doi:10.6041/j.issn.1000-1298.2026.13.029

多阶段自适应增强的奶牛后乳房性状分割方法

李旭文[1,2]　高荣华[1]　李奇峰[1]　王　荣[1]　坎　杂[2]　何盈盈[1]　戎玉娇[1]
周　杰[1]　张　俊[1]
(1.北京市农林科学院信息技术研究中心，北京 100097；2.石河子大学机械电气工程学院，石河子 832002)

摘要：奶牛后乳房性状是评估奶牛生产性能与育种价值的关键指标，其精准自动化评定对提升牛场管理效率以及遗传选育水平具有重要意义。针对奶牛后乳房结构形态复杂、边界自然模糊，且挤奶现场存在遮挡、光照多变等干扰，使得对其进行高精度、自动化的图像分割与性状评定困难问题，本文提出了一种多阶段自适应增强的奶牛后乳房性状分割模型(MAAE-SegNet)。通过引入自适应参数激活机制，增强骨干网络对复杂场景中乳房特征的动态表达能力，并构建动态门控注意力模块以有效聚焦后乳房关键区域，提升后乳房分割边界的清晰度与完整性。试验结果表明，与 Mask2Former 模型相比，本文改进后模型的检测框精确率、召回率分别提升 0.5、1.5 个百分点，分割精确率与召回率分别提升 1.8、2.0 个百分点。其中模型参数量为 $4.705\,5\times10^{7}$，浮点数运算量为 1.59×10^{11}，改进模型在参数量不激增情况下精度更高。

关键词：奶牛后乳房；图像分割；注意力机制；线性评分
中图分类号：TP391　　**文献标识码**：A　　**文章编号**：1000-1298(2026)13-0347-12　　**OSID**：

Multi-stage Adaptive Activation Enhancement Segmentation Method for Dairy Cow Rear Udder Traits

Li Xuwen[1,2]　Gao Ronghua[1]　Li Qifeng[1]　Wang Rong[1]　Kan Za[2]　He Yingying[1]
Rong Yujiao[1]　Zhou Jie[1]　Zhang Jun[1]
(1. *Research Center of Information Technology*, *Beijing Academy of Agriculture and Forestry Sciences*, *Beijing* 100097, *China*
2. *College of Mechanical and Electrical Engineering*, *Shihezi University*, *Shihezi* 832002, *China*)

Abstract: Cow rear udder traits are key indicators for evaluating dairy cows' production performance and breeding value, and their accurate and automated evaluation is of great significance for improving dairy farm management efficiency and genetic breeding levels. The complex structural morphology, naturally blurred boundaries of cow rear udders, as well as interferences such as occlusion and variable lighting in milking sites, make high-precision and automated image segmentation and trait evaluation extremely challenging. A multi-stage adaptive enhancement segmentation network for cow rear udder traits (MAAE-SegNet) was proposed. By introducing an adaptive parameter activation mechanism, it enhanced the backbone network's dynamic expression capability for udder features in complex scenarios, and constructed a dynamic gated attention module to effectively focus on the key regions of the rear udder, thereby improving the clarity and completeness of rear udder segmentation boundaries. Experimental results showed that compared with the Mask2Former model, the improved model achieved 0.5 and 1.5 percentage points improvements in detection box accuracy and recall rate respectively, and 1.8 and 2.0 percentage points improvements in segmentation accuracy and recall rate respectively. The model had a parameter count of $4.705\,5\times10^{7}$ and a floating-point operation (FLOP) count of 1.59×10^{11}, demonstrating higher accuracy without a significant increase in parameter quantity.

Key words: dairy cow rear udder; image segmentation; attention mechanism; linear scoring

收稿日期：2025-11-23　修回日期：2026-01-31
基金项目：北京市自然科学基金面上项目(43242037)和北京市农林科学院探索项目(TSXM202511)
作者简介：李旭文(2000—)，男，博士生，主要从事畜牧信息化与视觉行为分析研究，E-mail：lxw18239841882@163.com
通信作者：高荣华(1977—)，女，研究员，主要从事畜牧信息化与视觉行为分析研究，E-mail：gaorh@nercita.org.cn

0 引言

奶牛种质资源是保障奶业可持续发展的核心基础。当前我国奶牛核心种质资源对外依存度超过70%,品种登记、生产性能测定及体型鉴定等基础育种工作亟待完善[1-3]。体型线性评定作为奶牛育种体系的关键环节,其评价结果与奶牛产奶年限、抗病能力及最终生产潜力均存在显著关联[4-6]。该鉴定方法通过量化描述奶牛外貌性状的生物学范围,采用9分制线性评分实现对特定性状的客观度量[7]。后乳房作为奶牛最重要的功能体型结构之一,其附着高度、宽度是决定泌乳系统价值的关键线性性状[8-10]。

传统人工评定主要依赖半圆仪、测杖与皮尺等工具进行接触式测量,存在效率低、主观性强、数据可比性差等问题,难以满足现代化育种对标准化、高通量数据采集的需求[11]。为提升评定效率与客观性,基于图像的自动测量方法逐渐得到应用[12-15]。黄君冉等[16]利用模板匹配技术提取奶牛背部关键点,实现了体高、体斜长等指标的自动测量,准确率超过90%。然而,传统图像方法对动物姿态、光照变化敏感,在非结构化养殖环境中稳健性不足。

近年来,深度相机等三维传感设备为体型评定提供了新途径[17]。张馨月等[18]通过构建奶牛背部点云,进一步实现了体尺的自动化提取。郭浩等[19]利用RGB-D相机获取奶牛关键部位点云数据,线性评定指标相对误差控制在9%以内。Pezzuolo等[20]采用多Kinect相机系统同步采集奶牛三维数据,实现了臀宽、体高和胸围等多参数的高一致性测量。尽管三维方法在精度方面表现良好,但其设备成本高、操作复杂,对采集环境的要求比较苛刻,制约了在生产现场的大规模部署。

随着深度学习技术的突破,基于实例分割的低成本视觉测量方法展现出显著优势[21-25]。该类方法通过端到端的掩码预测直接提取目标区域,结合像素尺度换算实现性状参数的自动化测量。Lewis等[26]利用二维成像和深度学习自动评分奶牛体况;张勤等[27]提出基于SAM优化的RTFTR模型,在复杂环境中平均分割精度达98.1%,推理速度达52.9 f/s;李昊玥等[28]通过改进Mask R-CNN实现奶牛个体分割,掩码识别精度达91.34%;张姝瑾等[29]提出YOLO v8n-seg-FCA-BiFPN模型,对乳房等8个部位进行分割,乳房检测平均精度达97.1%;Qiao等[30]利用Mask R-CNN提取奶牛整体轮廓,平均像素精度达92%。目前面向结构复杂、边界模糊的后乳房区域的精细实例分割研究仍较缺乏,尤其在光照多变、存在遮挡的实际环境中,分割精度与模型稳健性仍有待提高。

针对以上问题,本文尝试以Mask2Former为基线模型,引入自适应参数激活机制与动态门控注意力模块,拟提出一种多阶段自适应激活增强的奶牛后乳房性状分割模型(MAAE-SegNet),旨在提高遮挡与光照变化环境下后乳房区域的识别精度,以期实现对奶牛后乳房附着高度与后乳房附着宽度性状的自动化、高精度线性评分,为奶牛体型鉴定的工程化应用提供有效解决方案。

1 材料与方法

1.1 试验数据获取

奶牛后乳房视频数据采集于河北首农某畜牧养殖基地的挤奶厅,采集时间为2023年2月至2024年5月,对象为荷斯坦奶牛。采集设备选用海康威视全彩筒型网络摄像机(DS-2CD3T87WDV3-L型),焦距6 mm,分辨率3 840像素×2 160像素,帧率20 f/s。为增强模型对不同视角与光照条件的适应能力,在挤奶转盘后方距奶牛尻部1 m处,设置3个不同高度的摄像机位,分别对应高视(2.85 m)、中视(1.95 m)和低视(1.18 m)3种拍摄角度,结构如图1所示,涵盖早、中、晚不同时段的光照条件。

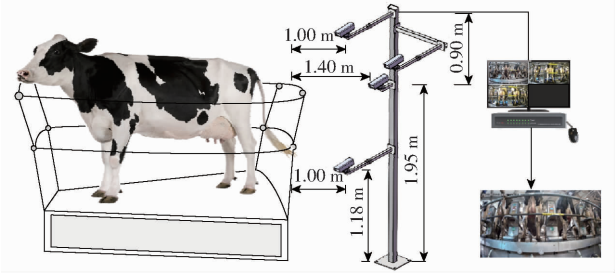

图1 奶牛后乳房性状数据获取场景

Fig. 1 Data acquisition scenario for rear udder traits of dairy cows

1.2 数据集构建和增强

经人工筛选后,截取包含完整后乳房的图像并裁剪为1 800像素×1 800像素。最终构建数据集Cowudder1000,含训练集图像800幅、测试集图像200幅,利用Labelme标注标签为“udder”。图2呈现了数据集中奶牛后乳房的图像示例,涵盖了不同拍摄视角与光照条件,依次为高视角(图2a)、中视角(图2b)、低视角(图2c)以及灯光条件(图2d)。

为提升数据多样性与模型泛化能力,在训练阶段引入了系统化的数据增强流程,如图3所示。输入图像尺寸为1 800像素×1 800像素,首先以50%概率进行随机水平翻转,以消除方位偏差。随后,在



(a) 高视视角　(b) 中视视角　(c) 低视视角　(d) 灯光条件

图 2　奶牛后乳房性状数据示例

Fig. 2　Data samples for rear udder traits in dairy cows

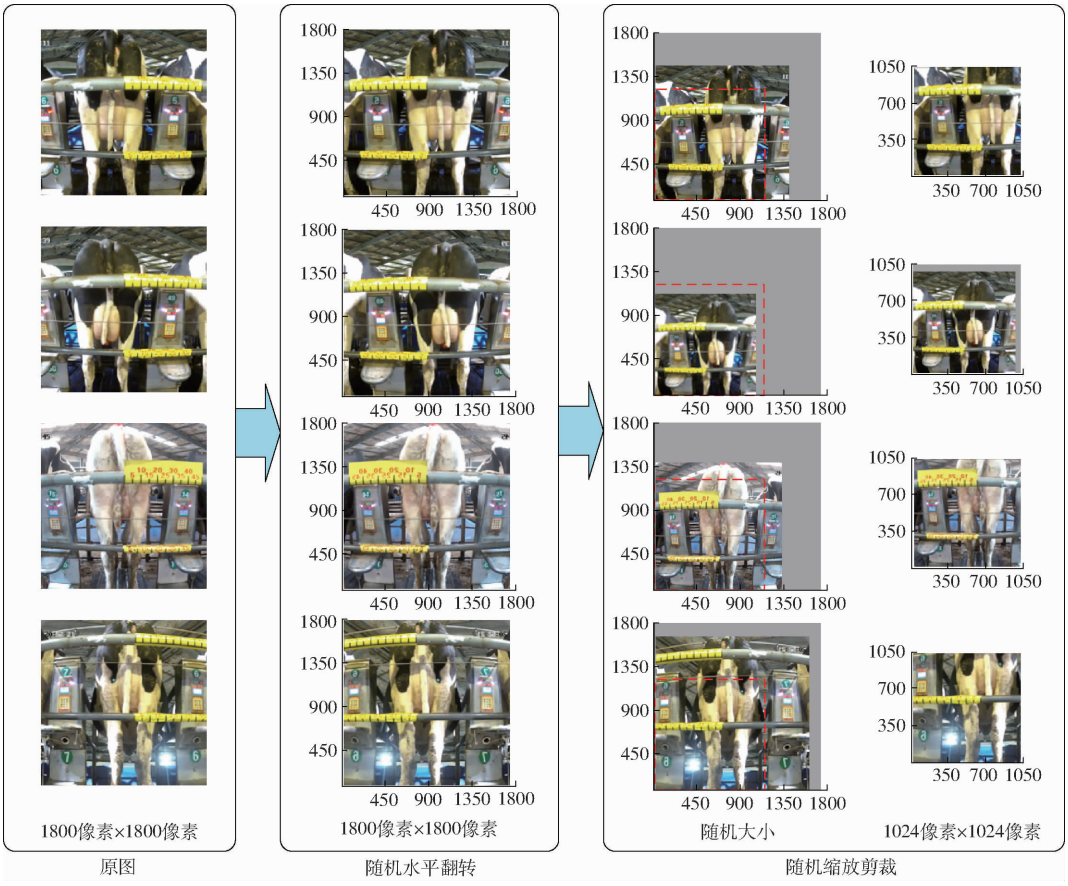

图 3　数据增强过程

Fig. 3　Data augmentation process

0.1 至 2.0 范围内随机选取缩放比例进行尺度变换,过程中保持宽高比不变,防止目标形变。缩放比例为 0.8、1.2 和 1.6 时,图像分别调整为 819 像素 × 819 像素、1 229 像素 × 1 229 像素和 1 638 像素 × 1 638 像素。最后,通过裁剪统一输出为 1 024 像素 × 1 024 像素。通过上述增强,数据集图像动态扩充至 8 000 幅(训练集图像 6 400 幅,测试集图像 1 600 幅),有效提升了模型对多变光照与尺度的适应性。

2 模型构建

奶牛后乳房性状评定主要依赖乳房区域的像素级分割。后乳房分割面临 3 个难点:①目标边界具有高度模糊性。②成像环境干扰严重。③形态结构存在显著个体差异。本文选取 Mask2Former 作为基准,其掩码注意力机制能有效建模全局上下文。提出 MAAE - SegNet 模型,如图 4 所示,主要改进包括自适应参数激活骨干网络与动态门控注意力模块。

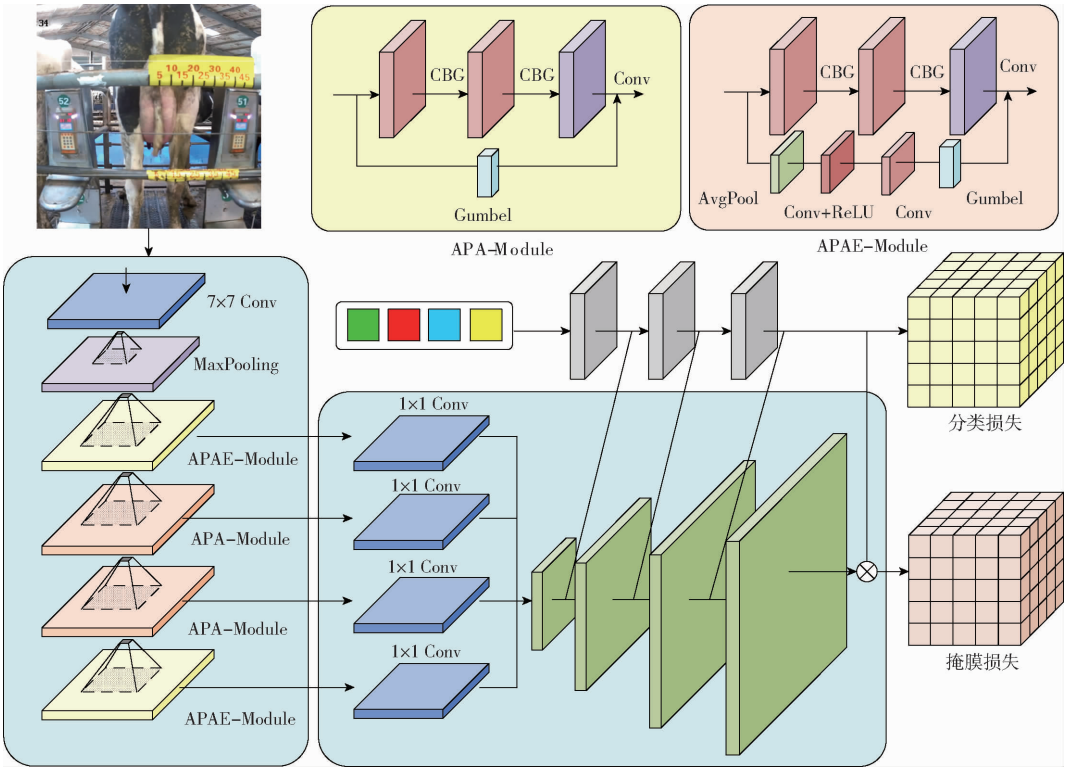

图 4 MAAE - SegNet 网络结构

Fig. 4 Architecture of MAAE - SegNet network

2.1 自适应参数激活骨干网络的构建

面向实际生产环境中奶牛乳房性状分割这一具体场景时,现有方法难以充分考虑奶牛后乳房边界困难区域与中心简单区域的特征差异性,同时缺乏针对性的自适应学习策略。针对这一技术瓶颈,本研究重新设计了一种自适应参数激活骨干网络用于 MAAE - SegNet 网络中的特征提取部分,通过动态感知不同区域的学习难度实现差异化特征表征。在新的骨干网路中设计了 2 种残差模块,分别为 APA - Module 模块和 APAE - Module 模块。其中,APA - Module 模块适用于逐层提取图像特征,APAE - Module 模块是 APA - Module 的增强版,两者结构如图 5 所示。

APA - Module 是一种面向深度残差网络的双分支结构,其核心由主分支的序列化卷积-归一化-激活(CBG)操作与次分支的参数化自适应激活单元

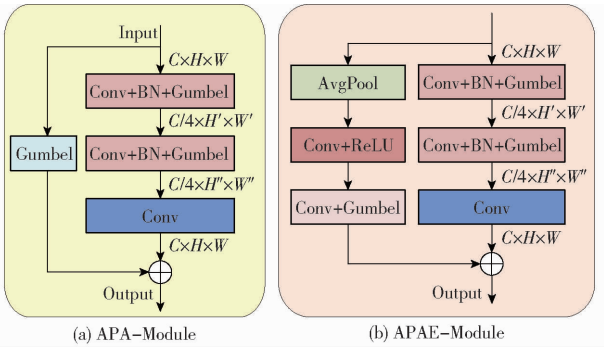

图 5 APA - Module 和 APAE - Module 结构

Fig. 5 Architectures of APA - Module and APAE - Module

共同构成。主分支由 2 个级联的 CBG 单元和通道压缩激励模块构成,从而完成特征降维、空间建模与升维操作。给定输入特征图 $\boldsymbol{X} \in \mathbf{R}^{C\times H\times W}$,其中 C、H、W 分别代表特征通道数、特征图高度、特征图宽度。通过 1 × 1 卷积压缩通道维度,输出特征 $\boldsymbol{F}_1 \in \mathbf{R}^{\frac{C}{r}\times H'\times W'}$,通道压缩比 $r=4$,H' 与 W' 分别表示压缩

后特征图的高度与宽度，$\boldsymbol{F}_1$ 计算公式为

$$\boldsymbol{F}_1 = \mathrm{Conv}_{1\times1}(\boldsymbol{X};\boldsymbol{W}_1;s_1) \tag{1}$$

式中　$\boldsymbol{W}_1$——该卷积层的可学习权重参数

s_1——该卷积层的步长

进行批量归一化与自适应激活得到特征 $\hat{\boldsymbol{F}}_1$

$$\hat{\boldsymbol{F}}_1 = \phi_\theta(\mathrm{BN}(\boldsymbol{F}_1)) \tag{2}$$

式中　BN——归一化操作

ϕ_θ——参数化激活函数，与次分支中的激活单元原理一致

将压缩过的图像特征 $\hat{\boldsymbol{F}}_1$ 输入到 3×3 卷积中提取奶牛乳房边界的空间特征 $\boldsymbol{F}_2 \in \mathbf{R}^{\frac{C}{4}\times H''\times W''}$，$H''$与 W''分别表示卷积操作后特征图的高度与宽度，由步长 s_2 决定，$\boldsymbol{F}_2$ 计算公式为

$$\boldsymbol{F}_2 = \mathrm{Conv}_{3\times3}(\hat{\boldsymbol{F}}_1;\boldsymbol{W}_2;s_2) \tag{3}$$

式中　$\boldsymbol{W}_2$——该卷积层的可学习权重参数

s_2——该卷积层的步长

最后输入到 1×1 卷积种恢复原有通道维度并输出特征 $\boldsymbol{F}_3$

$$\boldsymbol{F}_3 = \mathrm{Conv}_{1\times1}(\phi_\theta(\mathrm{BN}(\boldsymbol{F}_2))) \tag{4}$$

主分支中“降维-特征提取-升维”的设计目的是通过减少 APA - Moudule 的通道数，在降低模型参数量的同时，保持了模型的表达能力，保证基础特征流的稳定性。然而在奶牛后乳房图像分割任务中，目标区域通常呈现边界不规则的形态学特征，且存在中心区域占据大部分像素，边缘区域的像素稀疏。传统残差网络中固定形式的激活函数因其对称性缺失和硬饱和特性，难以动态适应此类复杂输入分布，导致细粒度特征丢失和梯度衰减，因此在 APA - Module 引入融合参数化自适应激活单元的次分支。

参数化自适应激活单元 ϕ_θ，采用改进的 Gumbel 激活机制，其非线性变换由可学习参数 λ、k 动态调节。对于输入 x，其激活输出的计算公式为

$$\phi(x) = \exp\left(-\frac{1}{\lambda}S_f(x)\right) \tag{5}$$

其中，S_f 是软阈值函数，其定义为

$$S_f(x) = \ln(1+\mathrm{e}^x) \tag{6}$$

而 APAE - Module 与 APA - Module 结构稍有不同，将 Gumbel 激活模块替换为动态门控注意力模块(Dynamic gated atttention, DGA)，增强了网络对奶牛后乳房图像中重要特征的提取能力。

2.2　基于动态门控注意力的模块设计

尽管 APA - Module 模块通过自适应参数化激活提升了特征变换的灵活性，但其本质仍是逐点线性映射，缺乏对通道与空间维度的显式注意力引导，借助 APAE 模块在 APA 基础上引入的动态门控注意力机制，利用多尺度特征校准与长过程依赖建模，提出一种压缩激励与参数化动态门控的注意力机制，将自适应激活函数替代传统固定非线性映射，实现通道权重的上下文敏感调节。给定输入特征图 $\boldsymbol{X}\in\mathbf{R}^{C\times H\times W}$，模块首先通过全局空间压缩提取通道统计特征 z_c

$$z_c = \frac{1}{HW}\sum_{i=1}^{H}\sum_{j=1}^{W}X_c(i,j) \tag{7}$$

其中，$X_c(i,j)$ 表示输入特征图在第 c 个通道、空间位置(i,j)处的特征响应强度。随后采用双全连接层瓶颈结构学习通道间的非线性依赖关系，并引入动态门控函数，遵循先降维后升维的通道变换方式，通过第 1 个全连接层将通道数从 C 降低到 C/r，然后应用 ReLU 激活函数，再通过第 2 个全连接层恢复通道数，即

$$\boldsymbol{u} = \delta(\boldsymbol{U}_1\boldsymbol{z}) \tag{8}$$

$$\boldsymbol{v} = \boldsymbol{U}_2\boldsymbol{u} \tag{9}$$

其中 $\boldsymbol{U}_1\in\mathbf{R}^{C\times C/r}$和 $\boldsymbol{U}_2\in\mathbf{R}^{C/r\times C}$是可学习权重矩阵，$r$ 取 16，δ 是 ReLU 激活函数，$\boldsymbol{z}$ 是通道统计特征向量，$\boldsymbol{u}$ 是降维后的中间特征向量，$\boldsymbol{v}$ 是最终通道权重向量。该结构可有效捕获通道间非线性依赖，适合于建模奶牛乳房边界的关联性。

随后将 $\boldsymbol{v}$ 送入参数化自适应激活单元，逐元素计算对应的门控系数向量。首先需对 $\boldsymbol{v}$ 进行线性缩放与平移，得到中间响应特征 y

$$y = k\boldsymbol{v} - \ln\lambda \quad (\lambda>0) \tag{10}$$

式中 λ 和 k 是可学习参数，分别控制门控函数的尺度和曲率。随后通过非线性变换将中间响应特征映射为门控系数向量 $\boldsymbol{g}$

$$\boldsymbol{g} = \exp\left(-\frac{1}{\lambda}\ln(1+\mathrm{e}^y)\right) \tag{11}$$

$\boldsymbol{g}$ 的各分量值域为(0,1)，其物理意义为对应通道的缩放因子。在奶牛后乳房性状图像的处理过程中，λ 能够自适应调整特征的响应敏感度，即处理高对比度乳房内部区域增大阈值，处理低对比度乳房边界区域降低阈值。参数 k 的作用是调节激活函数的非线性程度，灵活适应不同奶牛个体的乳房形态变化。门控函数内部通过梯度传播，其梯度计算方法为

$$\frac{\partial\boldsymbol{g}}{\partial\boldsymbol{v}} = k\boldsymbol{v}\frac{\boldsymbol{g}}{\lambda+\mathrm{e}^{k\boldsymbol{v}}} + \boldsymbol{g} \tag{12}$$

这种平滑的梯度传播特性确保了优化稳定性，使网络能有效学习奶牛乳房区域的细微特征。此外，为增强挤奶厅不同光照条件乳房图像的鲁棒性，在门控计算之前进行了归一化操作

$$z_{\mathrm{norm}} = \frac{z-\mu}{\sigma} \tag{13}$$

式中 μ——向量 z 中所有元素的均值

σ——向量 z 的标准差

z——归一化操作前特征

z_{norm}——归一化后的特征

最后经过动态门控调整得到重校准的特征图 $\hat{\boldsymbol{X}}$

$$\hat{\boldsymbol{X}} = \boldsymbol{X} \otimes \boldsymbol{g} \tag{14}$$

式中 $\boldsymbol{X}$ 为原始特征图，使得网络在训练中自动习得适应乳房图像特性的通道权重分配。

3 试验结果与分析

3.1 试验平台和模型测试指标

本文试验基于 Linux 操作系统、Pytorch 深度学习框架，采用 NVIDIA RTX A6000 训练模型，其中 Python 版本为 3.8，ubuntu 版本为 18.04，CUDA API 版本为 11.3。使用相同数据集和训练策略训练模型。

为全面评估本文所构建深度学习模型的综合性能，采用目标检测与实例分割领域的通用评估准则，从识别精度、模型复杂度及运行效率等多个维度进行综合分析。模型的检测性能利用平均精确率与平均召回率进行量化。

3.2 对比试验结果

为验证本文方法有效性，选取 Mask R-CNN、Mask2Former-ResNet、Mask2Former-Swin、Cascade Mask R-CNN 及 RTM_Det 等 5 种主流模型进行对比。基于构建的数据集进行 3 次独立重复训练，取最优权重，并以 0.7 置信度评估检测框和掩膜的精确率与召回率、参数量及浮点数运算量，结果如表 1 所示。

表 1 不同模型性能对比

Tab.1 Performance comparison of different models

模型	检测框平均精确率/%	检测框平均召回率/%	掩膜平均精确率/%	掩膜平均召回率/%	参数量	浮点数运算量
Mask R-CNN	88.5	91.0	91.7	94.0	$4.399\,1\times10^{7}$	1.87×10^{11}
Mask2Former-ResNet	89.8	93.0	92.5	95.0	$4.400\,3\times10^{7}$	1.59×10^{11}
Mask2Former-Swin	88.5	91.5	92.2	94.5	$4.742\,2\times10^{7}$	1.65×10^{11}
Cascade Mask R-CNN	90.1	93.5	92.5	94.5	$7.708\,2\times10^{7}$	1.752×10^{12}
RTM_Det	91.5	94.0	91.8	94.5	$5.730\,5\times10^{7}$	1.07×10^{11}
MAAE-SegNet	90.3	94.5	94.3	97.0	$4.705\,5\times10^{7}$	1.59×10^{11}

由表 1 可知，Mask R-CNN 掩膜精确率仅为 91.7%；Cascade Mask R-CNN 精确率虽达 92.5%，但参数量高达 $7.708\,2\times10^{7}$；RTM_Det 浮点数运算量虽低至 1.07×10^{11}，但掩膜精确率仅 91.8%，无法满足精细分割需求。相比之下，Mask2Former-ResNet 在保证精确率 92.5% 的基础上参数量仅 $4.400\,3\times10^{7}$，故选其为改进基线。改进后的 MAAE-SegNet 参数量为 $4.705\,5\times10^{7}$，掩膜精确率提升至 94.3%，且浮点数运算量为 1.59×10^{11}，与基线相当。这表明改进模型在未显著增加计算成本的前提下，有效平衡了精度与效率。

图 6a 综合指标均值显示，MAAE-SegNet 的 4 项指标均值为 94.03%，表现最佳。图 6b 采用 Friedman 非参数检验分析模型间的整体差异，其统计量计算公式为

$$\chi_F^2 = \frac{12N}{m(m+1)}\left[\sum_{j=1}^{m} R_j^2 - \frac{m(m+1)^2}{4}\right] \tag{15}$$

式中 m——模型数量，取 6

N——评价指标数量，取 4

R_j——第 j 个模型在所有指标上的平均排名

计算得到差异值 $\chi_F^2 = 17.866\,7$，对应 $p = 0.001\,3$，表明各模型性能存在统计学显著差异；MAAE-SegNet 平均排名 1.25，显著优于排名 6.00 的 Mask R-CNN。图 6c 展示了 Wilcoxon 符号秩检验的两两比较结果，图中浅色区域表明 MAAE-SegNet 与其他基准模型之间 p 值极小，存在显著的统计学差异，验证了改进的有效性。图 6d 雷达图直观展示了 6 种模型在 4 项指标上的分布，MAAE-SegNet 包围面积最大且形态均衡，尤其在掩膜召回率上达到 97.0% 的最高值。

多维度统计分析一致表明，MAAE-SegNet 实现了全面且显著的性能提升。

3.3 消融试验

本文基于 Mask2Former 框架，引入自适应参数激活模块（APA）与自适应参数激活增强模块（APAE），构建 MAAE-SegNet 模型。为验证各模块的有效性，采用控制变量法设计消融试验，在 Cowudder1000 数据集上训练并保留最优权重，于测试集中评估后乳房性状识别性能，分别展示检测框平均精确率、检测框平均召回率、掩膜平均精确率、掩膜平均召回率、参数量以及浮点数运算量，其结果如表 2 所示。

在分割掩膜精确率方面，于 Mask2Former 基础上引入 APA 模块后，检测框平均精确率、检测框平

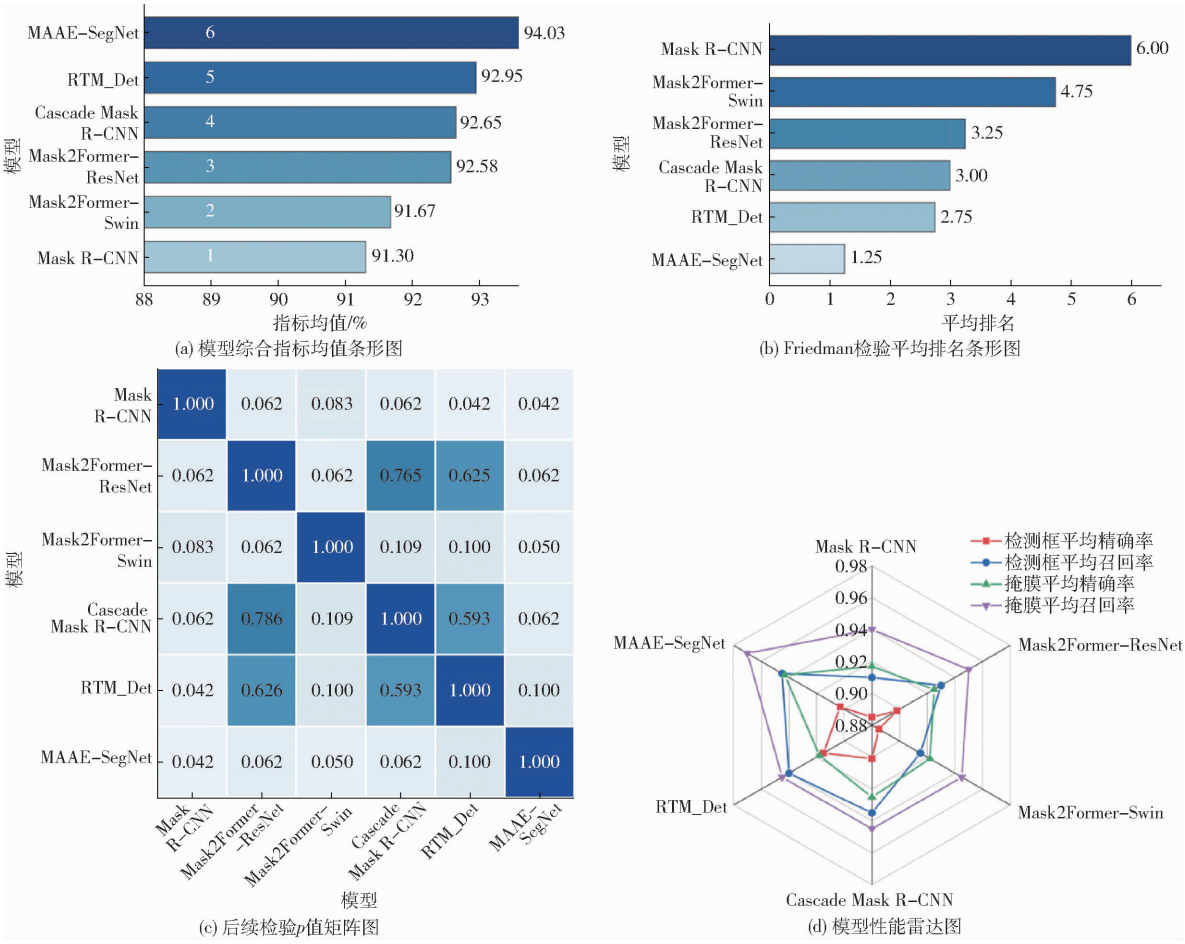

图 6　模型显著性对比分析图

Fig. 6　Graphs of model significance comparison analysis

表 2　不同改进模块的试验结果

Tab. 2　Results of different improved modules

模型	检测框平均精确率/%	检测框平均召回率/%	掩膜平均精确率/%	掩膜平均召回率/%	参数量	浮点数运算量
Mask2Former－ResNet	89.8	93.0	92.5	95.0	$4.400\,3\times10^{7}$	1.59×10^{11}
＋APA	91.9	94.5	93.3	96.0	$4.705\,0\times10^{7}$	1.59×10^{11}
＋APA＋APAE	90.3	94.5	94.3	97.0	$4.705\,5\times10^{7}$	1.59×10^{11}

均召回率、掩膜平均精确率与掩膜平均召回率分别提升 2.1、1.5、0.8、1.0 个百分点。APA 模块通过其双分支结构增强特征变换灵活性，提升了对奶牛后乳房性状的定位与分割能力。进一步加入 APAE 模块后，掩膜平均精确率提升至 94.3%，掩膜平均召回率提升至 97.0%，但检测框平均精确率略有下降，检测框平均召回率保持不变。分析认为，APAE 模块通过多尺度特征校准与长距离依赖建模，强化了通道权重的上下文感知能力，使模型更聚焦于分割任务所需的精细边界特征，但也因此弱化了全局定位能力。鉴于本研究目标为基于精准分割掩膜的自动化评分，改进策略更侧重于分割性能的提升。

在模型效率方面，浮点数运算量稳定为 1.59×10^{11}。APA 与 APAE 模块参数量分别仅增加 3.02×10^{6} 和 3.025×10^{6}，表明所提方法在控制复杂度的前提下，通过轻量化设计实现了有效的特征校准与性能提升，验证了优化策略的有效性。

为验证本文所设计动态门控注意力机制在奶牛后乳房性状分割中的有效性，在自适应参数激活增强模块中分别嵌入 DGA、图注意力网络（Graph convolutional network，GCN）及空间与通道协同注意力（Spatial channel synergistic attention，SCSA）3 种注意力模块，并系统比较了其在不同网络深度下的性能表现，试验结果如表 3 所示。

消融试验表明，注意力模块的类型与部署位置对模型精度影响显著。DGA 模块凭借多尺度特征校准与长距离依赖建模能力，在第 1 与第 4 阶段部署时性能最优，其检测框与掩膜的平均精确率分别

表 3 不同注意力机制的试验结果

Tab. 3 Results of different attention mechanisms %

模块	添加位置				检测框平均精确率	检测框平均召回率	掩膜平均精确率	掩膜平均召回率
	1	2	3	4				
DGA	√			√	90.3	94.5	94.3	97.0
	√	√	√	√	88.8	92.0	91.7	94.5
GCN	√			√	88.4	94.0	92.1	95.5
	√	√	√	√	87.9	91.5	92.3	94.5
SCSA	√			√	87.5	90.0	93.0	95.5
	√	√	√	√	83.7	89.0	93.0	96.0

达到 90.3% 和 94.3%，掩膜平均精确率较全阶段部署提升约 2.6 个百分点，有效增强了模型对乳房边缘细节与整体形态的协同建模能力。相比之下，GCN 模块全阶段部署后掩膜平均召回率由 95.5% 降至 94.4%，推测其图注意力机制在深层网络中过度聚焦局部，削弱了全局识别能力。而 SCSA 模块对性能提升有限，掩膜平均精确率维持于 93.0%。

综上，针对奶牛后乳房性状识别任务，采用 DGA 模块并配合分阶段部署策略可获得最佳的检测与分割效果。

3.4 后乳房性状分割可视化效果

为直观评估本文所提模型对奶牛后乳房性状的分割性能，图 7 选取了对比试验中 4 种代表性模型，对测试集中多视角、多光照条件下的典型样本进行可视化对比。

各子图清晰展示了原始图像与模型预测分割掩膜的叠加效果。分析可见，图 7b 中红色圆圈区域显示 Mask2Former－Swin 模型存在检测定位偏移；图 7e 绿色圆圈区域表明 RTMDet 算法出现误检现象；而图 7k 与图 7o 中的蓝色圆圈区域则反映出 Mask2Former－ResNet 模型存在掩膜分割边界模糊的问题。相比之下，MAAE－SegNet 在不同视角与光照条件下均能实现后乳房区域的精准分割，其边界完整清晰，与奶牛体表结构贴合紧密，有效克服了后肢、尾部及背景干扰。试验结果表明，该模型具备良好的鲁棒性与泛化能力，为后续性状的



(a) 高视视角，RTM_Det (b) 高视视角，Mask2Former-Swin (c) 高视视角，Mask2Former-ResNet (d) 高视视角，MAAE-SegNet
(e) 中视视角，RTM_Det (f) 中视视角，Mask2Former-Swin (g) 中视视角，Mask2Former-ResNet (h) 中视视角，MAAE-SegNet
(i) 低视视角，RTM_Det (j) 低视视角，Mask2Former-Swin (k) 低视视角，Mask2Former-ResNet (l) 低视视角，MAAE-SegNet
(m) 灯光条件，RTM_Det (n) 灯光条件，Mask2Former-Swin (o) 灯光条件，Mask2Former-ResNet (p) 灯光条件，MAAE-SegNet

图 7 奶牛后乳房性状识别可视化结果

Fig. 7 Visualization results of posterior udder trait recognition for dairy cows

自动化测量与评分提供了可靠的掩膜数据基础。

3.5　奶牛后乳房性状线性评分方法与结果分析

本文设计了奶牛后乳房性状的自动评分方法，通过将实例分割模型得到的分割掩膜转换为对奶牛后乳房 2 个关键性状后乳房附着宽度和后乳房附着高度的线性评分。奶牛后乳房附着宽度与附着高度的测量及计算方法依据《荷斯坦牛体型鉴定操作技术规范》(T－DACS002—2021)进行界定。

由图 8 文件标准可知，后乳房附着宽度定义为两后肢与乳腺组织上缘连接处之间的水平宽度。根据乳房掩膜轮廓，提取乳房上沿所有点的 X 坐标的最小值 $X_{\min}$ 与最大值 $X_{\max}$，后乳房附着宽度的像素值 W_{physical} 计算公式为

$$W_{\text{physical}} = X_{\max} - X_{\min} \tag{16}$$

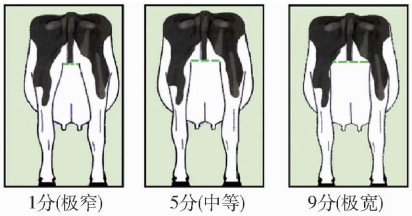

线性评分	1	2	3	4	5	6	7	8	9
后乳房附着宽度/cm	≤8	9.5	11	12.5	14	15.5	17	18.5	≤20

图 8　后乳房附着宽度评分标准

Fig. 8　Rear udder attachment width scoring standard

如图 9 标准所示，后乳房附着高度定义为后乳房乳腺组织最上缘与阴门基底部之间的垂直距离。

针对阴门基底部在图像中难以精准定位的问题，引入团队已有的尻宽检测研究成果，采用 YOLO v8 目标检测模型识别坐骨结节中心点坐标。训练数据源于团队自建的奶牛尻宽数据集 Buttocks_1000(训练集 800 幅，测试集 200 幅)，涵盖了不同的光照条件与姿态。其中 YOLO v8 在经过多次重复



线性评分	1	2	3	4	5	6	7	8	9
后乳房附着高度/cm	≥32	30	28	26	24	22	20	18	≤16

图 9　后乳房附着高度评分标准

Fig. 9　Rear udder attachment height scoring standard

训练后，取最优训练结果，在 200 轮次训练过程中得到平均精确率 93.06%、平均召回率 92.27%，结果如图 10 所示，具有较强鲁棒性。

YOLO v8 模型获取如图 11c 中红色框所示的检测框坐标后，通过计算两坐骨结节突出点的中心坐标，可得到图像中代表后乳房高度上边界的 Y 坐标 Y_{top}，该值表征坐骨结节在图像坐标系中的平均高度，后乳房高度下边界则由掩膜轮廓中 Y 坐标的最大值 $Y_{\max}$ 确定。最终，后乳房附着高度的像素值 H_{physical} 计算公式为

$$H_{\text{physical}} = Y_{\text{top}} - Y_{\max} \tag{17}$$

为将像素距离转换为实际物理距离(cm)，采用参照物标定法以获取比例系数，如图 11c 中的紫色连接线所示。在图像采集现场，于奶牛臀部附近放置已知实际长度为 L_t(cm)的标定物，通过人工标注获取其在图像中的像素长度 L_p(像素)，据此计算像素比例因子 k_r

$$k_r = \frac{L_t}{L_p} \tag{18}$$

已知像素测量值 L_{pixel} 和像素比例因子 k_r，均可转换为物理距离 L_{physical}，计算公式为

$$L_{\text{physical}} = L_{\text{pixel}} k_r \tag{19}$$

将测量得到的物理距离依据文件标准转换为线性评分。后乳房附着宽度自动化评分标准如表 4 所

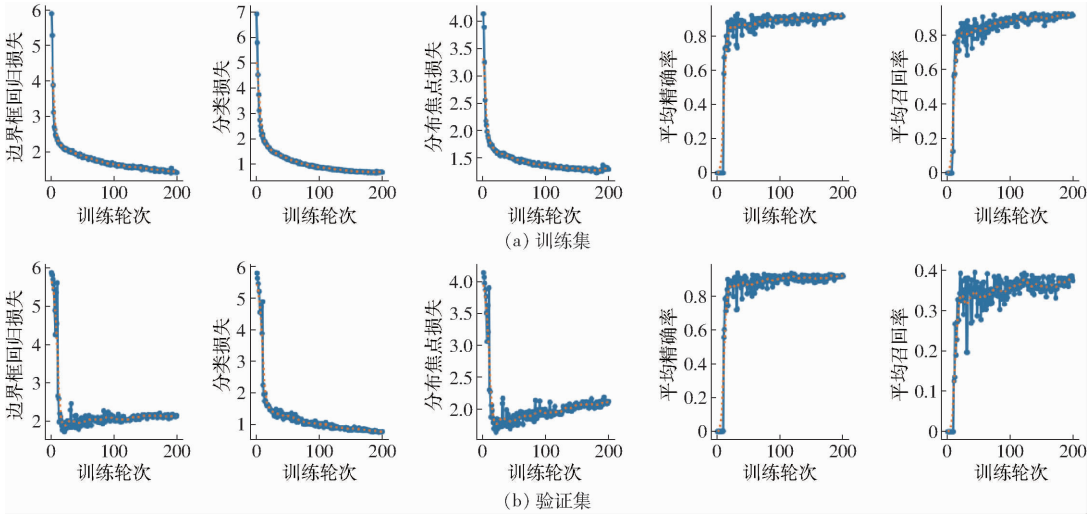

图 10　奶牛尻宽检测模型训练结果

Fig. 10　Training results of rump width detection model for dairy cows

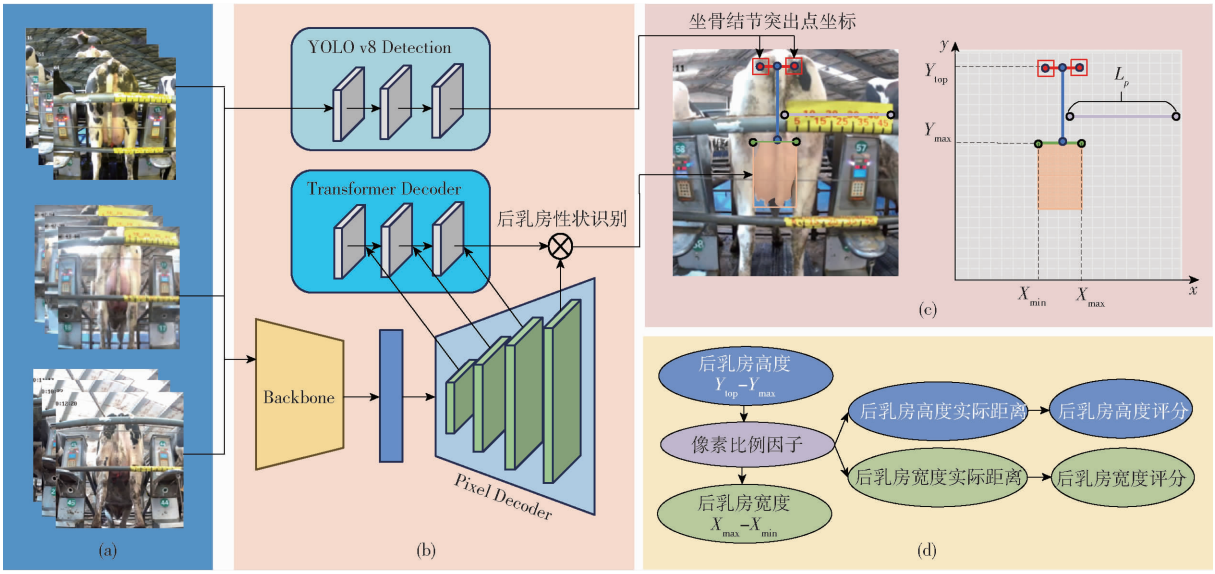

图 11 奶牛后乳房性状评分方法流程图

Fig. 11 Flowchart of scoring method for posterior udder traits of dairy cows

示,评分范围为 1 ~ 9 分,极窄评 1 分,中等评 5 分,极宽评 9 分。

表 4 后乳房附着宽度自动化评分标准

Tab. 4 Automated scoring criteria for rear udder attachment width

后乳房附着宽度物理距离/cm	后乳房附着宽度像素距离/像素	评分
≤8	≤61.25	1
9.5	61.25 ~ 71.75	2
11	71.75 ~ 82.25	3
12.5	82.25 ~ 92.75	4
14	92.75 ~ 103.25	5
15.5	103.25 ~ 113.75	6
17	113.75 ~ 124.25	7
18.5	124.25 ~ 134.75	8
≥20	≥134.75	9

后乳房附着高度自动化评分标准如表 5 所示,评分范围同样为 1 ~ 9 分,极低评 1 分,中等评 5 分,极高评 9 分。

表 5 后乳房附着高度自动化评分标准

Tab. 5 Automated scoring criteria for rear udder attachment height

后乳房附着高度物理距离/cm	后乳房附着高度像素距离/像素	评分
≥32	≥203	1
30	203 ~ 217	2
28	189 ~ 203	3
26	175 ~ 189	4
24	161 ~ 175	5
22	147 ~ 161	6
20	133 ~ 147	7
18	119 ~ 133	8
≤16	≤119	9

综上,结合掩膜信息与比例标定可实现自动化线性评分。为验证算法在遮挡及光照变化环境下的鲁棒性,选取 10 个典型样本进行人机评分对比,结果如图 12 所示。

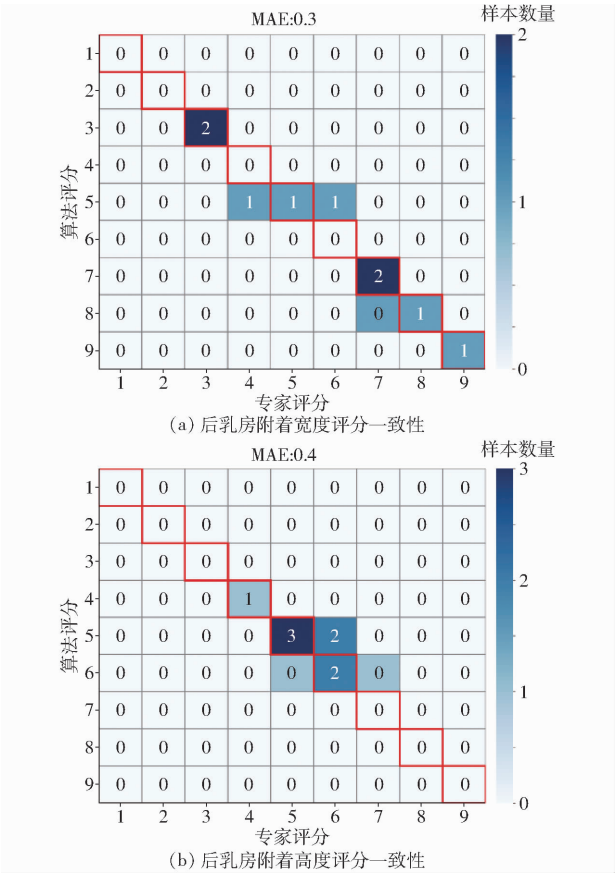

图 12 后乳房性状评分一致性热力图

Fig. 12 Heat maps of scoring consistency for posterior udder trait

分析热力图可知,自动化评分与专家评分呈现显著的一致性:后乳房附着宽度的平均绝对误差

(MAE)仅为 0.3,其中 7 个样本评分完全一致,其余偏差控制在 1 分以内。后乳房附着高度的 MAE 为 0.4,8 个样本实现完全一致。基于 MAAE - SegNet 的评分方法有效克服了复杂环境干扰,具备高精度、客观化体型鉴定的能力。

4　结论

(1)针对存在部分遮挡、光照变化等复杂环境下奶牛后乳房性状自动化评分难题,研究了基于多阶段自适应增强(MAAE - SegNet)的奶牛后乳房性状分割方法。

(2)MAAE - SegNet 分割模型在自建奶牛后乳房性状数据集上检测框平均精确率达 90.3%、召回率达 94.5%,掩膜平均精确率达 94.3%、召回率达 97.0%,模型参数量为 $4.705\,5\times10^{7}$,浮点数运算量为 1.59×10^{11},相比于基线模型 Mask2Former,在维持参数量不激增的情况下精度更高。

(3)设计了像素级映射算法实现部分遮挡、光照变化环境下,后乳房附着宽度与高度的自动化线性评分。对比专家人工评分,后乳房附着宽度自动评分平均绝对误差为 0.3,后乳房附着高度评分平均绝对误差为 0.4,平均整体评分准确率估计达 90%,能够替代人工评分方法,提升奶牛后乳房性状评定效率与客观性。

参　考　文　献

[1] 李春平,朱新培,孙开兰,等. 奶牛养殖产业发展现状及对策研究[J]. 中国乳业,2022(2):22 - 25.
Li Chunping, Zhu Xinpei, Sun Kailan, et al. Study on the development status and countermeasures of dairy farming industry [J]. China Dairy, 2022(2):22 - 25. (in Chinese)

[2] 张胜利,孙东晓. 奶牛种业的昨天、今天和明天[J]. 中国畜牧业,2021(15):22 - 26.
Zhang Shengli, Sun Dongxiao. Yesterday, today and tomorrow of dairy cattle breeding[J]. China Animal Husbandry Bulletin, 2021(15):22 - 26. (in Chinese)

[3] 范涛,张西伟. 奶牛生产性能测定及提高产奶量的养殖技术解析[J]. 吉林畜牧兽医,2024(9):118 - 120.
Fan Tao, Zhang Xiwei. Analysis of dairy cow performance testing and milk yield improvement techniques[J]. Jilin Animal Husbandry and Veterinary Medicine, 2024(9): 118 - 120. (in Chinese)

[4] 张小白,杨超群,冯欣. 国内不同地域荷斯坦牛体型差异变化分析与研究[J]. 中国奶牛,2025(3):63 - 67.
Zhang Xiaobai, Yang Chaoqun, Feng Xin. Analysis and research on the variation of Holstein cow body conformation in different regions of China[J]. China Dairy Cattle, 2025(3): 63 - 67. (in Chinese)

[5] 赵凤茹. 提升奶牛群体遗传水平的国家奶牛核心育种场管理优化研究[J]. 中国乳业, 2025(6): 93 - 99.
Zhao Fengru. Research on management optimization of national core breeding farms for improving genetic level of dairy cattle populations[J]. China Dairy, 2025(6): 93 - 99. (in Chinese)

[6] 母童, 虎红红, 冯小芳, 等. 宁夏地区荷斯坦牛乳房性状的遗传参数估计和主成分分析[J]. 畜牧兽医学报, 2021, 52(4): 954 - 966.
Mu Tong, Hu Honghong, Feng Xiaofang, et al. Genetic parameter estimation and principal component analysis of udder traits of Holstein cows in Ningxia region[J]. Chinese Journal of Animal and Veterinary Sciences, 2021, 52(4): 954 - 966. (in Chinese)

[7] 汪聪勇,武泽文,闫青霞,等. 对中国奶牛体型鉴定员体型鉴定评分偏差的分析与研究[J]. 中国奶牛,2021(8):20 - 23.
Wang Congyong, Wu Zewen, Yan Qingxia, et al. Analysis and research on scoring deviation of dairy cow type classifiers in China[J]. China Dairy Cattle, 2021(8):20 - 23. (in Chinese)

[8] 杨坤,高民,魏晓玲,等. 奶牛产奶量影响因素研究进展[J]. 中国奶牛,2023(1):10 - 13.
Yang Kun, Gao Min, Wei Xiaoling, et al. Research progress on factors affecting milk yield in dairy cows[J]. China Dairy Cattle, 2023(1): 10 - 13. (in Chinese)

[9] 吉虹锦,王语浓,张海亮,等. 北方地区娟姗牛乳房深度群体特征及其与泌乳性能的关系 [J]. 中国畜牧杂志,2024, 60(12): 200 - 206.
Ji Hongjin, Wang Yunong, Zhang Hailiang, et al. Population characteristics of udder depth in Jersey cattle in northern China and its relationship with lactation performance[J]. Chinese Journal of Animal Science, 2024, 60(12): 200 - 206. (in Chinese)

[10] 吴欣悦,卢徐斌,徐天乐,等. 苏北地区中国荷斯坦牛体型性状遗传参数及其与产奶性状关系的分析[J]. 黑龙江畜牧兽医, 2022(7): 65 - 70.
Wu Xinyue, Lu Xubin, Xu Tianle, et al. Analysis on genetic parameters of body shape traits and their relationship with milk production traits of Chinese Holstein cattle in northern Jiangsu[J]. Heilongjiang Animal Science and Veterinary Medicine, 2022(7): 65 - 70. (in Chinese)

[11] Kopec T, Filipcik R, Drizhalova B, et al. The effect of exterior traits on milk production and calving ease in Czech Fleckvieh cows in first parity[J]. Archives Animal Breeding, 2024, 67(1): 133 - 142.

[12] 赵健,周国源,王智文,等. 基于 SGPointNet + + 模型的奶牛点云分割与表型自动测定系统设计[J]. 农业机械学报, 2025,56(3): 180 - 187.
Zhao Jian, Zhou Guoyuan, Wang Zhiwen, et al. Design of automatic determination system for point cloud segmentation and

morphology of dairy cows based on SGPointNet + + model[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(3): 180 - 187. (in Chinese)

[13] 邓洪兴,许兴时,王云飞,等. 基于双目立体匹配与改进 YOLOv8n - Pose 关键点检测的奶牛体尺测量方法[J]. 华南农业大学学报,2024,45(5): 802 - 811.
Deng Hongxing, Xu Xingshi, Wang Yunfei, et al. Body size measurement method of dairy cows based on binocular stereo matching and improved YOLOv8n - Pose keypoint detection[J]. Journal of South China Agricultural University, 2024, 45(5): 802 - 811. (in Chinese)

[14] 王立中,麻硕士,薛河儒,等. 基于 SIFT 检测与匹配算法的奶牛形体图像技术研究[J]. 内蒙古农业大学学报(自然科学版),2009,30(1):238 - 242.
Wang Lizhong, Ma Shuoshi, Xue Heru, et al. Study of the technology based on SIFT detection and matching algorithm in the cow's conformation images[J]. Journal of Inner Mongolia Agricultural University (Natural Science Edition), 2009, 30(1): 238 - 242. (in Chinese)

[15] 沈维政,郭金彦,戴百生,等. 基于两阶段关键点定位算法的奶牛体型评定指标自动测量[J]. 东北农业大学学报,2022(12):82 - 90.
Shen Weizheng, Guo Jinyan, Dai Baisheng, et al. Automatic measurement of dairy cow conformation evaluation indices based on two-stage keypoint localization algorithm[J]. Journal of Northeast Agricultural University, 2022(12): 82 - 90. (in Chinese)

[16] 黄君冉,钱东平,王文娣,等. 基于图像处理技术的奶牛体型线性评定系统[J]. 农业机械学报,2007,38(4):111 - 113.
Huang Junran, Qian Dongping, Wang Wendi, et al. Developing linear appraisal of dairy cow conformation system with image processing technique[J]. Transactions of the Chinese Society for Agricultural Machinery, 2007, 38(4): 111 - 113. (in Chinese)

[17] Ladyka V I, Hmelnychyi L M, Hmelnychyi S L, et al. Parameters of measurements of the linear traits of first-calf cows Ukrainian brown dairy breed in the aspect of methodology linear classification of animal by conformation type[J]. Animal Breeding and Genetics, 2019, 58: 130 - 136.

[18] 张馨月,刘刚,经玲,等. 基于点云精简的奶牛背部体尺测点自动提取方法[J]. 农业机械学报,2019,50(增刊 1):267 - 275.
Zhang Xinyue, Liu Gang, Jing Ling, et al. Automatic extraction method of cow's back body measuring point based on simplification point cloud[J]. Transactions of the Chinese Society for Agricultural Machinery, 2019, 50(S1): 267 - 275. (in Chinese)

[19] 郭浩,王鹏,马钦,等. 基于深度图像的奶牛体型评定指标获取技术[J]. 农业机械学报,2013,44(增刊 1):273 - 276,229.
Guo Hao, Wang Peng, Ma Qin, et al. Acquisition of appraisal traits for dairy cow based on depth image[J]. Transactions of the Chinese Society for Agricultural Machinery, 2013, 44(S1): 273 - 276, 229. (in Chinese)

[20] Pezzuolo A, Guarino M, Sartori L, et al. A feasibility study on the use of a structured light depth-camera for three-dimensional body measurements of dairy cows in free-stall barns[J]. Sensors, 2018, 18(2): 673.

[21] Bello R-W, Owolawi P A, Van Wyk E A, et al. Transfer learning-driven cattle instance segmentation using deep learning models[J]. Agriculture, 2024, 14(12): 2282.

[22] 田文斌,姚渝,吕昊暾,等. 基于改进 YOLO v11n - seg 的奶牛乳房炎检测方法[J]. 农业机械学报,2025,56(6):237 - 246.
Tian Wenbin, Yao Yu, Lü Haotun, et al. Detection method for cow mastitis based on improved YOLO v11n - seg[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(6): 237 - 246. (in Chinese)

[23] Jia N, Kootstra G, Koerkamp P G, et al. Segmentation of body parts of cows in RGB-depth images based on template matching[J]. Computers and Electronics in Agriculture, 2021, 180: 105897.

[24] Yang G, Li R, Zhang S, et al. Extracting cow point clouds from multi-view RGB images with an improved YOLACT + + instance segmentation[J]. Expert Systems with Applications, 2023, 230: 120730.

[25] Salau J, Krieter J, et al. Instance segmentation with Mask R - CNN applied to loose-housed dairy cows in a multi-camera setting[J]. Animals, 2020, 10(12): 2402.

[26] Lewis R, Kostermans T, Brovold J W, et al. Automated body condition scoring in dairy cows using 2D imaging and deep learning[J]. AgriEngineering, 2025, 7(7): 241.

[27] 张勤,翁凯航. 基于 SAM 优化的饲喂目标实时识别方法[J]. 华南理工大学学报(自然科学版),2025,53(7):60 - 69.
Zhang Qin, Weng Kaihang. Real-time feeding target recognition method based on SAM optimization[J]. Journal of South China University of Technology (Natural Science Edition), 2025, 53(7): 60 - 69. (in Chinese)

[28] 李昊玥,陈桂芬,裴傲. 基于改进 Mask R - CNN 的奶牛个体识别方法研究[J]. 华南农业大学学报,2020,41(6):161 - 168.
Li Haoyue, Chen Guifen, Pei Ao. Research on dairy cow individual identification method based on improved Mask R - CNN[J]. Journal of South China Agricultural University, 2020, 41(6): 161 - 168. (in Chinese)

[29] 张姝瑾,许兴时,邓洪兴,等. 基于 YOLO v8n - seg - FCA - BiFPN 的奶牛身体分割方法[J]. 农业机械学报,2024,55(3):282 - 289,391.
Zhang Shujin, Xu Xingshi, Deng Hongxing, et al. Segmentation model of cow body parts based on YOLO v8n - seg - FCA - BiFPN[J]. Transactions of the Chinese Society for Agricultural Machinery, 2024, 55(3): 282 - 289, 391. (in Chinese)

[30] Qiao Y, Truman M, Sukkarieh S. Cattle segmentation and contour extraction based on Mask R - CNN for precision livestock farming[J]. Computers and Electronics in Agriculture, 2019, 165: 104958.