

doi:10.6041/j.issn.1000-1298.2026.05.039

# 基于 WT - SSA - LSTM 的羊舍 PM<sub>2.5</sub> 浓度预测模型研究

周冰<sup>1</sup> 董佳琦<sup>1</sup> 邢赫<sup>2</sup> 陈苑冰<sup>1</sup> 王裕莞<sup>1</sup> 刘双印<sup>3,4</sup>

(1. 广州商学院现代信息产业学院, 广州 511363; 2. 广州商学院信息技术与工程学院, 广州 511363;

3. 仲恺农业工程学院人工智能学院, 广州 510225; 4. 仲恺农业工程学院智慧农业创新研究院, 广州 510225)

**摘要:** 集约化羊养殖中, 环境管理技术落后和缺失是导致羊舍环境恶化的关键因素, 准确预测羊舍的环境参数变化对于确保羊的健康成长和提高羊养殖业的经济收益至关重要。PM<sub>2.5</sub> 颗粒物是威胁羊健康成长和繁殖的重要因素, 为了精准把握羊舍内 PM<sub>2.5</sub> 的浓度规律, 本文提出 WT - SSA - LSTM 模型, 使用小波变换 (Wavelet transform, WT) 对羊舍环境参数数据进行分解重构, 消除数据噪声, 结合麻雀搜索算法 (Sparrow search algorithm, SSA) 对长短时记忆网络 (Long short-term memory network, LSTM) 模型的隐藏层神经元数、学习率和 batch\_size 进行优化, 调整输入模型的参数, 避免参数选取的随机性, 进一步提高模型性能。实验结果表明, WT - SSA - LSTM 模型的各项指标均优于其他预测模型, 其 MAE、RMSE、MSE、NRMSE、R<sup>2</sup> 分别达到 0.349 7 μg/m<sup>3</sup>、0.600 4 μg/m<sup>3</sup>、0.360 5 μg<sup>2</sup>/m<sup>6</sup>、0.005 7 和 0.998 1, 证明本文提出的 WT - SSA - LSTM 预测模型具有较高的精度和较好的稳定性, 为集约化羊群养殖羊舍的 PM<sub>2.5</sub> 浓度变化监测和调控提供指导性建议。

**关键词:** 羊舍; PM<sub>2.5</sub> 浓度预测; 小波变换降噪; 麻雀搜索算法; 长短时记忆网络

**中图分类号:** TP18; TP391 **文献标识码:** A **文章编号:** 1000-1298(2026)05-0417-10

**OSID:**

## PM<sub>2.5</sub> Concentration Prediction Model in Sheep House Based on WT - SSA - LSTM

ZHOU Bing<sup>1</sup> DONG Jiaqi<sup>1</sup> XING He<sup>2</sup> CHEN Yuanbing<sup>1</sup> WANG Yuwan<sup>1</sup> LIU Shuangyin<sup>3,4</sup>

(1. School of Modern Information Industry, Guangzhou College of Commerce, Guangzhou 511363, China

2. School of Information Technology and Engineering, Guangzhou College of Commerce, Guangzhou 511363, China

3. College of Artificial Intelligence, Zhongkai University of Agriculture and Engineering, Guangzhou 510225, China

4. Academy of Intelligent Agricultural Engineering Innovations, Zhongkai University of Agriculture and Engineering, Guangzhou 510225, China)

**Abstract:** In intensive sheep farming, the lack and backwardness of environmental management technologies are key factors contributing to the deterioration of sheep house environments. Accurately predicting changes in sheep house environmental parameters are crucial for ensuring the healthy growth of sheep and improving the economic benefits of the sheep farming industry. To accurately understand the PM<sub>2.5</sub> concentration patterns within sheep houses, the wavelet transform (WT) was used to decompose and reconstruct sheep house environmental parameter data to eliminate data noise. The sparrow search algorithm (SSA) was then used to optimize the number of hidden layer neurons, learning rate, and batch size of the LSTM model. This approach also adjusted the input model parameters to avoid randomness in parameter selection and further improve model performance. Experimental results showed that the WT - SSA - LSTM model outperformed other prediction models in all metrics, with MAE, RMSE, MSE, NRMSE, and R<sup>2</sup> reaching 0.349 7 μg/m<sup>3</sup>, 0.600 4 μg/m<sup>3</sup>, 0.360 5 μg<sup>2</sup>/m<sup>6</sup>, 0.005 7, and 0.998 1, respectively. This demonstrated the high accuracy and stability of the proposed WT - SSA - LSTM prediction model, effectively providing guidance for monitoring and regulating PM<sub>2.5</sub> levels in intensive

收稿日期: 2025-08-22 修回日期: 2025-09-15

**基金项目:** 国家自然科学基金项目(62373390)、广东省自然科学基金重点项目(2022B1515120059)、广州市科技计划项目(2023E04J1238、2023E04J1239)、新疆维吾尔自治区重大科技专项(2022A02011)、云浮市科技计划项目(2024020202、2022020303、2023020302)、2025年度广州商学院校级科研项目(2025XJYB038)和2025年度广州商学院校级教学质量与教学改革工程项目(2025ZLGC33)

**作者简介:** 周冰(1999—),女,助教,主要从事机器学习和数据挖掘研究,E-mail: imzhoubing@163.com

**通信作者:** 刘双印(1977—),男,教授,博士,主要从事人工智能和智能信息处理技术研究,E-mail: hdlisylq@126.com

sheep farming facilities. Future applications suggested that the proposed model could be applied to environmental parameter prediction for other animal housing applications, such as piggeries and cattle sheds.

**Key words:** sheep house; PM<sub>2.5</sub> concentration prediction; wavelet transform noise reduction; sparrow search algorithm; long short-term memory network

## 0 引言

随着羊养殖密度的提高,羊舍环境的恶化问题愈加严重,影响着羊的健康和畜产品的安全,给羊养殖业造成很大损失<sup>[1]</sup>。各种羊舍环境参数中,PM<sub>2.5</sub>颗粒物浓度(简称PM<sub>2.5</sub>浓度)是威胁羊健康成长和繁殖的重要因素,PM<sub>2.5</sub>颗粒物暴露可引起羊多种急慢性呼吸系统疾病,严重影响到羊只的健康生长与繁殖,甚至导致死亡<sup>[2]</sup>。因此,利用现代信息技术,探索羊舍养殖环境中PM<sub>2.5</sub>浓度的变化规律,事先对羊舍的环境变量进行准确预测和调控是急需解决的问题。

当前针对PM<sub>2.5</sub>浓度的调控工作仍局限于在线监测层面。在线监测本质上是对当前及历史PM<sub>2.5</sub>浓度变化的实时记录,仅能反映已发生的环境数据变化状态,属于被动式数据采集<sup>[3]</sup>,无法对未来短期甚至长期的环境参数变化趋势进行预判。而模型预测能通过挖掘历史监测数据中PM<sub>2.5</sub>浓度与其他环境参数的时序关联特征和非线性依赖关系,可主动输出未来一段时间内的PM<sub>2.5</sub>浓度预测结果,能够将环境监测从事后记录升级为事前预警<sup>[4]</sup>,形成涵盖预测预警、主动干预的一体化调控体系。

目前对时间序列进行预测的模型主要分为机理模型和基于智能算法的模型<sup>[5]</sup>。随着物联网技术快速应用于农业领域,羊舍环境数据量迅速增长<sup>[6]</sup>。由于其属于典型的时间序列数据,具有大时滞、强耦合、高维度、非线性的特征<sup>[7]</sup>,传统的机理模型不适合对非线性数据进行建模,在数据处理和深度挖掘方面欠缺<sup>[8]</sup>。而基于智能算法的预测模型能从深层次角度分析和建模复杂数据,不少专家学者对PM<sub>2.5</sub>浓度预测模型展开连续多年研究,并在环境科学和资源利用等领域多有应用<sup>[9-13]</sup>,然而这些预测模型在挖掘数据中隐藏的各种复杂信息方面存在不足,而且模型结构复杂、冗余度高,导致消耗计算资源,延长迭代优化周期,训练过程中难以快速收敛。

长短时记忆网络(Long short-term memory network, LSTM)是典型的深度学习算法之一,作为一种高效高可靠的计算工具,能有效保留和传递长期信息,适合处理时间跨度大的序列数据,通过对历史

时序数据特征进行提取,表现出良好的时序数据拟合能力和泛化能力<sup>[14]</sup>。不少专家学者对LSTM预测模型展开研究,在工业和农业领域取得了优异的预测结果<sup>[15-17]</sup>。LSTM神经网络的参数选取多依赖经验与随机尝试,不合适的参数组合易导致模型性能与预测精度下降<sup>[18]</sup>,因此采用群体智能优化算法对超参数进行全局寻优具有重要必要性。麻雀搜索算法(Sparrow search algorithm, SSA)作为主流群体智能搜索算法之一,在优化模型上其鲁棒性和收敛速度均优于传统的遗传算法和灰狼优化算法<sup>[19]</sup>,很多专家学者通过麻雀搜索算法对人工智能算法参数进行全局寻优,大大降低了预测模型的训练时间,提高了模型的精度<sup>[20-21]</sup>。

此外,对羊舍环境参数进行降噪,能有效去除养殖环境数据内的噪声,降低数据冗余和输入模型的特征复杂度。小波变换(Wavelet transform, WT)信号降噪方法具有多尺度和局部化分析的特性,能多尺度细分高频信号和低频信号<sup>[22]</sup>,许多研究人员使用这种方法,通过对原始时序数据进行分解和重构,得到平滑且波动小的去噪数据,降噪效果显著<sup>[23-24]</sup>。

基于前人的研究基础,本文提出混合WT-SSA-LSTM羊舍PM<sub>2.5</sub>浓度预测模型,首先使用小波变换对羊舍环境参数数据进行降噪,并结合麻雀搜索算法对LSTM最佳超参数进行寻优,确定LSTM神经网络中的最优参数组。与其他预测模型进行仿真对比,以验证该模型具有优良的拟合能力和高可靠性。

## 1 材料与方法

### 1.1 实验区域

本文数据来源于新疆维吾尔自治区昌吉回族自治州玛纳斯县的肉羊养殖基地(北纬44°27'18",东经86°10'47")。该养殖场集萨福克品种羊育种、繁殖、饲养为一体,其主要区域用来收集实验数据,占地面积约为422 m<sup>2</sup>。羊舍结构为半封闭式,分为主要区域、遮阳区和饮食区3部分,如图1所示。其中,主要区域位于羊舍中部,是羊的日常休息区;遮阳区位于北部,饮食区位于南部。

羊舍的主要区域长约33.75 m,宽约12.5 m,四面

均为砖墙和混凝土墙,有门窗,屋顶由钢板制成,地面为压实的土壤。夏季,羊舍通过自然通风和北侧遮阳帐篷来避暑;冬季,羊群被关在主要区域进行保暖和封闭式繁殖,并通过排风扇进行通风。为了在线监测羊舍温度、相对湿度、CO<sub>2</sub> 浓度、PM<sub>2.5</sub> 浓度、PM<sub>10</sub> 浓度、光照强度、噪声强度、TSP 浓度和 H<sub>2</sub>S 浓度等环境参数,在主要地区部署 NH<sub>3</sub>、H<sub>2</sub>S、噪声和其他传感器,分别安装在距地面 3.2、3.7、3.1、3.3 m 处。

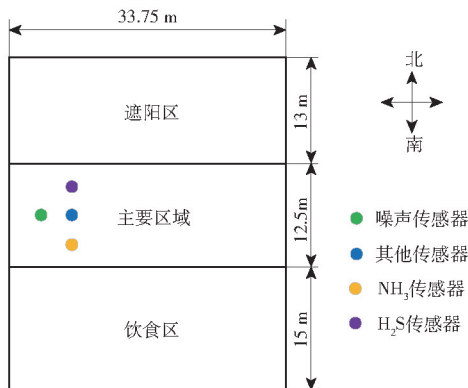


图1 基于物联网的羊舍监测平面示意图

Fig.1 Schematic of sheep house monitoring based on Internet of Things

### 1.2 实验数据获取

以新疆萨福克品种羊养殖基地羊舍环境为研究对象,通过如图2所示的物联网云服务平台,利用安装在羊舍里的传感器以 10 min 的间隔进行在线数据收集,将传感器采集到的羊舍温度、相对湿度、CO<sub>2</sub> 浓度、PM<sub>2.5</sub> 浓度、PM<sub>10</sub> 浓度、光照强度、噪声强度、TSP 浓度和 H<sub>2</sub>S 浓度等环境参数数据通过网关上传到远程物联网云服务平台。从 2021 年 2 月 8 日 17:11 这一时刻开始采集数据,至 2021 年 3 月 26 日 23:53 结束,传感器以 10 min 为间隔采集到共 6 640 条单一时刻数据,按照采集时间顺序选择前 4 648 条时刻数据作为训练集用于模型训练,后 1 992 条时刻数据作为测试集用于结果对比,用来预测未来 10 min 羊舍 PM<sub>2.5</sub> 浓度。

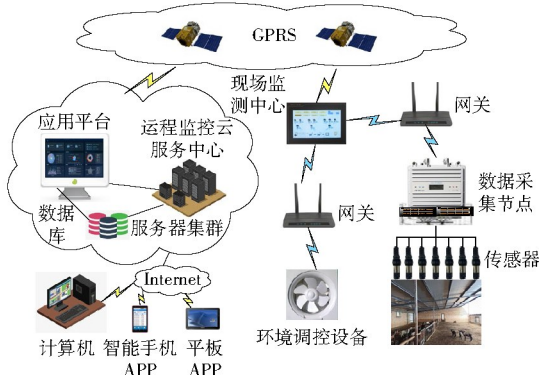


图2 物联网云服务平台拓扑架构图

Fig.2 Topology of IoT cloud service platform

### 1.3 羊舍环境数据预处理

由于羊舍环境中的参数具有不同的数值和单位,影响了数据分析和学习结果,需要通过数据标准化来消除参数集之间的量纲影响,确保羊舍各环境数据处于一个合理的分布范围内,以便算法能够更容易地学习和分析数据中隐藏的结构关系。此外,进行数据标准化也是为了加速模型的学习与训练,在相同条件下比未标准化的训练模型达到更稳定的效果,提供更均匀的拟合,以及更高的效率和精度<sup>[25]</sup>。标准化公式为

$$Z_m^* = \frac{Z_m - \bar{Z}_m}{Z_s} \quad (1)$$

式中  $Z_s$ ——标准差  $\bar{Z}_m$ ——均值  
 $Z_m$ ——真实值  
 $Z_m^*$ ——标准化后得到的值

## 2 基于混合模型的羊舍 PM<sub>2.5</sub> 浓度预测模型构建

### 2.1 小波变换

小波变换由傅里叶变换算法演变而来<sup>[26]</sup>,其对信号进行局部化分析的思想,使得低频信号和高频信号能得到细分和保留。同时增强了窗口大小的灵活性,其随频率改变的“时间-频率”窗口机制非常适合处理非线性、非平稳的羊舍环境参数信号。

在函数空间内,对于羊舍环境参数数据  $g(x)$ ,连续小波变换定义为

$$Q_T(u, v) = |u|^{-\frac{1}{2}} \int_{-\infty}^{+\infty} g(x) \eta\left(\frac{x-v}{u}\right) dx \quad (2)$$

式中  $\eta(t)$ ——小波函数  
 $u$ ——尺度系数,为定位频率  
 $v$ ——平移因子,为定位时间  
 $\eta\left(\frac{x-v}{u}\right)$ ——确定函数跳跃值的共轭复数  
 $Q_T(u, v)$ ——小波变换后的信号

小波变换去噪法关键是小波函数的选择。为了选择最佳小波函数对数据进行去噪,在评价指标上选取代表有用信号和噪声信号比值的信噪比(Signal-to-noise ratio, SNR)和代表匹配目标相关性的归一化互相关(Normalized cross-correlation, NCC)对小波函数 Daubechies、Haar、Coiflets 和 Symlets 的降噪效果进行评估,SNR 和 NCC 的计算公式为

$$V_{SNR} = 10 \lg \left( \frac{\sum_i y_i^2}{\sum_i (y_i - y'_i)^2} \right) \quad (3)$$

$$N_{NCC} = \frac{\sum (y_i - \text{mean}(y_i))(y'_i - \text{mean}(y'_i))}{\sqrt{\sum (y_i - \text{mean}(y_i))^2 \sum (y'_i - \text{mean}(y'_i))^2}} \quad (4)$$

式中  $y_i$ ——原始数据  
 $y'_i$ ——小波降噪处理后的数据  
 $V_{SNR}$ ——信噪比  
 $N_{NCC}$ ——归一化互相关系数

## 2.2 麻雀优化算法

麻雀优化算法(SSA)<sup>[27]</sup>于2020年提出,是通过模仿麻雀和反捕猎群体的搜索行为而提出的一种群体智能优化算法。这种算法的参数更少,搜索能力更强,而且性能更快<sup>[28]</sup>。SSA将不同个体分为探索者和跟随者,探索者积极搜索食物,跟随者紧跟探索者,期间侦察员加入<sup>[29]</sup>,其主要过程可以解释如下:

(1)随机生成麻雀群体的初始位置,其过程可表示为

$$D = \begin{bmatrix} d_{1,1} & d_{1,2} & \cdots & d_{1,m} \\ d_{2,1} & d_{2,2} & \cdots & d_{2,m} \\ \vdots & \vdots & & \vdots \\ d_{k,1} & d_{k,2} & \cdots & d_{k,m} \end{bmatrix} \quad (5)$$

式中  $k$ ——麻雀的种群数量  
 $m$ ——选择变量优化的维度  
 $D$ ——麻雀群体的初始位置  
 所有麻雀个体的适应度  $W_D$  为

$$W_D = \begin{bmatrix} w[d_{1,1} & d_{1,2} & \cdots & d_{1,m}] \\ w[d_{2,1} & d_{2,2} & \cdots & d_{2,m}] \\ \vdots & & & \\ w[d_{k,1} & d_{k,2} & \cdots & d_{k,m}] \end{bmatrix} \quad (6)$$

式中  $w$ ——每只麻雀的适应度

(2)在每个迭代期间,探索者更新其状态计算式为

$$D_{i,j}^{t+1} = \begin{cases} D_{i,j}^t \exp\left(-\frac{i}{\beta T}\right) & (a < A) \\ D_{i,j}^t RL & (a \geq A) \end{cases} \quad (7)$$

式中  $T$ ——最大迭代次数

$t$ ——当前迭代次数

$D_{i,j}^{t+1}$ ——麻雀种群第  $t+1$  次迭代后在第  $j$  维的新位置

$\beta$ ——0到1之间的随机数

$D_{i,j}^t$ ——麻雀种群第  $t$  次迭代后在第  $j$  维的位置

$R$ ——满足正态分布的随机数

$L$ ——1行  $m$  列的向量,且该向量每一个元素值都是1

$a$ ——种群预警值,  $a \in (0, 1)$

$A$ ——种群安全值,  $A \in (0.5, 1)$

如果  $a \geq A$ ,意味着猎人的位置暴露,整个麻雀种群都必须快速地从当前位置转移到其他安全区域。当  $a < A$  意味着没有猎人,探索者就会进入广

泛的搜索模式。

麻雀搜索食物过程中,跟随者位置更新公式为

$$D_{i,j}^{t+1} = \begin{cases} R \exp\left(\frac{D_B^t - D_{i,j}^t}{t^2}\right) & \left(i > \frac{k}{2}\right) \\ D_M^{t+1} + |D_{i,j}^t - D_M^{t+1}| PL & \left(i \leq \frac{k}{2}\right) \end{cases} \quad (8)$$

式中  $D_B^t$ ——第  $t$  次迭代中全局最差位置

$D_M^{t+1}$ ——第  $t+1$  次迭代中全局最优位置

$P$ ——1行  $k$  列的向量,向量中每个值都被随机设置为1或-1

当  $i > k/2$ ,表明第  $t$  次迭代中该跟随者具有较差的适应度,需要飞至其他位置寻找食物,当  $i < k/2$ ,意味着当前迭代中该跟随者可以在现有全局最佳位置继续随机进食。

(3)麻雀种群中存在着侦察员机制,比例通常设置为10%~20%,主要负责勘探危险并警示族群麻雀,位置更新公式为

$$D_{i,j}^{t+1} = \begin{cases} D_M^t + \eta |D_{i,j}^t - D_M^t| & (c_i > c_g) \\ D_{i,j}^t + S \frac{|D_{i,j}^t - D_B^t|}{c_i - c_w + \kappa} & (c_i = c_g) \end{cases} \quad (9)$$

式中  $D_M^t$ ——第  $t$  次迭代中全局最优位置

$\kappa$ ——随机数,避免分母为0,数值极小

$S$ ——随机数,用以表示麻雀移动方向和步长,且  $S \in [-1, 1]$

$c_i, c_g, c_w$ ——麻雀的当前适应度、全局最优适应度和全局最差适应度

$c_i = c_g$  表示侦察员意识到了危险,需要引领种群移动位置以规避风险; $c_i > c_g$  表明侦察员就处于群体的边缘,有受到攻击的风险。

(4)将每个麻雀个体的适应度与上次迭代适应度进行对比,如果新的适应度高于当前适应度,则新的适应度代替当前适应度成为全局最优适应度,并且更新麻雀的位置;如果新的适应度没有高于当前适应度,则不变更迭代适应度。

(5)如果迭代次数小于设定的迭代最大次数,则继续从步骤(2)循环。否则,该算法停止,并输出最佳解组合。

## 2.3 LSTM

LSTM由HOCHREITER等<sup>[30]</sup>在1997年提出,是一种高效的RNN结构,并在各个领域得到广泛的应用。LSTM作为一种流行的时间序列预测,可以专业地处理长期依赖性数据<sup>[31]</sup>。

LSTM是一种RNN变形结构,通过在隐藏层增加记忆单元来控制时间序列数据的记忆信息<sup>[32]</sup>。信息在隐藏层的单元之间通过一系列的可编程门(输入门、输出门和遗忘门)来传递。LSTM可以通

过引入门控机制来选择性地更新和维持单元的状态,这可以解决短期和长期记忆的依赖问题,从而避免了梯度消失和爆炸问题。

图3描述了基本的 LSTM 单元,一个存储单元中有3个门:输入门的功能是跟踪记忆单元中的最新信息;输出门的功能是保持对整个网络其余部分的最新信息传播的控制;遗忘门的功能是根据前一个单元的状态来决定是否应该删除信息。LSTM 单元状态实现和更新以及 LSTM 输出计算式为

$$F_t = \sigma(W_{xf}X_t + W_{hf}H_{t-1} + B_f) \quad (10)$$

$$I_t = \sigma(W_{xi}X_t + W_{hi}H_{t-1} + B_i) \quad (11)$$

$$\bar{C}_t = \sigma(W_{xc}X_t + W_{hc}H_{t-1} + B_c) \quad (12)$$

$$C_t = F_t C_{t-1} + I_t \bar{C}_t \quad (13)$$

$$O_t = \sigma(W_{xo}X_t + W_{ho}H_{t-1} + B_o) \quad (14)$$

$$H_t = O_t \tanh(C_t) \quad (15)$$

$$Y_t = \sigma(W_{hy}H_t + B_y) \quad (16)$$

$$\sigma(x) = \frac{1}{1 + \exp(-x)} \quad (17)$$

式中  $X_t$ ——输入向量  $Y_t$ ——输出向量

$I_t$ ——输入门结果

$F_t$ ——遗忘门结果

$O_t$ ——输出门结果

$H_t$ ——隐藏状态向量

$H_{t-1}$ ——上一时刻隐藏状态

$C_t$ ——存储块中的结束状态

$\bar{C}_t$ ——暂时存储状态

$\sigma$ ——sigmoid 函数

$W_{xf}$ 、 $W_{xi}$ 、 $W_{xc}$ 、 $W_{xo}$ ——输入权重矩阵

$W_{hf}$ 、 $W_{hi}$ 、 $W_{hc}$ 、 $W_{ho}$ ——循环权重矩阵

$W_{hy}$ ——输出权重矩阵

$B_f$ 、 $B_i$ 、 $B_c$ 、 $B_o$ 、 $B_y$ ——相关偏置向量

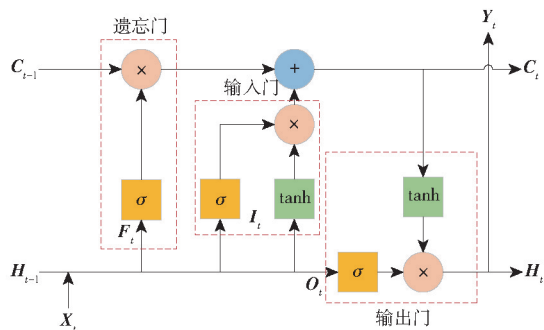


图3 LSTM 结构图

Fig. 3 LSTM structure diagram

### 2.4 混合 PM<sub>2.5</sub> 浓度预测模型

基于所提出的 WT-SSA-LSTM 方法,实现了羊舍 PM<sub>2.5</sub> 浓度的混合预测模型,具体预测流程如图4所示。

使用 WT-SSA-LSTM 模型对 PM<sub>2.5</sub> 浓度预测

的主要步骤如下:

(1)设计实验方案,选取羊舍温度、相对湿度、CO<sub>2</sub>浓度、PM<sub>2.5</sub>浓度、PM<sub>10</sub>浓度、光照强度、噪声强度、TSP浓度和 H<sub>2</sub>S 浓度等环境参数作为数据集。

(2)使用小波变换中的4种小波函数对各个羊舍环境参数进行降噪处理,得到高质量数据集。

(3)将经过降噪处理后的数据进行数据标准化操作,设置前70%为训练集,其余部分为测试集。

(4)基于训练集,使用麻雀搜索算法对 LSTM 模型的隐藏层神经单元数、学习率和 batch\_size 进行优化。

(5)将麻雀搜索算法全局寻优后获得的最佳超参数应用到 LSTM 模型中,得到 WT-SSA-LSTM 组合预测模型。

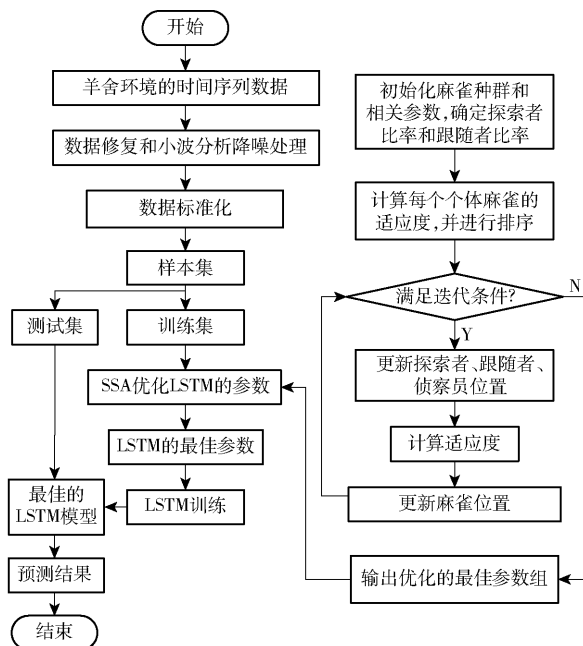


图4 WT-SSA-LSTM 算法流程图

Fig. 4 WT-SSA-LSTM algorithm flowchart

### 2.5 模型评价标准

本文模型以决定系数 ( $R^2$ )、平均绝对误差 (Mean absolute error, MAE)、均方根误差 (Root mean square error, RMSE)、归一化均方根误差 (Normalized root mean square error, NRMSE) 和均方误差 (Mean square error, MSE) 作为评价指标,以计算评估预测结果。

### 3 仿真结果与讨论

#### 3.1 数据源

将每隔 10 min 通过传感器实时在线采集的羊舍养殖环境数据作为实验数据,采集时间为 47 d,从 2021 年 2 月 8 日 17:11 起始,至 2021 年 3 月 26 日 23:53 结束,共包括 9 项环境因子:空气温度、空气

相对湿度、CO<sub>2</sub>浓度、H<sub>2</sub>S浓度、PM<sub>2.5</sub>浓度、PM<sub>10</sub>浓度、TSP浓度、光照强度、噪声强度,共收集6640条以10 min为间隔的单一时刻数据。为了反映每条数据在这47 d全局序列中的位置,帮助模型感知环境参数随时间变化的长期累积趋势,将这6640条时刻数据按采集时间顺序从1到6640编号,直接对应从2021年2月8日17:11至2021年3月26日23:53的以10 min为间隔的每个时刻的

完整时间轴,模型可通过该编号索引捕捉各环境参数随时间推移的变化趋势,并将按采集时间顺序的前4648条时刻数据作为训练集用于模型训练,后1992条时刻数据作为测试集用于结果对比,用来预测未来10 min羊舍PM<sub>2.5</sub>浓度。其中,羊舍环境数据原始数据如表1所示。图5所示为PM<sub>2.5</sub>浓度随时间推移的变化趋势,可以观察到其随时间呈周期性变化。

表1 2021年2月8日至3月26日收集的部分羊舍环境原始数据

Tab.1 Raw data of some sheep house environments collected from February 8 to March 26, 2021

时间	空气 温度/ ℃	空气 相对 湿度/%	CO <sub>2</sub> 质量浓度/ ( $\mu\text{g}\cdot\text{m}^{-3}$ )	PM <sub>2.5</sub> 质量浓度/ ( $\mu\text{g}\cdot\text{m}^{-3}$ )	PM <sub>10</sub> 质量浓度/ ( $\mu\text{g}\cdot\text{m}^{-3}$ )	光照 强度/ lx	噪声 强度/ dB	TSP 质量浓度/ ( $\mu\text{g}\cdot\text{m}^{-3}$ )	H <sub>2</sub> S 质量浓度/ ( $\mu\text{g}\cdot\text{m}^{-3}$ )
2021-02-08 17:11:56	4.2	78	1355	16.3	81.3	146	31.1	120.7	5.2
2021-02-08 17:21:35	3.9	78.4	1330	26.5	107.1	97	72.7	165.3	5.2
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2021-03-26 23:33:14	15	87.9	2180	5.1	9.6	0	37.9	18.2	0
2021-03-26 23:43:14	15	87.2	2125	3.7	52.6	0	32	69.3	0
2021-03-26 23:53:14	15	87	2175	3.2	4.3	0	32.4	9.3	0




图5 原始PM<sub>2.5</sub>浓度变化曲线

Fig.5 Original PM<sub>2.5</sub> concentration change curve

### 3.2 实验环境与参数选取

实验配置为第11代Intel(R)Core(TM)i7-1165G7处理器(2.80 GHz)、16 GB运行内存的计算机,运行Windows 10 64位操作系统,搭载Anaconda 3平台和Python 3.6编程语言(64位);通过安装NumPy、Sklearn、Pandas、Keras等工具包完成模拟环境的搭建。

麻雀优化算法中,初始化麻雀种群数量为20,最大迭代次数为10,预设LSTM隐藏层神经元数搜索范围为[0,100]、学习率搜索范围为[0,1],batch\_size搜索范围为[2,500],共寻优40轮,以均方根误差作为适应度。

LSTM隐藏层神经元数为7,学习率为0.12,batch\_size为270。

### 3.3 小波变换降噪

传感器采集羊舍环境数据中,可能存在元器件老化、高频电流干扰和人为因素导致采集的羊舍数据含有噪声,为了提升数据集优质量,保证模型预测的精度,本文选择小波变换对羊舍环境数据进行降

噪处理,4种小波函数在9种羊舍环境数据上的降噪效果如表2所示。由于Haar函数降噪后的SNR和NCC较差,后续未使用Haar函数。选取小波函数Daubechies-8处理H<sub>2</sub>S浓度数据;小波函数Coiflets处理PM<sub>2.5</sub>浓度、PM<sub>10</sub>浓度、光照强度、噪声强度、TSP浓度数据;小波函数Symlets处理空气温度、空气相对湿度、CO<sub>2</sub>浓度数据。各环境参数经过小波函数处理后降噪效果如图6所示。

### 3.4 仿真结果分析

如图7所示,WT-SSA-LSTM模型的预测曲线能显著地贴合真实值曲线,这表明基于WT-SSA-LSTM的羊舍PM<sub>2.5</sub>浓度预测模型具有高精度、高拟合性能的优点。同时,为了证明本文提出的模型在羊舍PM<sub>2.5</sub>浓度预测领域的优越性和有效性,本文模型与单一GRU模型、单一BPNN模型、SSA-LSTM模型、WT-LSTM、CGWO-SVR这5个模型对同一数据集的预测结果进行对比,得到的对比结果如图8所示,可以观察到,本文提出的WT-SSA-LSTM模型的预测曲线更契合真实曲线,尤其在对峰值的预测上,本文提出的模型预测效果更接近理想效果。

为了验证本文提出的WT-SSA-LSTM模型的长时间预测效果,从收集到的2021年2月8日至3月26日的6620条时刻数据中以1 h为单位选取1100条时刻数据,以时间为顺序划分前880条时刻数据为训练集,后220条时刻数据为测试集,得到的预测结果如图9所示,结果表明,使用WT-SSA-

表 2 4 种小波函数在羊舍环境数据上的降噪效果

Tab.2 Noise reduction effects of four wavelet functions on sheep house environmental data

环境参数	评判指标	小波函数			
		Daubechies - 8	Haar	Coiflets	Symlets
空气温度	SNR/dB	32.982 625	33.024 642	33.206 166	33.554 132
	NCC	0.998 828	0.998 812	0.998 923	0.998 975
空气相对湿度	SNR/dB	41.837 740	41.064 457	41.661 144	42.366 931
	NCC	0.996 711	0.996 640	0.996 776	0.997 082
CO <sub>2</sub> 浓度	SNR/dB	29.376 446	26.623 473	29.056 035	29.560 205
	NCC	0.998 613	0.997 102	0.998 647	0.998 710
PM <sub>2.5</sub> 浓度	SNR/dB	21.659 508	20.025 064	22.294 947	22.238 713
	NCC	0.993 344	0.991 082	0.994 404	0.994 077
PM <sub>10</sub> 浓度	SNR/dB	21.087 268	19.729 038	22.650 248	21.483 862
	NCC	0.993 558	0.992 103	0.995 752	0.993 997
光照强度	SNR/dB	19.752 973	20.193 638	22.387 201	19.420 483
	NCC	0.996 004	0.996 473	0.997 701	0.995 363
噪声强度	SNR/dB	28.210 707	28.161 010	28.427 409	28.283 992
	NCC	0.995 884	0.995 828	0.995 997	0.995 873
TSP 浓度	SNR/dB	21.449 347	19.956 633	23.016 239	22.102 738
	NCC	0.993 737	0.992 045	0.995 872	0.994 515
H <sub>2</sub> S 浓度	SNR/dB	25.437 751	25.417 253	24.707 927	24.965 719
	NCC	0.996 925	0.997 028	0.996 455	0.996 570

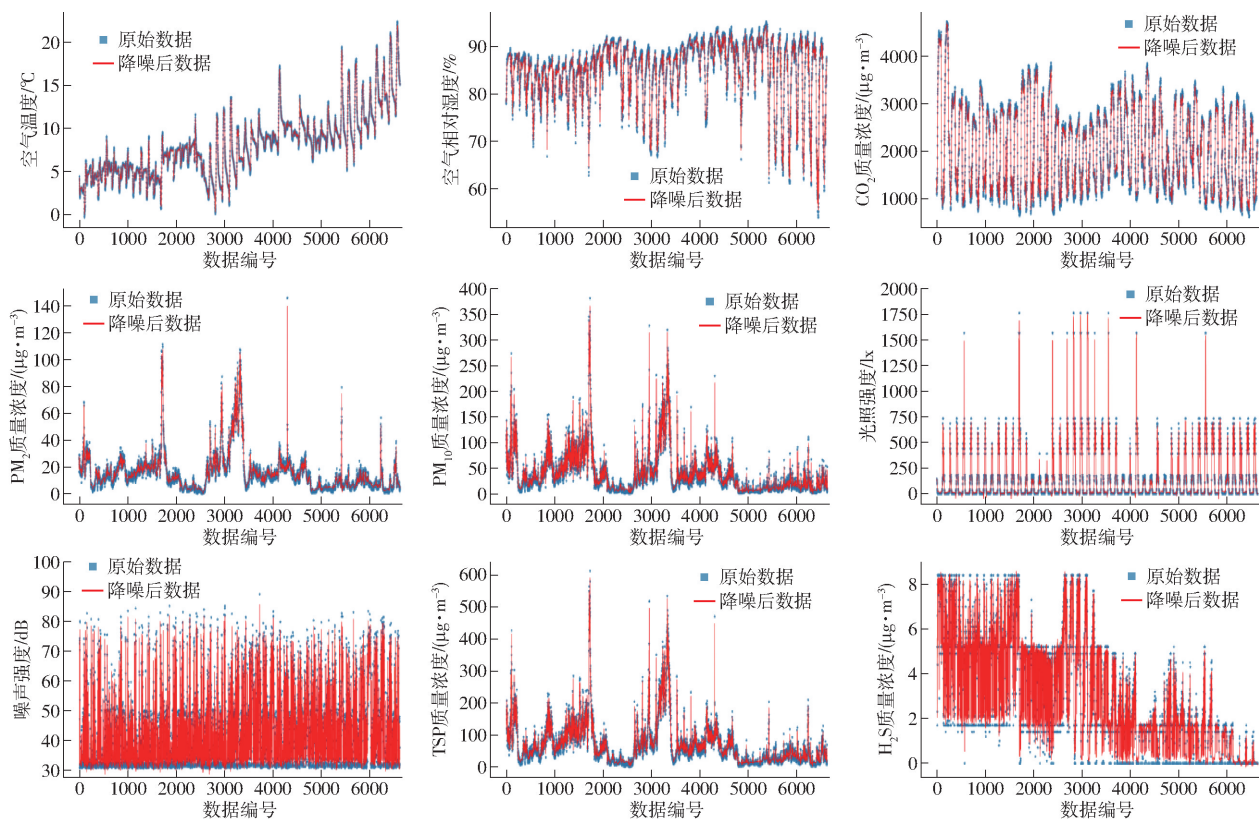


图 6 羊舍环境原始数据与小波变换降噪后的数据对比图

Fig.6 Comparison of original data of sheep house environment and data after wavelet transform noise reduction

LSTM 模型对 PM<sub>2.5</sub> 浓度的预测曲线几乎契合真实值曲线,其 MAE、RMSE、MSE、NRMSE、R<sup>2</sup> 分别达到 0.461 5 μg/m<sup>3</sup>、0.852 6 μg/m<sup>3</sup>、0.726 9 μg<sup>2</sup>/m<sup>6</sup>、0.008 9 和 0.997 2,表明该模型不仅能够实现对未来短时序列的精准预测,还具备适配长期数据预测任务的能力,在短、长期预测场景中均表现出良好的

适用性。

图 10 为基于不同模型预测的 PM<sub>2.5</sub> 浓度箱型图,其中 GRU、BPNN 的预测结果最不稳定,WT-SSA-LSTM 模型的预测更稳定,其上四分位数、下四分位数和中位数均达到实际值的标准,预测结果也更接近实际值,对于原始环境数据中出现的偏移

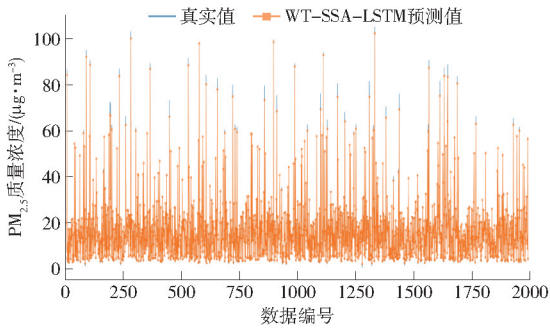


图7 WT-SSA-LSTM预测结果

Fig. 7 WT-SSA-LSTM prediction results




图8 不同模型预测结果对比图

Fig. 8 Comparison of prediction results of different models



图9 WT-SSA-LSTM对未来1h PM<sub>2.5</sub>预测的结果Fig. 9 WT-SSA-LSTM prediction results for PM<sub>2.5</sub> in next hour

图10 不同模型预测结果箱型图

Fig. 10 Box plot of prediction results of different models

值,WT-SSA-LSTM模型的预测结果也比其他模型更准确。

图11所示为PM<sub>2.5</sub>模型预测值与实际值对比的验证泰勒图,每一个散点代表一个模型,它汇聚着相




图11 不同模型预测结果泰勒图

Fig. 11 Taylor diagram of prediction results of different models

关系数、中心均方根误差和标准差的3个指标的信息量,Measured点代表着PM<sub>2.5</sub>浓度实际值的标准差,预测值到原点的距离代表其相对于实际值的标准差,散点越接近实际值所在的圆弧线,表明预测值与实际值越接近。预测值方位角的余弦表示其与实际值的相关系数,预测值到实际值的距离为均方根误差。其中,WT-SSA-LSTM模型最接近实际值所在的圆弧线,与实际值的距离最短,这表明该模型预测值与实际值的相关系数最高,均方根误差最小。

由表3可以看出,本文提出的基于WT-SSA-LSTM的羊舍PM<sub>2.5</sub>浓度预测模型各项指标均优于其他预测模型,其MAE、RMSE、MSE、NRMSE、R<sup>2</sup>分别达到0.3497 μg/m<sup>3</sup>、0.6004 μg/m<sup>3</sup>、0.3605 μg<sup>2</sup>/m<sup>6</sup>、0.0057和0.9981。对于单一模型而言,单一LSTM模型的预测精度较单一GRU和单一BPNN模型高,单一LSTM模型的MAE、RMSE、MSE、NRMSE、R<sup>2</sup>较GRU提高了72%、49%、74%、46%、29%,较BPNN提高了12%、50%、75%、47%、32%,这说明LSTM能更好地挖掘羊舍PM<sub>2.5</sub>浓度数据隐藏的关联信息并有着良好的适应性,在非线性问题上具有优越的拟合能力。同时,通过SSA优化的LSTM模型,其MAE、RMSE、MSE、NRMSE,较单一LSTM模型高28%、38%、62%、6%,这进一步证明SSA在局部寻优和全局寻优之间能较好地保持着良好的平衡,使用SSA对LSTM的隐藏层神经元数、学习率和批次进行寻优能显著提高模型精度。

其中,WT-SSA-LSTM的MAE、RMSE、MSE、NRMSE和R<sup>2</sup>较SSA-LSTM提高73%、76%、94%、75%和3%,从而说明采用WT对羊舍数据降噪处理,可以很好地保留数据原始信息,提高数据质量,增强模型的泛化性能。此外,使用小波变换降噪处

表3 不同预测模型的评价指标对比

Tab.3 Comparison of evaluation indicators of different prediction models

预测模型	MAE/( $\mu\text{g}\cdot\text{m}^{-3}$ )	RMSE/( $\mu\text{g}\cdot\text{m}^{-3}$ )	MSE/( $\mu\text{g}^2\cdot\text{m}^{-6}$ )	NRMSE	R <sup>2</sup>
GRU	6.260 5	7.889 8	62.249 6	0.071 1	0.712 5
BPNN	2.014 5	8.116 6	65.879 3	0.073 1	0.695 7
LSTM	1.763 3	4.037 0	16.298 1	0.038 6	0.917 3
WT-LSTM	0.472 3	0.840 1	0.705 8	0.008 0	0.994 2
SSA-LSTM	1.273 9	2.503 0	6.265 3	0.022 5	0.971 0
WT-SSA-LSTM(未来1h预测模型)	0.461 5	0.852 6	0.726 9	0.008 9	0.997 2
WT-SSA-LSTM(未来10min预测模型)	0.349 7	0.600 4	0.360 5	0.005 7	0.998 1

理过的 LSTM 模型,其 MAE、RMSE、MSE、NRMSE、R<sup>2</sup>较单一 LSTM 模型提高 73%、79%、96%、79% 和 8%,这进一步证明采用小波变换对数据降噪能提高模型的拟合效果和精确度。

综上所述,本文提出的 WT-SSA-LSTM 预测模型对采集到的羊舍 PM<sub>2.5</sub> 时间序列数据具有较高的预测精度,该模型能挖掘出羊舍环境数据间隐藏的关联信息,较精确地预测羊舍未来 10 min 的 PM<sub>2.5</sub> 浓度变化规律,可用于集约化羊群养殖羊舍中 PM<sub>2.5</sub> 浓度的预测与调控。

## 4 结论

(1)使用小波变换对羊舍环境参数数据进行降噪处理,能在不破坏原有数据特征的情况下保存最大信息量,获取高质量数据集,在保证数据完整性的前提下使模型得到更好的训练。

(2)SSA 具有结构简单、易于实现等优点,由于在搜索过程中引入了随机性,防止算法陷入局部最优,使算法在局部寻优和全局寻优之间保持着良好的平衡。

(3)LSTM 适合处理时间序列敏感问题,在处理非线性问题上具有高稳定性、强鲁棒性的优势,在处理复杂的长距离依赖能力问题时具有优秀的泛化能力和预测精度。

(4)本文提出的 PM<sub>2.5</sub> 浓度预测模型 WT-SSA-LSTM 稳定性强,其 MAE、RMSE、MSE、NRMSE、R<sup>2</sup>为 0.349 7  $\mu\text{g}/\text{m}^3$ 、0.600 4  $\mu\text{g}/\text{m}^3$ 、0.360 5  $\mu\text{g}^2/\text{m}^6$ 、0.005 7 和 0.998 1,具有良好的泛化能力和预测效果,能切实地发现集约化羊养殖中 PM<sub>2.5</sub> 变化规律,为新疆萨福克品种羊羊舍 PM<sub>2.5</sub> 精准预测提供保障,并且可以推广到未来其他应用领域的 PM<sub>2.5</sub> 浓度预测研究中。

## 参 考 文 献

- [1] 郑爽玉,潘丽莎,李军. 近 10 年来我国肉羊产业发展特征与未来挑战[J]. 中国畜牧杂志,2023,59(11):317-322. ZHENG Shuangyu, PAN Lisha, LI Jun. Development characteristics and future challenges of my country's mutton industry in the past 10 years[J]. Chinese Journal of Animal Science, 2023, 59(11): 317-322. (in Chinese)
- [2] 叶小梅,章欣悦,刘洋,等. 畜禽养殖场臭气治理研究进展[J]. 饲料工业,2025,46(7):174-184. YE Xiaomei, ZHANG Xinyue, LIU Yang, et al. Research progress on odor control in livestock and poultry farms[J]. Feed Industry, 2025, 46(7): 174-184. (in Chinese)
- [3] 祖可欣,龚元均,董华斌,等. 昆明市 PM<sub>2.5</sub> 中无机水溶性离子的在线监测及污染特征分析[J]. 北京大学学报(自然科学版),2025,61(2):265-276. ZU Kexin, GONG Yuanjun, DONG Huabin, et al. Characteristics of water-soluble inorganic ions in PM<sub>2.5</sub> of Kunming based on on-line monitoring[J]. Acta Scientiarum Naturalium Universitatis Pekinensis, 2025, 61(2): 265-276. (in Chinese)
- [4] 吴超,周紫静,黄锦铎,等. 基于长短时记忆的农作物生长环境数据预测[J]. 深圳大学学报(理工版),2024,41(5):563-573. WU Chao, ZHOU Zijing, HUANG Jinhua, et al. Prediction of crop growth environmental data using LSTM[J]. Journal of Shenzhen University (Science and Engineering), 2024, 41(5): 563-573. (in Chinese)
- [5] 李鹏,黄文琦,王鑫,等. 数据与知识联合驱动的人工智能方法在电力调度中的应用综述[J]. 电力系统自动化,2024,48(1):160-175. LI Peng, HUANG Wenqi, WANG Xin, et al. Review on application of combined data-knowledge-driven artificial intelligence methods in power dispatching[J]. Automation of Electric Power Systems, 2024, 48(1): 160-175. (in Chinese)
- [6] FENG D, ZHOU B, HAN Q, et al. A novel combined model for predicting humidity in sheep housing facilities[J]. Animals, 2022, 12(23): 3300.
- [7] 梁正龙,祁少刚,畅青霞,等. 基于 LSTM-SVM 的日光温室环境预测模型[J]. 农业机械学报,2025,56(7):279-287. LIANG Zhenglong, QI Shaogang, CHANG Qingxia, et al. Environmental prediction model of solar greenhouse based on LSTM-SVM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(7): 279-287. (in Chinese)
- [8] WAN H, XU R, ZHANG M, et al. A novel model for water quality prediction caused by non-point sources pollution based on deep learning and feature extraction methods[J]. Journal of Hydrology, 2022, 612: 128081.
- [9] KIM B Y, LIM Y K, CHA J W. Short-term prediction of particulate matter (PM<sub>10</sub> and PM<sub>2.5</sub>) in Seoul, South Korea using tree-

- based machine learning algorithms[J]. *Atmospheric Pollution Research*, 2022, 13(10): 101547.
- [10] FARAJI M, NADI S, GHAFFARPASAND O, et al. An integrated 3D CNN - GRU deep learning method for short-term prediction of PM<sub>2.5</sub> concentration in urban environment[J]. *Science of the Total Environment*, 2022, 834: 155324.
- [11] SARKAR N, GUPTA R, KESERWANI P K, et al. Air quality index prediction using an effective hybrid deep learning model [J]. *Environmental Pollution*, 2022, 315: 120404.
- [12] 丁成亮, 郑洪波. 基于改进机器学习的 PM<sub>2.5</sub> 浓度预测模型研究[J]. *大连理工大学学报*, 2024, 64(4): 353 - 360.  
DING Chengliang, ZHENG Hongbo. Study of PM<sub>2.5</sub> concentration prediction model based on improved machine learning[J]. *Journal of Dalian University of Technology*, 2024, 64(4): 353 - 360. (in Chinese)
- [13] GUO Z, YANG C, WANG D, et al. A novel deep learning model integrating CNN and GRU to predict particulate matter concentrations[J]. *Process Safety and Environmental Protection*, 2023, 173: 604 - 613.
- [14] WEN X, LI W. Time series prediction based on LSTM-attention - LSTM model[J]. *IEEE Access*, 2023, 11: 48322 - 48331.
- [15] WANG K, WANG D, ZHOU A, et al. Research on intelligent regulation strategy of negative pressure in gas drainage parallel boreholes based on LSTM prediction model[J]. *Energy*, 2025, 330: 136964.
- [16] ZHANG Y, LI C, JIANG Y, et al. Accurate prediction of water quality in urban drainage network with integrated EMD - LSTM model[J]. *Journal of Cleaner Production*, 2022, 354: 131724.
- [17] 于珍珍, 邹华芬, 于德水, 等. 基于 SSA - LSTM 的玉米土壤含氧量预测模型[J]. *农业机械学报*, 2022, 53(11): 360 - 368, 411.  
YU Zhenzhen, ZOU Huafen, YU Deshui, et al. SSA - LSTM-based model for predicting soil oxygen content in maize[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(11): 360 - 368, 411. (in Chinese)
- [18] BAI Z. Residential electricity prediction based on GA - LSTM modeling[J]. *Energy Reports*, 2024, 11: 6223 - 6232.
- [19] 陆健强, 陈祖城, 兰玉彬, 等. 基于改进麻雀搜索算法和贝塞尔曲线的无人农场机器人路径规划方法[J]. *农业机械学报*, 2025, 56(2): 115 - 123.  
LU Jianqiang, CHEN Zucheng, LAN Yubin, et al. Path planning of robot based on improved sparrow search algorithm and Bessel curve[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2025, 56(2): 115 - 123. (in Chinese)
- [20] 伟利国, 马若飞, 周利明, 等. 基于 SSA - RFR 算法的采棉机测产传感器研究[J]. *农业机械学报*, 2023, 54(9): 154 - 163.  
WEI Liguang, MA Ruofei, ZHOU Liming, et al. Yield sensor of cotton picker based on SSA - RFR algorithm[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(9): 154 - 163. (in Chinese)
- [21] 谢秋菊, 马超凡, 王圣超, 等. 猪舍氨气与二氧化碳浓度变化时序预测模型优化[J]. *农业机械学报*, 2023, 54(7): 381 - 391.  
XIE Qiuju, MA Chaofan, WANG Shengchao, et al. Optimal prediction model for gas concentrations of NH<sub>3</sub> and CO<sub>2</sub> time-series in pig house [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2023, 54(7): 381 - 391. (in Chinese)
- [22] HARROU F, ZEROUAL A, KADRI F, et al. Enhancing road traffic flow prediction with improved deep learning using wavelet transforms[J]. *Results in Engineering*, 2024, 23: 102342.
- [23] 杨苗, 任玲, 王双, 等. 基于 CEEMDAN - 小波阈值的电容式棉种监测信号降噪方法[J]. *农业机械学报*, 2025, 56(5): 71 - 81.  
YANG Miao, REN Ling, WANG Shuang, et al. Noise reduction method of capacitive cotton seed monitoring signal based on CEEMDAN - Wavelet threshold[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2025, 56(5): 71 - 81. (in Chinese)
- [24] 田中大, 潘信澎. 小波消噪和优化支持向量机的网络流量预测[J]. *北京邮电大学学报*, 2022, 45(5): 79 - 84.  
TIAN Zhongda, PAN Xinpeng. Network traffic prediction using wavelet denoising and optimized support vector machine[J]. *Journal of Beijing University of Posts and Telecommunications*, 2022, 45(5): 79 - 84. (in Chinese)
- [25] PACHOULY J, AHIRRAO S, KOTECHA K, et al. A systematic literature review on software defect prediction using artificial intelligence: datasets, data validation methods, approaches, and tools[J]. *Engineering Applications of Artificial Intelligence*, 2022, 111: 104773.
- [26] GROBBELAAR M, PHADIKAR S, GHADERPOUR E, et al. A survey on denoising techniques of electroencephalogram signals using wavelet transform[J]. *Signals*, 2022, 3(3): 577 - 586.
- [27] XUE J, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. *Systems Science & Control Engineering*, 2020, 8(1): 22 - 34.
- [28] 尹航, 吕佳威, 陈耀聪, 等. 基于 LightGBM - SSA - ELM 的新疆羊舍 CO<sub>2</sub> 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 CO<sub>2</sub> 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)
- [29] AWADALLAH M A, AL-BETAR M A, DOUSH I A, et al. Recent versions and applications of sparrow search algorithm[J]. *Archives of Computational Methods in Engineering*, 2023, 30(5): 2831 - 2858.
- [30] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. *Neural Computation*, 1997, 9(8): 1735 - 1780.
- [31] 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 Qinyu, 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)
- [32] DAI Y, WEI J, QIN F. Recurrent neural network (RNN) and long short-term memory neural network (LSTM) based data-driven methods for identifying cohesive zone law parameters of nickel-modified carbon nanotube reinforced sintered nano-silver adhesives[J]. *Materials Today Communications*, 2024, 39: 10899.