doi:10.6041/j.issn.1000-1298.2025.10.054

基于改进 YOLO v9u－pose 的肉牛质量估算方法

段青玲[1,2]　杨丽莎[1,2]

（1.中国农业大学信息与电气工程学院，北京 100083；2.农业农村部智慧养殖技术重点实验室，北京 100083）

摘要：在肉牛养殖中，肉牛质量对其生长监测和育种改良具有重要意义。传统的称量方法费时费力，且易造成牛只应激反应。然而，现有的非接触方法易受姿态和复杂背景影响，精度较低，鲁棒性差。为此，本文提出了基于改进 YOLO v9u－pose 的肉牛质量估算方法，包括关键点检测和质量估算 2 个阶段。在关键点检测阶段，以 YOLO v9u－pose 作为基线网络，利用 ODConv（Omni-dimensional dynamic convolution）替换主干网络的普通卷积；采用 DySample 替换颈部网络的上采样模块；并在与检测头连接的 RepNCSPELAN4 模块中添加 EMA 注意力机制（Excitation and modulation attention），进而提高肉牛关键点检测算法精度。在质量估算阶段，利用深度图和局部点云聚类等方法提取体尺特征，并构建基于体尺和 PSO－XGBoost（Particle swarm optimization－eXtreme gradient boosting，PSO－XGBoost）的肉牛质量估算算法。在自建的数据集上测试，本文提出的关键点检测算法 F1 值和平均精度均值（mAP@0.75）分别为 97.2% 和 98.2%，质量估算算法平均绝对百分比误差为 3.97%。最终将所提方法部署至开发板，为肉牛智能化养殖提供了技术支持。

关键词：肉牛；质量估算；关键点检测；YOLO v9u－pose；PSO－XGBoost

中图分类号：TP391.4　　**文献标识码**：A　　**文章编号**：1000-1298(2025)10-0596-10　　**OSID**：

Weight Estimation Method of Beef Cattle Based on Improved YOLO v9u－pose

DUAN Qingling[1,2]　YANG Lisha[1,2]

（1. *College of Information and Electrical Engineering*, *China Agricultural University*, *Beijing* 100083, *China*
2. *Key Laboratory of Smart Breeding Technology*, *Ministry of Agriculture and Rural Affairs*, *Beijing* 100083, *China*）

Abstract: In beef cattle farming management, the weight of beef cattle is crucial for monitoring growth, improving breeding, and controlling costs. Traditional weighing methods are not only time-consuming and labor-intensive but also prone to causing stress in the cattle. However, existing non-contact estimation methods are easily affected by posture and complex backgrounds, leading to low algorithm accuracy and poor robustness. Therefore, a beef cattle weight estimation method was proposed based on improved YOLO v9u－pose, which mainly consisted of two stages: key point detection and weight estimation. In the key point detection stage, YOLO v9u－pose was used as the baseline model, where the standard convolutions in the backbone network were replaced with omni-dimensional dynamic convolution (ODConv); DySample was employed to replace the upsampling module of the neck network; additionally, the excitation and modulation attention (EMA) was added to the RepNCSPELAN4 module connected to the detection head to improve the accuracy of the beef cattle key point detection algorithm. In the weight estimation stage, body size parameters were extracted by using depth maps and local point cloud processing methods. A beef cattle weight estimation algorithm was then constructed based on the parameters and the particle swarm optimization－eXtreme gradient boosting (PSO－XGBoost) approach. On testing with a self-constructed dataset, the F1 score, and mean average precision (mAP@0.75) of the key point detection model proposed were 97.2% and 98.2%, respectively. The mean absolute percentage error (MAPE) of weight estimation method based on PSO－XGBoost was 3.97%. Finally, the proposed cattle weight estimation model was deployed to a development board, providing technical support for intelligent beef cattle farming.

Key words: beef cattle; weight estimation; key point detection; YOLO v9u－pose; PSO－XGBoost

收稿日期：2024－07－07　修回日期：2024－09－30

基金项目：校企合作项目(202305510810142)

作者简介：段青玲(1967—)，女，教授，博士生导师，主要从事智能信息处理研究，E-mail：dqling@cau.edu.cn

0　引言

在肉牛养殖过程中，精准地获取肉牛质量不仅可以帮助养殖人员制定科学的饲养方案，还有助于确定其最佳销售时间，肉牛质量的突变能够提醒养殖者及时发现疾病的存在[1]。传统的称量式测量法易造成牛只应激反应，增加人畜共患病传染概率，影响动物福利。因此，研究非接触式肉牛质量估算方法对肉牛的生长监测和健康评估具有重要意义。

机器视觉技术具有高精度、非接触性和自动化等特点，目前已广泛用于动物健康养殖研究中[2-3]，如牲畜体况评分评估[4-5]、行为识别[6]、跛行检测[7-8]等。基于机器视觉的牲畜质量估算方法主要分为两类：端到端的牲畜质量估算方法和基于体尺的牲畜质量估算方法。

端到端的牲畜质量估算方法是一种从输入到输出的直接映射方法。通过将原始输入数据送入模型后，直接生成最终的质量估算结果，中间过程不需要人为干预。端到端的牲畜质量估算方法[9-10]有效地提高了肉牛质量估算自动化水平，但这类方法由 RGBD 图像和质量数据直接训练模型，对图像中的深度信息较为敏感。当光线条件和牲畜姿态变化时，易出现不完整或错误的深度信息，估算模型精度有待提升。同时，这类方法主要依靠深度学习模型回归，模型可解释性较差，无法根据估算结果分析影响肉牛质量具体特征。

基于体尺的牲畜质量估算方法根据牲畜体长、体高、胸围等特征，拟合质量估算模型[11-13]，在预估估算质量的同时还可获得各项体尺，帮助畜牧人员改良育种。文献[14－16]所使用方法均属于基于体尺的肉牛质量估算方法，其精度与体尺测量关键点密切相关。以往研究人员常基于牲畜的轮廓分割算法[17-18]，结合边缘检测、凸包凹陷检测和曲率计算等预处理步骤提取体尺测量点，过程较为繁琐；且不同的肉牛姿态和不同位置的测量点形态不同，需要采用不同的图像处理算法来提取，方法鲁棒性差。近年来，有研究人员尝试使用基于深度学习的关键点检测算法直接提取体尺测量点[19-20]，以简化关键点提取过程。然而，部分用于体尺测量的关键点位于牛体边缘，易与复杂背景混淆，影响关键点定位，算法精度有待提升。在动物体型测量领域中，基于深度学习算法直接提取体尺测量关键点的研究较少，因此基于深度学习的测量关键点提取方法仍面临着较大挑战。

为此，本文基于深度学习的关键点检测算法，提出一种基于改进 YOLO v9u－pose 的肉牛质量估算方法，以实现自动体尺测量和质量估算。在实际采集环境中，捕捉的肉牛图像可能存在各种姿态，为保证估算算法精度，提出基于 YOLO v8 的图像筛选算法，以去除肉牛关键点不完整的图像；构建基于改进 YOLO v9u－pose 的肉牛关键点检测模型，提取体尺测量关键点，结合基于局部点云处理的特征提取方法获得肉牛体尺；构建基于 PSO－XGBoost（Particle swarm optimization－eXtreme gradient boosting）的肉牛质量估算模型，将肉牛体尺和质量进行拟合，并利用粒子群算法优化模型的超参数以提高 XGBoost 性能，最终将模型部署至开发板，以实现肉牛质量准确估算，以期为实现畜禽养殖智能化提供技术支持。

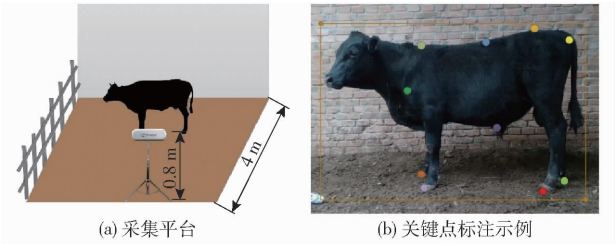
1　材料与方法

1.1　数据采集和数据集构建

肉牛图像和质量数据于内蒙古正蓝旗鑫源牧场采集，用于构建肉牛关键点检测和质量估算数据集。

1.1.1　肉牛关键点检测数据集

图像采集平台如图 1a 所示，为获得完整的肉牛侧视图像，相机与牛只的距离在 1.2～3.5 m 内调整，且相机距离地面 0.8 m。使用 Intel RealSense D435i 型深度相机从侧面拍摄自由活动的肉牛 RGBD 图像，分辨率为 1 280 像素×720 像素。如图 2 所示，当肉牛关键部位拍摄不全时，可能会增大估算方法的误差，因此本文使用基于 YOLO v8 的图像筛选算法获得关键点完整且处于站立姿态的肉牛图像，图像筛选数据集共 4 028 幅，其中部分图像来自公开数据集[21]，正负类样本比例为 1∶1，关键点完整且站立的侧视图像为正样本，其他图像为负样本。如图 1b 所示，依据人工测量体尺的位置，使用 Labelme 在图像上标注关键点。所构建关键点检测数据集，包含 1 905 幅图像和 2 401 个实例。图像筛选和关键点检测数据集均按比例 8∶1∶1 划分为训练集、验证集和测试集。



(a) 采集平台　　(b) 关键点标注示例

图 1　数据采集平台和关键点标注示例

Fig. 1　Data collection platform and key point annotation example


(a) 臀部正对相机

(a) 头部正对相机


(c) 头部拍摄不全


(d) 四蹄拍摄不全

图 2 关键点拍摄不全示意图

Fig. 2 Schematics of incomplete capture of key points

1.1.2 质量估算数据集

以 200 ~ 318 kg 的安格斯肉牛为研究对象，由养殖人员使用测杖和卷尺测量肉牛真实的体尺数据，使用地磅测量质量数据，用于验证本文方法的有效性。将本文方法所计算的体尺和人工测量的质量结合，最终得到包含 97 个样本的体尺质量数据集，将其按照比例 7∶3 划分为训练集和测试集。

1.2 质量估算总体流程

本文提出了一种基于改进 YOLO v9u - pose 的关键点检测肉牛质量估算方法，肉牛质量总体流程如图 3 所示。

(1)关键点检测：基于 YOLO v8 分类算法筛选具有完整关键点且处于站立姿态的肉牛图像，构建基于改进 YOLO v9u - pose 的肉牛关键点检测模型，

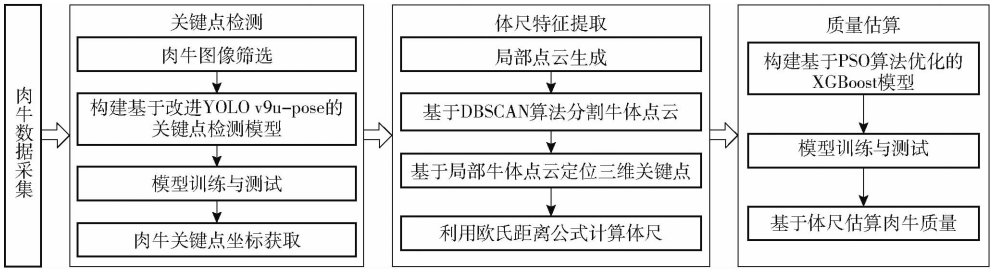


图 3 肉牛质量估算总体流程图

Fig. 3 Overall process diagram of beef cattle weight estimation

获得体尺测量关键点像素坐标。

(2)体尺特征提取：将像素坐标、深度图和相机参数相结合生成关键点对应的局部点云，使用 DBSCAN 算法对点云聚类分割出牛体点云，最后在点云中定位三维关键点，根据欧氏距离公式计算体尺。

(3)质量估算：基于 PSO - XGBoost 算法构建质量估算模型，实现肉牛质量准确估算。

1.3 基于改进 YOLO v9u - pose 的肉牛体尺关键点检测模型

在实际应用中，相机捕捉的肉牛图像包含的关键点可能不完整或肉牛处于躺卧姿态，因此本文首先通过 YOLO v8 图像二分类算法筛选肉牛图像，然后再进行关键点检测。同时，安格斯肉牛被毛为深黑色或红棕色，易与背景和地面混淆，且肉牛的关键点位于牛体边缘，因此关键点检测难度较大。YOLO v9u - pose 基于 YOLO v9[22] 和 ultralytics 库实现，可用于关键点检测和姿态估计任务。为提高检测精度，本文提出了基于改进 YOLO v9u - pose 的关键点检测模型，其包括输入、主干网络、颈部和检测头 4 部分。模型结构如图 4 所示，改进部分用橙色显示。

主要改进包括：①采用 ODconv[23]（Omni-dimensional dynamic convolution）替代原骨干网络中的部分卷积以捕获更丰富的肉牛图像特征。②使用 DySample[24] 替代 Neck 网络中的上采样模块，在不增加额外负担的情况下提升图像分辨率。③在与连接检测头的 3 个 RepNCSPELAN4 模块中添加 EMA[25]（Excitation and modulation attention）注意力机制，提升检测头对重要特征的关注和利用能力。

1.3.1 ODConv 模块

卷积层在模型特征提取过程中起着决定性作用，YOLO v9u - pose 中的卷积为静态卷积，只有 1 个固定卷积核去对输入图像进行处理，提取特征能力不足，易导致信息丢失或冗余。ODConv 作为一种融合多维度注意力机制的全维动态卷积模块，其不仅考虑卷积核形状和大小，还考虑空间维度、输入通道维度和输出通道维度，因此具有更灵活的参数量和计算成本，可以更好地适应不同的输入数据。本文将 YOLO v9u - pose 中的部分普通卷积替换为 ODConv，使模型可捕获更丰富的肉牛图像特征。ODConv 网络结构如图 5 所示。

图 5 表示了输入经过全局平均池化(GAP)、全连接(FC)层和 ReLU 激活函数后，利用多维注意力机制和并行策略，在卷积层的 4 个维度上学习卷积

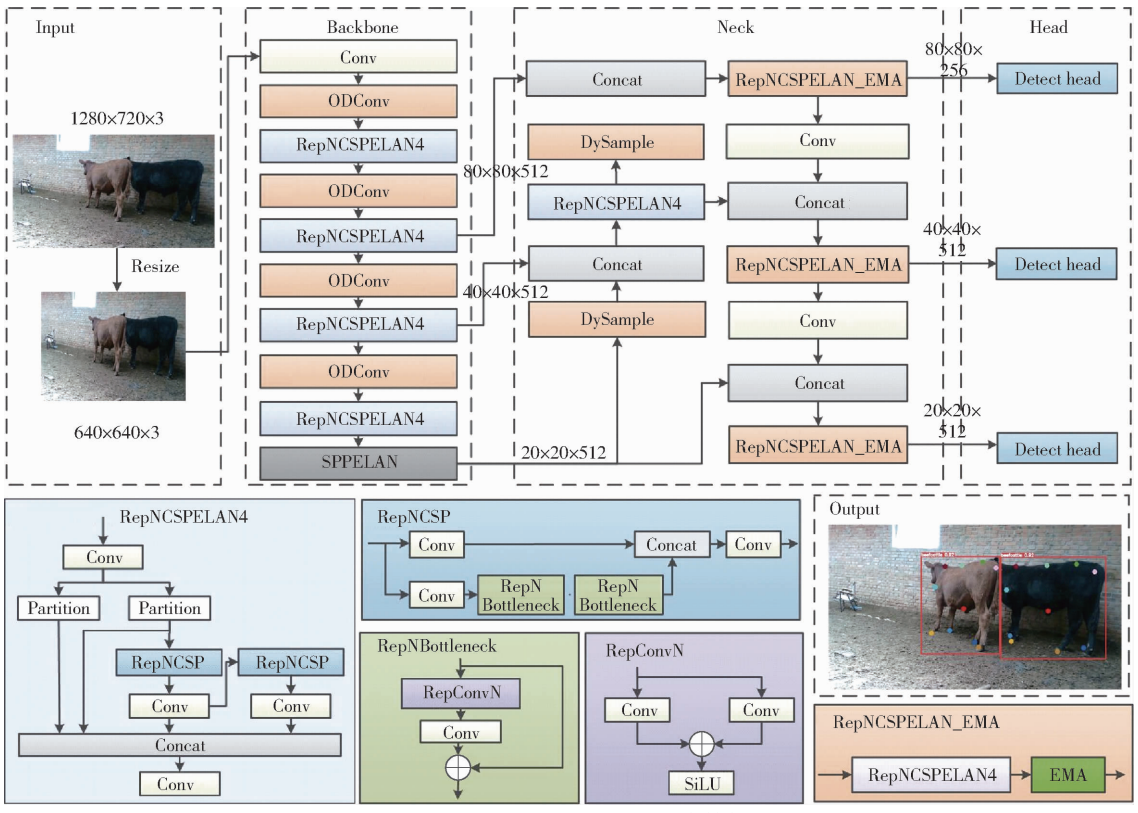


图 4　改进 YOLO v9u－pose 网络结构图

Fig. 4　Structure diagram of improved YOLO v9u－pose network

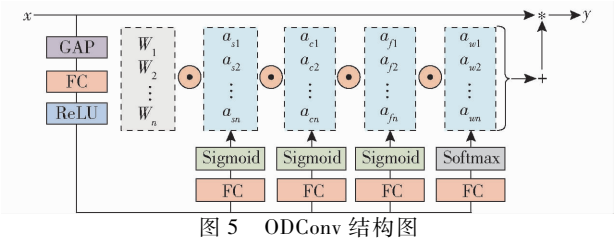


图 5　ODConv 结构图

Fig. 5　ODConv structure diagram

核注意力的过程。其中，α_{wi} 表示卷积核 W_i 的注意力标量，α_{si}、α_{ci}、α_{fi} 表示引入的 3 个注意力，分别沿空域维度、输入通道维度以及输出通道维度。

1.3.2　DySample 上采样

在检测网络中，YOLO v9u－pose 通过上采样将低分辨率的特征图放大，使其与高分辨率的特征图对齐，从而帮助网络更好的理解和定位目标。传统上采样方法采用固定的采样方案，具有一定局限性，可能导致图像关键细节损失。DySample 是一种轻量且有效的动态上采样器，其绕过动态卷积并从点采样的角度制定上采样，避免了耗时的动态卷积操作和额外的子网络，可有效提升模型效率和性能。在实际场景中，肉牛可能会因为自由移动或光线等问题使拍摄的图像出现模糊，导致细粒度细节丢失和特征学习困难，因此本文将 Neck 部分的上采样模块替换为 DySample，在不增加额外负担的情况下提升图像分辨率，从而以最小的计算成本提高模型效率和性能。

1.3.3　RepNCSPELAN_EMA 模块

EMA 模块将部分通道重构为批量维度，并将其分组为多个子特征，使空间语义特征在每个特征组内得到良好分布，进而在不增加太多参数和计算成本的情况下有效地提高特征表示能力。EMA 采用 2 个 1×1 分支和 1 个 3×3 分支的路径提取分组特征图的注意力权重描述符，通过在每个并行分支中对全局信息进行编码以重新校准通道权重，并利用跨维度交互进一步聚合两个并行分支的输出特征，以捕捉像素级的成对关系[26]。在与连接检测头的 3 个 RepNCSPELAN4 模块中添加 EMA 注意力机制，以提升检测头对重要特征的关注和利用能力，从而提高肉牛关键点检测精度。RepNCSPELAN_EMA 模块结构如图 4 所示。

1.4　肉牛体尺特征提取方法

1.4.1　三维关键点提取

为计算肉牛真实体尺，需将像素关键点映射到三维空间。然而在向三维空间映射时，处于边缘的关键点深度易与背景混淆，影响体尺质量的准确测量，因此本文采用一种基于深度图和局部点云的体尺特征提取算法，主要流程包括局部点云生成、牛体点云分割和三维关键点搜索。

如图 6 所示，首先将部分关键点向外扩张成边长为 d（d = 30 像素）的矩形区域，然后结合区域像

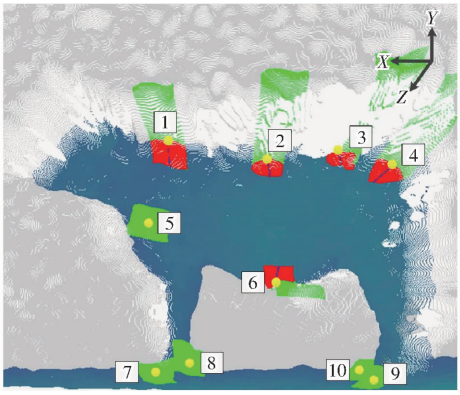


图 6 关键点位置

Fig. 6 Positions of key points

素和相机参数生成关键点对应的局部点云,即图 6 中的绿色点云(编号 1 ~ 10)。d 的取值不易过小,否则局限区域无法包含牛体。然后使用 DBSCAN 算法对局部点云(编号 1 ~ 4、6)进行聚类分割获得牛体点云,牛体点云如图 7 所示(红色点云)。最后在牛体点云中搜索各个特征点的三维坐标,具体细节如下:关键点 1 ~ 3 为对应牛体点云中线的最高点,关键点 4 为过牛体点云中点且法向量为 [1,1,0](头在左侧)或[-1,1,0](头在右侧)的平面与牛体点云交线的最高点。关键点 6 为所对应牛体点云中线的最低点,其余特征点受背景影响较少,因此直接取各个点云中点为关键点三维坐标。

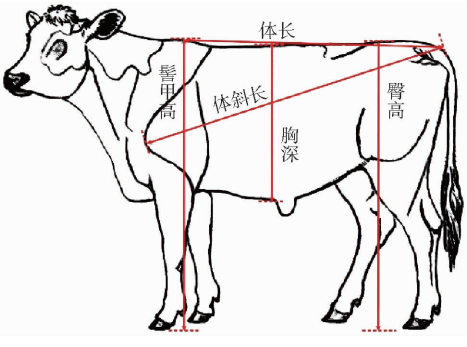


图 7 体尺特征示意图

Fig. 7 Schematic of body size features

1.4.2 体尺特征提取

基于上述关键点从肉牛侧视图像中提取 5 项体尺数据。如图 7 所示,其中 WH、HH、BD、BL、OBL 分别表示鬐甲高、臀高、胸深、体长、体斜长。

在获得各个关键点的三维坐标后,本文基于两端关键点和欧氏距离公式计算各项体尺,其中鬐甲高为关键点 1 与两只前脚中点距离,臀高同理。以鬐甲高为例,假设鬐甲高上下两端测量点 A、B 坐标分别为(X_a,Y_a,Z_a)和(X_b,Y_b,Z_b),则鬐甲高计算公式为

$$WH = \sqrt{(X_a - X_b)^2 + (Y_a - Y_b)^2 + (Z_a - Z_b)^2}$$

1.5 基于 PSO - XGBoost 的肉牛质量估算模型

XGBoost 是一种决策树集成算法,其核心思想是通过梯度提升方法逐步构建并优化决策树,结合正则化和二阶泰勒展开提高模型的鲁棒性和精确性[27]。对于机器学习算法,超参数的选择直接影响模型的学习过程和最终效果,合适的超参数可显著提高模型的准确性和泛化能力。网格搜索法[28]是一种常用的参数优化方法,其通过手动指定超参数空间的子集进行穷举搜索。然而,XGBoost 算法的超参数数量较多,采用网格搜索法对其调参存在效率低、耗时长问题。粒子群优化算法[29]通过群体中的个体共享信息,使整个群体在问题求解空间中从无序逐渐演化为有序,最终找到最优解,其不仅能提高收敛速度,还能增强全局搜索能力,从而避免过早陷入局部最优解。因此本文利用粒子群算法优化超参数,以提升 XGBoost 模型的训练效率和预测精度。采用本文所提出的体尺提取方法从 RGBD 图像中计算体尺,并将体尺作为自变量,真实质量作为因变量,构建基于 PSO - XGBoost 的肉牛质量估算模型。肉牛质量估算模型流程如图 8 所示,首先利用箱线图可视化体尺的异常值,并使用平均值修正;然后对数据进行归一化,消除量纲和数量级的影响;接着将训练集 3 折交叉验证平均值定义为 PSO 算法中的适应度目标函数,多次迭代获得 XGBoost 模型最优参数组合,最后将测试集输入最优模型以评估模型。

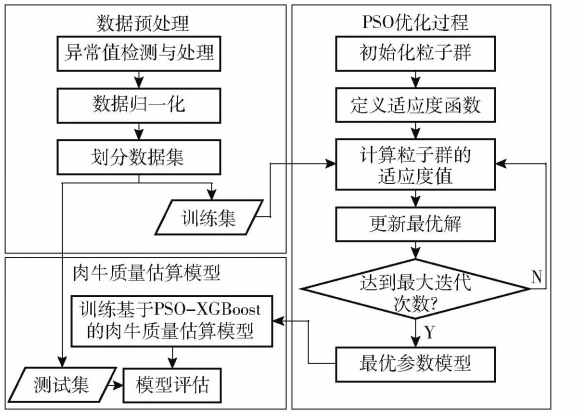


图 8 基于 PSO - XGBoost 的肉牛质量估算方法流程图

Fig. 8 Flowchart of beef cattle weight estimation based on PSO - XGBoost

1.6 实验设计与评价指标

1.6.1 实验设计

为验证本文中的关键点检测算法和质量估算方法的有效性,分别设计了 3 组实验。

(1)图像筛选算法实验。验证本文基于 YOLO v8 分类算法的性能,在训练时,设置初始学习率为

0.01，批次大小为 8，权重衰减为 0.000 5，优化器为 Adam，训练次数为 300。训练完成后批次大小设置为 1，在单 GPU 上进行模型性能测试。

（2）关键点检测算法实验。主要包括消融实验和对比实验。采用消融实验验证本文对原算法改进的有效性，采用对比实验将本文的肉牛关键点检测网络与 YOLO v8－pose、YOLO v7－pose、YOLO v6－pose、Simple baseline[30] 和 HRNet[31] 模型进行对比分析，训练环境与筛选实验环境一致。

（3）质量估算算法实验。将本文构建的 PSO－XGBoost 质量估算方法与支持向量回归（Support vector regression，SVR）、多元线性回归（Multiple linear regression，MLR）、K 近邻（K-nearest neighbor，KNN）、Extra Trees（Extremely randomized trees）、Random Forest 和 XGBoost 共 6 种回归方法进行对比分析。

实验基于 Ubuntu 20.04.6、Python 3.7.16 和 Pytorch 1.13.0 搭建深度学习框架。配置使用 2 块 Intel（R） Xeon（R） Platinum 8260 CPU，NVIDIA Quadro RTX 6000/8000 显卡，CUDA 版本为 11.7。

1.6.2　评价指标

采用准确率评估图像筛选算法分类性能，采用精确率（P）、召回率（R）、F1 值和平均精度均值（mean Average Precision，mAP）评估关键点检测模型性能，mAP@0.75 表示当 OKS 阈值为 0.75 的平均精度均值，OKS 为目标关键点相似度，类似于目标检测任务中的 IoU，而 mAP@0.5:0.95 表示 OKS 阈值从 0.5 到 0.95，步长为 0.05 的平均精度均值。采用平均绝对误差（Mean absolute error，MAE）和平均相对误差（MAPE）评估体尺特征提取结果，并采用均方根误差（RMSE）、MAE、MAPE 和决定系数 R^2 作为回归模型性能评价指标。

2　结果与分析

2.1　关键点检测实验

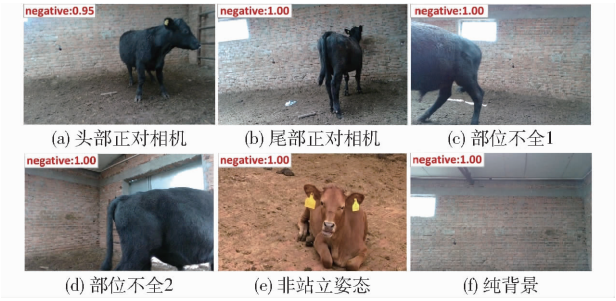
2.1.1　图像筛选

为验证图像筛选算法性能，将算法在所建的测试数据集上进行测试，结果如表 1 所示。部分测试集的预测结果如图 9 所示，当图像为负类（negative）时，即牛头或尾部正对相机、身体拍摄不全、非站姿和纯背景时，均能分类正确，因此，本文先通过图像筛选算法去除分类为负类的图像，然后再对肉牛图像进行特征提取和质量估算。

表 1　图像筛选（分类）结果

Tab.1　Image filtering（classification）results

类别	测试图像数/幅	筛选成功数/幅	分类准确率/%
正类	201	197	98.0
负类	201	199	99.0



(a) 头部正对相机　(b) 尾部正对相机　(c) 部位不全1
(d) 部位不全2　(e) 非站立姿态　(f) 纯背景

图 9　负样本预测结果

Fig.9　Negative sample prediction results

2.1.2　消融实验

为验证改进部分对原基础网络所做的贡献和有效性，进行消融实验。将基线网络和进行各模块改进后的网络在所建数据集上测试。训练中软硬件环境和训练参数均保持一致。各个模型结果如表 2 所示。

表 2　消融实验结果

Tab.2　Ablation experiments results

YOLO v9u－pose	ODConv	DySample	EMA	精确率/%	召回率/%	F1 值/%	mAP@0.75/%	mAP@0.5:0.95/%
√	×	×	×	96.3	97.5	96.9	97.8	93.2
√	√	×	×	96.6	97.5	97.1	98.1	94.1
√	√	√	×	96.2	97.9	97.1	98.0	94.8
√	√	√	√	96.4	97.9	97.2	98.2	95.1

注：√表示采用此模块，×表示不采用此模块。

从表 2 可以看出，改进模型与基准模型相比，精确率、召回率、F1 值、mAP@0.75 和 mAP@0.5:0.95 分别提升 0.1、0.4、0.3、0.4、1.9 个百分点。其中，将主干网络的部分卷积替换成 ODConv 的模型与基准模型相比，精确率、F1 值、mAP@0.75 和 mAP@0.5:0.95 分别提升 0.3、0.2、0.3、0.9 个百分点；在替换普通卷积和将上采样变成 DySample 模块后，模型召回率提升 0.4 个百分点，mAP@0.95 提升 0.7 个百分点；在将前两个改进和 RepNCSPELAN_EMA 结合之后，本文所提模型与基准模型相比各指标均有所提高，其中 mAP@0.95 的提升幅度最大，达到 1.9 个百分点，结果验证了本文所采用 3 种改进方

法的有效性。

图 10 为 YOLO v9u－pose 算法和本文方法在测试集上的检测结果。由图 10 可以看出，本文方法检测结果较准确，而利用 YOLO v9u－pose 算法检测的图 10a、10b 中的左后蹄均未准确定位在牛蹄上。图 10c 中，YOLO v9u－pose 算法在检测左后蹄点和右后蹄点时均出现了较大偏差。整体来看，本文方法检测的关键点精度较高，更贴切真值，满足实际养殖环境中准确地检测肉牛关键点的需求。并且，本文方法属于基于深度学习的关键点检测算法，可迁移到其他动物的体型测量，根据待测动物图像微调模型，实现动物体尺关键点准确检测。

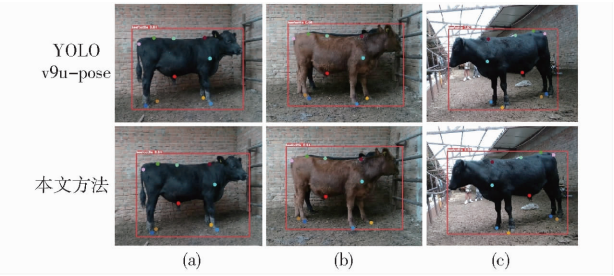


图 10 检测结果对比

Fig. 10 Comparison of detection results

2.1.3 对比实验

为验证本文关键点检测算法性能，将其与 YOLO v8－pose、YOLO v7－pose、YOLO v6－pose、Simple baseline 和 HRNet 算法在本文所建的肉牛关键点检测数据集上进行对比实验，结果如表 3 所示。

表 3 对比实验结果

Tab. 3 Comparative experiment results %

模型	F1 值	mAP@0.75	mAP@0.5:0.95
YOLO v8－pose	95.8	97.8	93.9
YOLO v7－pose	97.0	98.2	93.7
YOLO v6－pose	96.4	97.3	92.7
Simple baseline		97.9	93.4
HRNet		95.6	89.6
本文	97.2	98.2	95.1

由表 3 可知，本文方法的 F1 值、mAP@0.75 和 mAP@0.5:0.95 分别达到 97.2%、98.2% 和 95.1%。其中，与 YOLO v8－pose、YOLO v7－pose、YOLO v6－pose、Simple baseline 和 HRNet 算法对比，mAP@0.5:0.95 分别提升 1.2、1.4、2.4、1.7、5.5 个百分点。与 YOLO v8－pose 和 YOLO v7－pose、YOLO v6－pose 相比，本文方法 F1 值提升 1.4、0.2、0.8 个百分点。结果验证了本文方法的各项检测指标均为最佳，满足肉牛体尺关键点检测精度需求。

2.2 质量估算实验

2.2.1 肉牛质量估算

图 11 为各项体尺箱线图，其包含本文方法在质量数据集上估算的所有体尺结果。箱线图方框采用 5 种度量值表示数据，从下到上的深色水平线分别为：下须、下四分位数(Q1)、中位数(Q2)、上四分位数(Q3)以及上须，其中上(下)须为非异常范围内数据的最大(小)值，高于上须或是低于下须的数据被视为异常值。Q1、Q2 和 Q3 表示在整个数据集中分别有 25%、50%、75% 的数据点小于该值，因此方框不同部分之间的间距可表示数据分散、扩散和偏度程度[32]。

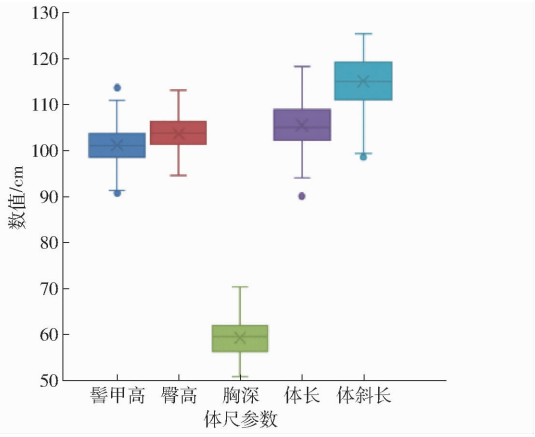


图 11 体尺结果箱线图

Fig. 11 Box plot of body size results

体尺误差会直接影响质量估算精度，如图 11 所示，可以观察到髻甲高、胸深、体长和体斜长中均包含异常值。因此，为提高质量估算算法精度，本文采用整体平均值修正异常值。修正后各项体尺与人工测量值之间的平均绝对误差和相对误差如表 4 所示。

表 4 体尺误差

Tab. 4 Body size errors

参数	髻甲高	臀高	胸深	体长	体斜长
MAPE/%	3.78	4.38	5.05	4.64	3.63
MAE/cm	3.88	4.77	3.03	5.07	4.14

由表 4 可以看出，测量的 5 项体尺平均相对误差不大于 5.05%，绝对误差为 3.0～5.1 cm，总体误差较小，可用于质量估算。为验证 PSO－XGBoost 模型的性能，本文估算了包含 30 个样本的质量估算测试集，表 5 为肉牛质量估算测试集中的部分测量结果。

图 12 为 PSO－XGBoost 算法用于预测质量的特征贡献率。其中，对肉牛质量估算影响最高的参数是臀高，特征贡献率为 28.64%。其次分别为 OBL、

表 5　质量估算结果

Tab. 5　Weight estimation results

编号	估算质量/kg	真实质量/kg	相对误差/%	编号	估算质量/kg	真实质量/kg	相对误差/%
1	228.0	237	3.80	11	262.2	265	1.06
2	233.6	220	6.18	12	253.0	250	1.20
3	232.4	233	0.26	13	231.8	238	2.61
4	246.4	260	5.23	14	214.0	225	4.89
5	284.2	302	5.89	15	239.2	231	3.55
6	255.1	265	3.74	16	246.4	260	5.23
7	234.3	222	5.54	17	264.4	285	7.23
8	214.7	210	2.24	18	227.1	235	3.36
9	268.6	275	2.33	19	229.2	232	1.21
10	241.2	238	1.34	20	224.6	222	1.17

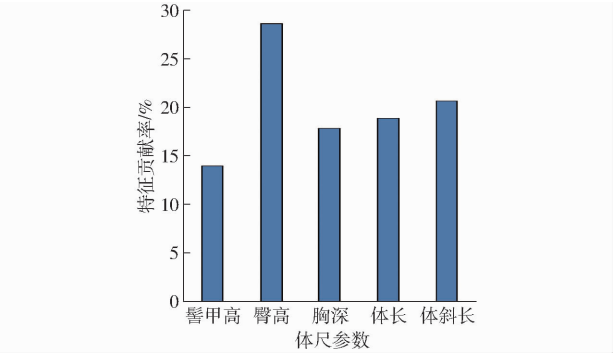


图 12　使用 PSO－XGBoost 算法预测质量的特征贡献率

Fig. 12　Feature contribution rate in weight prediction using PSO－XGBoost algorithm

BL、BD、WH，对应的特征贡献率分别为 20.65%、18.87%、17.86%、13.97%。

2.2.2　不同估算方法对比

为验证本文提出的基于 PSO－XGBoost 的肉牛质量估算方法的性能，将其与 SVR、MLR、KNN、Extra Trees、Random Forest 和 XGBoost 算法对比。使用归一化后的训练集分别对各模型进行训练，并在测试集上进行评估，不同方法对比结果如表 6 所示。

表 6　不同肉牛质量估算方法对比结果

Tab. 6　Comparison results of different beef cattle weight estimation methods

方法	RMSE/kg	MAE/kg	MAPE/%	R^2
SVR	13.82	10.29	4.26	0.590
MLR	13.19	9.81	4.06	0.625
KNN	13.32	10.18	4.24	0.610
Extra Trees	15.34	12.68	5.20	0.490
Random Forest	13.70	9.88	4.06	0.600
XGBoost	14.47	11.67	4.79	0.550
PSO－XGBoost(本文)	12.82	9.64	3.97	0.650

从表 6 可以看出，本文方法 RMSE 为 12.82 kg，MAE 为 9.64 kg，MAPE 达到 3.97%，R^2 为 0.65。与 XGBoost 相比，PSO－XGBoost 方法 RMSE、MAE 和 MAPE 分别降低 1.65、2.03 kg 和 0.82 个百分点，R^2 提高 0.1，证明了 PSO 优化的有效性。与 SVR、MLR、KNN、Extra Trees 和 Random Forest 相比，本文方法各项指标均为最优，其中 MAE 分别降低 0.65、0.17、0.54、3.04、0.24 kg，MAPE 分别降低 0.29、0.09、0.27、1.23、0.09 个百分点，R^2 分别提高 0.06、0.025、0.04、0.16、0.05。总体而言，本文方法具有较高的估算精度，满足实际养殖场景中肉牛质量估算需求。经分析，质量估算方法误差来源包括：①如果牛只运动速度过快可能会导致拍摄的图像模糊，影响关键点检测算法精度。②养殖场中的牛只处于自由活动状态，相机很有可能捕捉到牛蹄离地画面，然而离地的牛蹄测量点位置偏高，会增大体尺提取方法误差，因此下一步将尝试使用姿态估计算法，根据牛只腿部骨架线，去除此类情况图像。③光照强度或视野限制可能导致生成的点云出现空洞，使体尺和质量估算出现较大误差。

3　肉牛质量估算模型应用

在实际农场中，随身携带计算机进行测量存在不便，影响测量效率。因此本文使用 Jetson TX2 NX 嵌入式开发板控制 Intel RealSense D435i 型深度相机实时拍摄图像数据，然后将数据自动上传至云端服务器，转送至算法服务器检测和估算，待估算完成后返回结果到显示屏。开发板部署原理如图 13a 所示，封装后设备图像如图 13b 所示。

肉牛体尺测量和质量估算系统界面如图 14 所示。系统使用 Vue 搭建前端框架，通过 Flask 封装后端接口，采用 Axios 实现前后端交互；利用 Nginx 部署实现远程访问，并使用 MySQL 数据库存储体尺和质量测量结果；最终通过实时采集或上传 RGB 图和深度图实现肉牛体尺的自动测量和质量估算。整个系统部署在 Intel(R) Xeon(R) Platinum 8255C CPU 的服务器上。未来将把设备安装至牛场的通道，以实现肉牛体尺和质量的非接触式测量。同时与个体识别技术相结合，进一步提高肉牛养殖产业智能化水平。

4　结论

(1)提出了一种基于深度学习的肉牛关键点提取算法。首先构建了基于 YOLO v8 的图像筛选算法以筛选关键点完整的肉牛站立图像，然后提出了

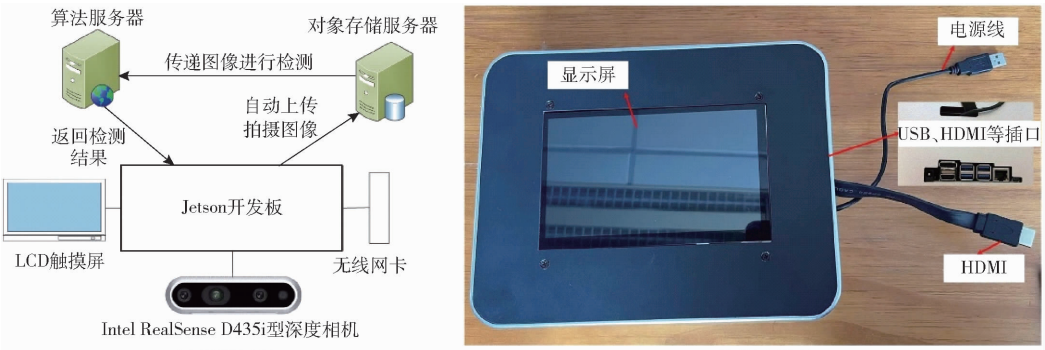


图 13 肉牛边缘端设备

Fig. 13 Edge device for beef cattle

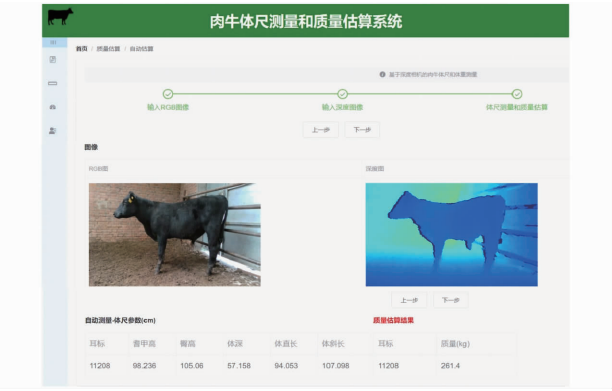


图 14 基于 Web 的体尺测量和质量估算系统

Fig. 14 Web-based body measurement and weight estimation system

基于改进 YOLO v9u - pose 的肉牛关键点检测算法以获得测量点像素坐标。结果表明,改进 YOLO v9u - pose 算法 F1 值为 97.2%,mAP@0.75 为 98.2%,检测精度较高。

(2)提出了基于局部点云处理的体尺特征提取方法,有效减少了当像素关键点向三维空间映射时,与背景深度混淆的问题,提高了算法鲁棒性。

(3)构建了基于 PSO - XGBoost 的肉牛质量估算方法。通过使用粒子群优化算法提高了原模型收敛速度和预测精度,MAPE 为 3.97%,实现了肉牛质量准确估算。最终将模型部署至开发板上,证明了本文算法具有应用于实际场景的潜力。

参 考 文 献

[1] FRIGO E, DECHOW C D, PEDRON O, et al. The genetic relationship of body weight and early-lactation health disorders in two experimental herds[J]. Journal of Dairy Science, 2010, 93(3): 1184 - 1192.

[2] HANSEN M F, SMITH M L, SMITH L N, et al. Automated monitoring of dairy cow body condition, mobility and weight using a single 3D video capture device[J]. Computers in Industry, 2018, 98:14 - 22.

[3] 李道亮,姜国旗,杨建安,等. 基于计算机视觉的鱼类低氧胁迫行为检测与跟踪算法[J]. 农业机械学报, 2023, 54(10): 399 - 406.
LI Daoling, JIANG Guoqi, YANG Jian'an, et al. Detection and tracking algorithm of fish hypoxia stress behavior based on computer vision[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(10): 399 - 406. (in Chinese)

[4] 吴宇峰,李一鸣,赵远洋,等. 基于计算机视觉的奶牛体况评分研究综述[J]. 农业机械学报, 2021, 52(增刊): 268 - 275.
WU Yufeng, LI Yiming, ZHAO Yuanyang, et al. Review of research on body condition score for dairy cows based on computer vision[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(Supp.):268 - 275. (in Chinese)

[5] 黄小平,冯涛,郭阳阳,等. 基于改进 YOLO v5s 的轻量级奶牛体况评分方法[J]. 农业机械学报, 2023, 54(6):287 - 296.
HUANG Xiaoping, FENG Tao, GUO Yangyang, et al. Lightweight dairy cow body condition scoring method based on improved YOLO v5s[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(6):287 - 296. (in Chinese)

[6] 段青玲,赵芷青, 蒋涛, 等. 基于 SNSS - YOLO v7 的肉牛行为识别方法[J]. 农业机械学报, 2023, 54(10): 266 - 274,347.
DUAN Qingling, ZHAO Zhiqing, JIANG Tao, et al. Behavior recognition method of beef cattle based on SNSS - YOLO v7[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(10): 266 - 274,347. (in Chinese)

[7] BEGGS D S, JONGMAN E C, HEMSWORTH P H, et al. Lame cows on Australian dairy farms: a comparison of farmer-identified lameness and formal lameness scoring, and the position of lame cows within the milking order[J]. Journal of Dairy Science, 2019, 102(2): 1522 - 1529.

[8] ZHAO K, BEWLEY J M, HE D, et al. Automatic lameness detection in dairy cattle based on leg swing analysis with an image processing technique[J]. Computers and Electronics in Agriculture, 2018, 148: 226 - 236.

[9] HE C, QIAO Y, MAO R, et al. Enhanced LiteHRNet based sheep weight estimation using RGB - D images[J]. Computers and Electronics in Agriculture, 2023, 206: 107667.

[10] RUCHAY A, DOROFEEV K, KALSCHIKOV V, et al. Live weight prediction of cattle using deep image regression[C]//

2021 IEEE International Workshop on Metrology for Agriculture and Forestry, 2021: 32－36.
[11] NISHIDE R, YAMASHITA A, TAKAKI Y, et al. Calf robust weight estimation using 3D contiguous cylindrical model and directional orientation from stereo images[C]// Proceedings of the 9th International Symposium on Information and Communication Technology, 2018: 208－215.
[12] ISABELLA C C, TAMI M B, KESIA O S, et al. Evaluation of a depth sensor for mass estimation of growing and finishing pigs [J]. Biosystems Engineering, 2018, 173: 11－18.
[13] RUCHAY A N, KOLPAKOV V I, KALSCHIKOV V V, et al. Predicting the body weight of Hereford cows using machine learning[J]. IOP Conference Series. Earth and Environmental Science, 2021, 624(1): 012056.
[14] SONG X, BOKKERS E M A, TOL P P J, et al. Automated body weight prediction of dairy cows using 3-dimensional vision [J]. Journal of Dairy Science, 2018, 101(5): 4448－4459.
[15] WEBER V A M, WEBER F D L, OLIVERIRA A D S, et al. Cattle weight estimation using active contour models and regression trees Bagging[J]. Computers and Electronics in Agriculture, 2020, 179: 105804.
[16] COMINOTTE A, FERNANDES A F A, DOREA J R R, et al. Automated computer vision system to predict body weight and average daily gain in beef cattle during growing and finishing phases[J]. Livestock Science, 2020, 232: 103904.
[17] SHI C, TENG G, LI Z. An approach of pig weight estimation using binocular stereo system based on LabVIEW[J]. Computers and Electronics in Agriculture, 2016, 129: 37－43.
[18] 叶文帅, 康熙, 贺志将, 等. 基于深度图像的多姿态肉牛体尺自动测量方法[J]. 智慧农业(中英文), 2022, 4(4): 144－155.
YE Wenshuai, KANG Xi, HE Zhijiang, et al. Automatic measurement of multi-posture beef cattle body size based on depth image[J]. Smart Agriculture, 2022, 4(4): 144－155. (in Chinese)
[19] LI R, WEN Y, ZHANG S, 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.
[20] DU A, GUO H, LU J, et al. Automatic livestock body measurement based on keypoint detection with multiple depth cameras [J]. Computers and Electronics in Agriculture, 2022, 198:107059.
[21] FAN Q, LIU S, LI S, et al. Bottom-up cattle pose estimation via concise multi-branch network[J]. Computers and Electronics in Agriculture, 2023, 211: 107945.
[22] WANG C, YEH I, LIAO H. YOLOv9: learning what you want to learn using programmable gradient information[C]// Proceedings of the Conference on Computer Vision and Pattern Recognition (CVPR), 2024: 1－21.
[23] LI C, ZHOU A, YAO A. Omni-dimensional dynamic convolution[C]// International Conference on Learning Representations (ICLR), 2022: 1－20.
[24] LIU W, HAO L, FU H, et al. Learning to upsample by learning to sample[C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV), 2023: 6004－6014.
[25] OUYANG D, HE S, ZHANG G, et al. Efficient multi-scale attention module with cross-spatial learning[C]// International Conference on Acoustics, Speech, and Signal Processing (ICASSP), 2023: 1－5.
[26] 蒋伟, 王万虎, 杨俊杰. AEM－YOLOv8s:无人机航拍图像的小目标检测[J]. 计算机工程与应用, 2024, 60(17): 191－202.
JIANG Wei, WANG Wanhu, YANG Junjie. AEM－YOLOv8s: small target detection algorithm for UAV aerial images[J]. Computer Engineering and Applications, 2024, 60(17): 191－202. (in Chinese)
[27] CHEN T, GUESTRIN C. XGBoost: a scalable tree boosting system[C]// Knowledge Discovery and Data Mining. ACM, 2016: 785－794.
[28] SWAMI A, JAIN R. Scikit-learn: machine learning in python[J]. Journal of Machine Learning Research, 2013, 12(10): 2825－2830.
[29] SHAMI T, El-SALEH A A, AlSWAITTI M, et al. Particle swarm optimization: a comprehensive survey[J]. IEEE Access, 2022, 10: 10031－10061.
[30] XIAO B, WU H, WEI H. Simple baselines for human pose estimation and tracking[C]// Computer Vision-ECCV,2018: 1－16.
[31] SUN K, XIAO B, LIU D, et al. Deep high-resolution representation learning for human pose estimation[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2019: 5686－5696.
[32] ALEXEY R, VITALY K, KONSTANTIN D, et al. Comparative analysis of machine learning algorithms for predicting live weight of Hereford cows[J]. Computers and Electronics in Agriculture, 2022,195:106837.