

# 水文预报的人工神经网络方法\*

吴超羽

张 文

(中山大学河口海岸研究所, 广州 510275) (华南理工大学自动化系, 广州 510631)

**摘 要** 本文在水文学文献上首次应用人工神经网络模型(ANN)对广东省目前最大的飞来峡水电枢纽工程控制水文站北江横石站的日均及逐时流量进行了预报, 资料包括 5 年洪水季节的逐时流量和全年的日均流量. 研究表明能有效的模拟非线性的实际水文系统. 本文提出的模型与现有的 CAR, AR 和 RWTL 等线性模型进行了比较. 为此鉴别了 149 个模型, ANN 模型在明显的增加了预报长度同时提高了预报精度.

**关键词** 水文预报, 人工神经网络模型, 系统预报, 北江, 飞来峡

**分类号** P332.4

目前洪水预报方法可分为三类——经验预报、概念模型和系统或黑箱模型. 系统模型在近 20 多年来广泛应用于水文预报, 尤其适用于有较长观测序列的地区. 目前较为成熟的系统水文预报模型大都是线性的. 严格说实际的水文系统都是非线性系统, 解决这一问题有较大的理论意义和实际应用价值, 有助于延长预报长度和提高预报精度. 虽然在自动控制领域<sup>[1]</sup>和水文学领域各自有不少非线性模型提出, 但非线性系统模型在水文预报上尚未取得很大成功.

人工神经网络模型(Artificial Neural Net 即 ANN)是生物神经网络部分特性的理论抽象. 它是由大量的基本信息单元—神经元—通过丰富的相互联结而成的非线性动力学系统. 它具有一般非线性系统的共性又有其自身的特点, 如①高维性, 网络中神经元数目大, 表现出一定的统计特性; ②神经元之间的广泛联结性增强了网络的功能; ③自适应和自组织能力. 为了和现存线性模型比较, 应用 CAR, AR 和 RWTL 模型对同样资料进行了建模和预报.

## 1 方 法

### 1.1 人工神经网络(ANN)模型

神经网络系统是由大量简单元件(神经元)广泛相连接而成的网络系统, 反映了人脑

收稿日期: 1993-03-30

\* 国家及广东省自然科学基金资助项目

功能的若干基本特性(图 1),神经网络系统是高度非线性动力学系统,Hopfield 提出的人工神经网络模型是由下列非线性微分方程描写的<sup>[2,3]</sup>:

$$C_i \frac{du_i}{dt} = \sum_{j=1}^n T_{ij} f(u_j) - \frac{1}{R_i} u_i + I_i \quad (i=1, 2, \dots, n) \quad (1)$$

其中  $U_i$  是第  $i$  个神经元的膜电位,  $C_i$  是它的输入电容,  $R_i$  是输入电阻,  $I_i$  是输入电流,  $T_{ij}$  是第  $j$  个神经元对第  $i$  个神经元的联系强度,  $f(u)$  是  $u$  的非线性函数. 下面简单介绍模型原理.

### 人 工 神 经 网 络 模 型




图 1 有四层隐元的神经网络模型

Fig. 1 Artificial neural net with four hidden layers

(1)简单神经网络系统. 设有  $n$  个神经元连接, 每个神经元的活化状态  $S_i (i=1, 2, \dots, n)$  只取值 0 或 1, 代表抑制与兴奋. 每一神经元的状态按下述规则受其他神经元的制约

$$S_i = \sigma \left( \sum_j W_{ij} S_j - \theta_i \right) \quad (j=1, 2, \dots, n) \quad (2)$$

其中  $W_{ij}$  是神经元间的连接强度,  $W_{ij} = 0, (i=j)$  是可调实数,  $\theta_i$  是阈值,  $\sigma(x)$  是阶跃函数:

$$\sigma(x) = \begin{cases} 1 & x > 0 \\ 0 & x \leq 0 \end{cases} \quad (3)$$

实际网络可有多种变型,  $S_{ij}$  可连续取值.

(2)反传神经网络(Back-propagation). Rumelhart 1986 年提出“误差传播法”训练多层神经网络<sup>[4]</sup>. 神经元  $i$  的输入值  $net_i$  和输出值  $o_i$  分别为

$$net_i = \sum_j W_{ij} O_j + \theta_i \quad (4)$$

和

$$O_i = 1 / (1 + e^{-\theta_i}) \quad (5)$$

其中  $\theta_i$  是阈值,  $W_{i,j}$  是联系神经元  $i$  和  $j$  的强度. 网络的训练就是根据误差函数  $E$  调整神经元之间的联结强度和阈值.  $E$  定义为

$$E = 1/2 \sum (t_i - O_i)^2 \quad (6)$$

如令  $\partial E / \partial net_i = -\delta_i$  和

$$\Delta W_{i,j} = -\eta \partial E / \partial W_{i,j} \quad (7)$$

由式(4), (5), (6)和(7)可以导出

$$\Delta W_{i,j} = W_{i,j}(n+1) - W_{i,j}(n) = \eta \delta_i O_j \quad (8)$$

$$\Delta \theta_i = \theta_i(n+1) - \theta_i(n) = \eta \delta_i \quad (9)$$

$$\delta_j = \begin{cases} (t_j - O_j) O_j (1 - O_j) & (\text{当 } u_j \text{ 为输出元}) \\ O_j (1 - O_j) \sum_i \delta_i W_{j,i} & (\text{当 } u_j \text{ 为隐元}) \end{cases} \quad (10)$$

其中  $O_i$  为输出层实际输出,  $t_i$  为要求输出,  $E$  代表误差. 学习算法就是使  $E$  取极小值. 式(4)至(10)构成了 BP 网络的基本学习算法<sup>(4,5)</sup>.

### 1.2 随机过程的自回归 AR(Autoregressive)模型

AR 和 CAR 模型都是系统模型. 系统辨识就是在输入和输出数据基础上, 从一组给定的模型中, 确定一个与所测系统等价的模型. 建模包括模型识别, 参数估计和模型检验<sup>(6)</sup>. AR 模型可以定义为

$$X(n) = - \sum_{i=1}^p A_i X(n-i) + e(n) \quad (11)$$

式中  $\{e(n)\}$  是自噪声过程.  $\{X(n)\}$  是随机过程, 具有零均值.  $\{A_i\}$  是待定参数.  $p$  是模型阶数. 上式也称 AR( $p$ ) 过程.

### 1.3 多变量受控 CARMA (Controlled Autoregressive and Moving Averaged) 模型

CARMA 模型可以定义为:

$$A(z^{-1})Y(t) = B(z^{-1})U(t) + C(z^{-1})e(t) \quad (12)$$

其中

$Y(t) = [y_1(t), y_2(t), \dots]^T$  是  $p \times 1$  维系统输出,

$U(t) = [u_1(t), u_2(t), \dots]^T$  是  $r \times 1$  维系统输入,

$e(t) = [e_1(t), e_2(t), \dots]^T$  是  $p \times 1$  维自噪声 (13)

$z^{-1}$  是单位滞后算子,  $A, B, C$  是  $z^{-1}$  的矩阵多项式, 即

$$A(z^{-1}) = I - A_1 z^{-1} - \dots - A_{n_a} z^{-n_a}$$

$$B(z^{-1}) = B_0 - B_1 z^{-1} - \dots - B_{n_b} z^{-n_b}$$

$$C(z^{-1})=I-C_1z^{-1}-\dots-C_{na}z^{-na}$$

式中  $A, B, C_k$  分别是  $p \times p, p \times r, p \times p$  维系数矩阵,  $p$  是输出变量个数,  $r$  是输入变量个数.  $na, nb$  分别为输入输出的阶.  $I$  是单位阵.

当  $C(z^{-1})=I$  时, 得到 CAR 模型

$$A(z^{-1})Y(t)=B(z^{-1})U(t)+e(t) \quad (14)$$

由于 CARMA 模型可以用充分高阶的 CAR 模型逼近到任何精度. 一般可使用 CAR 模型对各系统建模. 最大似然法参数估计具有较好的估计性质, 但计算量较大. 获得模型之后, 主要通过检验模型的残差序列的白色性以判别模型的有效性.

#### 1.4 时滞多元回归模型

多元回归模型定义为

$$y=b_0+b_1x_1+b_2x_2+\dots+b_kx_k+e \quad (15)$$

$y$  是应变量,  $x_1, x_2, \dots, x_k$  是自变量,  $e$  是误差项. 如果将自变量和应变量处理为时间序列, 带时滞的多元回归模型(RWTL)可定义为

$$y(t)=b_0+b_1^0x_1(t)+b_1^1x_1(t)+\dots+b_1^kx_1(t)+b_2^0x_2(t)+b_2^1x_2(t)+\dots+b_2^kx_2(t)+e(t) \quad (16)$$

$b^0, b_1^1, b_1^2, \dots$  等系数可用最小二乘法确定. 需要指出此类模型可能存在多重共线性问题.

## 2 资料序列与研究地区

珠江位于华南, 由西、北、东三江汇合而成. 本文研究区域位于北江下游(图 2). 目前拟建的飞来峡水电枢纽工程即位于此地. 至横石站流域面积为  $34097\text{km}^2$ . 自北而南有武水、泮水、连江和潏江汇入北江干流. 本研究以泮江的泮湾站和武水的黎市站的流量作为系统的输入, 横石站流量为系统输出. 资料序列包括 1964, 1966, 1971, 1976 和 1982 年洪季的逐时流量(采样间隔为 6 h)和 1976 年日平均流量.

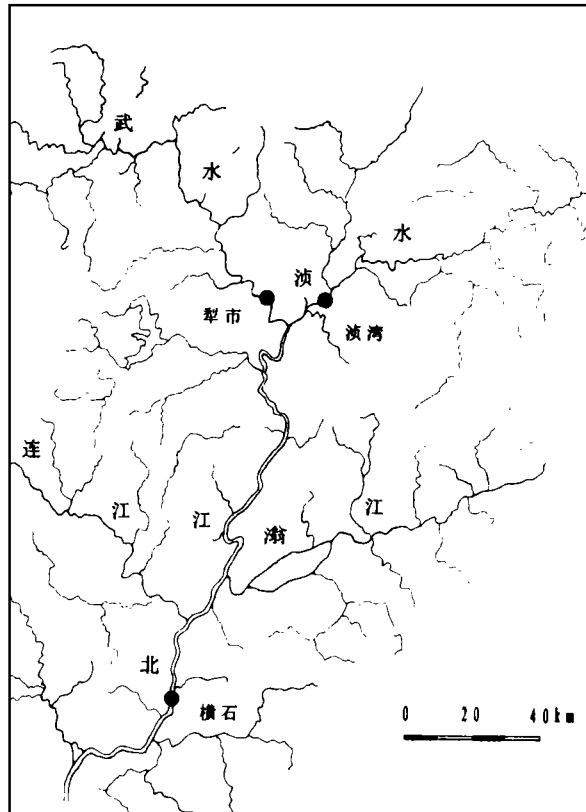


图 2 研究地区

Fig. 2 Study area

### 3 预报方案

根据本区水文特点,实时预报分为两部分.第一部分为确定性模型,第二部分为随机模型.第二部分的设计是通过模拟确定的误差过程作实时修正以增加预报的精度,一般在实时预报中应用.各种概念模型及系统模型如 CAR, AR 和 RWTL 模型均可以作为确定性模型. AR, MA 或 CAR 模型可以作为随机部分. AR 模型这里与在线的卡尔曼滤波预报器等价. ANN 模型可以作为确定性模型和随机模型.下文讨论的误差均为该模型作为确定性部分的预报(由于事件已经发生,实际是后报,下同)误差,以便于比较各种模型.

目前的系统是一多输入单输出(MISO)系统.输入变量是支流的流量,输出为横石站的流量.模型的预报质量用有效系数  $d_y$  和相对误差判断.有效系数定义如下

$$d_y = 1 - [S_e^2 / S_y^2] \quad (17)$$

$$S_e = \sqrt{\sum (Y_i - Y)^2 / n} \quad (18)$$

$$S_y = \sqrt{\sum (Y_i - Y_m)^2 / n} \quad (19)$$

式中  $S_e$  为预报误差的均方差,  $S_y$  为预报要素(流量)的均方差,  $Y_i$  为实测值,  $Y_m$  为实测值的均值,  $Y$  为预报值,  $n$  为序列的点数.

### 4 结果与讨论

CAR, AR 和 RWTL 模型应用于 1964, 1966, 1971, 1976 和 1982 年洪季的逐时流量和 1976 年日平均流量.为此建立了 129 个三阶 CAR, AR 和 RWTL 模型.参数用最小二乘法估计.三分之二的序列长度用以建模,三分之一用以检验模型.表 1 和表 2 列出了 1976 年逐时和日均流量模型的估计参数.

表 1 参数估计 (日均流量, 1976 年)  
Tab. 1 Parameter estimate (daily, 1976)

MODEL	LAG	$A_1$	$A_2$	$A_3$	$B_1^1$	$B_1^2$	$B_1^3$	$B_2^1$	$B_2^2$	$B_2^3$
CAR	1	0.630	0.111	-0.048	2.515	-2.346	0.483	1.231	-0.175	-0.483
	2	0.168	0.224	0.062	3.160	-2.485	0.000	1.162	0.283	-0.447
	3	0.153	0.259	0.021	1.602	-1.862	0.188	1.950	-0.667	-0.228
AR	1	1.337	-0.672	0.211						
	2	1.173	-0.806	0.347						
	3	0.979	-0.715	0.374						
RWTL	1				2.809	-0.874	0.184	1.576	0.510	0.333
	2				2.630	-1.390	0.241	2.149	-0.237	0.472
	3				1.085	-0.976	0.503	2.716	-0.464	0.259

表 2 参数估计 (逐时流量, 1976 年)  
Tab. 2 Parameter estimate (daily, 1976)

MODEL	LAG	A <sub>1</sub>	A <sub>2</sub>	A <sub>3</sub>	B <sub>1</sub> <sup>1</sup>	B <sub>1</sub> <sup>2</sup>	B <sub>1</sub> <sup>3</sup>	B <sub>2</sub> <sup>1</sup>	B <sub>2</sub> <sup>2</sup>	B <sub>2</sub> <sup>3</sup>
CAR	1	1.743	-1.051	0.220	0.154	-0.256	0.193	0.517	-0.181	-0.090
	2	1.566	-1.017	0.157	-0.011	0.194	0.004	1.912	-1.187	0.134
	3	1.084	-0.581	-0.015	0.012	0.178	0.099	4.425	-3.744	0.832
	4	0.612	-0.202	-0.109	-0.044	0.746	-0.286	5.760	-5.230	1.371
	5	0.253	0.231	-0.289	0.148	0.761	-0.612	6.410	-6.004	1.655
	6	0.271	0.284	-0.389	0.681	-0.000	-0.537	7.373	-7.932	2.529
	7	0.363	-0.143	-0.153	0.597	-0.377	-0.410	6.644	-6.690	2.261
	8	0.084	-0.031	-0.167	0.053	-0.538	0.122	6.748	-6.430	2.299
AR	1	2.202	-1.651	0.428						
	2	3.116	-3.058	0.868						
	3	3.538	-3.721	1.029						
	4	3.423	-3.669	0.991						
	5	3.140	-3.397	0.909						
	6	2.826	-3.182	0.892						
	7	3.028	-3.776	1.174						
	8	2.187	-2.414	0.556						
RWTL	1				1.008	-1.874	1.544	1.167	-1.970	3.785
	2				0.452	-0.845	0.974	2.111	-1.627	2.562
	3				0.505	-0.748	0.898	4.345	-3.174	1.869
	4				0.473	-0.007	0.210	6.480	-6.115	2.522
	5				0.266	0.458	-0.146	6.528	-5.738	1.896
	6				0.578	-0.050	-0.040	7.508	-7.139	2.032
	7				0.114	0.119	-0.089	7.486	-6.727	1.568
	8				0.482	0.384	-0.150	6.893	-5.574	0.950

模型建立后即可用于预报. 图 3 是 CAR 模型 1976 年日均流量的一步预报与实测值. 一步(天)的有效系数达 0.98, 三步(天)的预报质量迅速降低. 图 4 是 1966 年洪季逐时




图 3 CAR 模型预报 1976 年日均流量(一步(日)预报)

Fig. 3 Daily mean discharge forecasting of 1976 by CAR model, one step(day) forecasting

(6h 采样间隔) CAR 模型 4 步(24h)预报. 计算表明, 对所有的时间序列, 三种线性模型对逐时资料的预报质量在预报步长小于 2~3 步时结果良好. 当预报期增加时, 预报质量迅速下降. 用三分之二的序列长度训练 ANN 模型(2 层隐元, 多输入, 多输出), 然后用得到的网络联结强度矩阵(权重矩阵)预报余下的三分之一序列. 图 5 是 1976 年日均流量的 ANN 模型预报值与观测值. 图 6 与图 4 用的是同一资料序列, 可以看到 ANN 模型的预报结果明显优于系统模型. 图 7 是 1971 和 1982 年逐时洪水过程 24h 预报. 表 3 到表 8 列出了各模型对各资料序列预报的有效系数. 表 9 和表 10 是 ANN 模型预报流量峰值的相对误差.

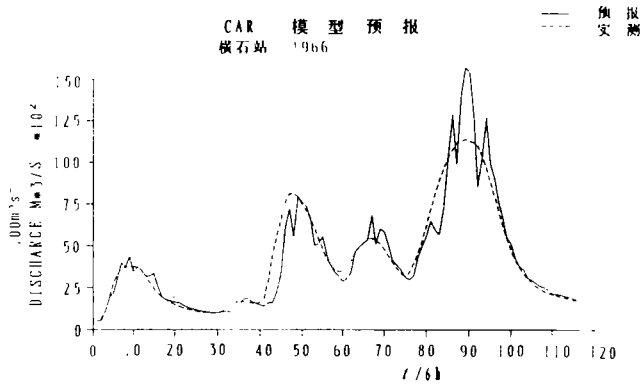


图 4 CAR 模型预报 1976 年洪季逐时流量(四步 24h 预报, 采样间隔 6h)

Fig. 4 Hourly discharge forecasting of the flood season in 1966 by CAR model. The lead time is 24 hours




图 5 ANN 模型预报 1976 年日均流量(一步(日)预报)

Fig. 5 Daily mean discharge forecasting of 1976 by ANN model one step(day) forecasting




图 6 ANN 模型预报 1976 年洪季逐时流量(四步 24h 预报, 采样间隔 6h)

Fig. 6 Hourly discharge forecasting of the flood season in 1966 by ANN model. The lead time is 24 hours

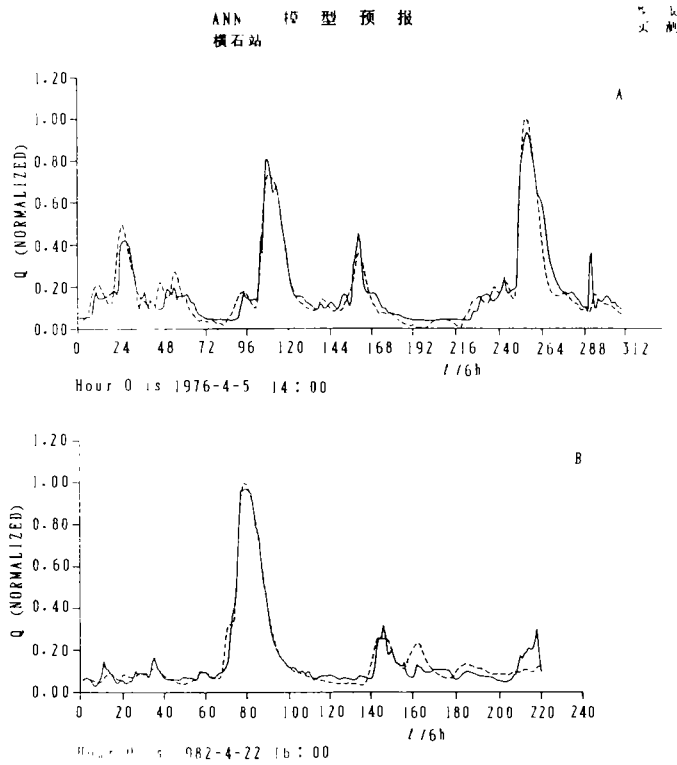


图 7 ANN 模型预报洪季逐时流量(四步 24h 预报, 采样间隔 6h) (a)1971 年;(b)1982 年  
 Fig. 7 Hourly discharge forecasting of the flood season in (a) 1971 and (b) 1982 by ANN model. The lead time is 24 hours, sampling interval is 6 hours

图 8 是 CAR, AR, RWTL 和 ANN 四种模型(141 个)预报的确定性系数的平均值与预报步长. 所有模型的有效系数在预报期短(<3 步)时均大于 0.8(RWTL 模型较差). 当预报步长增大时, 本研究所有线性模型的预报质量迅速降低. 而 ANN 模型的有效系数在预报步长增加至 7~8 步时仍达 0.8 以上. ANN 模型在预报期和预报精度上较线性模型有明显的优越性.




图 8 各类模型预报期(步)的平均有效系数  
 Fig. 8 Efficiency versus lead time based on 140 models identified

表3 模型有效系数 (采样间隔:6h,1964年)

Tab.3 Model efficiency coefficients(1964,hourly)

步长	t/h	CAR	AR	RWTL	ANN	
		调试	调试	调试	调试	验证
1	6	1.00	1.00	0.92	0.98	0.97
2	12	0.98	0.97	0.93		
3	18	0.96	0.94	0.92		
4	24	0.93	0.88	0.90	0.97	0.96
5	30	0.88	0.80	0.86		
6	36	0.81	0.70	0.79	0.98	0.94
7	42	0.72	0.59	0.70		
8	48	0.64	0.47	0.61	0.95	0.87

表4 模型有效系数 (采样间隔:6h,1966年)

Tab.4 Model efficiency coefficients (1966,hourly)

步长	t/h	CAR	AR	RWTL	ANN	
		调试	调试	调试	调试	验证
1	6	1.00	0.99	0.59	0.99	0.98
2	12	0.98	0.98	0.62		
3	18	0.93	0.95	0.59		
4	24	0.85	0.88	0.66	0.96	0.95
5	30	0.76	0.76	0.60		
6	36	0.66	0.63	0.59	0.91	0.89
7	42	0.56	0.43	0.43		
8	48	0.25	0.28	0.26	0.79	0.73

表5 模型有效系数 (采样间隔:6h,1971年)

Tab.5 Model efficiency coefficients (1971,hourly)

步长	t/h	CAR	AR	RWTL	ANN	
		调试	调试	调试	调试	验证
1	6	0.98	0.98	0.77	0.98	0.97
2	12	0.94	0.91	0.74		
3	18	0.86	0.79	0.68		
4	24	0.73	0.66	0.58	0.90	0.84
5	30	0.57	0.50	0.43		
6	36	0.44	0.34	0.24	0.88	0.75
7	42	0.29	0.19	0.07		
8	48	0.15	0.09	-0.05	0.81	0.66

表 6 模型有效系数 (采样间隔:4h,1976 年)  
Tab. 6 Model efficiency coefficients (1976, hourly)

步长	$t/h$	CAR	AR	RWTL	ANN	
		调试	调试	调试	调试	验证
1	4	1.00	0.93	0.94	0.99	0.98
2	8	0.98	0.23	0.80		
3	12	0.96	0.23	0.81		
4	16	0.95	0.23	0.80	0.92	0.95
5	20	0.88	0.23	0.81	0.93	0.90
6	24	0.83	0.23	0.78	0.91	0.77

表 7 模型有效系数 (采样间隔:6h,1982 年)  
Tab. 7 Model efficiency coefficients (1982, hourly)

步长	$t/h$	CAR	AR	RWTL	ANN	
		调试	调试	调试	调试	验证
1	6	1.00	0.99	0.85	0.99	0.98
2	12	0.98	0.96	0.83		
3	18	0.94	0.89	0.83		
4	24	0.91	0.80	0.82	0.95	0.95
5	30	0.86	0.71	0.79		
6	36	0.80	0.63	0.71	0.90	0.90
7	42	0.70	0.55	0.62		
8	48	0.59	0.45	0.52	0.77	0.77

表 8 模型有效系数 (采样间隔:1d,1976 年)  
Tab. 8 Model efficiency coefficients (1976, hourly)

步长	$t/d$	CAR	AR	RWTL	ANN	
		调试	调试	调试	调试	验证
1	1	0.95	0.61	0.83	0.98	0.98
2	2	0.67	0.39	0.50	0.95	0.94
3	3	0.36	0.15	0.28	0.75	0.73

表 9 洪峰相对误差(ANN 模型)  
Tab. 9 Relative error for peak discharge(hourly)

NO	年份	预 报 期 (步长/h)		
		4/24	6/36	8/48
1	1964	-0.07	-0.03	-0.02
2	1964	0.10	-0.03	0.06
3	1966	-0.06	-0.09	-0.06
4	1966	0.09	-0.08	0.10
5	1966	-0.02	-0.04	-0.05
6	1971	-0.06	0.10	0.12
7	1971	-0.03	0.00	0.01
8	1971	0.07	0.04	0.04
9	1971	0.21	0.01	0.03
10	1971	0.41	0.31	0.37
11	1971	-0.14	-0.18	0.09
12	1982	-0.03	-0.05	-0.01
13	1982	-0.07	-0.19	-0.15

表 10 洪峰相对误差(ANN 模型,1976 年)  
Tab. 10 Relative error for peak discharge(daily)

NO	预 报 期 (步长/h)		
	4/16	5/20	6/24
1	0.06	-0.03	-0.03
2	-0.05	-0.01	-0.02
3	-0.37	-0.38	-0.41
4	-0.09	-0.06	-0.03
5	-0.02	-0.03	+0.08
6	-0.14	-0.12	-0.13

## 5 结 论

(1)本文在水文学文献上首次应用人工神经网络模型(ANN)进行水文预报.人工神经网络模型具有生物神经网络的一些特性,能够“学习”.因此易于应用于各种类型的流域系统.

(2)ANN 模型是高度非线性模型,能较有效的模拟本质为非线性的实际水文系统.

(3)经比较, CAR、RWTL、AR 和 ANN 四种模型的有效系数在预报期短(<3 步)时均大于 0.8. 当预报步长增大时,所有线性模型的预报质量迅速降低.而 ANN 模型的有效系数在预报步长增加至 7~8 步时仍达 0.80 以上. ANN 模型在预报期和预报精度上较对比线性模型有明显的优越性.

## 参 考 文 献

- 1 Billings S A, Voon W S F. Least squares parameter estimation algorithms for non-linear systems. *Int J system Sci*, 1984, 15(6):601~675
- 2 Hopfield J J. Neural networks and physical system with emergent collective computational abilities. *Proc Natl Acad Sci, USA*. 1982, 79:2554~2558
- 3 Hopfield J J. Neurons with graded response have collective computational properties like those of two-state neurons. *Proc Natl Acad Sci, USA*. 1984, 81:3088~3092
- 4 Rumelhart R, Hinton G E, Williams R J. Learning internal representations by error propagation. In Rumelhart D E, McClelland J L (Eds.) *Parallel Distributed Processing: Explorations in the Microstructure of cognition*. Vol. 1 Foundation. Cambridge MA: MIT Press, 1986
- 5 Wu C Y. Application of artificial neural net-A new approach for hydrological forecasting (Abstract). 27th. International Geographic Conference, Washington D C, 1992
- 6 Wu C Y. Response of the Pearl River estuarine complex to the meteorological forcing: A cybernetics approach. *Journal of Coastal Research*, 1991, 7(4):1153~1167

## Application of Artificial Neural Net: A New Approach for Hydrological Forecasting

Wu ChaoYu\* Zhang Wen

**Abstract** A highly nonlinear artificial neural network (ANN) model is introduced as an alternative approach for river flow forecasting of the Hengshi station, the control station of the largest key project of water and electricity in Guangdong province. Data for model calibration and test include five year hourly and one year daily mean discharge. The model can efficiently simulate the nonlinear process of a real hydrological system. Comparisons are made between the ANN model and the existing system analysis models, e. g. CAR, RWTL and AR models. Totally 149 models are identified in this study, in all cases, the ANN model is superior to the system analysis models in the sense of increasing the forecasting lead time and improving the forecasting quality at the mean time.

**Keywords** hydrological forecasting, artificial neural net model, system analysis forecasting, North Jiang River

---

\* Institute of Estuary and Coast, Zhongshan University, Guangzhou 510275