

基于 CNN - GRU 的菇房多点温湿度预测方法研究

赵全明¹ 宋子涛^{1,2} 李奇峰³ 郑文刚² 刘 宇⁴ 张钟莉莉³

(1. 河北工业大学电子信息工程学院, 天津 300401; 2. 北京农业智能装备技术研究中心, 北京 100097;

3. 北京农业信息技术研究中心, 北京 100097; 4. 北京市农林科学院植物保护环境保护研究所, 北京 100097)

摘要: 有效获取温室出菇房的温湿度空间分布对于优化食用菌环境胁迫、病害预警、出菇房预调控至关重要,但传统的单点预测不能很好地满足菇房整体环境性能评估的需求。针对出菇房内温湿度时序性、非线性、空间分布差异性的特点,提出一种基于卷积神经网络(CNN)与门控循环单元神经网络(GRU)相结合的菇房多点温湿度预测方法。将温室室外历史气象数据、温室室内历史小气候环境数据、多点环境分布特征、通风信息和加湿信息多特征数据按照时间序列构造二维矩阵作为输入,采用CNN挖掘数据中蕴含的有效信息,提取反映温室环境数据相互联系的高维特征,将提取的特征向量构造为时间序列输入GRU网络进行多点温湿度预测。将该预测方法应用于北京市农林科学院的日光温室出菇房内多点温湿度预测,实验结果表明,该预测方法对于出菇房内各点温度RMSE平均值为0.211℃,MAE平均值为0.140℃,误差控制在±0.5℃范围内的平均比例为97.57%;对于出菇房内各点相对湿度RMSE平均值为2.731%,MAE平均值为1.713%,误差控制在±5%范围内的平均比例为92.62%;相比传统的BP神经网络、长短期记忆神经网络(LSTM)和门控循环单元神经网络(GRU),该预测方法具有更高的预测精度。

关键词: 温室出菇房; 环境分布; 温湿度预测; 卷积神经网络; 门控循环单元神经网络

中图分类号: S625.5⁺1; TP181 **文献标识码:** A **文章编号:** 1000-1298(2020)09-0294-10

OSID:



Multi-point Prediction of Temperature and Humidity of Mushroom Based on CNN - GRU

ZHAO Quanming¹ SONG Zitao^{1,2} LI Qifeng³ ZHENG Wen'gang² LIU Yu⁴ ZHANG Zhonglili³

(1. School of Electronic Information Engineering, Hebei University of Technology, Tianjin 300401, China

2. Beijing Research Center of Intelligent Equipment for Agriculture, Beijing 100097, China

3. Beijing Research Center for Information Technology in Agriculture, Beijing 100097, China

4. Institute of Plant and Environmental Protection, Beijing Academy of Agricultural and Forestry Sciences, Beijing 100097, China)

Abstract: It was vitally important to effectively obtain the spatial distribution of temperature and humidity of the greenhouse mushroom house in advance for optimizing environmental stress of edible fungi, early warning of disease and pre-regulation of the mushroom house. The traditional single-point prediction could not well meet the demand of evaluation of overall environmental performance for the mushroom house. According to the characteristics of time series, non-linear and different spatial distribution of temperature and humidity in mushroom house, a multi-point prediction method of temperature and humidity for the mushroom house based on convolutional neural network (CNN) and gated recurrent unit neural network (GRU) was proposed, which took the historical outdoor meteorological data of the greenhouse, the indoor microclimate environmental data, environmental distribution characteristics, the ventilation information and the humidification information as input by constructing a two-dimensional matrix according to the time series. Firstly, CNN was used to mine the effective information contained in the data to extract the high-dimensional features reflecting the interrelation of greenhouse environmental data, and then the extracted feature vectors were constructed as time series and input to the GRU network for multi-point prediction of temperature and humidity. The prediction model proposed was applied to the

收稿日期: 2020-03-25 修回日期: 2020-05-09

基金项目: 农业农村部岗位科学家项目(CARS-20)、北京市百千万人才工程项目(2018A33)和北京市农林科学院科研创新平台建设项目

作者简介: 赵全明(1968—),男,教授,博士,主要从事智能信息处理研究,E-mail: qmzh@hebut.edu.cn

通信作者: 李奇峰(1981—),男,副研究员,博士,主要从事农业信息化研究,E-mail: liqf@nrcita.org.cn

multi-point prediction of temperature and humidity in the mushroom house of a solar greenhouse in Beijing Academy of Agricultural and Forestry Sciences, and the experimental results showed that the averaged RMSE and MAE were 0.211℃ and 0.140℃, respectively, for the temperature prediction at each point in the mushroom house, and the average proportion of error control within $\pm 0.5^{\circ}\text{C}$ was 97.57%. For the humidity prediction at each point in the mushroom house, the averaged RMSE and MAE were 2.731% and 1.713%, respectively, and the average proportion of error control within $\pm 5\%$ was 92.62%. Comparing with traditional BP neural network, long short-term memory neural network (LSTM), and gated recurrent unit neural network (GRU), the prediction model proposed had higher prediction accuracy.

Key words: greenhouse mushroom house; environmental distribution; temperature and humidity prediction; convolutional neural network; gated recurrent unit neural network

0 引言

目前,我国食用菌的栽培设施类型主要以大棚和温室为主^[1],调控方式大多依靠农业生产者的经验,通过对当前采集的环境数据进行分析,进而做出调控决策,其数据采集的反馈与调控措施的生效都存在滞后性^[2]。建立以出菇房主要环境因子为输出变量的高精度预测模型可提前掌握主要环境因子在未来一段时间的环境分布趋势,是进行高效、精准环境预测和出菇房预调控的重要前提。

温室出菇房内影响食用菌生长发育的小气候环境因素是相互作用、相互耦合的动态时间变量,且空间分布具有差异性和不均匀性,同时,对其有着重要影响的设施结构、材料、装备等因素不易测量,所以很难通过机理模型对其整体的环境分布进行精准描述^[3-4]。目前,针对温室小气候环境因素时序性、非线性特点采用的预测方法可分为统计学和机器学习的方法,但鲜有研究考虑其环境空间分布差异特性。统计学方法主要有时序分析法^[5]、回归预测法^[6]和自回归积分滑动平均法^[7]等,这些方法能够很好地处理稳定的平稳时间序列数据,但是温室小气候环境因素由于受外界气候变化、温室内部食用菌生理作用及调控措施等多方面因素影响而具有非平稳性、高波动性^[8],所以其预测能力受到很大限制。机器学习方法包括支持向量机^[9](SVM)和人工神经网络^[10-12](ANN)等,其能够很好地处理非线性、非平稳的时间序列数据。SVM 较适合处理小样本数据,而温室小气候环境的空间分布包含着大量多点多维稀疏混合特征,使其难以实施;ANN 由于具有很强的自适应学习能力而被广泛应用到了预测领域^[13],能解决数据的非线性问题,但是其收敛速度慢、泛化能力差,处理数据维度有限,很难精准地挖掘温室小气候环境空间分布、时间序列的相关性。

近年来深度学习因可以实现任意函数的高维逼

近、并具有更强大的特征学习能力而逐渐成为研究热点^[14-17]。深度学习可以精准预测温室出菇房的环境空间分布情况,但是目前鲜见将深度学习与温室出菇房环境分布预测相结合的研究。卷积神经网络(CNN)作为在图像处理、计算机视觉等领域被广泛应用的模型^[18],其特殊的网络结构通过共享权重的特性可以很好地处理高维稀疏特征^[19],对非时序特征的空间结构关系进行有效建模。将时序概念引入网络结构的门控循环单元神经网络(GRU)和长短期神经网络(LSTM)作为循环神经网络(RNN)的特殊变种,被广泛地应用到了各个领域^[20-25],并取得了不错的效果。不仅很好地解决了 RNN 的梯度消失和梯度爆炸的问题,而且能够充分挖掘时间序列数据的时序性、非线性的关系。但是难以较好地表达非时序性特征的空间结构,影响了预测的精度。

为了精准预测出菇房内多点温湿度的空间分布情况,本文提出一种基于 CNN-GRU 的菇房多点温湿度预测模型。通过传感器网络采集出菇房不同区域的环境数据,将室外历史气象数据、室内小气候历史数据、环境分布特征、加湿特征及通风特征按照时间序列构造二维矩阵作为输入,采用 CNN 挖掘数据中蕴含反映温室环境数据相互联系的高维有效特征,将提取的特征向量构造为时间序列,输入到 GRU 网络进行多点温湿度预测。

1 CNN-GRU 环境预测模型

1.1 卷积神经网络

卷积神经网络主要包括卷积层、池化层和全连接层,采用局部连接和权值共享的方式。卷积层对原始数据中更高层次、更抽象的特征进行提取,充分挖掘数据的内部联系,池化层又称为下采样层,可以有效降低网络的复杂度,减少训练参数的数目^[26],对特征进行降维。CNN 网络结构如图 1 所示。

1.2 门控循环单元神经网络

为了克服 RNN 的长期依赖问题^[27],




图 1 CNN 网络结构

Fig. 1 Structure of CNN network

HOCHREITER 等^[28]在 1997 年提出了长短期记忆神经网络 (LSTM), 通过将隐藏层的神经元替换成具有 3 个门结构的特殊细胞状态控制信息, 从而解决了梯度消失、梯度爆炸等问题, 实现了信息的记忆和更新。

由于 LSTM 的内部结构非常复杂会导致训练的时间过长, CHO 等^[29]在 LSTM 的基础上提出新变体门控循环单元神经网络 (GRU), 它具有更加简洁的模型结构, 在保证预测精度的同时减少了网络训练的参数, 收敛速度更快。GRU 相对于 LSTM 的内部结构最大的改进在于将 LSTM 中的 3 个门结构简化为更新门和重置门 2 个门结构, 具有更高的计算效率。更新门主要决定被添加到当前状态信息中的历史信息量, 传递的历史信息越多其值越大。重置门主要决定历史信息被遗忘的程度, 被忘记的历史信息越多其值越小^[30]。GRU 内部结构单元如图 2 所示。

门控循环单元神经网络计算公式为

$$\begin{cases} r_t = \sigma(W_r[h_{t-1}, x_t]) \\ z_t = \sigma(W_z[h_{t-1}, x_t]) \\ \tilde{h}_t = \tanh(W_h[r_t h_{t-1}, x_t]) \\ h_t = (1 - z_t)h_{t-1} + z_t \tilde{h}_t \end{cases} \quad (1)$$




图 2 GRU 网络结构

Fig. 2 Structure of GRU network

- 式中
- x_t ——输入

r_t ——重置门

z_t ——更新门

W_r ——重置门权重矩阵

W_z ——更新门权重矩阵

W_h ——候选隐藏状态权重矩阵

h_t ——隐藏层输出

$\tilde{h}_t$ ——候选隐藏状态

$\sigma(\cdot)$ ——sigmoid 激活函数

$\tanh(\cdot)$ ——双曲正切激活函数

1.3 CNN-GRU 网络混合模型

影响出菇房内各点温湿度的因素包括室外空气温度、室外空气相对湿度、室外风速、室内基质温度、室内光照强度等相互独立的时间序列特征以及环境分布特征、通风特征、加湿特征等非时序性特征。为了耦合这些影响温室出菇房内温湿度的特征信息, 充分挖掘这些特征的内部潜在联系及空间规律, 对温室出菇房的温湿度空间分布情况进行精准预测, 本文将卷积神经网络 (CNN) 与门控循环单元神经网络 (GRU) 相结合, 构建了基于 CNN-GRU 的菇房多点温湿度预测模型, 网络结构如图 3 所示。

(1) 输入层。将出菇房内某一时刻的温湿度与




图 3 CNN-GRU 网络混合模型

Fig. 3 Hybrid model of CNN-GRU network

其相关的室外空气温度、室外空气相对湿度、室外风速、室内基质温度、室内光照强度、环境分布特征、通风特征和加湿特征串联成全新的时间序列特征向量,将出菇房室外的历史气象数据、室内的历史小气候数据表达为时间步长 $\times$ 特征向量的二维矩阵,对其预处理后输入预测模型中。

(2) CNN 层。CNN 层主要捕捉输入的历史序列中深层次的时间、空间特征规律,根据输入数据非线性、稀疏性、强耦合性的特点,设计 4 层卷积层 (Conv2D),卷积核数目依次为 16、16、32、32,并选取 ReLU 激活函数进行激活。每经过 2 次连续卷积进行一次最大池化 (MaxPooling2D),对提取的高维特征进行降维,压缩数据,加快运行效率。为了充分利用现有的出菇房室外气象数据、室内环境分布数据、非时序多特征数据,将卷积核尺寸设为 3×3 ,池大小为 2,最后通过 Flatten 操作,将其提取的深层次抽象特征转换为全局特征向量作为 GRU 层的输入。

(3) GRU 层。GRU 层对 CNN 层提取的全局特征向量进行学习,经过不断改进可得,构建 2 层 GRU 结构达到了最好的预测效果,激活函数采用 ReLU 激活函数,神经元数目分别为 64、128,最后将全连接层 (Dense) 的输出经过反归一化得 20 min 后

的温湿度。

2 实验

2.1 实验数据获取

实验地点为北京市农林科学院日光温室出菇房,共 4 间,每间面积约 90 m^2 ,总高度约 6 m,室内装有加湿喷雾设备。实验期间相邻 2 间出菇房内栽植不同基质的平菇,出菇方式为袋装,采用的码堆栽培方式有普通式、架杆式、花式 3 种,每种码堆方式堆 3 ~ 4 层菌袋,行与行之间的走道间距为 0.5 m 左右,适宜的温度为 $5 \sim 30^\circ\text{C}$,适宜的空气相对湿度为 85% ~ 90%。为符合平菇的种植要求,防止病害发生,出菇房内需常开窗进行换气通风,如遇持续恶劣天气时需人工进行关闭,出菇房内的加湿喷雾设备的阈值设定为 90%,当相对湿度高于 90% 时,加湿喷雾设备自动关闭。有时会在临近傍晚时分将加湿器关闭以减少电力消耗,同时关闭窗户盖下保温被保持室内温湿度,在第 2 天清晨或中午时卷起保温被并同时开窗通风。如果白天开窗通风换气或天气恶劣,相对湿度可能达不到所需的需求,需根据实际情况进行人工喷湿。实验场地示意图如图 4 所示。




图 4 温室出菇房内部环境与监测设备布局

Fig. 4 Internal environment of greenhouse mushroom house and layout of monitoring equipment

1. 1 号采集器 2. 2 号采集器 3. 3 号采集器 4. 4 号采集器 5. 5 号采集器 6. 6 号采集器

本文所需的温室出菇房室外空气温度、空气相对湿度、风速等气象数据通过温室北侧约 20 m 的 HOBO 气象站自动采集记录,采样间隔为 5 min,时间为 2019 年 11 月 18 日至 2020 年 1 月 6 日。温室出菇房室内采用国家农业智能装备工程技术研究中心研发的温室云环境 EP400 型数据采集器进行环境监测,每个数据采集器可对空气温度 (量程: $-40 \sim 80^\circ\text{C}$,精度: $\pm 0.5^\circ\text{C}$)、空气相对湿度 (量程: $0 \sim 100\%$,精度: $\pm 3\%$)、土壤温度 (量程: $-40 \sim 80^\circ\text{C}$,精度: $\pm 0.5^\circ\text{C}$)、光照强度 (量程: $0 \sim 100\text{ klx}$,精度: $\pm 10\text{ klx}$) 进行测量。本实验共选取 6 个数据采

集点,如图 4 所示。在相邻两间温室出菇房内各架设 3 个仪器进行数据采集,其都呈三角式分布。温室出菇房 1 中的 5 号采集器正对窗户,1 号采集器斜靠窗,6 号采集器位于加湿器另一侧 (靠室内)。温室出菇房 2 的 3 号采集器放置在加湿器正下方,2 号采集器与 4 号采集器均匀分布在加湿器两侧,其中 2 号采集器靠窗户,4 号传感器靠室内。数据采集器安装在三脚架上,距地面高度约为 1.1 m,仪器于 2019 年 11 月 18 日至 2020 年 1 月 6 日每 20 min 利用 GPRS 网络模块将数据发送至服务器进行存储,减少了硬件的传输损耗,使得传感器保持稳

定、高效的数据传输,从而保证对出菇房环境的有效监测,同时又可以满足模型对大量数据的需求。

2.2 实验数据预处理

2.2.1 异常数据处理

温室出菇房内的相对湿度较大,长时间放置于出菇房内进行监测的传感器的精度会受到一定的影响。同时由于白天的通风换气、外界气候变化使得出菇房的相对湿度达不到所需的要求,因此会根据实际情况进行人工喷湿,存在着人为干扰,加上网络传输的质量、设备故障等问题,使得传感器在进行数据采集的过程中出现数据异常、数据缺失等情况。这些因素都会对预测模型的精度造成一定的影响,因此针对短时数据的缺失采用线性插值法进行插补,即

$$x_{a+i}=x_a+\frac{i(x_{a+j}-x_a)}{j} \quad (0<i<j) \quad (2)$$

式中 x_{a+i} —— $a+i$ 时刻缺失数据

x_a,x_{a+j} —— $a,a+j$ 时刻原始数据

若数据连续缺失较多或其缺失时间跨度较大,则将天气状况相同或者相临近几天中同一时刻的数据对其进行填补。对于数据异常处理则采用均值法对数据进行平滑修复,即

$$x_k=\frac{x_{k-1}+x_{k+1}}{2} \quad (3)$$

式中 x_k ——异常数据

x_{k-1},x_{k+1} ——相邻的有效数据

2.2.2 归一化处理

为了消除出菇房室内外环境参数量纲的差异对预测的精度造成不良影响,本文对各影响因子和目标变量进行归一化处理。计算公式为

$$x^*=\frac{x-x_{\min}}{x_{\max}-x_{\min}} \quad (4)$$

式中 $x_{\max}$ ——最大值 $x_{\min}$ ——最小值

x^* ——归一化值

2.3 模型评价指标

为了评估模型的预测效果与精度,选用平均绝对误差(MAE)、均方根误差(RMSE)、平均绝对百分比误差(MAPE)3个指标对其进行评价^[31],MAE、RMSE、MAPE越小,表明模型的预测结果更加精准。

MAE、RMSE、MAPE的计算公式为

$$MAE=\frac{1}{N}\sum_{i=1}^N|y_i-\bar{y}_i| \quad (5)$$

$$RMSE=\sqrt{\frac{1}{N}\sum_{i=1}^N(y_i-\bar{y}_i)^2} \quad (6)$$

$$MAPE=\frac{1}{N}\sum_{i=1}^N\frac{|y_i-\bar{y}_i|}{y_i}\times 100\% \quad (7)$$

式中 N ——预测结果总个数

y_i ——第*i*个采样点实际温湿度

$\bar{y}_i$ ——第*i*个采样点预测温湿度

为了比较各模型方法的预测效率,本文选取训练时间作为其评价标准,在模型训练的损失函数值趋于稳定时将其记录,训练时间越短其效率越高,损失函数采用均方误差。

3 实验结果与分析

3.1 数据采集与实验平台

选取了相邻两间温室出菇房内的6个数据采集点进行数据采集,从2019年11月18日至2020年1月6日每个数据采集点均采集了3600条数据,共21600条数据,将其和室外气象数据、非时序多特征数据相融合后用于模型训练和测试,其中将每个数据点从2019年11月18日至2020年1月1日采集的共19440条数据用于训练,2020年1月2日至2020年1月6日的共2160条数据用于测试,数据的采样间隔均为20min,24h连续采集。将下载好的数据采用One-hot编码对环境分布特征、通风特征、加湿特征进行特征编码。例如数据点1的特征编码为6列矩阵,第1位为1,其余为0。对于开窗通风和加湿器的特征编码为开启置1,否则为0。最后将处理好的Excel格式数据转换为csv格式,方便程序对环境数据进行读取和保存。

实验所使用的计算机硬件配置如下:处理器为Intel(R)Core(TM)i5-8250U,内存8GB,操作系统为64位Windows10系统,GPU显卡NVIDIA GeForce MX150 2G。软件框架结构为Keras深度学习工具,以Tensorflow深度学习框架(版本为GPU2.0)作为后端支持,编程语言为Python(版本为3.7),集成开发环境(IDE)为Pycharm。

3.2 模型训练

采用CNN-GRU神经网络构建温室出菇房多点温湿度预测模型,作为评价出菇房的整体环境状态。对于时间步长的选取,若时间步长过长则会造成数据冗余,影响模型的收敛速度,若时间步长过短,则不能对模型的输出进行完全充分的表达,影响其预测精度,设置时间步长为9。利用Adam优化算法不断地调整模型参数,使模型的性能达到最优。为了避免模型陷入局部最小值,经过多次实验,初始学习率设置为0.001,每迭代100次学习率调整为原来的10%,迭代200次后损失值趋于稳定值,效果达到最优。

图 5 为 CNN - GRU 模型对 2020 年 1 月 2 日至 2020 年 1 月 6 日各点温湿度预测值与真实值的平均相关性程度分析。在开窗通风、加湿器关闭的瞬间,以及室外气象短暂突变时,室内的温湿度会发生较大的波动,对预测精度造成一定的影响。由图 5 可以看出,温室出菇房内各点的温度、相对湿度的真

实值与预测值整体在直线 $y = x$ 附近呈均匀分布状态,决定系数 R^2 分别平均达到了 0.983 9、0.970 7,表明预测值与真实值之间存在强相关性,说明模型对温室出菇房内的各点温湿度有较好的拟合程度,总体上能较好地应对突变情况,达到了理想的预测精度。




图 5 CNN - GRU 模型对各点温湿度预测值与真实值的相关性分析

Fig. 5 Correlation analysis between predicted and actual values of temperature and humidity at each point of CNN - GRU model

表 1 为异常数据修复前后 CNN - GRU 模型对 2020 年 1 月 2 日至 2020 年 1 月 6 日各点温湿度预测效果对比分析。数据的缺失会导致模型在训练过程中损失值出现 NaN 值现象而无法进行,因此在训练模型之前需通过预处理对缺失数据进行填补。由表 1 可以看出,在异常数据修复后 CNN - GRU 模型对各点温度、相对湿度预测的 MAPE 较异常数据修复前分别降低了 4.56%、7.46%,原因为异常数据作为训练样本所提取的样本特征不够完整、准确,对模型的预测效果有着直接的影响,表明了采用均值法对异常数据修复的有效性。

4.11%。对于出菇房内各点湿度预测的平均 RMSE 和 MAE,CNN - GRU 分别达到了 2.731%、1.713%,较 BP 模型分别下降了 15.66%、16.48%;较 LSTM 模型分别下降了 11.65%、8.93%;较 GRU 模型分别下降了 10.75%、7.51%。由此可以得出,CNN - GRU 模型预测的效果更加理想,泛化性能更好,与实际的温室出菇房内各点温湿度较为接近,能够更好地评估温室出菇房整体的环境分布状态。

图 6 为 BP 模型、LSTM 模型、GRU 模型和 CNN - GRU 模型的误差对比,其中实线为零基准线,虚线为误差区间。由图 6 可见,基于 CNN - GRU 模型的多点温湿度预测值误差最小,拟合性能最优,BP 模型的误差较大,偏离实际的温湿度最大,GRU 模型对于整体的预测性能稍优于 LSTM 模型。由表 2 可得出,对于温室出菇房内各点温度的预测,BP 模型、LSTM 模型、GRU 模型和 CNN - GRU 模型的预测误差控制在 $\pm 0.5^{\circ}\text{C}$ 范围内的各点平均比例分别为 91.38%、94.67%、95.43%、97.57%,CNN - GRU 模型相比其他 3 种模型分别提高了 6.19%、2.90%、2.14 个百分点。对于温室出菇房内各点相对湿度的预测,BP 模型、LSTM 模型、GRU 模型和 CNN - GRU 模型的预测误差控制在 $\pm 5\%$ 范围内的各点平均比例分别为 90.86%、91.52%、91.72%、92.62%,CNN - GRU 模型相比其他 3 种模型分别提高了 1.76%、1.10%、0.90 个百分点,可以看出与其他 3 种模型相比,CNN - GRU 模型对于整体的预测效果最优,误差的波动性较小,能够更准确预测温室出菇房内未来 20 min 的多点温湿度的空间分布趋

表 1 异常数据修复对 MAPE 的影响分析		
Tab.1 Analysis of influence of abnormal data repair on MAPE		
	%	
	repair on MAPE	
异常数据	温度	相对湿度
修复前	1.317	2.706
修复后	1.257	2.504

3.3 模型预测效果对比

为了验证所提出的预测模型的科学性和稳定性,本文将 BP 模型、LSTM 模型和 GRU 模型进行实验对比分析,模型定量分析评价结果如表 2 所示。由表 2 可以看出,相比较其他 3 种预测模型,CNN - GRU 模型可以更好地处理多点多维稀疏特征数据,其预测精度最高,效果最优。对于出菇房内各点温度预测的平均 RMSE 和 MAE,CNN - GRU 模型分别达到了 0.211、0.140 $^{\circ}\text{C}$,较 BP 模型分别下降了 31.49%、33.33%;较 LSTM 模型分别下降了 9.83%、5.41%;较 GRU 模型分别下降了 6.64%、

表 2 1 月 2—6 日各模型预测精度评价分析

Tab.2 Analysis of prediction accuracy of each model from January 2th to 6th

区域	模型	温度			相对湿度		
		RMSE/℃	MAE/℃	误差区间比例/% (±0.5℃)	RMSE/%	MAE/%	误差区间比例/% (±5%)
1	BP	0.271	0.192	92.57	3.098	1.961	92.29
	LSTM	0.219	0.149	95.71	2.933	1.786	92.29
	GRU	0.192	0.134	96.29	2.897	1.789	92.00
	CNN-GRU	0.183	0.127	98.86	2.283	1.580	94.86
2	BP	0.319	0.204	92.57	3.015	1.907	93.14
	LSTM	0.263	0.165	93.43	2.788	1.675	91.43
	GRU	0.248	0.158	94.29	2.755	1.650	92.86
	CNN-GRU	0.243	0.159	96.57	2.432	1.475	94.57
3	BP	0.336	0.222	91.43	3.247	2.035	90.29
	LSTM	0.252	0.149	94.57	3.114	1.884	91.71
	GRU	0.250	0.146	95.14	3.091	1.773	91.43
	CNN-GRU	0.224	0.138	97.71	2.795	1.656	91.71
4	BP	0.290	0.197	92.29	3.065	1.992	91.14
	LSTM	0.238	0.148	94.29	2.919	1.816	92.57
	GRU	0.238	0.139	95.43	2.876	1.736	92.57
	CNN-GRU	0.204	0.132	98.00	2.715	1.603	92.86
5	BP	0.285	0.207	92.00	3.703	2.335	88.57
	LSTM	0.196	0.129	95.43	3.729	2.260	89.14
	GRU	0.188	0.134	96.57	3.687	2.281	89.14
	CNN-GRU	0.184	0.139	98.29	3.365	2.131	89.43
6	BP	0.344	0.239	87.43	3.297	2.074	89.71
	LSTM	0.234	0.148	94.57	3.064	1.869	92.00
	GRU	0.237	0.166	94.86	3.054	1.883	92.29
	CNN-GRU	0.226	0.144	96.00	2.794	1.835	92.29
平均	BP	0.308	0.210	91.38	3.238	2.051	90.86
	LSTM	0.234	0.148	94.67	3.091	1.881	91.52
	GRU	0.226	0.146	95.43	3.060	1.852	91.72
	CNN-GRU	0.211	0.140	97.57	2.731	1.713	92.62

表 3 各模型的预测效率比较

Tab.3 Comparison of prediction efficiency of each model

模型	训练时间/s	损失值
BP	140.64	0.002 2
LSTM	377.77	0.002 0
GRU	360.38	0.002 0
CNN-GRU	263.37	0.001 8

势,可以为温室出菇房的整体环境调控提供决策依据。

表 3 为各模型的预测效率比较。由表 3 可知,CNN-GRU 模型的耗时比结构较简单的 BP 模型长,但模型损失值与其相比降低了 18.18%,预测精度更好。由于 CNN 局部连接和权值共享的特性,在捕捉高层次特征的同时可由池化层特征降维,减少参数,CNN-GRU 模型相比 LSTM 模型和 GRU 模型

的训练时间明显缩短,并且模型的损失值更低,预测效果更好,损失值较 LSTM 模型和 GRU 模型均降低了 10%。结果表明,CNN-GRU 对于复杂多变的出菇房小气候环境数据有着很好的适应能力,同时模型的运行效率也得到了提升。

4 结论

(1)将食用菌温室出菇房室外的气象数据及室内的海量环境数据构造时间步长×特征向量的二维矩阵作为输入,考虑影响食用菌温室出菇房内温湿度的多特征数据特点,通过 CNN 模型的特殊结构,捕捉环境数据的时间、空间分布的内在规律,挖掘了深层次的有效信息。

(2)GRU 模型能更好地学习 CNN 提取的高维时间序列特征,针对其时序性、非线性、高波动性、强耦合性的特点进行有效的动态时间序列数据




图 6 1 月 2—6 日菇房各区域温湿度预测结果误差

Fig. 6 Errors of temperature and humidity prediction results in various areas of mushroom house from January 2th to 6th

建模。

(3)CNN-GRU 网络混合模型充分利用了 CNN 模型和 GRU 模型的优势,实验结果表明,与 BP 模型、LSTM 模型、GRU 模型相比,本文方法在提高预测精度的同时还兼顾了运行效率,提升了整个模型的预测性能。

参 考 文 献

[1] 李天来. 外行视角看我国设施食用菌发展[J]. 食药用品,2019,27(4):225-230.

[2] 任守纲,杨薇,王浩云,等. 基于 CFD 的温室气温时空变化预测模型及通风调控措施[J]. 农业工程学报,2015,31(13):207-214.

REN Shougang, YANG Wei, WANG Haoyun, et al. Prediction model on temporal and spatial variation of air temperature in greenhouse and ventilation control measures based on CFD [J]. Transactions of the CSAE, 2015, 31(13): 207-214. (in Chinese)

[3] 邵成. 智能温室控制算法的研究与应用[D]. 南京:南京邮电大学, 2013:1-15.

TAI Cheng. The research and applications on the intelligent control algorithm for the greenhouse[D]. Nanjing: Nanjing University of Posts and Telecommunications, 2013:1-15. (in Chinese)

[4] 徐立鸿,苏远平,梁毓明. 面向控制的温室系统小气候环境模拟要求与现状[J]. 农业工程学报,2013,29(19):1-15.

XU Lihong, SU Yuanping, LIANG Yuming. Requirement and current situation of control-oriented microclimate environmental model in greenhouse system [J]. Transactions of the CSAE, 2013, 29(19):1-15. (in Chinese)

[5] 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,2010,41(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, 2010, 41(11):173-177,182. (in Chinese)

[6] 张良,管泽锋,洪亚杰,等. 2 种屋顶全开窗型温室温度预测模型比较[J]. 江苏农业科学,2017,45(15):182-185.

ZHANG Liang, GUAN Zefeng, HONG Yajie, et al. Comparison of temperature prediction models of two kinds of roof window full open type greenhouse [J]. Jiangsu Agricultural Science, 2017, 45(15):182-185. (in Chinese)

[7] 曹雯. 秋冬季南方单栋塑料温室小气候分析与温湿环境模拟研究[D]. 南京:南京信息工程大学,2012.

CAO Wen. Analysis and simulation of microclimate of single-span plastic greenhouse for South China in autumn and winter[D]. Nanjing: Nanjing University of Information Science & Technology, 2012. (in Chinese)

[8] 邹伟东,张百海,姚分喜,等. 基于改进型极限学习机的日光温室温湿度预测与验证[J]. 农业工程学报,2015,31(24):194-200.

ZOU Weidong, ZHANG Baihai, YAO Fenxi, et al. Verification and forecasting of temperature and humidity in solar greenhouse based on improved extreme learning machine algorithm [J]. Transactions of the CSAE, 2015, 31(24):194-200. (in Chinese)

[9] 王定成. 温室环境的支持向量机回归建模[J]. 农业机械学报,2004,35(5):106-109.

WANG Dingcheng. SVM regression modeling for greenhouse environment[J]. Transactions of the Chinese Society for Agricultural Machinery, 2004, 35(5):106-109. (in Chinese)

[10] 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/OL]. 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/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(Supp.): 353-358. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=2017s054&journal_id=jcsam. DOI: 10.6041/j.issn.1000-1298.2017.S0.054. (in Chinese)

[11] AI Tao, YU Junqi, LIU Yanfeng, et al. Study on neural network self-tuning PID control for temperature of active solar house heating system[C] // International Workshop on Intelligent Systems and Applications. IEEE, 2010:1-4.

[12] ZHAO H, SHI L R, WANG H J. Sunlight greenhouse temperature prediction model based on Bayesian regularization BP neural network[J]. Applied Mechanics & Materials, 2015, 740:871-874.

[13] 郁莹珺,徐达宇,寿国忠,等. 基于经验模态分解和小波神经网络的温室温湿度预测[J]. 江苏农业科学,2019,47(1):211-216.

YU Yingjun, XU Dayu, SHOU Guozhong, et al. Prediction of temperature and humidity in greenhouse based on empirical mode decomposition and wavelet neural network [J]. Jiangsu Agricultural Sciences, 2019, 47(1):211-216. (in Chinese)

[14] 陈英义,程倩倩,方晓敏,等. 主成分分析和长短时记忆神经网络预测水产养殖水体溶解氧[J]. 农业工程学报,2018,34(17):183-191.

CHEN Yingyi, CHENG Qianqian, FANG Xiaomin, et al. Principal component analysis and long short-term memory neural network for predicting dissolved oxygen in water for aquaculture [J]. Transactions of the CSAE, 2018, 34(17):183-191. (in Chinese)

[15] 杨亮,刘春红,郭昱辰,等. 基于 EMD-LSTM 的猪舍氨气浓度预测研究[J/OL]. 农业机械学报,2019,50(增刊):353-360.

YANG Liang, LIU Chunhong, GUO Yuchen, et al. Prediction of ammonia concentration in fattening piggyery based on EMD-LSTM [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(Supp.):353-360. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx?flag=1&file_no=2019s054&journal_id=jcsam

- csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 2019s054&journal_id = jcsam. DOI:10.6041/j.issn.1000-1298.2019.S0.054. (in Chinese)
- [16] ZHAO Z, CHEN W, WU X, et al. LSTM network: a deep learning approach for short-term traffic forecast[J]. IET Intelligent Transport Systems, 2017, 11(2): 68-75.
- [17] 余永维,杜柳青,易小波,等.基于时序深度学习的数控机床运动精度预测方法[J/OL].农业机械学报,2019,50(1):421-426. YU Yongwei, DU Liuqing, YI Xiaobo, et al. Prediction method of NC machine tool's motion precision based on sequential deep learning [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(1): 421-426. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 20190149&journal_id = jcsam. DOI:10.6041/j.issn.1000-1298.2019.01.049. (in Chinese)
- [18] 郑远攀,李广阳,李晔.深度学习在图像识别中的应用研究综述[J].计算机工程与应用,2019,55(12):20-36. ZHENG Yuanpan, LI Guangyang, LI Ye. Survey of application of deep learning in image recognition [J]. Computer Engineering and Applications, 2019, 55(12): 20-36. (in Chinese)
- [19] 林年添,张栋,张凯,等.地震油气储层的小样本卷积神经网络学习与预测[J].地球物理学报,2018,61(10):4110-4125. LIN Niantian, ZHANG Dong, ZHANG Kai, et al. Predicting distribution of hydrocarbon reservoirs with seismic data based on learning of the small-sample convolution neural network [J]. Chinese Journal of Geophysics, 2018, 61(10): 4110-4125. (in Chinese)
- [20] FU Rui, ZHANG Zuo, LI Li. Using LSTM and GRU neural network methods for traffic flow prediction [C] // 2016 31st Youth Academic Annual Conference of Chinese Association of Automation (YAC), Wuhan, 2016: 324-328.
- [21] 王鑫,吴际,刘超,等.基于LSTM循环神经网络的故障时间序列预测[J].北京航空航天大学学报,2018,44(4):772-774. WANG Xin, WU Ji, LIU Chao, et al. Exploring LSTM based recurrent neural network for failure time series prediction [J]. Journal of Beijing University of Aeronautics and Astronautics, 2018, 44(4): 772-774. (in Chinese)
- [22] KIM N, KIM M, CHIO J K. LSTM based short-term electricity consumption forecast with daily load profile sequences [C] // 2018 IEEE 7th Global Conference on Consumer Electronics (GCCE), Nara, 2018: 136-137.
- [23] 张宇帆,艾芊,林琳,等.基于深度长短时记忆网络的区域级超短期负荷预测方法[J].电网技术,2019,43(6):1884-1892. ZHANG Yufan, AI Qian, LIN Lin, et al. A very short-term load forecasting method based on deep LSTM RNN at zone level [J]. Power System Technology, 2019, 43(6): 1884-1892. (in Chinese)
- [24] WANG B, KONG W, GUAN H, et al. Air quality forecasting based on gated recurrent long short term memory model in internet of things [C] // IEEE Access, 2019: 69524-69534.
- [25] 王增平,赵兵,纪维佳,等.基于GRU-NN模型的短期负荷预测方法[J].电力系统自动化,2019,43(5):53-62. WANG Zengping, ZHAO Bing, JI Weijia, et al. Short-term load forecasting method based on GRU-NN model [J]. Automation of Electric Power Systems, 2019, 43(5): 53-62. (in Chinese)
- [26] 周飞燕,金林鹏,董军.卷积神经网络研究综述[J].计算机学报,2017,40(6):1229-1251. ZHOU Feiyan, JIN Linpeng, DONG Jun. Review of convolutional neural network [J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251. (in Chinese)
- [27] BENGIO Y, SIMARD P, FRASCONI P. Learning long-term dependencies with gradient descent is difficult [J]. IEEE Transactions on Neural Networks, 1994, 5(2): 157-166.
- [28] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural Computation, 1997, 9(8): 1735-1780.
- [29] CHO K, MERRIENBOER B V, BAHDANAU D, et al. On the properties of neural machine translation: encoder-decoder approaches [EB/OL]. [2018-06-05]. <https://arxiv.org/pdf/1409.1259.pdf>.
- [30] WANG Y, LIAO W, CHANG Y. Gated recurrent unit network-based short-term photovoltaic forecasting [J]. Energies, 2018, 11(8): 1-14.
- [31] 吴静,李振波,朱玲.融合ARIMA模型和GAWNN的溶解氧含量预测方法[J/OL].农业机械学报,2017,48(增刊):205-210. WU Jing, LI Zhenbo, ZHU Ling. Hybrid model of ARIMA model and GAWNN for dissolved oxygen content prediction [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(Supp.): 205-210. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? flag = 1&file_no = 2017s033&journal_id = jcsam. DOI:10.6041/j.issn.1000-1298.2017.S0.033. (in Chinese)