

非平稳时间序列的动态水位神经网络预报模型*

薛联青¹ 崔广柏¹ 陈凯麒²

(1 河海大学水环境学院, 南京 210098 2 中国水利水电科学研究院, 北京 100044)

提 要 水文预报系统是一个复杂的非线性动力学过程, 站点水位受各种因素的影响不仅呈现出非平稳动态随机变化特性, 而且各因素间的关系也很难确定. 淮河流域五河站水位由于受到洪泽湖回水影响及季节性的影响, 也呈现出这一动力学的非平稳特性, 因此本文在考虑了相关站点和回水影响的基础上, 建立了一种多站变量时间序列的神经网络预报模型, 预报结果表明该方法预测效果较好, 运行简单.

关键词 时间序列 预报模型 水位 回水影响 神经网络

分类号 P338⁺.1

水位预报系统是一个复杂的非线性动力学过程, 站点水位受各种因素的影响不仅呈现出非平稳动态复杂非线性关系, 而且各因素间的关系也很难确定. 合理的水位预报不仅对防止地区洪涝灾害、湖区安全及合理引水等都有一定的预警作用, 因此建立合理的水位预报模型具有重要意义. 本文在 Thomas 等人的神经网络预测理论的基础上^[1, 2], 分析了淮河流域五河站水位的季节性非平稳时间序列及受洪泽湖回水顶托影响的特点, 以时间序列神经网络模型为基础, 建立了一种相关站点的多变量时间序列神经网络预报模型, 并基于模型提出对实际监控数据进行了剔点和光滑处理, 以消除个别由于纯人为因素引起的序列中奇异点影响, 避免了传统时序神经网络模型在预报中将丢失序列趋势的缺点. 将该模型运用于淮河流域五河站的水位预报, 预测结果表明该方法运行合理, 并且较时序统计模型简单, 预测能力和预报周期都有所增加.

1 多变量时间序列神经网络模型

1.1 多变量时间序列

如有多变量时间序列 X 表示为 $(X_{1,1}, X_{1,2}, \dots, X_{1,s}) (X_{2,1}, X_{2,2}, \dots, X_{2,s}), \dots, (X_{i,1}, X_{i,2}, \dots, X_{i,s}), \dots$, 每个单变量有 S 个时间序列值, 则认为时间序列的未来值与其输入变量序列的前 D 个值之间有某种函数关系:

$$(X_{t+d+1,1}, X_{t+d+1,2}, \dots, X_{t+d+1,s}) \\ = F(X_{t,1}, X_{t,2}, \dots, X_{t,s}; X_{t+1,1}, \dots, X_{t+1,s}; \dots; X_{t+d,1}, X_{t+d,2}, \dots, X_{t+d,s})$$

利用神经网络拟合 $F(\cdot)$ 进行预测.

1.2 时间序列神经网络模型结构

对于一个时间序列 X , 以 D 作为某输入单变量序列的前 D 个值的时序数(文中为时间序

* 收稿日期 2001-04-20 收到修改稿日期 2001-09-17. 薛联青, 女, 1973 年生, 博士研究生. E-Mail: xuelianqing@263.net




图 1 时间序列神经网络模型

Fig.1 Neural network model of Time Series

列的续延天数), S 为输入的多变量个数,则模型输入层是由 $S \times D$ 个结点构成,输出层有 K 个结点(也可为 1 个).设进行网络训练的 n 个学习样本为: $P_1 = (x_{1,1}, x_{1,2}, \dots, x_{1,s}; x_{2,1}, x_{2,2}, \dots, x_{2,s}; \dots, x_{D,1}, x_{D,2}, \dots, x_{D,s}; y_{1+T+1,1}, y_{1+T+1,2}, \dots, y_{1+T+1,K})$; \dots ; $P_i = (x_{i,1}, x_{i,2}, \dots, x_{i,s}; \dots, x_{D+i,1}, x_{D+i,2}, \dots, x_{D+i,s}; y_{i+T+1,1}, y_{i+T+1,2}, \dots, y_{i+T+1,K})$; \dots . 通过网络实际输出值与相应的教师样本 Y_1, Y_2, \dots, Y_n 之间的误差来修正连接权,使输出值与期望值误差较小,即网络输出层误差平方和达到精度要求.

建立的模型结构如图 1 所示,模型由三层结点构成,从上到下依次为输入层、隐含层和输出层.输入时间序列矢量为 XR^n . 隐含层有 R 个神经元,输出层有 K 个神经元.输入层与隐含层之间的权为 $w_{1,ij}$,阈值为 b_1 .隐含层与输出层之间的权为 $w_{2,jk}$,阈值为 b_2 . f_1 与 f_2 为转换函数.网络输入层的神经元分别映射多变量时间序列动态的多个离散点,输出层的结点与输入相关时变序列的离散点(可为一个或多个)映射^[3].

(1)信息正向传递:设隐含层中第 i 个神经元的输出为

$$a_{1i} = f_1\left(\sum_{j=1}^S w_{1,ij}p_j + b_{1,i}\right) \quad (i = 1, 2, \dots, R)$$

其中, $f_1 = 1/(1 + e^{-x})$.

输出层第 k 个神经元的输出为:

$$a_{2k} = f_2\left(\sum_{i=1}^R w_{2,ki}a_{1i} + b_{2,k}\right) \quad (k = 1, 2, \dots, K)$$

其中, $f_2 = x$; 其误差函数为:

$$E(W, B) = \frac{1}{2} \sum_{k=1}^K (t_k - a_{2,k})^2$$

用梯度下降法求权值变化及误差的反向传播.

(2)输出层的权值变化:对从第 i 个输入到第 k 个输出的权值有:

$$\Delta w_{2,ki} = -\eta \frac{\partial E}{\partial w_{2,ki}} = -\eta \frac{\partial E}{\partial a_{2,k}} \frac{\partial a_{2,k}}{\partial w_{2,ki}} = \eta (t_k - a_{2,k}) f_2' \cdot a_{1i} = \eta \delta_{ki} a_{1i}$$

其中, $\delta_{ki} = (t_k - a_{2,k}) = e_{kf}'$; $e_k = t_k - a_{2,k}$. 同理可得:

$$\Delta b_{2,ki} = -\eta \frac{\partial E}{\partial b_{2,ki}} = -\eta \frac{\partial E}{\partial a_{2,k}} \cdot \frac{\partial a_{2,k}}{\partial b_{2,ki}} = \eta(t_k - a_{2,k}) \cdot f_2' = \eta \cdot \delta_{ki}$$

(3) 隐含层权值变化:对从第 j 个输入到第 i 个输出的权值,有

$$\Delta w_{1,ij} = -\eta \frac{\partial E}{\partial w_{1,ij}} = -\eta \sum_{k=1}^{S_2} \frac{\partial E}{\partial w_{1,ij}} = \eta \sum_{k=1}^{S_2} (t_k - a_{2,k}) \cdot f_2' \cdot w_{2,ki} f_1' \cdot p_j = \eta \delta_{ij} p_j$$

其中 $\delta_{ij} = e_i \cdot f_1'$; $e_i = \sum_{k=1}^{S_2} \delta_{ki} w_{2,ki}$; 同理可得 $\Delta b_{1,i} = \eta \delta_{ij}$.

(4) 学习速率:该模型采用自动调整学习速率^[4-6],检查权值的修正值是否真正降低了误差函数,如果降低,则说明所选取的学习速率值小了,可以增加学习速率,否则相反.自适应学习速率的调整计算公式为:

$$\eta(k+1) = \begin{cases} 1.05\eta(k) & SSE(k+1) < SSE(K) \\ 0.7\eta(K) & SSE(k+1) > 1.04SSE(k) \\ \eta(k) & \text{其它} \end{cases} \quad (1)$$

同时采用附加动量法^[7,8],考虑误差在梯度上的影响及在误差曲面上变化趋势的作用修正网络权值.模型是在反向传播法的基础上在每一个权值的变化上加上一项正比于前一次权值变化量的值,并根据反向传播法来产生新的权值变化,调节公式为:

$$\Delta w_{ij}(k+1) = (1 - m_c)\eta\delta_i p_j + m_c \Delta w_{ij}(k) \quad \Delta b_i(k+1) = (1 - m_c)\eta\delta_i + m_c \Delta b_i(k)$$

其中 k 为训练次数,为 m_c 动量因子, $m_c = 0.95$.

2 应用研究

考虑到五河站水位常会受洪泽湖回水的影响而与远离洪泽湖的站点水位具有相异的特性,因此建立的传统的站点水位预报模型往往预测周期较短,精度也较难保证.本文考虑了洪泽湖回水的影响,特选取蚌埠(简记为 BB)及蒋坝站(JB,可近似代表洪泽湖回水影响水位)五河(WH)1984-1987年四年的日平均水位观测序列作为网络训练的基础,通过建立多变量的时序人工神经网络动态非线性动力学预测模型.鉴于篇幅,仅给出了预报站五河四年监测水位(图2),蚌埠及蒋坝站水位值从略.




图2 五河站1984-1997年水位曲线

Fig.2 Water-level curve of Wuhe Station in 1984-1987




图 3 各站点水位平均光滑值
Fig. 3 Average water-level value of each hydrology Station




图 4 五河水位 7 日预报期预测与实际值
Fig. 4 Seven-day period predicting value and practical water-level of Wehe Station




图 5 五河站不同时间段 2 日水位预测
Fig. 5 Two-day water-level predicting of different time of Wuhe Station

2.1 数据处理

水文时间序列具有很大的波动性,由于受外部突变影响或错误点而产生的某些局部异常点突变,如特大洪水、人为造成等影响常常会影响预测效果,因此为了保证不因外部因素突变而扰乱神经网络的预测效果,导致模拟及预测失败,本文在利用神经网络拟合 $F(\cdot)$ 时,对输入输出时间序列均作了光滑处理,进而加速网络的学习速度,提高网络的预报效果.对网络输入序列和网络输出的教师训练序列作平滑处理后,参证站(BB、WH、JB)平均水位见图 3.

2.2 网络训练

网络预测中所采用的误差 $SSE = 1.5$,采用自学习方法调整速率,初始选用学习速率 $\eta = 0.007$.输入层神经元映射多变量延迟时间段为 $D = 5$ 的 10 个结点^[9],输出层神经元映射射为预报周期为 T 的变元结点.隐含层神经元数选取是个较为困难的问题:神经元太少,网络不能很好地学习,需要训练的次数也多,训练精度也不高,神经元数太多,训练时间较长,甚至可能导致不收敛,因此通过多次调试选择隐含层较理想的 6 个神经元,循环网络收敛误差小于 0.2.

2.3 五河水位预报分析

选取淮河流域五河站作为模型的水位预报站点,蚌埠站、蒋坝站及五河站 1984 年 1 月 - 1987 年 8 月的水位资料进行网络训练.以预报站五河 1987 年 9 月的实测水位进行校核.由于流域上各站之间水运移延迟、降水时差及风速等其它外界因素影响,提出选用各个输入神经元的动态延迟时间序列为节点输入,为增强预测的外延效果,文中选取参证站较大的延迟水位用于预测五河站水位值,预报周期 S 为 7d,即以 $(X_{1,k}, X_{1,k+1}, \dots, X_{1,k+D-1}),$

$(X_{2,k}, X_{2,k+1}, \dots, X_{2,k+D-1})$ 为第 K 个样本输入 ($D = 5$), $A_{1,i+12}, A_{2,i+12}, \dots, A_{n,i+12}$ (本文 $i = 12, 13, \dots, 353$) 为网络预测输出值.相对于传统的时间序列模型,文中的动态时间序列神经网络模型的预报周期较长,预测较为准确.部分预测与实测结果如图 4 所示,预报均方

差为 5.3% , 预报满足精度要求. 增加实测序列 1991—1992 年的水文资料, 运用该模型作了预报周期为 2d 不同季节的站点水位预报, 延迟不变, 结果如表 1 和图 5 所示. 计算预测结果的均方差为 2% , 远远达到精度要求.

神经网络模型的外延效果一般不是很理想, 因此通过对模型运行结果分析, 可以得出, 选择适当、合理的延迟也会取得较好的预测效果, 当然预报期的长短也同样影响预报精度. 因此根据不同研究对象的特征, 选取合适的输入端延迟对预报效果有一定的改善作用.

表 1 五河(WH)站 2d 水位预报分析

单位: m

Tab. 1 Two-day water-level prediction analysis of Wuhe Station

实测	预测	误差	实测	预测	误差	实测	预测	误差
13.38	13.445	0.07	13.45	13.520	0.07	13.85	13.781	-0.07
13.33	13.369	0.04	13.45	13.499	0.05	13.80	13.673	-0.13
13.31	13.271	-0.04	13.45	13.487	0.04	13.76	13.681	-0.08
13.30	13.233	-0.07	13.45	13.449	0.00	13.72	13.675	-0.04
13.29	13.253	-0.04	13.46	13.378	-0.08	13.68	13.618	-0.06
13.28	13.280	0.00	13.46	13.325	-0.13	13.64	13.562	-0.08
13.27	13.269	0.00	13.47	13.319	-0.15	13.58	13.523	-0.06
13.26	13.246	-0.01	13.52	13.334	-0.19	13.49	13.450	-0.04
13.25	13.233	-0.02	13.61	13.340	-0.27	13.38	13.329	-0.05
13.25	13.230	-0.02	13.77	13.567	-0.2	13.31	13.223	-0.09
13.26	13.244	-0.02	13.97	13.979	0.01	13.29	13.184	-0.11
13.28	13.270	-0.01	14.11	14.427	0.32	13.29	13.212	-0.08
13.33	13.329	0.00	14.14	14.429	0.29	13.31	13.259	-0.05
13.41	13.414	0.00	14.14	14.390	0.25	13.35	13.285	-0.06
13.45	13.517	0.07	14.10	14.257	0.16	13.39	13.296	-0.09
13.46	13.584	0.12	14.02	14.157	0.14	13.43	13.301	-0.13
13.46	13.565	0.11	13.92	13.997	0.08			

3 结论

所建立的人工神经网络用于淮河流域考虑特定影响因素的水文站点的水位预报, 预测结果表明该模型具有较好的预测效果, 具有相对长的预报期, 对地区防洪和保护湖区安全具有一定意义. 该模型充分体现了数据的时序动态的非平稳特性^[10], 为解决多变量的时间序列问题提供了较好的分析手段. 在数据处理上提出了神经元输入平滑处理的思想, 一定程度上增加了网络预报效果. 模型运行简便, 具有一定的应用价值.

参 考 文 献

- 1 Casdagli M. Nonlinear prediction of chaotic time series. *Physica D*, 1989, 35
- 2 项静恬. 动态和静态数据处理——时间序列和数理统计分析. 北京: 气象出版社, 1991
- 3 Varfis A, Versino C. Univariate economic time series forecasting by connectionist methods. *IEEE ICNN-90*, 1990, 342-346
- 4 施鸿宝. 神经网络及其应用. 西安: 西安交通大学出版社, 1995. 35-38

- 5 刘元波,陈伟民. 湖泊藻类动态模拟. 湖泊科学, 2000, 12(2):171-177
- 6 Chakraborty K. Forecasting the behavior of multivariate time series using neural networks. *Neural Networks*, 1992, 5
- 7 An H Z. Non-negative autoregressive models. *J Time Series Anal*, 1992, 13:82-195
- 8 George E P B, Gwilyn M J, Gregory C. *Times Series Analysis Forecasting and Control*. 顾岚译. 北京: 中国统计出版社, 1997
- 9 靳 蕃, 范俊波, 谭永东. 神经网络与神经计算机原理应用. 西南交通大学出版社, 1991
- 10 安鸿志, 陈 敏. 非线性时间序列分析. 上海科学技术出版社, 1998. 185-251

Dynamic Water-Level Neural-Network Forecast Model on Non-Stationary Time Series

XUE Lianqing¹ CUI Guangbai¹ CHEN Kaiqi²

(1: Hohai University, Nanjing 210098, P. R. China ;

2: Institute of Water Conservancy and Hydropower Research of China, Beijing 100044, P. R. China)

Abstract

Hydrology prediction is a complex non-linear dynamic process, and the station water-level often shows dynamic changing character owing to all kinds of factors. In the Huaihe Basin, Wuhe station water-level will be influenced by the backwater influence of Hongze lake and shows the non-stationary changing. In the paper based on the neural-network model of time series and the data characteristics of hydrology, a non-stationary multi-station variable dynamic sequence prediction model is made by using artificial neural-network and practised in Wuhe station water-level prediction of Huaihe River. The calculation results indicates that the model is not only reasonable but also its predicting period is longer. It is valuable when being used in practices.

Key Words time series, prediction model, water-level, backwater influence, ANN