

基于多模型融合策略的温室番茄光合速率预测方法

刘 潭^{1,2} 朱洪锐¹ 袁青云¹ 王永刚¹ 张大鹏¹ 丁小明³

(1. 沈阳农业大学信息与电气工程学院, 沈阳 110866; 2. 辽宁省农业信息化工程技术研究中心, 沈阳 110866;
3. 农业农村部规划设计研究院, 北京 100125)

摘要: 温室番茄光合速率的准确预测对于番茄的生长和产量评估具有重要意义。然而, 由于温室环境的复杂性和多变性, 传统的光合速率预测模型往往难以满足精准预测的需求。因此, 为了进一步提高预测模型的准确性和稳定性, 本研究提出了一种基于多模型融合策略的温室番茄光合速率预测方法。首先, 采集温湿度、光照强度、CO₂浓度不同组合下的番茄光合速率, 构建样本集, 并采用五折交叉验证法 (Cross-Validation) 对数据进行预处理。以预处理的数据为基础, 分别基于粒子群优化支持向量机 (PSO-SVR)、布谷鸟优化极限学习机 (CS-ELM) 和北方苍鹰优化高斯过程回归 (NGO-GPR) 算法建立番茄光合速率预测模型对光合速率进行初步预测, 然后采用 Stacking 算法通过基于决策树的集成学习模型 (XGBoost) 组合各基础模型的预测结果, 进而实现多模型融合。仿真分析结果表明, 与单一预测模型相比, 基于多模型融合的光合速率预测模型充分发挥了各基础模型的优势, 可以进一步提高光合速率预测的准确性和稳定性, 该模型验证集 MAE 为 0.569 7 $\mu\text{mol}/(\text{m}^2 \cdot \text{s})$, RMSE 为 0.721 4 $\mu\text{mol}/(\text{m}^2 \cdot \text{s})$ 。因此, 本文提出的方法在温室作物光合速率预测方面具有一定的优势, 可为温室番茄等作物光环境优化调控提供一定的理论基础和技术支撑。

关键词: 温室; 番茄; 光合速率预测; 极限学习机; 高斯过程回归; 多模型融合

中图分类号: S126; S641.2 文献标识码: A 文章编号: 1000-1298(2024)04-0337-09

OSID:



Prediction of Photosynthetic Rate of Greenhouse Tomatoes Based on Multi-model Fusion Strategy

LIU Tan^{1,2} ZHU Hongrui¹ YUAN Qingyun¹ WANG Yonggang¹ ZHANG Dapeng¹ DING Xiaoming³

(1. College of Information and Electrical Engineering, Shenyang Agricultural University, Shenyang 110866, China

2. Liaoning Engineering Research Center for Information Technology in Agriculture, Shenyang 110866, China

3. Academy of Agricultural Planning and Engineering, Ministry of Agriculture and Rural Affairs, Beijing 100125, China)

Abstract: Accurately predicting the photosynthetic rate of greenhouse tomatoes is crucial for evaluating their growth and yield. However, due to the complexity and variability of the greenhouse environments, traditional photosynthetic rate prediction models often fail to meet the demand of precise prediction. To address this issue and enhance the accuracy and stability of prediction model, a multi-model fusion strategy for predicting the photosynthetic rate of greenhouse tomatoes was proposed. Initially, the photosynthetic rate of tomato was collected under various combinations of temperature, humidity, light intensity, and carbon dioxide concentration, and a sample set was constructed. The data was preprocessed by using five-fold cross-validation method. Based on preprocessed data, prediction models for tomato photosynthetic rate were established by using particle swarm optimization-support vector regression (PSO-SVR), cuckoo search optimization-extreme learning machine (CS-ELM), and northern goshawk optimization-Gaussian process regression (NGO-GPR) algorithms, and preliminary predictions were made. Next, the Stacking algorithm was used to combine the predictions of the basic models through training an ensemble tree meta-model (XGBoost), thereby achieving multi-model fusion.

收稿日期: 2023-08-18 修回日期: 2023-10-10

基金项目: 辽宁省教育厅面上项目 (LJKMZ20221035、LJKZ0683)、辽宁省科技厅面上项目 (2023-MS-212)、国家自然科学基金项目 (32001415、61673281) 和辽宁省自然基金指导计划项目 (2019-ZD-0720)

作者简介: 刘潭 (1985—), 男, 副教授, 博士, 主要从事智能优化算法和农业遥感研究, E-mail: liutan_0822@126.com

通信作者: 袁青云 (1986—), 女, 讲师, 博士, 主要从事智能优化和温室环境调控研究, E-mail: yqy8_29@126.com

The results of simulation analysis demonstrated that compared with a single prediction model, the photosynthetic rate prediction model based on multi-model fusion effectively utilized the advantages of the basic models, enhancing the accuracy and stability of predicting photosynthetic rate. The MAE of the validation set for the model was $0.569\ 7\ \mu\text{mol}/(\text{m}^2\cdot\text{s})$, and the RMSE was $0.721\ 4\ \mu\text{mol}/(\text{m}^2\cdot\text{s})$. Therefore, the method proposed had significant advantages in predicting the photosynthetic rate of greenhouse crops, and can provide theoretical basis and technical support for the management and control of the light environment of greenhouse tomatoes and other crops.

Key words: greenhouse; tomato; photosynthetic rate prediction; extreme learning machine (ELM); Gaussian process regression (GPR); multi-model fusion

0 引言

光合作用是实现作物物质积累,提升其质量和品质,满足其生长发育的一个重要过程^[1-3]。作物在光合作用过程中,光合速率与多个环境因子密切相关^[4-5],如温度直接影响作物体内酶的活性和气孔导度^[6-8],CO₂作用于作物体内暗反应过程和干物质积累^[9-10],光照强度是作物进行光合作用的前提条件^[11],相对湿度影响叶片气孔导度等^[12-13],且各因子之间存在很强的耦合关系^[14]。为此,探究满足作物最大光合速率的各环境参数,对提升作物的质量和品质至关重要。

在现代温室中,人们通过工程技术手段创造相对可控的人工环境,如温度、光照、水和气等,以满足作物光合作用并提高其光合速率^[15-16]。但是,由于温室受倾斜角、结构、覆盖材料、太阳辐射角、阴雨天气的影响,造成光照不足。特别是在弱光条件下,作物净光合速率降低,生长发育减缓,病虫害发生概率加大,造成坐果率低、开花量低,严重影响作物产量和品质^[17-18]。因此,构建多因子耦合的光合速率预测模型,可为面向作物需求的温室光环境调控提供重要的理论依据。

近年来,许多学者在建立作物光合速率预测模型方面进行了相关研究,基于作物光合速率的温室环境调控方法逐渐成为主流。CHEN 等^[19]利用 SVR 算法对开花结果期的草莓进行模拟,并实现对其光合速率的准确预测。PU 等^[20]以黄瓜幼苗为试验对象,通过 QGA 算法改进径向基函数(RBF)建立光合速率模型,取得了良好的拟合效果。ZHANG 等^[21]结合荧光参数,利用 PSO-BP 神经网络构建黄瓜冠层叶片光合速率预测模型,以准确表征作物光合作用。ZHANG 等^[22]通过多种智能算法对杨树叶片的光合速率进行预测,结果表明使用 XGBoost 算法建立的预测模型效果最佳。XIN 等^[23]利用 Levenberg-Marquardt (LM) 算法训练神经网络(ANN),提出了一种基于人工神经网络的黄瓜光合速率预测模型,实现了对整个光合过程的预测。上

述文献通过智能优化算法寻优建立光合速率预测模型,在一定程度上取得了较为良好的效果。然而,往往只考虑部分环境因子,并且所建立的光合速率预测模型缺乏对空气温湿度、光照或 CO₂ 浓度等关键变量的考虑。此外,现有研究普遍采用单一预测方法,无法克服单一模型适应性不足的问题。集成预测方式或多模型融合策略则是通过融合各个模型的优势,对未知问题具有更强的解释能力,可有效提高预测模型泛化能力,降低模型预测误差^[24-25]。一些研究表明,其预测精度普遍高于单一预测模型^[26]。

针对上述问题,本文以温室番茄为研究对象,对采集到的温湿度、光照强度、CO₂ 浓度、光合速率进行非线性分析,建立可直接应用于光环境调控的光合速率精确预测模型^[27]。首先,分别构建基于粒子群优化支持向量机(PSO-SVR)、布谷鸟搜索算法优化极限学习机(CS-ELM)、北方苍鹰算法优化高斯过程回归(NGO-GPR)的光合速率预测模型。以此为基础,提出一种基于 Stacking 多模型融合策略的光合速率预测方法。该方法将 3 个改进模型(PSO-SVR、CS-ELM 和 NGO-GPR)作为基学习器,以避免 SVR、ELM 和 GPR 模型收敛性差和过拟合等问题,然后将基学习器训练得到的预测结果进行整合和维数转换输入到元学习器。第 2 层模型选择 SSA-XGBoost 作为元学习器进行训练,通过麻雀搜索算法进一步提升模型稳定性和精确性,以期为光环境优化调控提供可靠的模型基础和目标函数支持。

1 材料与方法

1.1 试验材料

试验于 2020 年 9 月 5 日—11 月 22 日在河北省永清县日光温室试验基地进行。温室为半地下琴弦式土墙结构,长度 50 m,跨度 11 m,下深 1 m,脊高 3.2 m,后墙底部厚度 6 m。供试材料为“红美玉”樱桃番茄,该番茄品种果实为椭圆形,成熟后转亮红色,单果质量 20 g 左右。在培养皿中,将膨大的种子进行发芽处理,然后在 72 孔穴盘播种,进行育苗。

育苗基质是农业育苗的专用基质,其营养含量为有机质质量分数 50% 以上,腐殖酸质量分数 20% 以上,pH 值 5.5 ~ 6.5。在幼苗培育期间,保持水肥充足,当番茄幼苗长出 5 ~ 6 片真叶时,选择茎粗为 0.6 ~ 0.8 cm、株高为 10 cm 左右的幼苗进行定植。试验采用无土栽培的椰糠条,将番茄幼苗定植到已提前 2 d 用营养液泡发好的椰糠条上。定植后,当植株从上到下的第 7 片叶子生长到宽度超过 3 cm 时,选择在阳光下生长旺盛均匀的叶片进行光合作用试验。在整个试验期间,无农药或激素类药物喷洒,所有移植、浇水、上肥等流程均属于日常操作,无特殊处理。

1.2 试验方法

由于测量在实际日光温室内进行,为避免作物“午休”对试验数据的影响,测量时间选择每日 09:00—11:30 和 14:30—17:30 进行。试验采用 LI-6400XT 型光合测量仪进行测量,具体如图 1 所示。使用时,首先将叶片封闭在叶室内,控制叶室内的温度、CO₂ 浓度、光照强度等环境参数。然后,根据物质平衡,用气体分析仪测量样本室和标准室的 CO₂ 和 H₂O 的差值,准确地得到光合速率。由于气体分析仪安装在叶室顶部,因此可以在分析仪顶部进行气体分流。从而消除了仪器管路带来的延迟和误差,使光合仪具有精度高、响应快的特点。




图 1 光合速率测定图

Fig. 1 Measurement diagram of photosynthetic rate

试验测定过程中,采用 LI-6400XT 型光合测量仪测定系统人工营造所需的小环境条件,其中,利用 CO₂ 浓度注入系统提升叶室 CO₂ 浓度,利用苏打管降低叶室 CO₂ 浓度;利用电阻丝提升叶室温度,利用冷凝器降低叶室温度;利用荧光光源模块控制光合光子通量密度 (Photosynthetic photon flux density, PPFD)。试验过程中,红蓝光光质比例选择为气体交换经验比例 9:1,叶室相对湿度增减通过仪器加湿管与干燥剂实现。

根据番茄种植经验^[28],温度范围设定为适合光合作用的 15 ~ 30℃,梯度间隔为 3℃,即具体划分为 15、18、21、24、27、30℃;相对湿度范围设定为

60% ~ 75%,梯度间隔为 5%,即 60%、65%、70%、75%;另外,番茄的 CO₂ 饱和点一般不低于 600 μmol/mol,不高于 1 400 μmol/mol,因此设定 CO₂ 浓度为 600、800、1 000、1 200、1 400 μmol/mol 共 5 个梯度;同时,根据相关研究表明,番茄开花前期的光饱和点通常不高于 2 000 μmol/(m²·s)^[29],因此,将光量子通量密度梯度设置在 800 ~ 1 800 μmol/(m²·s),步长为 200 μmol/(m²·s),即具体划分为 800、1 000、1 200、1 400、1 600、1 800 μmol/(m²·s)。本试验以嵌套方式进行,在每种组合条件下,对定植后番茄苗的相应叶片光合速率进行 3 次测量,对 3 次重复测量的数据求平均、剔除异常数据之后最终获得 700 组数据。

2 光合速率预测模型建立与性能评估

2.1 基于 PSO-SVR 的光合速率预测模型

支持向量机回归算法 (Support vector regression, SVR) 是通过一个非线性映射 ϕ 将数据 x 映射到高维的特征空间,并在该空间进行线性回归。利用 SVR 构建光合速率预测模型,假设给定训练样本集为 $G = \{(x_i, y_i)\}_{i=1}^m$,其中 x_i 为第 i 个样本的输入向量,包括温度、相对湿度、光照强度和 CO₂ 浓度, y_i 为相应的输出变量,即光合速率。则回归估计公式为

$$f(x) = \omega\phi(x) + b \tag{1}$$

其中 ω 和 b 表示回归因子。在支持向量机回归算法中,常用的核函数有径向基核函数和多项式核函数,其中径向基函数具有映射维度广、需确定参数少、运算相对简单等优点,因此,本研究选择径向基核函数。SVR 训练过程实际就是对模型中的惩罚因子 c 和核函数参数 g 进行寻优过程。

粒子群优化算法是一种模拟群体智能的优化算法,根据整个群体和粒子本身的最优位置更新位置和速度,并不断向最好的位置靠近^[30]。为获取精度更高的 SVR 预测模型,本文利用 PSO 算法对 SVR 建模过程的参数进行寻优,基于 PSO 优化 SVR 的光合速率建模流程如图 2 所示。具体实现步骤如下:

- (1) 将数据进行归一化处理,确定模型的输入为温湿度、光照强度、CO₂ 浓度,输出为光合速率。
- (2) 将样本数据划分为训练集和测试集。
- (3) 初始化粒子群参数。设置参数范围、惯性因子初始值和种群规模,并随机产生粒子速度与位置,设定最大迭代次数。
- (4) 更新粒子惯性权重、速度和位置信息,计算适应度。
- (5) 判断群体最优适应度是否满足条件或超过最大迭代次数,不满足继续重复步骤(3),满足则迭




图 2 基于 PSO-SVR 的光合速率建模流程图
Fig. 2 Photosynthetic rate modeling flowchart based on PSO-SVR

代结束,确定最佳参数模型 $c、g$ 。

(6)将最佳参数代入 SVR 光合速率模型进行回归预测,输出光合速率最终预测结果。

2.2 基于 CS-ELM 的光合速率预测模型

极限学习机 (Extreme learning machine, ELM) 是 HUANG 等^[31]提出的一种单隐层前向神经网络的训练算法。对于样本数据 $(x_i, y_i), i = 1, 2, \dots, n$, 其中第 i 个样本的输入向量 x_i 也是由温度、相对湿度、光照强度和 CO_2 浓度组成, y_i 为相应的输出变量, 即光合速率。基于样本数据和输入输出之间的非线性关系, 利用 ELM 建立的光合速率模型表示为

$$y_j = \sum_{i=1}^K \beta_i g_i(\omega_i x_j + b_i) \quad (y_j \in \mathbf{R}^n) \quad (2)$$

- 式中 K ——隐含层节点数
 β_i ——隐含层与输出层的输出权值
 g_i ——激活函数
 ω_i ——连接第 i 个隐含层节点和输入节点之间的权重
 b_i ——第 i 个隐含层的偏置

对于 ELM 模型, 不同的设定值会产生不同结果。随机设定参数会直接影响极限学习机的精度和整体模型的准确性。针对这个问题, 本文采用布谷鸟优化算法, 通过多次迭代寻找出最佳的隐层节点数来改进以上不足。

布谷鸟算法不仅结合了鸟类特殊的 Lévy 飞行进行搜索, 还增加了群体之间的信息交流, 使函数收敛速度变得更快, 且参数少, 易于实现^[32]。基于 CS 优化 ELM 的光合速率建模流程如图 3 所示。具体实现步骤如下:

- (1)对数据进行预处理, 确定模型的输入输出, 划分出训练集和测试集, 并设置 CS 算法参数。
- (2)运行 CS 算法选取最优鸟巢, 通过搜索鸟巢




图 3 基于 CS-ELM 的光合速率建模流程图
Fig. 3 Photosynthetic rate modeling flowchart based on CS-ELM

- 位置, 输入 ELM 隐层节点数。
- (3)在 ELM 算法中, 得到输入权值 W 、偏置 b 、输出权值 β , 计算出预测误差, 输入到 CS 算法中。
- (4)得到适应度, 进而更新鸟巢位置。
- (5)判断是否满足迭代次数, 如不满足, 继续选取最优鸟巢, 满足则输出最优鸟巢位置。
- (6)通过最优鸟巢位置取整后作为 ELM 的隐层节点数 M 及其所对应的网络结构 $W、b、\beta$, 建立基于 CS-ELM 光合速率预测模型, 根据预测集进行测试, 输出光合速率最终预测结果。

2.3 基于 NGO-GPR 的光合速率预测模型

设 $\{f(x), x \in X\}$ 为 m 维空间的随机分布, 其中 X 为北方苍鹰的种群矩阵, 对任意 x , 均有随机变量 $f(x)$ 与之对应, 则称 $x \rightarrow f(x)$ 的回归过程为高斯过程回归^[33]。其表达式为

$$f(x) \sim GP(m(x), k(x, x)) \quad (3)$$

- 式中 x ——环境变量向量
 $f(x)$ ——光合速率 $m(x)$ ——均值函数
 $k(x, x)$ ——协方差函数
 $GP(\cdot)$ ——高斯过程回归函数

传统的 GPR 通常使用共轭梯度法来获得最优超参数, 存在优化结果过于依赖初始值、迭代次数难以以及难以获得全局最优解等不足。针对上述问题, 在最优超参数求解过程中, 引入北方苍鹰优化算法, 流程如图 4 所示, 图中 N 表示目标种群数。

北方苍鹰优化 (Northern goshawk optimization,




图 4 基于 NGO - GPR 的光合速率建模流程图
Fig. 4 Photosynthetic rate modeling flowchart based on NGO - GPR

NGO)算法是一种基于种群的优化算法,该算法具有卓越的优化性能以及较高的收敛精度和良好的稳定性^[34-35]。北方苍鹰狩猎策略分为猎物识别阶段与追击和逃逸阶段。通过以上 2 个阶段完成对高斯过程回归算法的优化,寻找到最佳超参数。具体实现步骤如下:

- (1) 试验数据进行归一化处理,确定模型的输入为温度、相对湿度、光照强度、CO₂ 浓度,输出为光合速率。
- (2) 随机选取猎物,计算第 1 阶段北方苍鹰第 j 维的新位置。
- (3) 更新第 1 阶段北方苍鹰位置。
- (4) 计算第 2 阶段北方苍鹰第 j 维的新位置。
- (5) 更新第 2 阶段北方苍鹰位置。
- (6) 输出最优解,获得 GPR 最优核函数超参数 lf, n 。
- (7) 建立基于 NGO - GPR 光合速率预测模型,输出最终光合速率预测结果。

2.4 基于多模型融合策略的温室番茄光合速率预测模型

2.4.1 基于 Stacking 的集成学习方式

Stacking 集成学习框架首先采用五折交叉验证

法 (cross - validation) 对数据进行预处理,然后将数据划分成若干子数据集,输入到第 1 层光合速率预测模型的 3 个基学习器中,每个基学习器输出各自的预测结果。然后第 1 层的输出作为第 2 层的输入,对预测模型的元学习器进行训练,第 2 层的模型输出作为最终预测结果^[36-37],结构示意图如图 5 所示。




图 5 基于 Stacking 的集成学习方法
Fig. 5 Ensemble learning method based on Stacking

基于 Stacking 的多模型融合方法使第 1 层的训练结果能够充分用于第 2 层的归纳过程当中,并纠正第 1 层学习算法中的预测误差,进一步提升模型的精度。

2.4.2 基于 Stacking 的融合模型构建

本文所研究的温室番茄光合速率预测模型属于回归问题,选用 Stacking 策略进行融合。根据“误差一分歧分解 (Error - ambiguity decomposition)”理论,立足于基学习器的预测能力,在 SVR、ELM、GPR 3 个基本模型的基础上,分别进行了改进,使之成为 PSO - SVR、CS - ELM、NGO - GPR 3 个改进模型,并将其作为基学习器第 1 层模型。研究表明,优化的集成树模型 XGBoost 可以取得较好的预测结果^[33],故本文选用 XGBoost 作为第 2 层元学习器,同时为了增加模型预测精度,采用麻雀算法进行优化,进而构建融合模型,标记为 SEG - FM。具体融合模型架构如图 6 所示。具体实现步骤为:

- (1) 结合交叉验证将数据集 D 随机划分为 5 个大小相等且互不相交子集 $D_1, D_2, \dots, D_5$ 。
- (2) 对于 PSO - SVR 模型,依次选择数据集 D 中的一个子集 $D_i (i = 1, 2, \dots, 5)$ 作为验证集,其余作为训练集进行训练,最终得到 5 个预测结果,计算平均值并将其组合为集合 P_1 ,作为 PSO - SVR 模型的预测结果。
- (3) 对于 CS - ELM 和 NGO - GPR 模型,重复步骤(2)操作,得到集合 P_2 和 P_3 。
- (4) 将 3 个基学习器的预测结果横向拼接为新数据集 $P = \{P_1, P_2, P_3\}$,以 P 作为第 2 层元学习器




图 6 基于 Stacking 多模型融合温室番茄光合速率预测方法

Fig. 6 Prediction method of tomato photosynthetic rate in greenhouse with multi-model fusion based on Stacking

的输入特征,进行二次泛化训练,最终得到光合速率预测结果。

3 仿真结果与分析

将采集到的数据经过预处理后,共筛选出 700 组作为仿真模拟数据,其中选择 500 组作为训练集合,200 组作为测试集。首先,采用 PSO-SVR、CS-ELM 和 NGO-GPR 改进算法建立光合速率预测模型,分别与 3 个标准模型 SVR、ELM 和 GPR 进行比较,具体预测结果如图 7 所示。在 PSO-SVR

算法中,设置粒子群算法参数: $c_1 = 1.5, c_2 = 1.7$,最大进化迭代次数为 100,种群规模为 20,通过不断迭代寻优得到最优参数 $c = 0.1, g = 209.887$;在 CS-ELM 算法中,基于 CS 较强的全局寻优能力,设置布谷鸟搜索参数:优化参数个数为 150,迭代次数为 100,巢穴数量为 20,被宿主发现的概率为 0.25,优化参数目标上下限为 $[-1, 1]$;在 NGO-GPR 算法中,设置北方苍鹰搜索参数:目标种群为 20,迭代次数为 100,优化下界矩阵为 $[0.01 \ 0.01 \ 0.1]$,优化上界矩阵为 $[10 \ 10 \ 100]$,通过不断迭代寻优得到最佳核函数超参数为 $l = 0.010 \ 1, f = 3.531 \ 2, n = 0.1$ 。

在生成的点线图上,从标准 SVR 模型、ELM 模型和 GPR 模型的预测结果中可以看出,SVR 模型精度相对较差,存在着比较严重的过拟合和局部最优的现象,ELM 和 GPR 模型稍优于 SVR 模型,整体上虽然 3 种基本模型对番茄光合速率的趋势有一定的预测效果,但预测结果波动较大,对峰值点的预测不够准确,而 PSO-SVR、CS-ELM 和 NGO-GPR 预测模型,采用智能优化算法对基本模型寻优参数后,改善了模型的预测性能,使模型预测精度和稳定性得到了一定程度的提升。接着,采用本文提出的多模型融合策略将 3 种改进模型 PSO-SVR、CS-ELM 和 NGO-GPR 融合,构建融合模型 SEG-FM 对光合速率进行预测,预测结果如图 8 所示。

由图 8 可以看出,基于 Stacking 多模型融合策略构建的 SEG-FM 模型可以进一步提高单一模型的预测精度,减少模型参数不确定性因素的影响。图 9 为 SEG-FM 模型与其他各模型的绝对相对误




图 7 基于单模型的光合速率预测结果

Fig. 7 Prediction results of photosynthetic rate based on single model




图 8 基于 SEG-FM 模型的光合速率预测结果
Fig. 8 Prediction results of photosynthetic rate based on SEG-FM model




图 9 绝对相对误差结果对比
Fig. 9 Comparison of absolute relative error curve results

表 1 不同算法构建的光合速率模型预测结果
Tab.1 Prediction results of photosynthetic rate models constructed by different algorithms

模型	$\mu\text{mol}/(\text{m}^2 \cdot \text{s})$	
	MAE	RMSE
SVR	1.797 1	2.340 6
ELM	1.649 5	2.173 9
GPR	1.680 5	2.063 5
PSO-SVR	1.302 6	1.471 8
CS-ELM	1.321 6	1.557 8
NGO-GPR	1.199 6	1.363 2
SEG-FM	0.569 7	0.721 4

由表 1 可知,标准 SVR、ELM 和 GPR 模型的 MAE 和 RMSE 相对较大,通过智能优化算法对模型参数进行寻优后,精度上均有了较为明显的改善,如 ELM 模型测试集的 RMSE 和 MAE 分别为 2.173 9、1.649 5 $\mu\text{mol}/(\text{m}^2 \cdot \text{s})$,改进后 CS-ELM 模型的 RMSE 和 MAE 分别为 1.557 8、1.321 6 $\mu\text{mol}/(\text{m}^2 \cdot \text{s})$,精度提升的较为明显。本文提出的 SEG-FM 模型,

差曲线。由图 9 可以看出,对于 3 个基本算法 SVR、ELM 和 GPR 而言,相对误差曲线不平稳,起伏较大,误差分布较为松散。而 PSO-SVR、CS-ELM 和 NGO-GPR 3 种模型改进效果较为明显,有效降低了过高误差的出现,一定程度改善了误差曲线的起伏状况。相比于单模型,本文提出的 SEG-FM 融合模型,显示了一个更加紧密的误差分布,分别与 6 种算法相比较,其相对误差更小,预测结果更为可靠。为进一步评价 SEG-FM 模型的预测性能,分别列出了各模型绝对误差平均值 (MAE) 和均方根误差 (RMSE) 相关评价指标,结果如表 1 所示。

在预测精度上具有明显优势,与基本算法相比,精度提升 3 倍左右,同时与单模型 PSO-SVR、CS-ELM 和 NGO-GPR 相比,基于 Stacking 集成方式融合 PSO-SVR、CS-ELM 和 NGO-GPR 模型后,模型精度得到了进一步提升,其中测试集的 RMSE 和 MAE 分别为 0.721 4、0.569 7 $\mu\text{mol}/(\text{m}^2 \cdot \text{s})$,具有更小的平均误差,且鲁棒性较好,能够实现光合速率的有效预测。

4 结论

- (1)以温室番茄为研究对象,将采集的温度、相对湿度、光照强度和 CO_2 浓度作为输入,光合速率作为输出,分别建立了 PSO-SVR、CS-ELM、NGO-GPR 预测模型,采用智能优化算法对基本模型寻优参数后,一定程度改善了模型预测性能,提升了模型预测精度。
- (2)提出一种基于多模型融合策略的温室番茄光合速率预测方法,通过充分考虑各个模型的优势,基于 Stacking 多模型融合策略构建 SEG-FM 模型,

进一步提高了单一模型的预测精度,减少模型参数不确定性因素的影响。

(3)相比于标准 SVR、ELM 和 GPR 预测模型,本文建立的 SEG-FM 模型优势较大,具有较低预测误差和较高的预测精度;与 PSO-SVR、CS-ELM 和 NGO-GPR 改进模型相比,同样显示了技术优势,具有更高的预测精度,且具有良好的鲁棒性和稳定性。

参 考 文 献

[1] SMITH J H. Concurrency of carbohydrate formation and carbon dioxide absorption during photosynthesis in sunflower leaves[J]. *Plant Physiology*, 1944, 19(3):394-403.

[2] ARNON D I. The photosynthetic energy conversion process in isolated chloroplasts[J]. *Experientia*, 1966, 22(5):273-287.

[3] ARO E M, VIRGIN I, ANDERSSON B. Photoinhibition of photosystem II. Inactivation, protein damage and turnover[J]. *Biochim. Biophys. Acta*, 1993, 1143(2):113-134.

[4] LU C, DENG L, FEI M. An improved visualization modelling method of greenhouse tomato plants based on L-System[C]//2015 Chinese Automation Congress (CAC). IEEE, 2015:480-485.

[5] HU J, XIN P, ZHANG S, et al. Model for tomato photosynthetic rate based on neural network with genetic algorithm[J]. *International Journal of Agricultural and Biological Engineering*, 2019, 12(1):179-185.

[6] HIKOSAKA K, ISHIKAWA K, BORJIGIDAI A, et al. Temperature acclimation of photosynthesis: mechanisms involved in the changes in temperature dependence of photosynthetic rate[J]. *Journal of Experimental Botany*, 2006, 57(2):291-302.

[7] ROESSLER P G, MONSON R K. Midday depression in net photosynthesis and stomatal conductance in *Yucca glauca*: relative contributions of leaf temperature and leaf-to-air water vapor concentration difference[J]. *Oecologia*, 1985, 67(3):380-387.

[8] SALVUCCI M E, CRAFTS-BRANDNER S J. Inhibition of photosynthesis by heat stress: the activation state of Rubisco as a limiting factor in photosynthesis[J]. *Physiologia Plantarum*, 2004, 120(2):179-186.

[9] VORONIN P Y. Experimental installation for measurements of chlorophyll fluorescence, CO₂ exchange, and transpiration of a detached leaf[J]. *Russ. J. Plant Physiol.*, 2014, 61(2):269-273.

[10] WANG W, CAI C, HE J, et al. Yield, dry matter distribution and photosynthetic characteristics of rice under elevated CO₂ and increased temperature conditions[J]. *Field Crops Research*, 2020, 248:107605.

[11] LIU Y, PAN T, TANG Y, et al. Proteomic analysis of rice subjected to low light stress and overexpression of OsGAPB increases the stress tolerance[J]. *Rice*, 2020, 13:1-10.

[12] CHAVES M M, FLEXAS J, PINHEIRO C. Photosynthesis under drought and salt stress: regulation mechanisms from whole plant to cell[J]. *Annals of Botany*, 2009, 103(4):551-560.

[13] GILBERT M E, ZWIENIECKI M A, HOLBROOK N M. Independent variation in photosynthetic capacity and stomatal conductance leads to differences in intrinsic water use efficiency in 11 soybean genotypes before and during mild drought[J]. *Journal of Experimental Botany*, 2011, 62(8):2875-2887.

[14] POPE D H. Effects of light intensity, oxygen concentration, and carbon dioxide concentration on photosynthesis in algae[J]. *Microbial Ecology*, 1975, 2:1-16.

[15] COOMANS M, ALLAERTS K, WITTEMANS L, et al. Monitoring and energetic performance of two similar semi-closed greenhouse ventilation systems[J]. *Energy Conversion and Management*, 2013, 76:128-136.

[16] SRBINOVSKA M, GAVROVSKI C, DIMCEV V, et al. Environmental parameters monitoring in precision agriculture using wireless sensor networks[J]. *Journal of Cleaner Production*, 2015, 88:297-307.

[17] WU G, YANG Q, FANG H, et al. Photothermal/day lighting performance analysis of a multifunctional solid compound parabolic concentrator for an active solar greenhouse roof[J]. *Solar Energy*, 2019, 180:92-103.

[18] HU L, LIAO W, DAWUDA M M, et al. Appropriate : ratio improves low light tolerance of mini-Chinese cabbage seedlings [J]. *BMC Plant Biology*, 2017, 17:22.

[19] CHEN X, JIANG Z, TAI Q, et al. Construction of a photosynthetic rate prediction model for greenhouse strawberries with distributed regulation of light environment[J]. *Mathematical Biosciences and Engineering*, 2022, 19(2):12774-12791.

[20] PU L, LI Y, GAO P, et al. A photosynthetic rate prediction model using improved RBF Neural Network[J]. *Scientific Reports*, 2022, 12(1):9563.

[21] ZHANG P, ZHANG Z, LI B, et al. Photosynthetic rate prediction model of newborn leaves verified by core fluorescence parameters[J]. *Scientific Reports*, 2020, 10(1):3013.

[22] ZHANG X, HUANG Z, SU X, et al. Machine learning models for net photosynthetic rate prediction using poplar leaf phenotype data[J]. *PLoS One*, 2020, 15(2):1-18.

[23] XIN P, ZHANG H, HU J, et al. An improved photosynthesis prediction model based on artificial neural networks intended for cucumber growth control[J]. *Applied Engineering in Agriculture*, 2018, 34(5):769-787.

[24] 范士雄, 刘幸蔚, 於益军, 等. 基于多源数据和模型融合的超短期母线负荷预测方法[J]. *电网技术*, 2021, 45(1):243-250.

FAN Shixiong, LIU Xingwei, YU Yijun, et al. A method for ultra-short-term bus load forecasting based on multi-source data

and model fusion[J]. Power System Technology, 2021, 45(1): 243 – 250. (in Chinese)

[25] 肖白, 赵晓宁, 姜卓, 等. 利用模糊信息粒化与支持向量机的空间负荷预测方法[J]. 电网技术, 2021, 45(1): 251 – 258.
XIAO Bai, ZHAO Xiaoning, JIANG Zhuo, et al. A spatial load forecasting method using fuzzy information granulation and support vector machines[J]. Power System Technology, 2021, 45(1): 251 – 258. (in Chinese)

[26] 陈锦鹏, 胡志坚, 陈伟楠, 等. 二次模态分解组合 DBiLSTM – MLR 的综合能源系统负荷预测[J]. 电力系统自动化, 2021, 45(13): 85 – 94.
CHEN Jinpeng, HU Zhijian, CHEN Weinan, et al. Comprehensive energy system load forecasting using second-order modal decomposition combined with DBiLSTM – MLR[J]. Automation of Electric Power Systems, 2021, 45(13): 85 – 94. (in Chinese)

[27] WANG W, ZHANG M, LIU C, et al. Real-time monitoring of environmental information and modeling of the photosynthetic rate of tomato plants under greenhouse conditions[J]. Applied Engineering in Agriculture, 2013, 29(5): 783 – 792.

[28] SHU S, TANG Y, YUAN Y, et al. The role of 24-epibrassinolide in the regulation of photosynthetic characteristics and nitrogen metabolism of tomato seedlings under a combined low temperature and weak light stress[J]. Plant Physiol. and Biochem., 2016, 107: 344 – 353.

[29] 张继波, 陈辰, 李楠, 等. 极端寡照天气对设施番茄光合特性及抗氧化酶活性的影响[J]. 山东农业科学, 2017, 49(3): 64 – 68.
ZHANG Jibo, CHEN Chen, LI Nan, et al. The impact of extreme low-light weather on the photosynthetic characteristics and antioxidant enzyme activity of cultivated tomatoes[J]. Shandong Agricultural Sciences, 2017, 49(3): 64 – 68. (in Chinese)

[30] KENNEDY J, EBERHART R. Particle swarm optimization[C] // Proceedings of IEEE International Conference on Neural Networks, 1995: 1942 – 1948.

[31] HUANG G, ZHOU H, DING X, et al. Extreme learning machine for regression and multiclass classification[J]. IEEE Transactions on Systems, 2011, 42(2): 513 – 529.

[32] 张晓凤, 王秀英. 布谷鸟搜索算法综述[J]. 计算机工程与应用, 2018, 54(18): 8 – 16.
ZHANG Xiaofeng, WANG Xiuying. Cuckoo search algorithm review[J]. Computer Engineering and Applications, 2018, 54(18): 8 – 16. (in Chinese)

[33] LU H, CHEN J, LIAO W. Nonparametric regression via variance-adjusted gradient boosting Gaussian process regression[J]. IEEE Transactions on Knowledge and Data Engineering, 2021, 33(6): 2669 – 2679.

[34] DEHGhani M, HUBALOVSKY S, TROJOVSKY P. Northern goshawk optimization: a new swarm-based algorithm for solving optimization problems[J]. IEEE Access, 2021, 9: 162059 – 162080.

[35] EL-DABAH M A, EL-SEHIEMY R A, HASANIEN H M, et al. Photovoltaic model parameters identification using Northern Goshawk Optimization algorithm[J]. Energy, 2023, 262: 125522.

[36] ZHAN Y, ZHANG H, LI J, et al. Prediction method for ocean wave height based on stacking ensemble learning model[J]. Journal of Marine Science and Engineering, 2022, 10(8): 1150.

[37] ALMADANI M, KHEIMI M. Stacking artificial intelligence models for predicting water quality parameters in rivers[J]. Journal of Ecological Engineering, 2023, 24(2): 152 – 164.

(上接第 336 页)

[14] DOUGHER T A, BUGBEE B. Differences in the response of wheat, soybean and lettuce to reduced blue radiation[J]. Photochem Photobiol, 2001, 73(2): 199 – 207.

[15] WANG Jun, LU Wei, TONG Yuxin, et al. Leaf morphology, photosynthetic performance, chlorophyll fluorescence, stomatal development of lettuce (*Lactuca sativa* L.) exposed to different ratios of red light to blue light[J]. Front. Plant Science, 2016, 7: 250.

[16] LISCUM E. Blue light-induced intracellular movement of phototropins: functional relevance or red herring? [J]. Front. Plant Science, 2016, 7: 205000.

[17] MAXIMILIANO S L, CHRISTIAN D L, PABLO D C. Bottom-up assembly of the phytochrome network[J]. PLoS Genetics, 2016, 12(11): 1006413.

[18] 陈晓丽, 杨其长, 王利春, 等. 红蓝光交替照射下生菜能量利用与光合性能分析[J]. 农业机械学报, 2021, 52(6): 344 – 350.
CHEN Xiaoli, YANG Qichang, WANG Lichun, et al. Analysis of energy use efficiency and photosynthesis of lettuce under alternating red and blue irradiation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(6): 344 – 350. (in Chinese)

[19] CHENG M C, KATHARE P K, PAIK I, et al. Phytochrome signaling networks[J]. Annu. Rev. Plant Biol., 2021, 72: 217 – 244.

[20] 王美娇, 彭晶, 齐立娟, 等. 光信号调控植物响应非生物胁迫的研究进展[J]. 植物生理学报, 2023, 59(4): 682 – 704.
WANG Meijiao, PENG Jing, QI Lijuan, et al. Research advances on light control of plant responses to abiotic stresses[J]. Plant Physiology Journal, 2023, 59(4): 682 – 704. (in Chinese)