

太阳黑子数的小波包-小波网络混沌时序预测

潘玉民 张晓宇 张全柱

(华北科技学院信息与控制技术研究所 北京 101601)

摘要 太阳黑子是表征太阳活动的重要现象,影响地球、人体乃至生命环境。针对影响太阳黑子的因子难以确定的问题,引入小波包和混沌相空间重构子序列揭示太阳黑子时间序列的动力学及物理规律。该方法采用小波包分解原始时间序列,用混沌相空间重构恢复影响因子,并采用小波神经网络预测子序列,再经小波包重构获得太阳黑子的最终预测结果。其中小波神经网络采用自行开发的工具箱,其具有方便、收敛速度快、数据吞吐量大、预测精度高以及实用性强等特点,对推广小波神经网络应用具有重要作用,并为太阳黑子数的预测提供了一条新途径。

关键词 太阳黑子,小波神经网络,工具箱,小波包,混沌,预测

中图分类号 TP18 **文献标识码** A

Chaotic Time Series Prediction of Sunspots Number with Wavelet Packet-wavelet Neural Network

PAN Yu-min ZHANG Xiao-yu ZHANG Quan-zhu

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

Abstract Sunspot is an important phenomenon of the solar activity, and it is influencing the earth, human beings and the life environment. Because it is hard to identify the factors impacting the sunspots, we introduced the wavelet packet and chaos phase space reconstruction the subsequence, to find out the dynamics and physical laws of the sunspots time series. The method decomposes the original time series by wavelet packet, restructures and recovers the impact factors, predicts the subsequence by wavelet neural network toolbox and gets the final prediction result of the sunspots by wavelet packet restructure. The wavelet neural network is developed by myself, which is convenient with fast convergence speed and great data-processing capacity and is accurate in prediction with strong practicality. The method plays an important role to the promotion of using wavelet neural network, which provides a new way to predict the number of sunspots.

Keywords Sunspots, Wavelet neural network, Toolbox, Wavelet packet, Chaotic, Prediction

1 引言

太阳黑子是太阳表面非常显著的现象,也是很多太阳耀斑和太阳风暴产生的发源地^[1]。太阳黑子是太阳光球层发生的一种炽热气体的巨大漩涡,温度大约为 4500℃,因为比太阳的光球层表面温度要低,所以看上去像一些深暗色的斑点,故称为太阳黑子。

太阳黑子相对数的变化一般被认为是太阳活动水平的一个重要指标,因此,对太阳黑子数序列及其预测方法的研究一直是这一领域的一个重要课题^[2]。与人类早期预报地球上灾难性飓风类似,人类目前主要依靠对太阳黑子周期的预报来监测太阳风暴的强度以及可能对地球产生的影响。迄今为止,导致太阳黑子数变化的影响因子仍很难获取,目前的预测方法主要是对已有的观测数据采用时间序列预测法。

时序预测法有传统的线性预测法和非线性预测法,线性预测法有 AR 预测模型、ARMA 预测模型和 Markov 链等。

由于太阳黑子的年、月平均活动数据被认为是典型的非线性、非高斯分布、非平稳的时间序列^[3],通常具有混沌特性,因此采用线性预测无法取得满意的预测效果。

目前,神经网络被认为是非线性预测的最佳解决方案,它提供了解决复杂问题的基本途径。但神经网络应用于太阳黑子数的预测研究的文献目前还较少:文献[3]采用小波神经网络对太阳黑子年平均活动序列进行预测,明显提高了预测精度;文献[4]提出了一种时变阈值过程神经网络的时间序列预测模型;文献[5]采用 RBF 网络对未来太阳黑子数月均值进行预报;文献[6]针对 BP 神经网络,以太黑子数据为例,分析了网络预测拓扑结构及网络允许的训练误差对其预测能力的影响等。

但是,神经网络在应用于预测时存在的问题是:网络结构目前尚无统一的设计方法;预测结果具有随机性;过度拟合现象;局部极小;隐层节点数选取和初始权值的设置等问题。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

到稿日期:2012-05-20 返修日期:2012-12-13 本文受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)资助。

潘玉民(1958-),男,硕士,副教授,主要研究方向为复杂系统建模、系统仿真,E-mail: pym_001@ncist.edu.cn;张晓宇(1978-),男,博士,副教授,主要研究方向为模糊控制、滑模控制、复杂系统建模;张全柱(1965-),男,博士后,教授,主要研究方向为风力发电、电力电子技术、电气传动。

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。

神经网络预测结果的随机性,在目前的文献中鲜有讨论。随机性是指神经网络多次预测结果不相同,也是神经网络预测模型特有的现象。一般是进行多次实验进行评价,但这样处理其完备性很难保证,如果将其中一次最好的结果确定为最终模型并进行后续预测,则训练样本必须具有广泛的典型性,否则当检验样本与训练过的样本相关性较差时,模型的有效性会降低。

笔者经过大量的预测实验表明:当神经网络结构确定后,即网络输入层、隐层、输出层神经元个数确定后,预测结果取决于网络参数的初始值。如果初始值设置为确定值,则预测结果就是唯一的。通常在设计神经网络时将初始值设为随机数,它是导致预测结果随机的本质原因。但是,对于众多的网络参数采用人工确定几乎是不可能的。近年来,出现的遗传算法、粒子群算法以及混沌优化算法等是优化初始化参数的有效方法,但对于具有多个网络的模型其工作量也是很可观的,而且优化算法也并非一次能获取最优值。

基于上述原因,提出了一种太阳黑子的小波神经网络工具箱预测方法,其实现了神经网络确定性预测,即预测结果具有可重复性。相对于编程实现的小波神经网络,该方法可以大幅度提高预测精度和预测效率,而且使用方便、快速,尤其适合于大规模数据的训练。

由于目前太阳黑子数预测可利用的主要是一维历史观测数据,因此,如何从中提取更多的信息就显得更加重要。从结果出发,尽管人们不能完全掌握引起太阳黑子数变化的各种影响因子的时间序列,但是在太阳黑子一维时序观测数据中已经包含了诸多相关因素作用的结果。

本文从以下两方面考虑:频率特征量的提取和相空间重构获取等价的多影响因子。引入小波包分解对太阳黑子时间序列进行高低频精细分解。众所周知,频率特性也是一个重要的数学模型,利用小波包变换能获得完备的频率特征物理量。另一方面,引入混沌理论对小波包变换后的不同频段子序列进行混沌特性分析,对不具有混沌特性的子序列,采用一般神经网络预测法;如子序列具有混沌特性,则进行相空间重构,恢复出子序列对应系统的动力学特征,即给出与子序列等价的高维系统,恢复多影响因子,这一点对太阳黑子数的预测来说尤其重要。用不同的小波神经网络对各子序列重构的相空间进行预测,再将各子序列的预测结果进行小波包重构,得到最终的预测结果。

本文采用小波包分解太阳黑子时间序列,对于低频子序列,一般 BP 网络即可适应,而对于高频随机子序列的预测,实验表明其适应能力很差,同时会引起较大的预测误差。本文采用的小波神经网络工具箱将优于 BP 网络工具箱和编程实现的小波神经网络,可以获得确定的预测结果,能很好地解决高频随机序列的预测问题,而且训练速度快、预测准确。借助神经网络非凡的非线性函数逼近能力,通过学习历史输入/输出数据样本,特别是小波神经网络特征提取能力,自动提取其中蕴含的基本规律,反映系统的非线性系统的动力学特性,对太阳黑子预测无疑是有利的。

目前,在统计学文献中,太阳黑子时间序列被当作评价和比较新预测方法的一个标准序列,许多研究都以此来检验神

经网络方法的效果^[7]。

2 小波包变换理论

小波变换只能在固定的频率空间上分解,缺乏灵活性,存在着在时间分辨率高时频率分辨率低的缺陷,这就有可能导致某些频率空间中反映系统状态征兆特征的信息丢失,而小波包能够克服上述缺陷。小波包是小波变换的进一步发展,能提供比小波变换更高的分辨率,是一种更精细的分解方法。

2.1 小波包理论

设 $\{V_j, j \in Z\}$ (Z 是整数集) 构成 $L^2(R)$ (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^[8]:

$$\begin{cases} \varphi(t) = \sqrt{2} \sum_{k \in Z} h(k) \varphi(2t-k) \\ \psi(t) = \sqrt{2} \sum_{k \in Z} g(k) \varphi(2t-k) \end{cases} \quad (1)$$

式中,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。

双尺度方程形式表明:小波基 $\psi(t)$ 可以由尺度函数 $\varphi(t)$ 的平移和伸缩的线性组合获得,其构造归结为滤波器 $H(\omega)$ ($h(k)$ 的频域表示) 和 $G(\omega)$ ($g(k)$ 的频域表示) 的设计。

将尺度空间 V_j 和小波子空间 W_j 用新空间 U_j^0 表示,即 $U_j^0 = V_j, U_j^1 = W_j, j \in Z$, 则 Hilbert 空间的正交分解 $V_{j+1} = V_j \oplus W_j$ 即可用 U_j^0 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^{n-1} 是函数 $w_{n-1}(t)$ 的闭包空间。对于固定尺度的情况,定义递归函数关系:

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

式中, $n=0, 1, 2, \dots, N$ 。当 $n=0$ 时,

$$\begin{cases} w_0(t) = \sqrt{2} \sum_{k \in Z} h(k) w_0(2t-k) \\ w_1(t) = \sqrt{2} \sum_{k \in Z} g(k) w_0(2t-k) \end{cases} \quad (3)$$

2.2 小波包分解与重构

设 $g_l^j(t) \in U_j^l$, 则 g_l^j 可以表示为 $g_l^j(t) = \sum_i d_i^{j,n} u(2^j t - l)$

小波包分解算法:

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

$$\begin{cases} d_i^{j,2n} = \sum_k a_{k-2i} d_k^{j+1,n} \\ d_i^{j,2n+1} = \sum_k b_{k-2i} d_k^{j+1,n} \end{cases} \quad (4)$$

小波包重构算法:

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

$$d_i^{j+1,n} = \sum_k [h_{i-2k} d_k^{j,2n} + g_{i-2k} d_k^{j,2n+1}] \quad (5)$$

小波包算法对小波变换中没有细分的高频部分进一步分解,同时能够根据被分析信号的特征,自适应地选择相应频带,使之与信号谱相匹配,进一步提高了时频分辨率,因而能够捕捉到不同频率空间中反映系统状态征兆特征的信息。因此应用小波包精细分解进行复杂系统状态预测,能够提高预测的准确性。

3 小波包-小波神经网络预测模型

本文提出的小波包-小波神经网络工具箱预测模型如图

1 所示。




图1 小波包-小波神经网络预测模型

图1中,原始太阳黑子时序采用小波包3层分解,利用db4小波基,得到低频到高频8个频率成分S30,S31,...,S37。然后对8个子序列进一步分析,以确认其是否具有混沌特性,如存在混沌特性,则应用混沌理论分别建立预测模型,再分别采用小波神经网络工具箱进行预测,即图1中的WNN1,WNN2,...,WNN8。最后,基于小波包理论将混沌模型预测的结果予以小波包重构,获得总的预测结果。

3.1 太阳黑子序列的小波包分解

实验数据来源于文献[9],为1750年1月-2000年12月的3012个太阳黑子月平均数据,取其中后2000个数据为研究对象。数据序列进行三层分解,如图2所示。




图2 3层小波包分解树

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,对高频部分也同样作进一步分解。在这里只对第3层分解得到的所有时间序列进行研究,则原始序列S可表示为

$$S = AAA_3 + DAA_3 + ADA_3 + DDA_3 + AAD_3 + DAD_3 + ADD_3 + DDD_3 \quad (6)$$

原始信号S及小波包分解子序列如图3所示,其中SSN表示太阳黑子数。




图3 原始信号及小波包分解

图3中,S30,S31,...,S37分别表示应用小波包分解后得到的第三层从低频到高频8个频率成分的时间序列。目前文献中小波包分解在故障诊断中应用较多,而在预测领域应用很少,主要原因是一般神经网络难以适应高频信号的预测,而本文方法不存在这个问题。

3.2 小波神经网络

小波神经网络(wavelet neural network, WNN)是小波变换和神经网络的有机结合,兼有小波变换时频局部性质和神经网络自学习、容错能力等优点,具有很强的自适应分辨性和良好的容错能力。该网络引入了2个新的参变量,即伸缩因子和平移因子,因此具有比一般神经网络更多的自由度,具有更灵活有效的函数逼近能力,并具有较快的学习速度。

小波神经网络结构如图4所示,网络结构为m-n-q。其中 $x_i (i=1,2,\dots,m)$ 为网络输入变量, $y_i (i=1,2,\dots,q)$ 为网络输出。 $\psi_i(t)$ 为小波基函数,其中, $i=1,2,\dots,n$ 。 w_{ij} 、 w_{jk} 为输入层/隐层、隐层/输出层之间的连接权。




图4 小波神经网络结构

在图4中,通过对 $\psi(t)$ 小波基函数做尺度伸缩和平移,得到基小波函数族,即

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right) \quad (7)$$

式中, $a,b \in R, a \neq 0$ 。 a 和 b 分别为伸缩、平移尺度因子。小波变换为

$$(W_{\psi}f)(a,b) = \langle f(t), \psi_{a,b}(t) \rangle = \int_{-\infty}^{\infty} f(t) \psi_{a,b}^*(t) dt \quad (8)$$

式(8)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^[10]。 $\psi(x)$ 通常取 Morlet 小波,表达式为

$$\psi(x) = \cos(1.75x) \exp(-x^2/2) \quad (9)$$

对样本的输入输出样本,定义

$$J = \frac{1}{2} \sum_{j=1}^n \sum_{i=1}^n (\hat{y}_i^j - y_i^j)^2 \quad (10)$$

式中, P 是样本个数, \hat{y} 是WNN的输出, y 为实际测量值。输出取 Sigmoid 函数,即 $f(x) = 1/(1 + e^{-x})$ 。于是 y 的表达式为

$$y(k) = f\left(\sum_{i=1}^n w_{jk} \psi\left(\frac{\sum_{i=1}^m w_{ij} x_i - b_j}{a_j}\right)\right) \quad (11)$$

$$j=1,2,\dots,n; k=1,2,\dots,q$$

$$w_{ij}(k) = w_{ij}(k-1) - \eta \frac{\partial J}{\partial w_{ij}} + \alpha \Delta w_{ij} \quad (12)$$

$$w_{jk}(k) = w_{jk}(k-1) - \eta \frac{\partial J}{\partial w_{jk}} + \alpha \Delta w_{jk} \quad (13)$$

$$a(k) = a(k-1) - \eta \frac{\partial J}{\partial a} + \alpha \Delta a \quad (14)$$

$$b(k) = b(k-1) - \eta \frac{\partial J}{\partial b} + \alpha \Delta b \quad (15)$$

式(12)一式(15)中, η 为学习速率, α 是动量因子, $\eta, \alpha \in [0, 1]$ 。通过调整 WNN 的各参数使式(10)最小化。

3.3 小波神经网络工具箱

在 MATLAB 环境中开发小波网络工具箱的基本思路是:以 BP 网络工具箱的强大功能作为平台,将小波函数移植到 BP 网络中,优势互补。目前, MATLAB 软件新版本虽然具有 wavenet 函数可以产生小波网络,但是远没有 BP 网络工具箱使用方便。BP 网络工具箱训练速度快、功能强、操作方便,训练方法也有多种算法可选择,因此得到了广泛应用。通过对 BP 工具箱的改造实现小波网络功能。如实现 Morlet 小波算法,可以在 BP 网络工具箱的基础上,将 tansig、logsig 等函数作为一个模板进行编程,将其替换为 Morlet 函数及其导数:

$$y = \cos(1.75x) \times \exp(-x^2/2) \quad (16)$$

$$\begin{aligned} dy/dx = & -x \cos(1.75x) \times \exp(-x^2/2) - \\ & 1.75 \sin(1.75x) \times \exp(-x^2/2) \end{aligned} \quad (17)$$

这样处理存在的问题是只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,可以将其等效后并入连接权和阈值调节中^[11]。

$$\begin{aligned} \psi_{a,b} \left(\sum_{i=1}^n w_{ij} x_i^p + \theta_h \right) &= \psi \left(\frac{\sum_{i=1}^n w_{ij} x_i^p + \theta_h - b_h}{a_h} \right) \\ &= \psi \left(\sum_{i=1}^n \frac{w_{ij}}{a_h} x_i + \frac{\theta_h - b_h}{a_h} \right) = \psi \left(\sum_{i=1}^n w_{ij}' x_i + \theta_h' \right) \end{aligned} \quad (18)$$

式中, $w_{ij}' = \frac{w_{ij}}{a_h}$, $\theta_h' = \frac{\theta_h - b_h}{a_h}$ 。

式中, θ_h 为隐层神经元的阈值, $h=1, 2, \dots, n$ 。因此,权值和阈值包含伸缩因子和平移因子的功能。于是可采用 MATLAB 神经网络工具箱,其与普通 BP 网络一样训练小波神经网络,如采用训练函数:“trainlm”;输出层神经元激活函数采用“purelin”、“logsig”或“tansig”等。

上述小波工具箱进行预测实验时,从统计结果上看效果略好于 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差异不明显,因此该工具箱意义不大,体现不出小波神经网络的优越性。为此,本文采用命令 rand('state', Q) 来获得稳定的预测结果,其中 Q 是自定义的控制参数,在这里不代表品质因数,而是表示网络预测性能。Q 的取值需要通过实验加以确定,该函数可以再现曾经产生过的随机数,通过改变 Q 值可以得到较好的小波网络初始值。

4 预测模型实现

按前述方法分别对各子序列建立混沌相空间,以及小波神经网络预测模型。相空间重构的关键是确定延迟时间和饱和嵌入维数。

4.1 子序列混沌特性分析

在重构相空间的过程中,延迟时间 τ 的选择很重要。相空间延迟时间的选取方法主要有自相关法、互信息法、C-C 法等。本文子序列的延迟时间计算采用文献[12]中的互信息法,即利用绘制的互信息 $I(\tau)$ 与 τ 的关系曲线,第一次达到最小小时的滞时可以作为相空间重构的时间延迟 τ 。

嵌入维数采用文献[13]中的 Cao 氏法确定,该方法具有小数据量等诸多性质。采用李雅普诺夫指数法确定最大 Lyapunov 指数^[14],根据 $L(t_i) = \min_{j \neq i} [\| Y(t_i) - Y(t_j) \|]$, $i, j = 1, 2, \dots, p$ 求得欧氏空间意义上 $Y(t_i)$ 的最邻近点 $Y(t_j)$, 计算两点间距离为 $L(t_i)$ 。最后求得最大 Lyapunov 指数,即

$$\lambda = \frac{1}{p-1} \frac{1}{\tau} \sum_{i=1}^{p-1} \ln \frac{L(t_{i+1})}{L(t_i)} \quad (19)$$

计算各子序列 S30-S37 的饱和嵌入维数 m 、延迟时间 τ (见表 1),经计算, Lyapunov 指数分别为 0.1318、0.1498、0.2480、0.1125、0.0541、0.1137、0.3141、0.1721,均大于 0,因此都具有混沌特性。根据 S30-S37 各自的饱和嵌入维数、延迟时间重构对应的相空间,即

$$\begin{aligned} y(i) &= [x(i), x(i+\tau), \dots, x(i+(m-1)\tau)] \\ i &= 0, 1, 2, \dots, n-(m-1)\tau \end{aligned}$$

式中, $N = n - (m-1)\tau$ 表示向量序列的有效长度。重构的状态空间的每个分量都具有 m 个元素。

4.2 预测实验

实验环境: MATLAB R2006 b。小波神经网络输入层神经元取各自的饱和嵌入维数,隐层神经元个数取 $2m+1$, m 为饱和嵌入维数,输出层神经元均设计为一个,即单步预测,小波神经网络结构为: $m(2m+1)-1$ 。在仿真时除了 WNN1 的训练精度设为 0.001,其余均为 0.005。

对 S30 序列,由于 $\tau=19, m=3$,从 S30 的 2000 个数据中取前 1500 构建训练样本,重构获得 1461 个训练样本,后 500 个数据组成 461 个检验样本。对应的 WNN1 结构为 3-7-1,经试验证明,针对 WNN1 的 $Q=17$,训练 3 步即可达到 0.001 的精度要求,绝对平均预测精度为 2.5401%,如表 1 所列。

表 1 各子序列对应的训练和预测结果

小波包子序列	类别	WNN 工具箱	BP 工具箱	网络结构 Q 值选择最大精度
S30	①	$\tau=19, m=3$	$\tau=19, m=3$	3-12-1
	②	2.5401%	10.7415%	Q=17
	③	0.4885s	0.7267s	12.5915%
S31	①	$\tau=3, m=5$	$\tau=3, m=5$	5-12-1
	②	103.5810%	134.7427%	Q=9
	③	0.8526s	2.7209s	8550.2%
S32	①	$\tau=1, m=7$	$\tau=1, m=7$	7-12-1
	②	83.7349%	77.2484%	Q=20
	③	0.7824s	0.6441s	5794.6%
S33	①	$\tau=2, m=7$	$\tau=2, m=7$	7-12-1
	②	127.7064%	243.0069%	Q=12
	③	0.7020s	0.7056s	3836.9%
S34	①	$\tau=6, m=6$	$\tau=6, m=6$	6-12-1
	②	67.1353%	237.2186%	Q=20
	③	0.6551s	0.6049s	6355.3%
S35	①	$\tau=2, m=7$	$\tau=2, m=7$	7-12-1
	②	97.2741%	237.5403%	Q=13
	③	1.0667s	0.5747s	2939.4%
S36	①	$\tau=1, m=3$	$\tau=1, m=3$	3-12-1
	②	118.5692%	353.0019%	Q=15
	③	0.7004s	1.3679s	6015.9%
S37	①	$\tau=2, m=3$	$\tau=2, m=3$	3-12-1
	②	295.4412%	331.9787%	Q=6
	③	0.9237s	0.5131s(0.05)	1239.0%
总计	②	2.6081%	9.4296%	

预测精度计算方法:采用平均绝对百分比误差 (Mean Absolute Percentage Error, MAPE) 评价模型预测性能:

$$\sigma_{MAPE} = \frac{1}{N} \sum_{i=1}^N \frac{|x_i - \hat{x}_i|}{x_i} \times 100\% \quad (20)$$

式中, x_t 为实际值, x'_t 为预测值, N 为检验样本数。在仿真实验过程中, 需用 `rand('state', Q)` 指令对各子序列进行控制和调节, 通过该命令可以获得唯一的预测值。其功能是: 重置生成器到原来的状态, 表示随机产生数的状态 `state`。状态 `state` 的作用是产生与前面某个状态相同的随机数。

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 设置为不同的状态将得到不同的计算结果, 但同时也是唯一的计算结果, 这一点正是其价值所在。几种表达式的含义如下:

`RAND('state', 0)`: 重置生成器为初始状态;

`RAND('state', S)`: 重置生成器为其第 S 个状态;

`RAND('state', J)`: 对整数 J , 重置生成器为其第 J 个状态。

应用 `rand('state', Q)` 指令进行实验, 可以使网络预测结果具有可重复性, 以实现不同网络在相同条件下的比较, 这对预测问题来说是至关重要的。 Q 值的选取通过实验确定, 即将预测误差的绝对平均值作为性能指标, 确定合适的 Q 值。

表 1 中: 符号①表示延迟因子和饱和嵌入维数; ②为绝对平均预测精度; ③为训练和预测时间之和。表中最后一列给出了网络结构、 Q 值及 WNN 工具箱的最大预测精度。

由表 1 可知, 除了 S30 预测精度较高之外, 其余精度均较差, 这并不意味着小波包重构后总的精度低, 但是这些子序列的预测精度越高, 则总的精度会越高。各子序列预测结果如图 5—图 17 所示, 各图中, “—”代表实际值, “*”表示预测值。图 6、图 8 分别是 S30、S31 的混沌吸引子示例, 显然该序列具有比较规则的奇怪吸引子结构。嵌入定理指出, 混沌时间序列内部具有确定的规律性, 其重构出的混沌吸引子的相空间具有高精度短期预测性^[15]。




图 5 S30 序列实际值和预测值




图 6 S30 序列的混沌吸引子




图 7 S31 序列实际值和预测值




图 8 S31 混沌吸引子




图 9 S32 序列的实际值和预测值




图 10 S33 序列实际值和预测值




图 11 S34 序列实际值和预测值




图 12 S35 序列实际值和预测值




图 13 S36 序列实际值和预测值




图 14 S37 序列实际值和预测值




图 15 重构后的实际值和预测值




图 16 预测精度





图 17 编程实现的小波网络预测 S30



由于各子序列的延迟因子、饱和嵌入维数不同, 因此, 相应的子序列预测数据的长度也不同, 按子序列的顺序, 数据长度分别为 461、487、493、487、469、487、497、495 个。故应按其中最长的 S30 的 461 个数据来进行小波包重构。461 个预测数据对应原始序列 2000 个数据中的第 1540~2000 个数据, 对应时间为 1962 年 8 月—2000 年 12 月。重构后的预测结果如图 15 所示, 是实际值和预测值的对比, 图 16 为总预测精度。

由图 16 的数据计算可知, 小波包重构后的最终的绝对平均预测精度 $\sigma_{MAPE} = 2.6081\%$, 最大精度为 13.3965%。在 461 个数据中, 预测精度大于 10% 的有 2 个, 大于 5% 的有 34 个, 大于 1% 的有 185 个, 大于 1% 的占 40%。对 BP 神经网络进行同样的实验, 预测精度为 $\sigma_{MAPE} = 9.4296\%$, 最大精度为 30.101%, 预测精度大于 10% 的有 187 个, 大于 5% 的有 296 个, 大于 1% 的有 363 个, 大于 1% 的占 78.7%。显然 WNN 工具箱优于 BP 工具箱预测效果。

编程实现的小波神经网络实验: 网络结构为 $m-12-1$, 学习速率 $\eta = 0.15$, 动量因子 $\alpha = 0.02$ 。当训练精度为 0.5 时 S30 能达到精度要求, 而其余子序列很难训练出来, 也就无法重构。S30 序列的训练、预测结果如图 17 所示, 其中 (a) 为训练曲线, (b) 为实际值和预测值对比。(b) 图的预测精度为

(下转第 267 页)

$buyer_i$ 具有 M_{buyer_j} 。市场中, 每个买者都能够和其他的多个卖者进行交易, 每个交易都相互独立, 这里独立意味着买者必须服从 $D_i = f_i(p) = a_i - b_i p$ 。考虑到这点, 一个买者能够与每个直接相连的卖者进行交易。

$$D_i = \begin{cases} 0, & p_i = 0, \text{ price is not reached} \\ a_i - b_i p_i, & p_i \neq 0, \text{ price is reached} \end{cases}$$

实际在传统的观点上没有考虑买者的竞争。本模型将讨论由于结构所导致的竞争。一个竞争只有当买者或者卖者具有相同的第三方时才能发生。

(a) 如果 $buyer_i$ 和 $buyer_j$ 共享 $buyer_{i,j}$, 则 $buyer_i$ 和 $buyer_j$ 是 $buyer_{i,j}$ 的直接竞争者;

(b) 对于间接竞争者 $buyer_i$ 和 $buyer_j$, 如果其最短路径是无穷的, 则没有可能的线路将 $buyer_i$ 和 $buyer_j$ 连接起来, 即它们不是竞争者。

3) 网络上的卖者




图4 资源紧缺, 理性决策来最大化利益

一个卖者实际上是在交易中克服一定成本通过提供产品来获得回报的参与者。 $-c_j$ 是交易成本。其目标是最大化自

己的利益, 并在多边中建立交易关系。图4表达了, 在市场资源紧缺的情况下, 卖者在交易过程中通过控制成本来决定市场, 以确定目标各个环节的理性决策, 使效益最大化。

结束语 本文基于复杂网络上的社会经济系统的研究给出了一种研究社会和经济系统的新手段。其基本思想是在研究这些系统的时候将系统的结构考虑进来, 将现有的社会经济系统模型再造到复杂网络上, 并将被抽取的社会经济模型重新模拟为更适应现实社会的复杂网络模型加以研究, 对复杂网络上的社会经济系统的研究具有一定的启发作用。

参考文献

(上接第264页)

$\sigma_{MAPE} = 14.6383\%$, 最大精度为 49.0910% , 耗时 $14.088s$ 。显然, 编程实现的小波网络与工具箱实现的小波网络在此没有可比性。因此, 对大规模数据的训练和预测, 本文方法的优越性是明显的。

对原序列的混沌预测实验: 不采用小波包分解, 对原始序列直接进行混沌分析。计算得到: $\tau = 14, m = 7$, Lyapunov 指数 $\lambda = 0.0363 > 0$, 表明原序列具有混沌特性, 用前 1500 个数据产生训练样本, 后 500 个产生检验样本。小波网络结构: 7-12-1。经寻优处理得: 当 $0 \leq Q \leq 20, Q = 12$ 时最好, $\sigma_{MAPE} = 4.0177\%$, 最大精度为 20.9731% ; 扩大 Q 的取值范围, $Q = 60$ 时, $\sigma_{MAPE} = 3.080\%$, 最大精度为 21.9153% , 均不及本文方法。

结束语 利用小波包变换和相空间理论, 提取和重构太阳黑子时间序列的内在本质特征, 通过分析频率特性、影响因子, 构造高维状态空间描述复杂系统, 采用小波神经网络工具箱对太阳黑子数进行预测, 其显著特点是预测速度快、数据吞吐量、预测效率高。

预测实验证明了所提方法的有效性。指出了神经网络预测结果不稳定的本质原因, 并给出了一种确定性的预测方法。其中小波网络工具箱及预测方法, 对于混沌时序预测准确拟合混沌吸引子, 以及对小波神经网络的推广应用具有重要意义, 是太阳黑子数预测的一种有效方法。

参考文献

[1] http://www.bao.ac.cn/xwzx/kydt/201108/t20110819_3324282.html

[1] 房艳君. 动态经济网络结构及其稳定性研究[J]. 经济数学, 2010(3): 92-97

[2] 何土产. 复杂网络基本模型分析[J]. 科技经济市场, 2007(2): 53-57

[3] Latora V, Marchiori M. The Architecture of complex systems [M]. Gell-Mann M, Tsallis C. Nonextensive entropy; interdisciplinary applications. New York: Oxford University Press, 2002: 377-386

[4] 贾秀丽. 一类边同时变化的无标度复杂网络模型研究[J]. 东北师大学报: 自然科学版, 2008(4): 58-62

[5] 包兴海, 姚洪兴. 一类经济系统生命体模型的建立与系统分析[J]. 复杂系统与复杂性科学, 2006(1): 53-58

[2] 柳士俊, 俞小鼎, 陈永义. 太阳黑子活动的守恒量预报[J]. 科学通报, 2003, 48(17): 1832-1835

[3] 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

[4] 丁刚, 钟诗胜. 基于时变阈值过程神经网络的太阳黑子数预测[J]. 物理学报, 2007, 56(2): 1224-1230

[5] 赵海娟, 王家龙, 宗位国, 等. 用径向基函数神经网络方法预报太阳黑子数平滑月均值[J]. 地球物理学报, 2008, 51(1): 31-35

[6] 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

[7] Weigend A B, et al. Predicting the future: a connection -ist approach[J]. Intl. J. Neur. Sys., 1990, 1: 193-209

[8] 飞思科技产品研发中心. 小波分析理论与 MATLAB 7 实现 [M]. 北京: 机械工业出版社, 2006: 116-117

[9] <http://sidc.oma.be/sunspot-data>

[10] 雷明, 韩崇昭, 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

[11] 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

[12] Abarbanel H D I, Masuda N, Rabinovich M I, et al. Distribution of Mutual Information[J]. Physics Letters A, 2001(281): 368-373

[13] Cao Liang-yue, Mees A, Judd K. Dynamics from multivariate time series[J]. Physica D, 1998, 121: 75-88

[14] Wolf A, Swift J B, Swinney H L, et al. Determining Lyapunov exponents from a time series[D]. Physica 16D, 1985: 285-317

[15] 韩敏. 混沌时间序列预测理论与方法[M]. 北京: 中国水利出版社, 2007: 155-157