

DOI:10.3969/j.issn.1004-6933.2013.02.013

极限学习机在湖库总磷、总氮浓度预测中的应用

崔东文

(云南省文山州水务局,云南 文山 663000)

摘要:基于传统 BP 人工神经网络模型训练速度慢、参数选择困难、易陷入局部极值等问题,提出极限学习机(ELM)的水质预测模型。以云南某水库为例,选取 $\text{NH}_3\text{-N}$ 、 $\text{NO}_2\text{-N}$ 、 $\text{NO}_3\text{-N}$ 、 COD_{Mn} 和 水体透明度作为网络输入,TP、TN 作为输出,构建基于 ELM 的湖库 TP、TN 预测模型,并将 ELM 预测结果与传统 BP、GA-BP、RBF 人工神经网络模型模拟结果进行比较。结果表明,ELM 模型预测精度高于传统 BP 和 RBF 模型模拟结果,甚至略高于 GA-BP 模型的预测精度,并且 ELM 模型具有参数选择简便、训练速度快、不会陷入局部最优值等特点,有着较大的计算优势。

关键词:极限学习机;人工神经网络模型;GA-BP; BP; RBF;水质预测;湖库

中图分类号:X502;O242.1 文献标志码:A 文章编号:1004-6933(2013)02-0061-06

Application of extreme learning machine to total phosphorus and total nitrogen forecast in lakes and reservoirs

CUI Dongwen

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

Abstract: The traditional BP neural network model has the disadvantages of low training speed and difficulty in parameter selection, and it can easily fall into local extremum issues. In order to solve these problems, a water quality prediction model, the extreme learning machine (ELM), is proposed. The model was applied to a reservoir in Yunnan Province. $\text{NH}_3\text{-N}$, $\text{NO}_2\text{-N}$, $\text{NO}_3\text{-N}$, COD_{Mn} , and water transparency were selected as the network inputs, and TP and TN were selected as the outputs to build the TP and TN prediction model based on ELM. The predicted results of ELM were compared with those of the traditional BP, GA-BP, and RBF neural network models. The results show that the ELM model's prediction accuracy was higher than those of the traditional BP and RBF neural network models, and even slightly higher than that of the GA-BP model. In addition, ELM model parameter selection is simple, has a capability for fast training, and is not likely to fall into local optimum values; it has a large computational advantage.

Key words: extreme learning machine; artificial neural network model; GA-BP; BP; RBF; water quality prediction; lakes and reservoirs

氮、磷是引起水体富营养化和水华的主导性因子,也是湖库营养状态评价、污染物排放总量控制的重要性指标。湖库氮(N)、磷(P)等营养物质的大量增加,总是伴随着水体富营养化,甚至水华现象的发生^[1]。因此准确预测湖库中的 N、P 浓度对预防水体富营养化具有重要现实意义。近年来,人工神经网络(artificial neural network, ANN)广泛运用于水

质预测研究领域,如水体矿化度的预测^[2]、河湖水华预测^[3-5]、河流 BOD-DO 模拟预测^[6]、湖库叶绿素预测^[7]、水质指标预测^[8]等,均取得了较好效果。然而传统 BP 人工神经网络模型存在着学习收敛速度慢、易陷入局部极值以及网络结构难以确定等缺点,为克服其算法的不足,学者们提出基于附加动量、自适应调整参数、弹性方法、拟牛顿法、共轭梯度

作者简介:崔东文(1978—),男,高级工程师,主要从事水资源、水环境及水资源保护等研究工作。E-mail:cdwgr@163.com

法以及 Levenberg-Marquardt 等的改进算法^[9-10],但在实际应用中仍不够完善,不能完全克服 BP 算法固有的缺陷。针对传统 BP 算法固有的缺陷,目前普遍采用遗传算法对 BP 网络结构、网络权值和阈值进行优化^[9]。遗传算法(genetic algorithm,GA)虽然具有良好的全局优化性能,与 BP 网络相结合,能够较好地对网络的权值、阈值进行寻优,使网络性能得到较大改善,避免局部极值等问题^[11]。然而,GA-BP 算法同样面临着复杂的参数选取和编码等问题。径向基函数算法(radial basis function,RBF)虽然有着良好的非线性逼近能力和精度,但隐含层神经元中心的选取是制约其精度提高的主要因素。极限学习机(extreme learning machine,ELM)是文献[12-18]提出的一种新型单隐层前向神经网络(single-hidden layer feedforward neural network,SLFN),ELM 算法随机产生输入层与隐含层间的连接权值及隐含层神经元阈值,且在训练过程中无需调整,只需要设置隐含层神经元的个数,便可以获得唯一的最优解。与传统的训练方法相比,该方法具有学习速度快、泛化性能好等优点。

本文基于 ELM 算法基本原理,以云南省某水库为例,采用 SPSS 软件分析 TP、TN 质量浓度与环境因子的相关性,选取 $\text{NH}_3\text{-N}$ 、 $\text{NO}_2\text{-N}$ 、 $\text{NO}_3\text{-N}$ 、 COD_{Mn} 质量浓度和水体透明度作为网络输入,TP、TN 质量浓度作为输出,构建基于 ELM 的湖库 TP、TN 质量浓度预测模型,并构建传统 BP、GA-BP、RBF 人工神经网络模型作为对比预测模型进行比较,为湖库 TP、TN 质量浓度预测探寻新的方法和途径。

1 极限学习机概述

给定一个输入层含有 n 个输入变量、隐含层有 l 个神经元、输出层有 m 个神经元的典型 SLFN 网络。不失一般性,设输入层与隐含层间的连接权值为 ω ,隐含层与输出层间的连接权值为 β ,隐含层神经元阈值为 b ,则 ω 、 β 和 b 分别为:

$$\omega = \begin{bmatrix} \omega_{11} & \cdots & \omega_{1n} \\ \omega_{21} & & \omega_{2n} \\ \vdots & & \vdots \\ \omega_{l1} & \cdots & \omega_{ln} \end{bmatrix}_{l \times n}$$

$$\beta = \begin{bmatrix} \beta_{11} & \cdots & \beta_{1m} \\ \beta_{21} & \cdots & \beta_{2m} \\ \vdots & & \vdots \\ \beta_{l1} & \cdots & \beta_{lm} \end{bmatrix}_{l \times m}$$

$$b = \begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_l \end{bmatrix}_{l \times 1}$$
(1)

式中: ω_{ij} 表示输入层第 i 个神经元与隐含层第 j 个神经元间的连接权值; β_{jk} 表示隐含层第 j 个神经元与

输出层第 k 个神经元间的连接权值; b 为隐含层神经元阈值。

设该网络具有 Q 个样本的训练集输入矩阵 X 和输出矩阵 Y 分别为:

$$X = \begin{bmatrix} x_{11} & \cdots & x_{1Q} \\ x_{21} & \cdots & x_{2Q} \\ \vdots & & \vdots \\ x_{n1} & \cdots & x_{nQ} \end{bmatrix}_{n \times Q}$$

$$Y = \begin{bmatrix} y_{11} & \cdots & y_{1Q} \\ y_{21} & \cdots & y_{2Q} \\ \vdots & & \vdots \\ y_{m1} & \cdots & y_{mQ} \end{bmatrix}_{m \times Q}$$
(2)

给定隐含层神经元激励函数 $g(x)$,则网络输出 T 为:

$$T = [t_1, t_1, \cdots, t_Q]_{m \times Q}$$

$$t_i = \begin{bmatrix} t_{1j} \\ t_{2j} \\ \vdots \\ t_{mj} \end{bmatrix}_{m \times 1} = \begin{bmatrix} \sum_{i=1}^l \beta_{i1} g(\omega_i x_j + b_i) \\ \sum_{i=1}^l \beta_{i2} g(\omega_i x_j + b_i) \\ \vdots \\ \sum_{i=1}^l \beta_{im} g(\omega_i x_j + b_i) \end{bmatrix}_{m \times 1}$$
(3)

式中: $j=1,2,\cdots,Q$; $\omega_i = [\omega_{i1}, \omega_{i2}, \cdots, \omega_{in}]$, $x_j = [x_{1j}, x_{2j}, \cdots, x_{nj}]^T$ 。

式(3)可表示为

$$H\beta = T^T \quad (4)$$

其中, T^T 为矩阵 T 的转置; H 称为神经网络的隐含层输出矩阵,具体形式为式(5)所示:

$$H(\omega_1, \omega_2, \cdots, \omega_l, b_1, b_2, \cdots, b_l, x_1, x_2, \cdots, x_Q) = \begin{bmatrix} g(\omega_1 x_1 + b_1) & g(\omega_2 x_1 + b_2) & g(\omega_l x_1 + b_l) \\ g(\omega_1 x_2 + b_1) & g(\omega_2 x_2 + b_2) & g(\omega_l x_2 + b_l) \\ \vdots & \vdots & \vdots \\ g(\omega_1 x_Q + b_1) & g(\omega_2 x_Q + b_2) & g(\omega_l x_Q + b_l) \end{bmatrix}_{Q \times l}$$
(5)

Huang 等在前人研究的基础上,提出并证明了以下两个定理^[12-18],为 ELM 的应用提供了理论基础。

定理 1 给定任意 Q 个不同样本 (x_i, t_i) ,其中 $x_i = [x_{i1}, x_{i2}, \cdots, x_{in}]^T \in R^n$, $t_i = [t_{i1}, t_{i2}, \cdots, t_{im}] \in R^m$,一个任意区间无限可微的激活函数 $g: R \rightarrow R$,则对于具有 Q 个隐含层神经元的 SLFN,在任意赋值 $\omega_i \in R^n$ 和 $b_i \in R^n$ 的情况下,其隐含层输出矩阵 H 可逆且 $\|H\beta - T^T\| = 0$ 。

定理 2 给定任意 Q 个不同样本 (x_i, t_i) ,其中 $x_i = [x_{i1}, x_{i2}, \cdots, x_{in}]^T \in R^n$, $t_i = [t_{i1}, t_{i2}, \cdots, t_{im}] \in R^m$,

给定任意小误差 $\varepsilon(\varepsilon>0)$ 和一个任意区间无限可微的激活函数 $g:R\rightarrow R$, 则总存在一个含有 $K(K\leq Q)$ 个隐含层神经元的 SLFN, 在任意赋值 $\omega_i \in R^n$ 和 $b_i \in R^n$ 的情况下, 有 $\|H_{N\times M}\beta_{M\times m}-T'\| \leq \varepsilon$ 。

由定理 1 可知, 若隐含层神经元个数与训练集样本个数相等, 则对于任意 ω 和 b , 都可以以零误差逼近训练样本, 即

$$\sum_{j=1}^Q \|t_i - y_i\| = 0 \tag{6}$$

其中, $y_i=[y_{1j}, y_{2j}, \cdots, y_{mj}]^T, j=1, 2, \cdots, Q$ 。

在实际应用中, 当训练样本数 Q 较大时, 为减少计算量和保证网络的泛化能力, 通常隐含神经元数 K 的取值要比 Q 小。

由此可知, 当激活函数 $g(x)$ 无限可微时, ELM 的参数网络参数无需全部调整, ω 和 b 在训练前可以随机选择, 且在训练过程中保持不变。而隐含层与输出层间的连接权值 β 可以通过求解以下方程组的最小二乘解获得:

$$\min_{\beta} \|H\beta - T'\| \tag{7}$$

其解为

$$\hat{\beta} = H^+ T' \tag{8}$$

式中: H^+ 为隐含层输出矩阵 H 的 Moore-Penrose 广义逆。

ELM 学习算法主要有以下几个步骤^[19]: ①确定隐含层神经元个数, 随机设定输入层与隐含层间的连接权值 ω 和隐含层神经元的偏置 b ; ②选择一个无限可微的函数作为隐含层神经元的激活函数, 进而计算隐含层输出矩阵 H ; ③计算输出层权值 $\hat{\beta}$ 。

2 实例分析

2.1 基本资料与相关分析

以云南省某水库 TP、TN 质量浓度预测为例进行实例分析。依据 GB 3838—2002《地表水环境质量标准》, 选取水位、库容等 14 项可能对 TP、TN 质量浓度产生影响的评价因子, 采用 SPSS 软件计算统计数据的相关系数, 分析 TP、TN 浓度与环境因子的相关性, 分析结果见表 1。

从表 1 可以看出, $\rho(\text{TP})$ 与水温、 $\rho(\text{NH}_3\text{-N})$ 、 $\rho(\text{COD}_{\text{Mn}})$ 和水体透明度显著相关, 其中与水温、 $\rho(\text{NH}_3\text{-N})$ 、 $\rho(\text{COD}_{\text{Mn}})$ 呈显著正相关, 与水体透明度呈显著负相关; 与水位等无显著相关。 $\rho(\text{TN})$ 与库

容、 $\rho(\text{NH}_3\text{-N})$ 、 $\rho(\text{NO}_2\text{-N})$ 、 $\rho(\text{NO}_3\text{-N})$ 、 $\rho(\text{COD}_{\text{Mn}})$ 和水体透明度显著相关, 其中与库容、 $\rho(\text{NH}_3\text{-N})$ 、 $\rho(\text{NO}_2\text{-N})$ 、 $\rho(\text{NO}_3\text{-N})$ 、 $\rho(\text{COD}_{\text{Mn}})$ 呈显著正相关, 与透明度呈显著负相关; 与水位等无显著相关。

本文选用 2007—2011 年某水库相关数据建模, 选取 $\rho(\text{NH}_3\text{-N})$ 、 $\rho(\text{NO}_2\text{-N})$ 、 $\rho(\text{NO}_3\text{-N})$ 、 $\rho(\text{COD}_{\text{Mn}})$ 和水体透明度作为网络输入, $\rho(\text{TP})$ 、 $\rho(\text{TN})$ 作为输出。按月统计, 共获得 60 组数据, 并以 2007—2010 年 48 组数据作为网络训练样本, 以 2011 年 12 组数据作为网络预测样本。

2.2 TP、TN 预测的实现

2.2.1 数据处理

由于水质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, 在网络训练前要先对于原始数据进行归一化处理。表 1 中, $\rho(\text{NH}_3\text{-N})$ 、 $\rho(\text{NO}_2\text{-N})$ 、 $\rho(\text{NO}_3\text{-N})$ 、 $\rho(\text{COD}_{\text{Mn}})$ 与 $\rho(\text{TP})$ 、 $\rho(\text{TN})$ 呈显著正相关, 采用最大最小法进行数据归一化处理, 公式如下:

$$\hat{x} = (x - x_{\min}) / (x_{\max} - x_{\min}) \tag{9}$$

水体透明度与 $\rho(\text{TP})$ 、 $\rho(\text{TN})$ 呈显著负相关, 采用如下公式进行数据归一化处理:

$$\hat{x}' = 1 - (x - x_{\min}) / (x_{\max} - x_{\min}) \tag{10}$$

式中: $\hat{x}$ 为经过标准化处理的数据, x 为原始数据, $x_{\max}$ 和 $x_{\min}$ 分别为数据序列中的最大数和最小数。经过标准化处理后, 数据处于 0 ~ 1 范围之内, 有利于网络训练。

2.2.2 性能评价

选用决定系数 R^2 和平均相对误差绝对值 MPE 两个评价指标对 ELM 以及传统 BP、GA-BP、RBF 神经网络模型进行评价, 并选用最大相对误差作为参考指标。决定系数 R^2 范围在 [0, 1] 内, 愈接近 1, 表明模型性能越好; 平均相对误差绝对值 MPE 与最大相对误差越小, 表明模型的性能越好。

评价指标计算公式如下:

$$R^2 = \frac{\left(n \sum_{i=1}^n \hat{y}_i y_i - \sum_{i=1}^n \hat{y}_i \sum_{i=1}^n y_i\right)^2}{\left(n \sum_{i=1}^n \hat{y}_i^2 - \left(\sum_{i=1}^n \hat{y}_i\right)^2\right) \left(n \sum_{i=1}^n y_i^2 - \left(\sum_{i=1}^n y_i\right)^2\right)} \tag{11}$$

$$MPE = \frac{1}{n} \sum_{i=1}^n \frac{|\hat{y}_i - y_i|}{y_i} \times 100\% \tag{12}$$

$i = 1, 2, \cdots, n$

表 1 $\rho(\text{TP})$ 、 $\rho(\text{TN})$ 与环境因子的相关系数

项目	水位	库容	气温	水温	气压	pH	$\rho(\text{DO})$	$\rho(\text{NH}_3\text{-N})$	$\rho(\text{NO}_2\text{-N})$	$\rho(\text{NO}_3\text{-N})$	$\rho(\text{COD}_{\text{Mn}})$	$\rho(\text{F}^-)$	透明度
$\rho(\text{TP})$	0.005	-0.224	0.242	0.320 *	-0.009	0.084	0.101	0.338 **	0.212	0.225	0.403 **	0.057	-0.617 **
$\rho(\text{TN})$	0.102	0.293 *	0.139	0.165	-0.171	-0.184	-0.125	0.630 **	0.699 **	0.937 **	0.345 **	0.015	-0.532 **

注: “*”表示在 0.05 水平(双侧)上显著相关; “**”表示在 0.01 水平(双侧)上显著相关。

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。

2.2.3 网络训练

笔者基于 MATLAB 环境,创建及训练 ELM 以及传统 BP、GA-BP 和 RBF 神经网络模型对湖库 TP、TN 进行预测。以 $\text{NH}_3\text{-N}$ 、 $\text{NO}_2\text{-N}$ 、 $\text{NO}_3\text{-N}$ 、 COD_{Mn} 质量浓度和 水体透明度作为网络输入向量,即输入层神经元数为 5 个;以 TP、TN 质量浓度作为输出向量,即输出层的神经元数为 2 个,构建 5 输入 2 输出的预测模型。

由于 ELM 只需在确定激励函数的情况下选择隐含层节点数,参数确定过程较为简单。选取 sigmoidal 为激励函数,采用循环算法确定当 ELM 隐含层神经元个数为 21 时, R^2_{TP} 、 R^2_{TN} 同时达到最大值,此时网络有着较好的预测精度和泛化能力。隐含层神经元个数对 ELM 性能影响见表 2 和图 1。




图 1 隐含层神经元个数对 ELM 性能的影响

从表 2 和图 1 可以看出,对于 TP,随着隐含层神经元个数的增加,其 R^2_{TP} 先增后减的趋势明显,隐含层神经元个数在 20 ~ 27 区间中 R^2_{TP} 变化不大;对于 TN,隐含层神经元个数在 7 ~ 30 区间中时,其 R^2_{TN} 趋势平缓,ELM 性能较好,当隐含层神经元个数小于 7 或大于 30 时, R^2_{TN} 呈减小趋势;对于 $R^2_{\text{TP}}+R^2_{\text{TN}}$,当隐含层神经元个数在 20 ~ 27 区间时达到最大。因此,综合考虑 R^2_{TP} 、 R^2_{TN} 以及 $R^2_{\text{TP}}+R^2_{\text{TN}}$,当 ELM 隐含层神经元个数为 21 时,三者同时达到最优。

传统 BP 神经网络模型采用目前较为普遍的

Kolmogorov 定理^[9-11]确定隐含层神经元数,利用逐步增长或逐步修剪法确定最终神经元数为 7,预测模型结构为 5-7-2,隐含层和输出层传递函数分别采用 logsig 和 purelin,训练函数采用 traindxd,期望误差为 0.002 2,最大训练轮回为 8 000 次时网络达到了较好的预测精度。GA-BP 网络模型结构为 5-20-2,隐含层和输出层传递函数分别采用 tansig 和 purelin,训练函数采用 trainlm,期望误差为 0.001 5,最大训练轮回为 1 000 次,种群规模为 50,进化次数为 200 次,交叉概率为 0.4,变异概率为 0.09 时网络达到了较好的预测精度。RBF 神经网络人为调节的参数少,只有 1 个阈值,程序采取循环训练算法,最终确定 RBF 神经网络的 SPREAD 和期望误差分别为 1 和 0.0018 时,网络达到较佳预测效果。

2.3 TP、TN 预测结果及分析

利用上述训练好的 ELM、传统 BP、GA-BP 和 RBF 神经网络预测模型对某水库 TP、TN 质量浓度进行预测。预测结果见表 3、表 4。

分析表 3、表 4 可以得出以下结论:①从决定系数 R^2 上看,对于 TP 质量浓度的模型预测精度(由高到低,下同)依次是:ELM、GA-BP、RBF 和传统 BP,其数值分别为 0.913 1、0.911 9、0.903 7、0.889 8;对于 TN 质量浓度的预测精度依次是:GA-BP、ELM、RBF 和传统 BP,其数值分别为 0.939 7、0.939 5、0.934 9、0.902 0,从平均相对误差 MPE 上看,对于 TP 质量浓度的预测精度依次是:ELM、RBF、传统 BP 和 GA-BP,分别为 19.608 6%、21.025 9%、22.090 1%、22.859 8%;对于 TN 质量浓度,预测精度依次是:ELM、GA-BP、RBF 和传统 BP,其数值分别为 13.458 5%、14.910 0%、15.505 0%、17.818 8%。从最大相对误差上看,对于 TP 质量浓度的预测精度依次是:GA-BP、传统 BP、ELM 和 RBF;对于 TN 质量浓度的预测精度依次是:ELM、RBF、GA-BP 和传统 BP。综合比较而言,ELM 模型预测精度高于传统 BP 和

表 2 隐含层神经元个数对 ELM 性能的影响

隐含层神经元个数	R^2_{TN}	R^2_{TP}	$R^2_{\text{TN}}+R^2_{\text{TP}}$	隐含层神经元个数	R^2_{TN}	R^2_{TP}	$R^2_{\text{TN}}+R^2_{\text{TP}}$	隐含层神经元个数	R^2_{TN}	R^2_{TP}	$R^2_{\text{TN}}+R^2_{\text{TP}}$
5	0.771 0	0.387 8	1.158 8	17	0.928 7	0.803 5	1.732 2	29	0.896 3	0.820 7	1.717 0
6	0.882 9	0.477 9	1.360 8	18	0.930 3	0.820 9	1.751 2	30	0.937 2	0.765 2	1.702 4
7	0.918 6	0.499 1	1.417 7	19	0.933 0	0.766 5	1.699 5	31	0.854 8	0.777 8	1.632 6
8	0.919 8	0.485 3	1.405 1	20	0.940 9	0.868 7	1.809 6	32	0.851 3	0.906 7	1.758 0
9	0.919 8	0.651 2	1.571 0	21	0.939 5	0.913 1	1.852 6	33	0.892 3	0.797 5	1.689 8
10	0.918 9	0.647 3	1.566 2	22	0.929 4	0.906 6	1.836 0	34	0.829 5	0.609 5	1.439 0
11	0.919 9	0.687 7	1.607 6	23	0.938 3	0.826 8	1.765 1	35	0.794 8	0.688 2	1.483 0
12	0.926 9	0.759 1	1.686 0	24	0.931 4	0.875 7	1.807 1	36	0.935 6	0.742 0	1.677 6
13	0.922 4	0.673 1	1.595 5	25	0.927 5	0.859 1	1.786 6	37	0.650 1	0.837 6	1.487 7
14	0.927 9	0.770 0	1.697 9	26	0.949 8	0.872 7	1.822 5	38	0.878 8	0.468 0	1.346 8
15	0.935 3	0.802 2	1.737 5	27	0.939 2	0.897 1	1.836 3	39	0.763 5	0.824 0	1.587 5
16	0.930 0	0.782 3	1.712 3	28	0.941 6	0.692 2	1.633 8	40	0.715 2	0.818 8	1.534 0

表 3 某水库 TP 质量浓度预测结果及其模型比较

实测值 $\rho(\text{TP})/$ ($\text{mg} \cdot \text{L}^{-1}$)	ELM 网络模型		传统 BP 网络模型		GA-BP 网络模型		RBF 网络模型	
	拟合值 $\rho(\text{TP})/$ ($\text{mg} \cdot \text{L}^{-1}$)	相对误差/%	拟合值 $\rho(\text{TP})/$ ($\text{mg} \cdot \text{L}^{-1}$)	相对误差/%	拟合值 $\rho(\text{TP})/$ ($\text{mg} \cdot \text{L}^{-1}$)	相对误差/%	拟合值 $\rho(\text{TP})/$ ($\text{mg} \cdot \text{L}^{-1}$)	相对误差/%
0.031	0.0147	52.5806	0.0228	26.4516	0.0249	19.5301	0.0145	53.2258
0.011	0.0119	8.1818	0.0123	11.8182	0.0305	1.4999	0.0107	2.7273
0.011	0.0157	42.7273	0.0123	11.8182	0.0212	31.5623	0.0173	57.2727
0.020	0.0203	1.5000	0.0151	24.5000	0.0303	2.2931	0.0199	0.5000
0.012	0.0083	30.8333	0.0058	51.6667	0.0309	0.4002	0.0087	27.5000
0.011	0.0136	23.6364	0.0067	39.0909	0.0176	43.2384	0.0118	7.2727
0.032	0.0327	2.1875	0.0337	5.3125	0.0179	42.4184	0.0261	18.4375
0.005	0.0050	0.9279	0.0039	22.0000	0.0220	29.1606	0.0055	10.0000
0.025	0.0269	7.6000	0.0305	22.0000	0.0225	27.5513	0.0265	6.0000
0.032	0.0233	27.1875	0.0217	32.1875	0.0159	48.7824	0.0210	34.3750
0.017	0.0222	30.5882	0.0173	1.7647	0.0295	4.9615	0.0206	21.1765
0.034	0.0315	7.3529	0.0284	16.4706	0.0239	22.9199	0.0293	13.8235

表 4 某水库 TN 质量浓度预测结果及其模型比较

实测值 $\rho(\text{TN})/$ ($\text{mg} \cdot \text{L}^{-1}$)	ELM 网络模型		传统 BP 网络模型		GA-BP 网络模型		RBF 网络模型	
	拟合值 $\rho(\text{TN})/$ ($\text{mg} \cdot \text{L}^{-1}$)	相对误差/%	拟合值 $\rho(\text{TN})/$ ($\text{mg} \cdot \text{L}^{-1}$)	相对误差/%	拟合值 $\rho(\text{TN})/$ ($\text{mg} \cdot \text{L}^{-1}$)	相对误差/%	拟合值 $\rho(\text{TN})/$ ($\text{mg} \cdot \text{L}^{-1}$)	相对误差/%
2.34	1.5627	33.2179	1.3526	42.1966	1.5378	34.2810	1.5480	33.8462
1.30	1.1616	10.6462	1.0134	22.0462	1.1818	9.0887	1.1161	14.1462
1.16	1.0658	8.1207	0.9853	15.0603	1.0400	10.3444	1.0822	6.7069
1.14	1.2381	8.6053	1.0847	4.8509	1.2066	5.8385	1.2263	7.5702
1.24	0.9320	24.8387	0.8959	27.7500	0.9364	24.4866	0.8945	27.8629
0.817	0.8205	0.4284	0.6486	20.6120	0.6460	20.9351	0.6652	18.5802
1.15	0.9963	13.3652	1.2654	10.0348	1.0290	10.5184	1.1341	1.3826
1.16	1.1708	0.9310	0.9685	16.5086	1.0321	11.0255	0.8927	23.0431
0.777	0.7876	1.3642	0.6816	12.2780	0.7258	6.5905	0.8168	5.1223
0.995	0.7175	27.8894	0.7711	22.5025	0.6657	33.0947	0.7592	23.6985
0.701	0.7922	13.0100	0.7830	11.6976	0.7471	6.5781	0.7989	13.9658
0.590	0.7026	19.0847	0.6389	8.2881	0.6262	6.1389	0.6498	10.1356

RBF 网络模型,甚至略高于 GA-BP 模型的预测精度。②从模型结构、参数选择及训练时间上比较,ELM 模型具有较大的优势,其参数选择简便,训练速度快(运行时间与 RBF 相当),不会陷入局部最优值等优点,较传统 BP 神经网络的性能有着较大的提高。③从某湖库 TP、TN 质量浓度预测结果上看,ELM 模型预测精度高,泛化能力好,表明研究建立的 ELM 湖库 TP、TN 质量浓度预测模型是合理可行和有效的,可为湖库 TP、TN 质量浓度预测预报提供新的途径和方法。④由于 TP 与 $\text{NO}_2\text{-N}$ 和 $\text{NO}_3\text{-N}$ 质量浓度相关性并不显著,这在一定程度上影响了 TP 质量浓度的预测精度,从表 3 与表 4 可以看出,无论从决定系数 R^2 还是从平均相对误差 MPE 上看,TP 的质量浓度预测效果均不如 TN 的。

3 结 语

相比传统的 SLFN 学习算法,ELM 在训练过程中具有调节参数少、学习速度快、泛化能力强、预测精度高,且不存在局部极小值等优点。本文构建了

基于 ELM、传统 BP、GA-BP、RBF 人工神经网络模型的湖库 TP、TN 质量浓度预测模型,并对各预测模型进行比较分析,结果表明,ELM 网络模型在多输入、多输出的水质预测中获得了令人满意的预测效果,其预测精度直逼 GA-BP 模型,可以预见,ELM 神经网络模型将愈来愈广泛地应用于各行业、各领域中。

参考文献:

[1] 舒金华.我国主要湖泊富营养化程度的评价[J]. 海洋与湖沼,1993,24(6):616-620. (SHU Jinhua. Assessment of eutrophication in main lakes of China[J]. Oceanologia Et Limnologia Sinica,1993,24(6):616-620. (in Chinese))

[2] 金菊良,王文圣,洪天求,等.流域水安全智能评价方法的理论基础探讨[J]. 水利学报,2006,37(8):918-925. (JIN Juliang, WANG Wensheng, HONG Tianqiu, et al. Theoretical basis of intelligent evaluation methods of watershed water security [J]. Journal of Hydraulic Engineering,2006,37(8):918-925. (in Chinese))

[3] 邓大鹏,刘刚,李学德,等.基于神经网络简单集成的湖

- 库富营养化综合评价模型[J]. 生态学报, 2007, 27(2): 725-731. (DENG Dapeng, LIU Gang, LI Xuede, et al. A model based on simple ensemble of neural networks for comprehensive eutrophication assessment of lake and reservoir[J]. The Journal of Ecology, 2007, 27(2): 725-731. (in Chinese))
- [4] 陈安, 罗亚田. 人工神经网络方法在环境科学领域应用进展[J]. 重庆环境科学, 2003, 25(9): 65-70. (CHEN An, LUO Yatian. Artificial neural network method in environmental science field application progress [J]. Chongqing Environmental Science, 2003, 25(9): 65-70. (in Chinese))
- [5] 任黎, 董增川, 李少华. 人工神经网络模型在太湖富营养化评价中的应用[J]. 河海大学学报: 自然科学版, 2004, 32(2): 147-150. (REN Li, DONG Zengchuan, LI Shaohua. Application of artificial neural network model to assessment of Taihu Lake eutrophication [J]. Journal of Hohai University: Natural Science, 2004, 32(2): 147-150. (in Chinese))
- [6] 韩涛, 李怀恩, 彭文启. 基于 MATLAB 的神经网络在湖泊富营养化评价中的应用[J]. 水资源保护, 2005, 21(1): 24-26. (HAN Tao, LI Huaen, PENG Wenqi. Application of neural network based on MATLAB toolbox to the evaluation of lake eutrophication [J]. Water Resources Protection, 2005, 21(1): 24-26. (in Chinese))
- [7] 吴利斌, 尚士友, 岳海军, 等. 利用模糊神经网络对湖泊富营养化程度进行评价的研究[J]. 内蒙古农业大学学报, 2004, 25(4): 67-70. (WU Libin, SHANG Shiyu, YUE Haijun, et al. Study on evaluation of eutrophication of lakes based on fuzzy neural network [J]. Journal of Inner Mongolia Agricultural University, 2004, 25(4): 67-70. (in Chinese))
- [8] 曾光明, 卢宏伟, 金相灿, 等. 洞庭湖水体水质状况及运用小波神经网络对营养状态的评价[J]. 湖南大学学报: 自然科学版, 2005, 32(1): 91-94. (ZENG Guangming, LU Hongwei, JIN Xiangcan, et al. Assessment of the water quality and nutrition of the dongting lake with wavelet neural network [J]. Journal of Hunan University: Natural Science, 2005, 32(1): 91-94 (in Chinese))
- [9] 楼文高. 湖库富营养化人工神经网络评价模型[J]. 水产学报, 2001, 25(5): 474-478. (LOU Wengao. Eutrophication assessment model using artificial neural networks for lakes and reservoirs [J]. Journal of Fisheries of China, 2001, 25(5): 474-478. (in Chinese))
- [10] VLADIMIR N. V. 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] 李正最, 谢悦波. 洞庭湖富营养化支持向量机评价模型研究[J]. 人民长江, 2010, 41(10): 75-78. (LI Zhengzui, XIE Yuebo. Study on eutrophication evaluation model of Dongting Lake based on SVM [J]. Yangtze River, 2010, 41(10): 75-78. (in Chinese))
- [12] 王贵作, 任立良, 王斌, 等. 基于投影寻踪的湖泊富营养化程度评价模型[J]. 水资源保护, 2009, 25(5): 14-18. (WANG Guizuo, REN Liliang, WANG Bin, et al. Lake eutrophication evaluation model based on projection pursuit method [J]. Water Resources Protection, 2009, 25(5): 14-18. (in Chinese))
- [13] 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, 25(5): 12-18. (CUI Dongwen. Applications of several neural network models to eutrophication evaluation of lakes and reservoirs [J]. Water Resources Protection, 2012, 25(5): 12-18. (in Chinese))
- [14] 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.
- [15] 施彦, 韩力群, 廉小亲. 神经网络设计方法与实例分析[M]. 北京: 北京邮电大学出版社, 2009.
- [16] MATLAB 中文论坛. 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.
- [17] 史峰, 王辉, 郁磊, 等. MATLAB 智能算法 30 个案例分析[M]. 北京: 北京航空航天大学出版社, 2011.
- [18] SL395—2007 地表水资源质量评价技术规程[S].
- [19] 雷德明, 严新平. 多目标智能优化算法及其应用[M]. 北京: 科学出版社, 2009.

(收稿日期: 2012-04-01 编辑: 高渭文)

(上接第 60 页)

- [4] 梁捷, 曾光明, 郭生练, 等. 渗透系数的非均质性对地下水溶质运移的影响[J]. 水利学报, 2008, 39(8): 900-906. (LIANG Jie, ZENG Guangming, GUO Shenglian, et al. Effect of hydraulic conductivity heterogeneity on solute transport in groundwater [J]. Journal of Hydraulic Engineering, 2008, 39(8): 900-906. (in Chinese))
- [5] 季叶飞, 束龙仓, 王振龙. 地下水可开采系数计算结果的可靠性与敏感性[J]. 河海大学学报: 自然科学版, 2010, 38(6): 687-692. (JI Yefei, SHU Longcang, WANG Zhenlong. Reliability and sensitivity analysis of calculated results of allowable withdrawal coefficient of groundwater [J]. Journal of Hohai University: Natural Sciences, 2010, 38(6): 687-692. (in Chinese))
- [6] 《水文地质手册》编写组. 水文地质手册[M]. 北京: 地质出版社, 1983.
- [7] 水利部水资源司. 21 世纪初期中国地下水资源开发利用[M]. 北京: 中国水利水电出版社, 2004.
- [8] 广东省地质局. 区域水文地质普查报告[R]. 广州: 广东省地质局, 1981.

(收稿日期: 2012-08-03 编辑: 徐娟)