

基于 SSA - LSTM 的玉米土壤含氧量预测模型

于珍珍¹ 邹华芬² 于德水³ 汪 春^{1,2} 刘天祥¹ 张欣悦¹

(1. 黑龙江八一农垦大学工程学院, 大庆 163319; 2. 中国热带农业科学院南亚热带作物研究所, 湛江 524003;
3. 华中科技大学管理学院, 武汉 430074)

摘要: 土壤含氧量(Soil oxygen content, SOC)是影响作物生长的重要土壤环境因素之一,具有时序性、不稳定性及非线性等特点,精确预测土壤环境中含氧量的变化趋势,有助于制定更加合理的土壤通气增氧方案。本研究提出基于麻雀搜索算法(Sparrow search algorithm, SSA)和长短时记忆(Long and short-term memory, LSTM)神经网络预测模型,利用国家土壤质量湛江观测实验站记录玉米种植期间的气象环境和土壤环境数据,基于 SSA - LSTM 模型对 SOC 变化进行预测及相关性分析,并与传统的 BP 预测模型、LSTM 预测模型、GA - LSTM 预测模型及 PSO - LSTM 预测模型进行对比。试验结果表明, SOC 与降雨量、土壤含水率、土壤温度、土壤充气孔隙度相关性极显著,相关系数高于 0.8,与大气温度和风速相关性显著,与大气湿度和土壤呼吸速率相关性较弱。SSA - LSTM 模型预测精度明显高于其他 4 组对照预测模型, R^2 达到 0.959 79, RMSE 仅为 0.491 7%, MAPE 为 3.733 1%, MAE 为 0.362 0%, 预测值与试验值之间的拟合程度高。本研究可为土壤含氧量变化的精准预测及土壤通气增氧技术的应用推广提供理论支撑与科学依据。

关键词: 玉米; 土壤; 含氧量预测; 麻雀搜索算法; 长短时记忆网络; BP 神经网络

中图分类号: S152.6 **文献标识码:** A **文章编号:** 1000-1298(2022)11-0360-09

OSID:



SSA - LSTM-based Model for Predicting Soil Oxygen Content in Maize

YU Zhenzhen¹ ZOU Huafen² YU Deshui³ WANG Chun^{1,2} LIU Tianxiang¹ ZHANG Xinyue¹

(1. College of Engineering, Heilongjiang Bayi Agricultural University, Daqing 163319, China
2. South Subtropical Crops Research Institute, Chinese Academy of Tropical Agricultural Sciences, Zhanjiang 524003, China
3. School of Management, Huazhong University of Science and Technology, Wuhan 430074, China)

Abstract: Soil oxygen content (SOC) is one of the important soil environmental factors that affect crop growth. It has the characteristics of time series, instability and nonlinearity. It can accurately predict the change trend of oxygen content in the soil environment, which is helpful to formulate a more reasonable soil aeration and oxygenation program. A prediction model based on the sparrow search algorithm (SSA) and long and short-term memory (LSTM) neural network was proposed, the meteorological environment and soil environment record data during the corn planting period were to recorded by using the equipment at the National Soil Quality Zhanjiang Observation and Experimental Station. The SSA - LSTM model predicted and analyzed the SOC changes, and it was compared with the traditional BP prediction model, LSTM prediction model, GA - LSTM prediction model and PSO - LSTM prediction model. The test results showed that the correlation between SOC and rainfall, soil water content, soil temperature and air-filled porosity was extremely significant, the correlation coefficient was higher than 0.8, the correlation with atmospheric temperature and wind speed was significant, and the correlation with atmospheric humidity and soil respiration rate was relatively significant. The prediction accuracy of the SSA - LSTM model was significantly higher than that of the other four groups of control prediction models. The R^2 reached 0.959 79, the RMSE was only 0.491 7%, the MAPE was 3.733 1%, and the MAE was 0.362 0%. The degree of fit between the predicted value and the experimental value was high. The research result

收稿日期: 2021 - 11 - 28 修回日期: 2022 - 01 - 20

基金项目: 海南省自然科学基金面上项目(322MS118)和海南省自然科学基金青年基金项目(322QN375)

作者简介: 于珍珍(1994—),女,博士生,主要从事旱作农业工程与信息技术研究,E-mail: yudq1994@hotmail.com

通信作者: 汪春(1963—),男,教授,博士生导师,主要从事旱作农业工程技术研究,E-mail: wangchun1963@126.com

can provide theoretical support and scientific basis for the accurate prediction of soil oxygen content changes and the application and promotion of soil aeration and oxygenation technology.

Key words: maize; soil; oxygen content prediction; sparrow search algorithm; long and short-term memory network; BP neural network

0 引言

土壤含氧量 (Soil oxygen content, SOC) 是影响作物生长发育的重要土壤环境因子, 土壤中水分、气体比例不协调是农业可持续发展的主要障碍, 也是影响我国生态环境健康和农业生产发展的重要制约因素^[1-2]。当 SOC 小于 10% 时, 作物有氧呼吸受阻或者中断, 作物水分和养分利用效率下降, 呼吸作用产生的三磷酸腺苷 (ATP, 高能磷酸化合物) 水平下降^[3-5]。植物地上部分则表现为叶片萎缩, 作物鲜质量和干质量显著下降, 是农作物高产的主要限制条件^[6-7], 加气灌溉技术是目前对土壤进行通气增氧的有效措施, 但是由于土壤环境复杂而不稳定, 土壤氧气含量变化具有时序性、不稳定性及非线性等特点, 通气增氧的相关参数尚未形成量化体系^[8-10]。SOC 容易受到气象因子 (大气温湿度、太阳辐射、降雨量等) 及土壤环境因子 (土壤温度、土壤含水率等) 的影响^[11-13], 各因素存在复杂的耦合关系, 因此, 建立 SOC 预测模型对于作物种植具有重要的生产意义, 也为土壤通气增氧技术的管理决策提供理论依据。

近几年人工神经网络迅速发展, 在解决函数逼近与数据预测等问题上效果良好^[14-16], 但是关于土壤含氧量预测方面的研究未见报道。关于水中溶解氧 (Dissolved oxygen, DO) 预测取得了一定的研究成果。长短时记忆 (Long and short-term memory, LSTM) 神经网络模型, 对长时间序列数据层具有较好的传递记忆功能, 可以深度挖掘长距离时序数据信息, 并且能消除反向梯度消失问题, 被广泛应用于各个领域^[17]。LIU 等^[18]利用注意机制和递归神经网络通过水温、大气相对湿度、太阳辐射等预测 DO。HUAN 等^[19]以 pH 值、水温、大气相对湿度等为影响因素, 采用基于梯度增强决策树 (GBDT) 特征选择的 LSTM 模型对 DO 进行预测; 陈英义等^[20]提出了基于 WT - CNN - LSTM 的溶解氧含量预测模型, 提高池塘溶解氧的预测精度, 后期, 曹守启等^[21]提出了基于 K-means 聚类和改进粒子群优化 (Improved particle swarm optimization, IPSO) 的 LSTM 神经网络预测模型, 该模型一定程度解决了天气突变状况下的数据缺失、鲁棒性差等问题。

LSTM 预测的准确性与其权重和阈值的设置密

切相关^[22-23]。生物启发式算法是 LSTM 参数优化的有效方法, 包括遗传算法 (Genetic algorithm, GA)^[24-26]、粒子群算法 (Particle swarm optimization, PSO)^[27-30]、蝙蝠算法 (Bat algorithm, BA)^[31]、灰狼优化算法 (Grey wolf optimizer, GWO)^[32-34] 和麻雀搜索算法 (Sparrow search algorithm, SSA)^[35-37]。其中, SSA 基于麻雀种群的觅食和反捕食行为, 解决模型输入权值和阈值的随机变化问题, 具有高性能全局搜索能力, 稳定性及收敛精度好。SSA 算法具有较快的收敛速度和强大的搜索能力, 采用网格搜索对 LSTM 神经网络模型的初始权值和阈值进行优化, 克服了传统神经网络模型参数选择的盲目性和不确定性, 目前, SSA 被广泛应用于非线性时间序列数据处理, 如短期风速预报、降雨分析预报, 在收敛速度和寻优精度等方面有着显著优势且结构简单、能准确应对复杂问题。

本研究提出 SSA - LSTM 神经网络模型预测土壤含氧量, 基于国家土壤质量湛江观测实验站 2021 年田间获取的气象因子及土壤环境因子, 通过皮尔逊相关系数 (Pearson correlation coefficient, Pearson) 及斯皮尔曼相关系数 (Spearman's rank correlation coefficient, Spearman) 明确土壤含氧量变化影响因子的主次顺序, 基于麻雀搜索算法优化建立 SSA - LSTM 神经网络预测模型, 并与传统的 BP 预测模型、LSTM 预测模型、GA - LSTM 预测模型及 PSO - LSTM 预测模型训练前后的精度及预测误差进行对比, 为探究土壤含氧量变化规律及土壤通气增氧技术整体管理措施调整及决策提供技术指导。

1 材料与方法

1.1 数据来源

研究区域位于广东省湛江市 (110°27'E, 21°16'N) 国家土壤质量湛江观测实验站, 年平均日照时间为 2 160 h, 无霜期为 350 d, 年平均气温为 23.2℃, 是典型的亚热带季风气候。试验时间为 2021 年 8 月 21 日—11 月 12 日, 季节性种植作物为玉米, 试验区及定位试验点如图 1 所示。

SOC 主要来自土壤与大气之间气体交换。土壤空气组成与大气空气组成近似 (表 1)。土壤 O₂ 浓度低于大气, 土壤和大气之间产生 O₂ 分压差, 在分压梯度的驱动下, O₂ 不断从大气向土壤空气扩散。




图 1 研究区域及定位试验点示意图

Fig.1 Schematic of study area and positioning experiment points

土壤与大气之间进行气体扩散和整体交换,使得土壤中保持一定量 O_2 (图 2a)。大气环境主要通过影响气体扩散进而影响 SOC。大气环境因素中, WILLEY 等^[10] 研究表明, 大气温度 (Atmospheric temperature, T_a) 变化是引起大气与土壤气体交换的主要因素, 同时发现, 随着风速 (Wind speed, SW) 和大气相对湿度 (Atmospheric humidity, RH) 的升高, SOC 也逐渐提高。

表 1 土壤空气与大气空气组成成分比较

Tab.1 Comparison of composition of soil air and atmospheric air

气体	O_2 体积 分数/%	CO_2 体积 分数/%	N_2 体积 分数/%	其他气体
近地区大气	20. 94	0. 03	78. 08	Ar、Ne、He、Kr 等
土壤空气	20. 03 ~ 18. 00	0. 15 ~ 0. 65	78. 00 ~ 80. 24	CH_4 、 H_2S 、 NH_3 等

土壤中连续的充气孔隙是作物根系-土壤-大气之间唯一的联系通道^[30]。土壤充气孔隙度 (Air-filled porosity, AFP) 充满了空气或水以及溶解的物质, 固体为根和固定植物结构提供支持, 水分满足作物蒸腾需求, 空气为作物根系 (和微生物) 呼吸提供氧气。 O_2 以溶解氧方式通过根外水膜扩散到根系表面, 最后, 氧气由根系表面扩散到根组织内, 用于维持土壤中一切生物化学过程正常进行 (图 2c)。田间灌溉和降雨 (Rainfall, RF) 会使土壤中持续存在饱和湿润区, 导致水分代替空气存在于土壤中, 进而限制了 SOC 的可利用性和移动性 (图 2d), 土壤 SOC 降低会导致作物根系土壤低氧胁迫, 土壤呼吸 (土壤中各项代谢活动) 将受到限制 (图 2b)。

土壤温度 (Soil temperature, T_s) 以多种方式影响土壤氧气的移动性与可利用性。首先, 氧气在水中的溶解度与溶液温度成反比^[11], 其次, 土壤温度通过影响土壤呼吸 (图 2d) (Soil respiration, Rs) 进




图 2 大气-土壤-作物之间 O_2 交换示意图

Fig.2 Schematics of O_2 exchange between atmosphere, soil and crop

而影响 SOC 的变化^[13]。土壤含水率 (Soil water content, Ws) 是影响 SOC 的关键因素。THONGBAI 等^[38] 和 BHATTARAI 等^[39] 的研究均表明较高的水分变化可以调控植物体内水分的再分配和改变土壤的透气性, 从而影响植物体和微生物的代谢活动, 最终导致 SOC 发生变化, 通过进一步采用关联系数法发现, 较高的土壤水分不但阻碍大气与土壤之间的气体交换, 直接导致 SOC 下降, 也会抑制 O_2 在作物根部周围运动^[11]。

因此, 本研究选取 T_a 、 RH 、 RF 、 SW 、 AFP 、 T_s 、 Rs 及 Ws 共 8 个指标作为输入, 以 SOC 作为输出构建网络模型进行训练和预测。

1.2 数据处理

气象数据采用小气候观测仪 (CAWS2000 型, 北京华云尚通科技有限公司), 采集的气象数据主要包括 T_a 、 RH 、 RF 和 SW ; 土壤温湿度 (T_s 和 Ws) 主要由浙江托普云农科技股份有限公司生产的 TZS-PHW-4G 型土壤多功能参数测定仪测定, 可以自动存储数据, 土壤温度测试范围为 $-40 \sim 100^\circ C$, 精度为 $\pm 0.5^\circ C$, 分辨率为 $0.1^\circ C$; 土壤含水率测试范围为 $0 \sim 100\%$, 精度小于等于 3% , 分辨率为 0.1% 。

SOC 采用 MO-200 型土壤氧气测定仪进行定位记录, 由于土壤深度 10 cm 左右与大气气体交换较为通畅, 一般不会出现缺氧现象, 而作物根系大部分分布在土壤深度 $30 \sim 40$ cm, 所以本试验选择测定深度为 30 cm。Rs 采用 Li-6400 型土壤呼吸仪测定。AFP 计算公式为

$$AFP = 1 - \rho_b / \rho_s - W_s$$
 (1)

式中 AFP ——土壤充气孔隙度, %

ρ_b ——土壤容重,取 1.32 g/cm³
 ρ_s ——土粒密度,取 1.75 g/cm³
 W_s ——土壤含水率, %

1.3 试验方法

相关试验参数在每日 07:00—09:00 之间进行测量,相关研究表明该时段测得的土壤呼吸、充气孔隙度等相关参数可以代表当日的平均值。人工测量时实时读取数据,如遇强降雨天气则推迟时间段进行测定。由于土壤含氧量的影响因素之一——土壤呼吸主要由作物根系呼吸及土壤微生物呼吸组成,因此,为了丰富数据来源,在玉米种植前 9 d(2021 年 8 月 12—20 日)进行裸地测量(此时,未进行玉米种植,土壤中不存在作物根系,微生物丰度也较低),玉米种植期间(2021 年 8 月 21 日—11 月 12 日)及玉米收获后 10 d(2021 年 11 月 12—21 日)进行裸地测量(此时,土壤中还存在一些玉米根茬及相关土壤微生物)。因此,本研究所测的 7 个试验地点共获得 682 组试验数据。其中 6 个试验地点土壤含氧量为训练样本,以 1 个试验地点数据作为验证,分别采用 BP 预测模型、LSTM 预测模型、PSO - LSTM 预测模型、GA - LSTM 预测模型以及 SSA - LSTM 预测模型进行预测,全文采用 Matlab 进行编程与模型建立。

2 预测模型构建

2.1 LSTM 神经网络模型构建

LSTM 最初是传统递归神经网络的变体。在处理时间序列预测时具有较强的记忆能力,被广泛应用于时间序列中具有长时间时间间隔和时滞的预测场景,LSTM 单元的基本结构如图 3a 所示。

LSTM 在神经网络的基础上增加了更多的神经网络层,增加了记忆单元、输入门、输出门和遗忘门 4 个具有记忆功能的模块,有选择地让信息通过,每个门的功能各不相同。

遗忘门 f_t 负责决定从记忆单元中丢弃哪些信息,更新公式为

$$f_t = \sigma(w_{fx}x_t + w_{fh}h_{t-1} + w_{fc}C_{t-1} + b_f) \quad (2)$$

式中 $\sigma(\cdot)$ ——sigmoid 的激活函数

x_t —— t 时刻输入

h_{t-1} —— $t - 1$ 时刻输出


C_{t-1} —— $t - 1$ 时刻候选向量

w_{fx} 、 w_{fh} 、 w_{fc} ——遗忘门权重系数


b_f ——遗忘门偏置

输入门 i_t 负责决定哪些信息可以保存在记忆单元中,更新公式为

$$i_t = \sigma(w_{ix}x_t + w_{ih}h_{t-1} + w_{ic}C_{t-1} + b_i) \quad (3)$$



(a) LSTM神经网络



(b) SSA优化的LSTM神经网络预测模型

图 3 预测模型

Fig. 3 Prediction model construction

$$\tilde{C}_t = \tanh(w_{cx}x_t + w_{ch}h_{t-1} + b_o) \quad (4)$$

$$C_t = f_t C_{t-1} + i_t \tilde{C}_t \quad (5)$$

式中 w_{ix} 、 w_{ih} 、 w_{ic} ——输入门权重系数

b_i ——输入门偏置

w_{cx} 、 w_{ch} ——候选向量的权重系数

b_o ——候选向量偏置

$\tanh(\cdot)$ ——双曲正切激活函数

$\tilde{C}_t$ ——候选向量更新值

C_t —— t 时刻的候选向量

输出门决定将输出哪些信息。除所需信息外,没有其他信息可以通过输出门。其表达式为

$$o_t = \sigma(w_{ox}x_t + w_{oh}h_{t-1} + w_{oc}C_{t-1} + b_o) \quad (6)$$

$$h_t = o_t \tanh(C_t) \quad (7)$$

式中 o_t ——输出门

w_{ox} 、 w_{oh} 、 w_{oc} ——输出门权重系数

h_t —— t 时刻输出

2.2 SSA 优化算法

SSA 是根据麻雀觅食和反捕食行为的启发而提出的新型群体智能优化算法。SSA 主要模拟了麻雀群体觅食的过程,每只麻雀都有 3 种可能的行为:发现者(搜索食物);加入者(跟随发现者觅食);侦察者(警戒侦查)。其中,发现者是麻雀中找到食物较早的个体,加入者则为其他个体,同时在麻雀种群中还有一定比例的个体进行侦察预警,它们的任务是在发现危险的情况下放弃食物,选择安全第一。

在模拟试验中,使用虚拟麻雀来寻找实物, n 只麻雀种群可以表示为

$$X = \begin{bmatrix} x_1^1 & x_1^2 & \cdots & x_1^d \\ x_2^1 & x_2^2 & \cdots & x_2^d \\ \vdots & \vdots & & \vdots \\ x_n^1 & x_n^2 & \cdots & x_n^d \end{bmatrix} \tag{8}$$

式中 d ——待优化变量维数

所有麻雀适应度可以表示为

$$F_x = \begin{bmatrix} f([x_{11} & x_{12} & \cdots & x_{1d}]) \\ f([x_{21} & x_{22} & \cdots & x_{2d}]) \\ \vdots \\ f([x_{n1} & x_{n2} & \cdots & x_{nd}]) \end{bmatrix} \tag{9}$$

式中 $f(x)$ ——适应度

SSA 算法中所有的生产者、具有较好适应度的发现者在搜索过程中会优先获取食物,并负责为种群寻觅食物以及为发现者、加入者和侦察者根据各自的规则更新喂食,表达式为

$$X_{ij}^{t+1} = \begin{cases} x_{ij} \exp\left(-\frac{i}{\alpha r_{\max}}\right) & (R_2 < S_T) \\ X_{ij}^t + QL & (R_2 \geq S_T) \end{cases} \tag{10}$$

式中 t ——当前迭代次数

$r_{\max}$ ——最大迭代次数,常数

X_{ij} ——第 i 只麻雀在第 j 维中的位置信息,
 $j = 1, 2, \cdots, d$

α ——随机数, $\alpha \in (0, 1]$

S_T ——安全值, $S_T \in [0.5, 1]$

R_2 ——警告值,当 $R_2 \leq S_T$ 时,发现者可以执行搜索操作,而当 $R_2 \geq S_T$,表示发现者种群发出预警,迅速飞离, $R_2 \in (0, 1]$

Q ——服从正态分布的随机数

L —— $L \times d$ 矩阵,矩阵中的每个元素均为 1

对于加入者执行

$$X_{ij}^{t+1} = \begin{cases} X_{best}^t + \beta |X_{ij}^t - X_{best}^t| & (f_i > f_g) \\ X_{ij}^t + K \left(\frac{|X_{ij}^t - X_{worst}^t|}{f_i - f_w + \varepsilon} \right) & (f_i = f_g) \end{cases} \tag{11}$$

式中 X_{best} ——当前最优位置

X_{worst} ——极差位置

β ——步长控制参数

K ——服从正态分布的随机数, $K \in [-1, 1]$,
其均值为 0,方差为 1

f_i ——当前麻雀的个体适应度

f_g, f_w ——当前全局最佳适应度和最差适应度

ε ——避免分母为零的最小常数

监视发现者同时随时准备与之竞争,否则执行

$$X_{ij}^{t+1} = \begin{cases} Q \exp\left(\frac{x_{worst}^t - x_{ij}^t}{\alpha r_{\max}}\right) & (i > n/2) \\ X_p^t + |X_{ij}^t - X_p^{t+1}| A^+ L & (i \leq n/2) \end{cases} \tag{12}$$

式中 X_p ——发现者所占据的最佳位置

A —— $1 \times d$ 矩阵,其中每个元素随机赋值为 1
或者 -1,且 $A^+ = A^T(AAY)^{-1}$

当 $i > n/2$,表示适应度较低的第 i 个加入者没有得到食物。

预警者一般占种群数量的 10% ~ 20%,按式(12)更新站位。

SSA 实现步骤如下:①初始麻雀数量并定义相关参数。②按照适应度进行顺序排列,找到当前最佳适应度个体和最差适应度个体。③利用式(10)更新麻雀(发现者)在适应度方面的位置。④使用式(12)更新晚期麻雀(scrounger)的适应度位置。⑤使用式(11)随机更新部分麻雀的位置。⑥获取当前更新位置。⑦如果新的位置比旧的位置好,则更新旧的位置。⑧重复步骤④~⑧。⑨输出最佳适应度和单个麻雀。

2.3 SSA - LSTM 组合预测模型

为了提高预测精度和稳定性,本文提出了一种混合模型 SSA - LSTM(图 3b),利用 SSA 优化 LSTM 的初始隐层节点数和学习率。SSA - LSTM 模型的主要步骤如下:

(1)模型初始化:初始化 SSA 的参数,包括麻雀种群位置、参数取值上下限及最大迭代次数。初始化 LSTM 结构,以 LSTM 模型的隐层节点数和学习率作为优化目标。

(2)目标函数建立:SSA 的目标函数是未经训练的 LSTM 模型预测值与实际值相比的均方根误差(RMSE)。

(3)优化:根据目标函数的结果更新麻雀的位置,当满足初始设定的迭代次数时,LSTM 的初始值达到最优。

(4)LSTM 训练:将寻优后求得的最优参数代入 LSTM 模型,重新进行训练和预测,得到最终的预测模型。

2.4 模型性能评估

为了定量评估 SSA - LSTM 优化的神经网络预测模型的有效性和准确性,采用均方根误差 (RMSE)、平均绝对误差 (MAE) 和平均误差 (MAPE) 进行模型评估。

3 结果与分析

3.1 土壤含氧量变化及影响因子相关性分析

由 8 个影响因子与 SOC 的 Pearson 相关系数可知,SOC 与 RF、Ws、Ts 和 AFP 相关性极显著,相关系数均高于 0.8,与 Ta、SW 相关性显著,与 RH、Rs 相关性较弱 (图 4)。




图 4 SOC 与影响因子的 Pearson 相关系数

Fig.4 Pearson correlation coefficient of SOC and impact factor




图 5 不同神经网络模型的预测曲线

Fig.5 Prediction curves of different neural network models

考虑到大气温度与土壤温度对 SOC 的影响有一定的滞后效应,大气温度的变化对土壤温度产生直接影响,土壤温度的变化对土壤中的运动、土壤中各项生化活动产生影响,进而对 SOC 的变化产生影响,所以考虑滞后效应,修正后大气温度相关系数由 0.43 提升至 0.51,土壤温度相关系数由 -0.72 提升至 -0.81。

3.2 算法参数设置

通过前期试验,采用试凑法得到本次试验设置的 BP 预测模型中相应参数:最大迭代次数为 500,隐层节点数目为 25,训练精度为 0.000 01,学习率设置为 0.1;SSA 算法优化 LSTM 网络的两个参数为隐藏神经元数和学习率,将 SOC 真实数据与预测数据的均方根误差作为适应度函数。同时设置麻雀种群数量为 20,迭代次数为 50,神经元个数 m 设置范围为 $[1,100]$,学习率为 $[0.000\ 1,0.01]$,经过 SSA 算法优化后隐藏神经元数和学习率的取值为 30、0.008 5;设置 GA 算法的种群规模为 20,交叉概率为 0.3,变异概率为 0.1,迭代次数为 50;设置 PSO 算法中种群迭代次数为 50,规模为 20,参数 c_1 和 c_2 均为 1.8。

3.3 模型预测对比分析

根据所测数据,构建基于 BP 预测模型、LSTM 预测模型、GA - LSTM 预测模型、PSO - LSTM 预测模型、SSA - LSTM 预测模型共 5 种预测模型,各模型对 SOC 预测结果如图 5 所示。由图 5a、5b 可以看出,BP 预测模型及 LSTM 预测模型预测误差较

大。PSO-LSTM 预测模型在土壤含氧量 9.6%~12.5% 的范围内模型预测误差较大;GA-LSTM 预测模型具有良好的收敛性,当土壤含氧量高于 14.2% 时,会出现较大的误差,且遗传算法步骤复杂,运算繁琐。SSA-LSTM 预测模型具有良好的适应性和预测精度(图 5e),实测值与预测值曲线拟合更接近,说明 SSA-LSTM 预测模型具有更好的拟合效果和泛化能力,体现了优化算法的相对优越性。

为了验证 5 种模型的预测性能,验证数据的实测值与预测值的相关系数曲线如图 6 所示。不同网

络模型的拟合程度由高到低依次为 SSA-LSTM 预测模型、GA-LSTM 预测模型、PSO-LSTM 预测模型、LSTM 预测模型、BP 预测模型。SSA-LSTM 预测模型回归拟合较好,相关系数 R 增加到 0.979 69,决定系数 R^2 增加到了 0.959 79,与传统的 BP 预测模型、LSTM 预测模型、GA-LSTM 预测模型及 PSO-LSTM 预测模型相比,SSA-LSTM 算法的 R 分别提高 5.52%、2.30%、0.28%、1.25%, R^2 提高 10.74%、4.55%、0.56%、2.48%。

对 5 种预测模型的预测结果进行量化,并利用




图6 不同神经网络模型预测值与实测值间的相关性分析

Fig. 6 Correlation analysis between predicted and measured values of different neural network models

模型评价指标对模型进行对比分析(表 2)。与传统的 BP 预测模型、LSTM 预测模型、GA-LSTM 预测模型及 PSO-LSTM 预测模型相比,SSA-LSTM 模型的 RMSE 分别降低 58.64%、42.40%、20.04%、42.32%,MAPE 分别降低 59.85%、44.16%、4.02%、41.21%,MAE 分别降低 58.22%、43.70%、2.45%、38.26%。

表2 BP 预测模型、LSTM 预测模型和 SSA-LSTM 预测模型性能分析

Tab.2 Performance analysis of BP, LSTM and SSA-LSTM prediction models				%
模型	RMSE	MAPE	MAE	
BP	1.188 8	9.298 0	0.866 4	
LSTM	0.853 6	6.685 1	0.643 0	
GA-LSTM	0.590 2	3.883 0	0.370 9	
PSO-LSTM	0.699 7	5.271 6	0.500 5	
SSA-LSTM	0.491 7	3.733 1	0.362 0	

3.4 模型预测误差分析

不同模型的预测误差分布如图 7 所示。以分布误差为 0 的分界线,向两端扩散增大,0 轴表示真实值与预测值结果一致,越接近 0,代表预测值与实测值的差值越小,模型的预测精度越高。从图 7 可以看出,与 BP、LSTM 预测模型相比,GA-LSTM、PSO-LSTM 及 SSA-LSTM 预测模型的误差直方图误差接近 0 的个数更多且误差更小。其中,在组合预测模型里,本文所提出的 SSA-LSTM 模型在零区间分布的数量更多,误差更小,其他组合模型 GA-LSTM、PSO-LSTM 在零区间分布个数分别为 48 和 38,误差较大。

4 结论

(1)利用 SSA 搜索算法优化后的 LSTM 神经网络预测模型,采用网格搜索对 LSTM 神经网络模型的隐层节点数和学习率进行优化,克服了传统神经




图 7 不同神经网络模型预测误差分布图

Fig. 7 Forecast error distributions of different neural network models

网络模型参数选择的盲目性和不确定性,提高了搜索精度、收敛速度和预测稳定性。

(2)通过对所选影响因子与 SOC 的 Pearson 相关系数分析可知,SOC 与 RF、Ws、Ts 和 AFP 相关性极显著,相关系数均高于 0.8,与大气温度、风速相关性显著,与大气湿度和土壤呼吸速率相关性较弱,其中,土壤呼吸是吸收 O₂ 排出 CO₂ 的过程,呼吸强度不仅受到土壤非生物因子的影响,更多地是受到生物因子的制约,主要与土壤中的根系、微生物数量有关,因此,土壤呼吸速率与 SOC 的相关性较弱。

(3) 将 BP 预测模型、LSTM 预测模型、GA - LSTM 预测模型、PSO - LSTM 预测模型和 SSA - LSTM 神经网络模型进行 SOC 预测分析,SSA - LSTM 预测模型比其他神经网络模型表现出更好的预测性能。经过不断迭代训练,SSA - LSTM 网络模型预测精度 R^2 达到 0.959 79, RMSE 仅为 0.491 7%, MAPE 为 3.733 1%, MAE 为 0.362 0%,预测值与试验值之间的拟合程度高。研究结果为土壤氧气含量的预测提供一种新的思路和方法,为土壤通气增氧技术提供理论依据与基础。

参 考 文 献

[1] 朱艳. 温室番茄生长和根区土壤微环境对加气灌溉的响应机制[D]. 杨凌:西北农林科技大学,2020.
ZHU Yan. Response mechanism of the growth and soil micro-environment in root zone of greenhouse tomato to oxygation[D]. Yangling:Northwest A&F University, 2020. (in Chinese)

[2] 刘恬恬. 加气地下滴灌对温室番茄生长发育和养分积累的影响研究[D]. 泰安:山东农业大学,2019.
LIU Tiantian. Effect of aerated subsurface drip irrigation on growth and nutrient accumulation of greenhouse tomato[D]. Taian: Shandong Agricultural University, 2019. (in Chinese)

[3] ZHU Y, DYCK M, CAI H J, et al. The effects of aerated irrigation on soil respiration, oxygen, and porosity[J]. Journal of Integrative Agriculture, 2019,18: 2854 - 2868.

[4] 于珍珍,汪春,王宏轩,等. 增氧灌溉系统的优化设计[J]. 农机化研究,2019,41(10):106 - 110.
YU Zhenzhen, WANG Chun, WANG Hongxuan, et al. Optimization design of aerobic irrigation system[J]. Journal of Agricultural Mechanization Research, 2019,41(10):106 - 110. (in Chinese)

[5] 李元,牛文全,张明智,等. 加气灌溉对大棚甜瓜土壤酶活性与微生物数量的影响[J]. 农业机械学报,2015,46(8):121 - 129.
LI Yuan, NIU Wenquan, ZHANG Mingzhi, et al. Effect of aeration on rhizosphere soil enzyme activities and soil microbes for muskmelon in plastic greenhouse[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(8): 121 - 129. (in Chinese)

[6] 臧明. 水肥气耦合滴灌下土壤-作物响应机理研究[D]. 郑州:华北水利水电大学,2020.
ZANG Ming. Study on the influencing mechanism of water-fertilizer-air coupling drip irrigation on soil - crop system[D]. Zhengzhou: North China University of Water Conservancy and Hydropower, 2020. (in Chinese)

[7] 于珍珍. 水肥气耦合调控土壤环境对玉米生长影响的研究[D]. 大庆:黑龙江八一农垦大学,2020.
YU Zhenzhen. Study on the effect of water, fertilizer and gas coupling on the soil growth and control of maize growth[D]. Daqing: Heilongjiang Bayi Agricultural University, 2020. (in Chinese)

[8] 朱艳,蔡焕杰,宋利兵,等. 加气灌溉下气候因子和土壤参数对土壤呼吸的影响[J]. 农业机械学报,2016,47(12):223 - 232.

- ZHU Yan, CAI Huanjie, SONG Libing, et al. Effects of climatic factors and soil parameters on soil respiration under oxygation conditions[J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(12): 223–232. (in Chinese)
- [9] 张文正, 翟国亮, 王晓森, 等. 微纳米加气灌溉对温室番茄生长、产量和品质的影响[J]. 灌溉排水学报, 2017, 36(10): 24–27.
- ZHANG Wenzheng, ZHAI Guoliang, WANG Xiaosen, et al. Aerating irrigation with mixed nano-micro air bubbles increases growth, yield and quality of greenhouse tomato[J]. Journal of Irrigation and Drainage, 2017, 36(10): 24–27. (in Chinese)
- [10] WILLEY C R, TANNER C B. Membrane covered electrode for measurement of oxygen concentration in soil[J]. Soil Sci. Soc. Am., 1996, 27(6): 511–515.
- [11] 王振华, 陈潇洁, 吕德生, 等. 水肥耦合对加气滴灌加工番茄产量及品质的影响[J]. 农业工程学报, 2020, 36(19): 66–75.
- WANG Zhenhua, CHEN Xiaojie, LÜ Desheng, et al. Effects of water and fertilizer coupling on the yield and quality of processing tomato under aerated drip irrigation[J]. Transactions of the CSAE, 2020, 36(19): 66–75. (in Chinese)
- [12] BHATTARAI S P, HUBER S, MIDMORE D J. Aerated subsurface irrigation water gives growth and yield benefits to zucchini, vegetable soybean and cotton in heavy clay soils[J]. Ann. Appl. Biol., 2004, 144: 285–298.
- [13] BHATTARAI S P, MIDMORE D J. Oxygation enhances growth, gas exchange and salt tolerance of vegetable soybean and cotton in a saline vertisol[J]. Integr. Plant Biol., 2009, 51: 675–688.
- [14] 胡星, 王千祥. 深度学习在缺陷修复者推荐中的应用[J]. 计算机科学与探索, 2017, 11(5): 700–707.
- HU Xing, WANG Qianxiang. Application of deep learning in recommendation of bug reports assignment[J]. Journal of Frontiers of Computer Science and Technology, 2017, 11(5): 700–707. (in Chinese)
- [15] LIANG Haibo, ZOU Jialing, LIANG Wenlong. An early intelligent diagnosis model for drilling overflow based on GA BP algorithm[J]. Cluster Comput., 2019, 22(5): 10649–10668.
- [16] 闫重熙, 陈皓. 基于改进天牛须搜索算法优化 LSSVM 短期电力负荷预测方法研究[J]. 电测与仪表, 2020, 57(6): 6–11, 18.
- YAN Chongxi, CHEN Hao. Research of LSSVM short-term load forecasting method based on the improved beetle antennae search algorithm[J]. Electrical Measurement & Instrumentation, 2020, 57(6): 6–11, 18. (in Chinese)
- [17] 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)
- [18] LIU Y, ZHANG Q, SONG L, et al. Attention-based recurrent neural networks for accurate short-term and long-term dissolved oxygen prediction[J]. Computers and Electronics in Agriculture, 2019, 165: 104964.
- [19] HUAN J, LI H, LI M, et al. Prediction of dissolved oxygen in aquaculture based on gradient boosting decision tree and long short-term memory network: a study of Changzhou fishery demonstration base, China[J]. Computers and Electronics in Agriculture, 2019, 175: 105–123.
- [20] 陈英义, 方晓敏, 梅思远, 等. 基于 WT-CNN-LSTM 的溶解氧含量预测模型[J]. 农业机械学报, 2020, 51(10): 284–291.
- CHEN Yingyi, FANG Xiaomin, MEI Siyuan, et al. Dissolved oxygen prediction model based on WT-CNN-LSTM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(10): 284–291. (in Chinese)
- [21] 曹守启, 周礼馨, 张铮. 采用改进长短时记忆神经网络的水产养殖溶解氧预测模型[J]. 农业工程学报, 2021, 37(14): 235–242.
- CAO Shouqi, ZHOU Lixin, ZHANG Zheng. Prediction model of dissolved oxygen in aquaculture based on improved long short-term memory neural network[J]. Transactions of the CSAE, 2021, 37(14): 235–242. (in Chinese)
- [22] SADAIE H J, E SILVA P C D L, GUIMARÃES F G, et al. Short-term load forecasting by using a combined method of convolutional neural networks and fuzzy time series[J]. Energy, 2019, 175: 365–377.
- [23] LEE D, BALDICK R. Short-term wind power ensemble prediction based on Gaussian processes and neural networks[J]. IEEE Transactions on Smart Grid, 2013, 5(1): 501–510.
- [24] 叶绍干, 葛纪刚, 侯亮, 等. 基于遗传算法的轴向柱塞泵配流盘密封环结构多目标优化[J]. 农业机械学报, 2022, 53(1): 441–450.
- YE Shaogan, GE Jigang, HOU Liang, et al. Multi-objective optimization of cylinder/valve-plate sealing ring in axial piston pump based on genetic algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(1): 441–450. (in Chinese)
- [25] 李修华, 李婉, 张木清, 等. 基于田间环境及气象数据的甘蔗产量预测方法[J]. 农业机械学报, 2019, 50(增刊): 233–236.
- LI Xiuhua, LI Wan, ZHANG Muqing, et al. Sugarcane yield prediction method based on field environmental and meteorological data[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(Supp.): 233–236. (in Chinese)
- [26] 孙洁, 崔婷婷, 刘晓悦, 等. PSO-GA 优化 ELM 的高炉铁水硅含量预测[J]. 机械设计与制造, 2022(3): 228–232, 237.
- SUN Jie, CUI Tingting, LIU Xiaoyue, et al. Prediction of silicon content in blast furnace hot metal by PSO-GA optimized ELM[J]. Machinery Design & Manufacture, 2022(3): 228–232, 237. (in Chinese)
- [27] 庄肖波, 李耀明, 王曜, 等. 基于粒子群算法的混联机构神经网络自适应反演控制[J]. 农业机械学报, 2020, 51(增刊1): 576–583.
- ZHUANG Xiaobo, LI Yaoming, WANG Yao, et al. Neural network adaptive backstepping control of hybrid mechanism based on PSO[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(Supp. 1): 576–583. (in Chinese)
- [28] 王宽, 李萍, 汤航, 等. 基于改进粒子群算法优化 BP 网络的短期风电功率预测[J]. 工业控制计算机, 2021, 34(11): 119–121.
- WANG Kuan, LI Ping, TANG Hang, et al. Short-term wind power prediction based on improved particle swarm optimization BP network[J]. Industrial Control Computer, 2021, 34(11): 119–121. (in Chinese)
- [29] 邓涛, 卢任之, 李亚南, 等. 运用改进 PSO 算法的驾驶员自适应方向与速度综合控制优化研究[J]. 重庆理工大学学报(自然科学), 2015, 29(8): 12–17.
- DENG Tao, LU Renzhi, LI Ya'nan, et al. Optimization for driver model of integrated control of direction and speed based on improved PSO algorithm[J]. Journal of Chongqing University of Technology (Natural Science), 2015, 29(8): 12–17. (in Chinese)

- [J]. Food Chemistry, 2018, 240: 32–42.
- [14] 邵园园, 王永贤, 玄冠涛, 等. 基于高光谱成像的肥城桃品质可视化分析与成熟度检测[J]. 农业机械学报, 2020, 51(8): 344–350.
SHAO Yuanyuan, WANG Yongxian, XUAN Guantao, et al. Visual detection of SSC and firmness and maturity prediction for Feicheng peach by using hyperspectral imaging[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(8): 344–350. (in Chinese)
- [15] 陈东杰, 姜沛宏, 郭风军, 等. 不同速度对近红外光谱预测库尔勒香梨品质模型的影响[J]. 光谱学与光谱分析, 2020, 40(6): 1839–1845.
CHEN Dongjie, JIANG Peihong, GUO Fengjun, et al. Effect of prediction model of kolar pear based on NIR diffuse transmission under different moving speed on online[J]. Spectroscopy and Spectral Analysis, 2020, 40(6): 1839–1845. (in Chinese)
- [16] 薛志祥, 余旭初, 谭熊, 等. 局部超图拉普拉斯约束的高光谱影像低秩表示去噪方法[J]. 光学学报, 2017, 37(5): 77–85.
XUE Zhixiang, YU Xuchu, TAN Xiong, et al. Local hypergraph laplacian regularized low-rank representation for noise reduction of hyperspectral images[J]. Acta Optica Sinica, 2017, 37(5): 77–85. (in Chinese)
- [17] ZHU R, DONG M, XUE J H. Spectral nonlocal restoration of hyperspectral images with low-rank property[J]. IEEE Journal of Selected Topics in Applied Earth Observations & Remote Sensing, 2014, 8(6): 3062–3067.
- [18] LIU Z, HE Y, CEN H, et al. Deep feature representation with stacked sparse auto-encoder and convolutional neural network for hyperspectral imaging-based detection of cucumber defects[J]. Transactions of the ASABE, 2018, 61(2): 425–436.
- [19] YU J, HUANG D, WEI Z. Unsupervised image segmentation via stacked denoising auto-encoder and hierarchical patch indexing[J]. Signal Processing, 2017, 143: 346–353.
- [20] WANG N, ZHOU W, WANG J, et al. Transformer meets tracker: exploiting temporal context for robust visual tracking[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 1571–1580.
- [21] YAN B, PENG H, FU J, et al. Learning spatio-temporal transformer for visual tracking[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 10448–10457.
- [22] LIU Z, LIN Y, CAO Y, et al. Swin transformer: hierarchical vision transformer using shifted windows[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 10012–10022.
- [23] 龚韬. 基于低秩表示与张量分解的高光谱降噪算法研究[D]. 北京: 中国科学院大学, 2020.
GONG Tao. Research on hyperspectral denoising algorithm based on low rank representation and tensor decomposition[D]. Beijing: University of Chinese Academy of Sciences, 2020. (in Chinese)
- [24] FAN H, CHEN Y, GUO Y, et al. Hyperspectral image restoration using low-rank tensor recovery[J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017, 10(10): 4589–4604.
- [25] MARCO J, HERNANDEZ Q, MUNOZ A, et al. DeepToF: off-the-shelf real-time correction of multipath interference in time-of-flight imaging[J]. ACM Transactions on Graphics, 2018, 36(6): 1–12.

(上接第 368 页)

- [30] 滕峰成, 王珊珊, 杨雪璠, 等. 基于 PSO 算法的 GMM 改进 J-A 磁滞模型的参数辨识与验证[J]. 计量学报, 2021, 42(9): 1193–1199.
TENG Fengcheng, WANG Shanshan, YANG Xuepan, et al. Parameter identification and verification of improved J-A hysteresis model of GMM based on PSO algorithm[J]. ACTA Metrologica Sinica, 2021, 42(9): 1193–1199. (in Chinese)
- [31] ALSALIBI B, ABUALIGAH L, KHADER A T. A novel bat algorithm with dynamic membrane structure for optimization problems[J]. Appl. Intell., 2021, 51(4): 1992–2017.
- [32] ALTAN A, KARASU S, ZIO E. A new hybrid model for wind speed forecasting combining long short-term memory neural network, decomposition methods and grey wolf optimizer[J]. Applied Soft Computing, 2021, 100(11): 25–39.
- [33] NADIMI-SHAHRABI M H, TAGHIAN S, MIRJALILI S. An improved grey wolf optimizer for solving engineering problems[J]. Expert Systems with Applications, 2021, 166: 113917.
- [34] 李伟中, 孔令成, 王美玲. 结合模糊逻辑的自适应灰狼优化算法[J]. 小型微型计算机系统, 2021, 42(10): 2023–2030.
LI Weizhong, KONG Lingcheng, WANG Meiling. Adaptive gray wolf optimization algorithm combined with fuzzy logic[J]. Journal of Chinese Computer Systems, 2021, 42(10): 2023–2030. (in Chinese)
- [35] WU Y H, SUN L Q, WANG B N. A hybrid XGBoost-SSA-LSTM model for accurate short-term and long-term dissolved oxygen prediction in ponds[J]. Environmental Science and Pollution Research, 2021, 9(5): 863–876.
- [36] XUE J K, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1): 269–284.
- [37] ZHANG C L, DING S F. Stochastic configuration network based on chaotic sparrow search algorithm[J]. Knowledge Based Systems, 2021, 220(23): 1103–1116.
- [38] THONGBAI P, MILROY S, BANGE M, et al. Agronomic responses of cotton to low soil oxygen during waterlogging[C]// 10th Australian Agronomy Conference, Hobart, Tasmania, 2001: 185–190.
- [39] BHATTARAI S P, MCHUFH A D, LOTZ G, et al. Cotton under subsurface drip and furrow irrigation in a heavy clay soil[J]. Aust. J. Exp. Agr., 2005, 18(3): 1321–1329.