doi:10.6041/j.issn.1000-1298.2026.04.032

基于时域与频域的牛只动态称重方法

张　永[1,2]　周　宇[1,2]　苏力德[1,2]　张　顺[3]　张龙飞[1,2]　沈亚锴[1,2]

(1.内蒙古农业大学机电工程学院,呼和浩特 010018;
2.农业农村部奶牛养殖工程与装备全程机械化科研基地,呼和浩特 010018;
3.内蒙古自治区巴彦淖尔市现代农牧事业发展中心,巴彦淖尔 015001)

摘要:在牛只精细化养殖领域,体质量是衡量其健康与生产性能的关键指标。传统称量方式效率低且成本高,而现有动态称量算法受限于鲁棒性和稳定性。针对这一问题,对牛只动态称量信号的隐藏信息与牛只行为信息进行量化分析,并对现有动态称量算法进行改进,提出了一种基于时、频域的运动状态分类与预测误差补偿的牛只动态称量算法。通过对信号进行模态分解获取初步体质量预测值,并计算与静态称量参数的参考误差;优化窗函数权值对信号加窗,获取可靠的信号时、频域特征参数,并探究其与运动标签和对应状态下参考误差的关系;建立运动状态分类模型和2类误差补偿模型,采用黏菌优化算法(Slime mold algorithm,SMA)对后者进行超参数优化,综上建立完整牛只动态称量模型。结果表明,牛只动态称量预测模型表现较优;运动分类模型准确率为 98.4%;在低、高活跃运动状态下,最终体质量预测值均方根误差分别为 4.03、8.96 kg,平均百分比误差分别为 0.53% 和 0.87%。该模型拥有良好的鲁棒性和泛化能力,可为实际养殖场景中的智能化体质量监测提供参考,对于推动精细化养殖的发展具有一定意义。

关键词:牛只体质量测量;时域与频域;运动状态分类;窗函数优化

中图分类号:S826.4　　**文献标识码**:A　　**文章编号**:1000-1298(2026)04-0327-12　　**OSID**:

Dynamic Weighing Method for Cattle Based on Time and Frequency Domains

ZHANG Yong[1,2]　ZHOU Yu[1,2]　SU Lide[1,2]　ZHANG Shun[3]　ZHANG Longfei[1,2]　SHEN Yakai[1,2]

(1. *College of Mechanical and Electrical Engineering, Inner Mongolia Agricultural University, Hohhot* 010018, *China*
2. *Full Mechanization Research Base of Dairy Farming Engineering and Equipment, Ministry of Agriculture and Rural Affairs, Hohhot* 010018, *China*
3. *Modern Agriculture and Animal Husbandry Development Center, Bayannur, Inner Mongolia Autonomous Region, Bayannur* 015001, *China*)

Abstract: In the field of precision breeding of cattle, weight is a key indicator for measuring their health and production performance. Traditional weighing methods are not only inefficient but also costly, while existing dynamic weighing algorithms are limited by insufficient robustness and stability. In response to this issue, the hidden information and behavioral information of cattle dynamic weighing signals were quantitatively analyzed, and existing dynamic weighing algorithms were improved by proposing a cattle dynamic weighing algorithm based on classification of time-frequency domain motion state and compensation for error prediction. Firstly, preliminary weight prediction values were obtained through modal decomposition algorithm, and the reference error with static weighing parameters was calculated. Secondly, weights of the window function were optimized to establish an adaptive window function, obtain reliable signal time-frequency domain feature parameters, and explore their relationship with motion labels and corresponding reference errors in the state. Finally, a motion state classification model and two types of error compensation models were established, and the slime mold algorithm (SMA) was used to

收稿日期:2024-11-11　修回日期:2024-12-30

基金项目:内蒙古农业大学高层次人才科研启动项目(NDYB2020-21)、国家自然科学基金项目(32460859)、内蒙古自治区一流学科科研专项项目(YLXKZX-NND-049)、内蒙古自治区直属高校基本科研业务费科研创新平台能力建设专项项目(BR251015)和内蒙古自治区高等学校创新团队项目(NMGIRT2312)

作者简介:张永(1970—),男,教授,博士生导师,主要从事数字化装备及自动控制技术研究,E-mail:yongz@imau.edu.cn

通信作者:苏力德(1989—),男,副教授,主要从事畜牧业智能感知技术研究,E-mail:sld@imau.edu.cn

perform hyperparameter optimization on the latter. Based on this, a complete dynamic weighing model for cattle was established. The experimental results indicated that the dynamic weighing prediction model for cattle performed well. The accuracy of the motion classification model was 98.4%. In low and high activity states, the root mean square error (RMSE) of the final weight prediction values were 4.03 kg and 8.96 kg, respectively, and the mean percentage error (MAPE) were 0.53% and 0.87%, respectively. This algorithm had good robustness and generalization ability, which can provide reference for intelligent weight monitoring in practical breeding scenarios, and it had certain significance for promoting the development of precision breeding.

Key words: weight measurement of cattle; time domain and frequency domain; motion state classification; window function optimization

0 引言

体质量参数是牛只精细化养殖的一项重要指标[1],其精准获取在牛只营养状态评估、生长发育、健康状况以及生产性能等方面具有重要意义[2-8]。随着科技进步,智能化、自动化的动态称量得到发展,文献[9-10]分别研发了奶牛场出口处设立自动步行称量系统和山羊室外自动称量装备,完成称量的同时节省了大量人力物力,但二者动态称量结果存在一定误差。

针对动态称量存在一定误差的问题,前人根据牛只运动状态进行分类,采取不同策略进行处理。冯宁宁等[11]根据牛只行为信息,提出基于 EMD 的动态测量算法,将奶牛运动状态分为走停、慢速、快速和剧烈运动,采用不同方式进行预测,预测误差低于 1.35%。FENG 等[12]建立活跃度分类模型,利用信号自身特征将牛只运动分为低、中、高 3 种运动状态,分别进行牛只体质量预测,平均误差率分别为 0.183 8%、0.672 4% 和 0.946 2%。二者利用牛只行为信息,根据不同行为状态采取不同策略,然而却忽视了分类后信号本身进一步分析,仅采用滤波结合模态分解的方式进行处理。

将信号处理技术结合智能算法解决动态称量的误差问题,近年来得到较多应用。马聪等[13]提出一种 LSTM 结合 BP 神经网络的方法对肉牛进行动态称量,并进行误差分析及算法改进,使肉牛动态称量误差低于 1.70%。HE 等[14]提出利用信号时域特征,建立以麻雀优化支持向量回归 SSA-SVR 误差补偿模型,进而修正奶牛预测体质量参数的动态称量算法,平均百分比误差为 0.68%。二者利用信号中的隐藏信息,提高了牛只动态称量精度,但前者并未量化隐藏信息且 LSTM 网络在复杂环境中并不稳定,后者仅利用了时域特征,并未涉及到同样为信号隐藏信息即频域特征的应用。

时频分析法是处理非平稳信号的重要工具[15],在农牧业上的利用更是一个研究热点。蒋易宇等[16]提取生菜不同叶片的不同部位时域和频域的力学特征,以此作为输入,叶片成熟特性指标作为输出,建立了水培生菜成熟度检测与分类模型,为生菜成熟度监测分类提供了新方法。林建新等[17]利用信号分析系统,采用时域和频域分析相结合的方式,确定了油菜机械直播铲锹种床整备机机组工作时的主要激振源,据此进行优化改进。尉鹏亮等[18]对超宽带雷达的土壤回波信号进行处理,提取时域与频域特征,结合 CNN 卷积神经网络建立了土壤体积含水率分级以及回归预测模型,在土壤体积含水率分级和回归预测方面较传统方式具有明显优势。以上案例利用时频分析法处理非平稳信号皆取得了良好的成果,推动了相关发展,然而时频分析法在处理牛只动态信号方面仍存在问题,时频域转换过程会导致一定的频谱泄漏,尽管窗函数的应用能将其有效降低,但因有效信号各不相同,传统的窗函数自身参数固定而无法针对性处理每一信号而实现良好的频谱抑制与频谱平滑,这将降低频域分析的可靠性,亟需进行窗函数的优化和改进。

陈至豪等[19]利用遗传算法(GA)优化组合余弦窗函数参数,实现了效果较好的四谱线插值 FFT 的电力谐波分析。张付瑗等[15]利用 S 变换方法优化窗函数,自适应地求取窗函数的尺度参数,引入新的优化调节参数以保证高频端和低频端的高分辨率。尹柏强等[20]提出一种基于改进 Kaiser 窗快速 S 变换,改善了 S 变换在电能质量扰动检测中存在计算量过大,时频分辨率低的问题。以上窗函数的优化皆取得了不错效果,但针对牛只称量信号这种低频非平稳信号的频域分析并不适用,缺少相关的窗函数优化,亟需一种能够进行窗函数权值自适应优化的方式提高时频分析的可靠性。

针对牛只称量信号特点,本文优化窗函数固定参数,建立自适应窗函数以较为可靠地对信号进行频域分析,以时频分析法对牛只动态称量信号的隐藏信息与牛只的行为信息进行量化分析,提出一种基于时域与频域的运动状态分类与预测误差补偿的

牛只动态称量方法，探究牛只动态称量信号中时、频域特征与运动状态和误差的潜在关联，进而建立运动分类模型和不同运动状态下误差补偿模型，在区分不同运动状态后，执行相应状态的误差修正，以此建立牛只动态称量预测模型，以期提升牛只体质量算法鲁棒性和动态称量精度。

1　数据获取

1.1　数据采集

试验于 2024 年在内蒙古农业大学海流图科技园区和呼和浩特市土默特左旗的小型牧场内进行，以肉牛 221 头、奶牛 193 头（共 414 头牛只）为研究对象，邀请 3 名相关专家对牛只运动状态进行评分，采集不同时段牛只自然行走状态下的称量数据，共采集数据 951 组，包含牛只静态称量参数、动态称量信号及运动状态标签。其中，低、高活跃状态数据分别为 495 组和 456 组，以 80% 作为训练集，20% 作为测试集，对本文所提预测方法进行训练和验证。

科技园区及小型牧场内包含牛用通道，数据采集平台安装至牛只通道出口处，如图 1 所示。



图 1　称量平台安置图

Fig. 1　Arrangement diagram of weighing platform

1.2　数据采集平台搭建

数据采集平台分为 2 个部分，其中一部分对牛只动态称量信号进行采集，由称量平台和硬件电路组成，另一部分则采集静态称量参数。2 个平台间根据实际情况间隔一定距离，称量示意图如图 2 所示。为保证采集动态称量信号在一个行走周期以上且方便安装，设计平台长度为 512 cm，同时设置平台高度不超过 10 cm 以保证牛只正常通行。

先行将数据采集平台安装在通道内或通道口一周，使得牛只对其逐渐适应，以确保能在牛只自然行走状态下完成信号采集。

在称量平台四角安装称量传感器（SQB－500 型），额定量程为 500 kg，灵敏度为（3.0 ±0.003）mV/V，精度等级为 C4。牛只体质量信号经称量传感器转换成电压信号后，由称量变送器进一步转换传输至数据采集卡，最终传输到 PC 端保存，硬件电路图如图 3 所示。

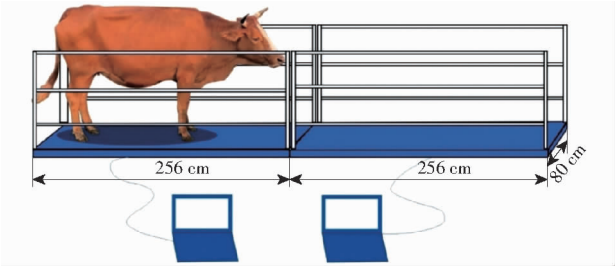

图 2　整体示意图

Fig. 2　Overall schematic

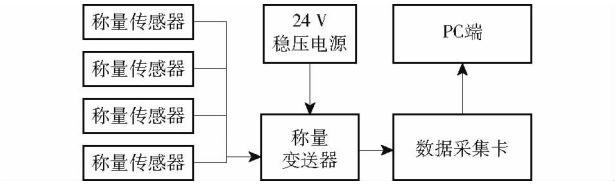

图 3　电路整体示意图

Fig. 3　Schematic of circuit as a whole

2　试验方法

2.1　整体流程

（1）通过数据采集平台对牛只动态称量信号进行采集，经过低通滤波后，与运动状态标签一同保存至 PC 端。

（2）对采集到的动态称量信号进行信号预处理，提取有效信号，然后对其进行时域特征参数提取，对信号加以自适应窗函数并进行快速傅里叶变换后，进行频域特征参数提取。

（3）对有效信号进行变分模态分解（Variational mode decomposition，VMD），得到初步体质量预测值。对初步体质量预测值和静态称量参数作差，得到参考误差。

（4）分别对时、频域特征参数与运动状态和 2 类参考误差进行相关性分析，并进行特征降维，构建运动状态分类模型和 2 类误差补偿模型的数据集。

（5）以降维处理后的数据作为输入，运动状态标签和参考误差作为输出，利用支持向量机算法，建立运动状态分类模型；使用 2 类误差数据集分别训练随机森林模型（Random forests，RF）模型，并使用黏菌优化算法优化。

（6）将得到的误差预测模型与 VMD 变分模态分解算法组成牛只动态称量预测模型，即预测误差值与初步体质量预测值相加，得到最终体质量预测值。

整体技术路线如图 4 所示。

2.2　牛只体质量信号采集与处理

2.2.1　信号采集

信号采集软件由 Labview 编写，由 2 部分组成：采集部分（生产机）和保存部分（消费机），其程序结

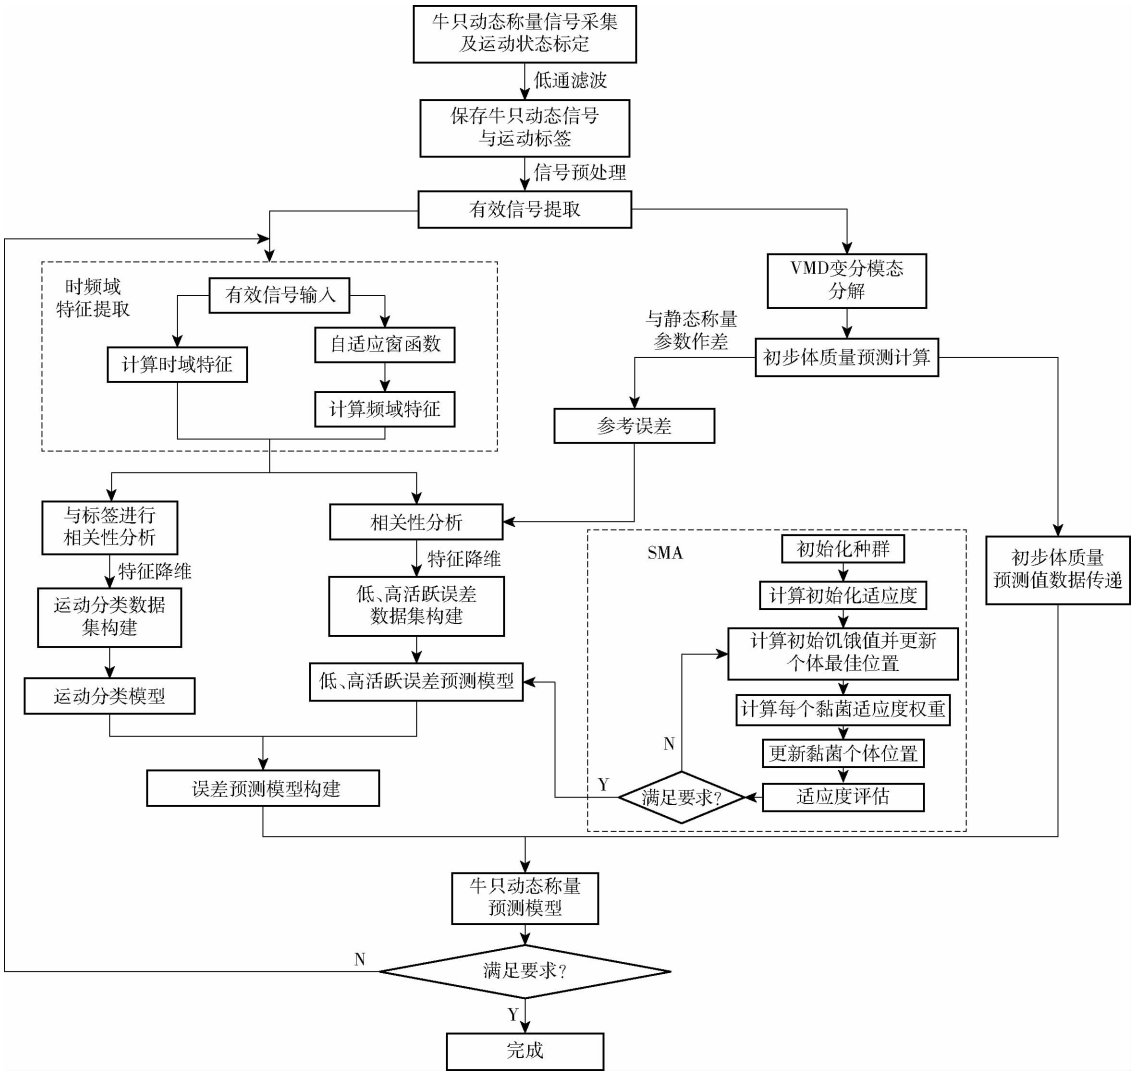

图 4 整体流程图

Fig. 4 Overall flowchart

构如图 5 所示。牛只动态称量信号经低通滤波器滤波后,将其保存为 TMDS 文件到 PC 端,以供下一步处理。

试验开始前,安装数据采集平台与静态称量平台,并使两者间隔一定距离。设采样间隔为 50 ms,每当牛只走过数据采集平台后,进行刷新置零,确保牛只称量不会受到其他杂物影响。当牛只经过动态称量平台时,利用软件内置低通滤波

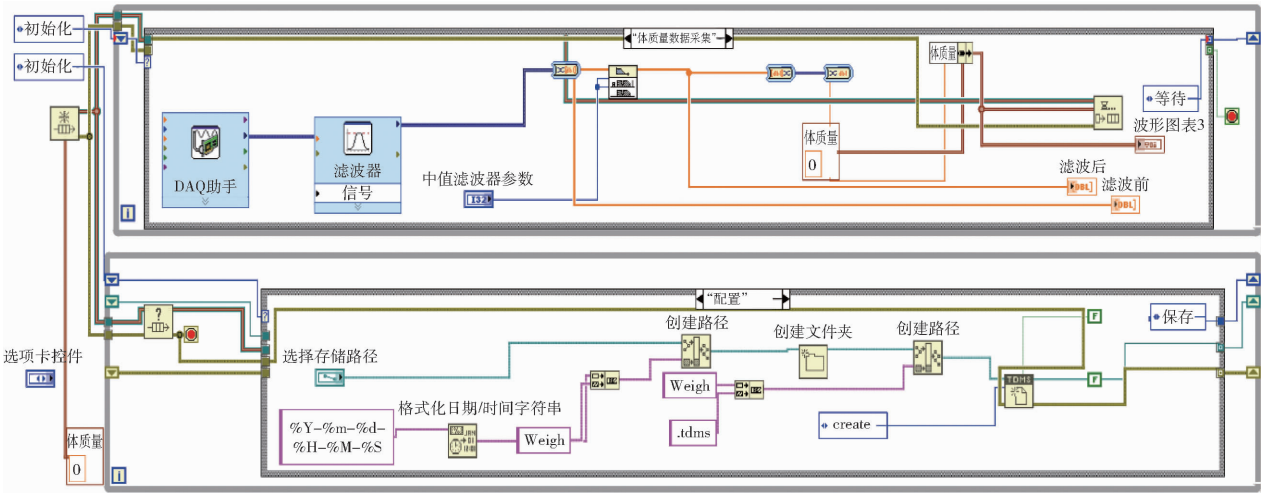

图 5 信号采集软件设计

Fig. 5 Signal acquisition software design

器对动态信号进行预处理，实时保存至 PC 端，如图 6 所示。当牛只走过静态称量平台时，对牛只进行拦截，待牛只静止 2 ~ 4 s 后，获取静态称量参数，如图 7 所示。



(a) 肉牛动态采集　　(b) 奶牛动态采集

图 6　动态信号获取

Fig. 6　Dynamic signal acquisition



(a) 肉牛静态采集　　(b) 奶牛静态采集

图 7　静态体质量参考值获取

Fig. 7　Static weight reference value acquisition

牛只动态称量信号采集界面如图 8 所示，其中包含滤波前后对比与动态称量信号波形。

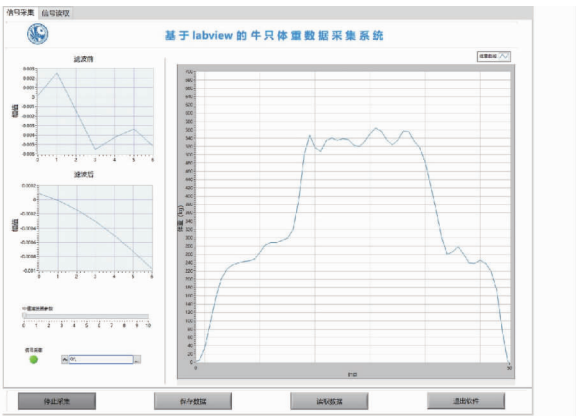

图 8　信号采集界面

Fig. 8　Signal acquisition

2.2.2　奶牛运动状态划分

牛只运动状态和健康状态对信号波形有直接影响，牛只抬腿高度、行进速度都会使信号产生不同变化，从而为信号的时域与频域带来变化。通过观察牛只自然行走状态，邀请 3 位相关专家对牛只的健康状态（如蹄部健康、精神状态等）结合牛只抬腿高度、行进速度、自身静态称量参数和称量信号幅值 4 项指标[14]，将牛只运动分为 2 个状态，即低活跃和高活跃运动状态，在采集数据过程对相应数据进行标定。牛只低活跃和高活跃状态下动态称量信号如图 9 所示。

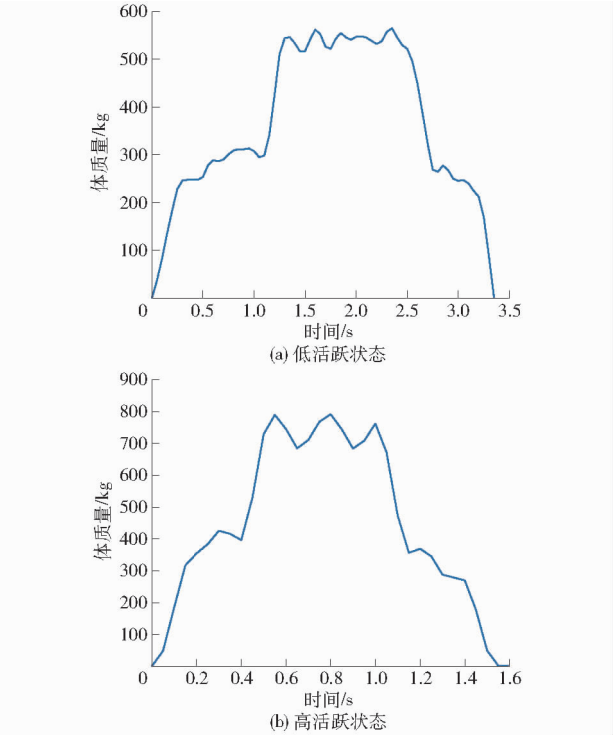

图 9　不同运动状态波形

Fig. 9　Waveform diagrams of different motion states

2.2.3　有效信号提取

动态信号上传至 PC 端后，进行有效信号提取。牛只为四足动物，当牛只体质量压力完全施加在平台上时，得到有效信号。本文以牛只动态称量信号内最大值的 0.8 倍[21]作为阈值，如图 10 所示，其分为 3 步：①对信号的最大值进行计算，设定最大值的 0.8 倍为阈值。②提取信号最大值的 0.8 倍以上信号，并找到此部分的第 1 个左极大值和右极大值。③提取阈值以上左极大值与右极大值之间的信号，设为有效信号。

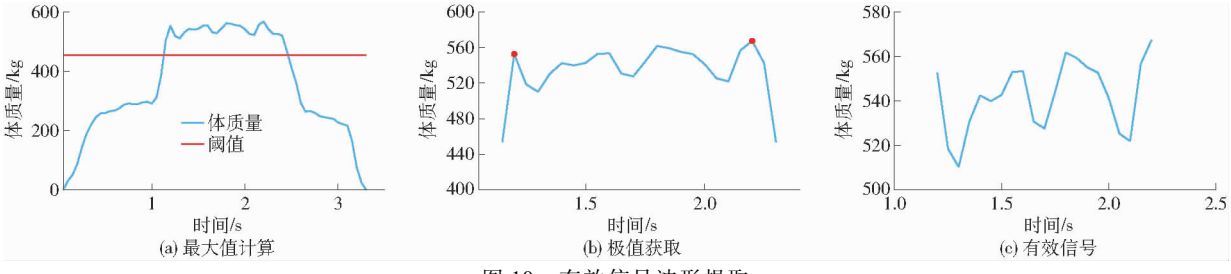

图 10　有效信号波形提取

Fig. 10　Effective signal waveform extraction

2.3 利用变分模态分解处理信号

牛只动态称量信号本身包含多种频率,其中含有牛只自身体质量、运动带来的冲量以及各种噪声,选用 VMD 算法[22]对有效信号进行模态分解,其可通过自适应模态分解得到给定信号的有效成分,降低复杂度高,非线性强的时间信号的非平稳性,因此适用于对牛只动态称量信号[23]。

运用 VMD 算法得到初步体质量预测值前,首先确定变分模态数量 K[24],过小的 K 无法充分分解有效信号,会导致一定程度的信号混叠。过大的 K 会产生过多模态,引入不必要的噪声。自 $K=2$ 开始不断增大 K,进行有效信号分解。经观察新增模态 IMF 的能量变化,最优 K 为 6,部分信号结果分解如图 11、12 所示,其中 IMF 1 平均值为初步体质量预测值。

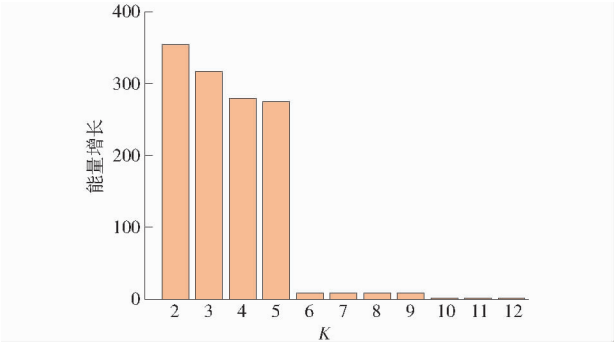

图 11 K 值增大后能量变化图

Fig. 11 Energy change diagram with increasing K value

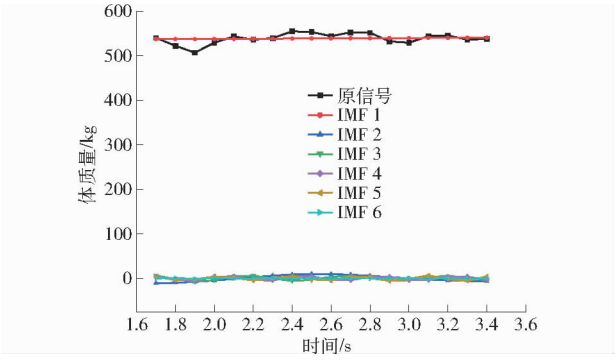

图 12 模态分解图

Fig. 12 Modal decomposition diagram

2.4 自适应窗函数

频域分析是进行信号分析的一种重要方式,利用快速傅里叶变换(Fast Fourier Transform, FFT)分析时间有限的信号切片,但随之出现的频谱泄漏却极大影响信号的频域分析,而窗函数的使用可有效规避频谱泄漏发生。

常见窗函数如矩形窗、汉明窗、布莱克曼窗等。然而,传统窗函数存在一些问题,如矩形窗的频谱平滑度较差,汉明窗旁瓣抑制效果一般等,且因大部分牛只动态称量信号自身长度和频率并不相同,针对每一信号的加窗效果也并不相同,无法达到较优效果。

为提高本次频域特征提取可靠性,结合本次试验所采集的信号特性,提出麻雀搜索算法[25](Sparrow search algorithm, SSA)优化 4 项组合余弦窗函数,建立自适应窗函数,根据信号的自身特性进行权值自适应优化,其对比其他元启发式算法同时具备收敛速度快、鲁棒性和适应性强,全局搜索能力较强等优点[26-28],能够保证计算速度的同时,较好地完成任务。组合余弦窗函数初始为

$$\omega_n = a_0 - a_1\cos\frac{2\pi n}{L-1} + a_2\cos\frac{4\pi n}{L-1} - a_3\cos\frac{6\pi n}{L-1} \quad (0\leqslant n\leqslant L-1) \tag{1}$$

其中 $$a_0 + a_1 + a_2 + a_3 = 1$$

式中 L——序列的样本数量

n——序列中的元素序号

麻雀搜索算法更新规则如下:

发现者位置更新

$$X_{ij}^{t+1} = \begin{cases} X_{ij}^{t}\exp\left(\dfrac{-i}{\alpha t_{\max}}\right) & (R_2 < S_T) \\ X_{ij}^{t} + QA & (R_2 \geqslant S_T) \end{cases} \tag{2}$$

式中 t——迭代次数

$t_{\max}$——最大迭代次数

X_{ij}——第 i 只麻雀在 j 维的位置

α——包含于(0,1]的随机数

Q——服从正态分布的随机数

$\boldsymbol{A}$——$1\times d$ 的矩阵

R_2——预警值

S_T——安全值

跟随者位置更新

$$X_{ij}^{t+1} = \begin{cases} Q\exp\left(\dfrac{X_w^t - X_{ij}^t}{\alpha t_{\max}}\right) & \left(i > \dfrac{2}{n}\right) \\ X_{ij}^{t+1} + \left|X_{ij}^{t} - X_p^{t+1}\right|\boldsymbol{A}^{+}\boldsymbol{A} & \left(i \leqslant \dfrac{2}{n}\right) \end{cases} \tag{3}$$

式中 X_p——发现者最优位置

X_w——发现者最差位置

警戒者位置更新

$$X_{ij}^{t+1} = \begin{cases} X_b^t + \beta_0\left|X_{ij}^t - X_b^t\right| & (f_i \neq f_g) \\ X_{ij}^t + K_1\dfrac{\left|X_{ij}^t - X_w^t\right|}{f_i - f_w - \varepsilon} & (f_i = f_g) \end{cases} \tag{4}$$

式中 X_b——发现者全局最优位置

β_0——符合正态分布的随机步长控制系数

ε——调整常数,规避分母为 0 的情况

K_1——[-1,1]的随机数

f_i——麻雀的适应度值

f_g——麻雀算法最优适应度值

f_w——麻雀算法最差适应度值

本次采集的有效信号具有以下特点：①低频主导。牛只在数据采集平台的四足前进、姿势变化，使得动态称量信号表现较为平滑且低频。②噪声较少。前文通过低通滤波的方式对高频噪声进行了一定程度的滤除，信号内高频噪声较少。③变化缓慢。牛只在自然行走下，通常不会进行剧烈运动，因此信号频域特征较集中在较窄频率范围内。

针对以上特点，着重抑制旁瓣泄漏和频谱平滑度两点的平衡对适应度函数进行设计，一定程度上抑制旁频泄漏，同时保证频域特征提取的精确性，因此建立适应度公式为

$$F_{fit} = \min\left(\alpha S_{SR} + \beta \frac{1}{S(\omega)}\right) \tag{5}$$

其中　　$\alpha + \beta = 1$

式中　α——旁频泄漏惩罚权重

β——平滑度惩罚权重

S_{SR}——旁瓣抑制比

$S(w)$——频谱平滑度

2.5　时频域特征提取

2.5.1　时频域特征选取

分别计算提取时域与频域特征共 18 种，与运动分类标签及参考误差进行相关性分析及主成分法降维后，构建 3 个数据集的输入部分，流程如图 13 所示。

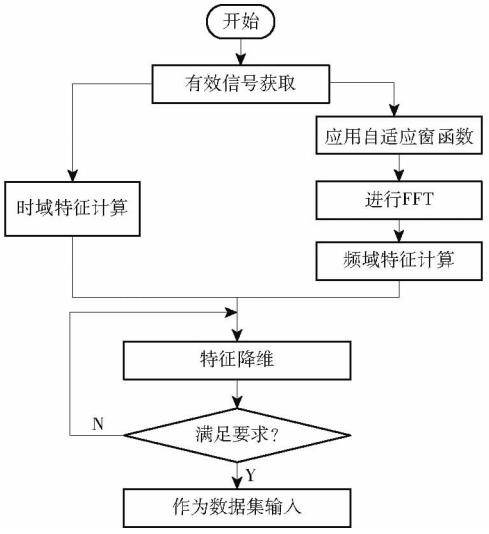

图 13　时频域特征提取流程

Fig. 13　Feature extraction process in time-frequency domain

2.5.2　时频域特征计算

信号的时域特征能够反映信号在时间维度的变化规律，对时域特征分别进行计算，包括均值、峰峰值、均方根等 12 维特征。时域特征计算公式如表 1 所示。

表 1　时域特征参数

Tab. 1　Time domain characteristic parameters

特征参数	计算式
均值	$\bar{x} = \frac{1}{N}\sum_{i=1}^{N} x_i$
峰值	$x_{peak} = \max(\lvert x_i \rvert)$
峰峰值	$x_{pp} = x_{\max} - x_{\min}$
整流平均值	$x_{arv} = \frac{1}{N}\sum_{i=1}^{N} \lvert x_i \rvert$
均方根	$x_{rms} = \sqrt{\frac{1}{N}\sum_{i=1}^{N} x_i^2}$
标准差	$\sigma = \sqrt{\frac{1}{N-1}\sum_{i=1}^{N} (x_i - \bar{x})^2}$
波形因子	$k_f = \frac{x_{rms}}{x_{arv}}$
峰值因子	$C_f = \frac{x_{peak}}{x_{rms}}$
脉冲因子	$I_p = \frac{x_{peak}}{x_{arv}}$
裕度因子	$C_e = \frac{x_{peak}}{\left(\frac{1}{N}\sum_{i=1}^{N} \sqrt{\lvert x_i \rvert}\right)^2}$
峭度	$x_{kurt} = \frac{\frac{1}{N}\sum_{i=1}^{N} (x_i - \bar{x})^4}{\left[\frac{1}{N}\sum_{i=1}^{N} (x_i - \bar{x})^2\right]^2}$
偏度	$S_k = \frac{\frac{1}{N}\sum_{i=1}^{N} (x_i - \bar{x})^3}{\left[\frac{1}{N}\sum_{i=1}^{N} (x_i - \bar{x})^2\right]^{\frac{3}{2}}}$

计算频域特征包括谱质心、谱熵、谱能量等 6 维特征，计算公式如表 2 所示。

表 2　频域特征参数

Tab. 2　Frequency domain characteristic parameters

特征参数	计算式
谱质心	$x_{SC} = \frac{\sum_{k=0}^{N-1} f_k \lvert X(k) \rvert}{\sum_{k=0}^{N-1} \lvert X(k) \rvert}$
谱平坦度	$x_{SF} = \frac{\left(\prod_{k=0}^{N-1} \lvert X(k) \rvert\right)^{\frac{1}{N}}}{\frac{1}{N}\sum_{i=0}^{N-1} \lvert X(k) \rvert}$
谱熵	$x_{SE} = -\sum_{k=0}^{N-1} \frac{\lvert X(k) \rvert}{\sum_{k=0}^{N-1} \lvert X(k) \rvert} \log_2\left(\frac{\lvert X(k) \rvert}{\sum_{k=0}^{N-1} \lvert X(k) \rvert}\right)$
谱斜率	$x_{SS} = \frac{\sum_{k=0}^{N-1} f_k \lvert X(k) \rvert - \sum_{k=0}^{N-1} f_k \sum_{k=0}^{N-1} \lvert X(k) \rvert}{N\sum_{k=0}^{N-1} f_k^2 - \left(\sum_{k=0}^{N-1} f_k\right)^2}$
谱能量	$x_{SEN} = \sum_{k=0}^{N-1} \lvert X(k) \rvert^2$
谱扩展	$x_{SSP} = \sqrt{\frac{\sum_{k=1}^{N} (f_k - x_{SC})^2 \lvert X(k) \rvert}{\sum_{k=1}^{N} \lvert X(k) \rvert}}$

2.6 牛只动态称量预测模型

2.6.1 运动分类模型

针对本次试验数据特性，选用支持向量机(Support vector machine, SVM)模型作为运动分类模型。支持向量机为一种较为常用的有监督机器学习算法，其可有效的解决线性二分类问题，引入核函数将向量投影到高维空间，以提高数据线性可分性[29]。

2.6.2 误差预测模型

针对数据集的特性，选用随机森林回归模型(Random forest regression，RFR)进行误差补偿，其在小样本容量情况下也能拥有较好的鲁棒性和更高的精度[30]。

为提高随机森林回归模型计算预测误差的精度，选用黏菌优化算法[31](Slime mold algorithm，SMA)对 RFR 模型的超参数即树的数量和最大深度进行优化，其对比其他元启发式算法，同时具有收敛性能优异、鲁棒性和稳定性较好和动态适应性强等优点，能够较好地完成预期的任务。

SMA 算法借鉴黏菌的生物行为，可以总结为 3 个步骤，即：接近食物、包围食物和抓取食物，黏菌优化算法步骤为：

(1)设置参数：初始化种群，计算适应度，公式为

$$X_i = Rand(U_B - L_B) + L_B \tag{6}$$

式中 X_i——第 i 个个体位置

U_B、L_B——搜索上、下界

$Rand$——0 ~ 1 之间的随机数

(2)接近食物：探索阶段，黏菌分离部分个体探索其他领域，尝试寻找更高质量的食物源。更新公式为

$$X(t+1) = Rand(U_B - L_B) + L_B \quad (Rand < z < 0.03) \tag{7}$$

(3)开发阶段：当黏菌发现食物时，会发生收缩，其收缩模式可描述为

$$X(t+1) = \begin{cases} X_b(t) + v_b(WX_A(t) - X_B(t)) & (r < p) \\ v_c X(t) & (r \geqslant p) \end{cases} \tag{8}$$

式中 v_b——$[-a, a]$ 内的随机数

v_c——$[-1, 1]$ 内振荡并最终趋于零的参数

$X_b(t)$——当前适应度最优个体位置

$X(t)$——当前黏菌个体位置

$X_A(t)$、$X_B(t)$——2 个随机个体位置

W——黏菌权重系数

更新黏菌的权重系数 W 和参数 a、b，即

$$p = \tan|S(i) - D_F| \quad (i = 1, 2, \cdots, N) \tag{9}$$

$$a = \operatorname{arctanh}\left(-\frac{t}{t_{\max}} + 1\right) \tag{10}$$

$$W = \begin{cases} 1 + Rand\ln\left(\dfrac{b_F - S(i)}{b_F - w_F} + 1\right) & \left(i < \dfrac{N}{2}\right) \\ 1 - Rand\ln\left(\dfrac{b_F - S(i)}{b_F - w_F} + 1\right) & \left(i \geqslant \dfrac{N}{2}\right) \end{cases} \tag{11}$$

式中 N——种群数量

$S(i)$——第 i 个黏菌个体适应度

D_F——当前取得最优适应度

b_F——在当前迭代获得的最佳适应度

w_F——在当前迭代获得的最差适应度

根据决定系数 R^2 和均方误差 MSE 建立适应度函数，R^2 表示模型的可解释能力，MSE 表示模型的回归精度，函数公式为

$$F_{fit} = \min[MSE(1 - R^2)] \tag{12}$$

黏菌算法通过对树数量和树深度的组合进行搜索，计算出最小适应度，实现绝对系数和均方误差组合的最优解，以此得出树数量和树深度的参数最优组合。

2.6.3 最终体质量预测值

将黏菌优化随机森林回归模型 SMA - RFR 得出的预测误差值与初步体质量预测值相加，得到最终体质量预测值，如图 14 所示。

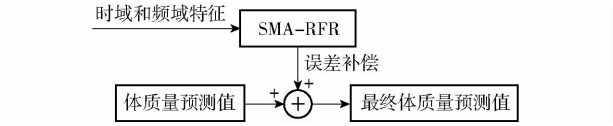

图 14 最终体质量预测值

Fig. 14 Predicted final body weight

3 结果与讨论

3.1 窗函数优化

对信号加以窗函数处理后，进行 FFT 变换。α 决定旁瓣抑制比强度大小，β 决定频谱平滑度[19]。当 $\alpha = 1$、$\beta = 0$ 时，则完全侧重于旁瓣抑制；当 $\alpha = 0$、$\beta = 1$ 时，则完全侧重于频谱平滑度。

为兼顾旁瓣抑制比和频谱平滑度的平衡，根据待处理信号实际情况，经过不断的参数调整并进行对比，最终设置 α 和 β 为 0.2 和 0.8，在保证旁瓣抑制较好情况下，提升频谱平滑度。

旁瓣抑制比计算式为

$$S_{SR} = 20\lg\left(\frac{P_m}{P_s}\right) \tag{13}$$

部分信号结果表现如表 3 所示。由表 3 可以看出，优化窗函数的抑制泄漏能力较强，旁瓣泄漏比为 14.17 dB，适用于高频噪声较少的抑制泄漏，且频谱

表 3　窗函数对比

Tab. 3　Window function comparison

窗类型	旁瓣抑制比/dB	平滑度方差
自适应窗	14. 17	0. 24
布莱克曼窗	4. 49	0. 18
矩形窗	40. 34	0. 31
汉明窗	7. 41	0. 21
布莱克曼-哈里斯窗	3. 34	0. 17
Nuttall 窗	3. 43	0. 17

平滑度为 0. 24，实现了旁瓣抑制和频谱平滑度的平衡。

3. 2　评价指标

针对牛场对于牛只体质量精度的需求，选用准确率（ACC）、查准率（PREC）、召回率（REC）和 F1 分数作为分类评价指标。选用均方根误差（RMSE）、平均绝对误差（MAE）和平均绝对百分比误差（MAPE）作为所使用方法得到的最终体质量预测值评价指标。

3. 3　VMD 算法预测结果

通过 VMD 算法得到初步体质量预测值，低活跃状态体质量预测如图 15a 所示，RMSE、MAE 和 MAPE 分别为 11. 78 kg、8. 63 kg 和 1. 67%，与其他模态分解算法对比如表 4 所示。

高活跃状态初步体质量预测值结果如图 15b 所示，RMSE、MAE 和 MAPE 分别为 16. 36 kg、10. 37 kg 和 2. 03%，与其他模态分解算法相比（表 5），其表现更优。

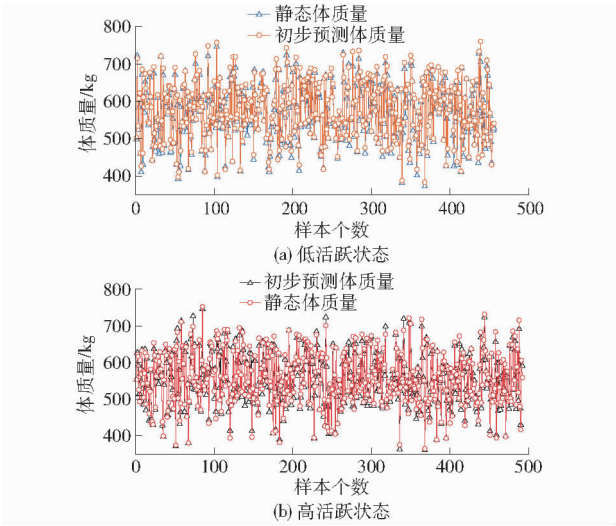

图 15　静态称量参数值与初步体质量预测值对比

Fig. 15　Comparison of static weighing parameter values

表 4　低活跃初步体质量预测对比

Tab. 4　Weighing results under low activity

方法	RMSE/kg	MAE/kg	MAPE/%
VMD	11. 78	8. 63	1. 67
EEMD	17. 99	11. 09	2. 17
EMD	16. 45	11. 97	2. 31

表 5　高活跃体质量预测对比

Tab. 5　Weighing results in high active state

方法	RMSE/kg	MAE/kg	MAPE/%
VMD	16. 36	10. 37	2. 03
EEMD	16. 65	14. 06	2. 74
EMD	16. 70	14. 09	2. 75

3. 4　特征提取与降维

3. 4. 1　运动分类模型

对时、频域特征与运动状态标签进行讨论，以时频域特征与运动分类标签进行相关性分析，判别并提取与运动状态标签相关系数绝对值不小于 0. 2 的特征，结果如图 16 所示。

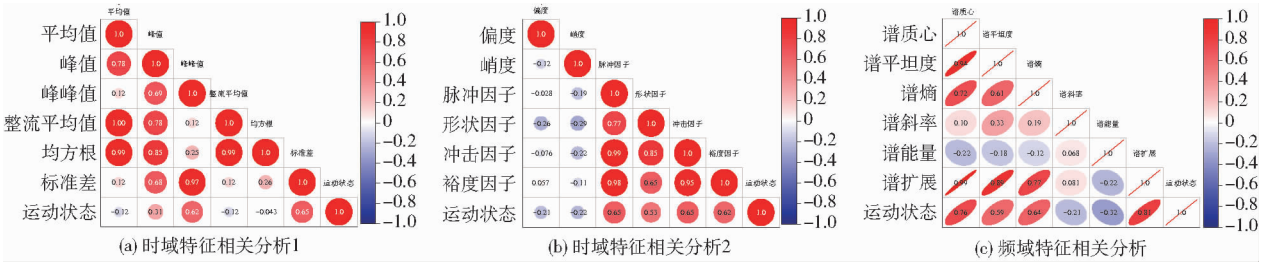

图 16　时频域特征相关性热力图

Fig. 16　Time-frequency domain feature correlation heat maps

由图 16 可得，共 15 个时频域特征与运动标签 y 的相关系数绝对值皆不小于 0. 2，但多个如峰峰值与标准差等特征为强相关线性关系，因此需要进行 PCA 主成分降维。

对时频域特征进行标准化后，进行 PCA 主成分降维。经计算，当主成分数量为 5 时，较为满足要求，信息占比为 89. 3%，可以代表相关特征的大部分信息。因此选择 PCA 主成分数为 5 对时域与频域特征进行降维。

3. 4. 2　误差补偿模型

为补偿 VMD 算法得出的初步体质量预测值与静态体质量参数的误差，建立黏菌优化算法优化随机森林回归 SMA－RFR 误差预测模型以提高精度。

首先建立 2 类运动状态下的时频域特征与误差的数据集。其次对 RFR 模型进行训练并利用 SMA 黏菌优化算法对 RFR 模型的 2 个超参数即树数量和最大深度进行优化。然后,利用训练好的优化模型,对测试数据进行误差预测。最后将最终体质量预测值和静态体质量参数的误差与参考误差进行对比,并计算出最终体质量预测值的 3 个评价指标即 RMSE、MAE 和 MAPE,以验证模型可行性。

(1)低活跃状态误差预测模型

对低活跃状态下的数据集进行相关性分析,并提取与参考误差相关系数绝对值 $|r|$ 不小于 0.2 的特征参数,相关性分析结果如图 17 所示。

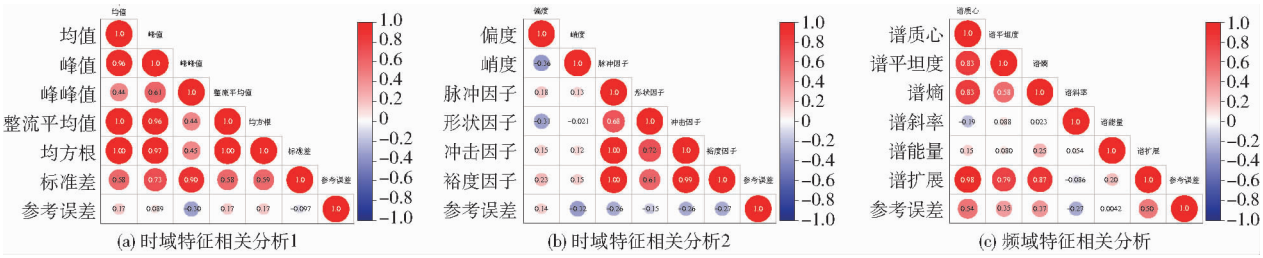

(a) 时域特征相关分析1 (b) 时域特征相关分析2 (c) 频域特征相关分析

图 17 低活跃误差相关热力图

Fig. 17 Correlation heat maps of low active error data sets

其中时域有纲量特征中选用峰峰值,时域无纲量特征中选用峭度、峰值因子、脉冲因子和间隙因子,频域特征中选用谱质心、谱平坦度、谱熵、谱斜率和谱扩展共 10 维特征。

特征提取并标准化后,进行 PCA 降维。经计算,当 PCA 主成分数量为 5 时,较为满足要求,信息累计占比为 92.14%,可以表示大部分信息,故选择主成分数为 5。

(2)高活跃状态误差预测模型

对高活跃状态误差数据集进行相关性分析并进行降维提取,相关性结果如图 18 所示。

由图 18 可知,高活跃误差数据与低误差数据集

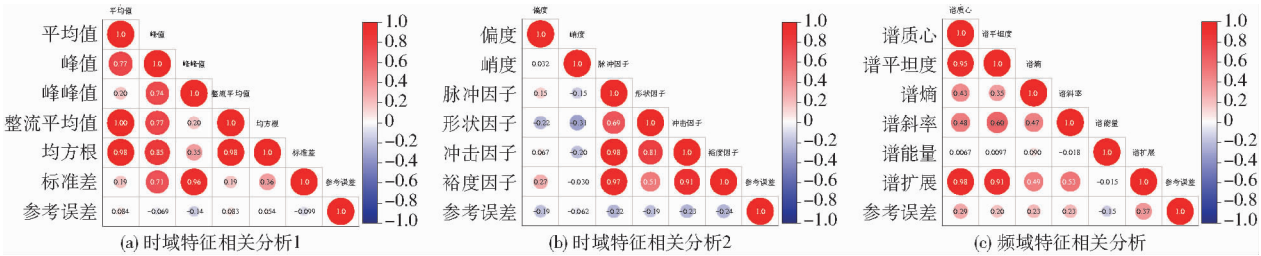

(a) 时域特征相关分析1 (b) 时域特征相关分析2 (c) 频域特征相关分析

图 18 高活跃误差相关热力图

Fig. 18 Correlation heat maps of low active error data sets

提取的相关特征并不相同,分别为峰值因子、冲击因子、间隙因子、谱质心、谱平坦度、谱熵、谱斜率、谱扩展共 8 维特征。

特征提取并标准化后,以 PCA 主成分法进行降维。经计算,当 PCA 主成分数量为 2 时,信息累计占比为 82.99%,表示信息较少。当 PCA 主成分数量为 3 时,信息累计占比为 96.90%,可以表示大部分信息,综合考虑,选择主成分数为 3。

3.5 模型预测结果

3.5.1 运动分类模型结果

利用 PCA 主成分分析法进行特征降维完成后,以此数据集对 SVM 模型进行训练,超参数为默认参数,核函数选择为高斯核,结果如图 19 所示,从图 19 可以看出,本模型分类效果较为良好,可有效区分 2 类运动状态。

运动状态分类模型准确率、查准率、召回率和 F1 分数分别为 98.42%、98.04%、99.01% 和 98.52%,拥有较好的分类能力,本文模型与其他分类模型等进行对比,结果如表 6 所示,由表 6 可得,相较于其他分类模型,本文模型拥有较高的鲁棒性和准确率。

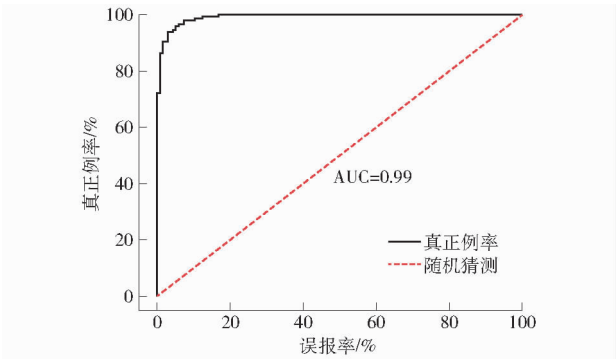

图 19 ROC 曲线

Fig. 19 ROC curves

3.5.2 低活跃状态误差预测模型结果

对 RFR 模型进行训练,并利用 SMA 模型进行

表 6　分类预测结果对比

Tab. 6　Comparison of classification prediction results

%

方法	准确率	查准率	召回率	F1 分数
SVM	98.42	98.04	99.01	98.52
RF	97.89	98.99	97.03	98.00
LR	95.26	95.37	95.26	95.25
DT	96.84	98.97	95.05	96.97

优化，适应度公式计算后，得到最优超参数即树数量和树深度分别为 600 和 13，RMSE、MAE 和 MAPE 分别为 4.03 kg、2.69 kg 和 0.53%，较之初步预测结果分别提升 8.25 kg、4.92 kg 和 1.17%。由图 20 可以看出，经误差补偿后，大部分误差都在 10 kg 以下，拥有较好的泛化能力和鲁棒性。SMA－RF 模型与其他模型对比结果如表 7 所示。

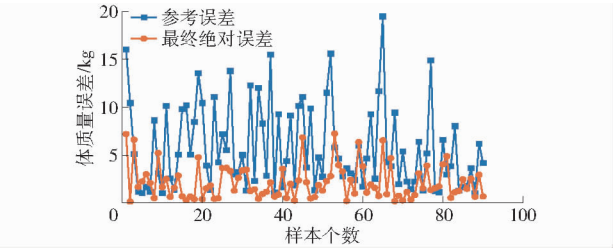

图 20　低活跃误差对比图

Fig. 20　Error comparison diagram at low activity

表 7　低活跃误差对比

Tab. 7　Low active error comparison

模型	RMSE/kg	MAE/kg	MAPE/%
SMA－RF	4.03	2.69	0.53
SVR	7.68	5.44	1.07
GBR	4.52	3.35	0.66
LR	7.64	5.47	1.07

3.5.3　高活跃状态误差预测模型

经训练优化后，本文模型最优超参数即树数量和树深度分别为 400 和 27，RMSE、MAE 和 MAPE 分别为 8.96 kg、4.40 kg 和 0.87%，较之初步预测结果分别提升 7.50 kg、7.58 kg 和 1.44%，误差补偿前后误差对比如图 21 所示。SMA－RF 模型与其他模型对比结果如表 8 所示，本文模型较其他模型表现更优。

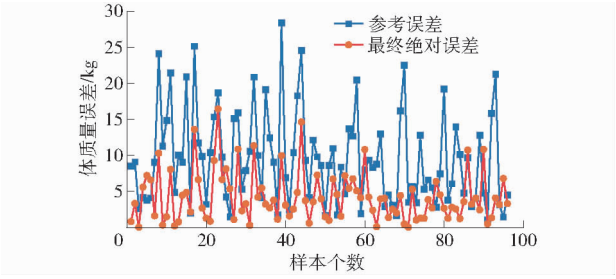

图 21　高活跃误差对比

Fig. 21　Error comparison diagram at high activity

表 8　高活跃误差对比

Tab. 8　High active error comparison

模型	RMSE/kg	MAE/kg	MAPE/%
SMA－RF	8.96	4.40	0.87
SVR	15.27	9.45	1.87
GBR	9.85	5.94	1.18
LR	15.12	9.50	1.88

4　结论

（1）VMD 变分模态分解算法针对具备非平稳性的牛只动态称量信号，能够有效地将有效信号分解为多个相对平稳的 IMF 分量，分离牛只动态称量信号的趋势分量和噪声，从有效信号中获取信号趋势分量，得出初步体质量预测值。

（2）窗函数结合麻雀搜索算法进行自适应权值优化后，可得到较为适合当前信号的自适应窗函数，有效降低旁瓣泄漏的同时保证了一定频谱平滑度，从而能够进行较为可靠的频域分析。

（3）信号时域与频域的变化可较为可靠地表现牛只当时运动状态。以时频域特征建立牛只运动状态分类模型，其准确率为 98.4%，证明了牛只动态称量信号的时域和频域在一定程度上反馈了牛只当时运动状态。

（4）经信号模态分解得到的初步体质量预测值在低、高活跃状态误差补偿模型处理后，其修正的 RMSE、MAE 和 MAPE 分别为 4.03 kg、2.69 kg、0.53% 和 8.96 kg、4.40 kg、0.87%，可为实际养殖场景中的智能化体质量监测提供参考，对推进牛只精细化养殖的发展具有一定意义。

参　考　文　献

[1]　陈育忠. 奶牛精细养殖综合技术分析[J]. 畜禽业，2021，32(6)：43－44.

[2]　刘云玲，魏艳辉，徐小伟，等. 奶牛健康监测设备与技术研究及应用进展综述[J]. 农业机械学报，2023，54(增刊 1)：303－314.
LIU Yunling, WEI Yanhui, XU Xiaowei, et al. Review of research on dairy cow health monitoring equipment, technology and application[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(Supp. 1): 303－314. (in Chinese)

[3]　魏书青，韩博，李艳华，等. 奶牛生长与健康性状遗传规律研究进展[J]. 中国畜牧杂志，2024，60(9)：21－27.
WEI Shuqing, HAN Bo, LI Yanhua, et al. Research progress on renetic regularity of growth and health traits of dairy cows[J]. Chinese Journal of Animal Science, 2024, 60(9): 21－27. (in Chinese)

[4] GIRI A, BHARTI V K, KALIA S, et al. A review on water quality and dairy cattle health: a special emphasis on high-altitude region[J]. Applied Water Science, 2020, 10(3): 1 - 16.
[5] SALMAN M, STENERODEN K. Important zoonotic diseases of cattle and their prevention measures[M]//Zoonoses: infections affecting humans and animals. Cham: Springer International Publishing, 2022: 1 - 22.
[6] ODUBOTE I K. Characterization of production systems and management practices of the cattle population in Zambia[J]. Tropical Animal Health and Production, 2022, 54(4): 216.
[7] SEGERKVIST K A, HÖGLUND J, ÖSTERLUND H, et al. Automatic weighing as an animal health monitoring tool on pasture [J]. Livestock Science, 2020, 240: 104157.
[8] HERRERO M, MASON-D'CROZ D, THORNTON P K, et al. Livestock and sustainable food systems: status, trends, and priority actions[J]. Science and Innovations for Food Systems Transformation, 2023: 375 - 399.
[9] DICKINSONR A, MORTON J M, BEGGS D S, et al. An automated walk-over weighing system as a tool for measuring liveweight change in lactating dairy cows[J]. Dairy Sci., 2013, 96: 4477 - 4486.
[10] GONZÁLEZ-GARCÍA E, ALHAMADA M, PRADEL J, et al. A mobile and automated walk-over-weighing system for a close and remote monitoring of liveweight in sheep[J]. Computers and Electronics in Agriculture, 2018, 153: 226 - 238.
[11] 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)
[12] 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(18): 5363.
[13] 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.
[14] HE Z, LI Q, CHU M, et al. Dynamic weighing algorithm for dairy cows based on time domain features and error compensation [J]. Computers and Electronics in Agriculture, 2023, 212: 108077.
[15] 张付瑗,陈学华,罗鑫,等.改进的窗参数优化 S 变换及其在河道检测中的应用[J].石油地球物理勘探,2021,56(4): 809 - 814.
[16] 蒋易宇,王硕,张丽娜,等.基于水培生菜力学特征的成熟度分类方法[J].农业工程学报,2023,39(1):179 - 187.
JIANG Yiyu, WANG Shuo, ZHANG Li'na, et al. Maturity classification using mechanical characteristics of hydroponic lettuce [J]. Transactions of the CSAE, 2023, 39(1): 179 - 187. (in Chinese)
[17] 林建新,廖庆喜,张青松,等.油菜机械直播铲锹式种床整备机振动特性分析与结构改进[J].农业工程学报,2023, 39(19):39 - 48.
LIN Jianxin, LIAO Qingxi, ZHANG Qingsong, et al. Vibration characteristics analysis and structural improvement of the shovel type seedbed preparation machine suitable for rapeseed mechanical direct seeding[J]. Transactions of the CSAE, 2023, 39(19): 39 - 48. (in Chinese)
[18] 尉鹏亮,周昱宏,王若蓁,等.基于超宽带雷达回波短时傅里叶变换的土壤含水率检测[J].农业机械学报,2024,55(8): 352 - 360.
WEI Pengliang, ZHOU Yuhong, WANG Ruozhen, et al. Soil volumetric moisture content detection based on short-time Fourier transform of ultra-wide band radar echo[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(8): 352 - 360. (in Chinese)
[19] 陈至豪,王立德,王冲,等.基于组合余弦优化窗四谱线插值 FFT 的电力谐波分析方法[J].电网技术,2020,44(3):1105 - 1113.
CHEN Zhihao, WANG Lide, WANG Chong, et al. Anapproach for electrical harmonic analysis based on optimized composite cosine window four-spectrum-line interpolation FFT[J]. Power System Technology, 2020, 44(3): 1105 - 1113. (in Chinese)
[20] 尹柏强,陈奇彬,李兵,等.基于改进 Kaiser 窗快速 S 变换和 LightGBM 的电能质量扰动识别与分类新方法[J].中国电机工程学报,2021,41(24):8372 - 8384.
YIN Baiqiang, CHEN Qibin, LI Bing, et al. A new method for identification and classification of power quality disturbance based on modified Kaiser window fast S-transform and LightGBM[J]. Proceedings of the CSEE, 2021,41(24):8372 - 8384. (in Chinese)
[21] LONG J, TAKAHATA H, UMETSU K, et al. A livestock walk-through scale system[J]. Nogyo Shisetsu, 1991, 21:175 - 182.
[22] ZOSSO D, DRAGOMIRETSKIY K. Variational mode decomposition[J]. IEEE Transactions on Signal Processing: A Publication of the IEEE Signal Processing Society, 2014,62(3):531 - 544.
[23] CIVERA M, SURACE C. A comparative analysis of signal decomposition techniques for structural health monitoring on an experimental benchmark[J]. Sensors, 2021, 21: 1825.
[24] 贺志将,李前,王彦超,等.基于 VMD - LSTM 的奶牛动态称量算法[J].农业机械学报,2022,53(增刊 2):234 - 240.
HE Zhijiang, LI Qian, WANG Yanchao, et al. Cow dynamic weighing algorithm based on VMD - LSTM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(Supp. 2): 234 - 240. (in Chinese)

(下转第 354 页)

60(10): 795 - 803.
SONG Jia, SHI Ruoling, GUO Xiaohong, et al. KELM based diagnostics for air vehicle faults[J]. Journal of Tsinghua University (Science and Technology), 2020, 60(10): 795 - 803. (in Chinese)
[23] GILL M K, ASEFA T, KEMBLOWSKI M W, et al. Soil moisture prediction using support vector machines[J]. Journal of the American Water Resources Association, 2006, 42(4): 1033 - 1046.
[24] HONG Z, KALBARCZYK Z, IYER R K. A data-driven approach to soil moisture collection and prediction[C]// IEEE International Conference on Smart Computing (SMARTCOMP). IEEE, 2016: 1 - 6.
[25] 赵文博, 刘洪杰, 田雪婷, 等. 基于 UCMap 的城市环境气候空间格局分析——以广州市为例[J]. 地理科学进展, 2019, 38(3): 452 - 464.
ZHAO Wenbo, LIU Hongjie, TIAN Xueting, et al. Environmental climate spatial pattern of Guangzhou City based on urban climatic map[J]. Progress in Geography, 2019, 38(3): 452 - 464. (in Chinese)
[26] 张西良,谢飞洋,盛庆元,等. 基于电导率对相对介电常数补偿的土壤含水率电容传感器标定方法[J]. 农业机械学报, 2024,55(8):344 - 351.
ZHANG Xiliang, XIE Feiyang, SHENG Qingyuan, et al. Calibration method of soil moisture capacitance sensor based on compensation of electrical conductivity to relative permittivity[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(8): 344 - 351. (in Chinese)
[27] CHAAMWE N, LIU W, JIANG H. Wave propagation communication models for wireless underground sensor networks[C]// IEEE 12th International Conference on Communication Technology. IEEE, 2010: 9 - 12.
[28] LI W Z, ZHANG G, LI Z. Simulation of channel model for WUSN based on NS2[J]. Computer and Modernization, 2016(1): 121.
[29] EBERHART R, KENNEDY J. Particle swarm optimization[C]// Proceedings of the IEEE International Conference on Neural Networks. IEEE, 1995: 1942 - 1948.
[30] CORTES C, VAPNIK V. Support-vector networks[J]. Machine Learning, 1995, 20(3): 273 - 297.

(上接第 338 页)

[25] XUE J, SHEN B. A novel swarm intelligence optimization approach: sparrow search algorithm[J]. Systems Science & Control Engineering, 2020,8(1): 22 - 34.
[26] 孟志军,刘淮玉,安晓飞,等. 基于 SPA - SSA - BP 的小麦秸秆含水率检测模型[J]. 农业机械学报,2022,53(2):231 - 238,245.
MENG Zhijun, LIU Huaiyu, AN Xiaofei, et al. Prediction model of wheat straw moisture content based on SPA - SSA - BP[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(2): 231 - 238,245. (in Chinese)
[27] 祖林禄,柳平增,赵妍平,等. 基于 SSA - LSTM 的日光温室环境预测模型研究[J]. 农业机械学报,2023,54(2):351 - 358.
ZU Linlu, LIU Pingzeng, ZHAO Yanping, et al. Solar greenhouse environment prediction model based on SSA - LSTM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(2): 351 - 358. (in Chinese)
[28] 麻芳兰,罗一鸣,李嘉诚,等. 甘蔗收获机根部切割系统负载压力预测模型研究[J]. 农业机械学报,2024,55(12):81 - 89.
MA Fanglan, LUO Yiming, LI Jiacheng, et al. Load pressure prediction model for sugarcane harvester base-cutting system[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024,55(12):81 - 89. (in Chinese)
[29] 刘潭,李子默,冯帅,等. 基于 LMPSO - SVM 的高光谱水稻稻瘟病害分级检测[J]. 农业机械学报,2023,54(11):208 - 216,235.
LIU Tan, LI Zimo, FENG Shuai, et al. Classification detection of hyperspectral rice blat disease based on LMPSO - SVM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 208 - 216,235. (in Chinese)
[30] 解毅,王佳楠,刘钰. 基于 Sentinel - 1/2 数据特征优选的冬小麦种植区识别方法研究[J]. 农业机械学报,2024,55(2): 231 - 241.
XIE Yi, WANG Jia'nan, LIU Yu, et al. Research on winter wheat planting area identification method based on Sentinel - 1/2 data feature optimization[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(2): 231 - 241. (in Chinese)
[31] LI S, CHEN H, WANG M, et al. Slime mould algorithm: a new method for stochastic optimization[J]. Future Generation Computer Systems, 2020, 111: 300 - 323.