

基于改进YOLOv8的蓝莓果实成熟度检测方法研究

陈 炜, 王世刚, 高学山

广西科技大学自动化学院, 广西 柳州

收稿日期: 2026年3月16日; 录用日期: 2026年4月9日; 发布日期: 2026年4月15日

摘 要

蓝莓是果园种植户经济收益较高的水果之一, 识别不同成熟度的蓝莓果实具有重要经济意义, 可帮助种植户规划施药方案、估算产量并高效开展采收作业。为提高基于深度学习的蓝莓果实成熟度检测算法的精确性与鲁棒性, 提出了一种基于改进YOLOv8的蓝莓果实成熟度检测算法YOLO-BLUE。为了减少参数量, 改善目标检测效果, 采用BoTNet (Bottleneck Transformer Network)骨干架构代替原YOLOv8的Backbone网络, 并引入CoordAttention注意力机制, 提升模型对空间结构的理解能力。为了更有效地提高目标检测的准确度, 引入边框损失函数WIoU。为验证YOLO-BLUE改进算法的有效性, 采集四个成熟度的蓝莓果实并构成数据集, 试验结果表明, YOLO-BLUE的精确度 P 、召回率 R 以及平均精度均值 $mAP@0.5$ 达到83.9%、81.6%和87.5%, 分别提升4.3%、5.0%和3.7%, 为蓝莓果实的成熟度检测算法提供了新的改进思路。

关键词

蓝莓果实, 成熟度检测, 注意力机制, 深度学习, 损失函数

Research on the Detection Method of Blueberry Fruit Maturity Based on Improved YOLOv8

Wei Chen, Shigang Wang, Xueshan Gao

School of Automation, Guangxi University of Science and Technology, Liuzhou Guangxi

Received: March 16, 2026; accepted: April 9, 2026; published: April 15, 2026

Abstract

Blueberries are one of the fruits with relatively high economic benefits for orchard growers.

文章引用: 陈炜, 王世刚, 高学山. 基于改进YOLOv8的蓝莓果实成熟度检测方法研究[J]. 建模与仿真, 2026, 15(4): 91-104. DOI: 10.12677/mos.2026.154056

Identifying blueberry fruits at different ripening stages holds significant economic value, as it can help growers plan pesticide application schemes, estimate yields, and carry out efficient harvesting operations. To enhance the accuracy and robustness of deep learning-based blueberry ripeness detection algorithms, this study proposes an improved blueberry ripeness detection algorithm (YOLO-BLUE) based on YOLOv8. To reduce the number of parameters and improve target detection performance, the backbone architecture of the original YOLOv8 was replaced with BoTNet (Bottleneck Transformer Network). Additionally, the CoordAttention (Coordinate Attention) mechanism was introduced to enhance the model's ability to understand spatial structures. For more effective improvement of target detection accuracy, the bounding box loss function WIoU was adopted. To verify the effectiveness of the improved YOLO-BLUE algorithm, blueberry fruits at four ripening stages were collected to construct a dataset. Experimental results show that the precision (P), recall (R), and mean average precision at IoU = 0.5 (mAP@0.5) of YOLO-BLUE reached 83.9%, 81.6%, and 87.5%, representing increases of 4.3%, 5.0%, and 3.7% respectively. This study provides a new improvement approach for blueberry ripeness detection algorithms.

Keywords

Blueberry Fruits, Maturity Detection, Attention Mechanism, Deep Learning, Loss Function

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

近年来,全球蓝莓产业发展迅速,产量呈持续攀升态势,蓝莓也由此成为继草莓之后的全球第二大浆果作物[1]。2020年,中国蓝莓种植面积与总产量均位列全球首位;2024年,我国蓝莓栽培面积已超过140万亩,相较于2020年,种植面积提升44%,产量增幅高达197%[2]。作为一种兼具高营养价值与经济价值的浆果类作物,蓝莓的产业价值已得到广泛认可[3]。

成熟度作为蓝莓的核心表型特征,不仅直接关联果实采收的难易程度与总产规模,还可作为追踪浆果生长动态、优化作物管理策略的关键指标[4][5]。对果园内蓝莓果实成熟度进行实时监测,能够帮助种植户精准掌握蓝莓生长进程,进而完成产量估算,并制定科学合理的农艺管理措施。此外,相较于仅针对单一类别果实的识别工作,对不同成熟度蓝莓果实的识别能力,可进一步为机器人的路径规划与避障操作提供指导,最终实现果园作业的连续性[6][7]。

在蓝莓果实生长发育过程中,叶绿素呈现逐步降解趋势,而花青素的合成量则持续增加[8];这一生理变化直接导致果实颜色从初始的白绿色,依次过渡为粉色、红色,最终呈现典型的蓝色[9]。

基于蓝莓上述生长与表型特征,其成熟度识别工作面临诸多技术挑战:一方面,蓝莓果实簇生且遮挡现象显著,加之成熟周期较长,导致同一果簇内常同时存在不同成熟度、不同大小的果实,增加了识别的复杂性[10];另一方面,未成熟蓝莓果实的颜色与叶片颜色相似度较高,这一表型共性使得未成熟果实的检测精度普遍偏低[11]。上述问题的存在,均为不同成熟度蓝莓果实的精准识别带来了阻碍。

机器学习与深度学习可通过颜色特征(如RGB、HSV、光谱信息等)识别果实,从而克服上述挑战[12]。但传统机器学习算法往往高度依赖表层特征,难以有效捕捉复杂模式,导致其泛化能力和环境适应性受限。

与传统机器学习方法相比,深度学习方法在识别领域通常具有更高的精度[13]。例如,针对马铃薯农田实景拍摄图像中,花朵在图像中特征信息占比小,当达到开花普遍期和盛花期时花朵不仅细小,且分

布密集的问题, 提出 YOLOv5CD5-256 模型[14]; 针对玉米苗间杂草种类繁多、检测复杂度 high、检测速度慢的问题, 设计一种基于优化 YOLOv5 算法的玉米苗间杂草检测方法[15]。针对茄子生长环境的复杂性和不确定性使得采摘机器人难以准确对采摘点进行定位的问题, 提出了一种基于重参数结构的 YOLO-CRC 实例分割模型[16]; 针对苹果果实密度高、遮挡重叠严重导致的识别精度低的问题, 提出了改进的 YOLOv7 模型[17]; 针对由于颗粒状农作物品种繁多且环境中存在杂物干扰, 容易发生错检和漏检的情况, 同时传统色选设备对光线要求高, 需设计昂贵的光路元件以维持光线条件稳定等问题, 提出研究基于 YOLO 的颗粒状农作物检测算法[18]。为了快速精确识别田间复杂环境下的蓝莓果实的成熟度, 提出了一种基于 YOLOv8 蓝莓成熟度轻量化检测模型[19]。

然而, 当前的一些农作物果实成熟度检测研究中仍然存在一些问题。首先, 许多研究还是使用的较为落后的网络模型和方法, 导致模型参数多、结构复杂。其次, 现有的一些成熟度检测分类不完全, 导致模型的泛化能力弱。

基于上述挑战与启发, 本研究提出一种结合颜色特征的改进 YOLOv8s 模型(命名为 YOLO-BLUE 模型), 用于自然环境中不同成熟度蓝莓果实的检测识别。

2. 数据集获取与预处理

蓝莓成熟度图像采集于广西柳州的一个蓝莓采摘农场, 拍摄工具为 iPhone 14 Pro, 结合蓝莓采摘机器人在果园开展采摘工作的实际场景, 并参考行业专家的判定建议, 为适配机器人对果实成熟度的精准识别需求, 将蓝莓成熟度共划分为 4 个等级, 分别为未成熟、初熟(即“刚开始成熟”)、半成熟、完全成熟。各类别蓝莓的外观特征(如颜色、果形饱满度)及具体判定标准详见图 1。



Figure 1. Images of blueberries with different ripeness
图 1. 不同成熟度蓝莓图像

在田间实际生长过程中, 蓝莓会面临多种复杂环境问题。包括背景叶形成的视觉干扰、周围枝叶对果实的物理遮挡、果实间的相互重叠, 以及逆光带来的光照不均衡, 这些情况如图 2 所示。



Figure 2. Blueberry images in different situations
图 2. 不同情况下的蓝莓图像

为了提升模型的泛化能力，我们首先将采集的图像按 8:1:1 的比例划分为训练集、验证集和测试集，并进行图像预处理。利用裁剪、旋转、过滤、添加噪声等一系列预处理方法得到蓝莓图像 1497 张，验证集和测试集各 182 张，其中验证集图像中含有未成熟果实 742，初熟果实 108，半熟果实 153，完全成熟果实 1453。然后使用 Labelimg 工具对蓝莓图像进行标注处理。

3. YOLO-BLUE 目标检测网络

3.1. YOLOv8 网络框架

YOLOv8 是 YOLO 系列目标检测模型的重要代表之一。该模型共提供五种不同规模的版本，包括 YOLOv8n、YOLOv8s、YOLOv8m、YOLOv8l 和 YOLOv8x。其中，YOLOv8s 在识别精度和识别速度上最为平衡。基于这一优势，并结合实际任务对效率与精度的综合需求，本研究选择 YOLOv8s 作为蓝莓果实成熟度识别任务的基础模型。

YOLOv8 整体遵循“输入层、骨干网络、颈部网络、检测头”的经典单阶段检测器架构，其中骨干网络包含 5 个卷积块、4 个 C2f 块和 1 个 SPPF 块，骨干网络负责特征提取，核心改进是替换 YOLOv5 的 C3 模块为 C2f 模块。颈部网络采用了路径聚合网络(Path Aggregation Network, PANet) [20]。相较于特征金字塔网络(Feature Pyramid Network, FPN) [21]，PANet 引入了自底向上的路径增强机制，可以更好的进行特征提取与融合。头部网络将回归任务与分类任务解耦，分别使用独立的分支进行处理。该结构可以使得模型在训练任务中迅速收敛，从而提高检测效率。

3.2. 改进后的 YOLOv8 目标检测网络

田间复杂环境为蓝莓果实的目标检测带来诸多挑战，不仅需满足实时检测需求，还需尽可能提升模型对果实成熟度的分类与定位精度。针对这一需求，本研究以 YOLOv8s 为基线模型，设计了 YOLO-BLUE 模型，并实施以下三项关键改进：1) 使用 BoTNet (Bottleneck Transformer Network)骨干架构代替原 YOLOv8 的主干网络结构；2) 在主干网络中引入 Coordinate Attention 注意力机制；3) 使用边界框损失函数 WIoU 代替原来的 CIoU 损失函数。

本研究提出的 YOLO-BLUE 目标检测网络架构如图 3 所示，由输入层、主干特征提取网络、路径聚合网络及输出层四个核心组件构成。

BoTNet 的核心是轻量级全局自注意力建模，若插入浅层，高分辨率特征会导致自注意力计算量呈平方级增长，违背 YOLOv8s 轻量高效的设计初衷；同时浅层特征的语义模糊性会让注意力被背景噪声干扰，无法有效建模蓝莓簇的空间关联。而 SPPF 之后的深层特征层是多尺度池化融合后的结果：既保留了全局上下文信息，又控制了分辨率，是注入全局自注意力的最优时机。此时 BoTNet 可以在高语义特征上建模蓝莓簇的长距离空间依赖，如同一枝条上的多颗重叠果实，同时避免计算爆炸，完美契合 BoTNet 的轻量全局建模特性。

Coordinate Attention 的核心优势是显式编码水平和垂直坐标信息，保留目标空间位置，若插入深层(如 SPPF 后)，特征图分辨率过低，位置信息严重压缩，Coordinate Attention 的坐标感知能力会失效；若插入最浅层(第一个 C2f 后)，语义信息匮乏，注意力易聚焦于背景噪声，无法有效强化果实特征。因此需要在保留足够分辨率的特征层插入才能发挥作用，既保留了充足的空间位置信息，又积累了一定的语义信息，实现了位置感知和语义强化的完美平衡。

3.2.1. 主干网络的改进

在野外田间蓝莓检测场景中，叶片、枝条、土壤等背景与果实特征相似度高，纯 CNN 主干易混淆背

景与目标特征。除此之外，蓝莓单果体积小，常成簇生长，果实间重叠度高，原 YOLOv8s 的 C2f 纯 CNN 主干仅能提取局部特征，易将重叠果实误判为单个目标、或丢失遮挡小果实。

针对上述的目标与挑战，BoTNet (Bottleneck transformers) [22]作为一种即插即用的骨干网络，它结合了用于多个计算机视觉任务的自注意力，包括图像分类、对象检测和实例分割。BoTNet 通过全局注意力聚焦果实目标的全局语义特征，抑制枝叶等无效背景噪声，提升目标与背景的分度。除此之外，BoTNet 的全局自注意力可建模簇生蓝莓间的空间位置关联，区分相邻和重叠果实的独立特征，大幅提升密集遮挡场景下的小目标检出率。最后，由于田间拍摄距离不定，蓝莓目标尺度差异大，BoTNet 的多尺度特征融合和自注意力可适配不同尺度果实特征；同时其轻量化结构契合 YOLOv8s 轻量定位，满足蓝莓实景检测的实时性需求。

通过仅在 ResNet 的最后三个瓶颈块中用全局自注意力替换空间卷积并且没有其他更改，在实例分割和对象检测方面显著改进了基线，同时还减少了参数，而延迟开销最小，如图 4 所示。

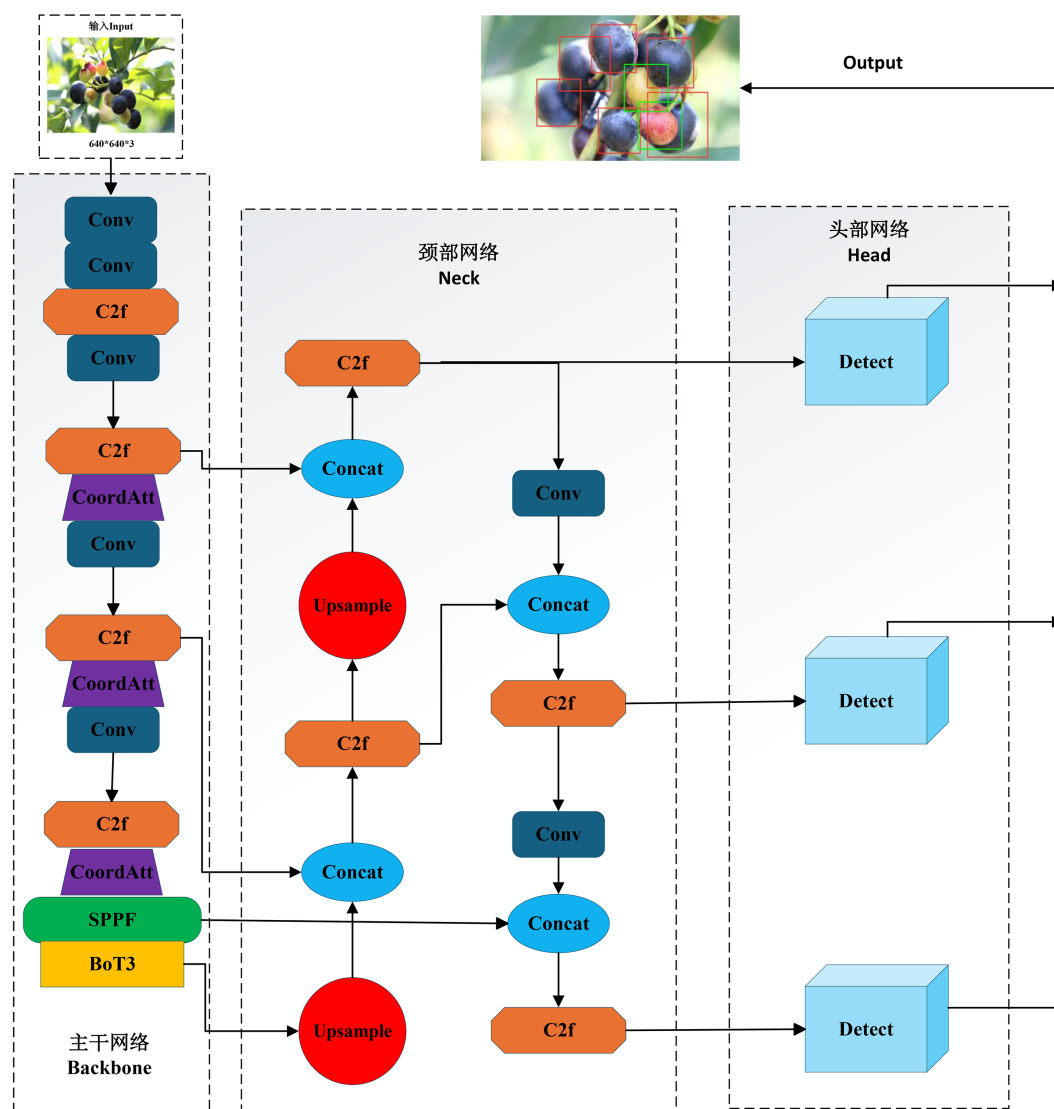


Figure 3. Network structure of YOLO-BLUE

图 3. YOLO-BLUE 模型架构




Figure 4. A ResNet bottleneck block and A Bot-tleneck transformer (BoT) block
图 4. ResNet 瓶颈块和 BoT 多头自注意力块

上图中的 MHSA 为 BoT 块中使用的多头自注意力(Multi-Head Self-Attention)层，通过“全局 all2all 注意力 + 相对位置编码 + 多头部机制”，既解决了传统卷积的长距离依赖建模缺陷，又弥补了纯自注意力的位置感知不足，在提升性能的同时，通过“瓶颈结构复用 + 注意力局部化”控制参数与计算开销，成为 BoTNet 在视觉任务中高效运行的核心支撑。其具体架构如图 5 所示。

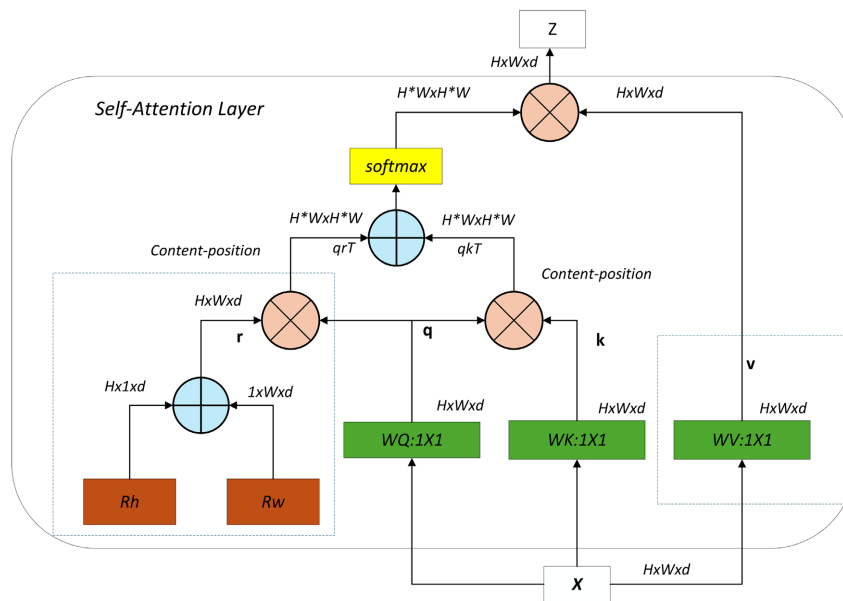


Figure 5. Multi-head self-attention (MHSA) layer used in the BoT block
图 5. BoT 块中使用的多头注意力层

3.2.2. Coordinate Attention 注意力机制

新加坡国立大学与 SEA AI Lab 团队提出 Coordinate Attention [23] (CA, 坐标注意力), 旨在解决移动端网络中传统通道注意力忽略位置信息、空间注意力难以建模长距离依赖的缺陷。蓝莓属于典型小目标, 普通注意力机制通过全局池化压缩空间信息, 会丢失小果实的精准坐标, 导致定位偏移。Coordinate Attention 保留水平、垂直方向的位置信息, 精准感知小蓝莓的空间坐标, 从特征层强化目标定位精度, 避免漏检、定位偏差。其次簇生蓝莓间距极小, 普通注意力无法区分相邻目标的位置边界, Coordinate Attention 通过坐标感知精准分割单个果实的特征区域, 避免将多个果实合并为一个检测框, 解决密集场景下的粘连误检痛点。最后, Coordinate Attention 计算量极低, 嵌入 BoTNet 主干后不破坏模型轻量化结构, 完美适配蓝莓检测对模型速度和精度的双重要求。

YOLO-BLUE 模型在骨干网络中添加的 CA 模块如图 6 所示, 输入特征图通过两个池化层(XAvg 和 YAvg)进行编码, 并聚合到图像的每个通道上。将两个方向的特征图进行拼接, 然后执行二维卷积。接着进行批归一化和分割操作, 使用尺寸为 1×1 的卷积核对分割后的特征图进行卷积。通过 Sigmoid 函数处理分割后的特征图, 输出注意力向量。

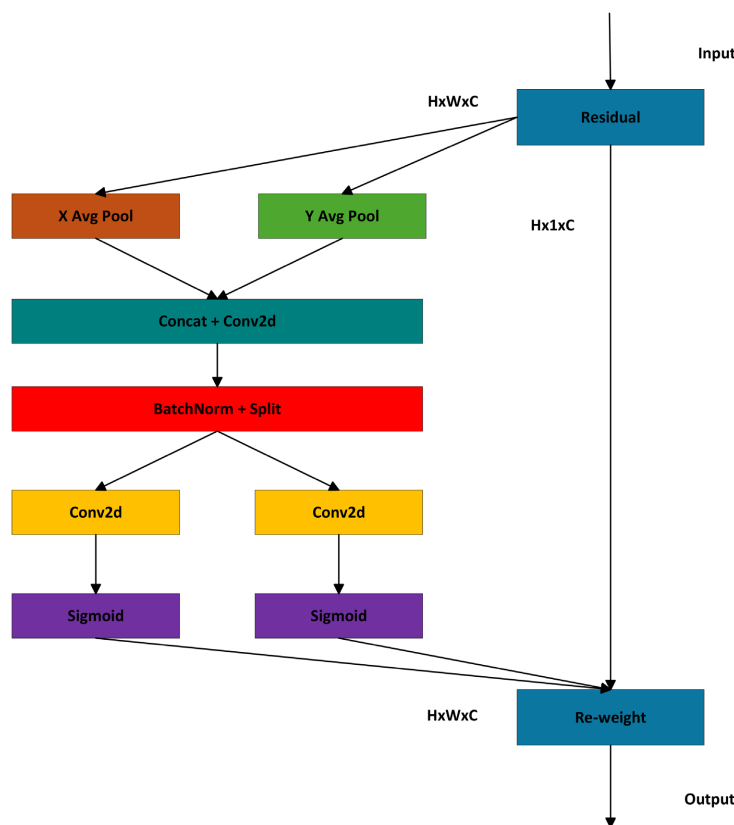


Figure 6. The structure and processing flow of the CoordAtt block
图 6. CoordAtt 模块结构与处理流程

3.2.3. 损失函数改进

蓝莓重叠遮挡时, 原生 CIoU 易出现框包裹多个果实、框与果实轮廓不匹配的问题; WIoU [24] 强化边界框与果实真实轮廓的几何对齐与交并比优化, 精准为每个重叠果实生成独立、贴合的检测框, 解决簇生场景下的框回归混乱问题。同时, 田间蓝莓果实姿态各异、形状略有不规则, WIoU 的柔性对齐机制

可适配不同姿态果实的边界框回归，相比 CIoU 的固定几何约束，对不规则小目标的兼容性更强。最后，WIoU 损失梯度更平滑，能让 YOLO-BLUE 模型更快收敛，在蓝莓数据集上以更少迭代次数达到更高定位精度，适配小样本、实景数据集的训练需求。

1) Wise-IoUv1

训练集中的低质量图像，当使用几何度量时，损失函数的泛化性能会大幅下降。为减弱几何度量的惩罚力度并提升模型的泛化能力，新的边界框损失 L_{WIoUv1} 如公式(1)~(3)所示。

$$L_{\text{IoU}} = 1 - \text{IoU} = 1 - \frac{W_i H_i}{S_n} \quad (1)$$

$$\mathcal{R}_{\text{WIoU}} = \exp\left(\frac{(x - x_{\text{gt}})^2 + (y - y_{\text{gt}})^2}{(W_g^2 + H_g^2)^*}\right) \quad (2)$$

$$L_{\text{WIoUv1}} = \mathcal{R}_{\text{WIoU}} L_{\text{IoU}} \quad (3)$$

式中 L_{IoU} 为基础的边界框损失函数； x 和 y 分别代表中心坐标； x_{gt} 和 y_{gt} 表示真实边界框的中心坐标； W ， H 分别代表预测边界框的宽度和高度。

2) Wise-IoUv2

与焦点损失(Focal Loss)为交叉熵(cross-entropy)所设计的单调聚焦机制类似，WIoUv2 通过单调聚焦系数，提升模型在难样本上的性能表现。

$$L_{\text{WIoUv2}} = L_{\text{IoU}}^* L_{\text{WIoUv1}}, \gamma > 0 \quad (4)$$

为 L_{WIoUv1} 构建了一个单调聚焦系数 L_{IoU}^* ，并引入 L_{IoU} 的均值作为归一化因子，以提升梯度增益。

$$L_{\text{WIoUv2}} = \left(\frac{L_{\text{IoU}}^*}{L_{\text{IoU}}}\right)^\gamma L_{\text{WIoUv1}} \quad (5)$$

此外，由于随着 L_{IoU} 减小， L_{IoU}^* 的梯度增益会衰减，收敛速度趋于变慢。为了解决梯度下降的难题并保持较高的收敛速度，滑动平均 $\overline{L_{\text{IoU}}}$ 被更新作为归一化因子，从而得到 L_{WIoUv2} 。

1) Wise-IoUv3

WIoUv3 引入了异常度的概念，并将其定义为锚框质量的表征指标。

$$\beta = \frac{L_{\text{IoU}}^*}{L_{\text{IoU}}} \in [0, +\infty) \quad (6)$$

异常度的大小与锚框的质量正相关。因此，异常度较小的锚框被分配较小的梯度增益，而异常度较大的锚框被分配较大的梯度增益。此外，引入一个非单调聚焦因子 r 来改进 L_{WIoUv1} 。最终的 L_{WIoUv3} 由公式(7)所示

$$L_{\text{WIoUv3}} = r L_{\text{WIoUv1}}, \quad r = \frac{\beta}{\delta \alpha^{\beta - \delta}} \quad (7)$$

由于是 $\overline{L_{\text{IoU}}}$ 动态的，锚框的质量分类标准也具有动态性，这使得 WIoUv3 能够在每一刻分配最适配当前场景的梯度增益。因此，本研究所采用的 WIoUv3 函数能够有效增强低质量绝缘子图像的收敛效果，从而提升算法的整体性能。

3.3. 实验环境与方法

本研究的模型训练环境具体配置如下：硬件平台为 Intel Core i7-13650HX 处理器、NVIDIA RTX 4060

显卡(8GB 显存), 内存为 16GB; 软件框架采用 Python3.8.20 编程语言, 搭配 PyTorch1.10.1 深度学习框架及 cudatoolkit11.3 加速库。训练过程中设置的核心超参数为: 批次大小(batch size) = 16, 初始学习率(initial learning rate) = 0.01, 总训练轮次(total epochs) = 150。

为实现对蓝莓成熟度分级模型性能的科学且全面的量化评估, 本研究构建了多维度评价体系, 涵盖准确率(Precision, P)、召回率(Recall, R)、F1 分数、平均精度均值(mAP@0.5)、检测推理速度及边界框回归损失(box_loss)等关键指标, 以此全方位表征模型在蓝莓成熟度分级任务中的检测性能与泛化能力。

本研究采用单张蓝莓图像的识别耗时衡量检测速度, 单位为 ms。

4. 实验过程与结果分析

4.1. 不同主干网络结果对比分析

为了对 2.2 节所提出的主干网络改进方法进行实验验证与分析, 本小节通过在 YOLOv8s 的基础上分别使用 BoTNet、VanillaNet 作为 YOLOv8s 的主干网络, 并对这三个模型的各个评价指标进行对比, 对比结果如表 1 所示。

Table 1. The experimental results of different backbone networks

表 1. 不同主干网络试验结果

模型	mAP@0.5/%	检测速度(ms)
YOLOv8s	83.2	13.0
YOLOv8+BoTNet	85.8	13.5
YOLOv8+VanillaNet	83.4	14.5

从图 7(a)的可视化检测结果可以看出, 原 YOLOv8 模型在蓝莓多目标识别任务中性能欠佳, 存在显著的漏检与误识别问题, 检测结果的准确性与完整性均达不到实际田间应用标准。如图 7(b)所示, 以 VanillaNet 替换 YOLOv8 主干网络后, 模型检测效果未实现有效提升, 不仅依旧存在蓝莓漏检问题, 还出现了果实成熟度误判的新缺陷, 无法适配蓝莓复杂田间检测场景。而图 7(c)的实验结果表明, 将 YOLOv8 主干网络更换为 BoTNet 后, 模型检测性能得到大幅优化, 在果实重叠遮挡、逆光等复杂环境下均可完成精准检测, 无漏检现象, 同时保持了优异的推理速度, 可同时满足蓝莓多目标检测对精度与实时性的双重要求。综合上述对比实验结论, 本研究最终选定 BoTNet 作为改进模型的主干特征提取网络。




Figure 7. Model recognition results of different backbone networks

图 7. 不同主干网络的模型识别结果

4.2. 不同注意力机制算法对比

本研究以 YOLOv8 作为基准模型, 通过在其主干特征提取网络 DarkNet-53 中引入不同类型注意力机

制，增强模型对关键特征的聚焦与提取能力，从而提升目标检测框定位准确性与模型整体检测精度。为定量分析不同注意力机制在蓝莓成熟度特征提取中的作用差异，本文选用 CBAM、GAM 两类经典注意力模块与本文设计的 CA 注意力模块进行性能对比。实验对比数据如表 2 所示，mAP@0.5 指标的可视化对比结果如图 8 所示。

Table 2. Comparison of results of different attention mechanisms
表 2. 不同注意力机制结果比较

模型	mAP@0.5/%	P/%	R/%	F1/%
YOLOv8s	83.2	79.4	79.3	79.1
YOLOv8 + CBAM	82.2	78.3	75.1	76.4
YOLOv8 + GAM	85.9	82.4	78.8	79.8
YOLOv8 + CA	86.4	79.6	79.9	80.2

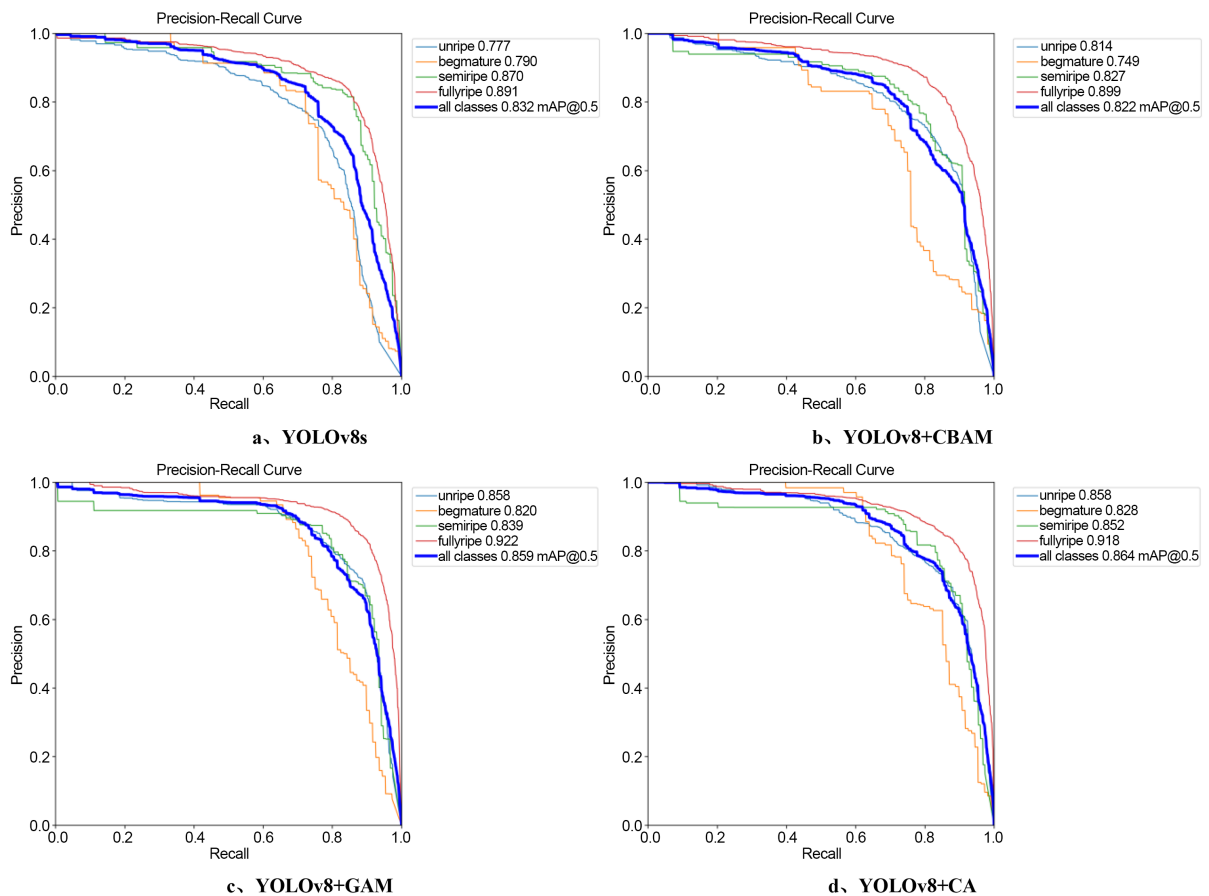


Figure 8. Comparison of mAP@0.5 with different attention mechanisms added to the backbone network
图 8. 主干网络加入不同注意力 mAP@0.5 对比

通过在 YOLOv8 基础模型的主干网络上分别引入 CBAM、GAM 及本文提出的 CA 注意力模块开展对比实验，从 mAP@0.5、精确率(P)、召回率(R)和 F1 分数等多维度指标进行评估，结果显示 YOLOv8 + CA 在各项关键检测指标上均显著优于 YOLOv8s 原始模型及引入 CBAM、GAM 的模型，其中 mAP@0.5 达 86.4%、F1 分数达 80.2%，充分验证了 CA 注意力模块在特征提取与目标识别任务中的有效性，且通

过对比实验明确了其相较于 CBAM、GAM 的性能优势，为基于注意力机制的目标检测模型优化提供了扎实的实验支撑。

4.3. 使用不同损失函数结果分析

鉴于 YOLOv8 模型所采用的原生 CIoU 损失函数存在收敛速度不足、计算效率低下等局限性，本研究对边界框回归损失函数进行优化改进，以 WIoU 损失函数替代原有 CIoU 损失函数。为客观验证该改进策略对模型性能的提升效果，本研究设置对照实验，对比分析改进模型与基准模型的核心检测指标，进而证明损失函数优化方案的可行性与有效性。

Table 3. Experimental results of different loss functions

表 3. 不同损失函数实验结果

损失函数 Loss functions	mAP@0.5/%	定位损失 box_loss	分类损失 cls_loss
CIoU	83.2	1.09	0.63
WIoU	84.5	0.67	0.60

由表 3 不同损失函数实验结果可知，相较于原模型的 CIoU 损失函数，将其替换为 WIoU 后，模型的 mAP@0.5 提升 1.3 个百分点，定位损失(box_loss)降低 0.42，分类损失(cls_loss)降低 0.03。其具体检测效果如图 9 所示，由图 9(A)可知，当采用 CIoU 作为模型损失函数时，最下方的被半遮挡蓝莓出现了漏检的情况，由图 9(B)可知，当采用 WIoU 作为模型损失函数时，则上述情况的识别效果良好，验证了采用 WIoU 损失函数对 YOLOv8 模型性能优化的有效性。



Figure 9. Detection results of models with different loss functions

图 9. 不同损失函数模型检测结果

4.4. 与其他经典模型的比较

为验证 YOLO-BLUE 模型的有效性与优越性，本研究在相同数据集与实验环境条件下，将该模型与 YOLOv5、YOLOv4 及改进前的基准模型 YOLOv8s 等当前主流目标检测模型进行综合性能对比。各模型的精度、召回率、平均精度均值(mAP@0.5)与 F1 分数等关键性能评价指标如表 4 所示。

由实验结果可知，YOLO-BLUE 模型在各项性能指标上均取得最优表现：其 mAP@0.5 达到 87.5%，较基准模型 YOLOv8s 提升 4.3 个百分点；精度为 83.9%，召回率为 81.6%，分别较 YOLOv8s 提升 4.5 和 2.3 个百分点；F1 分数为 81.2%，较 YOLOv8s 提升 2.1 个百分点。相较于更早的 YOLOv4、YOLOv5 模型，YOLO-BLUE 的性能优势更为显著，充分验证了其在目标检测任务中的有效性与竞争力。

Table 4. Performance comparison of different detection models
表 4. 不同检测模型性能对比

模型 Models	$mAP@0.5/\%$	P/%	R/%	F1/%
YOLOv8s	83.2	79.4	79.3	79.1
YOLOv5	81.6	78.8	78.3	78.6
YOLOv4	80.4	76.2	75.9	75.8
YOLO-BLUE	87.5	83.9	81.6	81.2

4.4. YOLO-BLUE 的消融实验

为明确本研究提出的 YOLO-BLUE 模型的性能提升效果,本研究设计与 YOLOv8s 模型的逐步对比实验,通过分层对照逐一验证模型各改进环节的实际效用,相关对比结果详见表 5。

Table 5. Results of ablation experiments
表 5. 消融试验结果

BoTNet	CA	WIoU	$mAP@0.5/\%$	P/%	R/%	F1/%
×	×	×	83.2	78.9	77.9	78.7
√	×	×	85.8	82.5	77.2	80.0
×	√	×	86.4	79.6	79.9	80.2
×	×	√	84.5	81.6	76.4	78.8
√	√	×	84.6	83.8	76.3	79.8
√	×	√	86.3	81.8	79.7	80.3
×	√	√	84.8	79.1	78.7	79.0
√	√	√	87.5	83.9	81.6	81.2

注：“×”表示未使用此改进策略；“√”表示使用此改进策略。

由表 5 试验结果可知,从单策略改进来看,BoTNet 的引入使 $mAP@0.5$ 从 83.2% 提升至 85.8%,精确率提升 3.6 个百分点,验证了其在特征提取与目标检测上的有效性;CA 单独作用时, $mAP@0.5$ 达 86.4%,召回率提升 2.0 个百分点,体现了其对注意力机制的优化价值;WIoU 的应用让 $mAP@0.5$ 提升 1.3 个百分点,定位损失收敛更优,凸显了损失函数改进的作用。

从两策略组合效果分析,BoTNet+CA 的组合 $mAP@0.5$ 为 84.6%,虽略低于 CA 单独使用,但精确率达 83.8%,展现出特征提取与注意力机制的部分协同性;BoTNet+WIoU 组合 $mAP@0.5$ 达 86.3%,精确率与召回率均优于单策略 BoTNet 或 Wiou;CA+WIoU 组合 $mAP@0.5$ 为 84.8%,在分类与定位损失间取得一定平衡。

当 BoTNet、CA、WIoU 三者协同应用时,模型在 $mAP@0.5$ 、精确率、召回率及 F1 分数上均达到最优,分别为 87.5%、83.9%、81.6% 和 81.2%,较原模型分别提升 4.3 个百分点、5.0 个百分点、3.7 个百分点和 2.5 个百分点,充分证明三种改进策略在特征提取、注意力增强、损失函数优化三个维度存在互补性,联合使用可全方位提升 YOLO-BLUE 模型对蓝莓的检测精度、定位准确性与分类可靠性,验证了本研究多模块改进方案的科学性与有效性。

4.5. YOLO-BLUE 在自然环境中的识别性能

为了更好的评估 YOLO-BLUE 模型在自然环境中识别不同成熟度蓝莓果实的性能,采用无过多遮挡、枝叶遮挡、果实重叠及光线干扰四类环境下的蓝莓果实图像进行逐一验证测试,识别结果如图 10 所示。

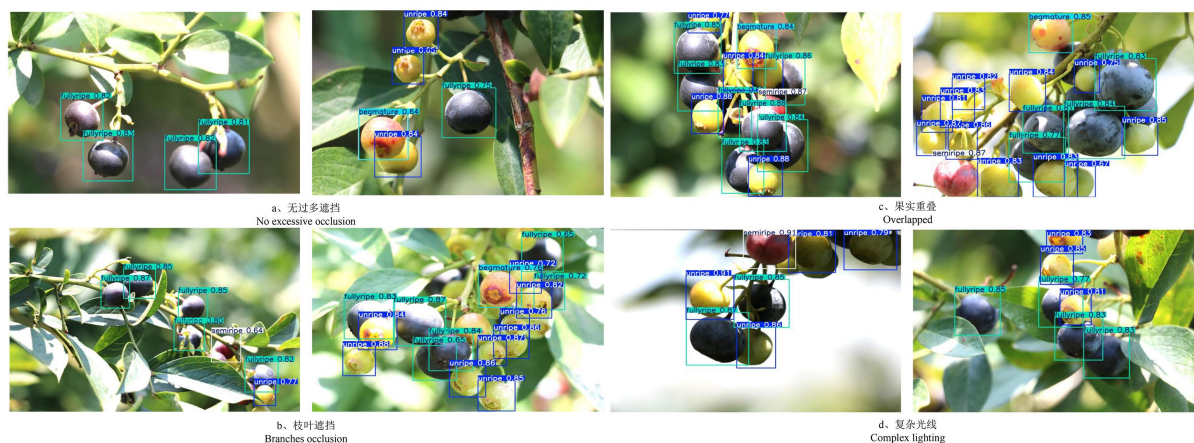


Figure 10. Detection results of the YOLO-BLUE model for blueberry ripeness under different natural environments
图 10. YOLO-BLUE 模型在不同自然环境下蓝莓成熟度检测结果

由图 10 可见, YOLO-BLUE 模型在各类复杂环境中的检测性能均表现优异, 基本无漏检、误检现象。进一步从算法性能层面分析, 该模型在目标检测任务中表现突出, 能够更精准地定位目标区域, 尤其在小目标与重叠目标的检测上优势显著。

5. 结论

针对野外田间复杂环境下蓝莓成熟度检测难度大、现有模型检测精度与实时性难以兼顾的问题, 本研究以 YOLOv8 为基础, 通过网络结构优化与损失函数改进, 提出了 YOLO-BLUE 目标检测算法, 并通过系统的实验对其性能进行了验证。

实验结果表明, YOLO-BLUE 算法在蓝莓复杂场景数据集上展现出卓越的检测性能, 其 $mAP@0.5$ 指标较基准模型 YOLOv8 提升显著, 精度与召回率均得到有效改善, 能够精准应对野外田间光照波动、枝叶遮挡、果实重叠等干扰因素, 实现不同成熟度蓝莓果实的高效识别与定位。在检测速度方面, 该算法保持了轻量化优势, 推理效率满足田间实时检测需求, 具备较强的场景适配能力。

本研究不仅验证了 YOLO-BLUE 算法在蓝莓成熟度检测中的有效性与优越性, 也为农产品田间智能检测技术的创新与应用提供了新的思路与技术支撑, 对促进农业智能化升级、提高蓝莓产业生产效率具有重要的实际应用价值与理论参考意义。

参考文献

- [1] 李亚东, 裴嘉博, 孙海悦. 全球蓝莓产业发展现状及展望[J]. 吉林农业大学学报, 2018, 40(4): 421-432.
- [2] 段毅, 王淑娟. “产量冠军”如何迈上“价值高地” [N]. 云南日报, 2025-07-21(001).
- [3] 黄国辉. 蓝莓种植效益分析[J]. 新农业, 2025(4): 92-95.
- [4] Ni, X., Li, C., Jiang, H. and Takeda, F. (2021) Three-Dimensional Photogrammetry with Deep Learning Instance Segmentation to Extract Berry Fruit Harvestability Traits. *ISPRS Journal of Photogrammetry and Remote Sensing*, **171**, 297-309. <https://doi.org/10.1016/j.isprsjprs.2020.11.010>
- [5] Meng, F., Li, J., Zhang, Y., Qi, S. and Tang, Y. (2023) Transforming Unmanned Pineapple Picking with Spatio-Temporal Convolutional Neural Networks. *Computers and Electronics in Agriculture*, **214**, Article 108298. <https://doi.org/10.1016/j.compag.2023.108298>
- [6] Chen, M., Chen, Z., Luo, L., Tang, Y., Cheng, J., Wei, H., et al. (2024) Dynamic Visual Servo Control Methods for Continuous Operation of a Fruit Harvesting Robot Working throughout an Orchard. *Computers and Electronics in Agriculture*, **219**, Article 108774. <https://doi.org/10.1016/j.compag.2024.108774>
- [7] Tang, Y., Qi, S., Zhu, L., Zhuo, X., Zhang, Y. and Meng, F. (2024) Obstacle Avoidance Motion in Mobile Robotics.

Journal of System Simulation, **36**, 1-26.

- [8] Routray, W. and Orsat, V. (2014) Variation of Phenolic Profile and Antioxidant Activity of North American Highbush Blueberry Leaves with Variation of Time of Harvest and Cultivar. *Industrial Crops and Products*, **62**, 147-155. <https://doi.org/10.1016/j.indcrop.2014.08.020>
- [9] Little, C.M., Chapman, T.W. and Hillier, N.K. (2018) Effect of Color and Contrast of Highbush Blueberries to Host-Finding Behavior by *Drosophila Suzukii* (Diptera: Drosophilidae). *Environmental Entomology*, **47**, 1242-1251. <https://doi.org/10.1093/ee/nvy102>
- [10] Zhu, X., Ma, H., Ji, J., Jin, X., Zhao, K. and Zhang, K. (2020) Detecting and Identifying Blueberry Canopy Fruits Based on Faster R-CNN. *Journal of Southern Agriculture*, **51**, 1493-1501.
- [11] Wang, L., Qin, M., Lei, J., Wang, X. and Tan, K. (2021) Blueberry Maturity Recognition Method Based on Improved YOLOv4-Tiny. *Transactions of the Chinese Society of Agricultural Engineering*, **37**, 170-178.
- [12] Barnea, E., Mairon, R. and Ben-Shahar, O. (2016) Colour-Agnostic Shape-Based 3D Fruit Detection for Crop Harvesting Robots. *Biosystems Engineering*, **146**, 57-70. <https://doi.org/10.1016/j.biosystemseng.2016.01.013>
- [13] Marji Alresheedi, K., Aladhadh, S., Ullah Khan, R. and Mustafa Qamar, A. (2022) Dates Fruit Recognition: From Classical Fusion to Deep Learning. *Computer Systems Science and Engineering*, **40**, 151-166. <https://doi.org/10.32604/csse.2022.017931>
- [14] 邬桐, 朱永宁, 武向娟, 等. 基于改进型 YOLOv5 的马铃薯花朵识别技术[J]. 中国农业气象, 2025, 46(10): 1512-1520.
- [15] 张天宇, 韩静, 廖洪晖, 曲欣锐. 基于优化 YOLOv5 算法的玉米苗间杂草检测研究[J]. 中国农机化学报, 2025, 46(7): 220-225.
- [16] 刘芹, 欧阳婧玟, 周智彬, 等. 基于 YOLO-CRC 的茄子及茄子梗分割与定位方法[J]. 农业工程学报, 2025, 41(19): 196-205.
- [17] Yang, H., Liu, Y., Wang, S., Qu, H., Li, N., Wu, J., et al. (2023) Improved Apple Fruit Target Recognition Method Based on YOLOv7 Model. *Agriculture*, **13**, Article 1278. <https://doi.org/10.3390/agriculture13071278>
- [18] 申志超. 基于 YOLO 的颗粒状农作物检测算法研究[D]: [硕士学位论文]. 哈尔滨: 哈尔滨工业大学, 2021.
- [19] 田有文, 覃上声, 闫玉博, 等. 基于改进 YOLOv8 的田间复杂环境下蓝莓成熟度检测[J]. 农业工程学报, 2024, 40(16): 153-162.
- [20] Roy, A.M., Bose, R. and Bhaduri, J. (2022) A Fast Accurate Fine-Grain Object Detection Model Based on YOLOv4 Deep Neural Network. *Neural Computing and Applications*, **34**, 3895-3921. <https://doi.org/10.1007/s00521-021-06651-x>
- [21] Lin, T., Dollar, P., Girshick, R., He, K., Hariharan, B. and S. Belongie. (2017) Feature Pyramid Networks for Object Detection. 2017 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Honolulu, 21-26 July 2017, 936-944. <https://doi.org/10.1109/cvpr.2017.106>
- [22] Srinivas, A., Lin, T., Parmar, N., Shlens, J., Abbeel, P. and Vaswani, A. (2021) Bottleneck Transformers for Visual Recognition. 2021 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Nashville, 20-25 June 2021, 16514-16524. <https://doi.org/10.1109/cvpr46437.2021.01625>
- [23] Hou, Q., Zhou, D. and Feng, J. (2021) Coordinate Attention for Efficient Mobile Network Design. 2021 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Nashville, 20-25 June 2021, 13708-13717. <https://doi.org/10.1109/cvpr46437.2021.01350>
- [24] Tong, Z., Chen, Y., Xu, Z. and Yu, R. (2023) Wise-IoU: Bounding Box Regression Loss with Dynamic Focusing Mechanism. arXiv:2301.10051.