

高山寒区径流预报人工神经网络模型研究 ——以乌鲁木齐河源区为例

牟丽琴, 田富强, 胡和平

(清华大学水利水电工程系, 水沙科学与水利水电工程国家重点实验室, 北京 100084)

摘 要: 开展高山寒区径流预报对合理开发利用我国西北地区水资源有重要意义, 由于恶劣自然环境造成的观测困难、干扰因素较多等问题, 建立简单有效的径流预报模型是研究高山寒区水文规律的途径之一。近年来, 人工神经网络技术作为一种简单有效的新方法被广泛应用于水文预报, 但在冰川融雪为主的流域径流预报中的应用较少, 本文以乌鲁木齐河源 1 号冰川区为研究对象, 构建了高山寒区冰川作用区径流预报的前馈型人工神经网络模型(BP-ANN)。通过 1 号冰川水文站各水文要素之间的相关分析初步确定网络的输入, 以 Nash 效率系数最大等为目标函数, 优选网络结构, 并在此基础上对所优选网络结构的合理性及模型预见期进行了分析。

关键词: 水文学; 寒区水文; 径流预报; BP 神经网络; 乌鲁木齐河源区

中图分类号: TV211.1⁺1 文献标识码: A

Artificial neural network model of runoff prediction in high and cold mountainous regions: a case study in the source drainage area of Urumqi River

MOU Liqin, TIAN Fuqiang, HU Heping

(State Key Laboratory of Hydrosience and Engineering, Department of Hydraulic
Engineering, Tsinghua University, Beijing 100084)

Abstract: Artificial neural network (ANN) model is intensively exploited for hydrological prediction. This is the case of predictions for snow/glacier melting which is of critical importance for sustainable utilization of water resources in the arid plain oases of Northwest China. In this paper, a parsimonious optimization ANN model based on back propagation algorithm is developed to simulate and predict runoff in high and cold mountainous regions. The source drainage area of the Urumqi River in Northwest China is selected for the case study. The network inputs, i. e., the preceding daily positive accumulative temperature and previous runoff are determined by the correlative analysis, and the network structure is optimized with the maximum Nash coefficient as the objection function. The detailed study has also been conducted to test the effect of alternative inputs and forecasting periods on model performance which suggests that 3—3—1 network, i. e., 3 inputs (2 days preceding positive accumulative temperature and one day preceding runoff) and 3 hidden nodes, is the optimal network structure. The reasonability of optimized network structure and the effect of different forecast periods for model performance have also been studied, which would be helpful for runoff prediction in high and cold mountainous regions.

Key words: hydrology; hydrology in cold regions; runoff prediction; artificial neural network; source drainage area of the Urumqi River

0 引言

高山寒区的冰雪消融是我国西北地区山前平原绿洲水资源的主要来源, 研究其模拟和预报方法对于合理开

收稿日期: 2007-10-25

基金项目: 国家自然科学基金青年项目(50509013)

作者简介: 牟丽琴(1981—), 女, 博士研究生. E-mail: mlq03@mails.tsinghua.edu.cn

发利用水资源具有重要意义。但在高山寒区恶劣的自然条件下, 相关观测资料难以获取且精度不高, 对资料数量、质量要求较高的物理性和概念性水文模型都难以取得理想的应用效果。人工神经网络模型模拟人脑的反馈机制, 通过学习历史资料建立输入和输出变量之间的映射关系, 具有自组织、自适应、容错性等特点, 在高山寒区径流模拟预测应用中有很潜力。事实上, 人工神经网络技术在水文水资源领域已经得到了广泛的应用^[1~5], 尤其是径流的模拟和预测^[6], 但其在冰雪融水补给为主的高山寒区径流模拟预测方面的研究还比较缺乏。为此, 本文在常规观测数据的基础上, 构建了基于误差反向传播算法的前馈型神经网络模型, 简称 BP-ANN, 利用所优选的网络结构对乌鲁木齐河源区 1 号冰川水文站径流进行模拟预测, 并对该网络结构的合理性及模型预见期进行了分析。

乌鲁木齐河源 1 号冰川位于天山中部喀拉乌成山脉主脉北坡的乌鲁木齐河源头, 属双支冰斗—山谷冰川, 面积约 $1.8/(\text{km}^2)$, 冰川最高点海拔 $4476/(\text{m})$, 冰舌末端海拔 $3734/(\text{m})$ 。1 号冰川水文站以上流域面积 $3.34/(\text{km}^2)$, 流域内年均气温在 $-5 \sim -7/(\text{℃})$ 之间, 降雪量占年降水量的 75% 以上^[7]。

1 人工神经网络结构优选

人工神经网络结构优选主要包括静态构造和动态构造两类^[8]。本文在三层前馈神经网络的基础上, 以目标函数最大为原则, 动态确定网络输入和隐含层节点数, 优选最佳网络结构, 并在此基础上对 1 号冰川水文站以上流域 5~8 月日均流量进行模拟预测。网络结构如图 1 所示, 其中网络输入 X 为水文站常规观测资料如气温、降水、前期径流等; 网络输出 Y 为当日径流量; 输入层和隐含层节点数 n_0, n_1 通过优选确定, 输出节点 n_2 为 1; 输入层与隐含层、隐含层与输出层之间分别通过 Sigmoid 函数、线性函数及相应权重系数 W, W' 和阈值 b, b' 联系。为保证训练样本充足, 同时不造成“过度训练”, 选择 1 号冰川水文站 1990—2002 年中日均流量较大、中等、较小的 3 年资料, 即 1990、1991 和 1999 年作为率定期, 其余年份作为检验期。

1.1 网络输入的确定

根据研究对象的物理意义选择网络输入, 是优选网络结构的关键^[2,9]。因此, 对 1 号冰川水文站 1990—2002 年的日均流量、日均温度、降水等系列进行相关分析, 选取与日均流量相关性好的变量作为网络输入。结果表明仅日均温度、正积温与日均流量的相关系数大于 0.5, 如图 2 所示(其中日正积温在假设白天温度正弦分布, 夜间温度指数分布的基础上, 由日最高、最低、日均温度资料求得^[10])。此外, 当时间间隔小于等于两天时, 日均流量的自相关系数大于 0.6, 但随着时间间隔的增加, 其自相关性逐渐减弱, 如图 3 所示。由此, 选取前 k 天正积温、前 n 天日均流量作为神经网络的输入, 其中 k, n 通过优选确定。




图 1 三层前馈神经网络拓扑结构
Fig. 1 Structure of 3-Layer BP-ANN model




图 2 (1990~2002 年) 日均流量与日正积温的相关关系
Fig. 2 Correlation analysis between daily runoff and positive accumulative temperature(1990—2002)




图 3 1990~2002 年日均流量自相关性
Fig. 3 Auto-correlation analysis on daily runoff(1990—2002)

1.2 训练算法及学习算法的确定

网络训练就是根据误差调整权重和阈值, 实质是非线性最优化。为了避免海森矩阵 H 为奇异矩阵的情况, 本文网络训练采用 Leveberg-Marquardt 法, 如式(1), 学习算法采用带动量的最速下降法, 该法能根据当前梯度和误差曲面最近的趋势来响应权重变化, 如式(2)。

$$W_{k+1} = W_k - H_k^{-1}g_k = W_k - [J^TJ + \mu I]^{-1}J^Te$$

(1)

$$dW = mc \times dW_{prev} + (1 - mc) \times lr \times gW$$

(2)

其中: J 为误差对权值微分的 Jacobi 矩阵, e 为误差向量, I 为单位阵, μ 为自适应调整系数, mc 为动量因子, l 为学习效率, dW_{prev} 为前一次的权重变化, gW 为按规则计算的权重变化。

1.3 数据的预处理方法的确定

各神经元往往具有不同量纲, 计算时易出现截断误差, 同时传递函数如 Tansig 函数对数据有一定的要求, 当输入绝对值过大时输出结果将出现饱和现象。因此模拟前需要对数据进行归一化预处理, 如式(3)。

$$B = B_{min} + (B_{max} - B_{min}) / (A_{max} - A_{min}) \times (A - A_{min})$$

(3)

其中: A 、 B 分别为变换前后的数据, 根据模型需求以及传递函数的取值范围确定 B_{max} 和 B_{min} , 本文将数据归一到 $[0, 1]$ 范围内, 即 $B_{max}=1$, $B_{min}=0$ 。

2 神经网络模拟及预测结果

目前对于网络结构的确定缺乏理论指导, 尤其是输入神经元个数和隐含层节点个数的确定。考虑到网络结构的简洁与性能, 本文根据率定期 Nash 效率系数、水量守恒指数极大化原则, 优选最佳的输入神经元组合以及隐含层的节点个数。优选出的网络结构是 3-3-1, 即输入神经元为前 1 天径流, 前 1 天正积温, 当日正积温; 隐含层节点数为 3 个节点, 输出神经元为当日平均流量。结果如表 1~2、图 4~5 所示。表 1、2 分别为率定期和检验期模拟结果的 Nash 效率系数 R^2 、水量守恒指数 IVF ; 图 4、5 分别为率定期和检验期的模拟流量过程线, 其中横坐标以 5 月 1 日为起始点 1, R^2 、 IVF 计算公式如式(4)、(5)所示。

Nash 效率系数:

$$R^2 = 1 - \frac{\sum_{i=1}^n (Q_i - Q_i)^2}{\sum_{i=1}^n (Q_i - Q)^2}$$

(4)

水量守恒指数:

$$IVF = \sum Q_i \backslash \sum Q_i$$

(5)

Q_i , Q_i , Q 分别为流量的计算值, 实测值及实测均值。

表1 率定期各年 Nash 效率系数 R^2 及水量守恒指数 IVF

Table 1 Nash coefficient and IVF for calibration period				
年份	1990	1991	1999	平均
R^2	0.71	0.90	0.88	0.83
IVF	1.06	1.02	0.97	1.02

对比表 1 与表 2、图 4 与图 5 可知检验期的预测结果比率定期略差, 但检验期 10 年平均 Nash 效率系数 R^2 达 0.79, 平均水量守恒指数 IVF 为 0.94, 其中预测较好的 2000 年 R^2 达 0.85, IVF 为 1.01, 预测较差为 1998 年 R^2 为 0.72, IVF 为 0.87。根据我国水文情况预报规范, 检验期预测精度都已达到我国洪水预报的乙级要求。

表2 检验期各年 Nash 效率系数 R^2 及水量守恒指数 IVF

Table 2 Nash Coefficient and IVF for Validation Period											
年份	1993	1994	1995	1996	1997	1998	1992	2000	2001	2002	平均
R^2	0.83	0.78	0.72	0.74	0.80	0.72	0.83	0.85	0.78	0.85	0.79
IVF	0.90	0.92	1.00	0.93	0.92	0.87	1.04	1.01	0.93	0.89	0.94




图4 率定期模拟结果

Fig. 4 Simulated and observed hydrograph for calibration period




图 5 检验期模拟结果

Fig. 5 Simulated and observed hydrograph for validation period

3 网络结构分析

为分析该网络结构最优性, 选择不同水文要素作为神经网络的输入, 对比其模拟结果。

3.1 将前 n 天日均流量作为网络输入

优选的网络结构: 输入前 1 日日均流量、隐含层节点为 5。模拟结果如表 3 所示, 率定期平均 Nash 效率系数为 0.72, 其中 1990 年 Nash 效率系数仅为 0.55; 检验期平均 Nash 效率系数为 0.73, 但 1995 年 Nash 效率系数仅为 0.58。

表 3 前 n 天日均流量作为输入时的模拟结果

Table 3 Evaluation merits for proceeding runoff input only models

年份	率定期				检验期										
	1990	1991	1999	平均	1992	1993	1994	1995	1996	1997	1998	2000	2001	2002	平均
R^2	0.55	0.83	0.79	0.72	0.64	0.78	0.77	0.58	0.72	0.80	0.66	0.81	0.66	0.85	0.73
IVF	1.05	1.00	0.98	1.01	1.06	0.97	0.99	1.01	0.98	0.98	0.95	0.98	0.95	0.98	1.98

3.2 将前 m 天降水、正积温以及前 n 天日均流量作为网络输入

考虑夏季降水的影响, 将前 m 天降水资料和前 k 日正积温以及前 n 天日均流量资料一并作为网络输入, 通过模型优选得到最优 $m=1, n=1, k=1$, 即前 1 天降水、当日降水、前 1 天正积温、当日正积温以及前 1 天日均流量作为输入组合, 通过优选得到网络隐含层节点为 6。

模拟结果如表 4 所示, 率定期平均 Nash 效率系数为 0.85, 其中 1990 年 Nash 效率系数仅为 0.76; 检验期平均 Nash 效率系数为 0.77, 但 1998 年 Nash 效率系数仅为 0.67, 且检验期的水量守恒指数较小, 即模拟值较实测值偏小。

将表 3 和表 4 分别与表 1、2 比较, 发现仅靠径流作为输入建立的网络性能较差; 而增加降水输入, 模型率定期效率系数改善程度不大。可见, 在正积温和前 n 天日均流量资料的基础上, 增加降水作为网络的输入神经元, 不能明显提高网络的性能, 反而隐含层节点由 3 个增加到 6 个, 增加了网络的复杂性。因此, 权衡网络的简洁与性能, 以前 1 天及当日正积温和前 1 天日均流量为输入构建的网络较优。这也验证了 1 号冰川水文站 5~8 月降水因子对径流的影响程度不大, 径流主要还是由正积温控制的冰雪融化组成。

表 4 前 m 天降水、正积温以及前 n 天日均流量作为输入时模拟结果
Table 4 Evaluation merits for pscipitation, positive accumalative temperature and runoff inputs models

年份	率定期				检验期										
	1990	1991	1999	平均	1992	1993	1994	1995	1996	1997	1998	2000	2001	2002	平均
R^2	0.76	0.91	0.90	0.85	0.81	0.78	0.83	0.74	0.74	0.77	0.67	0.84	0.77	0.82	0.77
IVF	1.09	1.03	0.98	1.03	1.08	0.85	0.93	0.96	1.01	0.86	0.85	0.96	0.88	0.86	0.92

4 不同预见期下的径流模拟

对于资料缺乏的高山寒区,上文中优选网络结构的输入条件往往不能得以满足,因此研究在不同预见期径流模拟预测的方法及模型效率随预见期的变化趋势等,具有重要的现实意义。本文利用神经网络,以各种预见期的径流或正积温组合为网络输入,当日径流为网络输出,隐含层节点分别为 1~20 的网络结构,分别针对设定的 3 种情景,分析了模型效率在不同预见期的变化规律,模拟结果如图 6~8 所示。

(1)情景 1:径流预见期分别为 1、4 天,正积温预见期为 1~4 天。即前 1 天径流,前 1 天正积温;前 1 天径流,前 2 天正积温;前 4 天径流,前 1 天正积温,依次类推等 8 种组合情况分别作为网络输入。




图 6 情景 1 率定期模拟结果
Fig. 6 Nash coefficients for case 1 in calibration period




图 8 情景 3 率定期模拟结果
Fig. 8 Nash coefficients for case 3 in calibration period




图 7 情景 2 率定期模拟结果
Fig. 7 Nash coefficients for case 2 in calibration period

(2)情景 2:正积温预见期为 1 天,径流预见期分别为 1~6 天,即前 1 天正积温,前 1 天径流;前 1 天正积温,前 2 天径流等 6 种组合情况分别作为网络输入。

(3)情景 3:正积温预见期为 4 天,径流预见期分别为 1~6 天。即前 4 天正积温,前 1 天径流;前 4 天正积温,前 2 天径流等 6 种组合情况分别作为网络输入。

图 6 中竖线左右部分分别是径流预见期为 1、4 天情况下,温度预见期从左到右依次为 1、2、3、4 天的模拟结果;图 7 中的六组点从左到右依次为正积温预计期为 1 天时,径流预见期 1~6 天的模拟结果;图 8 中的六组点从左到右依次为正积温预见期为 4 天时,径流预见期 1~6 天模拟结果。图 6~8 中每组点都包括隐含层节点分别为 1~20 情况下的 Nash 效率系数。

由图 6~8 可知,任一情景的各组试验中,随着节点数增多,模型 Nash 效率系数都不断增加。情景 1:当径流预见期为 1 天时,正积温预见期长短对模型效率影响不大,如图 6 所示;而当径流预见期增大为 4 天时,随着正积温预见期的增加,Nash 效率系数不断减少,需要通过增加隐含层节点提高模型效率,这增加了网络结构的复杂程度。情景 2:当温度预见期为 1 天时,如图 7 所示,径流的预见期长度也对模型效率影响不大。情景 3:当温度预见期为 4 天时,如图 8 所示,模型效率随着径流预见期的增长为降低。可见,当正积温和径流其中一个因子预见期为 1 天时,另外一个因子的预见期长度对模型效率的影响不大。

5 结束语

本文以 Nash 效率系数、水量守恒指数 IVF 为目标函数,通过模型优选确定乌鲁木齐 1 号冰川水文站径流模拟的网络结构 3—3—1,即当日正积温、前日正积温、以及前日径流量为输入,3 个隐层节点,输出为当日径流量的网络结构为最优网络结构。本文还分析了在不同预见期下径流模拟的模型效率的变化趋势,结果表明当正积温和径流其中一个预见期为 1 天时,另一个的预见期长度对模型效率的影响不大。可见,神经网络对于观测资料缺乏且精度不高的冰川消融为主的高山寒区径流模拟预测,不但能获得较好的模拟和预测结果,而且通过对网络结构特点的分析,能够为研究冰川消融的径流规律提供一定的参考。目前研究区域仅限于河源区冰川水文站以上流域,建立的网络结构反映了以冰川径流为主的径流规律,对于整个河源区的径流规律,涉及到积雪、冻土等因素,其径流内在规律还需进一步研究。

参考文献:

- [1] Rao S. Govindaraju. Artificial neural networks in hydrology I : Preliminary concepts[J]. Journal of Hydrology Engineering, 2000, 5(2): 115 ~ 123.
- [2] Rao S. Govindaraju. Artificial neural networks in hydrology. II : Hydrologic applications[J]. Journal of Hydrology Engineering, 2000, 5(2): 124 ~ 137.
- [3] 胡铁松,袁鹏,丁晶.人工神经网络在水文水资源中的应用[J].水科学进展,1995,6(1):76~82.
HU Tiesong, YUAN Peng, DING Jing. Applications of artificial neural network to hydrology and water resources[J]. Advances in Water Science, 1995, 6(1): 76—82. (in Chinese)
- [4] 黄国如,胡和平.基于 BP 神经网络的黄河下游引黄灌区引水量分析[J].灌溉排水,2000,19(3):20~23.
HUANG Guoru, HU Heping. Analyzing water diversion demand for irrigation areas at lower reach of Yellow River with BP neural network techniques[J]. Irrigation and Drainage, 2000, 19(3): 20—23. (in Chinese)
- [5] 黄国如,胡和平,田富强.用径向基函数神经网络模型预报感潮河段洪水位[J].水科学进展,2003,14(2):158~162.
HUANG Guoru, HU Heping, TIAN Fuqiang. Flood level forecast model for tidal channel based on the radial basis function artificial neural network[J]. Advances in Water Science, 2003, 14(2): 158—162 (in Chinese)
- [6] 徐中民,蓝永超,程国栋.人工神经网络方法在径流预报中的应用[J].冰川冻土,2000,22(4):372~375.
XU Zhongmin, LAN Yongchao, CHENG Guodong. A study on runoff forecast by artificial neural network model[J]. Journal of Glaciology and Geocryology, 2000, 22(4): 372—375. (in Chinese)
- [7] 康尔泗,施雅风,杨大庆等.乌鲁木齐河山区流域径流形成的试验研究[J].第四纪研究,1997,5(3):139~145.
KANG Ersi, SHI Yafeng, YANG Daqing, et al. An experimental study on runoff formation in the mountainous basin of the Urumqi River [J]. Quaternary Sciences, 1997, 5(3): 139—145. (in Chinese)
- [8] 孟祥武,程虎.优化神经网络结构[J].计算机研究与发展,1997,34(8):594~598.
MENG Xiangwu, CHENG Hu. Optimal neural network architectures[J]. Journal of Computer Research and Development, 1997, 34(8): 594—598. (in Chinese)
- [9] Gavin J. Bowden, Graeme C. Dandy, Holger R. Maier. Input determination for neural network models in water resources applications Part I: background and methodology[J]. Journal of Hydrology, 2005, 301: 75~92.
- [10] 丛振涛.冬小麦生长与土壤—植物—大气连续体水热运移的耦合研究[D].北京:清华大学研究生论文,2003.
CONG Zhentao. Study on coupling between winter wheat growth and water-heat transfer in soil-plant-atmosphere continuum[D]. Beijing: Tsinghua University, 2003. (in Chinese)