

基于 IBWO – Stacking 的猪舍环境预测模型优化

马铁民¹ 刘雨霆¹ 张天宇¹ 谢秋菊² 刘金明¹ 王 雪¹

(1. 黑龙江八一农垦大学信息与电气工程学院, 大庆 163319; 2. 东北农业大学电气与信息学院, 哈尔滨 150030)

摘要: 稳定的温湿度环境对于妊娠母猪的健康和生产性能至关重要。为解决传统预测模型在妊娠猪舍多因子耦合场景中适应性不足的问题,提出了基于改进白鲸优化算法(Improved beluga whale optimization, IBWO)和 Stacking 集成学习的猪舍环境预测模型 IBWO – Stacking。在原白鲸优化算法的基础上引入 Logistic 混沌映射、自适应变量的调整以及 Pattern Search 提高 BWO 的寻优能力,实现了对猪舍温湿度预测模型超参数的精准优化,预测猪舍环境中的温湿度。实验结果显示,IBWO – Stacking 模型预测相对湿度的平均绝对误差、均方误差和均方根误差分别为 1.123 7%、3.243 4%² 和 1.800 9%,预测温度时 3 项误差指标分别为 0.210 4℃、1.216 5℃² 和 1.102 9℃;与 BWO – Stacking 模型对比,预测猪舍相对湿度和温度的模型决定系数分别提高了约 0.55% 和 1.32%,平均绝对误差降低约 7.35% 和 6.36%、均方误差降低约 17.23% 和 30.92%,均方根误差降低约 9.02% 和 16.9%,验证了 IBWO – Stacking 模型具有较好的预测性能和鲁棒性,为妊娠猪舍的智能化环境调控提供决策支持,助力减少环境应激对母猪繁殖性能的负面影响。

关键词: 妊娠猪舍; 环境预测; 白鲸优化算法; Logistic 混沌映射; 自适应变量调整; 集成学习

中图分类号: S8 – 01 **文献标识码:** A **文章编号:** 1000-1298(2026)15-0365-09

OSID:



Optimization of IBWO – Stacking-based Environmental Prediction Model for Swine Housing

Ma Tiemin¹ Liu Yuting¹ Zhang Tianyu¹ Xie Qiuju² Liu Jinming¹ Wang Xue¹

(1. College of Information Engineering, Heilongjiang Bayi Agricultural University, Daqing 163319, China

2. College of Electrical and Information, Northeast Agricultural University, Harbin 150030, China)

Abstract: A stable temperature and humidity environment is crucial for the health and production performance of pregnant sows. To address the inadequacy in adaptability of traditional prediction models under multi-factor coupling scenarios in gestation pig houses, an IBWO – Stacking prediction model was proposed based on improved beluga whale optimization (IBWO) and Stacking ensemble learning. The proposed method enhanced the optimization capability of the original beluga whale optimization (BWO) algorithm through three key improvements: Logistic chaotic mapping initialization, adaptive variable adjustment, and pattern search integration. These enhancements enabled effective hyperparameter optimization of base learners in the Stacking ensemble framework, the model predicted environmental temperature and humidity. Experimental results demonstrated that the IBWO – Stacking model achieved superior performance metrics: for humidity prediction, the mean absolute error (MAE), mean squared error (MSE), and root mean squared error (RMSE) were 1.123 7%, 3.243 4%² and 1.800 9% respectively. For temperature prediction, these metrics reached 0.210 4℃, 1.216 5℃² and 1.102 9℃. Comparative analysis with the baseline BWO-stacking model showed significant improvements: the coefficient of determination (R^2) was increased by approximately 0.55% for humidity and 1.32% for temperature prediction. Concurrently, MAE was decreased by 7.35% and 6.36%, MSE was reduced by 17.23% and 30.92%, while RMSE declined by 9.02% and 16.9% for humidity and temperature predictions respectively. These results validated the enhanced predictive capability and robustness of the IBWO – Stacking model, providing decision-making support for intelligent environmental control in gestation pig houses, thereby mitigating the negative impacts of environmental stress on the reproductive performance of sows.

Key words: gestation pig houses; environmental prediction; beluga whale optimization; Logistic chaotic mapping; adaptive variable adjustment; ensemble learning

0 引言

随着社会对肉类需求的持续增长,生猪养殖业正逐步朝着规模化、现代化和智能化的方向发展^[1]。研究表明,猪舍的温湿度对猪只的生理反应有很大影响^[2]。高温高湿对畜禽的繁殖效果、呼吸系统健康、水分摄入与排泄以及采食量均产生负面影响;妊娠期热应激直接影响仔猪出生后胴体成分,肌纤维数量、长度和采食量^[3-5]。通过对猪舍温湿度等关键指标的综合分析,可以准确地评估猪舍环境质量,促进现代畜牧业的可持续发展^[6]。

近年来,以机器学习为代表的人工智能技术发展迅速,在农业领域展现出巨大的应用潜力^[7-9]。但是,现有研究多采用单一预测方法,难以克服单一模型适应性不足的问题。研究表明,群智能优化算法可以进一步提高畜舍环境预测精度。群智能优化算法通常能够更快速地找到近似最优解,使模型具有更好的鲁棒性和适应性。因此,Zhang 等^[10]提出基于多策略改进麻雀搜索算法(ISSA)优化 LSSVM 的猪舍温度预测模型,该模型温度预测效果较好且能提高预测精度。谢秋菊等^[11]提出有害气体浓度时序数据预测模型 ISSA-GRU-ARIMA,模型具有较高的预测精度,可为猪舍有害气体浓度精准控制提供科学依据。Kim 等^[12]提出利用 LSTM 模型开发预测舍内空气温度缺失数据模型,对比预测与实测气温数据,预测误差率在 3.5% 以内,较为准确。

在众多群智能优化算法中,白鲸优化算法(Beluga whale optimization, BWO)作为一种新兴的高效方法,由 Zhong 等^[13]2022 年提出,相较于其他群智能优化算法,具有高效收敛性等优点,在求解单峰、多峰优化问题时表现出显著优势,但同时也存在勘探与开发失衡、全局勘探乏力、易陷入局部极值的问题,从而导致模型预测精度偏低等状况^[14-15]。Yuan 等^[16]使用垂直交叉算子、水母搜索算法与 BWO 融合,提高了算法性能,但寻优过程复杂,算法复杂度较高;陈奕君等^[17]针对 BWO 易陷入局部最优和丢失次优解的问题,提出通过更新精英群体机制和反向学习策略来解决。

Stacking^[18]作为集成算法的经典策略,通过多样的基学习器和元学习器,整合多模型的解析能力,以弥补单一模型不足。He 等^[19]基于“双碳”目标提出一种碳排放 GA-Stacking 预测方法,该组合模型可以发挥单一模型的优势提升碳排放预测的准确性。刘潭等^[20]提出了一种基于多模型融合策略的温室番茄光合速率预测方法,证明了融合模型比单一模型具备更优的性能。

因此,为了提升模型的稳定性和精确性,本文提出基于白鲸优化改进算法和 Stacking 集成学习框架相结合的猪舍环境预测模型 IBWO-Stacking。首先,采用混沌映射、自适应变量调整以及引入模式搜索算法等策略改进白鲸优化算法。其次,利用 Stacking 集成学习框架构建多模型的基学习器,再采用白鲸优化改进算法分别对基学习器中的模型进行超参数寻优,经过基学习器训练得到预测结果后输入到元学习器,预测未来猪舍环境中的温湿度,以为猪舍养殖环境调控提供可参考方法。

1 材料与方法

1.1 数据来源

数据来源于黑龙江省哈尔滨市尚志市亚布力养殖基地(44.78°N,128.47°E)的妊娠母猪舍,地面是水泥漏粪地板。猪舍尺寸 19.5 m×10.5 m×2.4 m,限位栏尺寸 2.2 m×0.65 m×1 m。猪舍内安装了以 STM32F103VET6 芯片为核心、基于物联网系统的自动环境监测及控制器,设有 3 个环境监测点覆盖母猪活动核心区域,每个监测点有温湿度、NH₃ 质量浓度、CO₂ 质量浓度、CH₄ 质量浓度、H₂S 质量浓度传感器,传感器距地面 1.6 m,以 3 个监测点数据平均值作为舍内温湿度以及 NH₃、CO₂、CH₄、H₂S 质量浓度取值。舍外有 1 个温湿度传感器实时监测舍外温湿度。环境数据采样间隔 1 min,采集到的环境数据上传至后台以便存储。猪舍现场和平面结构分别如图 1、2 所示。



图 1 猪舍现场图
Fig. 1 Pig house site map




图 2 猪舍平面结构图
Fig. 2 Plan structure diagram of pigsty

1.2 相关算法

1.2.1 白鲸优化算法

白鲸优化算法采用随机数生成器初始化种群位置,其中包括平衡因子 B_f 和鲸鱼鲸落概率 W_f 两个自适应变量^[21]。

实验研究表明,简单随机的初始化方式可能导致初始种群成员过于集中或相似,缺乏多样性,不利于算法在搜索初期快速覆盖解空间,与文献[22]得到的结论一致。线性递减的自适应变量策略可能导致在搜索后期趋于保守,在应对猪舍环境因子的突变如突然降温、通风变化时易导致模型响应滞后或过度,从而陷入局部最优。难以灵活地求解最优解的分布,成为解决复杂实际问题中平衡探索与利用问题的障碍,尤其在猪舍环境预测中,温湿度与 NH_3/CO_2 浓度存在强耦合关系,传统算法难以捕捉多因子动态交互特征。因此,改进初始化种群策略和自适应变量的计算方式,引入更加灵活的非线性调整机制,是增强种群多样性,提升算法搜索效率和全局寻优精度的有效策略。

1.2.2 Stacking 集成学习方法

Stacking 是两层结构的集成学习算法,核心思想是通过堆叠多个层次的学习器,实现模型性能的提升和优异的泛化能力^[23]。该方法在 Kaggle 等各类数据科学竞赛中被证明能够提升预测模型的准确性,在处理高维数据集时表现得尤为突出。堆叠集成已成为地表覆盖分类、植被光合作用效能评估及农作物产量预估等领域数据分析中的关键技术^[24-26]。Stacking 通过基学习器差异化建模,可全面表征猪舍环境系统的复杂性。

1.3 IBWO-Stacking 环境预测模型

1.3.1 基于多策略改进的白鲸优化算法 IBWO

1.3.1.1 Logistic 映射促进种群多样性

为了改善白鲸优化算法种群初始化成员过于集中或相似的问题,初始化种群位置时,针对妊娠猪舍内因栏位布局、通风死角、猪群分布不均等因素造成的温湿度空间分布异质性,采用 Logistic 混沌映射^[27]生成初始种群,确保算法勘探能力匹配实际环境梯度。

Logistic 映射公式为

$$x_{n+1} = rx_n(1 - x_n) \tag{1}$$

式中 x_n, x_{n+1} —— $n, n+1$ 时刻取值

r ——Logistic 混沌映射的控制参数

Logistic 映射具有良好的遍历性和伪随机性,即使初始值和参数相同,产生的混沌序列也会在解空间内均匀分布,且相邻个体间存在较大的差异^[28]。确保初始种群具有足够的多样性,能更全面地覆盖潜在

的解空间,避免因初始点过于集中而错过表征妊娠猪舍不同区域环境变化规律的最优超参数组合。

1.3.1.2 自适应变量调整策略的改进

白鲸算法中自适应变量采用线性递减策略时,可能在搜索后期出现趋于保守的问题,分别对算法中自适应变量 B_f 和 W_f 引入周期性波动与非线性衰减机制,以增强算法的全局探索与局部优化能力。并在参数计算中引入正态随机分布,即每次迭代时,鲸落概率和平衡因子会受到符合正态分布范围内的随机扰动。这种非线性和随机性的引入,使算法能更灵活地响应猪舍环境中常见的、非平稳的动态变化,如昼夜温差、开关门通风、饲喂活动引起的局部温湿度波动,避免模型参数更新僵化,提升预测模型在复杂多变实际场景下的鲁棒性和适应性。

(1) 平衡因子的改进

平衡因子 B_f 决定了算法在每次迭代中进行勘探和开发的比例。通过加入余弦函数增加周期性变化,使得平衡因子随迭代周期性波动,促使算法在不同阶段交替强化探索与开发策略,增加搜索过程中的随机性和多样性。尤其当遭遇局部最优解时,能够适时调整方向,以探索更广阔解空间。改进后的平衡因子计算公式为

$$B_f = \left| \cos \left(\pi \frac{T}{i_t} \right) \right| \tag{2}$$

式中 T ——迭代次数 i_t ——最大迭代次数

(2) 鲸落概率的非线性调整

为了增强算法在不同迭代阶段的适应性,增加鲸落概率的非线性调整策略,使其随迭代次数 T 以平方根的形式减小,降低鲸落概率的下降速度,在算法初期为全局探索提供了充足的机会,有助于覆盖更广阔的解空间并发现潜在的最优解区域。随着迭代推进,鲸落概率持续减小,在搜索后期,使算法仍然保持一定程度的探索活力,有效减少陷入局部最优而提前停止探索的风险。改进后的鲸落概率计算公式为

$$W_f = 0.1 \sqrt{1 - \left(\frac{T}{i_t} \right)^2} \tag{3}$$

1.3.1.3 基于 Pattern Search 的白鲸优化算法搜索策略改进

白鲸优化算法在搜索后期因过度探索难以在已发现的较优区域进行深度挖掘,从而错过更能精确描述猪舍温湿度变化细微特征的局部最优解。为解决此问题,在上述算法改进策略的基础上,迭代后期引入精细化的局部搜索技术 Pattern Search。在算法迭代后期,针对性地对当前全局最优解附近的解空间进行深度挖掘。

1.3.2 基于 IBWO 的集成学习模型构建

猪舍内温湿度受通风、外部气候等因素影响,猪代谢产生的 CO_2 、 NH_3 等有害气体间接影响环境且能反映通风效率,需纳入模型捕捉动态反馈。特征选择涵盖直接影响与间接影响的环境因子^[29]。

构建妊娠猪舍环境预测的 Stacking 分层集成学习模型时,基学习器通过交叉验证筛选;训练集用于构建模型,验证集量化泛化误差以选出预测误差小的优化模型。研究保留 50% 数据为测试集,剩余数据做 4 折交叉验证,以平均绝对误差为主参考,采用多种机器学习算法进行交叉验证,评估均值如图 3 所示。




图 3 交叉验证的结果比较

Fig.3 Comparison of cross validation results




图 4 IBWO-Stacking 模型图

Fig.4 IBWO-Stacking model diagram

各算法在测试函数上独立运行 30 次,适应度平均值和标准差见表 1。IBWO 在 F6、F12、F13 中均值远低于其他算法且接近 0,标准差小,解质量高、稳定性强;F14 中 BWO 与 IBWO 均值接近最优值 1,但 BWO 标准差大于 0.000 2,IBWO 仅 4.65×10^{-11} ,稳定性更优;WOA、HHO、SSA 和

根据 4 折交叉验证后的结果,选择梯度提升机 (Gradient boosting, GB)^[30]、极限梯度提升机 (eXtreme gradient boosting, XGB)^[31] 和轻量级梯度提升机 (Light gradient boosting machine, LGBM)^[32] 作为 Stacking 的基学习器;因线性回归结构简单、参数少,可抑制过拟合,故第 2 层选用 Linear Regression 作为元学习器。基于 IBWO 优化的 Stacking 集成学习模型如图 4 所示。

1.4 模型评价指标

在测试模型效果时,选择均方误差、平均绝对误差、均方根误差和决定系数作为衡量模型的评价指标。

2 结果与分析

2.1 IBWO 效果验证与对比

为验证 IBWO 优化效果,实验选取 SSA、WOA、HHO、BWO、SAO 作为对比算法,种群规模 40、迭代次数 500,采用单峰函数 F6,多峰函数 F12、F13,固定维多峰函数 F14、F20 (最优值分别为 0、0、0、1、-3.32) 测试收敛性能。

SAO 算法的适应度平均值均大于 1.4,与最优值偏差较大,表明这些算法在 F14 测试函数下的表现均不够稳定。F20 中,IBWO 均值 -3.322, BWO 均值 -3.286 4, IBWO 标准差更优、更稳定, WOA 等算法均值 -3.1 ~ -3.27、标准差 0.06 ~ 0.17,表现较差且有波动。

表 1 各算法的适应度平均值和标准差

Tab.1 Average and standard deviation of fitness of each algorithm

参数	BWO		WOA		SSA		SAO		HHO		IBWO	
	平均值	标准差	平均值	标准差	平均值	标准差	平均值	标准差	平均值	标准差	平均值	标准差
F6	1.63×10^{-14}	4.24×10^{-14}	0.123	0.090 883	1.14×10^{-8}	2.73×10^{-8}	2.53×10^{-5}	3.90×10^{-5}	8.88×10^{-5}	0.000 189	7.65×10^{-26}	2.04×10^{-25}
F12	2.81×10^{-14}	4.23×10^{-14}	0.015 744	0.023 774	1.72×10^{-9}	5.74×10^{-9}	0.017 28	0.055	3.90×10^{-6}	4.43×10^{-6}	2.27×10^{-25}	4.72×10^{-25}
F13	2.28×10^{-13}	3.63×10^{-13}	0.353 59	0.232 69	1.45×10^{-8}	3.64×10^{-8}	0.002 23	0.005 21	5.23×10^{-5}	6.55×10^{-5}	6.76×10^{-25}	2.01×10^{-24}
F14	0.998 05	0.000 275	2.539	2.999	1.687 3	1.873 4	3.158 9	3.248 3	1.492 4	1.262 6	0.998	4.65×10^{-11}
F20	-3.286 4	0.035 272	-3.216 7	0.172 33	-3.241 7	0.080 8	-3.254 6	0.059 92	-3.101	0.110 4	-3.322	2.71×10^{-12}

为进一步验证改进策略对白鲸优化算法的性能优势,通过多组测试函数的适应度收敛曲线对比不同算法优化特性,如图 5 所示。F6、F12、F13 中,WOA、HHO、SAO 收敛速度与准确性一般,SSA 初期收敛快但后期乏力;IBWO 因增强全局探索与局部

优化能力,最终解精度更接近理论最优。F14 中,IBWO 中期逼近最优后收敛平缓,BWO 中期收敛快于 IBWO,最终均贴近最优,但 IBWO 标准差小、更稳定。F20 中,SAO 前期收敛快,IBWO 后期精度更优,最终解更接近理论最小值。




图 5 不同算法在测试函数上的性能

Fig.5 Performance of different algorithms on test functions

从以上实验结果分析可以看出,IBWO 在不同测试函数下,均展现出较高的稳定性和一致性,且收敛速度优于对比算法,说明 IBWO 算法在处理参数优化问题时具有较高的准确性和效率。

2.2 IBWO 优化参数过程分析

IBWO 对基学习器进行超参数寻优的过程中,将优化算法的种群数目设定为 20,迭代次数为 50。基学习器需优化的超参数优化结果见表 2。

2.3 模型预测结果分析

实验中选取了 2020 年 8 月 6 日至 10 月 8 日期

表 2 基学习器超参数优化结果			
Tab.2 Optimization hyperparameters for base learners			
参数	LGBM	XGB	GB
learning_rate	0.291 905	0.1	0.1
num_leaves	200		
max_depth	19	10	10
n_estimators	200	352	400
subsample		0.542 54	
max_features			0.506 99

间妊娠舍的环境数据,共 2 916 条,时间跨度共计 64 d。在相同数据条件下对比分析基学习器(LGBM、

XGB、GB)、深度学习模型 (LSTM、Transformer) 以及集成模型 (Stacking、BWO - Stacking、IBWO - Stacking) 在预测妊娠舍环境湿度变化的准确性。评估指标结果如表 3 所示。

表 3 不同算法构建的模型性能

Tab.3 Evaluation of models constructed by different algorithms

模型	舍内相对湿度				舍内温度			
	R^2	平均绝对	均方	均方根	R^2	平均绝对	均方	均方根
		误差/%	误差/% ²	误差/%		误差/℃	误差/℃ ²	误差/℃
LGBM	0.949 5	1.405 6	6.477 1	2.545 0	0.669 9	0.772 8	14.111 3	3.756 5
XGB	0.922 6	1.302 5	9.930 8	3.151 3	0.583 1	0.365 3	17.820 8	4.221 4
GB	0.964 5	1.409 1	4.558 0	2.134 9	0.944 3	0.256 3	2.377 4	1.541 8
LSTM	0.903 5	2.737 5	13.166 1	3.628 5	0.935 4	0.585 1	1.682 9	1.297 2
Transformer	0.935 1	2.014 8	8.337 0	2.887 4	0.914 9	0.387 2	3.637 5	1.907 2
Stacking	0.968 0	1.306 4	4.103 1	2.025 6	0.953 6	0.253 2	1.981 8	1.407 7
BWO - Stacking	0.969 4	1.212 9	3.918 6	1.979 5	0.958 8	0.224 7	1.761 0	1.327 0
IBWO - Stacking	0.974 7	1.123 7	3.243 4	1.800 9	0.971 5	0.210 4	1.216 5	1.102 9

通过表 3 对比分析集成模型、基模型、LSTM 模型和 Transformer 模型的效果。可以看出,在温度预测中,LSTM 模型和 Transformer 模型的 R^2 值分别为 0.935 4 和 0.914 9。虽然优于 XGB 和 LGBM 单一模型方法,但是低于 GB 单模型和包括本文的集成学习方法。而在舍内相对湿度预测中两种深度学习模型的平均绝对误差分别为 2.737 5%、2.014 8%,均明显高于实验中选择的基础学习器模型和集成模型,LSTM 的 R^2 也分别低于所有基学习器 2% ~ 6%,Transformer 模型的 R^2 值虽然略高于 XGB 模型,但是分别低于 LGBM 和 GB 模型 1.5% 和 3.0%,低于集成模型 3.51%。

通过智能优化算法寻优并集成后,模型精度明显改善。本文模型与最优单模型 GB 相比,预测相对湿度时平均绝对误差、均方误差、均方根误差分别下降 20.25%、28.84%、15.65%, R^2 提升 1.06%;预测温度时,三者分别降低约 17.91%、48.83%、28.47%, R^2 提升约 2.88%。

BWO - Stacking 较 Stacking 模型,相对湿度与温度的平均绝对误差、均方误差、均方根误差均下降,表明白鲸优化可提升精度。IBWO - Stacking 较 BWO - Stacking 预测相对湿度时 R^2 提升 0.55%,平均绝对误差、均方误差、均方根误差分别降低 7.35%、17.23%、9.02%;预测温度时平均绝对误差、均方误差、均方根误差分别降低 6.36%、30.92%、16.9%, R^2 提升 1.32%。

通过模型指标的对比分析,尽管深度学习模型在某些特定场景中展现出良好性能,但在本次猪舍环境预测任务中的综合表现不及集成学习模型。本文构建的 IBWO - Stacking 模型鲁棒性相对较好,具有更小的平均误差,能够满足猪舍环境预测的模型性能要求。

为了进一步讨论本文模型的预测效果,对各模型预测相对湿度的前 200 组数据的预测值与测试集真实值进行对比,预测结果及残差对比如图 6 所示。

从图 6 可以看出,单模型预测时,结果的离散程度较大,并且预测误差的波动较为明显。LSTM 模型残差均值为 0.266%,标准差高于其他对比模型,达到了 2.389%,表明其预测结果的离散程度极高,误差波动剧烈,可能因其对猪舍环境时序数据中的依赖特征捕捉不足所致。Transformer 模型虽标准差略低,为 1.718%,接近 XGB 模型水平,但其残差均值为 -0.794%,是唯一呈现负值的模型,反映出该模型存在显著的整体低估偏差,预测值与真实值的平均偏离方向一致,在猪舍相对湿度预测中可能对数据分布的学习存在系统性偏移。

XGB 模型的标准差为 1.766%,而 LGBM 模型和 GB 模型则超过 1.8%,均高于集成框架模型,说明从预测集标准差的角度评价集成学习模型优于单个模型。但是难以通过预测结果的残差均值来分析模型结果的优劣,说明单个模型和简单的集成框架模型均难以保证预测的准确性和稳定性。

仅添加白鲸优化算法的 BWO - Stacking 模型准确性和稳定性如图 6g 所示,残差均值达 0.23%,与实际值的平均偏离程度较为突出;标准差超过 1.87%,表明其预测误差波动范围较宽。

改进后的白鲸优化算法与集成学习相结合的模型 IBWO - Stacking 准确性和稳定性如图 6h 所示,残差均值和标准差为 0.089% 和 1.568%,是所有模型中最小的,它的预测结果最为接近真实情况,不存在明显的整体高估或低估现象。预测误差的波动范围相对较窄,表明模型在数据存在一定噪声或变化的情况下,仍然能够保持较为一




图 6 不同模型预测值与真实值对比及残差图

Fig. 6 Point line graphs and residual graphs of predicted values and true values of different models

致的预测准确性,从而使预测结果具有较高的可信度,模型具有可重复性。

2.4 IBWO 改进策略的时间复杂度分析

为了说明改进策略对算法效率的影响,进一步分析白鲸算法改进前后的时间复杂度。设置种群规模 40、迭代次数 500 次,IBWO 与 BWO 算法不同测试函数的耗时结果对比如表 4 所示。可以看出,在单峰函数 F6 上,由于无需复杂的局部优化过程,IBWO 改用 Logistic 混沌映射,每生成 1 个个体需 1 次混沌迭代,平衡因子与鲸落概率的改进也是在迭代过程中仅增加三角函数求值等常数级运算,未改变复杂度阶次,在前面分析中可见 IBWO 对比 BWO 模型性能显著提升,算法效率也比 BWO 算法高。对于固定维多峰 F14、F20 函数,IBWO 耗时接近 BWO。对于多峰函数 F12 和 F13,IBWO 的耗时高于 BWO,主要是在处理具有多个局部最优解的复杂多峰问题时,IBWO 采用的 Pattern Search 局部优化机制引入了额外的计算负担;但是 Pattern Search 局部优化仅在最后 20% 迭代阶段触发,因此该开销完全可控,且改进带来的预测精度提升远超

过计算成本的增加,符合妊娠猪舍环境预测的工程应用需求。

3 结论

(1)提出一种白鲸优化算法的改进算法 IBWO,通过引入 Logistic 混沌映射、参数非线性自适应调整、局部搜索等混合策略较好地提升了算法的寻优能力。

(2)以妊娠猪舍为研究对象,将猪舍采集到的数据作为输入,相对湿度与温度作为输出,采用 IBWO 智能优化算法对基本集成框架模型寻优后,建立了 IBWO-Stacking 预测模型,预测相对湿度时模型的 R^2 可以达到 0.974 7、平均绝对误差为 1.123 7%、均方根误差为 1.800 9%,进行温度预测时模型的 R^2 、平均绝对误差和均方根误差分别为 0.971 5、0.210 4℃ 和 1.102 9℃。

(3)IBWO-Stacking 模型相较于 Stacking 模型和 BWO-Stacking 模型,在相对湿度与温度预测上展现了显著的性能提升。IBWO-Stacking 相较于 BWO-Stacking 在平均绝对误差、均方误差和均方根误差上分别降低约 7.35%、17.23% 和 9.02%,温度预测的平均绝对误差、均方误差和均方根误差降低了 6.36%、30.92% 和 16.9%。表明 IBWO-Stacking 具有良好的鲁棒性和稳定性,能够在复杂多变的实际环境中持续提供准确可靠的预测结果。

表 4 算法耗时分析

Tab.4 Algorithm time consumption analysis

算法	F6	F12	F13	F14	F20
BWO	3.427 7	8.663 5	8.699 2	12.405 4	2.137 1
IBWO	3.149 0	15.624 6	15.571 8	12.511 8	1.713 6

参 考 文 献

[1] 郭利京,林云志. 中国生猪养殖业规模化动力、路径及影响研究[J]. 农村经济,2020(8):126-135.
Guo Lijing,Lin Yunzhi. China's large-scale pig breeding industry: incentives, paths and impact[J]. Rural Economy,2020(8):126-135. (in Chinese)

[2] 马畅,尹靖东,董冰. 饲养环境因素对母猪生产性能的影响[J]. 中国畜牧杂志,2018,54(12):5-9.
Ma Chang,Yin Jingdong,Dong Bing. Research progress on effect of feeding environment factors on sow production[J]. Chinese Journal of Animal Science,2018,54(12):5-9. (in Chinese)

[3] 青林,王春光,靳敏,等. 北方地区环境温湿度对育肥猪采食量的影响研究[J]. 家畜生态学报,2021,42(6):69-74.
Qing Lin,Wang Chunguang,Jin Min,et al. Influence of environmental temperature and humidity on feed intake of finishing pigs in northern China[J]. Journal of Domestic Animal Ecology,2021,42(6):69-74. (in Chinese)

[4] 赵云翔,邝伟键,彭兴,等. 湿热环境对后备公猪采食行为和饲料效率的影响[J]. 中国畜牧杂志,2019,55(9):123-128.
Zhao Yunxiang,Kuang Weijian,Peng Xing,et al. Effect of hot and humid environment on the feeding behavior and feed efficiency of Duroc boar[J]. Chinese Journal of Animal Science,2019,55(9):123-128. (in Chinese)

[5] Kim Y,Kyoung H,Park K I,et al. PSXIII-6 effects of high humidity under high-temperature conditions on growing pigs[J]. Journal of Animal Science,2023,101(S3):575-576.

[6] 沈明霞,陈金鑫,丁奇安,等. 生猪自动化养殖装备与技术研究进展与展望[J]. 农业机械学报,2022,53(12):1-19.
Shen Mingxia,Chen Jinxin,Ding Qi'an,et al. Current situation and development trend of pig automated farming equipment application[J]. Transactions of the Chinese Society for Agricultural Machinery,2022,53(12):1-19. (in Chinese)

[7] 王鹏新,王婕,田惠仁,等. 基于遥感多参数和门控循环单元网络的冬小麦单产估测[J]. 农业机械学报,2022,53(9):207-216.
Wang Pengxin,Wang Jie,Tian Huiren,et al. Yield estimation of winter wheat based on multiple remotely sensed parameters and gated recurrent unit neural network[J]. Transactions of the Chinese Society for Agricultural Machinery,2022,53(9):207-216. (in Chinese)

[8] Tyagi S,Zhang X,Saraswat D,et al. Flash drought: review of concept, prediction and the potential for machine learning, deep learning methods[J]. Earth's Future,2022,10(11):e2022EF002723.

[9] Thakur P S,Khanna P,Sheorey T,et al. Trends in vision-based machine learning techniques for plant disease identification: a systematic review[J]. Expert System with Application,2022,208:118117.

[10] Zhang Y,Zhang W,Wu C,et al. Prediction model of pigsty temperature based on ISSA-LSSVM[J]. Agriculture,2023,13(9):1710.

[11] 谢秋菊,马超凡,王圣超,等. 猪舍氨气与二氧化碳浓度变化时序预测模型优化[J]. 农业机械学报,2023,54(7):381-391.
Xie Qiuju,Ma Chaofan,Wang Shengchao,et al. Optimal prediction model for gas concentrations of NH₃ and CO₂ time-series in pig house[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(7):381-391. (in Chinese)

[12] Kim J G,Lee S Y,Lee I B. The development of an LSTM model to predict time series missing data of air temperature inside fattening pig houses[J]. Agriculture,2023,13(4):795.

[13] Zhong C,Li G,Meng Z. Beluga whale optimization: a novel nature-inspired metaheuristic algorithm[J]. Knowledge-Based Systems,2022,251:109215.

[14] 张莉,张小庆,孙民民,等. 蝴蝶搜索与动态反向学习柯西变异的白鲸优化算法[J]. 计算机工程与应用,2025,61(10):96-110.
Zhang Li,Zhang Xiaoqing,Sun Minmin,et al. Beluga optimization algorithm based on butterfly search and dynamic inverse learning Cauchy variation[J]. Computer Engineering and Applications,2025,61(10):96-110. (in Chinese)

[15] 文裕杰,张达敏,邓佳欣,等. 额隆感知和围攻机制改进的白鲸优化算法[J]. 小型微型计算机系统,2024,45(12):2858-2866.
Wen Yujie,Zhang Damin,Deng Jiaxin,et al. Beluga optimization algorithm with improved melon sensing and siege mechanism[J]. Journal of Chinese Computer Systems,2024,45(12):2858-2866. (in Chinese)

[16] Yuan X,Hu G,Zhong J,et al. HBWO-JS: jellyfish search boosted hybrid beluga whale optimization algorithm for engineering applications[J]. Journal of Computational Design and Engineering,2023,10(4):1615-1656.

[17] 陈奕君,郑嘉利,李芷芊,等. 基于改进型白鲸算法的 RFID 网络规划[J]. 计算机科学,2024,51(3):317-325.
Chen Yijun,Zheng Jiali,Li Zhiqian,et al. Improved beluga whale optimization for RFID network planning[J]. Computer Science,2024,51(3):317-325. (in Chinese)

[18] 韩威,姜淑娟,周伟. 基于 CodeBERT 和 Stacking 集成学习的补丁正确性验证方法[J]. 计算机科学,2025,52(1):250-258.
Han Wei,Jiang Shujuan,Zhou Wei. Patch correctness verification method based on CodeBERT and Stacking ensemble learning[J]. Computer Science,2025,52(1):250-258. (in Chinese)

[19] He H, Pan Y, Chen X, et al. An integrated learning carbon emission prediction algorithm optimized for stacking based on genetic algorithm[C]//2024 Second International Conference on Cyber-Energy Systems and Intelligent Energy. Piscataway: IEEE, 2024:1 – 5.

[20] 刘潭, 朱洪锐, 袁青云, 等. 基于多模型融合策略的温室番茄光合速率预测方法[J]. 农业机械学报, 2024, 55(4):337 – 345.
Liu Tan, Zhu Hongrui, Yuan Qingyun, et al. Prediction of photosynthetic rate of greenhouse tomatoes based on multi-model fusion strategy[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(4):337 – 345. (in Chinese)

[21] Hassan M H, Kamel S, Jurado F, et al. Economic load dispatch solution of large-scale power systems using an enhanced beluga whale optimizer[J]. Alexandria Engineering Journal, 2023, 72: 573 – 591.

[22] 林敏, 徐航, 林金山. 多策略融合改进的白鲸优化算法[J]. 延边大学学报(自然科学版), 2024, 50(3): 45 – 50.
Lin Min, Xu Hang, Lin Jinshan. Improved beluga whale optimization algorithm with multi-strategy integration[J]. Journal of Yanbian University(Natural Science Edition), 2024, 50(3):45 – 50. (in Chinese)

[23] Chuluunsaikhan T, Kim J H, Park S H, et al. Analyzing internal and external factors in livestock supply forecasting using machine learning: sustainable insights from South Korea[J]. Sustainability, 2024, 16(16):6907.

[24] 马帅印, 李敏, 殷磊, 等. 基于特征加权集成学习的陶瓷制造能效预测方法研究[J]. 计算机集成制造系统, 2025, 31(10):3817 – 3830.
Ma Shuaiyin, Li Min, Yin Lei, et al. Energy efficiency prediction method for ceramic manufacturing based on feature-weighted ensemble learning[J]. Computer Integrated Manufacturing Systems, 2025, 31(10):3817 – 3830. (in Chinese)

[25] 齐浩, 吕亮杰, 孙海芳, 等. 基于无人机高光谱遥感与机器学习的小麦品系产量估测研究[J]. 农业机械学报, 2024, 55(7):260 – 269.
Qi Hao, Lü Liangjie, Sun Haifang, et al. Yield estimation of wheat lines based on UAV hyperspectral remote sensing and machine learning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(7):260 – 269. (in Chinese)

[26] Guo J, Cui D, Guo J, et al. Hyperspectral estimation of tea leaf chlorophyll content based on Stacking models[J]. Agriculture, 2025, 15(10):1039.

[27] 史红伟, 叶明昊, 谢酶, 等. 基于改进鲸鱼算法优化 LSTM 的粮油温度预测[J]. 陕西科技大学学报, 2024, 42(6):208 – 214.
Shi Hongwei, Ye Minghao, Xie Mei, et al. Grain and oil temperature prediction based on improved whale algorithm optimized LSTM[J]. Journal of Shaanxi University of Science, 2024, 42(6):208 – 214. (in Chinese)

[28] 王亚辉, 张虎晨, 王学兵, 等. 基于混沌反向学习和水波算法改进的白鲸优化算法[J]. 计算机应用研究, 2024, 41(3):729 – 735.
Wang Yahui, Zhang Huchen, Wang Xuebing, et al. Improved beluga whale optimization algorithm based on chaotic inverse learning and water wave algorithm[J]. Application Research of Computers, 2024, 41(3):729 – 735. (in Chinese)

[29] 朱佳明, 孙彬, 蒲施桦, 等. 基于多环境因素分析的猪舍温湿度预测模型[J]. 华南农业大学学报, 2024, 45(5):709 – 721.
Zhu Jiaming, Sun Bin, Pu Shihua, et al. Improved beluga whale optimization algorithm based on chaotic inverse learning and water wave algorithm[J]. Journal of South China Agricultural University, 2024, 45(5):709 – 721. (in Chinese)

[30] Mangalathu S, Jang H, Hwang S H, et al. Data-driven machine-learning-based seismic failure mode identification of reinforced concrete shear walls[J]. Engineering Structures, 2020, 208:110331.

[31] Chen T, Guestrin C. XGBoost: a scalable tree boosting system[PP/OL]. V3. arXiv(2016 – 06 – 10)[2025 – 08 – 21]. <https://doi.org/10.48550/arXiv.1603.02754>.

[32] Machado M R, Karray S, Sousa I T. LightGBM: an effective decision tree gradient boosting method to predict customer loyalty in the finance industry[C]//2019 14th International Conference on Computer Science & Education. Piscataway: IEEE, 2019: 1111 – 1116.