doi:10.6041/j.issn.1000-1298.2026.02.036

基于小样本迁移学习的跨地点菇房温度预测模型研究

胡　瑾[1,2]　刘行行[2,3]　孙大虎[2,3]　张　莹[4]　杨永霞[1,2]　雷文晔[2,3]

(1.西北农林科技大学信息工程学院,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.西北农林科技大学机械与电子工程学院,陕西杨凌 712100;4.西北农林科技大学图书馆,陕西杨凌 712100)

摘要:菇房温度精准预测是保证食用菌工厂化高效生产的关键,现有预测模型在面向不同地点菇房实际应用中缺乏普适性。本文考虑菇房设备对环境变化的扰动影响,融合设备运行状态特征建立一种基于时序卷积网络和长短期记忆网络(Temporal convolution network-long short-term memory,TCN-LSTM)的菇房温度时序预测模型,采用 TCN 在时间维度上提取特征局部信息,利用 LSTM 捉时序数据的长期依赖关系。与未融合设备工作状态特征的模型相比,当预测时长为 1、2、3 h 时,TCN-LSTM 模型 MSE 分别降低 17.1%、35.7%、44.1%,MAE 分别降低 4.3%、28.0%、38.0%;结果表明考虑融合设备工作状态提升了模型预测性能。与其他不同浅层和深度学习模型相比,TCN-LSTM 模型在不同预测时长下均具有最佳的预测精度,当预测时长为小于,3 h 模型 R^2 不小于 0.982、MSE 和 MAE 不大于 0.57℃,可满足菇房环境调控对温度预测精度和时长要求。基于迁移学习的预训练及微调方式在小样本数据集中调整网络参数,实现面向不同地点的菇房温度预测模型快速构建。结果表明,当预测时长为 1、2、3 h 时,以不同地点数据作为目标域建立的预测模型在测试集中 R^2 不小于 0.912,MSE 不大于 4.02℃,MAE 不大于 2.01℃,因此,在小样本条件下基于迁移学习构建的面向不同地点模型可实现不同步长下温度精准预测。

关键词:菇房;温度;时序预测模型;迁移学习;小样本

中图分类号:TP273⁺.1　　**文献标识码**:A　　**文章编号**:1000-1298(2026)02-0375-09　　**OSID**:

Cross-location Mushroom House Temperature Prediction Model Based on Small Sample Transfer Learning

HU Jin[1,2]　LIU Hangxing[2,3]　SUN Dahu[2,3]　ZHANG Ying[4]　YANG Yongxia[1,2]　LEI Wenye[2,3]

(1. *College of Information 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. *College of Mechanical and Electronic Engineering*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*
4. *Library*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*)

Abstract: Accurate temperature prediction in mushroom houses is crucial to ensuring the efficient industrial production of edible mushrooms. However, existing predictive models often lack generalizability when applied to mushroom houses located in different regions. Taking into account the disruptive effects of environmental changes caused by equipment in mushroom cultivation houses, and equipment operation state features was integrated to develop a temperature prediction model based on the temporal convolution network and long short-term memory model (TCN-LSTM). This model used TCN to extract local information along the temporal dimension, while LSTM captured the long-term dependencies of time series data. Compared with models that did not integrate device operating state features, the TCN-LSTM model that incorporated these features reduced the MSE by 17.1%, 35.7%, and 44.1%, and reduced MAE by 4.3%, 28.0%, and 38.0% for prediction horizons of 1 hour, 2 hours, and 3 hours, respectively. This result indicated that incorporating equipment operating states had a significantly positive effect on the prediction performance. Compared with other shallow and deep learning models, the TCN-LSTM model achieved the best prediction accuracy for different prediction horizons, with R^2 no less than 0.982, and both MSE and MAE no more than 0.57℃ for horizons up to 3 hours, satisfying the requirements of accuracy and duration in temperature predictions for mushroom room environmental control. This study

收稿日期:2024-10-18　修回日期:2025-02-10

基金项目:陕西省重点研发计划项目(2024NC-ZDCYL-05-07)

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

employed transfer learning via pre-training and fine-tuning to adjust network parameters in small sample datasets, achieving rapid construction of temperature prediction models for mushroom rooms at different locations. The results indicated that for prediction horizons of 1 hour, 2 hours, and 3 hours, the prediction models built using different locations as target domains achieved R^2 values no less than 0.912, MSE values no more than 4.02℃, and MAE values no more than 2.01℃ in the test set. These results suggested that under small sample conditions, the temperature models constructed for different locations using transfer learning can achieve accurate temperature predictions at different steps.

Key words: mushroom house; temperature; time-series prediction model; transfer learning; small sample

0 引言

中国是全球最大的食用菌生产国之一,食用菌种类丰富。近年来,食用菌产业逐渐从传统的家庭种植向规模化、工厂化生产转变[1]。随着现代农业技术发展,自动化控制技术在食用菌工厂化生产中的应用日益普及。通过实现菇房环境信息监测以及温湿度自动化控制,提高了食用菌生产效率和品质[2]。温度作为影响食用菌生长的关键因素之一,其适宜范围对于促进菌菇生长至关重要[3]。因此,为了克服季节和气候波动对生产稳定性的影响,智能化温度控制设备被广泛应用于菇房管理中,为食用菌工厂化高效、稳定生产提供了重要保障。

菇房环境温度精准预测是设备高效控制的关键。近年来,国内外学者探索了基于机器学习和深度学习的温室环境预测模型构建方法。基于传统数理统计方法的预测模型,如时序分析法和逐步回归分析法,能够在一定程度上捕捉环境因子的变化特征[4]。目前基于数据驱动的模型在菇房环境预测中应用广泛,如时序分析法、线性回归法、BP 神经网络等[5-7]模型预测精度和泛化能力显著提升。此外,通过构建结合卷积神经网络(CNN)和长短期记忆网络(LSTM)的组合模型,有效提取时间序列中复杂的特征,进一步提高了预测准确性[8]。循环神经网络(RNN)及门控循环单元(GRU)也被应用于设施环境温湿度预测中,以捕捉时序消息中的长期依赖关系,更好地解决温度和相对湿度非线性和滞后性问题[9-12]。

尽管针对菇房温度预测模型已开展了大量研究并取得了一定进展,但许多研究仅关注环境因子对温度的影响,而忽略了设备运行状态的扰动效应。设备运行状态对温度扰动具有显著的非线性和时变性,通过简单的环境因子建模难以全面反映设备扰动对菇房环境的影响,导致预测模型适用性较差[13]。传统预测模型训练通常依赖于大量历史数据,而在处理长期时序数据时,数据长度过长、维度过多会导致模型预测能力迅速下降[14]。对于新建或改造的菇房,由于缺乏足够的历史数据,难以快速建立高精度菇房温度预测模型[15-16]。

针对上述问题,本文提出一种基于 TCN-LSTM 模型的菇房温度预测方法,并通过迁移学习实现小样本条件下不同地点的模型快速构建。搭建菇房内外环境监测平台,获取温度、相对湿度、CO_2浓度等环境因子以及设备运行状态等数据,通过网络参数优化与特征提取,分析内外环境因子及扰动因子对室内温度的相关性,以特征和时间步长二维矩阵作为输入。通过网络叠加及参数优化,建立基于 TCN-LSTM 的菇房温度预测模型。基于迁移学习以预训练及微调方式在小数据集中调整网络参数,构建面向多地点条件下的菇房温度预测。

1 数据采集与预处理

1.1 平台搭建与数据采集

试验于 2023 年 9 月 26 日至 10 月 26 日在广东省黄埔区航新农业食用菌工厂化种植基地进行,菇房内栽培作物为金耳,适宜生长温度为 20 ~ 22℃。以该地点获取的数据为源域数据实现模型构建。试验地位于北纬 23°15′、东经 113°25′,海拔 40 m,属于亚热带季风气候,年均温度 22℃。菇房为标准化厂房结构,单个菇房长 10 m,宽 3 m,高 4 m,墙体采用聚氨酯泡沫板结构,具有空调温度控制设备、超声波湿度控制设备、新风系统、灯光系统、栽培种植架等设备,同时为使菇房内部温度趋于均匀,保证作物生产一致性,采用绕动风机加快菇房内空气流动。在菇房内距菇房左侧和右侧墙体 1.5 m 2 个位置分别放置传感器,且距地面高度 2 m,距门位置 5 m。室外传感器距菇房 2 m,在阴凉避雨环境下且周围无热源和影响温度极具变化的设备。

数据获取平台由菇房内外环境信息监测模块、设备通信模块、菇房物联网平台 3 部分组成,如图 1 所示。每日 0:00—24:00 连续采集,采样间隔为 10 min,共采集 6 种环境因子,包括室内外空气温度(兆泰盛温度传感器,量程:-30 ~ 70℃,精度:±0.1℃)、室内外空气相对湿度(兆泰盛湿度传感

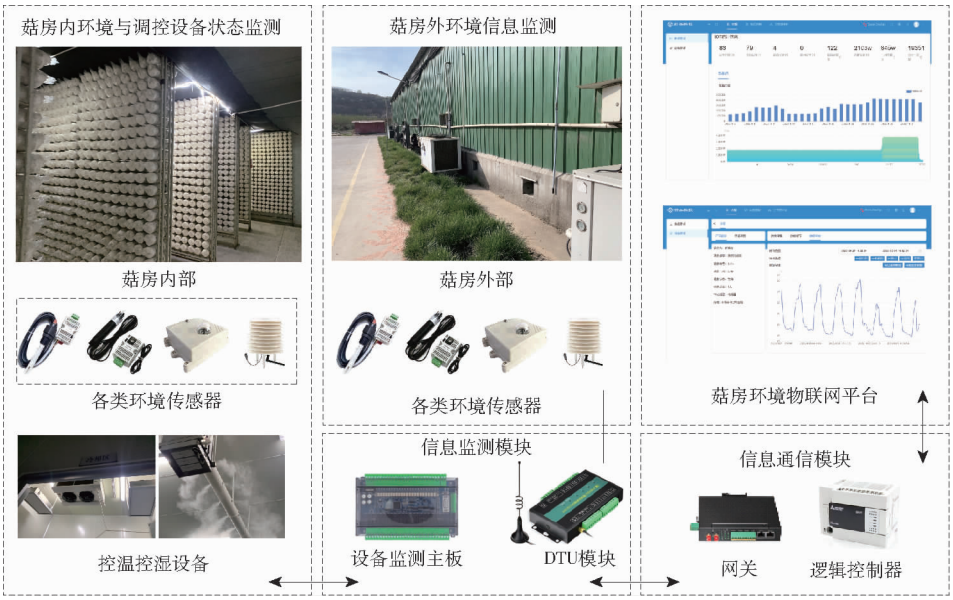


图 1　数据获取平台

Fig. 1　Data acquisition platform

器，量程：0% ~ 100%，精度：±3%）、室内外 CO_2 浓度（兆泰盛 CO_2 浓度传感器，量程：0 ~ 5 × 10^{-3} μmol/mol，精度：4 × 10^{-5} μmol/mol），共采集 2 种菇房设备工作状态，包括控温设备（百福特菇房专用制冷设备，功率：4 kW，控温区间：14 ~ 30℃）和加湿设备（多乐信 DRS－18A 型工业超声波加湿器，加湿量：18 kg/h）。设备均为定频工作模式，只有启动和停止 2 种工作状态，用 1 表示设备启动，0 表示设备停止，采集 31 d，共获取 4 464 组样本数据。依据阈值控制控温设备和加湿设备启停，用户根据菇房生产需求设定温度和相对湿度目标值，根据设定值与环境监测值比较进行控温设备和加湿设备启停工作。将菇房实时环境信息通过多通道 DTU 模块进行连接通信，环境传感器基于 RS485 接口与 DTU 网络模块连接，调控设备工作状态基于 IO 口与 DTU 网络模块建立连接。菇房内外环境信息通过搭载网关和逻辑控制器通信模块上传到云平台，通过菇房物联网云平台解析菇房环境信息并在可视化图表显示，同时物联网平台随时查看菇房环境信息和设备工作情况，通过数据记录和下载，更方便处理菇房环境数据。

为验证小样本迁移对比模型，试验在西北农林科技大学曹新庄实验农场食用菌研究中心食用菌工厂化种植基地进行。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℃。试验于 2023 年 10 月 8—26 日进行，期间天气与广东食用菌工厂基地类似。

1.2　数据预处理

菇房需要采用各类控制设备进行环境调控，且室内空气相对湿度较大，导致长时间放置于菇房的传感器会受到湿度影响导致监测数据有误。由传感器采集的数据可能存在缺失值和异常值，进而对预测模型精度产生一定程度的影响，因此在建立模型前需要进行数据清洗。

针对在数据监测过程中传感器采集故障或数据传输问题造成的数据缺失及异常情况，利用箱线图观察数据整体分布情况并剔除异常数据。对于缺失数据，当缺失数量小于 5 时，采用线性插值进行填充；当缺失数据较多时，为避免长距离间的虚假插值，使用最接近缺失值且天气状况相同的数据进行填充。

2　模型构建

2.1　TCN 模型

TCN 具有独特的因果序列模块，适合处理时序数据，通过模块并行处理可有效避免梯度消失和爆炸等问题[17]。其网络整体基于一维全连接卷积层（Fully-convolution network，FCN），每个 FCN 具有因果卷积、扩张卷积功能，同时 TCN 层与层之间通过残差模块连接，原理如图 2 所示。因果卷积设置每一层任意时刻的预测信息仅依赖于该时刻前层以及该时刻前多层信息，且输入信息长度等于输出信息长度，保证了模型输入序列时序性[18-19]。扩张卷积使 TCN 感受野呈指数型扩大，同时使网络基于更长的记忆序列预测，扩张系数 d 插入 FCN 的普通感受野中，d 通常为[1，2，4，8，…] 的指数序列。当底层网络 d = 1 时，表示其输入序列的每个信息点均采样；当隐藏层 d = 2 时，表示输入序列每 2 个信息点

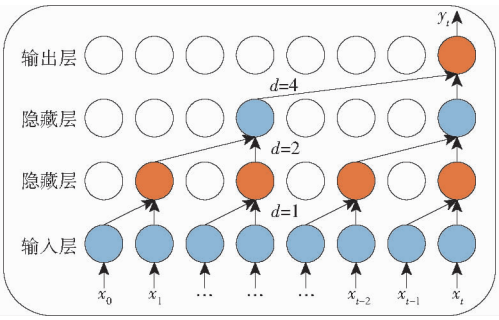


图 2 TCN 模型原理图

Fig. 2 TCN schematic

只采样 1 个。随着 d 的增加网络采样间隔与卷积窗口也变大,不仅增大了感受野也在一定程度上降低了运算量。网络通过其上下获取数据信息,即使存在较少网络层也能得到较大的感受野,计算公式为

$$F(s)=\sum_{i=0}^{k-1} f(i)X_{s-di} \tag{1}$$

式中 k——卷积核尺寸

X_{s-di}——输入序列

$f(i)$——卷积核第 i 个元素信息

除此之外,TCN 增加残差链接解决梯度问题,通过残差模块将下层特征提取并引入上层信息中,减少模型泛化误差,结构如图 3 所示。

在图 3 中,输入通过空洞因果卷积、批量标准化以及激活函数完成计算,同时添加 Dropout 防止模型过拟合,经过两轮操作后将得到的残差函数与卷积模块相加,最终完成模型输出,实现残差链接。

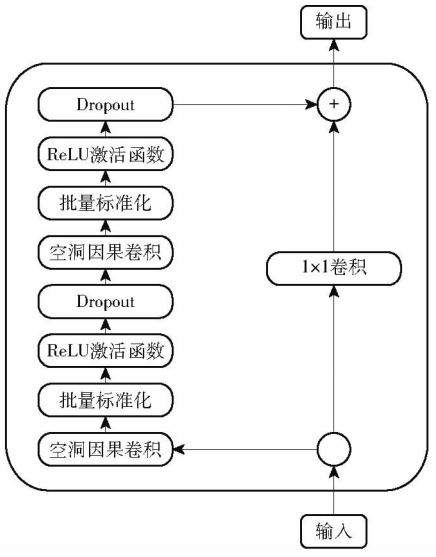


图 3 残差模块

Fig. 3 Residual modules

2.2 LSTM 模型

长短期记忆网络 LSTM 是通过其特有的门控机制增强了对长期依赖的学习能力[20-21]。如图 4 所示,遗忘门 f_t 决定哪些信息从细胞状态中丢弃,输入门 i_t 控制新信息摄入量,而输出门 o_t 则决定细胞状态中有多少信息会被用于计算当前时间步输出,且具有 3 输入:当前时间点接收到的新信息 x_t、上一时间步隐藏状态 h_{t-1} 和上一时间步细胞状态 c_{t-1};3 输出:当前时间步隐藏状态 h_t、当前时间步细胞状态 c_t 和当前时间步输出 h_t。因此 LSTM 不仅能够有效存储短期输入信息,还能有选择性地保留或忘记这些信息,进而维护一个跨时段长期记忆状态[22-24]。

LSTM 模型计算公为

$$f_t=\sigma(W_f[H_{t-1},X_t]+b_f) \tag{2}$$

$$i_t=\sigma(W_i[H_{t-1},X_t]+b_i) \tag{3}$$

$$\widetilde{C}_t=\tanh(W_C[H_{t-1},X_t]+b_C) \tag{4}$$

$$C_t=f_tC_{t-1}+i_t\widetilde{C}_t \tag{5}$$

$$o_t=\sigma(W_o[H_{t-1},X_t]+b_o) \tag{6}$$

$$H_t=o_t\tanh(C_t) \tag{7}$$

式中 $\widetilde{C}_t$、C_t、H_t——t 时刻候选单元状态、当前单元状态和隐层状态

X_t——t 时刻输入向量

W、b——对应单元状态权重系数矩阵和偏置

tanh——激活函数

σ——Sigmoid 激活函数

2.3 TCN-LSTM 网络结构

为提取多维数据潜在特征,进一步探究特征与时间步长隐层信息,使模型更加高效地学习时间序列中交互的复杂关系,将 TCN 和 LSTM 相结合构建

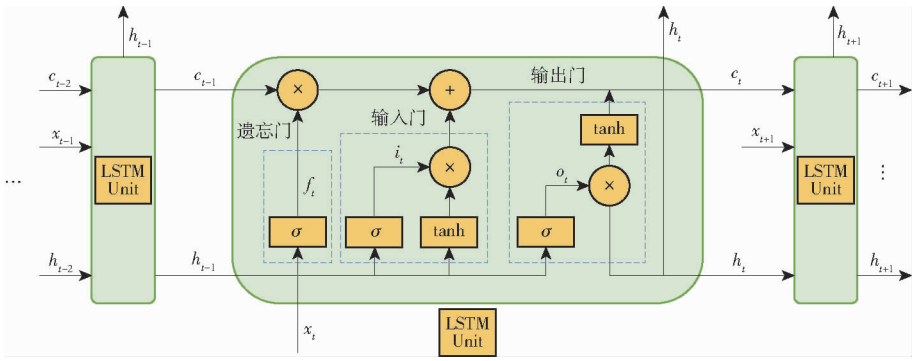


图 4 LSTM 模型原理图

Fig. 4 LSTM schematic

TCN－LSTM 网络。该网络整体结构基于逐个堆叠方式连接的方式，采用 4 层网络，通过 TCN 进行特征提取后将获取的信息输入至第 1 层 LSTM 中，第 1 层 LSTM 返回带有时间轴的三维数据组至第 2 层 LSTM 中，第 2 层 LSTM 返回每个序列的最终值并将数据发送至全连接层，全连接层将浅层所获取的特征映射至该层中，输出多步时序序列，具体结构如图 5 所示。

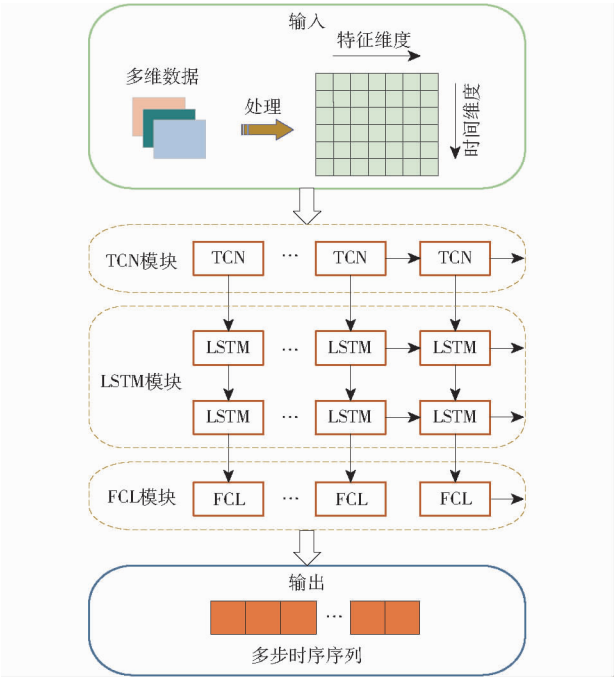


图 5　TCN－LSTM 网络结构

Fig. 5　TCN－LSTM network structure

2.4　基于迁移学习的温度预测模型建立

基于 TCN－LSTM 网络构建温度源域预测模型。源域模型以室内外温度、室内外空气相对湿度、室内外 CO_2 浓度、控温设备及加湿设备工作状态为输入，时间步长为 10，即输入矩阵为 8×10；以 1、2、3 h 后温度为输出。

为实现不同地点条件下小数据集温度预测模型精准化建立，采用基于模型的迁移学习法建立目标域预测模型[25]。通过建立的温度预测模型，采用预训练和微调方式在小数据集中调整网络参数，使其达到最优权重，与特征提取互为补充[26]。对于用于特征提取的冻结模型基，将其顶部的几层“解冻”，并将解冻层和新增加的部分联合训练，建立温度源域目标域预测模型方法如图 6 所示。

具体过程如下：

（1）为加速网络收敛速度、增加模型稳定性与泛化能力，归一化法对样本数据进行处理，计算公式为

$$x_{nor}=\frac{x-x_{min}}{x_{max}-x_{min}} \tag{8}$$

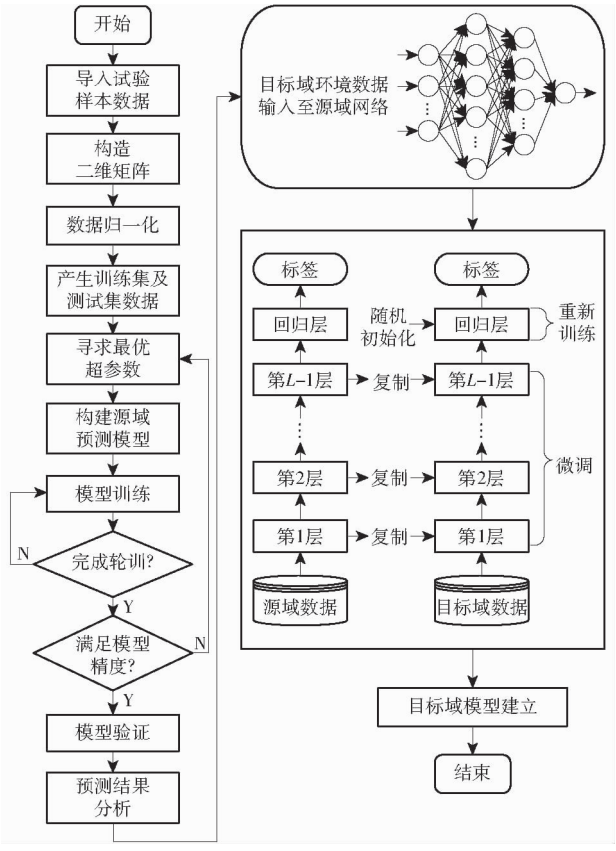


图 6　基于迁移学习的温度预测模型构建

Fig. 6　Construction of temperature prediction model based on transfer learning

式中　x_{min}——每类数据最小值

x_{max}——每类数据最大值

x_{nor}——归一化后数据

（2）对源域 31 d，4 464 组数据中，选取 3 125 组数据（占样本总数据 70%）作为训练集，其余 1 339 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源域模型，测试集数据验证源域模型的泛化能力及精度。

（3）在模型建立中，TCN 通过扩张因子获取数据信息，处理具有特定批量大小、通道数和序列长度张量，输出一个与输入张量长度保持一致的张量（式（1））。在双层 LSTM 中此张量通过遗忘门 f_t、输入门 i_t 和输出门 o_t 输出当前时间步的细胞状态 c_t 和当前时间步的输出（隐藏状态）h_t（式（2）～（7））。

（4）源域模型经过试参后整体网络均基于 Adam 优化算法训练，ReLU 为激活函数，均方误差函数（Mean square error，MSE）为损失函数。TCN 模块卷积核为 3×3，卷积核个数为 64，每层扩张系数为[1，2，4，8]，LSTM 模块为双层网络，每层节点均为 32，全连接层节点为 10。

（5）以测试集温度为实际值，源域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，再以决定系数 R^2、均方误差（MSE）和平均绝对误差

(MAE)为评价指标,对源域模型精度及泛化能力进行评估。

(6)获取源域模型后,以预训练和微调方式将目标域试验数据导入源域模型网络训练,深层网络冻结并保留其权重,浅层网络更新权重,在小样本条件下建立目标域预测模型,并以上述评价指标验证目标域模型精度与泛化能力[27]。

以在广东省黄埔区航新农业食用菌工厂化种植基地采集的 31 d 数据为源域,并采用该数据集作为建立 TCN - LSTM 网络预训练,将在西北农林科技大学曹新庄实验农场食用菌研究中心食用菌工厂化种植基地获取的数据作为目标域。由于目标域试验数据共采集 19 d,因此为探寻目标域时间与层数的关系,共设计 2 组对比测试,以目标域最后 9 d 作为测试集,并以同一目标域中 1/1(10 d)、1/2(5 d)数据样本作为训练集,具体划分如图 7 所示。

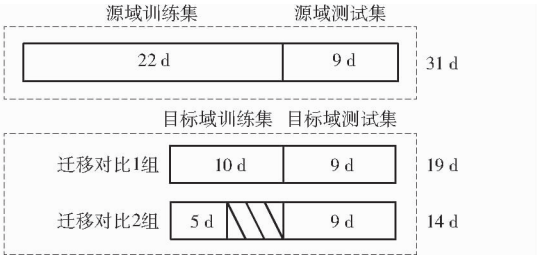


图 7 目标域数据划分

Fig. 7 Target domain data division

在模型迁移时数据划分方式为:当源域网络冻结时序卷积层与顶端循环层,其余网络参数重新训练时,目标域选取 2023 年 10 月 8—17 日数据(共 10 d)及 2023 年 10 月 8—12 日数据(共 5 d)作为训练集训练模型;当源域网络冻结时序卷积层与 2 层循环层,其余网络参数重新训练时,目标域选取方法与之前相同。上述模型均以 2023 年 10 月 18—26 日数据(共 9 d)作为测试集验证模型泛化能力及精度。其中,训练周期为 500,学习率为 0.001,分别在不同预测时长、不同冻结层数与不同训练集时间进行建模。

3 试验结果与分析

3.1 菇房设备扰动性

根据菇房内环境变化来调整设备工作状态,以确保菇房内温湿度条件始终处于最佳状态。菇房内设备运行情况对环境变化的影响显著,其中温控和加湿设备对菇房内温度和湿度扰动影响结果如图 8 所示。

如图 8 所示,在温控设备和加湿设备状态发生改变时,菇房内温度和相对湿度的变化呈一定波动性,表明控温和加湿设备工作状态对室内温度变化趋势的影响显著。对于位于菇房内不同位置的 2 个温度和湿度传感器,两者数据相异较小,且随环境调

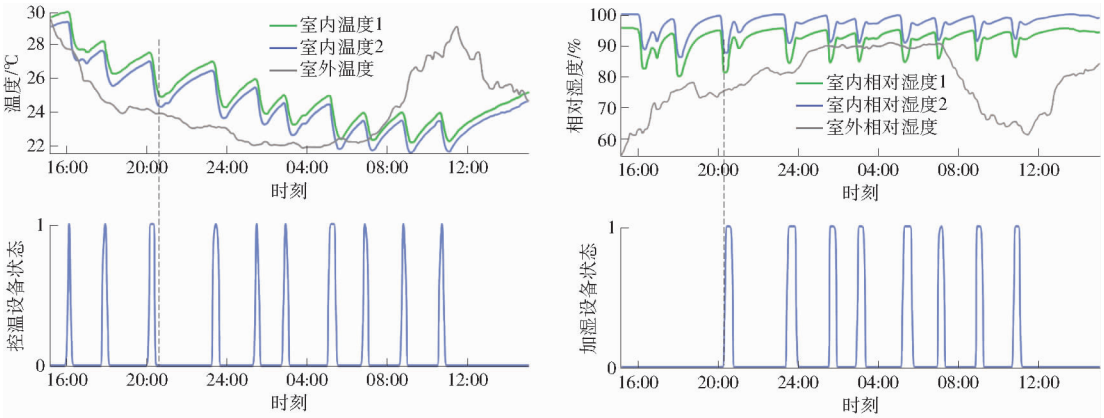


图 8 设备对环境因子的扰动影响

Fig. 8 Disturbance impact of devices on environmental factors

控设备开启状态呈同步变化。结果表明,除历史温度数据对未来温度变化的影响外,设备工作状态对菇房内温度的影响极显著,在菇房环境建模时应充分考虑设备工作状态。

3.2 融合设备状态扰动模型验证

以 R^2、MSE 和 MAE 为评价指标,对比预测时长 1、2、3 h 下融合设备状态和仅考虑历史时序数据的模型预测结果,融合设备状态 TCN - LSTM 模型温度预测结果如表 1 所示。

由表 1 可知,在不同预测时长下,融合设备状态温度模型相较于仅考虑历史时序数据的模型准确性都有显著提升。模型 R^2 均不小于 0.962,表明模型具有良好的拟合能力。当预测时长为 1、2、3 h 时,融合设备工作状态的 TCN - LSTM 模型预测性能呈逐渐下降趋势,其在测试集中 MSE 为 0.34、0.36、0.57℃,MAE 为 0.44、0.46、0.57℃。较未融合设备工作状态预测模型,融合设备工作状态的 TCN - LSTM 模型 MSE 分别降低 17.1%、35.7%、44.1%,

表 1　融合设备状态的 TCN－LSTM 模型温度预测结果

Tab. 1　TCN－LSTM model prediction results of integrated device status

预测时长/h	融合扰动因子	训练集			测试集		
		R^2	MSE/℃	MAE/℃	R^2	MSE/℃	MAE/℃
1	是	0.991	0.31	0.40	0.991	0.34	0.44
	否	0.988	0.34	0.41	0.985	0.41	0.46
2	是	0.986	0.31	0.40	0.986	0.36	0.46
	否	0.980	0.48	0.65	0.975	0.50	0.68
3	是	0.985	0.42	0.48	0.982	0.57	0.57
	否	0.970	0.97	0.87	0.962	1.02	0.92

MAE 分别降低 4.3%、28.0%、38.0%。结果表明考虑融合设备工作状态对于模型预测性能提升具有重要作用。

3.3　不同模型预测精度对比

为验证提出的 TCN－LSTM 算法预测性能，以 R^2、RMSE 和 MAE 为评价指标，将其与参数优化后多元线性回归法（Multiple linear regression，MLR）、反向传播神经网络（Belief propagation neural networks，BP）、时序卷积网络 TCN 及长短期记忆网络 LSTM 的建模效果进行对比，结果如表 2 所示。

表 2　不同模型预测效果对比

Tab. 2　Comparison results of prediction performance of different models

预测时长/h	算法	训练集			测试集		
		R^2	MSE/℃	MAE/℃	R^2	MSE/℃	MAE/℃
1	MLR	0.905	4.86	2.11	0.901	4.97	2.35
	BP	0.940	1.50	1.36	0.938	1.55	1.40
	TCN	0.975	0.78	0.85	0.972	0.79	0.87
	LSTM	0.982	0.54	0.66	0.980	0.58	0.69
	TCN－LSTM	0.991	0.31	0.40	0.991	0.34	0.44
2	MLR	0.837	34.88	6.235	0.801	36.94	6.59
	BP	0.919	3.29	1.872	0.910	3.69	1.90
	TCN	0.965	1.60	1.194	0.961	1.68	1.27
	LSTM	0.974	0.70	0.806	0.970	0.75	0.84
	TCN－LSTM	0.986	0.31	0.404	0.986	0.36	0.46
3	MLR	0.462	85.32	9.280	0.449	88.32	9.79
	BP	0.858	30.26	5.975	0.852	35.74	6.04
	TCN	0.950	2.72	1.673	0.948	2.88	1.70
	LSTM	0.968	1.73	1.032	0.961	1.82	1.07
	TCN－LSTM	0.985	0.42	0.485	0.982	0.57	0.57

由表 2 可知，在预测时长为 1 h 时，不同模型 R^2 不小于 0.901，MLR 和 BP 模型 MSE 和 MAE 低于深度学习模型结果，但其总体相差不大。但随着预测时长的增加，MLR 和 BP 模型预测精度快速下降。当预测时长为 2 h 时，BP 模型在测试集中的 MSE 和 MAE 分别为 3.69℃ 和 1.90℃；当预测时长为 3 h 时，其预测性能显著下降。结果说明 BP 算法虽然具有一定的非线性建模能力，但其对多维时序数据处理能力有限，难以实现对菇房内温度精准预测。在深度学习法中，TCN－LSTM 模型预测效果最佳，LSTM 模型次之，TCN 模型最差。当预测时长为 1 h 时，LSTM 模型 MSE 和 MAE 较低，接近于 TCN－LSTM 模型；TCN 模型在单独使用时的表现较 TCN－LSTM 模型较差，但仍优于 MLR 和 BP 模型。随着预测时长增加，当预测时长为 2 h 时不同模型预测差距逐步显现。当预测时长为 3 h 时，TCN－LSTM 模型 MSE 和 MAE 均优于其他模型，其在测试集中 MSE 为 0.57℃，MAE 为 0.57℃。上述结果说明，TCN 模型相比于 MLR 模型和 BP 模型预测效果有所提升，可能是因为其结构更适合捕捉时间相关的特征。LSTM 模型能够有效地学习时间序列数据中的长期依赖关系，较 TCN 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 TCN 模型预测精度虽提高，但随预测时长增加其预测精度降低，难以满足生产需求。TCN－LSTM 模型结合 TCN 的特征提取能力和 LSTM 的时序数据长期依赖关系提取能力，在预测时长 3 h 内 R^2 均不小于 0.982、MSE 和 MAE 均不大于 0.57℃，长期预测方面明显优于其余对照模型，其可满足环境调控过程中对预测温度精度和时长方面要求。

3.4　不同地点菇房温度预测模型迁移结果

为验证 TCN－LSTM 模型对于多步长预测下的适用性，当输出时长为 1、2、3 h 时，预测模型在不同地点迁移结果如表 3 所示。

表 3　基于迁移学习的模型预测效果对比

Tab. 3　Comparison of model prediction performance based on transfer learning

预测时长/h	冻结层数	时间/d	训练集			测试集		
			R^2	MSE/℃	MAE/℃	R^2	MSE/℃	MAE/℃
1	2	10	0.989	0.34	0.41	0.986	0.36	0.42
		5	0.980	0.46	0.63	0.978	0.47	0.65
	3	10	0.975	0.90	0.85	0.973	0.92	0.87
		5	0.962	1.19	1.11	0.960	1.21	1.30
2	2	10	0.982	0.44	0.60	0.979	0.46	0.64
		5	0.976	0.87	0.82	0.971	0.88	0.84
	3	10	0.970	0.97	0.91	0.966	0.99	0.94
		5	0.953	2.56	1.64	0.950	2.74	1.77
3	2	10	0.973	0.86	0.84	0.970	0.90	0.86
		5	0.960	1.25	1.10	0.955	1.26	1.27
	3	10	0.953	2.67	1.79	0.950	2.88	1.92
		5	0.918	3.86	1.90	0.912	4.02	2.01

由表 3 可知，当冻结层数为 2 和 3 时所建模型

在各项评价指标中均表现较优,且冻结层数越少所建模型精度越高。当预测时长为 1 h、冻结层数为 2 时,训练集 10 d 的模型较 5 d 的模型在测试集上预测效果更好,且训练集 MSE 为 0.34℃,测试集 MSE 为 0.36℃,两数据集之间的结果相差较小,表明泛化能力较 5 d 模型更好。当预测时长为 1 h 时,冻结层数和时间对模型精度影响不显著,但当预测时长为 2、3 h 时模型精度变化较为显著,这是由于在短时预测时温度在此时间段内变化缓慢,模型可以较为精准预测温度,但随着预测时长增加,样本和网络权重对模型的影响逐渐增加,模型需要挖掘更多的数据和保留精准的网络权重,所以导致后续预测模型精度受限。当预测时长为 2、3 h,网络冻结层数为 2 时模型精度最高、拟合效果最好,且训练集为 10 d 所建立的模型较 5 d 精度更高,表明样本数据越多其模型在测试集表现效果越好;在网络冻结层数变多时,模型随着层数变多精度降低,且样本数据量并不存在明显优势。

4 结论

(1)分析了菇房内设备运行情况对环境变化的影响。结果表明,设备工作状态对菇房内环境变化的影响极显著,在菇房环境建模时,应考虑历史温度数据和设备工作状态对未来温度的变化的影响。

(2)将 TCN 和 LSTM 模型相结合提出基于 TCN - LSTM 的菇房温度预测模型。相比于统计学法和浅层神经网络法对温度预测精度有显著提升。

(3)提出了一种基于 TCN - LSTM 模型的小样本迁移学习温度预测方法。试验结果表明,当预测时长为 1、2、3 h 时,面向不同地点的温度预测模型的 R^2 不小于 0.912,MSE 不大于 4.02℃,MAE 不大于 2.01℃。在小样本条件下,基于 TCN - LSTM 面向不同地点可实现不同步长下温度的连续精准化预测。

参 考 文 献

[1] 李长田,谭琦,边银丙,等. 中国食用菌工厂化的现状与展望[J]. 菌物研究,2019,17(1):1 - 10,2.
LI Changtian, TAN Qi, BIAN Yinbing, et al. The status and prospection of edible mushroom industry in China[J]. Journal of Fungal Research,2019,17(1):1 - 10,2. (in Chinese)

[2] LU H, LOU H, HU J, et al. Macrofungi: a review of cultivation strategies, bioactivity, and application of mushrooms[J]. Comprehensive Reviews in Food Science and Food Safety, 2020, 19(5): 2333 - 2356.

[3] QIU Z, WU X, ZHANG J, et al. High temperature enhances the ability of *Trichoderma asperellum* to infect *Pleurotus ostreatus* mycelia[J]. PLoS One, 2017, 12(10): e0187055.

[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):042001.

[5] 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 CSAE, 2020, 36(3): 190 - 197. (in Chinese)

[6] 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):012036.

[7] 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 networks[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(Supp.): 353 - 358. (in Chinese)

[8] 符杨, 任子旭, 魏书荣, 等. 基于改进 LSTM - TCN 模型的海上风电超短期功率预测[J]. 中国电机工程学报, 2022, 42(12): 4292 - 4303.
FU Yang, REN Zixu, WEI Shurong, et al. Ultra-short-term power prediction of offshore wind power based on improved LSTM - TCN model[J]. Proceedings of the CSEE, 2022, 42(12): 4292 - 4303. (in Chinese)

[9] GUL M J, URFA G M, PAUL A, et al. Mid-term electricity load prediction using CNN and Bi - LSTM[J]. The Journal of Supercomputing, 2021, 77: 10942 - 10958.

[10] 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)

[11] 杨玉强,宋坤,罗焕芝. 基于 IBKA - ACNN - DD 的短期土壤温度预测模型[J]. 农业机械学报, 2025, 56(7): 541 - 548.
YANG Yuqiang, SONG Kun, LUO Huanzhi. Short-term soil temperature prediction model based on IBKA - ACNN - DD[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(7): 541 - 548. (in Chinese)

[12] 杨信廷,郭向阳,韩佳伟,等. 基于 TiDE - PatchTST 模型的柑橘冷藏效率时序预测模型优化[J]. 农业机械学报, 2024, 55(7): 396 - 404.

YANG Xinting, GUO Xiangyang, HAN Jiawei, et al. Optimization of citrus cold storage efficiency time-series prediction model based on TiDE-PatchTST[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(7): 396-404. (in Chinese)

[13] LIU R, YUAN S, HAN L. Evaluation and analysis on the temperature prediction model for bailing mushroom in Jizhou, Tianjin[J]. Agriculture, 2022, 12(12): 2044.

[14] 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. (in Chinese)

[15] 王晓霞, 艾兴成,王涛. 基于实例迁移学习的小样本光伏功率短期预测[J]. 太阳能学报, 2024, 45(6): 325-333.
WANG Xiaoxia, AI Xingcheng, WANG Tao. Few-shot photovoltaic power short-term forecasting based on instance transfer learning[J]. Acta Energiae Solaris Sinica,2024, 45(6): 325-333. (in Chinese)

[16] 王学智, 李清亮,李文辉. 融合迁移学习的土壤湿度预测时空模型[J]. 吉林大学学报(工学版), 2022, 52(3): 675-683.
WANG Xuezhi, LI Qingliang, LI Wenhui. Spatio-temporal model of soil moisture prediction integrated with transfer learning [J]. Journal of Jilin University(Engineering and Technology Edition), 2022, 52(3): 675-683. in Chinese)

[17] ZHANG L, HONG D E, TIAN W Z, et al. A production prediction method of single well in water flooding oilfield based on integrated temporal convolutional network model[J]. Petroleum Exploration and Development, 2022, 49(5): 1150-1160.

[18] CHI D, YANG C. Wind power prediction based on WT-BiGRU-attention-TCN model[J]. Frontiers in Energy Research, 2023, 11: 1156007.

[19] 时培明, 郭轩宇, 杜清灿, 等. 基于 TCN-BiLSTM-Attention-ESN 的光伏功率预测[J]. 太阳能学报, 2024,45(9): 304-316.
SHI Peiming, GUO Xuanyu, DU Qingcan, et al. Photovoltaic power prediction based on TCN-BiLSTM-Attention-ESN [J]. Acta Energiae Solaris Sinica,2024,45(9):304-316. (in Chinese)

[20] HEWAGE P, BEHERA A, TROVATI M, et al. Temporal convolutional neural (TCN) network for an effective weather forecasting using time-series data from the local weather station[J]. Soft Computing, 2020, 24(21): 16453-16482.

[21] FAN D, SUN H, YAO J, et al. Well production forecasting based on ARIMA-LSTM model considering manual operations [J]. Energy, 2021, 220: 119708.

[22] 龚立雄, 钞寅康, 黄霄, 等.基于 CNN-LSTM 电力消耗预测模型及系统开发[J].计算机仿真,2024,41(8):77-83.
GONG Lixiong, CHAO Yinkang, HUANG Xiao, et al. Power consumption forecast model and system development based on CNN-LSTM[J]. Computer Simulation, 2024,41(8):77-83. (in Chinese)

[23] SHERSTINSKY A. Fundamentals of recurrent neural network (RNN) and long short-term memory (LSTM) network[J]. Physica D: Nonlinear Phenomena, 2020, 404: 132306

[24] 庞军恒, 黄炜楠, 董胜. 基于多变量 DSD-LSTM 模型的有效波高预测[J]. 太阳能学报, 2024, 45(7): 121-127.
PANG Junheng, HUANG Weinan, DONG Sheng. Prediction of significant wave height based on multivariable DSD-LSTM model[J]. Acta Energiae Solaris Sinica, 2024, 45(7): 121-127. (in Chinese)

[25] ZHUANG F, QI Z, DUAN K, et al. A comprehensive survey on transfer learning[J]. Proceedings of the IEEE, 2020, 109(1): 43-76.

[26] 邬娜,王健,杨建伟,等.变工况及小样本情况下滚动轴承故障迁移学习方法综述[J].科学技术与工程,2024,24(10):3939-3951.
WU Na, WANG Jian, YANG Jianwei, et al. Review of rolling bearing migration learning under variable operating conditions and small samples[J]. Science Technology and Engineering,2024,24(10):3939-3951. (in Chinese)

[27] RUDER S, PETERS M E, SWAYAMDIPTA S, et al. Transfer learning in natural language processing[C]// Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics, 2019.