

# 基于 EL – YOLO v8n 的轻量化群养猪只姿态识别与跟踪方法

张 稳<sup>1,2</sup> 张鑫哲<sup>1</sup> 张在莹<sup>1</sup> 林 海<sup>3</sup> 施正香<sup>4</sup> 傅生辉<sup>1,2</sup>

(1. 山东农业大学机械与电子工程学院, 泰安 271018;

2. 山东农业大学山东省设施园艺智慧生产技术装备重点实验室(筹), 泰安 271018;

3. 山东农业大学动物科技学院, 泰安 271018; 4. 中国农业大学水利与智能工程学院, 北京 100083)

**摘要:** 针对复杂群养环境下不同日龄生猪姿态复杂、个体相似度高及相互遮挡导致的检测精度低和跟踪难等问题, 本文提出一种基于 EL – YOLO v8n 的轻量化群养生猪姿态识别跟踪方法。在 YOLO v8n 模型基础上引入 EfficientRepBiFusion 结构增强多尺度特征融合, 设计 LSDGCD 轻量化检测头提升特征提取能力, 同时采用优化的 EIoU 损失函数提高正样本的学习效果。在轨迹跟踪方面, 结合 ByteTrack 算法实现了复杂场景下猪只身份保持和连续性跟踪, 有效减少因遮挡和姿态切换带来的 ID 切换和漏检。试验结果表明, 该模型对群养猪只的站立、躺卧、犬坐和趴卧等姿态识别精确率分别为 98.7%、93.2%、99.3% 及 92.3%, 与 YOLO v8n 相比, 平均检测精确率提升 6.24%, 召回率提升 7.61%, mAP@0.5 提升 8.49%, 参数量降低 15.28%, 模型内存占用量仅 5.45 MB; 与 ByteTrack 结合, IDF1 达到 90.7%, MOTA 和 HOTA 分别为 88.6% 和 66.2%, 优于 DeepSORT 和 BoT – SORT。该模型基于 Jetson Nano 在猪场侧边缘部署, 实现了猪只姿态的持续检测跟踪, 为生猪智慧养殖管理提供了技术支撑。

**关键词:** 猪只姿态识别跟踪; EL – YOLO v8n; 轻量化; 智慧养殖; 边缘部署

中图分类号: TP391.4

文献标识码: A

文章编号: 1000-1298(2026)14-0298-09

OSID:



## Lightweight Method for Group-housed Pig Pose Recognition and Tracking Based on EL – YOLO v8n

Zhang Wen<sup>1,2</sup> Zhang Xinzhe<sup>1</sup> Zhang Zaiying<sup>1</sup> Lin Hai<sup>3</sup> Shi Zhengxiang<sup>4</sup> Fu Shenghui<sup>1,2</sup>

(1. College of Mechanical and Electronic Engineering, Shandong Agricultural University, Taian 271018, China

2. Key Laboratory of Smart Production Technology and Equipment for Facility Horticulture in Shandong Province (Proposed), Shandong Agricultural University, Taian 271018, China

3. College of Animal Science and Technology, Shandong Agricultural University, Taian 271018, China

4. College of Water Resources and Intelligence Engineering, China Agricultural University, Beijing 100083, China)

**Abstract:** Aiming to address the problems of low detection accuracy and difficult tracking caused by complex postures, high individual similarity and mutual occlusion of group-housed pigs, a lightweight pose recognition and tracking method for pigs based on an EL – YOLO v8n model was proposed. On the basis of YOLO v8n, EfficientRepBiFusion (ERB) structure was introduced to enhance multi-scale feature fusion, a lightweight LSDGCD detection head was designed to improve feature extraction capability, and an optimized EIoU loss function was adopted to enhance the learning effect of positive samples. In trajectory tracking, ByteTrack was integrated to achieve identity maintenance and tracking continuity of pigs, effectively reducing ID switches and missed detections caused by occlusion and pose switching. Experimental results showed that in the pose detection of pigs, the recognition accuracies of the proposed model for standing, lying, sitting and sprawling postures were 98.7%, 93.2%, 99.3% and 92.3%, respectively. Compared with YOLO v8n, the average detection accuracy of the model was improved by 6.24%, the recall rate was increased by 7.61%, the mean average precision (mAP@0.5) was raised by 8.49%, the number of parameters was reduced by 15.28%, and the model memory footprint was only 5.45 MB. When combined with ByteTrack, the model attained an IDF1 of 90.7%, with multiple object

收稿日期: 2026-01-22 修回日期: 2026-02-27

基金项目: 山东省重点研发计划项目(2024TZXD014)和山东省自然科学基金青年项目(ZR2022QE141)

作者简介: 张稳(1988—), 女, 副教授, 博士, 主要从事智能畜牧装备与环境调控技术研究, E-mail: wenzhang\_098@sdau.edu.cn

通信作者: 傅生辉(1989—), 男, 副教授, 博士, 主要从事智能农机装备与车辆电子控制技术研究, E-mail: fush@sdau.edu.cn

tracking accuracy (MOTA) and higher order tracking accuracy (HOTA) reaching 88.6% and 66.2% respectively, outperforming that of DeepSORT and BoT - SORT. The model realized edge deployment at pig farms by Jetson Nano, enabling continuous detection and tracking of the pig postures, which provided technical support for group-housed pig intelligent breeding.

**Key words:** pig pose recognition and tracking; EL - YOLO v8n; lightweight; intelligent breeding; edge deployment

0 引言

群养猪姿态识别与跟踪技术是生猪智慧养殖的核心技术。群养模式下通过猪只姿态变化实时连续监测,可精准捕捉健康异常、应激反应、发情行为等关键信息,从而实现养殖全周期的健康风险早期预警、发情精准判定与应激及时干预,同时,该技术可为猪舍环境智能调控、生猪精准饲喂、生长状况动态评估提供关键数据支撑,既能显著降低人工巡检成本与养殖损耗,保障养殖全流程的标准化与可追溯性,又能推动生猪养殖产业降本增效,助力规模化养殖向智能化、精细化方向转型升级<sup>[1-5]</sup>。

目前,猪只姿态检测多以机器视觉技术为核心手段,该方法可有效规避传统检测方式易引发动物应激的问题<sup>[6-10]</sup>。文献[11-13]分别基于 YOLO 系列模型进行优化,实现了单一环境下猪只行为的有效检测。然而,在复杂群养环境下猪只行为的检测方法仍存在诸多局限,很大程度上制约了猪只行为模式的深度分析和精细化管理工作的进一步推进。因此,猪只行为检测与跟踪技术成为当前研究热点,典型多目标跟踪方法 DeepSORT、BoT - SORT 和 ByteTrack 等已在动物和人类目标跟踪中得到广泛应用<sup>[14-17]</sup>。在动物跟踪相关应用中,研究方向涵盖多摄像头跟踪、实时识别跟踪等,部分研究通过模型改进与通道剪枝技术,在保证监测效果前提下实现轻量化,兼顾检测精度与运行效率<sup>[18-21]</sup>。上述研究表明,行为检测跟踪技术能够在复杂场景维持目标个体身份的连续性,降低轨迹中断概率,可为动物行为定量分析提供可靠技术支撑。但群养猪只姿态识别与跟踪研究仍存在以下问题:①现有猪只姿态检测模型仅适配单一简单环境,难以应对复杂群养场景下猪只频繁遮挡、个体外观相似度高难题。②现有技术尚未有效解决群养场景中猪只姿态切换导致的检测漏检等问题,难以实现姿态的连续识别与稳定跟踪,且模型轻量化设计不足,无法兼顾复杂场景检测需求与边缘设备部署要求。

针对上述问题,本文提出一种基于 EL - YOLO v8n 的轻量化群养猪姿态识别跟踪方法。该方法融合 EfficientRepBiFusion(ERB)骨干网络、LSDGCD 轻量化检测头和 ByteTrack 算法,解决因遮挡和姿态

切换带来的猪只 ID 切换和漏检,以期实现复杂场景下猪只姿态持续识别跟踪,为生猪智慧养殖管理提供技术支持。

1 数据采集与预处理

1.1 数据采集

数据采自山东省泰安市某猪场。考虑猪只不同成长阶段的行为规律,试验对象选取 60 ~ 160 日龄阶段的三元杂肉猪 30 头,采集摄像头选用海康威视 DS - 2DC2204IW - D3 型,分辨率 1 920 像素 × 1 080 像素,俯视高度 2.6 m,摄像头俯角 45°。采集生猪站立、犬坐、躺卧、趴卧 4 种姿态,如表 1 所示。图 1 为前期开发的群养猪只环境行为采集系统,用于模型边缘部署<sup>[22]</sup>。

表 1 猪只姿态描述详情  
Tab.1 Details of description of pig's posture

| 行为 | 行为描述           | 标签        |
|----|----------------|-----------|
| 站立 | 四肢直立           | Stand     |
| 犬坐 | 前肢撑地、后肢弯曲,身体前倾 | Sit       |
| 躺卧 | 身体一侧着地,四肢伸直    | Lie       |
| 趴卧 | 腹部贴地,四肢伸展,身体平躺 | Lie_prone |




图 1 群养猪只环境行为采集系统  
Fig.1 Environmental behavior acquisition system for group-housed pigs

1.2 数据预处理及数据集构建

选取猪只图像 3 852 幅,为提高模型准确性和场景适配性,采用增亮、滤波、高斯模糊等多种方式进行样本扩增,如图 2 所示。最终猪只姿态各类样

本共 4 849 个,如表 2 所示。




图 2 样本增强示例

Fig. 2 Sample enhancement example

表 2 数据集划分

Tab.2 Dataset partitioning

| 类型 | 训练集 | 测试集 | 验证集 | 总计    |
|----|-----|-----|-----|-------|
| 站立 | 984 | 281 | 141 | 1 406 |
| 躺卧 | 870 | 248 | 125 | 1 243 |
| 犬坐 | 746 | 213 | 107 | 1 066 |
| 趴卧 | 793 | 226 | 114 | 1 133 |

2 EL – YOLO v8n 猪只姿态检测模型构建

YOLO v8n 因原生支持关键点检测、端到端实时性强、生态完善和成熟应用经验等特点,广泛用于畜禽智能化技术研究<sup>[23–24]</sup>。为进一步提升 YOLO v8n 检测效果,降低计算量,提出 EL – YOLO v8n 模型,如图 3 所示。该模型引入 ERB 结构,降低推理时间和计算量的同时,更好融合不同尺度特征。同时,设计了 LSDGCD 轻量化检测头,以便共享卷积层有效提取特征,降低模型复杂度。此外,引入 ByteTrack 跟踪算法,实现群养猪只多目标实时

跟踪。

2.1 LSDGCD 轻量化检测头

为提高复杂猪舍环境下猪只姿态特征提取能力,设计 DEConv\_GN 模块,修改 CBS 模块的 BN 层为 GN 层,主要原因在于 BN 层假设每个 batch 内的数据分布相似,样本增强后的数据分布存在差异,BN 层的归一化效果会受干扰,而 GN 层的归一化基于通道组内的统计信息,可避免干扰。此外,LSCD 检测头将原有 Conv2d 卷积替换为 DEConv 细节卷积,可有效捕捉图像高频细节信息,通过整合差异卷积(Difference convolutions,DCs)增强特征提取能力。

如图 4 所示,DEConv 包含 1 个传统卷积层(Vanilla convolution,VC)和 4 个差异卷积层。其中,差异卷积层包括中心差异卷积(Central difference convolution,CDC)、角度差异卷积(Angular difference convolution,ADC)、水平差异卷积(Horizontal difference convolution,HDC)和垂直差异卷积(Vertical difference convolution,VDC)。其中,CDC 通过计算邻域内的中心差分特征,增强特征对光照变化的鲁棒性;ADC 捕捉特征图中不同方向的差异信息,增强特征区分度,区分站立、躺卧等姿态;HDC 捕捉水平方向的差异信息,减少冗余信息;VDC 捕捉垂直方向的差异信息,区分站立、犬坐等姿态。

2.2 EfficientRepBifusion 骨干网络

提出一种 EfficientRepBiFusion 骨干网络,结合 EfficientRep 结构和 BiFusion 特征融合机制,通过双向特征融合和重参数化技术,有效提取和融合不同尺度、不同层次的特征信息。其中,EfficientRep 结构中 RepConv 利用重参数化设计减少模型推理的




图 3 EL – YOLO v8n 模型结构

Fig. 3 Structure of EL – YOLO v8n model




图 4 细节卷积结构

Fig. 4 Structure of DEConv

浮点运算量和内存占用量,并通过不同步长的卷积操作,生成多尺度特征图,捕捉猪只局部和全局上下文信息,提高识别准确性。RepBlock 堆叠多个 Conv 模块,增强特征表达能力,提高模型鲁棒性。由于猪只姿态复杂多样,训练中会产生不同分辨率的尺寸, BiFusion 采用双向特征融合机制,与传统 PANet、FPN 和 NAS - FPN 算法单向聚合和拓扑搜索方式相比,无需复杂搜索过程,可更精准地捕捉猪只姿态细节和整体行为特征,减少了计算时间和资源消耗,其结构如图 5 所示。




图 5 BiFusion 框架金字塔

Fig. 5 BiFusion frature pyramid

由图 5 可知, CORE 模块首先输入来自第  $i - 1$  层特征图,经过 2 个 Bottleneck 结构包含  $1 \times 1$  降维卷积,  $3 \times 3$  特征提取卷积,以及  $1 \times 1$  升维卷积,以减少浮点运算量。通过 Concatenation 及 Reorg 操作进行特征拼接和重组。最后,经 Bottleneck 结构处理后作为第  $i + 1$  层的输出。 Prediction 模块接收来自前面特征融合模块的输出特征图通过 Bottleneck 结构和  $3 \times 3$  卷积对特征进行整合,以达到“纯化”作用。并构建一个新的双融合特征金字塔,用于目标检测,减少了搜索成本和时间,易于实际应用和部署。

2.3 优化边界框损失函数

生猪养殖环境下常有背景与目标相似度较高的情况出现,正负样本之间难以区分。而 YOLO v8n 默认采用 CIoU 损失函数,即

$$\begin{cases} CIoU = 1 - \left( IoU - \frac{\rho^2}{c^2} - \alpha v \right) \\ \rho = \sqrt{(x_{\text{pred}} - x_{\text{true}})^2 + (y_{\text{pred}} - y_{\text{true}})^2} \\ c = \sqrt{(x_{\text{max}} - x_{\text{min}})^2 + (y_{\text{max}} - y_{\text{min}})^2} \\ v = \frac{4}{\pi^2} \left( \arctan \frac{\omega_{\text{ture}}}{h_{\text{ture}}} \arctan \frac{\omega_{\text{pred}}}{h_{\text{pred}}} \right)^2 \end{cases} \quad (1)$$

式中  $IoU$ ——预测框和真实框交并比  
 $\rho$ ——预测框中心点和真实框中心点欧氏距离  
 $c$ ——预测框和真实框最小外接矩形对角线长度  
 $v$ ——长宽比一致性惩罚项  
 $\alpha$ ——长宽比一致性惩罚项权重  
 $x_{\text{pred}} \setminus y_{\text{pred}}$ ——预测框中心点坐标  
 $x_{\text{true}} \setminus y_{\text{true}}$ ——真实框中心点坐标  
 $\omega_{\text{ture}} \setminus h_{\text{ture}}$ ——真实目标框宽度、高度  
 $\omega_{\text{pred}} \setminus h_{\text{pred}}$ ——网络输出预测边框的宽度、高度

然而, CIoU 损失函数存在宽高比例不明确问题,可能导致宽度和高度差异被忽略。因此引入 EIoU 损失函数,全面评估边界框预测准确性,进一步提高模型性能,即

$$EIoU = 1 - \left( IoU - \frac{\rho^2}{c^2} - \alpha v - \beta \omega \right) \quad (2)$$

式中  $\omega$ ——长宽比尺寸惩罚项  
 $\beta$ ——长宽比尺寸惩罚项权重

2.4 ByteTrack 猪只跟踪模型

在群养猪只行为跟踪任务中,个体数量多、运动范围重叠、相互遮挡频繁以及姿态快速切换,易导致猪只行为轨迹中断或身份漂移。因此,将 ByteTrack 与 EL - YOLO v8n 算法结合,对检测结果进行多目标跟踪。与 DeepSORT 的高置信度检测框不同, ByteTrack 采用双阶段匹配机制,利用高置信度检测结果完成主要目标匹配,然后引入低置信度检测框,补全遮挡或复杂背景下遗漏的轨迹。

设  $t$  时刻目标轨迹为

$$T_t = \{b_t, s_t, h_t\}$$

(3)

式中  $b_t$ ——边界框位置  
 $s_t$ ——轨迹置信度分数  
 $h_t$ ——轨迹历史状态信息  
 $t$ 时刻检测器输出结果为

$$D_t = \{d_t^1, d_t^2, \cdots, d_t^n\}$$

(4)

其中  $d_t^i = (b_t^i, c_t^i)$

式中  $d_t^i$ ——当前帧第  $i$  个检测框  
 $c_t^i$ ——检测框的置信度分数  
采用级联匈牙利匹配,即

$$COST(T_{t-1}^j, d_t^i) = 1 - IoU(b_{t-1}^j, b_t^i)$$

(5)

式中  $T_{t-1}^j$ ——上一帧第  $j$  条轨迹  
 $b_{t-1}^j$ ——轨迹边界框  
 $b_t^i$ ——检测框边界框  
 $COST$ ——匹配代价,越小表示轨迹和检测框越可能属于同一头猪只

匹配正确则更新轨迹,其余未匹配的轨迹进入“暂存”状态。在低置信度检测集合,“暂存”轨迹再次进行匹配,以最大化利用检测信息。若轨迹在连续  $N_{lost}$  帧中未被匹配,则认为轨迹丢失;若新的检测框在连续  $N_{init}$  中稳定匹配,则生成新轨迹;更新后的轨迹置信度通过指数加权更新,即

$$S_t = \lambda S_{t-1} + (1 - \lambda) c_t \quad (\lambda \in [0, 1])$$

(6)

式中  $S_t$ ——当前  $t$  帧轨迹置信度  
 $S_{t-1}$ —— $t - 1$  帧轨迹置信度  
 $\lambda$ ——平滑系数  
 $c_t$ ——第  $t$  帧瞬时检测置信度

2.5 评价指标

采用召回率(R)、精确率(P)、平均精度均值(mAP@0.5)、参数量、浮点运算量、模型内存占用量评估识别模型性能。其中,mAP@0.5 表示在 IoU 阈值为 0.5 条件下所有类别平均精度均值;参数量

为模型权重总量,浮点运算量反映计算复杂度,模型内存占用量反映运行时的硬件资源消耗。选取高阶跟踪准确率(HOTA)、多目标跟踪准确率(MOTA)、识别平均率(IDF1)评估跟踪性能。其中,HOTA 体现算法整体跟踪精度,MOTA 反映跟踪整体准确率,IDF1 衡量目标识别匹配效果。

3 结果与分析

模型训练采用戴尔 T3650 图形工作站,配置为 Intel Core i9 - 13900K CPU 和 Nvidia GeForce RTX4080 显卡,同时配置 UDA 12.1,深度学习框架 Pytorch 2.1.0。训练过程中,初始学习率 0.01,采用余弦退火策略对学习率进行调整,批次大小设置为 16,训练迭代次数为 300,使用随机梯度下降对模型参数进行更新,动量因子设置为 0.97。

3.1 不同模型性能测试

选取常见识别模型进行试验,结果如表 3 所示。YOLO v8n 模型在猪只行为检测任务中展现出最佳综合性能。其精确率(90.24%)、召回率(89.14%)及 mAP@0.5(88.95%)均显著优于 SSD、Faster R - CNN 与 YOLO v5n,较 YOLO v10n、YOLO 11n、YOLO 12n 均保持领先或相当水平。在效率方面,YOLO v8n 参数量( $3.01 \times 10^6$ )、浮点运算量( $8.2 \times 10^9$ )与模型内存占用量(6.5 MB)实现了轻量化设计,且帧率达 186 f/s,远高于 Faster R - CNN(28 f/s)、SSD(68 f/s)与 YOLO v5n(110 f/s),较 YOLO v10n 等后续系列模型分别提高 20.78%、21.57% 及 66.1%,能更好地满足现场部署对实时性的要求。同时,考虑到 YOLO v8n 在训练与推理稳定性、社区支持、部署兼容性等方面的优点,结合猪只识别跟踪的检测精度与实时性双重需求,最终选定 YOLO v8n 作为基础检测模型。

表 3 不同模型性能测试结果  
Tab.3 Test results of different models performance

| 模型             | 精确率/% | 召回率/% | mAP@0.5/% | 参数量                | 浮点运算量                 | 模型内存占用量/MB | 帧率/(f·s <sup>-1</sup> ) |
|----------------|-------|-------|-----------|--------------------|-----------------------|------------|-------------------------|
| SSD            | 78.56 | 76.89 | 77.23     | $3.47 \times 10^7$ | $3.50 \times 10^{10}$ | 90.0       | 68                      |
| Faster R - CNN | 85.35 | 84.54 | 85.12     | $4.23 \times 10^7$ | $1.72 \times 10^{11}$ | 106.3      | 28                      |
| YOLO v5n       | 88.95 | 87.68 | 88.21     | $2.51 \times 10^6$ | $7.20 \times 10^9$    | 5.2        | 110                     |
| YOLO v8n       | 90.24 | 89.14 | 88.95     | $3.01 \times 10^6$ | $8.20 \times 10^9$    | 6.5        | 186                     |
| YOLO v10n      | 90.58 | 87.62 | 88.60     | $2.71 \times 10^6$ | $6.50 \times 10^9$    | 5.8        | 154                     |
| YOLO 11n       | 89.98 | 89.22 | 88.32     | $2.59 \times 10^6$ | $6.40 \times 10^9$    | 5.5        | 153                     |
| YOLO 12n       | 90.15 | 88.89 | 88.30     | $2.57 \times 10^6$ | $6.30 \times 10^9$    | 5.4        | 112                     |

3.2 消融试验

以 YOLO v8n 为基准模型开展消融试验,结果如表 4 所示。引入 ERB 模块,精确率、召回率、mAP@0.5 基本不变,但参数量、浮点运算量、模型

内存占用量分别降低 6.64%、8.54% 及 9.23%,表明模型在不损失性能的情况下,泛化能力增强,浮点运算量显著降低。替换轻量化 LSCD 检测头,精确率、召回率、mAP@0.5 分别提高 0.34、1.64、1.35 个

百分点,参数量、浮点运算量、模型内存占用量分别降低 21.26%、20.73% 及 24.62%,表明 LSCD 利用共享卷积机制,减少了冗余参数,同时通过 Scale 层对不同尺度的目标进行特征缩放,在保持性能的同时,降低了模型规模。此外,在 LSCD 基础上构建的 LSDGCD 检测头,精确率、召回率、mAP@0.5 较 LSCD 分别提高 1.77、3.13、2.4 个百分点,参数量、浮点运算量、模型内存占用量较 LSCD 变化较小,表明细节增强卷积提升了模型特征提取能力。结合

ERB 与 LSCD,精确率、召回率、mAP@0.5 分别提高 2.95、4.02、4.99 个百分点,参数量、浮点运算量、模型内存占用量分别降低  $2.6 \times 10^5$ 、 $8 \times 10^8$ 、1.2 MB,模型整体性能提升,参数量、浮点运算量和模型内存占用量显著减少,轻量化策略有效。结合 ERB 模块与 LSDGCD,与 YOLO v8n 相比,平均检测精确率提升 6.24%,召回率提升 7.61%,mAP@0.5 提升 8.49%,参数量降低 15.28%,模型内存占用量仅 5.45 MB。

表 4 消融试验结果  
Tab.4 Results of ablation experiment

| YOLO v8n | ERB | LSCD | LSDGCD | 参数量                | 精确率/% | 召回率/% | mAP@0.5/% | 浮点运算量              | 模型内存占用量/MB |
|----------|-----|------|--------|--------------------|-------|-------|-----------|--------------------|------------|
| √        | ×   | ×    | ×      | $3.01 \times 10^6$ | 90.24 | 89.14 | 88.95     | $8.20 \times 10^9$ | 6.50       |
| √        | √   | ×    | ×      | $2.81 \times 10^6$ | 90.18 | 90.27 | 89.56     | $7.50 \times 10^9$ | 5.90       |
| √        | ×   | √    | ×      | $2.37 \times 10^6$ | 90.55 | 90.60 | 90.15     | $6.50 \times 10^9$ | 4.90       |
| √        | ×   | ×    | √      | $2.56 \times 10^6$ | 92.32 | 93.73 | 92.55     | $5.40 \times 10^9$ | 5.10       |
| √        | √   | √    | ×      | $2.75 \times 10^6$ | 93.19 | 93.16 | 93.94     | $7.40 \times 10^9$ | 5.30       |
| √        | √   | ×    | √      | $2.55 \times 10^6$ | 95.88 | 95.93 | 96.55     | $5.46 \times 10^9$ | 5.45       |

注:√表示采用此模块,×表示未采用此模块。

图 6 直观呈现了不同模型对特征学习机制的影响。图 6a 中,YOLO v8n 骨干网络依赖轻量化卷积提取全局语义信息,虽兼顾检测效率,但姿态识别所需的关键局部特征(如四肢关节、躯干轮廓)未得到针对性强化,导致特征响应分散于猪只全身,难以聚焦姿态判别核心区域,对犬坐与站立、趴卧与侧卧等相似姿态的区分能力受限。图 6b 中,引入 ERB 模块后,模型通过重参数化多尺度特征提取与双向特征融合,强化姿态敏感区域的特征权重,使特征响应向肢干、腹部等关键区域聚集,初步提升了姿态轮廓的感知能力,但对细微姿态差异的捕捉仍显不足。图 6c 中,LSDGCD 模块通过 DEConv 多方向差异卷积精准捕捉姿态细节,并借助 GN 层提升归一化鲁棒性,使特征响应聚焦于四肢关节、躯干轮廓等动态区域,显著降低相似姿态混淆,然而受轻量化设计约束,模型对趴卧、躺卧等低对比度姿态的特征表达不够充分,特征响应强度不足。图 6d 中,EL-YOLO v8n 整合了特征强化与细节捕捉优势,特征响应高

度聚焦于姿态判别核心区域(如四肢弯折处、躯干形态变化区),有效解决易混淆姿态的识别难题,综合表现最佳,验证了模型性能提升的合理性。

图 7 为不同模型训练平均精确率、损失值变化,进一步表明了所提模型优越性。





图 6 不同模型可视化热力图

图 7 模型训练参数结果

Fig.6 Comparison of heat maps of different models

Fig.7 Results of training parameters of various models

3.3 模型检测结果

EL-YOLO v8n 生猪姿态识别结果如表 5 和图 8 所示。由表 5 可知,站立、躺卧、犬坐和趴卧 4 种姿态识别精确率分别为 98.7%、93.2%、99.3% 及 92.3%。表 6 为群养猪识别跟踪模型试验结果。由表 6 可知,EL-YOLO v8n + ByteTrack 综合表现最优,其中 IDF1 为 90.7%,MOTA 与 HOTA 分别为 88.6% 和 66.2%,并保持实时处理帧率为 30 f/s。表明所提模型可在复杂群养环境中实现更稳定的实时跟踪,有效降低因检测抖动导致的身份切换和个体漏检。与 DeepSORT 和 BoT-SORT 相比,ByteTrack 在维持个体身份连续性方面表现更突出,尤其在猪只数量多、分布密集及姿态突变情况下,能够显著降低同一猪只因短时遮挡或姿态改变被误判

表 5 生猪姿态识别结果

Tab.5 Recognition results of pig posture and behavior

| 类型 | 精确率  | 召回率  | mAP@0.5 |
|----|------|------|---------|
| 站立 | 98.7 | 98.6 | 98.4    |
| 躺卧 | 93.2 | 90.4 | 94.6    |
| 犬坐 | 99.3 | 99.2 | 98.5    |
| 趴卧 | 92.3 | 95.5 | 94.7    |

的情况。此外,该方法在不同姿态切换时,仍能准确关联同一个体轨迹,保证了轨迹的完整性与连续性。




图 8 改进 EL-YOLO v8n 模型识别结果  
Fig.8 Recognition results of improved EL-YOLO v8n

表 6 群养猪跟踪模型试验结果

Tab.6 Experimental results of group-housed pig tracking model

| 算法                      | IDP/% | IDR/% | IDF1/% | MOTA/% | HOTA/% | 帧率/(f·s <sup>-1</sup> ) |
|-------------------------|-------|-------|--------|--------|--------|-------------------------|
| YOLO v8n + ByteTrack    | 88.7  | 87.2  | 87.9   | 86.5   | 63.1   | 32                      |
| EL-YOLO v8n + ByteTrack | 91.3  | 90.1  | 90.7   | 88.6   | 66.2   | 30                      |
| YOLO v8n + DeepSORT     | 87.1  | 85.6  | 86.3   | 84.8   | 61.0   | 28                      |
| YOLO v8n + BoT-SORT     | 90.2  | 88.7  | 89.4   | 87.5   | 64.9   | 29                      |

图 9 为所提模型猪场 Jetson Nano 部署效果。在复杂背景、强遮挡和猪群动态交互情况下,轨迹结

果显示了个体运动路径与行为变化,表明该模型仍 能实现每头猪的实时检测和跟踪,为后续健康监测




图 9 改进 EL-YOLO v8n 模型跟踪检测结果  
Fig.9 Tracking and detection effect of improved EL-YOLO v8n model

和行为分析提供数据支持。

4 结论

(1)提出一种改进的轻量化 EL-YOLO v8n 模型,通过融合 ERB 骨干网络、LSDGCD 轻量化检测头,有效增强了多尺度特征融合能力与细粒度姿态特征表达能力,实现了复杂猪舍环境下猪只行为的准确识别。试验结果表明,该模型对猪只站立、躺卧、犬坐和趴卧 4 种姿态识别精度分别为 98.7%、

93.2%、99.3% 及 92.3%,具有较强的鲁棒性。

(2)结合 ByteTrack 算法实现了猪只个体持续跟踪,显著减少了因相互遮挡和高相似度导致的 ID 切换与轨迹中断问题,保证了时间序列上的行为跟踪持续性。试验结果表明,与 DeepSORT 和 BoT-SORT 等算法相比,所提方法综合表现最佳,IDF1 为 90.7% 和 MOTA 为 88.6%,通过在猪场 Jetson Nano 边缘设备部署,实现了 30 f/s 的猪只姿态检测与跟踪,满足了实际工程需求。

参 考 文 献

[1] 李永振,王朝元,黄仕伟,等. 饲养密度和玩具对育肥猪生产性能、行为和生理指标的影响[J]. 农业工程学报, 2021, 37(12):191-198.  
Li Yongzhen, Wang Chaoyuan, Huang Shiwei, et al. Effects of stocking density and toy provision on production performance, behavior and physiological indexes of finishing pigs[J]. Transactions of the CSAE, 2021, 37(12): 191-198. (in Chinese)

[2] Cordeiro A F S, Nääs I A, Leitão F S, et al. Use of vocalisation to identify sex, age, and distress in pig production[J]. Biosystems Engineering, 2018, 173: 57-63.

[3] Bhoj S, Tarafdar A, Chauhan A, et al. Image processing strategies for pig liveweight measurement: updates and challenges[J]. Computers and Electronics in Agriculture, 2022, 193:106693.

[4] 李艳文,李菊霞,纳腾潇,等. 基于 YOLOX-NGS 的群养猪只攻击行为识别[J]. 农业工程学报, 2023, 39(24):177-184.  
Li Yanwen, Li Juxia, Na Tengxiao, et al. Recognizing attack behavior of herd pigs using improved YOLOX[J]. Transactions of the CSAE, 2023, 39 (24): 177-184. (in Chinese)

[5] 沈明霞,太猛, Cedric Okinda, 等. 基于深层卷积神经网络的初生仔猪目标实时检测方法[J]. 农业机械学报, 2019, 50(8):270-279.  
Shen Mingxia, Tai Meng, Cedric Okinda, et al. Real-time detection method of newborn piglets based on deep convolution neural network[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(8): 270-279. (in Chinese)

[6] Li D, Zhang K, Li Z, et al. A spatiotemporal convolutional network for multi-behavior recognition of pigs[J]. Sensors, 2020, 20(8): 2381.

[7] Alaeer A, Kyriazakis I, Dalton H A, et al. Automatic recognition of feeding and foraging behaviour in pigs using deep learning [J]. Biosystems Engineering, 2020, 197: 91-104.

[8] Lin J, Wu R, Yin L, et al. Hierarchical model with integrated probabilistic strategy for classifying pig behaviors using active electronic ear tags[J]. Computers and Electronics in Agriculture, 2025, 230: 109915.

[9] Achour B, Belkadi M, Aoudjit R, et al. Unsupervised automated monitoring of dairy cows' behavior based on inertial measurement unit attached to their back[J]. Computers and Electronics in Agriculture, 2019, 167: 105068.

[10] 邓铭辉,龚俊杰,郑飘逸,等. 基于改进 YOLOX 的群养生猪轻量化目标检测方法[J]. 农业机械学报, 2023, 54(11): 277-285.  
Deng Minghui, Gong Junjie, Zheng Piaoyi, et al. Lightweight target detection method for group-raised pigs based on improved YOLOX[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(11): 277-285. (in Chinese)

[11] 全志民,徐天哲,石传淼,等. 基于 CBCW-YOLO v8 的猪只行为识别方法研究[J]. 农业机械学报, 2025, 56(2): 411-419.  
Tong Zhimin, Xu Tianzhe, Shi Chuanmiao, et al. Pig behavior recognition based on CBCW-YOLO v8 model [J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(2): 411-419. (in Chinese)

[12] 李菊霞,李艳文,牛帆,等. 基于 YOLO v4 的猪只饮食行为检测方法[J]. 农业机械学报, 2021, 52(3):251-256.  
Li Juxia, Li Yanwen, Niu Fan, et al. Pig diet behavior detection method based on YOLO v4[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(3): 251-256. (in Chinese)

[13] 王鲁,刘晴,曹月,等. 基于改进 Cascade Mask R-CNN 与协同注意力机制的群猪姿态识别[J]. 农业工程学报, 2023, 39(4):144-153.  
Wang Lu, Liu Qing, Cao Yue, et al. Posture recognition of group-housed pigs using improved Cascade Mask R-CNN and cooperative attention mechanism[J]. Transactions of the CSAE, 2023, 39 (4): 144-153. (in Chinese)

[14] 涂淑琴,黄正鑫,梁云,等. 改进 TransTrack 多目标生猪行为跟踪方法[J]. 农业工程学报, 2023, 39(15):172-180.  
Tu Shuqin, Huang Zhengxin, Liang Yun, et al. Methods for multi-target tracking of pig action using improved TransTrack[J]. Transactions of the CSAE, 2023, 39 (15): 172-180. (in Chinese)

[15] 曾志雄,董冰,吕恩利,等. 猪舍环境无线多点多源远程监测系统设计与试验[J]. 农业机械学报, 2020, 51(2):332-340, 349.  
Zeng Zhixiong, Dong Bing, Lü Enli, et al. Design and experiment of wireless multi-point and multi-source remote monitoring system for pig house environment[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(2): 332-340, 349. (in Chinese)

- [16] Tu S, Cai Y, Liang Y, et al. Tracking and monitoring of individual pig behavior based on YOLO v5 - Byte[J]. Computers and Electronics in Agriculture, 2024, 221: 108997.
- [17] Chen P Y, Chang M C, Hsieh J W, et al. Parallel residual bi-fusion feature pyramid network for accurate single-shot object detection[J]. IEEE Transactions on Image Processing, 2021, 30:9099 - 9111.
- [18] Zhu X, Li X, Wang L, et al. Optimizing black cattle tracking in complex open ranch environments using YOLO v8 embedded multi-camera system[J]. Scientific Reports, 2025, 15: 91553.
- [19] Tong L, Fang J, Wang X, et al. Research on cattle behavior recognition and multi-object tracking algorithm based on YOLO - BoT[J]. Animals (Basel), 2024, 14(20): 2993.
- [20] 张宏鸣, 汪润, 董佩杰, 等. 基于 DeepSORT 算法的肉牛多目标跟踪方法[J]. 农业机械学报, 2021, 52(4): 248 - 256.  
Zhang Hongming, Wang Run, Dong Peijie, et al. Beef cattle multi-target tracking based on DeepSORT algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(4): 248 - 256. (in Chinese)
- [21] Zheng Z, Qin L. Pruned YOLO - Tracker: an efficient multi-cows basic behavior recognition and tracking technique[J]. Computers and Electronics in Agriculture, 2023, 213:108172.
- [22] 张稳, 张鑫哲, 傅生辉, 等. 数据驱动的生猪养殖环境分析预警系统设计与实现[J]. 中国农机化学报, 2026, 47(3): 1 - 9.  
Zhang Wen, Zhang Xinzhe, Fu Shenghui, et al. Design and implementation of data-driven environment analysis and early warning system for pig breeding[J]. Journal of Chinese Agricultural Mechanization, 2026, 47(3): 1 - 9. (in Chinese)
- [23] 董力中, 孟祥宝, 潘明, 等. 基于姿态与时序特征的猪只行为识别方法[J]. 农业工程学报, 2022, 38(5): 148 - 157.  
Dong Lizhong, Meng Xiangbao, Pan Ming, et al. Recognizing pig behavior on posture and temporal features using computer vision[J]. Transactions of the CSAE, 2022, 38(5): 148 - 157. (in Chinese)
- [24] 陈虹余, 尹令, 杨明, 等. 视觉和传感器融合的多模态猪只行为识别[J]. 农业工程学报, 2025, 41(8): 194 - 203.  
Chen Hongyu, Yin Ling, Yang Ming, et al. Multimodal recognition of pig behavior using vision and sensors[J]. Transactions of the CSAE, 2025, 41(8): 194 - 203. (in Chinese)
- 

(上接第 119 页)

- [100] 鲍国丞, 王公仆, 胡良龙, 等. 甘薯联合收获机高度自适应集薯装置设计与优化[J]. 农业工程学报, 2023, 39(2): 24 - 33.  
Bao Guocheng, Wang Gongpu, Hu Lianglong, et al. Design and optimization of a height-adaptive sweet potato collecting device for a combine harvester[J]. Transactions of the CSAE, 2023, 39(2): 24 - 33. (in Chinese)
- [101] 陈小冬. 自走式甘薯联合收获机薯茎分离特性研究与机构优化[D]. 合肥: 安徽农业大学, 2020.  
Chen Xiaodong. Study on stem-tuber separation characteristics and mechanism optimization of a self-propelled sweet potato combine harvester[D]. Hefei: Anhui Agricultural University, 2020. (in Chinese)
- [102] Peng J, Shen H, Ding W, et al. Research and analysis of conveyor separation mechanism of light and simple sweet potato combine harvester based on EDEM discrete element method[J]. Computational Particle Mechanics, 2025, 12: 3421 - 3438.
- [103] Wolfert S, Ge L, Verdouw C, et al. Big data in smart farming: a review[J]. Agricultural Systems, 2017, 153: 69 - 80.
- [104] Fountas S, Carli G, Sørensen C G, et al. Farm management information systems: current situation and future perspectives [J]. Computers and Electronics in Agriculture, 2015, 115: 40 - 50.
- [105] Kamilaris A, Prenafeta-Boldú F X. Deep learning in agriculture: a survey[J]. Computers and Electronics in Agriculture, 2018, 147: 70 - 90.
- [106] Bechar A, Vigneault C. Agricultural robots for field operations: concepts and components[J]. Biosystems Engineering, 2016, 149: 94 - 111.
- [107] Bac C W, Van H E J, Hemming J, et al. Harvesting robots for high-value crops: state-of-the-art review and challenges ahead [J]. Journal of Field Robotics, 2014, 31(6): 888 - 911.
- [108] Tzounis A, Katsoulas N, Bartzanas T, et al. Internet of things in agriculture, recent advances and future challenges[J]. Biosystems Engineering, 2017, 164: 31 - 48.
- [109] Badia-Melis R, Mishra P, Ruiz-García L. Food traceability: new trends and recent advances[J]. Food Control, 2015, 57: 393 - 401.
- [110] Kumari L, Narsaiah K, Grewal M K, et al. Application of RFID in agri-food sector[J]. Trends in Food Science & Technology, 2015, 43: 144 - 161.
- [111] Carbajal M, Jones D, Williams C, et al. In-season yield forecasting using multitemporal remote sensing environmental observations and machine learning: applications for sweetpotato in North Carolina, USA[J]. European Journal of Agronomy, 2026, 172: 127818.
- [112] Lowenberg-Deboer J, Erickson B. Setting the record straight on precision agriculture adoption[J]. Agronomy Journal, 2019, 111(4): 1552 - 1569.
- [113] Shafi U, Mumtaz R, García-Nieto J, et al. Precision agriculture techniques and practices: from considerations to applications [J]. Sensors, 2019, 19: 3796.
- [114] Ahmed T, Wijewardane N K, Lu Y, et al. Advancing sweetpotato quality assessment with hyperspectral imaging and explainable artificial intelligence[J]. Computers and Electronics in Agriculture, 2024, 220: 108855.