

DOI:10.3969/j.issn.1003-5060.2025.02.001

基于改进 PSO-ELM 的坑湖水质预测与评价

石秀峰^{1,2}, 王进^{1,2}, 揣新³, 王绍平³, 罗长海³, 岳正波^{1,2}

(1. 合肥工业大学 资源与环境工程学院, 安徽 合肥 230009; 2. 合肥工业大学 安徽省工业废水处理与资源化工程研究中心, 安徽 合肥 230009; 3. 安徽马钢矿业资源集团南山矿业有限公司, 安徽 马鞍山 243031)

摘要: 采矿行业产生的尾矿水具有较高的金属离子和硫酸盐质量浓度, 同时具有酸化的风险, 对尾矿水水质的预测和评价有利于保障尾矿水资源循环利用和可持续发展。文章将线性原始数据通过滑动窗口处理转化为模型的输入矩阵, 利用粒子群优化算法 (particle swarm optimization, PSO) 对极限学习机 (extreme learning machine, ELM) 进行改进, 提出一种基于 PSO-ELM 的水质预测模型, 以安徽马鞍山某矿区坑湖为对象, 使用不同网络模型对水质参数进行预测。结果表明, 改进后的 PSO-ELM 模型较 BP (back propagation) 神经网络、传统 ELM 具有更高的预测精度, 决定系数达到 82%, 均方误差仅为 0.04, 并且具有更快的计算和收敛速度。将训练集数据与预测数据相结合, 采用 Spearman 秩相关系数法评价水质稳定性, 结果表明 pH 值和主要无机盐离子质量浓度较为稳定, 无明显变化趋势, 满足生态和生产需求。

关键词: 水质监测; 滑动窗口; 粒子群优化算法 (PSO); 极限学习机 (ELM); 水质评价

中图分类号: X824

文献标志码: A

文章编号: 1003-5060(2025)02-0145-06

Prediction and assessment of water quality in pit lake based on improved PSO-ELM

SHI Xiufeng^{1,2}, WANG Jin^{1,2}, CHUAI Xin³, WANG Shaoping³, LUO Changhai³, YUE Zhengbo^{1,2}

(1. School of Resources and Environmental Engineering, Hefei University of Technology, Hefei 230009, China; 2. Anhui Engineering Research Center of Industrial Wastewater Treatment and Resource Recovery, Hefei University of Technology, Hefei 230009, China; 3. Nanshan Mining Co., Ltd., Anhui Masteel Mining Resources Group, Ma'anshan 243031, China)

Abstract: The tailing water generated by the mining industry has a high concentration of metal ions and sulfate, as well as the risk of acidification. The prediction and assessment of tailing water quality is beneficial to guaranteeing the recycling and sustainable development of tailing water resources. In this paper, the linear raw data are transformed into the input matrix of the model by sliding window processing, and the extreme learning machine (ELM) is improved by using the particle swarm optimization (PSO) algorithm to propose a water quality prediction model based on PSO-ELM. Different network models were used to predict the water quality parameters of a pit lake in a mining area in Ma'anshan City, Anhui Province. The results show that the improved PSO-ELM has higher prediction accuracy compared with back propagation (BP) neural network and traditional ELM, with 82% fitting degree and only 0.04 mean square error, and has faster calculation and convergence speed. The training set data was combined with the predicted data, and the Spearman's rank correlation coefficient method was used to evaluate the stability of water quality. The results show that the pH value and the content of major inorganic salt ions are stable, without obvious change trend, which meet the ecological and production needs.

Key words: water quality monitoring; sliding window; particle swarm optimization (PSO); extreme learning machine (ELM); water quality assessment

收稿日期: 2023-03-03; 修回日期: 2023-03-28

基金项目: 国家自然科学基金联合基金资助项目 (U19A20108); 安徽省重点研究与开发计划资助项目 (2022107020015)

作者简介: 石秀峰 (1998—), 男, 安徽合肥人, 合肥工业大学硕士生;

王进 (1978—), 女, 安徽淮南人, 博士, 合肥工业大学教授, 博士生导师;

岳正波 (1980—), 男, 河南济源人, 博士, 合肥工业大学教授, 博士生导师, 通信作者, E-mail: zbyue@hfut.edu.cn.

随着矿产资源被不断的开采,工业产生的铁矿石尾矿等危险工业废物及尾矿水的不断增加正成为严重的环境问题^[1]。为合理利用和处理尾矿水,露天开采形成的矿坑不断收纳尾矿水,形成深坑状的坑湖水体。金属矿区的尾矿水中含有较高的铁、铜、锰等重金属离子,同时选矿工艺易造成硫酸盐浓度上升^[2],大量蓄积会造成地貌景观和植被破坏、地下水含水层破坏和不稳定边坡等生态环境问题^[3]。因此,对坑湖水质准确可靠的评价以及对水质变化合理有效的预测有助于实现循环经济和清洁生产,同时有助于矿区生态环境修复。

目前水质预测的模型根据理论基础不同可分为 4 类:第 1 类是水动力模型,以水质模拟原理为理论基础,其中 QUAL^[4]、WASP^[5]、EFDC^[6]、SWAT^[7]等模型应用广泛;第 2 类是回归分析模型,通过建立线性数学关系式预测水质,其中支持向量机应用广泛;第 3 类是灰色理论模型,通过不确定性理论建立水质趋势预测模型,最具代表的是 GM(1,1)模型;第 4 类是近些年研究广泛的神经网络数学模型,其原理是在水质参数与多元数据之间建立映射关系,传统的映射关系主要是建立显式的方法,得到线性的相关性,如多元线性回归^[8]、自回归积分移动平均^[9]等,但建立显式的方法无法体现实际水质的非线性特征。因此以人工神经网络为代表的通过隐式建立映射关系成为近些年来研究的热门领域。

在水质预测与评价中,水质参数的时间序列具有非平稳性。传统的线性关系无法满足水质情况,因此人工神经网络的优势得以体现,由于具有泛化能力强、计算复杂度低、学习和收敛速度快等优点,目前已在湖泊^[10]、矿区地表水^[11]和地下水预测中得到广泛应用。其中前馈神经网络(feed-forward neural network, FFNN)的研究和应用最为广泛。BP(back propagation)神经网络广泛应用于水体预测^[12],但易造成局部极小值降低预测精度。本研究选取的极限学习机(extreme learning machine, ELM)是一种特殊形式的 FFNN,其结构是前反馈单隐藏层的神经网络。与 BP 神经网络相比,ELM 具有更强的学习能力和更广泛的适用性,尽管容易产生过拟合^[13],但可通过粒子群优化算法(particle swarm optimization, PSO)模拟鸟类觅食来迭代优化目标函数^[14]。

本文对粒子群算法进行优化,设置自适应惯性权重和变异因子,构建 PSO-ELM 模型用于坑湖水质参数时间序列预测,取得了良好的拟合预

测效果,相较于传统的 BP 神经网络,ELM 有更好的精度。通过将实测数据与拟合数据结合,进行水质稳定性评价,实现水质监控与预测。

1 区域概况及数据来源

1.1 区域概况与样品采集

本文研究的露天采矿坑位于安徽马鞍山向山镇南山矿凹山选矿厂以东 3 km,该采场闭坑后最大深度达到约 255 m。蓄水后的坑湖占地面积为 7 690 m²,垂向截面呈锥形,最大深度为 210 m,目前周边建成为占地 60 000 m² 的凹山地质文化公园。根据坑湖所处地理位置及矿企生产取水工艺,生产用水多次循环可能导致水体中铁、锰等金属离子累积^[15],造成水体重金属污染风险。周边地下水、雨水输入等外源性物质^[16]与岩石侵蚀、尾矿组分溶解可能导致硫化物进入坑湖^[17],造成水体存在酸化风险。因此对水质变化趋势进行预测和评价有利于凹山采场水环境治理,同时为矿区生态修复提供技术指导。

本文综合考虑凹山坑周边排水、土壤和植被环境对水体的影响,选定 5 个取样位点,2020 年 7 月至 2022 年 6 月每间隔 1 个月采集 1 次样品。

1.2 数据预处理

由于自然天气和灾害等影响,缺少少量月份的水质数据。本研究用平均值填补缺失值,建立新的完整时间序列的水质数据^[18]。

滑动窗口原理为:假定某水质指标 X 的数据集为 n 个按时间序列的数值,按时间序列构造的数据集为 $X_{(n)} = \{x_{(1)}, x_{(2)}, \dots, x_{(m)}, \dots, x_{(n)}\}$,其中 $x_{(m)}$ 代表水质指标 X 在 m 时间节点上的监测值。以 $x_{(m)}$ 表示当前时刻,则水质指标 X 前 t 个时间段的时间序列可表示为 $X_{(m)} = \{x_{(m-t+1)}, \dots, x_{(m-1)}, x_{(m)}\}$, t 为滑动窗口的大小^[19]。依据滑动窗口的大小,将该水质指标的监测数据转变为滑动窗口处理的数据集,作为 ELM 模型的输入,其原理如图 1 所示。




图 1 滑动窗口原理图

2 改进的 PSO-ELM 模型

2.1 粒子群优化算法

粒子群优化算法是由 Eberhart 在 1995 年提

出,是一种模仿鸟群觅食行为发展起来的进化算法^[20]。假设有 N 个粒子存在于多维度空间,粒子 $i(i < N)$ 的当前位置为 $X_i = (X_{i1}, X_{i2}, \dots, X_{iD})$,当前速度为 $V_i = (V_{i1}, V_{i2}, \dots, V_{iD})$,同时每个粒子具有当前适应度值的位置 $P_i = (P_{i1}, P_{i2}, \dots, P_{iD})$ 。每个粒子为了寻求个体最优解 P_{id} (个体极值)和群体最优解 P_{bd} (群体极值),粒子会不断更新自己的速度和位置,具体公式如下:

$$V_{id}^{k+1} = \omega V_{id}^k + c_1 r_1 (P_{id}^k - X_{id}^k) + c_2 r_2 (P_{bd}^k - X_{id}^k) \quad (1)$$

$$X_{id}^{k+1} = X_{id}^k + V_{id}^{k+1} \quad (2)$$

其中: ω 为惯性权重,该系数用于表示离子对原来速度的保持程度; V_{id} 为粒子速度; k 为当前迭代次数; c_1 、 c_2 分别为粒子自我追踪和整个群体最优值的因子系数,一般在 $[0, 2]$ 区间内; r_1 、 r_2 为 $0 \sim 1$ 之间的随机数。

2.2 改进粒子群优化算法

传统粒子群优化算法中粒子在寻求个体最佳位置和群体最佳位置的聚集过程中易造成趋同效应,算法的收敛速度过快导致局部搜索能力不强,且无法保证做到全局搜索,经常在某个局部最优收敛^[21-22]。为了克服上述缺陷,本研究采用动态非线性变化的权重因子和变异因子进行优化。

2.2.1 自适应惯性权重

惯性权重 ω 反映了当前速度受到上一时刻速度的影响程度,惯性权重数值较小,则粒子群的局部搜索能力强,聚集程度高;当惯性权重数值大时,粒子群全局搜索能力强。而未优化的粒子群算法不能改变惯性权重导致寻优准确度较差。而在实际问题中,水质参数主要是非线性的复杂变化,对于全局搜索能力提出了较高要求。因此本文提出一种改进的自适应非线性动态惯性权重计算公式,具体如下:

$$\omega = \omega_{\max} - \frac{(\omega_{\max} - \omega_{\min})T^2}{T_{\max}^2} \quad (3)$$

其中: ω_{\max} 为初始的权重最大值; ω_{\min} 为最终的权重最小值; T 为当前迭代次数; T_{\max} 为最大迭代次数。在迭代初期, ω 趋于 ω_{\max} ,算法聚集的速度较快,全局搜索能力强,此后 ω 逐渐减小,算法的全局搜索能力转变为局部搜索能力。

2.2.2 变异因子

为避免 PSO 算法过早收敛现象,本文提出一种跳出局部最优的策略。依据遗传算法中的变异思想,引入一个变异因子,通过分析粒子的聚集程度与变异因子的关系,构造了全局位置的更新函

数,使得算法跳出局部最优。具体过程为:① 记录第 t 次迭代时粒子的最优位置;② 随机选择一个位置使变量发生变异,记录变异粒子与当前最佳适应度位置的距离;③ 当随机产生的变异因子与参考因子之间相对位置距离小于 0.5,说明存在距离最优位置小于 0.5 的粒子,此时聚集的粒子将跳出当前最优区域进行搜索和位置更新,变异发生。

2.3 ELM 模型

ELM 由南洋理工大学黄广斌教授首次提出^[23],其输入层初始权值和隐藏层的阈值是随机设定的,只要设置网络的隐层节点个数,算法过程无需调整输入权值。给定 M 个任意样本 $Y_i = (x_i, y_i)$,其中 x_i 为输入数据, y_i 为真实数据,则具有 k 个隐藏结点的单隐藏层极限学习网络输出可以表示为:

$$f_k(x) = \sum_{i=1}^k \beta_i h_i(x) = \mathbf{H}(x)\boldsymbol{\beta} \quad (4)$$

其中: $\mathbf{H}(x)$ 为隐藏节点输出; $h_i(x)$ 为第 i 个隐藏层节点的输出。 $h_i(x)$ 可表示为:

$$h_i(x) = G(\omega_i, b_i, x) = G(\omega_i x + b_i) \quad (5)$$

其中: $\boldsymbol{\omega} = [\omega_1 \ \omega_2 \ \dots \ \omega_k]^T$ 为输入权值; b_i 为第 i 个输入节点和隐含层节点的偏差值; $\boldsymbol{\beta} = [\beta_1 \ \beta_2 \ \dots \ \beta_k]^T$ 为隐藏层(k 个节点)与输出层之间的输出权重; $G(\omega_i, b_i, x)$ 为激活函数,即逼近收敛的非线性分段连续函数。ELM 模型结构如图 2 所示。




图 2 ELM 模型结构

2.4 改进的 PSO-ELM 模型

将 PSO 对 ELM 进行改进,具体步骤如下:

1) 确定输入和输出样本,使用滑动窗建立输入数据集,并对其进行归一化处理。

2) 设置粒子最大迭代次数、惯性权重、群体规模等参数,确定粒子飞行速度,限制取值范围。

3) 确定 ELM 的输入层、隐含层和输出层的神经元个数,并随机生成一组粒子群。

4) 选择 ELM 的激活函数,对 ELM 权值阈值进行赋值。输入学习样本运用 ELM 对网络进行寻优迭代,根据训练集的均方根误差作为适应度值函数,从而确定个体极值和全局极值,记录粒子迭代后的最佳位置。

5) 更新粒子的速度和位置。引入变异因子,计算适应度值,更新粒子的个体极值和群体极值。

6) 判断是否满足结束条件,当适应度值满足精度要求,或达到最大迭代次数,寻优程序终止。将迭代优化后的连接权值、偏置阈值作为网络结构的输入参数,经过模型训练后输出最优解,若未满足要求则返回步骤 4)继续迭代。

具体流程如图 3 所示。

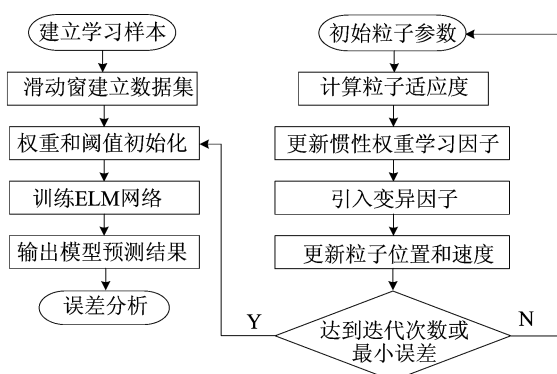


图 3 优化算法流程

3 算法实现与结果分析

3.1 坑湖水质预测模型

粒子群优化算法参数设置为:种群规模 $M = 30$,惯性权重最大值 $\omega_{\max} = 0.9$,最小值 $\omega_{\min} = 0.2$,学习因子 $c_1 = c_2 = 1.5$,最大迭代次数为 100,粒子变异概率为 5%,粒子最大速度 $V_{\max} = 10$,最小速度 $V_{\min} = -10$ 。ELM 神经网络参数设置为:滑动窗口大小为 5,输入层节点个数 $N_1 = 6$,隐藏层节点数 $N_2 = 20$,输出层节点 $N_3 = 1$ 。

选取坑湖水质数据 pH 值、 ρ (溶解氧)、 ρ (总氮)、 ρ (硫酸根)、 ρ (铁离子)、 ρ (锰离子)作为模型输入层。将原始数据归一化处理为 $[0, 1]$ 范围,其中:80%水质数据设为训练集;20%水质数据设为测试集,用于模型测试检验。建立改进的 PSO-ELM 模型,将运行得到的预测值与实际值进行比较分析。使用决定系数 R^2 、均方误差 E_{MSE} 和运行时间作为评价标准,评价标准的计算公式分别为:

$$R^2 = \frac{\sum_{i=1}^n [(y_i - \bar{y}_i)(y - \bar{y})]^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2 \sum_{i=1}^n (y - \bar{y})^2} \quad (6)$$

$$E_{\text{MSE}} = \sum_{i=1}^n (y_i - y)^2 / n \quad (7)$$

其中: y_i 为实测数据; y 为模型预测数据; \bar{y}_i 为实测数据的平均值; \bar{y} 为模型预测数据的平均值; n 为样本数量。

3.2 预测结果分析

为验证改进的 PSO-ELM 模型的实际预测效果,将其与 BP 神经网络和传统的 ELM 模型的预测结果进行比较,其中传统 ELM 神经网络参数设置与本研究提出的 PSO-ELM 模型保持一致。BP 神经网络同样使用单隐藏层结构,输入层的节点数设置为 1,隐藏层的节点数量根据公式 $m = \sqrt{n+l} + \alpha$ 确定,其中: n 为输入层节点数; l 为输出层节点数; α 取 10 以内的自然数,最终确定为 9。故隐藏层节点数为 10,输出层节点数为 1。训练集和验证集数据比例分别为 80% 和 20%,与 ELM 模型保持一致。

将实测数据与各模型模拟数据比对,以 2022 年 1—6 月监测数据作为评价标准,评价指标见表 1 所列,结果如图 4 所示。

表 1 中:改进后的 PSO-ELM 平均决定系数为 0.822,优于传统 ELM 模型的 0.681 和 BP 神经网络的 0.615;平均均方误差仅为 0.04,传统 ELM 模型和 BP 神经网络分别为 0.17 和 0.25。此外,改进后的网络模型平均训练时间仅为 7 s。

表 1 各模型预测指标

预测指标	模型	R^2	E_{MSE}	训练时间/s
pH 值	BP	0.724	0.207	54
	ELM	0.768	0.171	25
	PSO-ELM	0.882	0.008	17
ρ (溶解氧)	BP	0.489	0.282	34
	ELM	0.652	0.143	24
	PSO-ELM	0.791	0.017	8
ρ (总氮)	BP	0.613	0.261	44
	ELM	0.665	0.223	19
	PSO-ELM	0.726	0.062	3
ρ (硫酸根)	BP	0.563	0.256	38
	ELM	0.591	0.163	18
	PSO-ELM	0.756	0.071	5
ρ (铁离子)	BP	0.681	0.287	29
	ELM	0.712	0.172	21
	PSO-ELM	0.883	0.052	4
ρ (锰离子)	BP	0.621	0.226	31
	ELM	0.698	0.169	18
	PSO-ELM	0.835	0.049	5

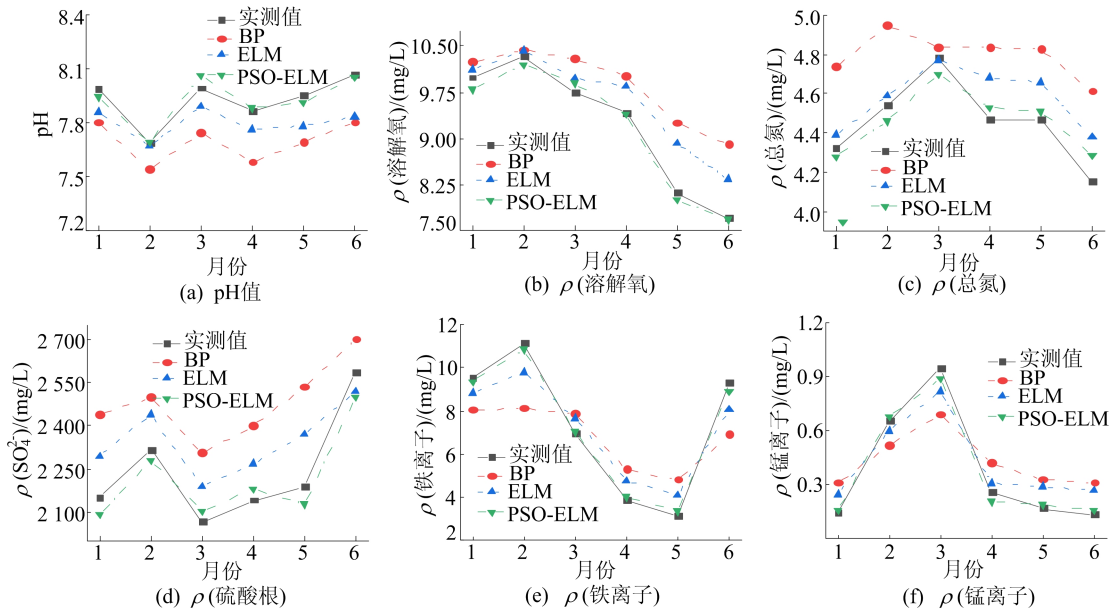


图 4 各模型预测指标拟合曲线

改进后的 PSO-ELM 模型训练集和测试集的决定系数如图 5 所示,该模型的决定系数显著提高,均达到了 0.8 以上,精度也显著提高。因此,本研究模型在传统模型基础上做出改进,表现出良好的预测效果,具有更高的训练效率和收敛速度。




图 5 各模型决定系数对比

3.3 水质稳定性评价

将坑湖训练集数据与预测数据相结合,搭建时间序列的数据集,进行水质稳定性评价。采用 Spearman 的秩相关系数进行 Daniel 趋势检验,评价理化因子变化趋势是否显著。给出时间周期 Y_1, \dots, Y_N 和相应值 X ,排列顺序由大到小,秩相关系数的计算公式^[24]如下:

$$r_s = 1 - 6 \sum_{i=1}^n d_i^2 / (N^3 - N) \quad (7)$$

$$d_i = X_i - Y_i \quad (8)$$

其中: d_i 为变量 X_i 与 Y_i 的差值; X_i 为周期 1 到周期 N 按质量浓度值从小到大排列的序号; Y_i 为按时间排列的序号。

将秩相关系数 r_s 的绝对值与 Spearman 秩相关系数中的临界值 W_p 进行比较:当 $r_s > W_p$ 则表明变化趋势有显著意义,若 r_s 为负值表明在评价时段内统计量指标变化呈下降或好转趋势, r_s 为正值,呈上升或加重趋势;当 $r_s \leq W_p$ 说明在评价时段内水质稳定,评价结果见表 2 所列。

表 2 水质评价结果

评价参数	r_s 值	W_p 值	评价结果
pH 值	0.648	0.679	水质稳定
ρ (溶解氧)	0.532	0.679	水质稳定
ρ (总氮)	0.428	0.679	水质稳定
ρ (硫酸根)	0.671	0.679	水质稳定
ρ (铁离子)	0.198	0.679	水质稳定
ρ (锰离子)	-0.582	0.005	下降趋势

计算结果表明:水体水质情况稳定,pH 值、 ρ (溶解氧)、 ρ (总氮)、 ρ (硫酸根)和 ρ (铁离子)评价结果稳定,无明显变化趋势, ρ (锰离子)呈现下降或好转趋势。评价时段内均未出现上升和加重趋势,表明生产过程和环境因素对水体没有造成污染加重趋势。

4 结 论

本文提出改进的 PSO-ELM 模型对传统粒子群优化算法进行改进,并提出一种改进的自适应惯性权重值计算方法和引入变异因子,提高了全

局和局部搜索能力,极大地降低了陷入局部极值的概率。改进后的 PSO-ELM 模型与传统 ELM、BP 神经网络相比具有更好的泛化性能和更快的速度,能较好地反映和预测坑湖水质的变化情况。将 PSO-ELM 的训练数据与预测数据相结合评价水质稳定性和未来水质指标变化趋势,发现水质稳定性良好,趋势稳定。本研究对坑湖水质的预测与评价有利于矿企的选厂工艺优化和循环水质资源化利用,同时也有利于加快矿区生态修复。

[参 考 文 献]

- [1] GUIMARAES R N, MOREIRA V R, CRUZ J R A, et al. History of tailings dam failure; impacts on access to safe water and influence on the legislative framework[J]. *Science of the Total Environment*, 2022, 852: 158536.
- [2] HARTSOCK J A, PIERCEY J, HOUSE M K, et al. An evaluation of water quality at Sandhill Wetland; implications for reclaiming wetlands above soft tailings deposits in northern Alberta, Canada[J]. *Wetlands Ecology and Management*, 2021, 29(1): 111-127.
- [3] WANG G, TIAN S, HU B, et al. Evolution pattern of Tailings flow from dam failure and the buffering effect of Debris Blocking Dams[J]. *Water*, 2019, 11(11): 2388.
- [4] AL-ZUBAIDI H A M, WELLS S A. Analytical and field verification of a 3D hydrodynamic and water quality numerical scheme based on the 2D formulation in CE-QUAL-W2[J]. *Journal of Hydraulic Research*, 2020, 58(1): 152-171.
- [5] OBIN N, TAO H N, GE F, et al. Research on water quality simulation and water environmental capacity in Lushui River based on WASP Model[J]. *Water*, 2021, 13(20): 2819.
- [6] KIM J, SEO D, JANG M, et al. Augmentation of limited input data using an artificial neural network method to improve the accuracy of water quality modeling in a large lake[J]. *Journal of Hydrology*, 2021, 602: 126817.
- [7] ZHANG Y, XIA J, SHAO Q, et al. Water quantity and quality simulation by improved SWAT in highly regulated Huai River basin of China[J]. *Stochastic Environmental Research and Risk Assessment*, 2013, 27(1): 11-27.
- [8] RAJAEI T, BOROUMAND A. Forecasting of chlorophyll-a concentrations in South San Francisco Bay using five different models[J]. *Applied Ocean Research*, 2015, 53: 208-217.
- [9] ELHAG M, GITAS I, OTHMAN A, et al. Time series analysis of remotely sensed water quality parameters in arid environments, Saudi Arabia[J]. *Environment Development and Sustainability*, 2021, 23(2): 1392-1410.
- [10] HUO S, HE Z, SU J, et al. Prediction of lake eutrophication using artificial neural networks[J]. *International Journal of Environment and Pollution*, 2015, 56 (1/2/3/4): 63-78.
- [11] GONTIJO E S J, MONTEIRO A S C, TONELLO P S, et al. Analyses of colloidal, truly dissolved, and DGT-labile metal species and phosphorus in mining area surrounded by tailing dams using self-organising maps[J]. *Chemosphere*, 2022, 303: 125003.
- [12] CHEN S, FANG G, HUANG X, et al. Water quality prediction model of a water diversion project based on the improved artificial bee colony-backpropagation neural network[J]. *Water*, 2018, 10(6): 806.
- [13] JIANG L, YANG L, HUANG Y, et al. COD optimization prediction model based on CAWOA-ELM in water ecological environment[J]. *Journal of Chemistry*, 2021, 11: 6611777.
- [14] 张利彪, 周春光, 马铭, 等. 基于粒子群算法求解多目标优化问题[J]. *计算机研究与发展*, 2004(7): 1286-1291.
- [15] 范雯霆, 陈诚, 姚斯洋, 等. 平原河网区湖泊湖荡群沉积相重金属污染特征及来源解析[J]. *长江流域资源与环境*, 2022(1): 1-12.
- [16] CASTENDYK D N, WEBSTER-BROWN J G. Sensitivity analyses in pit lake prediction, Martha Mine, New Zealand 1; relationship between turnover and input water density[J]. *Chemical Geology*, 2007, 244(1/2): 42-55.
- [17] ZHU C, HU F Q, BURDEN D S. Multi-component reactive transport modeling of natural attenuation of an acid groundwater plume at a uranium mill tailings site[J]. *Journal of Contaminant Hydrology*, 2001, 52(1/2/3/4): 85-108.
- [18] YAN J, LIU J, YU Y, et al. Water quality prediction in the Luan River based on 1-DRCNN and BiGRU hybrid neural network model[J]. *Water*, 2021, 13(9): 1273.
- [19] GARIBAY V M, GITAU M W, KIGGUNDU N, et al. Evaluation of reanalysis precipitation data and potential bias correction methods for use in data-scarce areas[J]. *Water Resources Management*, 2021, 35(5): 1587-1602.
- [20] 杨维, 李歧强. 粒子群优化算法综述[J]. *中国工程科学*, 2004(5): 87-94.
- [21] 刘建华. 粒子群算法的基本理论及其改进研究[D]. 长沙: 中南大学, 2009.
- [22] 徐大明, 杜永贵, 孙传恒, 等. 基于改进粒子群优化极限学习机的养殖氨态氮含量预测模型[J]. *江苏农业科学*, 2017, 45(4): 183-186.
- [23] HUANG G B, ZHU Q Y. Extreme learning machine: theory and applications[J]. *Neurocomputing*, 2006, 70 (1/2/3): 489-501.
- [24] 高伟, 陈岩, 徐敏, 等. 抚仙湖水质变化(1980—2011年)趋势与驱动力分析[J]. *湖泊科学*, 2013, 25(5): 635-642.

(责任编辑 吴 亮)