

小波神经网络模型的确定性预测及应用

潘玉民*, 邓永红, 张全柱

(华北科技学院 信息与控制技术研究所, 北京 101601)

(*通信作者电子邮箱 pym_001@ncist.edu.cn)

摘要:针对神经网络模型预测结果的随机性,构建了一种紧致性小波神经网络工具箱。该方法将小波函数移植到BP网络隐层,并采用一种随机确定状态命令获得确定的预测结果。与编程实现的小波神经网络和BP网络比较,该方法适合于大批量数据训练,对数据样本的适应能力和鲁棒性强,尤其对高频随机时间序列有更好的适应能力,具有预测结果确定及实用性强等特点,可显著提高模型的训练速度、预测精度和预测效率。基于小波包变换和小波神经网络的瓦斯涌出量预测实验证明了所提方法的有效性。

关键词:小波神经网络;工具箱;小波包;瓦斯涌出量;预测

中图分类号: TP273 **文献标志码:** A

Deterministic prediction of wavelet neural network model and its application

PAN Yumin*, DENG Yonghong, ZHANG Quanzhu

(Information and Control Technology Institute, North China Institute of Science and Technology, Beijing 101601, China)

Abstract: Concerning the random prediction results of the neural network model, a compact wavelet neural network was constructed. The method transferred the wavelet function into the hidden layer of the Back-Propagation (BP) network and made use of a random certain state command to obtain the definite prediction results. Compared with the wavelet neural network realized by programming and BP network, this method is suitable for mass data training and has such advantages as strong adaptability and robustness for data samples, especially has better adaptability for high frequency stochastic time series, and has characteristics of determined predicted results, powerful practicability and so on. It can obviously improve the training speed, prediction accuracy and prediction efficiency of the model. Its efficiency has been proved by the gas emission prediction experiment of wavelet packet transformation and wavelet neural network.

Key words: wavelet neural network; toolbox; wavelet packet; gas emission; prediction

0 引言

神经网络引入预测领域使预测理论及方法产生了质的飞跃。传统的线性预测方法,如自回归(AutoRegressive, AR)模型、滑动平均(Moving Average, MA)模型等在解决非线性严重的预测问题时遇到很大困难,而神经网络在非线性预测方面有着独特的优势,它不需要建立复杂的非线性系统的显式关系及数学模型,通过数据样本训练即可提取数据特征和内在规律,实现信息的分布存储,产生联想记忆,从而对未经训练的样本能够给出外推的预测效果,为非线性预测提供了强有力的工具。

1987年,A. Lapedes和R. Farber首次利用神经网络对非线性时间序列进行预测,开创了神经网络应用于预测领域的先河^[1]。之后,神经网络在预测中的应用得到快速发展。近年来,小波神经网络作为一种新颖的神经网络日益受到关注,它兼有小波函数时频局部特性和神经网络函数逼近和泛化能力,在预测领域具有强大的优势。

目前,神经网络预测形式主要有两种:趋势预测与基于因果关系的回归预测,分别对应时间序列预测和多元回归预测。神经网络具有分布式、联想、记忆和很强的泛化能力,以及自学习和容错性,可以以任意精度逼近非线性函数等优点,是线

性预测方法无法比拟的。对于大多数预测对象,尤其是含有非线性关系的数据,使用神经网络预测都会得到更高的预测精度。

但是,神经网络应用于预测中存在如下问题:网络结构的设计目前尚无确定的理论依据;预测结果有随机性;机理缺乏透明度;初始参数难确定;存在过度拟合现象;易陷入局部极小等。其中大多数问题需要以实验效果为依据进行确定,利用统计方法对预测结果进行评价,或采用试凑法找出网络“最佳”参数进行下一步预测^[2]。

在上述问题中比较突出的问题是神经网络预测结果的随机性,小波神经网络也不例外,即多次预测结果不同,有时分散性很大,即神经网络的预测精度具有不可控性质。对此,在目前的文献中鲜有介绍。本文针对小波神经网络给出一种简单、实用的确定的预测方法,可以获得稳定的预测结果。

1 预测结果的不确定因素

对神经网络预测模型进行的大量实验表明:网络初始参数对预测结果的影响举足轻重^[3-4]。当网络结构确定后,即网络输入层、隐层、输出层神经元个数,以及学习速率、训练精度等确定后,预测结果取决于网络的初始参数值。初始参数包括网络权值、阈值,对于小波神经网络还包括平移因子和尺

收稿日期:2012-10-12;修回日期:2012-11-26。

基金项目:国家安全生产监督管理总局安全生产科技发展指导性计划项目(06-472);河北省教育厅科学技术研究项目(Z2006439)。

作者简介:潘玉民(1958-),男,内蒙古赤峰人,副教授,主要研究方向:智能控制、复杂系统建模;邓永红(1975-),男,湖南涟源人,工程师,硕士,主要研究方向:微机控制、电力电子与电能变换;张全柱(1965-),男,内蒙古乌兰察布人,教授,博士,主要研究方向:电力电子、交流传动。

度参数。

神经网络的初始参数通常都设为 $[-1, 1]$ 的随机数,它是导致预测结果不确定的本质原因。在网络结构确定的前提下,如果初始参数设为定值,预测结果必然是唯一的。实验表明,对常用的三层神经网络,影响最大的是网络参数的初始值,之后是训练精度、隐层神经元数、学习速率以及动量因子等。

无论是对于BP网络还是小波神经网络,网络参数的初始化过程对于网络的后续学习是否收敛以及收敛的快慢都非常重要;初始权值选择得好,可大大加快收敛;初始权值设置不当,则学习次数会大为增加,乃至于不收敛;对小波网络,若尺度参数与位移参数初始化不合适,将导致整个网络学习过程的不收敛^[5]。

文献[2-4]提出了几种网络参数初始化的方法,这些方法揭示了初始参数与网络结构、学习样本等的联系,但都具有一定的局限性。目前主要采用遗传算法、粒子群算法、混沌优化等方法优化网络初始参数,但是对于多个复杂网络其工作量也是很可观的。而且,优化算法本身也并非一次就能确定出最优值。

2 紧致性小波神经网络

紧致性小波神经网络是小波函数和神经网络有机结合的产物,是指用小波函数或尺度函数作为神经网络隐层激励函数形成神经元^[6-7]。如采用小波函数 Morlet 代替 BP 神经网络隐层的 Sigmoid 激活函数,网络结构如图1所示。




图1 小波神经网络结构

图1为三层小波网络结构。其中, x_i 为网络输入变量,输出为一个神经元,在本文输出 y 对应瓦斯涌出量; $\psi_i(t)$ 为小波基函数($i = 1, 2, \dots, m$); v_{ni}, w_i 为输入层/隐层、隐层/输出层之间的连接权。目前常用的具有较好局部性和光滑性的母小波有样条小波和 Morlet 小波,这些函数的伸缩和平移因子可以构成 $L^2(\mathbf{R})$ 的标准正交基,使其生成的小波级数可以最佳逼近函数。本文隐层采用 Morlet 小波函数,表达式为

$$\psi(x) = \cos(1.75x) \exp(-x^2/2) \quad (1)$$

小波变换对于平方可积的 Hilbert 空间 $L^2(\mathbf{R})$,若存在函数 $\psi(x) \in L^2(\mathbf{R})$, $\int_{\mathbf{R}} |\psi(t)|^2 dt < +\infty$,并且其傅里叶变换

$$C_\psi = \int_{\mathbf{R}} \frac{|\hat{\psi}(\omega)|^2}{|\omega|} d\omega < +\infty \quad (2)$$

则该函数 $\psi(t)$ 为一个基小波,通过对基小波做尺度伸缩和平移,得到基小波函数族

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) \quad (3)$$

其中: $a, b \in \mathbf{R}, a \neq 0$ 。 a 和 b 分别为伸缩平移尺度因子。小波变换为

$$(W_\psi f)(a, b) = \langle f(t), \psi_{a,b}(t) \rangle = \int_{\mathbf{R}} f(t) \psi_{a,b}^*(t) dt \quad (4)$$

$\psi(x)$ 为小波函数。式(4)表明,小波变换相当于信号函数在小波基函数上的投影,或者是把信号与小波函数在尺度为 a 、位置为 b 处进行相关比较,变换 $(W_\psi f)(a, b)$ 描述了二者之间的相似程度。投影的大小反映了信号在该尺度上能量的大小^[8]。

图1所示的小波网络结构由三层组成,输入层、隐层和输出层。设三层神经元数分别为 $n, m, 1$,每个隐层神经元的激发函数为 $\psi_{a,b}(x)$,输出层神经元激发函数取 Sigmoid,则输出表达式为

$$y^p(t) = \phi\left(\sum_{h=1}^m w_h \psi\left(\sum_{i=1}^n v_{ih} x_i^p(t) - b_h\right)/a_h\right) \quad (5)$$

其中 $p = 1, 2, \dots, P$ (P 是样本个数)。设 y 为实际值, \hat{y} 为预测值,则对训练样本 p ,取误差能量函数为:

$$J = \frac{1}{2} \sum_{j=1}^P \sum_{i=1}^m (\hat{y}_i^j - y_i^j)^2 \quad (6)$$

$$v_{ih}(k) = v_{ih}(k-1) - \eta_v \frac{\partial J}{\partial v_{ih}} + \alpha \Delta v_{ih} \quad (7)$$

$$w_h(k) = w_h(k-1) - \eta_w \frac{\partial J}{\partial w_h} + \alpha \Delta w_h, \quad (8)$$

$$a(k) = a(k-1) - \eta_a \frac{\partial J}{\partial a} + \alpha \Delta a \quad (9)$$

$$b(k) = b(k-1) - \eta_b \frac{\partial J}{\partial b} + \alpha \Delta b \quad (10)$$

其中: $\eta_v, \eta_w, \eta_a, \eta_b$ 为学习速率, α 是动量因子,通过调整WNN的各参数使式(6)最小化。

3 小波神经网络工具箱

Matlab 软件新版本中提供了 wavenet 命令实现小波神经网络,但它远没有 BP 神经网络工具箱使用方便。目前小波神经网络的应用主要是通过编程来实现,一般程序设计比较复杂,编程周期长,而且形式各异,尤其对某些数据集或大批量数据不易训练,使小波神经网络固有的优越性受到制约。小波神经网络工具箱实现的关键是自定义传递函数,即需要创建小波函数。利用 BP 神经网络工具箱 tansig, logsig 等函数进行改造,如将其替换为 Morlet 小波函数及其导数:

$$y = \cos(1.75x) \times \exp(-x^2/2) \quad (11)$$

$$\frac{dy}{dx} = -x \cos(1.75x) \times \exp(-x^2/2) -$$

$$1.75 \sin(1.75x) \times \exp(-x^2/2) \quad (12)$$

上述处理只是对激活函数进行了替换,还不具有平移和伸缩功能,即网络中没有伸缩因子 a 和平移因子 b ,通过以下证明,可将其等效后并入连接权和阈值中^[9]。

$$\begin{aligned} \psi_{a,b}\left(\sum_{i=1}^n v_{ih} x_i^p + \theta_{ih}\right) &= \psi\left(\left(\sum_{i=1}^n v_{ih} x_i^p + \theta_{ih} - b_h\right)/a_h\right) = \\ \psi\left(\sum_{i=1}^n \frac{w'_{ih}}{a_h} x_i + \frac{\theta'_{ih} - b_h}{a_h}\right) &= \psi\left(\sum_{i=1}^n w'_{ih} x_i + \theta'_{ih}\right) \end{aligned} \quad (13)$$

其中: $w'_{ih} = w_{ih}/a_h$, $\theta'_{ih} = (\theta_{ih} - b_h)/a_h$ 。

由式(13)可知,式(5)中的伸缩因子 a_h 和平移因子 b_h 并入权和阈值中,即权值和阈值包含伸缩因子和平移因子的功能。与普通 BP 网络一样训练小波神经网络,利用工具箱提供的训练函数,如训练函数取“trainlm”,输出层神经元激活函数采用“logsig”或“purelin”。

4 神经网络参数初始化方法

在采用上述小波工具箱进行实验时存在的问题是:小波工具箱效果从统计角度总体略好于 BP 网络工具箱,由于预测结果均为随机数,在多次预测过程中结果不相上下,从这个

角度该工具箱意义不大,体现不出小波神经网络的优越性。因此,本文采用命令 $\text{rand}('state', Q)$ 来获得稳定的预测结果,其中 Q 是自定义参数,表示网络预测性能指标。 Q 的取值需要通过实验加以确定,该命令可以再现曾经产生过的随机数,通过改变 Q 值得到较好的初始值。 Q 值的评价采用预测误差的平均绝对百分比。在此将 Q 定义为神经网络预测精度的控制参数。

在 Matlab 软件中, $\text{rand}('state', Q)$ 指令的功能是:重置生成器到原来的状态,表示随机产生数的状态 state 。设置 state 的作用:由于每次 rand 产生的随机数不一样,为了得到与前面某个状态相同的结果,用这个函数来产生该相同的随机数。

由 rand 命令产生的数字序列是由 Matlab 中的生成器内部状态决定的。生成器设置为相同的固定状态 (Q) 可以实现重复计算; Q 设置为不同状态将得到不同的计算结果,但同时也是唯一的计算结果,这一点正是其应用价值所在。但它对统计特性没什么改善,因为 Matlab 重新启动时,在固定的 Q 值下, rand 生成相同的数字序列。采用的表达式及含义如下:

$\text{rand}('state', 0)$: 重置生成器为初始状态;

$\text{rand}('state', S)$: 重置生成器为其第 S 个状态;

$\text{rand}('state', J)$: 对整数 J , 重置生成器为其第 J 个状态

应用 $\text{rand}('state', Q)$ 指令进行实验,可以使网络预测结果具有可重复性,实现不同网络在相同条件下比较,这对预测来说是十分重要的。

本文取规律性较差的瓦斯涌出量数据为研究对象进行实验。为了提取瓦斯涌出量数据的地质特征,采用小波包变换对原始序列进行精细的分解,对子序列分别采用不同的小波神经网络进行预测,再对各子序列的预测结果进行小波包重构获得最终预测结果。

瓦斯涌出量是一个非常复杂的地质参数,它受许多因素的影响,如地质构造、煤层厚度、煤体结构、埋藏深度等自然因素,以及与开采技术等相关,这些因素本身是随机变量,各因素之间相互制约、互为因果。因此,瓦斯涌出量实际上是一个多变量、时变、灰色、高度非线性及复杂的动力学系统,通常很难精确预测。瓦斯涌出量的大小反映不同煤层的危险程度,同时也是决定开发新井、新采区、新工作面规模、通风、安全技术水平的重要指标^[10]。

目前,在瓦斯涌出量预测中以 BP 网络为多见,但 BP 网络存在收敛时间长,易陷入局部极小等问题。

5 小波包变换理论

5.1 小波包变换

设 $\{V_j; j \in \mathbf{Z}\}$ (\mathbf{Z} 是整数集) 构成 $L^2(\mathbf{R})$ (\mathbf{R} 是实数) 上的正交多分辨率分析,其尺度函数、母小波函数分别为 $\varphi(t)$ 和 $\psi(t)$, 它们满足下述二尺度方程^[11]:

$$\begin{cases} \varphi(t) = \sqrt{2} \sum_{k \in \mathbf{Z}} h(k) \varphi(2t - k) \\ \psi(t) = \sqrt{2} \sum_{k \in \mathbf{Z}} g(k) \varphi(2t - k) \end{cases} \quad (14)$$

其中:系数 $h(k)$ 与 $g(k)$ 是多分辨率分析中的滤波器系数; $g(k) = (-1)^k h(1 - k)$, 即两个系数具有正交关系。

将尺度空间 V_j 和小波子空间 W_j 用新空间 U_j^n 表示,即 $U_j^0 = V_j, U_j^1 = W_j, j \in \mathbf{Z}$, 则 Hilbert 空间的正交分解 $V_{j+1} = V_j \oplus W_j$ 即可用 U_j^n 表示:

$$U_{j+1}^0 = U_j^0 \oplus U_j^1$$

定义子空间 U_j^n 是函数 $w_n(t)$ 的闭包空间, U_j^{2n} 是函数

$w_{2n}(t)$ 闭包空间。对于固定尺度的情况,定义递归函数关系:

$$\begin{cases} w_{2n}(t) = \sqrt{2} \sum_{k \in \mathbf{Z}} h(k) w_n(2t - k) \\ w_{2n+1}(t) = \sqrt{2} \sum_{k \in \mathbf{Z}} g(k) w_n(2t - k) \end{cases} \quad (15)$$

其中 $n = 0, 1, 2, \dots, N$ 。当 $n = 0$ 时,

$$\begin{cases} w_0(t) = \sqrt{2} \sum_{k \in \mathbf{Z}} h(k) w_0(2t - k) \\ w_1(t) = \sqrt{2} \sum_{k \in \mathbf{Z}} g(k) w_0(2t - k) \end{cases} \quad (16)$$

5.2 小波包分解与重构

设 $g_j^n(t) \in U_j^n(t)$, 则 g_j^n 可以表示为:

$$g_j^n(t) = \sum_l d_l^{j,n} u(2^j t - l)$$

小波包分解算法^[12]:

由 $\{d_l^{j+1,n}\}$ 求 $\{d_l^{j,2n}\}, \{d_l^{j,2n+1}\}$

$$\begin{cases} d_l^{j,2n} = \sum_k a_{k-2l} d_k^{j+1,n} \\ d_l^{j,2n+1} = \sum_k b_{k-2l} d_k^{j+1,n} \end{cases} \quad (17)$$

小波包重构算法:

由 $\{d_l^{j,2n}\}, \{d_l^{j,2n+1}\}$ 求 $\{d_l^{j+1,n}\}$:

$$d_l^{j+1,n} = \sum_k [h_{l-2k} d_k^{j,2n} + g_{l-2k} d_k^{j,2n+1}] \quad (18)$$

5.3 瓦斯涌出量数据的小波包分析

利用小波包变换对瓦斯涌出量数据序列进行预测,首先要对其进行小波包分解。分解层数的选择根据预测误差最小而定,本文选择3层。采用 db4 小波,分解为从低频到高频8个频率成分,如图2所示。




图2 3层小波包分解

图2中, A 表示低频, D 表示高频, 下标表示小波包分解的层数。可以看到, 小波包变换不但对每一次分解得到的低频部分作进一步分解, 而且对高频部分也作同样的进一步分解。

原始序列 S 可表示为:

$$S = AAA_3 + DAA_3 + ADA_3 + DDA_3 + AAD_3 + DAD_3 + ADD_3 + DDD_3 \quad (19)$$

实验原始数据来自文献^[13]: 429 个瓦斯涌出量的日记记录数据。原始数据为信号 S , 采用 db4 进行小波包变换得到 $S30, S31, \dots, S37$ 共8个子序列。

6 小波包-小波神经网络预测模型

预测模型构成方法: 原始瓦斯涌出量数据序列, 经小波包分解为 $S30, S31, \dots, S37$ 。各子序列分别采用不同的小波神经网络工具箱进行预测, 即采用 $WNN1, WNN2, \dots, WNN8$ 。将各自的预测结果进行小波包重构^[14], 得到最终的预测结果。

目前采用小波包分析进行故障诊断的文献较多, 而用于预测的极少, 主要原因是小波包分解子序列, 特别是对高频子序列一般神经网络很难适应, 而且预测工作量很大。如果高频成分测不准, 预测结果将受到很大影响。本文采用小波神经网络进行预测, 可以有效提取高频子序列的特征信息, 通过小波神经网络工具箱, 使训练速度大幅度提高, 并具有很强的鲁棒性。子序列的时序预测: 时序预测就是利用过去和当前

的观测值估计未来值。设一维时序列为 $\{x(i)\} (i = 1, 2, \dots, n)$ 用 n 时刻之前的相邻 m 个值 ($m < n$), 预测第 $n + 1$ 时刻的值 $\hat{x}(n + 1)$ [15], 即未来值和过去值存在某种确定的函数关系:

$$\hat{x}(n + 1) = f[x(k + 1), x(k + 2), \dots, x(k + m)]$$

同理, 用 $x(k + 2), x(k + 3), \dots, x(k + m + 1)$ 时刻的数值预测第 $n + 2$ 时刻的值 $\hat{x}(n + 2)$, 依此递推。若序列 $\{x(i)\}$ 可以分成 h 组, 则可以获得训练神经网络的样本集 (\hat{x}_h, f_h) 。根据预测效果取 $m = 7$, 即小波神经网络输入层神经元为 7 个, 输出神经元为 1 个。隐含层神经元 $q = 2n + 1, n = 7, n$ 是网络输入变量个数, 因此 $q = 15$, 即网络结构为 5-15-1。训练误差精度设置为 0.0001, 归一化采用 normr 命令, 反归一化采用 norm, 这种数据处理方法可以避免数据中出现 0 和 1, 以改善模型的预测性能。将归一化数据输入网络进行训练。

7 实验结果及分析

对子序列 S30, 在 429 个时序数据中, 利用前 7 天的数据预测第 8 天, 依此递推, 构成 422 个样本集, 取前 300 个样本训练小波神经网络, 后 122 个样本用作检验。

小波神经网络 WNN1 的设计: 在 Matlab R2006b 环境下进行实验。网络结构: 7-15-1, 训练精度设置为 0.0001, 网络隐层取小波网络工具箱函数 “wavenet_tool”, 输出层选择 “purelin” 函数, 采用 “trainlm” 算法进行训练。初始条件经实验设置为 $Q = 9$, 即采用命令 rand(‘state’, 9) 初始化小波网络参数, S30 的预测结果如图 3 所示, 详细信息如表 1 所示。表 1 同时给出了 S31 ~ S37 的预测结果及在相同条件下 BP 网络的预测结果以进行对比。

表 1 小波包分解子序列预测结果

小波包子序列	指标	WNN			网络结构, Q 值选择, 精度设置
		工具箱	BP 工具箱	工具箱	
S30	预测精度/%	0.373 0	3.213 6		7-15-1
	最大精度/%	2.111 2	8.274 3		$Q = 9$
	训练和预测时间/s	1.423	1.3653		0.000 1
S31	预测精度/%	83.495	453.16		7-15-1
	最大精度/%	2 297.0	25 217		$Q = 5$
	训练和预测时间/s	1.400 6	1.285 6		0.000 1
S32	预测精度/%	32.042	256.53		7-15-1
	最大精度/%	316.83	3 483.3		$Q = 18$
	训练和预测时间/s	1.336 4	1.288 3		0.000 1
S33	预测精度/%	86.246	276.30		7-15-1
	最大精度/%	1 665.7	4 264.8		$Q = 24$
	训练和预测时间/s	1.408 4	1.244 8		0.000 1
S34	预测精度/%	19.738	413.92		7-15-1
	最大精度/%	317.27	9 526.0		$Q = 11$
	训练和预测时间/s	1.284 2	1.456 1		0.000 1
S35	预测精度/%	56.092	230.40		7-15-1
	最大精度/%	736.73	3 539.7		$Q = 12$
	训练和预测时间/s	1.250 5	1.255 0		0.000 1
S36	预测精度/%	45.038	465.06		7-15-1
	最大精度/%	1 560.1	24 253		$Q = 6$
	训练和预测时间/s	1.262 7	1.466 0		0.000 1
S37	预测精度/%	94.810	137.10		7-15-1
	最大精度/%	1 467.1	3 774.2		$Q = 2$
	训练和预测时间/s	1.347 2	1.250 5		0.000 1
重构	预测精度/%	3.184 3	15.617 4		

类似于 S30, 对 S31 ~ S37 子序列作同样处理。 Q 值的确定方法: 范围一般取 $0 \leq Q \leq 20$ 即可满足要求, Q 取整数, 值,

通过逐一测试, 或以预测精度为性能指标编程优化确定。预测结果如图 4 ~ 10 所示, 各图均为实际值和预测值对比。从结果可以看出, 子序列中, S30 的预测精度最高, 为 0.373 0%, S30 的最大预测精度为 2.111 2%, 该预测结果可重复。图 3 可以说明小波网络工具箱具有很强的拟合与泛化能力, 其余子序列图形表明 WNN 工具箱方法对高频信号的适应能力也很强, 并且比 BP 网络要好得多。在本方法中 S30 的预测精度很重要, 它在信号重构时占主要成分。




图 3 S30 预测结果




图 4 S31 预测结果




图 5 S32 预测结果




图 6 S33 预测结果

当各子序列预测之后, 即可进行小波包重构, 结果如图 11 所示, 该图是总预测结果实际值与预测值的对比。最终预测精度为 3.144 4%, 最大预测精度为 -14.352 2%, 重构所需时间为 0.873 1 s。BP 网络重构后的总的预测精度为 15.617 4%, 最大预测精度为 39.170%。

表 1 中最后一列给出了网络结构、 Q 值 (BP、WNN) 及训练预测精度设置。

对表 1 的几点说明如下:




图7 S34 预测结果




图8 S35 预测结果




图9 S36 预测结果




图10 S37 预测结果




图11 小波包重构后的预测结果

1) 表1中预测精度结果可重复实验获得,训练时间不可重复,但其波动很小,可忽略其影响。

2) 表1中BP网络预测是在与小波神经网络相同的实验条件下得出的,因此其预测结果也是确定的。 Q 值是针对WNN的优化值,对BP来说不一定最优的。

3) 表1中有些高频子序列预测精度很差,似乎难以理解,但这并不意味着总的预测精度低,它们的精度越高则总的预

测精度会提高。

4) 神经网络属于数据驱动模型,对数据有较大依赖性。同样,小波网络预测结果与数据样本质量也有很大关系,不同的数据可能获得不同的预测结果。

训练和预测时间的计算:8个子序列训练和预测,共计用时10.713 s,重构预测用时0.8731 s,总计耗时11.5861 s,其中不含操作时间。这要比程序编写的BP、WNN神经网络速度高得多,而且基于编程的BP、WNN由于有局部极小等原因有时很难训练出来。

利用编程实现的WNN1对S30的预测实验。编程实现的WNN1网络结构:7-15-1,学习速率为0.3,动量因子为0.02。当训练精度设为0.003时,绝对平均预测精度为1.5078%,最大精度6.4080%,训练和预测所需时间为12.3387 s。所有的子序列当训练精度设为0.0001时均难以训练。S31~S37训练精度设为0.05时可以达到训练精度要求,但预测精度很差,表明编程实现的WNN与小波网络工具箱性能相差较大。

8 结语

随机性是神经网络预测方法的自然特性,本文通过对紧致性小波神经网络工具箱的研究,利用选择 Q 值的初始化命令使预测模型的随机性转化为具有确定性,是对小波神经网络预测理论的一种拓展。对瓦斯涌出量的小波包-小波网络预测实例表明,该方法既有小波函数特征提取能力,又有BP网络工具箱的一系列优势,而且训练速度快、操作方便,尤其适合于大批量数据的训练和处理,数据适应能力和鲁棒性强,具有灵活、实用性强等特点。通过控制参数 Q 获得最佳预测值,比遗传算法、粒子群等优化算法方便。本文方法对小波神经网络的推广应用具有实际意义。

参考文献:

- [1] 郑小平,高金吉,刘梦婷.事故预测理论与方法[M].北京:清华大学出版社,2009:210-212.
- [2] 陈果.神经网络模型的预测精度影响因素分析及其优化[J].模式识别与人工智能,2005,18(5):528-534.
- [3] 杨伟,倪黔东,吴军基. BP神经网络权值初始值与收敛性问题研究[J].电力系统及其自动化学报,2002,14(1):20-22.
- [4] 魏海坤,徐嗣鑫,宋文忠.神经网络的泛化理论和泛化方法[J].自动化学报,2001,27(6):806-815.
- [5] 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:自然科学版,2003,31(2):77-79.
- [6] 陈哲,冯天瑾,张海燕.基于小波神经网络的混沌时间序列分析与相空间重构[J].计算机研究与发展,2001,38(5):591-596.
- [7] 罗航,王厚军,龙兵.基于“紧致型”小波神经网络的时间序列预测研究[J].计算机应用研究,2008,25(8):2366-2368.
- [8] 雷明,崇昭,郭文艳,等.非线性时间序列的小波分频预测[J].物理学报,2005,54(5):1988-1993.
- [9] 王永林.小波神经网络训练研究及在织物预测中的应用[J].信息技术,2010,27(12):1637-1640.
- [10] 姜文忠,霍中刚,秦玉金.矿井瓦斯涌出量预测技术[J].煤炭科学技术,2008,36(6):1-4.
- [11] 飞思科技产品研发中心.小波分析理论与Matlab 7实现[M].北京:电子工业出版社,2006:116-117.
- [12] 常松,何建敏.小波包与神经网络相结合的股票价格预测模型[J].东南大学学报:自然科学版,2011,31(5):90-95.
- [13] 王一莉.瓦斯涌出量预测方法及其应用研究[D].南京:南京工业大学,2005:33-37.
- [14] 殷光伟,郑丕涛.复杂系统状态预测的小波包方法[J].山东大学学报:工学版,2005,35(4):105-108.
- [15] 雷霆,余镇危.一种网络流量预测的小波神经网络模型[J].计算机应用,2006,26(3):526-528.