

doi:10.6041/j.issn.1000-1298.2023.07.038

# 猪舍氨气与二氧化碳浓度变化时序预测模型优化

谢秋菊<sup>1</sup> 马超凡<sup>1</sup> 王圣超<sup>1</sup> 包军<sup>2,3</sup> 刘洪贵<sup>2,4</sup> 于海明<sup>1</sup>

(1. 东北农业大学电气与信息学院, 哈尔滨 150030; 2. 东北农业大学动物科技学院, 哈尔滨 150030;

3. 农业农村部生猪养殖设施工程重点实验室, 哈尔滨 150030;

4. 教育部北方寒区智能化繁育与养殖工程研究中心, 哈尔滨 150030)

**摘要:** NH<sub>3</sub>质量浓度和CO<sub>2</sub>质量浓度是猪舍环境精准控制的重要指标。由于畜禽舍气体浓度具有时变性、非线性耦合等特点,目前有害气体浓度预测模型存在预测精度低的问题。提出了基于门控循环单元(Gated recurrent unit, GRU)、改进麻雀搜索算法(Improved sparrow search algorithm, ISSA)并融合差分整合移动平均自回归模型(Autoregressive integrated moving average model, ARIMA)的有害气体浓度时序数据预测模型ISSA-GRU-ARIMA。首先构建了GRU气体浓度时序预测模型,然后通过引入Tent混沌序列、混沌扰动和高斯变异增强ISSA算法的局部寻优能力,实现GRU模型超参数优化;然后利用统计学习ARIMA方法提取优化后的ISSA-GRU模型预测残差的线性特征,最终达到提升模型预测精度的目的。以采集的52 d猪舍环境的1248组数据对模型进行训练和测试。结果表明,ISSA-GRU-ARIMA模型NH<sub>3</sub>质量浓度预测的均方根误差(RMSE)、平均绝对百分比误差(MAPE)和决定系数R<sup>2</sup>分别为0.263 mg/m<sup>3</sup>、8.171%和0.928,CO<sub>2</sub>质量浓度预测的分别为55.361 mg/m<sup>3</sup>、4.633%和0.985。本文构建的ISSA-GRU-ARIMA模型具有较高的预测精度,可为猪舍有害气体浓度精准控制提供科学依据。

**关键词:** 猪舍空气质量; 环境控制; 时序预测; 残差

中图分类号: TP391 文献标识码: A 文章编号: 1000-1298(2023)07-0381-11

OSID:



## Optimal Prediction Model for Gas Concentrations of NH<sub>3</sub> and CO<sub>2</sub> Time-series in Pig House

XIE Qiuju<sup>1</sup> MA Chaofan<sup>1</sup> WANG Shengchao<sup>1</sup> BAO Jun<sup>2,3</sup> LIU Honggui<sup>2,4</sup> YU Haiming<sup>1</sup>

(1. College of Electrical and Information, Northeast Agricultural University, Harbin 150030, China

2. College of Animal Science and Technology, Northeast Agricultural University, Harbin 150030, China

3. Key Laboratory of Swine Facilities Engineering, Ministry of Agriculture and Rural Affairs, Harbin 150030, China

4. Engineering Research Center of Pig Intelligent Breeding and Farming in Northeast Cold Region,  
Ministry of Education, Harbin 150030, China

**Abstract:** Concentrations of ammonia and carbon dioxide are important indicators for indoor environment control in pig house. Due to the time-varying and nonlinear coupling characteristics of gas concentration, the prediction accuracy of pig house environment prediction models is still relatively low. Aiming to achieve the precision control for gases concentration in pig house, a time-series data prediction model named ISSA-GRU-ARIMA for harmful gas concentrations was proposed based on gated recurrent unit (GRU), improved sparrow search algorithm (ISSA) fused with autoregressive integrated moving average model (ARIMA). Firstly, a GRU gas concentration time series prediction model was constructed, and Tent chaotic sequence, chaotic disturbance and Gaussian mutation were introduced to enhance the local optimization ability of ISSA algorithm and optimize the hyperparameters of GRU model; then the statistical learning ARIMA method was used to extract the linear features of the optimized ISSA-GRU model's prediction residuals in order to improve the prediction accuracy of the model. A dataset with 1 248

收稿日期: 2023-04-21 修回日期: 2023-05-11

基金项目: 国家自然科学基金面上项目(32072787)、东北农业大学东农学者计划项目(19YJXG02)和黑龙江省博士后资助项目(LBH-Q21070)

作者简介: 谢秋菊(1976—),女,教授,博士生导师,主要从事猪舍环境控制及智慧养殖关键技术研究,E-mail: xqj197610@163.com

通信作者: 于海明(1973—),男,教授,主要从事智慧养殖设施工程技术研究,E-mail: yhm1973@163.com

environment data that collected for 52 d was used for model training and testing. It was shown that the RMSE, MAPE and  $R^2$  of ISSA - GRU - ARIMA model for ammonia concentration prediction were 0.263 mg/m<sup>3</sup>, 8.171% and 0.928, respectively, and those for carbon dioxide concentration prediction were 55.361 mg/m<sup>3</sup>, 4.633% and 0.985, respectively. The constructed ISSA - GRU - ARIMA had high predictive performance, it can provide scientific basis for accurate control of harmful gases in pig house.

**Key words:** air quality in pig house; environmental control; time-series prediction; residual

## 0 引言

猪舍空气质量是影响生猪呼吸道健康的关键因素,是猪舍环境控制关注的热点之一。在生猪养殖过程中,猪呼吸产生的 CO<sub>2</sub>、猪粪尿等排泄物和饲料残渣分解产生的 NH<sub>3</sub>、H<sub>2</sub>S、CH<sub>4</sub>等有害气体对猪的生长、繁殖、健康造成极大危害。其中 NH<sub>3</sub>与 CO<sub>2</sub>的气体浓度备受关注。因为 NH<sub>3</sub>是一种无色具有刺激气味的有害气体,不同浓度的 NH<sub>3</sub>会对猪的呼吸系统、黏膜等造成不同程度的损伤,并且 NH<sub>3</sub>排放还会造成周围环境污染<sup>[1]</sup>;猪舍中的 CO<sub>2</sub>浓度是衡量猪舍内空气质量状况的重要标志,它主要来自于猪的呼吸,舍内 CO<sub>2</sub>浓度过高不仅会造成猪头昏和生产性能下降,更有可能对猪造成生命威胁<sup>[2]</sup>。因此,对猪舍中 NH<sub>3</sub>和 CO<sub>2</sub>这两种气体浓度进行监测与控制,是实现猪舍环境控制的重要任务。通过大量的现场实验得出,在猪舍内进行一系列控制,例如开启风机 1 h,舍内的温湿度、气体浓度会有较明显的变化。通过对舍内气体浓度变化进行预测,可以实现猪舍环境控制设备运行状态的提前调控,从而弥补在猪舍环境实际控制过程中的环境控制效果滞后的问题。

目前,畜禽舍内有害气体浓度变化模型主要有两种,一种是基于理化统计的模型,这类模型通过对气体的产生机理或者不同影响因素进行分析构建预测模型,例如:文献[3]在多种不同空气温度和空气湿度组合下连续测量多天粪便的 NH<sub>3</sub>排放构建鸡粪 NH<sub>3</sub>排放模型;文献[4]通过对多种不同地板类型的猪舍的 NH<sub>3</sub>排放进行检测和分析,得到不同地板类型猪舍的 NH<sub>3</sub>排放系数。这些模型测量方法较复杂且受实际畜禽舍结构影响大,实用性较差。另一种是基于人工智能算法的预测模型,例如,基于支持向量回归机(Support vector regression, SVR)、随机森林(Random forest, RF)、极限随机树(Extra tree, ET)等传统机器学习算法构建的预测模型<sup>[5-7]</sup>,基于卷积神经网络(Convolutional neural networks, CNN)、GRU 等深度学习算法构建的预测模型<sup>[2,8-13]</sup>,将自回归模型(Autoregressive model, AR)、ARIMA 等统计学习算法与机器学习算法互相结合的混合预测模

型<sup>[5,14-15]</sup>。与传统理化统计模型相比,基于人工智能算法的模型具有预测精度高,可更好地提取气体浓度变化特征的优点,已成为畜禽舍气体环境控制领域研究的热点。

畜禽舍内有害气体浓度随时间不断变化,具有典型的时序序列数据的特征<sup>[9]</sup>。在众多的智能预测算法中,GRU 模型不仅擅长提取时间序列中非线性长期依赖关系且训练速度较快。因此,许多学者关注 GRU 模型对时间序列数据的预测<sup>[16-17]</sup>,同时探索将 CNN、注意力机制与 GRU 模型相融合的混合网络模型<sup>[9]</sup>,以提高时序序列数据的关键特征及信息提取能力。在时序序列数据预测神经网络模型中,超参数是影响模型性能的重要因素。然而,依据传统经验选取超参数往往较难取得良好效果。因此,学者们开始尝试使用麻雀搜索算法(Sparrow search algorithm, SSA)、粒子群优化算法(Particle swarm optimization, PSO)、灰狼优化算法(Grey wolf optimization, GWO)等优化算法进行神经网络超参数寻优<sup>[2,18-24]</sup>,来提升网络模型预测性能。研究表明,通过模拟麻雀种群觅食和躲避天敌的行为而提出的麻雀搜索算法<sup>[21]</sup>,其搜索精度和收敛速度均优于 PSO、GWO 和遗传算法(Genetic algorithm, GA),但是 SSA 仍然存在容易陷入局部最优的问题<sup>[23]</sup>,进而导致模型预测精度低。

为了解决当前有害气体浓度预测模型存在的预测精度低的问题,本文构建基于 ISSA - GRU - ARIMA 的猪舍有害气体浓度预测模型,该模型使用改进麻雀搜索算法对 GRU 模型超参数进行寻优,以提升 GRU 模型非线性拟合能力,同时融合 ARIMA 模型对时间序列模型的残差序列信息进一步提取以提高模型预测精度。

## 1 材料与方法

### 1.1 数据来源

#### 1.1.1 猪舍结构

本文数据来源于黑龙江省哈尔滨市尚志市亚布力惊哲养殖基地(44.78°N, 128.47°E)的一个妊娠母猪舍,猪舍地面是水泥漏粪地板。猪舍尺寸为 19.5 m × 10.5 m × 2.4 m,限位栏尺寸为 2.2 m × 0.65 m × 1 m。猪舍采用机械通风,一侧墙上安装了

3 个风机, 风机 1 (fan1) 和风机 2 (fan2) 尺寸均为  $0.8 \text{ m} \times 0.8 \text{ m}$ , 额定功率为  $0.37 \text{ kW}$ , 风机 3 (fan3) 尺寸为  $1 \text{ m} \times 1 \text{ m}$ , 额定功率为  $0.55 \text{ kW}$ 。舍内饲养有 37 头妊娠母猪, 猪平均质量约为  $165 \text{ kg}$ , 猪舍现场如图 1 所示, 平面结构如图 2 所示。



图 1 猪舍现场图

Fig. 1 Scene drawing of pig house

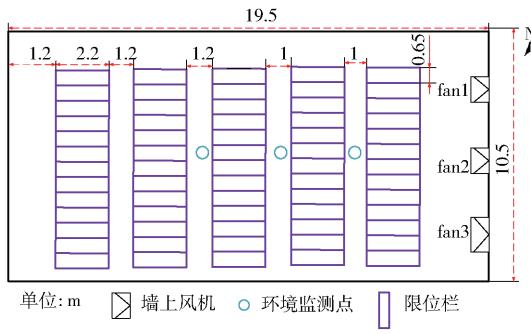


图 2 猪舍平面结构图

Fig. 2 Plane structure diagram of pig house

### 1.1.2 猪舍环境监测

猪舍内安装了基于物联网系统的自动环境监测及控制器, 该控制器以 STM32F103VET6 芯片为核心。在猪舍内设有 3 个环境监测点, 每个监测点分别安装有温湿度、 $\text{NH}_3$  质量浓度、 $\text{CO}_2$  质量浓度传感器, 传感器距离地面高度为  $1.6 \text{ m}$ , 将 3 个环境监测点监测数据的平均值作为舍内温湿度、 $\text{NH}_3$  质量浓度、 $\text{CO}_2$  质量浓度取值。舍外布置 1 个温湿度传感器对舍外温湿度进行实时监测, 3 个压差传感器分别布置在 3 个风机正上方, 对墙上风机承受的压力差进行监测, 环境数据采样时间间隔为  $1 \text{ min}$ , 采集到的环境数据通过 Wi-Fi 模块上传至物联网云平台, 传感器输出信号类型均为 RS-485, 通信协议为 Modbus, 传感器具体参数如表 1 所示。通风速率通过持续监测风机运行时间、风机承受的压差变化以及现场实验数据拟合线性方程<sup>[25]</sup>计算得到, 公式为

$$V = (0.5342P_1 + 112.9)e_1 + (0.5217P_2 + 106.5)e_2 + (0.6268P_3 + 213.6)e_3 \quad (1)$$

式中  $P_i$  —— 风机  $i$  所承受的压差,  $\text{Pa}, i = 1, 2, 3$

$e_i$  —— 风机  $i$  在  $1 \text{ min}$  内运行的时间占比, %

$V$  —— 猪舍风机通风速率,  $\text{m}^3/\text{min}$

猪舍投喂饲料和清理粪便均采用人工的方式, 其中,

表 1 传感器技术参数

Tab. 1 Sensor technical parameters

检测指标	量程	精度	传感器型号	品牌
温度/℃	-40~60	±0.5	VMS-3002-WS-N01	威盟士
相对湿度/%	0~100	±3	VMS-3002-WS-N01	威盟士
$\text{NH}_3$ 质量浓度/( $\text{mg} \cdot \text{m}^{-3}$ )	0~50	±2.5	VMS-3002-NH <sub>3</sub> -N01-50P-2	威盟士
$\text{CO}_2$ 质量浓度/( $\text{mg} \cdot \text{m}^{-3}$ )	0~10 000	±300	VMS-3002-CO <sub>2</sub> -N01	威盟士
压差/Pa	-500~500	5	CCY16	星仪

喂食时间为每日 08:00—08:30 和 14:00—14:30, 清粪时间为每日 08:30—09:00 和 14:30—15:00。

### 1.2 模型开发环境

本文模型开发硬件环境为 Intel core i7 12700H 处理器, Nvidia RTX3070 显卡, Windows 11 64 位操作系统。模型算法开发采用 Python 3.7 编程语言结合 Tensorflow 框架和 sklearn 框架。

### 1.3 气体浓度预测优化模型构建

本文构建以 GRU 模型为核心的时序数据预测模型, 提取猪舍环境数据的非线性特征, 然后建立改进的麻雀搜索算法对 GRU 模型的超参数进行优化, 提升 GRU 模型的非线性特征拟合能力, 再利用 ARIMA 模型的线性数据拟合能力来提取残差数据的线性特征。建立的 ISSA-GRU-ARIMA 模型结合了 ISSA 的寻优能力、GRU 的非线性处理能力和

ARIMA 的线性处理能力, 提升了模型的预测精度。将舍内温度、舍内相对湿度、舍外温度、舍外相对湿度、 $\text{CO}_2$  质量浓度、 $\text{NH}_3$  质量浓度、通风速率的数据序列作为 ISSA-GRU-ARIMA 模型输入, 模型输出为 2 个值, 分别是  $1 \text{ h}$  后的  $\text{CO}_2$  质量浓度和  $\text{NH}_3$  质量浓度。优化模型构建过程如下:

(1) 将预处理后的环境数据划分为训练集 1、训练集 2 和测试集 3 部分, 在训练集 1 上对 GRU 模型进行训练, 然后通过 ISSA 算法对模型超参数进行寻优得到最优 GRU 模型, 命名为 ISSA-GRU 模型。

(2) 使用 ISSA-GRU 模型对训练集 2 上的气体浓度进行预测, 分别得到  $\text{NH}_3$  质量浓度、 $\text{CO}_2$  质量浓度的观测值与预测值之间的残差序列  $D_{\text{NH}_3}$  和  $D_{\text{CO}_2}$ 。

(3) 以残差序列  $D_{\text{NH}_3}$  和  $D_{\text{CO}_2}$  作为数据集构建 ARIMA 模型, ARIMA 模型可以提取  $D_{\text{NH}_3}$  和  $D_{\text{CO}_2}$  的

变化规律。

(4) 构建 ISSA - GRU - ARIMA 模型对未来时刻的有害气体浓度进行预测, 在测试集上对 ISSA - GRU - ARIMA 模型预测精度进行测试。

### 1.3.1 数据预处理及数据集划分

选取从 2022 年 8 月 10 日到 9 月 30 日共 52 d 的环境数据(舍内温度、舍内相对湿度、舍外温度、舍外相对湿度、CO<sub>2</sub>质量浓度、NH<sub>3</sub>质量浓度、通风速率)作为实验数据。对于传感器采集的极个别时刻的缺失值采用线性插值法进行补全;然后采取拉伊达准则对数据进行处理剔除其中的异常值, 异常值被替换为相邻数据的平均值。

1 h 内环境因素变化较小, 因此将时间间隔为 1 min 的数据平均化处理为时间间隔为 60 min 的数据, 共得到 1 248 组数据。为了消除量纲的差异, 将数据输入模型前需要进行归一化, 模型预测结果需

要进行反归一化。

通过滑动窗口构建数据集, 使用前 3 h 的数据序列对后 1 h 的有害气体质量浓度进行预测。将实验数据划分为训练集 1、训练集 2 和测试集 3 部分, 各部分占比分别是 70%、20.4% 和 9.6%。训练集 1 用于 ISSA - GRU 模型训练, 训练集 2 用于 ISSA - GRU - ARIMA 模型拟合, 最后使用测试集对 ISSA - GRU - ARIMA 模型进行测试。

### 1.3.2 气体质量浓度预测 GRU 非线性模型

猪舍环境具有时序性、非线性、相互耦合的特性<sup>[8]</sup>, 尤其是舍内 NH<sub>3</sub>质量浓度与 CO<sub>2</sub>质量浓度受多因素条件影响, 因此需要构建具有较强的非线性拟合能力和最大限度地提取时序数据特征的 GRU 神经网络模型来预测气体质量浓度变化。本文构建的 GRU 神经网络模型由输入层、隐藏层和全连接层 3 部分组成, 其结构如图 3 所示。

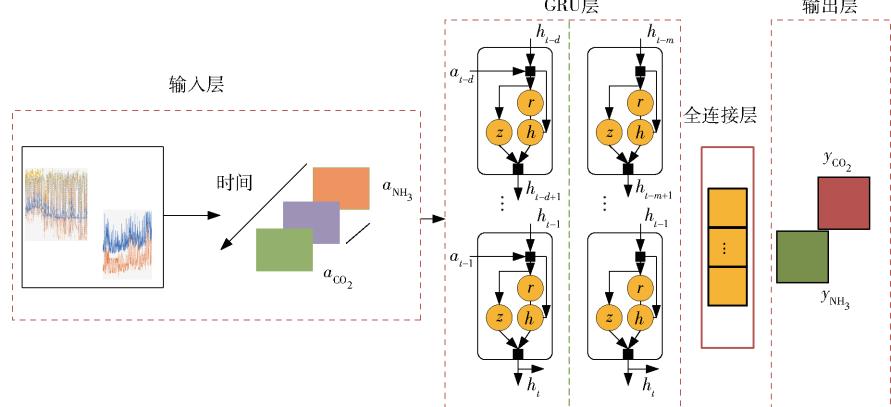


图 3 GRU 神经网络结构

Fig. 3 Neural network structure of GRU

输入层接收到舍内温度、舍内相对湿度、舍外温度、舍外相对湿度、CO<sub>2</sub>质量浓度、NH<sub>3</sub>质量浓度、通风速率时序数据, 然后按照公式

$$z'_i = \frac{z_i - z_{\min}}{z_{\max} - z_{\min}} \quad (2)$$

式中  $z_i$  —— 输入的环境数据

$z'_i$  —— 归一化后的环境数据

$z_{\max}$  —— 输入环境数据最大值

$z_{\min}$  —— 输入环境数据最小值

进行归一化, 归一化后的数据直接传入隐藏层。

隐藏层由 2 个 GRU 子层组成。两个 GRU 子层的神经元数量分别为 486 和 315, GRU 神经网络单元使用更新门和重置门两个门来实现信息的记忆和传递<sup>[16]</sup>, 如图 4 所示。更新门  $z_t$  决定当前节点的新增历史信息比例, 从而可以捕捉序列数据的短期依赖关系; 重置门  $r_t$  决定抛弃历史信息的比例, 可以更好地提取序列数据的长期依赖关系。时序序列多环境因子之间依赖关系的计算公式为

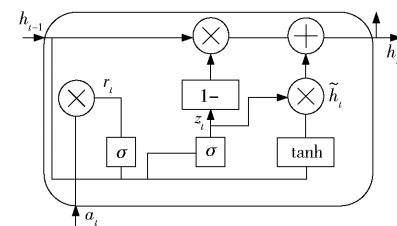


图 4 GRU 神经单元结构

Fig. 4 Cell structure of GRU

$$r_t = \sigma(W_r [h_{t-1}, a_t] + b_r) \quad (3)$$

$$z_t = \sigma(W_z [h_{t-1}, a_t] + b_z) \quad (4)$$

$$\tilde{h}_t = \tanh(W_h [r_t h_{t-1}, a_t] + b_h) \quad (5)$$

$$h_t = (1 - z_t) h_{t-1} + z_t \tilde{h}_t \quad (6)$$

式中  $a_t$  —— 当前单元输入值

$h_{t-1}$  —— 上一神经单元状态

$h_t$  —— 输出状态  $\tilde{h}_t$  —— 当前隐藏状态

$W_r, W_z, W_h$  —— 重置门、更新门、当前隐藏状态的权值

$b_r, b_z, b_h$ ——重置门、更新门、当前隐藏状态的偏置值  
 $\sigma$ ——sigmod 激活函数

全连接层每一个结点都与 GRU 子层的所有结点相连, 通过 GRU 子层学习到的特征传入全连接层。全连接层经过非线性变换提取数据之间的依赖关系并输出预测值, 最后按照式(2)对输出进行反归一化, 全连接层的输出为  $\text{NH}_3$  质量浓度预测值和  $\text{CO}_2$  质量浓度预测值。

GRU 神经网络使用均方误差(MSE)作为损失函数, 通过 MSE 计算误差后反向传播, 然后通过 Adam 优化器根据误差不断优化权重, 最终得到预测精度较高的模型。

### 1.3.3 改进麻雀搜索算法

由于 GRU 预测模型的超参数众多, 这些参数对网络模型的性能影响较大, 因此需要对 GRU 网络模型超参数进行优化, 以获得最佳的模型性能。SSA 是一种模拟麻雀觅食和躲避天敌行为而提出的群智能优化算法<sup>[21]</sup>, 具有较好的全局探索能力和较快的收敛速度<sup>[22]</sup>, 有助于 GRU 预测模型对超参数进行寻优, 但是 SSA 存在容易陷入局部最小值的问题。

混沌序列具有规律性、遍历性和随机性, 将其用于搜索算法可以有效提升寻优效果, 在混沌序列中, Tent 序列相比常用的 Logistic 序列分布更加均匀且收敛速度更快; Tent 混沌序列可以用于种群初始化以提高种群多样性<sup>[26]</sup>, 还可以对局部极值进行扰动以扩大搜索空间, 从而有利于算法跳出局部最优<sup>[24]</sup>; 高斯分布在期望附近概率最大, 引入高斯变异可以对原始解周围进行重点搜索。因此, 本文使用混沌序列、高斯变异和混沌扰动对麻雀搜索算法进行改进, 来提升初始解分布的均匀性及局部寻优效果, 得到改进的麻雀搜索算法。在 ISSA 中, 一只麻雀代表一组解, 包含时间窗口、学习率、批数目、第 1 层 GRU 子层神经元个数和第 2 层 GRU 子层神经元个数这些需要搜索的超参数, 麻雀个数代表解的个数。ISSA 算法步骤如下:

#### (1) 使用公式

$$S_{i+1} = (2S_i) \bmod 1 + \text{rand}(0, 1) \frac{1}{O} \quad (7)$$

式中  $O$ ——粒子数量

$\text{rand}(0, 1)$ —— $[0, 1]$  范围内的随机数

产生 Tent 混沌序列  $S$  对种群进行初始化, 然后使用公式

$$X_{\text{new}}^{(u)} = u_{\min} + (u_{\max} - u_{\min}) S_u \quad (8)$$

式中  $X_{\text{new}}^{(u)}$ ——解序列的第  $u$  维变量

$u_{\min}$ ——解序列第  $u$  维变量的最小值

$S_u$ ——混沌序列的第  $u$  维变量

$u_{\max}$ ——解序列第  $u$  维变量的最大值

将其映射到原始解空间, 产生的解维度为 5, 个数为 10。

(2) 计算种群中所有个体的适应度  $f_i$ , 并对其进行排序, 适应度是评判解优劣的指标, 本实验适应度函数设置为均方误差, 适应度越低表明优化算法搜索到的解越优秀。

(3) 根据适应度选出发现者和捕食者, 然后分别按照公式

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j}^t \exp \left( \frac{-i}{\alpha \text{iter}_{\max}} \right) & (R_2 < S_T) \\ X_{i,j}^t + QL & (R_2 \geq S_T) \end{cases} \quad (9)$$

其中  $\alpha \in (0, 1)$   $S_T \in [0.5, 1]$   $R_2 \in [0, 1]$

式中  $t$ ——迭代次数

$\text{iter}_{\max}$ ——最大迭代次数

$\alpha$ ——随机数

$X_{i,j}$ ——第  $i$  个解在第  $j$  维的位置信息

$S_T$ ——预警值

$R_2$ ——安全值, 当  $R_2 < S_T$  时, 此位置安全, 发现者可以继续进行搜索, 当  $R_2 \geq S_T$  时, 此位置危险, 麻雀中警戒者发出预警, 所有麻雀更换到其他位置进行觅食

$Q$ ——符合正态分布的随机数

$L$ ——元素都为 1 的  $1 \times u$  的矩阵

$$X_{i,j}^{t+1} = \begin{cases} Q \exp \left( \frac{X_{\text{worst}}^t - X_{i,j}^t}{i^2} \right) & \left( i > \frac{n}{2} \right) \\ X_p^{t+1} + |X_{i,j}^t - X_p^{t+1}| C^+ L & \left( 0 \leq i \leq \frac{n}{2} \right) \end{cases} \quad (10)$$

其中  $C^+ = C^T (CC^T)^{-1}$

式中  $X_p$ ——当前发现者最优位置

$X_{\text{worst}}$ ——全局最差位置

$C$ ——元素为 1 或 -1 的  $1 \times u$  的矩阵且当

$i > \frac{n}{2}$  时, 第  $i$  只捕食者适应度较低, 需要改变位置

对其位置进行更新。

(4) 随机选取种群中一定比例的个体作为警戒者, 并按照公式

$$X_{i,j}^{t+1} = \begin{cases} X_g^t + \beta (X_{i,j}^t - X_g^t) & (f_i > f_g) \\ X_{i,j}^t + K \frac{X_{i,j}^t - X_{\text{worst}}^t}{f_i - f_{\text{worst}} + \varepsilon} & (f_i = f_g) \end{cases} \quad (11)$$

式中  $X_g$ ——全局最优位置

$f_g$ ——全局最佳适应度,  $f_i > f_g$  表示麻雀处于

边缘位置且容易被天敌发现,  $f_i = f_g$  表示警戒者发现了敌人, 需要前往安全位置

$\beta$ —服从均值为 0、方差为 1 的正态分布的随机数, 用于控制步长

$K$ —随机数, 表示麻雀移动的方向, 取  $(-1, 1)$

$f_{\text{worst}}$ —全局最差适应度

$\varepsilon$ —无限接近 0 的常数, 避免分母出现 0

对其进行更新。

(5) 在进行一轮迭代后, 输出当前迭代的最小适应度, 以及对应的 GRU 模型超参数寻优值, 然后重新计算所有解的适应度  $f_i$  和平均适应度  $f_{\text{avg}}$ 。

(6) 当  $f_i < f_{\text{avg}}$  时, 使用公式

$$g = x(1 + N(0, 1)) \quad (12)$$

式中  $x$ —需要进行变异的解

$N$ —随机数, 均值为 0, 方差为 1

$g$ —高斯变异后的解

进行高斯变异对此解周围区域进行重点搜索, 然后将变异后的解与原始解进行比较, 两者之中保留最优的解。当  $f_i \geq f_{\text{avg}}$  时, 使用公式

$$\mathbf{X}'_{\text{new}} = (\mathbf{X}' + \mathbf{X}_{\text{new}})/2 \quad (13)$$

式中  $\mathbf{X}'_{\text{new}}$ —Tent 混沌扰动后产生的解

$\mathbf{X}'$ —需要进行 Tent 混沌扰动的解

$\mathbf{X}_{\text{new}}$ —使用式(7)、(8)新产生的扰动量

对此解进行 Tent 混沌扰动, 然后将扰动后的解与原始解进行比较, 两者之中保留最优的解。

(7) 对种群进行更新后得到最优适应度以及最优位置。

(8) 当算法达到最大迭代次数时停止算法, 未达到时返回步骤(3)。

### 1.3.4 ARIMA 残差预测模型

ISSA-GRU 模型的有害气体浓度预测精度虽然相比于单一 GRU 模型有所提升, 但是通过本文实验研究发现, ISSA-GRU 模型预测得到的残差序列仍然具备一定的规律, 有必要对其进行进一步提取。ARIMA 算法可以通过历史数据对未来值进行预测, 不仅具有优秀的时间序列提取能力, 更能精确反映时间序列发展规律<sup>[14]</sup>, 因此使用 ARIMA 算法对历史气体质量浓度残差序列的有价值信息进行提取和挖掘, 然后对未来气体质量浓度残差值进行预测, 以获得更加精确的预测值。ARIMA( $p, d, q$ ) 模型是由差分运算和自回归滑动平均模型 (Autoregressive moving average model, ARMA) 模型组成,  $d$  指的是序列转化成平稳序列所需的差分次数; ARMA( $p, q$ ) 模型是由自回归项和移动平均项组成的,  $p$  指的是自

回归项阶数,  $q$  指的是移动平均项阶数, ARMA( $p, q$ ) 模型为

$$N_t = \lambda + \alpha_1 N_{t-1} + \alpha_2 N_{t-2} + \cdots + \alpha_p N_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \cdots + \theta_q \varepsilon_{t-q} \quad (14)$$

式中  $N_t$ —残差序列中第  $t$  个值

$\alpha_i$ —自回归项系数

$\theta_q$ —移动平均项系数

$\varepsilon_t$ —白噪声序列中第  $t$  个值

$\lambda$ —常数

ARIMA( $p, d, q$ ) 模型建模步骤如下:

(1) 使用 ISSA-GRU 模型对训练集 2 进行预测, 观测值序列与预测值序列的差值为残差序列, 残差序列为 ARIMA 模型的输入。

(2) 由于 ARIMA 模型的输入序列必须为平稳序列, 使用单位根检验对残差时序数据的平稳性进行检验, 当  $P < 0.05$  拒绝原假设, 该序列为平稳序列, 否则该序列为非平稳序列, 需要对序列进行差分直到序列平稳, 方能通过平稳性检验。

(3) 对差分后的序列使用 Ljung\_Box 检验进行白噪声检验, 当  $P < 0.05$  拒绝原假设, 该序列为非白噪声序列, 否则该序列为白噪声序列, 通过白噪声检验后进行下一步。

(4) 使用最小赤池信息准则 (Akaike information criterion, AIC) 确定  $p$  和  $q$  的参数, AIC 取值最小的 ARIMA 模型为最优模型。

(5) 使用最优的 ARIMA( $p, d, q$ ) 模型对残差值进行预测。

## 1.4 模型评价指标

采用均方根误差 (RMSE)、平均绝对百分比误差 (MAPE) 和决定系数  $R^2$  对模型的性能进行评估。

## 2 结果与分析

### 2.1 猪舍环境因子监测结果及相关性分析

选取 2022 年 8 月 10 日到 9 月 30 日共 52 d 的预处理后环境数据作为实验数据, 猪舍环境因子变化曲线如图 5 所示; 其统计结果如表 2 所示。

猪舍内有害气体浓度受猪舍内外温度、湿度等多环境因素的影响, 构建有害气体浓度预测模型时加入外部影响因素可以使模型更加充分学习到预测目标的特征。使用 Pearson's 系数分析法 ( $P < 0.05$ ) 对影响 NH<sub>3</sub> 质量浓度和 CO<sub>2</sub> 质量浓度的多环境因素进行相关性分析, 如表 3 所示。

猪舍内 NH<sub>3</sub> 质量浓度与 CO<sub>2</sub> 质量浓度具有较强的正相关性, 相关系数为 0.72。猪舍内 NH<sub>3</sub> 质量浓度与舍内、外温度和通风速率呈负相关性, 相关系数

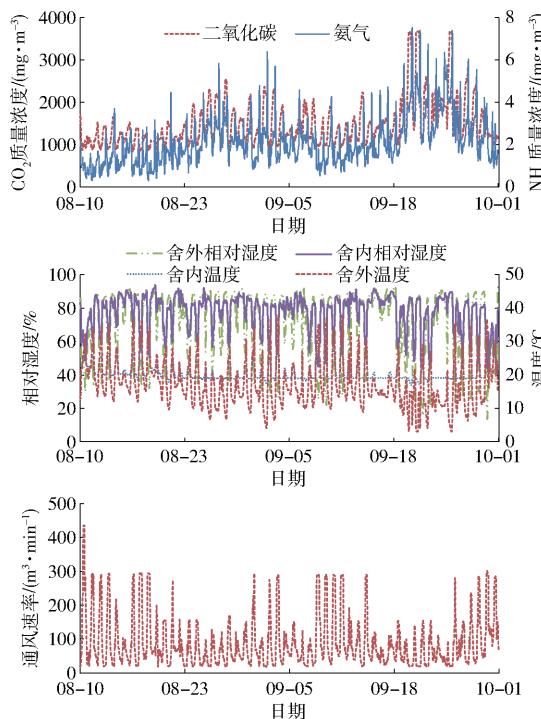


图 5 环境因子变化曲线

Fig. 5 Change curves of environmental factors

表 2 猪舍环境数据统计

Tab. 2 Statistical results of environmental data of pig house

环境因子	最大值	最小值	平均值	标准差
NH <sub>3</sub> 质量浓度/(mg·m <sup>-3</sup> )	7.6	0.3	2.2	1.2
CO <sub>2</sub> 质量浓度/(mg·m <sup>-3</sup> )	3 681	844	1 457	529
舍外温度/℃	37.8	3.1	17.7	7.0
舍外相对湿度/%	93.0	13.7	70.0	19.9
舍内温度/℃	27.9	17.0	20.7	2.4
舍内相对湿度/%	93.9	43.5	77.0	11.4
通风速率/(m <sup>3</sup> ·min <sup>-1</sup> )	435.7	17.2	89.2	77.3

表 3 皮尔森系数相关性分析

Tab. 3 Pearson coefficient factor correlation analysis

环境因素	NH <sub>3</sub> 质量浓度	CO <sub>2</sub> 质量浓度
通风速率	-0.36	-0.48
舍外相对湿度	0.21	0.30
舍外温度	-0.58	-0.81
CO <sub>2</sub> 质量浓度	0.72	1
NH <sub>3</sub> 质量浓度	1	0.72
舍内相对湿度	0.26	0.41
舍内温度	-0.49	-0.62

数分别为 -0.49、-0.58 和 -0.36; NH<sub>3</sub>质量浓度与舍内、外湿度具有正相关性, 相关系数分别为 0.26 和 0.21。猪舍内 CO<sub>2</sub>质量浓度与舍内、外相对湿度具有正相关性, 相关系数分别为 0.41 和 0.30; CO<sub>2</sub>质量浓度与舍内、外温度和通风速率具有较强的负相关性, 相关系数分别为 -0.81、-0.62 和 -0.48。

相关性分析的结果证明了猪舍内环境因子之间

具有相关性, 建模时加入外部影响因素可以减少模型预测误差。因此, 本文选取通风速率、舍内温度、舍内相对湿度、舍外温度、舍外相对湿度、CO<sub>2</sub>质量浓度作为 NH<sub>3</sub>质量浓度的外部影响因素; 选取通风速率、舍内温度、舍内相对湿度、舍外温度、舍外相对湿度、NH<sub>3</sub>质量浓度作为 CO<sub>2</sub>质量浓度的外部影响因素。

## 2.2 ISSA-GRU 模型构建

在使用优化算法对超参数进行寻优之前通过预实验确定 GRU 子层数目。实验结果如图 6 所示, 当 GRU 子层数目为 1 时, 模型预测的 RMSE 分别为 90.51 mg/m<sup>3</sup> 和 0.4962 mg/m<sup>3</sup>; 当 GRU 子层数增加到 2 时, 模型预测的 RMSE 分别为 83.15 mg/m<sup>3</sup> 和 0.381 mg/m<sup>3</sup>; 当 GRU 子层数继续增加时, 预测精度却下降, 故本模型 GRU 子层数目设置为 2。

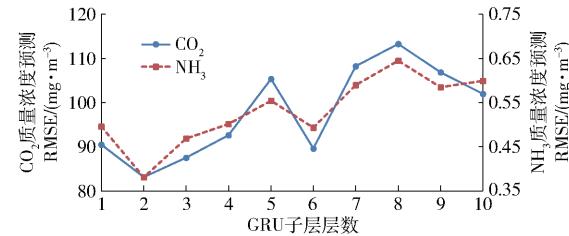


图 6 不同 GRU 层次时模型预测的均方根误差变化

Fig. 6 RMSE variations of GRU prediction model with different numbers of sublayers

使用 ISSA 算法对 GRU 神经网络的时间窗口、学习率、批数目、GRU 子层 1 神经元个数、GRU 子层 2 神经元个数这 5 个超参数进行寻优, 寻优范围如表 4 所示。ISSA 对 GRU 模型超参数寻优过程中优化算法种群数目设置为 10, 迭代次数设置为 50, 预警值设置为 0.8, 发现者比例设置为 80%, 警戒者比例设置为 20%。ISSA 算法对 GRU 模型的超参数优化结果如表 4 所示, 当时间窗口值为 3, 学习率为 0.0006, 批数目为 71, 两个 GRU 子层的神经元数目分别为 486 和 315 时模型预测精度最优。

表 4 ISSA 寻优参数

Tab. 4 ISSA optimization parameters

寻优参数	寻优范围	寻优结果
时间窗口	1~10	3
学习率	0.0001~0.001	0.0006
批数目	32~500	71
GRU 子层 1 神经元个数	1~600	486
GRU 子层 2 神经元个数	1~600	315

为了更好评估 ISSA 算法对 GRU 模型预测精度的优化, 本文选取 PSO 算法、SSA 算法和 GWO 算法进行对比。如图 7 所示。随着迭代次数的增加 4 种

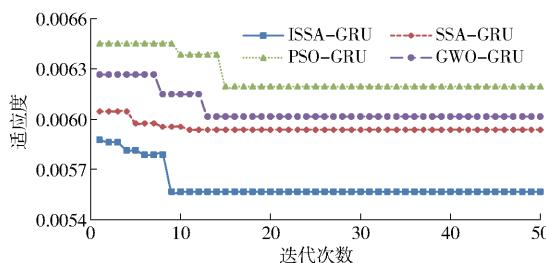


图 7 4 种不同算法适应度变化曲线

Fig. 7 Variation curves of fitness values of four different algorithms

算法都逐渐收敛,ISSA 算法的适应度最低(0.0056),较 PSO(0.0062)、SSA(0.0059)和 GWO(0.0060)3 种算法的适应度分别降低 9.68%、5.08% 和 6.67%,因此说明 ISSA 算法具有更高的搜索精度。

### 2.3 ARIMA 模型构建

以训练集 2 为数据集,使用超参数优化后的 ISSA-GRU 模型对舍内  $\text{NH}_3$  质量浓度、 $\text{CO}_2$  质量浓度进行预测,得到的监测值与预测值的残差序列如图 8 所示,使用残差序列构建 ARIMA 模型。

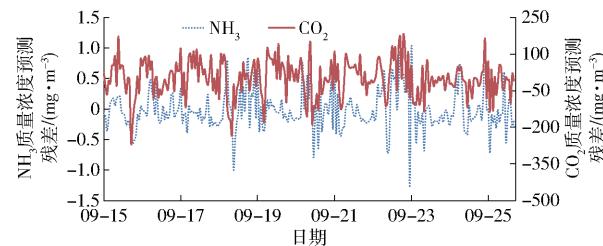


图 8 残差变化曲线

Fig. 8 Variation curves of error data

以  $\text{NH}_3$  质量浓度残差序列为输入,对 ARIMA 模型输入序列的平稳性进行检验,  $P = 8.85 \times 10^{-14} < 0.05$ , 该序列通过平稳性检验,  $\text{NH}_3$  质量浓度残差序列为平稳序列,因此  $d = 0$ 。 $\text{NH}_3$  质量浓度残差序列的白噪声检验  $P = 5.44 \times 10^{-4} < 0.05$ ,  $\text{NH}_3$  残差序列为非白噪声序列。以  $\text{CO}_2$  质量浓度残差序列为输入,对 ARIMA 模型输入序列的平稳性进行检验,  $P = 6.27 \times 10^{-13} < 0.05$ , 该序列通过平稳性检验,  $\text{CO}_2$  质量浓度残差序列为平稳序列,因此  $d = 0$ 。 $\text{CO}_2$  质量浓度残差序列的白噪声检验  $P = 1.60 \times 10^{-21} < 0.05$ ,  $\text{CO}_2$  质量浓度残差序列为非白噪声序列。

使用网格搜索法确定  $p$  和  $q$  的取值,当  $p$  取 3 且  $q$  取 1 时  $\text{NH}_3$  质量浓度残差 ARIMA 预测模型 AIC 值最小,为 447.232 2,此时 ARIMA 模型最优,  $\text{NH}_3$  质量浓度残差最优 ARIMA 模型为 ARIMA(3,0,1),根据相同步骤可确定  $\text{CO}_2$  质量浓度残差最优 ARIMA 模型为 ARIMA(4,0,1)。

### 2.4 ISSA-GRU-ARIMA 模型预测结果验证

使用测试集对模型预测精度进行测试,如图 9 所示,ISSA-GRU-ARIMA 模型对  $\text{NH}_3$  质量浓度和  $\text{CO}_2$  质量浓度的预测值变化趋势与观测值变化趋势都非常接近,呈现出周期性正弦或余弦曲线波动变化。 $\text{NH}_3$  质量浓度观测值变化范围为 0.9~5.4 mg/m<sup>3</sup>,ISSA-GRU-ARIMA 模型预测值变化范围为 0.8~5.5 mg/m<sup>3</sup>,预测值与观测值的最小误差为 0 mg/m<sup>3</sup>,最大误差为 1 mg/m<sup>3</sup>,平均误差为 0.2 mg/m<sup>3</sup>。 $\text{CO}_2$  质量浓度观测值变化范围为 983.5~2 796.5 mg/m<sup>3</sup>,ISSA-GRU-ARIMA 模型预测值变化范围为 978.5~2 823.5 mg/m<sup>3</sup>;预测值与观测值的最小误差为 1 mg/m<sup>3</sup>,最大误差为 194 mg/m<sup>3</sup>,平均误差为 41 mg/m<sup>3</sup>。

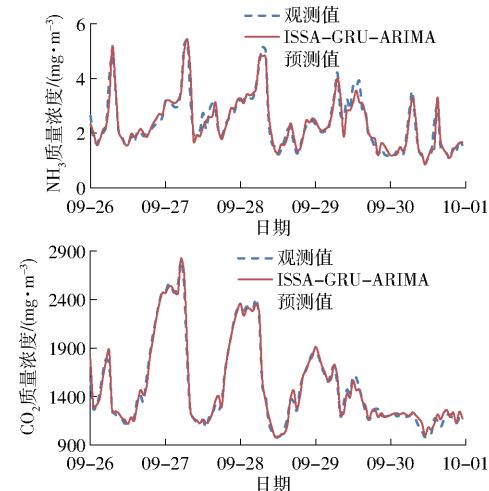


图 9 不同模型预测值对比

Fig. 9 Comparison of predicted values of different models

#### 2.4.1 不同模型预测结果对比

为了进一步验证模型预测效果,使用 CNN、GRU、SVR、RF、PSO-GRU、GWO-GRU、SSA-GRU、ISSA-GRU、ISSA-CNN、ISSA-CNN-ARIMA 模型进行对比实验,与本文所提模型 ISSA-GRU-ARIMA 使用相同数据集,实验结果如表 5 所示。CNN、GRU、SVR、RF 是常见基础模型,PSO-GRU、GWO-GRU、SSA-GRU 是使用其他优化算法对 GRU 模型进行优化,ISSA-CNN、ISSA-CNN-ARIMA 是使用 ISSA 算法和 ARIMA 算法对 CNN 进行优化。

如表 5 所示,本文模型 ISSA-GRU-ARIMA 预测精度最优,  $\text{NH}_3$  质量浓度预测的 RMSE、MAPE 和  $R^2$  分别为 0.263 mg/m<sup>3</sup>、8.171% 和 0.928, $\text{CO}_2$  质量浓度预测的 RMSE、MAPE 和  $R^2$  分别为 55.361 mg/m<sup>3</sup>、4.633% 和 0.985。传统机器学习模型 RF 预测精度最差,  $\text{NH}_3$  质量浓度预测 RMSE、MAPE 和  $R^2$  分别为

表5 模型预测精度对比  
Tab. 5 Comparison of model prediction accuracy

模型	NH <sub>3</sub> 质量浓度			CO <sub>2</sub> 质量浓度		
	RMSE/(mg·m <sup>-3</sup> )	MAPE/%	R <sup>2</sup>	RMSE/(mg·m <sup>-3</sup> )	MAPE/%	R <sup>2</sup>
GRU	0.381	11.247	0.849	83.151	6.916	0.967
CNN	0.393	11.453	0.839	91.882	7.448	0.959
SVR	0.599	16.575	0.654	147.737	10.685	0.895
RF	0.722	20.592	0.498	170.873	12.926	0.859
PSO - GRU	0.368	12.653	0.859	79.744	6.561	0.969
GWO - GRU	0.337	10.074	0.882	79.722	6.471	0.969
SSA - GRU	0.322	10.935	0.892	69.741	5.912	0.976
ISSA - GRU	0.298	9.301	0.907	65.974	5.515	0.979
ISSA - CNN	0.343	11.842	0.878	68.251	5.524	0.977
ISSA - CNN - ARIMA	0.319	10.833	0.894	56.882	4.646	0.984
ISSA - GRU - ARIMA	0.263	8.171	0.928	55.361	4.633	0.985

0.722 mg/m<sup>3</sup>、20.592% 和 0.4978, CO<sub>2</sub> 质量浓度预测的 RMSE 和 MAPE 和 R<sup>2</sup> 分别为 170.873 mg/m<sup>3</sup>、12.926% 和 0.859。本文模型与 RF 模型相比, NH<sub>3</sub> 质量浓度预测 RMSE 和 MAPE 分别下降 63.51% 和 60.31%, R<sup>2</sup> 提升 86.41%, CO<sub>2</sub> 质量浓度预测的 RMSE 和 MAPE 分别下降 67.58% 和 64.14%, R<sup>2</sup> 提升 14.65%。

ISSA - GRU 模型与 GRU 模型相比, NH<sub>3</sub> 和 CO<sub>2</sub> 质量浓度预测的 RMSE 和 MAPE 分别降低 21.69% 和 20.66%, 17.25% 和 20.25%; R<sup>2</sup> 分别提升了 6.87% 和 1.28%, 说明使用 ISSA 算法进行寻优显著可提升 GRU 模型的预测精度。ISSA - GRU 与 PSO - GRU、GWO - GRU 和 SSA - GRU 相比, NH<sub>3</sub> 质量浓度预测的 RMSE 分别下降 18.97%、11.57% 和 7.27%, CO<sub>2</sub> 质量浓度预测的 RMSE 分别下降 17.26%、17.24% 和 5.40%; NH<sub>3</sub> 质量浓度预测的 MAPE 分别下降 26.48%、7.64% 和 14.91%, CO<sub>2</sub> 质量浓度预测的 MAPE 分别下降 15.94%、14.77% 和 6.71%; NH<sub>3</sub> 质量浓度预测的 R<sup>2</sup> 分别上升 5.63%、2.92% 和 1.69%, CO<sub>2</sub> 质量浓度预测的 R<sup>2</sup> 分别上升 1.01%、1.00% 和 0.26%, 说明 ISSA 相比其他优化算法拥有更优秀的寻优能力。

ISSA - GRU - ARIMA 模型与 ISSA - GRU 相比, NH<sub>3</sub> 质量浓度预测的 RMSE 和 MAPE 分别下降 11.66% 和 12.13%, R<sup>2</sup> 提升 2.24%, CO<sub>2</sub> 质量浓度预测的 RMSE 和 MAPE 分别下降 16.08 和 15.99%, R<sup>2</sup> 提升 0.64%, 由此可见, 融合线性统计 ARIMA 方法后的 ISSA - GRU - ARIMA 模型, 可以充分挖掘 ISSA - GRU 预测残差序列的有用信息, 进一步提升模型预测精度。

#### 2.4.2 结果分析

近年来, 对猪舍气体浓度进行预测已成为猪舍

环境控制研究的关注热点, 国内外学者针对畜禽舍内不同气体构建了不同的预测模型。例如, 文献[7]提出的基于 ANFIS 的 NH<sub>3</sub> 质量浓度预测模型 R<sup>2</sup> 为 0.648; 文献[9]构建的融合注意力机制和 CNN 网络的 CNN - LSTM - AT 模型, 其 CO<sub>2</sub> 质量浓度预测的 R<sup>2</sup> 为 0.8170; 文献[27]使用不同时间间隔环境因子构建基于长短期记忆网络的 CO<sub>2</sub> 质量浓度预测模型, 其 R<sup>2</sup> 分别为 0.859 和 0.656, 文献[28]使用多种机器学习模型对 NH<sub>3</sub> 质量浓度进行预测, 梯度提升树算法取得了最好的预测效果, R<sup>2</sup> 为 0.402。这些模型对 NH<sub>3</sub> 质量浓度和 CO<sub>2</sub> 质量浓度预测的 R<sup>2</sup> 范围为 0.4~0.9, 本文所提出 ISSA - GRU - ARIMA 模型对 NH<sub>3</sub> 质量浓度和 CO<sub>2</sub> 质量浓度预测 R<sup>2</sup> 分别是 0.928 和 0.985, 优于上述已有研究中的模型, 可为猪舍气体浓度预测及环境控制提供可行的方法。

综上, 本文 ISSA - GRU - ARIMA 气体质量浓度预测模型预测精度较优, 可用于猪舍 NH<sub>3</sub> 质量浓度和 CO<sub>2</sub> 质量浓度预测。

### 3 结论

(1) 通过 ISSA 算法优化 GRU 模型的超参数, 可提升气体质量浓度预测模型的精度。ISSA - GRU 模型 NH<sub>3</sub> 质量浓度预测的 RMSE、MAPE 和 R<sup>2</sup> 分别为 0.298 mg/m<sup>3</sup>、9.301% 和 0.907, CO<sub>2</sub> 质量浓度预测的分别为 65.974 mg/m<sup>3</sup>、5.515% 和 0.979; 与 GRU(RMSE 分别为 0.381 mg/m<sup>3</sup> 和 83.151 mg/m<sup>3</sup>, MAPE 分别为 11.247% 和 6.916%, R<sup>2</sup> 分别为 0.849 和 0.967)相比, RMSE、MAPE 分别降低 21.69% 和 20.66%, 17.25% 和 20.25%; R<sup>2</sup> 分别提升 6.87% 和 1.28%。

(2) 融合统计学习 ARIMA 方法对 ISSA - GRU

模型进行优化,使得  $\text{NH}_3$  质量浓度和  $\text{CO}_2$  质量浓度预测的 RMSE 分别下降 11.66% 和 16.08%,因此 ARIMA 模型对残差进行线性特征提取可以提升模型预测精度。

(3) 提出的 ISSA - GRU - ARIMA 模型对  $\text{NH}_3$  质量度和  $\text{CO}_2$  质量浓度预测的  $R^2$  分别为 0.928 和 0.985, 预测精度较高, 预测结果可以为猪舍有害气体浓度控制提供科学依据。

## 参 考 文 献

- [1] 李新建, 吕刚, 任广志. 影响猪场氨气排放的因素及控制措施[J]. 家畜生态学报, 2012, 33(1): 86–93.  
LI Xinjian, LÜ Gang, REN Guangzhi. Factors affecting ammonia emission from pig farm and control measures[J]. Journal of Domestic Animal Ecology, 2012, 33(1): 86–93. (in Chinese)
- [2] 尹航, 吕佳威, 陈耀聪, 等. 基于 LightGBM - SSA - ELM 的新疆羊舍  $\text{CO}_2$  浓度预测[J]. 农业机械学报, 2022, 53(1): 261–270.  
YIN Hang, LÜ Jiawei, CHEN Yaocong, et al. Prediction of  $\text{CO}_2$  concentration in Xinjiang breeding environment of mutton sheep based on LightGBM - SSA - ELM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(1): 261–270. (in Chinese)
- [3] XING T, ZHAO L, HEBER A J, et al. Mechanistic modelling of ammonia emission from laying hen manure at laboratory scale [J]. Biosystems Engineering, 2020, 192(3): 24–41.
- [4] 汪开英, 代小蓉, 李震宇, 等. 不同地面结构的育肥猪舍  $\text{NH}_3$  排放系数[J]. 农业机械学报, 2010, 41(1): 163–166.  
WANG Kaiying, DAI Xiaorong, LI Zhenyu, et al.  $\text{NH}_3$  emission coefficient of fattening pig houses with different ground structures[J]. Transactions of the Chinese Society for Agricultural Machinery, 2010, 41(1): 163–166. (in Chinese)
- [5] 刘双印, 黄建德, 徐龙琴, 等. 基于 PCA - SVR - ARMA 的狮头鹅养殖禽舍气温组合预测模型[J]. 农业工程学报, 2020, 36(11): 225–233.  
LIU Shuangyin, HUANG Jiande, XU Longqin, et al. Combined model for prediction of air temperature in poultry house for lion-head goose breeding based on PCA - SVR - ARMA[J]. Transactions of the CSAE, 2020, 36(11): 225–233. (in Chinese)
- [6] 丁露雨, 吕阳, 李奇峰, 等. 融合多环境参数的鸡粪氨气排放预测模型研究[J]. 农业机械学报, 2022, 53(5): 366–375.  
DING Luyu, LÜ Yang, LI Qifeng, et al. Prediction model of ammonia emission from chicken manure based on multi-environmental parameters[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(5): 366–375. (in Chinese)
- [7] XIE Q, NI J, SU Z. A prediction model of ammonia emission from a fattening pig room based on the indoor concentration using adaptive neuro fuzzy inference system[J]. Journal of Hazardous Materials, 2017, 325: 301–309.
- [8] 谢秋菊, 郑萍, 包军, 等. 基于深度学习的密闭式猪舍内温湿度预测模型[J]. 农业机械学报, 2020, 51(10): 353–361.  
XIE Qiuju, ZHENG Ping, BAO Jun, et al. Thermal environment prediction and validation based on deep learning algorithm in closed pig house[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(10): 353–361. (in Chinese)
- [9] XIE Q, NI J, LI E, et al. Sequential air pollution emission estimation using a hybrid deep learning model and health-related ventilation control in a pig building[J]. Journal of Cleaner Production, 2022, 371: 133714.
- [10] 刘春红, 杨亮, 邓河, 等. 基于 ARIMA 和 BP 神经网络的猪舍氨气浓度预测[J]. 中国环境科学, 2019, 39(6): 2320–2327.  
LIU Chunhong, YANG Liang, DENG He, et al. Prediction of ammonia concentration in piggery based on ARIMA and BP neural network[J]. China Environmental Science, 2019, 39(6): 2320–2327. (in Chinese)
- [11] 冀荣华, 史珊弋, 赵迎迎, 等. 基于 LSTM - Seq2Seq 的兔舍环境多参数预测[J]. 农业机械学报, 2021, 52(增刊): 396–401, 409.  
JI Ronghua, SHI Shan'ge, ZHAO Yingying, et al. Multivariable environmental prediction model of rabbit house based on LSTM - Seq2Seq[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(Supp.): 396–401, 409. (in Chinese)
- [12] 王春颖, 潘伟婷, 李祥, 等. 基于 ST - LSTM 的植物生长发育预测模型[J]. 农业机械学报, 2022, 53(6): 250–258.  
WANG Chunying, PAN Weiting, LI Xiang, et al. Prediction model of plant growth and development based on ST - LSTM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(6): 250–258. (in Chinese)
- [13] 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]. 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 piggery based on EMD - LSTM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(Supp.): 353–360. (in Chinese)
- [14] 陈乐, 高文科, 冀宏, 等. 基于 HP 滤波与 ARIMA - GARCH 模型的柱塞泵泄漏量预测[J]. 农业工程学报, 2022, 38(10): 61–67.  
CHEN Le, GAO Wenke, JI Hong, et al. Predicting leakage in a piston pump using HP filter and ARIMA - GARCH model [J]. Transactions of the CSAE, 2022, 38(10): 61–67. (in Chinese)
- [15] 孙天齐. 基于 HP 滤波与 ARIMA 模型的柱塞泵泄漏量预测[D]. 兰州: 兰州理工大学, 2021.  
SUN Tianqi. Leakage prediction of piston pump based on HP filter and ARIMA model[D]. Lanzhou: Lanzhou University of

- Technology, 2021. (in Chinese)
- [16] 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 house based on CNN-GRU[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(9): 294-303. (in Chinese)
- [17] 马超凡,谢秋菊,王圣超,等. 融合统计学习与深度学习的猪舍环境预测模型[J]. 山西农业大学学报(自然科学版), 2022, 42(6): 24-32.  
MA Chaofan, XIE Qiuju, WANG Shengchao, et al. A prediction model for environmental factors in a pig house based on statistical learning and deep learning[J]. Journal of Shanxi Agricultural University(Natural Science Edition), 2022, 42(6): 24-32. (in Chinese)
- [18] 郭建军,韩铃钰,董佳琦,等. 基于 SSA-PSO-LSTM 模型的羊舍相对湿度预测技术[J]. 农业机械学报, 2022, 53(9): 365-373, 398.  
GUO Jianjun, HAN Lingyu, DONG Jiaqi, et al. Prediction of sheep house humidity based on SSA-PSO-LSTM model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(9): 365-373, 398. (in Chinese)
- [19] 谌英敏,王贺,苏勤,等. 基于 GA-BPNN 的采后蜜桃预冷效果预测模型[J]. 农业工程学报, 2021, 37(23): 264-272.  
CHEN Yingmin, WANG He, SU Qin, et al. Prediction model of precooling effect of postharvest peach based on GA-BPNN [J]. Transactions of the CSAE, 2021, 37(23): 264-272. (in Chinese)
- [20] 赵丽清,段东瑶,殷元元,等. 基于 PSO-Elman 算法的茶叶烘干含水率预测[J]. 农业工程学报, 2021, 37(19): 284-292.  
ZHAO Liqing, DUAN Dongyao, YIN Yuanyuan, et al. Prediction of moisture content in tea drying based on PSO-Elman algorithm[J]. Transactions of the CSAE, 2021, 37(19): 284-292. (in Chinese)
- [21] XUE J, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [22] 张永芳,王芳. 基于 SSA-RBF 网络的日光温室温湿度预测模型研究[J]. 河北农业大学学报, 2021, 44(3): 115-121.  
ZHANG Yongfang, WANG Fang. Study on temperature and humidity prediction model of solar greenhouse based on SSA-RBF network[J]. Journal of Hebei Agricultural University, 2021, 44(3): 115-121. (in Chinese)
- [23] 吕鑫,慕晓冬,张钧,等. 混沌麻雀搜索优化算法[J]. 北京航空航天大学学报, 2021, 47(8): 1712-1720.  
LÜ Xin, MU Xiaodong, ZHANG Jun, et al. Chaotic sparrow search optimization algorithm[J]. Journal of Beijing University of Aeronautics and Astronautics, 2021, 47(8): 1712-1720. (in Chinese)
- [24] 魏雷. 基于改进粒子群算法的 RFID 网络部署优化研究[D]. 无锡:江南大学, 2014.  
WEI Lei. Research on RFID network deployment optimization based on improved particle swarm optimization[D]. Wuxi: Jiangnan University, 2014. (in Chinese)
- [25] NI J Q, LIU S, LOPES I M, et al. Monitoring, modeling, and characterizing single-speed ventilation fans for an animal building[J]. Building and Environment, 2017, 118: 225-233.
- [26] 张娜,赵泽丹,包晓安,等. 基于改进的 Tent 混沌万有引力搜索算法[J]. 控制与决策, 2020, 35(4): 893-900.  
ZHANG Na, ZHAO Zedan, BAO Xiaoan, et al. Gravitational search algorithm based on improved Tent chaos[J]. Control and Decision, 2020, 35(4): 893-900. (in Chinese)
- [27] 星玲. 日光温室环境参数的变频采集及预测模型研究[D]. 沈阳:沈阳农业大学, 2022.  
XING Ling. Study on frequency conversion acquisition and prediction model of environmental parameters in solar greenhouse [D]. Shenyang: Shenyang Agricultural University, 2022. (in Chinese)
- [28] HEMPEL S, ADOLPHS J, LANDWHER N, et al. How the selection of training data and modeling approach affects the estimation of ammonia emissions from a naturally ventilated dairy barn-classical statistics versus machine learning [J]. Sustainability, 2020, 12(3): 1030.