

# 智能预报模式与水文中长期智能预报方法

陈守煜, 郭瑜, 王大刚

(大连理工大学土木水利学院, 辽宁大连 116024)

**[摘要]** 建立了以模糊优选、BP神经网络及遗传算法有机结合的智能预报模式与方法。在应用该方法进行中长期水文智能预报时, 首先选取训练样本的数量, 根据预报因子与预报对象的相关关系得到相对隶属度矩阵; 再将其作为BP神经网络输入值以训练连接权重; 最后将得到的连接权重值用于预报检验。计算结果表明, 智能预报模式与方法的运行速度、精度及稳定性都达到了实际应用的要求。

**[关键词]** 模糊优选; BP神经网络; 遗传算法; 智能预报模式; 中长期水文智能预报

**[中图分类号]** U641 **[文献标识码]** A **[文章编号]** 1009-1742(2006)07-0030-06

## 1 引言

预测或预报, 特别是中长期预报是自然与技术科学领域内的一个难题, 具有十分重要的理论与实际意义。由于水文现象本身的复杂性, 目前还很难用严密的物理方法对水文现象进行描述, 人们主要借助数理统计方法以及其他一些不确定的方法来描述水文现象, 以弥补物理方法的不足<sup>[1,2]</sup>。不确定的方法主要指运用概率统计<sup>[3]</sup>、时间序列<sup>[4]</sup>、模糊数学<sup>[5]</sup>和灰色理论<sup>[6]</sup>等来探索水文现象。这些方法都需有显式函数, 而难以找到, 或只能用近似表达式描述, 一般都有较大的误差。人们一直在寻找更加合理与灵活的理论和方法来对中长期水文现象进行预报与预测。笔者提出模糊优选、神经网络与遗传算法有机结合的智能预报模式与方法, 建立水文中长期智能预报新途径, 对提高水文中长期预报精度有重要意义, 也可应用于洪水预报以及其他领域的预报或预测问题, 具有普适性。

## 2 智能预报模式

因果联系是客观世界普遍联系和相互制约的表现形式之一。自然界中任何一个或一些现象或因子

都会引起另一个或另一些现象或因子的产生。设以  $y$  代表多因子作用下的某种现象, 它是人们需要预报的对象, 称预报对象。 $x_i (i = 1, 2, \dots)$  代表影响  $y$  的各种因子, 称预报因子。显然, 预报对象  $y$  是多因子作用的结果。

设有  $n$  个预报对象组成样本集合, 其特征值向量为  $y = (y_1, y_2, \dots, y_n)$ , 应用规格化公式即预报对象  $y$  对模糊概念  $A$  的相对隶属度公式<sup>[7]</sup>

$${}_y r_j = (y_j - \min y_j) / (\max y_j - \min y_j),$$
$$j = 1, 2, \dots, n \quad (1)$$

进行规格化得到  ${}_y r = ({}_y r_1, {}_y r_2, \dots, {}_y r_n) = ({}_y r_j)$ , 式中  $\max y_j, \min y_j$  分别为预报对象的最大、最小特征值。

每个样本值对应着筛选出的  $m$  个预报因子特征值, 对于  $n$  个样本, 则有预报因子特征值矩阵:

$$X = (x_{ij}), i = 1, 2, \dots, m, j = 1, 2, \dots, n \quad (2)$$

其中  $x_{ij}$  为样本  $j$  因子  $i$  的特征值。由于  $m$  个预报因子特征值的物理量纲不同, 且有的预报因子特征值与预报对象特征值之间呈正相关, 有的为负相关, 故矩阵式 (2) 应进行规格化。规格化公式要求对

[收稿日期] 2005-05-08; 修回日期 2006-06-28

[基金项目] 水利部科技创新资助项目 (SCX2000-38)

[作者简介] 陈守煜 (1930-), 男, 浙江宁波市人, 大连理工大学教授, 博士生导师, 主要研究方向: 水利水电工程、模糊水文水资源学、模糊系统与科学

$x_{ij}$  取值的正或负都适用。对正、负相关的预报因子采用不同的规格化公式，全部预报因子特征值的规格化数，均对应于模糊概念  $A$  的相对隶属度。

预报因子特征值  $x_{ij}$  与预报对象  $y$  之间呈正相关，或两者的相关系数为正时，其规格化采用

$${}_x r_{ij} = (x_{ij} - \min_j x_{ij}) / (\max_j x_{ij} - \min_j x_{ij}) \quad (3)$$

预报因子特征值  $x_{ij}$  与预报对象  $y$  之间呈负相关，或两者的相关系数为负时，其规格化采用

$${}_x r_{ij} = (\max_j x_{ij} - x_{ij}) / (\max_j x_{ij} - \min_j x_{ij}) \quad (4)$$

式中  $\max_j x_{ij}$ 、 $\min_j x_{ij}$  分别为  $n$  个样本第  $i$  个预报因子的最大、最小特征值。

矩阵式 (2) 经规格化变换为元素在  $[0, 1]$  区间的预报因子特征值规格化矩阵，即对模糊概念  $A$  的相对隶属度矩阵

$${}_x R = ({}_x r_{ij}), \quad i = 1, 2, \dots, m, \quad j = 1, 2, \dots, n \quad (5)$$

根据文献 [7] 构建智能预报的 BP 神经网络拓扑结构：网络共分为 3 层，网络的输入层节点数等于预报因子数  $m$ ，输出层只有一个节点（预报对象），隐含层节点数为  $l$ （根据经验选取），用  $i, k, p$  分别表示输入层、隐含层、输出层节点。

输入层节点  $i$  直接将信息传递给隐含层节点，故节点的输出与输入相等，即

$$u_{ij} = r_{ij} \quad (6)$$

隐含层节点的激励函数采用笔者模糊优选 Sigmoid 函数<sup>[7]</sup>。其输入、输出的函数分别为

$$I_{kj} = \sum_{i=1}^m w_{ik} u_{ij},$$

$$u_{kj} = \left\{ 1 + \left[ \left( \sum_{i=1}^m w_{ik} u_{ij} \right)^{-1} - 1 \right]^2 \right\}^{-1} \quad (7)$$

式中  $w_{ij}$  为输入层节点  $i$  到隐含层节点  $k$  的连接权重。

网络输出层节点  $p$  的激励函数也采用模糊优选 Sigmoid 函数，其输入、输出函数分别为

$$I_{pj} = \sum_{k=1}^l w_{kp} u_{kj},$$

$$u_{pj} = \left\{ 1 + \left[ \left( \sum_{k=1}^l w_{kp} u_{kj} \right)^{-1} - 1 \right]^2 \right\}^{-1} \quad (8)$$

式中  $w_{kp}$  为隐含层节点  $k$  到输出层节点  $p$  的连接权重。网络的实际输出  $u_{pj}$  就是网络对输入样本集  ${}_x r_{ij}$  的响应。设样本  $j$  的期望输出为  ${}_y r_j$ ，其平方误差为

$$E = (u_{pj} - {}_y r_j)^2 / 2, \quad j = 1, 2, \dots, n \quad (9)$$

则  $n$  个样本的平均误差为

$$E = \frac{1}{n} \sum_{j=1}^n E_j = \frac{1}{2n} \sum_{j=1}^n (u_{pj} - {}_y r_j)^2 \quad (10)$$

由式 (6) 至式 (10)，可以推出 BP 神经网络权重调整公式。隐含层节点  $k$  与输出层节点  $p$  的连接权重调整量为

$$\Delta w_{kp} = \frac{2\eta}{n} \sum_{j=1}^n \left[ u_{pj}^2 u_{kj} \frac{1 - \sum_{k=1}^l w_{kp} u_{kj}}{\left( \sum_{k=1}^l w_{kp} u_{kj} \right)^3} ({}_y r_j - u_{pj}) \right] \quad (11)$$

$\eta$  为学习效率。输入层节点  $i$  与隐含层节点  $k$  的连接权重调整量为

$$\Delta w_{ik} = \frac{2\eta}{n} w_{kp} \sum_{j=1}^n \left[ u_{ij} u_{kj}^2 \frac{1 - \sum_{i=1}^m w_{ik} u_{ij}}{\left( \sum_{i=1}^m w_{ik} u_{ij} \right)^3} \delta_{pj} \right] \quad (12)$$

式中

$$\delta_{pj} = 2u_{pj}^2 \left[ \frac{1 - \sum_{k=1}^l w_{kp} u_{kj}}{\left( \sum_{k=1}^l w_{kp} u_{kj} \right)^3} \right] ({}_y r_j - u_{pj}) \quad (13)$$

则权重调整公式为

$$w_{ik}(t+1) = w_{ik}(t) + \Delta w_{ik}(t+1) \quad (14)$$

$$w_{ip}(t+1) = w_{ip}(t) + \Delta w_{ip}(t+1) \quad (15)$$

式中  $t$  为迭代次数。应用模型式 (11) 至式 (15)，选定网络误差，就可根据模糊优选 BP 神经网络迭代算法，确定网络的连接权重值，使实际输出与期望输出的平均误差  $E$  最小。但由于神经网络 BP 模型的误差函数为平方型，存在局部极小值问题，且收敛速度较慢。为此，将模糊优选神经网络 BP 算法与遗传算法结合起来，用混合算法对网络进行训练。其训练步骤如下：

Step 1: 设有  $n$  个训练样本，已知预报对象的规格化向量、预报因子的规格化矩阵分别为：

$${}_y r = ({}_y r_1, {}_y r_2, \dots, {}_y r_n) = ({}_y r_j),$$

$${}_x R = \begin{bmatrix} {}_x r_{11} & {}_x r_{12} & \dots & {}_x r_{1n} \\ {}_x r_{21} & {}_x r_{22} & \dots & {}_x r_{2n} \\ \vdots & \vdots & & \vdots \\ {}_x r_{m1} & {}_x r_{m2} & \dots & {}_x r_{mn} \end{bmatrix} = ({}_x r_{ij}),$$

$$i = 1, 2, \dots, m, \quad j = 1, 2, \dots, n。$$

随机给出初始权重值，作为模糊优选 BP 神经网络训练的初始值，输入矩阵  ${}_x R$ ，给定网络训练计算误差的精度  $\epsilon$ 。

Step 2: 应用式 (12) 和式 (11) 计算输入层

和隐含层、隐含层和输出层的连接权重调整量值。

Step 3: 应用式 (14) 和式 (15) 计算调整后的权重值。

Step 4: 应用式 (7) 和式 (8) 计算样本集的实际输出值 (向量), 并用式 (10) 计算输出样本集的平均误差  $E$ 。

Step 5: 设  $\Delta E(t)$  为前后两次迭代结果输出值  $E$  的差值, 即  $\Delta E(t) = E(t) - E(t-1)$ , 若  $\Delta E(t) < \Delta$  ( $\Delta$  为预先设定的判断收敛速度缓慢性的指标), 转入加速遗传算法<sup>[8]</sup>。

Step 6: 根据预先设定的遗传算法参数: 群体规模、优秀个体数目、加速次数、变量 (权重) 变化范围, 应用加速遗传算法 AGA 进行循环计算之后, 再次转入模糊优选 BP 神经网络进行训练。

Step 7: 重复步骤 Step 2 至 Step 6, 直至全局误差小于预先设定的计算误差精度  $\epsilon$ 。

Step 8: 输出经过训练后的智能网络的连接权重值, 供智能预报之用, 训练结束。该网络由于结合了模糊优选、神经网络与遗传算法的有关原理, 故称其为智能网络。

智能预报步骤如下:

Step 1: 将预报对象的前期预报因子的实测值, 应用式 (3) 和式 (4) 作规格化处理, 输入已经学习、训练后的智能网络。

Step 2: 智能网络对输入做出响应, 给出输出  $y_j$ , 根据预报对象  $y$  样本资料的  $\max y_j$  与  $\min y_j$  值, 应用式 (1) 计算预报值:

$$y_j = \min y_j + y_j (\max y_j - \min y_j) \quad (16)$$

### 3 水文中长期智能预报方法

水文中长期预报有着极为重要的理论与实际意义。目前实用中存在的主要问题是预报精度较低, 难以有效地指导生产实践。为了探索提高水文中长期预报精度的有效途径, 在智能预报模式的基础上, 提出水文中长期智能预报方法。

实践表明, 表征水资源自然属性的水文现象  $y$  是一种多因子  $x_i$  综合作用的结果。

一般说来,  $y$  与单一因子之间的线性相关关系不会很好, 但从成因的角度来看,  $y$  毕竟与每个影响作用于它的单因子有着成因方面的联系, 这就从本质上决定了  $y$  与每一个单因子之间又有一定的关系。因此计算预报对象  $y$  与每一个预报因子  $x_i$  之间的线性相关系数, 根据统计相关分析有

$$\rho_i = \frac{\sum_{j=1}^n (x_{ij} - \bar{x}_i)(y_j - \bar{y})}{\sqrt{\sum_{j=1}^n (x_{ij} - \bar{x}_i)^2 \sum_{j=1}^n (y_j - \bar{y})^2}} \quad (17)$$

式中  $\rho_i$  为预报因子  $x_i$  与  $y$  的线性相关系数;  $\bar{x}_i$  为预报因子  $i$  的特征值均值;  $\bar{y}$  为预报对象  $y$  的均值。

用相关系数  $\rho_i$  绝对值的大小来衡量各个预报因子对预报对象作用影响的大小, 筛选预报因子, 并由此确定预报因子, 然后用筛选的预报因子特征值, 根据建立的水文中长期智能预报模式与方法对  $y$  做出预报。如果预报检验达到规定的精度要求, 则可以按筛选的预报因子与建立的模式进行预报, 并在预报实践中随着资料的增多不断完善模式中的计算参量, 进一步提高预报精度。否则, 应进行反馈, 再次筛选预报因子, 如此反复, 直到达到要求, 即确定出合适的预报因子为止。

### 4 实例计算

水文现象具有确定性 (必然性) 与非确定性两方面。而非确定性包含两个侧面: 水文特征值大小出现的随机性与特征值“丰”、“枯”在识别过程中的模糊性。水文现象模糊性的基本特点是识别中的亦此亦彼性<sup>[9, 10]</sup>。因此, 水文中长期智能预报方法的建立, 可基于对模糊概念丰的识别。现以新疆伊犁河雅马渡站的年径流长期预报来论述水文中长期智能预报方法。

新疆伊犁河雅马渡站的 23 年实测年径流量及其相应的前期 4 个预报因子特征值列于表 1。其中因子  $x_1$  为前一年 11 月至当年 3 月伊犁气象站的总降雨量; 因子  $x_2$  为前一年 8 月欧亚地区月平均纬向环流指数; 因子  $x_3$  为前一年 5 月欧亚地区经向 (经度方向) 环流指数; 因子  $x_4$  为前一年 6 月的 2.8 THz 太阳射电流量。

根据训练所必要的资料数量, 并考虑预报检验的需要, 将前 20 年资料用于确定智能预报模型参数, 后 3 年资料用于检验。下面应用雅马渡站的年径流资料, 阐明智能预报模式与方法的详细步骤。

1) 建立对模糊概念  $\tilde{A}$  (丰) 进行识别的参照系, 确定预报对象  $y$  与前期预报因子  $x_i$  对  $\tilde{A}$  的相对隶属函数。对  $y$  取其最大特征值  $\max y_j$  对  $\tilde{A}$  的相对隶属度为 1, 最小特征值  $\min y_j$  对  $\tilde{A}$  的相对隶属度为 0。对与  $y$  呈正相关的预报因子, 取  $\max x_{ij}$  对  $\tilde{A}$  的

**表 1 新疆伊犁河雅马渡站实测年径流量与因子特征值**

Table 1 Observed annual runoff quantities and factors feature values of Yamadu Hydrographic Sation at Yili River, Xinjiang

序号	$x_1/\text{mm}$	$x_2$	$x_3$	$x_4$ $/\text{zW}\cdot\text{m}^{-2}\cdot\text{Hz}^{-1}$	年径流量 $y$ $/\text{m}^3\cdot\text{s}^{-1}$
1	114.6	1.10	0.71	8.5	346
2	132.4	0.97	0.54	7.3	410
3	103.4	0.96	0.66	6.7	385
4	179.3	0.88	0.57	8.7	446
5	92.7	1.15	0.44	15.4	300
6	115.0	0.74	0.65	25.2	453
7	163.6	0.85	0.58	22.0	495
8	139.5	0.70	0.59	21.7	478
9	76.7	0.95	0.51	16.2	341
10	42.1	1.08	0.47	11.0	326
11	77.8	1.19	0.57	9.1	364
12	100.6	0.82	0.59	8.3	456
13	55.3	0.96	0.40	6.9	300
14	89.9	0.96	0.38	10.5	314
15	78.5	0.89	0.44	9.4	280
16	29.8	0.83	0.49	12.0	289
17	248.6	0.79	0.50	14.7	483
18	64.9	0.59	0.50	16.7	402
19	95.7	1.02	0.48	16.0	384
20	152.1	1.04	0.49	7.7	433
21	121.8	0.83	0.60	14.0	401
22	81.0	1.08	0.54	9.6	336
23	90.0	0.95	0.43	8.9	301

相对隶属度为 1,  $\min_j x_{ij}$  对  $\tilde{A}$  的相对隶属度为 0; 对与  $y$  呈负相关的预报因子, 取  $\min_j x_{ij}$  对  $\tilde{A}$  的相对隶属度为 1, 取  $\max_j x_{ij}$  对  $\tilde{A}$  的相对隶属度为 0。

2) 按表 1 的样本资料 1, 2, ..., 20, 由式 (17) 计算年径流  $y$  与各预报因子  $x_{ij}$  ( $i = 1, 2, 3, 4; j = 1, 2, \dots, 20$ ) 的相关系数分别为  $\rho_1 = 0.80, \rho_2 = -0.63, \rho_3 = 0.44, \rho_4 = 0.40$ 。对预报因子 1, 3, 4 用式 (3)、对预报因子 2 用式 (4) 作规格化处理, 则预报因子对  $\tilde{A}$  的相对隶属度矩阵即输入样本的规格化矩阵为

$${}_x R = (A \mid B \mid C),$$

$$A = \begin{bmatrix} 0.387 & 0.469 & 0.337 & 0.683 & 0.287 & 0.389 & 0.612 \\ 0.184 & 0.449 & 0.469 & 0.633 & 0.082 & 0.918 & 0.694 \\ 1 & 0.452 & 0.839 & 0.613 & 0.129 & 0.806 & 0.581 \\ 0.097 & 0.032 & 0 & 0.119 & 0.470 & 1 & 0.827 \\ 0.501 & 0.214 & 0.056 & 0.117 & 0.559 & 0.234 & 0 \\ 1 & 0.490 & 0.224 & 0.469 & 0.306 & 0.224 & 0.735 \\ 0.613 & 0.355 & 0.226 & 0 & 0.290 & 0.452 & 0.290 \\ 0.811 & 0.514 & 0.232 & 0.011 & 0.054 & 0.157 & 0.286 \end{bmatrix},$$

$$B = \begin{bmatrix} 1 & 0.160 & 0.301 & 0.275 & 0.219 & 0.324 \\ 0.816 & 1 & 0.347 & 0.469 & 0 & 0.755 \\ 0.323 & 0.258 & 0 & 0.548 & 0.613 & 0.613 \\ 0.432 & 0.541 & 0.503 & 0.205 & 0.130 & 0.080 \end{bmatrix}.$$

用式 (1) 计算得到预报对象对  $\tilde{A}$  的相对隶属度向量, 即输出样本的规格化向量为

$${}_y r = (0.277, 0.587, 0.466, 0.762, 0.053, 0.796, 1.0, 0.917, 0.252, 0.180, 0.364, 0.811, 0.053, 0.699, 0.228, 0, 0.942, 0.549, 0.461, 0.121).$$

将表 1 中前 20 年资料作为智能预报的训练样本。网络的拓扑结构为: 设置 3 层网络, 根据预报因子数输入层设 4 个节点, 根据经验隐含层设 4 个节点, 输出层为 1 个节点。

设置误差精度和智能预报混合算法的运行参数。误差精度  $\epsilon = 0.005$ , BP 神经网络的学习效率 0.8, 遗传算法的群体规模 30, 优秀个体数目 5, 加速循环次数 2, 各个权重变化范围为其本身的 0.5 倍。应用智能预报模式与混合算法对智能网络进行训练后, 得到智能网络输入层节点与隐含层节点的连接权重矩阵为

$$W = \begin{bmatrix} 0.611 & 0.278 & 0.006 & -0.011 \\ 0.115 & 0.140 & 0.832 & 0.186 \\ 0.187 & 0.430 & 0.116 & 0.300 \\ 0.379 & 0.166 & 0.020 & 0.175 \end{bmatrix}.$$

隐含层节点与输出层节点的连接权重向量为

$$w = (0.369 \quad 0.416 \quad 0.108 \quad 0.265).$$

智能网络训练预报值与实测值的对比结果列于表 2。

对雅马渡站最后 3 年的年径流量作预报检验如下: 将表 1 中序号 21, 22, 23 的预报因子  $x_i$  用式 (3) 和式 (4) 作规格化, 得到预报因子对  $\tilde{A}$  的相对隶属度矩阵

$${}_x R = \begin{bmatrix} 0.420 & 0.223 & 0.275 \\ 0.735 & 0.612 & 0.490 \\ 0.645 & 0.129 & 0.097 \\ 0.395 & 0.146 & 0.119 \end{bmatrix} = ({}_x r_{ij})$$

$i = 1, 2, 3, 4; j = 1, 2, 3。$

表 2 训练样本与实测值的对比

Table 2 Contrasting of training samples to observed quantities

样本号	预报值/ $m^3 \cdot s^{-1}$	实测值/ $m^3 \cdot s^{-1}$	相对误差/%
1	377.335	346	9.056
2	416.515	410	1.589
3	393.343 2	385	2.167
4	470.487 1	446	5.49
5	311.738 3	300	3.913
6	471.262 9	453	4.032
7	482.055	495	2.615
8	484.572 5	478	1.375
9	364.734 9	341	6.96
10	283.613 5	326	13.002
11	344.92	364	5.242
12	419.756	456	7.948
13	280.808 3	300	6.397
14	292.886 4	314	6.724
15	305.424 4	280	9.08
16	290.468 4	289	0.508
17	494.728 6	483	2.428
18	423.821 6	402	5.428
19	365.132 5	384	4.913
20	420.777	433	2.823

将上面矩阵输入训练好的智能网络，输出相应的预报对象  $y$  特征值规格化向量或对  $A$  的相对隶属度向量为

$${}_y r = ({}_y r_1, {}_y r_2, {}_y r_3) = (0.605, 0.018, 0.116)$$

将向量  ${}_y r$  代入式 (16) 得到预报检验值列于表 3。由预报检验值的相对误差可见，智能预报的检验精度令人满意。

表 3 预报检验结果

Table 3 Forecasting prove-test results

样本号	预报值/ $m^3 \cdot s^{-1}$	实测值/ $m^3 \cdot s^{-1}$	相对误差/%
21	447.678 7	401	11.641
22	343.173 6	336	2.135
23	306.968 9	301	1.983

### 5 讨论

由于神经网络初始权重以及遗传算法初始群体的产生都是随机的，因而算法的结果会产生不稳定现象。如果算法的模型选择合理，算法的参数设置合适，计算结果就会相对比较稳定。为验证算法的稳定性，选用同样的 BP 神经网络和遗传算法参数，分别单独进行 5 次计算，其预测结果如表 4。

表 4 不同次数的预报检验结果

Table 4 Forecasting prove-test results under different number

次数	样本序号	预报值/ $m^3 \cdot s^{-1}$	实测值/ $m^3 \cdot s^{-1}$	相对误差/%	平均相对误差/%	计算时间 /s	神经网络循环次数	遗传算法循环次数
1	21	440.001 3	401	9.726	4.039	93	40	15
	22	342.053 4	336	1.820				
	23	302.772 6	301	0.589				
2	21	426.703 4	401	6.41	2.545	99	202	16
	22	336.385 4	336	0.115				
	23	304.342 5	301	1.11				
3	21	438.551 6	401	9.364	5.391	79	42	13
	22	327.054 7	336	2.662				
	23	313.485 2	301	4.148				
4	21	442.031 8	401	10.232	4.263	113	79	19
	22	334.675 6	336	0.394				
	23	294.492 5	301	2.162				
5	21	435.332 8	401	8.562	5.481	100	272	15
	22	325.330 4	336	3.173				
	23	315.171 5	301	4.708				

从表 4 可以看出，每一次计算的预报和实测值都很接近，预报精度较高，满足中长期水文预报所

要求达到的精度。算法平均循环次数为 97 次，而且每次运行速度差别不大，说明算法在保持高效的

同时, 稳定性也很高。

#### 参考文献

- [ 1 ] Vasechkina E F, Timchenko I E, Yarin V D. Prediction of hydrological phenomena using self-organizing mathematical models [J]. *Oceanographic Literature Review*, 1997, 44(11): 1388
- [ 2 ] See L, Abrahart R J. Multi-model data fusion for hydrological forecasting [J]. *Computers and Geosciences*, 2001, 27(10): 987 ~ 994
- [ 3 ] Krzysztofowicz R. The case for probabilistic forecasting in hydrology [J]. *Journal of Hydrology*, 2001, 249(8): 2 ~ 9
- [ 4 ] Nayak P C, Sudheer K P, Rangan D M, et al. A neuro-fuzzy computing technique for modeling hydrological time series [J]. *Journal of Hydrology*, 2004, 291(5): 52 ~ 66
- [ 5 ] Nijssen B, Bowling L C, Lettenmaier D P, et al. Simulation of high latitude hydrological processes in the Torne(Kalix basin; PILPS Phase 2(e); 2: Comparison of model results with observations [J]. *Global and Planetary Change*, 2003, 38(7): 31 ~ 53
- [ 6 ] Xie Quanmin, Zhu Ruigeng. Gray classification for evaluation the stability of dangerous rock-block masses [J]. *Journal of Wuhan University of Technology-Materials Science*, 2000, 15(1): 73 ~ 77
- [ 7 ] 陈守煜. 复杂水资源系统优化模糊识别理论与应用 [M]. 长春: 吉林大学出版社, 2002
- [ 8 ] 金菊良, 丁 晶. 遗传算法及其在水科学中的应用 [M]. 成都: 四川大学出版社, 2000
- [ 9 ] Chen Shouyu. Relative membership function and new frame of fuzzy sets theory for pattern recognition [J]. *The Journal of Fuzzy Mathematics*, 1997, (2): 401 ~ 411
- [ 10 ] Chen Shouyu. Multi-objective decision making theory and application of neural network with fuzzy optimum selection [J]. *The Journal of Fuzzy Mathematics*, 1998, (4): 957 ~ 967

## Intelligent Forecasting Mode and Approach of Mid and Long Term Intelligent Hydrological Forecasting

Chen Shouyu, Guo Yu, Wang Dagang

(*School of Civil Engineering and Architecture, Dalian University of Technology, Dalian, Liaoning 116024, China*)

[ **Abstract** ] Intelligent calculating tools such as fuzzy optimization approaches, BP neural network and genetic algorithm are proven to be efficient when applied individually to a variety of problems. Recently, there has been a growing interest in combing all these approaches, and then, in this paper, the author organically synthesizes fuzzy optimal selection, BP neural network and genetic algorithm and establishes intelligent forecasting mode and method. When illustrating the method by an application to forecast mid and long term hydrological process of Yamadu Hydrographic Station at Yili River in Xinjiang, China, the author first selects the amount of training samples, and gets relative membership degree matrix according to the correlation of forecasting factors and forecasting objective, then takes the matrix as input of BP neural network to train link-weights, and finally, uses gained link-weight values to verify forecasting. The results are highly promising and show that the operation speed, precision and stability of intelligent forecasting mode presented in this paper can completely meet actual requirement.

[ **Key words** ] fuzzy optimal selection; BP neural network; genetic algorithm; intelligent forecasting mode; mid and long term intelligent hydrological forecasting