

卢宏宇, 贡宇, 任妮, 等. 基于 DBO-LSTM-Attention 模型的设施番茄茎粗预测[J]. 江苏农业学报, 2026, 42(5): 982-989.
doi:10.3969/j.issn.1000-4440.2026.05.012

基于 DBO-LSTM-Attention 模型的设施番茄茎粗预测

卢宏宇^{1,2}, 贡宇², 任妮^{1,2}, 金晶², 李德翠², 刘磊¹, 毛晓娟²

(1. 淮安大学计算机与软件工程学院, 江苏 淮安 223001; 2. 江苏省农业科学院农业信息研究所/农业农村部长三角智慧农业技术重点实验室, 江苏 南京 210014)

摘要: 茎粗变化量是评估番茄生长状况的重要生理指标, 提前预测其动态变化对温室环境的精准调控具有重要意义。针对现有模型在茎粗预测中存在特征提取不充分、长时间依赖关系捕捉能力不足等问题, 本研究提出一种融合蜣螂优化算法 (DBO)、长短期记忆网络 (LSTM) 与注意力机制 (Attention) 的茎粗预测模型 (DBO-LSTM-Attention)。该模型利用 LSTM 捕捉茎粗变化量与空气温度、空气湿度、二氧化碳浓度、光合有效辐射等环境因子之间的时间依赖关系; 引入注意力机制动态分配权重, 增强模型对关键时间步的关注能力; 采用 DBO 算法实现超参数自适应寻优, 提升模型泛化性能。结果表明, 在短时长和长时长预测任务中, DBO-LSTM-Attention 模型均表现出较高的预测稳定性与准确性, 各项评价指标均优于对比模型。且随着预测时长增加, 模型预测性能下降幅度较小, 表明其具有较强的时序建模与泛化能力。综上, DBO-LSTM-Attention 模型能够有效融合番茄植株生长参数与温室环境因子, 实现对茎粗动态变化的高精度预测, 为设施番茄生长环境的智能调控提供了理论依据。

关键词: 番茄; 茎粗; 时序预测模型; 蜣螂优化算法; 长短期记忆网络; 注意力机制

中图分类号: S641.2 **文献标识码:** A **文章编号:** 1000-4440(2026)05-0982-08

Prediction of stem diameter of protected tomato based on DBO-LSTM-Attention model

LU Hongyu^{1,2}, GONG Yu², REN Ni^{1,2}, JIN Jing², LI Decui², LIU Lei¹, MAO Xiaojuan²

(1. School of Computer and Software Engineering, Huai'an University, Huai'an 223001, China; 2. Institute of Agricultural Information, Jiangsu Academy of Agricultural Sciences/Key Laboratory of Intelligent Agricultural Technology (Yangtze River Delta), Ministry of Agriculture and Rural Affairs, Nanjing 210014, China)

Abstract: Stem diameter variation is a vital physiological indicator for evaluating tomato growth status. Accurately predicting its dynamic changes in advance is of great significance for precise regulation of greenhouse environments. Aiming at the deficiencies of existing prediction models such as insufficient feature extraction and weak capability in capturing long-term dependencies, this study proposed a stem diameter prediction model integrating dung beetle optimizer (DBO), long short-term memory (LSTM) network and attention mechanism, namely DBO-LSTM-Attention. The model used LSTM module to capture temporal dependencies between stem diameter dynamics and environmental factors including air temperature,

air humidity, carbon dioxide concentration and photosynthetically active radiation. The attention mechanism was introduced to dynamically assign weights, thereby enhancing the model's focus on critical time steps. The DBO algorithm was adopted for adaptive hyperparameter optimization to improve model generalization perfor-

收稿日期: 2026-03-24

基金项目: 农业农村部部长项目

作者简介: 卢宏宇 (1997-), 男, 重庆人, 硕士研究生, 研究方向为设施环境智能调控。(E-mail) rogerluhongyu@163.com

通讯作者: 毛晓娟, (E-mail) 20190033@jaas.ac.cn

mance. The results revealed that the DBO-LSTM-Attention model achieved superior prediction stability and accuracy in both short-term and long-term prediction tasks, with all evaluation indices outperforming those of the comparative models. Its performance declined slightly with the increase of prediction horizon, proving strong temporal modeling and generalization ability. In conclusion, the DBO-LSTM-Attention model can effectively fuse tomato plant growth parameters and greenhouse environmental factors to realize high-precision prediction of dynamic changes in stem diameter, and provide a theoretical reference for intelligent regulation of growing environments for protected tomatoes.

Key words: tomato; stem diameter; time series prediction model; dung beetle optimizer; long short-term memory network; attention mechanism

番茄是典型的设施栽培作物,中国番茄种植产量和规模均位居世界前列。随着农业物联网技术的发展,设施农业监测技术日渐成熟,利用对作物生理的监测数据精准智能调控设施农业环境已成为当前研究的热点^[1-2]。当前国内外关于作物生长预测的模型主要分为两类,一类是数据模型,另一类是生长模型^[3]。生长模型基于生理机制和数学原理,动态模拟作物生长发育与形态建成的过程,能够反映生物内外环境对生长发育的影响,是研究作物生长的重要手段^[4-5]。Spitters 等^[6]提出了 TOMSIM 模型,用于模拟番茄在温室环境中的干物质生产、器官发育及资源分配的过程。Dayan 等^[7]提出了 TOMGRO 模型,通过微分方程描述叶片、果实、茎节等器官的发生、老化与干物质积累过程,模拟不同环境条件下番茄的生长发育与产量形成过程。Faurobert 等^[8]提出了一种能够反映番茄果实生长与环境之间关系的模型,用于模拟番茄果实生长过程。员玉良等^[9]结合温室环境数据与茎秆变化数据,采用主成分回归分析模型对作物茎直径进行预测,并取得了良好的结果。然而,上述生长模型大多依赖于对作物生理过程的简化假设,且模型结构固定,难以完全适应设施环境中的多因素耦合效应。数据模型主要依赖海量历史数据驱动,利用数据和算法挖掘作物生长与环境参数之间的规律,无需考虑作物复杂的生理生态过程。陈毅飞等^[10]将多层感知机算法与植物生理生态信息相结合,构建了番茄短时茎直径动态变化预测模型。韩坤林等^[11]融合环境因子与植物本体数据,采用主成分分析法和反向传播神经网络算法(BPNN),以解析番茄所需水肥规律。唐友等^[12]采用 K 近邻算法(KNN)对缺失数据及异常值进行处理,并结合番茄生理学特点,利用支持向量机算法(SVM)建立了温室番茄生长发育的非线性模型,提升了模型对番茄生长预测的准确率。尽管上述方法一定程度上提高了预测精度,但其模型结构

较为简单,特征提取能力有限,在长时序预测任务中易出现精度下降和性能衰退等问题。

番茄茎粗变化具有显著的时间序列特性,适用于基于时间序列分析的预测方法。传统机器学习算法在处理长时序数据时,常因模型表征能力有限而难以捕捉时序动态,导致预测误差偏大。相比之下,深度学习通过构建深层神经网络结构,具备更强的特征提取与模式挖掘能力。循环神经网络(RNN)^[13]作为深度学习在时序建模中的代表性架构,通过引入时序反馈机制,在时间序列任务中表现出良好的适应性。然而,传统 RNN 常面临梯度消失或梯度爆炸等问题,难以有效捕捉时序中的长期依赖关系^[14]。为此,Hochreiter 等^[15]提出长短期记忆网络(LSTM),通过引入门控机制和改进记忆单元,有效克服了传统循环神经网络在长时序建模中的局限,已成为应用广泛的时序预测模型^[16]。在农业预测领域,LSTM 网络已被初步应用并取得了一定成效。陆棚等^[17]结合隐马尔可夫模型(HMM)和 LSTM 网络,为网纹蜜瓜构建数字孪生长模型,该系统能根据实时环境数据,在虚拟场景中同步展示蜜瓜从种子发芽、幼苗、开花结果各阶段的生长状态,并对生长过程进行智能推演,从而提高水资源利用效率,辅助种植管理决策,然而该模型的预测精度有限。为解决温室环境控制决策滞后的问题,Yang 等^[18]将 LSTM 和前馈注意力机制相结合,用于预测未来温室温度,以实现更精准的环境调控及低温、高温等灾害预警,但该模型的参数设定依赖人工经验,易陷入局部最优。

针对现有模型在时序预测中特征提取不充分、难以捕捉长期依赖关系等问题,本研究拟将 LSTM 的时序建模能力、注意力机制的关键信息聚焦能力与蜣螂优化算法^[19]的超参数全局寻优能力进行融合,以期提升模型对设施番茄茎粗变化的预测精度与鲁棒性。

1 材料与方 法

1.1 试验概况

试验在江苏省农业科学院日光植物工厂(118°52'25"E,32°2'3"N)进行。温室内配备 LED 自动升降补光灯、热风机、除湿机、二氧化碳增施设备及中央控制器等环境智能调控系统。利用椰糠基质栽培樱桃番茄,品种为阿鲁。本试验种植 36 株樱桃番茄,从中选取 2 株生长状态相近的植株(样本 1 和样本 2)用于试验。试验周期为 2025 年 3 月上旬至 7 月下旬,包括番茄植株生长的幼苗期、开花期与坐果

表 1 本试验所用传感器的采集性能

Table 1 Acquisition performance of sensors used in this experiment

传感器	精度	分辨率	测量范围
空气温度传感器	±0.5 °C	0.1 °C	-40~120 °C
空气相对湿度传感器	±2%	0.1%	0~100%
二氧化碳浓度传感器	±72 mg/m ³	1 mg/m ³	0~9 000 mg/m ³
光合有效辐射传感器	±5%	1 μmol/(m ² ·s)	0~3 000 μmol/(m ² ·s)
茎粗变化传感器	±0.1%	0.002 mm	2~25 mm

选取 2025 年 3 月 15 日至 4 月 15 日期间的监测数据,采样间隔为 10 min,总共获取 4 608 条样本数据。针对传感器采集过程中可能产生的高斯噪声,采用数字滤波进行平滑去噪。针对数据中的缺失值与异常值,采用线性插值法进行数据填充,并结合均值法进行修正。为消除各特征在单位与量纲上的差异,首先利用公式 1 对全部数据进行归一化。

$$y' = \frac{y - y_{\min}}{y_{\max} - y_{\min}} \quad (1)$$

式中, y 为原始数据; y' 为归一化后的数据; y_{\min} 、 y_{\max} 分别为同一量纲下时间序列数据的最小值和最大值。

将预处理后的数据按 6 : 2 : 2 的比例划分为训练集、验证集和测试集,对应数据量分别为 2 764 条、921 条与 921 条。最终选取茎粗变化量、空气温度、空气相对湿度、光合有效辐射与二氧化碳浓度 5 个特征作为模型输入,以下一时刻的茎粗作为输出标签。

1.3 设施番茄茎粗变化预测模型构建

1.3.1 长短期记忆网络(LSTM) 长短期记忆网络借助记忆单元和门控机制能够有效保留数据中的长

期。试验期间依托物联网智能管控平台进行自动化环境控制,水肥管理参照常规园区管理规程执行。

1.2 数据采集与预处理

温室内部署无线传感器,用于采集室内二氧化碳浓度、空气温湿度及光合有效辐射等环境数据,监测点设于距离供试植株样本约 1 m 处。番茄茎粗变化量采用线性位移传感器(LVDT)连续监测,传感器安装于子叶节位茎秆处,共部署 2 套。所有通过传感器采集终端采集的数据实时上传至云平台并存储于数据库。所用传感器的采集性能详见表 1。

期重要信息,并抑制无关信息对预测结果的干扰^[20-23]。门控机制包含输入门、遗忘门与输出门三部分,分别负责信息的存入、保留与输出控制。在遗忘门与输入门的协同作用下,记忆单元实现对自身状态的动态更新。图 1 为 LSTM 结构示意图。

遗忘门计算公式为:

$$f_t = \text{sigmoid}(W_f^T \times h_{t-1} + U_f^T \times x_t + b_f) \quad (2)$$

输入门计算公式为:

$$i_t = \text{sigmoid}(W_i^T \times h_{t-1} + U_i^T \times x_t + b_i) \quad (3)$$

上一时刻记忆单元公式为:

$$c'_t = \tanh(W_c^T \times h_{t-1} + U_c^T \times x_t + b_c) \quad (4)$$

当前记忆单元公式为:

$$c_t = f_t \times c_{t-1} + i_t \times c'_t \quad (5)$$

输出门计算公式为:

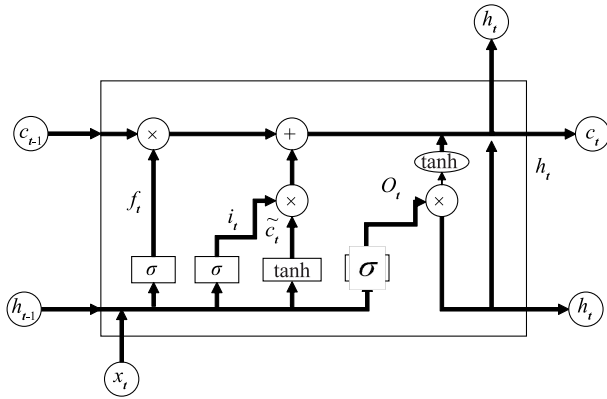
$$o_t = \text{sigmoid}(W_o^T \times h_{t-1} + U_o^T \times x_t + b_o) \quad (6)$$

隐藏状态公式为:

$$h_t = o_t \times \tanh(c_t) \quad (7)$$

式中, f_t 、 i_t 、 c'_t 、 c_t 、 o_t 、 h_t 分别为在 t 时刻的遗忘门、输入门、上一时刻记忆单元、当前记忆单元、输出门和隐藏状态; x_t 为 t 时刻的输入向量; W 、 U 和 b 分别为对应门结构和单元状态的输出值权重、输入值

权重和偏置; tanh 和 sigmoid 为激活函数。



x_t, h_t, c_t 分别为在 t 时刻的输入、输入、记忆信息; σ : Sigmoid 函数; tanh: 双曲正切函数; O_t : 输出门的激活值。

图 1 长短期记忆网络结构示意图

Fig.1 Schematic diagram of the long short-term memory network structure

1.3.2 注意力机制(Attention) 注意力机制^[24-26]的核心思想是模仿人类处理信息时选择性关注重要信息的特点,通过对输入时序数据动态分配权重,使模型重点关注当前任务最关键的部分,从而减少无关信息的干扰,增强模型的代表能力与预测准确性。注意力机制结构如图 2 所示。注意力机制通过计算查询向量(Query)和键向量(Key)之间的相似度,并利用 Softmax 函数将相似度转化为注意力权重,最后将权重与值向量(Value)进行加权。计算公式为:

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Softmax}\left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}}\right)\mathbf{V} \quad (8)$$

式中, $\mathbf{Q}, \mathbf{K}, \mathbf{V}$ 分别为查询矩阵、键矩阵和值矩阵; $\sqrt{d_k}$ 为向量维度。


1.3.3 蜥螂优化算法(DBO) 蜥螂优化算法通过模拟不同角色的蜥螂个体在搜索空间中的移动与位置更新机制,实现全局寻优与局部开发的平衡。蜥螂行为可分为滚球、跳舞、觅食、繁殖和偷窃。

滚球蜥螂利用天体线索来导航,使其沿直线运动,其公式为:

$$x_i(t+1) = x_i(t) + \alpha \times k \times x_i(t-1) + b \times \Delta x \quad (9)$$

$$\Delta x = |x_i(t) - X^w| \quad (10)$$

式中, t 为迭代次数; $x_i(t)$ 为第 t 次迭代时第 i 只蜥螂的位置信息; k 为偏转系数, $k \in (0, 2]$; b 为 $(0, 1)$ 的一个定值; α 为自然系数,取值为 1 或者



Feature: 特征; Query: 查询向量; Key: 键向量; Value: 值向量; Softmax: 归一化函数; Output: 输出。

图 2 注意力机制结构示意图

Fig.2 Schematic diagram of the attention mechanism structure

-1, -1 表示偏离原方向, 1 表示无偏差; X^w 为全局最差位置; Δx 为“太阳光”强度的变化值。

当蜥螂无法前进时,蜥螂通过跳舞来再次获得新的路线,其公式为:

$$x_i(t+1) = x_i(t) + \tan\theta \times |x_i(t) - x_i(t-1)| \quad (11)$$

式中, θ 为偏转角,取值范围为 $[0, \pi]$; $|x_i(t) - x_i(t-1)|$ 为第 i 只蜥螂在第 t 次迭代时的位置与其在 $t-1$ 次迭代时的位置之差。当 $\theta = 0, \pi/2, \pi$, 蜥螂的位置不更新。

繁殖蜥螂利用产卵区域确定边界选择策略,其公式为:

$$Ub^* = \min[X^* \times (1+R), Ub] \quad (12)$$

$$Lb^* = \max[X^* \times (1-R), Lb] \quad (13)$$

$$B_i(t+1) = X^* + b_1 \times [B_i(t) - Lb^*] + b_2 \times [B_i(t) - Ub^*] \quad (14)$$

式中, X^* 为当前局部最佳位置, Ub^* 和 Lb^* 分别为产卵区的上边界和下边界; $R = 1 - \frac{t}{T_{max}}$, T_{max} 为最大

迭代次数; Ub 和 Lb 分别为优化问题的上边界和下边界; $B_i(t)$ 为第 i 个育雏蜥螂在第 t 次迭代时的位置信息; b_1 和 b_2 为两个大小为 $1 \times D$ 的独立随机向量; D 为优化问题的维数。

觅食蜥螂通过觅食行为搜索全局最优解,其公式为:

$$Ub^b = \min[X^b \times (1+R), Ub] \quad (15)$$

$$Lb^b = \max[X^b \times (1-R), Lb] \quad (16)$$

$$x_i(t+1) = x_i(t) + C_1 \times [x_i(t) - Lb^b] + C_2 \times [x_i(t) - Ub^b] \quad (17)$$

式中, $x_i(t)$ 为第 t 次迭代时第 i 只蜣螂的位置信息; C_1 表示一个服从正态分布的随机数; C_2 为取值 $(0, 1)$ 的随机向量; X^b 为全局最佳位置; Lb^b 和 Ub^b 分别为最优觅食区域的上界和下界。

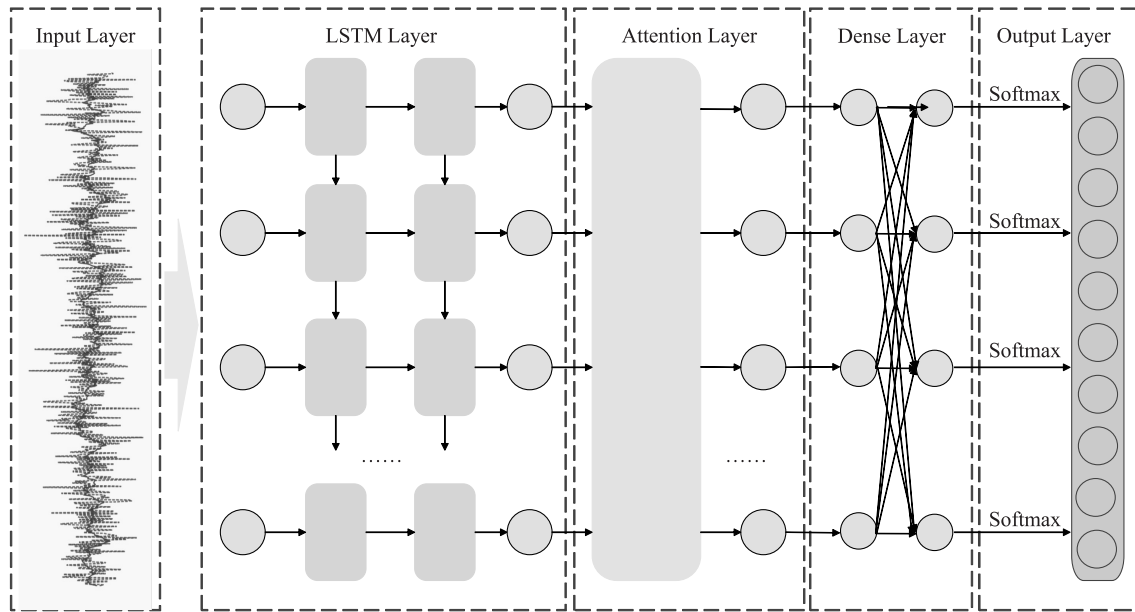
偷窃蜣螂依据全局最优解与局部最优解更新自身位置, 其公式为:

$$X_i^{t+1} = X_i^b + S \times g \times (|X_i^t - X_i^*| + |X_i^t - X_i^b|) \quad (18)$$

式中, X_i^t 为第 i 个偷窃蜣螂在第 t 次迭代时的位置信息; X_i^b 为第 i 个偷窃蜣螂所在的局部最优位置; X_i^* 为第 i 个偷窃蜣螂在第 t 次迭代时的位置; S 为常数; g 为随机向量, 其取值服从正态分布。

1.3.4 DBO-LSTM-Attention 模型 如图 3 所示, LSTM-Attention 模型结构具体分为以下 2 个部分: 第一部分, 时序数据特征输入与 LSTM 建模。输入模型的数据为 5 个特征的时序张量, 包括茎粗变化量、

空气温度、空气相对湿度、光合有效辐射、二氧化碳浓度, LSTM 层采用 Tanh 作为隐藏层激活函数, 借助其特殊的门结构与记忆单元, 有效捕捉时序数据长期依赖的关系, 提取作物生长与环境参数之间的动态变化与非线性特征。第二部分, 注意力机制加权与关键信息聚焦。在 LSTM 层输出的数据基础上引入注意力机制层, 该层通过计算值向量、键向量与查询向量之间的相似度, 自适应地为各个时间步分配权重, 以增强模型对关键时间步的关注能力, 从而提升预测精度。最后, 采用蜣螂优化算法 (DBO) 对 LSTM-Attention 的超参数进行自适应寻优, 包括 LSTM 隐藏神经元个数、学习率与迭代次数, 具体流程为: 初始化蜣螂种群, 并按比例分配滚球、跳舞、繁殖、觅食、偷窃等行为角色, 根据目标函数计算个体适应度, 依据不同行为规则更新个体位置, 并判断是否超出边界, 更新全局最优解与适应度值, 重复上述迭代过程, 直至满足终止条件, 最终输出最优超参数组合。



Input Layer: 输入层; LSTM Layer: 长短期记忆网络层; Attention Layer: 注意力机制层; Dense Layer: 全连接层; Output Layer: 输出层; Softmax: 归一化函数。

图 3 LSTM-Attention 模型结构图
Fig.3 Structure diagram of the LSTM-Attention model

1.3.5 模型评价指标 本研究采用均方根误差 (RMSE)、平均绝对误差 (MAE)、平均绝对百分比误差 (MAPE) 和决定系数 (R^2) 作为模型评价指标, 具

体表达式为:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y'_i - y_i)^2} \quad (19)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |y'_i - y_i| \quad (20)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|y'_i - y_i|}{y_i} \quad (21)$$

$$R^2 = 1 - \frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{\sum_{i=1}^N (y_i - \bar{y})^2} \quad (22)$$

式中, N 为预测样本数; \hat{y}_i 和 y_i 分别为设施番茄茎粗生长量的预测值与真实值; \bar{y} 为真实值的平均值。RMSE、MAE 和 MAPE 数值越小, 且 R^2 越接近 1, 表示模型预测效果越好。

1.4 试验环境及模型参数设置

基于 Python 3.11 编程语言, 采用 Keras 深度学习框架构建模型。硬件配置为: 13th Gen Intel^(R) Core^(TM) i7-13700HX 处理器 (5 GHz), NVIDIA GeForce RTX 4060 显卡 (8 GB 显存), 32 GB 三星 DDR4 内存。操作系统为 Windows 11 64 位。

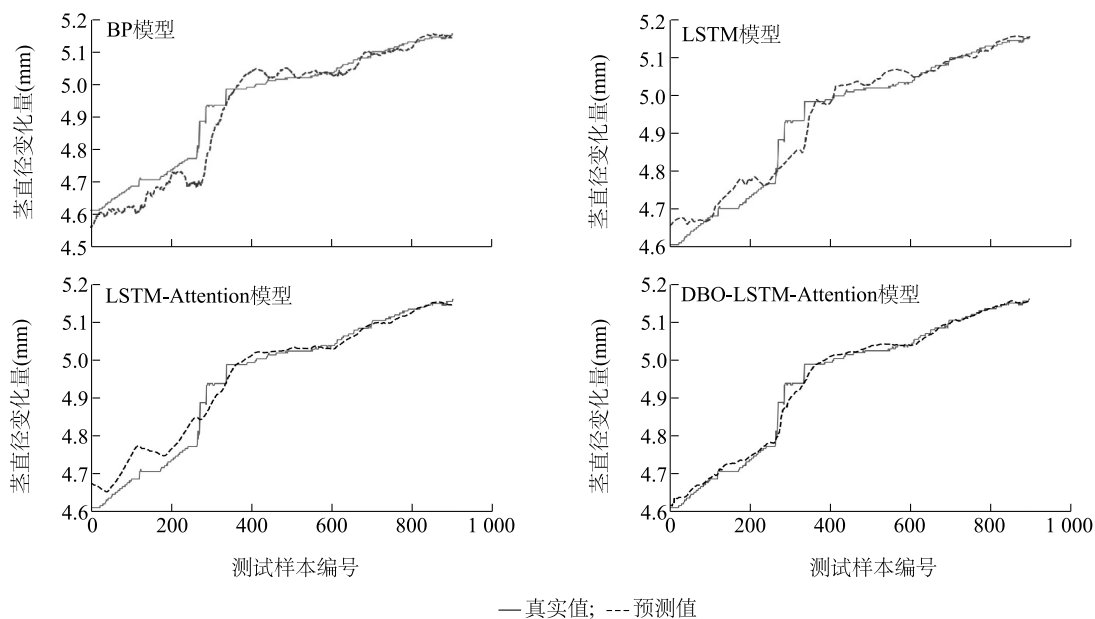
采用 Adam 优化器对模型参数进行优化与更新, 并使用 DBO 算法对关键超参数进行寻优。寻优

范围设定为: LSTM 层隐藏单元数 [32, 128], 学习率 [0.000 1, 0.010 0], 迭代次数 [80, 200]。初始蛭螂种群规模为 20, 按 6 : 6 : 7 : 11 的比例划分不同蛭螂角色, 最大迭代次数为 30。优化后得到的最佳参数为: LSTM 层隐藏单元数 71, 最优学习率 0.002 8, 迭代次数 177。

2 结果与分析

2.1 不同模型对番茄茎粗变化量的预测性能对比

选择 BP 模型、LSTM 模型和 LSTM-Attention 模型与 DBO-LSTM-Attention 模型进行对比。如图 4 所示, BP 模型预测值波动较大, 与真实值之间存在明显偏差。相较于 BP 模型, LSTM 模型预测效果虽有改善, 但在部分时间点上仍存在滞后或偏差。LSTM-Attention 模型利用注意力机制增强了对关键时间步的关注, 拟合度有所提升。而 DBO-LSTM-Attention 模型的预测值与实测值最为接近, 表现出更高的拟合度与稳定性。



BP: 反向传播神经网络; LSTM: 长短期记忆网络; Attention: 注意力机制; DBO: 蛭螂优化算法。

图 4 不同模型对番茄茎直径变化的预测曲线

Fig.4 Prediction curves of stem diameter variation by different models

2.2 DBO-LSTM-Attention 模型预测性能

2.2.1 DBO-LSTM-Attention 模型短时长预测性能
如表 2 所示, DBO-LSTM-Attention 模型 RMSE、MAE、MAPE 和 R^2 均优于 LSTM-Attention 模型, 表明

DBO 优化算法能有效实现超参数自适应寻优, 提升模型泛化能力与鲁棒性。LSTM-Attention 模型 RMSE、MAE、MAPE 和 R^2 均优于 LSTM 模型, 表明注意力机制能有效提升模型对关键信息的捕捉能力。

随着预测时长增加,各模型性能均呈下降趋势,但 DBO-LSTM-Attention 模型预测性能仍保持较高稳定

性,并且在 6 h 预测的 $RMSE$ 、 MAE 、 $MAPE$ 和 R^2 均优于对比模型,表明其具有较强的稳定性与泛化能力。

表 2 不同模型对番茄茎粗变化量的预测性能

Table 2 Prediction performance of different models on tomato stem diameter variation

预测时间(h)	模型	$RMSE$	MAE	$MAPE$	R^2
1	BP	0.048 7	0.035 0	0.722 2	0.923 3
	LSTM	0.041 5	0.031 1	0.639 7	0.941 7
	LSTM-Attention	0.034 0	0.024 7	0.514 3	0.961 5
	DBO-LSTM-Attention	0.019 8	0.013 0	0.266 0	0.987 2
3	BP	0.052 3	0.036 4	0.749 7	0.910 3
	LSTM	0.044 6	0.033 3	0.683 5	0.935 0
	LSTM-Attention	0.037 0	0.027 8	0.576 0	0.953 7
	DBO-LSTM-Attention	0.026 8	0.017 0	0.348 2	0.976 6
6	BP	0.053 7	0.037 2	0.760 0	0.906 5
	LSTM	0.050 4	0.038 0	0.778 7	0.917 6
	LSTM-Attention	0.042 5	0.032 1	0.666 0	0.939 6
	DBO-LSTM-Attention	0.034 8	0.023 4	0.480 3	0.960 6

BP:反向传播神经网络模型;LSTM:长短期记忆网络模型;Attention:注意力机制;DBO:蜣螂优化算法。 $RMSE$:均方根误差; MAE :平均绝对误差; $MAPE$:平均绝对百分比误差; R^2 :决定系数。

2.2.2 DBO-LSTM-Attention 模型长时长预测性能
为进一步验证模型在更长时间范围内的预测性能稳定性和预测结果可靠性,利用 DBO-LSTM-Attention 模型分别对番茄茎粗进行了 12 h、18 h 及 24 h 的长时预测。如表 3 所示,随着预测时间延长,模型预测误差逐渐增大,但 DBO-LSTM-Attention 模型仍保持较高的预测稳定性。

表 3 DBO-LSTM-Attention 模型的长时预测性能

Table 3 Long-term prediction performance of the DBO-LSTM-Attention model

预测时间(h)	$RMSE$	MAE	$MAPE$	R^2
12	0.044 0	0.033 1	0.684 5	0.940 0
18	0.052 7	0.038 1	0.789 4	0.913 5
24	0.058 3	0.041 6	0.864 2	0.891 3

$RMSE$:均方根误差; MAE :平均绝对误差; $MAPE$:平均绝对百分比误差; R^2 :决定系数。

3 讨论与结论

本研究提出了 DBO-LSTM-Attention 模型,用于设施番茄茎粗的动态变化量预测。该模型中,LSTM 通过门控机制增强了对历史信息的记忆能力,适用于处理茎粗这类连续变化的时序数据。注意力机制

通过强化关键时间步的权重分配,增强了模型对时序动态特征的捕捉能力。在此基础上,采用 DBO 算法实现模型超参数自适应寻优,从而增强模型泛化能力。结果表明,在短时长和长时长预测任务中, DBO-LSTM-Attention 模型均保持较高的预测稳定性与准确性,各项评价指标均优于对比模型。且随着预测时长增加,模型性能下降幅度较小,表明其具有较强的时序建模与泛化能力。

综上所述, DBO-LSTM-Attention 模型能够有效融合番茄植株生长参数与温室环境因子,实现对茎粗动态变化量的高精度预测,为设施番茄生长环境的智能调控提供可靠的理论依据与决策支持。未来研究中,可进一步引入土壤水分、植株营养状态等多源生理生态信息,构建更全面的生长状态预测模型,以提升其在复杂生产场景中的适用性与预测准确性。

参考文献:

- [1] 毛晓娟,刘家祥,任妮,等.基于物联网的数字温室环境自动调控系统设计[J].江苏农业科学,2020,48(21):229-232.
- [2] OMAR N B, ZEN H, ALDRIN N N A, et al. Accuracy and reliability of data in IoT system for smart agriculture[J]. International Journal of Integrated Engineering,2020,12(6):105-116.

- [3] 施雨田. 基于时序数据的玉米生长预测[D]. 武汉:华中农业大学,2022.
- [4] 朱 艳,汤 亮,刘蕾蕾,等. 作物生长模型(CropGrow)研究进展[J]. 中国农业科学,2020,53(16):3235-3256.
- [5] SINCLAIR T R, SELIGMAN. Crop modeling:from infancy to maturity[J]. *Agronomy Journal*,1996,88(5):698-704.
- [6] SPITTERS C J T. Separating the diffuse and direct component of global radiation and its implications for modeling canopy photosynthesis Part II. Calculation of canopy photosynthesis[J]. *Agricultural and Forest Meteorology*,1986,38(1):231-242.
- [7] DAYAN E, VAN KEULEN H, JONES J W, et al. Development, calibration and validation of a greenhouse tomato growth model: I. Description of the model[J]. *Agricultural Systems*,1993,43(2):145-163.
- [8] FAUROBERT M, MIHR C, BERTIN N, et al. Major proteome variations associated with cherry tomato pericarp development and ripening[J]. *Plant Physiology*,2007,143(3):1327-1346.
- [9] 员玉良,盛文溢. 基于主成分回归的茎直径动态变化预测方法[J]. *农业机械学报*,2015,46(1):306-314.
- [10] 陈毅飞,杨会民,马 艳,等. 基于多层感知机的温室番茄茎直径变化预测模型[J]. *新疆农业科学*,2020,57(3):562-571.
- [11] 韩坤林,王钊英,杨会民,等. 基于 PCA-BPNN 的温室番茄果实直径预测模型[J]. *新疆农业科学*,2022,59(2):485-492.
- [12] 唐 友,张 威. 基于 KNN-SVM 算法的温室番茄生长预测模型[J]. *安徽农业科学*,2024,52(10):219-224.
- [13] JORDAN M L. Serial order: a parallel distributed processing approach[J]. *Advanced in Connectionist Theory Speech*,1986,121(97):471-495.
- [14] 张镇洲. 基于句法模式、动词类别和主题提示的故事生成研究[D]. 广州:广东工业大学,2024.
- [15] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*,1997,9(8):1735-1780.
- [16] KALMANI V H, DHARWADKAR N V, THAPA V. Crop yield prediction using deep learning algorithm based on CNN-LSTM with attention layer and skip connection[J]. *Indian Journal of Agricultural Research*,2025,59(8):A-6300.
- [17] 陆 棚,刘明堂,吴姗姗,等. 基于 HMM+LSTM 算法的网纹蜜瓜数字孪生体生长模型设计[J]. *灌溉排水学报*,2025,44(5):122-132.
- [18] YANG Y X, GAO P, SUN Z T, et al. Multistep ahead prediction of temperature and humidity in solar greenhouse based on FAMILSTM model[J]. *Computers and Electronics in Agriculture*,2023,213:108261.
- [19] XUE J K, BO S. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization[J]. *The Journal of Supercomputing*,2022,79(7):7305-7336.
- [20] 李星宇,李 玥,高玉红. 基于 CNN-BiLSTM-Attention 模型的胡麻产量预测[J]. *江苏农业学报*,2025,41(7):1342-1349.
- [21] 冯国富,卢胜涛,陈 明,等. 基于自注意力机制和改进的 K-BiLSTM 的水产养殖水体溶解氧含量预测模型[J]. *江苏农业学报*,2024,40(3):490-499.
- [22] 朱 敏,段 娟,钱 晶,等. 基于 RIME-VMD-LSTM 法的流固耦合作用下叶片裂纹特征[J]. *排灌机械工程学报*,2025,43(8):786-794.
- [23] 欧 斌,张才溢,陈德辉,等. 基于 EMD-小波阈值-LSTM 模型的混凝土坝变形预测[J]. *排灌机械工程学报*,2025,43(4):379-386.
- [24] 刘宇雄,兰艳亭,陈晓栋. 基于级联式分组注意力机制的葡萄病害识别模型[J]. *江苏农业科学*,2025,53(5):121-128.
- [25] 李英豪,施爱平,范欣竹. 基于 Attention-GRU 模型的酿酒葡萄蒸腾量预测[J]. *排灌机械工程学报*,2024,42(11):1181-1188.
- [26] 赫晓慧,王劲勇,李盼乐,等. 基于时空注意力的河南冬小麦长势预测[J]. *江苏农业科学*,2025,53(17):211-221.

(责任编辑:成纾寒)