

doi:10.6041/j.issn.1000-1298.2022.09.037

基于 SSA – PSO – LSTM 模型的羊舍相对湿度预测技术

郭建军^{1,2} 韩铃钰^{1,2} 董佳琦^{1,3} 周冰^{1,2} 徐龙琴^{1,2} 刘双印^{1,4}

(1. 仲恺农业工程学院广州市农产品质量安全溯源信息技术重点实验室, 广州 510225;
2. 仲恺农业工程学院信息科学与技术学院, 广州 510225; 3. 深圳信息职业技术学院数字媒体学院, 深圳 518172;
4. 仲恺农业工程学院智慧农业创新研究院, 广州 510225)

摘要: 羊舍湿度过高或过低都会直接威胁肉羊健康生长, 及时掌握湿度变化趋势并提前调控是确保规模化肉羊无应激环境下健康养殖的关键。为提高湿度预测精度, 提出了基于奇异谱分析 (SSA)、粒子群优化算法 (PSO)、长短期记忆网络 (LSTM) 的羊舍湿度非线性组合预测模型。利用 SSA 分离出正常序列和噪声序列, 将原始序列转换为平滑序列; 其次通过 PSO 不断迭代优化确定 LSTM 的最优参数组合, 降低 LSTM 的训练成本; 最终依据优化参数建立组合预测模型分别对两序列进行预测, 模型结果之和为最终预测结果。利用该模型对新疆维吾尔自治区 2021 年 3 月 17—27 日期间的羊舍空气相对湿度进行预测, 结果表明, 该组合预测模型具有良好的泛化性、稳定性和收敛性。与标准的 ELM、SVR、LSTM、PSO – LSTM、EMD – PSO – LSTM 等模型相比, 本文提出的 SSA – PSO – LSTM 组合模型具有更高的预测精度, 其均方误差、平均绝对误差和决定系数分别为 1.127%²、0.803% 和 0.988。

关键词: 羊舍; 湿度预测; 奇异谱分析; 粒子群优化; 长短期记忆网络

中图分类号: TP391 **文献标识码:** A **文章编号:** 1000-1298(2022)09-0365-09

OSID:



Prediction of Sheep House Humidity Based on SSA – PSO – LSTM Model

GUO Jianjun^{1,2} HAN Qianyu^{1,2} DONG Jiaqi^{1,3} ZHOU Bing^{1,2} XU Longqin^{1,2} LIU Shuangyin^{1,4}

(1. Guangzhou Key Laboratory of Agricultural Products Quality and Safety Traceability Information Technology, Zhongkai University of Agriculture and Engineering, Guangzhou 510225, China
2. College of Information Science and Technology, Zhongkai University of Agriculture and Engineering, Guangzhou 510225, China
3. School of Digital Media, Shenzhen Institute of Information Technology, Shenzhen 518172, China
4. Academy of Intelligent Agricultural Engineering Innovations, Zhongkai University of Agriculture and Engineering, Guangzhou 510225, China)

Abstract: Sheep house humidity has the characteristics of large time delay, nonlinearity and spatial distribution difference, and the interaction mechanism with a variety of environmental parameters is complex and highly coupled. The humidity prediction model constructed by traditional prediction methods is difficult to meet the needs of large-scale accurate breeding of mutton sheep. Too high or too low humidity of sheep house will directly threaten the healthy growth of sheep. Timely control of the trend of humidity and early regulation is the key to ensure the welfare of sheep. A nonlinear combined prediction model of sheep house humidity based on singular spectrum analysis (SSA), particle swarm optimization (PSO) and optimized long short-term memory network (LSTM) was proposed for accuracy humidity prediction. Firstly, the normal sequence and noise sequence were separated by SSA, and the original sequence was transformed into smooth sequence. Secondly, the optimal parameter combination of LSTM was determined through PSO iterative optimization to reduce the training cost of LSTM. Finally, a combined prediction model was established according to the optimized parameters to predict the two sequences respectively, and the sum of the model results was the final prediction result. The model was

收稿日期: 2021-11-10 修回日期: 2021-12-28

基金项目: 国家自然科学基金项目(61871475)、广州市创新平台建设计划实验室建设专项(201905010006)、广州市重点研发计划项目(201903010043、202103000033)、广东省农业技术研发项目(2018LM2168)、广东省科技计划项目(2020A141405060、2016A020210122、2020B0202080002、2021B42121631)和广州市增城区农村科技特派员项目(2021B42121631)

作者简介: 郭建军(1982—),男,副教授,博士,主要从事农业信息化与自动化、机器学习和数据挖掘研究,E-mail: glgxbaobao@163.com

通信作者: 刘双印(1977—),男,教授,博士,主要从事机器学习、人工智能和智能信息处理研究,E-mail: hdlxylq@126.com

used to predict the air humidity in sheep houses in Xinjiang Uygur Autonomous Region from March 17, 2021 to March 27, 2021. The results showed that the combined prediction model had good generalization, stability and convergence. Compared with the standard ELM, SVR, LSTM, PSO – LSTM, EMD – PSO – LSTM and other models, the proposed SSA – PS – LSTM combined model had higher prediction accuracy. Its mean square error (MSE), mean absolute error (MAE) and determination coefficient (R^2) were $1.127\% ^2$, 0.803% and 0.988, respectively. The experimental results showed that the established model had better prediction performance, which can provide important decisions for formulating optimized sheep house environmental control strategy, solving the lag problem of environmental control effect, and it made a strong support for the healthy growth of sheep.

Key words: sheep house; humidity prediction; singular spectrum analysis; particle swarm optimization; long short-term memory network

0 引言

规模化肉羊养殖场是肉羊栖息地重要场所,羊舍湿度过高或过低直接威胁肉羊健康生长,导致肉羊疾病暴发甚至大批量死亡,造成巨大经济损失^[1-2]。而羊舍湿度具有大时滞、非线性和空间分布差异性的特点,且与多种环境参数相互作用,机理复杂、耦合性强,传统的预测方法构建的湿度预测模型难以满足规模化肉羊精准养殖的需要^[3-4]。因此,采用新型人工智能算法对羊舍湿度精准预测,及时掌握湿度变化规律并提前调控是确保规模化肉羊在无应激环境下健康的关键^[5-6]。

国内外专家学者已对相对湿度预测进行了多年研究,并在温室、果园、土壤温湿度、配电网环境等领域得到成功应用^[7-13]。上述模型虽然取得一定的预测效果,但是仍存在训练时间长、收敛速度慢、欠学习和过学习、易陷入局部最优等不足,难以满足规模化肉羊养殖场湿度精准调控需要。

在线采集的规模化肉羊养殖场湿度数据具有时序性、非线性等特点。而作为深度学习典型方法之一的长短时记忆网络(Long short-term memory, LSTM)具有通过提取历史时序数据特征来挖掘未来数据变化趋势的能力,使其在许多领域的时序数据预测中得到广泛应用^[14-16]。鉴于LSTM在复杂预测任务上的潜力,本文采用LSTM算法进行预测,以期提高精度。

LSTM其性能受参数的影响很大,如何选择最佳参数组合以获得更好的预测结果,是LSTM预测模型必须要解决的主要问题之一。粒子群优化(Particle swarm optimization, PSO)算法具有搜索速度快、效率高、鲁棒性好、算法简单、更容易收敛的优点,在现有的湿度预测模型中,被一些学者研究使用^[17-19],且研究成果均证明粒子群优化算法在湿度预测模型中具有很好的优化效果,因此本文采用PSO进行组合参数的优化。

传感器采集数据时,传感器老化、电磁干扰等问题会造成数据存在噪声,直接对数据进行预测则会影响预测精度。目前,很多学者利用奇异谱分析(Singular spectrum analysis, SSA)法进行预处理,达到了很好的降噪效果^[20-22],证实奇异谱分析具有一定的研究价值。

因此,基于前人的研究成果,为解决单一LSTM模型训练耗时长、泛化能力不足、难以处理大量级数据的问题,本文将奇异谱分析法、粒子群优化算法和长短期记忆网络相结合,提出一种基于SSA – PSO – LSTM的新疆羊舍环境湿度组合预测模型,首先利用SSA分离出正常序列和噪声序列,将原始序列转化为平滑序列;其次通过PSO不断迭代优化确定LSTM的最优参数,降低LSTM的训练成本;最终依据优化参数建立组合预测模型分别对两序列进行预测,模型结果之和为最终预测结果。采用从新疆玛纳斯新澳畜牧有限公司5号育种群母羊舍采集的系统数据,对不同时间间隔的湿度进行预测,以验证该试验模型的有效性。

1 材料与方法

1.1 试验区域

本研究试验数据区域为新疆维吾尔自治区昌吉回族自治州玛纳斯县玛纳斯新澳畜牧有限责任公司基地(北纬44°27'18",东经86°10'47"),总面积约1367 m²、试验(主体区域)面积约422 m²。该基地是一个集萨福克羊育种、种苗繁育、集约化养殖等多功能一体化的萨福克羊综合养殖基地。本试验选取的半封闭式萨福克羊养殖场按《畜禽养殖小区建设管理规范》进行设计,四面墙体均采用砖混结构,顶面采用钢板结构,地面是泥土结构建造半封闭羊舍(长约33.75 m,宽约12.5 m)。羊舍结构分为主体区域(中间,日常休息区域)、遮阳区域(北侧)、活动区域(南侧,饮食区),主体区域与遮阳区域以及活动区域都有可关闭门通道。羊舍夏季采用自然通风

以及北侧的遮阳棚进行避暑,冬季在主体区域进行封闭式养殖,在主体区域安装了温度传感器、湿度传感器、噪声传感器、光照传感器、PM2.5 传感器、PM10 传感器、TSP(总悬浮颗粒物体积比)传感器、CO₂传感器、NH₃传感器以及 H₂S 传感器,传感器分布在主体区域中心下檐,其中 CO₂传感器和 TSP 传感器距地面 2.4 m,其余传感器距地面 3 m 左右,其平面示意图如图 1 所示。




图 1 新疆羊舍监测平面示意图

Fig.1 Schematic of Xinjiang sheep house monitoring

1.2 试验数据采集

以新疆玛纳斯新澳畜牧有限公司 5 号育种群母

羊舍相对湿度为研究对象,利用基于物联网的禽舍养殖环境监测系统,每 10 min 采集一次数据,将采集的 2021 年 3 月 17—27 日的 1 584 条羊舍参数数据作为试验数据,根据文献[23 - 25]可知,噪声过高易导致饲料利用率降低;氨气浓度过高易导致绵羊质量降低;湿热易导致羊的免疫功能下降;硫化氢浓度过高易阻碍动物呼吸中枢,甚至窒息死亡;二氧化碳浓度过高易导致动物缺氧,引发二氧化碳中毒;PM2.5 指数、PM10 指数、TSP 过高易导致传染病及呼吸道疾病的发生;光照强度过高时间过长易抑制动物体内褪黑素的分泌;温度过高易对动物的繁殖能力以及饮水量和采食量产生不利影响。经过以上结果分析及畜牧业养殖专家指导建议,筛选影响因子包括空气温度、空气湿度、二氧化碳浓度、PM2.5 指数、PM10 指数、光照强度、噪声、TSP、氨气浓度、硫化氢浓度等参数,来实现对未来 10 min 的羊舍湿度预测。采集的羊舍养殖环境部分原始数据如表 1 所示。

表 1 2021 年 3 月 17—27 日采集的部分原始数据

Tab.1 Some original data collected from March 16 to March 26, 2021

监测时间	空气 温度/℃	空气相对 湿度/%	二氧化碳体积 比/(μL·L ⁻¹)	PM2.5 指数	PM10 指数	光照强 度/lx	噪声/ dB	TSP/ (μL·L ⁻¹)	氨气浓度/ (mol·L ⁻¹)	硫化氢体积比/ (μL·L ⁻¹)
2021-03-16 00:03:02	9.1	92.0	3160	3.7	4.3	1	32.7	9.9	0	1.7
2021-03-16 00:12:57	9.1	92.0	3175	4.1	4.5	1	34.1	10.7	0	1.7
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
2021-03-26 23:33:14	15	87.0	2175	3.2	4.3	0	32.4	9.3	0	0
2021-03-26 23:43:14	15	87.2	2125	3.7	52.6	0	32	69.3	0	0
2021-03-26 23:53:14	15	87.9	2180	5.1	9.6	0	37.9	18.2	0	0

1.3 试验数据预处理

由于羊舍环境中各参数量纲和数值量级相差过大,为了提高预测精度,应对各数据项进行归一化处理,计算式为

$$Y'_i = \frac{Y_i - Y_{\min}}{Y_{\max} - Y_{\min}} \tag{1}$$

式中 $Y_{\max}$ ——最大值 $Y_{\min}$ ——最小值
 Y_i ——真实值 Y'_i ——归一化值

1.4 性能评价

为评价本文提出的羊舍湿度预测模型性能,采用均方误差(MSE)、平均绝对误差(MAE)和决定系数 R^2 作为预测结果的评价指标。

2 相关理论与技术

2.1 奇异谱分析(SSA)

奇异谱分析^[26]适用于分析具有潜在结构的时间序列,其主要思想是通过将时间序列的轨迹矩阵

进行分解和重构,从中提取出长期趋势信号、周期信号和噪声信号^[27]。该方法将原始序列转化为平滑序列,通过消除噪声进行精准预测,主要用于识别和提取数据的主成分。具体步骤如下:

(1)嵌入

将长度为 N 的一维时间序列 $\boldsymbol{F} = (f_1, f_2, \cdots, f_N)$ 转化为 $d \times K$ 维的轨迹矩阵 $\boldsymbol{F}$ 。其中 $d = N - K + 1$, d 为整数且 $1 < d < N$,定义延迟向量 $\boldsymbol{F}_i = (f_i, f_{i+1}, \cdots, f_{i+d-1})^T$,轨迹矩阵为

$$\boldsymbol{F} = \begin{bmatrix} f_1 & \cdots & f_K \\ \vdots & & \vdots \\ f_d & \cdots & f_N \end{bmatrix} \tag{2}$$

式中 K ——窗口长度

N ——样本数量

(2)奇异值分解

对 $\boldsymbol{F}$ 进行奇异值分解,先对 $\boldsymbol{F}\boldsymbol{F}^T$ 进行特征分解,得到 d 个降序排列的非负特征值 $\lambda_1 \geq \lambda_2 \geq \cdots \geq$

$\lambda_d \geq 0, U_1, U_2, \dots, U_d$ 为对应的正交特征向量, p 为非零特征值的个数, 则

$$E_i = \sqrt{\lambda_i} U_i V_i^T \quad (i = 1, 2, \dots, p) \tag{3}$$

$$V_i = F^T U_i / \sqrt{\lambda_i} \tag{4}$$

$$F = E_1 + E_2 + \dots + E_p \tag{5}$$

式中 $\sqrt{\lambda_i}$ —— F 的奇异值

V_i ——主成分

E_i ——基本矩阵

(3) 分组

将 $F = E_1 + E_2 + \dots + E_p$ 分割成 q 个不同的组 $I_1, I_2, \dots, I_q$, 记作 $I_i = \{i_1, i_2, \dots, i_p\}$, 将 q 个不相交矩阵相加得到 F , 则

$$F_{I_i} = F_{i_1} + F_{i_2} + \dots + F_{i_p} \tag{6}$$

$$F \approx F_{I_1} + F_{I_2} + \dots + F_{I_q} \tag{7}$$

$$\alpha_i = \frac{\lambda_i}{\sum_{i=1}^d \lambda_i} \tag{8}$$

式中 α_i ——每组贡献率

(4) 重构

根据奇异值的贡献率, 利用对角平均将矩阵还原为时间序列。设 Y 为 $d \times K$ 的矩阵, $d^* = \min(d, K), K^* = \max(d, K), K = N - d + 1$, 令 Y_{ij} 为矩阵 Y 的第 i 行第 j 列元素, 若 $d < K$, 则 $Y_{ij}^* = Y_{ij}$, 反之 $Y_{ij}^* = Y_{ji}$ 。具体操作为

$$Y_k = \begin{cases} \frac{1}{k} \sum_{q=1}^k Y_{q, k-q+1}^* & (1 \leq k < d^*) \\ \frac{1}{d^*} \sum_{q=1}^{d^*} Y_{q, k-q+1}^* & (d^* \leq k < K^*) \\ \frac{1}{N-k+1} \sum_{q=K-K^*+1}^{N-K^*+1} Y_{q, k-q+1}^* & (K^* \leq k < N) \end{cases} \tag{9}$$

2.2 粒子群优化算法 (PSO)

粒子群优化算法^[28]是一种全局随机搜索算法, 通过追随当前搜索到的最优值来寻找全局最优, 其基础是信息的社会共享。PSO 具有算法简洁、易于实现、参数调整较少、不需要梯度信息的优点, 可综合 3 条简单准则来构建这个行为: 远离最近的邻居; 向目标靠近; 向群体的中心靠近。文献[29]试验结果显示, 采用 PSO 优化算法代替传统 BPTT(基于时间的反向传播)算法对 LSTM 网络内部权值更新, 进行轨迹预测, 所需时间更短, 能够满足在线预测的时间要求, 精度也有所提高。具体步骤如下:

(1) 初始化参数

设置阈值 ε , 最大迭代次数 $N_{\max}$, 粒子初始位置 $z_i^{(0)}$, 每个粒子初始速度 $v_i^{(0)}$, 粒子群规模 M 。

(2) 个体极值与全局最优解

测量每个粒子的适应值 $z_i^{(0)}$, 表示为 $D_i^{(0)}$, $p_i^{(0)} = z_i^{(0)}$ (粒子初始位置为当前个体最优), 根据 $D_i^{(0)} = \min\{D_1^{(0)}, D_2^{(0)}, \dots, D_m^{(0)}\}$ 找出全局最优 $p_g^{(0)}$ 。

(3) 更新速度和位置

令 $k = 0, k \leftarrow k + 1$, 根据公式

$$v_{id}^{(k+1)} = w v_{id}^{(k)} + c_1 r_1 (p_{id}^{(k)} - z_{id}^{(k)}) + c_2 r_2 (p_{gd}^{(k)} - z_{id}^{(k)}) \tag{10}$$

式中 r_1, r_2 —— $[0, 1]$ 之间的随机数

c_1, c_2 ——学习因子

w ——惯性权重因子

$p_{id}^{(k)}$ ——当前粒子局部最优值

$p_{gd}^{(k)}$ ——全局最优值

更新粒子速度 $v_i^{(k)}$, 根据公式

$$z_{id}^{(k+1)} = z_{id}^{(k)} + v_{id}^{(k+1)} \tag{11}$$

更新粒子位置 $z_i^{(k)}$ 。

2.3 长短时记忆网络 (LSTM)

长短时记忆网络^[30]是为了解决长期依赖而提出的一种特殊的 RNN(循环神经网络)变体, 其在 RNN 的基础上在隐藏层增加了记忆模块, 通过在网络拓扑结构中引入门控单元, 来控制记忆细胞删减或添加信息, 能够有效解决反向传播过程中存在的梯度消失和梯度爆炸的问题。

LSTM 神经网络由输入层、输出层和隐含层 3 部分组成, 并由多个循环单元相互递归连接, 每个神经元看作一个记忆细胞, 每个记忆模块由输入门、输出门和遗忘门构成, 其基本结构^[31]如图 2 所示。




图 2 LSTM 结构图

Fig. 2 LSTM structure diagram

(1) 输入门

输入门用于控制网络当前输入数据 x_t 流入记忆单元的数量, 也就是有多少可以保存在 c_t 中, 输入门公式为

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \tag{12}$$

式中 σ ——sigmoid 函数

i_t ——输入门 W_i ——输入门权重

b_i ——输入门偏置

h_{i-1} ——上一时刻隐藏层单元的输出

(2) 遗忘门

遗忘门可以控制信息的选择或遗忘, 决定历史信息中的哪些信息被丢弃, 也就是判断上一时刻记忆单元 c_{i-1} 中的信息对当前记忆单元 c_i 的影响程度, 遗忘门公式为

$$f_i = \sigma(W_f[h_{i-1}, x_i] + b_f) \quad (13)$$

$$\tilde{c}_i = \tanh(W_c[h_{i-1}, x_i] + b_c) \quad (14)$$

$$c_i = f_i \odot c_{i-1} + i_i \odot \tilde{c}_i \quad (15)$$

式中 W_c ——候选向量权重

W_f ——遗忘门权重

b_f ——遗忘门偏置

f_i ——遗忘门

b_c ——候选向量偏置

$\tilde{c}_i$ —— t 时刻的候选向量更新值

(3) 输出门

输出门控制记忆单元 c_i 对当前输出值 h_i 的影响, 也就是记忆单元中的哪一部分会在 t 时刻输出, 输出门公式为

$$o_i = \sigma(W_o[h_{i-1}, x_i] + b_o) \quad (16)$$

$$h_i = o_i \odot \tanh(c_i) \quad (17)$$

式中 o_i ——输出门

W_o ——输出门权重

b_o ——输出门偏置项

3 试验与结果分析

3.1 试验数据

本文选取的样本数据为新疆玛纳斯新澳畜牧有限公司 5 号育种群母羊舍 2021 年 3 月 17—27 日的养殖环境数据, 每 10 min 记录一次, 共计 1 584 条。将空气温度、空气湿度、二氧化碳含量、PM2.5 指数、PM10 指数、光照强度、噪声、总悬浮颗粒物体积比、氨气浓度、硫化氢体积比共 10 种环境参数作为输入参数, 用以预测 10 min 后湿度数据, 采用前 90% 的数据作为训练集, 后 10% 数据作为验证集, 其羊舍原始湿度数据如图 3 所示, 据图 3 可知, 羊舍湿度数据呈现周期性、非线性的特点。

3.2 试验环境

本试验环境为: 处理器 Intel I5 - 5200U, CPU 频率 2.2 GHz, 内存 8 GB, 操作系统 Windows 10, 程序设计语言 Python 3.7, 集成开发环境 Anaconda 3, 编程语言为 Python 3.6, 试验采用 Keras 和 Sklearn 来实现基于 SSA - PSO - LSTM 组合模型的羊舍空气湿度预测。




图 3 原始湿度变化曲线

Fig. 3 Raw humidity data chart

3.3 试验过程

为了提高湿度预测模型性能, 将 SSA、PSO 和 LSTM 模型有机结合, 构建基于 SSA - PSO - LSTM 的羊舍养殖环境湿度非线性组合预测模型, 其基本思想: 对羊舍养殖环境数据进行归一化处理, 将 SSA 作为长短时记忆神经网络的前置预处理系统, 根据公式设置嵌入维度分离出正常序列和噪声序列, 然后分别对正常序列和噪声序列进行长短时记忆神经网络预测。使用 PSO 优化算法对两个模型中神经元个数进行调优, 使其精度进一步提高, 最后将两个模型结果做和得出预测结果。具体步骤如图 4 所示。

(1) 将新疆羊舍湿度数据标准化处理, 并划分样本训练集和测试集。其中前 90% 用于训练, 后 10% 用于测试。

(2) 采用奇异谱分析法 (SSA) 将训练集数据分为 i 组, 经 SSA 分解后全部分量组如图 5、6 所示。对序列进行重构, 将分量值超出 $[-0.5, 0.5]$ 的序列做和得到趋势序列使其趋势序列的贡献度大于 99%。剩余的序列做和得到噪声序列。

(3) 使用粒子群优化算法 (PSO) 对 LSTM 算法的迭代数及神经元个数进行调优, 并分别对趋势序列和噪声序列进行预测, 得到基于趋势序列的 PSO - LSTM 模型和基于噪声序列的 PSO - LSTM 模型。其中预设迭代数范围为 $[0, 10]$, 神经元个数为 $[0, 20]$, 共寻优 20 轮, 每轮 5 个粒子, 以 R^2 作为适应度, 基于趋势序列的 PSO - LSTM 模型寻优结果显示, PSO 在第 2 轮之后每代的最优适应度均大于 0.985, 在第 15 轮之后每代的最优适应度均大于 0.99, 已基本上满足 LSTM 模型的精度要求。

(4) 将基于趋势序列的 PSO - LSTM 模型和基于噪声序列的 PSO - LSTM 模型预测结果相加, 得到最终结果。预测结果如图 7 所示。

3.4 结果分析

为了验证提出模型的预测性能, 将本文所提出的 SSA - PSO - LSTM 预测模型同其他 7 个模型进行对比, 包括支持向量回归^[32] (Support vector




图 4 预测流程图

Fig. 4 Forecast flow chart




图 5 SSA 分量组 1

Fig. 5 SSA component group 1




图6 SSA分量组2
Fig.6 SSA component group 2




图7 SSA-PSO-LSTM预测结果
Fig.7 SSA-PSO-LSTM prediction results

regression,SVR)、极限学习机^[33](Extreme learning machine, ELM)、SSA-PSO-ELM、LSTM、GA(遗传算法)-LSTM、PSO-LSTM、EMD(经验模态分解)-PSO-LSTM,试验以相同数据源为基础,采用训练集对上述模型进行训练,测试集对模型预测性能进行验证,并采用均方误差、平均绝对误差和决定系数 R^2 作为预测模型的评价指标,预测模型结果对比如图8所示。

由图8可知,不同预测模型预测结果的拟合曲线趋势相同,但波动较大,易出现极值点,而本文所




图8 预测结果对比
Fig.8 Comparison of prediction results

提出的SSA-PSO-LSTM的预测曲线与真实值曲线最为接近,能够很好地拟合羊舍湿度非线性变化曲线,取得较好的预测效果。

本文所提出的SSA-PSO-LSTM预测模型以及7个对比模型的性能评价指标如表2所示。可以看出,本文提出的SSA-PSO-LSTM预测模型的均方误差、平均绝对误差和 R^2 分别为 $1.127\%^2$ 、

表 2 不同预测模型试验结果对比

prediction models			
预测模型	均方误差/% ²	平均绝对误差/%	R ²
SVR	8.229	2.081	0.913
ELM	5.220	1.668	0.945
LSTM	4.393	1.692	0.954
GA-LSTM	2.405	1.148	0.975
PSO-LSTM	2.235	1.142	0.976
SSA-PSO-ELM	4.522	1.332	0.952
EMD-PSO-LSTM	8.911	2.000	0.906
SSA-PSO-LSTM	1.127	0.803	0.988

0.803%和0.988,各项评价指标均优于其它预测模型,与传统的SVR、ELM和LSTM相比,该算法的均方误差分别降低了86.30%、78.41%和74.35%,表明仅靠单一模型自身训练,不能达到最优效果,其预测效果不能满足实际需求。与经过优化处理后的GA-LSTM、PSO-LSTM相比,本文提出的算法的均方误差分别降低了53.14%和49.57%,表明采用优化算法能够提高模型的预测精度,且粒子群优化算法的寻优效果优于遗传算法,但原始数据由于存在噪声干扰,仅通过优化后的模型预测效果不理想,而本文所提出的经过SSA降噪处理后的模型效果更优。同时将EMD-PSO-LSTM模型与本文所提模型对比,其MSE更是降低了87.35%,试验结果表明SSA对羊舍非线性湿度序列中的非平稳特征提取具

有优异效果。为了更好地说明该模型的优越性,避免模型的偶然性,将SSA-PSO模型算法应用于ELM算法上,同样相比原模型拥有更好的预测准确率。结果表明,本文提出的SSA-PSO-LSTM预测模型具有更高的准确性与更好的拟合性,更有利于单一时间序列预测,实时性较好,具有较强记忆功能的LSTM网络,能够对历史数据进行记忆,准确预测10 min后羊舍空气湿度,为羊舍空气湿度预测预警提供了强有力的决策依据。

4 结论

- (1)SSA能够提取时间序列中的不同成分序列,直接分离原始信号的趋势、震荡和噪声信息,减少计算量,降低数据的复杂度,有效压缩研究对象的时空信息,适用于非线性数据进行时频分析。
- (2)采用PSO算法对LSTM进行全局搜索,解决了依据经验选取参数的弊端,对比GA算法具有更快的收敛速度,可以获得更优参数来优化模型,使LSTM的R²从0.954升至0.976。
- (3)试验证明,本文提出的SSA-PSO-LSTM模型能够有效地预测短时间羊舍空气湿度变化趋势,预测精度高于SVR、ELM等典型的预测模型,具有良好的泛化性、稳定性和收敛性,预测结果可对羊群生长环境改善提供重要支持,有利于羊群健康成长,为羊舍空气湿度预警提供有力支撑。

参 考 文 献

[1] 张灿. 湿热应激对藏绵羊和山羊生产性能、瘤胃发酵及血液生化指标影响的比较研究[D]. 雅安:四川农业大学,2016.
ZHANG Can. Comparative study on the effects of damp heat stress on production performance, rumen fermentation and blood biochemical indexes of Tibetan sheep and goats[D]. Yaan:Sichuan Agricultural University, 2016. (in Chinese)

[2] 吴伟东. 影响舍饲羊生长速度的环境因素[J]. 吉林畜牧兽医,2021,42(2):83-84.
WU Weidong. Environmental factors affecting the growth rate of house fed sheep[J]. Jilin Animal Husbandry and Veterinary, 2021,42(2):83-84. (in Chinese)

[3] LI H, YANG Y, CHENG Y, et al. Application of time series model in relative humidity prediction[C]//Journal of Physics: Conference Series. IOP Publishing, 2020: 012017.

[4] ARULMOZHI E, BASAK J K, SIHALATH T, et al. Machine learning-based microclimate model for indoor air temperature and relative humidity prediction in a swine building[J]. Animals, 2021, 11(1): 222.

[5] 徐巧年. 基于物联网的肉羊养殖基地环境监测系统设计[J]. 信息技术与信息化,2020(9):34-36.
XU Qiaonian. Design of environmental monitoring system for mutton sheep breeding base based on Internet of things[J]. Information Technology and Informatization, 2020(9):34-36. (in Chinese)

[6] 李晓东. 肉羊养殖场的环境控制措施[J]. 畜牧兽医科技信息,2019(5):49.
LI Xiaodong. Environmental control measures for mutton sheep farms[J]. Animal Husbandry and Veterinary Science and Technology Information,2019(5):49. (in Chinese)

[7] 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)

[8] 韦玉翡,赵建贵,高安琪,等. 温室小气候温度和湿度动态模型预测及验证[J]. 湖北农业科学,2021,60(9):32-38.
WEI Yufei, ZHAO Jiangui, GAO Anqi, et al. Prediction and verification of greenhouse microclimate temperature and humidity dynamic model[J]. Hubei Agricultural Science, 2021,60(9):32-38. (in Chinese)

[9] 郁莹璐,徐达宇,寿国忠,等. 基于经验模态分解和小波神经网络的温室温湿度预测[J]. 江苏农业科学,2019,47(1):211-216.
YU Yingjun, XU Dayu, SHOU Guozhong, et al. Greenhouse temperature and humidity prediction based on empirical mode decomposition and wavelet neural network[J]. Jiangsu Agricultural Science, 2019,47(1):211-216. (in Chinese)

[10] 周亚同,赵翔宇,何峰,等. 基于高斯过程混合模型的大气温湿度预测[J]. 农业工程学报,2018,34(5):219 - 226.
ZHOU Yatong, ZHAO Xiangyu, HE Feng, et al. Prediction of large temperature and humidity based on Gaussian process mixture model[J]. Transactions of the CSAE, 2018,34(5):219 - 226. (in Chinese)

[11] 温永菁,李春,薛庆禹,等. 基于逐步回归与 BP 神经网络的日光温室温湿度预测模型对比分析[J]. 中国农学通报,2018,34(16):115 - 125.
WEN Yongjing, LI Chun, XUE Qingyu, et al. Comparative analysis of temperature and humidity prediction model of solar greenhouse based on stepwise regression and BP neural network[J]. Chinese Agronomy Bulletin, 2018,34(16):115 - 125. (in Chinese)

[12] 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)

[13] 杨再宋,谢菊芳,胡东,等. 基于 AW - GA - BP 算法的配电网设备运行环境相对湿度的预测方法及应用[J]. 重庆师范大学学报(自然科学版),2019,36(6):104 - 109,2.
YANG Zaishong, XIE Jufang, HU Dong, et al. Prediction method and application of relative humidity of distribution network equipment operating environment based on AW - GA - BP algorithm[J]. Journal of Chongqing Normal University (Natural Science Edition), 2019,36(6):104 - 109,2. (in Chinese)

[14] 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)

[15] 方黄峰,刘瑶瑶,张文彪. 基于 LSTM 神经网络的流化床干燥器内生物质颗粒湿度预测[J]. 化工学报,2020,71(增刊 1):307 - 314.
FANG Huangfeng, LIU Yaoyao, ZHANG Wenbiao. Prediction of biomass particle humidity in fluidized bed dryer based on LSTM neural network[J]. Journal of Chemical Industry, 2020,71(Supp.1):307 - 314. (in Chinese)

[16] 陈亮,张媛媛,刘韵婷. 基于改进的 LSTM 的药品温湿度预测方法[J]. 电子测量与仪器学报,2019,33(1):106 - 112.
CHEN Liang, ZHANG Yuanyuan, LIU Yunting. Drug temperature and humidity prediction method based on improved LSTM[J]. Journal of Electronic Measurement and Instrumentation, 2019,33(1):106 - 112. (in Chinese)

[17] 岳有军,权峻,王红君,等. 基于 PSO - LM - RBF 温室温湿度预测[J]. 节水灌溉,2019(3):94 - 97.
YUE Youjun, QUAN Jun, WANG Hongjun, et al. Greenhouse temperature and humidity prediction based on PSO - LM - RBF[J]. Water Saving Irrigation, 2019(3):94 - 97. (in Chinese)

[18] 匡亮,华驰,邓小龙,等. 一种优化极限学习机的果园湿度预测方法[J]. 传感技术学报,2019,32(3):418 - 423.
KUANG Liang, HUA chi, DENG Xiaolong, et al. An orchard humidity prediction method based on optimized limit learning machine[J]. Journal of Sensing Technology, 2019,32(3):418 - 423. (in Chinese)

[19] 吉威,刘勇,甄佳奇,等. 基于随机权重粒子群优化极限学习机的土壤湿度预测[J]. 新疆大学学报(自然科学版),2020,37(2):150 - 155,189.
JI Wei, LIU Yong, ZHEN Jiaqi, et al. Soil moisture prediction based on stochastic weighted particle swarm optimization limit learning machine[J]. Journal of Xinjiang University, 2020,37(2):150 - 155,189. (in Chinese)

[20] 王丽丽,李新,冉有华,等. 基于奇异谱分析-灰狼优化-支持向量回归混合模型的黑河正义峡月径流预测[J]. 遥感技术与应用,2020,35(2):355 - 364.
WANG Lili, LI Xin, RAN Youhua, et al. Monthly runoff prediction of Zhengyixia in the Heihe River based on singular spectrum analysis - gray wolf optimizer - support vector regression hybrid model[J]. Remote Sensing Technology and Application, 2020,35(2):355 - 364. (in Chinese)

[21] 商强,杨兆升,张伟,等. 基于奇异谱分析和 CKF - LSSVM 的短时交通流量预测[J]. 吉林大学学报(工学版),2016,46(6):1792 - 1798.
SHANG Qiang, YANG Zhaosheng, ZHANG Wei, et al. Short term traffic flow prediction based on singular spectrum analysis and CKF - LSSVM[J]. Journal of Jilin University (Engineering Edition), 2016,46(6):1792 - 1798. (in Chinese)

[22] 殷豪,曾云,孟安波,等. 基于奇异谱分析-模糊信息粒化和极限学习机的风速多步区间预测[J]. 电网技术,2018,42(5):1467 - 1474.
YIN Hao, ZENG Yun, MENG Anbo, et al. Multi-step interval prediction of wind speed based on singular spectrum analysis fuzzy information granulation and limit learning machine[J]. Power Grid Technology, 2018,42(5):1467 - 1474. (in Chinese)

[23] 焦伟娜,李卓程,刘虹家,等. 新疆南北疆两羊场春季养殖环境指标差异比较及羔羊健康状况调查[J]. 中国畜牧兽医,2020,47(1):306 - 314.
JIAO Weina, LI Zhuocheng, LIU Hongjia, et al. Comparison of breeding environment indexes between two sheep farms in North and South Xinjiang in spring and investigation on lamb health status[J]. China Animal Husbandry and Veterinary, 2020,47(1):306 - 314. (in Chinese)

[24] 高航,袁雄坤,姜丽丽,等. 猪舍环境参数研究综述[J]. 中国农业科学,2018,51(16):3226 - 3236.
GAO Hang, YUAN Xiongkun, JIANG Lili, et al. Review on environmental parameters of pig house[J]. Scientia Agricultura Sinica, 2018,51(16):3226 - 3236. (in Chinese)

[25] 朱莹琳,邵广龙,曹子薇,等. 北方寒冷地区有窗式羊舍冬季环境质量分析与评价[J]. 黑龙江畜牧兽医,2019(21):51 - 56.
ZHU Yinglin, SHAO Guanglong, CAO Ziwei, et al. Analysis and evaluation of winter environmental quality of windowed sheep houses in cold areas of North China[J]. Heilongjiang Animal Husbandry and Veterinary, 2019(21):51 - 56. (in Chinese)

[17] 夏吉庆,郑先哲,刘成海. 储藏方式对稻米黏度和脂肪酸含量的影响[J]. 农业工程学报, 2008,24(11):260–263.
XIA Jiqing, ZHENG Xianzhe, LIU Chenghai. Effects of storage methods on viscosity and fattyacid content of rice [J]. Transactions of the CSAE, 2008,24(11):260–263. (in Chinese)

[18] DEKA S C, SOOD D R, GUPTA S K. Effect of storage on fatty acid profiles of basmati rice (*Oryza sativa* L.) genotypes[J]. Journal of Food Science and Technology (Mysore),2000,37(3):217–221.

[19] ZHAO Q, GUO H, HOU D, et al. Influence of temperature on storage characteristics of different rice varieties[J]. Cereal Chemistry, 2021,98(4):935–945.

[20] 刘欣,姚远航,陈文若,等. 动态温湿度条件下糙米主要储藏品质指标变化[J]. 食品科学, 2019,40(3):245–250.
LIU Xin, YAO Yuanhang, CHEN Wenruo, et al. Changes in main storage quality indices of brown rice under dynamic temperature and humidity conditions[J]. Food Science,2019,40(3):245–250. (in Chinese)

[21] 赵卿宇,郭辉,沈群. 两种香米在不同温度储存过程中理化性质和食用品质的变化[J]. 食品科学, 2021,42(9):160–168.
ZHAO Qingyu, GUO Hui, SHEN Qun. Variations in physicochemical properties and eating quality of two fragrant rice varieties during storage at different temperatures[J]. Food Science,2021,42(9):160–168. (in Chinese)

[22] 曹俊,蒋伟鑫,刘欣,等. 温度动态变化对不同水分含量稻谷主要品质变化的影响[J]. 食品科学, 2016,37(17):76–83.
CAO Jun, JIANG Weixin, LIU Xin, et al. Effects of dynamic temperature changes on main quality attributes of paddy rice with different moisture contents[J]. Food Science,2016,37(17):76–83. (in Chinese)

[23] 宋婷,白晶,翟爱华. 储藏后对不同加工精度大米食用品质变化规律的研究[J]. 粮食与油脂, 2016,29(12):70–74.
SONG Ting, BAI Jing, ZHAI Aihua. Change regularity of different precision of milled riceedible quality after storage [J]. Cereals & Oils, 2016,29(12):70–74. (in Chinese)

[24] 毕文雅,张来林,石天玉,等. 低温、准低温储藏对甬优 15 优质稻质构特性的影响研究[J]. 粮食与饲料工业,2021(3):1–3,9.
BI Wenya, ZHANG Lailin, SHI Tianyu, et al. Study on the effect of low temperatureand quasi-low temperature storage on the texture characteristics of high-quality rice of Yongyou15[J]. Cereal & Feed Industry,2021(3):1–3,9. (in Chinese)

[25] 袁道骥,史韬琦,王月慧,等. 水分对低温储藏优质稻品质的影响[J]. 中国粮油学报, 2019,34(6):6–11.
YUAN Daoji, SHI Taoqi, WANG Yuehui, et al. Effect of moisture on quality of low temperature storage high quality rice[J]. Journal of the Chinese Cereals and Oils Association, 2019,34(6):6–11. (in Chinese)

[26] IJIMA K, SUZUKI K, HORI K, et al. Endosperm enzyme activity is responsible for texture and eating quality of cooked rice grains in Japanese cultivars[J]. Bioscience, Biotechnology, and Biochemistry, 2019,83(3):502–510.

[27] 高振鹏,宋杨,张美娜,等. 益生菌发酵苹果汁过程中总酚酸变化与动力学研究[J]. 农业机械学报,2019,50(11):350–356.
GAO Zhenpeng, SONG Yang, ZHANG Meina, et al. Changes and kinetics of total phenolic acids of apple juice fermented by probiotics[J]. Transactions of the Chinese Society for Agricultural Machinery,2019,50(11):350–356. (in Chinese)

(上接第 373 页)

[26] ELSNER J B, TSONIS A A. Singular spectrum analysis—a new tool in time series analysis[M]. New York: Plenum Press, 1996: 39–50.

[27] 孔雯,车权,赵慧荣,等. 基于奇异谱分析与长短时记忆神经网络的电厂存煤量短期预测[J]. 信息与控制,2020,49(6):742–751.
KONG Wen, CHE Quan, ZHAO Huirong, et al. Short term prediction of coal storage in power plant based on singular spectrum analysis and short-term memory neural network[J]. Information and Control, 2020,49(6):742–751. (in Chinese)

[28] EBERHART R, KENNEDY J. A new optimizer using particle swarm theory[C]//Mhs95 Sixth International Symposium on Micro Machine & Human Science. IEEE, 2002.

[29] 谢磊,丁达理,魏政磊,等. AdaBoost–PSO–LSTM 网络实时预测机动轨迹[J]. 系统工程与电子技术,2021,43(6):1651–1658.
XIE Lei, DING Dali, WEI Zhenglei, et al. Real time prediction of maneuver trajectory using AdaBoost–PSO–LSTM network [J]. Systems Engineering and Electronic Technology,2021,43(6):1651–1658. (in Chinese)

[30] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8):1735–1780.

[31] 魏腾飞,潘庭龙. 基于改进 PSO 优化 LSTM 网络的短期电力负荷预测[J]. 系统仿真学报,2021,33(8):1866–1874.
WEI Tengfei, PAN Tinglong. Short term power load forecasting based on improved PSO optimized LSTM network[J]. Journal of System Simulation,2021,33(8):1866–1874. (in Chinese)

[32] BASAK D, SRIMANTA P, PATRANBIS D C. Support vector regression[J]. Neural Information Processing Letters & Reviews, 2007,11(10):203–224.

[33] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70(1/3):489–501.