

基于 1D CNN – GRU 的日光温室温度预测模型研究

胡 瑾^{1,2} 雷文晔^{1,3} 卢有琦^{1,2} 魏子朝^{1,3} 刘行行^{1,2} 高茂盛⁴

(1. 西北农林科技大学机械与电子工程学院, 陕西杨凌 712100; 2. 农业农村部农业物联网重点实验室, 陕西杨凌 712100; 3. 陕西省农业信息感知与智能服务重点实验室, 陕西杨凌 712100; 4. 杨凌高新农业气象技术联合研示中心, 陕西杨凌 712100)

摘要: 准确预测日光温室温度是实现温室高效调控的关键,对作物生长发育具有重要意义,但因温度具有时序性、非线性及多耦合性等特征,难以实现连续、精准、长时化预测。提出了一种基于 1D CNN – GRU (One dimensional convolutional neural networks – gated recurrent unit) 的日光温室温度预测模型,通过温室内外监测平台获取内外环境因子,以斯皮尔曼相关系数获取相关性强特征,构造特征与时间步长的二维矩阵输入网络进行温度预测,模型在测试集上预测 1 ~ 4 h 后的决定系数为 0.970 ~ 0.994,均方根误差为 0.612 ~ 1.358℃,平均绝对误差为 0.428 ~ 0.854℃,绝对值的最大绝对误差为 0.856 ~ 1.959℃。并在不同清晰度指数 K_T 下进行验证,结果表明,模型在 $K_T \geq 0.5$ (晴)时预测效果最好,且在其他 K_T 下模型相对误差在 10% 以内,可以达到温室生产所需的预测精度要求,为日光温室精准高效控温提供了重要依据。

关键词: 日光温室; 温度; 预测模型; 一维卷积神经网络; 门控循环单元

中图分类号: S624.4⁺2 文献标识码: A 文章编号: 1000-1298(2023)08-0339-08

OSID:



Solar Greenhouse Temperature Prediction Model Based on 1D CNN – GRU

HU Jin^{1,2} LEI Wenyue^{1,3} LU Youqi^{1,2} WEI Zichao^{1,3} LIU Hangxing^{1,2} GAO Maosheng⁴

(1. College of Mechanical and Electronic Engineering, Northwest A&F University, Yangling, Shaanxi 712100, China
2. Key Laboratory of Agricultural Internet of Things, Ministry of Agriculture and Rural Affairs, Yangling, Shaanxi 712100, China
3. Shaanxi Key Laboratory of Agricultural Information Awareness and Intelligent Services, Yangling, Shaanxi 712100, China
4. Yangling High-tech Agricultural Technology Combined Research Center, Yangling, Shaanxi 712100, China)

Abstract: Accurate prediction of heliostat temperature was the key to achieve efficient greenhouse regulation, which was of great importance to crop growth and development, but it was difficult to achieve continuous and accurate prediction due to the characteristics of time series, nonlinearity and multi coupling of temperature. At the same time, the current production regulation of greenhouse mostly depended on the relevant experience of producers. This method had caused the lag of feedback control and affected the growth of crops. A temperature prediction model of solar greenhouse based on 1D CNN – GRU was proposed. The internal and external environmental factors were obtained through the monitoring platform inside and outside the greenhouse, and the strong correlation features and structural features were obtained by Spearman correlation coefficient and the two-dimensional matrix input network with time step, which was used for temperature prediction. The determination coefficient of the model after 1 ~ 4 h prediction on the test set was 0.970 ~ 0.994, the root mean square error was 0.612 ~ 1.358℃, the average error was 0.428 ~ 0.854℃, and the maximum absolute error after the absolute value was 0.856 ~ 1.959℃. The model was verified under different K_T and the results showed that the model had the best prediction effect when $K_T \geq 0.5$ (sunny), and the model also achieved ideal prediction accuracy under other K_T , indicating that the model was universal and provided an important basis for accurate and efficient temperature control of solar greenhouse.

Key words: solar greenhouse; temperature; prediction model; one-dimensional convolutional neural networks; gated recurrent unit

收稿日期: 2022 – 12 – 08 修回日期: 2023 – 02 – 10

基金项目: 国家重点研发计划项目(2020YFD1100602)和陕西省重点研发计划项目(2021ZDLNY03 – 02)

作者简介: 胡瑾(1980—),女,教授,主要从事设施光环境调控和智能信息处理研究, E-mail: hujin007@nwsuaf.edu.cn

0 引言

温度是影响日光温室内农作物产量和品质的重要参数之一,其过高或过低均会对农作物生长发育产生危害^[1-2]。随着设施农业不断发展,日光温室已成为设施农业的重要组成部分,对我国经济发展发挥着显著作用。温度调控是日光温室环境调控的重要手段^[3],但温室温度不仅是具有时变性、非线性、周期性^[4]等特征的连续时间序列,还与温室内外多种环境因子存在复杂的耦合关系。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^[5],这种方法会造成反馈控制存在滞后性,影响作物生长。研究证明,提前预测温度并进行提前的有效控制,对日光温室的增产增效具有重要意义^[6]。因此,融合温室内外多环境因子构建温室温度长期预测模型,是日光温室温度精准高效控制的重要前提。

目前,国内外学者对温室温度建模的方法可分为基于能量和质量平衡的机理模型和基于数据驱动的非机理模型。机理模型具有可解释性强及外推性良好等优点,但其参数难以获取、边界条件变化程度高的问题导致其在长时精准预测中难以应用。随着现代信息数据的采集越来越容易,基于数据驱动的非机理模型因其具有精度较高、泛化能力强和参数易于获取的特点,被广泛应用于温室温度预测领域。现有数据驱动建模方式可分为统计回归法^[7-8]和浅层神经网络法^[9-10]。其中,统计回归法虽然可对时序数据进行预测,但其处理非线性问题能力有限且不考虑时间序列存在的规律,导致其拟合精度普遍较低。浅层神经网络法作为智能算法,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^[11],仅能实现对于短期温室温度的精准预测,但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。

近年来,深度学习法成为研究热点,其因具有较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。然而目前基于深度学习的温室温度预测相关研究^[11-12]多聚焦于单一时序网络,无法挖掘环境数据间深层次有效信息,且模型最大预测时长仅为 1h,仍不能真正实现模型精度、效率和时长的需求。为此,本文引入双重叠加网络

长时预测模型。其中,卷积神经网络是一种具有卷积计算能力的深度结构前馈神经网络,可提取时序数据中隐含的复杂动态变化高维特征^[13]。一维卷积神经网络相比于二维卷积神经网络保留了原始时序数据各时刻点间的相关性及及时域特征,同时网络参数的减少提升了模型运行效率,但一维卷积神经网络仅保留数据间有效信息,难以提取其长期数据的序列信息^[14]。门控循环单元是循环神经网络的一种有效特殊形式,处理具有时间相关性且连续变化的数据效果较佳,既充分挖掘了数据间的时间相关性同时也提高了数据非线性逼近的能力,但其无法挖掘各维数据的内部规律^[15]。因此,单独采用任何一种方法都无法实现对温室长时温度的精准高效预测,但由于二者优势互补,将二者叠加进行温室长时温度预测可能会提升模型精度^[16]。

因此,本文提出一种基于一维卷积神经网络和门控循环单元(GRU)的混合模型温室温度预测方法。首先搭建温室内外监测平台,获取并分析内外环境因子对室内温度的影响程度,以斯皮尔曼相关系数选取相关性高的特征构造特征与时间步长的二维矩阵作为 CNN 层输入;其次完成模型网络设计并进行参数优化,通过 CNN 网络挖掘数据中蕴含反映温室环境数据相互联系的有效特征,将提取特征输入 GRU 网络,构建面向冬季的日光温室温度预测模型;最后为验证本文模型在不同天气下适用性,以清晰度指数 K_T 对天气进行分类,分别验证在不同 K_T 下模型的预测效果,为实现高效、精准的温度预测和日光温室的生产调控提供依据。

1 平台搭建和数据获取

试验于 2019 年 12 月 2—31 日在西北农林科技大学泾阳蔬菜试验示范站东五号日光温室内进行。试验地位于北纬 34°53′、东经 108°84′,海拔 404 m,属于暖温带大陆性季风气候,年均温度 13℃。温室为单栋单坡面式,骨架采用轻钢结构,后坡采用 PC 板和丝绵棉被覆盖,东侧、西侧与北侧是墙体部分,均采用黏土建造。东西走向,长 50 m,宽 10 m,后墙高 3 m,脊高 1.6 m,具有天窗、风机、卷帘机、遮阳网、湿帘以及喷淋器等设备,将传感器放置于其中部,距地面垂直高度 1.2 m。由于温室空气温湿度空间分布不均^[17],在任何位置放置传感器均不能准确表征温室内温度。为减少监测节点放置位置对空气温湿度监测结果的影响,本研究采用绕动风机加快温室内的空气流动^[18-19],使温室内部温度趋于均匀,保证作物生产一致性。

试验期间,冬季共包括晴、晴转多云、多云、阴霾

及霾转多云 5 种天气。为进一步分析不同天气条件下温度的预测效果,以清晰度指数 K_T 对上述天气进行分类。 K_T 表征太阳辐射经过大气层时衰减程度,与当时的天气状况密切相关^[20]。如表 1 所示,根据清晰度指数对应的天气现象,将冬季天气分为 4 类。其中 $K_T \geq 0.5$ 共 15 d、 $0.5 > K_T \geq 0.2$ 共 5 d、 $0.2 > K_T \geq 0.1$ 共 10 d、 $K_T < 0.1$ 共 0 d。温室室内栽培作物为番茄,以滴灌方式培育,试验期间每日于 08:00—08:30 揭盖保温被,当 $K_T \geq 0.5$ 及 $0.5 > K_T \geq 0.2$ 时温室于 10:00—10:30 开窗换气通风;当 $0.2 > K_T \geq 0.1$ 时根据实际情况适当延后温室开窗时间。

表 1 清晰度指数对应的天气现象

Tab.1 Weather phenomena corresponding to clarity index	
清晰度指数 K_T	天气现象
≥ 0.5	晴、晴转多云、多云转晴
$0.2 \sim 0.5$	多云、多云转阴、阴转多云
$0.1 \sim 0.2$	小雨转雨、多云转雨、阴霾、霾转多云
$0 \sim 0.1$	小雨到中雨、小雨到暴雨

温室内外监测平台由信息监测模块、信息传输模块及农业生产物联网监测平台组成,每日于 00:00—24:00 连续采集,采样间隔为 20 min,共采集 10 种环境因子,包括室内光照强度(QY-150A 型光照强度传感器,量程:0~200 klx,精度: ± 1 lx)、室内外空气温度(PT1000 型温度传感器,量程:-200~200℃,精度: ± 0.1 ℃)、室内外空气相对湿度(DHT11 型湿度传感器,量程:20%~90%,精度: $\pm 5\%$)、室内外土壤温度(PT1000 型温度传感器,量程:-200~200℃,精度: ± 0.1 ℃)、室内外土壤含水率(EC-5 型土壤含水率传感器,量程:0~100%,精度: $\pm 3\%$)及室外 CO₂ 浓度(体积比)(T6615 型 CO₂ 传感器,量程:0~10 000 μL/L,精度:75 μL/L),各采集 30 d,共获取 2 160 组样本数据。其中,信息传输模块是将感知信息通过 ZigBee 网络发送至网关节点对其进行数据处理,随后通过 GPRS 网络传输至移动基站,将获取的数据上传至农业生产物联网监测平台,具体过程如图 1 所示。

2 相关性分析

2.1 斯皮尔曼相关系数

温室内部温度不仅受室内空气相对湿度、室内土壤温度、室内土壤含水率及室内光照强度等室内环境因子的影响,还与室外空气温度、室外空气相对湿度、室外 CO₂ 浓度、室外土壤温度及室外土壤含水率等室外环境因子有关^[21]。同时温室温度具有时




图 1 温室内外监测平台

Fig.1 Monitoring platform inside and outside greenhouse

序性和自相关性,即前一时刻的数据影响当前时刻的数据变化^[22]。因此,模型不仅应考虑室内外环境因子对温度的影响,还应考虑历史温度数据对当前时刻温度的影响。为提高模型输入信息的有效性及减少无用信息的噪声干扰,本文采用斯皮尔曼相关系数 p ,分析各因子对温室温度的影响程度,选取相关性高的因子作为模型输入。斯皮尔曼相关系数 p 是一种基于单调方程评价两变量间相关关系的方法,范围为(-1, 1),其绝对值越趋近于 1,相关性越强,其值与相关程度的关系如表 2 所示。

表 2 相关系数绝对值与相关程度的关系

Tab.2 Relationship between absolute value of correlation coefficient and degree of correlation					
相关系数 绝对值	(0.8,1)	(0.6,0.8]	(0.4,0.6]	(0.2,0.4]	[0,0.2]
相关程度	极强相关	强相关	中相关	弱相关	极弱相关

2.2 温度与各类影响因子分析

利用斯皮尔曼相关系数分别计算室内温度、室内空气相对湿度、室内土壤温度、室内土壤含水率、室内光照强度、室外空气温度、室外空气相对湿度、室外 CO₂ 浓度、室外土壤温度及室外土壤含水率 10 个因子与 1 h 后温室温度的相关系数绝对值,其结果如表 3 所示。

表 3 各因子与温室温度的相关系数绝对值

Tab.3 Absolute value of correlation coefficient between each factor and greenhouse temperature	
影响因子	相关系数绝对值
室内温度	0.706
室内空气相对湿度	0.687
室内土壤温度	0.603
室内土壤含水率	0.169
室内光照强度	0.629
室外空气温度	0.657
室外空气相对湿度	0.562
室外 CO ₂ 浓度	0.174
室外土壤温度	0.423
室外土壤含水率	0.272

由表 3 可知,室内空气温度、相对湿度、土壤温度、光照强度,以及室外空气温度与 1 h 后温度属于强相关;室外空气相对湿度、土壤温度与 1 h 后温度属于中相关;其余因子属于弱相关或极弱相关。其中,室内土壤含水率相关性最低,较室外土壤含水率影响程度更小,这是由于温室内栽培作物采用膜下滴灌方式,室内土壤由于覆膜处理导致土壤水分蒸发减弱,减少了其对室内空气相对湿度等因素的影响,而室内空气相对湿度又是影响温度的关键因素;而室外土壤由于未覆膜处理导致其影响室外湿度,进而影响温室内温度,所以在本试验条件下,室外土壤含水率相较于室内更能影响温室温度。

为降低模型复杂度,本文仅考虑与温室温度具有极强相关、强相关及中相关 3 种相关程度的因子。因此,日光温室温度模型选择室内温度、室内空气相对湿度、室内土壤温度、室内光照强度、室外空气温度、室外空气相对湿度及室外土壤温度 7 种因子作为输入。

3 模型构建

3.1 1D CNN - GRU 网络结构

基于 1D CNN - GRU 深度神经网络具体结构如图 2 所示,整体结构采用逐个堆叠方式连接,共分为 4 部分。其中,输入层 $X_{t+j,i}$ 为二维矩阵, i 为特征个数, j 为时间步长; $X_{t,i} \sim X_{t+j,i}$ 表示第 t 时刻到第 $t+j$ 时刻输入样本的第 i 个特征数据; $X_{t,1} \sim X_{t,i}$ 表示 t 时刻样本数据共有 $1 \sim i$ 个特征。卷积层采用一维卷积滤波器提取数据特征,因样本数据维度较少,未添加池化层。循环层选择 2 层 GRU,第 1 层网络返回每个时间步输出的完整序列,第 2 层网络返回每个输入序列的最终输出。最后全连接层作为输出层输出目标时刻的预测值。




图 2 1D CNN - GRU 网络结构

Fig. 2 1D CNN - GRU network structure

其中,1D CNN 是深度学习中的一种有效学习框架,通过卷积运算模拟人脑从局部中提取特征,在计算机视觉方面取得了较好的效果。同时在序列问题中,1D CNN 可通过卷积层的滤波器捕捉输入数据间的相互关系,并将其组合成更短的特征序列输入至下一层网络中进行预测。例如,当卷积滑动窗口尺寸为 5 时,1D CNN 通过窗口滑动依次从序列中提取局部一维序列段与权重作点积,如图 3 所示。




图 3 1D CNN 工作原理图

Fig. 3 1D CNN working principle

门控循环单元 (GRU) 是一种基于循环神经网络的优化网络,通过引入“门”的概念,优化了神经元内部结构,有选择性地传递信息,解决了循环神经网络难以学习序列中长距离依赖关系问题。在隐层中,各神经元相互连接,输入不仅与当前时刻输入层输入有关,还与上一时刻隐层输出有关。如图 4a 所示, x 为总输入, h 为隐层输出, o 为总输出。在图 4b 中,GRU “门”包括重置门 r 和更新门 z ,重置门 r 融合输入 x_t 与前一时刻的历史数据 h_{t-1} ,并丢弃与时间无关的历史数据,保留短序列数据间的依赖关系;更新门 z 通过存储上一时刻记忆 h_{t-1} ,选择性地记忆信息,不断更新其值来捕捉长序列数据间的依赖关系。

3.2 温室温度预测模型建立

基于上述网络结构,本文构建基于 1D CNN - GRU 的温度预测模型。模型以室内温度、室内空气相对湿度、室内土壤温度、室内光照强度、室外空气温度、室外空气相对湿度及室外土壤温度为输入,时间步长为 6,即输入矩阵尺寸为 6×7 ;以 1、2、3、4 h 后温度为输出,其具体流程图如图 5 所示。

(1) 由于不同样本数据间数值范围存在较大差异,量纲也有所不同,为加快神经网络拟合速度并提高模型预测精度,故对样本数据采用归一化处理缩放至 $[0,1]$ 之间。




图 4 门控循环单元结构
Fig.4 GRU structure




图 5 温度预测模型建立流程图

Fig.5 Flow chart of establishing temperature prediction model

(2)在归一化后的 2 160 组数据中,选取 1 512 组数据(占样本总数据 70%)作为训练集,其余 648 组数据(占样本总数据 30%)作为测试集,最后以训练集数据训练模型,测试集数据验证模型的泛化能力及精度。

(3)卷积层将第 t 个输入样本数据 s_t 与一维卷积核执行卷积操作后,加以偏置 b_{cnn} 通过激活函数进入循环层,即

$$y_t=f(W_{cnn}s_t+b_{cnn}) \tag{1}$$

式中 f ——激活函数
 W_{cnn} ——输入层到卷积层对应的权值矩阵
 s_t ——第 t 个输入样本数据
 b_{cnn} ——输入层到卷积层对应的偏置矩阵
 y_t ——第 t 个输出样本数据

在循环层中样本数据 x_t 通过重置门 r 、更新门 z 及 t 时刻提供临时单元状态 c 点乘运算输出至全连接层,具体计算过程为

$$z=\text{sigmoid}(W_z h_{t-1}+U_z x_t) \tag{2}$$

$$r=\text{sigmoid}(W_r h_{t-1}+U_r x_t) \tag{3}$$

$$c=\tanh(W_c(h_{t-1}\otimes r)+U_c x_t) \tag{4}$$

$$h_t=(z\otimes c)\oplus((1-z)\otimes h_{t-1}) \tag{5}$$

式中 h_t ——当下时间步终时记忆数据
 $W_z、W_r、W_c、U_z、U_r、U_c$ ——更新门、重置门和临时输出的权值矩阵

(4) 每层网络均采用线性整流函数 (Rectified linear unit, ReLU) 作为激活函数,均方误差函数 (Mean square error, MSE) 为损失函数。同时为实现神经网络权重的更新,利用自适应运动估计优化算法,使模型性能达到最佳。它是一种结合自适应梯度算法和前向均方根梯度下降算法二者优点的智能优化算法,优势在于解决稀疏梯度和非平稳问题上表现良好。在每次迭代中,以损失函数最小值为优化目标,通过计算梯度的一阶动量项和二阶动量项使学习率自适应地更新。

基于试参法寻优得到最优的学习率为 0.001,训练轮数为 500,当模型完成规定的训练轮数后,判断其输出结果是否满足模型精度,若不满足则重新调整参数值,继续训练直到达到模型精度;若满足则输出结果。

(5)以测试集温度为实际值,模型输出值为预测值,先对二者反归一化,恢复原有量纲级别,再以各类评价指标对模型精度及泛化能力进行评估。

4 算法对比与模型验证

4.1 不同算法和时长对比

为验证本文算法的预测性能,以决定系数 R^2 、均方根误差 (Root mean square error, RMSE)、平均绝对误差 (Mean absolute error, MAE) 和绝对值的最大绝对误差 (Maximum absolute error, MaAE) 为评价指标,参数优化后的多元线性回归法 (Multiple linear regression, MLR)、BP 神经网络算法 (Belief propagation neural networks, BPNN)、一维卷积神经网络 (1D CNN) 及门控循环单元 (GRU) 与一维卷积门控循环单元网络 (1D CNN - GRU) 建模效果进行对比,其预测结果如表 4 所示。

表 4 不同算法和时间结果对比

Tab.4 Comparison results of different algorithms and durations

预测 时间/h	算法	训练集				测试集			
		R^2	RMSE/℃	MAE/℃	MaAE/℃	R^2	RMSE/℃	MAE/℃	MaAE/℃
1	MLR	0.937	1.927	1.352	2.890	0.932	2.071	1.446	3.023
	BP	0.973	1.258	0.778	1.602	0.969	1.387	0.805	1.630
	1D CNN	0.983	1.047	0.684	1.101	0.982	1.053	0.695	1.282
	GRU	0.993	0.636	0.446	0.902	0.992	0.655	0.457	0.941
	1D CNN – GRU	0.994	0.604	0.421	0.820	0.994	0.612	0.428	0.856
2	MLR	0.764	3.841	2.856	5.312	0.755	3.955	3.135	5.435
	BP	0.921	2.159	1.425	2.663	0.918	2.277	1.431	2.750
	1D CNN	0.937	1.767	1.297	2.020	0.934	1.851	1.324	2.104
	GRU	0.953	1.684	1.102	1.589	0.949	1.711	1.155	1.621
	1D CNN – GRU	0.990	0.702	0.676	1.068	0.989	0.713	0.692	1.182
3	MLR	0.529	5.386	4.391	8.056	0.507	5.615	4.614	8.349
	BP	0.832	3.271	2.167	4.016	0.825	3.343	2.248	4.112
	1D CNN	0.847	3.037	1.994	2.892	0.842	3.173	2.063	2.905
	GRU	0.921	1.720	1.325	2.232	0.914	1.798	1.527	2.392
	1D CNN – GRU	0.978	1.184	0.775	1.411	0.975	1.245	0.797	1.489
4	MLR	0.267	6.523	5.451	11.240	0.258	6.893	5.745	11.862
	BP	0.691	4.429	3.236	5.809	0.680	4.525	3.261	5.850
	1D CNN	0.838	3.131	2.105	3.898	0.832	3.278	2.289	3.945
	GRU	0.882	2.188	1.901	3.256	0.874	2.342	1.989	3.350
	1D CNN – GRU	0.975	1.228	0.797	1.881	0.970	1.358	0.854	1.959

由表 4 可知,在预测时间为 1 h 时,MLR 模型和 BP 模型的预测精度虽均低于深度学习模型结果,但其总体相差不大。但随着时间的增加,前两者的预测精度快速下降。在 2 ~ 4 h 期间 MLR 模型较 1D CNN – GRU 模型 RMSE、MAE 和 MaAE 分别增加 3.242 ~ 5.535℃、2.443 ~ 4.891℃ 和 4.253 ~ 9.903℃;BP 模型较 1D CNN – GRU 模型 RMSE、MAE 和 MaAE 分别增加 1.564 ~ 3.167℃、0.739 ~ 2.407℃ 和 1.568 ~ 3.891℃。上述结果说明,这 2 类方法对多维时序数据处理能力有限,无法实现对温室内长时温度的精准预测。在深度学习法中,1D CNN – GRU 模型预测效果最好,GRU 模型次之,1D CNN 模型最差,且误差随时间逐渐变大,2 h 后这 3 类方法的预测差距逐步显现。当预测时间超过 3 h 后,1D CNN 模型和 GRU 模型 MaAE 均超过了 2℃,1D CNN 模型较 1D CNN – GRU 模型 RMSE、MAE 和 MaAE 分别增加 1.920 ~ 1.928℃、1.266 ~ 1.435℃ 和 1.416 ~ 1.986℃;GRU 模型较 1D CNN – GRU 模型 RMSE、MAE 和 MaAE 分别增加 0.553 ~ 0.984℃、0.730 ~ 1.135℃ 和 0.903 ~ 1.391℃。上述结果说明,1D CNN 模型虽然相比于 MLR 模型和 BP 模型预测效果有所提升,但由于其无法提取序列信息,导致长时预测精度不高;GRU 模型能够捕获长程依赖关系,较 1D CNN 模型更适应于时序数据,但由于局部特征提取能力

不足,导致其较 1D CNN 模型预测精度虽提高,但其精度仍不满足生产需求。1D CNN – GRU 模型结合 1D CNN 局部特征提取能力和 GRU 时间特征提取能力,在 4 h 内 R^2 均不小于 0.970、RMSE 均不大于 1.358℃、MAE 均不大于 0.854℃、MaAE 均不大于 1.959℃,长期预测方面明显优于上述 4 组对照模型,其可满足环境调控过程中对预测温度精度和时长方面的要求。

4.2 日光温室温度预测模型验证

为验证日光温室温度预测模型的泛化能力和预测性能,以测试集的 648 组样本数据对模型预测 1、2、3、4 h 后温度进行验证。验证结果表明,模型在测试集上预测 1 ~ 4 h 后的决定系数为 0.970 ~ 0.994,均方根误差为 0.612 ~ 1.358℃,平均绝对误差为 0.428 ~ 0.854℃,绝对值的最大绝对误差为 0.856 ~ 1.959℃,其拟合直线分别为 $y = 0.183 + 1.004x$ 、 $y = 0.049 + 1.006x$ 、 $y = 0.198 + 0.977x$ 、 $y = 0.132 + 0.969x$,它们的拟合系数均接近于 1,截距均接近于零,说明该模型预测值和实际值几乎在直线 $y = x$ 两侧,二者存在较强相关性,模型达到理想预测精度。

同时,为验证本文模型在不同 K_T 下适用性,以 RMSE、MAE 和绝对值的平均相对误差 (Average relative error, ARE) 为评价指标,验证在 2019 年 12 月 23—31 日中的 3 类天气检验模型预测效果,其预

测结果如表 5 所示。其中,12 月 26 日(晴)、12 月 27 日(晴转多云)、12 月 28 日(晴)、12 月 30 日(晴)及 12 月 31 日(晴)为 $K_T \geq 0.5$;12 月 25 日(多云)为 $0.5 > K_T \geq 0.2$;12 月 23 日(阴霾)、12 月 24 日(阴霾)及 12 月 29 日(霾转多云)为 $0.2 > K_T \geq 0.1$ 。

表 5 不同 K_T 下模型验证结果

Tab.5 Verification results of model under different K_T				
预测时间/h	清晰度指数 K_T	RMSE/℃	MAE/℃	ARE/%
1	≥ 0.5	0.544	0.387	2.370
	$0.2 \sim 0.5$	0.417	0.289	2.690
	$0.1 \sim 0.2$	0.745	0.507	3.488
2	≥ 0.5	0.771	0.470	3.310
	$0.2 \sim 0.5$	0.543	0.419	3.988
	$0.1 \sim 0.2$	1.046	0.674	4.686
3	≥ 0.5	1.025	0.718	4.847
	$0.2 \sim 0.5$	0.855	0.578	5.816
	$0.1 \sim 0.2$	1.589	1.006	7.188
4	≥ 0.5	1.128	0.793	4.924
	$0.2 \sim 0.5$	0.962	0.653	6.522
	$0.1 \sim 0.2$	1.766	1.174	7.858

如表 5 所示,在不同天气条件下均方根误差为 $0.417 \sim 1.766^\circ\text{C}$,平均绝对误差为 $0.289 \sim 1.174^\circ\text{C}$,绝对值的平均相对误差为 $2.370\% \sim 7.858\%$ 。随着 K_T 的下降 ARE 逐渐增大,这可能是由于云层及雾霾颗粒的影响^[23-24],导致温室内光照产生波动,从而影响温度预测精度。进一步分析 RMSE 和 MAE 可以发现,虽然多云天会出现光照度波动,但晴天温室温度普遍高于其他天气,因而当 $K_T \geq 0.5$ 时其 RMSE 和 MAE 会略高于 $0.5 > K_T \geq 0.2$ 条件,但并无显著差异。而 $0.2 >$

$K_T \geq 0.1$ 时,虽然其温度也相对较低,但其不仅存在温室内光照产生波动的影响,而且阴霾天较晴天和多云天存在湿度高且波动大的特点^[25],由于室内湿度本就对温度影响程度较大,加之传感器在高湿环境下会出现误差偏移,因此其精度明显低于前两种环境状态。综合考虑,模型在 $K_T \geq 0.5$ (晴)时预测效果最好,在各 K_T 下模型均表现出较高准确性,说明此方法具有适用性,可应用于实际生产,在冬季室内太阳辐射较弱时,可通过该模型提前预知温度,利用加温设备为温室补充加温,为作物优质生产提供可靠性依据。

5 结论

(1)基于斯皮尔曼相关系数选取室内温度、室内空气相对湿度、室内土壤温度、室内光照强度、室外空气温度、室外空气相对湿度及室外土壤温度 7 种因子作为输入,1、2、3、4 h 后温度为输出,构建日光温室温度预测模型。结果表明,模型在测试集上预测 1~4 h 后的决定系数为 $0.970 \sim 0.994$,均方根误差为 $0.612 \sim 1.358^\circ\text{C}$,平均绝对误差为 $0.428 \sim 0.854^\circ\text{C}$,绝对值的最大绝对误差为 $0.856 \sim 1.959^\circ\text{C}$ 。相比于统计学法和浅层神经网络法,该模型对温度预测的精度具有显著提升。

(2)以 K_T 对天气分类的验证结果表明,该模型在 $K_T \geq 0.5$ (晴)时温度预测效果最好,此外不同 K_T 下模型均方根误差为 $0.417 \sim 1.766^\circ\text{C}$,平均绝对误差为 $0.289 \sim 1.174^\circ\text{C}$,绝对值的平均相对误差为 $2.370\% \sim 7.858\%$ 。模型在不同天气条件下的预测精度均符合要求,验证了该模型对天气条件的普适性。

参 考 文 献

[1] GAO P, LI B, BAI J, et al. Method for optimizing controlled conditions of plant growth using U-chord curvature[J]. Computers and Electronics in Agriculture, 2021, 185(1): 106141.

[2] 杨洋,张小虎,张亚红,等. 设施调控夜间温度对赤霞珠葡萄果实品质的影响[J]. 食品科学, 2021, 42(4): 80-86. YANG Yang, ZHANG Xiaohu, ZHANG Yahong, et al. Effects of regulated night temperature in greenhouse on grape quality of cabernet sauvignon[J]. Food Science, 2021, 42(4): 80-86. (in Chinese)

[3] 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.

[4] 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): 42001-42007.

[5] 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)

[6] ZOU W, YAO F, ZHANG B, 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.

[7] 刘永华,沈明霞,熊迎军,等. 基于两级预测的温室 WSN 系统数据传输方法[J]. 农业机械学报, 2014, 45(12): 329-334. LIU Yonghua, SHEN Mingxia, XIONG Yingjun, et al. Data transmission of WSN system in greenhouse based on two-level

- prediction[J]. Transactions of the Chinese Society for Agricultural Machinery, 2014, 45(12): 329–334. (in Chinese)
- [8] 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)
- [9] LI X, ZHANG X, WANG Y, et al. Temperature prediction model for solar greenhouse based on improved BP neural network[J]. Journal of Physics: Conference Series, 2020, 1639(1): 12011–12036.
- [10] 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 CSAE, 2020, 36(3): 190–197. (in Chinese)
- [11] GHARGHORY S M. Deep network based on long short-term memory for time series prediction of microclimate data inside the greenhouse[J]. International Journal of Computational Intelligence and Applications, 2020, 19(2): 2050013.
- [12] LIU Y, LI D, WAN S, et al. A long short-term memory-based model for greenhouse climate prediction[J]. International Journal of Intelligent Systems, 2021, 37(1): 135–151.
- [13] CHURCHILL R M, TOBIAS B, ZHU Y. Deep convolutional neural networks for multi-scale time-series classification and application to tokamak disruption prediction using raw, high temporal resolution diagnostic data[J]. Physics of Plasmas, 2020, 27(6): 62510.
- [14] WANG W, ZHAO X, LIU D. Design and optimization of 1D-CNN for spectrum recognition of underwater targets[J]. Integrated Ferroelectrics, 2021, 218(1): 164–179.
- [15] HUANG G, LI X, ZHANG B, et al. PM_{2.5} concentration forecasting at surface monitoring sites using GRU neural network based on empirical mode decomposition[J]. Science of the Total Environment, 2021, 768(3): 144516.
- [16] CHEN L, YAN H, YAN J, et al. Short-term water demand forecast based on automatic feature extraction by one-dimensional convolution[J]. Journal of Hydrology, 2022, 606: 127440.
- [17] 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)
- [18] 李康吉,张世通,孟凡跃,等. 考虑时空变异特性的温室多环境因子优化策略[J]. 农业机械学报, 2021, 52(11): 343–350.
LI Kangji, ZHANG Shitong, MENG Fanyue, et al. Optimization strategy of greenhouse multiple environmental factors considering temporal and spatiotemporal variability[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(11): 343–350. (in Chinese)
- [19] 孙维拓,周波,徐凡,等. 日光温室正压湿帘冷风降温性能及冷负荷计算模型[J]. 农业工程学报, 2019, 35(16): 214–224.
SUN Weituo, ZHOU Bo, XU Fan, et al. Performance of positive pressure fan-pad cooling system and cooling load model for Chinese solar greenhouse[J]. Transactions of the CSAE, 2019, 35(16): 214–224. (in Chinese)
- [20] 崔杨,成驰,陈正洪. 基于数值天气预报的光伏组件温度预测研究[J]. 太阳能学报, 2021, 42(5): 202–208.
CUI Yang, CHENG Chi, CHEN Zhenghong. Research on photovoltaic module temperature prediction based on NWP data[J]. Acta Energetica Solaris Sinica, 2021, 42(5): 202–208. (in Chinese)
- [21] XU Z, CHEN J, ZHANG J, et al. Incremental auto regressive prediction models with external variables of greenhouse air temperature for control purposes[J]. International Journal of Smart Home, 2016, 10(9): 45–58.
- [22] 裴雪. 日光温室温度预测模型与卷帘智能控制方法研究[D]. 杨凌:西北农林科技大学, 2018.
PEI Xue. Temperature prediction model of greenhouse and the design of intelligent control method of rolling quilt[D]. Yangling: Northwest A&F University, 2018. (in Chinese)
- [23] 毛前军,王莉. 典型雾霾粒子及团簇的散射吸湿增长特性[J]. 光学学报, 2020, 40(24): 184–192.
MAO Qianjun, WANG Li. Scattering hygroscopic growth characteristics of typical haze particles and clusters[J]. Acta Optica Sinica, 2020, 40(24): 184–192. (in Chinese)
- [24] 王子衡. 考虑源荷功率随机波动性的光伏发电机组频率平滑调节方法研究[D]. 北京:华北电力大学, 2021.
WANG Ziheng. Research on frequency smoothing regulation method of photovoltaic generator set considering random fluctuation of source-load power[D]. Beijing: North China Electric Power University, 2021. (in Chinese)
- [25] 吕欢欢,牛源艺,张漫,等. 日光温室光照强度与空气温湿度变化趋势分析[J]. 农业机械学报, 2021, 52(增刊): 410–417.
LÜ Huanhuan, NIU Yuanyi, ZHANG Man, et al. Analysis of variation trend of light intensity and air temperature and humidity in solar greenhouse[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(Supp.): 410–417. (in Chinese)