



DOI: 10.13476/j.cnki.nsbdqk.2017.06.006

李晓英, 苏志伟, 周华, 等. 基于主成分分析的 GA-BP 模型在城市需水预测中的应用[J]. 南水北调与水利科技, 2017, 15(6): 39-44. LI X Y, SU Z W, ZHOU H, et al. Application of GA-BP model based on principal component analysis to urban water demand prediction[J]. South to North Water Transfers and Water Science & Technology, 2017, 15(6): 39-44. (in Chinese)

基于主成分分析的 GA-BP 模型 在城市需水预测中的应用

李晓英¹, 苏志伟¹, 周华², 贾晓菲², 叶根苗¹, 蔡晨凯¹

(1. 河海大学 水利水电学院, 南京 210098; 2. 泰州市水资源管理处, 江苏 泰州 225300)

摘要: 针对城市需水预测模型中需水量影响因子多、影响因子之间普遍存在多重共线问题, 以及 BP 神经网络收敛速度慢、易陷入局部最优等缺点, 提出一种由主成分分析、遗传算法及 BP 神经网络三者相结合的改进预测模型。以泰州市为实例, 建立以主成分分析筛选需水量主要影响因子, 遗传算法优化 BP 网络连接权值和阈值的需水预测模型, 预测结果与 BP 神经网络预测模型预测结果做对比。结果表明: 改进预测模型对泰州市 2003–2014 年需水量预测的平均相对误差为 0.564%, 最大相对误差为 1.681%, 精度优于 BP 神经网络预测模型; 改进预测模型预测值与实际泰州市需水量吻合良好且训练速度更快、预测精度更高, 可作为需水预测的一种有效方法。

关键词: 主成分分析; BP 神经网络; 遗传算法; GA-BP 模型; 需水预测

中图分类号: TV211 文献标识码: A 文章编号: 1672-1683(2017)06-0039-06

Application of GA-BP model based on principal component analysis to urban water demand prediction

LI Xiaoying¹, SU Zhiwei¹, ZHOU Hua², JIA Xiaofei², YE Genmiao¹, CAI Chenkai¹

(1. College of Water Conservancy and Hydropower Engineering, Hohai University, Nanjing 210098, China;

2. Water Resources Management Department of Taizhou City, Taizhou 225300, China)

Abstract: There are too many impact factors of water demand in the urban water demand prediction model and most of the factors are multicollinear. Besides, the BP neural network has slow convergence rate and easily gets into a local optimum. To tackle these problems, we proposed an improved prediction model by combining the principal component analysis (PCA), genetic algorithm (GA), and back propagation neural network (BPNN). Taizhou city was taken as a case for study. We established a water demand prediction model that selects the main impact factors of water demand by principal component analysis and optimizes the connection weights and thresholds of the BP neural network by genetic algorithm. The BP neural network prediction model was set up as the contrast model. The results showed that the average relative error and the maximum relative error of water demand prediction by the improved model in 2003–2014 in Taizhou city were 0.564% and 1.681% respectively. The precision was superior to that of the BP neural network prediction model. The results predicted by the GA-BP model matched with the actual water demand data of Taizhou city, and the model had faster calculation speed and higher precision. It can be used as an effective method for water demand prediction.

Key words: principal component analysis; BP neutral network; genetic algorithm; GA-BP model; water demand prediction

收稿日期: 2016-12-24 修回日期: 2017-01-14 网络出版时间: 2017-1-16

网络出版地址: <http://kns.cnki.net/kcms/detail/13.1334.T.V.20171116.1130.005.html>

基金项目: 国家重点计划研发课题(2016YFC0400909; 2016YFC0402605); 江苏省高校优势学科建设工程资助项目(水利工程)

Funds: National Key R & D Program of China (2016YFC0400909; 2016YFC0402605); A Project Funded by the Priority Academic Program Development of Jiangsu Higher Education Institutions (Water Conservancy Engineering)

作者简介: 李晓英(1978-), 女, 江苏徐州人, 讲师, 博士, 主要从事水资源系统规划与动能经济方面的研究。E-mail: Lixy3@hhu.edu.cn

通讯作者: 苏志伟(1992-), 男(回族), 青海西宁人, 主要从事水资源系统规划与动能经济方面的研究。E-mail: 444625795@qq.com

需水预测是一个由区域总人口、产业结构、各产业发展水平、社会经济发展程度等共同作用的多因素、多层次复杂非线性系统^[1]。现有的需水预测方法主要有粒子群算法、人工神经网络、灰色模型理论、小波神经网络、回归分析模型、支持向量机、随机森林模型等^[2-9], 目前尚不存在公认的普适性预测方法。城市需水量是一个受诸多因素影响的变量, 因其外生变量(城市人口、产业结构等)受人为规划和实践的影响, 具有较强的不确定性和模糊性^[10]。自 J. M. Bates 等^[11]在 1969 年提出组合预测模型的理论及方法以来, 已有许多学者应用组合模型进行城市需水预测。巩琳琳^[12]采用遗传模拟退火算法的神经网络模型对陕西省进行需水预测, 有效提高了预测精度; 舒媛媛等^[13]采用基于主成分分析的 BP 神经网络预测模型对延安市进行预测分析, 有效简化了网络; 崔东文^[14]将相空间重构原理与遗传算法相结合, 建立了城市需水预测模型, 消除了变量间的多重共线问题, 有效提高了预测精度; 张倩等^[15]将灰色理论和回归分析相结合, 对大鹏半岛进行了需水预测。已有研究中, 对于人工神经网络收敛速度慢、易陷入局部最优等问题的处理有待进一步优化。为此, 本文针对上述问题, 提出了基于主成分分析的 GA-BP 需水预测模型, 即通过主成分分析筛选出需水量主要影响因子, 达到简化网络结构的目的; 采用遗传算法优化 BP 神经网络的连接权值和阈值, 达到提高网络收敛速度及避免网络陷入局部最优的目的, 为城市需水预测提供一种新的思路方法。

1 方法原理

1.1 主成分分析法

主成分分析法是通过数学降维方法, 从众多原始变量中找出几个综合性强的变量来替代原始变量, 这些综合性强的几个变量彼此间互不相关且能尽可能地反映原始变量的信息量。

主成分分析计算步骤^[16]如下。

步骤 1: 对原始数据进行标准化处理并计算其相关系数矩阵。

步骤 2: 计算特征值与特征向量。求出相关系数矩阵的特征值 $\lambda(i=1, 2, \dots, p)$, 并使其按大小顺序排列, 即 $\lambda_1 > \lambda_2 > \dots > \lambda_p > 0$, 然后分别求出对应于特征值的特征向量 $e_i(i=1, 2, \dots, p)$, 其中 p 为相关系数矩阵的阶数。

步骤 3: 计算主成分贡献率与累计贡献率。经过筛选分析, 选取累计贡献率达到 85% 以上的因子作为需水量的主要影响因子即主成分。

步骤 4: 计算主成分载荷。表示原始数据的协方

差矩阵的特征值。

1.2 BP 神经网络

BP 神经网络^[17]的学习过程分为两个阶段, 正向学习阶段和反向学习阶段。其学习规则采用梯度下降算法, 输入向量首先正向传递到隐含层, 经过传递函数计算, 将结果传递到输出层即得到输出结果。若实际输出结果与期望输出结果存在误差时, 则进行误差反向传递, 根据预测误差来调整网络权值与阈值, 从而使 BP 神经网络预测输出不断逼近期望误差, 最终达到设定期望误差或设定学习次数作为网络学习终止条件。BP 神经网络训练过程基本步骤如下。

步骤 1: 初始化网络。包括网络输入向量确定、隐含层数确定、输出层确定、权值和阈值的初始化。

步骤 2: 隐含层输出计算。由输入向量、权值及阈值计算隐含层输出。

步骤 3: 输出层输出计算。由隐含层输出及权值与阈值, 计算神经网络的预测输出。

步骤 4: 预测误差计算。由输出层输出与期望输出作差即得到预测误差。

步骤 5: 权值、阈值更新。由预测误差反向传递更新网络的权值、阈值。

步骤 6: 由终止条件判断迭代是否结束, 若没有结束, 则返回步骤 2。

1.3 GA-BP 神经网络模型

遗传算法和 BP 神经网络均具有极强解决问题的能力^[18-22], 遗传算法优化 BP 神经网络是采用遗传算法来优化 BP 神经网络的初始值与阈值, 使优化后的 BP 神经网络能够更好地预测函数输出。网络建立步骤如下^[23]。

步骤 1: 确定编码长度 S 及输入层个数 R 、隐含层个数 S_1 、输出层个数 S_2 。

$$S = R + S_1 + S_1 \cdot S_2 + S_1 + S_2 \quad (1)$$

步骤 2: 种群初始化。包括种群规模、迭代次数、交叉概率、变异概率的确定。

步骤 3: 适应度函数确定。本文把预测输出和实际值的绝对误差值之和作为个体适应度值。

步骤 4: 种群迭代, 生成新的种群并计算其适应度值, 直到迭代次数达到设定值结束。

步骤 5: 将种群中最优个体进行解码, 作为 BP 神经网络的权值和阈值。

步骤 6: 设定神经网络参数, 进行神经网络模型的训练、检验、预测。

2 实例应用

2.1 研究区域概况

泰州位于江苏省中部, 长江北岸, 北部与盐城毗

邻,东邻南通,西接扬州,是苏中入江达海5条航道的交汇处。全境属于亚热带季风气候,四季分明,雨量夏丰冬少,如何合理充分利用水资源,对社会经济及城市的发展具有重要的影响。因此,对泰州市进行需水量预测可为城市合理分配水资源提供依据。

2.2 主要影响因子确定

以2003—2014年为时间序列,依据《泰州市水资源公报2003—2014》社会经济和水资源利用相关数据,初步选取10个影响因子做为泰州市需水预测的影响因子,见表1。

表1 需水预测影响因子统计
Tab. 1 Table of impact factors for water demand prediction

影响因子	GDP (X_1)	人口 (X_2)	农业用水量 (X_3)	工业用水量 (X_4)	生活用水量 (X_5)	第一产业值 (X_6)	第二产业值 (X_7)	第三产业值 (X_8)	降雨量 (X_9)	耕地面积 (X_{10})
单位	亿元	万人	亿 m ³	亿 m ³	亿 m ³	亿元	亿元	亿元	亿 m ³	万亩

基于MATLAB软件编写主成分分析法程序并运行程序,得到标准化后的数据见表2,影响因子主成分特征值和贡献率及累计贡献率见表3,主成分载荷矩阵见表4。由表3可见,前4个因子的累计贡献率达93.414%,由此表明,前4个因子代表了原来10个因子90%以上的信息,即选用GDP、人口、农业用水量、工业用水量4个影响因子作为主成分替代原影

响因子。另外从表4可以看到 X_{10} 即耕地面积与主成分 X_1 相关系数达到0.7724, X_8 即第三产业值与主成分 X_2 相关系数达到0.7613,而其余变量与主成分之间相关系数较低,小于0.6,因此耕地面积与第三产业值也选作为主要影响因子。综上,选取GDP、人口、农业用水量、工业用水量、耕地面积、第三产业值6个因子作为需水预测模型的输入量。

表2 泰州市2003—2014年需水影响因子标准化后的数据
Tab. 2 Standardized data of impact factors of water demand in Taizhou City from 2003 to 2014

年份	X_1	X_2	X_3	X_4	X_5	X_6	X_7	X_8	X_9	X_{10}
2003	0.1605	0.0078	0.0005	0.1340	0.0130	0.2410	0.0043	0.0003	0.1496	0.0055
2004	0.1603	0.0018	0.0301	0.0736	0.1088	0.0731	0.0004	0.0274	0.1122	0.0584
2005	0.0070	0.0006	0.1616	0.0129	0.3186	0.0034	0.0004	0.2046	0.0056	0.4164
2006	0.0014	0.0290	0.0765	0.1088	0.1145	0.0004	0.0269	0.1469	0.0496	0.0628
2007	0.0009	0.1201	0.0182	0.2749	0.0052	0.0003	0.2042	0.0105	0.3136	0.0027
2008	0.0228	0.0828	0.1612	0.1145	0.0005	0.0194	0.1321	0.0744	0.0530	0.0002
2009	0.0794	0.0278	0.3399	0.0055	0.0003	0.1368	0.0098	0.4225	0.0024	0.0003
2010	0.0583	0.1901	0.1707	0.0005	0.0249	0.0847	0.0857	0.0792	0.0002	0.0258
2011	0.0130	0.3289	0.0075	0.0004	0.1848	0.0089	0.4395	0.0036	0.0002	0.1842
2012	0.1514	0.2008	0.0009	0.0235	0.1089	0.0683	0.0920	0.0003	0.0215	0.1772
2013	0.1845	0.0092	0.0005	0.1601	0.0117	0.2905	0.0042	0.0003	0.1642	0.0077
2014	0.1602	0.0011	0.0322	0.0912	0.1088	0.0732	0.0004	0.0300	0.1280	0.0586

表3 影响因子主成分特征值和贡献率及累计贡献率

Tab. 3 Eigenvalues, contribution rates, and cumulative contribution rates of principal components of impact factors

成分	特征值	贡献率(%)	累计贡献率(%)
X_1	3.717	37.170	37.170
X_2	2.624	26.244	63.414
X_3	1.668	16.678	80.092
X_4	1.332	13.322	93.414
X_5	0.327	3.271	96.685
X_6	0.148	1.483	98.168
X_7	0.100	1.005	99.173
X_8	0.053	0.525	99.698
X_9	0.028	0.277	99.975
X_{10}	0.003	0.025	100.000

表4 主成分载荷矩阵

Tab. 4 Load matrix of principal components

影响因子	成分			
	X_1	X_2	X_3	X_4
X_1	-0.6144	0.2568	0.5663	0.4125
X_2	0.4282	-0.6757	-0.2247	0.5224
X_3	0.4483	0.7198	-0.4965	0.0092
X_4	-0.7556	-0.3115	-0.2540	-0.4957
X_5	0.6998	-0.1445	0.5947	-0.3380
X_6	-0.6525	0.3838	0.2531	0.4272
X_7	0.3502	-0.7877	-0.3352	0.2509
X_8	0.4458	0.7613	-0.3545	-0.1328
X_9	-0.7909	-0.3256	-0.1179	-0.4318
X_{10}	0.7724	-0.1115	0.5620	-0.2821

2.3 需水预测模型建立

2.3.1 GA-BP 需水预测模型

将选取的 6 个因子作为 GA-BP 模型的输入量, 泰州市总需水量作为输出量, 建立 3 层的神经网络模型。从样本中选取 2003—2010 年数据作为训练样本, 2011—2014 年数据作为检验样本。由于样本数据的量纲及数量级不相同, 首先需对样本数据进行归一化处理, 再输入到 GA-BP 模型中进行学习训练。其中, 网络参数设定如下: 隐含层神经元个数经过试算取 10, 种群规模取 40^[24], 遗传迭代次数取 80, 交叉概率取 0.4, 变异概率取 0.08, 网络训练函数采用 traindm, 性能函数采用 mse, 设定期望均方差为 0.001, 通过学习训练后得到预测模型。

2.3.2 BP 神经网络需水预测模型

将选取的 6 个因子作为 BP 神经网络的输入量, 泰州市总需水量输出量, 建立 3 层的神经网络模型。从样本中选取 2003—2010 年数据作为训练样本, 2011—2014 年数据作为检验样本。对样本数据进行归一化处理后输入到 BP 神经网络模型中进行学习训练。其中, 网络参数设定如下: 隐含层神经元个数经过试算取 8, 网络训练函数采用 traindm, 学习率取 0.1, 性能函数采用 mse, 期望均方差为 0.001, 通过学习训练后得到预测模型。

2.4 模型评价指标

选用平均相对误差 e_{MRE} 及最大相对误差 e_{maxMRE} 作为需水预测模型评价的标准, 其计算公式如下:

$$e_{MRE} = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{x}_i - x_i|}{x_i} \quad (2)$$

$$e_{maxMRE} = \frac{|\hat{x}_i - x_i|}{x_i} \quad (1 \leq i \leq n) \quad (3)$$

式中: \hat{x}_i 为第 i 个样本的预测值, x_i 为第 i 个样本的实际值。

2.5 需水预测结果及分析

利用训练好的 GA-BP 需水预测模型和 BP 需水预测模型对泰州市 2003—2014 年需水量进行预测, 预测结果及实际需水量见表 5。模型训练中的误差变化曲线见图 1、图 2。

由表 5 可见, GA-BP 需水预测模型对样本的拟合效果及对检验样本的预测性能均优于 BP 神经网络需水预测模型, GA-BP 需水预测模型对检验样本(2011—2014 年)的平均相对误差和最大相对误差分别为 1.0961% 和 1.6807%, 对整体样本(2003—2014 年)的平均相对误差和最大误差分别为 0.5640% 和 1.6807%, 此四项数据均优于 BP 神经网络预测模型预测结果。可见, GA-BP 需水预测模型具有较高的预测精度和泛化能力。由图 1、图 2 可以看到, GA-BP

神经网络在训练 213 步时达到了目标误差值 0.001, 而 BP 神经网络训练次数到 1174 步时才达到目标误差值 0.001, 可以看出, GA-BP 神经网络在经过权值和阈值的优化后能快速收敛到目标值, 对网络的优化效果非常显著。

表 5 GA-BP 预测模型与 BP 预测模型的拟合结果比较

Tab. 5 Comparison between the fitting results of GA-BP prediction model and BP model

年份	实际需水量 / 亿 m ³	GA-BP 神经网络		BP 神经网络	
		预测值 / 亿 m ³	相对误差 (%)	预测值 / 亿 m ³	相对误差 (%)
2003	29.63	29.6205	0.0320	29.9223	0.9865
2004	26.58	26.5269	0.1997	26.8348	0.9586
2005	28.17	28.2760	0.3762	27.9692	0.7128
2006	27.85	27.7580	0.3303	28.1247	0.9863
2007	29.76	29.3451	1.3942	30.1286	1.2386
2008	27.15	27.2586	0.4000	27.3632	0.7853
2009	28.73	28.8218	0.3195	28.1542	2.0041
2010	28.09	27.9934	0.3439	28.9415	3.0313
2011	27.93	27.9533	0.0834	25.8761	7.3537
2012	27.41	27.8707	1.6807	26.8512	2.0387
2013	27.36	27.0797	1.0244	27.9446	2.1367
2014	26.68	26.5244	0.5832	26.0571	2.3347

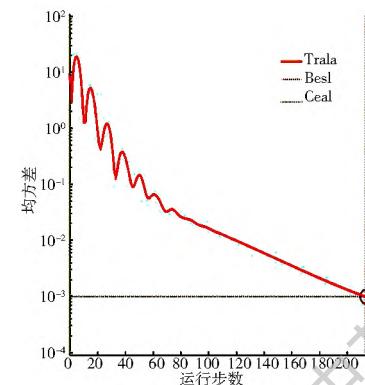


图 1 GA-BP 神经网络误差曲线

Fig. 1 Error curve of GA-BP neural network

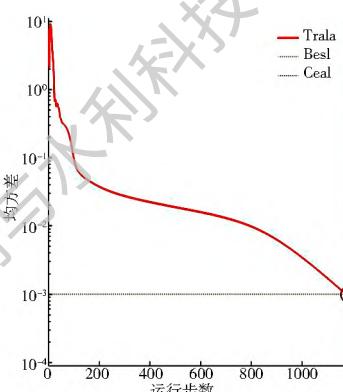


图 2 BP 神经网络误差曲线

Fig. 2 Error curve of BP neural network

另外从 GA-BP 需水预测模型对泰州市 2010–2014 年的需水预测结果可以看出, 需水量呈负增长趋势, 其增幅在 -2.84% ~ -0.14% 之间, 实际泰州市需水量变化从 2010 年的 28.09 亿 m³ 到 2014 年的 26.68 亿 m³, 逐年呈负增长趋势, 其最大增幅为 -2.49%, 预测结果与实际需水情况相符, 这也与我国实行最严格的水资源管理制度、以水定产、建设节水型社会的国情相符合, 表明基于主成分分析的 GA-BP 预测模型是一种有效的需水量预测方法。

3 结论

(1) 以泰州市为例, 通过主成分分析, 从 10 个需水量影响因子中筛选出 6 个影响因子, 作为预测模型的输入量, 降低了网络的复杂性, 同时也进一步的提高预测速度与精确度。

(2) 以泰州市 2003–2014 年的相关数据建立基于主成分分析的 GA-BP 改进预测模型, 通过与 BP 神经网络预测模型进行比较, GA-BP 预测模型的收敛速度更快, 模型预测结果与实际情况更加吻合, 预测准确度更高, 表明了该模型是一种有效的需水量预测方法。

(3) 本文虽然用主成分分析法确定了需水预测的主要影响因子, 但是这些因子都是选自于可量化的数据, 并未考虑到系统内部因素, 如节水因素对需水预测的影响, 因此, 需水预测模型还不够完善, 有待进一步优化。

参考文献(References):

- [1] 鲁凤, 徐建华, 王占永. 合肥市需水预测遗传小波神经网络模型研究[J]. 测绘科学, 2013, 38(5): 28-31. (LU F, XU J H, WANG Z Y. Research on Hefei water demand prediction model based on wavelet neural network[J]. Science of Surveying and Mapping, 2013, 38(5): 28-31. (in Chinese)) DOI: 10.16251/j.cnki.1009-2307.2013.05.002.
- [2] 郭华, 郑侃, 林占东, 等. 粒子群算法在城市需水预测模型中的应用[J]. 中国农村水利水电, 2008(12): 63-65. (GUO H, ZHENG N, LIN Z D, et al. Application of particle swarm optimization in urban water demand forecasting [J]. China Rural Water and Hydropower, 2008(12): 63-65. (in Chinese))
- [3] 俞亭超, 张土乔, 毛根海, 等. 预测城市用水量的人工神经网络模型研究[J]. 浙江大学学报(工学版), 2004, 38(9): 55-60. (YU T C, ZHANG T Q, MAO G H, et al. Study of artificial neural network model for forecasting urban water demand[J]. Journal of Zhejiang University(Engineering Science), 2004, 38(9): 55-60. (in Chinese))
- [4] 屈迟文, 傅彦铭, 戴俊. 改进的 CS GRNN 模型在城市需水量预测中的应用[J]. 西南师范大学学报(自然科学版), 2014, 39(9): 127-132. (QU C W, FU Y M, DAI J. On application of generalized regression neural network optimized by chckoo search algorithm in urban water demand prediction [J]. Journal of Southwest China Normal University (Natural Science Edition), 2014, 39(9): 127-132. (in Chinese)) DOI: 10.13718/j.cnki.xsxb.2014.09.022.
- [5] 王弘宇, 马放, 杨开, 等. 灰色新陈代谢 GM(1,1) 模型在中长期城市需水量预测中的应用研究[J]. 武汉大学学报(工学版), 2004, 37(6): 32-35. (WANG H Y, MA F, YANG K, et al. A study of information renewal GM(1,1) model for predicting urban medium and long-term water demand [J]. Engineering Journal of Wuhan University (Engineering Science), 2004, 37(6): 32-35. (in Chinese)) DOI: 10.13718/j.cnki.xsxb.2014.09.022.
- [6] 佟长福, 史海滨, 包小庆, 等. 基于小波分析理论组合模型的农业需水量预测[J]. 农业工程学报, 2011, 27(5): 93-98. (TONG C F, SHI H B, BAO X Q, et al. Application of a combined model based on wavelet analysis for predicting crop water requirement [J]. Transactions of the CSAE, 2011, 27(5): 93-98. (in Chinese)) DOI: 10.3969/j.issn.1002-6819.2011.05.015.
- [7] 王春娟, 冯利华, 罗伟, 等. 主成分回归在需水预测中的应用[J]. 水资源与水工程学报, 2013, 24(1): 50-53. (WANG C J, FENG L H, LUO W, et al. Application of principle component regression model to water demand forecast [J]. Journal of Water Resources and Water Engineering, 2013, 24(1): 50-53. (in Chinese))
- [8] 张日俊, 董增川, 郭慧芳. 基于支持向量机的鄱阳湖环湖区需水预测模型[J]. 水电能源科学, 2010, 28(4): 22-23, 55. (ZHANG R J, DONG Z C, GUO H F. Water demand forecast model of Poyang lake area based on support vector machine [J]. Water Resources and Power, 2010, 28(4): 22-23, 55. (in Chinese))
- [9] 王盼, 陆宝宏, 张翰文, 等. 基于随机森林模型的需水预测模型及其应用[J]. 水资源保护, 2014, 30(1): 34-37, 89. (WANG P, LU B H, ZHANG H W, et al. Water demand prediction based on random forests model and its application [J]. Water Resources Protection, 2014, 30(1): 34-37, 89. (in Chinese)) DOI: 10.3969/j.issn.1004-6933.2014.01.007.
- [10] 张灵, 陈晓宏, 刘丙军, 等. 基于 AGA 的 SVM 需水预测模型研究[J]. 水文, 2008, 28(1): 38-42, 46. (ZHANG L, CHEN X H, LIU B J, et al. SVM Model of Water Demand Prediction Based on AVG [J]. Journal of China Hydrology, 2008, 28(1): 38-42, 46. (in Chinese))
- [11] BATES J M, GRANGER C W J. The combination of forecast [J]. Operation Research Quarterly, 1969, 20: 451-468.
- [12] 巩琳琳. 基于遗传模拟退火算法的神经网络模型在陕西省需水预测中的应用[J]. 地下水, 2006, 28(5): 10-13, 20. (GONG L L. The NN Model based on annealing arithmetic of genetic simulation under the application of water demand forecast in Shaanxi province [J]. Ground Water, 2006, 28(5): 10-13, 20. (in Chinese))
- [13] 舒媛媛, 周维博, 刘雷, 等. 基于主成分分析的 BP 神经网络在延安市需水预测中的应用[J]. 水资源与水工程学报, 2012, 23(6): 172-175. (SHU Y Y, ZHOU W B, LIU L, et al. Application of BP neutral networks to water demand forecast of Yanan City based on principle component analysis [J]. Journal of Water Resources and Water Engineering, 2012, 23(6): 172-175. (in Chinese))
- [14] 崔东文. 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[J]. 水利水电科技进展, 2014, 34(1): 85-89. (CUI D W. Application of genetic neural network model to urban water demand prediction based on theory of space reconstruction [J]. Advances in Science and Technology of Water Resources, 2014, 34(1): 85-89. (in Chinese)) DOI: 10.3880/j.issn.1006-7647.2014.01.018.
- [15] 张倩, 沈利, 蔡焕杰, 等. 基于灰色理论和回归分析的需水量组合预测研究[J]. 西北农林科技大学学报(自然科学版), 2010,

- 38(8): 223-227. (ZHANG Q, SHEN L, CAI H J, et al. Combination forecast research on water demand based on the grey theory and regression analysis [J]. Journal of Northwest A & F University (Natural Science), 2010, 38(8): 223-227. (in Chinese))
- [16] 万金保, 曾海燕, 朱邦辉. 主成分分析法在乐安河水质评价中的应用 [J]. 中国给水排水, 2009, 25(16): 104-108. (WAN J B, ZENG H Y, ZHU B H. Application of principal component analysis in evaluation of water quality of Le'an river [J]. China Water and Waste Water, 2009, 25(16): 104-108. (in Chinese))
- [17] 杨建刚. 人工神经网络实用教程 [M]. 杭州: 浙江大学出版社, 2003: 44-45. (YANG J G. Artificial neural network practical tutorial [M]. Hangzhou: Zhejiang University Press, 2003: 44-45. (in Chinese))
- [18] 崔东文. 基于 BP 神经网络的文山州水资源承载能力评价分析 [J]. 长江科学院报, 2012, 29(5): 9-15. (CUI D W. Evaluation and analysis of water resources carrying capacity in Wenshan prefecture based on BP neural network [J]. Journal of Yangtze River Scientific Research Institute, 2012, 29(5): 9-15. (in Chinese)) DOI: 10.3969/j.issn.1001-5485.2012.05.003.
- [19] 王小川, 史峰, 郁磊, 等. MATLAB 神经网络 30 个案例分析 [M]. 北京: 北京航空航天出版社, 2002. (WANG X C, SHI F, YU L, et al. Analysis of 30 cases of MATLAB neural network [M]. Beijing: Beijing Aerospace University Press, 2002. (in Chinese))
- [20] 何斌, 张澎辉, 梁国华, 等. 基于 BP 神经网络的场次洪水河道沙量预报 [J]. 南水北调与水利科技, 2015, 13(3): 406-408, 416. (HE B, ZHANG P H, LIANG G H, et al. Flood and sediment prediction based on BP neural network [J]. South-to-North Water Transfers and Water Science & Technology, 2015, 13(3): 408, 416. (in Chinese)) DOI: 10.13476/j.cnki.nsbdqk.2015.03.002.
- [21] 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. (YUAN X M, LI H Y, LIU S K, et al. Application of neural network and genetic algorithm in water science [M]. Beijing: China Water power Press, 2002. (in Chinese))
- [22] 张德丰. MATLAB 神经网络应用设计 [M]. 北京: 机械工业出版社, 2009. (ZHANG D F. MATLAB neural network design [M]. Beijing: Mechanical Industry Press, 2009. (in Chinese))
- [23] 蔡臣, 黄涛, 李云桢. 基于 GA-BP 神经网络水下隧道涌水量预测及应用 [J]. 路基工程, 2013(1): 39-42. (CAI C, HUANG T, LI Y Z. Forecast and application on water inflow of underwater tunnel based on GA-BP neural network [J]. Subgrade Engineering, 2013(1): 39-42. (in Chinese)) DOI: 10.3969/j.issn.1003-8825.2013.01.010.
- [24] 刘晓霞. 种群规模对遗传算法性能的研究 [D]. 保定: 华北电力大学, 2010. (LIU X X. Research of population size on the performance of genetic [D]. Baoding: North China Electric Power University, 2010. (in Chinese))

(上接第 25 页)

- [9] 纪永明, 陈静, 矫梅燕. 基于多中心 TIGGE 资料的区域 GRAPES 集合预报初步试验 [J]. 气象, 2011(4): 392-402. (JI Y M, CHEN J, JIAO M Y. The preliminary experiment of GRAPES MESO ensemble prediction based on TIGGE data [J]. Meteorological Monthly, 2011(4): 392-402. (in Chinese))
- [10] 智协飞, 季晓东, 张璟, 等. 基于 TIGGE 资料的地面气温和降水的多模式集成预报 [J]. 大气科学学报, 2013, 36(3): 257-266. (ZHI X F, JI X D, ZHANG J, et al. Multimodel ensemble forecasts of surface air temperature and precipitation using TIGGE datasets [J]. Journal of Nanjing Institute of Meteorology, 2013, 36(3): 257-266. (in Chinese)) DOI: 10.3967/j.issn.1001-0596.2013.03.0257-10.
- [11] 任正果, 张明军, 王圣杰, 等. 1961-2011 年中国南方地区极端降水事件变化 [J]. 地理学报, 2014, 69(5): 640-690. (REN Z G, ZHANG M J, WANG S J, et al. Changes in precipitation extremes in South China during 1961-2011 [J]. Acta Geographica Sinica, 2014, 69(5): 640-690. (in Chinese)) DOI: 10.11821/dlx.201405007.
- [12] 李佰平, 智协飞. ECMWF 模式地面气温预报的四种误差订正方法的比较研究 [J]. 气象, 2012, 38(8): 897-902. (LI B P, ZHI X F. Comparative study of four correction schemes of the ECMWF surface temperature forecasts [J]. Meteorological Monthly, 2012, 38(8): 897-902. (in Chinese))
- [13] 王雨. 2004 年主汛期各数值预报模式定量降水预报评估 [J]. 应用气象学报, 2006, 17(3): 316-323. (WANG Y. Evaluation of quantitative precipitation forecasting of multiple NWP models in summer of 2004 [J]. Journal of Applied Meteorological Science, 2006, 17(3): 316-323. (in Chinese))
- [14] 张建海, 诸晓明. 数值预报产品和客观预报方法预报能力检验 [J]. 气象, 2006, 32(2): 58-63. (ZHANG J H, ZHU X M. Verification of prediction capability of NWP products and objective forecast methods [J]. Meteorological Monthly, 2006, 32(2): 58-63. (in Chinese))
- [15] 杨云川, 程根伟, 范继辉, 等. 卫星降水数据在高山峡谷地区的代表性与可靠性 [J]. 水科学进展, 2013, 24(1): 24-33. (YANG Y C, CHENG G W, FAN J H, et al. Representativeness and reliability of satellite rainfall dataset in alpine and gorge region [J]. Advances in Water Science, 2013, 24(1): 24-33. (in Chinese)) DOI: 10.3969/j.issn.1003-6791.2013.01-0024-10.
- [16] 黄嘉佑. 气象统计分析与预报方法 [M]. 北京: 气象出版社, 2004. (HUANG J Y. Meteorological statistical analysis and forecast method [M]. Beijing: Meteorological Press, 2004. (in Chinese))
- [17] 国家气象中心. 气象中常用检验方法概述 [M]. 北京: 气象出版社, 1991: 2-5. (The National Meteorological Center. Summary of test method commonly used in meteorology [M]. Beijing: Meteorological Press, 1991: 2-5. (in Chinese))
- [18] Murphy J. An evaluation of statistical and dynamical techniques for downscaling local climate [J]. Journal of Climatology, 1999, 12: 2256-2284. (in Chinese)) DOI: 10.1007/s00340-007-0401-05.
- [19] 马清, 龚建东, 李莉, 等. 超级集合预报的误差订正与集合研究 [J]. 气象, 2008, 34(3): 42-48. (MA Q, GONG J D, LI L, et al. Study of bias correction and consensus in regional multi-model super ensemble forecast [J]. Meteorological Monthly, 2008, 34(3): 42-48. (in Chinese))
- [20] 王丽, 金琪, 柯怡明. 三种数值预报产品短期强降水预报定量误差评估 [J]. 暴雨灾害, 2007, 26(4): 301-305. (WANG L, JIN Q, KO Y M. Quantitative evaluation of short term strong precipitation forecasting of three NWP models [J]. Torrential Rain and Disasters, 2007, 26(4): 301-305. (in Chinese))