

基于 SSA - LSTM 的日光温室环境预测模型研究

祖林禄^{1,2} 柳平增^{2,3} 赵妍平¹ 李天华¹ 李辉³

(1. 山东农业大学机械与电子工程学院, 泰安 271018; 2. 农业农村部黄淮海智慧农业技术重点实验室, 泰安 271018;
3. 山东农业大学信息科学与工程学院, 泰安 271018)

摘要: 构建日光温室环境预测模型, 准确预测温室环境变化有助于精准调控作物生长环境, 促进果蔬生长。而温室小气候环境数据多参数并存、耦合关系复杂, 且具有时序性和非线性, 难以建立准确的预测模型。针对以上问题, 提出一种基于麻雀搜索算法 (SSA) 优化的长短期记忆网络 (LSTM) 温室环境预测模型, 实现了温室环境数据的精准预测。实验结果表明, 采用 SSA 自动进行参数选优的方式, 解决了 LSTM 模型参数手动选择的难题, 大幅缩短模型训练时间, 且最优的网络参数能够发挥模型的最佳性能。对日光温室内空气温湿度、土壤温湿度、CO₂ 浓度和光照强度 6 种环境参数进行预测, SSA - LSTM 平均拟合指数高达 97.6%, 相比 BP、门控循环单元 (GRU)、LSTM, 其预测拟合指数分别提升 8.1、4.1、4.3 个百分点, 预测精度明显提升。

关键词: 日光温室; 物联网; 麻雀搜索算法; 长短期记忆网络; 环境预测模型

中图分类号: TP391 文献标识码: A 文章编号: 1000-1298(2023)02-0351-08

OSID:



Solar Greenhouse Environment Prediction Model Based on SSA - LSTM

ZU Linlu^{1,2} LIU Pingzeng^{2,3} ZHAO Yanping¹ LI Tianhua¹ LI Hui³

(1. College of Mechanical and Electronic Engineering, Shandong Agricultural University, Taian 271018, China
2. Key Laboratory of Huang - Huai - Hai Smart Agricultural Technology,
Ministry of Agriculture and Rural Affairs, Taian 271018, China
3. College of Information Science and Engineering, Shandong Agricultural University, Taian 271018, China)

Abstract: The accurate prediction of greenhouse environment variation based on the constructed prediction model is helpful to precisely regulate the crop environment, and promote the growth of fruits and vegetables. Due to the coexistence of multiple parameters, complex coupling with each other, temporality and nonlinearity of greenhouse microclimate environment, the accurate prediction model is difficult to establish. Based on above issues, a greenhouse environment prediction model was proposed based on the sparrow search algorithm (SSA) optimized-long short term memory (LSTM) neural network method, so as to realize the prediction of greenhouse environment data sequence with the Internet of things (IoT) collecting accurate multipoint environment data. The experimental results showed that the automatic parametric optimization process by SSA could deal with the time consuming problem of manual parameter selection for the LSTM model. The proposed SSA - LSTM method could lower the model training time, and the optimal parameters selection could make sure the model worked with the optimum capability. The trained SSA - LSTM model was used to predict six kinds of greenhouse environment data, including the air temperature, air humidity, soil temperature, soil humidity, CO₂ concentration, and the illumination intensity. The proposed SSA - LSTM could realize a 97.6% average prediction fit index, compared with the back-propagation network, the gated recurrent unit neural network and the LSTM, the prediction fit index was elevated by 8.1 percentage points, 4.1 percentage points and 4.3 percentage points. Therefore, the prediction accuracy of SSA - LSTM was obviously improved. The research result could provide reference for the development of greenhouse environment control strategy and deal with the lag problem of environment control.

Key words: solar greenhouse; Internet of things; sparrow search algorithm; LSTM neural network; environment prediction model

收稿日期: 2022 - 03 - 22 修回日期: 2022 - 04 - 18

基金项目: 山东省农业重大应用技术创新项目 (SD2019ZZ019)、山东省科技型中小企业创新能力提升工程项目 (2022TSGC2047) 和山东省重大科技创新工程项目 (2022CXGC020708)

作者简介: 祖林禄 (1988—), 男, 讲师, 博士生, 主要从事农业信息化研究, E-mail: zulinlu@sdau.edu.cn

通信作者: 柳平增 (1968—), 男, 教授, 博士生导师, 主要从事农业物联网及大数据研究, E-mail: pzliu@sdau.edu.cn

0 引言

我国是世界上温室面积最大的国家,其类型主要分为塑料大棚、日光温室、连栋温室等^[1]。2020 年底我国温室面积为 $1.873 \times 10^6 \text{ hm}^2$,其中日光温室面积占比约 30%^[2]。适宜的温室环境能促进温室作物的健康高效生长,利用物联网精准采集温室环境数据、设计高精度的环境预测模型是实现温室环境精准调控的关键和重要前提^[3-5]。

温室环境模型主要包括机理模型和数据驱动模型两种^[6-7]。其中,机理模型为根据能量守恒和质量守恒等原理构建的温室动力学模型,如文献[8]构建黄瓜温室的小气候模型描述能量和物质的传递过程,此模型能够预测自然通风条件下空气、作物、栽培基质及塑料覆盖层的温度,但此类模型不能计算温室温度和湿度的分布(空间特征);文献[9]通过构建温室建筑计算流体力学模型,实现温室环境因子的多目标、高效率优化,其中温室的结构、材料和热环境组件是主要研究对象。这两种机理建模过程存在大量的物理参数和变量,建模过程较为复杂。

由于温室系统存在时间变化缓慢的特点且温室环境的时间序列数据具有特定的变化趋势和周期特征,温室时间序列建模可用于研究数据变化的具体规律。文献[10]利用物联网、云服务和微信平台相结合的方式,设计开发了基于差分时间序列模型的温室环境监测与温度预测系统;文献[11]提出基于非线性自回归动态神经网络模型进行日光温室温度预测;文献[12]分别构建人工神经网络、非线性自回归模型和长短期记忆网络(Long short term memory,LSTM)模型对空气温度、湿度和 CO₂ 浓度进行预测,基于时间序列算法的非线性自回归模型和 LSTM 模型优于传统的人工神经网络模型,论证了基于深度学习的预测模型用于温室调控的可行性,此研究未详细讨论 LSTM 超参数调节过程,对空气湿度的预测效果较差。文献[13]利用 LSTM 和 4 个月的温度数据,提前 24 h 预测温室内是否会出现极

端低温,预测误差小于 0.8℃,此研究为单变量建模,温室内其它变量也可能对温度预测效果产生影响。

以上相关研究主要是针对温室内空气温度和湿度要素的监测和预测,而多维温室物联网数据存在体量大、计算成本高等特点,传统的 LSTM 模型在训练过程中依靠人工经验手动调节参数,通用性差、不确定性高,在处理高维数据时收敛速度较慢且容易陷入局部最优^[14]。麻雀搜索算法(SSA)是由 XUE 等^[15]提出,模拟了麻雀群觅食并逃避捕食者的行为而提出的群智能优化算法,其结构简单,在收敛速度和寻优精度等方面有着明显优势^[16]。考虑到温室物联网数据庞大、人工经验手动调节参数不确定性高特点,本文提出一种基于 SSA-LSTM 的温室环境预测模型,通过物联网采集温室不同区域的环境数据,将室内小气候历史环境数据按照时间序列构造输入矩阵,输入到 SSA-LSTM 模型进行训练,以实现日光温室多维环境数据的精准预测。

1 实验数据获取与处理

1.1 实验地点

实验地点位于山东农业大学(泮河校区)科技产业园区番茄日光温室(36.174°N,117.166°E),温室为下挖式新型日光温室,墙体采用砖加土垒基水泥加固,温室东西长 70.0 m,南北跨度 9.8 m,下挖深度 0.5 m,后墙高 3.8 m,脊高 5 m。

1.2 物联网数据采集系统

构建温室环境物联网数据采集系统,实时、准确获取环境信息,是实现温室环境预测的前提和保障。

物联网数据采集系统主要由 CPU、感知模块和传输模块等构成,感知模块完成对空气温度、相对湿度、CO₂ 浓度、光照强度及土壤温度和湿度的测量,采用传感器相关参数如表 1 所示;整体系统架构如图 1 所示。为保证对温室环境的有效监测,将多组传感器均匀布设在温室内,其布设示意图如图 2 所示;以东西方向 14 m、南北方向 2.5 m 为单位将温室

表 1 物联网传感器参数
Tab.1 Parameters of environmental sensors

传感器类型	型号	量程	精度	输出信号
空气温湿度传感器	DB-171	温度: -40 ~ 120℃	±0.1℃	4 ~ 20 mA
		相对湿度: 0 ~ 100%	±1.0%	
CO ₂ 传感器	EE820	0 ~ 2 000 μL/L	±50 μL/L	4 ~ 20 mA
光照传感器	TBQ-6	0 ~ 200 klux	±0.02 klux	4 ~ 20 mA
土壤传感器	5TE	温度: -40 ~ 60℃	±0.1℃	数字信号
		相对湿度: 0 ~ 80%	±0.08%	
		电导率: 0 ~ 23 dS/m	0.01 dS/m	




图 1 物联网系统架构图

Fig.1 System architecture of IOT




图 2 传感器布设示意图

Fig.2 Layout diagram of sensors

均匀划分布设平面,分别在高度 0.6、1.8、3.0 m 进行传感器布设;为保证数据及时有效处理,布置 3 套物联网系统,如图 2a 中 1#1 为第 1 套系统的第 1 个空气温湿度传感器,光 1 为第 1 个光照传感器,以此类推。传感器现场布设及物联网数据采集系统上位机界面如图 3 所示。



图 3 物联网数据采集系统

Fig.3 Data acquisition system of IoT

1.3 数据预处理

1.3.1 实验数据

通过上述物联网数据采集系统,自动采集空气温度、空气相对湿度、土壤温度、土壤湿度、CO₂ 浓度(体积比)和光照强度 6 种数据,通过 GPRS 网络上传至服务器,采样时间为 2020 年 8 月 1 日至 2021

年 7 月 31 日,采样间隔为 30 min,部分原始数据如图 4 所示(以 2020 年 9 月空气温度为例)。




图 4 部分原始数据

Fig.4 Part of original data

由图 4 可见,实验数据存在缺失,存在温度跳变至零的现象。分析实验数据可知,数据中的缺失部分主要来自两方面,一是当天的数据记录存在缺失,二是某些时间段的数据存在缺失。

1.3.2 缺失数据处理

考虑到训练数据、未来的测试数据中都可能存在缺失数据,而且它们的记录方式是相同的,避免预处理不同导致数据分布不一致问题的出现,同时对它们使用了相同的填充方式。由于存在多种缺失情况,仅使用一种方式填充可能会导致填充出现缺漏,因此本文同时使用了 forward fill、backward fill 与均值填充相结合的方式以保证填充覆盖率,填充前后数据对比如图 5 所示(以 2020 年 9 月数据为例)。由图 5 可见,填充后数据变化趋势保持一致,填充效果较好。

1.3.3 数据归一化

为使得不同特征的数据规范到一个统一的范围,有利于神经网络的反向传播(假如不进行规范化,神经网络可能会刻意捕捉不同批次数据的变化,而忽视了预测任务本身),采用 Min - Max 标准化方法对数据进行归一化处理^[17]。

2 SSA - LSTM 环境预测模型

2.1 麻雀搜索算法

SSA 是模拟麻雀群觅食并逃避捕食者的行为而提出的群智能优化算法^[15]。在觅食过程中,位置是麻雀的唯一属性,觅食麻雀分为发现者和跟随者,前者搜索并发现食物,后者跟随发现者觅食;发现者和跟随者的身份是动态变化的,但所占整个种群数量的比重是不变的。同时,觅食过程还叠加了侦查预警机制,当意识到危险时,群体边缘的麻雀会迅速向安全区域移动,以获得更好的位置。

在模拟实验中,使用虚拟麻雀进行食物的寻找,假设有 n 只麻雀, d 维待优化问题变量,适应度为 f ,则种群适应度可表示为




图5 填充前后数据对比

Fig. 5 Data comparison before and after filling

$$f_x = \begin{bmatrix} f([X_{1,1} & X_{1,2} & \cdots & X_{1,d}]) \\ f([X_{2,1} & X_{2,2} & \cdots & X_{2,d}]) \\ \vdots & \vdots & & \vdots \\ f([X_{n,1} & X_{n,2} & \cdots & X_{n,d}]) \end{bmatrix} \quad (1)$$

式中 $X_{n,d}$ ——第 n 只麻雀 d 问题变量的位置
在 SSA 中,发现者在种群中搜索具有丰富食物的区域,提供觅食的区域和方向,发现者迭代位置更新公式为

$$x_{i,d}^{(t+1)} = \begin{cases} x_{i,d}^{(t)} \exp\left(\frac{-i}{\alpha n_{\max}}\right) & (R_2 < T) \\ x_{i,d}^{(t)} + Q & (R_2 \geq T) \end{cases} \quad (2)$$

式中 $x_{i,d}^{(t)}$ ——种群中第 t 代中第 i 个麻雀的 d 维位置

- α —— $(0, 1]$ 中的均匀随机数
- $n_{\max}$ ——最大迭代次数
- R_2 ——预警值,取 $[0, 1]$ 中的均匀随机数
- T ——警戒阈值,取 $[0.5, 1]$
- Q ——标准正态分布随机数

可以看出,当 $R_2 \geq T$ 时,表示有麻雀发现了捕食者并发出了警报,此时所有麻雀都需要飞到安全位置进行觅食;当 $R_2 < T$ 时表示安全,可以进行搜索食物。

跟随者会时刻监视发现者,当它们察觉到发现者找到了更好的食物,它们会立即离开现在的位置去争夺食物,跟随者位置更新公式为

$$x_{i,j}^{(t+1)} = \begin{cases} Q \exp\left(\frac{X_{\text{worst}} - X_{i,j}^{(t)}}{\alpha n_{\max}}\right) & \left(i > \frac{n}{2}\right) \\ X_p^{(t+1)} + |X_{i,j} - X_p^{(t+1)}| A^+ L & \left(i \leq \frac{n}{2}\right) \end{cases} \quad (3)$$

其中 $A^+ = A^T (A A^T)^{-1}$

- 式中 X_p ——发现者占据的最优位置
- X_{worst} ——最差位置
- A ——1 行 D 列的矩阵,其每一维都随机从 $\{-1, 1\}$ 中选取

L ——元素均为 1 的 1 行 D 列的矩阵
当 $i > n/2$ 时,表明第 i 个跟随者没有获得食物,此时需要到其它地方觅食以获得较多能量;当 $i \leq n/2$ 时,其取值为当前最优的麻雀的位置加上该麻雀与最优位置每一维距离随机加减后,将总和均分到每一维上。该过程可以描述为在当前最优位置附近随机找一个位置,且每一维距最优位置的方差将会变得更小,即不会出现在某一维上与最优位置相差较大,而其他位置相差较小,其值收敛于最优位置。

在麻雀觅食过程中,10% ~ 20% 的麻雀会进行预警行为,如果有危险发生,它们会放弃食物而移动到一个新的位置,预警者位置更新公式为

$$x_{i,j}^{(t+1)} = \begin{cases} X_{\text{best}}^{(t)} + \beta |X_{i,j}^{(t)} - X_{\text{best}}^{(t)}| & (f_i > f_g) \\ X_{i,j}^{(t)} + K \left(\frac{|X_{\text{worst}}^{(t)} - X_{i,j}^{(t)}|}{f_i - f_w + \varepsilon} \right) & (f_i = f_g) \end{cases} \quad (4)$$

- 式中 X_{best} ——全局最优位置
- f_g, f_w ——全局最佳和最差适应度
- f_i ——当前麻雀适应度
- β ——符合标准正态分布的随机数
- K ——麻雀移动方向,属于 $[-1, 1]$ 中随机数
- ε ——一个较小非零数(防止分母取值为 0)

从式(4)可以看出, $f_i > f_g$ 表示该麻雀不在最优位置,容易受到攻击,它将移动到最优位置附近; $f_i = f_g$ 表示当前麻雀处于最优位置,它会移动到自身附近的一个位置,具体移动距离取决于自身位置与最差位置之差和自身适应度与最差适应度之差的比值。

2.2 长短期记忆人工神经网络

LSTM 来源于递归神经网络 (Recursive neural network, RNN)^[18], 可以学习长期依赖信息, 且在一定程度上解决梯度消失和梯度爆炸这两个问题。

如图 6a 所示, RNN 是重复单一的神经网络层, 在其隐藏块中只有一个内部操作, 例如一个 tanh 层, 作用在于帮助调节流经网络的值, 使得数值始终限制在 -1 ~ 1 之间。LSTM 中的重复模块则包含 4 个交互的层, 3 个 Sigmoid 和 1 个 tanh 层, 并以一种非常特殊的方式进行交互, 如图 6b 所示。




图 6 RNN 和 LSTM 结构

Fig. 6 Block of RNN and LSTM

LSTM 拥有遗忘门、输入门和输出门 3 种类型的门结构, 来去除或者增加信息到细胞状态, 其结构如图 7 所示^[19]。




图 7 LSTM 门结构

Fig. 7 Door structure of LSTM

遗忘门, 决定从细胞状态中丢弃的信息, 即

$$f_t = \sigma(W_f(h_{t-1}, x_t) + b_f) \quad (5)$$

式中 f_t ——遗忘门输出值 W_f ——权值

σ ——Sigmoid 激活函数

h_{t-1} ——上一个输出值

x_t ——当前输入值 b_f ——偏差

输入层, 用来确定被存放在细胞状态中的新信息, 包含两方面, 一是 Sigmoid 层称“输入门层”, 决定将要更新的值; 二是 tanh 层, 创建一个新的候选值向量, 会被加入到状态中。公式为

$$i_t = \sigma(W_i(h_{t-1}, x_t) + b_i) \quad (6)$$

$$\tilde{C}_t = \tanh(W_c(h_{t-1}, x_t) + b_c) \quad (7)$$

式中 i_t ——输入层门输出值

W_i ——输入层权值 b_i ——输入层偏差

$\tilde{C}_t$ ——细胞状态候选值

W_c ——候选值权值 b_c ——候选值偏差

细胞状态, 更新旧细胞状态的时间, C_{t-1} 更新为 C_t , 即

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (8)$$

输出门, 确定输出的值, 即

$$o_t = \sigma(W_o(h_{t-1}, x_t) + b_o) \quad (9)$$

$$h_t = o_t \tanh C_t \quad (10)$$

式中 o_t ——输出层门输出值

W_o ——输出层权值 b_o ——输出层偏差

h_t ——输出层输出

2.3 SSA 优化的 LSTM 温室环境预测模型

在 LSTM 模型中, 神经元个数、迭代次数、输入批量和学习率等超参数选择对模型拟合能力起着重要作用^[20], 而温室环境预测模型中输入数据是多维度的, 传统的 LSTM 靠人工经验进行调参, 效率低且准确性差, 为使模型的性能达到最优, 采用局部搜索能力极强, 收敛速度较快的 SSA 优化算法对模型超参数进行迭代选优, 算法流程图如图 8 所示, 具体步骤如下:

(1) SSA 参数设置。初始化麻雀种群参数, 包括麻雀种群数量、初始位置、最佳位置、全局最佳适应度等。将初始化的麻雀位置根据适应度函数评估麻雀位置并进行排序, 选取前 20% 作为发现者, 其余为跟随者, 随机选取 10% ~ 20% 的麻雀作为警戒者负责警戒和侦查。

(2) 根据麻雀数目与优化参数 (神经元个数、迭代次数、输入批量和学习率) 形成搜索空间矩阵并初始化相关参数, 设置最大迭代次数。

(3) 根据条件式 (1) ~ (3) 更新发现者、参与者、侦察者位置, 并以边界函数约束对 LSTM 所需超参数传参。

(4) 将返回结果通过适应度函数进行位置评估, 找出最优适应度个体及最劣适应度个体。若本次迭代中麻雀最佳适应度优于全局最佳适应度则用

其代替,否则不变。

(5)判断是否满足设定的达到误差和最大迭代次数的停止条件。若符合,则将全局最优超参数组设为 LSTM 的参数;若不符合,则返回步骤(3)。




图 8 SSA-LSTM 流程图

Fig. 8 Flow chart of SSA-LSTM

2.4 模型评价指标

为了直观地表示 SSA 优化后的模型预测能力,分别使用均方根误差 (RMSE)、平均绝对百分比误差 (MAPE) 以及拟合指数 R_f 作为预测模型性能评价指标^[21]。

3 实验结果与分析

3.1 实验平台

训练所使用的服务器环境如下: 处理器为 E5-2673V3 * 2, 内存 32 GB, GPU 显卡为 NVIDIA GTX3090 24G * 2, 操作系统 64 位 Windows 10, 编程软件为 Matlab R2021a。

3.2 SSA-LSTM 模型优化及训练

为更加精准地建立温室环境预测模型,采用多组传感器的平均值作为模型训练数据,实验数据采样时间为 2020 年 8 月 1 日至 2021 年 7 月 31 日,采样间隔 30 min,单环境参数数据约为 17 520 条,按 9:1 的比例将其划分为训练集和测试集。构建输入输出同为 6 参数的多维数据预测模型,同时对温室内 6 种参数进行训练和预测。

优化训练参数设置如下:SSA 中麻雀总数为

30,发现者占比 20%,警戒者占比 15%;隐含层神经元数 m 搜索范围 [100, 500],迭代次数搜索范围 [10, 200],输入批量搜索范围 [128, 1 024],学习率搜索范围 [10^{-5} , 10^{-2}];最大训练轮数设为 100。

训练过程中,利用 SSA 优化算法不断地调整 LSTM 中神经元个数、迭代次数、输入批量和学习率 4 个模型参数,预测结果的平均绝对百分比误差作为麻雀适应度,当适应度连续 3 轮没有变化时训练停止。优化结果如表 2 所示,训练 16 轮时达到最优适应度。

表 2 SSA-LSTM 优化结果

Tab. 2 Optimization results of SSA-LSTM

训练轮数	神经元数	迭代次数	输入批量	学习率	适应度/%
1	100	10	128	0.01	9.08
2	218	93	256	0.006 3	7.76
⋮	⋮	⋮	⋮	⋮	⋮
14	383	141	512	0.002 7	2.53
15	385	143	512	0.002 6	2.52
16	384	140	512	0.002 6	2.52

3.3 预测结果及对比分析

根据 SSA 优化结果设置 LSTM 模型参数,对日光温室空气温湿度、光照强度、CO₂ 浓度及土壤温湿度分别进行未来 21 d 预测,预测结果如图 9 所示。

为了更好地验证 SSA-LSTM 模型在多维温室环境数据预测中的优越性,同时利用 BP 神经网络、LSTM 及 GRU 模型对温室环境预测并对比分析。在相同运算环境的输入参数条件下,4 种模型环境预测性能的对比如表 3 所示。

由表 3 可知,采用 SSA-LSTM 模型对温室空气温湿度、土壤温湿度、CO₂ 浓度和光照强度 6 种参数进行预测,对空气温度预测拟合指数最高,为 98.2%,平均绝对百分比误差为 2.5%,均方根误差为 0.6℃;受人工灌溉等因素影响,对土壤相对湿度预测拟合指数相对偏低,为 96.8%,其 MAPE 为 3%,RMSE 为 0.7%。

采用了 SSA 自动进行参数选优方式的 SSA-LSTM,使模型预测性能发挥到极致,SSA-LSTM 的平均 MAPE 降低至 2.7%,相比 BP、GRU、LSTM 分别降低 6.3、3.2、3.4 个百分点;BP、GRU、LSTM 和 SSA-LSTM 拟合指数分别为 89.5%、93.5%、93.3% 和 97.6%,对比其它 3 种模型,SSA-LSTM 预测拟合指数分别提升 8.1、4.1、4.3 个百分点,模型预测性能最佳。




图 9 基于 SSA - LSTM 的温室环境预测结果

Fig.9 Greenhouse environment prediction results based on SSA - LSTM

表 3 4 种模型预测性能对比					Tab.3 Comparison results of four predictive model				
参数	模型	均方根 误差	平均绝对百 分比误差/%	拟合指 数/%	参数	模型	均方根 误差	平均绝对百 分比误差/%	拟合指 数/%
空气温度	BP	1.6℃	8.7	90.2	CO ₂ 浓度	BP	7.4 μL/L	8.8	90.1
	GRU	1.0℃	5.4	94.5		GRU	5.8 μL/L	5.5	94.2
	LSTM	1.1℃	5.6	94.1		LSTM	6.1 μL/L	5.8	93.9
	SSA - LSTM	0.6℃	2.5	98.2		SSA - LSTM	4.2 μL/L	2.6	98.0
空气相对湿度	BP	2.5%	8.9	89.5	光照强度	BP	1.7klux	9.1	89.3
	GRU	1.8%	6.4	92.5		GRU	1.1klux	5.8	93.6
	LSTM	1.8%	6.5	92.7		LSTM	1.2klux	5.9	93.1
	SSA - LSTM	1.1%	2.8	97.1		SSA - LSTM	0.7klux	2.7	97.4
土壤温度	BP	1.5℃	9.6	88.7	平均	BP		9.0	89.5
	GRU	0.8℃	6.4	92.6		GRU		5.9	93.5
	LSTM	0.9℃	6.4	92.9		LSTM		6.1	93.3
	SSA - LSTM	0.6℃	2.6	97.8		SSA - LSTM		2.7	97.6
土壤相对湿度	BP	1.2%	9.0	89.4					
	GRU	0.9%	6.1	93.3					
	LSTM	0.9%	6.2	93.0					
	SSA - LSTM	0.7%	3.0	96.8					

4 结论

(1)针对农业物联网数据体量大、维数爆炸、计算成本高,传统的 LSTM 在训练过程中依靠人工经验手动调节参数,处理高维数据时收敛速度慢且容易陷入局部最优等问题,本文提出一种基于 SSA 优化的 LSTM 温室环境预测模型,实现了温室空气温湿度、土壤温湿度、CO₂ 浓度及光照强度 6 种环境数

据的精准预测。
(2)与 BP 神经网络、GRU 及 LSTM 模型进行温室环境预测对比分析。实验结果表明:BP、GRU、LSTM 和 SSA - LSTM 拟合指数分别为 89.5%、93.5%、93.3% 和 97.6%,SSA - LSTM 的拟合效果明显提升。证明本研究提出的 SSA - LSTM 模型在温室环境数据预测中具有较高的优越性。

参 考 文 献

[1] 傅建行. 基于物联网的番茄温室环境智能调控系统设计与实现[D]. 泰安: 山东农业大学, 2020.

[2] 国家统计局. 2021 中国统计年鉴[J]. 北京: 中国统计出版社, 2021.

[3] 毛罕平, 晋春, 陈勇. 温室环境控制方法研究进展分析与展望[J]. 农业机械学报, 2018, 49(2): 1 - 13.

MAO Hanping, JIN Chun, CHEN Yong. Research progress and prospect on control methods of greenhouse environment[J].

- Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(2): 1–13. (in Chinese)
- [4] 赵建贵, 李志伟, 王文俊, 等. 日光温室番茄种植环境参数时空分布测试与分析[J]. 山西农业科学, 2019, 47(12): 2172–2176, 2181.
ZHAO Jiangui, LI Zhiwei, WANG Wenjun, et al. Spatial and temporal distribution test and analysis of tomato planting environment parameters in solar greenhouse[J]. Journal of Shanxi Agricultural Sciences, 2019, 47(12): 2172–2176, 2181. (in Chinese)
- [5] 张传帅, 徐岚俊, 李小龙, 等. 日光温室主要环境参数对番茄本体长势的影响[J]. 中国农业大学学报, 2019, 24(10): 118–124.
ZHANG Chuanshuai, XU Lanjun, LI Xiaolong, et al. Effects of main environmental parameters on the growth of tomato in solar greenhouse[J]. Journal of China Agricultural University, 2019, 24(10): 118–124. (in Chinese)
- [6] CHOAB N, ALLOUHI A, EL MAAKOUL A, et al. Review on greenhouse microclimate and application: design parameters, thermal modeling and simulation, climate controlling technologies[J]. Solar Energy, 2019, 191: 109–137.
- [7] 杨学坤, 韩柏和, 蒋晓. 日光温室系统模型的研究现状与对策[J]. 中国农机化学报, 2017, 38(4): 42–48.
YANG Xuekun, HAN Baihe, JIANG Xiao. Research status and countermeasures of solar greenhouse system model[J]. Journal of Chinese Agricultural Mechanization, 2017, 38(4): 42–48. (in Chinese)
- [8] SINGH M C, SINGH J P, SINGH K G. Development of a microclimate model for prediction of temperatures inside a naturally ventilated greenhouse under cucumber crop in soilless media[J]. Computers and Electronics in Agriculture, 2018, 154(2): 227–238.
- [9] 李康吉, 张世通, 孟凡跃, 等. 考虑时空变异特性的温室多环境因子优化策略[J]. 农业机械学报, 2021, 52(11): 343–350.
LI Kangji, ZHANG Shitong, MENG Fanyue, et al. Optimization strategy of greenhouse multiple environmental factors considering temporal and spatiotemporal variability[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(11): 343–350. (in Chinese)
- [10] 任延昭, 陈雪瑞, 贾敬敦, 等. 基于微信平台的温室环境监测与温度预测系统[J]. 农业机械学报, 2017, 48(增刊): 302–307.
REN Yanzhao, CHEN Xuerui, JIA Jingdun, et al. Environment monitoring and temperature prediction in greenhouse based on Wechat platform[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48 (Supp.): 302–307. (in Chinese)
- [11] 杜太行, 刘德, 孙曙光, 等. 基于模型预测的日光温室温度优化控制[J]. 中国测试, 2022, 48(1): 85–91.
DU Taihang, LIU De, SUN Shuguang, et al. Optimal temperature control of solar greenhouse based on MPC method[J]. China Measurement & Test, 2022, 48(1): 85–91. (in Chinese)
- [12] JUNG D H, KIM H S, JHIN C, et al. Time-serial analysis of deep neural network models for prediction of climatic conditions inside a greenhouse[J]. Computers and Electronics in Agriculture, 2020, 173(1): 105402.
- [13] GUILLEN N M Á, MARTINEZ E R, BUENO C A, et al. An LSTM deep learning scheme for prediction of low temperatures in agriculture[C]//Intelligent Environments (Workshops), 2019: 130–138.
- [14] 桑德罗 斯卡尼. 深入浅出深度学习[M]. 杨小冬, 译. 北京: 清华大学出版社, 2021.
- [15] XUE J K, SHEN B. Novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1): 22–34.
- [16] 李雅丽, 王淑琴, 陈倩茹, 等. 若干新型群智能优化算法的对比研究[J]. 计算机工程与应用, 2020, 56(22): 1–12.
LI Yali, WANG Shuqin, CHEN Qianru, et al. Comparative study of several new swarm intelligence optimization algorithms [J]. Computer Engineering and Applications, 2020, 56(22): 1–12. (in Chinese)
- [17] 刘建伟, 赵会丹, 罗雄麟, 等. 深度学习批归一化及其相关算法研究进展[J]. 自动化学报, 2020, 46(6): 1090–1120.
LIU Jianwei, ZHAO Huidan, LUO Xionglin, et al. Reaearch progress on batch normalization of deep learning and its related algorithms[J]. ACTA Automatic Sinica, 2020, 46(6): 1090–1120. (in Chinese)
- [18] 杨丽, 吴雨茜, 王俊丽, 等. 循环神经网络研究综述[J]. 计算机应用, 2018, 38(增刊2): 1–6, 26.
YANG Li, WU Yuxi, WANG Junli, et al. Research on recurrent neural network[J]. Journal of Computer Applications, 2018, 38(Supp. 2): 1–6, 26. (in Chinese)
- [19] 孙龙清, 吴雨寒, 孙希蓓, 等. 基于 IBAS 和 LSTM 网络的池塘水溶解氧含量预测[J]. 农业机械学报, 2021, 52(增刊): 252–260.
SUN Longqing, WU Yuhan, SUN Xibei, et al. Dissolved oxygen prediction model in ponds based on improved beetle antennae search and LSTM network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52 (Supp.): 252–260. (in Chinese)
- [20] 张永, 辛宇琪, 钱启政, 等. PSO 优化的 BiLSTM – Attention 网络的锂电池健康状态评估[J]. 控制工程, 2022, 29(2): 287–293.
ZHANG Yong, XIN Yuqi, QIAN Qizheng, et al. Estimation on sate of health for lithium-ion battery with PSO-optimized BiLSTM – Attention network[J]. Control Engineering of China, 2022, 29(2): 287–293. (in Chinese)
- [21] 李莉, 李文军, 马德新, 等. 基于 LSTM 的温室番茄蒸腾量预测模型研究[J]. 农业机械学报, 2021, 52(10): 369–376.
LI Li, LI Wenjun, MA Dexin, et al. Prediction model of transpiration of greenhouse tomato based on LSTM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(10): 369–376. (in Chinese)