

DOI:10.19651/j.cnki.emt.2212017

基于多模态数据驱动的黄瓜温室湿度预测方法^{*}

黄天艺^{1,2} 吴华瑞^{2,3,4} 朱华吉^{2,3,4}

(1. 广西大学计算机与电子信息学院 南宁 530004; 2. 国家农业信息化工程技术研究中心 北京 100097;

3. 北京市农林科学院信息技术研究中心 北京 100097; 4. 农业农村部数字乡村技术重点实验室 北京 100097)

摘要: 温室湿度精准预测对病害防治策略制定、水肥自动灌溉等具有重要意义。本文研究了一种基于多模态数据驱动的预测方法。为解耦温室环境控制中环境变量复杂关系,提高模型预测效率,利用LASSO回归从多温室环境参数中筛选得到温室空气湿度变化强关联环境因子,结合CNN提取图像空间特征的优势,基于GAF理论将温室时间序列分别转化为GASF与GADF二维图像,进一步增强有效信息,抑制环境噪声,通过引入低复杂度的双卷积层充分提取图像潜在特征,识别湿度变化趋势,对不同湿度变化趋势的时间序列逐一构建Bayesian_LSTM预测模型,增加平稳输入提高预测精度。针对黄瓜温室,将室内温度、湿度、光照强度历史时间序列转化为二维图像作为输入,分析验证了模型的预测性能。试验数据显示当时间滑动窗口大小为15,选用GADF转化图像,Bayesian_LSTM隐藏节点数为100时,平均绝对误差、平均绝对百分比误差、均方根误差分别达到2.58%、4.56%、4.80%,为模型性能最优。对比RNN、GRU、Bi-GRU、1D-CNN共4种主流预测模型,试验结果均表现出良好的预测性能。

关键词: 环境预测;格拉姆角场;卷积神经网络;长短期记忆神经网络;贝叶斯神经网络

中图分类号: TP183 文献标识码: A 国家标准学科分类代码: 510.40

Research on humidity prediction method of cucumber greenhouse based on multi-mode data driving

Huang Tianyi^{1,2} Wu Huarui^{2,3,4} Zhu Huaji^{2,3,4}

(1. College of Computer and Electronic Information, Guangxi University, Nanning 530004, China;

2. National Engineering Research Center for Information Technology in Agriculture, Beijing 100097, China;

3. Information Technology Research Center, Beijing Academy of Agriculture and Forestry Sciences, Beijing 100097, China;

4. Key Laboratory of Digital Village Technology, Ministry of Agriculture and Rural Affairs, Beijing 100097, China)

Abstract: The accurate prediction of greenhouse humidity is of great significance to the formulation of disease control strategies and automatic irrigation of water and fertilizer. In this paper, a prediction method based on multi-modal data driven for full or Chinese names is studied. In order to decouple the complex relationship of environmental variables in greenhouse environmental control and improve the prediction efficiency of the model, this paper uses LASSO regression to screen the strongly related environmental factors of greenhouse air humidity changes from multiple greenhouse environmental parameters. Combining the advantages of CNN in extracting image spatial characteristics, based on GAF theory, the greenhouse time series are converted into two dimensional images of Gram angle summation field and Gram angle difference field, further enhancing effective information and suppressing environmental noise. The low complexity double convolution layer is introduced to fully extract the potential features of the image, identify the humidity change trend, and construct for the time series of different humidity change trends one by one Bayesian_LSTM prediction model, increase smooth input to improve prediction accuracy. In this paper, the historical time series of indoor temperature, humidity and light intensity are converted into two-dimensional images as input for cucumber greenhouse, and the prediction performance of the model is analyzed and verified. The experimental data shows that when the time sliding window size is 15, Gram angular difference field, Bayesian_ When the number of LSTM hidden nodes is 100, the average absolute error, average absolute percentage error, and root mean square error reach 2.58%, 4.56%, and 4.80% respectively, which is the best performance of the model. Compared with four mainstream prediction models, RNN, GRU, Bi-GRU and 1D-CNN, the test results show good prediction performance.

Keywords: environmental prediction; Gram corner field; convolution neural network; long and short term memory neural network; Bayesian neural network

0 引言

温室气候复杂,具有多参数和非线性特征,受外部气候

和内部设施管控策略等多因素影响^[1-4]。而温室内空气湿度对作物病害发生极其重要,病菌繁殖速度在湿度超出标准阈值后会迅速增长^[5]。因此,科学准确地预测温室空

收稿日期:2022-11-09

*基金项目:国家科技创新2030“新一代人工智能”重大项目(2021ZD0113604)、国家现代农业产业技术体系(CARS-23-D07)项目资助

气湿度,有利于提前采取通风、除湿等措施将温室湿度控制在适宜区间^[6],避免人工控制的滞后性,对于作物高质量生产具有重要作用。

传统温室环境预测模型根据对象、生产过程的内部机制或者物质流的传递机理建立数学模型。张良等^[7]、Herrero 等^[8]、Huang 等^[9]、石欣等^[10]分别基于能量平衡方程、第一性原理、拉普拉斯变换动态热模型和 CFD 研究环境预测,该类机理模型所需建筑物物理量和未知参数较多,很难大规模推广应用^[11]。随着计算机技术的快速发展,利用数据驱动的非线性模型预测温室小型气候成为当前温室智能管控研究热点。将传感器收集温室环境信息作为训练数据,最小二乘支持向量机、BP 神经网络、Elman 神经网络、复数神经网络等模型通过挖掘数据内在自相关特性,捕捉历史数据变化趋势预测温室环境^[12-15]。基于不同时间窗口尺寸,Liu 等^[16]对比了 RNN、LSTM 和 GRU 在黄瓜、番茄和辣椒数据集上的预测精度,试验结果表明 LSTM 具有最佳预测效果。Belouz 等^[17]基于 ANN 预测番茄产量并对投入产能进行敏感性分析,试验结果表明杀虫剂、农家粪便、钾、氮、电和杀菌剂是温室番茄生产中最重要的投入,与 MLP 相比 ANN 预测精度最高。田东等^[18]将食用菌温室内部温度作为包含线性或非线性分量的动态叠加时间序列,提出一种 MA-ARIMA-GASVR 方法建立温度预测模型,与传统 SVR、ARIMA-SVR 方法相比,预测精度有明显提高。

以上研究虽然取得了较高的准确预测精度,但模型易受外部环境噪声影响,所有时间序列作为同一模型输入容易错误刻画时间序列的非平稳性,影响预测精度。因此,本文提出一种基于多模态数据驱动(LASSO-GAF-CNN-Bayesian_LSTM)的预测模型,以黄瓜温室为研究对象,采用 LASSO 回归进行温室环境因子的特征筛选来降低模型冗余参数,利用时间滑动窗口将截取历史时间序列后基于格拉姆角场理论(Gramian angular field,GAF)转化为密度图像,引入低复杂度的双卷积层神经网络(convolutional neural network,CNN)进行趋势判别,最后对输出的每类密度图像的原始时间序列建立贝叶斯长短记忆神经网络(Bayesian long short term memory,Bayesian_LSTM)预测模型,保证模型鲁棒性,这种“先筛选,再分类,后训练”的方法增加了平稳输入,进一步提高预测精度。

1 材料与方法

1.1 实验地点

国家精准农业研究示范基地六号棚日光温室尺寸为 30 m×7.5 m×3 m,属半干旱半湿润季风气候区,黄瓜栽培试验于 2021 年 10 月~2022 年 5 月进行,共计种植两茬黄瓜。

1.2 实验数据获取

将传感器部署至温室内,采集室内空气温度(℃)、室内空气湿度(%RH)、室内光照强度(Lux)、室内土壤温度

(℃)、室内土壤湿度(%RH)、室外地面气压(hPa)、降水量(mm)、室外地表温度(℃)、室外相对湿度(%RH)、室外蒸发量(mm)、室外潜在蒸发量(mm)。采集时间范围为 0:00~23:59,间隔 30 min 上传一次,共得到 10 176 条数据,其中 8 141 组样本作为训练集,2035 组样本作为测试集,分别用来训练和测试温室湿度预测模型。试验温室如图 1 所示。



图 1 试验温室

1.3 特征筛选

温室传感器种类繁多,若将所有环境因子作为模型的输入会使网络结构过于庞大,硬件监测成本较高。因此,将数据标准化处理后,利用 LASSO 回归筛选与温室湿度变化趋势强相关的环境因子。LASSO 回归通过在线性回归添加惩罚项构造惩罚函数,将与目标回归变量关联较小的变量系数压缩^[19]。该特征筛选方法基于 LASSO 回归为:

$$\hat{(\lambda, \beta)} = \arg \min_{(\lambda, \beta)} \sum_{i=1}^n \left(y_i - \sum_{j=1}^p x_{ij} \beta_j \right)^2 + \sum_{i=1}^n \sum_{j=1}^p (\lambda x_{ij}) \quad (1)$$

式中: x_{ij} 是输入的各项环境因子, i 代表时间, j 代表各类环境因子, y_i 代表下一时刻温室空气湿度, λ 是超参数, β_j 是各项回归系数。通过调整 λ 以减小 β_j , 最终将 β_j 压缩至零,达到特征筛选的目的。

LASSO 回归系数求解一般采用信息赤池法则(Akaike information criterion,AIC),这一方法可以评估模型参数选择的优劣,方法定义如下:

$$AIC = 2K - n \ln(SSR/n) \quad (2)$$

式中: k 是输入参数的数量, n 是样本的数量, SSR 是模型回归后的残差平方和。AIC 达到最小值时,获得在全局范围内最佳的变量的子集。

2 黄瓜温室空气湿度预测算法模型构建

本文提出的模型预测流程如图 2 所示。该模型由 LASSO 特征筛选模块、GAF-CNN 湿度变化趋势分类模块、Bayesian_LSTM 湿度预测模块组成。与传统预测模型相比,利用 LASSO 回归筛选出与下一时刻温室湿度变化强相关的环境因子,且提出的 GAF 模块进一步增强了有效信息,抑制环境噪声,CNN 模块有效识别湿度变化趋势,基于 Bayesian_LSTM 对每一类时间序列建模预测,增加平稳

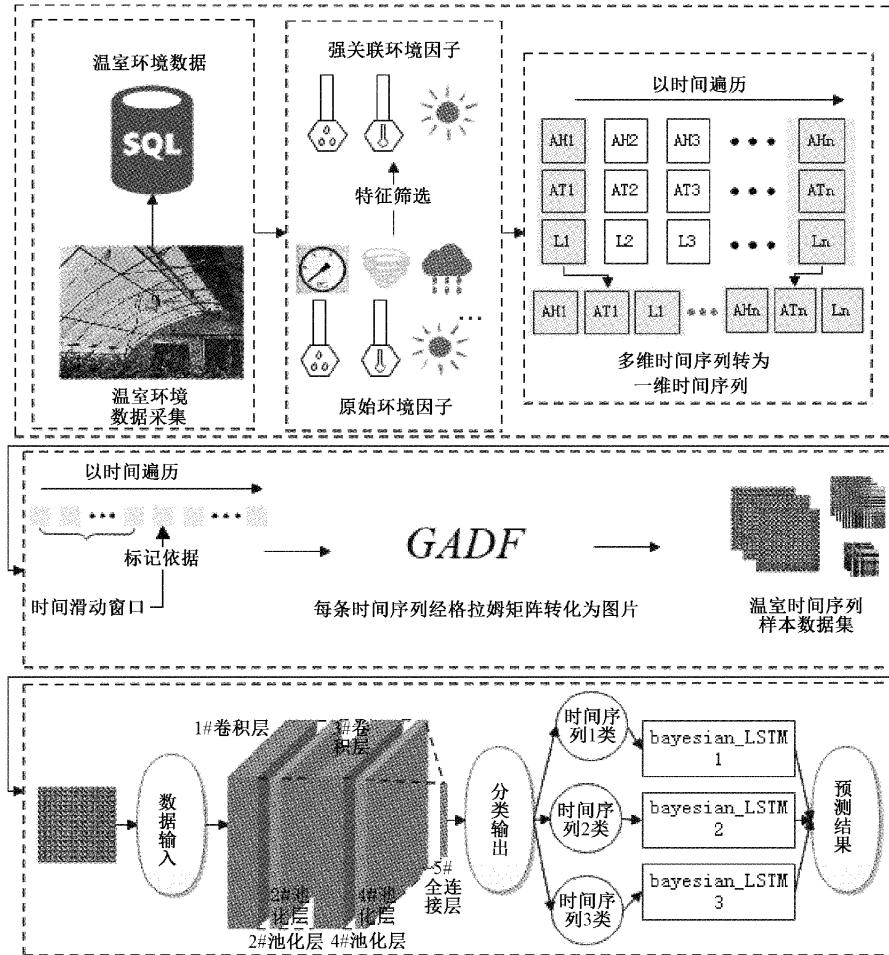


图 2 基于 LASSO-GAF-CNN-Bayesian_LSTM 温室空气湿度预测模型整体

输入,保证模型的鲁棒性及精准度。

2.1 基于 GAF 技术的温室时间序列成像

由于多维温室时间序列在时间和空间方向存在单向相关性,无法解释不同环境因子在时间维度、空间维度的多水平时空特征,且时间序列的点积运算无法区分时间序列趋势变化的有效信息和高斯噪声。因此,本文提出将多维温室时间序列归一化处理后以时间为顺序转换为一维时间序列并基于 GAF 理论转化为二维图像。该方法利用角关系输出的稀疏信号将有效信息和高斯噪声区分,充分挖掘温室时间序列中的隐藏特征。

霜霉病菌孢子在黄瓜温室空气湿度低于 45% 和高于 75% 时,其萌发速度会加快^[20]。为减小高湿、低湿带来黄瓜病害的影响,本文在长度为 T_x 的温室时间序列上,以 L 为滑动窗口尺寸,以 1 作为滑动步长,共可截取温室环境时间序列 $T_x - L + 1$ 组数据样本,记 X_{T_x-L+1} 为每次截取时间序列的最后一个时刻,将每组样本湿度变化趋势以 $X_{T_x-L+1} + 1$ 时刻的室内空气湿度低于 45%、处于 45%~75%、高于 75% 分为 3 类。

GAF 是一种将时间序列转为二维图像的编码方式^[21]。将每组数据样本时间序列通过式(3)归一化后以时间戳顺序转化为一维时间序列 \tilde{x} ,然后将通过式(4)将数值编码为余角弦。

$$\tilde{x}_{pq} = \frac{(\tilde{x}_{pq} - \max(\tilde{x}_p)) + (\tilde{x}_{pq} - \min(\tilde{x}_p))}{\max(\tilde{x}_p) - \min(\tilde{x}_p)} \quad (3)$$

式中: p 为各项环境因子, q 为时间戳。

为将时间序列中时间轴与对应值的相关性转化为半径和角度的映射关系,将 \tilde{x} 转化为极坐标,公式如下:

$$\begin{cases} \theta_{pq} = \arccos(\tilde{x}_{pq}) & \tilde{x}_{pq} \in \tilde{x} \\ r_q = \frac{q}{\delta} \end{cases} \quad (4)$$

式中: p 为各项环境因子, q 为时间戳, δ 是用来规范极坐标系跨度的常数, r_q 为半径。

原始时间序列由上述变换得到半径 r_q 和角度 θ_{pq} , 将 θ_{pq} 下角标改写为: $\theta = (\theta_1, \theta_2, \dots, \theta_i, \dots, \theta_m)$, 代入 GASF 和 GADF, 基于两类矩进行升维并进行图像编码转换, 得到 GAF 密度分布图, 其中 GASF 基于余弦函数, GADF 基

于正弦函数。

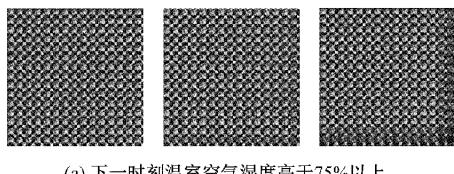
GASF 和 GADF 的公式如下：

$$GASF = \begin{bmatrix} \cos(\theta_1 + \theta_1) & \cdots & \cos(\theta_1 + \theta_i) & \cdots & \cos(\theta_1 + \theta_m) \\ \vdots & & \vdots & & \vdots \\ \cos(\theta_i + \theta_1) & \cdots & \cos(\theta_i + \theta_i) & \cdots & \cos(\theta_i + \theta_m) \\ \vdots & & \vdots & & \vdots \\ \cos(\theta_m + \theta_1) & \cdots & \cos(\theta_m + \theta_i) & \cdots & \cos(\theta_m + \theta_m) \end{bmatrix} \quad (5)$$

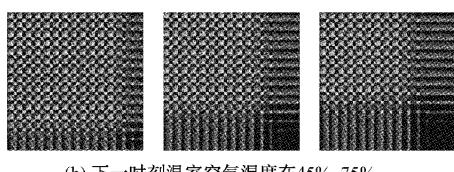
$$GASF = \begin{bmatrix} \sin(\theta_1 - \theta_1) & \cdots & \sin(\theta_1 - \theta_i) & \cdots & \sin(\theta_1 - \theta_m) \\ \vdots & & \vdots & & \vdots \\ \sin(\theta_i - \theta_1) & \cdots & \sin(\theta_i - \theta_i) & \cdots & \sin(\theta_i - \theta_m) \\ \vdots & & \vdots & & \vdots \\ \sin(\theta_m - \theta_1) & \cdots & \sin(\theta_m - \theta_i) & \cdots & \sin(\theta_m - \theta_m) \end{bmatrix} \quad (6)$$

由式(3)~(6)可知,原始时间序列 \tilde{x} 随 θ_i 自左上角到右下角逐步转换,原始时间序列与 GAF 矩阵呈双射关系,既保证时间依赖性,又将温室时间序列完整映射到二维图像中。

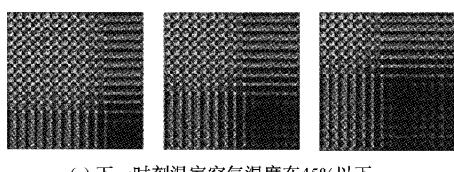
3 类时间序列分别经 GASF 和 GADF 转化后如图 3(a)~(c)和图 4(a)~(c)所示。通过观察图 3、4 中转化后图像密度分布可以看到随着湿度逐渐下降,图 3(a)~(c)密度自右下到左上逐渐降低,图 4(a)~(c)的左下角和右上角密度逐渐增加,在对比图 3、4 时,密度变化的颜色差异更为明显,因此利用 GAF 理论可以将温时间序列的变化特征通过图像体现。



(a) 下一时刻温室空气湿度高于75%以上

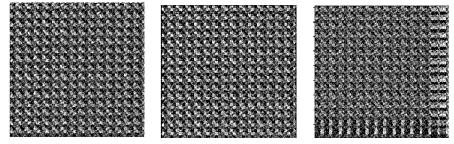


(b) 下一时刻温室空气湿度在45%~75%

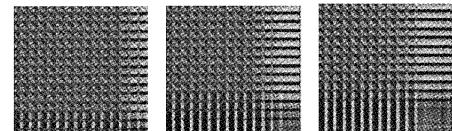


(c) 下一时刻温室空气湿度在45%以下

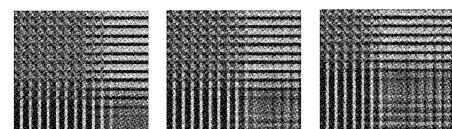
图 3 基于 GASF 的图像转化



(a) 下一时刻温室空气湿度高于75%以上



(b) 下一时刻温室空气湿度在45%~75%



(c) 下一时刻温室空气湿度在45%以下

图 4 基于 GADF 的图像转化

2.2 温室环境分类卷积网络

CNN 在处理图像分类任务中的优越性已经得到大量证实^[22-24]。将温室时间序列映射到格拉姆角场生成 GAF 密度图像后利用 CNN 对其进行训练学习,可以有效提高分类的准确率。本文基于双卷积层构成浅层 CNN 模型实现温室环境时间序列分类,该 CNN 具有两个卷积层、两个池化层、一个全连接层、一个输出层。

为充分挖掘温室时间序列的潜在变化趋势,基于卷积算子感知图像特征,在形成特征提取的权重矩阵后输入至池化层进行特征选择,减少冗余特征,进一步缩短训练计算时间。将 ReLU 函数加入卷积层与池化层之间,使输入权重矩阵中的某些为 0 的权重位置代表的神经元失活来减少模型参数数量,提高收敛速度。

该激活函数的表达式为:

$$F_{ReLU} = (x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (7)$$

式中: x 为卷积算子在特征提取后所获权重。

在经过上述两轮试算后,将提取出的特征输入至全连接层并使用 Softmax 函数来进行特征分类,分类结果由输出层输出。GAF-CNN 温室时间序列分类模型分类的具体步骤如下:

1) 采集温室多环境因子时间序列,根据 1.3 节中的方法进行数据预处理。

2) 将温室多维时间序列以时间为顺序转为一维时间序列,利用 GAF 技术转化为二维密度分布图像。

3) 将二维密度分布图像训练集作为 CNN 网络的输入,输出室内湿度变化趋势类别,标签为 0 或 1 或 2,网络参数 Batchsize 设置为 128,采用 Adam 初始动态学习率 0.001,交叉熵为损失函数。

4) 调整时间滑动窗口大小并重复步骤 2)~3)以提高模型最优分类精度。

5) 将测试集样本利用 GAF 技术转化为二维密度分布图像,输入至训练好的 CNN 模型。验证分类精度。

2.3 基于 Bayesian_LSTM 的温室空气湿度预测

Bayesian_LSTM 利用贝叶斯后验分布中的变分推断,将 LSTM 的权值和偏差重设为一个概率分布 $P(\omega | D)$,

在输入数据 x 后使得该分布可以计算得出数据的预测分布:

$$P(y | x) = E_{p(\theta|D)}[P(y | x, \theta)] \quad (8)$$

变分推断是一种通过优化逼近机器学习中难以解决的概率分布的方法,变分学习通过搜索 Killback-Leibler(KL) 散度中最优变分参数 θ 来找到最佳变分 $q(\theta | \mu, \sigma)$ ^[25-26]。

$$(\mu, \sigma)^* = \underset{\mu, \sigma}{\operatorname{argmin}} KL[q(\theta | \mu, \sigma) \| P(\theta | D)] \quad (9)$$

Bayesian_LSTM 温室空气湿度预测具体步骤如下:

1) 将 2.2 节输出一类密度图像的原时间序列以训练集输入至 Bayesian_LSTM 网络中,设置 Batchsize 为 30,采用 Adam 初始动态学习率 0.01, MSE 作为损失函数进行训练,输出下一时刻预测的室内空气湿度值。

2) 对 2.2 节中输出的每一类密度图像重复步骤 1),不断调整模型隐藏层节点数量,直到达到模型训练的最优解。

3) 将测试集中的时间序列利用 GAF 转化为二维密度图像,输入至 2.2 节训练好的 GAF-CNN 模型,判别属于黄瓜温室环境中哪一类湿度变化趋势后,将时间序列输入至对应类的训练好的 Bayesian_LSTM 网络中,输出下一时刻预测室内空气湿度的值。

3 结果与分析

为训练最优模型,评价各模块效果,验证模型有效性,本文进行了参数选择实验、消融实验、对比实验。实验运行硬件环境为 Inter Core i7-10750H 处理器和 RTX 2060 显卡,软件运行环境为 Pycharm。

3.1 基于 LASSO 回归的参数选择

LASSO 回归在原始数据集上筛选出与下一时刻温室空气湿度变化趋势强相关的环境因子。由于实验中采集的样本量较多,为避免维度灾难的现象,本文采用将 AIC 中的惩罚项 $2k$ 替换为 $k \ln(n)$ 的贝叶斯信息法则(Bayesian information criterion, BIC)寻找 LASSO 回归的最优解,在 BIC 达到最小时模型解为最优。

将采集的 11 种环境因子作为输入,以室内空气湿度作为回归目标,通过调整参数 λ 筛选对室内空气湿度变化影响较大的环境参数。当参数 λ 为 1 时各参数系数均未选入模型,随着 λ 逐渐减小,不断有变量被选入模型,直到 λ 等于 0 时,所有变量被选入模型,总共使用了 14 步找出全部解。

表 1 给出了 BIC 准则下模型前 6 步的结果。

表 1 LASSO 回归模型变量筛选

系数	影响因素	1	2	3	4	5	6
β_1	室外地面气压	0	0	0	0	0	0
β_2	降水量	0	0	0	0	0	0
β_3	室外空气温度	0	0	0	0	0.000 018	0.000 050
β_4	室外空气湿度	0	0	0	0	0	0
β_5	室外蒸发量	0	0	0	0	0	0
β_6	室外潜在蒸发量	0	0	0	0	0	0
β_7	室内空气温度	0	0	0.000 035	0.000 027	0.000 008	0
β_8	室内空气湿度	0	0.995 794	0.999 560	0.999 726	0.999 857	0.999 907
β_9	室内光照强度	0	0	0	0.000 001	0.000 044	0.000 038
β_{10}	室内土壤温度	0	0	0	0	0	0
β_{11}	室内土壤湿度	0	0	0	0	0	0
BIC		-657 636.15	-672 098.28	-673 726.74	-668 702.45	-658 460.68	

由表 6 可知,随着 λ 逐渐减小,在第 4 步时 BIC 达到最小值,第 5 步及以后 BIC 的值逐渐上升,此时模型选取到变量:室内空气温度、室内空气湿度、室内光照为模型最优解。

3.2 GADF-CNN 与 GASF-CNN 对比试验

根据 3.1 节试验结果显示,选择将空气温度、空气湿度、光照作为 GAF-CNN 模型输入,为探究 GADF 与 GASF 在黄瓜温室数据集上的表现,本文分别将 GADF、GASF 两种图像输入至 CNN 中进行相关试验,比较两种不同图像转换方式作为模型输入的分类准确率。

本文采用双卷积层构成的浅层 CNN 网络参数如表 2 所示。

表 2 CNN 网络参数

序号	层类型	内核大小	内核个数	步长	填补
1	卷积层 1	3×3	16	1	1
2	池化层 1	2×2	16	2	0
3	卷积层 2	3×3	32	1	0
4	池化层 2	2×2	32	2	0
5	全连接层	128	1	0	0

在 CNN 迭代了 100 轮后,获得的测试集的准确率曲线如图 5 所示。由图 5 可以看出,在模型训练过程中,随着迭代次数的增加,GADF-CNN 的训练数据准确率收敛于

0.91~0.92, 而 GASF-CNN 的训练数据准确率收敛于 0.88~0.89。

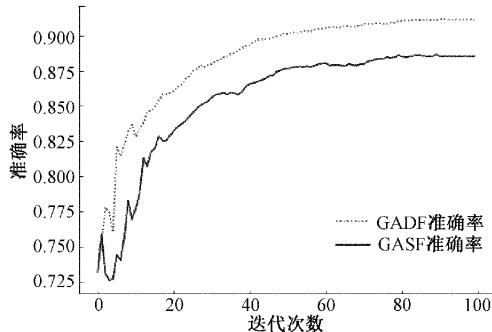


图 5 测试集分类准确率比较

3.3 GADF-CNN-Bayesian_LSTM 参数及结构优化

时间滑动窗口尺寸、网络隐藏层数等对黄瓜温室预测准确度具有较大影响, 设置不同参数值验证模型预测性能以优化模型结构。

1) 时间滑动窗口尺寸对 GADF-CNN 的影响

时间滑动窗口顺序截取的时间序列对模型的性能具有重要影响。若时间滑动窗口取值过小, 则子时间序列所包涵的温室环境变化趋势的有效信息过少, 而取值过大时, 子时间序列所包涵的温室环境变化趋势的无效信息过多, 时间滑动窗口过小和过大都会严重影响模型分类效果。

为探究在该黄瓜温室数据集上型最优整体识别率的时间窗口尺寸, 在迭代次数为 100 的情况下, 设置 5、10、15、20、25 共 5 组对照实验, 其测试集的试验结果如表 3 所示。

表 3 不同时间滑动窗口模型分类的正确率

时间滑动窗口尺寸	5	10	15	20	25
正确率	0.830 1	0.881 5	0.911 4	0.875 6	0.856 5

从表 3 看出, 分类准确率随时间滑动窗口尺寸的增加呈先增大后减小的趋势。在增加到 15 个时刻时, 模型分类准确率最高, 达到 91.14%。因此, 在本黄瓜温室数据集中, 选取以 15 个时刻为大小作为最佳时间窗口尺寸。

2) 网络参数对 Bayesian_LSTM 的影响

网络隐藏层节点数量对 Bayesian_LSTM 预测模型的精准度具有重要影响。隐藏层节点数量过少会降低预测性能, 造成模型不稳定, 数量过多则会使模型过于臃肿, 预测性能也会降低。在迭代次数为 50 时, 设置 20、50、100、150 共 4 组对照实验, 研究在本黄瓜温室数据集上隐藏节点数量取值对预测精度的影响, 并从平均绝对误差 (mean absolute error, MAE)、平均绝对百分比误差 (mean absolute percentage error, MAPE)、均方根误差 (root

mean square error, RMSE) 3 种评价指标进行对比, 获取最佳隐藏层节点参数。

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (11)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (12)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (13)$$

式中: y_i 代表实际值, \hat{y}_i 代表预测值。

在测试集的实验结果如表 4 所示。

表 4 不同隐藏层节点数预测精度比较

隐藏层节点数	MAE/%	MAPE/%	RMSE/%
20	2.81	4.90	5.02
50	2.72	4.71	4.88
100	2.58	4.56	4.80
150	2.65	4.68	4.91

根据表 4 发现, 预测精度随隐藏节点数量增加呈先上升后下降的趋势。当隐藏层节点数增加到 100 时, MAE、MAPE、RMSE 都最低, 分别达到了 2.58%、4.56%、4.80%。

3.4 消融实验

为了进一步评价 LASSO-GAF-CNN-Bayesian_LSTM 每个模块效果, 本文在黄瓜温室数据集上开展了消融实验。

表 5 为 6 种模型的性能比较。为确保评估的合理性, 不同模型的相同模块采用相同的模型参数。

表 5 消融实验下各模块预测精度对比

模型种类	MAE/ %	MAPE/ %	RMSE/ %
	%	%	%
LSTM	2.92	5.12	5.20
Bayesian_LSTM	2.84	4.93	5.02
LASSO-LSTM	2.90	5.13	5.37
LASSO-Bayesian_LSTM	2.80	4.97	4.99
LASSO-GAF-CNN-LSTM	2.69	4.69	4.87
LASSO-GAF-CNN-Bayesian_LSTM	2.58	4.56	4.80

根据表 5 可以看出, 不管采取哪种融合方式的模型, 任何一个模块的缺失, 都会降低模型性能, 尤其是 GAF-CNN 模块和 Bayesian_LSTM 模块。这说明 GAF-CNN 模块有效将不同湿度变化趋势的时间序列进行分类后, 利用 Bayesian_LSTM 模块逐一对每种类别时间序列进行训练时有效增加了平稳输入, 降低了将所有子时间序列作为同一模型输入而错误刻画的非平稳性对预测精度的影响, 在未对数据降噪处理的情况下, 其高斯训练过程提供了可靠的不确定性估计、鲁棒性, 进一步提升模型预测性能。

3.5 对比实验

本实验采用目前较为常用的几种时间序列预测算法进行对比:RNN、GRU、Bi-GRU、1D-CNN。RNN 在时间步较短时具有良好的长短时记忆能力;GRU 参数少训练快,在时间步较长时仍能保持长短时记忆;Bi-GRU 可以提取时间序列的反向特征;1D-CNN 具有提取空间特征的优势。

其中 RNN、GRU、Bi-GRU 网络参数均与消融实验中 Bayesian_LSTM 网络相同,1D-CNN 由一层单卷积层和一层全连接层组成,其神经元都设置为 100。上述深度学习模型迭代次数都设置为 50,Batchsize 设置为 30,Adam 初始动态学习率设置为 0.01,均方误差为损失函数。5 种模型在测试集上的预测精度结果对比如表 6 所示。

表 6 不同模型预测精度对比

模型种类	MAE/	MAPE/	RMSE/
	%	%	%
RNN	2.83	4.99	5.10
GRU	2.96	5.11	5.08
Bi-GRU	2.95	5.08	5.31
1D-CNN	3.09	42.38	5.30
LASSO-GAF-CNN-Bayesian_LSTM	2.58	4.56	4.80

试验结果截取了 2022 年 4 月 4 日 3 类湿度变化趋势下不同模型预测对比情况,如图 6(a)、(b)及(c)所示。可

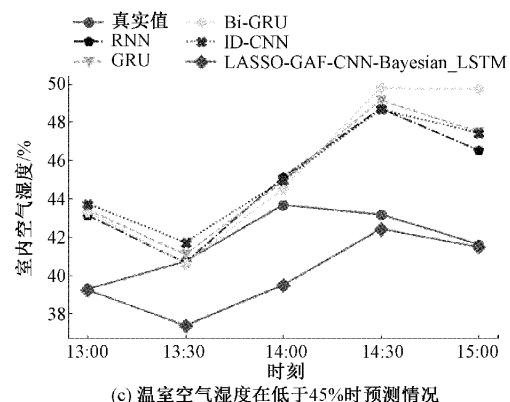
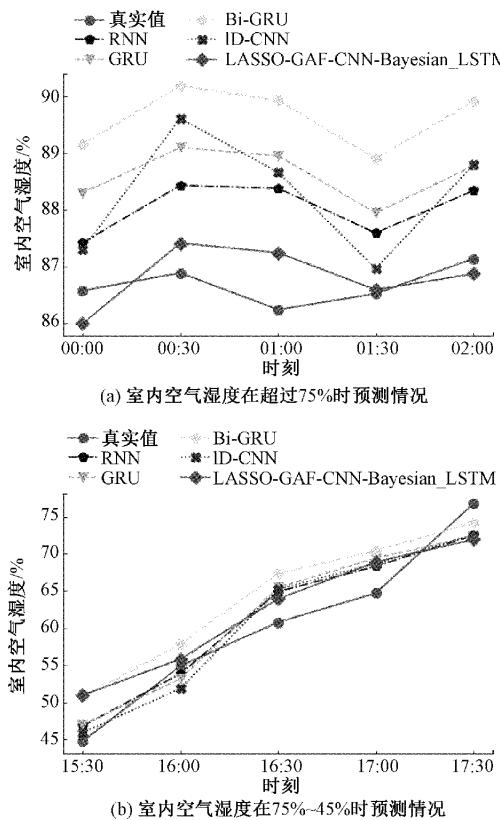


图 6 不同模型预测结果对比

以看出,本研究提出的模型预测结果最贴近真实数据,能较好地拟合黄瓜温室空气湿度的变化趋势。由于 RNN、GRU、Bi-GRU、1D-CNN 未对输入进行变量筛选和分类,使输入信息冗余且错误刻画非平稳输入致使预测精度降低,本文提出模型的 LASSO-GAF-CNN 模块有效减少了这种缺陷,在未对温室环境数据进行降噪处理的情况下,Bayesian_LSTM 模块的高斯训练过程为模型提供了可靠的鲁棒性,进一步提升预测精度。

4 结 论

本文提出一种基于多模态数据驱动(LASSO-GAF-CNN-Bayesian_LSTM)的黄瓜温室湿度预测模型。首先利用 LASSO 回归降低模型冗余参数,然后基于 GAF 理论转化为密度图像,增强有效信息,抑制环境噪声,引入双卷积层 CNN 提取图像特征,对湿度变化趋势进行分类,最后基于 Bayesian_LSTM 对每一类时间序列构建湿度预测模型,增加平稳输入并保证模型鲁棒性。该方法以图像、时间序列两种模态数据驱动预测模型,可以精准预测黄瓜温室内空气湿度变化,对温室精准调控具有重要意义。本文提出的模型在 MAE、MAPE、RMSE 三种评价指标下,预测精度分别达到了 2.58%、4.56%、4.80%。通过对比和消融实验,结果表明本文方法在各项指标均优于其他网络。但是,模型只具备单步预测的能力,在后续工作中将针对多步预测方法做进一步研究。

参考文献

- [1] WANG Y G, LU Y J, XIAO R M. Application of nonlinear adaptive control in temperature of Chinese solar greenhouses[J]. Electronics, 2021, 10(13): 1582.
- [2] YOUNESI A M, KHAFAJEH H, ZAREIN M. Factors affecting energy consumption and productivity in greenhouses[J]. Spanish Journal of Agricultural Research, 2021, 19(4): e0209.
- [3] 秦琳琳, 马国旗, 储著东, 等. 基于灰色预测模型的温室温湿度系统建模与控制[J]. 农业工程学报,

- 2016, 32(S1): 233-241.
- [4] SOUNDIRANL R, RADHAKRISHNAN T K, NATARAIAN S. Modeling of greenhouse agro-ecosystem using optimally designed bootstrapping artificial neural network[J]. Neural Computing and Applications, 2019, 31(11): 7821-7836.
- [5] LIU K G, ZHANG C H, YANG X T, et al. Development of an occurrence prediction model for cucumber downy mildew in solar greenhouses based on long-short term memory neural network [J]. Agronomy-Basel, 2022, 12(2): 442.
- [6] 曹宏鑫, 葛道阔, 张文字, 等. 农业模型发展分析及应用案例[J]. 智慧农业, 2020, 2(1): 147-162.
- [7] 张良, 管泽锋, 洪亚杰, 等. 2种屋项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.
- [8] HERRERO J M, BLASCO X, MARTINEZ M, et al. Non-linear robust identification of a greenhouse model using multi-objective evolutionary algorithms [J]. Biosystems Engineering, 2007, 98(3): 335-346.
- [9] HUANG L, DENG L H, LI A G, et al. A novel approach for solar greenhouse air temperature and heating load prediction based on Laplace transform[J]. Journal of Building Engineering, 2021, 44: 102682.
- [10] 石欣, 田文斌, 冷正立. 基于CFD和LightGBM算法的建筑室内温度全局预测模型[J]. 仪器仪表学报, 2021, 42(1): 237-247.
- [11] AXEL E G, GENARO M, MANUEL T A, et al. Applications of artificial neural networks in greenhouse technology and overview for smart agriculture development [J]. Applied Sciences-Basel, 2020, 10(11): 3835.
- [12] 杨雷, 张宝峰, 朱均超, 等. 基于PCA-PSO-LSSVM的温室大棚温度预测方法[J]. 传感器与微系统, 2018, 37(7): 52-55.
- [13] 李渊朴, 王秀玲. 基于改进遗传算法和神经网络的大棚环境预测[J]. 电子测量技术, 2020, 43(7): 46-49.
- [14] 张建超, 单慧勇, 景向阳, 等. 基于Elman神经网络的温室环境因子预测方法[J]. 中国农机化学报, 2021, 42(8): 203-208.
- [15] 徐宇, 冀荣华. 基于复数神经网络的智能温室温度预测研究[J]. 中国农机化学报, 2019, 40(4): 174-178.
- [16] LIU Y W, LI D J, WAN S H, et al. A long short-term memory-based model for greenhouse climate prediction[J]. International Journal of Intelligent Systems, 2021, 37(1): 135-151.
- [17] BELOUZ K, NOURANI A, ZEREG S, et al. Prediction of greenhouse tomato yield using artificial neural networks combined with sensitivity analysis [J]. Scientia Horticulturae, 2022, 293: 110666.
- [18] 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.
- [19] 李翼, 张本慧, 郭宇燕. 改进粒子群算法优化下的Lasso-Lssvm预测模型[J]. 统计与决策, 2021, 37(13): 45-49.
- [20] 国淑梅, 牛贞福. 温湿度对黄瓜霜霉菌病斑产孢和孢子囊萌发的影响[J]. 北方园艺, 2013, 37(13): 151-153.
- [21] WANG Z G, OATES T. Encoding time series as images for visual inspection and classification using tiled convolutional neural Networks[C]. Workshops at the Twenty-ninth AAAI Conference on Artificial Intelligence, 2015: 40-46.
- [22] ABDELMALEK B, HAFED Z, AHMED K, et al. Deep learning techniques to classify agricultural crops through UAV imagery: A review [J]. Neural Computing & Applications, 2022, 34(12): 9511-9536.
- [23] AHMED H A, NOR A I, KHAMEL A, et al. Classification of weed using machine learning techniques: A review-challenges, current and future potential techniques[J]. Journal of Plant Diseases and Protection, 2022, 129(4): 745-768.
- [24] 孙红, 李松, 李民赞. 农业信息成像感知与深度学习应用研究进展[J]. 农业机械学报, 2020, 51(5): 1-17.
- [25] GOAN E, FOOKES C. Bayesian neural networks: An introduction and survey [C]. Case Studies in Applied Bayesian Data Science: CIRM Jean-Morlet Chair. Fall 2018, 2020: 45-87.
- [26] FENG R H. Uncertainty analysis in well log classification by Bayesian long short-term memory networks [J]. Journal of Petroleum Science and Engineering, 2021, 205: 108816.

作者简介

- 黄天艺, 硕士研究生, 主要研究方向为农业温室环境预测。
E-mail: huangty@nercita.org.cn
- 吴华瑞(通信作者), 博士, 研究员, 主要研究方向为农业智能系统与物联网。
E-mail: wuhr@nercita.org.cn