

DOI:10.19651/j.cnki.emt.2415883

基于 CSSA-LSTM 神经网络的动态称重算法的研究*

狄俊豪 郭晨霞 杨瑞峰

(中北大学仪器与电子学院 太原 030051)

摘要: 为了提高动态称重的测量精度,实现智慧牧场的实时监测和精细化管理,提出利用混沌麻雀搜索算法优化 LSTM 的神经网络的动态称重算法。通过动态称重台进行数据采集,并使用卡尔曼滤波算法对干扰数据进行处理。利用 Tent 映射策略和高斯变异后的麻雀搜索算法优化 LSTM 神经网络各参数,从而建立 CSSA-LSTM 神经网络模型。结果表明,CSSA-LSTM 神经网络的平均绝对百分比误差在 1.5% 以内,平均绝对误差减少了 0.874,均方根误差减少了 1.115 3。对比实验证明,该混合算法预测的误差最小,有效提高了动态称重的测量精度。

关键词: 动态称重;卡尔曼滤波算法;混沌麻雀搜索算法;LSTM 神经网络

中图分类号: TN99;TP274 **文献标识码:** A **国家标准学科分类代码:** 510.4030

Research on dynamic weighing algorithm based on CSSA-LSTM neural network

Di Junhao Guo Chenxia Yang Ruifeng

(School of Instrument and Electronics, North University of China, Taiyuan 030051, China)

Abstract: In order to improve the measurement accuracy of dynamic weighing and realize real-time monitoring and fine management of intelligent pasture, a dynamic weighing algorithm based on chaotic sparrow search algorithm to optimize LSTM neural network is proposed. The data is collected by the dynamic weighing platform, and the Kalman filter algorithm is used to process the interference data. The CSSA-LSTM neural network model is established by using the Tent mapping strategy and the sparrow search algorithm after Gaussian mutation to optimize the parameters of the LSTM neural network. The results show that the average absolute percentage error of CSSA-LSTM neural network is within 1.5%, the average absolute error is reduced by 0.874, and the root mean square error is reduced by 1.115 3. The comparative experiments show that the hybrid algorithm has the smallest prediction error and effectively improves the measurement accuracy of dynamic weighing.

Keywords: dynamic weighing; Kalman filter algorithm; chaos sparrow search algorithm; LSTM neural network

0 引言

随着信息化科技的发展,中国养羊业已从散养式向更大规模、集约化、精细化的方向发展^[1]。为了提高我国的畜牧业现代化发展水平,促进我国畜牧业向智能化、机械化、规模化发展,我国政府出台相关文件强调“业供给侧结构性改革为主线”,鼓励畜牧业机械设备的研发以及物联网、人工智能等技术在畜牧业中应用^[2]。羊只的体重在侧面反映了羊只的发育情况和身体健康情况,对后续的营养供给、选中配种和疫苗注射等工作提高了数据参考,对智慧牧场系统的发展具有重要意义。

现如今,测量羊只体重的方式一般有静态称重、体测

量^[3]和动态称重 3 种。动态称重方法如今已有很多。李琦等^[4]设计了一种基于卡尔曼滤波的牲畜动态称重系统并且设计了上位机,实现了牲畜称重数据的实时显示和历史体重数据可视化。王奎等^[5]将经验模态分解(EMD)和平均值处理动态称重算法相结合,设计出一套羊只动态称重分群系统且对两种算法进行试验对比。实验结果显示,在相同时间下,EMD 算法平均误差 1.1%,平均值算法平均误差 2.7%,但预测结果精度不高。马聪等^[6]提出了基于 LSTM 神经网络的肉牛动态称重,根据 LSTM 神经网络可以有效地处理长时间序列的特性,将得到的肉牛称重时行走时间序列数据输入到 LSTM 神经网络进行训练和测试,结果显示测试数据的平均误差为 0.70%,但神经网络参数

收稿日期:2024-04-18

* 基金项目:山西省中央引导地方科技发展自由探索类基础研究项目(YDZJSX20231A032)资助

需手动选择,不能得到准确参数,可能导致结果不准确。李达等^[7]提出基于改进 PSO-BP 神经网络的动态称重,平均相对误差控制在 5.3%,未对数据进行预处理,且预测精度不高。董小宁^[8]设计了一种奶牛动态称重系统,并使用 BP 神经网络对动态称重数据进行研究,但数据集较小,平均误差在 20% 以上且误差较大。胡肄农等^[9]研究了一种牛动态称重系统,通过神经网络学习算法,将牛运动造成的载荷冲击和振动干扰从地磅测量称重信号中分离,使称量结果更接近牛静态体重,从而实现牛的自动化动态称重。李建鑫等^[10]提出利用改进的基于分段包络线抑制端点效应的 EMD 算法处理非平稳的动态称重信号,有效抑制端点效应的同时,还能减少延拓端点引入的误差。

根据以上研究,本文提出混沌麻雀搜索算法(chaos sparrow search algorithm, CSSA)对 LSTM 神经网络(long short-term memory, LSTM)的最大迭代次数、隐藏神经元和最优开始学习率进行优化。同时, CSSA 可以防止优化结果陷入局部最优解,提高算法的优化能力。最后,将采集的数据传入神经网络模型中,利用 CSSA-LSTM 神经网络模型预测出羊只的真实体重,实现动态称重。

1 羊群动态称重系统

羊群称重系统主要由感应单元、称重单元、出入门控单元、DAM1624 继电器、工控机等组成。系统的称重平台由四个压力传感器构成,并且安装在平台的四个脚,平台前后配备由 DAM1624 继电器控制的两个电机闸门,周围由焊接的围栏围住。同时,光电传感器安装在前后两个门处,防夹装置安装在出入门上,其功能是防止羊只被出入门夹伤。NCM604 变送器用于读取压力传感器的数据并上传至由 LabVIEW 软件编写完成的上位机。系统结构如图 1 所示。

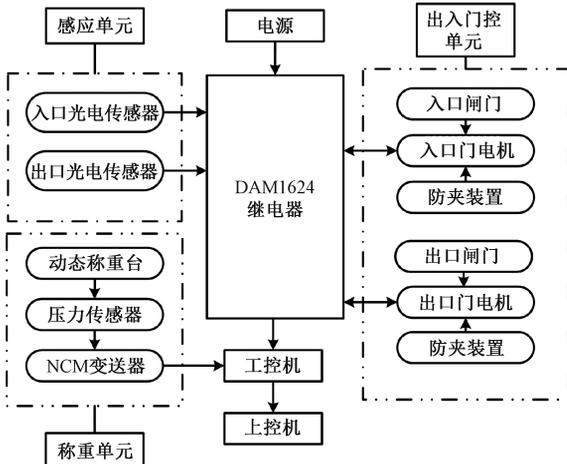


图 1 动态称重系统

Fig. 1 Weigh-in-motion system

羊只称重过程主要是:羊只经过前电机闸门时,入口光电传感器将会进行识别,并通过控制 DAM1624 继电器打开前闸门,等待羊只全部进入称重平台后关闭前闸门。然

后对羊只进行体重测量,体重数据由变送器传输给上位机并保存。测量结束后,控制后闸门打开,等待出口光电传感器识别到羊只后,关闭后闸门,称重结束。在称重过程中防夹装置保护羊只安全。动态称重的实物图如图 2 所示。



图 2 动态称重实物图

Fig. 2 Dynamic weighing physical map

动态体重测量的物理原理:当羊群个体在称重台上运动或者变换姿势时,装置内部的传感器可以检测到相应的压力变化,从而实现动态体重测量。

2 CSSA-LSTM 神经网络

2.1 LSTM 神经网络

将神经网络应用到动态称重系统中,实质是利用神经网络的学习能力和非线性关系建模能力来处理动态称重系统中复杂的数据和模式,从而得到精准的预测结果。LSTM 神经网络可以处理长序列数据,避免了梯度消失或梯度爆炸的问题^[11],同时 LSTM 具有记忆性,有助于模型更好地理解数据中的序列结构和模式。LSTM 常见单元结构如图 3 所示。

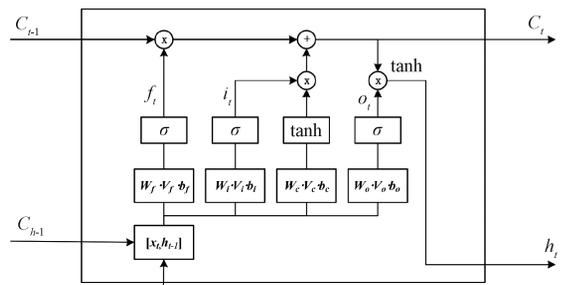


图 3 LSTM 单元结构

Fig. 3 LSTM unit structure

LSTM 遗忘门计算公式为:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \tag{1}$$

式中: f_t 为遗忘门,其对 C_{t-1} 中无用信息选择性遗忘, W_f 为权重系数, b_f 为偏置项, σ 为 sigmoid 函数。

i_t 为输入门,计算公式为:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \tag{2}$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (3)$$

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (4)$$

式中: \tilde{C}_t 为网络内部状态, C_t 为更新后的单元结构状态, b_i, b_C 为偏置项, W_i, W_C 为权重系数。

o_t 为输出门公式为:

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (5)$$

$$h_t = o_t \times \tanh(C_t) \quad (6)$$

式中: W_o 为权重参数, b_o 为偏置项。

2.2 麻雀搜索算法

传统的 LSTM 神经网络需要手动选择参数,可能导致预测效果差,结果不收敛、不稳定等缺点,为了解决这一缺点采用麻雀搜索算法进行参数的寻优。麻雀搜索算法(sparrow search algorithm, SSA)思想是借鉴自然界中麻雀的捕食行为和反哺行为^[12]。

2.3 混沌麻雀搜索算法

由于 SSA 很容易陷入局部最优解,故使用 CSSA。CSSA 结合 Tent 混沌映射和高斯变异改进了算法,增加了麻雀初始化种群的多样性,提高了算法的全局搜索能力和优化性能^[13]。

2.4 Tent 混沌映射

原始的 SSA 种群随机初始化过程有缺陷,使用 Tent 混沌映射可以增加种群初始化的多样性和随机性。Tent 混沌映射表达式为:

$$X_{i+1} = \begin{cases} \frac{X_i}{a}, & 0 < X_i \leq a \\ \frac{(1-X_i)}{(1-a)}, & a < X_i \leq 1 \end{cases} \quad (7)$$

式中: X_i 为第 i 次迭代时的映射函数值; a 为混沌系数。

为了避免更新迭代过程中的一些非平稳性周期点,在 Tent 混沌映射中加入扰动,产生 Tent 扰动,计算公式如下^[14]:

$$X_{i+1} = \begin{cases} \frac{X_i + \text{rand}(0.5, 1)}{a}, & 0 < X_i \leq a \\ \frac{(1-X_i) + \text{rand}(0.5, 1)}{(1-a)}, & a < X_i \leq 1 \end{cases} \quad (8)$$

式中: N 为混沌序列的粒子数, rand 为产生随机数的函数。

2.5 高斯变异

高斯变异具体指在进行变异操作时,用符合均值为 μ , 方差为 σ^2 的正态分布的一个随机数来替代原基因值^[15]。变异公式为:

$$\text{mutation}(x) = x(1 + N(0, 1)) \quad (9)$$

式中: x 为原来的参数值; $N(0, 1)$ 为 $(0, 1)$ 正态分布的随机数; $\text{mutation}(x)$ 为高斯变异后的数值。

2.6 混沌麻雀搜索算法优化 LSTM 实现步骤

步骤 1) 将数据集划分为训练集和测试集, 构建 LSTM

神经网络并等待参数输入。

步骤 2) 对麻雀种群个数、最大迭代次数、上下边界、发现者个数等参数初始化, 通过 Tent 混沌映射对麻雀种群进行初始化。

步骤 3) 通过计算每只麻雀的适应度值, 得到当前种群最优和最差麻雀的适应度值和位置。

步骤 4) 通过比较所有麻雀的适应度值并选取发现者和跟随者, 发现者的选取方法是: 在较优适应度值的麻雀中选取一部分, 剩余其他的麻雀为跟随者, 并且更新位置。

步骤 5) 在麻雀种群中随机选取一部分麻雀作为警戒者同时更新位置。

步骤 6) 每次得到寻优结果后, 计算每只麻雀的适应度值 f_i 和种群平均适应度值 f_{avg} 。通过比较两个适应度值会出现两种情况。

(1) 若 $f_i < f_{avg}$, 需要进行高斯变异, 如变异后的个体效果更好, 则替换原来个体, 否则, 不进行改变。

(2) 若 $f_i \geq f_{avg}$, 则进行 Tent 扰动, 如变异后的个体效果更好, 则替换原来个体, 否则, 不进行改变。

步骤 7) 通过更新得到最新的麻雀最优位置和其适应度值。

步骤 8) 判断是否完成迭代, 若完成则结束循环, 否则, 返回到步骤 4)。

步骤 9) 将优化后的参数输入到神经网络并进行预测, 判断是否达到中止条件, 若达到则结束循环。流程图如图 4 所示。

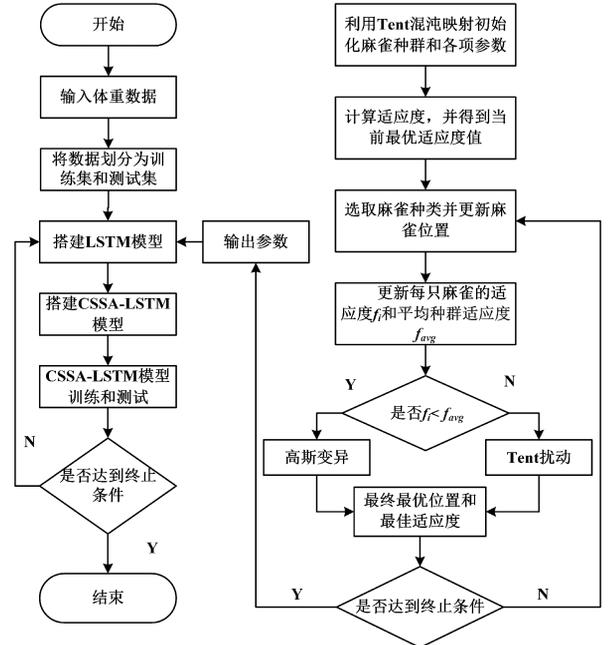


图 4 CSSA-LSTM 算法流程图

Fig. 4 CSSA-LSTM algorithm flowchart

CSSA-LSTM 算法在预测较差做出了改进有: 首先采用 LSTM 神经网络, 更好的捕捉时间序列的规律, 然后使

用 CSSA 优化 LSTM 神经网络参数,使结果预测更加准确。

3 实验与结果分析

3.1 数据处理

实验数据是通过 7 个不同体重的实验人员携带 0、0.5、1、3、5、10、20 kg 的砝码,模拟不同体重羊只动态测量得到的。实验对不同体重的数据采集 88 次,共测得 4 312 组数据,数据集是由四个为一组的体重值构成。将数据集划分为训练集和测试集,并随机选取 400 组作为测试集数据,训练集和测试集之比约为 9 : 1。

由于在动态测量过程中会存在噪声和一些不确定因素,如:外界刺激造成在称重过程中羊只反应过激,使得测量采集的数据过大,影响算法预测的结果。所以需要实验数据进行滤波处理,使得实验结果趋向于真实值。数据处理使用卡尔曼滤波进行处理。

卡尔曼滤波的基本思想是利用当前时刻的状态估计值和当前时刻的观测值来确定当前状态的估计值,非常适合处理动态称重产生的数字信号^[16]。

卡尔曼滤波主要分为预测和更新。卡尔曼滤波预测方程为:

$$\mathbf{X}_k = \mathbf{A}\mathbf{X}_{k-1} + \mathbf{B}\mathbf{U}_{k-1} \quad (10)$$

$$\mathbf{P}_k = \mathbf{A}\mathbf{P}_{k-1}\mathbf{A}^T + \mathbf{Q} \quad (11)$$

式(10)是状态预测方程, k 时刻的状态 \mathbf{X}_k 是 $k-1$ 时刻的状态 \mathbf{X}_{k-1} 与状态转移矩阵 \mathbf{A} 相乘,与输入控制矩阵 \mathbf{B} 和外界对系统的作用 \mathbf{U}_{k-1} 的乘积相加得到的。式(11)是误差矩阵预测, \mathbf{Q} 是预测噪声协方差矩阵, \mathbf{P}_k 是误差矩阵。

卡尔曼滤波更新方程为:

$$\mathbf{K}_k = \mathbf{P}_k\mathbf{H}^T(\mathbf{H}\mathbf{P}_k\mathbf{H}^T + \mathbf{R})^{-1} \quad (12)$$

$$\mathbf{X}_k = \mathbf{X}_k + \mathbf{K}_k(\mathbf{Z}_k - \mathbf{H}\mathbf{X}_k) \quad (13)$$

$$\mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k\mathbf{H})\mathbf{P}_k \quad (14)$$

式(12)是卡尔曼增益方程, \mathbf{K}_k 是卡尔曼增益, \mathbf{R} 为测量噪声协方差矩阵, \mathbf{H} 为观测矩阵。式(13)为输出的最终卡尔曼滤波的值, \mathbf{Z}_k 为 k 时刻的观测的值。式(14)为协方差矩阵更新。

在称重之前测得称重台空载状态下存在的误差约为 0.5 kg,故设置 $\mathbf{R} = 0.5$ 。预测噪声协方差矩阵 \mathbf{Q} 在实验中很难测到,选取经验值为 0.1。观测矩阵的作用是把传感器读取的数据对应到系统状态量上,由于观测值的数量和状态量的数量相等,所以观测矩阵 \mathbf{H} 选取值为 1。实验中设置参数 $\mathbf{A} = \mathbf{H} = 1$, $\mathbf{Q} = 0.1$, $\mathbf{R} = 0.5$,由于称重过程中除体重外无输入,故输入控制矩阵 $\mathbf{B} = 0$, \mathbf{X}_{k-1} 初始状态为体重静态真实值。选取实验中一段数据作为原始数据并进行滤波,效果图如图 5 所示。滤波后的数据更接近真实值,数据动态值波动减小并且数据异常值(尖点)减小数据更加平滑稳定,对后续实验有一定帮助。当前后相邻的测量对象之间的差值非常大时,卡尔曼滤波输出会出现较大失真,

可以根据数据动态调整 \mathbf{R} 和 \mathbf{Q} 数值,使实验对异常值的处理效果更好。

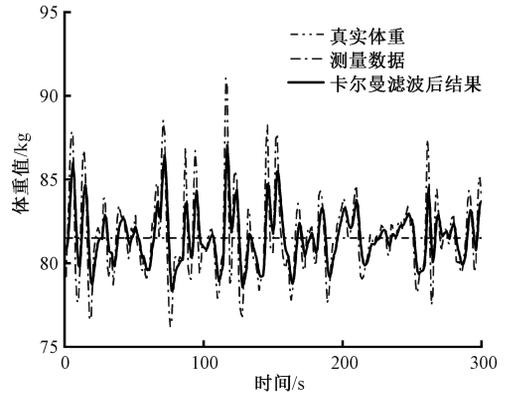


图 5 滤波前后对比图

Fig. 5 Comparison before and after filtering

3.2 实验结果

实验在 Matlab R2021b 平台实现,在构建神经网络之前使用 mapminmax 函数对数据进行归一化处理,实验参数设置:优化器为 Adam,初始化学学习率为 0.1,下边界 $lb = [50, 50, 0.005]$;上边界 $ub = [200, 200, 0.1]$,三个参数分别为隐藏神经元个数、训练周期和初始学习率,麻雀的种群数量为 5,正则化参数 L2Regularization 为 0.01,由于动态称重过程时间较短,根据实际情况,迭代次数不应过大,所以选取最大迭代次数为 20 次,适应度函数为均方误差(MSE)。优化结果为隐藏神经元个数:86,训练周期:95,初始学习率:0.005 9。优化算法适应度收敛曲线如图 6 所示。结果显示,CSSA-LSTM 的适应度函数值较小,说明模型效果更好。

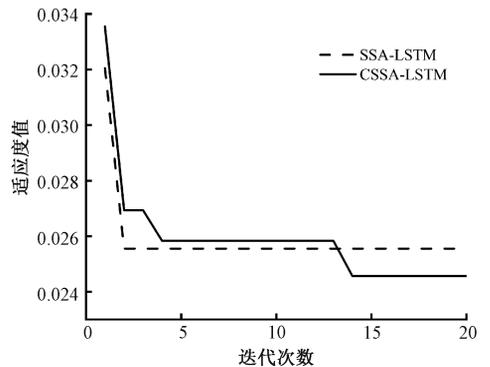


图 6 适应度收敛对比图

Fig. 6 Fitness convergence comparison diagram

将测试集 400 组数据输入到三种预测模型中得到预测结果和误差结果,LSTM、SSA-LSTM、CSSA-LSTM 的输入都为四个为一组的体重值,输出为预测的体重值,结果显示为图 7、8 所示。实验结果显示在测试集的大多数样本中 CSSA-LSTM 预测结果的体重值更接近真实值,误差更小。

表 1 为 3 种模型参数结果对比。经对比表 1 数据可

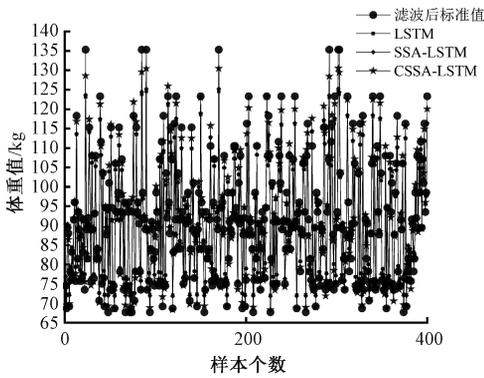


图 7 预测结果对比图

Fig. 7 Comparison chart of prediction results

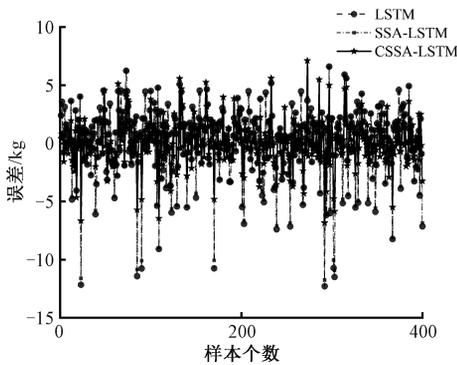


图 8 误差结果对比图

Fig. 8 Comparison diagram of error results

知:CSSA-LSTM 神经网络 MSE、RMSE、MAPE 3 个参数较 LSTM 神经网络分别减少了 0.874、1.115 3、0.985 4%,CSSA-LSTM 的 R^2 值更接近于 1,表明 CSSA-LSTM 预测结果更加精准。虽然实验原始数据集会对结果产生较大影响,但优化算法会使实验结果误差减小,结果显示实验遵循这一原则。

表 1 3 种模型参数结果对比表

Table 1 Comparison table of three model parameter results

模型	MAE	RMSE	MAPE/%	R^2
LSTM	2.215 2	3.005 6	2.419 4	0.963 06
SSA-LSTM	2.154 9	2.905 3	2.354 8	0.965 49
CSSA-LSTM	1.341 2	1.890 3	1.434	0.985 39

注:MAE 为平均绝对误差, RMSE 为均方根误差, MAPE 为平均绝对百分比误差, R^2 线性回归模型的拟合度量。

4 结 论

针对动态称重测量精度不高的问题,本文使用卡尔曼滤波对数据进行预处理,并提出了基于 CSSA-LSTM 神经

网络模型对动态称重信号进行处理。对比实验结果表明,该混合算法的平均绝对百分比误差、平均绝对误差和均方误差根误差均小于其他模型,预测值更接近于真实值,满足对羊群进行动态称重的要求。由于 LSTM 神经网络的训练过程较慢,会导致动态称重系统实际称重时间过长,后续需要改进这一缺点。

参考文献

- [1] 姚州,谭焱,田芳,等. 计算机视觉技术在智慧羊场中的研究进展[J]. 中国饲料,2021(7):7-12.
YAO ZH, TAN H, TIAN F, et al. Research progress of computer vision technology in intelligent sheep farm[J]. China Feed, 2021(7):7-12.
- [2] 李建雄,耿爽. 我国畜牧业供给侧结构性改革的五大重点方向探究[J]. 农业经济,2019,(1):21-23.
LI J X, GENG SH. The five key directions of the structural reform of the supply side of animal husbandry in China[J]. Agricultural Economy, 2019,(1): 21-23.
- [3] 孙炜,钮华明,陈玲. 成年湖羊体重估测初探[J]. 畜牧与兽医,2016,48(2):144.
SUN W, NIU H M, CHEN L. Preliminary study on weight estimation of adult hu sheep [J]. Animal Husbandry and Veterinary Medicine, 2016,48(2):144.
- [4] 李琦,夏云龙. 基于卡尔曼滤波的牲畜动态称重系统的设计[J]. 黑龙江畜牧兽医,2017(23):23-27,285-286.
LI Q, XIA Y L. Design of livestock dynamic weighing system based on Kalman filter [J]. Heilongjiang Animal Husbandry and Veterinary, 2017(23):23-27, 285-286.
- [5] 王奎,武佩,宣传忠,等. 羊只动态称重及分群系统的设计与试验[J]. 中国农机化学报,2019,40(9):164-170.
WANG K, WU P, XUAN CH ZH, et al. Design and experiment of dynamic weighing and grouping system for sheep [J]. Chinese Journal of Agricultural Machinery Chemistry, 2019,40(9):164-170.
- [6] 马聪,李锋,张建华,等. 基于 LSTM 神经网络的肉牛动态称重算法研究[J]. 黑龙江畜牧兽医,2020(20):60-63,157-158.
MA C, LI F, ZHANG J H, et al. Research on dynamic weighing algorithm of beef cattle based on LSTM neural network [J]. Heilongjiang Animal Husbandry and Veterinary, 2020(20):60-63,157-158.
- [7] 李达,郭晨霞,杨瑞峰. 基于改进 PSO-BP 算法的动态称重数据处理[J]. 电子测量技术,2021,44(20):132-136.
LI D, GUO CH X, YANG R F. Dynamic weighing data processing based on improved PSO-BP algorithm [J]. Electronic Measurement Technology, 2021,44(20):132-136.

- [8] 董小宁. 基于 STM32 的奶牛动态称重系统研究[D]. 泰安:山东农业大学,2018.
DONG X N. Research on STM32-based dynamic weighing system for dairy cows[D]. Taian: Shandong Agricultural University, 2018.
- [9] 胡肄农,仇振升,朱红宾,等. 一种牛动态称重系统的研发[J]. 中国畜禽种业,2023,19(10):51-54.
HU Y N, QIU ZH SH, ZHU H B, et al. Development of a cattle dynamic weighing system[J]. China Livestock and Poultry Breeding Industry, 2023, 19(10):51-54.
- [10] 李建鑫,郭晨霞,杨瑞峰,等. 基于分段包络线抑制端点效应的 EMD 动态称重算法[J]. 电子测量技术, 2023,46(22):109-115.
LI J X, GUO CH X, YANG R F, et al. EMD dynamic weighing algorithm based on segmented envelope to suppress endpoint effect[J]. Electronic Measurement Technology, 2023,46(22): 109-115.
- [11] 叶鑫,王海瑞,李远博,等. 基于 VMD 和优化的 LSTM 锂离子电池寿命预测方法[J]. 电子测量技术, 2022, 45(23):153-158.
YE X, WANG H R, LI Y B, et al. Based on VMD and optimized LSTM lithium-ion battery life prediction method [J]. Electronic Measurement Technology, 2022,45(23):153-158.
- [12] 李梦源,董瑞科,王彦海,等. 基于 ISSA-BP 神经网络的滑坡区输电铁塔状态预测模型[J]. 电子测量技术, 2023,46(11):74-82.
LI M Y, DONG R K, WANG Y H, et al. State prediction model of transmission tower in landslide area based on ISSA-BP neural network[J]. Electronic Measurement Technology,2023,46(11):74-82.
- [13] 吕鑫,慕晓冬,张钧,等. 混沌麻雀搜索优化算法[J]. 北京航空航天大学学报,2021,47(8):1712-1720.
LYU X, MU X D, ZHANG J, et al. Chaotic sparrow search optimization algorithm [J]. Journal of Beijing University of Aeronautics and Astronautics, 2021, 47(8):1712-1720.
- [14] 朱广明,华亮,赵佳皓,等. CSSA-DWNN 算法的机器人焊接工艺参数优化研究[J]. 实验室研究与探索,2023, 42(7):48-53.
ZHU G M, HUA L, ZHAO J H, et al. Optimization of robot welding process parameters based on CSSA-DWNN algorithm [J]. Laboratory Research and Exploration,2023,42(7):48-53.
- [15] 王晓慧,刘雪英,白梅花. 引入高斯变异和最速下降算子的人口迁移算法[J]. 计算机工程与应用, 2009, 45(20):57-60,62.
WANG X H, LIU X Y, BAI M H. Population migration algorithm with Gaussian mutation and steepest descent operator [J]. Computer Engineering and Application,2009,45(20):57-60,62.
- [16] 吴铁洲,李炎,祁军,等. 卡尔曼滤波结合数字锁相放大器的弱光声信号降噪方法研究[J]. 仪表技术与传感器,2020(10):98-102.
WU T ZH, LI Y, QI J, et al. Research on noise reduction method of weak photoacoustic signal based on Kalman filter combined with digital lock-in amplifier[J]. Instrument Technology and Sensor,2020(10):98-102.

作者简介

狄俊豪, 硕士研究生, 主要研究方向为物联网智能感知与溯源方法。

E-mail: 1486310644@qq.com

郭晨霞(通信作者), 博士, 副教授, 主要研究方向为测控技术和视觉测量。

E-mail: guochenxia@nuc.edu.cn

杨瑞峰, 教授, 主要研究方向为自动化测试与控制技术。

E-mail: yangruifeng@nuc.edu.cn