光电技术及应用

DOI：10.16818/j.issn1001－5868.20250823002

# 基于YOLOv11n的轻量化石英坩埚内壁缺陷检测算法

黄晶晶[1]，宋宇辉[2*]，赵　谦[3]

（1. 江苏双良低碳产业技术研究院有限公司，江苏 无锡 214400；2. 西安科技大学 通信与信息工程学院，西安 71000；3. 西安地山视聚科技有限公司，西安 712044）

**摘　要：** 针对传统人工检测方法对石英坩埚质检主观性强、误检率高，文章提出一种基于YOLOv11n的轻量化缺陷检测模型MCS-YOLO。首先，在YOLOv11n基础上采用多尺度卷积模块设计全新的C3k2结构，以提升对微小缺陷的感知精度；其次，在颈部网络中嵌入卷积块注意力模块，引导网络聚焦于关键缺陷区域；最后，采用SCYLLA-IoU（SIoU）边界框损失函数优化回归路径，提升目标定位性能。实验结果表明，该算法在自建石英坩埚数据集上平均精度均值达到92.7%，较基准模型提升3.4%，参数量为3.02 M，计算量为7.26 GFLOPs，权重仅为6.30 MB，兼具高精度、轻量化与高鲁棒性，适合应用于工业检测场景。

**关键词：** 石英坩埚；深度学习；YOLOv11n；缺陷检测；注意力机制

**中图分类号：** TP391.41　**文章编号：** 1001－5868(2025)06－1079－09

## Lightweight Defect Detection Algorithm for Quartz Crucible Inner Walls Based on YOLOv11n

HUANG Jingjing[1], SONG Yuhui[2], ZHAO Qian[3]

(1. Jiangsu Shuangliang Low - Carbon Industrial Technology Research Institute Co., Ltd., Wuxi 214400, CHN; 2. School of Communication and Information Engineering, Xi'an University of Science and Technology, Xi'an 710000, CHN; 3. Xi'an Dishan Vision Technology Limited Company, Xi'an 712044, CHN)

**Abstract:** To address the problems of strong subjectivity and high false positive rate in the traditional manual inspection method for quartz crucible quality inspection, a lightweight defect detection model MCS-YOLO based on YOLOv11n is proposed. First, the C3k2 structure is designed on the basis of YOLOv11n, which adopts the multi-scale convolution module (MSCB) to improve the perception accuracy of tiny defects. Second, the convolutional block attention module (CBAM) is embedded into the neck network to guide the network to focus on key defect areas. Finally, the SCYLLA-intersection over union (SIoU) bounding box loss function is used to optimize the regression path and improve target positioning performance. Experimental results show that the algorithm achieves a mAP@0.5 of 92.7% on the self-built quartz crucible dataset, which is 3.4% higher than that of the baseline model. With 3.02 M parameters requiring 7.26 GFLOPs of calculation and a weight of only 6.30 MB, the model features high precision, lightweight performance, and strong robustness, making it suitable for applications in industrial detection scenarios.

**收稿日期：**2025－08－23.

**基金项目：**陕西省科技成果转化计划-百项科技成果转化行动项目(2023-YD-CGZH-29)；陕西秦创原"科学家＋工程师"队伍建设项目(S2023-YF-LLRH-QCYK-0271)；西安市科技计划(科学家＋工程师队伍建设项目)(24KGDW0030).

* **通信作者：**宋宇辉

**Key words**: quartz crucible; deep learning; YOLOv11n; defect detection; attention mechanism

## 0 引言

随着半导体、光伏以及光电子材料的迅猛发展,单晶硅材料作为核心载体被广泛应用于晶圆制造和太阳能电池片制备中[1-2]。在单晶硅生长过程中,石英坩埚作为关键耗材,其内壁表面质量直接影响硅晶体的生长质量[3]。然而,目前国内多数石英坩埚制造企业仍依赖人工目视检测对石英坩埚内壁缺陷进行分类与分级,这种方式检测效率低、主观性强,易导致误检、漏检。

随着机器视觉的发展,基于深度学习的智能检测逐步成为突破传统人工的关键引擎,目标检测作为机器视觉领域的核心任务已在多个应用场景中展现出显著潜力[4-5]。刘传洋等[6]对航拍图像的绝缘子缺陷检测方法进行了系统梳理,发现深度卷积网络和目标检测框架在复杂户外场景的设备缺陷识别中同样展现出良好应用前景。谭鑫平等[7]在原始YOLOv5神经网络模型基础上加入空域图像增强模块,提高了模型的特征提取能力和细胞检测准确率。Cen[8]结合卷积神经网络(CNN)与循环神经网络(RNN)设计了改进型R-FCN结构,提升移动机器人多模态目标检测性能,展示出对时序与音频特征的整合潜力。杨志锐等[9]提出一种基于网中网卷积神经网络的红枣缺陷检测方法,通过加入1×1卷积层和改进的网络架构,在提高精度的同时显著降低了计算量。Xu等[10]提出的FAR-Net网络通过引入特征级注意力和标签间关系学习机制,在多标签缺陷数据集上展现了较传统方法更优的性能。Lin等[11]提出Focal Loss损失函数,缓解密集目标检测中类别不平衡问题,显著增强了RetinaNet的精度与鲁棒性。任晶晶等[12]提出的基于双层优化元学习的域自适应方法,通过针对不同数据集和目标任务的优化策略,提升了红枣缺陷检测模型在多域间的适应性。在轻量化检测方面,Tan等[13]设计的EfficientDet通过复合尺度策略和BiFPN结构兼顾效率与精度,为资源受限环境下的部署提供了新的解决方案。赵嘉伟等[14]在YOLOv4基础上引入MobileNetV3和CBAM注意力机制,实现马铃薯田间杂草的高速高精识别。进一步,Wang等[15]提出YOLOv7,通过Bag-of-Freebies策略在不增加推理成本的情况下实现速度与精度的双重突破。喻擎苍等[16]针对柑橘瓣外观检测提出YOLOv7-VSS,结合EfficientViT和Slim-neck结构实现模型压缩与精度平衡。代少升等[17]在YOLOv8的基础上提出一种高精度盲区目标检测算法,采用尺度序列特征融合模块(SSFF)融合图像多个尺度的深层语义信息。Xu等[18]提出面向小样本场景的SDD-CNN网络,通过标签膨胀与半监督数据增强策略实现滚动轴承微小表面缺陷的高精度识别。Ju等[19]则构建了基于迁移学习的SE-ResNet50-CL模型,在小样本数据集上实现了较高的分类精度。这些研究为视觉检测任务的性能提升提供了诸多有益思路。

然而,将目标检测算法应用于石英坩埚内壁缺陷检测任务仍面临一定挑战。该任务缺陷目标尺寸小、边界模糊、与背景纹理相似度高,且现有轻量化检测算法尚未在该领域得到广泛验证,仍需进一步设计适用于石英坩埚缺陷特性的检测网络,提高检测的准确性和鲁棒性。

为此,本文在YOLOv11n基础上提出轻量化缺陷检测模型MCS-YOLO,引入多尺度卷积模块(MSCB)构建C3k2-MSCB模块增强微小缺陷感知能力;嵌入卷积块注意力模块(CBAM),提升特征提取精度;采用SCYLLA-IoU(SIoU)损失函数,优化回归路径,提升定位性能。所提出模型在保持轻量化的同时,实现了内壁缺陷检测精度与鲁棒性的双提升。

## 1 YOLOv11模型

YOLOv11是Ultralytics公司于2024年下半年推出的最新一代YOLO模型,在物体检测、姿态估计和分类等多项任务中展现了先进的性能。作为YOLO系列新一代版本,YOLOv11在YOLOv8的基础上进行了多维度的架构优化与模块升级,进一步提升了特征提取能力、轻量化水平与复杂场景适应性,其网络结构如图1所示。

YOLOv11在YOLOv8基础上进行了多维度的架构优化。其主干网络(Backbone)引入了增强浅层特征提取效率的C3k2模块和集成多头注意力机制的C2PSA模块,后者被嵌入SPPF层后以提升复杂场景下的特征融合能力。颈部网络(Neck)延续

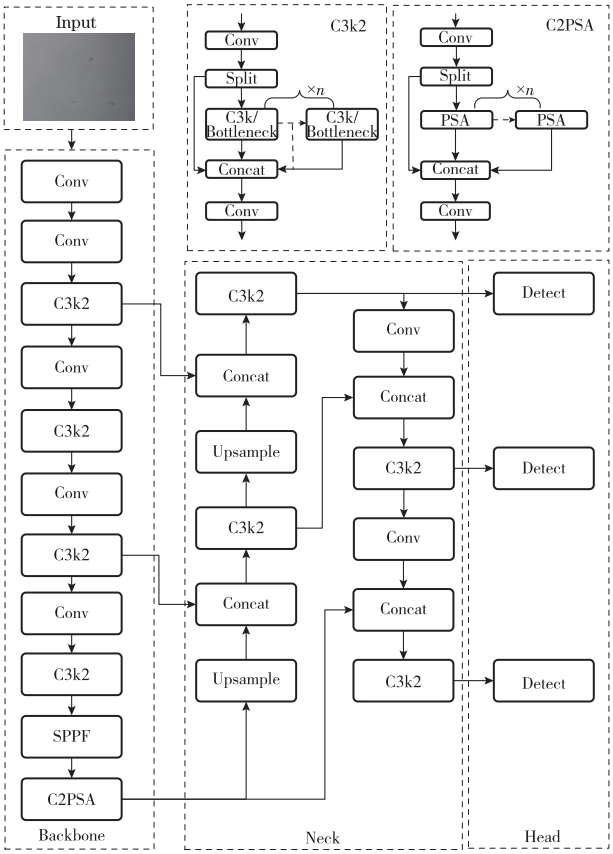



图1　YOLOv11网络结构

PAN结构但采用C3k2模块替代C2f模块，以优化跨尺度特征聚合。头部网络（Head）采用解耦头设计，其分类分支使用深度可分离卷积（DWConv）替代常规卷积以显著降低计算量与参数量，并通过调整网络深度与宽度增强复杂环境鲁棒性。此外，延续了多尺度（n/s/m/l/x）设计策略，其中YOLOv11n计算量最小、推理速度快且准确度较高，本文在此模型的基础上进行了改进。

## 2　MCS-YOLO模型

为进一步提升YOLOv11在石英坩埚内胆缺陷检测任务中的精度与鲁棒性，在YOLOv11n模型的基础上提出改进模型MCS-YOLO。首先，在Backbone中，将MSCB嵌入C3k2结构，以增强网络对多尺度纹理特征的感知能力；其次，在Neck结构中引入CBAM，联合通道与空间注意力，有效提升特征融合阶段对缺陷区域的响应强度；最后，使用SIoU损失函数替代原始模型损失函数（CIoU），进一步优化边界框回归过程的收敛速度与定位精度。改进模型结构如图2所示。

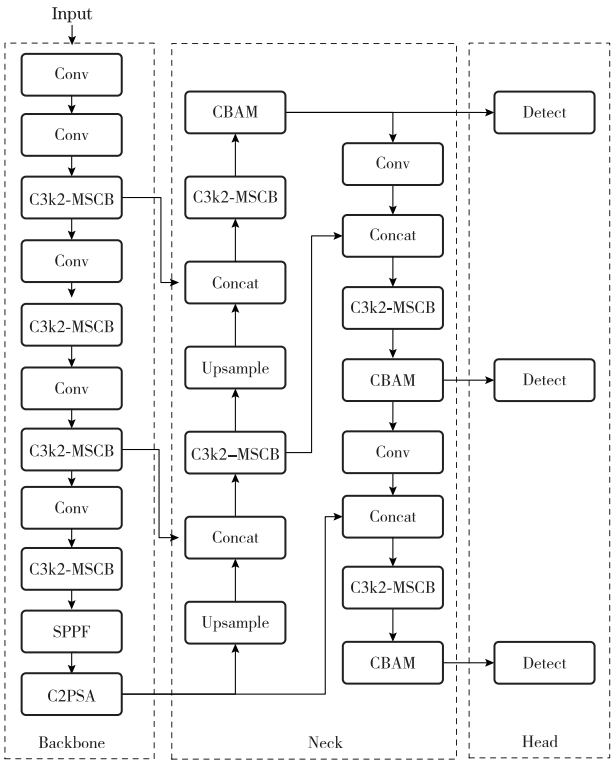



图2　MCS-YOLO网络结构

### 2.1　C3k2-MSCB模块

YOLOv11模型Backbone中所采用的C3k2结构在提升浅层特征提取效率的同时，通过Bottleneck模块引导深层特征融合，在大多数目标检测任务中已展现出良好的性能。然而，该模块对多尺度特征的建模能力仍存在局限，Xu等[20]提出的MSF-Net通过构建双模块特征提取器（DMF），在网络中显式增强多尺度感受野与特征融合能力，验证了多尺度特征学习对于跨尺度缺陷识别的重要性。当面对尺寸变化显著的石英坩埚内壁缺陷时，容易出现特征响应不充分、漏检等问题。现有多尺度特征融合方法包括特征金字塔网络（FPN）、双向特征金字塔（BiFPN）和自适应空间特征融合（ASFF）等，以FPN为例，其跨层融合过程可表示为：

$$F_l = \mathrm{Conv}\left(U(F_{l+1}) + F_l\right) \tag{1}$$

式中，$F_l$表示第$l$层特征，$U(\cdot)$表示上采样操作，Conv(·)为卷积变换。该结构通过上采样高层特征并与当前层特征融合，从而增强了多尺度特征表达能力。然而，由于下采样/上采样操作本质上相当于低通滤波，其频率响应会削弱高频分量，导致对石英坩埚微小缺陷的响应不足。此外，尽管多层卷积堆叠有助于扩大感受野，但往往会带来较大的计算量与参数量，不利于轻量化部署。

MSCB是一种融合多尺度感受野的信息增强模块[21]。该模块通过并联三组不同核大小($k$=p, q, s)的深度可分离卷积(DWConv)进行多尺度特征提取,以增强特征图的感受野,实现局部细节与全局语义的协同表达。令MSCB并行采用核集$\{k_b\}$,则并联结构的感受野为:

$$RF_{\mathrm{MSCB}}=\max_{b} k_b \tag{2}$$

式中,$k_b$表示第$b$个卷积分支的卷积核大小,$RF_{\mathrm{MSCB}}$表示并联结构整体的有效感受野。MSCB能在单层结构中实现较大的感受野,对跨尺度特征特别是微小缺陷的表征更加充分。

MSCB采用DWConv结合逐分支1×1卷积进行降维,各分支特征在通道维度上拼接后,再通过1×1卷积进行融合,整体参数量为:

$$P_{\mathrm{MSCB}}=C_{\mathrm{in}}\sum_{b=1}^{B}k_b^2+BrC_{\mathrm{in}}^2+(BrC_{\mathrm{in}})C_{\mathrm{out}} \tag{3}$$

标准卷积参数量为:

$$P_{\mathrm{std}}=C_{\mathrm{out}}C_{\mathrm{in}}k^2 \tag{4}$$

式中,$C_{\mathrm{in}}$表示输入通道数,$C_{\mathrm{out}}$表示输出通道数,$B$为并行分支数,$r$为分支降维比。与标准卷积相比,若MSCB配置输入与输出通道数为64,3个并行分支,卷积核大小分别取3,5,7,分支降维比为0.25,仅需约11 456个参数,而标准3×3卷积需36 864个参数,计算量相差约3.2倍。

因此,MSCB在轻量化的同时实现了跨尺度感受野的扩展,更加契合石英坩埚缺陷检测中尺寸跨度大、边界模糊的特征。

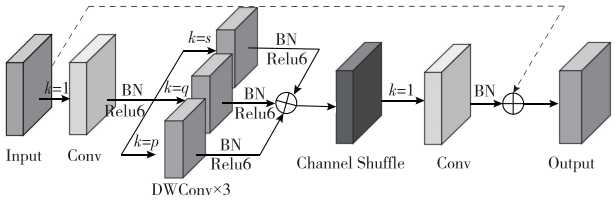



图3 MSCB结构

在C3k2模块基础上进行结构改进,依据MSCB结构设计C3k2-MSCB模块,其结构如图4所示。C3k2模块通过设定参数C3k=True/False控制其内部结构差异:当C3k为True时,C3k2中嵌套多个C3k子模块以实现分组残差学习;而当为False时,则采用传统Bottleneck结构对主干特征进行提取。尽管两者均提升了特征表达能力,但对坩埚内壁缺陷尺度变异显著的微小缺陷仍存在感受野受限、语义聚合不足的问题。基于此,分别在上述两种结构下引入多尺度卷积机制。具体而言,当C3k=True时,将原始C3k子模块替换为改进的C3k-MSCB子模块,该模块在主路径上串联两组MSCB块,同时引入跨通道残差连接以保持梯度流稳定性;当C3k=False时,则直接用标准MSCB替代原Bottleneck模块,以更高的特征尺度响应能力提取多粒度信息。与传统Bottleneck相比,MSCB可在不显著增加计算负担的前提下有效补足单尺度卷积对部分细节缺陷的建模盲区。

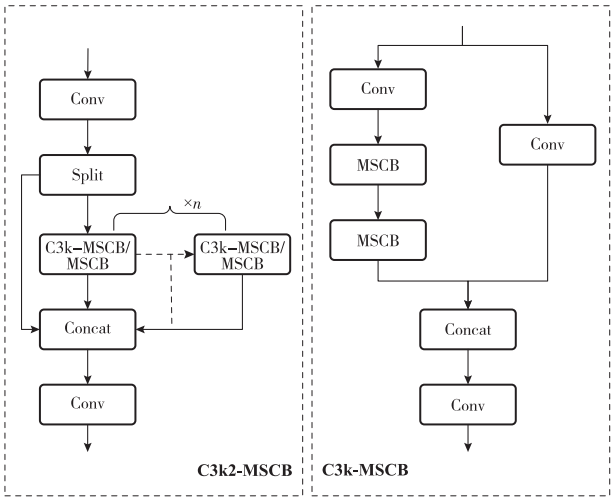



图4 改进C3k2结构

## 2.2 CBAM模块

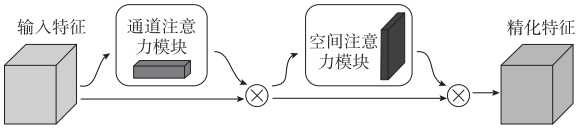
Woo等[22]提出的CBAM模块由通道注意力(CA)与空间注意力(SA)两个子模块串联组成,能够在轻量代价下实现特征图的自适应增强,已被证实能有效提升分类与检测性能。

考虑到石英坩埚内壁缺陷图像中常伴随模糊边界、灰度干扰与背景纹理干扰等因素,而传统特征融合过程易出现关键信息弱化的问题,本文引入CBAM模块如图5(a)所示,以进一步增强模型对关键区域与显著特征的响应能力,提升其在复杂背景中的目标感知性能。

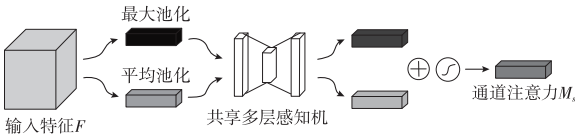
设输入特征图为$F\in R^{C\times H\times W}$,首先输入至CA模块(图5(b)),分别通过全局平均池化(AvgPool)和全局最大池化(MaxPool)沿空间维度生成两个通道描述向量$\boldsymbol{f}_{\mathrm{avg}}$和$\boldsymbol{f}_{\mathrm{max}}$,两者的维度均为$R^{C\times 1\times 1}$。随后,将二者输入至共享权重的多层感知机(MLP)中,经过逐元素求和与Sigmoid激活,生成通道注意力权重图$\boldsymbol{M}_c\in \mathrm{R}^{C\times 1\times 1}$。该权重用于调节每个通道的重要性,通道注意力模块的输出为:

$$F'=\boldsymbol{M}_c\otimes F \tag{5}$$

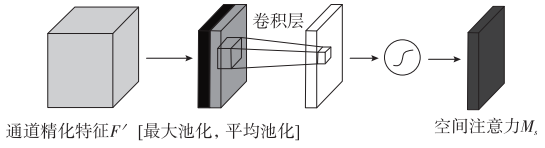
式中,$\otimes$表示逐通道的广播乘法操作。




（a）CBAM模块




（b）CA模块




（c）SA模块

图5　CBAM，CA及SA结构

接着将通道加权后的特征图$F'$输入至SA模块（图5(c)）。该模块首先在通道维度上分别施加最大池化和平均池化操作，得到两个$R^{1\times H\times W}$的空间特征图，并沿通道维度拼接为$R^{2\times H\times W}$的张量。随后将该张量输入至一个7×7卷积层，经过Sigmoid激活后生成空间注意力图$M_s\in R^{1\times H\times W}$。最终输出空间加权后的特征图：

$$F''=M_s\otimes F' \tag{6}$$

式中，$F''$即为CBAM模块的最终输出特征图，融合了显著通道响应与空间位置信息。

结合CA与SA模块，CBAM能够引导网络聚焦于对最终任务判别贡献较大的通道特征与空间区域，提升特征表达的有效性。将CBAM模块嵌入至Neck各尺度特征图拼接后，用于动态增强融合特征中的目标区域响应，进一步提高模型对石英坩埚内壁微小缺陷的敏感性与判别能力。

### 2.3　SCYLLA-IoU损失函数

在YOLOv11中，回归损失函数采用CIoU，其不仅考虑了预测框与真实框之间的区域重叠程度，还引入了中心点距离惩罚项与宽高比一致性约束，实现更精准的边界框回归。表达式如下：

$$L_{CIoU}=1-CIoU \tag{7}$$

$$CIoU=IoU-\frac{\rho^2}{c^2}-\alpha\cdot v \tag{8}$$

式中，$\rho$表示预测框与目标框中心点之间的欧氏距离，$c$为两者最小外接框对角线长度。形状项$v$则通过预测框与真实框宽高比之间的差异计算得到：

$$v=\frac{4}{\pi^2}\left[\arctan\left(\frac{w^g}{h^g}\right)-\arctan\left(\frac{w}{h}\right)\right]^2 \tag{9}$$

式中，权重因子$\alpha$的定义如下，用以动态调节形状项在总损失中的贡献：

$$\alpha=\frac{v}{(1-IoU)+v} \tag{10}$$

CIoU在常规场景下能有效提升模型的定位能力，但由于其回归路径缺乏方向性建模，难以适应石英坩埚内壁缺陷这种位置偏移较大且形状随机的目标检测任务。为进一步增强模型对石英坩埚内壁微小缺陷的定位能力，引入由Gevorgyan[23]提出的SIoU损失函数，其通过引入距离归一化、方向约束和非线性形状调整项，在IoU框架下融合多个几何因素，构建更具方向引导性的回归路径，从而有效克服传统IoU在收敛速度与定位精度方面的限制。其损失形式如下：

$$L_{SIoU}=1-IoU+\Delta_{dis}+\Delta_{angle}+\Delta_{shape} \tag{11}$$

式中，$\Delta_{dis}$为距离约束项。考虑预测框中心与真实框中心点之间的坐标偏移，该项对偏移量进行了目标尺寸归一化，使梯度在不同尺度目标间更具一致性，具体计算公式为：

$$\Delta_{dis}=\left(\frac{x_p-x_g}{w_g}\right)^2+\left(\frac{y_p-y_g}{h_g}\right)^2 \tag{12}$$

式中，$\Delta_{angle}$表示角度引导项，用于引导回归路径朝向正确方向：

$$\Delta_{angle}=1-\cos\theta \tag{13}$$

式中，角度$\theta$定义为预测框中心指向真实框中心的方向向量与$x$轴之间的夹角，避免了路径抖动和不合理跳变，提升了收敛稳定性：

$$\theta=\arccos\left[\frac{x_p-x_g}{\sqrt{(x_p-x_g)^2+(y_p-y_g)^2}}\right] \tag{14}$$

式中，$\Delta_{shape}$为形状调整项，采用指数函数处理预测框与真实框的宽高比差异：

$$\Delta_{shape}=1-\exp\left\{-\left[\left(\frac{w-w^g}{w^g}\right)^2+\left(\frac{h-h^g}{h^g}\right)^2\right]\right\} \tag{15}$$

相较于CIoU中对宽高比差异采用线性度量，SIoU通过高斯衰减函数实现非线性梯度调控，有效缓解训练后期预测框震荡问题。其不仅在损失构成上更具几何解释性，还通过引入方向感知机制和尺度归一化策略，在石英坩埚内壁缺陷检测等对边界定位要求较高的场景下展现出更强的泛化能力与鲁棒性。

## 3 实验结果与分析

### 3.1 数据集建立

石英坩埚内壁缺陷数据暂无公开数据集，实验用自建数据集进行训练，其来源于本团队自主搭建的检测平台，主要由主机、六轴机械臂、旋转平台、坩埚夹板装置、操作台、工业视觉光源、工业相机、镜头等组件构成。检测平台结构如图6所示。

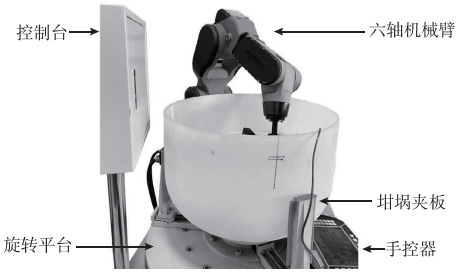



图6 石英坩埚检测平台

数据集分别包含黑点缺陷图像393张、气泡297张、白斑334张、水滴气泡171张以及析晶点169张，如图7所示，共计1 364张。Guo等[24]结合RGB颜色空间分割与深度卷积生成对抗网络构建复合卷积神经网络模型，通过丰富缺陷样本并缓解类别不平衡问题。针对数据规模偏小带来的问题，引入数据增强策略，包括随机翻转、旋转、缩放、亮度以及对比度调整，扩充样本多样性，提升模型训练的可靠性。所有图像均统一裁剪和缩放至640×640，并进行人工标注，将训练集与验证集按照8∶2的比例随机划分。

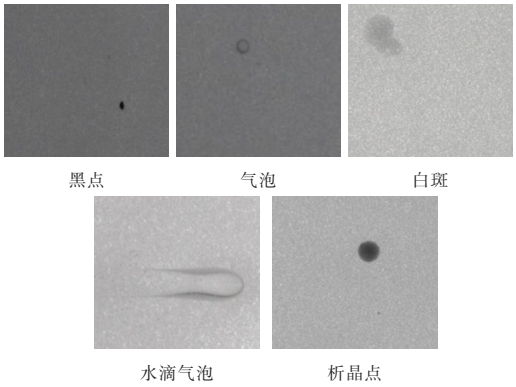



图7 石英坩埚内壁缺陷

### 3.2 训练配置

实验硬件配置：GPU为NVIDIA GeForce RTX 4060 Laptop GPU；CPU为Intel® Core™ i7-13700H；内存（RAM）为32 GB；显存（VRAM）为8 GB。

软件配置：操作系统为Windows 11；深度学习框架为PyTorch 2.6.0（CUDA 12.6）；开发语言为Python 3.10。

训练参数设置：优化器（Optimizer）为SGD；训练轮数（epoch）为300；批次大小（batch size）为16，数据加载线程（works）为8，输入图像尺寸为640；初始学习率（lr0）为0.01。

### 3.3 评估指标

为全面衡量模型在检测精度、模型复杂度与部署友好性方面的综合表现，采用平均精度均值（mAP）、模型参数量（Parameters）、每秒浮点运算量（GFLOPs）与权重文件大小（Size）作为评价指标。其中GFLOPs与参数量刻画计算与存储开销，权重文件大小反映模型的存储与分发成本，mAP用于总体精度评估，其计算公式如式（16）～（19）：

$$P=\frac{TP}{TP+FP} \tag{16}$$

$$R=\frac{TP}{TP+FN} \tag{17}$$

$$AP_i=\int_0^1 P_i(R)\mathrm{d}R \tag{18}$$

$$mAP=\frac{1}{C}\sum_{i=1}^{C}AP_i \tag{19}$$

式中，$TP$表示将正样本判为正的数量；$FP$表示将负样本误判为正的数量；$FN$表示将正样本漏检的数量；$AP$表示平均精度，等价于该类$P$-$R$曲线下的面积；$mAP$为各类$AP$的算术平均。

### 3.4 消融实验

为验证本文改进算法对检测性能的贡献，在相同的数据划分、训练策略与超参数条件下，开展逐项与组合的消融实验，分别将MSCB，CBAM，SIoU依次引入基准网络，并进一步考察多模块的协同效应。实验结果如表1所示，表中“√/×”表示是否启用相应改进，第1组为YOLOv11n基准模型。

由表1可知，三项改进模块均在不同程度上提升了模型的检测性能。Group 2单独引入C3k2-MSCB模块，相较基准模型Group 1，$mAP$@0.5与$mAP$@0.5∶0.95分别提升2.6%，0.9%，参数量由2.62 M增至2.87 M，GFLOPs增长0.35，但精度提升显著，表明该模块有效增强了多尺度特征表达能力。Group 3引入CBAM模块后，$mAP$@0.5与$mAP$@0.5∶0.95分别提升1.8%，0.6%，参数与GFLOPs分别为2.68 M和6.72，说明通道与空间注意力机制能在轻量结构中提升特征响应。在Group 5中，当C3k2-MSCB与CBAM两者联合引入时，$mAP$@0.5保持在91.8%，参数量与GFLOPs分别上升至

表1　消融实验结果

| Group | C3k2-MSCB | CBAM | SIoU | *mAP*@0.5/% | *mAP*@0.5:0.95/% | *Parameters*/M | *GFLOPs* | *Size*/MB |
|---|---|---|---|---|---|---|---|---|
| 1 | × | × | × | 89.3 | 60.5 | 2.62 | 6.60 | 5.24 |
| 2 | √ | × | × | 91.9 | 61.4 | 2.87 | 6.95 | 5.82 |
| 3 | × | √ | × | 91.1 | 61.1 | 2.68 | 6.72 | 5.42 |
| 4 | × | × | √ | 89.6 | 58.1 | 2.64 | 6.65 | 5.31 |
| 5 | √ | √ | × | 91.8 | 61.5 | 2.95 | 7.13 | 6.23 |
| 6 | × | √ | √ | 92.0 | 62.4 | 2.70 | 6.78 | 5.43 |
| 7 | √ | × | √ | 91.6 | 60.6 | 2.90 | 6.98 | 5.91 |
| 8 | √ | √ | √ | **92.7** | 62.3 | 3.02 | 7.26 | 6.30 |

2.95 M和7.13，提升幅度相较单模块更稳定，验证二者在结构上具备互补性。进一步在此基础上引入SIoU损失函数（Group 8），*mAP*@0.5与*mAP*@0.5:0.95提升至最高的92.7%和62.3%，相较Group 1分别提高3.4%，1.8%，参数量控制在3.02 M，GFLOPs为7.26，模型整体仍维持在轻量化水平。

### 3.5　对比实验

有研究指出DETR类方法在实时检测任务中逐步展现出对YOLO系列模型的性能超越趋势[25]。为验证所提MCS-YOLO模型在目标检测任务中的性能优势，选取当前主流的YOLO系列算法以及RT-DETR进行对比实验。所有模型均在统一环境与训练配置下进行训练与测试，确保公平与可比性。实验结果如表2所示。

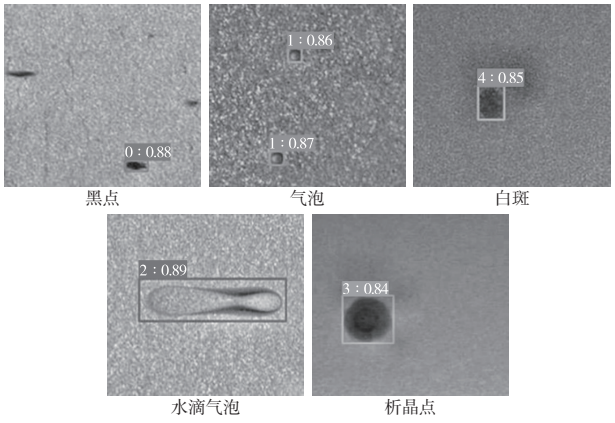
表2　不同模型检测结果对比

| 模型 | *mAP*@0.5/% | *mAP*@0.5:0.95/% | *Parameters*/M | *GFLOPs* | *Size*/MB |
|---|---|---|---|---|---|
| YOLOv5n | 88.2 | 57.6 | 1.9 | 4.5 | 3.8 |
| YOLOv5s | 90.5 | 61.1 | 7.2 | 16.5 | 14.0 |
| YOLOv-n | 90.1 | 58.7 | 4.3 | 9.5 | 7.80 |
| RT-DETR | 91.0 | 61.7 | 7.5 | 18.6 | 15.1 |
| YOLOv7-tiny | 89.5 | 60.2 | 6.2 | 13.1 | 11.4 |
| YOLOv8n | 88.8 | 59.8 | 3.2 | 8.7 | 6.1 |
| YOLOv8s | 92.1 | 62.7 | 11.2 | 28.0 | 22.6 |
| YOLOv11n | 89.3 | 60.5 | 2.62 | 6.6 | 5.24 |
| MCS-YOLO | **92.7** | 62.3 | 3.02 | 7.26 | 6.30 |

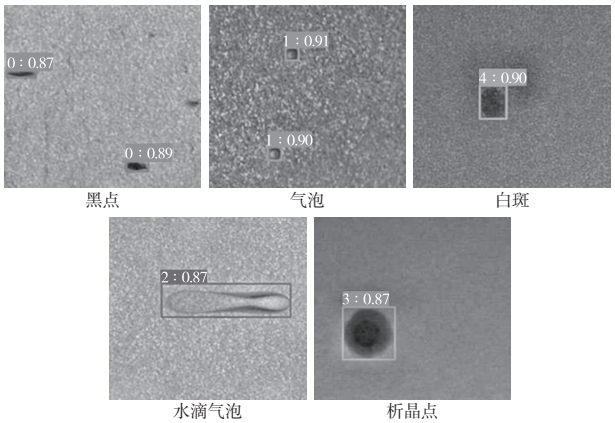
由表2可知，YOLOv5n和YOLOv8n等轻量模型在参数量和模型体积上具有优势，但*mAP*@0.5相对较低，仅为88.2%和88.8%。YOLOv5s，YOLOv6-n和YOLOv7-tiny虽精度有所提升，但GFLOPs明显增大，部署效率受限。RT-DETR-R18的*mAP*@0.5达91.0%，但其计算量和模型体积最大。YOLOv11n在保持轻量结构的同时*mAP*@0.5取得89.3%，而所提MCS-YOLO在参数量仅增加0.4 M的基础上将*mAP*@0.5提升至92.7%，实现了精度与效率的良好平衡，具备较强的实际应用潜力。

### 3.6　检测结果可视化

为了更直观地展示MCS-YOLO模型在石英坩埚内壁缺陷检测中的实际效果，选取部分典型缺陷图像进行可视化检测结果对比，结果如图8所示，图中每组图像从左至右依次包含黑点、气泡、白斑、水滴气泡与析晶点五类典型缺陷。图8(a)为YOLOv11n的检测结果，图8(b)为改进模型MCS-YOLO的检测结果。由图可以直观看出，YOLOv11n模型在复杂背景下易出现漏检、框选不准问题，对于部分缺陷检测置信度相对较低，边界框不够贴合。




(a) YOLOv11n检测结果




(b) 改进模型检测结果

图8　可视化检测结果对比

相比之下，MCS-YOLO在各类缺陷中均表现出更高的检测精度与边界拟合度。模型不仅减少了漏检现象，且生成的框更加紧致、置信度更高，表现出良好的鲁棒性。

## 4 结论

本文针对石英坩埚内壁缺陷检测中存在的微小、不规则缺陷边界模糊以及检测效率低下等问题，提出了一种基于YOLOv11n的改进型轻量化检测模型MCS-YOLO。该模型通过引入C3k2-MSCB模块，增强了对多尺度特征的表达能力，显著提升了模型对尺寸差异较大缺陷的感知与识别性能；融合CBAM注意力机制，引导网络聚焦关键缺陷区域，有效抑制背景噪声干扰；采用SIoU边界框回归损失函数，优化了检测框的位置和形状回归，使模型在面对边界模糊或形态不规则的目标时具有更高的定位精度。实验结果表明，MCS-YOLO在保持轻量化特性的同时，*mAP*@0.5达92.7%，较基准模型提升3.4%，且在可视化检测结果中表现出更好的缺陷边界拟合度和更高的置信度，验证了模型的有效性与实用性。后续工作会进一步探索多源信息融合与缺陷等级评估机制，以提升系统的智能化水平与应用广度。

**参考文献：**


[1] 黄海龙，刘贤金，刘文峰，等. 海外单晶硅太阳电池生产线建设的分析与研究[J]. 太阳能，2023(6)：9-23.
Huang Hailong，Liu Xianjin，Liu Wenfeng，et al. Analysis and research on construction of overseas mono-Si solar cell production line[J]. Solar Energy，2023(6)：9-23.

[2] 陈俊帆，赵生盛，高 天，等. 高效单晶硅太阳电池的最新进展及发展趋势[J]. 材料导报，2019，33(1)：110-116.
Chen Junfan，Zhao Shengsheng，Gao Tian，et al. High-efficiency monocrystalline silicon solar cells：development trends and prospects[J]. Materials Reports，2019，33(1)：110-116.

[3] 莫 宇，张颖武，韩焕鹏，等. 石英坩埚对大直径直拉硅单晶生长的影响[J]. 电子工艺技术，2021，42(1)：46-49.
Mo Yu，Zhang Yingwu，Han Huanpeng，et al. Effects of quartz crucible on growth of large diameter czochralski silicon[J]. Electronics Process Technology，2021，42(1)：46-49.

[4] 操晓春，赵思成，武阿明，等. 目标检测技术在开放环境中的挑战与进展[J]. 中国图象图形学报，2025，30(6)：1616-1637.
Cao Xiaochun，Zhao Sicheng，Wu Aming，et al. Challenges and progress of object detection technology in open environments[J]. Journal of Image and Graphics，2025，30(6)：1616-1637.

[5] 程锦锋，方贵盛，高惠芳. 表面缺陷检测的机器视觉技术研究进展[J]. 计算机应用研究，2023，40(4)：967-977.
Cheng Jinfeng，Fang Guisheng，Gao Huifang. Research progress of surface defect detection based on machine vision technology[J]. Application Research of Computers，2023，40(4)：967-977.

[6] 刘传洋，吴一全，刘景景. 无人机航拍图像中绝缘子缺陷检测的深度学习方法研究进展[J]. 电工技术学报，2025，40(9)：2897-2916.
Liu Chuanyang，Wu Yiquan，Liu Jingjing. Research progress of deep learning methods for insulator defect detection in UAV based aerial images[J]. Transactions of China Electrotechnical Society，2025，40(9)：2897-2916.

[7] 谭鑫平，高志辉，韩航迪，等. 基于改进YOLOv5的荧光图像细胞智能检测研究[J]. 半导体光电，2023，44(5)：709-716.
Tan Xinping，Gao Zhihui，Han Hangdi，et al. Intelligent detection of cells in fluorescence images based on improved YOLOv5[J]. Semiconductor Optoelectronics，2023，44(5)：709-716.

[8] Cen H. Target location detection of mobile robots based on R-FCN deep convolutional neural network[J]. International Journal of System Assurance Engineering and Management，2023，14(2)：728-737.

[9] 杨志锐，郑 宏，郭中原，等. 基于网中网卷积神经网络的红枣缺陷检测[J]. 食品与机械，2020，36(2)：140-145，181.
Yang Zhirui，Zheng Hong，Guo Zhongyuan，et al. Detection of jujube defects based on the neural network with network convolution[J]. Food & Machinery，2020，36(2)：140-145，181.

[10] Xu X，Zheng H，You C，et al. FAR-net：feature-wise attention-based relation network for multilabel jujube defect classification[J]. Sensors，2021，21(2)：392.

[11] Lin T Y，Goyal P，Girshick R，et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence，2020，42(2)：318-327.

[12] 任晶晶，郭中原，鞠剑平. 基于双层优化元学习的域自适应红枣缺陷检测[J]. 中国农机化学报，2025，46(7)：104-110.
Ren Jingjing，Guo Zhongyuan，Ju Jianping. Domain-adaptive defect detection in jujubes using meta-learning with bi-level optimization[J]. Journal of Chinese Agricultural Mechanization，2025，46(7)：104-110.

[13] Tan M，Pang R，Le Q V. EfficientDet：scalable and efficient object detection [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition，2020：10778-10787.

[14] Zhao J，Tian G，Qiu C，et al. Weed detection in potato fields based on improved YOLOv4：optimal speed and accuracy of weed detection in potato fields [J]. Electronics，2022，

11(22)：3709.

[15] Wang C Y, Bochkovskiy A, Liao H M. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors [C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2023: 7464-7475.

[16] 喻擎苍，邱　锐，傅林杰，等. YOLOv7-VSS轻量化橘瓣外观检测模型[J]. 现代电子技术，2025，48(10)：85-91.
Yu Qingcang, Qiu Rui, Fu Linjie, et al. YOLOv7-VSS lightweight orange segment appearance detection model [J]. Modern Electronics Technique, 2025, 48(10): 85-91.

[17] 代少升，周　漫，余自安，等. 基于改进YOLOv8n的货车盲区目标检测方法[J]. 半导体光电，2025，46(1)：172-179.
Dai Shaosheng, Zhou Man, Yu Zian, et al. Object detection in the blind spot of truck based on improved YOLOv8n [J]. Semiconductor Optoelectronics, 2025, 46(1): 172-179.

[18] Xu X, Zheng H, Guo Z, et al. SDD-CNN: small data-driven convolution neural networks for subtle roller defect inspection[J]. Applied Sciences, 2019, 9(7): 1364.

[19] Ju J, Zheng H, Xu X, et al. Classification of jujube defects in small data sets based on transfer learning [J]. Neural Computing and Applications, 2022, 34(5): 3385-3398.

[20] Xu P, Guo Z, Liang L, et al. MSF-net: multi-scale feature learning network for classification of surface defects of multifarious sizes[J]. Sensors, 2021, 21(15): 5125.

[21] Rahman M M, Munir M, Marculescu R. EMCAD: efficient multi-scale convolutional attention decoding for medical image segmentation[C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 11769-11779.

[22] Woo S, Park J, Lee J Y, et al. CBAM: convolutional block attention module [C]//Computer Vision-ECCV 2018. Cham: Springer, 2018: 3-19.

[23] Gevorgyan Z. SIoU loss: More powerful learning for bounding box regression [J]. arxiv preprint, arxiv: 2205.12740, 2022.

[24] Guo Z, Zheng H, Xu X, et al. Quality grading of jujubes using composite convolutional neural networks in combination with RGB color space segmentation and deep convolutional generative adversarial networks [J]. Journal of Food Process Engineering, 2021, 44(2): e13620.

[25] Zhao Y, Lv W, Xu S, et al. DETRs beat YOLOs on real-time object detection [C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 16965-16974.

**作者简介：**

**黄晶晶**(1988—)，男，硕士，工程师，主要研究方向为N型高效硅片、高品质长寿命石英坩埚；

**宋宇辉**(2001—)，男，硕士研究生，主要研究方向为机器视觉、视频图像处理。