

· 自动化技术 ·

## 随钻声波测井数据压缩的小波神经网络法

张 伟, 师奕兵, 王志刚

(电子科技大学自动化工程学院 成都 610054)

**【摘要】**针对当前石油工程声波随钻测井中大量测井数据需要在井下实时压缩存储的迫切要求,结合声波测井数据的特点,提出了一种基于小波神经网络的数据压缩算法,并利用共轭梯度法优化网络参数。实验结果表明,该算法具有参数收敛速度快、数据压缩比高的特点,能够满足随钻声波数据高速实时处理的需要。

**关键词** 随钻声波测井; 共轭梯度法; 数据压缩; 小波神经网络;  
**中图分类号** TP273 **文献标识码** A

## Wavelet Neural Network Method for Acoustic Logging-While-Drilling Waveform Data Compression

ZHANG Wei, SHI Yi-bing, and WANG Zhi-gang

(School of Automation Engineering, University of Electronic Science and Technology of China Chengdu 610054)

**Abstract** A large of logging data must be stored in downhole imminently in the acoustic logging-while-drilling of petroleum engineering. In this paper, an efficient data compression algorithm based on wavelet networks for acoustic wave data is presented. The experiment result shows the features of algorithm such as fast parameter approximation rate and high compression ratio. It can meet the need of the high-speed real-time processing in petroleum engineering.

**Key words** acoustic logging-while-drilling; conjugate grads algorithm; data compression; wavelet neural networks

石油工程随钻测井<sup>[1]</sup>在钻井的同时测量地层岩石物理参数,与传统的电缆测井相比较有非常多的优势。传统电缆测井需占用一定的钻机在用时间,井眼环境和泥浆滤液的浸入严重影响常规测井数据的质量;而随钻测井资料是在泥浆浸入地层之前或浸入很浅时测得的,能更真实地反映原状地层的地质特征。另外,对于大斜度井、水平井或特殊地质环境钻井,电缆测井困难或风险大,以至于不能进行作业,随钻测井可以取而代之。

目前海上钻井几乎都使用随钻测井技术。然而,由于受数据传输技术的限制,大量的测井数据先是被存储于井下仪器的存储器中,起钻后再回放。比如贝克休斯公司的随钻声波测井仪APX<sup>[1]</sup>和斯仑贝谢公司的随钻声波测井仪sonicVISION<sup>[1]</sup>都是将声波波形数据存储于精心设计的井下高速存储器中,起钻后再将波形资料回放,进行后处理。但是,井下

仪器的存储器容量有限,为了适应海量声波测井数据的存储,对声波测井数据进行实时压缩具有非常重要的现实意义。声波测井数据是一种非平稳信号,它包括大小相互独立作用的叠加信号(如纵波、横波以及斯通利波),其信号幅度的变化范围大,无直流分量,分频带特性强。小波变换<sup>[2]</sup>因其良好的时频特性和多分辨率分析能力,在数据压缩、模式识别、信噪分离等方面有广泛的应用。神经网络是具有学习能力的模式识别模型,对非平稳信号有逐级细化和特征提取能力,在模式识别、函数逼近等方面有独特的优点<sup>[3]</sup>。基于小波变换的压缩算法和基于神经网络的压缩算法都属于参数提取算法,实际应用表明这两种算法具有相当好的性能。小波神经网络<sup>[4]</sup>是小波分析理论与神经网络理论相结合的产物,它既利用了小波分析能对信号进行多分辨率分析的特性,又利用了神经网络的非线性映射和学习能力。

收稿日期: 2007-06-25; 修回日期: 2008-04-23

基金项目: 国家863计划(2006AA06Z222); 教育部新世纪优秀人才支持计划(NCET-05-0804)

作者简介: 张 伟(1979-),男,博士生,主要从事石油测井相关信号处理方面的研究。

本文利用小波神经网络对随钻声波测井数据进行压缩, 实验结果表明, 通过调节小波基参数和权值, 网络在大量压缩数据的同时能够很好地恢复原有的声波测井数据。

## 1 小波神经网络的数据压缩原理

### 1.1 基于小波神经网络的信号表示方法

小波变换实质上是不同参数空间之间的一种积分变换:

$$w(\mathbf{p}) = \int_{\Omega} f(\mathbf{T})h(\mathbf{p}, \mathbf{T})d\mathbf{T} \quad f(\mathbf{T}) \in L^2(R) \quad (1)$$

式中 向量  $\mathbf{p} = (p_1, p_2, \dots, p_n)$  和  $\mathbf{T} = (t_1, t_2, \dots, t_n)$  分别为  $n$  维和  $m$  维参数空间中的坐标;  $h(\mathbf{p}, \mathbf{T})$  称为小波基。在一维信号  $f(t)$  情况下, 小波基  $h(a, b, t)$  可以按照下述方式产生:

$$h(a, b, t) = \frac{1}{\sqrt{|a|}} h\left[\frac{t-b}{a}\right] \quad (2)$$

式中  $h(t)$  为基本小波或母小波;  $|a|^{-1/2}$  为归一化系数;  $a$  和  $b$  分别为  $h(a, b, t)$  的伸缩因子和平移因子, 对于信号  $f(t)$ , 其局部结构的分辨可以通过调节参数  $a$  和  $b$ , 即调节小波基窗口的大小和位置来实现。

小波网络是基于小波分析而构造的神经网络模型, 即在神经元中用小波基取代通常的Sigmoid函数作为激活函数, 其信号表述是通过将所选取的小波基进行线性叠加来实现的。信号  $f(t)$  可用小波基  $h(a, b, t)$  进行如下拟合:

$$\bar{f}(t) = \sum_{k=1}^K w_k h\left[\frac{t-b_k}{a_k}\right] \quad (3)$$

式中  $\bar{f}(t)$  是对原信号  $f(t)$  的估计;  $w_k (1 \leq k \leq K)$  为隐层到输出层的权值;  $a_k (1 \leq k \leq K)$  为隐层小波基的伸缩因子;  $b_k (1 \leq k \leq K)$  为隐层小波基的平移因子;  $K$  为小波基的个数。

单输入单输出的单层网络结构<sup>[5]</sup>如图1所示。




图1 单输入单输出小波神经网络结构

基于小波神经网络的数据压缩, 其原理是通过建立输入点与输出原始数据间的映射, 保留小波神经网络的结构参数, 通过这些参数实现对原始信号

$f(t)$  的重建, 本质上是利用小波网络的函数逼近功能。由于小波神经网络的结构参数明显比原始数据少得多, 便于实现数据压缩。图1所示的单输入单输出小波神经网络, 学习收敛速度快, 结构简单, 利用少量的神经元就具有很强的表达能力, 能充分提取学习对象的全局特征和局部细节, 对非平稳时间序列有很好的逼近效果<sup>[6-7]</sup>。

### 1.2 小波神经网络的学习算法

网络参数  $w_k$ 、 $a_k$ 、 $b_k (1 \leq k \leq K)$  可通过最小均方误差能量函数进行优化:

$$E = \frac{1}{2} \sum_{n=1}^N [f(t_n) - \bar{f}(t_n)]^2 \quad (4)$$

采用Morlet母小波为小波基函数, 该小波是余弦调制的高斯波, 同时具有较高的时域和频域分辨率, 即:

$$h(t) = \cos(1.75t) \exp(-t^2/2) \quad (5)$$

若令  $t' = (t - b_k)/a_k$ , 则  $E$  的梯度分别为:

$$g(w_k) = \frac{\partial E}{\partial w_k} = - \sum_{n=1}^N [f(t_n) - \bar{f}(t_n)] \times \cos(1.75t'_n) \exp(-t_n'^2/2) \quad (6)$$

$$g(a_k) = \frac{\partial E}{\partial a_k} = - \sum_{n=1}^N [f(t_n) - \bar{f}(t_n)] w_k \times [1.75 \sin(1.75t'_n) \exp(-t_n'^2/2t_n') + \cos(1.75t'_n) \exp(-t_n'^2/2)t_n'] / a_k \quad (7)$$

$$g(b_k) = \frac{\partial E}{\partial b_k} = - \sum_{n=1}^N [f(t_n) - \bar{f}(t_n)] w_k \times [1.75 \sin(1.75t'_n) \exp(-t_n'^2/2t_n') + \cos(1.75t'_n) \exp(-t_n'^2/2)t_n'] / a_k \quad (8)$$

采用共轭梯度法优化<sup>[8-10]</sup>网络参数  $w_k$ 、 $a_k$ 、 $b_k$ , 令  $w = (w_1, w_2, \dots, w_k, \dots, w_K)$ ;  $g(w) = (g(w_1), g(w_2), \dots, g(w_k), \dots, g(w_K))$ ; 记  $s_i(w)$  为  $w$  的第  $i$  次循环搜索方向, 则有:

$$s_i(w) = \begin{cases} -g_i(w) & i=1 \\ -g_i(w) - \frac{g_i(w)g_i^T(w)}{g_{i-1}(w)g_{i-1}^T(w)} s_{i-1}(w) & i > 1 \end{cases} \quad (9)$$

类似地, 可以定义  $a$ 、 $b$  和  $s_i(a)$ 、 $s_i(b)$ , 而  $w$ 、 $a$ 、 $b$  分别调节为:

$$w_{i+1} = w_i + \alpha_{w_i} s_i(w) \quad (10)$$

$$a_{i+1} = a_i + \alpha_{a_i} s_i(a) \quad (11)$$

$$b_{i+1} = b_i + \alpha_{b_i} s_i(b) \quad (12)$$

采用一维变步长搜索算法计算最佳步长  $\alpha_{w_i}$ 、 $\alpha_{a_i}$  和  $\alpha_{b_i}$ , 每次循环时按照式(10)~(12)调整网络参


数  $w$ 、 $a$ 、 $b$ ，直至  $E$  小于某一设定误差或循环结束为止。为了合理及方便表示，网络每次循环后的输出误差  $E'$  表述为：

$$E' = \frac{\sum_{n=1}^N [f(t_n) - \bar{f}(t_n)]^2}{\sum_{n=1}^N [f(t_n)]^2} \quad (13)$$


## 2 声波测井信号数据压缩

将上述算法实际应用渤海某井随钻声波全波列测井数据压缩处理。设每一条声波波列都包含有纵波、横波和斯通利波这3种组分波成分，每一波列中纵波最先到达，频率较高，且幅度较小；跟随其后的是横波，频率接近于纵波，但幅度较大；斯通利波最晚到达，频率较低，幅度最大。它们反映了地层的多种物性参数，可以用来评价地层、判断岩性、识别裂缝等。

引入渤海某井1 209.20 m深度的一段声波测井数据进行压缩训练研究，声波测井信号的大小为目标输出，输入为采样点数，将要进行压缩的原始声波数据的采样点数为500。采用15个小波基进行训练，将  $w_k$ 、 $a_k$  初始值定为随机数(范围从-100~100)。为了加快网络收敛速度及避免误差局部最小，以波峰和波谷等所反映的位置作为  $b_k$  的初始值，开始步长分别为  $\alpha_{w_i} = 0.01$ ； $\alpha_{a_i} = \alpha_{b_i} = 10^{-6}$ 。



a. BP神经网络训练收敛曲线




b. 小波神经网络训练收敛曲线

图2 两种神经网络收敛曲线对比图


BP神经网络与小波神经网络训练收敛曲线如图2所示。对比图2a和图2b可知，小波神经网络经过288次训练，网络收敛，训练结束后输出误差  $E'$  为0.048。传统的BP网络需要594 12次训练才能达到相同的目的。图中还可明显看出小波网络的收敛速度

比传统的BP网络快得多，大大缩短了网络训练的时间，加快了数据压缩的速度，非常适合井下高速实时处理的要求。解压缩只需根据小波神经网络参数对照式(3)求取相应数据即可，恢复后的声波测井数据的误差也为0.048。

渤海某井1209.20 m深度一段声波测井数据的原始波形与恢复后波形的对比如图3所示。



a. 原始声波数据



b. 解压缩后的声波数据

图3 1 209.20 m深度点第5通道声波原始数据与解压缩后的再现数据对比图

从图中可以看出恢复后的声波信号能很好地保持原始声波信号的特性，特别是能够较准确地反映波峰的位置和强度。小波基个数的选取是一个十分重要的问题，个数太多，虽然能使收敛速度加快，但所需参数要增加，压缩比降低；相反，个数太少，压缩比可以增大，但收敛速度变慢甚至不收敛。经过实验，选择15组是比较合适的。这样，原始声波测井数据就可以用15组  $w_k$ 、 $a_k$  和  $b_k$  (共45个参数)表示出来，即用45个网络参数就可以表示500点的原始数据，压缩比约为11:1，从而实现了声波测井数据的压缩表征，结果令人满意。

## 3 声波信号井下处理系统设计

井下信号处理的工作原理为：模拟通道对声波信号进行模拟滤波、整形、放大等预处理，并将其

送到DSP处理器; DSP处理器利用其自带的AD转换器对模拟声波信号进行数字化转换, 将结果通过DMA通道送往FPGA处理模块, 在FPGA处理模块中设计如图5的小波神经网络结构完成对声波数据的压缩; 与此同时, DSP处理器继续进行井下实时首波到时提取、自动增益控制等处理, 声波原始数据(数据量大, 需要进行实时压缩、存储)的处理过程就能与首波到时提取等主要用于现场采集控制的处理(计算复杂, 但只需将最后结果上传)并行起来, 大大节省了处理时间。DSP处理器完成后续工作后, 将处理结果传送到FPGA处理模块中, 通过FPGA中的曼切斯特编码器将实时监测参数编码后及时上传给地面系统。而声波数据经过压缩后按照以深度点为行地址、小波神经网络参数为列地址的格式存储到井下大容量存储器中, 等待起钻后再回放处理。

井下信号处理电路的基本结构如图4所示。

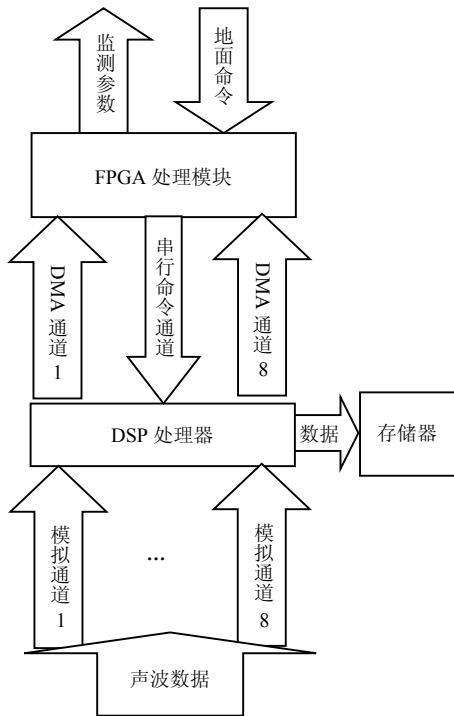


图4 井下信号处理电路结构框图

小波神经网络的FPGA硬件实现结构<sup>[10-11]</sup>如图5所示。图5a为单个神经元结构的硬件模型, 它由MAC(multiply accumulate circuit)、ROM(memory circuit)和LUT(look-up table)3部分构成, 其中MAC为求和单元, 计算神经元输入信息的加权和; ROM为存储单元, 存储神经元的连接权值; LUT为激励函数的实现单元(查找表形式)。图5b是小波神经网络的结构图, 在控制单元状态机的控制下, 隐含层里15个类似于图5a的神经元高速并行运算, 而不同层

间的信息传递则串行进行, 完成单道声波数据的实时压缩运算。而整个FPGA处理模块中存在8个类似的小波神经网络结构, 它们高速并行工作, 完全能够满足井下海量声波数据的实时处理任务。

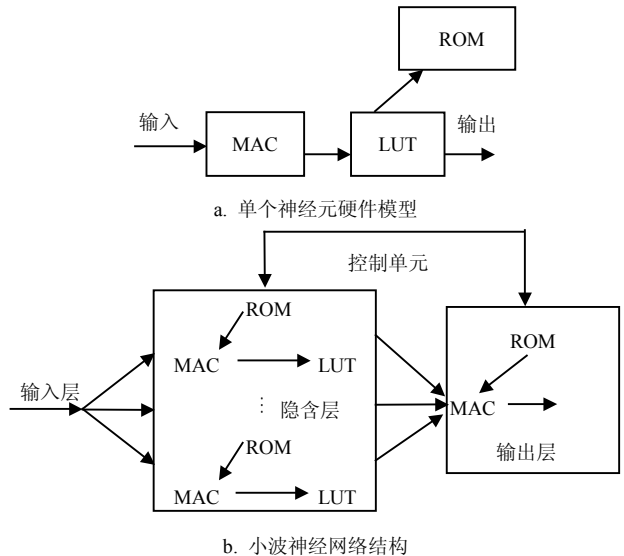


图5 小波神经网络的FPGA实现结构图

声波测井数据的解压缩由地面系统来实现。地面系统软件首先根据存储格式读取相应深度点的小波神经网络参数, 然后按照式(3)重建声波测井数据, 并进行波形显示、滤波、首波提取、时差计算等后续处理。

### 4 结论

小波神经网络继承了小波分析的函数表达能力和神经网络的自适应特性, 特征提取能力强, 学习效率高。实验表明, 基于小波神经网络的随钻声波测井数据压缩方法, 能够达到预期的目的。需要指出的是, 小波基的数量和网络参数的初始值对网络训练有很大的影响。此外, 采用不同的母小波和误差能量函数, 可能会减少训练误差以及加快网络收敛速度。

### 参 考 文 献

[1] 张辛耘, 王敬农, 郭彦军. 随钻测井技术进展和发展趋势[J]. 测井技术, 2006, 30(1): 10-15  
 ZHANG Xin-yun, WANG Jing-nong, GUO Yan-jun. Advances and trends in logging while drilling technology[J]. Well Logging Technology, 2006, 30(1): 10-15  
 [2] BRUCE A, DONHO D, GAO Hong-ye. Wavelet analysis[J]. IEEE Spectrum, 1996, (10): 26-35.

(下转第921页)

- E-Commerce Technology. San Diego, USA: IEEE Computer Society, 2004: 146-152.
- [9] AIELLO M, PLATZER C, ROSEENBERG F, et al. Web service indexing for efficient retrieval and composition[C]//Proceedings of the 8th IEEE International Conference on E-Commerce Technology and the 3rd IEEE International Conference on Enterprise Computing, E-Commerce, and E-Services (CEC/EEE '06). Palo Alto, USA: IEEE Computer Society, 2006: 63-65.
- [10] BLAKE M B, CHEUNG W, JAEGER M C, et al. WSC-06: the web service challenge[C]//Proceedings of the 8th IEEE International Conference on E-Commerce Technology and the 3rd IEEE International Conference on Enterprise Computing, E-Commerce, and E-Services (CEC/EEE '06). Palo Alto, USA: IEEE Computer Society, 2006: 62-63.
- [12] 朱海平. 基于概念图的语义搜索[D]. 上海: 上海交通大学, 2006.
- ZHU Hai-ping. Semantic search by matching conceptual graphs[D]. Shanghai: Shanghai Jiaotong University, 2006.

编辑 熊思亮

(上接第817页)

## 参 考 文 献

- [1] HAYKIN S. Cognitive radio: Brain-empowered wireless communications[J]. IEEE Journal on Selected Areas in Communications, 2005, 23(2): 201-220.
- [2] HEREDIA-URETA H, CRUZ-PEREZ F A, ORTIGOZA-GUERRERO L. Capacity optimization in multiservice mobile wireless networks with multiple fractional channel reservation[J]. Vehicular Technology, IEEE Transactions on, 2003, 52(6): 1519-1539.
- [3] ANDREWS M, KUMARAN K, et al. CDMA data QoS scheduling on the forward link with variable channel conditions[R]. Bell Laboratories Technical Report, April 2000.
- [4] SHAKKOTTAI S, STOLYAR A L. Scheduling for multiple flows sharing a time-varying channel- the exponential rule[R]. Bell Laboratories Technical Report, Dec 2000.
- [5] VISWANATH P, TSE D N C, LARROIA R. Opportunistic beamforming using dumb antennas[J]. Information Theory, IEEE Transactions on, 2002, 48(6): 1277-1294.
- [6] ELI S, GERALD C. WRAN channel modeling. [2005- 07-12]. [http://www.ieee802.org/22/Meeting\\_documents/2005\\_July/22-05-0055-01-0000\\_WRAN\\_Channel\\_Modeling-ES-GC.doc](http://www.ieee802.org/22/Meeting_documents/2005_July/22-05-0055-01-0000_WRAN_Channel_Modeling-ES-GC.doc).
- [7] CAI X, GIANNAKIS G B. A two dimensional channel simulation model for shadow fading processes[J]. IEEE Transactions on Vehicular Technology, 2003, 52(6): 1558-1567.
- [8] BAUGH C R, HUANG J. Traffic model for 802.16 TG3 MAC/PHY simulations[DB/OL]. [2001-03-02]. [http://www.ieee802.org/16/tg3/contrib/802163c-01\\_3\\_0r1.pdf](http://www.ieee802.org/16/tg3/contrib/802163c-01_3_0r1.pdf).
- [9] WEISS T A, JONDRAL F K. Spectrum pooling an innovative strategy for the enhancement of spectrum efficiency[J]. Communications Magazine, IEEE, 2004, 42(3): S8-14.
- [10] BENKO J, CHEONG Y C, CORDEIRO C. A PHY/ MAC proposal for IEEE 802.22 WRAN systems part 2: The Cognitive MAC[DB/OL]. [2006-02-23]. [http://www.ieee802.org/22/Meeting\\_documents/2006\\_Mar/22-06-0003-03-0000\\_ETRI-FT-I2R-Motorola-Philips-Samsung-Thomson\\_MAC\\_Spec.doc](http://www.ieee802.org/22/Meeting_documents/2006_Mar/22-06-0003-03-0000_ETRI-FT-I2R-Motorola-Philips-Samsung-Thomson_MAC_Spec.doc).

编辑 漆 蓉

(上接第903页)

- [3] SZU H H, TELFER B A, KADAMBE S L. Neural network adaptive wavelets for signal representation and classification[J]. Optical Engineering, 1992, 31(9): 1907-1916.
- [4] ZHANG Q, BENVENISE A. Wavelet network[J]. IEEE Trans on Neural Network, 1992, 3(6): 889-898.
- [5] SZU H H, TELFER B, KADAMBE B. Neural network adaptive wavelets for signal representation and classification[J]. Optical Engineering, 1992, 31(9): 1907-1916.
- [6] ZHANG J, WALTER G, MIAO Y, et al. Wavelet neural networks for function learning[J]. IEEE Transactions on Signal Processing, 1995, 43(6): 1485-1497.
- [7] CAO L, HONG Y. Predicting chaotic time series with wavelet networks[J]. Physic D, 1995, 21(5): 85-97.
- [8] 马 光. 共轭梯度法训练小波神经网络[J]. 信息技术, 2004, 28(9): 54-60.
- MA Guang. Training arithmetic of wavelet neural network conjugate grads algorithm[J]. Information Technology, 2004, 28(9): 54-60.
- [9] ZHANG J, WALTER G, MIAO Y, et al. Wavelet neural network for function learning[J]. IEEE Transactions on Signal Processing, 1995, 43(6): 1485-1497.
- [10] Zhang Qing-hua. Using wavelet network in nonparametric estimation[J]. IEEE Trans Neural Network, 1997, 8(2): 227-236.
- [11] COHEN M, A, GROSSBERG S. Absolute stability of global pattern formation and parallel memory storage by competitive neural networks[J]. IEEE Trans Syst Man Cybern, 1983, SMC-13: 815-826.

编辑 熊思亮