

机器学习在水生态环境领域的应用研究进展

侯俊¹, 周宁远¹, 张越¹, 李永年², 丁伟¹, 吴军¹

(1. 河海大学环境学院; 2. 大庆油田水务环保公司)

摘要:针对水生态环境研究中数据稀疏、非线性强和机理刻画不足等问题,基于中国知网和 Web of Science 核心合集 2014—2024 年的相关文献,在梳理经典机器学习、深度学习、集成学习及自动机器学习基本原理的基础上,从水质预测与管理、水体污染物分析、富营养化与蓝藻水华研究、水生态系统保护 4 类场景综述了机器学习在水生态环境领域的应用进展,并结合数据特征、任务目标与模型性能进行了比较分析,提出了问题导向的算法选择建议。结果表明:随机森林、XGBoost 等集成学习算法在中小样本、多因子非线性关系挖掘和变量重要性识别方面具有较好的适用性;LSTM、GRU 等模型更适用于多站点、多时间尺度序列预测;CNN、Transformer 等模型在遥感识别和藻类生物图像分析中展现出较好的应用潜力。目前,机器学习仍面临数据质量不一、模型可解释性不足、算力消耗较高以及与机理模型协同不够等问题,未来可结合数据共享系统,进一步拓展机器学习在水生态环境领域的应用空间。

关键词:机器学习;水生态环境;水质预测;蓝藻水华;生态保护

中图分类号:X52

文献标志码:A

文章编号:1006-7647(2026)05-0001-10

Research progress on application of machine learning in field of aquatic ecological environment//Hou Jun¹, Zhou Ningyuan¹, Zhang Yue¹, Li Yongnian², Ding Wei¹, Wu Jun¹ (1. College of Environment, Hohai University; 2. Daqing Oilfield Water Affairs and Environmental Protection Company)

Abstract: Aiming at the problems of sparse data, strong nonlinearity and insufficient mechanism characterization in aquatic ecological environment research, this paper uses literature published between 2014 and 2024 retrieved from the China National Knowledge Infrastructure (CNKI) and the Web of Science Core Collection. On the basis of sorting out the basic principles of classical machine learning, deep learning, ensemble learning and automated machine learning, this paper reviews the application progress of machine learning in the field of aquatic ecological environment from four research scenarios, including water quality prediction and management, water pollutant analysis, eutrophication and cyanobacterial bloom research, and aquatic ecosystem protection. Furthermore, a comparative analysis is carried out based on data characteristics, task objectives and model performance, and problem-oriented suggestions for algorithm selection are proposed. The results indicate that ensemble learning algorithms such as random forest and XGBoost have good applicability for small- and medium-sized samples, the mining of multi-factor nonlinear relationships and the identification of variable importance. Models including LSTM and GRU are more applicable to multi-site and multi-temporal scale sequence prediction. CNN, Transformer and other models show considerable application potential in remote sensing recognition and algal biological image analysis. At present, the application of machine learning still faces several challenges, including inconsistent data quality, insufficient model interpretability, high computational cost, and inadequate collaboration with mechanistic models. In the future, by leveraging data-sharing systems, the application scope of machine learning in the aquatic ecological environment field can be further expanded.

Key words: machine learning; aquatic ecological environment; water quality prediction; cyanobacterial bloom; ecological protection

随着全球气候变化加剧以及城市化和工业化进程的快速推进,水生态环境问题日益严峻,主要表现为水质恶化、水资源供需矛盾加剧、生态系统退化

等^[1-2]。然而,现有研究在监测、预测与管理实践方面,仍面临数据缺失和水生态环境模型局限两大挑战:①水质数据往往比流量数据更加稀疏^[3],且多为

基金项目:国家重点研发计划项目(2024YFC3210903);国家自然科学基金项目(U23A2058,52370164);江苏省水利科技项目重点项目(2023003)

作者简介:侯俊(1979—),男,教授,博士,主要从事河湖水质改善与生态修复研究。E-mail:hjy_hj@hhu.edu.cn

针对特定环境问题的局部、短期数据,难以全面反映水生态环境的动态变化和长期趋势^[4];②传统的水生态环境模型通常基于现有的机理模型和经验公式^[5],在处理复杂多变的实际情况时,往往存在较大的局限性和不确定性,预测性能难以满足实际需求^[6-7]。

在此背景下,机器学习凭借其强大的数据处理能力和预测性能,成为水生态环境领域研究和实践的有力工具^[8-10]。机器学习是一种通过从历史数据中学习规律,自动生成模型来进行预测和决策的技术。该技术无需显式编程或预设规则,而是利用算法和统计模型从数据中提取特征、建立映射关系,从而实现智能化的任务处理与分析。将机器学习应用于水生态环境领域,不仅可以有效弥补监测数据的缺失,增强数据的时空连续性,而且可以在机理尚不明晰的情况下,借助大数据分析揭示水质变化的内在规律^[4,11]。此前已有研究将改进 BP 神经网络用于地下水环境质量评价^[12],验证了该思路的可行性。

近年来,机器学习越来越受到水生态环境领域研究人员的重视。本文对 2014—2024 年中国知网 (CNKI) 和 Web of Science 核心合集的相关文献进行了检索,检索时间截至 2024 年 12 月,文献类型包括研究论文与综述论文,得到中文论文 224 篇,英文论文 902 篇(图 1)。基于检索结果,本文系统梳理了机器学习算法的分类及基本原理,概述了其在水质预测与管理、水体污染物分析、富营养化与蓝藻水华研究以及水生态系统保护中的主要应用(表 1),并进一步从问题导向出发,讨论不同任务场景下的算法选择与使用边界,以期机器学习在水生态环境领域的进一步应用提供借鉴。




图 1 2014—2024 年机器学习在水生态环境领域相关文献发表趋势

表 1 2014—2024 年机器学习在水生态环境领域不同方向的发文占比

文献来源	发文占比/%				
	水质预测与管理	水体污染物分析	富营养化与蓝藻水华研究	水生态系统保护	其他
中文	37.1	21.9	20.5	12.9	7.6
英文	30.3	23.2	22.4	18.0	6.2
合计	31.6	22.9	22.0	17.0	6.5

1 水生态环境领域常见机器学习算法

机器学习的概念最早由亚瑟·塞缪尔于 1959 年提出^[13],即“在不直接针对问题进行编程的情况下,赋予计算机学习能力的一个研究领域”。20 世纪中后期,机器学习经过了一段漫长而曲折的发展历程^[14-22],进入 21 世纪,深度置信网络^[23]的提出使得机器学习迎来了复兴。如今,大模型和自监督学习推动着机器学习在各领域的广泛应用,如语言处理和语音识别^[24-25],智能化的新时代已经开启。

机器学习主要包括数据预处理、数据集划分、模型构建训练、验证优化及结果分析。通过多指标评价获取最优模型,完成特征重要性分析与指标预测。从任务属性和模型结构角度出发,机器学习算法目前可以大致分为经典机器学习算法、深度学习算法、集成学习算法 3 类^[26],此外,自动机器学习 (AutoML) 目前也受到越来越多的关注。表 2 总结了常用算法的基本原理及适用特点。

经典机器学习可以分为监督学习、无监督学习和半监督学习。监督学习通过学习已有数据的输入-输出对应关系来训练模型,预测新的输入数据的输出,可分为分类算法与回归算法两大类。典型的分类算法有朴素贝叶斯 (NB)^[27]、逻辑回归 (LR)^[28]等。对于回归算法,常见的有多元线性回归 (MLR)^[29]、岭回归 (RR)^[30]等。此外还有兼顾分类与回归的算法,如著名的支持向量机 (SVM)^[31]和决策树 (DT)^[20]。无监督学习通常用于处理没有标注的数据,通过寻找数据的潜在结构进行学习,可分为聚类、降维两类^[32],其常用算法分别为 k 均值聚类 (KMC)^[33]和主成分分析 (PCA)^[34]。除此以外,无监督学习也常用于异常值检测,如局部离群因子 (LOF) 法^[35]。半监督学习结合了少量标注数据和大量未标注数据,通过这两类数据的组合来训练模型^[36]。目前在水生态环境领域,半监督学习的应用仍然较少^[37]。

深度学习实际上是具有多个隐藏层 (≥ 2) 的神经网络 (NN),神经网络是一类受生物神经系统启发的机器学习算法,特别适用于解决复杂的非线性问题,它们由多个互相连接的神经元组成,分为输入层、隐藏层和输出层,每层神经元通过权重与下一层的神经元相连,能够通过训练从数据中自动学习特征和规律^[23]。深度学习的主要算法有卷积神经网络 (CNN)、循环神经网络 (RNN)、长短期记忆网络 (LSTM)、门控循环单元 (GRU)、生成对抗网络 (GAN) 等^[4]。

表 2 常见机器学习算法的基本原理及适用特点

机器学习分类	代表算法	基本原理	适用特点
监督学习	NB	基于贝叶斯定理的分类算法,通过现有先验概率计算所需的后验概率	适合处理大规模数据
	LR	对预测值进行归一化,计算事件的概率与选定的阈值进行比较	适用于二分类问题
	MLR	估计两个或多个独立特征与一个相关特征之间的线性关系	适用于线性或弱非线性任务
	RR	在线性回归的基础上加入 L2 正则化	减少过拟合
	SVM	构建超平面对高维数据进行分类,可以分为支持向量分类(SVC)和支持向量回归(SVR)	适合小样本,高维度特征场景
	DT	通过树形结构的决策规则进行分类,由根节点输入,最后从叶节点输出,分为分类树和回归树	规则直观,可解释性较强
无监督学习	KMC	将数据点分配到 k 个簇中,令簇内的方差最小化	适用于样本分类
	PCA	通过线性变换将数据投影到主成分方向上,实现降维	压缩特征,减少信息损失
半监督学习	Self-Training	通过少量标注数据和大量未标注数据的组合来训练模型	适用于标签稀缺场景
深度学习	CNN	通过卷积操作提取图像的局部特征	适用于图像分类
	RNN、LSTM、GRU	用于处理序列数据,LSTM 是 RNN 的改进版本,能够处理长序列数据中的依赖关系	适用于多时间尺度,多站点序列预测
	GAN	生成模型和判别模型相互对抗来学习,生成数据	适用于数据增强与样本扩展
集成学习(袋装法)	RF	集成多个决策树的预测结果,具有较高的精度与鲁棒性	适用于异构数据与变量筛选
集成学习(提升法)LightGBM、XGBoost		顺序训练多个基学习器,每个都试图纠正前一个的错误,最终将所有结果加权平均,能够在复杂数据集上减少模型的偏差,提高集成模型的预测能力	适用于非线性拟合与重要特征识别
集成学习(堆叠法)		将多个基学习器的预测结果用于训练一个新学习器来进行最终的预测	适合模型比选,提升预测精度
自动机器学习	H2O AutoML、AutoKeras	自动数据预处理、特征工程、模型选择、超参数调优等	适合快速建模,上手难度较低

集成学习算法是一种通过结合多个基学习器(如 DT)来提高模型性能的机器学习算法^[38]。常见的集成学习算法有袋装法(Bagging)、提升法(Boosting)和堆叠法(Stacking)。袋装法通过对原始数据集进行有放回的随机抽样,生成多个不同的子数据集,分别训练多个基学习器,最后将各个基学习器的预测结果以取平均值或投票方式取得最终结果^[39],代表算法是随机森林(RF)^[14]。提升法主要算法有自适应提升算法(AdaBoost)、梯度提升决策树(GBDT)、轻量梯度提升机(LightGBM)、极端梯度提升机(XGBoost)等^[40-42]。堆叠法则没有固定的算法,它可以组合多个不同类型的基学习器,从而获得更强的学习能力^[43]。

自动机器学习(AutoML)是一种通过自动化流程来优化和简化机器学习任务的技术。它能够减少人类在机器学习模型开发过程中的手动干预,从而降低使用门槛。AutoML 提供了从数据预处理、特征提取、模型选择到超参数调优等全流程的自动化解方案,大幅降低了机器学习模型开发的复杂性^[44]。常见的自动机器学习框架有 H2O AutoML、AutoKeras 等。

2 机器学习在水生态环境领域的应用

2.1 水质预测与管理

水质预测与管理是机器学习应用最广泛的场景

之一,其核心问题包括单指标预测、多指标综合评估和缺失数据填补。

在单指标预测方面,溶解氧、叶绿素 a、高锰酸盐指数(COD_{Mn})和浊度等均是当前研究的重点。溶解氧浓度受水温、光照、污染物浓度等多种环境变量的影响,目前对溶解氧变化及其控制因素的理解有限^[45],机器学习能够更好地探究溶解氧和各个因素之间的关系。例如:Zhi 等^[46-47]通过 LSTM 模型的时间序列分析,初步实现了河流溶解氧水平的动态预测;Bao 等^[48]结合鱼群行为特征与 T-S 模糊神经网络对溶解氧变化进行了建模,说明机器学习在多源信息融合预测方面具有较强潜力。对于其他机理尚不明确或难以实时监测的水质指标,机器学习同样适用。例如:Barzegar 等^[49]开发了 CNN 与 LSTM 相结合的混合模型,用于预测湖泊的叶绿素 a 浓度;Nong 等^[50]和 Zare 等^[51]通过集成学习算法,分别预测了水体的 COD_{Mn} 和浊度;美国农业研究局结合灌溉池中的水质参数和无人机影像数据,提升了对大肠杆菌浓度的预测精度^[52]。

除了单一的水质指标预测外,机器学习可以通过耦合多个变量特征,实现综合性的预测。例如:Smith 等^[53]综合了地质地貌、基础设施、土壤特性等静态空间特征和气象、径流、土地覆盖等动态时间特征,提出了预测特拉华河流域盐度的 RF 模型,用于评估驱动流域河流的盐碱化过程;Kim 等^[54]将水质

指数(WQI)与LSTM模型结合,在不依赖COD、TP这类难以实时测量的参数的情况下,对芬兰普拉韦西湖流域进行了综合性的水质评估;Madni等^[55]则基于H2O AutoML平台构建了以WQI为基础的自动化水质分类预测模型,并通过SHAP值^[56]来解释不同特征对模型预测的贡献;Wang等^[57]提出了一种基于Bayesian-LSTM-GRU的混合模型,实现了金清河流域平原河网多水质指标的综合性预测。

在复杂环境下,不同程度的数据缺失或数据量过少是难以避免的,机器学习可以通过数据增强(如随机采样和噪声添加)有效地拓展数据集,提高模型性能。例如:Zhi等^[4]基于监测地点的水质数据,融合水文气象、遥感及流域特征等多源空间数据,构建了深度学习模型,并将其推广至数据稀缺流域,实现了对缺失数据的有效填补;Qi等^[58]在预测水体盐度时,采用数据增强策略有效扩展了数据集,并通过迁移学习在数据量较少的情况下提升了模型的泛化能力和预测精度。

2.2 水体污染物分析

水中污染物的研究对于水生态环境保护具有重要意义。然而,受复杂环境条件和多因素交互作用的制约,现有方法难以全面、准确地反映污染物的动态行为^[59]。机器学习能够提供更精确的溯源分析和迁移预测手段,同时为黑臭水体的研究开辟新的方法路径。

准确识别水生态环境中污染物的来源是预防和修复污染的关键。Duan等^[60]提出了一种整合了机器学习、物联网和大数据的多技术集成的智慧水环境监测系统(S-WEQM),能够准确高效地识别污染物并精准追踪其来源与路径。对于水体中的溶解性有机物(DOM),Liu等^[61]将RF模型与荧光光谱结合,提出了一种新的识别源指数(SI),能有效区分不同来源的DOM;Li等^[62]使用RF模型分析了德国Elbe河微量重金属的来源,发现矿业、金属工业废水的直接排放是最主要的污染源。将机器学习的分类方法与宏基因组数据结合,还能用于抗生素抗性基因(ARGs)的溯源,进而定量评估不同污染源对ARGs污染的贡献^[63]。

机器学习模型也常被用于模拟污染物在水体中的迁移转化过程。例如:Bao等^[64]利用XGBoost模型研究了梯级水库中氮的迁移转化规律,揭示了梯级水库对氮元素输运和保留的影响以及硝酸盐转化的时空变化;Sarkar等^[65]研究了微塑料(MPs)在湿地系统中的迁移、转化、去除机制,并利用*t*-SNE聚类算法分析了MPs作为重金属载体对鱼类等水生动物的影响;Xu等^[66]采用XGBoost方法构建了定

量构效关系(QSAR)模型^[67],模拟和预测了多氯联苯(PCBs)在不同环境条件下的光降解路径和机制;此外,Gao等^[68]将RF与QSAR模型结合,分析了水体有机污染物在二价铁介导下的还原动力学特征,结果表明,耦合模型的拟合与预测性能均显著优于单一模型。

黑臭水体是指呈现令人不悦的颜色或散发令人不适气味的水体。对于黑臭水体的识别,解明权等^[69]提出了基于贝叶斯卷积网络(BCN)的黑臭水体遥感识别算法,能够精确地提取遥感图像中的黑臭水体特征;刘中等^[70]进一步将DOM数据与RF算法结合,解析了黑臭水体的形成机制,对水体中有机的种类及其与黑臭程度的关系进行了深入分析。关于黑臭水体中的致嗅物质,Huang等^[71]将分子指纹特征和MS²质谱数据与气味特性关联,采用RF/GBDT等算法,实现了对水中复杂化学物质气味特性的预测,为进一步理解黑臭水体中的气味成因提供了科学依据。

2.3 富营养化与蓝藻水华研究

富营养化与蓝藻水华是湖泊、水库和河口等缓流水体中最突出的生态环境问题之一,其形成与演变受营养盐输入、水温、风场、水动力条件及人类活动等多种因素共同影响,具有显著的非线性和时空异质性。因此,该领域已成为机器学习算法的重要应用场景,现有研究主要集中在水体营养状态评估与水华预警、蓝藻水华时空分布特征分析、环境驱动因子分析以及藻类图像处理等方面。

营养状态指数(TSI)是基于水体中的透明度、叶绿素a、总磷等参数计算所得的综合指标,用于量化评估水体的营养水平并划分富营养化等级,对富营养化控制具有重要意义。Zhang等^[72]提出了一种通过光学吸收系数间接推算TSI的方法,并与深度神经网络(DNN)结合,评估了中国961个湖泊的营养状态;Meng等^[73]则利用BP神经网络构建了TSI反演模型,并通过麻雀搜索算法(SSA)优化模型,实现了洪泽湖营养状态的较高精度评估;Shang等^[74]利用XGBoost模型和遥感数据,预测了湖泊的腐殖化指数(HIX),并分析了其在不同营养状态下的变化趋势。在充分掌握水体营养状态之后,可以进一步实现水华预警,如Qian等^[75]结合大数据与深度学习技术,开发了一种预测有害藻华(HABs)的Bloomformer-2模型,优化了自注意力机制,能够提供比传统LSTM更精确的预警结果。

机器学习模型与遥感技术结合能够有效提取蓝藻水华的时空分布特征。在时间分布上,于家斌等^[76]和Ni等^[77]分别通过遗传算法和注意力机制

优化了长短期记忆网络 (LSTM) 模型,提高了叶绿素 a 的预测精度,进而表征水华爆发的时间特点。在空间分布上,Pan 等^[78]将遥感指数引入 RF 模型,并通过量子粒子群算法 (QPSO) 优化参数选择,能够更全面地表征不同水文条件下的蓝藻水华特征;Liu 等^[79]结合图像超分辨率和侧窗卷积技术开发了一种基于深度学习的蓝藻水华识别算法 HAB-Net,提高了对条带状分布藻华的识别精度;Song 等^[80]利用无人机多光谱影像训练了改进的 Transformer 模型,结果显示,在光照和阴影条件下,该模型的水华检测精度较传统遥感指数法 NDVI 分别提升了 11.1% 和 5.4%。

机器学习能够识别蓝藻水华与环境因子之间的关系。RF 模型在这方面展现了极大的潜力,模型能够有效捕捉环境因子与蓝藻水华之间的非线性关系^[81],已被用于分析太湖蓝藻爆发的主要气象驱动因子^[82]和水质驱动因子^[83]。例如:金晓龙等^[84]利用水质监测数据与气象数据训练增强了回归树模型,成功识别了爆发期与非爆发期影响巢湖蓝藻水华的主要驱动因子;潘佳敏等^[85]通过小波-神经网络模型分析了富营养化与气象因子的多尺度耦合关系,揭示了不同时间尺度上气象因子对氮磷浓度变化的影响,并提出了季节性削减氮磷比的治理策略。

深度学习模型在藻类图像识别中的应用,为藻类的快速、准确检测和分类提供了新思路。例如:Chong 等^[86]建立了深度卷积神经网络 (DCNN) 与自动编码器相结合的模型,用于藻类显微图像的识别与分类,在处理低分辨率显微图像时表现优异;Sonmez 等^[87]开发了一种 CNN 与 SVM 的混合模型,用于区分蓝藻和绿藻的图像,准确率高达 99.66%;Chan 等^[88]利用基于 GAN 的 StyleGAN2-ADA 实现藻类图像增强,通过生成人工图像扩充数据集,提高了分类模型的性能,尤其增强了对稀有藻类的识别能力。

2.4 水生态系统保护

生态领域的数据具有多维度、高复杂性和不确定性等特征^[89],且多种环境因素之间往往存在复杂的耦合作用,使得单因素分析方法(如相关性分析和回归分析)难以获得较好的效果。机器学习能够耦合多个特征进行预测,为这些问题提供了创新的解决方案。机器学习在生态系统保护方面的应用主要包括物种识别与保护、栖息地保护和生态系统健康评估。

物种识别与保护是生物多样性保护的核心任务。传统的物种识别方法依赖于人工观察和分类,费时且易出错。基于深度学习的图像识别技术能够

实现物种的高精度自动化识别,如 Yang 等^[90]利用 CNN 模型,通过自动提取特征,成功实现了部分鱼类的识别。此外,深度学习还有助于监测人类活动对生态系统的影响,如 Chen 等^[91]采用神经网络 (NN) 模型预测了中国淡水鱼类的保护状况与灭绝风险,为未来制定保护优先策略指明了方向。

栖息地保护对于维护水生生态系统平衡至关重要。机器学习能够在复杂的水生环境中捕捉复杂的模式和关系,为栖息地保护提供了强大的分析工具。例如:Agrawal 等^[92]通过机器学习模型分析了复杂的环境模式,成功实现了鱼类的栖息地适宜性分析;Yoshida 等^[93]分析了不同环境因子对鲈鱼产卵栖息地适宜性的影响,发现水温、盐度和河床基质对鱼类产卵成功与否至关重要。在数据支持的情况下,机器学习还能监测栖息地的变化。例如:唐希颖等^[94]验证了 RF 模型在湿地植物物种多样性大尺度反演方面的预测能力,实现了大范围、较高精度的湿地变化预测;何博浩^[95]利用 RF 和鲸鱼优化算法 (RF-SWOA) 结合多维环境数据进行建模,预测了海草栖息地的分布及未来变化。

生态系统健康评估旨在量化生态系统的稳定性和可持续性,从而更好地保护生态资源。随着多源数据的涌现,机器学习通过整合气候、环境、水质等多维数据,为生态系统健康评估提供了新的分析方式。例如:崔东文等^[96]通过构建 RF 模型,实现了云南文山州水生态环境的初步评价,表明该方法在复杂指标体系处理中具有较好的适用性;Kwon 等^[97]构建了 CNN 模型,引入营养硅藻指数、底栖大型无脊椎动物指数和鱼类评估指数构建了水生态系统健康指数,预测了水生生态系统的健康水平。

3 分析与讨论

3.1 问题导向的算法选择建议

不同问题类型在数据结构、研究目标和模型需求上存在明显差异,算法选择不能脱离具体任务场景而单独讨论。然而,现有研究多侧重于具体案例中的模型构建与性能比较,对于不同水生态环境问题应如何结合数据特征、任务目标和应用需求选择合适算法,尚缺乏系统归纳。事实上,机器学习算法并不存在适用于所有场景的统一最优方案,不同算法在样本规模、特征维度、时空结构、可解释性和计算成本等方面各具优势与局限。因此,在前述应用进展基础上,有必要进一步从问题导向出发,总结不同类型水生态环境研究中机器学习算法的适用场景与选择依据,从而为相关研究和实践应用提供更具针对性的参考。表 3 从典型问题出发,总结了常用

表 3 水生态环境典型问题的机器学习算法选择建议

问题场景	数据特征	推荐算法	推荐理由	应用要点
水质单指标短期预测	连续监测数据,时间依赖性强	LSTM、GRU	能够捕捉时序依赖与非线性波动	需保证样本长度并控制过拟合
水质综合评价与分级	中小样本,多指标耦合	RF、XGBoost、LightGBM	兼顾精度、稳健性和变量重要性识别	建议结合交叉验证与特征筛选
缺失数据填补与跨区域迁移	样本不平衡,站点差异较大	自编码器、LSTM、迁移学习	适于学习隐含结构并提升迁移能力	需关注源域与目标域差异
污染物溯源与驱动因子识别	多源异构数据,可解释性要求较高	RF、XGBoost+SHAP、AutoML	精度与解释性相对平衡	分析结果应结合实际规律
水华时间序列预警	叶绿素 a、藻密度等连续序列	LSTM、Transformer	适于多步预测和长期依赖建模	宜引入气象和水动力变量
水华空间识别与遥感反演	多光谱或高分辨率影像	CNN、Transformer、RF	空间特征提取能力较强	应区分识别任务与预警任务
物种识别与生态图像分析	图像样本,类别不均衡	CNN、GAN、Transformer	适于图像分类与样本增强	需关注样本偏移与泛化能力
生态健康综合评估	多维指标,管理导向明显	RF、Stacking、AutoML	便于综合评价与模型比选	建议结合专家知识进行校核

算法的适配关系与选择依据。

总体来看,若研究目标是解释驱动机制或为管理决策提供支撑,应优先考虑 RF、XGBoost、LightGBM 等兼顾精度与可解释性的模型;若研究对象具有明显的长时间依赖或高维影像特征,则更适合采用 LSTM、GRU、CNN 或 Transformer;当样本规模有限且需要快速建立可比模型时,AutoML 和树模型具有较高实践价值。

3.2 算法选择的关键考量

在实际应用中,算法选择至少应考虑 4 个方面:①数据规模与标签质量。小样本、噪声较大的监测数据不宜直接使用参数量过大的深度模型。②时空结构。多站点长序列预测应突出时间依赖建模,遥感识别与生物图像分类则更关注空间纹理和上下文特征。③可解释性需求。面向污染溯源、驱动因子识别和管理决策的研究,不仅需要较高精度,还需要明确变量贡献和响应方向,可结合 SHAP 等解释方法增强结果可信度。④部署与推广成本。对于基层监测和业务化应用,训练效率、参数可复用性和模型可迁移性与预测精度同样重要。综合考虑上述 4 个因素,H2O AutoML 因其自带可解释性模块、自动训练、集成模型等特点,在水生态环境领域有着较好的应用前景。

4 挑战与展望

机器学习在水生态环境领域应用前景广阔,但同时也在数据获取、模型可解释性、计算资源以及与机理模型整合等方面面临着挑战。

4.1 数据获取与质量

数据是机器学习模型成功的基础,然而在水生态环境领域,数据的获取及其质量管理是两大主要

瓶颈。此外,水生态环境数据通常包括物理、化学、生物和气象等多维度数据,这些数据源异构性强,如何有效整合和处理多源异构数据是机器学习应用中的难点之一。针对数据获取与质量问题,未来应加强多源监测数据标准化、共享平台建设和质量控制流程,推动长时间序列、跨区域、跨尺度数据的整合,以提高模型训练基础。

4.2 模型可解释性与可用性

虽然机器学习模型在预测和分析中的表现优异,但其“黑箱”特性常常限制了其在环境科学领域的广泛应用,尤其是当应用场景对透明性和可解释性提出明确要求时,这一缺陷更为突出。此外,水生态环境领域的研究人员可能缺乏机器学习方面的专门知识,这使其在实际应用上面临较大困难。机器学习模型的复杂算法不仅需要大量数据,还需要专业的编程和模型调优能力,传统的环境科学家在实际操作中会感到困难。针对模型可解释性与可用性不足的问题,应发展更适配环境科学场景的解释框架,集成变量贡献分析、响应阈值识别和不确定性表达,并降低模型部署和使用门槛。

4.3 计算资源与能效

在水生态环境领域,机器学习模型通常需要处理大量的时空数据,这对计算资源的要求极高。尤其是深度神经网络等复杂模型通常需要大量的计算资源来进行训练和推理,当面对大规模环境数据时,这一需求更为迫切。深度学习模型的训练通常依赖高性能计算资源,对环境研究团队的技术基础设施提出了较高的要求。针对计算资源与业务化应用之间的矛盾,应根据任务复杂度选择适度模型,避免在小样本场景中盲目采用高算力模型,同时关注 AutoML 在实际场景中的应用潜力。

4.4 与传统机理模型的整合与平衡

机器学习模型擅长模式识别和大数据分析,属于数据驱动的方法,而传统的机理模型基于明确的物理规律和机理。如何将两者有效整合,使其优势互补,是当前研究的难点。河湖生态环境演变往往受到流量、水位、水动力条件及水文节律等多种水文要素的共同调控,具有显著的多因子耦合和动态响应特征。因此,许多应用场景需要同时兼顾物理过程机理与机器学习模型的预测能力。针对数据驱动方法与机理认知脱节的问题,未来应加强机器学习与水文、水动力、水质及生态过程模型的耦合研究,以提升模型的泛化能力和科学解释力。

5 结 语

水生态环境领域充斥着复杂的非线性过程,机器学习由于能够较好地处理复杂非线性关系,在水生态环境领域展现出较大的应用潜力。现有研究表明,机器学习已广泛应用于水质预测与管理、污染物分析、富营养化与蓝藻水华研究、水生态系统保护等方面,并在非线性拟合、多源数据融合和复杂模式识别等方面表现出较强优势。总体上,RF、XGBoost 等模型更适合作为中小样本和因子识别任务的首选方案,LSTM、GRU 和 Transformer 更适用于长序列预测与高维特征学习,CNN、GAN 等则更适合遥感与图像分析任务。未来研究应着眼于提高模型的可解释性、优化数据获取与整合、平衡模型复杂度与计算资源消耗,同时探索与机理模型的有机结合,以推动水生态环境领域的智能化发展。

参考文献:

[1] Larsen T A,Hoffmann S,Lüthi C,et al. Emerging solutions to the water challenges of an urbanizing world [J]. Science,2016,352(6288):928-933.

[2] 景晓栋,田贵良,张钰宁. 治水新思路下我国水生态补偿实践探索与政策建议[J]. 水利经济,2024,42(6): 50-57. (Jing Xiaodong, Tian Guiliang, Zhang Yuning. Exploration of water ecological compensation practice and policy suggestions in China under new thinking of water governance[J]. Journal of Economics of Water Resources, 2024,42(6):50-57. (in Chinese))

[3] McCabe M F,Rodell M,Alsdorf D E,et al. The future of Earth observation in hydrology [J]. Hydrology and Earth System Sciences,2017,21(7):3879-3914.

[4] Zhi W,Appling A P,Golden H E,et al. Deep learning for water quality[J]. Nature Water,2024,2(3):228-241.

[5] 周信哲,陈永娟,蒲文鹏. 机器学习在水质预测中的应用[C]//2020 中国环境科学学会科学技术年会. 南京:

中国环境科学学会,2020:3942-3947.

[6] 万雅虹. 神经网络模型在水质评价中的应用[D]. 舟山:浙江海洋大学,2017.

[7] 朱瑶,梁志伟,李伟,等. 流域水环境污染模型及其应用研究综述[J]. 应用生态学报,2013,24(10): 3012-3018. (Zhu Yao,Liang Zhiwei,Li Wei,et al. Watershed water environment pollution models and their applications: a review[J]. Chinese Journal of Applied Ecology,2013,24(10):3012-3018. (in Chinese))

[8] Zhong Shifa, Zhang Kai, Bagheri M, et al. Machine learning:new ideas and tools in environmental science and engineering [J]. Environmental Science & Technology, 2021,55(19):12741-12754.

[9] 曹俊,张晓敏,朱迪,等. 基于机器学习模型的长江上游典型产漂流性卵鱼类自然繁殖与环境特征关系研究 [J]. 水资源保护,2025,41(6): 251-258. (Cao Jun, Zhang Xiaomin, Zhu Di, et al. Relationship between natural reproduction of typical producing semi-buoyant eggs fish in upper reaches of the Yangtze River and environmental characteristics based on machine learning models[J]. Water Resources Protection, 2025,41(6): 251-258. (in Chinese))

[10] 刘娣,孙佳倩,余钟波. 基于机器学习模型的多层土壤湿度反演[J]. 河海大学学报(自然科学版),2024,52(3):7-14. (Liu Di,Sun Jiaqian,Yu Zhongbo. Multi-layer soil moisture inversion based on machine learning models [J]. Journal of Hohai University (Natural Sciences), 2024,52(3):7-14. (in Chinese))

[11] 涂吉昌,陈超波,王景成,等. 基于深度学习的水质预测模型研究[J]. 自动化与仪表,2019,34(6):96-100. (Tu Jichang,Chen Chaobo,Wang Jingcheng,et al. Research on water quality prediction model based on deep learning [J]. Automation & Instrumentation, 2019,34(6): 96-100. (in Chinese))

[12] 曹剑峰,平建华,Sumare O,等. 改进 BP 神经网络在地下水环境质量评价中的应用[J]. 水利水电科技进步,2006,26(3):21-23. (Cao Jianfeng,Ping Jianhua,Sumare O,et al. Application of improved BP neural network to groundwater environmental quality evaluation [J]. Advances in Science and Technology of Water Resources, 2006,26(3):21-23. (in Chinese))

[13] Samuel A L. Some studies in machine learning using the game of checkers [J]. IBM Journal of Research and Development,1959,3(3):210-229.

[14] Breiman L. Random forests[J]. Machine Learning,2001,45(1):5-32.

[15] Rosenblatt F. The perceptron: a probabilistic model for information storage and organization in the brain [J]. Psychological Review,1958,65(6):386-408.

[16] Minsky M, Papert S A. Perceptrons: an introduction to computational geometry[M]. Cambridge:The MIT Press,

- [17] Werbos P. Beyond regression; new tools for prediction and analysis in the behavioral sciences [D]. Cambridge: Harvard University, 1974.
- [18] Linnainmaa S. Taylor expansion of the accumulated rounding error[J]. BIT, 1976, 16(2): 146-160.
- [19] McClelland J L, Rumelhart D E, Group P R, et al. Parallel distributed processing, volume 2: explorations in the microstructure of cognition: psychological and biological models[M]. Cambridge: The MIT Press, 1986.
- [20] Quinlan J R. Induction of decision trees [J]. Machine Learning, 1986, 1(1): 81-106.
- [21] LeCun Y, Boser B, Denker J S, et al. Backpropagation applied to handwritten zip code recognition [J]. Neural Computation, 1989, 1(4): 541-551.
- [22] Cortes C, Vapnik V. Support-vector networks[J]. Machine Learning, 1995, 20(3): 273-297.
- [23] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- [24] Seide F, Li Gang, Yu Dong. Conversational speech transcription using context-dependent deep neural networks[C]//Interspeech 2011. Florence: ISCA, 2011: 437-440.
- [25] Stokel-Walker C, Van Noorden R. What ChatGPT and generative AI mean for science [J]. Nature, 2023, 614(7947): 214-216.
- [26] Huang Ruixing, Ma Chengxue, Ma Jun, et al. Machine learning in natural and engineered water systems [J]. Water Research, 2021, 205: 117666.
- [27] McCallum A, Nigam K. A comparison of event models for Naive Bayes text classification [C]//AAAI-98 Workshop on Learning for Text Categorization. Madison: AAAI Press, 1998: 41-48.
- [28] Friedman J, Hastie T, Tibshirani R. Additive logistic regression; a statistical view of boosting (with discussion and a rejoinder by the authors) [J]. The Annals of Statistics, 2000, 28(2): 337-407.
- [29] Noori R, Khakpour A, Omidvar B, et al. Comparison of ANN and principal component analysis-multivariate linear regression models for predicting the river flow based on developed discrepancy ratio statistic [J]. Expert Systems with Applications, 2010, 37(8): 5856-5862.
- [30] Hoerl A E, Kennard R W. Ridge regression: biased estimation for nonorthogonal problems [J]. Technometrics, 2000, 42(1): 80-86.
- [31] Schölkopf B, Smola A J. Learning with kernels: support vector machines, regularization, optimization, and beyond [J]. IEEE Transactions on Neural Networks, 2005, 16(3): 781-781.
- [32] Hofmann T. Unsupervised learning by probabilistic latent semantic analysis [J]. Machine Learning, 2001, 42(1/2): 177-196.
- [33] Jain A K. Data clustering; 50 years beyond K-means [J]. Pattern Recognition Letters, 2010, 31(8): 651-666.
- [34] Jolliffe I T, Cadima J. Principal component analysis: a review and recent developments [J]. Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences, 2016, 374(2065): 20150202.
- [35] Breunig M M, Kriegel H P, Ng R T, et al. LOF: identifying density-based local outliers [C]//Proceedings of the 2000 ACM SIGMOD International Conference on Management of Data. Dallas: ACM, 2000: 93-104.
- [36] Zhu Xiaojin, Goldberg A B. Introduction to semi-supervised learning [M]. Cham: Springer, 2009.
- [37] Haggerty R, Sun Jianxin, Yu Hongfeng, et al. Application of machine learning in groundwater quality modeling: a comprehensive review [J]. Water Research, 2023, 233: 119745.
- [38] Dietterich T G. Ensemble methods in machine learning [C]//Proceedings of the 1st International Workshop on Multiple Classifier Systems. Cagliari: Springer, 2000: 1-15.
- [39] Breiman L. Bagging predictors [J]. Machine Learning, 1996, 24(2): 123-140.
- [40] Friedman J H. Greedy function approximation: a gradient boosting machine [J]. The Annals of Statistics, 2001, 29(5): 1189-1232.
- [41] Chen Tianqi, Guestrin C. XGBoost: a scalable tree boosting system [C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco: ACM, 2016: 785-794.
- [42] Ke Guolin, Meng Qi, Finley T, et al. LightGBM: a highly efficient gradient boosting decision tree [C]//Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc. , 2017: 3149-3157.
- [43] Ting Kaiming, Witten I H. Stacking bagged and dagged models [C]//Proceedings of the 14th International Conference on Machine Learning. San Francisco: Morgan Kaufmann Publishers Inc. , 1997: 367-375.
- [44] He Xin, Zhao Kaiyong, Chu Xiaowen. AutoML: a survey of the state-of-the-art [J]. Knowledge-Based Systems, 2021, 212: 106622.
- [45] Sánchez E, Colmenarejo M F, Vicente J, et al. Use of the water quality index and dissolved oxygen deficit as simple indicators of watersheds pollution [J]. Ecological Indicators, 2007, 7(2): 315-328.
- [46] Zhi Wei, Feng Dapeng, Tsai W P, et al. From hydrometeorology to river water quality: can a deep learning model predict dissolved oxygen at the continental scale? [J]. Environmental Science & Technology, 2021,

- 55(4):2357-2368.
- [47] Pyo J, Pachepsky Y, Kim S, et al. Long short-term memory models of water quality in inland water environments[J]. Water Research X, 2023, 21:100207.
- [48] Bao Yujun, Ji Changying, Zhang Bing. Prediction of dissolved oxygen content changes based on two-dimensional behavior features of fish school and T-S fuzzy neural network[J]. Water Science and Engineering, 2022, 15(3):210-217.
- [49] Barzegar R, Aalami M T, Adamowski J. Short-term water quality variable prediction using a hybrid CNN-LSTM deep learning model [J]. Stochastic Environmental Research and Risk Assessment, 2020, 34(2):415-433.
- [50] Nong Xizhi, Lai Cheng, Chen Lihua, et al. A novel coupling interpretable machine learning framework for water quality prediction and environmental effect understanding in different flow discharge regulations of hydro-projects [J]. Science of the Total Environment, 2024, 950:175281.
- [51] Zare M S, Nikoo M R, Al-Rawas G, et al. Integrated ensemble learning approach for multi-depth water quality estimation in reservoir environments[J]. Journal of Water Process Engineering, 2024, 66:105840.
- [52] Hong S M, Morgan B J, Stocker M D, et al. Using machine learning models to estimate *Escherichia coli* concentration in an irrigation pond from water quality and drone-based RGB imagery data [J]. Water Research, 2024, 260:121861.
- [53] Smith J D, Koenig L E, Sleckman M J, et al. Predictive understanding of stream salinization in a developed watershed using machine learning [J]. Environmental Science & Technology, 2024, 58(42):18822-18833.
- [54] Kim H I, Kim D, Mahdian M, et al. Incorporation of water quality index models with machine learning-based techniques for real-time assessment of aquatic ecosystems [J]. Environmental Pollution, 2024, 355:124242.
- [55] Madni H A, Umer M, Ishaq A, et al. Water-quality prediction based on H₂O AutoML and explainable AI techniques[J]. Water, 2023, 15(3):475.
- [56] Lundberg S M, Lee S I. A unified approach to interpreting model predictions [C]//Proceedings of the 31st International Conference on Neural Information Processing System. Long Beach:Curran Associates Inc. , 2017:4768-4777.
- [57] Wang Kefan, Liu Lei, Ben Xuechen, et al. Hybrid deep learning based prediction for water quality of plain watershed [J]. Environmental Research, 2024, 262:119911.
- [58] Qi Siyu, He Minxue, Hoang R, et al. Salinity modeling using deep learning with data augmentation and transfer learning[J]. Water, 2023, 15(13):2482.
- [59] Chen Fanlun, Yang B C, Peng Shuyi, et al. Applying a deployment strategy and data analysis model for water quality continuous monitoring and management [J]. International Journal of Distributed Sensor Networks, 2020, 16(6):155014772092982.
- [60] Duan Qiannan, Zhang Qi, Quan Xudong, et al. Innovations of water pollution traceability technology with artificial intelligence[J]. Earth Critical Zone, 2024, 1(1):100009.
- [61] Liu Dongping, Nie Lei, Xi Beidou, et al. A novel-approach for identifying sources of fluvial DOM using fluorescence spectroscopy and machine learning model [J]. npj Clean Water, 2024, 7(1):79.
- [62] Li Peifeng, Hua Pei, Zhang Jin, et al. Ecological risk and machine learning based source analyses of trace metals in typical surface water [J]. Science of the Total Environment, 2022, 838:155944.
- [63] Li Liguan, Huang Qi, Yin Xiaole, et al. Source tracking of antibiotic resistance genes in the environment: challenges, progress, and prospects [J]. Water Research, 2020, 185:116127.
- [64] Bao Yufei, Wang Yuchun, Hu Mingming, et al. Deciphering the impact of cascade reservoirs on nitrogen transport and nitrate transformation: insights from multiple isotope analysis and machine learning [J]. Water Research, 2025, 268:122638.
- [65] Sarkar D J, Das Sarkar S, Das B K, et al. Occurrence, fate and removal of microplastics as heavy metal vector in natural wastewater treatment wetland system [J]. Water Research, 2021, 192:116853.
- [66] Xu Jianqiao, Wei Junyan, Wei Xinyuan, et al. Photodegradation of polychlorinated biphenyls (PCBs) on suspended particles from the Yellow River under sunlight irradiation; QSAR model and mechanism analysis [J]. Water Research, 2024, 267:122547.
- [67] Lyu Yitao, Huang Taobo, Liu Wen, et al. Unveil the quantum chemical descriptors determining direct photodegradation of antibiotics under simulated sunlight: batch experiments and model development [J]. Journal of Environmental Chemical Engineering, 2022, 10(3):108086.
- [68] Gao Yidan, Zhong Shifa, Torralba-Sanchez T L, et al. Quantitative structure activity relationships (QSARs) and machine learning models for abiotic reduction of organic compounds by an aqueous Fe(II) complex [J]. Water Research, 2021, 192:116843.
- [69] 解明权, 闵松寒, 杨辉, 等. 基于贝叶斯卷积网络的农村黑臭水体遥感识别算法研究[J]. 环境科学学报, 2024, 44(3):215-226. (Xie Mingquan, Min Songhan, Yang Hui, et al. A remote sensing recognition algorithm for rural black and odorous water bodies on Bayesian convolutional networks [J]. Acta Scientiae Circumstantiae, 2024, 44

- (3):215-226. (in Chinese))
- [70] 刘中,吴蕊,顾霓涛,等.溶解性有机质数据结合机器学习算法对黑臭水体形成机制的解析[J].环境工程,2025,43(8):280-291. (Liu Zhong, Wu Rui, Gu Nitao, et al. Analysis of formation mechanism of black-odor water bodies by combining dissolved organic matter data with machine learning[J]. Environmental Engineering, 2025, 43(8):280-291. (in Chinese))
- [71] Huang Yuanxi, Bu Lingjun, Huang Kuan, et al. Predicting odor sensory attributes of unidentified chemicals in water using fragmentation mass spectra with machine learning models[J]. Environmental Science & Technology, 2024, 58(26):11504-11513.
- [72] Zhang Dong, Shi Kun, Wang Weijia, et al. An optical mechanism-based deep learning approach for deriving water trophic state of China's lakes from Landsat images[J]. Water Research, 2024, 252:121181.
- [73] Meng Dinghua, Mao Jingqiao, Li Weifeng, et al. An integrated framework for remote sensing assessment of the trophic state of large lakes[J]. Remote Sensing, 2023, 15(17):4238.
- [74] Shang Yingxin, Song Kaishan, Lai Fengfa, et al. Remote sensing of fluorescent humification levels and its potential environmental linkages in lakes across China[J]. Water Research, 2023, 230:119540.
- [75] Qian Jing, Qian Li, Pu Nan, et al. An intelligent early warning system for harmful algal blooms: harnessing the power of big data and deep learning[J]. Environmental Science & Technology, 2024, 58(35):15607-15618.
- [76] 于家斌,尚方方,王小艺,等.基于遗传算法改进的一阶滞后滤波和长短期记忆网络的蓝藻水华预测方法[J].计算机应用,2018,38(7):2119-2123. (Yu Jiabin, Shang Fangfang, Wang Xiaoyi, et al. Cyanobacterial bloom forecast method based on genetic algorithm-first order lag filter and long short-term memory network[J]. Journal of Computer Applications, 2018, 38(7):2119-2123. (in Chinese))
- [77] Ni Jianjun, Liu Ruping, Tang Guangyi, et al. An improved attention-based bidirectional LSTM model for cyanobacterial bloom prediction[J]. International Journal of Control, Automation and Systems, 2022, 20(10):3445-3455.
- [78] Pan Xin, Yuan Jie, Yang Zi, et al. Spatio-temporal variation of cyanobacteria blooms in Taihu Lake using multiple remote sensing indices and machine learning[J]. Remote Sensing, 2024, 16(5):889.
- [79] Liu Rongjie, Cui Binge, Dong Wenwen, et al. A refined deep-learning-based algorithm for harmful-algal-bloom remote-sensing recognition using *Noctiluca scintillans* algal bloom as an example[J]. Journal of Hazardous Materials, 2024, 467:133721.
- [80] Song Ze, Xu Wenxin, Dong Huilin, et al. Research on cyanobacterial-bloom detection based on multispectral imaging and deep-learning method[J]. Sensors, 2022, 22(12):4571.
- [81] 徐虹,戴丛蕊,何雨琴,等.定量评估气象条件对滇池蓝藻水华发生的影响及预测[J].水生生态学杂志,2024,47(2):89-96. (Xu Hong, Dai Congrui, He Yuqin, et al. Quantitative assessment and prediction of effects of meteorological conditions on the occurrence of cyanobacteria blooms in Dianchi Lake[J]. Journal of Hydroecology, 2024, 47(2):89-96. (in Chinese))
- [82] 罗晓春,杭鑫,曹云,等.太湖富营养化条件下影响蓝藻水华的主导气象因子[J].湖泊科学,2019,31(5):1248-1258. (Luo Xiaochun, Hang Xin, Cao Yun, et al. Dominant meteorological factors affecting cyanobacterial blooms under eutrophication in Lake Taihu[J]. Journal of Lake Sciences, 2019, 31(5):1248-1258. (in Chinese))
- [83] 王梦竹.太湖富营养化变化过程及环境驱动因子识别[D].天津:天津大学,2019.
- [84] 金晓龙,邓学良,戴睿,等.基于多源数据的巢湖蓝藻水华时空分布及驱动因素分析[J].环境科学,2024,45(5):2694-2706. (Jin Xiaolong, Deng Xueliang, Dai Rui, et al. Analysis of the spatiotemporal distribution of algal blooms and its driving factors in Chaohu Lake based on multi-source datasets[J]. Environmental Science, 2024, 45(5):2694-2706. (in Chinese))
- [85] 潘佳敏,冯禹昊,谢平,等.基于小波-神经网络耦合模型对云南星云湖富营养化气象驱动因子的分析[J].湖泊科学,2021,33(2):428-438. (Pan Jiamin, Feng Yuhao, Xie Ping, et al. Meteorological driving factor of eutrophication in Lake Xingyun, Yunnan based on the coupling model of wavelet analysis and neural network[J]. Journal of Lake Sciences, 2021, 33(2):428-438. (in Chinese))
- [86] Chong J W R, Khoo K S, Chew K W, et al. Trends in digital image processing of isolated microalgae by incorporating classification algorithm[J]. Biotechnology Advances, 2023, 63:108095.
- [87] Sonmez M E, Eczacioglu N, Gumus N E, et al. Convolutional neural network-support vector machine based approach for classification of cyanobacteria and chlorophyta microalgae groups[J]. Algal Research, 2022, 61:102568.
- [88] Chan W H, Fung B S B, Tsang D H K, et al. A freshwater algae classification system based on machine learning with StyleGAN2-ADA augmentation for limited and imbalanced datasets[J]. Water Research, 2023, 243:120409.

(下转第33页)

and Hydropower Research, 2016, 14 (6) : 431-436. (in Chinese))

[8] Yang Enhua,Sahmaran M,Yang Yingzi,et al. Rheological control in production of engineered cementitious composites [J]. ACI Materials Journal, 2009, 106 (4) : 357-366.

[9] Ley-Hernández A M,Feys D. Resting time effect on the rheological behavior of cement paste in presence of superplasticizer [J]. Cement and Concrete Research, 2021,142:106347.

[10] 胡伟,李家正,石妍,等. 不同配合比的 HECC 力学与干缩性能试验研究[J]. 人民长江,2024,55 (4) :222-229. (Hu Wei,Li Jiazheng,Shi Yan,et al. Experimental study on mechanical and drying shrinkage properties of HECC with different mix proportions[J]. Yangtze River,2024,55 (4) :222-229. (in Chinese))

[11] 杨志全,丁一,杨溢,等. 不同水灰比的牛顿型水泥浆液流变性随时间变化规律[J]. 农业工程学报,2020,36 (19) :161-167. (Yang Zhiquan,Ding Yi,Yang Yi,et al. Hydration-time-dependent rheological behaviors of Newtonian cement grouts with different water cement ratios [J]. Transactions of the Chinese Society of Agricultural Engineering,2020,36(19) :161-167. (in Chinese))

[12] Kwan A K H,Fung W W S. Roles of water film thickness and SP dosage in rheology and cohesiveness of mortar[J]. Cement and Concrete Composites,2012,34(2) :121-130.

[13] Kwan A K H,Fung W W S,Wong H H C. Water film thickness,flowability and rheology of cement-sand mortar [J]. Advances in Cement Research,2010,22(1) :3-14.

[14] Vikan H,Justnes H. Rheology of cementitious paste with silica fume or limestone [J]. Cement and Concrete Research,2007,37(11) :1512-1517.

[15] 张明璇,王鹏飞,杨涛,等. 聚羧酸减水剂对硫铝酸盐水泥基注浆材料影响[J]. 煤炭科学技术,2025,53 (4) : 348-361. (Zhang Mingxuan,Wang Pengfei,Yang Tao,et al. Effect of polycarboxylic acid superplasticizer on sulphoaluminate cement based grouting material[J]. Coal Science and Technology, 2025, 53 (4) : 348-361. (in Chinese))

[16] Kuder K G,Ozyurt N,Mu E B,et al. Rheology of fiber-reinforced cementitious materials [J]. Cement and Concrete Research,2007,37(2) :191-199.

[17] 林宝城. 高效减水剂对新拌混凝土坍落度损失的影响 [J]. 建材与装饰,2016(22) :161-163. (Lin Baocheng. Effect of high-efficiency superplasticizer on slump loss of fresh concrete[J]. Construction Materials & Decoration, 2016(22) :161-163. (in Chinese))

[18] 黄伟,周佳敏,衷从浩,等. 早强型聚羧酸系减水剂对基准水泥早期水化的影响研究[J]. 硅酸盐通报,2022,41 (4) :1211-1221. (Huang Wei,Zhou Jiamin,Zhong Conghao,et al. Effect of early-strength polycarboxylate superplasticizer on early hydration of reference cement [J]. Bulletin of the Chinese Ceramic Society, 2022, 41 (4) :1211-1221. (in Chinese))

(收稿日期:2025 - 07 - 14 编辑:俞云利)

+++++

(上接第 10 页)

[89] 徐楚原. 机器学习在生态环境大数据中的应用[J]. 化工设计通讯, 2023, 49 (8) : 177-179. (Xu Chuyuan. Application of machine learning in ecological environment big data [J]. Chemical Engineering Design Communications,2023,49(8) :177-179. (in Chinese))

[90] Yang Xinting,Zhang Song,Liu Jintao,et al. Deep learning for smart fish farming: applications, opportunities and challenges[J]. Reviews in Aquaculture,2021,13(1) :66-90.

[91] Chen Jinnan,Ding Chengzhi,He Dekui,et al. Assessing the conservation status of Chinese freshwater fish using deep learning[J]. Reviews in Fish Biology and Fisheries, 2023,33(4) :1505-1521.

[92] Agrawal S,Dubey S,Naik K J. Deep reinforcement learning for forecasting fish survival in open aquaculture ecosystem[J]. Environmental Monitoring and Assessment, 2023,195(11) :1389.

[93] Yoshida K,Yajima H,Islam M T,et al. Assessment of spawning habitat suitability for Amphidromous Ayu (*Plecoglossus altivelis*) in tidal Asahi River sections in Japan;implications for conservation and restoration [J]. River Research and Applications, 2024, 40 (8) : 1497-1511.

[94] 唐希颖,李化哲,崔丽娟,等. 湿地植物物种多样性无人机高光谱遥感反演研究[J]. 地球信息科学学报,2024,26(8) :1954-1974. (Tang Xiyang,Li Huazhe,Cui Lijuan,et al. Inversion of wetland plant species diversity using UAV hyperspectral data [J]. Journal of Geo-information Science,2024,26(8) :1954-1974. (in Chinese))

[95] 何博浩. 基于机器学习的潜在海草适宜性栖息地预测研究[D]. 海口:海南大学,2024.

[96] 崔东文,金波. 基于随机森林回归算法的水生态文明综合评价[J]. 水利水电科技进展,2014,34 (5) :56-60. (Cui Dongwen,Jin Bo. Comprehensive evaluation of water ecological civilization based on random forests regression algorithm[J]. Advances in Science and Technology of Water Resources,2014,34(5) :56-60. (in Chinese))

[97] Kwon Y S,Kang H,Pyo J. Estimation of aquatic ecosystem health using deep neural network with nonlinear data mapping[J]. Ecological Informatics,2024,81:102588.

(收稿日期:2025 - 10 - 19 编辑:俞云利)