doi:10.6041/j.issn.1000-1298.2025.12.055

基于局部感知的肉牛多行为检测与统计方法

王　芳[1,2]　刘星宇[1,2]　任力生[1,2]　付辰伏[1,2]　贾惠煊[1,2]
(1.河北农业大学信息科学与技术学院,保定 071001;2.河北省农业大数据重点实验室,保定 071001)

摘要:针对目前肉牛行为研究主要集中在基本行为识别,缺乏对复杂行为间的局部感知,本文对肉牛基本行为下的精细行为进行识别研究,提出基于改进 YOLO v8 的肉牛多行为检测与统计方法。采集肉牛行为图像,构建包括站立、躺卧、进食、饮水等基本行为和回舔、行走、探究、甩尾等精细行为的肉牛行为数据集;选用 YOLO v8n-P2 作为基础模型,以增强模型对犊牛的检测能力;设计 C2f-PPA 特征提取结构,捕捉肉牛不同行为间局部特征变化;采用交互策略对 YOLO v8 检测头改进,构建任务动态对齐检测头 TDADH;采用 MPDIoU 损失函数,解决了 CIoU 局限性问题。基于检测结果对全天候时间内肉牛行为统计,对不同遮挡环境下统计结果进行图像可视化显示。结果表明,PTPM-YOLO v8 模型识别全部(8 种)行为的精确率为 91.0%,召回率为 87.9%,平均精度均值为 94.3%。与原模型 YOLO v8n 相比,PTPM-YOLO v8n 的 mAP@0.5 提高 3.0 个百分点,参数量降低 23.3%;识别全部行为和基本行为的 mAP@0.5 分别提升 3.0、2.4 个百分点。本文实现了养殖环境下肉牛精细行为准确识别,可为肉牛多行为监测提供参考。

关键词:肉牛;目标检测;多行为识别;行为统计;YOLO v8
中图分类号:TP391.4　　**文献标识码**:A　　**文章编号**:1000-1298(2025)12-0603-12　　**OSID**:

Multi Behavior Detection and Statistical Method for Beef Cattle Based on Local Perception

WANG Fang[1,2]　LIU Xingyu[1,2]　REN Lisheng[1,2]　FU Chenfu[1,2]　JIA Huixuan[1,2]
(1. *College of Information Science and Technology*, *Hebei Agricultural University*, *Baoding* 071001, *China*
2. *Key Laboratory of Agricultural Big Data of Hebei Province*, *Baoding* 071001, *China*)

Abstract: Given the current research on beef cattle behavior, which mainly focused on basic behavior recognition and lacked local perception of complex behaviors, the identification of fine behaviors under basic behaviors of beef cattle was researched. A multi-behavior detection and statistical method based on YOLO v8 for beef cattle was proposed. Cattle behavior images were collected by cameras to build a comprehensive dataset that included fundamental behaviors such as standing, lying down, feeding, and drinking, as well as fine behaviors like licking, walking, searching, and tail flicking. YOLO v8n-P2 was selected as the basic model to enhance the ability of the model to detect calves; the feature extraction structure of C2F-PPA was designed; the YOLO v8 detection head was improved by interactive strategy, and the TDADH was constructed. MPDIoU loss function was used to address limitations associated with CIoU. Subsequently, statistical analysis of cattle behaviors based on detection results throughout the day was conducted; these results were visually displayed for various occlusion environments. The experimental results showed that the PTPM-YOLO v8n model achieved precision rate of 91.0%, a recall rate of 87.9%, and a mAP@0.5 score of 94.3% in recognizing all eight behaviors tested. Compared with the original model YOLO v8n, the mAP@0.5 of PTPM-YOLO v8n was increased by 3.0 percentage points, and the parameter number was decreased by 21.9%. which identified all behaviors and basic behaviors, the mAP@0.5 was increased by 3.0 and 2.4 percentage points, respectively. The method presented can accurately identify fine behaviors of beef cattle under farming conditions, providing a reference for multi-behavior monitoring of beef cattle.

Key words: beef cattle; object detection; multi behavior recognition; behavioral statistics; YOLO v8

收稿日期:2024-08-10　修回日期:2024-10-13
基金项目:河北省省级科技计划项目(19220119D)
作者简介:王芳(1971—),女,教授,博士,主要从事从事计算机网络与智能信息处理、农业信息化研究,E-mail:8335901@qq.com
通信作者:任力生(1971—),男,教授,主要从事电子系统设计和物联网技术研究,E-mail:rls60683@163.com

0 引言

牛肉作为我国畜牧业最大产出之一,提高牛肉产量和品质是当前养殖业的重点[1-2]。肉牛健康程度直接影响其数量和肉质,可通过识别肉牛行为判断[3],如:进食行为反映肉牛饥饿程度、饲料偏好与摄入量,进而关系到肉牛生长发育情况[4];当肉牛感到不适或受到蚊虫叮咬时会频繁甩尾,间接反映牛舍卫生程度[5]。肉牛基本行为主要反映其基本健康状况,而精细行为能够表达肉牛复杂的生理信息并反映牛舍环境状况,因此在牛群管理和畜牧生产中,准确地识别和监测肉牛行为对于保障牛群健康和提高牛舍管理水平至关重要[6]。

目前,为提高肉牛行为识别准确率,有诸多学者将传感器数据[7-9]与深度学习算法相结合,LI 等[10]提出结合 IMU 数据和机器学习算法的框架,实现牛只行为的识别与分类。HOSSEININOORBIN 等[11]使用联合时频域表示的传感器数据结合序列深度神经网络进行奶牛行为分类。PENG 等[12]提出 LSTM-RNN 模型,结合产犊前最后 3 d 的 IMU 数据,识别奶牛产犊前后的基本行为。但佩戴在肉牛身体上的传感器在肉牛运动过程中易脱落和受到损坏,影响肉牛行为识别。

随着深度学习发展,诸多学者通过视频图像分析提取肉牛行为特征,实现肉牛行为识别[13-16]。WANG 等[17]提出了基于 YOLO v5 的奶牛发情行为检测方法,识别奶牛爬跨行为。张宏鸣等[18]对 YOLO v3 进行改进,识别肉牛的站立和卧倒行为。LI 等[19]基于奶牛骨骼和混合卷积算法识别奶牛行走、站立、躺卧共 3 种基本行为。付辰伏等[20]提出了基于改进 YOLO v8 的肉牛行为识别方法,识别肉牛 5 种基本行为。段青玲等[21]对 YOLO v7 模型进行优化,有效识别肉牛的爬跨、躺卧、探究、站立、运动、舔砥和互斗 7 种行为。综上所述,目前基于计算机视觉的牛只行为识别方法[22]较为热门,但大部分学者主要针对牛只站立、躺卧、进食、饮水等基本行为进行识别研究,少有针对探究、甩尾、行走和回舔等精细行为进行识别研究。

针对上述问题,本文提出基于改进 YOLO v8 的肉牛多行为检测与统计方法,对站立、躺卧、进食、饮水、回舔、行走、探究和甩尾共 8 种行为进行识别研究,在识别基本行为的基础上,对精细行为进行研究。在 YOLO v8n-P2 的基础上构建 C2f-PPA 结构、提出 TDADH 检测头、替换损失函数为 MPDIoU 等对 YOLO v8 进行改进。最后,通过试验验证肉牛多行为识别效果,并基于目标检测结果对不同遮挡环境下的肉牛行为进行统计与图像可视化显示。

1 材料与方法

1.1 数据采集

选取河北省邢台市新河县某小型养殖牛舍为试验地点,摄像头安装于牛舍西南角的电线杆上,确保拍摄可以覆盖整个牛舍。视频采集时间为 2023 年 4 月和 10 月,期间,由于摄像头安装位置局限性,植物生长致使牛舍围墙处肉牛活动区域受到枝叶遮挡,存在大量草木枝叶遮挡部分肉牛身体现象,因此将所采集视频类型分为无遮挡牛舍场景和遮挡牛舍场景,采集牛舍环境如图 1 所示。该牛舍共有 2 处食槽和 1 处水槽,除图 1 标识外,另一处食槽位于牛棚下休息区内侧。试验共采集视频 99 段,其中 4 月 49 段,10 月 50 段。



(a) 无遮挡牛舍场景(4月) (b) 遮挡牛舍场景(10月)

图 1 牛舍环境实例图

Fig. 1 Example of cowshed environment

1.2 数据预处理

将采集的视频使用视频分帧技术处理成图像,保存格式为 jpg。通过人工筛选去除冗余图像,采用 LabelImg 进行肉牛行为标注。本文在识别肉牛站立、躺卧、进食和饮水 4 种基本行为的基础上,进一步将细节划分回舔、行走、探究和甩尾 4 种精细行为。其中甩尾行为比较特殊,会与其他行为同时出现。因此,本文定义甩尾行为标准:当甩尾行为与基本行为同时出现,将其认定为甩尾行为;而当甩尾行为与其他精细行为同时出现时,将该行为标注为其他行为。肉牛行为判定标准与行为示例图如表 1 和图 2 所示。

表 1 肉牛行为判定标准

Tab. 1 Cattle behavior recognition criteria

行为类别	行为描述	标签
站立	四肢蹄部立于地面,头部无特性动作	Stand
躺卧	四肢弯曲且腹部全部贴于地面	Lying
进食	站立的同时,牛只头部伸入食槽或进食栅栏	Feed
饮水	站立的同时,牛只头部俯身或低头伸入水槽	Drinking
回舔	牛只回转头部同时,舔舐腹部皮肤	Lick back
行走	蹄部抬起不处于同一水平线,四肢交叉且头未与地面接触	Walk
探究	牛只头部靠近地面或与地面接触,头靠近墙或栏杆	Search
甩尾	牛尾非自然下垂,向左、向右或向上甩	Tail flick



图 2　肉牛不同行为示例图

Fig. 2　Example diagram of different behaviors of cattle

制作完成后的数据集标签共分为 8 类，但肉牛日常活动中，相较于基本行为，精细行为较少出现。为丰富数据集信息、防止模型过拟合和降低行为类别不平衡带来的影响，通过数据增强技术，采用旋转、镜像、缩放、裁剪、平移等数据增强技术将数据集扩充到 8 370 幅图像，将数据集按比例 7∶2∶1 划分训练集、验证集和测试集，其中训练集 5 859 幅，验证集 1 674 幅，测试集 837 幅，构成本文的肉牛行为识别数据集。

2　肉牛行为识别方法

2.1　YOLO v8 简介

YOLO v8 有 n、s、m、l、x 共 5 种不同参数量的模型（支持目标检测、图像分类和实例分割等多种图像处理任务），以及针对小目标检测的 YOLO v8 - P2 和用于高分辨率图像检测的 YOLO v8 - P6 两个版本。本文采用参数量最小、推理速度较快的 YOLO v8n 作为肉牛行为识别的基础模型，针对数据集中存在犊牛小目标，选用 YOLO v8n - P2 作为肉牛行为识别改进的最终模型。

YOLO v8n - P2 在 YOLO v8n 模型基础上添加 P2 小目标检测层。原 YOLO v8n 模型中只有 3 个检测层（P3、P4、P5），检测头输出特征图尺寸分别为 80 × 80 × 255、40 × 40 × 255、20 × 20 × 255，对应 3 组初始化锚框，分别用于检测较小、中等和较大目标。YOLO v8n - P2 共 4 个检测层，P2 层的输出特征图尺寸为 160 × 160 × 255，专门用于检测尺寸为 4 × 4 以上的目标。P2 检测层在主干网络中只进行 2 次下采样操作，含有目标信息更为丰富的底层特征信息。颈部网络中自上而下和自下而上得到 2 个 P2 层特征与主干网络中同尺度特征进行特征融合，输出特征为 3 个输入特征的融合结果。在特征金字塔中，P2 特征图具有较高分辨率和丰富的细节信息，可以综合利用不同尺度信息，提供更全面和准确的小目标肉牛行为特征表示，进而增强模型对犊牛的检测能力。

2.2　PTPM - YOLO v8 网络结构

针对肉牛多行为识别中视觉局部特征分布特点对 YOLO v8 网络结构进行改进。首先，针对小目标检测层 P2 能够增强模型对犊牛的辨识能力，选用 YOLO v8n - P2 作为试验的基础模型；为增强模型的局部感知能力，采用 PPA 模块对 YOLO v8 原 C2f 结构进行改进，设计 C2f - PPA 结构；将定位与分类任务交互，构建 TDADH 检测头；最后使用损失函数 MPDIoU 替换 CIoU，进行损失函数相似性度量优化。改进 PTPM - YOLO v8 模型结构如图 3 所示。

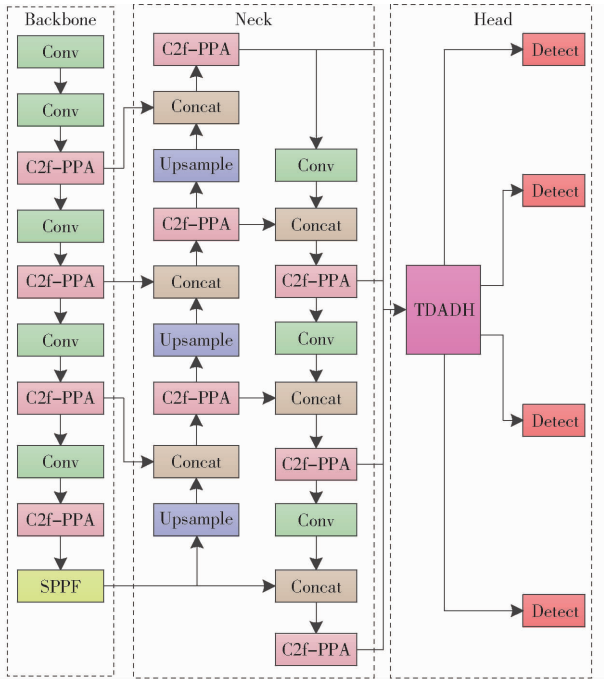

图 3　PTPM - YOLO v8 结构图

Fig. 3　PTPM - YOLO v8 structure diagram

2.2.1　C2f - PPA 结构

虽然肉牛体型较大、行动缓慢且易于识别，但该试验数据集中监控摄像头安装在牛舍的远景位置，距离较远，远景视角下肉牛所占像素较少且与本文识别的精细行为较为相似，不同行为间的区别集中于头部、蹄部和尾部等局部。针对以上问题，使

用并行化斑块感知模块[23]替换用于特征提取 C2f 模块中的 Bottleneck 模块,构建 C2f-PPA 结构,增强模型局部感知能力,如图 4 所示,其中 h 表示特征图高度,w 表示特征图宽度,c 表示通道数,p 表示补丁大小。

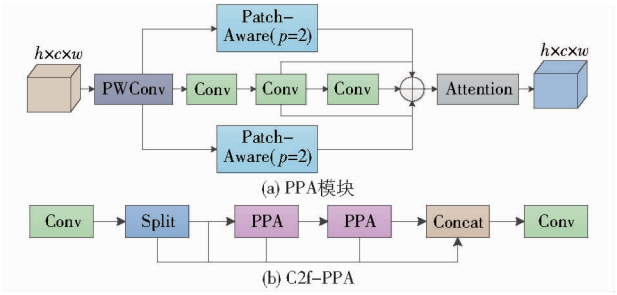

图 4 PPA 模块结构和 C2f-PPA 结构

Fig. 4 PPA module structure and C2f-PPA structure

PPA 模块采用多分支并行方法,包括局部分支、全局分支和串行卷积分支,每个分支负责提取不同规模和级别的特征。多分支特征提取后,利用一系列高效通道注意力和空间注意力构成的注意力模块进行特征加权整合和自适应特征增强。通过控制斑块参数 p 大小区别局部分支和全局分支,局部分支从特征张量中提取局部特征,使用较小的感受野和高分辨率特征图,以捕捉肉牛图像中精细行为间的微小变化;全局分支负责提取全局特征,采用较大的感受野和低分辨率特征图,以获取图像中的肉牛整体行为模式和背景信息;串行卷积分支通过多层卷积操作逐步提取和增强特征,并与其他分支特征融合。多分支并行处理不同尺度和级别的特征,确保有效地捕获到肉牛表面复杂花纹信息和行为细节,从而提高肉牛行为检测的准确性。

2.2.2 任务动态对齐检测头

牛舍养殖环境下,肉牛活动量较大,行为多变,而 YOLO v8 模型原有头部采用 2 个并行独立的分支完成定位和分类任务,导致模型无法准确定位肉牛行为。分类任务旨在学习肉牛行为的关键部分特征并区别,而定位任务致力于检测目标时精确定位肉牛整体及其边界。2 个任务分开完成,易导致远景视角下肉牛边界框回归与行为类别预测结果不一致,进而影响肉牛行为识别准确度。

受到任务无关目标检测[24]启发,在 YOLO v8 头部的基础上进行改进,采用交互策略将 2 个互相独立的分支进行交互处理,提出 TDADH 检测头,旨在远景视角下提高模型的性能。设计思路:通过 Conv 模块使用 2 个 3×3 卷积核提取肉牛行为特征,得到具有边界框回归和行为类别概率的交互特征。定位分支在任务拆解后引入可变形卷积(DCNv2)[25],使模型关注肉牛行为聚集区域,使用交互特征生成 DCNv2 所需的调制标量 Mask;分类分支在任务拆解后使用交互特征进行动态特征选择。最后,对特征进行动态缩放以应对每个检测头所检测目标尺度不同的挑战。TDADH 通过任务对齐结构,从多个卷积层中提取任务交互特征,优化分类和定位任务的协同。其结构如图 5 所示。

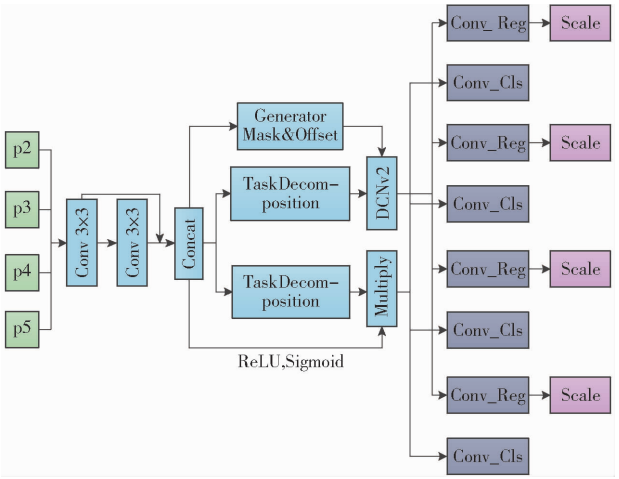

图 5 TDADH 检测头结构

Fig. 5 TDADH detection head structure

2.2.3 MPDIoU 损失函数

回归损失函数 IoU 表示预测框和真实框之间的重叠程度。YOLO v8 默认使用 CIoU 作为边界框回归损失函数,通过真实框和边界框的重叠面积、中心距离和长宽比,评估模型的预测框和真实框的不一致程度。但 CIoU 采用的长宽比是相对值,不适用于肉牛姿态变化的情景以及多行为识别过程中肉牛不同行为间局部特征分布不均的情况。为解决上述问题,本文引入 MPDIoU[26]作为损失函数,其为一种新型的基于最小点距离的边界框相似性度量。通过计算预测框和真实框的左上角和右下角点之间的最小距离,可有效地衡量 2 个宽高比不同矩形的几何相似性。计算公式为

$$MPDIoU = \frac{A \cap B}{A \cup B} - \frac{d_1^2}{w^2 + h^2} - \frac{d_2^2}{w^2 + h^2} \tag{1}$$

其中

$$d_1^2 = (x_1^B - x_1^A)^2 + (y_1^B - y_1^A)^2 \tag{2}$$

$$d_2^2 = (x_2^B - x_2^A)^2 + (y_2^B - y_2^A)^2 \tag{3}$$

式中 A、B——2 个任意图形

(x_1^A, y_1^A)、(x_2^A, y_2^A)——A 左上、右下点坐标

(x_1^B, y_1^B)、(x_2^B, y_2^B)——B 左上、右下点坐标

d_1、d_2——A、B 左上角点之间欧氏距离、右下角点之间欧氏距离

MPDIoU 损失函数简化了 2 个边界框之间的相似性比较,且综合考虑多种几何特性,提升了边界框定位精度和模型训练效果,可有效应对肉牛体型不一和不同行为间局部特征分布不均带来的挑战。

2.3　试验环境与评价指标

服务器硬件配置为 NVIDIA GeForce RTX 3090 显卡，AMD Ryzen 5 7600 下 6 - core 处理器，运行内存为 64 GB。试验在 Windows 10 操作系统环境下运行，试验平台为 Pycharm，编程语言为 Python 3.8，并配置运算平台 CUDA 12.1 和深度学习框架 pytorch 2.2.2。模型训练过程输入分辨率为 640 像素 × 640 像素的图像，初始学习率均设置为 0.01，图像批大小为 32，训练迭代次数设置为 200。采用精确率（Precision）、召回率（Recall）、平均精度均值（mAP@0.5）、参数量、浮点计算量和帧率（Frames per second，FPS）作为肉牛行为识别模型评价指标。

3　结果与分析

3.1　数据扩充对比试验

本试验肉牛行为识别任务所需检测的行为较多，存在数据集类别不平衡，通过数据扩充以期降低类别不平衡带来的影响。

为验证数据扩充在降低数据集类别不平衡方面的有效性，对比 YOLO v8n 在原始数据集和扩充后数据集上的肉牛行为识别结果，如表 2 所示，数据扩充后，样本数量多的基本行为（站立、躺卧、进食）平均精度均值（mAP@0.5）略微浮动。饮水行为，由于牛舍水槽较小且仅有 1 个，只能同时容纳 1 头或 2 头牛只同时饮水，饮水行为数量较少，扩充后精度进一步提升。同时，样本数量少的精细行为在数据扩充后明显提升。总体来看，与原始数据集相比，数据扩充后全部行为之间的识别精度差异更小。样本数量大的行为平均精度均值轻微浮动，而样本数量少的行为平均精度均值显著提升，缩小了不同行为间的识别效果差距，进而降低了类别不平衡带来的影响。

表 2　数据扩充前后对比试验

Tab.2　Comparison test before and after data expansion　%

行为类别		原始数据集	数据扩充后数据集
基本行为	站立	92.0	93.6
	躺卧	96.6	95.9
	进食	96.0	95.3
	饮水	89.1	94.2
精细行为	回舔	82.8	89.4
	行走	82.6	88.5
	探究	83.1	88.7
	甩尾	80.4	85.0

3.2　损失函数对比试验

为验证不同损失函数对模型识别效果的影响，对比常用损失函数（CIoU、DIoU、EIoU、SIoU 和 MPDIoU）在 YOLO v8n 收敛后的识别效果，结果如表 3 所示，采用 MPDIoU 后模型平均精度均值达到 92.7%，较其他损失函数都高，对比 YOLO v8n 原模型提高 1.3 个百分点。损失变化过程如图 6 所示，经过 200 次迭代，损失变化曲线逐渐趋于稳定，使用 CIoU、DIoU、EIoU、SIoU 和 MPDIoU 损失函数模型分别收敛于 0.963、0.916、0.995、0.927 和 0.913，未出现过拟合、欠拟合[27]等现象。采用 MPDIoU 损失函数不仅收敛速度快，且模型收敛后的边界框损失值较低。证明 MPDIoU 损失函数提高了模型的训练效果，可以有效应对肉牛体型不同和姿态变化带来的挑战。

表 3　不同 IoU 损失模型性能对比

Tab.3　Performance comparison of different IoU loss

损失函数	mAP@0.5/%
CIoU	91.3
DIoU	92.5
EIoU	92.5
SIoU	92.3
MPDIoU	92.7

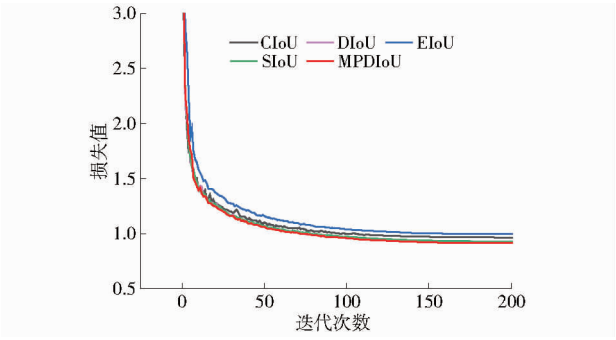

图 6　损失变化曲线

Fig.6　Loss variation curves

3.3　消融试验

为验证本文提出的基于 PTPM - YOLO v8n 的肉牛行为识别方法的有效性，设计了 8 组消融试验，使用相同的数据集进行训练，结果如表 4 所示。

相较于 YOLO v8n，添加小目标检测层 P2 后，平均精度均值提升 1.3 个百分点，浮点计算量提升至 1.2×10^{10}，分析原因是小目标检测层 YOLO v8 - P2 网络结构更为复杂，能够识别远景视角下的肉牛以及牛犊。使用 C2f - PPA 结构平均精度均值、召回率和精确率均有提升，这表明 C2f - PPA 结构在一定程度上捕捉到肉牛不同行为特征的微小变化，增强了模型的局部感知能力。融合小目标检测层 P2 和 TDADH 检测头后，平均精度均值提高至 93.8%，浮点计算量降低至 9.8×10^{9}，由此证明 TDADH 检测头不仅能有效降低模型的计算复杂度，而且适用

表 4 消融试验结果

Tab. 4 Results of ablation experiment

YOLO v8n	P2	C2f－PPA	TDADH	MPDIoU	准确率/%	召回率/%	mAP@0.5/%	参数量	浮点计算量	帧率/(f·s^{-1})
√					91.3	82.3	91.3	3.0×10^{6}	8.1×10^{9}	156.3
	√				91.2	84.5	92.6	2.9×10^{6}	1.2×10^{10}	153.8
√		√			91.5	84.8	92.8	3.4×10^{6}	9.1×10^{9}	137.0
√			√		91.0	85.5	93.0	1.7×10^{6}	5.2×10^{9}	179.5
√				√	91.3	84.6	92.6	3.0×10^{6}	8.1×10^{9}	163.9
√	√		√		90.9	87.5	93.8	1.8×10^{6}	9.8×10^{9}	144.9
√	√	√	√		91.8	87.4	94.1	2.3×10^{6}	1.2×10^{10}	140.8
√	√	√	√	√	91.0	87.9	94.3	2.3×10^{6}	1.2×10^{10}	148.9

注:√表示采用此模块。

于肉牛多行为识别任务,其通过定位和分类的任务交互,在定位肉牛整体的同时有效区分不同行为间的局部特征。在以上改进基础上,进行 MPDIoU 损失函数优化,模型平均精度均值最终达到 94.3%,参数量为 2.3×10^{6},浮点计算量为 1.2×10^{10},帧率为 148.9 f/s。本文 PTPM－YOLO v8n 与原 YOLO v8－P2 相比,虽然帧率有所降低,但平均精度均值、参数量和浮点计算量均优于 YOLO v8－P2。相较于 YOLO v8n 原模型,PTPM－YOLO v8n 平均精度均值提高 3.0 个百分点。原因是肉牛姿态变化会导致边界框发生形变,不同行为的边界框纵横比不同,如:肉牛回舔时,边界框纵横比变小;肉牛躺卧时,边界框纵横比变大。MPDIoU 损失函数在处理肉牛更为复杂的姿态变化时尤为有效。根据试验结果可知,本文模型在肉牛多行为识别任务中,模型精度提高效果明显,可以很好完成远景视角下精细行为较为相似且局部特征分布不均的肉牛多行为识别检测任务。

图 7(蓝色圆圈表示检测错误,红色圆圈表示检测正确)为 YOLO v8n 和 PTPM－YOLO v8n 在不同遮挡环境下的肉牛行为检测结果。由图 7 可以看出,无遮挡情况下 YOLO v8n 易识别错误肉牛行为,如图 7b 所示,将探究行为识别为站立行为,原因是精细行为的关键识别特征位于头部、蹄部和尾部等局部,不易识别。同样在大量枝叶遮挡严重情况下,YOLO v8n 检测性能更低,如图 7b 所示,将枝叶遮挡部分误判为躺卧肉牛。针对局部感知提出的 PTPM－YOLO v8n 能够解决 YOLO v8n 在精细行为识别上的局限性问题,准确识别所有行为(图 7c)。



图 7 模型检测效果对比

Fig. 7 Comparison of model detection results

3.4 行为精细化对比试验

回舔、行走、探究和甩尾 4 种精细行为均是从站立行为衍生而来,在基本行为数据集基础上构建包含有基本行为与精细行为的全部行为数据集。对比基本行为和全部行为在 YOLO v8n 和 PTPM－YOLO v8n 上收敛后的识别结果表现,结果如表 5 所示。

表 5 不同行为种类识别效果对比

Tab. 5 Comparison of recognition effect of different behavior categories %

模型	基本行为	全部行为
YOLO v8n	93.4	91.3
PTPM－YOLO v8n	95.8	94.3

改进后 PTPM－YOLO v8n 模型在识别 4 种基本行为和 8 种全部行为时,对比原 YOLO v8n,mAP@0.5 均有提升,表现优异,证明本文模型改进方法泛化能力较强,能够适应不同行为种类数量的肉牛行

为识别任务。但 YOLO v8n 和 PTPM－YOLO v8n 对 4 种基本行为的识别结果均高于模型对 8 种全部行为的识别结果，分析原因为精细行为之间的相似性较高且识别关键特征集中在肉牛局部，模型易混淆。只对肉牛 4 种基本行为进行识别，无法准确识别肉牛精细行为，不利于观察肉牛更为复杂的健康状态。后期随着 PTPM－YOLO v8n 模型改进，已缩小了基本行为和复杂行为间的识别差距。

3.5　肉牛行为识别结果

为验证本文模型对 8 种肉牛行为识别的有效性，将改进模型对站立、躺卧、进食、回舔、饮水、行走、探究和甩尾共 8 种行为进行识别，结果如表 6 所示。

表 6　不同行为识别结果

Tab. 6　Result of different behavior recognition　%

行为类别	精确率	召回率	mAP@0.5
站立	91.7	92.9	96.6
躺卧	97.6	96.1	98.2
进食	94.2	92.3	97.4
饮水	92.2	91.3	96.5
回舔	87.7	86.5	91.9
行走	89.6	80.5	91.7
探究	88.3	82.2	91.7
甩尾	86.5	81.3	90.2
全部行为	91.0	87.9	94.3

由表 6 可知，本文模型在所有行为中对躺卧行为识别平均精度均值最高（98.2%），其原因为躺卧行为是肉牛趴在地面上，而其余行为均是四蹄立于地面上，此行为与其余行为相似度较低，易于区分。在所有行为中，对甩尾行为识别的平均精度均值最低，原因是甩尾行为较为特殊，易与其他行为同时出现，同一头牛在出现甩尾行为的同时可能伴随其他行为。本文模型对基本行为识别平均精度均值普遍高于精细行为，原因为基本行为特征明显易于区分，而精细行为较为复杂相似且局部特征分别位于头部和蹄部等易重叠位置不易于识别。回舔、行走、探究和甩尾 4 种精细行为与站立行为较为相似，模型识别容易混淆。本文模型对回舔、行走、探究和甩尾 4 种行为识别平均精度均值分别为 91.9%、91.7%、91.7% 和 90.2%，虽然本文所提 PTPM－YOLO v8n 模型对精细行为识别精度略低于基本行为，但全部行为识别平均精度均值皆保持在 90% 以上，证明本文方法对肉牛行为识别的有效性。

3.6　不同网络试验结果

为验证 PTPM－YOLO v8n 肉牛行为识别效果，分别使用 Faster R－CNN[28]、RT－DETR、YOLO v3－tiny[29]、YOLO v5n、YOLO v7－tiny、YOLO v8n、YOLO v9t 和 YOLO v10n 等主流目标检测模型在肉牛行为数据集上进行训练，结果如表 7 所示。

表 7　不同模型试验结果

Tab. 7　Different model experiment results

模型	精确率/%	召回率/%	mAP@0.5/%	参数量	浮点计算量	帧率/(f·s^{-1})
Faster R－CNN	90.2	88.1	89.7	4.3×10^{7}	2.13×10^{11}	46.0
RT－DETR	90.4	85.9	87.8	4.2×10^{7}	1.26×10^{11}	51.6
YOLO v3－tiny	89.9	82.4	90.1	1.2×10^{7}	1.90×10^{10}	217.4
YOLO v5n	90.4	81.3	90.5	2.5×10^{6}	7.10×10^{9}	147.1
YOLO v7－tiny	90.1	83.1	90.7	6.0×10^{6}	1.30×10^{10}	74.6
YOLO v8n	91.3	82.3	91.3	3.0×10^{6}	8.10×10^{9}	156.3
YOLO v9t	87.8	80.5	89.4	2.0×10^{6}	7.60×10^{9}	91.7
YOLO v10n	87.4	80.8	88.7	2.7×10^{6}	8.20×10^{9}	142.9
PTPM－YOLO v8n	91.0	87.9	94.3	2.3×10^{6}	1.20×10^{10}	148.9

由表 7 可知，与两阶段目标检测模型 Faster R－CNN 和实时目标检测模型 RT－DETR 相比，YOLO 系列目标检测模型在肉牛行为识别任务上不仅识别精度高且较为轻量，说明 YOLO 系列目标检测模型更适用于本文的肉牛基本行为与精细行为识别任务。与之前版本的 YOLO v3－tiny、YOLO v5n 和 YOLO v7－tiny 等 YOLO 系列目标检测模型相比，PTPM－YOLO v8n 平均精度均值分别提升 4.2、3.8、3.6 个百分点。

对比最新 YOLO 模型 YOLO v9t 和 YOLO v10n，YOLO v9t 参数量最低，仅为 2.0×10^{6}，YOLO v8n 虽然参数量较高，但精确率、召回率、平均精度均值和帧率均高于 YOLO v9t 和 YOLO v10n；在 YOLO v8n 基础上改进的 PTPM－YOLO v8n 模型召回率和平均精度均值均最高，分别达到 87.9% 和 94.3%。与原模型 YOLO v8n 相比，PTPM－YOLO v8n 的 mAP@0.5 提高 3 个百分点，参数量下降 23.3%。结果表明，相较于其他目标检测模型，PTPM－YOLO v8n 在肉牛行为数据集上的识别效果最佳，验证了本文模型的优越性。

3.7 局部感知可视化试验

为了更直观地观察其中 C2f－PPA 结构在捕捉肉牛不同行为间局部特征变化的作用，本文采用 Layer－CAM 算法绘制模型添加 C2f－PPA 结构前后的热力图，对模型识别效果可视化。

由图 8 可知，仅使用 YOLO v8n 进行肉牛行为识别任务，热力图大多呈直柱状，特征提取较为分散（图 8b 左侧蓝色圆圈处）；而添加 C2f－PPA 结构后，热力图可基本勾勒出肉牛躯体形状，且模型提取的特征信息主要聚焦于肉牛四肢与颈部（图 8c 左侧红色圆圈处）。图 8b 右侧蓝色圆圈处存在肉牛行为漏检现象，而 YOLO v8n－C2f－PPA 能基本识别所有肉牛行为，降低了肉牛行为漏检概率，验证了 C2f－PPA 结构用于捕捉肉牛不同行为间局部特征变化的有效性。



(a) 原图 (b) YOLO v8n热力图 (c) YOLO v8n-C2f-PPA热力图

图 8 局部感知可视化对比

Fig. 8 Visual comparison of local perception

3.8 不同光照情况下识别效果

为验证本文提出的 PTPM－YOLO v8n 肉牛多行为识别方法的实用性，对不同光照情况下的肉牛行为识别效果进行测试。如图 9（蓝色圆圈表示误检，红色圆圈表示漏检）所示，RT－DETR、YOLO v7－tiny 和 YOLO v9t 在不同光照条件下会产生重叠框现象，即将同一肉牛行为识别为 2 种肉牛行为；Faster R－CNN、YOLO v3－tiny、YOLO v5n、YOLO v8n 和 YOLO v10n 易将不同光照条件下的精细行为误检；改进模型 PTPM－YOLO v8n 在光照不均、昏暗和黑暗 3 种光照条件下基本能准确识别 8 种肉牛行为。尤其在黑暗条件下，肉牛行为不易观察且精细行为间区别特征位于局部，PTPM－YOLO v8n 仍能识别该环境条件的肉牛行为。表明本文模型能够准确检测肉牛基本行为与精细行为，并且具有较好的识别能力。

3.9 近景视角下识别效果

为进一步测试 PTPM－YOLO v8n 在不同视角下的检测性能与泛化能力，使用安装于牛棚内部的摄像头采集近景视角下肉牛行为图像进行测试，并对比不同算法的识别效果，不同光照条件下近景视角肉牛行为识别效果如图 10 所示。

受摄像头安装位置影响，采集的近景图像中肉牛所占像素较大，相较于远景视角下的识别效果，近景视角下的肉牛行为检测框更大，易被识别，但受栏杆遮挡以及肉牛相互遮挡较为严重，RT－DETR、YOLO v3－tiny、YOLO v5n 和 YOLO v8n 重叠框现象较为严重；Faster R－CNN、YOLO v7－tiny 和 YOLO v10n 误检和漏检较多，不适用于遮挡严重的肉牛多行为检测任务。在牛棚遮阳板影响下，发现牛棚内部光线较暗，摄像头附近装有照明灯，随着时间变化，导致不同光照条件下采集的图像越发明亮 。由图 10 可知，PTPM－YOLO v8n 在近景视角下仍能准确识别肉牛基本行为与精细行为，受光照条件与遮挡程度影响较小，模型泛化性较强。

3.10 肉牛全天日常行为统计

为更好地观察与了解该试验牛舍肉牛日常行为习性，对肉牛行为识别数据进行统计与可视化。首先视频输入，通过 PTPM－YOLO v8n 模型统计每一帧中的肉牛行为数量，并在视频右上角显示统计结果，如图 11 所示。其次，设置阶段结果观测。每 10 min 以饼状图形式输出当前肉牛行为统计结果，如图 12a 所示。最后汇总全天肉牛行为变化趋势。将之前每 2 h 统计的结果保留，对牛舍 06:00—20:00 肉牛行为统计汇总，如图 12b 所示。

由图 11 可知，本文模型能够实现无遮挡环境和遮挡环境下的肉牛行为与总体数量统计，进而可以帮助农场主检测牛舍有无肉牛丢失。图 12a 为牛舍 06:00 的肉牛行为统计结果，早晨以站立行为居多，受昼夜节律和温度影响，牛群比较活跃。以饼状图形式输出统计结果，可更直观地观察肉牛群体当前阶段主要行为。最后，在图 12a 结果基础上，进行全天肉牛行为统计。发现进食行为受饲养者发放饲料时间限制，主要集中于早上和傍晚，躺卧行为主要集中于光照强度较高的中午和下午。而其他行为受肉牛主观因素影响较高，数量较少，不易于观察。通过肉牛行为识别结果统计，可更全面地观察肉牛群体全天日常行为，了解肉牛行为习性。

4 结论

（1）提出了基于改进 YOLO v8 的肉牛行为检测

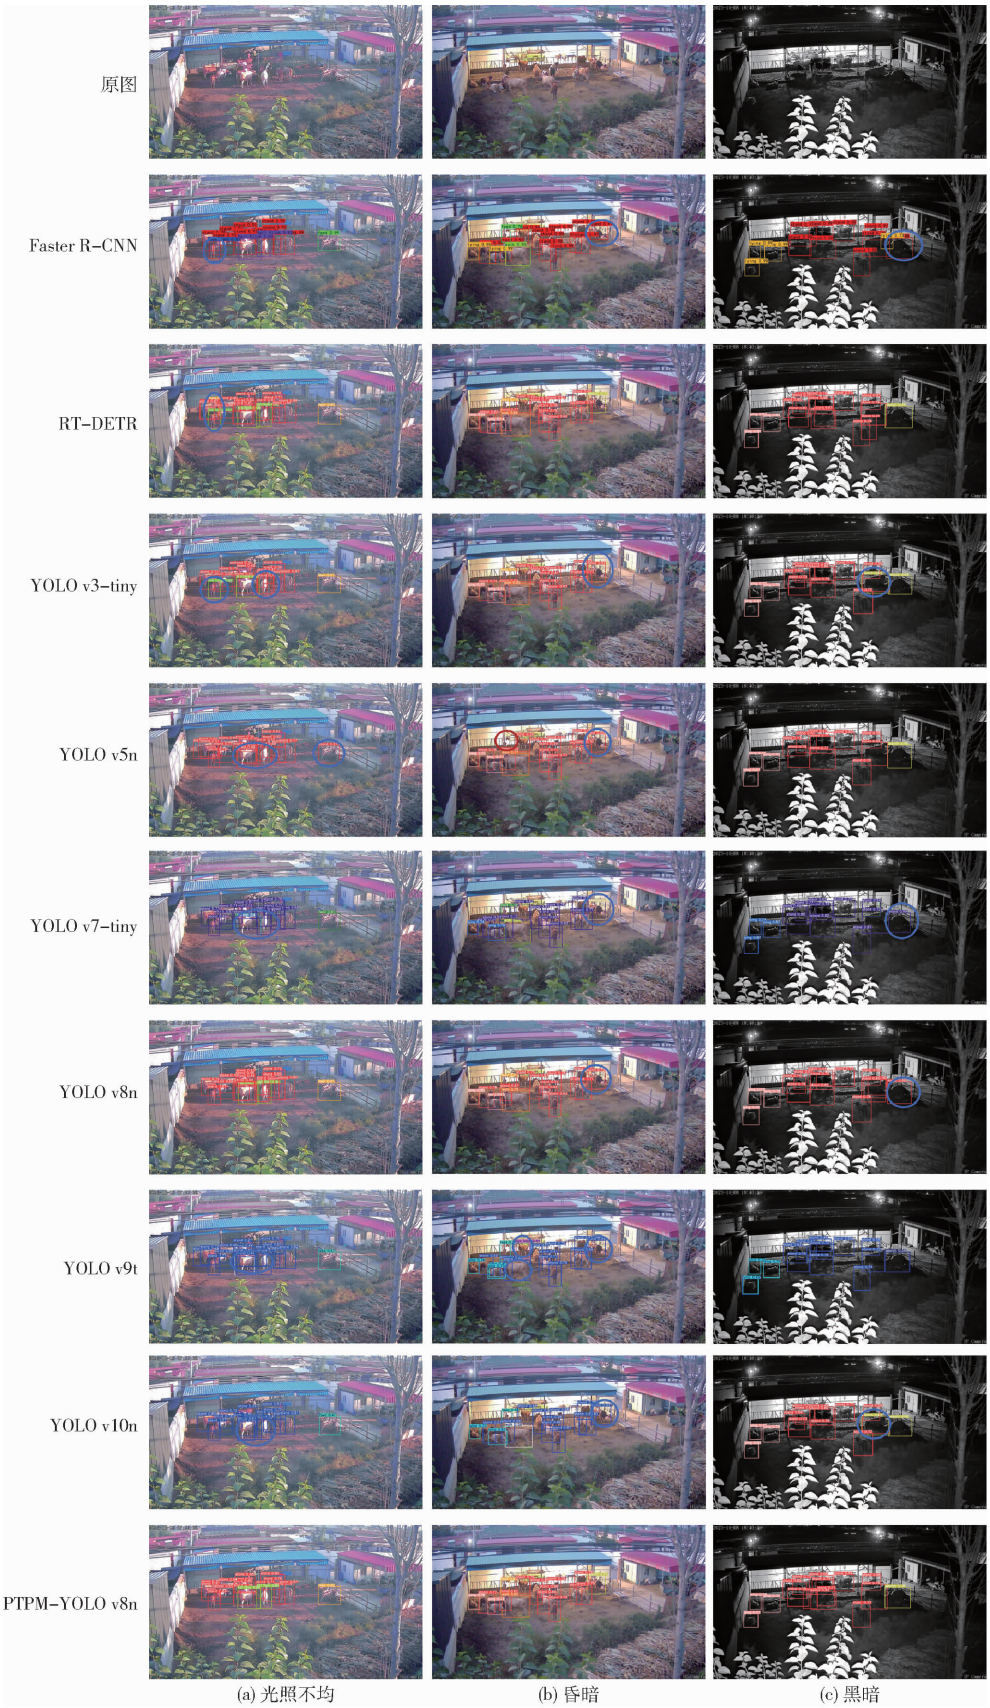

图 9　不同光照情况下肉牛行为识别效果

Fig. 9　Behavior recognition effect of beef cattle under different lighting conditions

与统计方法。PTPM－YOLO v8 能有效识别站立、躺卧、进食、饮水、回舔、行走、探究、甩尾共 8 种肉牛行为，试验结果表明，识别精确率、召回率和 mAP@0.5 分别为 91.0%、87.9% 和 94.3%。与原模型 YOLO v8n 相比，PTPM－YOLO v8n 的 mAP@0.5 提高 3 个百分点，参数量下降 23.3%。

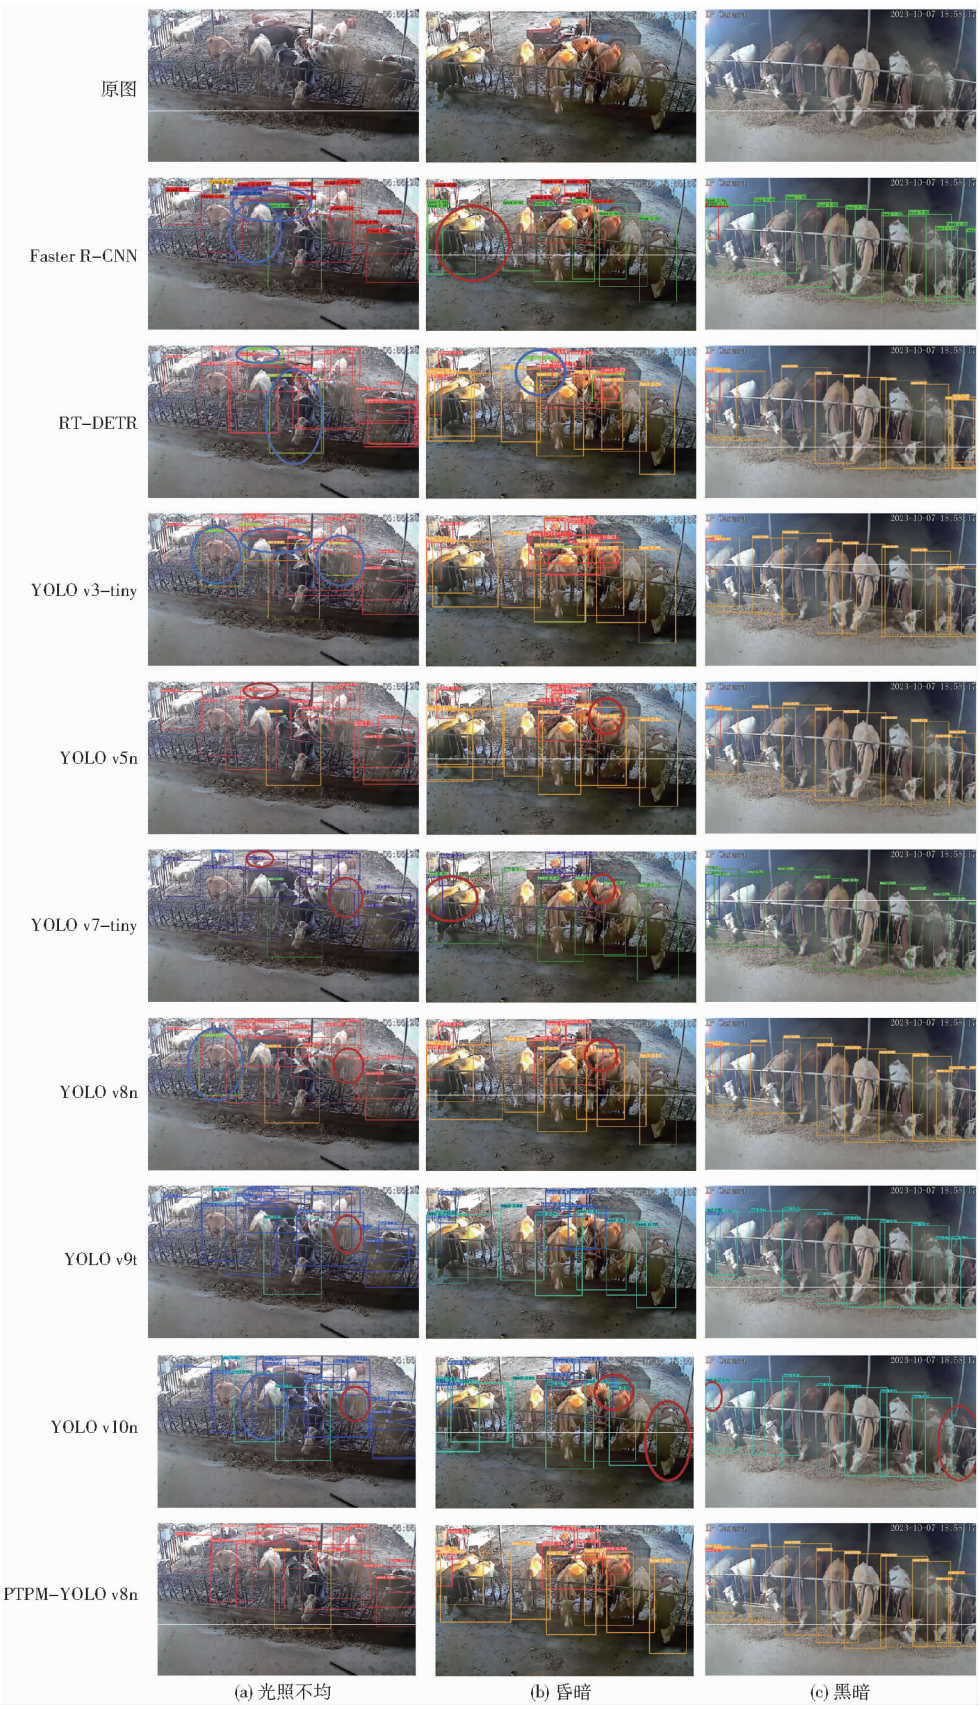

图 10 近景视角下肉牛行为识别效果

Fig. 10 Performance recognition of beef cattle behavior from a close-up perspective

(2)与 Faster R-CNN、RT-DETR、YOLO v3-tiny、YOLO v5n、YOLO v7n、YOLO v9t 和 YOLO v10n 在肉牛行为数据集上的识别效果对比,本文模型的 mAP@0.5 分别提高 4.6、6.5、4.2、3.8、3.6、4.9、5.6 个百分点。对比 PTPM-YOLO v8n 和 YOLO v8n 在基本行为数据集和全部行为数据集上的识别



(a) 无遮挡牛舍场景



(b) 遮挡牛舍场景

图 11　肉牛行为识别示例

Fig. 11　Example diagrams of cattle behavior

效果，结果表明，改进模型优于原模型。

(3)基于检测结果进行肉牛行为数量统计并进行图像可视化显示，以更直观方式观察肉牛行为习性。PTPM－YOLO v8n 能有效完成肉牛多行为检测与统计任务，识别牛舍环境下的基本行为与精细行为。

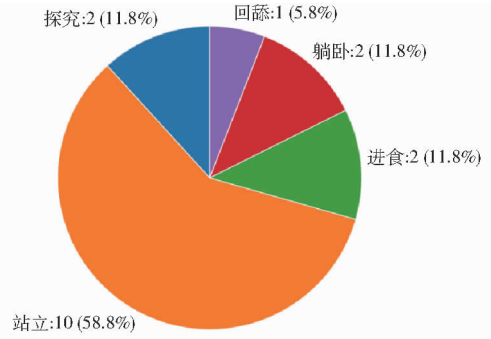

(a) 统计饼状图

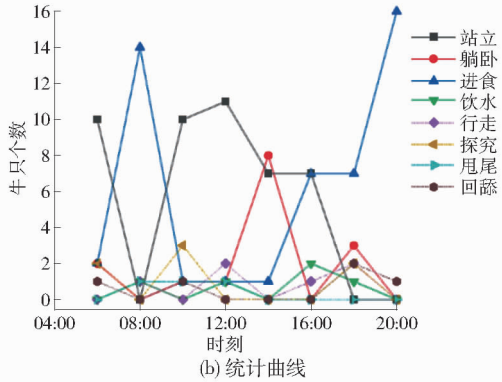

(b) 统计曲线

图 12　肉牛行为统计图

Fig. 12　Statistical charts of cattle behavior

参　考　文　献

[1] 许金奎. 肉牛养殖技术及饲养管理措施[J]. 中国畜牧业，2022(24)：69－70.

[2] 陈浩，王纯洁，斯木吉德，等. 牛肉品质及其影响因素研究进展[J]. 动物营养学报，2021，33(2)：669－678.
CHEN Hao, WANG Chunjie, SI Mujide, et al. Research progress of beef quality and its influencing factors[J]. Chinese Journal of Animal Nutrition, 2021, 33(2): 669－678. (in Chinese)

[3] YAZDANBAKHSH O, ZHOU Y, DICK S. An intelligent system for livestock disease surveillance[J]. Information Sciences, 2017, 100(378): 26－47.

[4] 张宏鸣，武杰，李永恒，等. 多目标肉牛进食行为识别方法研究[J]. 农业机械学报，2020，51(10)：259－267.
ZHANG Hongming, WU Jie, LI Yongheng, et al. Recognition method of feeding behavior of multi-target beef cattle[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(10): 259－267. (in Chinese)

[5] 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)

[6] 康熙，刘刚，初梦苑，等. 基于计算机视觉的奶牛生理参数监测与疾病诊断研究进展及挑战[J]. 智慧农业(中英文)，2022，4(2)：1－18.
KANG Xi, LIU Gang, CHU Mengyuan, et al. Research progress and challenges of physiological parameter monitoring and disease diagnosis of dairy cows based on computer vision[J]. Smart Agriculture, 2022, 4(2): 1－18. (in Chinese)

[7] WANG J, ZHANG H, JI J, et al. Development of a wireless measurement system for classifying cow behavior using accelerometer data and location data[J]. Applied Engineering in Agriculture, 2019, 35(2): 135－147.

[8] 任晓惠，刘刚，张淼，等. 基于支持向量机分类模型的奶牛行为识别方法[J]. 农业机械学报，2019，50(增刊)：290－296
REN Xiaohui, LIU Gang, ZHANG Miao, et al. Dairy cattle's behavior recognition method based on support vector machine classification model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(Supp.): 290－296. (in Chinese)

[9] 李丽华，刘志伟，赵学谦，等. 基于加速度传感器的本交笼种鸡个体行为监测与识别[J]. 农业机械学报，2019，50(12)：247－254.
LI Lihua, LIU Zhiwei, ZHAO Xueqian, et al. Monitoring and identification of natural mating cage breeding chickens individual behavior based on acceleration sensor[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(12): 247－254. (in Chinese)

[10] LI Y, SHU H, BINDELE J, et al. Classification and analysis of multiple cattle unitary behaviors and movements based on machine learning methods[J]. Animals, 2022, 12(9): 1060.

[11] HOSSEININOORBIN S, LAYEGHY S, KUSY B, et al. Deep learning-based cattle behaviour classification using joint time-frequency data representation[J]. Computers and Electronics in Agriculture, 2021, 187: 106241.

[12] PENG Y, KONDO N, FUJIURA T, et al. Classification of multiple cattle behavior patterns using a recurrent neural network with long short-term memory and inertial measurement units[J]. Computers and Electronics in Agriculture, 2019, 157: 247 - 253.

[13] 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. Dysfunctional 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)

[14] 刘月峰,边浩东,何滢婕,等. 基于幅值迭代剪枝的多目标奶牛进食行为识别方法[J]. 农业机械学报,2022,53(2):274 - 281.
LIU Yuefeng, BIAN Haodong, HE Yingjie, et al. Detection method of multi-objective cows feeding behavior based on iterative magnitude pruning[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(2): 274 - 281. (in Chinese)

[15] YU R, WEI X, LIU Y, et al. Research on automatic recognition of dairy cow daily behaviors based on deep learning[J]. Animals, 2024, 14(3): 458.

[16] WANG Z, HUA Z, WEN Y, et al. E - YOLO: recognition of estrus cow based on improved YOLOv8n model[J]. Expert Systems with Applications, 2024, 238: 122212.

[17] WANG R, GAO Z, LI Q, et al. Detection method of cow estrus behavior in natural scenes based on improved YOLO v5[J]. Agriculture, 2022, 12(9): 1339.

[18] 张宏鸣,李永恒,周利香,等. 基于改进 YOLO v3 的肉牛多目标骨架提取方法[J]. 农业机械学报,2022,53(3):285 - 293.
ZHANG Hongming, LI Yongheng, ZHOU Lixiang, et al. Multi-target skeleton extraction method of beef cattle based on improved YOLO v3[J]. Transactions of the Chinese Society for Agricultural Machinery, 2022, 53(3): 285 - 293. (in Chinese)

[19] LI Z, SONG L, DUAN Y, et al. Basic motion behaviour recognition of dairy cows based on skeleton and hybrid convolution algorithms[J]. Computers and Electronics in Agriculture, 2022, 196: 106889.

[20] 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 improved cattle behavior recognition and tracking based on YOLO v8[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(5): 290 - 301. (in Chinese)

[21] 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)

[22] 张宏鸣,孙扬,赵春平,等. 反刍家畜典型行为监测与生理状况识别方法研究综述[J]. 农业机械学报,2023,54(3):1 - 21.
ZHANG Hongming, SUN Yang, ZHAO Chunping, et al. Review on typical behavior monitoring and physiological condition identification methods for ruminant livestock[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(3): 1 - 21. (in Chinese)

[23] XU S, ZHENG S C, XU W, et al. HCF - Net: hierarchical context fusion network for infrared small object detection[J]. arXiv Preprint arXiv: 2403.10778, 2024.

[24] FENG C, ZHONG Y, GAO Y, et al. Tood: task-aligned one-stage object detection[C]// 2021 IEEE/CVF International Conference on Computer Vision (ICCV). IEEE Computer Society, 2021: 3490 - 3499.

[25] ZHU X, HU H, LIN S, et al. Deformable convnets v2: more deformable, better results[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 9308 - 9316.

[26] SILIANG M, YONG X. MPDIoU: a loss for efficient and accurate bounding box regression[J]. arXiv Preprint, arXiv: 2307.07662, 2023.

[27] 陈禹,吴雪梅,张珍,等. 基于改进 YOLOv5s 的自然环境下茶叶病害识别方法[J]. 农业工程学报,2023,39(24):185 - 194.
CHEN Yu, WU Xuemei, ZHANG Zhen, et al. Method for tea leaf disease recognition in natural environment based on improved YOLOv5s[J]. Transactions of the CSAE, 2023, 39(24): 185 - 194. (in Chinese)

[28] 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 and Machine Intelligence, 2016, 39(6): 1137 - 1149.

[29] LI H, DENG L, YANG C, et al. Enhanced YOLO v3 tiny network for real-time ship detection from visual image[J]. IEEE Access, 2021, 9: 16692 - 16706.