

地下水位动态预测的人工神经网络方法

Artificial neural network method for forecast of underground water level

郑书彦^{1,2}, 李占斌¹, 李喜安²

(1. 中国科学院水利部水土保持研究所, 陕西 杨陵 712100; 2. 长安大学, 陕西 西安 710054)

摘要: 介绍了人工神经网络的基本原理, 用该方法进行地下水位预测, 结果表明该方法精度较高, 具有一定的推广应用价值。

关键词: 地下水位; 动态预测; 人工神经网络

中图分类号: TV211.1+2

文献标识码: A

文章编号: 1008-5858(2002)02-0014-03

ZHENG Shu-yan^{1,2}, LI Zhan-bin¹, LI Xi-an²

(1. Institute of Soil and Water Conservation, the Chinese Academy of Sciences and Ministry of Water Resources, Yangling, Shaanxi 712100, China; 2. Chang'an University, Xi'an, Shaanxi 710054, China)

Abstract: In this paper, the basic principle of artificial neural network is introduced, the method for forecast of underground water level is exemplified, which is more precise and more applicable.

Key words: underground water level; dynamic forecasting; artificial neural network

在地下水动态的分析工作中, 地下水水位的预测至关重要, 但常常遇到地下水位观测资料不完整, 为了插补缺测数据, 有许多方法可资利用, 多种方法均存在优缺点, 本文将近年来在其它领域应用比较活跃的人工神经网络方法引进地下水位预测领域, 利用人工神经网络并行分布处理的高度非线性, 进行地下水位的预测。

1 原理

地下水位的变化受区域地下水系统中影响水位变化的因素所激励, 即影响因素与地下水位之间存在着一种映射关系, 这种映射关系一般是非线性的, 而人工神经网络正是一种高度非线性的并行分布处理系统, 用人工神经网络建立地下水水位预报模型, 可以达到预测地下水水位的目的。

目前人工神经网络应用中 80% ~ 90% 都是应用 BP 网络(Backpropagation)^[2], 该网络一般由一个输出层、一个输入层以及若干个隐层组成, 理论上已证明, 三层的 BP 网络能够满足绝大多数函数的映射或拟合问题^[1]。输出层、输入层的神经元数一般由所给问题来决定, 隐层的神经元数目前还没有确

定的方法, 一般根据经验或用试错法来决定^[4,5]。

BP 网络的学习机理包括正向传播和反向传播两个部分^[1]: 在正向传播的过程中, 输入信号从输入层经隐含诸层处理, 并传向输出层, 每一层神经元的状态只影响下一层神经元的状态; 若输出层不能得到期望的输出值, 则转入反向传播过程, 将实际输出信号同期望输出值之间的误差沿原来的连接通路返回, 通过修改各层神经元的权值, 使得误差信号最小。

假设 BP 网络共有 m 层, 第 l 层的节点数为 n_l , $y_k^{(l)}$ 代表第 l 层节点 k 的输出, BP 网络的误差反向传播算法(Backpropagation Algorithm)由下列步骤实现:

- (1) 给各层的连接权值 W_{ij} 和阈值 B_j 提供随机初始值, 范围 $(-1, 1)$;
- (2) 提供学习用的样本: 输入向量 X_n ($n = 1, 2, \dots, n_l$) 和期望输出 y_i ($i = 1, 2, \dots, n_l$);
- (3) 计算网络输出层的输出及隐含层输出:

$$\bar{y}_k^{(l)} = W_k^{(l)} \cdot y^{(l-1)} = \sum_{j=1}^{n_{l-1}} W_{kj}^{(l)} y_j^{(l-1)} \quad (1)$$

$$y_k^{(l)} = f\left[\bar{y}_k^{(l)}\right] \quad k = 1, 2, \dots, n_l \quad (2)$$

收稿日期: 2002-04-25

基金项目: 陕西省自然科学基金项目(2000D08)黄土高原植被重建过程中的水文效应研究资助。

作者简介: 郑书彦(1958—), 男(汉族), 在读博士。主要从事水土保持、地质工程、水资源及相关领域的教学和科研工作, 发表学术论文 20 余篇, 合作出版著作 3 部。

式中: $W_k^{(l)}$ 为连接第 $l-1$ 层节点 k 的权向量, $Y^{(0)} = X$ 。

(4) 计算输出层、隐含层的训练误差:

$$E(W) = \frac{1}{2} \sum_{k=1}^{n_m} (Y_k - \hat{Y}_k)^2 \quad (3)$$

这里 \hat{Y}_k 为网络的输出, 且 $\hat{Y}_k = y_k^{(m)}$ 。

(5) 用求得的 $E(W)$ 由梯度下降法修正权值, 既权向量 $W_i^{(l)}$ 的修正可由下式求得:

$$\Delta(W)_i^{(l)} = -\alpha \frac{\partial E}{\partial W_i^{(l)}} = \alpha \delta_i^{(l)} y^{(l-1)} \quad (4)$$

式中:

$$\delta_i^{(l)} = (Y_i - Y_i^{(m)}) f'(Y_i^{(m)}) \quad (5)$$

对于输出层, 而对于其它层:

$$\delta_i^{(l)} = \sum_{j=1}^{n_{l+1}} W_{ij}^{(l+1)} \delta_j^{(l+1)} f'(Y_i^{(l)}) \quad (6)$$

$l = 1, 2, \dots, m-1$

(6) 判断输出是否满足精度要求, 这里可取:

$$E(W) \leq \epsilon$$

ϵ 为所给的误差限, 是一个很小的正数, 若满足要求, 则停止, 否则转到 2)。

网络的学习过程, 就是网络节点间连接权的自适应、自组织过程, 经过多次学习训练后, 网络具有了对学习样本的记忆、联想能力, 就可以进行下一步的预测评价过程。

2 实例

本文利用实测资料, 某地傍河试验井 24 个月地下水水位实测序列值及河道流量、气温、饱和差、降水量、蒸发量五个影响因素实测值^[3], 将这些资料整理列于表 1。

根据这个实例, 我们知道 BP 网络的输入层有五个神经元, 输出层有一个神经元, 隐层经试算确定为 11 个神经元, 这时的网络拓扑结构如图 1 所示。

表 1 地下水位及预测因子实测值

| 序号 | 河道流量 X_1 | 气温 X_2 | 饱和差 X_3 | 降水量 X_4 | 蒸发量 X_5 | 水位埋深 Y |
|----|---------------|-------------|--------------|--------------|--------------|-------------|
| 1 | 1.50 | - 10.00 | 1.20 | 1.00 | 1.20 | 6.92 |
| 2 | 1.80 | - 10.00 | 2.00 | 1.00 | 0.80 | 6.97 |
| 3 | 4.00 | - 2.00 | 2.50 | 6.00 | 2.40 | 6.84 |
| 4 | 13.00 | 10.00 | 5.00 | 30.00 | 4.40 | 6.50 |
| 5 | 5.00 | 17.00 | 9.00 | 18.00 | 6.30 | 5.75 |
| 6 | 9.00 | 22.00 | 10.00 | 113.00 | 6.60 | 5.54 |
| 7 | 10.00 | 23.00 | 8.00 | 29.00 | 5.60 | 5.63 |
| 8 | 9.00 | 21.00 | 6.00 | 74.00 | 4.60 | 5.62 |
| 9 | 7.00 | 15.00 | 5.00 | 21.00 | 2.30 | 5.96 |
| 10 | 9.50 | 8.50 | 5.00 | 15.00 | 3.50 | 6.30 |
| 11 | 5.50 | 0.00 | 6.20 | 14.00 | 2.40 | 6.80 |
| 12 | 12.00 | 0.50 | 4.50 | 11.00 | 0.80 | 6.90 |
| 13 | 1.50 | 11.00 | 2.00 | 1.00 | 1.00 | 6.70 |
| 14 | 3.00 | - 7.00 | 2.50 | 2.00 | 1.30 | 6.77 |
| 15 | 7.00 | 0.00 | 3.00 | 4.00 | 4.10 | 6.67 |
| 16 | 10.00 | 10.00 | 7.00 | 0.00 | 3.20 | 6.33 |
| 17 | 4.50 | 18.00 | 10.00 | 19.00 | 6.50 | 5.82 |
| 18 | 8.00 | 21.50 | 11.00 | 81.00 | 7.70 | 5.58 |
| 19 | 57.00 | 22.00 | 5.50 | 186.00 | 5.50 | 5.48 |
| 20 | 35.00 | 19.00 | 5.00 | 114.00 | 4.60 | 5.38 |
| 21 | 39.00 | 13.00 | 5.00 | 60.00 | 3.60 | 5.51 |
| 22 | 23.00 | 6.00 | 3.00 | 35.00 | 2.60 | 5.84 |
| 23 | 11.00 | 1.00 | 2.00 | 4.00 | 1.70 | 6.32 |
| 24 | 4.50 | - 7.00 | 1.00 | 6.00 | 1.00 | 6.56 |

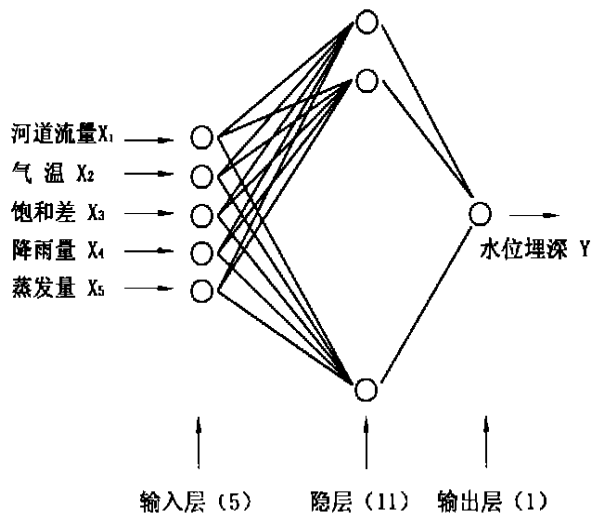


图1 BP网络拓扑结构图

我们用序列 6~24 作为已知样本训练网络, 由于输入、输出各因子量纲不同, 训练时先将数据进行归一化处理, 用 \bar{S} 为网络权值矩阵赋初值, 训练精度为 0.01, 学习率为 0.02, 递增乘因子 1.05, 递减乘因子 0.7, 误差速率 1.04, 经训练得到网络的权值矩阵与阈值矩阵 B , 计算拟合值列于表 2。

表2 拟合成果表

| 训练样本 | 拟合值 (m) | 实测值 (m) | 绝对误差 (m) | 相对误差 (%) |
|------|---------|---------|----------|----------|
| 6 | 5.45 | 5.54 | -0.09 | 1.62 |
| 7 | 5.83 | 5.63 | 0.20 | 3.56 |
| 8 | 5.67 | 5.62 | 0.05 | 0.88 |
| 9 | 6.19 | 5.96 | 0.23 | 3.86 |
| 10 | 6.32 | 6.30 | 0.02 | 3.17 |
| 11 | 6.63 | 6.80 | -0.17 | 2.50 |
| 12 | 6.61 | 6.90 | 0.29 | 4.20 |
| 13 | 6.65 | 6.70 | -0.05 | 0.75 |
| 14 | 6.81 | 6.77 | 0.04 | 0.59 |
| 15 | 6.54 | 6.67 | -0.13 | 1.95 |
| 16 | 6.39 | 6.33 | 0.06 | 0.95 |
| 17 | 6.25 | 5.82 | 0.43 | 7.39 |
| 18 | 5.34 | 5.58 | -0.24 | 4.30 |
| 19 | 5.56 | 5.48 | 0.08 | 1.46 |
| 20 | 5.43 | 5.38 | 0.05 | 0.93 |
| 21 | 5.52 | 5.51 | 0.01 | 0.18 |
| 22 | 5.90 | 5.84 | 0.06 | 1.03 |
| 23 | 6.52 | 6.32 | 0.20 | 3.16 |
| 24 | 6.57 | 6.56 | 0.01 | 0.15 |

从表 2 可以看出, 17 号误差比较高(7.39%),

这可能有不确定的因素在起作用, 其余拟合精度很高, 相对误差均小于 5%。

用训练好的网络进行预测, 序列 1~5 作为检测样本, 预测水位埋深值列于表 3。

表3 预测成果表

| 检测样本 | 预测值 (m) | 实测值 (m) | 绝对误差 (m) | 相对误差 (%) |
|------|---------|---------|----------|----------|
| 1 | 6.84 | 6.92 | -0.08 | 1.16 |
| 2 | 6.90 | 6.97 | -0.07 | 1.00 |
| 3 | 6.66 | 6.84 | -0.18 | 2.63 |
| 4 | 6.27 | 6.50 | -0.23 | 3.54 |
| 5 | 5.87 | 5.75 | 0.12 | 2.09 |

从表 3 我们看到, 预测结果最大误差 3.54%, 最小误差 1.0%, 人工神经网络用于地下水位动态预测有较高的预测精度, 计算方法比较成熟, 目前比较流行的多元回归分析、灰色聚类分析、模糊模式识别法、季节性指数平滑法等, 与人工神经网络模型用于地下水位预测可比较检验。

3 结 论

利用 BP 网络进行地下水水位预报是一种新方法, 该方法预测精度较高, 具有一定的推广应用价值。

为了提高精度, 要收集新资料充实已知序列来训练网络, 不断提高 BP 网络用于地下水水位的预报能力。

参考文献:

- [1] Hassoun M. Foundations of artificial neural networks [M]. MIT Press, Cambridge, 1995.
- [2] 焦李成. 神经网络计算[M]. 西安: 西安电子科技大学出版社, 1995.
- [3] 樊保东. 山区地下水动态关联分析[J]. 地下水, 1997(1).
- [4] A. N. Michel, J. Si and G. Ten. Analysis and synthesis of a class of discrete-time neural networks described on hypercubes[J]. IEEE Trans. NN, 1991, 2: 32—46.
- [5] E. Maron. AM neural networks with concatenated vectors and nonzero diagonal terms[J]. Neural Networks, 1990, 3: 311—318.