

人工神经网络在潮汐预测中应用研究

李明昌, 梁书秀, 孙昭晨*

(大连理工大学 海岸和近海工程国家重点实验室, 辽宁 大连 116024)

摘要: 海洋环境中, 精确预测潮汐是关系到建筑物和人类活动的重要工作. 利用人工神经网络进行单测站潮位和多测站对应潮位预测, 并结合潮汐现象的特点, 提出了在预测之前有针对性的数据处理分析方法——周期分析概念, 并将其应用到实际的潮位预测当中, 实例证明这种方法可以解决潮位预测中存在的时滞问题, 提高了预测的精度. 同时根据不同测站潮汐数据之间的相关性, 以及潮汐数据规律性较强这一特点, 进行了不同潮位测站之间的对应潮位预测, 取得了很好的结果.

关键词: 人工神经网络; 潮汐预测; 周期分析; 时滞

中图分类号: P731.34 **文献标识码:** A

0 引言

海洋潮汐是指海水受天体引力作用产生的一种周期性升降运动, 周期性是其显著的特点. 我国幅员辽阔, 有长 3.2×10^4 km 的海岸线, 沿岸地区是我国经济发展比较迅速的地区, 这些地区的潮汐现象都直接或间接地影响着人民的生产和生活. 因此, 潮汐预测具有广泛而重要的作用^[1].

传统的潮汐预测模型在实践中已得到了大量的应用. Darwin^[2]建立了典型的平衡潮汐理论来描述潮位变量的特征, 其主要特点是, 利用分潮的周期不同对实测资料进行各个分潮系的分离. 然而, Darwin模型不能针对复杂的地形条件作出精确预测. Doodson^[3]利用最小二乘法确定调和常数. 这种调和分析方法得到了广泛的应用, 其主要的缺点是, 需要长期的实测潮位资料去确定调和常数. 近来, Yen等^[4]在有限的已知潮汐资料的基础上应用 Kalman滤波方法来确定调和常数. 然而, 这种方法只能用于短期预测, 而不能用于长期预测.

人工神经网络是一种复杂的非线性信息处理系统. 自1943年, 心理学家 Warren和数理学家 Walter从信息处理的角度出发, 采用数理模型方法提出形式神经元模型(MP模型)以来, 神经网络

方法飞速发展, 现已在模式识别、非线性动力系统的辨识、预报预测等领域得到了广泛的应用并取得了良好的效果. Tsai等^[5]应用这种方法进行了全日潮和半日潮的预测. 同传统的调和和分析潮位预测方法相比, 神经网络的预测方法可以在有限的已知数据基础上进行较高精度的长期、短期预测.

目前利用人工神经网络进行潮位预测的方法大致有以下几种类型: 一种是根据实测潮位数据直接进行神经网络预测^[6-7]; 另一种是在对实测潮位数据进行谱分析的基础之上, 以特征波高(如 $H_{1/3}$ 、 $H_{1/10}$ 等)为依据来进行预测^[8]; 还有一种类似于传统的调和和分析方法, 这种方法以多个潮汐要素为网络输入同实测潮汐数据进行拟合和预测^[9]. 以上几种方法在将人工神经网络应用于潮汐预测中做了大量工作, 并取得了很好的预测效果, 但是, 都存在着一定问题(特别是第一种方法): 预测值时间序列曲线与实际值时间序列曲线相比存在相位差, 即时滞现象. 而产生时滞现象的根本原因是未对网络输入输出的潮位数据进行相应的周期性分析; 未将潮汐现象的规律性与人工神经网络的特点有机地结合. 潮位数据的记录是以小时为时间单位来进行统计的. 但是, 潮位

收稿日期: 2005-09-10; 修回日期: 2006-10-22.

基金项目: 国家自然科学基金资助项目(50509005); 辽宁省自然科学基金资助项目(20032115).

作者简介: 李明昌(1977-), 男, 博士生; 孙昭晨*(1960-), 男, 教授, 博士生导师, E-mail: szc@dlut.edu.cn.

©1994-2015 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

时间序列有规律性,具有一定的周期,因此针对其特点,本文提出对潮位数据资料进行周期性分析来提高预测精度,解决相位差问题.同时,神经网络虽然具有自组织、自适应、自学习能力等优点,但是,现阶段此算法对于网络输入输出数据具有一定程度的依赖性,因此周期性分析(保持网络输入输出时间序列的周期对应性)对于解决相位差问题,提高网络预测的精度是十分必要的.本文以此方式进行潮汐预测预报,以期提高预测的精度和解决相位差(时滞)问题.

1 BP神经网络

本文采用神经网络 BP算法^[10]进行潮位预测. BP网络的一个学习循环包括两个阶段:一是前传,逐层向前传播输入信息;一是反传,根据模拟输出和实际输出的误差,由后向前逐层修改网络权重.

1.1 BP算法

BP算法采用最陡下降法的概念,将误差函数予以最小化.而误差的逆传播是其核心.本文中, BP网络的非线性转换函数采用如式(1)所示的双曲型 Sigmoid函数:

$$f(x) = \frac{1}{1 + e^{-x + \theta}} \quad (1)$$

其中 θ 表示阈值.

算法中采用均方根误差 (R_{mse}) 评价网络的预测能力,其表达式为

$$R_{mse} = \frac{\sum_{i=1}^n (Y_i - \bar{Y}_i)^2}{\sum_{i=1}^n Y_i^2} \quad (2)$$

式中: n 表示样本数; Y_i 表示潮位实测值; \bar{Y}_i 表示潮位的神经网络预测值.

BP算法的收敛特性和收敛速度很大程度上取决于学习率,而且学习率的取值与所研究的具体问题有关.根据潮位时间序列规律性强、易于学习的特点,本文学习速率选为 0.085.

在网络计算前应对相关潮位数据进行预处理,包括两方面:分析潮位数据的规律性、周期性,保证网络输入-输出数据之间的周期对应性;对网络中的所有潮位数据进行统一标准的归一化处理

$$\bar{Y}_i = \frac{Y_i - Y_{\min}}{Y_{\max} - Y_{\min}} \quad (3)$$

式中: \bar{Y}_i 表示归一化后的潮位值; Y_i 表示归一化前的潮位实测值; Y_{\max} 表示所有潮位数据中的最大值; Y_{\min} 表示所有潮位数据中的最小值.

1.2 潮位时间序列预测模型

潮位时间序列以 $\{X_t\}$ 表示,其中 $X_t = X(t)$ ($t = 0, 1, 2, 3, \dots, n$),是指任一时刻的潮位值.而潮位预测的实质是根据其历史数据对现在或未来的值作出预测,即认为时间序列现在和未来的值与其前面的 m 个数据之间存在某种函数关系:

$$x_{n+k} = F(x_n, x_{n-1}, x_{n-2}, \dots, x_{n-m+1}) \quad (4)$$

潮位时间序列的神经网络预测即是利用 BP算法来拟合函数 $F(\cdot)$,然后将其用于时间序列的神经网络预测,而 BP网络的特点恰恰是其能在训练样本的基础之上逼近任意的非线性连续函数^[11-12].

1.3 神经网络预测方法

神经网络的预测方法包括一步预测和多步预测.当式(4)中的 $k = 1$ 时,为一步预测;当 $k > 1$ 时,为多步预测.其中还有在一步预测的基础之上进行预测的方法,称为迭代一步预测^[13],其具体做法为将一步预测的结果 x_{n+1} 反馈给网络作为下一步预测的输入数据.本文提出在多步预测的基础之上迭代一步预测的方法,可称为迭代多步预测.

2 潮位预测

影响神经网络预测精度的因素主要包括:隐含层层数、隐含层节点数、预测方法、拟合误差、迭代步数等.

目前,利用人工神经网络进行潮位预测大多是单测站预测,文献[8]进行了多测站预测方面的研究和实践.本文针对潮汐时间序列的特点就多测站之间对应预测的可行性,做了深入的分析 and 探讨.

2.1 隐含层层数、隐含层节点数对神经网络预测精度的影响

神经网络隐含层层数、节点数与待解决问题的复杂程度有关,对于潮汐现象这种具有明显周期性的时间序列,并不属于复杂问题,所以只需采用一个隐含层即可.隐含层的节点数可用下式计算:

$$N_h = \frac{N_i + N_o}{2} \quad (5)$$

式中： N_h 表示隐含层节点数； N_i 表示输入层节点数； N_o 表示输出层节点数。

表 1 给出了隐含层层数分别为 1 2 时对网络预测精度的影响。虽然增加隐含层的数量可以最大限度地反映一个问题的复杂程度，使网络的训练步数有较大减少，但是从表 1 的数据中可以发现，对于潮位数据这种周期性、规律性比较强的时间序列，隐含层增加对于预测精度的提高并无太大帮助，这也是“过拟合”（overfitness）现象的表现之一，因此采用一个隐含层来解决此类问题是满足要求的，且精度相对较高。

表 1 隐含层层数对网络预测精度的影响

Tab. 1 Effect of number of hidden layers on forecasting precision

隐含层数	E_p	S_i	E_f
1	0.008 900 17	916	< 0.003
2	0.012 490 10	548	

注： E_p 为预测误差； S_i 为循环步数； E_f 为拟合误差

表 2 为隐含层节点数取不同值时对网络预测精度的影响。从表 2 中可以看出利用式 (5) 计算确定的隐含层节点数的网络其误差最小，因此由式 (5) 确定的神经网络隐含层节点数 (50) 一般是最优解，其原因同样可以用“过拟合”理论进行解释。

表 2 隐含层节点数对网络预测精度的影响

Tab. 2 Effect of node number of hidden layer on forecasting precision

N_h	E_p	S_i	E_f
52	0.008 915 66	916	
50	0.008 900 17	916	< 0.003
48	0.009 006 30	937	

2.2 不同类型预测方法对神经网络预测精度影响

神经网络的预测方法对网络预测精度的影响

表 3 不同类型预测方法对网络预测精度的影响
Tab. 3 Effect of forecasting method on forecasting precision

预测方法	E_p	S_i	E_f
一步预测	0.011 639 70	904	
多步预测	0.008 900 17	916	< 0.003

本文中采用的多步预测（有别于文献 [13]）可称为迭代多步预测，是以拟合时网络输出值作为预测时的输入，依此类推，逐步迭代。此方法以下列两式为依据：

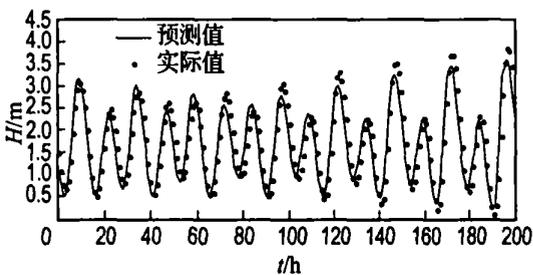
$$\text{拟合 } x_{n+k} = F(x_n, x_{n-1}, x_{n-2}, \dots, x_{n-m+1})$$

$$\text{预测 } x_{n+k+1} = F(x_{n+1}, x_n, x_{n-1}, x_{n-2}, \dots, x_{n-m})$$

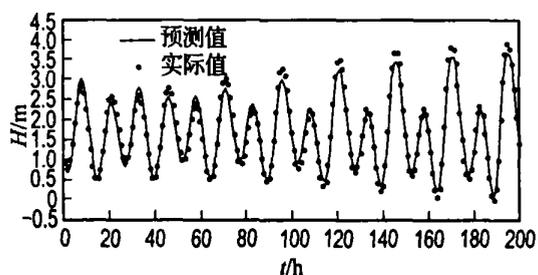
这种预测方法精度较高，因此是时间序列预测工作中保证精度的一种可行方法。

2.3 单测站潮位的预测

针对已有的神经网络潮汐预测方法中存在的时滞现象，作者进行了深入研究，提出了周期分析法，并利用已有的鲅鱼圈的一个月潮位资料进行下一个月潮位的预测。图 1 中工况 1 2 分别是进行周期分析前后的潮位预测曲线。表 4 给出了相应的预测误差。从表 4 中可以看出经过周期分析之后的预测精度要高于周期分析之前的精度。而相位的差异通过对比图 1 中计算工况 1 2 可以明显看出。计算工况 1 中明显存在相位差（时滞）问题。差异的原因是在进行周期分析前，未结合神经网络和潮汐现象各自的特点加以分析，找出拟合和预测两者之间的关系，即网络两次输入输出



(a) 计算工况 1



(b) 计算工况 2

图 1 鲅鱼圈潮位预测值和实测值的比较

Fig. 1 Comparison of tidal level of Bayuquan between forecasting and field data

表 4 周期分析前后神经网络预测精度的比较

Tab. 4 Comparison of pre-periodicity analysis and post-periodicity analysis on forecasting precision

计算工况	是否进行周期分析	E_p	S_i	E_f
1	否	0.044 969 40	5 927	
2	是	0.019 952 40	5 868	< 0.003

时间序列之间的周期对应性,而这种关系对于潮汐预测这种具有明显周期性的时间序列的拟合和预测工作具有决定性的意义.利用本文提出的周期分析方法进行潮汐预测可以达到相当高的精度.

2.4 神经网络预测同传统调和分析方法预测结果的对比

调和分析方法就是根据实测潮位过程推求当地各组成分潮的调和常数,并以此进行潮位时间序列的预测.图 2 是神经网络与调和分析的预测值同实测值之间的比较.

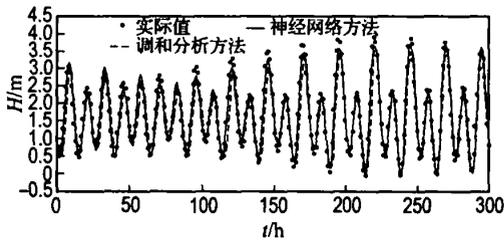


图 2 鲛鱼圈潮位实测值和两种不同方法下预测值的比较

Fig. 2 Comparison of tidal-level of Bayuquan between forecasting data derived from two different methods and field data

由图 2 可以看出神经网络方法解决了调和分析方法中存在的时滞问题,在精度上要优于调和分析方法(神经网络方法的预测误差为 0.019 952 40,调和分析方法的预测误差为 0.131 517 50).

2.5 不同测站对应预测

在实际的潮汐资料中,常常会遇到这样的情形:某一测站的已有实测潮汐数据较少,不足以进行神经网络的预测.针对此类问题,文献[8]进行了有益的研究,其多点预测取位于同一港口内的 3 个点进行.在实际应用中,不同测站的同步潮位过程是必要的.而很多情况是所需的多个测站的潮位资料中,某个或几个测站只有很短时间的潮位资料.用传统的潮位分析和预测方法较难进行

长时间的预测,且预测的精度较差.本文尝试根据多个测站潮汐数据之间存在的相关性,以及潮汐数据规律性较强这一特点,利用有限的潮位同步资料,进行不同测站之间的潮位对应预测.以长兴岛和秦皇岛两测站为例对其进行说明.

图 3 比较了秦皇岛和长兴岛的潮汐类型,可以看出两站的潮汐类型明显不同,秦皇岛为全日潮,长兴岛为半日潮.

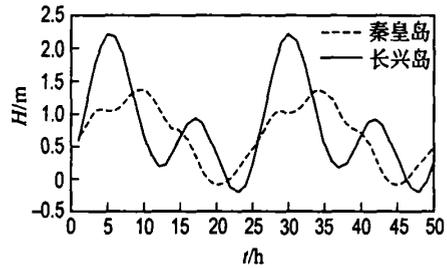


图 3 潮汐类型对比

Fig. 3 Comparison of tide type

图 4 给出了点对点预测方法下秦皇岛实测值和预测值的比较,从图可以看出点对点预测方法的精度很高,计算预测误差为 0.006 158 82.由此可见,点对点预测方法并不受潮汐类型的限制.

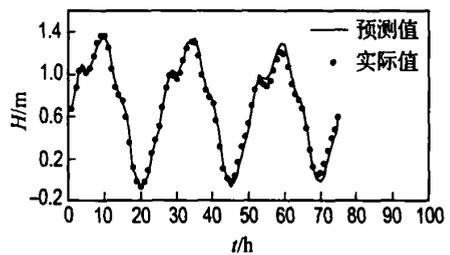


图 4 点对点预测方法下秦皇岛实测值和预测值的对比

Fig. 4 Comparison of forecast and field data by site to site method

3 结 语

本文利用人工神经网络 BP 算法进行潮位时间序列的预测,针对潮位时间序列具有一定周期性、规律性的特点,提出在预测之前对用于拟合的数据进行周期性分析,并应用实例进行验证,结果表明经周期分析后的预测结果很好地解决了未经分析而产生的时滞问题,提高了网络的预测精度.

本文根据两个不同时间序列具有“互相关性”的特点,论证了多测站潮位对应预测的可行性,应

用人工神经网络 BP 算法进行了多测站潮位的对应预测, 结果令人满意。

与传统的调和分析方法相比, 人工神经网络方法具有对实测数据要求少的优点, 可以利用有限的实测数据进行较高精度的预测, 本文通过对时间序列的分析, 认为其根本保证是潮位时间序列具有平稳性。

参考文献:

- [1] 陈宗镛. 潮汐学 [M]. 北京: 科学出版社, 1980: 5-9
- [2] DARWIN G H. On an apparatus for facilitating the reduction of tidal observations [J]. *Proc Royal Soc London A*, 1892, **52**: 345-376
- [3] DOODSON A T. The analysis of observations [J]. *Phil Trans Roy*, 1928, **A265**: 223-279
- [4] YEN P H, JAN C D, LEE Y P, *et al*. Application of Kalman filter to short-term tide level prediction [J]. *J Waterway Port Coastal Ocean Eng*, 1996, **122**(5): 226-231.
- [5] TSAI C P, LEE T L. Back-propagation neural network in tidal-level forecasting [J]. *J Waterway Port Coastal Ocean Eng*, 1999, **125**(4): 195-202
- [6] 陈明杰, 倪晋仁, 查克麦, 等. 遗传神经网络在二维潮流特性模拟中的应用 [J]. 水利学报, 2003, **10**: 87-95
- [7] LEE T L, JENG D S. Application of artificial neural networks in tide forecasting [J]. *Ocean Eng*, 2002, **29**(9): 1003-1022
- [8] TSAI C P, LIN C, SHEN J N. Neural network for wave forecasting among multi-stations [J]. *Ocean Eng*, 2002, **29**(13): 1683-1695
- [9] LEE T L, TSAI C P, JENG D S, *et al*. Neural network for the prediction and supplement of tidal record in Taichung, Taiwan [J]. *Adv Eng Software*, 2002, **33**(6): 329-338
- [10] HAYKIN S. 神经网络原理 [M]. 北京: 机械工业出版社, 2004
- [11] HORNIK K, STINCHCOMBE M, WHITE H. Multilayer feedforward networks are universal approximators [J]. *Neural Networks*, 1989, **2**(5): 359-366
- [12] HORNIK K. Approximation capabilities of multilayer feedforward networks [J]. *Neural Networks*, 1991, **4**(2): 251-257
- [13] 文新辉, 陈开周. 一种基于神经网络的非线性时间序列模型 [J]. 西安电子科技大学学报, 1994, **1**(21): 73-78
- [14] 顾 岚. 时间序列分析预测与控制 [M]. 北京: 中国统计出版社, 1997

Application of artificial neural networks to tide forecasting

LI Mingchang, LIANG Shuxiu, SUN Zhaochen*

(State Key Lab. of Coastal and Offshore Eng., Dalian Univ. of Technol., Dalian 116024, China)

Abstract In ocean environment, accurate tide forecasting is a kind of significant work for constructions and human activities. Artificial neural networks (ANN) model is presented for forecasting the tidal-level using limited field data of one site or multi-sites. Based on the characteristics of tide time series, a new conception – the periodicity analysis on tide data is proposed and applied to the testing of the performance of ANN model. The numerical results indicate that this method is efficient to solve the time lag problem existing in previous ANN models. Based on the pertinence of tidal-level data among different tidal gauge stations, a new tide forecasting method – site to site is developed, and the numerical results agree well with field data.

Key words artificial neural networks; tide forecasting; periodicity analysis; time lag