

基于改进 YOLOv8n 的猪胴体分割特征检测方法

刘春山¹ 李志昂¹ 邓文斌² 尚 涛² 肖学才¹

(1. 佳木斯大学机械工程学院, 黑龙江 佳木斯 154007;
2. 嘉兴大学机械工程学院(机器人工程学院), 浙江 嘉兴 314001)

摘要:[目的] 实现对猪胴体不易区分、相对较小的分割特征的准确、高效检测。[方法] 通过在 Backbone 层中引入 Ghost-Conv 模块和 C3Ghost 模块替代原有 YOLOv8n 特征提取网络中的普通卷积和 C2 模块, 以减少计算量, 降低模型复杂度; 将 SPPF 模块替换为 SPPELAN 模块, 使模型能更有效应对多尺度和小目标特征; 最后在 3 个检测头前面引入无参数注意力 SimAM, 提高复杂环境下对下猪胴体小目标特征的识别能力。[结果] 改进 YOLOv8n 模型在自制数据集上的 mAP50 为 97.3%, 相较原始 YOLOv8n 提高了 5.3% 的精度。改进模型的参数量 Params 和计算量 FLOPs 分别为 1.5 M 和 4.9 G, 模型大小为 3.5 MB, 仅为 YOLOv8n 的 50.0%, 60.5%, 55.6%。模型推理速度为 120.2 帧/s, 提高了 20.7 帧/s。[结论] 改进 YOLOv8n 模型在检测精度与轻量化方面具有优势, 可以有效识别猪胴体的小目标分割特征。

关键词: 猪胴体; 目标检测; YOLOv8n; C3Ghost; SPPELAN; SimAM

Segmentation feature detection method of pig carcass based on improved YOLOv8n

LIU Chunshan¹ LI Zhiang¹ DENG Wenbin² SHANG Tao² XIAO Xuecai¹

(1. College of Mechanical Engineering, Jiamusi University, Jiamusi, Heilongjiang 154007, China;
2. College of Mechanical Engineering (Robot Engineering), Jiaxing University, Jiaxing, Zhejiang 314001, China)

Abstract: [Objective] To achieve accurate and efficient detection of pig carcasses' segmentation features, which are hard to distinguish and relatively small. [Methods] The Ghost Conv module and C3Ghost module are introduced into the Backbone layer to replace the ordinary convolution and C2 modules in the original YOLOv8n feature extraction network, aiming to reduce the computational amount and model complexity. The SPPF module is replaced with the SPPELAN module, so that the model can more effectively cope with multi-scale and small target features. Finally, parameter-free attention SimAM is introduced in front of the three detection heads to improve the ability to recognize the small target features of the lower pig carcass in a complex environment. [Results] The mAP50 of the improved YOLOv8n model on the self-made dataset is 97.3%, which is 5.3% higher than that of the original YOLOv8n. The parameter Params, computational FLOPs, and the model size of the improved model are 1.5 M, 4.9 G, and 3.5 MB, respectively, which are only 50.0%, 60.5% and 55.6% of YOLOv8n. The FPS of the model inference speed is 120.2 frames/s, which is increased by 20.7 frames/s. [Conclusion] The improved YOLOv8n model has advantages in detection accuracy and lightweight, and can effectively identify the small target segmentation features of pig carcasses.

Keywords: pig carcass; target detection; YOLOv8n; C3Ghost; SPPELAN; SimAM

2023 年中国猪肉产量 5 794 万 t, 比上年增长了 4.6%^[1-2]。生猪屠宰一般包括击晕、放血、烫毛、开膛、摘内脏、劈半、分割等过程, 猪胴体分割是屠宰加工的重要一环。猪胴体分割一般从第 5~6 肋骨间和腰椎与荐椎连

基金项目:浙江省“尖兵领雁+X”研发攻关计划(编号:2024C04028);浙江省教育厅一般科研项目(编号:Y202455539);平湖市科技计划项目(编号:产业发展攻关专项 202505)

通信作者:邓文斌(1985—),男,嘉兴大学讲师,博士。E-mail: wbdeng@zjxu.edu.cn

收稿日期:2024-12-06 **改回日期:**2025-07-22

引用格式:刘春山,李志昂,邓文斌,等. 基于改进 YOLOv8n 的猪胴体分割特征检测方法[J]. 食品与机械,2025,41(11):76-83.

Citation:LIU Chunshan, LI Zhiang, DENG Wenbin, et al. Segmentation feature detection method of pig carcass based on improved YOLOv8n[J]. Food & Machinery, 2025, 41(11): 76-83.

接处下刀,分割出前、中、后3段^[3]。目前,中国屠宰行业中,猪胴体分割多为传统手工分割,生产效率低,环境卫生条件差,人工劳动强度大且识别精度难以保证。因此,将目标检测技术与猪肉分割设备结合可以实现胴体分割过程的自动化与智能化,大幅降本增效、提高产品质量^[4-5]。刘银等^[6]采用传统图像处理方法对猪胴体图像进行边缘检测并计算拐点以定位猪胴体特征。赵世达^[7]通过X射线对猪胴体进行扫描,从而获得猪胴体骨骼信息,并通过智能算法得到猪胴体分割路径。江一宇等^[8]提出了一种基于机器学习的生猪胴体分割方法,通过利用断层扫描技术对猪胴体进行扫描,获得猪胴体骨骼、肌肉、脂肪等数据后,设计分割路径,再通过机器学习得到分割路径。李春保等^[9]提出了一种猪半胴体智能分割方法,通过采集胴体质量和胴体轮廓尺寸信息,并利用胴体各部位尺寸关系函数计算胴体详细尺寸以获得详细尺寸。传统图像处理方法依赖图像质量,对光源要求高,且不能识别脂肪黏连,识别准确率较低,难以满足实际生产要求。通过X射线获取胴体特征的方法精度高,但存在成本过高以及食品辐射的风险。通过断层扫描技术构建猪胴体三维模型需要大量工作,采集效率低,不适合工厂生产条件。而通过采集胴体质量以及尺寸再通过尺寸关系函数计算胴体详细尺寸的方法精度难以保证。

近年来,随着深度学习目标检测的发展,众多学者在家畜检测方向开展了相关应用^[10],但在猪肉分割领域相关研究较少,通过目标检测算法识别猪胴体分割特征引导后续定位,将大幅提高检测效率,降低检测成本。而YOLOv8n作为最先进的目标检测算法之一,在检测精度与检测速度上均具有一定优势^[11-12]。在猪胴体图像中,分割特征目标尺寸小于原图尺寸的0.1倍,属于小目标特征^[13-14],且目标特征弱,血肉与骨头区分度不够明显,检测难度较大。在后续部署时,还需要考虑计算资源有限的问题。研究拟选择YOLOv8n作为基线模型进行改进,在Backbone层中引入轻量卷积模块GhostConv和C3Ghost模块^[15-16],替代原有YOLOv8n特征提取网络中的普通卷积和C2模块,以有效降低模型复杂度;将SPPF模块替换为SPPELAN^[17]模块,以提高模型应对多尺度目标和小目标的检测能力;最后在每个检测头前引入无参数注意力SimAM^[18],以提高对复杂环境下猪胴体小目标分割特征的识别能力,以期实现对猪胴体的小目标分割特征进行检测,为猪胴体自动化分割提供可行的目标检测方案。

1 改进YOLOv8n的猪胴体图像分割目标检测算法

1.1 YOLOv8n网络

YOLOv8^[19]是一种单阶段检测算法,利用端到端检测技术高效、准确地识别图像中存在的各种目标。在YOLO^[20]的基础上,YOLOv8进行了迭代和优化,从而在

目标检测领域中获得了广泛关注和认可。YOLOv8n^[21]是YOLOv8的n、s、m、l、x 5个版本中最小的模型,可以部署在资源受限的设备中,且处理速度具有显著优势,其网络结构如图1所示。

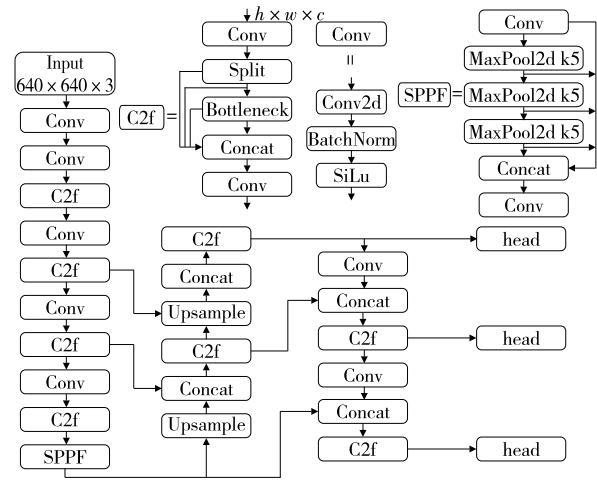


图1 YOLOv8n 网络结构图

Figure 1 YOLOv8n network

在骨干网络中,YOLOv8n采用Darknet^[22]作为其基础网络架构,这是一种由卷积层和池化层构成的深度卷积神经网络,旨在优化参数量和计算复杂度。Darknet的主要功能是从输入图像中提取特征,以实现高效的实时目标检测。在骨干网络和颈部网络之间YOLOv8n引入了SPPF模块,又被称为快速空间金字塔池化^[23-24]。SPPF模块可以有效地融合不同尺度的特征信息,从而提高模型对目标的识别能力。颈部网络采用特定FPN^[25]+PANet^[26]的结构来增强特征图的多尺度表达和信息融合能力,以实现不同尺度的特征融合。检测头是主流的解耦头结构,可以将分类任务和回归任务解耦。

1.2 改进YOLOv8n网络

猪胴体图像中的单个分割特征在图片像素中占比<2%,属于小目标特征。YOLOv8n模型不能满足较高的检测需求,且模型需面对部署设备算力有限的问题。因此,研究以YOLOv8n作为基础网络作出改进,改进后整体框架如图2所示。在Backbone层中引入轻量卷积模块GhostConv和C3Ghost模块替代原有YOLOv8n特征提取网络中的普通卷积和C2模块,通过高效的线性运算代替原本冗余的卷积操作,有效降低了模型计算量,并提高了模型对猪胴体小目标特征的检测精度。然后将SPPF模块替换为SPPELAN模块,SPPELAN模块是在SPP的基础上融合了ELAN模块,通过对多尺度特征图进行池化,能够提取不同大小的目标,后通过高效局部特征聚合机制捕捉局部特征细节,减少信息丢失,使模型能更有效检测多尺度目标和小目标特征。最后在颈部网络中引入无

参数注意力机制 SimAM, 通过推断特征图的三维注意权重, 着重识别有辨别的图像特征, 减少非目标区域的影响, 在不增加参数量的同时提高对小目标特征识别能力。

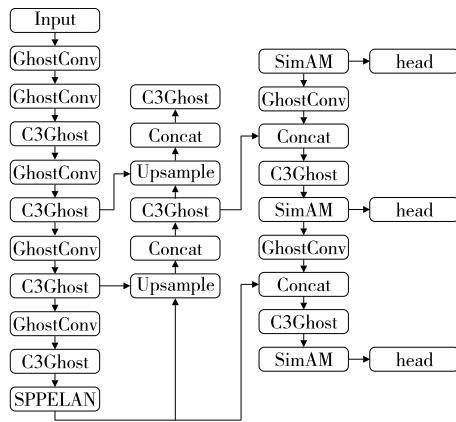


图 2 改进 YOLOv8n 网络结构图

Figure 2 Improved YOLOv8n network

1.2.1 GhostNet 模块 在传统卷积神经网络训练中, 面临着模型过于复杂, 无法在资源受限的设备上运行的问题。GhostNet 是一种可以平衡高精度和低计算成本的高效轻量级网络架构, 适合在资源有限的设备上进行部署。为了应对冗余特征带来的资源浪费问题, GhostNet 提出了 GhostConv 模块。Ghost 模块的设计显著降低了模型的计算复杂度, 从而使模型变得更加轻量化和高效。在 YOLOv8n 的骨干网络中, 将标准卷积模块替换为 GhostConv 模块, GhostConv 模块的运行原理如图 3 所示。输入特征图是一个 $C \times H \times W$ 的张量, 其中 C 为通道数, H 为输入(输出)数据的高度, W 为输入(输出)数据的宽度, n 代表输出的特征图数量, ϕ_i 代表线性运算。

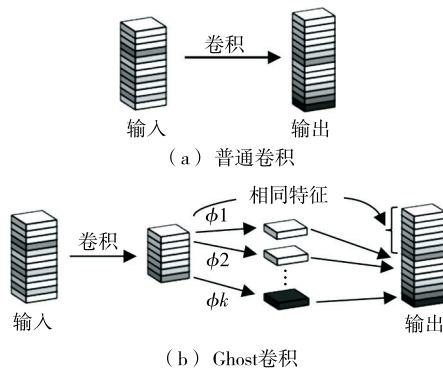


图 3 普通卷积与 Ghost 卷积

Figure 3 Common convolution and Ghost convolution

为了比较 Ghost 模块与原始的一层标准卷积操作在参数量和计算量上的差异, 假设每个线性运算的内核大小和卷积核大小均为 $K \times K$, 同时假设通过卷积得到的特

征图和通过线性变换得到的特征图数量均为 $N/2$, Ghost 模块操作流程为:首先使用标准卷积将输入特征图通道数调整为 $N/2$, 然后使用线性变换获取剩余的 $N/2$ 个特征图, 最后将这些特征图堆叠在一起得到最终的输出特征图。分别按式(1)、式(2)计算 Ghost 模块的参数量与标准卷积之比和计算量与标准卷积之比。

$$r_c = \frac{n \times c \times k \times k}{\frac{n}{2} \times c \times k \times k + \frac{n}{2} \times k \times k} = \frac{2 \times c}{c + 1} \approx 2, \quad (1)$$

$$r_s = \frac{n \times c \times k \times k \times h' \times w'}{\frac{n}{2} \times c \times k \times k \times h' \times w' + \frac{n}{2} \times k \times k \times h' \times w'} = \frac{2 \times c}{c + 1} \approx 2, \quad (2)$$

式中:

r_c —Ghost 模块的参数量与标准卷积之比;

r_s —计算量与标准卷积之比;

n —卷积核个数;

c —卷积核通道数。

GhostConv 相较于传统卷积在计算量和参数量上的下降非常显著。使用 C3Ghost 模块替换 C2f 模块, 可以实现多个卷积层之间的权重共享, 从而有效降低整体的计算复杂度。C3Ghost 的网络结构图如图 4 所示。其中, k_1 代表卷积核大小, s_1 代表步长, p_0 代表填充。在 C3Ghost 结构中, 包含了 3 个标准卷积层以及多个 GhostBottleneck 模块。每个 GhostBottleneck 结构由两个 Ghost 模块组成, 这些模块利用其显著降低的参数量和计算量特性, 有效降低了整个骨干网络的复杂度。

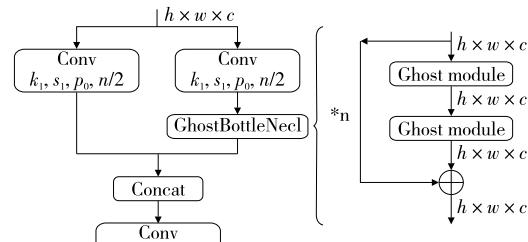


图 4 C3Ghost 结构图

Figure 4 C3Ghost structure

1.2.2 SPPELAN 模块 YOLOv8 中采用的 SPPF 模块是在 SPP 模块的基础上改进得来的简化和优化版本。SPP 模块通过对多尺度特征图进行池化操作, 提取不同尺度的特征。这种方法使得模型能够处理不同大小的目标, 增强了模型对多尺度目标的检测能力。SPPF 模块通过最大池化操作提取输入信息特征, 并利用拼接实现特征融合, 降低了模型复杂度并减少了冗余计算, 平衡了检测速度与精度。但 SPPF 的最大池化操作会丢失部分全局特征信息, 尤其是在多尺度目标和小目标特征时, 存在信息

丢失或不足,从而影响模型对目标细节的捕捉。

因此,引入 SPPELAN 模块替换 SPPF 模块。SPPELAN 模块结合了空间金字塔池化 SPP 和高效层聚合网络 ELAN。ELAN 模块通过高效局部特征聚合机制,能够更有效地整合来自图像不同区域的特征,从而更好地整合局部信息。通过精简的网络结构和高效的特征处理方法,降低了计算复杂度和参数量,从而提高了检测速度。SPPELAN 模块不仅减少了冗余特征,还提高了特征的表达能力,使得模型对细节和小目标的检测更加准确,从而更好应对复杂场景和多尺度目标。SPPELAN 中的空间金字塔池化结构如图 5 所示。

1.2.3 SimAM 注意力机制 SimAM 是一种轻量级且无需参数的卷积神经网络注意力机制。计算机视觉中现有的注意力模块主要集中在通道域或空间域。这两种注意机制与人类大脑中的基于特征的注意和基于空间的注意完全对应,但是在人脑中,这两种机制是共同作用的。表现出明显空间抑制效应的神经元在视觉加工中应该被赋予更高的优先级,在已有的空间抑制理论的基础上,研究设计了优化能量函数以挖掘特征映射中每个神经元的重

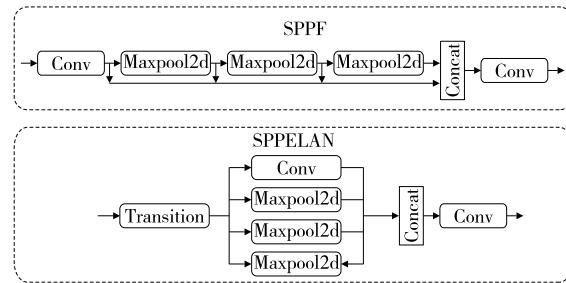


图 5 SPPF 与 SPPELAN 结构图

Figure 5 SPPF and SPPELAN structure

要性,并推导出能量函数的快速封闭解使得大部分计算均基于能量函数的解选择,避免了过多的结构调整工作。如图 6 所示,现有的通道注意力机制或空间注意力机制从特征 X 生成一维或二维权重,然后将生成的权重扩展到通道或空间注意力。与其他注意力机制相比,SimAM 注意力机制可以在不向原始网络添加参数的情况下推断出特征图的三维注意力权重,使网络能够学习到更多具有辨别的神经元,抑制无效区域的影响,以增强对小目标特征提取的效果。

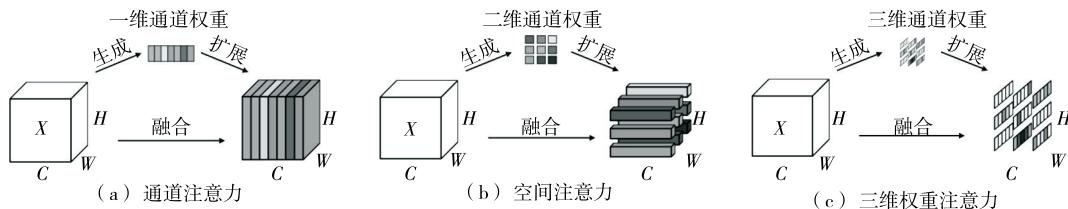


图 6 不同注意力步骤对比图

Figure 6 Comparisons of different attention steps

2 试验与方法

2.1 数据集制作

研究使用的图像采集于苏州市某食品厂的猪肉屠宰加工生产线,该猪肉屠宰加工生产线是一种在中国大多数猪肉加工企业中广泛使用的半机械化、半人工化的加工平台。这种平台对国内猪肉加工企业具有较强的普遍适用性。采集对象为经过去内脏、劈半后的二分猪胴体,品种为长白猪。采集系统由光学镜头、工业相机、三角支架、黑色背景板等组成。相机型号为海康威视 MV-120C-EDU,镜头型号为海康威视 MVL-HF0624M-10MP,相机分辨率为 4 024 像素 \times 3 036 像素。在猪肉屠宰生产线上,以固定距离与角度拍摄正常光和暗光场景下的猪胴体原始图像,共计 300 幅。猪胴体分割特征包含肋骨特征与椎荐骨特征两种。

为去除图像中的多余背景并减小图像尺寸,对拍摄得到的原始图像进行人工裁剪。由于猪胴体分割特征位于图像上下两端的特性,将图像中间横向切块,得到上下两

张包含分割特征的图像以降低计算量、加速处理时间。经图像切块后,使用镜像翻转进行数据扩充,共得到 1 200 幅猪胴体图像。使用 LabelImg 工具对猪胴体分割特征进行标注,将包含猪胴体分割特征的类别及位置等信息存储在对应 txt 文件中。将试验数据按 8:1:1 划分为训练集、验证集和测试集。在实际生产过程中,通过调整猪胴体间距以及增加背景板解决存在多余背景的问题。另外,在生产线安装传感器,猪胴体可停止在采集位置,通过传统视觉技术提取固定位置的 ROI(感兴趣区域),再将 ROI 区域图片进行目标检测推理。

2.2 评价指标

研究采用 mAP₅₀^[27]、FLOPs^[28]、Params^[29]、FPS^[30] 和 Model-size^[31]作为衡量目标检测效果的指标。其中,mAP₅₀ 为 IoU 阈值为 0.5 时所有类别的平均检测精度;Params 表示参数量,即模型所包含的参数的数量,数值越低模型计算量越少;FLOPs 表示浮点运算次数,数值越低表示模型复杂度越低;FPS 为每秒传输帧数,用来表示检测速度,FPS 值越高检测速度越快,Model-size 用来表示

模型大小，并分别按(3)~式(7)进行计算。

$$P = \frac{T_p}{T_p + F_p}, \quad (3)$$

$$R = \frac{T_p}{T_p + F_n}, \quad (4)$$

$$AP = \int_0^1 P(R) dR, \quad (5)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i, \quad (6)$$

$$FPS = 1000ms / (t_1 + t_2 + t_3), \quad (7)$$

式中：

P ——准确率，%；

R ——召回率，%；

T_p ——正确检测到的阳性样本数；

F_n ——错误检测到的阴性样本数；

F_p ——正确检测到的阴性样本数^[32]；

AP——平均精度，%；

mAP——不同类别 AP 的均值，%；

N ——检测类别数，取 2；

t_1 ——图像预处理时间，ms；

t_2 ——图像推理时间，ms；

t_3 ——后处理时间，ms。

2.3 试验环境与配置

试验在 Windows10 系统上运行，搭载 Intel(R) Core(TM)i9-10900K CPU，主频 3.7 GHz，最高睿频 4.8 GHz，NVIDIA Quadro RTX 4000 显卡，GPU 加速库 CUDA 版本为 12.4，Python3.9，深度学习框架为 Pytorch2.4.0。初始学习率为 0.01，动量初始值为 0.937，权重衰减系数为 0.000 5，图像输入尺寸为 640 像素 × 640 像素，batch-size 为 16，选择 AdamW 优化器，训练轮次为 500，IoU 阈值为 0.5。

3 结果与分析

3.1 消融试验

为了测试研究提出的每种改进方法的可行性，详细分析 Ghost 模块、SPPELAN 模块和 SimAM 注意力机制的可行性与有效性，使用自制猪胴体图像数据集对 YOLOv8n 作为改进的基础网络进行消融试验并在验证集上测试分割特征的检测性能，结果见表 1。

表 1 消融试验对比结果

Table 1 Comparative results of ablation experiments

模型	模块			mAP50/%	参数量 (×10 ⁶)	计算量 (×10 ⁹)	模型大小/ MB	FPS/ (帧·s ⁻¹)
	Ghost	SimAM	SPPELAN					
YOLOv8n	×	×	×	92.0	3.0	8.1	6.3	99.5
	√	×	×	96.4	1.7	5.0	3.8	108.6
	×	√	×	97.0	3.0	8.1	6.3	107.0
	×	×	√	96.3	2.8	8.0	5.9	104.7
	×	√	√	95.8	2.8	8.0	5.9	110.4
	√	×	√	96.3	2.2	6.8	4.6	104.1
	√	√	×	97.2	1.7	5.0	3.8	101.0
	√	√	√	97.3	1.5	4.9	3.5	120.2

由表 1 可知，在骨干特征提取网络中，将原有的 C2f 和 Conv 模块分别替换为 C3Ghost 和 GhostConv 模块，相比原 YOLOv8n 其 mAP50 上升了 4.4 个百分点，同时计算量 FLOPs 从 8.1 G 降至 5.0 G，参数量 Params 从 3.0 M 降至 1.7 M，模型大小从 6.3 MB 降至 3.8 MB，模型计算速度也有所提升；相比原 YOLOv8n，在颈部网络中引入 3 个无参数注意力机制 SimAM，在计算量 FLOPs、参数量和模型大小均保持不变的情况下，其 mAP50 从 92.0 升至 97.0，上升了 5.0 个百分点；将 SPPF 替换为 SPPELAN，相比原 YOLOv8n，其 mAP50 上升了 4.3 个百分点，同时计算量 FLOPs 降低了 0.1 G，参数量 Params 从 3.0 M 降至 2.8 M，模型大小从 6.3 MB 降至 5.9 MB。相比于只引入 3 个无参数注意力机制 SimAM 的模型，在此基础上将原有的 C2f 和 Conv 模块分别替换为 C3Ghost 和 GhostConv 模块后，

在 mAP50 提升至 97.2% 的情况下，计算量 FLOPs 降低了 3.1 G，参数量 Params 从 3.0 M 降至 1.7 M，模型大小从 6.3 MB 降至 3.8 MB。在引入 SimAM、C3Ghost 和 GhostConv 模块的基础上，将 SPPF 替换为 SPPELAN，其参数量 Params 降低了 0.2 M，计算量 FLOPs 降低了 0.1 G，模型大小降低了 0.3 MB，同时 mAP50 提升至 97.3%。综上，引入 C3Ghost 和 GhostConv 模块，并引入无参数注意力机制 SimAM 和 SPPELAN 可有效提升模型对猪胴体小目标特征检测精度，保证模型的轻量化，验证了提出的改进 YOLOv8n 算法的有效性。

3.2 不同注意力机制对比试验

为了评估网络模型在引入不同注意力机制后的性能表现，对改进 YOLOv8n 中的 SimAM 注意力模块进行了替换试验。将 SimAM 分别替换为 SE、ECA 和 SA，对比结

果见表2。由表2可知,使用SimAM注意力机制的改进模型,其mAP50为97.3%,相比SE、ECA、SA分别高出1.8%、3.6%、6.3%。使用SimAM注意力机制的改进模型,其FPS最高,相比SE、ECA、SA分别高出27.1%、22.3%、27.4%。对比SimAM注意力机制,其他注意力机制的参数量、浮点计算量和模型大小几乎没有变化。综上,SimAM注意力机制在保持模型轻量化的基础上检测精度最高,且检测速度最快。

表2 不同注意力机制对比试验

Table 2 Comparative experiment of different attention mechanisms

注意力机制	mAP50/%	参数量($\times 10^6$)	计算量($\times 10^9$)	模型大小/MB	FPS/(帧·s ⁻¹)
SE	95.5	1.5	4.9	3.5	93.1
ECA	93.7	1.5	4.9	3.4	97.9
SA	91.0	1.5	4.9	3.4	92.8
SimAM	97.3	1.5	4.9	3.5	120.2

3.3 不同模型对比试验

为验证研究提出的改进算法对猪胴体分割特征检测的优势,在自制猪胴体图像数据集下,将其与当前主流算法YOLOv5n、YOLOv5s、YOLOv7-Tiny、YOLOv8n进行综合性能对比,结果见表3。

由表3可知,对比YOLOv5n,试验改进模型的FLOPs高出0.9 G,但比Params、Model_size分别低11.8%、10.2%,FPS增加了9.1帧/s。试验改进模型在模型轻量化

表3 不同模型对比实验

Table 3 Comparative experiment of different models

模型	mAP50/%	参数量($\times 10^6$)	计算量($\times 10^9$)	模型大小/MB	FPS/(帧·s ⁻¹)
YOLOv5n	90.7	1.7	4.1	3.9	111.1
YOLOv5s	91.3	7.0	15.8	14.4	96.2
YOLOv7-tiny	92.1	6.0	13.2	12.3	51.8
YOLOv8n	92.0	3.0	8.1	6.3	99.5
试验模型	97.3	1.5	4.9	3.5	120.2

方面比YOLOv5n更有优势,且YOLOv5n的mAP50最低。与YOLOv5s和YOLOv7-tiny模型相比,改进模型GES-YOLOv8n的mAP50分别提高了6.0%和5.2%,Params分别降低了5.5,4.5 M。改进模型的计算量FLOPs为YOLOv5s和YOLOv7-tiny的31.0%和37.1%,模型权重大小为YOLOv5s和YOLOv7-tiny的24.3%和28.5%,检测速度远高于YOLOv5s和YOLOv7-tiny。相比原YOLOv8n模型,改进YOLOv8n算法精度更高,参数量计算量以及模型权重大小均更低,检测速度更快。综上,研究提出的改进模型的检测精度与速度均最优,模型轻量化效果最好,同时检测速度最快,可以满足猪胴体分割生产线的要求

3.4 检测结果可视化

为直观展示检测效果,选择YOLOv8n和改进模型对猪胴体分割特征的检测结果进行可视化试验,分别将椎荐骨目标和肋骨目标在暗光、正常光两种场景下进行对比,结果如图7所示。由图7可知,在暗光和正常光场景

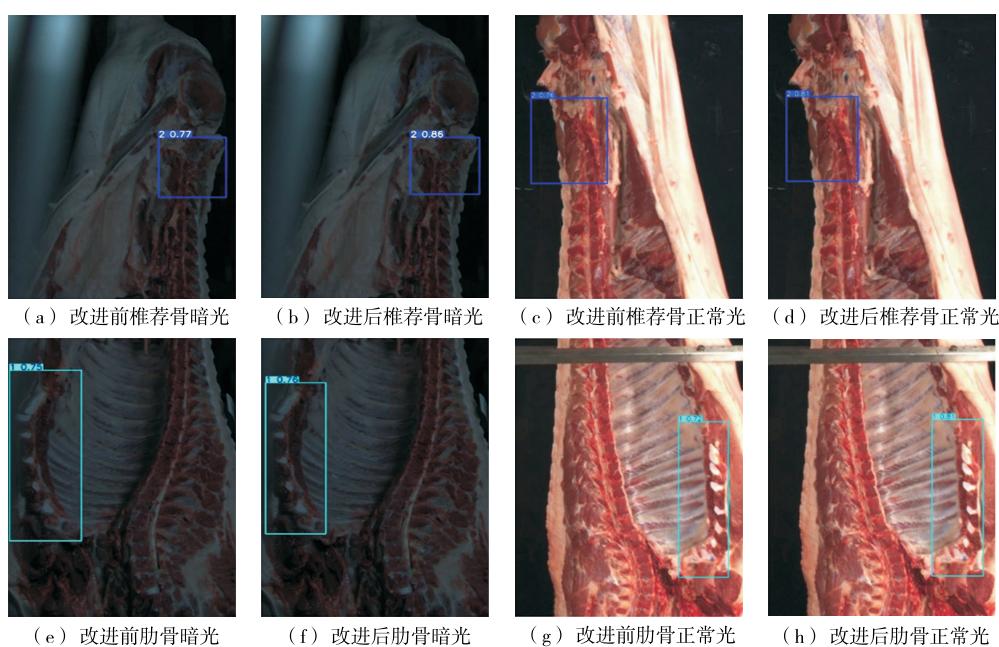


图7 改进前后检测效果对比

Figure 7 Comparison of detection results before and after improvement

下,改进后模型的预测框更加切合真实框,且改进模型的置信度均高于基准模型。表明改进模型可以有效检测猪胴体的小目标分割特征,其检测效果更好,且鲁棒性更强。

4 结论

为应对传统图像处理方法对光源要求高、识别精度低,并解决目标检测过程中分割目标较小、目标特征不明显以及设备计算资源限制等问题,提出了一种基于改进YOLOv8n的猪胴体分割特征检测方法。在Backbone层中引入轻量卷积模块GhostConv和C3Ghost模块替代原有YOLOv8n特征提取网络中的普通卷积C2模块,在减少模型计算量的同时提高了对小目标特征的检测精度。将SPPF模块替换为SPPELAN模块,使模型能更有效捕捉多尺度目标和小目标特征,并提高了模型检测精度与速度。在3个检测头前引入无参数注意力SimAM,在不增加参数量的情况下,大幅提高了模型对猪胴体小目标特征识别能力。通过对自制数据集进行试验,试验算法检测速度为120帧/s,平均精度均值mAP50为97.3%,满足实际应用要求。综上,研究提出的改进模型在模型大小、检测精度和检测速度方面均优于原YOLOv8n模型。改进的模型对猪胴体的小目标分割特征可以有效进行实时检测识别。由于猪胴体图像数据采集困难,研究中的数据集的规模与多样性仍有提升空间,后续研究中将进一步采集更多不同场景下的猪胴体分割图像,增加数据集样本量与多样性,以提高模型的泛化能力。

参考文献

- [1] 国家统计局. 中华人民共和国2023年国民经济和社会发展统计公报[J]. 中国统计, 2024(3): 4-21.
- [2] 赵文豪. 我国猪肉产业国际竞争力研究[D]. 福州: 福州大学, 2019.
- [3] 国家市场监督管理总局, 国家标准化管理委员会. 畜禽肉分割技术规程 猪肉: GB/T 40466—2021[S]. 北京: 中国标准出版社, 2021.
- [4] 王志伟, 王志刚, 陈静. 推进生猪屠宰业转型升级的思考与建议[J]. 猪业科学, 2020, 37(9): 122-123.
- [5] 高胜普, 温晓辉, 孟庆阳, 等. 中国畜禽屠宰加工装备产业发展现状及趋势[J]. 肉类工业, 2021(1): 23-27.
- [6] GAO S P, WEN X H, MENG Q Y, et al. Development status and trend of slaughtering and processing equipment industry of livestock and poultry in China[J]. Meat Industry, 2021(1): 23-27.
- [7] 刘银, 郑丽敏, 朱虹, 等. 改进的Canny算法对猪胴体特征有效分割的研究[J]. 农业网络信息, 2014(4): 56-60.
- [8] LIU Y, ZHENG L M, ZHU H, et al. Research on the effective segmentation of pig carcass characteristics based on improved canny algorithm[J]. Agriculture Network Information, 2014(4): 56-60.
- [9] 赵世达. 羊骨架关键部位识别方法及自动切割系统研发[D]. 武汉: 华中农业大学, 2022.
- [10] ZHAO S D. Identification method of key parts of sheep skeleton and research and development of automatic cutting system[D]. Wuhan: Huazhong Agricultural University, 2022.
- [11] 江一宇, 杨耀国. 基于机器学习的生猪胴体分割方法及系统: CN113643401A[P]. 2021-11-12.
- [12] JIANG Y Y, YANG Y G. Pig carcass segmentation method and system based on machine learning: CN113643401A[P]. 2021-11-12.
- [13] 李春保, 高廷轩, 陈玉仑, 等. 一种猪半胴体智能分割方法: CN114342986B[P]. 2023-03-28.
- [14] LI C B, GAO T X, CHEN Y L, et al. An intelligent segmentation method for pig semi-carcass: CN114342986B[P]. 2023-03-28.
- [15] 赵世达, 王树才, 李振强, 等. 基于U型卷积神经网络的羊肋排图像分割[J]. 食品与机械, 2020, 36(9): 116-121, 154.
- [16] ZHAO S D, WANG S C, LI Z Q, et al. Image segmentation of sheep ribs based on U-shaped convolutional neural network[J]. Food & Machinery, 2020, 36(9): 116-121, 154.
- [17] ZHANG X R, WANG Y L, FANG H S. Steel surface defect detection algorithm based on ESI-YOLOv8[J]. Materials Research Express, 2024, 11(5): 056509.
- [18] 唐兴萍, 王白娟, 杨红欣, 等. 基于YOLOv8的水果外观检测与分类方法[J]. 食品与机械, 2024, 40(7): 103-110.
- [19] TANG X P, WANG B J, YANG H X, et al. Research on fruit appearance detection and classification method based on YOLOv8[J]. Food & Machinery, 2024, 40(7): 103-110.
- [20] 刘颖, 刘红燕, 范九伦, 等. 基于深度学习的小目标检测研究与应用综述[J]. 电子学报, 2020, 48(3): 590-601.
- [21] LIU Y, LIU H Y, FAN J L, et al. A survey of research and application of small object detection based on deep learning[J]. Acta Electronica Sinica, 2020, 48(3): 590-601.
- [22] 张志凯, 韩红章, 赵雪芊, 等. 基于改进YOLOv3模型的软包装食品自动识别方法[J]. 食品与机械, 2023, 39(5): 95-100.
- [23] ZHANG Z K, HAN H Z, ZHAO X Q, et al. Automatic recognition method for soft packaged food based on improved

- YOLOv3 model[J]. Food & Machinery, 2023, 39(5): 95-100.
- [15] HAN K, WANG Y H, TIAN Q, et al. GhostNet: more features from cheap operations[C]// 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, WA: IEEE, 2020: 1 577-1 586.
- [16] 崔家乐,曾祥峰,任政威,等.基于轻量化 Ghost-YOLOv8 和智能手机的田间水稻有效分蘖检测方法[J].智慧农业(中英文),2024, 6(5): 98-107.
- CUI J L, ZENG X F, REN Z W, et al. Detection method of effective tillering of rice in field based on lightweight ghost-YOLOv8 and smart phone[J]. Smart Agriculture, 2024, 6(5): 98-107.
- [17] 王福奇,王志峰,金建成,等.基于 GSL-YOLO 模型的综放工作面混矸率检测方法[J].工矿自动化,2024, 50(9): 59-65, 137.
- WANG F Q, WANG Z F, JIN J C, et al. Detection method for gangue mixed ratio in fully mechanized caving faces based on the GSL-YOLO model[J]. Journal of Mine Automation, 2024, 50(9): 59-65, 137.
- [18] YANG L X, ZHANG R Y, LI L D, et al. Simam: a simple, parameter-free attention module for convolutional neural networks[C]// Proceeding of the 38th International Conference on Machine Learning. Virtual: PMLR, 2021: 11 863-11 874.
- [19] CHENG G, CHAO P Z, YANG J, et al. SGST-YOLOv8: an improved lightweight YOLOv8 for real-time target detection for campus surveillance[J]. Applied Sciences, 2024, 14(12): 5 341.
- [20] JIANG P Y, ERGU D, LIU F Y, et al. A review of yolo algorithm developments[J]. Procedia Computer Science, 2022, 199: 1 066-1 073.
- [21] MA S B, LIU Y N, ZHANG Y P. Fabric defect detection based on improved lightweight YOLOv8n[J]. Applied Sciences, 2024, 14(17): 8 000.
- [22] MA S Z, LU H M, LIU J, et al. LAYN: lightweight multi-scale attention YOLOv8 network for small object detection[J]. IEEE Access, 2024, 12: 29 294-29 307.
- [23] JOOSHIN H K, NANGIR M, SEYEDARABI H. Inception-YOLO: computational cost and accuracy improvement of the YOLOv5 model based on employing modified CSP, SPPF, and inception modules[J]. IET Image Processing, 2024, 18(8): 1 985-1 999.
- [24] HE K M, ZHANG X Y, REN S Q, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition [C]// Computer Vision-ECCV 2014. Cham: Springer International Publishing, 2014: 346-361.
- [25] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]// 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI: IEEE, 2017: 936-944.
- [26] LIU S, QI L, QIN H F, et al. Path aggregation network for instance segmentation[C]// 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT: IEEE, 2018: 8 759-8 768.
- [27] LIN T Y, MAIRE M, BELONGIE S, et al. Microsoft COCO: common objects in context[M]// Computer Vision-ECCV 2014. Cham: Springer International Publishing, 2014: 740-755.
- [28] TANG R, ADHIKARI A, LIN J. FLOPs as a direct optimization objective for learning sparse neural networks[EB/OL]. (2018-11-07) [2025-02-26]. <https://arxiv.org/abs/1811.03060v2>.
- [29] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV: IEEE, 2016: 770-778.
- [30] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]// 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV: IEEE, 2016: 779-788.
- [31] HAN Y Z, HUANG G, SONG S J, et al. Dynamic neural networks: a survey[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(11): 7 436-7 456.
- [32] POWERS D M W. Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation [J]. Journal of Machine Learning Technologies, 2011, 2(1): 2 229.