

doi:10.6041/j.issn.1000-1298.2024.03.035

基于模型预测控制的菇房空调整节能控制方法

张馨^{1,2} 孔祥书^{1,2} 郑文刚² 王明飞^{2,3} 单飞飞² 鲍峰²

(1. 新疆农业大学机电工程学院, 乌鲁木齐 830052; 2. 北京市农林科学院智能装备技术研究中心, 北京 100097;

3. 农业农村部华北都市农业重点实验室, 北京 100096)

摘要: 当前工厂化食用菌生产菇房空调控制方法存在节能效率低、室内温度波动大等问题, 提出了一种基于卷积神经网络(Convolutional neural network, CNN)、门控循环单元神经网络(Gated recurrent unit neural network, GRU)与注意力机制(Attention)的菇房空调整节能控制方法。该方法以 CNN – GRU – Attention 组合神经网络为预测模型, 结合预测误差补偿和预测模型数据集动态更新机制, 实现对菇房室内温度精准预测; 建立以空调控制量为状态量的目标函数, 分别利用熵权法、主观法明确目标函数权重系数, 运用带精英策略的快速非支配排序遗传算法(Non-dominated sorting genetic algorithm II, NSGA-II)求解出空调在控制时域内最优控制序列, 集成滚动优化和反馈机制, 实现菇房环境的精准及节能控制。试验结果表明, 提出的 CNN – GRU – Attention 菇房室内温度预测模型, 以历史 30 min 数据预测未来 10 min 室内温度效果最好, 选取的典型日内预测最大均方根误差为 0.122°C、最小决定系数为 0.807、最大平均绝对百分比误差为 0.611%; 菇房空调模型预测控制方法对天气波动具有较好的抗干扰能力。与阈值开关法和 PID 法相比, 在空调整节能方面, 能耗分别减少 21% 和 14%; 在控制温度精度方面, RMSE 可分别降低 72%、46%。

关键词: 菇房; 预测模型; 模型预测控制; 多目标优化; 神经网络

中图分类号: TP273+.1 文献标识码: A 文章编号: 1000-1298(2024)03-0352-10

OSID:



Energy-saving Control Method of Air Conditioning in Mushroom House Based on Model Predictive Control

ZHANG Xin^{1,2} KONG Xiangshu^{1,2} ZHENG Wen'gang² WANG Mingfei^{2,3} SHAN Feifei² BAO Feng²

(1. College of Mechanical and Electrical Engineering, Xinjiang Agricultural University, Urumqi 830052, China

2. Intelligent Equipment Technology Research Center, Beijing Academy of Agriculture and Forestry Sciences, Beijing 100097, China

3. North China Urban Agriculture Key Laboratory, Ministry of Agriculture and Rural Affairs, Beijing 100096, China)

Abstract: At present, there are some problems such as low energy saving efficiency and large indoor temperature fluctuation in the control methods of mushroom air conditioning in factory production. An energy saving control method based on convolutional neural network (CNN), gated recurrent unit neural network (GRU) and self-attention mechanism was proposed. The CNN – GRU – Attention combined neural network was used as the prediction model, and the prediction error compensation and the dynamic updating mechanism of the prediction model data set were combined to achieve accurate prediction of indoor temperature in mushroom houses. The control quantity of air conditioning was established as the objective function of state quantity, and the weight coefficient of the objective function was defined by entropy weight method and subjective method, respectively. The optimal control sequence of air conditioning in the control time domain was solved by non-dominated sorting genetic algorithm II (NSGA-II), and the rolling optimization and feedback mechanism were integrated to realize the accurate and energy-saving control of the greenhouse environment. The experimental results showed that the CNN – GRU – Attention indoor temperature prediction model proposed in mushroom house showed that the previous 30 min data had the best effect in predicting the indoor temperature in the future 10 min. On a typical intra-day the maximum root mean square error of prediction accuracy was 0.122°C, the

收稿日期: 2023-08-07 修回日期: 2023-10-12

基金项目: 国家食用菌产业技术体系项目(CARS-20)和北京市食用菌创新团队项目(BAIC03-2023)

作者简介: 张馨(1982—), 男, 副研究员, 主要从事食用菌工厂化智能管控研究, E-mail: zhangx@nercita.org.cn

通信作者: 王明飞(1984—), 男, 高级工程师, 博士, 主要从事食用菌智能检测与控制技术研究, E-mail: wangmf@nercita.org.cn

minimum coefficient of determination was 0.807, and the maximum mean absolute percentage error was 0.611% . The model predictive control method of mushroom air conditioning had a good anti-interference ability in weather fluctuation. Compared with threshold switching method and PID method, the energy consumption of air conditioning can be saved by 21% and 14%, respectively. In terms of temperature control accuracy, the root mean square error was decreased by 72% and 46%, respectively.

Key words: mushroom house; prediction model; model predictive control; multi-objective optimization; neural network

0 引言

食用菌产业是我国种植业的支柱产业,同时我国也是全球最大的食用菌生产与出口国^[1]。食用菌种植模式主要有露天或林下模式、大棚种植模式、工厂化生产模式,其中工厂化生产模式被视为未来的发展趋势^[2]。而能耗高是制约工厂化发展的因素之一,通常需从围护结构、空调机组和节能调控方法3方面解决,其中基于环境节能调控方法具有代价小、易推广等优点得到广泛关注。

目前食用菌行业内空调控制方法有阈值开关法和PID法,这些方法在实际应用中存在能源利用率低、温度超调等问题^[3]。模型预测控制(Model predictive control, MPC)方法作为一种先进的控制策略,已有大量研究表明其在空调控制方面具有跟踪能力强、节能降耗等优点^[4-8]。MPC三要素为预测模型、滚动优化、反馈校正^[9-10],三者结合实现了控制系统的闭环,其中预测模型是实现MPC的前提。常用预测模型主要有:以热平衡方程为代表的白箱模型^[11]、以等效电阻-电容(Resistor - capacitance circuit, RC)电路模型为代表的灰箱模型^[12]和以神经网络为代表的黑箱模型^[13]。热平衡方程以及等效RC电路模型等都需要复杂的建模过程,且其参数不易测得,难以精准建模,而神经网络可以精准地捕捉到输入与输出之间的动态关系,但受限于数据量未能得到规模化应用^[14]。

近年来随着物联网的发展逐渐解决了数据获取问题,使得将神经网络模型作为MPC的预测模型成为可能。文献[15]在锅炉控制上使用基于有源自回归模型(Auto-regressive with extra inputs, ARX)的MPC方法,相比开关控制能耗节省12%。文献[16]将基于人工神经网络(Artificial neural network, ANN)的MPC调控策略应用到办公建筑的供热、通风及空气调节(Heating, ventilation and air conditioning, HVAC)系统中,从而最大限度地节省了能耗。文献[17]将多层次前馈神经网络应用到泵流量的MPC控制中,以低能耗与高精度为目标函数,搭配具有随机跳跃的 ϵ 约束差分进化算法(Differential evolution, DE)将建筑能源系统的运营

成本节省3.4%。文献[18]使用基于输出反馈神经网络预测温度,证明MPC在通风控制中性能优越。文献[19]将反向传播神经网络(Back propagation, BP)与MPC结合用以改善空气源热泵的控制。文献[20]将两个3层的BP神经网络应用到空调冷冻站系统的优化控制中。文献[21]使用支持向量机(Support vector regression, SVR)、BP神经网络作为室内通风风量的预测模型,并将其应用到MPC控制中。文献[22]使用长短期记忆(Long short term memory, LSTM)网络作为预测模型,并优化了建筑内温度控制策略,结果表明电能消耗降低35%。文献[23]将带有外部输入的非线性自回归神经网络(Nonlinear auto-regressive model with exogenous inputs, NARX)应用到区域供冷MPC中,在不同模式下均实现了节能目标。文献[24]将GRU(门控循环单元神经网络)与MPC结合用以处理电力负荷分配优化问题。

综上所述,基于神经网络的MPC方法已在商业建筑、电力分配等领域得到广泛研究,并表现出较好的应用效果^[25]。但食用菌工厂化菇房与商业建筑不同,其内部菌棒种植密度高,室内热时滞性大,且室内目标温度需随着食用菌生长周期动态变化。因此,针对食用菌工厂化菇房现有空调调控方法节能效率低、温度波动范围大的问题,本文以神经网络模型作为预测模型,以设备运行低能耗和高精度温度控制为目标函数,提出基于神经网络的MPC空调调控策略,在保障菌菇正常生长的前提下,最大限度地节省空调能耗。

1 材料与方法

1.1 数据收集

试验在北京市某海鲜菇种植公司开展,菇房面积为112 m²,高为5 m。此菇房采用定频空调制冷,空调主要由压缩机、冷凝器、蒸发器、室内风机等部件组成,在实际运行过程中,接通电源后主要部件同时运行。因此,空调能耗与开启时间成正比。

在试验过程中忽略工人进出所交换的热量、室内湿度(试验过程中室内相对湿度均在90%以上)和室外湿度的影响。此外,在开启新风机时对新风

会先进行预冷动作,且通风时间短,对室内温度变化无明显影响,因此可忽略新风的影响。

本文将室内温度、室外温度、太阳辐射量、空调开启时间4个要素作为预测模型的输入,其中室内温度数据通过均匀分布在室内的10台HOBO U23-001A型温度传感器获得,室外温度数据通过HOBO U23-001A型温度传感器获得,太阳辐射量通过SMP3型辐射传感器和CR1000型数据采集器获取,空调开启时间由HOBO CTV-C型交流电流传感器获取,电流传感器安装在空调控制柜中,试验布置如图1所示。温度数据与太阳辐射量数据每1 min采集一次,电流数据每10 s采集一次。试验设备参数如表1所示。

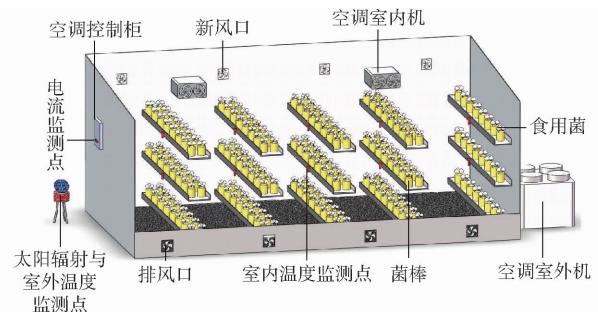


图1 菇房结构与传感器安装位置示意图

Fig. 1 Structure diagram of mushroom house
and installation position of sensor

表1 设备技术参数

Tab. 1 Equipment technical parameters

设备	生产企业	型号	量程
温度传感器	HOBO	U23-001A	温度 -40~70℃
交流电流传感器	HOBO	CTV-C	电流 0~100 A
辐射传感器	Kipp&Zonen	SMP3	辐射量 0~2000 W/m ²
辐射记录仪	Campbell	CR1000	
温度/电流记录仪	HOBO	UX120-006M	

试验时间为2022年5月11日—9月11日。试验期间菇房温度上下限设置范围为14~15℃。为方便展示,选择7月13—22日间数据,空调开启时间以每天计,室内温度以平均每小时计。太阳辐射量、室外温度、室内温度、空调开启时间如图2所示。

1.2 数据预处理

由于本文所用传感器采样周期不同,将所有数据的采样周期统一处理为10 min,其中空调开启时间为10 min内的实际开启时间。为避免不同量纲和数量级对训练神经网络及优化求解产生不利影响,需对原始数据进行归一化处理,采用归一化方法Max-Min法将所有数据全部归于[0, 1]之间。

1.3 评价指标

为评价本文所涉及模型的性能,选用均方根误

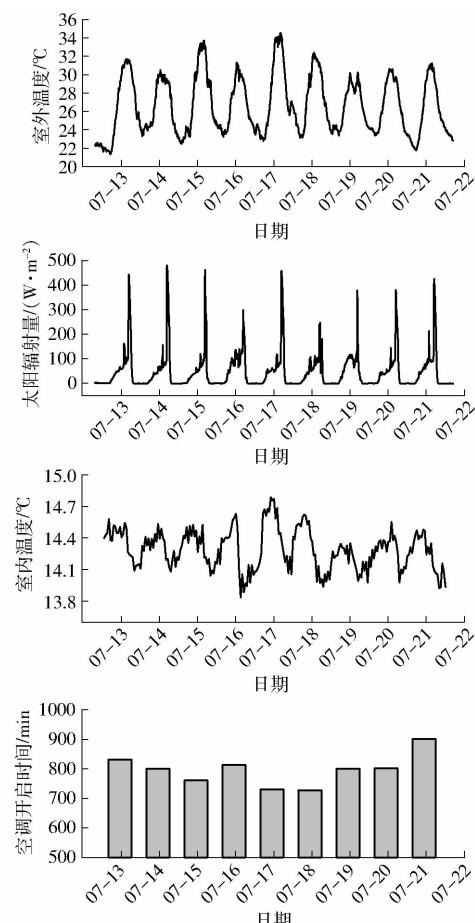


图2 环境测量数据

Fig. 2 Environmental meteorological data

差(Root mean square error, RMSE)、决定系数R²、平均绝对百分比误差(Mean absolute percentage error, MAPE)对精度进行衡量。

1.4 开发环境

本文试验所用计算机硬件配置如下: Intel(R) Core(TM) i7-11700F, 内存16 GB, 操作系统为64位Windows 11系统。软件框架结构为Keras深度学习工具,以Tensorflow 2.0.0深度学习框架作为后端支持,编程语言为Python(版本为3.6),集成开发环境(IDE)为Pycharm。

2 模型设计

2.1 预测模型

菇房空调系统可看为多输入单输出的非线性系统。假设系统的神经网络预测模型为

$$t(k+1) = f(t(k), d(k+1), u(k+1)) \quad (1)$$

式中 t —室内温度, ℃

u —控制量(空调开启时间), min

d —室外气象因素

k —采样周期数

本文以历史数据预测未来10 min时段内室内平均温度。

在确定好预测模型结构后,使用带精英策略的快速非支配排序遗传算法(NSGA-II)对模型的神经元数、学习率等超参数加以优化。以预测值与实际值的RMSE作为目标函数,此函数可表示为

$$j(x) = \text{RMSE}(x_1, x_2, \dots) \quad (2)$$

式中 x —需要优化的神经网络超参数

优化神经网络超参数使得预测值与实际值的RMSE最小,即计算 $j(x)$ 最小值。

2.2 滚动优化

通过菇房室内温度预测模型和参考轨迹建立目标函数

$$j(k) = \sum_{i=1}^N p(t_p(k+i) - t_c(k+i))^2 + \sum_{i=0}^{N-1} qu^2(k+i) \quad (3)$$

式中 p —温度误差(精度项)权重系数

q —控制量(能耗项)权重系数

t_c —设定温度(参考轨迹), $^{\circ}\text{C}$

N —控制时域

t_p —预测温度, $^{\circ}\text{C}$

式(3)等号右侧第1项为预测温度与参考轨迹的误差项即精度项,第2项为控制量能耗项。第1项最小化可以使预测温度与参考轨迹的误差最小,第2项最小化可以使在追踪参考轨迹时所消耗的能量最小。将预测模型的输入与输出通过迭代的方法代入到目标函数中并利用优化算法最小化目标函数,得出预测时域内的最优控制量,且只取第1个时间步下的控制量 $u(k)$ 作用于空调,以此循环往复实现滚动优化。

在优化算法选取方面,DE^[17]、粒子群优化算法(Particle swarm optimization, PSO)^[22]、遗传算法(Genetic algorithm, GA)^[23]与 NSGA-II^[26]等都可用于求解目标函数,在3.2节开展试验验证。

在控制时域选取方面,文献[15,17,27]在研究过程中发现MPC方法中控制时域会影响MPC的控制效果,计算量与 N^3 成正比。短控制时域下可减少计算资源,但控制效果非最优;长控制时域控制过程平缓且精度较好,但计算量也相应增大。综合考虑下,本文控制时域 N 选择为 5。

2.3 反馈校正

因预测误差和外部干扰因素,模型精度会逐渐劣化,本文从两方面进行反馈补偿:

(1) 基于预测误差反馈:在得到 $k+1$ 时刻的实际温度与预测温度后,利用二者误差进行反馈调节,预测误差计算公式为

$$t_p(k+1) - t_r(k+1) = e_{MPC}(k+1) \quad (4)$$

式中 t_r —实际温度, $^{\circ}\text{C}$

e_{MPC} —预测温度与实际温度的误差, $^{\circ}\text{C}$

利用此误差对下一预测时域中的预测温度进行反馈调节, $k+i$ 时刻校正后的预测温度计算公式为

$$t'_p(k+i) = t_p(k+i) + he_{MPC}(k+1) \quad (5)$$

式中 h —反馈校正系数

t'_p —校正后的预测温度, $^{\circ}\text{C}$

将校正后的预测温度代入到下一周期的代价函数中。

(2) 基于预测模型数据集更新:数据集由训练、验证与测试数据依次串联排列组成。因工厂海鲜菇实际出菇周期为 23 d,出菇净库后 3 d 用于消毒,无需空调调节,故以 23 d 为单元,固定总数据集长度为 3 312 条,后续以每天计动态更新。每天产生 144 条新数据后,将其置于测试数据集尾部,其余数据依次向上平移直至完成全部数据集更新。

3 结果与分析

3.1 预测模型选取

为研究常用时序预测模型在食用菌工厂菇房中适用性,分别利用 CNN(卷积神经网络)、LSTM、GRU 及 Attention 等神经网络^[28-36]预测室内温度,再通过评估模型性能指标,选出最适模型。其中,所有预测模型中预测时间步长为 3,并以 NSGA-II 为优化算法进行超参数优化。训练集、验证集与测试集分别占总数据的 80%、10%、10%。试验结果如表 2 所示。

表 2 不同预测模型性能比较

Tab. 2 Performance comparison of different prediction models

预测模型	RMSE/ $^{\circ}\text{C}$	R^2	MAPE/%	耗时/s
GRU	0.114	0.716	0.664	17
CNN-GRU	0.107	0.729	0.607	32
CNN-LSTM	0.109	0.740	0.592	33
GRU-Attention	0.108	0.744	0.620	18
CNN-GRU-Attention	0.090	0.824	0.499	35

由表 2 可知,CNN-GRU-Attention 模型预测精度最高,其 RMSE 与 GRU 模型相比降低 21%,与 CNN-GRU、CNN-LSTM、GRU-Attention 模型相比降低约 15%;CNN-GRU-Attention 模型运行时间,与 GRU、GRU-Attention 模型相比增加了约 100%,与 CNN-GRU、CNN-LSTM 模型相比无明显变化,这是由于 CNN 层中多重卷积计算复杂度远高于 Attention 层中的数乘运算,导致含有 CNN 层的模型

运行时间大幅增加。

因控制周期远高于预测模型运行耗时,而预测模型精度会直接影响控制效果^[15],故选取 CNN -

室外温度	太阳辐射量	室内温度	空调开启时间
$T(k-2)$	$F(k-2)$	$t(k-3)$	$u(k-2)$
$T(k-1)$	$F(k-1)$	$t(k-2)$	$u(k-1)$
$T(k)$	$F(k)$	$t(k-1)$	$u(k)$

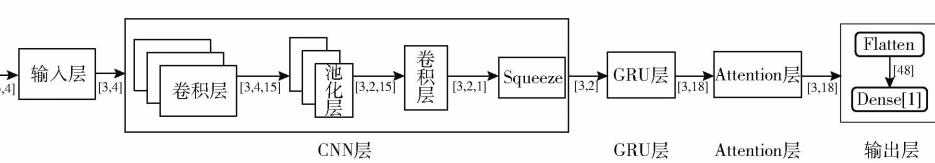


图 3 CNN - GRU - Attention 模型结构

Fig. 3 CNN - GRU - Attention model structure

(1) 输入层: 将室内温度、空调开启时间、室外温度、太阳辐射量预处理后再以时间步长 \times 特征向量的二维矩阵表示(数据维度为 [3,4]),并输入到预测模型中。

(2) CNN 层: 输入数据由第 1 卷积层(padding = same, stride = 1)运算处理同时抓取数据中时空维度特征后,数据维度变为 [3,4,15],再经池化处理,数据维度变为 [3,2,15]后送入第 2 层卷积层(padding = same, stride = 1)处理后,数据维度变为 [3,2,1],之后添加 1 层 Squeeze 层,将输出维度压缩至 [3,2],并输出到 GRU 层。2 层卷积层均使用 ReLU 为激活函数。

(3) GRU 层: 使用 L2 范式正则化防止模型过拟合。经处理后数据维度变为 [3,18]。

(4) Attention 层: Attention 层是通过加权的方式提高对重要信息的注意力。注意力机制的计算公式为

$$\text{Attention}((K, V), Q) = \alpha V \quad (6)$$

其中 $\alpha = \text{softmax}(F'(Q, K))$ (7)

式中 K, V, Q ——Key、Value、Query, 维度均为 [3, 18]

$F'(Q, K)$ ——Query 与 Key 的相似度, 由

Query 与 Key 经点积法计算出

(5) 输出层: Flatten 层将 Attention 层输出转换为全局特征后, 数据维度变为 [48], 再连接 1 层全连接层输出预测结果。

神经网络参数由 NSGA - II 算法明确, 优化对象为第 1 层卷积层中卷积核数量、GRU 层中神经元个数及模型学习率(取 0.1、0.01 或 0.001)。NSGA - II 算法各项参数设置如表 3 所示, 并设置随机种子固定模型训练过程中所产生的随机数, 保证模型运行结果具有可复现性。当迭代次数完成后, 输出令 $j(x)$ 最小的解。神经网络各项超参数如表 4 所示。

GRU - Attention 为预测模型。模型结构主要由输入层、CNN 层、GRU 层、Attention 层、输出层构成, 详细结构如图 3 所示。

表 3 NSGA - II 算法参数

Tab. 3 Parameters of NSGA - II algorithm

参数	数值
初代人口数量	20
子代人口数量	20
交叉概率	0.6
变异概率	0.1
迭代次数	5

表 4 神经网络超参数

Tab. 4 Neural network hyperparameters

参数	数值
第 1 层卷积核数量	15
第 1 层卷积核尺寸	3×3
池化核尺寸	1×2
第 2 层卷积核数量	1
第 2 层卷积核尺寸	3×3
GRU 神经元数量	18
学习率	0.001

3.2 优化算法选取

为选择合适的优化算法, 分别将 PSO、模拟退火算法(Simulated annealing, SA)、GA、DE、NSGA - II 等用于求解目标函数。假设函数温度误差权重系数和控制量权重系数分别为 10 和 0.01, 结果如表 5 所示。

表 5 不同优化算法的计算性能

Tab. 5 Calculation performance of different optimization algorithms

算法种类	种群规模	$j(k)$	程序运行时间/s
SA		0.328	364
PSO	70	0.159	312
GA	70	0.633	310
DE	70	0.341	622
NSGA - II	70	0.159	260

由表 5 可知, 在优化效果方面, NSGA - II 算法与 PSO 算法适应度最小。在程序运行时间方面, NSGA - II 算法明显优于其它算法, 与文献[37]结论

一致。

故本文优化算法选用 NSGA - II 算法, 具体流程如图 4 所示。NSGA - II 各项参数设置如表 6 所示, 并设置随机种子。迭代次数 Gen 达到最大迭代次数 maxGen 时输出最优解。

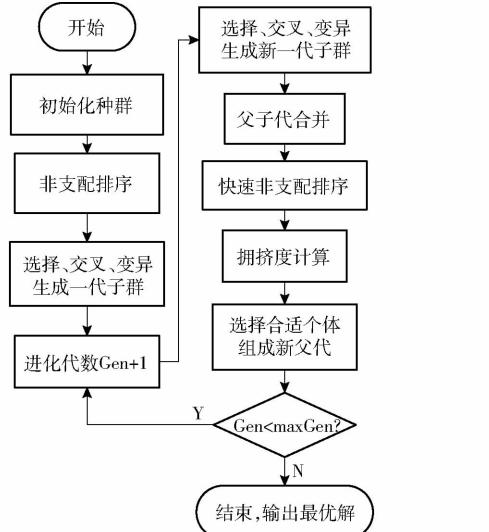


图 4 NSGA - II 算法流程图

Fig. 4 Flowchart of NSGA - II algorithm

表 6 NSGA - II 算法参数设置

Tab. 6 Parameters setting of NSGA - II algorithm

参数	数值
初代人口数量	70
子代人口数量	60
交叉概率	0.6
变异概率	0.1
迭代次数	40

3.3 预测时间步长选取

时间步长会影响预测模型精度和训练时间。为选择合适预测时间步长, 分别从时间步长为 1 ~ 10 (即历史时段 10 ~ 100 min) 中选取适宜参数。试验结果如图 5 所示, 时间步长在 1 ~ 5 范围内, 预测精度随着时间步长增加而提高; 时间步长为 6 时, 预测精度趋于稳定; 时间步长继续增长精度无明显上升。预测模型训练时间与预测时间步长成正比。故理论上时间步长为 6 为最佳选择, 但将其用于目标函数优化求解出的空调应开启时间为 0, 这是因为预测时间步长过长, 使得 k 时刻空调开启时间对 $k+1$ 时刻温度影响不显著, 导致式(3)温度误差部分和控制量部分经优化后均为 0, 与实际情况相悖。后经试验验证, 预测时间步长选择为 3, 即以 30 min 历史时段数据预测未来 10 min 时段内平均室内温度。

分别选择 6 月 15 日、7 月 20 日、8 月 24 日、9 月 1 日进行预测, 预测温度与实际温度拟合如图 6 所示, 最大误差为 0.45°C, 平均误差为 0.07°C, RMSE

最大为 0.122°C, R^2 最小为 0.807, MAPE 最大为 0.611%。

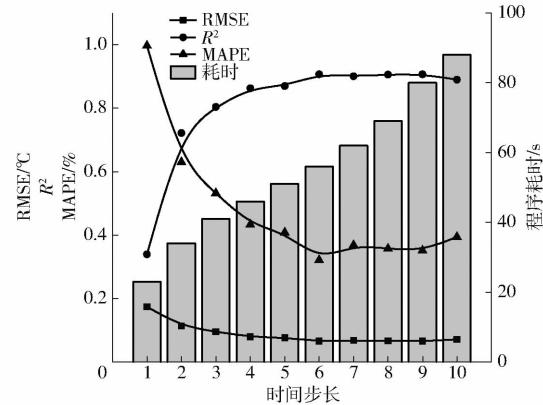


图 5 不同时间步长的精度对比

Fig. 5 Precision comparison of different time steps

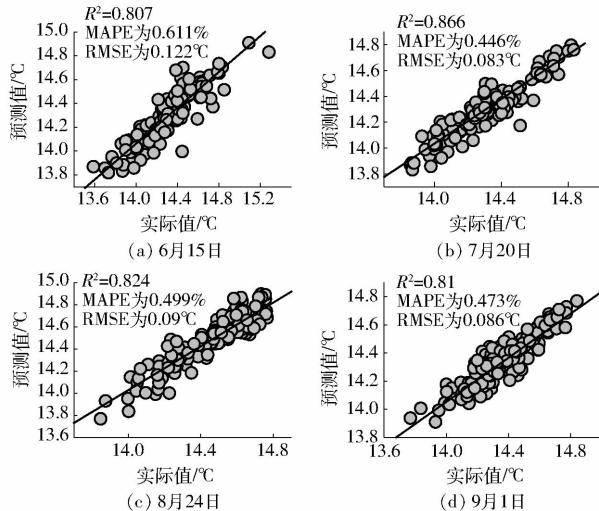


图 6 CNN - GRU - Attention 模型预测结果

Fig. 6 CNN - GRU - Attention model prediction result

3.4 目标函数权重选取

MPC 中的目标函数如式(3)所示, 是多目标求解问题, 此类问题通常通过设置权重转化为单目标问题, 确定权重是求解关键所在。熵权法是根据数据信息熵来确定权重, 具有客观性强的优势。主观法则取决于研究人员的先验知识。为研究不同权重赋值方法对优化求解的影响, 分别选用熵权法^[38]、主观法确定权重系数。

利用熵权法求解, 首先将目标函数还原为

$$j_1(k) = \sum_{i=1}^N (t_p(k+i) - t_e(k+i))^2 \quad (8)$$

$$j_2(k) = \sum_{i=0}^{N-1} u^2(k+i) \quad (9)$$

式中 j_1 ——精度项指标

j_2 ——能耗项指标

后续步骤如下:

(1) 使用 NSGA - II 求解出 $j_1(k)$ 、 $j_2(k)$ 的 Pareto 解集。

(2) 将 Pareto 解集进行归一化处理, 本文中两项指标均为负向指标, 所以归一化公式为

$$j'_{al} = \frac{\max\{j_{a1}, j_{a2}, \dots, j_{al}\} - j_{al}}{\max\{j_{a1}, j_{a2}, \dots, j_{al}\} - \min\{j_{a1}, j_{a2}, \dots, j_{al}\}} \quad (10)$$

式中 a ——指标数

l ——每项指标中的样本数

(3) 计算第 a 项指标下, 第 l 个样本所占比重 r_{al} , 公式为

$$r_{al} = \frac{j'_{al}}{\sum_{l=1}^{70} j'_{al}} \quad (11)$$

(4) 计算第 a 项指标熵 s_a , 公式为

$$s_a = -\frac{1}{\ln 70} \sum_{l=1}^{70} r_{al} \ln r_{al} \quad (12)$$

(5) 计算各项指标权重 w_a , 公式为

$$w_a = \frac{1 - s_a}{\sum_{a=1}^2 (1 - s_a)} \quad (13)$$

(6) 计算样本得分 g_l , 公式为

$$g_l = \sum_{a=1}^2 w_a j'_{al} \quad (14)$$

(7) 根据得分 g 最高样本得到对应空调控制量。

上述过程可表示为

$$j(k) = p j_1(k) + q j_2(k) \quad (15)$$

式(15)近似等于文献[10, 15]中使用权重为 $p = 10, q = 0.01$ 的主观法。

为进一步验证两种方法对控制效果的影响, 分别将熵权法与权重为 $p = 10, q = 0.01$ 的主观法进行对比试验, 以控制时域内室内温度和空调开启时间两方面为评价指标。由图 7a 可知, 主观法室内温度在 $14.465 \sim 14.667^\circ\text{C}$ 之间, $25\% \sim 75\%$ 在 $14.539 \sim 14.591^\circ\text{C}$ 之间, 中位数为 14.561°C , 平均值为 14.568°C ; 熵权法室内温度在 $14.409 \sim 14.715^\circ\text{C}$ 之间, $25\% \sim 75\%$ 在 $14.532 \sim 14.619^\circ\text{C}$ 间, 中位数与平均值均为 14.572°C 。可见以熵权法与确定权重的主观法进行控制时, 预期温度的统计指标差异极小。由图 7b 可知, 以熵权法确定权重对应的空调开启时间为 617 min ; 而以主观法确定权重对应的空调开启时间为 624 min , 二者差异约为 1% , 2 种权重赋值方法节能效果基本相同。在实际应用中, 熵权法比主观法所需计算开销大, 可先通过熵权法明确目标函数中权重, 再通过赋值权重以主观法来求解。

为进一步研究权重对控制精度和节能效果的影响, 以 $p = 10, q = 0.01$ 为中心, 通过固定 q , 改变 p 值

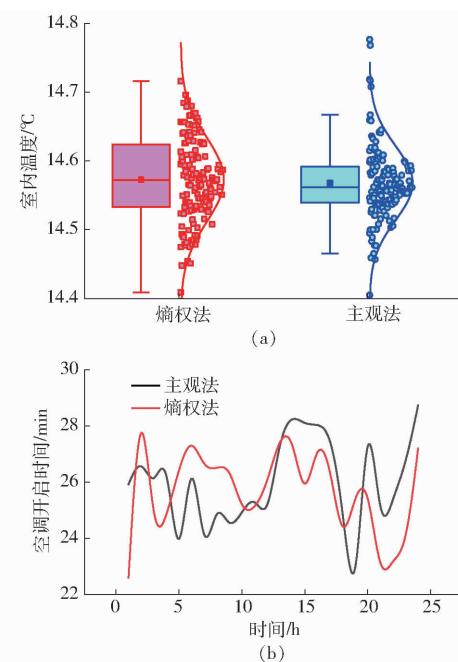


图 7 熵权法与主观法仿真对比

Fig. 7 Simulation comparison between entropy weight method and subjective method

开展仿真试验。设定室内温度为 $14 \sim 15^\circ\text{C}$, 以 8 月 24 日为例, 结果如表 7 所示。

表 7 不同权重影响下的 MPC 控制效果

Tab. 7 MPC control effect under influence of different weights

权重		空调开启时间/min	预期室温/°C
p	q		
1		547	14.910
2.5		564	14.718
4		605	14.613
10	0.01	624	14.568
50		634	14.515
150		666	14.506

由表 7 可知, 当 p 为 10 时, 当天室内平均温度为 14.568°C , 空调开启时间为 624 min , 室内平均温度与设定温度(14.5°C)偏差不超过 0.1°C 。随着 p 值增大, 空调需开启时间增加, 室内期望温度逼近设定值; 随着 p 值减小, 空调需开启时间减少, 室内温度逐渐偏离设定温度, 无法精准追踪参考轨迹, 这与文献[14, 15]结论一致。当海鲜菇在出菇后期, 对温度波动不敏感时, 可适当减小精度项权重以降低空调能耗。

3.5 模型天气抗干扰性评估

为评估 MPC 控制方法的抗干扰性能, 选取试验中室外温度波动最为剧烈的 7 月 17 日为测试对象, 并对其进行随机噪声。

据统计北京地区非极端天气条件下每小时最大温差为 $3 \sim 5^\circ\text{C}$, 故选择噪声波动范围 $-5^\circ \sim 5^\circ\text{C}$, 即

对室外温度引入范围为 $[-5^{\circ}\text{C}, 5^{\circ}\text{C}]$ 的噪声。室外温度与加入噪声的室外温度如图8a所示。

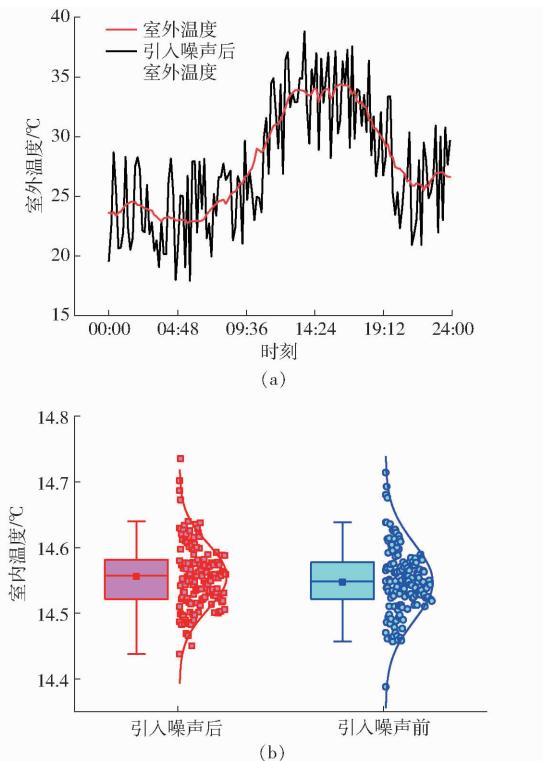


图8 不同室外温度下的仿真结果

Fig. 8 Simulation results at different outdoor temperatures

将两种情况分别代入所构建 MPC 控制方法进行仿真分析,结果如图8b所示。引入噪声前室内温度在 $14.457 \sim 14.638^{\circ}\text{C}$ 之间,25% ~ 75% 数据在 $14.521 \sim 14.577^{\circ}\text{C}$ 之间,中位数与平均值均为 14.540°C ;引入噪声后室内温度在 $14.438 \sim 14.640^{\circ}\text{C}$ 之间,25% ~ 75% 数据在 $14.521 \sim 14.582^{\circ}\text{C}$ 之间,中位数与平均值均为 14.556°C 。

由此可见,室外温度引入噪声前后室内温度无明显差异,本研究所构建的 MPC 方法在天气波动方面具有较好抗干扰能力。

3.6 MPC 方法控制效果评估

为验证所构建基于 CNN - GRU - Attention 的 MPC 方法控制效果,分别与阈值开关法、PID 方法进行比较。阈值开关方法设定温度范围为 $14 \sim 15^{\circ}\text{C}$;PID 采用传统位置式,控制周期为 1 min,比例参数 P 为 0.01、积分参数 I 为 -0.8、微分参数 D 为 0.01;目标温度与 MPC 相同,均为 14.5°C 。仍以 7 月 17 日为例,结果如图 9 所示。

图 9a 展示了阈值开关法、PID 法与 MPC 法控制菇房室内温度波动范围。其中,阈值开关控制室内温度在 $13.818 \sim 15.041^{\circ}\text{C}$ 之间,25% ~ 75% 数据在 $14.296 \sim 14.675^{\circ}\text{C}$ 之间,中位数为 14.526°C ,平均值为 14.474°C ;PID 控制在 $14.177 \sim 15.015^{\circ}\text{C}$ 之间,

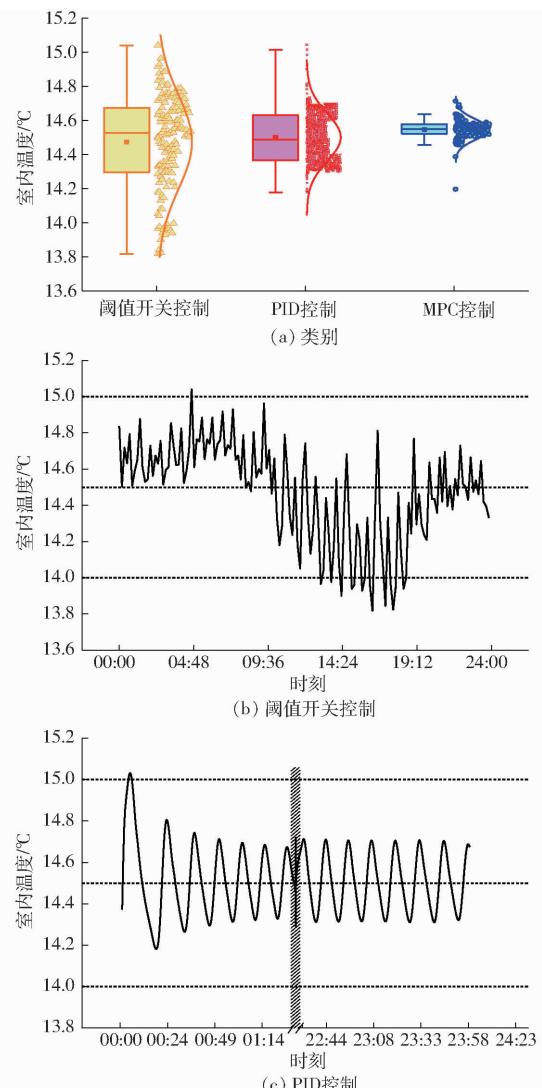


图9 阈值开关控制、PID 与 MPC 控制效果对比

Fig. 9 Comparison of threshold switch control, PID and MPC control effect

25% ~ 75% 数据在 $14.366 \sim 14.631^{\circ}\text{C}$ 之间,中位数与平均值分别为 14.488 、 14.501°C ;MPC 控制效果见图 8b 中引入噪声前所示,在菇房室内温度控制精度方面,MPC 法与阈值开关法和 PID 法相比 RMSE 降低 72% 和 46%,无超出设定温度范围现象。

为进一步评估 MPC 法控制效果性能,分别以时间为横坐标绘制阈值开关法与 PID 法控制下的室内温度,如图 9b、9c 所示。阈值开关法有 90 min 低于设定温度下限 14°C ,10 min 高于上限 15°C ;PID 法在前 20 min 温度波动大,存在超调现象,有近 2 min 超出了设定温度范围,1 h 后仍存在近 0.4°C 的波动。

图 10 为 3 种控制方法下空调开启时间,经统计 PID 法下空调开启时间为 672 min,阈值开关法则为 731 min。MPC 时间为 576 min,在能耗方面 MPC 相较于 PID 可节省 14% 的能耗;相较阈值开关控制则节省 21% 的能耗。

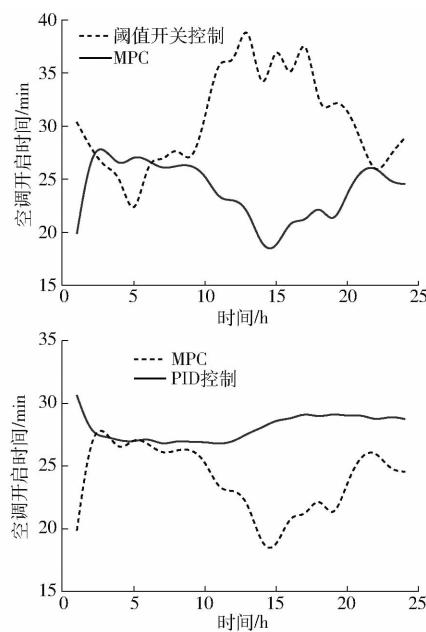


图 10 阈值开关控制、PID 控制与 MPC 空调开启时间对比

Fig. 10 Comparison of threshold switch control, PID and MPC air conditioner opening time

由此可知,所构建的 MPC 方法对设定温度跟踪能力强,不存在温度超调现象,同时节能效果也优于其它 2 种方法。

4 结论

(1) 提出了 CNN – GRU – Attention 菇房室内温度预测模型,明确了食用菌工厂菇房室内温度的预测模型以历史 30 min 数据预测未来 10 min 室内温度效果最好,并利用预测误差补偿和预测模型数据集动态更新,保证了较好的预测精度。试验表明, RMSE 最大为 0.122°C 、 R^2 最小为 0.807、MAPE 最大为 0.611%。

(2) 基于预测模型、滚动优化与反馈校正,设计了基于深度神经网络的数据驱动式 MPC 菇房空调模型预测控制方法,探明了目标函数中权重系数确定步骤,明确了权重系数对菇房室内温度控制精度和空调整能效果的影响规律。

(3) 所构建的 MPC 方法在天气波动方面具有较好的抗干扰能力,与当前食用菌工厂普遍使用的阈值开关、PID 方法相比,在控制温度精度方面, RMSE 分别降低 72% 和 46%。在空调整能方面,能耗分别节约 21% 和 14%。

(4) 本研究所提出的基于 CNN – GRU – Attention 菇房空调模型预测控制方法,可为工厂化菇房节能调控提供决策依据。

参 考 文 献

- [1] 闫华清,吴芳.中国食用菌出口特征、国际竞争力水平与贸易潜力分析[J].北方园艺,2022(19):142–150.
YAN Huaqing, WU Fang. Analysis of export characteristics, international competitiveness and trade potential of edible fungi in China[J]. Northern Horticulture, 2022(19):142–150. (in Chinese)
- [2] 曹斌.新时代背景下中国香菇消费市场发展特征与趋势[J].食用菌学报,2023,30(3):90–102.
CAO Bin. Characteristics and trends of shiitake mushroom consumption market in China in the new era[J]. Acta Edulis Fungi, 2023,30(3):90–102. (in Chinese)
- [3] KATHIRGAMANATHAN A, DE R M, MANGINA E, et al. Data-driven predictive control for unlocking building energy flexibility: a review[J]. Renewable and Sustainable Energy Reviews, 2021, 135: 110120.
- [4] SHAO J, HUANG Z, CHEN Y, et al. A practical application-oriented model predictive control algorithm for direct expansion (DX) air-conditioning (A/C) systems that balances thermal comfort and energy consumption[J]. Energy, 2023, 269: 126748.
- [5] GODOY J L, SCHIERLOH R M. Predictive management of the hybrid generation dispatch and the dispatchable demand response in microgrids with heating, ventilation, and air-conditioning (HVAC) systems[J]. Sustainable Energy, Grids and Networks, 2022, 32: 100857.
- [6] 赵洪山,赵慧.配电房温度的模型预测优化控制方法[J].电机与控制学报,2020,24(6):135–142.
ZHAO Hongshan, ZHAO Hui. Model prediction optimization control method for power distribution room temperature [J]. Electric Machines and Control, 2020, 24(6):135–142. (in Chinese)
- [7] 杨旭,苏啸天,涂壤,等.基于模糊区间优化的建筑空调系统预测控制方法[J].北京工业大学学报,2023,49(3):346–354.
YANG Xu, SU Xiaotian, TU Rang, et al. Method of model predictive control for building air-conditioning system based on fuzzy interval optimization[J]. Journal of Beijing University of Technology, 2023, 49(3):346–354. (in Chinese)
- [8] YANG S, MAN P W, BING F N, et al. Experimental study of model predictive control for an air-conditioning system with dedicated outdoor air system[J]. Applied Energy, 2020, 257: 113920.
- [9] WANG H, BO S, ZHU C, et al. A zoned group control of indoor temperature based on MPC for a space heating building[J]. Energy Conversion and Management, 2023, 290: 117196.
- [10] DRAGONA J, ARROYO J, CUPEIRO F I, et al. All you need to know about model predictive control for buildings[J]. Annual Reviews in Control, 2020, 50: 190–232.
- [11] 李卓阳,靳小龙,贾宏杰,等.考虑建筑物热动态特性的暖通空调模型预测控制方法[J].中国电机工程学报,2020,40(12):3928–3940.
LI Zhuoyang, JIN Xiaolong, JIA Hongjie, et al. Model predictive control method for the HVAC system of buildings considering the thermal dynamic characteristics of the envelope[J]. Proceedings of the CSEE, 20, 40(12):3928–3940. (in Chinese)
- [12] COLOMBO P, SCOCCIA R, APRILE M, et al. Minimalist RC network for building energy simulations: a case study based on OpenBPS[C]//E3S Web of Conferences. EDP Sciences, 2020, 197: 02005.

- [13] 周红标,张钰,柏小颖,等.基于自适应模糊神经网络的非线性系统模型预测控制[J].化工学报,2020,71(7):3201–3212.
ZHOU Hongbiao, ZHANG Yu, BAI Xiaoying, et al. Model predictive control of nonlinear system based on adaptive fuzzy neural network[J]. CIESC Journal, 2019, 71(7):3201 – 3212. (in Chinese)
- [14] 陈炯德,王子轩,姚晔,等.变风量空调系统用非线性模型预测控制方法研究[J].制冷学报,2019,40(6):62–69.
CHEN Jiongde, WANG Zixuan, YAO Ye, et al. Nonlinear model predictive control for a variable air volume air-conditioning system[J]. Journal of Refrigeration, 2019, 40(6):62 – 69. (in Chinese)
- [15] LEE H, HEO Y. Simplified data-driven models for model predictive control of residential buildings[J]. Energy and Buildings, 2022, 265: 112067.
- [16] AFRAM A, JANABI S F, FUNG A S, et al. Artificial neural network (ANN) based model predictive control (MPC) and optimization of HVAC systems: a state of the art review and case study of a residential HVAC system [J]. Energy and Buildings, 2017, 141: 96 – 113.
- [17] LEE D, OOKA R, IKEDA S, et al. Model predictive control of building energy systems with thermal energy storage in response to occupancy variations and time-variant electricity prices[J]. Energy and Buildings, 2020, 225: 110291.
- [18] JUNG D H, KIM H J, KIM J Y, et al. Model predictive control via output feedback neural network for improved multi-window greenhouse ventilation control[J]. Sensors, 2020, 20(6): 1756.
- [19] 高龙,杨奕,任晓琳,等.基于BP神经网络的空气源热泵温度 MPC 策略[J].控制工程,2021,28(9):1765 – 1772.
GAO Long, YANG Yi, REN Xiaolin, et al. MPC strategy of air source heat pump temperature based on BP neural network [J]. Control Engineering of China, 2019, 28(9):1765 – 1772. (in Chinese)
- [20] 魏东,焦焕炎,冯浩东.基于负荷预测的冷冻站系统非线性预测控制[J].控制理论与应用,2021,38(10):1619 – 1630.
WEI Dong, JIAO Huanyan, FENG Haodong. Nonlinear predictive control of refrigeration system based on load forecasting[J]. Control Theory & Applications, 2021, 38(10):1619 – 1630. (in Chinese)
- [21] CHEN Y, GAO J, YANG J, et al. An hour-ahead predictive control strategy for maximizing natural ventilation in passive buildings based on weather forecasting[J]. Applied Energy, 2023, 333: 120613.
- [22] JEON B K, KIM E J. LSTM-based model predictive control for optimal temperature set-point planning[J]. Sustainability, 2021, 13(2): 894.
- [23] COX S J, KIM D, CHO H, et al. Real time optimal control of district cooling system with thermal energy storage using neural networks[J]. Applied Energy, 2019, 238: 466 – 480.
- [24] 王阳,刘希喆.基于GRU-MPC的光储电站日前-日内两阶段优化控制[J].电力自动化设备,2022,42(10):177 – 183.
WANG Yang, LIU Xizhe. Day-ahead and intra-day two-stage optimal control of photovoltaic-energy storage charging station based on GRU – MPC[J]. Electric Power Automation Equipment, 2022, 42(10):177 – 183. (in Chinese)
- [25] SUN Y, HAGHIGHAT F, FUNG B C M. A review of the-state-of-the-art in data-driven approaches for building energy prediction[J]. Energy and Buildings, 2020, 221: 110022.
- [26] ASCIONE F, DE M R F, FESTA V, et al. Optimizing space cooling of a nearly zero energy building via model predictive control: energy cost vs comfort[J]. Energy and Buildings, 2023, 278: 112664.
- [27] LAGUNA G, MOR G, LAZZARI F, et al. Dynamic horizon selection methodology for model predictive control in buildings [J]. Energy Reports, 2022, 8: 10193 – 10202.
- [28] 赵全明,宋子涛,李奇峰,等.基于CNN-GRU的菇房多点温湿度预测方法研究[J].农业机械学报,2020,51(9):294 – 303.
ZHAO Quanming, SONG Zitao, LI Qifeng, et al. Multi-point prediction of temperature and humidity of mushroom based on CNN – GRU[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(9):294 – 303. (in Chinese)
- [29] SAJJAD M, KHAN Z A, ULLAH A, et al. A novel CNN – GRU-based hybrid approach for short-term residential load forecasting[J]. IEEE Access, 2020, 8: 143759 – 143768.
- [30] HOU J, WANG Y, ZHOU J, et al. Prediction of hourly air temperature based on CNN – LSTM [J]. Geomatics, Natural Hazards and Risk, 2022, 13(1): 1962 – 1986.
- [31] 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): 2166235.
- [32] HE Z, LIN R, WU B, et al. Pre-attention mechanism and convolutional neural network based multivariate load prediction for demand response[J]. Energies, 2023, 16(8): 3446.
- [33] ELMAZ F, EYCKERMAN R, CASTEELS W, et al. CNN – LSTM architecture for predictive indoor temperature modeling[J]. Building and Environment, 2021, 206: 108327.
- [34] 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. Research on 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)
- [35] 祖林禄,柳平增,赵妍平,等.基于SSA-LSTM的日光温室环境预测模型研究[J].农业机械学报,2023,54(2):351 – 358.
ZU Linlu, LIU Pingzeng, ZHAO Yanping, et al. Solar greenhouse environmental prediction model based on SSA – LSTM [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(2):351 – 358. (in Chinese)
- [36] 杜柳青,李仁杰,余永维.基于注意力机制的时空卷积数控机床热误差模型研究[J].农业机械学报,2021,52(5):404 – 411.
DU Liqing, LI Renjie, YU Yongwei. Spatiotemporal convolution thermal error model of CNC machine tools based on attention mechanism[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(5):404 – 411. (in Chinese)
- [37] DENG W, ZHANG X, ZHOU Y, et al. An enhanced fast non-dominated solution sorting genetic algorithm for multi-objective problems[J]. Information Sciences, 2022, 585: 441 – 453.
- [38] XU J, ZHANG N, WANG J, et al. Multi-objective adaptive cruise control optimization algorithm for electric vehicles based on model predictive control[C]//2022 6th CAA International Conference on Vehicular Control and Intelligence (CVCI), 2022: 1 – 6.