

# BP神经网络在洞庭湖氨氮浓度预测中的应用

杨琴<sup>1</sup>, 谢淑云<sup>2</sup>

(1. 中国地质大学 材料科学与化学工程学院, 湖北 武汉 430074;

2. 中国地质大学 地球科学学院, 湖北 武汉 430074)

**摘要:** 采用BP网络的三种改进算法,对洞庭湖桂花园8年(1995年~2002年)的氨氮浓度和其影响因子实测资料进行分析,建立了基于BP神经网络的氨氮浓度预测模型,并对三种改进算法的训练结果进行了比较。结果表明:作为数据驱动型模型的BP网络,用来建模的学习样本质量至关重要,可以直接影响网络的预测精度。1995年~2002年的丰水期(9月份)数据分布比较均匀,能让网络对样本充分学习,与传统的统计建模方法相比,预测精度较高,能较好地反映洞庭湖氨氮浓度与其影响因子之间变化规律。

**关键词:** BP神经网络;改进算法;浓度预测;样本质量;洞庭湖

中图分类号:X824

文献标识码:A

文章编号:1672-643X(2006)01-0065-06

## Application of BP neural network into predicting NH<sub>3</sub>-N concentration of Dongting Lake

YANG Qin<sup>1</sup>, XIE Shu-yun<sup>2</sup>

(1. School of Materials Science and Chemical Engineering, China University of Geosciences, Wuhan, Hubei 430074, China;

2. Faculty of Earth Science, China University of Geosciences, Wuhan, Hubei 430074, China)

**Abstract:** According to the analysis of 8 years(1995~2002) recorded data of NH<sub>3</sub>-N concentration and its affecting factors, a model is developed to predict NH<sub>3</sub>-N concentration of the Dongting Lake at Guihuayuan hydrologic station based on BP artificial neural network. The model is optimized with three different improved BP algorithms and the training results are compared. The study indicates that the key factor affecting the predicted precision of BP neural network as a data-driven model directly is the quality of the training patterns. Comparing with conventional statistics methods, the distribution of the data which is measured in the period of highest flow from 1995 to 2002 is uniform, so the network can learn from the training patterns fully, and has good ability to reflect the change rules between NH<sub>3</sub>-N concentration and its affecting factors with higher predicted precision.

**Key words:** BP artificial neural network; improved algorithm; concentration predicting; training patterns quality; Dongtinghu Lake

## 1 概述

洞庭湖是我国最大的淡水湖泊,区域总面积为18 780 km<sup>2</sup>。作为世界基金会所列全球最为重要的湿地区域,洞庭湖湿地正在成为人们关注的焦点。它汇4水吞长江,是长江的重要蓄洪区,也是湖南省农业及渔业的主要生产基地。目前,洞庭湖及其湖区生态环境的严重退化,已经构成了对湖泊资源和功能

的危害,成为湖区社会经济可持续发展的制约因素,并危及长江水系的生态安全。据1999年调查统计,洞庭湖纯湖区主要工业企业共计100个,年排工业废水排放量2.0046亿t,其中排放氨氮2 487 t<sup>[1]</sup>。利用1999年~2000年洞庭湖的水质检测数据,采用有关标准和指数法进行综合评价,氨氮的超标率为4.7%<sup>[2]</sup>。众所周知,当氨氮含量较高时,会对水生生物产生直接危害或使水质变坏,对人体健康有危害

收稿日期:2005-09-01

作者简介:杨琴(1982-),女(汉族),湖北洪湖人,硕士研究生,研究方向:分析化学。

作用,因此对氨氮浓度的准确预测具有十分重要的意义。

水质浓度预测过程可认为是一种复杂非线性函数关系的逼近过程,要对其进行较为准确的预报,就必须采用能捕捉非线性变化规律的预报方法。BP神经网络具有逼近任意连续函数和非线性映射的能力,并可进行高维非线性的精确映射。它是由大量的、同时也是很简单的神经元通过广泛的互相连接而形成的复杂网络系统,它反映了人脑功能的许多基本特性。其信息处理是通过学习动态修改各神经元之间的连接权值使系统不断产生“进化”来实现。

## 2 BP神经网络及其改进学习算法

### 2.1 BP神经网络原理

BP神经网络是一种具有三层或三层以上阶层型结构的神经网络。层间各种神经元实现全连接,即下层的每一个神经元与上层的每个神经元都实现权连接,而每层各神经元之间不连接<sup>[3]</sup>。网络中每一层神经元的连接权值都可以通过学习来调整。当给定一个输入节点数为 $N$ 、输出节点数为 $M$ 的BP网络,输入信号由输入层到输出层传递,通过非线性函数的复合来完成从 $N$ 维欧氏空间到 $M$ 维欧氏空间的映射,该过程是向前传播的过程;如果实际输出信号存在误差,网络就转入误差反向传播过程,并根据误差的大小来调节各层神经元之间的连接权值。当误差达到人们所希望的要求时,网络的学习过程就结束。关于BP网络训练步骤可参见文献<sup>[4]</sup>。

BP网络具有非线性、非局域性、非定常性和非凸性,在信息处理方面具有如下显著特点:①BP网络模型的建立不需要有关体系的先验知识,主要依赖于资料。只需给网络若干训练实例,BP网络就可以通过自学习来完成,完全能够发现其隐含的信息,并有所创新;②BP网络具有自适应和自组织能力,通过与外界环境的相互作用,从外界环境中获取知识,把环境的统计规律反映到自身结构上来,并能有机地融合多种信息。当外界环境发生变化时,只需输入新的资料让模型再学习即可很快跟踪环境的变化,可操作性强。③由于神经元之间的高维、高密度的并行计算结构,神经网络具有很强的集体计算能力,完全可以进行高维数据的实时处理,同时也可以进行分布式联想存储。④作为一个高度的非线性动态处理系统,具有很强的容错功能。

### 2.2 BP网络改进学习算法

传统BP网络的学习算法实质上是一种简单的

最速下降静态寻优算法,在修正权值 $W(k)$ 时,只是按照 $k$ 时刻的负梯度方式进行修正,而没有考虑到以前积累的经验,即以前时刻的梯度方向,从而常常使学习过程发生振荡,通常具有收敛速度慢、易陷入局部极小值和网络推广能力不强等方面的缺陷。本文采用MATLAB神经网络工具箱提供的三种改进快速学习算法,有效克服了传统BP网络学习算法的缺陷<sup>[5]</sup>。

(1) traingdm(动量梯度下降反向传播算法)。该算法在对权重和阈值更新时不仅考虑当前的梯度方向,而且还考虑了前一时刻的梯度方向,从而降低了网络性能对参数调整的敏感性,有效地抑制了局部极小,但收敛速度较慢。

(2) trainlm(Levenberg-Marquardt优化方法)。Levenberg-Marquardt优化方法能够根据网络训练误差变化情况,自动调节网络训练参数 $\mu$ ,使网络实时采取适宜的训练方法。当 $\mu$ 较小,网络训练过程主要依据Gauss-Newton法;当 $\mu$ 较大,网络训练过程主要依据梯度下降算法。该训练函数的效率优于梯度下降法,但占用内存较大,适用于规模较小的网络。

(3) trainbr(Levenberg-Marquardt优化方法与Bayesian正则化方法)。trainbr函数采用Levenberg-Marquardt优化方法进行网络权值和阈值的最优化搜索,并采用Bayesian正则化方法在网络训练过程中自适应地调节性能函数比例系数 $\gamma$ 的大小,使其达到最优,并且采用trainbr函数训练后BP网络具有较好的推广能力。

## 3 水质浓度预测BP网络的建立

目前BP神经网络已广泛应用于水质的评价和预测、径流量的模拟和预测等方面,但以洞庭湖区作为建模的研究对象的报道还不是很多。谢作涛<sup>[6]</sup>运用BP网络建立了洞庭湖城陵矶流量预报模型。本文运用BP网络,对洞庭湖桂花园断面1995~2002年氨氮浓度和其影响因子实测资料进行分析,建立了基于BP神经网络氨氮浓度与其影响因子之间的预测模型。

### 3.1 网络拓扑结构的建立

隐层在BP网络中起着很重要的作用,它具有高度的抽象功能,并可从输入单元中提取特征。隐层层数的选择与问题的复杂性有关,为了确保训练后人工神经网络模型的泛化能力和预测能力,应在满足精度要求的前提下取尽可能紧凑的网络结构。根

据 Kolmogrov 神经网络映射存在定理,三层结构的神经网络,通过选择一定的非线性和联接强度调节规律,就可以解决任何一个信息处理问题<sup>[3]</sup>。本文也采用3层的BP网络结构模型,即一个输入层、一个隐层和一个输出层。

3.1.1 网络输入层与输出层节点数的确定 输入层与输出层的节点数目由实际问题决定。通常,输入层节点数的确定应有明确的物理意义,输出层节点数则根据问题目标要求予以确定。氨氮挥发是氮循环过程的一部分,水中氨氮挥发不但受风速、水温和pH值影响,还受大气压变化及实际水质影响。水中存在的氨氮包括离子氨与非离子氨,氨氮挥发主要指非离子氨从水中向大气转移,而离子氨是很难挥发的<sup>[7]</sup>。由于受实测资料的限制,选水温、pH值和非离子氨浓度作为输入层因子,氨氮浓度作为预测目标进行输出,建立一个三输入、一输出的研究模型。

3.1.2 网络隐层节点数的确定 隐层节点数的多少将影响网络的非线性处理能力和网络学习过程时间的长短,是网络成功的关键。实践证明,隐层节点数太少,网络容错性能差,而增加隐层节点数虽可增强网络的分析能力且收敛性能也会提高,但也会使网络训练复杂化。目前对隐层节点数取值范围的研究较多,但并没有定论。一般说来,隐层节点数与问题的要求、输入输出节点数的多少都有直接的关系。对于函数逼近的问题,如要求逼近的精度高,隐层节点数就要多<sup>[8]</sup>。本文依据这一原则,采用试错法确定隐层节点数。

### 3.2 样本分析及数据预处理

网络学习样本的质量对模型预测精度及准确度影响极大。学习样本自身的噪声干扰降低了模型的预测精度及准确度。本文使用的是洞庭湖桂花园1995年~2002年的实际监测值,其监测频率为:全年采样27次,时间按枯、丰、平3期,每期采样9次。通过观察,枯、丰、平3期氨氮浓度与其影响因子相差很大,呈季节性变化,因此对枯、丰、平3期分别建立预测模型,以便提高预测精度及准确度。

由于本文BP网络隐层中的神经元采用Sigmoid型变换函数,输出层的神经元采用纯线性变换函数,故学习前需将学习样本归一化,使各样本元素在(0,1)之间,这样才能使Sigmoid型变换函数真正起到非线性转移作用,保证网络对样本具有足够的输入敏感性和良好的拟合性,提高网络的收敛速度。

对输入样本依下式进行变换处理:

$$\bar{X}_i = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}} \cdot d_1 + d_2 \quad (1)$$

式中:  $X_{\max}$ 、 $X_{\min}$  分别为输入样本  $X_i$  的最大值和最小值,  $\bar{X}_i$  为处理后的样本输入值;  $d_1$ 、 $d_2$  分别取 0.998 和 0.001。

为了防止部分神经元达到过饱和状态,对输出样本亦需作如上变换。这样实际上将输入输出样本变换到[0.001, 0.999]区间,避免了0和1两个值。因为0和1恰好是Sigmoid型函数的极小值和极大值,要求联接权足够大才能使网络的输出值与其匹配,从而需要相当多的训练次数来不断修正权值,导致训练速度缓慢。

### 3.3 网络的训练和检验

经预处理后的训练样本数加载到所建立的人工神经网络上,即可用BP算法对网络训练。为了检验训练后神经网络解决问题的能力,通常需要测试样本对训练后的网络进行测试和检验。通过训练和测试的神经网络模型才可用于氨氮浓度的预测。随着数据的积累,网络的训练和测试应经常进行,以使神经网络适应氨氮浓度及其影响因子间新的动态变化规律和变化特征。

用有效性系数  $COE$ <sup>[9]</sup> 和相对误差  $EQ$ <sup>[5]</sup> 来判断经三种改进算法训练后网络的性能,比较拟合和预测效果,公式如下:

$$COE = 1 - \frac{\frac{1}{m} \sum_{i=1}^m (y_i - \hat{y}_i)^2}{\frac{1}{m-1} \sum_{i=1}^m (y_i - \bar{y}_i)^2} \quad (2)$$

$$EQ = \frac{\sum_{i=1}^m |y_i - \hat{y}_i|}{\sum_{i=1}^m y_i} \quad (3)$$

式中:  $y_i$  为实测值;  $\bar{y}_i$  为实测浓度均值;  $\hat{y}_i$  为计算值;  $m$  为样本数。 $COE$  的最佳值为 1, 低于 0.8 则拟合度较差。 $EQ$  的最佳值为 0, 高于 0.1 则拟合度较差。网络的其它学习参数如学习速率  $\eta$ 、动量因子  $\alpha$  以有效性系数最大作为优选的评价标准自动选取。

## 4 结果分析

### 4.1 三种改进算法拟合效果比较

以 1995 年~2000 年的数据作为训练样本, 2001 年的数据作为测试样本, 对 BP 网络进行训练仿真。根据网络多次训练结果, 确定隐层节点数为 10, 期望误差为 0.0001。枯水期、平水期和丰水期 3 种改进算法的拟合结果分别列于表 1, 表 2, 表 3。

表1 枯水期三种改进算法的氨氮浓度拟合结果

年份	traingdm 函数		trainlm 函数		trainbr 函数	
	COE	EQ	COE	EQ	COE	EQ
1995~2000	0.787	0.181	0.998	0.013	0.987	0.040
1995	0.906	0.088	0.997	0.014	0.982	0.035
1996	0.913	0.128	0.999	0.008	0.995	0.030
1997	0.833	0.304	0.999	0.005	0.999	0.031
1998	0.708	0.162	0.994	0.021	0.993	0.024
1999	0.700	0.255	0.999	0.007	0.976	0.067
2000	0.062	0.179	0.976	0.022	0.913	0.043
2001	0.760	0.169	0.871	0.094	0.939	0.069

表2 平水期三种改进算法的氨氮浓度拟合结果

年份	traingdm 函数		trainlm 函数		trainbr 函数	
	COE	EQ	COE	EQ	COE	EQ
1995~2000	0.745	0.211	0.997	0.023	0.994	0.036
1995	0.666	0.197	0.998	0.018	0.992	0.043
1996	0.001	0.166	0.929	0.038	0.894	0.047
1997	0.488	0.159	0.994	0.017	0.984	0.027
1998	0.344	0.381	0.971	0.094	0.945	0.129
1999	0.733	0.090	0.991	0.015	0.993	0.015
2000	0.572	0.489	0.999	0.017	0.999	0.024
2001	0.718	0.129	0.899	0.077	0.984	0.028

表3 丰水期三种改进算法的氨氮浓度拟合结果

年份	traingdm 函数		trainlm 函数		trainbr 函数	
	COE	EQ	COE	EQ	COE	EQ
1995~2000	0.970	0.121	0.997	0.044	0.999	0.027
1995	0.977	0.106	0.995	0.047	0.997	0.035
1996	0.759	0.104	0.882	0.071	0.956	0.040
1997	0.956	0.076	0.999	0.019	0.999	0.010
1998	0.852	0.151	0.984	0.055	0.990	0.042
1999	0.724	0.354	0.985	0.081	0.999	0.027
2000	0.958	0.178	0.995	0.073	0.996	0.068
2001	0.340	0.257	0.981	0.064	0.992	0.025

从表1、表2、表3可知,对传统BP网络学习算法作出不同改进的三种学习算法在实际应用中它们的性能各不相同。traingdm函数拟合精度最低,对7年的平水期模拟中,有效性系数全小于0.8,只有1999年的相对误差小于0.1。这是因为traingdm函数虽然采用了动量梯度下降反向传播算法,能够有效地抑制局部极小,但其收敛速度太慢,20000次的训练并把期望误差增大为0.01仍然难以找出最优的网络权值和阈值。而trainlm和trainbr函数均采用Levenberg-Marquardt优化方法,能够快速获得最优的网络权值和阈值,收敛速度较快。仔细比较trainlm和trainbr函数的模拟结果可以发现,trainlm函数在训练年(1995年~2000年)的拟合精度有时要比trainbr函数高,而在检验年(2001年)trainbr函数始终要比trainlm函数的拟合精度高。如在训练年的枯水期,trainlm函数的有效性系数都要比trainbr函数高,相对误差也都比trainbr函数低。推广能力是衡量神经网络性能好坏的重要标志。trainbr函数采用了Bayesian正则化方法,通过修正神经网络的训练性能函数来提高推广能力,防止出现“过度训练”。虽然有时候trainbr函数对训练样本的拟合精度要低于trainlm函数,但其有效性系数都高于0.8,甚至绝大多数都大于0.9,相对误差也是绝大多数都小于0.01。且在检验年,如枯水期和平水期trainbr函数的有效性系数要分别高于trainbr函数的有效性系数7.81%和9.45%。经多次数值实验可知,采用trainbr函数训练的BP网络稳定性要优于trainlm函数和traingdm函数,且通常只需几百次的训练就能使网络收敛,找到最优的网络权值和阈值。

图1为采用trainbr函数训练的1995年~2000年丰水期氨氮浓度拟合线,横坐标表示训练样本的采样次数,纵坐标为氨氮的浓度,其中实线为实测浓度,星号为计算浓度。




图1 利用trainbr函数训练的1995年~2000年丰水期氨氮浓度拟合线

由图1可知,绝大多数样本点的实测值与计算值  
是基本重合的,但有些样本点的实测值与计算值相  
差比较大,原因分析如下:

(1) 水中氨氮挥发不但受风速、水温和 pH 值  
影响,还受大气压变化及实际水质影响,但由于受实  
测资料限制,只选了水温、pH 值和非离子氨浓度作  
为其影响因子,影响了氨氮浓度的计算精度。

(2) BP 神经网络自身还存在着一些缺陷,特别  
是网络隐层的层数及隐层的节点数的选取尚无理论  
依据,通常是根据实验或经验确定,因此使网络具有  
很大的冗余性,也会影响拟合和预测效果。

#### 4.2 BP 神经网络模型与多元回归模型比较

采用 trainbr 函数训练 BP 网络,对2002年丰水  
期的9次氨氮采样浓度进行预测。同时建立多元线性  
回归模型,以便对神经网络模型与传统的统计建模  
方法预测结果进行比较。所建多元回归模型为:

$$Y = -0.1001X_1 - 0.4954X_2 + 0.8659X_3 + 0.3561 \quad (4)$$

式中: Y 表示氨氮浓度;  $X_1$ 、 $X_2$ 、 $X_3$  分别代表水温、  
pH 值、非离子氨浓度。

各模型预测结果见表4、表5。由表4、表5可以看  
出,神经网络模型的预测值最大误差和相对平均误差  
均小于多元回归模型的预测值。在多元回归模型的  
预测结果中,有一个预测值是负的,说明氨氮浓度  
与其影响因子之间应满足更复杂的函数关系,多元  
线性回归模型不适合而导致预测出不符合实际情况  
的氨氮浓度值。BP 神经网络氨氮浓度预测模型可全  
面地考虑影响氨氮浓度的各种因子,不需要考虑数  
学模型的内部结构,不必对变量之间的关系作出任  
何前提假设,不需要人为地确定因子权重,只需利用  
在学习阶段所获得的知识,通过对已知样本的学习  
和训练,找到输入和输出变量的内在关系。这种处理  
方式能够更好的符合客观实际,因而得到的结果将  
具有更大的可靠性。

#### 4.3 神经网络外推能力的讨论

上述预测模型虽对2002年的丰水期作出了比较  
令人满意的预测,但对枯水期和平水期的预测效果  
却不是很理想,因为神经网络模型的外推能力较差。  
神经网络经过训练样本和测试样本的学习和检验,  
对跟训练样本和测试样本具有相同数据结构并在其  
数据范围之内的预测样本能作出比较令人满意的预  
测。1995年~2002年的丰水期数据分布比较均匀,输  
入样本预处理后,最大值和最小值都集中在训练样  
本中,这样就能让网络对样本充分学习,并有所创

新,对在其数据范围之内的样本容错性好,作出比较  
令人满意的预测。表6是2002年平水期学习样本经调  
整后的预测结果,9次采样只有1次采样浓度的相对  
误差大于10%,预测效果比较理想。

表4 2002年丰水期氨氮浓度 BP 神经网络模型  
预测结果及回归模型比较 mg/L

预测 样本	实测值	BP 模型		多元线性回归模型	
		预测值	实际误差	预测值	实际误差
1	0.090	0.094	0.004	0.054	-0.036
2	0.130	0.128	-0.002	0.103	-0.027
3	0.368	0.379	0.011	0.436	0.068
4	0.223	0.218	-0.005	0.227	0.004
5	0.064	0.059	-0.005	0.030	-0.034
6	0.236	0.239	0.003	0.259	0.023
7	0.064	0.059	-0.005	-0.013	-0.077
8	0.088	0.085	-0.003	0.039	-0.049
9	0.262	0.260	-0.002	0.307	0.045

注:实际误差=预测值-实测值。

表5 两种模型相对误差比较

项 目	BP 模型	多元线性回归模型
预测平均相对误差/%	-1.584	-26.921
预测最大相对误差/%	-8.187	-120.133
预测相对误差大于 10%的样本个数/个	0	7

注:相对误差=(预测值-实测值)/实测值。

表6 2002年平水期学习样本经调整后的氨氮浓度预测结果

预测 样本	实测值 /(mg·L <sup>-1</sup> )	预测值 /(mg·L <sup>-1</sup> )	实际 误差	相对误差 /%
1	0.112	0.118	0.006	5.436
2	0.116	0.129	0.013	10.923
3	0.136	0.132	-0.004	-2.685
4	0.156	0.162	0.006	3.642
5	0.144	0.130	-0.014	-9.895
6	0.168	0.163	-0.005	-3.221
7	0.172	0.169	-0.003	-1.547
8	0.164	0.165	0.001	0.825
9	0.136	0.147	0.011	8.387

注:实际误差=预测值-实测值

相对误差=(预测值-实测值)/实测值

## 5 结论与认识

本文采用 BP 网络的三种改进算法,对洞庭湖  
桂花园断面8年(1995年~2002年)的氨氮浓度和其  
影响因子实测资料进行分析,建立了基于 BP 神经  
网络的氨氮浓度预测模型。通过模型建立和本文研  
究可以得出以下结论:

(1) 本文采用的三种改进算法, trainbr 函数采用了 Levenberg—Marquardt 优化方法与 Bayesian 正则化方法, 具有较好的推广能力, 预测精度高于 traingdm 函数和 trainlm 函数, 且经其训练的网络具有较好的稳定性。

(2) 作为数据驱动型模型的 BP 网络, 用来建模的学习样本质量至关重要, 它直接影响网络的预测精度。trainbr 函数具有较好的推广能力, 但其外推能力仍然较差。文献[10]采用引入部分常用公式的结果来增加样本以便让 BP 网络对样本充分学习, 但是如果这种类型的训练样本过多, 神经网络模型逼近的函数就会趋近于传统公式, 从而失去了采用新模型的意义。所以今后应寻求能增强神经网络外推能力的算法来改进这项有意义的工作。

(3) BP 神经网络突出的优点是具有很强的非线性映射能力和柔性的网络结构, 与传统的统计建模方法相比, 预测精度较高, 能较好地反映洞庭湖氨氮浓度与其影响因子之间变化规律。

通过 BP 神经网络建模的方法, 很好地再现了氨氮浓度与其影响因子之间复杂的非线性函数关系, 且预报精度较高。但是人工神经网络模型并不能完全取代有物理意义的模型, 因此应考虑加入更多的物理影响因子以提高氨氮浓度的预测精度。在预

测精度要求较高的情况下, 本文所建立的预测模型可给出未来几年氨氮浓度比较准确的变化趋势。

#### 参考文献:

- [1] 姜加虎, 黄群. 洞庭湖区生态环境退化状况及其原因分析[J]. 生态环境, 2004, 13(2): 277—280.
- [2] 毛德华, 夏军. 洞庭湖湿地生态环境问题及形成机制分析[J]. 冰川冻土, 2002, 24(4): 444—451.
- [3] 陈守余, 周梅春. 人工神经网络模拟实现与应用[M]. 武汉: 中国地质大学出版社, 2000.
- [4] 冯利华. 基于神经网络的洪水预报研究[J]. 自然灾害学报, 2000, 9(2): 45—48.
- [5] 袁飞, 任立良, 姜红梅, 等. MATLAB 神经网络工具箱在径流模拟中的应用[J]. 人民长江, 2003, 34(6): 38—40.
- [6] 谢作涛, 张小峰, 谈广鸣. 洞庭湖城陵矶流量逐日预报研究[J]. 武汉大学学报(工学版), 2004, 37(2): 5—7.
- [7] 庄源益, 戴树桂, 张明顺. 水中氨氮挥发影响因素探讨[J]. 环境化学, 1995, 14(4): 343—346.
- [8] 李奎贤, 宋桂秋, 张东, 等. BP 神经网络法在产品质量预测中的应用[J]. 东北大学学报(自然科学版), 2001, 22(6): 682—684.
- [9] 王玲, 朱传宝, 吴道喜. 人工神经网络评价城市化对径流生成的影响[J]. 人民长江, 2002, 33(3): 21—22.
- [10] 张鹏, 李玉柱, 徐照明. 基于人工神经网络的挑流冲刷预报[J]. 清华大学学报(自然科学版), 2003, 43(11): 1538—1541.