

基于 BOA – BiLSTM 的鱼菜菇共生温室二氧化碳浓度预测模型

张俊红¹ 卓 实¹ 张佳然¹ 于 杰² 王 亮^{3,4} 王 聪^{5,6} 石科举¹

(1. 北京建筑大学智能科学与技术学院, 北京 100044; 2. 北京建筑材料检验研究院股份有限公司, 北京 100041; 3. 中国农业大学国家数字渔业创新中心, 北京 100083; 4. 萨里大学工程与物理科学学院, 吉尔福德 GU2 7XH; 5. 中国农业大学信息与电气工程学院, 北京 100083; 6. 农业农村部智慧养殖技术重点实验室, 北京 100083)

摘要: 二氧化碳(CO₂)浓度是影响鱼菜菇共生系统生态循环与作物产量的关键参数,其精准预测对温室环境的智能调控具有重要意义。针对温室CO₂浓度受多重环境因子非线性耦合影响导致预测精度不足、模型超参数难以实现自主高效寻优的问题,提出一种基于贝叶斯优化算法(Bayesian optimization algorithm, BOA)与双向长短期记忆网络(Bidirectional long short-term memory, BiLSTM)相结合的混合预测模型(BOA – BiLSTM)。该方法首先结合主成分分析(Principal component analysis, PCA)与农业系统动力学机制,筛选出鱼菜区温度、培养基温度、pH值等5个核心驱动因子作为输入特征;随后通过BOA算法的自适应寻优机制,对BiLSTM模型的关键超参数进行全局自动优化,有效克服了陷入局部最优的缺陷。试验结果表明,BOA – BiLSTM模型在CO₂浓度单步预测中表现优异,其决定系数、均方根误差和平均绝对误差分别达到0.982和7.217、5.739 μmol/mol。相较于基线模型,该模型不仅在多步预测中展现出更高的抗衰减稳定性,更在温室CO₂异常突变区间的阈值事件识别中取得显著优势,其F1分数高达0.926,且模型平均推理时间仅为0.726 ms。该方法为鱼菜菇共生温室环境的高效异常预警与精细化管理提供了兼具高精度与高实用性的技术支撑。

关键词: 鱼菜菇共生温室; CO₂浓度预测; 双向长短期记忆网络; 贝叶斯优化

中图分类号: S625.51; TP183 **文献标识码:** A **文章编号:** 1000-1298(2026)21-0390-10

OSID:



Prediction of Carbon Dioxide Concentration in Aquaponic-mushroom Greenhouse Based on BOA – BiLSTM Model

Zhang Junhong¹ Zhuo Shi¹ Zhang Jiaran¹ Yu Jie² Wang Liang^{3,4} Wang Cong^{5,6} Shi Keju¹

(1. School of Intelligence Science and Technology, Beijing University of Civil Engineering and Architecture, Beijing 100044, China
2. Beijing Building Materials Testing Academy Co., Ltd., Beijing 100041, China
3. National Innovation Center for Digital Fishery, China Agricultural University, Beijing 100083, China
4. Faculty of Engineering and Physical Sciences, University of Surrey, Guildford GU2 7XH, UK
5. College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China
6. Key Laboratory of Smart Farming Technologies for Aquatic Animals and Livestock, Ministry of Agriculture and Rural Affairs, Beijing 100083, China)

Abstract: Carbon dioxide (CO₂) concentration is a critical parameter influencing the ecological cycle and crop yield in aquaponic-mushroom symbiotic greenhouses, yet its accurate prediction remains challenging due to the highly nonlinear and strongly coupled multi-environmental factors. To address the low prediction accuracy and difficulty in achieving autonomous and efficient hyperparameter optimization of existing models, a hybrid prediction model (BOA – BiLSTM) was proposed integrating the Bayesian optimization algorithm (BOA) with a bidirectional long short-term memory (BiLSTM) network. Initially, principal component analysis (PCA) combined with agricultural system dynamics was employed to select five core driving factors, involving aquaponic area temperature, substrate temperature, pH value, salinity, and atmospheric pressure as input features, thereby reducing data redundancy and significantly

收稿日期: 2026-03-19 修回日期: 2026-05-20

基金项目: 国家自然科学基金项目(32502350)

作者简介: 张俊红(1975—),女,副教授,主要从事先进感知与智能信息处理研究,E-mail: zhangjunhong@bucea.edu.cn

通信作者: 王亮(1988—),男,高级工程师,博士,主要从事鱼菜共生系统机理建模和调控研究,E-mail: liang.wang@surrey.ac.uk

enhancing model interpretability. The BOA was then utilized to automatically optimize the critical hyperparameters of the BiLSTM model. Comparative experiments on optimization algorithms revealed that, compared with genetic algorithm (GA), particle swarm optimization (PSO), and hippopotamus optimization (HO), the BOA-optimized model achieved maximum reductions of 27.67% and 24.17% in mean absolute error (MAE) and root mean square error (RMSE), respectively, alongside a maximum of 152.63% improvement in the coefficient of determination (R^2). Furthermore, the BOA - BiLSTM model was comprehensively evaluated across multiple prediction horizons (2 min, 10 min, 30 min, and 1 h) against baseline models, including temporal convolutional network - Transformer (TCN - Transformer), bidirectional long short-term memory - gated recurrent unit (BiLSTM - GRU), convolutional neural network - recurrent neural network (CNN - RNN), and mind evolutionary algorithm - back propagation neural network (MEA - BP). In 2-min single-step prediction, the proposed model demonstrated superior performance with an R^2 , RMSE, and MAE of 0.982, 7.217 $\mu\text{mol/mol}$, and 5.739 $\mu\text{mol/mol}$, respectively, while exhibiting remarkable anti-decay stability in multi-step forecasting tasks. Ablation studies among LSTM, BiLSTM, BOA - LSTM, and BOA - BiLSTM architectures further confirmed that the integration of the bidirectional structure and BOA global optimization significantly mitigated local optima traps and maximized feature extraction synergy. Practically, the model secured a substantial advantage in identifying threshold exceedance events during abnormal CO_2 mutations with an F1 score of 0.926, maintaining a low average inference time of 0.726 ms. Finally, the dominant factors driving CO_2 changes were revealed to be pH value and aquaponic temperature through the integral gradient method, in order to improve the interpretability of the model. This approach can provide a highly accurate, robust, and deployable technical foundation for intelligent environmental regulation and precision management in symbiotic greenhouse facilities.

Key words: aquaponics-mushroom greenhouse; CO_2 concentration prediction; bidirectional long short-term memory network; Bayesian optimization

0 引言

2024 年全球温室总面积达到 $1.862 \times 10^6 \text{ hm}^2$, 提供的农作物产量占比居民饮食的 10%^[1], 对于保障粮食安全至关重要。二氧化碳(CO_2)作为植物光合作用的主要底物, 是温室环境调控的关键参数之一。 CO_2 浓度水平直接影响作物光合效率与最终产量, 科学调控 CO_2 浓度能够协同减少其他资源如水、肥料等的过度消耗^[2-3]。因此, 建立有效的 CO_2 浓度预测方法, 对于提高温室产量、减少环境资源浪费、推动农业低碳可持续发展具有重要意义。

作为一种新兴的生态农业模式, 鱼菜菇共生温室将水产养殖、蔬菜及食用菌栽培结合, 形成了由水生生物、植物、微生物以及多项环境因子共同参与的复合生态系统^[4]。在该系统中, CO_2 浓度的变化受到多重过程的交互影响, 如光照、植物光合作用与菌类呼吸等^[5-6], 呈现出强非线性、时变和强耦合的特征。因此, 传统的预测方法难以准确捕捉 CO_2 浓度的动态演变规律, 其精准预测亟待突破。

数据挖掘算法如神经网络、机器学习、深度学习等已被广泛用于温室内的 CO_2 浓度预测。Ning 等^[7]提出基于时序分析的自回归积分移动平均模型 (Autoregressive integrated moving average model, ARIMA) 预测 CO_2 浓度, 通过建立的 ARIMA(p, d, q)

模型成功预测了中国 4 个省级行政区未来 3 年的 CO_2 排放趋势, 其中广东省 CO_2 排放预测的决定系数 (R^2) 达到了 0.985 5。双向长短期记忆网络 (Bidirectional long short-term memory, BiLSTM) 凭借其双向时序建模与门控机制优势, 为解决 CO_2 浓度预测受复杂环境因素影响提供了有效方法。谢伟明等^[8]提出外部注意力机制 (External attention, EA)、BiLSTM 和沙猫群优化算法 (Sand cat swarm optimization, SCSO) 混合模型 (EA - BiLSTM - SCSO), 通过 SCSO 优化 EA 与 BiLSTM 的融合架构, 选取历史蒸腾量、太阳辐射等 5 类核心特征, 实现对参考作物蒸腾量多步逐小时尺度预测, 其 R^2 达 0.722, 较 CNN 模型提升 12.6%。Lu 等^[9]构建了卷积神经网络 (Convolutional neural network, CNN)、BiLSTM 和注意力机制 (Attention) 混合模型 (CNN - BiLSTM - Attention), 在 3 种不同的数据集上, 该模型的 macro-F1 分数分别达到 77.68%、73.37% 和 83.57%。上述研究表明了 BiLSTM 在动态参数预测中的精度优势, 然而仍存在超参数组合依赖人工调试、模型结构复杂导致的高计算成本等局限性, 且针对鱼菜菇共生这一新兴生态农业模式的 CO_2 浓度预测研究尚未见报道。

本文提出一种基于贝叶斯优化算法 (Bayesian optimization algorithm, BOA) 改进的 BiLSTM 预测模

型(BOA-BiLSTM),用于鱼菜菇共生温室的CO₂浓度预测。以鱼菜区温度、培养基温度、pH值、盐度和大气压强作为输入,通过BOA自动寻优BiLSTM的关键超参数,降低模型对人工经验的依赖,在保证精度的同时控制计算成本。并通过从多步长预测精度、峰值区误差、阈值事件识别能力等方面验证BOA-BiLSTM模型的性能;最后通过积分梯度法揭示驱动CO₂浓度变化的主导因素,以提升模型的可解释性,为鱼菜菇共生系统的环境精准调控与低碳高效生产提供技术支撑。

1 材料和方法

1.1 数据采集

本研究以山东省寿光市寒桥镇中国农业大学寿光蔬菜研究院生产基地为试验现场进行试验。温室面积1 000 m²,其中温室内建设鱼菜区域375 m²,其

中养殖水体容量90 m³,该区域种植生菜、养殖鲤鱼;蘑菇种植房63 m²,蘑菇基质放置区30 m²,该区域种植平菇。温室内环境有顺畅的通风交换风机和通道,保证温室内各区域空气质量交换均匀。

本试验传感器采集点布设如图1所示。具体采集参数以及传感器性能如表1所示。数据采集间隔为2 min,数据采样周期为23 d,有效样本数据共计15 717组。样本集按照比例7:3划分为训练集与测试集。




图1 传感器布设示意图
Fig. 1 Layout of sensors

表1 传感器性能参数
Tab. 1 Parameters and sensors performance

传感器类型	放置位置	测量范围	测量精度	电气参数
温度传感器	鱼菜区、蘑菇房、培养基、养殖池	-40 ~ 120℃	±0.5℃	DC 24 V
相对湿度传感器	鱼菜区、蘑菇房、培养基	0 ~ 100%	±3%	DC 24 V
环境CO ₂ 浓度传感器	鱼菜区	0 ~ 5 000 μmol/mol	±40 μmol/mol	DC 12 ~ 30 V
大气压强传感器	鱼菜区	300 ~ 1 100 kPa	±0.5 kPa	DC 12 ~ 30 V
光照强度传感器	鱼菜区	0 ~ 200 000 lx	±5%	DC 24 V
溶解氧质量浓度传感器	养殖池	0 ~ 20 mg/L	≤0.1 mg/L	DC 1.8 ~ 5 V
盐度传感器	养殖池	0 ~ 50 g/kg	±0.1 g/kg	DC 24 V
pH值传感器	养殖池	0 ~ 14	±0.05	DC 24 V

1.2 数据处理

鱼菜菇共生温室是一个半封闭的生态循环系统,其环境参数通常在一定范围内波动,其中不乏有部分数值因传感器测量故障或其他不可控因素使得原始样本数据出现明显异常或缺失,对此本文采用正态分布3σ原则确定异常值,再通过均值替代法对异常数据进行处理^[10],以提高模型的训练效果,处理后样本数据如图2所示。

由图2c可知,CO₂浓度在夜间至凌晨期间处于高峰区间,普遍在500 μmol/mol以上;而白天CO₂浓度逐渐降低,在12:00附近降至最低,普遍在400 μmol/mol左右波动,温室内CO₂浓度24 h内呈现夜间高、白天低的周期性波动规律。

为了消除多维环境特征相互之间的维度影响,采用归一化函数对多维数据进行归一化处理,即^[11]

$$X_{\text{norm}} = \frac{X_i - X_{\text{min}}}{X_{\text{max}} - X_{\text{min}}} \tag{1}$$

式中 X_i 、 X_{norm} ——实测值与归一化处理值
 X_{min} 、 X_{max} ——实测参数的最小值与最大值

1.3 关键影响变量筛选

鱼菜菇共生温室作为复合生态农业系统,通过鱼类养殖、蔬菜水培与食用菌栽培的协同运作实现物质循环,温室内CO₂浓度受到系统多环境因子的综合调控,所涉及的环境变量多、相互作用复杂。本研究基于主成分分析(Principal component analysis, PCA)^[12],结合农业系统动力学机制,筛选关键因子,旨在兼顾模型精简性与可解释性。

对采集的12个环境变量进行PCA降维。如图3a所示,PC1、PC2、PC3、PC4的累计解释率约为87.10%,能够充分代表原始数据信息。关键因子对应的载荷矩阵如图3b所示(注:DO、Sal和WT分别为养殖池溶解氧质量浓度、盐度和水温;RTa和Ha为鱼菜区温度和相对湿度,E为鱼菜区光照强度;Pm为大气压强;RTm和Hm为蘑菇房温度和相对湿度;ST和SH为培养基温度和相对湿度),其中PC1主要代表温室内环境特征,包括鱼菜区温湿度、蘑菇房温湿度以及鱼菜区光照强度,是影响CO₂浓度的主要环境因子;PC2主要反映基质与养殖池的




图 2 处理后鱼菜菇温室数据
Fig. 2 Processed data of aquaponic-mushroom greenhouse




图 3 PCA 关键因子筛选
Fig. 3 Identifying key factors via PCA

物理状态 (培养基温度、pH 值), PC3 和 PC4 的核心载荷分别为盐度和大气压强。

通过变量间关联研究发现 (图 3c), 鱼菜区温湿度、蘑菇房温湿度、鱼菜区光照强度均高度相关 (相关系数大于 0.9)。为消除共线性导致的模型振荡, 且考虑到温度是决定系统内植物与微生物呼吸代谢速率的根本热力学驱动力^[13], 本研究剔除相对湿度变量及重叠的蘑菇房环境数据, 保留鱼菜区温度作为空气热力学核心输入。培养基温度通过影响蘑菇呼吸速率影响 CO₂ 浓度^[14]; pH 值反映水体碳酸平衡, 在中长期预测尺度下, 水体碳汇缓冲效应凸显^[15], 因此保留 pH 值。盐度通过影响水体离子强度、CO₂ 溶解度及碳酸盐平衡^[16], 进而调节养殖水体向棚内空气的释碳过程; 大气压强则通过表征外界风压场与棚体自然通风强度^[17], 影响棚内 CO₂ 的滞留与排散, 因此二者均可能成为温室 CO₂ 变化的重要耦合因子。

综合主成分贡献率、相关矩阵以及系统动力学

分析, 最终筛选出 5 个关键影响因子: 鱼菜区温度、培养基温度、pH 值、盐度和大气压强, 作为后续预测模型的输入向量。

1.4 BOA - BiLSTM 混合模型建立

LSTM 通过在循环神经网络中引入记忆单元和门控机制, 有效缓解了传统循环神经网络 (Recurrent neural network, RNN) 在长序列建模中易出现的梯度消失和长期依赖难以保持的问题。对于时刻 t , 标准 LSTM 单元可表示为

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \tag{2}$$

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \tag{3}$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \tag{4}$$

$$\tilde{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \tag{5}$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \tag{6}$$

$$h_t = o_t \odot \tanh(c_t) \tag{7}$$

式中 i_t 、 f_t 、 o_t ——输入门、遗忘门和输出门
 x_t ——当前时刻输入

h_{t-1} ——上一时刻隐藏状态
 $W_i、U_i$ ——输入门权重矩阵
 b_i ——输入门偏置项
 $W_f、U_f$ ——遗忘门权重矩阵
 b_f ——遗忘门偏置项
 $W_o、U_o$ ——输出门权重矩阵
 b_o ——输出门偏置项
 $W_c、U_c$ ——候选记忆状态权重矩阵
 b_c ——候选记忆状态偏置项
 $\sigma(\cdot)$ ——Sigmoid 激活函数
 $\tilde{c}_t$ ——候选记忆状态
 c_t ——当前时刻单元状态
 c_{t-1} ——上一时刻单元状态
 $\odot$ ——逐元素乘法
 h_t ——当前时刻隐藏状态

在此基础上,BiLSTM 通过引入两个彼此独立的 LSTM 子网络,分别从时间正向和反向对输入序列进行编码,使模型在时刻 t 不仅能够利用过去信息,还能够综合未来上下文信息^[18]。若正向隐状态和反向隐状态分别记为 $\vec{h}_t$ 与 $\overleftarrow{h}_t$,则 BiLSTM 的特征融合过程可写为

$$\vec{h}_t = \text{LSTM}_f(x_t, \vec{h}_{t-1}) \tag{8}$$

$$\overleftarrow{h}_t = \text{LSTM}_b(x_t, \overleftarrow{h}_{t+1}) \tag{9}$$

$$h_t = [\vec{h}_t; \overleftarrow{h}_t] \tag{10}$$

$$\hat{y}_t = W_y h_t + b_y \tag{11}$$

式中 $\hat{y}_t$ ——模型在时刻 t 的预测值
 W_y ——输出层权重 b_y ——输出层偏置

BiLSTM 能够同时提取序列的前向依赖和后向依赖,因此更适用于多因素耦合、动态变化明显且存在时滞效应的环境变量预测任务^[19],尤其适用于鱼菜菇共生温室 CO₂ 浓度预测场景。

BiLSTM 模型性能高度依赖超参数配置,但传统调参方式效率低且易陷入局部最优,难以适配温室复杂环境的预测需求。为此,本文引入 BOA 对 BiLSTM 模型的超参数进行智能寻优,以提升模型在温室 CO₂ 浓度预测任务中的综合性能。与传统网格搜索和随机搜索相比,BOA 根据历史搜索结果动态调整采样方向,从而显著提高超参数寻优效率^[20]。

设待优化的超参数向量 $\lambda \in \Lambda$,以验证集误差作为目标函数,则优化目标可表示为^[21]

$$\lambda^* = \operatorname{argmin} J(\lambda) \quad (\lambda \in \Lambda) \tag{12}$$

$$J(\lambda) \sim GP(m(\lambda), k(\lambda, \lambda')) \tag{13}$$

$$D_t = \{(\lambda_i, J_i)\}_{i=1}^t \tag{14}$$

$$\mu_t(\lambda) = k_t(\lambda)^T (K_t + \sigma_n^2 I)^{-1} J_t \tag{15}$$

$$\sigma_n^2(\lambda) = k(\lambda, \lambda) - k_t(\lambda)^T (K_t + \sigma_n^2 I)^{-1} k_t(\lambda) \tag{16}$$

式中 $J(\lambda)$ ——当超参数取为 λ 时,模型在验证集上的误差

λ^* ——最优超参数向量

$m(\lambda)$ ——均值函数

$k(\lambda, \lambda')$ ——协方差函数

$k(\lambda, \lambda)$ ——输入点 λ 先验方差

GP ——高斯过程

D_t ——前 t 次迭代得到的数据

J_i ——第 i 组超参数对应的目标函数值

$\mu_t(\lambda)$ ——当前候选参数点的预测均值

K_t ——已有样本点之间的协方差矩阵

$k_t(\lambda)$ ——候选点与已有样本点之间的协方差向量

σ_n^2 ——噪声方差

I ——单位矩阵

J_t ——已有样本的目标函数值向量

进一步地,为兼顾搜索的探索性与开发性,采用期望改进函数作为采集函数,其表达式为

$$EI_t(\lambda) = (J_{\min} - \mu_t(\lambda) - \xi) \Phi(Z) + \sigma_t(\lambda) \varphi(Z) \tag{17}$$

$$Z = \frac{J_{\min} - \mu_t(\lambda) - \xi}{\sigma_t(\lambda)} \tag{18}$$

$$\lambda_{t+1} = \operatorname{argmax} EI_t(\lambda) \tag{19}$$

式中 $EI_t(\lambda)$ ——期望改进值
 $\sigma_t(\lambda)$ ——当前候选参考点的预测标准差
 $J_{\min}$ ——当前已经观察到的最小误差
 $\Phi(\cdot)$ ——标准正态分布的累积分布函数
 $\varphi(\cdot)$ ——标准正态分布的概率密度函数
 ξ ——平衡探索与利用的调节参数

本研究提出的 BOA - BiLSTM 预测模型构建过程如图 4 所示。模型训练采用 Adam 优化器,并通过均方误差 (Mean squared error, MSE) 作为损失函数,通过迭代优化权重,最小化损失函数,逐步提升模型的预测性能。BOA - BiLSTM 混合模型基础配置包括输入层、BiLSTM 层、Dropout 层、全连接层和输出层,每层描述如下:

(1)输入层:模型输入为多维时序序列特征变量,输入转化为适宜 BiLSTM 计算的 3 维阵列 (None, T , m),即批量大小 None、窗口大小 T 、特征数量 m 。

(2)BiLSTM 层:基于最优超参数设置隐藏层数量和神经元个数,每层双向 LSTM 由前向 LSTM 和后向 LSTM 组成,两者独立处理同一时序序列,采用多层堆叠逻辑,输出序列的最后一个时间步的隐藏




图 4 BOA - BiLSTM 混合模型构建流程图

Fig. 4 Flowchart of BOA - BiLSTM model establishment

状态。

(3) Dropout 层: 基于最优 Dropout 率, 抑制过拟合。

(4) 全连接层: 进行局部信息采集和维度转换, 将 BiLSTM 的输出映射到预测值空间。

(5) 输出层: 实现预测结果的输出。

1.5 性能评价指标

为评估 BOA - BiLSTM 混合模型的预测性能, 以平均绝对误差 (Mean absolute error, MAE)、均方根误差 (Root mean square error, RMSE) 以及 R^2 为性能评价指标。此外, 本文进一步引入参数规模、模型体积、平均推理时间、峰值区 MAE 和峰值区 RMSE、阈值事件识别指标以及趋势方向准确率等指标, 以构建面向实际应用的综合评价框架^[22]。

2 结果与讨论

2.1 模型参数设置

为获得 BOA - BiLSTM 模型的最佳预测性能,

采用 BOA 对模型关键超参数进行寻优, BOA - BiLSTM 的超参数搜索范围和优化结果如表 2 所示。优化过程中以验证集损失为目标函数, 并采用 Smooth L1 损失函数进行训练, 以减弱异常误差对参数更新的干扰。BOA 搜索阶段训练轮数为 20, 最终模型训练轮数为 100。构建的 BOA - BiLSTM 模型采用 3 层 BiLSTM 结构, 输出端采用 Linear - ReLU - Dropout - Linear 全连接层完成未来时刻室内 CO₂ 浓度预测。

表 2 BOA - BiLSTM 模型的超参数搜索范围和结果

Tab. 2 Optimized hyperparameter search range and results for BOA - BiLSTM model

超参数	搜索范围	最优值
时间窗口长度	{ 12, 24, 36, 48, 60 }	12
BiLSTM 隐藏单元数	[64, 256]	224
BiLSTM 层数	[1, 3]	3
失活率	[0. 05, 0. 35]	0. 090 621
学习率	[1×10^{-4} , 3×10^{-3}]	0. 000 109
权重衰减系数	[1×10^{-8} , 1×10^{-4}]	$1. 391\ 017 \times 10^{-8}$
批量大小	{ 32, 64, 128 }	128

2.2 智能优化算法对比

为验证 BOA 的优化性能, 将 BOA、遗传算法^[23] (Genetic algorithm, GA)、河马优化算法^[24] (Hippopotamus optimization, HO)、粒子群优化^[25] (Particle swarm optimization, PSO) 分别与 BiLSTM 预测模型相结合进行对比试验, 以观察优化算法对预测性能的影响, 各对比优化算法搜索到的超参数如表 3 所示。4 种优化算法优化后的 BiLSTM 模型预测性能评价指标如图 5 所示。

4 种优化算法下的模型预测性能均随着步长的增加而下降。BOA - BiLSTM 模型的各项指标优于另外 3 种模型。具体而言, 与 GA - BiLSTM 相比, BOA - BiLSTM 模型的 MAE、RMSE 最多下降

表 3 不同优化算法搜索到的超参数设置

Tab. 3 Hyperparameter settings obtained by different optimization algorithms

优化算法	时间窗口长度	BiLSTM 隐藏单元数	BiLSTM 层数	失活率	学习率	权重衰减系数	批量大小
GA	12	111	2	0. 120 780	0. 002 680	$5. 629\ 632 \times 10^{-8}$	32
PSO	24	256	1	0. 083 732	0. 003 000	$1. 725\ 727 \times 10^{-5}$	32
HO	48	239	3	0. 094 830	0. 000 403	$5. 770\ 905 \times 10^{-6}$	64

26. 40%、19. 81%, R^2 最多提升 152. 63%; 与 PSO - BiLSTM 相比, MAE、RMSE 最多分别下降 27. 67%、24. 17%, R^2 最多提升 84. 62%; 与 HO - BiLSTM 相比, 其 MAE、RMSE 最多降低 24. 79%、17. 25%, R^2 最多提升 100%。这说明本研究提出的 BOA 能够很好地优化预测模型参数组合, 从而更好地模拟

CO₂ 浓度的变化趋势。

单步预测时 BOA - BiLSTM 模型的预测值更接近实际值, 其次分别为 GA - BiLSTM、PSO - BiLSTM、HO - BiLSTM (图 6)。这归因于 BOA 基于高斯过程构建代理模型, 能高效捕捉超参数与模型性能之间的非线性关系, 避免了传统网格搜索、随机




图5 不同步长下4种优化算法优化的BiLSTM模型评价指标

Fig. 5 Evaluation metrics of BiLSTM models optimized by four algorithms with different steps




图6 单步预测中不同优化算法CO₂浓度预测曲线
(7月22日)

Fig. 6 CO₂ concentration prediction curves of different optimization algorithms in single-step prediction (22st July)

搜索的盲目性。与 PSO - BiLSTM、GA - BiLSTM、HO - BiLSTM 相比,BOA - BiLSTM 在时序预测任务中更精准地挖掘数据关联性,有效降低了预测误差,尤其在多步长预测场景下表现更优。

2.3 模型预测结果对比分析

为验证所提出的 BOA - BiLSTM 预测模型在鱼菜菇温室 CO₂ 浓度预测中的性能,本研究将其与近 5 年文献中报道的多种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 BiLSTM - 门控循环单元^[26] (Gated recurrent unit, GRU) (BiLSTM - GRU)、思维进化算法-误差反向传播神经网络^[27] (Mind evolutionary algorithm - back propagation neural network, MEA - BP)、CNN - RNN^[28]、时序卷积网络-Transformer^[29] (Temporal convolutional network - Transformer, TCN - Transformer),各模型结构参数将按照其原始文献中的描述进行配置,结果如图 7 所示。

BOA - BiLSTM 在各个预测步长下相比其他模型表现出一定优势。当预测步长为 1 时,模型的 MAE 和 RMSE 分别为 5.739、7.217 μmol/mol, R² 达 0.982,较基线模型 MAE 和 RMSE 最多分别降低 73.47% 与 72.62%, R² 最多提升 29.97%;随着预测步长的增加,各模型性能均有所下降,然而 BOA - BiLSTM 仍保持相对优势,尤其在步长为 15 时,BOA -




图7 不同预测时长5种模型预测性能对比

Fig. 7 Comparison of predictive performance of five models under different prediction horizons

BiLSTM 的 R^2 仍保持在 0.819。相较于其他对比模型, BOA - BiLSTM 的各项指标随步长增加下降幅度更为平缓, 表明其具有更好的稳定性和泛化能力。

与基线模型相比(图 8), 本研究所提出的 BOA - BiLSTM 模型的预测值与真实 CO_2 浓度变化曲线更加贴合, 预测结果更接近于真实值, 且没有出现极端偏差。BiLSTM 的双向结构提供了更全面的时序特




图 8 单步预测中不同模型的 CO_2 浓度预测曲线
(7 月 21 日)

Fig. 8 CO_2 concentration prediction curves of different models in single-step prediction(21st July)

表 4 不同模型单步预测下的实用性指标比较结果

Tab. 4 Comparison results of practical metrics of different models under one-step prediction

模型	峰值区平均 MAE/ ($\mu\text{mol}\cdot\text{mol}^{-1}$)	峰值区平均 RMSE/ ($\mu\text{mol}\cdot\text{mol}^{-1}$)	阈值事件 精确率	阈值事件 召回率	阈值事件 F1 分数	趋势方向 准确率	参数量	平均推理 时间/ms
BOA - BiLSTM	8.732	11.044	0.940	0.948	0.926	0.505	1.269×10^6	0.726
MEA - BP	31.063	33.007	1.000	0.604	0.753	0.361	1.49×10^2	0.045
BiLSTM - GRU	11.488	14.394	0.918	0.922	0.920	0.506	7.8×10^4	0.455
CNN - RNN	39.072	42.682	1.000	0.535	0.697	0.494	2.79×10^5	0.681
TCN - Transformer	43.828	49.275	0.966	0.374	0.539	0.493	1.25×10^5	1.719

BOA - BiLSTM 在峰值区误差方面优势突出, 其峰值区平均 MAE 和峰值区平均 RMSE 远低于基线模型, 比次优的 BiLSTM - GRU 分别降低约 24.0% 和 23.3%, 表明其对高浓度突变区间的捕捉能力最强; 阈值事件识别能力方面, BOA - BiLSTM 的 F1 分数最高(0.926), 且得益于 BOA 在损失函数中对罕见事件的隐式加权, 其召回率达 0.948, 说明其对超标事件的漏报风险最低; 趋势方向准确率各模型整体差异不大, 但 BOA - BiLSTM 仍处于中上水平。在部署成本方面, BOA - BiLSTM 的参数量和平均推理时间均相对较大, 但 BOA - BiLSTM 的平均推理时间仅为 0.726 ms, 仍远低于实际温室环境监测系统的采样周期, 能够满足在线预测与实时预警需求, 其部署成本在可接受范围内。综合来看, BOA -

征提取能力, BOA 算法确保了模型始终运行在最优配置下, 从而在长步长预测中有效抑制了误差膨胀, 展现出优于基线模型的稳定性和准确性。

在本研究的鱼菜菇共生温室中, CO_2 浓度调节主要通过化学反应式发生装置与通风设备完成。自然条件下大气 CO_2 浓度约为 $420\ \mu\text{mol}/\text{mol}$, 生菜适宜生长的 CO_2 浓度为 $400\sim600\ \mu\text{mol}/\text{mol}$ ^[30]; 平菇出菇阶段 CO_2 浓度则应控制在 $600\ \mu\text{mol}/\text{mol}$ 以下, 以避免菌柄伸长和菌盖发育受抑^[31]。因此, 本研究 CO_2 浓度调节范围以 $400\ \mu\text{mol}/\text{mol}$ 为下限、 $600\ \mu\text{mol}/\text{mol}$ 为上限。当模型预测 CO_2 浓度将低于下限阈值时, 启动 CO_2 发生装置进行补碳; 当预测结果显示 CO_2 浓度将升高接近或超过上限阈值时, 开启通风换气设备排碳。基于 BOA - BiLSTM 模型的预测结果实现对温室 CO_2 浓度的前瞻调控, 为鱼菜菇共生系统的环境优化与 CO_2 浓度精细化管理提供了有效支撑。

为进一步验证模型在实际温室调控场景中的 CO_2 浓度预测应用潜力, 进一步从峰值区误差、阈值事件识别能力、趋势方向识别能力等角度, 对 BOA - BiLSTM、TCN - Transformer、MEA - BP、CNN - RNN 和 BiLSTM - GRU 进行单步预测下的实用性比较, 各项指标如表 4 所示。

BiLSTM 以适度增加的模型复杂度换取了更优的关键区间预测性能和更强的高风险事件识别能力, 在鱼菜菇共生温室系统 CO_2 浓度异常预警中具有最高的实用价值。

2.4 消融试验及结果分析

为验证本文提出的 BOA - BiLSTM 混合预测模型的有效性, 设计了 3 项消融试验, 分别为 LSTM^[32]、BiLSTM 以及 BOA - LSTM。消融试验使用同样的训练集和测试集, 预测步长为 5 步(10 min)。

如表 5 所示, BiLSTM 模型的各项指标均略低于 LSTM, 这归因于引入的双向传播机制。引入 BOA 对 LSTM 进行超参数寻优后, BOA - LSTM 的 MAE 和 RMSE 分别降低 10.45% 和 7.05%, R^2 提升

1.47%,证实了 BOA 模块在自动搜索最优超参数、提升模型泛化能力方面的作用。进一步,BOA - BiLSTM 模型相比 BiLSTM 模型,其 MAE 和 RMSE 分别降低 24.28% 和 38.35%, R^2 提升 8.28%,表明在 BOA 的优化下,双向结构能够更充分地提取时序特征,协同效应显著。消融试验结果表明,BOA - BiLSTM 模型对 CO_2 浓度预测具有较高精度与强鲁棒性。

表 5 消融试验结果对比
Tab.5 Comparison of ablation study results

模型	MAE/ ($\mu\text{mol}\cdot\text{mol}^{-1}$)	RMSE/ ($\mu\text{mol}\cdot\text{mol}^{-1}$)	R^2
LSTM	12.435	16.840	0.902
BiLSTM	13.597	18.456	0.882
BOA - LSTM	11.136	15.653	0.915
BOA - BiLSTM	10.295	11.379	0.955

2.5 基于积分梯度的模型可解释性分析

为探究鱼菜菇共生温室中各环境因子对 CO_2 浓度预测的驱动机制,本研究通过积分梯度法对最优预测模型进行特征归因分析,结果如图 9 所示。




图 9 关键因子全局重要性及局部贡献度对比
Fig.9 Comparison of global feature importance and local contribution of core environmental factors

由全局特征重要性可知,模型在预测 CO_2 浓度动态演变时,高度依赖 pH 值、鱼菜区温度和大气压强这 3 个核心因子。其中,pH 值的全局特征贡献均值最高,这与鱼菜共生系统水体底层的碳酸盐缓冲体系密切相关,pH 值的波动会直接打破化学平衡,引发水体与空气间 CO_2 交换;同时,鱼菜区温度作

为热力学驱动力,影响系统内动植物的呼吸代谢与微生物的降解速率。在 CO_2 浓度突变时刻,pH 值、鱼菜区温度和大气压强依然构成了最强的正向推力,而盐度和培养基温度的贡献度相对较小。
上述基于数据驱动的归因分析结果与农业系统动力学规律相吻合,证明本研究所提出的模型能够反映温室环境的物理与生化耦合机制,具备较强的工程可解释性与可信度。

3 结论

(1)针对鱼菜菇共生温室二氧化碳浓度受多环境因子耦合影响、时序依赖性强及模型超参数难以自主高效寻优等问题,本研究提出了一种 BOA - BiLSTM 的混合预测模型。

(2)BOA - BiLSTM 模型在鱼菜菇共生温室内的 CO_2 浓度预测中表现优异,其预测结果与实际变化趋势高度一致,模型的 R^2 达 0.982,MAE 和 RMSE 分别为 $5.739\ \mu\text{mol}/\text{mol}$ 与 $7.217\ \mu\text{mol}/\text{mol}$,验证了该模型在捕捉 CO_2 浓度动态变化方面的有效性与准确性。

(3)对比 BOA 优化 BiLSTM 模型与 GA、PSO、HO 优化 BiLSTM 模型的性能,在不同预测步长任务中,BOA 表现出更优的参数搜索能力;消融试验进一步验证在同时引入 BOA 与双向结构后,模型预测性能显著提升,这表明 BOA 有效规避了传统算法易陷入局部最优、收敛效率低的问题,与 BiLSTM 双向时序结构存在显著协同效应。

(4)与 MEA - BP、CNN - RNN、BiLSTM - GRU 和 TCN - Transformer 等主流预测模型相比,BOA - BiLSTM 模型在各项评价指标上均具有突出优势。其 F1 分数达 0.926,在高浓度风险样本识别和关键变化过程捕捉方面表现出更强优势。实用性指标分析表明,BOA - BiLSTM 在模型预测精度与实时部署可行性之间实现了较好的平衡,在鱼菜菇共生温室系统 CO_2 浓度异常预警中体现出较高的实用价值。此外,通过积分梯度法揭示了 pH 值和温度是驱动 CO_2 浓度变化的主导因素,提升了黑盒模型的可解释性。

参 考 文 献

[1] 中国报告大厅. 2023—2028 年中国温室大棚产业运行态势及投资规划深度研究报告[R]. 北京:中国报告大厅, 2023.
[2] 周钰凡, 蒯金山, 姚东东, 等. 不同 CO_2 施肥方式对设施葡萄光合作用与产量的影响[J]. 农业机械学报, 2025, 56(7): 627 - 638.
Zhou Yufan, Xi Jinshan, Yao Dongdong, et al. Effects of different CO_2 fertilization methods on photosynthesis and yield of greenhouse grapes[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(7): 627 - 638. (in Chinese)
[3] Nonaka A, Hamada T. Practical utility assessment of a remote system for monitoring CO_2 in greenhouses by using a farmer-built IoT system, and usefulness of the system together with a state-space model in detecting anomalous values[J]. Agricultural

- Information Research, 2023, 31(4): 95 - 106.
- [4] Zamnuri M A H, Qiu S, Rizalmy M A A, et al. Integration of IoT in small-scale aquaponics to enhance efficiency and profitability: a systematic review[J]. Animals, 2024, 14(17): 2555.
- [5] Chandramenon P, Aggoun A, Tchuenbou-Magaia F. Smart approaches to Aquaponics 4. 0 with focus on water quality: comprehensive review[J]. Computers and Electronics in Agriculture, 2024, 225: 109256.
- [6] Wang Z, Liu Z, Yuan M, et al. A machine learning-based irrigation prediction model for cherry tomatoes in greenhouses: leveraging optimal growth data for precision irrigation[J]. Computers and Electronics in Agriculture, 2025, 237: 110558.
- [7] Ning L, Pei L, Li F. Forecast of China's carbon emissions based on ARIMA method[J]. Discrete Dynamics in Nature and Society, 2021, 2021(1): 1441942.
- [8] 谢伟明, 张钟莉莉, 陶建平, 等. 基于 EA - BiLSTM - SCSO 的多步逐小时参考作物蒸腾量预测方法[J]. 节水灌溉, 2025(3): 57 - 63, 70.
- Xie Weiming, Zhang Zhonglili, Tao Jianping, et al. Multi-step hourly reference crop transpiration prediction method based on EA - BiLSTM - SCSO[J]. Water Saving Irrigation, 2025 (3): 57 - 63, 70. (in Chinese)
- [9] Lu G, Liu Y, Wang J, et al. CNN - BiLSTM - Attention: a multi-label neural classifier for short texts with a small set of labels[J]. Information Processing & Management, 2023, 60(3): 103320.
- [10] Rehman S A, Shabbir J, Al-Essa L A. On the development of survey methods for novel mean imputation and its application to abalone data[J]. Heliyon, 2024, 10(11): e31423.
- [11] Chen L, Yang X, Sun C, et al. Feed intake prediction model for group fish using the MEA - BP neural network in intensive aquaculture[J]. Information Processing in Agriculture, 2020, 7(2): 261 - 271.
- [12] 林枫, 丁红蕾, 魏超杰, 等. 基于主成分分析-神经网络的燃煤电厂二氧化碳排放预测[J]. 中国电机工程学报, 2026, 46(1): 305 - 314.
- Lin Feng, Ding Honglei, Wei Chaojie, et al. CO₂ emission prediction of coal-fired power plants with principal component analysis and neural network[J]. Proceedings of the CSEE, 2026, 46(1): 305 - 314. (in Chinese)
- [13] Goddek S, Joyce A, Kotzen B, et al. Aquaponics and global food challenges[M] // Goddek S, Joyce A, Kotzen B, et al. Aquaponics food production systems: combined aquaculture and hydroponic production technologies for the future. Cham: Springer International Publishing, 2019: 3 - 17.
- [14] Meilleur M A, Bastien D, Monfet D. Modeling mushrooms' carbon dioxide emission and heat exchange rates for synergistic cultivation with leafy greens[J]. Sustainability, 2023, 15(24): 16740.
- [15] 吴波, 谢晶. 溶解氧水平和振动对有水活运过程中石斑鱼氧化应激的影响[J]. 食品与机械, 2019, 35(8): 137 - 142, 182.
- Wu Bo, Xie Jing. Effects of the dissolved oxygen level and the vibration on oxidative stress of grouper during water transport [J]. Food & Machinery, 2019, 35(8): 137 - 142, 182. (in Chinese)
- [16] Bhattacharyya S, Chanda A, Hazra S, et al. Effect of enhanced salinity on the chlorophyll-a concentration and partial pressure of CO₂ of a sewage-fed freshwater aquaculture pond: a microcosm experiment[J]. Chemistry and Ecology, 2021, 37(9 - 10): 840 - 849.
- [17] Van Hooff T, Blocken B. CFD evaluation of natural ventilation of indoor environments by the concentration decay method: CO₂ gas dispersion from a semi-enclosed stadium[J]. Building and Environment, 2013, 61: 1 - 17.
- [18] Fan Y, Tang Q, Guo Y, et al. BiLSTM - MLAM: a multi-scale time series prediction model for sensor data based on Bi - LSTM and local attention mechanisms[J]. Sensors, 2024, 24(12): 3962.
- [19] Zrira N, Kamal-Idrissi A, Farssi R, et al. Time series prediction of sea surface temperature based on BiLSTM model with attention mechanism[J]. Journal of Sea Research, 2024, 198: 102472.
- [20] Garnett R. Bayesian optimization[M]. Cambridge: Cambridge University Press, 2023.
- [21] Kim J, Choi S. BayesO: a Bayesian optimization framework in Python[J]. Journal of Open Source Software, 2023, 8(90): 5320.
- [22] Lipton Z C, Elkan C, Narayanaswamy B. Thresholding classifiers to maximize F1 score[PP/OL]. V1. arXiv(2014 - 02 - 08) [2026 - 03 - 01]. <https://arxiv.org/abs/1402.1892>.
- [23] 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.
- [24] 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)
- [25] 张佳然, 马玉超, 于杰, 等. 基于 PSO - SABO - CGA 的养殖水氨氮预测模型研究[J]. 农业机械学报, 2026, 57(15): 374 - 383.
- Zhang Jiaran, Ma Yuchao, Yu Jie, et al. Ammonia nitrogen prediction model for aquaculture water based on PSO - SABO - CGA[J]. Transactions of the Chinese Society for Agricultural Machinery, 2026, 57(15): 374 - 383. (in Chinese)

Chinese)

[16] Wang C Y, Yeh I H, Mark Liao H Y. YOLO v9: learning what you want to learn using programmable gradient information[C] //European Conference on Computer Vision, Milan, Italy: Springer Nature Switzerland, 2024: 1 – 21.

[17] Misra D, Nalamada T, Arasanipalai A U, et al. Rotate to attend: convolutional triplet attention module[C] //Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision, Waikoloa, America: IEEE, 2020: 3139 – 3148.

[18] Tan M, Pang R, Le Q V. Efficientdet: scalable and efficient object detection[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, Washington, America: IEEE, 2020: 10781 – 10790.

[19] Zheng Z, Wang P, Ren D, et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation[J]. IEEE Transactions on Cybernetics, 2021, 52(8): 8574 – 8586.

[20] Tong Z, Chen Y, Xu Z, et al. Wise – IoU: bounding box regression loss with dynamic focusing mechanism[PP/OL]. V3. arXiv (2023 – 04 – 08) [2025 – 06 – 30]. <https://doi.org/10.48550/arxiv.2301.10051>.

[21] Tan M, Le Q. Efficientnetv2: smaller models and faster training[C] //International Conference on Machine Learning, Vienna, Austria: PMLR, 2021: 10096 – 10106.

[22] Qin D, Leichner C, Delakis M, et al. MobileNetV4: universal models for the mobile ecosystem[C] //European Conference on Computer Vision, Milan, Italy: Springer Nature Switzerland, 2024: 78 – 96.

[23] Mehta S, Rastegari M. Separable self-attention for mobile vision transformers[PP/OL]. V1. arXiv (2022 – 06 – 06) [2025 – 06 – 30]. <https://doi.org/10.48550/arxiv.2206.02680>.

[24] Zheng Z, Wang P, Liu W, et al. Distance – IoU loss: faster and better learning for bounding box regression[C] //Proceedings of the AAAI Conference on Artificial Intelligence, New York, America: AAAI Press, 2020: 12993 – 13000.

[25] Zhang Y F, Ren W, Zhang Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. Neurocomputing, 2022, 506: 146 – 157.

[26] Gevorgyan Z. SIoU loss: more powerful learning for bounding box regression[PP/OL]. V1. arXiv (2022 – 05 – 25) [2025 – 06 – 30]. <https://doi.org/10.48550/arxiv.2205.12740>.

[27] Ma S, Xu Y. Mpdious: a loss for efficient and accurate bounding box regression[PP/OL]. V1. arXiv (2023 – 07 – 14) [2025 – 06 – 30]. <https://doi.org/10.48550/arxiv.2307.07662>.

(上接第 399 页)

[26] 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)

[27] Chen L, Yang X, Sun C, et al. Feed intake prediction model for group fish using the MEA – BP neural network in intensive aquaculture[J]. Information Processing in Agriculture, 2020, 7(2): 261 – 271.

[28] 赫晓慧, 罗浩田, 乔梦佳, 等. 基于 CNN – RNN 网络的中国冬小麦估产[J]. 农业工程学报, 2021, 37(17): 124 – 132.

He Xiaohui, Luo Haotian, Qiao Mengjia, et al. Yield estimation of winter wheat in China based on CNN – RNN network[J]. Transactions of the CSAE, 2021, 37(17): 124 – 132. (in Chinese)

[29] 袁诗佳, 余江, 麦竣深, 等. 基于 TCN – Transformer 与混合超参数优化的轴承剩余寿命预测模型[J]. 南方农机, 2026, 57(5): 119 – 122, 129.

Yuan Shijia, Yu Jiang, Mai Junshen, et al. Bearing remaining useful life prediction model based on TCN – Transformer and hybrid hyperparameter optimization[J]. Southern Agricultural Machinery, 2026, 57(5): 119 – 122, 129. (in Chinese)

[30] Farhangi H, Mozafari V, Roosta H R, et al. Optimizing growth conditions in vertical farming: enhancing lettuce and basil cultivation through the application of the Taguchi method[J]. Scientific Reports, 2023, 13(1): 6717.

[31] Guragain D P, Shrestha B, Bajracharya I. A low-cost centralized IoT ecosystem for enhancing oyster mushroom cultivation[J]. Journal of Agriculture and Food Research, 2024, 15: 100952.

[32] 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 experiment of prediction model for disease and growth of cultured fish based on MTL – LSTM – SAT[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(11): 590 – 598, 620. (in Chinese)