doi:10.6041/j.issn.1000-1298.2026.07.031

基于 HG2 - ECA - M - YOLO v8n 的奶牛产前行为识别方法

王　娟[1,2]　付鑫培[1]　梁姿佳[1]　张　弛[1]

(1.河北农业大学机电工程学院, 保定 071001;
2.河北省畜禽养殖智能装备与新能源利用重点实验室, 保定 071001)

摘要: 奶牛产前行为的精准监测和及时干预,对保障奶牛健康、提升繁殖效率、提高养殖效益等具有重要价值。翘尾、塌陷等奶牛产前行为,存在目标偏小、特征重叠等问题,受复杂环境因素干扰,识别难度大、易出现混淆。为实现复杂牛舍环境下奶牛产前行为的快速准确识别,本研究提出了一种基于改进 YOLO v8n 的奶牛产前行为识别方法,主干网络采用改进的 HGNet V2,在 Head 部分的 C2f 模块后引入轻量级 ECA(Efficient channel attention)注意力模块,采用 MPDIoU Loss(Minimum penalty distance IoU loss)替换 CIoU(Complete intersection over union loss)损失函数。通过上述改进措施增强了对特定行为的聚焦能力、减少计算量并优化定位与分类,显著提升了模型在复杂牛舍环境中对翘尾和塌陷等行为的识别准确率、鲁棒性与检测速度。在自建数据集上开展对比实验,与基线模型相比,改进模型对 4 种产前行为识别的平均检测精度 mAP@0.5(Mean average precision)达到 92.9%,提高了 1.6 个百分点;翘尾和塌陷行为的平均精度(Average precision,AP)分别提高了 5.6、1.7 个百分点,降低了模型对两种行为的混淆程度;与 Faster R - CNN、SSD、EfficientDet、DETR、YOLO v5n、YOLO v7 - tiny、YOLO v10n、YOLO 11s 和 YOLO 12s 等模型相比,改进模型的 mAP@0.5 分别提高了 9.6、10.5、10.9、6.5、3.0、2.8、1.0、1.0、1.1 个百分点。本研究所构建的模型展现出较强的鲁棒性,能够在复杂的养殖环境以及全天候条件下,实现对奶牛产前行为的精确识别。

关键词: 奶牛;产前行为识别;注意力机制;YOLO v8n;HGNet V2;MPDIoU Loss

中图分类号: TP391.4　　**文献标识码**: A　　**文章编号**: 1000-1298(2026)07-0337-13　　**OSID**:

Prepartum Behavior Recognition in Dairy Cows Using HG2 - ECA - M - YOLO v8n

WANG Juan[1,2]　FU Xinpei[1]　LIANG Zijia[1]　ZHANG Chi[1]

(1. *College of Mechanical and Electrical Engineering*, *Hebei Agricultural University*, *Baoding* 071001, *China*
2. *Hebei Key Laboratory of Intelligent Equipment and New Energy Utilization of Livestock and Poultry Breeding*, *Baoding* 071001, *China*)

Abstract: Accurate monitoring and timely intervention of dairy cows' prepartum behavior are of great value for safeguarding the health of dairy cows, enhancing reproductive efficiency, and improving breeding productivity. However, prepartum behaviors such as tail warping and pelvic relaxation are characterized by small target sizes and overlapping features; they are also highly susceptible to interference from environmental factors (e.g., complex backgrounds and illumination variations), which often leads to misrecognition. To achieve rapid and accurate identification of dairy cows' prepartum behavior in complex barn environment, a prepartum behavior recognition method was proposed based on improved YOLO v8n. Firstly, an optimized HGNet V2 model was integrated to enhance the model's target recognition performance in complex barn scenarios. This optimization not only improved the accuracy and robustness of target recognition, but also maintained high inference speed. Secondly, a lightweight efficient channel attention (ECA) module was introduced after the C2f module in the model's head section. This module strengthened the model's ability to focus on behavior-specific features while reducing computational overhead, thereby balancing the model's performance and computational efficiency.

收稿日期: 2025 - 08 - 12　修回日期: 2025 - 10 - 29

基金项目: 河北省重点研发计划项目(19227213D)和河北省研究生课程思政示范项目(YKCSZ2026023)

作者简介: 王娟(1981—),女,副教授,博士,主要从事图像处理与模式识别研究,E-mail: wangjuan@hebau.edu.cn

Finally, the MPDIoU Loss function was adopted to replace the CIoU loss function. By enabling precise bounding box localization and incorporating classification probability into loss calculation, this replacement significantly improved the model's detection accuracy and category discrimination capability for tail warping and pelvic relaxation behaviors in complex barn environments. Experimental results showed that compared with the baseline YOLO v8n model, the improved model achieved a mean average precision (mAP@0.5) of 92.9% for the recognition of the four prepartum behaviors-representing an increase of 1.6 percentage points. Specifically, the average precision (AP) for tail warping and pelvic relaxation behaviors was increased by 5.6 and 1.7 percentage points, respectively, effectively reducing confusion between the two similar behaviors. When compared with other mainstream detection models (Faster R-CNN, SSD, EfficientDet, DETR, YOLO v5n, YOLO v7-tiny, YOLO v10n, YOLO 11s and YOLO 12s), the improved model's mAP@0.5 was enhanced by 9.6, 10.5, 10.9, 6.5, 3.0, 2.8, 1.0, 1.0 and 1.1 percentage points, respectively. In conclusion, the model constructed exhibited strong robustness, enabling accurate identification of dairy cows' prepartum behaviors under dynamic and complex breeding environments as well as all-weather conditions.

Key words: cow; prepartum behavior recognition; attention mechanism; YOLO v8n; HGNet V2; MPDIoU Loss

0 引言

奶牛是我国重要的畜禽养殖品种,其健康状况对牛奶品质有重要意义,因此需要实时监测其健康状况[1-3]。奶牛行为是其内部生理变化或对外部环境刺激做出的反应,直接或间接地反映奶牛的健康状况。奶牛产前行为具有明显的特征,躺卧、臀部塌陷(骨盆韧带松弛)、翘尾和回望等行为是奶牛分娩前的典型信号。准确识别这些行为至关重要,能够为接产准备提供宝贵的时间、减少分娩过程中的风险、提高犊牛的成活率。在畜牧业智能化转型的大背景下,智能化行为监测技术成为关键。智能监控系统、自动饲喂系统、环境控制系统等智能化设备的应用,大大提高了畜牧业的生产效率和管理水平[4-6]。

目前,产前行为识别研究正经历着从接触式到非接触式的变革。早期研究多采用穿戴设备,如项圈和加速度传感器,实时监测奶牛的运动和生理数据[7-12]。接触式识别虽能实现姿态的精准识别,但在复杂行为预测上表现不佳,且因动物应激、成本高、行为覆盖局限及环境脆弱性,逐渐被非接触式方法替代。基于计算机视觉的非接触式技术通过深度学习处理视频图像,以无侵入、非接触、高效的方式提供实时行为监测,助力动物福利提升、疾病预防及养殖管理优化[13-14]。初期的研究重点在于验证视觉技术识别基础行为的可行性[15-16],随着研究的深入,焦点转向如何提升模型在真实养殖场景中的性能,主要体现在 2 个层面:①模型轻量化[17-18]。②提高复杂场景下的多尺度行为识别能力[19-20]。

当前,奶牛产前行为识别面临多维度技术瓶颈,主要表现在环境干扰对视频分析检测效果的影响。不同养殖环境下的模型性能差异明显,个体生理特征的多样性导致行为预测存在系统性偏差,轻量化模型在算力优化与部署成本之间难以平衡,多模态融合系统的技术成熟度仍处于早期验证阶段。现有解决方案在复杂环境奶牛产前行为识别准确性、时序特征动态捕捉以及边缘计算设备适配性等方面存在不足,制约了技术的规模化应用进程。

针对上述问题,本文提出一种基于改进 YOLO v8n 的实际养殖环境下奶牛产前行为识别方法。首先,将 YOLO v8n 的主干网络替换成 HGNet V2 增强初始响应特征,有效捕捉牛群动态行为,提高在复杂光照场景下特征提取的完整度。其次,融合 ECA 注意力机制提高牛体姿态识别准确率,提升小目标识别的检测召回率。最后,引入 MPDIoU Loss 进一步提高行为识别的准确性和区分度。该方法在考虑复杂光照场景的同时,对模型进行轻量化改进,以期实现可视化系统边缘部署。

1 材料与方法

1.1 图像采集

本研究视频采集于河北省石家庄市无极县某奶牛养殖场(38°17′N,114°92′E)。摄像头安装于围栏西南角,图像分辨率为 1 920 像素 × 1 080 像素,帧率为 30 f/s,视频保存格式为 MP4。共选取了 2023 年 4—5 月不同时段视频 56 段,牛只 5 头,包含了白天、夜晚等场景。奶牛产前行为包含躺卧、臀部塌陷、翘尾和回望等。

1.2 数据预处理

利用视频分帧技术将采集的 56 段视频分帧,每隔 30 帧抽取 1 幅图像,以 jpg 格式保存。去除冗余后,共得到 7 221 幅图像,划分为训练集 6 140 幅、验

证集 731 幅和测试集 350 幅，作为本文行为识别数据集。采用 LabelImg 人工标注图像中的躺卧、翘尾、回望和塌陷等 4 种行为。表 1 所示为奶牛产前行为判定标准和数据集信息。

表 1　奶牛产前行为判定标准和数据集信息

Tab. 1　Prepartum behavior assessment criteria and dataset information for dairy cows

行为类别	行为描述	数量	标签
躺卧	奶牛分娩前频繁起卧的举动	1 438	wo
翘尾	由于胎儿压迫子宫，奶牛不自觉地将尾巴抬起的一种生理反应	1 429	qiaowei
回望	奶牛分娩前频繁回头望向自身腹部或后躯的动作	2 383	huiwang
塌陷	由于胎儿重量以及宫缩的影响，奶牛后躯或臀部肌肉松弛、下沉的一种现象	1 971	taxian

数据集构建过程中综合考虑了行为多样性和光照变化因素，采集了涵盖不同光照条件下奶牛产前多种行为的图像数据，应对实际生产中可能遇到的光照变化，提高模型的泛化能力和鲁棒性。

为了进一步丰富训练样本的多样性，本研究对现有数据集实施了 Mosaic 处理[21]。通过分辨率下采样（0.33 倍率）实现小目标等效放大：将原始 1080P 图像中小于 32 像素的小目标（如翘尾、塌陷等特征），在下采样后的 360P 图像中提升至等效 64 像素的检测尺度，从而优化小目标的识别效果。实验表明该策略可使小目标特征响应强度提升 2.3 倍，分辨率降低使模型推理速度提升 62.2%，计算量减少 88.9%，小目标（如翘尾、塌陷等特征）平均精度（Average precision，AP）提高 1.3%，Mosaic 增强前后对比结果如表 2 所示。

表 2　Mosaic 增强效果对比

Tab. 2　Mosaic enhancement effect comparison

模式	指标		
	推理速度/（f·s^{-1}）	计算量	小目标（小于 32 像素）AP/%
1080P	31.15	3.15×10^{9}	81.95
360P	50.51	3.50×10^{8}	83.05
改善幅度/%	62.2	88.9	1.3

2　奶牛产前行为识别方法

奶牛产前行为识别的关键在于对非刚性形变剧烈、关键特征细微、行为状态模糊且环境干扰复杂的场景，如何精准捕捉局部动态变化、区分过渡状态并保持鲁棒性。

本研究将基线模型 YOLO v8n[22－24] 的主干网络替换成 HGNet V2，并在 Head 部分融合了 ECA 注意力机制，最后，采用 MPDIoU Loss 替换 CIoU 损失函数。改进模型命名为 HG2－ECA－M－YOLO v8n，结构如图 1 所示。将预处理后的图像输入以 HGNet V2 为核心的主干网络，该网络通过下采样与上采样交替操作，高效提取多尺度特征并扩大感受野，有效应对奶牛的非刚性形变。在特征提取过程中，引入 ECA 注意力机制，自适应增强与特定行为相关的重要通道响应（如翘尾行为强化尾部通道，塌陷行为

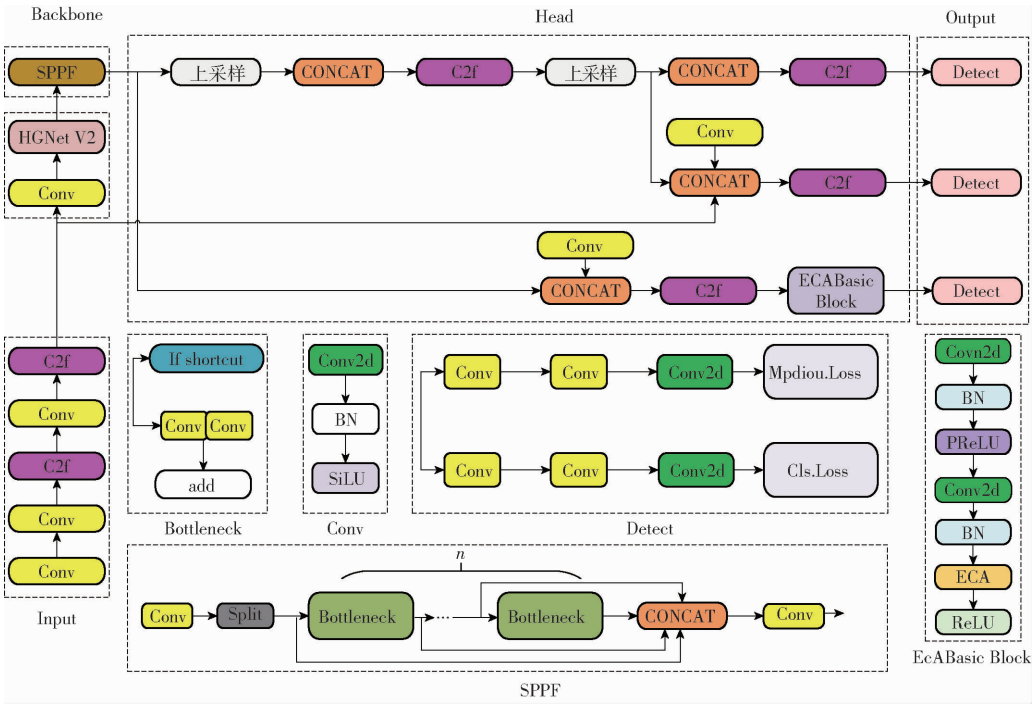


图 1　HG2－ECA－M－YOLO v8n 模型结构图

Fig. 1　HG2－ECA－M－YOLO v8n model architecture diagram

强化躯干通道),同时抑制无关信息干扰,提升特征的判别性。增强后的特征经 PAN-FPN 结构进行多尺度融合,再由解耦检测头分别完成分类与定位任务。最终,采用 MPDIoU 损失函数优化边界框回归,使检测框在位置和形态上更贴合目标。该方法实现了特征增强与定位优化的有效协同,显著提升了产前行为识别的准确性与可量化性。

2.1 HGNet V2 主干网络

牛舍环境复杂易形成严重遮挡,加之雨雪风沙等恶劣天气导致的摄像头模糊、晃动等,增加了图像的干扰信息,削弱了卷积神经网络对牛只特征的识别能力。同时,模型复杂度的提升进一步加剧了计算资源消耗,并增加了过拟合风险。

HGNet V2[25-26]是百度团队自研的高性能骨干网络,旨在优化 GPU 平台上的性能,其主干网络结构如图 2 所示。

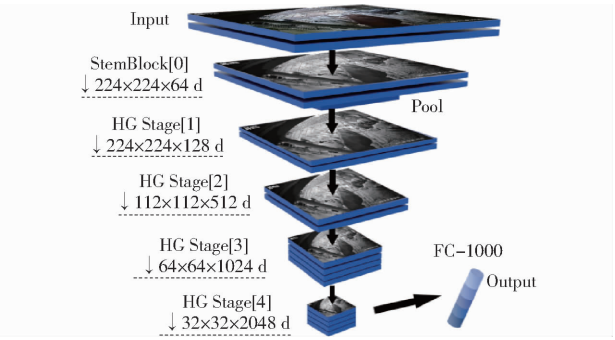


图 2 HGNet V2 主干网络结构图

Fig. 2 Structure diagram of HGNet V2 backbone network

相较于 HGNet V1,HGNet V2 通过 StemBlock 和多个 HG Stage 进行特征提取和降维,逐步细化特征并增加深度(神经网络层数),最终通过全连接层输出 1 000 个类别的分类结果。该网络结构采用改进的层次图块设计以更好地处理多尺度特征,引入计算效率更高的 LDS(Learnable down-sampling)层降低计算复杂度和参数量。同时,改进特征融合模块以提升检测精度。

HGNet V2 核心架构分为两部分:

(1)核心模块采用改进的 CSP(Cross stage partial)结构,通过浅层卷积链替代传统深度卷积,将特征图通道拆分为多个分支,分别处理后逐层融合。这种设计增强了多尺度特征表达能力,尤其适合识别动态行为(如翘尾的快速抬升、塌陷的缓慢下沉)。创新点包括 GhostConv 模块和 ResPath 残差路径。

GhostConv 模块通过并行分支能同时捕捉尾部抬起的动态轨迹(时序特征)和尾部与背部的角度变化(空间特征),避免因计算延迟导致动作漏检。将时序特征分支与空间特征分支的输出进行融合,所得结果即为 GhostConv 模块的最终输出。

融合时序特征与空间特征的奶牛翘尾及塌陷行为判别流程如图 3 所示。

ResPath 残差路径通过融合低层边缘特征(例如翘尾时的尾巴角度动态变化)与高层语义特征(例如身体姿态的类别判定),可以有效区分“正常摆尾”与“产前弓腰扭动”两类行为。同时,该路径进一步结合浅层纹理特征(例如尾根区域肌肉轮廓的模糊程度)与深层空间特征(例如塌陷区域相对于周围组织的空间位置关系),实现对尾根塌陷起始点的精准定位。上述双重作用能够显著提升奶牛产前行为识别的准确性与鲁棒性。

(2)多尺度特征金字塔:通过堆叠 CSP Ghost Module 构建密集特征金字塔,在浅层捕捉尾巴的摆

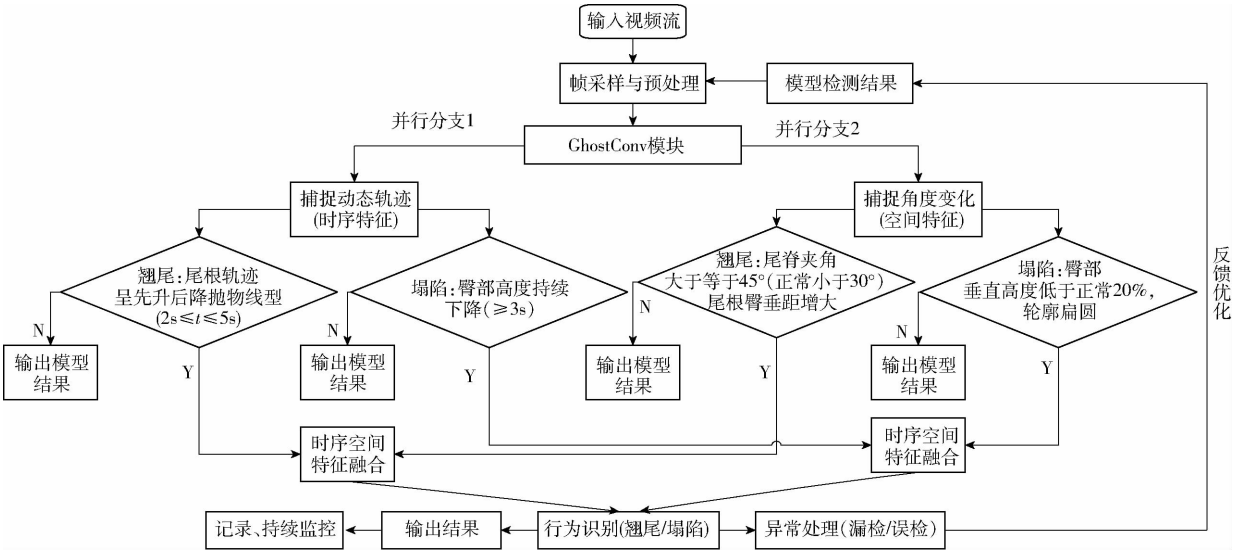


图 3 奶牛翘尾与塌陷行为判定流程图

Fig. 3 Flowchart for identification of tail raising and sinking behaviors in dairy cows

动角度变化，深层提取语义信息，结合身体姿态分类，区分正常摆尾与产前行为。通过多尺度融合，避免单一尺度特征导致的误判，数学表达式为

$$M_c = \sigma[\boldsymbol{W}_2 \mathrm{ReLU}(\boldsymbol{W}_1 \mathrm{GlobalAvgPool}(x))] \quad (1)$$

式中　M_c——通道注意力权重，每一个通道对应一个权重值，用于后续特征融合或加权，提升模型对关键通道特征的敏感度，避免单一尺度特征导致的误判

σ——Sigmoid 函数，对内部计算结果进行非线性变换，生成每个通道的权重，并将最终输出 M_c 压缩到(0,1)区间

$\boldsymbol{W}_1$——可学习权重矩阵，对全局平均池化后的特征进行线性变换

$\boldsymbol{W}_2$——可学习权重矩阵，对 ReLU 激活函数的输出进行线性变换，然后输入到 Sigmoid 函数中生成 (0,1)的权重

ReLU——激活函数，引入非线性，使模型增加学习复杂通道间的依赖关系，抑制负值特征并增强特征表达能力

GlobalAvgPool(x)——全局平均池化，对每个通道的特征图的空间维度取平均值，输出 $C \times 1 \times 1$，提取各通道全局统计特征

HGNet V2 在准确性、场景适应性、参数与计算量精简、训练稳定性及多任务学习支持等方面均取得显著突破。其基准测试性能稳居领先水平，不仅支持多模态输入，更在轻量化设计与高效训练之间达成出色平衡，尤其适用于资源受限场景的部署需求。针对复杂牛舍环境中目标密集、背景杂乱、遮挡严重以及图像质量差等问题，本研究将 YOLO v8n 网络的主干网络替换为 HGNet V2。HGNet V2 以高效的混合编码器结构，结合 CNN 和 Transformer 的优点，实现更强的特征提取能力，有效捕捉牛只细节信息，提高密集场景下的识别能力。其次，自适应特征融合模块动态整合不同尺度特征，丰富语义信息，减少遮挡影响。此外，HGNet V2 的抗干扰能力和多尺度特征融合能够增强算法的鲁棒性，即使在恶劣天气下也能保持较高检测精度。HGNet V2 采用高效编码与压缩技术加速检测，能够满足实时监控需求，实现速度与能效双优。综上所述，HGNet V2 的集成能够提高 YOLO v8n 在复杂牛舍环境中目标检测的准确性，提升模型的鲁棒性以及检测速度。

2.2　MPDIoU Loss 损失函数

YOLO v8n 的损失函数 CIoU 通过动态权重调节实现多任务平衡与样本均衡，量化误差优化参数，同步提升检测精度与泛化能力。CIoU 默认用于边框回归，通过宽高比度量位置偏差，但忽略了方向对齐性，导致角度校准不足，因此本文引入 MPDIoU Loss 作为检测框回归损失函数[27]。

DIoU Loss(Distance - IoU Loss)在目标检测中用于优化锚框和真实框之间的定位精度。MPDIoU Loss 作为 DIoU Loss 的改进版本，是一款高效的目标检测损失函数，融合了交并比(IoU)、中心点距离及长宽比差异三大核心维度的考量，在锚框回归任务中实现了精度与效率的双重突破，不仅能显著提升定位精度，更可加快模型收敛速度，为目标检测任务提供了更优的损失优化方案。高定位精度的实现，源于对目标中心点距离与长宽比的精准建模；而快速收敛特性，则得益于其直接优化锚框与真实框几何关系的设计对模型优化过程的大幅简化。此外，MPDIoU Loss 对不同尺度目标具有优异的鲁棒性，能从容应对目标尺度变化带来的挑战。

奶牛的翘尾、塌陷行为发生时，其身体轮廓会发生显著变化。对于翘尾(对应高窄形态预测框)与塌陷(对应宽扁形态预测框)这类长宽比存在极端差异的目标，MPDIoU Loss 的 v 值会呈现极大数值，进而导致总损失 L_{MPDIoU} 急剧升高。该损失变化会向模型传递强烈且明确的梯度信号，驱动模型快速调整预测框的宽高参数，促使预测框形状与奶牛行为发生时的真实身体姿态精准匹配。对需要精细分析局部部位的行为，如翘尾角度的量化判定、塌陷深度的精准测算，能够提升识别精度。

数据集中翘尾与塌陷 2 种行为存在特征重叠，易导致模型区分困难。针对这一问题，MPDIoU Loss 函数通过最小化边界框顶点距离(替代传统区域重叠计算)，确保目标非重叠时仍能保持有效梯度；同时引入分类概率感知机制，优化复杂样本的区分能力。这一方案有效降低了因定位误差引发的翘尾行为误判，以及因类别区分不足导致的塌陷行为混淆，显著提升了模型在目标检测任务中的定位精度与类别辨识能力。与 CIoU Loss 相比，MPDIoU Loss 的核心改进在于将惩罚项从对中心点距离与长宽比偏差的考量，扩展为对预测框与真实框 4 个顶点不重合程度的量化约束。通过计算顶点距离平方和实现惩罚机制，对边界框的形状与位置实现更精细的优化调控，显著提升边界框的紧致度，有效减少因不规则凸起(如翘尾)导致的背景包含现象，极大地提升对非刚性、剧烈形变目标(如塌陷)的定位精度。归一化顶点距离 d_{vertex} 计算式为

$$d_{\mathrm{vertex}} = \sum_{i=1}^{4} \| \boldsymbol{V}_p^{(i)} - \boldsymbol{V}_t^{(i)} \|^2 \quad (2)$$

其中 $\boldsymbol{V}^{(1)}=(x-w/2,y-h/2)$

$\boldsymbol{V}^{(2)}=(x+w/2,y-h/2)$

$\boldsymbol{V}^{(3)}=(x+w/2,y+h/2)$

$\boldsymbol{V}^{(4)}=(x-w/2,y+h/2)$

式中 $\boldsymbol{V}_p^{(i)}$——预测四边形的第 i 个顶点向量

$\boldsymbol{V}_t^{(i)}$——真实四边形的第 i 个顶点向量

$\|\boldsymbol{V}_p^{(i)}-\boldsymbol{V}_t^{(i)}\|^2$——预测顶点与真实顶点之间欧氏距离的平方

i——顶点标号

x、y——预测或真实边界框的中心横、纵坐标

w、h——边界框的宽度、高度

同时，为消除尺度影响，通过将分类概率融入定位损失 L_{joint} 的设计，可针对性增强复杂样本（如翘尾与塌陷）的区分度，进而有效减少模型训练的迭代次数。计算式为

$$L_{\text{joint}}=\lambda_1 D+\lambda_2(1-p_j) \tag{3}$$

式中 λ_1——调整距离度量的权重

λ_2——调整概率相关项 $(1-p_j)$ 的权重

D——距离度量，即预测值与真实值之差

p_j——预测框对真实类别 j 的概率

MPDIoU Loss 通过顶点距离惩罚项细化为对中心点位置、宽度和高度这 3 个关键维度的独立惩罚。对翘尾行为，通过高度和宽度惩罚，有效抑制因不规则凸起导致的背景包含现象，生成更紧致的主体框；对塌陷行为，通过高度惩罚，精确捕捉剧烈的形变，确保预测框高度的准确性。MPDIoU Loss 解决了传统损失在遮挡、小目标和相似类别场景下的缺陷，为复杂环境中的目标检测提供了更优的梯度特性。计算式为

$$L_{\text{MPDIoU}}=1-IoU+\frac{\rho^2(d)}{l^2}+\alpha\frac{\rho^2(\Delta w)}{l^2}+\beta\frac{\rho^2(\Delta h)}{l^2} \tag{4}$$

式中 IoU——锚框和真实框之间的交并比

d——锚框和真实框中心点之间的欧几里得距离

l——锚框和真实框最小闭包矩形的对角线长度

Δw——锚框宽度与真实框宽度的差值，表征水平方向上的不匹配度

Δh——锚框高度与真实框高度的差值，表征垂直方向上的不匹配度

$\rho^2(\cdot)$——用于平滑处理的函数，通常可以是一个简单的平方函数

α、β——用于调整宽度和高度差异权重的超参数

对于小目标，边界框的微小偏移可能导致 IoU 显著下降，较大的 α 和 β 取值既能确保模型在训练过程中更加聚焦于边界框的精确回归、提高定位精度，又能避免因参数值过大导致模型不稳定或过拟合问题。为了提升模型对小目标的检测性能，本实验选取 $\alpha=0.6$，$\beta=0.6$。

2.3 ECA 注意力机制

基于 YOLO v8n 模型，在 Head 部分的 C2f 模块后引入 ECA 注意力机制[28-30]，通过查询自适应方式精准聚焦翘尾、塌陷 2 类特定行为特征，同时剔除其他非关键标记干扰。这一设计在确保性能提升的同时，兼顾了计算效率的优化，实现了精准性与轻量化的协同提升。在图 1 中 ECA 模块前加入 Conv2d 承担特征提取与细化的双重作用；而 BN（BatchNorm2d）与 PReLU 激活函数的协同配合，通过标准化特征处理并增强非线性表达能力，有效优化了模型的训练过程与整体表现；同时，PReLU 凭借学习细粒度的特征差异、提升模型泛化能力、增强网络鲁棒性以及适应多样化数据分布等特性，在行为识别任务中，能够显著提高对相似行为的识别准确度，并降低模型过拟合的风险。

在 C2f 模块之后接入 ECA 模块，其目的在于借助轻量级通道注意力模块，有效提升网络的表征能力。图 4 展示了 ECA 注意力模块的结构。

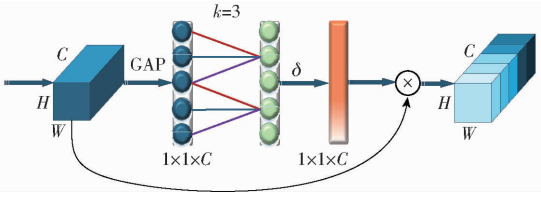


图 4 ECA 注意力模块

Fig. 4 ECA attention module

首先，通过全局平均池化对输入特征图进行空间信息压缩，为每个通道生成一个标量值以保留全局分布信息。与传统 1×1 卷积不同，ECA 模块采用大小为 k 的滑动窗口进行局部跨通道交互，通过一个简单的全连接层（即 k 大小的卷积核）快速生成权重，有效避免了参数冗余。随后，这些权重经 Sigmoid 激活函数归一化至 0 和 1 之间，以此重新校准各通道的重要性。最终，激活后的权重逐通道与原始特征图相乘，通过调整特征响应强化关键特征并抑制次要特征，从而在保持轻量级特性的同时，有效升网络性能。k 的计算式为

$$k=\left[\frac{\text{lb}C}{\beta_0}+\frac{b}{\beta_0}\right]_{\text{odd}} \tag{5}$$

式中 C——输入特征图的通道数

$[\cdot]_{\text{odd}}$——取最近奇整数操作符

β_0——缩放因子，取 2

b——偏移量，取 1

ECA 注意力机制凭借轻量化的通道交互（参数量不足 10^3）和动态化的特征增强（通道权重调整精度高达 0.01），在小目标检测任务中巧妙地平衡了精度与效率。

2.4　实验平台与评价指标

本实验在 Windows 10 系统环境下进行，编程平台为 VS Code，编程语言为 Python 3.8，深度学习框架为 Pytorch 1.11.0。硬件环境为 Intel－酷睿 i7－11700 处理器、24 GB 内存、NVIDIA GeForce RTX 4080 显卡。

将标注的奶牛产前行为图像输入 HG2－ECA－M－YOLO v8n 目标检测网络，输入图像尺寸为 640 像素×640 像素，图像批量大小为 8，初始学习率为 0.01，学习率衰减因子为 0.01，权重衰减为 0.000 5，防止过拟合。采用随机梯度下降作为优化器。采用动态验证频率机制平衡计算效率与模型监控需求，具体机制如下：初始阶段（0～50 个训练轮次）每 100 步（即 0.25 个训练轮次）验证 1 次，共验证 200 次，重点监控模型快速学习情况和梯度爆炸风险；中期阶段（50～150 个训练轮次）每 200 步（即 0.5 个训练轮次）验证 1 次，共验证 200 次，监控模型收敛状态和学习率调整效果；后期阶段（150～200 个训练轮次）每 300 步（即 0.75 个训练轮次）验证 1 次，共验证 66 次，关注模型过拟合风险和最终性能优化。此方法能有效减少验证计算开销，同时保证对模型训练各阶段的充分监控。模型训练 200 轮次，在保证收敛的前提下，对数据集进行评价。

本研究采用精确率（Precision，P）、召回率（Recall，R）、平均精度 AP、平均精度均值 mAP、参数量、计算量（GFLOPs）、F1 分数和帧率作为评价指标衡量模型性能。P、R、AP、mAP 越高，目标检测识别越准确。

3　实验与结果分析

3.1　产前行为识别检测实验与结果分析

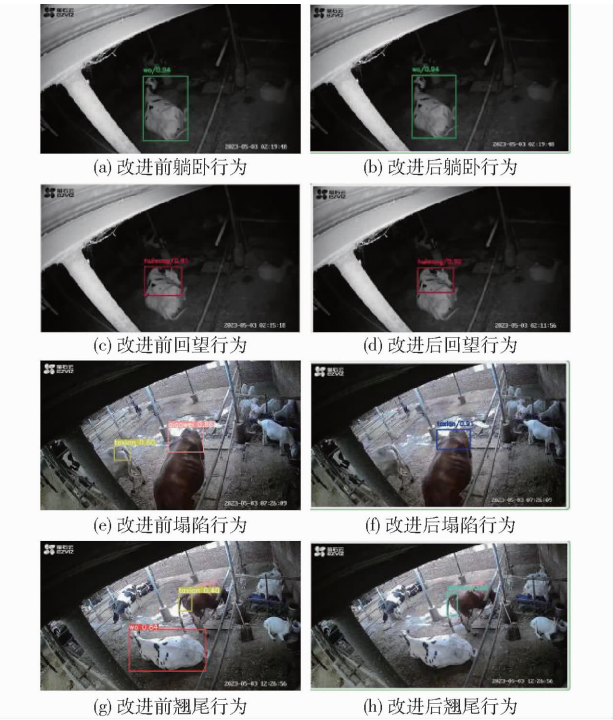
为了验证本文提出的 HG2－ECA－M－YOLO v8n 模型在奶牛产前 4 种行为（躺卧、翘尾、回望、塌陷）识别任务中的优越性，将其与基线模型 YOLO v8n 进行对比实验，结果如表 3 所示。

由表 3 可知，与基线模型 YOLO v8n 相比，改进模型 HG2－ECA－M－YOLO v8n 识别翘尾和塌陷行为的 AP 显著优异，分别提升了 5.6、1.7 个百分点；识别躺卧和回望行为的 mAP@0.5 略有降低，分别下降 0.6、0.1 个百分点。相关识别效果对比如图 5 所示。

表 3　奶牛产前行为识别对比结果

Tab.3　Cow prepartum behavior recognition comparison results

行为类别	数量	mAP@0.5/%	
		HG2－ECA－M－YOLO v8n	YOLO v8n
躺卧	1 438	98.8	99.4
翘尾	1 429	84.1	78.5
回望	2 883	99.3	99.4
塌陷	1 971	89.3	87.6
全部行为	7 721	92.9	91.3



(a) 改进前躺卧行为　(b) 改进后躺卧行为
(c) 改进前回望行为　(d) 改进后回望行为
(e) 改进前塌陷行为　(f) 改进后塌陷行为
(g) 改进前翘尾行为　(h) 改进后翘尾行为

图 5　改进前后识别效果对比

Fig.5　Comparison of recognition effectiveness before and after improvement

奶牛产前翘尾与塌陷行为，尾部形态的变化十分细微，空间特征相似度高，且在远距离监控场景下目标尺度较小，这使得基线模型容易出现类别混淆的问题。通过引入 ECA 模块动态调整通道权重，模型得以强化尾部区域与躯干塌陷区域的局部特征响应。ECA 模块提升了模型对尾部边缘和塌陷姿态的激活强度，能够有效区分空间分布相似但时序特征存在差异的行为。而基线模型 YOLO v8n 的主干网络对小目标（如塌陷时的局部躯干形变）特征提取能力不足，容易造成细节信息的丢失。HGNet V2 通过引入跨阶段密集连接，有效增强了浅层特征（高分辨率、低语义）与深层特征（低分辨率、高语义）的融合效率，显著提升了小目标检测 AP 值。CIoU 损失对边界框中心点偏移较为敏感，而翘尾行为中尾部的摆动会导致边界框产生抖动，进一步加剧定位偏差。MPDIoU 通过解耦边界框的中心点与宽高优化，有效

降低了对动态目标的敏感度。在翘尾行为测试集上，改进后的边界框定位误差显著降低，减少了因定位偏差导致的误分类问题。

躺卧与回望 2 种行为精度下降的原因主要有：①ECA 模块在强化对小目标和复杂特征关注的同时，削弱了对全局显性特征（如卧姿的整体轮廓）的建模能力。②HGNet V2 的轻量化压缩处理，因参数量减少导致部分冗余特征的表达能力受损，使得模型对高精度场景中微特征（如回望行为的头部姿态）的敏感度降低。③为提升模型在复杂场景中的鲁棒性，训练过程中增加了遮挡与运动模糊的数据增强操作，这可能对静态行为卧姿的纹理特征学习产生干扰。

综上所述，改进模型通过特征聚焦、多尺度融合与定位优化，针对性地解决了小目标及相似行为的识别难题，尽管在躺卧和回望 2 种行为识别上存在一定性能下降，但整体而言，显著提升了模型在复杂场景下的实用价值。

3.2 消融实验

3.2.1 模型改进对比

改进的 HG2 - ECA - M - YOLO v8n 模型优化了主干网络、加入了注意力机制，引入了新的损失函数。为了验证本文改进方法在奶牛产前行为识别任务中的有效性，设计了消融实验验证改进效果，对比结果如表 4 所示。

表 4 消融实验结果对比

Tab. 4 Comparison of ablation experimental results

%

实验编号	ECA	HGNet V2	MPDIoU Loss	P	R	mAP@0.5	AP	
							翘尾	塌陷
1	×	×	×	89.2	90.4	91.3	78.5	87.6
2	√	×	×	87.8	88.8	90.7	79.1	88.1
3	×	√	×	87.6	90.4	91.8	80.5	88.4
4	×	×	√	88.2	89.7	91.4	78.8	88.5
5	√	√	×	90.3	89.8	91.9	80.1	89.1
6	√	×	√	88.9	90.1	91.1	78.1	87.5
7	√	√	√	88.9	91.2	92.9	84.1	89.3

注：√表示进行此种改进，×表示未进行此种改进。

由表 4 可知，ECA 注意力机制使翘尾行为的 AP 提升了 1.6 个百分点，塌陷行为提升了 0.5 个百分点，表明其更适配局部动态目标。经混淆矩阵定量分析，ECA 将翘尾识别为塌陷的误分类率从 14.7% 降至 7.4%；将塌陷识别为翘尾的误分类率从 12.4% 降至 8.1%。分析原因在于 ECA 注意力机制通过捕捉通道间的相互关系，动态调整各通道的特征响应，使模型能够更加聚焦于信息量丰富的核心特征，同时抑制次要特征。对于翘尾和塌陷这 2 种具有相似性却又存在本质差异的行为，ECA 注意力机制可增强模型对关键特征的关注度，进而在特征层面提升模型对二者的区分能力。

HGNet V2 通过部署密集跨层连接机制，显著增强了网络对躯干形变特征的高阶抽象能力；同时其采用深度可分离卷积技术优化特征提取流程，有效减少了参数量和计算成本。在替换原有主干网络后，HGNet V2 凭借其独特的多尺度特征融合模块及层次化特征金字塔网络结构，强化了模型对细粒度行为模式的感知能力，提升了翘尾与塌陷行为的识别精度，其中翘尾行为的识别平均精度提升了 2.0 个百分点。

采用 MPDIoU Loss 损失函数替换 CIoU 损失函数，有效解决了塌陷行为因边界框抖动引发的定位敏感问题，使塌陷行为识别的平均精度提升了 0.9 个百分点。

通过将 ECA 注意力机制与 HGNet V2 相结合，模型进一步聚焦局部行为关键区域的特征，整体识别效率与鲁棒性均得到提升。在此基础上，引入 MPDIoU Loss 损失函数，该损失函数通过最小化预测框与真实框在相同长宽比条件下的点距离偏差，有效解决了边界框宽高值不一致导致的定位误差问题，最终构成本文改进模型。HG2 - ECA - M - YOLO v8n 模型在翘尾与塌陷行为的识别精度上分别提升 5.6、1.7 个百分点，表明所采用的优化策略有效增强了模型对二者的区分能力，成功解决了基线模型中两类行为易混淆的问题，显著提高了整体识别精度。

3.2.2 注意力机制横向对比实验

为了验证引入注意力机制在提升小目标检测能力及增强类别区分度方面的有效性，本研究分别基于 ECA、卷积块注意力模块（Convolutional block attention module，CBAM）、相似性注意力模块（Similarity-aware activation module，SimAM）等 3 种注意力机制对 YOLO v8n 网络进行改进。改进后模型均训练 150 轮次，随后对 3 种注意力机制的性能展开评估，对比结果如表 5 所示。

由表 5 可知，与 HG2 - CBAM - M - YOLO v8n 相比，HG2 - ECA - M - YOLO v8n 的精确率、召回率、mAP@0.5 分别提高了 1.5、2.3、1.3 个百分点；与 HG2 - SimAM - M - YOLO v8n 进行对比，HG2 - ECA - M - YOLO v8n 精确率、召回率、mAP@0.5 分别提高了 0.6、0.9、1.3 个百分点；3 种模型相比，HG2 - ECA - M - YOLO v8n 在翘尾与塌陷 2 种行为的区分性能上表现最优。

表 5　注意力机制横向对比结果

Tab. 5　Comparative results of attention mechanisms　%

模型	P	R	mAP@0.5	AP			
				躺卧	翘尾	回望	塌陷
HG2 - CBAM - M - YOLO v8n	87.4	88.9	91.6	99.3	79.3	99.4	88.3
HG2 - SimAM - M - YOLO v8n	88.3	90.3	91.6	99.0	79.9	99.5	87.9
HG2 - ECA - M - YOLO v8n	88.9	91.2	92.9	98.8	84.1	99.3	89.3

由上述分析可见，3 种注意力机制均能提升改进模型的性能，其中 ECA 注意力机制的综合性能较 CBAM、SimAM 更为显著。尤其在小目标检测任务中，对于因特征重叠引发的分类难题，ECA 注意力机制采用 1D 卷积替代传统全连接层，通过自适应学习通道权重，高效捕捉通道间的依赖关系。相比 CBAM，ECA 无需额外空间注意力计算，大幅降低计算量，同时保持对局部细微特征（如翘尾时尾部边缘的摆动轨迹、塌陷时躯干形变的纹理变化）的敏感度；相比 SimAM，ECA 的 1D 卷积更擅长捕捉线性相关的通道特征，而奶牛行为的细微差异，如翘尾的周期性摆动与塌陷的持续性下垂这 2 种动态行为依赖通道间的线性特征关联。奶牛产前翘尾与塌陷的空间特征高度重叠，2 种行为的尾部曲率差异小于 0.12，且目标尺度微小。ECA 注意力机制通过动态强化关键通道（如尾部边缘、躯干塌陷区域）的特征响应，使模型在细微形态差异下，仍能有效区分时序特征中翘尾行为的摆动频率与因塌陷行为而导致的姿态失稳。而 CBAM 空间注意力分散资源和 SimAM 简化过度导致特征丢失，无法像 ECA 注意力机制一样保持全局优化能力。

3.3　不同模型对比实验结果分析

为进一步验证模型性能，选择 Faster R - CNN、SSD、EfficientDet、DETR、YOLO v5n、YOLO v7 - tiny、YOLO v10n、YOLO 11s、YOLO 12s 模型进行对比，结果如表 6 所示。

表 6　不同模型对比结果

Tab. 6　Comparison results of different models

模型	P/%	R/%	F1 分数	参数量	计算量	帧率/(f·s^{-1})	mAP@0.5/%	AP/%			
								躺卧	翘尾	回望	塌陷
Faster R - CNN	60.8	91.0	0.73	1.37×10^{8}	8.70×10^{9}	4.3	83.3	93.9	56.6	98.7	88.8
SSD	82.7	70.6	0.76	2.62×10^{7}	5.80×10^{9}	23.7	82.4	95.5	49.0	98.7	86.4
EfficientDet	84.9	77.5	0.81	6.6×10^{6}	1.37×10^{10}	45.3	82.0	95.4	51.3	99.1	82.3
DETR	87.7	83.1	0.83	4.13×10^{7}	8.65×10^{10}	33.5	86.4	96.1	64.3	99.4	86.4
YOLO v5n	84.0	88.6	0.86	6.31×10^{6}	4.50×10^{9}	64.9	89.9	97.8	74.6	99.2	88.0
YOLO v7 - tiny	88.3	88.5	0.88	6.22×10^{6}	1.32×10^{10}	10.6	90.1	99.0	74.9	99.5	87.1
YOLO v10n	88.5	89.3	0.89	2.77×10^{6}	6.80×10^{9}	102.3	91.9	99.1	80.8	99.3	88.2
YOLO 11s	87.9	90.4	0.89	9.45×10^{6}	2.13×10^{10}	19.8	91.9	99.3	79.6	99.4	89.1
YOLO 12s	88.4	89.9	0.89	9.23×10^{6}	2.12×10^{10}	10.4	91.8	99.5	79.1	99.3	89.2
HG2 - ECA - M - YOLO v8n	88.9	91.2	0.90	4.84×10^{6}	4.80×10^{9}	44.4	92.9	98.8	84.1	99.3	89.3

由表 6 可知，HG2 - ECA - M - YOLO v8n 模型的 mAP@0.5 达 92.9%，对比 Faster R - CNN、SSD、EfficientDet、DETR、YOLO v5n、YOLO v7 - tiny、YOLO v10n、YOLO 11s、YOLO 12s 算法，分别提高了 9.6、10.5、10.9、6.5、3.0、2.8、1.0、1.0、1.1 个百分点。Faster R - CNN、SSD、EfficientDet、DETR 的 mAP@0.5 均较低，且翘尾行为的 AP 较低，在高召回率区间内，精确率显著下降；YOLO v5n、YOLO v7 - tiny 模型的翘尾行为的 AP 较低；YOLO v10n、YOLO 11s、YOLO 12s 3 个模型的 mAP@0.5 略低于 HG2 - ECA - M - YOLO v8n 模型，且翘尾行为分别降低了 3.3、4.5、5.0 个百分点，塌陷行为分别降低了 1.1、0.2、0.1 个百分点。与 Faster R - CNN、SSD、EfficientDet、DETR、YOLO v5n、YOLO v7 - tiny、YOLO 11s、YOLO 12s 算法相比，HG2 - ECA - M - YOLO v8n 模型参数量分别减少 96.5%、81.5%、26.7%、88.3%、23.3%、22.2%、48.8%、47.6%；与 YOLO v10n 相比，参数量虽然略有提升，但计算量降低 2.0×10^{9}，且拥有最高的精确率、召回率、F1 分数和 mAP@0.5，翘尾与塌陷 2 种行为的 AP 最高。与 Faster R - CNN、SSD、EfficientDet、DETR、YOLO v7 - tiny、YOLO v10n、YOLO 11s、YOLO 12s 相比，HG2 - ECA - M - YOLO v8n 模型计算量分别减少了 44.8%、17.2%、65.0%、94.5%、63.6%、29.4%、77.5%、77.4%；与 YOLO v5n 模型相比，计算量虽略有提升，但其余指标均有大幅度提升。在牧场等

大规模场景中,低计算量模型能够降低单个设备的部署成本,提升实时性,有利于实现对奶牛行为的全面覆盖与实时监测。在监控设备上,帧率 44.4 f/s 可支持实时监控,满足对奶牛产前行为的连续监测需求。该指标为 Faster R-CNN、SSD、DETR、YOLO v7-tiny、YOLO 11s、YOLO 12s 模型帧速率的 10.3 倍、1.9 倍、1.3 倍、4.2 倍、2.2 倍与 4.3 倍。尽管 HG2-ECA-M-YOLO v8n 模型在速度上稍逊于 EfficientDet、YOLO v5n、YOLO v10n,但其在小目标识别、遮挡场景适应及动态光照环境下的鲁棒性,使其更适合实际牧场的复杂环境。

综上所述,相比其他 9 个模型,HG2-ECA-M-YOLO v8n 模型的精确率为 88.9%,召回率为 91.2%,F1 分数为 0.90,mAP@0.5 为 92.9%,帧率为 44.4 f/s,综合性能更优。

相较于现有奶牛产前行为识别研究,本文提出的 HG2-ECA-M-YOLO v8n 模型展现出显著优势。文献[31]通过人工解析海量行为时序数据观测奶牛分娩前行为模式,存在行为分类粒度粗化、难以捕捉动态变化特征、分析时效性不足等问题。文献[32]提出基于 YOLO v8 的机器视觉系统,实时识别待产奶牛的站立和躺卧 2 种姿态,分析分娩行为的变化规律;文献[33]提出改进视觉词典法,通过视频自动识别单只母牛产前行走、侧卧和回望行为;以上 2 项研究仅针对单奶牛目标识别,未进行多奶牛目标识别实验。而 HG2-ECA-M-YOLO v8n 模型,利用 C2f 多尺度特征融合增强了对复杂背景、遮挡及恶劣光照的鲁棒性;ECA 注意力机制增强了对细微行为特征的捕捉;针对多奶牛目标检测,在保持较高帧率的同时具有高精确率、召回率和 mAP@0.5;轻量化设计支持边缘设备部署,能够实现奶牛产前行为的实时检测。

3.4 不同光照情况下检测效果

3.4.1 不同光照条件下模型识别效果

为了验证 HG2-ECA-M-YOLO v8n 模型对光照条件的鲁棒性,本研究对不同光照条件下奶牛产前行为识别效果进行分析。具体过程如下:从数据集中随机选取躺卧、回望、翘尾和塌陷等 4 种行为的图像各 500 幅,通过伽马变换技术调整图像的灰度级并优化图像对比度,以此模拟不同光照场景下的图像;基于此制作不同光照条件的奶牛产前行为测试集,输入改进网络进行测试并获取评价指标。

作为一种对图像灰度值的非线性操作,伽马校正借助指数变换调整亮度分布,有效提升低照度图像的视觉质量与细节表现力,不同光照场景下相关检测结果如表 7 所示。

表 7 5 种光照场景下检测性能结果

Tab.7 Detection performance results under five lighting conditions

γ	P/%	R/%	mAP@0.5/%	AP/%			
				躺卧	翘尾	回望	塌陷
0.4	89.5	88.8	92.0	99.0	80.3	99.4	89.4
0.7	87.0	91.0	91.7	99.0	80.1	99.1	88.7
1.0	88.9	91.2	92.9	98.8	84.1	99.3	89.3
1.5	88.0	90.6	92.0	99.1	81.2	99.4	88.4
2.5	87.1	90.5	91.5	99.0	78.5	99.2	89.2

本研究选择 γ 值分别为 0.4、0.7、1.5、2.5,共模拟 4 种不同光照条件下的图像,并与原始图像($\gamma=1.0$)展开对比。其中,$\gamma=0.4$ 时接近 11:00—13:00 的亮度;$\gamma=0.7$ 时接近 13:00—15:00 的亮度;$\gamma=1.5$ 时接近 17:00—19:00 的亮度;$\gamma=2.5$ 时接近 20:00—22:00 的亮度[34]。

与原始数据集检测结果相比,不同光照条件下的 P、R 与 mAP@0.5 均有下降;同等光照条件下卧、回望、塌陷 3 种行为 AP 下降不大,而翘尾行为的 AP 分别下降 3.8($\gamma=0.4$)、4($\gamma=0.7$)、2.9($\gamma=1.5$)、5.6($\gamma=2.5$)个百分点;表明光照对奶牛产前行为的识别具有干扰作用,其中翘尾对光照的敏感度明显高于其他行为。分析原因,翘尾的识别依赖尾根角度、尾毛纹理、尾部与臀部的相对位置等细节特征,在 $\gamma=2.5$ 的低照度条件下容易出现边缘模糊、纹理丢失和对比度降低,导致模型难以捕捉关键特征,进而引发 AP 下降。相比之下,尺度更大、形态变化更明显的回望和躺卧行为受此影响较小。为此,在实际牧场应用中,需重点关注夜间低照度场景下翘尾行为的识别,通过图像增强和补充局部补光设备等减少细节特征丢失,提升识别稳定性。

3.4.2 基于多尺度自适应伽马校正的低照度图像增强

基于多尺度自适应伽马校正的低照度图像增强技术通过动态调整 γ,精准优化低光照图像的亮度分布与细节层次,能够显著提升低照度下奶牛产前行为识别的准确性与鲁棒性。

该技术首先通过多尺度分解,将低光照图像分离为不同频率子带分别处理,针对低频层,采用高斯滤波提取奶牛的整体轮廓(如躯干姿态、躺卧状态等),同时有效抑制噪声干扰;而高频层则借助拉普拉斯金字塔保留关键细节信息,以此规避传统单尺度伽马校正中常见的细节丢失问题。随后,该技术基于局部区域亮度统计特性动态计算 γ,针对低亮度区域(如牛舍角落等光照不足区域),采用低 γ 值

($\gamma<1.0$)提升对比度,清晰凸显奶牛的肢体动作细节;对于高亮度区域(如灯光直射或反射处),则采用高 γ 值($\gamma>1.0$)抑制过强光线,避免过度曝光,以此保障行为特征的完整性。通过这种差异化调节,最终实现暗区细节的精准增强与亮区信息的有效保护,达成二者的协同优化效果。自适应伽马校正系数 $\gamma_{adaptive}$ 的计算式为

$$\gamma_{adaptive}=\frac{1}{1+\frac{\eta\mu}{\delta}} \tag{6}$$

式中　μ——局部均值　　δ——标准差

η——调节系数

通过多尺度自适应伽马校正的技术处理,弱光环境下奶牛产前行为识别的准确性与鲁棒性得到显著提升。在 $\gamma=2.5$ 的光照条件下,增强前后相关实验数据及结果如表 8 所示。

表 8　增强前后对比

Tab. 8　Comparison before and after enhancement

%

模型	P	R	mAP@0.5	AP(翘尾)
HG2 - ECA - M - YOLO v8n	87.1	90.5	91.5	78.5
HG2 - ECA - M - YOLO v8n + 多尺度自适应伽马校正	89.0	89.5	91.5	79.0

结果显示,对数据集进行多尺度自适应伽马校正处理后,采用 HG2 - ECA - M - YOLO v8n 模型的检测精确率提升了 1.9 个百分点。这一结果表明,该处理手段通过增强图像对比度,有效强化了背景与目标的区分度,帮助模型更精准地识别奶牛特征,显著降低假阳性(FP)出现的概率,减少误报,提升预测准确性。召回率则下降 1.0 个百分点。这是由于多尺度自适应伽马校正使模型的判定策略更趋保守,在优先保障高精确率的前提下,其对低对比度或模糊样本的检测标准更为严格,导致部分真实正例被误判为负例,使假阴性(FN)出现小幅增加。mAP@0.5 指标保持稳定,这表明多尺度自适应伽马校正并未对模型的整体性能产生显著影响。该指标的稳定性进一步说明,在常见类别的识别任务中,模型性能始终保持一致。值得注意的是,在 $\gamma=2.5$ 的光照条件下,翘尾行为的 AP 提升了 0.5 个百分点,这得益于多尺度自适应伽马校正通过精准调整图像亮度,有效增强了尾部类别样本的特征辨识度提升了识别效果。

3.5　模型嵌入式设备部署实验

为验证 HG2 - ECA - M - YOLO v8n 模型在嵌入式设备部署时的实时识别速度,分别将 YOLO v8n、HG2 - ECA - M - YOLO v8n 模型部署于嵌入式设备 Jetson Nano B01 和搭载 Intel - 酷睿 i9 - 13980HX 处理器、16 GB 内存、NVIDIA GeForce RTX 4060 显卡的 PC 平台,选取 3 段时长为 30 s 的奶牛产前视频作为测试数据,3 段视频包含躺卧、翘尾、回望、塌陷等 4 种行为。两种模型部署实验检测帧率如表 9 所示。

表 9　模型部署后的检测帧率

Tab. 9　Detection frame rate after model deployment

f/s

模型	Jetson Nano B01	PC 平台
YOLO v8n	4.5	15.2
HG2 - ECA - M - YOLO v8n	18.6	44.4

由表 9 可知,HG2 - ECA - M - YOLO v8n 模型在 2 种设备上的部署识别帧率高于 YOLO v8n,在 Jetson Nano B01 上的部署实时识别帧率为 18.6 f/s,比 YOLO v8n 模型高 313.3%;在 Intel 移动平台上部署实时识别帧率为 44.4 f/s,比 YOLO v8n 模型高 192.1%。

综上所述,本文提出的 HG2 - ECA - M - YOLO v8n 模型在嵌入式设备上展现了优异的实时性,能够满足规模化散养牧场的产前行为监测帧率大于等于 15 f/s 的需求。在低温起雾、多目标并发的实际场景中,设备的检测帧率会有所降低。另外,实际牧场部署还需考虑算力、摄像头部署角度等硬件适配问题,动态遮挡与场景变化的影响,成本与运营挑战等。为此,可采用动态帧率调节策略,随奶牛活动频率调整检测帧率,以兼顾识别效率与能耗成本;依场景选择广角摄像头或特写摄像头,降低环境对图像质量的影响;构建场景自适应模型,提高模型的泛化能力;采用轻量化部署方案,多摄像头共享一个嵌入式设备,降低成本。

4　结论

(1)提出了一种改进的奶牛产前行为识别模型 HG2 - ECA - M - YOLO v8n,为精准畜牧业中的奶牛健康管理提供了新的技术支撑。

(2)对 YOLO v8n 模型进行了多维度且协同优化的改进,首先,将主干网络替换为轻量级且高效的 HGNet V2,显著增强了模型对多尺度特征的融合能力,为精准检测奠定了基础;其次,在 Head 部分引入 ECA 注意力机制,有效引导模型聚焦奶牛行为中的关键视觉特征;最后,采用 MPDIoU Loss 替代传统的 CIoU Loss,优化了检测框的回归精度。最终 HG2 - ECA - M - YOLO v8n 模型的精确率为 88.9%,召回

率为 91.2%，mAP@0.5 为 92.9%，与基线模型 YOLO v8n 相比，模型的精确率、召回率和 mAP@0.5 均有提升。

(3)对于翘尾与塌陷这 2 种形态相似却本质不同的行为，ECA 注意力机制通过增强模型对关键特征的聚焦能力，在特征提取层面显著提升了二者的区分度；同时，将主干网络替换为 HGNet V2 后，其特有的多尺度特征融合机制与高效的网络结构，有效提升了模型对这两种行为的识别精度。引入 MPDIoU Loss 后，又提升了这 2 种行为的 AP 值。消融实验验证了改进方法的有效性，翘尾与塌陷行为的识别精度分别显著提升 5.6、1.7 个百分点。

(4)在相同训练环境和参数配置下，与 Faster R-CNN、SSD、EfficientDet、DETR、YOLO v5n、YOLO v7-tiny、YOLO v10n、YOLO 11s 和 YOLO 12s 开展的对比实验表明，HG2-ECA-M-YOLO v8n 模型在保证轻量化的同时，mAP@0.5 分别提高了 9.6、10.5、10.9、6.5、3.0、2.8、1.0、1.0、1.1 个百分点，验证了改进模型的优越性。

参 考 文 献

[1] 王以中，辛翔飞，林青宁，等. 我国畜禽种业发展形势及对策[J]. 农业经济问题，2022(7)：52-63.
WANG Yizhong, XIN Xiangfei, LIN Qingning, et al. Development situation and countermeasures of the livestock and poultry seed industry in China[J]. Issues in Agricultural Economy, 2022(7): 52-63. (in Chinese)

[2] 沈明霞，丁奇安，陈佳，等. 信息感知技术在畜禽养殖中的研究进展[J]. 南京农业大学学报，2022，45(5)：1072-1085.
SHEN Mingxia, DING Qi'an, CHEN Jia, et al. A review of information perception technology in livestock breeding[J]. Journal of Nanjing Agricultural University, 2022, 45(5): 1072-1085. (in Chinese)

[3] 贾云飞，郑伟程，何泽军，等. 我国畜牧业绿色发展：现状、制约与战略应对[J]. 中国畜牧杂志，2023，59(1)：323-329.

[4] 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)

[5] 何沛桐，张建华，张凝，等. 基于视觉感知的畜禽智慧养殖管理与疫病诊断研究进展[J]. 中国农业大学学报，2023，28(10)：141-165.
HE Peitong, ZHANG Jianhua, ZHANG Ning, et al. Research progress in intelligent livestock and poultry breeding management and disease diagnosis based on visual perception[J]. Journal of China Agricultural University, 2023, 28(10): 141-165. (in Chinese)

[6] 宋怀波，王云飞，邓洪兴，等. 基于视频分析的规模化奶牛智能监测技术研究进展[J]. 华南农业大学学报，2024，45(5)：649-660.
SONG Huaibo, WANG Yunfei, DENG Hongxing, et al. Research progress of intelligent monitoring technology for large-scale dairy cows based on video analysis[J]. Journal of South China Agricultural University, 2024, 45(5): 649-660. (in Chinese)

[7] MAO A, HUANF E, WANG X, et al. Deep learning-based animal activity recognition with wearable sensors: overview, challenges, and future directions[J]. Computers and Electronics in Agriculture, 2023, 211: 108043.

[8] ALIPIO M, VILLENA M L. Intelligent wearable devices and biosensors for monitoring cattle health conditions: a review and classification[J]. Smart Health, 2023, 27: 100369.

[9] 代肖飞，吴建寨，程国栋，等. 可穿戴设备在畜禽健康管理中的应用与挑战[J]. 南京农业大学学报，2025，48(4)：766-780.
DAI Xiaofei, WU Jianzhai, CHENG Guodong, et al. Application and challenges of wearable devices in livestock and poultry health management[J]. Journal of Nanjing Agricultural University, 2025, 48(4): 766-780. (in Chinese)

[10] 罗西尔，卢小龙，刘庆友，等. 肉牛智慧养殖技术研究进展[J]. 华南农业大学学报，2024，45(5)：661-671.
LUO Xi'er, LU Xiaolong, LIU Qingyou, et al. Research progress on intelligent farming techniques of beef cattle[J]. Journal of South China Agricultural University, 2024, 45(5): 661-671. (in Chinese)

[11] 张帆，周梦婷，熊本海，等. 肉牛生理指标智能监测技术研究进展与展望[J]. 智慧农业(中英文)，2024，6(4)：1-17.
ZHANG Fan, ZHOU Mengting, XIONG Benhai, et al. Research advances and prospect of intelligent monitoring systems for the physiological indicators of beef cattle[J]. Smart Agriculture, 2024, 6(4): 1-17. (in Chinese)

[12] BALASSO P, MARCHESINI G, UGHELINI N, et al. Machine learning to detect posture and behavior in dairy cows: information from an accelerometer on the animal's left flank[J]. Animals, 2021, 11(10): 2972.

[13] LIU N, QI J, AN X, et al. A review on information technologies applicable to precision dairy farming: focus on behavior, health monitoring, and the precise feeding of dairy cows[J]. Agriculture, 2023, 13: 1858.

[14] 吴赛赛，吴建寨，程国栋，等. 基于姿态估计的动物行为识别研究进展[J]. 中国农业大学学报，2023，28(6)：22-35.
WU Saisai, WU Jianzhai, CHENG Guodong, et al. Research progress of animal behavior recognition based on pose estimation [J]. Journal of China Agricultural University, 2023, 28(6): 22-35. (in Chinese)

[15] 李恩泽，王克俭，司永胜，等. 基于改进 ConvNeXt 的奶牛行为识别方法[J]. 农业机械学报，2024，55(5)：282-289，404.

LI Enze, WANG Kejian, SI Yongsheng, et al. Cow behavior recognition method based on improved ConvNeXt [J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(5): 282 - 289, 404. (in Chinese)

[16] VAZQUEZ-DIOSDADO J A, GRUHIER J, MIGUEL-PACHECO G G, et al. Accurate prediction of calving in dairy cows by applying feature engineering and machine learning[J]. Preventive Veterinary Medicine, 2023, 219: 106007.

[17] XU Xingshi, WANG Yunfei, HUA Zhixin, et al. Light-weight recognition network for dairy cows based on the fusion of YOLOv5s and channel pruning algorithm[J]. Transactions of the CSAE, 2023, 39(15): 152 - 162.

[18] 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)

[19] 白强,高荣华,赵春江,等. 基于改进 YOLOV5s 网络的奶牛多尺度行为识别方法[J]. 农业工程学报,2022,38(12):163 - 172.
BAI Qiang, GAO Ronghua, ZHAO Chunjiang, et al. Multi-scale behavior recognition method for dairy cows based on improved YOLOV5s network[J]. Transactions of the CSAE, 2022, 38(12): 163 - 172. (in Chinese)

[20] 宋怀波,李嵘,王云飞,等. 基于 ECA - YOLO v5s 网络的重度遮挡肉牛目标识别方法[J]. 农业机械学报,2023,54(3):274 - 281.
SONG Huaibo, LI Rong, WANG Yunfei, et al. Recognition method of heavily occluded beef cattle targets based on ECA - YOLO v5s[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(3): 274 - 281. (in Chinese)

[21] BOCHKOVSKIY A, WANG C Y, LIAO H. YOLOv4: optimal speed and accuracy of object detection[J]. arXiv Preprint, arXiv, 2020, 1704: 04861.

[22] JIA Q, YANG J, HAN S, et al. CAMLLA - YOLOv8n: cow behavior recognition based on improved YOLOv8n[J]. Animals, 2024, 14(20): 3033.

[23] 王旺,王福顺,张伟进,等. 基于改进 YOLO v8s 的羊只行为识别方法[J]. 农业机械学报,2024,55(7):325 - 335,344.
WANG Wang, WANG Fushun, ZHANG Weijin, et al. Sheep behavior recognition method based on improved YOLO v8s[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(7): 325 - 335, 344. (in Chinese)

[24] MU Y, HU J, WANG H, et al. Research on the behavior recognition of beef cattle based on the improved lightweight CBR - YOLO model based on YOLOv8 in multi-scene weather[J]. Animals, 2024, 14(19): 2800.

[25] YAO T, LI Y, MEI T. HGNet: learning hierarchical geometry from points, edges, and surfaces[C]// 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2023: 21846 - 21855.

[26] ZHAO Y, LV W, XU S, et al. DETRs beat YOLOS on real-time object detection[C]// 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2023: 16965 - 16974.

[27] 耿春新,王爱民,阎天宇,等. 基于改进 YOLOv8n 损失函数的克氏原螯虾体特征识别算法[J]. 渔业现代化,2024,51(5):72 - 80.
GENG Chunxin, WANG Aimin, YAN Tianyu, et al. Research on the identification algorithm of crayfish body features based on the improved YOLOv8n loss function[J]. Fishery Modernization, 2024, 51(5): 72 - 80. (in Chinese)

[28] JI X, NIU Y. A lightweight network for human pose estimation based on ECA attention mechanism[J]. Electronics, 2023, 13(1): 13.

[29] NI H, SHI Z, KARUNGARU S, et al. Classification of typical pests and diseases of rice based on the ECA attention mechanism[J]. Agriculture, 2023, 13: 1066.

[30] CAO Y, CHEN J, ZHANF Z. A sheep dynamic counting scheme based on the fusion between an improved-sparrow-search YOLOv5x - ECA model and few-shot deepsort algorithm[J]. Computers and Electronics in Agriculture, 2023, 206: 107696.

[31] CAVENDISH B, MCDONAGH J, TZIMIROPOULOS G et al. Changes in dairy cow behavior with and without assistance at calving[J]. Agriculture, 2021, 11: 722.

[32] AN Y, SONG Y, JIANG H, et al. Analysis of calving cow posture recognition, behavioral changes, and influencing factors based on machine vision[J]. Animals, 2025, 15: 1201.

[33] 温长吉,王生生,赵昕,等. 基于视觉词典法的母牛产前行为识别[J] 农业机械学报,2014,45(1):266 - 274.
WEN Changji, WANG Shengsheng, ZHAO Xin, et al. Visual dictionary for cows sow behavior recognition[J]. Transactions of the Chinese Society for Agricultural Machinery, 2014, 45(1): 266 - 274. (in Chinese)

[34] 刘志成,王殿伟,刘颖,等. 基于二维伽马函数的光照不均匀图像自适应校正算法[J]. 北京理工大学学报,2016,36(2):191 - 196,214.
LIU Zhicheng, WANG Dianwei, LIU Ying, et al. Adaptive adjustment algorithm for non-uniform illumination images based on 2D Gamma function[J]. Transactions of Beijing Institute of Technology, 2016, 36(2): 191 - 196, 214. (in Chinese)