

太阳黑子活动周期特征的神经网络和小波分析

潘春花, 孙 燕, 朱 存

(青海民族大学 计算机学院, 青海 西宁 810007)

摘 要: 太阳黑子数是描述太阳活动水平的主要指标, 太阳活动直接影响日地环境。依据前人对太阳黑子数的观测资料, 采用 BP 神经网络及小波分析和自相关相结合的方法, 分析了 1770–1869 年的太阳黑子数年均值, 得出了太阳黑子存在 11–12 年周期的结论, 并对该算法及噪声鲁棒性进行了仿真。实验结果表明, 该算法对研究太阳活动的本质规律是有效的。两种方法与其他方法, 如自相关法、功率谱法等, 进行了相比, 不仅得出与实际一致的结论, 而且对噪声有较强的鲁棒性, 这对含噪信号的分析研究是很有意义的。

关键词: 太阳黑子数; BP 神经网络; 小波分析; 自相关; 周期; 鲁棒性

中图分类号: TP391

文献标识码: A

文章编号: 1673–629X(2016)03–0158–04

doi: 10.3969/j.issn.1673–629X.2016.03.037

BP Neural Network and Wavelet Analysis of Period of Sunspot Activity

PAN Chun-hua, SUN Yan, ZHU Cun

(Computer Department of Qinghai University for Nationalities, Xining 810007, China)

Abstract: The sunspot number is the main indicator of the level of solar activity, solar activity directly affects the daily environment. Based on the sunspot number observation data of the predecessor, using BP neural network and wavelet analysis and self integrating method, the 1770–1869 sunspot number mean is analyzed, it is concluded that the sunspots are 11–12 year cycle, and the algorithm and its noise robustness is simulated. The experimental results show that the algorithm is effective for the essential rule of solar activity. Two methods with other methods, such as self correlation method, the power spectrum method, are compared to not only draw the practical conclusions but also have the strong robustness for noise, which is very significant for noise signal analysis.

Key words: sunspot numbers; BP neural network; wavelet analysis; autocorrelation; cycle; robustness

0 引 言

人们对太阳的日常活动进行了长期的观测, 包括太阳黑子数随时间变化的情况, 人们用这些记录研究了太阳的日常活动及太阳对地球环境的影响, 尤其是在太阳黑子数非常活跃年份的预报, 太阳黑子数活跃年份引起的自然灾害及对人类疾病预防等诸多方面都取得了显著的成绩^[1–5]; 但到目前为止, 还没有一个非常完善的理论可以完美地解释黑子的形成, 人们还在不断探索研究太阳活动及黑子的本质及二者形成过程等基本问题。

文中在古人记录的资料^[6–7]的基础上, 使用 BP 神经网络算法, 对 1770–1869 年的太阳黑子数年均值时间序列进行预测分析, 研究太阳黑子数的周期变化的规律, 天文学家把太阳黑子最多的年份称为“太阳活动峰年”, 太阳黑子最少的年份称为“太阳活动谷年”。

文中利用 BP 神经网络和小波分析及自相关研究了太阳黑子峰年周期特征, 并将该算法对加性噪声的鲁棒性进行了仿真。太阳黑子是太阳活动的重要标志, 结果表明该算法对研究太阳活动乃至天体规律是有效的。

神经网络里的单个神经元能够反映神经网络非线性本质特征, 经过多个单个神经元的组合, 神经网络可以反映得到的任意非线性连续函数, 经过自组织自适应学习过程, 进而让神经网络预测训练序列的本质变化规律。神经网络模型具有自适应、自组织及自学习能力, 对外界的干扰不受影响, 在工程上容易实现。

1 BP 神经网络

BP 神经网络又称反向误差传播 (Back Propaga-

tion)神经网络^[8],它是前向型具有多个层次的神经网络,分别具有 sigmoid 隐层和输出层,可以逼近有限个不连续的函数^[9]。

1.1 BP 神经元的结构

图 1 是一个典型的由两层神经元构成的 BP 神经网络。其中,中间层叫隐层,其传递函数为 tansig,线性输出层的传递函数为 purelin。

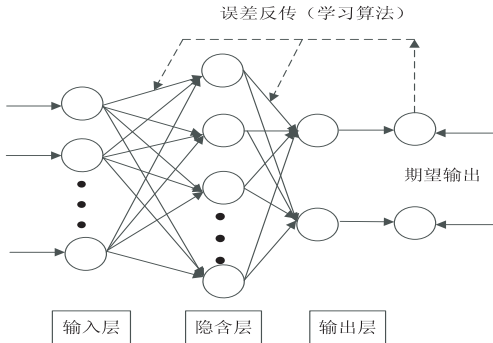


图 1 由两层神经元构成的 BP 神经网络结构

1.2 BP 算法

BP 神经网络的学习过程是在输入层输入向量 p 并期望得到响应 t 在有监督的训练下完成网络的学习。有监督的学习训练过程中,根据误差性能调整神经网络的权值和偏差,最终得到神经网络预期的性能^[10-12]。

其中,误差函数沿着减小最快的方向迭代,计算公式为:

$$x_{k+1} = x_k - a_k g_k \tag{1}$$

其中: x_k 为当前的权值和偏差; x_{k+1} 为迭代产生的下一次的权值偏差; g_k 为当前误差函数的梯度; a_k 为学习速率。

下面以含有两个隐层的 BP 神经网络为例进行推导^[13-14]。设输入层的输入矢量数目为 M ,任意一个矢量用 m 来标记;中间层的第 1 个隐层记为 I ,有 I 个神经元,任意一个神经元用 i 来标记;中间层的第 2 个隐层记为 J ,有 J 个神经元,任意一个神经元用 j 来标记;最后一个层次为输出层,记为 P ,包含 P 个神经元,任意一个神经元用 p 来标记。输入层与中间层的第 1 隐层之间的权值记为 w_{mi} ;第 1 隐层与第 2 隐层之间的权值记为 w_{ij} ;第 2 隐层与输出层的权值记为 w_{jp} 。 u_i^1 表示第 1 隐层第 i 个神经元的输入,输出记为 v 。

训练样本集为:

$$X = [X_1, X_2, \dots, X_N]$$

期望响应为:

$$d_k = [d_{k1}, d_{k2}, \dots, d_{kp}]^T$$

实际输出为:

$$Y_k = [Y_{k1}, Y_{k2}, \dots, Y_{kp}]^T$$

当网络输入训练样本为 $X = [X_1, X_2, \dots, X_N]$,网

络信号以向前的方式传递对于各层的中间值,可以写出表达式:

第 1 隐层第 i 个神经元的输入为:

$$u_i^1 = \sum_{m=1}^M w_{mi} x_{km}$$

第 1 隐层第 i 个神经元的输出为:

$$v_i^1 = f(\sum_{m=1}^M w_{mi} x_{km})$$

输出层第 p 个神经元的输入为:

$$u_p^p = \sum_{j=1}^J w_{jp} v_j^J$$

网络输出为:

$$y_{kp} = v_p^p = f(\sum_{j=1}^J w_{jp} v_j^J)$$

输出层第 p 个神经元输出误差为:

$$e_{kp}(n) = d_{kp}(n) - y_{kp}(n) \tag{2}$$

其中各层之间的权值修改如下:

隐层 J 与输出层 P 之间权值下一次迭代为:

$$w_{jp}(n+1) = w_{jp}(n) + \Delta w_{jp}(n) \tag{3}$$

隐层 I 与隐层 J 之间权值下一次迭代为:

$$w_{ij}(n+1) = w_{ij}(n) + \Delta w_{ij}(n) \tag{4}$$

输入层 M 与隐层 I 之间权值下一次迭代为:

$$w_{mi}(n+1) = w_{mi}(n) + \Delta w_{mi}(n) \tag{5}$$

2 小波分析

设 $\psi(t) \in L^2(\vec{R})$ ($L^2(\vec{R})$ 表示平方可积的实数空间,即能量有限的信号空间),其傅里叶变换为 $\hat{\psi}(\omega)$ 。当 $\hat{\psi}(\omega)$ 满足允许条件(见式(6))时,称 $\psi(t)$ 为基本小波或母小波。

$$C_\psi = \int_{\vec{R}} \frac{|\hat{\psi}(\omega)|}{|\omega|} d\omega < \infty \tag{6}$$

将母小波 $\psi(t)$ 经伸缩和平移后,就可以得到一个 小波序列。对于连续情况,小波序列为:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{|a|}} \psi\left(\frac{t-b}{a}\right), a, b \in \vec{R}; a \neq 0 \tag{7}$$

其中: a 为伸缩因子; b 为平移因子。

对于任意函数 $f(t) \in L^2(\vec{R})$ 的连续小波变换为:

$$W_f(a, b) = \langle f, \psi_{a,b} \rangle = |a|^{-\frac{1}{2}} \int_{\vec{R}} f(t) \psi^*\left(\frac{t-b}{a}\right) dt \tag{8}$$

对于离散情况,小波序列为:

$$\psi_{j,k}(t) = 2^{-\frac{j}{2}} \psi(2^{-j}t - k), j, k \in Z \tag{9}$$

对于任意函数 $f(t)$ 的离散化小波变换系数为:

$$C_{j,k} = \int_{-\infty}^{\infty} f(t) \psi_{j,k}^*(t) dt = \langle f, \psi_{j,k} \rangle \tag{10}$$

其重构公式为：

$$f(t) = C \sum_{j=-\infty}^{\infty} \sum_{k=-\infty}^{\infty} C_{j,k} \psi_{j,k}(t) \tag{11}$$

其中， C 是一个与信号无关的常数。上面各式中的 ψ^* 是 ψ 的复共偶。

3 太阳黑子数时间序列的 BP 神经网络和小波分析

1770–1869 年的太阳黑子数年均值时间序列 (HZS) 及含加性高斯白噪声的 HZS 的时域波形见图 2^[15–16]。




图 2 太阳黑子数时间序列时域波形

BP 神经网络的输入层、隐含层和输出层选取如下：对于 1770–1865 年的数据，选择前 4 年的数据作为序列的输入样本，下一年的数据作为网络的输出，选用 1867 和 1869 年的数据作为检验样本，并对输入向量作归一化处理。构建的 BP 神经网络的隐含层神经元的数目为 12 个。BP 神经网络结构图见图 3^[11–12]。

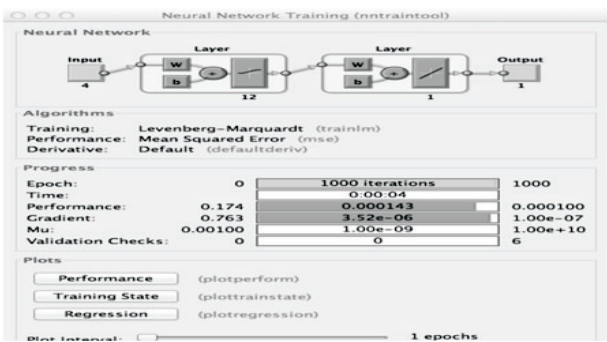


图 3 BP 网络结构图

小波分析与自相关相结合的分析算法主要思想是：

- (1) 对输入信号 HZS 作 5 层小波分解；
- (2) 在不同层估计噪声，依此来调整阈值，且采用斯坦 (Stein) 的无偏似然估计，进行自适应阈值选择；
- (3) 用选取的阈值对小波变换所得系数进行阈值处理，即自动消噪；
- (4) 用小波变换的低频系数和经阈值处理即自动消噪后的高频系数重构信号；
- (5) 将重构信号作自相关，也可以在 1 之后，直接用低频系数对信号进行重构，再作自相关。

算法原理如图 4 所示。




图 4 小波与自相关相结合的算法原理

按照图 4 的算法原理对未加噪的 HZS 进行处理，所得结果如图 5 所示。




图 5 太阳黑子数年均值时间序列的周期性

由图可知:在未加随机噪声的情况下,文中的 BP 神经网络和小波自相关法与直接自相关法以及中心消波自相关法所得结果完全一致;HZS 的各周期大小略有不同,其中第 2 和第 4 周期比其他周期长,第 4 周期在全部 9 个周期中最长;从第 5 周期开始的 5、6、7、8、9 周期似乎是第 1、2、3、4 周期的重复。




图 6 SNR=36 dB 的分析结果

5 结束语

用 BP 神经网络和小波分析与自相关相结合的综合分析法分析太阳黑子活动的周期性,得出这两种算法的结果是可靠的。从图 5 可以看出,神经网络方法的太阳黑子峰年的峰值更清晰,平均周期为 11-12 年,次之是小波分析法,但是神经网络在加噪在 SNR 为 36 时比小波分析法差(见图 6),但仍然可看出峰年。

文中的两种方法与其他方法如自相关法、功率谱法等相比,不仅得出与实际一致的结论,而且对噪声有较强的鲁棒性,这对含噪信号的分析研究很有意义。

参考文献:

[1] 顾圣士,王志谦,程极泰. 太阳黑子数时间序列的分形研究及预测[J]. 应用数学和力学,1999,20(1):79-84.

[2] 李金艳,余英林, Tommy W S Chow. 高阶神经网络与太阳黑子序列[J]. 华南理工大学学报:自然科学版,1997,25(11):28-36.

[3] 黄磊,邵雪梅. 青海德令哈地区近 400 年来的降水量变化与太阳活动[J]. 第四纪研究,2005,25(2):184-192.

[4] 刘长海,陈宇卫,刘义高. 华东地区中强地震与太阳黑子数时间变化的呼应[J]. 地震地磁观测与研究,2003,24(5):57-59.

[5] 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.

[6] Proakis J G, Manolakis D G. Introduction to digital signal processing [M]. New York: Macmillan Publishing Company,

4 对噪声鲁棒性的检验

为了检验文中的 BP 神经网络和小波自相关法对噪声的鲁棒性,对 HZS 加入不同方差的零均值高斯白噪声^[17-18]。

图 6 是信噪比 SNR 为 36 时所得结果。

1988.

[7] Marple S L. Digital spectral analysis with applications [M]. Englewood Cliffs, NJ: Prentice-Hall, 1987.

[8] 朱凯,王正林. 精通 MATLAB 神经网络 [M]. 北京:电子工业出版社,2010.

[9] The Mathwork Inc. Neural network toolbox user's guide (version 4) [M]. [s. l.]: The Mathwork Inc, 2001.

[10] 柯熙政,吴振森. 太阳黑子数的时-频域模型[J]. 中国科学院研究生院学报,1998,15(1):68-73.

[11] 丁玉美. 数字信号处理—时域离散随机信号处理 [M]. 西安:西安电子科技大学出版社,2002:157-158.

[12] 孙燕,姜占才. 太阳黑子活动周期特征的小波自相关分析[J]. 计算机应用与软件,2008,25(6):245-246.

[13] 许东,吴铮. 基于 MATLAB6. x 的系统分析与设计—神经网络 [M]. 西安:西安电子科技大学出版社,2003.

[14] 林坤辉,息晓静,周昌乐. 基于 HMM 与神经网络的声学模型研究[J]. 厦门大学学报:自然科学版,2006,45(1):44-46.

[15] Sarkav D. Methods to speed up error BP learning algorithm [J]. ACM Computing Survey, 1995,27(4):519-592.

[16] 高小榕,杨福生. 采用同伦 BP 算法进行多层前向神经网络的训练[J]. 计算机学报,1996,19(9):687-694.

[17] Yi S. Global optimization for NN training [J]. IEEE Computer, 1996,3:45-54.

[18] Looney C G. Advances in feed forward neural networks, demystifying knowledge acquiring black axes [J]. IEEE Trans on Knowledge and Data Engineering, 1996,8(2):211-226.