doi:10.6041/j.issn.1000-1298.2026.02.024

基于 DCT－YOLO 的轻量化奶牛爬跨行为检测方法

潘浩文[1,2]　何梦腾[1,2]　邓洪兴[1,2]　许兴时[1,2]　赵永杰[1,2]　宋怀波[1,2]

（1.西北农林科技大学机械与电子工程学院，陕西杨凌 712100；
2.陕西省农业信息感知与智能服务重点实验室，陕西杨凌 712100）

摘要：针对现有接触式奶牛发情检测装置成本高，易造成奶牛应激反应，部分基于深度学习的检测方法存在复杂环境影响下识别精度不高、模型复杂度高及部署困难等问题，基于 YOLO v8n 模型提出了 DCT－YOLO 的轻量化奶牛爬跨行为与发情奶牛检测模型。首先，骨干部分的特征提取与下采样采用 YOLO v7 的 MPConv（MaxPool-Conv）模块，提升模型对远景小目标奶牛爬跨行为的识别能力；其次，在检测头部分采用动态任务对齐检测头（Task align dynamic detection head，TADDH），融合爬跨行为与发情奶牛间的特征关联，达到通过爬跨行为这一显著特征增强网络对发情奶牛个体关注度的目的；上采样部分采用内容感知重组模块（Content－aware reassembly of features，CARAFE），通过跨维度交互进行发情奶牛特征增强。为了验证模型性能，标注了 2 239 幅图像用于模型训练与测试。试验结果表明，DCT－YOLO 模型精确率为 94.8%，召回率为 80.1%，平均精度均值（mAP@0.5）为 87.5%，浮点计算量为 8.5×10^9，参数量为 2.08×10^6，检测速度为 256.41 f/s。与 SSD、Faster R－CNN、YOLO v5n、YOLO v5s、YOLO v7－tiny、YOLO v8n 和 YOLO v8s 目标检测模型相比，参数量分别降低 91.19%、98.48%、16.93%、77.18%、65.41%、30.82% 和 81.31%，检测速度分别提高 192.72、226.56、34.19、97.68、187.92、39.02、126.54 f/s，平均精度均值（mAP@0.5）仅比 YOLO v8s 低 1.9 个百分点，比其他模型的最高值高 0.2 个百分点，结果表明，模型取得了检测精度与速度的良好平衡。综上，本研究可为奶牛爬跨行为识别与发情奶牛定位等任务提供关键信息支撑。

关键词：奶牛爬跨行为；YOLO v8；轻量化；CARAFE；TADDH；MPConv

中图分类号：TP391.4　　**文献标识码**：A　　**文章编号**：1000-1298(2026)02-0245-11　　**OSID**：

Lightweight Cow Mounting Behavior Detection Method Based on DCT－YOLO

PAN Haowen[1,2]　HE Mengteng[1,2]　DENG Hongxing[1,2]　XU Xingshi[1,2]　ZHAO Yongjie[1,2]　SONG Huaibo[1,2]

（1. *College of Mechanical and Electronic Engineering*, *Northwest A&F University*, *Yangling*, *Shaanxi* 712100, *China*
2. *Key Laboratory of Agricultural Information Sensing and Intelligent Service of Shaanxi Province*, *Yangling*, *Shaanxi* 712100, *China*）

Abstract: Accurate and effective cow estrus detection is the foundation for improving herd reproductive performance. Existing contact cow estrus detection devices are costly and prone to cause stress in cows, and some deep learning-based detection methods suffer from poor detection accuracy under the influence of complex environments and deployment difficulties due to high model complexity. Therefore, a lightweight DCT－YOLO model for cow climbing spanning behavior and estrus cow detection was proposed based on the YOLO v8n model for improvement. Firstly, the MPConv structure was adopted for the feature extraction and subsampled of the Backbone part to improve the recognition ability of the model for small-target cow mounting behavior. Secondly, the detection head adopted a dynamic TADDH, which fused the feature association between estrous cows and mounting behavior, and improved the network's focus on individual estrous cows through the distinctive feature of mounting behavior. Finally, the interpolating part adopted CARAFE, which enhanced the features of estrus cows through cross-dimensional interactions. To validate the performance of the model, totally 2 239 images were labeled for model training and testing. The experimental results showed that DCT－YOLO model had a precision of

收稿日期：2024－10－08　修回日期：2024－10－29

基金项目：国家自然科学基金项目（32472964、32272931）、陕西省农业关键核心技术攻关项目（2025NYGG005）、国家重点研发计划项目（2023YFD1301801）、陕西省重点产业创新链项目（2024NC－ZDCYL－05－12）和中央引导地方专项—区域科技创新体系建设项目（2025ZY－QYCXYL－04）

作者简介：潘浩文（2001—），男，硕士生，主要从事智能化检测与技术研究，E-mail：969122826@nwafu.edu.com

通信作者：宋怀波（1980—），男，教授，博士生导师，主要从事模式识别研究，E-mail：songyangfeifei@163.com

94.8%, a recall of 80.1%, a mean average precision (mAP@0.5) of 87.5%, floating-point operations (FLOPs) of 8.5×10^9, params of 2.08×10^6, and a detection speed of 256.41 f/s. Compared with SSD, Faster R-CNN, YOLO v5n, YOLO v5s, YOLO v7-tiny, YOLO v8n and YOLO v8s target detection networks, the number of parameters was reduced by 91.19%, 98.48%, 16.93%, 77.18%, 65.41%, 30.82% and 81.31%, and the detection speed was respectively improved by 192.72 f/s, 226.56 f/s, 34.19 f/s, 97.68 f/s, 187.92 f/s, 39.02 f/s and 126.54 f/s, respectively, mAP@0.5 was only 1.9 percentage points lower than that of YOLO v8s and 0.2 percentage points higher than that of the best of the other models and the results showed that the model achieved a good balance between detection accuracy and speed. In summary, the model was lightweight, real-time accurate and robust, and it can provide important information support for tasks such as cow mounting behavior detection and estrus cow localization.

Key words: cow mounting behavior; YOLO v8; lightweight; CARAFE; TADDH; MPConv

0 引言

奶牛发情行为及时、准确监测与其配种、产犊、产奶密切相关,是提高牛场经济效益的核心作业环节[1]。目前,我国大部分奶牛养殖场仍以人工监测为主,存在成本高、效率低、发情时间鉴别不准等问题,易错过最佳配种时间。爬跨行为是奶牛发情显著的外部特征[2],可作为奶牛发情的判定依据。因此,开展奶牛爬跨行为实时、准确检测方法研究,有助于提高现代化奶牛养殖水平[3]。

奶牛发情行为监测方式主要分为接触式和非接触式 2 种。接触式检测方法[4-6]主要是将加速度传感器、温度传感器和计步器在内的多类传感器置于奶牛身体不同部位以获取奶牛的生理数据,并利用分类算法判别是否发情。现有研究表明,接触式发情行为监测方法可不间断对奶牛多项生理指标进行监测。然而,监测结果受奶牛跛行[7]或环境温度[8]等影响,准确性较低;且发情监测设备成本较高,维护困难,容易损坏,对奶牛有应激作用。

在非接触式奶牛发情行为检测研究方面,研究人员基于热红外图像和声音的发情监测方法开展试验。WANG 等[8]提出了一种基于 LOGISTIC 和 SVM 的奶牛热红外图像发情监测模型。LOGISTIC 模型发情检测率为 82.37%,SVM 模型发情检测率为 81.42%,以奶牛眼部和外阴最高温度为输入点,召回率在 86% 以上。受热红外图像采集的局限,该方法仅适用于小规模养殖情况。WANG 等[9]开发了一种双声道录音装置,利用显著的声音特征提高发情检测的检出率,并且提出了一种基于最优组合的双长短时记忆联合判别策略,以提升发情检测性能。但奶牛声音提取精度低,易受温度和湿度等外部因素影响。基于深度学习的目标检测技术在奶牛发情检测领域取得了较好效果[10-12]。文献[13-14]将 YOLO 系列模型应用于奶牛发情行为检测,取得了较好效果。随着现有模型精度的不断提升,研究者开始致力于提高模型的轻量化及边缘部署能力。王政等[15]提出了一种融合 YOLO v5n 与通道剪枝算法的轻量化奶牛发情行为识别方法,与原模型相比,剪枝后模型平均精度均值(mean Average Precision, mAP)不变的情况下,参数量和计算量分别减少 59.32% 和 49.63%,检测速度提高 33.71%。但模型仅检测奶牛的爬跨行为,未定位到发情奶牛。LI 等[16]提出的 IATEFF-YOLO 模型适用于检测夜间奶牛爬跨行为及图像中奶牛尺度变化,mAP 为 99.3%,检测速度为 102 f/s。WANG 等[17]提出了 E-YOLO 发情奶牛识别模型,相比于原始模型在发情奶牛(mAP_{estrus})方面提高 5.4 个百分点,在爬跨($mAP_{mounting}$)方面提高 3.3 个百分点。然而该研究认定被爬跨奶牛为发情奶牛,存在判定误差。

当前,基于深度学习的奶牛发情行为检测部分算法模型结构复杂,部署难度较大,且绝大多数目标检测模型仅专注于奶牛的爬跨行为,缺少对发情奶牛个体的关注度。因此,本研究针对复杂环境下奶牛爬跨行为检测难题,提出一种基于 YOLO v8n 的奶牛爬跨行为识别模型并进行轻量化改进,将 YOLO v7 的 MPConv(MaxPool-Conv)模块用于骨干网络特征提取和下采样,替换动态任务对齐检测头,并采用内容感知重组模块上采样,使模型检测任务更关注于发情奶牛个体,以期为实现轻量化、鲁棒性、实时准确的爬跨行为与发情奶牛个体检测提供支持。

1 材料与方法

1.1 材料

1.1.1 数据获取

数据于 2021 年 10 月—2023 年 10 月采集自宁夏回族自治区臻牛牧业奶牛养殖场和五里牛园牧业奶牛养殖场。为提高视觉模块在奶牛爬跨行为识别

中不同自然环境下的鲁棒性和通用性，实施了全天候样本采集策略，以便在任何时间点捕捉到爬跨行为。使用 2 个 2MP PTZ 网络摄像机（DS－2CD3626FWD－LPTZ 型（2.7～12 mm））获取数据。将摄像机安装在每个奶牛活动场的棚舍角落位置，向下倾斜角度约 25°，安装高度约 2.5 m，摄像机布局与安装位置如图 1 所示[15]，选取室外活动场进行奶牛爬跨行为数据采集。数据采集场地包括 6 个奶牛活动场，每个奶牛活动场长×宽为 60 m×20 m。



(a) 布局示意图　　(b) 具体安装位置

图 1　摄像机安装示意图

Fig. 1　Camera installation diagrams

1.1.2　样本集构建

共手动截取包含奶牛爬跨行为 199 段视频，其中 186 段采集自臻牛牧业奶牛养殖场，13 段采自五里牛园牧业奶牛养殖场，视频时长 3～15 s 不等，帧率为 30 f/s。每段视频经过人工筛选，只有 1 次爬跨行为。调整视频分辨率为 1 280 像素（水平）×720 像素（垂直），每 6 帧取 1 帧以获取图像数据，得到视频图像 3 681 幅。截取后图像以 JPG 格式进行存储。

采用结构相似性（Structural similarity，SSIM）算法剔除相似数据[18]，计算公式为

$$SSIM_{X,Y}=\frac{(2\mu_X\mu_Y+C_1)(2\delta_{XY}+C_2)}{(\mu_X^2+\mu_Y^2+C_1)(\delta_X^2+\delta_Y^2+C_2)} \quad (1)$$

式中　$SSIM_{X,Y}$——度量 X、Y 图像相似度指标

μ_X、μ_Y——X、Y 图像均值

δ_X、δ_Y——标准差　　δ_{XY}——协方差

C_1、C_2——任意常数

经处理后，由西北农林科技大学兽医专家鉴定，共获得包含奶牛爬跨行为图像 2 239 幅。为确保训练集样本图像与测试集样本图像不是同一爬跨片段，手动选取不同情况的数据集作为测试集。使用 LabelImg 手动标记数据集内的爬跨行为与发情奶牛，如图 2 所示，以包围爬跨行为和每个发情奶牛的最小外部矩形作为基本准则。采用 Mounting、oestrus－1 与 oestrus－2 3 类标签，其中，“Mounting”标签表示标记奶牛爬跨这一交互行为，“oestrus－1”与“oestrus－2”标签分别表示标记爬跨奶牛与被爬跨奶牛，将爬跨行为作为参考，实现发情奶牛个体的定位，“all”表示在评估阶段将上述 3 类样本合并后的整体表现。标注文件保存为 PascalVOC 格式。



图 2　标注示意图

Fig. 2　Labeling schematic

图 3 为奶牛爬跨行为部分复杂场景示例，室外活动场的摄像机视场角较大，奶牛爬跨行为在视野中所占比例较小。当目标长宽尺寸小于原图尺寸的 0.1 倍时可认为是相对小物体。同时发情奶牛的辨认仅在发生爬跨行为过程，而爬跨行为还存在奶牛遮挡、夜间及逆光等问题，因此实现发情奶牛识别具有较大难度。

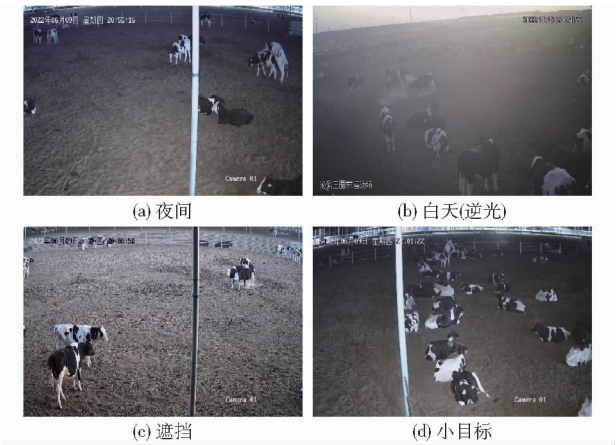

(a) 夜间　　(b) 白天(逆光)

(c) 遮挡　　(d) 小目标

图 3　复杂场景示例

Fig. 3　Complex scenario examples

训练集与测试集中均包含光照、有无遮挡、不同目标尺寸等不同场景奶牛爬跨图像，图像具体分类数据如表 1 所示。最终 1 794 幅图像（80%）作为训练集用于模型训练，445 幅图像（20%）作为模型训练结果评估的测试集，各类样本集间无数据重叠。

表 1　图像信息

Tab. 1　Details of images

影响因素	具体场景	图像数量		
		训练集	测试集	合计
光照	白天	1 579	232	1 811
	白天(逆光)	84	39	123
	夜间	131	174	305
遮挡	无遮挡	1 173	299	1 472
	有遮挡	621	146	767
目标尺寸	小目标	549	61	610
	大目标	1 245	384	1 629

1.2 方法

DCT－YOLO 模型结构如图 4 所示，主要改进如下：①将 YOLO v8n 网络 Backbone 及下采样 CBS 模块替换为 MPConv 模块，以增强网络对远景小目标的识别能力。②检测头更换为 TADDH，融合发情奶牛与爬跨行为之间的特征关联以提升网络对发情奶牛的关注度。③上采样部分采用内容感知重组模块，通过跨维度交互以增强发情奶牛特征。

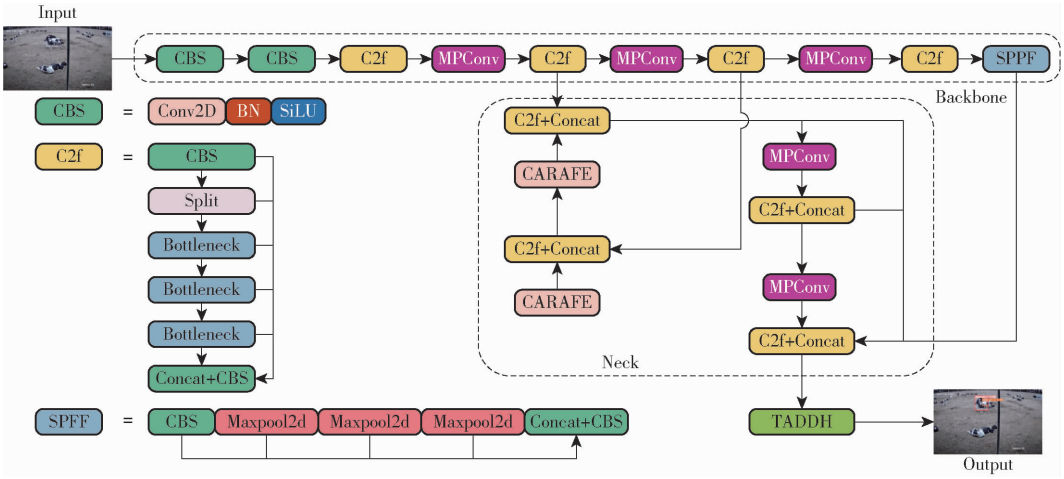

图 4 DCT－YOLO 网络结构

Fig. 4 Network structure of DCT－YOLO

1.2.1 YOLO v8n 目标检测模型

YOLO v8 模型提供了 5 种不同尺度的模型，以满足不同场景需求。选择 Nano 版本，相比 YOLO v8 系列其他模型，其在减少模型参数量与计算量的同时保证了一定识别精度，适用于类别较少，特征简单的目标检测任务。

其网络结构包括输入端、主干特征提取网络、颈部网络和检测头 4 个部分，Backbone 主要由 C2f 和 CBS 模块组成，对输入图像进行特征提取，其中 C2f 模块可以在保证轻量化的同时获得更加丰富的梯度流信息。Neck 部分将 YOLO v5 的 PAN 中 C3 模块替换为 C2f 模块。此外，还去掉上采样前的 1×1 卷积，直接将 Backbone 不同阶段输出的特征送入上采样操作。Head 部分选择解耦头（Decoupled head）和无锚框（Anchor－free）策略，仅保留解耦分类和回归分支。

1.2.2 重参数化卷积网络结构

WANG 等[19]提出的 YOLO v7 模型中的一些优化模块和方法可在不增加推理成本的情况下，显著提高检测精度。如图 5 所示，引入 MPConv 模块下采样。其中，B 为批大小（batch size），C 为输入特征图通道数，H 为输入特征图高，W 为输入特征图宽，In_c 表示模型输入下采样的通道数。输入通道数减半，得到的结构用于构建 2 个输入通道数相同的下采样路径。MaxPooling 路径包括 1 个最大池化层（MaxPool2d）和 1 个 1×1 的卷积层。最大池化层将输入特征图进行下采样，1×1 的卷积层用于调整通道数，MaxPooling 路径通过池化操作捕获全局特征。

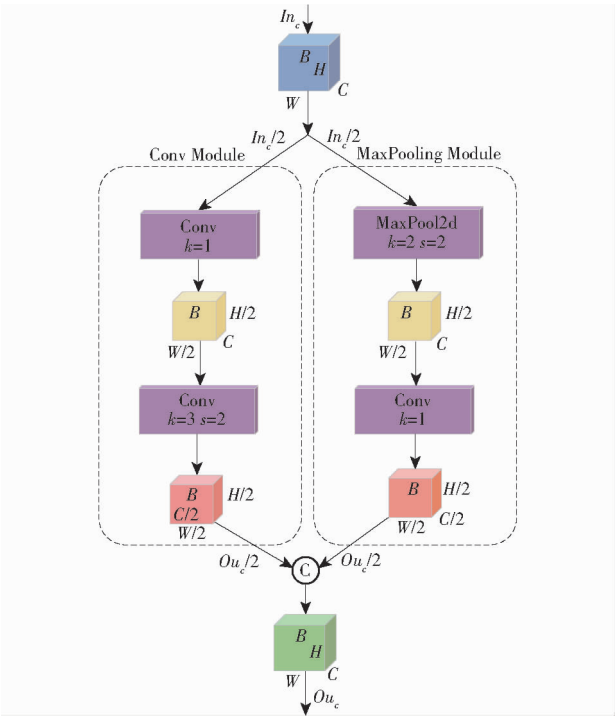

图 5 MPConv 网络结构

Fig. 5 Network structure of MPConv

Conv 路径包括 2 个卷积层，Conv（In_c，$k=1$）和 Conv（In_c，$k=3$，$s=2$），该操作可实现特征提取与特征图尺寸减半。最后，将 2 个分支的结果在低维通道上进行拼接。这样，输出的通道数将是 2 个分支输出通道数的和，由于每个分支输出 $Ou_c/2$ 通道，因此合并后的输出通道数恢复为原始的 Ou_c。

这种双分支特征的融合可以提高模型对于不同尺度奶牛爬跨行为的识别能力并减少计算量。使用双分支的下采样路径可以互相补充并共同学习有效

的特征表示，同时也能一定程度减少过拟合风险，提高模型鲁棒性。奶牛爬跨行为具有不同的运动速度、姿势和背景等变化，多路径的结构能够提高模型检测的准确性和鲁棒性。

1.2.3　内容感知重组模块

YOLO v8 目标检测网络模型中的上采样主要是基于最近邻插值或双线性差值实现的，但这 2 种方法缺乏对于整个接收域中的信息感知。针对此难题，WANG 等[20]提出了一种通用、轻量且高效的内容感知特征重组 CARAFE 结构，既可在较大的接收域中更好地聚合上下文并利用奶牛爬跨特征信息，增强发情奶牛与普通奶牛的特征对比，又可根据重新排列生成的特征作为一个空间块完成特征上采样。该结构支持特定于实例的内容感知处理，其可动态地生成自适应内核以促进内容感知，同时 CARAFE 引入更小的参数量与计算量，提高模型轻量化和检测速度。CARAFE 上采样网络结构如图 6 所示，其中，σ 为上采样的倍数（通常为 2），k_{up} 为预测的上采样核大小，C_m 为降维后的特征层通道数，X 为原输入特征图，X' 为重组特征图，N 为正方形区域。

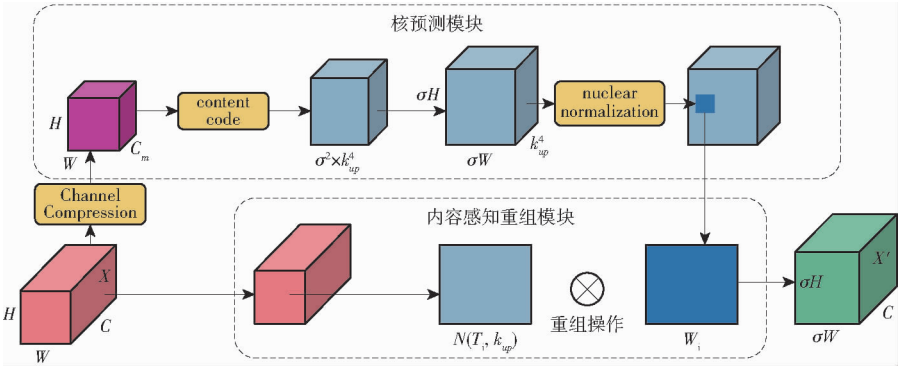

图 6　CARAFE 网络结构

Fig. 6　Network structure of CARAFE

CARAFE 上采样主要分为上采样核预测模块和内容感知重组模块。在核预测模块中，对于形状为 $H \times W \times C$ 输入特征图，采用 1×1 卷积层将其压缩到 C_m，减少后续操作过程的计算量。得到 $H \times W \times C_m$ 特征图，该过程可以提高模型检测效率，降低通道数变化对模型性能的影响。利用 1 个上采样核尺寸为 $k_{up} \times k_{up}$ 的卷积层预测上采样核，即

$$C_m = \sigma^2 k_{up}^2 \tag{2}$$

将得到尺寸为 $\sigma H \times \sigma W \times k_{up}^2$ 的上采样核重组并在空间上进行核归一化，使卷积核权重之和为 1。在内容感知重组模块中，利用预测的上采样核对特征进行重组，提取奶牛爬跨行为目标特征。对于输出特征图的各个空间坐标，将其映射回输入特征图，取出以之为中心的 $k_{up} \times k_{up}$ 区域，与预测到该点位置的上采样核作点积，得到输出值。

CARAFE 上采样能够对不同的特征分别生成不同的内容编码，而不是空间距离的远近，扩展模型对特征图的全局视野。因此，引入 CARAFE 模块，降低模型复杂度，提高网络对奶牛爬跨行为特征的提取能力。

1.2.4　动态任务对齐检测头

单阶段目标检测通常通过优化目标分类和定位 2 个子任务来实现，使用 2 个并行分支的头部，但是，这可能会导致 2 个任务之间的预测出现一定程度的空间错位。FENG 等[21]提出一种任务对齐单阶段对象检测器，其以一种基于学习的方式显式地对齐 2 个任务。首先，设计了一种新型的任务对齐头（Task-aligned head，T－Head），其能更好地平衡学习任务交互和任务特定的特征，并通过一种新的任务对齐预测器进行预测。然后，根据任务对齐学习提供的学习信号对齐 2 个预测的空间分布。本研究基于 T－Head 网络结构，提出了一种动态任务对齐检测头，其网络结构如图 7 所示。

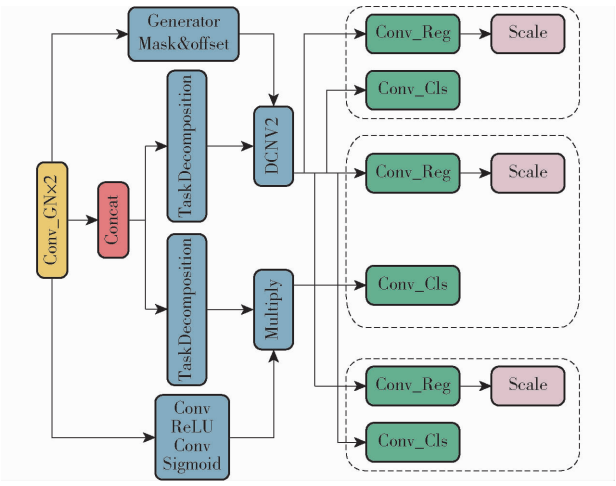

图 7　TADDH 网络结构

Fig. 7　Network structure of TADDH

该结构通过使用共享卷积，可大幅减少参数量，使得模型更轻便，有利于实现模型部署。为应对每个检测头所检测的发情奶牛目标尺度不一致问题，

使用 Scale 层对特征进行缩放,减少检测精度的丢失,提高模型对不同尺度奶牛目标的感知能力。参照任务对齐单阶段对象检测器的思想,除标签分配策略上的任务对齐,在检测头上也采用定制任务对齐的结构。现有目标检测器头部通常使用独立的分类和定位分支,这会导致 2 个任务之间缺乏交互,TADDH 通过特征提取器从多个卷积层中学习任务交互特征,得到奶牛爬跨行为与发情奶牛的联合特征,定位分支使用 DCNV2 和交互特征生成 DCNV2 的 offset 和 Mask,分类分支使用交互特征进行动态特征选择,增强对发情奶牛位置和形状的感知能力,并通过生成偏移和掩码来实现对目标位置和形状的自适应调整。而分类分支则使用交互特征进行动态特征选择,以提高发情奶牛分类准确性。

1.2.5 评价指标

采用精确率(Precision, P)、召回率(Recall, R)、平均精度(Average precision, AP)、平均精度均值(mean Average Precision, mAP@0.5)和检测速度评估模型性能。使用浮点计算量(Floating point operations, FLOPs)和参数量对模型轻量级进行评估。AP 值为所预测的每一个类别 P-R 曲线与坐标轴围成的面积,mAP 为所有类别 AP 值的平均值,mAP@0.5 表示 IoU 阈值为 0.5 的平均精度。

2 结果与分析

2.1 训练结果

试验平台是 Windows 10 操作系统,Python 编译器为 PyCharm,编程语言为 Python 3.7,硬件为 Intel(R)Core(TM)i7-10700K CPU@3.80 GHz,NVIDIA GeForce RTX 2080 Ti,显存 11 GB。采用自适应矩估计算法(Adaptive moment estimation, Adam)对模型进行调优。网络训练超参数如表 2 所示。

表 2 网络训练超参数

Tab.2 Hyperparameters for network training

参数	数值/形式
初始学习率	0.01
最终学习率	0.01
优化器	Adam
权重衰减	0.000 5
批量大小	32
置信度	0.7
迭代次数	300
输入图像尺寸/(像素×像素)	640×640

共训练 300 轮次,各指标在训练过程中变化趋势如图 8 所示。在训练前 50 轮,模型精确率、召回率和 mAP@0.5 快速提高,而损失值迅速下降。从 50~200 轮,所有指标变化缓慢,模型收敛。经过

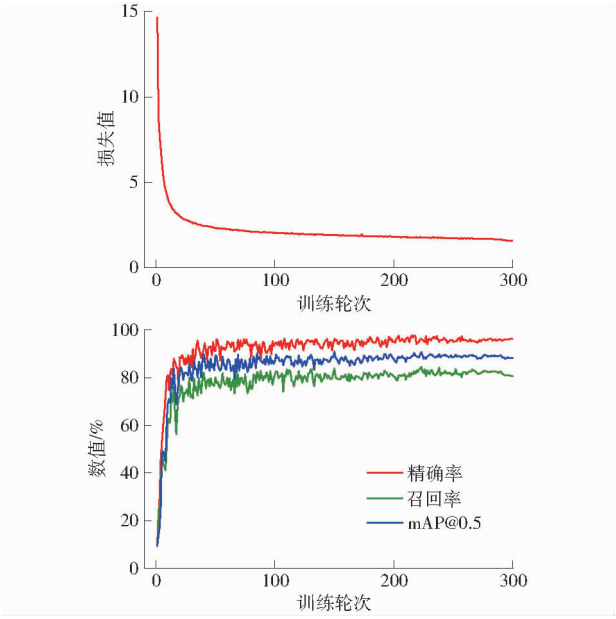

图 8 训练过程

Fig.8 Training process

300 轮次训练,模型所有精度指标曲线斜率收敛为零,损失值接近最小值,表明模型收敛。为防止过拟合,停止训练。

2.2 不同基础模型性能对比

为验证基础模型先进性,选取 YOLO v8 与 YOLO v10 系列的 Nano 模型作为基线模型首选,其中 YOLO v9 系列缺少 Nano 版本,而 YOLO v10 系列的 Nano 版本与 YOLO v8 系列相近,因此,对 2 种基础模型试验结果进行讨论。

结果如表 3 所示,YOLO v10 系列 Nano 版本的参数量与浮点计算量低于 YOLO v8 模型。然而,针对奶牛爬跨行为特定数据集的识别问题,YOLO v10n 模型的检测速度与 mAP@0.5 低于 YOLO v8n,识别效果较差。同时,YOLO v10 系列模型以 YOLO v8 系列模型为基础,引入了轻量级分类头与空间通道解耦下采样,与本研究模型改进部分重合,模型可扩展性降低。因此,选取 YOLO v8 系列模型作为本研究基础模型。

表 3 不同基础模型性能对比

Tab.3 Performance comparison of different base models

模型	mAP@0.5/%	浮点计算量	参数量	检测速度/(f·s^{-1})
YOLO v8n	87.3	8.1×10^{9}	3.01×10^{6}	217.39
YOLO v10n	84.0	6.5×10^{9}	2.71×10^{6}	185.19

2.3 模型检测效果

为评价本文模型对奶牛爬跨行为及发情奶牛个体的检测效果,在测试集上对模型进行测试,结果如表 4 所示。DCT-YOLO 的精确率为 94.8%,召回率为 80.1%,mAP@0.5(Mounting)为 91.0%,

表 4　不同模型性能对比

Tab. 4　Performance comparison of different models

模型	mAP@0.5/%				参数量	浮点计算量	检测速度/(f·s^{-1})	模型内存占用量/MB
	all	Mounting	oestrus－1	oestrus－2				
SSD	78.0	95.0	94.0	78.0	2.36×10^{7}	1.4×10^{11}	63.69	91.6
Faster R－CNN	63.0	67.0	68.0	60.0	1.37×10^{8}	2.0×10^{11}	29.85	108
YOLO v5n	85.9	89.7	88.4	79.7	2.50×10^{6}	7.1×10^{9}	222.22	5.03
YOLO v5s	85.6	88.2	88.8	79.7	9.11×10^{6}	2.4×10^{10}	158.73	17.6
YOLO v7－tiny	83.0	84.1	85.6	79.3	6.01×10^{6}	1.3×10^{10}	68.49	11.6
YOLO v8n	87.3	90.1	90.2	82.6	3.01×10^{6}	8.1×10^{9}	217.39	5.95
YOLO v8s	89.4	92.6	93.8	81.8	1.11×10^{7}	2.8×10^{10}	129.87	21.4
DCT－YOLO	87.5	91.0	90.6	84.7	2.08×10^{6}	8.5×10^{9}	256.41	4.21

mAP@0.5(oestrus－1)为 90.6%，mAP@0.5(oestrus－2)为 84.7%，参数量为 2.08×10^{6}，浮点计算量为 8.5×10^{9}，检测速度为 256.41 f/s。

DCT－YOLO 能够有效地检测出不同大小目标、光照条件和遮挡情况下爬跨行为与发情奶牛，且漏检与误检率较低。图 9 为典型场景下奶牛爬跨行为与发情奶牛的检测结果，由于奶牛爬跨行为与发情奶牛个体重叠，为清楚地显示预测框位置，将标签和置信水平省略。

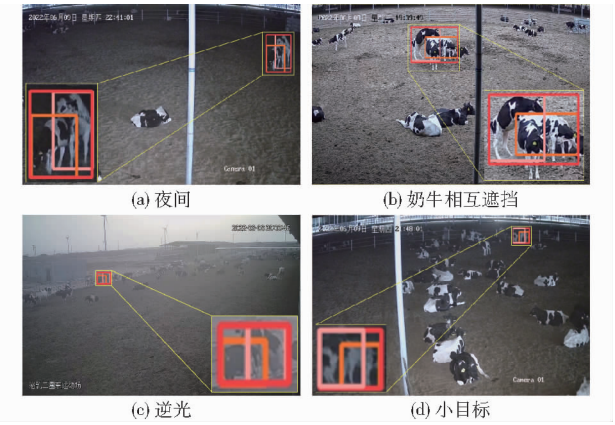

(a) 夜间　(b) 奶牛相互遮挡　(c) 逆光　(d) 小目标

图 9　奶牛爬跨行为检测效果

Fig. 9　Effectiveness of cow mounting behavior detection

2.4　不同检测模型效果对比

为验证 DCT－YOLO 模型性能，将本文模型与其他 7 种常见模型对比分析，包括 SSD[22]、Faster R－CNN[23]、YOLO v5n[24]、YOLO v5s[25]、YOLO v7－tiny[19]、YOLO v8n 和 YOLO v8s 模型。表 4 为 DCT－YOLO 与其他模型性能对比。

在 mAP@0.5(Mounting)方面，DCT－YOLO 模型比 Faster R－CNN、YOLO v5n、YOLO v5s、YOLO v7－tiny 和 YOLO v8n 模型分别提高 35.82%、1.45%、3.17%、8.20% 和 1.00%，低于 SSD 和 YOLO v8s，在 mAP@0.5(oestrus－1)方面，DCT－YOLO 模型比 Faster R－CNN、YOLO v5n、YOLO v5s、YOLO v7－tiny 和 YOLO v8n 模型分别提高 33.24%、2.49%、2.03%、5.84% 和 0.44%，同样低于 SSD 和 YOLO v8s，在 mAP@0.5(oestrus－2)方面，DCT－YOLO 模型比 SSD、Faster R－CNN、YOLO v5n、YOLO v5s、YOLO v7－tiny、YOLO v8n 和 YOLO v8s 模型分别提高 8.59%、41.17%、6.27%、6.27%、6.81%、2.54% 和 3.55%。因此，综合 mAP@0.5(Mounting)、mAP@0.5(oestrus－1)和 mAP@0.5(oestrus－2)3 个评价指标，与上述 7 种检测模型相比，DCT－YOLO 具有较高的检测精度。

在模型部署方面，DCT－YOLO 浮点计算量和模型参数量具有显著优势，使其成为移动和边缘部署设备的理想选择。与 SSD、Faster R－CNN、YOLO v5n、YOLO v5s、YOLO v7－tiny、YOLO v8n 和 YOLO v8s 模型相比，DCT－YOLO 具有更少的浮点计算量、参数量和更高的检测速度。其中，DCT－YOLO 参数量分别降低 91.19%、98.48%、16.93%、77.18%、65.41%、30.82% 和 81.31%，DCT－YOLO 的检测速度为 256.41 f/s，分别提高 192.72、226.56、34.19、97.68、187.92、39.02、126.54 f/s，DCT－YOLO 浮点计算量为 8.5×10^{9}，略高于 YOLO v5n 和 YOLO v8n。DCT－YOLO 轻量化得到验证。

综上，在模型对比下，DCT－YOLO 在参数量、模型内存占用量和检测速度 3 个轻量级指标上均取得最优表现。在奶牛爬跨行为检测性能方面，DCT－YOLO 的 mAP@0.5 为 87.5%，低于 YOLO v8s，但高于其他对比模型。然而，SSD、YOLO v5s 与 YOLO v8s 的检测速度远低于 DCT－YOLO，并且其模型内存占用量和浮点计算量不适用于内存和计算资源不足的低性能设备。考虑到奶牛爬跨行为检测的有效性和模型的轻量化，DCT－YOLO 表现出了最好的性能。

为验证所提方法的有效性，选取夜间、遮挡干扰和小目标 3 种复杂场景，比较 SSD、Faster R－CNN、YOLO v5n、YOLO v5s、YOLO v7－tiny、YOLO v8n、YOLO v8s 和 DCT－YOLO 在具体场景下的检测性能，如图 10 所示。

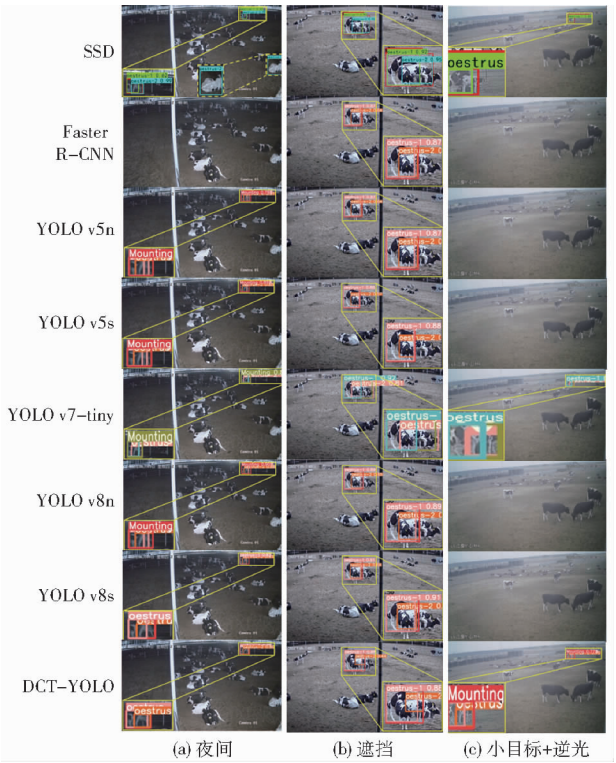

图 10 不同模型检测效果对比

Fig. 10 Comparison of detection performance across different models

Faster R－CNN 由于检测精度太低，实际检测时未能识别出爬跨行为和发情奶牛。在夜间场景下，DCT－YOLO 与其余模型均可准确识别奶牛爬跨行为，SSD 存在误检现象。在遮挡场景中，Faster R－CNN、YOLO v5n、YOLO v5s、YOLO v7－tiny、YOLO v8n 和 YOLO v8s 模型虽然都能检测出爬跨行为和发情奶牛，但会将遮挡奶牛误检为被爬跨奶牛，DCT－YOLO 却能够准确识别被爬跨奶牛，消除遮挡信息影响。在小目标与逆光场景中，DCT－YOLO 的表现优于其他模型，Faster R－CNN、YOLO v5n、YOLO v5s、YOLO v8n 和 YOLO v8s 未检测到爬跨行为和发情奶牛的情况。在夜间、遮挡干扰和小目标 3 种具体情况下，DCT－YOLO 与其他轻型 YOLO 模型相比，表现出优越的检测能力。这表明 DCT－YOLO 更为稳健。同时，DCT－YOLO 在检测爬跨行为与发情奶牛的特征提取方面可在参数量较少的情况下优于大多数传统模型。

综上，DCT－YOLO 是一种轻量级、快速的模型，可以部署在低性能设备上。该算法实现轻量化和检测精度之间的平衡，并通过模型结构优化优于一些非轻量化模型。

2.5 消融试验

设计消融试验评价 3 种改进策略，如表 5 所示，其中 S1 为 YOLO v8n 模型，M1～M3 分别代表 3 种改进方法。

表 5 消融试验结果

Tab. 5 Results of ablation experiment

模型	M1	M2	M3	mAP@0.5/%			参数量	F1 值/%	浮点计算量	检测速度/(f·s^{-1})
				Mounting	oestrus－1	oestrus－2				
S1				90.1	90.2	82.6	3.01×10^{6}	85.1	8.1×10^{9}	217.39
S2	√			89.6	90.7	82.2	2.74×10^{6}	84.2	7.8×10^{9}	204.08
S3	√	√		88.9	90.2	84.8	1.94×10^{6}	87.0	8.2×10^{9}	192.31
S4	√	√	√	91.0	90.6	84.7	2.08×10^{6}	86.8	8.5×10^{9}	256.41

注：√表示采用此模块(方法)。M1 表示引入 MPConv 重卷积结构，M2 表示替换 TADDH 检测头，M3 表示采用 CARAFE 上采样。

由表 5 可知，DCT－YOLO mAP@0.5(Mounting)、mAP@0.5(oestrus－1)和 mAP@0.5(oestrus－2)分别达到 91.0%、90.6%和 84.7%，相比于 YOLO v8n 模型分别提高 0.9、0.4、2.1 个百分点，虽其浮点计算量略有提高，但检测速度提高 17.9%。将 CBS 模块更换为 MPConv 重参数卷积结构(M1)以及检测头更换为 TADDH(M2)后，S1 轻量化得到显著的提升。例如，更换 MPConv 模块后，S2 参数量和浮点计算量分别降低 8.9%和 3.7%。同样，S3 参数量降低 35.48%。然而，值得注意的是，该模型的轻量化对其性能产生负面影响，M1 导致 mAP@0.5(Mounting)和 mAP@0.5(oestrus－2)分别下降到 89.6%和 82.2%，检测速度下降 6.1%。同样 M2 导致 mAP@0.5(Mounting)下降到 88.9%，检测速度下降 11.54%。

通过使用 CARAFE 模块(M3)扩展全局视野信息，利用跨维度交互，减少了特征信息的丢失，从而提高了 mAP@0.5。模型复杂度显著降低，计算量维持稳定，且模型检测速度提高 33.3%。

综上，M1、M2、M3 模块(方法)对于模型改进性能提升效果显著，在保证模型精度一定的情况下，模型参数量与推理时间显著降低。且 3 种改进方式兼容性较强，DCT－YOLO 较 YOLO v8n 模型具有全面的性能提升。因此，基于模型结构的改进方法是有效的。

2.6 不同下采样网络性能对比

为了评估 MPConv 模块对小目标的爬跨行为与发情奶牛检测的性能，在相同条件下，分别基于 SPD－

Conv[26]、KernelWarehouse[27] 和 RFA－Conv[28] 3 种奶牛爬跨行为检测算法对同一数据集进行训练。训练量同样为 300 轮次，采用 mAP@0.5、浮点计算量、参数量与检测速度对训练完成后的模型进行评估。3 种检测模型性能如表 6 所示。由表 6 可知，MPConv 的 mAP@0.5 分别比 SPD－Conv、KernelWarehouse 和 RFA－Conv 高 0.3、8.1、1.6 个百分点；检测速度与 SPD－Conv 相同，比 KernelWarehouse 低 18.14 f/s，比 RFA－Conv 高 22.26 f/s。其参数量分别比 SPD－Conv 和 KernelWarehouse 少 1.99×10^6 和 3.5×10^5，比 RFA－Conv 高 6.0×10^4。浮点计算量比 SPD－Conv 和 RFA－Conv 分别少 4.2×10^9 和 1×10^8，比 KernelWarehouse 高 3.3×10^9。

表 6　4 种下采样算法性能对比

Tab.6　Performance comparison of four downsampling algorithms

下采样	mAP@0.5/%	浮点计算量	参数量	检测速度/(f·s^{-1})
SPD－Conv	87.2	1.2×10^{10}	4.73×10^6	204.08
KernelWarehouse	79.4	4.5×10^9	3.09×10^6	222.22
RFA－Conv	85.9	7.9×10^9	2.68×10^6	181.82
本文	87.5	7.8×10^9	2.74×10^6	204.08

SPD－Conv 具备一个空间到深度(SPD)层和一个非跨步卷积层组成，完全摒弃了目前广泛使用的步长卷积和池化操作结构，不丢失可学习信息，但同时带来了计算量从而导致检测速度较慢；KernelWarehouse 减少了卷积核维度，并显著增加了卷积核数量，故计算量较小。但同时 KernelWarehouse 线性混合的密集运算与卷积核层次相关，而模型尺寸预算有限，故精度较低；RFA－Conv 采用与 MPConv 相似的并行分支结构，检测效果与 MPConv 相近，较弱于 MPConv。

综上，MPConv 在保持较高准确度的同时有较快的检测速度，实现了精度与速度的良好平衡。

2.7　不同检测头算法性能对比

检测头是用于特征提取的主要组件，为了对比不同检测头对网络性能的影响，保持 MPConv 为下采样，测试了 SEAMHead、MultiSEAMHead、dyhead 3 种主干网络，并采用 mAP@0.5、计算量、参数量与检测速度对训练完成后的模型进行评估。如表 7 所示，MPConv 为下采样时的 mAP@0.5 分别比 SEAMHead[29]、MultiSEAMHead 和 dyhead[30] 高 1.9、1.0、0.1 个百分点，检测速度分别比 SEAMHead 和 MultiSEAMHead 高 17.79、7.12 f/s，比 dyhead 低 34.96 f/s；参数量分别比 SEAMHead、MultiSEAMHead 和 dyhead 少 1.74×10^6、2.71×10^6、1.28×10^6，浮点计算量分别比 dyhead 少 1.2×10^9，比 SEAMHead 和 MultiSEAMHead 多 2.7×10^9、1.2×10^9。

表 7　4 种检测头性能对比

Tab.7　Comparison of performance of four inspection heads

检测头	mAP@0.5/%	浮点计算量	参数量	检测速度/(f·s^{-1})
SEAMHead	86.1	5.5×10^9	3.68×10^6	174.52
MultiSEAMHead	87.0	7.0×10^9	4.65×10^6	185.19
dyhead	87.9	9.4×10^9	3.22×10^6	227.27
本文	88.0	8.2×10^9	1.94×10^6	192.31

综上，TADDH 为检测头时，mAP@0.5 最高，参数量最少，检测速度与计算量较好，表明其可在保持与更大网络相同精度的前提下具有更小的模型体积和计算量。

3　讨论

3.1　基于深度学习的奶牛发情行为检测性能对比

为验证模型先进性，将 DCT－YOLO 模型与其他文献模型对奶牛发情行为检测进行对比，如表 8 所示。

表 8　本文模型与其他文献模型对比

Tab.8　Comparison of the proposed and related methods

模型	mAP@0.5/%		F1 值/%	参数量	浮点计算量	检测速度/(f·s^{-1})
	Mounting	oestrus				
YOLO v4[13]		83.0	80.00			
改进 YOLO v3[14]	99.15		97.62			31.00
改进 YOLO v5n(融合剪枝)[15]	97.70		96.79	7.20×10^5	6.8×10^8	50.26
IATEFF－YOLO[16]	99.30		98.59		1.1×10^{11}	102.00
E－YOLO[17]	95.70	93.9	93.74	3.04×10^6	9.9×10^9	123.46
DCT－YOLO(本文)	91.00	90.6,84.7	86.80	2.08×10^6	8.5×10^9	256.41

YOLO v4[13]、改进 YOLO v3[14] 模型作为较早期的奶牛发情行为检测模型，旨在实现奶牛发情行为的检测，模型评价体系不够完善，仅关注检测精度，且模型结构复杂，难以实现部署。其中 YOLO v4[13]

模型利用奶牛身体部位坐标判别发情行为,检测精度低,误检率较高。文献[14]将 YOLO 系列模型用于奶牛爬跨行为检测,引入改进方法,提高了模型识别准确率,然而模型提出版本过早,模型性能较差。随着研究不断深入,文献[12]提出了一种融合 YOLO v5n 与通道剪枝的算法,模型的参数量与计算量低于本模型。然而该模型的轻量化来自模型修剪,压缩模型结构。改进 YOLO v5n(融合剪枝)[15]模型仅检测奶牛的爬跨行为,缺少对发情奶牛个体的关注,因而检测任务量小,模型轻量化程度高。IATEFF-YOLO[16]适用于检测夜间奶牛爬跨行为及图像中奶牛尺度变化,模型针对特殊场景,计算量与检测速度较低,因而轻量化程度较差。文献[17]模型与本研究基础模型都为 YOLO v8n,从奶牛爬跨行为的检测出发,文献[17]将被爬跨奶牛认定为发情奶牛个体,但相关研究表明,爬跨奶牛依然存在发情可能。且试验结果表明,DCT-YOLO 参数量、浮点计算量及检测速度都优于 E-YOLO[17]模型。所有模型爬跨行为检测精度都高于 90%。

3.2 基于 HiResCAM 的热力图可视化分析

HiResCAM 是一种用于解释模型预测的方法,可以理解模型在做出预测时关注的图像信息。图 11 为HiResCAM 得到的热力图,由图 11 可知(其中第 1 行中红色框为奶牛爬跨行为及其放大图,第 2、3 行中红色框为奶牛爬跨行为在热力图中所在位置),YOLO v8n 热点颜色较浅,置信度较低,有多个高温点,而 DCT-YOLO 的热点尺寸较大,颜色较深,置信度较高。此外,DCT-YOLO 仅有 1 个高温点。这表明,DCT-YOLO 相较于 YOLO v8n 具有更强的特征提取能力,假阳性结果的风险较低,并且 DCT-YOLO 可以学习到 YOLO v8n 无法检测到的细微特征,避免遗漏检测。

3.3 漏检分析

DCT-YOLO 模型虽能较好地识别发情奶牛及爬跨行为,但由于养殖场环境复杂多样,常有逆光、遮挡、光照较弱及小目标等干扰因素叠加,导致部分图像出现漏检等情况。如图 12a 所示,由于奶牛目标距离摄像机过远,在图像中仅占极小的像素,且存在逆光影响,导致特征过少,因此模型对极小目标无法做出准确判断;如图 12b 所示,此时处于夜间环境,光照较弱,由于奶牛花斑黑白相间,黑色花斑与背景颜色相同,且被爬跨奶牛存在严重遮挡现象,导致模型在检测时无法提取到完整的特征信息,因此出现漏检。

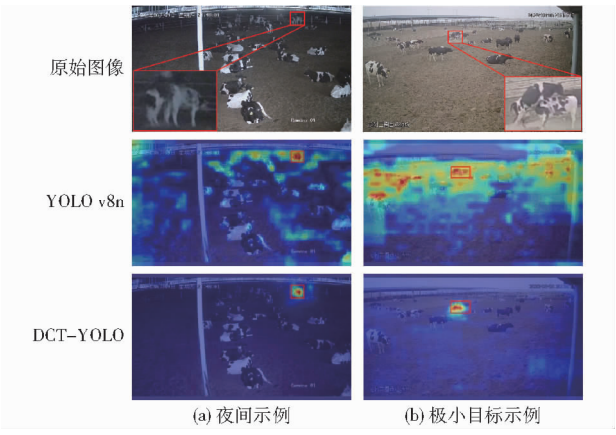

图 11 模型优化前后热力图对比

Fig. 11 Comparison of heat maps before and after model optimization

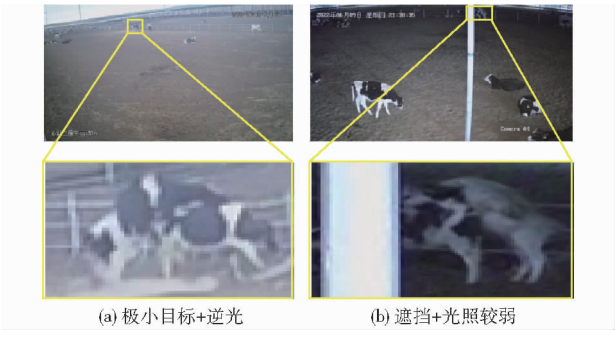

图 12 漏检示例

Fig. 12 Examples of missed detection

4 结论

(1)对 YOLO v8n 进行轻量化改进,构建了奶牛爬跨行为识别模型,DCT-YOLO 作为轻量化网络,其改进方法能够在轻量化与高识别率之间保持平衡,有利于实现高效的奶牛爬跨行为特征提取,更加适合于实际应用场景的模型部署。

(2)本文模型精确率为 94.8%,召回率为 80.1%,mAP@0.5 为 87.5%,浮点计算量为 8.5×10^9,参数量为 2.08×10^6,检测速度为 256.41 f/s。在模型对比下,DCT-YOLO 拥有更低的参数量、更小的模型内存占用量和更快的检测速度,模型轻量化程度最高,表明改进方法可有效提升模型性能。

参 考 文 献

[1] 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 Zheng, SONG Huaibo, WANG Yunfei, et al. Research progress and technology trend of intelligent morning of dairy cow motionbehavior[J]. Smart Agriculture, 2022, 4(2): 36-52. (in Chinese)
[2] ROELOFS J, LÓPEZ-GATIUS F, HUNTER R, et al. When is a cow in estrus? Clinical and practical aspects[J]. Theriogenology, 2010, 74(3): 327-344.
[3] 王祯, 宗哲英, 王海超,等. 奶牛发情数字化检测方法研究现状与发展[J]. 中国饲料, 2021(21): 134-138.

WANG Zhen, ZONG Zheying, WANG Haichao, et al. Research status and development of digital detection methods for cow estrus[J]. China Feed, 2021(21): 134－138. (in Chinese)
[4] 谭益, 何东健, 郭阳阳,等. 基于 Storm 的奶牛发情实时监测系统设计与实现[J]. 中国农业科技导报, 2018, 20(12): 83－90.
TAN Yi, HE Dongjian, GUO Yangyang, et al. Design and implementation of real-time monitoring system for cow in estrus based on Storm[J]. China Agricultural Science and Technology Review, 2018, 20(12): 83－90. (in Chinese)
[5] 刘忠超, 何东健. 奶牛阴道植入式电阻传感器与无线监测系统研究[J]. 农业机械学报, 2019, 50(11): 175－185.
LIU Zhongchao, HE Dongjian. Research of implantable sensor and wireless monitoring system for cow's vaginal resistance[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(11): 175－185. (in Chinese)
[6] WANG J, ZHANG Y, BELL M, et al. Potential of an activity index combining acceleration and location for automated estrus detection in dairy cows[J]. Information Processing in Agriculture, 2022, 9(2): 288－299.
[7] 韩书庆, 张晶, 程国栋,等. 奶牛跛行自动识别技术研究现状与挑战[J]. 智慧农业(中英文), 2020, 2(3): 21－36.
HAN Shuqing, ZHANG Jing, CHENG Guodong, et al. Current state and challenges of automatic lameness detection in dairy cattle[J]. Smart Agriculture, 2020, 2(3): 21－36. (in Chinese)
[8] WANG Z, WANG S, WANG C, et al. A non-contact cow estrus monitoring method based on the thermal infrared images of cows[J]. Agriculture, 2023, 13(2): 385.
[9] WANG J, SI Y, WANG J, et al. Discrimination strategy using machine learning technique for oestrus detection in dairy cows by a dual-channel-based acoustic tag[J]. Computers and Electronics in Agriculture, 2023, 210: 107949.
[10] 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.
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. (in Chinese)
[11] 付辰伏, 任力生, 王芳. 基于改进 YOLO v8 的牛只行为识别与跟踪方法[J]. 农业机械学报, 2024, 55(5):290－301.
FU Chenfu, REN Lisheng, WANG Fang. Method for cattle behavior recognition and tracking based on improved YOLO v8[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(5): 290－301. (in Chinese)
[12] 田富洋, 张立印, 张帅扬,等. 基于巡检机器人和改进 RT－DETR 的奶牛挑食行为识别方法[J]. 农业机械学报,2025, 56(6):258－267.
TIAN Fuyang, ZHANG Liyin, ZHANG Shuaiyang, et al. Selective feeding behavior recognition method for dairy cows based on inspection robot and improved RT－DETR[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(6): 258－267. (in Chinese)
[13] LODKAEW T, PASUPA K, LOO C K. CowXNet: an automated cow estrus detection system[J]. Expert Systems with Applications, 2023, 211: 118550.
[14] 王少华, 何东健. 基于改进 YOLO v3 模型的奶牛发情行为识别研究[J]. 农业机械学报, 2021, 52(7): 141－150.
WANG Shaohua, HE Dongjian. Estrus behavior recognition of dairy cows based on improved YOLO v3 model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(7): 141－150. (in Chinese)
[15] 王政, 许兴时, 华志新,等. 融合 YOLO v5n 与通道剪枝算法的轻量化奶牛发情行为识别[J]. 农业工程学报, 2022, 38(23): 130－140.
WANG Zheng, XU Xingshi, HUA Zhixin, et al. Lightweight recognition for the oestrus behavior ofdairy cows combining YOLO v5n and channel pruning[J]. Transactions of the CSAE, 2022, 38(23): 130－140. (in Chinese)
[16] LI D, DAI B, LI Y, et al. IATEFF－YOLO: focus on cow mounting detection during nighttime[J]. Biosystems Engineering, 2024, 246: 54－66.
[17] WANG Z, HUA Z, WEN Y, et al. E－YOLO: recognition of estrus cow based on improved YOLO v8n model[J]. Expert Systems with Applications, 2024, 238: 122212.
[18] WANG S. The image classification algorithm research using class information loss and joint structural similarity [J]. International Journal of Information and Communication Technology, 2020, 16(3): 203－213.
[19] WANG C Y, BOCHKOVSKIY A, LIAO H Y M. YOLO v7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464－7475.
[20] WANG J, CHEN K, XU R, et al. Carafe: content-aware reassembly of features[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 3007－3016.
[21] FENG C, ZHONG Y, GAO Y, et al. Tood: task-aligned one-stage object detection[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 3490－3499.
[22] LIU W, ANGUELOV D, ERHAN D, et al. SSD: single shot multibox detector[C]// Computer Vision-ECCV 2016: 14th European Conference, Amsterdam, The Netherlands, 2016: 21－37.
[23] REN S, HE K, GIRSHICK R, et al. Faster R－CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2017, 39(6): 1137－1149.
[24] XU X, WANG Y, SHANG Y, et al. Few-shot cow identification via meta-learning[J]. Information Processing in Agriculture, 2024,12(1):80－90.
[25] XU X, WANG Y, HUA Z, et al. Light-weight recognition network for dairy cows based on the fusion of YOLO v5s and channel pruning algorithm[J]. Transactions of the CSAE, 2023, 39(15): 152－162.
[26] SUNKARA R, LUO T. No more strided convolutions or pooling: a new CNN building block for low-resolution images and small objects[C]// Proceedings of the Joint European Conference on Machine Learning and Knowledge Discovery in Databases, 2022: 443－459.
[27] LI C, YAO A. KernelWarehouse: rethinking the design of dynamic convolution[J]. arXiv: 2406.07879,2024.
[28] ZHANG X, LIU C, YANG D, et al. RFAConv: innovating spatial attention and standard convolutional operation[J]. arXiv: 2304.03198, 2023.
[29] YU Z, HUANG H, CHEN W, et al. Yolo-face v2: a scale and occlusion aware face detector[J]. Pattern Recognition, 2024, 155: 110714.
[30] DAI X, CHEN Y, XIAO B, et al. Dynamic head: unifying object detection heads with attentions[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 7373－7382.