

基于改进型 BP 神经网络马尔科夫模型的区域需水量预测

朱新国¹,张展羽¹,祝 卓²

(河海大学水利水电学院 ,江苏 南京 210098 ;2. 桐乡市水利局 ,浙江 桐乡 314500)

摘要 :为提高需水量预测的精确度 ,应用了一种 BP 神经网络与马尔科夫相结合的预测模型 ,介绍了它的基本原理及算法 ,并给出了该模型建立的具体过程 ,最后该模型被应用于需水量预测工作中 ,计算证明取得了较好的效果。

关键词 :BP 神经网络 ;马尔科夫模型 ;需水量预测

中图分类号 :TV21 文献标识码 :A 文章编号 :1004-693X(2010)02-0028-04

Prediction of water demand based on improved BP neural network and Markov model

ZHU Xin-guo¹ , ZHANG Zhan-yu¹ , ZHU Zhuo²

(1. College of Water Conservancy and Hydropower Engineering , Hohai University , Nanjing 210098 , China ;
2. Tongxiang Water Conservancy Bureau , Tongxiang 314500 , China)

Abstract : In order to enhance the prediction accuracy of water demand forecasting , the BP neural network model was used in combination with the Markov model . The basic principle and algorithm were introduced in detail , and the model development process was also described . This model was applied to a water demand forecasting example and obtained good results .

Key words : BP network ; Markov model ; water demand forecasting

需水量预测在区域建设规划、水资源优化配置与调度管理中具有重要作用。由于用水系统的复杂性、需水量的季节性以及气候变化等 ,使得确定的需水量模拟和预测模型难以建立 ,因此国内外大多数的需水量预测方法都建立在对历史数据的统计分析的基础上。根据对数据处理方式的不同 ,预测方法可分为时间序列法、回归分析、灰色模型、神经网络、系统动力学方法、组合预测模型和分类预测模型等。预测方法多种多样 ,然而在众多的预测方法中寻找一种适合需水量预测的方法仍然比较困难。刘俊良等^[1]将 BP(back propagation)神经网络方法引入到城市需水量预测中 ;杨维等^[2]采用 BP 人工神经网络对辽宁省营口市人均综合用水量进行预测 ,进而预测出城市需水量 ,取得了满意的效果 ;张雪飞等^[3]设定不同的神经网络运行次数 ,根据预测结果

进行误差分析 ,BP 神经网络需水量预测中网络运行 5 000 次时 ,具有高度的可信度和可行性。笔者提出了一种基于改进的 BP 神经网络与马尔可夫链的组合预测方法 ,首先采用 BP 神经网络 ,用少量的样本数据粗略拟合需水量曲线 ,在此基础上借助马尔可夫链缩小预测区间以提高预测精确度 ,从而为需水量预测提供一种新的思路。

1 BP 神经网络与马尔可夫链组合预测模型的构建

1.1 改进的 BP 神经网络学习算法

BP 算法是一种正向求解、反向传播误差并达到修改网络层次之间权值和阈值的网络模型。BP 算法的步骤是 :对一个输入样本 ,从输入层经隐层逐层正向计算 ,得到输出层的输出。若得到了期望的输

出,学习算法结束,否则,转至反向传播。反向传播就是将误差信号按原连接通路反向计算,由梯度下降法调整各层神经元的权值和阈值,从而使网络输出逼近期望输出,通常使之达到误差均方差取最小为止。

BP 算法成功地用于训练多层网络具有重大的意义。但在实际应用中,BP 算法遇到了两个困难:一是收敛速度慢,训练时间长;另一个是训练易陷入局部极小。针对以上问题及现象,众多学者都对 BP 算法进行了改进。笔者在此基础上进行了深入的研究,结合已有的改进方法,采用下列方案对 BP 进行改进。

1.1.1 基于 LM 改进 BP^[4]

为了进一步减小振荡、加快收敛速度,笔者利用 LM 算法对网络权值和阈值进行修正。该算法由经典 Newton 算法发展而来,利用非线性最小二乘法来推演 Hessian 矩阵的近似形式,大大地减少了计算量。LM 算法的基本方法是:

$$\mathbf{w}(k+1) = \mathbf{w}(k) - [\mathbf{J}^T(k)\mathbf{J}(k) + \mu(k)\mathbf{I}]^{-1}\mathbf{J}^T(k)\mathbf{e}(k) \quad (1)$$

式中: $\mathbf{w}(k)$ 为当前的权值和阈值矩阵; $\mathbf{J}(k)$ 为当前网络的 Jacobian 矩阵; $\mathbf{I}$ 为单位矩阵; $\mathbf{e}(k)$ 为当前网络的误差项; $\mu(k)$ 为自适应因子,当 $\mu(k)$ 很小时,LM 算法接近高斯-牛顿法,当 $\mu(k)$ 很大时,则接近最速下降法。 $\mu(k)$ 的调整方法如下:若 $e(k+1) \geq e(k)$,则 $\mu(k+1) = 10\mu(k)$;否则 $\mu(k+1) = \mu(k)/10$ 。

1.1.2 隐层节点数优化^[5]

BP 网络隐层节点数直接影响着网络的容量、泛化能力、学习速度和输出性能。虽然神经网络神经元的冗余说明它具有良好的容错性,但冗余太多,网络性能势必会受到一定的影响,以致降低预测精度。所以,有必要采用适当大的隐含层节点数。根据隐含层结点之间的相关性大小合并结点,分散度大小删除结点,确定一个最佳的网络结构。

设 y_{ip} 为隐含层结点 i 在学习第 p 个样本时的输出, $\bar{y}_i$ 为隐含层结点 i 在学习 N 个样本的平均输出, N 为训练样本总数:

$$\bar{y}_i = \frac{1}{N} \sum_{p=1}^N y_{ip} \quad (2)$$

隐含层结点的相关系数 r_{ij} :

$$r_{ij} = \frac{\frac{1}{N} \sum_{p=1}^N y_{ip}y_{jp} - \bar{y}_i\bar{y}_j}{\sqrt{\left(\frac{1}{N} \sum_{p=1}^N y_{ip}^2 - \bar{y}_i^2\right)\left(\frac{1}{N} \sum_{p=1}^N y_{jp}^2 - \bar{y}_j^2\right)}} \quad (3)$$

r_{ij} 说明隐含层结点 i 和 j 之间的相似程度。 r_{ij} 过大,

说明结点 i 和 j 非常相似,需要合并。

样本对隐含层结点的输出的分散度 S_i :

$$S_i = \frac{1}{N} \sum_{p=1}^N y_{ip}^2 - \bar{y}_i^2 \quad (4)$$

S_i 过小,说明隐含层结点 i 的输出值变化很小,它对网络训练没有起什么作用,可删除此结点。

当 $|r_{ij}| > c$ 且 $S_i > d$ 和 $S_j > d$ 时,则隐含层结点 i 和 j 可以合二为一;若 $S_i < d$ 时,则隐含层结点 i 可以删除。一般 c 取 $0.8 \sim 0.9$, d 取 $0.001 \sim 0.01$ 。

1.2 马尔可夫预测模型的应用

马尔可夫链是一种特殊的随机过程,它的基本原理是:按照某系统的发展,时间可离散为 $n = 0, 1, 2, 3, \dots$, 对每个系统的状态可用随机变量表示,并且对应一定的概率,称为状态概率^[6]。当系统由某一阶段状态转移到另一阶段状态时,在这个转移过程中,存在着转移的概率,称为转移概率。如果转移概率只与目前相邻两状态的变化有关,即下阶段的状态只与现在状态有关而与过去无关,那么这种离散状态按照离散时间的随机转移系统过程,称为马尔可夫过程。

马尔可夫链预测的理论基础是马尔可夫过程,对其运动变化的分析,主要是研究链内有限马尔可夫过程的状态及其相互关系,进而预测链的未来状况,据此作出决策。马尔可夫模型可表示为:

$$\mathbf{x}(n) = \mathbf{x}(0)\mathbf{p}^n \quad (5)$$

式中: $\mathbf{x}(n)$ 为 n 时刻的状态概率向量; $\mathbf{x}(0)$ 为初始时刻的状态概率向量; $\mathbf{p}$ 为状态转移概率矩阵。上式具有根据 $\mathbf{p}$ 及 $\mathbf{x}(0)$ 预测第 n 步的意义。

对于 BP 神经网络,将前期神经网络预测值与实测值的相对差值 δ 所处的不同上下阈值作为状态划分值域,由此来建立状态划分标准。取 $y_{k(i)}$ 为 i 时刻位于状态 k 的样本,设 k 状态样本数为 N_{kj} ;系统总样本数为 N ,则从状态 k 到状态 j 的转移概率 P_{kj} 为^[7]:

$$P_{kj} = \frac{N_{kj}}{N} = \frac{N_{kj}}{\sum_{j=1}^N N_{kj}} \quad (6)$$

根据预测时刻状态转移概率组成各步转移概率向量 $\mathbf{x}(n)$ 中最大列向量概率值,确定预测时刻状态概率,对神经网络预测值进行修正,完成计算。

2 BP 神经网络马尔可夫预测模型的应用^[7-10]

应用 BP 神经网络马尔可夫预测模型,对文献[11]中的资料进行实例计算,预测 2006 年、2007 年、2010 年以及 2015 年的区域需水量。

2.1 建模原理

神经网络马尔可夫预测的基本思想 :首先建立 BP 神经网络预测模型 ,再对由 BP 神经网络预测得到的结果运用马尔可夫模型 ,分析其误差的波动幅度与波动发展趋势 ,获得误差的状态转移概率矩阵 ,并据此矩阵对 BP 神经网络预测结果进行修正 ,每个预测值被修正为一组由概率状态表示的预测区间值。

2.2 建模步骤

BP 神经网络马尔可夫预测模型的具体步骤如下。

2.2.1 建立 BP 神经网络模型

利用 MATLAB 构造 BP 神经网络的初始结构 :采用 3 层 BP 网络结构 ,输入层含 n_1 个神经元 (以前 1 年用水量为输入 , $n_1 = 1$) ,输出层含 n_3 个神经元 ($n_3 = 1$) , n_2 个隐含神经元。采用上述改进的 BP 学习算法训练网络 ,随机生成网络权值和域值初始值 ,允许误差设为 0.001。网络按照上述 1.1.1 中的改进进行学习 ,直至达到规定的学习精度。当网络达到稳定后 ,开始进行网络结构优化 ,隐含层结点的合并和删除 ,最终得到优化的 BP 神经网络结构为 1-10 -1。对前 15 组训练样本的实际输出和理想输出的结果及其相对误差分析见表 1。

表 1 BP 用水量拟合结果

年份	实际用水量/ (万 m ³ ·a ⁻¹)	预测用水量/ (万 m ³ ·a ⁻¹)	相对误差/ %
1990	217.09	220.29	1.473
1991	363.94	358.76	1.424
1992	487.90	508.59	4.241
1993	630.94	670.37	6.249
1994	856.51	844.63	1.387
1995	1073.70	1031.91	3.896
1996	1373.50	1232.53	10.264
1997	1487.91	1446.94	2.756
1998	1543.69	1675.34	8.523
1999	1610.99	1917.73	19.038
2000	2361.92	2174.22	7.948
2001	2533.12	2444.59	3.497
2002	2852.80	2728.43	4.361
2003	2834.61	3025.27	6.723
2004	3386.59	3284.24	3.022
2005	4051.96	3654.53	9.809

从表 1 可见 ,1990 年到 2005 年拟合值的平均误差约为 5.821 % ,最大误差为 19.038 %。

2.2.2 根据预测对象的具体情况 ,划分状态区间

根据表 1 中 BP 拟合值相对误差 ,考虑到数据量不多的实际情况 ,将马尔可夫状态区域划分为如下 3 种状态 :①[0 ,4%] ,②(4% ,10%]和 ③(10% ,20%]。根据上述分类 ,可获得 1990 ~ 2003 年需水量 BP 预测结果的马尔可夫状态转移情况 ,如表 2 所示。

表 2 1990 ~ 2003 年需水量预测结果的马尔可夫状态转移

状态	①	②	③	合计
①	2	3	1	6
②	2	2	1	5
③	1	1	0	2
合计	5	6	2	13

2.2.3 计算转移概率矩阵

由表 2 可确定马尔可夫状态转移概率矩阵

$$P = \begin{bmatrix} 0.333 & 0.500 & 0.167 \\ 0.400 & 0.400 & 0.200 \\ 0.500 & 0.500 & 0.000 \end{bmatrix}$$

2.2.4 预测

根据马尔可夫链预测模型 ,得到 2004 年、2005 年、2010 年以及 2015 年的需水量预测状态向量 ,如表 3 所示。综上所述 ,可得出需水量的最终预测结果 ,如表 4 所示。

表 3 需水量预测状态向量

状态	2004 年	2005 年	2010 年	2015 年
①	0.400	0.393	0.390	0.390
②	0.400	0.455	0.455	0.455
③	0.200	0.156	0.156	0.156

2004 年、2005 年 BP 网络预测误差分别为 3.022 %和 9.809 % ,马尔可夫修正后的预测误差分别为 1.083 %和 7.000 %。可见 BP 神经网络马尔可夫预测精度更高。而且 ,BP 神经网络马尔可夫给出了预测值区间及其概率 ,能反映需水量变化所处的状态 ,比直接应用 BP 预测更具说服力 ,更易于接受。预测的 2010 年和 2015 年需水量分别为 5 465.4 万 m³/a 和 7 077.2 万 m³/a。

表 4 需水量实际值、BP 拟合值与马尔可夫改进值对比

年份	实测值/ (万 m ³ ·a ⁻¹)	BP 拟合值/ (万 m ³ ·a ⁻¹)	马尔可夫链改进后的 预测结果		预测值/ (万 m ³ ·a ⁻¹) (取最大概率 中间值)
			预测区间	概率/%	
2004	3386.59	3284.24	[3284.24 3415.61]	0.400	3349.93
			[3415.61 3612.66]	0.400	
			[3612.66 3941.09]	0.200	
2005	4051.96	3654.53	[3654.53 3800.71]	0.393	4335.60
			[3800.71 4019.98]	0.455	
			[4019.98 4385.44]	0.156	
			[5107.84 5312.15]	0.390	
2010	—	5107.84	[5312.15 5618.62]	0.455	5465.39
			[5618.62 6129.41]	0.156	
			[6614.32 6878.80]	0.390	
2015	—	6614.23	[6878.80 7275.65]	0.455	7077.23
			[7275.65 7937.08]	0.156	

3 结 语

有限样本训练的 BP 网络结构往往不完全稳定 ,由其完成的后续预测值一般是在一定范围内波

动的。笔者采用了马尔可夫模型分析方法,有效地预见和修正了由于系统的随机性产生的预测不确定性误差,得到了更准确的预测结果,具有较强的科学性。该方法不仅预测精度高,而且简便实用,可操作性强。此外,笔者构建的改进型 BP 神经网络,经实例验证该方法可行。

参考文献：

[1] 刘俊良,刘兴坡,张树军,等. BP 神经网络在城市需水量预测中的应用[J]. 河北建筑工程学院学报, 2001, 19(2): 1-3.

[2] 杨维,王恩德,陈畅. 应用 BP 神经网络预测城市需水量的探析[J]. 资源调查与环境, 2003, 24(3): 217-221.

[3] 张雪飞,郭秀锐,程水源,等. BP 神经网络法预测唐山市需水量[J]. 安全与环境学报, 2005, 5(5): 95-98.

[4] 曹邦兴. LM 算法在地下水动态预测中的应用研究[J]. 广西水利水电, 2007(3): 4-5.

[5] 罗强,任庆利,罗莉. 应用 BP 神经网络研究水滑石/聚合

物纳米复合材料的制备工艺[J]. 稀有金属材料与工程, 2007, 36(2): 283-285.

[6] 刘克. 实用马尔可夫决策过程[M]. 北京: 清华大学出版社, 2004.

[7] 陈继光,祝令德. 基于神经网络的马尔可夫预测模型[J]. 计算机工程与应用, 2006, 42(6): 225-226.

[8] 杨励雅,邵春福. 基于 BP 神经网络与马尔可夫链的城市轨道交通周边房地产价格的组合预测方法[J]. 吉林大学学报: 工学版, 2008, 38(3): 514-519.

[9] 王义民,于兴杰,畅建霞,等. 基于 BP 神经网络马尔科夫模型的径流量预测[J]. 武汉大学学报: 工学版, 2008, 41(5): 14-17.

[10] 吕佳良,张振刚. 基于灰色关联指标筛选的 BP 神经网络中长期电力负荷滚动预测马尔可夫残差修正模型研究[J]. 华东电力, 2008, 36(9): 10-13.

[11] 翟春年. 开发区给水规划中需水量预测的研究[D]. 天津: 天津大学, 2007.

(收稿日期 2009-05-20 编辑 徐 娟)

(上接第 12 页)

c. 总体而言,平阴湿地是由鱼塘改建而成的,采用天然基质,没有特别的强化脱 N 设计,使得去 N 效果并不理想。湿地的设计和运行维护还需要进一步改进,如引入去污效果较好的水生植物,定期更换底泥等。

参考文献：

[1] 应俊辉. 利用人工湿地处理农村生活污水的研究[J]. 安徽农业科学, 2007, 35(4): 1104-1105.

[2] 刘衍君. 人工湿地在污水处理中的应用及其展望[J]. 中山大学研究生学刊: 自然科学、医学版, 2003, 24(2): 34-39.

[3] 张晟,黎莉莉,陈建,等. 人工湿地在处理小城镇生活污

水中的应用[J]. 环境科学与管理, 2006, 31(9): 62-65.

[4] 彭超英,朱国洪,尹国,等. 人工湿地处理污水的研究[J]. 重庆环境科学, 2000, 22(6): 43-45.

[5] 罗固源. 水污染控制工程[M]. 北京: 高等教育出版社, 2006: 404.

[6] 张军,周琪,何蓉. 表面流人工湿地中氮磷的去除机理[J]. 生态环境, 2004, 13(1): 98-101.

[7] 吴晓磊. 人工湿地废水处理机理[J]. 环境科学, 1994, 16(3): 83-86.

[8] 吴振斌,成水平,贺锋,等. 垂直流人工湿地的设计及净化功能初探[J]. 应用生态学报, 2002, 13(6): 715-718.

[9] 李霞. 微生物在氮循环中的作用[J]. 松辽学刊: 自然科学版, 1998(4): 30-31, 36.

[10] GB18918—2002 城镇污水处理厂污染物排放标准[S].

(收稿日期 2009-08-10 编辑 徐 娟)

(上接第 27 页)树干对流场的影响。通过对多组试验结果的数模计算分析得出植树护岸条件下河道水流的特性:①滩地种树使滩地水流偏斜进入主槽,并在滩地上形成滞水区域,滩地与主槽交界处有旋涡;②滩地种树使滩地流速减小,主槽流速和主槽的过流能力增加;③滩地种树对水位影响不大。

参考文献：

[1] 黄本胜,赖冠文,邱静,等. 河滩种树对行洪影响实验研究[J]. 水动力学研究与进展, 1999, 14(4): 468-474.

[2] PASCHE E, ROUVE G. Overbank flow with vegetatively roughened flood plains[J]. Journal of Hydraulic Engineering, 1985, 111: 1262-1278.

[3] 唐士芳,李蓓. 桩群阻力影响下的潮流数值模拟研究

[J]. 中国港湾建设, 2001, 10(5): 25-29.

[4] 李光炽,周晶晏,张贵寿. 高桩码头对河道流场影响的数值模拟[J]. 河海大学学报: 自然科学版, 2004, 32(2): 216-220.

[5] 程莉. 植树护岸条件下河道水流的数值模拟[D]. 南京: 河海大学, 2002.

[6] 刘希云. 流体力学中的有限元与边界元方法[M]. 上海: 上海交通大学出版社, 1993.

[7] KING I P, NORTON W R, ICEMAN K R. A finite element solution for two - dimensional stratified flow problems[C]// Finite Elements in Fluids. New York: John Wiley&Sons, 1975.

[8] 汪德. 计算水力学理论及运用[M]. 南京: 河海大学出版社, 1989.

[9] 何少苓,WARREN I R. 平面二维明渠流动数值计算中涡黏性系数项的合理选取[J]. 水利学报, 1990(4): 1-10.

(收稿日期 2009-09-01 编辑 徐 娟)