

基于关键点检测的动态山羊体尺测量

董 萧^{1,2} 张顺龙³ 张子睿³ 孔维康⁴ 饶 元⁴ 孙少明^{1,2}

(1. 中国科学技术大学, 合肥 230026; 2. 中国科学院合肥物质科学研究院智能机械研究所, 合肥 230031;
3. 安徽农业大学工学院, 合肥 230036; 4. 安徽农业大学信息与人工智能学院, 合肥 230036)

摘要: 山羊体尺测量是养殖管理的基础性环节,可提供量化生产性能、解析遗传特性、提升选种配准确性,监控健康状态的核心指标,对提升养殖经济效益与优化遗传育种方案发挥着不可替代的决策支撑作用。针对多姿态下动态山羊体尺测量困难问题,本研究提出了基于山羊关键点的多姿态体尺测量方法。采用改进 YOLO v8n-Pose 深度学习模型 YOLO v8n-SK 对通道内山羊进行关键点检测,该模型特别侧重于对山羊膝关节关键点的精确检测,旨在动态运动状态下最大限度地降低运动对体高测量的干扰;引入空间与通道重建卷积(ScConv)模块优化卷积到特征(C2f)结构,减少参数冗余的同时,增强模型的特征提取能力;加入 CBAM 注意力机制模块提高模型的抗干扰能力;并采用 EIoU 损失函数进一步优化模型训练过程,提升检测框的定位精度。进一步地从提取到的关键点坐标中获得山羊体尺相关特征,并结合单目深度估计数据,通过非线性回归模型对山羊体尺进行预测。实验结果表明,该模型在山羊躯干及背部关键点检测方面展现出优异的性能:检测精确率和召回率分别达 98.0% 和 98.1%, mAP@50-95 提升至 95.8%,模型复杂度显著降低,参数量和浮点计算量分别为 6.7×10^6 和 7.9×10^9 。体尺参数预测中,体高、胸围、腹围及体斜长平均绝对百分比误差分别为 2.408%、1.731%、1.340% 和 2.519%,表现出较高的测量精度。与传统人工测量方法相比,本方法能够大幅提升山羊体尺测量效率,并避免山羊受到应激刺激,在不干扰山羊情况下较为准确、快速地预测山羊体尺。

关键词: YOLO v8-Pose; 山羊; 体尺测量; 关键点检测

中图分类号: S818.9 文献标识码: A 文章编号: 1000-1298(2026)08-0278-11

OSID:



Dynamic Body Size Measurement of Individual Goats Based on Keypoint Detection

DONG Xiao^{1,2} ZHANG Shunlong³ ZHANG Zirui³ KONG Weikang⁴ RAO Yuan⁴ SUN Shaoming^{1,2}

(1. University of Science and Technology of China, Hefei 230026, China

2. Institute of Intelligent Machines, Hefei Institutes of Physical Science, Chinese Academy of Sciences, Hefei 230031, China

3. School of Engineering, Anhui Agricultural University, Hefei 230036, China

4. School of Information and Artificial Intelligence, Anhui Agricultural University, Hefei 230036, China)

Abstract: Body measurement of goats is a fundamental aspect of livestock management, serving as a core indicator for quantifying production performance, analyzing genetic traits, improving the accuracy of breeding selection, and monitoring health status. It plays an irreplaceable role in enhancing economic efficiency and optimizing genetic breeding strategies. To address the challenges of measuring goat body dimensions under dynamic and multi-posture conditions, a non-contact, rapid, and accurate measurement method was proposed. An improved YOLO v8n-Pose deep learning model, named YOLO v8n-SK, was developed for keypoint detection of goats in the channel environment. This model specifically focused on accurately detecting the knee joints of goats to minimize the interference of movement on height measurements during motion. The model introduced a spatial-channel collaborative reconstruction convolution (ScConv) module to optimize the convolution-to-feature (C2f) structure, reducing parameter redundancy while enhancing feature extraction capability. CBAM attention mechanism

收稿日期: 2025-08-13 修回日期: 2025-11-13

基金项目: 国家自然科学基金项目(32371993)、安徽省自然科学基金青年基金项目(2308085QC106)和安徽省教育厅高校科研项目(2023AH050982)

作者简介: 董萧(1992—),男,博士生,安徽农业大学讲师,主要从事计算机视觉和智慧养殖研究,E-mail: dx012210@ahau.edu.cn

通信作者: 孙少明(1978—),男,研究员,博士,主要从事农业机械与人工智能研究,E-mail: smsun@iim.ac.cn

was integrated to improve the model's robustness to interference, and an EIoU loss function was adopted to further optimize the training process and improve bounding box localization accuracy. From the extracted keypoints, body measurement-related features were obtained and combined with monocular depth estimation data. A nonlinear regression model was then employed to predict the goat body dimensions. Experimental results demonstrated that the proposed model exhibited excellent performance in detecting trunk and back keypoints, achieving a precision of 98.0%, recall of 98.1%, and mAP@50-95 of 95.8%. Meanwhile, the model complexity was significantly reduced, with parameters and FLOPs controlled at 6.7×10^6 and 7.9×10^9 , respectively. In the prediction of body measurement parameters, the mean absolute percentage errors (MAPE) for height, chest girth, abdominal girth, and body diagonal length were 2.408%, 1.731%, 1.340% and 2.519% respectively, demonstrating high measurement accuracy. Compared with traditional manual methods, the proposed approach significantly improved measurement efficiency and avoided stress responses in goats, enabling fast and accurate body measurement without disturbing the animals.

Key words: YOLO v8 - Pose; goat; linear body measurements; keypoint detection

0 引言

羊肉是我国居民日常饮食中重要的蛋白质来源,随着人民生活水平提升,其需求量逐年增长^[1]。据国家统计局数据,我国羊肉产量从 2018 年的 4.7507×10^6 t 增至 2024 年的 5.12×10^6 t,增长趋势显著^[2]。现代化规模养殖中,传统体尺测量需人工束缚羊只并用皮尺检测,不仅耗时费力、劳动强度大、易产生人为误差,还可能引发羊只应激反应,难以满足高效、低扰动的生产需求^[3-4]。因此,研发快速、精准、非接触式的山羊体尺采集方法,对提升养殖生产效率和数据准确性至关重要^[5]。

近年来,非接触式体尺测量技术在畜牧业应用广泛,已在牛、猪、鸡等多种畜体测量中取得诸多成果^[6-10]。但相较于其他畜种,山羊非接触式体尺测量在效率、精度及动态适应性上仍面临挑战。谷志帅等^[11]提出激光雷达测量系统,结合点云滤波与曲线拟合提取小尾寒羊 4 项体尺参数,平均耗时 5.1 s,平均相对误差为 2.23% ~ 6.40%,实时性不足;MENESATTI 等^[12]采用低成本双网络摄像机构建立体视觉系统,测量 Alpagota 绵羊肩高、胸深误差约 3.5%,体长误差约 5.0%,纵深指标易受姿态影响;ZHANG 等^[13]用三摄像头系统提取 6 项体尺参数,最大相对误差不大于 4.73%,但仅适用于静态姿态。因此,研发山羊动态非接触式测量技术尤为必要。

深度学习技术发展为动物体尺检测带来突破^[14-15]。RONG 等^[16]结合 YOLO v5s、Lite - HRNet 关键点检测与 Global - Local Path 深度估计算法,测量肉牛 4 项体尺参数,平均相对误差为 6.75% ~ 8.97%;SUN 等^[17]提出 KCGATNet 点云分割网络,经迁移学习应用于牛猪体部件分割,mIoU 约 90%,

提升了关键点定位精度;李明煌等^[18]利用 Azure Kinect 型相机与改进 YOLO v8n - Pose 模型,结合点云处理与三维重建,测量蒙古马 5 项体尺参数,平均相对误差为 2.29%;耿艳利等^[19]基于改进 PointNet 网络,利用 KinectV2 型相机测量大约克夏猪 6 项体尺参数,分割准确率为 86.3%,平均相对误差为 4.47%;赵宇亮等^[20]采用 DeepLabCut 算法与 EfficientNet b6 主干网络,结合 SVM 模型优化,测量猪只体尺最大均方根误差为 1.79 cm,提升了实时性与精度。

针对羊只自动化体尺测量的核心难题,本文基于现有视觉测量技术,提出双单目相机结合改进深度学习关键点检测的体尺预测方法。引入改进的 YOLO v8n - Pose 模型(YOLO v8n - SK),强化膝关节检测能力,通过捕捉髌甲、坐骨结节等核心关键点,借助几何关系稳定定义体尺参数,克服动态屈膝对体高的干扰;采用双普通单目相机替代高成本设备,通过相机标定与视差原理估算关键点深度,降低成本的同时满足 3D 体尺推算需求。结合回归模型预测体尺,以期实现自然无干扰状态下动态羊的高效精准测量,为羊只养殖体尺监测、健康评估提供技术支撑。

1 材料和方法

1.1 数据采集和制作

实验于安徽农业大学江淮分水岭试验站标准化室外羊圈内开展,该羊圈主体结构尺寸为长 45 m、宽 36 m、高 1.7 m。核心区域为特制通行通道(2.4 m × 1.2 m),通道中轴线 1.5 m 高度处安装海康威视 DS - 2DE3Q140MY - T 型相机,侧向 0.8 m 高度配置同型号相机,双机位形成 90°空间夹角以实现多视角同步采集。视频分辨率为 2 560 像素 × 1 440 像素,帧率为 25 f/s。

1.1.1 数据采集

实验对象为 50 头多品种杂交山羊,月龄(12 ± 2)月,体质量为(18.8 ~ 44.4) kg。为保证所采集数据质量,实验前实施 7 d 适应性训练,每日 08:00 和 16:00 进行 30 min 通道引导训练。数据采集周期为 2024 年 8 月 17—19 日,每日设置 08:30—10:30 和 14:30—16:30 2 个采集窗口,通过分组引导策略实现 3 ~ 4 只/批次的有序通行,批次间隔时间严格控制在(5 ± 0.5) min。通道如图 1 所示。




图 1 特制通行通道及摄像机安装位置
Fig.1 Specially designed access channels and camera installation locations

影像数据采集系统共记录有效视频 346 段,经预筛选后提取 1 012 幅高质量图像,其中俯视角图像 506 幅(分辨率 2 560 像素 × 1 440 像素),侧视角图像 506 幅(分辨率 1 440 像素 × 2 560 像素),为保证模型的泛化性,利用几何变换,亮度调节以及添加噪声对原始数据进行数据增强生成数据集 1 636 幅用于山羊 YOLO v8n - Pose 关键点检测模型的训练和评估,将标注完成的数据集按照比例 7:3 分为训练集和验证集,其中训练集和验证集分别为 1 146 幅和 490 幅。

为建立体尺预测回归模型,从 50 头山羊中随机选取 25 头实验羊进行测量任务:使用防水荧光记号笔在羊只两侧肋部标记唯一 ID 编号(尺寸 20 cm × 20 cm),随后在专业畜牧人员指导下,采用标准卷尺(精度 1 mm)测量站立状态下身高(髻甲至地面垂直距离)、胸围(肩胛后缘体躯周径)、腹围(腹部最膨大处周径)及体斜长(肩端至坐骨结节直线距离)。测量过程由 2 名操作员协同完成,一人固定羊体保持自然站立姿态,另一人执行测量操作,每项指标连续测量 3 次取算术平均值作为最终值,最大程度降低操作误差。引导山羊通过特制通行通道,其中编号 1 ~ 18 的羊只为训练集 220 组 440 幅图像数据,编号 19 ~ 25 的羊只为测试集 86 组共 172 幅图像数据。

1.1.2 数据标注

采用 Labelme 工具对实验图像中的羊体进行边界框标注,以蓝色框标识羊体轮廓,并在此基础上完成关键点位置的人工标注,为模型训练提供准确标签信息;共定义 15 类解剖关键点,其选择严格从解剖学意义与体尺计算需求出发,明确各关键点功能定位,如图 2 所示,侧视图和俯视图分别注释了 10 个关键点位置和 5 个关键点位置以获得山羊体尺信息。体高计算核心点包括蹄底 1、膝关节 2、肘关节 3、髻甲 5,相较于传统体高标注点,额外增加膝关节 2 与肘关节 3 可有效消除腿部弯曲状态对体高测量的干扰;体斜长计算核心点涵盖侧视图肩端 4、坐骨结节 8 及俯视图尾根 11、右腹部突 12、右肩胛 14,完全符合畜牧学中体斜长的定义规范;胸围/腹围计算核心点则分别由侧视图上肩胛 6、下肩胛 10/腹部上端 7、腹部下端 9 及俯视图右肩胛 14、左肩胛 15/右腹部突 12、左腹部突 13 组成,可通过多视角关键点特征构建更精准的围度计算模型。



图 2 羊只体尺参数对应关键点分布示意图
Fig.2 Schematic diagram of keypoint distribution corresponding to sheep body size parameters

为减小羊只移动导致其与摄像头距离发生变化引起的误差,引入单目深度估计技术:基于相机参数建立透视投影模型,通过关键点的空间坐标计算实际体尺参数。

1.2 关键点检测

基于 YOLO v8n - Pose 架构构建羊只关键点检测模型。YOLO v8n - Pose 作为一种轻量级单阶段目标检测算法,通过融合目标检测与姿态估计任务,在 COCO 数据集上展现出优异的性能平衡性^[20-23]。为适应山羊体尺检测场景中复杂背景干扰、目标形变及实时性需求,提出改进模型 YOLO v8n - SK,结构如图 3 所示,其核心改进包括特征压缩优化、注意力增强机制以及损失函数更换。

1.2.1 ScConv

在 YOLO v8 - Pose 关键点检测框架中,针对原 C2f 模块存在的特征冗余问题,采用空间-通道协同重建卷积(Spatial-channel collaborative reconstruction convolution, ScConv)模块^[24]。如图 4 所示,该模块通过级联式特征重建机制,在空间与通道维度实现双重优化:空间重构单元(Spatial reconstruction unit,




图 3 改进模型 YOLO v8n-SK 结构图
Fig. 3 Improved model YOLO v8n-SK structure diagram

SRU)采用动态特征剪枝策略消除空间冗余,通道重构单元(Channel reconstruction unit, CRU)通过分治融合策略压缩通道冗余,二者协同作用显著提升了关节点特征的判别性表达^[25]。

对于编码器给定中间特征张量 $\mathbf{X} \in \mathbf{R}^{N \times C \times H \times W}$ (其中 N 为批量大小, C 为通道数, H 、 W 分别为特征图空间高度与宽度), SRU 首先通过群体归一化(Group normalization, GN)评估特征信息量,首先,对输入特征 $\mathbf{X}$ 进行标准化处理,其计算过程为

$$\varepsilon_X^{out} = \text{GN}(\mathbf{X}) = \gamma \frac{\mathbf{X} - \boldsymbol{\mu}}{\sqrt{\boldsymbol{\sigma}^2 + \mathcal{J}}} + \boldsymbol{\beta} \quad (1)$$

式中 $\gamma, \boldsymbol{\beta}$ ——可学习参数




图 4 ScConv 模块结构
Fig. 4 Structure diagram of ScConv module

μ, σ ——特征图均值与标准差

$\mathcal{J}$ ——用于保证稳定性的极小常数

基于归一化结果,采用 L1 归一化生成通道注意力权重矩阵 $\mathbf{W}_r$,并通过门控 Sigmoid 函数实现硬阈值分,即

$$\mathbf{X}_w = H(\mathbf{W}_r \odot \text{GN}(\mathbf{x})) \quad (2)$$

其中

$$\mathbf{W}_r = \frac{w_i}{c} \sum_{j=1}^c \gamma_j$$

式中 H 为阈值函数,将权重映射至二元分布 $\{0, 1\}$ 。经 SRU 处理后的特征 $\mathbf{X}_w$ 输入至 CRU 单元,采用“拆分-变换-融合”(Split-transform-fusion, STF)策略进行通道维度优化:按分光比 $\alpha = 0.5$ 将特征划分为主支 $\mathbf{X}_m$ 与残支 $\mathbf{X}_r$,主支通过 4 组 3×3 分组卷积(Group weighted convolution, GWC)捕获局部空间关联性,残支则经压缩比 r 为 $1/4$ 的逐点卷积(Pointwise convolution, PWC)实现通道降维,最终通过特征拼接与 PWC 恢复通道维度,其定义为

$$\mathbf{Y} = \text{PWC}(\text{GWC}(\mathbf{X}_m) \text{PWC}(\mathbf{X}_r)) \quad (3)$$

在典型参数配置 ($\alpha = 0.5, g = 4, r = 1/4$) 下, ScConv 参数量 P_{sc} 较标准卷积 P_s 降低 66.7%,即

$$\frac{P_s}{P_{sc}} \approx \frac{k^2 C_1 C_1}{\frac{1}{r} [\alpha^2 + (1 - \alpha)^2] C_1^2 + \frac{k^2}{g} \alpha C_1 C_1} = 3 \quad (4)$$

将该模块嵌入 C2f 的 Bottleneck 结构形成 C2f-ScConv 改进模块,能够有效提升特征提取能力,其

优势体现在 SRU 对细粒度特征的保留、CRU 的动态通道选择机制对遮挡关键点的鲁棒性增强以及整体浮点运算量的显著降低。

1.2.2 CBAM

在数据采集环境中,存在金属框架、杂草等复杂背景干扰^[26-28],易导致模型提取的特征包含冗余信息或噪声。

在主干网络末端集成了卷积块注意力模块(CBAM)(结构如图 5 所示,由通道注意力子模块(CAM)与空间注意力子模块(SAM)串联构成),其能自适应地调整通道和空间维度的特征响应权重,有效增强山羊目标相关特征,抑制无关背景信息,从而生成更高质量、更具判别性的特征图。其计算过程为

$$F_{cam} = \text{Sigmoid}(\text{MLP}(\text{AvgPool}(F)) + \text{MLP}(\text{MaxPool}(F))) \otimes F \quad (5)$$
$$F_{sam} = \text{Sigmoid}(f^{7 \times 7}([\text{AvgPool}(F_{cam}); \text{MaxPool}(F_{cam})])) \otimes F_{cam} \quad (6)$$

式中 F_{cam} ——通道注意力模块
 F_{sam} ——空间注意力模块
MLP——独立参数的多层感知机
AvgPool——全局平均池化
MaxPool——最大池化
 $f^{7 \times 7}$ —— 7×7 卷积操作




图 5 CBAM 模块结构图

Fig. 5 CBAM module structure diagram

CBAM 模块通过级联式通道-空间注意力权重调整,使模型聚焦于羊只主体区域特征,抑制无关背景信息响应。在模型轻量化设计方面,通过替换主干网络的 C2f 模块为 ScConv,并优化注意力模块参

数配置,使最终构建的 YOLO v8n-SK 模型在保证检测精度的同时,降低计算复杂度。改进模型采用动态特征融合策略,在解码器阶段通过跨尺度特征混合与上采样操作,有效恢复目标细节信息,提升关键点定位精度。

1.2.3 EIou

YOLO v8-Pose 模型将目标检测任务与关键点检测任务融合于同一端到端统一框架中,目标检测部分预测每个物体的边界框(bbox)和类别,关键点检测部分在每个检测框内部回归 k 个关键点的二维空间坐标(x,y)及可见性标志 v (0 或 1),目标检测准确性在很大程度上决定关键点定位质量。

YOLO v8-Pose 中,原始使用的 Complete IoU(CIoU)损失函数在传统 IoU 基础上引入中心点距离和宽高比的一致性惩罚,以提升边界框空间对齐能力。其表达形式为

$$L_{CIoU} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{c^2} + \alpha_1 v \quad (7)$$

式中 $\rho(\cdot)$ ——预测框中心点与真实框中心点之间的欧氏距离

c ——两框最小外接矩形对角线长度
 v ——宽高比差异项
 α_1 ——调节权重

虽然 CIoU 在大多数静态图像检测任务中表现良好,但在动物动态通过狭窄通道这一特殊场景下,其对目标形状细节的建模能力存在一定不足,尤其是在长条形目标的宽高比例适应和帧间稳定性方面,表现出梯度不足、框体震荡等问题,进而影响关键点定位的准确性与连贯性。

为此,引入 Efficient IoU Loss(EIoU)替代 CIoU,用于提升边界框拟合的结构敏感性与收敛速度。EIou 在保留 IoU 与中心点距离项的基础上,将目标框的宽度与高度误差显式地分离建模,并归一化至最小外接框的尺度范围内,从而更细致地约束预测框与真实框在形状上的匹配。其定义为

$$L_{EIou} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{c^2} + \frac{(w_p - w_{gt})^2}{w_c^2} + \frac{(h_p - h_{gt})^2}{h_c^2} \quad (8)$$

式中 w_p, h_p, w_{gt}, h_{gt} ——预测框与真实框宽度、高度
 w_c, h_c ——两者共同外接矩形宽、高

与 CIoU 中对宽高比差异的间接建模不同, EIou 通过直接回归尺寸残差,使模型能够更敏锐地感知边界框在比例和尺寸上的误差,从而更快收敛至精确形状。在本研究场景中,羊只在通道中通常以身体长轴与通道平行的方式移动,检测框必须保

持足够的尺寸和中心稳定性,才能为关键点坐标回归提供高质量空间参考。通过将 CIoU 替换为 EIoU,不仅提升了边界框的尺度拟合精度,也增强了帧间一致性,可有效减少因检测框跳变引起的关键点定位偏移和体尺估算误差。

1.3 单目深度估计

采用 HR-Depth 自监督单目深度估计方法,通过连续图像序列实现羊只体尺的三维重建。该方法结合特征金字塔与边缘感知机制,在提升边界预测精度的同时保持较低计算复杂度。整体网络包含编码、解码与轻量化 3 个模块,分别用于多尺度特征提取、深度恢复与模型压缩优化。单目深度估计示意图如图 6 所示。



(a) 侧视图

(b) 俯视图

图 6 单目深度估计示意图

Fig. 6 Schematics of monocular depth estimation

1.4 羊只体尺测量

为提高羊只体尺参数(如体高、腹围、胸围、体斜长)的预测精度,提出了一种融合关键点检测与单目深度估计的方法。该方法充分考虑了羊只在通道内行走过程中存在的横向与纵向运动范围,并能够在其腿部弯曲的动态状态下,仍准确提取与体高相关的信息。采集侧视图和俯视图图像时,同一羊只因所处位置不同导致体尺深度信息存在轻微差异。为此,在提取关键点之间欧氏距离的同时,引入了相应的深度校正信息,校正因距离变化产生的测量误差,显著提高了整体预测的准确性。

提出体尺估计系统深度融合关键点检测模型与单目深度估计框架,通过多视角几何约束构建羊只三维参数化模型。系统以侧视/俯视双相机图像为输入,经 YOLO v8n-SK 模型提取 15 个体尺关键点后,如图 7 所示,结合 HR-Depth 网络输出的深度图进行空间映射。

单目相机位置固定,焦距、分辨率保持一致,因此需先通过标定确定其相机内参矩阵,具体标定过程如下:采用张正友棋盘格标定法,准备精度为 0.01 mm 的棋盘格标定板,在实验预设场景内,调整标定板的倾斜角度、摆放高度及与相机距离,采集 15~20 组不同姿态的标定图像;随后利用 OpenCV 视觉库的 calibrateCamera 接口,对采集的标定图像进行棋盘格角点检测,并通过亚像素级角点优化算




图 7 单目相机图像点到三维空间坐标的几何映射关系

Fig. 7 Geometric mapping from monocular camera image points to 3D spatial coordinates

法提升角点定位精度;基于检测到的角点坐标与标定板的实际物理坐标,构建透视投影方程,求解得到相机内参矩阵,同时完成径向畸变 k_1, k_2, k_3 与切向畸变 p_1, p_2 参数的校准;最后通过计算重投影误差(确保重投影误差不大于 0.5 像素)验证标定结果可靠性,经标定后的相机内参矩阵可重复使用。

在单目深度估计中,须利用上述畸变参数对原始图像进行校正。对任一像素的原始畸变坐标 $(u_{\text{distorted}}, v_{\text{distorted}})$,先转换至归一化坐标系,即

$$\begin{aligned} x &= \frac{u_{\text{distorted}} - c_x}{f_x} \\ y &= \frac{v_{\text{distorted}} - c_y}{f_y} \end{aligned} \quad (9)$$

式中 f_x, f_y ——图像 x 和 y 方向焦距
(c_x, c_y)——主点坐标

接着依次施加径向与切向畸变校正。径向畸变校正及切向畸变校正为

$$\begin{aligned} x' &= x(1 + k_1 r^2 + k_2 r^4 + k_3 r^6) \\ y' &= y(1 + k_1 r^2 + k_2 r^4 + k_3 r^6) \end{aligned} \quad (10)$$

$$\begin{aligned} x'' &= x' + 2p_1 x' y' + p_2 (r^2 + 2x'^2) \\ y'' &= y' + p_1 (r^2 + 2y'^2) + 2p_2 x' y' \end{aligned} \quad (11)$$

其中

$$r^2 = x^2 + y^2$$

将校正后的归一化坐标重新映射为图像像素坐标,得到无畸变坐标 $(u_{\text{undistorted}}, v_{\text{undistorted}})$ 。将校正图像输入 HR-Depth 网络,获取各像素相对于相机深度 Z_c ,从而实现从图像坐标系到相机坐标系转换。相机内参矩阵表示为

$$K = \begin{bmatrix} f_x & 0 & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{bmatrix} \quad (12)$$

基于校正后像素坐标 $(u_{\text{undistorted}}, v_{\text{undistorted}})$ 与对应深

度 Z_c , 可通过反投影公式计算该点在相机坐标系下三维坐标 (X_c, Y_c, Z_c) 为

$$\begin{cases} Z_c = Z_c \\ X_c = \frac{Z_c (u_{undistorted} - c_x)}{f_x} \\ Y_c = \frac{Z_c (v_{undistorted} - c_y)}{f_y} \end{cases} \quad (13)$$

对于体高、胸围、腹围和体斜长 4 类关键体尺维度, 通过提取与之高度相关的牲畜体表关键点之间的空间距离作为基础特征。2 个关键点 P_1 与 P_2 之间空间欧氏距离为

$$d = \| P_1 - P_2 \| = \sqrt{(X_1 - X_2)^2 + (Y_1 - Y_2)^2 + (Z_1 - Z_2)^2} \quad (14)$$

式中 X_i, Y_i, Z_i ——关键点在世界坐标系下的三维坐标

如图 8 所示, 通过计算体高、胸围、腹围和体斜长维度所对应关键点对之间的欧氏距离, 可得到 1 组特征距离向量。



图 8 4 个体尺维度和相关关键点之间的映射关系
Fig. 8 Mapping between four body-measurement dimensions and corresponding keypoints

采用多层感知机 (Multilayer perceptron, MLP) 作为体尺参数估计的回归模型^[23]。该 MLP 模型包含 1 个输入层、3 个隐藏层和 1 个输出层。输入层接收由上述方法提取的 4 类空间距离特征构成的向量 $d = (d_1, d_2, d_3, d_4)$ 。每个隐藏层包含若干神经元, 其输出通过以下过程计算: 首先, 第 l 层中第 j 个神经元输入值 $z_j^{(l)}$ 为其接收到的上一层所有神经元输出 $h^{(l-1)}$ 的加权和加上偏置项, 公式为

$$z_j^{(l)} = \sum_i w_{ji}^{(l)} h_i^{(l-1)} + b_j^{(l)} \quad (15)$$

式中 $w_{ji}^{(l)}$ ——连接第 $l-1$ 层第 i 个神经元到第 l 层第 j 个神经元权重
 $b_j^{(l)}$ ——第 l 层第 j 个神经元偏置项

$h_i^{(l-1)}$ ——第 $l-1$ 层第 i 个神经元输出值
接着, 该值通过非线性激活函数 (Rectified linear unit, ReLU) 计算得到该神经元输出为

$$h_j^{(l)} = \phi(z_j^{(l)}) = \max(0, z_j^{(l)}) \quad (16)$$

输出层则根据最后 1 个隐藏层的输出, 生成最终预测值, 即对应的体高、胸围、腹围和体斜长 4 项体尺参数。

1.5 评价指标

采用测试集从关键点检测与回归 2 个角度对算法性能开展评估, 模型整体性能基于涵盖 2 个视角图像的全测试集进行综合分析, 以全面衡量模型在羊体关键点检测任务中的表现。测试使用包含 172 幅 RGB 图像的测试集, 图像采集于 2 个不同视角, 整体性能在全测试集上统计, 特定视角性能则仅在对应视角图像上计算; 测试阶段保持与训练阶段一致的 NMS (Non-maximum suppression) 和 IoU 阈值设置, 且每幅图像仅保留最高置信度检测结果, 确保评估结果的唯一性。为定量描述检测性能, 采用精确率 (P)、召回率 (R)、平均精度均值 (mAP) 作为关键点检测模型的评价指标; 体尺测量评估针对回归模型的羊体尺预测表现, 采用包含羊体特征关键点、目标检测框和真实体尺数据的数据集开展分析, 考虑到体尺预测误差主要源于关键点定位偏差引发的 2D 姿态估计误差, 选用平均绝对误差 (MAE)、平均绝对百分比误差 (MAPE) 和决定系数 (R^2) 作为线性回归模型的性能评价指标。

2 结果与分析

2.1 实验环境及参数设置

实验在 NVIDIA RTX 2060 GPU (6 GB) 与 PyTorch 2.1.0, Python 3.9 框架下进行。超参数设置为初始学习率 0.001、批量大小 16, 训练次数 1 000。

2.2 不同注意力机制性能对比

为抑制此类干扰并突出山羊关键特征, 将选用的 CBAM 注意力机制与 ECA-Net、CoordAttention、SimAM、NAM 和 ConvNeXt-Attention 5 种方法进行综合比较, 结果如表 1 所示。

表 1 不同注意力机制性能对比
Tab. 1 Performance comparison of different attention mechanisms

注意力机制	精确率/%	召回率/%	mAP@ 50 - 95/%	参数量	浮点运算量
ECA-Net	97.6	97.7	95.0	6.5×10^6	7.8×10^9
CoordAttention	97.9	98.0	95.4	7.0×10^6	8.2×10^9
SimAM	98.0	98.2	95.6	7.3×10^6	8.5×10^9
NAM	97.7	97.8	95.2	6.7×10^6	8.0×10^9
ConvNeXt-Attention	98.0	98.1	95.5	7.5×10^6	8.9×10^9
CBAM (本文用)	98.1	98.3	95.7	7.4×10^6	8.7×10^9

综合分析表明,CBAM 在多种注意力机制中展现出显著的综合优势。与 ECA - Net 和 NAM 相比,CBAM 在检测精度方面具有明显提升,尤其在抑制背景干扰和捕捉羊只关键特征方面表现更优;相较于 CoordAttention 与 SimAM,CBAM 在保持相当或更优精度的同时,将参数量与浮点运算量控制在合理范围内;与 ConvNeXt - Attention 相比,尽管后者部分指标接近,但 CBAM 在精度相当的情况下有效避免了因结构复杂导致的过高计算开

销。总体而言,CBAM 在检测精度与模型轻量化之间实现了较优平衡,既满足了复杂场景下对羊只关键点的精确定位需求,也符合实际部署中对计算效率的要求。

2.3 关键点检测结果

2.3.1 消融实验

为验证各改进模块对模型关键点检测性能的贡献,在自建数据集上进行了消融实验,结果如表 2 所示。

表 2 改进前后 YOLO v8 - Pose 模型识别性能对比

Tab.2 Comparison of recognition performance between original and improved YOLO v8 - Pose models

改进模块	C2f - ScConv	CBAM	EIoU	精确率/%	召回率/%	mAP@ 50 - 95/%	参数量	浮点运算量
A	×	×	×	97.7	97.8	94.7	7.1×10^6	8.6×10^9
B	√	×	×	97.2	96.8	94.5	6.2×10^6	7.5×10^9
C	×	√	×	98.1	98.3	95.7	7.4×10^6	8.7×10^9
D	×	×	√	97.7	97.8	95.4	7.3×10^6	8.7×10^9
E	√	√	×	97.8	97.9	95.2	6.5×10^6	7.7×10^9
F	√	×	√	97.5	97.2	95.0	6.3×10^6	7.6×10^9
G	×	√	√	98.2	98.4	95.9	7.5×10^6	8.8×10^9
H	√	√	√	98.0	98.1	95.8	6.7×10^6	7.9×10^9

注:√表示采用此模块(方法),×表示未采用此模块(方法)。

由表 2 可知,不同改进模块(方法)使得模型的 mAP@ 50 - 95、参数量、浮点运算量均发生不同程度变化。单独引入 C2f - ScConv 模块(方法 B)后,mAP@ 50 - 95 降至 94.5%,但参数量和浮点运算量分别降至 6.2×10^6 与 7.5×10^9 ,显示出良好的模型压缩效果。单独引入 CBAM 模块(方法 C)时,mAP@ 50 - 95 提升至 95.7%,精确率和召回率达到 98.1% 和 98.3%,但浮点运算量略有上升。使用 EIoU 损失函数(方法 D)后 mAP@ 50 - 95 提升 0.7 个百分点(提升至 95.4%),计算资源变化极小。

在此基础上,进一步组合多个模块。方法 E (C2f - ScConv + CBAM)在参数量和浮点运算量明显下降的前提下,使 mAP@ 50 - 95 提升至 95.2%;方法 F(C2f - ScConv + EIoU)平衡了模型轻量化与精度,适合资源受限设备;方法 G (CBAM + EIoU)达到最高的精度水平(mAP@ 50 - 95 达 95.9%),但模型复杂度略高。最终模型 YOLO v8n - SK(方法 H,集成 C2f - ScConv + CBAM + EIoU)融合了三者优势,mAP@ 50 - 95 提升至 95.8%,同时参数量和浮点运算量分别下降至 6.7×10^6 和 7.9×10^9 ,体现出优秀的精度-复杂度平衡能力。

综上所述,YOLO v8n - SK 在 mAP@ 50 - 95 上较基线模型提升 1.1 个百分点,参数量和浮点运算量分别减少 4×10^5 和 7×10^8 。其中,CBAM 有效增强了网络的特征提取能力,抑制了冗余信息;C2f - ScConv 则显著压缩了模型结构;EIoU 在定位回归

精度上表现出明显优势。YOLO v8n - SK 在保持精度的同时降低了计算资源消耗,更适合部署于边缘设备或资源受限的智能场景。

2.3.2 模型对比

图 9 为原 YOLO v8n - Pose 模型与本文改进模型的检测结果对比。由图 9 和表 3 可知,大多模型能成功检测到羊只目标,展示了深度学习模型强大的特征提取能力。在这种情况下 YOLO v5n - Pose、YOLO v8n - Pose、YOLO v10n - Pose 和 YOLO 11n - Pose 在关键点检测位置上表现出偏差。相比之下,YOLO v8n - SK 展示了不错的检测结果,准确检测了羊只两侧关键点位置。



图 9 关键点检测结果对比

Fig.9 Results comparison of key points detection

在关键点检测任务中,不同模型在架构设计、精度、参数量和实时性等方面表现出明显差异。

由表 3 可知,YOLO v5n - Pose 基于 CSPDarknet53 主干与 PAFPN 特征金字塔结构,采用 Sigmoid 激活的关键点回归分支,mAP@ 50 - 95 为 88.7%,参数量为 5.6×10^6 ,浮点运算量为 8.1×10^9 ,作为较早的轻量级型代表,精度仍有提升空间。

YOLO v8n - Pose 引入了更优化的结构设计和训练策略,在保持参数量 7.1×10^6 的同时, $\text{mAP}@50-95$ 提升至 94.7%,浮点运算量为 8.6×10^9 ,展现出较强的检测能力。YOLO v10n - Pose 在保持轻量化(参数量 6.5×10^6)和相对少浮点运算量(8.4×10^9)的基础上,引入 Rank - Based Feature Selection 等机制,使得 $\text{mAP}@50-95$ 达到 93.1%,在性能与效率间取得了平衡。YOLO 11n - Pose 结合 Dynamic Convolution 与 CSPC(跨阶段部分连接)结

构,进一步提升检测精度, $\text{mAP}@50-95$ 达到 94.5%,但其参数量上升至 8.2×10^6 ,浮点运算量降至 6.9×10^9 ,具备较好的推理效率。改进模型 YOLO v8n - SK(本文)在 YOLO v8n 的基础上引入了 ScConv 模块以抑制冗余特征传递,并融合 CBAM 注意力机制以增强关键区域响应,最终实现 $\text{mAP}@50-95$ 提升至 95.8%,参数量为 6.7×10^6 ,浮点运算量降至 7.9×10^9 ,在保持轻量化前提下实现更优的检测精度,展现出良好的实用潜力。

表 3 不同关键点检测模型各类别检测性能对比

Tab.3 Comparison of detection performance of different categories of key point detection models					
模型	精确率/%	召回率/%	$\text{mAP}@50-95/\%$	参数量	浮点运算量
YOLO v8n - Pose	97.7	97.8	94.7	7.10×10^6	8.60×10^9
YOLO v5n - Pose	94.5	93.9	88.7	5.60×10^6	8.10×10^9
YOLO v8s - Pose	98.2	98.0	95.6	2.39×10^7	2.94×10^{10}
YOLO v10n - Pose	96.0	96.5	93.1	6.50×10^6	8.40×10^9
YOLO 11n - Pose	96.8	97.0	94.5	8.20×10^6	6.90×10^9
YOLO v8n - SK(本文)	98.0	98.1	95.8	6.70×10^6	7.90×10^9

2.4 体尺测量结果

为了评价羊只体尺测量系统性能,手动测量上述标记的 25 头羊只体斜长、体高、胸围、腹围真实值。将图像输入到单目深度网络中以获得相对深度图像。基于关键点检测与深度估计结果,体尺回归模型在测试集(6 头标记山羊共 172 幅图像)上展现出优异的测量精度。如表 4 所示,体高、胸围、腹围及体斜长平均绝对误差(MAE)分别为 1.888 7、1.261 3、1.229 4、2.462 7 cm,对应平均绝对百分比误差(MAPE)分别为 2.408%、1.731%、1.340% 和 2.519%。所有参数的预测值与实测值决定系数(R^2)均不小于 0.884 5,表明模型能够有效表征羊只体尺参数的生物学关联性。

表 4 体尺预测性能统计

Tab.4 Body size prediction performance statistics			
参数	MAE/cm	MAPE/%	R^2
体高	1.888 7	2.408	0.895 6
胸围	1.261 3	1.731	0.948 8
腹围	1.229 4	1.340	0.957 6
体斜长	2.462 7	2.519	0.884 5

如图 10 所示,利用箱线图对平均绝对百分比误差进行分析,箱体范围覆盖 25% ~ 75% 数据,从箱体延续出来的虚线显示数据正常范围,超出虚线视为异常值。体高测量值平均绝对百分比误差中位数、最大值和最小值分别为 2.125%、5.850% 和 0.010%,误差可能由数据采集角度、姿态变化引起;胸围测量值中位数、最大值和最小值分别为 1.520%、5.060% 和 0,误差的波动主要受测量区域




图 10 绝对百分比误差箱线图

Fig.10 Box plot of average relative error

边缘不规则性、光照变化和图像分辨率限制的影响;腹围测量值中位数、最大值和最小值分别为 1.105%、5.480% 和 0.060%,表明腹部区域相对稳定,但部分极端值可能与腹部皮肤褶皱或局部遮挡有关;体斜长测量值中位数、最大值和最小值分别为 1.900%、7.300% 和 0.060%,测量误差较高,主要是由于体侧面轮廓不够清晰、拍摄角度偏差和特征点检测不准确。总体来看,各项测量误差均受到数据采集条件、羊只姿态变化及自动标注精度的综合影响,未来可通过优化数据预处理和模型算法进一步提升测量准确性。

3 讨论

融合多视角视觉感知与深度学习技术,构建了高效、精准的山羊体尺自动化测量系统。实验结果显示,系统在关键点检测精度、深度估计鲁棒性和体尺参数预测准确性方面均达到了行业领先水平,为畜牧智能化管理提供了新的技术范式。

在方法有效性验证方面,侧视与俯视双目相机

的协同工作显著提升了体尺测量的空间完整性。通过标定板数据拟合获得深度校正系数(α 为0.978)有效补偿了单目深度估计的尺度漂移,确保体斜长预测误差控制在2.5 cm以内(平均绝对百分比误差MAPE为2.77%)。YOLO v8n-SK模型通过引入ScConv模块和CBAM注意力机制,在mAP@50-95(95.8%)和浮点运算量(7.9×10^9)方面优于传统模型(如YOLO v8n-Pose的mAP@50-95为94.7%,浮点运算量为 8.6×10^9)。这些改进为体高和体斜长的高精度预测奠定了基础。

系统在测试集上的体尺参数预测性能表现出色,其对体高、胸围、腹围与体斜长平均绝对误差(MAE)分别为1.888 7、1.261 3、1.229 4、2.462 7 cm,对应平均绝对百分比误差(MAPE)分别为2.408%、1.731%、1.340%和2.519%,表明模型能够高效提取关键点信息并实现精确的体尺测量;与采用更高成本的2台Kinect V2型深度相机构建的三维非接触测量系统相比,该方法在体长、体高、胸宽及腹宽4项指标上的相对误差分别为0.96%、-1.21%、-2.32%与-1.51%,且该三维系统需将羊只限制于单一测量通道中才能保证测量稳定性,而本文方法无需对动物活动进行额外约束。

技术局限性仍需关注。膝关节定位误差较大,主要源于腿部交叉或毛发遮挡。未来可引入时序信息(如LSTM或Transformer)或对抗训练以增强局部特征提取能力。单目深度估计的局限性也对体斜长预测产生了一定影响。为此,探索双目视觉或ToF

传感器实现多模态深度感知将是一个值得研究的方向。

在实际应用方面,系统单样本测量耗时仅为3 s,较人工测量效率提升25倍,为个体化饲喂决策提供了有力支持,预计可降低12%~18%的饲料浪费。同时,体高、胸围等参数的连续监测有助于早期发现生长异常,如提高发育迟缓检出率,从而可以提前进行健康干预。

4 结论

(1)提出了一种基于多模态感知的山羊非接触式生物参数测量方法,通过目标检测、关键点定位与单目深度估计的协同架构,实现了体尺(体高、胸围、腹围、体斜长)的自动化采集。

(2)基于YOLO v8-Pose构建的改进关键点检测网络,通过引入空间-通道协同重建卷积(ScConv)模块和CBAM注意力机制,在数据集上实现mAP@50-95(95.8%)及模型参数量减少 4×10^5 ,浮点运算量降低 7×10^8 ,满足实时监测需求。

(3)构建的MLP模型,通过动态置信度加权与平滑正则化,在25头山羊实测数据集中达到:体高误差为1.888 7 cm($R^2=0.895\ 6$)、胸围误差为1.261 3 cm($R^2=0.948\ 8$)、腹围误差为1.229 4 cm($R^2=0.957\ 6$)、体斜长误差2.462 7 cm($R^2=0.884\ 5$)较传统手动测量效率提升25倍。经验证,该方法有效的应用在山羊运动的场景,在非静止状态下仍能很好地完成测量任务。

参 考 文 献

[1] HENCHION M, MOLONEY A P, HYLAND J, et al. Review: trends for meat, milk and egg consumption for the next decades and the role played by livestock systems in the global production of proteins[J]. *Animal*, 2021, 15(Supp.): 100287.

[2] 李宏,张迎锐,张眉,等.国内外肉羊产业发展现状与陕西省肉羊产业发展思考[J]. *家畜生态学报*,2025,46(2):115-121.
LI Hong,ZHANG Yingrui,ZHANG Mei,et al. Development status of the sheep industry at home and abroad and reflections on the development of the sheep industry in Shaanxi Province[J]. *Journal of Domestic Animal Ecology*,2025,46(2):115-121. (in Chinese)

[3] BROWN D J, SAVAGE D B, HINCH G N, et al. Monitoring liveweight in sheep is a valuable management strategy: a review of available technologies[J]. *Animal Production Science*, 2015, 55(4): 427-436.

[4] 梁金鑫,苑志宇,罗新惠,等.家畜高通量体尺测量及体重预估技术研究进展[J]. *中国畜牧兽医*,2025,52(2):749-758.
LIANG Jinxin,YUAN Zhiyu,LUO Xinhui,et al. Advances on high-throughput body measurement and body weight estimation technology for livestock[J]. *Chinese Journal of Animal Science and Veterinary Medicine*,2025,52(2):749-758. (in Chinese)

[5] CHEBOI J, GREATHEAD H, NKUKWANA T, et al. Farmers' knowledge, perceptions and attitudes on crop-dairy goat integration farming system in Elgeyo Marakwet County[J]. *Sustainability*, 2023, 16(1): 1-16.

[6] PENG Y, PENG Z, ZOU H, et al. A dynamic individual yak heifer live body weight estimation method using the YOLO v8 network and body parameter detection algorithm[J]. *Journal of Dairy Science*, 2024, 107(8): 6178-6191.

[7] 杜晓冬,李笑笑,樊士冉,等.生猪体尺检测和体重预估方法研究进展[J]. *中国畜牧杂志*,2023,59(1):41-46,56.
DU Xiaodong,LI Xiaoxiao,FAN Shiran,et al. A review of the methods of pig body size measurement and body weight estimation [J]. *Chinese Journal of Animal Science*,2023,59(1):41-46,56. (in Chinese)

[8] CAMPBELL M, MILLER P, CHITO D K, et al. Automated precision weighing: leveraging 2D video feature analysis and machine learning for live body weight estimation of broiler chickens[J]. *Smart Agricultural Technology*, 2025,10: 100793.

- [9] SANDOR S, MARTA A. Practical aspects of weight measurement using image processing methods in waterfowl production[J]. Agriculture, 2022, 12(11): 1869.
- [10] BALABAN M O, ÜNAL ŞENGÖR G F, SORIANO M G, et al. Using image analysis to predict the weight of Alaskan salmon of different species[J]. Journal of Food Science, 2010, 75 (3): 157 – 162.
- [11] 谷志帅,蔡振江,程曼,等. 基于激光雷达的小尾寒羊体尺快速获取方法[J]. 黑龙江畜牧兽医,2025(1):52 – 58.
GU Zhishuai, CAI Zhenjiang, CHENG Man, et al. Fast method of acquiring body size of short-tail Han sheep based on lidar [J]. Heilongjiang Animal Science and Veterinary Medicine, 2025(1): 52 – 58. (in Chinese)
- [12] MENESATTI P, COSTA C, ANTONUCCI F, et al. A low-cost stereovision system to estimate size and weight of live sheep [J]. Computers and Electronics in Agriculture, 2014, 103: 33 – 38.
- [13] ZHANG L, WU P, WUYUN T, et al. Real-time non-contact monitoring method for growth parameters of sheep based on image analysis[J]. Transactions of the CSAE, 2017, 33(24): 182 – 191.
- [14] ZHAO Y, QIAO Q, LI J, et al. Review on image-based animals weight weighing [J]. Computers and Electronics in Agriculture, 2023, 215: 108456.
- [15] 李振波,孙浩翔,郭倩男,等. 机器视觉技术在大体型家畜无接触体尺测量中的研究进展[J]. 农业工程学报,2025, 41(7):1 – 12.
LI Zhenbo, SUN Haoxiang, GUO Qiannan, et al. Research progress on machine vision technology for non-contact body measurement of large livestock [J]. Transactions of the CSAE, 2025, 41(7): 1 – 12. (in Chinese)
- [16] RONG L, YUCHEN W, SHUJIN Z, et al. Automated measurement of beef cattle body size via key point detection and monocular depth estimation[J]. Expert Systems with Applications, 2024, 244: 123042.
- [17] SUN Y, WANG Y, YANG L, et al. A transfer learning-based network model integrating kernel convolution with graph attention mechanism for point cloud segmentation of livestock [J]. Computers and Electronics in Agriculture, 2024, 225: 109325.
- [18] 李明煌,苏力德,张永,等. 基于改进 YOLO v8n – pose 和三维点云分析的蒙古马体尺自动测量方法[J]. 智慧农业 (中英文), 2024, 6(4): 91 – 102.
LI Minghuang, SU Lide, ZHANG Yong, et al. Automatic measurement of Mongolian horse body based on improved YOLO v8n – pose and 3D point cloud analysis [J]. Smart Agriculture, 2024, 6(4): 91 – 102. (in Chinese)
- [19] 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)
- [20] 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 – 255,292.
ZHAO Yuliang, ZENG Fanguo, JIA Nan, et al. Rapid measurements of pig body size based on DeepLabCut algorithm [J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(2): 249 – 255, 292. (in Chinese)
- [21] 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)
- [22] YUAN Z, SHAO P, LI J, et al. YOLO v8 – ACU: improved YOLO v8 – pose for facial acupoint detection [J]. Frontiers in Neurobotics, 2024, 18: 1355857.
- [23] KUZDEUOV A, TARATYNOVA D, TLEULIYEV A, et al. OpenThermalPose: an open-source annotated thermal human pose dataset and initial YOLO v8 – Pose baselines [C] // IEEE International Conference on Automatic Face and Gesture Recognition (FG). IEEE, 2024: 1 – 8.
- [24] LI J, WEN Y, HE L. Scconv: spatial and channel reconstruction convolution for feature redundancy [C] // Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 6153 – 6162.
- [25] CHEN S, LIU M, HU L, et al. A pedestrian detection network based on EfficientDet combined with SCConv [C] // Proceedings of the 3rd International Conference on Robotics, Artificial Intelligence and Intelligent Control (RAIIC). IEEE, 2024: 378 – 383.
- [26] TOLSTIKHIN I O, HOULSBY N, KOLESNIKOV A, et al. MLP – Mixer: an all-MLP architecture for vision [J]. Advances in Neural Information Processing Systems, 2021, 34: 24261 – 24272.
- [27] 潘泰任,彭鹏,郑太康,等. 基于双视角深度相机的羊只三维重构及体尺测量[J]. 激光杂志,2023,44(5):78 – 83.
PAN Tairen, PENG Peng, ZHENG Taikang, et al. Three-dimensional reconstruction and body size measurement of goat using dual view depth cameras [J]. Laser Journal, 2023, 44(5): 78 – 83. (in Chinese)
- [28] 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)