

基于改进 YOLO 11 - Jetson Orin NX 的猪只体尺自动测量方法

黎 焯^{1,2} 王起繁¹ 刘小磊³ 王海燕⁴ 罗 俊⁴ 徐迪红^{1,2}

(1. 华中农业大学工学院, 武汉 430070; 2. 农业农村部智慧养殖技术重点实验室, 武汉 430070;
3. 湖北洪山实验室, 武汉 430070; 4. 华中农业大学信息学院, 武汉 430070)

摘要: 针对传统猪只体尺测量强度大、效率低、现有体尺测量边缘计算方法缺乏等问题, 提出一种适用于 Jetson Orin NX 边缘平台的猪只体尺自动测量方法。基于时间序列化猪只数据构建了姿态检测数据集 10 413 幅与关键点数据集 9 555 幅, 并以栏位划分数据集; 为使模型轻量化的同时保证模型性能, 构建了基于改进 YOLO 11n 算法的姿态检测与关键点检测模型; 通过降低网络宽度系数压缩模型体积, 采用 DySample 动态上采样, 减少计算冗余并增强跨尺度特征交互, 使模型在低参数量的情况下实现高效特征提取与融合, 提升压缩后的模型性能; 通过 pt-ONNX-engine 三阶段权重转换流程重构网络结构, 优化模型推理速度并完成 Jetson Orin NX 边缘部署; 结合 SGBM 算法获取测点三维坐标测得体尺信息。结果表明, 改进 YOLO 11nds 模型在精度、推理速度及模型参数量方面表现优异, 在姿态检测任务中, 准确率为 99.17%, F1 分数为 94.26%, 推理速度为 156.25 f/s, 参数量为 8.2×10^5 , 在关键点检测任务中, OKS 为 97.50%, PCK 为 97.06%, 推理速度为 169.49 f/s, 参数量为 8.7×10^5 。在 2 个任务上优化后推理速度分别提高 265.47%、362.71%。选取 2024 年 1 月 28 日与 3 月 9 日视频数据进行自动测量, 与人工测量结果相比, 2 组体长、体宽、臀宽、体高、臀高平均相对误差分别为 1.58%、1.70%、2.17%、2.00%、2.93% 与 1.90%、2.18%、2.90%、3.10%、2.80%。本文方法在准确性与实时性方面均表现较优, 能够高效运行于 Jetson Orin NX, 为猪只体尺自动化测量提供可靠方案。

关键词: 种猪; 姿态检测; 关键点检测; 体尺测量; 边缘部署

中图分类号: S24 文献标识码: A 文章编号: 1000-1298(2026)06-0271-10

OSID:



Automatic Pig Body Size Measurement Method Based on Improved YOLO 11 and Jetson Orin NX

LI Xuan^{1,2} WANG Qifan¹ LIU Xiaolei³ WANG Haiyan⁴ LUO Jun⁴ XU Dihong^{1,2}

(1. College of Engineering, Huazhong Agricultural University, Wuhan 430070, China

2. Key Laboratory of Smart Farming for Agricultural Animals, Ministry of Agriculture and Rural Affairs, Wuhan 430070, China

3. Hubei Hongshan Laboratory, Wuhan 430070, China

4. College of Informatics, Huazhong Agricultural University, Wuhan 430070, China)

Abstract: Aiming to address the high labor intensity, low efficiency of traditional pig body size measurement, and the lack of edge computing methods for automated measurement, an automatic pig body size measurement approach tailored for the Jetson Orin NX edge platform was proposed. A time-series dataset comprising 10 413 posture images and 9 555 keypoint images was constructed and partitioned by enclosure. To achieve a lightweight yet high-performing model, an improved YOLO 11nds-based architecture was developed for posture and keypoint detection. The network width coefficient was reduced to compress model size, and DySample dynamic upsampling was incorporated to reduce computational redundancy and enhance cross-scale feature interactions, enabling efficient feature extraction and fusion with fewer parameters. A three-stage weight conversion process from pt to ONNX to

收稿日期: 2025-07-31 修回日期: 2025-10-16

基金项目: 科技创新 2030——生物育种重大项目(2022ZD0401802)、湖北省支持种业高质量发展资金项目(HBZY2023B006-03)和武汉市生物育种重大专项(2022021302024853)

作者简介: 黎焯(1980—), 男, 教授, 博士, 主要从事生猪行为智能识别与智能装备研究, E-mail: lx@mail.hzau.edu.cn

通信作者: 徐迪红(1974—), 男, 讲师, 博士, 主要从事农业领域计算机视觉应用研究, E-mail: xudihong@mail.hzau.edu.cn

engine was employed to reconstruct the network structure, optimize inference speed, and deploy the model on Jetson Orin NX. The SGBM algorithm was integrated to obtain 3D coordinates of key measurement points for body size estimation. Experimental results demonstrated that the improved YOLO 11nds model achieved superior accuracy, inference speed, and parameter efficiency. For posture detection, it reached 99.17% of accuracy, an F1 score of 94.26%, an inference speed of 156.25 f/s, and 8.2×10^5 parameters. For keypoint detection, it achieved 97.50% OKS, 97.06% PCK, 169.49 f/s, and 8.7×10^5 parameters. Optimizations improved inference speeds by 265.47% and 362.71% for the two tasks. Automatic measurements using videos from January 28 and March 9, 2024, showed mean relative errors of 1.58%, 1.70%, 2.17%, 2.00%, and 2.93%, and 1.90%, 2.18%, 2.90%, 3.10%, and 2.80% for body length, body width, rump width, body height, and rump height compared with that of manual measurements. This method demonstrated high accuracy and real-time performance, efficiently operating on Jetson Orin NX and providing a reliable solution for automated pig body size measurement.

Key words: breeding pigs; posture detection; keypoint detection; body size measurement; edge deployment

0 引言

在现代猪只育种中,准确评估猪只生长性能是选育优质种猪的关键步骤^[1-2]。其中,体尺参数不仅能够反映猪只的骨架发育和体型结构,还与生长速度、瘦肉率等经济性状密切相关,是对体质量等常规指标的重要补充^[3]。传统体尺测量方法依赖人工操作,存在劳动强度大、猪只应激反应强烈等问题^[4-8]。随着计算机视觉技术的发展,深度学习在动植物表型信息提取方向得到广泛应用^[9-15]。借助这一技术手段,可实现猪只体尺参数的非接触式精准测量,进一步拓展育种评估维度,提升数据获取的全面性与科学性,为育种决策提供更加可靠的依据。

目前对猪只体尺无接触式测量的研究已取得一定进展。司永胜等^[16]基于 Kinect 相机采集的猪体视频数据,提出理想姿态检测算法,结合投影法、差分法、骨骼化及霍夫变换检测耳部缺失和头部歪斜,设计了体尺测量算法;赵宇亮等^[17]基于 DeepLabCut 算法,使用离群特征点临近区深度数据替换算法动态优化局部深度数据缺失问题,精准测量猪只体尺;刘刚等^[18]基于改进 YOLO v5 - pose 融合三维点云数据实现了群养生猪体尺自动测量;LI 等^[19]基于深度相机同步采集点云数据并进行三维点云重建,完成育肥猪体长、体高、体宽、臀高和臀宽的自动化测量。JIANG 等^[20]提出了一种融合双激光雷达与改进 PointVector++ 网络的多模态方法,结合 B 样条曲线拟合与 NURBS 曲面重建算法,达成对体长、胸围等 10 项猪表型参数的自动化测量;耿艳利等^[21]基于 PointNet 网络,结合注意力模块构建语义分割模型,用于针对不同分割部位猪只体尺测量。SHI 等^[22]基于改进 Point Transformer 的点云分割网络自

动测量方法,引入自适应卷积、偏移注意力机制及 Focal loss 构建 ACPT 网络,实现猪只点云分割与关键点提取,显著提高了非接触体尺测量精度。XU 等^[23]提出基于测地距离回归的猪只点云关键点检测方法,结合改进 PointNet++ 与加权特征聚合(WFA)机制,直接定位体尺关键点并完成体长、体宽、体高及围度等参数测量。基于深度学习的猪只体尺测量方法已较为丰富,但现有研究多依赖高性能 GPU 或复杂 3D 传感设备,算法模型普遍较大,难以直接部署于资源受限的边缘计算设备上。面向低功耗、实时性场景的轻量化体尺测量算法研究亟需加强。

针对上述问题,本文提出一种基于改进 YOLO 11 与 Jetson Orin NX 的猪只体尺自动测量方法。基于时间序列化数据分别搭建猪只姿态检测与关键点检测 2 个模型,结合 SGBM 算法获取三维坐标,计算猪只体尺参数并将算法部署于 Jetson Orin NX 平台,以实现猪只体尺高效、精准测量。

1 数据采集与预处理

1.1 猪只图像采集

数据采集于湖北省武汉市江夏区金口镇某猪场,试验对象为 30 头三元猪,每个饲养栏内各 10 头。猪场内设置 3 个饲养栏,每个饲养栏内均放置 1 台测定站,每台测定站上方配置 1 个分辨率为 2560 像素 × 720 像素的像元跃动 D435 型双目相机,确保对进入测定站的猪只在采食前、采食中及采食后行为进行全阶段采集。试验装置部署如图 1 所示。

试验周期为 2024 年 1 月 28 日—3 月 30 日,覆盖了猪只从 35 kg 增长至 105 kg 的体质量区间,为连续采集不同生长阶段的体尺数据提供了条件。



图 1 试验装置部署图

Fig. 1 Deployment diagram of experimental device

1.2 数据集构建

对采集的视频进行抽帧,抽帧速率为 3 f/s,抽帧结束后获得初始数据集。初始数据集内容杂乱、图像质量参差不齐。为提高数据集质量,对数据进行人工初步筛选,剔除掉模糊、遮挡、有噪声等问题数据后,得到备用数据集。备用数据集包含猪只进站、采食、出站全过程,涵盖猪只生长周期,具有数据连续性。基于备用数据集,依次建立猪只姿态数据集和猪只关键点数据集。

1.2.1 猪只姿态数据集构建

基于备用数据集,再次进行人工筛选对数据进行分类,将数据分为标准测定姿态与非标准测定姿态 2 个类别。标准测定姿态要求目标帧猪只处于直立、身体不弯曲、头部不偏或偏头角度微小且能明显看见猪鼻的状态,非标准测定姿态包括过度抬头姿态、过度低头姿态、偏头姿态、屈身以及多猪只挤压姿态^[5,24]。

完成筛选后使用 LabelMe 进行矩形框标注,将非标准测定姿态的矩形框标签类别设为 0,将标准测定姿态的矩形框标签设为 1,标注后数据如图 2 所示。共获得猪只姿态数据 10 413 幅,其中 1 号栏数据 3 891 幅、2 号栏数据 3 453 幅、3 号栏数据 3 069 幅。

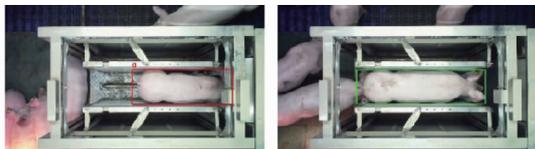


图 2 矩形框标注展示图

Fig. 2 Bounding box annotation illustration

为规范数据划分,将 1 号栏与 3 号栏数据混合后按照比例 8:2 划分为训练集、验证集,得到训练集 5 567 幅数据,验证集 1 393 幅数据,将 2 号栏 3 453 幅数据全部划分为测试集。此划分方式能够更好地检验模型的鲁棒性与泛化能力,也更加接近实际应用情况。

1.2.2 猪只关键点数据集构建

猪只体尺测点包括颈部中点(F)、尾根中点

(B)、肩部最宽处左侧点(L_1)、肩部最宽处右侧点(R_1)、臀部最宽处左侧点(L_2)和臀部最宽处右侧点(R_2),关键点具体介绍和位置详见表 1。这 6 个体尺测点能够有效表征猪只体尺^[24]。

表 1 体尺测点定义

Tab. 1 Definition of body measurement keypoints

| 体尺测点 | 定义 |
|-------|--------------|
| F | 位于猪只颈部与躯干连接处 |
| B | 位于猪只尾巴根部中心位置 |
| L_1 | 肩部区域最宽处左侧边缘点 |
| L_2 | 臀部区域最宽处左侧边缘点 |
| R_1 | 肩部区域最宽处右侧边缘点 |
| R_2 | 臀部区域最宽处右侧边缘点 |

猪只体尺测点为基准点,同时加入鼻尖关键点(点 N),共 7 个关键点,构建关键点数据集。其中,点 N 与点 F 连线可以量化猪只偏头角度,进一步对姿态进行精筛。7 个关键点位置示意图如图 3 所示。



图 3 关键点标注位置示意图

Fig. 3 Schematic of keypoint annotation locations

基于备用数据集筛选后,使用 LabelImg 标注符合要求的的数据,包括“pig”类别框及 N 、 F 、 L_1 、 R_1 、 L_2 、 R_2 、 B 关键点,点 N 因姿态变化可能不可见,此时通过人工预测标注以保证一致性。处理后共获得猪只关键点数据 9 555 幅,其中 1 号栏 3 527 幅、2 号栏 2 399 幅、3 号栏 3 629 幅。

与猪只姿态数据划分相同,将 1 号栏和 3 号栏数据混合后,按照比例 8:2 划分为训练集 5 724 幅和验证集 1 432 幅,同时将 2 号栏 2 399 幅数据作为测试集。

2 材料与方法

2.1 YOLO 11n 网络

体尺测量的难点之一在于找到满足体尺测量标准姿态的数据^[25-26],传统的单幅图像拍摄或低帧拍摄难以采集到目标数据,因此有必要采用较高帧拍摄方法采集猪只进站、采食、出站的完整过程,通过算法检测出为数不多的标准测定姿态,这对算法的检测速度提出了显著挑战。YOLO 11 作为一种高效的目标检测算法,更适应该任务需求。作为 one-stage 方法的一种,无论是推理速度还是精度均优于 R-CNN 系列的 two-stage 算法^[27]。故而选用 YOLO

11n 网络作为基础网络。

2.2 YOLO 11n 姿态与关键点检测模型

YOLO 11n 基于 CNN,采用多层 C3k2 模块提升特征提取效率并降低计算量,通过 SPPF^[28] 和 C2PSA 模块增强多尺度和空间位置信息感知,颈部网络利用上采样与特征融合,头部网络进行检测与预测。

对于猪只姿态检测任务,头部网络直接在特征图上预测锚框的类别与位置。对于猪只关键点检测任务,通过在头部添加姿态估计层,构建多任务学习方式实现关键点坐标的预测^[29]。

2.2.1 损失函数

猪只姿态检测任务使用边界框回归损失 (Box loss) 衡量预测框与真实框的差异;使用分类损失 (Classification loss) 优化分类准确性;使用 DFL (Distribution focal loss) 平衡正负样本。猪只关键点检测任务在此基础上额外增加关键目标损失 (Key object loss) 和姿态损失 (Pose loss) 促使模型回归学习关键点信息。

2.2.2 算法平台

在 PC 端部署模型的训练与测试环境,软件环境为 Windows 11、Python 3.9、Pytorch 1.12.0、Cuda 11.6。CPU 采用 12th Gen Inter(R) Core(TM) i9-12900K 处理器,GPU 为 NVIDIA GeForce RTX 4090,显存 24 GB。

2.3 模型改进与优化

YOLO 11n 虽在模型轻量化方面具备优势,但其精度仍需进一步提高。为此,引入轻量级动态上采样算子 DySample^[30],避开动态卷积,同时其独特的点采样方法优于传统的内核方法,减少计算冗余并增强跨尺度特征交互,使模型在较低参数的情况下依然保持丰富的语义表示能力,实现高效特征提取与融合。改进模型为 YOLO 11nd,结构如图 4 所示,图中 Head 部分的 Detect 输出为姿态检测结果, Pose 输出为关键点检测结果,分别对应猪只姿态检测模型与猪只关键点检测模型。模型实际输出根据超参数所设定的任务类型而变动,不会同时输出。

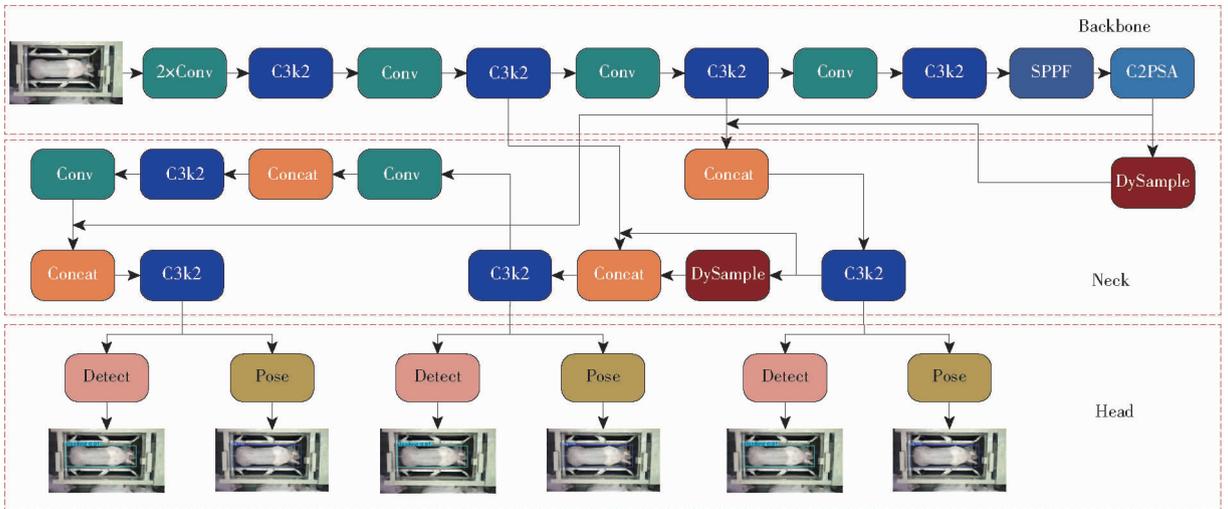


图 4 改进 YOLO 11 模型结构

Fig. 4 Architecture of improved YOLO 11 model

为提升边缘部署性能,在保持网络深度 1 024 不变的前提下,将宽度系数由 (0.5, 0.25) 缩小至 (0.25, 0.125),形成轻量模型 YOLO 11ns;进一步引入 DySample 算子,得到优化模型 YOLO 11nds。将模型分别在猪只姿态数据集与关键点数据集上进行训练,用于姿态检测与关键点检测任务。

2.4 模型训练

模型训练主要有 4 个步骤: Mosaic 增强、数据加载与解析、前向传播、损失函数计算预测误差,具体内容为:①通过 Mosaic 方法增强输入图像,增加数据样本多样性,帮助提高模型鲁棒性与泛化能力。②加载处理后训练数据与对应标签,解析获取标签

信息后写入内存。③读取内存中的数据,通过 Backbone 进行特征提取,Neck 增强特征并产生不同层次的特征信息,最后输入 Head 生成预测输出。④根据预测输出与真实标签计算各部分损失值,通过反向传播更新权重与偏置。

训练时主要超参数包括:训练轮次 (epochs) 为 100、批次大小为 16、优化器为 Adam、初始学习率为 0.01、最终学习率为 0.000 1。

2.5 猪只体尺测量方法

将双目视频输入姿态检测模型,提取左右目图像均为标准测定姿态的数据帧并保存。对每帧尺寸为 2 560 像素 × 720 像素的图像从中间裁剪,得到左

目与右目各 1 280 像素 \times 720 像素的图像对。将左目图像输入关键点检测模型, 结合鼻尖关键点 N 进一步判断和矫正姿态。若姿态合格, 则利用 SGBM 对左右目图像进行立体匹配生成视差图, 并将关键

点映射至对应位置, 通过相机高度减去测点深度值获得体高与臀高, 通过欧氏距离计算体长、体宽、臀宽。测量流程如图 5 所示, 其中 L 为左目图, R 为右目图, D 为视差图。

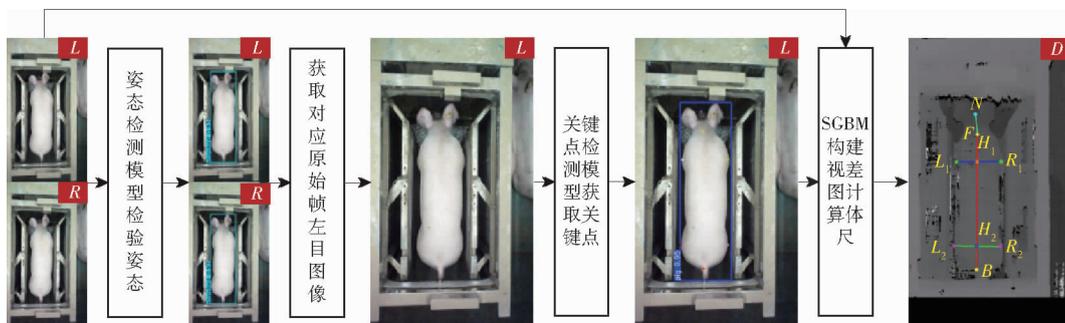


图 5 猪只体尺测量方法示意图

Fig. 5 Schematic of pig body size measurement method

体尺参数的具体计算方法如表 2 所示。其中, 体高臀高测点 H_1 与 H_2 分别为 $L_1 - R_1$ 、 $L_2 - R_2$ 与 $F - B$ 连线的交点, 体高和臀高通过相机高度 H 分别减去测点处深度 $D(H_1)$ 与 $D(H_2)$ 获得, 1 号栏、2 号栏、3 号栏的双目相机安装高度分别为 1.875、1.970、1.980 m; 体长为 $F - H_1$ 、 $H_1 - H_2$ 、 $H_2 - B$ 3 段连线的三维欧氏距离之和 $O(F - H_1) + O(H_1 - H_2) + O(H_2 - B)$, 以此降低猪体弯曲所带来的影响; 体宽为 $L_1 - R_1$ 连线的三维欧氏距离 $O(L_1 - R_1)$; 臀宽为 $L_2 - R_2$ 连线的三维欧氏距离 $O(L_2 - R_2)$ 。

表 2 体尺参数计算方法

Tab. 2 Body size parameter calculation methods

| 参数 | 计算点 | 计算公式 |
|----|------------------|--|
| 体高 | H_1 | $H - D(H_1)$ |
| 臀高 | H_2 | $H - D(H_2)$ |
| 体长 | F, H_1, H_2, B | $O(F - H_1) + O(H_1 - H_2) + O(H_2 - B)$ |
| 体宽 | L_1, R_1 | $O(L_1 - R_1)$ |
| 臀宽 | L_2, R_2 | $O(L_2 - R_2)$ |

2.6 模型部署

2.6.1 模型部署平台

PC 端设备存在成本高、功耗大、体积庞大等问题, 难以适应猪场工作环境。因此, 选择采用 NVIDIA Jetson Orin NX 16 GB 版本作为边缘计算平台。该设备具有体积小、功耗低等显著优点。设备操作系统为 Ubuntu 22.04, Jetpack 版本为 5.12。

2.6.2 模型转换加速

将 PC 端训练好的 YOLO 11 系列模型 (n、ns、nd、nds) 迁移至 Jetson Orin NX, 通过将 PyTorch 权重 (pt) 转换为 ONNX 格式, 再转为 engine 格式, 实现模型编译与部署, 并通过 TensorRT 加速推理。

加速过程主要步骤为: ①将卷积、偏置以及激活

层合并成一个 CBR 结构, 形成层间融合, 减少 CUDA 核心占用, 合成示意图如图 6 所示。②将 32 位浮点数降低为 FP16 或 INT8, 减少内存占用量、降低延迟。③指定每一个 tensor 调用, 提高重复使用效率。

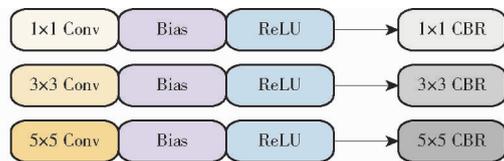


图 6 层间融合

Fig. 6 Inter-layer fusion

2.6.3 边缘计算流程

在 Jetson Orin NX 边缘平台上构建了一套完整的猪只体尺测量流程, 边缘部署流程如图 7 所示, 部署于 Jetson Orin NX 运行示意图如图 8 所示。流程包含 3 个主要模块: 姿态检测、关键点检测与映射、体尺测量, 并通过自动化的 Shell 脚本串接各个步骤, 确保系统高效、稳定地运行。

系统启动后进行内存清理操作, 清除上次运行的残留数据, 确保系统在每次运行时都能以无历史数据干扰的状态进行数据处理。随后进入姿态筛选模块, 该模块主要功能为提取猪只视频中的标准姿态数据帧, 并裁剪成左右目图像对。该模块所输出的图像中左目部分作为关键点检测与映射的输入, 以此降低计算量, 提升推理速度。在关键点检测与映射模块中, 主要任务是进行猪只关键点检测、SGBM 立体匹配, 并将匹配后的关键点映射到视差图中。完成后, 带有关键点信息的视差图被传输至体尺测量模块, 该模块负责获取关键点的三维信息并进行体尺参数的测量。在体尺测量过程中, 双目立体匹配会产生少量空洞点导致深度值爆炸, 故进行异常值检测与剔除, 避免测量结果失真。最后取

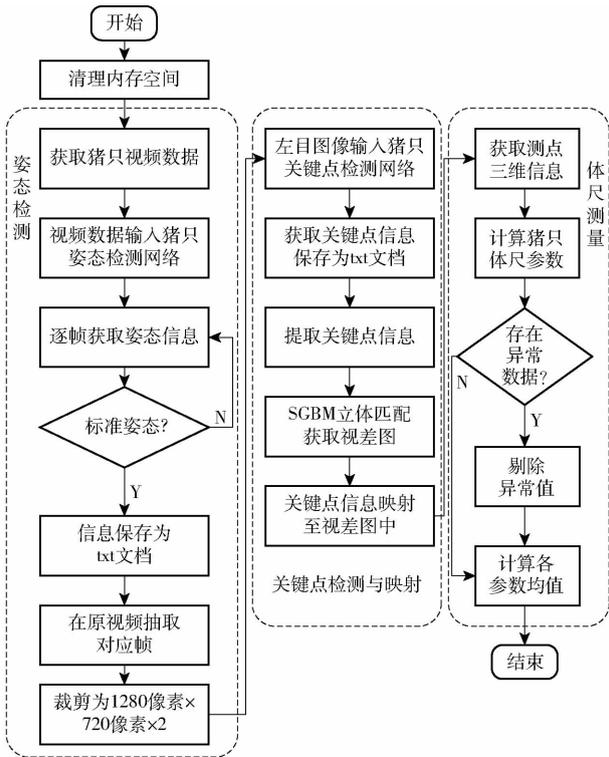


图7 边缘部署流程图

Fig. 7 Diagram of edge deployment architecture



Jetson Orin NX 七英寸液晶显示屏

图8 Jetson Orin NX 运行示意图

Fig. 8 Schematic of Jetson Orin NX operation

符合测量条件的所有数据帧的体尺均值作为最终结果并输出。

2.7 评估指标

为对各模型性能进行客观、全面评价,针对猪只姿态检测模型,采用平均精度均值(mean Average Precision, mAP)、准确率、F1 分数、推理速度及参数量作为评价指标。其中,采用 mAP@0.5:0.95 即在交并比 (Intersection over union, IoU) 阈值为 0.5 ~ 0.95、以 0.05 为步长计算得到平均精度均值;推理速度用于衡量模型实时性,表示模型每秒可完成推理的图像数量。

针对猪只关键点检测模型,采用 mAP、目标关键点相似度 (Object keypoint similarity, OKS)、正确关键点比例 (Percentage of correct keypoints, PCK)、推理速度及参数量进行综合评估。其中,OKS 通过综合考虑各关键点的定位误差及其尺度标准差,对

预测关键点与真实标注之间的相似程度进行度量; PCK 则基于预测关键点与真实关键点之间的欧氏距离,判断该距离是否满足给定阈值,从而对关键点定位的准确性进行量化评估。本文将 PCK 阈值设置为 0.05。

3 结果与分析

3.1 训练结果分析

训练 100 轮次的姿态检测模型在验证集上的分类损失值、边界框损失值曲线如图 9 所示;训练 100 轮次的关键点检测模型在验证集上的关键目标损失值、边界框损失值曲线如图 10 所示。

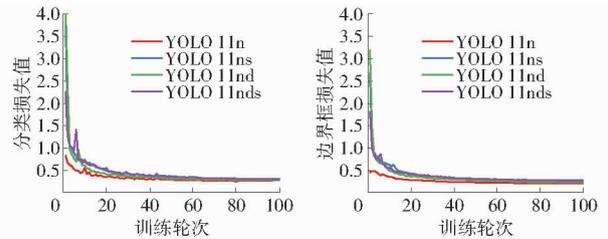


图9 姿态检测模型损失曲线

Fig. 9 Loss curves of posture detection model

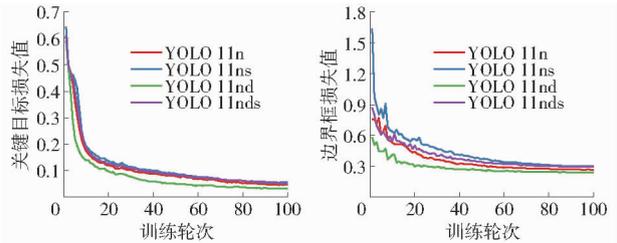


图10 关键点检测模型损失曲线

Fig. 10 Loss curves of keypoint detection model

由图 9 可知,4 个模型分类损失值与边界框损失值在前 10 个训练轮次内快速下降,后保持振荡收敛趋势缓慢下降并趋于稳定;由图 10 可知,关键目标损失值、边界框损失值在前 20 个轮次内快速下降并收敛。无论是姿态检测还是关键点检测的 4 个模型均得到了有效的特征拟合,学习效果良好。

训练 100 轮次的姿态检测模型与关键点检测模型在验证集上的平均精度均值如图 11 所示。

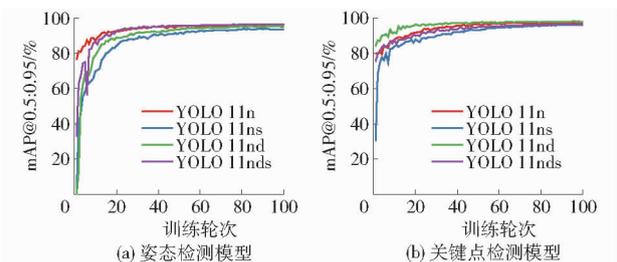


图11 验证集平均精度均值

Fig. 11 Validation set mAP@0.5:0.95 results

由图 11 可知,不同姿态检测模型与关键点检测

模型在验证集上均表现出良好的性能。其中,图 11a 显示 YOLO 11n 模型收敛速度较快,仅在几个训练轮次内其 $mAP@0.5:0.95$ 就超过 80%,而其余模型的收敛过程相对较慢。引入 DySample 算子的 YOLO 11nds 模型在多轮训练后取得了最高的 $mAP@0.5:0.95$,初步验证了改进模型性能的提升。由图 11b 可以观察到 YOLO 11nd 模型性能优于 YOLO 11n 模型。同时,YOLO 11nds 模型也优于仅调整网络宽度系数的 YOLO 11ns,进一步验证了改进方法有效性及改进模型性能优越性。

3.2 测试结果分析

为进一步多角度评估模型性能,将 2 个模型在测试集上进行测试。测试可视化结果如图 12 所示,

测试集详细评估结果如表 3 所示。

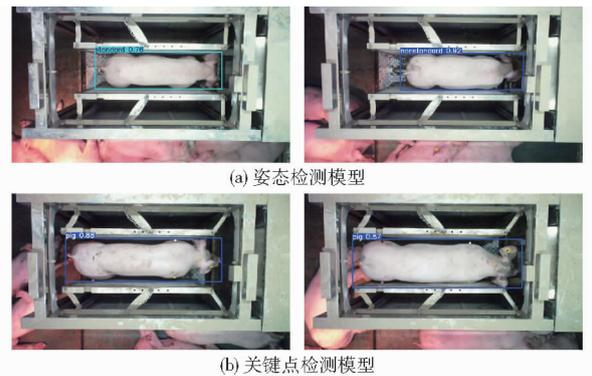


图 12 测试可视化结果

Fig. 12 Results of visualization evaluation

由表 3 可知,YOLO 11n 在姿态检测任务中的准

表 3 测试集评估结果

Tab. 3 Evaluation metrics on test set

| 模型 | 猪只姿态 | | | | 猪只关键点 | | | |
|------------|-------|---------|---------------------------|--------------------|-------|-------|---------------------------|--------------------|
| | 准确率/% | F1 分数/% | 推理速度/($f \cdot s^{-1}$) | 参数量 | OKS/% | PCK/% | 推理速度/($f \cdot s^{-1}$) | 参数量 |
| YOLO 11n | 97.96 | 93.29 | 63.94 | 2.59×10^6 | 97.51 | 97.05 | 57.87 | 2.69×10^6 |
| YOLO 11ns | 96.23 | 91.98 | 75.76 | 8.10×10^5 | 96.51 | 93.94 | 65.23 | 8.60×10^5 |
| YOLO 11nd | 98.21 | 93.38 | 61.69 | 2.60×10^6 | 97.84 | 97.89 | 57.05 | 2.70×10^6 |
| YOLO 11nds | 97.18 | 92.98 | 73.96 | 8.20×10^5 | 97.04 | 95.83 | 62.58 | 8.70×10^5 |

确率达到 97.96%,F1 分数达到 93.29%,在关键点检测任务中的 OKS 和 PCK 分别为 97.51%、97.05%,可知作为基线模型,无论是在猪只姿态检测任务中还是在猪只关键点检测任务中,已具备较佳的特征拟合能力与表达能力。改进模型 YOLO 11nd,进一步提升了多个指标,姿态检测任务的准确率达 98.21%,F1 分数达 93.38%,相较于 YOLO 11n 分别提升 0.25、0.09 个百分点;关键点检测任务的 OKS 和 PCK 分别达到 97.84%、97.89%,较 YOLO 11n 分别提升 0.33、0.84 个百分点。YOLO 11nds 作为进一步改进的模型,旨在保证模型效果的同时降低模型参量、提升模型推理速度。从表 3 可以看出,YOLO 11nds 的姿态任务准确率为 97.18%,F1 分数为 92.98%,较 YOLO 11ns 分别提升 0.95、1.00 个百分点,推理速度为 73.96 f/s ,较 YOLO 11ns 慢 1.80 f/s ,参数量多 1.0×10^4 ;关键点检测任务的 OKS、PCK 分别为 97.04%、95.83%,相对于 YOLO 11ns 分别提升 0.53、1.89 个百分点,推理速度为 62.58 f/s ,稍慢于 YOLO 11ns 2.65 f/s ,参数量多 1×10^4 。整体而言,YOLO 11nds 的各指标虽非最优,但较 YOLO 11n、YOLO 11nd 参数量,仅为其近 25%,推理速度提升 10%~20%,而各指标并没有下降太多,在精度保持、推理效率提升与轻量化设计之间取得了最优平衡,综合性能最佳,无论是对猪只姿态检测任务还是猪只关键点检测任务均表现

出了较好的适应性。

综上,YOLO 11nds 是综合性能最佳的模型,因此后续部署应用选用该模型进行猪只姿态检测以及猪只关键点检测。

3.3 模型部署结果分析

基于 YOLO 11nds 模型,经 $pt - ONNX - engine$ 转换后,分别得到姿态模型与关键点模型的 $engine$ 格式权重文件。对 pt 权重和 $engine$ 权重在测试集上分别进行测试,同时将 PC 端与 Jetson Orin NX 端结果进行对比,如表 4 所示,其中平台 Jetson 为 Jetson Orin NX 的省略形式。

表 4 PC 端与 Jetson 端测试结果

Tab. 4 Results on PC and Jetson platforms

| 平台 | 权重格式 | 精度 | 猪只姿态 | | | 猪只关键点 | | |
|--------|----------|------|-------|---------|---------------------------|-------|-------|---------------------------|
| | | | 准确率/% | F1 分数/% | 推理速度/($f \cdot s^{-1}$) | OKS/% | PCK/% | 推理速度/($f \cdot s^{-1}$) |
| PC | pt | FP32 | 97.18 | 92.98 | 73.96 | 97.04 | 95.83 | 62.58 |
| PC | $engine$ | FP32 | 99.25 | 94.32 | 270.27 | 97.51 | 97.08 | 212.77 |
| PC | $engine$ | FP16 | 99.19 | 94.27 | 294.12 | 97.50 | 97.04 | 277.78 |
| PC | $engine$ | Int8 | 98.51 | 92.88 | 322.58 | 96.97 | 95.43 | 285.71 |
| Jetson | pt | FP32 | 98.54 | 93.24 | 42.74 | 97.04 | 95.83 | 36.63 |
| Jetson | $engine$ | FP32 | 99.22 | 94.31 | 121.95 | 97.51 | 97.05 | 123.46 |
| Jetson | $engine$ | FP16 | 99.17 | 94.26 | 156.25 | 97.50 | 97.06 | 169.49 |
| Jetson | $engine$ | Int8 | 98.40 | 92.84 | 212.77 | 96.43 | 93.43 | 188.68 |

由表 4 可知,无论是在 PC 端还是 Jetson 端,转

换成 engine 权重后构建的各个精度模型综合性能均优于基于 pt 权重构建的模型,其中 PC 端 FP32 精度的 engine 权重推理结果表现最佳,在猪只姿态任务中准确率达 99.25%,F1 分数达到 94.32%,推理速度达到 270.27 f/s,比 pt 权重预测结果分别高 2.07、1.34 个百分点、196.31 f/s;而在猪只关键点检测任务中其 OKS 为 97.51%,PCK 为 97.08%,推理速度为 212.77 f/s,比 pt 权重的预测结果分别高 0.47、1.23 个百分点、150.19 f/s。这一结果表明,pt 转成 engine 时,层间融合不仅优化了网络结构,还提高了推理速度。达到了全面提升模型性能的效果,为边缘部署提供了可靠支撑。

由 Jetson 端的表现知,engine 权重各个精度预测结果均低于 PC 端对应的 engine 权重各精度预测结果,如猪只姿态任务的 FP16 精度 engine 权重在 PC 端上的准确率为 99.19%,F1 分数为 94.27%,而在 Jetson 端的对应准确率为 99.17%,F1 分数为 94.26%。虽稍低一些,但差距并不大,表明 Jetson 虽不具备 PC 端强大的细节推理能力,但也并不逊色过多,可以很好地完成模型边缘化部署任务。

其中,FP16 精度的 engine 权重各指标较 FP16 精度相差无几,但较 Int8 精度有明显优势,因此选取 FP16 精度的 engine 权重作为最终模型部署使用

权重。基于此模型在保证精度情况下,在 2 个任务上推理速度比优化前模型分别提高 265.47%、362.71%,实现了速度和精度双优。

3.4 体尺测量结果分析

基于边缘部署的模型,对 2024 年 1 月 28 日与 2024 年 3 月 9 日猪只 104 条原始视频数据分别进行推理,获取目标姿态猪只及其关键点信息后,进行立体匹配后测算体尺的 5 个指标,立体匹配后可视化结果如图 13 所示,得到的体尺结果如图 14 所示,相对误差结果如表 5 所示。其中,真实值为人工测量体尺数据,预测值为模型输出结果,相对误差百分比为预测值相对于真实值相对误差绝对值,均值为所测指标相对误差均值。

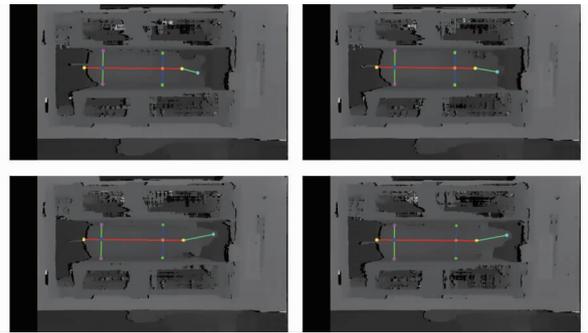


图 13 立体匹配可视化结果

Fig. 13 Visualization of stereo matching results

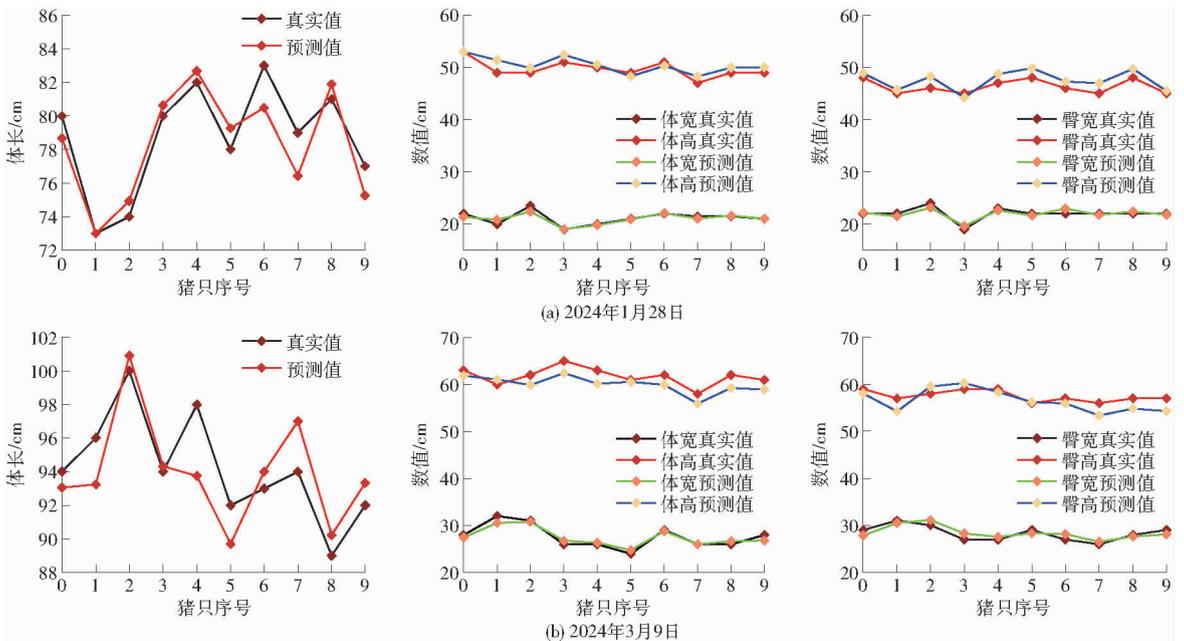


图 14 预测结果与人工测量结果

Fig. 14 Prediction results vs manual measurements

图 13 动态展示了经检测后符合测定姿态条件的连续帧视差图效果,可见立体匹配得到的视差图效果良好,关键点信息完整、映射位置正确。由图 14 及表 5 可知,不论是在 2024 年 1 月 28 日(较小育龄)还是在 2024 年 3 月 9 日(较大育龄)猪只

数据中,体长、体宽、臀宽、体高及臀高等体尺参数的相对误差均在 5% 以内,表明本文方法在不同生长阶段猪只体尺测量中具有较好精度。与基于点云与测地距离回归的体尺测量方法相比,本文在关键点检测前增加了姿态筛选方法。与文献[23]

表 5 相对误差结果

Tab. 5 Relative error results %

| 猪只 序号 | 2024年1月28日 | | | | | 2024年3月9日 | | | | |
|----------|------------|------|------|------|------|-----------|------|------|------|------|
| | 体长 | 体宽 | 臀宽 | 体高 | 臀高 | 体长 | 体宽 | 臀宽 | 体高 | 臀高 |
| 0 | 1.64 | 2.75 | 0.98 | 0.01 | 1.79 | 1.00 | 1.90 | 3.87 | 1.80 | 1.63 |
| 1 | 0.01 | 4.27 | 2.25 | 4.88 | 1.62 | 2.88 | 4.45 | 1.56 | 1.86 | 4.90 |
| 2 | 1.27 | 4.80 | 3.69 | 1.76 | 4.90 | 0.90 | 0.65 | 3.73 | 3.42 | 2.64 |
| 3 | 0.80 | 0.39 | 3.30 | 2.77 | 1.71 | 0.34 | 2.77 | 4.77 | 3.94 | 2.15 |
| 4 | 0.82 | 0.99 | 1.49 | 0.97 | 3.59 | 4.34 | 1.18 | 1.97 | 4.54 | 1.09 |
| 5 | 1.64 | 0.35 | 1.68 | 1.50 | 3.92 | 2.50 | 3.17 | 2.34 | 0.67 | 0.42 |
| 6 | 3.03 | 0.63 | 4.28 | 1.44 | 2.77 | 1.08 | 0.75 | 4.22 | 3.40 | 1.86 |
| 7 | 3.25 | 1.93 | 1.08 | 2.60 | 4.34 | 3.19 | 0.03 | 2.00 | 3.61 | 4.74 |
| 8 | 1.09 | 0.59 | 1.93 | 2.00 | 3.52 | 1.38 | 2.59 | 1.34 | 4.42 | 3.83 |
| 9 | 2.26 | 0.27 | 0.99 | 2.08 | 1.12 | 1.43 | 4.36 | 3.17 | 3.37 | 4.72 |
| 均值 | 1.58 | 1.70 | 2.17 | 2.00 | 2.93 | 1.90 | 2.18 | 2.90 | 3.10 | 2.80 |

结果对比显示,本文算法在1月28日测量的体长、体宽、体高精度分别提升1.25、3.63、0.84个百分点;在3月9日测量的体长、体宽分别提升0.93、3.15个百分点,体高仅略低0.26个百分点,弥补了文献[23]未做姿态筛选的局限。

综上,本文算法对2批数据检测相对误差均值均较低,且对不同猪只个体间相对误差波动范围较小,无论是试验之初的较小猪只数据还是试验末期的较大猪只数据,均表现了较好的适应性,表明本文方法具有较高的测量精度与较强的鲁棒性。

4 结论

(1)基于时间序列化猪只数据构建猪只姿态数据集与猪只关键点数据集,建立YOLO 11系列模型并对模型进行改进,训练猪只姿态检测模型与猪只关键点检测模型,在RTX4090环境下测试基础模型

YOLO 11n和改进模型YOLO 11ns、YOLO 11nd以及YOLO 11nds,并进行对比试验。结果表明,改进YOLO 11nds姿态检测模型在保持参数量仅 8.2×10^5 的情况下,推理速度达到73.96 f/s;关键点检测模型则以参数量为 8.7×10^5 实现了62.58 f/s的推理速度,在精度与速度之间取得了优异平衡,为嵌入式部署提供了坚实基础。

(2)搭建基于Jetson Orin NX的软硬件环境,使用模型量化技术对模型权重结构与内容进行优化,利用TensorRT推理引擎进行加速推理,实现基于YOLO 11nds的猪只姿态检测模型与猪只关键点检测模型在Jetson Orin NX移动平台的嵌入式部署。在Jetson Orin NX上对猪只姿态检测模型与猪只关键点检测模型分别进行测试,在FP16精度模式下,检测推理速度分别为156.25、169.49 f/s,猪只姿态检测准确率与F1分数为99.17%、94.26%,猪只关键点检测OKS与PCK为97.50%、97.06%。综合考虑模型精度与运行效率,FP16模型展现出最优综合性能,模型足够轻量且运行效率足够高,能够在边缘计算设备中实现猪只姿态与猪只关键点自动实时检测。

(3)提出一种基于SGBM算法的体尺测量方法,对具有真实标签的2批数据进行测试,结果显示,在第1批育龄较小数据上体长、体宽、臀宽、体高、臀高相对误差均值分别为1.58%、1.70%、2.17%、2.00%、2.93%,在第2批育龄较大数据上相应指标的相对误差均值分别为1.90%、2.18%、2.90%、3.10%、2.80%,验证了算法在猪只体尺精准自动测量方面的有效性,且对不同体型个体均具备良好的泛化能力。

参 考 文 献

- [1] BJARNE N, VESTERGAARD L H, P S T, et al. Selection for social genetic effects in purebred pigs improves behaviour and handling of their crossbred progeny[J]. *Genetics Selection Evolution*, 2023, 55(1): 54.
- [2] 周波. 猪育种中关键福利性状选择的重要性及其研究进展[J]. *猪业科学*, 2024, 41(10): 19-22.
- [3] 黎焯, 刘诗尧, 赵书红, 等. 融合体尺信息的封闭式种猪性能测定站设计与试验[J]. *农业机械学报*, 2022, 53(7): 267-274. LI Xuan, LIU Shiyao, ZHAO Shuhong, et al. Development and experiment of closed performance measuring station for breeding pig integrating body size information[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2022, 53(7): 267-274. (in Chinese)
- [4] 王可, 郭浩, 马钦, 等. 基于单视角点云镜像的猪只体尺测量方法[J]. *农业机械学报*, 2018, 49(3): 187-195. WANG Ke, GUO Hao, MA Qin, et al. Pig body size measurement method based on mirror reflection of single angle point cloud [J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2018, 49(3): 187-195. (in Chinese)
- [5] 周明彦, 黎焯, 祝志慧, 等. 基于双目-红外多源数据的猪只体尺自动测量方法[J]. *华中农业大学学报*, 2025, 44(2): 9-16. ZHOU Mingyan, LI Xuan, ZHU Zhihui, et al. Method of automatically measuring body size of pigs based on stereo-infrared multi-source data[J]. *Journal of Huazhong Agricultural University*, 2025, 44(2): 9-16. (in Chinese)
- [6] 王可, 郭浩, 刘威林, 等. 基于点云旋转归一化的猪体体尺测点提取方法[J]. *农业工程学报*, 2017, 33(增刊1): 253-259. WANG Ke, GUO Hao, LIU Weilin, et al. Extraction method of pig body size measurement points based on rotation normalization of point cloud[J]. *Transactions of the CSAE*, 2017, 33(Supp. 1): 253-259. (in Chinese)
- [7] 李卓, 杜晓冬, 毛涛涛, 等. 基于深度图像的猪体尺检测系统[J]. *农业机械学报*, 2016, 47(3): 311-318. LI Zhuo, DU Xiaodong, MAO Taotao, et al. Pig dimension detection system based on depth image[J]. *Transactions of the Chinese Society for Agricultural Machinery*, 2016, 47(3): 311-318. (in Chinese)

- [8] 初梦苑, 司永胜, 李前, 等. 家畜体尺自动测量技术研究进展[J]. 农业工程学报, 2022, 38(13): 228-240.
CHU Mengyuan, SI Yongsheng, LI Qian, et al. Research advances in the automatic measurement technology for livestock body size[J]. Transactions of the CSAE, 2022, 38(13): 228-240. (in Chinese)
- [9] 田芳, 彭彦昆. 生猪肉产量预测的非接触实时在线机器视觉系统[J]. 农业工程学报, 2016, 32(2): 230-235.
TIAN Fang, PENG Yankun. Machine vision system of nondestructive real-time prediction of live-pig meat yield[J]. Transactions of the CSAE, 2016, 32(2): 230-235. (in Chinese)
- [10] 翟肇裕, 张梓涵, 徐焕良, 等. YOLO 算法在动植物表型研究中应用综述[J]. 农业机械学报, 2024, 55(11): 1-20.
ZHAI Zhaoyu, ZHANG Zihan, XU Huanliang, et al. Review of applying YOLO family algorithms to analyze animal and plant phenotype[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(11): 1-20. (in Chinese)
- [11] 赵健, 周国源, 王智文, 等. 基于 SGPointNet++ 模型的奶牛点云分割与表型自动测定系统设计[J]. 农业机械学报, 2025, 56(3): 180-187.
ZHAO Jian, ZHOU Guoyuan, WANG Zhiwen, et al. Design of automatic determination system for point cloud segmentation and morphology of dairy cows based on SGPointNet++ model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(3): 180-187. (in Chinese)
- [12] 袁培森, 丁毅飞, 徐焕良. 基于深度主动学习与 CBAM 的细粒度菊花表型识别[J]. 农业机械学报, 2024, 55(2): 258-267.
YUAN Peisen, DING Yifei, XU Huanliang. Fine-grained chrysanthemum phenotype recognition based on deep active learning and CBAM[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(2): 258-267. (in Chinese)
- [13] SHUMALY M, PARK Y, AGHA S, et al. Computer vision-based animal phenotyping and analysis in presence of uncertain identification[J]. Computers and Electronics in Agriculture, 2025, 237(Part A): 110560.
- [14] CHEN Z, LU J, WANG H. A review of posture detection methods for pigs using deep learning[J]. Applied Sciences, 2023, 13(12): 6997.
- [15] DONG W, ZHANG J, TAN S, et al. Detection method of fat content in pig b-ultrasound based on deep learning[J]. IEICE Transactions on Information and Systems, 2023, E106.D(5): 726-734.
- [16] 司永胜, 安露露, 刘刚, 等. 基于 Kinect 相机的猪体理想姿态检测与体尺测量[J]. 农业机械学报, 2019, 50(1): 58-65.
SI Yongsheng, AN Lulu, LIU Gang, et al. Ideal posture detection and body size measurement of pig based on Kinect[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(1): 58-65. (in Chinese)
- [17] 赵宇亮, 曾繁国, 贾楠, 等. 基于 DeepLabCut 算法的猪只体尺快速测量方法研究[J]. 农业机械学报, 2023, 54(2): 249-255.
ZHAO Yuliang, ZENG Fanguo, JIA Nan, et al. Measurements of pig body size based on DeepLabCut algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(2): 249-255. (in Chinese)
- [18] 刘刚, 曾雪婷, 刘晓文, 等. 基于改进 YOLO v5-pose 的群养生猪体尺自动测量方法[J]. 农业机械学报, 2025, 56(5): 455-465.
LIU Gang, ZENG Xueting, LIU Xiaowen, et al. Automatic measurement method of body size of group-raised pigs based on improved YOLO v5-pose[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(5): 455-465. (in Chinese)
- [19] LI Z, WENG Z, LIN W, et al. Point cloud reconstruction and body size measurement of a contactless pig body[C]//IEEE Conference on Machine Learning, Cloud Computing and Intelligent Mining, 2023: 1-7.
- [20] JIANG Y H, LI Z C, CAO J S, et al. Body parts segmentation and phenotypic traits extraction of pig using an improved point cloud segmentation network with multi-LiDAR[J]. Computers and Electronics in Agriculture, 2025, 237: 110624.
- [21] 耿艳利, 季燕凯, 岳晓东, 等. 基于点云语义分割的猪只体尺测量方法研究[J]. 农业机械学报, 2023, 54(7): 332-338, 380.
GENG Yanli, JI Yankai, YUE Xiaodong, et al. Pigs body size measurement based on point cloud semantic segmentation[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(7): 332-338, 380. (in Chinese)
- [22] SHI K, GENG Y, LIU S, et al. Automatic measurement method of pig body size based on improved point Transformer segmentation network[C]//IEEE Conference on Image Processing, Computer Vision and Machine Learning, 2024: 636.
- [23] XU Z K, LI Q F, MA W H, et al. A geodesic distance regression-based semantic keypoints detection method for pig point clouds and body size measurement[J]. Computers and Electronics in Agriculture, 2025, 234: 110285.
- [24] 刘同海, 滕光辉, 付为森, 等. 基于机器视觉的猪体体尺测点提取算法与应用[J]. 农业工程学报, 2013, 29(2): 161-168.
LIU Tonghai, TENG Guanghui, FU Weisen, et al. Extraction algorithms and applications of pig body size measurement points based on computer vision[J]. Transactions of the CSAE, 2013, 29(2): 161-168. (in Chinese)
- [25] 王晨阳. 猪非接触式体尺测定和发情鉴定的应用研究[D]. 杨凌: 西北农林科技大学, 2022.
WANG Chenyang. Application of non-contact body size measurement and estrus identification in pigs[D]. Yangling: Northwest A&F University, 2022. (in Chinese)
- [26] 安露露. 基于机器视觉的猪体尺测量及行为识别研究[D]. 保定: 河北农业大学, 2020.
AN Lulu. Research on pig measurement and behavior recognition based on machine vision[D]. Baoding: Hebei Agricultural University, 2020. (in Chinese)
- [27] 宋国柱, 黄文静, 崔帅帅, 等. 基于改进 YOLOv8n 的轻量化番茄叶片小目标病害识别方法[J]. 农业工程学报, 2025, 41(10): 232-242.
SONG Guozhu, HUANG Wenjing, CUI Shuaishuai, et al. Identifying the small target disease of tomato leaves using lightweight improved YOLOv8n[J]. Transactions of the CSAE, 2025, 41(10): 232-242. (in Chinese)
- [28] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[C]//2015 IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015: 1904-1916.
- [29] ZHAO Y, JIANG Z. YOLO-WWBi: an optimized YOLO 11 algorithm for PCB defect detection[J]. IEEE Access, 2025, 13: 74288-74297.
- [30] LIU W, LU H, FU H, et al. Learning to upsample by learning to sample[C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV), 2023: 6004-6014.