

基于BP神经网络的龙羊峡水库 年末消落水位控制研究^{*}

王义民, 畅建霞, 黄 强, 薛小杰, 于长生, 席秋义

(西安理工大学 水利水电学院, 陕西 西安 710048)

[摘 要] 龙羊峡水库长期处于低水位运行, 严重影响了其综合效益。运用逐步回归的方法寻找影响水库年末消落水位的主要因素, 以此为基础, 建立了控制龙羊峡水库年末消落水位的BP神经网络模型, 并采用长系列资料对逐步回归模型和BP神经网络模型的预测结果进行了比较和误差分析。结果表明, BP神经网络模型优于逐步回归模型。

[关键词] 龙羊峡水库; 年末消落水位; BP神经网络; 水位控制; 逐步回归

[中图分类号] TV 671.1

[文献标识码] A

[文章编号] 1671-9387(2005)07-0068-05

龙羊峡水库是黄河上唯一一座具有多年调节性能的龙头水库, 其总库容为 247 亿 m^3 , 正常蓄水位为 2 600 m, 装机 128 万 kW。通过其蓄丰补枯, 不仅使下游梯级获得了很好的水电效益, 而且提高了下游的灌溉用水保证率。但不可否认的是, 龙羊峡水库自建成蓄水以来, 一直处于不合理的低水位运行状态, 作者曾分析了其低水位运行的自然因素和人为因素^[1]。显然, 低水位运行损害了其长期利益, 削弱了水库的多年调节性能, 因此, 合理控制其年末消落水位, 是提高运行水位和充分发挥龙羊峡水库多年调节性能与龙头水库功能的关键。但是, 对多年调节水库, 究竟年末(水文年, 龙羊峡水库为 6 月底)水位控制在多少比较合适, 在不同的来水情况下是补还是蓄, 目前对此尚未找出很好的解决方法^[1, 2]。田嘉宁等^[3]通过分析起调水位对多年调节水库年末消落水位的影响, 获得了控制年末消落水位的单因子线性规则, 但该规则不能全面反映多年调节水库年末消落水位的影响因素和影响方式。

神经网络具有较好的模式识别能力, 可以克服统计等方法的限制, 通过自适应学习, 训练逼近任意一个非线性函数。神经网络已成功应用于水库调度中, 但多侧重于水库调度函数的获取^[4~8]。本研究首先采用逐步回归方法^[9]寻找影响龙羊峡水库年末消落水位的主要因素, 其次根据获得的影响因素, 建立控制年末消落水位的BP网络模型, 以获得龙羊峡

水库科学合理的年末控制水位, 用于指导水库调度, 扭转其低水位运行的不利方式。

1 龙羊峡水库年末消落水位的主要影响因素分析

为了建立控制龙羊峡水库年末消落水位的BP神经网络模型, 必须先分析影响年末消落水位的各种因素, 选取主要影响因素作为神经网络的输入分量。

影响多年调节水库年末消落水位的因素很多, 从理论上讲, 不仅与水库当年的年初库水位和入库水量有关, 而且与后续几年的来水以及库群中其余电站的调节方式有关^[2]。这些因素间存在一定的相关性, 可以利用以统计分析为基础的逐步回归分析方法确定相对重要的因子。其思路是: 将相关因子逐个引入, 引入的条件是该因子的偏回归平方和(即方差贡献)在没有引入方程的其余因子中为最大, 且是显著的。同时, 每引入一个新因子后, 在新方程的基础上, 再在已引入方程的因子中找出偏回归平方和最小的一个, 作显著性检验, 如不显著则剔除, 否则保留, 即每一步(引入一个变量或剔除一个变量)前后都要作 F 检验, 直到最后没有显著的变量可引入, 也没有不显著的变量可剔除为止, 实际上是双重检验的逐步回归。

设有 n 个影响年末水位的因子 x (自变量), 一

^{*} [收稿日期] 2004-10-18

[基金项目] 国家自然科学基金项目(50479024); 陕西省教育厅专项科研计划项目(04JK233)

[作者简介] 王义民(1972-), 男, 山西新绛人, 讲师, 博士, 主要从事水资源系统工程研究。

个年末消落水位值 y (因变量), 有 N 组样本值, 系数矩阵和相关系数增广矩阵分别为:

$$X = \begin{bmatrix} X_{11} & X_{12} & \dots & X_{1n} \\ X_{21} & X_{22} & \dots & X_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ X_{N1} & X_{N2} & \dots & X_{Nn} \end{bmatrix}$$

$$R = \begin{bmatrix} r_{11} & \dots & r_{1n} & r_{1,n+1} \\ X_{21} & \dots & X_{2n} & X_{2,n+1} \\ \vdots & & \vdots & \vdots \\ X_{n1} & \dots & X_{nn} & X_{n,n+1} \end{bmatrix} \quad (1)$$

其中, r_{ij} 为变量 x_i 和 x_j 的相关系数, 且

$$r_{ij} = \frac{l_{ij}}{\sqrt{l_{ii} \cdot l_{jj}}} \quad (i = 1, 2, \dots, n, j = 1, 2, \dots, n) \quad (2)$$

式中, $l_{ij} = \sum_{k=1}^N (x_{ki} - \bar{x}_i)(x_{kj} - \bar{x}_j) = \sum_{k=1}^N x_{ki}x_{kj} - N \cdot \bar{x}_i\bar{x}_j$; $l_{ii} = \sum_{k=1}^N (x_{ki} - \bar{x}_i)^2$; $l_{jj} = \sum_{k=1}^N (x_{kj} - \bar{x}_j)^2$; $\bar{x}_i = \frac{1}{N} \sum_{k=1}^N x_{ki}$; $\bar{x}_j = \frac{1}{N} \sum_{k=1}^N x_{kj}$ 。方差贡献为:

$$V_i = \frac{r_{i(n+1)}^2}{r_{ii}} \quad (3)$$

引进因子时:

$$F_1 = \frac{V_i}{r_{n+1,n+1} - V_i} (N - K - 1) \quad (4)$$

剔除因子时:

$$F_2 = \frac{V_i}{r_{ii}} (N - K - 1) \quad (5)$$

式中, K 为引入变量的次序。

计算步骤为:

(1) 计算全部因子的方差贡献 V , 选最大的 $V_{\max}$, 计算相应的 F_1 ;

(2) 若 $F_1 > F_{\alpha}(1, N - K - 1)$, 则引入该因子, 否则结束;

(3) 计算剩余因子的 V , 选 $V_{\max}$ 计算 F_1 ;

(4) 若 $F_1 > F_{\alpha}(1, N - K - 1)$, 引入该因子, 并进行下一步, 否则结束;

(5) 对已引入的因子计算 V , 选最小的 $V_{\min}$, 计算相应的 F_2 ;

(6) 若 $F_2 > F_{\alpha}(1, N - K - 1)$, 则保留全部已引入因子; 若 $F_2 < F_{\alpha}(1, N - K - 1)$, 则剔除该因子, 并重新开始步骤(5), 直到 $F_2 > F_{\alpha}(1, N - K - 1)$;

(7) 重新开始步骤(3), 直到无因子可引入。

由于龙羊峡水库的不合理运行, 所以实际调度

资料受人因素干扰太大, 不适宜作为样本系列, 因此, 本文以长系列(1950~2000年)模拟计算得出的龙羊峡水库每年年末消落水位变化过程为样本资料, 用上述逐步回归分析法, 得出龙羊峡水库年末消落水位 $Z_{\text{末}}$ 与当年初始水位 Z_0 、干流当年用水 W 、来水 W_1 , 以及后3年来水 (W_2, W_3, W_4) 6个因素显著相关, 而与未来第4年及以后的来水相关不显著。因此, 可认为 Z_0, W, W_1, W_2, W_3 和 W_4 是 $Z_{\text{末}}$ 的6个主要影响因素。同时, 相关因子 W_2, W_3 和 W_4 的获得, 与龙羊峡入库站年径流具有以3年为周期的近似周期一致。

2 控制龙羊峡水库年末消落水位的BP神经网络模型

2.1 网络结构确定

龙羊峡水库年末消落水位的BP神经网络选用三层网络结构(图1), 其中输入变量有6个, 为逐步回归确定的对龙羊峡水库年末消落水位有显著影响的6个主要因素; 输出变量为1个, 即龙羊峡水库年末消落水位 $Z_{\text{末}}$; 隐层单元数目由神经元输入、输出个数决定, 其选择应兼顾网络的学习能力和学习速度, 但对于给定的一个网络, 其隐层单元数究竟为多少, 目前还没有理论依据。本研究采用试算法确定隐层单元数。通过试算, 中间层取4个神经元。




图1 网络结构示意图

Fig. 1 Network architecture diagram

2.2 模型建立及求解

利用BP神经网络建立龙羊峡水库年末消落水位控制模型的过程大致可分为4个阶段, 即样本数据的预处理, 神经网络的训练, 利用训练后的网络确定参数、建立模型, 利用模型预测龙羊峡年末消落控制水位。其主要步骤为:

(1) 样本数据预处理。考虑到目前水文中长期预报的可靠性不高, 甚至大多数情况下仅能给出一个中长期的趋势预测结果, 难以提供定量的来水预报结果。因此, 为使模型更符合实际情况, 本研究将模

型输入的 W_2, W_3, W_4 由数字信息转化为来水年型预测信息, 分 5 个等级, 即丰水年、偏丰水年、中水年、偏枯水年和枯水年, 分别用数值 0.9, 0.7, 0.5, 0.3 和 0.1 表示。这样只要已知后 3 年的来水年型, 就可通过模型得出龙羊峡水库应消落的水位。

输入层各单元由于代表的数据物理意义不同, 量纲不同, 数量级差别较大, 在训练前需要对数据进行标准化处理, 考虑到网络训练中的转换函数是 S 型函数, 如果规范化后的输入数据出现 0 或 1, 就恰好是 S 型函数的极小或极大值, 可能导致训练速度减低。因此, 应采用如下方法规范数据, 以使规范后的数据符合 (0, 1) 的要求。

$$x'_{ki} = \frac{x_{ki}}{\max_k x_{ki} + \min_k x_{ki}} \quad (6)$$

$$y'_k = \frac{y_k}{\max_k y_k + \min_k y_k}$$

式中, $\max_k x_{ki}$ 为第 i 个输入单元 (影响因子) 的最大样本值; $\min_k x_{ki}$ 为第 i 个输入单元 (影响因子) 的最小样本值; $\max_k y_k$ 和 $\min_k y_k$ 为输出样本的最大值和最小值; $i = 1, 2, \dots, n$; $k = 1, 2, \dots, N$ 。

(2) 网络初始化。随机生成 (0, 1) 之间的随机数, 并赋给所有权值和阈值作为初值。

(3) 样本输入。对每个学习样本输入向量 $x_k = (x_{k1}, x_{k2}, \dots, x_{kn})$ 和期望输出向量 $y_k = (y_k)$ 。

(4) 计算实际输出。以每一层的输出作为下一层的输入, 依次计算各层中每个神经元的输出。隐层与输出层的输出计算公式为:

隐层:

$$b_{kj} = f \left(\sum_{i=1}^n w_{ji} x_{ki} - \theta \right) = \frac{1}{1 + \exp \left[- \left(\sum_{i=1}^n w_{ji} x_{ki} - \theta \right) \right]} \quad (7)$$

$j = 1, 2, \dots, p$

输出层:

$$C_k = f \left(\sum_{j=1}^p V_j b_{kj} - r \right) = \frac{1}{1 + \exp \left[- \left(\sum_{j=1}^p V_j b_{kj} - r \right) \right]} \quad (8)$$

式中, k 为网络训练样本 ($k = 1, 2, \dots, N$); w_{ji} 表示第 j 个隐层单元与第 i 个输入层单元间的联接权; V_j 表示输出层单元与第 j 个隐层单元间的联接权; θ 表示第 j 个隐层单元的阈值; r 表示输出层单元的阈值; n 为输入变量个数 (本文 $n = 6$); p 为隐含层

神经元个数 (本文 $p = 4$); C_k 为第 k 组样本的输出值; b_{kj} 为第 k 组样本第 j 个隐层单元的输出值。

(5) 计算网络输出误差, 网络输出误差 E 的计算公式为:

$$E = \frac{1}{N} \sum_k E_k = \frac{1}{N} \sum_k \frac{1}{2} (C_k - y_k)^2 \quad (9)$$

式中, E_k 为第 k 组样本的输出误差; y_k 为第 k 组样本的实际值。

(6) 训练终止判断。若 $E < E_p$ (系统允许误差限) 或迭代次数达到指定值, 学习结束; 否则进行误差反向传播, 继续下一步。

(7) 计算训练误差。

输出层:

$$d_k = C_k \cdot (y_k - C_k) \cdot (1 - C_k) \quad (10)$$

隐层:

$$e_{kj} = d_k \cdot v_j \cdot b_{kj} \cdot (1 - b_{kj}) \quad (11)$$

式中, d_k 为第 k 组样本输出层误差, e_{kj} 为第 k 组第 j 个隐含层单元的输出误差。

(8) 权值和阈值修正。反向计算权值和阈值, 计算公式如下:

输出单元权值:

$$v_j^{(u+1)} = v_j^{(u)} + \alpha \cdot d_k \cdot b_{kj} + \eta \cdot (v_j^{(u)} - v_j^{(u-1)}) \quad (12)$$

式中, u 为迭代次数; α ($0 < \alpha < 1$) 为参数。下同。

输出单元阈值:

$$r^{(u+1)} = r^{(u)} + \alpha \cdot d_k + \eta \cdot (r^{(u)} - r^{(u-1)}) \quad (13)$$

隐层单元权值:

$$w_{ji}^{(u+1)} = w_{ji}^{(u)} + \beta \cdot e_{kj} \cdot a_{ki} + \eta \cdot (w_{ji}^{(u)} - w_{ji}^{(u-1)}) \quad (14)$$

式中, β ($0 < \beta < 1$) 和 η ($0 < \eta < 1$) 为参数。下同。

隐层单元阈值:

$$\theta_j^{(u+1)} = \theta_j^{(u)} + \beta \cdot e_{kj} + \eta \cdot (\theta_j^{(u)} - \theta_j^{(u-1)}) \quad (15)$$

(9) $u = u + 1$, 转至第 (3) 步。

(10) 获得达到训练要求的权值和阈值, 并建立预测模型, 进行预测。

3 计算结果与分析

任意选取长系列样本资料 (1950~2000 年) 中的 40 个样本作为训练样本, 采用上述方法与计算步骤进行数据标准化和网络训练, 利用训练 5 000 次后的权值和阈值进行预测。最后用未参与训练的 10 个样本数据检验模型, 结果见表 1。为便于比较, 采用 6 个相关显著的因子建立逐步回归预测模型, 同

样对这 10 个样本进行预测, 预测结果见表 1。

表 1 BP 神经网络模型与逐步回归模型计算结果比较

Table 1 Comparison between results from BP model and those of regress analysis model

样本序号 Sample ID	样本值 Sample value	BP 模型 BP model		逐步回归 Regress analysis	
		预测值 Forecast value	相对误差/% Relative error	预测值 Forecast value	相对误差/% Relative error
1	2 593 52	2 593 12	- 0.63	2 592 48	- 1.64
2	2 589 76	2 590 11	0.59	2 588 08	- 2.81
3	2 590 14	2 589 77	- 0.62	2 588 56	- 2.63
4	2 583 54	2 583 96	0.78	2 582 62	- 1.72
5	2 580 45	2 579 65	- 1.59	2 581 95	2.97
6	2 581 38	2 581 24	- 0.27	2 580 74	- 1.25
7	2 576 43	2 576 02	- 0.88	2 577 19	1.64
8	2 570 12	2 570 33	0.52	2 570 85	1.82
9	2 572 6	2 572 24	- 0.85	2 571 96	- 1.50
10	2 576 94	2 576 82	- 0.26	2 576 03	- 1.94

为了进一步定量比较 2 种模型的预测效果, 采用以下 4 个定量指标对预测结果进行误差分析:

(1) 平均绝对百分比误差

$$E_1 = \frac{1}{N} \sum_{k=1}^N \frac{|y_k - C_k|}{|y_k|} \quad (16)$$

(2) 均方根误差

$$E_2 = \sqrt{\frac{1}{N} \sum_{k=1}^N (y_k - C_k)^2} \quad (17)$$

(3) 平均绝对误差

$$E_3 = \frac{1}{N} \sum_{k=1}^N |y_k - C_k| \quad (18)$$

(4) 均等系数

$$Y = 1 - \frac{\sqrt{\sum_{k=1}^N (C_k - y_k)^2}}{\sqrt{\sum_{k=1}^N (y_k)^2} + \sqrt{\sum_{k=1}^N (C_k)^2}} \quad (19)$$

式(16)~(19)中, y_k 和 C_k 分别为样本值和预测值, N 为样本个数。

由表 2 可以看出, BP 神经网络预测结果的平均绝对百分比误差、均方根误差、平均绝对误差均小于逐步回归模型预测结果的相应误差。均等系数表示

预测值与实际值的拟合度, 一般当 $Y > 0.90$ 时表示拟合较好。BP 神经网络的均等系数达到 0.98, 大于逐步回归模型的均等系数 0.85, 表明预测结果十分精确, 证明了模型的精确性。

表 2 2 种模型统计评价指标比较

Table 2 Comparison between the evaluation indexes of two models

特征指标 Character index	E_1	E_2	E_3	Y
BP 神经网络模型 BP model	0.000 13	0.40	0.36	0.98
逐步回归模型 Regress analysis model	0.000 41	1.11	1.04	0.85

4 结 语

多年调节水库年末消落水位的控制是多年调节水库实际运行中的一个难点。本研究采用逐步回归法找出影响年末消落水位的显著影响因子, 并以此为基础, 建立了控制龙羊峡水库年末消落水位的 BP 神经网络模型。与传统的统计方法相比, 其预测精度有所提高, 但复杂性远远增加, 计算时间也相应延长。

[参考文献]

[1] 王义民, 黄 强, 朱教新, 等. 龙羊峡水库长期低水位运行原因分析及抬高水位对策研究[J]. 水利水电技术, 2003, 34(5): 53- 56
[2] McLaughlin D, Velasco H L. Real-time control of a system of large hydropower reservoirs[J]. Water Resour Res, 1990, 26(4): 623- 635
[3] 田嘉宁, 王增发, 黄 强. 多年调节水库年末消落水位控制规则研究[J]. 西安理工大学学报, 1999, 15(1): 71- 74
[4] 胡铁松, 万永华, 冯尚友. 水库群优化调度函数的神经网络方法研究[J]. 水科学进展, 1995, 6(1): 53- 60
[5] 张保生, 纪昌明, 陈森林. 多元线性回归和神经网络在水库调度中的应用比较研究[J]. 中国农村水利水电, 2004, (7): 29- 32
[6] 王本德, 许海军. 水库防洪实时调度决策模糊推理神经网络模型及其应用[J]. 水文, 2003, 23(6): 8- 11
[7] 缪益平, 纪昌明. 运用改进神经网络算法建立水库调度函数[J]. 武汉大学学报(工学版), 2003, 36(1): 42- 45
[8] 陈建康, 马光文. 水库最优调度规则的神经网络模型[J]. 四川水力发电, 2001, 20(2): 94- 96
[9] 周纪芄. 实用回归分析方法[M]. 上海: 上海科学技术出版社, 1990

Water level control of Longyangxia reservoir based on BP at the end of year

WANG Yim-in, CHANG Jian-xia, HUANG Qiang, XUE Xiao-jie, YU Chang-sheng, XI Qiu-yi

(College of Water Resource and Hydroelectricity Engineering, Xi'an University of Technology, Xi'an, Shaanxi 710048, China)

Abstract: The Longyangxia reservoir has been operating at a low water level for a long time, which has affected the benefits of Longyangxia. In this paper, the main factors related to water level at the end of year of Longyangxia reservoir are discussed by using regress method. The BP model is also introduced for controlling Longyangxia reservoir water level. The prediction results are compared and analyzed between regress model and BP model. Results indicate that the BP model is more reasonable and feasible.

Key words: Longyangxia reservoir; water level at the end of year; back propagation network; water level control; regress analysis

(上接第 67 页)

Abstract ID: 1671-9387(2005)07-0065-EA

Factors of gene transformation affecting wheat callus

CAO Tuan-wu¹, ZHU Jian-chu¹, KANG Fu-ren², CHEN Yao-feng¹

CAO Xin¹, ZHAO Yun-xiang¹, REN Hui-li¹, LI Chu-lian¹

(1 College of Agronomy, Northwest A & F University, Yangling, Shaanxi 712100, China;

2 Yulin College, Yulin, Shaanxi 719000, China)

Abstract: The plasmid *pMA35-1* containing both *GUS* gene and *Psag12-IPT* gene was driven by CAMV35S promoter into wheat callus using ballistic method. Parameters affecting transformation efficiency were studied by *GUS* transient expression. The result showed that it had a remarkable role in the transformation efficiency at a relatively high gold particle amount per bombardment and it was best when coated by 2.0 μg DNA. The expression efficiency of *GUS* gene reduced with the increase of callus culture time and remained stable after 28 d. The examination of *GUS* gene transient expression should be at 1 d and the examination of *GUS* gene stable expression should be after 28 d.

Key words: transgenic wheat; ballistic; wheat callus (*Triticum aestivum* L.); *GUS* gene; transient expression