

基于相空间重构原理的遗传神经网络模型在城市需水预测中的应用

崔东文

(云南省文山州水务局,云南 文山 663000)

摘要:针对多元变量需水预测模型中变量之间普遍存在多重共线性问题以及BP神经网络收敛速度慢、易陷入局部极值等缺点,将相空间重构原理及遗传算法(GA)引入BP神经网络需水预测模型中,提出基于相空间重构原理的GA-BP城市需水预测模型,并对上海市需水预测进行实例分析。实例分析结果表明:GA-BP模型对上海市2005—2009年的年用水量预测平均相对误差绝对值和最大相对误差绝对值分别为1.4344%和2.7672%,对2010—2011年的年需水量预测相对误差分别为0.5136%和0.0270%,精度均优于BP神经网络预测模型;基于相空间重构原理的GA-BP需水预测模型具有较好的预测精度和泛化能力,是提高需水预测精度和泛化能力的有效方法。

关键词:相空间重构;BP神经网络;遗传算法;需水预测

中图分类号:TV214 **文献标志码:**A **文章编号:**1006-7647(2014)01-0085-05

Application of genetic neural network model to urban water demand prediction based on theory of phase space reconstruction//CUI Dongwen (Wenshan Water Conservancy Bureau of Yunnan Province, Wenshan 663000, China)

Abstract: Due to the multicollinearity problems existing in the variables in the model of multivariate water demand prediction, and the defaults, such as the convergence speed of the BP neural network is slow for it to easily fall into local extreme values, the theories of phase space reconstruction and genetic algorithms (GA) were introduced into the BP neural network water demand prediction model. A GA-BP model for urban water demand prediction based on the theory of phase space reconstruction was put forward. Taking water demand prediction in Shanghai as an example, the effect of the GA-BP urban water demand prediction model was analyzed. The results show that the absolute value of the average relative error and the maximum absolute value of the relative error of the annual water demand prediction for the period of 2005 to 2009 in Shanghai based on the GA-BP urban water demand prediction model are 1.4344% and 2.7672%, prospectively, and the relative error of water demand prediction for the period of 2010 to 2011 are 0.5136% and 0.0270%, prospectively. The accuracy of the GA-BP model for urban water demand prediction is better than that of the BP neural network prediction model. The GA-BP model for urban water demand prediction based on the theory of phase space reconstruction has better prediction accuracy and generalization ability, being an effective method to improve the water demand prediction accuracy and generalization ability.

Key words: phase space reconstruction; BP neural networks; genetic algorithm; water demand prediction

城市需水预测是城市供水总体规划和工程规划的基础。城市需水预测的方法众多,如定额法、时间序列法、弹性系数预测法、回归分析法以及灰色预测法等,这些方法广泛应用于城水需水预测中,但均存在预测精度不高等问题^[1]。为提高需水预测的精度,混沌理论、灰色系统理论、神经网络理论、系统动力学方法等一些非传统需水预测理论及方法被引入到需水预测中,并在提高需水预测精度上取得了较好的效果^[2-6]。人工神经网络(artificial neural network, ANN)具有较强的非线性映射能力以及鲁棒性、容错性、自适应性、自组织性、自学习性等特

性,适宜解决高维、非线性系统问题,是智能算法中运用最为广泛的算法之一。BP神经网络(back-propagation neural network)是ANN中常用的神经网络模型,广泛运用于需水预测。然而,将BP神经网络应用于需水预测存在两个方面的不足:①输入向量(影响因子)间可能存在着高度相关性,易产生共线性问题从而影响模型的预测精度和泛化能力;②BP神经网络存在学习收敛速度慢、易陷入局部极值以及网络结构难以确定等缺点,极大地制约了BP神经网络在需水预测中的精度和泛化能力。近年来,随着对混沌理论及其应用技术研究的不断深入,

基于混沌时间序列建模和预测已成为混沌信息处理研究领域中的热点,并成功应用于城市需水预测中^[7],其相空间重构是影响需水预测成败的关键,而延迟时间 τ 和嵌入维数 m 的选取对相空间重构具有十分重要的意义。关于延迟时间 τ 与嵌入维数 m 的选取,目前主要有两种观点:一种观点认为两者互不相相关,即 τ 和 m 的选取是独立进行的,如求延迟时间的自相关函数法^[8]、互信息法^[9],求嵌入维数的 G-P 算法^[10]、假最近邻法^[11]等;另一种观点认为两者是相关的,即 τ 和 m 的选取是互相依赖的,如嵌入窗法^[12]、C-C 方法^[13]等,可同时计算出延迟时间和时间窗口。然而,在实际应用中对于同一时间序列,上述各种方法的确定结果往往不尽相同,这对延迟时间 τ 和嵌入维数 m 的选取带来困难。遗传算法(genetic algorithm,GA) 具有很强的宏观搜索能力和良好的全局优化性能,将 GA 与 BP 神经网络相结合,利用 GA 训练 BP 神经网络的权值和阈值,有效克服了 BP 神经网络易陷入局部极值等缺点。

针对上述问题及原因,本文基于相空间重构原理,利用试凑的方法确定需水预测时间序列中的延迟时间 τ 和嵌入维数 m ,将一维需水时间序列拓展为多维,以解决多变量需水预测模型中变量之间普遍存在的多重共线性问题;对于 BP 神经网络的固有缺陷,采用 GA 优化 BP 神经网络的权值和阈值,以克服 BP 神经网络易陷入局部极值等缺点,提出基于相空间重构原理的 GA-BP 需水预测模型,以上海市需水预测为例进行实例分析,研究提高需水预测精度的有效方法。

1 基于相空间重构原理的 GA-BP 需水预测模型

1.1 相空间重构原理

相空间重构的目的是在高维相空间中恢复混沌

吸引子。由于吸引子的内在行为具有不规则性及混沌吸引子具有复杂的几何结构,一般来说,不同的混沌实测数据应建立不同的混沌模型。混沌模拟是在相空间中进行的,其原理就是在相空间中找到一个非线性模型去逼近系统动态特性,实现一定时期内的预测^[14]。

设给定的时间序列为 $x_t(t=1,2\cdots,N)$,将一维时间序列延拓为 m 维相空间时间序列:

$$y_t = \{x_t, x_{t+\tau}, x_{t+2\tau}, \cdots, x_{t+m\tau}\} \quad (t = 1, 2, \cdots, M) \tag{1}$$

式中: N 为总相点数; m 为嵌入维数; τ 为延迟时间; M 为相空间中的相点数,且 $M=N-m\tau$ 。根据 Takens 定理,选择合适的嵌入维数和时间延迟就可以在拓扑等价的意义下恢复原来系统的动力学形态,因此存在一个光滑映射 $F:\mathbf{R}^m\rightarrow\mathbf{R}^m$,给出相空间轨迹的表达式为

$$y_{t+\eta} = F(y_t) \quad (t = 1, 2, \cdots, N) \tag{2}$$

式中: η 为预测步长。

1.2 GA-BP 算法流程

GA 与 BP 神经网络均具有极强的解决问题的能力^[15-18],二者相结合形成 GA-BP 算法,该算法将 GA 的全局寻优能力与 BP 神经网络的指导性搜索思想相结合,既克服了寻优中的盲目性,又避免了局部收敛情况的发生,使网络性能得到极大的改善^[19-20]。GA-BP 算法流程如图 1 所示。

GA-BP 算法的实现步骤如下:

- a. 初始化种群 P ,包括交叉规模、交叉概率 P_c 、突变概率 P_m 以及对网络权值和阈值初始化,并采用实数编码方式对初始值进行编码,设定种群规模 n 。
- b. 计算各个体评价函数,将其排序,按下式概率值选择网络个体:




图 1 GA-BP 算法流程

$$p_i = f_i / \sum_{i=1}^n f_i \quad (3)$$

其中 $f_i = 1/E_i$ (4)

$$E_i = \sum_{k=1}^r \sum_{i=1}^q (d_i - \gamma_i)^2 \quad (5)$$

式中： p_i 为选择概率； f_i 为个体 i 的适应度值； n 为染色体数； E_i 为误差平方和； r 为学习样本数； q 为输出节点数； γ_i 为网络实际输出； d_i 为期望输出。

c. 以交叉概率 P_c 对个体 G_i 和 G_{i+1} 进行交叉操作,产生新个体 G'_i 和 G'_{i+1} ,没有进行交叉操作的个体直接进行复制。

d. 利用变异概率 P_m 突变产生 G_j 的新个体 G'_j 。

e. 将新个体插入到种群 P 中,并计算新个体的评价函数。

f. 判断计算是否结束。如果找到满意个体,则结束;否则转到步骤 c 进入下一轮运算。

g. 计算结束,达到预先设定的性能指标后,将最终种群中的最优个体解码,即可得到优化后的网络连接权值系数。

h. 将优化得到的网络连接权值系数赋值给 BP 神经网络进行训练及预测输出。

1.3 GA-BP 需水预测模型

基于相空间重构原理,利用试凑的方法确定需水预测时间序列的延迟时间 τ 与嵌入维数 m ,构建 BP 神经网络需水预测模型。在确定 BP 最佳网络结构以及获得较好预测精度的前提下,为不失一般性,在相同网络结构、传递函数、训练函数及期望误差等条件下,运用 GA 来优化 BP 神经网络的初始权值和阈值,构建 GA-BP 需水预测模型,具体预测步骤如下:

a. 利用试凑的方法确定需水预测时间序列的延迟时间 τ 与嵌入维数 m ,确定 BP 神经网络的输入向量、输出向量、训练样本和检验样本,构建 BP 神

经网络需水预测模型。

b. 依据经验给定 BP 神经网络需水预测模型的期望误差和训练次数,根据 Kolmogorv 定理得出一个初始隐含层节点数,利用逐步增长或逐步修剪法确定最终隐含层节点数;然后采用调整期望误差或训练次数,以及替换传递函数和训练函数等方法获得最佳预测效果时的各相关参数。

c. 在 BP 神经网络需水模型预测精度达到较理想状态下,为不失一般性,利用 GA 优化 BP 神经网络的初始权值和阈值,构建 GA-BP 需水预测模型。

d. 利用训练样本对 GA-BP 需水预测模型进行训练,确定 GA-BP 预测模型等相关参数。

e. 采用平均相对误差和最大相对误差两个性能评价指标对 BP 神经网络需水预测模型和 GA-BP 需水预测模型的预测效果进行评价分析。

2 实例验证

2.1 数据来源与相空间重构

以上海市需水预测为例,收集了上海市 1980—2011 年的年用水量,并以 1980—2009 年的数据构建需水预测模型的输入、输出向量,其中以上海市 1980—2004 年的年用水量作为训练样本,2005—2009 年的年用水量作为检验样本,在模型达到期望精度后用于上海市 2010—2015 年的需水预测。

由于用水时间序列较短,设定延迟时间 τ 和嵌入维数 m 的取值范围为 1~4,并利用试凑的方法最终确定 $\tau=1$ 、 $m=4$ 时的模型具有较好的预测效果,模型的输入、输出向量见表 1。

2.2 需水预测的实现

2.2.1 时间序列预测方法

在单变量时间序列预测中,设有时间序列 $\{x_i\}$,其中历史数据为 $\{x_j, x_{j+1}, \dots, x_{j+l}\}$,对未来 $j+l+\eta$ ($\eta>0$)

表 1 上海市 1980—2010 年需水预测模型输入、输出向量 亿 m³

年份	输入向量				输出向量 (当年)	年份	输入向量				输出向量 (当年)
	前 4 年	前 3 年	年 2 年	前 1 年			前 4 年	前 3 年	年 2 年	前 1 年	
1984	9.73	10.17	10.09	10.21	10.64	1997	14.94	16.27	22.07	23.11	23.32
1985	10.17	10.09	10.21	10.64	11.54	1998	16.27	22.07	23.11	23.32	24.12
1986	10.09	10.21	10.64	11.54	11.71	1999	22.07	23.11	23.32	24.12	23.51
1987	10.21	10.64	11.54	11.71	12.71	2000	23.11	23.32	24.12	23.51	24.00
1988	10.64	11.54	11.71	12.71	12.61	2001	23.32	24.12	23.51	24.00	24.15
1989	11.54	11.71	12.71	12.61	12.92	2002	24.12	23.51	24.00	24.15	24.40
1990	11.71	12.71	12.61	12.92	13.32	2003	23.51	24.00	24.15	24.40	25.82
1991	12.71	12.61	12.92	13.32	13.53	2004	24.00	24.15	24.40	25.82	27.35
1992	12.61	12.92	13.32	13.53	14.10	2005	24.15	24.40	25.82	27.35	28.65
1993	12.92	13.32	13.53	14.10	14.94	2006	24.40	25.82	27.35	28.65	29.19
1994	13.32	13.53	14.10	14.94	16.27	2007	25.82	27.35	28.65	29.19	30.34
1995	13.53	14.10	14.94	16.27	22.07	2008	27.35	28.65	29.19	30.34	30.90
1996	14.10	14.94	16.27	22.07	23.11	2009	28.65	29.19	30.34	30.90	30.47

注:资料来源于《2012 年上海市统计年鉴》。

时刻的取值进行预测,即预测 $x_{j+l+\eta}$ 的值。方法是求出历史数据 $\{x_j, x_{j+1}, \dots, x_{j+l}\}$ 与 $x_{j+l+\eta}$ 的某种非线性函数关系: $x_{j+l+\eta} = F(x_j, x_{j+1}, \dots, x_{j+l})$ 。

单变量时间序列预测常用的方法有 3 种: 单步预测 ($\eta=1$)、多步预测 ($\eta>1$) 和滚动预测 (进行单步预测,然后将输出反馈给输入端作为网络输入的一部分,预测未来某个时刻的值)。本文采用单变量滚动预测的方法对上海市 2010—2015 年的需水量进行预测。

2.2.2 数据标准化处理

对原始数据进行归一化处理有利于神经网络训练。本文采用最大最小法进行数据处理,公式如下:

$$\hat{x} = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \tag{6}$$

式中: $\hat{x}$ 为经过标准化处理的数据; x 为原始数据; $x_{\max}$ 为预测极大值 (上限值), 为数据序列中最大数的 2 倍; $x_{\min}$ 为预测极小值 (下限值), 为数据序列中最小数的 0.5 倍。

2.2.3 神经网络训练

BP 神经网络模型: 采用 MATLAB 软件编写 BP 神经网络算法程序实现需水预测, 程序采取循环训练算法确定网络结构, 最终确定 BP 神经网络需水预测模型的结构为 4-3-1, 隐含层和输出层传递函数分别采用 logsig 和 purelin, 训练函数采用 traingdx, 学习速率为 0.01, 设定期望误差为 0.0001, 最大训练轮回为 10000 次时网络达到了较好的预测精度。

GA-BP 模型: 基于公平原则, 在上述 BP 神经网络较佳结构及相同参数条件下, 运用 GA 来优化 BP 神经网络的权值和阈值。GA 参数设置为: 种群规模为 100, 进化次数为 100 次, 交叉概率和变异概率等参数采用谢菲尔德 GA 工具箱的默认值。

2.2.4 模型评价指标

选取平均相对误差 e_{MRE} 、最大相对误差 e_{maxRE} 作为模型的评价指标, 其计算公式如下:

$$e_{\text{MRE}} = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{y_i} \tag{7}$$

$$e_{\text{maxRE}} = \max \frac{|\hat{y}_i - y_i|}{y_i} \quad (1 \leq i \leq n) \tag{8}$$

式中: $\hat{y}_i$ 为第 i 个样本预测值; y_i 为第 i 个样本实测值。

2.3 需水预测结果及分析

利用上述训练好的 BP 神经网络需水预测模型、GA-BP 需水预测模型对上海市 2005—2009 年的样本进行检验, 并对 2010—2015 年的年需水量进行预测, 结果见表 2 和表 3。

表 2 上海市 2005—2009 年的年用水量检验结果及比较

年份	实际值/ 亿 m ³	预测值/亿 m ³		相对误差/%	
		GA-BP 模型	BP 模型	GA-BP 模型	BP 模型
2005	28.65	28.1307	28.3201	1.8125	1.1515
2006	29.19	29.3135	29.9929	0.4232	2.7507
2007	30.34	29.6952	30.5247	2.1253	0.6087
2008	30.90	30.8865	31.1432	0.0437	0.7871
2009	30.47	31.3132	31.9802	2.7672	4.9563

表 3 上海市 2010—2015 年的年需水量预测结果及比较

年份	实际值/ 亿 m ³	预测值/亿 m ³		相对误差/%	
		GA-BP 模型	BP 模型	GA-BP 模型	BP 模型
2010	30.90	30.7413	31.2513	0.5136	1.1369
2011	31.13	31.1216	31.2297	0.0270	0.3203
2012		31.5090	31.7629		
2013		31.8569	32.0638		
2014		32.1692	32.5417		
2015		32.4517	33.0227		

分析表 2、表 3 可以得出:

a. 基于相空间重构的 BP 神经网络需水预测模型和 GA-BP 需水预测模型的需水预测效果均令人满意, GA-BP 需水预测模型样本检验的平均相对误差和最大相对误差分别为 1.4344% 和 2.7672%, 均优于 BP 神经网络模型预测结果, 表明基于相空间重构的 GA-BP 需水预测模型用于需水预测具有较好的预测精度和泛化能力, 是提高需水预测精度的有效途径和方法。

b. 由于本文 BP 神经网络训练采用 traingdx 算法, 该算法具有附加动量和自适应调整算法的优点, 在一定程度上能有效避免收敛速度慢、陷入局部极值的缺陷。因此, 基于相空间重构原理的 BP 神经网络需水预测模型在上海市需水预测中同样具有很好的预测精度。在相同网络结构、传递函数、训练函数等条件下, 采用 GA 算法优化 BP 神经网络权值和阈值, 使 GA-BP 模型的需水预测达到了更高的精度。

c. 从表 3 可以看出, 相同年份的 GA-BP 预测模型对上海市的需水预测结果要小于 BP 神经网络需水预测模型。GA-BP 需水预测模型对 2010—2015 年的需水预测结果表明, 其年需水量增幅在 1.24% ~ 0.88% 之间, 呈逐年下降趋势, 这与我国实行最严格水资源管理制度以及城市需水增长缓慢的实际基本相符, 表明基于相空间重构的 GA-BP 需水预测模型用于城市需水预测的精度更高、更合理。从 2010—2011 年需水预测结果与实际值相比来看, GA-BP 需水预测模型需水量预测结果的相对误差仅分别为 0.5136% 和 0.0270%, 均优于 BP 神经网络需水预测模型。

3 结 语

针对多元变量需水预测模型中变量之间普遍存

在多重共线性问题以及 BP 神经网络收敛速度慢、易陷入局部极值等缺点,提出了一种基于相空间重构原理的 GA-BP 单因子需水预测模型,并对上海市需水预测为例进行实例验证。结果表明,GA-BP 需水预测模型克服了传统多变量需水预测模型输入变量之间产生的多重共线性问题以及 BP 神经网络易陷入局部极值等缺点,提高了需水预测的精度。GA-BP 模型具有预测精度高、泛化能力强等优点,有着良好的推广应用价值。按照本文提出的相空间重构 GA-BP 单因子需水预测模型预测出上海市 2012—2015 年的年需水量分别为 31.51 亿 m^3 、31.86 亿 m^3 、32.17 亿 m^3 和 32.45 亿 m^3 。

参考文献:

- [1] 刘卫林. 几种需水量预测模型的比较研究[J]. 人民长江, 2008, 39(6): 19-22. (LIU Weilin. Comparative research on several models for water demand forecast[J]. Yangtze River, 2008, 39(6): 19-22. (in Chinese))
- [2] 王建华. 城市需水量的混沌预测[J]. 中国农村水利水电, 2008(8): 32-34. (WANG Jianhua. Chaos-prediction in urban water consumption[J]. China Rural Water and Hydropower, 2008(8): 32-34. (in Chinese))
- [3] 蒋绍阶, 江崇国. 灰色神经网络最优权组合模型预测城市需水量[J]. 重庆建筑大学学报, 2008, 30(2): 113-115. (JIANG Shaojie, JIANG Chongguo. Urban water demand forecasting by combining improved BP neural network and grey model with optimum weight[J]. Journal of Chongqing Jianzhu University, 2008, 30(2): 113-115. (in Chinese))
- [4] CUBERO R G. Neural networks for water demand time series forecasting [C]//The proceedings of international workshop on artificial neural networks (IWANN), 1991. Granada: [s. n.], 1991: 453-460.
- [5] 张雪花, 张宏伟, 张宝安. SD 法在城市需水量预测和水资源规划中的应用研究[J]. 中国给水排水, 2008, 24(9): 42-46. (ZHANG Xuehua, ZHANG Hongwei, ZHANG Baoan. Application of system dynamics approach to urban water demand forecasting and water resources planning [J]. China Water & Wastewater, 2008, 24(9): 42-46. (in Chinese))
- [6] 张志果, 邵益生, 徐宗学. 基于恩格尔系数与霍夫曼系数的城市需水量预测[J]. 水利学报, 2011, 41(11): 1304-1306. (ZHANG Zhiguo, SHAO Yisheng, XU Zongxue. Prediction of urban water demand based on Engel Index and Hoffmann Coefficient [J]. Journal of Hydraulic Engineering, 2011, 41(11): 1304-1306. (in Chinese))
- [7] 刘勇健, 沈军. 城市需水量预测的混沌神经网络模型[J]. 水电能源科学, 2005, 23(1): 15-17. (LIU Yongjian, SHEN Jin. Prediction model of urban water consumption based on chaos neural network [J]. Hydroelectric Energy, 2005, 23(1): 15-17. (in Chinese))
- [8] KANTZ H, SCHREIBER T. Nonlinear time series analysis [M]. Cambridge: Cambridge University Press, 1997.
- [9] FRASER A M, SWINNEY H L. Independent coordinates for strange attractors from mutual information [J]. Physical Review A, 1986, 33(2): 1134-1140.
- [10] GRASSBERGER P, PROCACCIA I. Measuring the strangeness of strange attractors [J]. Physica D, 1983, 9: 189-208.
- [11] KENNEL M B, BROWN R, ABARBANEL H D I. Determining embedding dimension for phase-space reconstruction using a geometrical construction [J]. Physical Review A, 1992, 45(6): 3403-3407.
- [12] KUGIURMTZIS D. State space reconstruction parameters in the analysis of chaotic times series-the role of the time window length [J]. Physica D, 1996, 95: 13-28.
- [13] KIM H S, EYKHOLT R, SALAS J D. Nonlinear dynamics, delay times and embedding windows [J]. Physica D, 1999, 127: 48-60.
- [14] 邵东国, 刘丙军, 阳书敏, 等. 水资源繁杂系统理论 [M]. 北京: 科学出版社, 2012.
- [15] 崔东文. 基于 BP 神经网络的文山州水资源承载力评价分析 [J]. 长江科学院报, 2012, 29(5): 9-15. (CUI Dongwen. Evaluation and analysis of water resources carrying capacity in wenshan prefecture based on BP neural network [J]. Yangtze River Scientific Research Institute, 2012, 29(5): 9-15. (in Chinese))
- [16] 崔东文. 几种神经网络模型在湖库富营养化程度评价中的应用 [J]. 水资源保护, 2012, 28(6): 12-18. (CUI Dongwen. Applications of several neural network models to eutrophication evaluation of lakes and reservoirs [J]. Water Resources Protection, 2012, 28(6): 12-18. (in Chinese))
- [17] 王小川, 史峰, 郁磊, 等. MATLAB 神经网络 30 个案例分析 [M]. 北京: 北京航空航天大学出版社, 2010.
- [18] 苑希民, 李鸿雁, 刘树坤, 等. 神经网络和遗传算法在水科学领域的应用 [M]. 北京: 中国水利水电出版社, 2002.
- [19] 翟宜峰, 李鸿雁, 刘寒冰, 等. 遗传算法优化神经网络初始权重方法的研究 [J]. 吉林大学学报: 工学版, 2003, 33(2): 45-50. (ZHAI Yifeng, LI Hongyan, LIU Hanbing, et al. Method for optimizing initial weights of ANNs by GAs [J]. Journal of Jilin University of Technology: Natural Science Edition, 2003, 33(2): 45-50. (in Chinese))
- [20] 汪金良, 卢宏, 曾青云. GA-BP 算法及其在冰铜品位神经网络模型中的应用 [J]. 江西有色金属, 2003, 17(3): 39-41. (WANG Jinliang, LU Hong, ZENG Qingyun. Application of GA-BP to the Matte Grade Model Based on Neural Network [J]. Jiangxi Nonferrous Metals, 2003, 17(3): 39-41. (in Chinese))

(收稿日期: 2013-01-22 编辑: 周红梅)