

基于改进 YOLOv12 的铝型材工件缺陷检测技术研究^{*}

景会成 鲍成明

(华北理工大学电气工程学院 唐山 063210)

摘要: 针对铝型材工件生产中缺陷检测精度低以及小目标缺陷漏检和误检的问题,本文对 YOLOv12n 模型进行了优化,提出了一种基于 YOLO-PCSU 的铝型材表面缺陷检测方法。首先,引入 PartialConv 卷积对 YOLOv12 模型的 A2C2f 结构进行改进,设计一种新的结构 A2C2f-PConv,减少冗余计算和内存访问的同时加强网络特征提取能力;其次,在特征提取网络引入 CoordAttention,在不增加额外计算的基础上提升检测精度;再次,在检测头引入注意力模块 SEAM,解决小目标漏检误检问题;最后,通过用 U-IoU 损失函数替代 YOLOv12n 模型中的 CIoU,加快模型的收敛速度并提高了检测结果的精度。在铝型材工件缺陷数据集中进行实验,检测精度达到 90.3%,实验结果相比于原 YOLOv12n 算法 mAP@0.5 提升 2.3%,参数量降低 9%,计算量降低 14%。在 VOC2012 数据集和东北大学热轧带钢表面缺陷数据集上表明改进算法有良好的鲁棒性。

关键词: 表面缺陷检测; YOLOv12n; SEAM; 损失函数

中图分类号: TN911.73 文献标识码: A 国家标准学科分类代码: 510.4050

Research on defect detection technology of aluminum profile workpiece based on improved YOLOv12

Jing Huicheng Bao Chengming

(School of Electrical Engineering, North China University of Science and Technology, Tangshan 063210, China)

Abstract: To address the issues of low detection accuracy and missed or false detections of small defects in aluminum profile production, this paper proposes an improved YOLOv12n-based method, termed YOLO-PCSU, for surface defect detection. First, a novel A2C2f-PConv structure is designed by integrating PartialConv into the A2C2f module of YOLOv12n, enhancing feature extraction while reducing redundant computation and memory access. Second, CoordAttention is introduced into the backbone to improve detection accuracy without increasing computational cost. Third, the SEAM attention module is added to the detection head to mitigate missed and false detections of small targets. Finally, the U-IoU loss replaces the original CIoU loss to accelerate convergence and enhance prediction precision. Experiments on an aluminum profile defect dataset demonstrate a detection accuracy of 90.3%, with a 2.3% mAP@0.5 improvement over the baseline YOLOv12n, a 9% reduction in parameters, and a 14% reduction in computation. Additional evaluations on the VOC2012 and Northeastern University hot-rolled strip steel surface defect datasets confirm the robustness of the proposed approach.

Keywords: surface defect detection; YOLOv12n; SEAM; loss function

0 引言

铝型材工件拥有低密度、高可塑性和耐腐蚀等性能,所以应用领域广泛包括建筑、工业生产、交通物流和航空航天等。在铝型材加工过程中,生产设备和环境因素常导致工件表面出现多种缺陷,如不导电、擦花、桔皮、脏点、漆泡和角位漏底等,这些瑕疵会显著降低产品的质量和可靠性。

在基于深度学习的缺陷检测算法^[1]中,分为两阶段目标检测和单阶段目标检测,两阶段目标检测需要先得到缺陷检测的锚点框,再进行分类和回归,如:R-CNN、Fast R-CNN 和 Faster R-CNN。单阶段目标算法只需要一步,即端到端的检测,如:SSD、RetinaNet 和 YOLO 系列。

两阶段检测算法以 R-CNN 系列为代表,苏立鹏等^[2]提出了一种基于改进快速区域卷积神经网络 (Faster-

RCNN)的起重机钢丝绳表面缺陷识别检测方法,该方法通过结合多个关键技术进展,显著提升了钢丝绳表面缺陷识别的性能,模型的鲁棒性较差。杨莉等^[3]提出一种改进的基于区域的快速卷积神经网络(faster region-based convolutional neural network, Faster-RCNN)钢材表面缺陷的检测算法,引入引导锚定区域提议网络(guided anchoring region proposal network, GA-RPN)进行预测锚点的位置与形状,提出多任务特征金字塔网络来改善小目标的检测性能。陈利琼等^[4]针对焊缝缺陷模型对图像复杂背景和光照变化的适应性不足的问题,提出了基于改进Faster R-CNN的焊缝缺陷检测方法,引入感兴趣区域对齐技术,显著提高了焊缝缺陷检测的精度和鲁棒性,但计算方面较为复杂。Wei 等^[5]提出了一种基于 Faster RCNN 的多尺度缺陷检测网络,将 FPN 的特征融合思想添加到 Faster RCNN 中,但检测速度较慢。

相对于复杂的两阶段目标检测算法,作为单阶段目标检测算法的 YOLO 系列算法在实际研究中使用更广泛。徐瑞杰等^[6]针对森林火灾初期的环境背景复杂和小目标火焰,提出基于 YOLOv5s 的轻量化检测算法 YOLO-VRG,使用极简主义网络 VanillaNet 作为特征提取网络并设计了空间和通道特征重建注意力卷积模块,在提升检测精度的同时大幅降低参数量,但是在复杂场景下检测能力较差。赵亚凤等^[7]针对铁路轨道缺陷检测精度低和漏检率高问题,提出了基于 YOLOv7 的检测算法 YOLO-FCA,设计了多尺度自适应空间特征融合策略模块(MSASFF),增强了模型的检测精度和鲁棒性,但模型会伴随计算量的增加。梁礼明等^[8]提出的改进模型 YOLOv8s 算法,重新设计特征交互模块,抑制空间和通道冗余信息,提高检测精度并提升小目标的特征提取能力。崔克彬等^[9]在 YOLOv8 算法的基础上,提出了一种改进的通道注意力机制,以改进钢材表面缺陷检测任务中误检、漏检等问题。Yang 等^[10]将 YOLOv8s 模型应用于农业领域,证明了深度学习技术的跨域潜力。Xiong 等^[11]通过 YOLOv8-GAM-Wise-IoU 模型优化了桥面裂缝检测的准确性。孙铁强等^[12]针对工业上铝型材表面缺陷检测速度慢,采用跨尺度特征融合,提升网络对多尺度信息的感知能力,并引入轻量级 RepGhost 模块,以降低参数数量和计算量。李季村等^[13]分析了铝型材表面缺陷特点并对比现有深度学习目标检测算法,基于 YOLOv8n 网络模型提出了一种融合 GhostBottleneck 及注意力机制的铝型材表面缺陷检测算法,精度提升但所依托的模型版本相对较早。吴葛等^[14]针对钢材缺陷检测模型较老并存在漏检的情况,基于 YOLOv10 提出了一种钢材表面缺陷检测算法 FAA-YOLO,通过引入多尺度注意力和自适应细粒度通道注意力,提高了模型的检测精度。上述的单阶段目标检测算法仍存在一定局限性。首先,部分算法在检测小尺寸缺陷目标时存在精度下降的问题,尤其在工业复杂背景下,容易出现漏检与误检。其次,虽然轻

量化设计能降低计算复杂度,但往往以牺牲特征提取能力为代价,影响模型的检测性能。

本文针对铝型材工件缺陷检测精度不足的问题,在最新的 YOLOv12n 模型的基础上,引入并设计新的结构设计了新的铝型材缺陷检测算法。主要工作包括:1)从公开的天池数据集中选取 6 种缺陷类别,利用 labelme 给数据集图像做标签,并通过数据增强技术对数据集进行扩充;2)引入部分卷积(partial convolution, PConv)来设计一种新的结构替代基础模型中的 A2C2f 和 C3k2 结构,来提升网络性能;3)在骨干网络中加入协调注意力机制(coordinate attention, CA);4)在检测头部分加入挤压-激励注意力模块(squeeze-and-excitation attention module, SEAM),降低模型的参数并提升网络检测性能;5)为了平衡注意力和收敛率的矛盾,引入统一损失函数 U-IoU 来提升检测的泛化能力。

1 YOLOv12n 算法介绍

YOLOv12 算法结构如图 1 所示。Backbone 部分重新设计了 A2C2f 模块,通过引入区域注意力机制,显著降低了计算复杂度,同时保持了较大的感受野。YOLOv12 提出了重参数化高效层聚合网络(re-parameterized efficient layer aggregation network, R-ELAN),R-ELAN 在原始的 ELAN 的基础上引入了两项改进:1)采用缩放技术的块级残差连接;2)重新设计的特征聚合方法,提高了训练稳定性和特征提取能力。在 Head 部分,YOLOv12 的检测头引入二维卷积 Conv2Former、渐进式预测聚合(progressive prediction aggregation, PPA)等模块。这些模块通过卷积调制操作、多分支特征提取和注意力机制等技术,提高了检测头的特征提取和处理能力等,改进模型 YOLO-PCSU 的结构如图 2 所示。

2 改进的 YOLOv12n 算法

2.1 结合 PConv 的 A2C2f_PConv

本文借鉴了 FasterNet^[15]中的 FasterBlock 和 PConv 设计了一种改进 A2C2f 部分卷积(A2C2f-PConv),原 A2C2f 模块和 C3k2 模块结构如图 3 所示,改进后的 A2C2f 模块和 C3k2 模块如图 4 所示。

PConv 的设计旨在加速神经网络,通过减少浮点运算次数(FLOPs)来优化网络速度。PConv 只在少数几个输入通道上应用过滤器,而对其余通道不做处理,与传统卷积相比,减少了冗余计算和内存访问次数,有效降低了计算量和内存访问,提升了网络的运行效率。FasterBlock 和 PConv 的结构如图 5 所示。

因此,本文通过在主干特征提取网络中引入 PConv,可以有效降低目标检测过程中的计算量和内存访问量,实现模型的轻量化并提升推理速度。此优化降低了模型对计算资源的依赖,并提升了模型的检测精确度,能够在检测任务

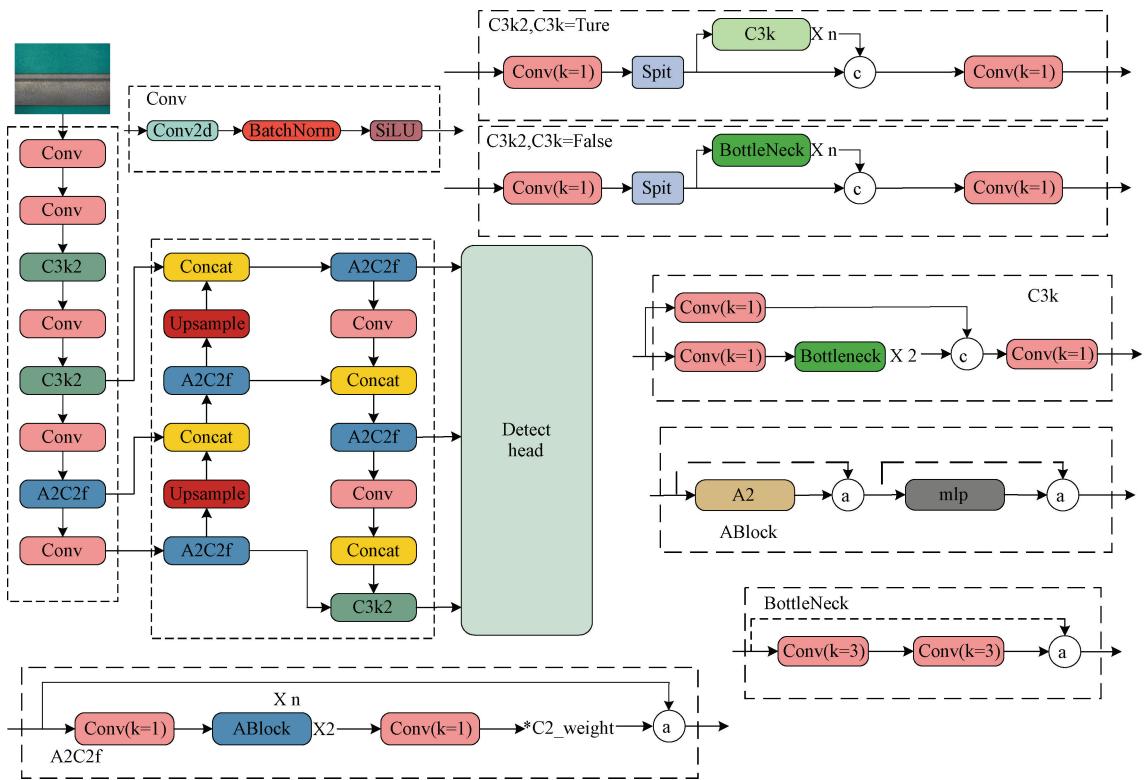


图 1 YOLOv12n 基础模型结构
Fig. 1 Basic architecture of the YOLOv12n model

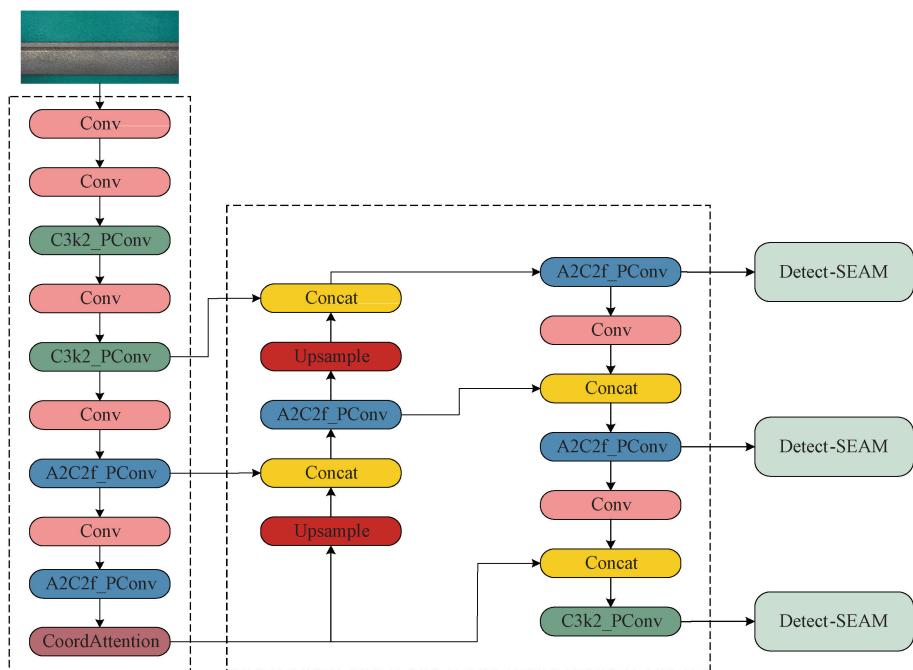


图 2 YOLO-PCSU 模型的结构图
Fig. 2 Architecture of the YOLO-PCSU model

中做到高效率和高精度。

2.2 CA 注意力模块

CA 注意力机制放在特征提取网络中, CA 注意力机制

不仅关注通道间的信息编码, 更重视位置信息的重要性。CA 结构图如图 6 所示。

从图 6 中可以看出, 协调注意力将通道注意力拆分成

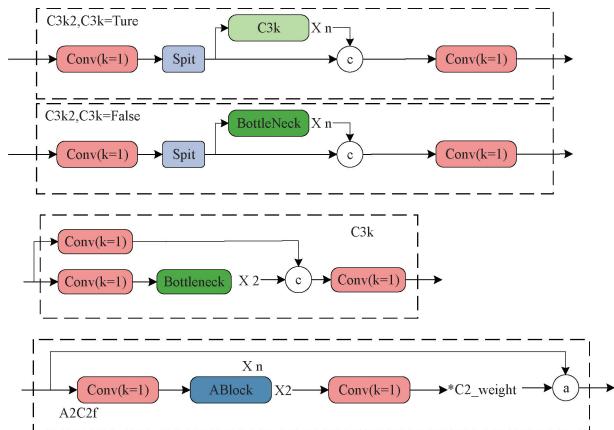


图 3 原 C3k2 和 A2C2f 模块

Fig. 3 Original C3k2 and A2C2f modules

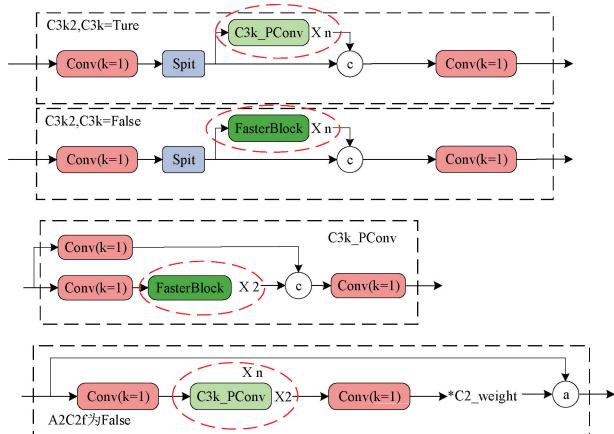


图 4 改进后的 C3k2 和 A2C2f 模块

Fig. 4 Improved C3k2 and A2C2f modules

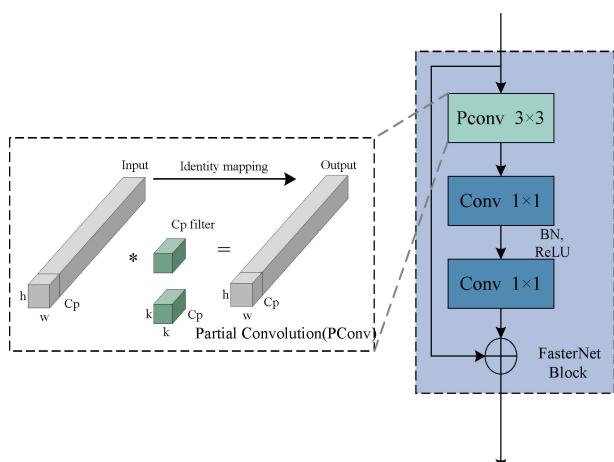


图 5 FasterBlock 和 PConv 模块

Fig. 5 FasterBlock and PConv modules

两个一维特征，并分别对特征进行编码，最后将这两个不同空间方向的特征进行融合。这样的处理方式使得改进后的模型能够在一个方向上捕捉远程依赖，同时在另一个

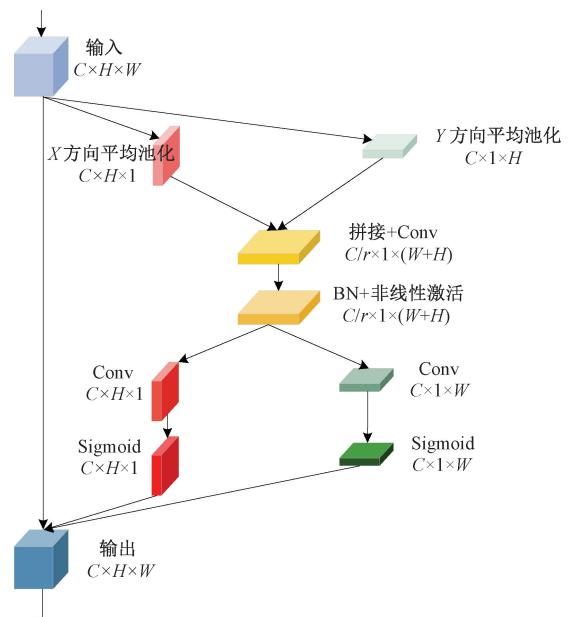


图 6 CA 注意力机制

Fig. 6 Coordinate attention mechanism

方向上保持原始的位置信息精度。特征图会被 CA 注意力处理成一对注意力图，一个是具有方向感知的，另一个是具备位置敏感的，这些图互相补充各自的短板最后用于到输入的特征图。协调注意力考虑通道之间的关系和位置信息，使特征图信息更充分有利于模型更准确地定位和识别缺陷区域。对于铝型材数据集中脏点这种小目标检测更加精准，能够提升模型的检测精度。

2.3 Detect-SEAM 模块

本文在检测头中引入了 SEAM 模块，构建了新的 Detect-SEAM 检测头，旨在实现多尺度目标检测，重点强化图像中的目标区域并抑制背景区域。SEAM 模块^[16]的结构如图 7 所示，首先通过深度可分离卷积对每个通道进行深度分离。深度可分离卷积将标准卷积分解为深度卷积和逐点卷积，既能学习各通道的重要性，又能减少计算开销，但会丢失通道间的信息。为弥补这一缺失，深度卷积的输出通过逐点卷积进行重组，以增强通道之间的信息流动，从而提高特征表达能力，并有效整合通道信息。此过程通过一个两层全连接网络进一步增强通道间的联系，确保信息流动更为顺畅。SEAM 模块被插入到检测头中，如图 8 和图 9 所示，提升了模型在小目标检测中的表现，减少了漏检误检现象。

2.4 损失函数改进

YOLOv12 网络使用 CIoU 作为边界框的损失函数，CIoU 在宽高比计算时会加重对低质量样本的惩罚，以及梯度不稳定的问题，本文采用一种新的损失函数 U-IoU 进行替换。

U-IoU 提出了一种新的预测框动态加权方法：通过缩小边界框，可以放大预测框和真实框的 IoU 损失，相当于给

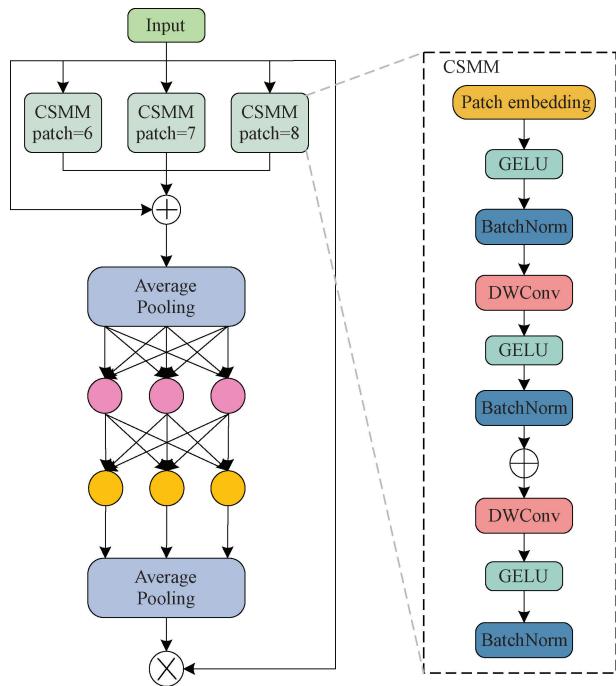


图 7 SEAM 模块结构

Fig. 7 Structure of the SEAM module

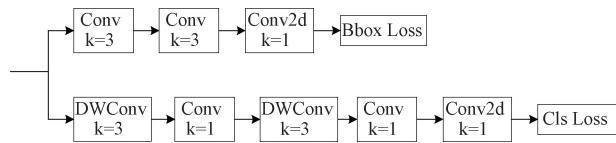


图 8 原始 YOLOv12 检测头结构

Fig. 8 Original YOLOv12 detection head structure

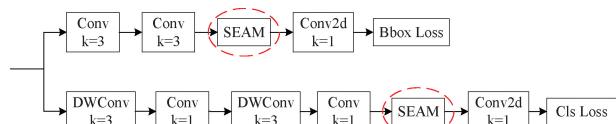


图 9 改进后的 SEAM-Detect 结构

Fig. 9 Improved SEAM-Detect structure

高质量的预测框更多的权重,达到将模型集中在高质量预测框上的效果。为了平衡模型的注意力和收敛率之间的矛盾,U-IoU 设计了一个动态超参数“ratio”来调整边界框的缩放比例。具体来说,在训练开始时,放大了边界框,相当于减少了高质量预测框的 IoU 损失,模型专注于低质量的锚框,可以更快地收敛。在训练的后期,减少了边界框,相当于增加了高质量预测框的 IoU 损失,使模型的注意力集中在高质量的锚框上。U-IoU 的计算公式如式(1)~(8)所示。

1) 动态缩放机制

设原始预测框和真实框的坐标为和,通过缩放比例 $ratio$ 调整尺寸:

$$w'_p = w_p \times ratio, h'_p = h_p \times ratio \quad (1)$$

$$w'_g = w_g \times ratio, h'_g = h_g \times ratio \quad (2)$$

缩放后的 IoU 计算:

$$IoU_{scaled} = \frac{B'_{pred} \cap B'_{gt}}{B'_{pred} \cup B'_{gt}} \quad (3)$$

其中, w_p, h_p 为预测框的原始宽度和高度, w_g, h_g 为真实框的原始宽度和高度, $ratio$ 为动态缩放因子, 随着训练轮数调整。

2) 动态退火策略

线性退火:

$$ratio = -0.005 \times epoch + 2 \quad (4)$$

余弦退火:

$$ratio = 0.75 \times \cos\left(\frac{\pi \times epoch}{T}\right) + 1.25 \quad (5)$$

分数退火:

$$ratio = \frac{200}{epoch + 100} \quad (6)$$

3) 损失函数公式:

$$Loss_{U-IoU} = (1 - IoU_{scaled}) \times Weight_{focal-inv} \quad (7)$$

$$Weight_{focal-inv} = Confidence^\gamma \quad (8)$$

其中, $(1 - IoU_{scaled})$ 为衡量缩放后预测框和真实框的重叠损失, $confidence$ 为预测框的置信度, γ 为超参数, 控制权重分配。

3 实验设计与结果分析

3.1 实验环境及相关参数

本实验建立在 Windows 操作系统中, 实验环境 GPU 采用 RTX3090, 环境为 Pytorch2.3.0, python3.12, CUDA 版本为 12.1, 相关参数如表 1 所示, 模型初始图像大小为 640×640 , 模型迭代次数为 300 轮。

表 1 实验训练参数

Table 1 Experimental training parameters

实验项目	型号
操作系统	Windows11 64 位
CPU	Intel Xeon Processor(lcelake)
GPU	RTX3090(24 GB)
编译器	Pycharm2024 专业版
算法框架	PyTorch2.3.0+Python3.12+Cuda12.1

3.2 数据集创建

实验中所用数据集的图片选自公开天池铝型材表面缺陷数据集, 本文选取其中 6 种缺陷, 分别是不导电、擦花、桔皮、漆泡、脏点和角位漏底, 如图 10 所示。在实验前利用 labelme 对图片进行重新标注, 总共标注图像为 1100 张。为增强模型的泛化能力和鲁棒性, 本文通过平移、旋转、裁剪、亮度调整、镜像及 cutout 等数据增强技术扩充了数据集。将原始数据集增加至 4400 张, 并按 8:1:1 的比例将其划分为训练集、验证集和测试集。

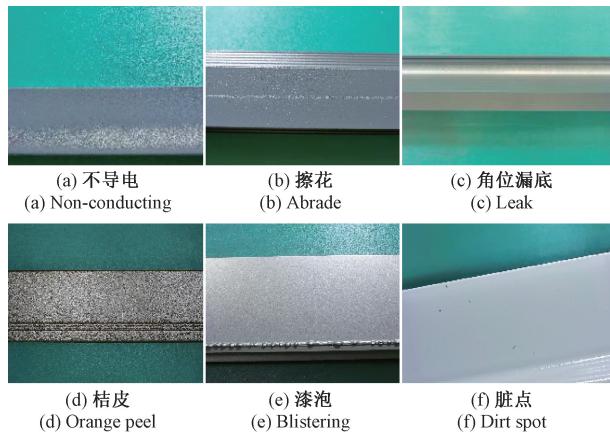


图 10 铝型材缺陷类别

Fig. 10 Categories of aluminum profile defects

3.3 实验评价指标

本研究采用精确度(Precision)、召回率(Recall)和平均精度均值(mean average precision, mAP)来评估模型的检测精度,同时使用参数量(Parameters)和浮点运算量(giga floating point operations, GFLOPs)来衡量模型的轻量化性能,帧率(frame rate)作为衡量检测速度的指标。精确度(P)表示所有预测为正类的样本中,实际为正类的比例;召回率(R)则指所有真实为正类的样本中,成功预测为正类的比例;mAP则是不同类别精度的平均值,用于综合评估模型在多个类别上的表现。上述评价指标的计算方法如式(9)~(12)所示。

$$P = \frac{TP}{TP + FP} \quad (9)$$

$$R = \frac{TP}{TP + FN} \quad (10)$$

$$AP = \int_0^1 P(R) dR \quad (11)$$

$$mAP = \frac{\sum_{m=1}^M AP}{M} \quad (12)$$

其中,TP(true positives)表示实际为正类且正确预测为正类的样本数;FP(false positives)表示实际为负类但误判为正类的样本数;FN(false negative)表示实际为正类但误判为负类的样本数;AP(average precision)指的是精确度(P)与召回率(R)曲线下,纵轴为精度、横轴为召回率所围成的面积;M是数据集中类别的总数。

3.4 对比实验

1) YOLO-PCSU 模型的对比实验

本文将改进后的 YOLO-PCSU 模型与 YOLOv8n、YOLOv10n、YOLOv11n 和 YOLOv12n 等多个模型在同一个数据集下进行了对比实验,实验结果如表 2 所示。

根据 mAP@0.5 指标,YOLO-PCSU 模型的检测精度达到了 90.3%,比 YOLOv12n 提高了 2.3%,并且在所有

表 2 YOLO-PCSU 模型的对比实验结果

Table 2 Comparative experimental results of the YOLO-PCSU model

模型	mAP@0.5 / %	参数量	GFLOPs	帧率 / fps
YOLOv8	87.6	3.01	8.1	433
YOLOv10n	85.3	2.27	6.5	410
YOLOv11n	88.0	2.58	6.3	680
YOLOv12n	88.0	2.56	6.3	619
YOLO-PCSU	90.3	2.31	5.4	674

对比模型中表现最佳。在模型参数量方面,改进的 YOLO-PCSU 模型相比 YOLOv12n 减少了 9%,显示出更高的计算效率。另一方面,在 GFLOPs 和帧率方面,YOLO-PCSU 模型也优于 YOLOv12n,展现了更高的计算性能和处理速度。尽管在帧率方面,改进模型的表现比 YOLOv11 低 6 fps,但在参数量和计算效率(GFLOPs)上,改进模型仍然优于 YOLOv11。这表明,改进模型在减少参数量和提升计算效率方面具有显著优势。总体来看,改进后的模型在所有关键评估指标上均优于 YOLOv12n 和其他对比模型,证明其在精度、效率和计算资源消耗方面的综合优势。YOLO-PCSU 各项损失指标在不同训练轮数下的变化如图 11 所示。图 11 中显示,随着迭代次数的增加,训练集与验证集的边界框损失、分类损失和目标置信度损失逐步稳定,表明模型在训练过程中已实现较好的收敛效果。

改进模型和基础 YOLOv12n 对铝型材缺陷检测的精度如图 12 和 13 所示。

针对小目标缺陷脏点和漆泡的检测对比效果如图 14 和 15 所示,图像从左到右依次为随机铝型材缺陷图像、YOLOv12n 模型检测结果和改进模型检测结果。图 14 中包含多个脏点缺陷,基础的 YOLOv12n 模型在检测时存在将 3 个脏点同一框和一个脏点漏检的情况,而改进模型将每个脏点精准检测。图 15 中包含 2 个漆泡缺陷,基础模型只检测出其中一个比较明显的漆泡缺陷,改进模型精准地检测出 2 个漆泡缺陷。上述小目标检测对比,说明改进模型在数据集的检测精度优于基础模型,并且在小目标检测方面效果表现更优。

2) 损失函数对比实验

损失函数对比实验结果如表 3 所示。根据表 4 可以得出,U-IoU 损失函数在 mAP @ 0.5 上比 CIoU 提高了 0.9%。与其他损失函数相比,U-IoU 不仅提升了检测精度和速度,还加速了模型的收敛过程。

3) 数据集优化对比实验

本部分对数据集优化前后的 YOLOv12n 原始模型在检测铝型材表面缺陷的训练结果进行对比,验证数据集优化的实际效果。实验过程中,两组模型除数据集更改外,其余参数保持一致,保证实验结果的可靠性,数据集优化前后训练结果对比如表 4 所示。

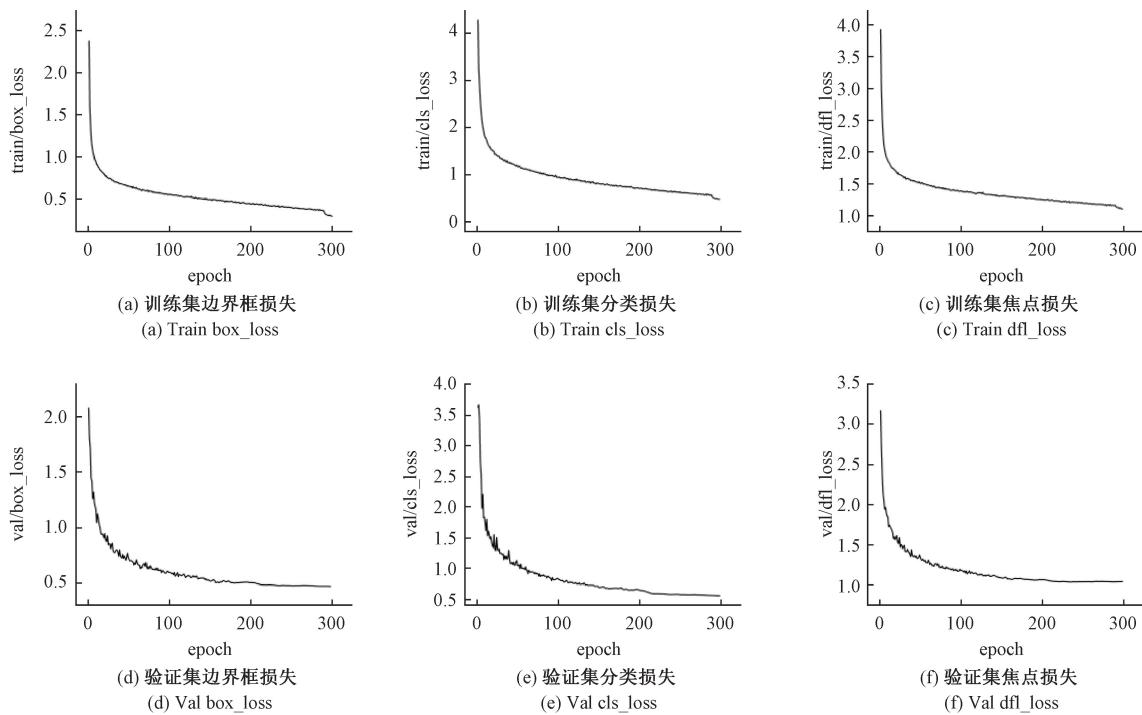


图 11 YOLO-PCSU 的损失曲线

Fig. 11 Loss curves of the YOLO-PCSU model

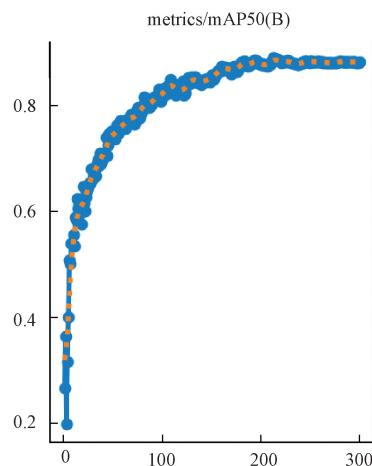


图 12 YOLOv12n 模型检测精度

Fig. 12 Detection accuracy of the YOLOv12n model

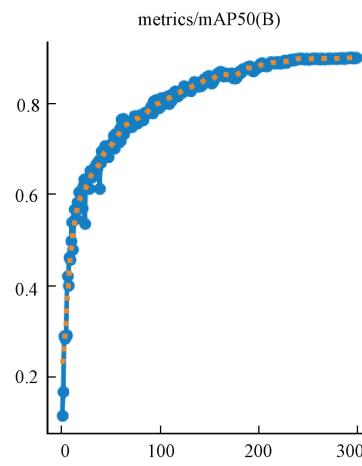


图 13 改进模型检测精度

Fig. 13 Detection accuracy of the improved model



图 14 该图片有多个脏点缺陷

Fig. 14 The image contains multiple dirty spot defects



图 15 该图中有两个漆泡缺陷

Fig. 15 Two paint bubble defects in the image

表 3 损失函数选用的对比实验

Table 3 Comparative experiments on the choice of loss functions

模型	损失函数	mAP@0.5/%	帧率/fps
YOLOv12+ A2C2fPConv+ CA+SEAM-Head	CIoU	89.4	657
	DIoU	88	631
	Wasserstein-IoU	87.1	602
	Shape-IoU	89.5	643
	Inner-IoU	87	614
	U-IoU	90.3	674

3.5 消融实验

消融实验结果如表 5 所示,模型 1 为 YOLOv12n 的基础版本,其余模型为各改进模块的消融实验。根据表 6 的数据显示,模型 2 在 YOLOv12n 中引入 A2C2f-PConv 模块后,检测精度提升了 1%,同时计算量减少了 15%。将 CA 注意力机制加入 YOLOv12n 骨干网络后,mAP 提升

表 4 数据集优化前后结果对比

Table 4 Comparison of results before and after dataset optimization

数据集	模型	mAP@0.5/%	参数量/ $\times 10^6$	GFLOPS	帧率/fps
优化前	YOLOv12n	76.9	2.56	6.3	722
优化后	YOLOv12n	88	2.56	6.3	619

了 1.2%,有效增强了特征提取能力,使得特征信息更为丰富,从而提高了检测精度。使用新设计的 SEAM-Detect 检测头替换 YOLOv12n 的原检测头后,mAP 提升了 1.6%,并且参数量降低了 1%,表明 SEAM 模块进一步增强了特征提取能力,改善了小目标的漏检与误检问题。在 YOLOv12n 中加入 U-IoU 损失函数后,mAP@0.5 提升了 0.3%,U-IoU 不仅加速了模型收敛,还提升了检测精度。模型 6~8 通过结合不同改进方案进行消融实验,均表现出检测精度的提升。整体来看,YOLO-PCSU 模型在 mAP@0.5、参数量、GFLOPs 和帧率方面,相较于原 YOLOv12n 模型,均表现出明显优势。

表 5 YOLO-PCSU 模型的消融实验结果

Table 5 Ablation experimental results of the YOLO-PCSU model

模型	A2C2-PConv	CA	SEAM-Detect	U-IoU	mAP@50/%	参数量 $\times 10^6$	GFLOPs	帧率/fps
1					88	2.56	6.3	619
2	✓				89	2.45	5.3	679
3		✓			89.2	2.53	6.5	605
4			✓		89.6	2.51	6.7	648
5				✓	88.3	2.56	5.2	663
6	✓	✓			89.5	2.38	5.6	705
7	✓	✓	✓		89.9	2.31	5.4	685
8	✓	✓	✓	✓	90.3	2.31	5.4	674

3.6 鲁棒性验证

为验证改进模型的鲁棒性,分别在东北大学热轧带钢表面缺陷数据集(6类)和 VOC2012 数据集(20类)上对改进模型与原 YOLOv12n 模型进行了实验,具体方法为在铝材缺陷数据集上训练得到模型后,直接将其迁移至上述两个数据集进行测试,未进行任何微调或再训练,以评估模型在不同数据分

布下的泛化性能。实验结果如表 6 和 7 所示。从表 6 的实验结果可以看出,在东北大学热轧带钢表面缺陷数据集上,本文提出的 YOLO-PCSU 模型相比原 YOLOv12n 模型,mAP@0.5 提高了 1.3%,同时模型的计算量减少了 14%。在 VOC2012 数据集中改进模型比 YOLOv12n 模型在 mAP@0.5 提升了 1.6%,计算量降低了 11%。

表6 东北大学热轧带钢表面缺陷数据集实验结果

Table 6 Experimental results of the northeastern university hot-rolled strip steel surface defect dataset

模型	mAP@0.5/ %	GFLOPS	帧率/ fps	参数量 $\times 10^6$
YOLOv12n	78.9	6.3	432	2.56
YOLO-PCSU	80.2	5.4	460	2.31

表7 VOC2012 数据集鲁棒性实验结果

Table 7 Robustness experimental results of the VOC2012 dataset

模型	mAP@0.5/ %	GFLOPS	帧率/ fps	参数量 $\times 10^6$
YOLOv12n	71.5	6.3	750	2.56
YOLO-PCSU	73.1	5.6	753	2.31

4 结论

为改善铝型材表面缺陷检测中精度不足及小目标缺陷(如脏点、漆泡)漏检误检的问题,本文提出了一种基于YOLO-PCSU模型的检测方案。通过在骨干网络引入部分卷积设计了新的结构A2C2f-PConv代替原有结构,减少层层卷积造成的冗余计算;在骨干网络加入了CA协调注意力机制,增强了模型的特征提取能力。在检测头加入SEAM模块,能够增强忽略的特征信息,避免缺少特征信息造成的漏检问题;针对引入注意力和收敛率的矛盾问题,引入UIoU损失函数。实验结果表明,改进模型比原YOLOv12n算法mAP@0.5提升2.3%,参数量降低9%,计算量降低14%,改进模型检测精度提升并减少小目标缺陷漏检误检的问题,能够实现工业上铝型材表面缺陷的检测要求。未来,将继续对改进模型和铝型材缺陷检测进行研究,实现提升模型在更精细和复杂恶劣环境下整体检测性能。

参考文献

[1] 曾勇杰,范必双,杨涯文,等.改进YOLOv8算法在风机叶片缺陷检测上的应用[J].电子测量与仪器学报,2024,38(8):26-35.

ZENG Y J, FAN B SH, YANG Y W, et al. YOLOv8 algorithm is improved in the defect detection of wind turbine blades applications [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38 (8): 26-35.

[2] 苏立鹏,娄益凡,杨昊奔,等.基于改进Faster-RCNN的起重机钢丝绳表面缺陷识别方法[J].机电工程,2025,42(7):1341-1349.

SU L P, LOU Y F, YANG W B, et al. Method of surface defect recognition of crane wire rope based on improved Faster-RCNN[J]. Journal of Mechanical & Electrical Engineering, 2025, 42(7): 1341-1349.

[3] 杨莉,张亚楠,王婷婷,等.基于改进Faster R-CNN的钢材表面缺陷检测方法[J].吉林大学学报(信息科学版),2021,39(4):409-415.

YANG L, ZHANG Y N, WANG T T, et al. New method for steel surface defect detection based on improved faster R-CNN[J]. Journal of Jilin University (Information Science Edition), 2021, 39(4): 409-415.

[4] 陈利琼,梅后金,胡洪宣,等.基于改进Faster R-CNN的焊缝缺陷检测方法[J].科学技术与工程,2025,25(5):2027-2033.

CHEN L Q, MEI H J, HU H X, et al. Weld defect detection based on improved faster R-CNN method[J]. Science Technology and Engineering, 2025, 25 (5): 2027-2033.

[5] WEI L, SOLOHIN M I, ASTUTI W, et al. Surface defects detection of cylindrical high-precision industrial parts based on deep learning algorithms: A review[J]. Operations Research Forum, 2024, 5 (3), DOI: 10.1007/S43069-024-00337-5.

[6] 徐瑞杰,谢辉,姜吴瑾,等.融合多尺度注意力的轻量化初期林火检测算法[J/OL].电子测量技术,1-12[2025-04-22]. <https://link.cnki.net/urlid/11.2175.TN.20250401.1021.002>.

XU R J, XIE H, JIANG W J, et al. Lightweight early-stage forest fire detection algorithm integrating multi-scale attention [J/OL]. Electronic Measurement Technology, 1-12[2025-04-22]. <https://link.cnki.net/urlid/11.2175.TN.20250401.1021.002>.

[7] 赵亚凤,宋文华,刘晓璐,等.基于改进YOLOv7的钢轨缺陷检测方法[J].电子测量技术,2024,47(20):177-185.

ZHAO Y F, SONG W H, LIU X L, et al. Improved rail defect detection algorithm of YOLOv7 [J]. Electronic Measurement Technology, 2024, 47 (20): 177-185.

[8] 梁礼明,龙鹏威,金家新,等.基于改进YOLOv8s的钢材表面缺陷检测算法[J].浙江大学学报(工学版),2025,59(3):512-522.

LIANG L M, LONG P W, JIN J X, et al. Steel surface defect detection algorithm based on improved YOLOv8s [J]. Journal of Zhejiang University (Engineering Science), 2025, 59(3): 512-522.

[9] 崔克彬,焦静颐.基于MCB-FAH-YOLOv8的钢材表面缺陷检测算法[J].图学学报,2024,45(1):112-125.

CUI K B, JIAO J Y. Steel surface defect detection algorithm based on MCB-FAH-YOLOv8 [J]. Journal

of Graphics, 2024, 45(1):112-125.

[10] YANG S, WANG W, GAO S, et al. Strawberry ripeness detection based on YOLOv8 algorithm fused with LW-Swin Transformer [J]. Computers and Electronics in Agriculture, 2023, 215:108360.

[11] XIONG C, ZAYED T, ABDELKADER E M. A novel YOLOv8-GAM-Wise-IoU model for automated detection of bridge surface cracks[J]. Construction and Building Materials, 2024, 414:135025.

[12] 孙铁强,魏光辉,宋超,等.基于 YOLO 的多模态钢轨表面缺陷检测方法[J].电子测量技术,2024,47(21):72-81.

SUN T Q, WEI G H, SONG CH, et al. Multi-modal rail surface defect detection method based on YOLO [J]. Electronic Measurement Technology, 2024, 47(21):72-81.

[13] 李季村,郑鹏,李岩,等.融合 GhostBottleneck 及注意力机制的铝型材表面缺陷检测算法研究[J].现代制造工程,2025(3):115-123.

LI J C, ZHENG P, LI Y, et al. Research on an aluminum profile surface defect detection algorithm integrating GhostBottleneck and attention mechanism [J]. Modern Manufacturing Engineering, 2025(3):115-123.

[14] 吴葛,朱宇凡,叶天成.改进 YOLOv10 的钢材表面缺陷检测方法[J].电子测量技术,2025,48(4):158-168.

WU G, ZHU Y F, YE T CH. Improving the steel surface defect detection method of YOLOv10 [J]. Electronic Measurement Technology, 2025, 48(4):158-168.

[15] CHEN J, KAO S H, HE H, et al. Run, don't walk: Chasing higher FLOPS for faster neural networks [C]. 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), 2023.

[16] YU Z, HUANG H, CHEN W, et al. YOLO-FaceV2: A scale and occlusion aware face detector[J]. Pattern Recognition, 2024, 155:10.

作者简介

景会成,副教授,研究生导师,主要研究方向为机器视觉和缺陷检测。

E-mail:jinghc606@163. com

鲍成明(通信作者),硕士研究生,主要研究方向为机器视觉、目标检测和深度学习。

E-mail:3786180380@qq. com