

基于 NARX 神经网络的千岛湖藻类短期预测模型构建

李 未¹, 朱梦圆¹, 王裕成², 朱广伟¹

1. 中国科学院南京地理与湖泊研究所, 湖泊与环境国家重点实验室, 江苏 南京 210008

2. 杭州市生态环境局淳安分局, 浙江 杭州 311700

摘要: 局部水域的藻类异常增殖现象逐渐成为千岛湖面临的水环境保护难题. 构建以数据驱动的水华预测模型, 实现对重点水域叶绿素 a (Chla) 浓度短期动态变化的预测, 是快速应对潜在水华风险的有效手段之一. 鉴于 NARX 神经网络在预测非平稳时间序列动态特征方面的优势, 以千岛湖国控监测断面小金山 2016—2019 年 Chla 的高频时间序列作为研究对象, 对 Chla 剖面数据进行沿深平均、缺失值插补后, 分别以连续 3 d 和连续 7 d 的 Chla 浓度作为输入, 构建了基于 NARX 神经网络的藻类预测模型, 用于预测未来 0.5~7 d Chla 浓度的变化, 探讨了相关参数设置、训练及评价方法, 并针对不同的预见期分析了模型性能. 结果表明: ① 模型预测性能稳定, 预测值与实测值相关系数保持在 0.8~0.9 之间, 均方误差在 15~30 之间. ② 随着预见期的变化, 模型性能不同. 其中, 在未来 0.5~4 d 的预测中, 使用连续 3 d 的 Chla 浓度作为输入的预测效果较好; 在未来 4.5~7 d 的预测中, 使用连续 7 d 的 Chla 浓度作为输入的预测效果较好. 研究显示, 该模型可以较为准确地预测未来 0.5~7 d 的 Chla 浓度, 可为构建以数据驱动的千岛湖水华监测预警系统提供科学依据.

关键词: 藻类预测; 高频率序列; 神经网络; 千岛湖

中图分类号: X524

文章编号: 1001-6929(2022)04-0918-08

文献标志码: A

DOI: 10.13198/j.issn.1001-6929.2022.02.17

Short-Term Forecasting Model for Algae Based on NARX Neural Network in Qiandaohu Reservoir

LI Wei¹, ZHU Mengyuan¹, WANG Yucheng², ZHU Guangwei¹

1. State Key Laboratory of Lake Science and Environment, Nanjing Institute of Geography and Limnology, Chinese Academy of Sciences, Nanjing 210008, China

2. Hangzhou Bureau of Ecology and Environment Chun'an Branch, Hangzhou 311700, China

Abstract: In recent years, Qiandaohu Reservoir has suffered from abnormal growth of algae. Short-term forecasting models of algal blooms driven by data can be built to predict the temporal variation of chlorophyll-a (Chla) concentration in some concern water. It is considered effective to deal with potential bloom risks. NARX (nonlinear autoregressive with external input) neural network has a competitive advantage in predicting the dynamic characteristics of non-stationary time series. In this paper, a high-frequency monitoring buoy dataset of Xiaojinshan Station, a state-controlled section in Qiandaohu Reservoir from 2016 to 2019 was handled with vertical integration and missing value interpolation. An algal bloom forecasting model based on NARX neural network was then built to predict the temporal variations of Chla over the next 0.5-7 days. To drive the model, Chla concentrations from the first 3 and 7 days were used as initial inputs, respectively. Parameters settings, trainings and evaluations were discussed, and model performance was analyzed according to different foreseeable periods. The results showed that: (1) The performance of the model was steady. The correlation coefficients between prediction and observation reached 0.8-0.9, and the corresponding mean square error values were 15-30. (2) In the 0.5-4 days of forecasting, the model using the first 3-day Chla concentration as the initial input had higher accuracy, while the model using the first 7-day chlorophyll concentration as initial input showed better precision in the forecast for days 4.5-7. It is therefore recommended to use models with different inputs for different forecast periods. The model contributed to provide a methodology for a bloom early warning system driven by data.

收稿日期: 2021-11-30 修订日期: 2022-02-12

作者简介: 李未(1980-), 女, 山东临清人, 副研究员, 博士, 主要从事湖库蓝藻水华短期预测预警研究, liwei@niglas.ac.cn.

基金项目: 国家自然科学基金项目 (No.41977339); 中国科学院野外站联盟项目 (No.KFJ-SW-YW036); 江苏省水利科技项目 (No.2020004)

Supported by National Natural Science Foundation of China (No.41977339); Field Station Alliance Project of Chinese Academy of Sciences, China (No.KFJ-SW-YW036); Water Resource Science and Technology Project in Jiangsu Province, China (No.2020004)

Keywords: algae forecasting; high-frequency time series; neural network; Qiandaohu Reservoir

千岛湖又名新安江水库,是长三角最大的战略水源地及杭州市的饮用水源,以水质优异而著称^[1-2]。千岛湖设有4个国控监测断面,其中,街口断面位于安徽省和浙江省交界处,水质考核标准为GB 3838—2002《地表水环境质量标准》河道Ⅱ类;库体内有3个监测断面,分别为小金山、三潭岛和大坝前,水质考核标准均为GB 3838—2002湖库Ⅰ类(除小金山TP浓度 ≤ 0.025 mg/L外)。近年来,随着流域经济的发展,千岛湖承接的外源污染负荷增大,加上水文气象过程的影响,库区水质出现不稳定性,局部地区开始出现富营养化和藻类异常增殖现象^[3-7]。尤其是小金山断面,地处自上游狭长河道往开敞型水面过渡的区域,极易受到上游河流断面的影响,导致水质状况无法稳定达标,成为千岛湖面临的水环境保护难题^[8-9]。

为了快速捕捉水质与藻类变化,自2011年起千岛湖开始在国控监测断面建设集水温、pH、溶解氧浓度、浊度、叶绿素a浓度等参数于一体的剖面高频监测系统。在获取高频时间序列对水质状况进行实时自动监测的同时,尝试用科学手段挖掘数据特征和规律,在千岛湖沉降通量、热成层和溶解氧分层的稳定性以及藻类垂向分布规律方面取得了新进展^[9-13]。但是,目前通过高频时间序列实现对千岛湖水质的短期预测,从而对藻类异常增殖带来的水质风险做出预判的研究较少。

大数据及人工智能技术使得以数据驱动的建模方式对时间序列进行短期预测成为可能^[14],尤其是人工神经网络(artificial neural network, ANN)模型,因其具有良好的非线性映射和自学习能力,在非平稳时间序列的高精度预测方面具有独特的优势。BP(back propagation, 反向传播)神经网络作为主流网络之一,结构简单、映射能力强,已在医学^[15]、大气^[16-17]、水文^[18]、土壤^[19-20]、生物^[21]、环境^[22-23]等多学科领域广泛应用。但是,BP神经网络属于静态神经网络,信息流动是由输入层单向流动到输出层,对于历史输入输出缺乏记忆联想,对时间序列时变特性的适应能力不强,从而影响预测精度^[24-25]。

NARX(nonlinear auto-regressive with exogenous inputs, 带有外部输入的非线性自回归)神经网络是动态神经网络的一种,其输入结果是当前外部输入和历史输出结果的非线性函数,可看作是有时延输入的BP神经网络加上输出到输入的延时反馈连接。由于网络结构中存在时延和反馈,因此其可反映系统的历

史状态信息,是一种有记忆功能的神经网络,可以模拟时间序列长期动态特征^[26-30]。近年来,NARX神经网络在环境空气质量^[31-32]、水文预报^[33]、大坝变形^[34]、地表沉降^[35]、农作物水分蒸腾^[36]、股票择时^[37]等预测中均取得了较好的效果。研究^[27,34]表明,NARX神经网络可用于预测时间序列,且通常可以保留信息的时间是常规递归神经网络的2~3倍。

鉴于此,该研究以千岛湖小金山国控监测断面的水质自动监测站叶绿素a(Chla)高频监测数据为研究对象,构建基于NARX神经网络的藻类预测模型,分析该模型在千岛湖Chla浓度时序变化预测的效果,探讨最优预见期,以期构建以数据驱动的千岛湖水华监测预警系统提供科学依据。

1 材料与方法

1.1 研究点概况与浮标数据

小金山国控监测断面(见图1)距上游浙江省与安徽省交界的街口断面约28.6 km,距下游三潭岛断面约15.0 km,水深约40 m。布设在小金山国控监测断面的水质自动监测系统为固定浮标站(29°36'38"N、118°56'45"E),浮标悬挂有型号为YSI EXO2的多参数水质仪(Yellow Springs Instrument Co., 美国),可自上而下地同步记录水深(单位为m)和Chla浓度(单位为 $\mu\text{g/L}$)。水深为0.1~10 m时,测量间隔为0.5 m;水深为10~40 m时,测量间隔为2 m。浮标在2016年每3 h(分别为00:00、03:00、06:00、09:00、12:00、15:00、18:00、21:00)记录一次数据,2017年以后每4 h(分别为00:00、04:00、08:00、12:00、16:00、20:00)记录一次数据。为保持数据的一致性,该研究取用每日

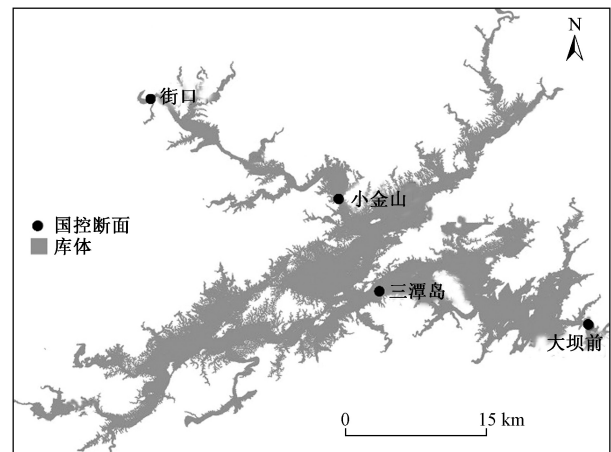


图1 千岛湖库体及国控监测断面分布
Fig.1 Qiandaohu Reservoir and location of state-controlled sections

00:00 与 12:00 的数据进行分析.

1.2 数据处理

小金山国控监测断面逐日高频剖面观测数据的监测时间为 2016 年 9 月 8 日—2019 年 12 月 2 日. 从 Chla 浓度随时间的剖面变化〔见图 2(a)〕可见: Chla 浓度剖面存在明显的季节性变化特征, 冬季、春季水柱垂向差别不明显, 呈几乎完全混合的状态; 夏

季、秋季上层 Chla 浓度明显高于下层. 随机取夏季某一次监测剖面数据, 分析 Chla 浓度随水深的变化〔见图 2(b)〕发现: 水深 10 m 以上, Chla 浓度较高且变化较大; 水深 10 m 以下, Chla 浓度较低且趋于稳定. 因此, 对每日 00:00 和 12:00 0~10 m 的 Chla 浓度监测数据运用梯形求和公式, 得到随时间变化的 Chla 浓度在水深 10 m 以上的沿深平均值, 时间间隔为 0.5 d.




图 2 小金山国控断面高频监测 Chla 浓度的剖面变化情况

Fig.2 High frequency observed Chla profile at Xiaojinshan Station

高频监测期间, 由于仪器维护或恶劣天气等人为不可抗拒原因, 出现了一些时长为半天至十几天的测量间断. 缺测值采用窗口长度为 7 的移动中位数进行线性填充, 即以缺测值位置为中心, 向前、向后各移动 3 个位置, 形成长度为 7 的移动窗口; 若没有足够的数填满窗口, 则窗口自动在前或向后继续移动或直至端点处截断. 当窗口被截断时, 根据窗口内的数据计算出中位数, 替代缺测值.

1.3 NARX 神经网络结构及构建

NARX 神经网络的拓扑结构分为输入层、隐含层、输出层 3 个层次以及输出到输入的延时 (见图 3). 神经网络的输出延时保存后, 通过外部反馈引入输入层, 与输入样本共同学习, 按一定的训练标准计算网络的实际输出值与期望输出值的误差, 不断进行误差

反向传播, 从而调整网络各层权重, 使误差达到最小, 完成学习目的. 隐含层神经元的数目根据经验公式〔见式 (1)〕进行确定^[32,35].

$$h = \sqrt{n+m} + a \quad (1)$$

式中, h 为隐含层神经元数目, n 、 m 分别为输入层、输出层单元数, a 为 1~10 之间的常数.

NARX 神经网络训练采用列文伯格-马夸尔特 (Levenberg-Marquardt, LM) 算法^[38-39], 计算公式:


$$\Delta\omega = (J^T J + \mu I)^{-1} J^T(\omega) e(\omega) \quad (2)$$

式中, ω 为权重阈值参数, J 为雅克比矩阵, J^T 为 J 的转置, μ 为学习常数, I 为单位矩阵, e 为误差向量.

NARX 神经网络建模的基本步骤主要包括: ①初始化网络, 包括网络参数的选择和设定; ②训练, 训练时应尽量防止网络过度拟合; ③仿真, 其中如何初始化网络和提高模型泛化能力对神经网络的构建十分关键.

1.4 NARX 神经网络藻类预测模型性能评价

为了评价 NARX 神经网络藻类预测模型的预测性能, 采用均方误差 (MSE) 和相关系数 (R) 对预测值和实际观测值进行对比分析. 均方误差反映训练输出值与目标值之间的误差, 其值越小表示模拟效果越好; 相关系数范围在 0~1 之间, 其值越大说明模拟数据和实测数据相关度越高, 模型的模拟精度也越高^[32,34].



注: $X(t)$ 为外部输入向量; $Y(t)$ 为期望目标向量; d 为延时阶数; L 和 b 分别为神经网络各层的权重矩阵及偏置, 其中, 上标 1 代表隐含层, 上标 2 代表输出层; f 为各层激活函数, 其中, 隐含层的激活函数 f^1 取双曲正切函数, 输出层的激活函数 f^2 取线性函数.

图 3 NARX 神经网络拓扑结构

Fig.3 Topology architecture of NARX neural network

2 结果与讨论

为了探讨 NARX 神经网络藻类预测模型在千岛湖 Chla 浓度时序变化的预测情况,分别采用连续 3 d 的 Chla 浓度观测值以及连续 7 d 的 Chla 浓度观测值作为输入样本,未来 0.5~7 d 的 Chla 浓度作为输出,建立输入-输出之间的响应模型共 28 个。

模型采用 3 层神经网络,即输入层、隐含层和输出层各 1 层,其中将利用连续 3 d Chla 浓度预测未来 0.5~7 d Chla 浓度的预测模型定义为第 1 类模型,输入层为 6 个单元,输入向量 $X_i=(C_i, C_{i+1}, \dots, C_{i+5})$,输出层为 1 个单元,输出值 $Y_i=C_{i+j}$ ($j=6,7,\dots,19$);将利用连续 7 d Chla 浓度预测未来 0.5~7 d Chla 浓度的预测模型定义为第 2 类模型,输入层为 14 个单元,输入向量 $X_i=(C_i, C_{i+1}, \dots, C_{i+13})$,输出层为 1 个单元,输出值 $Y_i=C_{i+j}$ ($j=14,15,\dots,27$)。该研究指定隐含层神经元个数为 10,延时阶数为 3 d。初始化权值及阈值取 $[-1, 1]$ 之间的随机数。

经插补后,小金山监测断面 2016 年 9 月 8 日—2019 年 12 月 2 日的 Chla 浓度数据共 2 361 个,按占总样本数量 75%、15% 和 10% 的比例,分为训练集、验证集和测试集。其中,训练集样本在模型训练过程中输入到网络中,神经网络在完成初始化之后,根据输出值与标注值之间的误差不断进行权值和偏置值的调整;验证集样本不直接参与上述训练调整,主要用于测度在训练过程中网络泛化能力的表现,在泛化能力停止改进时停止训练,从而防止神经网络训练中发生过拟合现象,导致泛化能力的下降;测试集样本对训练过程不施加影响,而在训练期间及训练后作为独立于训练的样本数据,对神经网络的性能进行测试、分析及评价。

经过多次试验对比发现,两类模型在训练过程中训练集、测试集和验证集的试验效果均十分理想,相关系数在 0.953~0.986 之间,均方误差在 1.387~4.483 之间,模型训练性能较好,可用于预测。

以 2019 年 1—7 月数据作为预测数据输入已训练好的 28 个 NARX 神经网络进行计算,输出未来 0.5~7 d 的 Chla 浓度预测值,并与实际观测值进行比较,从而评价模型预测效果(见表 1)。两类模型的预测性能总体比较稳定,相关系数保持在 0.8~0.9 之间,均方误差在 15~30 之间。随着预见期的增加,两类模型的均方误差均呈上升趋势,相关系数呈下降趋势,但趋势平缓,符合神经网络的预测性能,即随着预测时间的增加,预测精度逐渐下降^[23,32]。相比而言,在未来 0.5~4 d 的预测中,第 1 类模型的预测精度优于第

表 1 两类模型预测性能对比

Table 1 Prediction performance of two NARX models

预测时间/d	第1类模型		第2类模型	
	均方误差	相关系数	均方误差	相关系数
0.5	14.873 9	0.906 0	17.970 0	0.889 1
1	17.802 1	0.895 6	21.203 8	0.872 0
1.5	21.668 5	0.860 6	21.252 3	0.895 1
2	30.179 9	0.821 7	19.472 3	0.875 8
2.5	20.040 9	0.883 5	26.882 3	0.861 5
3	18.671 5	0.893 3	25.329 5	0.850 4
3.5	19.054 2	0.879 9	26.371 2	0.842 0
4	27.698 6	0.830 2	30.232 8	0.848 3
4.5	25.332 1	0.856 2	23.903 1	0.846 9
5	22.195 0	0.856 4	24.383 0	0.870 7
5.5	28.066 7	0.850 9	38.656 5	0.777 4
6	27.782 3	0.824 2	11.819 7	0.929 4
6.5	22.477 7	0.882 9	23.565 6	0.870 7
7	30.385 5	0.813 9	23.425 4	0.873 8

2 类模型,即使用连续 3 d 的 Chla 浓度作为输入的预测模型精度较高;而在未来 4.5~7 d 的预测中,第 2 类模型的预测精度优于第 1 类模型。

图 4~6 分别为第 1 类模型和第 2 类模型对于未来 0.5、3 和 6 d Chla 浓度预测值与观测值的对比。由图 4 可见,对于未来 0.5 d 的预测,两类模型预测值与观测值的趋势变化情况基本相似,吻合程度较高,但在第 2 类模型中存在一些时刻预测值略小于实测值,整体预测程度不如第 1 类模型。由图 5 可见,对于未来 3 d 的预测,两类模型均存在某些预测值小于实测值的情况,但第 1 类模型与实测值吻合程度良好,而第 2 类模型明显存在预测趋势平缓的现象,尤其是没有预测出 6 月 Chla 浓度的高值区,7 月的 Chla 浓度存在明显的相位差。由图 6 可见,对于未来 6 d 的预测,第 2 类模型的预测值与实测值吻合程度高于第 1 类模型,尤其是对 5 月后高低值的振荡趋势模拟较好,而第 1 类模型没有预测出 6 月以后 Chla 浓度的高值区。

在已构建的预测千岛湖水体富营养化的 BP 神经网络模型^[22]中,为了预测 Chla 浓度的周尺度变化,采用了水温、pH、Chla 浓度、透明度和总氮 5 个输入变量,并且随着输入变量减少为 1 个,模型训练过程中的相关系数降至 0.744。而 NARX 神经网络藻类预测模型仅用 Chla 浓度作为输入变量,得到了比 BP 神经网络高的预测精度,进一步说明 NARX 神经网络藻类预测模型在时间序列预测中的优势,以及减少输入参数可以降低输入参数带来的模型不确定性^[23,40]。




图 4 两类模型对未来 0.5 d Chla 浓度的预测值与观测值对比

Fig.4 Performance of two NARX models forecasting the dynamics of Chla in the future 0.5 day




图 5 两类模型对未来 3 d Chla 浓度的预测值与观测值对比

Fig.5 Performance of two NARX models forecasting the dynamics of Chla in the future 3 day

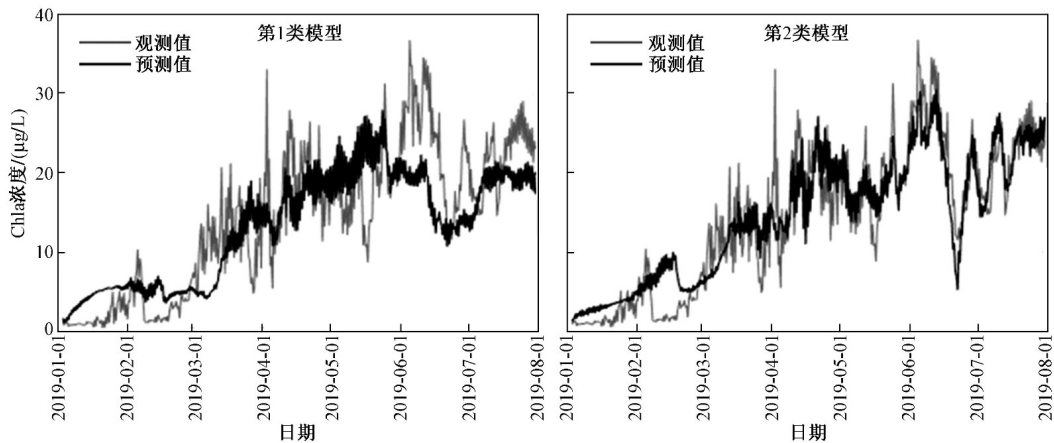


图 6 两类模型对未来 6 d Chla 浓度的预测值与观测值对比

Fig.6 Performance of two NARX models forecasting the dynamics of Chla in the future 6 day

3 结论

a) 基于输入样本不同而定义的两类 NARX 神经网络藻类预测模型预测性能总体比较稳定, 预测值与实测值相关系数保持在 0.8~0.9 之间, 均方误差在

15~30 之间, 可以较为准确地预测未来 0.5~7 d 的 Chla 浓度值, 说明 NARX 神经网络藻类预测模型对于千岛湖 Chla 时序变化的预测是可行的。

b) 随着预见期的变化, 模型性能不尽相同. 建议

在实际应用过程中,采取二者相结合的方法,在未来0.5~4 d的预测中,使用连续3 d的Chla浓度作为输入的预测模型;在未来4.5~7 d的预测中,使用连续7 d的Chla浓度作为输入的预测模型。

c) 相比于基于机理过程的藻类预测数值模型,基于数据驱动的NARX神经网络藻类预测模型结构简单,运行成本较低,具有较强的实用性和时效性。如果采用其他点位的监测数据对所构建模型进行训练、测试和验证,同样可以实现对其他点位Chla时序变化的预测,因此又具有较好的可移植性。

d) 目前预测获得的时间序列平滑性有待进一步提升,这主要是因为原始时间序列为非平稳序列,不仅包含较平稳的有用信息,还包含影响数据可靠性和预测精度的随机噪声。在接下来的研究中,将针对时间序列的特性,继续构建基于小波分析的NARX神经网络藻类预测模型,进一步优化模型参数,提高Chla浓度的预测精度。

e) 总体来讲,基于NARX神经网络的藻类预测模型是可靠的,可以用于千岛湖重点水域藻类生长的短期预测,为水华的监测预警系统构建提供借鉴与依据。

参考文献 (References):

- [1] 盛海燕,吴志旭,刘明亮,等.新安江水库近10年水质演变趋势及与水文气象因子的相关分析[J].环境科学学报,2015,35(1):118-127.
SHENG H Y,WU Z X,LIU M L,et al.Water quality trends in recent 10 years and correlation with hydro-meteorological factors in Xin'anjiang Reservoir[J].Acta Scientiae Circumstantiae,2015,35(1):118-127.
- [2] 笪文怡,朱广伟,吴志旭,等.2002—2017年千岛湖浮游植物群落结构变化及其影响要素[J].湖泊科学,2019,31(5):1320-1333.
DA W Y,ZHU G W,WU Z X,et al.Long-term variation of phytoplankton community and driving factors in Qiandaohu Reservoir,southeast China[J].Journal of Lake Sciences,2019,31(5):1320-1333.
- [3] 吴志旭,刘明亮,兰佳,等.新安江水库(千岛湖)湖泊区夏季热分层期间垂向理化及浮游植物特征[J].湖泊科学,2021,24(3):460-465.
WU Z X,LIU M L,LAN J,et al.Vertical distribution of phytoplankton and physico-chemical characteristics in the lacustrine zone of Xin'anjiang Reservoir (Lake Qiandao) in subtropic China during summer stratification[J].Journal of Lake Sciences,2021,24(3):460-465.
- [4] 韩晓霞,朱广伟,吴志旭,等.新安江水库(千岛湖)水质时空变化特征及保护策略[J].湖泊科学,2013,25(6):836-845.
HAN X X,ZHU G W,WU Z X,et al.Spatial-temporal variations of water quality parameters in Xin'anjiang Reservoir (Lake Qiandao) and the water protection strategy[J].Journal of Lake Sciences,2013,25(6):836-845.
- [5] LI Y,ZHANG Y,SHI K,et al.Spatiotemporal dynamics of chlorophyll-a in a large reservoir as derived from Landsat 8 OLI data:understanding its driving and restrictive factors[J].Environmental Science and Pollution Research,2018,25(2):1359-1374.
- [6] 笪文怡,黎云祥,朱广伟,等.水文气象过程对千岛湖氮磷变化的影响[J].水生态学杂志,2019,40(5):9-19.
DA W Y,LI Y X,ZHU G W,et al.Influence of hydrometeorological processes on nutrient dynamics in Qiandao Lake[J].Journal of Hydroecology,2019,40(5):9-19.
- [7] LIU M,ZHANG Y,SHI K,et al.Spatial variations of subsurface chlorophyll maxima during thermal stratification in a large,deep subtropical reservoir[J].Journal of Geophysical Research: Biogeosciences,2020,125(2):e2019JG005480.
- [8] 韩博平.中国水库生态学研究的回顾与展望[J].湖泊科学,2010,22(2):151-160.
HAN B P.Reservoir ecology and limnology in China:a retrospective comment[J].Journal of Lake Sciences,2010,22(2):151-160.
- [9] 史鹏程,朱广伟,杨文斌,等.新安江水库悬浮颗粒物时空分布、沉降通量及其营养盐效应[J].环境科学,2020,41(5):2137-2148.
SHI P C,ZHU G W,YANG W B,et al.Spatial-temporal distribution of suspended solids and its sedimentation flux and nutrients effect in Xin'anjiang Reservoir,China[J].Environmental Science,2020,41(5):2137-2148.
- [10] LIU M,ZHANG Y,SHI K,et al.Thermal stratification dynamics in a large and deep subtropical reservoir revealed by high-frequency buoy data[J].Science of the Total Environment,2019,651:614-624.
- [11] 笪文怡,朱广伟,黎云祥,等.新安江水库河口区水质及藻类群落结构高频变化[J].环境科学,2020,41(2):713-727.
DA W Y,ZHU G W,LI Y X,et al.High-frequency dynamics of water quality and phytoplankton community in inflowing river mouth of Xin'anjiang Reservoir,China[J].Environmental Science,2020,41(2):713-727.
- [12] LIU M,ZHANG Y,SHI K,et al.Effects of rainfall on thermal stratification and dissolved oxygen in a deep drinking water reservoir[J].Hydrological Processes,2020,34:3387-3399.
- [13] ZHANG M,ZHANG Y,DENG J,et al.High-resolution temporal detection of cyanobacterial blooms in a deep and oligotrophic lake by high-frequency buoy data[J].Environmental Research,2022,

- 203:111848.
- [14] ROUSSO B Z, BERTONE E, STEWART R, et al. A systematic literature review of forecasting and predictive models for cyanobacteria blooms in freshwater lakes[J]. *Water Research*, 2020, 182:115959.
- [15] 刘天, 姚梦雷, 黄继贵, 等. BP神经网络在传染病时间序列预测中的应用及其MATLAB实现[J]. *预防医学情报杂志*, 2019, 35(8): 812-821.
- LIU T, YAO M L, HUANG J G, et al. Application of back propagation neural network in prediction of infectious disease time series and its MATLAB implementation[J]. *Journal of Preventive Medicine Information*, 2019, 35(8): 812-821.
- [16] 张怡文, 胡静宜, 王冉. 基于神经网络的PM_{2.5}预测模型[J]. *江苏师范大学学报(自然科学版)*, 2015, 33(1): 63-65.
- ZHANG Y W, HU J Y, WANG R. PM_{2.5} forecasting model based on neural network[J]. *Journal of Jiangsu Normal University (Natural Science Edition)*, 2015, 33(1): 63-65.
- [17] 赵文怡, 夏丽莎, 高广阔, 等. 基于加权KNN-BP神经网络的PM_{2.5}浓度预测模型研究[J]. *环境工程技术学报*, 2019, 9(1): 14-18.
- ZHAO W Y, XIA L S, GAO G K, et al. PM_{2.5} prediction model based on weighted KNN-BP neural network[J]. *Journal of Environmental Engineering Technology*, 2019, 9(1): 14-18.
- [18] SEO Y, KIM S, KISI O, et al. Daily water level forecasting using wavelet decomposition and artificial intelligence techniques[J]. *Journal of Hydrology*, 2015, 520: 224-243.
- [19] 屈雅静, 魏海英, 马瑾. 基于BP神经网络的北京城区公园土壤PAHs含量预测[J]. *环境科学研究*, 2020, 33(12): 2864-2871.
- QU Y J, WEI H Y, MA J. Prediction of polycyclic aromatic hydrocarbons (PAHs) content in soil of urban parks in Beijing based on BP neural network[J]. *Research of Environmental Sciences*, 2020, 33(12): 2864-2871.
- [20] 任加国, 龚克, 马福俊, 等. 基于BP神经网络的污染场地土壤重金属和PAHs含量预测[J]. *环境科学研究*, 2021, 34(9): 2237-2247.
- REN J G, GONG K, MA F J, et al. Prediction of heavy metal and PAHs content in polluted soil based on BP neural network[J]. *Research of Environmental Sciences*, 2021, 34(9): 2237-2247.
- [21] 曾纳, 任小丽, 何洪林, 等. 基于神经网络的三江源区草地上生物量估算[J]. *环境科学研究*, 2017, 30(1): 59-66.
- ZENG N, REN X L, HE H L, et al. Aboveground biomass of grasslands in the three-river headwaters region based on neural network[J]. *Research of Environmental Sciences*, 2017, 30(1): 59-66.
- [22] 刘恒, 严力蛟. BP神经网络在千岛湖水体富营养化变化预测中的应用[J]. *科技通报*, 2008, 24(3): 411-416.
- LIU H, YAN L J. Back-propagation network model for predicting the change of eutrophication of Qiandao Lake[J]. *Bulletin of Science and Technology*, 2008, 24(3): 411-416.
- [23] XIAO X, HE J, HUANG H, et al. A novel single-parameter approach for forecasting algal blooms[J]. *Water Research*, 2017, 108: 222-231.
- [24] 代兴兰. 遗传算法与最小二乘支持向量机在年径流预测中的应用[J]. *水资源与水工程学报*, 2014, 25(6): 231-235.
- DAI X L. Application of genetic algorithm and least squares support vector machine in prediction of annual runoff[J]. *Journal of Water Resources and Water Engineering*, 2014, 25(6): 231-235.
- [25] 崔东文, 金波. 基于改进的回归支持向量机模型及其在年径流预测中的应用[J]. *水力发电学报*, 2015, 34(2): 7-14.
- CUI D W, JIN B. Improved support vector machine regression model and its application to annual runoff forecasting[J]. *Journal of Hydroelectric Engineering*, 2015, 34(2): 7-14.
- [26] SIEGELMANN H T, HORNE B G, GILES C L. Computational capabilities of recurrent NARX neural networks[J]. *IEEE Transactions on Systems, Man & Cybernetics: Part B*, 1997, 27(2): 208.
- [27] ZOUNEMAT-KERMANI M, STEPHAN D, HINKELMANN R. Multivariate NARX neural network in prediction gaseous emissions within the influent chamber of wastewater treatment plants[J]. *Atmospheric Pollution Research*, 2019, 10(6): 1812-1822.
- [28] ROGHANCI P, KOCISIS K C. Quantifying the thermal damping effect in underground vertical shafts using the nonlinear autoregressive with external input (NARX) algorithm [J]. *International Journal of Mining Science and Technology*, 2019, 29(2): 255-262.
- [29] WONG C X, WORDEN K. Generalised NARX shunting neural network modeling of friction[J]. *Mechanical Systems and Signal Processing*, 2007, 21(1): 553-572.
- [30] SHOAIB M, SHAMSELDIN A Y, MELVILLE B W, et al. A comparison between wavelet based static and dynamic neural network approaches for runoff prediction[J]. *Journal of Hydrology*, 2016, 535: 211-225.
- [31] 赵琦琳, 邱飞, 杨健. NARX神经网络模型在昆明市环境空气质量预测中的应用[J]. *中国环境监测*, 2019, 35(3): 42-48.
- ZHAO Q L, QIU F, YANG J. Application of NARX neural network model in environmental air quality prediction in Kunming[J]. *Environmental Monitoring in China*, 2019, 35(3): 42-48.
- [32] 张丹宁, 张猛, 张博. 基于NARX神经网络的PM_{2.5/10}浓度值预测模型: 以咸阳市两寺渡监测站为例[J]. *地球环境学报*, 2020, 11(2): 161-168.
- ZHANG D N, ZHANG M, ZHANG B. The model to predict PM_{2.5/10} concentrations based on NARX neural network: taking Liangsidu monitoring station in Xianyang as an example[J]. *Journal of Earth*

- Environment,2020,11(2):161-168.
- [33] 刘墨阳,李巧玲,李致家,等.基于小波分析的NARX神经网络在水位预测中的应用[J].南水北调与水利科技,2019,17(5):56-63.
LIU M Y,LI Q L,LI Z J,et al.The application of NARX neural network model based on wavelet analysis for water level prediction[J].South-to-North Water Transfers and Water Science & Technology,2019,17(5):56-63.
- [34] 范哲南,刘小生.NARX神经网络在大坝变形预测中的应用[J].人民黄河,2021,43(2):18-21.
FAN Z N,LIU X S.Application of NARX neural network in dam deformation prediction[J].Yellow River,2021,43(2):18-21.
- [35] 方苏阳,蒋创,魏涛,等.基于时间序列的动态神经网络沉降预测[J].测绘与空间地理信息,2018,41(11):24-27.
FANG S Y,JIANG C,WEI T,et al.Time series-dynamic neural network on settlement prediction[J].Geomatics & Spatial Information Technology,2018,41(11):24-27.
- [36] 孙国祥,闫婷婷,汪小昆,等.基于小波变换和动态神经网络的温室黄瓜蒸腾速率预测[J].南京农业大学学报,2014,37(5):143-152.
SUN G X,YAN T T,WANG X C,et al.A method of cucumber transpiration rate forecast based on wavelet transform and dynamic neural network[J].Journal of Nanjing Agricultural University,2014,37(5):143-152.
- [37] 陈婷.NARX动态神经网络的择时策略研究[D].上海:上海师范大学,2019.
- [38] GUZMAN S M,PAZ J O,TAGERT M L M.The use of NARX neural networks to forecast daily groundwater levels[J].Water Resources Management,2017,31(5):1591-1603.
- [39] YUE S,PILON P,CAVADIAS G.Power of the Mann-Kendall and Spaman's test for detecting monotonic trends in hydrological series[J].Journal of Hydrology,2002,259:254-271.
- [40] ZHAO Y,KOCKELMAN K M.The propagation of uncertainty through travel demand models:an exploratory analysis[J].Annals of Regional Science,2002,36:145e163.

(责任编辑:刘 方)