

基于机器学习的养殖水体硝氮浓度预测方法研究进展

李道亮^{1,2} 朱弘烨^{1,2} 赵聪慧^{3,4} 张盼^{1,2}

(1. 国家数字渔业创新中心, 北京 100083; 2. 中国农业大学信息与电气工程学院, 北京 100083;

3. 山东省数字渔业重点实验室, 烟台 264670; 4. 中国农业大学烟台研究院, 烟台 264670)

摘要: 养殖水体硝氮($\text{NO}_3^- \text{N}$)浓度是影响水产养殖生态平衡与经济效益的关键参数,其精准预测对水质调控至关重要。水体硝氮浓度变化受众多因素影响,精准预测极其困难。相比传统机理模型依赖复杂方程,机器学习方法能有效挖掘水质参数间的非线性关系,展现出显著优势。本文系统综述了机器学习驱动的养殖水体硝氮浓度预测技术与研究进展,包含传统机器学习方法、神经网络方法和混合机器学习模型,并阐述了各类方法性能与应用场景,在此基础上探讨了当前研究面临的挑战,并对未来研究趋势进行展望,为养殖水体硝氮浓度预警与调控提供方法参考。

关键词: 硝氮浓度预测; 机器学习; 水产养殖; 人工神经网络; 混合模型

中图分类号: S959; TP18

文献标识码: A

文章编号: 1000-1298(2026)14-0001-12

OSID:



Advances in Machine Learning-based Methods for Nitrate Nitrogen Concentration Prediction in Aquaculture Water

Li Daoliang^{1,2} Zhu Hongye^{1,2} Zhao Conghui^{3,4} Zhang Pan^{1,2}

(1. National Innovation Center for Digital Fishery, Beijing 100083, China

2. College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China

3. Key Laboratory of Digital Fisheries of Shandong Province, Yantai 264670, China

4. Yantai Institute of China Agricultural University, Yantai 264670, China)

Abstract: The concentration of nitrate nitrogen ($\text{NO}_3^- \text{N}$) in aquaculture water bodies is a critical parameter influencing both the ecological balance and economic benefits of aquaculture. Accurate prediction of $\text{NO}_3^- \text{N}$ levels plays a pivotal role in effective water quality control. The change of nitrate nitrogen concentration in water is affected by many factors, so it is difficult to accurately predict it. Compared with the traditional mechanism model which relies on complex equations, machine learning method can effectively mine the nonlinear relationship between water quality parameters, demonstrating significant advantages. The research progress of machine learning driven nitrate nitrogen prediction technology in aquaculture water was systematically summarized, and the performance and application scenarios of various methods were introduced. The traditional machine learning methods effectively captured the complex relationship between water quality parameters through feature engineering and integration strategy. The neural network method improved the prediction ability by time series modeling and attention mechanism, while the hybrid machine learning model broke through the limitations of a single model through algorithm collaboration and optimization strategy. Based on this, the challenges faced by the current research were discussed, and the future research trends were prospected, providing a method reference for the early warning and regulation of nitrate nitrogen concentration in aquaculture water.

Key words: nitrogen concentration prediction; machine learning; aquaculture; artificial neural networks; hybrid model

0 引言

水环境是水生生物赖以生存的环境,其直接影响水产品生长和发育情况,因此维持良好的水质是水产养殖的关键^[1]。在众多水质参数中,硝态氮($\text{NO}_3^- \text{N}$,简称硝氮)作为氮循环的最终产物^[2],其适宜的浓度是维持水体生态平衡的重要保障,它为水生植物提供必需氮源、促进光合作用。若浓度过高,则会引发水体富营养化,促使藻类等浮游生物大量繁殖形成水华,不仅阻碍水生植物光照吸收,还会因藻类死亡造成水体缺氧,致使水生动物窒息死亡,带来严重的经济损失。此外,高浓度硝氮本身对水生生物产生直接毒性作用,影响其生长、繁殖和免疫力,增加疾病发生率,降低养殖产品质量和产量。因此,精准预测养殖水体硝氮浓度,对于及时调控水质、预防水质恶化、确保水产养殖可持续发展具有重要意义。

硝氮浓度预测受到水温、溶解氧浓度、pH 值、光照、微生物群落结构、投喂量、水交换率等多维因素的复杂非线性交互作用。早期研究侧重于利用历史数据建立统计规律,如 GM(1,1)灰色模型^[3-4]与 ARIMA 时间序列模型^[5],这类方法计算相对简单,但因线性假设和静态建模的特性难以应对水体环境动态变化,导致预测精度受限。此外,研究者通过描述水流运动、物质转移扩散、生物化学反应建立微分方程组或经验公式^[6-11],如综合水动力学、生物地球化学过程的水质数学模型^[10-11],在流域尺度的水文水质模拟方面应用广泛^[6-7],或针对特定养殖系统构建质量平衡模型,如鱼菜共生系统^[8]、循环水系统^[9]等。但机理模型依赖复杂数值求解,涉及的参数在养殖环境中难以准确获取,养殖系统中生物、物理、化学多场耦合的随机扰动导致模型构建难、求解慢、鲁棒性差。因此,亟需探索更为灵活、适应性更强的新方法。

近年来,机器学习(Machine learning, ML)在水质预测^[12-13]领域应用广泛,为硝氮浓度预测开辟了新路径。它能够挖掘硝氮与众多影响因子之间复杂的、非线性映射关系,相比机理模型,构建机器学习模型相对快速,更能灵活地适应新的养殖场景或环境变化。国内外研究者在该领域取得了显著进展,传统机器学习方法在自然水体与养殖场景中均实现了高精度预测^[14-15];Transformer 架构^[16]通过自注意力机制在鱼菜共生系统场景中实现了硝氮浓度精准预测;混合模型融合多种算法优势,如 CNN-LSTM^[17]提升时空预测能力,成为当前研究的重要趋势。

本文综述机器学习驱动的养殖水体硝氮浓度预测方法研究进展,涵盖传统机器学习方法、神经网络方法以及混合机器学习模型,总结现有技术不足并展望未来研究趋势,以期对相关研究提供参考。

1 基于传统机器学习的硝氮浓度预测

传统机器学习方法借助特征工程与算法优化,能有效捕捉硝氮浓度与水温、溶解氧浓度、pH 值、投喂量等多源环境参数间的非线性关联。如图 1 所示,传统机器学习方法可系统分为 3 大类:统计回归方法、基于决策树的方法、支持向量机相关方法。




图 1 传统机器学习方法分类

Fig. 1 Classification of traditional machine learning methods

1.1 统计回归方法

统计回归方法是水质预测中常用的传统机器学习方法之一,尤其在硝氮浓度预测中被广泛应用。水产养殖水体硝氮浓度受多因子协同作用,而统计回归方法通过建立输入变量与硝氮浓度之间的数学关系,能够有效预测水体中的硝氮浓度。例如,线性回归(Linear regression, LR)虽受限于线性假设,但在工厂化养殖场景中,当硝氮浓度主要受单一主导因子(如恒温条件下的投喂量)驱动时,仍可发挥快速预测的工程价值。Zare 等^[18]在地下水硝氮浓度预测中验证了 LR 基础性能;Jacob 等^[19]发现线性回归虽不如复杂模型精确,但在低复杂度场景下仍具有实用价值。

相比之下,多元线性回归 (Multivariate linear regression, MLR) 通过多变量协同建模优势,能更好地捕捉硝氮浓度与多个水质参数之间的复杂关系。Knoll 等^[20]利用 MLR 模型对硝氮浓度进行了大规模预测,在实际养殖场景中,MLR 可通过引入更多环境参数预测硝氮浓度,但硝氮浓度可能因微生物代谢及化学反应变化而导致预测结果出现偏差,此时多项式回归 (Polynomial regression, PR) 的适应性优势凸显,其通过引入高次项,能够更好地拟合非线性关系。Ahmed 等^[21]发现二次多项式回归模型预测效率最高,但 PR 模型复杂度随多项式次数增加而显著增加,在数据量有限的情况下易导致过拟合,需谨慎选择多项式次数。

回归克里金 (Regression Kriging, RK) 模型结合回归模型和空间插值技术,能够有效处理空间数据中非线性关系和空间自相关性,在养殖水体硝氮浓度预测中展现独特价值。Jang^[22]使用 RK 模型预测地下水硝氮空间分布,结果表明 RK 在处理极端数据时优于 MLR 和普通克里金 (Ordinary Kriging, OK); Canion 等^[23]研究表明利用 RK 模型能够显著提高硝氮浓度预测模型精度。该技术也可迁移到水产养殖场景中,通过结合水体空间分布信息,比如水流方向,预测硝氮浓度空间分布,对于大规模养殖水体监测具有重要意义。

偏最小二乘回归 (Partial least squares regression, PLSR) 在高维数据处理中的降维能力,适用于水质参数之间存在多重共线性的情况。Zhang 等^[24]基于偏最小二乘法构建了沿海海水养殖池塘水质参数的反演模型,其建立的“叶绿素 a-硝氮”协同反演框架,可迁移至藻类调控的生态养殖系统,通过藻相监测间接预测硝氮浓度变化趋势。在水产养殖中,PLSR 模型通常结合光谱数据 (如多光谱或紫外光谱) 实现硝氮浓度快速检测, Wu 等^[25]利用 PLSR 模型结合傅里叶变换红外光谱,快速测定了水体中硝氮同位素;宋彧等^[26]提出基于区间偏最小二乘法 (Interval partial least squares, iPLS) 的改进模型,通过选择光谱特征波段,进一步提高了模型预测精度。此外,PLSR 模型与其他方法结合可进一步提升性能,王金梅等^[27]提出的 SG-Lasso-PLS 模型,通过 Savitzky-Golay 滤波消除光谱噪声、Lasso 回归筛选关键波长,可有效应对养殖水体因饲料溶散导致的浊度突变问题; Wang 等^[28]提出了一种基于遗传算法 (Genetic algorithm, GA) 和 PLSR 的改进模型,通过优化特征波长选择,显著提高硝氮浓度预测精度。这些统计回归方法通过参数体系重构与算法增强,在水产养殖中应用前景广阔。

1.2 基于决策树的方法

决策树是经典的机器学习方法之一,养殖水体硝氮浓度动态变化受多种因素影响,而决策树系列模型通过特征重要性分析与规则提取,能够有效解析此类复杂交互机制,已被证明在硝氮浓度预测中具有显著优势。

如图 2a 所示,决策树 (Decision trees, DT) 通过递归将数据集划分为多个子集,构建树状结构,每个内部节点表示 1 个特征测试,每个分支表示 1 个测试结果,而每个叶节点则表示 1 个类别或回归值。Ho 等^[29]利用决策树实现了水质指数 (Water quality index, WQI) 等级的准确分类; Tanaka^[30]将其应用于预测养猪废水处理厂出水中无机氮化合物浓度,结果表明决策树能够有效捕捉运行条件 (如曝气池水温、pH 值和 MLSS) 与氮浓度之间的关系,这种决策方法可以用到循环水养殖工厂中,通过实时监测关键参数预测硝氮突变风险。分类与回归树 (Classification and regression tree, CART) 是 DT 的一种基本实现,能够同时处理分类和回归任务, Knoll 等^[20]利用 CART 模型成功预测了硝氮浓度。但模型预测精度可能受限于单一树结构,因此在实际应用中常结合其他集成方法。

随机森林 (Random forest, RF) 通过集成多棵决策树并对结果进行平均或投票,提高模型鲁棒性和预测精度,在硝氮浓度预测中达到了良好的性能^[31-32], RF 方法建模过程如图 2b 所示^[33]。Ha 等^[14]研究表明随机森林回归模型 R^2 达到 0.903; Canion 等^[23]通过回归克里金法结合随机森林模型进一步提高了硝氮浓度预测精度; Wang 等^[34]开发的简约 RF 硝氮浓度预测模型在少量预测因子的情况下仍能保持较高的预测精度,为设备受限的养殖场提供了轻量化解决方案,仅需部署溶解氧、水温等基础传感器即可实现硝氮浓度趋势预警; Sakaa 等^[35]提出的 RF-SMO-SVM 混合架构预测水质指数,在减少输入变量数量的情况下仍能保持较高的预测性能,这种思路可借鉴到养殖水体硝氮浓度预测中,通过结合 RF 和其他机器学习算法提高预测精度。

极端梯度提升 (eXtreme gradient boosting, XGBoost) 和轻梯度提升机 (Light gradient boosting machine, LightGBM) 是基于梯度提升决策树 (Gradient boosting decision tree, GBDT) 的高效集成学习方法,通过迭代优化损失函数提高预测精度。如图 2c 所示, XGBoost 算法的基本原理是使用决策树作为基本的学习器,采用按层生长 (level-wise) 的决策树生长策略;而 LightGBM 算法则是采用带深度




图 2 基于决策树的方法模型示意图

Fig. 2 Schematics of method model based on decision tree

限制的按叶子生长 (leaf-wise) 算法。周念清等^[15]利用改进的 XGBoost 模型 (BO - XGBoost) 实现硝氮浓度预测 $R^2 > 0.90$, 为高密度养殖精准调控提供了参考; Ransom 等^[36]开发的三维 XGBoost 模型在预测水体硝氮浓度中表现出色; Jeong 等^[37]发现 XGBoost 在预测水质指标 (总氮、硝氮、氨氮) 时性能优于 LightGBM。XGBoost 和 LGBM 的优势在于高效性和对大规模数据处理能力, XGBoost 通过正则化技术减少了过拟合风险, 而 LGBM 通过基于直方图的决策树算法进一步提高了计算效率, 但这 2 种方法对超参数节选择较为敏感, 需结合交叉验证或优化算法进行调节。

在构建针对养殖场景的模型时, 改进型决策树方法展现出独特优势: 如图 2d 所示, 额外树回归 (Extra trees regressor, ETR) 通过随机选择特征分割点增加模型的多样性, Asadollah 等^[38]比较了 ETR、支持向量回归 (Support vector regression, SVR) 和决策树回归 (DTR) 在预测 WQI 中的性能, 发现 ETR 模型预测精度最高。如图 2e 所示, 提升回归树 (Boosted regression trees, BRT) 通过加权组合多个弱

学习器构建强学习器, Ransom 等^[39]使用 BRT 模型预测地下水中硝氮浓度, 能够有效识别重要预测变量 (如氧化还原条件和氮输入); Alnahit 等^[40]研究表明, RF 适用于需快速响应的投喂决策系统, 而 BRT 更契合精细化水质溯源需求。此外, Islam 等^[41]提出的集成学习框架 (包括 Boosting、Bagging 和随机森林) 可用于预测养殖水体中硝氮浓度敏感性; Li 等^[42]发现简化误差剪枝树 (Reduced error pruning tree, REPTree) 在预测硝氮浓度和负荷时表现最佳, 同样适用于养殖水体。研究表明, 决策树相关方法通过特征工程适配与算法增强, 正逐步突破自然水体研究边界, 为养殖水体硝氮浓度预测提供技术蓝本。

1.3 支持向量机相关方法

支持向量机 (Support vector machine, SVM) 作为一种经典的机器学习算法, 通过寻找最优超平面实现分类或回归任务, 具有较强的泛化能力。因其在处理高维数据和非线性问题中的优异表现, 被广泛应用于水质预测领域。核 SVM 利用核函数 (Kernel function) 将样本从低维空间 (输入空

间)映射到高维空间(特征空间)进行线性划分,能够高效解决非线性分类问题,SVM 模型示意图如图 3 所示。

Arabgol 等^[43]研究表明采用 RBF 核函数的 SVM 模型是预测硝氮浓度的可靠方法。近年来,SVM 及其多种改进方法被提出并应用于水质预测中,其优势与局限性如表 1 所示。支持向量回归(SVR)是 SVM 在回归问题中的扩展,能够以较少的计算量高度拟合仿真模型输入-输出关系^[44],通过引入 ε 不敏感损失函数,能够处理连续变量预测问题。Yang 等^[47]使用 SVR 模型预测河流硝氮同位素组成($\delta^{15}\text{N-NO}_3^-$),性能显著优于多元线性回归和广义回归神经网络模型;Aldemir^[48]也验证了 SVR 模型能够准确预测硝氮浓度、铵态氮浓度和磷酸盐浓度等关键指标,该方法也可用于高密度养殖池的硝氮预警系统,如通过结合电导率(EC)、化学氮肥施




图 3 支持向量机(SVM)模型示意图

Fig. 3 Schematics of support vector machine (SVM) model

表 1 支持向量机方法优势与局限性

Tab. 1 Advantages and limitations of support vector machine method

方法	优势	局限性	文献序号
SVM	处理高维数据和非线性问题,泛化能力强	参数选择敏感,计算复杂度高	[43]
SVR	适用于连续变量预测, ε 不敏感损失函数减少过拟合	核函数、惩罚参数 C 和 ε 需精细调优	[44]
MKSVR	多核组合提高模型表达能力,PSO 优化提升精度	核函数组合策略复杂,计算资源需求高	[45]
LSSVM	优化问题转换为线性方程组,计算效率高	对数据噪声敏感,需结合预处理技术	[46]
SMO-SVM	分解大规模优化问题,适合实时监测	输入变量减少可能牺牲部分信息	[35]

用量(NF)和降雨量(PPT)等易于获取的指标,实现对养殖水体硝氮浓度快速预测^[34]。但 SVR 参数选择(如核函数类型、惩罚参数 C 和 ε)对模型性能影响较大,可能限制其在实际应用中的效率。多核支持向量回归(Multi kernel support vector regression, MKSVR)通过核函数组合突破单一映射局限,提高模型表达能力。Najafzadeh 等^[45]提出了一种基于粒子群优化(Particle swarm optimization, PSO)的 MKSVR 算法,在预测河流化学需氧量(COD)和生化需氧量(BOD)时精度优于传统 SVR 和随机森林,其多核融合机制为解析养殖水体的复杂互作网络提供了新思路。

在具有实时监测需求的工厂化养殖场景中,改进 SVM 方法更具工程价值。最小二乘支持向量机(Least squares support vector machine, LSSVM)将优化问题转换为线性方程组降低计算复杂度,使用 RBF 作为核函数的 LSSVM 是最佳模型^[46],Najafzadeh 等^[49]在预测 BOD5 和 COD 时,LSSVM 精度显著高于传统多元回归方法,该方法可适配循环水系统的分钟级水质监测,实现低延迟硝氮突变预警;Nourani 等^[50]发现 LSSVM 比前馈神经网络预测性能更优;李婷婷^[51]在工厂化养殖中实证表明经小

波降噪预处理的 LSSVM 模型可显著提升溶解氧-硝氮预测精度。顺序最小优化(Sequential minimal optimization, SMO)支持向量机(SMO-SVM)则通过分解大规模优化问题为多个小规模子问题提高计算效率。Sakaa 等^[35]研究表明 SMO-SVM 在减少输入变量数量的同时保持了较高的预测精度,因此,SMO-SVM 可用于构建基于少量关键水质参数的预测模型,实现对养殖水体硝氮浓度快速监测。未来研究可进一步探索 SVM 及其改进方法在水产养殖中的应用潜力,例如结合物联网(IoT)技术,实现水质实时监测和智能预警,推动水产养殖智能化和可持续发展^[52]。

2 基于神经网络方法的硝氮浓度预测

神经网络作为机器学习核心分支,通过模拟生物神经元的工作机制,在水质预测中展现出强大的非线性拟合能力。从技术演进角度,神经网络在水质预测中应用可划分为 3 大类:前馈神经网络(Feedforward neural network, FNN)通过单向层级传递结构实现对静态数据的非线性映射;循环神经网络(Recurrent neural network, RNN)借助时序反馈机制捕捉水体参数的时间序列特征;基于

自注意力机制的 Transformer 则突破了传统架构时空限制,通过动态权重分配建立全局依赖关系。研究结果表明神经网络在水质预测中展现出显著优势,Stamenkovic^[53]对比 ANN 和 SVM 发现,ANN 在预测硝氮和磷酸盐浓度方面表现更优;Bhattarai 等^[54]通过 9 种算法对比试验证实 ANN 在农业流域的硝氮浓度预测中表现优异。近年来,随着 Transformer 等新型架构的应用,神经网络在捕捉水

体参数的非线性动态特征方面取得突破性进展。

2.1 前馈神经网络(FNN)及其变体

前馈神经网络(FNN)作为基础架构,通过层间前向传播实现特征变换,通过多层神经元线性组合和非线性激活函数,捕捉输入变量与输出变量之间的复杂非线性关系,表 2 总结了前馈神经网络及其变体模型在硝氮浓度预测中的优点与缺点。

表 2 前馈神经网络模型在硝氮浓度预测中的优点和缺点

模型类型	描述	优点	缺点	文献序号
多层感知器 (MLP)	通过多层神经元和非线性激活函数(如 ReLU、Sigmoid)捕捉输入与输出间的复杂非线性关系	处理高维数据;捕捉非线性关系;模型简单易实现	训练速度慢;易过拟合	[55-56]
BP 神经网络	MLP 的经典实现,通过反向传播算法优化权重,可结合降噪方法(如 EEMD)提升性能	梯度下降优化;预测精度高(优于 GM(1,1)和线性回归)	数据量少时表现差;需手动调参;噪声敏感	[57-58]
RBF 神经网络	隐藏层使用径向基函数(如高斯函数),输出层线性组合,适合插值和函数逼近	训练速度快;抗噪声能力强	依赖基函数选择和参数设置;预测精度低	[51, 59]
GRNN	基于概率密度函数,仅含隐藏层和输出层,无需迭代训练	鲁棒性强;无需复杂训练	计算复杂度高;对输入数据分布敏感	[60]
ELM/TELM	单隐层前馈网络,随机初始化权重,训练速度快;双层极限学习机(TELM)优化高频数据预测	训练速度极快;适合大数据场景	依赖隐层神经元数;噪声敏感	[61-62]

FNN 早期形态单层感知器(Single layer perceptron, SLP)仅含输入层和输出层,没有隐藏层,只能解决线性可分问题,难以应对水质预测的复杂非线性关系。多层感知器(Multi-layer perceptron, MLP)通过引入隐藏层和非线性激活函数(如 Sigmoid、ReLU),显著提升了模型表达能力,成为主流架构。Zaqoot 等^[56]通过比较 MLP 和 RBF 神经网络发现,MLP 对地下水硝氮浓度预测效果更优。基于反向传播算法(Back propagation, BP)的 MLP 改进版本——BP 神经网络,通过梯度下降优化网络权重,推动了 FNN 的工程应用。Li 等^[55]使用 BP 神经网络预测地表水总氮去除效果,决定系数高达 0.985,精度显著优于多元线性回归模型;Wagh 等^[63]在硝氮浓度预测中使用多种 BP 算法,包括

Levenberg-Marquardt 3 层反向传播、传统反向传播算法和弹性反向传播算法;Gao 等^[64]在硝氮去除过程模型构建中,使用 BPNN 成功预测了出水水质,预测精度优于传统数学模型;张青等^[57]则通过 BP 模型实现多项水质指标的高精度预测,均方误差较 GM(1,1)模型降低 35% 以上。然而,BP 神经网络在数据量不足时表现较差^[51],但通过集合经验模态分解(Ensemble empirical mode decomposition, EEMD)对输入数据进行降噪预处理,可显著提升在小样本水质预测中的稳定性,为数据获取受限的养殖场提供了可行性方案。

针对养殖水体中常见的噪声干扰与动态变化,FNN 变体展现出独特优势,架构见图 4。

径向基函数神经网络(Radial basis function




图 4 前馈神经网络(FNN)及其变体模型架构

Fig. 4 Architecture of feedforward neural network (FNN) and its variant models

neural network, RBFNN) 是一种特殊的 FNN, 隐藏层使用径向基函数(如高斯函数)作为激活函数, 在非线性的水质预测中展现出快速训练和抗噪声优势。Deng 等^[59]将其应用于地下水硝氮污染预测, 结果表明在非线性的环境条件下表现出较高的预测精度。但 RBFNN 性能依赖于基函数选择和参数设置, 在养殖水体预测溶解氧浓度和氨氮浓度时表现较好, 预测硝氮浓度时精度较低^[51]。广义回归神经网络(General regression neural network, GRNN)是径向基神经网络的一种变化形式, 基于概率密度函数简化了神经网络, 由输入层、模式层、求和层和输出层 4 层组成, 无需迭代训练即可完成动态硝氮浓度预测, 满足实时监测的需求。Kumar 等^[60]使用其预测河流中硝氮浓度和氨氮浓度, 验证了 GRNN 鲁棒性(最小回归值 0.92)。极限学习机(Extreme learning machine, ELM)是一种单隐层前馈神经网络(SLFN), 通过随机初始化隐藏层权重大幅提升运算效率, 俞方罡等^[61]研究结果表明, ELM 在硝氮浓度预测中数据量较大时较 SVM 具有更高的实时性优势; 而 ELM 性能依赖于隐藏层神经元数量; McGill 等^[62]提出的 2 层极限学习机(Two-hidden-layer extreme learning machine, TELM)模型进一步优化高频径流数据建模能力, NSE 达 0.94, 为密集型水产养殖系统中硝氮浓度实时监测提供了技术范式。

近年来, FNN 改进方向聚焦于特征提取与模型融合, 栈式自编码器(Stacked auto encoder, SAE)与 BP 结合的 SAE-BP 模型通过无监督预训练增强特征表征能力, 付泰然^[58]研究结果表明, 该模型对氨氮浓度和亚硝氮浓度预测精度显著提升($R^2 \geq 0.95$), 但对硝氮浓度预测仍存在局限性($R^2 = 0.718$)。此外, 赵敏等^[65]通过融合 RBF 神经网络与比例积分-广义预测控制(PI-GPC)算法, 实现了溶解氧-硝氮解耦控制。这些跨场景技术迁移表明, FNN 及其变体通过架构创新与领域适应性改进, 在水产养殖中具有潜在应用价值。

2.2 循环神经网络(RNN)及其变体

循环神经网络(RNN)是一类专门用于处理时间序列数据的神经网络, 与传统前馈神经网络不同, RNN 通过在时间维度上建立隐藏状态传递机制, 将历史信息融入当前时刻的预测过程, 这一特性使其在硝氮、溶解氧等具有明显时序关联性的水质参数预测中展现独特优势。Elman 神经网络作为早期经典架构, 通过隐藏层输出反馈机制捕捉短期依赖关系, 简洁的层级结构为后续 RNN 发展奠定基础。Kumar 等^[66]结合蚁群优化算法改进的 ACO-Elman 模型, 在硝氮浓度预测中显著提升了精度。而传统

RNN 存在梯度消失和爆炸问题, 限制了在长序列数据上的表现, 为此研究者开发了多种改进模型, 各类变体通过技术创新不断突破水质时序建模瓶颈^[67], 图 5 为 4 类循环模型架构。




图 5 4 类循环模型架构

Fig. 5 Four types of loop model architecture

长短期记忆网络(Long short-term memory network, LSTM)作为 RNN 重要改进, 通过引入记忆单元和门控机制(输入门、遗忘门和输出门), 有效解决梯度消失问题, 能够捕捉长序列数据中时间依赖性。Farhi 等^[68]应用 LSTM 预测氨氮和硝氮浓度, 准确率分别达 99% 和 90%; Zhou 等^[69]提出基于多目标深度神经网络的数字化工业水产养殖管理方案, 使用双隐藏层 BP 神经网络预测鱼类状态, LSTM 神经网络预测水质参数。为了进一步提升 LSTM 性能, 研究者提出了将主成分分析(PCA)与 LSTM 结合的 PCA-LSTM 模型^[70], 在预测高锰酸盐指数和氨氮浓度时优于单一 LSTM 模型。针对 LSTM 计算复杂度高的问题, 门控循环单元(Gated recurrent unit, GRU)通过合并记忆单元与隐藏状态精简了参数, 在保持时序建模能力的同时提升运算效率。Tian 等^[71]构建的 DeepTCN-GRU 模型, 通过深度时间卷积网络提取多尺度特征后输入 GRU 进行时序建模, 在 pH 值和总氮浓度预测中综合性能超越传统模型; Huang 等^[72]研究结果表明, GRU 在河流水质参数预测中较 LSTM 具有更高的计算效率, 尤其在短序列数据处理时表现更优。

为突破单一时序建模局限, 研究者提出融合多源环境变量的复合模型。非线性自回归外生模型(Nonlinear auto-regressive model with exogenous inputs, NARX)结合自回归模型和外生输入的动态系统建模方法, 使用神经网络实现非线性映射, 通过外部变量(如流量、温度等)提升预测精度。研究者们使用 NARX 模型预测硝氮浓度, 在考虑多个外部输入变量时精度较高^[73]。为应对非平稳数据限制, Chen 等^[74]结合小波分析(WA)和迁移学习(TL)提

出 WA-LSTM-TL 模型;Meng 等^[75]提出了基于最优变分模态分解 (Variational mode decomposition, OVMD) 和 GRU 的模型预测如氨氮和总磷浓度,预测精度和鲁棒性均优于传统模型。表 3 为 RNN 及其改进方法在水质预测中的优点与缺点,这些方法在水产养殖中具有潜在的应用价值,未来研究可结合多种方法(如深度学习与传统机器学习)以及数据预处理技术(如降噪和特征选择),进一步提升水质预测精度和鲁棒性。

2.3 基于自注意力机制的 Transformer 模型

Transformer 模型通过自注意力机制,能同时分

析不同时间点的多个水质参数关系。该模型最初由 Vaswani 等^[76]于 2017 年提出用于自然语言处理任务,近年来在时间序列预测领域也展现出强大的潜力,尤其是在处理长序列数据时性能优异。不同于依赖循环结构的 RNN 及其变体,Transformer 模型完全使用自注意力机制 (Self-Attention) 捕捉序列数据的全局依赖关系。虽然结构不同,但 Transformer 仍然属于神经网络的范畴,因为它的基本组成单元(如全连接层、层归一化、残差连接)都是神经网络的一部分。

对于养殖水体硝氮浓度预测,Transformer 能有

表 3 RNN 及其改进方法在水质预测中的优点和缺点

Tab.3 Characteristics of RNN and its improved methods in water quality prediction

模型	描述	优点	缺点	文献序号
Elman	经典 RNN 变体,通过隐藏层输出反馈捕捉短期依赖性	结构简单,易于实现	处理长序列数据时易出现梯度消失问题	[66]
LSTM	通过引入记忆单元和门控机制解决梯度消失问题,适合长序列数据建模	处理长序列数据能力强	计算复杂度高,需要大量数据训练	[68]
PCA-LSTM	结合主成分分析 (PCA) 降维和 LSTM 建模,减少数据维度并保留主要特征	降低模型复杂度,提高预测精度	对非线性数据处理能力有限,依赖 PCA 降维效果	[70]
GRU	LSTM 的简化版本,通过合并记忆单元和隐藏状态减少参数,提高效率	计算效率高,适合短序列数据处理	处理长序列数据时可能不如 LSTM 稳定	[72]
OVMD-GRU	结合最优变分模态分解 (OVMD) 和 GRU,增强模型对非线性和非平稳数据的处理能力	预测精度和鲁棒性优于传统模型	模型复杂度高,对数据预处理要求较高	[75]
NARX	结合自回归模型和外生输入,用外部变量(如流量、温度)提升预测精度	结合多变量进行预测,适合复杂场景	模型复杂度较高,对外部变量依赖性较强	[73]

效分析溶解氧浓度、水体温度、pH 值等多个参数的时序变化特征,量化各参数动态波动对硝氮浓度的影响关系,适合处理高密度养殖池中因投饵、换水引起的浓度剧烈波动。Vaswani 等^[76]提出的基础 Transformer 架构通过位置编码 (Positional encoding) 将时序信息融入特征向量,克服了传统注意力机制对序列顺序的忽略问题。Metin 等^[16]在此基础上开发了一种基于时间融合 Transformer 模型,引入可解释性注意力权重和动态特征选择模块,成功预测了鱼菜共生系统硝氮浓度变化趋势,在 MAE、MSE 和解释方差等指标上均优于传统基线模型。

3 基于混合机器学习的硝氮浓度预测

混合机器学习模型通过结合多种机器学习模型和优化技术,有效提升了预测精度和模型泛化能力。混合模型的应用在水质硝氮浓度预测领域逐渐增多,尤其是处理非线性、高维度和复杂水质数据时表现出色,因此介绍几种典型混合机器学习模型,并探讨在水产养殖中应用潜力,相关研究如表 4 所示。

(1) 基于优化算法与神经网络的混合模型,通

过引入优化算法(如蚁群优化算法、遗传算法等)优化神经网络的参数或结构。例如,Kumar 等^[66]通过蚁群优化算法 (Ant colony optimization, ACO) 优化 Elman 神经网络 (Elman neural network, ENN) 的参数,提出的 ACO-ENN 模型,显著提高了硝氮浓度和氨氮浓度预测精度,通过敏感性分析量化了温度与光强对氮素迁移的影响权重,为养殖水体生态调控提供了量化依据。Wu 等^[77]利用遗传算法 (GA) 优化非线性硝氮浓度预测模型参数,预测效果优于传统方法。

(2) 基于深度学习的混合模型,深度学习模型在处理时间序列数据和空间数时表现出色。Hu 等^[17]通过结合卷积神经网络 (Convolutional neural network, CNN) 和 LSTM,提出的 CNN-LSTM 混合模型成功预测了河流中每小时硝氮浓度,为养殖水体立体监测提供了技术范式:通过卷积神经网络 (CNN) 提取池塘分区的空间特征,结合 LSTM 捕捉昼夜投喂周期引发的硝氮浓度波动规律,可实现对养殖池三维硝氮浓度分布的动态预测。

(3) 基于神经模糊系统的混合模型,神经模糊系统 (Neuro-Fuzzy, NF) 结合模糊逻辑和神经网络

表 4 混合机器学习模型在水质硝氮浓度预测中的特点与应用

Tab. 4 Characteristics and applications of hybrid machine learning models in water quality nitrate prediction

类别	描述	性能	应用	文献 序号
优化算法与神经网络混合模型	ACO-ENN 通过 ACO 优化提升神经网络性能	MSE 为 0.012 mg ² /L ² , MAE 为 0.069 mg/L ² , NSE 为 0.984	适用于养殖水体中硝氮的动态预测	[66]
	GA-ANN 通过 GA 优化提升神经网络性能	RMSE 为 2.035 7, PBIAS 为 -0.801 2		[77]
深度学习融合模型	CNN-LSTM 结合 CNN 和 LSTM 处理时空数据	NSE 为 0.60 ~ 0.83 mg ² /L ²	适用于养殖水体中硝氮的时空预测	[17]
神经模糊系统混合模型	NF 结合模糊逻辑和神经网络	R ² = 0.998 9, MAD 为 0.059 0	适用于养殖水体中硝氮数	[78]
	ANFIS 将模糊推理系统和神经网络相结合	NSE 为 0.963 4 mg ² /L ² , MAE 为 0.021 9 mg ² /L ²	据不确定性较高的情况下	[79]
因子分析与机器学习混合模型	FA-ML 通过因子分析优化机器学习模型的输入	R ² = 0.974 3 (Ntot (eff)), 0.993 8 (NO ₃ ⁻ N - eff)	适用于养殖水体中硝氮的多源数据预测	[80]

的优点,能够处理不确定性和非线性问题。Manzar 等^[78] 研究表明,神经模糊模型(NF)在水质指数预测中表现优异,优于传统的神经网络和支持向量机模型;Jang^[22] 将模糊推理系统和神经网络相结合,开发了自适应神经模糊推理系统(Adaptive-network-based fuzzy inference system,ANFIS),通过神经网络建模,得到了 FIS 参数;Pham 等^[79] 也验证了自适应神经模糊系统(ANFIS)在湿地水质预测中的有效性。这一技术路径可为生态养殖系统提供启示。

(4)基于因子分析与机器学习的混合模型,因子分析(Factor analysis,FA)可以提取数据中潜在因子,优化机器学习模型的输入。Lü 等^[80] 提出的 FA-ML 模型通过因子分析优化机器学习模型的输入,通过对反硝化因子、污染物负荷因子等潜在变量的提取,将硝氮浓度预测精度 R^2 提至 0.974,并具备未来 3 d 的有效预测能力。通过因子分析筛选关键驱动变量,结合机器学习构建预测模型,为养殖水体硝氮浓度精准预测提供核心算法支撑。

4 挑战与展望

基于机器学习的养殖水体硝氮浓度预测模型能够实现早期预警,对保障水产品安全、提升养殖效益及促进产业可持续发展具有重大实践价值。然而,当前研究仍面临诸多挑战,未来研究需聚焦以下关键问题:

(1)多模态数据融合:传感器、光谱、气象等不同模态数据的时空对齐和标准化缺乏统一框架,传统特征拼接或浅层融合方法难以充分挖掘其互补信息。多模态融合可有效克服单一模态局限,但不同模态之间的复杂交互机制仍有待进一步挖掘^[81]。

未来需发展自适应多模态融合架构,并结合图模型与知识驱动方法建模水质参数间复杂互作网络,逐步构建面向养殖过程感知、分析与调控闭环的数字孪生系统^[82]。

(2)模型泛化性与鲁棒性:现有模型多基于实验室或特定场景数据构建,在单一场景下精度较高,模型在 1 个地区训练后,可能无法直接应用于其他地区,对跨区域、跨养殖模式的适应性不足。未来可构建覆盖多养殖模式的基准数据集,研发基于元学习的快速适配框架,使模型能够快速适配新环境。

(3)模型可解释性与决策:当前多数模型仍为“黑箱”,预测结果不利于指导实际调控操作。未来可以结合注意力机制、特征重要性分析、可解释人工智能(XAI)方法,设计内在可解释的混合架构,如将 ANFIS 模糊规则系统与神经网络结合,融合预测模型与优化控制理论,构建硝氮浓度智能调控系统,实现预测结果到控制指令的自动转化。

(4)轻量化部署与实时性:现有复杂模型难以在资源受限的养殖场边缘设备上实时运行,制约了实时在线预测与预警的应用。未来可以利用知识蒸馏将复杂混合模型能力迁移至微型网络,开发适配嵌入式设备的轻量级架构,结合云计算-边缘计算协同架构,优化计算负载分配,最终构建低功耗、高响应的嵌入式预警系统。

通过优化硝氮浓度预测精度与实时性,可降低水体富营养化风险,减少养殖病害发生率,提升资源利用效率。未来通过技术迭代与跨领域协作,有望实现硝氮浓度预测从“感知-预警”到“自主调控”的跨越,最终服务于水产养殖业的绿色、高效、可持续发展。

参 考 文 献

- [1] 李道亮,刘畅. 人工智能在水产养殖中研究应用分析与未来展望[J]. 智慧农业(中英文),2020,2(3):1-20.
Li Daoliang, Liu Chang. Recent advances and future outlook for artificial intelligence in aquaculture[J]. Smart Agriculture, 2020,2(3):1-20. (in Chinese)
- [2] 尹宝全,曹闪闪,傅泽田,等. 水产养殖水质检测与控制技术研究进展分析[J]. 农业机械学报,2019,50(2):1-13.
Yin Baoquan, Cao Shanshan, Fu Zetian, et al. Review and trend analysis of water quality monitoring and control technology in aquaculture[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019,50(2):1-13. (in Chinese)
- [3] 沈煜恒,戴小鹏,湛誉,等. 基于灰色模型的水质监测预警系统设计[J]. 农业工程,2019,9(8):31-34.
Shen Yuheng, Dai Xiaopeng, Zhan Yu, et al. Design of water quality monitoring and early warning system based on grey model[J]. Agricultural Engineering, 2019,9(8):31-34. (in Chinese)
- [4] Du Y, Wei K, Liu E, et al. Grey prediction model of water quality based on clustering and fusion[J]. Desalination and Water Treatment, 2017,64:48-53.
- [5] 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.
Huang Yue, Huang Zhilin, Xiao Wenfa, et al. Analysis and prediction of effects of Three Gorges Reservoir water level scheduling on the outflow water quality[J]. Journal of Water Resources & Water Engineering, 2020,31(4):78-85. (in Chinese)
- [6] Yang X, Jomaa S, Zink M, et al. A new fully distributed model of nitrate transport and removal at catchment scale[J]. Water Resources Research, 2018,54(8):5856-5877.
- [7] Jiang S Y, Zhang Q, Werner A D, et al. Effects of stream nitrate data frequency on watershed model performance and prediction uncertainty[J]. Journal of Hydrology, 2019,569:22-36.
- [8] Kalvakaalva R, Smith M, Ayipio E. Mass-balance process model of a decoupled aquaponics system[J]. Journal of the ASABE, 2023,66(4):955-967.
- [9] Tanveer M, Moulick S, Mukherjee C K. Mathematical model for goldfish recirculating aquaculture system (GRAS)[J]. Aquacultural Engineering: an International Journal, 2020,90(1):102092.
- [10] Jomaa S, Jiang S, Thraen D, et al. Modelling the effect of different agricultural practices on stream nitrogen load in central Germany[J]. Energy Sustainability & Society, 2016,6(1):11.
- [11] Kim J, Jonoski A, Solomatine D P, et al. Water quality modelling for nitrate nitrogen control using HEC-RAS: case study of Nakdong River in South Korea[J]. Water, 2023,15(2):247.
- [12] 谢再秘,贾宝柱,王骥,等. 基于 ICS 优化 RBF 的水库水质三维预测方法[J]. 农业机械学报,2024,55(2):306-314.
Xie Zaimi, Jia Baozhu, Wang Ji, et al. Reservoir water quality three-dimensional prediction method based on ICS optimization RBF[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(2):306-314. (in Chinese)
- [13] 陈亚松,刘家雯,赵云鹏,等. 基于机器学习的人工湿地出水水质预测与影响因素[J]. 中国环境科学,2025,45(6):3161-3170.
Chen Yasong, Liu Jiawen, Zhao Yunpeng, et al. Prediction of effluent water quality and analysis of influencing factors in constructed wetlands based on machine learning[J]. China Environmental Science, 2025,45(6):3161-3170. (in Chinese)
- [14] Ha N, Nguyen H Q, Truong C Q, et al. Estimation of nitrogen and phosphorus concentrations from water quality surrogates using machine learning in the Tri An Reservoir, Vietnam[J]. Environmental Monitoring and Assessment, 2020,192(12):809.
- [15] 周念清,夏明锐,陆帅帅,等. 利用改进 XGBoost 模型预测和分析湿地潜流带地下水中硝态氮含量[J]. 上海国土资源, 2024,45(2):41-47.
Zhou Nianqing, Xia Mingrui, Lu Shuaishuai, et al. Using an improved XGBoost model to predict and analyze nitrate nitrogen content in groundwater of wetland hyporheic zones[J]. Shanghai Land and Resources, 2024,45(2):41-47. (in Chinese)
- [16] Metin A, Kasif A, Catal C. Temporal fusion transformer-based prediction in aquaponics[J]. Journal of Supercomputing, 2023, 79(17):19934-19958.
- [17] Hu Y, Liu C, Wollheim W M, et al. A hybrid deep learning approach to predict hourly riverine nitrate concentrations using routine monitored data[J]. Journal of Environmental Management, 2024,360:121097.
- [18] Zare A H, Bayat V M, Daneshkare A P. Forecasting nitrate concentration in groundwater using artificial neural network and linear regression models[J]. International Agrophysics, 2011,25(2):187-192.
- [19] Jacob C, Masilamani U S. Performance evaluation of different machine learning algorithms for prediction of nitrate in groundwater in Thiruvannamalai District[J]. Clean-Soil Air Water, 2025,53(1):2400060.
- [20] Knoll L, Breuer L, Bach M. Large scale prediction of groundwater nitrate concentrations from spatial data using machine learning[J]. Science of the Total Environment, 2019,668:1317-1327.
- [21] Ahmed U, Mumtaz R, Anwar H, et al. Efficient water quality prediction using supervised machine learning[J]. Water, 2019, 11(11):2210.
- [22] Jang C. Geostatistical estimates of groundwater nitrate-nitrogen concentrations with spatial auxiliary information on DRASTIC-LU-based aquifer contamination vulnerability[J]. Environmental Science and Pollution Research, 2023, 30(33):81113-81130.

- [23] Canion A, Mccloud L, Dobberfuhl D. Predictive modeling of elevated groundwater nitrate in a karstic spring-contributing area using random forests and regression-kriging[J]. *Environmental Earth Sciences*, 2019, 78(9): 271.
- [24] Zhang Y, Jing W, Deng Y, et al. Water quality parameters retrieval of coastal mariculture ponds based on UAV multispectral remote sensing[J]. *Frontiers In Environmental Science*, 2023, 11: 1079397.
- [25] Wu K, Ma F, Wei C, et al. Rapid determination of nitrate nitrogen isotope in water using fourier transform infrared attenuated total reflectance spectroscopy (ftir-atr) coupled with deconvolution algorithm[J]. *Molecules*, 2023, 28(2): 567.
- [26] 宋彧, 李卫华, 薛同站, 等. 短程硝化过程的光谱特征波段选择与间隔偏最小二乘法建模[J]. *光谱学与光谱分析*, 2024, 44(8): 2224 – 2232.
- Song Yu, Li Weihua, Xue Tongzhan, et al. Spectral feature band selection and interval partial least squares modeling of short-range nitrification process[J]. *Spectroscopy and Spectral Analysis*, 2024, 44(8): 2224 – 2232. (in Chinese)
- [27] 王金梅, 何适, 张航熙, 等. 基于 SG – Lasso – PLS 融合算法的水体硝酸盐氮紫外光谱检测研究[J]. *光谱学与光谱分析*, 2023, 43(4): 1037 – 1042.
- Wang Jinmei, He Shi, Zhang Hangxi, et al. Study on the detection method of nitrate nitrogen in water based on ultraviolet spectroscopy[J]. *Spectroscopy and Spectral Analysis*, 2023, 43(4): 1037 – 1042. (in Chinese)
- [28] Wang X, Hu B, Yu T, et al. Research of nitrate concentration prediction based on GA[C] // SPIE Conference on Ocean Optics and Information Technology, 2018.
- [29] Ho J Y, Afan H A, El-Shafie A H, et al. Towards a time and cost effective approach to water quality index class prediction[J]. *Journal of Hydrology*, 2019, 575: 148 – 165.
- [30] Tanaka Y. Machine learning for prediction of inorganic nitrogenous compounds concentration in swine wastewater treatment plant effluent[J]. *Nihon Yoton Gakkaishi*, 2021, 58(2): 65 – 79.
- [31] Knoll L, Breuer L, Bach M. Nation-wide estimation of groundwater redox conditions and nitrate concentrations through machine learning[J]. *Environmental Research Letters*, 2020, 15(6): 064004.
- [32] Meter K J, Schultz V O, Chang S Y. Data-driven approaches demonstrate legacy N accumulation in Upper Mississippi River Basin groundwater[J]. *Environmental Research Letters*, 2023, 18(9): 094016.
- [33] Haghbin M, Sharafati A, Dixon B. Application of soft computing models for simulating nitrate contamination in groundwater: comprehensive review, assessment and future opportunities[J]. *Archives of Computational Methods in Engineering*, 2020, 28(5): 3569 – 3591.
- [34] Wang P, Zhang D, Tao X, et al. A parsimonious model for predicting the NO_3^- -N concentration in shallow groundwater in intensive agricultural areas using few easily accessible indicators and small datasets based on machine learning[J]. *Journal of Hydrology*, 2023, 619: 129356.
- [35] Sakaa B, Elbeltagi A, Boudibi S, et al. Water quality index modeling using random forest and improved SMO algorithm for support vector machine in Saf – Saf river basin[J]. *Environmental Science and Pollution Research*, 2022, 29(32): 48491 – 48508.
- [36] Ransom K M, Nolan B T, Stackelberg P E, et al. Machine learning predictions of nitrate in groundwater used for drinking supply in the conterminous United States[J]. *Science of the Total Environment*, 2022, 807(3): 151065.
- [37] Jeong Y, Lee J. A study on the prediction model for analysis of water quality in gwangju stream using machine learning algorithm[J]. *The Journal of the Korea Institute of Electronic Communication Sciences*, 2024, 19(3): 531 – 538.
- [38] Asadollah S B H S, Sharafati A, Motta D, et al. River water quality index prediction and uncertainty analysis: a comparative study of machine learning models[J]. *Journal of Environmental Chemical Engineering*, 2021, 9(1): 104599.
- [39] Ransom K M, Nolan B T, Traum J A, et al. A hybrid machine learning model to predict and visualize nitrate concentration throughout the Central Valley aquifer, California, USA[J]. *Science of the Total Environment*, 2017, 601: 1160 – 1172.
- [40] Alnahit A O, Mishra A K, Khan A A. Stream water quality prediction using boosted regression tree and random forest models[J]. *Stochastic Environmental Research and Risk Assessment*, 2022, 36(9): 2661 – 2680.
- [41] Islam A R M T, Pal S C, Chowdhuri I, et al. Application of novel framework approach for prediction of nitrate concentration susceptibility in coastal multi-aquifers, Bangladesh[J]. *Science of the Total Environment*, 2021, 801: 149811.
- [42] Li S, Bhattarai R, Cooke R A, et al. Relative performance of different data mining techniques for nitrate concentration and load estimation in different type of watersheds[J]. *Environmental Pollution*, 2020, 263: 114618.
- [43] Arabgol R, Sartaj M, ASghari K. Predicting nitrate concentration and its spatial distribution in groundwater resources using support vector machines(SVMs) model[J]. *Environmental Modeling & Assessment*, 2016, 21(1): 71 – 82.
- [44] Fan Y, Lu W, Miao T, et al. Optimal design of groundwater pollution monitoring network based on the SVR surrogate model under uncertainty[J]. *Environmental Science and Pollution Research*, 2020, 27(19): 24090 – 24102.
- [45] Najafzadeh M, Niazmardi S. A novel multiple-kernel support vector regression algorithm for estimation of water quality parameters[J]. *Natural Resources Research*, 2021, 30(5): 3761 – 3775.
- [46] Chia S L, Chia M Y, Koo C H, et al. Integration of advanced optimization algorithms into least-square support vector machine (LSSVM) for water quality index prediction[J]. *Water Supply*, 2021, 22(2): 1951 – 1963.
- [47] Yang Y, Shang X, Chen Z, et al. A support vector regression model to predict nitrate-nitrogen isotopic composition using hydrochemical variables[J]. *Journal of Environmental Management*, 2021, 290: 112674.

- [48] Aldemir A. Water quality modelling using combination of support vector regression with sequential minimal optimization for akkopru stream in Van, Turkey[J]. Fresenius Environmental Bulletin, 2021, 30(2): 1518 – 1526.
- [49] Najafzadeh M, Ghaemi A. Prediction of the five-day biochemical oxygen demand and chemical oxygen demand in natural streams using machine learning methods[J]. Environmental Monitoring and Assessment, 2019, 191(6): 380.
- [50] Nourani V, Andalib G, Dqbrowska D. Conjunction of wavelet transform and SOM-mutual information data pre-processing approach for AI-based multi-station nitrate modeling of watersheds[J]. Journal of Hydrology, 2017, 548: 170 – 183.
- [51] 李婷婷. 基于机器学习的工厂化水产养殖水质模拟预测[D]. 烟台: 鲁东大学, 2023.
Li Tingting. Simulation and prediction of water quality in industrial aquaculture system by using machine learning method[D]. Yantai: Ludong University, 2023. (in Chinese)
- [52] Li T, Lu J, Wu J, et al. Predicting aquaculture water quality using machine learning approaches[J]. Water, 2022, 14(18): 2836.
- [53] Stamenkovic L. Application of ANN and SVM for prediction nutrients in rivers[J]. Journal of Environmental Science and Health Part a-Toxic/Hazardous Substances & Environmental Engineering, 2021, 56(8): 867 – 873.
- [54] Bhattarai A, Dhakal S, Gautam Y, et al. Prediction of nitrate and phosphorus concentrations using machine learning algorithms in watersheds with different landuse[J]. Water, 2021, 13(21): 3096.
- [55] Li C, Hu W, Ye C, et al. Study on prediction of total nitrogen removal effect of a surface water purification device based on BP neural network[J]. Journal of Environmental Engineering Technology, 2018, 8(6): 651 – 655.
- [56] Zaqoot H A, Hamada M, Miqdad S. A comparative study of ANN for predicting nitrate concentration in groundwater wells in the southern area of Gaza strip[J]. Applied Artificial Intelligence, 2018, 32(7 – 10): 727 – 744.
- [57] 张青, 王学雷, 张婷, 等. 基于 BP 神经网络的洪湖水水质指标预测研究[J]. 湿地科学, 2016, 14(2): 212 – 218.
Zhang Qing, Wang Xuelei, Zhang Ting, et al. Prediction of water quality index of Honghu Lake based on back propagation neural network model[J]. Wetland Science, 2016, 14(2): 212 – 218. (in Chinese)
- [58] 付泰然. 基于 SAE – BP 神经网络的水体“三氮”在线预测模型研究[D]. 武汉: 华中农业大学, 2020.
Fu Tairan. Establishment of a water “Three nitrogens” concentrations prediction model basing on stacked autoencoder-BP neural network[D]. Wuhan: Huazhong Agricultural University, 2020. (in Chinese)
- [59] Deng Y, Ye X, Du X. Predictive modeling and analysis of key drivers of groundwater nitrate pollution based on machine learning[J]. Journal of Hydrology, 2023, 624: 129934.
- [60] Kumar P, Lai S H, Mohd N S, et al. Optimised neural network model for river-nitrogen prediction utilizing a new training approach[J]. Plos One, 2020, 15(9): e0239509.
- [61] 俞方罡, 秦斌. 基于 BSM1 的硝态氮浓度辨识建模[J]. 电子产品世界, 2020, 27(2): 49 – 54.
Yu Fanggang, Qin Bin. Modeling and optimal control of wastewater treatment process based on BSM1[J]. Electronic Engineering & Product World, 2020, 27(2): 49 – 54. (in Chinese)
- [62] McGill T, Ford W I. Extreme learning machine predicts high-frequency stream flow and nitrate-N concentrations in a karst agricultural watershed[J]. Journal of the ASABE, 2024, 67(2): 305 – 319.
- [63] Wagh V, Panaskar D, Muley A, et al. Neural network modelling for nitrate concentration in groundwater of Kadava River Basin, Nashik, Maharashtra, India[J]. Groundwater for Sustainable Development, 2018, 7: 436 – 445.
- [64] Gao H, Chen B, Qaisar M, et al. Machine learning-based model construction and identification of dominant factor for simultaneous sulfide and nitrate removal process[J]. Bioresource Technology, 2023, 390: 129848.
- [65] 赵敏, 赵强. 基于神经网络的污水处理系统广义预测控制[J]. 控制工程, 2023, 30(11): 2091 – 2099.
Zhao Min, Zhao Qiang. Generalized predictive control for wastewater treatment system based on neural network[J]. Control Engineering of China, 2023, 30(11): 2091 – 2099. (in Chinese)
- [66] Kumar P, Lai S H, Mohd N S, et al. Enhancement of nitrogen prediction accuracy through a new hybrid model using ant colony optimization and an Elman neural network[J]. Engineering Applications of Computational Fluid Mechanics, 2021, 15(1): 1843 – 1867.
- [67] Chen Y, Song L, Liu Y, et al. A review of the artificial neural network models for water quality prediction[J]. Applied Sciences, 2020, 10(17): 5776.
- [68] Farhi N, Kohen E, Mamane H, et al. Prediction of wastewater treatment quality using LSTM neural network[J]. Environmental Technology & Innovation, 2021, 23(2): 101632.
- [69] Zhou Y, Yang J, Tolba A, et al. A data-driven intelligent management scheme for digital industrial aquaculture based on multi-object deep neural network[J]. Mathematical Biosciences & Engineering, 2023, 20(6): 10428 – 10443.
- [70] 习文双, 江敏, 吴昊, 等. 基于 PCA – LSTM 神经网络的凡纳滨对虾养殖水质预测[J]. 上海海洋大学学报, 2023, 32(1): 108 – 117.
Xi Wenshuang, Jiang Min, Wu Hao, et al. Prediction of water quality in *Litopenaeus vannameia* quaculture ponds based on the PCA – LSTM neural network model[J]. Journal of Shanghai Ocean University, 2023, 32(1): 108 – 117. (in Chinese)
- [71] Tian Q, Luo W, Guo L. Water quality prediction in the Yellow River source area based on the DeepTCN – GRU model[J]. Journal of Water Process Engineering, 2024, 59: 105052.

[31] Li Y, Jia S, Li Q. BalanceHRNet: an effective network for bottom-up human pose estimation[J]. Neural Networks, 2023, 161: 297 – 305.

[32] 袁红春,李春桥. 基于改进可变形卷积的 FDC – YOLO v8 水下生物目标检测方法研究[J]. 农业机械学报,2024, 55(11):140 – 146.
Yuan Hongchun, Li Chunqiao. Research on FDC – YOLO v8 underwater biological object detection method improved by deformable convolution[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 140 – 146. (in Chinese)

[33] 罗斌,李家超,周亚男,等. 基于改进 YOLO v8 的轻量化稻瘟病孢子检测方法[J]. 农业机械学报,2024,55(11):32 – 38.
Luo Bin, Li Jiachao, Zhou Ya'nan, et al. Lightweight rice blast spores detection method based on improved YOLO v8[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 32 – 38. (in Chinese)

[34] 杨断利,齐俊林,陈辉,等. 基于改进 YOLO v8n 模型的散养蛋鸡个体行为识别方法与差异分析[J]. 农业机械学报, 2024, 55(11): 112 – 123.
Yang Duanli, Qi Junlin, Chen Hui, et al. Individual behavioral identification and differential analysis of free-range laying hens based on improved YOLO v8n model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 112 – 123. (in Chinese)

[35] 徐浩哲,王元兴. 改进 YOLO v10n 的无人机航拍图像检测算法[J]. 计算机科学与应用, 2025, 15(1): 230 – 238.
Xu Haozhe, Wang Yuanxing. Algorithm for aerial image detection of unmanned aerial vehicles based on improved YOLO v10n [J]. Computer Science and Application, 2025, 15(1): 230 – 238. (in Chinese)

[36] Chen R, Zhou H, Xie H, et al. YOLO – CE: an underwater low-visibility environment target detection algorithm based on YOLO 11[J]. The Journal of Supercomputing, 2025, 81(5): 1 – 24.

[37] 徐洁,杨长茂,陈建平,等. 基于多流形的单样本人脸模糊分类算法[J]. 计算机工程与设计, 2025, 46(3): 719 – 725.
Xu Jie, Yang Changmao, Chen Jianping, et al. Multi-manifold based fuzzy classificational gorithm for single face image problem [J]. Computer Engineering and Design, 2025, 46(3): 719 – 725. (in Chinese)

[38] Lim-Apo F A, Oliveira F, Hamacher S. Decision tree enhancer (DTE): improving decision trees with optimization[J]. Knowledge-Based Systems, 2026, 339: 115597.

[39] Xu W, Zhu H, Zheng Y, et al. ELXGB: an efficient and privacy-preserving XGBoost for vertical federated learning[J]. IEEE Transactions on Services Computing, 2024, 17(3): 878 – 892.



(上接第 12 页)

[72] Huang S, Wang Y, Xia J. Which riverine water quality parameters can be predicted by meteorologically-driven deep learning? [J]. Science of the Total Environment, 2024, 946: 174357.

[73] Nunno F D, Race M, Granata F. A nonlinear autoregressive exogenous(NARX) model to predict nitrate concentration in rivers [J]. Environmental Science and Pollution Research, 2022, 29(27): 40623 – 40642.

[74] Chen S, Huang J, Wang P, et al. A coupled model to improve river water quality prediction towards addressing non-stationarity and data limitation[J]. Water Research: a Journal of the International Water Association, 2024, 248: 120895.

[75] Meng H, Song J, Huang L, et al. Water quality prediction method based on OVMD and spatio-temporal dependence[J]. Technical Gazette/Tehnički Vjesnik, 2024, 31(1): 286 – 295.

[76] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need [C] // Proceedings of the 31st International Conference on Neural Information Processing System, 2017: 6000 – 6010.

[77] Wu R, Painumkal J T, Volk J M, et al. Parameter estimation of nonlinear nitrate prediction model using genetic algorithm [C] // IEEE Congress on Evolutionary Computation (CEC), SPAIN, 2017: 1358 – 2069.

[78] Manzar M S, Benaafi M, Costache R, et al. New generation neurocomputing learning coupled with a hybrid neuro-fuzzy model for quantifying water quality index variable: a case study from Saudi Arabia[J]. Ecological Informatics, 2022, 70: 101696.

[79] Pham Q B, Mohammadpour R, Linh N T T, et al. Application of soft computing to predict water quality in wetland[J]. Environmental Science and Pollution Research, 2021, 28(1): 185 – 200.

[80] Lü J, Du L, Lin H, et al. Enhancing effluent quality prediction in wastewater treatment plants through the integration of factor analysis and machine learning[J]. Bioresource Technology, 2024, 393: 130008.

[81] 李道亮,赵晔,杜壮壮. 农业领域多模态融合技术方法与应用研究进展[J]. 农业机械学报, 2025, 56(1): 1 – 15.
Li Daoliang, Zhao Ye, Du Zhuangzhuang. Advances in multi-modal fusion techniques and applications in agricultural field [J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(1): 1 – 15. (in Chinese)

[82] 马若飞,杜岳峰,郭大方,等. 农场数字孪生技术发展现状与展望[J]. 农业机械学报, 2025, 56(9): 257 – 277.
Ma Ruofei, Du Yuefeng, Guo Dafang, et al. Development status and prospect of digital twin farm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(9): 257 – 277. (in Chinese)