doi:10.6041/j.issn.1000-1298.2025.07.026

基于 LSTM - SVM 的日光温室环境预测模型

梁正龙[1]　祁少刚[1]　畅青霞[2]　张　盘[1]　张国强[1]　牛立群[1]
(1. 兰州理工大学机电工程学院, 兰州 730050; 2. 兰州交通大学外国语学院, 兰州 730050)

摘要: 准确预测日光温室内环境参数可有效降低温室控制的滞后性,是实现日光温室智能化控制的关键,对于实现日光温室生产过程的精细化智能管理具有重要意义。本文通过设置多层 LSTM 网络模型并结合 SVM 设计用于预测温室环境参数的混合模型,在模型预测过程中加入未来一段时期的天气信息辅以修正模型,以提高模型预测结果的准确性,实现在复杂天气条件下温室内环境参数预测。实验结果表明,该模型充分利用了 LSTM 在序列数据长期依赖关系处理上的特长以及 SVM 在特征提取和分类上的优势,实现了在复杂变化的室外环境条件对日光温室内关键环境参数的精确预测,预测决定系数 R^2 均不小于 0.93。实验验证对比结果表明,提出的加入未来一段时间天气信息修正的 LSTM - SVM 混合预测模型在复杂天气条件下对日光温室环境参数预测准确性和稳定性明显优于单一模型和其他传统方法。

关键词: 日光温室; 长短期记忆网络; 支持向量机; 环境预测模型
中图分类号: S126　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)07-0279-09　　**OSID**:

Environmental Prediction Model of Solar Greenhouse Based on LSTM - SVM

LIANG Zhenglong[1]　QI Shaogang[1]　CHANG Qingxia[2]　ZHANG Pan[1]　ZHANG Guoqiang[1]　NIU Liqun[1]
(1. *School of Mechanical and Electrical Engineering*, *Lanzhou University of Technology*, *Lanzhou* 730050, *China*
2. *School of Foreign Languages*, *Lanzhou Jiaotong University*, *Lanzhou* 730050, *China*)

Abstract: Accurate prediction of environmental parameters in solar greenhouse can effectively reduce the lag of greenhouse control, which is the key to realize the intelligent control of solar greenhouse. It is of great significance to realize the fine intelligent management of solar greenhouse production process. A multi-layer LSTM network model was set up and combined with SVM to design a hybrid model for predicting greenhouse environmental parameters. In the process of model prediction, weather information in the future period was added to supplement the modified model to improve the accuracy of model prediction results and realize the prediction of environmental parameters in greenhouse under complex weather conditions. The experimental results showed that the model made full use of the advantages of LSTM in long-term dependency processing of sequence data and the advantages of SVM in feature extraction and classification. The accurate prediction of the key environmental parameters in the solar greenhouse under the complex outdoor environmental conditions was realized, and the prediction determination coefficient R^2 was not less than 0.93. The experimental verification and comparison showed that the proposed LSTM - SVM hybrid prediction model with future weather information correction was superior to the single model and other traditional methods in the prediction accuracy and stability of solar greenhouse environmental parameters under complex weather conditions.

Key words: solar greenhouse; long short-term memory network; support vector machine; environmental prediction mode

0　引言

随着现代科技不断进步和农业现代化的推进,农业机械信息化正成为塑造智慧农业未来的关键因素,这一技术将传统农业与现代科技深度融合,为农业生产提供全新的可能性。日光温室作为一种重

收稿日期: 2025-01-15　修回日期: 2025-04-14
基金项目: 甘肃省重点研发计划项目(24YFWA014)和国家自然科学基金地区科学基金项目(52405594)
作者简介: 梁正龙(1990—),男,副教授,博士,主要从事智能控制和智慧农业研究,E-mail: liangzl@lut.edu.cn

要、高效、可控的农业生产方式,实现日光温室自动化智能控制是现代农业向自动化、信息化转型的重要环节之一[1-3]。由于日光温室环境参数不仅具有时变性、非线性、周期性等特征的连续时间序列,还与温室外多种环境因子存在复杂的耦合关系,导致难以对温室内的环境参数实现精准预测,进而使目前温室的生产调控大多依靠生产者相关经验或通过短时预测模型进行调控决策[4-6]。这种生产模式对于温室环境调控存在滞后性,影响农业生产效率,同时也限制了温室农业生产的自动化、智能化和精细化管理水平[7]。因此,开发一种高效、准确、可靠的环境参数预测模型对于实现温室环境精准调控和温室生产自动化具有重要意义[8]。

机器学习和深度学习技术在环境预测领域具有巨大优势[9]。因其具有较强的非线性逼近及深层特征提取能力,以及可以为时序数据提供良好的理论支撑等特点,被广泛应用于温室温湿度等参数预测领域[10]。随着基于物联网技术的温室信息采集技术的成熟,温室大棚内信息数据采集越来越容易,这也为温室预测模型训练提供了可靠的数据来源[11-12]。对于温室预测模型研究,已有基于机器学习和深度学习技术,利用数据驱动建立的环境参数预测模型[13]。然而目前针对温室环境参数预测模型相关研究多聚焦于使用单一的神经网络,这种方法虽然在一定程度上可以保证预测准确度,但难以实现在复杂天气条件下,长期对温室环境参数的精准化预测。

近年来,国内外学者为构建一种长期、准确、高效的环境参数预测模型,主要从两方面进行研究,分别为在单一神经网络中加入其他影响温室环境参数因子而设计的预测模型和融合多个单一的神经网络构建而成的混合预测模型。其中文献[14]提出通过从中国天气网发布的天气预报中获取试验地点 72 h 天气状况、室外气温等气象信息,采用多元线性回归,利用对建模数据量要求较少的支持向量机回归和随机森林回归方法,构建基于天气预报的温室内夜间逐时气温预测模型,该模型虽然具有较高的精确度,可以满足生产实践的精确度需求,指导主动集放热系统连续多夜放热策略制定,但模型主要用于预测夜间温室环境参数,未能实现对于温室环境参数连续、长时间预测;文献[15]提出的基于 1D CNN-GRU 的日光温室温度预测模型和文献[16]提出的基于 SSA-LSTM 的日光温室环境预测模型等混合模型基本可以实现连续、精准、长时预测温室环境参数,但面对复杂天气条件时温室环境参数的预测结果仍会有较大误差。

基于以上研究中预测模型不能同时满足在复杂天气条件实现精准预测和连续、精准、长时预测等问题,且训练模型需要大量样本数据,本文提出一种基于 LSTM-SVM 神经网络模型并在预测过程中加入未来一段时间天气信息以修正预测数据的混合模型。通过设计物联网数据采集系统获取温室内外环境参数,将获取的数据根据预测需要按序列构造输入矩阵,输入到 LSTM-SVM 模型进行训练,并通过在模型中输入温室外天气状态信息修正模型的预测结果,以实现在复杂天气状态下 LSTM-SVM 预测模型对温室环境参数连续、精准、长时预测。

1 实验数据获取与处理

1.1 数据获取平台

实验地点位于甘肃省武威市陇原智慧物联网科技股份有限公司智能日光温室。实验用于获取数据的日光温室采用镀锌钢管组成的拱形结构为主体架构,采用透明塑料薄膜作为温室覆盖层。温室为南北走向,长 50 m,宽 10 m,拱高 4 m。温室内配备先进的环境控制系统,安装有卷帘机、卷膜机、水肥一体机和增温除霜补光灯等设备,可以自动调节温室内部温度、相对湿度、光照强度和土壤湿度等环境参数。实验温室实景如图 1 所示。



图 1 实验温室实景图

Fig. 1 Experimental greenhouse scene map

考虑获取实验数据的温室空间较大,温室内不同位置的环境参数差异较大,为减少采样位置对获取参数样本质量的影响,将传感器安装在温室较为中心的区域,同时在距离传感器 2~3 m 范围内安装简易玻璃管壁挂式温湿度计辅助测量,以保证获取参数样本数据的准确性[17-18]。

1.2 物联网数据采集系统

设计物联网数据采集系统可以实时、准确、便捷地获取温室内环境参数信息[19]。数据采集系统主要由核心板 STM32F103C8T6、温湿度传感器、光照传感器、二氧化碳传感器、ESP8266-01S 型联网模块等组成。传感器相关参数如表 1 所示。

所获取数据主要由两部分组成:①室外环境参数,利用和风天气网 API 密匙通过网站获取大棚所

表 1　物联网数据采集系统传感器参数

Tab. 1　Sensor parameters for IoT data acquisition system

传感器类型	型号	工作量程	精度	输出信号
温湿度传感器	DHT11	－20～60℃（温度） 5%～95%（相对湿度）	±2℃ ±5%	3.3～5.5 V
光照传感器	BH1750	0～65 535 lx	±1 lx	3～5 V
CO_2 传感器	CCS811	300～5 000 μmol/mol	±1 μmol/mol	1.8～3.6 V

在地区的室外天气状态（将天气状态划分为晴天、晴转多云和雨天等）和室外温湿度。②温室内环境参数，通过安装在温室内的物联网数据采集系统获取，并利用 ESP8266－01S 型联网模块通过 MQTT 协议上传至阿里云生活物联网平台进行显示和保存。物联网数据采集系统结构如图 2 所示。

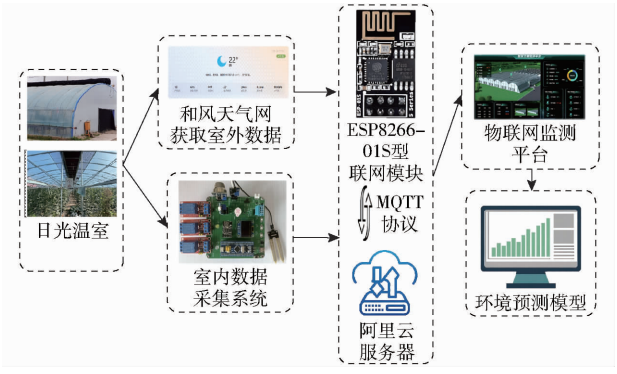

图 2　物联网数据采集系统结构图

Fig. 2　Structure diagram of IoT data collection system

1.3　数据相关性处理

1.3.1　实验数据获取与预处理

通过爬取和风天气网获取温室所在地区未来 3 d 的天气预报信息，同时读取物联网数据采集系统采集的温室环境参数，将采样间隔设置为 1 h，获取的部分数据如图 3 所示。数据采集时间为 2024 年 5 月 30 日—11 月 8 日，通过 PyCharm 软件编写脚本将获取的温室内外样本数据根据时间特征合并在同一个表格，以便于后续研究中模型训练和测试。

如图 3 所示，获取的初始数据中存在数据缺失和数据骤变等现象。由于温室内是一个相对比较稳定的小气候环境，一般不会出现环境参数在短时间内剧烈变化的现象[20]，故将骤变数据认为是异常值。

分析数据获取方式，可知数据中的异常值主要来源于两方面：①数据在传输过程中由于网络波动造成数据缺失。②在温室内数据采集过程中，由于设计的物联网数据采集系统可能存在电路共地干扰隐患和数据传输环节的系统干扰等问题导致获取的

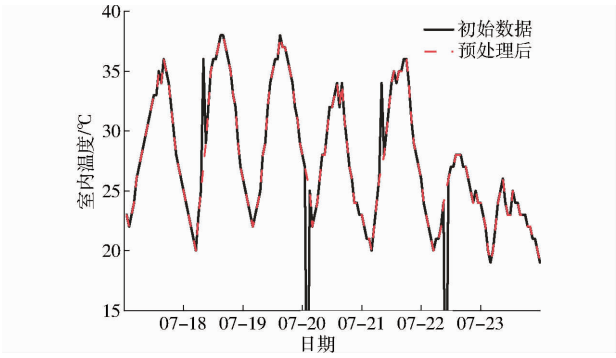

图 3　数据预处理前后对比图

Fig. 3　Comparison diagram before and after data preprocessing

部分数据偏大等原因，造成获取的数据有明显错误[21－22]。

对于缺失数据，使用线性插值法根据相邻数据点来推测缺失数据并标记，补充初始数据中的缺失值以减少对整体数据完整性的影响。采用阈值法对异常数据识别处理，即通过编写脚本比较同一时刻初始数据和记录的简易玻璃管壁挂式温湿度计数据，参考传感器测量精度，对传感器数值设置合理的上下误差限阈值，将误差超出该范围的数据视为异常值。设定恒定温度误差阈值为 ±2℃，相对湿度误差阈值为 ±5%。对于检测到的异常数据利用线性插值法通过相邻时间段的有效数据来校正[23]。通过使用以上异常数据预处理方法对获取的初始数据处理后，可以保证预处理前后数据的整体变化趋势和关键数据保持一致，有效提高了数据完整性和可靠性。处理后数据效果如图 3 所示。

1.3.2　时间特征化处理

时间特征化可以使模型能够充分利用时间序列中的信息，从而显著提高预测精度。通过提取和处理时间特征，模型可以更好地适应数据中的周期性波动和趋势变化，使得预测结果更加稳定和可靠，不易受到噪声或异常数据的干扰[24]。

为了更好地捕捉周期性，使用正弦和余弦函数对时间进行编码，计算式为

$$h_{\sin} = \sin\frac{2\pi h}{24} \tag{1}$$

$$h_{\cos} = \cos\frac{2\pi h}{24} \tag{2}$$

式中　h——当前时刻对应的小时数，取值范围为 [0,23]

$h_{\sin}$——时间特征的三角函数编码，表示正弦映射

$h_{\cos}$——时间特征的三角函数编码，表示余弦映射

通过将时间特征进行三角变换处理，生成 2 个

新的特征。这 2 个特征可用于捕捉 1 d 内环境参数的周期性变化,采用的模型可以通过这 2 个特征更有效捕捉时间的周期性规律,增强模型对不同时间段环境数据感知和理解,能使模型更精确地预测温室环境中的参数变化。

1.3.3 数据归一化处理

在使用经过预处理后的数据进行模型训练过程中,数据归一化处理是一个重要步骤,主要是为了提高模型预测准确性和效率。

环境参数(如温度、相对湿度、光照强度、二氧化碳浓度等)具有不同量纲,这会导致模型在处理这些数据时偏向于数值较大的特征。数据归一化可以将所有特征值调整到相同尺度上,从而消除不同量纲对模型训练的影响。通过数据归一化处理后的数据在模型中可以表现出更好的预测效果,特别是在神经网络等复杂模型中,其预测精度可以显著提升,同时使模型的训练过程更加平稳和快速,可有效减少训练时间,增强模型在处理未见数据时的泛化能力。本研究所使用的各类参数均在对应的一定范围内变化,故采用 Min - Max 标准化方法对数据进行归一化处理。

2 LSTM - SVM 环境预测模型

2.1 LSTM 神经网络模型

长短期记忆网络(Long short-term memory, LSTM)是一种特殊的递归神经网络(RNN),旨在解决传统 RNN 在处理长序列数据时遇到的梯度消失和梯度爆炸问题[25-26]。如图 4 所示,LSTM 内部结构包含输入门、遗忘门和输出门,这些门控机制共同作用,有效管理信息流入、保留和流出[27]。

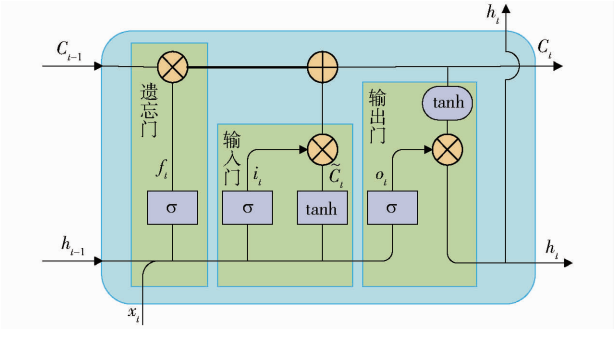

图 4 LSTM 模型内部结构图

Fig. 4 Internal structure of LSTM model

LSTM 的设计核心在于其记忆单元,这个单元能保存并传递关键信息,从而使得网络有能力跨越较长的时间间隔,维持对过去信息的记忆,这对于当前的预测任务至关重要。在日光温室环境预测模型研究中,LSTM 的这些门控机制能有效捕捉和利用时间序列数据中的复杂动态关系,为后续的支持向量机(SVM)分类或回归任务提供精确的特征表示。

2.2 SVM 网络模型

支持向量机(Support vector machine, SVM)是一种强大的监督学习算法[28]。SVM 的核心在于寻找一个最优的决策边界,即超平面,它能够最大程度地分隔不同类别的数据点,并且最大化类别间的间隔。这种算法特别适用于处理高维数据,并且在样本数量较少的情况下仍能保持良好的性能。由于温室环境参数(如温度、相对湿度、光照强度等)通常具有高维度的特征空间,而数据采集的高频率又使得样本数量庞大,SVM 在处理这类数据时有优越的表现。尤其是在特征数量众多而样本量相对有限的情况下,SVM 的优势更为明显。

温室环境参数间的复杂非线性关系,如光照强度与温度间的相互作用,可以通过 SVM 的核函数有效建模[29]。采用径向基函数(Radial basis function, RBF)核,它能够捕捉数据中的非线性结构,从而提高预测准确性。通过将 LSTM 网络提取的时间序列特征输入到 SVM 模型中,构建一个强大的预测系统,该系统能有效地从复杂的温室环境数据中学习和预测,为温室作物的生长管理提供科学依据。

2.3 LSTM - SVM 网络模型

通过将 LSTM 与 SVM 相结合,构建一个基于 LSTM - SVM 的日光温室逐时环境预测模型。该模型利用 LSTM 对时间序列数据的强大处理能力,捕捉温室环境参数间的复杂动态变化关系[30]。同时,借助 SVM 的特征提取和降维能力,减少输入数据中的冗余和噪声,从而提升模型泛化能力,实现对温室内部环境参数的精确预测。此外,模型能通过连续输入的天气信息实时修正预测参数,确保在复杂多变的天气条件下,实现连续、精准、长时间的温室环境参数预测。LSTM - SVM 模型框架如图 5 所示。

预测模型主要包含数据输入与气象动态修正、LSTM 特征提取和 SVM 数据预测与动态迭代修正 3 部分。

(1)给定输入数据序列 $X = \{x_1, x_2, \cdots, x_n\}$,其主要包含日期、天气、室外温度、室外相对湿度 4 个室外参数和室内温度、室内相对湿度、室内光照强度、室内二氧化碳浓度 4 个室内参数。由于温室内的环境参数变化具有周期性,数据输入前首先根据式(1)、(2)将日期特征进行三角函数编码实现时间特征化。同时针对天气特征引入天气类型感知的门控权重机制,根据实时天气调整室外参数的贡献度。如雨天相对湿度权重提升,晴天温度权重提升。权重计算公式为

$$w_t = \sigma(W_g[e_w; h_{t-1}]) \tag{3}$$

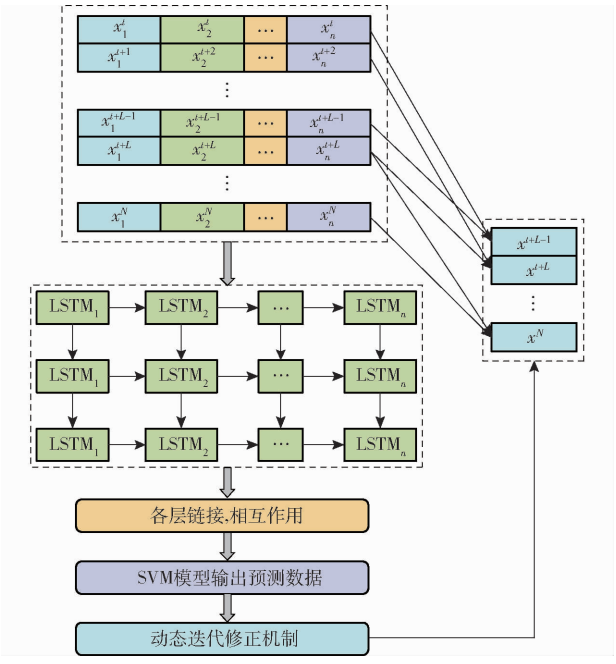

图 5　LSTM－SVM 模型框架

Fig. 5　LSTM－SVM model framework

式中　w_t——当前时刻的天气权重

σ——Sigmoid 激活函数

$\boldsymbol{W}_g$——学习参数矩阵

$\boldsymbol{e}_w$——天气特征的 One－hot 编码向量

h_{t-1}——LSTM 隐状态

通过数据特征编码处理后可以将日期的时间信息转化为周期性特征来处理，有利于模型捕捉温室环境参数随时间变化的规律，使其能与温室内环境参数的变化趋势更好地耦合。天气类型感知的门控权重机制可以增强环境参数数据的特征表达能力，有利于模型预测过程中及时调整环境参数的变化。

(2)将数据输入 LSTM 模型，模型设置 3 层 LSTM 网络，每一层执行不同功能。LSTM 层 1 通过双向 LSTM 结构提取时间序列的潜在模式，进行数据挖掘，用于初步挖掘时间序列中的潜在模式；LSTM 层 2 基于门控机制过滤噪声，以保留与目标参数强相关特征的方式进行数据筛选，筛选出与目标变量高度相关的特征，并过滤掉噪声和不相关信息；LSTM 层 3 进行特征输出，采用时间注意力机制压缩和整合多步特征，生成最终的特征向量。

(3)将 LSTM 模型输出的特征向量输入 SVM 模型，SVM 模型通过核函数映射(RBF)输出预测值(如预测温室内的温度、相对湿度、光照强度、二氧化碳浓度)。

为保证模型在各种天气条件下输出预测结果的准确性，对预测结果采用动态迭代修正机制。基于历史预测误差的统计特性，定义动态阈值 τ。当预测均方根误差(RMSE)大于 τ 时，判定为“复杂环境”，触发模型修正流程。模型对于输出预测结果的温度、相对湿度、CO_2 浓度和光照强度分别计算动态阈值，若任一参数超限则启动修正，避免局部误差累积。

当在复杂天气环境下模型预测结果触发修正时，模型会利用未来 k 小时的天气预报信息构建扩展输入序列 X_{extend}，并将当前时刻 t 之前 L 步的真实环境数据与未来气象数据拼接，形成修正训练集 $D_{retrain}$，其中未来部分标签为空，用于引导模型基于气象特征进行预测。

将新生成的训练集输入模型重复之前的训练，冻结模型 LSTM 主干网络参数，仅开放气象门控权重矩阵 $\boldsymbol{W}_g$ 与 SVM 核函数参数进行训练。为防止模型进入无限循环训练，当修正后的模型连续 3 次对历史时段 $t-L\sim t$ 的预测结果误差满足 RMSE 小于 τ 时，认为模型预测结果达标，迭代终止并输出预测结果。采用这种基于未来气象数据驱动的增量重学习策略，可以在原有模型参数基础上进行微调，保留历史知识，减少计算量并防止过拟合。

LSTM－SVM 网络模型的逻辑流程图如图 6 所示。

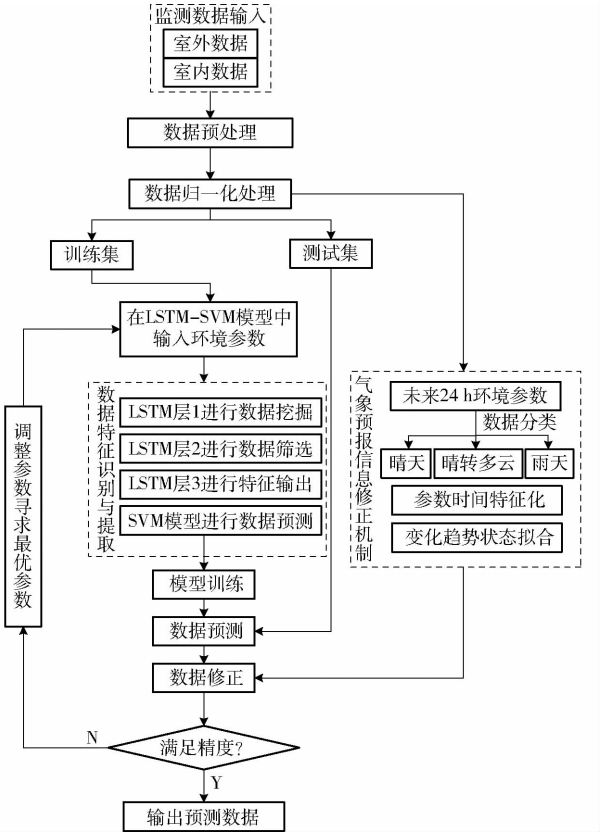

图 6　LSTM－SVM 逻辑流程图

Fig. 6　LSTM－SVM logic flow chart

在温室环境参数预测中，LSTM－SVM 模型不仅能对单一环境参数进行预测，还能同时预测多个环境参数，从而实现更加全面的环境预测，使其在应对

复杂的环境数据预测任务时表现出显著优越性。

2.4 模型评估

采用均方误差(Mean squared error,MSE)和决定系数(Coefficient of determination,R^2)作为模型评价指标。MSE 用于直观地表示模型预测的环境参数(如温度、相对湿度)与实际观测值之间的平均差异,而 R^2 则量化模型对温室环境变化解释的具体程度。

3 预测结果与分析

采用小样本对 LSTM - SVM 模型进行训练,为弥补训练样本数量较少导致模型预测精度不高的问题,通过在模型预测过程中加入未来一段时期的天气信息用于修正模型预测以提高模型预测结果的准确性。

使用的数据集由 2024 年 5 月 30 日—11 月 8 日连续的实验温室内外环境参数组成,包括日期、天气、室外温度、室外相对湿度(4 个温室外部参数)以及室内温度、室内相对湿度、室内光照强度、室内二氧化碳浓度(4 个温室内部参数)。数据时间段跨越了 3 个季节(如夏季高温、秋季温和、冬季低温等),因此能反映不同季节下温室环境参数的特征差异。由于数据集中数据连续,所训练的 LSTM - SVM 预测模型不仅能适应单一季节预测,还能在季节切换时依然保持较高的准确性。

将样本数据按比例 9∶1 划分为训练集和测试集,分别使用基础 LSTM - SVM 模型及其融合天气信息的改进模型,针对日光温室环境参数开展复合预测。为深入评估模型在不同气象条件下的适应性,基于训练集天气特征构建了分类验证框架:将样本划分为晴天、晴转多云、雨天 3 类典型天气场景。模型预测结果如图 7 所示。这种分类验证方法的模型预测结果有效说明了在各种天气条件下模型预测结果的准确性。

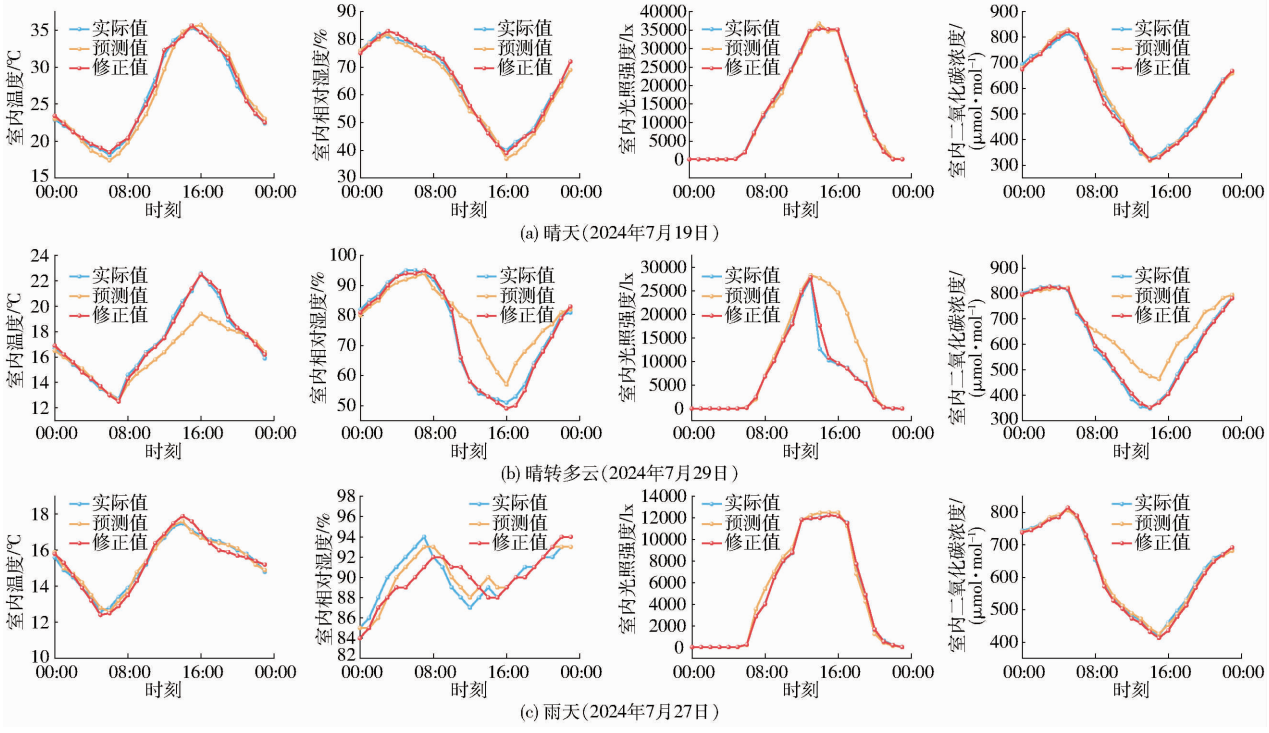

图 7 不同天气条件下 LSTM - SVM 模型预测结果

Fig. 7 Prediction results of LSTM - SVM model under different weather conditions

根据预测结果计算出 STM - SVM 模型和加入天气信息修正的 LSTM - SVM 模型在不同天气条件下对每个温室环境参数预测结果的 MSE 和 R^2,如表 2 所示。

由表 2 可以看出,未修正 LSTM - SVM 模型在不同天气条件下的预测效果不同。在预测较复杂天气条件下(如晴转多云)表现较差,尤其在室内二氧化碳浓度预测方面,未修正 LSTM - SVM 模型 R^2 只有 0.65,在室内温度、室内相对湿度和室内光照强度预测方面 R^2 也只有 0.75、0.75 和 0.71,说明模型在预测较复杂天气条件的环境参数时拟合效果不佳。而在预测简单天气条件下(如晴天和雨天)表现有所改善,在室内温度预测方面 R^2 为 0.96 和 0.95,MSE 也较低,表明模型在简单天气条件下仍能较好预测温室环境参数。加入天气信息修正的 LSTM - SVM 模型明显改善了在所有天气条件下的预测性能。例如,在晴天条件下,室内温度和室内相对湿度预测 MSE 较低,R^2 接近 1,分别为 0.98 和

表 2　不同天气条件下模型预测精度

Tab. 2　Model prediction accuracy under different weather conditions

天气	模型	室内温度		室内相对湿度		室内光照强度		室内二氧化碳浓度	
		MSE/℃	R^2	MSE/%	R^2	MSE/lx	R^2	MSE/(μmol·mol^{-1})	R^2
晴天	未修正	0.97	0.96	3.85	0.92	5.26	0.94	18.05	0.93
	修正后	0.26	0.98	1.34	0.97	5.32	0.94	12.12	0.95
晴转多云	未修正	5.46	0.75	6.77	0.75	25.42	0.71	50.27	0.65
	修正后	1.20	0.95	2.43	0.95	6.73	0.93	15.36	0.94
雨天	未修正	1.25	0.95	2.78	0.94	2.48	0.95	12.36	0.95
	修正后	0.28	0.98	1.59	0.97	2.43	0.95	10.24	0.96

0.97。说明加入天气信息修正后的模型可以更好地拟合真实数据，预测更加准确。在复杂天气条件下，虽然修正后模型仍有一定误差（如晴转多云室内光照强度预测 R^2 为 0.93），但整体上误差大幅降低，决定系数也提高，表明修正后模型在适应复杂天气方面有显著改进。

总体来说，LSTM－SVM 模型和加入天气信息修正的 LSTM－SVM 模型在简单天气条件下（如晴天和雨天）对温室环境参数都具有较高的预测准确度。但在预测较复杂天气条件下（如晴转多云）的温室环境参数时，加入天气信息修正的 LSTM－SVM 模型预测性能显著优于未修正模型，尤其是室内光照强度和室内二氧化碳浓度预测准确度有显著提高。

4　算法对比与模型验证

为更直观地评价加入天气信息修正的 LSTM－SVM 模型在小样本下对日光温室环境参数的预测性能，分别选取 BP 神经网络、SVM 模型、LSTM 模型以及本文提出的加入天气信息修正 LSTM－SVM 混合模型对温室内的环境参数进行预测，并通过 MSE 和 R^2 对模型预测精度进行评价。对比结果如表 3 所示。

表 3　4 种模型预测性能对比

Tab. 3　Comparison of predictive performance among four models

模型	室内温度		室内相对湿度		室内光照强度		室内二氧化碳浓度	
	MSE/℃	R^2	MSE/%	R^2	MSE/lx	R^2	MSE/(μmol·mol^{-1})	R^2
BP	1.94	0.90	5.37	0.88	8.56	0.89	22.63	0.91
SVM	1.55	0.92	3.13	0.93	6.44	0.92	30.17	0.88
LSTM	1.16	0.94	4.48	0.90	7.25	0.91	25.14	0.90
修正 LSTM－SVM	0.58	0.97	1.79	0.96	4.83	0.94	12.57	0.95

从表 3 可以看出，修正 LSTM－SVM 模型在各项环境参数预测中均表现出最优预测效果，尤其是在室内温度和室内相对湿度预测中，MSE 较低，R^2 接近 1，表明模型拟合效果良好。相比之下，传统的 BP 神经网络和 SVM 模型预测精度较低，尤其是在室内光照强度和室内二氧化碳浓度预测中，误差较大，说明这些传统的单一模型在处理复杂环境数据时存在一定局限性。

LSTM 模型在处理时间序列数据上表现良好，但其预测效果仍不如修正 LSTM－SVM 模型。结合 SVM 的修正 LSTM－SVM 模型通过利用 SVM 的分类和回归能力，使得模型在处理复杂耦合的环境参数时能更加准确地捕捉其内在规律，显著提升了预测准确性和稳定性。

5　结论

（1）提出了一种基于 LSTM－SVM 的混合模型，通过在模型预测过程中加入未来一段时期的天气信息用于修正模型预测以提高模型预测结果的准确性，用于在复杂天气条件下对日光温室环境参数预测。通过对比实验验证，本模型在预测精度和稳定性方面均优于传统的 BP 神经网络、SVM 模型和 LSTM 模型，特别是在使用小样本训练模型的情况下，加入天气信息修正的 LSTM－SVM 模型表现出更高的泛化能力和鲁棒性。

（2）研究结果表明，LSTM－SVM 模型不仅能较为准确地预测日光温室的室内温度、室内相对湿度、室内光照强度和室内二氧化碳浓度等关键环境参数，而且在复杂天气条件下（如晴转多云或雨天）的预测效果优于其他模型。加入天气信息修正的模型进一步提高了预测准确度，表明该修正方法可以有效提升模型在复杂环境下的表现。研究结果为智能温室环境管理提供了可靠技术支持，具有广泛应用前景。

参 考 文 献

[1] LIN Jinlong,MA Jing,LIU Kuan, et al. Development and test of an autonomous air-assisted sprayer based on single hanging track for solar greenhouse[J]. Crop Protection, 2021, 142:105502.

[2] 唐静. 智能温室农业环境自动监控系统设计[D]. 北京:中国科学技术大学, 2011.
TANG Jing. Design of intelligent automatic monitoring system for greenhouse agriculture environment[D]. Beijing: University of Science and Technology of China, 2011. (in Chinese)

[3] 王福禄. 寒地日光温室远程监测系统的研究[D]. 哈尔滨:东北农业大学, 2011.
WANG Fulu. The research of cold region greenhouse remote monitoring system[D]. Harbin: Northeast Agicultural University, 2011. (in Chinese)

[4] DONG Bowen, LÜ Wu, XIE Zhi. Research on temperature prediction model of molten steel of tundish in continuous casting [J]. Scientific Reports, 2024, 14(1):1 - 21.

[5] 张宁, 谭亲跃, 张戈风. 温室地上环境因子模型研究综述[J]. 中国农学通报, 2019, 35(2):93 - 99.
ZHANG Ning, TAN Qinyue, ZHANG Gefeng. Ground environment factor model in greenhouse: a review[J]. Chinese Agricultural Science Bulletin, 2019, 35(2):93 - 99. (in Chinese)

[6] 陈昕, 唐湘璐, 李想,等. 二次聚类与神经网络结合的日光温室温度二步预测方法[J]. 农业机械学报, 2017, 48(增刊):353 - 358.
CHEN Xin, TANG Xianglu, LI Xiang, et al. Two-steps prediction method of temperature in solar greenhouse based on twice cluster analysis and neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(Supp.): 353 - 358. (in Chinese)

[7] ZOU Weidong, YAO Fenxi, ZHANG Baihai, et al. Verification and predicting temperature and humidity in a solar greenhouse based on convex bidirectional extreme learning machine algorithm[J]. Neurocomputing, 2017, 249:72 - 85.

[8] 谢秋菊, 马超凡, 王圣超,等. 猪舍氨气与二氧化碳浓度变化时序预测模型优化[J]. 农业机械学报, 2023, 54(7): 381 - 391.
XIE Qiuju, MA Chaofan, WANG Shengchao, et al. Optimal prediction model for gas concentrations of NH_3 and CO_2 time-series in pig house[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(7):381 - 391. (in Chinese)

[9] 董润婷, 吴利, 王晓英,等. 深度学习在天气预报领域的应用分析及研究进展综述[J]. 计算机应用, 2023, 43(6):1958 - 1968.
DONG Runting, WU Li, WANG Xiaoying, et al. Review of application analysis and research progress of deep learning in weather forecasting[J]. Journal of Computer Applications, 2023, 43(6):1958 - 1968. (in Chinese)

[10] 蒋鸿儒, 方巍. 深度学习在气象数据订正中的应用综述[J]. 计算机应用, 2024, 44(12):3930 - 3940.
JIANG Hongru, FANG Wei. Survey of application of deep learning in meteorological data correction[J]. Journal of Computer Applications, 2024, 44(12):3930 - 3940. (in Chinese)

[11] EL-BASIONI B M M, MOHAMED E S, BELAL A A, et al. A case study of a real-time internet of things system for site-specific potato crop management in El-Salhia Area-Egypt[J]. Scientific Reports, 2022, 12(1):1 - 29.

[12] ZAMORA-IZQUIERDO M A, SANTA J, MARTINEZ J A, et al. Smart farming IoT platform based on edge and cloud computing[J]. Biosystems Engineering, 2019, 177:4 - 17.

[13] 王纪章, 王涛, 付益辉,等. 数字孪生技术在农业生产管控中的应用现状与展望[J]. 农业机械学报, 2024, 55(9):1 - 20.
WANG Jizhang, WANG Tao, FU Yihui, et al. Application status and development prospects of digital twin technology in agricultural production process control[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(9):1 - 20. (in Chinese)

[14] 宗成骥, 王建玉, 宋卫堂,等. 基于天气预报的日光温室夜间逐时气温预测模型构建[J]. 农业工程学报, 2022, 38(增刊1):218 - 225.
ZONG Chengji, WANG Jianyu, SONG Weitang, et al. Construction and validation of hourly air temperature prediction model in solar greenhouse at night[J]. Transactions of the CSAE, 2022, 38(Supp.1):218 - 225. (in Chinese)

[15] 胡瑾, 雷文晔, 卢有琦,等. 基于1D CNN - GRU的日光温室温度预测模型研究[J]. 农业机械学报, 2023, 54(8):339 - 346.
HU Jin, LEI Wenye, LU Youqi, et al. Solar greenhouse temperature prediction model based on 1D CNN - GRU[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(8):339 - 346. (in Chinese)

[16] 祖林禄, 柳平增, 赵妍平,等. 基于SSA - LSTM的日光温室环境预测模型研究[J]. 农业机械学报, 2023, 54(2):351 - 358.
ZU Linlu, LIU Pingzeng, ZHAO Yanping, et al. Solar greenhouse environment prediction model based on SSA - LSTM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(2):351 - 358. (in Chinese)

[17] 李浩. 基于物联网的日光温室卷膜通风智能控制系统[D]. 杨凌:西北农林科技大学, 2024.
LI Hao. IoT-based intelligent control system for rollfilm ventilation in solar greenhouse[D]. Yangling: Northwest A&F University, 2024. (in Chinese)

[18] 张军华, 沈楷程, 陈丹艳,等. 基于物联网的日光温室冠层特征温度时空变化规律分析[J]. 农业机械学报, 2021, 52(7):335 - 342.
ZHANG Junhua, SHEN Kaicheng, CHEN Danyan, et al. Spatio-temporal variation of canopy characteristic temperature in solar greenhouse[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(7):335 - 342. (in Chinese)

[19] SENOO E E K, ANGGRAIN L, KUMI J A, et al. IoT solutions with artificial intelligence technologies for precision agriculture: definitions, applications, challenges, and opportunities[J]. Electronics, 2024, 13(10):1894.
[20] 吕欢欢, 牛源艺, 韩雨晓,等. 日光温室作物冠层夏季光照强度与空气温湿度时空变化规律研究[J]. 农业机械学报, 2024, 55(5):368－378.
LÜ Huanhuan, NIU Yuanyi, HAN Yuxiao, et al. Spatiotemporal variation of crop-canopy light intensity and air temperature and humidity in summer solar greenhouse[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(5): 368－378. (in Chinese)
[21] 王立舒, 李岩, 梁秋艳,等. 基于改进肖维涅算法的温室环境数据采集[J]. 农业工程学报, 2015, 31(5):212－217.
WANG Lishu, LI Yan, LIANG Qiuyan, et al. Greenhouse environmental data collection based on improved Chauvenet's criterion[J]. Transactions of the CSAE, 2015, 31(5):212－217. (in Chinese)
[22] 卢绮玲. 气象观测环境变化对气象记录准确性的影响情况分析[J]. 广东气象, 2003, 25(2):37－39..
[23] 王坤, 付钰, 段雪源,等. 基于深度学习的 SDN 异常流量分布式检测方法[J]. 通信学报, 2024, 45(11):114－130.
WANG Kun, FU Yu, DUAN Xueyuan, et al. Distributed abnormal traffic detection method for SDN based on deep learning [J]. Journal on Communications, 2024, 45(11):114－130. (in Chinese)
[24] 徐筠雯, 陈宗镭, 李天瑞,等. 基于季节分解的混合神经网络的时间序列预测[J]. 计算机科学, 2024, 51(增刊 2): 553－559.
XU Junwen, CHEN Zonglei, LI Tianrui, et al. Time series prediction of hybrid neural networks based on seasonal decomposition[J]. Computer Science, 2024, 51(Supp. 2):553－559. (in Chinese)
[25] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8):1735－1780.
[26] 刘建伟, 宋志妍. 循环神经网络研究综述[J]. 控制与决策, 2022, 37(11):2753－2768.
LIU Jianwei, SONG Zhiyan. Overview of recurrent neural networks[J]. Control and Decision, 2022, 37(11):2753－2768. (in Chinese)
[27] 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)
[28] VLADIMIR V, STEVEN E G, ALEX S. Support vector method for function approximation, regression estimation and signal processing[C]//Proceedings of the 10th International Conference on Neural Information Processing Systems,1996:281－287.
[29] 陈一飞, 齐凯, 刘柏成,等. 日光温室集群大系统的复杂性与系统控制[J]. 中南大学学报(自然科学版), 2013, 44(增刊 1):377－381.
CHEN Yifei, QI Kai, LIU Baicheng, et al. System control and complex characteristic of solar greenhouse cluster large system [J]. Journal of Central South University (Science and Technology), 2013, 44(Supp. 1):377－381. (in Chinese)
[30] 张琴琴, 刘文强, 陈之鸿,等. 基于 LSTM－SVM 模型的河流流量预测[J]. 天津师范大学学报(自然科学版), 2023, 43(6):45－52.
ZHANG Qinqin, LIU Wenqian, CHEN Zhihong,et al. Forecasting of river flow based on LSTM－SVM model[J]. Journal of Tianjin Normal University (Natural Science Edition), 2023, 43(6):45－52. (in Chinese)

(上接第 264 页)

[30] 沈金星. 水培蔬菜苗盘自动上盘系统设计[D]. 马鞍山:安徽工业大学, 2019.
SHEN Jinxing. Design of automatic tray system for hydroponic vegetable seedling[D]. Maanshan: Anhui University of Technology, 2018. (in Chinese)
[31] 贾洪雷, 房殿海, 刘慧力, 等. 车载智能土壤采样系统设计与试验[J]. 农业机械学报, 2020, 51(11): 292－301,312.
JIA Honglei, FANG Dianhai, LIU Huili, et al. Design and experiment of vehicle-mounted intelligent soil sampling system[J]. Transactions of the Chinese Society for Agricultural Machinery,2020,51(11):292－301,312. (in Chinese)
[32] 贺兴隆, 王玉琳. 控制力矩陀螺随形焊接装置的设计与实现[J]. 机床与液压, 2022, 50(21): 92－96.
HE Xinglong, WANG Yulin. Design and implementation of shape-follow welding device for control moment gyroscope[J]. Machine Tool & Hydraulics,2022,50(21):92－96. (in Chinese)
[33] GB/T 17587.5—2008　滚珠丝杠副 第 5 部分:轴向额定静载荷和动载荷及使用寿命[S].2008.
[34] GB/T 17587.3—2017　滚珠丝杠副 第 3 部分:验收条件和验收检验[S].2017.
[35] 袁小伟,杨双平,金若成,等. 双螺旋对辊式辣椒收获装置的设计与试验[J]. 农业工程学报,2021,37(15):1－9.
YUAN Xiaowei, YANG Shuangping, JIN Ruocheng, et al. Design and experiment of double helix pair roller pepper harvesting device[J]. Transactions of the CSAE,2021,37(15):1－9. (in Chinese)