doi:10.6041/j.issn.1000-1298.2025.11.056

基于多任务学习的同步奶牛体况评分和个体识别方法

姜红花[1,2]　李金鸿[1,2]　法润萱[3]　张桂国[3]　毛文华[4]　乔永亮[5]

(1. 山东农业大学信息科学与工程学院, 泰安 271018; 2. 山东省高等学校智慧农业特色实验室, 泰安 271018;
3. 山东农业大学动物科技学院, 泰安 271018; 4. 中国农业机械化科学研究院集团有限公司, 北京 100083;
5. 阿德莱德大学机器学习研究所, 阿德莱德 SA5000)

摘要: 动物个体精细化管理与饲喂是现代牧业的关键需求,而在实际饲养环境中,基于传统机器视觉的奶牛体况评分和个体识别方法研究中仍存在模型鲁棒性低、可靠性较差、泛化性弱以及相互之间不能及时关联的问题。为此,提出了一种多任务学习模型,基于奶牛背部生物视觉特征来同步实现并优化奶牛体况评分和个体识别准确率。通过深度相机获取奶牛背部彩色图和深度图。改进 YOLO v8s 模型实现对奶牛背部区域自动定位和检测:在 YOLO v8s 网络中引入 GSConv 模块,减少网络参数同时也降低网络结构复杂性;采用加权交并比边界损失(Weighted Intersection over Union,WIoU)为边界框损失,提高模型识别准确率。在奶牛背部区域检测基础上,进一步提取奶牛背部区域生物视觉特征,基于奶牛体况评分和个体识别任务之间的共性特征,构建基于硬参数共享的多任务学习模型,同步实现牛只个体身份识别和体况得分评估。试验结果表明,本文模型对体况评分和个体身份识别的准确率为 93.9% 和 92.2%,较单一任务模型分别提高 1.9、4.5 个百分点;识别用时为 5.84 ms,较单一任务模型同时完成两个任务所需时间减少 6.37 ms,实时性明显提高。本文模型实现了体况得分和个体编号的高效精准同步输出,可为奶牛规模化智慧养殖的个体精准化管理提供理论依据与技术支撑。

关键词: 多任务学习; RGB-D; 奶牛检测; 生物视觉信息; 体况评分; 身份识别

中图分类号: S823　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)11-0581-09　　**OSID**:

Multi-task Learning-based Method for Simultaneous Dairy Cow Body Condition Scoring and Individual Identification

JIANG Honghua[1,2]　LI Jinhong[1,2]　FA Runxuan[3]　ZHANG Guiguo[3]　MAO Wenhua[4]　QIAO Yongliang[5]

(1. *School of Information Science and Engineering*, *Shandong Agricultural University*, *Taian* 271018, *China*
2. *Smart Agriculture Characteristic Laboratory of Colleges and Universities in Shandong Province*, *Taian* 271018, *China*
3. *College of Animal Science and Technology*, *Shandong Agricultural University*, *Taian* 271018, *China*
4. *Chinese Academy of Agricultural Mechanization Sciences Group Co., Ltd.*, *Beijing* 100083, *China*
5. *Institute for Machine Learning*, *The University of Adelaide*, *Adelaide SA*5000, *Australia*)

Abstract: Precision breeding in animal husbandry is a crucial requirement of modern husbandry. However, there are still some issues in the research of cow body condition scoring and individual identification methods based on traditional machine vision in the actual feeding environment. These issues included low robustness, poor reliability, weak generalization, and timely correlation between multi-tasks. To address these challenges, a multi-task learning model was proposed based on the biological visual features of the back of cows to implement and optimize the body condition scoring and individual identification model of cows. Firstly, a depth camera was used to obtain the back image of the cow. Secondly, improvements were made to the YOLO v8s model to achieve automatic positioning and detection of the back area of cows. The GSConv module was introduced into the YOLO v8s network to reduce network parameters and simplify its structure. Additionally, weighted intersection over union loss was utilized as bounding box loss to enhance recognition accuracy. Based on detecting the back region of cows, further extraction was conducted on their biological visual features from this region. Finally, a

收稿日期: 2024-07-08　修回日期: 2024-07-28

基金项目: 山东省重点研发计划项目(2022TZXD0018)

作者简介: 姜红花(1971—),女,教授,博士,主要从事物联网与自动控制研究,E-mail: j_honghua@sdau.edu.cn

通信作者: 乔永亮(1988—),男,研究员,博士,主要从事农业机器人和人工智能和智能感知研究,E-mail: yongliang.qiao@ieee.org

multi-task learning model based on hard parameter sharing was constructed to simultaneously realize individual identification and body condition score evaluation of cows, leveraging the common features between cow body condition scoring and individual recognition tasks. The experimental results demonstrated that the proposed multi-task learning model achieved an accuracy of 93.9% for body condition scoring and 92.2% for individual identification, which was 1.9 and 4.5 percentage points higher than that of the single task model, respectively. Furthermore, the recognition time was reduced to 5.84 ms, which was 6.37 ms less than the time required by the single task model to complete two tasks at once, resulting in significantly improved real-time performance. In conclusion, a multi-task learning model was presented based on the biological visual features of the back region of cows, enabling efficient and accurate output of body condition score and individual identification simultaneously. The research result can provide a theoretical basis and technical support for precise individual management in large-scale intelligent breeding of dairy cows.

Key words: multi-task learning; RGB - D; dairy cow detection; biological visual information; body condition score; individual identification

0 引言

奶牛规模化养殖趋向于精准化、智慧化,其中体况评分(Body condition score, BCS)和个体识别(Individual identification)是实现奶牛高质量智慧养殖的关键[1]。体况评分能够科学且精准地反映动物个体能量储备水平,帮助养殖者监测牛只健康状况[2]、预测牛只生产性能[3]、保障动物福利以及评估饲养管理水平[4]。而个体识别有助于养殖者将每头奶牛的生长记录、健康状况、生产性能等信息与个体相关联,为科学养殖提供有力支持。

在奶牛体况评分的相关研究中,大多数学者采用2D或3D深度相机获取包含脊椎、尾根、骶骨韧带等骨骼结构特征的奶牛背部图像,实现体况评分[5]。赵凯旋等[6]提出了一种基于奶牛后驱点云凸包特征的评分方法,通过提取体况有关视觉特征(凸包度、轮廓边缘、曲面曲率等),构建了基于EfficientNet的分类模型,体况分类准确率为73.12%。HUANG等[7]基于Faster R-CNN目标检测模型对奶牛尾部检测并评估体况评分,牛尾检测准确率达到84%,BCS分类平均准确率为71%。SUN等[8]使用3D传感器获取奶牛背部三维图像,通过训练深度学习网络模型,实现奶牛体况评分的自动检测。

传统奶牛个体识别常采用耳标或项圈等方式,其工作量大、成本高、易引起奶牛应激反应,此外身份信息会随着耳标、项圈的丢失或损坏而丢失[9]。基于计算机视觉的个体识别,采用2D或3D深度相机获取奶牛图像信息,通过提取身份有关视觉特征(颜色、纹理、斑点、形状等),实现无接触的身份识别[10]。XIAO等[11]提出了一种基于改进的Mask R-CNN和SVM组合的方法,通过提取奶牛背部图案特征,在牛舍环境中实现了个体奶牛识别。QIAO等[12]通过采集的肉牛俯视图,利用BiLSTM模型实现牛只个体身份识别,准确率达到91%。何东健等[13]采集奶牛背部图像,利用YOLO v3模型识别奶牛个体,准确率为95.91%。

虽然基于机器学习和计算机视觉技术等非接触式的体况评分和身份识别方法正逐步发展[14-15],但大多数是基于奶牛背部区域的单一任务研究,无法同时获取奶牛身份和体况信息,影响二者的实时关联,难以在智慧养殖系统中发挥更高的效率。奶牛背部区域的特征信息对个体身份识别和体况评分均意义重大,而多任务学习能够更好地利用任务间的相关性,通过同时学习多个任务并共享相关信息,从而提高整体的学习效率和检测性能[16]。因此,本文提出一种基于多任务学习的奶牛体况评分和个体识别分类方法。使用3D深度相机采集奶牛背部图像,构建基于改进YOLO v8s的目标检测模型实现对奶牛背部区域的初步定位;基于奶牛背部RGB图和深度图,提取奶牛背部生物视觉特征;基于奶牛体况和个体身份的共性特征,构建基于硬参数共享[17]的多任务学习模型,通过多任务学习机制,模型参数之间能够相互优化和补充,从而提高奶牛体况评分和个体识别的准确率,以期为实时监测奶牛个体体况信息提供技术支持。

1 基于多任务学习的体况评分和个体识别方法

本文所提基于多任务学习的体况评分和个体识别方法,主要由基于改进YOLO v8s的奶牛背部区域检测和基于硬参数共享的多任务学习两大部分构成,实现流程如图1所示。

(1)奶牛背部区域检测:通过改进的YOLO v8s模型,在RGB图像上精确地识别并标注出奶牛背部区域;基于检测框的坐标信息,进一步在对应的深度

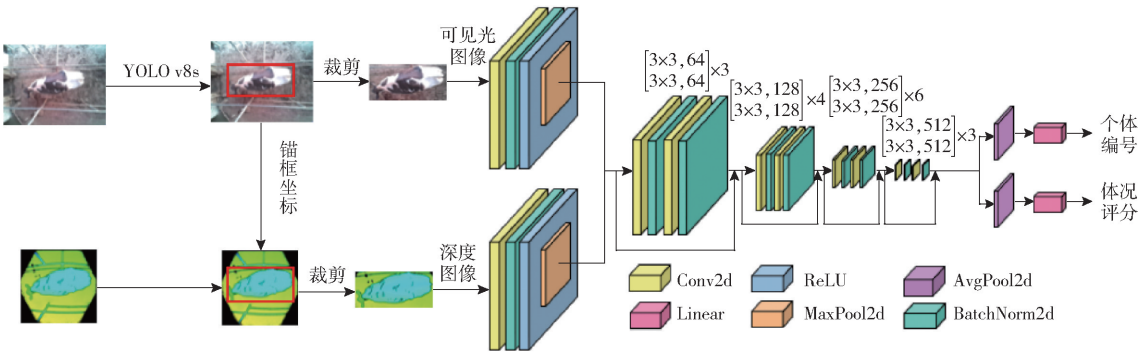


图 1　奶牛体况评分和个体识别流程

Fig. 1　Flowchart for dairy cow BCS and individual identification

图像上定位出相应的奶牛背部深度区域，从而得到奶牛背部区域的 RGB－D 图。

（2）基于硬参数共享的多任务学习：以 ResNet34 网络为基础主干网络，分别从奶牛背部区域的 RGB 图像和深度图像中提取关键生物视觉特征并进行融合，随后基于硬共享机制分别为体况评分和个体识别 2 个任务设计各自独立的特定分支输出，在实现任务间参数共享的同时又保持各自任务的独立性，增强了模型的学习能力和辨识性能，提高了体况评分和个体识别的准确率，可更有效地评估奶牛个体的健康状况。

1.1　基于改进 YOLO v8s 的奶牛背部区域检测

YOLO v8 是一种单阶段的目标检测算法，主要包括 4 部分：输入端（Input）、主干网络（Backbone）、颈部网络（Neck）和头部网络（Head）。输入端以原始图像作为输入，并对输入图像进行缩放、归一化、裁剪等预处理操作，以便于模型能够正确地处理图像信息。主干网络：对数据进行特征提取，供后续的目标检测任务使用。主干网络中的主要结构包含 CBS 模块、C2f 模块、SPPF[18] 模块。其中 CBS 模块是主干网络的主要组成部分，实现对输入特征的转换和提取；C2f 模块主要负责将深层特征与浅层特征进行融合；SPPF 模块旨在增强 YOLO v8 学习特征的能力。颈部网络遵循路径聚合网络[19]（Path aggregation network，PAN）和特征金字塔[20]（Feature pyramid network，FPN）的设计理念，有效地聚合信息。头部网络使用任务对齐分配器进行正负样本匹配，使用不同大小的下采样特征，以实现对小型、中型和大型目标的多尺度准确预测。

YOLO v8 模型采用 CIoU[21]（Complete intersection over union）作为边界框回归的损失函数。CIoU 相较原始 IoU，需额外计算中心点间距和长宽比，计算量的增加及低质量实例对几何因素的影响，降低了模型的鲁棒性。在规模化复杂养殖环境中，YOLO v8 模型计算复杂度高、推理时间长、内存占用量大，难以实时部署。

针对上述问题，本文提出基于改进 YOLO v8s 的奶牛背部区域检测模型，如图 2 所示（改进模块用红框标出），采用 WIoU[22] 作为边界框回归损失函数，提高模型数据利用率和鲁棒性；引入 GSConv 卷积和 Slim－Neck 方法[23]，以提高模型检测速度。

（1）WIoU 损失函数

在目标检测中，边界框损失是目标定位损失中的关键部分，为改善 YOLO v8s 模型中 CIoU 边界框损失函数计算复杂度高、鲁棒性差的问题，采用 WIoU 作为边界框损失函数，在计算过程中使用动态非单调机制和合理的梯度增益分配策略，以减少极端实例对模型训练的影响，有效提高模型鲁棒性、数据利用率和检测性能。

（2）GSConv 轻量化模块

为实现实时检测要求，需对模型进行轻量化设计，减少模型计算量。通过在 YOLO v8s 模型主干网络中引入 GSConv 卷积，在颈部网络中引入 VoV－GSCSP 模块，实现了在保持模型高精度的同时，减少了网络参数量。

1.2　基于硬参数共享的多任务学习模型

多任务学习（Multi-task learning，MTL），利用不同任务之间的共享信息，提升模型的整体性能，从而取得比单任务学习更好的效果[24]。多任务学习的共享机制包括硬参数共享和软参数共享。硬参数共享模式，是通过参数共享减少参数规模，降低计算成本，促进不同任务间的知识迁移和互补，适用于任务间相似性较高，能够共享底层特征的情况。而软参数共享模式则允许每个任务拥有独立的模型结构和特定参数，适用于任务之间特征表示差异较大、每个任务都需要学习特定特征的场景。奶牛体况评分和个体识别均依赖背部生物视觉特征，可共享底层特征，因此本文采用基于硬参数共享的多任务学习模型，以降低计算量，满足实时性要求。

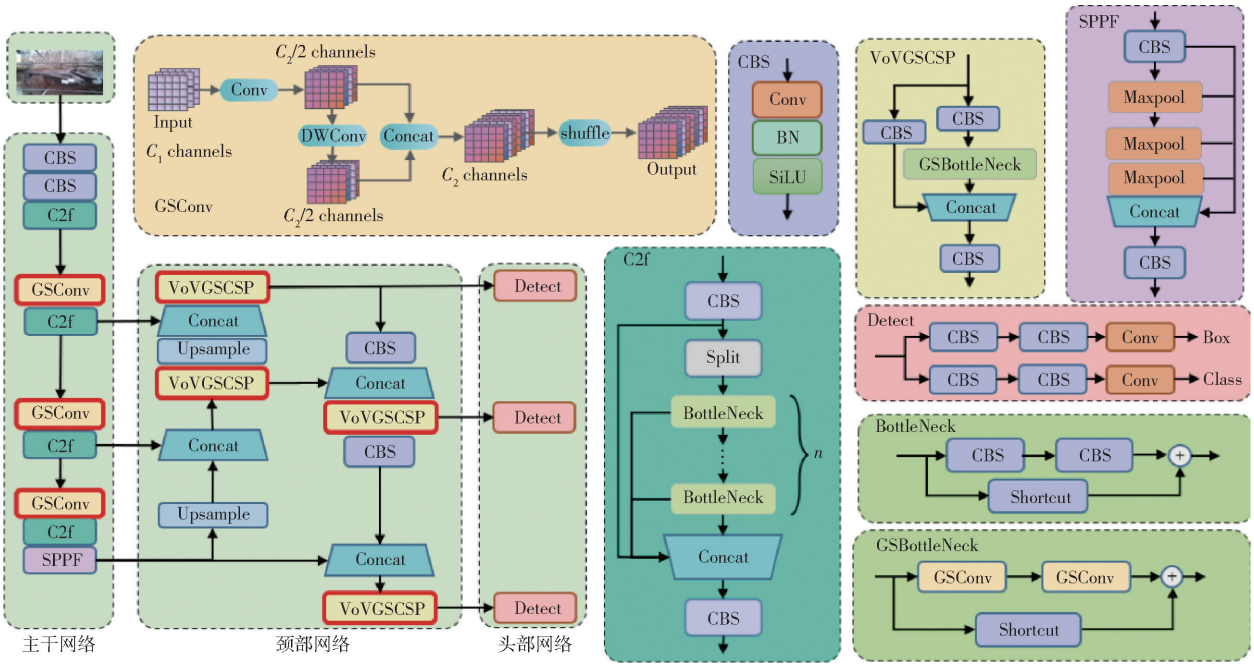


图 2 改进 YOLO v8s 网络结构图

Fig. 2 Network structure diagram of improved YOLO v8s

ResNet 是一种常用的特征提取网络[25]，特征提取效果优异且网络结构相对简单，因此本文以 ResNet34 网络为基础主干网络搭建多任务学习模型(简称为 RGBD－MTL)，如图 3 所示，输入深度图像和可见光图像的同时，提取出各自对应的特征图，通过 Concat 特征融合提取共同特征，作为后续深层级特征提取的输入。将深层级特征输入到对应任务的特征提取层中，以确保能够捕获到与任务最相关的特征信息。在特征提取过程中，通过跳层连接(Skip connection)的方式，允许低层级的特征信息跳过部分卷积层，与高层特征相加，形成残差连接。这种结构使得网络可以学习输入与输出之间的残差映射，在提取高层级特征的同时保留低层级特征，从而获取更加丰富的奶牛背部生物视觉特征，为后续体况评分和个体身份识别提供信息支撑。残差单元函数为

$$y = F(x) + x$$

式中 x——低层级特征

$F(x)$——高层级特征

y——残差映射

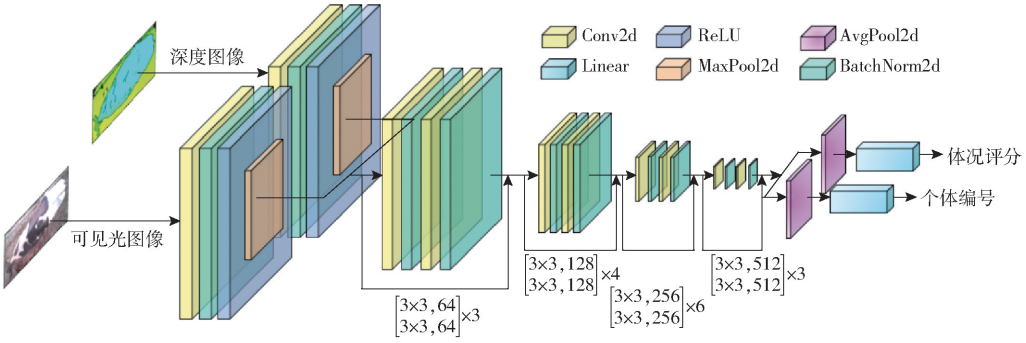


图 3 基于 RGB－D 特征融合的多任务学习模型

Fig. 3 Multi-task learning model based on RGB－D feature fusion

2 试验

2.1 数据采集与处理

所采集图像数据来自山东省泰安市一大型奶牛养殖场，该场共饲养奶牛 1 000 头以上，主要以荷斯坦奶牛为主。选用 Microsoft Kinect Azure DK 型相机，可同时采集彩色图像和对应的深度图像，能够全面捕捉奶牛的多维度信息。相机安装在奶牛挤奶必经通道上方，距地面 2.7 m，以俯视角度拍摄奶牛经过时的画面。拍摄时间选择 2023 年 5—7 月 05:00—07:00 及 21:00—23:00 两个时段进行拍摄，数据采集平台如图 4 所示。

以 Visual Studio 2017 为开发平台并基于 Azure Kinect SDK v1.4.1 进行奶牛背部深度视频处理，将

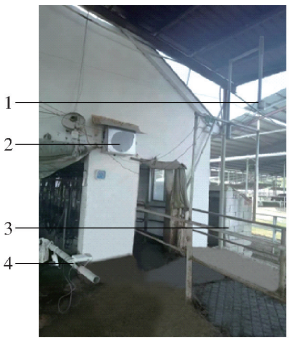
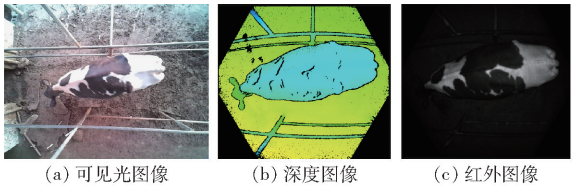


图 4　奶牛数据采集平台

Fig. 4　Data acquisition platform for dairy cows

1. 俯视相机　2. 工控机　3. 挤奶通道　4. 侧视相机

视频拆分为可见光图像、深度图像及红外图像，如图 5 所示。使用均值哈希算法删除相似度大于 60% 的图像，共选出包含 72 头奶牛的图像数据 2 048 幅。



(a) 可见光图像　(b) 深度图像　(c) 红外图像

图 5　数据样本

Fig. 5　Data samples

2.1.1　目标检测数据集构建

使用 LabelImg 数据标注软件，分别在 2 048 幅图像中绘制出完全包裹奶牛目标的矩形框，以比例 3∶1 划分为训练集、验证集，构建 YOLO 格式的图像和标签文件目标检测数据集。

2.1.2　多任务分类数据集构建

本文建立的多任务分类数据集包括奶牛背部图像，以及对应的个体编号、体况评分文本标签 2 部分。其中，奶牛背部图像数据是通过对 2 048 幅图像进行裁剪，确保每幅图像中仅包含 1 头奶牛；个体编号数据来源于奶牛佩戴的射频识别设备，根据时间戳对奶牛图像和个体编号进行匹配；体况评分数据由 2 名资深员工共同讨论确定，使用 5 分制评分标准[26-27]（评分以 0.25 为单位递增，从 1 分极度消瘦到 5 分过度肥胖）。由于畜牧场过于肥胖和过于消瘦的奶牛较少，大多奶牛体况分布在 3 ~ 4 分之间，极端体况的奶牛数据有限。但在商业情况下，极端体况在养殖场属于特例，通过对 3 ~ 4 分体况奶牛的研究，能够更好地分析奶牛的营养需求和健康状态，在商业生产中仍有实际应用价值，因此，本文选用体况分别为 3、3.25、3.5、3.75、4 分，共计 5 种类型的标签构建数据集，以比例 3∶1 划分为训练集、验证集，为保证各类数据的数据量在同一水平，对训练集根据不同数量类别进行数据增强，增强后数据集各类图像数量如表 1 所示。

表 1　不同 BCS 对应的数据集图像数量分布

Tab. 1　Image distribution of data sets corresponding to different BCS values

数据集	体况评分/分				
	3	3.25	3.5	3.75	4
训练集	144	339	893	218	98
验证集	28	112	296	72	4

2.2　训练环境与网络参数

试验软件环境为 Windows 10 专业版，编译环境为 PyCharm Community，使用 Python 作为编程语言，PyTorch 框架版本 1.10.0，CUDA 版本 11.3。硬件方面，服务器 CPU 为 Intel i7 - 11700 2.5 GHz，内存 16 GB；GPU 为 GeForceGTX1080Ti，显存 11 GB。

目标检测模型使用 Adam 优化器进行优化，批量大小为 16，迭代次数为 200，学习率为 0.000 1，采用早停策略（Early stopping），当模型在验证集上的性能连续迭代 50 次未提升时自动停止训练，以有效避免过拟合。多任务学习模型批量大小为 8，迭代次数为 200，2 个任务均使用交叉熵损失。为保证 2 个任务的平等性，在训练过程中同时优化，因此在计算最终损失时，采用权重 1∶1 对 2 个任务的损失进行加权求和。

2.3　评价指标

评价指标聚焦于机器学习中的混淆矩阵，旨在通过对比奶牛背部区域检测模型和多任务学习模型各自的预测结果与真实标签，精确地量化这 2 个模型的性能。混淆矩阵是一个用于展示模型分类结果的矩阵。矩阵包含 4 个基本指标，分别为真正类（True positive，TP）、假负类（False negative，FN）、假正类（False positive，FP）和真负类（True negative，TN）。以混淆矩阵的 4 个基本指标为基础衍生出多种性能评价指标：精确率（Precision，P）、召回率（Recall，R）、准确率（Accuracy，Acc）、F1 分数（F1 score）、平均精度（Average precision，AP）、平均精度均值（mean Average Precision，mAP）。除源自混淆矩阵的指标外，使用检测时间作为反映模型效率的指标，即单次预测所需的平均时长。

3　结果与分析

3.1　奶牛背部区域检测模型结果

为评价改进 YOLO v8s 模型的检测效果，本文使用 YOLO v5s、YOLO v6s、YOLO v7、Faster R - CNN、SSD 3 种主流模型在同一环境下对奶牛目标检测数据集进行训练和测试。由表 2 可知，单独引入 GSConv 模块后，在平均精度均值不变的情况下，模型浮点运算量下降 4.2×10^9；单独引入 WIoU 后

表 2 模型性能综合评价

Tab. 2 Comprehensive evaluation of model performance

模型	F1 分数/%	平均精度均值/%	浮点运算量	参数量	模型内存占用量/MB
Faster R - CNN	73.00	94.93	1.779×10^{11}	4.11×10^{7}	108.00
SSD	87.00	93.42	1.733×10^{11}	3.19×10^{7}	90.60
YOLO v5s	92.10	93.70	1.580×10^{10}	7.01×10^{6}	13.70
YOLO v6s	89.99	94.90	4.400×10^{10}	1.62×10^{7}	32.80
YOLO v7	91.03	90.60	1.051×10^{11}	3.71×10^{7}	74.80
YOLO v8s	92.10	95.40	2.840×10^{10}	1.11×10^{7}	21.40
YOLO v8s - GSConv	92.39	95.40	2.420×10^{10}	9.87×10^{6}	19.10
YOLO v8s - WIoU	92.87	95.10	2.840×10^{10}	1.11×10^{7}	21.40
YOLO v8s - GSConv - WIoU	92.30	96.40	2.420×10^{10}	9.87×10^{6}	19.10

平均精度均值有一定下降,但 F1 分数提升 0.77 个百分点;使用 GSConv 模块和 WIoU 共同优化,F1 分数基本不变,平均精度均值提高 1 个百分点,表明 WIoU 提供了更准确的度量方法,从而更有效地去除重叠度较高的冗余预测框,有效提高模型数据利用率;同时添加 GSConv 和 WIoU 模块的 YOLO v8s 模型,平均精度均值达到 96.4%,相较 Faster R - CNN、SSD、YOLO v5s、YOLO v6s 和 YOLO v7 分别提升 1.47、2.98、2.7、1.5、5.8 个百分点,尽管相较 YOLO v5s 参数量有所增加,但性能上的提升充分证明了优化措施的有效性,有助于更准确地完成目标检测任务。结果证明,本文改进模型能够在保证精度损失较少的同时,降低模型的参数量和浮点运算量,提高了综合性能。

为更直观地展示本文模型在目标检测方面的性能,选取白天和黑夜环境下,单头与多头奶牛通过挤奶通道的图像,展示其目标检测结果,如图 6 所示。其中,红色框表示模型的预测框,绿色框表示真实的标注框。尽管 YOLO v8s 在大多情况下表现良好,但仍有部分误检情况出现。其主要原因在于,奶牛身上的黑色花纹与背景颜色相近导致模型难以准确界定目标边界;而在黑夜环境中,由于光照条件的影响,图像质量较差,模型在目标检测过程中同样出现了定位不准的情况。从图看出,改进模型能够更好地处理光照变化对图像质量的影响,准确提取并识别奶牛特征,从而实现了更精确的目标框定位。

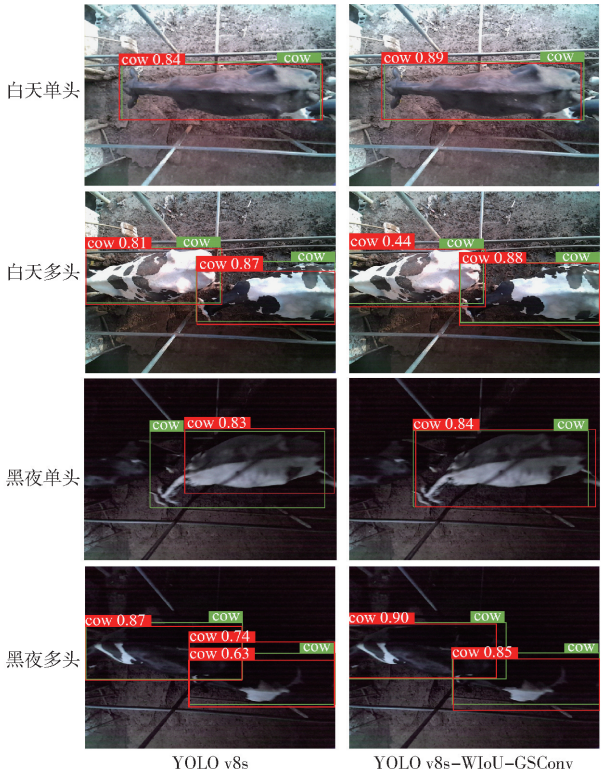


图 6 YOLO v8s 和 YOLO v8s - WIoU - GSConv 目标检测效果

Fig. 6 YOLO v8s and YOLO v8s - WIoU - GSConv object detection results

3.2 多任务学习模型试验结果

为验证所提 RGBD - MTL 模型的有效性,设计了 3 个模型进行比较,包括仅依赖 RGB 图像数据进行单任务预测的 ResNet34 网络模型(RGB - ResNet34)、基于 RGBD 数据的 ResNet 单任务学习模型(RGBD - ResNet34)、以及基于 RGB 数据的多任务学习模型(RGB - MTL),结果如表 3 所示。

表 3 不同分类方法对比

Tab. 3 Comparison of different classification methods

任务	精确率/%				检测时间/ms			
	单任务学习		多任务学习		单任务学习		多任务学习	
	RGB - ResNet34	RGBD - ResNet34	RGB - MTL	RGBD - MTL	RGB - ResNet34	RGBD - ResNet34	RGB - MTL	RGBD - MTL
个体识别	87.70	89.90	87.50	92.20	6.96	9.50	5.43	5.84
体况评分	92.00	91.60	93.10	93.90	5.25	7.58		

由表 3 可知，所提多任务学习模型获得了相较于单任务学习模型更高的精确率和更快的检测速度。在个体识别任务方面，较单任务学习模型 RGB－ResNet34 和 RGBD－ResNet34 的精确率分别提升 4.5、2.3 个百分点；体况评分方面，较单任务学习模型 RGB－ResNet34 的精确率提升 1.9 个百分点；在识别用时方面，多任务学习模型同时完成 2 个任务所需的检测时间比单一任务模型 RGB－ResNet34 完成全部任务时间减少 6.37 ms。结果表明，本文构建的多任务学习模型，通过共享不同任务之间的信息，能够更有效地学习数据内在特征，提高模型的泛化能力，高效地完成奶牛个体识别和体况评分任务。

为进一步了解多任务学习模型对各类体况评的详细分类情况，列出了如图 7 所示的多任务学习模型的混淆矩阵。图 7 表明模型在多个体况评分类别中均表现出了较好的分类能力，展现了模型的稳定性。

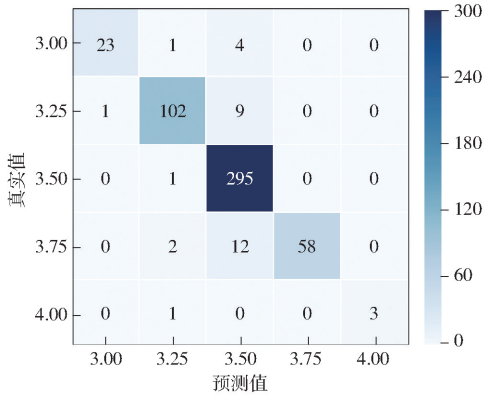
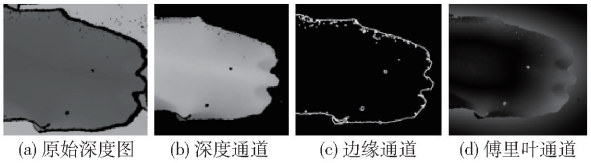


图 7　体况评分分类结果

Fig. 7　Classification results of body condition score

为进一步说明本文方法的可行性和有效性，本研究选择并复现 ALVAREZ 等[28]提出的方法，并将其应用于本文建立的数据集。该方法基于 SqueezeNet 的奶牛体况自动评分模型，主要关注背部深度信息的提取，并未涉及头部特征，从而提供了一个客观的对比基准。复现过程严格遵循原文方法，确保试验的严谨性和可重复性。去除头部和颈部的背部深度图像如图 8 所示，图 8b 为通过差分法去除背景后的深度通道，图 8c 为使用 Canny 算子定位奶牛背部深度图像的身体轮廓后的边缘通道，图 8d 为通过傅里叶高通滤波处理深度图像后的傅里叶通道，结果对比如表 4 所示。



(a) 原始深度图　(b) 深度通道　(c) 边缘通道　(d) 傅里叶通道

图 8　本文复现数据集样例

Fig. 8　Sample diagrams of reproduced data set

表 4　奶牛体况评分中相关工作的性能对比

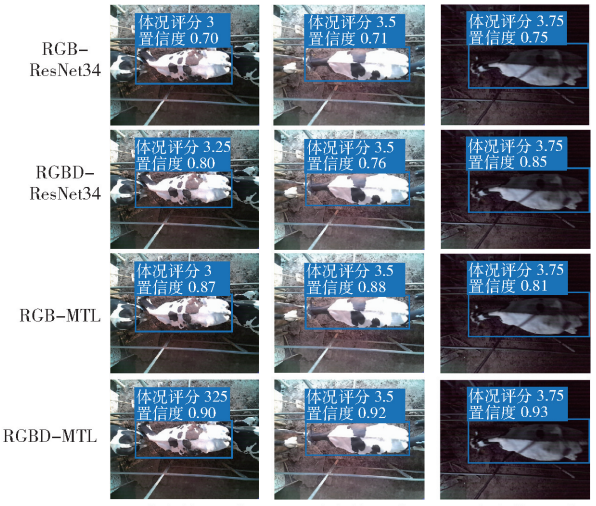
Tab. 4　Performance comparison of related works in cow body condition scoring

方法	数据集	准确率/%
文献[28]	原文数据集	40.00
文献[28]	本文复现数据集	58.00
本文方法	本文数据集	93.90

由表 4 可知，本文数据集与原文数据集在体况评分任务的关键属性上表现出较高的相似性。这表明本文建立的数据集是可靠且适用于相关研究的，同时也排除了数据集对试验结果可能产生的干扰，从而验证了本文方法的可行性。

3.2.1　体况评分结果可视化

图 9 为本文模型在实际奶牛活动场景中的体况评分结果及置信度。图 9b、9c 为模型预测正确的结果，而图 9a 预测有偏差，即 1 头原本应得 3.25 分的奶牛被预测为 3 分。这种情况出现在奶牛行走过程中，由于头部位置的摆动或过高过低，导致图像中头部区域的占比减少，进而影响了评分模型的最终判断。结果表明，尽管存在奶牛行走时头部位置变化这一挑战，但本文提出的多任务学习模型能够更有效地处理这种变化，展现出了更高的鲁棒性和准确性。



(a) 真实值3.25分　(b) 真实值3.5分　(c) 真实值3.75分

图 9　体况评分结果

Fig. 9　Body condition score results

3.2.2　个体识别结果可视化

图 10 为本文模型在实际奶牛活动场景中个体识别结果及置信度。从图 10a、10b 可以看出，本文构建的多任务学习模型在处理奶牛背部花纹的相似性、牛体表面污染（如灰尘或泥土的附着）以及不同光照条件导致的花纹特征强度和对比度变化等情况时，均展现出了良好性能。充分证明了本文构建的

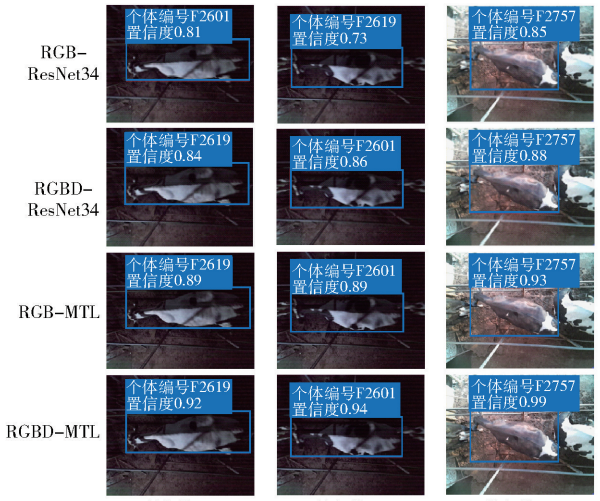


图 10 个体识别结果

Fig. 10 Individual identification results

多任务学习在奶牛个体识别任务中的精确性和稳定性,体现了模型在处理多变环境因素时的高效性。

4 结论

(1)提出了基于改进 YOLO v8 的奶牛背部区域检测模型,通过添加 GSConv 模块,修改损失函数为 WIoU,将模型平均精度均值和浮点运算量分别为 96.4% 和 2.420×10^{10},相较原模型,平均精度均值提升了 1 个百分点,浮点运算量减少 14.7%,实现了奶牛背部区域自动定位与检测。

(2)利用奶牛个体识别和体况评分两种任务均依赖于奶牛背部区域特征的共性,构建了基于硬参数共享的可同步输出奶牛体况评分和个体识别的多任务学习模型。结果表明,基于多任务学习的体况评分和个体识别准确率分别达到 93.9% 和 92.2%,相较单一任务模型,相应提高 1.9、4.5 个百分点;多任务学习模型同时完成两种任务检测时间,比单一任务模型分别完成两种任务总时间减少 6.37 ms,实现了奶牛个体体况精准高效监测。

参 考 文 献

[1] 陈紫昕, 孙宝丽, 刘德武, 等. 奶牛智慧养殖关键技术研究与应用[J]. 中国奶牛, 2024(2): 52-58.
CHEN Zixin, SUN Baoli, LIU Dewu, et al. Research and application of key technologies for dairy cattle smart farming[J]. China Dairy Cattle, 2024(2): 52-58. (in Chinese)

[2] MOHAMMED B S, RAMANOON S Z, MOSSADEQ W M S, et al. Association between lameness and indicators of dairy cow welfare based on locomotion scoring, body and hock condition, leg hygiene and lying behavior[J]. Animals, 2017, 7(11): 79.

[3] PFEIFER L F M, RODRIGUES W B, NOGUEIRA E. Relationship between body condition score index and fertility in beef cows subjected to timed artificial insemination[J]. Livestock Science, 2021, 248: 104482.

[4] ROCHE J R, FRIGGENS N C, KAY J K, et al. Invited review: body condition score and its association with dairy cow productivity, health, and welfare[J]. Journal of Dairy Science, 2009, 92(12): 5769-5801.

[5] 赵凯旋. 基于机器视觉的奶牛个体信息感知及行为分析[D]. 杨凌: 西北农林科技大学, 2017.
ZHAO Kaixuan. Dairy cattle's information perception and behavior analysis based on machine vision[D]. Yangling: Northwest A&F University, 2017. (in Chinese)

[6] 赵凯旋, 刘晓航, 姬江涛. 基于 EfficientNet 与点云凸包特征的奶牛体况自动评分[J]. 农业机械学报, 2021, 52(5): 192-201, 73.
ZHAO Kaixuan, LIU Xiaohang, JI Jiangtao. Automatic body condition scoring method for dairy cows based on EfficientNet and convex hull feature of point cloud[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(5): 192-201, 73. (in Chinese)

[7] HUANG Xiaoping, LI Xinru, HU Zelin. Cow tail detection method for body condition score using Faster R-CNN[C]//2019 IEEE International Conference on Unmanned Systems and Artificial Intelligence (ICUSAI). IEEE, 2019: 347-351.

[8] SUN Yukun, HUO Pengju, WANG Yujie, et al. Automatic monitoring system for individual dairy cows based on a deep learning framework that provides identification via body parts and estimation of body condition score[J]. Journal of Dairy Science, 2019, 102(11): 10140-10151.

[9] 刘娜, 安晓萍, 王园, 等. 机器视觉技术在奶牛精准化管理中的应用研究进展[J]. 中国畜牧杂志,2024,60(7):34-40.
LIU Na, AN Xiaoping, WANG Yuan, et al. Research progress on the application of machine vision technology in the precision management of dairy cows[J]. Chinese Journal of Animal Science,2024,60(7):34-40. (in Chinese)

[10] 司永胜, 肖坚星, 刘刚, 等. 基于 MSRCP 与改进 YOLO v4 的躺卧奶牛个体识别方法[J]. 农业机械学报, 2023, 54(1):243-250,262.
SI Yongsheng, XIAO Jianxing, LIU Gang, et al. Individual identification method of lying cows based on MSRCP and improved YOLO v4 mode[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(1):243-250, 262. (in Chinese)

[11] XIAO Jianxing, LIU Gang, WANG Kejian, et al. Cow identification in free-stall barns based on an improved Mask R-CNN and an SVM[J]. Computers and Electronics in Agriculture, 2022, 194: 106738.

[12] QIAO Yongliang, SU Daobilige, KONG He, et al. BiLSTM-based individual cattle identification for automated precision

livestock farming[C]//2020 IEEE 16th International Conference on Automation Science and Engineering (CASE). IEEE, 2020: 967 - 972.

[13] 何东健, 刘建敏, 熊虹婷, 等. 基于改进 YOLO v3 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 Dongjian, LIU Jianmin, XIONG Hongting, et al. Individual identification of dairy cows based on improved YOLO v3[J]. Transactions of the Chinese Society for Agricultural Machinery, 2020, 51(4): 250 - 260. (in Chinese)

[14] QIAO Yongliang, KONG He, CLARK C, et al. Intelligent perception for cattle monitoring: a review for cattle identification, body condition score evaluation, and weight estimation[J]. Computers and Electronics in Agriculture, 2021, 185: 106143.

[15] 郭阳阳, 杜书增, 乔永亮, 等. 深度学习在家畜智慧养殖中研究应用进展[J]. 智慧农业(中英文), 2023, 5(1): 52 - 65.
GUO Yangyang, DU Shuzeng, QIAO Yongliang, et al. Advances in the applications of deep learning technology for livestock smart farming[J]. Smart Agriculture, 2023, 5(1): 52 - 65. (in Chinese)

[16] 彭璟, 罗浩宇, 赵淦森, 等. 深度学习下的医学影像分割算法综述[J]. 计算机工程与应用, 2021, 57(3): 44 - 57.
PENG Jing, LUO Haoyu, ZHAO Gansen, et al. Survey of medical image segmentation algorithm in deep learning[J]. Computer Engineering and Applications, 2021, 57(3): 44 - 57. (in Chinese)

[17] RUDER S. An overview of multi-task learning in deep neural networks[J]. arXiv Preprint, arXiv:1706.05098, 2017.

[18] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904 - 1916.

[19] LIU Shu, QI Lu, QIN Haifang, et al. Path aggregation network for instance segmentation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018: 8759 - 8768.

[20] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2117 - 2125.

[21] ZHENG Zhaohui, WANG Ping, LIU Wei, et al. Distance-IoU loss: faster and better learning for bounding box regression[C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 12993 - 13000.

[22] TONG Zanjia, CHEN Yuhang, XU Zewei, et al. Wise - IoU: bounding box regression loss with dynamic focusing mechanism[J]. arXiv Preprint, arXiv:2301.10051, 2023.

[23] LI Hulin, LI Jun, WEI Hanbing, et al. Slim-neck by GSConv: a better design paradigm of detector architectures for autonomous vehicles[J]. arXiv Preprint, arXiv:2206.02424, 2022.

[24] THUNG K H, WEE C Y. A brief review on multi-task learning[J]. Multimedia Tools and Applications, 2018, 77(22): 29705 - 29725.

[25] HE Kaiming, ZHANG Xiangyu, REN Shaoqing, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770 - 778.

[26] WILDMAN E E, JONES G M, WAGNER P E, et al. A dairy cow body condition scoring system and its relationship to selected production characteristics[J]. Journal of Dairy Science, 1982, 65(3): 495 - 501.

[27] EDMONSON A J, LEAN I J, WEAVER L D, et al. A body condition scoring chart for holstein dairy cows[J]. Journal of Dairy Science, 1989, 72(1): 68 - 78.

[28] ALVAREZ J R, ARROQUI M, MANGUDO P, et al. Body condition estimation on cows from depth images using convolutional neural networks[J]. Computers and Electronics in Agriculture, 2018, 155: 12 - 22.