doi:10.6041/j.issn.1000-1298.2025.06.023

基于改进 YOLO v11n - seg 的奶牛乳房炎检测方法

田文斌　姚　渝　吕昊暾　杜瑞杰　王　宁
(中国农业大学工学院, 北京 100083)

摘要: 奶牛患乳房炎时其乳表温度与眼表温度差值较大,因此可将奶牛乳眼温差作为乳房炎判断指标。针对现有热红外图像检测奶牛乳房炎精度低、容易误检和漏检等问题,本文提出了一种基于 YOLO v11n - seg 结合热红外与可见光配准图像的奶牛乳房炎检测方法。为了在有限算力下能更精准地分割奶牛乳房和眼睛,对基线模型(YOLO v11n - seg)进行了改进。使用 ADown 卷积模块替换基线模型部分普通卷积进行特征提取,在资源有限的环境下有利于模型部署和使用;在主干网络末端引入 MLCA 注意力机制,显著提升了小尺度目标特征提取能力;颈部网络采用 RepGFPN 结构优化特征融合与信息传递能力,进一步提升分割精度。改进 YOLO v11n - seg 模型对奶牛眼睛和乳房平均分割精度分别为 90.3% 和 97.9%。与基线模型相比,其对眼睛和乳房的平均分割精度提高 7.1、0.7 个百分点,模型参数量减少 14.3%,模型计算量降低 12.5%。比较分割掩膜与温度矩阵提取的乳眼温差与设定的温差阈值,并用体细胞计数法进行验证。结果表明,奶牛乳房炎检测精度可达 88.46%。表明该方法能够实现奶牛乳眼分割并应用于奶牛乳房炎检测。

关键词: 奶牛乳房炎; 实例分割; YOLO v11; 轻量化; 智慧养殖
中图分类号: TP391　　**文献标识码**: A　　**文章编号**: 1000-1298(2025)06-0237-10　　**OSID**:

Detection Method for Cow Mastitis Based on Improved YOLO v11n - seg

TIAN Wenbin　YAO Yu　LÜ Haotun　DU Ruijie　WANG Ning
(*College of Engineering*, *China Agricultural University*, *Beijing* 100083, *China*)

Abstract: When dairy cows suffer from mastitis, the temperature difference between their udder surface and eye surface is relatively large. Therefore, the temperature difference between the udder and eye can be used as an indicator for mastitis detection. To address the issues of low accuracy, false detections, and missed detections in existing thermal infrared image-based mastitis detection methods, an improved YOLO v11n - seg method for mastitis detection in dairy cows was proposed, which utilized both thermal infrared and visible light registered images. To achieve more precise segmentation of the cow's udder and eyes under limited computational resources, targeted improvements were made. Firstly, the ADown convolution module was used to replace some of the ordinary convolution layers in the baseline model (YOLO v11n - seg) for efficient feature extraction, which was beneficial for model deployment and usage in resource-constrained environments. Secondly, the MLCA attention mechanism was introduced at the end of the backbone network, significantly enhancing the feature extraction capability for small-scale objects. Finally, the RepGFPN structure was adopted in the neck network to optimize feature fusion and information transmission, further improving segmentation accuracy. The improved YOLO v11n - seg model achieved an average segmentation accuracy of 90.3% for cow eyes and 97.9% for udders. Compared with the baseline model, the improved YOLO v11n - seg model increased the average segmentation accuracy by 7.1 percentage points and 0.7 percentage points, respectively, while reducing the number of model parameters by 14.3% and the computational cost by 12.5%. The temperature difference between the udder and eye, extracted from the segmentation mask and temperature matrix, was compared with the set temperature difference threshold and verified by the somatic cell count method. The results showed that the accuracy of mastitis detection in dairy cows reached 88.46%. This proved that the proposed method can achieve udder and eye segmentation in dairy cows and can be applied to mastitis detection.

Key words: cow mastitis; instance segmentation; YOLO v11; lightweight; smart farming

收稿日期: 2025 - 04 - 16　修回日期: 2025 - 04 - 30
基金项目: 国家重点研发计划项目(2022YFC2304004)
作者简介: 田文斌(1988—),男,副教授,主要从事智能传感与测控技术研究,E-mail: wenbin.tian@cau.edu.cn
通信作者: 吕昊暾(1983—),男,讲师,博士,主要从事传感检测与伺服控制研究,E-mail: lvhaotun@cau.edu.cn

0 引言

在奶牛养殖过程中,奶牛乳房炎是影响奶牛健康的主要疾病之一[1-2],会导致牛奶产量降低、质量下降[3-4]。常用的奶牛乳房炎检测方法如体细胞计数法(Somatic cell count, SCC)[5-6]、加州乳房炎试验[7]、乳汁电导率法(Electric conductivity, EC)[8]、乳汁 pH 值法[9]等耗时费力,难以在大型养殖场中推广。由于缺乏客观、精准的评判标准,只有出现明显症状时才能诊断疾病,从而错过了理想的治疗期[10]。因此,探索一种快速、准确且能够用于大规模生产实际的奶牛乳房炎自动检测方法对奶牛养殖智能化具有重要意义。

研究发现,当奶牛患有乳房炎时,乳房局部温度会高于体温,因此可以基于温度特征实现对奶牛乳房炎自动检测[11]。红外热成像技术(Infrared thermography, IRT)具有无创、快速、热分布可视化等特点,可用于远程测量动物表面温度[12-13]。ZANINELLI 等[14]通过热红外图像分析证实奶牛乳表温度与 SCC 之间存在显著正相关,并将乳房炎分类阈值设定为乳汁体细胞数 2×10^5 个/mL。GEORGE 等[15]证实 IRT 测量的奶牛眼表温度可作为奶牛温度指标。此外,SATHIYABARATHI 等[16]利用 IRT 技术观察奶牛体温和乳房皮肤表面温度,结果显示,患病部位温度比体温高 0.8℃。

近年来,随着深度学习发展,计算机视觉中目标检测发展迅速,已有学者将其运用到奶牛乳房炎检测[17]。王彦超等[18]基于热红外图像提出了一种改进 YOLO v3-tiny 目标检测算法,乳房炎检测准确率为 77.3%。ZHANG 等[19]提出了一种 EFMYOLO v3 深度学习算法,对热红外图像细节进行增强,以补偿热图像弱细节,增强前景和背景对比度,该算法准确率为 83.33%。为了进一步提高检测精度,WANG 等[20]结合了奶牛眼睛和乳房温差以及左右乳房温差,得到奶牛乳房炎检测准确率为 85.71%。

然而,基于深度学习的奶牛乳房炎检测仍存在以下问题亟待解决:热红外图像信噪比低、对比度差、边缘模糊、纹理细节不够丰富,难以对奶牛眼睛和乳房定位,容易出现误检和漏检;奶牛眼睛和乳房区域附近的一些区域,如奶牛腹部、大腿内侧等高温区域,因目标检测主要提供对象的边界框,而不包含对象精确轮廓,影响温度提取,导致奶牛乳房炎检测准确性不高;奶牛眼睛区域目标面积较小,检测和分割难度较高;模型复杂度较高,计算负担较大,难以在资源有限的平台上进行部署和使用。

本文利用 YOLO v11n-seg(YOLO v11 架构的扩展)作为基线模型[21],提出一种改进 YOLO v11n-seg 模型,以期能够显著提高奶牛眼睛和乳房分割精度的同时尽量降低模型复杂度,进而提高奶牛乳房炎检测准确性,并满足在资源有限的平台上部署和使用需求。

1 材料与方法

1.1 数据采集

实验数据采集于北京鼎晟誉玖牧业有限责任公司奶牛养殖场,采集时间为 2024 年 9 月,采集对象为 220 头处于泌乳期的荷斯坦奶牛。考虑到农业装备经济性的需求,经过牛场实地考察,双目摄像仪选取为鑫泰 HT-S320 型摄像仪。为避免机械挤奶对奶牛乳房温度的影响,视频在挤奶前采集。挤奶前,奶牛需要依次通过通道进入挤奶厅。将摄像仪放置在挤奶厅入口一侧,镜头与通道护栏相距 1.5 m,以确保奶牛眼睛和乳房可以被清晰地拍摄,热像仪另一端与 Windows 11 系统计算机连接。为获得尽可能多光照条件下奶牛图像,每天进行 3 次图像采集,采集时间段为 07:00—09:00、13:00—15:00、19:00—21:00。奶牛热红外和可见光图像采集系统如图 1 所示。

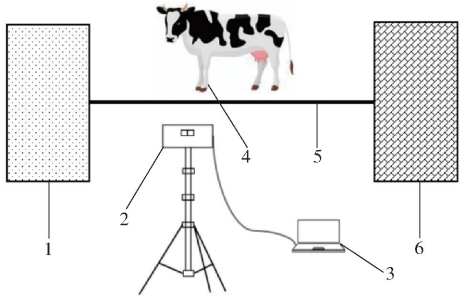

图 1 奶牛热红外和可见光图像采集系统示意图

Fig. 1 Schematic of dairy cow thermal infrared and visible light image acquisition system

1. 挤奶间 2. 鑫泰 HT-S320 型双目摄像仪 3. 计算机 4. 奶牛 5. 通道 6. 棚舍

1.2 图像配准

从奶牛眼睛和乳房区域提取温度时,需将可见光图像中检测到的眼睛和乳房区域映射到红外温度矩阵,并从温度矩阵中提取结果。因此,可见光图像中眼睛、乳房区域和热红外图像中眼睛、乳房区域须处于同一像素区域。由于拍摄热红外和可见光图像的摄像头视角略有偏差,因此同一物体在两类图像中的像素分布并不一致。需对两类图像进行配准,使其像素对齐。将两幅图像变换考虑为仿射变换,并设置仿射矩阵 $\boldsymbol{M}$ 为

$$\boldsymbol{M}=\begin{bmatrix} m_{11} & m_{12} & m_{13} \\ m_{21} & m_{22} & m_{23} \end{bmatrix} \tag{1}$$

式中 m_{11}、m_{12}、m_{13}、m_{21}、m_{22}、m_{23}为参数。

仿射变换包括旋转、缩放、平移以及其任意组合。设 $P'(x',y')$为热红外图像上某点，$P(x,y)$为可见光图像上某点。将点 $P(x,y)$变换为点 $P'(x',y')$，变换公式为

$$\begin{bmatrix} x' \\ y' \end{bmatrix} = \boldsymbol{M} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} \tag{2}$$

仿射矩阵 $\boldsymbol{M}$ 有 6 个参数，因此理论上只需在红外图像和可见光图像之间找到 3 对对应的特征点，代入式(2)求解仿射矩阵参数。为了减小误差，采用 RANSAC(Random sample consensus)算法[22－23]，从 1 组观测数据中计算出最优模型。通过在红外和可见光图像上手动标记 9 对特征点，并将这 9 对特征点坐标代入 RANSAC 算法中，求出最优仿射矩阵 $\boldsymbol{M}$。将可见光图像与热红外图像进行配准，得到最优仿射矩阵 $\boldsymbol{M}$。将仿射矩阵 $\boldsymbol{M}$ 对可见光图像进行仿射变换，得到配准后可见光图像。配准前后两幅图像效果如图 2a 和图 2b 所示。可见光图像与热红外图像叠加得到的融合图像如图 2c 所示。从图 2c 可以看出，配准后可见光图像与红外图像对齐良好，表明配准后可见光图像可代替红外图像进行目标区域定位。

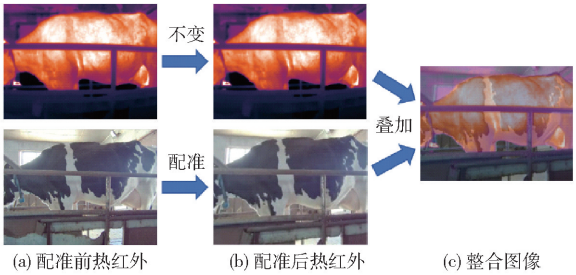

(a) 配准前热红外　(b) 配准后热红外　(c) 整合图像

图 2　热红外和可见光图像处理示例

Fig. 2　Examples of processing thermal infrared and visible light images

1.3　数据集构建

使用的数据集包括两部分：①配准后可见光图像，用于基于深度学习模型自动检测，为数据集 A。②与可见光图像对应热红外图像，为数据集 B。

使用实例分割模型对奶牛可见光图像中的眼睛和乳房区域进行定位，在模型训练前需对数据集进行标注[24－25]。在去除遮挡严重、模糊不清、有人入镜的图像后，得到 1 000 幅可见光图像。随机选出验证集和测试集各 200 幅，剩余 600 幅为训练集。数据集样本多样性与模型泛化性和鲁棒性存在一定正比关系，会直接影响模型训练效果，因此采用镜像翻转、添加噪声、锐化、亮度增强和亮度减弱 5 种方法对训练集中的 200 幅可见光图像进行了图像增强，以增加训练基础数据量，共增加 1 000 幅训练集图像。数据增强示例如图 3 所示。上述数据增强方法可使训练后奶牛关键部位实例分割模型适应不同的视角、光线及噪声影响，提升模型训练后泛化性和鲁棒性，同时避免训练过程中因部分数据集样本过少而出现过拟合。最终数据集 A 包含 2 000 幅可见光图像，其中训练集 1 600 幅，验证集和测试集各 200 幅。使用 Labelme 软件对奶牛可见光图像中的眼睛和乳房进行手动分割并进行标记，作为不同的类别“eye”和“udder”，从而产生包含标签位置和类别的 JSON 格式文件。最后，将 JSON 文件转换为适用于网络模型的 txt 格式文件，用于训练深度学习模型。

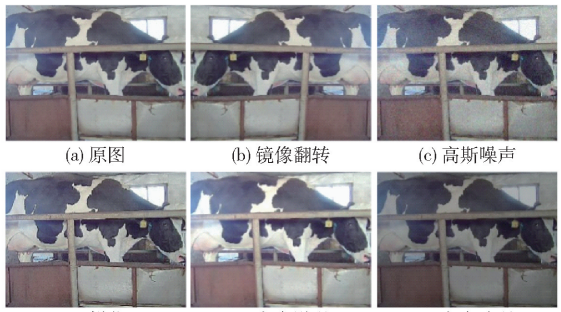

(a) 原图　(b) 镜像翻转　(c) 高斯噪声

(d) 锐化　(e) 亮度增强　(f) 亮度减弱

图 3　图像增强示例

Fig. 3　Examples of image enhancement

为了比较实例分割算法在红外和可见光图像的定位性能，通过使用脚本将标签从可见光图像数据集 A 转移到红外图像数据集 B 上。数据集 B 和数据集 A 有相同的标签名称和标签位置。

1.4　实验平台

训练模型所用实验平台参数如表 1 所示。训练时数据集选用建立的奶牛数据集，批量大小设为 4，迭代次数设为 150，初始学习率设为 0.001。

表 1　实验平台参数

Tab. 1　Experimental platform parameters

参数	配置
CPU	Intel(R) Core(TM) i9－14900HX@2.20 GHz
内存/GB	16
GPU	NVIDIA GeForce RTX 4060
GPU 加速库	CUDA 11.8、CUDNN 8.9.0
操作系统	Windows(64 位)
环境	Python 3.10、Pytorch 11.8

2　奶牛乳房炎自动检测方法

2.1　奶牛眼睛、乳房分割模型

2.1.1　改进 YOLO v11n－seg 模型

奶牛关键部位分割模型旨在检测奶牛眼睛和乳房位置，并勾画出眼睛和乳房轮廓。选择 YOLO

v11n－seg(YOLO v11 架构扩展)作为基线模型,针对奶牛关键部位进行训练,确保检测性能和分割准确性。该模型由 3 部分组成:用于特征提取的主干模块、用于特征融合的颈部模块和用于最终检测和分割任务的头部模块。输入图像经特征提取网络处理,利用卷积层和改进 C3k2 模块提取多尺度特征。C3k2 模块改进自 YOLO v8 的 C2f 模块,结合卷积与分组卷积优势,支持灵活选择自定义卷积核大小,以平衡特征提取效率与模型配置灵活性。此外,在 SPPF 层后新增 C2PSA 层,通过注意力机制强化特征表达,并向颈部网络传递多尺度特征。特征融合网络采用 PAN－FPN 结构[26－27],通过上采样与下采样融合高级语义与低级图像特征,增强多尺度目标检测能力。头部模块中检测分支执行边界框回归,而分割分支结合基掩码和掩码系数。ProtoNet 靠全卷积网络(FCN)生成与输入特征大小相同的基掩码作为原型,并行检测子网络预测掩膜权重作为掩码系数,非极大值抑制(NMS)在通过线性叠加组合原型和系数前过滤重复检测,最终掩码使用阈值 0.5 进行二值化。

尽管 YOLO v11n－seg 在普通场景下实例分割的表现优异,但其在养殖场环境中对奶牛关键部位分割仍存在不足,包括模型参数量大、计算复杂度高,限制了资源受限平台部署;对养殖场复杂背景适应性较弱,难以满足奶牛眼睛即小尺度目标精准分割需求,小尺度目标定位和分割能力有待提升。提出了改进 YOLO v11n－seg 模型,如图 4 所示。主要改进策略包括采用轻量化的 ADown 模块代替普通卷积模块,在降低计算复杂度的同时保留高效特征提取能力;在主干网络末端引入 MLCA 注意力层,提升模型对奶牛关键部位尤其是小目标特征提取能力;利用 RepGFPN 结构优化了特征融合与信息传递能力,进一步提高了对小目标的检测与分割能力[28－30]。

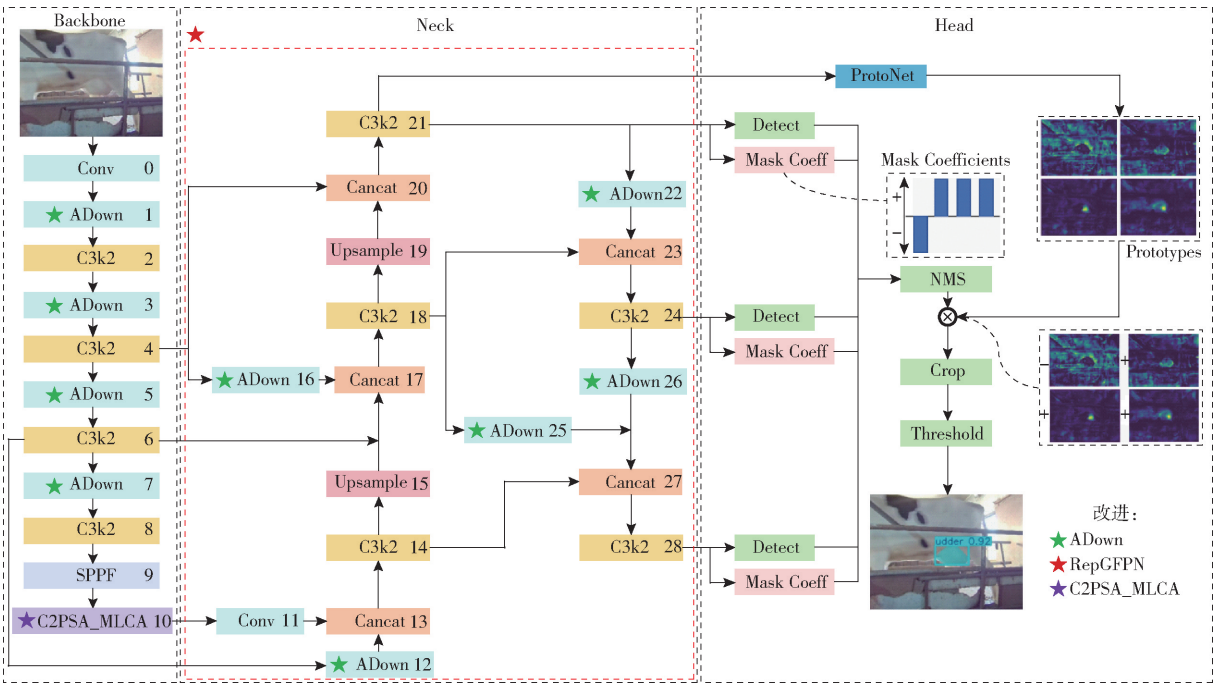

图 4 改进 YOLO v11－seg 网络结构

Fig. 4 Improved YOLO v11－seg network structure

2.1.2 ADown 卷积

考虑到模型会在不同环境下进行部署和使用,若在资源受限的环境中,需要兼顾模型内存占用量和分割精度。在 YOLO v11n－seg 网络模型中,大量卷积层会显著增加整体网络参数量,从而导致模型体积较大。ResNet[31] 和 VGGNet[32] 网络结构虽然精度很高,但其体积过于庞大,导致检测时间显著延长,在资源受限设备中表现不够理想。而 MobileNet[33] 和 ShuffleNet[34] 等轻量主干网络通过引入深度可分离卷积,减少了参数量和计算量,从而大大降低了模型复杂度和运行时间。然而,这些轻量化设计往往会以牺牲检测精度为代价,导致模型在复杂环境下处理任务时表现不如更大型的网络。针对上述问题,引入 ADown 卷积模块替换部分普通卷积 Conv。ADown 卷积模块有效减少了参数量,降低了模型复杂度,还能在降低特征图空间分辨率的同时尽可能多地保留图像信息,实现模型轻量化。其网络结构如图 5 所示。在 ADown 卷积中,首先对输入特征图进行平均池化,同时保持特征图空间信息。将通道的一半通过一个 3×3 卷积层进行处理,

卷积层负责提取更加丰富的空间特征。另一半通道则先经过一个 3×3 最大池化层以进一步降低特征图尺寸，随后通过一个 1×1 卷积层进行处理，以整合全局信息并减少维度。通过引入 ADown 卷积模块使得模型不牺牲分割精度的同时减少参数量，模型轻量化使其更适用于资源有限的设备。

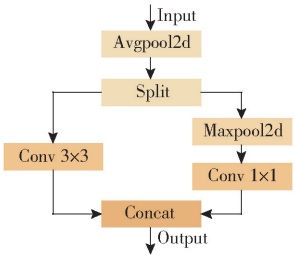

图 5　ADown 内部结构图

Fig. 5　Internal structure diagram of ADown

2.1.3　MLCA 注意力机制

奶牛眼睛较小，不易检测与分割，易出现漏检和误检。为了解决这一问题，将 YOLO v11n－seg 模型的 C2PSA 模块中的注意力层替换为 MLCA，组合成 C2PSA_MLCA 模块，通过 MLCA 结合局部和全局特征以及通道和空间特征的信息，有效增强了模型对重要信息的捕获，C2PSA_MLCA 对特征表示的有更高的性能和适应性。该模块能够同时整合通道信息和空间信息，以及局部信息和全局信息来提升网络表达效果，在提高精度的同时保持模型轻量化。其网络结构如图 6 所示。MLCA 首先对输入特征图进行局部和全局平均池化，然后通过卷积进行特征转换。局部池化后的特征与原始输入特征相结合，全局池化后的特征则与局部池化特征相结合，最终通过反池化恢复到原始空间维度。这种方法在保持计算效率的同时，提高了奶牛眼睛即小尺度目标分割精度。

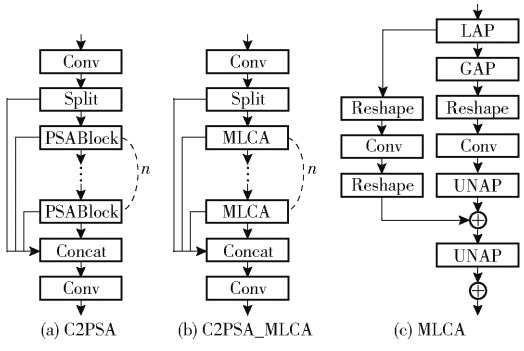

图 6　原始 C2PSA、C2PSA_MLCA 和 MLCA 结构图

Fig. 6　Original C2PSA, C2PSA_MLCA and MLCA structure diagram

2.1.4　RepGFPN 特征融合网络

YOLO v11n－seg 使用 PAN－FPN 架构构建颈部模块，虽然通过路径聚合优化了多尺度特征融合，但在处理多目标时仍存在信息丢失导致分割精度低的问题。为此，将带有跨尺度连接的 RepGFPN 作为颈部网络，促进大尺度和小尺度特征信息交流，增强模型特征融合能力。通过其高效特征融合设计，实现了更为有效的多尺度特征整合。如图 7 所示，多个特征层通过拼接进入 RepGFPN 的融合模块（Fusion Block）进行迭代处理，在融合模块内部利用双分支卷积网络对特征进行提取和融合，有效结合了图像高层和低层语义信息。将其作为模型的颈部网络，提升了特征融合效果，在几乎不增加额外计算的情况下，进一步提高了对奶牛关键区域分割精度。

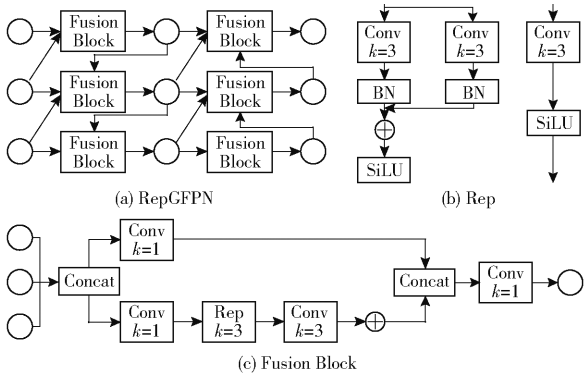

图 7　RepGFPN、Fusion Block 和 Rep 结构图

Fig. 7　RepGFPN, Fusion Block and Rep structure diagram

2.2　奶牛关键部位温度提取

使用改进 YOLO v11n－seg 模型训练完成后，向模型输入可见光图像，输出奶牛眼睛和乳房区域掩膜。由于可见光图像已通过配准与红外图像对齐，将得到的掩膜区域像素坐标映射到热红外图像对应的温度矩阵中，即可提取奶牛眼睛和乳房最高温度。奶牛眼睛和乳房温度表示为

$$T_{\text{eye}} = \max_{n\in\{1,N_e\}}\left(\max_{i,j\in\{1,S_e\}}\left(T(x_i,y_j)\right)\right) \tag{3}$$

$$T_{\text{udder}} = \max_{m\in\{1,N_u\}}\left(\max_{i,j\in\{1,S_u\}}\left(T(x_i,y_i)\right)\right) \tag{4}$$

式中　T_{eye}——奶牛眼睛温度，即其奶牛核心体温

T_{udder}——奶牛乳房温度

N_e——图中包含奶牛眼部区域像素数量

N_u——图中包含奶牛乳房区域像素数量

S_e——温度矩阵中奶牛眼部区域元素数量

S_u——温度矩阵中奶牛乳房区域元素数量

传统红外温度提取方法与本文所提方法的具体工作流程图工作流程图如图 8 所示。

2.3　奶牛乳房炎检测及诊断标准

以奶牛眼睛区域最高温度作为奶牛体温，通过与奶牛乳房区域最高温度进行比较来判断奶牛是否患有乳房炎。奶牛乳房温度与眼睛温度在没有患有乳房炎奶牛中差异不明显，而患有乳房炎的奶牛乳房温度将比眼睛温度高 0.8℃[15-16]。因此，奶牛乳

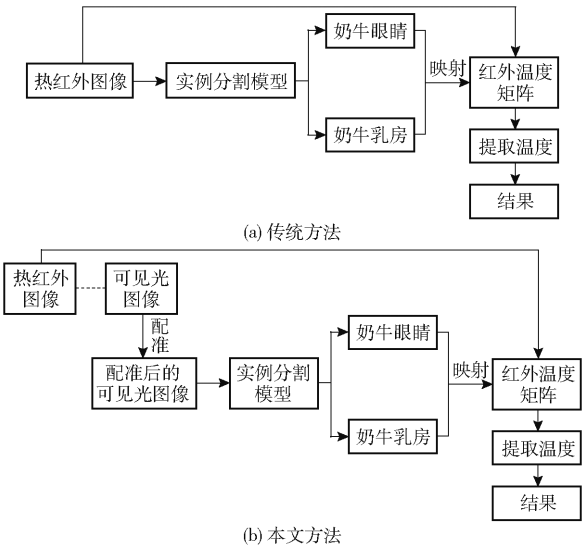

图 8 传统方法和本文方法流程图

Fig. 8 Traditional and proposed methods flowcharts

房炎判定条件表示为

$$C_m=\begin{cases}0 & (T_{\text{udder}}-T_{\text{eye}}\leqslant 0.8℃)\\ 1 & (T_{\text{udder}}-T_{\text{eye}}>0.8℃)\end{cases} \tag{5}$$

式中 C_m——奶牛乳房炎诊断结果

0 表示奶牛未患乳房炎,1 表示奶牛患有乳房炎。

为验证本研究提出的算法对检测奶牛乳房炎的有效性,以乳汁体细胞计数法的检测结果为真值,计算奶牛乳房炎检测的准确性。

2.4 网络模型评价指标

选用精确率(Precision,P)、召回率(Recall,R)、平均精度(Average precision,AP)、参数量、浮点运算数作为模型评价指标。

3 实验结果与分析

3.1 奶牛关键部位分割结果

3.1.1 与传统方法对比实验

本文方法与传统红外温度提取方法的不同之处在于使用不同的图像对目标区域进行定位与分割。本文方法使用可见光图像进行目标区域分割,而传统方法使用红外图像进行目标区域分割。为了证明本文方法优于传统方法,只需证明同一实例分割算法在可见光图像即数据集 A 上比在热红外图像即数据集 B 上有更高的精度即可。使用 YOLO v11n-seg 算法在上述 2 个数据集上进行训练,在训练过程中保持超参数一致,并在测试集上评估模型性能。YOLO v11n-seg 算法在两个数据集上对比实验结果如表 2 所示。

所有类别在可见光图像(数据集 A)上的指标均高于热红外图像(数据集 B)。眼睛和乳房在数据集 A 上 AP@0.5 分别达到 83.2% 和 97.2%,分别比数据集 B 高 1.6、17.8 个百分点。由表 2 可得 YOLO v11n-seg 算法在可见光图像中对所有类别的平均分割精度都高于热红外图像。

表 2 YOLO v11n-seg 算法在两个数据集上对比实验结果

Tab. 2 Comparison experimental results of YOLO v11-seg algorithm on two datasets %

数据集	类别	P	R	AP@0.5	AP@0.5:0.95
热红外图像	eye	86.7	71.2	81.6	34.7
(数据集 B)	udder	74.6	79.1	79.4	32.2
可见光图像	eye	88.6	76.2	83.2	35.9
(数据集 A)	udder	96.7	92.4	97.2	68.3

图 9a 和图 9d 都正确检测和分割出奶牛乳房区域。图 9b 中正确检测和分割出奶牛眼睛区域,而图 9e 中由于奶牛头部和眼睛区域温度均高,无法检测和分割出眼睛区域,出现漏检现象。图 9c 中正确检测和分割出奶牛乳房区域,而图 9f 中虽然正确检测和分割出奶牛乳房区域,但由于奶牛有其他区域温度偏高,也被当作奶牛乳房区域,出现误检现象。

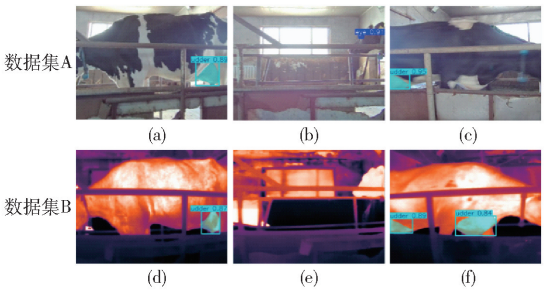

图 9 YOLO v11n-seg 算法在两个数据集上的对比结果

Fig. 9 Comparison results of YOLO v11n-seg algorithm on two datasets

3.1.2 消融实验

消融实验结果如表 3 所示。由表 3 可知,ADown 卷积模块在轻量化方面表现显著,能够有效降低模型参数量和计算复杂度,对分割精度影响较小,在资源受限的设备中有良好的应用前景。MLCA 注意力机制的引入显著提升了模型分割精度,并且参数量和计算量略有下降。RepGFPN 特征融合网络虽然使得参数量和计算资源略有增加,但进一步提升了模型分割精度。通过逐步添加各改进模块,观察到模块间的协同作用。消融实验验证了各模块的有效性,权衡了模型分割精度和模型内存占用量。本文模型相较于基线模型,参数量减少 14.3%,计算量降低 12.5%。针对眼睛类别,P 提升 3 个百分点,R 提升 13.3 个百分点,AP@0.5 提升 7.1 个百分点,AP@0.5:0.95 提升 6.3 个百分点。针对乳房类别,P 提升 1.1 个百分点,R 提升 4.9 个

表 3　消融实验结果

Tab. 3　Results of ablation experiments

模型	类别	*P*/%	*R*/%	AP@0.5/%	AP@0.5:0.95/%	参数量	浮点运算数
YOLO v11n－seg	eye	88.6	76.2	83.2	35.9	2.8×10^6	1.04×10^{10}
	udder	96.7	92.4	97.2	68.3		
YOLO v11n－seg＋ADown	eye	88.9	82.1	85.9	37.8	2.3×10^6	9.00×10^9
	udder	96.3	91.2	96.9	72.0		
YOLO v11n－seg＋MLCA	eye	91.2	83.0	88.6	39.1	2.8×10^6	1.02×10^{10}
	udder	95.7	91.6	97.8	71.0		
YOLO v11n－seg＋RepGFPN	eye	91.5	82.1	87.9	37.4	3.1×10^6	1.06×10^{10}
	udder	97.1	92.7	97.3	70.4		
YOLO v11n－seg＋ADown＋MLCA	eye	90.3	83.4	87.2	39.3	2.3×10^6	9.00×10^9
	udder	96.3	92.6	97.1	69.4		
YOLO v11n－seg＋ADown＋MLCA＋RepGFPN(本文模型)	eye	91.6	89.5	90.3	42.2	2.4×10^6	9.10×10^9
	udder	97.8	97.3	97.9	72.9		

百分点，AP@0.5 提升 0.7 个百分点，AP@0.5:0.95 提升 4.6 个百分点。

3.1.3　与不同实例分割模型对比实验

选取多个主流实例分割模型与改进模型进行了对比实验。Mask R－CNN[35] 在 Faster R－CNN[36] 的基础上增添 1 个分支，从而具备分割功能。它属于自上而下的双阶段分割模型，首先运用目标检测方法确定实例所在的区域，随后在检测框内进行分割。这一特性使得它相较于其他模型能够更精准地定位目标。Mask R－CNN 虽性能出色，但对硬件资源的要求较高，并且图像处理速度相对较慢，难以满足实时性需求。YOLACT[37] 属于单阶段实例分割模型，它通过对 Mask 原型图和原型置信度进行线性组合来生成实例分割结果。虽然其在速度方面超越了 Mask R－CNN，但精度却稍显不足。YOLO v8n－seg[38] 是基于 YOLACT 模型实现的，可以使用更轻量化的模型实现更高的精确度。不同实例分割模型对比实验结果如表 4 所示。

表 4　不同实例分割模型对比实验结果

Tab. 4　Comparison experimental results of different instance segmentation models

模型	类别	*P*/%	*R*/%	AP@0.5/%	AP@0.5:0.95/%	参数量	浮点运算数
Mask R－CNN	eye	90.4	87.6	89.7	41.9	4.4×10^7	2.29×10^{11}
	udder	97.4	92.4	97.4	71.7		
YOLACT	eye	80.3	77.9	79.5	33.7	3.5×10^7	6.15×10^{10}
	udder	93.4	87.1	92.8	52.9		
YOLO v8n－seg	eye	88.2	75.3	82.1	35.2	3.3×10^6	1.21×10^{10}
	udder	94.6	88.3	96.7	67.2		
本文模型	eye	91.6	89.5	90.3	42.2	2.4×10^6	9.10×10^9
	udder	97.8	97.3	97.9	72.9		

由表 4 可以看出，本文提出的改进模型在减少参数量的同时，性能依然超越了 Mask R－CNN、YOLACT 和 YOLO v8－seg 模型。与 Mask R－CNN、YOLACT 和 YOLO v8－seg 模型相比，本文模型对奶牛眼睛和乳房平均分割精度分别提高 0.6、0.5 个百分点，10.8、5.1 个百分点，8.2、1.2 个百分点。并且本文模型参数量更少、计算量更小、更适合部署在资源有限的场景中。

对各模型分割结果进行可视化分析，如图 10 所示。

3.2　奶牛乳房炎自动检测结果评价

为了评估模型准确性，利用改进 YOLO v11n－seg 模型对选取的 26 头奶牛进行乳房炎检测，并与体细胞数目检测结果进行对比，以乳汁体细胞数目大于 2×10^5 个/mL 作为判断奶牛患有乳房炎的标准[14]。表 5 为 26 头奶牛检测结果。检测结果中 0 表示未患乳房炎，1 表示患有乳房炎。

由表 5 可知，以奶牛眼睛与乳房之间 0.8℃ 的温差作为判断阈值，本文模型对奶牛乳房炎检测精度为 88.46%，表明本文模型可以应用于奶牛乳房炎检测，并具有较好的检测效果。但是由于距离对红外热像仪检测的温度会产生一定的影响，当奶牛行走过程中姿态发生变化时，奶牛眼睛和乳房与热像仪距离会发生变化，使得红外热像仪检测到的奶

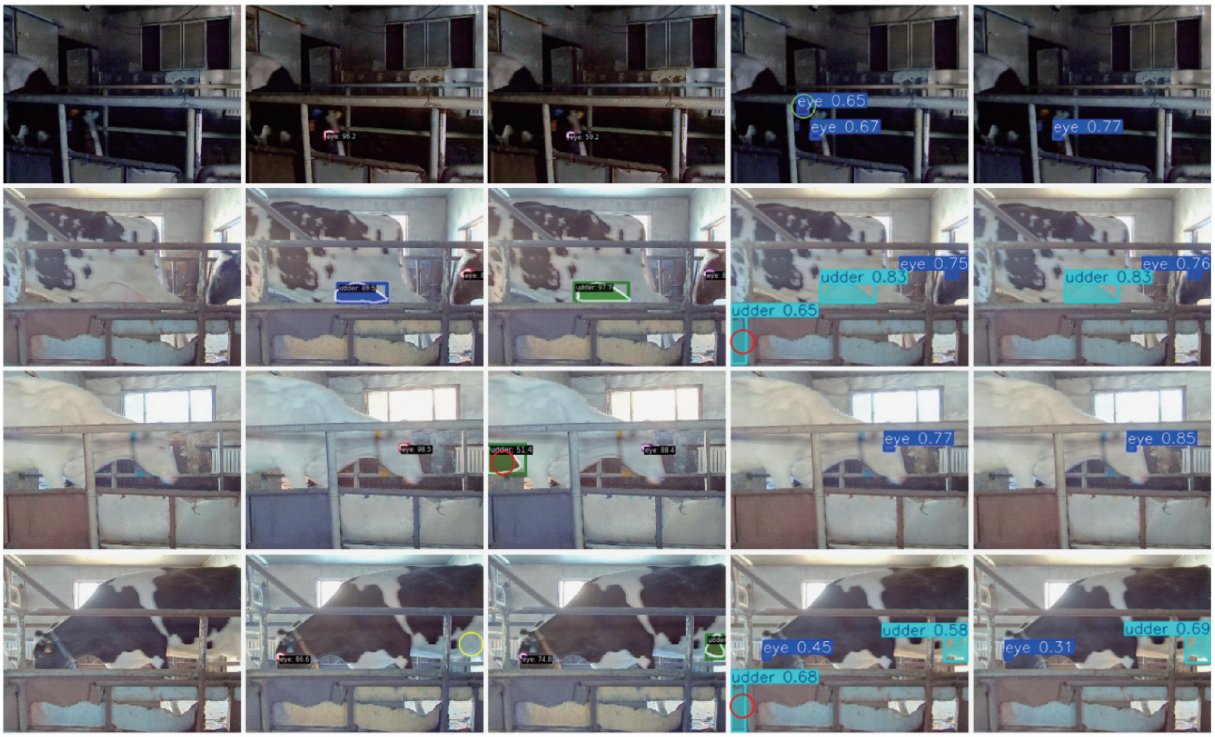

图 10 不同实例分割模型对比结果

Fig. 10 Comparison results of different instance segmentation models

表 5 奶牛乳房炎检测结果对比

Tab. 5 Comparison of results of dairy cow mastitis

奶牛序号	温差/℃	SCC/(个·mL^{-1})	本文模型检测结果	体细胞数目判断结果	检测结果是否正确
1	2.9	6.8×10^5	1	1	是
2	0.3	5.2×10^4	0	0	是
3	0.9	1.6×10^5	1	0	否
4	3.8	8.6×10^5	1	1	是
5	2.8	8.4×10^5	1	1	是
6	0.1	4.1×10^4	0	0	是
7	0.9	2.6×10^5	1	1	是
8	3.7	1.1×10^6	1	1	是
9	0.2	3.7×10^4	0	0	是
10	0.2	5.9×10^4	0	0	是
11	2.5	7.3×10^5	1	1	是
12	0.6	2.8×10^5	0	1	否
13	0.2	9.3×10^4	0	0	是
14	0.7	1.2×10^5	0	0	是
15	0.5	1.9×10^5	0	0	是
16	2.2	4.7×10^5	1	1	是
17	0.5	1.7×10^5	0	0	是
18	1.2	2.3×10^5	1	1	是
19	1.4	5.9×10^5	1	1	是
20	0.6	1.5×10^5	0	0	是
21	2.7	7.7×10^5	1	1	是
22	0.5	9.4×10^4	0	0	是
23	1.1	1.5×10^5	1	0	否
24	0.7	1.6×10^5	0	0	是
25	3.0	8.3×10^5	1	1	是
26	2.1	5.5×10^5	1	1	是

牛眼睛或乳房温度不准确,进而导致乳房炎检测精度降低;奶牛养殖场栏杆的遮挡、奶牛之间相互遮挡以及泥污的附着会影响奶牛关键区域分割,使得奶牛乳房炎检测精度降低。这些因素均会导致奶牛乳房炎检测精度受限,检测精度仍需进一步提高。

4 结论

(1)提出了一种基于热红外和可见光配准图像的奶牛乳眼分割方法。该方法利用可见光图像中纹理细节更丰富,更容易识别特征的特点,用其代替热红外图像进行奶牛眼睛和乳房的分割。实验结果表明,本文提出的方法比现有的单一热红外图像方法能更好地分割出奶牛眼睛和乳房,有效减少漏检和误检。

(2)提出了一种改进 YOLO v11n - seg 模型。使用 ADown 卷积模块替换基线模型的部分普通卷积进行高效的特征提取,轻量化模型有利于其在资源有限的设备上部署和使用;主干网络末端引入 MLCA 注意力机制,提升对小尺度目标特征提取能力;颈部网络采用 RepGFPN 结构优化了特征融合与信息传递能力,进一步提高模型对奶牛关键部位分割精度。通过 6 组消融实验证明了各模块有效性及模块间的协同作用。改进 YOLO v11n - seg 模型与基线模型相比,参数量和运算量分别下降 14.3%、12.5%,而奶牛眼睛和乳房的平均分割精度分别提高 7.1、0.7 个百分点。

（3）与 Mask R－CNN、YOLCAT、YOLO v8n－seg 主流实例分割模型相比，本文模型对奶牛眼睛和乳房平均分割精度分别提高 0.6、0.5 个百分点，10.8、5.1 个百分点，8.2、1.2 个百分点。本文模型参数更少、运算量更小。

（4）通过分割掩膜和温度矩阵，得到了奶牛乳眼温差，将其与设定的温度阈值进行比较，以判定奶牛是否患有乳房炎。结果表明，本文方法对奶牛乳房炎检测精度为 88.46%，可以准确、快速、无创地检测奶牛乳房炎。

参 考 文 献

[1] GONÇALVES J L, DECAMPOS J L, STEINBERGER A J, et al. Incidence and treatments of bovine mastitis and other diseases on 37 dairy farms in Wisconsin[J]. Pathogens, 2022, 11(11): 1282－1294.

[2] 蔡一欣，马丽，刘刚. 奶牛隐性乳房炎便携式计算机视觉快速检测系统设计与试验[J]. 农业工程学报，2017，33(增刊)：63－69.
CAI Yixin, MA Li, LIU Gang. Design and experiment of rapid detection system of cow subclinical mastitis based on portable computer vision technology[J]. Transactions of the CSAE, 2017, 33(Supp.): 63－69. (in Chinese)

[3] 孙艳，周国燕，伍天碧，等. 我国奶牛乳房炎近期研究进展[J]. 中国乳业，2022(4)：43－51.
SUN Yan, ZHOU Guoyan, WU Tianbi, et al. Recent research progress of cow mastitis in China[J]. China Dairy, 2022(4): 43－51. (in Chinese)

[4] SHARMA N, JEONG D K. Stem cell research: a novel boulevard towards improved bovine mastitis management[J]. International Journal of Biological Sciences, 2013, 9(8): 818－829.

[5] DENG Z, LAM T, HOGEVEEN H, et al. Regularly fluctuating somatic cell count pattern in dairy herds[J]. Journal of Dairy Science, 2021, 104(10): 11126－11134.

[6] 詹经纬，童津津，熊本海，等. 奶牛乳腺健康与乳中体细胞数之间关系的研究进展[J]. 动物营养学报，2021，33(3)：1299－1305.
ZHAN Jingwei, TONG Jinjin, XIONG Benhai, et al. Research progress on relationship of mammary gland health and milk somatic cell count of dairy cows [J]. Chinese Journal of Animal Nutrition, 2021, 33(3): 1299－1305. (in Chinese)

[7] 李海强，杨大盛，卢琦，等. 2 种奶牛隐性乳房炎检测方法比较[J]. 中国畜牧兽医，2020，47(8)：2677－2683.
LI Haiqiang, YANG Dasheng, LU Qi, et al. Comparison of two methods for detecting recessive mastitis in cows[J]. China Animal Husbandry and Veterinary Medicine, 2020, 47(8): 2677－2683. (in Chinese)

[8] INZAGHI V, ZUCALI M, THOMPSON P D, et al. Changes in electrical conductivity, milk production rate and milk flow rate prior to clinical mastitis confirmation[J]. Italian Journal of Animal Science, 2021, 20(1): 1554－1561.

[9] ALI A, MIR M U R, GANIE S A, et al. Milk-compositional study of metabolites and pathogens in the milk of bovine animals affected with subclinical mastitis[J]. Molecules, 2022, 27(23): 8631－8652.

[10] KIM H, MIN Y, CHOI B. Real-time temperature monitoring for the early detection of mastitis in dairy cattle: methods and case researches[J]. Computers and Electronics in Agriculture, 2019, 162: 119－125.

[11] 杨春合. 奶牛乳区温度影响因素及与乳房炎的关系研究[D]. 北京：中国农业科学院，2015.
YANG Chunhe. Study on influential factors on udder temperature of dairy cows and the relationship between udder temperature and mastitis[D]. Beijing: Chinese Academy of Agricultural Sciences, 2015. (in Chinese)

[12] CAI Z J, CUI J L, YUAN H B, et al. Application and research progress of infrared thermography in temperature measurement of livestock and poultry animals: a review[J]. Computers and Electronics in Agriculture, 2023, 205: 107586.

[13] 郭艳娇，杨圣慧，迟宇，等. 基于热红外图像的奶牛乳区温度分布与乳房炎识别方法[J]. 农业工程学报，2022，38(2)：250－259.
GUO Yanjiao, YANG Shenghui, CHI Yu, et al. Recognizing mastitis using temperature distribution from thermal infrared images in cow udder regions[J]. Transactions of the CSAE, 2022, 38(2): 250－259. (in Chinese)

[14] ZANINELLI M, REDAELLI V, LUZI F, et al. First evaluation of infrared thermography as a tool for the monitoring of udder health status in farms of dairy cows[J]. Sensors, 2018, 18(3): 862.

[15] GEORGE W D, GODFREY R W, KETRING R C, et al. Relationship among eye and muzzle temperatures measured using digital infrared thermal imaging and vaginal and rectal temperatures in hair sheep and cattle[J]. Journal of Animal Science, 2014, 92(11): 4949－4955.

[16] SATHIYABARATHI M, JEYAKUMAR S, MANIMARAN A, et al. Infrared thermography to monitor body and udder skin surface temperature differences in relation to subclinical and clinical mastitis condition in Karan Fries (*Bos taurus* x *Bos indicus*) crossbred cows[J]. Indian Journal of Animal Science, 2018, 88(6): 694－699.

[17] 初梦苑，刘晓文，曾雪婷，等. 奶牛乳房炎自动检测技术研究进展[J]. 农业工程学报，2023，39(11)：1－12.
CHU Mengyuan, LIU Xiaowen, ZENG Xueting, et al. Research advances in the automatic detection technology for mastitis of dairy cows[J]. Transactions of the CSAE, 2023, 39(11): 1－12. (in Chinese)

[18] 王彦超，康熙，李孟飞，等. 基于改进 YOLO v3-tiny 的奶牛乳房炎自动检测方法[J]. 农业机械学报，2021，52(增刊)：

276 – 283.
WANG Yanchao, KANG Xi, LI Mengfei, et al. Automatic detection method for dairy cow mastitis based on improved YOLO v3-tiny[J]. Transactions of the Chinese Society for Agricultural Machinery, 2021, 52(Supp.): 276 – 283. (in Chinese)
[19] ZHANG X, KANG X, FENG N, et al. Automatic recognition of dairy cow mastitis from thermal images by a deep learning detector[J]. Computers and Electronics in Agriculture, 2020, 178: 105754.
[20] WANG Y, KANG X, HE Z, et al. Accurate detection of dairy cow mastitis with deep learning technology: a new and comprehensive detection method based on infrared thermal images[J]. Animal, 2022, 16(10): 100646.
[21] JEGHAM N, CHAN Y K, MARWAN A, et al. Evaluating the evolution of YOLO (You only look once) models: a comprehensive benchmark study of YOLO11 and its predecessors[J]. arXiv Preprint, arXiv: 2411.00201, 2024.
[22] FISCHLER M A, BOLLES R C. Random sample consensus: a paradigm for model fitting with applications to image analysis and automated cartography[J]. Communications of the ACM, 1981, 24(6): 381 – 395.
[23] ZHANG B, XIAO D Q, LIU J B, et al. Pig eye area temperature extraction algorithm based on registered images[J]. Computers and Electronics in Agriculture, 2024, 217: 108549.
[24] 王福顺,王旺,孙小华,等. 基于改进 YOLO v8n – seg 的羊只实例分割方法[J]. 农业机械学报, 2024, 55(8): 322 – 332.
WANG Fushun, WANG Wang, SUN Xiaohua, et al. Sheep instance segmentation method based on improved YOLO v8n – seg[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(8): 322 – 332. (in Chinese)
[25] 马中杰,罗晨,骆巍,等. 基于改进 YOLO v7-tiny 的玉米种质资源雄穗检测方法[J]. 农业机械学报, 2024, 55(7): 290 – 297.
MA Zhongjie, LUO Chen, LUO Wei, et al. Tassel detection method of maize germplasm resources based on improved YOLO v7-tiny[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(7): 290 – 297. (in Chinese)
[26] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2017: 936 – 944.
[27] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2018: 8759 – 8768.
[28] WANG C Y, YEH I H, LIAO H Y M. Yolov9: learning what you want to learn using programmable gradient information[C]// Proceedings of the 18th European Conference on Computer Vision, 2024: 1 – 21.
[29] WAN D, LU R, SHEN S, et al. Mixed local channel attention for object detection[J]. Engineering Applications of Artificial Intelligence, 2023, 123: 106442.
[30] XU X, JIANG Y, CHEN W, et al. Damo-YOLO: a report on real-time object detection design[J]. arXiv preprint arXiv: 2211.15444, 2022.
[31] 李炳臻,刘克,顾佼佼,等. 卷积神经网络研究综述[J]. 计算机时代, 2021(4): 8 – 12, 17.
LI Bingzhen, LIU Ke, GU Jiaojiao, et al. Review of the researches on convolutional neural networks[J]. Computer Era, 2021(4): 8 – 12, 17. (in Chinese)
[32] 倪天宇. 晶圆表面缺陷自动检测技术的研究[D]. 上海: 东华大学, 2022.
NI Tianyu. Research on automatic detection technology of wafer surface defects[D]. Shanghai: Donghua University, 2022. (in Chinese)
[33] HOWARD A, SANDLER M, CHEN B, et al. Searching for MobileNetV3[C]// 2019 IEEE/CVF International Conference on Computer Vision (ICCV). IEEE, 2019: 1314 – 1324.
[34] ZHANG X, ZHOU X, LIN M, et al. ShuffleNet: an extremely efficient convolutional neural network for mobile devices[C]// 2018 IEEE/ CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2018: 6848 – 6856.
[35] HE K M, GKIOXARI G, DOLLÁR P, et al. Mask R – CNN[C]// Proceedings of the IEEE International Conference on Computer Vision (ICCV). IEEE, 2017: 2980 – 2988.
[36] 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.
[37] BOLYA D, ZHOU C, XIAO F, et al. YOLACT: real-time instance segmentation[C]// Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV). IEEE, 2019: 9156 – 9165.
[38] JOCHER G. Ultralytics YOLOv8[EB/OL]. 2023 – 01 – 11 [2025 – 04 – 02]. https://github.com/ultralytics/ultralytics.