

基于BP神经网络的潇河流域水质预测

张秀菊¹, 王柳林¹, 李秀平², 王灵生²

(1. 河海大学 水文水资源学院, 江苏 南京 210098; 2. 晋中市水利局, 山西 晋中 030600;)

摘要: 针对传统水质预测方法存在预测精度不理想以及对实测数据要求较高的问题, 建立基于BP神经网络的水质预测模型, 以掌握研究流域未来一定时段的水环境质量情况。模型以潇河流域6个水质监测断面2017年1月-2020年5月的重铬酸盐指数和高锰酸盐指数的浓度作为训练集, 以2020年6月-2020年8月的水质数据作为验证集进行模拟与预测。结果表明: BP神经网络模型经训练后, 模拟的各断面水质指标平均相对误差均小于7%, 相关性系数均超过了0.98, 验证集的水质指标平均相对误差均小于18%。构建的BP神经网络模型预测精度较高, 可以用于潇河流域的水质预测。

关键词: 水质预测; BP神经网络; 相关性系数; 水质指标; 潇河流域

中图分类号: X824

文献标识码: A

文章编号: 1672-643X(2021)05-0019-08

Water quality prediction of the Xiaohe River Basin based on BP neural network model

ZHANG Xiuju¹, WANG Liulin¹, LI Xiuping², WANG Lingsheng²

(1. College of Hydrology and Water Resources, Hohai University, Nanjing 210098, China;

2. Jinzhong Water Authority, Jinzhong 030600, China)

Abstract: Conventional water quality prediction methods have the disadvantages of poor prediction accuracy and high requirements for monitored data, in order to have a better grasp of the future water environment quality of the Xiaohe River Basin over a certain period of time, a BP neural network model was established to predict the concentration of water quality indices. The indices of COD_{Cr} and COD_{Mn} of six water quality monitoring sections in the basin from January 2017 to May 2020 were selected as the training set and the water quality data from June to August 2020 as the validation set for the model. The simulation results show that the average relative error of the water quality index of each section simulated by the trained BP neural network model was less than 7%, and all the correlation coefficients exceeded 0.98. The average relative errors of the water quality indices in the verification set were all less than 18%. The prediction accuracy of the proposed model is high and satisfactory, so it can be used for the water quality prediction of Xiaohe River Basin.

Key words: water quality prediction; BP neural network; correlation coefficient; water quality index; the Xiaohe River Basin

1 研究背景

优质的水环境质量是提升城乡居民生活环境及人文内涵的必要条件, 改善水环境是各流域机构与地方政府长期且艰巨的任务, 而水质预测则是水环境管理与保护中的重要环节。水质预测是利用现有

实测资料, 通过建立水质模型预测未来水环境状况的一种方法。科学准确的水质预测有助于认识水体环境的变化规律和发展态势, 可以为水环境保护与水污染防治工作提供技术支撑, 提高管理部门的决策主动性。

国内外在水质预测方面的研究始于20世纪20

收稿日期: 2021-03-22; 修回日期: 2021-06-16

基金项目: 国家重点研发计划项目(2018YFC1508200); 山西省水利科技项目(XS2019004)

作者简介: 张秀菊(1971-), 女, 河北藁城人, 博士, 副教授, 硕士生导师, 研究方向为水资源规划与管理。

通讯作者: 王柳林(1997-), 男, 湖北安陆人, 硕士研究生, 研究方向为水资源规划与管理。

年代。初期学者们主要关注机理性水质模型,此类模型从物理、化学、生物等多方面因素研究水质的变化机理,受到诸多学者的青睐^[1]。机理性水质模型先后经历了一维、二维及三维几个发展阶段,一维水质模型有 S-P 水质模型^[2]、MIKE11 模型^[3]、QUAL2K 模型^[4]等,随后 MIKE21 水动力-水质模型^[5]、CE-QUAL-W2 水质模型^[6]等二维水质模型得到发展,二维模型考虑了污染物浓度在河流纵向和横向上的演变,预测内容较一维模型明显增加。后来学者们研发了 EFDC 模型^[7]、WASP 模型^[8]等三维水质模型,可以模拟更加复杂的水质状况。

上述机理性水质模型较为复杂,在实际运用中需要大量的基础资料作为支撑^[9],例如利用水动力-水质耦合模型进行水质预测时需要有实测的河道断面尺寸、河道流量、水位及水质资料,且需要掌握研究河段范围内的时段降雨与蒸发量,以及精确的污染源、取排口等资料,基础资料成为模拟与预测精度的主要约束。故而一些学者开始转向研究非机理性水质模型,如:陈昭明等^[10]运用多元回归模型对汉丰湖水质进行了预测;黄玥等^[11]采用时间序列模型对三峡水库出库水质进行了预测;Zhou 等^[12]利用灰色预测模型对水库水质进行了预测;Liu 等^[13]利用支持向量机对水质进行了预测。上述非机理性水质模型在一些流域得到了实际运用,然而这些模型自身也存在诸多缺陷。例如回归分析模型相对简单,但其对统计数据的要求较高,需要大样本且数据须有较好的分布规律;时间序列模型具有相对完善的理论基础,但其预测的准确性较差^[14];灰色预测模型适用于历史数据较少且不连续的情况,但模型容易受到不稳定数据的影响,导致预测误差较大;支持向量机适用于小样本,但其对参数和核函数的选择较为敏感。

基于以上研究方法的不足,考虑到人工神经网络模型具有很强的自适性、自学习和高度容错能力,本文以潇河流域晋中段为研究区域,在 Python 环境下建立 BP 神经网络模型,通过模拟流域内重铬酸盐指数(COD_{Cr})和高锰酸盐指数(COD_{Mn})的时空变化规律,预测未来一定时段的水质态势,为水资源管理与水环境保护提供参考依据。

2 数据来源与研究方法

2.1 研究区概况

潇河发源于山西省晋中市昔阳县,流经昔阳、寿阳、和顺、榆次、小店、清徐 6 个县区,最终汇入汾河,河长为 147 km,总流域面积为 3 894 km²,其中晋中

段流域面积为 3 781 km²。潇河流域建有 2 座中型水库,5 座小型水库,目前可以供水的水库为松塔水库、蔡庄水库与郑家庄水库。流域内有 6 条一级支流,现设有松曲、马坊、蔡庄水库、冷泉寺、东赵、郝村 6 个水质监测断面。潇河流域晋中段水系分布及各水质监测断面位置如图 1 所示。



图 1 潇河流域晋中段水系分布及各水质监测断面位置

2.2 数据来源

水质数据取自潇河流域 6 个监测断面的水质资料,数据来源为晋中市水利局。本次选取的数据长度为 2017 年 1 月-2020 年 8 月,由于部分月份河流有断流、结冰或缺测情况,故导致这些月份水质数据缺失,水质数据缺失情况统计见表 1。为了确保水质数据的连续性,本文运用拉格朗日插值法补充缺失值^[15],拉格朗日插值多项式如下:

$$L_1(t) = x_h \frac{t_{h+1} - t}{t_{h+1} - t_h} + x_{h+1} \frac{t - t_h}{t_{h+1} - t_h} \quad (1)$$

式中: t_h 、 t 、 t_{h+1} 为相邻的 3 个月份; x_h 、 $L_1(t)$ 、 x_{h+1} 为相邻 3 个月份对应的水质指标(COD_{Cr} 或 COD_{Mn})浓度,mg/L,其中 $L_1(t)$ 为数据缺失月份水质指标浓度插值。

表 1 研究区水质指标数据缺失情况统计表

水质监测断面	COD_{Cr} 指标		COD_{Mn} 指标	
	时间/(年-月)	原因	时间/(年-月)	原因
蔡庄水库	2018-02	冰冻	2018-02	冰冻
	2017-07	断流	2017-07	断流
郝村	2018-12	缺测	2019-12	缺测
	2019-12	缺测		

2.3 研究方法

2.3.1 BP 神经网络原理 1957 年,Rosenblatt 基于

大脑神经元工作原理发明了感知器,它是最简单的人工神经网络,仅能解决线性问题。1974年,Paul Werbos发明了反向传播算法,使得利用多层神经网络求解非线性问题成为可能,由此产生了BP(back propagation)神经网络。图2为BP神经网络结构图。




图2 BP神经网络结构图

图2中BP神经网络有 m 个运算层,其中,输入层位于第1层,输出层位于第 m 层,输入层与输出层之间的 $m-2$ 个运算层称为隐含层。BP神经网络模型计算包括训练和验证两部分,其具体流程如下:(1)设置神经网络结构,随机分配算法的权值和阈值;(2)选择一个样本($x_1^0, x_2^0, \dots, x_i^0$)进行输入,然后产生输出值;(3)计算输出值与实测值的误差,再根据误差进行反向传递^[16],调整权值与阈值;(4)选取新的样本($x_1^n, x_2^n, \dots, x_i^n$),返回步骤(2),直至所有样本训练完毕;(5)计算全局误差,若精度满足要求或达到最大学习次数即训练过程结束;(6)输入验证集数据,然后产生输出值;(7)计算相对误差,达到误差允许范围即结束。BP神经网络计算流程见图3。




图3 BP神经网络模型流程图

2.3.2 数据处理 由于部分监测断面的实测水质数据波动范围较大,可能影响模型的收敛速度,因此在训练前需要对数据进行预处理。本研究选择改进的最大最小值归一化方法,可以有效避免出现0值,从而降低原始数据对模型训练的影响^[17]。公式(2)与(3)是对数据进行预处理和反预处理的方法。

数据预处理方法的计算公式为:

$$x' = \frac{(0.8 - 0.2) \cdot (x - \min(x))}{(\max(x) - \min(x))} + 0.2 \quad (2)$$

反预处理方法的计算公式为:

$$x = \frac{(x' - 0.2) \cdot (\max(x) - \min(x))}{(0.8 - 0.2)} + \min(x) \quad (3)$$

式中: x 为 COD_{Cr} 或 COD_{Mn} 的原始数值; x' 为经数据处理后的数据; $\min(x)$ 和 $\max(x)$ 分别为 COD_{Cr} 或 COD_{Mn} 数值的最小值和最大值。

2.3.3 模型构建 BP神经网络模型构建主要包括神经网络的结构设置、激活函数的选取、求解器的选取3个部分。

(1)BP神经网络的结构设置。理论上,对于一个3层的BP神经网络,只要隐含层节点数足够多,则可以逼近任意非线性函数^[18]。本研究确定BP神经网络的总层数为3层。

BP神经网络在训练过程中,输入层节点数设定为 k 个,输出层节点数为1个。输出层,即第 n 个节点的 COD_{Cr} 或 COD_{Mn} 的浓度为前 k 个节点的历史数据的函数,其预测动态系统^[19]为:

$$y_n = f(x_{n-1}, x_{n-2}, \dots, x_{n-k}) \quad (4)$$

式中: y_n 为对应编号为 n 的 COD_{Cr} 或 COD_{Mn} ; k 为滞后编号数。

这样整个系统的输入为某编号为 n 的前 k 个编号的 COD_{Cr} 或 COD_{Mn} ,而输出则是第 n 个节点的 COD_{Cr} 或 COD_{Mn} 。若节点数太少,则网络训练性能会变差,而节点数太多,容易出现过拟合的状况。因此,本研究在程序设计时,设定了相应区间和步长,利用计算机自动寻优确定节点数量,最终确定的节点数见表2。以表2中的松曲断面 COD_{Cr} 为例,其对应的输入层节点数为6个,在模型训练期间,首先输入2017年1月-2017年6月的 COD_{Cr} 浓度实测值,通过模型训练输出2017年7月的 COD_{Cr} 浓度模拟值,然后依次滑动,最后输入2019年11月-2020年4月的 COD_{Cr} 浓度实测值,通过模型训练输出2020年5月的 COD_{Cr} 浓度模拟值。

(2)激活函数的选取。常见的激活函数有identity函数、logistic函数、tanh函数和relu函数。其中

identity 函数为线性函数,当计算问题为非线性时,该激活函数不适于单独使用;logistic 函数和 tanh 函数计算量大且容易出现梯度消失问题;relu 函数可以加快收敛速度,且解决了梯度弥散问题,故本研究选用 relu 函数,即 $f(x)=\max(0,x)$ 。

(3)求解器的选取。求解器可以用来优化权重,常见的求解器有 lbfgs、sgd、adam。其中 sgd 求解器每步接受的信息有限,造成目标函数收敛不稳定甚至不收敛;adam 求解器主要适用于数据集较多的情况;lbfgs 为准牛顿方法家族中的优化程序,对于小型数据集,lbfgs 可以收敛得更快并且性能更好,故本研究选用 lbfgs 求解器。

3 结果与分析

3.1 模型训练

以潇河流域 2017 年 1 月 -2020 年 5 月监测的

水质指标 COD_{Cr} 和 COD_{Mn} 逐月浓度数据作为训练集,利用构建好的模型对 6 个监测断面的水质数据进行拟合,模型的最大学习次数设为 2 000,学习速率为 0.001。模型训练结果见图 4 和 5,其中,图 4 为各水质监测断面 COD_{Cr} 浓度模拟结果,图 5 为各水质监测断面 COD_{Mn} 浓度模拟结果。由于各断面 BP 神经网络输入节点数不一致(见表 2),故图 4 和 5 存在各断面起始模拟值的时间不一致的情况。

表 2 BP 神经网络结构表

水质断面	输入层节点个数		隐含层节点个数		输出层节点个数	
	COD_{Cr}	COD_{Mn}	COD_{Cr}	COD_{Mn}	COD_{Cr}	COD_{Mn}
松曲	6	10	32	20	1	1
马坊	12	11	18	28	1	1
蔡庄水库	6	9	23	23	1	1
冷泉寺	13	14	27	13	1	1
东赵	15	14	25	16	1	1
郝村	8	13	20	8	1	1




图 4 研究区各水质监测断面 COD_{Cr} 浓度模拟结果

由图 4、5 可以看出,潇河流域各监测断面的实测水质数据在时间尺度上呈现非线性变化,而 BP 神经网络模拟值与水质数据实测值的变化趋势基本一致,表明 BP 神经网络经训练后能较好地反映水质变化趋势。

现将各断面水质指标的实测值与模拟值进行对比分析,用相关性系数和平均相对误差来衡量模型拟合的效果,表 3 为水质指标拟合效果表。

由表 3 可以看出,6 个监测断面的 COD_{Cr} 浓度相关性系数均超过了 0.98,为强相关。相关性系数由大到小排序为:东赵 > 冷泉寺 > 郝村 > 马坊 > 蔡庄

水库 > 松曲,相关性系数最大的为东赵断面,其相关性系数为 0.999 8,相关性系数最小的为松曲断面,相关性系数为 0.989 2。6 个监测断面的 COD_{Cr} 浓度平均相对误差的平均值约为 3%,平均相对误差由小到大排序为:东赵 < 郝村 < 冷泉寺 < 马坊 < 蔡庄水库 < 松曲,平均相对误差最大的为松曲断面,对应的平均相对误差为 6.59%,平均相对误差最小的为东赵断面,对应的平均相对误差为 0.63%。整体而言,各断面 COD_{Cr} 浓度的拟合效果较好,其中东赵断面的拟合效果最佳。从空间位置上看,下游监测断面的 COD_{Cr} 浓度模拟效果好于上游断面。6 个监测

断面的 COD_{Mn} 浓度相关性系数均超过了 0.99,属于强相关。相关性系数由大到小排序为:冷泉寺 > 松曲 > 蔡庄水库 > 东赵 > 郝村 > 马坊,相关性系数最大的为冷泉寺断面,对应的相关性系数为 0.999 9,相关性系数最小的为马坊断面,对应的相关性系数为 0.993 1。6 个监测断面的 COD_{Mn} 浓度平均相对误差的平均值为 1.5%,平均相对误差由小到大排序为:冷泉寺 < 松曲 < 蔡庄水库 < 东赵 < 郝村 < 马坊,平均相对误差最大的为马坊断面,对应的平均相对误差为 4.63%,平均相对误差最小的为冷泉寺断面,对应的平均相对误差为 0.15%。整体而言,各断面 COD_{Mn} 浓度的拟合效果较好,其中冷泉寺断面的拟合效果最佳。从空间位置上看,上游监测断面 COD_{Mn} 浓度的模拟效果好于下游断面。

3.2 模型验证

利用模型模拟期优化得到的权值与阈值,对潇河流域 2020 年 6-8 月的水质进行验证。具体检验结果见表 4 和 5。其中表 4 为各断面 COD_{Cr} 浓度模型验证结果,表 5 为各断面 COD_{Mn} 浓度模型验证结果。

表 3 研究区各断面水质指标拟合效果表

水质断面	COD _{Cr} 浓度		COD _{Mn} 浓度	
	相关性系数	平均相对误差/%	相关性系数	平均相对误差/%
松曲	0.9892	6.59	0.9997	0.33
马坊	0.9977	3.95	0.9931	4.63
蔡庄水库	0.9952	4.48	0.9992	0.66
冷泉寺	0.9997	1.61	0.9999	0.15
东赵	0.9998	0.63	0.9980	1.36
郝村	0.9995	1.07	0.9958	2.14




图 5 研究区各水质监测断面 COD_{Mn} 浓度模拟结果

表 4 2020 年 6-8 月研究区各水质断面 COD_{Cr} 浓度模型验证结果 mg/L

时间	松曲断面			马坊断面			蔡庄水库断面		
	实测值	验证值	相对误差/%	实测值	验证值	相对误差/%	实测值	验证值	相对误差/%
2020-06	11	8.8	-20.00	5	5.1	2.00	11	13.7	24.55
2020-07	13	11.4	-12.31	13	13.4	3.08	10	11.8	18.00
2020-08	20	16.1	-19.50	10	11.4	14.00	14	13.1	-6.43

时间	冷泉寺断面			东赵断面			郝村断面		
	实测值	验证值	相对误差/%	实测值	验证值	相对误差/%	实测值	验证值	相对误差/%
2020-06	32	26.6	-16.88	10	9.3	-7.00	11	10.2	-7.27
2020-07	35	34.0	-2.86	16	14.9	-6.88	11	8.7	-20.91
2020-08	20	22.4	12.00	30	21.0	-30.00	22	25.3	15.00

表 5 2020 年 6–8 月研究区各水质断面 COD_{Mn} 浓度模型验证结果

mg/L

时间	松曲断面			马坊断面			蔡庄水库断面		
	实测值	验证值	相对误差/%	实测值	验证值	相对误差/%	实测值	验证值	相对误差/%
2020-06	3.1	3.0	-3.23	2.8	2.4	-14.29	1.9	2.2	15.79
2020-07	3.0	2.8	-6.67	2.6	2.6	0.00	3.1	2.8	-9.68
2020-08	3.5	3.4	-2.86	3.0	2.5	-16.67	2.9	3.1	6.90

时间	冷泉寺断面			东赵断面			郝村断面		
	实测值	验证值	相对误差/%	实测值	验证值	相对误差/%	实测值	验证值	相对误差/%
2020-06	6.8	6.6	-2.94	3.5	3.2	-8.57	3.6	3.9	8.33
2020-07	7.7	6.1	-20.78	4.0	4.0	0.00	2.7	2.7	0.00
2020-08	6.4	5.8	-9.38	3.6	3.7	2.78	4.7	4.4	-6.38

根据表 4 中的验证结果,蔡庄水库断面在 2020 年 6 月份、东赵断面在 2020 年 8 月份、郝村断面在 2020 年 7 月份的 COD_{Cr} 浓度相对误差较大,各断面其余月份的 COD_{Cr} 浓度的相对误差均未超过 20%。因此,构建的 BP 神经网络模型通过检验,可以用于预测潇河流域的 COD_{Cr} 浓度;根据表 5 中的验证结果,除冷泉寺断面在 2020 年 7 月份的误差较大外,其余断面各月份的 COD_{Mn} 浓度验证结果较好。因此,构建的 BP 神经网络模型通过检验,可以用于预测潇河流域的 COD_{Mn} 浓度。

4 讨 论

BP 神经网络对于历史数据具有很好的适应性,能较好地适用于水质浓度变化缓慢的情况,且模拟与验证精度较高。但若由于人为因素影响,个别月份水质指标浓度发生较大变化时,BP 模型的精度会降低。总体而言,本文在模拟期各断面水质指标的平均相对误差均小于 7%,模拟精度较高。

根据相关文献,验证期的水质预测误差是不易控制的,例如董瑞瑞等^[20]利用 MIKE11 水动力-水质模型对汉江中下游 COD_{Mn} 浓度进行预测时,其验证期的平均相对误差为 14.5%;王墨瑞等^[21]利用一维水质预测模型对 COD_{Cr} 浓度进行预测,验证期 COD_{Cr} 浓度的平均相对误差为 24%。本研究中,在验证期,月最大相对误差未超过 30% (东赵断面),各断面大多数月份的误差小于 15%。其中,各断面 COD_{Cr} 浓度的平均相对误差均小于 18%, COD_{Mn} 浓度的平均相对误差均小于 12%,验证精度优于其他模型。因此,本文验证精度较优,其预测结果可以接受。

为剖析蔡庄水库、东赵、郝村、冷泉寺断面部分月份水质指标验证误差偏大的原因,对该 4 个断面水质指标的实际检测浓度进行比较,2017 年 1 月–2020

年 8 月该 4 个断面的水质指标浓度变化情况见图 6。

由图 6(a)可以看出,蔡庄水库断面 COD_{Cr} 浓度在 2017 年 1 月–2020 年 4 月平稳振荡,2020 年 4 月之后, COD_{Cr} 实测浓度明显降低,较其他年份同时期 COD_{Cr} 浓度值小,由此导致 2020 年 6 月 COD_{Cr} 浓度模拟值大于实测值,相对误差较大。根据潇河实测流量资料,蔡庄水库在 2020 年 4 月–2020 年 8 月的河道流量偏小,故推测 COD_{Cr} 浓度降低的原因应该是当地水利部门实施了严格的污染物入河管控措施,污染物浓度出现减小趋势。

由图 6(b)可以看出,东赵断面 COD_{Cr} 浓度在 2017 年 1 月–2020 年 6 月基本保持平稳振荡,但 2018 年 4 月和 2020 年 8 月存在两个峰值,其浓度远高于历史平均数值,例如 2020 年 8 月 COD_{Cr} 的实测浓度是往年相同月份的 2 倍。经核对,东赵断面在 2020 年 8 月份的河道流量较往年大,故 COD_{Cr} 浓度大幅度增大的原因可能是存在临时性或突发性的人河污染物增多的问题。


由图 6(c)可以看出,郝村断面 COD_{Cr} 浓度在 2017 年 1 月–2020 年 8 月平稳振荡,而郝村断面在 2020 年 7 月的 COD_{Cr} 浓度相对误差较大,其原因应是由于模型自身存在误差,BP 神经网络出现了陷入局部极值的现象。

由图 6(d)可以看出,冷泉寺断面在冬季 1 或 2 月份均出现检测峰值,但总体上 COD_{Mn} 浓度呈现减小的态势,且 2020 年 4 月之后, COD_{Mn} 浓度与其他年份同时期相比显著偏小,由此导致 2020 年 7 月验证的相对误差变大。由于冷泉寺断面在流域各断面中水质相对较差,近些年流域机构加强了对周边入河污染物的管控,这也是该断面 COD_{Mn} 浓度下降的原因。


BP 神经网络模型只考虑了潇河流域各水质指标

的历史数据,而外部环境的改变对河流水质的影响较大,会对神经网络训练过程产生干扰,从而影响模型


精度。如何降低外部因素的干扰,亦或考虑将影响水质的影响因素加入模型中,还有待进一步研究。




(a) 蔡庄水库断面 COD_{Cr} 浓度变化



(b) 东赵断面 COD_{Cr} 浓度变化



(c) 郝村断面 COD_{Cr} 浓度变化



(d) 冷泉寺断面 COD_{Mn} 浓度变化

图6 2017年1月-2020年8月4个断面的实测水质指标浓度变化情况

5 结论与展望

本文分析了传统水质预测方法的优缺点,通过构建BP神经网络模型,利用潇河流域晋中段实测水质资料进行水质模拟与权值优化,进而对潇河流域6个水质监测断面的 COD_{Cr} 和 COD_{Mn} 指标未来3个时段的浓度进行预测,主要结论与展望如下:

(1)BP神经网络能较好地反映水质数据的变化趋势,训练集的各断面水质指标平均相对误差均小于7%,相关性系数均超过了0.98;验证集的各断面水质指标平均相对误差均低于18%,预测精度高,可用于预测潇河流域的 COD_{Cr} 和 COD_{Mn} 浓度,为水资源管理与水环境保护提供参考依据。

(2)本研究在选取神经网络节点数量时,在程序中设置了相应区间和步长,对训练集的平均相对误差和相关性系数进行了约束,利用计算机自动寻优,降低了模型的不确定性,节省了参数率定的时间。

(3)为了提高收敛速度与预测精度,以及改善过拟合的问题,将人工神经网络与其他算法的结合应是今后研究的重点。

参考文献:

[1] 王丽学,马慧,杨旭,等.基于MATLAB的BP神经网络大伙房水库非汛期水质预测[J].沈阳农业大学学报,2014,45(3):363-367.

[2] 徐韶楠,李亚男,许元青.基于改良最优搜索程序的F河A段S-P水质模型[C]//中国环境科学学会环境工程分会2019年科学技术年会-环境工程技术创新与应用分论坛论文集(四).西安,2019.

[3] 黄丽娇,王川涛. MIKE11在湖泊水量水质保障中的应用研究[J].水利规划与设计,2021(4):35-39+69.

[4] ZHANG Yali, YANG Huige, WANG Zhisong. Simulating water quality of Wei River with QUAL2K Model, a case study of Hai River Basin in China[C]// MATEC Web of Conferences, Paris: EDP Sciences, 2016.

[5] 田传冲,黄冬菁,毕佳成,等.建闸对甬江干流水质影响分析[J].水电能源科学,2015,33(7):43-47.

[6] 方爱红,周勤,楼成林,等. CE-QUAL-W2模型在上海市大型饮用水水库中的应用[J].环境科学与管理,2012,37(11):76-79+100.

[7] 卢诚,安瑛达,张晓彤,等.基于EFDC模型的神定河水水质模拟[J].中国环境监测,2020,36(4):106-114.

[8] 王思文,齐少群,于丹丹,等.基于WASP模型的水环境质量预测与评价研究——以松花江哈尔滨江段为例[J].自然灾害学报,2015,24(1):39-45.

[9] 宁雄.基于分布式CA和BP水质模型的城市空间增长边界研究[D].北京:清华大学,2015.

[10] 陈昭明,王伟,赵迎,等.改进主成分分析与多元回归融合的汉丰湖水水质评估及预测[J].环境监测管理和技术,2020,32(4):15-19.

[11] 黄玥,黄志霖,肖文发,等.三峡水库水位调度对出库水质影响分析与水质预测[J].水资源与水工程学报,

- 2020, 31(4): 78–85.
- [12] ZHOU Yi, HU Jiarui, XIE Mengfan. Research on reservoir water quality prediction based on Grey Model[C] // IOP Conference Series: Earth and Environmental Science. Bristol: IOP Publishing, 2021, 621(1): 012120.
- [13] LIU Wen, WANG Guoyin, FU Jianyu, et al. Water quality prediction based on improved wavelet transformation and support vector machine[J]. Advanced Materials Research, 2013, 2480: 3547–3553.
- [14] 李 扬, 窦炳臣, 陈 振, 等. 地下水水质评价与预测方法综述[J]. 山东国土资源, 2015, 31(8): 33–36.
- [15] 查木哈, 卢志宏, 翟继武, 等. 双隐层 BP 神经网络模型在老哈河水质预测中的应用[J]. 水资源与水工程学报, 2018, 29(2): 56–61.
- [16] 李海峰, 李纯果. 深度学习结构和算法比较分析[J]. 河北大学学报(自然科学版), 2012, 32(5): 538–544.
- [17] 郭庆春, 何振芳, 李 力, 等. BP 神经网络模型在太湖污染指标预测中的应用[J]. 南方农业学报, 2011, 42(10): 1303–1306.
- [18] 据振闯, 王 晓, 弓艳霞. 基于 BP 神经网络的黄河水质预测研究[J]. 青海大学学报, 2017, 35(3): 88–92 + 102.
- [19] 张秀菊, 安 焕, 赵文荣, 等. 基于支持向量机的水质预测应用实例[J]. 中国农村水利水电, 2015(1): 85–89.
- [20] 董瑞瑞, 陈和春, 王继保, 等. 汉江中下游突发性水污染事故预测模型研究[J]. 水力发电, 2017, 43(12): 1–5.
- [21] 王墨瑞, 郭星佑, 聂艾琳, 等. 一维稳态水质模型应用于邢台汪洋沟的适用性研究[J]. 环境科学与管理, 2019, 44(11): 68–71.

(上接第 18 页)

- [24] BROWN M E, ARIAS S D, NEUMANN T, et al. Applications for ICESat–2 data: From NASA’s early adopter program[J]. IEEE Geoscience and Remote Sensing Magazine, 2016, 4(4): 24–37.
- [25] LU Xiaomei, HU Yongxiang, YANG Yuekui, et al. Enabling value added scientific applications of ICESat–2 data with effective removal of afterpulses[J]. Earth and Space Science, 2021, 8(6): e2021EA001729.
- [26] 吴红波. 基于星载雷达测高资料估计博斯腾湖水位–水量变化研究[J]. 水资源与水工程学报, 2019, 30(3): 9–16.
- [27] SANTOS DA SILVA J, CALMANT S, SEYLER F, et al. Water levels in the Amazon basin derived from the ERS 2 and ENVISAT radar altimetry missions[J]. Remote Sensing of Environment, 2010, 114(10): 2160–2181.
- [28] PHAN V H, LINDENBERGH R, MENENTI M. ICESat derived elevation changes of Tibetan lakes between 2003 and 2009[J]. International Journal of Applied Earth Observation and Geoinformation, 2012, 17: 12–22.
- [29] OSBORNE I S. Extending the reach of LIDAR[J]. Science, 2021, 372(6542): 585.7–586.
- [30] JASINSKI M, STOLL J, HANCOCK D, et al. Algorithm theoretical basis document (ATBD) for inland water data products ATL13 Version 002 [J/OL]. Boulder, Colorado USA: NASA National Snow and Ice Data Center Distributed Active Archive Center, 2019[2019-11-11]. <https://nsidc.org/data/atl13/versions/2>.
- [31] DEVRIES B, HUANG Chengquan, LANG W M, et al. Automated quantification of surface water inundation in wetlands using optical satellite imagery[J]. Remote Sensing, 2017, 9(8): 807–828.
- [32] 吴红波, 郭忠明, 陈安安, 等. 坡度和粗糙度对 ICESat–GLAS 回波特征及其光斑脚点高程误差的影响研究[J]. 地理与地理信息科学, 2016, 32(4): 30–37.
- [33] MUNYANEZA O, WALI U G, UHLENBROOK S, et al. Water level monitoring using radar remote sensing data: Application to Lake Kivu, central Africa[J]. Physics and Chemistry of the Earth, Parts A/B/C, 2009, 34(13–16): 722–728.