

DOI:10.3969/j.issn.1004-6933.2014.02.006

加权平均集成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:针对单一神经网络模型预测误差波动大、精度不高等问题,提出基于SVM、BP和Elman神经网络基本模型的加权平均集成需水预测模型。首先,利用相关分析和ADF单位根检验,选取需水预测主要影响因子。为避免模型过度拟合,引入虚拟维,并针对BP、Elman神经网络标准算法收敛速度慢、易陷入局部极值的不足,采用自适应动量算法改进BP和Elman神经网络标准算法,依次构建SVM、BP和Elman需水预测单一模型,并对上海市2002—2011年需水量进行预测;最后,基于加权平均方法对各单一模型预测结果进行综合集成。结果表明:利用加权平均集成模型对上海市2002—2011年需水量进行预测的平均相对误差绝对值为1.8004%,最大相对误差绝对值为3.6995%,精度和泛化能力均大幅优于各单一模型。说明本研究建立的加权平均集成模型用于需水预测是合理可行和有效的,它综合了各单一模型的优点,有效避免了单一模型预测误差过大和不稳定的缺点,具有预测精度高、泛化能力强、误差变化幅度不大等特点。

关键词:需水预测;支持向量机;BP神经网络;Elman神经网络;加权平均集成模型

中图分类号:TV213.4

文献标志码:A

文章编号:1004-6933(2014)02-0027-06

Application of weighted average integrated neural network model to urban water demand forecasting

CUI Dongwen

(Wenshan Water Conservancy Bureau of Yunnan Province, Wenshan 663000, China)

Abstract: A single neural network model has the disadvantages of a large degree of error fluctuation and low precision. To solve these problems, a weighted average integrated water demand forecast model was developed based on the SVM, BP, and Elman neural network models. First, correlation analysis and an ADF test of the unit root were conducted to select the main factors in water demand forecasting. In order to avoid model overfitting, the virtual dimension was introduced. To overcome the shortcomings, including the slow convergence and likely occurrence of local extreme values of the BP and Elman neural network standard algorithms, the adaptive momentum algorithm was used to improve the BP and Elman neural network algorithms. The SVM, BP, and Elman models, each of them being a single model, were constructed, and were applied to water demand forecasting in Shanghai City during the period from 2002 to 2011. Finally, the weighted average method was used to integrate the results of the three single models. The study results show that the absolute value of the average relative error and the absolute value of the maximum relative error of the integrated model were 1.800 4%, and 3.699 5%, respectively, for water demand forecasting in Shanghai City during the period from 2002 to 2011. The precision and generalization ability of the integrated model were much better than those of the single model, indicating that the proposed weighted average integrated model was a feasible option and effective in water demand forecasting. The proposed model integrates the advantages of each single model, effectively avoids the problem of a large degree of prediction error and the instability of a single model, and has the advantages of high precision, strong generalization ability, and slight changes in errors.

Key words: water demand prediction; support vector machine; BP neural network; Elman neural network; weighted average integrated model

1 研究背景

城市需水量预测是给水系统规划与管理的重要内容之一,也是制定水资源发展战略的重要环节^[1],准确有效地预测需水量对社会经济和环境的协调发展具有重要的意义。传统需水预测一般采用定额法、时间序列法、回归分析法以及灰色预测法等方法,这些传统方法忽视了需水诸影响因素间动态相互制约的关系,存在预测精度不高等问题和不足^[2-3]。城市需水预测是以经济发展特征和用水现状为基础,受到城市规模、社会经济发展水平和政府政策等诸多相关因素的影响,是一个典型的多层次复杂非线性系统,适宜借助人工神经网络(artificial neural network, ANN)等智能算法来解决其高维、非线性预测问题。ANN 中的 BP 神经网络(back-propagation network, BP)和 Elman 神经网络在城市需水预测中得到了广泛应用^[4-5]。然而在实际应用中, BP 神经网络存在着学习收敛速度慢、易陷入局部极值等不足。为克服 BP 算法中的不足,基于附加动量法、自适应速率调整法、弹性算法、拟牛顿法、共轭梯度法、Levenberg-Marquardt 法以及遗传算法(genetic algorithm, GA)等智能算法优化 BP 网络权值阈值等的改进算法被提出^[6-8],并在改进的 BP 神经网络算法中得到了应用^[5,9]。Elman 神经网络是一种典型的动态神经元网络,其网络结构及算法较 BP 神经网络有较大改善,但由于 Elman 神经网络是在 BP 神经网络的基础上改进而来,也采用 BP 神经网络算法进行权值修正,因此同样存在着学习速度较慢,易陷入局部极值等缺点。支持向量机(support vector machine, SVM)是一种通用的前馈神经网络,用于解决模式分类和非线性映射问题。SVM 具有严谨的数学基础,通过统计学习中的 VC 维(vapnik-chervonenkis dimension)理论和寻求结构风险最小化原理来提高泛化能力,已成为继 ANN 之后机器学习领域新的研究热点,其最小结构风险二次规划寻优理论、支持向量决定 SVM 拓扑结构、支持向量数目决定计算复杂程度的三大优势决定了它在机器学习领域有着举足轻重的地位^[8,10-11]。集成预测是 Bates 等^[12]在 1969 年提出的组合预测思想,其目的是为了有效地利用各种模型的优点,将不同的预测方法进行适当组合,综合利用各种方法所提供的信息,从而尽可能提高预测精度。实践表明,不同的预测方法往往有不同的预测结果,不同的预测方法能挖掘不同的有用信息,不同模型的预测结果通常具有互补性,其预测精度也各有悬殊。没有一种适用于所有预测的通用方法,任何一种预测方法都有其适用

性和局限性,因此应依据实际问题选择适当的模型与方法^[13]。

在实际应用中,决定预测模型精度的关键因素是问题本身的复杂程度,针对不同问题选择恰当的预测方法是决定预测效果优劣的关键。基于此,笔者针对上海市需水预测的小样本容量问题,经过调试和筛选,选用 SVM、BP 和 Elman 神经网络作为基本预测模型,并利用下述方法提高 SVM、BP 和 Elman 单一模型的预测精度和泛化能力:一是采用交叉验证法(cross validation, CV)确定 SVM 模型中的惩罚因子 c 和核函数参数 g ;二是针对 BP、Elman 神经网络标准算法收敛速度慢、易陷入局部极值的不足,采用自适应动量算法改进 BP、Elman 神经网络标准算法;最后,基于集成预测的思想,采用加权平均方法构建综合集成预测模型,并以上海市 2002—2011 年需水量预测为例,以验证加权平均集成模型的预测精度。

2 预测模型简介

2.1 支持向量机(SVM)

SVM 是 20 世纪 90 年代中后期发展起来的基于统计学习理论而构建的典型神经网络。SVM 用于回归时,其基本思想不再是寻找最优分类面将样本分开,而是寻找一个最优超平面,使得所有训练样本离该最优超平面距离最短,这个超平面可看作拟合好的曲线。SVM 类似于一个 3 层前馈神经网络,其隐层节点数对应于输入样本与一个支持向量机的内积核函数,输出节点数对应于隐层输出的线性组合。SVM 神经网络拓扑结构及算法步骤可参阅笔者论文^[8,14]及相关文献^[10-11]。

2.2 BP 与 Elman 神经网络

BP 神经网络是一种单向传播的多层前馈神经网络,主要特点是信号前向传播,误差反向传播,其算法的精髓是将网络的输出与期望输出间的误差通过反向传播分摊到各神经元的权值和阈值,通过多次迭代使 BP 神经网络的预测输出不断逼近期望输出。由非线性变换单元组成的 BP 神经网络,不仅结构简单(仅含输入、输出和隐节点 3 层),而且具有良好的非线性映射能力,主要应用于函数逼近、模式识别、分类和数据压缩等领域。限于篇幅,其网络拓扑结构及算法步骤可参阅笔者的研究^[9,15-17]及相关文献^[6-7,11,18]。

Elman 神经网络是 Elman 于 1990 年提出的,该模型是在前馈式网络的隐含层中增加了一个承接层,作为一步延时算子,以达到记忆的目的,从而使系统具有适应时变特性的能力,能够更生动、更直接

地反映系统的动态特性。与 BP 神经网络本质上的区别是,Elman 网络既有前馈连接,又有反馈连接,能有效克服 BP 神经网络不具备动态特性的缺点。Elman 神经网络同样可以以任意精度逼近任意非线性映射,工程中主要用于动态预测,在函数逼近、模式识别等方面也均有应用,其网络拓扑结构及算法步骤可参阅笔者论文^[9,16,19]及相关文献^[6-7,11,18]。

2.3 BP 与 Elman 神经网络算法的改进

由于 BP 和 Elman 神经网络均是采用梯度下降算法,其权值和阈值的调整是沿着误差函数下降最快的方向——负梯度方向进行的。梯度下降算法在最初几步下降较快,但随着接近最优值,梯度趋于零,误差函数开始下降缓慢,陷入局部极值。针对 BP 和 Elman 神经网络算法中的不足,笔者采用自适应动量算法改进标准梯度下降算法。自适应动量算法是将附加动量法和自适应学习速率调整法结合起来,利用二者的优点,大大提高 BP 和 Elman 神经网络的收敛速度和预测精度。自适应动量算法的原理及步骤^[6-7,9,18]简述如下:

步骤一:附加动量法。附加动量法是在反向算法的基础上,在每一个权值变化基础上增加一项正比于前次权值变化量的值,并根据反向算法来产生新的权值变化。附加动量法权值、阈值的调节公式为

$$\Delta w(k+1) = (1 - m_c) \eta \nabla f(w(k)) + m_c \Delta w(k) \quad (1)$$

$$\Delta b(k+1) = (1 - m_c) \eta \nabla f(w(k)) + m_c \Delta b(k) \quad (2)$$

式中: k 为训练次数; η 为学习速率; m_c 为动量因子,一般取 0.95 左右; $\nabla f(w(k))$ 为误差函数的梯度; Δw 为权值变化量; Δb 为阈值变化量。

附加动量法实质是将最后一次权阈值的变化通过一个动量因子来传递,当增加动量项后,使得权阈值调节向着误差曲面底部的平均方向变化,当网络权值、阈值进入误差曲面底部的平坦区时, $\nabla f(w(k))$ 变得很小,此时 $\Delta w(k+1) \approx \Delta w(k)$,从而避免了 $\Delta w=0$ 情况的出现,有助于使网络从误差曲面的局部极小值中跳出。合理使用权值修正公式的判断条件为

$$m_c = \begin{cases} 0 & \text{当 } S_{SE}(k) > S_{SE}(k-1) \times 1.04 \\ 0.95 & \text{当 } S_{SE}(k) < S_{SE}(k-1) \\ m_c & \text{其他} \end{cases} \quad (3)$$

式中: S_{SE} 为网络误差。

步骤二:自适应学习速率调整法。上述式(1)和式(2)中学习速率 η 的选择对于网络训练及预测效果的影响较大, η 选择太大,将导致误差值 S_{SE} 来

回振荡; η 选择太小,则导致太小的动量能量,从而使网络只能跳出很小的“坑”,而对于较大的“坑”或“谷”则无能为力,这必然对学习速率 η 的选择带来困难。为了解决学习速率 η 的选择问题,提出了自适应学习速率调整法。自适应学习速率调整公式为

$$\eta(k+1) = \begin{cases} 1.05\eta(k) & \text{当 } S_{SE}(k+1) < S_{SE}(k) \\ 0.7\eta(k) & \text{当 } S_{SE}(k+1) > 1.04S_{SE}(k) \\ \eta(k) & \text{其他} \end{cases} \quad (4)$$

式中,学习速率 η 可根据误差值 S_{SE} 的大小自动调整。当新 S_{SE} 超过旧 S_{SE} 一定的倍数时,学习速率将减小;否则其学习速率保持不变;当新 S_{SE} 小于旧 S_{SE} 时,学习速率将增加。该方法可以保证网络总是以最大可接受的学习速率进行训练。

自适应动量算法综合了附加动量法和自适应学习速率调整法的优点,具有收敛速度快、预测精度高、不易陷入局部极值等优点,在 BP 和 Elman 神经网络算法中得到了广泛应用。

2.4 集成预测方法

加权平均预测法是依据各单一模型预测效果的优劣给出不同的权重,然后求加权平均值,以加权平均值作为集成模型预测值^[20-21]。加权平均值 $\bar{x}$ 的计算公式为

$$\bar{x} = \sum_{i=1}^k w_i \bar{x}_i \quad (5)$$

式中: $\bar{x}_i (i=1,2,\dots,k)$ 为第 i 个模型的预测值; w_i 为第 i 个模型的权重, $\sum_{i=1}^k w_i = 1, w_i \geq 0$ 。权重 w_i 的确定一般根据各单一模型的预测值或拟合值的平均相对误差计算得到,对于预测或拟合精度高的模型给出更大的权重。本文以预测平均相对误差绝对值作为确定各单一模型权重的依据,即给予预测相对误差绝对值较小的模型更大的权重。权重的计算公式为

$$w_i = \frac{1/|e_i|}{\sum_{i=1}^k 1/|e_i|} \quad (6)$$

式中: $|e_i|$ 为第 i 个模型预测相对误差的绝对值。

2.5 集成预测步骤

基于上述 SVM、BP 和 Elman 神经网络基本原理和集成预测方法,加权平均集成神经网络模型实现需水预测的步骤可归纳如下:

a. 确定输入向量。利用相关分析和多重线性回归 P 值检验的方法遴选出与需(用)水密切相关的影响因子,利用 ADF 进行单位根检验,对所选取的影响因子原始序列进行平稳性检验,对不平稳的序列进行差分,确定影响因子原始序列的平稳性和

模型的输入向量。

b. 引入虚拟维。由于需水预测序列时间较短,经调试,各单一模型预测的精度达不到基本精度要求。为保证各单一模型的预测精度和泛化能力,避免模型过度拟合,引入噪声变量,即虚拟维。

c. 构建模型。依次构建 SVM、BP 和 Elman 单一需水预测模型,利用训练样本对模型各相关参数及结构进行调试和率定,在各单一模型处于最佳预测效果时确定相关参数及结构,并计算各模型的预测值和预测误差绝对值。

d. 确定权重。利用公式(6)计算各单一模型的权重。

e. 利用集成模型进行需水预测。利用集成预测模型公式(5)对需水量进行预测和分析。若集成模型预测值达不到期望精度和泛化能力的要求,则反向对各单一模型进行调试和预测,直至集成模型预测值满足期望精度的要求。

3 应用实例

3.1 数据来源与数据分析

以上海市为例,收集上海市 1980—2011 年的年用水量及相关数据。进行相关分析可知,上海市 1980—2011 年用水序列与户籍人口、轻工业产值、重工业产值、建筑业总产值、农业总产值和服务业产值的相关系数均大于 0.8,需水序列与社会、经济相关序列之间存在着较强的相关性。鉴于输入变量间高度相关易导致多重共线性问题的发生,进而影响模型的泛化能力和预测精度,因此,本文利用多重线性回归 P 值检验的方法从户籍人口等 6 个指标中遴选出户籍人口、轻工业产值和服务业产值 3 个因

子作为输入变量,并利用 E-views 软件对需水量、户籍人口、轻工业产值和服务业产值序列进行 ADF 单位根检验,得知需水量、服务业产值序列为一阶平稳,户籍人口和轻工业产值序列为二阶平稳,表明需水量、户籍人口、轻工业产值和服务业产值为平稳序列,可用于预测。上海市 1980—2011 年各需水预测指标序列见表 1。

从表 1 可以看出,1982 年、1988 年、1999 年和 2009 年用水量较前一年有所下降,这与一定时期内用水量变化趋势不相吻合。为避免模型过度拟合,有效提高模型的预测精度和泛化能力,笔者引入噪声变量,即虚拟维。引入原则是:1982 年、1988 年、1999 年和 2009 年的噪声变量设置为 0,其余各年噪声变量按用水量年度增幅大小设置为 0.05~0.3 不等(各序列归一化范围为 0~0.5),若年度用水量增幅小于 0.5 亿 m³,则噪声变量设置为 0.05;小于 1 亿 m³,设置为 0.1;小于 1.5 亿 m³,设置为 0.2;大于 1.5 亿 m³,设置为 0.3;对于“未知”样本,可按年度用水量增幅小于 0.5 亿 m³ 计,即噪声变量设置为 0.05。

3.2 需水预测的实现

3.2.1 数据归一化处理

由于需水预测影响因子具有不同的物理意义和不同的量纲及数量级,因此,在网络训练前需对原始数据进行归一化处理,公式为

$$\hat{x} = (x - 0.5x_{\min}) / (2x_{\max} - 0.5x_{\min}) \quad (7)$$

式中: $\hat{x}$ 为经过归一化处理的数据; x 为原始数据; $x_{\max}$ 、 $x_{\min}$ 分别为数据序列中的最大值和最小值。式(7)将各序列归一化到 0~0.5 之间,便于网络训练,并满足一定时期内的需水量预测需求,也避免数

表 1 上海市 1980—2011 年用水量及其影响因子情况

年份	总用水量/ 亿 m ³	户籍人口/ 万人	服务业产值/ 亿元	轻工业 产值/亿元	年份	总用水量/ 亿 m ³	户籍人口/ 万人	服务业产值 /亿元	轻工业 产值/亿元
1980	9.73	1 146.52	65.69	331.13	1996	23.11	1 304.43	1 292.11	2 334.29
1981	10.17	1 162.84	69.84	360.12	1997	23.32	1 305.46	1 592.74	2 528.19
1982	10.09	1 180.51	74.44	359.62	1998	24.12	1 306.58	1 855.36	2 527.56
1983	10.21	1 194.01	82.97	363.92	1999	23.51	1 313.12	2 129.60	2 679.71
1984	10.64	1 204.78	98.22	395.60	2000	24.00	1 321.63	2 486.86	2 880.74
1985	11.54	1 216.69	121.59	456.59	2001	24.15	1 327.14	2 728.94	2 929.50
1986	11.71	1 232.33	135.12	493.09	2002	24.40	1 334.23	3 038.90	3 077.11
1987	12.71	1 249.51	159.48	556.96	2003	25.82	1 341.77	3 404.19	3 416.80
1988	12.61	1 262.42	187.89	679.17	2004	27.35	1 352.39	4 097.26	3 871.33
1989	12.92	1 276.45	200.73	789.57	2005	28.65	1 360.26	4 776.20	4 299.31
1990	13.32	1 283.35	241.82	846.63	2006	29.19	1 368.08	5 508.48	4 747.28
1991	13.53	1 287.20	309.07	976.34	2007	30.34	1 378.86	6 821.11	5 318.85
1992	14.10	1 289.37	402.77	1 132.75	2008	30.90	1 391.04	7 872.23	5 839.41
1993	14.94	1 294.74	579.03	1 401.33	2009	30.47	1 400.70	8 930.85	5 663.34
1994	16.27	1 298.81	794.80	1 890.12	2010	30.90	1 412.32	9 833.51	6 692.35
1995	22.07	1 301.37	1 020.20	2 092.89	2011	31.13	1 419.32	11 142.86	7 420.92

注:资料来源于《2012 年上海市统计年鉴》。

据的溢出。

3.2.2 网络训练

本研究以 1980—2011 年影响上海市需水量的相关因子建模,以户籍人口、轻工业产值、服务业产值以及虚拟维作为网络输入,需水量作为输出,构建 4 输入 1 输出的神经网络模型;以 1980—2001 年的 22 组数据作为网络训练样本;2002—2011 年 10 组数据作为网络预测检验样本。基于 MATLAB 环境,创建及训练 SVM、BP 和 Elman 神经网络模型,进行需水量预测。经反复调试,在下述参数设置条件下,SVM、BP 和 Elman 神经网络模型具有较好的预测效果。

SVM 模型:基于 libsvm 工具箱,选择径向基核函数为 SVM 的核函数。设置惩罚因子 c 和核函数参数 g 的搜索空间,均设置为 $2^{-2} \sim 2^6$, k 取值 2, g 和 c 的步进大小均取 0.5,参考文献[8]和[14],利用交叉验证法(cross validation, CV)确定模型中的惩罚因子 c 和核函数参数 g 分别为 2.445 28 和 0.25 时(其他参数采用默认值),SVM 模型性能达到最优。

BP 模型:对 BP 神经网络各隐层神经元数的选取,目前并没有统一的计算方法,主要做法是:先依据 Kolmogorv 定理得出一个初始神经元数,然后利用逐步增长或逐步修剪法确定最终神经元数。本文参考文献[13]、[17]和[21],最终确定 BP 神经网络模型的模型结构为 4-4-1,隐含层和输出层传递函数均采用 logsig,训练函数采用 traingdx,设定期望误差为 0.000 1,最大训练轮回为 5 000 次(其他参数采用默认值),此时该模型性能达到最优。

Elman 模型:做法同 BP 神经网络模型,最终确定 Elman 神经网络模型的模型结构为 4-3-1,隐含层和输出层传递函数均采用 logsig,训练函数采用 traingdx,设定期望误差为 0.000 1,最大训练轮回为

2 000 次(其他参数采用默认值),这时,Elman 模型性能达到最优。

3.3 集成预测模型权重的确定

按照上述集成预测方法和步骤,利用 SVM、BP 和 Elman 神经网络模型需水量预测值的平均相对误差绝对值来确定其各自权重。通过计算,SVM、BP 和 Elman 3 种模型的集成预测权重依次为 0.386 8、0.402 5 和 0.210 6。

3.4 需水预测结果及分析

利用上述训练好的 SVM、BP 和 Elman 神经网络模型以及加权平均集成模型对上海市 2002—2011 年需水量进行预测,预测结果见表 2。

分析表 2 和表 3,可以看出:①利用加权平均集成模型对上海市 2002—2011 年进行需水预测的平均相对误差为 1.800 4%,最大相对误差为 3.699 5%,精度和泛化能力均大幅优于各单一模型,表明该模型用于需水预测是合理可行而有效的。加权平均集成模型综合了各单一模型的优点,有效避免了单一模型预测误差过大和不稳定的缺点,具有预测精度高、泛化能力强、误差变化平稳的等特点。②就各单一模型进行比较,SVM 模型的精度和泛化能力要优于 BP 模型和 Elman 模型,且 SVM 模型具有较大的权重,这在很大程度上克服了简单平均集成方法的不足,保证了集成模型的预测精度和泛化能力。③整体而言,各单一模型预测的平均相对误差绝对值均小于 5%,最大相对误差绝对值均在 8% 以内,在一定程度上均能满足需水预测精度的要求。但从实际预测结果来看,BP 模型预测结果偏大,Elman 模型预测结果偏小,SVM 模型预测结果略偏大,但各单一模型都具有较好的互补性,从而保证了加权平均集成模型具有较高的预测精度和泛化能力。

表 2 几种模型对上海市 2002—2011 年需水量预测的结果及其比较

年份 (年)	实际值/ 亿 m ³	SVM 模型		BP 模型		Elman 模型		加权平均集成模型	
		预测值/亿 m ³	相对误差/%	预测值/亿 m ³	相对误差/%	预测值/亿 m ³	相对误差/%	预测值/亿 m ³	相对误差/%
2002	24.40	24.410 1	0.041 3	25.970 4	6.436 1	25.990 2	6.517 3	25.302 7	3.699 5
2003	25.82	25.752 0	-0.263 5	27.055 7	4.785 7	27.209 7	5.382 2	26.534 7	2.767 9
2004	27.35	26.773 2	-2.108 9	28.558 1	4.417 3	28.409 2	3.872 7	27.748 2	1.456 0
2005	28.65	28.985 6	1.171 2	29.219 6	1.988 1	28.886 7	0.826 1	29.029 3	1.323 8
2006	29.19	30.631 7	4.939 2	29.856 0	2.281 7	29.045 2	-0.496 2	29.972 9	2.682 2
2007	30.34	31.860 1	5.010 3	30.661 4	1.059 2	29.366 2	-3.209 7	30.830 7	1.617 5
2008	30.90	32.327 2	4.618 9	31.218 1	1.029 3	29.451 7	-4.687 1	31.222 3	1.043 0
2009	30.47	31.731 6	4.140 5	31.866 0	4.581 4	28.946 8	-4.999 1	31.024 3	1.819 2
2010	30.90	31.829 6	3.008 4	32.378 4	4.784 6	29.120 7	-5.758 3	31.267 1	1.188 1
2011	31.13	30.704 9	-1.365 5	33.295 5	6.956 2	28.919 9	-7.099 5	31.003 4	-0.406 8
平均相对误差 绝对值(%)		2.666 8		3.542 6		4.284 8		1.800 4	
最大相对误差 绝对值(%)		5.010 3		6.956 2		7.099 5		3.699 5	

4 结 语

本研究建立了基于 SVM、BP 和 Elman 神经网络的加权平均集成需水预测模型,该模型很好地综合了各种单一模型的优点,克服了单一模型预测误差过大和不稳定的缺点,在预测精度、泛化能力和误差稳定性方面较单一模型均有较大提高,使得验证实例的预测结果达到理想状态。在利用加权平均集成模型进行需水预测中,有两个关键之处值得借鉴:①集成模型预测精度取决于各单一模型的预测精度和模型间的互补性。互补性是指各单一模型预测平均相对误差与各自权重之积的和趋近于 0,越趋近于 0,表明模型间的互补性越强,互补性越强也就意味着集成模型的预测精度越高。②引入噪声向量,即虚拟维,避免模型过度拟合,可有效提高模型的预测精度和泛化能力。

参考文献:

[1] 陈坤.上海水资源可持续利用的经济学研究 [M]. 上海:上海人民出版社,2007.

[2] 张灵,陈晓宏,谢毅文. 投影寻踪在珠海市需水预测中的应用[J]. 人民长江,2008,39(6):41-43. (ZHANG Ling, CHEN Xiaohong, XIE Yiwen. Application of projection pursuit in Zhuhai water demand forecasting [J]. Yangtze River,2008,39(6):41-43. (in Chinese))

[3] 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 Weiling. Several water demand prediction models comparative study[J]. Yangtze River,2008,39(6):19-22. (in Chinese))

[4] 崔东文,郭荣. BP 神经网络模型与灰色 GM(1,1)模型在需水预测中的应用[J]. 水资源保护,2012,28(3):19-22. (CUI Dongwen, GUO Rong. BP neural network model and gray GM (1,1) model in water demand prediction[J]. Water Resources Protection, 2012,28(3):19-22. (in Chinese))

[5] 崔东文. 基于改进的 Elman 神经网络在需水预测中的应用[J]. 水电能源科学,2013,31(8):38-41. (CUI Dongwen. Aplication of GA-Elman multivariate water demand forecasting model [J]. Water Resources and Power,2013,31(8):38-41. (in Chinese))

[6] 张德丰. MATLAB 神经网络应用设计[M]. 北京:机械工业出版社,2009.

[7] 张良均,曹晶,蒋世忠. 神经网络实用教程[M]. 北京:机械工业出版社,2008.

[8] 崔东文. 支持向量机在水资源类综合评价中的应用研究:以全国 31 个省级行政区水资源合理性配置为例 [J]. 水资源保护,2013,29(5):20-27. (CUI Dongwen. Support vector machine for comprehensive evaluation of water resources: application to reasonable allocation of

water resources in 31 provincial-level administrative regions in China[J]. Water Resources Protection, 2013, 29(5):20-27. (in Chinese))

[9] 崔东文. 基于改进 BP 神经网络模型的区域水资源脆弱性综合评价[J]. 长江科学院院报, 2013,30(2):1-7. (CUI Dongwen. Comprehensive assessment of the water resources by improved BP neural network model [J]. Journal of Yangtze River Scientific Research Institute, 2012,30(2):1-7. (in Chinese))

[10] VAPNIK V N. 统计学习理论的本质[M]. 张学工,译. 北京:清华大学出版社,2000.

[11] 田景文,高美娟. 人工神经网络算法研究及应用[M]. 北京:北京理工大学出版社,2006.

[12] BATES J M, GRANGER C W J. The combination of forecasts [J]. Operational Research Quarterly, 1969, 20(1):451-468.

[13] 郭彦,金菊良,梁忠民. 基于集对分析的区域需水量组合预测模型[J]. 水利水电科技进展,2009,29(5):42-45. (GUO Yan, JIN Juliang, LIANG Zhongmin. Combined prediction model for regional water demand based on set pair analysis [J]. Advances in Science and Technology of Water Resources, 2009,29(5):42-45. (in Chinese))

[14] 崔东文. 支持向量机在湖库营养状态识别中的应用研究[J]. 水资源保护, 2013, 29(4):26-30. (CUI Dongwen. Application of support vector machine to lake and reservoir trophic status recognition [J]. Water Resources Protection, 2013, 29(4):26-30. (in Chinese))

[15] 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]. Journal of 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] 崔东文. 多隐层 BP 神经网络模型在径流预测中的应用 [J]. 水文,2013,33(1):68-73. (CUI Dongwen. Multi-layers BP neural network model in runoff prediction [J]. Journal of China Hydrology, 2013, 33(1):68-73. (in Chinese))

[18] 丛爽. 面向 MATLAB 工具箱的神经网络理论与应用 [M]. 合肥:中国科学技术大学出版社,2009.

[19] 崔东文. 改进 Elman 神经网络在径流预测中的应用 [J]. 水利水运工程学报,2013,38(2):71-77. (CUI Dongwen. An improved Elman neural network and its application to runoff forecast [J] Hydro-Science and Engineering,2013,33(1):71-77. (in Chinese))

(下转第 45 页)

状垃圾堆积场周边受到严重污染,水质类别为Ⅴ类,不适宜饮用;其他地点第Ⅰ含水层水质达到Ⅰ~Ⅱ类水质标准,水质较好,第Ⅱ、第Ⅲ含水层地下水达到了Ⅱ类水质标准,可以适用于各种用途。

b. 在进行定量评判水环境质量的同时,应结合水环境污染因子对人类的毒副作用与危害性开展研究,弥补采用不同方法评价水环境质量产生的差异,以保证评价的合理性。

参考文献:

[1] 梅学彬,王福刚,曹剑锋. 模糊综合评判法在水质评价中的应用及探讨[J]. 世界地质,2000,19(2):172-177. (MEI Xuebin, WANG Fugang, CAO Jianfeng. The application of fuzzy comprehensive evaluation on water quality and discussion[J]. World Geology,2000,19(2):172-177. (in Chinese))

[2] 束龙仓,邱汉学. 济宁市开采层地下水水质的 FUZZY 综合评判及 FORTRAN 程序[J]. 长春地质学院学报,1998,18(4):431-440. (SHU Longcang, QIU Hanxue. Fuzzy comprehensive method and the devised FORTRAN program evaluating the quality of groundwater from producing in Jining City [J]. Journal of Changchun University of Earth science,1998,18(4),431-440. (in Chinese))

[3] 韩银富,杨林. 运用模糊数学综合评判法评价宝应县地下水质量[J]. 地质灾害与环境保护,2000,11(1):17-20. (HAN Yinfu, YANG Lin. Evaluation of the quality of groundwater in Baoying using fuzzy mathematics comprehensive judgement [J]. Journal of Geological Hazards and Environment Preservation,2000,11(1):17-20. (in Chinese))

[4] 罗海江,朱建平,蒋火华. 我国河流水质评价污染因子选择方案探讨[J]. 中国环境监测,2002,18(4):51-55. (LUO Haijiang, ZHU Jianping, JIANG Huohua. The suggestion of selecting pollution items on water quality evaluation[J]. Environmental Monitoring in China,2002,18(4):51-55. (in Chinese))

[5] GB/T14848—93 地下水质量标准[S].

[6] 谷朝君,潘颖,潘明杰. 内梅罗指数法在地下水水质评

价中的应用及存在问题[J]. 环境保护科学,2002,28(1):45-47. (GU Zhaojun, PAN Ying, PAN Mingjie. The application and existed problems of nemero index in groundwater quality evaluation [J]. Environmental Protection Science,2002,28(1):45-47. (in Chinese))

[7] 吴万铎. 模糊数学与计算机应用[M]. 北京:电子工业出版社,1998.

[8] 张华侨,窦明,赵辉,等. 郑州市水安全模糊综合评价[J]. 水资源保护,2010,26(6):42-46. (ZHANG Huaqiao, DOU Ming, ZHAO Hui, et al. Fuzzy comprehensive evaluation of water security in Zhengzhou City[J]. Water Resources Protection,2010,26(6):42-46. (in Chinese))

[9] 涂向阳,高学平. 模糊数学在海水入侵地下水水质评价中的应用[J]. 水利学报,2003(8):64-69. (TU Xiangyang, Gao Xueping. Application of fuzzy mathematical method in evaluation of seawater intrusion [J]. Journal of Hydraulic Engineering,2003(8):64-69. (in Chinese))

[10] 刘洪,孙国曦. 南京市岩溶地下水质量的模糊评价[J]. 地质灾害与环境保护,2007,18(3):76-79. (LIU Hong, SUN Guoxi. The application of fuzz judgement in karst groundwater quality of Nanjing City [J]. Journal of Geological Hazards and Environment Preservation,2007,18(3):76-79. (in Chinese))

[11] 王淑文,刘臣. 水环境质量评价的模糊数学法[J]. 吉林水利,2001(2):20-22. (WANG Shuwen, LIU Chen. Brief discussion on fuzzy math method used in evaluation of quality for water environment[J]. Jilin Water Resources,2001(2):20-22. (in Chinese))

[12] 王勇,曹丽文,刘勇,等. 淮北某矿区地下水环境质量评价[J]. 煤田地质与勘探,2011,39(2):34-37. (WANG Yong, CAO Liwen, LIU Yong, et al. Groundwater environmental quality assessment for a mine area in Huaibei[J]. Coal Geology & Exploration,2011,39(2):34-37. (in Chinese))

[13] 范建华. 环滇池城区地质环境资源综合评价与规划[D]. 长春:吉林大学,2008.

(收稿日期:2013-03-07 编辑:彭桃英)

(上接第32页)

[20] 郑莉,段冬梅,陆凤彬,等. 我国猪肉消费需求集成预测:基于 ARIMA、VAR 和 VEC 模型的实证[J]. 系统工程理论与实践,2013,33(4):918-925. (ZHENG Li, DUAN Dongmei, LU Fengbin, et al. Integration forecast of Chinese pork consumption demand: empirical based on ARIMA、VAR and VEC models [J]. Systems Engineering—Theory & Practice, 2013,33(4):918-925. (in Chinese))

[21] 崔东文. 基于极限学习机的长江流域水资源开发利用综合评价[J]. 水利水电科技进展,2013,33(2):14-19. (CUI Dongwen. Comprehensive evaluation of water resources development and utilization in Yangtze River Basin based on extreme learning machine [J]. Advances in Science and Technology of Water Resources,2013,33(2):14-19. (in Chinese))

(收稿日期:2013-05-31 编辑:彭桃英)