

基于 LSTM-AT 的温室空气温度预测模型构建

张观山^{1,2}, 丁小明^{1,3}, 何芬^{1,3}, 尹义蕾^{1,3}, 李天华²,
任吉傲², 周俊毅², 齐飞^{1,3*}

(1. 农业农村部规划设计研究院, 北京 100125; 2. 山东农业大学机械与电子工程学院, 泰安 271018;
3. 农业农村部农业设施结构与智能建造重点实验室, 北京 100125)

摘要: 构建精确的温室空气温度预测模型是采用模型预测控制等控制算法实现温室空气温度精准控制的前提条件。长短记忆神经网络 (long short-term memory, LSTM) 以处理时间序列数据方面的优势而广泛应用于温室空气温度预测, 然而其面对长时间序列数据存在由于数据遗忘而导致温室空气温度预测精度降低的问题。为解决以上问题, 该研究将 LSTM 模型与注意力机制 (attention mechanism, AT) 结合构建 LSTM-AT 模型, 根据 LSTM 模型隐藏层输出状态重要性程度为隐藏层输出分配权重, 以提高温室空气温度长时间预测精度。该研究在不同预测时长 (12、24 和 48 h) 和不同天气状况两种情况下将 LSTM-AT 模型与递归神经网络、门控循环单元、双向长短记忆网络、LSTM 模型进行对比。结果表明, LSTM-AT 模型空气温度预测值与测量值变化趋势较为一致, 模型计算值与空气温度测量值的决定系数最小为 0.95, 均方根误差最大为 1.34 °C, 平均绝对误差最大为 10.51%; LSTM-AT 模型、LSTM 模型、门控循环单元、递归神经网络、双向长短记忆网络 5 种模型温室空气温度预测均方根误差平均值分别为 0.89、1.42、1.89、2.10、1.51 °C, 平均绝对百分比误差平均值分别为 4.26%、8.96%、13.57%、17.70%、10.67%。由此可知, 相较于其他 4 种模型, 该研究提出的 LSTM-AT 模型具有更高的预测精度, 能够精确预测温室空气温度。

关键词: 温室; 空气温度; 长短记忆神经网络; 注意力机制; 预测模型

doi: 10.11975/j.issn.1002-6819.202404199

中图分类号: S24

文献标志码: A

文章编号: 1002-6819(2024)-18-0194-08

张观山, 丁小明, 何芬, 等. 基于 LSTM-AT 的温室空气温度预测模型构建[J]. 农业工程学报, 2024, 40(18): 194-201.

doi: 10.11975/j.issn.1002-6819.202404199 <http://www.tcsae.org>

ZHANG Guanshan, DING Xiaoming, HE Fen, et al. Predicting greenhouse air temperature using LSTM-AT[J]. Transactions of the Chinese Society of Agricultural Engineering (Transactions of the CSAE), 2024, 40(18): 194-201. (in Chinese with English abstract) doi: 10.11975/j.issn.1002-6819.202404199 <http://www.tcsae.org>

0 引言

根据全国农业机械化统计年报显示, 2022 年中国温室面积达 177.8 万 hm^2 。温室作为中国设施农业的一种重要生产类型, 通过工程技术手段营造相对可控的环境条件, 解决了作物生长受外部环境条件限制的问题, 实现了作物优质高效生产^[1], 丰富了老百姓的“菜篮子”^[2]。

温室环境尤其是空气温度决定着作物产量、品质以及运行成本, 温度过高或过低均易使作物产生病害, 影响作物产量^[3], 因此温室环境控制首先需考虑如何保持适宜作物生长的空气温度^[4]。温室是一个高度非线性的多输入多输出系统^[5], 其空气温度受室外气象、覆盖材

料以及其他多个因素共同影响^[6-7], 充分研究和理解影响温室空气温度的各个因素, 构建精确的空气温度预测模型, 是实现温室高效环境调控的重要途径之一。

目前温室空气温度预测模型总体上分为 3 种类型: 机理模型、计算流体力学 (computational fluid dynamics, CFD) 模型和数据驱动模型。

机理模型通常假设室内空气温度均匀^[8], 采用热力学理论分析温室内动态能量、质量交换过程, 基于能量和质量守恒原理描述温室系统变化规律。SINGH 等^[9] 构建了一种温室微气候机理模型, 针对自然通风且种植黄瓜的温室, 开展了室内空气温度预测研究。LIU 等^[10] 使用热力学理论构建了一种温室瞬态微气候模型, 并使用该模型评估了日光温室空气温湿度。ZHANG 等^[11] 基于能量平衡原理构建了一种玻璃温室热环境模型, 实现了空气温度等参数的准确预测。张观山等^[12] 提出了覆盖层太阳辐射动态吸收率计算方法, 构建了一种玻璃温室覆盖层温度预测机理模型。以上研究在模型构建过程中需要温室结构以及能量、质量交换系数等较多的输入参数, 且部分输入参数如对流换热系数、长波辐射换热系数等难以准确获取^[3]。此外, 作物对环境的影响还处于研究阶段^[13], 这些因素导致难以构建完善的温室机理模型。

收稿日期: 2024-02-03 修订日期: 2024-06-19

基金项目: 农业农村部规划设计研究院自主研发计划项目 (SP202101); 国家自然科学基金项目 (32201657); 山东省自然科学基金项目 (ZR2021QF091); 山东省重点研发计划重大科技创新工程项目 (2022CXGC020708); 山东省重点研发计划乡村振兴科技创新提振行动计划项目 (2023TXZD065)

作者简介: 张观山, 博士, 高级实验师, 研究方向为设施农业。

Email: zgz9919@sdau.edu.cn

*通信作者: 齐飞, 研究员, 研究方向为设施农业。

Email: qf2008@188.com

CFD 模型属于一种特殊的机理模型^[14]。近年来, 很多研究采用 CFD 建模方法, 如 MAO 等^[15]集成了 CFD 模拟和测量数据, 采用计算流体力学方法实现了温室温湿度场模拟。JILANI 等^[16]采用 CFD 模型对集成土壤空气换热器的温室热环境表现和气流模式进行了模拟和分析。XIAO 等^[17]采用 CFD 模型对集成土壤-空气热交换器的日光温室进行了空气温度预测研究。以上研究构建的 CFD 模型能够较为精确的模拟室内温湿度场分布, 但需要大量计算机仿真资源且存在收敛速度较慢甚至有时无法收敛的问题。因此, CFD 模型适用于温室结构优化设计、能耗模拟与分析等计算实时性要求较低的领域, 不适用于温室环境控制等实时性要求较高的领域^[15]。

随着人工智能^[18]、数据监测以及计算和通讯设备的快速发展^[19], 很多专家学者采用数据驱动模型对空气温度预测进行研究^[5]。数据驱动模型精度依赖于数据集和算法结构, 虽然训练过程需要较长时间, 但训练完成后其预测速度很快。目前常用的机器学习模型包括回归模型^[20]、BP 神经网络^[21]、递归神经网络 (recurrent neural network, RNN)^[22]、径向基函数神经网络^[23]、LGBM 模型^[24]、卷积神经网络等。长短记忆神经网络 (long short-term memory, LSTM)^[25]作为目前流行的时间序列处理算法, 以其在处理序列数据方面的优势而被应用于温室空气温度预测。但随着预测时间增长, LSTM 模型预测精度严重降低^[26-27], 因此如何在多输入特征和数据情况下, 实现温室空气温度多步长时间精确预测是当前研究的重点。

注意力机制是一种在机器学习和自然语言处理中经常使用的技术。通过引入注意力机制可以实现根据输入序列不同动态调整对输入的关注度, 以更好表达输入的重要内容。近年来, 很多专家学者在注意力机制提升模型预测表现方面开展了相关研究, 如 YANG 等^[28]将时间序列卷积神经网络与注意力机制结合进行温室温度预测研究, 结果显示预测值与测量值的均方根误差 (root mean square error, RMSE) 提升了 7.44%, 平均绝对误差提升了 2.53%, 平均绝对百分比误差 (mean absolute percentage error, MAPE) 提升了 3.15%。GUO 等^[29]结合时空注意力机制与 LSTM 进行空气温度和水温预测, 预测精度相比传统 LSTM 具有较大的提升。

为解决温室空气温度预测精度随预测时间增长而降低的问题, 本研究拟将 LSTM 与注意力机制结合构建 LSTM-AT 模型, 根据重要性程度为 LSTM 隐藏层输出状态分配权重, 以实现温室空气温度长时间准确预测。

1 数据获取与分析方法

1.1 试验温室

试验地点位于山东省泰安市 (36°08'N, 116°95'E), 试验对象为玻璃温室。温室南北朝向, 长度 5 m, 宽度 3 m, 檐高 2.05 m, 脊高 3 m, 屋顶倾角 26°。屋顶使用单层钢化玻璃, 厚度 8 mm, 温室四周墙体使用单层钢化玻璃, 厚度 6 mm。

1.2 数据采集平台

试验数据采集选用武汉汉秦信通科技有限公司生产的 HQZDZ 型数据采集器, 室外采集的参数包括大气温度、大气湿度、太阳总辐射、CO₂ 浓度、风速、风向, 室内采集的参数为空气温度, 室内总共布置了 4 个温度传感器, 传感器在室内均匀分布, 4 个传感器测量数据平均值作为室内空气温度数据。传感器技术参数参考表 1。

表 1 传感器技术参数
Table 1 Technical specifications of sensors

传感器名称 Sensor name	型号 Model	精度 Accuracy	测量范围 Measuring range
温度传感器	HQWD	±0.3 °C	-50~100 °C
湿度传感器	HQSD	±3%	0~100%
太阳辐射传感器	HQTBQ	1 W·m ⁻²	0~2 000 W·m ⁻²
风向传感器	HQFX	±3 °	0~360 °
风速传感器	HQFS	±0.3 m·s ⁻¹	0~70 m·s ⁻¹
CO ₂ 浓度传感器	HQCO ₂	±40×10 ⁶	0~2 000×10 ⁶

1.3 数据预处理与特征变量选择

1.3.1 数据预处理

本研究采用箱线法对异常数据进行处理, 采用线性插值的方式补充缺失数据, 采用式 (1) 将所有数据归一化处理至 0~1 范围内。

$$r = \frac{d - d_{\min}}{d_{\max} - d_{\min}} \quad (1)$$

式中 d 为原始数据, d_{\min} 和 d_{\max} 分别为原始数据中的最小值和最大值, r 为归一化之后的数据。

1.3.2 特征变量选择

本研究通过相关系数 R (式 (2)) 计算每个特征变量与温室空气温度之间的相关性^[30]。如果 $0.8 < |R| \leq 1$, 两者具有极强相关性, $0.6 < |R| \leq 0.8$, 两者具有强相关性, $0.4 < |R| \leq 0.6$, 两者具有中相关性, $0.2 < |R| \leq 0.4$, 两者具有弱相关性, $0 \leq |R| \leq 0.2$, 两者具有极弱相关性。本研究选择 $|R|$ 大于 0.4 的变量作为最终的特征输入变量。

$$R = \frac{\sum_{k=1}^p (X_k - \bar{X})(Y_k - \bar{Y})}{\sqrt{\sum_{k=1}^p (X_k - \bar{X})^2} \sqrt{\sum_{k=1}^p (Y_k - \bar{Y})^2}} \quad (2)$$

式中 X_k 、 Y_k 代表第 k 个特征变量和温室空气温度样本数据, p 为样本数量, \bar{X} 、 \bar{Y} 分别代表特征变量与温室空气温度数据平均值。

经计算, 大气温度、大气湿度、太阳总辐射、风速、风向、CO₂ 浓度与温室空气温度的 $|R|$ 分别为 0.859、0.105、0.676、0.433、0.183、0.073, 选择 $|R|$ 大于 0.4 的变量作为特征输入变量, 因此本研究选择的特征输入变量为大气温度、太阳辐射强度、风速。

2 模型构建

2.1 长短记忆神经网络模型

如图 1 所示, LSTM 门结构包括 4 个关键的单元: 遗忘门 f_t 、更新门 u_t 、细胞状态 \tilde{c}_t 和输出门 o_t 。每个时间

步有3个输入： t 时刻外部输入 x_t 、 $t-1$ 时刻LSTM单元输出 h_{t-1} 、 $t-1$ 时刻细胞状态 C_{t-1} 。以上输入数据经过LSTM门控单元处理，得到输出 h_t 和细胞状态 C_t 。门控单元输出计算过程如式(3)~(8)。

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3)$$

$$u_t = \sigma(W_u \cdot [h_{t-1}, x_t] + b_u) \quad (4)$$

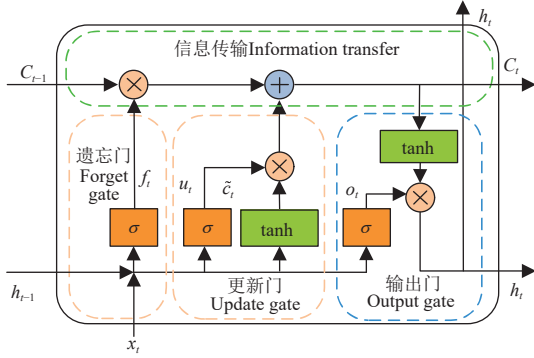
$$\tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (5)$$

$$C_t = f_t \cdot C_{t-1} + u_t \cdot \tilde{c}_t \quad (6)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (7)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (8)$$

式中 \tanh 代表双曲正切函数， σ 代表激活方程。 W_f 、 W_u 、 W_c 、 W_o 和 b_f 、 b_u 、 b_c 、 b_o 分别代表遗忘门、更新门、细胞状态和输出门的权重和偏置矩阵，以上权重和偏置矩阵随机设置初值，通过数据训练获取。



注： C_{t-1} 为 $t-1$ 时刻细胞状态； C_t 为 t 时刻细胞状态； h_{t-1} 为 $t-1$ 时刻输出； h_t 为 t 时刻输出； f_t 为遗忘门； u_t 为更新门； o_t 为输出门； \tilde{c}_t 为细胞状态； σ 为激活方程； \tanh 为双曲正切函数。

Note: C_{t-1} is cell state at time $t-1$; C_t is cell state at time t ; h_{t-1} is output at $t-1$; h_t is output at t ; f_t is forget gate; u_t is update gate; o_t is output gate; \tilde{c}_t is cell state; σ is activation equation; \tanh is hyperbolic tangent function.

图1 长短记忆神经网络门结构

Fig.1 Door structure of long short-term memory

2.2 注意力机制

注意力机制包括3个输入向量，分别为向量 Q 、 K 、 V 。 Q 是查询向量，用于获取与其他向量的相关性。 K 是键向量，用于衡量 Q 与其他向量之间的关联程度。 V 为值向量，包含需要根据 Q 进行加权聚合的信息，表示根据 Q 的重要性进行加权聚合的向量。注意力机制通过计算 Q 和 K 之间的相似性，来决定对 V 进行加权聚合时分配多少注意力。具体而言，通过计算 Q 和 K 的点积，经过一个标准化操作（例如Softmax函数），得到了 K 向量各元素重要性的权重，然后这些权重与对应的 V 进行加权求和得到最终的表示。

如图2所示，注意力机制的计算过程包括以下3个步骤：

步骤1：通过式(9)~(11)分别计算获取 Q 、 K 、 V 。

$$Q: q_i = W_Q x_i \quad (9)$$

$$K: k_i = W_K x_i \quad (10)$$

$$V: v_i = W_V x_i \quad (11)$$

式中 x 为特征输入； i 代表特征输入序号，范围 $1 \sim l_0$ ； W_Q 、 W_K 、 W_V 分别为参数矩阵。

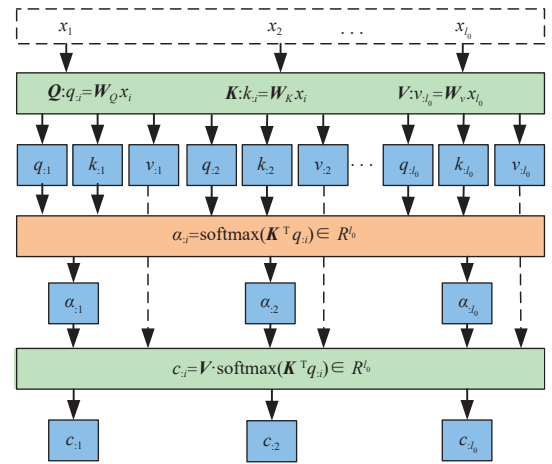
步骤2：通过式(12)将 Q 与 K 进行相似度计算得到相似性得分，将计算的相似性得分使用Softmax函数进行归一化处理，得到注意力分布 α_i ，其值越大，表明第 i 个输入与任务目标的相关性越高。

$$\alpha_i = \text{softmax}(K^T q_i) \quad (12)$$

步骤3：通过式(13)，将归一化的权重与 V 进行点积运算，得到注意力机制输出：

$$c_i = V \cdot \text{softmax}(K^T q_i) \quad (13)$$

式中 c_i 为注意力机制输出。



注： x_1, x_2, \dots, x_{l_0} 为特征输入； W_Q 、 W_K 、 W_V 为参数矩阵； Q 为查询向量； K 为键向量； V 为值向量； q_i 代表向量 Q 的元素； k_i 代表向量 K 的元素； v_i 代表向量 V 的元素； α_i 为注意力分布；Softmax函数为归一化函数； c_i 为注意力机制输出； i 为特征序号；范围 $1 \sim l_0$ 。

Note: x_1, x_2, \dots, x_{l_0} are feature input; W_Q, W_K and W_V are parameter matrix; Q is query vector; K is key vector; V is value vector; q_i is the element of Q vector; k_i is the element of K vector; v_i is the element of V vector; α_i is the attention distribution; Softmax is the normalized function; c_i is output of attention mechanism; i is the feature number, the range is 1 to l_0 .

图2 注意力机制原理图

Fig.2 Schematic diagram of attention mechanism

2.3 LSTM-AT模型

本研究提出将注意力机制与LSTM模型结合进行温室空气温度预测，模型总体框架如图3所示。首先，多变量时间序列模型通过LSTM模型进行特征学习，随后使用注意力机制，通过权重系数指示当前数据与历史数据的相关性，根据相关性分配不同的权重，从而获取最相关的信息。LSTM-AT模型通过忽略不相关信息，关注关键信息，提高模型的预测表现。

LSTM-AT模型包括输入层、隐藏层、注意力层、全连接层、输出层，每层描述如下：

1) 输入层：模型输入为多维时间序列特征变量，将输入数据转换为适宜LSTM计算的3维矩阵(S 、 T 、 X)^[27]，即输入表维度 S 、时间维度 T 、特征输入维度 X 。

2) 隐藏层：由多个LSTM单元组成，通过式(3)~(8)，将输入层信息存储至隐藏层状态 h_1 至 h_n ，并将

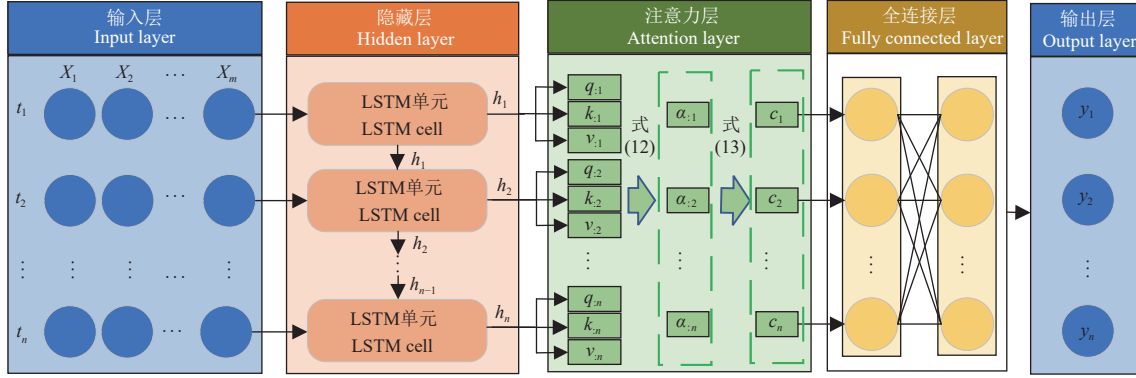
其输入下一层。

3) 注意力层：通过式 (9) ~ (11)，计算出每个隐藏层状态对应的 Q 、 K 和 V ，通过式 (12) 将 Q 与 K 进行相似度计算得到相似性得分，使用 Softmax 函数进行归一化处理，得到注意力分布，其值越大表明输入信

息与任务目标相关性越高。通过式 (13) 将归一化的权重与向量 V 进行点积运算，计算得到注意力输出。

4) 全连接层：全连接层进行局部信息集成和数据维度转换。

5) 输出层：实现预测结果的输出。



注： t_1, t_2, \dots, t_n 为时间序列； X_1, X_2, \dots, X_m 为输入变量；LSTM 为长短期记忆神经网络； y_1, y_2, \dots, y_n 为输出。
Note: t_1, t_2, \dots, t_n are time series; X_1, X_2, \dots, X_m are input variables; LSTM is long short-term memory; y_1, y_2, \dots, y_n are output.

图 3 LSTM-AT 原理图

Fig.3 Schematic diagram of LSTM-AT

2.4 评价指标

本研究采用的模型评价指标包括决定系数 R^2 、均方根误差 C_{RMSE} 、平均绝对百分比误差 C_{MAPE} ，其表达式如式 (14) ~ (16) 所示：

$$C_{RMSE} = \sqrt{\frac{1}{p} \sum_{k=1}^p (X_k - Y_k)^2} \quad (14)$$

$$C_{MAPE} = \frac{1}{p} \sum_{k=1}^p \left| \frac{X_k - Y_k}{Y_k} \right| \times 100\% \quad (15)$$

$$R^2 = 1 - \frac{\sum_{k=1}^p (X_k - Y_k)^2}{\sum_{k=1}^p (\bar{Y}_k - Y_k)^2} \quad (16)$$

3 结果与分析

因本研究面向的温室类型、区域气候特点以及数据集特征变量、数据量、数据质量等与前人研究不同，将本研究的模型预测效果与前人研究对比和讨论缺乏科学性。为了充分验证本研究构建的 LSTM-AT 模型相比 LSTM 模型以及现有研究中应用较为广泛的几种典型深度学习模型在温室室内空气温度预测方面的提升效果，本研究分别在不同预测时长以及不同天气状况两种情况下将 LSTM-AT 模型与 4 种目前常用的深度学习模型：RNN、LSTM、门控循环单元 (gated recurrent unit, GRU)、双向长短期记忆网络 (bi-directional long short-term memory, BiLSTM) 的温室空气温度预测表现进行了对比和分析。

3.1 模型参数设置

本研究试验数据采集时间为 2020 年 7 月 30 日至

2021 年 4 月 30 日，数据采集时间间隔为 5 min，数据总共 77232 条，按照 7: 3 的比例将数据划分为训练集和测试集，用于模型训练和检验。

本研究基于 Tensorflow 深度学习框架，训练迭代次数均设置为 80，最大训练轮数设置为 100，采用 “Adam” 和 “mean_squared_error” 分别作为模型训练的优化器和损失函数，LSTM 神经元的数量设置为 256。为了模型比较公平性，不同模型中相同模块设置参数相同。

3.2 不同预测时长结果分析

图 4 为 LSTM-AT、LSTM、GRU、RNN、BiLSTM 模型不同预测时长模拟值与测量值对比曲线。由图 4a~4c 得，预测时长为 12、24、48 h 时，LSTM-AT 模型的预测偏差最大值分别为 1.74、2.12、3.78 °C；图 4d~4f 显示 LSTM-AT 模型预测偏差最大值分别为 1.84、3.15、4.13 °C。

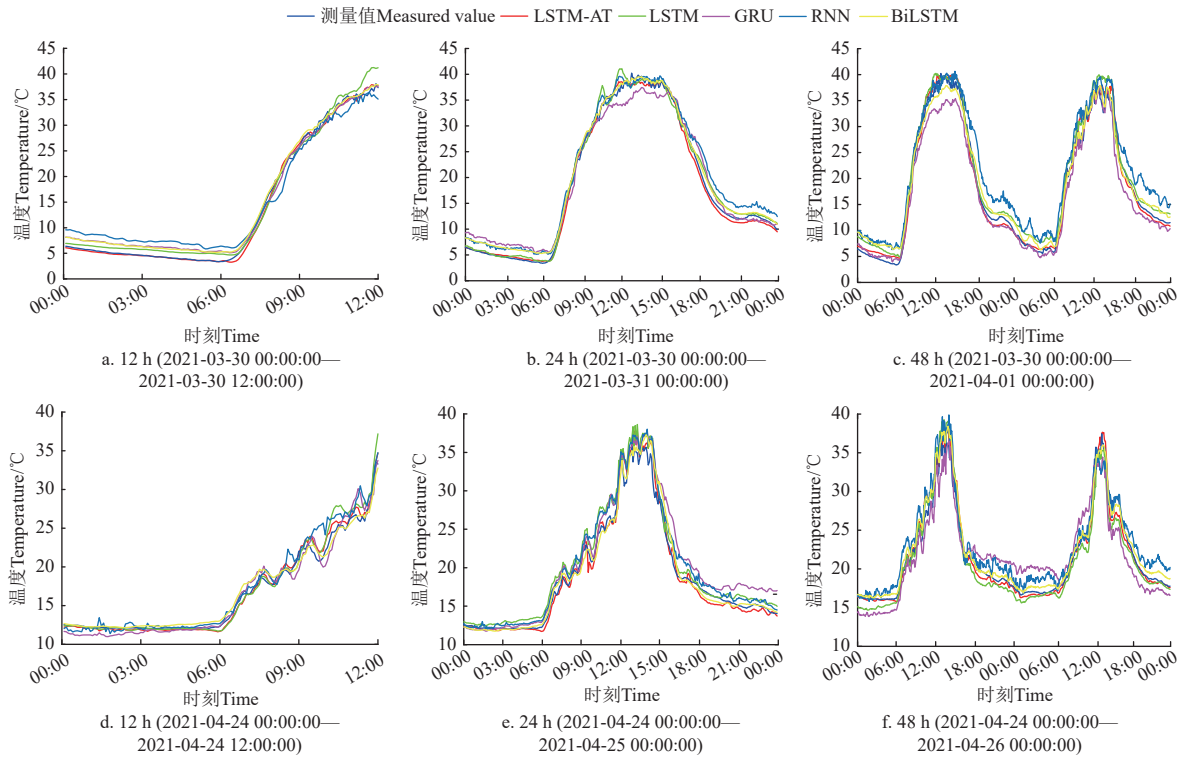
由表 2 可知，5 种模型的预测精度均随着预测时间延长而降低。LSTM-AT 模型预测决定系数最小值 0.98，最大值 0.99，其余模型预测决定系数最小值 0.97，最大值 0.99。从决定系数来看，不同预测时长情况下 5 种模型均能较好的模拟空气温度的变化趋势。LSTM-AT 模型预测均方根误差最小值 0.59 °C，最大值 1.34 °C，另外 4 种模型预测均方根误差最小值 0.66 °C，最大值 3.37 °C。LSTM-AT 模型预测平均绝对百分比误差最小值 2.48%，最大值为 8.14%，另外 4 种模型预测平均绝对百分比误差最小值 2.90%，最大值 38.7%。

LSTM-AT、LSTM、GRU、RNN、BiLSTM 模型预测 RMSE 平均值分别为 0.89、1.42、1.89、2.10、1.51 °C，MAPE 平均值分别为 4.26%、8.96%、13.57%、17.70%、10.67%。通过以上结果能够得出 5 种模型预测效果从好到差的排序依次为 LSTM-AT、LSTM、BiLSTM、GRU、

RNN。

综上，通过以决定系数、均方根误差和平均绝对百分比误差 3 个评价指标对 5 种模型不同预测时长温室空

气温度预测精度进行对比得出，本研究构建的 LSTM-AT 模型具有更高预测精度，能够更为准确的预测温室空气温度。



注：LSTM-AT 为 LSTM 与注意力机制结合构建的模型；RNN 为递归神经网络；GRU 为门控循环单元；BiLSTM 为双向长短期记忆网络；图 4a~4c 模型输入时间范围为 2021 年 3 月 15 日至 2021 年 3 月 29 日；图 4d~4f 模型输入时间范围为 2021 年 4 月 9 日至 2021 年 4 月 23 日。
 Note: LSTM-AT is the model that combines LSTM and attention mechanism; RNN is recurrent neural network; GRU is gated recurrent unit; BiLSTM is bi-directional long short-term memory; The model's input time range of Fig4a-4c is from March 15, 2021 to March 29, 2021; The model's input time range of Fig4d-4f is from April 9, 2021 to April 23, 2021.

图 4 不同预测时长预测值与测量值曲线
 Fig.4 Curves of predicted and measured values at different prediction horizons

表 2 不同预测时长 5 种模型预测性能对比
 Table 2 Performance comparison of five models at different output horizons

时间起点 Starting time	预测时长 Forecast duration/h	LSTM-AT			LSTM			GRU			RNN			BiLSTM		
		R^2	RMSE/°C	MAPE/%	R^2	RMSE/°C	MAPE/%	R^2	RMSE/°C	MAPE/%	R^2	RMSE/°C	MAPE/%	R^2	RMSE/°C	MAPE/%
2021-03-30 00:00:00	12	0.99	0.68	4.06	0.99	1.41	16.11	0.99	1.46	24.10	0.99	2.45	38.70	0.99	1.34	22.66
	24	0.99	0.75	4.40	0.99	1.18	6.05	0.99	2.06	20.03	0.99	2.03	18.76	0.99	1.17	14.41
	48	0.99	1.34	8.14	0.99	1.87	15.56	0.99	2.18	10.31	0.99	3.37	29.12	0.99	1.69	16.33
2021-04-24 00:00:00	12	0.99	0.59	2.48	0.99	0.94	2.90	0.98	1.03	4.64	0.98	1.30	4.43	0.99	0.66	3.05
	24	0.99	0.88	2.96	0.99	1.47	6.31	0.98	1.96	8.22	0.99	1.46	5.83	0.99	0.96	3.07
	48	0.98	1.10	3.51	0.98	1.63	6.84	0.91	2.66	14.12	0.97	1.99	9.41	0.99	1.09	4.54

注：RMSE 为均方根误差；MAPE 为平均绝对百分比误差。
 Note: RMSE is root mean square error; MAPE is mean absolute percentage error.

3.3 不同天气状况模型预测结果分析

为探索 LSTM-AT 模型不同天气状况的普适性，本

研究分别在晴天、多云、雨天 3 种天气状况下对 LSTM-AT 与 LSTM 模型的预测效果进行了分析和对比 (图 5)。




图 5 LSTM、LSTM-AT 模型不同天气状况预测结果
 Fig.5 Prediction results of LSTM and LSTM-AT model in different weather conditions

观察图 5a~5d 得出, LSTM-AT 模型预测偏差最大值分别为 2.02、2.21、0.65、1.46 °C, LSTM 模型预测偏差最大值分别为 3.74、3.11、1.76、3.79 °C。通过以上曲线及数据对比结果得出, 不同天气状况下, 相较于 LSTM 模型, LSTM-AT 模型具有更高的预测精度。

表 3 为 LSTM 和 LSTM-AT 模型不同天气状况温室空气温度预测量化对比结果。由表 3 可知, LSTM-AT 模型预测决定系数最小值 0.95, 最大值 0.99, LSTM 模型预测决定系数最小值 0.87, 最大值 0.99; 决定系数相对较小的日期均发生在多云或者雨天, 说明在多云或雨天情况下, 两种模型的预测效果均下降, LSTM-AT 模型能够更好的模拟温室空气温度的变化趋势; LSTM-AT 模型预测均方根误差最小值为 0.26 °C, 最大值为 0.70 °C, LSTM 模型预测均方根误差最小值为 0.68 °C, 最大值为 1.57 °C, 且 4 个典型日 LSTM-AT 模型预测均方根误差均小于 LSTM 模型; LSTM-AT 模型预测平均绝对百分比误差最小值 1.61%, 最大值 10.51%, LSTM 模型预测平均绝对百分比误差最小值 4.27%, 最大值 25.07%, 且 4 个典型日 LSTM-AT 模型预测平均绝对百分比误差均小于 LSTM 模型。

综合决定系数、均方根误差、平均绝对百分比误差这 3 个评价指标来看, 不同天气状况下 LSTM-AT 模型相比 LSTM 模型具有更高的预测精度。

表 3 不同天气状况下模型表现对比

Table 3 Model's performance comparison in different weather conditions

日期 Date	LSTM-AT			LSTM		
	R ²	RMSE/°C	MAPE/%	R ²	RMSE/°C	MAPE/%
2021-02-20	0.99	0.63	9.54	0.98	1.57	25.07
2021-02-24	0.95	0.70	10.51	0.94	1.19	17.90
2021-04-02	0.98	0.26	1.61	0.87	0.68	4.27
2021-04-05	0.99	0.43	3.10	0.99	1.06	10.60

4 结 论

针对长短记忆神经网络 (long short-term memory, LSTM) 模型面向长时间温室空气温度序列数据存在由于数据遗忘而导致预测精度降低的问题, 本研究提出了将 LSTM 模型与注意力机制 (attention mechanism, AT) 结合, 构建了 LSTM-AT 模型。该方法采用注意力机制为 LSTM 模型隐藏层输出状态分配权重, 解决 LSTM 模型长时间序列数据遗忘问题, 并通过试验验证 LSTM-AT 模型精度, 同时与常用的 LSTM、门控循环单元 (gated recurrent unit, GRU)、递归神经网络 (recurrent neural network, RNN)、双向长短记忆网络 (bi-directional long short-term memory, BiLSTM) 模型预测效果进行对比, 得出如下结论:

1) LSTM-AT 模型空气温度预测值与测量值变化趋势较为一致, 模型计算值与空气温度测量值的决定系数最小为 0.95, 均方根误差最大为 1.34 °C, 平均绝对百分比误差最大为 10.51%。

2) LSTM-AT、LSTM、GRU、RNN、BiLSTM 5 种

模型预测均方根误差平均值分别为 0.89、1.42、1.89、2.10、1.51 °C; 平均绝对百分比误差平均值分别为 4.26%、8.96%、13.57%、17.70%、10.67%。由此得出, LSTM-AT 模型相比 LSTM、GRU、RNN、BiLSTM 模型具有更高的预测精度, 可以用于长时间温室空气温度预测。

由于本研究仅以泰安市一栋玻璃温室为对象构建数据集及进行模型验证, 模型对其他地区以及结构参数温室的适用性有待于进一步验证。将 LSTM-AT 模型与模型预测控制等控制理论结合, 开展玻璃温室环境控制研究对提升玻璃温室环境调控精度具有重要的意义, 也将是下一步的研究方向。

[参 考 文 献]

- [1] 胡瑾, 杨永霞, 李远方, 等. 温室环境控制方法研究现状分析与展望[J]. 农业工程学报, 2024, 40(1): 112-128.
HU Jin, YANG Yongxia, LI Yuanfang et al. Analysis and prospect of the environmental control systems for greenhouse[J]. Transactions of the Chinese Society of Agricultural Engineering(Transactions of the CSAE), 2024, 40(1): 112-128. (in Chinese with English abstract)
- [2] 皮铁轩, 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(Transactions of the CSAE), 2023, 39(23): 185-195. (in Chinese with English abstract)
- [3] CHOAB N, ALLOUHI A, EL M A, et al. Review on greenhouse microclimate and application: Design parameters, thermal modeling and simulation, climate controlling technologies[J]. *Solar Energy*, 2019, 191: 109-137.
- [4] 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.
- [5] LI Z, WANG PENG, ZHANG J, et al. A strategy of improving indoor air temperature prediction in HVAC system based on multivariate transfer entropy[J]. *Building and Environment*, 2022, 219: 109164.
- [6] KAVGA A, THOMOPOULOS V, PISCHINAS E, et al. Design and simulation of a greenhouse in a computational environment (ANSYS/FLUENT) and an automatic control system in a LABVIEW environment[J]. *Simulation Modelling Practice and Theory*, 2023, 129: 102837.
- [7] 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.
- [8] BOULARD T, KITTAS C, ROY J C, et al. SE—Structures and environment: Convective and ventilation transfers in

- greenhouses, part 2: Determination of the distributed greenhouse Climate[J]. *Biosystems Engineering*, 2002, 83(2): 129-147.
- [9] 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.
- [10] LIU R, LI M, GUZMAN J L, et al. A fast and practical one-dimensional transient model for greenhouse temperature and humidity[J]. *Computers and Electronics in Agriculture*, 2021, 186: 106186.
- [11] ZHANG G, DING X, LI T, et al. Dynamic energy balance model of a glass greenhouse: An experimental validation and solar energy analysis[J]. *Energy*, 2020, 198: 117281.
- [12] 张观山, 李天华, 侯加林. 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. Model for predicting the temperature of glass greenhouse cover considering dynamic absorptivity[J]. *Transactions of the Chinese Society of Agricultural Engineering(Transactions of the CSAE)*, 2020, 36(5): 201-211. (in Chinese with English abstract)
- [13] LOPEZ C I, FITZ R E, SALAZAR M R, et al. Development and analysis of dynamical mathematical models of greenhouse climate: A review[J]. *European Journal of Horticultural Science*, 2018, 83(5): 269-279.
- [14] 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.
- [15] MAO C, SU Y. CFD based heat transfer parameter identification of greenhouse and greenhouse climate prediction method[J]. *Thermal Science and Engineering Progress*, 2024, 49: 102462.
- [16] JILANI M N H, MOHAPATRA P K. Computational fluid dynamics simulation of earth air heat exchanger combined with the Quonset type greenhouse to develop a sustainable controlled environment[J]. *Geothermics*, 2024, 116: 102845.
- [17] XIAO J, WANG Q, WANG X, et al. An earth-air heat exchanger integrated with a greenhouse in cold-winter and hot-summer regions of northern China: Modeling and experimental analysis[J]. *Applied Thermal Engineering*, 2023, 232: 120939.
- [18] YUAN X, XUE X. Prediction of soil thermal conductivity using artificial intelligence approaches[J]. *Geothermics*, 2023, 113: 102769.
- [19] WANG Z, SRINIVASAN R S. A review of artificial intelligence based building energy use prediction: Contrasting the capabilities of single and ensemble prediction models[J]. *Renewable and Sustainable Energy Reviews*, 2017, 75: 796-808.
- [20] DING X, JIANG Y, HUI D, et al. Model simulation of cucumber yield and microclimate analysis in a semi-closed greenhouse in China[J]. *HortScience: A publication of the American Society for Horticultural Science*, 2018, 54(3): 547-554.
- [21] DING J, TU H, ZANG Z, et al. Precise control and prediction of the greenhouse growth environment of *Dendrobium candidum*[J]. *Computers and Electronics in Agriculture*, 2018, 151: 453-459.
- [22] WANG H, LI L, WU Y, et al. Recurrent neural network model for prediction of microclimate in solar greenhouse[J]. *IFAC-PapersOnLine*, 2018, 51(17): 790-795.
- [23] FERREIRA P M, RUANO A E. Predicting the greenhouse inside air temperature with RBF neural networks[J]. *IFAC Proceedings Volumes*, 2001, 34(11): 67-72.
- [24] 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.
- [25] HOU J, WANG Y, HOU B, et al. Spatial simulation and prediction of air temperature based on CNN-LSTM[J]. *Applied Artificial Intelligence*, 2023, 37(1): 2166325.
- [26] DATTA P, FAROUGH S A. A multihead LSTM technique for prognostic prediction of soil moisture[J]. *Geoderma*, 2023, 433: 116452.
- [27] 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.
- [28] YANG J, GUO Y, CHEN T, et al. Data-driven prediction of greenhouse aquaponics air temperature based on adaptive time pattern network[J]. *Environmental Science and Pollution Research*, 2023, 30(16): 48546-48558.
- [29] GUO Y, ZHANG S, YANG J, et al. Dual memory scale network for multi-step time series forecasting in thermal environment of aquaculture facility: A case study of recirculating aquaculture water temperature[J]. *Expert Systems with Applications*, 2022, 208: 118218.
- [30] WANG Y, ZHAO J, YANG C, et al. Remaining useful life prediction of rolling bearings based on Pearson correlation-KPCA multi-feature fusion[J]. *Measurement*, 2022, 201: 111572.

Predicting greenhouse air temperature using LSTM-AT

ZHANG Guanshan^{1,2}, DING Xiaoming^{1,3}, HE Fen^{1,3}, YIN Yilei^{1,3}, LI Tianhua²,
REN Ji'ao², ZHOU Junyi², QI Fei^{1,3*}

(1. Academy of Agricultural Planning and Engineering, Ministry of Agriculture and Rural Affairs, Beijing 100125, China; 2. College of Mechanical and Electronic Engineering, Shandong Agricultural University, Tai'an 271018, China; 3. Key Laboratory of Farm Building in Structure and Intelligent Construction, Ministry of Agriculture and Rural Affairs, Beijing 100125, China)

Abstract: An accurate prediction model of greenhouse air temperature can be required for the greenhouse environment control using control algorithm, such as model predictive control. Long short-term memory neural networks (LSTM) have been widely used to predict time series data, such as air temperature. However, the prediction accuracy of LSTM can be reduced for the long time series data, due to data forgetting. In this study, the LSTM model was combined with the attention mechanism to construct the LSTM-AT model. The query vector, key vector, and value vector were calculated, according to attention mechanism and output states of LSTM's hidden layer. The similarity between the query and key vector was calculated to obtain the similarity score. Softmax function was used to obtain attention distribution for the normalization processing. The larger the attention value was, the higher the relevance of input information to the task objective was. The dot product operation was carried out with the normalized weight and value vector to obtain the output of the attention mechanism. The local information integration and data dimension transformation were carried out through the full connection layer. Finally, the output data was obtained in the output layer of the LSTM-AT model. The weights were assigned to the output states of LSTM's hidden layer, according to the degree of importance. The forgetting of long time series data was effectively solved to improve the prediction accuracy of indoor air temperature. The prediction performances were verified and compared on the LSTM-AT, LSTM, recurrent neural network (RNN), gated recurrent unit (GRU), and bi-directional long short-term memory (BiLSTM) model in the different prediction horizons (12, 24 and 48 h). The results showed that the prediction accuracy of the five models shared a decreasing trend with the increase in prediction time. The maximum and minimum RMSE for the LSTM-AT model were 1.34 and 0.59 °C, respectively. The maximum and minimum RMSE for the rest four models were 3.37 and 0.66 °C, respectively. The maximum and minimum MAPE for the LSTM-AT model were 8.14% and 2.48%, respectively. The maximum and minimum MAPE for the rest four models were 38.7% and 2.90%, respectively. The average RMSE for LSTM-AT, LSTM, GRU, RNN, and BiLSTM were 0.89, 1.42, 1.89, 2.10, and 1.51 °C, respectively. The average MAPE for LSTM-AT, LSTM, GRU, RNN, and BiLSTM were 4.26%, 8.96%, 13.57%, 17.70%, and 10.67%, respectively. The sort data of the prediction model was ranked in descending order of the LSTM-AT, LSTM, BiLSTM, GRU, and RNN. Therefore, the prediction accuracy of the LSTM-AT model was higher than that of rest four models. The prediction performances of the LSTM-AT and LSTM model were compared under different weather conditions (sunny, cloudy, and rainy), in order to further explore the universality of the LSTM-AT model. The minimum and maximum RMSE for LSTM-AT were 0.26 and 0.70 °C, respectively. The minimum and maximum RMSE for LSTM were 0.68 and 1.57 °C, respectively. The minimum and maximum MAPE for LSTM-AT were 1.61% and 10.51%, respectively. The minimum and maximum MAPE for LSTM were 4.27% and 25.07%, respectively. The prediction accuracy of the LSTM-AT model was higher than LSTM in all weather conditions. The LSTM-AT model has a higher prediction accuracy to accurately predict the indoor air temperature.

Keywords: greenhouse; air temperature; long short-term memory neural network; attention mechanism; prediction model