

基于VMD-LSTM的奶牛动态称量算法

贺志将^{1,2} 李前^{1,2} 王彦超^{1,2} 刘刚^{1,2}

(1. 中国农业大学智慧农业系统集成研究教育部重点实验室, 北京 100083;

2. 中国农业大学农业农村部农业信息获取技术重点实验室, 北京 100083)

摘要: 针对当前奶牛动态称量研究对动态称量信号的信息利用率偏低,不能充分提取称量信号深层信息的问题,提出一种基于变分模态分解(Variational mode decomposition, VMD)与长短期记忆网络(Long short-term memory, LSTM)的动态称量算法,以提高奶牛体质量预测精度。首先,使用阈值过滤的方法从采集到的奶牛动态称量信号中获得有效信号;其次,使用VMD算法将预处理后的有效信号分解为5个本征模态函数(Intrinsic mode function, IMF),以提取奶牛动态称量信号中蕴含的深层信息,并降低有效信号的非平稳性对预测精度产生的影响;最后,分别将归一化后的各IMF分量与有效信号结合,作为特征输入到LSTM神经网络进行训练,预测奶牛体质量。通过对使用不同特征的模型的预测结果进行对比,选用误差最小的模型作为本文的奶牛体质量预测模型。试验结果表明,本文提出的动态称量算法能够有效提取奶牛动态称量信号的深层信息,体质量预测的平均相对误差为0.81%,均方根误差为6.21 kg。与EMD算法和GRU算法相比,本文算法误差更小,更能满足养殖场的实际需求。

关键词: 奶牛; 动态称量算法; 变分模态分解; 长短期记忆网络

中图分类号: TP391.9; S823.9⁺1 **文献标识码:** A **文章编号:** 1000-1298(2022)S2-0234-07

Cow Dynamic Weighing Algorithm Based on VMD-LSTM

HE Zhijiang^{1,2} LI Qian^{1,2} WANG Yanchao^{1,2} LIU Gang^{1,2}

(1. Key Laboratory of Smart Agriculture Systems, Ministry of Education, China Agricultural University, Beijing 100083, China

2. Key Laboratory of Agricultural Information Acquisition Technology, Ministry of Agriculture and Rural Affairs, China Agricultural University, Beijing 100083, China)

Abstract: The dynamic weighing signal of dairy cows contains many signals in different frequency domains, including the weight signal of dairy cows, the inertial component signal and various noise signals. In the previous studies, the information utilization rate of dynamic weighing signal was low, and the deep information of weighing signal could not be fully extracted. To solve this problem, a method based on variational mode decomposition (VMD) and long short-term memory network (LSTM) dynamic weighing algorithm was proposed to improve the accuracy of weight prediction. Firstly, the threshold filtering method was used to obtain the effective signal from the collected dairy cow dynamic weighing signal. Secondly, in order to extract the deep information contained in the dynamic weighing signal of dairy cows, the VMD algorithm was used to decompose the pre-processed effective signal into five intrinsic mode functions (IMF). Finally, each IMF component was combined with the effective signal as feature, which was input into the LSTM neural network as features for training, and then the weight of cows was output. The prediction results of models with different characteristics were compared, as a result, the model with the minimum error was selected as the cow body weight prediction model. The experimental results showed that the proposed dynamic weighing algorithm can effectively extract the deep information contained in the dynamic weighing signal of dairy cows. The average relative error of weight prediction was 0.81%, and the root mean square error was 6.21 kg. Compared with EMD algorithm and GRU algorithm commonly used in the field of dynamic weighing, the error of the proposed algorithm was smaller.

Key words: dairy cattle; dynamic weighing algorithm; variational mode decomposition; long short-term memory network

收稿日期: 2022-06-04 修回日期: 2022-08-06

基金项目: 国家重点研发计划项目(2021YFD1300502)

作者简介: 贺志将(1998—),男,硕士生,主要从事农业健康养殖智能信息技术研究, E-mail: he1667848656@163.com

通信作者: 刘刚(1966—),男,教授,博士生导师,主要从事电子信息信息技术农业应用研究, E-mail: pac@cau.edu.cn

0 引言

体质量是养殖场对奶牛生长发育状况进行评估的一项重要指标,可以作为明确用药剂量、确定营养供给、判断繁殖性能、预测分娩时间、测定产奶性能、以及实现疾病预警等众多需求的依据^[1-6]。传统的称量方法需驱赶奶牛至带有围栏的秤台上并记录其体质量,易引起奶牛的应激反应^[7]。随着计算机技术的快速发展,养殖场奶牛称量正在向着自动化、智能化的动态称量方向发展。

动态称量算法是动态称量的核心技术,主要分为经典算法与现代化智能算法两类,其中经典算法包括最大值测量法^[8]和算术平均法^[9]等,这类方法计算较为简单,只适用于速度较低、行走较为稳定以及称量平台足够长等理想条件,因此近些年来已逐渐被淘汰。现代化智能算法种类繁多,其中主要包括信号分解算法和神经网络算法等。

结合信号模态分解以及神经网络算法建立预测模型进行质量预测,是近年动态称量研究的热点。辛宇等^[10]利用小波变换对信号进行滤波去噪与重构,通过 GA-PSO 算法迭代寻优神经网络超参数的权值,以滤波重构的动态质量、速度等作为网络输入,拟合动态质量与静态质量间的非线性关系,可以使称量误差控制在 1% 以内。然而小波分解算法对信号分解的模式较为固定,处理非线性和时序性的称量信号较为困难,而且还需要设定准确的小波基,不同的小波基选取会使得分析结果大不相同。XU 等^[11]对去噪及重构后的质量信号建立了基于 BSO 算法优化的 BP 神经网络模型,结果表明 BSO-BP 模型收敛速度快、精度高,最大质量相对误差为 1.41%。但 BP 神经网络存在易陷入局部最优解等缺点^[12],这势必会引起信号中重要信息的丢失。还有学者利用其它算法,如门控循环单元 (Gated recurrent unit, GRU)^[13]、奇异谱分析 (Singular spectrum analysis, SSA)^[14]以及支持向量机 (Support vector machines, SVM)^[15]等,也取得了较好的体质量预测结果。

奶牛动态称量信号包含多种不同频域的信号,包括奶牛本身的体质量信号、奶牛运动时所产生惯性分量的信号以及各种噪声信号等。这些不同频域的信号相互影响,相互叠加,使得奶牛动态称量信号表现出重组性、非平稳性以及复杂性的特点。前人的研究在使用信号模态分解方法将奶牛动态称量信号分解后,往往仅使用残余分量结合其他算法进行体质量预估,对信号的信息利用率偏低,对称量信号的深层信息探索不足,因此在动态称量精度上仍有

提升的空间。为进一步提高奶牛体质量预测精度,本文提出一种基于 VMD 与 LSTM 的动态称量算法。

1 材料与方法

1.1 数据采集

本文所用数据于 2019 年 7 月在河北鼎源牧业有限公司的养殖场采集得到,以 223 头奶牛为实验对象,每头奶牛采集 4 组数据,共采集得到 892 组数据。将采集到的动态称量信号样例绘制为动态质量曲线,如图 1 所示。

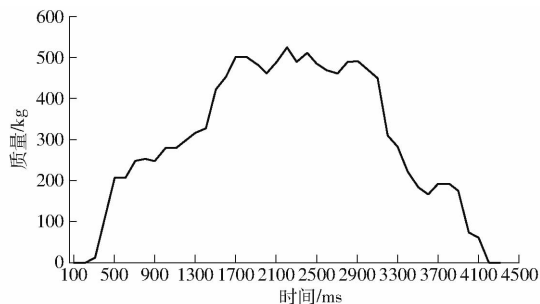


图 1 动态质量曲线

Fig. 1 Dynamic weight curve

实验设备安装在挤奶厅出口通道,设备的现场安装图如图 2a 所示。称量平台宽 0.8 m,长 2 m,为了防止在实验过程中出现两头奶牛并行或前后紧跟的情况,利用图 2b 中的围栏及闸门形成仅供单头奶牛通过的称量通道。为了保证奶牛始终在称量平台上行走,不偏离路线,在通道两侧加装了固定围栏。设备安装侧视图与正视图如图 2c 与图 2d 所示。采集数据时,将两台称量设备连接后安装在挤奶厅出口,待奶牛挤奶结束后,令其通过第 1 台称量设备走出挤奶厅以采集奶牛动态称量信号,同时,在第 2 台设备尽头设置障碍使奶牛在设备上保持短暂的静止,以此获得静态称量值,作为奶牛的真实体质量。

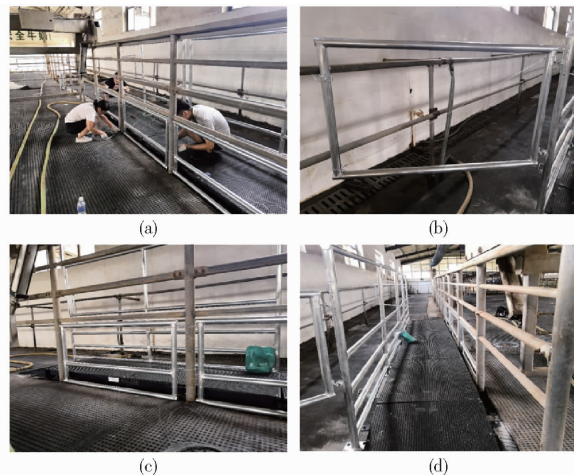


图 2 实验设备现场安装图

Fig. 2 Field installation drawings of experimental equipment

1.2 VMD 算法

VMD 算法是一种完全非递归的信号处理方法, VMD 的分解过程实质为变分问题的求解过程, 在分解时, 本征模态函数 IMF 被定义成一种包含带宽限制的调幅-调频函数, VMD 算法通过构造并求解约束变分问题, 将原始信号分解为指定个数的 IMF 分量。

VMD 算法分解信号的具体过程如下:

- (1) 初始化 $\{v_k^1\}$ 、 $\{\omega_k^1\}$ 、 λ^1 以及 $n=0$ 。
- (2) 进入循环, 令 $n=n+1$ 。
- (3) 根据更新公式对 ω_k 和 v_k 进行更新, 直到分解数为 K 时停止内循环, 更新公式为

$$\omega_k^{n+1} = \frac{\int_0^\infty \omega |v_k^{n+1} \omega|^2 d\omega}{\int_0^\infty |v_k^{n+1} \omega|^2 d\omega} \quad (1)$$

$$v_k^{n+1} = \frac{f(\omega) - \sum_{l \neq k} v_l(\omega) + \lambda(\omega)/2}{1 + 2\alpha(\omega - \omega_k)^2} \quad (2)$$

式中 ω ——频率 α ——惩罚参数
 λ ——拉格朗日乘子
 n ——迭代次数 k ——分量数
 v_k^{n+1} ——第 $n+1$ 次更新时的模态分量

- (4) 根据更新公式更新 λ 为

$$\lambda^{n+1} = \lambda^n(\omega) + \gamma \left(f(\omega) - \sum_k v_k^{n+1}(\omega) \right) \quad (3)$$

- (5) 给定精度 ε , 若满足停止条件

$$\sum_k \|v_k^{n+1} - v_k^n\|_2^2 / \|v_k^n\|_2^2 < \varepsilon \quad (4)$$

则停止循环, 否则回到步骤(2)继续循环。

上述步骤中, $\{v_k\} = \{v_1, v_2, \dots, v_k\}$ 表示分解后的各 IMF 分量, $\{\omega_k\} = \{\omega_1, \omega_2, \dots, \omega_k\}$ 表示各分量的中心频率。 γ 表示噪声容限, 当信号含有强噪声时可设定 $\gamma=0$ 以达到更好的去噪效果。

1.3 LSTM 神经网络

长短期记忆网络 (LSTM) 是在递归神经网络 (Recurrent neural network, RNN) 的基础上改进而来^[16]。 LSTM 的核心概念在于细胞状态以及“门”结构, 其中细胞状态类似于信息传输的途径, 它使得序列处理过程中的相关信息能够一直传递下去, 因此即使是较早时间步长中的信息也能被传输至较后的细胞中, 达到克服短时记忆影响的效果。 信息的添加与移除将通过特殊的“门”结构实现, 在训练过程中“门”结构会学习存储或遗忘相关信息的规则。 LSTM 细胞单元结构如图 3 所示。

图 3 中 $f(t)$ 、 $i(t)$ 与 $o(t)$ 分别为遗忘门、输入门以及输出门。 遗忘门决定了上一时刻细胞状态中的多少信息能够被传递到当前时刻; 输入门能够控制当前输入中新生成的信息是否可以被加入到细胞状态; 最后, 输出门将基于更新后的细胞状态, 输出隐藏状态。

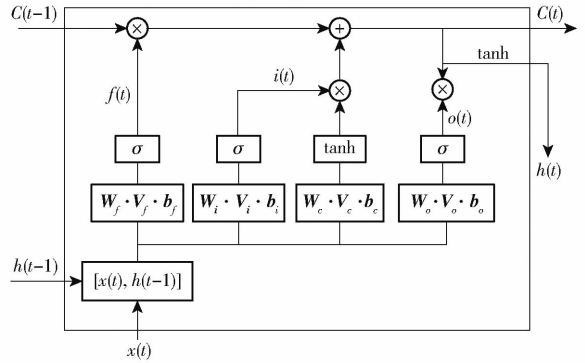


图 3 LSTM 细胞单元结构

Fig. 3 Diagram of LSTM cell structure

$f(t)$ 、 $i(t)$ 与 $o(t)$ 以及最终的输出 $C(t)$ 与 $h(t)$ 的计算公式分别为

$$f(t) = \sigma(W_f[h(t-1), x(t)] + b_f) \quad (5)$$

$$i(t) = \sigma(W_i[h(t-1), x(t)] + b_i) \quad (6)$$

$$o(t) = \sigma(W_o[h(t-1), x(t)] + b_o) \quad (7)$$

$$\tilde{c}(t) = \tanh(W_c[h(t-1), x(t)] + b_c) \quad (8)$$

$$C(t) = f(t)C(t-1) + i(t)\tilde{c}(t) \quad (9)$$

$$h(t) = o(t)\tanh(C(t)) \quad (10)$$

式中 W ——权重矩阵 b ——偏置

σ ——Sigmoid 激活函数

$x(t)$ —— t 时刻的输入

$C(t-1)$ 、 $h(t-1)$ —— $t-1$ 时刻的网络输出

$\tilde{c}(t)$ —— t 时刻传输到细胞状态的信息

1.4 VMD-LSTM 模型

1.4.1 模型预测流程

奶牛的动态称量信号包含较强的时序信息, 当奶牛四蹄全部踏入称台后, 质量将在一定范围内波动, 此时信号主要表现非线性、非平稳性的特点。 针对奶牛动态称量信号的特点, 本文构建了 VMD-LSTM 模型, 该模型的体质量预测流程如图 4 所示。

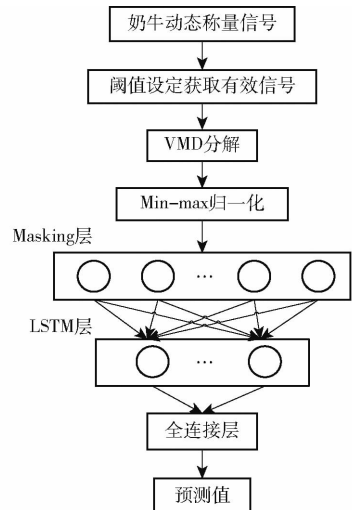


图 4 体质量预测流程图

Fig. 4 Process of weight prediction

首先使用阈值过滤的方法对动态称量信号进行预处理以获得包含主要成分的有效信号;其次,通过中心频率观察法^[17]确定 VMD 的分解个数,对有效信号进行 VMD 分解得到 IMF 分量;最后分别将各归一化后的 IMF 分量与有效信号结合,作为特征输入,以奶牛的真实体质量作为标签构建数据集对 LSTM 神经网络进行训练并输出预测结果,选取结果最优的模型作为本文的最终预测模型。

1.4.2 信号预处理

奶牛在踏上称台后,体质量信号从 0 开始逐步

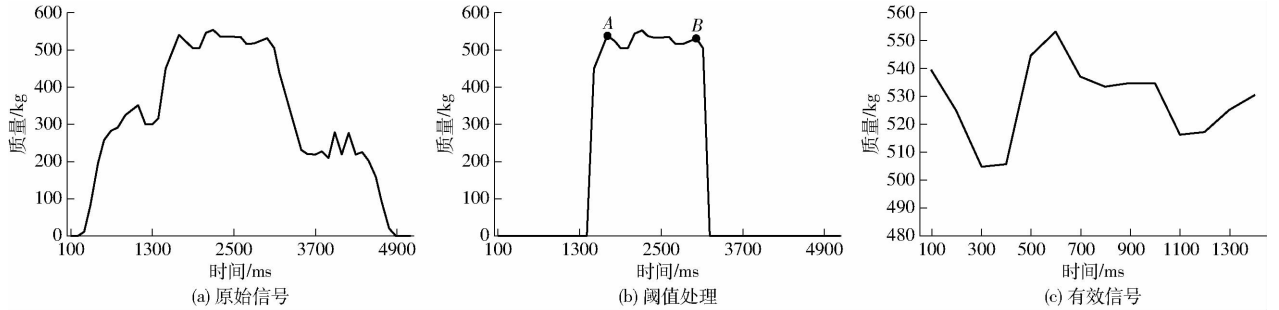


图 5 有效信号处理

Fig. 5 Effective signal processing

1.4.3 有效信号 VMD 分解

通过观察预处理后的有效信号,可以发现有效信号的波动较大,当不同活跃度的奶牛行走时,有效信号的波动幅度也不同^[19]。当奶牛处于高活跃度运动状态时,有效信号波动幅度较大,称量持续时间较短;当奶牛处于低活跃度运动状态时,有效信号波动较小,信号整体较为平稳。

VMD 算法通过信号分解得到给定信号的有效成分,可以降低复杂度高且非线性强的时间信号的非平稳性,以此得到包含多个不同频率尺度且相对较为平稳的子信号,适用于对奶牛动态称量信号的有效信号作进一步的处理。

在使用 VMD 算法之前,首先要确定变分模态的分解模态数 K 。 K 的取值将直接影响 VMD 算法的分解精度:当 K 过小时,得到的 IMF 分量个数小于信号中有效成分的个数,由于分解不充分,会导致原始信号中的一些重要信息被过滤;当 K 过大时,相邻模态分量的中心频率过于靠近,会生成一些多余的噪声分量,对结果产生一定影响。

本文通过观察中心频率的方法确定分解模态数 K 的取值,从 $K=2$ 开始不断增大 K ,分析中心频率的分布情况,如表 1 所示。当分解模态数的取值在 5 以后,最后一个模态分量的中心频率始终保持在 0.418,若继续增大 K 的取值,由于最后一层中心频率不变,分解层数越多,各分量中心频率的间隔就越小,越容易产生额外噪声分量。综上所述,可以确定

增加,当四肢全部踏入称台后体质量信号将开始在一定幅度上下震荡,直到奶牛开始下称后信号将逐渐减小至 0,如图 5a 所示。信号中奶牛上称与下称部分的信号为无效数据,需要剔除,因此本文设定了阈值 $M = \alpha f_{\max}$,其中 f_{\max} 为原始信号最大值, α 为阈值系数,设置 $\alpha = 0.8$ ^[18],将低于 M 的数据全部剔除,得到信号如图 5b 所示。取图 5b 中信号的第一个上升沿的终点 A 与最后一个下降沿的起点 B, A 与 B 之间的信号即为有效信号,如图 5c 所示。

表 1 各 IMF 分量中心频率

Tab.1 Center frequency of each IMF component

	Hz					
K	2	3	4	5	6	7
IMF1	1.9×10^{-7}	1.5×10^{-7}	1.1×10^{-7}	6.6×10^{-8}	4.5×10^{-8}	4.3×10^{-8}
IMF2	0.247	0.165	0.125	0.088	0.085	0.045
IMF3		0.288	0.247	0.170	0.166	0.165
IMF4			0.291	0.280	0.245	0.209
IMF5				0.418	0.291	0.290
IMF6					0.418	0.370
IMF7						0.418

本文分解模态数 K 的最优值为 5。

1.4.4 LSTM 预测

为了预测奶牛体质量,本文建立了 LSTM 神经网络模型,将由 VMD 算法分解得到的多个 IMF 分量与有效信号结合,作为特征输入,以奶牛的真实体质量作为标签建立数据集 $f = \{(x, i_1, i_2, \dots, i_n), m\}$,其中 x 表示奶牛动态称量信号的有效信号, i 表示有效信号被分解后的部分 IMF 分量, m 为奶牛真实体质量。

由于奶牛的动态称量信号的有效信号长度各不相同,因此在输入 LSTM 神经网络进行训练以及预测前,需要对数据进行补零操作以使其长度对齐,同时为了消除补零操作对训练过程的影响,在模型中加入 Mask 机制将被添加的无效数据屏蔽。最后还需对输入数据归一化以提高模型训练的速度与精

度,具体公式为

$$x^* = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (11)$$

式中 x ——输入信号

$\min(x)$ 、 $\max(x)$ ——信号最小值、最大值

x^* ——归一化后信号

2 结果与讨论

2.1 VMD 分解结果分析

将奶牛动态称量信号进行预处理得到有效信号后,使用 VMD 算法对其进行分解,分解结果如图 6 所示。

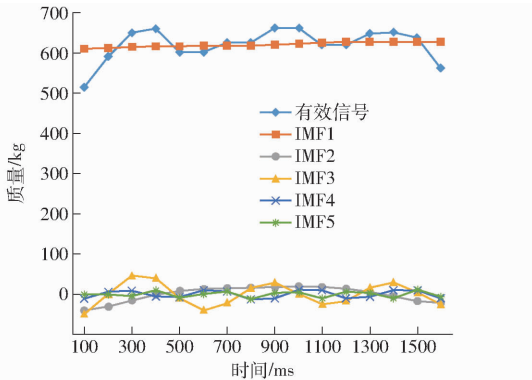


图 6 VMD 分解结果

Fig. 6 Decomposition results of VMD

IMF1 为频率最低的 IMF 分量,一般被称为残余分量,表示信号的趋势或均值;其余各分量表征了原信号在不同频率段的震荡变化,反映信号的局部特征以及深层信息。

2.2 模型特征选取

各 IMF 分量中包含了蕴含深层信息的有用信号,以及噪声信号等无用信号。为了消除无用信号对训练过程以及预测精度产生的影响^[20],得到最佳预测结果,本文首先使用预处理后的有效信号作为数据集特征,对模型进行训练并输出预测结果。其次分别对数据集特征加入 IMF1、IMF2、IMF3、IMF4 以及 IMF5 分量,对模型进行训练后,得到各自的预测结果。最后,为了对选用不同特征的模型的预测结果进行直观分析,选取均方根误差 (RMSE) 和平均相对误差 (MRE) 作为评价指标,对比结果如表 2 所示。

由表 2 可知,使用 IMF2 分量与有效信号作为特征的模型预测结果的 MRE 与 RMSE 指标分别为 0.81% 与 6.21 kg,优于使用有效信号作为特征的模型。IMF1、IMF3 以及 IMF5 分别与有效信号作为特征的模型预测结果的误差变大,说明 IMF1、IMF3 与 IMF5 分量信号不包含奶牛动态称量信号的深层信息,属于噪声信号。使用 IMF4 分量与有效信号作

为特征的模型预测结果的 MRE 指标减少 0.03 个百分点, RMSE 指标增大 0.20 kg,由于差别过小,有出现随机误差的可能。为了验证 IMF4 分量对预测结果的影响,本文进一步使用 IMF2、IMF4 与预处理后的有效信号结合,作为特征输入 LSTM 神经网络,对奶牛体质量进行预测。预测结果的 MRE 为 0.85%, RMSE 为 6.73 kg,误差大于使用 IMF2 分量与有效信号作为特征的模型,这表明 IMF4 分量信号为无效信号分量,不包含深层信息,会使预测结果误差变大。

表 2 不同特征预测结果对比

Tab. 2 Comparison of prediction results with different characteristics

特征	RMSE/kg	MRE/%
有效信号	7.00	0.94
有效信号与 IMF1	7.72	1.01
有效信号与 IMF2	6.21	0.81
有效信号与 IMF3	8.18	1.00
有效信号与 IMF4	7.20	0.91
有效信号与 IMF5	8.37	1.08

综上所述,本文将 IMF2 分量与预处理后的有效信号结合,作为特征输入 LSTM 神经网络,建立预测模型。

2.3 LSTM 预测结果分析

为了对奶牛真实体质量进行预测,本文建立了单层多维序列输入的 LSTM 神经网络模型,模型采用 Adam 算法优化,使用 MAE 损失函数计算误差,同时添加了 Dropout 正则化以减少过拟合现象,丢弃率设置为 0.2。

本文共获取 24 418 条数据,取 20% 用作测试,其余全部用于模型训练,迭代次数为 300,学习率设置动态调整,初始值为 0.001,若连续 20 轮迭代的损失不下降,则学习率自动降为原来的一半。训练完成后对测试数据进行预测,结果如图 7 所示。

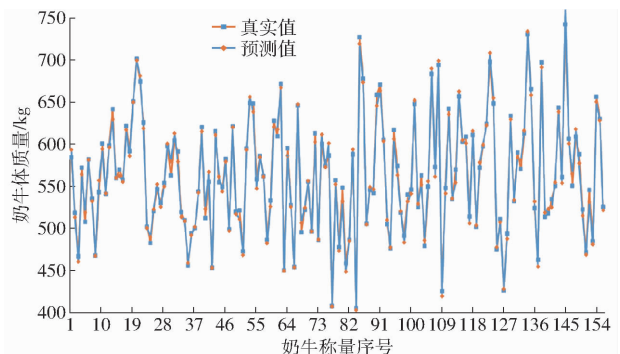


图 7 模型预测结果

Fig. 7 Model prediction result

为了验证本文算法的有效性,使用动态称量领域中常用的 EMD 算法以及 GRU 神经网络作为对

照。为了让对照结果更加直观,只选取部分结果差异较大的数据,如图 8 所示。

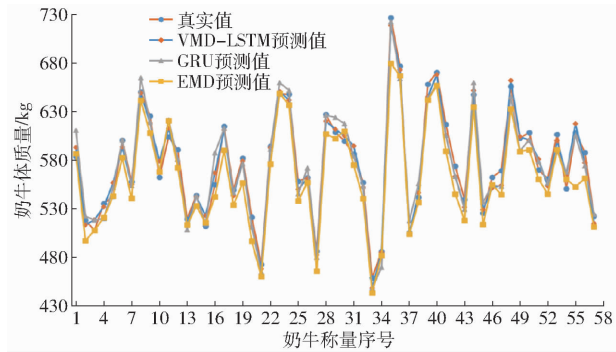


图 8 各模型预测结果对比

Fig. 8 Comparison of prediction results of each models

由图 8 可以看出,相较于 GRU 神经网络以及 EMD 算法,本文预测模型精度更高、结果偏差更小,能够有效适应不同波动范围的预测数据。3 种不同预测模型的预测性能指标如表 3 所示。

表 3 各模型性能指标

Tab. 3 Performance index of each model

预测模型	RMSE/kg	MRE/%
VMD-LSTM	6.21	0.81
GRU	8.77	1.24
EMD	10.14	1.79

由表 3 可以看出,本文预测模型的表现最好, RMSE 与 MRE 指标分别为 6.21 kg、0.81%,为三者之中最小;GRU 以及 EMD 模型的 MRE 指数均大于本文模型,分别为 1.24%、1.79%。在均方根误差方面,EMD 模型与本文模型相比相差将近一倍,为 10.14 kg,GRU 模型的 RMSE 为 8.77 kg。造成以上结果的原因是奶牛在称量过程中行走活跃度不同,

导致动态称量信号的波动幅度不同,其蕴含的深层信息复杂多变,奇异性较大。本文提出的 VMD-LSTM 算法能够有效提取出不同奶牛个体动态称量信号的各种成分信息,从而根据不同成分信号之间的差异更加准确地对奶牛体质量做出预测;使用有效信号作为输入的 GRU 模型无法读取这种差异,导致预测过程不稳定,出现较多误差较大的预测结果;使用 EMD 算法的预测模型,由于直接将残余分量的均值作为最终预测结果,未考虑到其它 IMF 分量中包含的深层信息对结果的影响,导致最终预测结果不稳定,误差较大。

3 结论

(1) 变分模态分解算法 VMD 可以将非线性、非平稳的奶牛动态称量信号的有效信号分解为多个相对较为平稳的 IMF 分量,可以清晰地反映出质量的变化趋势并有效地提取出奶牛动态称量信号中蕴含的深层信息。

(2) 分别将各 IMF 分量与有效信号结合,作为特征输入 LSTM 网络,得到各自的预测结果。分析表明,使用 IMF2 分量与有效信号一同作为特征的模型预测误差最小,这说明 IMF2 分量信号中蕴含着奶牛动态称量信号的深层信息,可以加入 LSTM 神经网络模型的输入特征以减小误差。

(3) 通过与动态称量领域常用的 GRU 以及 EMD 算法的预测结果进行对比,本文设计的 VMD-LSTM 模型的预测结果在 RMSE 与 MRE 两个评价指标上均取得更优结果,分别为 6.21 kg 以及 0.81%,验证了 VMD-LSTM 模型在奶牛动态称量应用上的有效性,更适于养殖场实际情况。

参 考 文 献

- [1] GUI J G, MU J, LIU K C, et al. Dynamic weighing system based on internet of things technologies[J]. Journal of Physics: Conference Series. IOP Publishing, 2019, 1187(3): 32013-32020.
- [2] PSZCZOLA M, SZALANSKI M, RZEWUSKA K, et al. Short communication: improving repeatability of cows' body weight recorded by an automated milking system[J]. Livestock Science, 2018, 214: 149-152.
- [3] 麻柱,李艳华. 奶牛生长性状研究进展与展望[J]. 中国奶牛,2020(2):34-37.
MA Zhu, LI Yanhua. Research progress and prospects of growth trait in dairy cattle[J]. China Dairy Cattle, 2020(2):34-37. (in Chinese)
- [4] ALDRIDGE M N, LEE S J, TAYLOR J D, et al. The use of walk over weigh to predict calving date in extensively managed beef herds[J]. Animal Production Science, 2017, 57(3):583-591.
- [5] CHEN S, TENG G, LI Z. An approach of pig weight estimation using binocular stereo system based on LabVIEW[J]. Computers & Electronics in Agriculture, 2016, 129:37-43.
- [6] SEGERKVIST K A, HGLUND J, STERLUND H, et al. Technical note: automatic weighing as an animal health monitoring tool on pasture[J]. Livestock Science, 2020, 240:104157-104162.
- [7] GONZLEZ L A, BISHOP-HURLEY G, HENRY D, et al. Wireless sensor networks to study, monitor and manage cattle in grazing systems[J]. Animal Production Science, 2014, 54:1687-1693.
- [8] 程路,张宏建,曹向辉. 车辆动态称重技术[J]. 仪器仪表学报,2006,27(8):943-948.
CHENG Lu, ZHANG Hongjian, CAO Xianghui. Vehicle weigh-in-motion technology [J]. Chinese Journal of Scientific

- Instrument, 2006, 27(8):943-948. (in Chinese)
- [9] 吕乾涛,秦兴. 用于动物的动态称重系统设计与研究[J]. 工业控制计算机, 2016, 29(11): 100-101.
Lǚ Qiantao, QIN Xing. Design and research for animals dynamic weighing system[J]. Industrial Control Computer, 2016, 29(11): 100-101. (in Chinese)
- [10] 辛宇,陈兴,许素安,等. 基于 GA-PSO-BP 的车辆动态称重算法研究[J]. 中国测试, 2021, 47(7):26-30.
XIN Yu, CHEN Xing, XU Su'an, et al. Research on vehicle dynamic weighing algorithm based on GA-PSO-BP[J]. China Measurement & Test, 2021, 47(7):26-30. (in Chinese)
- [11] XU Su'an, CHEN Xing, FU Yaqiong, et al. Research on weigh-in-motion algorithm of vehicles based on BSO-BP[J]. Sensors, 2022, 22(6):2109-2121.
- [12] 陈英义,程倩倩,成艳君,等. 基于 GA-BP 神经网络的池塘养殖水温短期预测系统[J]. 农业机械学报, 2017, 48(8): 172-178.
CHEN Yingyi, CHENG Qianqian, CHENG Yanjun, et al. Short-term prediction system of water temperature in pond aquaculture based on GA-BP neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2017, 48(8):172-178. (in Chinese)
- [13] 李涛,姚婧,吕雪涛. 基于 EEMD-GRU 的短期电力负荷预测方法[J]. 湖北理工学院学报, 2022, 38(2):7-11, 51.
LI Tao, YAO Jing, Lǚ Xuetao. Short-term power load forecasting method based on EEMD-GRU[J]. Journal of Hubei Polytechnic University, 2022, 38(2):7-11, 51. (in Chinese)
- [14] 刘小锋,冯志敏,陈跃华,等. 车辆动态称重压电信号的 SSA 降噪算法与试验[J]. 振动与冲击, 2018, 37(5):180-187.
LIU Xiaofeng, FENG Zhimin, CHEN Yuehua, et al. SSA de-noising algorithm and tests for piezoelectric signals of vehicle weigh-in-motion[J]. Journal of Vibration and Shock, 2018, 37(5):180-187. (in Chinese)
- [15] 韩芝星,蔡晓龙. 基于二叉树 SVM 的动态称重系统作弊检测的研究[J]. 工业仪表与自动化装置, 2018, 48(1):82-85.
HAN Zhixing, CAI Xiaolong. Research of cheating detection for dynamic weighing system based on binary tree SVM[J]. Industrial Instrumentation & Automation, 2018, 48(1):82-85. (in Chinese)
- [16] 杨亮,刘春红,郭昱辰,等. 基于 EMD-LSTM 的猪舍氨气浓度预测研究[J]. 农业机械学报, 2019, 50(增刊):353-360.
YANG Liang, LIU Chunhong, GUO Yuchen, et al. Prediction of ammonia concentration in fattening piggery based on EMD-LSTM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(Supp.):353-360. (in Chinese)
- [17] 贾亚飞,朱永利,王刘旺,等. 基于 VMD 和多尺度熵的变压器内绝缘局部放电信号特征提取及分类[J]. 电工技术学报, 2016, 31(19):208-217.
- [18] 冯宁宁,刘刚,张彦娥,等. 基于 EMD 的奶牛动态称量算法[J]. 农业机械学报, 2019, 50(增刊):305-312.
FENG Ningning, LIU Gang, ZHANG Yan'e, et al. Dynamic weighing algorithm of dairy cow based on EMD[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(Supp.):305-312. (in Chinese)
- [19] FENG N, KANG X, HAN H, et al. Research on a dynamic algorithm for cow weighing based on an SVM and empirical wavelet transform[J]. Sensors, 2020, 20:5363-5380.
- [20] 王俊,李霞,周昔东,等. 基于 VMD 和 LSTM 的超短期风速预测[J]. 电力系统保护与控制, 2020, 48(11):45-52.
WANG Jun, LI Xia, ZHOU Xidong, et al. Ultra-short-term wind speed prediction based on VMD-LSTM[J]. Power System Protection and Control, 2020, 48(11):45-52. (in Chinese)