doi:10.6041/j.issn.1000-1298.2026.04.033

基于低成本电子耳标的母猪发情自动预测方法

桑高丽[1,2]　殷亚鹏[1,2]　高开富[1,2]　万　亮[3]　姚雪飞[4]　罗朝飞[4]

(1.浙江理工大学计算机科学与技术学院(人工智能学院),杭州 310018;2.嘉兴大学人工智能学院,嘉兴 314001;
3.天津大学智能与计算学部,天津 300072;4.浙江华腾牧业有限公司,嘉兴 314513)

摘要:针对母猪发情自动化检测成本高、推广难的问题,提出了一种基于改进遗传算法(Genetic algorithm, GA)优化轻量级梯度提升机算法(Light gradient boosting machine, LightGBM)对母猪发情进行预测的模型。模型利用低成本电子耳标实时采集母猪耳温数据,并提出小时平均体温重采样策略。实验结果表明,该策略可显著降低过拟合风险。针对传统 GA 收敛慢、易陷入局部最优的问题,设计了"强制子代迭代"(Forced offspring iteration, FOI)机制进行改进,在保证全局搜索能力的同时提升算法收敛效率。基于浙江华腾牧业有限公司 311 头母猪的实测数据集,FOI-GA 优化 LightGBM 的模型 FOI-GA-LightGBM 在验证集上准确率达到 83.91%,AUC 值为 0.839 0,性能显著优于其他模型。

关键词:母猪发情检测;改进遗传算法;电子耳标;强制子代迭代;轻量级梯度提升机

中图分类号:TP399　　**文献标识码**:A　　**文章编号**:1000-1298(2026)04-0339-08　　**OSID**:

Automatic Prediction Method for Sow Estrus Based on Low-cost Electronic Ear Tags

SANG Gaoli[1,2]　YIN Yapeng[1,2]　GAO Kaifu[1,2]　WAN Liang[3]　YAO Xuefei[4]　LUO Chaofei[4]

(1. *School of Computer Science and Technology (School of Artificial Intelligence), Zhejiang Sci-tech University, Hangzhou* 310018, *China*
2. *College of Artificial Intelligence, Jiaxing University, Jiaxing* 314001, *China*
3. *School of Intelligence and Computing, Tianjin University, Tianjin* 300072, *China*
4. *Zhejiang Huateng Animal Husbandry Co., Ltd., Jiaxing* 314513, *China*)

Abstract: Using ear temperature instead of body temperature to predict and analyze the estrus of sows. To address the issues of high cost and limited scalability in the automated detection of sow estrus, a prediction model (denoted as GA-LightGBM) was proposed based on the improved genetic algorithm (GA) optimizing the light gradient boosting machine (LightGBM). Compared with infrared cameras and infrared imaging equipment, low-cost and low-power electronic ear tags were used to collect real-time ear temperature data from sows, and an hourly average temperature resampling strategy was innovatively proposed. Comparative experiments showed that this strategy significantly reduced the risk of overfitting. To overcome the problems of slow convergence speed and falling into local optima in traditional genetic algorithms, a forced offspring iteration (FOI) mechanism was designed to improve the algorithm, enhancing the convergence efficiency while maintaining the global search capability. In experiments, a LightGBM model optimized by the particle swarm optimization (PSO) (denoted as PSO-LightGBM) was introduced for comparison. After verification using a dataset containing 311 sows provided by Zhejiang Huateng Animal Husbandry Co., Ltd., the improved GA-optimized LightGBM model (denoted as FOI-GA-LightGBM) achieved an accuracy of 83.91% and an AUC of 0.839 0 on the test set, significantly outperforming the GA-LightGBM and PSO-LightGBM models. At the same time, FOI-GA-LightGBM was also compared with random forest (RF) and support vector machine (SVM) in terms of performance. The overall performance of FOI-GA-LightGBM was superior to RF and SVM.

Key words: sow estrus detection; improved genetic algorithm; electronic ear tags; forced offspring iteration; light gradient boosting machine

收稿日期:2025-07-01　修回日期:2025-09-23

基金项目:浙江省重点研发计划项目(2021C02007)和嘉兴市公益性研究计划项目(2024AD10046)

作者简介:桑高丽(1986—),女,副教授,博士,主要从事智慧农业研究,E-mail:glsang@zjxu.edu.cn

通信作者:万亮(1979—),女,教授,博士生导师,主要从事计算机视觉和智能数据分析等研究,E-mail:lwan@tiu.edu.cn

0 引言

全球人口增长推动物蛋白需求提升,对畜牧业生产效率提出更高要求[1]。在此背景下,精准畜牧业(Precision livestock farming,PLF)作为提升养殖精细化、智能化的关键技术体系,已获学术界与产业界广泛关注[2],其 2024 年市场规模突破 50 亿美元,年增长率超 15%。在生猪养殖中,母猪繁殖效率是生产效益核心[3-4],发情预测准确性是关键瓶颈。研究显示,一次有效发情延误可使单头母猪年产值损失 300~500 元,万头规模养殖场年均损失或超百万元[5-9]。然而,传统发情检测方式(如背压试验、公猪试情)高度依赖人工观察,劳动密集且成本高[10],大型猪场约 30% 劳动力用于发情检测[11-12],亟需自动化、低成本、高可靠性的发情检测技术替代。

为实现发情自动监测,研究者已探索阴道黏液、生殖道电导率、外阴水肿、体温变化及行为模式等多类可量化指标[13-14]。在众多指标中,体温(尤其体表温度)因与母猪生理状态(含发情期激素变化)高度相关,且能通过非接触或植入式传感器实现连续、客观、自动化采集,被普遍视为极具应用前景的关键参数。如 SYKES 等[15]用数字红外热成像技术,王晨阳等[16]用智能红外摄像机(Y3TB01 型),探究母猪体表特定区域温度与直肠温度、发情状态(周期)的关联性及体表温度替代直肠测温的可行性。但基于红外成像的方案成本高昂,单台设备的购置成本通常超过 500 美元,例如 FLIR ThermoCAM S60 单价为 714 美元[15],IRT-C3 单价为 570 美元[16],且仍需人工操作目标定位与数据采集,限制了规模化推广。

相比之下,集成温度传感器的电子耳标有独特综合优势:①电子耳标单价为 48 美元。②能全天候自动化采集传输个体体温数据,减少人工干预。③易规模化部署管理,推广潜力较好。其部署便捷性在安装时尤为明显,采用简单穿刺式安装,单个工人不到 1 min 即可完成佩戴,远优于需专业人员安装调试的红外设备。④运维成本上,电子耳标能大幅降低日常管理总开销。红外方案运维成本高、长期稳定性差,核心原因是设备在养殖场恶劣环境(潮湿、高温、氨气等)中使用寿命受限,侵蚀加速设备损坏推高维护成本;而电子耳标采用模块化设计,关键部件可单独更换,既提升耐用性(通常达 5 年以上)、降低维修更换成本,又因环境适应性强,能更好应对恶劣环境,进一步减少长期运维经济负担。

本文提出一种基于低成本电子耳标的母猪发情预测方法。通过非接触式实时采集耳温数据,并采用小时平均耳温重采样策略构建特征,在模型构建上引入 LightGBM[17],提出 FOI 机制改进遗传算法(FOI-GA)对 LightGBM 超参数进行高效优化。以期为构建低成本、高可靠性的母猪发情自动化检测提供参考。

1 数据收集和预处理

1.1 数据采集设备与方法

数据来源于浙江华腾牧业有限公司恒华养殖场。每头限位栏母猪均配有低功耗智能有源电子耳标(TS-01 型),如图 1 所示。该设备内置高精度温度传感器,可实现母猪耳温实时监测。为了确保数据的准确性和稳定性,在数据采集过程设置多重校准机制,并定期对设备进行维护和校准。

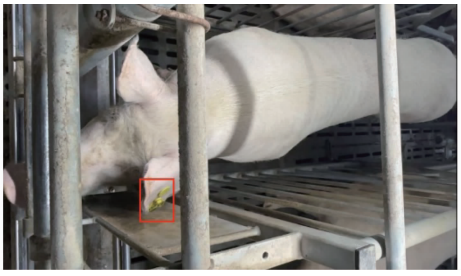

图 1 配备智能电子耳标的限位栏母猪

Fig. 1 Sows in limit stalls equipped with intelligent electronic ear tags

1.2 数据预处理

图 2 所示为母猪原始体温数据与按小时重采样后的体温曲线变化趋势。为明确更适用于母猪发情

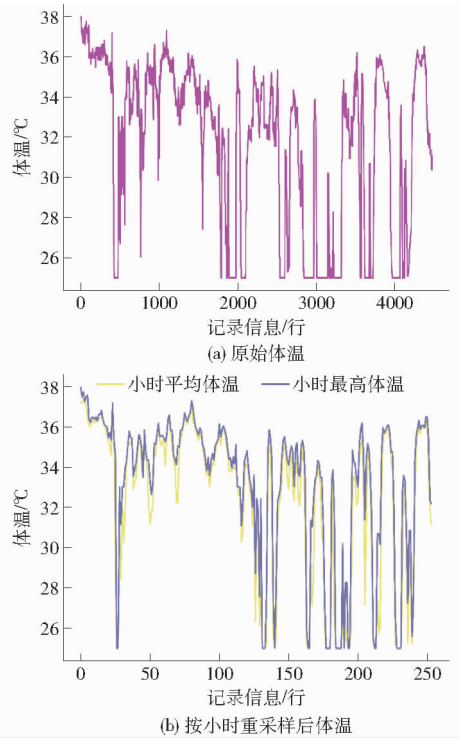

图 2 体温曲线

Fig. 2 Body temperature curves

预测的特征，从而提升模型的预测精度和稳定性，后续将对小时平均体温与小时最高体温的预测效果进行对比，具体的对比结果在 3.5.2 节呈现。最终选用小时平均体温作为母猪发情预测数据。

数据预处理流程如图 3 所示。按小时重采样后的数据集中，一行数据对应 1 h，小时可能存在缺失而不连续。标签设置以养殖场人工查情结果为依据：每天上午 08:30 与下午 15:30 各进行 1 次人工查情，将查情判定为发情的母猪标签设为 1，判定为未发情的母猪标签设为 0，最终输出特征矩阵 $\boldsymbol{X}$ 与标签向量 $\boldsymbol{y}$ 的组合（$\boldsymbol{X}$，$\boldsymbol{y}$），用于模型训练。

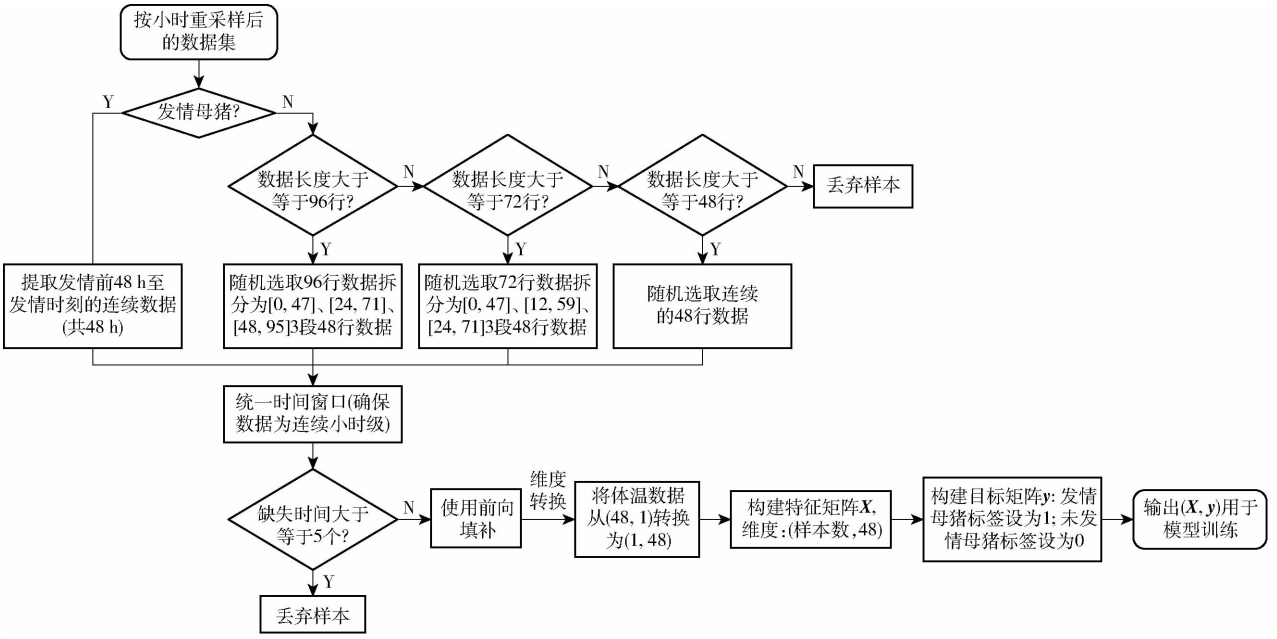

图 3　数据预处理流程

Fig. 3　Data preprocessing peocedure

1.3　数据标准化

为了消除不同特征之间的尺度差异，提高模型的收敛速度和预测精度，选择标准化方法对数据进行规范化处理。标准化能够将数据转换为均值为 0、标准差为 1 的标准正态分布，从而避免因尺度差异导致的模型权重分配偏差及收敛效率问题。标准化后，所有特征在梯度下降中的权重更加均衡，模型能够更有效地学习各个特征的重要性，加速收敛并提高预测准确性。具体公式为

$$z = \frac{x - \mu}{\sigma} \tag{1}$$

式中　z——标准化得分　　x——原始数据

μ——训练数据均值

σ——训练数据标准差

2　方法

2.1　LightGBM

LightGBM 是一种针对大规模结构化数据优化的梯度提升框架，建立在传统梯度提升决策树（Gradient boosting decision tree，GBDT）基础上[18]。其核心机制是迭代地构建一组弱学习器（决策树）：在每一轮迭代中，模型计算当前预测与真实标签之间的负梯度（即残差），并通过最小化损失函数训练新的树以拟合该残差；最终预测结果为所有弱学习器输出的加权和[19]。

2.2　GA

GA 类似于自然进化机制中存在的繁殖过程，GA 是随机搜索和优化方法，包括选择、交叉、突变、适者生存和进化[20]。选择操作确定从旧种群中选择特定染色体进行繁殖的次数。交叉操作以某种方式相互交换 2 个配对染色体的部分基因从而形成新的个体。突变操作是根据某种概率对个体染色体编码串中的某些基因座上的基因值进行修改，改变的基因值是一个或多个，从而形成新的个体。

2.3　FOI－GA－LightGBM 母猪发情预测模型构建

改进遗传算法核心在于提出“强制子代迭代”机制。该机制通过在交叉操作后直接淘汰参与交叉的父代个体，强制保留其子代进入下一轮迭代，从而切断了父代基因在种群中的持续传递，显著提高了种群多样性。同时，该机制有效增强了算法在参数空间中的全局探索能力，尤其在应用于优化 LightGBM 模型的关键超参数时，能够更高效地遍历参数空间，避免陷入局部最优解。

在模型优化过程中，重点关注 4 个超参数：num_leaves、learning_rate、max_depth 和 min_child_weight，其默认值和含义如表 1 所示。

表 1 LightGBM 超参数默认值和含义

Tab. 1 Default values and meanings of LightGBM hyperparameters

名称	默认值	含义
num_leaves	31	树的最大叶子节点数量
learning_rate	0.1	学习率,每次迭代的模型步长
max_depth	-1	最大树深度,负值表示深度不受限制
min_child_weight	1	最小叶子权重,范围[0,∞)

遗传算法在处理大规模问题时,需在每一代中进行适应度评估、选择、交叉、变异,这些操作导致计算量较大,计算时间较长。通过针对性优化交叉操作并结合策略调整,提出一种新的强制子代迭代机制改进现有遗传算法,可在保证求解质量的前提下提升算法效率。

传统遗传算法在选择操作中保留父代个体,可能导致种群多样性下降,从而影响算法的探索能力。FOI 策略的核心改进为

$$P_{t+1} = C_t \cup M(C_t) \tag{2}$$

式中 P_{t+1}——新一代种群

C_t——交叉子代

$M(C_t)$——变异算子

通过淘汰率 100% 强制种群更新,提升了算法探索能力,并显著减少了收敛迭代次数。

图 4 为 FOI-GA 优化 LightGBM 模型的过程。模型输入为数据预处理后 434 个样本的 48 h 体温数据,即维度为 434×48 的特征矩阵 $\boldsymbol{X}$。通过循环执行 FOI-GA 不断进行 LightGBM 的参数搜索直至多次连续测试集准确率无提升后停止,并输出 FOI-GA 确定的参数组合。

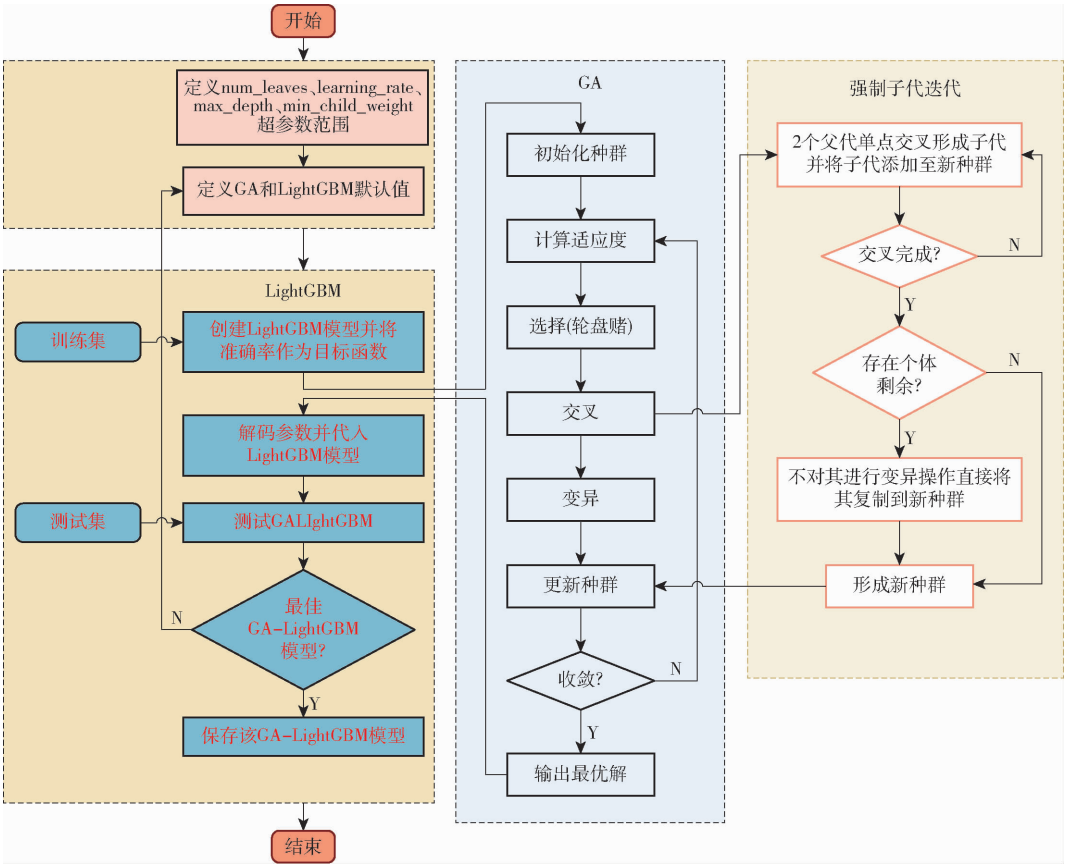

图 4 FOI-GA-LightGBM 的母猪发情预测流程图

Fig. 4 Flowchart of sow estrus prediction using FOI-GA-LightGBM

“强制子代迭代”机制优化传统遗传算法搜索流程:直接淘汰交叉后的 2 个父代、完全保留子代进入下一轮,未被操作个体直接进入下一代;该机制移除传统方法中父代子代混合选择、重复适应度评估的冗余步骤,显著提升计算效率。具体优势有两方面:①快速淘汰低适应度个体,避免父代干扰种群,迫使算法通过交叉变异持续探索更优解。②无父代滞留,增强算法在搜索空间(如 LightGBM 参数优化)的探索能力,尤其对非线性关联参数组合(如 num_leaves 和 max_depth),能更高效跳出局部最优,加速收敛至全局更优解。该设计兼顾搜索效率的同时,强化了算法在高维参数空间的寻优能力。

3 实验与结果

实验环境为 Intel(R) Core(TM) i7-10750H CPU@2.60 GHz,内存 16 GB,Windows 10 操作系统。

3.1 实验数据

共收集 362 头母猪的体温监测数据，经数据清理得到 311 头合格样本，包括 235 头发情母猪和 76 头非发情母猪。经数据预处理后，共获得 434 条有效样本，其中发情样本 215 条，非发情样本 219 条，数据分布接近均衡。为评估模型泛化能力，采用随机划分策略，将数据集划分为训练集（60%，用于模型参数学习），测试集（20%，通过超参数调优优化模型表现），验证集（20%，在模型训练完成后独立评估其泛化性能）。为确保评估可靠性，3 组数据严格独立。训练阶段仅使用训练集，测试集用于早停和超参数调整，最终模型性能以验证集结果为准。

3.2 评价指标

采用准确率（Accuracy）、精确率（Precision）、召回率（Recall）、F1 值（F1 score）、受试者工作特征曲线（Receiver operating characteristic curve，ROC）下的面积（Area under curve，AUC）评价模型。

3.3 模型参数设置

遗传算法初始种群大小为 100，共迭代 50 次。表 2 为 4 个超参数的 DNA 编码位数和取值范围，其中染色体长度共 17 位，设置突变概率为 0.01。

表 2　GA 调整的参数及范围

Tab. 2　Parameters and ranges for GA adjustment

参数	DNA 编码位数	范围	步长
num_leaves	6	2 ~ 1 010	16
learning_rate	5	0.01 ~ 0.30	0.009 35
max_depth	3	3 ~ 10	1
min_child_weight	3	1 ~ 8	1

3.4 模型性能

除基准方法 LightGBM、GA－LightGBM 外，还选取 PSO 算法作为对比方法。PSO 因其灵活性高、收敛速度快且参数配置相对简单，被广泛用于各类优化问题[21]，但其初期收敛快，接近最优解时局部搜索能力弱，易陷入次优解，影响优化精度。相比之下，GA 依托基于种群的全局搜索策略，在 LightGBM 等复杂模型的参数优化中表现更优，逼近全局最优解的概率更高。为系统验证 FOI－GA－LightGBM 的优化效果，引入 PSO－LightGBM 作为对比基准。

3.4.1 与基准方法性能对比

表 3 为 LightGBM、PSO－LightGBM、GA－LightGBM 和 FOI－GA－LightGBM 模型在测试集和验证集上的评估指标表现。

表 3　各模型在测试集和验证集上的性能对比

Tab. 3　Performance comparison of each model on test set and validation set　%

模型	测试集				验证集			
	准确率	精确率	召回率	F1 值	准确率	精确率	召回率	F1 值
LightGBM	71.26	68.75	76.74	72.53	71.26	73.68	65.12	69.14
PSO－LightGBM	73.56	72.73	74.42	73.56	74.71	74.42	74.42	74.42
GA－LightGBM	70.11	67.35	76.74	71.74	75.86	76.19	74.42	75.29
FOI－GA－LightGBM	77.01	74.47	81.40	77.78	83.91	83.72	83.72	83.72

由表 3 可知，在测试集上，FOI－GA－LightGBM 所有指标均优于对比模型。其准确率、精确率、召回率、F1 值显著优于默认参数 LightGBM 和 GA－LightGBM；PSO－LightGBM 虽整体优于前两者，但召回率比 GA－LightGBM 低 2.32 个百分点，且仍不及 FOI－GA－LightGBM。在验证集上，FOI－GA－LightGBM 优势进一步扩大。相较于 PSO－LightGBM，其准确率、精确率、召回率、F1 值分别高 12.31%、12.50%、12.50%、12.50%；相较于 GA－LightGBM，分别高 10.61%、9.88%、12.50%、11.20%。且 FOI－GA－LightGBM 在验证集较测试集提升显著（准确率、精确率和 F1 值分别提升 8.96%、12.42%、7.64%），PSO－LightGBM 提升则少于 5%。上述结果表明，FOI－GA 机制不仅提升了 LightGBM 精度，还增强了其泛化能力；验证集与测试集优化趋势一致，证明该方法鲁棒性、稳定性更强，可适用于实际场景。

如图 5 所示，FOI－GA－LightGBM 在测试、验证集中均最优，识别发情的真阳性（TP）最高，误判（FP）与漏判（FN）最低，说明其识别精度和跨数据集泛化能力更优。

表 4 为 4 个模型在训练集和验证集上的 AUC 值。FOI－GA－LightGBM 在泛化能力和预测性能上均显著优于对比模型。FOI－GA－LightGBM 验证集 AUC 达 0.839 0，较 PSO－LightGBM（0.747 0）和 GA－LightGBM（0.758 4）分别高 12.13% 和 10.61%，且其验证集表现明显优于测试集（高 6.84%），充分证明了所提方法在提升模型泛化性能和预测精度方面的优越性。

3.4.2 与其他机器学习方法性能对比

通过对比实验评估了 FOI－GA－LightGBM 模型与主流机器学习方法的性能表现（表 5），FOI－GA－LightGBM 在验证集上展现出最优性能，其平均准确率达到75.69%，AUC 值为 0.756 9，均高于

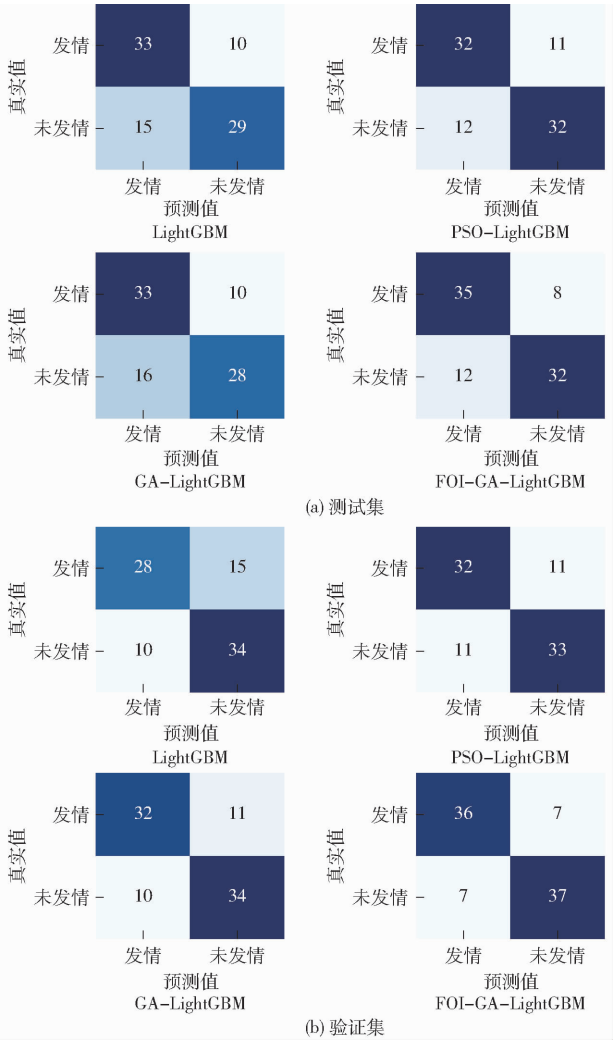

图 5 各模型测试集和验证集的混淆矩阵

Fig. 5 Confusion matrices of training set and validation set of each model

表 4 各模型在测试集和验证集上的 AUC 值

Tab. 4 AUC values of each model on training set and validation set

模型	测试集	验证集
LightGBM	0.713 3	0.711 9
PSO－LightGBM	0.735 7	0.747 0
GA－LightGBM	0.701 9	0.758 4
FOI－GA－LightGBM	0.770 6	0.839 0

表 5 与主流机器学习方法性能对比

Tab. 5 Comparison of performance with mainstream machine learning methods

模型	测试集		验证集	
	平均准确率/%	平均 AUC 值	平均准确率/%	平均 AUC 值
RF	72.99	0.730 0	72.99	0.729 8
SVM	69.73	0.697 3	67.24	0.672 9
FOI－GA－LightGBM	73.18	0.732 2	75.69	0.756 9

随机森林(RF)和支持向量机(SVM)的表现。在验证集上的优异表现进一步证明了提出算法相较对比方法具有更强的泛化能力。

其他详细对比指标如图 6 所示。准确率方面(图 6a),测试集上 FOI－GA－LightGBM 与 RF 相近且略高于 SVM,验证集上则持续上升;精确率方面(图 6b),测试集 FOI－GA－LightGBM 高于 SVM、与 RF 接近,验证集进一步上升并超越 RF,远优于呈下降趋势的 SVM;召回率方面(图 6c),测试集 FOI－GA－LighGBM 已高于 RF 和 SVM,验证集仍持续提升;F1 值方面(图 6d),测试集 FOI－GA－LightGBM 优于 SVM、与 RF 相近,验证集持续上升,最终显著优于 SVM(下降)与基本持平的 RF,综合性能更优。综上,FOI－GA－LightGBM 在准确率、精确率、召回率、F1 值 4 个核心指标上,相比 SVM 和 RF 均表现更优(或泛化能力更强),充分证明了其有效性。

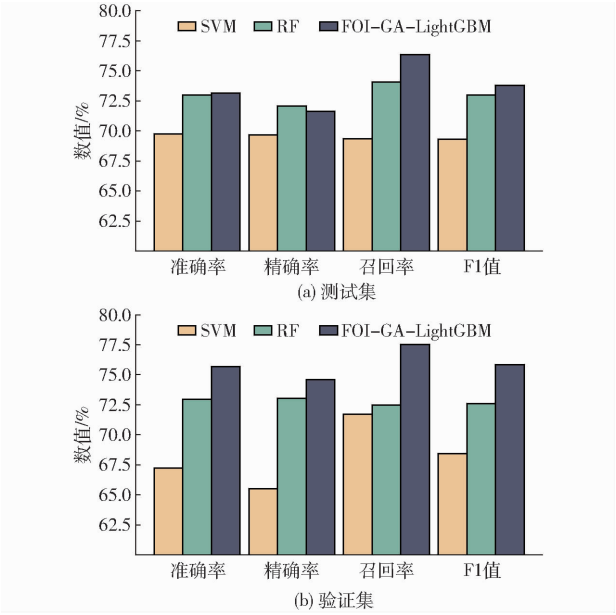

图 6 与其他机器学习方法其他评估指标对比

Fig. 6 Comparison with other evaluation metrics of other machine learning methods

3.5 消融实验

3.5.1 模型时间效率

为了进一步验证优化算法计算效率,分别对 PSO、GA 和 FOI－GA 优化算法进行 10 次独立运行实验,并记录其时间性能,结果如图 7 所示。

由图 7 可知,PSO 执行时间波动较大,这一现象可能与其在全局搜索过程中易陷入局部最优解有关,导致其稳定性和计算效率下降。GA 的执行时间虽比 PSO 更稳定,但仍不如 FOI－GA 高效。相比之下,FOI－GA 在时间效率与稳定性上均表现最佳,各次运行耗时波动极小(标准差仅 0.94 s),且收敛速度最快。具体而言,FOI－GA 的平均耗时仅为(14.55 ± 0.94) s,相比 PSO 优化方法效率提升达 40.67%,充分体现了其在计算效能和鲁棒性方面的

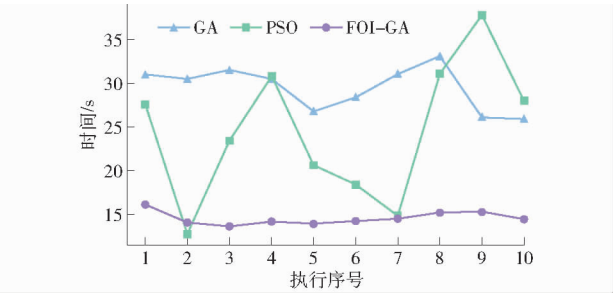

图 7　不同方法确定最佳参数所需时间对比

Fig. 7　Comparison of time required to find optimal parameters using different methods

双重优势。

表 6 为 3 种优化算法(GA、PSO、FOI－GA)在计算时间方面的性能对比。从平均计算时间来看，FOI－GA 表现出显著优势，其平均耗时仅为 14.548 7 s，相比 GA(29.493 9 s)和 PSO(24.520 9 s)分别降低约 50.7% 和 40.7%。值得注意的是，FOI－GA 在计算时间上表现出极高的稳定性，其标准差仅为 0.716 4 s，说明该算法在不同运行条件下仍能保持高度一致的时间性能。

表 6　不同方法执行时间对比

Tab. 6　Comparison of execution time of different methods　　s

优化算法	平均值	最大值	最小值	标准差
GA	29.493 9	33.120 5	23.934 5	2.401 2
PSO	24.520 9	37.796 0	12.742 7	7.650 8
FOI－GA	14.548 7	16.088 4	13.612 8	0.716 4

3.5.2　不同体温指征母猪发情预测分析

为了评估小时平均体温和小时最高体温对母猪发情预测效果，使用 PSO－LightGBM、GA－LightGBM 和 FOI－GA－LightGBM 3 个模型分别多次对随机选择的相同数据进行训练、测试和验证并取其平均准确率和平均 AUC 值，如表 7、8 所示。

表 7　不同体温重采样方式下各模型平均准确率

Tab. 7　Average accuracy of each model under different resampling methods for body temperature　　%

模型	小时平均体温		小时最高体温	
	测试集	验证集	测试集	验证集
PSO－LightGBM	74.71	69.35	78.29	67.43
GA－LightGBM	68.20	64.37	67.83	62.45
FOI－GA－LightGBM	77.78	71.26	75.97	68.58

由表 7、8 可知，不同重采样方式对模型泛化能力具有显著影响。在测试集中，GA－LightGBM 与 FOI－GA－LightGBM 在平均体温条件下表现更优，而 PSO－LightGBM 则在最高体温条件下表现更好；

表 8　不同体温重采样方式下各模型平均 AUC 值

Tab. 8　Average AUC values of each model by different resampling methods for body temperature

模型	小时平均体温		小时最高体温	
	测试集	验证集	测试集	验证集
PSO－LightGBM	0.748 0	0.694 1	0.784 5	0.675 4
GA－LightGBM	0.682 5	0.643 9	0.680 2	0.626 6
FOI－GA－LightGBM	0.778 7	0.713 3	0.761 4	0.687 5

然而，在验证集中，所有模型在平均体温下的准确率与 AUC 值均优于最高体温(平均高 3.91% 和 3.75%)，表明最高体温数据易引发过拟合，降低模型泛化性能，而平均体温策略能够有效提升预测稳定性。

3.5.3　母猪发情前后体温变化可视化分析

为进一步探究母猪发情前后的体温变化规律，随机选取 33 头发情母猪，统计其在发情前后 48 h 内的体温数据。对每头母猪体温数据先进行前向填补防止存在空值，再通过减去个体自身平均体温得到体温偏差，最终统计 33 头母猪在每个监测时间点上体温偏差群体均值与标准差，以揭示发情前后母猪群体体温变化特征，结果如图 8 所示。

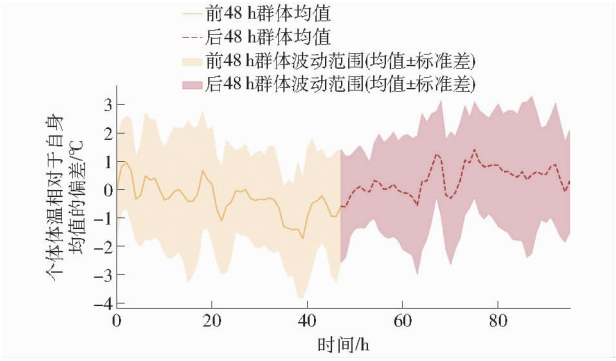

图 8　33 头母猪发情前后各 48 h 体温偏差的群体均值与标准差分布

Fig. 8　Distribution of group mean and standard deviation of body temperature deviation in 33 sows 48 h before and after estrus

在发情前 48 h 母猪体温偏差的均值曲线整体在零值附近及以下波动，表明发情前体温相对个体基线较为平稳但存在一定下降趋势，而在发情后 48 h 体温偏差均值呈现一致的上升趋势，反映出发情这一生理过程对母猪体温存在普遍的“升温驱动”，使体温相对于个体基线的偏差整体升高。

从方差变化来看，发情前 48 h 的波动范围较为紧凑，表明该阶段不同母猪的体温变化较为一致，个体差异较小；发情后 48 h 方差波动范围明显扩大，说明不同母猪对发情刺激的体温响应存在较大异质性：部分母猪体温偏差显著升高，部分则变化相对平缓，体现出个体在发情生理调节上的差异性。

4 结束语

提出了基于低成本电子耳标的母猪发情自动预测方法,在浙江华腾牧业有限公司 311 头母猪数据验证集上准确率为 83.91%,AUC 值为 0.839 0,性能显著优于对比模型。所提出的小时平均体温重采样策略有效缓解了过拟合风险,提升了模型预测精度。提出的“强制子代迭代”(FOI)机制,改进了 GA 在收敛速度和避免局部最优方面的不足,有效提升了模型收敛效率和预测精度。然而,本文仍存在若干局限性:数据集仅来自单一牧场且在时间维度上覆盖有限,可能影响模型跨区域和跨品种泛化能力;当前模型仅基于单模态体温数据,尚未融合其他潜在有效的生理或行为特征并且未划分母猪品种做发情预测;电子耳标采集过程中产生的数据噪声尚未建立系统性的处理机制。此外,该模型具有较低的硬件成本和较高的预测精度,展现出良好的实际应用潜力。通过与传统的人工查情方式相结合,可以有效减少养殖场重复性劳动强度,提升管理效率和经济效益。

参 考 文 献

[1] GODFRAY H C J, GARNETT T. Food security and sustainable intensification[J]. Philosophical Transactions of the Royal Society B: Biological Sciences, 2014, 369(1639): 20120273.

[2] BERCKMANS D. Precision livestock farming (PLF)[J]. Computers and Electronics in Agriculture, 2008, 62(1): 1.

[3] RIAZ U, IDRIS M, AHEMD M, et al. Infrared thermography as a potential non-invasive tool for estrus detection in cattle and buffaloes[J]. Animals, 2023, 13(8): 1425.

[4] ADENUGA A H, JAACK C, OLAGUNJU K O, et al. Economic viability of adoption of automated oestrus detection technologies on dairy farms: a review[J]. Animals, 2020, 10(7): 1241.

[5] 薛鸿翔,沈明霞,刘龙申,等. 基于改进 YOLO v5s 的经产母猪发情检测方法研究[J]. 农业机械学报,2023,54(1):263 - 270.
XUE Hongxiang, SHEN Mingxia, LIU Longshen, et al. Estrus detection method of parturient sows based on improved YOLO v5s[J]. Transactions of the Chinese Society for Agricultural Machinery,2023,54(1):263 - 270. (in Chinese)

[6] ZHENG H, ZHANG H, SONG S, et al. Automatic detection of sow estrus using a lightweight real-time detector and thermal images[J]. International Journal of Agricultural and Biological Engineering, 2023, 16(3): 194 - 207.

[7] WENG R C. Variations in the body surface temperature of sows during the post weaning period and its relation to subsequent reproductive performance[J]. Asian-Australasian Journal of Animal Sciences, 2019, 33(7): 1138 - 1147.

[8] LEE J H, LEE D H, YUN W, et al. Quantifiable and feasible estrus detection using the ultrasonic sensor array and digital infrared thermography[J]. Journal of Animal Science and Technology, 2019, 61(3): 163 - 169.

[9] KOKETSU Y, TANI S, IIDA R. Factors for improving reproductive performance of sows and herd productivity in commercial breeding herds[J]. Porcine Health Management, 2017, 3(1): 1.

[10] 高开富,桑高丽. 基于生理与行为特征的母猪发情识别研究进展[J]. 中国畜牧杂志,2025,61(9):102 - 108.
GAO Kaifu, SANG Gaoli. Research progress on sows estrus identification based on physiological and behavioral characteristics [J]. Chinese Journal of Animal Science,2025,61(9):102 - 108. (in Chinese)

[11] SHARIFUZZAMAN M, MUN H S, AMPODE K M B, et al. Technological tools and artificial intelligence in estrus detection of sows—a comprehensive review[J]. Animals, 2024, 14(3): 471.

[12] YESTE M, ESTRADA E, PINART E, et al. The improving effect of reduced glutathione on boar sperm cryotolerance is related with the intrinsic ejaculate freezability[J]. Cryobiology, 2014, 68(2): 251 - 261.

[13] GLENCORSE D, GRUPEN C G, BATHGATE R. A review of the monitoring techniques used to detect oestrus in sows[J]. Animals, 2025, 15(3): 331.

[14] LUNO V, GIL L, JEREZ R A, et al. Crystallisation pattern of vestibular mucus and its relation to vestibular electrical resistance in cycling sow[J]. Veterinary Record, 2012, 171(12): 298.

[15] SYKES D J, COUVILLION J S, CROMIAK A, et al. The use of digital infrared thermal imaging to detect estrus in gilts[J]. Theriogenology, 2012, 78(1): 147 - 152.

[16] 王晨阳,胡冰艳,李雨晴,等. 非接触式测温鉴定母猪典型生理状态[J]. 农业工程学报,2022,38(20):149 - 155.
WANG Chenyang, HU Bingyan, LI Yuqing, et al. Identification of the typical physiological state of sows by non-contact temperature measurement[J]. Transactions of the CSAE,2022,38(20):149 - 155. (in Chinese)

[17] KE G, MENG Q, FINLEY T, et al. Lightgbm: a highly efficient gradient boosting decision tree[J]. Advances in Neural Information Processing Systems, 2017, 30:52.

[18] FRUEFMAN J H. Greedy function approximation: a gradient boosting machine[J]. Annals of Statistics, 2001,29(5): 1189 - 1232.

[19] 赵文举, 丁磊, 俞海英, 等. 基于变量优选与机器学习的农田 CO_2 排放通量反演模型研究[J]. 农业机械学报,2025,56(8):398 - 410.
ZHAO Wenju, DING Lei, YU Haiying, et al. Farmland CO_2 emission flux inversion model based on variable optimization and machine learning algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery,2025,56(8):398 - 410. (in Chinese)

[20] LI M, TAO H, LIU M, et al. Study on enhanced fault diagnosis of chiller units in HVAC systems under the imbalanced data environment using GA-Optimized LightGBM[J]. Energy and Buildings, 2025, 330: 115360.

[21] ORUC R, BAKLACIOGLU T. Cruise range modeling of different flight strategies for transport aircraft using genetic algorithms and particle swarm optimization[J]. Energy, 2024, 294: 130917.