

基于 PSO – SABO – CGA 的养殖水氨氮预测模型研究

张佳然¹ 马玉超¹ 于杰¹ 王亮^{2,3} 杜卓轩¹ 王聪^{4,5}

(1. 北京建筑大学智能科学与技术学院, 北京 100044; 2. 萨里大学工程与物理科学学院, 吉尔福德 GU2 7XH;
3. 国家数字渔业创新中心, 北京 100083; 4. 农业农村部智慧养殖技术重点实验室, 北京 100083;
5. 中国农业大学信息与电气工程学院, 北京 100083)

摘要: 氨氮含量是影响水产养殖水质的重要指标之一,其精准预测对水产养殖管理具有重要意义。针对氨氮浓度变化受多环境因素影响、预测精度不足的问题,提出一种基于粒子群 (Particle swarm optimization, PSO)-减法平均优化器 (Subtract average-based optimizer, SABO) 改进的卷积神经网络-门控循环单元-注意力机制 (Convolutional neural network – gated recurrent unit – attention, CGA) 预测模型 (PSO – SABO – CGA)。该方法通过融合 PSO 优化算法的全局最优引导机制,增强 SABO 算法在超参数空间中的全局探索与收敛能力,并利用该改进算法对 CGA 模型的关键超参数进行自动寻优。试验结果表明,该研究提出的 PSO – SABO – CGA 模型在养殖水氨氮浓度预测中表现优异,其平均绝对误差、均方根误差和决定系数分别达到 0.062 mg/L、0.082 mg/L 和 0.934;相较于基线模型,PSO – SABO – CGA 模型在短期与长期预测中均显示出更高的精度与稳定性,当预测时间为 24 h 时决定系数仍高达 0.842,为养殖水体氨氮浓度的精准预测提供了可靠方法。

关键词: 水产养殖; 氨氮预测模型; 超参数优化; PSO – SABO – CGA

中图分类号: S951.2 文献标识码: A 文章编号: 1000-1298(2026)15-0374-10

OSID:



Ammonia Nitrogen Prediction Model for Aquaculture Water Based on PSO – SABO – CGA

Zhang Jiaran¹ Ma Yuchao¹ Yu Jie¹ Wang Liang^{2,3} Du Zhuoxuan¹ Wang Cong^{4,5}

(1. School of Intelligence Science and Technology, Beijing University of Civil Engineering and Architecture, Beijing 100044, China
2. Faculty of Engineering and Physical Sciences, University of Surrey, Guildford GU2 7XH, UK
3. National Innovation Center for Digital Fishery, Beijing 100083, China
4. Key Laboratory of Smart Farming Technologies for Aquatic Animals and Livestock, Ministry of Agriculture and Rural Affairs, Beijing 100083, China
5. College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China)

Abstract: Accurate prediction of ammonia nitrogen (ammonia-N) concentration is critical for water quality management in intensive aquaculture. However, ammonia-N dynamics exhibit pronounced nonlinear characteristics due to coupled environmental factors, making precise forecasting challenging. To address this issue, a hybrid prediction model integrating a convolutional neural network – gated recurrent unit-attention (CGA), optimized by a particle swarm optimization (PSO)-enhanced subtraction average-based optimizer (SABO), was proposed. Key environmental variables influencing ammonia-N dynamics were identified by using Pearson correlation analysis, with dissolved oxygen, nitrate-nitrogen, pH value, and water temperature selected as input features. To overcome hyperparameter optimization challenges, the PSO – SABO algorithm was developed by integrating the global memory mechanism of PSO into the update framework of SABO to enhance global exploration and accelerate convergence. Experimental results demonstrated that the proposed PSO – SABO – CGA model achieved superior prediction performance. For the 5-min prediction horizon, it attained a mean absolute error (MAE) of 0.062 mg/L, a root mean square error (RMSE) of 0.082 mg/L, and a coefficient of determination (R^2) of 0.934.

收稿日期: 2026-02-17 修回日期: 2026-03-13

基金项目: 国家自然科学基金项目 (32502350) 和国家重点研发计划项目 (2022YFD2001702)

作者简介: 张佳然 (1988—), 女, 讲师, 博士, 主要从事渔业先进感知与智能信息处理研究, E-mail: zhangjiaran@bucea.edu.cn

通信作者: 王聪 (1986—), 男, 副教授, 博士, 主要从事渔业先进感知与智能信息处理研究, E-mail: ndfic_wc@cau.edu.cn

Comparative analyses revealed that PSO - SABO achieved faster and more stable convergence than the hippopotamus optimization (HO) and genetic algorithm (GA), reducing MAE and RMSE by up to 24.26% and 25.19%, respectively. Ablation studies confirmed the effectiveness of the GRU component and the necessity of PSO global guidance. Compared with the temporal convolutional network (TCN), bidirectional long short-term memory (BiLSTM), backpropagation neural network (BPNN), and standard GRU, the proposed model reduced MAE by up to 15.07% for the 5-min horizon and maintained an R^2 of 0.842 for the 24 h horizons. These findings indicated that the PSO-enhanced global search, combined with SABO's adaptive mechanism, significantly improved hyperparameter optimization. This enabled the framework to effectively capture nonlinear ammonia-N dynamics under multi-factor interactions, offering superior accuracy, robustness, and generalization across both short-term and extended prediction horizons. This approach can provide a reliable technical foundation for intelligent water quality monitoring and precision management in aquaculture systems.

Key words: aquaculture; ammonia-nitrogen predictive model; hyperparameter optimization; PSO - SABO - CGA

0 引言

2024 年我国水产品养殖产量达 6 060 万吨,占全球总量 60% 以上,居世界首位^[1]。氨氮具有生物毒性,其含量是衡量水产养殖环境质量的重要指标之一。过高浓度的氨氮不仅会引起水体富营养化,还会威胁鱼类的生长生存。通常,当氨氮质量浓度超过 0.02 mg/L 时,就会引起水生生物中毒乃至大量死亡^[2]。因此,精准预测氨氮浓度,对于实现水产养殖的精准化管理、防范风险至关重要。

氨氮浓度易受水体温度、pH 值、溶解氧浓度以及大气压力等多种环境因素的影响,表现出强烈的非线性、时序性波动特征^[3]。例如,pH 值每升高 1 个单位,水中游离氨的比例增加约 3 ~ 5 倍;同时,温度每升高 10 ℃,氨氮对鱼类的毒性效应也会增强 1.5 ~ 2 倍^[4]。此外,在高密度养殖模式下,过量投饵、生物代谢物及残骸分解等会导致内源性氨氮污染不断累积^[5]。在这些因素的多重耦合影响下,氨氮浓度的精准预测一直是水产养殖领域的难题。

数据挖掘算法如神经网络、机器学习等已被广泛用于水质氨氮浓度的预测^[6]。通过超参数优化,模型的时序依赖捕捉能力被进一步提高^[7]。

随着深度学习技术在时序预测领域的深入,长短期记忆网络(Long short-term memory, LSTM)、门控循环单元(Gated recurrent unit, GRU)及注意力机制(Attention)等因其在提取局部特征、捕捉长期依赖及聚焦关键信息方面的优势,逐渐成为氨氮预测研究的热点。针对氨氮预测动态过程复杂、数据稀缺等问题,Qiu 等^[8]提出 Transformer - LSTM 混合预测模型,通过融合 Transformer 编码器捕捉长程依赖的能力与 LSTM 解码器建模周期性过程时序模式的

优势,该模型的平均绝对误差(Mean absolute error, MAE)达 2.043 0 mg/L,展现出较强的实用性。韩旭等^[9]构建了基于卷积神经网络(Convolutional neural network, CNN)-双向门控循环单元(BiGRU)-多头注意力机制(Multi-head attention, MHA)的混合模型预测氨氮浓度,以国家公开水质数据作为实际算例,氨氮预测实际值与预测值的 MAE 为 0.009 91 mg/L,决定系数(R^2)达 0.962 8。

此外,也有研究尝试将水质变化的物理机理与数据驱动模型相结合,以增强模型的解释性与鲁棒性。Zhu 等^[10]提出了一种融合物理约束(Physics informed, PI)、图卷积网络(Graph convolutional network, GCN)与 LSTM 结构的氨氮预测混合模型。PI 有助于抑制预测结果的异常突变,从而提升输出与实际数据的一致性;GCN 则增强了模型对数据空间特征的提取能力。然而,受限于物理约束与数据拟合难以有效平衡等因素,此类融合物理信息的方法通常结构复杂^[11]。此外,现有数据驱动模型在参数优化方面多依赖人工经验、难以兼顾精度与效率,且常规优化算法在处理复杂高维空间时易陷入局部最优、收敛速度缓慢^[12],制约了模型预测性能的进一步提升。

针对上述问题,本研究提出一种基于 PSO - 减法平均优化器(Subtract average-based optimizer, SABO)改进的卷积神经网络-门控循环单元-注意力机制(Convolutional neural network - gated recurrent unit - attention, CGA)模型(PSO - SABO - CGA),用于养殖水中的氨氮浓度预测。通过结合 PSO 全局引导项的 SABO 算法优化 CGA 模型参数,降低养殖水氨氮预测模型的复杂度,克服时序依赖特性对模型预测精度的不利影响,为水产养殖水体氨氮浓度的短期与长期精准预测提供新方法。

1 材料与方法

1.1 试验数据

本研究以中国农业大学数字渔业养殖中心的养殖池为试验现场,开展试验。养殖池直径 20 m,水深约 1.3 m。为确保数据覆盖养殖池不同空间区域的环境特征,传感器部署于水深 0.8 m 处,实时采集水质环境参数。具体参数包括溶解氧质量浓度、水温、硝酸盐氮质量浓度、水位、pH 值以及氨氮质量浓度。传感器参数性能如表 1 所示。

表 1 传感器参数性能

Tab.1 Sensor parameter performance

传感器类型	量程	精度	电压/V
溶解氧质量浓度传感器	0 ~ 20 mg/L	0.1 mg/L	1.8 ~ 5.0
水温传感器	-10 ~ 70 ℃	± 0.2 ℃	1.8 ~ 5.0
硝酸盐氮质量浓度传感器	0 ~ 100 mg/L	0.3 mg/L	12 ~ 24
水位传感器	0 ~ 50 m	± 0.05%	12 ~ 24
酸碱度传感器	0 ~ 14	± 0.05	1.8 ~ 5.0
氨氮质量浓度传感器	0 ~ 100 mg/L	0.1 mg/L	12 ~ 24

数据采集时间为 2023 年 7 月 28 日—8 月 25 日,共持续 28 d,采样间隔设定为 5 min,共获得有效样本数据 8 206 条。样本集按照比例 7:3 划分为训练集与测试集。整个试验周期内,未对基础水质参数进行额外干预,仅依靠常规养殖操作维持水体环境的稳定性。

1.2 数据处理

传感器数据易受环境噪声污染,导致原始信号包含高频随机波动,影响模型预测稳定性和精度。对于在数据采集过程中因传感器故障导致的异常值与缺失值,本研究采用插值法和数据剔除法进行处理^[13]。数据剔除过程中,严格遵守时序一致性原则,确保数据集的时域特征保持完整的对应关系。对于缺失值,根据其所在位置的邻近数据点前后的两个观测值的平均值来填补,即

$$V_k = \frac{V_{k-1} + V_{k+1}}{2}$$

(1)

式中 V_k ——需要替换的异常值或缺失值
 V_{k-1} 、 V_{k+1} ——该值前后时刻的数据值

处理后部分氨氮数据如图 1 所示,在 3 d 的监测期内,氨氮质量浓度在 0.30 ~ 0.50 mg/L 之间呈周期性波动,每日凌晨氨氮质量浓度高于 0.43 mg/L,每日 11:00—12:00 之间,氨氮质量浓度低于 0.35 mg/L。其间出现一次轻度峰值(0.51 mg/L),但均迅速恢复至正常范围,表明水体中氨氮的生成与消耗过程基本处于动态平衡状态,整体水质较为稳定。




图 1 数据处理后氨氮质量浓度变化曲线
Fig.1 Change curve of mmonia-nitrogen mass concentration after data processing

此外,为消除量纲差异、提升预测效果,对水质参数进行归一化处理,计算式为^[14]

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}}$$

(2)

式中 x_{norm} ——水环境参数的标准化值
 x_{max} 、 x_{min} ——该参数的最大值、最小值

经归一化处理后的数据范围在[0,1]之间,解决因数据间量纲差异较大导致的误差问题。

1.3 关键影响因素筛选

养殖水体中的氨氮主要来源于鱼类的排泄和有机物的分解,其消耗则主要通过硝化细菌的氧化作用。氨氮浓度的变化过程受到多种环境因素的调控,包括水温、溶解氧浓度、pH 值、硝酸盐氮浓度及水位等,这些参数通过影响物理、化学平衡与微生物活性共同决定氨氮的动态变化^[15]。为识别影响氨氮浓度的关键变量,本研究采用皮尔逊相关系数法^[16],并结合系统动力学分析,对各潜在因素进行相关性分析。

皮尔逊相关性分析结果显示(图 2),溶解氧与氨氮浓度呈高度正相关,而 pH 值与氨氮浓度呈强负相关;水温与氨氮浓度的相关性最弱,相关系数仅




图 2 氨氮浓度与各水质参数的皮尔逊相关系数
Fig.2 Pearson correlation coefficients between ammonia-nitrogen concentration and water parameters

为 -0.039 。从系统动力学角度分析,溶解氧是硝化过程的必需物质,其浓度直接影响硝化效率,低溶解氧环境不仅抑制硝化作用,导致氨氮积累,还可能诱发鱼类应激,进一步加剧氨氮排放^[17];pH 值通过调控离子铵与游离氨之间的平衡影响氨氮形态分布^[18]。在本研究养殖池中,pH 值处于 $7.2 \sim 7.8$ 区间,基本处于硝化细菌较适宜的活性范围。较高的硝化速率会促进氨氮向硝酸盐氮转化,使氨氮浓度降低。但随着硝化过程的进行,会释放 H^+ ,从而对水体 pH 值产生一定的降低作用。因此,pH 值与氨氮浓度总体呈负相关,同时与硝酸盐氮浓度也表现出负相关性;硝酸盐氮作为硝化作用的终产物,其浓度可间接反映系统硝化能力的强弱。此外,水温通过影响硝化细菌的活性来影响系统中氨氮浓度^[19]。水位通过压强影响游离氨在水中的溶解度,然而本研究中,水位变化在 $0.79 \sim 0.82$ m 之间,对氨溶解度的影响几乎可以忽略。

总之,上述参数并非独立作用,而是通过影响化学平衡、微生物活性及物理传输过程,构成了一个包含正负反馈的氮循环网络。综合考虑皮尔逊相关性和系统动力学作用过程,本研究选取溶解氧浓度、硝酸盐氮浓度、pH 值及水温作为构建氨氮预测模型的输入参数,以更全面地反映养殖水体中氨氮变化的复杂动力学机制。

1.4 养殖水氨氮预测模型设计

1.4.1 CGA 模型

为解决养殖水体中氨氮浓度变化受多环境因素耦合影响的问题,本研究构建了 CGA 预测模型,通过 CNN 空间特征提取、GRU 时序依赖建模、Attention 关键信息加权以及全链层预测输出,实现对氨氮浓度的精准预测。模型结构如图 3 所示。




图 3 CGA 模型结构图

Fig. 3 Diagram of CGA model architecture

CNN 模块用于从输入的多维时间序列数据(包括水温、硝酸盐氮浓度、溶解氧浓度和 pH 值)中提取空间局部特征。通过卷积层与池化层的操作,CNN 能够有效捕捉不同环境因素之间的局部相关性,并实现数据降维,为后续时序建模提供高质量的特征表示^[20]。

GRU 模块作为时序建模的核心,用于捕捉氨氮浓度随时间变化的长期依赖关系。GRU 通过其更新门与重置门机制,能够有效控制历史信息的传递

与遗忘,克服传统循环神经网络在长序列训练中出现的梯度消失或爆炸问题^[21]。给定 CNN 提取的特征序列 $x = (x_1, x_2, \dots, x_t)$ 作为输入,GRU 在时间步 t 的计算过程为^[22]

$$\begin{cases} z_t = \sigma(W_z[h_{t-1}, x_t]) \\ r_t = \sigma(W_r[h_{t-1}, x_t]) \\ \tilde{h}_t = \tanh(W[\tilde{r}_t h_{t-1}, x_t]) \\ h_t = (1 - z_t)h_{t-1} + z_t \tilde{h}_t \end{cases} \quad (3)$$

式中 z_t, r_t ——更新门和重置门在时间步 t 的输出
 W_z, W_r, W ——对应的权重矩阵
 h_{t-1} ——上一时间步的隐藏状态
 $\tilde{h}_t$ ——时刻 t 的候选隐状态
 h_t ——当前时间步隐藏状态
 $\sigma, \tanh$ ——激活函数

为进一步提高模型对关键时序特征的敏感度,引入了 Attention 机制。通过对 GRU 输出的隐藏状态 $\{h_1, h_2, \dots, h_t\}$ 进行加权融合,自动识别并强化对氨氮浓度预测贡献最大的特征时段。其计算过程为^[23]

$$\begin{cases} u_t = \tanh(W_i h_t + b) \\ a_t = \text{softmax}(u_t^T, u_w) \\ A_n = \sum_{t=0}^T a_t u_t \end{cases} \quad (4)$$

式中 W_i ——权重矩阵
 b ——偏置项
 t ——当前迭代次数
 T ——最大迭代次数
 u_t ——中间特征表示向量
 u_w ——通过模型训练学习得到的上下文向量
 a_t ——经 softmax 函数归一化后的注意力权重
 A_n ——加权求和后得到的最终上下文向量

最终,将 Attention 机制输出的综合特征向量 A_n 输入至全连接层,映射得到氨氮浓度的最终预测值。该 CGA 模型通过端到端的训练方式,实现了从原始多变量水质时序数据到氨氮浓度预测值的非线性映射,具有较强的特征表达能力和时序建模能力,为养殖水体氨氮浓度的精准预测提供可靠的技术基础。

1.4.2 PSO 改进的 SABO 参数调优

模型的性能在很大程度上依赖其超参数配置。为提升 CGA 模型的预测精度与泛化能力,本研究采用基于数学自适应行为的优化算法 SABO 对模型关键超参数进行自动寻优。SABO 算法通过模拟搜索

代理在解空间中的数学交互行为,有效平衡全局探索与局部开发,具有收敛速度快、鲁棒性强的特点^[24]。

然而,在对 CGA 复杂深度模型的高维超参数空间进行优化时,经典 SABO 算法更新策略高度依赖于当前种群个体间的瞬时相对关系,缺乏对搜索过程中已发现的全局最优经验的持续利用,导致全局开发能力不足,收敛至最优区域的速度较慢;此外,在优化末期,算法易在局部最优解附近振荡,收敛稳定性有待加强。

本研究引入 PSO 的全局记忆与导向机制,以增强对优质区域的精准开发。通过将 PSO 与 SABO 结合,增强全局搜索能力,优化流程如图 4 所示。




图 4 PSO-SABO 优化流程图

Fig. 4 Flowchart of PSO-SABO optimization

首先在设定的边界内随机初始化种群

$$X(i,j)=lo_j+\text{rand}(hi_j-lo_j) \tag{5}$$

式中 $X(i,j)$ ——第 i 个个体的第 j 维变量
 lo_j,hi_j ——变量的下界和上界
 rand —— $[0,1]$ 之间的随机数

随后,计算每个个体的适应度并找到当前全局最优个体,即

$$\begin{cases} \text{fit}(i)=\text{fitness}(X(i,:)) \\ f_{\text{best}}=\min(\text{fit}) \mathbf{x}_{\text{best}}=X(i_{\text{best}},:) \end{cases} \tag{6}$$

式中 $\text{fit}(i)$ ——第 i 个个体的适应度
 $\text{fitness}(\cdot)$ ——目标函数,用于评估个体优劣
 $X(i,:)$ ——第 i 个体位置向量
 $\mathbf{x}_{\text{best}}$ ——当前种群中适应度最优个体的位置
 f_{best} ——对应的最优适应度
 i_{best} ——最优个体的索引号

算法主循环迭代从第 1 代到第 T 代,步骤如下:

(1)惯性权重 w 动态调整,以增强初期全局搜索能力,并促进后期局部收敛,其计算式为

$$w=0.9-\frac{0.5t}{T} \tag{7}$$

(2)社会学习与差分更新。基于 SABO 的差分向量 $\mathbf{DX}$,计算每个个体 i 与其他个体的位置及适应度差异,其计算式为

$$\mathbf{DX}=\sum_{j=1}^N(X(j,:)-IX(i,:))\text{sign}(\text{fit}(i)-\text{fit}(j)) \tag{8}$$

式中 $\mathbf{DX}$ ——第 i 个个体相对全体个体的差异向量
 I ——集合 $\{1,2\}$ 中随机选取的整数,用于增强多样性

$\text{sign}(\cdot)$ ——当 $\text{fit}(i)>\text{fit}(j)$ 返回正值,反之为负;当 $\text{fit}(i)=\text{fit}(j)$ 时返回值为 0

$X(j,:)$ ——第 j 个个体的位置向量
 N ——种群规模

(3)融合 PSO 的全局引导项,作为修正量加入个体更新中,从而提升对全局最优的收敛能力^[25],即

$$\text{global}_{\text{influence}}=c_1\mathbf{r}_1(\mathbf{x}_{\text{best}}-X(i,:)) \tag{9}$$

式中 $\text{global}_{\text{influence}}$ ——全局最优引导分量
 c_1 ——学习因子
 $\mathbf{r}_1$ ——随机向量

(4)结合个体位置更新与边界处理,构造最终位置更新公式,并对越界变量执行修正,确保所有解在合法范围内,有

$$X_{\text{new}}=\begin{cases} X_i+w\left(\frac{\text{rand}(1,m)\mathbf{DX}}{N}\right)+\text{global}_{\text{influence}} \\ \max(\min(X_{\text{new}},hi),lo) \end{cases} \tag{10}$$

式中 X_{new} ——第 i 个体的新位置
 X_i ——第 i 个候选解位置向量
 $\text{rand}(1,m)$ ——长度为 m 的随机向量

(5)贪婪选择与局部搜索。为防止算法陷入局部最优,加入 10% 概率的维度随机变异操作,并采用“优者生存”机制,以更优的新解替换旧解^[26]。

$$X_i=\begin{cases} X_{\text{new}} & (\text{fit}_{\text{new}}<\text{fit}(i)) \\ X_i & (\text{其他}) \end{cases} \tag{11}$$

式中 fit_{new} ——更新后新位置对应的适应度
当迭代进入中后期($t>T/2$ 且每 5 轮一次),采用局部搜索机制,对当前最优个体进行局部扰动,实现精细搜索,有

$$X_{\text{local}}=\mathbf{x}_{\text{best}}+r_s(hi-lo)(2\text{rand}(1,m)-1) \tag{12}$$

式中 X_{local} ——局部搜索后的个体位置

r_s ——局部搜索半径,即控制扰动强度
随着迭代进程逐步减小

$$r_s = 0.1 \left(1 - \frac{t}{T} \right) \tag{13}$$

记录适度收敛曲线 $best_{sofar}(t)$ 并输出最优结果

$$best_{sofar}(t) = f_{best} average(t) = \frac{1}{N} \sum fit(i) \tag{14}$$

式中 $f_{best} average(t)$ ——第 t 次迭代时最优个体平均适应度

1.4.3 基于 PSO - SABO - CGA 的氨氮预测模型

基于 PSO - SABO - CGA 的氨氮预测流程如图 5 所示。




图 5 氨氮预测流程图

Fig. 5 Flowchart for ammonia-nitrogen prediction

(1)数据采集与处理。对原始数据进行异常值和缺失值处理,去除噪声,并进行归一化处理,为后续建模提供高质量、标准化的数据;分析各水质变量与氨氮之间的相关性,筛选出关键特征变量^[26]。

(2)模型构建与优化。确定 CGA 模型的整体架构,包括 CNN、GRU 和 Attention 机制各模块的初步层级设计。并依据先验知识确定待优化超参数,

包括卷积层和卷积核个数、GRU 层数以及学习率等。为避免手动调参的盲目性与传统优化算法易陷入局部最优的缺陷,融合 PSO 的全局引导机制与 SABO 的差分学习框架,通过模拟代理间的信息交互和群体智能的全局搜索经验,在复杂的超参数空间中高效寻优,最终获取 CGA 模型的最佳超参数组合。

(3)模型测试与性能评估。将测试样本代入进行测试,将得到的预测结果与真实值数据进行比较分析,量化其预测精度;设计消融试验,分别评估各组件对最终预测精度的贡献,从而验证模型结构设计的合理性与必要性。

1.5 模型评价指标

本研究采用 3 个指标评价预测模型的性能,具体包括 R^2 、MAE 和均方根误差 (Root mean square error, RMSE)。

2 试验

2.1 优化算法对比试验

为验证 PSO - SABO 算法的性能,本研究将其与河马优化算法 (Hippopotamus optimization, HO)^[27]、遗传算法 (Genetic algorithm, GA)^[28] 分别与 CGA 预测模型结合进行对比试验,以分析不同优化算法对模型预测性能的影响。试验设定群体规模为 6,最大迭代次数为 25。3 种优化算法与 CGA 结合后的模型预测性能评价结果如图 6 所示。




图 6 不同步长下 3 种优化算法优化的 CGA 模型预测性能

Fig. 6 Prediction performance of CGA model optimized by three algorithms under different step sizes

随着预测步长增加,各模型预测精度均呈下降趋势。PSO - SABO - CGA 模型的 R^2 介于 0.876 ~ 0.934 之间,优于 HO - CGA 与 GA - CGA 模型 (0.832 ~ 0.908),说明其能够更好地模拟氨氮的变化趋势。在 RMSE 方面,PSO - SABO - CGA 模型为 0.082 ~ 0.136 mg/L,同样低于另外两种模型 (0.101 ~ 0.177 mg/L)。此外,PSO - SABO - CGA 模型的 MAE 范围为 0.062 ~ 0.103 mg/L,亦优于对比模型 (0.074 ~ 0.136 mg/L)。

在相同预测步长下,相较于 HO - CGA 模型,PSO - SABO - CGA 的 MAE 与 RMSE 最大降幅分别为 24.26% 和 25.19%, R^2 最高提升 7.48%;相较于 GA - CGA 模型,MAE 与 RMSE 最大降幅分别为 18.68% 和 18.81%, R^2 最高提升 5.29%。如图 7 所示,在单步预测中,PSO - SABO - CGA 模型的预测曲线最接近真实值,其次为 HO - CGA、GA - CGA,说明 PSO - SABO 能更有效地优化模型参数组合。




图7 不同时间内3种优化算法的氨氮预测曲线

Fig.7 Ammonia-nitrogen prediction curves of CGA model optimized by three algorithms over time

从迭代过程来看(图8),PSO-SABO从首次迭代开始即处于较优的目标函数值(−0.074),并持续稳定下降至第5次迭代的−0.091,展现出良好的收敛稳定性与较快的初期收敛趋势。相比之下,HO和GA算法初始值较差,直至后期才逐步下降至负值区域,且其收敛速度不及PSO-SABO。这表明PSO-SABO在迭代过程中能够更迅速、更稳定地逼近高质量解,有利于提升CGA模型参数优化的效率与可靠性。




图8 不同优化算法优化的CGA模型收敛曲线

Fig.8 Convergence curves of CGA models optimized by three algorithms

综上所述,本研究构建的PSO-SABO优化算法能显著提升CGA模型的预测精度,更准确地对养殖水氨氮含量进行预测,尤其在对非线性变化趋势的响应与极端值的拟合方面表现突出,适用于具有复杂变化特征的时序预测任务。

2.2 不同预测步长下的模型对比试验

通过PSO-SABO优化,PSO-SABO-CGA模型核心参数如下:卷积层数为2层,第1层卷积核数量为32,核尺寸为4;第2层卷积核数量为64,核尺寸为1。GRU隐藏单元数为35,学习率为0.0026,Dropout率为0.051。

为了全面评估PSO-SABO-CGA的模型性能,本研究将其与多种典型神经网络模型在相同数据集与预测步长下进行对比分析,包括时序卷积网络(Temporal convolutional network,TCN)^[29]、双向长短

期记忆网络(Bidirectional long short-term memory,BiLSTM)^[30]、反向传播神经网络(Back propagation,BP)^[31]以及GRU^[32]。根据实际水产养殖过程的不同需求,选取了4个典型预测步长,1步(5 min)、12步(1 h)、144步(12 h)和288步(24 h),以同时考察模型在短时响应与长时稳定预测中的适用性,这与近年来养殖场景下多步时序预测研究的评价思路基本一致^[16],结果如表2所示。

表2 不同模型在不同预测步长下的预测性能

Tab.2 Prediction performance of different models at different forecasting steps				
模型	步长	R^2	MAE/ ($\text{mg}\cdot\text{L}^{-1}$)	RMSE/ ($\text{mg}\cdot\text{L}^{-1}$)
PSO-SABO-CGA	1	0.934	0.062	0.082
	12	0.912	0.074	0.098
	144	0.876	0.103	0.136
	288	0.842	0.121	0.158
TCN	1	0.812	0.073	0.082
	12	0.768	0.087	0.109
	144	0.741	0.114	0.142
	288	0.702	0.132	0.165
BiLSTM	1	0.798	0.064	0.084
	12	0.771	0.079	0.102
	144	0.728	0.109	0.138
	288	0.689	0.127	0.162
BP	1	0.846	0.069	0.083
	12	0.821	0.083	0.105
	144	0.776	0.112	0.140
	288	0.739	0.130	0.168
GRU	1	0.842	0.067	0.081
	12	0.797	0.078	0.097
	144	0.756	0.106	0.135
	288	0.722	0.123	0.159

如表2所示,PSO-SABO-CGA在所有预测步长下性能指标均显著优于对比模型。其 R^2 较对比模型平均提升约12%~22%,MAE与RMSE分别平均降低约5%~15%、2%~10%。尤其随着预测步长增加,PSO-SABO-CGA的各项指标

较其他对比模型,下降幅度更为平缓,表明其在长期预测中具有更好的稳定性和泛化能力。如图 9 所示,与对比模型相比,PSO - SABO - CGA 模型的预测值更接近实际值。在氨氮浓度突变上升的剧烈波动区,所有模型的预测存在约 1 步的响应滞后,然而,本研究提出的 PSO - SABO - CGA 模型最快收敛至真实轨迹,且未出现振荡放大或误差累积扩散现象。这表明模型对异常波动具有较强的适应能力与鲁棒性。




图 9 单步预测中不同模型的氨氮预测曲线
Fig.9 Ammonia-N prediction curves of different models in one-step prediction

为进一步验证 PSO - SABO - CGA 模型对氨氮浓度预测性能,分析了模型的预测残差分布。如图 10 所示,PSO - SABO - CGA 的残差分布最集中,其中位数显著优于对比模型,表明其预测结果具有最小的系统性偏差。此外,PSO - SABO - CGA 模型的残差主体区间(25% ~ 75%)在 ± 0.002 mg/L 以内,且 10% ~ 90% 分位整体跨度最小,相比之下,TCN、BiLSTM、GRU 及 BP 模型的残差分布范围相对更为分散,这表明 PSO - SABO - CGA 模型具有更高的预测稳定性。




图 10 单步预测中不同模型的残差分布小提琴图
Fig. 10 Violin plot of residual distributions of different models in one-step prediction

上述分析表明,PSO - SABO - CGA 模型在单步

和多步预测任务中均显著优于 TCN、BiLSTM、BP 和 GRU 模型。残差分布分析表明该模型无明显系统偏差,且在峰值和突变区间仍能保持较好的趋势捕捉能力与误差控制能力。PSO - SABO 算法通过引入自适应平衡机制,有效提升了参数搜索过程中的全局探索与局部开发能力;在此基础上,CGA 预测模型依托其训练框架,能够更准确地捕捉数据中的复杂分布与非平稳特征,从而提高对时序动态的建模精度与预测稳定性。

2.3 消融试验

为验证本研究提出的 PSO - SABO - CGA 模型各组件的有效性,设计了 3 组消融试验,分别为无优化的基础 CGA 模型、建模方法中 CGA 的 GRU 替换为 LSTM^[33](CNN - LSTM - Attention, CLA)、无 PSO 的 SABO - CGA 模型。消融试验使用与 PSO - SABO - CGA 模型相同的数据集训练,预测步长分别为 1、12、144、288 步。

如表 3 所示,在所有步长下,CLA 模型的各项指标均明显落后于基础 CGA 模型,表明 GRU 在局部空间特征提取中的关键价值;在引入 SABO 优化器后,平均 MAE 和 RMSE 相较于基础 CGA 分别下降了 3.94% 和 4.43%, R^2 平均提升了 1.97%,各项指标改善有限;所提出的 PSO - SABO - CGA 模型取得了最优性能,其 R^2 平均提升约 11.28%,尤其在 144、288 步长(12、24 h)的长期预测中,PSO - SABO - CGA 模型的 R^2 仍能达到 0.842 以上,这表明 PSO - SABO 优化策略能够有效协同 PSO 的全局搜索能力与 SABO 的自适应平衡机制,从而更高效地规避

表 3 消融试验结果
Tab.3 Ablation test results

模型	步长	R^2	MAE/ ($\text{mg}\cdot\text{L}^{-1}$)	RMSE/ ($\text{mg}\cdot\text{L}^{-1}$)
CGA	1	0.849	0.064	0.087
	12	0.832	0.073	0.099
	144	0.781	0.096	0.132
	288	0.743	0.118	0.158
CLA	1	0.654	0.087	0.121
	12	0.618	0.101	0.143
	144	0.552	0.132	0.181
	288	0.503	0.154	0.209
SABO - CGA	1	0.854	0.063	0.085
	12	0.838	0.072	0.096
	144	0.803	0.091	0.124
	288	0.771	0.109	0.148
PSO - SABO - CGA	1	0.934	0.062	0.082
	12	0.912	0.074	0.098
	144	0.876	0.103	0.136
	288	0.842	0.121	0.158

局部最优,寻得更佳模型参数组合。消融试验结果表明,PSO-SABO-CGA 模型对氨氮浓度预测具有较高精度与强鲁棒性。

3 结 论

(1)为实现养殖水体中氨氮浓度的精准预测,本文针对多环境因素耦合影响、时序依赖性强及模型参数难以优化等问题,构建了一种基于 PSO-SABO 优化的 CGA 预测模型。

(2)PSO-SABO-CGA 模型在氨氮浓度预测中表现优异,其预测结果与实际值变化趋势高度一致。模型在短期预测中 R^2 为 0.934,MAE 和 RMSE 分别为 0.062 mg/L 和 0.082 mg/L,验证了该模型在捕捉氨氮动态变化方面的有效性与准确性。

(3)将 PSO-SABO 优化 CGA 模型与 HO、GA 优化 CGA 模型进行对比,无论是在单步还是多步预测任务中,PSO-SABO 均表现出更优的参数搜索能力与收敛稳定性。该算法通过 PSO 的全局引导机制,有效缓解了 SABO 算法在后期易陷入局部最优、搜索多样性不足的问题,从而显著提升了 CGA 模型的泛化能力与预测可靠性。

(4)与 TCN、BiLSTM、BP 及 GRU 等主流预测模型相比,PSO-SABO-CGA 在各项评价指标上均具有明显优势。尤其在长时间序列预测中,该模型表现出更好的抗误差累积能力与预测稳定性(24 h 的 R^2 为 0.842),结合消融试验,验证了其结构设计及优化策略能有效提升对养殖水体复杂非线性过程的建模精度。

参 考 文 献

[1] 倪蒙,邵长伟,吴珊珊.我国水产养殖种质资源总体状况[J].中国水产,2025(9):8-10.
Ni Meng, Shao Changwei, Wu Shanshan. Overall status of aquaculture germplasm resources in China[J]. China Aquaculture, 2025(9): 8-10. (in Chinese)

[2] 闫振广,孟伟,刘征涛,等.我国淡水生物氨氮基准研究[J].环境科学,2011,32(6):1564-1570.
Yan Zhenguang, Meng Wei, Liu Zhengtao, et al. Development of freshwater aquatic life criteria for ammonia in China[J]. Environmental Science, 2011, 32(6): 1564-1570. (in Chinese)

[3] 时家辉,于亚光,杨普,等.基于微流控和比色光谱法的水产养殖海水氨氮含量检测[J].农业机械学报,2020,51(增刊1):397-404.
Shi Jiahui, Yu Yaguang, Yang Pu, et al. Detection of ammonia nitrogen in seawater in aquaculture based on microfluidics and colorimetric spectroscopy[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(S1): 397-404. (in Chinese)

[4] Yan Z, Zheng X, Fan J, et al. China national water quality criteria for the protection of freshwater life: ammonia[J]. Chemosphere, 2020, 251: 126379.

[5] 张佳然,于杰,赵天驰,等.基于氮掺杂石墨烯量子点的荧光法检测水中的氨氮含量[J].农业工程学报,2025,41(2):242-250.
Zhang Jiaran, Yu Jie, Zhao Tianchi, et al. Detection of ammonia nitrogen in water by fluorescence method based on nitrogen-doped graphene quantum dots[J]. Transactions of the CSAE, 2025, 41(2): 242-250. (in Chinese)

[6] 王魏,郭戈.基于随机配置网络的海水养殖氨氮浓度软测量模型[J].农业机械学报,2020,51(1):214-220.
Wang Wei, Guo Ge. Soft measurement model for ammonia nitrogen concentration in marine aquaculture based on stochastic configuration networks[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(1): 214-220. (in Chinese)

[7] 陈英义,成艳君,杨玲,等.基于改进深度信念网络的池塘养殖水体氨氮预测模型研究[J].农业工程学报,2019,35(7):195-202.
Chen Yingyi, Cheng Yanjun, Yang Ling, et al. Prediction model of ammonia-nitrogen in pond aquaculture water based on improved multi-variable deep belief network[J]. Transactions of the CSAE, 2019, 35(7): 195-202. (in Chinese)

[8] Qiu C, Li Q, Jing J, et al. Transforming prediction into decision: leveraging transformer-long short-term memory networks and automatic control for enhanced water treatment efficiency and sustainability[J]. Sensors, 2025, 25(6): 1652.

[9] 韩旭,段中兴,尚旭东.基于多头注意力机制和 CNN-BiGRU 模型的水质预测方法[C]//2024 中国自动化大会论文集,2024:146-151.
Han Xu, Duan Zhongxing, Shang Xudong. Water quality prediction method based on multi head attention mechanism and CNN-BiGRU model[C]//Proceedings of the 2024 China Automation Conference, 2024: 146-151. (in Chinese)

[10] Zhu J, Dai W, Shao J, et al. An enhanced combined model for water quality prediction utilizing spatiotemporal features and physical-informed constraints[J]. Expert Systems with Applications, 2025, 274: 126937.

[11] 魏泽宇,侯洪飞,邱小琮,等.基于深度学习与 IPSO 算法校正 SWAT 模型的黄河宁夏段氮磷模拟[J].农业工程学报,2025,41(24):142-152.
Wei Zeyu, Hou Hongfei, Qiu Xiaocong, et al. Nitrogen and phosphorus simulation using the SWAT model calibrated by deep learning and IPSO algorithm in the Ningxia Section of the Yellow River, China[J]. Transactions of the CSAE, 2025, 41(24): 142-152. (in Chinese)

[12] Zhang J, Tang C, Wang L, et al. Data mining algorithms for the prediction of inorganic nitrogen in water: mechanisms, techniques, and applications[J]. Information Processing in Agriculture, 2026,13(2):318-342.

[13] Huang G. Missing data filling method based on linear interpolation and light GBM[J]. Journal of Physics: Conference Series,

- 2021, 1754(1): 012187.
- [14] 郝永飞, 王永桂, 张昱, 等. 淮河干流典型污染物时空分布特性分析[J]. 河海大学学报(自然科学版), 2020, 48(4): 315 - 321.
Hao Yongfei, Wang Yonggui, Zhang Yu, et al. Spatial and temporal distribution analysis of typical contaminants in main stream of Huaihe River[J]. Journal of Hohai University (Natural Sciences), 2020, 48(4): 315 - 321. (in Chinese)
- [15] Kim J H, Yi Y B, Choi J H. Toxic effects on bioaccumulation, hematological parameters, oxidative stress, immune responses and neurotoxicity in fish exposed to microplastics: a review[J]. Journal of Hazardous Materials, 2021, 413: 125423.
- [16] 王朕, 陈聪, 曹光乔, 等. 基于 MTL - LSTM - SAT 的养殖鱼类患病及生长预测模型构建与试验[J]. 农业机械学报, 2025, 56(11): 590 - 598, 620.
Wang Zhen, Chen Cong, Cao Guangqiao, et al. Construction and evaluation of prediction model for disease and growth of farmed fish based on MTL - LSTM - SAT[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(11): 590 - 598, 620. (in Chinese)
- [17] Ning M, Li X, Lu Z, et al. Heterotrophic nitrification-aerobic denitrification (HNAD) in marine aquaculture wastewater treatment: nitrogen removal performance, mechanism and microbial community characteristics[J]. Journal of Water Process Engineering, 2025, 70: 107006.
- [18] Meng J, Hu Z T, Wang Z Y, et al. Determining factors for nitrite accumulation in an acidic nitrifying system: influent ammonium concentration, operational pH, and ammonia-oxidizing community[J]. Environmental Science & Technology, 2022, 56(16): 11578 - 11588.
- [19] Jiang Z, Tang S Y, Liao Y H, et al. Effect of low temperature on contributions of ammonia oxidizing archaea and bacteria to nitrous oxide in constructed wetlands[J]. Chemosphere, 2023, 313: 137585.
- [20] Mo S, Yang C, Mo Y, et al. From global to local: a lightweight CNN approach for long-term time series forecasting[J]. Computers & Electrical Engineering, 2025, 123: 110192.
- [21] Zhang Y, Liu L, Zhang S H, et al. Monitoring and warning for ammonia nitrogen pollution of urban river based on neural network algorithms[J]. Analytical Sciences, 2024, 40(10): 1867 - 1879.
- [22] Das T, Guchhait S. A hybrid GRU and LSTM-based deep learning approach for multiclass structural damage identification using dynamic acceleration data[J]. Engineering Failure Analysis, 2025, 170: 109259.
- [23] 苏祎桓, 罗风光, 杨柳, 等. 基于逐比特估计的低复杂度 CNN - BiGRU - Attention 光纤非线性补偿方法[J]. 光学学报, 2026, 46(2): 172 - 180.
Su Yihuan, Luo Fengguang, Yang Liu, et al. Fiber nonlinearity compensation method based on stepwise bit estimation using low complexity CNN - BiGRU - Attention[J]. Acta Optica Sinica, 2026, 46(2): 172 - 180. (in Chinese)
- [24] Guo J, Zhang T, Xue K, et al. Fault diagnosis of rolling bearing based on parameter-adaptive re-constraint VMD optimized by SABO[J]. Measurement Science and Technology, 2025, 36(1): 016174.
- [25] Zhuo H, Li T R, Lu W, et al. Prediction model for spontaneous combustion temperature of coal based on PSO - XGBoost algorithm[J]. Scientific Reports, 2025, 15(1): 2752.
- [26] Ajimakin A D, Devi V S. The competing genes evolutionary algorithm: avoiding genetic drift through competition, local search, and majority voting[J]. IEEE Transactions on Evolutionary Computation, 2023, 27(6): 1678 - 1689.
- [27] 徐龙琴, 赫敏, 陈子昂, 等. 基于 IHO - Mamba - MHSA 的红瓜子斑鱼养殖水温多步预测模型[J]. 农业机械学报, 2025, 56(8): 655 - 664.
Xu Longqin, He Min, Chen Ziang, et al. Multi-step water temperature prediction model for *Cephalopholis sonnerati* based on IHO - Mamba - MHSA[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(8): 655 - 664. (in Chinese)
- [28] Luo Y, Meng X, Zhai Y, et al. Prediction of water quality in agricultural watersheds based on VMD - GA - LSTM model[J]. Mathematics, 2025, 13(12): 195.
- [29] Li Q, Ren X Y, Zhang F, et al. A novel ultra-short-term wind power forecasting method based on TCN and Informer models[J]. Computers & Electrical Engineering, 2024, 120: 109632.
- [30] 石庆兰, 束金阳, 李道亮, 等. 基于 BiLSTM - GRU 融合网络的稻虾养殖溶解氧含量预测[J]. 农业机械学报, 2023, 54(10): 364 - 370.
Shi Qinglan, Shu Jinyang, Li Daoliang, et al. Dissolved oxygen prediction in rice and shrimp culture based on BiLSTM - GRU fusion neural networks[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(10): 364 - 370. (in Chinese)
- [31] 陈英义, 程倩倩, 成艳君, 等. 基于 GA - BP 神经网络的池塘养殖水温短期预测系统[J]. 农业机械学报, 2017, 48(8): 172 - 178.
Chen Yingyi, Cheng Qianqian, Cheng Yanjun, et al. Short-term prediction system of water temperature in pond aquaculture based on GA - BP neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(8): 172 - 178. (in Chinese)
- [32] Gandh D R, Harigovindan V P, Haq K, et al. Attention-driven LSTM and GRU deep learning techniques for precise water quality prediction in smart aquaculture[J]. Aquaculture International, 2024, 32(6): 8455 - 8478.
- [33] Yan X, Yang W, Gao M, et al. The WOA - CNN - LSTM - Attention model for predicting GNSS water vapor[J]. IEEE Transactions on Geoscience and Remote Sensing, 2024, 62: 4105215.