

基于改进 YOLO 11 的轻量化异常鸡蛋识别方法

杨立伟 付 帅 赵江涛 张 月 李 寒 张 漫
(中国农业大学智慧农业系统集成研究教育部重点实验室, 北京 100083)

摘要: 异常鸡蛋的出现往往与鸡只的健康状况密切相关,对鸡蛋的检测可以及时发现鸡只健康问题并提升鸡蛋的整体品质。为解决鸡舍中鸡蛋粘连及鸡蛋与铁丝网之间遮挡的问题,本研究提出一种 ATW - YOLO (YOLO 11n + ADown + Triplet Attention + BiFPN + WIoU) 轻量化目标检测模型,应用于正常/异常鸡蛋的检测。首先,将主干网络和颈部网络的部分常规卷积替换成 ADown 模块实现模型轻量化,提取局部显著特征;再向 C2PSA 模块中融入 Triplet Attention 注意力机制,提高了模型对跨纬度特征的提取能力,有效改善鸡蛋粘连和遮挡问题;再引入加权双向特征金字塔网络 BiFPN,强化了模型特征融合性能并提高了模型精度;最后引入 WIoU 损失函数,提升模型对普通质量样本的关注度。试验结果表明,ATW - YOLO 轻量化目标检测模型的精确度 (P)、召回率 (R)、平均精确度 ($mAP_{0.5}$) 分别达到 90.4%、89.5%、93.3%,较 YOLO 11n 模型分别提高 1.9、2.5、2.0 个百分点,模型参数数量和浮点计算量分别为 5.2×10^6 和 2.18×10^9 ,较 YOLO 11n 分别降低 4×10^5 和 1.1×10^9 ,检测速度达到 197.2 f/s,可满足鸡蛋的实时识别需求。综上,ATW - YOLO 模型在正常/异常鸡蛋识别任务中展现出优良的综合性能,为实现鸡舍自动化、智能化管理提供了技术支持。

关键词: 鸡蛋; 目标检测; YOLO 11; 深度学习; 轻量化网络

中图分类号: TP391 文献标识码: A 文章编号: 1000-1298(2026)21-0409-09 OSID: 

Lightweight Abnormal and Normal Eggs Detection Method Based on Improved YOLO 11

Yang Liwei Fu Shuai Zhao Jiangtao Zhang Yue Li Han Zhang Man
(Key Laboratory of Smart Agriculture System, Ministry of Education,
China Agricultural University, Beijing 100083, China)

Abstract: The occurrence of abnormal eggs is often closely related to the health status of poultry, and egg detection can promptly identify health issues in chickens while improving overall egg quality. To address the challenges of egg adhesion and occlusion between eggs and wire mesh in chicken coops, a lightweight object detection model named ATW - YOLO was proposed for normal/abnormal egg detection. Firstly, part of the standard convolutions in the backbone and neck networks were replaced with ADown modules to achieve model lightweighting and extract locally salient features. Then, the triplet attention mechanism was incorporated into the C2PSA module to enhance the model's ability to extract cross-dimensional features, effectively mitigating egg adhesion and occlusion issues. Additionally, a weighted bidirectional feature pyramid network (BiFPN) was introduced to strengthen feature fusion performance and improve model accuracy. Finally, the WIoU loss function was adopted to increase the model's focus on medium-quality samples. Experimental results demonstrated that the ATW - YOLO lightweight object detection model achieved precision (P), recall (R), and mean average precision ($mAP_{0.5}$) of 90.4%, 89.5%, and 93.3%, respectively. Compared with the YOLO 11n model, these metrics showed improvements of 1.9, 2.5, and 2.0 percentage points, respectively. The model parameters and floating-point operations (FLOPs) were 5.2×10^6 and 2.18×10^9 , representing reductions of 4×10^5 and 1.1×10^9 compared with that of YOLO 11n. The detection speed reached 197.2 frames per second (FPS), meeting the requirements for real-time egg recognition. In conclusion, the ATW - YOLO model exhibited superior comprehensive performance in normal/abnormal egg detection tasks, providing technical support for automated and intelligent management in poultry farming.

Key words: egg; object detection; YOLO 11; deep learning; lightweight network

0 引言

鸡蛋作为重要的蛋白质来源,在全球范围内被广泛消费,其品质直接关系到消费者的健康和禽蛋产业的效益^[1]。在鸡只产蛋过程中,由于疾病、营养不均衡、饲养环境不良等因素的影响,会导致鸡蛋出现沙壳、斑点、破壳等异常情况^[2-3]。这些异常鸡蛋不仅影响消费者的购买体验,还会对禽蛋产业的声誉造成负面影响。此外,异常鸡蛋的出现往往与鸡只的健康状况密切相关,可作为鸡只疾病的重要衡量指标之一。因此,对异常鸡蛋进行高效、准确识别,不仅能够帮助养殖户及时发现鸡只的健康问题,还能有效提升鸡蛋的整体品质。

传统鸡蛋检测主要采用人工目检,不仅效率低下、主观性强,还可能导致鸡只应激反应^[4]。随着机器视觉^[5]和深度学习技术的不断发展,这类具备非接触、低成本和自动化优势的方法被广泛应用于畜禽养殖领域,为鸡蛋检测提供了创新的技术解决方案。目前,基于深度学习的目标检测算法^[6]主要分为两类:以 Faster R-CNN 系列为代表的两阶段目标检测器和以 YOLO 系列^[7-10]、SSD 系列为代表的单阶段目标检测器。文献^[11-13]模型具有良好的检测性能,但较大的参数量和浮点计算量导致在计算资源受限的设备上难以实现实时检测。针对轻量化嵌入式设备的应用需求,具有参数量小、计算复杂度低、推理速度快的轻量化目标检测网络展现出突出优势^[14-15]。轻量化网络具有高实时性、少参数量和易部署等特点,方便部署于移动机器臂或其他嵌入式设备上对异常鸡蛋进行检测,为实际场景下的应用提供了可能。目前正常/异常鸡蛋的检测研究存在以下问题:①对异常鸡蛋的轻量化实时检测鲜有研究,针对轻量化嵌入式设备的应用需求,需要轻量化、高效的方法。②在笼养模式下,由于鸡蛋粘连及鸡蛋与铁丝网之间遮挡和异常鸡蛋表型特征多样,易造成鸡蛋的误检与漏检。

针对上述问题,本文以海兰褐壳蛋鸡所产鸡蛋为研究对象,提出基于 ATW-YOLO 的轻量化异常鸡蛋识别方法。首先引入轻量化 ADown 模块替换主干网络和颈部网络的部分常规卷积实现轻量化,再向 C2PSA 模块中融入 Triplet Attention 注意力机制,有效改善鸡蛋粘连和遮挡问题,更换新的特征融合网络,最后以 WIoU 作为损失函数,通过动态非单调聚焦机制提升模型对普通质量样本的关注度。

1 数据采集与处理

1.1 数据采集

以海兰褐壳蛋鸡所产的褐壳蛋为试验对象。海

兰褐壳蛋鸡是一种广泛应用于蛋品生产的商业化蛋鸡品种,具有产蛋率高、蛋壳质地坚硬、表面光滑且无明显杂质等特点,其蛋壳颜色呈浅褐色。鉴于鸡蛋在外形特征上与鸭蛋、鹌鹑蛋等其他禽类蛋品具有较高的相似性,本研究的成果可进一步推广至其他蛋品的异常检测任务中,具备较高的普适性和应用潜力。

试验数据采集自内蒙古自治区巴彦淖尔高新养殖场,旨在构建一个涵盖多种异常类型鸡蛋的图像数据集,异常鸡蛋描述如表 1 所示。数据采集设备采用荣耀 90 型手机,其摄像头分辨率为 1 920 像素×1 080 像素,帧率为 60 f/s,摄像头与蛋槽水平距离 25~35 cm,垂直距离 10~20 cm,俯角 60°和 30°拍摄,可清晰捕捉鸡蛋的微观细节特征。为增强数据集的多样性和模型的泛化能力,采集过程覆盖了 08:00—09:00 时间段和 14:00—16:00 时间段,及光照不均、鸡蛋粘连和鸡蛋与笼网遮挡等不同场景下的鸡蛋视频,视频共记录了 3 656 枚鸡蛋的数据,其中包含 2 195 枚异常鸡蛋,异常类别细分为沙壳蛋、斑点蛋、脏污蛋和破壳蛋,如图 1 所示,其中沙壳蛋 329 枚、斑点蛋 658 枚、脏污蛋 660 枚、破壳蛋 548 枚。所有异常鸡蛋均经由专业养殖人员核实,以确保数据标注的准确性。




图 1 鸡蛋类别

Fig. 1 Egg category

1.2 数据处理与增强

在数据预处理阶段,首先利用 OpenCV 库对视频数据进行抽帧处理,按照每 30 帧抽取 1 幅图像,

共获得 2 824 幅初始图像。由于采集过程中摄像头移动速度不均匀,部分图像存在运动模糊或内容重复等问题。因此,对图像进行筛选,剔除相似度过高和运动模糊的图像,最终保留 852 幅高质量的异常鸡蛋图像。使用 Make Sense 标注工具对图像进行标注,并将数据集按照比例 6:2:2 划分为训练集、验证集和测试集。为有效提升模型性能和泛化能力,在训练过程中采用多种数据增强策略对数据进行增强,包括颜色变换、随机缩放、平移、翻转等,增强效果如图 2 所示。




图 2 数据增强

Fig. 2 Data augmentation

2 网络模型

2.1 YOLO 11 模型结构改进

YOLO 系列算法作为一阶段目标检测算法的代表,以其高效的速度和较高的检测精度在目标检测领域占据了重要地位。YOLO 11 作为 YOLO 系列的较新版本,继承了前几代算法的优点,并在网络结构、特征融合和检测策略等方面进行了多项创新,进一步提升了检测性能。

YOLO 11 的网络结构主要由 3 部分组成:主干网络、Neck 和 Head。主干网络新增了 C2PSA 模块,并使用 C3k2 替换了 YOLO v8 的 C2f 模块。C3k2 模块结合了 YOLO v8 的 C2f 模块的速度优势和 C3k 的灵活性,允许在运行时选择是否使用 C3k 层来处理特征,既可以作为灵活的特征提取模块,也可以作为快速的特征融合模块。C2PSA 模块是一种融入了注意力机制的特征处理模块,增强对关键区域的关注度;Neck 部分采用 PAN - FPN 的设计思想,融合深浅层特征,用 C3k2 模块替换 YOLO v8 的 C2f 模块提高了特征聚合过程的速度和性能;Head 部分引入了 DWConv 模块,大幅减少参数量和计算量,为弥补深度卷积缺乏跨通道信息整合的问题,在深度卷积后配合 1×1 逐点卷积,对通道维度进行混合,整合不同通道的信息。

YOLO 11 有 5 个不同版本,本研究选取 YOLO 11n 作为网络基线模型,其为 YOLO 11 系列中最小模型,更易满足轻量化要求。尽管 YOLO 11 已具备

优秀的检测性能,但在鸡蛋粘连、鸡蛋与铁丝网之间遮挡及模型轻量化等场景下仍有提升空间,因此本研究在 YOLO 11n 基础上进行改进,为减小模型参数量和浮点计算量,并保持检测精度,首先将主干网络和颈部网络的部分常规卷积替换为轻量化 ADown 模块实现模型轻量化。为提高检测性能,向 C2PSA 模块融入 Triplet Attention 注意力机制,以提高对鸡蛋遮挡、粘连场景下的检测能力。使用 BiFPN 特征融合网络代替 PANet 网络,自适应抑制噪声特征,增强有效特征。最后,采用 WIoU 损失函数聚焦于普通质量的锚框,提高模型泛化能力。改进模型 ATW - YOLO 的结构如图 3 所示。

2.2 ATW - YOLO 模型构建

2.2.1 轻量化 ADown 模块

YOLO 11 模型在特征提取与多尺度特征融合中使用常规卷积,常规卷积在处理特征时会会对每个位置进行全局计算,导致模型参数量和浮点计算量负担较重,并且其缺乏高效的下采样机制。为保持精度的同时进一步对模型轻量化,本研究引入轻量化 ADown^[16] 模块替换主干网络和颈部网络的部分常规卷积,ADown 模块的结构如图 4 所示。

ADown 是 YOLO v9 中的轻量化下采样卷积模块,下采样是减少特征图空间维度的常用技术,它有助于模型在更高层次上捕捉图像的特征,能更好地检测不同尺度的鸡蛋特征,同时减少计算量。ADown 模块的设计旨在以一种高效且对性能影响较小的方式进行下采样,其输入特征维数为 $C \times H \times W$ (C 、 H 、 W 分别为特征图的通道数、高度、宽度)的特征张量,经过平均池化提取全局特征并通过通道分割将其划分为 2 个不同通道方向的张量,一部分经过 3×3 卷积对输入张量进行下采样和空间特征提取,另一部分经过最大池化和 1×1 卷积显著降低参数量和浮点计算量,同时提取局部显著特征,增强细节信息,最后将两部分在通道维度拼接,增强模型的表达能力和特征提取的多样性,参数量降低至常规卷积的 $1/3$ 以下,浮点计算量也有所下降,提高了部署便利性。

2.2.2 Triplet Attention 注意力机制

由于模型轻量化导致的特征表达能力下降,以及鸡蛋检测存在鸡蛋粘连、遮挡和背景复杂多变等问题,对模型检测能力有较高的要求。在不增加模型参数量和浮点计算量的前提下使模型更加关注鸡蛋特征,本研究引入 Triplet Attention^[17] 注意力机制嵌入到 C2PSA 模块中,形成 C2PSA - TA 模块。由于能够在通道或空间位置之间建立相互依存关系,注意力机制近年来得到了广泛的研究,并应用于各




图 3 ATW-YOLO 模型结构图
Fig. 3 ATW-YOLO model structure




图 4 ADown 模块结构图
Fig. 4 ADown block structure

种计算机视觉任务中。Triplet Attention 是一种轻量化且有效的注意力机制,使用三支结构捕捉交叉维度交互信息来计算注意权重,在鸡蛋粘连和遮挡场景中,这种跨维度的特征交互有助于区分重叠区域的特征,从而更好地分离粘连目标。图 5 为 Triplet Attention 模块结构图,给定输入张量 $X \in \mathbb{R}^{C \times H \times W}$,分别将其传递到 3 个分支中,每个分支用于捕捉通道维度 C 、空间维度 H 和 W 三者之二的交互特征。3 个分支都通过旋转输入张量得到 X_i ,经过 Z-Pool 和卷积实现了跨维度的交互注意力,再通过 Sigmoid 激活函数生成注意力权重加权到 X_i 上,最后旋转并加权平均融合。其中 Z-Pool 是对特征图在通道维度上压缩到 2,生成一个低维但信息丰富的特征表示。通过旋转操作和残差变换, Triplet Attention 能够捕获通道与空间维度之间的交

互关系,可以更好地建模遮挡与粘连区域的特征,同时轻量级的卷积操作和 Z-Pool 操作使得计算开销减小,在提高模型性能的同时加快了推理速度。




图 5 Triplet Attention 模块结构图
Fig. 5 Triplet Attention block structure

2.2.3 加权双向特征金字塔网络 BiFPN

YOLO 11 的特征融合网络是基于 PANet 的,其在 FPN 基础上增加了自下而上的路径,使浅层特征也能影响深层,有效解决了 FPN 浅层特征易丢失的问题。然而,PANet 的固定权重融合难以区分粘连和遮挡目标的特征边界,且无法动态调整不同尺度特征的贡献,其单次交互可能导致细节信息在深层网络中逐渐衰减,尤其是被遮挡鸡蛋的局部特征,同时对密集排列的中小鸡蛋目标缺乏跨尺度特征的动态加权整合能力,难以适应异常鸡蛋表型的特征多样性变化。因此,引入加权双向特征金字塔网络 (BiFPN)^[18],模型结构如图 6b 所示,通过重复双向

交互显著增强深浅特征的互补性,其加权融合策略针对中小目标的多尺度特征进行优先级分配,使模型对形态各异的异常鸡蛋表型具备更强的特征表达能力。BiFPN 通过可学习权重自适应抑制遮挡区域的噪声特征、强化未遮挡部分的有效特征,减少了粘连、遮挡鸡蛋的漏检和误检。此外,BiFPN 删除了 2 个节点,未增加额外融合节点,进一步降低了计算成本。




图 6 模型结构图
Fig. 6 Model structure diagrams

2.2.4 边界框损失函数优化

在目标检测任务中,边界框回归损失函数对模型的定位性能有着至关重要的影响。YOLO 11 默认使用的是 CIoU^[19] 损失函数,它通过引入中心点距离和宽高比的惩罚项,提升了边界框回归的精度,但 CIoU 在处理低质量样本时存在一定的局限性,尤其是在训练数据中存在标注不准确或边界框不完整的情况下,CIoU 可能会产生过大的梯度,导致模型过拟合或泛化性能下降。为了解决这一问题,本研究引入了 Wise-IoU (WIoU)^[20] 损失函数。WIoU 通过动态非单调聚焦机制,根据锚框质量自适应调整梯度增益,减少低质量样本对模型训练的负面影响,同时提升模型对普通质量样本的关注度,有助于提高模型的泛化能力和定位精度,WIoU 计算公式为

$$L_{WIoU} = rR_{WIoU}L_{IoU} \tag{1}$$

其中
$$L_{IoU} = 1 - IoU \tag{2}$$

$$R_{WIoU} = e^{\frac{(x-x_{gt})^2 + (y-y_{gt})^2}{(W_g^2 + H_g^2) *}} \tag{3}$$

$$r = \frac{\beta}{\delta\alpha^{\beta-\delta}} \tag{4}$$

式中 r ——动态非单调聚焦系数
 IoU ——交并比
 R_{WIoU} ——预测框与真实框中心点之间的距离度
 $x、y、x_{gt}、y_{gt}$ ——预测框和真实框的中心点坐标
 $W_g、H_g$ ——最小封闭框的宽和高
 $*$ ——将 $W_g、H_g$ 从计算图中分离的运算符

β ——离群度,用于描述锚框的质量
 $\delta、\alpha$ ——超参数

β 较小意味着预测框质量高,因此为其分配较小的梯度增益,以便使边界框损失聚焦于普通质量的锚框上, β 较大意味着低质量标注,同样分配较小的梯度增益。

3 试验环境与评价指标

3.1 试验环境

本研究的试验在统一的硬件和软件环境下进行,以确保试验结果的可靠性和可重复性。硬件环境包括:CPU 为 Intel(R) Core(TM) i7-14700HX (20 核心 28 线程)、内存为 16 GB DDR5、GPU 为 NVIDIA GeForce RTX 4060、显存为 8GB GDDR6。软件环境包括:Windows 11 操作系统、Python 3.11、PyTorch 2.5.1 深度学习框架、CUDA 12.2 和 cuDNN 9.0.1 用于 GPU 加速计算。训练超参数设置如表 2 所示。

表 2 训练超参数
Tab. 2 Training hyperparameters

超参数	数值
学习率	0.01
批量大小	16
训练轮数	300
优化器	SGD
动量	0.937
权重衰减	0.000 5

3.2 评价指标

在鸡蛋检测任务中,本研究采用了一系列广泛认可的评价指标,以全面评估模型的性能。具体指标包括:精确度 (Precision, P)、召回率 (Recall, R)、平均精确度 (Mean average precision, $mAP_{0.5}$)、浮点计算量 (Floating point operations, FLOPs)、参数量 (Parameters) 和帧率 (Frames per second, FPS)。

4 结果与分析

4.1 不同网络模型对比试验

为验证改进的目标检测模型 ATW-YOLO 在鸡蛋识别任务的优越性,将其与其他主流目标检测模型 Faster R-CNN、YOLO v5、YOLO v8、YOLO v10 和未改进的 YOLO 11 在模型性能方面进行对比试验;在模型轻量化方面,与轻量化主干网络 EfficientNetV2^[21]、MobileNetV4^[22]、MobileViTv2^[23] 进行对比试验,所有试验均在同一参数和数据集上进行,结果如表 3 所示。

表 3 不同网络模型对比结果

Tab. 3 Comparative results of different network models

模型	$P/\%$	$R/\%$	$mAP_{0.5}/\%$	浮点计算量	参数量	帧率/($f \cdot s^{-1}$)
Faster R – CNN	61. 7	87. 2	82. 6	$2. 4 \times 10^{11}$	$2. 832 \times 10^7$	10. 5
YOLO v5	89. 3	83. 4	91. 5	$5. 8 \times 10^9$	$2. 18 \times 10^6$	162. 3
YOLO v8	85. 8	85. 3	90. 3	$6. 8 \times 10^9$	$2. 69 \times 10^6$	210. 8
YOLO v10	81. 8	83. 8	87. 9	$8. 2 \times 10^9$	$2. 70 \times 10^6$	197. 0
YOLO 11	88. 5	87. 0	91. 3	$6. 3 \times 10^9$	$2. 58 \times 10^6$	185. 3
YOLO 11 – EfficientNetV2	87. 2	84. 9	90. 7	$5. 2 \times 10^9$	$2. 19 \times 10^6$	212. 4
YOLO 11 – MobileNetV4	78. 0	84. 6	86. 0	$4. 3 \times 10^9$	$1. 80 \times 10^6$	230. 4
YOLO 11 – MobileViTv2	89. 9	88. 6	92. 8	$9. 8 \times 10^9$	$3. 01 \times 10^6$	92. 3
ATW – YOLO	90. 4	89. 5	93. 3	$5. 2 \times 10^9$	$2. 18 \times 10^6$	197. 2

由表 3 可知,在鸡蛋目标检测任务上,ATW – YOLO 具有最高的 P 、 R 和 $mAP_{0.5}$ 。与 YOLO 11 相比,ATW – YOLO 的 P 、 R 和 $mAP_{0.5}$ 分别提高 1. 9、2. 5、2. 0 个百分点,由于轻量化 ADown 模块替换常规卷积,模型参数量和浮点计算量显著降低,在该硬件环境下,帧处理速率为 197. 2 f/s,充分满足了实时检测的需求,表明 ATW – YOLO 对于 YOLO 11 的改进是有效的。相比之下,双阶段 Faster R – CNN 模型对鸡蛋目标检测的性能最差,在较大参数量下,低于其他 YOLO 系列模型。与 YOLO v5、YOLO v8 和 YOLO v10 相比,ATW – YOLO 的 $mAP_{0.5}$ 分别提高 1. 8、3. 0、5. 4 个百分点。总的来说,在鸡蛋目标检测任务上,ATW – YOLO 的改进是有效的。

在模型轻量化方面,虽然 MobileViTv2 轻量化主干网络具有较高的 $mAP_{0.5}$,但其浮点计算量和参数量相较于 ATW – YOLO 增加了 $4. 6 \times 10^9$ 和 $8. 3 \times 10^5$,帧率下降了 104. 9 f/s,相比之下,ATW – YOLO 在保持最高 P 、 R 、 $mAP_{0.5}$ 的同时,显著降低了模型复杂度,更适合部署在计算资源受限的边缘设备上,可满足实时目标检测的需求。MobileNetV4 轻量化主干网络的参数量和浮点计算量最低,但过度追求模型压缩导致特征提取能力显著下降, P 、 R 、 $mAP_{0.5}$ 分别降低 12. 4、4. 9、7. 3 个百分点。此外,EfficientNetV2 轻量化主干网络的各项性能指标均弱于 ATW – YOLO,进一步凸显了 ATW – YOLO 在轻量化设计上的优势。

4. 2 边界框损失函数优化结果分析

为验证 WIoU 损失函数的有效性,本研究将其与 CIoU、DIoU^[24]、EIoU^[25]、SIoU^[26] 和 MPDIoU^[27] 损失函数进行对比试验,结果如表 4 所示。

试验结果表明,WIoU 损失函数的 P 、 R 、 $mAP_{0.5}$ 相较于 CIoU、DIoU、SIoU 和 MPDIoU 损失函数都有所提升,虽然 R 比 EIIoU 降低 0. 2 个百分点,但 P 和 $mAP_{0.5}$ 分别提升 2. 0、1. 1 个百分点,整体性能更佳。

综合看来,WIoU 在模型检测任务中展现了更高的鲁棒性和泛化能力。

表 4 损失函数对比结果

Tab. 4 Comparison results of loss function %

损失函数	P	R	$mAP_{0.5}$
CIoU	89. 7	87. 9	92. 8
DIoU	89. 5	87. 6	92. 4
EIoU	88. 4	89. 7	92. 2
SIoU	89. 7	87. 6	92. 1
MPDIoU	88. 4	87. 5	91. 8
WIoU	90. 4	89. 5	93. 3

4. 3 消融试验

为进一步验证轻量化下采样卷积模块 ADown、Triplet Attention 注意力机制、BiFPN 特征融合网络、WIoU 损失函数的有效性和对鸡蛋目标检测任务的适用性,本研究采用消融试验对每一模块进行性能测试。试验结果如表 5 所示。

由表 5 可知,在原始 YOLO 11n 模型上将常规卷积替换为轻量化 ADown 模块后,模型参数量和浮点计算量分别下降了 $4. 8 \times 10^5$ 和 $1. 2 \times 10^9$,但轻量化设计对特征提取能力产生了一定影响,导致模型性能指标出现轻微下降, P 、 R 和 $mAP_{0.5}$ 分别下降 0. 5、0. 3、0. 1 个百分点。尽管 ADown 模块有效降低了模型复杂度,但在特征表达能力上仍需进一步优化,以平衡模型效率与检测精度之间的关系。在引入 Triplet Attention 注意力机制后,充分捕获通道与空间维度之间的交互关系,一定程度上弥补了模型轻量化带来的影响, $mAP_{0.5}$ 提高了 0. 8 个百分点,增强了对鸡蛋粘连、遮挡场景的适应能力和整体检测性能,但其对复杂特征和噪声的敏感性,导致 P 、 R 分别下降 0. 4、0. 7 个百分点。因此使用 BiFPN 特征融合网络的可学习权重自适应抑制噪声的影响,增加鸡蛋的有效特征,提高对异常鸡蛋表型特征的表达能力,其内部包含上采样、下采样和特征融合,会使模型参数量和浮点计算量轻微上浮, P 、

表 5 消融试验结果

Tab.5 Results of ablation tests

模型	$P/\%$	$R/\%$	$mAP_{0.5}/\%$	浮点计算量	参数量	帧率/($f \cdot s^{-1}$)
YOLO 11n	88.5	87.0	91.3	6.3×10^9	2.58×10^6	185.3
YOLO 11n + ADown	88.0	86.7	91.2	5.1×10^9	2.10×10^6	201.8
YOLO 11n + ADown + Triplet Attention	87.6	86.0	92.0	5.1×10^9	2.05×10^6	201.1
YOLO 11n + ADown + Triplet Attention + BiFPN	89.7	87.9	92.8	5.2×10^9	2.18×10^6	198.5
YOLO 11n + ADown + Triplet Attention + BiFPN + WIoU (ATW - YOLO)	90.4	89.5	93.3	5.2×10^9	2.18×10^6	197.2

R 和 $mAP_{0.5}$ 分别提高 2.1、1.9、0.8 个百分点。最后引入 WIoU 损失函数提升模型对普通质量样本的关注度,通过动态梯度分配策略降低了噪声的影响,模型各项指标较原始 YOLO 11n 都得到了提高,在模型检测性能方面, P 、 R 和 $mAP_{0.5}$ 分别提高 1.9、2.5、2.0 个百分点;在模型轻量化方面,模型参数量和浮点计算量分别下降了 4×10^5 和 1.1×10^9 。综上,本研究改进后的模型在鸡蛋检测任务上实现检测性能与轻量化的双重提升,其对正常蛋、沙壳蛋、斑点蛋、脏污蛋、破壳蛋的 $mAP_{0.5}$ 分别为 93.5%、94.4%、

91.9%、92.0%、94.7%。

4.4 鸡蛋检测结果分析

为验证改进模型的泛化性能,将 YOLO 11n、YOLO 11n + ADown、YOLO 11n + ADown + Triplet Attention、YOLO 11n + ADown + Triplet Attention + BiFPN 和 ATW - YOLO 在鸡蛋粘连、遮挡场景下进行对比,检测结果如图 7 所示。其中红色框和绿色框分别表示鸡蛋粘连场景下的漏检和误检,蓝色框和黄色框分别表示鸡蛋遮挡场景下的漏检和误检。



图 7 检测结果可视化

Fig. 7 Detection visualization

由图 7 可知,在原始 YOLO 11n 模型中出现检测精度低、漏检和误检的现象,在引入 ADown 模块后遮挡、粘连鸡蛋的漏检数量减少,表明 ADown 模块能够有效捕捉鸡蛋的局部显著特征,但由于模型轻量化的影响,整体检测精度下降。为解决鸡蛋粘连和遮挡的问题,引入了 Triplet Attention 注意力机制,该机制显著降低了模型在鸡蛋遮挡、粘连场景下的漏检,表明 Triplet Attention 模块能够解决由于模型轻量化带来的精度损失问题,但其因特征交互过

强而引入噪声。为此,更换 BiFPN 特征融合网络,模型的检测精度进一步提升,同时减少了异常蛋的漏检和误检。最后引入了 WIoU 损失函数,通过动态梯度分配和低质量样本抑制,有效提升了模型鲁棒性,模型精度达到最优。结果表明,ATW - YOLO 在遮挡和粘连鸡蛋场景中取得了最佳检测效果。综上,改进后的模型能够更好地适应遮挡和粘连情况下的鸡蛋检测任务,提高了识别精度并有效减少了漏检现象。

5 结 论

(1)提出了 ATW – YOLO 轻量化目标检测模型,该模型基于 YOLO 11n 网络结构,使用 ADown 模块替换部分常规卷积减小模型参数量和浮点计算量,在 C2PSA 模块融入 Triplet Attention 注意力机制以解决模型轻量化导致识别精度降低和鸡蛋粘连、遮挡的问题,更换 BiFPN 特征融合网络抑制噪声特征的影响,采用 WIoU 损失函数,提升模型对普通质量样本的关注度。

(2)ATW – YOLO 模型参数量为 2.18×10^6 ,浮点计算量为 5.2×10^9 ,相比原始 YOLO 11n 模型分别减少 4×10^5 和 1.1×10^9 ,实现轻量化效果。ATW –

YOLO 识别鸡蛋的 $mAP_{0.5}$ 达到 93.3%, P 达到 90.4%, R 达到 89.5%,识别速度达到 197.2 f/s,该模型兼顾了性能和复杂度。

(3)ATW – YOLO 模型在目标检测方面,较 YOLO v5、YOLO v8、YOLO v10、Faster R – CNN 的 $mAP_{0.5}$ 提高了 1.8、3.0、5.4、10.7 个百分点;在模型轻量化方面,较轻量化主干网络 EfficientNetV2 和 MobileViTv2 的模型参数量和浮点计算量有所降低,虽然 MobileNetV4 的参数量和浮点计算量最低,但其检测精度大幅降低。通过对比试验与消融试验的结果表明,ATW – YOLO 在鸡蛋粘连及鸡蛋与铁丝网之间遮挡情况下均能实现快速、高精度识别。

参 考 文 献

[1] 庄珑昱,郑江霞.鸡蛋品质评价方法研究进展及其影响因素分析[J].中国家禽,2024,46(3):87 – 94.
Zhuang Longyu, Zheng Jiangxia. Research progress on egg quality evaluation methods and analysis of influencing factors[J]. China Poultry, 2024, 46(3): 87 – 94. (in Chinese)

[2] 陈淑庆,李霞.蛋鸡产蛋异常的原因及预防措施[J].中国畜牧业,2023(24):113 – 114.
Chen Shuqing, Li Xia. Causes of abnormal egg production in laying hens and preventive measures[J]. China Animal Industry, 2023(24): 113 – 114. (in Chinese)

[3] So J H, Joe S Y, Hwang S H, et al. Current advances in detection of abnormal egg: a review[J]. J. Anim. Sci. Technol., 2022, 64(5):813 – 829.

[4] Ren C, Kim D K, Jeong D. A survey of deep learning in agriculture: techniques and their applications[J]. Journal of Information Processing Systems, 2020, 16(5): 1015 – 1033.

[5] 郭建军,杨霖,张恩威,等.基于机器视觉的裂纹鸡蛋分拣系统设计[J].现代农业装备,2024,45(1):45 – 52.
Guo Jianjun, Yang Lin, Zhang Enwei, et al. Design of cracked egg sorting system based on machine vision[J]. Modern Agricultural Equipment, 2024, 45(1): 45 – 52. (in Chinese)

[6] Zaidi S S A, Ansari M S, Aslam A, et al. A survey of modern deep learning based object detection models[J]. Digital Signal Processing, 2022, 126: 103514.

[7] Jocher G, Chaurasia A, Stoken A, et al. Ultralytics/yolov5: v6.2 – yolov5 classification models, apple m1, reproducibility, ClearML and deci. AI integrations[EB/OL]. (2020 – 06 – 09) [2025 – 06 – 30]. <https://github.com/ultralytics/yolov5>.

[8] Varghese R, Sambath M. YOLOv8: a novel object detection algorithm with enhanced performance and robustness[C]//2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS), Chennai, India: IEEE, 2024: 1 – 6.

[9] Wang A, Chen H, Liu L, et al. YOLOv10: real-time end-to-end object detection[J]. Advances in Neural Information Processing Systems, 2024, 37: 107984 – 108011.

[10] Khanam R, Hussain M. YOLOv11: an overview of the key architectural enhancements[PP/OL]. V1. arXiv (2024 – 10 – 23) [2025 – 06 – 30]. <https://doi.org/10.48550/arxiv.2410.17725>.

[11] 魏晶鑫,陈中举,许浩然.融合 Fasternet 与 YOLOv5 模型的鸡蛋外观检测[J].食品与机械,2024,40(8):105 – 112,165.
Wei Jingxin, Chen Zhongju, Xu Haoran. Detection of egg appearance based on Fasternet and YOLOv5 model[J]. Food & Machinery, 2024, 40(8): 105 – 112, 165. (in Chinese)

[12] Geffen O, Yitzhaky Y, Barchilon N, et al. A machine vision system to detect and count laying hens in battery cages[J]. Animal, 2020, 14(12):2628 – 2634.

[13] Bhavya B, Sai S R G, Ashis K D. Eggshell crack detection using deep convolutional neural networks[J]. Journal of Food Engineering, 2022, 315: 110798.

[14] 易诗,沈练,周思尧,等.基于增强型 Tiny – YOLOV3 模型的野鸡识别方法[J].农业工程学报,2020,36(13):141 – 147.
Yi Shi, Shen Lian, Zhou Siyao, et al. Recognition method of pheasant using enhanced Tiny – YOLOV3 model[J]. Transactions of the CSAE, 2020, 36(13): 141 – 147. (in Chinese)

[15] 赵春江,梁雪文,于合龙,等.基于改进 YOLO v7 的笼养鸡/蛋自动识别与计数方法[J].农业机械学报,2023,54(7):300 – 312.
Zhao Chunjiang, Liang Xuewen, Yu Helong, et al. Automatic identification and counting method of caged hens and eggs based on improved YOLO v7[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(7): 300 – 312. (in

Chinese)

[16] Wang C Y, Yeh I H, Mark Liao H Y. YOLO v9: learning what you want to learn using programmable gradient information[C] //European Conference on Computer Vision, Milan, Italy: Springer Nature Switzerland, 2024: 1 – 21.

[17] Misra D, Nalamada T, Arasanipalai A U, et al. Rotate to attend: convolutional triplet attention module[C] //Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision, Waikoloa, America: IEEE, 2020: 3139 – 3148.

[18] Tan M, Pang R, Le Q V. Efficientdet: scalable and efficient object detection[C] //Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, Washington, America: IEEE, 2020: 10781 – 10790.

[19] Zheng Z, Wang P, Ren D, et al. Enhancing geometric factors in model learning and inference for object detection and instance segmentation[J]. IEEE Transactions on Cybernetics, 2021, 52(8): 8574 – 8586.

[20] Tong Z, Chen Y, Xu Z, et al. Wise – IoU: bounding box regression loss with dynamic focusing mechanism[PP/OL]. V3. arXiv (2023 – 04 – 08) [2025 – 06 – 30]. <https://doi.org/10.48550/arxiv.2301.10051>.

[21] Tan M, Le Q. Efficientnetv2: smaller models and faster training[C] //International Conference on Machine Learning, Vienna, Austria: PMLR, 2021: 10096 – 10106.

[22] Qin D, Leichner C, Delakis M, et al. MobileNetV4: universal models for the mobile ecosystem[C] //European Conference on Computer Vision, Milan, Italy: Springer Nature Switzerland, 2024: 78 – 96.

[23] Mehta S, Rastegari M. Separable self-attention for mobile vision transformers[PP/OL]. V1. arXiv (2022 – 06 – 06) [2025 – 06 – 30]. <https://doi.org/10.48550/arxiv.2206.02680>.

[24] Zheng Z, Wang P, Liu W, et al. Distance – IoU loss: faster and better learning for bounding box regression[C] //Proceedings of the AAAI Conference on Artificial Intelligence, New York, America: AAAI Press, 2020: 12993 – 13000.

[25] Zhang Y F, Ren W, Zhang Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. Neurocomputing, 2022, 506: 146 – 157.

[26] Gevorgyan Z. SIoU loss: more powerful learning for bounding box regression[PP/OL]. V1. arXiv (2022 – 05 – 25) [2025 – 06 – 30]. <https://doi.org/10.48550/arxiv.2205.12740>.

[27] Ma S, Xu Y. Mpdious: a loss for efficient and accurate bounding box regression[PP/OL]. V1. arXiv (2023 – 07 – 14) [2025 – 06 – 30]. <https://doi.org/10.48550/arxiv.2307.07662>.

(上接第 399 页)

[26] 石庆兰, 束金阳, 李道亮, 等. 基于 BiLSTM – GRU 融合网络的稻虾养殖溶解氧含量预测[J]. 农业机械学报, 2023, 54(10): 364 – 370.

Shi Qinglan, Shu Jinyang, Li Daoliang, et al. Dissolved oxygen prediction in rice and shrimp culture based on BiLSTM – GRU fusion neural networks[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(10): 364 – 370. (in Chinese)

[27] Chen L, Yang X, Sun C, et al. Feed intake prediction model for group fish using the MEA – BP neural network in intensive aquaculture[J]. Information Processing in Agriculture, 2020, 7(2): 261 – 271.

[28] 赫晓慧, 罗浩田, 乔梦佳, 等. 基于 CNN – RNN 网络的中国冬小麦估产[J]. 农业工程学报, 2021, 37(17): 124 – 132.

He Xiaohui, Luo Haotian, Qiao Mengjia, et al. Yield estimation of winter wheat in China based on CNN – RNN network[J]. Transactions of the CSAE, 2021, 37(17): 124 – 132. (in Chinese)

[29] 袁诗佳, 余江, 麦竣深, 等. 基于 TCN – Transformer 与混合超参数优化的轴承剩余寿命预测模型[J]. 南方农机, 2026, 57(5): 119 – 122, 129.

Yuan Shijia, Yu Jiang, Mai Junshen, et al. Bearing remaining useful life prediction model based on TCN – Transformer and hybrid hyperparameter optimization[J]. Southern Agricultural Machinery, 2026, 57(5): 119 – 122, 129. (in Chinese)

[30] Farhangi H, Mozafari V, Roosta H R, et al. Optimizing growth conditions in vertical farming: enhancing lettuce and basil cultivation through the application of the Taguchi method[J]. Scientific Reports, 2023, 13(1): 6717.

[31] Guragain D P, Shrestha B, Bajracharya I. A low-cost centralized IoT ecosystem for enhancing oyster mushroom cultivation[J]. Journal of Agriculture and Food Research, 2024, 15: 100952.

[32] 王朕, 陈聪, 曹光乔, 等. 基于 MTL – LSTM – SAT 的养殖鱼类患病及生长预测模型构建与试验[J]. 农业机械学报, 2025, 56(11): 590 – 598, 620.

Wang Zhen, Chen Cong, Cao Guangqiao, et al. Construction and experiment of prediction model for disease and growth of cultured fish based on MTL – LSTM – SAT[J]. Transactions of the Chinese Society for Agricultural Machinery, 2025, 56(11): 590 – 598, 620. (in Chinese)