

BP网络的城市时用水量预测组合模型

陈 卫¹, 陆 健², 吴志成³

(1 河海大学 环境科学与工程学院, 南京 210098, cw5826@hhu.edu.cn; 2 江苏省工程咨询中心, 南京 210003;
3 南京市自来水总公司, 南京 210002)

摘 要: 为建立起城市用水量与其影响因素间的预测模型, 以预测的城市用水量趋于合理, 针对城市时用水量的特点及影响因素, 在考虑充分利用各因素历史观测数据的基础上, 利用 BP 神经网络建立了城市时用水量的时间序列预测与解释性预测组合模型, 并对南京市的时用水量进行了预测. 预测结果与实际情况具有很好的一致性, 预测误差小, 能满足供水系统调度的实际需要. 可见, 本预测组合模型是合理的, 为城市时用水量预测提供了一种可行方法.

关键词: 时用水量; 组合模型; 预测; BP 神经网络

中图分类号: TU991.3 **文献标识码:** A **文章编号:** 0367-6234(2009)06-0197-04

Combined forecast model of urban hourly water consumption based on BP neural network

CHEN Wei¹, LU Jian², WU Zhi-cheng³

(1. College of Environmental Science and Engineering, Hohai University, Nanjing 210098, China, cw5826@hhu.edu.cn; 2. Jiangsu Engineering Consulting Center, Nanjing 210003, China; 3. Nanjing Water Supply General Company, Nanjing 210002, China)

Abstract: To establish the relationship between urban water consumption and its affecting factors, according to the characteristics of urban hourly water consumption, a combined urban hourly water consumption prediction model has been developed based on BP neural network. The model has been performed on the historical observation data of Nanjing city. The results show that the forecast error of the developed model is small and meets the practical requirement of water-supply dispatch system. It can be concluded that this model is reasonable and feasible for the forecast of urban hourly water consumption.

Key words: urban hourly water consumption; combined model; forecasting; BP neural network

城市时用水量的预测是给水系统优化调度的前期工作, 预测结果的准确性直接影响到调度决策的可靠性和实用性. 本文在分析城市时用水量特点、影响因素及预测方法的基础上, 建立基于 BP 神经网络的时间预测和解释性预测组合模型, 为城市时用水量的预测提供了一种可行方法.

1 城市时用水量预测方法分析

用水量预测方法通常分为解释性预测法和时间序列预测法. 研究发现, 城市时用水量变化存在

一定的周期性、趋势性和随机性, 历史观测数据是该系统内部变化机理的综合体现, 一定数量的历史观测数据能够在一定程度上表现出这种变化机理和变化规律. 基于这一思想, 时间序列预测法通过分析历史数据模式, 建立用水量自相关性数学函数, 进而对未来时段的用水量进行预测. 若将时用水量分为周期性、趋势性和随机性分量^[1], 预测则能比较准确地预测周期性分量和趋势性分量; 但预测误差会较大. 基于神经网络建立上述两种预测模型, 并对它们加以有效组合, 则可克服两类模型建模时的困难, 又可充分利用时用水量的历史观测数据和各影响因素的历史信息, 从而提高预测精度, 保障优化调度的可靠性.

收稿日期: 2006-06-16

基金项目: 国家自然科学基金重点资助项目 (50638020).

作者简介: 陈卫 (1958—), 女, 教授, 博士生导师.

2 BP神经网络模型的建立

根据 BP神经网络结构理论和预测目的,确定输入单元数和输出单元数.研究表明,三层神经网络在其隐含层中使用 S 形传输函数,在输出层中使用线性传输函数,可以任意精度逼近任意函数^[2];在文献[3]的基础上采用“试错法”^[4]来增加网络隐层数的确定.为保证网络具有一定的推广能力,网络训练样本的容量应足够大,训练样本中的数据点数不应少于网络参数个数;同时为避免网络陷入过渡训练状态,样本容量不宜过大.网络的训练函数和学习函数可根据样本数据的性质,结合“尝试法”给予确定.根据数理统计思想对含不同训练函数、学习函数和隐层单元数的网络分别训练 50 次,以构成大数统计分析样本,最后根据预测模型的常规评价指标对各个网络进行正交比较评价、选取网络特性参数、确定网络结构.

3 组合预测权系数优化理论

组合预测能综合利用各单项预测方所提供的信息,是提高预测精度的有效途径^[5],其关键是确定各单项预测的组合权重.

1) 预测方法的有效度指标. 设 y_t ($t = 1, 2, \dots, N$) 为实际观测值, f_{it} 为第 i ($i = 1, 2, \dots, N$) 种预测方法的预测值. A_{it} 为 f_{it} 在时刻 t 的预测精度:

$$A_{it} = 1 - \left| \frac{(y_t - f_{it})}{y_t} \right|, t = 1, 2, \dots, N. \quad (1)$$

由 A_{it} 构成预测方法 f_{it} 的精度序列,令该序列的均值与均方差分别为 $E(A_{it})$ 、 $\sigma(A_{it})$,则预测方法 f_i 的有效度指标定义为

$$S_i = E(A_{it}) [1 - \sigma(A_{it})]. \quad (2)$$

S 越大就表明预测方法 f_i 越有效.

2) 组合预测优化模型. 以预测方法的有效度指标为目标函数,建立求解组合预测权系数的优化模型.通过对组合预测方法精度的分析,对最优组合预测权系数优化模型进行近似和简化,以寻求组合预测权系数最优近似解.

设 A_{1t} 、 A_{2t} 、 A_t 分别为预测方法 f_{1t} 、 f_{2t} 及组合预测方法 f_t 在时刻 t 的预测精度,其精度序列均值和均方差分别为 $E(A_{1t})$ 、 $E(A_{2t})$ 、 $E(A_t)$ 、 $\sigma(A_{1t})$ 、 $\sigma(A_{2t})$ 、 $\sigma(A_t)$,设组合权系数为 k 、 $1 - k$,则组合预测为

$$f_t = k f_{1t} + (1 - k) f_{2t}.$$

经数学分析可得近似关系等式:

$$A_t = k A_{1t} + (1 - k) A_{2t}. \quad (3)$$

$$E(A_t) = k E(A_{1t}) + (1 - k) E(A_{2t}). \quad (4)$$

$$\sigma(A_t) = \sigma_{\min} + \frac{\sigma(A_{1t}) - \sigma_{\min}}{1 - k_0} (k - k_0) = \frac{\sigma(A_{1t}) - \sigma_{\min}}{1 - k_0} k + \frac{\sigma(A_{1t}) - \sigma_{\min} k_0}{1 - k_0}. \quad (5)$$

其中:

$$k_0 = \frac{\sigma^2(A_{2t}) - \text{cov}(A_{1t}, A_{2t})}{\sigma^2(A_{1t}) + \sigma^2(A_{2t}) - 2\text{cov}(A_{1t}, A_{2t})}. \quad (6)$$

若式 (6) 计算得到的 k_0 值不在 $[0, 1]$ 之间,则对其进行修正,记式 (6) 右端计算为 k_{opt} :

$$k_0 = \begin{cases} 1 & k_{\text{opt}} \geq 1 \\ k_{\text{opt}} & 0 < k_{\text{opt}} < 1 \\ 0 & k_{\text{opt}} \leq 0, \end{cases} \quad (7)$$

$$\sigma_{\min} = [k_0^2 \sigma^2(A_{1t}) + (1 - k_0)^2 \sigma^2(A_{2t}) + 2k_0(1 - k_0) \text{cov}(A_{1t}, A_{2t})]^{1/2}. \quad (8)$$

将式 (4) 与式 (5) 代入组合预测优化模型得求解组合预测权系数近似解的优化模型:

$$\begin{aligned} \max_{k_0} \text{函数} &= [E(A_{1t}) - E(A_{2t})] k + E(A_{2t}) \cdot \\ &\left[1 - \frac{\sigma(A_{1t}) - \sigma_{\min}}{1 - k_0} k - \frac{\sigma_{\min} - \sigma(A_{1t}) k_0}{1 - k_0} \right] \\ \text{st } &k_0 \leq k \leq 1. \end{aligned} \quad (9)$$

令 $\frac{d\text{函数}}{dk} = 0$, 使 函数达到最大值最优解为

$$k = \frac{1}{2} \left[\frac{(1 - \sigma_{\min}) - (1 - \sigma(A_{1t})) k_0}{\sigma(A_{1t}) - \sigma_{\min}} - \frac{E(A_{2t})}{E(A_{1t}) - E(A_{2t})} \right]. \quad (10)$$

若式 (10) 确定的 k 值不在 $[k_0, 1]$, 则对 k 修正为^[6]

$$k = \sigma(A_{2t}) / (\sigma(A_{1t}) + \sigma(A_{2t})). \quad (11)$$

4 模型应用

以南京市长江以南地区 2005 年间某时期连续 36 d 时用水量的 SCADA 系统实测数据,以及相对应的气象资料 (每天的最高温度、最低温度、晴雨状况) 和节假日情况为神经网络模型建立的样本数据.整个建模过程通过 MATLAB 软件平台、编写 MATLAB 程序完成.

4.1 时间序列预测模型

用第 29 d 某一小时用水量预测第 30 d 对应时段用水量,预测 24 h 用水量.

网络初步结构:一个输入单元、一个隐层、一个输出单元,输入/输出变量均为时用水量.

数据处理:用 premmx 函数对样本数据进行归一化处理,使样本数据落入 $[-1, 1]$ 范围内.

训练样本:以前 28 d 的某一小时的用水量为训练输入样本,以依次顺延一天的后 28 d 对应时段的用水量为目标样本.

测试样本:以第 29 d 的某一小时的用水量为测试输入样本,以第 30 d 的对应时段的用水量为比较样本。

网络作用函数:隐层神经元作用函数为 Sigmoid,输出层神经元作用函数为 purelin,用以“尝试性”比较的网络训练函数有 trainbr、trainlm、traingdm,网络学习函数为 leamgdm。

隐层神经元数:用于“试错法”比较的隐层神经元数为:4、5、6、7、8

表 1 时间序列预测模型网络结构正交比较结果

神经元数		4	5	6	7	8
平均绝对误差 MAD	trainbr	278.66	86.85	92.32	161.33	379.40
	trainlm	2221.47	2610.01	3370.81	2351.27	3571.70
	traingdm	2226.97	2798.61	3052.35	2365.27	3529.61
平均平方误差 MSE	trainbr	9.62	2.42	6.68	4.78	47.68
	trainlm	747.99	977.40	1470.37	827.30	1913.60
	traingdm	721.45	1151.89	1428.21	831.67	1789.67
平均绝对百分比误差 MAPE/%	trainbr	0.0078	0.0024	0.0026	0.0045	0.0107
	trainlm	0.0625	0.0735	0.0949	0.0662	0.1006
	traingdm	0.0627	0.0788	0.0859	0.0666	0.0994

4.2 解释性预测模型

用第 29 d 的气象资料预测第 29 d 的小时用水量,共预测 24 h 的用水量。

网络初步结构:四个输入单元、一个隐层、一个输出单元,输入变量为最低温度、最高温度、晴雨状况和节假日状况,输出变量为时用水量。

数据处理:根据时用水量随晴雨状况、节假日状况变化的规律,依照表 2 对其进行数字化处理,根据网络需要对输入样本和输出样本进行归一化处理。

训练样本:以归一化后的前 28 d 的气象资料为训练输入样本,以这 28 d 的时用水量为目标样本。

测试样本:以第 29 d 的气象资料为测试输入样本,以第 29 d 时用水量为比较样本。

网络作用函数:隐层神经元作用函数为 Sig-

模型评价指标:平均绝对误差 MAD、平均平方误差 MSE、平均绝对百分比误差 MAPE^[7]。

网络正交比较结果:对含不同训练函数和隐层单元数的网络分别训练 50 次,根据预测模型的常规评价指标对各个网络进行正交比较评价,如表 1 所示(以 0:00 - 1:00 时段为例)。

模型最后结构:一个输入单元、一个隐层、一个输出单元,隐层单元数为 5,网络训练函数为 trainbr,网络学习函数为 leamgdm。

moid,输出层神经元作用函数为 purelin,经试运行比较分析后网络训练和自适应调整函数采用 traingdm,网络学习函数为 leamgdm。

隐层神经元数:用于“试错法”比较的隐层神经元数为:7、8、9、10、11。

模型评价指标:平均绝对误差 MAD、平均平方误差 MSE、平均绝对百分比误差 MAPE。

网络正交比较结果:对含不同隐层单元数的网络分别训练 50 次,比较结果如表 3 所示(以 0:00 - 1:00 时段为例)。

模型最后结构:四个输入单元、一个隐层、一个输出单元,隐层单元数为 9,网络训练函数为 traingdm,网络学习函数为 leamgdm。

表 2 晴雨及节假日状况数字化参照表

晴雨状况							节假日状况	
晴	晴转多云(多云转晴)	多云	多云转阴(阴转多云)	阴	阴有雨(小雨)	中雨	大雨	工作日 节假日
2.125	2	1.75	1.5	1.25	1	0.75	0.5	0.5

表 3 解释性预测模型网络结构正交比较结果

神经元数	7	8	9	10	11
平均绝对误差 MAD	701.37	706.61	665.51	674.14	749.60
平均平方误差 MSE	577278.70	561578.50	495940.50	500087.60	621172.20
平均绝对百分比误差 MAPE/%	0.0206	0.0204	0.0192	0.0194	0.0216

4.3 组合预测模型

用上述两种模型连续预测 7 d 的时用水量,构成组合模型所需的精度序列,然后依据组合预测权系数优化理论对模型进行组合,为不失一般

性,以用水量变化较大的时段(如 7:00~8:00)为例,时间序列预测模型的权系数为 0.6403,解释性预测模型的权系数为 0.3597,各模型预测结果如表 4 所示。

4.4 预测结果比较

中所提的有效度指标对上述模型进行评价,评价采用常规的预测模型精度综合评价指标和文结果如表 5 所示.

表 4 各模型预测结果

实际用水量 $Q_0/\text{m}^3\cdot\text{h}^{-1}$	时间序列预测		解释性预测		组合预测	
	预测值 $Q_1/\text{m}^3\cdot\text{h}^{-1}$	精度序列	预测值 $Q_2/\text{m}^3\cdot\text{h}^{-1}$	精度序列	预测值 $Q_3/\text{m}^3\cdot\text{h}^{-1}$	误差 /%
43870	44888.01	0.9768	43624.55	0.9944	44433.70	- 1.28
44260	45100.61	0.9810	42932.28	0.9700	44320.92	- 0.14
41310	41330.96	0.9995	42728.40	0.9657	41833.45	- 1.27
40790	41013.03	0.9945	42469.87	0.9588	41536.88	- 1.83
43120	43615.08	0.9885	43108.13	0.9997	43432.79	- 0.73
43610	43840.30	0.9947	42981.53	0.9855	43531.51	0.18
43630	43775.98	0.9966	42712.84	0.9790	43393.70	0.54

表 5 预测效果评价

	时间序列预测	解释性预测	组合预测
平均绝对误差 MAD	424.85	889.85	360.36
平均绝对百分比误差 MAPE/%	0.98	2.10	0.85
模型有效度 S	0.9824	0.9653	0.9857

从表 5 中可看出,组合模型的评价指标均优于其它两种预测模型,该模型在一定程度上有中和预测误差、提高预测精度的作用.从表 4 中可看出,组合模型的预测相对误差均 <5%,满足城市供水调度所需的工程精度.可见,用基于 BP 神经网络的组合模型预测城市时用水量方法可行.

5 结 论

- 1)基于 BP神经网络建立城市用水量预测模型时,在模型训练前应对数据样本进行预处理,调整样本中因某些事故所致用水量突变的数据,为模型预测可靠性提供保障.
- 2)为减少系统误差,在收集建模资料时应以气象部门所提供的资料为准.此外,在对部分气象资料进行数字化处理时应认真判断该气象资料的所属范围,否则会影响 BP网络学习过程中的模式判断能力.
- 3)城市时用水量预测属于短期预测,距预测时间越近的资料对预测结果影响越大,在实际中应对模型样本数据不断更新.

参考文献:

[1] 吕谋,赵洪宾,李红卫,等. 时用水量预测的自适应组

合动态建模方法[J]. 系统工程理论与实践, 1998, 18(8): 101 - 107, 112

[2] HAGAN M T, DEMUTH H B, BEALEM H. 神经网络设计[M]. 戴葵,等译. 北京: 机械工程出版社, 2005

[3] 单金林,戴雄奇,李江涛. 利用 BP网络建立预测城市用水量模型[J]. 中国给水排水, 2001, 17(8): 61 - 63

[4] 黄胜伟,董曼玲. 自适应变步长 BP神经网络在水质评价中的应用[J]. 水利学报, 2002, 33(10): 119 - 123

[5] 王明涛. 确定组合预测权系数最优近似解的方法研究[J]. 系统工程理论与实践, 2000, 20(3): 104 - 109

[6] 李 斌,许仕荣,柏光明,等. 灰色 - 神经网络组合模型预测城市用水量[J]. 中国给水排水, 2002, 18(2): 66 - 68

[7] 陆 健. 基于 BP神经网络和遗传算法的城市供水系统优化调度模型研究[D]. 南京: 河海大学, 2007.

(编辑 张 红)