doi:10.6041/j.issn.1000-1298.2020.10.040

基于深度学习的密闭式猪舍内温湿度预测模型

谢秋菊[1,2]　郑　萍[1]　包　军[3]　苏中滨[1]

(1.东北农业大学电气与信息学院,哈尔滨 150030;
2.东北农业大学农业农村部生猪养殖设施工程重点实验室,哈尔滨 150030;
3.东北农业大学动物科学技术学院,哈尔滨 150030)

摘要:针对目前猪舍环境控制中传感器只能实现对当前环境状况的监测,无法对猪舍内环境变化趋势作出预判,不能提前对环境控制设备运行状态进行调节,在一定程度上造成环境控制效果滞后的问题,基于深度学习方法,结合实际传感器监测的历史数据和猪舍外影响数据,建立了长短时记忆(Long short-term memory,LSTM)网络预测模型,实现了精确的猪舍内温湿度变化预测。结果表明,猪舍内冬季和夏季温湿度预测值与实测值变化趋势一致,温度最大误差 1.9℃,平均误差为 0.5℃;相对湿度最大误差为 13.5%,平均误差为 2.3%;温度和相对湿度预测的平均决定系数分别为 0.821 和 0.645。本文建立的预测模型具有较优性能,可为制定优化的猪舍内环境控制策略,解决环境控制效果滞后问题提供可行的参考。

关键词:密闭式猪舍;热湿环境;深度学习;长短时记忆网络;环境控制优化

中图分类号:TU264$^+$.3　　**文献标识码**:A　　**文章编号**:1000-1298(2020)10-0353-09　　**OSID**:

Thermal Environment Prediction and Validation Based on Deep Learning Algorithm in Closed Pig House

XIE Qiuju[1,2]　ZHENG Ping[1]　BAO Jun[3]　SU Zhongbin[1]

(1. *College of Electrical and Information*, *Northeast Agricultural University*, *Harbin* 150030, *China*
2. *Key Laboratory of Swine Facilities Engineering*, *Ministry of Agricullture and Rural Affairs*, *Northeast Agricultural University*, *Harbin* 150030, *China*
3. *College of Animal Science and Technology*, *Northeast Agricultural University*, *Harbin* 150030, *China*)

Abstract: With the development of scaled pig farm, the environmental-controlled breeding production with closed house has got a rapid progress in recent years. However, in order to maximize the commercial interests, there are always limited living space designed for pigs in the closed pig house. Indoor environmental quality, especially the thermal environment quality, is particularly important in the limited living space of the closed pig house, which has significant effect on pig's health, welfare and reproductivity. The indoor environment mainly includes thermal environment, harmful gas, dust, bacteria, light, etc. The thermal environment mainly refers to the indoor air temperature and humidity. The indoor air temperature is one of the most important environmental factors that directly affects the heat balance of pigs. Because pigs maintain a constant body temperature and carry out normal life activities through the balance of heat production and dissipation. So, indoor air temperature takes a critical role on keeping a constant pig body temperature and affect the health level and reproductive capacity of pigs. The humidity affects the evaporation and the body heat regulation of pigs. The high temperature and high humidity environment will seriously affect the pigs' daily weight gain, at the same time, it will cause bacteria growth and disease. So, the indoor air temperature and humidity were payed much attention by many researchers in the past decades in order to maintain a suitable indoor environment for pigs. An optimized control strategy, an accuracy and timeliness environmental control was the first important task

收稿日期:2020-02-06　修回日期:2020-03-31

基金项目:国家自然科学基金面上项目(32072787)、东北农业大学农业农村部生猪养殖设施工程重点实验室开放课题、国家生猪产业技术体系项目(CARS-35)、东北农业大学东农学者计划项目(19YJXG02)和国家重点研发计划项目(2016YFD0800602)

作者简介:谢秋菊(1976—),女,教授,博士,主要从事畜舍环境控制研究,E-mail:xqj197610@163.com

通信作者:苏中滨(1965—),男,教授,博士生导师,主要从事农业信息技术研究,E-mail:suzb001@163.com

for pig house environmental control system. At present, the operation of environmental control devices in pig house mainly relies on data that collected by sensors. However, due to the data collected by sensors can only reflect the current indoor environmental conditions, it can not predict the trend of environmental variation in pig house, thus can not adjust the operation status of environmental control device in advance, to some extent, which leads to some time lag of environmental control system. Predictions of indoor environment is an effective way to provide a precision and optimal control strategy with forecasting for the indoor temperature and humidity variations to avoid some control lags. Combined with the actual historical temperature and humidity data and external influence data that collected by sensors, and based on the deep learning method, the long short-term memory (LSTM) prediction model was developed to achieve an accurate prediction and verification of temperature and humidity variation in pig house. The results showed that the predictions of temperature and humidity were consistent well with the observations whatever in winter or in summer. The maximum error of temperature was 1.9℃, and the mean error was 0.5℃; the maximum error of relative humidity was 13.5%, and the mean error was 2.3%; the mean determination coefficients R^2 of temperature and humidity were 0.821 and 0.645, respectively. The established prediction model achieved a higher performance, which can provide a feasible reference for an optimal environmental control strategy and the reduction of time lag for environmental control in pig house.

Key words: closed pig house; thermal environment; deep learning; long short-term memory; optimized environment control

0 引言

随着商业利益和消费需求的不断增长,环境可控式的密闭猪舍养殖方式发展迅速。在密闭式猪舍的有限空间中环境品质尤为重要,它是除遗传基因之外制约养猪生产发展的关键因素[1]。在众多因素中,温度是维持猪体温恒定、影响猪的健康水平和繁殖能力的重要外部环境因素之一,直接影响猪体的热平衡[2]。猪体通过产热和散热平衡来维持恒定的体温,进行正常的生命活动[3]。猪舍空气湿度影响猪的体热调节,高温高湿环境严重影响猪的日增质量,同时造成细菌滋生,诱发疾病[4]。因此,营造适宜的舍内热湿环境可以有效地提高猪群的健康水平、繁殖能力,降低饲料消耗,提高生长效率。研究低延迟、精准化的猪舍环境调控方法是实现猪舍内环境精准控制的关键。

猪舍内热湿环境受猪舍建筑样式、舍内饲养猪的数量和质量、通风模式[5]、猪的活动量、生产方式、舍外天气情况等多种因素相互耦合的影响。国内外许多学者针对畜禽舍内温湿度控制进行了大量研究[6-17]。

这些研究大多基于传感器网络技术实时监测猪舍中的环境状况,并做出判断,实现舍内环境调控。传感器只能对当前舍内环境状况进行监测,无法提前对舍内的环境因子变化趋势作出预判,因而只依靠传感器监测数据来决定控制系统的运行状态。然而,由于猪舍内的热湿环境随着舍内的气流而逐渐变化,因此导致环境调控设备运行后对环境调控达到预期效果会存在一定的滞后性,这种滞后性因受猪舍空间结构、建筑样式、舍内通风、加热等控制设备运行效率的影响而不同。试验测试表明,在开启通风或加热等设备 20 min 后舍内热湿环境可以得到明显改善。因此,需要对猪舍内环境因子变化提前作出预测,从而提前决定环境控制设备的运行状态,实现舍内环境优化控制、降低控制效果的滞后。目前,随着传感器及大数据技术的发展,猪舍环境监测的数据量不断增加,传统的数据驱动预测方法,如线性[18]和非线性的方法[19-20]、CFD 方法[8-9]、神经网络方法[21-23]等,已经无法实现大数据量的输入时序序列数据的精确预测。

猪舍内温湿度监测数据是由猪舍环境监测传感器在一定时间间隔内获取的大量时序数据。长短时记忆(Long short-term memory, LSTM)网络是由 GERS 等[24]提出的深度学习的典型代表方法之一。LSTM 通过对时序数据历史特征的提取实现数据未来变化的预测,它适合于多个领域时序数据处理及预测应用[25-28]。然而,根据传感器监测获取的大量猪舍内温湿度时序数据,应用 LSTM 预测模型的研究尚未见报道。

本文基于深度学习方法,结合传感器监测的大量时序序列历史数据,综合考虑各环境因素对猪舍内温湿度变化的影响,建立具有多层结构的长短时记忆 LSTM 网络的温湿度变化预测模型,以实现当前时间猪舍内温湿度的变化预测。

1 影响因素相关性分析

密闭猪舍是一个由砖、保温板等为围护结构的封闭空间。猪舍内环境温湿度变化受猪舍建筑样

式、围护结构，舍内饲养猪的数量和质量，舍内加热及通风系统，舍外天气状况等的影响。建立猪舍内温湿度变化预测需要对影响因素进行分析，确定影响因素，为建立优化的预测模型奠定基础。本文在实际监测的数据基础上，考虑除建筑样式和围护结构相关的影响因素，利用皮尔逊（Pearson）相关分析方法（$P<0.05$），确定猪舍内温湿度变化的相关影响因素，如表 1 所示。

表 1　影响因素相关性系数

Tab. 1　Correlations coefficients between factors

因素	猪舍内温度	猪舍内相对湿度
猪舍内温度	1	0.284
猪舍内相对湿度	0.284	1
猪舍外相对湿度	−0.315	−0.178
猪舍外温度	0.489	0.238
猪活动量	0.395	0.378
猪总质量	−0.436	−0.253
通风率	0.147	0.144
粪坑温度	0.518	0.293

从表 1 可以看出，猪舍内温度（Pig living space temperature，PLS T）与猪舍外温度（Outdoor temperature，Out T）、粪坑温度（Pit temperature，Pit T）和猪的活动量（Activity，Act）呈现较大的正相关性，相关系数分别为 0.489、0.518 和 0.395；同时，猪舍内温度与猪舍外相对湿度（Pig living space relative humidity，PLS RH）和猪的总质量（Weight，Wt）呈现负相关性，相关系数分别为 −0.315 和 −0.436。因此表明，猪舍内温度受猪舍外温度、舍内猪的总质量、粪坑温度、舍外相对湿度影响较大；此外，猪舍内温度与猪舍内相对湿度和通风量（Ventilation，Vent）也具有一定的相关性，相关系数分别为 0.284 和 0.147。

猪舍内相对湿度与猪的活动量呈现正相关性，相关系数为 0.378，表明当猪由于进食或排泄等的活动量增大时可导致舍内相对湿度增大；同时，猪舍内相对湿度与猪舍内温度和粪坑温度呈现正相关性，相关系数分别为 0.284 和 0.293；与猪的总质量和猪舍外相对湿度（Outdoor relative humidity，Out RH）呈现负相关性，相关系数分别为 −0.253 和 −0.178。

因此，本文选取猪舍内相对湿度、猪舍外相对湿度、猪舍外温度、猪的活动量、猪的总质量、通风率、粪坑温度作为猪舍内温度预测的外部影响因素；选取猪舍内温度、猪舍外温度、猪舍外相对湿度、猪的活动量、猪的总质量、通风率、粪坑温度作为猪舍内相对湿度预测的外部影响因素。

2　基于 LSTM 的猪舍内温湿度预测模型

2.1　模型结构

预测模型由时序数据输入层、隐含层和输出层组成。模型结构如图 1 所示。

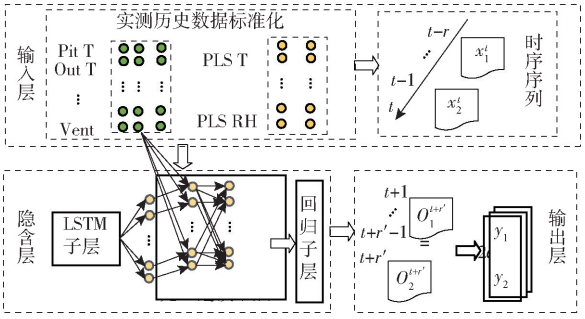

图 1　LSTM 预测模型结构图

Fig. 1　Structure diagram of LSTM prediction model

输入层负责接收采集到的猪舍内温度、相对湿度历史数据，舍外温度、相对湿度，粪坑温度，通风率，猪的活动量及总质量数据，并且将其进行标准化处理。标准化处理公式为

$$z_i' = \frac{z_i - \bar{z}}{\sqrt{\frac{1}{n}\sum_{i=1}^{n}(z_i - \bar{z})^2}} \tag{1}$$

式中　z_i'——标准化后的数据

z_i——输入的时序数据

$\bar{z}$——输入时序数据的平均值

n——时序序列数据的长度

标准化后的猪舍内温度和相对湿度历史数据转换成时序序列 x_1 和 x_2。猪舍内温度和相对湿度的外部影响因素被标准化处理后参与完全连接层的运算。输入层节点数量为 $2t$，t 为猪舍内温度和相对湿度历史时序序列长度。

隐含层包含 LSTM、完全连接和回归 3 个子层。LSTM 子层负责学习时间序列数据每步之间的长期依赖关系，以执行有助于改善长序列梯度流的交互。LSTM 子层由元胞状态 $\boldsymbol{c}$、隐含状态 $\boldsymbol{h}$、输入门 $\boldsymbol{i}$、遗忘门 $\boldsymbol{f}$、候选门 $\boldsymbol{g}$ 和输出门 $\boldsymbol{o}$ 组成，如图 2 所示[29-30]。

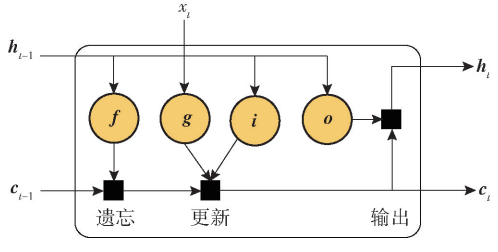

图 2　LSTM 子层组成结构图

Fig. 2　Consist structure diagram of LSTM sublayer

元胞状态 $\boldsymbol{c}$ 包含从前一步学习来的信息，并且

在每一步的学习中,LSTM 子层将从元胞状态 $\boldsymbol{c}$ 中加入或删除信息。每一步的隐含状态 $\boldsymbol{h}$ 都包含上步 LSTM 层的输出信息。为了使信息能够更好地更新,LSTM 层增加了输入门 $\boldsymbol{i}$、遗忘门 $\boldsymbol{f}$、元胞候选门 $\boldsymbol{g}$ 和输出门 $\boldsymbol{o}$。输入门 $\boldsymbol{i}$ 决定元胞的更新程度,遗忘门 $\boldsymbol{f}$ 决定元胞状态的重置水平,候选门 $\boldsymbol{g}$ 负责向元胞中加入一些新的信息,输出门 $\boldsymbol{o}$ 决定将有多少元胞信息加入隐含状态。

每一步元胞状态和隐含状态计算式为

$$\boldsymbol{c}_t = \boldsymbol{f}_t \circ \boldsymbol{c}_{t-1} + \boldsymbol{i}_t \circ \boldsymbol{g}_t \tag{2}$$

$$\boldsymbol{h}_t = \boldsymbol{o}_t \circ \sigma(\boldsymbol{c}_t) \tag{3}$$

式中 $\circ$——向量元素相乘符号

$\boldsymbol{i}_t$、$\boldsymbol{f}_t$、$\boldsymbol{g}_t$、$\boldsymbol{o}_t$——输入门、遗忘门、候选门、输出门

σ——状态激活函数

在每一个时间步 t 中,输入门 i_t、遗忘门 f_t、输出门 o_t 和候选门 g_t 可描述为

$$i_t = \sigma_g(w_i x_t + R_i h_{t-1} + b_i) \tag{4}$$

$$f_t = \sigma_g(w_f x_t + R_f h_{t-1} + b_f) \tag{5}$$

$$g_t = \sigma_c(w_g x_t + R_g h_{t-1} + b_g) \tag{6}$$

$$o_t = \sigma_g(w_o x_t + R_o h_{t-1} + b_o) \tag{7}$$

式中 σ_c——状态激活函数,采用双曲正切函数 tanh 来计算状态激活函数

σ_g——门状态函数

激活函数由公式 $\sigma(x) = (1 + e^{-x})^{-1}$ 计算得到;LSTM 层中的权重是由具有可学习性的输入矩阵 $\boldsymbol{W}$、回归权重矩阵 $\boldsymbol{R}$ 以及每个分量偏差矩阵 $\boldsymbol{b}$ 组成。这些矩阵表示为

$$\boldsymbol{W} = \begin{bmatrix} w_i \\ w_f \\ w_g \\ w_o \end{bmatrix} \quad \boldsymbol{R} = \begin{bmatrix} R_i \\ R_f \\ R_g \\ R_o \end{bmatrix} \quad \boldsymbol{b} = \begin{bmatrix} b_i \\ b_f \\ b_g \\ b_o \end{bmatrix}$$

完全连接子层中的所有节点都与 LSTM 子层中的节点以及外部影响数据相连接,以获得上一层和外部影响因素对输入变量 x_1 和 x_2 学习所得的所有特征。完全连接层的每一步都是独立执行的,输入变量与权重矩阵 $\boldsymbol{W}$ 相乘后,再加上偏置矩阵向量 $\boldsymbol{b}$。此层输出变量数目等于输入变量的数目 2,即温度和相对湿度 2 个输入变量。

回归子层与完全连接子层相连,用于计算序列到序列网络的均方根误差损失(Half-mean-squared-error loss)。每步的未归一化的损失预测响应计算式为

$$L = \frac{1}{2S} \sum_{k=1}^{S} \sum_{j=1}^{2} (t_{kj} - y_{kj})^2 \tag{8}$$

式中 L——计算序列到序列网络的均方根误差损失

S——序列的长度

t_{kj}、y_{kj}——第 k 步的序列值、网络预测值

当网络训练时,观察值的平均损失由小批量网络训练时计算而得。

输出层将隐含层输出量 O_1 和 O_2 反归一化处理成预测值猪舍内温度 y_1 和猪舍内相对湿度 y_2,反标准化公式采用式(1)对观察值进行标准化处理时的变换所得。

2.2 模型评价

本文通过统计分析方法中的决定系数 R^2、均方根误差 e_{RMSE} 和平均绝对误差百分比 e_{MAPE} 来评价 LSTM 预测模型的性能。

2.3 模型参数设置

在 LSTM 子层中,初始网络参数设置为:隐含层神经元数为 200,状态激活函数为双曲正切函数 tanh,门激活函数为 sigmod,采用自适应矩估计 Adam 优化器进行训练,最大步数设置为 250,初始学习速率为 0.005,时间间隔(Time lag)为 1。

为了获得最优的 LSTM 预测模型,需要对预测模型中的 LSTM 子层和完全连接层中的神经元数、网络的学习速率 2 个主要参数进行对比及组合优化。设 LSTM 子层和完全连接层中的神经元个数取值集合为{200,400,800,1 200,1 600,2 000},网络的学习速率取值集合为{0.001, 0.003, 0.005, 0.008, 0.010}。

2.4 模型数据集选取

时序序列数据集分为训练数据集和验证数据集。训练数据集训练 LSTM 模型自学习及调整连接参数等,验证数据集对模型相关性能参数进行验证。本文中所用数据集包含从 2015 年 8 月 28 日至 9 月 30 日(代表夏季数据集)和 2015 年 12 月 24 日至 2016 年 1 月 13 日(代表冬季数据集)共计 1 320 组监测数据。将这些数据分成 4 个数据集,在夏季数据集中前 94% 的监测数据(从 2015 年 8 月 28 日至 9 月 28 日)用作模型训练,剩余 6% 的监测数据(从 2015 年 9 月 29 日至 30 日)用于模型验证;在冬季数据集中前 90.4% 的监测数据(从 2015 年 12 月 24 日至 2016 年 1 月 11 日)用于模型训练,剩余 9.6% 的监测数据(从 2016 年 1 月 12 日至 13 日)用于模型验证。

本文使用 Matlab 对 LSTM 模型进行训练及验证。在 LSTM 模型中共用到 8 个变量,分别作为输入变量和外部影响变量进行模型特征提取,实现下一时刻猪舍内温度和相对湿度的预测。其中,猪舍内温度、相对湿度历史数据作为模型的输入变量;猪舍内相对湿度、猪舍外温度、猪舍外相对湿度、猪舍

粪坑温度、舍内通风率、猪的活动量、猪的总质量作为猪舍内温度预测的外部影响变量；猪舍内温度、猪舍外相对温度、猪舍外湿度、猪舍粪坑温度、舍内通风率、猪的活动量、猪的总质量作为猪舍内相对湿度预测的外部影响变量。

3　预测结果实例验证

3.1　数据来源及数据监测

本文 LSTM 预测模型中用到的训练及验证数据来源于普渡大学动物研究教育中心猪舍[31]开展的研究项目(the USDA National Institute of Food and Agriculture Hatch project)。该猪舍位于美国印第安那州西拉法叶市，地处大陆性湿润气候，冬季寒冷，1 月气温最低，平均温度为 -7.2℃，相对湿度为 69%；夏季炎热，7 月温度最高，平均温度为 29.4℃，平均相对湿度为 71%。

该猪舍为密闭式机械通风、钢木混结构。猪舍共有 12 个南北朝向的小间，舍外新鲜空气通过猪舍东西两侧进风口送入舍内，然后通过棚顶和过道入口送入各个小间。单个小间尺寸为 11 m × 6.1 m × 2.7 m(长 × 宽 × 高)，内部建有双列钢质围栏，中间为过道，每列有 6 个猪栏，可以容纳 60 头育肥猪。小间内是水泥漏缝地板，地板下方有 1.8 m 深的储粪池。猪舍外部实景及结构如图 3 所示[32]。



(a) 猪舍实景图

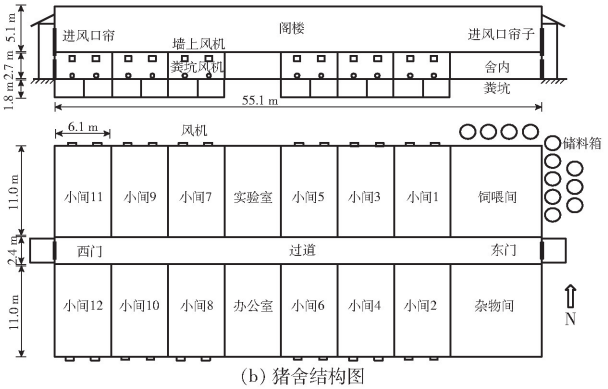

(b) 猪舍结构图

图 3　猪舍外部实景和结构图

Fig. 3　Photo and structure diagram of pig building

每个小间分别安装有天然气加热器(Guardian 60 型，L. B. White Co.，美国)和 2 个直径分别为 356 mm(V4E35 型，Multifan，美国)和 508 mm(V4E50 型，Multifan，美国)的墙上恒速风机，用于舍内加热和通风。舍内温度和粪坑温度数据分别通过安装在距离猪舍地面 1.5 m 和储粪池的排风口处的 T 型热电耦监测得到。猪舍内相对湿度通过安装在猪栏中间距离地面 1.5 m 处的相对湿度传感器(HX92BC 型，Omega，美国)测量得到。小间内墙上风机所受压力通过气压测量仪(260 型，Setra Systems，Inc.，美国)测得。

猪舍的通风率包括舍内墙上风机的通风率和粪坑风机通风率。在猪舍下方的储粪池外墙上部安装有 2 个直径为 250 mm 的变速风机(P4E30 型，Multifan，美国)，为每间猪舍提供最小量通风，粪池风机的通风率由风速仪直接测量得到[32]；墙上风机的通风率通过持续测量墙上风机的运行时间、小间内静压力以及后期风机测量模型[33]间接计算得到。

在每个小间墙上安装有红外活动量传感器(Visonic SRN 2000 Detector 型，Visonic Inc.，美国)将探测到的红外光线信号转换成电压信号，用于猪的活动量(以电压度量)监测[34]。

每个小间中猪的数量是由人工每个星期进行计数得到。猪的质量由猪的初始质量和生长模型计算而得到，猪的生长模型曲线表示为

$$W_{0\sim29}=0.008\,592\,3D^2+0.107\,91D+5.35 \quad (9)$$

$$W_{30\sim150}=0.002\,339\,7D^2+0.562\,14D-3.31 \quad (10)$$

式中　$W_{0\sim29}$、$W_{30\sim150}$——入栏 0 ~ 29 d 和 30 ~ 150 d 的猪质量

D——入栏的时间，d

由生长曲线计算得到的猪的质量与实际质量的拟合度为 0.999 8，说明由生长模型计算得到的猪的质量完全可以反映猪的质量变化情况。这些数据根据需要，插值处理成时间间隔为 1 h 的数据。

猪舍外部温度与相对湿度等天气数据来源于距离猪舍 5 km 的普渡大学园艺研究与教育中心，以及安装在距离猪舍南侧 70 m 的 Davis 6152 Wireless Vantage Pro2 型气象站(Davis Instruments，美国)监测得到。

根据猪舍所处地理位置、气候特点以及监测数据的完整性等，本文分别选取 2 个朝南向的小间 2 和小间 4，从 2015 年 8 月 28 日至 9 月 30 日和 2015 年 12 月 24 日至 2016 年 1 月 13 日 2 个阶段的采集间隔为 1 min 的舍内、外环境数据，将这些数据处理为时间间隔为 1 h 的数据进行模型训练与验证，实际监测数据变化，如表 2 和图 4 所示。

3.2　模型参数性能对比及选取

3.2.1　不同学习速率

从不同网络的学习速率取值集合{0.001，0.003，0.005，0.008，0.010}中对模型进行测试，以

表 2 实际监测数据变化范围

Tab. 2 Variations of collected data

季节	数据统计	舍内温度/℃	舍内相对湿度/%	舍外相对湿度/%	舍外温度/℃	猪活动量/V	猪总质量/kg	通风率/($m^3 \cdot min^{-1}$)	粪坑温度/℃
夏季	最小值	20.3	26.3	23.4	6.4	0.6	1 942.4	33.7	22.0
	最大值	26.8	51.7	97.7	33.3	1.5	4 157.3	14 294.0	31.3
	平均值±标准差	22.6±1.1	45.5±6.0	72.3±18.8	20.3±5.9	0.8±0.2	3 026.1±659.4	7 056.0±5 494.4	25.6±2.0
冬季	最小值	17.6	9.8	50.4	−17.4	0.1	6 212.2	33.0	−6.9
	最大值	23.7	59.2	97.0	12.6	1.0	7 719.1	9 730.5	19.0
	平均值±标准差	21.6±1.1	41.9±6.0	84.5±8.4	−0.1±6.0	0.4±0.2	6 955.4±435.1	1 704.3±1 682.7	8.4±5.2

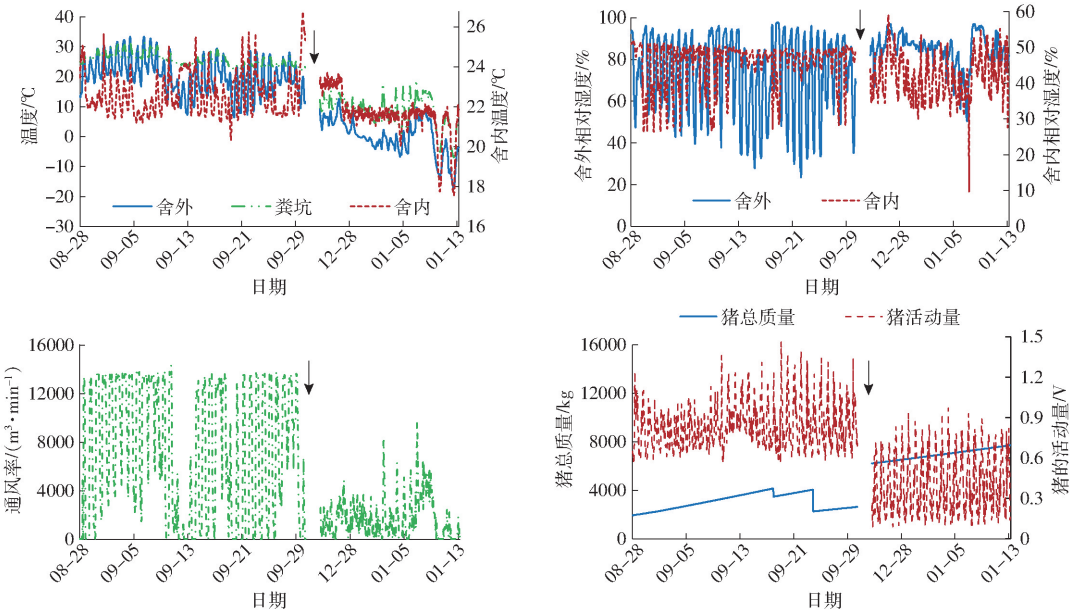

图 4 猪舍内外环境监测数据

Fig. 4 Indoor and outdoor environmental data of pig building

得到高时效、训练损失较小的优化模型。不同学习速率下网络损失如表 3 所示，当学习速率取值增大时，网络训练损失迅速下降。虽然在学习速率 0.010 时网络训练损失值最小，但是，网络损失变化率最小，在夏季和冬季分别为 0.500 0 和 0.517 2；然而在学习速率为 0.008 时的预测模型在夏季和冬季的网络训练损失变化率分别为 0.843 3 和 0.701 0，基本达到最大值，表明在学习速率大于 0.008 后，预测模型的网络训练损失下降不再明显。因此综合考虑网络训练损失和训练时间效率，本文选取 0.008 作为 LSTM 预测模型的网络训练学习速率。

表 3 不同学习速率下的网络训练损失

Tab. 3 Training losses at different learning rates

学习速率	网络训练损失		网络训练损失变化率	
	冬季	夏季	冬季	夏季
0.001	0.216 0	0.091 7		
0.003	0.063 5	0.023 3	0.706 0	0.745 9
0.005	0.021 7	0.009 7	0.658 3	0.583 7
0.008	0.003 4	0.002 9	0.843 3	0.701 0
0.010	0.001 7	0.001 4	0.500 0	0.517 2

3.2.2 不同节点数

网络训练的学习速率为 0.008 时，对 LSTM 子层和完全连接子层的节点数进行测试，以获得较优的预测性能。如图 5a、5b 所示，舍内温度和相对湿度夏季预测模型的 e_{RMSE} 和 e_{MAPE} 虽然在节点数为 2 000 和 1 600 时达到最小值，然而当节点数大于 400 时，e_{RMSE} 和 e_{MAPE} 下降较缓慢，并且相对湿度预测的 e_{RMSE} 变化曲线有逐渐上升的趋势；冬季温度和相对湿度预测模型都在节点数为 400 时，e_{RMSE} 和 e_{MAPE} 达最小值。如图 5c 所示，夏季舍内温度和相对湿度预测模型的决定系数 R^2 分别在节点数为 2 000 和 1 600 时达到最大值，然而当节点大于 400 时，温度预测模型的 R^2 增加较为缓慢；冬季温度和相对湿度预测模型都在节点数为 400 时，R^2 达最大值。因此，根据以上温度和相对湿度预测模型的 e_{RMSE}、e_{MAPE} 和 R^2 的性能变化分析，同时结合模型节点数与运行效率考虑，本文选取节点数 400 作为预测模型 LSTM 子层和完全连接层神经元的数目，优化模型的预测性能。

3.3 预测结果验证

选取 2015 年 9 月 29—30 日和 2016 年 1 月

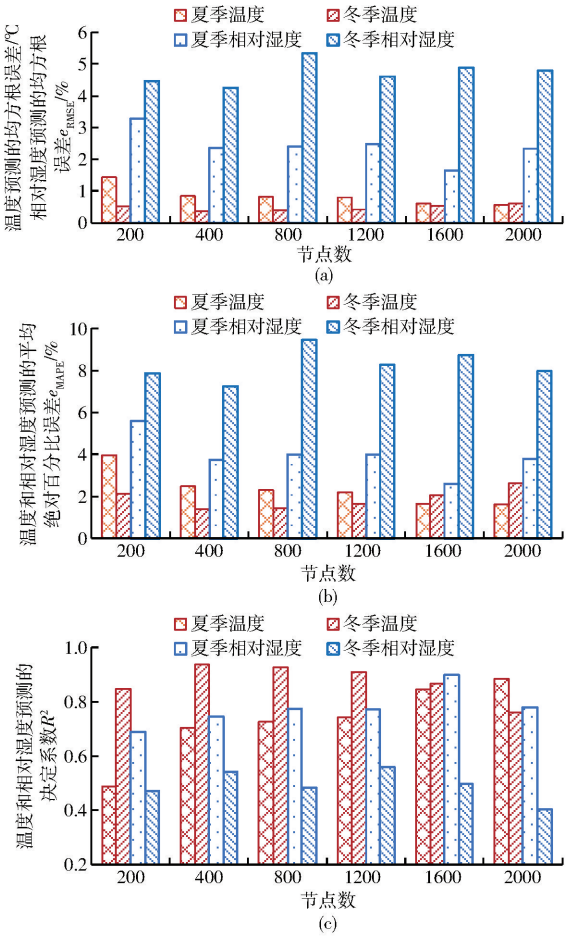

图 5　不同节点数时 LSTM 预测模型的性能变化

Fig. 5　Performances of LSTM mode with different neurons

12—13 日 4 d 监测的猪舍内环境数据以及舍外的天气数据作为猪舍内夏季、冬季温度和相对湿度验证数据对预测模型进行验证。

3.3.1　温度预测验证

如图 6 所示，猪舍内温度预测值和实际测量值变化趋势非常一致，能够很好地反映舍内温度变化情况。

如图 6a 所示，夏季猪舍内温度高峰出现在 14:00—15:00，温度低谷出现在 01:00—02:00；猪内实测温度变化范围为 21.5 ~ 26.6℃，预测温度变化范围为 21.6 ~ 25.3℃；预测值与实测值的最大误差为 1.9℃，最小误差为 0℃，平均误差 0.6℃；预测值与实测值的平均绝对百分比误差 e_{MAPE} 为 2.504%，决定系数 R^2 为 0.703。

如图 6b 所示，冬季猪舍内温度高峰出现在 22:00—01:00，温度低峰出现在 04:00—05:00；温度实际测量值变化范围为 17.6 ~ 22.1℃，预测温度变化范围为 17.6 ~ 22.1℃；预测值与实际测量值的最大误差为 1.3℃，最小误差为 0，平均误差为 0.3℃；预测值与实测值的平均绝对百分比误差 e_{MAPE} 为 1.392%，决定系数 R^2 为 0.938。

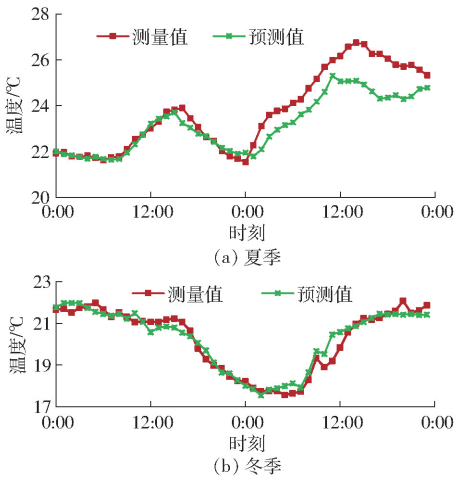

图 6　舍内温度预测值与实测值对比

Fig. 6　Comparisons of indoor temperature predictions and observations

因此，无论在冬季还是在夏季，温度预测值与实测值的误差都较小，能够较准确地反映猪舍内温度变化情况，本文所建立的温度预测模型，可以作为猪舍内温度优化调控策略的参考，实现舍内风机或加热器等温度控制设备的预先启停控制，在一定程度上弥补环境控制效果滞后问题。

3.3.2　相对湿度模拟验证

猪舍内相对湿度预测值与实际测量值对比如图 7 所示，猪舍内相对湿度预测值与实测值的整体变化趋势一致。

如图 7a 所示，由于在 9 月 29 日 06:00 起完全开启直径为 508 mm 的风机进行通风，通风量达到 9 800 m^3/min 以上，此时刻的舍外温度为 20.6℃，舍内相对湿度在 10:00 出现低峰值 28.2%，相对湿度变化较大；夏季舍内相对湿度实际测量值变化范围为 28.2% ~ 50.1%，平均值为 46.8%；相对湿度预测值变化范围为 34% ~ 50.7%，平均值 47.1%；相

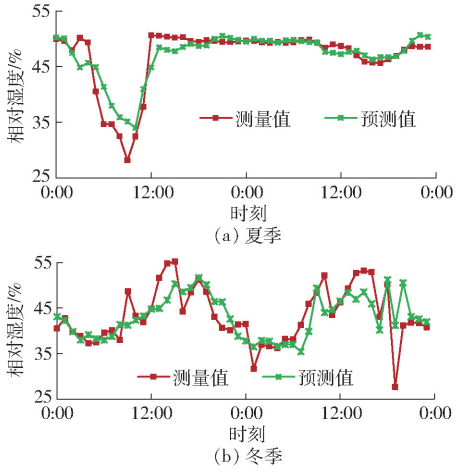

图 7　舍内相对湿度预测值与实测值对比

Fig. 7　Comparisons of indoor relative humidity predictions and observations

对湿度预测值与实测值的最大误差为 7%,最小误差为 0,平均误差为 1.6%;相对湿度的预测值与实测值 e_{MAPE}、e_{RMSE}、R^2 分别为 3.769%、2.346%、0.747。

如图 7b 所示,冬季猪舍内相对湿度变化呈现正弦周期曲线变化趋势,高峰值出现在 13:00—15:00,低峰值出现在 02:00—06:00;相对湿度实测值变化范围为 27.7% ~55.2%,相对湿度预测值变化范围为 35.4% ~51.7%;相对湿度预测值与实测值的最大误差为 13.5%,最小误差为 0,平均误差为 3.1%;相对湿度的预测值与实测值的 e_{MAPE}、e_{RMSE}、R^2 分别为 7.281%、4.245%、0.542。

根据猪舍环境控制要求及猪舍环境管理经验,在猪舍各环境因素中舍内相对湿度重要性稍次于舍内温度,允许在一定范围内舍内相对湿度稍微大一些的变化。虽然,冬季相对湿度预测值与实测值最大误差为 13.5%,但是仍然满足舍内相对湿度控制要求。因此,本研究建立的舍内相对湿度预测模型能够反映舍内实际相对湿度环境变化情况。

3.3.3 结果分析

本文建立的 LSTM 温湿度预测模型是结合传感器监测所得猪舍内外环境历史时序数据和相关影响因素时序数据,对建立的预测模型进行训练,获取最优化的网络参数;而文献[20]是通过能量和质量平衡方程,建立猪舍内动态变化的热湿小气候模型,结合传感器监测数据,利用多元非线性回归的方法和一些经验值来确定模型中的相关参数,会有一定的局限性。

文献[20]中,温度模拟值与实测值的最大误差为 2.4℃,平均误差为 0.6℃,平均决定系数 R^2 为 0.812;相对湿度模拟值与实测值的最大误差为 13.3%,最小平均误差为 3.35%,平均决定系数 R^2 为 0.905。

本文建立的预测模型中,温度预测值与实测值最大误差为 1.9℃,平均误差为 0.5℃,平均决定系数 R^2、平均 e_{RMSE} 和平均 e_{MAPE} 分别为 0.821、0.605℃和 1.984%;相对湿度预测值与实测值的最大误差为 13.5%,平均误差为 2.3%,平均决定系数 R^2、平均 e_{RMSE} 和平均 e_{MAPE} 分别为 0.645、3.297% 和 5.525%。

因此,综合考虑各项参数,本文建立的温湿度预测模型性能较优。

4 结论

(1)通过实测数据对 LSTM 温湿度预测模型参数进行训练优化,确定网络学习速率为 0.008,完全连接子层神经元数目为 400 时,模型可以达到较优的性能。舍内温度预测的平均 e_{RMSE} 和 e_{MAPE} 分别为 0.605℃和 1.984%,舍内相对湿度预测的平均 e_{RMSE} 和 e_{MAPE} 分别为 3.297% 和 5.525%。

(2)无论在夏季还是在冬季,采用建立的预测模型舍内温度与相对湿度预测值与实测值变化趋势一致。预测温度与实测温度的平均决定系数 R^2 为 0.821,舍内温度预测值与实测值最大误差为 1.9℃,平均误差为 0.5℃;预测相对湿度与实测相对湿度的平均决定系数 R^2 为 0.645,舍内相对湿度预测值与实测值的最大误差为 13.5%,平均误差为 2.3%。

(3)提出的基于深度学习的温湿度预测模型较精确地反映了猪舍内温度与相对湿度的变化情况,将预测模型的预测输出加入到控制策略中,可以预测下一小时的猪舍环境状况、提前对环境控制设备发出控制指令,控制设备提前运行可缓解控制效果滞后的问题,为猪舍内环境优化控制策略提供可靠的参考。

参 考 文 献

[1] 施正香. 猪舍环境设计应“以猪为本”[J]. 北方牧业, 2018(12): 15 -16.

[2] 孙朋朋, 宋春阳. 猪舍环境因素对猪生长性能的影响及应对措施[J]. 猪业科学, 2014(8): 86 -87.

[3] 高航, 姜丽丽, 王军军, 等. 热应激对猪生长性能、行为、生理的影响及调控措施[J]. 中国畜牧杂志, 2017, 53(11):11 -15.
GAO Hang, JIANG Lili, WANG Junjun, et al. Effects of heat stress on growth performance, behavior, and physiology in pigs and regulation measures[J]. Chinese Journal of Animal Science, 2017, 53(11):11 -15. (in Chinese)

[4] 蒲红州, 陈磊, 张利娟, 等. 湿热环境对自由采食生长育肥猪采食行为的影响[J]. 动物营养学报, 2015, 27(5):1370 -1376.
PU Hongzhou, CHEN Lei, ZHANG Lijuan. Effects of hot and humid environment on feeding behavior in growing-finishing pigs with ad libitum feeding[J]. Chinese Journal of Animal Nutrition, 2015,27(5):1370 -1376. (in Chinese)

[5] 李修松,叶章颖,李保明,等. 不同通风模式对保育猪舍冬季环境的影响[J/OL]. 农业机械学报,2020,51(3):317 -325.
LI Xiusong, YE Zhangying, LI Baoming,et al. Influence of different ventilation system on the environment of nursery piggery in winter [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2020,51(3):317 -325. http://www.j-csam.org/jcsam/ch/reader/view_abstract.aspx? file_no =20200336&flag =1. DOI: 10.6041/j.issn.1000-1298.2020.03.036. (in Chinese)

[6] NASIRAHMADI A, RICHTER U, HENSEL O, et al. Using machine vision for investigation of changes in pig group lying patterns[J]. Computers and Electronics in Agriculture, 2015, 119: 184 -190.

[7] STINN J. Environmental assessment and control towards improved swine breeding-gestation-farrowing operation in the Midwestern United States[D]. Ames: Iowa State University, 2014.
[8] BJERG B, RONG L, ZHANG G, et al. Computational prediction of the effective temperature in the lying area of pig pens[J]. Computers and Electronics in Agriculture, 2018, 149: 71 - 79.
[9] LEE I B, KWON K S, ZHANG G Q, et al. Computational fluid dynamics analysis of the thermal distribution of animal occupied zones using the jet-drop-distance concept in a mechanically ventilated broiler house[J]. Biosystems Engineering, 2015, 136: 51 - 68.
[10] ROJANO F, BOURNET P E, HASSOUNA M, et al. Computational modelling of thermal and humidity gradients for a naturally ventilated poultry house[J]. Biosystems Engineering, 2016, 151: 273 - 285.
[11] COSTANTINO A, FABRIZIO E, GHIGGINI A, et al. Climate control in broiler houses: a thermal model for the calculation of the energy use and indoor environmental conditions[J]. Energy and Buildings, 2018, 169: 110 - 126.
[12] 高云,刁亚萍,林长光,等. 机械通风楼房猪舍热环境及有害气体监测与分析[J]. 农业工程学报, 2018, 34(4): 239 - 247.
GAO Yun, DIAO Yaping, LIN Changguang, et al. Monitoring and analysis of thermal environment and harmful gases in mechanically ventilated multistory pig buildings[J]. Transactions of the CSAE, 2018, 34(4): 239 - 247. (in Chinese)
[13] JACKSON P, GUY J, EDWARDS S A, et al. Application of dynamic thermal engineering principles to improve the efficiency of resource use in UK pork production chains[J]. Energy and Buildings, 2017, 139: 53 - 62.
[14] HEMPEL S, KÖNIG M, MENZ C, et al. Uncertainty in the measurement of indoor temperature and humidity in naturally ventilated dairy buildings as influenced by measurement technique and data variability[J]. Biosystems Engineering, 2018, 166: 58 - 75.
[15] 谢秋菊,苏中滨,NI J Q, 等. 密闭式猪舍多环境因子调控系统设计及调控策略[J]. 农业工程学报, 2017, 33(6): 163 - 170.
XIE Qiuju, SU Zhongbin, NI J Q, et al. Control system design and control strategy of multiple environmental factors in confined swine building[J]. Transactions of the CSAE, 2017, 33(6): 163 - 170. (in Chinese)
[16] NILSSON M, HERLIN A H, ARDO H, et al. Development of automatic surveillance of animal behavior and welfare using image analysis and machine learned segmentation technique[J]. Animal Behavior Bulletin, 2015, 9(11): 1859 - 1865.
[17] 宣传忠,武佩,马彦华,等. 基于自适应模糊神经网络的畜禽猪舍环境控制系统的研究[J]. 内蒙古农业大学学报, 2013, 44(4): 397 - 403.
XUAN Chuanzhong, WU Pei, MA Yanhua, et al. A study on controlling system for the animal housing environment based on fuzzy neural network [J]. Journal of Inner Mongolia Agricultural University, 2013, 44(4): 397 - 403. (in Chinese)
[18] MCGINN S M, FLESCH T K. Ammonia and greenhouse gas emissions at beef cattle feedlots in Alberta Canada [J]. Agricultural and Forest Meteorology, 2018, 258(4): 43 - 49.
[19] HEMPEL S, SAHA C K, FIEDLER M, et al. Non-linear temperature dependency of ammonia and methane emissions from a naturally ventilated dairy barn[J]. Biosystems Engineering, 2016, 145: 10 - 21.
[20] 谢秋菊, NI J Q, 包军, 等. 基于能质平衡的密闭猪舍内小气候环境模拟与验证[J]. 农业工程学报, 2019, 35(10): 148 - 156.
XIE Qiuju, NI J Q, BAO Jun, et al. Simulation and verification of microclimate environment in closed swine house based on energy and mass balance[J]. Transactions of the CSAE, 2019, 35(10): 148 - 156. (in Chinese)
[21] MOON J W, YOON Y, JEON Y H, et al. Prediction models and control algorithms for predictive applications of setback temperature in cooling systems[J]. Applied Thermal Engineering, 2017, 113: 1290 - 1302.
[22] LI X, ZHAO T, ZHANG J, et al. Predication control for indoor temperature time-delay using Elman neural network in variable air volume system[J]. Energy and Buildings, 2017, 154: 545 - 552.
[23] TATAR A, BARATI-HAROONI A, NAJAFI-MARGHMALEKI A, et al. Predictive model based on ANFIS for estimation of thermal conductivity of carbon dioxide[J]. Journal of Molecular Liquids, 2016, 224: 1266 - 1274.
[24] GERS F A, SCHMIDHUBER J, CUMMINS F, et al. Learning to forget: continual prediction with LSTM [J]. Neural Computing, 2000, 12(10): 2451 - 2471.
[25] ZHENG H, YUAN J, CHEN L, et al. Short-term load forecasting using EMD - LSTM neural networks with a XGBoost algorithm for feature importance evaluation[J]. Energies, 2017, 10(8): 1168.
[26] KARIM F, MAJUMDAR S, DARABI H, et al. Multivariate LSTM - FCNs for time series classification[J]. Neural Networks, 2019, 116: 237 - 245.
[27] FAN C, WANG J, GANG W, et al. Assessment of deep recurrent neural network-based strategies for short-term building energy predictions[J]. Applied Energy, 2019, 236: 700 - 710.
[28] WEN C, LIU S, YAO X, et al. A novel spatiotemporal convolutional long short-term neural network for air pollution prediction [J]. Science of Total Environment, 2019, 654: 1091 - 1099.
[29] KUDO M, TOYAMA J, SHIMBO M, et al. Multidimensional curve classification using passing-through regions[J]. Pattern Recognition Letters, 1999, 20(11 - 13): 1103 - 1111.
[30] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735 - 1780.
[31] NI J Q, SHI C, LIU S, et al. Effects of antibiotic-free pig rearing on ammonia emissions from five pairs of swine rooms in a wean-to-finish experiment[J]. Environment International, 2019, 131: 104931.
[32] NI J Q, KAELIN D, LOPES I M, et al. Design and performance of a direct and continuous ventilation measurement system for variable-speed pit fans in a pig building[J]. Biosystems Engineering, 2016, 147: 151 - 161.
[33] 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.
[34] NI J Q, LIU S, RADCLIFFE J S, et al. Evaluation and characterization of passive infrared detectors to monitor pig activities in animal environmental research[J]. Biosystems Engineering, 2017, 158: 86 - 94.