

基于改进YOLOv8s-Seg的鸡蛋沙壳区域分割方法研究

张艳¹,孙震^{1*},陈嵩¹,王鲁^{2**}

1. 山东农业大学信息科学与工程学院,山东 泰安 271018

2. 山东女子学院人工智能学院,山东 济南 250300

摘要: 本文针对鸡蛋品质评估及蛋鸡饲养状况监测中的自动化检测需求,提出了YOLOv8-CTAC模型,以解决沙壳蛋蛋壳表面粗糙钙化物的自动分割难题。针对YOLOv8s-Seg模型在处理多尺度信息、特征表达及关键区域关注度方面的不足,本文通过整合尺度序列特征融合(SSFF)模块、三重特征编码(TFE)模块和通道与位置注意力机制(CPAM)模块,优化了模型的特征提取与表达能力。同时,为应对沙壳类别不平衡问题,引入了变焦损失(VFL)函数。实验结果表明,YOLOv8-CTAC模型在边界框(box)和掩码(mask)两个评估层面上的准确率、召回率和平均精度均值相较于YOLOv8s-Seg模型分别提升了6.7%、8.3%、7.4%和8.3%、8.9%、8.2%,且在平均精准度均值上相较于Mask R-CNN、SOLOv2、YOLOv8n-Seg及YOLOv8s-Seg等主流算法分别提升了3.2%、10.1%、10.3%、6.7%,显著优化了复杂沙壳区域的检测效果,为沙壳蛋的自动化检测和分割任务提供了强有力的技术支撑和方法保障。

关键词: 深度学习; 多尺度特征提取; 图像分割; YOLOv8s; 沙壳蛋

中图法分类号: TP391.4

文献标识码: A

文章编号: 1000-2324(2025)06-0938-11

Eggshell Sand Area Segmentation Method Based on Improved YOLOv8s-Seg

ZHANG Yan¹, SUN Zhen^{1*}, CHEN Song¹, WANG Lu^{2**}

1. College of Information Science and Engineering/Shandong Agricultural University, Tai'an 271018, China

2. College of Artificial Intelligence/Shandong Women's University Shandong, Jinan 250300, China

Abstract: To address the automated detection needs in egg quality assessment and laying hen rearing condition monitoring, this paper proposes the YOLOv8-CTAC model to solve the problem of automatic segmentation of rough calcified matter on the surface of sand-shelled eggshells. Aiming at the shortcomings of YOLOv8s-Seg model in handling multi-scale information, feature expression, and attention to key regions, this study optimizes the feature extraction and expression ability of the model by integrating the Scale Sequence Feature Fusion (SSFF) module, Triple Feature Encoding (TFE) module, and Channel and Position Attention Mechanism (CPAM) module. Meanwhile, to cope with the sand shell category imbalance problem, the Varifocal Loss (VFL) function is introduced. The experimental results show that the YOLOv8-CTAC model exhibits significant improvements in both bounding box and mask evaluation aspects. Compared to the YOLOv8s-Seg model, it achieves enhancements of 6.7% in accuracy, 8.3% in recall, and 7.4% in mean Average Precision (mAP) for bounding box evaluation. For mask evaluation, it improves by 8.3% in accuracy, 8.9% in recall, and 8.2% in mAP. Moreover, compared to mainstream algorithms such as Mask R-CNN, SOLOv2, YOLOv8n-Seg, and YOLOv8s-Seg, it achieves an average improvement of 3.2%, 10.1%, 10.3%, and 6.7% respectively in mAP, significantly enhancing the detection performance in complex sandy-shell regions. This provides robust technical support and methodological assurance for the automated detection and segmentation tasks of sandy-shell eggs.

Keywords: Deep learning; multi-scale feature extraction; image segmentation; YOLOv8s; sand-shelled eggs

鸡蛋作为日常消费品,含有丰富的营养物质,深受广大消费者的青睐^[1],并在消费市场中占据着举足轻重的位置。2023年,我国鸡蛋年总产量已达3 563万t,且未来一段时期该行业仍然向好^[2]。在当前的消费市场上,鸡蛋品质已经

成为生产者和消费者共同关注的焦点,其中,蛋壳质量,蛋形指数等外在性状对运输过程中的鸡蛋破损率有决定作用,这直接影响着生产者的经济效益^[3]。

近年来,基于深度学习的目标检测和图像分

收稿日期: 2024-12-06

修回日期: 2025-11-12

第1作者简介: 张艳(1979-),女,硕士,副教授,研究方向:农业信息化。E-mail: zhangyandxy@sdau.edu.cn

*同等贡献作者简介: 孙震(2001-),男,硕士研究生,研究方向:计算机视觉。E-mail: 2658130549@qq.com

**通讯作者: Author for correspondence. E-mail: wangl@sdau.edu.cn

割技术发展迅猛。在禽蛋检测领域,Zhang等^[4]研究了一种改进的三通道卷积神经网络(T-CNN)用于鸡蛋检测和分割,包括利用中值滤波、OTSU方法进行分割,以及Kirsch算子用于边缘提取,并使用支持向量机(SVM)进行分类。为了准确检测可孵化和不可孵化的鸡蛋,Saifullah等^[5]强调了CNN迁移学习在非破坏性孵化检测中的潜力,并强调需要进一步的研究来提高模型的能力,以确保准确的分类。刘雪等^[6]改进的MobileNetV3-DA模型为鸡蛋供应链各环节进行鸡蛋新鲜度快速、准确识别提供了算法支持。胡建超^[7]以粉壳鸡蛋为研究对象,结合图像处理与深度学习技术,通过提取鸡蛋缺陷特征建立模型可以实现对裂纹蛋的有效判别。W TANG等^[8]提出一种在线检测识别破损皮蛋的方法,即MobileNetV3_egg模型,利用矩阵拼接方案对破损皮蛋进行识别,准确率达到96.3%。祝志慧等^[9]提出一种基于改进YOLOv7模型的复杂环境鸭蛋检测方法,在主干网络加入卷积注意力模块CBAM,加强网络信息传递,提高模型对特征的敏感程度,减少复杂环境对鸭蛋识别干扰。Y Luo等^[10]提出了一种基于改进YOLOv5网络的漏蛋检测模型。将双向特征金字塔网络(BiFPN)替换为特征金字塔网络和路径聚合网络(FPNPANet),在不增加计算成本的情况下提高了多尺度目标识别能力。赵祚喜等^[11]提出了一种基于改进YOLOv7的破壳鸡蛋在线实时检测系统,该系统通过优化网络结构和训练策略,有效提高了鸡蛋品质检测的效率和准确性。Yang等^[12]设计了一套基于计算机视觉的自动鸡蛋分级与缺陷检测系统,该系统能够自动对鸡蛋进行分级并检测缺陷,如裂纹、污渍等,提高了鸡蛋分级的效率和准确性。Lim等^[13]则利用支持

向量机构建了一个基于视觉的鸡蛋分级系统,进一步丰富了鸡蛋分级技术的研究内容。类似地,Jiang等^[14]针对鸽子蛋检测任务提出了改进的YOLOv8模型,通过轻量化设计,在保证检测精度的同时降低了模型复杂度,适用于资源受限的嵌入式设备。

上述主要研究工作主要涉及对边缘光滑的大中型待检区域进行检测和分割,而对小型且边缘不规则区域研究相对较少。沙壳蛋是典型蛋壳缺陷,其表面沙壳区域导致厚度不均,边缘不规则且易损,且蛋鸡饲养专业研究人员可根据沙壳蛋沙化情况判断蛋鸡健康状况,因此,本文提出基于改进YOLOv8s-Seg的鸡蛋沙壳区域目标检测与分割算法,为鸡蛋品质分级和蛋鸡饲养健康状况评估提供技术理论支持。

1 数据采集与预处理

1.1 数据采集

本文数据采集地为山东省济宁市汶上县农业科技产业园,时间为2024年8月1日至2024年8月17日,每天09:00-15:00。采集环境为室内,光源为自然光。选取芦花鸡蛋为拍摄对象,使用Xiaomi Redmi K70手机(主摄像头分辨率3 072×4 096像素,光圈f/1.8)进行图像采集,为了降低计算复杂度,所有图像在输入模型前被下采样至1 024×1 024像素。根据蛋壳表面粗糙区域(沙壳区域)常分布于赤道端、尖端和钝端的特点,本文选取拍摄角度为赤道端左侧(赤道端1)、赤道端右侧(赤道端2)、尖端、钝端四个角度,如图1所示,以此建立数据集。在选取鸡蛋过程中,特意挑选不同光泽(高光、哑光)、不同蛋壳颜色(浅褐色、深褐色、白色)、不同大小(重量范围为50~70 g)、不同鸡龄(6~12个月)所产鸡蛋,旨在提升




图1 数据采集示例图

Fig. 1 Data collection example diagram

数据集的多样性和鲁棒性,确保模型在不同条件下的泛化能力。每枚鸡蛋从四个角度拍摄,最终获得 3 256 张图像。

1.2 数据预处理

本文将按照下面四个步骤进行数据预处理,以得到最终实验所需的数据集。

(1)数据集筛选。采取人工筛选的方式,对所采集到的图像依据清晰度大小、是否有缺失等指标进行筛选。最终得到 3 164 张图像。




(2)数据集划分。将获取到的图像数据,按照 7:2:1 的比例划分为训练集、验证集、测试集三部分。各部分图像数量分别为 2 215 张,633 张和 316 张。

(3)数据增强。由于筛选后的图像数量难以达到模型训练所需的规模,因此本文对所建立的数据集进行了图像增强处理,包括添加随机高斯噪声、进行随机旋转、调整随机亮度以及改变随机尺寸。经过这些处理后,训练集、验证集和测试集分别扩充至 4 634 张、1 324 张和 662 张图像。

(4)数据集标注。使用 Labelme 工具对数据标注,包括点状沙壳、面状沙壳和光滑区域三类标签,并制作成 YOLO 格式的分割数据集。具体类别特征如表 1 所示。

表 1 各类别典型特征

Table 1 Typical characteristics of various categories

类别 Class	典型特征 Typical characteristics
点状沙壳 (Point)	
面状沙壳 (Area)	
光滑蛋壳 (Edge)	

2 沙壳区域分割方法

2.1 YOLOv8s-Seg 模型结构

在深度学习领域,YOLO 系列框架以其高效的实时目标检测能力而著称,其框架架构主要有三部分组成:Backbone(主干网络)、Neck(颈部网络)和 Head(头部网络)。随着技术的演进,YOLOv8 引入了一系列创新,特别是在网络主干

设计上,采用了 c2f 这样的新型模块^[15]。c2f 模块相较于 YOLOv5 中的 c3 模块^[16],在保持特征图尺寸一致性的同时,通过更少的参数实现了更深的特征提取,显著提升了特征表示能力。

YOLOv8 中,Backbone 层提取多尺度特征图(P1-P5),捕捉细节和上下文信息以提高检测准确性。YOLOv8-Seg 是一种高效实例分割算法^[17,18],对于沙壳蛋沙壳区域分割任务,YOLOv8-Seg 模型展现了其强大的灵活性和适应性。通过采用解耦头的设计,YOLOv8-seg 能够生成针对边界框回归(Box)、类别预测(Cls)以及实例分割(Mask)的专用特征图。特别地,Head 层生成的 Mask 特征图包含了丰富的空间信息,能够精确地描绘出沙壳蛋的沙壳区域轮廓。本文通过结合 YOLOv8s-Seg 模型的高效检测能力和精确分割能力,可以实现对沙壳蛋沙壳区域的快速、准确识别与分割,为相关行业的自动化处理流程提供有力支持。YOLOv8s-Seg 网络模型工作路线如图 2 所示。

2.2 YOLOv8-CTAC 模型结构

本文提出了一种基于 YOLOv8s-Seg 框架的改进模型,该模型针对沙壳蛋图像中的小目标检测(点状沙壳区域)进行了优化。在 Neck 部分设计新结构,结合多尺度特征融合与注意力机制,提升小目标检测鲁棒性。该设计能精确捕捉并融合不同尺度特征,并通过聚焦关键特征进一步提升识别精度。具体而言,本文模型加入了尺度序列特征融合(Spatial and Scale Fusion Feature, SSFF)模块和三重特征编码(Triple Feature Encoding, TFE)模块,以深度整合从路径聚合网络(PANet)^[19]主干中提取的多尺度特征图。随后,通道与位置注意力机制(Channel and Position Attention Mechanism, CPAM)被整合进来,该模块融合了 SSFF 和 TFE 模块中的特征信息,特征表达能力得到进一步增强。

在整体架构层面,上述模块集成到 YOLOv8 框架,形成高效精准的端到端实例分割模型,如图 3。此策略能够保持 YOLOv8 的高效准确性,同时增强了小目标的检测性能。

2.2.1 尺度序列特征融合(SSFF)模块 针对沙壳蛋图像中沙壳区域的多尺度特征提取,传统 FPN 方法特征融合方式单一。本文通过 SSFF 模

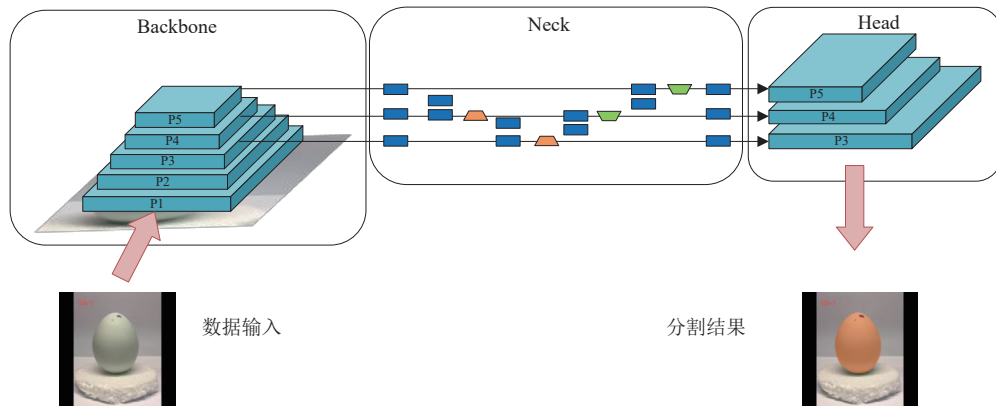


图 2 YOLOv8s-Seg 模型流程图
Fig. 2 YOLOv8s-Seg Model Working Roadmap

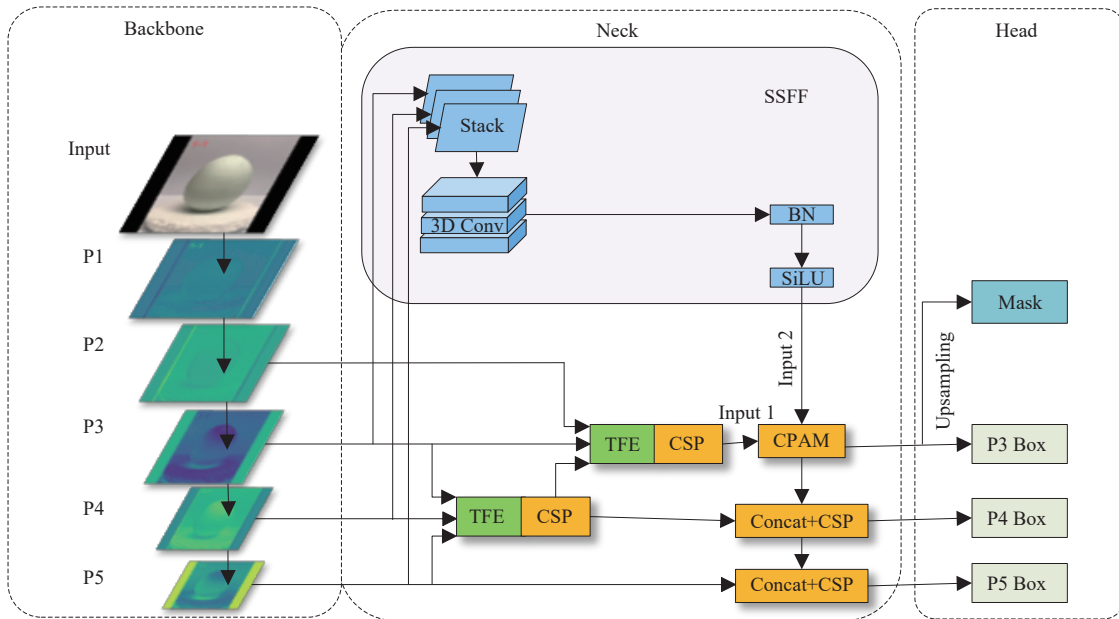


图 3 YOLOv8-CTAC 模型结构
Fig. 3 YOLOv8-CTAC model structure

块,结合深层高级语义信息与浅层精细节,强化相同长宽比特特征间的信息互补,细节如图 3 所示。同时,构建主干网络生成层次特征图 P1 至 P5,这些特征图分层次地覆盖了从精细到粗犷的多级图像细节,有效表征了沙壳蛋表面的多样性和复杂性。为了进一步提升特征表达的丰富性和针对性,P3、P4、P5 这三层较深层级的特征图首先会与一系列均方差逐渐增大的高斯核进行卷积操作^[20-22],计算式如(1)(2)。此步骤旨在通过高斯滤波的平滑与放大效应,增强特征图对不同尺度沙壳区域的敏感度,并抑制噪声,为后续任务奠定基础。

$$F_{\sigma(i,j)} = \sum_u \sum_v f(i-u, i-v) \times G_{\sigma}(u,v) \quad (1)$$

$$G_{\sigma}(x,y) = \frac{1}{2\pi\sigma^2} e^{- (x^2 + y^2) / 2\sigma^2} \quad (2)$$

公式中 x 和 y 代表像素的坐标, σ 表示标准差, G_{σ} 是高斯滤波器, f 是二维特征图, i 和 j 是经过高斯滤波后的输出特征图 F_{σ} 中的像素坐标,而 u 和 v 是高斯滤波器 G_{σ} 核窗口中的位置坐标。

将不同尺度特征图水平堆叠成特征立方体,采用三维卷积^[23]提取尺度序列特征。为解决高斯平滑导致的分辨率差异,特别是高分辨率特征图在捕捉小目标上的优势,本文使用最近邻插值法^[24]统一特征图分辨率至 P3 水平,避免信息损失。最终,通过三维卷积、批量归一化和 SiLU^[25] 激活函数完成特征提取。

2.2.2 三重特征编码(TFE)模块 TFE 模块旨在解决FPN在特征融合时忽略大尺寸特征层细节的问题。在沙壳蛋分割任务中,大尺寸特征图富含边缘信息和细节纹理,对界定沙化区域边界

至关重要。TFE 模块将特征图分为大、中、小三类,对大尺寸特征图进行精细卷积和通道调整,以与中等尺寸特征保持一致,便于后续融合与比较,细节信息如图4所示。

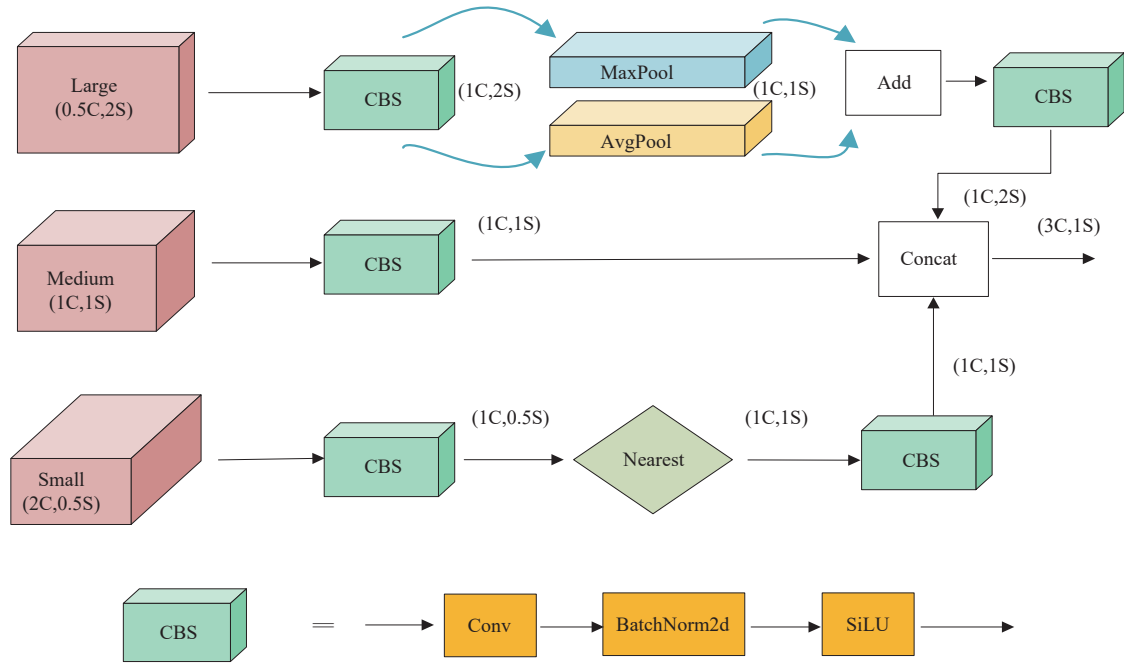


图 4 TFE 模块结构

Fig. 4 Structure of the TFE module

注:C代表通道数,S代表特征图尺寸大小。

Note: C represents the number of channels, S represents the size of the feature map.

TFE 模块采用混合池化策略,结合最大池化与平均池化,对大特征图下采样,保留显著特征并降低空间维度,提高效率,同时增强对沙壳蛋复杂纹理和位置变化的鲁棒性。对于小特征图,采用最近邻插值法进行上采样,相较于其他插值方法(如双线性插值^[26]、双三次插值^[27]),在保留局部特征连续性方面更具优势,尤其适合保持点状沙斑的尖锐边缘和细节。最后,将处理后的三个尺度特征图在通道维度拼接,形成融合特征图,显著提升沙壳蛋沙化区域的敏感度和识别精度。如式3所示。

$$F_{TFE} = Concat(F_l, F_m, F_s) \quad (3)$$

F_{TFE} 表示 TFE 模块输出的特征图, F_l, F_m, F_s 分别代表大、中、小尺寸的特征图。经过 Concat 操作后, F_{TFE} 具有与 F_m 相同的分辨率以及 3 倍的通道数。

2.2.3 通道与位置注意力机制(CPAM) 鉴于

不同通道特征信息的差异性,通过 CPAM 机制来整合 SSFF 模块和 TFE 模块的多尺度特征。CPAM 结合 CSP 后输出 (Input1) 与 SSFF 模块输出 (Input2), 通过结合通道与位置注意力, 显著增强模型从复杂图像中提取关键特征的能力, 特别是针对沙壳蛋细微特征与边界的识别, 如图 5 所示。这种策略通过融合互补信息, 使模型既能识别重要通道, 又能精确定位关键特征的空间位置。

通道注意力机制是一种无降维注意力机制, 其结构如图 6 所示, 旨在高效捕捉多通道数据间的复杂交互信息。该机制摒弃了传统注意力模型中的维度缩减步骤, 采用通道级全局平均池化直接作用于输入通道, 以保留完整信息。通过考虑每个通道及其 k 个最近邻, 利用一维卷积捕获局部跨信道交互, 其中, 设定 k 大小的卷积核以定义局部交互广度, 该模块可使模型动态聚焦关




图 5 通道和位置注意力机制

Fig. 5 Channel and position attention mechanism

注: ⊕ 代表矩阵相加操作。

Note: ⊕ represents matrix addition operation.




图 6 通道注意力机制

Fig. 6 Channel attention module

注: ⊗ 代表矩阵点乘操作。

Note: ⊗ represents matrix dot multiplication operation.

键通道间关系,因为通道维度 C 常遵循 2 的幂次方增长,手动调整 k 既耗时又复杂。因此需要一种更加系统化、自动化的方法来确定 k 值,以适应不同应用场景的需求,计算式如下:

$$C = \psi(k) = 2^{(\gamma \times k - b)} \quad (4)$$

$$k = \Psi(C) = \left\lfloor \frac{\log_2(C) + b}{\gamma} \right\rfloor_{\text{odd}} \quad (5)$$

(4)式中的 γ 和 b 是控制卷积核大小 k 与通道维数 C 之比的缩放系数,其中 $\lfloor \cdot \rfloor_{\text{odd}}$ 表示最近邻的奇数, γ 的值设为 2, b 设为 1,根据上述非线性映射关系,高价值通道的交换时间较长,而低价值通道的交换时间较短,因此通道注意力机制可以对多个通道特征进行更深层次的挖掘。

如图 7 所示,将通道注意力机制的输出与 SSFF 模块的输出 Input2 结合,作为位置注意力机制的输入。该机制将特征图在水平 (pw) 和垂直 (ph) 方向上分解并编码,使模型能独立关注不同轴向的特征变化,如沙壳蛋的横向裂纹和纵向纹理。通过池化处理保留并强化空间结构信息,对精确定位沙壳区域边界至关重要。最终,合并两个方向的特征编码,生成既含关键通道信息又具精确位置信息的输出特征图,计算式如下:

$$p_w(i) = \frac{1}{H} \sum_{0 \leq j < H} E(i,j) \quad (6)$$

$$p_h(j) = \frac{1}{W} \sum_{0 \leq i < W} E(i,j) \quad (7)$$




图 7 位置注意力机制

Fig. 7 Position attention module

其中 W 和 H 分别是输入特征图的宽度和高度。 $E(i, j)$ 是输入特征图位置 (i, j) 处的值。生成位置注意力坐标时,对水平轴和垂直轴应用级联和卷积操作:

$$P(a_w, a_h) = \text{Conv} [\text{Concat} (p_w, p_h)] \quad (8)$$

其中 $P(a_w, a_h)$ 表示位置注意力坐标的输出, Conv 表示 1×1 卷积, Concat 表示级联操作。

进行拆分注意力特征计算,以生成与位置相关的特征图对,如下所示:

$$s_w = \text{Split} (a_w) \quad (9)$$

$$s_h = \text{Split} (a_h) \quad (10)$$

其中 s_w 和 s_h 分别是拆分输出的宽度和高度。CPAM 的最终输出定义为:

$$F_{\text{CPAM}} = E \times s_w \times s_h \quad (11)$$

其中 E 表示通道注意力和位置注意力的权重矩阵。

2.3 变焦损失(VFL)函数

点状沙壳区域在检测图像中占比较小,导致沙壳类别不平衡,且其边缘分类具有挑战性。原始损失函数可能因权重分配不当而难以准确检测和分割点状沙壳区域。本文采用变焦损失函数(Varifocal Loss, VFL)来解决这一问题。变焦损失通过引入动态聚焦因子,根据沙壳区域样本

的复杂性及预测置信度进行自适应调整,从而实现沙壳类别更精确、更平衡的关注。变焦损失的概念源自焦损失(Focal Loss)^[28,29]。Focal Loss 的数学表达式如式(12)所示。

$$FL(p_t) = -(1 - p_t)^\gamma \log(p_t), \quad p_t = \begin{cases} p, & y = 1 \\ 1 - p, & y = 0 \end{cases} \quad (12)$$

$$VFL(p_t) = -\alpha(1 - p_t)^\gamma \log(p_{t_hat}) - \alpha(1 - p_{t_hat})^\beta \log(p_{t_hat}) \quad (13)$$

式(13)是变焦损失函数的数学表达式,涉及 p_t (正类预测概率)和 p_{t_hat} (正确预测为正类的概率),以及平衡因子 α (调节正负样本权重)。该损失函数通过动态调整焦点因子,对预测概率接近 1 的样本降低权重,而对接近 0 的样本增加权重,以应对类别不平衡问题。 γ 和 β 为可调参数,用于调整易分类样本的权重,优化聚焦精度和平衡性,从而提升模型检测和分割沙壳区域的能力。

3 结果与分析

本实验所用的硬件配置以及软件环境配置如表 2 所示。训练的批量大小设置为 16,迭代次数设置为 200,优化器为自适应矩阵估计,初始学习率为 0.01,动量因子为 0.937。

表 2 硬件配置和软件环境

Table 2 Hardware configuration and software environment

硬件 Hardware	配置 Configuration	软件环境 Software environment	版本 Version
CPU	Intel(R) Core(TM) i9-12900K	Pytorch	1.13.1
内存	64 GB	Python	3.8
GPU	NVIDIA GeForce RTX 3090	CUDA	11.6
OS	Windows 11	Pycharm	2023.1.2

为了衡量改进后的模型以及其他模型的性能,本文采用了 box 与 mask 级别的精确率 (precision, P)、召回率 (recall, R)、平均精度均值 (mean average precision, mAP)、参数量 (Params) 和模型大小 (Model size) 作为核心评估指标。

3.1 训练结果

采用构建好的数据集,分别对原始模型 YOLOv8s-Seg 和本文模型 YOLOv8-CTAC 进行训练,两个模型经过 200 次迭代后,训练集的边界框损失 (Box_Loss),掩膜损失 (Seg_Loss),分

类损失 (Cls_loss) 平均精度均值 (mAP) 曲线对比情况如图 8 所示,蓝色曲线为原始模型,红色曲线为本文模型。可以看出,随着框损失和分割损失曲线逐渐下降,表示模型对目标位置的预测逐渐准确,随着分类损失逐渐下降表示模型对目标分类更加准确。迭代次数小于 75 轮次时,两个模型训练损失曲线均表现为快速下降,平均精度均值曲线表现为快速上升。当迭代次数达到 150 轮次时,损失值曲线和平均精度均值曲线趋于平缓,模型训练过程趋于稳定。可以看出,改进后的模型与原始模型相比,拥有更低的损失值,更高的平均精度均值。

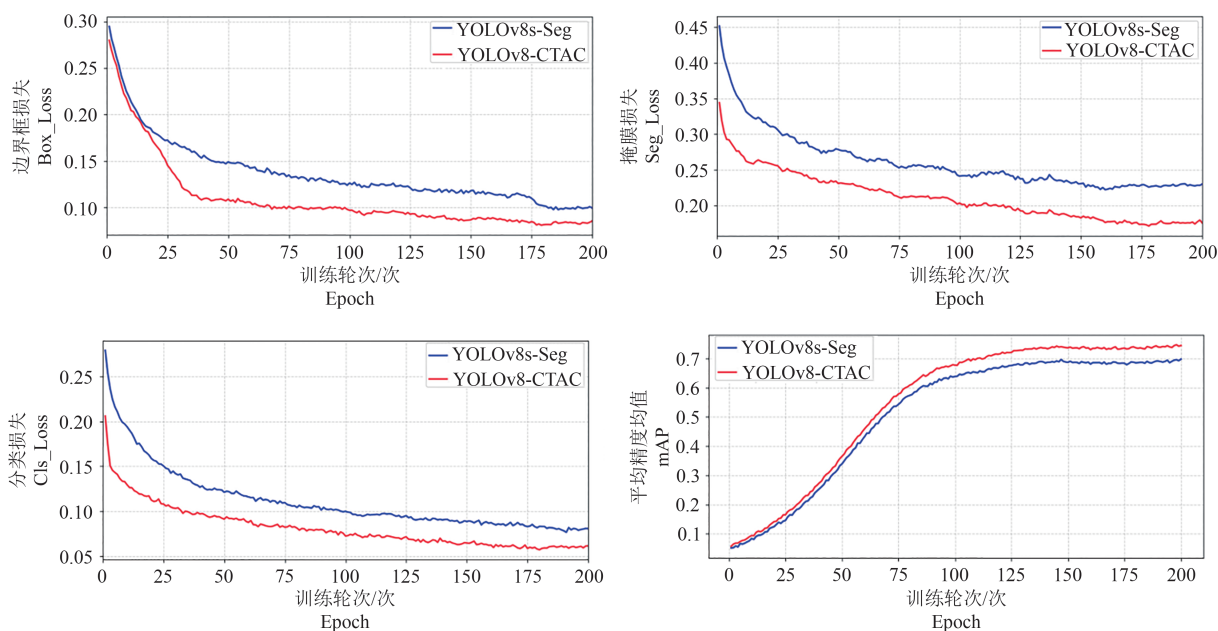


图 8 曲线对比图

Fig. 8 Comparison of curves

3.2 消融实验

为了深入理解各个组件对 YOLOv8-CTAC 模型性能的具体贡献,本文设计了一系列消融实验。本文中的消融实验通过系统地增加模型中的各个关键组件,来评估它们对模型性能的影响。实验结果如表 3 所示。

原始模型 YOLOv8s-Seg 在 box 和 mask 水平上的性能指标分别为准确率 63.3%/59.6%、召回率 60.5%/57.6% 和平均精度均值 65.8%/62.4%,为后续实验提供了参考。加入 VFL 后,

召回率和平均精度均值有所提升,表明其能有效缓解类别不平衡问题,提升复杂点状沙壳区域的检测能力。在此基础上加入 TFE 模块,box 和 mask 水平的准确率、召回率和平均精度均值均有所提升,表明 TFE 模块对多尺度特征融合的有效性。进一步加入 SSFF 模块,虽召回率基本不变,但准确率和平均精度均值显著提高,表明 SSFF 模块有效捕捉了沙壳区域的复杂纹理和多尺度特征。最终,结合 CPAM 机制,模型性能达到最佳,表明 CPAM 有助于模型整合和特征信息的利用。

表 3 消融实验

Table 3 Ablation experiment

模型 Model				准确率/% Precision		召回率/% Recall		平均精度均值/% mAP	
VFL	TFE	SSFF	CPAM	Box 水平	Mask 水平	Box 水平	Mask 水平	Box 水平	Mask 水平
×	×	×	×	63.3	59.6	59.5	56.6	65.8	62.4
√	×	×	×	63.5	60.5	61.6	57.9	66.3	65.2
√	√	×	×	65.7	62.8	62.3	58.2	67.6	66.3
√	×	√	×	64.9	61.2	61.7	58.0	66.5	65.9
√	√	√	×	68.9	65.0	62.3	58.5	68.9	67.4
×	√	√	√	67.1	65.6	62.4	59.5	69.2	68.0
√	√	√	√	69.0	67.9	67.8	65.5	73.2	70.6

注:“×”表示不使用相应的策略,“√”表示使用相应的策略。

Note: “×” indicates not using the corresponding strategy, and “√” indicates using the corresponding strategy.

消融实验显示,各组件均对模型性能提升有积极影响。TFE 和 SSFF 在多尺度特征融合与编

码上发挥关键作用,显著提高了沙壳蛋沙壳区域的检测与分割精度。CPAM 通过整合通道与位

置注意力,优化了模型对关键特征的识别。VFL 作为损失函数,有效缓解了类别不均衡问题,提升了目标检测能力。

3.3 与原始模型分割效果对比分析

3.3.1 不同沙壳类别分割性能对比 表4展示了本文模型相较于原始YOLOv8s-Seg模型在鸡蛋沙壳区域分割上的显著进步。具体而言,在处理光滑区域(Edge)时,本文模型在准确率、召回

率和平均精准度均值上虽略有下降但仍保持较高水平,对于点状沙壳区域(Point),本文模型在Box和Mask级别的准确率分别从59.6%和57.8%提升至64.3%和60.7%,召回率也分别从55.6%和52.1%提升至59.4%和57.3%,平均精准度均值也得到显著提升,展现出对微小沙壳点的更强捕捉能力。同样可以看出,本文模型相对原始模型在面状沙壳区域(Area)也表现出了优异的性能。

表4 不同沙壳类别分割性能对比

Table 4 Comparison of segmentation performance of different sand shell categories

模型 Model	准确率/% Precision		召回率/% Recall		平均精准度均值/% mAP	
	Box(v8) (our)	Mask(v8) (our)	Box(v8) (our)	Mask(v8) (our)	Box(v8) (our)	Mask(v8) (our)
光滑Edge	85.2 84.6	82.4 82.2	78.5 77.2	75.4 75.0	83.3 82.4	81.2 80.3
点状Point	59.6 64.3	57.8 60.7	55.6 59.4	52.1 57.3	57.6 63.5	56.4 62.8
面状Area	73.8 74.2	72.4 73.5	69.7 71.5	65.9 69.5	70.2 73.8	71.2 72.6

注:表中v8代表原始模型YOLOv8s-Seg模型,our代表本文所用模型。

Note: In the table, v8 represents the original YOLOv8s-Seg model, while our represents the model used in this paper.

3.3.2 整体分割效果性能对比 在图9对比了原模型YOLOv8s-Seg与本文模型在蛋壳沙壳区

域分割的效果。蛋壳沙壳区域因其非均匀质地和颜色变化,对图像分割构成挑战。原模型在处

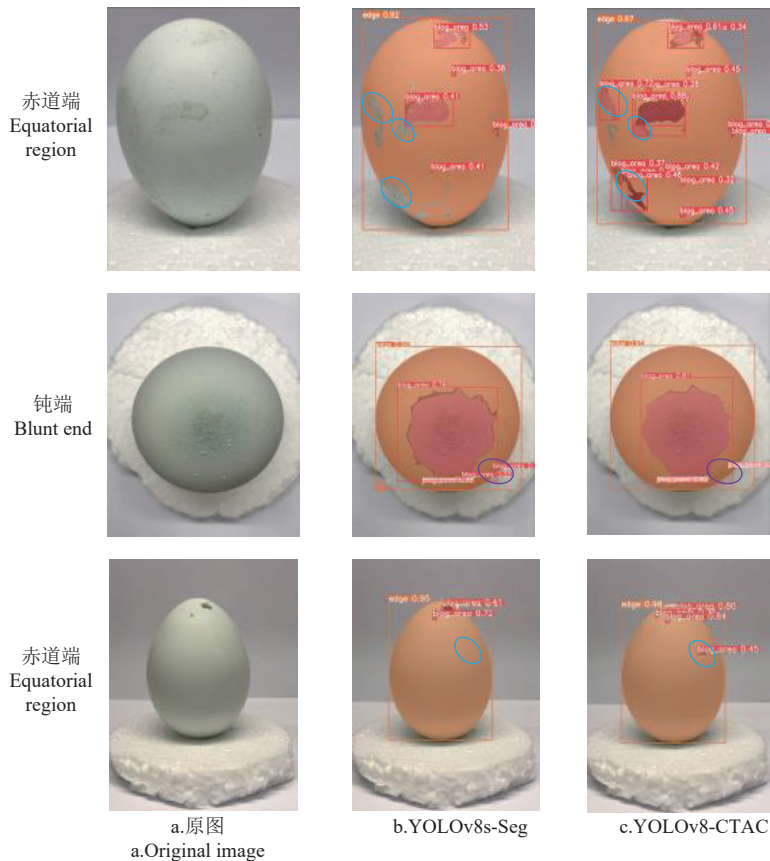


图9 原始模型与改进模型分割效果对比

Fig. 9 Comparison of segmentation effects between the original model and the improved model

理沙壳与光滑区域边界时存在漏检(图9b蓝色椭圆)和误检(图9b紫色椭圆)问题,可能因未充分捕捉细微差异或全局上下文信息整合不足。相比之下,本文模型展现出更高的准确度和鲁棒性(图9c),通过高效特征融合机制,更精确识别并区分沙壳与光滑区域,即使在颜色相近或纹理复杂情况下也保持较高分割精度,表明模型设计和

训练过程中重视全局上下文信息的整合与利用。

3.4 不同分割模型性能对比

为了进一步验证模型性能,在相同数据集下,本文所用模型YOLOv8-CTAC与Mask R-CNN、SOLOv2、YOLOv8n-Seg和YOLOv8s-Seg从平均精准度均值、召回率、参数量、模型大小进行对比,实验结果如表5所示。

表5 不同分割模型性能对比
Table 5 Performance comparison of different segmentation models

模型 Models	平均精准度均值/% mAP	召回率/% Recall	参数量/M Params	模型大小/MB Model size
Mask R-CNN	68.3	65.1	46.3	351.3
SOLOv2	61.4	59.4	41.5	338.1
YOLOv8n-Seg	61.2	59.8	3.2	6.5
YOLOv8s-Seg	64.8	62.3	11.2	22.8
YOLOv8-CTAC	71.5	65.7	12.3	23.4

本文模型在鸡蛋沙壳区域分割任务中,平均精准度均值较Mask R-CNN、SOLOv2、YOLOv8n-Seg、YOLOv8s-Seg分别高出3.2%、10.1%、10.3%、6.7%,召回率分别高出0.5%、6.3%、5.9%、3.4%。与参数量较小的YOLOv8n-Seg相比,本文模型在平均精准度均值上高出10.3%,在召回率上高出5.9%。而Mask R-CNN虽精度较高但参数量和模型大,对计算资源要求高。综上,本文模型在保持高效的同时实现了更高分割精度。

4 结论

本文基于改进YOLOv8s-Seg模型,通过对模型的优化和改进,显著提升了沙壳区域的分割性能。主要结论如下:

(1)本文采用的SSFF和TFE模块强化了局部特征提取与全局上下文信息整合,提升了多尺度特征融合能力。结合CPAM机制,增强了模型对沙壳区域的敏感度与识别精度。实验证明,与YOLOv8s-Seg相比,本文模型在准确率和召回率上均有显著提升,尤其在复杂点状沙壳区域表现优异。

(2)变焦损失的加入,使模型能够根据沙壳区域样本的复杂性、预测概率和置信度动态调整聚焦因子,改进后的模型加入变焦损失后,在box和mask两个评估层面上的准确率、召回率和平均精度均值相较于不加入均有大幅提升,具体为box层面提升1.9%、5.4%、4.0%,mask层面提

升2.3%、6.0%、2.6%,实验证明,变焦损失的加入可以有效缓解类别不平衡问题,提升了模型对复杂区域的检测能力。

(3)本文模型的平均精准度均值对比Mask RCNN、SOLOv2、YOLOv8n-Seg、YOLOv8s-Seg分别高出3.2%、10.1%、10.3%、6.7%,召回率则分别高出0.5%、6.3%、5.9%、3.4%。在保持较小参数量和模型大小的同时,本文模型实现了较高的分割精度。相较于其他大型模型如Mask R-CNN,本文模型具有更低的计算复杂度和资源消耗,更适用于鸡蛋沙壳区域分割的实际应用场景。

参考文献

- [1] Guyonnet V. Nutritional facts about eggs[M]. In: Handbook of Egg Science and Technology. Boca Raton: CRC Press, 2023:575-594.
- [2] 赵红兵,虞华.2023年我国禽蛋市场回顾及2024年价格走势展望[J].中国禽业导刊,2024,41(03):29-32.
- [3] Chen G Z, Li X, Zhang Y, et al. Combination of sensory evaluation with conventional physiochemical analyses to evaluate quality changes during long-term storage and estimate the shelf life of chicken eggs[J].British Poultry Science,2023,64(5):594-604.
- [4] Zhang D, Zhou F. Self-supervised image denoising for real-world images with context-aware transformer [J].IEEE Access,2023,11:14340-14349.

- [5] Saifullah S, Khan M, Ali N, et al. Nondestructive chicken egg fertility detection using CNN-transfer learning algorithms[EP]. arXiv preprint arXiv:2309.16257,2023.
- [6] 刘雪,沈长盈,吕学泽,等. 基于改进 MobileNetV3-Large 的鸡蛋新鲜度识别模型[J]. 农业工程学报, 2022,38 (17):196-204.
- [7] 胡建超. 基于 Android 的鸡蛋缺陷无损检测系统设计[D]. 武汉:华中农业大学,2022.
- [8] Tang W, Hu J, Wang Q. High-throughput online visual detection method of cracked preserved eggs based on deep learning[J]. Applied Sciences, 2022, 12(3):952.
- [9] 祝志慧,何昱廷,李沃霖,等. 基于改进 YOLOv7 模型的复杂环境下鸭蛋识别定位[J]. 农业工程学报, 2023,39 (11):274-285.
- [10] Luo Y, Huang Y, Wang Q, et al. An improved YOLOv5 model: Application to leaky eggs detection [J].LWT,2023, 187:115313.
- [11] 赵祚喜,魏洪飞,黄渊,等. 基于改进 YOLOv7 的破壳鸡蛋在线实时检测系统[J]. 农业工程学报,2023, 39(20):255-265.
- [12] Yang X, Li Y, Zhang S, et al. A computer vision-based automatic system for egg grading and defect detection[J]. Animals,2023,13(14):2354.
- [13] Lim W S, Tan C H, Lee K S, et al. Vision-based egg grading system using support vector machine[J]. International Journal on Robotics, Automation and Sciences,2024,6(1):13-19.
- [14] Jiang T, Liu J, Wang Y, et al. Improved YOLOv8 model for lightweight pigeon egg detection[J]. Animals,2024, 14(8):1226.
- [15] Jocher G, Chaurasia A, Qiu J. YOLO by ultralytics [CP]. Version 8.0.0,2023.
- [16] Jocher G. YOLO by Ultralytics[CP]. Version 5.7.0, 2022.
- [17] Qadri A A, Khan A, Shah S M, et al. Plant disease detection and segmentation using end-to-end YOLOv8: A comprehensive approach[C]. In: Proceedings of the 2023 IEEE 13th International Conference on Control System, Computing and Engineering (ICCSCE). Piscataway: IEEE,2023.
- [18] Yue X, Qi K, Na X, et al. Improved YOLOv8-Seg network for instance segmentation of healthy and diseased tomato plants in the growth stage[J]. Agriculture,2023,13(8):1643.
- [19] Liu S, Qi L, Qin H, Shi J, Jia J. Path aggregation network for instance segmentation[C]. In: Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway: IEEE, 2018: 8759-8768.
- [20] Lindeberg T. Scale-Space theory in computer vision [M]. Cham: Springer,1994.
- [21] Low D G. Distinctive image features from scale-invariant keypoints[J]. Journal of Computer Vision, 2004,60(2):91-110.
- [22] Tran D, Bourdev L, Fergus R, Torresani L, Paluri M. Learning spatiotemporal features with 3D convolutional networks[C]. In: Proceedings of IEEE International Conference on Computer Vision (ICCV). Piscataway: IEEE, 2015:4489-4497.
- [23] James J, Smith K, Brown A, et al. 3D convolutional neural networks for dendrite segmentation using fine-tuning and hyperparameter optimization[EP]. arXiv preprint arXiv:2205.01167,2022.
- [24] Rukundo O, Cao H. Nearest neighbor value interpolation [EP]. arXiv preprint arXiv:1211.1768,2012.
- [25] Elfving S, Uchibe E, Doya K. Sigmoid-weighted linear units for neural network function approximation in reinforcement learning[J]. Neural Networks, 2018, 107:3-11.
- [26] Kirkland E J. Bilinear interpolation [M]. In: Advanced computing in electron microscopy. Boston: Academic Press, 2010:261-263.
- [27] Li Y, Qi F, Wan Y. Improvements on bicubic image interpolation[C]. In: Proceedings of the 2019 IEEE 4th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC). Piscataway: IEEE,2019.
- [28] Gao M, Wang L, Zhang H, et al. A multiscale recognition method for the optimization of traffic signs using GMM and category quality focal loss[J]. Sensors,2020,20(17):4850.
- [29] Leng Z, Li S, Wang H, et al. Polyloss: A polynomial expansion perspective of classification loss functions [EP]. arXiv preprint arXiv:2204.12511,2022.