

杨平江, 何江波, 周吴, 等. 透明萃取管抓取机器人的目标识别算法研究[J]. 智能计算机与应用, 2026, 16(2): 49-54. DOI: 10.20169/j.issn.2095-2163.25082902

透明萃取管抓取机器人的目标识别算法研究

杨平江¹, 何江波¹, 周吴², 胡益豪², 陈单千², 杜梓忆²

(1 西华大学 机械工程学院, 成都 610039; 2 电子科技大学 机械与电气工程学院, 成都 611731)

摘要: 针对透明萃取管抓取机器人识别本文提出了一种改进 YOLOv8n 模型算法, 实现了对环境干扰、复杂多变背景及多尺度特征融合不一致的良好抑制。首先, 在主干网络引入 DynamicConv 模块, 通过参数增强函数增加模型容量, 提升对复杂背景的鲁棒性; 然后, 在 SPPF 层后添加 LSKA 注意力机制, 通过分解大卷积核扩大感受野, 强化对萃取管特征的提取能力; 最后, 在检测头融合 ASFF 策略, 动态学习萃取管的特征权重, 增强尺度不变性。实验结果表明, 对比 YOLOv8n 模型, 改进模型在准确率 (Precision, P)、召回率 (Recall, R)、平均精度 (mean Average Precision, mAP), 分别提升了 5.7%、4.0%、5.5%。该算法显著提升了复杂环境下透明萃取管的识别鲁棒性, 为实验智能化升级提供了有效视觉识别方案。

关键词: 改进 YOLOv8n 算法; 萃取管识别; 深度学习

中图分类号: TP242.6

文献标志码: A

文章编号: 2095-2163(2026)02-0049-06

Research on target recognition algorithm for transparent extraction tube grasping robot

YANG Pingjiang¹, HE Jiangbo¹, ZHOU Wu², HU Yihao², CHEN Danqian², DU Ziyi²

(1 School of Mechanical Engineering, Xihua University, Chengdu 610039, China; 2 School of Mechanical and Electrical Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China)

Abstract: An improved YOLOv8n model algorithm is proposed for the recognition of transparent extraction tubes, which achieves good suppression of environmental interference, complex and variable backgrounds, and inconsistent multi-scale feature fusion. Firstly, the DynamicConv module is introduced into the backbone network. The model capacity is increased through the parameter enhancement function to improve the robustness against complex backgrounds. Then, the LSKA attention mechanism is added after the SPPF layer to expand the receptive field by decomposing the large convolutional kernels and enhance the extraction ability of the extraction tube features. Finally, the ASFF strategy is fused in the detection head to dynamically learn the feature weights of the extraction tube and enhance scale invariance. The experimental results demonstrate that, compared with the YOLOv8n model, the improved model has increased the accuracy (Precision, P), Recall (Recall, R), and mean Average Precision (mAP) by 5.7%, 4.0%, and 5.5% respectively. This algorithm significantly enhances the recognition robustness of transparent extraction tubes in complex environments, providing an effective visual recognition solution for the intelligent upgrade of experiments.

Key words: improved YOLOv8n algorithm; extraction tube detection; deep learning

0 引言

在科学研究和工业生产中, 萃取实验是一项至关重要的操作, 而透明萃取管作为萃取实验中不可或缺的工具, 对其准确识别对于实验的自动化和智能化技术升级具有重要意义。当前萃取实验主要依赖人工与机械设备: 前者精度高但效率低、成本高;

后者效率提升, 但精度不足、且智能化程度有限。因此, 实现透明萃取管的自动化视觉识别成为推动实验智能化的关键环节。

近年来, 随着机器视觉技术的飞速发展, 目标检测算法在各个领域得到了广泛应用。其中, YOLO^[1] 系列算法以其高效、准确的特点, 成为目标检测领域的研究热点。YOLOv8^[2] 作为 Ultralytics 公

基金项目: 国家自然科学基金 (52205604)。

作者简介: 杨平江 (2001—), 男, 硕士研究生, 主要研究方向: 机器人, 机器视觉。

通信作者: 周吴 (1981—), 男, 博士, 教授, 主要研究方向: MEMS 微镜, MEMS 惯性传感器, 精密光电检测等。Email: zhouwu916@uestc.edu.cn。

收稿日期: 2025-08-29

司推出的单阶段目标检测算法,在图像分类、物体检测和实例分割等任务中表现出色。

董沛君^[3]通过目标检测算法的研究对比,优选出检测效果较好的 YOLOv3 算法,并根据实际需求在其网络上进行优化改进,设计出一种适用于本试管识别场景的目标检测网络。刘石坚等学者^[4]提出一种基于深度学习的试管-支架系统 Data Matrix 码识别方法 DeepDMCode,以 Mask R-CNN 模型为基础,通过内容差异化数据合成和同步自动化标注,实现训练数据的增强,提升模型的学习能力。张广志等学者^[5]提出一种无监督领域自适应的表面缺陷检测算法,来解决采集时管状容器表面缺陷图像,图像容易因环境因素发生变化,导致采集图像特征与算法训练图像特征不一致等问题。

然而现有的目标检测算法在萃取管识别的准确性和鲁棒性方面仍存在一定的不足。为了解决上述问题,本文提出了一种改进的 YOLOv8n 模型算法。

1 萃取管目标检测方法

1.1 改进的 YOLOv8 算法模型

为了提高对萃取管的实时准确检测,本文在 YOLOv8n 模型的主干网络引入 DynamicConv 模块替换原有的 Conv 模块,在 DynamicConv 模块中引入了一种名为 ParameterNet 设计原则,能在大规模视觉预训练模型中增加参数数量,同时尽量不增加浮点运算^[6],从而提高对萃取管的实时检测的准确性;在 SPPF 模块后增加一层 LSKAttention 机制,LSKAttention 在处理图像关键特征(如边缘、纹理和形状时),LSKAttention 能够有效地捕捉到重要信息^[7],增加对萃取管的形状特征提取;在检测头部分,把自适应空间特征融合(ASFF)与 Detect 融合成 ASFF_Detect 模块^[8],从而提高萃取管的特征尺度不变性。改进的 YOLOv8n 模型网络架构如图 1 所示。

1.2 DynamicConv 模块

由于萃取管的管身通常为透明的材料,易受背景环境的影响,难以区分萃取管和背景环境之间的特征,进而导致模型无法有效准确地辨别和提取萃取管特征。为此本文引入 DynamicConv 模块,在尽量不增加浮点运算的同时增加模型参数数量,从而提高模型对萃取管的识别精度,增加对背景环境的鲁棒性。

在具体实现上,给定输入特征 $X \in R^{C_{in} \times H \times W}$ 和权重 $W \in R^{C_{out} \times C_{in} \times K \times K}$,传统卷积层数学公式具体如下:

$$Y = X * W \quad (1)$$

其中, $Y \in R^{C_{out} \times H' \times W'}$ 表示卷积的输出层,全连接层可以视为卷积核大小为 1×1 的卷积层。

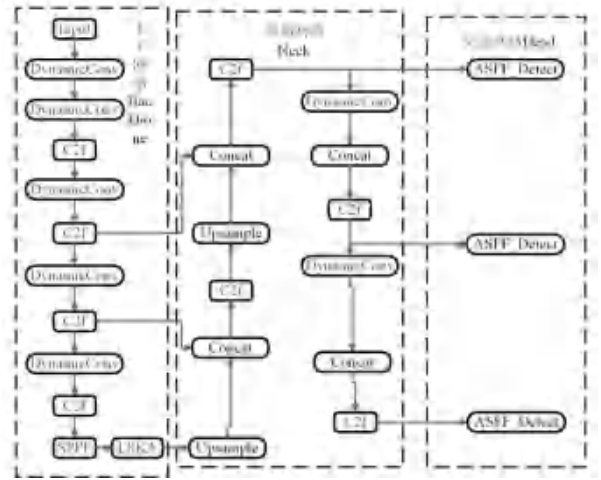


图 1 改进的 YOLOv8n 网络架构

Fig. 1 Improved YOLOv8n network architecture

DynamicConv 模块引入增强函数,来增加模型的参数数量,对此可以表示为:

$$W' = f(W) \quad (2)$$

其中, W 表示原权重张量; f 表示参数增强函数; W' 表示增加后的权重张量。增强函数满足 2 个基本规则:计算成本适中,大幅增加模型容量或可训练参数。

DynamicConv 包含 M 个动态专家^[9],研究推得的公式如下:

$$Y = X * W' \quad (3)$$

$$W' = \sum_{i=1}^M \alpha_i W_i \quad (4)$$

其中, $W_i \in R^{C_{out} \times C_{in} \times H \times W}$ 表示第 i 个卷积权重张量, α_i 表示相应的动态系数。系数 α_i 是根据不同的输入样本动态生成的,通常方法是使用 MLP 模块基于输入生成。对于输入 X ,应用全局平均池化将信息融合成向量^[10],然后使用带有 Softmax 激活函数的 2 层 MLP 模块动态生成系数,用到的公式为:

$$\alpha = \text{Softmax}(\text{MLP}(\text{Pool}(X))) \quad (5)$$

其中, $\alpha \in R^M$ 表示动态生成的系数向量。

本文使用 DynamicConv 替换主干网络中的 Conv 下采样模块,从而使模型的参数数量增加,提高对萃取管的识别准确性。DynamicConv 结构如图 2 所示。

1.3 LSKA 注意力机制

萃取管使用时背景环境复杂多变,为了提高模

型对透明管状的关键特征的提取, 本文在主干网络结构中加入 LSKA 注意力机制, LSKA 注意力机制的结构如图 3 所示。

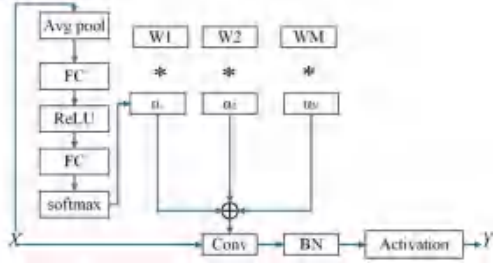


图 2 DynamicConv 结构图

Fig. 2 DynamicConv structure diagram




图 3 LSKA 注意力机制结构图

Fig. 3 LSKA attention mechanism structure diagram

该模块通过扩大卷积核的感受野, 更关注目标的整体形状特征^[11], 从而弱化背景纹理和颜色相近性对萃取管检测结果的干扰。

LSKA 将 $k \times k$ 的大卷积核分解成 $(2d - 1) \times (2d - 1)$ 的深度卷积、 $k/d \times k/d$ 的深度扩张卷积和 1×1 的卷积。将深度卷积和深度扩张卷积分解为横向和纵向 2 个层次, 最后通过连接卷积核来构建完整的网络构架^[12]。给定一个输入特征图 $F \in R^{C \times H \times W}$, 经过 LSKA 结构其输出为:

$$\bar{Z}^C = \sum_{H,W} W_{(2d-1) \times 1}^C * \left(\sum_{H,W} W_{1 \times (2d-1)}^C * F^C \right) \quad (6)$$

$$Z^C = \sum_{H,W} W_{\lfloor k/d \rfloor \times 1}^C * \left(\sum_{H,W} W_{1 \times \lfloor k/d \rfloor}^C * \bar{Z}^C \right) \quad (7)$$

$$A^C = W_{1 \times 1} * Z^C \quad (8)$$

$$\bar{F}^C = A^C \otimes F^C \quad (9)$$

其中, “*” 和 “ \otimes ” 分别表示卷积和哈达玛积; \bar{Z}^C 表示深度卷积的输出, 卷积核大小为 $(2d - 1) \times (2d - 1)$; $\sum_{H,W}$ 表示对高度 (H) 和宽度 (W) 求和; F^C 表示输入特征图; $W_{(2d-1) \times 1}^C$ 和 $W_{1 \times (2d-1)}^C$ 分别表示大小为 $(2d - 1) \times (2d - 1)$ 的卷积核; Z^C 表示中间计算结果; $W_{\lfloor k/d \rfloor \times 1}^C$ 和 $W_{1 \times \lfloor k/d \rfloor}^C$ 分别表示 $\lfloor k/d \rfloor \times 1$ 和 $1 \times \lfloor k/d \rfloor$ 的卷积核; “ $\lfloor \cdot \rfloor$ ” 表示向上取整; A^C 表示注意力权重图; $W_{1 \times 1}$ 表示 1×1 的卷积核; \bar{F}^C 表示输出特征图。

1.4 Detect_ASFF 模块

YOLOv8 的颈部采用改进的路径聚合网络-特征金字塔网络 (PAN-FPN) 结构, 优化了上采样阶段

的特征融合效率, 但多尺度特征融合可能导致信息冲突和不一致性。在萃取实验操作时, 实验物品种类繁多, 待检测的萃取管会存在光线变化与实验物品相互遮挡等因素导致萃取管的轮廓模糊、尺度差异和部分特征缺失的情况。在检测头部分引入自适应空间特征融合 (Adaptively Spatial Feature Fusion, ASFF) 策略, 通过空间过滤冲突信息以压制不一致性, 从而提高特征的尺度不变性。ASFF 结构如图 4 所示。图 4 中, Level 1、Level 2 和 Level 3 代表特征金字塔中不同层级的特征, 并且不同层级有不同的分辨率, 经过特征融合得到 ASFF-1、ASFF-2 和 ASFF-3 这 3 个 ASFF 层。




图 4 ASFF 结构图

Fig. 4 ASFF structure diagram

ASFF 策略的核心思想是自适应地学习每个尺度下特征图的融合空间权重, 包括 2 个步骤: 特征尺度调整与自适应权重融合。

(1) 特征尺度调整: 由于 YOLOv8n 中 3 个层级的特征具有不同的分辨率和通道数, 因此要修改每个尺度的上采样和下采样策略。对于上采样, 首先应用一个 1×1 卷积层来压缩特征的通道数至第 l 层的通道数, 然后通过插值分别提升分辨率^[13-18]。对于 $1/2$ 比例的下采样, 简单地使用一个步长为 2 的 3×3 卷积层同时改变通道数和分辨率。对于 $1/4$ 的比例, 在 2 步长卷积前添加一个 2 步长的最大池化层。

(2) 自适应权重融合: 融合的过程就是把特征尺度调整后的特征图与其对应的权重参数矩阵相乘, 对应元素值以相加的方式得到, 计算过程为:

$$\gamma_{ij}^l = \alpha_{ij}^l \cdot x_{ij}^{1 \rightarrow l} + \beta_{ij}^l \cdot x_{ij}^{2 \rightarrow l} + \gamma_{ij}^l \cdot x_{ij}^{3 \rightarrow l} \quad (10)$$

其中, $x_{ij}^{1 \rightarrow l}$ 表示从 1 层映射到 l 层在 (i, j) 位置上的特征向量; α_{ij}^l 、 β_{ij}^l 和 γ_{ij}^l 分别表示网络在 3 个不同层级 l 下特征图的空间重要性权重, 这些权重由网络自适应学习得出; α_{ij}^l 、 β_{ij}^l 和 γ_{ij}^l 表示简单的标量变量, 在所有通道中共享^[12], 还满足下列关系:

$$\alpha_{ij}^l + \beta_{ij}^l + \gamma_{ij}^l = 1 \quad (11)$$

$$\alpha_{ij}^l = \frac{e^{\lambda_{\alpha_{ij}}^l}}{e^{\lambda_{\alpha_{ij}}^l} + e^{\lambda_{\beta_{ij}}^l} + e^{\lambda_{\gamma_{ij}}^l}} \quad (12)$$


其中,对 $x^{1-l}, x^{2-l}, x^{3-l}$ 进行特征缩放操作后的3个特征图层使用 1×1 的卷积计算得到 $\lambda_{\alpha_{ij}}^l, \lambda_{\beta_{ij}}^l, \lambda_{\gamma_{ij}}^l$ 。

把 ASFF 策略引入到检测头部分,使用了自适应地学习每个尺度下特征图的融合空间权重思想。

2 实验与分析

2.1 数据集的建立

萃取管图像来自西华大学化学实验室,使用智能手机在自然光照下拍摄,图像格式以 jpg 保存,经过图像预处理后,共采集到 2 000 多张萃取管图像,随机划分为训练集、验证集和测试集,其分配比例为 7:2:1。将图像统一压缩成 640×640 ,然后使用 Labelme 软件进行标注如图 5 所示,获得原始数据。



(a) 标记前图片



(b) 标记后的图片

图 5 使用 Labelme 软件进行图像标注

Fig. 5 Image labeling using Labelme software

2.2 实验运行环境

本实验是在 Win 11 操作系统下进行,处理器为 Intel(R) Core(TM) i7-14650HX 2.20 GHz,图像处理器为 NVIDIA GeForce RTX 4060 (8 G),IDE 为 PyCharm2024,编程语言采用 Python 3.8,PyTorch 2.4.1 作为深度学习模型的框架,采用 CUDA12.2 对 GPU 进行优化。模型训练周期为 200,输入图像的尺寸为 640×640 ,每次训练 8 张图像,采用 SGD 优化器,学习率为 0.01,其余为模型默认参数。

2.3 评估指标

本文实验的评价指标为:准确率 (Precision, P)、召回率 (Recall, R)、平均精度 (mean Average

Precision, mAP)。

(1) Precision。是指检测出正确目标数与所有检测出目标数之比。定义公式如下:

$$P = \frac{T_p}{T_p + F_p} \quad (13)$$

其中, T_p 表示正确检测到物体数量; F_p 表示错误检测到的物体数量。

(2) Recall。是真实检测到的目标数与所有实际目标数之比。定义公式如下:

$$R = \frac{T_p}{T_p + F_N} \quad (14)$$

其中, F_N 表示错误检测为非物体的数量。

(3) AP。研究可知,精确率越高表明算法误检率低,召回率越高则漏检率越低。由于精确率和召回率是成反比的,引入纵坐标 P 和横坐标 R 的 n 个不同点围成的曲线面积 AP,来比较算法对每个类别识别的好坏程度。定义公式如下:

$$AP = \int_0^1 P(R) dR \quad (15)$$

(4) mAP。是所有类别 AP 的平均值,用于表示算法的综合检测精度。定义公式如下:

$$mAP = \frac{\sum_{i=1}^k AP_i}{k} \quad (16)$$

2.4 消融实验

为证明本论文研究的改进点的可效性,基于 YOLOv8n 模型做消融实验,分别引入 DynamicConv 模块、LSKA 注意力机制以及 Detect_ASFF 模块,研究不同模块和机制对萃取管检测的影响。将标注完的萃取管数据集分别输入 YOLOv8n、YOLOv8n + DynamicConv、YOLOv8n + LSKA、YOLOv8n + Detect_ASFF、YOLOv8n + DynamicConv + LSKA、YOLOv8n + DynamicConv + LSKA + Detect_ASFF 模型,结果见表 1。

在 YOLOv8n 中加入 DynamicConv 模块后,通过增强权重参数化能力, Precision 提升 2.4%、mAP50 提升 2.1%,但 Recall 降低 1.8%,表明其对复杂背景鲁棒性的优化需结合其他模块以平衡漏检率。研究在加入 LSKA 注意力机制后,大感受野注意力机制对关键形状特征提取效果显著,使 Precision 提升 3.9%,mAP50 提升 2.9%,但单独使用会抑制部分细节特征。加入 Detect_ASFF 模块后,自适应空间融合策略有效提升多尺度特征一致性,mAP50 增加 2.6%、且参数量增幅最小,验证其对尺度变化的适应性。

表1 消融实验结果

Table 1 Ablation research results

序号	DynamicConv	LSKA	Detect_ASFF	P/ %	C/ %	mAP50/ %	Params/10 ⁶
1				88.1	86.8	89.3	2.6
2	√			90.5	85.0	91.4	4.4
3		√		92.0	84.2	92.2	3.3
4			√	90.1	85.4	91.9	2.9
5	√	√		92.2	89.0	92.6	4.8
6	√	√	√	93.8	90.8	94.8	5.2

本模型在 mAP50 达 94.8%,表明综合改进显著提升检测鲁棒性;Recall 提升至 90.8%,优化了单一模块的漏检问题;Precision 提升至 93.8%,验证算法对误检的有效抑制。最终模型参数量增至 5.2 M,但 mAP50 显著提升 5.5%,证明其计算成本合理。尤其针对萃取管在复杂环境中的检测需求,参数量的增加对精度增益具有正向边际效应。

2.5 对比实验

将本模型与 YOLOv5s^[19]、YOLOv8n, YOLOv10s^[20]、YOLOv11^[21] 进行性能实验对比,实验结果见表 2。本模型的 mAP50(94.8%)远高于其对比的 YOLOv5s(88.8%)、原始 YOLOv8n(89.3%)、YOLOv10s(91.1%)和 YOLOv11(91.2%)等主流模型。相比 YOLOv8n 所得的 5.5%的提升证明了其引入的 DynamicConv、LSKA 和 ASFF 模块在复杂背景下提升萃取管识别精度的有效性。本模型不仅在精度(P, 93.8%)上比对比实验中的主流模型高,召回率(R, 90.8%)也达到了对比模型中的最高值。这解决了单一模块改进时可能出现的精度提升、但召回率下降的矛盾,表明其综合检测能力(查得全、查得准)最优。

表2 对比实验结果

Table 2 Comparative experimental results

模型	P/ %	C/ %	mAP50/ %	Params/10 ⁶
YOLOv5s ^[19]	88.6	82.1	88.8	2.2
YOLOv8n	88.1	86.8	89.3	2.6
YOLOv10s ^[20]	91.9	89.2	91.1	3.5
YOLOv11 ^[21]	89.3	84.3	91.2	3.3
本文模型	93.8	90.8	94.8	5.2

利用 D435C 深度相机对实时的萃取管进行目标识别实验。先将相机固定在同一位置,确保每次识别的图像不发生变化。利用训练完成的 YOLOv5s^[19](88.8%)、原始 YOLOv8n(89.3%)、YOLOv10s^[20](91.1%)和 YOLO11^[21](91.2%)等主

流模型,与本模型进行对比,对比结果如图 6 所示。图 6 中,只有本模型和 YOLOv11 识别出萃取管和萃取管盖,而其他模型只识别出萃取盖,另外本模型在识别萃取管的精度上高于 YOLO11 模型。




图6 实时萃取管的识别对比实验图

Fig. 6 Comparative experiment diagram of real-time extraction tube recognition

3 结束语

本文提出了一种改进的 YOLOv8n 模型算法。该模型算法在萃取管识别检测任务中与原 YOLOV8n 模型相比在准确率(Precision, P)上提升了 5.7%,从 88.1%提升到 93.8%,召回率(Recall, R)提升了 4%,从 86.8%提升到 90.8%,平均精度(Mean Average Precision, mAP50)提升了 5.5%,从 89.3%提升到 94.8%。该模型为萃取管在复杂环境下的检测提供了鲁棒性更强的解决方案,为实验自动化系统的视觉识别模块提供了可靠的技术支撑。

未来可进一步探索轻量化部署及多模态信息融

合的应用拓展。

参考文献

- [1] 张科, 彭远刚, 王跃明, 等. 基于改进 YOLOv8 的试管及液位识别算法[J]. 计算机应用, 2024, 44(S2):296-301.
- [2] VARGHESE R, SAMBATH M. YOLOv8: A novel object detection algorithm with enhanced performance and robustness [C]//Proceedings of 2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS). Piscataway, NJ;IEEE, 2024:1-6.
- [3] 董沛君. 基于机器视觉的试管识别系统研究与实现[D]. 成都: 四川大学, 2021.
- [4] 刘石坚, 林锦嘉, 陈梓灿, 等. 基于 Mask R-CNN 的试管-支架系统 Data Matrix 码识别方法[J]. 福建工程学院学报, 2023, 21(4):378-384.
- [5] 张广志, 李慧敏, 宋旭宁. 无监督领域自适应的管状容器表面缺陷检测[J]. 激光与光电子学进展, 2025, 62(2):155-165.
- [6] 孟志永, 贾雅微, 张秀清, 等. 基于 WAAP-YOLO 的玉米伴生杂草检测模型[J]. 河北科技大学学报, 2025, 46(4): 386-394.
- [7] HAN Kai, WANG Yuche, GUO Jianyuan, et al. ParameterNet: Parameters are all you need for large-scale visual pretraining of mobile networks[C]//Proceedings of 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ;IEEE,2024: 15751-15761.
- [8] LAU K W, PO L M, REHMAN Y A U. Large separable Kernel attention: Rethinking the large kernel attention design in CNN[J]. Expert Systems with Application, 2024, 236:121352.
- [9] LIU Songtao, HUANG Di, WANG Yunhong. Learning spatial fusion for single-shot object detection[J]. arXiv preprint arXiv, 1911. 09516, 2019.
- [10] 夏顺兴, 倪铭, 罗友璐, 等. 基于改进 YOLOv8n 的草莓叶片病害检测方法[J]. 江苏农业学报, 2025, 41(4):664-675.
- [11] 姚宏志, 王柯, 王玉笛, 等. 基于改进 YOLOv8n 的水稻籽粒检测模型[J/OL]. 重庆工商大学学报(自然科学版). [2025-01-14]. <https://link.cnki.net/urlid/50.1155.N.20250114.1152.002>.
- [12] 仲元昌, 陈宇, 杨子楚, 等. 面向小型无人机检测应用的改进 YOLOv8 算法[J]. 湖南大学学报(自然科学版), 2025, 52(4):57-67.
- [13] 侯志明. 基于改进 YOLOv8 的既有砌体裂缝检测方法[J/OL]. 重庆工商大学学报(自然科学版). [2025-05-12]. <https://link.cnki.net/urlid/50.1155.N.20250512.1107.002>.
- [14] 鹿明明, 邱威, 杨岑岑, 等. 基于改进 YOLOv8 的水轮机转轮叶片裂纹及气蚀缺陷识别方法[J]. 水电能源科学, 2025, 43(6):189-193.
- [15] 陈汝熠, 闫河, 王艳, 等. SLAW-YOLOv8:一种密集行人检测方法[J]. 小型微型计算机系统, 2025, 46(12):2941-2948.
- [16] 唐鸿宇, 卜登立, 莫冠豪, 等. DBW-YOLO:改进 YOLOv8n 的 PCB 表面缺陷检测方法[J/OL]. 广西科技大学学报. [2025-06-19]. <https://link.cnki.net/urlid/45.1395.T.20250619.0813.002>.
- [17] 朱之健, 范必双, 杨涯文, 等. 基于 MSRCP 图像增强与改进 YOLOv8 的臂章布料瑕疵识别方法[J]. 智能计算机与应用, 2025, 15(8):90-97.
- [18] 吕其修, 钱朝阳, 沈辉. 基于改进 YOLOv5 的地铁车厢乘客检测算法研究[J]. 智能计算机与应用, 2025, 15(8):167-172.
- [19] 李敏杰, 赵研科, 马婕, 等. 基于改进型 YOLOv5s 的荷塘作物的快速检测[J]. 拖拉机与农用运输车, 2025, 52(3):108-114.
- [20] WANG Ao, CHEN Hui, LIU Lihao, et al. YOLOv10: Real-time end-to-end object detection[J]. arXiv preprint arXiv, 2405.14458, 2024.
- [21] KHANAM R, HUSSAIN M. YOLOv11: An overview of the key architectural enhancements [J]. arXiv preprint arXiv, 2410.17725, 2024.