

文章编号: 1001-0920(2006)03-0315-04

基于紧框架小波神经网络的抽油机井故障诊断

任伟建, 段玉波, 张正刚, 董宏丽

(大庆石油学院 电气信息工程学院, 黑龙江 大庆 163318)

摘要: 所提出的小波网络包括初始的学习网络和训练过程中根据精度要求而自适应并入的子网络。通过对各维输入信号的综合时域分析, 选择合适的尺度参数和位移参数构造单尺度下的小波紧框架, 以构成各级子网络, 进而解决多维小波网络中存在的“维数灾”问题。针对对角回归结构, 推导出带遗忘因子的动态递推最小二乘法对网络的参数进行训练。将该网络应用于抽油机井的故障诊断, 得到了较好的效果。

关键词: 小波框架; 小波神经网络; 抽油机; 故障诊断

中图分类号: TP206 **文献标识码:** A

Fault Diagnosis of Pump-jack Based on Wavelet Neural Network with Compacted

REN Wei-jian, DUAN Yu-bo, ZHANG Zheng-gang, DONG Hong-li

(Faculty Electrical and Information Engineering, Daqing Petroleum Institute, Daqing 163318, China. Correspondent: REN Wei-jian, E-mail: renwj@126.com)

Abstract: A wavelet network is presented, which consists of an initial network and some sub-networks that are incorporated during training according to the accuracy. Compacted wavelet frames under the single dilation are constructed according to the relationship between dilation and translation parameters. And the boundaries of wavelet frames are derived by Daubechies, to solve the “dimension disaster” problem. Dynamical recurrent least square algorithm with forgetting factor is presented to train network parameters. This network is used to diagnose the faults of pump-jacks in the oil field and the good result is obtained.

Key words: Wavelet frames; Wavelet neural network; Pump-jack; Fault diagnosis

1 引言

抽油机是石油工业中的重要设备, 它的安全可靠运行直接影响石油的产量、电能消耗以及企业的经济效益。目前对抽油机井的故障诊断方法主要是绘制其功图, 然后人工进行分析判断, 往往是故障出现很长时间后才被发现, 造成不必要的经济损失和浪费, 因此对抽油机井开展自动故障诊断研究具有重要意义。

人工神经网络由于具备自组织、自学习性、并行性、容错性和联想记忆功能等信息处理的特点而被广泛应用于故障诊断领域。理论上, 神经网络的输入

可以接受任何形式的信号, 输入节点的个数也不受限制。但是, 由于待诊断系统的故障信号通常比较复杂, 若直接将其作为输入样本势必造成网络结构庞大而难以训练。小波分析技术的出现, 为故障诊断提供了一个有利的分析工具。它具有良好的时频局部化特性, 对信号在全频段进行逐层有效的分解, 更有利于提取信号的特征, 从而可以大大降低网络输入向量的维数。因此, 将小波与神经网络相结合而形成的小波神经网络融合了二者的优势, 并在电机振动故障诊断^[1]、滚动轴承故障监测^[2]、模拟电路故障诊断^[3]、旋转机械故障诊断^[4]等得到成功应用, 受到人们广泛的关注。但用于故障诊断时小波神经网络普

收稿日期: 2005-01-13; 修回日期: 2005-04-19

基金项目: 黑龙江省骨干教师基金项目(1053G002); 黑龙江省自然科学基金项目(TF2005-26)

作者简介: 任伟建(1963—), 女, 黑龙江泰来人, 教授, 博士生, 从事复杂系统的优化控制及故障诊断的研究;
段玉波(1951—), 男, 黑龙江木兰人, 教授, 博士生导师, 从事电力系统的预报和控制等控制

遍存在“维数灾”问题

本文构造的小波网络采用多级网络结构,在训练过程中根据精度要求自适应地并入子网络,每一级网络的隐层均由单尺度下的小波紧框架构成,较好地解决了“维数灾”问题。网络隐层神经元采用对角回归结构,从而优化了网络的结构。构造带遗忘因子的动态递推最小二乘法对网络的参数进行训练,在保证算法的收敛速度和精度的前提下,削减了算法的计算量,得到了较好的效果

2 网络结构及尺度和位移参数的选取

2.1 网络结构

本文构造的多维对角回归小波神经网络包括初始的学习网络和训练过程中根据精度要求而自适应并入的子网络。初始的学习网络和各子网络均为单隐层的前向神经网络,各级网络的隐层均由单尺度下的小波紧框架构成,且尺度逐级增加,整个网络实现了 $R^m \rightarrow R^n$ 的映射,其数学模型为

$$\begin{cases} \bar{y}_k(t) = y_k(t) + e_k(t) = \\ \quad \sum_j w_{jk}^o S_j(t) + e_k(t), \\ S_j(t) = \Psi(I_j(t)), \\ I_j(t) = \sum_i w_{ij}^l x_i(t) + w_j^d S_j(t-1). \end{cases} \quad (1)$$

其中: $x_i(t)$ 为网络的第 i 个输入, $i = 1, 2, \dots, m$; $I_j(t)$ 为第 j 个对角回归元的输入之和; $S_j(t)$ 为第 j 个对角回归元的输出, $j = 1, 2, \dots, n_h$; $\Psi(\bullet)$ 为单尺度紧框架构中的各 Marr 小波函数; $\bar{y}_k(t)$ 和 $y_k(t)$ 分别为网络的第 k 个输出节点的期望输出和实际输出, $k = 1, 2, \dots, n$; $e_k(t)$ 为模型误差; 输入层到隐层的权值为 w_{ij}^l ; 隐层到输出层的权值为 w_{jk}^o ; 对角回归元的权值为 w_j^d 且恒为 1。隐层节点采用对角回归结构,通过引入一阶自反馈环节来反映系统的动态特性。这样就可以不用象传统的多层动态前向网那样通过对网络的输入和输出分别作 m 阶和 n 阶时延并将网络的输出反馈至输入端来反映系统的动态特性,在很大程度上减小了网络的输入节点数。从式(1)可以看出,隐层节点的输入由当前时刻的输入和前一时刻的输出组成,而前一时刻的输出为该时刻输入的函数,前一时刻的输入又包含再前一时刻的输出,如此形成无限递推,所以其对信息的记忆是无限的。显然,与多层动态前向网相比,采用对角回归结构可以更好地反映系统的动态特性,而且不增加网络的输入节点数。各级子网络的并入过程如图 1 所示。

文献[5]中指出,只要选择出合适的尺度参数 j 值,便存在 $x(t), \Psi_{jk}$ 使 $\sum_k x(t), \Psi_{jk} \Psi_{jk}$ 以适当的精度逼近 $x(t)$ 。从图 1 可以看出,初始网络是由尺度

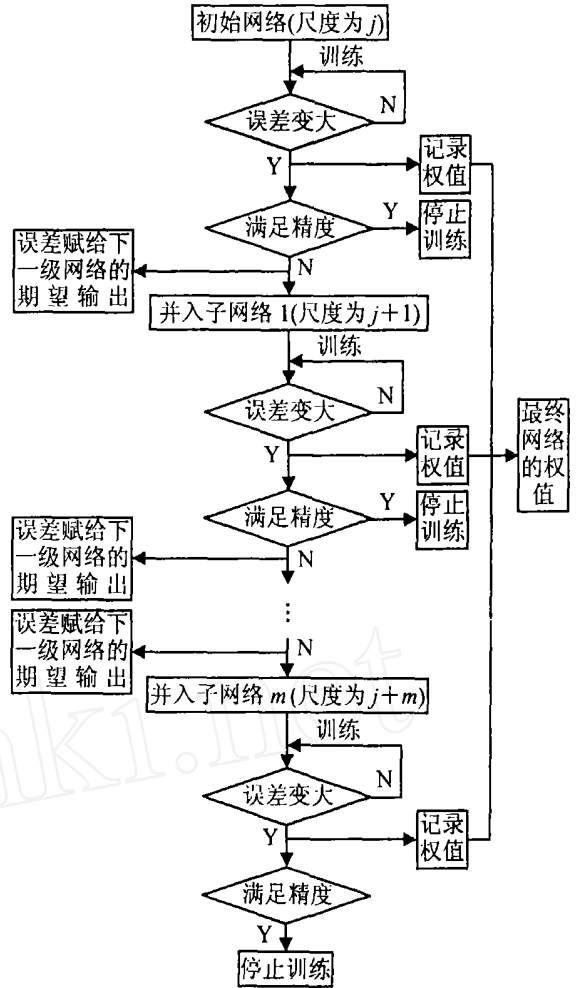


图 1 子网络并入的流程图

为 j 的小波紧框架构成的,其中 j 是一个较小的整数。当 j 取 1 或 2 时,训练精度通常很低,因此初始网络的尺度可取为 3, 4 或更大的整数。在对尺度为 j 的子网络训练过程中,误差逐渐减小直至保持基本恒定,而当误差变大时则表明网络训练过度^[6]。此时记录下误差变大之前的网络权值,并将其作为该子网络的最终权值;同时判断精度是否满足要求,若精度满足要求则停止训练,反之则并入尺度为 $j+1$ 的子网络,并令本级网络的期望输出为上一级网络的误差,即对上一级网络的误差进行学习。以此类推,直至并入第 m 个子网络,精度满足要求为止,此时便得到了已训练好的整个网络的权值。

在基于框架的多维小波网络中普遍存在“维数灾”问题,因为通常的基于框架的多维小波网络对于每一维输入信号到输出信号之间的非线性映射采用不同的小波框架去逼近,如文献[6],这样不仅各框架之间可能存在较大的冗余,而且随着输入维数的增长,网络的隐层节点数将会成倍增长。本文通过对各维输入信号进行综合时域分析,在尺度参数确定的情况下选择合适的位移参数,以使小波伸缩系

即单尺度下的小波紧框架能够覆盖各维输入向量, 如此便可以用一个小波紧框架去逼近各维输入信号到输出信号之间的非线性映射 这样, 不仅减小了不同小波框架之间的冗余, 而且网络的隐层节点数也不随着输入维数的增加而成倍地增长, 因而较好地解决了“维数灾”问题

2.2 尺度和位移参数的选取

为了使小波伸缩系能够覆盖各维输入向量, 由小波理论知, 若母小波的时域中心为 t^* , 半径为 $\Delta\psi$, 则小波伸缩系在时域的集中区域为 $[b + at^* - a\Delta\psi, b + at^* + a\Delta\psi]$, 其中 a 和 b 分别为连续小波变换中的尺度参数和位移参数, 则尺度参数和位移参数按文献[8]选取 网络的隐层节点数, 即单尺度小波紧框架中小波函数的个数可通过 $2^j + p - 1$ (p 为一小的整数) 来确定^[9]. 因此, 可以确定出每一个尺度参数所对应的位移参数

3 网络的学习算法

本文所构造的网络的隐含层为对角回归结构 下面推导出适合于对角回归结构的带遗忘因子的动态递推最小二乘(DRLS)算法, 对网络的参数进行训练

网络方程如式(1)所示 为了进行单个权值 $w_{ka}^o(t)$ 的训练, 假定其余权值 $w_{kj}^o(t), j = a$, 均取上一时刻的估计值 $\hat{w}_{kj}^o(t-1), j = a$, 并令

$$\zeta(t) = \sum_{j=a} w_{kj}^o(t) S_j(t) - \sum_{j=a} \hat{w}_{kj}^o(t-1) S_j(t), \quad (2)$$

则可得

$$\bar{y}_k(t) = w_{ka}^o(t) S_a(t) + \zeta(t) + e_k(t). \quad (3)$$

给定训练样本集 $\{x(l), \bar{y}(l) | l = 1, 2, \dots, p\}$, 便给定了 $\{S_j(l) | j = 1, 2, \dots, n_h; l = 1, 2, \dots, p\}$. 其中: p 为样本个数, n_h 为各级网络的隐层节点个数 令最小二乘指标为

$$J(w_{ka}^o(t)) = \sum_{t=1}^p [\bar{y}_k(t) - w_{ka}^o(t) S_a(t) - \zeta(t)]^2 \lambda^{p-t} + \sum_{t=1}^p e_k^2(t) \lambda^{p-t}, \quad (4)$$

其中 $0 < \lambda < 1$ 为遗忘因子 令 $\partial / \partial w_{ka}^o(t) = 0$, 可得如下正则方程:

$$\begin{aligned} \partial / \partial w_{ka}^o(t) = & \\ & - 2 \sum_{t=1}^p [\bar{y}_k(t) - w_{ka}^o(t) S_a(t) - \zeta(t)] S_a(t) \lambda^{p-t} = 0 \end{aligned} \quad (5)$$

由式(5)解得

$$w_{ka}^o(t) = U_a^{-1}(t) V_{ka}(t), \quad (6)$$

$$U_a(t) = S_a^2(t) + \lambda \sum_{t=1}^{p-1} S_a^2(t) \lambda^{(p-1)-t} = \lambda U_a(t-1) + S_a^2(t), \quad (7)$$

$$V_{ka}(t) = \lambda V_{ka}(t-1) + S_a(t) [\bar{y}_k(t) - \zeta(t)] \quad (8)$$

令 $P_a(t) = U_a^{-1}(t)$, 经变换得到

$$P_a(t) = \lambda^{-1} P_a(t-1) - \lambda^{-1} P_a(t) P_a(t-1) S_a^2(t). \quad (9)$$

将式(8)和(9)代入(6), 得

$$w_{ka}^o(t) = P_a(t) V_{ka}(t) = w_{ka}^o(t-1) + P_a(t) S_a(t) e_k(t). \quad (10)$$

综合上述各式, 得到对网络权值进行逐个辨识的带遗忘因子的动态递推最小二乘算法(DRLS)如下:

$$\begin{cases} w_{ka}^o(t) = w_{ka}^o(t-1) + P_a(t) S_a(t) e_k(t), \\ P_a(t) = \lambda^{-1} P_a(t-1) [1 + \lambda^{-1} P_a(t-1) S_a^2(t)]^{-1}, \\ e_k(t) = \bar{y}_k(t) - \sum_{j=1}^{n_h} \hat{w}_{kj}^o(t-1) S_j(t), \\ S_j(t) = \Psi \left(\sum_i w_{ij}^l x_i(t) + w_j^D S_j(t-1) \right). \end{cases} \quad (11)$$

由式(11)可以看到其中不含有矩阵运算, 因而使计算量大大减小

4 抽油机井故障诊断

抽油机井的主要故障是抽油杆断脱和抽油杆偏磨 网络的输入层有 10 个节点, 分别为反映抽油机井工作状态的电压和电流信号 网络的输出层有 4 个节点, 正常工作状态样本的期望输出为 $[1, 0, 0, 0]$, 抽油杆断脱状态样本的期望输出为 $[0, 1, 0, 0]$, 抽油杆中等偏磨状态样本的期望输出为 $[0, 0, 1, 0]$, 抽油杆过度偏磨状态样本的期望输出为 $[0, 0, 0, 1]$ 各级网络结构为 $10 - (2^j + p) - 4$ 其中: j 为各级小波框架的尺度, p 为大于或等于 1 的整数

用 20 个正常状态样本, 30 个抽油杆断脱状态样本, 30 个抽油杆中等偏磨状态样本和 30 个抽油杆过度偏磨状态样本对网络进行训练, 训练误差精度要求为 0.002, 训练结果如表 1 所示 训练结束后, 利用该网络对抽油机井的故障进行诊断 从表 2 中可以看出, 由诊断结果可以对抽油机井的各种故障作出准确的诊断 各尺度与隐层节点数, 学习时间与学习误差之间的关系如表 3 所示 由表 3 可以看出, 随着尺度的增加, 隐层节点数成指数增长 尺度较小时学

习时间变化不大,而学习误差变化较大;尺度较大时,随着尺度的增加,学习时间成指数增长,而学习误差却没有明显变化,甚至出现波动.因此,可以根据精度和网络的学习时间对尺度进行综合选择.

表1 训练样本的输出

输出节点	正常	断脱	中等偏磨	过度偏磨
节点1	0.9861	0.1167	0.0509	0.0472
节点2	0.0027	0.8970	0.2741	0.1653
节点3	0.1549	0.0019	0.9737	0.0094
节点4	0.0931	0.0581	0.0371	0.9573

表2 诊断结果

输出节点	正常	断脱	中等偏磨	过度偏磨
节点1	0.8691	0.0173	0.1097	0.0908
节点2	0.0405	0.9942	0.0735	0.1391
节点3	0.1879	0.1738	0.9571	0.0267
节点4	0.0147	0.0350	0.0029	0.9192

表3 尺度与学习误差、计算时间和隐层节点数之间的关系

尺度	学习误差/%	学习时间/s	隐层节点数
4	9.17	0.89	17
5	4.48	1.13	50
6	3.07	1.39	115
7	2.31	2.12	244
8	1.92	3.42	501
9	1.97	6.12	1014
10	1.76	10.26	2039
11	1.79	22.49	4088
12	1.71	46.92	8185
13	1.62	94.76	16378
14	1.32	275.08	32763

5 结 语

本文构造的基于单尺度多维紧支径向小波框架的小波神经网络优化了网络结构,缓解了多维小波神经网络中存在的“维数灾”问题.所推导出的带遗忘因子的动态递推最小二乘算法,既减小了计算量,又不存在局部极小问题.应用本文方法对81口抽油机井进行了故障诊断,正确率达95%以上.

参考文献(References)

- [1] 吴桂峰,翟玉庆,陈虹,等.基于小波神经网络的电机振动故障诊断[J].控制工程,2004,11(2):152-154,176
(Wu G F, Zhai Y Q, Chen H, et al. Fault Diagnosis of

Vibration in Electrical Machine Based on the Wavelet-neural Network [J]. Control Engineering of China, 2004, 11(2): 152-154, 176)

- [2] 李进玲,李治,李合生.基于小波包能量特征的滚动轴承故障监测方法[J].系统仿真学报,2003,15(1):76-80
(Li J L, Li Z, Li H S. The Method of Roller Bearing Fault Monitoring Based on Wavelet Packet Energy Feature [J]. J of System Simulation, 2003, 15(1): 76-80)
- [3] 谢宏,何怡刚,吴杰.基于小波神经网络模拟电路故障诊断方法的研究[J].仪器仪表学报,2004,25(5):672-675
(Xie H, He Y G, Wu J. Research on Analog Circuit Fault Diagnostic Method Based on Wavelet-neural Network [J]. Chinese J of Scientific Instrument, 2004, 25(5): 672-675)
- [4] 江磊,江凡.基于小波神经网络的旋转机械故障诊断[J].汽轮机技术,2004,46(3):204-206
(Jiang L, Jiang F. Fault Diagnosis of Rotation Machine Based on Wavelet Neural Network [J]. Turbine of Technology, 2004, 46(3): 204-206)
- [5] 黄德先,金以慧.基于小波神经网络的通用多变量非线性系统辨识算法和应用[J].控制理论与应用,2001,18(S1):63-68
(Huang D X, Jin Y H. Wavelet Networks Based General Multi-variable Non-linear System Identification Arithmetic and Its Application [J]. Control Theory and Applications, 2001, 18(S1): 63-68)
- [6] Wan Jian, Xu Demin, He Yuyao. Multidimensional Wavelet Networks Based on a Tensor Product Structure [J]. Control Theory and Applications, 2002, 19(3): 34-39
- [7] 杨福生.小波变换的工程分析与应用[M].北京:科学出版社,2003
(Yang F S. Engineering Analysis and Application of Wavelet Transform [M]. Beijing: Science Press, 2003: 56-70)
- [8] 赵学智,邹春华,陈统坚,等.小波神经网络的参数初始化研究[J].华南理工大学学报,2003,31(2):77-79,84
(Zhao X Z, Zhou C H, Chen T J, et al. A Research on the Initialization of Parameters of Wavelet Neural Networks [J]. J of South China University of Technology, 2003, 31(2): 77-79, 84)
- [9] Zhang Jun, Gilbert G Walter, Miao Y, et al. Wavelet Neural Networks for Function Learning [J]. IEEE Trans on Signal Processing, 1995, 43(6): 1485-1497.