



柳苹, 陈金鑫, 沈明霞, 等. 基于 YOLOv8n 的分娩舍母猪姿态识别研究[J]. 南京农业大学学报, 2026, 49(3): 685–696.

Liu L, Chen J X, Shen M X, et al. Research on sow posture recognition in farrowing pens based on YOLOv8n[J]. Journal of Nanjing Agricultural University, 2026, 49(3): 685–696.

基于 YOLOv8n 的分娩舍母猪姿态识别研究

柳苹^{1,4}, 陈金鑫^{2,4}, 沈明霞^{3,4}, 赵茹茜^{1,4}, 刘龙申^{3,4*}

(1. 南京农业大学动物医学院, 江苏 南京 210014; 2. 南京农业大学工学院, 江苏 南京 211800;
3. 南京农业大学人工智能学院, 江苏 南京 211800; 4. 农业农村部养殖装备重点实验室, 江苏 南京 211800)

摘要: [目的] 为提升分娩舍母猪行为监测的智能化水平, 降低新生仔猪死亡率并优化分娩管理效率, 本文提出一种基于 YOLOv8n 模型的母猪姿态识别方法。[方法] 以 32 头分娩舍母猪为研究对象, 采用安装于分娩栏上方的 RGB 摄像头实现全天候视频采集, 构建母猪姿态数据集, 并利用 YOLOv8 模型进行训练与推理, 实现对母猪不同姿态的精准识别。为提升识别结果的连续性与准确性, 引入滑动窗口算法对模型输出进行平滑处理, 并结合时序信息对姿态占比、姿态转换频次及活动量等行为指标进行统计分析, 以评估母猪的健康状态及分娩动态。[结果] YOLOv8n 模型在精确率 (97.5%)、召回率 (96.1%) 与推理速度 ($0.7 \text{ ms} \cdot \text{f}^{-1}$) 等方面表现优异, 实现了准确性与实时性的有效平衡, 满足养殖现场的实时监测需求。滑动窗口方法提升了姿态识别结果的稳定性, 降低了误检率。分析结果表明, 不同栏位母猪的姿态占比存在差异, 部分异常姿态比例较高, 提示潜在健康风险, 以便进行早期干预。分娩前后姿态转换频次的变化可用于辅助预测分娩时间。活动量变化规律可为环境优化提供依据。[结论] 本研究提出的基于 YOLOv8n 的母猪姿态识别方法, 具备高效性与准确性, 能够实现分娩舍母猪的行为异常监测和辅助分娩预警, 为现代化养猪场提供了智能化技术支持, 具有广泛的应用前景。

关键词: 分娩舍母猪; YOLOv8n; 姿态识别; 姿态分析; 异常预警; 计算机视觉技术

中图分类号: S828; TP391.4

文献标志码: A

文章编号: 1000–2030(2026)03–0685–12

Research on sow posture recognition in farrowing pens based on YOLOv8n

LIU Luo^{1,4}, CHEN Jinxin^{2,4}, SHEN Mingxia^{3,4}, ZHAO Ruqian^{1,4}, LIU Longshen^{3,4*}

(1. College of Veterinary Medicine, Nanjing Agricultural University, Nanjing 210014, China;

2. College of Engineering, Nanjing Agricultural University, Nanjing 211800, China;

3. College of Artificial Intelligence, Nanjing Agricultural University, Nanjing 211800, China;

4. Key Laboratory of Livestock Farming Equipment of the Ministry of Agriculture and Rural Affairs, Nanjing 211800, China)

Abstract: [Objectives] To enhance the level of intelligent behavior monitoring in farrowing pens, reduce piglet mortality, and optimize farrowing management efficiency, this paper proposes a sow posture recognition method based on the YOLOv8n model. [Methods] The study involved 32 sows in the farrowing pen, with 24/7 video capture achieved using RGB cameras installed above the farrowing pens. A sow posture dataset was constructed, and the YOLOv8n model was employed for training and inference to accurately recognize different sow postures. To improve the continuity and accuracy of the recognition results, a sliding window algorithm was introduced to smooth the model's output. Additionally, time-series information was used to statistically analyze behavioral metrics such as posture proportions, posture transition frequencies, and activity levels, in order to assess the sows' health status and farrowing dynamics. [Results] The YOLOv8n model demonstrated outstanding performance with precision (97.5%), recall (96.1%), and inference speed ($0.7 \text{ ms} \cdot \text{f}^{-1}$), effectively balancing accuracy and real-time performance to meet the real-time monitoring requirements in farming environments. The sliding window method enhanced the stability of posture recognition results and reduced misdetection rates. Analysis indicated differences in posture proportions among sows in different pens, with a higher proportion of abnormal postures in some, suggesting potential health risks and the need for early intervention. Changes in posture transition frequency before and after farrowing could assist in predicting farrowing time. The activity level change patterns provide a basis for environmental optimization. [Conclusions] The proposed YOLOv8n-based sow posture recognition method is efficient and accurate, capable of monitoring behavioral anomalies and providing early farrowing alerts for sows in the farrowing pens. It offers intelligent technological support for modern pig farms and has broad application prospects.

Keywords: farrowing pen sows; YOLOv8n; posture recognition; posture analysis; anomaly warning; computer vision technology

收稿日期: 2024–12–26

基金项目: 江苏省现代农业项目 (BE2021363)

* 通信作者: 刘龙申, 副教授, 硕导, 研究方向为智慧畜牧, E-mail: liulongshen@njau.edu.cn。

随着畜牧养殖业集约化和规模化程度的不断提高,如何高效监测与管理动物的健康和行为已成为亟待解决的重要问题。母猪的姿态变化是其母性行为的重要外在表现^[1],对其健康状态评估与行为分析具有重要意义。尤其在分娩舍的阶段,实时监控母猪的行为和姿态变化有助于识别潜在的健康问题、辅助分娩时间预测与生产管理优化,从而降低新生仔猪死亡率,提升养殖效益^[2]。在传统养殖模式中,母猪姿态的持续性监测普遍缺失,分娩行为的识别主要依赖人工观察和经验判断。这种方式不仅效率低下,且受制于观察者的主观经验,难以满足在分娩舍进行大规模、实时、精确监测的实际需求^[3]。因此,借助自动化与智能化监测可提升母猪养殖管理水平,具有重要的现实意义与推广价值。

随着养猪业向自动化、智能化方向发展,可穿戴传感器逐渐被应用于母猪行为的检测。闫丽等^[4]利用 MPU6050 传感器提出了一种哺乳期母猪姿态识别方法,结合小波变换与支持向量机对母猪的立、侧、倾姿态进行分类。Thompson 等^[5]利用加速度计结合支持向量机的方法,实现了对母猪的姿态及其变化的识别。传感器还被用于监测母猪分娩前活动量的增加,并可在分娩前 48 或 12 h 提供预警^[6]。近年来,计算机视觉技术被广泛应用于动物行为识别,为畜牧业智能化监测提供了有效的解决方案^[7]。基于深度学习的目标检测与行为识别方法,凭借其高效性与鲁棒性,正逐步在农业与畜牧领域推广应用。当前已有研究将计算机视觉技术应用于动物姿态与行为检测,如牛的采食行为分析^[8]、鸡群的健康监测^[9]等,均取得了一定成果。母猪行为检测相关研究亦逐步展开,涵盖采食、休息、站立等基础行为的识别,为母猪姿态识别提供了理论支持。Lao 等^[3]利用深度图像识别母猪的躺、坐、跪、站及进食等姿态。薛月菊等^[10]以深度视频图像为数据源,利用改进的 Faster R-CNN 算法有效提升了五类姿态的识别精度,识别速度为 $58 \text{ ms} \cdot \text{f}^{-1}$,此后又通过融合 2D-3D 卷积特征的卷积网络利用深度图像识别母猪姿态转换^[11]。施宏等^[12]通过 Kinect 利用深度数据和密度聚类算法有效区分母猪的站姿和卧姿。Yang 等^[13]采用卷积神经网络(CNN)对未经裁剪的深度视频进行哺乳母猪姿态变化监测。然而,传统的基于传感器方法及深度图像作为数据源在检测速度和系统可扩展性方面已难以满足母猪个体识别与养殖规模扩张的实际需求。

目前已有部分研究利用 2D 图像进行母猪姿态识别,Liu 等^[14]利用 Libra R-CNN 对妊娠后期母猪姿态转变特征进行分析,同时又利用 EfficientDet 网络对产床内母猪图像进行深层次特征提取,实现了母猪站、坐、胸卧、侧卧姿态及其侧卧方向的准确识别^[15]。有关结果可作为母猪分娩预测的有效参考,但识别效率仍较低。YOLO(You Only Look Once)系列算法在目标检测领域表现出色,作为单阶段检测方法,其在速度与精度之间实现了良好平衡,尤其适用于实时性要求较高的应用场景。YOLOv8 作为该算法系列的重要升级版本,具备更强的特征提取能力和更高的检测精度,得益于其在网络架构、特征融合与优化策略等方面的改进^[16]。Zhou 等^[17]开发了基于巡检机器人的 YOLOv8 识别算法,实现了对母猪的静态姿态和仔猪行为的检测。上述研究均未覆盖分娩舍母猪全阶段的姿态监测。然而,母猪分娩舍环境复杂,不同养殖企业使用的限位栏规格不一,并且母猪体型较大、遮挡频发,对姿态的快速准确识别带来挑战。当前尚缺乏对分娩舍母猪全周期姿态行为的系统分析,而这对于实现行为监测与异常预警具有重要意义。基于此,本文提出一种基于 YOLOv8 的母猪姿态识别方法,旨在实现对母猪分娩舍全阶段姿态的精准识别,并进一步分析其在分娩与哺乳阶段的姿态变化规律,为分娩预测与健康预警及管理提供数据支持与科学依据。本研究不仅为分娩舍母猪的智能化管理提供了技术路径,也为深度学习技术在畜牧领域的应用拓展了新方向,具有重要的现实意义与推广价值。

1 材料与方法

1.1 试验动物和场地

本试验于 2022 年 7 月 12 日至 8 月 12 日在江苏省镇江市丹阳市康乐农牧有限公司开展。根据企业生产计划及实际情况,选取 32 头妊娠约 107 d 的长大二元母猪作为试验对象,随机分配在 $245 \text{ cm} \times 180 \text{ cm}$ 的母猪分娩栏中饲养。母猪产房整体环境温度 $24 \sim 30 \text{ }^{\circ}\text{C}$,仔猪保温灯的开关状态根据环境温度自动调整。受产房设计因素影响,照明灯全天 24 h 开启。不同母猪的仔猪依据饲养员的经验存在交叉寄养。仔猪及母猪的免疫接种与疾病防控按照企业生产管理规范进行。

1.2 数据收集

视频采集系统主要由摄像机、网络硬盘录像机及交换机构成。RGB 摄像机(DS-2CD3325-I,海康威视)安装在每个限位栏上方 2.3 m 的高度,摄像头距地面 2.2 m,如图 1 所示。每台摄像机通过网线连接供

电与数据传输,并通过固定支架连接至以太网供电(POE)交换机(DS-3E0518P-E,海康威视)。24 h 不间断录制视频数据($25\text{ f}\cdot\text{s}^{-1}$),并将采集到的所有视频数据存储于硬盘录像机(DS-8832N-R8,海康威视)中,采集结束后导入本地计算机备用。

1.3 数据集制作

从所有的视频中随机选取产前与产后某一日的所有栏位的视频,编写 Python 脚本利用 OpenCV 间隔 5 min 截取 1 张图像存储至指定的文件下。接着,编写 Python 脚本利用 SSIM 计算灰度结构相似度,去除结构相似度过高的图片(图 2),以提高制作数据集的质量并减少工作量。使用 Labelimg 开源图像标注软件对母猪姿态数据集进行人工标注,标注工作由 2 人依据标准共同完成,并互相检查核对。将所有标注好的图片按 8:2 的比例划分为训练集与验证集。标注标准参考 Zheng 等^[18]的研究并结合固定式产床进行调整,具体标准及数量如表 1 所示。



图 1 摄像头安装示意图

Fig. 1 Schematic diagram of the camera installation



图 2 图片结构相似度剔除示意图

Fig. 2 Schematic diagram of image structure similarity elimination

“√”表示保留,“×”表示删除。“√”indicates retention,and“×”indicates deletion.

表 1 母猪姿态定义

Table 1 Definitions of sow postures

标签 Label	说明 Description	数量 Numbers	
		训练集 Training set	验证集 Validation set
侧卧 Lateral	完全依靠身体的一边侧卧于地面,四肢都往左或右可见,乳房完全露出可见 Lying completely on one side,with the body resting on the ground, all limbs visible to the left or right,and the teats fully exposed	2 419	637
腹卧 Ventral	依靠胸腹卧于地面,前后脚可折于身下,也可往左或右伸出可见,乳房部分侧漏可见或完全不可见 Lying on the chest and abdomen on the ground,with the front and hind legs folded under the body or extended to the left or right,and the teats partially exposed or completely not visible	1 194	286
坐立 Sit	前腿伸直,尾部接触地面,部分身体立起 Front legs extended,tail in contact with the ground,and part of the body raised	480	126
站立 Stand	身体直立,腿伸直,仅蹄接触地面 Body upright,legs extended,with only the hooves touching the ground	694	148

1.4 算法简介

1.4.1 目标检测算法 YOLO 是一种经典的实时目标检测算法,因其高效性与精度在计算机视觉领域广泛应用。YOLOv8 在前代算法的基础上进行了多项改进,旨在提升检测精度和速度^[16]。相较于 YOLOv5 和 YOLOv6, YOLOv8 在模型架构、训练策略与推理速度等方面进行了显著优化,尤其在精度与效率之间实现了更好的平衡,适用于多种实时应用场景。YOLOv8 的核心优势在于其全新的检测头设计与更高效的网络结构。YOLOv8 通过引入更多高效的卷积操作和改进的激活函数,在保持较低计算复杂度的同时,获得更优的目标检测性能。此外, YOLOv8 在数据增强和损失函数的设计上进行了优化,使模型更加鲁棒,能更好地应对不同的输入条件与环境变化。总之, YOLOv8 不仅继承了 YOLO 系列高效实时检测的优势,还通过技术创新和优化,进一步提升了目标检测精度和推理速度。因此,本研究选取 YOLOv8 作为目标检测工具。

1.4.2 程序环境 模型训练平台使用深度学习主机,处理器为 intel i9-13900KF, GPU 为 NVIDIA RTX 4090 显卡, 64 GB DDR5 内存, 操作系统为 Ubuntu 22.04。在 Pytorch 深度学习框架上进行模型训练。模型训练参数设置如下: 训练最大轮次为 300, 初始学习率为 0.01, 批量大小为 32, 权重衰减系数为 0.000 5, 动量为 0.937。

1.4.3 姿态判别及数据平滑 在母猪产床限位栏中, 猪只的姿态变化较为缓慢, 但由于误检等因素, 姿态数据可能出现短期波动。为了解决这一问题, 采用了滑动窗口方法对数据进行平滑处理。将数据按时间戳排序, 确保姿态变化的顺序符合实际情况。使用固定长度的滑动窗口 (window_length) 对每个时间点的数据进行处理, 窗口包含当前时刻及其前后若干个时刻的姿态数据。在窗口内, 统计各个姿态的出现频次, 并选择频次最高的姿态作为该时间点的平滑结果。对于每个时间点 i , 其计算公式为

$$\text{window}(i) = \{p_{i-\text{window_length}}, \dots, p_i, \dots, p_{i+\text{window_length}}\} \quad (1)$$

$$\text{freq}(p_j) = \text{count}(p_j \text{ in } \text{window}(i)) \quad (2)$$

$$\hat{p}_i = \text{argmax}(\text{freq}(p_j)) \quad (3)$$

式中: $\text{window}(i)$ 为以第 i 个时间点为中心构建的滑动窗口; window_length 为滑动窗口半宽, 即当前时刻前后所包含的时间点数; i 为当前时间点的序号; j 为滑动窗口内姿态数据的序号; $\hat{p}_i$ 为第 i 个时间点经滑动窗口平滑处理后得到的姿态类别; p_j 为滑动窗口内第 j 个姿态类别; $\text{freq}(p_j)$ 为姿态在滑动窗口中的出现频次; $\text{count}()$ 为计数函数; argmax 表示取使目标函数达到最大值时对应的姿态类别。

若窗口内的姿态分布异常, 可以通过设定阈值来忽略异常数据。经过滑动窗口平滑处理后, 姿态数据变得更加连续稳定, 去除了误检影响, 更准确地反映了猪只的实际状态。

1.4.4 母猪活动量的计算 母猪活动量的计算基于目标检测框中心点的位移变化。通过位置坐标获取每帧中的中心点坐标 (x_c, y_c), 公式如下:

$$x_c = \frac{x_{\min} + x_{\max}}{2}, y_c = \frac{y_{\min} + y_{\max}}{2} \quad (4)$$

式中: $x_{\min}, y_{\min}$ 为检测框左上角的坐标; $x_{\max}, y_{\max}$ 为检测框右下角的坐标。

在每两帧之间, 计算中心点的欧氏距离变化 (Δd_i), 公式如下:

$$\Delta d_i = \sqrt{(x_{c,i} - x_{c,i-1})^2 + (y_{c,i} - y_{c,i-1})^2} \quad (5)$$

累加所有帧的位移变化即得到活动量:

$$\text{Activity} = \sum_{i=2}^N \Delta d_i \quad (6)$$

式中: i 表示帧编号; N 是总帧数。

1.5 数据分析与处理

检测视频所用的工作站配置: Dell T640 工作站, 处理器为 Intel Xeon 5118 * 2, GPU 为 NVIDIA Tatin V 显卡, 256 GB DDR4 内存, 操作系统为 Ubuntu 22.04。数据平滑与图像绘制使用 R 语言 (Version 4.3.2)。使用的视频数据量约为 20.6 TB, 每间隔 5 s 检测 1 张图片, 共产生 17 622 181 条结果。

2 结果与分析

2.1 目标检测模型分析

2.1.1 模型训练结果 目标检测模型的训练结果如图3所示。所有模型的 Box_loss 曲线在训练过程中呈下降趋势,初期较高的值表明模型对目标框定位的准确性低,后期趋近低值表明模型在目标框定位能力得到优化。训练初期各模型的 Cls_loss 值较高,反映模型初期分类能力较弱,随着训练进展,该值持续下降并在末期收敛至较低水平,表明模型在目标类别分类方面显著进步。训练初期各模型的 Dfl_loss 值较高,随着训练轮次增加,曲线逐渐下降并在末期趋于稳定且较低,表明模型在边界框回归问题上得到有效优化。总体来看,YOLOv8 系列模型在这 300 个训练轮次内,在目标框定位、目标分类与边界框回归方面性能显著提升,损失值逐渐降低且趋于稳定,表现出良好的训练收敛性。




图3 训练过程 loss 曲线

Fig. 3 Loss curve during training

模型训练过程的验证结果如图4所示。所有架构的曲线在迭代次数 0~300 内波动变化,精确率取值为 0~1.0,最终曲线趋于平稳。各模型曲线在训练过程中也有波动,召回率取值为 0~1.0,且在训练后期逐渐趋于稳定。训练开始时各架构的值较低且波动明显,mAP@0.5 为 0~1.0,随着训练轮次增多,曲线上并趋于稳定。各架构曲线在训练初期值低且波动大,mAP@0.5:0.95 为 0~1.0,训练后期曲线上并趋




图4 模型测试结果

Fig. 4 Model testing results

于平稳。总体来看,YOLOv8 系列模型在这 300 个训练轮次内,上述 4 种性能指标都从波动状态逐渐趋于稳定。

2.1.2 模型测试结果 表 2 中展现了 YOLOv8 系列(包括 v8n、v8s、v8m、v8l 和 v8x)在多个性能指标与计算资源需求的对比结果。从各项指标来看,所有模型在精确率(Precision)、召回率(Recall)和平均精度均值(mAP@ 0.5 和 mAP@ 0.5:0.95)方面均表现出色。各模型精确率区间处于 96.1%~97.5%,其中 YOLOv8n 以 97.5%领先;召回率为 96.1%~98.2%,v8l 以 98.2%达到最高值;mAP@ 0.5 指标为 98.7%~99.0%,v8s 以 99.0%占据优势;mAP@ 0.5:0.95 为 89.8%~91.4%,v8x 以 91.4%为最高。

表 2 目标检测模型测试指标
Table 2 Object detection model test metrics

模型 Model	精确率/% Precision	召回率/% Recall	平均精度均值/% mAP@ 0.5	平均精度均值/% mAP@ 0.5:0.95	浮点运算次数 GFLOPs	推理速度/(ms·f ⁻¹) Inference speed
YOLOv8n	97.5	96.1	98.7	89.8	8.1	0.7
YOLOv8s	96.1	97.9	99.0	91.2	28.4	1.1
YOLOv8m	96.7	97.2	98.8	91.0	78.7	2.1
YOLOv8l	96.8	98.2	98.7	91.1	164.8	2.9
YOLOv8x	96.9	97.6	98.8	91.4	257.4	4.1

在计算资源需求方面,YOLOv8n 浮点运算数(GFLOPs)仅需 8.1,远低于其他模型,同时其推理速度(Speed)仅为 0.7 ms·f⁻¹,是所有模型中最快的。综合考虑,YOLOv8n 是一个理想的选择。其精确率高,能确保目标识别的准确性;召回率也较高,保证了目标发现的完整性。虽然在 mAP@ 0.5:0.95 这一指标上略逊于部分模型,但整体性能可靠。更重要的是,YOLOv8n 在计算资源需求和推理速度上具有显著优势,这使其非常适用于计算资源有限且对实时性要求高的应用场景,例如边缘计算设备或移动设备中的目标检测任务,能够在确保快速稳定运行的同时提供良好的检测性能。

2.1.3 模型对比结果 为进一步验证 YOLOv8n 在目标检测任务中的优越性,对比不同模型的检测性能,评价指标包括精确率、召回率、mAP 和 GFLOPs 及推理速度,结果如表 3 所示。在 mAP@ 0.5 指标上,YOLOv8n 与 YOLOv5n 均达到 98.7%,优于 YOLOv6n(98.3%)和 YOLOv3(98.5%),同时显著优于 RT-DETR-L(97.4%)。在更严格的 mAP@ 0.5:0.95 指标上,YOLOv8n 达到 89.8%,相比 YOLOv5n(89.1%)和 YOLOv6n(88.6%)仍具有明显优势,仅次于 YOLOv3(90.9%),但后者计算复杂度较高。YOLOv8n 在精确率(97.5%)及召回率(96.1%)上表现稳定且优异,相比 YOLOv6n(96.7%,95.6%)和 YOLOv5n(97.5%、95.2%),具有更好的平衡性,能够在保持高精度的同时确保较高的召回率。而 RT-DETR-L(97.8%、97.7%)在召回率方面表现更好,但 mAP 整体不及 YOLOv8n。YOLOv8n 仅需 8.1 GFLOPs,相较于 YOLOv6n(11.8 GFLOPs)计算复杂度更低,推理速度仅需 0.7 ms·f⁻¹,快于 YOLOv6n(0.8 ms·f⁻¹)和 YOLOv3(4.9 ms·f⁻¹),并且远低于 RT-DETR-L(3.5 ms·f⁻¹、103.4 GFLOPs),表明其计算效率更高,适用于资源受限的实时检测任务。

表 3 不同模型对目标检测的评价结果
Table 3 Evaluation results of different models for object detection

模型 Model	精确率/% Precision	召回率/% Recall	平均精度均值/% mAP@ 0.5	平均精度均值/% mAP@ 0.5:0.95	浮点运算次数 GFLOPs	推理速度/(ms·f ⁻¹) Inference speed
YOLOv8n	97.5	96.1	98.7	89.8	8.1	0.7
YOLOv6n	96.7	95.6	98.3	88.6	11.8	0.8
YOLOv5n	97.5	95.2	98.7	89.1	7.1	0.6
YOLOv3	96.4	97.9	98.5	90.9	282.2	4.9
RTDETR-L	97.8	97.7	97.4	88.8	103.4	3.5

YOLOv8n 在保证高检测精度(mAP@ 0.5=98.7%,mAP@ 0.5:0.95=89.8%)的同时,实现了更快的推理速度(0.7 ms·f⁻¹)和较低的计算复杂度(8.1 GFLOPs),优于 YOLOv6n 和 YOLOv5n,并在速度与精度的平衡性上显著优于 YOLOv3 和 RT-DETR-L。因此,YOLOv8n 在目标检测任务中展现出最佳的综合性能,尤其适用于对实时性要求较高的应用场景。

2.1.4 检测结果可视化 为验证模型的鲁棒性,对检测图片进行了数据增强变换手段,模拟养殖场中真实存在的情况,如摄像头旋转、画面抖动模糊、光暗变化和噪声等。图 5 展示了 YOLOv8n 模型检测结果的

可视化效果,包括目标框的定位、分类和置信度评分。每个目标的检测框均准确地标注在对应物体上,展示了模型在不同情况下和姿态下的有效检测能力。模型能够精确地识别目标位置,体现了其在定位方面的优异表现。此外,图中的分类标签和置信度分数进一步验证了模型在目标识别任务中的可靠性,结果准确且与实际情况匹配。整体而言,检测结果的可视化展示了模型在实际应用中对复杂场景的适应性及其高效检测能力,表明该模型在目标识别任务中的优异性能。




图5 目标检测可视化

Fig. 5 Object detection visualization

2.1.5 误检分析 尽管该模型具有优异的检测性能,但仍有部分误检的图片存在。图6展示了4种可能导致误检情况。图6-a展示了母猪的腹卧姿态被识别为坐立,猪只前肢清晰可见,肩部与臀部无明显高度差;图6-b展示了母猪的坐立被误识别为站立,猪只肩部与臀部高度差明显且臀部明显宽于肩部,与站立姿态定义不符;图6-c展示了母猪的坐立被误识别为腹卧,猪只肩部与臀部高度差明显且臀部明显宽于肩部,前肢不可见,明显符合坐立姿态;图6-d展示了侧卧被误识别为腹卧,母猪乳房清晰可见,三肢均明显可见且无弯曲,符合侧卧姿态。首先,图像中的角度和视角可能对模型的识别造成干扰。例如,在图6-a和图6-d的误检中,部分猪只的姿势可能由摄像角度变化导致前肢、肩部或臀部的视觉特征模糊,从而使模型难以准确区分不同姿态。其次,图像中的遮挡与不完整目标也可能导致误识别。在图6-c中,由于前肢被遮挡,模型未能捕捉到完整目标特征,误将坐立姿势识别为腹卧姿态。此外,模型在处理姿态分类时可能受限于训练数据的多样性导致误判,某些特定的姿态变化可能未能在训练过程中被充分覆盖。姿态识别模型在处理复杂的动态变化时,可能由于特征提取不足或训练样本偏差,未能准确捕捉到细微的姿势差异。




图 6 误检分析

Fig. 6 False detection analysis

2.2 滑窗算法的选择

在母猪产床限位栏中,猪只的姿态变化通常较为缓慢。对于个别误检的情况,可采用滑动窗口方法对姿态进行平滑处理,从而减少错误分类的影响,使统计结果更加连续,且更接近真实的姿态变化。如图 7-a 所示,随机选择的一段真实的序列,经过不同长度的窗口平滑均可去除噪声,且在大量的观察中,此类示例占绝大多数。如图 7-b 所示,经过不同长度的窗口平滑,获得了不同的统计序列,窗口长度越大,结果越为平滑连续。然而,较长的滑动窗口也会掩盖部分真实值,滤掉过多的中间姿态,由于猪只运动缓慢,当窗口长度为 4 时足以应对绝大多数复杂序列的平滑。因此,选择窗口长度为 4 进行后续的数据统计与分析。平滑后的姿态虽然未与真实序列一致,这可能是由程序的计算算法导致,算法以图片帧作为计算时间的标志,真实序列的观察以视频时间戳作为时间标志,但不影响姿态转换次数,并有效地过滤了噪声。




图 7 滑动窗口示意图

Fig. 7 Schematic of sliding window

"0" = "Lateral"; "1" = "Stand"; "2" = "Sit"; "3" = "Ventral".

2.3 行为分析

2.3.1 姿态占比 为研究母猪在分娩舍中的健康状况与行为特征,随机选取2022年8月6日的姿态数据进行分析。通过对各栏位猪只的姿态占比及全舍姿态分布进行可视化与统计分析,探讨其行为差异及健康异常特征。图8展示了分娩舍内所有栏位母猪在单日内各姿态(侧卧、腹卧、坐姿、站立)的占比,颜色代表不同姿态。结果显示侧卧为母猪最主要的姿态。第10栏母猪的坐姿占比异常高(17.94%),且站立姿态几乎不可见(0.06%)。这种异常行为与其他栏位母猪存在显著差异。第10栏母猪姿态分布的显著异常可能表明其存在健康问题,如腿部疼痛或活动受限,导致其长时间保持坐姿,几乎无法站立。建议对第10栏母猪进行健康预警,饲养员应对其进行驱赶观察或体检,排查潜在健康问题。




图8 不同栏位单日姿态占比

Fig.8 Proportion of sow postures in different pens

图9展示了编号为07栏母猪在分娩舍整个周期内的姿态占比变化。侧卧是母猪的主要姿态,除分娩前占比外在整个周期内始终保持在60%以上。分娩前1d,侧卧占比显著下降,坐姿和站立占比大幅上升。分娩后,母猪的侧卧占比迅速恢复至较高水平。分娩前1d的姿态变化表明母猪可能表现出筑巢行为,包括更多的起卧和站立动作。姿态占比的动态变化可作为分娩预警的重要特征,为开发母猪分娩预警系统提供数据支持。分娩后母猪恢复侧卧为主姿态模式,表明其行为逐渐恢复到稳定状态。




图9 单栏全周期姿态占比(栏位:07)

Fig.9 Proportion of sow postures across the entire cycle in pen 07

2.3.2 姿态转换次数 图10展示了编号09的栏位母猪在分娩日(2022年7月19日)的姿态变化及转换情况。图10的上半部分显示了母猪在1d内不同时间的姿态分布(包括侧卧、腹卧、坐姿和站姿),下半部分为姿态转换次数的随时间分布(以小时为区间),颜色深浅表明姿态转换频率的高低。从凌晨至清晨(00:00—07:00),母猪的姿态变化较为频繁,这是因为母猪在分娩前表现出明显的筑巢行为,其典型表现

为频繁切换姿态^[19],即使在分娩限位栏条件下仍有所体现^[20]。从上午到下午(08:00—15:00),母猪以侧卧为主,姿态转换次数相对减少。在 16:00 后,母猪的姿态基本保持为侧卧,表明此时母猪可能处于分娩阶段,活动减少。在凌晨(00:00—06:00),姿态转换次数较高,与筑巢行为相关。母猪在分娩前表现出更频繁的起卧和移动行为。在 16:00 后,姿态转换次数迅速减少,表明母猪进入分娩阶段,行为趋于安静。




图 10 单日单栏姿态分布及姿态转换次数(2022-07-19,栏位:09)

Fig. 10 Sow posture distribution and posture transition counts in a single pen (July 19, 2022, Pen:09)

图 11 展示了分娩舍中所有母猪在全周期范围内的每日姿态转换次数分布情况。颜色越深,表示对应栏位母猪在该日期的姿态转换次数越高;颜色越浅,表示该日期的姿态转换较少,甚至没有数据记录。热图中可以清晰地看到,在分娩前几天(7 月 12—20 日),多个栏位(如编号 09、20 和 27 栏)显示出颜色加深,表明母猪姿态转换次数明显增加。这与分娩前母猪的筑巢行为密切相关,属于母猪在准备分娩时典型的生理反应。具体而言,筑巢行为包括频繁的起卧、站立和侧卧等姿态切换,这些行为导致姿态转换频率大幅上升。分娩后大部分母猪的姿态转换次数显著减少,热图逐渐变为浅绿色,反映了分娩后母猪趋于安静的状态。这种行为是由于母猪开始专注于哺乳和恢复,表现出更少的起卧和移动。从栏位对比中可以发现,不同栏位的母猪姿态转换频率存在差异。例如,部分栏位的母猪(如编号 20 栏和 27 栏)姿态转换频率显著高于其他栏位,可能因素包括:1) 健康状况:焦躁或不适可能引发更多的姿态切换。2) 环境影响:如栏位位置的温度、光照或噪声差异。3) 个体差异:包括母猪的性格或体型等。热图右下角(如编号 06 栏的后期数据)显示数据缺失。这是因为 06 栏母猪因意外死亡导致记录中断。类似情况需在后续分析中剔除,避免对整体结果造成误导。




图 11 全舍全周期姿态转换次数

Fig. 11 Total number of posture transitions across the entire cycle across the entire house

2.3.3 运动距离及轨迹 为评估母猪在限位栏中的活动量和轨迹,结合目标检测到的位置信息,进行了运动情况的可视化展示与统计分析。图 12 展示了编号 03 栏位母猪在特定时间(00:00—01:00)的运动轨迹图,蓝色矩形展示了其中 1 张图像的检测结果,颜色区分了不同的姿态(如侧卧、站立、腹卧)。母猪的轨迹主要集中在限位栏中央区域,轨迹密集处表明母猪在该范围内存在较频繁的活动。由于限位栏的物理结构限制,母猪的轨迹范围较小,活动模式主要表现为短距离移动和姿态切换。不同颜色的轨迹点(如站立、腹卧)显示了母猪在运动过程中不同姿态的切换行为,这与筑巢和短时运动特征一致。运动轨迹密集的区域展示了母猪在栏内中部的活动频率最高,这可能是由于该区域相对舒适(如躺卧区域)。




图12 单日单栏1 h活动轨迹(2022-08-01 00:00-01:00,栏位:03)

Fig. 12 One-hour activity trajectory in a single pen(August 1,2022 00:00-01:00, Pen:03)

图13展示了全舍范围内所有母猪在分娩周期内的活动量分布。深蓝色区域表示高活动量,浅黄色区域表示低活动量。热图中可以看到不同栏位母猪活动量差异明显,部分栏位母猪的活动量远高于平均水平,而其他栏位则较为安静。可能原因包括:1)健康状况:焦躁、不适或疾病引发异常行为(如站立、重复动作)。2)环境差异:特定栏位的温度、湿度或噪声条件可能对母猪行为产生影响。3)个体特性:不同母猪在母性上的差异(拒绝哺乳频繁切换为非侧卧状态)。




图13 全舍全周期活动量统计

Fig. 13 Activity statistics across the entire house throughout the cycle

3 结论

本研究针对畜牧养殖业中母猪健康与行为监测的需求,提出了一种基于YOLOv8n的母猪姿态识别和活动量计算方法,结合时序姿态分析与滑动窗口算法,对母猪在分娩舍中的行为特征进行了深入研究。研究表明,YOLOv8n在准确率和速度上达到最佳平衡,适用于对实时性要求高的边缘计算场景。虽然检测结果存在一定误检现象,但通过滑动窗口算法可有效过滤噪声,提高检测结果的连续性和可靠性。批量数据检测显示母猪的侧卧为主要姿态,分娩前筑巢行为表现出明显的姿态变化特征,为分娩预警提供了重要依据。母猪姿态数据的异常分析为其健康问题的预警提供了可靠手段。异常姿态占比和高频姿态转换次数可作为健康问题及分娩预警的重要指标,为优化管理实践提供了科学支持。未来研究将进一步优化目标检测模型,增加多样化训练数据,并开发基于姿态动态变化的智能预警系统,为分娩舍母猪的自动化管理和健康监测提供更高效的解决方案。

参考文献 References:

- [1] Marchant J N, Broom D M, Corning S. The influence of sow behaviour on piglet mortality due to crushing in an open farrowing system[J].

- Animal Science, 2001, 72(1): 19–28.
- [2] Wang J S, Wu M C, Chang H L, et al. Predicting parturition time through ultrasonic measurement of posture changing rate in crated Landrace sows[J]. Asian-Australasian Journal of Animal Sciences, 2007, 20(5): 682–692.
- [3] Lao F, Brown-Brandl T, Stinn J P, et al. Automatic recognition of lactating sow behaviors through depth image processing[J]. Computers and Electronics in Agriculture, 2016, 125: 56–62.
- [4] 闫丽, 沈明霞, 姚文, 等. 基于 MPU6050 传感器的哺乳期母猪姿态识别方法[J]. 农业机械学报, 2015, 46(5): 279–285.
Yan L, Shen M X, Yao W, et al. Recognition method of lactating sows' posture based on sensor MPU6050[J]. Transactions of the Chinese Society for Agricultural Machinery, 2015, 46(5): 279–285 (in Chinese with English abstract).
- [5] Thompson R, Matheson S M, Plötz T, et al. Porcine lie detectors: automatic quantification of posture state and transitions in sows using inertial sensors[J]. Computers and Electronics in Agriculture, 2016, 127: 521–530.
- [6] Traulsen I, Scheel C, Auer W, et al. Using acceleration data to automatically detect the onset of farrowing in sows[J]. Sensors, 2018, 18(1): 170.
- [7] Rohan A, Rafiq M S, Hasan M J, et al. Application of deep learning for livestock behaviour recognition: a systematic literature review[J]. Computers and Electronics in Agriculture, 2024, 224: 109115.
- [8] Porto S M C, Arcidiacono C, Anguza U, et al. The automatic detection of dairy cow feeding and standing behaviours in free-stall barns by a computer vision-based system[J]. Biosystems Engineering, 2015, 133: 46–55.
- [9] Bhuiyan M R, Wree P. Animal behavior for chicken identification and monitoring the health condition using computer vision: a systematic review[J]. IEEE Access, 2023, 11: 126601–126610.
- [10] 薛月菊, 朱勋沐, 郑婵, 等. 基于改进 Faster R-CNN 识别深度视频图像哺乳母猪姿态[J]. 农业工程学报, 2018, 34(9): 189–196.
Xue Y J, Zhu X M, Zheng C, et al. Lactating sow postures recognition from depth image of videos based on improved Faster R-CNN[J]. Transactions of the Chinese Society of Agricultural Engineering, 2018, 34(9): 189–196 (in Chinese with English abstract).
- [11] 薛月菊, 李诗梅, 郑婵, 等. 融合 2D–3D 卷积特征识别哺乳母猪姿态转换[J]. 农业工程学报, 2021, 37(9): 230–237.
Xue Y J, Li S M, Zheng C, et al. Osture change recognition of lactating sow by using 2D-3D convolution feature fusion[J]. Transactions of the Chinese Society of Agricultural Engineering, 2021, 37(9): 230–237 (in Chinese with English abstract).
- [12] 施宏, 沈明霞, 刘龙申, 等. 基于 Kinect 的哺乳期母猪姿态识别算法的研究[J]. 南京农业大学学报, 2019, 42(1): 177–183. DOI: 10.7685/jnau.201803025.
Shi H, Shen M X, Liu L S, et al. Study on recognition method of lactating sows' posture based on Kinect[J]. Journal of Nanjing Agricultural University, 2019, 42(1): 177–183 (in Chinese with English abstract).
- [13] Yang X F, Zheng C, Zou C H, et al. A CNN-based posture change detection for lactating sow in untrimmed depth videos[J]. Computers and Electronics in Agriculture, 2021, 185: 106139.
- [14] Liu L S, Zhou J, Zhang B, et al. Visual detection on posture transformation characteristics of sows in late gestation based on *Libra* R-CNN[J]. Biosystems Engineering, 2022, 223: 219–231.
- [15] 刘龙申, 舒翠霓, 李波, 等. 基于 EfficientDet 的围产期母猪姿态识别[J]. 农业机械学报, 2022, 53(4): 271–279.
Liu L S, Shu C N, Li B, et al. Recognition of perinatal sows' posture based on EfficientDet algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(4): 271–279 (in Chinese with English abstract).
- [16] Jocher G, Chaurasia A, Qiu J. Ultralytics YOLOv8[EB/OL]. [2026–04–03]. <https://github.com/ultralytics/ultralytics>.
- [17] Zhou J, Liu L, Jiang T, et al. A novel behavior detection method for sows and piglets during lactation based on an inspection robot[J]. Computers and Electronics in Agriculture, 2024, 227: 109613.
- [18] Zheng C, Zhu X M, Yang X F, et al. Automatic recognition of lactating sow postures from depth images by deep learning detector[J]. Computers and Electronics in Agriculture, 2018, 147: 51–63.
- [19] Jensen P. Observations on the maternal behaviour of free-ranging domestic pigs[J]. Applied Animal Behaviour Science, 1986, 16(2): 131–142.
- [20] Wischner D, Kemper N, Krieter J. Nest-building behaviour in sows and consequences for pig husbandry[J]. Livestock Science, 2009, 124(1): 1–8.

责任编辑: 刘怡辰