

# 区域地下水位预报的季节型神经网络模型

薛联青<sup>1</sup>, 崔广柏<sup>1</sup>, 程 光<sup>2</sup>

(1. 河海大学, 江苏 南京 210098; 2. 东南大学, 江苏 南京 210096)

**摘要:** 根据西北干旱区地下水位周期性变化趋势明显的特点, 提出了测井水位预报的季节型神经网络模型。同时, 针对系列不同周期内变幅各异的特点, 对监测序列进行了光滑处理。预报结果表明: 该模型预测效果较好, 运行合理, 对规律性不强的地下水位动态预报具有一定的实用价值。

**关键词:** 区域; 地下水位; 季节型神经网络模型; 预报; 周期

中图分类号: P 641. 2 文献标识码: A 文章编号: 1001-6791(2002)04-473-05

地下水位系统是一个复杂的非线性动力学过程, 它受各种因素的影响, 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。多年来对地下水、土壤水分运动的预报主要采用水均衡方法、有限元及有限差分等数值求解方法, 这些方法物理意义明确、计算精度较高, 但模型预报时需获取边界条件参数及其它物理参数, 实际操作较为复杂。20 世纪 80 年代发展起来的神经网络具有强大的处理大规模非线性动力系统的功能, 模型需要的参数较少, 而且传统的神经网络模型已对具有趋向性的时间序列预测作了研究<sup>[1]</sup>。本文以季节型 ARMA (Auto-Regressive Integrated Moving Average model) 时间序列理论和神经网络预测理论为基础, 根据区域地下水位在长时间序列上具有一定的年周期变化特点, 建立了动态时间序列的季节性神经网络预测模型。并在预报中为提高模型的预报精度, 对实际数据进行了剔点和光滑处理, 从而避免了模型在预报中将丢失序列周期性的缺点, 并在一定程度上消除了数据突变等奇异点的影响。

## 1 季节型神经网络模型

### 1.1 常规的时间序列神经网络模型

常规的时间序列神经网络预测模型分为两种<sup>[2]</sup>: 一主要是对单变量的时间序列进行预测的神经网络模型。如: 设一时间序列  $X_1, X_2, \dots, X_n$ , 其中  $X_n$  为变量第  $n$  时刻的值。预测时则认为其未来值与前面  $m$  个值之间存在某种函数关系, 描述为  $X_{n+k} = F(X_n, X_{n-1}, \dots, X_{n-m+1})$ 。利用神经网络来拟合这种函数关系  $F(\bullet)$ , 并用它来推导未来值; 二为用于多变量

收稿日期: 2001-05-18; 修订日期: 2001-07-10

作者简介: 薛联青(1973-), 女, 新疆石河子人, 河海大学水文水资源及环境学院教师, 主要从事水资源规划与环境保护研究。

时间序列预测的神经网络模型，如多变量时间序列 $(X_{1,1}, X_{2,1}, \dots, X_{p,1}), (X_{1,2}, X_{2,2}, \dots, X_{p,2}), \dots, (X_{1,n}, X_{2,n}, \dots, X_{p,n})$ ，其中 $p$ 为变量数。同样认为时间序列的未来值与其前面 $m$ 个值之间的某种函数关系 $F(\cdot)$ 可描述为 $(X_{1,n+k}, X_{2,n+k}, \dots, X_{p,n+k}) = F[(X_{1,n-m+1}, X_{2,n-m+1}, \dots, X_{p,n-m+1}), \dots, (X_{1,n}, X_{2,n}, \dots, X_{p,n})]$ ，利用神经网络学习以拟合 $F(\cdot)$ ，进而进行预测。

1.2 季节型神经网络模型

(1) 建模思路 由于区域地下水位受年内规律性的灌溉、汛期降水、用水和干旱等众多因素的影响，在时间序列上将呈一定的年周期变化特性。如春灌对地下水产生入渗补给，导致地下水位上升，汛期降雨入渗引起地下水位较大幅度的上升，而其它时间大多为地下水位下降时期。因此设地下水位监测时间序列 $X(t)$ ，一般由趋势项 $A(t)$ 、周期项 $P(t)$ 、突变项 $B(t)$ 和随机项 $R(t)$ 组成<sup>[3]</sup>，其中随机项 $R(t)$ 又分为平稳时间序列项 $S(t)$ 和纯随机项 $N(t)$ (即白噪声)两项，白噪声仅与历史数据有关，与预测无关。监测的时间序列可表示为 $X(t) = A(t) + P(t) + B(t) + S(t) + N(t)$ ，其中趋势项反映变量时间序列的变化趋势，周期项反映的是水位的周期变化，突变项是由于受外部突变因素影响而产生的突变，其次就是随机项。地下水位从多年的长序列来看，在一定程度上呈现某种年周期变化特性，并在年周期内水位变化形态大致相仿。根据序列特点，模型分别考虑了 $A(t)$ 项、 $P(t)$ 项和 $R(t)$ 项，在其输入层和输出层神经元分别以一组神经元为单位，代表一个时间周期中的一组离散点，进行训练学习及预报(注： $B(t)$ 项在原始数据的剔点处理中剔除，处理后的数据再进行平滑处理消除纯随机项 $N(t)$ ，余下 $A(t)$ 、 $P(t)$ 和 $S(t)$ 项)。

(2) 模型结构 季节型神经网络模型是为解决周期性时间序列问题而从传统时间序列问题中发展起来。数学描述为设时间序列 $X: \{X_1, X_2, \dots, X_i, \dots\}$ 是以 $S$ 为周期的季节型时间序列，即 $X$ 表示为 $(X_{1,1}, X_{1,2}, \dots, X_{1,s}), (X_{2,1}, X_{2,2}, \dots, X_{2,s}), \dots, (X_{i,1}, X_{i,2}, \dots, X_{i,s}), \dots$ 。模型认为未来的一个周期是和历史上 $d+1$ 个周期值之间存在某种函数关系，即

$$\begin{aligned} &(X_{t+d+1,1}, X_{t+d+1,2}, \dots, X_{t+d+1,s}) \\ &= G(X_{t,1}, X_{t,2}, \dots, X_{t,s}; X_{t+1,1}, \dots, X_{t+1,s}; \dots; \\ &X_{t+d,1}, X_{t+d,2}, \dots, X_{t+d,s}) \end{aligned} \quad (1)$$

利用神经网络来拟合这个周期函数 $G(\cdot)$ ，并用它来预测未来周期的值。季节型神经网络模型结构如图1所示。

模型由三层神经元构成，从上到下依次为输入层(I层)、隐含层和输出层(O层)。I层的 $(d+1) \times S$ 个神经元映射周期中的时间序列的第 $t$ 至 $t+d$ 周期中的 $(d+1) \times S$ 个离散点，O层的 $S$ 个结点映射第 $t+d+1$ 周期的 $S$ 个离散点。模型的主要思想是：对于一个以 $S$ 为周




图1 季节型神经网络模型结构

Fig. 1 Structure of seasonal neural network model

期的季节型时间序列 $X$ , 设 $X$ 是由 $m$ 个周期为 $S$ 的时间序列 $X_1, X_2, \dots, X_m$ 构成, 模型输入层有 $(d+1) \cdot S$ 个神经元, 输出层有 $S$ 个神经元。规定 $n$ 个学习样本 $P = (P_1 = (X_1, X_2, \dots, X_s); P_2 = (X_2, X_3, \dots, X_{s+1}); \dots; P_n = (X_n, X_{n+1}, \dots, X_{n+s-1}))$ , 相对应的 $n$ 个教师样本 $T = (T_1 = X_{s+1}, T_2 = X_{s+2}, \dots, T_n = X_{s+n})$ 。学习的目的是用 $n$ 个样本 $P_1, P_2, \dots, P_n$ 学习后对应的神经网络输出 $A_1, A_2, \dots, A_n$ 与其相应的教师样本 $T_1, T_2, \dots, T_n$ 之间的误差来修正权值, 使 $A_i (i = 1, 2, \dots, n)$ 与期望的 $T_i$ 之间尽可能接近, 即使网络输出层的误差平方和达到最小<sup>[4,5]</sup>, 模型通过连续不断地在相对于误差函数斜率下降的方向上计算网络的权值和偏差的变化而逐步逼近目标, 每次权值和偏差的变化都与网络误差的影响成正比, 并以反方向传播方式传递到每一层。

模型由信息的正向传递与误差的反向传播两部分组成。在正向传播中, 输入信息从输入层经隐含层计算传向输入层, 每一层神经元的状态只影响下一层神经的状态, 如果在输出层没有得到期望的输出, 则计算输出层的误差变化值, 然后转向反向传播, 通过网络误差信号沿原来的连接通路反传回来, 修改各层神经元的权值, 直至达到期望目标。

①信息的正向传递 隐含层中第 $i$ 个神经元的输出为

$$a_{1i} = f_1\left(\sum_{j=1}^r w_{1j} p_j + b_{1i}\right), \quad (i = 1, 2, \dots, s_1)$$

其中  $f_1(x) = \frac{1}{1 + e^{-x}}$ ;  $u_i$  为隐含层第 $i$ 个结点的阈值;  $r$  为输入层结点数。

输出层第 $k$ 个神经元的输出为

$$a_{2k} = f_2\left(\sum_{i=1}^{s_1} w_{2ki} a_{1i} + b_{2k}\right), \quad (k = 1, 2, \dots, s_2)$$

其中  $f_2(x) = x$

定义误差函数为

$$E(W, B) = \frac{1}{2} \sum_{k=1}^{s_2} (t_k - a_{2k})^2$$

式中  $W$  为权重集合;  $\beta$  为阈值集合;  $r$  为输入层结点数;  $S_1$  为隐含层结点数;  $S_2$  为输出层结点数;  $w_{1j}$  为输入层第 $j$ 个结点和隐含层 $i$ 之间键路上的权重;  $b_{1i}$  为隐含层第 $i$ 个结点的阈值;  $w_{2ki}$  为隐含层第 $i$ 个结点和输出层第 $k$ 个结点之间键路的权重。

②梯度下降法求权值变化及误差的反向传播 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

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

其中  $\delta_{ki} = (t_k - a_{2k}) = e_k f_2'$ ;  $e_k = t_k - a_{2k}$

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

隐含层权值变化: 对从第 $j$ 个输入到第 $i$ 个输出的权值有

$$\Delta w_{1j} = -\eta \frac{\partial E}{\partial w_{1j}} = -\eta \sum_{k=1}^{s_2} \frac{\partial E_k}{\partial w_{1j}} = \eta \sum_{k=1}^{s_2} (t_k - a_{2k}) f_2' w_{2ki} f_1' p_j = \eta \delta_{ij} p_j$$

其中  $\delta_{ij} = e_j f_1'$ ,  $e_i = \sum_{k=1}^{s_2} \delta_{ki} w_{2ki}$ ; 并有  $\Delta b_{1i} = \eta \delta_{ij}$ ;  $\eta$  为学习速率。

③初始权值的选择及学习机制 由于模型是非线性的, 初始值对于学习是否达到局部最

小, 是否能够收敛以及训练时间的长短的关系很大。一般希望经过初始加权后的每个神经元的输出值都接近于零, 这样可保证每个神经元的权值都能够在它们的  $S$  型激活函数变化最大处进行调节, 所以取初始权值在  $(-1, 1)$  之间的随机数。模型采用自动调整学习速率<sup>[6]</sup>, 检查权值的修正值是否真正降低了误差函数。同时采用附加动量法, 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来修正网络权值。模型在反向传播法的基础上, 在每个权值的变化上加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。

## 2 应用研究

### 2.1 模型建立

选取北方灌区面积近  $70\,000\text{ km}^2$  的某区域作为分析对象, 该区域的农田灌溉水源以引黄渠灌为主, 井灌为辅。考虑区域内各监测井各项因素的差异, 将区域分成几个小区, 选择基本能代表小区地下水位特征的测井 1980-1989 年的月平均水位序列进行建模计算并进行预报。选取前 9 年的平均水位资料用于模型标定, 1989 年数据作为参证校核序列。网络训练的输入层采用 12 个神经元, 分别映射样本本年 12 个月的平均水位, 即季节模型输入为 1 个周期, 输出层采用 12 个神经元, 映射延迟一年的 12 个月的平均水位。进行数据处理后的水位时间序列记为  $WL = \{t_1 =$

$(t_{1,1}, t_{1,2}, \dots, t_{1,12}); t_2 = (t_{2,1}, t_{2,2}, \dots, t_{2,12}); \dots; t_9 = (t_{9,1}, t_{9,2}, \dots, t_{9,12})\}$ 。学习样本  $P = (t_1, t_2, \dots, t_8)$ , 其教师样本为  $T = (t_2, t_3, \dots, t_9)$ 。由于数据差别的影响, 直接用于训练容易产生较大误差, 因此在处理之前先将所有的流量数据进行归一化处理。

预测中误差取  $SSE = 0.01$ , 初始学习速率为  $\eta = 0.007$ 。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, 因此经过多次调试根据经验选择隐含层为 20 个神经元。图 2 为水位预报的季节神经网络训练的误差记录和学习速率的记录。

### 2.2 地下水位预报

由模型所计算的小区地下水位预报结果(1989 年月均水位)如图 3 所示。预报序列及实际监测序列预报值和实际监测值误差分析结果如表 1 所示。从预报图可以看出季节型神经网络模型的预测趋势与实测序列一致, 预报效果较好。




图 2 水位季节型神经网络训练记录

Fig. 2 Training records of water level seasonal network model

表 1 预测结果对比分析

**Table 1 Comparison of predicted and observed results**

时间/月	水位/m		误差/%
	实测值	预测值	
1	1.48	1.44	2.7
2	0.84	0.85	1.1
3	0.44	0.49	11.3
4	0.72	0.72	0.0
5	0.82	0.95	15.8
6	0.23	0.36	56.6
7	0.50	0.58	16.0
8	0.54	0.60	11.1
9	0.85	0.98	15.2
10	1.43	1.34	6.2
11	1.54	1.42	7.7
12	1.74	1.69	2.8




图 3 1989 年月均地下水位预报分析

Fig 3 Analysis of predicted average month groundwater level in 1989

### 3 结 语

地下水位虽受各种因素的影响呈规律性变化, 但各种因素很难给出定量的估计。文中基于时间序列和神经网络的分析方法, 建立了一种新的季节性网络预报模型。模型的输入层和输出层的神经元分别以时间序列的一个周期为单位, 根据历史周期的水位变化预测未来周期的水位。这种以周期为单位处理时间序列问题不会丢失时间序列中重要的周期信息, 同时通过该模型做一步预报就可以得出  $T$  (一个周期) 步的预报结果, 从而避免常规预报步数增多、预报误差增大的缺点。

#### 参考文献:

[ 1 ] 焦李成. 神经网络系统理论[M]. 西安: 西安电子科技大学出版社, 1996. 19- 35.  
 [ 2 ] George E P Box, Gwilym M Jenkins, Gregory C Reinsel 著, 顾岚译. 时间序列分析与控制[M]. 北京: 中国统计出版社, 1997. 98- 112.  
 [ 3 ] 杨位钦, 顾 岚. 时间序列分析与动态数据建模[ M ]. 北京: 北京理工大学出版社, 1988. 110- 135  
 [ 4 ] Casdagli M. Nonlinear prediction of chaotic time series[ J]. Physica D, 1989, 35- 65  
 [ 5 ] Thomas Kolarik, Gottfried Rudofier. Time series forecasting using neural networks[A]. ACM, time series & neural networks[ C ]. Sept. 1994  
 [ 6 ] Dorffner G. Neural networks for time series processing[J]. Neural Network World. 1996, 4: 447- 468.

## Seasonal neural-network forecast model for regional groundwater level

XUE Liang-qing<sup>1</sup>, CUI Guang-bai<sup>1</sup>, CHENG Guang<sup>2</sup>

(1. Hohai University, Nanjing 210098, China; 2. Dongnan University, Nanjing 210096, China)

**Abstract:** Based on the neural-network model of time series and the periodical changing characteristic of the groundwater level in dry region, a seasonal artificial neural-network forecast model is set up. At the same time the data smoothing process is carried out aimed at the different fluctuation during different period before these data are used for training. The prediction results indicate that the model is reasonable, its accuracy is better, and has some practical value when being used in the dynamic groundwater level analysis.

**Key words:** region; groundwater level; seasonal artificial neural-network model; prediction; period