2, \dots, w_{21}^2, \dots, w_{j1}^2, b_1, b_2, \dots, b_j, a_1, a_2, \dots, a_j, w_{11}^2, w_{21}^2, \dots, w_{K1}^2, w_{1j}^2, w_{2j}^2, \dots, w_{kj}^2, w_{1J}^2, w_{2J}^2, \dots, w_{KJ}^2]^T \quad (11)$$

令参数向量增量为:

$$d\mathbf{V} = -(D^T \cdot D + \lambda \cdot H)^{-1} \cdot D^T \cdot \mathbf{e} \quad (12)$$

式中: D 为 e 对 V 的 Jacobian 矩阵; H 为与 D 同维数的单位矩阵。

e 对 V 的 Jacobian 矩阵具体表示为:

$$D = \partial e / \partial V \quad (13)$$

根据 V 中元素排列顺序, 从 dV 中得到 w^1 、 a 、 b 、 w^2 各参数向量的增量分别为 dw^1 、 da 、 db 、 dw^2 。

则网络新的连接权值、阈值的调整算法为:

$$w^{1\text{new}} = w^1 + dw^1, b^{\text{new}} = b + db \quad (14)$$

$$a^{\text{new}} = a + da, w^{2\text{new}} = w^2 + dw^2 \quad (15)$$

3 辨识结果

在基于 WNN 的 SG 动态辨识中, 被辨识的参数为 SG 的水位 $y(k)$ 和压力 $p(k)$, 因而网络的实际输入向量 X_I 为:

$$\mathbf{X}_I = [Q_w(k), Q_w(k-1), Q_s(k), Q_s(k-1), y(k-1), p(k-1)]^T \quad (16)$$

式中: $Q_w(k)$, $Q_w(k-1)$ 与 $Q_s(k)$, $Q_s(k-1)$ 分别为 SG 给水流量、蒸汽流量及其延迟信号; $y(k-1)$ 与 $p(k-1)$ 分别为 $y(k)$ 和 $p(k)$ 的延迟。WNN 的实际输出为 $y(k)$ 与 $p(k)$, 即 SG 的水位和压力。

先利用 SG 运行采样得到的 WNN 输入参数数据的一部分构造训练样本集对 WNN 进行训练; WNN 训练成功后, 再利用训练好的 WNN 和网络训练时未使用过的 SG 运行参数采样数据对 SG 水位和压力的动态特性进行辨识。对 SG 典型运行工况下的辨识结果表明, 使用本文所提出的方法能够正确地辨识 SG 的动态特性且具有较高的辨识精度。下面给出一辨识实例。

当核动力装置蒸汽负荷由 A 下降到负荷 B , 然后再上升到负荷 A 时, 对 SG 水位与压力动态特性的辨识结果示于图 3。从辨识实例的结果可见, 应用 WNN 对 SG 进行动态辨识时获得了满意的辨识效果, 从而验证了所提辨识方法可行性。

4 结论

SG 复杂非线性特性和收缩-膨胀问题, 使其动态特性难以辨识。为提高 SG 动态特性辨

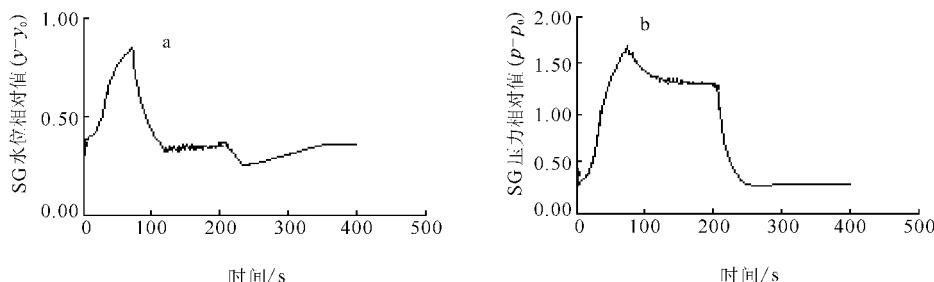


图3 负荷变化时 SG 水位(a)和压力(b)辨识结果

Fig. 3 Results of identification for SG water level(a) and pressure(b) when load changes

实线——实际值;虚线——WNN 辨识值

识效果,提出了基于 WNN 的 SG 动态特性辨识的新方法。对典型运行工况下 SG 动态特性辨识的结果表明,所提出的方法能够正确地辨识 SG 水位特性,并且具有较高的辨识精度。该工作为进一步研究基于神经网络的 SG 异常监测与诊断问题提供了基础。

参考文献:

- [1] IRVING E, MIOSSEC C, TASSART J. Toward efficient full automatic operation of the PWR steam generator with water level adaptive control [C]//Proceedings of 2nd International Conference Boiler Dynamics and Control in Nuclear Power Stations. London: British Nuclear Energy Society, 1979:309-329.
- [2] PARLOS A G, ATIYA A F, CHONG K T. Nonlinear identification of process dynamics using neural networks[J]. Nuclear Technology, 1992, 97: 79-96.
- [3] 刘志刚,王晓茹,钱清泉. 小波网络的研究进展与应用[J]. 电力系统自动化, 2003, 27(6):73-85.
LIU Zhigang, WANG Xiaoru, QIAN Qingquan. A review of wavelet networks and their applications [J]. Automation of Electric Power Systems,
- [4] ZHANG J, WALTER G G, MIAO Y B, et al. Wavelet neural networks for function learning [J]. IEEE Trans on Signal Processing, 1995, 43(6):1 485-1 497.
- [5] KUGARAJAH T, ZHANG Q H. Multidimensional wavelet frames[J]. IEEE Trans on Neural Networks, 1995, 6(6):1 552-1 556.
- [6] SATIO N, BEYLIN G. Multiresolution representations using the auto-correlation functions of compactly supported wavelets [J]. IEEE Trans on Signal Processing, 1993, 41(12): 3 584-3 590.
- [7] BEYLIN G, SATIO N. Wavelets, their auto-correlation functions and multiresolution representation of signals [J]. IEEE Trans on Signal Processing, 1997, (7):147-164.
- [8] SZU H H, TELFER B, KADAMBE B. Neural network adaptive wavelets for signal representation and classification[J]. Optical Engineering, 1992, 31(9):1 907-1 916.
- [9] HAGAN M T, DEMUTH H B, BEALE M H. Neural network design[M]. Beijing: Thomson Learning Asia and China Machine Press, 2002: 239-244.