

DOI: 10.13733/j.jcam.issn.2095-5553.2026.01.038

赵金彭, 张长富, 刘江, 等. 机器学习在日光温室温度预测的应用研究[J]. 中国农机化学报, 2026, 47(1): 274-285, 294

Zhao Jinpeng, Zhang Changfu, Liu Jiang, et al. Research on the application of machine learning in solar greenhouse temperature prediction [J]. Journal of Chinese Agricultural Mechanization, 2026, 47(1): 274-285, 294

机器学习在日光温室温度预测的应用研究*

赵金彭^{1, 2, 3}, 张长富¹, 刘江^{1, 2, 3}, 于景鑫^{2, 3}, 赵倩^{2, 3}, 魏晓明^{2, 3}

(1. 西安工业大学机电工程学院, 西安市, 710021; 2. 北京市农林科学院智能装备技术研究中心, 北京市, 100097; 3. 国家农业智能装备工程技术研究中心, 北京市, 100097)

摘要: 环境调控是日光温室精准控制的核心内容, 其中温度调控在提高能效和降低成本等方面产生重要影响。准确预测未来不同时段内温室的动态温度变化, 是实现温度精准调控的前提和基础。系统归纳当前的日光温室温度预测模型, 并根据模型理论依据的不同, 将日光温室温度预测模型分为传统温度预测模型和机器学习模型。在此基础上, 分析总结传统温度预测模型的发展现状, 包括机理模型和统计模型; 重点剖析机器学习模型的发展动态, 包括传统机器学习模型、深度学习模型、混合模型, 并说明不同模型的优势、局限性与应用场景, 并系统梳理机器学习模型的数据集类型与预处理方法。同时指出当前日光温室温度预测中存在的主要问题和研究方向, 认为当前的日光温室温度预测应当在构建多源多模态数据集、开发智能化数据预处理技术、发展多模型耦合集成预测、探索多场景分类预测等方面进行完善, 以为设施农业环境智能化管控提供指导。

关键词: 温室环境; 温度预测; 机器学习; 深度学习; 混合模型

中图分类号: S625 **文献标识码:** A **文章编号:** 2095-5553 (2026) 01-0274-13

Research on the application of machine learning in solar greenhouse temperature prediction

Zhao Jinpeng^{1, 2, 3}, Zhang Changfu¹, Liu Jiang^{1, 2, 3}, Yu Jingxin^{2, 3}, Zhao Qian^{2, 3}, Wei Xiaoming^{2, 3}

(1. College of Mechanical and Electrical Engineering, Xi'an Technological University, Xi'an, 710021, China; 2. Intelligent Equipment Technology Research Center, Beijing Academy of Agricultural and Forestry Sciences, Beijing, 100097, China; 3. National Engineering Research Center for Information Technology in Agriculture, Beijing, 100097, China)

Abstract: Environmental regulation is the core element of precise control in solar greenhouses, among which temperature control has a significant impact on improving energy efficiency and reducing costs. Accurately predicting the dynamic temperature changes in the greenhouse at different future time periods is a prerequisite and foundation for precise temperature control. This paper systematically summarizes the current temperature prediction models of solar greenhouses and categorizes them into traditional temperature prediction models and machine learning models based on different theoretical foundations of the models. On this basis, this paper analyzes and summarizes the current development state of traditional temperature prediction models, including mechanism-based and statistical models, focuses on analyzing the development trends of machine learning models, including traditional machine learning models, deep learning models, and hybrid models, and also explains the advantages, limitations, and application scenarios of different models, and systematically organizes the types of datasets and preprocessing methods for machine learning models. At the same time, it points out the main problems and research directions in the current temperature prediction of solar greenhouses. The study believes that the current temperature prediction of solar greenhouses should be improved in aspects such as building multi-source multi-modal datasets, developing intelligent data preprocessing technologies, developing multi-model coupling and integrated prediction, and

收稿日期: 2024 年 9 月 13 日 修回日期: 2025 年 4 月 30 日

* 基金项目: 山东省重点研发计划(重大科技创新工程)项目(2022CXGC020708); 北京市农林科学院 2024 年度科研创新平台建设(PT2024-29)

第一作者: 赵金彭, 男, 2000 年生, 山西长治人, 硕士研究生; 研究方向为机械工程。E-mail: 2194045776@qq.com

通讯作者: 魏晓明, 男, 1983 年生, 安徽涡阳人, 博士, 研究员; 研究方向为设施园艺工程。E-mail: weixm@nercita.org.cn

exploring multi-scenario classification prediction, with the aim of providing guidance for the intelligent management and control of the facility agricultural environment.

Keywords: greenhouse environment; temperature prediction; machine learning; deep learning; hybrid model

0 引言

温室园艺具有单产水平高、资源利用率高的特点,在保障重要农产品安全稳定供给方面发挥着重要的作用^[1]。据统计,我国温室占地面积约 1 900 km²,稳居世界第一^[2]。日光温室是我国北方主要的生产设施类型,运用现代工程技术设备,对其内部环境进行精准调控,以保护作物免受外界气候变化的影响。这一过程为作物营造了良好的生长条件。可调节的环境参数主要包括空气温度、空气相对湿度、光照强度、二氧化碳浓度、土壤温度和土壤湿度等关键因素^[3]。

室内温度是影响日光温室作物产量和品质的主要环境因子之一,其过高或过低都会对作物的生长产生危害^[4]。目前,日光温室内温度调控大多依靠生产者的经验进行决策,这种方式存在很大的滞后性,影响作物生长^[5]。研究表明,开展室内温度的提前预测对促进作物的生长及室内环境精准调控具有重要意义^[6]。

近年来,针对日光温室内温度预测的问题,国内外学者提出了一系列预测方法。例如:利用热量传递理论来预测温室内温度的变化,这种方法综合考虑了保

温、蓄热以及各组件的能量传递特征等关键因素^[7]。除此之外,基于统计学原理的温度预测因建模过程简单也备受学者的关注。近年来,随着人工智能算法的进步,以神经网络为代表的机器学习算法广泛应用于日光温室温度预测领域^[8]。

本文在系统归纳各类日光温室温度预测模型的基础上,总结日光温室温度预测模型的发展动态。重点阐述基于机器学习的日光温室温度预测模型的特点、性能、优势和局限性。根据日光温室温度及其他环境参数的变化规律,总结当前利用机器学习开展日光温室温度预测研究所面临的挑战、存在的问题和未来研究方向。

1 日光温室温度预测方法

近年来,学者在日光温室室内温度预测领域提出了一系列的预测模型和算法,这些方法的分类如图 1 所示。由于机器学习技术的不断发展以及基于机器学习的相关模型在时间序列预测研究中展现出的优越性能,日光温室温度预测从应用基于传热理论的机理模型和基于统计学原理的统计模型,逐步转变为研究能够捕获各影响因素时间相关性的机器学习模型。

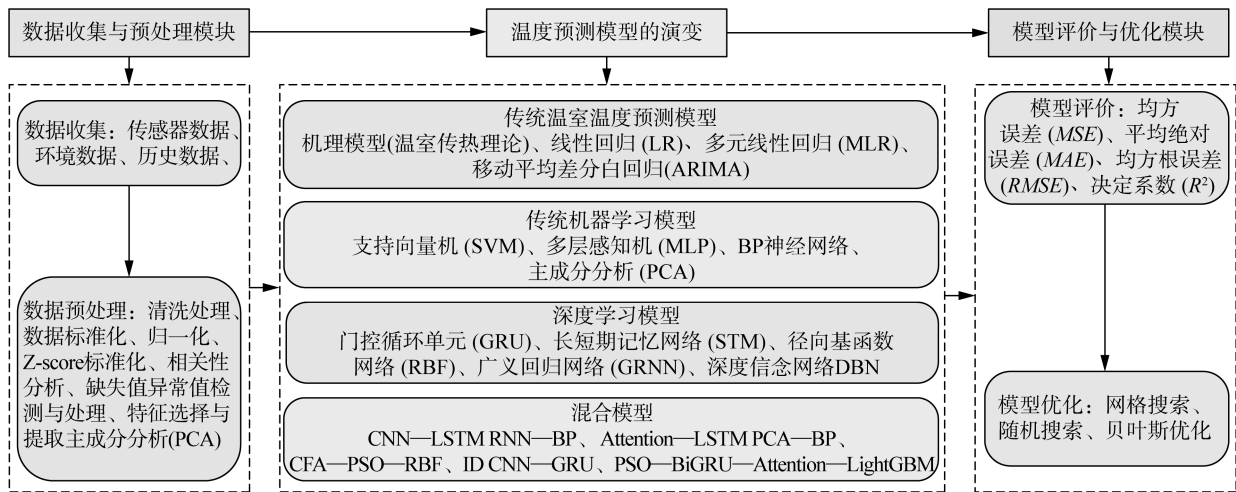


图 1 基于机器学习的温度预测

Fig. 1 Temperature prediction based on machine learning

1.1 传统温度预测方法

根据模型理论依据的不同,传统日光温室温度预测方法可分为基于温室传热理论的机理模型和基于统计学原理的统计模型两大类。

1.1.1 机理模型

机理模型^[9]是基于日光温室内外能量平衡和质量平衡原理,建立日光温室温度与各影响因素之间的

数学关系,从而进行预测。日光温室能量交换过程如图 2 所示。

国内外学者对基于机理模型预测室内温度进行了许多研究。Lian 等^[10]根据日光温室内土壤与空气的对流换热,对温室实时温度计算公式进行了简化,简化后的模型能够根据太阳辐射和土壤温度预测室内温度。Ahamed 等^[11]在日光温室室内热平衡的基础上建

立了采暖模型,预测土壤和北墙的表面温度。韦玉翡等^[12]通过采集的日光温室内外环境数据,结合改进的热量传递理论和质能平衡方程,构建并验证了一个室内温度的动态预测模型。机理模型具有较强的物理意义和可解释性,可以反映温室内外动态变化,适用于不同类型和规模的温室,也可以用于温室设计和优化。但是模型的参数较多,需要大量的数据和计算,模型精度受参数误差和模型假设的影响,对于温室内的局部温度分布和温度波动不够敏感。




图2 日光温室传热和能量交换

Fig. 2 Solar greenhouse heat transfer and energy exchange

1.1.2 统计模型

统计模型^[13]是基于温室温度与各影响因素之间的统计关系,利用历史数据进行预测的方法。统计模型的典型代表是线性回归(LR)、多元线性回归(MLR)和移动平均差分自回归(ARIMA)。田东等^[14]采用移动平均(MA)将温度序列分解为线性温度序列和非线性残差序列,并采用ARIMA对温度线性序列进行预测得到预测温度,将温度线性序列、非线性残差序列和预测温度序列作为输入变量建立日光温室未来2天的温度预测模型。左志宇等^[15]采用差分处理实现温度序列的平稳化,并使用ARMA预测日光温室室内温度。蔡淑芳等^[4]采用移动平均差分自回归(ARIMA)和径向基函数神经网络(RBF)组合建立日光温室温度预测模型。统计模型具有建模过程简单、不需要复杂的物理假设和参数、计算量小、精度较高等优点,但也存在缺乏物理意义和适应性、不能反映温室内外动态变化、也不能用于温室设计和优化等不足。

综上,基于机理和统计的传统温室温度预测方法虽然在一定程度上实现了温度的提前预警和调控,但仍然存在一些问题

1) 难以全面考虑影响温度的多种因素及其交互作用。温室环境是一个多因素耦合的复杂系统,既有显性因素(如通风、遮阳等控制量),也有隐性因素(如作物蒸腾、外部气象干扰等)。传统方法通常只考虑有限的几个主导因素,忽略因素之间的非线性耦合,导致模型的适用范围受限。

2) 无法充分挖掘和利用海量监测数据中蕴含的信息。随着温室物联网和传感技术的发展,温室环境监测呈现出多参数、高频次、大数据的特点。传统方法在处理高维时空数据时往往捉襟见肘,未能有效地挖掘和利用数据中的复杂模式和关联规律,难以进一步提升预测的精度。

3) 预测模型的适应性和泛化性不足。不同地区、不同类型的温室在结构参数、生态环境、管理模式等方面存在较大差异,导致温度的变化规律也不尽相同。传统方法得出的模型通常针对特定的温室,缺乏普适性,难以移植和推广到其他应用场景中。

针对上述问题,亟须探索一种新的温室温度预测范式,既能够充分挖掘和利用海量多源数据,又能够自适应地处理不同温室环境的动态变化,同时还具备一定的机理解释性和规律提炼能力。

1.2 机器学习模型

近年来,机器学习模型成为温度预测领域中最受学者欢迎的方法之一,并且从应用单一传统机器学习模型逐步转变为研究能够捕获时间相关性、多因素耦合、非线性的混合模型。

1.2.1 传统机器学习模型

传统机器学习模型是挖掘温室温度与各影响因素之间的数学规律,利用历史数据进行拟合和预测的方法。这类模型相对深度学习模型来说结构更为简单^[16]。常见的基于传统机器学习的温度预测算法有支持向量回归(SVM)、主成分回归(PCA)、BP神经网络和多层感知器(MLP)等。Taki等^[17]以伊朗连栋塑料膜温室为试验对象,使用13种训练算法训练SVM建立温度预测模型。He等^[18]基于SVM建立了不同输入变量下的日光温室温度预测模型。李宁等^[19]基于PCA建立了日光温室低温预测模型。Lei等^[20]基于随机森林(RF)建立了日光温室内的温度预测模型,并通过改变输入变量的组合方式研究输入变量个数对模型性能的影响。Mahmood等^[21]首先根据室外天气状况进行分类,然后基于MLP建立不同时间步长的温度预测模型。李欢等^[22]采用思维进化算法(MEA)优化LM-BP神经网络的输入权重和阈值建立温度预测模型,显著提高了模型的预测精度。表1为基于传统机器学习模型的温室温度预测方法总结。

对表1中所列举的基于传统机器学习模型的温室温度预测方法进行分析对比,可以发现,传统机器学习模型虽然在一定程度上提高了模型的预测精度,但是难以实现对大数据量的精准化预测,而温度变化是一个累积过程,当前数据会影响后续数据变化规律,且这种变化规律受多种因子影响,上述温度预测模型对多

维时序数据处理能力有限,仅能实现对短期温室温度的精准预测,随着预测时间的延长,其难以挖掘数据中

蕴含的时序特征,导致模型预测精度快速下降,难以满足实际生产过程中对精度和时长的双重需求。

表 1 基于传统机器学习的日光温室室内温度预测方法总结

Tab. 1 Summary of indoor temperature prediction methods in solar greenhouses based on traditional machine learning

模型	评价标准(时长)	优势	局限性	应用场景	参数设置
SVM ^[18]	$R^2=0.73\sim 0.89$	对样本数量小的日光温室温度数据处理效果很好。能够捕捉温度数据与各影响因素的非线性关系,学习速率快	当温度数据集容量较大、维度较高时,收敛速度慢,预测精度较低	小规模数据集	核函数选择、惩罚参数、核参数
MLP ^[21]	$R^2=0.82\sim 0.98$ (5~50 min)	在每一层都应用非线性激活函数,可以捕捉日光温室温度数据的深层特征和非线性关系	当温度发生突变时,模型预测性能下降,对异常温度值较敏感	通用场景	隐层节点数、学习率、训练轮数
BP ^[22]	$R^2=0.991$ 、 $MSE=1.34$ 、 $RMSE=1.16$	可以适应日光温室温度变化的动态特性,对于捕捉温室温度变化的复杂模式非常有用	学习速度慢、容易陷入局部最优,面对长时温度预测时,预测精度低	动态温度预测	学习率、隐层节点数、训练轮数
PCA ^[19]	$R^2=0.74\sim 0.91$	对于高维的温室数据,可以进行降维处理,能够消除温度影响因子之间的耦合性对预测结果的影响	对于非线性的温度数据,处理效果较差,在降维处理过程中,温度主成分可能丢失	高维数据处理	主成分数量、降维方法

1.2.2 深度学习模型

深度学习^[23]因具有较强的非线性逼近及深层特征提取能力成为当前研究的热点,通过构建深度学习模型,可以捕捉温室温度与各影响因子之间的复杂模式和长期依赖关系。常用的深度学习模型主要有门控循环单元(GRU)、长短期记忆神经网络(LSTM)、径向基函数神经网络(RBF)、广义回归神经网络(GRNN)和深度信念网络(DBN)等。LSTM 的核心在于设计了一种能够灵活控制信息流的细胞状态(Cell State)。该细胞状态贯穿整个序列,允许信息长期保存或遗忘。LSTM 由输入门(Input Gate)、遗忘门(Forget Gate)和输出门(Output Gate)构成,它们共同决定了细胞状态的更新以及最终的隐藏状态输出^[24]。长短期记忆网络结构如图 3 所示。Jung 等^[25]基于 LSTM 建立了不同时间步长的日光温室温度预测模型。




图 3 长短期记忆网络结构

Fig. 3 Long short-term memory network structure

RBF 网络由 3 个层次组成:输入层、隐含层和输出层。输入层由信号源结点组成,负责接收原始数据输入,直接将数据传递给隐含层。隐含层由一组径向基函数组成,每个基函数对应一个隐神经元。输出层的计算是基于隐含层输出的加权和。网络的参数主要

包括 3 种:径向基函数的中心、方差和隐含层到输出层的权值^[26]。径向基函数神经网络结构如图 4 所示。Monjezi 等^[27]基于 RBF、SVM、GPR 三种模型建立日光温室温度预测模型,研究表明,RBF 模型的预测精度更高。




图 4 径向基函数神经网络结构

Fig. 4 Radial basis function neural network structure

GRNN 是一种具有较好的非线性逼近能力的四层前向传播神经网络,它属于径向基神经网络的一种变形形式,数据输入网络后依次经过输入层、模式层、求和层、输出层得到输出结果,主要通过对模式层的平滑因子进行优化来获得好的输出结果^[28]。广义回归神经网络结构如图 5 所示。尹庆珍等^[29]针对新型复合墙体日光温室建立了基于广义回归神经网络温度预测模型,具有较好的精度和稳定性。




图 5 广义回归神经网络结构

Fig. 5 Generalized regression neural network structure

DBN 是一种深度神经网络,它包含多个层次,每一层都学习数据中的高级抽象特征^[30]。深度信念网络结

构如图 6 所示。周翔宇等^[31]针对传统机器学习预测精度低和学习时间长的问题,建立了基于改进的 DBN 的日光温室温度预测模型。徐宁等^[32]针对智能温室建立基于复数神经网络的温度预测模型,可以有效预测温室室内温度。GRU 将 LSTM 中的输入门和遗忘门合二为一,称为更新门(Update Gate),控制前边记忆信息能够继续保留到当前时刻的数据量;另一个门称为重置门(Reset Gate),控制要遗忘多少过去的信息^[33]。门控循环单元结构如图 7 所示。Acar 等^[34]基于支持向量机、长短期记忆网络、门控循环单元、随机森林、多元线性回归建立了不同输入变量下的日光温室温度预测模型,结果表明,门控循环单元预测性能最佳。表 2 为基于深度学习模型的温室温度预测方法总结。

对表 2 列举的基于深度学习模型的温室温度预测方法进行分析对比,可以发现,相较于传统机器学习模型,深度学习模型可以处理大型数据集,具有更强的非线性逼近及深层特征提取能力,为多维时序数据提供良好的理论支撑,提高了预测的准确性。但是目前基

于深度学习的温室温度预测相关研究多聚焦于单一时序网络,参数较多,模型结构复杂,无法挖掘环境数据间深层次的有效信息,仍不能真正满足模型精度、效率和时长的需求。




图 6 深度信念网络结构图

Fig. 6 Structure of a deep belief network (DBN)




图 7 门控循环单元结构图

Fig. 7 Gated recurrent unit (GRU) structure

表 2 基于深度学习的日光温室室内温度预测方法总结

Tab. 2 Summary of indoor temperature prediction methods in solar greenhouses based on deep learning

模型	评价指标(时长)	优势	局限性	应用场景	参数设置
GRU ^[34]	$R^2 = 0.88 \sim 0.95$	对输入变量不敏感,在输入变量较少的情况下,能实现较好预测	在不同温度情况下,预测精度不同	短期预测	隐层单元数、学习率、训练轮数
LSTM ^[25]	$R^2 = 0.84 \sim 0.98$ (5~30 min)	相对传统机器学习模型,预测精度更高,预测时间更长,能处理大量、高维数据	网络结构复杂,可解释性差,数据集样本数量少时,温度预测结果较差,容易过拟合	长期预测	隐层单元数、学习率、训练轮数
RBF ^[27]	$R^2 = 0.84 \sim 0.96$	全局逼近能力强、收敛速度快、泛化能力强	对噪声数据比较敏感,训练过程较复杂,当迭代次数较多时,易陷入局部最优	泛化能力强	中心数、宽度、学习率
GRNN ^[29]	$R^2 = 0.99$	能提取温室数据中的非线性关系,逼近复杂的非线性函数,参数固定,收敛速度快	对温度局部变化以及异常值比较敏感,容易过拟合	短期及长期预测	平滑因子
DBN ^[31]	MSE 较小	DBN 能自动学习温室环境数据中的复杂特征,适合于温室温度这类具有时间依赖性的数据	模型结构复杂,容易过拟合或者难以收敛	深层特征提取	隐层数、学习率、训练轮数

1.2.3 混合模型

基于混合模型^[35]的日光温室温度预测通常结合了多种建模技术,以提高预测的准确性和鲁棒性。混合模型可能包括机理模型、统计模型、传统机器学习模型和深度学习模型等,每种模型都针对特定的问题和数据类型进行了优化。在提升模型预测精度方面,Yu 等^[36]采用改进的粒子群优化算法(IPS0)优化最小二乘支持向量机(LSSVM)的超参数,建立了 IPS0—LSSVM 日光温室温度预测模型。杨雷等^[37]采用主成分分析法(PCA)、粒子群优化算法(PSO)优化最小二乘支持向量机(LSSVM)的超参数,建立

了 PCA—PSO—LSSVM 日光温室温度预测模型。李其操等^[38]采用 BP 神经网络和遗传算法(GA)对日光温室温度进行预测。Wang 等^[39]提出一种 RNN—BP 日光温室温度预测模型。张坤鳌等^[40]采用 CFA—PSO 算法对 RBF 模型的超参数(隐层中心及宽度)进行动态调优,建立 CFA—PSO—RBF 日光温室温度预测模型。Mao 等^[41]开发了一种结合双向门控循环单元(BiGRU—Attention)和梯度增强机(LightGBM)的日光温室温度预测模型,该模型利用注意机制来优化权重分配。此外,他们采用粒子群优化算法(PSO)对 BiGRU—Attention 和 LightGBM 在不

同时间点的组合权重系数进行优化。在改善模型预测时间步长方面, Li 等^[42]采用基于注意力机制的 LSTM 模型预测日光温室不同时间步长的温度, 在 8~16 步时间内, 模型预测精度高于单一 LSTM 模型, 有效提升了模型预测的时间步长。Jia 等^[43]建立了基于 LSTM 和 CNN-LSTM 的日光温室温度预测模型, 实现了未来较长时间内温度的准确预测。Yang 等^[44]利用 FAM-LSTM 方法, 根据不同时间步长的输入特征生成各自的关注权值, 以预测日光温室内的温度和湿度。在与 RNN、LSTM、GRU、FAM-RNN 和 FAM-GRU 等模型比较中, FAM-LSTM 展现出了对温室温度和湿度进行长时预测的能力。胡瑾等^[45]采用卷积神经网络和门控循环单元建立 1D CNN-GRU 温度预测模型, 既能有效提取数据中隐含的复杂高维特征, 又能提高处理非线性数据的能

力。Melal 等^[46]基于集成学习技术 (DT-RF-KNN-XGBoost) 建立日光温室湿度预测模型, 相比于单一模型, 集成模型预测精度更高。表 3 对基于混合模型的温室温度预测方法进行了总结。

对表 3 列举的基于混合模型的温室温度预测方法进行分析对比, 可以发现, 混合模型结合了不同模型的优点, 不同模型可能在特定方面表现更优, 混合模型可以利用这些互补优势, 如机理模型的理论基础和数据驱动模型的模式识别能力, 可以更全面地捕捉温室温度变化的复杂性和动态性, 有效提高了对新数据的泛化能力, 减少过拟合的风险。从预测精度上看, 混合模型的预测精度明显高于单一的深度学习模型和传统机器学习模型。但混合模型也存在结构相对复杂、集成策略和决策过程可能更难解释以及更多超参数等问题。

表 3 基于混合模型的日光温室室内温度预测方法总结

Tab. 3 Summary of indoor temperature prediction methods in solar greenhouses based on hybrid models

模型	评价指标(时长)	单一模型	混合模型	优势	局限性	应用场景	参数设置
IPSO-LSSVM ^[36]	$R^2=0.96$ (1~6t)	基本粒子群算法不能保证收敛到最优解, SVM 处理大规模数据集效果较差	IPSO 提高收敛概率, LSSVM 能更有效地处理大规模问题	动态优化超参数, 提高精度	超参数选择复杂	大规模数据预测	惩罚参数、核参数(γ)
PCA-PSO-LSSVM ^[37]	$R^2=0.97$	环境因子间多重耦合影响模型性能	PCA 降维消除耦合, PSO 优化超参数	消除变量耦合, 提高稳定性	超参数选择复杂	数据降维及优化	主成分数量、惩罚参数、核参数
RNN-BP ^[39]	$MAE=0.488$, $RMSE=0.751$ (16t)	BP 对温度峰值敏感, 预测波动较差	引入 RNN, 减小对峰值敏感度, 提高预测稳定性	捕捉时间序列特征, 性能稳定	训练时间长, 复杂度较高	动态温度预测	学习率、隐层节点数
Attention-LSTM ^[40]	$R^2=0.96\sim0.98$ (30~480 min)	LSTM 样本数据少时易过拟合	引入注意力机制, 动态调整权重, 减少过拟合	动态调整权重, 捕捉关键特征	训练复杂, 计算资源高	长期预测	学习率、隐层单元数
CNN-LSTM ^[41]	$R^2=0.98$ (3~24t)	LSTM 样本数据少时易过拟合	CNN 提取时间序列特征, 提高 LSTM 性能	自动特征提取, 性能稳定	训练复杂, 计算资源高	时间序列预测	学习率、卷积核数、隐层单元数
FAM-LSTM ^[42]	$R^2=0.96$ (12~48t)	LSTM 样本数据少时易过拟合	FAM 消除变量耦合, 减少时间消耗, 提高性能	消除耦合, 提高性能稳定性	超参数选择复杂	多步预测	学习率、隐层单元数
CFA-PSO-RBF ^[43]	$MAE=4.395$, $RMSE=5.179$	PSO 全局搜索和局部搜索能力不足	引入 CFA 改进 PSO, 提高全局和局部搜索能力	动态优化超参数, 提高精度	训练复杂, 计算资源高	超参数优化	隐层中心、宽度、学习率
1D-CNN-GRU ^[44]	$R^2=0.97\sim0.99$ (1~4t)	CNN 难提取长期序列信息, GRU 对温度波动敏感	结合 CNN 和 GRU 优势, 提高温度预测性能	提取动态变化特征, 性能稳定	训练复杂, 计算资源高	动态温度预测	卷积核数、隐层单元数
PSO-BiGRU-Attention-LightGBM ^[45]	$R^2=0.9902$, $MAE=0.3172$, $RMSE=0.5578$ (30~120 min)	单向 GRU 对历史信息敏感, LightGBM 对波动敏感	引入 PSO 和注意力机制, 动态优化权重, 提高预测精度	动态优化权重, 提高精度	训练复杂, 计算资源高	长期预测	学习率、卷积核数、隐层单元数

1.3 评价指标

为对比不同类型日光温室室内温度预测模型的预测精度, 引入一些标准的模型性能评价指标进行评估, 因为模型的预测结果会受到各种因素的影响, 例如模型本身、数据集和外部影响因素等。温室温度预测的相关

研究中, 常用评价指标有决定系数(R^2)、平均绝对误差(MAE)、平均绝对百分比误差(MAPE)、均方误差(MSE)、均方根误差(RMSE)。表 4 对上述 5 种评价指标进行总结。其中, y_i 是实际观测值, \hat{y}_i 是模型预测值, \bar{y} 是各观测值的平均值, n 是观测点的数量。

表 4 温室温度预测的评价指标

Tab. 4 Evaluation metrics for greenhouse temperature prediction

评价指标	定义	计算方法	适用条件	优点	缺点
R^2 ^[46]	反映预测值与观测值的相关程度,取值范围为 $[0, 1]$,越接近 1 越好	$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$	线性和非线性回归模型,数据分布不限	计算简单,结果直观,反映整体拟合优度	只度量相关性,不反映因果性,受样本量和异常值影响大
MSE ^[46]	预测值与观测值差值平方的平均值,越小越好	$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$	线性和非线性回归模型,数据分布不限	计算简单,放大较大误差的影响,惩罚极端偏差	量纲与数据相同,不同数据集间无可比性;受极端值主导,可能高估个别误差的影响
$RMSE$ ^[46]	预测值与观测值差值平方的平均值的平方根,越小越好	$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$	线性和非线性回归模型,数据分布不限	计算简单,结果直观,放大较大误差的影响,惩罚极端偏差;比 MSE 更稳健	量纲与数据相同,不同数据集间无可比性;受极端值主导,可能高估个别误差的影响
MAE ^[46]	预测值与观测值绝对值的平均值,越小越好	$MAE = \frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $	线性和非线性回归模型,数据分布不限	计算简单,结果直观,反映实际预测误差大小;对误差正负号不敏感,客观评估系统性偏差	量纲与数据相同,不同数据集间无可比性;受离群值影响大,可能低估较大误差的影响
$MAPE$ ^[46]	预测误差绝对值与观测值百分比的平均值,越小越好	$MAPE = \frac{1}{n} \sum_{i=1}^n \left \frac{y_i - \hat{y}_i}{y_i} \right $	线性和非线性回归模型,观测值非负且量级相近	无量纲,不同数据集间有可比性;百分比形式直观,易于解释和传播	观测值较小时误差会放大,观测值为 0 时无定义;受极端百分比误差主导

2 数据集与数据预处理方法

温室温度预测模型的性能很大程度上取决于训练数据的质量和数量。高质量的历史数据集是构建准确、鲁棒的预测模型的基础^[47]。

2.1 数据集类型

温室环境监测系统通常配备各种传感器和数据采集设备,可以连续记录温室内外环境参数、设备运行状态、结构材料与农事操作等多源数据。根据数据的来源和特点,可以将温室温度预测的数据集分为 4 类。

2.1.1 环境参数数据

环境参数数据是温室温度预测最常用的数据来源,主要包括温室内外空气温湿度、光照强度、二氧化碳浓度、风速等指标^[48]。这些参数通过温室内外部署的各类传感器实时采集,并以一定的时间频率(如每 1 min、每 5 min 等)记录和存储。环境参数数据直接反映了温室内外热量和物质交换过程,与温室内部温度的变化具有很强的相关性和因果性。因此,环境参数数据通常被视为温室温度预测模型的核心输入。

环境参数数据的特点是维度相对较低,一般在 10 个以内;时间序列较长,跨度从几天到几个月甚至几年不等;时间粒度较细,一般在分钟级别。这些特点决定了环境参数数据适合于时间序列预测模型的训练,如 ARIMA、RNN、LSTM 等。但环境参数数据也

存在一些问题,如不同参数的物理量纲和数值范围差异较大,需要进行归一化等预处理;部分参数存在较强的相关性和冗余性,需要进行特征选择或降维;传感器的故障、干扰等因素可能导致数据缺失或异常,需要进行数据清洗和插值等。因此,如何从环境参数数据中挖掘有价值的信息,构建稳定可靠的温室温度预测模型是一个值得深入研究的问题。

2.1.2 设备运行数据

除环境参数外,温室内部各类环境调控设备,如通风系统、补光灯、遮阳幕、热泵等的运行状态也会直接影响温室内部的热量平衡和温度分布^[49]。设备运行数据主要通过温室环境控制系统后台采集,包括设备的开关状态、运行功率、运行时长等信息。将设备运行数据纳入温室温度预测模型,可以提高模型对温室环境动态变化的刻画能力和预测精度,尤其是在设备调控较为频繁的情况下。

设备运行数据的特点是状态类型多,如两态(开、关)、三态(低、中、高)、连续(如开度百分比)等;时间粒度相对较粗,一般在分钟到小时级别。这些特点决定了设备运行数据不能直接用于时间序列预测模型,需要先进行状态量化或事件序列编码等预处理。此外,不同温室的环控设备配置差异较大,缺乏统一的数据采集和管理规范,导致不同来源的设备运行数据在语义、格式等方面不一致,给数据集的构建和模型的通用

化应用带来了挑战。

2.1.3 结构材料数据

温室的结构材料如覆盖材料、保温材料等的理化性能参数也会影响温室内部的散热和保温效果,进而影响内部空气温度的变化。结构材料数据主要通过产品说明或试验测试等方式获取,包括材料的密度、导热系数、比热容、透光率、透湿率等指标^[50]。将结构材料数据作为温室温度预测模型的辅助输入,可以提高模型对不同类型温室的适用性和外推性。

结构材料数据的特点是维度低,一般在 5 个以内;数值稳定,不随时间变化;获取成本高,依赖专业仪器和测试条件。这些特点决定了结构材料数据主要用于物理机理模型的参数估计和验证,很少直接用于数据驱动的机器学习模型。但借助一些先验知识和数据增强技术,将结构材料参数与环境参数数据相结合,有望提高机器学习模型的泛化性能和可解释性。

2.1.4 农事操作数据

农事操作如灌溉、施肥、通风、补光等改变温室内部的水分、养分、热量条件,间接影响温室空气温度^[51, 52]。农事操作数据主要通过人工记录或控制系统日志获取,包括操作的时间、方式、强度等信息。将农事操作数据纳入温室温度预测模型,可以提高模型对人为干预因素的考虑和适应能力。

农事操作数据的特点是事件驱动,时间分布不均匀;人工记录误差大,时间和空间上不连续^[53]。这些特点决定了农事操作数据很难直接用于连续时间序列预测模型,而更适用于离散事件序列或强化学习等模型。目前,农事操作数据在温室温度预测中的应用还比较少,主要原因是缺乏可靠、完备的数据采集手段和共享机制。随着农业物联网和智能手机的普及,通过应用 APP、语音识别、图像分类等技术实现农事操作的自动化记录 and 解析,有望为农事操作数据驱动的温室温度预测模型提供新的思路。

2.2 数据预处理方法

原始的温室环境监测数据和设备运行数据通常存在噪声干扰、异常值、缺失值等质量问题,直接用于温室温度预测模型的训练和测试会影响模型的性能和泛化能力^[54, 55]。因此,在构建机器学习模型之前,需要对原始数据进行一系列预处理操作,包括数据清洗、数据缺失修复、数据集成等,以提高数据的可用性和有效性。

2.2.1 数据清洗

数据清洗是指检测和去除数据中的噪声、异常值、不一致和重复数据的过程。常用数据清洗方法^[56]有 4 种。(1)异常值检测:利用统计方法(如 3σ 原则、箱线图)或机器学习方法(如聚类、孤立森林)识别和标记数

据中偏离正常范围或分布的异常值,如温度突变、湿度飙升等;(2)噪声去除:利用数字滤波方法(如移动平均滤波、中值滤波、小波去噪)或机器学习方法(如奇异值分解)平滑和去除数据中的高频随机噪声,提高信号的信噪比;(3)不一致校正:对不同来源、不同格式、不同时间戳的数据进行语义映射、格式转换、时间对齐等操作,消除数据之间的一致性,提高数据的可比性;(4)重复数据删除:对数据集中的重复记录或冗余特征进行识别和删除,减少数据的存储和计算开销,提高模型的训练效率。

数据清洗的关键是根据温室环境和设备的先验知识,设定合理的阈值、规则、约束等,既要尽可能地去除干扰因素,又要避免过度修改数据的原貌。清洗后的数据集应该更加准确、一致、简洁,为后续的特征工程和模型构建奠定基础。

2.2.2 数据缺失修复

由于传感器故障、通信中断、人为失误等原因,温室环境监测数据不可避免地存在不同程度的缺失现象。数据缺失会导致样本量减少、特征不完整、时间序列中断等问题,影响温室温度预测模型的训练和推理性能。常用的数据缺失修复方法^[57]有 5 种。(1)删除法:当缺失值所在的记录或特征的缺失率较高(如缺失率大于 50%)时,可以直接删除该记录或特征,避免缺失值带来的偏差和噪声;(2)均值、中位数、众数填充:用缺失值所在特征的均值、中位数或众数来替代缺失值,适用于缺失值随机分布且缺失率较低的情况;(3)最近邻插值:利用缺失值前后若干个时间点的有效观测值,通过线性插值或样条插值等方法估计缺失值,适用于时间序列数据的缺失修复;(4)回归、分类填充:根据缺失值所在特征与其他完整特征之间的相关关系,构建回归模型(对于连续型变量)或分类模型(对于离散型变量)来预测缺失值;(5)矩阵填充:利用低秩矩阵分解、自编码器等技术,通过最小化重构误差来估计数据矩阵中的缺失值,能够充分利用数据的全局结构和相关性。数据缺失修复的关键是权衡计算复杂度和估计精度之间的 trade-off,针对不同的缺失类型(完全随机缺失、随机缺失、完全非随机缺失)和不同的数据特点(时间序列、多元关联、高维稀疏等),选择合适的修复策略。修复后的数据集应该最大限度地保持原有数据分布的同时,又能满足机器学习模型对数据完整性和连续性的要求。

2.2.3 数据集成

数据集成是指将多源异构的数据进行清洗、转换、合并、统一表示的过程,目的是提高数据的一致性、完备性和可用性^[58]。在温室环境监测中,数据的来源和

类型高度多样化,如环境参数数据、设备运行数据、结构材料数据、农事操作数据等,且不同来源的数据在采集频率、数值精度、物理单位等方面存在较大差异。直接将这些原始数据输入机器学习模型,不仅会增加模型的学习难度,还可能引入噪声和偏差。因此,需要在数据预处理阶段对多源数据进行集成融合,形成一个高质量的训练数据集。常用的数据集成方法有4种。(1)数据同化:在物理机理模型的基础上,将观测数据与模型预测结果进行最优融合,动态更新模型的状态变量和参数,提高模型的估计精度和预测性能;(2)数据关联:通过时空对齐、属性匹配等操作,将不同来源的数据记录关联到同一时空框架下,形成一个多维属性表,关联过程中可能需要进行数据格式转换、语义映射、冗余属性删除等数据清洗操作;(3)数据融合:利用加权平均、贝叶斯估计、置信度投票等方法,将多个同类传感器或不同物理量的观测值融合成一个一致的估计值,减小观测误差和不确定性,也可以用机器学习模型(如多层感知机、自编码器)来自动学习不同特征的融合权重;(4)数据变换:对原始数据进行归一化、标准化等尺度变换,消除不同物理量之间数值范围的差异,进行特征编码、独热编码等类型变换,将非数值型变量转换为数值型变量,变换后的数据更加规则、稳定,有利于模型的收敛和泛化。

数据集成的关键是从物理机理出发,充分考虑不同环境要素、设备运行、结构材料、农艺措施等因素之间的内在联系,设计科学的融合架构和算法,最大限度地挖掘数据价值的同时,不引入额外的人为偏差。集成后的数据维度适中、信息丰富、冗余少、质量高,更加适合于数据驱动的建模分析和知识发现。

3 存在问题

尽管机器学习在温室温度预测中显示出良好的应用前景,但目前仍存在一些亟待解决的问题和挑战,主要体现在3个方面。

1) 多源异构数据的融合与预处理。温室环境是一个复杂的非线性动态系统,影响温室温度的因素涉及环境参数(如室内外温湿度、光照、风速等)、设施设备(如采暖通风系统、遮阳系统等)、结构材料(如覆盖材料、保温材料等)以及农事操作(如通风策略、灌溉施肥等)等多个方面。上述因素之间存在着多重耦合和交互作用,使得温室环境数据呈现出多源异构、高维复杂、动态变化的特点。如何有效地收集、处理和融合这些异构数据,提取对温度预测有价值的特征信息,是构建高精度预测模型的关键。目前大多数研究主要基于温室内外环境参数构建数据集,而忽略了设施设备、

结构材料等因素的影响,导致数据的代表性和完整性不足。此外,由于缺乏有效的数据清洗、特征选择和融合方法,原始数据中往往存在噪声干扰、信息冗余等问题,影响了模型的训练效果和泛化能力。

2) 模型的泛化性与适用性。不同地区的日光温室在室外气候条件、种植作物、设施设备、管理方式等方面存在显著差异,导致温室环境动态变化规律和影响机制也不尽相同。因此,在某一特定温室环境下训练得到的机器学习模型,其参数和结构未必能够直接迁移和适用于其他区域及其他结构的温室环境。目前的研究大多针对某一特定地区的某种温室类型展开,所构建的预测模型缺乏普适性,难以满足不同区域、不同类型温室的需求。如何在保证预测精度的同时,提高模型的泛化性和适用性,是一个亟待解决的问题。

3) 预测时域尺度的局限性。温室温度是一个连续动态变化的过程,具有明显的时间相关性和累积效应。当前的温度状态不仅取决于当前的影响因素,也与之前一段时间的温度状态和环境因素有关。因此,温室温度预测本质上是一个时间序列预测问题,需要考虑数据的时间维度特征。目前,大多数研究采用滑动窗口的方式构建时间序列样本,利用前一段时间的数据预测未来某一时刻的温度。这种单点预测模式只能实现对短期内温度的预估,预测精度会随时间尺度的增加而急剧下降。温室环境调控往往需要对未来较长一段时间内的温度变化进行预测,以便及时采取优化措施。因此,如何拓展机器学习模型的预测时域尺度,实现中长期乃至连续时间内的温度预测,是一个亟待突破的难题。

4 展望

1) 构建多源多模态数据集。当前机器学习温室温度预测模型使用的数据集主要来自温室内外环境监测系统,包括空气温湿度、光照强度、CO₂浓度等。这些环境参数数据虽然与温室温度密切相关,但仍难以全面刻画温室环境的热量收支特性。实际上,温室温度的变化是环境因素、结构材料、调控设备、农事操作等多重因素耦合作用的结果。因此,亟须拓展数据采集的广度和深度,构建多源、多模态、多尺度的温室环境数据集,为数据驱动的温度预测模型提供更加全面和丰富的样本信息。

2) 开发智能化数据预处理技术。原始采集的温室环境数据通常存在不同程度的噪声干扰、异常偏差、信息冗余等质量问题,严重影响数据驱动模型的训练效果和泛化能力。传统的数据预处理方法,如数据清洗、特征选择等,大多依赖于人工设定的阈值、规则或

准则,缺乏智能性和自适应性。因此,亟须开发能够自动优化数据质量、提高样本可用性的智能化预处理技术,减轻昂贵数据获取成本和繁重处理工作量,为后续的机器学习过程扫清数据障碍。

3) 发展多模型耦合集成预测方法。温室环境是一个时空多尺度、强耦合、非线性的复杂系统,不同时期、不同天气、不同作物下温室温度变化的内在机理和驱动模式差异很大。单一的机器学习模型,无论是经典的浅层模型,还是先进的深度模型,都难以全面刻画温室环境的复杂性,尤其是在极端天气、设备故障、幅度波动等非常规情景下,预测的精度和稳健性大打折扣。因此,亟须发展融合多种模型的集成预测方法,发挥不同模型的互补优势,从机理、数据、算法等多角度协同增强温度预测的能力。

4) 探索多场景分类预测方法。温室环境调控的核心目标是在动态多变的外部环境下,通过精准调节内部环境要素,实现作物生长性能的持续优化。但不同时期、不同天气、不同作物对环境温度的需求差异很大,“一刀切”的温度预测模型难以满足差异化、精细化环境调控的需求。因此,亟须针对不同应用场景开发有针对性的分类预测方法,通过环境分型、作物分类、模型分治,在提高预测精度的同时,提升预测结果对实际调控的指导性。

5 结语

针对日光温室温度预测,从数据、模型、分析、应用等多个角度进行系统梳理和归纳总结。通过文献调研和理论分析,概括日光温室温度预测的主要影响因素,评述典型的机器学习预测模型,剖析共性的难点和挑战,展望未来的重点研究方向。

1) 全面综合分析多源数据,揭示日光温室热量收支的驱动机制,构建高维语义特征空间,是温度预测的理论基础和数据基础。

2) 当前日光温室温度预测普遍采用的机器学习模型可分为传统机器学习、深度学习和混合模型三大类。发掘异构模型的互补性,因地制宜地开发多场景分类预测体系,是数据驱动温度调控的关键。

3) 选择最佳的模型参数、缓解数据质量问题、简化模型复杂度、平衡欠拟合与过拟合、设计可解释的评价机制,是提高预测模型实用性的必由之路。

4) 今后应着重开展的研究:构建多源异构数据融合集成技术,突破温度预测的数据瓶颈;发展自适应数据清洗、修复、降噪等预处理技术,提升样本质量;创新多模型协同集成、端到端自优化等方法,增强预测泛化性;针对环境、作物、调控需求等细分场景,探索精细

化、个性化预测理论与方法。

参 考 文 献

- [1] 中华人民共和国农业农村部. 全国现代设施农业建设规划(2023—2030年)[EB/OL]. http://www.jcs.moa.gov.cn/gzdt/202306/t20230615_6430323.htm, 2023-6-15.
- [2] 李天来. 设施蔬菜产业发展(一)我国设施蔬菜产业发展现状及展望[J]. 中国蔬菜, 2023(9): 1-6.
Li Tianlai. Development status of China's facility vegetable industry and outlook [J]. China Vegetables, 2023(9): 1-6.
- [3] 李伟, 金梁, 杜丽. 基于灰熵关联分析的温室智能调控系统研究[J]. 灌溉排水学报, 2022, 41(1): 57-61, 71.
Li Wei, Jin Liang, Du Li. A smart control system for greenhouse designed based on grey entropy correlation analysis [J]. Journal of Irrigation and Drainage, 2022, 41(1): 57-61, 71.
- [4] 蔡淑芳, 林营志, 吴宝意, 等. 利用线性和非线性耦合方式建立温室温湿度预测模型[J]. 中国农业气象, 2022, 43(7): 527-537.
Cai Shufang, Lin Yingzhi, Wu Baoyi, et al. Greenhouse temperature and humidity prediction models based on linear and nonlinear coupling methods [J]. Chinese Journal of Agrometeorology, 2022, 43(7): 527-537.
- [5] 高立婷, 戴思慧, 李明, 等. 基于作物与能耗的温室加温调控方法[J]. 中国农机化学报, 2021, 42(5): 49-54.
Gao Liting, Dai Sihui, Li Ming, et al. Control method of heating in greenhouse based on crop and energy consumption [J]. Journal of Chinese Agricultural Mechanization, 2021, 42(5): 49-54.
- [6] 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: 227-238.
- [7] 秦琳琳, 马娇, 黄云梦, 等. 基于积温理论的温室温度混杂系统预测控制[J]. 农业机械学报, 2018, 49(10): 347-355.
Qin Linlin, Ma Jiao, Huang Yunmeng, et al. Predictive control of greenhouse temperature hybrid system based on crop temperature integration theory [J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(10): 347-355.
- [8] Fan L, Ji Y, Wu G. Research on temperature prediction model in greenhouse based on improved SVR [J]. Journal of Physics: Conference Series, 2021, 1802(4): 14-15.
- [9] 于威, 刘文合, 白义奎, 等. 基于CFD的两连跨日光温室热环境模拟[J]. 农业工程学报, 2023, 39(16): 215-222.
Yu Wei, Liu Wenhe, Bai Yikui, et al. Simulating thermal environment in a two-span solar greenhouse using CFD [J]. Transactions of the Chinese Society of

- Agricultural Engineering, 2023, 39(16): 215–222.
- [10] Lian H D, Lin H, Ying Z, et al. Analytic model for calculation of soil temperature and heat balance of bare soil surface in solar greenhouse [J]. Solar Energy, 2023, 249: 312–326.
- [11] Ahamed M S, Guo H, Tanino K. Development of a thermal model for simulation of supplemental heating requirements in Chinese-style solar greenhouses [J]. Computers and Electronics in Agriculture, 2018, 150: 235–244.
- [12] 韦玉翡, 赵建贵, 高安琪, 等. 温室小气候温度和湿度动态模型预测及验证[J]. 湖北农业科学, 2021, 60(9): 32–38.
- [13] 马超凡, 谢秋菊, 王圣超, 等. 融合统计学习与深度学习的猪舍环境预测模型[J]. 山西农业大学学报(自然科学版), 2022, 42(6): 24–32.
Ma Chaofan, Xie Qiuju, Wang Shengchao, et al. A prediction model for environmental factors in a pig house based on statistical learning and deep learning [J]. Journal of Shanxi Agricultural University (Natural Science Edition), 2022, 42(6): 24–32.
- [14] 田东, 韦鑫化, 王悦, 等. 基于 MA—ARIMA—GASVR 的食用菌温室温度预测[J]. 农业工程学报, 2020, 36(3): 190–197.
Tian Dong, Wei Xinhua, Wang Yue, et al. Prediction of temperature in edible fungi greenhouse based on MA—ARIMA—GASVR [J]. Transactions of the Chinese Society of Agricultural Engineering, 2020, 36(3): 190–197.
- [15] 左志宇, 毛罕平, 张晓东, 等. 基于时序分析法的温室温度预测模型[J]. 农业机械学报, 2018, 41(11): 173–177, 182.
Zuo Zhiyu, Mao Hanping, Zhang Xiaodong, et al. Forecast model of greenhouse temperature based on time series method [J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 41(11): 173–177, 182.
- [16] Qian L, Zheng Y, Li L, et al. A new method of inland water ship trajectory prediction based on long short-term memory network optimized by genetic algorithm [J]. Applied Sciences, 2022, 12(8): 4073.
- [17] Taki M, Mehdizadeh S A, Rohani A, et al. Applied machine learning in greenhouse simulation; new application and analysis [J]. Information Processing in Agriculture, 2018, 5(2): 253–268.
- [18] He Z, Jiang T, Jiang Y, et al. Gated recurrent unit models outperform other machine learning models in prediction of minimum temperature in greenhouse based on local weather data [J]. Computers and Electronics in Agriculture, 2022, 202: 107416.
- [19] 李宁, 申双和, 黎贞发, 等. 基于主成分回归的日光温室内低温预测模型[J]. 中国农业气象, 2018(3): 306–311.
Li Ning, Shen Shuanghe, Li Zhenfa, et al. Forecast model of minimum temperature inside greenhouse based on principal component regression [J]. Chinese Journal of Agrometeorology, 2018(3): 306–311.
- [20] Zhao L, Lu L, Liu H, et al. A one-dimensional transient temperature prediction model for Chinese assembled solar greenhouses [J]. Computers and Electronics in Agriculture, 2023, 215: 108450.
- [21] Mahmood F, Govindan R, Bermak A, et al. Energy utilization assessment of a semi-closed greenhouse using data-driven model predictive control [J]. Journal of Cleaner Production, 2021, 324: 129172.
- [22] 李欢, 田芳明, 谭峰, 等. 基于 MEA—LM—BP 神经网络的棚室温度预测模型研究[J]. 农机化研究, 2021, 43(6): 189–193.
- [23] 皮轶轩, 张锦水, 马然, 等. 基于深度学习的温室大棚实例识别及模型迁移[J]. 农业工程学报, 2023, 39(23): 185–195.
Pi Yixuan, Zhang Jinshui, Ma Ran, et al. Recognizing greenhouse instance and model transfer using deep learning [J]. Transactions of the Chinese Society of Agricultural Engineering, 2023, 39(23): 185–195.
- [24] Codeluppi G, Davoli L, Ferrari G. Forecasting air temperature on edge devices with embedded AI [J]. Sensors, 2021, 21(12): 3973.
- [25] 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: 105402.
- [26] 梁华典, 洪天华, 高琦, 等. 基于滑模和径向基函数神经网络的城市轨道交通列车速度跟踪控制算法[J]. 城市轨道交通研究, 2024, 27(5): 73–77.
Liang Huadian, Hong Tianhua, Gao Qi, et al. Research on speed tracking control algorithm for urban rail transit trains based on sliding mode and RBF neural network [J]. Urban Mass Transit, 2024, 27(5): 73–77.
- [27] Monjezi P, Taki M, Abdanan M S, et al. Prediction of greenhouse indoor air temperature using Artificial Intelligence (AI) combined with sensitivity analysis [J]. Horticulturae, 2023, 9(8): 853.
- [28] 翟光耀, 章政, 郭昱琛, 等. 基于广义回归神经网络的视觉球形机器人建模[J]. 传感器与微系统, 2024, 43(6): 15–19.
Zhai Guangyao, Zhang Zheng, Guo Yuchen, et al. Visual spherical robot modeling based on generalized regression neural network [J]. Transducer and Microsystem Technologies, 2024, 43(6): 15–19.
- [29] 尹庆珍, 张天策, 郗丽娟, 等. 基于广义回归神经网络异质复合墙体日光温室温度场的预测[J]. 中国农业大学学报, 2019, 24(6): 137–146.
Yin Qingzhen, Zhang Tiance, Qie Lijuan, et al.

- Temperature field prediction and application of heterogeneous composite wall in solar greenhouse based on general regression neural network [J]. *Journal of China Agricultural University*, 2019, 24(6): 137-146.
- [30] 方娜, 陈浩, 邓心, 等. 基于 VMD—ARIMA—DBN 的短期电力负荷预测[J]. *电力系统及其自动化学报*, 2023, 35(06): 59-65.
Fang Na, Chen Hao, Deng Xin, et al. Short-term power load forecasting based on VMD—ARIMA—DBN [J]. *Proceedings of the CSU-EPSA*, 2023, 35(6): 59-65.
- [31] 周翔宇, 程勇, 王军, 等. 基于改进深度信念网络的农业温室温度预测方法[J]. *计算机应用*, 2019, 39(4): 1053-1058.
Zhou Xiangyu, Cheng Yong, Wang Jun, et al. Agricultural greenhouse temperature prediction method based on improved deep belief network [J]. *Journal of Computer Applications*, 2019, 39(4): 1053-1058.
- [32] 徐宇, 冀荣华. 基于复数神经网络的智能温室温度预测研究[J]. *中国农机化学报*, 2019, 40(4): 174-178.
Xu Yu, Ji Ronghua. Research on temperature prediction of intelligent greenhouse based on complex neural network [J]. *Journal of Chinese Agricultural Mechanization*, 2019, 40(4): 174-178.
- [33] 杜丽娜, 杨硕, 卓力, 等. 基于 ResNet—TSM 和 BiGRU 网络的移动视频感知质量评价模型[J]. *北京工业大学学报*, 2024, 50(1): 18-26.
Du Lina, Yang Shuo, Zhuo Li, et al. Mobile video perceptual quality assessment model with ResNet—TSM and BiGRU network [J]. *Journal of Beijing University of Technology*, 2024, 50(1): 18-26.
- [34] Acar Z, Nguyen P, Cui X, et al. Room temperature ionic liquids viscosity prediction from deep-learning models [J]. *Energy Materials*, 2023, 3(5): 300039.
- [35] 杨秋颖, 翁小清. 基于 2dSVD 和高斯混合模型的多变量时间序列聚类[J]. *计算机应用与软件*, 2024, 41(3): 283-289, 27.
Yang Qiuying, Weng Xiaoqing. Multi-Variate time series clustering based on two-dimensional singular value decomposition and gaussian mixture model [J]. *Computer Applications and Software*, 2024, 41(3): 283-289, 27.
- [36] Yu H, Dong H, Zeng Z, et al. Modeling temporal dual variations for return air temperature prediction of mK—level temperature-controlled clean chamber [J]. *Journal of Building Engineering*, 2024, 86: 108917.
- [37] 杨雷, 张宝峰, 朱均超, 等. 基于 PCA—PSO—LSSVM 的温室大棚温度预测方法[J]. *传感器与微系统*, 2018, 37(7): 52-55.
Yang Lei, Zhang Baofeng, Zhu Junchao, et al. Temperature prediction method of greenhouse based on PCA—PSO—LSSVM [J]. *Transducer and Microsystem Technologies*, 2018, 37(7): 52-55.
- [38] 李其操, 董自健. 基于 GA—BP 神经网络的温室温度预测研究[J]. *智能计算机与应用*, 2023, 13(9): 168-171.
Li Qicao, Dong Zijian. Greenhouse temperature prediction based on GA—BP neural network [J]. *Intelligent Computer and Applications*, 2023, 13(9): 168-171.
- [39] Wang L, Dai W, Liu J, et al. Research on the prediction model of greenhouse temperature based on fuzzy neural network optimized by genetic algorithm [J]. *IAENG International Journal of Computer Science*, 2022, 49(3): 828-832.
- [40] 张坤鳌, 赵凯. 基于改进 CFA PSO—RBF 神经网络的温室温度预测研究[J]. *计算机应用与软件*, 2020, 37(6): 95-99.
Zhang Kunao, Zhao Kai. Greenhouse temperature prediction based on improved CFA PSO—RBF neural network [J]. *Computer Applications and Software*, 2020, 37(6): 95-99.
- [41] Mao X, Ren N, Dai P, et al. A variable weight combination prediction model for climate in a greenhouse based on BiGRU—Attention and LightGBM [J]. *Computers and Electronics in Agriculture*, 2024, 219: 108818.
- [42] Li X, Zhang L, Wang X, et al. Forecasting greenhouse air and soil temperatures: A multi-step time series approach employing attention-based LSTM network [J]. *Computers and Electronics in Agriculture*, 2024, 217: 108602.
- [43] Jia W, Wei Z. Short term prediction model of environmental parameters in typical solar greenhouse based on deep learning neural network [J]. *Applied Sciences*, 2022, 12(24): 12529.
- [44] Yang Y, Gao P, Sun Z, et al. Multistep ahead prediction of temperature and humidity in solar greenhouse based on FAM—LSTM model [J]. *Computers and Electronics in Agriculture*, 2023, 213: 108261.
- [45] 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.
- [46] Melal S R, Aminian M, Shekarian S M. A machine learning method based on stacking heterogeneous ensemble learning for prediction of indoor humidity of greenhouse [J]. *Journal of Agriculture and Food Research*, 2024, 16: 101107.
- [47] Lei Z, Liang C L, Han L L, et al. A one-dimensional transient temperature prediction model for Chinese assembled solar greenhouses [J]. *Computers and Electronics in Agriculture*, 2023, 215: 108450.

(下转第 294 页)

- 验[J]. 农业机械学报, 2022, 53(2): 386—392.
- Che Gang, Wang Hongchao, Wan Lin, et al. Design and test of varying temperature mixing device on paddy rice drying [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(2): 386—392.
- [7] 盛韶阳, 吴敏, 胡纯秋, 等. 热风—真空复合工艺干燥玉米力学特性研究[J]. 农业机械学报, 2020, 51(S1): 476—482.
- [8] 张紫恒, 张吉军, 唐正, 等. 北方粳高粱微波干燥特性试验与仿真分析[J]. 中国农机化学报, 2021, 42(11): 65—71. Zhang Ziheng, Zhang Jijun, Tang Zheng, et al. Experiment and simulation analysis of microwave drying characteristics of northern Japonica Sorghum [J]. Journal of Chinese Agricultural Mechanization, 2021, 42(11): 65—71.
- [9] 于海明, 李海源, 张欣悦, 等. 水稻秸秆营养穴盘微波热风耦合干燥动力学模型研究[J]. 农业机械学报, 2020, 51(5): 339—348. Yu Haiming, Li Haiyuan, Zhang Xinyue, et al. Drying kinetic model of microwave coupled with hot air drying of straw-based nutrient seedling-growing bowl tray [J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(5): 339—348.
- [10] Guemouni S, Mouhoubi K, Brahmi F, et al. Convective and microwave drying kinetics and modeling of tomato slices, energy consumption, and efficiency [J]. Journal of Food Process Engineering, 2022, 45: e14113.
- [11] 姜春慧, 张倩, 杨娜, 等. 桔梗切片远红外干燥特性及动力学研究[J]. 中国农机化学报, 2021, 42(2): 92—100. Jiang Chunhui, Zhang Qian, Yang Na, et al. Study on far infrared drying characteristics and kinetics of platycodon grandiflorum slices [J]. Journal of Chinese Agricultural Mechanization, 2021, 42(2): 92—100.
- [12] 李树君. 农产品微波组合干燥技术[M]. 北京: 中国科学技术出版社, 2015.
- [13] Yuan L, Zheng X, Shen L. Continuous microwave drying of germinated red adzuki bean: Effects of various drying conditions on drying behavior and quality attributes [J]. Journal of Food Processing and Preservation, 2022, 46: e17090.
- [14] 王雪媛, 陈芹芹, 毕金峰, 等. 热风—脉动压差闪蒸干燥对苹果片水分及微观结构的影响[J]. 农业工程学报, 2015, 31(20): 287—293. Wang Xueyuan, Chen Qinqin, Bi Jinfeng, et al. Effect of hot air-pulsed sudden decompression flashing drying on moisture and microstructure in apple slices [J]. Transactions of the Chinese Society of Agricultural Engineering, 2015, 31(20): 287—293.
- (上接第 285 页)
- [48] 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, 167.
- [49] 高玲, 杨亚男. 基于电子信息技术温室环境自动调控系统设计[J]. 农机化研究, 2024, 46(11): 126—130.
- [50] 张观山, 李天华, 侯加林, 等. 考虑动态吸收率的玻璃温室覆盖层温度预测模型[J]. 农业工程学报, 2020, 36(5): 201—211. Zhang Guanshan, Li Tianhua, Hou Jialin, et al. Model for predicting the temperature of glass greenhouse cover considering dynamic absorptivity [J]. Transactions of the Chinese Society of Agricultural Engineering, 2020, 36(5): 201—211.
- [51] 张增林, 杨杰, 郭常江, 等. 设施生菜光合和蒸腾速率影响因素分析与预测模型构建[J]. 农业机械学报, 2024, 55(1): 339—349. Zhang Zenglin, Yang Jie, Guo Changjiang, et al. Analysis and model construction of factors affecting photosynthesis and transpiration rates in facility lettuce [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(1): 339—349.
- [52] Farhat M, Rajesh G, Amine B, et al. Energy utilization assessment of a semi-closed greenhouse using data-driven model predictive control [J]. Journal of Cleaner Production, 2021, 324: 129172.
- [53] Abbood H M, Nouri N M, Riahi M, et al. An intelligent monitoring model for greenhouse microclimate based on RBF neural network for optimal setpoint detection [J]. Journal of Process Control, 2023, 129: 103037.
- [54] Cai W, Wei R, Xu L, et al. A method for modelling greenhouse temperature using gradient boost decision tree [J]. Information Processing in Agriculture, 2022, 9(3): 343—354.
- [55] 许泽海, 赵燕东. 融合物联网多环境参数的茎干水分 SSA—BP 预测模型[J]. 农业工程学报, 2023, 39(16): 150—159. Xu Zehai, Zhao Yandong. SSA—BP model for predicting water contents in stem integrating multiple environmental factors acquired via IoT [J]. Transactions of the Chinese Society of Agricultural Engineering, 2023, 39(16): 150—159.
- [56] 徐爽, 蔡鸿明, 赵林畅, 等. 一种用于农产品供应链风险预测评估的贝叶斯决策树算法模型[J]. 西南大学学报(自然科学版), 2024, 46(3): 189—200. Xu Shuang, Cai Hongming, Zhao Linchang, et al. Research on risk assessment of agricultural products supply chain based on decision tree algorithm [J]. Journal of Southwest University (Natural Science Edition), 2024, 46(3): 189—200.
- [57] 王鼎, 王将宇, 乔俊飞. 融合自适应评判的随机系统数据驱动策略优化[J]. 自动化学报, 2024, 50(5): 980—990.
- [58] Lu W, Rui H, Liang C, et al. A method based on GA—CNN—LSTM for daily tourist flow prediction at scenic spots [J]. Entropy, 2020, 22(3): 261.