

基于小波分析与 BP 神经网络的西湖 叶绿素 a 浓度预测模型

卢志娟¹, 朱 玲², 裴洪平¹, 汪 勇³

(1. 浙江大学(西溪校区)环境与资源学院环境科学系, 杭州 310028; 2. 浙江省辐射环境监测站, 杭州 310012;
3. 浙江省环境保护科学设计研究院, 杭州 310007)

摘要:小波神经网络是基于小波分析理论所构造的一种分层的、多分辨率的新型人工神经网络。选择合适的小波基和分解尺度对西湖水体 Chl-a 进行小波分析, 将原序列分解成一个低频概貌分量和多个高频细节分量, 再通过 BP 网络建立西湖叶绿素 a 浓度短期预测模型 I 和模型 II。模型 I 将小波分析去除高频细节信息后的低频概貌部分作为输入变量预测 Chl-a 含量; 模型 II 则对低频部分和高频部分分别进行预测, 最后汇总各分网络输出得到最终结果。对确证集预测时, 模型 I 的平均误差为 4.4%, 模型 II 仅为 1.9%, 且误差范围较模型 I 小, 表明模型 II 具有较高的预测精度和稳定性。最后运用模型 II 进行水质预测, 预测值与实际值的平均相对误差为 6.4%, 并选取 3 号点(中山码头)进行模型的泛化, 平均相对误差为 6.9%, 取得了较理想的预测效果, 说明小波神经网络能成功预测西湖水体中 Chl-a 含量的短期变化趋势, 为西湖水质管理提供科学依据。

关键词:小波分析; BP 神经网络; Chl-a; 短期预测; 杭州西湖

文章编号: 1000-0933(2008)10-4965-09 中图分类号: Q178.15, Q945 文献标识码: A

The model of chlorophyll-a concentration forecast in the West Lake based on wavelet analysis and BP neural networks

LU Zhi-Juan¹, ZHU Ling², PEI Hong-Ping¹, WANG Yong³

1 Department of Environmental Science, College of Environment and Resource, Xixi Campus Zhejiang University, Hangzhou 310028, China

2 Zhejiang Province Environmental Radiation Monitoring Center, Hangzhou 310012, China

3 Environmental Science Research and Design Institute of Zhejiang Province, Hangzhou 310007, China

Acta Ecologica Sinica, 2008, 28(10): 4965 ~ 4973.

Abstract: Wavelet neural network is a new kind of hierarchical and multiresolution artificial neural network which based on wavelet analysis theory. In this paper, we choose an appropriate wavelet base and decompose scale to analysis chlorophyll-a of the West Lake. We divide the original sequence into a low frequency and several high frequency parts, then establish model I and model II for short-term prediction of chlorophyll-a concentration in the West Lake through BP neural networks. The model I uses low frequency part only as input for network to forecast the content of chlorophyll-a, while the model II uses the low frequency and the high frequency part as inputs, then summarizes the outputs to get the final product. Comparing with the two models, we can see the average error of model II is smaller than of model I, and the scope of error is also narrow. That means the precision and stability of model II are higher than of the model I. Finally, we forecast the water quality with the model II. That shows the average relative error between predictive value and actual value is 6.4%. By selecting the third pot (Zhongshan dock) to generalize the model II, which enable the average error is

基金项目:国家自然科学基金资助项目(39170169)

收稿日期:2007-05-18; **修订日期:**2008-01-09

作者简介:卢志娟(1983~), 女, 江苏盐城人, 硕士生, 主要从事水域生态研究. E-mail: zhijuanlu@163.com

Foundation item: The project was financially supported by the National Natural Science Foundation of China (No. 39170169)

Received date: 2007-05-18; **Accepted date:** 2008-01-09

Biography: LU Zhi-Juan, Master candidate, mainly engaged in waters ecology. E-mail: zhijuanlu@163.com

6.9%. The result indicates that wavelet neural network can successfully forecast the content of Chlorophyll-a in the West Lake, so can provide scientific guidance for the West Lake management.

Key Words: wavelet analysis; BP neural network; chlorophyll-a; short-term prediction; the West Lake

杭州西湖是我国著名的风景旅游湖泊,也是典型的富营养化浅水湖泊。80年代前后,杭州市政府实施了环湖砌岸、截污、局部疏浚、引水等一系列综合整治措施,使西湖水质得到了一定程度的改善,但西湖富营养化趋势仍未得到有效控制。因此,进一步研究能精确模拟湖泊富营养化变化趋势的模型,更好地应用于湖泊富营养化的管理过程中,将是西湖富营养化治理的一个重要方向^[1]。

神经网络具有强大的非线性处理问题的能力,在数据拟合、函数逼近等方面显示出较大优势,但存在因数据随机性大而出现“过拟合”现象,导致预测数据不精确^[2]。小波分析能有效地从信号中提取所需信息,实现时域和频域的高分辨局部定位。小波神经网络将神经网络的自学习能力和小波的局部特性结合,具有自适应分辨率和良好的容错能力,已成功应用到水质评价^[3]、水文预测^[4]等诸多相关领域,并取得了比传统方法更为科学的结果。

Chl-a 是水体富营养化的重要指标之一,通过测定 Chl-a 含量能够在一定程度上反映水质状况^[5],故本文以 Chl-a 为预测对象。通过小波分析对原数据进行处理,使低频和高频部分分离,根据输入变量的不同,利用 BP 网络建立两种模型并进行比较,选择预测精度和稳定性较高的模型对西湖叶绿素 a 浓度进行短期预测,为西湖富营养化管理提供科学依据。

1 研究材料

本文所采用的数据为 2000~2001 年采集的西湖水质参数数据。根据湖区的分布、近岸环境状况及游船往来等情况,共设 8 个采样点^[6](采样点分布见图 1),每月进行 1 次水质分析。监测项目主要包括水温 T_w ($^{\circ}\text{C}$),透明度 SD (cm),溶解氧 DO ($\text{mg}\cdot\text{L}^{-1}$),电导率 Ec ($\text{m}\cdot\text{s}^{-1}$),pH 值,总磷 TP ($\text{mg}\cdot\text{L}^{-1}$),总氮 TN ($\text{mg}\cdot\text{L}^{-1}$)以及叶绿素 a Chl-a ($\mu\text{g}\cdot\text{L}^{-1}$)等 8 个指标。

表 1 给出了各采样点的主要水质状况。从表 1 可看出,7 号点(湖心)的各主要水质因子年平均值均处于 8 个监测点的水质因子年平均值的中间,其水质状况基本可以代表全湖的水质状况。因此,从地理位置和水质因子分析可知,7 号点的水质在 8 个监测点中较能代表西湖水质状况,本文以 7 号点(湖心)作为研究对象。

西湖常规监测的频率是每月 1 次且监测时间都在月末,这些数据能基本反应西湖水生生态状况的变化趋势,但是无论对网络训练、还是小波分析来说,数据量呈现不足,也不符合文章作短期预测的本意。因此,本文在原有基础上,在相邻两个时间点监测数据间,插入 3 个值,使西湖 7 号点的数据频率由每月提高到每周(把每个月看成四周)^[7]。

2 小波神经网络模型构建

2.1 BP 网络结构及原理

本文采用的误差反向传播 BP 网络模型选取 3 层神经元,包括输入层,隐层和输出层。输入层接受外部




图 1 西湖各采样点分布图

Fig. 1 Sampling sites in West Lake

在原有基础上,在相邻两个时间点监测数据间,插入 3 个值,使西湖 7 号点的数据频率由每月提高到每周(把每个月看成四周)^[7]。

信息;隐层用来表示和存储知识,其层数和节点的个数决定了神经网络的复杂度;输出层输出结果。各相邻两层之间单方向互联,如图 2 所示。

BP 网络的学习思路是:给定一个网络的输入模式,由输入层单元传递到隐层单元,经处理后,传递到输出层单元。由输出层处理后产生一个输出模式,这个过程称为前向传播。如果输出响应与期望输出模式有误差时,就转入误差后向传播,将误差值沿连接通路逐层反向传递并修改各层的连接权值和阈值。如此不断重复向前传播和误差后向传播过程,直到各个训练模式都满足要求时,结束学习过程。

表 1 主要水质因子年平均值随监测点的变化

Table 1 Variation of annual mean values of main water quality factors at each sampling spot

项目 Item		样点 Spot							
		1	2	3	4	5	6	7	8
T_w (°C)	平均 Average	18.13	18.16	18.26	18.31	18.31	18.49	18.55	18.53
	范围 range	6.1 ~ 32.8	6.4 ~ 33.2	6.4 ~ 33.3	6.2 ~ 33.5	6.1 ~ 32.8	5.8 ~ 33.2	6.2 ~ 33.1	7 ~ 33.4
SD (cm)	平均	49.5	46.8	50.8	54.7	55.2	50.3	51.3	77.5
	范围	30 ~ 85	26 ~ 80	30 ~ 93	32 ~ 98	32 ~ 98	30 ~ 92	31 ~ 92	56 ~ 90
DO ($\text{mg} \cdot \text{L}^{-1}$)	平均	7.33	6.47	7.68	7.07	9.18	8.87	8.85	7.04
	范围	3.05 ~ 10.26	4.23 ~ 9.71	4.5 ~ 10.57	3.73 ~ 9.66	4.67 ~ 11.96	6.18 ~ 12.68	5.41 ~ 11.17	3.87 ~ 9.72
Ec ($\text{m} \cdot \text{s}^{-1}$)	平均	206.1	220.4	209.8	251.9	234.0	215.2	209.3	260.1
	范围	168 ~ 261	161 ~ 315	172 ~ 253	200 ~ 315	195 ~ 293	168 ~ 262	175 ~ 253	145 ~ 455
pH	平均	8.81	8.74	8.57	8.08	8.47	8.58	8.46	7.92
	范围	7.6 ~ 11	7.5 ~ 10.6	7.4 ~ 10.3	7.3 ~ 10.3	7.2 ~ 10.1	7.5 ~ 10.2	7.5 ~ 10.3	7.1 ~ 9.5
TP ($\text{mg} \cdot \text{L}^{-1}$)	平均	0.154	0.177	0.162	0.177	0.145	0.147	0.135	0.105
	范围	0.07 ~ 0.21	0.07 ~ 0.27	0.09 ~ 0.22	0.13 ~ 0.24	0.06 ~ 0.21	0.09 ~ 0.20	0.11 ~ 0.20	0.06 ~ 0.18
TN ($\text{mg} \cdot \text{L}^{-1}$)	平均	2.10	2.06	2.19	2.96	2.59	2.42	2.37	2.64
	范围	1.66 ~ 2.96	1.36 ~ 2.95	1.35 ~ 3.54	1.82 ~ 3.80	1.86 ~ 3.52	1.32 ~ 3.26	1.63 ~ 3.42	1.43 ~ 3.96
Chl-a ($\mu\text{g} \cdot \text{L}^{-1}$)	平均	83.3	101.7	78.6	83.7	71.0	75.4	82.0	20.6
	范围	24.0 ~ 153	31.8 ~ 181	28.6 ~ 169	34.3 ~ 181	35.3 ~ 123	34.2 ~ 149	24.5 ~ 176	5.4 ~ 46.8

2.2 小波多分辨率分析

小波分析可以对信号进行多尺度分析,有效地从信号中提取所需的信息,实现时域和频域的高分辨率定位。多分辨率分析就是寻找一组低通、高通滤波器组,随着分解尺度由小到大的变化,将信号不断向下分解,得到一系列不同分辨率的低频概貌信号和低频细节信号,实现在各尺度上由粗到精地观察目标信号。将这些得到的低频和高频信号通过重构过程可以还原出信号原貌。

小波基的最优选择是小波分析的重要步骤。常用的小波基主要有:haar,dbN,biorNr,Nd,coifN等。目前主要根据小波变换方法处理信号的结果与理论值的误差判定小波基的好坏,并由此选定小波基。众多研究表明,dbN小波基能较好地分析时间序列问题^[8]。因此本研究将选取dbN小波基作为核心变换工具,通过比较不同N值所产生的预测精度,确定一种db小波基进行分析。

对于任一个原序列s,小波变换可将其分解为低频部分ca1和高频部分cd1,然后对低频部分ca1进一步




图 2 三层 BP 网络模型

Fig. 2 Three layers of BP network model

分解,如此重复就可以得到任意尺度上的一个低频概貌部分 caN 和几个高频细节部分 $cd1 \sim cdN$ 。在一定预测精度要求下,分解尺度必须适中,本文通过比较不同尺度所产生的低频概貌与原序列的相似程度来选择分解尺度。

2.3 建模方法

经分析选择合适的小波基和分解尺度对 Chl-a 进行小波分析,将序列分解成一个低频概貌分量和多个高频细节分量,并在此基础上建立模型 I 和模型 II。

2.3.1 模型 I

将小波分析去除细节信息后的低频概貌部分作为 BP 神经网络的输入变量,选择相应参数,建立基于小波变换的 BP 网络预测模型 I (模型流程见图 3)。

2.3.2 模型 II

通过小波分析,得到一个低频概貌分量和多个高频细节分量,利用不同的 BP 网络对各分量分别预测,最后汇总各分网络输出得到 Chl-a 的预测结果,由此建立模型 II (模型流程见图 4)。




图3 模型 I 流程图

Fig. 3 The flow chart of model I




图4 模型 II 流程图

Fig. 4 The flow chart of model II

3 结果与讨论

3.1 Chl-a 的小波分析

3.1.1 小波基和分解尺度的确定

将 2000 年 1 月至 2001 年 7 月插值后 73 周的 Chl-a 含量作为小波分析的原序列 s 。

当 dbN 中的 N 取 1, 3, 5, 7 时,原序列与其两层分解的低频概貌的比较如图 5 所示。

从图 5 可看出,当 $N=1$ 时,分解序列呈锯齿状,随着 N 的增大,曲线越来越平滑,并趋近原序列,但当 $N=5, 7$ 时,曲线过于平滑,不能很好地体现原来的峰值。相比而言, $db3$ 对原序列概貌有较好地体现。因此选择 $db3$ 作为 Chl-a 小波分析的小波基。

当分解尺度分别取 1, 2 或 3 时,原序列 s 与低频概貌 caN 的比较如图 6 所示。由图可知,随着 N 的增大,分解序列越来越平滑,但当 $N=3$ 时,曲线过于平滑,不能充分体现原序列概貌。蒋晓辉等^[9]在作径流量的分析时,认为当 N 取 2 时,最适合小波分析,故选择尺度 2 对 Chl-a 进行两层小波分析。




图5 不同 N 值的小波分析结果

Fig. 5 The result of wavelet analysis with different value of N




图6 不同尺度下的低频概貌 caN

Fig. 6 The result of profile under low-frequency with different scale

3.1.2 小波分析

根据以上分析,选择 db3 对 Chl-a 进行两层小波分析,小波分析结果如图 7 所示。其中, s 为 Chl-a 原数据, $ca2$ 为其低频概貌部分, $cd1$ 、 $cd2$ 为其高频细节部分。由图 7 可知, $ca2$ 与原序列最为接近,体现了 Chl-a 的变化趋势,但一些小的波动,如第 14、17 个月的变化未得到很好体现; $cd2$ 为细节部分,对原序列的一些峰值如第 8 个月有较好地表达;相比之下, $cd1$ 则含较多的随机成分,在两个峰值处(第 8 个月和第 19 个月)呈现较大波动。

3.2 建模参数选择

3.2.1 输入变量选择

在模型 I 中,选择与输出变量(Chl-a)相关性大的参数作为输入变量。根据各水质参数相关性分析(见表 2),与 Chl-a 相关系数较大的水质参数有 T_w 、 Ec 和 SD 。此外,小波分析结果中的低频概貌分量 $ca2$ 体现了 Chl-a 的一般性规律,与 Chl-a 相关性极大。因此选择 T_w 、 Ec 、 SD 以及 $ca2$ 分量作为模型 I 的输入变量。

表 2 7 号点各水质参数相关性分析

Table 2 Correlation analysis of various water quality factors at spot 7								
参数 Parameter	T_w ($^{\circ}C$)	SD (cm)	DO ($mg \cdot L^{-1}$)	Ec ($m \cdot s$)	pH	TP ($mg \cdot L^{-1}$)	TN ($mg \cdot L^{-1}$)	Chl-a ($\mu g \cdot L^{-1}$)
$T_w(^{\circ}C)$	1.00							
$SD(cm)$	-0.73	1.00						
$DO(mg \cdot L^{-1})$	-0.38	0.28	1.00					
$Ec(m \cdot s)$	-0.84	0.64	0.31	1.00				
pH	0.64	-0.64	0.08	-0.51	1.00			
$TP(mg \cdot L^{-1})$	0.15	-0.22	-0.08	-0.21	-0.07	1.00		
$TN(mg \cdot L^{-1})$	0.03	0.30	0.02	0.30	-0.05	-0.54	1.00	
$Chl-a(\mu g \cdot L^{-1})$	0.75	-0.76	-0.60	-0.72	0.46	0.11	-0.22	1.00

在模型 II 中,各分网络的输出变量分别为 $ca2$ 、 $cd2$ 和 $cd1$,应根据各分网络的输出变量选择输入变量。 $ca2$ 为原序列 Chl-a 的趋势项,相关性较大的有 T_w 、 Ec 、 SD 以及 Chl-a。因此选择 T_w 、 Ec 、 SD 以及 Chl-a 作为预测 $ca2$ 分网络的输入变量; $cd2$ 和 $cd1$ 为原序列 Chl-a 的细节分量,基本上只受 Chl-a 影响。因此选择 Chl-a 为 $cd1$ 和 $cd2$ 分网络的输入变量。

3.2.2 数据集的划分

本文构建网络的目的是短期预测,即期望预测下一周的 Chl-a 含量,因此由第 N 周的若干因子(即输入变量)与第 $N+1$ 周的 Chl-a(即输出变量)组成一组样本对。根据 7 号点的实测数据,共有 72 组样本对。由于样本对容量有限,确定第 1~64 组样本对为网络拟合的训练集,第 65~67 组样本对为确证集,第 68~72 组样本对验证模型可行性。

3.3 模型比较

由于 BP 算法存在不稳定现象,即同一组训练确证数据重复运行得到的结果并不总是一致的^[10]。基于重复预测原理,本文通过 30 次重复运行网络提取平均值的方法,比较模型 I、模型 II 的稳定性和预测精度。模型 I 与模型 II 的训练集仿真相关性分析如图 8 所示。确证集的预测结果误差分析如表 3 所示。

由图 8 可知,训练集的仿真结果与实测值曲线重叠性模型 I 比模型 II 好,表明模型 I 的学习能力强于模型 II。

由表 3 可知,模型 II 的平均误差比模型 I 小,而且误差范围也更窄,3 周平均误差方差模型 I 为 4.4%,模型 II 仅为 1.9%,表明模型 II 的预测精度和稳定性均高于模型 I。




图 7 7 号点 Chl-a 小波分析数值变化曲线

Fig. 7 The fluctuations of the result of wavelet analysis at spot 7

表 3 7 号点预测结果误差分析

Table 3 Error analysis of the predicted values at spot 7

类别 Taxa	No. 66 (%)		No. 67 (%)		No. 68 (%)		No. 66~68 (%)		平均误差 标准方差 SS (%)
	平均误差	误差范围	平均误差	误差范围	平均误差	误差范围	平均误差	误差范围	
模型 I model I	7.5	0.2~15.7	9.4	0.6~19.6	7.8	2.8~17.5	8.3	1.7~16.2	4.4
模型 II model II	4.1	1.07~6.7	3.9	0.6~5.6	4.7	0.2~7.9	4.2	1.6~6.1	1.9

平均误差 Average error; 误差范围 Erroneous scope; 平均误差标准方差 Standard deviation of average error

综上所述,模型 I 的学习能力强于模型 II,但模型 II 的预测能力优于模型 I,表明模型 II 更适合 7 号点 Chl-a 含量的预测,而模型 I 则出现“过拟合”现象。由表 3 可知,在 30 次模型运行过程中,模型 II 单次预测的相对误差在 0.2% 至 7.9% 之间,因此,本研究认为通过小波分析的各分量分别预测的模型 II 更适合西湖水体 Chl-a 含量的预测,且单次预测即可获得相对理想的结果。

3.4 模型 II 的应用

为了研究该模型在实际操作中的可行性,运用模型 II 对第 69~73 周 Chl-a 含量进行预测。结果见表 4。

表 4 7 号点第 69~73 周预测结果及误差分析

Table 4 Error analysis of the predicted values from No. 69 to No. 73 at spot 7

周次 Weeks	实测值 Actual value ($\mu\text{g}\cdot\text{L}^{-1}$)	预测值 Predictive value ($\mu\text{g}\cdot\text{L}^{-1}$)	相对误差 Relative error (%)	平均相对误差 Average error (%)	均方根误差 Root-mean-square error ($\mu\text{g}\cdot\text{L}^{-1}$)
No. 69	95.2	91.3	-4.1	6.4	11.6
No. 70	99.8	101.0	1.2		
No. 71	110.5	115.7	4.7		
No. 72	132.8	121.1	-8.8		
No. 73	168.3	190.5	13.2		




图 8 7 号点训练集仿真相关性分析

Fig. 8 Correlation analysis of simulated values of training set at spot 7

由表可知,第 69 至 73 周的平均相对误差为 6.4%,RMSE 为 11.6 $\mu\text{g/L}$ 。前 4 周的绝对误差均在 10% 以内,第 73 周的误差偏高,为 13.2%,但对于西湖这样复杂的水生生态系统,这个误差在允许范围内。表明运用模型 II 预测西湖 Chl-a 的含量是可行的。

3.5 模型 II 的泛化

为进一步检验模型 II 在西湖其它点的适应性能,选取 3 号点(中山码头)进行网络的泛化。对 3 号点 2001 年 4 至 7 月(第 61 至 73 周)的 Chl-a 含量进行预测,预测值与实测值的相关性分析如图 9 所示,预测结果误差分析如表 5 所示。

由图 9 及表 5 知,预测值与实测值的曲线吻合性较好,其线性回归模型的相关系数达到 0.9887,平均相对误差控制在 10% 以内,预测值与实测值的均方根误差为 7.8 $\mu\text{g}\cdot\text{L}^{-1}$ 。表明本文建立的小波神经网络模型 II 具有较好的泛化性能。

4 结论

(1)文中通过小波多分辨分析对原始数据进行处理后,对低频概貌和高频细节分别预测的模型 II,避免了直接用神经网络对原始数据进行预测时对一些高频突变数据不能很好地进行学习的问题。

(2)运用模型 II 对 7 号点(湖心)及 3 号点(中山码头)进行叶绿素 a 浓度进行预测时,均取得了较好的预测结果,表明基于小波分析的 BP 神经网络具有较好的泛化性能和稳定性。




图9 3号点第61~73周预测结果相关性分析

Fig.9 Correlation analysis of predicted values from No. 61 to No. 73 at spot 3

表5 3号点第61~73周预测结果误差分析

Table 5 Error analysis of the predicted values from No. 61 to No. 73 at spot 3

周次 Weeks	实测值 actual value ($\mu\text{g}\cdot\text{L}^{-1}$)	预测值 predictive value ($\mu\text{g}\cdot\text{L}^{-1}$)	相对误差 relative error (%)	周次 Weeks	实测值 actual value ($\mu\text{g}\cdot\text{L}^{-1}$)	预测值 predictive value ($\mu\text{g}\cdot\text{L}^{-1}$)	相对误差 relative error (%)
No. 61	9.3	8.8	-5.4	No. 69	77.6	83.3	7.3
No. 62	17.3	16.1	-6.9	No. 70	80.1	78.2	-2.4
No. 63	49.0	53.3	8.8	No. 71	88.8	81.0	-8.8
No. 64	78.7	73.4	-6.7	No. 72	113.0	114.4	1.2
No. 65	85.6	88.5	3.4	No. 73	167.3	189.5	13.3
No. 66	82.6	76.2	-7.7	平均相对误差 Average error (%)			6.9
No. 67	79.2	85.3	7.6	均方根误差 ($\mu\text{g}\cdot\text{L}^{-1}$)			7.8
No. 68	77.6	85.2	9.8	Root-mean-square error			

(3) 众多研究表明 BP 网络存在不稳定现象,而本研究中基于小波分析构建的小波神经网络,能较好地避免因 BP 网络的不稳定而产生可靠性降低的问题。

研究表明,本文所建立的小波神经网络将小波多辨分析和神经网络强大的非线性逼近功能相结合,具有自适应分辨率和良好的容错能力,模型稳定且预测精度高,能有效地预测西湖叶绿素 a 浓度的短期变化趋势,并具有较好的泛化性能,适合西湖水质变化的短期预测,为西湖水质管理提供了决策依据。

References:

- [1] Pei H P. Research of Eutrophication model for West Lake. Journal of Biomathematics, 2001, 16(5):596—603.
- [2] Guneralp B, Barlas Y. Dynamic modeling of a shallow freshwater lake of ecological and economic sustainability. Ecological Modeling,2003, 167: 115—138.
- [3] Li XB, Ding J, Li H Q. The combination forecasting using artificial neural network based on wavelet transformed sequences. Journal of Hydraulic Engineering, 1999, 30(2):1—4.
- [4] Zeng G M, Lu H W, Jin X C, *et al.* Assessment of the Water Quality and Nut rition of the Dongting Lake with Wavelet Neural Network. Journal of Hunan University, 2005, 32(1):91—94.
- [5] Zhou H. Correlation between Water Quality and Chl-a of Phytoplankton and the Countermeasure of Inhibiting Algae Growth in West Lake, Hang

- Zhou. Journal of Zhejiang University (Neo-Confucianism), 2001, 28(4):439—442.
- [6] Pei H P, Ma J Y. Study on the algal dynamic model for West Lake, Hangzhou. Ecological Modeling, 2002, 148:67—77.
- [7] Pei H P, Luo N N. Applications of Back propagation neural network for predicting the concentration of chlorophyll-a in West Lake. Acta Ecologica Sinica, 2004, 24 (2): 246—251.
- [8] Zhou W, Gui L, Zhou L. High-level technology of MATLAB Wavelet Analysis. Xi'an: Xidian University, 2006.51—63.
- [9] Jiang X H, Liu C M. Radial Basis Function Networks Based on Wavelet Analysis for the Annual Flow Forecast. Journal of Applied Sciences, 2004, 22(3):411—414.
- [10] Thomann R V, Mueller J A. Principles of Surface Water Quality Modeling and Control. New York: Harper and Row, 1987.

参考文献:

- [1] 裴洪平. 杭州西湖富营养化模型研究. 生物数学学报, 2001, 16(5):596~603.
- [3] 李贤彬, 丁晶, 李后强. 基于子波变换序列的人工神经网络组合预测. 水利学报, 1999, 30(2):1~4.
- [4] 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. 湖南大学学报, 2005, 32(1):91~94.
- [5] 周宏. 杭州西湖水体中叶绿素 a 含量与水质的关系. 浙江大学学报(理学版), 2001, 28(4):439~442.
- [7] 裴洪平, 罗妮娜. 利用 BP 神经网络方法预测西湖叶绿素 a 的浓度. 生态学报, 2004, 24 (2): 246~251.
- [8] 周伟, 桂林, 周林. MATLAB 小波分析高级技术. 西安: 西安电子科技大学出版社, 2006.51~63.
- [9] 蒋晓辉, 刘昌明. 基于小波分析的径向基神经网络年径流量预测. 应用科学学报, 2004, 22(3):411~414.