

基于 GA - BP 与多隐层 BP 网络模型的水质预测及比较分析

王泽平

(云南省水文水资源局丽江分局, 云南 丽江 674100)

摘要: 采用循环算法确定最佳 BP 神经网络结构, 建立 BP 神经网络水质模型进行预测。鉴于 BP 神经网络学习收敛速度慢、易陷入局部极值等缺点, 在相同网络结构及期望误差等条件下, 运用 GA 优化 BP 神经网络初始权值和阈值, 构建 GA - BP 以及多隐层 BP 神经网络水质预测模型, 以云南省某水库总氮预测为例进行预测与比较分析。结果表明: ①GA - BP 网络水质模型预测精度高于基本 BP 网络, 表明遗传算法能有效优化 BP 网络初始权值和阈值。②增加 BP 神经网络隐层数能进一步提高网络预测精度, 但训练时间也随着延长。③GA - BP 及多隐层 BP 可作为提高网络预测精度的有效方法, 二者均可用于水质预测预报, 可为水质预测预报提供新的途径和方法。相对而言, GA - BP 模型收敛速度快、预测精度高, 具有一定的计算优势。

关键词: 神经网络; 遗传算法; 多隐层; 水质预测

中图分类号: TP183; X832

文献标识码: A

文章编号: 1672-643X(2013)03-0154-07

Prediction and comparative analysis of water quality based on GA - BP and multi - hidden - layer BP network model

WANG Zeping

(Lijiang Branch Bureau, Yunnan Province Hydrology Water Resources Bureau, Lijiang 674100, China)

Abstract: Taking round - robin algorithm to determine the optimal BP neural network structure, the paper established BP neural network model to predict water quality. In view of the shortcomings such as lower learning convergence speed of BP neural network, easy to fall into local extremum, in the same conditions of network structure and expectation error, the paper used GA to optimize the initial weights and threshold of BP neural network, and build GA - BP and multi - hidden layer BP neural network prediction model for water quality. The paper took total nitrogen of a reservoir in Yunnan Province for example to predict, compare and analyze. The results showed that ①prediction accuracy of GA - BP network model is better than that of water quality model of basic BP network, indicating that the genetic algorithm can effectively optimize the BP network initial weights and thresholds. ②The increase of hidden layers BP neural network can further improve the network prediction accuracy, but further extend the training time. ③GA - BP and a number of hidden - layer BP network can improve the prediction accuracy as an effective way, both can be used to forecast water quality, and provide new ways and methods for water quality forecast. In contrast, the faster convergence speed and higher prediction accuracy of GA - BP model have a certain computational advantages.

Key words: neural networks; genetic algorithm; more hidden layer; prediction of water quality

0 引言

水质预测是水环境质量影响评价、污染物排放总量控制指标制订以及水污染控制系统规划与管理的手段和依据, 在水资源管理和保护中有着举足轻重的地位和意义^[1]。人工神经网络(artificial neural

network) 是一种模拟人脑神经网络原理、自适应地响应环境信息、并自治演化出运算能力的非程序化计算模式^[2]。目前, 人工神经网络广泛应用于水质预测研究领域, 如水体矿化度的预测^[3]、河湖水质预测^[4-6]、河流 BOD - DO 模拟预测^[7]、湖库叶绿素预测^[8]、水质指标预测^[9]等, 均取得了很好的效果。

收稿日期: 2012-12-21; 修回日期: 2013-01-14

作者简介: 王泽平(1976-), 男, 云南丽江人, 工程师, 主要从事水环境监测、评价及水资源保护等工作。

BP 神经网络是人工神经网络中应用最广泛的算法,但由于 BP 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,为克服 BP 算法中的不足,提出基于附加动量、自适应调整参数、弹性方法、拟牛顿法、共轭梯度法以及 Levenberg - Marquardt 等的改进算法^[10-11],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 BP 算法固有的缺陷,目前普遍采用遗传算法对 BP 网络结构和网络权值、阈值进行优化^[10]。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,将遗传算法与 BP 网络相结合,训练时应用遗传算法对神经网络的权值、阈值进行寻优,缩小搜索范围后利用 BP 网络进行精确求解,可以使网络达到全局寻优和快速高效的目的,避免局部极值等问题^[12]。GA - BP 算法不仅具有全局搜索能力,而且具有自动获取和积累搜索空间知识及自适应地控制搜索过程的能力,从而使网络性能得到极大改善^[13]。

鉴于 BP 神经网络在实际应用中的缺点及不足,本文基于 GA 与 BP 神经网络基本原理,结合二者优点,以云南省某水库为例,采用 SPSS 软件分析总氮与环境因子的相关性,选取 $\text{NH}_4^+ - \text{N}$ 、 $\text{NO}_2^- - \text{N}$ 、 $\text{NO}_3^- - \text{N}$ 和透明度作为网络输入,总氮作为输出,采用循环算法确定最佳 BP 神经网络结构进行水质预测,并在相同网络结构、传递函数、训练函数及期望误差等条件下,运用 GA 优化 BP 神经网络初始权值和阈值,构建 GA - BP 神经网络水质预测模型,并构建多隐层 BP 神经网络水质预测模型作为对比分析模型,旨在分析比较基本 BP、GA - BP 以及多隐层 BP 神经网络水质预测模型的精确度以及模型的有效性与可行性,为水质预测预报探索新的方法和途径。

1 GA - BP 与多隐层 BP 网络模型

1.1 GA - BP 神经网络模型

1.1.1 BP 网络和遗传算法 BP 网络(Back - Propagation Network)是一种单向传播的多层前馈神经网络,其主要特点是信号前向传播,误差反向传播。在前向传播中,输入信号从输入层经隐层逐层处理,直至输出层。每一层的神经元状态只影响下一层神经元状态,如果输出层得不到期望输出,则转入反向传播,根据预测误差调整网络权值和阈值,从而使 BP 神经网络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 BP 网络主要应用于函数逼近、模式识别、分类和数据压缩等领域^[10-12]。

遗传算法是由美国 Michigan 大学的 JohnHolland 教授在 20 世纪 60 年代提出,它是模拟生物在自然环境中的遗传和进化过程而形成的一种自适应全局优化概率搜索算法。遗传算法是将问题的求解表示成“染色体”,将其置于问题的“环境”中,根据适者生存的原则,从中选择出适应环境的“染色体”进行复制,即再生(reproduction, selection),通过交叉(crossover)、变异(mutation)两种基因操作产生出新一代更适合环境的“染色体”群,这样一代代不断改进,最后收敛到一个最适合环境的个体上(当然也有其它的收敛准则),求得问题的最佳解。由于最好的染色体不一定出现在最后一代,开始时保留最好的染色体,如果在新的种群又发现更好的染色体,则用它代替原来的染色体,进化完成后,这个染色体可看作是最优化的结果。遗传算法可归纳为遗传运算(交叉与变异)和进化运算(选择)两种运算过程^[13]。

GA 与 BP 神经网络均具有极强的解决问题的能力,二者相结合,形成 GA - BP 算法,该算法将遗传算法的全局寻优能力与 BP 算法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^[14]。

1.1.2 GA - BP 模型的建立与算法实现 由于 BP 网络隐层层数、隐层节点数的确定,目前尚无统一的确定方法,普遍采用试算法确定。因此,本文主要采用遗传算法优化 BP 网络的初始权值和阈值。遗传算法优化 BP 神经网络算法流程^[15]如图 1 所示。

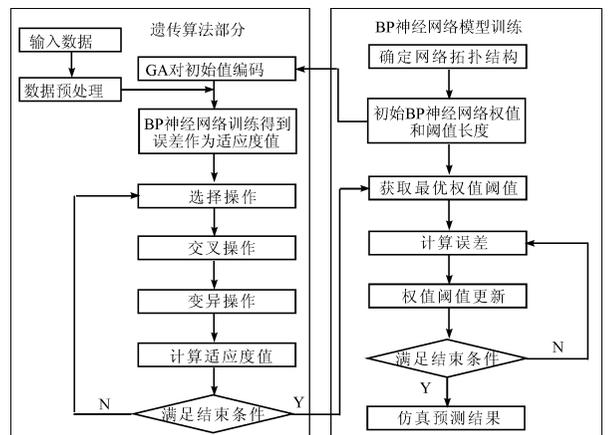


图 1 GA 优化 BP 神经网络算法流程

遗传算法优化 BP 神经网络分为 BP 神经网络结构的确定、遗传算法优化和 BP 神经网络预测 3

个部分。其中, BP神经网络结构确定部分根据模型输入输出参数个数确定 BP神经网络结构, 进而确定遗传算法个体长度; 遗传算法优化 BP神经网络的权值和阈值, 种群中的每个个体都包含了一个网络所有权值和阈值, 个体通过适应度函数计算个体适应度值, 遗传算法通过选择、交叉和变异操作找到最优适应度值对应个体。BP神经网络预测遗传算法得到的最优个体对网络初始权值和阈值进行赋值, 网络经训练后输出预测结果。遗传算法优化 BP神经网络权值的算法步骤如下^[10-11, 15]:

(1) 初始化种群 P , 包括交叉规模、交叉概率 P_c 、突变概率 P_m 以及对任一 w_{ih} 和 w_{ho} 初始化; 采用实数进行编码, 初始种群 n (视实际应用选择数值大小)。

(2) 计算每一个个体评价函数, 并将其排序, 按下式概率值选择网络个体:

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

式中: f_i 为个体 i 的适配值, 用误差平方和 E 来衡量, 即

$$f_i = 1/E(i) \quad (2)$$

$$E(i) = \sum_k \sum_o (d_o - \gamma O_o)^2 \quad (3)$$

式中: i 为染色体数, $i = 1, 2, \dots, n$; o 为输出结点数, $o = 1, 2, \dots, q$; k 为学习样本数, $k = 1, 2, \dots, m$; γO 为网络实际输出; d 为期望输出。

(3) 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。

(4) 利用变异概率 P_m 突变产生 G_j 的新个体 G'_j 。

(5) 将新个体插入到种群 P 中, 并计算新个体的评价函数。

(6) 判断算法是否结束。如果找到满意个体, 则结束; 否则转到③进入下一轮运算。

(7) 算法结束, 达到预先设定的性能指标后, 将最终群体中的最优个体解码即可得到优化后的网络连接权值系数。

(8) 将优化得到的网络连接权值系数赋值给 BP网络进行训练及预测输出。

本文基本 BP神经网络结构采用试算法进行确定, 在确定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, 运用遗传算法来优化 BP神经网络的初始权值和阈值。

1.2 多隐层 BP神经网络模型

由非线性变换单元组成的 BP神经网络, 不仅结构简单, 而且具有良好的非线性映射能力, 广泛应用于水文预测预报等领域。根据隐含层数的多少, BP网络可以划分为单隐层和多隐层网络, 隐层数的选择在神经网络的应用中是一个复杂的问题, 适合的隐层数目及节点数决定于训练样本的多少、样本噪音的大小以及所面对问题的复杂程度等多种因素^[16]。理论上, 一个三层的 BP网络已能映射或逼近任何有理函数, 故常采用含有一个隐层的 BP网络^[10, 17]。研究表明, 同单隐层相比, 多隐层 BP网络泛化能力强, 预测精度高。其隐层层数的选择需从网络精度和训练时间上考虑, 对于较简单的映射关系, 在精度满足需求时可选择单隐层, 以求网络速度; 对于复杂的映射关系, 可选择多隐层, 以期提高网络的预测精度^[10, 15, 17]。多隐层 BP神经网络的拓扑结构如图 2 所示^[13]。

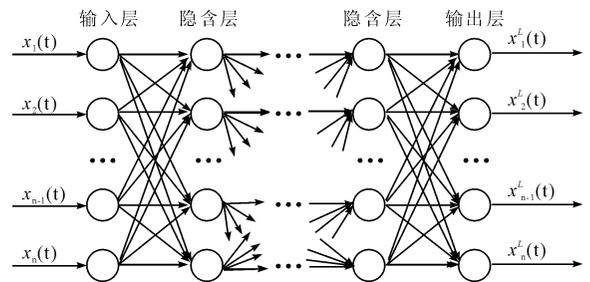


图 2 多隐层 BP神经网络模型结构图

图 2 中, 设有输入 $x_1(t), x_2(t), \dots, x_n(t)$, 输出 $x_1^l(t), x_2^l(t), \dots, x_n^l(t)$ 和若干隐层组成的多输入和多输出神经网络模型, L 表示网络层数 (不包括输入层)。若 N_l 表示第 l 层神经元数目, $x_i(t)$ 表示第 t 个模式输入矢量 $x(t)$ 的第 i 个分量, $x_i^{(l)}(t)$ 表示第 l 层中第 i 个神经元节点第 t 个模式输入时的输出, $y_i^{(l)}(t)$ 表示第 l 层中第 i 个神经元节点第 t 个模式输入时所接收到上一层的信息输入总和, $\omega_{ij}^{(l)}(t)$ 表示第 l 层中第 i 个神经元节点第 t 个模式输入时第 j 个连接权矢量, $d_i^{(l)}(t)$ 表示第 l 层中第 i 个神经元节点第 t 个模式输入时的期望输出, $\theta_i^{(l)}(t)$ 表示第 l 层中第 i 个神经元节点第 t 个模式输入时的偏值, $\varepsilon_i^{(l)}(t)$ 表示第 l 层中第 i 个神经元节点第 t 个模式输入时的误差信号。

$$x_i^0(t) = x_i(t) \quad 1 \leq i \leq N \quad (4)$$

在学习过程中, 偏值 $\theta_i^{(l)}(t)$ 作为一个权值来处理, 有:

$$\begin{cases} x_0^{(l)}(t) = 1 \\ \omega_{i0}^{(l+1)}(t) = \theta_i^{(l+1)}(t) \\ 1 \leq i \leq N_{l+1}, 1 \leq l \leq L - 1 \end{cases} \quad (5)$$

第 l 层中第 i 个神经元节点所接收到上一层的信息输入总和为:

$$\begin{aligned} y_i^{(l)}(t) &= \sum_{j=1}^{N_{l-1}} \omega_{ij}^{(l-1)}(t)x_j^{(l-1)}(t) + Q_i^{(l)}(t) \\ &= \sum_{j=0}^{N_{l-1}} \omega_{ij}^{(l)}(t)x_j^{(l-1)}(t) = x^{(l-1)}(t)w_i^l(t) \\ 1 \leq l \leq L, 1 \leq i \leq N_l \end{aligned} \quad (6)$$

$$w_i^l(t) = [\omega_{i0}^{(l)}(t), \omega_{i1}^{(l)}(t), \dots, \omega_{iN_{l-1}}^{(l)}(t)]^T \quad (7)$$

$$x_i^{(l-1)}(t) = [x_0^{(l-1)}(t), x_1^{(l-1)}(t), \dots, x_{N_{l-1}}^{(l-1)}(t)]^T \quad (8)$$

第 l 层中第 i 个神经元节点的输出为:

$$\begin{aligned} x_i^{(l)}(t) &= f[y_i^{(l)}(t)] \\ &= 1 / (1 + \exp[-\sigma y_i^{(l)}(t)]) \\ 1 \leq l \leq L, 1 \leq i \leq N_l \end{aligned} \quad (9)$$

式中: $f(\cdot)$ 为神经元节点转移函数, 选择极限值为 $[0, 1]$ 的 Sigmoid 函数; σ 为斜率参数。

若将 M 个训练样本分成 Q 个子块, 每个子块有 M_j 个训练样本, 有:

$$\sum_{j=1}^Q M_j = M \quad (10)$$

第 j 个模块数据对应输出层误差能量和为:

$$\begin{aligned} E^{(j)} &= \sum_{i=1}^{M_j} \sum_{l=1}^{N_L} \varepsilon_i^L(t) \\ &= \sum_{i=1}^{M_j} \sum_{l=1}^{N_L} [d_i^L(t) - x_i^L(t)] y_i^{(L)}(t) \end{aligned} \quad (11)$$

本文经过反复验证, 认为采用梯度下降法训练网络能达到较为理想的预测精度。梯度下降误差反向传递迭代算法步骤如下:

① 给定初始权值 $w_i^{(l)}(0)$, $1 \leq l \leq L, 1 \leq i \leq N_l$, 迭代终止误差为 ε , 最后迭代误差能量 E_0 , 且 $E_0 \leq \varepsilon$, 选择合适的学习率 η 和动量因子 α , 令 $j = 1$ 。

② 开始迭代, $k = 1$ 。

③ 计算输出层负误差信号矢量(权值修正量)为:

$$e_i^{(L)}(k) = \sum_{i=1}^{M_j} f[y_i^{(L)}(t)] [d_i^{(L)}(t) - x_i^{(L)}(t)] x^{(L-1)}(t) \quad (12)$$

④ 计算隐层单元的误差修正量为:

$$\begin{aligned} e_i^{(l)}(k) &= \sum_{i=1}^{M_j} f[y_i^{(l)}(t)] \cdot \\ &\sum_{j=1}^{N_{l+1}} e^{(l+1)}(k) \omega_{ji}^{l+1}(t) x^{(l-1)}(t) \\ 1 \leq l \leq L - 1, 1 \leq i \leq N_l \end{aligned} \quad (13)$$

⑤ 计算 l 层中第 i 个神经元节点 $k + 1$ 时刻对应的权值矢量迭代值为:

$$w_i^{(l)}(k + 1) = w_i^{(l)}(k) + \eta e_i^{(l)}(k) + \alpha [w_i^{(l)}(k) - w_i^{(l)}(k - 1)] \quad (14)$$

⑥ 由 (8) 式计算 $k + 1$ 时刻的误差能量 $E^{(j)}(k + 1)$ 值。

⑦ 若 $E^{(j)}(k + 1) > \varepsilon$, 转入 ③; 否则转入 ⑧。

⑧ 若 $E^{(j)}(k + 1) < E_0$, 转入 ⑩; 否则转入 ⑨。

⑨ 若 $j = Q$, 则转入 ③; 否则 $j = j + 1$, 转入 ②。

⑩ 训练结束。

本文双隐层 BP 神经网络结构采用试算法进行确定, 在确定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, 在相同传递函数、训练函数及期望误差等条件下, 依次增加隐层层数进行网络训练和预测。

2 实例分析

2.1 基本资料与相关分析

以云南省某水库总氮预测为例进行实例分析。依据《地表水环境质量标准》(GB3838 - 2002), 选取水位、库容等 14 项可能对总氮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, 分析总氮与环境因子的相关性, 分析结果见表 1。

表 1 总氮含量与环境因子的相关系数

项目	水位	库容	气温	水温	气压	pH	DO	NH ₄ ⁺ -N	NO ₂ ⁻ -N	NO ₃ ⁻ -N	COD _{Mn}	氟化物	TP	透明度
TN	0.098	0.298*	0.152	0.161	-0.170	-0.165	-0.120	0.619**	0.688**	0.931**	0.333*	0.003	0.282*	-0.515**

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。

从表 1 可以看出, TN 与库容、NH₄⁺-N、NO₂⁻-N、NO₃⁻-N、和 COD_{Mn}、TP 和透明度显著相关, 其中与库容、NH₄⁺-N、NO₂⁻-N、NO₃⁻-N、COD_{Mn} 和 TP 呈显著正相关, 与透明度呈显著负相关; 与水位、气温、水温、

气压、pH、DO 和氟化物无显著相关。

本文选用 2007 - 2011 年云南某水库相关数据建模, 选取与总氮在 0.01 水平(双侧)上显著相关的 NH₄⁺-N、NO₂⁻-N、NO₃⁻-N 和透明度作为网络输

入,总氮作为输出,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检验样本。

2.2 水质预测的实现

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, NH_4^+-N 、 NO_2^--N 、 NO_3^--N 与总氮呈显著正相关,采用最大最小法进行数据归一化处理,公式如下:

$$\hat{x} = (x - x_{\min}) / (x_{\max} - x_{\min}) \quad (15)$$

透明度与总氮呈显著负相关,采用如下公式进行数据归一化处理:

$$\hat{x} = 1 - (x - x_{\min}) / (x_{\max} - x_{\min}) \quad (16)$$

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 网络训练 本文采用 GA-BP、单隐层 BP、双隐层 BP 和三隐层 BP 神经网络模型进行水质预测。以 NH_4^+-N 、 NO_2^--N 、 NO_3^--N 和透明度作为输入向量,即输入层神经元数为 4 个;实测总氮值作为输出向量,即输出层的神经元数为 1 个。对于 BP 网络各隐层神经元数的选取,目前并没有统一的计算方法,本文采用目前较为普遍的 Kolmogorv 定理^[10,15] 确定隐层单元数,在确定隐层神经元数时,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。本文采用 Matlab 软件编写 BP 等神经网络算法程序进行水质预测,程序采取循环训练算法^[15],最终确定:单隐层 BP 神经网络水质预测模型结构为 4-11-1,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 lr 为 0.01,设定期望误差为 0.002 5,最大训练轮回为 50 000 次;双隐层 BP 神经网络水质预测模型结构为 4-8-4-1,隐含层和输出层传递函数分别采用 tansig、logsig 和 purelin,训练函数采用 traingdx,学习速率 lr 为 0.01,设定期望误差为 0.002 1,最大训练轮回为 50 000 次;三隐层 BP 神经网络水质预测模型结构为 4-6-4-4-1,隐含层和输出层传递函数分别采用 tansig、logsig、tansig 和 purelin,训练函数采用 traingdx,学习速率 lr 为 0.01,设定期望误差为 0.002 1,最大训练轮回为 50 000 次经过训练,网络达到了较好的预测精度。

对于 GA-BP 网络模型,本文是在上述单隐层

BP 神经网络结构前提下,即网络结构为 4-11-1,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 lr 为 0.01,设定期望误差为 0.0025,最大训练轮回为 50000 次,运用遗传算法来优化 BP 神经网络的初始权值和阈值。由于单隐层 BP 神经网络结构为 4-11-1,即输入层有 4 个节点,隐含层有 11 个节点,输出层有 1 个节点,共有 $4 \times 11 + 11 \times 1 = 55$ 个权值, $11 + 1 = 12$ 个阈值,所以遗传算法个体编码长度为 $55 + 12 = 67$ 。并确定遗传算法参数设置为:种群规模为 100,进化次数为 100 次,交叉概率为 0.4,变异概率为 0.1。

2.3 水质预测结果及分析

利用上述训练好的 GA-BP、单隐层 BP、双隐层 BP 和三隐层 BP 神经网络水质预测模型对某水库总氮进行预测,并以平均相对误差绝对值 MPE 作为衡量预测精度的指标。拟合—预测结果见表 2、表 3。平均相对误差 MPE :

$$MPE = \frac{1}{N} \sum_{i=1}^N \frac{| \text{实测值}(i) - \text{预测值}(i) |}{\text{实测值}(i)} \times 100 \% \quad (17)$$

分析表 2、表 3 可以得出以下结论:

(1) 在相同网络结构、传递函数、训练函数及期望误差等条件下,GA-BP 网络水质模型预测精度高于基本 BP 网络,表明遗传算法能有效优化 BP 网络初始权值和阈值。同样,在相同传递函数、训练函数及期望误差等条件下,依次增加 BP 神经网络隐层层数能进一步提高网络预测精度。表明研究建立的 GA-BP 及多隐层 BP 神经网络水质预测模型是可行的,模型均可用于水质预测,且模型泛化能力强,预测精度高,算法稳定,可为水质预测预报提供新的途径和方法。

(2) 从预测精度上看,模型精度高低顺序依次是:三隐层 BP 模型、GA-BP 模型、双隐层 BP 模型、基本 BP 模型;从拟合精度上看,模型精度高低顺序依次是:三隐层 BP 模型、双隐层 BP 模型、GA-BP 模型、基本 BP 模型;从总体精度上看,模型精度高低顺序依次是:三隐层 BP 模型、双隐层 BP 模型、GA-BP 模型、基本 BP 模型;从总体最大相对误差上看,由小到大顺序依次是:GA-BP 模型、双隐层 BP 模型、三隐层 BP 模型、基本 BP 模型。可见,GA-BP 模型和多隐层 BP 网络模型具有较高的预测精度,无论是拟合精度、预测精度还是最大相对误差均高于基本 BP 网络模型,表明 GA-BP 和多隐层 BP 神经网络模型具有较高的预测精度,是提高预测

精度的有效方法。

(3)同多隐层BP网络算法相比,GA-BP水质预测模型具有收敛速度快、预测精度高、不易陷入局

部极小值等优点,可以更快地预测评价网络,具有一定的计算优势。

表2 某水库总氮拟合结果及其比较

mg/L, %

序号	实测 TN	基本BP网络模型		GA-BP网络模型		双隐层BP网络模型		三隐层BP网络模型	
		TN拟合值	相对误差	TN拟合值	相对误差	TN拟合值	相对误差	TN拟合值	相对误差
1	0.760	0.6854	9.8206	0.6695	11.9121	0.6394	15.8691	0.6507	14.3778
2	0.690	0.8099	-17.3797	0.8763	-27.0039	0.8510	-23.3263	0.8188	-18.6681
...
47	1.690	1.7854	-5.6430	1.7801	-5.3328	1.7950	-6.2136	1.7340	-2.6056
48	1.330	1.6136	-21.3263	1.5529	-16.7613	1.6076	-20.8728	1.6373	-23.1066
训练样本 MPE		16.0604		15.8834		15.2889		15.2365	

表3 某水库总氮预测结果及其比较

mg/L, %

序号	实测 TN	基本BP网络模型		GA-BP网络模型		双隐层BP网络模型		三隐层BP网络模型	
		TN拟合值	相对误差	TN拟合值	相对误差	TN拟合值	相对误差	TN拟合值	相对误差
49	2.340	1.4604	37.5914	1.5015	35.8342	1.5620	33.2493	1.5303	34.6008
50	1.300	1.3001	-0.0057	1.2286	5.4897	1.3137	-1.0564	1.2751	1.9146
51	1.160	1.2333	-6.3198	1.0811	6.8054	1.1127	4.0780	1.0799	6.9011
52	1.140	1.2322	-8.0836	1.1446	-0.4039	1.2055	-5.7440	1.1889	-4.2937
53	1.640	0.9206	43.8638	0.9931	39.4445	0.9740	40.6107	0.9505	42.0407
54	0.817	0.8036	1.6460	0.8030	1.7160	0.7914	3.1375	0.7683	5.9667
55	1.150	1.0493	8.7589	1.0960	4.6940	1.0722	6.7683	1.1239	2.2709
56	1.160	1.0142	12.5691	0.9869	14.9186	0.9493	18.1600	1.0003	13.7683
57	0.780	0.9947	-28.0135	0.8065	-3.7997	0.8513	-9.5638	0.7462	3.9669
58	1.000	0.6713	32.5312	0.7255	27.0903	0.7064	29.0067	0.6557	34.0994
59	0.701	0.7327	-4.5273	0.7655	-9.1943	0.7434	-6.0518	0.7037	-0.3783
60	0.490	0.5956	-21.5496	0.6168	-25.8793	0.6227	-27.082	0.6095	-24.3826
检验样本 MPE		17.1217		14.6058		15.3757		14.5487	
总体 MPE		16.2727		15.6279		15.2263		15.0989	
总体最大相对误差		63.2197		39.4445		43.7495		48.6118	

(4)从本例可以看出,多隐层BP网络模型预测精度毫不逊色于GA-BP模型,表明BP等神经网络增加隐层数可以有效提高网络的预测精度。但难点是如何确定最佳网络结构和各类参数,本文多隐层BP网络所确定的结构和参数理论上仅仅是较佳,而非最佳。

(5)本例中,GA-BP模型及多隐层BP模型相对于基本BP网络模型预测精度的提升是十分有限的,基本BP网络模型预测精度同样令人满意,这表明选择合适的网络结构、传递函数、训练函数以及期望误差等对提高BP预测精度具有重要意义。

3 结 语

(1)本文构建了基本BP、GA-BP和多隐层BP神经网络水质预测模型,在基本BP网络获得较好

预测精度的前提下,运用遗传算法来优化BP神经网络的初始权值和阈值,以及增加隐层数来获得BP网络精度的提升,二者均获得了令人满意的预测效果,表明遗传算法能有效优化BP网络初始权值和阈值,增加BP神经网络隐层层数能进一步提高网络预测精度。GA-BP、多隐层BP神经网络模型算法稳定、预测精度高、泛化能力强,是提高预测精度的有效方法。

(2)目前国内外对于多隐层神经网络运用的研究不多,这是由于多隐层网络在隐层层数、隐层节点数、传递函数、训练函数以及期望误差等的选取上有一定的主观随意性,主要凭经验选取,这在一定程度上制约了多隐层神经网络的应用。加之在传递函数和训练函数确定的情况下,如何在隐层层数、期望误差和训练次数之间探寻网络的预测精度、“过拟合”和

泛化能力三者的平衡点,也是制约多隐层神经网络应用的另一因素。

(3) 鉴于多隐层 BP 网络收敛速度慢以及存在局部极值等缺点,如何利用遗传算法、粒子群算法等智能算法进行网络初始权值、阈值以及网络结构等的优化,以期进一步提高多隐层 BP 网络的预测精度及收敛速度,将是下一步研究的重点和方向。

参考文献:

- [1] 袁健, 树锦. 改进多元回归法与神经网络应用于水质预测[J]. 水资源保护, 2008, 24(3): 46-48.
- [2] 张立明. 人工神经网络的模型及其应用[M]. 上海: 复旦大学出版社, 1993. 1.
- [3] 过仲阳, 陈中原, 李绿芊, 等. 人工神经网络技术在水质动态预测中的应用[J]. 华东师范大学学报(自然科学版), 2001(1): 84-89.
- [4] 任黎, 董增川, 李少华, 等. 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.
- [5] 任宏洋, 张代钧. 基于结构化设计的湖库富营养化模型研究[J]. 环境污染与防治, 2005, 27(5): 371-371, 381.
- [6] 刘载文, 崔莉凤, 王小艺, 等. 基于 RBF 神经网络的河湖水质软测量方法[C]//程代展, 吴敏. 第 26 届中国控制会议论文集, 北京: 北京航空航天大学出版社, 2007: 108-111.

- [7] 郭劲松, 霍国友, 龙腾锐. BOD-DO 耦合人工神经网络水质模拟的研究[J]. 环境科学学报, 2001, 21(2): 140-143.
- [8] 裴洪平, 罗妮娜. 利用 BP 神经网络方法预测西湖叶绿素 α 的浓度[J]. 生态学报, 2004, 24(2): 246-251.
- [9] 王晓萍, 孙继洋, 金鑫. 基于 BP 神经网络的钱塘江水质指标的预测[J]. 浙江大学学报(工学版), 2007, 41(2): 361-364.
- [10] 张德丰, 等. Matlab 神经网络应用设计[M]. 北京: 机械工业出版社, 2009. 1.
- [11] 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. 2.
- [12] 傅荟璇, 赵红, 等. Matlab 神经网络应用设计[M]. 北京: 机械工业出版社, 2009. 10.
- [13] 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. 8.
- [14] 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.
- [15] 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. 4.
- [16] 范佳妮, 王振雷, 钱锋. BP 人工神经网络隐层结构设计的研究进展[J]. 控制工程, 2005, 12(S0): 105-109.
- [17] 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. 4.

(上接第 153 页)

本一致,也略小于 ζ_i (为 0.705 6),但断面的实际速度水头差为 $h_{v,1-2}$,以该值计算得到的 ζ 明显大于 ζ^* ,也大于 ζ_i 。令 $E_\zeta = (\zeta - \zeta_i)/\zeta_i$,其值见表 1,在 $Re < 4\ 000$ 时, ζ 比 ζ_i 大 20%,随着 Re 的增加, E_ζ 值逐渐减小,当 Re 为 5 500 时, E_ζ 约为 8%。显然,速度水头的计算方法要远大于沿程损失对 ζ 的影响,即在 $Re < 5\ 500$ 时,如果速度水头采用断面平均速度的方法来计算,并取动能修正系数为 1.0 时,用 ζ_i 计算管路的局部水头损失仍比实际的水头损失偏小。

4 结 语

从以上的计算结果和分析可知,Spalart-Allmaras 湍流模型能够对管路突然扩大的局部水头损失进行有效模拟;当 $Re < 5\ 500$ 时,突扩管上、下游断面间的沿程水头损失只占两断面间水头损失的 1%

~2%;断面速度水头的计算方法对局部损失系数的影响更明显,为使管路的水头损失计算更准确,应考虑断面速度水头的动能修正系数,在 $Re < 4\ 000$ 时,取动能修正系数为 1.15,在 $4\ 000 < Re < 5\ 500$ 时,取动能修正系数为 1.06~1.08。

参考文献:

- [1] 龙天渝, 蔡增基. 流体力学[M]. 北京: 中国建筑工业出版社, 2004. 5.
- [2] 赵宝峰, 金英子, 卢玉邦, 等. 对突然扩大局部水头损失的初探[J]. 东北农业大学学报, 1997, 28(2): 175-178.
- [3] 周志军, 林震, 周俊虎, 等. 不同湍流模型在管道流动阻力计算中的应用和比较[J]. 热力发电, 2007, 36(1): 18-23.