



田富洋,张立印,黄悦华,等. 基于 DRN-YOLO 融合模型的奶牛乳头检测方法研究[J]. 南京农业大学学报,2026,49(3):697-707.

Tian F Y, Zhang L Y, Huang Y H, et al. Research on bovine teat detection method based on the DRN-YOLO fusion model[J]. Journal of Nanjing Agricultural University, 2026, 49(3):697-707.

基于 DRN-YOLO 融合模型的奶牛乳头检测方法研究

田富洋^{1,2}, 张立印^{1,2}, 黄悦华³, 刘继峰⁴, 冯玉璞⁴, 次仁多吉⁵, 于镇伟^{1,2*}

(1. 山东农业大学机械与电子工程学院, 山东 泰安 271018; 2. 山东省农业装备智能化工程实验室, 山东 泰安 271018;
3. 山东省威海市文登区农业农村局, 山东 威海 264406; 4. 山东成城物联网科技股份有限公司, 山东 泰安 271000;
5. 西藏年雄孜吉牧业有限责任公司, 西藏 日喀则 857000)

摘要: [目的] 在自动化挤奶系统中, 奶牛乳头精确识别极为关键。由于挤奶厅环境复杂, 奶牛乳头检测存在精度差、效率低等问题, 这将影响挤奶操作准确性和工作效率, 降低养殖效益。本文旨在提出一种用于奶牛乳头检测的改进 DRN-YOLO 模型。[方法] 该模型采用 DRNet 模块优化 YOLOv8 骨干网络, 提升特征提取能力, 并且在路径增强网络中增加检测特征尺度和空间金字塔池化 (spatial pyramid pooling, SPP) 结构提升特征图特征提取的方法, 使模型可从更多维度分析、提取图像特征, 增强奶牛乳头识别效果, 优化参数配置。为测试 DRN-YOLO 性能, 用 600 张奶牛乳头图像构成测试集进行测试。[结果] 与常用目标检测模型 (YOLOv9 模型和 Faster RCNN 模型) 进行比较, DRN-YOLO 模型的精确率为 99.07%, 召回率为 98.88%, 平均精度均值 (mean average precision, mAP) 为 98.41%, F_1 得分 98.97%。相较于 YOLOv8, DRN-YOLO 模型各种检测指标数值均提高 2% 左右; 相较于 Faster RCNN, DRN-YOLO 模型检测时间缩短了 542 ms, 且检测精度提高 1%。[结论] 改进的 DRN-YOLO 模型能够实现对奶牛乳头的准确检测。

关键词: 奶牛乳头检测; 深度学习; YOLOv8; 改进的 DRN-YOLO 模型; 目标检测

中图分类号: TP391.4

文献标志码: A

文章编号: 1000-2030(2026)03-0697-11

Research on bovine teat detection method based on the DRN-YOLO fusion model

TIAN Fuyang^{1,2}, ZHANG Liyin^{1,2}, HUANG Yuehua³, LIU Jifeng⁴, FENG Yupu⁴, Ciren Duoji⁵, YU Zhenwei^{1,2*}

(1. College of Mechanical and Electronic Engineering, Shandong Agricultural University, Tai'an 271018, China;
2. Shandong Provincial Agricultural Equipment Intelligent Engineering Laboratory, Tai'an 271018, China;
3. Agriculture and Rural Affairs Bureau of Wendeng District, Weihai City, Shandong Province, Weihai 264406, China;
4. Shandong Chengcheng Internet of Things Technology Co., Ltd., Tai'an 271000, China;
5. Xizang Nianxiongzi Animal Husbandry Co., Ltd., Rikaze 857000, China)

Abstract: [Objectives] In automated milking systems, accurate identification of cow teats is crucial. Due to the complex environment of milking parlors, existing cow teat detection methods faced challenges such as poor accuracy and low efficiency, which negatively impacted milking operation precision, workflow efficiency, and farm profitability. To address these issues, an improved DRN-YOLO model for cow teat detection was proposed in this article. [Methods] The YOLOv8 backbone network was optimized using a DRNet module to enhance feature extraction capabilities. Additionally, the detection feature scale and a spatial pyramid pooling (SPP) structure were incorporated into the path enhancement network, enabling multi-dimensional analysis and feature extraction from images. This improved teat recognition performance and optimized parameter configuration. To evaluate the DRN-YOLO model, a test set composed of 600 cow teat images was utilized. [Results] Comparative experiments with widely-used object detection models (YOLOv9 and Faster R-CNN) demonstrated that the proposed model achieved a precision rate of 99.07%, recall rate of 98.88%, mean average precision (mAP) of 98.41%, and an F_1 -score of 98.97%. Compared to YOLOv8, all detection metrics of the DRN-YOLO model improved by approximately 2%. Furthermore, the detection time was reduced by 542 ms compared to Faster R-CNN, while detection accuracy surpassed Faster R-CNN by 1%. [Conclusions] The improved DRN-YOLO model enabled accurate cow teat detection.

Keywords: cow teat detection; deep learning; YOLOv8; improved DRN-YOLO model; object detection

收稿日期: 2024-12-15

基金项目: 山东省科技型中小企业创新能力提升工程项目 (2023TSGC059901); 日喀则市科技计划项目课题 (RKZ2024ZY-03)

*通信作者: 于镇伟, 博士, 副教授, 研究方向为智能畜牧装备研究, E-mail: zhenweiyu615@126.com。

在奶牛养殖业中,挤奶过程是劳动最密集、劳动力需求最大的活动。通常情况下日均人工挤奶次数达到2~3次,每年超过300 d。人工挤奶不稳定因素较多,成本大,并且人类活动还可能对奶牛产生负面影响^[1-2]。自动挤奶技术是奶牛养殖业中降低人工成本最合适的方法,自动挤奶将会逐步取代人工挤奶方式^[3]。自动挤奶技术最关键问题是准确识别奶牛乳头^[4]。目前,已经有一些传统奶牛乳头检测方法^[5-7],但上述研究数据均在实验室环境下获得,缺少实际挤奶厅环境的研究数据。与传统机器学习方法相比,深度学习通过自主学习图像特征表示,避免了人工监督学习特征需求,深度学习技术或将成为解决复杂环境下自动化挤奶关键技术。近年来,深度学习在奶牛养殖业中得到广泛应用^[8]。王彦超等^[9]利用改进YOLOv3-tiny算法实现奶牛乳房炎自动检测,奶牛乳房炎检测精度达到77.3%;Lu等^[10]基于R2Faster RCNN算法应用于旋转挤奶系统,模型平均精度(AP)值为80.41%,每幅图像检测时间为0.19 s;Porter等^[11]开发了一种深度学习网络用于预测荷斯坦牛乳头末端情况,区分奶牛乳头正常、平滑、粗糙和非常粗糙4种状态,特征曲线下面积分别为0.778、0.542、0.863和0.920;除了奶牛乳头检测外,研究人员还利用深度学习单阶段检测模型^[12-16]和双阶段检测模型^[17-19]用于畜牧养殖的其他方面研究,为深度学习在奶牛乳头检测领域提供了参考。

由于奶牛乳头属于小个体,形状不一,并且挤奶厅环境复杂,很容易对目标产生错检或者漏检,因此本文从上述问题出发,提出一种DRN-YOLO深度学习算法模型。该模型以YOLOv8模型为基础,通过使用DRNet模块构成的骨干网络减少网络参数,在特征金字塔网络的基础上增加了新的特征尺度,并使用路径增强网络和SPP结构,缩短高层级与低层级之间的特征融合路径,以增强对奶牛乳头识别准确性。

1 材料与方法

1.1 图像采集

本文使用的奶牛乳房数据来自山东省泰安市岱岳区金兰奶牛养殖公司,公司现存栏量超过2 000头优质中国荷斯坦奶牛。以泌乳期中国荷斯坦奶牛为研究对象,于2023年11月1日至30日,共计30 d,每日13:00至14:00(15:00开始挤奶)在1号挤奶厅采集奶牛乳头图像。挤奶厅为自然光采光,光照充足;挤奶厅尺寸为45 m×10 m,挤奶位采用“鱼骨式”排列,一侧拥有30个挤奶位,每个挤奶位每头奶牛挤奶时长约为12 min。为不失一般性及验证算法鲁棒性,利用手机(型号:荣耀10 GT)后置摄像头(2 400万像素+1 600万像素)专业相机模式进行拍摄,照片分辨率4 680像素×3 456像素,焦距等效35 mm胶片焦距,照片感光度为100~400,快门速度为1/60~1/180 s,拍摄镜头与乳头的距离控制在20~30 cm。如图1所示,以奶牛乳头处为坐标原点建立坐标轴,其中奶牛乳头垂直地面向上方向为Y轴正方向,奶牛乳头指向奶牛尾部并垂直于Y轴方向为Z轴正方向,于奶牛尾部观测奶牛乳头向右方向为X轴正方向,拍摄角度取YZ平面第4象限-90°~0°,XY平面第2、3象限-135°~-45°,镜头均对向奶牛乳头位置。




图1 奶牛拍摄角度图

Fig. 1 Diagram of cow shooting angle

金兰奶牛养殖公司依据标准化作业流程实施奶牛乳头图像采集工作,每日于挤奶环节固定开展单次数据采集,严格遵循“人工消毒—图像采集—套杯挤奶”作业时序,在乳头消毒完成后至挤奶杯组安装前进行图像采集。由于工序衔接时效,每日采集的奶牛数量为10~15头。随机采集奶牛乳头图像,在上述角度中随机取样,确保每头奶牛采集约20张图像,对同一奶牛进行多次不同角度的采集,且所有采集图像中均包含奶牛4个乳头。在30 d内,累计采集6 930张奶牛乳头RGB图像,以JPEG格式储存。经筛选剔除模糊、重影和重复的图像,最终选取1 400幅奶牛乳头图像进行试验,选择的奶牛乳头图像中包含不同

长度、不同遮挡程度奶牛乳头和拍摄时不同光照以及不同角度等可能影响检测效果的图像。逆光强、逆光弱、长乳头、短乳头、有遮挡和无遮挡的图像数量分别为 340、1 060、265、1 135、28 和 1 372 张。

1.2 图像预处理

使用开源标注工具 LabelImg 对 1 400 张奶牛乳头原始图像进行人工标注,将原始数据集按照 1:6 的比例分为包含 200 张图像的测试数据集和包含 1 200 张图像的训练数据集。图片尺寸调整为 416 像素×416 像素。由于奶牛乳头形状不一,可能存在遮挡或残缺现象,制定标注规则如下:1) 不标注有遮挡、不完整奶牛乳头;2) 分别标注相邻奶牛乳头。每次完成乳头图像标注,LabelImg 会自动生成相对应的 xml 文件,文件中记录奶牛乳头标注矩形框的左上角坐标和右下角坐标,标注矩形框的长、宽以及标注类别信息。为了优化训练过程,对奶牛乳头标注框做归一化处理,如式(1)所示。

$$x = \frac{x_{\max} + x_{\min}}{2R_w}, \quad y = \frac{y_{\max} + y_{\min}}{2R_h}, \quad w = \frac{x_{\max} - x_{\min}}{R_w}, \quad h = \frac{y_{\max} - y_{\min}}{R_h} \quad (1)$$

式中: x 、 y 、 w 、 h 分别表示归一化后奶牛乳头标注矩形框中心点坐标以及标注框的宽度和高度; $x_{\max}$ 、 $x_{\min}$ 、 $y_{\max}$ 、 $y_{\min}$ 分别为人工标注的奶牛乳头标注矩形框左上角和右下角坐标; R_w 、 R_h 分别为奶牛乳头图像的宽度和高度。

对标注完成的数据集采用镜像、缩放增强方式对数据集进行增强,增强后数据集总数为 4 200 张,其中测试集为 600 张,训练集为 3 600 张。

2 奶牛乳头识别方法

2.1 YOLOv8 模型

YOLO 系列^[20]为单阶段检测模型,检测速度相较于双阶段模型更快,但检测准确性差。单阶段模型引入注意力机制以提高精度,但会使深层网络速度变慢。为了在精度和速度之间取得平衡,本研究选择以 YOLOv8 模型为基础进行改进。YOLOv8 是目前 YOLO 系列中性能较为均衡版本,广泛应用于工业界和学术界,具有较高的参考价值。虽然 YOLO 系列已更新到更高版本(如 YOLOv10、YOLOv11 等),但这些版本在速度和精度上的改进主要针对特定场景,而 YOLOv8 的通用性和成熟度使其更适合作为本研究的基准模型。使用 DRNet 模块代替 CSPDarknet 模块,使用 SPP 金字塔池化结构^[21]并加强 PAN 路径增强网络与骨干网络的联系,在原有 3 个检测模块基础上增加 1 个检测模块,在保证奶牛乳头检测速度的基础上增加奶牛乳头检测的准确度。

2.2 YOLOv8 模型改进

2.2.1 DRNet 模块 在动物检测方面的目标检测通常采用边缘计算或者云计算方式,由于 YOLOv8 是通过堆叠卷积层与残差连接构建的骨干网络,所以模型复杂程度理论上可以满足需求。实际应用反馈表明,相较于双阶段目标检测算法,该模型虽然保持着单阶段检测器固有的推理速度优势,但在检测精度维度存在明显局限^[7]。特别是在奶牛乳头检测这种需要同时满足实时性与高准确率的特殊场景中,YOLOv8 现有的性能表现难以达到精准识别与快速判断的需求。

改进的 DRN-YOLO 算法模型使用了改进 DRNet 骨干网络替换 YOLOv8 骨干网络。DRNet 骨干网络借鉴 DenseNet^[22]和 ResNet 两种经典架构,融合了 Denseblock 和 Resblock 模块。DenseNet 骨干网络由 CBL 结构和 Denseblock 模块结合构成,通过 Denseblock 模块有效减轻了梯度消失现象,加强了特征图传递,并在一定程度上减少了参数量,使检测速度更快;ResNet 是由 CBL 结构和 Resblock 模块结合构成,通过 Resblock 模块,可以使网络层更深、学习能力更强。DRNet 骨干网络中 DRNblock 结构如图 2 所示:由 2 个 1×1 CBL 结构、2 个 3×3 CBL 结构、1 个张量相加层和 2 条快捷通道组成。特征信息由上一部分传入




图2 DRN 模块结构图

Fig. 2 Structural diagram of the DRN module

DRNblock 时,信息从 2 条路径传向下一级:一条路径经由快捷通道直接传入下一级;另一条路径则是先通过 1 个 1×1 CBL 结构和 1 个 3×3 结构,之后信息再次从 2 条路径向下传递,一条路径通过快捷通道,一条路径再次通过 1 个 1×1 CBL 结构和 1 个 3×3 CBL 结构,2 条路径由 1 个 add 层汇合,与最初快捷通道的信息进行张量拼接后传入下一级。特征信息通过 DRNblock 时,一方面直接将特征信息由快捷通道传到输出位置,保护信息完整性;另一方面模型只需要学习并强化输入、输出差别的那一部分,且每一层都直接连接输入和损失部分,在简化学习目标和难度的同时还可以减轻梯度消失现象。因此,DRN-YOLO 骨干网络相较于原 YOLOv8 骨干网络,模型深度更深,对特征图的特征信息提取更全面,学习能力更强。

2.2.2 SPP 结构 SPP 结构如图 3 所示。SPP 输入为任意大小特征图,经过多次不同尺度池化,采集各级池化后特征图并堆叠,最终得到固定维数输出的特征图。由于 SPP 结构把 1 个特征图从不同角度进行特征提取再聚合,增强了算法的鲁棒性与感受野,同时提高了检测精度。通过 SPP 结构可以实现局部特征和全局特征的特征图融合,丰富最终特征图表达能力,从而提高训练 AP 值。由于 SPP 结构只需要将特征图输入 1 次,其检测速度是 R-CNN 结构检测速度的 24~102 倍。




图 3 SPP 结构图

Fig. 3 Structure diagram of SPP

新增加特征金字塔特征尺度是与前端浅层网络连接,奶牛乳头特征信息相较于深层网络相对较少,特征提取可能会有缺失。在新的特征尺度与浅层网络之间加入 SPP 结构,可以使奶牛动作局部与全局的特征信息融合,使浅层网络的特征信息更加丰富并且增加感受野,提高奶牛动作目标检测的精度,同时提高模型的检测速度。

2.2.3 DRN-YOLO 模型的建立 利用手机拍摄的奶牛乳头图像为小样本数据,图像中奶牛乳头相较于整体图像占比小,并且奶牛乳头长度、大小及乳头间距存在个体间差异,导致浅层网络特征提取不足。为了解决此问题,引入 DRNet 模块,替换 YOLOv8 骨干网络。模型颈部方面,在原有特征金字塔网络 FPN^[23]基础上增加了新特征尺度,在新特征尺度上使用路径增强网络 PAN^[24]缩短高层级与底层级之间特征融合路径,并且融合了丰富特征信息。模型预测模块方面,采用 CIoU (complete intersection over union)^[25]代替 IoU (预测边界盒与地面真相边界盒相交并比率),考虑到尺度、距离、惩罚项和锚之间的重叠率对损失函数影响,目标帧回归变得更加稳定。CIoU 计算公式:

$$CIoU = IoU - \frac{\rho^2(b, b^{gt})}{c^2} - \alpha v \quad (2)$$

$$\alpha = \frac{v}{1 - IoU + v} \quad (3)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right)^2 \quad (4)$$

$$Loss_{CIoU} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{c^2} + \alpha v \quad (5)$$

式中: c 表示预测边界框与真实标注框的最小外接矩形对角线距离; α 表示权重函数; v 表示长宽比相似性; w 、 h 、 w^{gt} 、 h^{gt} 分别表示当前检测框的宽、高和下一帧预测框的宽、高; $\rho^2(b, b^{gt})$ 表示预测中心点与真实帧之间欧式距离,最后用 $1 - CIoU$ 得到相应损失。

DRN-YOLO 算法架构如图 4 所示,其检测流程包含多阶段特征融合机制。输入 416 像素×416 像素的奶牛乳头图像首先通过由 4 组 DRNet 模块(数量配比分别为 4、4、20、4)构建的骨干网络进行深度特征提取,随后接入 FPN+PAN 双向特征金字塔结构。该架构通过上采样、下采样操作实现跨层级特征交互,将浅层定位信息与深层语义特征进行多尺度融合,形成具有丰富空间-语义信息的复合特征图。最终,经过 3 次特征增强后的多维度信息在检测头完成解码,通过锚框回归与分类器协同输出目标检测结果。

3 结果与分析

3.1 试验参数设置

算法训练以及测试硬件平台配置: Intel Xeon (R) W-2135 CPU® 3.70 GHz 和 NVIDIA GeForce




图4 DRN-YOLO 模型结构图

Fig. 4 Structure diagram of DRN-YOLO model

RTX2080TI;环境配置:Ubuntu18.04.6 操作系统,Python 版本 3.6.5,CUDA 版本 10.2.89,CUDNN 版本 7.6.5,OpenCV 版本 4.4.0。

试验参数中,批处理大小(batch-size)和细分程度(subdivision)会影响训练所用时间。批处理图像数量越大,细分程度越小,训练所用时间越短。测试发现,当批处理图像超过 16、细分程度小于 8 时,系统终端会出现“CUDA Error:out of memory”。因此,参数设定为批处理图像为 16,细分程度为 8。在 YOLOv8 图像输入中,通常使用的输入尺寸有 416 像素×416 像素、520 像素×520 像素、608 像素×608 像素,为了节约计算成本,选择输入图像为 416 像素×416 像素。

通过调整不同学习率进行试验可知:当学习率为 0.1 时,损失函数会在迭代 390 次左右时出现损失值突然上升且无法收敛的情况(图 5-A);当学习率为 0.01 时,损失函数会在迭代 900 次左右出现损失值突然上升且无法收敛的情况(图 5-B);当学习率为 0.001 时,损失函数收敛良好,未出现爆炸式增长情况,符合预期收敛要求,因此设置初始学习率为 0.001。权重衰减率等同于 L2 范数正则化,通过为损失函数添加惩罚项,目的是将权重衰减到更小值以此减少模型过拟合问题,其值应接近于 0,而模型默认值为 0.000 5 符合要求,因此设置权重衰减率为 0.000 5。




图5 学习率对损失值影响

Fig. 5 The effect of different learning rates on loss value

A. 学习率为 0.1 时 With a learning rate of 0.1; B. 学习率为 0.01 时 With a learning rate of 0.01.

训练最大迭代次数与训练效果直接相关,分别在初始学习率为 0.001、权重衰减值为 0.000 5 条件下验证迭代次数的影响。研究发现:迭代 1 000 次时,损失曲线处于欠拟合状态,损失值为 2.854 3;迭代 10 000 次时,损失曲线已经开始收敛,但仍处于欠拟合状态,损失值为 1.250 8;迭代 20 000 次时,曲线依旧处于欠拟合状态,但曲线斜率已平缓,逐步接近完美拟合状态,损失值为 0.946 6;迭代 45 000 次时,曲线几乎平缓,未出现明显变化,表明曲线基本达到完美拟合状态,损失值为 0.398 2。为了确保达到完美拟合效

果,测试迭代 50 000 次情况,发现损失曲线几乎无变化,损失值为 0.360 9,表明模型训练已达到完美拟合,故设置最大迭代次数为 50 000 次。

3.2 评价指标

为了准确评价模型性能,采用目标检测算法中的常用性能评价指标:准确率 (accuracy)、精确率 (precision)、召回率 (recall)、平均精度均值 (mean average precision, mAP)、特异性 (specificity)、 F_1 得分 (F_1 -score) 和模型复杂度 (模型内存占有量和 FLOPs) 检验模型性能。

在精确率和召回率方面,预测测试样本有 4 种状态:真阳性 (T_p)、假阳性 (F_p)、真阴性 (T_N) 和假阴性 (F_N)。精确率和召回率计算公式:

$$Precision = \frac{T_p}{T_p + F_p} \quad (6)$$

$$Recall = \frac{T_p}{T_p + F_N} \quad (7)$$

平均精度、 F_1 得分、准确率和特异性计算公式:

$$AP = \int_0^1 Precision(Recall) dRecall \quad (8)$$

$$mAP = \frac{1}{m} \sum_m AP \quad (9)$$

$$F_1\text{-score} = 2 \times \frac{Precision \cdot Recall}{Precision + Recall} \quad (10)$$

$$Accuracy = \frac{T_p + T_N}{T_p + T_N + F_p + F_N} \quad (11)$$

$$Specificity = \frac{T_N}{T_N + F_p} \quad (12)$$

3.3 消融试验

为验证 DRN-YOLO 模型改进策略的有效性,基于 YOLOv8 框架开展消融试验,通过模块化组合验证方法系统评估各改进组件性能贡献。结果如表 1 所示,改进后的模型架构在关键指标上相较基准模型实现显著提升。

表 1 不同模块对模型性能的影响

Table 1 The impact of each module on model performance

YOLOv8	DRNet	四特征尺度 Four feature scale	SPP	平均精度均值/% mAP	F_1 得分 F_1 -score	精确率/% Precision	召回率/% Recall
✓				96.27	97.09	97.29	96.91
✓		✓		97.11	97.65	98.01	97.29
✓		✓	✓	97.48	98.07	98.42	97.73
✓	✓			97.34	97.62	97.80	97.44
✓	✓	✓		97.93	98.11	98.40	97.83
✓	✓	✓	✓	98.41	98.97	99.07	98.88

注:✓表示该模块添加至此模型。✓ indicates that this module is added to this model.

3.3.1 四特征尺度性能比较 奶牛乳头相对于奶牛本体属于小目标,且不同奶牛乳头长短不一。而 YOLOv8 模型检测对小目标检测能力不足,最直观的检测指标映射是模型损失曲线波动大,模型 mAP 值低(图 6-A)。为了增强对奶牛乳头这类小目标的检测效果,采用特征金字塔网络(FPN)增强方法,即增加 1 个特征尺度,使骨干网络中深层网络与颈部连接网络之间的联系更加密切。由表 1 和图 6-B 可以看出,相较于 YOLOv8,通过增加新的特征尺度,对模型损失曲线有明显抑制发散的作用,平均损失值由 1.372 0 降至 0.834 0,且 mAP 值从 96.21%提高至 97.11%,精确率和召回率也有不同程度的提高。通过增加特征尺度对奶牛乳头类似小目标进行检测,降低了奶牛乳头检测失检率,提高了模型检测性能。

3.3.2 SPP 池化结构性能比较 由表 1 和图 6-C 可以看出,增加到四特征尺度后 mAP 值有所提升。虽然增强了网络之间的连接,提升了奶牛乳头小目标的匹配度,但特征感受野提取不充分,导致特征提取方面不够全面。因此,加入 SPP 池化结构可以解决特征提取不充分的问题。使用 SPP 池化结构可以使浅层

网络的特征信息更加丰富并且增加感受野,以此提升模型检测性能。增加 SPP 池化结构后,mAP 值为 97.48%,比 YOLOv8 的 mAP 值高 1.37%。从结果可以看出,使用 SPP 池化结构对目标特征图感受野起到了有效扩大的作用。

3.3.3 DRNet 模块性能比较 由表 1 和图 6-C 可以看出,通过使用四特征尺度和 SPP 池化结构,模型检测效果提升,对奶牛乳头小目标检测更加准确,但结构增加使模型体量增大。为了降低模型复杂度,将 YOLOv8 中的骨干网络替换为 DRNet 模块,DRNet 模块中的 DRN block 可以在保证模型性能的同时降低模型复杂程度,减少模型内存消耗。由图 6-D 可以看出,加入 DRNet 模块后损失曲线值进一步降低,平均损失值由 1.372 0 降至 0.535 8,模型完美拟合。

3.3.4 DRN-YOLO 性能比较 由表 1 和图 6-F 可以看出,DRN-YOLO 使用了 DRNet 模块后并在增加的特征尺度上使用 SPP 结构,平均损失值降至 0.360 9,mAP 值为 98.41%,对比 YOLOv8 模型,性能较大提升。




图 6 不同模型增强后损失值

Fig. 6 Model improvement strategy performance comparison loss value

3.3.5 损失函数性能比较 为了验证 CIoU 替换 IoU 对模型的影响,设计对比试验,除损失函数外,模型其他结构均保持不变,结果如表 2 所示。与使用 IoU 模型相比,使用 CIoU 模型的平均精度均值、 F_1 得分、精确率和召回率分别增加 1.19%、1.66%、0.98%和 1.56%,这主要是因为 CIoU 损失函数会引入尺度不变性惩罚项,有效平衡不同尺寸目标回归权重,建立中心点距离约束机制,增强锚框定位精度,还会构建重叠区域动态补偿策略,优化边界框匹配质量。多维度改进使目标框回归过程具有更强的鲁棒性,最终推动模型整体性能持续优化。

表 2 不同损失函数对模型的影响

Table 2 The effect of different loss functions on the model

模型 Model	平均精度均值/% mAP	F_1 得分 F_1 -score	精确率/% Precision	召回率/% Recall
IoU 模型 IoU model	97.22	97.31	98.09	97.32
CIoU 模型 CIoU model	98.41	98.97	99.07	98.88

3.4 不同模型对比分析

为了验证奶牛乳头检测在深度学习应用中的有效性,进一步分析 DRN-YOLO 模型提升性能,使用 YOLOv9 和 Faster RCNN 模型,以准确率、精准度、召回率、平均精度均值、特异性和 F_1 得分为评价指标,结合平均检测时间,与 DRN-YOLO 模型进行综合对比。本文严格控制试验相关参数,使用统一图像大小(416 像素×416 像素)作为模型输入,统一训练集和测试集进行试验测试。各模型在测试集对比试验结果如表 3 所示。

表 3 不同模型的结果对比
Table 3 Comparison of experimental results of test set

模型 Model	准确率/% Accuracy	精确率/% Precision	召回率/% Recall	平均精度 均值/% mAP	特异性 Specificity	F ₁ 得分 F ₁ -score	平均检测时间/ms Mean time to detection	模型内存占有量/MB The amount of memory occupied by the model	FLOPs
YOLOv9	94.46	97.29	96.91	96.27	0.41	97.00	28	9.3	23.3
YOLOv8	95.50	97.80	97.44	97.34	0.52	97.61	28	8.9	13.5
Faster R-CNN	96.25	98.14	97.93	97.49	0.61	98.03	568	20.3	58.6
SSD	94.49	97.08	97.14	96.34	0.42	97.11	30	13.8	30.6
DRN-YOLO	98.04	99.07	98.88	98.41	0.80	98.97	26	8.6	12.3

试验结果表明,对于奶牛乳头数据集检测,双阶段 Faster RCNN 模型在识别准确性上,整体高于一阶段的 YOLOv9 模型和 SSD 模型,但低于 DRN-YOLO 模型。在检测精度和检测时间上,DRN-YOLO 均优于 YOLOv9、SSD 和 Faster RCNN 模型。在测试集中,DRN-YOLO 模型检测奶牛乳头准确率、精确率、召回率、平均精度均值、特异性、F₁ 得分、平均检测时间、模型内存占有量和 FLOPs 分别为 98.04%、99.07%、98.88%、98.41%、0.80、98.97、26 ms、8.6 MB 和 12.3。对比 YOLOv8 模型,准确率、精确度、召回率、平均精度均值、特异性和 F₁ 得分分别提高 3.58%、1.78%、1.97%、2.14%、0.39% 和 2.01%,平均检测时间、模型内存占有量和 FLOPs 分别减少 2 ms、0.3 MB 和 1.2。这主要是因为 DRNet 模块骨干网络,不仅降低了模型复杂度,还提升了学习能力、检测精度并缩短了检测时间。综上,单阶段 DRN-YOLO 模型检测精度已经高于双阶段模型 Faster RCNN,且检测奶牛乳头所使用时间更少,达到检测奶牛乳头准确快速的要求。

YOLOv9、Faster R-CNN、SSD 模型大小为 9.3、20.3 和 13.8 MB,而 DRN-YOLO 仅为 8.6 MB,在这几款模型中相对轻巧。YOLOv9、Faster R-CNN、SSD 的 FLOPs 分别为 23.3、58.6 和 30.6,DRN-YOLO 则低至 12.3,这意味着 DRN-YOLO 在计算量上具有明显优势,模型复杂度更低。从模型大小和 FLOPs 可以看出,DRN-YOLO 模型在保持轻量级的同时,计算资源需求少。这一特性使其在边缘计算和云计算中展现出独特优势。在边缘计算场景下,如奶牛养殖场现场部署的智能设备资源有限,而 DRN-YOLO 的模型具有较小计算量,所以其能够在低功耗设备上高效运行,实时检测奶牛乳头,及时发现健康问题。在云计算场景中,大量的数据处理任务对计算资源消耗巨大,DRN-YOLO 凭借其低 FLOPs,可以在相同的计算资源下,处理更多的检测任务,提高计算效率,降低成本。通过上述分析可以看出,DRN-YOLO 模型复杂程度更低,综合检测性能更强,对于奶牛乳头的检测更加准确。

3.5 模型检测结果的分析

3.5.1 模型特征图的分析 利用模型对奶牛乳头图像提取的特征图分析模型的优劣。由于特征图大小尺寸不一,部分特征图无法通过人工方式辨别,因此本文选取最具代表性的几张特征图,如图 7 所示。




图 7 卷积特征图
Fig. 7 Convolution feature map

将 DRN-YOLO 不同层特征图进行可视化,其中 $416 \times 416 \times 32$ 和 $208 \times 208 \times 64$ 为宽 $\times$ 高 $\times$ 通道含义,linear 为检测模块前一层特征图。随着网络不断深化,网络越来越重视目标语义表达,且特征图更加抽象。计算机具有处理高维深度语义特征信息的优势,从而实现准确识别。基于 DRN-YOLO,增加了特征图感受野,丰富了特征信息。由图 7 可以看出,模型提取特征信息后在检测模块前的特征图中只突出保留了奶牛乳头特征信息,过滤掉没用信息,验证了算法有效性。再次证明本算法对奶牛乳头识别的准确性。

3.5.2 光照强度、乳头长度和有无遮挡及拍摄角度对模型结果的影响 为了检测 DRN-YOLO 模型的鲁棒性,对采集的奶牛乳头图像在光照强度、奶牛乳头长度、有无遮挡以及拍摄角度等方面进行测试。从图 8 可以看出,光照强度、奶牛乳头长度以及拍摄角度不同的图像,对奶牛乳头识别位置以及置信度影响较小,均可定位奶牛乳头准确位置且置信度在 99% 以上。对于奶牛乳头有体毛遮挡的图像,模型可定位奶牛乳头具体位置,检测置信度为 78%,比没有体毛遮挡的图像检测置信度低 21%,这是因为体毛遮挡部分乳头特征,导致模型在特征提取时信息不完整,说明有体毛遮挡的奶牛乳头会影响检测精度。




图 8 不同因素对检测结果的影响

Fig. 8 Effects of different influencing factors on model results

3.5.3 噪声对结果的影响 在挤奶厅环境中,因为奶牛走动以及部分应激反应,可能会扬起部分灰尘影响摄像头检测。为测试模型抗噪声能力,对图片加入随机噪声,对 DRN-YOLO 模型进行测试,测试结果如图 9 所示。图 9-A 每张图像施加噪声点数量为 500,图 9-B 每张图像施加噪声点数量为 900。图片噪声对 DRN-YOLO 模型影响较小,置信度都在 90% 以上。DRN-YOLO 模型检测置信度加噪声高比加噪声低时降低 2%~3%,在检测示例图像中未出现漏检情况。这是由于 DRN-YOLO 模型在特征尺度上增加了 SPP 结构,丰富了特征图信息,特征提取更全面,噪声对模型影响较小。




图9 噪声对检测结果的影响

Fig. 9 DRN-YOLO model detection plus noise image

3.6 可行性与局限性分析

DRN-YOLO 模型检测性能、检测所用时间和模型复杂程度相较于原 YOLOv8 网络有了较大提升,非常适合应用于边缘计算以及云计算场合,模型推理速度保证实时检测的可行性,在挤奶厅这种受环境因素影响较大的情况下也可以进行准确判断。

DRN-YOLO 模型应用于边缘计算以及云计算等计算方式,模型体量较大,这导致模型的应用范围局限,便携性程度不高。在未来研究中,将在不损失模型识别准确性的情况下缩小模型的体量作为未来研究重点,以便适用于移动平台和嵌入式开发平台,模型的适用范围更加广泛。

4 结论

为实现奶牛乳头准确、快速检测,本文提出了一种基于 DRN-YOLO 融合模型的奶牛乳头检测算法。结论如下:

1) DRN-YOLO 对奶牛乳头检测平均精确率为 98.35%,检测单幅图像为 26 ms,实现了奶牛乳头准确、快速检测,在所测试的单阶段与双阶段检测模型中检测效果最优。在施加噪声后,置信度仅下降 2%~3%,证明 DRN-YOLO 拥有良好的抗噪声能力,对挤奶厅环境下奶牛乳头识别具有较好的鲁棒性。

2) 在挤奶厅环境中。不同光照强度、奶牛乳头长度以及拍摄角度对奶牛检测置信度影响较小,但奶牛乳头遮挡对检测置信度影响较大。

3) 尽管 DRN-YOLO 在奶牛乳头检测中表现出色,但在实际应用中仍存在一定局限性。当遇到极端复杂的遮挡情况,如多个奶牛乳头相互严重遮挡时,模型检测精度会受到较大影响,甚至出现漏检、误检的情况。并且模型对于一些特殊品种奶牛乳头特征的适应性有待提高,部分品种奶牛乳头形态、颜色等特征与训练集中数据存在较大差异时,检测效果会有所下降。下一步研究将着重研究奶牛乳头定位问题,通过优化算法,提高模型在复杂遮挡情况下的检测能力。例如探索更先进的目标分割与定位技术,将其融入 DRN-YOLO 模型中。并且,扩大训练数据集,涵盖更多不同品种奶牛乳头数据,以增强模型对各类乳头特征的适应性。还需对模型进行轻量化和优化计算资源利用的研究,使模型能够在有限计算资源下处理更大规模的检测任务。

参考文献 References:

- [1] 高然. 挤奶机器人对奶牛场挤奶管理能力的提升[J]. 中国乳业, 2024(9): 26-29.
Gao R. Milking robots enhance the milking management capabilities of dairy farms[J]. China Dairy, 2024(9): 26-29 (in Chinese with English abstract).
- [2] Múnera-Bedoya O D, Cassoli L D, Machado P F, et al. Influence of attitudes and behavior of milkers on the hygienic and sanitary quality of milk [J]. PLoS One, 2017, 12(9): e0184640.
- [3] 马慧, 丛慧敏, 钟景田. 机器人挤奶系统对奶牛行为、健康状况及生产性能影响的研究进展[J]. 中国奶牛, 2017(6): 59-63.
Ma H, Cong H M, Zhong J T. Research progress on the effect of automatic milking system on behavior, health status and performance of dairy cows[J]. China Dairy Cattle, 2017(6): 59-63 (in Chinese with English abstract).
- [4] 李昊原, 付彤, 李转见, 等. 规模化奶牛养殖场动物福利水平评价[J]. 家畜生态学报, 2023, 44(12): 54-59.
Li H Y, Fu T, Li Z J, et al. Assessment of animal welfare level in large-scale dairy farms[J]. Journal of Domestic Animal Ecology, 2023, 44(12): 54-59 (in Chinese with English abstract).

- [5] 夏事成,王磊,王成军,等. 基于改进YOLOv5的奶牛乳头目标检测与数据集构建[J]. 安徽科技学院学报,2023,37(5):64-70.
Xia S C, Wang L, Wang C J, et al. Nipples object detection and dataset construction based on improved YOLOv5[J]. Journal of Anhui Science and Technology University, 2023, 37(5): 64-70 (in Chinese with English abstract).
- [6] Rodriguez F A N, Lopes M A, Lima A L R, et al. Comparative analysis of milking and behavior characteristics of multiparous and primiparous cows in robotic systems[J]. Anais da Academia Brasileira de Ciencias, 2024, 96(3): e20221078.
- [7] Rastogi A, Ryuh B S. Teat detection algorithm: YOLO vs. Haar-cascade[J]. Journal of Mechanical Science and Technology, 2019, 33(4): 1869-1874.
- [8] 王政,宋怀波,王云飞,等. 奶牛运动行为智能监测研究进展与技术趋势[J]. 智慧农业(中英文), 2022, 4(2): 36-52.
Wang Z, Song H B, Wang Y F, et al. Research progress and technology trend of intelligent morning of dairy cow motion behavior[J]. Smart Agriculture, 2022, 4(2): 36-52 (in Chinese with English abstract).
- [9] 王彦超,康熙,李孟飞,等. 基于改进YOLOv3-tiny的奶牛乳房炎自动检测方法[J]. 农业机械学报, 2021, 52(增刊1): 276-283.
Wang Y C, Kang X, Li M F, et al. Automatic detection method for dairy cow mastitis based on improved YOLOv3-tiny[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(Suppl 1): 276-283 (in Chinese with English abstract).
- [10] Lu Z H, Zhao M F, Luo J, et al. Automatic teat detection for rotary milking system based on deep learning algorithms[J]. Computers and Electronics in Agriculture, 2021, 189: 106391.
- [11] Porter I R, Wieland M, Basran P S. Feasibility of the use of deep learning classification of teat-end condition in Holstein cattle[J]. Journal of Dairy Science, 2021, 104(4): 4529-4536.
- [12] 刘亚楠,沈明霞,刘龙申,等. 基于机器视觉的母猪哺乳行为监测方法研究[J]. 南京农业大学学报, 2022, 45(2): 404-411. DOI: 10.7685/jnau.202106027.
Liu Y N, Shen M X, Liu L S, et al. Research on monitoring method of sow's nursing behaviour based on machine vision[J]. Journal of Nanjing Agricultural University, 2022, 45(2): 404-411 (in Chinese with English abstract).
- [13] Jia Q X, Yang J C, Han S J, et al. CAMLLA-YOLOv8n: cow behavior recognition based on improved YOLOv8n[J]. Animals, 2024, 14(20): 3033.
- [14] 陆舟,沈明霞,刘龙申,等. 基于轻量化网络与注意力机制的育肥猪采食行为识别方法研究[J]. 南京农业大学学报, 2023, 46(4): 802-812. DOI: 10.7685/jnau.202208023.
Lu Z, Shen M X, Liu L S, et al. Study on feeding behavior recognition method of fattening pigs based on lightweight networks and attention mechanism[J]. Journal of Nanjing Agricultural University, 2023, 46(4): 802-812 (in Chinese with English abstract).
- [15] 张哲鼎,王超柱,陈骏,等. 基于YOLOX和DeepSORT的淡水鱼行为检测算法研究[J]. 智能化农业装备学报(中英文), 2025, 6(3): 88-97.
Zhang Z D, Wang C Z, Chen J, et al. Research on freshwater fish behavior detection algorithm based on YOLOX and DeepSORT[J]. Journal of Intelligent Agricultural Mechanization (in Chinese and English), 2025, 6(3): 88-97 (in Chinese with English abstract).
- [16] 何东健,刘建敏,熊虹婷,等. 基于改进YOLOv3模型的挤奶奶牛个体识别方法[J]. 农业机械学报, 2020, 51(4): 250-260.
He D J, Liu J M, Xiong H T, et al. Individual identification of dairy cows based on improved YOLOv3[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(4): 250-260 (in Chinese with English abstract).
- [17] Xu B B, Wang W S, Falzon G, et al. Automated cattle counting using Mask R-CNN in quadcopter vision system[J]. Computers and Electronics in Agriculture, 2020, 171: 105300.
- [18] 薛月菊,朱勋沐,郑婵,等. 基于改进Faster R-CNN识别深度视频图像哺乳母猪姿态[J]. 农业工程学报, 2018, 34(9): 189-196.
Xue Y J, Zhu X M, Zheng C, et al. Lactating sow postures recognition from depth image of videos based on improved Faster R-CNN[J]. Transactions of the Chinese Society of Agricultural Engineering, 2018, 34(9): 189-196 (in Chinese with English abstract).
- [19] Zheng C, Zhu X M, Yang X F, et al. Automatic recognition of lactating sow postures from depth images by deep learning detector[J]. Computers and Electronics in Agriculture, 2018, 147: 51-63.
- [20] 徐彦威,李军,董元方,等. YOLO系列目标检测算法综述[J]. 计算机科学与探索, 2024, 18(9): 2221-2238.
Xu Y W, Li J, Dong Y F, et al. Survey of development of YOLO object detection algorithms[J]. Journal of Frontiers of Computer Science and Technology, 2024, 18(9): 2221-2238 (in Chinese with English abstract).
- [21] Huang Z C, Wang J L, Fu X S, et al. DC-SPP-YOLO: dense connection and spatial pyramid pooling based YOLO for object detection[J]. Information Sciences, 2020, 522: 241-258.
- [22] Singh D, Kumar V, Kaur M. Densely connected convolutional networks-based COVID-19 screening model[J]. Applied Intelligence, 2021, 51(5): 3044-3051.
- [23] 庄前伟,王志明,吴龙貽,等. 基于改进SOLOv2的穴盘幼苗图像分割方法[J]. 南京农业大学学报, 2023, 46(1): 200-209. DOI: 10.7685/jnau.202203024.
Zhuang Q W, Wang Z M, Wu L Y, et al. Image segmentation method of plug seedlings based on improved SOLOv2[J]. Journal of Nanjing Agricultural University, 2023, 46(1): 200-209 (in Chinese with English abstract).
- [24] 邱天衡,王玲,王鹏,等. 基于改进YOLOv5的目标检测算法研究[J]. 计算机工程与应用, 2022, 58(13): 63-73.
Qiu T H, Wang L, Wang P, et al. Research on object detection algorithm based on improved YOLOv5[J]. Computer Engineering and Applications, 2022, 58(13): 63-73 (in Chinese with English abstract).
- [25] Ji S J, Ling Q H, Han F. An improved algorithm for small object detection based on YOLOv4 and multi-scale contextual information[J]. Computers and Electrical Engineering, 2023, 105: 108490.