

基于改进YOLOv8算法的焊缝缺陷检测研究

胡劭明, 罗柏文

湖南科技大学机电工程学院, 湖南 湘潭

收稿日期: 2026年4月22日; 录用日期: 2026年5月19日; 发布日期: 2026年5月27日

摘要

缺陷识别与分类是机器视觉焊缝缺陷检测流程的核心收尾环节。针对焊缝缺陷(如气孔、夹渣、裂纹、未熔合)特征微弱、易被噪声与背景纹理淹没的识别难题, 文章提出一种基于YOLOv8算法改进的YOLO-CCS模型。首先使用CSWinTransformer替换了原骨干网络的特征提取模块, 之后对其进行结构化通道剪枝, 降低模型参数量和计算量。其次在FPN-PAN网络中融合双注意力SimAM和CBAM形成AttentionFPNPAN颈部模块, 起到抑制焊接背景干扰和强化微小缺陷($\Phi 0.2\sim 2\text{ mm}$)特征的作用。同时新增P2微小缺陷检测头, 移除了原来的P5大目标检测头, 解决了对微小缺陷出现误检漏检的问题。结果表明, 训练后的精确率为92.3%, 召回率为90.2%, $mAP@0.5$ (%)达到90.3%, 效果优于其他主流算法。

关键词

焊缝缺陷, 微小缺陷, YOLOv8, CSWinTransformer

Research on Weld Defect Detection Based on Improved YOLOv8 Algorithm

Shaoming Hu, Baiwen Luo

School of Mechanical Engineering, Hunan University of Science and Technology, Xiangtan Hunan

Received: April 22, 2026; accepted: May 19, 2026; published: May 27, 2026

Abstract

Defect detection and classification constitute the critical concluding phase in machine vision-based weld defect inspection processes. To address the challenge of weak feature recognition for weld defects (e.g., porosity, slag inclusion, cracks, and incomplete fusion) that are easily obscured by noise and background textures, this study proposes an improved YOLO-CCS model based on the YOLOv8 algorithm. First, the original backbone network's feature extraction module is replaced with CSWinTransformer, followed by structured channel pruning to reduce model parameters and

computational complexity. The FPN-PAN network integrates dual attention mechanisms (SimAM and CBAM) in the AttentionFPNPAN neck module, effectively suppressing welding background interference while enhancing subtle defect ($\Phi 0.2\sim 2$ mm) detection. Additionally, a new P2 micro-defect detection head replaces the original P5 large-object detection head to resolve false detection and missed detection issues. Experimental results demonstrate a trained precision rate of 92.3%, recall rate of 90.2%, and $mAP@0.5\%$ score of 90.3%, outperforming other mainstream algorithms.

Keywords

Weld Defect, Micro Defect, YOLOv8, CSWinTransformer

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

焊接物件在我们身边无处不在,大到房屋结构,小到桌椅板凳,但焊接形成的焊缝往往因为各种因素形成焊缝缺陷,大幅降低了物件的使用寿命。现有技术大致分为物理检测法与机器视觉检测法两大类。其中物理检测法主要根据材料物理性质的不同来实现缺陷的识别,包括磁粉检测、超声检测、渗透检测、红外热成像检测[1]等。然而,物理检测因为其特殊性质在检测过程中经常出现检测效率低和检测流程复杂等情况,其检测结果还与检测环境和人工操作有很大关联,检测精度的稳定性难以保证。

为此急需检测效率高和检测精度高的焊缝缺陷检测方法,而基于机器视觉的检测方法往往可以满足这些要求。其中,深度学习方法在对缺陷的识别能力上有着明显优势。通过改进算法来进行特征融合,还能引进注意力机制等技术,提高特征增强能力。例如,Nowroth Christian [2]基于深度学习的焊接轮廓与激光束焊接半成品显微照片缺陷检测,实现焊缝特性的自动检测和量化;彭波[3]在检测大幅面管板焊缝研究中,通过在深度学习算法中将2D视觉与3D视觉相融合,提升了焊缝缺陷检测精度;程俊华[4]根据电磁涡流无损检测的理论基础,研究了基于深度学习的焊接缺陷电磁涡流检测及识别,结合电磁涡流特征,使得检测精度提高;王志鹏[5]在深度学习算法研究中,通过对传统Faster R-CNN算法的改进,来检测管道焊缝图像,在检测性能提升的同时还能适应复杂环境;肖文凯[6]主要研究怎么提高焊缝缺陷在无损缺陷检测状态下的性能,最终在卷积神经网络上进行改进,实现了焊缝缺陷自动化检测;彭洪晟[7]在研究X射线焊缝图像缺陷检测过程中,通过主流模型YOLOv4网络结构上的优化,提高检测精度;杨磊[8]主要研究一种自动焊接缺陷定位方法,在数字X射线图像U-net网络结构上进行改进,实现了缺陷自动定位;支泽林[9]为识别焊缝缺陷,通过CNN模块中的图像数据分析模块和特征分类模块,提出了DLFM模型和模式分类方法,DLFM模型可以在波形序列特征的基础上与深度学习网络模型进行融合;谷静[10]主要改进深度学习Faster RCNN模型算法,将其用于对小目标缺陷检测,解决常规深度学习对小目标缺陷检测精度不足和鲁棒性差的问题。

本文主要研究基于深度学习的焊缝缺陷检测方法,提出一种基于YOLOv8算法改进的YOLO-CCS模型,使算法面对复杂工业场景下也能稳定完成检测,有效改善了原有模型的不足,更适配工业产线在线检测的实际需求。

2. YOLO-CCS 缺陷检测网络

基于YOLOv8改进的YOLO-CCS模型,在原始YOLOv8骨干网络、颈部结构、检测头上进行改进,

主要通过替换原骨干网络增加双注意力模块, 增加微小缺陷检测头 P2, 移除大目标检测头 P5。YOLO-CCS 模型使用 CSWinTransformer [11]作为骨干网络, 输出多尺度原始特征, 在原颈部结构的 FPN-PAN 结构上融合双注意力机制进行特征增强融合, 将输出特征传递给缺陷预测输出模块。网络结构图见图 1:

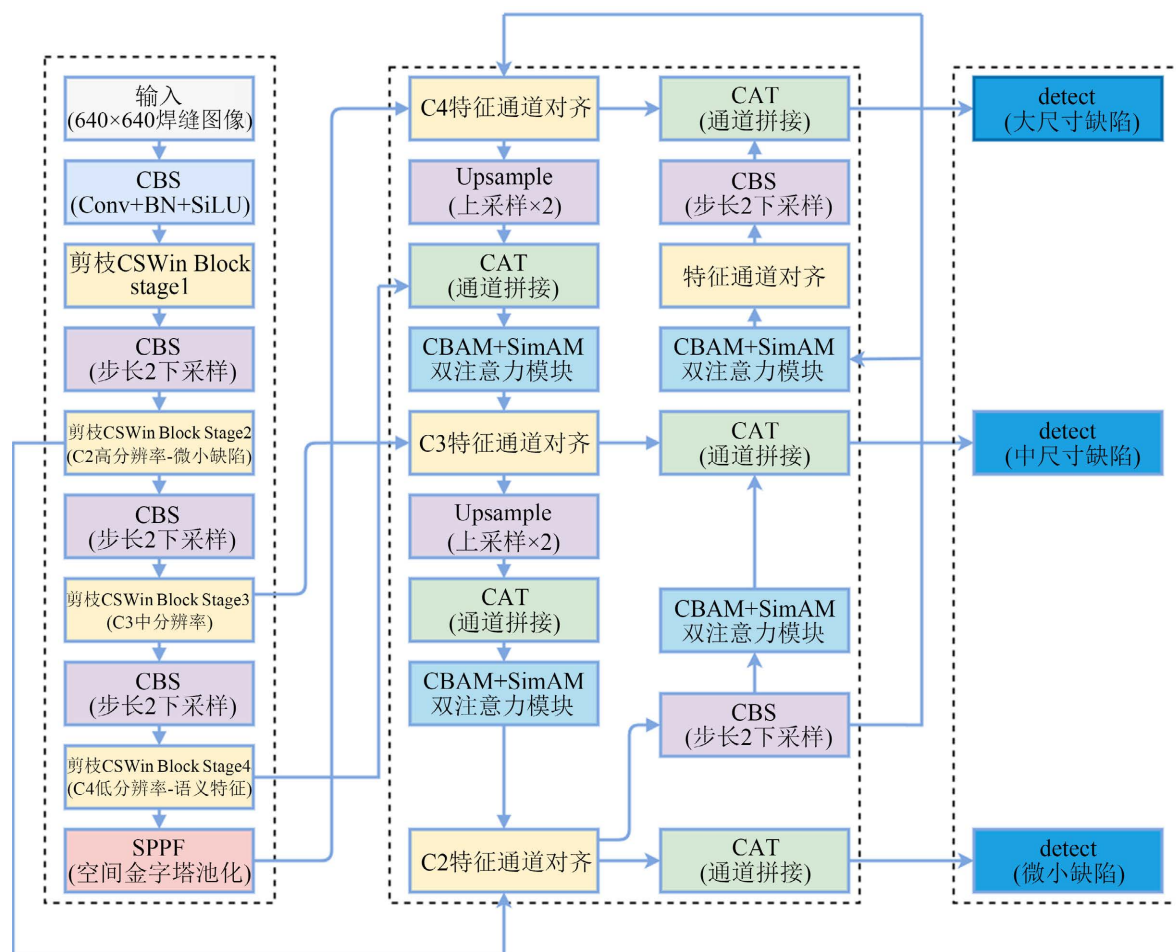


Figure 1. Network architecture diagram of the YOLO-CCS model

图 1. YOLO-CCS 模型网络结构图

2.1. CSwinTransformer 主干网络结构

原始的 YOLOv8 所用 CSPDarknet 卷积骨干存在“长距离特征依赖建模能力弱”的问题, 本模型将 YOLOv8 主干网络的 4 个 C2f 模块替换为 CSWinTransformer 模块, 通过其独特的“分块交叉注意力机制”, 实现焊缝图像中“细节 - 语义”双维度特征的高效提取。CSWinTransformer Block 模型架构图如图 2 所示。




Figure 2. CSwinTransformer block structure

图 2. CSwinTransformer block 结构

由图 2 可知, CSWinTransformer Block 首先执行层归一化(LN)操作, 将图像通过十字形窗口自注意力来联系特征之间的关系, 残差连接后再次进行归一化, 后经过多层感知器(MLP), 最后输出图像。

原 YOLOv8 的骨干网络分为 5 个阶段(Stage), 替换 CSWin Block 骨干主要是替换原生骨干 Stage2~Stage4, 其阶段是微小缺陷特征提取的重要阶段, 将此阶段的 C2f 模块全部替换为 CSWin Block, 保留原 Stage1 中的 CBS 和 C2f 模块以及 Stage5 的 SPPF 模块, 替换过程中保持通道数不变, 将 CSWin Block 嵌入 C2f 模块的残差分支中, 具体替换流程图见图 3:

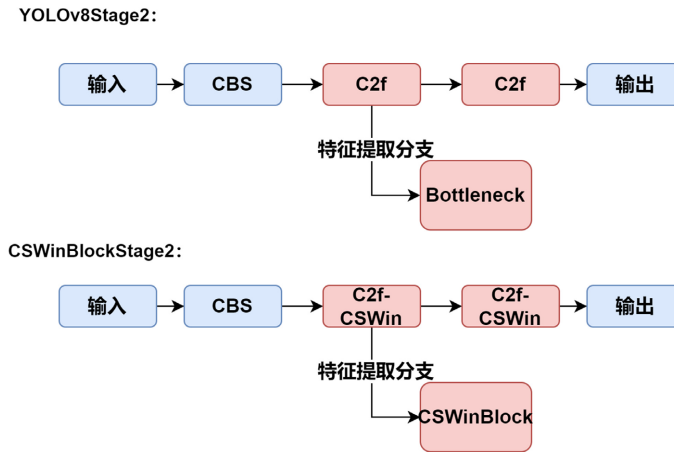


Figure 3. Comparison between original Stage2 and replacement
图 3. 原 Stage2 和替换后对比图

由图 3 可知, 替换结果保留了 C2f 的跨阶段残差连接的结构, 在 C2f 模块替换成 CSWin Block, 其中的特征提取分支 Bottleneck 替换成 CSWin Block 提取特征。其中 Stage3 和 Stage4 替换过程和 Stage2 一样。

由于 CSWin 的模型参数量和计算量都比较巨大, 在实际应用当中, 会操作显存的完全不足, 训练速度较慢的情况, 不符合工业实际需求, 所以为进一步优化模型的实时性与部署友好性, 本文对引入的 CSwin 模块进行结构化剪枝[12]。通过移除注意力机制中的冗余权重与无效通道, 显著降低模型参数量与计算量。剪枝结构见图 4:

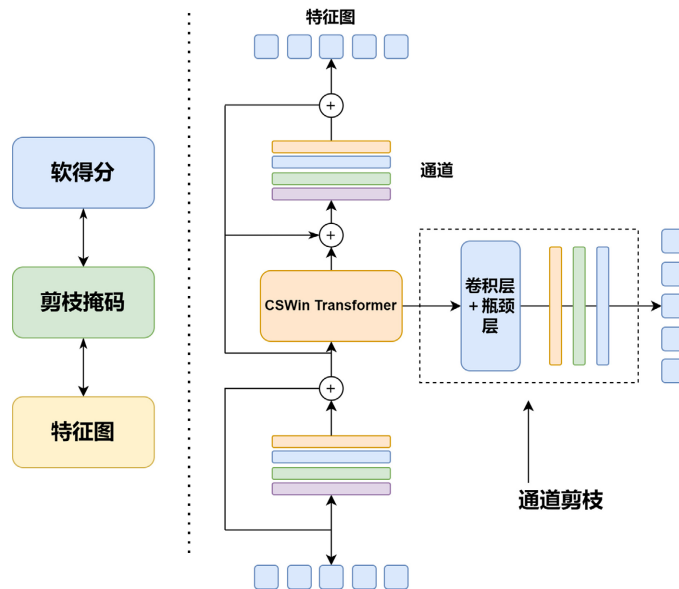


Figure 4. CSWinTransformer pruning vector diagram
图 4. CSWinTransformer 剪枝矢量图

本文依据注意力熵和梯度双维度的通道重要性评分来判断剪枝效果, 首先对特征图各通道计算软得分, 评估其对模型性能的重要性; 再依据得分生成剪枝掩码, 标记需保留或移除的通道; 最终在模型推理时, 掩码会过滤掉冗余通道与注意力权重, 实现结构化裁剪, 剪枝作用于 CSWin 的中间特征层: 输入特征图经上下残差模块与 CSWin 注意力模块提取特征后, 在瓶颈层执行通道剪枝, 仅保留高重要性通道; 剪枝后的特征再经卷积层处理, 最终输出轻量化特征。所以 CSWin 剪枝的核心是基于注意力熵加梯度的通道重要性评分, 而通道重要性评分计算是评分的核心。

2.2. FPN-PAN 颈部网络结构

原 YOLOv8Neck 的核心作用是通过 FPN (自上而下传递语义特征)和 PAN (自下而上传递细节特征), 完成不同层级特征的融合。针对该问题, YOLO-CCS 在原 FPN-PAN 结构融合 CBAM (通道与空间注意力机制) [13]与 SimAM (单样本注意力机制) [14]形成双注意力优化模块 AttentionFPNPAN 模块。FPN-PAN 结构是将特征金字塔网络(FPN)的“自上而下”语义传递与路径聚合网络(PAN)的“自下而上”细节补充结合, 形成双向特征融合通路。

在 YOLOv8 的特征融合结构中, FPN-PAN 是负责多尺度特征传递与融合的核心骨架, 而 CBAM (Convolutional Block Attention Module)是嵌入其中的注意力增强模块, CBAM 的主要原理是通过关注重要的特征并抑制不必要的特征来增强网络的表示能力。模块首先输入通道注意力, 得到重要特征, 然后输出到空间注意力, 关注这些特征的“重要位置”。原理结构图见图 5。




Figure 5. CBAM structure diagram
图 5. CBAM 结构图

由图 5 可知, CBAM 融合了通道注意力和空间注意力输入是一个中间特征图。将特征图输入至通道注意力模块(Channel Attention Module)获取通道注意力, 注意力权重作用在中间特征图。然后, 输出的特征图输入至空间注意力模块(Spatial Attention Module)获取空间注意力, 最后将注意力权重作用到特征图上, 得到优化后的特征。

在 YOLOv8 的 FPN-PAN 特征融合结构中, 本次研究引入 SimAM 模块作为轻量化注意力增强单元, 通过能量函数计算特征图中每个神经元的重要性, 能够精准抑制焊缝表面的氧化皮、飞溅等背景噪声, 进一步强化微小缺陷的有效特征。




Figure 6. SimAM structural diagram
图 6. SimAM 结构图

SimAM 直接生成 3D 全维度注意力权重, 基于能量函数计算每个神经元在通道、高度、宽度三维空间的重要性, 无需额外训练参数即可实现通道与空间维度的自适应增强。在焊缝缺陷检测场景中, SimAM

的 3D 权重能够精准抑制背景噪声, 增强微小缺陷的特征, 提升微小缺陷的检测精度。SimAM 模块原理结构图见图 6。

2.3. 双注意力模块 AttentionFPNPAN

双注意力模块 AttentionFPNPAN 是将 CBAM 和 SimAM 分为双注意力机制与 FPN-PAN 特征金字塔网络互相融合优化后的一个颈部模块, 主要用于目标检测任务中对多尺度特征进行增强和融合, 通过 CBAM 和 SimAM 进行优势上的互补, 精准地插入 FPN-PAN 结构中。

此模块以 YOLOv8 的 FPN-PAN 结构双向特征融合架构为基础, 整体结构从 FPN 自上而下的特征传递到 PAN 的自下而上的细节特征传递, 其中包括多尺度特征输入、融合双注意力 CBAM 和 SimAM、多尺度特征输出等部分。移除了原 FPN-PAN 结构中的 P5 大目标检测头, 新增 P2 微小缺陷检测头。

融合双注意力 CBAM 和 SimAM 中, 特征图先到 CBAM 模块, 从通道和空间维度筛选出与缺陷相关的特征通道和区域, 抑制焊接过程中飞溅等背景干扰, 在特征冗余的情况下, 淡化冗余特征, 输出的特征图在 SimAM 模块中从神经元层面, 进一步强化焊缝缺陷特征, 降低背景噪声干扰, 最后输出特征图到检测头。

在原 YOLOv8 的 FPN-PAN 结构中, 共有 6 个核心的特征融合节点。本文将 CBAM 和 SimAM 双模块均插入在特征拼接与 C2f 模块后, 具体见图 7:

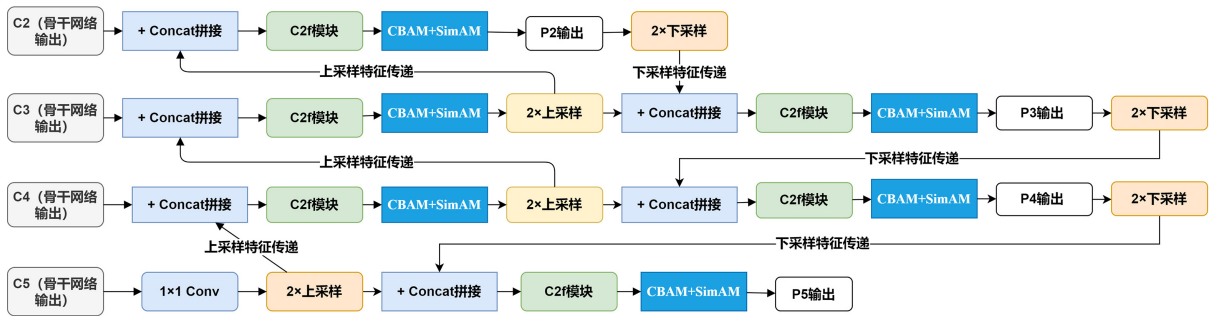


Figure 7. Structural diagram of FPN-PAN architecture integrating CBAM and SimAM modules
图 7. CBAM 和 SimAM 模块融合 FPN-PAN 结构图

图 7 中深蓝色是插入 CBAM 和 SimAM 双模块的位置, 在特征拼接与 C2f 模块完成多尺度特征融合后, 插入双注意力模块, 在每个特征融合节点后加入双注意力, 起到对浅层特征的增强效果。

本文双注意力模块的嵌入架构区别于原 FPN-PAN 结构, 在全部 6 个特征融合节点, 均将双注意力模块嵌入在 Concat 特征拼接与 C2f 特征提纯操作之后: 特征拼接与 C2f 模块已完成跨尺度特征的融合与基础提纯, 此时嵌入注意力模块, 可精准聚焦焊缝缺陷的有效特征, 对焊缝图像周围的特征干扰起到淡化特征作用, 同时放大微小缺陷的微弱特征。针对 C2、C3 对应的浅层特征融合节点, 本文对 CBAM 模块的空间注意力权重进行了优化, 提升了空间注意力的权重占比, 在对微小缺陷的空间细节特征上进行强化。针对 C4、C5 对应的深层特征融合节点, 提升通道注意力的权重占比, 重点优化缺陷类别的语义区分能力, 实现了对不同层级特征的差异化增强。

3. 实验结果与分析

3.1. 实验设定

本章以 WSDD (Welding Surface Defect Dataset) 公开数据集和商用数据集(AKZN)作预实验, 其中完成

模型预训练图像经过多种预处理, 适用于分类、目标检测等任务。WSDD 数据集经过挑选出气孔、裂纹、夹渣、未熔合四类缺陷, 其中原始焊缝缺陷图像 1315 张, AKZN 数据集含 1157 张原始焊缝缺陷图像, 总共 2472 张原始图像。采用 LabelImg 工具对图像进行标注划分。经过标记后的数据集划分为训练集、验证集和测试集, 其中 70% 为训练集、20% 为验证集、10% 为测试集。

针对微小缺陷样本少的问题, 采用不同光照、不同角度拍摄对数据扩增。对图像进行随机角度旋转图像; 对图像的亮度进行随机调整; Copy-Paste 小目标增强(每张图片至少采用 3 种方式中的两种进行处理)。

图像扩增后, 数据集图像达到原数据集的 6 倍, 共 14,562 张。其中训练集共 10,193 张, 测试集共 1456 张, 验证集共 2913 张。数据集每张图像中至少含有一个焊缝表面缺陷, 分析数据集中训练集、测试集与验证集标签数后可得表 1。

Table 1. Number of defects after data enhancement

表 1. 数据增强后缺陷数量表

表面缺陷	气孔	裂纹	夹渣	未熔合
测试集	439	411	492	230
训练集	3074	2877	3444	1613
验证集	879	822	984	461
总计	4392	4110	4920	2304

经过数据增强后, 数据集图像达到 14,562 张, 在后续机器深度学习中, 能够积累大量经验, 足以满足训练要求。

针对焊缝表面缺陷数据集的试验以及测试的试验平台软硬件所有试验平台, 其中 CPU 为 12vCPUIntel(R)Xeon(R)Platinum8260CPU@2.40GHz、GPU 为 vGPU-32 GB (32 GB); 显存为 32 G、内存为 64 G; CUDA 版本为 12.8; 使用 64 位 Windows 10 的操作系统; 语言使用 Python 3.12 进行编程。

在深度学习目标检测中, 常用的评价指标有以下几种: 平均精确率均值(mean Average Precision)、精确率(Precision)、召回率(Recall)、模型参数量(Parameter)、精确率(Precision, 指的是算法检测出的目标框中真实目标的比例)。相关评估指标计算见公式(1)~(4):

$$P = \frac{TP}{TP + FP} \times 100\% \quad (1)$$

$$R = \frac{TP}{TP + FN} \times 100\% \quad (2)$$

$$AP = \int_0^1 PdR \quad (3)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i \quad (4)$$

式中 P 为精确率, TP 为预测正确的正样本框数量, FP 为预测错误的正样本框数量; R 为召回率, FN 为遗漏的样本框的数量; AP 为平均精确率, AP_i 表示第 i 类目标检测的平均精确率; n 表示标记的类别, mAP 表示平均精确率均值; T 表示处理一帧所需要的时间, 单位为秒(s)。

为保证实验结果的客观性, 所有实验均在相同软硬件环境和训练参数下进行实验。训练配置如表 2 所示:

Table 2. Training parameters

表 2. 训练参数

参数名称	参数值
批量大小	16
输入图像尺寸	640 × 640
训练轮次	200
优化器	AdamW 优化器
初始学习率	0.01
权重衰减	0.0005
损失函数	CloULoss
目标分配策略	SimOTA

3.2. 消融实验

本章还需要对本文提出的多项改进策略进行消融实验，以逐一验证各模块对模型检测性能的提升作用。实验以 YOLOv8s 为基线模型，严格遵循单一变量原则，分别嵌入不同改进模块构建多组对照模型，各组模型的消融实验结果汇总如表 3 所示：

Table 3. Table of ablation experiment results for six models compared with the YOLO-CCS model

表 3. 六种模型与 YOLO-CCS 模型消融试验结果表

实验组号	CSWinTransformer	剪枝	双注意力模块	新增 P2	精确率 P (%)	召回率 R (%)	$mAP@0.5$ (%)	参数量(M)	FPS
1	×	×	×	×	81.6	73.2	82.9	11.66	112
2	√	×	×	×	86.6	81.6	86.8	12.89	98
3	√	√	×	×	86.2	80.9	86.1	6.45	105
4	×	×	√	×	85.6	82.7	86.8	11.7	108
5	×	×	×	√	85.6	81.7	85.4	11.02	106
6	√	√	√	×	88.7	87.6	88.5	6.49	101
7	√	√	√	√	92.3	90.2	90.3	5.83	96

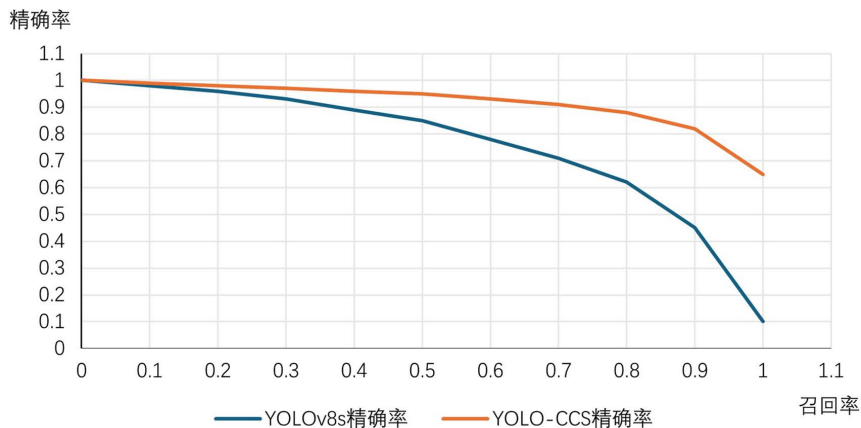


Figure 8. Precision-regression curve

图 8. 精度 - 回归曲线

从表 3 消融试验可以看出, 实验 3 对比实验 2, 进行剪枝后参数量下降到 6.45 M, FPS 提升了 7, 但是 $mAP@0.5$ 只下降了 0.7 百分点, 说明此次剪枝实现了轻量化。实验 4 对比实验 1 仅增加双注意力, $mAP@0.5$ 提升了 3.9 百分点, 说明此次优化增加了对微小缺陷的特征提取能量。实验 5 对比实验 1, 增加 P2 微小缺陷检测头, 移除 P5 大目标检测头, $mAP@0.5$ 提升了 2.5 百分点, 说明此次优化提升了对微小缺陷的检测能力。实验 7 为 YOLO-CCS 模型, 融合所有改进模块, 对比 YOLOv8s, $mAP@0.5$ 提升了 7.4 百分点, 召回率提升了 17 百分点, 参数量也下降了 50%。可以看出, YOLO-CCS 不管是在检测精度上, 还是模型的轻量化上都有很大的提升。改进模型的精度 - 回归曲线对比(Precision-Recall)如图 8 所示。




Figure 9. Comparison of mAP between the improved model and YOLOv8s during training

图 9. 改进后模型与 YOLOv8s 训练时 mAP 对比图

如图 8 精度 - 回归曲线展示了在不同阈值下的准确率和召回率之间的关系, 相同召回率下, YOLO-CCS 模型的精度比 YOLOv8s 更高, 说明改进后的 YOLO-CCS 模型具有较好的性能稳定性。其 $mAP@0.5$ 对比如图 9 所示。

图 9 中可知, YOLO-CCS 模型的检测精度曲线始终在原模型之上, 同时收敛速度更快, 在 160 轮左右即将收敛, 最终值也高于原模型 YOLOv8s。YOLO-CCS 模型边界框回归损失对比如图 10 所示。




Figure 10. Comparison of bounding box regression loss between YOLO-CCS and YOLOv8s

图 10. YOLO-CCS 与 YOLOv8s 边界框回归损失对比图

由图 10 可知, YOLO-CCS 模型的边界框回归损失下降速度更快, 最终收敛的损失值更低, 说明改进后模型定位精度更高, 更适合对微小缺陷特征的定位。

3.3. 对比实验

为了客观地展示改进模型的优势, 试验将改进模型与当前主流模型进行了比较。各模型对比结果如表 4 所示。

Table 4. Comparison of experimental results among different models

表 4. 不同模型对比实验结果表

算法模型	精确率 P (%)	召回率 R (%)	$mAP@0.5$ (%)	参数量(M)	FPS
Faster-RCNN	78.5	72.1	77.4	43.8	24
YOLOv5s	80.4	76.3	78.5	7.2	105
YOLOv8s	81.6	73.2	82.9	11.66	112
YOLOv10s	84.2	78.5	85.1	7.5	118
EfficientDet-D0	83.5	80.2	83.4	3.9	86
TOOD	87.1	83.3	86.6	8.1	92
YOLO-CCS	92.3	90.2	90.3	5.83	96




Figure 11. Comparison of detection results

图 11. 检测结果对比图

对比试验包括针对小目标检测的 TOOD [15], 轻量级小目标检测模型 EfficientDet-D0 [16], 双阶段算法中 Faster-RCNN 模型[17], 单阶段算法中 YOLOv5s [18]、YOLOv8s、YOLOv10s [19], 以及本文的改进模型 YOLO-CCS。在所有的对比模型中, 本文 YOLO-CCS 模型的 $mAP@0.5$ 达到了 90.3%, 是其中最高的, 相比双阶段算法 Faster-RCNN 模型, 提升了 7.4 个百分点, 相比 YOLOv10s 也提升了 5.2 个百分点。专门进行小目标检测的 TOOD 也有提升 3.7 个百分点。其充分体现了改进后的模型在检测精度上有很大提升。

相比轻量级小目标检测模型 EfficientDet-D0, 虽然参数量高于它, 但是 $mAP@0.5$ 比改进后的模型低了 6.9 个百分点, 召回率也比改进后的模型低了 10 个百分点。因此, 本文设计的 YOLO-CCS 模型在微小缺陷检测中, 能够在提升检测精度的同时, 有效降低由背景干扰引起的伪缺陷的误检率与漏检率。

为了充分说明本文改进模型的有效性, 选用 YOLOv8s 模型与本文 YOLO-CCS 模型对部分验证集图像进行检测对比, 以展示本文检测模型的检测性能。比较结果如图 11 所示。

对比了裂纹、气孔和未熔合三类典型焊缝缺陷的检测可视化结果可知, YOLO-CCS 模型的缺陷检测性能显著优于 YOLOv8s 基准模型。针对裂纹缺陷, YOLO-CCS 模型识别精度远大于 YOLOv8s, YOLOv8s 在对微小气孔识别中出现误检情况, 将裂纹识别成气孔。在其他缺陷的检测精度上, YOLO-CCS 模型置信度均有很大提升, 且在未熔合缺陷达到 0.9, 这表明融合 SimAM 与 CBAM 的双注意力 Attention-FPN-PAN 模块在对微小缺陷特征提取上起到很大的增强作用。

4. 结语

本文主要解决焊缝微小缺陷气孔、裂纹、夹渣、未熔合四类缺陷难识别问题; 同时为实现模型轻量化, 基于 YOLOv8 架构进行了改进, 提出面向焊缝缺陷检测的 YOLO-CCS 轻量化改进模型。具体改进路径如下: 采用 CSWinTransformer 替换原骨干网络的特征提取模块, 随后进行结构化通道剪枝, 大幅降低了模型的参数量与计算量; 在 FPN-PAN 颈部网络中融合双注意力模块, 有效抑制焊接背景干扰, 强化微小缺陷特征表达; 新增 P2 微小缺陷检测头并移除原 P5 大目标检测头, 针对性解决了微小缺陷易误检漏检的问题。最后通过多组消融对比实验验证, 改进后的模型 $mAP@0.5$ 较原生 YOLOv8s 提升 7.4 个百分点, 参数量降低 50%, 与现有主流算法相比, 本文算法综合比较更有优势。

参考文献

- [1] 李砚峰, 刘翠荣, 孙前来, 等. 基于机器视觉的机械钢板焊缝缺陷检测技术应用——评《焊接机械基础》[J]. 机械设计, 2020, 37(10): 149.
- [2] Nowroth, C., Gu, T., Grajczak, J., Nothdurft, S., Twiefel, J., Hermsdorf, J., et al. (2022) Deep Learning-Based Weld Contour and Defect Detection from Micrographs of Laser Beam Welded Semi-Finished Products. *Applied Sciences*, **12**, Article No. 4645. <https://doi.org/10.3390/app12094645>
- [3] 彭波, 曹毅, 邓徐韬, 等. 基于机器视觉的大幅面管板焊缝检测方法与系统设计[J]. 东方电气评论, 2023, 37(3): 62-66.
- [4] 程俊华. 基于深度学习的焊接缺陷电磁涡流检测及识别[D]: [硕士学位论文]. 天津: 天津工业大学, 2023.
- [5] 王志鹏. 基于改进的 Faster R-CNN 的焊缝缺陷检测研究[D]: [硕士学位论文]. 北京: 北京交通大学, 2023.
- [6] 肖文凯, 南水鱼, 张琳琳. 基于卷积神经网络的 X 射线焊缝缺陷检测算法研究[J]. 自动化仪表, 2022, 43(8): 67-72.
- [7] 彭洪晟. 深度学习在 X 射线焊缝图像缺陷检测中的应用研究[D]: [硕士学位论文]. 武汉: 武汉工程大学, 2022.
- [8] Yang, L., Wang, H., Huo, B., Li, F. and Liu, Y. (2021) An Automatic Welding Defect Location Algorithm Based on Deep Learning. *NDT & E International*, **120**, Article ID: 102435. <https://doi.org/10.1016/j.ndteint.2021.102435>
- [9] 支泽林, 姜洪权, 杨得焱, 等. 图谱数据深度学习融合模型及焊缝缺陷识别方法[J]. 西安交通大学学报, 2021, 55(5): 73-82.
- [10] 谷静, 谢泽群, 张心雨. 基于改进深度学习模型的焊缝缺陷检测算法[J]. 宇航计测技术, 2020, 40(3): 75-79+87.

- [11] Sun, H., Fu, R., Wang, X., Wu, Y., Al-Absi, M.A., Cheng, Z., *et al.* (2025) Efficient Deep Learning-Based Tomato Leaf Disease Detection through Global and Local Feature Fusion. *BMC Plant Biology*, **25**, Article No. 311. <https://doi.org/10.1186/s12870-025-06247-w>
- [12] 周舟, 王海鹏, 徐丰, 等. 基于通道剪枝的 SAR 图像舰船检测优化算法[J]. 上海航天(中英文), 2020, 37(4): 48-54.
- [13] Chen, B., Zhang, Z., Liu, N., Tan, Y., Liu, X. and Chen, T. (2020) Spatiotemporal Convolutional Neural Network with Convolutional Block Attention Module for Micro-Expression Recognition. *Information*, **11**, Article No. 380. <https://doi.org/10.3390/info11080380>
- [14] Shi, C., Zhu, D., Zhou, C., Cheng, S. and Zou, C. (2024) Gpmb-yolo: A Lightweight Model for Efficient Blood Cell Detection in Medical Imaging. *Health Information Science and Systems*, **12**, Article No. 24. <https://doi.org/10.1007/s13755-024-00285-8>
- [15] 郑有凯, 胡君红, 田春欣. 基于自适应特征融合和任务对齐的小目标检测算法[J]. 激光杂志, 2024, 45(2): 36-42.
- [16] 崔学智, 冯全, 王书志, 等. 边缘设备上的葡萄园田间场景障碍检测[J]. 中国农机化学报, 2021, 42(9): 150-156.
- [17] 曹晋晋. 基于改进的 Faster-RCNN 的焊缝特征提取[J]. 科技与创新, 2023(18): 63-67.
- [18] 周翌晨, 虞旦, 李佳成, 等. 基于改进 YOLOv5 的焊缝识别算法研究[J]. 制造技术与机床, 2024(7): 19-25.
- [19] 侯芯露, 黄凌霄, 姚新波, 等. 基于多版本 YOLO 模型的工业缺陷检测性能对比研究[J]. 电脑知识与技术, 2025, 21(31): 20-25.