

雨量站分布不均匀流域的降雨径流 预报人工神经网络模型*

王双银, 冯国章, 宋松柏

(西北农林科技大学 水利与建筑工程学院, 陕西 杨陵 712100)

[摘要] 为解决传统方法难以可靠预报雨量站分布不均匀流域的次降雨径流量这一水文预报难题, 探讨了人工神经网络模型用于该类水文预报问题的可能性。实例研究表明, 以次暴雨量及其前期影响雨量为输入, 次暴雨径流总量(净雨量)为输出的BP网络模型, 预报的相对误差比蓄满产流模型预报的相对误差平均低9.2%, 这说明, 人工神经网络模型可作为雨量站分布不均匀等雨量观测存在系统偏差或不足流域的降雨径流预报模型。

[关键词] 降雨径流预报; 人工神经网络模型; 误差控制准则; 雨量站; 流域

[中图分类号] P338+.9; P333.1

[文献标识码] A

[文章编号] 1671-9387(2002)05-0081-04

洪水预报是水库安全渡汛和江河防洪最重要的非工程措施之一, 可靠的洪水预报可最大限度地防御或减轻洪水灾害。洪水预报方法一直是水文预报研究的重点^[1,2]。其中, 以水库防洪为目的的降雨-径流预报, 亦即暴雨-洪水预报, 是汛期水库调度的重要依据, 在水库调度运行中发挥着重要作用。但是, 许多水库的产流区多在山区, 往往由于自然条件等的限制或其他原因, 高山地区的雨量站点一般很少, 常遇到雨量站点在水库集水面积上分布很不均匀的现象, 严重影响着降雨径流预报的精度。例如, 某大型水库, 控制流域面积673 km², 现有5个雨量站观测降水量, 但它们都分布在坝址附近约1/3的面积上, 暴雨和产流量大的高山河源区却无雨量站, 致使用现行的降雨-径流预报方法难以由次暴雨量推求出可靠的次洪水径流量。因此, 需要对雨量站分布不均匀流域降雨-径流的可靠预报寻求新的、更为有效的途径。

人工神经网络(ANN)已被成功地用于水文预报, 其强大的非线性特点和容错能力, 使一些用其他方法难以获得理想效果的预报问题成为可能。特别是在水文过程模拟和预报中显示出比时间序列等方法更为有效的特点, 在水文预报中具有潜在的应用前景^[3]。ANN在水文预报中的应用, 包括降雨-径流模拟、降雨预报、径流预报、水质参数预报、缺测数据插补、溶质运移模拟和地下水动态模拟等, 它们有的以水文循环机理为建模的理论基础, 有的以水文时

间序列为建模依据, 涉及不同时间尺度和空间尺度^[3-12]。但是, 就降雨-径流预报而言, 现有的研究一般都是对降雨-径流“过程”的预报或模拟^[3-12], 对于次降雨形成的径流总量(净雨量)的预报, 亦即次暴雨洪水的预报, 尚未见报道。本研究拟通过实例, 探讨用人工神经网络模型预报雨量站分布不均匀流域的次降雨径流量(暴雨洪水)的可能性。

1 人工神经网络模型

1.1 BP网络

人工神经网络(ANN)的形式很多, 本研究根据研究问题的特点, 选用BP网络作为ANN建模的基本网络。

BP网络是一种多层前向神经网络。图1所示为1个典型的3层(输入层、输出层和一个隐含层)ANN结构示意图。图1中, 输入层由 n 个单元(神经元或节点)组成, $x_i (i=1, 2, \dots, n)$ 表示其输入亦即该层的输出; 隐含层由 p 个单元组成, 输出层由 q 个单元组成, $y_k (k=1, 2, \dots, q)$ 表示其输出。用 $w_{ij}^h (i=1, 2, \dots, n; j=1, 2, \dots, p)$ 表示从输入层到隐含层的连接权, 用 $w_{jk}^o (j=1, 2, \dots, p; k=1, 2, \dots, q)$ 表示从隐含层到输出层的连接权。一般地, 1个ANN若有 m 个隐含层, 且每个隐含层均由 p 个单元组成, 则将其表示为ANN(n, m, p, q)。在图1所示的ANN中, 用 z_j^h 表示隐含层的输出, 则其算式为:

$$z_j^h = f(s_j) = f\left(\sum_{i=1}^n w_{ij}^h x_i + \theta\right)$$

* [收稿日期] 2001-12-05
[基金项目] 西北农林科技大学青年专项基金(0808)
[作者简介] 王双银(1969-), 男, 甘肃镇原人, 讲师, 主要从事水文学资源的研究。

$$(i=1, 2, \dots, n; j=1, 2, \dots, p) \quad (1)$$

式中, $f(s_j)$ 是表示生物神经元特性的 S 函数 (Sigmoid 函数), 亦称响应函数或激活函数; s_j 是 j 单元的输入; θ 是阈值。对输出层, 式(1)中的 $i=j=1, 2, \dots, p; j=k=1, 2, \dots, q_0$ 。当隐含层为 m 层时, 式(1)中的 $h=1, 2, \dots, m$, 且当 $h>1$ 时, $i=1, 2, \dots,$

p_0 。具体应用时可用 $\text{tansig}(s_j)$, $\text{logsig}(s_j)$ 等函数。

$$\text{其中 } \text{tansig}(s_j) = \tanh(s_j) = \frac{e^{s_j} - e^{-s_j}}{e^{s_j} + e^{-s_j}} \quad (2)$$

$$\text{logsig}(s_j) = \frac{1}{1 + e^{-s_j}} \quad (3)$$

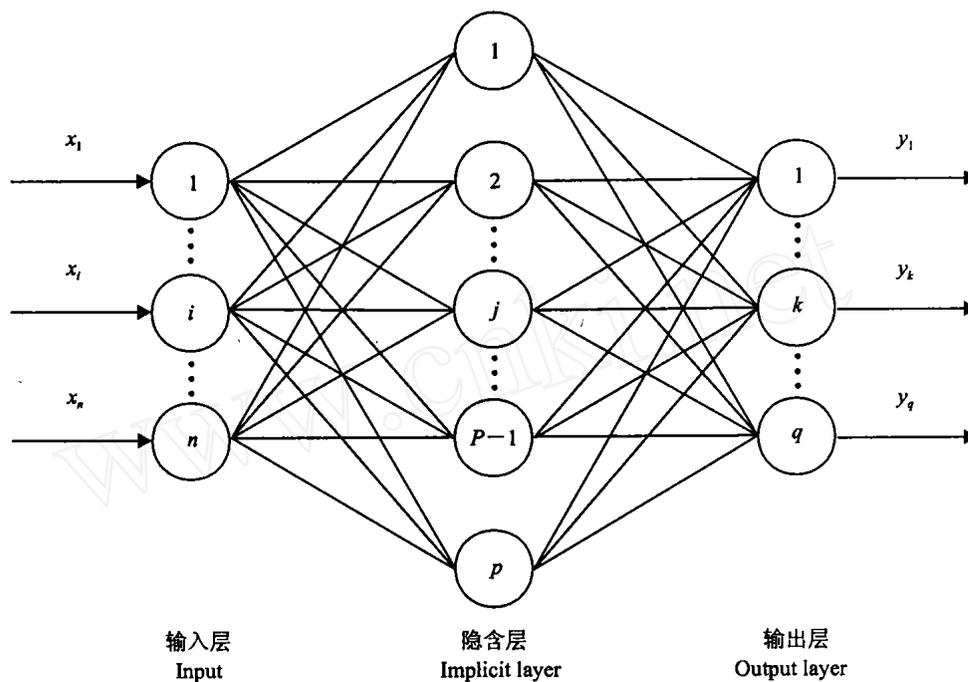


图 1 典型的 3 层 ANN 结构示意图

Fig. 1 Typical sketch map of three layer ANN

1.2 模型的基本形式

采用次暴雨洪水径流总量(净雨深) R 及与之相应的暴雨量 P 和前期影响雨量 P_a 建立 ANN 模型, 基本关系式为

$$R = f(P, P_a) \quad (4)$$

即 ANN 模型的输入层有 2 个单元(P 和 P_a), 输出层有 1 个单元(R)。建模时, 对 R , P 和 P_a 用下式进行规格化(亦称归一化)处理:

$$y = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \alpha + \beta \quad (5)$$

式中, x 和 y 分别为规格化前、后的模型输入和输出 (P, P_a, R); x_{\max} 和 x_{\min} 分别为 x 的最大、最小值; α 和 β 是规格化数据的上下限限定因子, 此处取 $\alpha=0.99$, $\beta=0.005$, 即把数据规格化为 $0.005 \sim 0.995$ 。

1.3 误差控制准则

当给定一组学习(输入)模式 $x_i (i=1, 2, \dots, N)$ (本文中为 P 和 P_a , 与时间无关), 并给定 ANN 结构, 即可用适当的算法对 ANN 进行训练, 使其输出 \hat{y}_i (预报值) 与实际输出即实测 y_i (本文中为 R , 与时间无关, 但与 P 和 P_a 对应) 之间的误差 E 小于等于

一限定值 E_0 , 即

$$E = \frac{1}{2} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \leq E_0 \quad (6)$$

则训练结束, 相应的 ANN 及其参数便构成所求问题的 ANN 模型, (6) 式便是现行的误差控制准则。

显然, E 是一个绝对量, 不同序列其值不同(即使是标准化或规格化数据也是如此), 很难确定一个恰当的 E_0 来对其进行控制。因此, 应采用与 E 有关的相对量作为判别网络训练效果及模型优劣的标准。考虑到水文预报中衡量模型或预报方案有效性的传统, 采用确定性系数作为模型评定与预报检验的标准。确定性系数的算式为:

$$D = 1 - \frac{S^2}{\sigma^2} = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} = 1 - \frac{2E}{\sum_{i=1}^N (y_i - \bar{y})^2} = 1 - \frac{2E}{(N-1)\sigma^2} \quad (7)$$

式中, S^2 和 σ^2 分别为 \hat{y}_i 误差的方差和 y_i 的方差; \bar{y} 为 y_i 的均值; D 为确定性系数, 模型评定用 D_c 表示, 预报检验用 D_v 表示; N 为用于建模或预报的暴

雨洪水次数, 模型评定和预报检验时取值不同。

2 降雨-径流ANN 模型的建立与应用

选用某水库 1970~ 1986 年的 71 场暴雨洪水资料作为研究对象, 建立降雨-径流 ANN 预报模型。该水库所处流域属于蓄满产流区, 经用蓄满产流模型计算次暴雨径流总量(净雨深), 建模的 61 场暴雨

洪水的确定性系数 $D_c = 0.719$ (模型评定), 模型预报与检验用的 10 场暴雨洪水的确定性系数 $D_v = 0.922$ 。虽然 D_c 较大, 但 71 场暴雨洪水的总体确定性系数只有 0.754 (表 1)。降雨径流关系图预报效果差的原因是雨量站分布在坝址附近, 使预报的次洪水径流总量(净雨深)存在系统偏差。

表 1 模型评定与模型检验结果

Table 1 Result of model assessment and model test

模型 Model	项目 Name	确定性系数 Deterministic coefficient	合格率/% Qualified ratio	相对误差/% Relative error		
				平均 Average	最大 Max	最小 Min
ANN _T (2, 1, 7, 1)	模型评定 Model assessment	0.941	87	11.2	68.0	0.3
	模型检验 Model verification	0.940	70	19.8	42.0	4.3
	总体 Total	0.940	85	12.4	68.0	0.3
ANN _R (2, 1, 7, 1)	模型评定 Model assessment	0.940	84	13.5	63.7	0.6
	模型检验 Model verification	0.940	90	12.7	52.7	1.0
	总体 Total	0.940	89	13.3	63.7	0.6
蓄满产流 Runoff yield at natural storage	模型评定 Model assessment	0.719	74	21.5	130.0	0.2
	模型检验 Model verification	0.922	70	19.4	58.7	0.8
	总体 Total	0.754	73	21.2	130.0	0.2

2.1 模型的建立与评定

建模采用两种方式, 一是按时序选取 61 次暴雨洪水资料建模, 另外 10 次用于预报检验, 以便同蓄满产流模型比较; 二是考虑洪水在成因上属独立事件, 建模采用的数据在时序上无关, 因此, 随机地将 71 次洪水在时序上完全打乱后选其中 51 次洪水建模, 其余 20 次洪水用于预报检验。为便于区别, 分别将两种方式建立的 ANN 模型表示为 ANN_T 和 ANN_R。

经对由式(4)确定的 BP 网络在不同隐层、不同隐层节点及节点转换函数下进行网络训练。最终认定以 1 个隐含层、7 个隐含层节点的网络为佳。这样, 两种建模方式的 ANN 结构均为 ANN(2, 1, 7, 1)。另外, 最终采用的隐层节点转换函数为 tansig 函数, 输出层节点转换函数为 logsig 函数。

结果(表 1)显示, 对第一种方式, 建模采用的 61 次洪水的 $R = f(P, P_a)$ 关系的确定性系数 $D_c = 0.941$, 第二种方式 51 次洪水的 $D_c = 0.940$ 。前者的合格率 $H_c = 87\%$, 后者的合格率 $H_c = 84\%$ 。实测 (R_m) 与计算(预报)的 (R_f) 关系见图 2。

2.2 预报与检验

用上述模型对预留洪水进行预报, 结果可得 ANN_T(2, 1, 7, 1) 和 ANN_R(2, 1, 7, 1) 的确定性系数 D_v 均等于 0.940, 但两者的合格率差异较大, 分别为 70% 和 90%。

2.3 模型的选择

对比 3 种模式(表 1), 不论从确定性系数、合格率, 还是相对误差来看, ANN 模型都优于蓄满产流模型, 而两种 ANN 模型的差别并不大, 其中确定性系数都在一个数量范围内(这是专门按此要求训练模型的结果)。从合格率看, ANN_T(2, 1, 7, 1) 的 H_c 略大于 ANN_R(2, 1, 7, 1) 的, 但 H_v 和 H_c (总合格率) 则是后者优于前者。从误差变化看, 虽然 ANN_R(2, 1, 7, 1) 的模型评定与总体平均误差均略大于 ANN_T(2, 1, 7, 1) 模型的, 但模型检验的平均相对误差则是后者远小于前者, 而且从变幅看(最大、最小相对误差), 亦可以认为 ANN_R(2, 1, 7, 1) 优于 ANN_T(2, 1, 7, 1)。特别是 ANN_R(2, 1, 7, 1) 模型采用随机选样, 且模型评定所用洪水次数是其他模型的 2 倍, 比较能够反映实际情况, 可用于该水库的洪水预报。

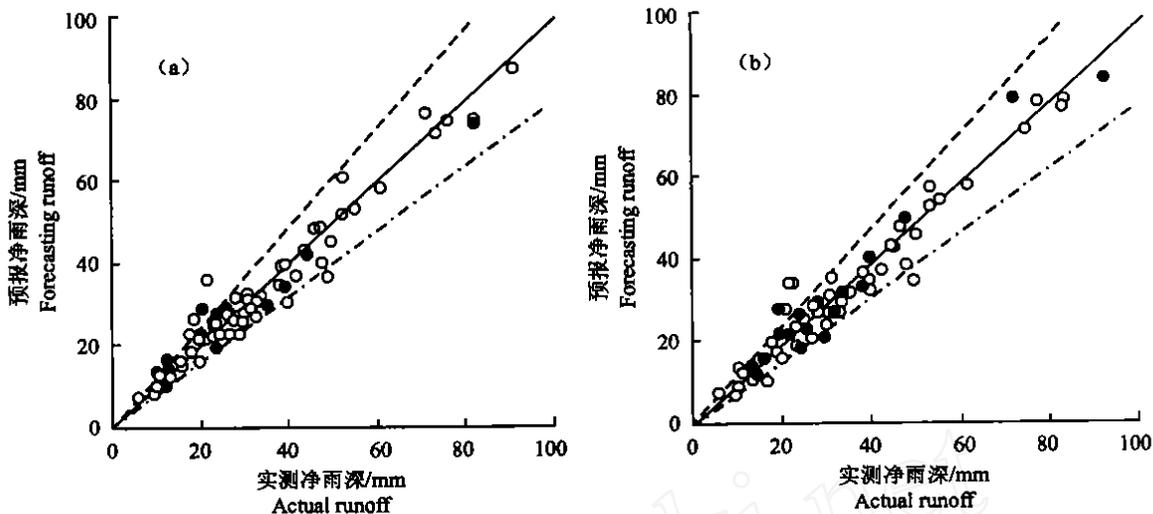


图2 ANN模型预报的净雨深与实测净雨深(次洪水总量)相关关系

(a).ANN_r(2,1,7,1)模型; (b).ANN_s(2,1,7,1)模型

○.评定值; ●.检验值; ——.1:1线; - - - - .+20%线; - · - · - .-20%线

Fig.2 Correlation between Forecasting Runoff by ANN model and Actual Runoff

(a).ANN_r(2,1,7,1) Model; (b).ANN_s(2,1,7,1) Model

○.Assessment; ●.Test; ——.1:1 line; - - - - .+20% line; - · - · - .-20% line

3 结论

1) 人工神经网络模型能够应用于流域降雨-径流预报,且预报效果良好。

2) 洪水在成因上属独立事件,采用随机选取的洪水建立的人工神经网络降雨-径流预报模型预报

结果,优于按时序选取的洪水建立的人工神经网络降雨-径流预报模型。

3) 雨量站网分布不均匀及水文资料不充分或存在系统偏差,是当前我国许多流域的现实,本研究的经验和结果表明,人工神经网络能够有效地处理这类问题,可望得到广泛应用。

[参考文献]

- [1] 长江水利委员会 水文预报方法(第2版)[M].北京:水利电力出版社,1993
- [2] 葛守西 现代洪水预报技术[M].北京:中国水利水电出版社,1999
- [3] 冯国章,李佩成 人工神经网络结构对径流预报精度的影响分析[J].自然资源学报,1998,13(2):169-174
- [4] 钟登华,王仁超,皮钧 水文预报时间序列神经网络模型[J].水利学报,1995(2):69-75
- [5] 杨荣富,丁晶,刘国东 具有水文基础的人工神经网络初探[J].水利学报,1998(8):23-27
- [6] 杨荣富,丁晶,刘国东 神经网络模拟降雨径流过程[J].水利学报,1998(10):69-73
- [7] 邱林,陈守煜,聂相田 模糊模式识别神经网络预测模型及其应用[J].水科学进展,1998,9(3):258-264
- [8] Coulibaly P, Anctil F, Bobée B. Daily reservoir inflow forecasting using artificial neural networks with stopped training approach[J]. Journal of Hydrology, 2000, 230(3-4):244-257
- [9] Luk K C, Ball J E, Shama A. A study of optimal model lag and spatial inputs to artificial neural network for rainfall forecasting[J]. Journal of Hydrology, 2000, 227(1-4):56-65
- [10] Zealand C M, Burn D H, Simonovic S P. Short term streamflow forecasting using artificial neural networks[J]. Journal of Hydrology, 1999, 214(1-4):32-48
- [11] Hsu K L, Gupta V, Sorooshian S. Artificial neural network modeling of the rainfall-runoff process[J]. Water Resources Research, 1995, 31(10):2517-2530
- [12] Smith J, Eli R N. Neural-network models of rainfall-runoff process[J]. Journal of Water Resources Planning and Management, 1995, 121(6):499-508

(下转第95页)

Regional collapse characteristics of intact loess and its rate of potential collapse

LUO Ya-sheng^{1,2}, XIE Ding-yi², XING Yi-chuan¹

(1 Institute of civil engineering, Xi'an University of Technology, Xi'an, Shaanxi 710048, China; 2 College of Water Resources and Architectural Engineering, Northwest Sci-Tech University of Agriculture and Forestry, Yangling, Shaanxi 712100, China)

Abstract: In this paper, collapse characteristics of intact loess from three typical loess areas under different moisture condition are studied, and the principles of loess collapsibility influenced by water content, dry density as well as pressure and behaviors of these in different loess are approached respectively. Base on the collapsibility difference existing in different loess area, a concept of rate of potential collapse is presented, and the test results show that it can be used to analyses the loess collapsibility and reflect the structure characteristics for different kinds of loess preferably.

Key words: intact loess; collapse characteristics; rate of potential collapse

(上接第 84 页)

Artificial neural network model of rainfall-runoff forecasting for rain gage unevenly distributed watersheds

WANG Shuang-yin, FENG Guo-zhang, SONG Song-bai

(College of Water Resources and Architectural Engineering, Northwest Sci-Tech University of Agriculture and Forestry, Yangling, Shaanxi 712100, China)

Abstract: This paper presents the possibility of using artificial neural network model to forecast runoff for rain gage unevenly distributed watersheds. Case study shows that the BP network model is significantly efficient for forecasting for rain gage unevenly distributed watersheds by using the total rainfall and the previous affected rainfall as model input, and net rainfall for runoff as model output. The forecasting relative error of the BP network model has an average value 9.2% lower than that of runoff yield at natural storage model. It is shown that artificial neural network model might be used to forecast or predict stream flow when the rainfall observation exhibits systematic errors.

Key words: rainfall-runoff forecasting; artificial neural network model; error control criteria; rain gage; watershed