

基于 BP 神经网络的农村饮用水水源地水质评价

伊璇¹ 孙安帅² 宿立明² 庞清江²

(1. 武汉大学水利水电学院 湖北 武汉 430072; 2. 山东农业大学水利土木工程学院 山东 泰安 271018)

摘要 通过构建 BP 神经网络模型,进行训练识别,应用于评价水源地水质。结果表明:基于 BP 神经网络的农村饮用水水源地水质评价能够改善其他水源地水质评价方法带来的不足,较好地改善评价对全局性的寻优能力,做到合理全面地评价水源地水质。同时,模型反映出了水源地水质变化的复杂性和可模拟性,提高了对水源地水质评价的可靠性和有效性。

关键词 农村饮用水 水源地 水质评价 BP 神经网络

中图分类号:X824 文献标识码:A 文章编号:1003-9511(2011)05-0065-03

近年来,我国饮用水面临着资源短缺和水质变差的双重挑战,水资源存在天然不足、分布不均的同时,显现出更为严重的水质问题,全国约有 54.7% 的人口饮用不安全的水^[1]。世界卫生组织指出,人类 80% 的疾病与饮用水不干净有关^[2]。水的安全性包括水量和水质的双重含义,水质不仅影响到水量的有效供给,更涉及健康安全,是供水的首要问题,目前水质问题已成为我国水资源问题的主要矛盾。

农村饮用水在水源的水体污染、供水条件以及对饮用水的水质处理等众多方面存在问题,目前,农村有 3 亿多人饮用水安全存在问题,1.9 亿人饮用水中有害物质含量超标^[3]。而针对农村水源地水质评价方法一般缺少全局性,笔者试图通过 BP 神经网络方法对水源地进行评价,以寻求较好的水源地水质评价方法。

1 评价研究方法及其模型的构建

1.1 BP 神经网络评价方法简介

研究方法采用神经网络评价法^[4]。BP 神经网络是基于误差反向传播的多层前向神经网络,采用反向传播的权值调整学习的算法^[5]。算法的步骤是:对一个输入样本,从输入层经隐层逐层正向计算,得到输出层的输出。若得到了期望的输出,学习算法结束,否则,转至反向传播。反向传播就是将误差信号按原连接通路反向计算,由梯度下降法调整

各层神经元的权值和阈值,从而使网络输出逼近期望输出,通常使之达到误差均方值取最小为止。

神经网络模拟人类思维方式,对事物的判断、分类不需预先建立某种模式,根据事物的性质特征,采用直观推理判断。神经网络应用于水质评价的方法有 BP 网络模型法、Hopfield 网络模型法、RBF 网络模型法等。

水源地水质形成过程高度复杂且具有非线性的特点,神经网络能够有效地处理非线性问题,对于水源地水质评价能够克服单因素指标评价等方法

1.2 评价模型的构建

1.2.1 人工神经元模型

图 1 表示人工神经网络的基本单元的神经元模型,它有 3 个基本要素^[6]:




图 1 人工神经元模型

a. 1 组连接(对应生物神经元突触),连接强度由权值表示,权值正表示激活,负表示抑制。

b. 1 个求和单元,求取各输入信号加权和(线性组合)。

基金项目:山东省教育厅重点项目(J06N05),泰安市大学生科技新行动计划(2010D1010)

作者简介:伊璇(1989—),山东泰安人,本科生,从事水文与水资源的研究。

通讯作者:庞清江(1957—),男,山东鄄城人,博士,从事水资源与水利工程等研究。E-mail: pangqingj1@163.com

c. 1 个非线性激活函数,起非线性映射作用并将神经元输出幅度限制在一定范围内(一般在 0.1 ~ -1.1 之间)。

此外还有一个阈值 $u_k = \sum_{j=1}^p w_{kj}x_j$

(或偏置 $u_k = \sum_{j=1}^p w_{kj}x_j$)。

1.2.2 人工神经元模型数学模型化

以上模型学习作用可分别以数学式表达出来:

$$u_k = \sum_{j=1}^p w_{kj}x_j \quad (1)$$

$$v_k = u_k - \theta_k \quad (2)$$

$$y_k = \varphi(v_k) \quad (3)$$

式中: x_1, x_2, \dots, x_p 为输入信号; $w_{k1}, w_{k2}, \dots, w_{kp}$ 为神经元 k 之权值; u_k 为线性组合结果; θ_k 为阈值; $\varphi(\cdot)$ 为激活函数; y_k 为神经元 k 的输出。

建立人工神经网络模型,通过调整参数,并应用所得饮用水水源水质监测资料对模型进行识别,对参数进一步优化。

1.2.3 水质评价人工神经网络模型具体步骤

建立水质评价 BP 神经网络模型,其具体步骤如下^[4]:

a. 以随机小量初始值,赋予连接权值 $\{W_{ij}^{(1)}\}$, $\{W_{ij}^{(2)}\}$, $\{W_{ij}^{(3)}\}$ 及阈值 $\{\theta_i^{(1)}\}$, $\{\theta_i^{(2)}\}$, $\{\theta_i^{(3)}\}$ 。其中, $\{W_{ij}^{(1)}\}$ 为输入层至第 1 隐含层连接权值 ($i = 1, 2, \dots, m$; $j = 1, 2, \dots, p$), $\{W_{ij}^{(2)}\}$ 为第 1 隐含层至第 2 隐含层连接权值 ($i = 1, 2, \dots, p$; $j = 1, 2, \dots, t$), $\{W_{ij}^{(3)}\}$ 为第 2 隐含层至输出层连接权值 ($i = 1, 2, \dots, t$; $j = 1, 2, \dots, n$), n 为输入层神经元数, p 为第 1 隐含层神经元数, t 为第 2 隐含层神经元数, $\{\theta_i^{(1)}\}$ 为第 1 隐含层神经元输出阈值 ($i = 1, 2, \dots, p$), $\{\theta_i^{(2)}\}$ 为第 2 隐含层各神经元输出阈值 ($i = 1, 2, \dots, t$), $\{\theta_i^{(3)}\}$ 为输出层各神经元输出阈值 ($i = 1$)。

b. 随机选一模式对 $X_k = (x_1, x_2, \dots, x_n)$ 及 Y_k 进行模拟训练 ($k = 1, 2, \dots, M$, M 为学习模式对数)。其中: X_k 为输入模式向量, Y_k 为期望输出向量。

c. 计算第 1 隐含层输入 $x_j^{(1)}$ 和输出 $y_j^{(1)}$:

$$x_j^{(1)} = \sum_{i=1}^n W_{ij}^{(1)}x_i - \theta_j^{(1)} \quad (j = 1, 2, \dots, p) \quad (4)$$

$$y_j^{(1)} = f(x_j^{(1)}) \quad (j = 1, 2, \dots, p) \quad (5)$$

其中, f 为 Sigmoid 函数,且 $f(x_j^{(1)}) = \frac{1}{1 + e^{-x_j^{(1)}}}$, 下同。

d. 计算第 2 隐含层的输入 $x_j^{(2)}$ 和输出 $y_j^{(2)}$:

$$x_j^{(2)} = \sum_{i=1}^p W_{ij}^{(2)}y_i^{(1)} - \theta_j^{(2)} \quad (j = 1, 2, \dots, t) \quad (6)$$

$$y_j^{(2)} = f(x_j^{(2)}) \quad (j = 1, 2, \dots, t) \quad (7)$$

e. 计算输出层输入 $x_j^{(3)}$ 和输出 Z_k :

$$x_j^{(3)} = \sum_{i=1}^t W_{ij}^{(3)}y_i^{(2)} - \theta_j^{(3)} \quad (j = 1) \quad (8)$$

$$Z_k = f(x_j^{(3)}) \quad (9)$$

其中: Z_k 为实际输出。

f. 由期望输出 Y_k 和实际输出 Z_k 计算输出层神经元一般化误差 $\delta_i^{(3)}$:

$$\delta_i^{(3)} = (Y_k - Z_k)Z_k(1 - Z_k) \quad (i = 1) \quad (10)$$

g. 计算第二隐含层各神经元一般化误差 $\delta_i^{(2)}$:

$$\delta_i^{(2)} = W_{ij}^{(3)}\delta_i^{(3)}y_i^{(2)} \quad (i = 1, 2, \dots, t; j = 1) \quad (11)$$

h. 计算第 1 隐含层各神经元一般化误差 $\delta_i^{(1)}$:

$$\delta_i^{(1)} = \left[\sum_{j=1}^t W_{ij}^{(2)}\delta_j^{(2)} \right] y_i^{(1)}(1 - y_i^{(1)}) \quad (i = 1, 2, \dots, p) \quad (12)$$

i. 用输出层神经元误差 $\delta_j^{(3)}$ 及第 2 隐含层各神经元输出 $y_i^{(2)}$ 修正连接权 $\{W_{ij}^{(3)}\}$ 及阈值 $\{\theta_j^{(3)}\}$:

$$W_{ij}^{(3)}(H+1) = W_{ij}^{(3)}(H) + \eta_3 y_i^{(2)} \delta_j^{(3)} \quad (i = 1, 2, \dots, t; j = 1) \quad (13)$$

$$\theta_j^{(3)}(H+1) = \theta_j^{(3)}(H) + \eta_3 \delta_j^{(3)} \quad (j = 1) \quad (14)$$

式中: η_3 为学习系数(学习率) $0 < \eta_3 < 1$; H 为学习训练次数,下同。

j. 用第 2 隐含层各神经元误差 $\delta_j^{(2)}$ 及第 1 隐含层各神经元的输出 $y_i^{(1)}$ 修正连接权 $\{W_{ij}^{(2)}\}$ 及阈值 $\{\theta_j^{(2)}\}$:

$$W_{ij}^{(2)}(H+1) = W_{ij}^{(2)}(H) + \eta_2 y_i^{(1)} \delta_j^{(2)} \quad (i = 1, 2, \dots, p; j = 1, 2, \dots, t) \quad (15)$$

$$\theta_j^{(2)}(H+1) = \theta_j^{(2)}(H) + \eta_2 \delta_j^{(2)} \quad (j = 1, 2, \dots, t) \quad (16)$$

式中: η_2 为学习系数(学习率) $0 < \eta_2 < 1$ 。

k. 用第一隐含层各神经元误差 $\delta_j^{(1)}$ 及输入层各神经元的输出 x_i 修正连接权 $\{W_{ij}^{(1)}\}$ 及阈值 $\{\theta_j^{(1)}\}$:

$$W_{ij}^{(1)}(H+1) = W_{ij}^{(1)}(H) + \eta_1 x_i^{(1)} \delta_j^{(1)} \quad (i = 1, 2, \dots, n; j = 1, 2, \dots, p) \quad (17)$$

$$\theta_j^{(1)}(H+1) = \theta_j^{(1)}(H) + \eta_1 \delta_j^{(1)} \quad (j = 1, 2, \dots, p) \quad (18)$$

式中: η_1 为学习系数(学习率) $0 < \eta_1 < 1$ 。

l. 随机选取下一模式对提供给网络,重复步骤 3 ~ 12,直至 m 个模式对全部训练完毕。

m. 计算模型全局误差函数值 E :

$$E = \frac{1}{2} \sum_{k=1}^m (Y_k - Z_k)^2 \quad (19)$$

若 $E < \epsilon$,则网络收敛 ,或网络的学习训练次数大于预先给定的数 ,学习训练结束。否则 ,转到下一步。

n. 重新从 m 个学习模式对随机选取一个模式对 ,返回步骤 c。直至 $E < \epsilon$,或网络的学习训练次数大于预先给定的数为止。

2 模型应用及水源地水质综合分级评价结果分析

2.1 人工神经元模型应用

在评价指标、评价标准及评价等级基础上建立人工神经网络综合评价模型 ,利用泰安市 248 处农村饮用水源的大量水质检测数据 ,根据检测结果选用总硬度、锰、硫酸盐、氯化物、溶解性总固体、氟化物、硝酸盐氮、氨氮等主要水质参数 ,分别对泰安市不同县区的农村饮用水水源地水质进行综合分级评价。

本次选用了除输入层和输出层外具有 2 个隐含层的 BP 神经网络模型(见图 2),隐含层的数目是根据经验和精度而确定的 ,模型输入层与两个隐含层的神经元数相等 ,皆为评价项目数 ,输出层有 1 个神经元^[4]。设定该模型等级期望输出值界定为 :1 级等于 0.0 ,2 级等于 0.5。对 BP 神经网络模型进行学习训练 10000 次后 ,使得模型误差 E 小于预先设定允许误差 $\epsilon = 0.00001$,模型等级实际输出 :1 级等于 0.00225 ,2 级等于 0.49798 ,网络学习训练结束。




图 2 水质评价 BP 神经网络模型

应用训练好的 BP 神经网络模型进行泰安市农村饮用水水源地水质综合分级评价 ,评价结果表明 :泰安市农村饮用水源共计 248 处 ,达到《生活饮用水水源水质标准》1 级标准的占 66.9% ,达到 2 级标准的占 23.7% ,介于两者之间的占 9.2% ,各县级市及地区的评价结果统计见图 3。

2.2 水源地水质综合分级评价结果综合分析

从总的分级评价结果看 ,达到《生活饮用水水源

水质标准》1 级标准的占 66.9% ,达到 2 级标准的占 23.7% ,介于两者之间的占 9.2%。

所构建神经网络模型能够符合当地实际情况 ,较为合理地评价当地饮用水水源地水质 ,为水质改善及当地用水评估提供可靠的分析数据 ,同时为未来本地区水质改善提供合理借鉴。




图 3 泰安市农村饮用水水源分级评价统计

3 结 论

传统水源地水质评价方法原理简单 ,单项指标能够有效确定水质是否达标 ,但评价难以完全符合标准。

本文以泰安市农村水源地为例 ,通过建立人工神经网络模型对水质进行综合评价。实践证明 :BP 神经网络提高了对饮用水水源地的综合评价 ,较为合理地反映了水质变化机制 ,更接近实际机理。

虽然本文建立的人工神经网络模型能够较好地评价泰安市农村饮用水水源地水质 ,但所建立的模型不能够完全适用于其他水源地的水质评价 ,因此对其他水源地水质评价时仍需构建新的模型并通过训练进行水质评价。

参考文献 :

- [1] 宋欣 ,栗果 ,黄鹤 ,等 .全国 29 省(区、市)安全饮用水和环境卫生现状与分忻[J].中国初级卫生保健 ,1998 ,12(4): 21-23.
- [2] World Health Organization and UNICEF. Meeting the MDG drinking water and sanitation target :the urban and rural challenge of the decade[R]. Geneva :World Health Organization and UNICEF ,2006.
- [3] 翟浩辉 .切实做好农村饮水安全工作[J].中国农村水利水电 ,2005(1):1-6.
- [4] 庞清江 .东平湖生态环境质量综合评价[J].海河水利 ,2004(3):17-20.
- [5] 魏茹生 ,沈冰 ,吴建华 .河道水量还原计算中的遗传 BP 神经网络方法[J].河海大学学报 :自然科学版 ,2008 ,36(2):161-164.
- [6] 王栋 ,曹升乐 .人工神经网络在水文水资源水环境系统中的应用研究进展[J].水利水电技术 ,1999 ,30(12):4-7.

(收稿日期 2010-12-30 编辑 陈玉国)