doi:10.6041/j.issn.1000-1298.2019.S0.054

基于 EMD - LSTM 的猪舍氨气浓度预测研究

杨 亮¹ 刘春红^{1,2} 郭昱辰¹ 邓 河¹ 李道亮^{1,2} 段青玲^{1,2} (1. 中国农业大学信息与电气工程学院,北京100083; 2. 北京市农业物联网工程技术研究中心,北京100083)

摘要:为提高猪舍氨气浓度预测的精度和效率,提出了基于经验模态分解和长短时记忆神经网络(EMD-LSTM)的 猪舍氨气浓度预测模型。首先,将猪舍氨气浓度时间序列数据进行经验模态分解,得到不同时间尺度下的固有模 态分量(IMF);然后,对 IMF 建立 LSTM 氨气浓度预测模型;最后,将各分量的预测结果相加求和作为猪舍氨气浓度 的最终预测值。将本文提出的预测模型应用于江苏省宜兴市实验基地某养猪场的氨气浓度预测中,并与 Elman 模 型、循环神经网络(RNN)模型、LSTM 模型和 EMD-LSTM 模型进行了对比实验,结果表明,基于 EMD-LSTM 模型 的预测精度较高,预测结果与真实值相比较,平均绝对误差、平均绝对百分误差和均方根误差为 0.072 3 mg/m³、 0.625 7% 和 0.094 5 mg/m³。

关键词: 猪舍; 氨气浓度; 经验模态分解; 长短时记忆神经网络 中图分类号: TP391 文献标识码: A 文章编号: 1000-1298(2019)S0-0353-08

Prediction of Ammonia Concentration in Fattening Piggery Based on EMD - LSTM

YANG Liang¹ LIU Chunhong^{1,2} GUO Yuchen¹ DENG He¹ LI Daoliang^{1,2} DUAN Qingling^{1,2}
 (1. College of Information and Electrical Engineering, China Agricultural University, Beijing 100083, China
 2. Beijing Engineering and Technology Research Center for Internet of Things in Agriculture, Beijing 100083, China)

Abstract: Ammonia is one of the key environmental parameters affecting the healthy growth of pigs. And it is the key to ensure the healthy growth of pigs by timely and accurately grasping the trend of ammonia concentration in piggeries. In order to improve the accuracy and efficiency of ammonia concentration prediction in piggeries, a prediction model of ammonia concentration in piggeries based on empirical mode decomposition and long short-term memory neural network (EMD - LSTM) was proposed. Firstly, the sequence data of ammonia concentration was decomposed to obtain the intrinsic mode function (IMF) at different time scales. Then, the long-term memory neural network prediction model was established for the intrinsic mode function. Finally, the prediction results of the components were summed as the final value of the concentration. The prediction model proposed was applied to the prediction of ammonia concentration in a pig farm in Yixing, Jiangsu Province. In order to verify the performance of the prediction model, the prediction model was compared with Elman prediction model, recurrent neural network (RNN) prediction model, long-term memory neural network prediction model and empirical mode decomposition and recurrent neural network prediction model. The results showed that the prediction accuracy of the empirical mode decomposition and long-term memory neural network model was higher. Compared with the real values, the mean absolute error, mean absolute percentage error and root mean square error were 0.072 3 mg/m^3 , 0.625 7% and 0.094 5 mg/m^3 , respectively.

Key words: piggeries; ammonia concentration; empirical mode decomposition; long short-term memory neural network

0 引言

随着畜禽养殖规模化、集约化、智能化发展,生

猪产量大幅度提高,经济效益稳健增长,2018年我 国猪肉产量5亿吨,生猪存栏4亿头,生猪出栏6亿 头。在生猪养殖中会产生大量有害气体,如氨气、硫

收稿日期:2019-04-25 修回日期:2019-05-20

基金项目:国家重点研发计划项目(2016YFD0700200)

作者简介:杨亮(1992—),男,硕士生,主要从事农业信息感知与预测预警研究,E-mail: muskmelon_yl@163.com

通信作者:刘春红(1977—),女,副教授,博士,主要从事农业物联网研究,E-mail: sophia_liu@ cau. edu. cn

化氢、二氧化碳、挥发性有机化合物和甲烷等,其中 氨气浓度是评价猪舍环境的关键指标之一^[1],猪舍 环境的好坏直接决定生猪的生长状态及生猪养殖行 业生产效益。氨气是一种有毒有害气体,具有强烈 的刺激性臭味,影响猪只的正常生长,导致猪只免疫 力和生产性能下降,诱发猪只呼吸道疾病,给生猪养 殖行业带来经济损失,而且对生态环境和人类健康 也产生严重的影响^[2]。及时、准确地预测猪舍氨气 浓度的变化情况,对于改善猪只生存环境和提高动 物福利具有非常重要的实际意义。

国内外研究者对氨气浓度的预测预警提出了一 些方法,主要分为两大类:基于理化统计的模型和基 于智能算法的模型。基于理化统计的模型,从物理 化学角度定量分析了氨气排放的变化规律^[3-9]。基 于智能算法的模型,利用机器学习算法对数据集进 行训练测试,构建基于最优参数的氨气预测模 型^[10-18]。

从国内外研究现状来看,基于理化统计的预测 模型需要精确的实验数据支持,其工作量大,预测模 型的实用性和稳定性差,预测精度难以保证:基于智 能算法的预测模型能够分析更多的环境影响因素. 实用性较强。但是,猪舍环境复杂,多种环境因素互 相影响。目前基于多种环境参数的猪舍氨气浓度预 测研究较少,而现有的模型预测精度也有待提高。 为了能够准确预测猪舍氨气浓度变化,本文提出基 **于** EMD - LSTM (Empirical mode decomposition-long short-term memory)的猪舍氨气浓度预测模型,首先 采用经验模态分解(EMD)算法对猪舍氨气浓度数 据进行多时间尺度分解,然后利用长短时记忆神经 网络(LSTM)算法对氨气浓度分解数据和猪舍环境 参数数据进行建模预测,优化调整预测模型参数,最 后将各分量的预测结果相加求和作为猪舍氨气浓度 的最终预测值,以此构建猪舍氨气浓度的预测模型, 实现猪舍氨气浓度变化的准确预测。

1 研究方法

1.1 经验模态分解(EMD)

EMD 是一种处理非线性、非平稳信号的数据分 析方法^[19]。该方法无需预设基函数,依据原始信号 根据其自身的时间尺度特征自适应地分解成有限个 具有不同尺度、平稳性和周期波动性特点的本征模 函数(Intrinsic mode function, IMF)和一个代表原始 信号总体趋势的残余量(RES)^[20-21],不同时间尺度 的 IMF 分量包含原始信号的局部特征信息,从而使 非平稳的原始信号数据平稳化^[22]。其中,每个 IMF 分量必须同时满足两个条件要求^[23]:原始信号局部 利用 EMD 算法对原始信号 *X*(*t*)进行分解的步骤^[24-25]:

(1)首先识别原始信号 X(t)的所有极值点,并
 用三次样条插值函数拟合出原始信号的上下包络线
 e₁(t)和 e₂(t),计算上下包络线的平均值

$$e(t) = (e_1(t) + e_2(t))/2$$
(1)

原始信号 X(t) 与包络线平均值 e(t) 的差值为

$$c_1(t) = X(t) - e(t)$$
 (2)

(2)判断 c₁(t)是否满足 IMF 分量的条件要求, 如果满足条件要求,将 c₁(t)作为原始信号的第一个 IMF 分量,记为 f₁(t);如果不满足 IMF 分量的条件 要求,则把 c₁(t)作为新的原始信号重复步骤(1), 直到满足 IMF 分量的条件要求为止。

(3)用原始信号 X(t) 减去 $f_1(t)$ 得到残余量 $r_1(t)$,将 $r_1(t)$ 作为新的原始信号,重复上面的步骤 得到原始信号的第2个 IMF 分量 $f_2(t)$,得到残余量 $r_2(t)$ 。

$$\begin{cases} r_{1}(t) = X(t) - f_{1}(t) \\ r_{2}(t) = r_{1}(t) - f_{2}(t) \\ \vdots \\ r_{n}(t) = r_{n-1}(t) - f_{n}(t) \end{cases}$$
(3)

(4) 直到 r_n(t) 变成一个单调函数或常量时,
 EMD 分解过程停止,即 n 个 IMF 和1 个残余量r_n(t)
 求和得原始信号 X(t)。

$$X(t) = \sum_{i=1}^{n} f_i(t) + r_n(t)$$
 (4)

式中 *f_i(t)*—*n* 个频率从高到低的本征模态函数 IMF 分量

r_n(t)——趋势项,代表信号的总体变化趋势

1.2 长短时记忆神经网络(LSTM)

循环神经网络(Recurrent neural networks, RNN)是一种具有反馈结构的神经网络,其输入不 仅和当前输入、网络的权值有关,而且也和输入时刻 之前的网络输入有关^[26]。RNN 能够将上一时刻的 隐藏层状态信息应用于当前输出的计算中,因此,该 方法适合处理时间序列数据。但是,RNN 存在梯度 消失的问题,随着时间序列跨度增大,RNN 丧失学 习能力,导致模型无法训练。为了解决这一问题, HOCHREITER 等^[27]在 1997 年提出了长短时记忆 神经网络(LSTM)。LSTM 神经网络在循环神经网 络基础上,将隐藏层的神经元换成了细胞状态和 3 个门结构,实现了控制信息在细胞状态上的更 新^[28]。LSTM 的内部单元结构如图 1 所示。



 $W_{xi}, W_{hi}, W_{ci}, W_{xf}, W_{hf}, W_{cf}, W_{xe}, W_{hc}, W_{xo}, W_{ho}$ 和 W_{co}为权重系数; b_i, b_f, b_c和 b_o为偏置向量。

输入门筛选新信息,决定输入信息;遗忘门根据 激活函数确定历史信息的丢弃;输出门决定最终的 输出和信息的保留^[29]。因此,LSTM 可以依据细胞 单元状态和3个门结构选择性地保留有效信息,在 预测中有很好的拟合能力,能更准确地进行预测分 析。

1.3 基于 EMD - LSTM 的氨气浓度预测模型

猪舍氨气浓度数据序列是受多种环境因素影响 的非平稳信号,本文将经验模态分解和长短时记忆 神经网络(EMD - LSTM)结合,构建了基于 EMD -LSTM 的猪舍氨气浓度预测模型,对氨气浓度进行 预测。基于 EMD - LSTM 的猪舍氨气浓度预测模型 流程图如图 2 所示。具体步骤为:

(1)数据采集与处理:利用基于物联网的猪舍 环境参数监测系统采集猪舍内部温度、相对湿度、二 氧化碳浓度、氨气浓度数据,利用小型气象站实时采 集获取猪舍外部风速、温度、相对湿度数据,并对采 集到的数据进行预处理分析。

(2) 氨气浓度数据序列分解:利用经验模态分解



Fig. 2 Flow chart of ammonia concentration prediction for piggery based on EMD – LSTM

对氨气浓度序列进行分解,通过 EMD 方法将非平稳、 非线性的氨气浓度序列分解成不同尺度的数据分量, 这些分量较为平稳,具有不同的局部特征信息。

(3)预测模型构建:采用 LSTM 算法对分解后的 各 IMF 分量和残余量 RES 分别进行建模,将猪舍内 部环境参数温度、相对湿度、二氧化碳浓度、风速和 猪舍外部环境参数温度、相对湿度作为输入变量,输 出值为未来1h的猪舍氨气浓度数据。首先,初始 化 LSTM 预测模型的参数,利用 Adam 算法不断优 化调整预测模型参数,使得 LSTM 能更准确地反映 EMD 分量的变化规律,以提高猪舍氨气浓度预测的 准确度。

(4) 氨气浓度预测:利用步骤(3) 的模型参数进行预测,把各 IMF 分量和余量 RES 的预测结果相加 求和,作为基于 EMD - LSTM 的猪舍氨气浓度的最 终预测结果。

2 实验

2.1 实验数据采集

以江苏省宜兴市实验基地某养猪场育肥猪舍的 氨气浓度为研究对象,利用基于物联网的猪舍环境 参数监测系统,每 3 min 采集一次数据,将采集的 2018年1月1日—2月11日的20160条猪舍环境 参数数据作为本文的实验数据,包括温度、相对湿 度、氨气浓度、二氧化碳浓度、硫化氢浓度和风速关 键环境数据,来实现对未来1h的猪舍氨气浓度预 测。育肥猪舍具体信息如表1,实验采集数据的育 肥猪舍如图3所示,基于物联网的猪舍环境参数检 测系统拓扑结构图如图4所示。 表1 实验猪舍详细信息

Tab. 1Details of experimental piggery									
猪舍尺寸/(m×m)	屋顶类型	地板类型	通风方式	清粪方式	清粪次数/(次·天 ⁻¹)	猪舍类型	过道类型		
32 × 5. 5	砖瓦双坡	全水泥地面	自然通风	水冲粪	1	开窗式	双列中走道		
饲喂方式	饮水方式	育肥方式	饲料种类	猪群组合	存栏数/头	猪栏数/个	平均质量/kg		
定时定量	咬式饮水	一贯肥育法	干料	群养	120	20	60		



图 3 实验猪舍 Fig. 3 Experimental piggery



图 4 猪舍环境参数监测系统拓扑结构

Fig. 4 Topological structure of environmental

parameters monitoring system in piggery

1. 猪舍环境参数远程监测 2. 猪舍环境参数现场监测 3. 交换 机 4. 天线 5. 猪舍环境调控箱 6. 育肥猪舍 7. 采集设备 8. 调控设备 a. 摄像头 b. 温度传感器 c. 湿度传感器 d. 氨 气传感器 e. 二氧化碳传感器 f. 负压风机 g. 湿帘 h. 污水 处理设备 i. 红外灯

2.2 实验数据预处理

猪舍环境参数数据的预处理分为3个步骤:

(1)异常数据处理

采用拉依达法则对传感器采集的数据进行处 理,即如果猪舍环境参数采集值与其平均值之差的 绝对值大于其标准差的3倍,将被认定为异常数据, 异常点处数据将被替换为异常点两侧数据的平均 值。

$$\begin{cases} |X_{n} - \overline{X}| > 3\sigma_{X_{n}} \\ X_{n}' = \frac{X_{n-1} + X_{n+1}}{2} \end{cases}$$
(6)

式中 X_n——猪舍环境参数采集值

X'-----异常数据处理后的参数值

____猪舍环境参数数据序列的均值

σ_x——猪舍环境参数数据序列的标准差

n----数据量

(2)小时平均处理

由于1h内猪舍环境参数的数值变化不大,因 此将猪舍环境参数数据按小时平均进行平滑,由于 采集频率为每3min采集一次数据,因此将猪舍环 境参数数据按小时平均即每20个采样点进行一次 平均。表2为经过小时平均处理的猪舍环境参数数 据。计算式为

$$X_{h} = \frac{X_{1} + X_{2} + \dots + X_{20}}{20} \tag{7}$$

(3) 归一化处理

由于猪舍内各环境参数的量纲不同,为提高预 测的准确性,本文对环境参数数据进行归一化处理。 计算式为

$$X^* = \frac{X_n - X_{\min}}{X_{\max} - X_{\min}}$$
(8)

式中 X_{max}——最大值 X_{min}——最小值 X^{*}——归—化值

2.3 实验结果评价标准

为了比较不同预测方法的预测结果,采用平均 绝对误差(MAE)、平均绝对百分比误差(MAPE)和 均方根误差(RMSE)3个指标来衡量各模型的预测 结果^[30]。误差越小,预测方法的精度越高,则说明 预测效果越好。

2.4 对比模型

本文除了与 RNN、LSTM 模型进行实验对比外, 还选择了 Elman 和 EMD - RNN 与 EMD - LSTM 模 型进行实验对比。

(1) Elman

Elman 神经网络对历史状态的数据具有敏感性,内部反馈网络的增加提高了网络本身处理动态 信息的能力^[31]。但当网络隐含层增加时,Elman 网 络学习效率降低,逼近精度不是很理想。

(2) EMD - RNN

采用 EMD 算法对数据进行分解,有利于降低原始数据的波动性对预测的影响,从而提高预测精度。本文将 EMD 和 RNN 结合,通过实验对比来验证 EMD – LSTM 模型的预测性能。

357

	表 2 2018 年 1 月 1 日—2 月 11 日部分环境参数数据
Гab. 2	Data of some environmental parameters from January 1st to February 11, 2018

时间点	温度/℃	相对	氨气浓度/	二氧化碳	风速/	猪舍外	猪舍外
		湿度/%	$(mg \cdot m^{-3})$	浓度	$(m \cdot s^{-1})$	温度/℃	相对湿度/%
2018 - 01 - 01 00:00	18.94	79.30	16. 61	1. 195 4 \times 10 ⁻³	1.0	9.1	75.4
2018 - 01 - 01 01 :00	18.91	79.75	16. 54	1. 486 4 \times 10 ⁻³	2.8	9.5	73.4
2018 - 01 - 01 02:00	18.93	79.75	16.88	1. 313 3 × 10 $^{-3}$	1.5	9.2	73.5
2018 - 01 - 01 03 :00	19.00	80.25	17.18	1. 522 4 $\times 10^{-3}$	2.1	9.1	72.4
2018 - 01 - 01 04:00	18.84	73.55	16.77	1. 280 5 × 10 $^{-3}$	1.5	9.0	72.5
2018 - 01 - 01 05 :00	18.96	79.70	16.62	1. 334 4 \times 10 ⁻³	1.2	8.8	72.3
÷	÷	÷	÷	÷	:	:	÷
2018 - 02 - 11 18:00	15.85	86.65	11.07	1. 558 4 $\times 10^{-3}$	3.5	6.8	86.4
2018 - 02 - 11 19:00	15.76	85.50	11.06	1. 617 6 \times 10 ⁻³	3.5	6.6	86.3
2018 - 02 - 11 20:00	15.81	85.70	11.05	1.627 2 × 10 $^{-3}$	2.1	6.6	87.7
2018 - 02 - 11 21 :00	15.62	84.65	11.08	1.664 $\times 10^{-3}$	3.3	6.0	86.1
2018 - 02 - 11 22:00	15.51	83.70	11.09	1.716 8 $\times 10^{-3}$	1.9	5.9	86.4
2018 - 02 - 11 23:00	15.48	82.70	11.11	1.818 4 \times 10 $^{-3}$	1.9	5.7	86.3

3 实验结果与分析

3.1 基于 EMD 的氨气浓度序列分解结果

针对猪舍氨气浓度数据序列具有明显的非线性 和非平稳性的特点,本文采用 EMD 算法对 2018 年 1月1日—2月11日42d采集到的猪舍氨气浓度数 据进行分解,将猪舍氨气浓度数据序列作为输入,输 出为氨气浓度数据的各分量,分解的结果如图 5。 采用 EMD 算法将氨气浓度数据序列分解为 8 个 IMF 和1个残余量 RES。氨气浓度数据 IMF 分量的 波动性依次降低,代表了猪舍内环境因素及猪舍周 围环境因素对氨气浓度周期性变化和波动特征的影 响,残余量 RES 是低频分量,表示了原始的猪舍氨 气浓度数据序列在 42 d 内随时间变化的整体变化 趋势。其中,IMF₁~IMF₄突变性强,频率较高,存在 一定的随机无序性,反映的是猪舍内外部随机不确 定因素对猪舍氨气浓度变化特征的影响;分量 IMF,~ IMF。的数据波动周期性相对比较明显,规律性比 IMF₁~IMF₄强一些,整体变化平稳,但是波动周期 并不稳定。

本文采用 EMD 算法将猪舍氨气浓度数据序 列分解成不同频率的 IMF 分量,各 IMF 分量及残 余量 RES 突出反映了猪舍氨气浓度数据序列的局 部特征信息和隐含变化信息。利用 EMD 算法分 解有利于降低猪舍氨气浓度数据的非平稳性、波 动性对预测精度的影响,有利于降低氨气浓度数 据的复杂度,从而简化基于 LSTM 神经网络的氨气 浓度预测。

3.2 基于 EMD - LSTM 的氨气浓度预测

本文利用 EMD - LSTM 模型对未来 1 h 的猪舍 氨气浓度进行预测,选取 2018 年 1 月 1 日—2 月 4

MF,	0.4	(11/11/16/20061-16/	enternerentere		u	-	an af any	111hallum	-Novelland	W/www//www.	
	-0.40	100	200	300	400	500 时间/h	600	700	800	900	1000
${\rm MF}_2$	0.2	nhwn/wh	w	mallinin		www.	Mar Marina	v= \/	- M -MM	Mmmm	~~~~
Ι	-0.2	100	200	300	400	500 时间/h	600	700	800	900	1000
${\rm MF}_3$	0.5	MM	~~~^^	~~~	m		~~~	mm-	~~~~	~~~~	~
Ξ.	-0.50	100	200	300	400	500 时间/h	600	700	800	900	1000
${\rm MF}_4$	0.4	$\sim \sim $	\sim	\sim	$\sim \sim$	~~~~	\sim	~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~~	\sim	\sim	\sim
н.	-0.4 0	100	200	300	400	500 时间/h	600	700	800	900	1000
MF_5	0.5	\sim	\wedge	\sim	~~	\sim	\sim	~~	~	\sim	~
Π	-0.50	100) 200	300	400	500 时间/h	600	700	800	900	1000
MF_6	0.4	\frown	$\langle /$	\sim	\sim	\sim	_	\sim	_	_	_
Ξ.	-0.4 0	100	200	300	400	500 时间/h	600	700	800	900	1000
MF_7	0.5				\sim	\smile	_				
Π.	-0.5 ^L 0	100	200	300	400	500 时间/h	600	700	800	900	1000
MF_{s}	0.5				_	\sim					_
Ξ.	-0.5 ^L 0	100	200	300	400	500 时间/h	600	700	800	900	1000
RES.	$16 \\ 14$										
	12 ₀	100	200	300	400	500 时间/h	600	700	800	900	1000
		图 5	基于	[:] EMI) 的复	虱气浓	度序	列分	解结	果	
Fig. 5 Decomposition result of ammonia											
concentration sequence based on EMD											

日的数据作为训练样本,选取2月5—11日的数据 作为测试样本。实验流程如图2所示,利用LSTM 模型对EMD分解所得的各IMF分量和残余量RES 进行训练和预测,输入变量数为6,输出变量数为1, 利用Adam算法不断优化调整预测模型参数,将输 入层的时间步设置为6,隐含层的层数设置为20,然 后对各IMF分量和残余量RES的预测结果相加得 到猪舍氨气浓度最终预测结果。为了验证本文提出 的预测模型性能,分别采用 RNN 模型、Elman 模型、 LSTM 模型、EMD - RNN 模型对猪舍氨气浓度预测 进行实验验证,同时选择文献中已有的 BP 模型和 L-M 优化 BP 模型实验对比分析,各预测模型的结 果如图 6 所示。通过对比图 6 中实际值与各预测值 曲线,直观上看,RNN、BP 和 L - M 优化 BP 模型的 预测结果都不理想,RNN 预测结果在第 70 个时间 点之前与氨气浓度实际值较为接近,而从第 110 个 时间点后,这3个模型预测出现严重误差,均明显超 过氨气浓度的实际值;Elman 模型的预测结果在部 分时间点处出现较大差值,偏离氨气浓度实际值最 大;相比于 Elman 模型和 RNN 模型,LSTM 模型和 EMD - RNN 模型的预测精度有所提高,但是在拐点 处仍存在较大误差;基于 EMD - LSTM 模型的预测 结果较好,与氨气浓度实际值基本一致,较其他4种 模型的预测结果更为准确。



Fig. 6 Results of ammonia concentration prediction from February 5th to 11th

图 7 为 RNN、BP、L-M 优化 BP、Elman、LSTM、 EMD-RNN和EMD-LSTM 模型的预测结果误差比 较,其中实线为零基准线。由图 7 可见,基于 EMD-LSTM 模型的氨气浓度预测值误差最小,而且预测 误差绝大部分在±0.2 mg/m³之间,只有极少数预测 误差绝大范围之外。基于 EMD-RNN 模型的氨 气浓度预测值误差也较小,而且预测误差大多数也 在±0.2 mg/m³之间。但是 RNN、BP、L-M 优化 BP、Elman和LSTM 预测模型的误差相对较大,预测 误差大部分超出了±0.2 mg/m³这一区间,尤其是在 第 110 个时间点后,预测误差集中在0.2~ 0.5 mg/m³之间,预测差值较大,预测结果不理想。 将图 6 和图 7 进行对比分析,可以得出基于 EMD-LSTM 猪舍氨气预测模型具有更高的精度,更接近 猪舍氨气浓度实际数据。

为了对模型的预测结果进行定量分析评价,本 文采用 MAE、MAPE 和 RMSE 3 个评价指标对各预 测模型进行统计对比分析,表 3 为各预测模型的统 计结果。

由表3可知, EMD - LSTM 模型的预测精度最高, MAE、MAPE、RMSE 分别为 0.072 3 mg/m³、 0.6257%和 0.094 5 mg/m³, 与 Elman 模型相比,



MAE、MAPE、RMSE 分别降低了 65.7%、65.7% 和 64.6%;与 BP 模型相比, MAE、MAPE、RMSE 分别降 低了 64.3%、65.0% 和 60.2%;与 RNN 模型相比, MAE、MAPE、RMSE 分别降低了 64.5%、65.2% 和 61.5%;与 L - M 优化 BP 模型相比, MAE、MAPE、 RMSE 分别降低了 49.9%、50.7% 和 44.4%;与 LSTM 模型相比, MAE、MAPE、RMSE 分别降低了 45.3%、 45.8% 和 39.6%;与 EMD - RNN 模型相比, MAE、 MAPE、RMSE 分别降低了 4.5%、4.8% 和 8.2%。

表 3 预测误差统计结果 Tab. 3 Statistical results of prediction errors

证从北与				模型			
时 7月 7日 75	Elman	BP	RNN	L-M优化 BP	LSTM	EMD – RNN	EMD – LSTM
MAE/(mg·m ⁻³)	0. 211 0	0. 202 6	0. 203 7	0. 144 3	0. 132 2	0.0757	0.0723
MAPE/%	1.8244	1.7882	1.7993	1.2689	1.1545	0.6570	0. 625 7
$RMSE/(mg \cdot m^{-3})$	0. 267 1	0. 237 2	0. 245 5	0. 169 9	0.1564	0. 102 9	0.094 5

总体来看,基于 EMD – LSTM 的氨气浓度预测 模型比其他模型预测精度更高,预测结果优于文献 中已有的 BP 模型和 L – M 优化 BP 模型,该模型对 猪舍氨气浓度时序数据变化趋势的预测精度有明显 提高,能更准确地预测猪舍氨气浓度变化规律和变 化趋势。

4 结论

(1)利用 EMD 对猪舍氨气浓度数据进行不同

的尺度分解,使氨气浓度数据序列平稳化,提取了猪 舍氨气浓度数据序列的局部特征信息,然后利用 LSTM 预测模型对猪舍氨气浓度进行建模预测,充 分发挥了 LSTM 神经网络数据处理的优势。

(2)提出的基于 EMD - LSTM 的猪舍氨气浓度 预测模型具有较好的预测效果,能够较好地拟合猪 舍环境参数与氨气浓度之间的关系,提高了猪舍氨 气浓度的预测精度,为猪舍氨气浓度的预测提供了 一种新的思路和方法。

参考文献

- [1] 王美芝,吴中红,刘继军,等. 猪舍有害气体及颗粒物环境参数研究综述[J]. 猪业科学,2016,33(4):94-97.
 WANG Meizhi, WU Zhonghong, LIU Jijun, et al. Review on environmental parameters of harmful gases and particulates in piggery [J]. Swine Industry Science,2016,33(4):94-97. (in Chinese)
- [2] 高航,袁乾坤,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 Qiankun, JIANG Lili, et al. Review of environmental parameters in pig house[J]. Scientia Agricultura Sinica,2018,51(16): 3226-3236. (in Chinese)
- [3] 朱海生,董红敏.猪舍氨气排放预测模型的研究现状[J].农业工程学报,2006,22(2):187-192.
 ZHU Haisheng, DONG Hongmin. Reasearch progress of models for predicting ammonia emission in swine houses [J].
 Transactions of the CSAE, 2006,22(2):187-192. (in Chinese)
- [4] 代小蓉.集约化猪场 NH₃ 的排放系数研究[D].杭州:浙江大学,2010.
 DAI Xiaorong. Study on ammonia emission factors in concentrated pig farm [D]. Hangzhou: Zhejiang University, 2010. (in Chinese)
- [5] 汪开英,代小蓉,李震宇,等. 不同地面结构的育肥猪舍 NH₃ 排放系数[J]. 农业机械学报,2010,41(1): 163 166.
 WANG Kaiying, DAI Xiaorong, LI Zhenyu, et al. NH₃ emission factor of fattening pig buildings with different floor systems[J].
 Transactions of the Chinese Society for Agricultural Machinery,2010,41(1): 163 166. (in Chinese)
- [6] 孙瑞锋. 肉鸡舍氨气挥发规律及控制方法研究[D]. 泰安:山东农业大学, 2008.
 SUN Ruifeng. Rule of ammonia emission and research on reducing ammonia concentration in broiler house [D]. Taian: Shandong Agricultural University, 2008. (in Chinese)
- [7] CHEN Yongxing, XIN Hongwei, LI Hong, et al. Comparison of ammonia emissions from poultry houses based on diurnal integration vs daily means of gas concentration and building ventilation rate[C]//The Ninth International Livestock Environment Symposium(ILES IX), 2012.
- [8] CHAI Lilong, ROLAND K, HENRY H J, et al. A regional mass balance model based on total ammoniacal nitrogen for estimating ammonia emissions from beef cattle in Alberta Canada [J]. Atmospheric Environment, 2014, 92: 292 - 302.
- [9] AMLAN K P. Prediction of enteric methane emission from cattle using linear and non-linear statistical models in tropical production systems [J]. Mitigation and Adaptation Strategies for Global Change, 2017, 22(4): 629-650.
- [10] 俞守华,张洁芳,区晶莹. 基于 BP 神经网络的猪舍有害气体定量检测模型研究[J]. 安徽农业科学,2009, 37(23): 11316-11317.

YU Shouhua, ZHANG Jiefang, QU Jingying. Research on quantitative detection model of harmful gas in pig house based on BP neural network[J]. Journal of Anhui Agricultural Sciences, 2009, 37(23):11316-11317. (in Chinese)

- [11] SUN G, HOFF S J, ZELLE B C, et al. Development and comparison of backpropagation and generalized regression neural network models to predict diurnal and seasonal gas and PM₁₀ concentrations and emissions from swine buildings [J]. Transactions of the ASABE, 2008, 51(2): 685-694.
- [12] 谢秋菊,罗文博,李妍,等. 基于神经网络猪舍氨气浓度预测方法研究[J]. 东北农业大学学报, 2016, 47(10):83-92.
 XIE Qiuju, LUO Wenbo, LI Yan, et al. Study on prediction method of ammonia concentrations in pig house using neural network[J]. Journal of Northeast Agricultural University, 2016, 47(10): 83-92. (in Chinese)

- [13] XIE Qiuju, NI Jiqin, SU Zhongbin. 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.
- [14] 周茁. 生猪养殖环境监测及氨气浓度预警模型研究[D]. 长沙:湖南农业大学,2014.
 ZHOU Zhuo. Research of pig breeding environment monitoring and early warning model of ammonia concentration [D].
 Changsha: Hunan Agricultural University, 2014. (in Chinese)
- [15] ROBERTO B, TAMARA A, ANTONIO O, et al. Prediction of carbon dioxide concentration in weaned piglet buildings by wavelet neural network models [J]. Computers and Electronics in Agriculture, 2017,143:201 - 207.
- [16] BAI Yun, LI Yong, WANG Xiaoxue, et al. Air pollutants concentrations forecasting using back propagation neural network based on wavelet decomposition with meteorological conditions [J]. Atmospheric Pollution Research, 2016,7(3):557-566.
- [17] 龚雪飞,刘萍,简家文.基于 PSO 算法集成神经网络的多元有害气体检测系统[J].传感技术学报,2015,26(6):938-942.

GONG Xuefei, LIU Ping, JIAN Jiawen. Based on the integrated neutral network optimized by PSO multiple harmful gas detection system [J]. Chinese Journal of Sensors and Actuators, 2015, 26(6): 938 – 942. (in Chinese)

- [18] STAMENKOVIC L J, DAVOR Z A, MIRJANA D R, et al. Modeling of methane emissions using artificial neural network approach[J]. Journal of the Serbian Chemical Society, 2015,80(3):421-433.
- [19] HUANG N E, ZHENG Shen, STEVEN R L, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis [J]. Proceeding, Mathematical, Physical and Engineering Sciences, 1998, 454 (1971):903-995.
- [20] 徐龙琴,张军,李乾川,等. 基于 EMD 和 ELM 的工厂化育苗水温组合预测模型[J]. 农业机械学报, 2016, 47(4):265-271. XU Longqin, ZHANG Jun, LI Qianchuan, et al. Combined prediction model of water temperature in industrialized cultivation based on empirical mode decomposition and extreme learning machine[J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(4):265-271. (in Chinese)
- [21] 宦娟,曹伟建,秦益霖,等. 基于经验模态分解和最小二乘支持向量机的溶氧预测[J]. 渔业现代化, 2017,44(4): 37-43.
 HUAN Juan, CAO Weijian, QIN Yilin, et al. Prediction of dissolved oxygen based on empirical mode decomposition and least squares support vector machine[J]. Fishery Modernization, 2017,44(4): 37-43. (in Chinese)
- [22] NORBERT A A, ABDOLLAH H. EMD-based predictive deep belief network for time series prediction: an application to drought forecasting[J]. Hydrology, 2018, 5(1): 18-38.
- [23] 王金峰,闫东伟,鞠金艳,等. 基于经验模态分解与 BP 神经网络的农机总动力增长预测[J]. 农业工程学报, 2017, 33(10):116-122.
 WANG Jinfeng, YAN Dongwei, JU Jinyan, et al. Prediction of total power growth of agricultural machinery based on empirical mode decomposition and BP neural network[J]. Transactions of the CSAE, 2017, 33(10):116-122. (in Chinese)
- [24] 张峰,薛惠锋,WANG Wei,等.水资源监测异常数据模态分解-支持向量机重构方法[J].农业机械学报,2017,48(11): 316-323.

ZHANG Feng, XUE Huifeng, WANG Wei, et al. Methods of abnormal data detection and recovery for water resources monitoring based on EEMD and PSO – LSSVM [J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(11):316-323. (in Chinese)

- [25] 施珮,袁永明,匡亮,等. 基于 EMD IGA SELM 的池塘养殖水温预测方法[J]. 农业机械学报, 2018,49(11): 312 319. SHI Pei, YUAN Yongming, KUANG Liang, et al. Water temperature prediction in pond aquaculture based on EMD - IGA -SELM neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(11): 312 - 319. (in Chinese)
- [26] JATIN Bedi, TOSHNIWAL D. Empirical mode decomposition based deep learning for electricity demand forecasting[J]. IEEE Access, 2018, 6:49144 - 49156.
- [27] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8):1735-1780.
- [28] 陈英义,程倩倩,方晓敏,等. 主成分分析和长短时记忆神经网络预测水产养殖水体溶解氧 [J]. 农业工程学报, 2018, 34(17): 183-191.

CHEN Yingyi, CHENG Qianqian, FANG Xiaomin, et al. Principal component analysis and long short-term memory neural network for predicting dissolved oxygen in water for aquaculture [J]. Transactions of the CSAE, 2018, 34(17): 183 – 191. (in Chinese)

- [29] 余永维,杜柳青,易小波,等. 基于时序深度学习的数控机床运动精度预测方法[J]. 农业机械学报, 2019, 50(1): 421-426.
 YU Yongwei, DU Liuqing, YI Xiaobo, et al. Prediction method of NC machine tool's motion precision based on sequential deep learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(1): 421-426. (in Chinese)
- [30] 吴静,李振波,朱玲. 融合 ARIMA 模型和 GAWNN 的溶解氧含量预测方法[J]. 农业机械学报, 2017, 48(增刊): 205-210.
 WU Jing,LI Zhenbo,ZHU Ling. Hybrid model of ARIMA model and GAWNN for dissolved oxygen content prediction[J].
 Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(Supp.): 205-210. (in Chinese)
- [31] LI Hongjuan, WANG Jianjun, WANG Hua, et al. An optimal method for prediction and adjustment on gasholder level and self-provided power plant gas supply in steel works[J]. Journal of Central South University, 2014, 21(7): 2779 2792.