

DOI:10.19651/j.cnki.emt.2416084

基于改进 YOLOv8n 的钢材表面缺陷检测*

赵洋^{1,2} 王军凯^{1,2} 林志毅^{1,2} 周忠祥^{1,2} 徐森^{1,2}

(1. 沈阳化工大学计算机科学与技术学院 沈阳 110142; 2. 辽宁省化工过程工业智能化技术重点实验室 沈阳 110142)

摘要: 为解决钢材表面缺陷检测中面临的缺陷类型繁多、尺寸差异显著以及现有模型复杂度高、检测精度不足等问题,本文提出了一种基于改进 YOLOv8n 的检测算法 YOLOv8-ODAW。首先,引入全维动态卷积(ODConv)增强对多维度特征的捕捉能力,减少信息损失;其次,嵌入渐进特征金字塔网络(AFPN)改善特征融合过程,实现了非相邻层级特征间的直接交互,有效缓解语义断层。最后,采用动态非单调聚焦机制的 Wise-IoUv3 损失函数优化边界框回归,加快网络收敛的同时提高检测精度。在 NEU-DET 数据集上进行多组实验,结果表明,改进后的 YOLOv8-ODAW 网络模型相比原网络模型 mAP50% 提升了 7.3%、GFLOPs 下降了 21.95%,展现出对钢材表面缺陷更佳的定位与识别能力,且检测速度满足工业应用需求。

关键词: 钢材;缺陷检测;YOLOv8n;全维动态卷积;渐进特征金字塔网络;Wise-IoUv3

中图分类号: TN911 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Steel surface defect detection algorithm based on improved YOLOv8n

Zhao Yang^{1,2} Wang Junkai^{1,2} Lin Zhiyi^{1,2} Zhou Zhongxiang^{1,2} Xu Sen^{1,2}

(1. School of Computer Science and Technology, Shenyang University of Chemical Technology, Shenyang 110142, China;

2. Liaoning Provincial Key Laboratory of Chemical Process Industry and Intelligent Technology, Shenyang 110142, China)

Abstract: To address the challenges posed by the diverse types of defects, significant size variations, and high complexity of existing models with insufficient detection accuracy in steel surface defect detection, this paper proposes a detection algorithm named YOLOv8-ODAW based on an improved YOLOv8n. Firstly, Omni-dimensional Dynamic Convolution (ODConv) was introduced to enhance the capability of capturing multi-dimensional features and reduce information loss. Secondly, an Asymptotic Feature Pyramid Network (AFPN) was embedded to improve the feature fusion process, enabling direct interaction between non-adjacent level features and effectively alleviating semantic disconnection. Finally, the Wise-IoUv3 loss function with a dynamic non-monotonic focusing mechanism was adopted to optimize bounding box regression, accelerating network convergence while improving detection accuracy. A series of experiments were conducted on the NEU-DET dataset, and the results demonstrated that the modified YOLOv8-ODAW network model outperformed the original network model with a 7.3% increase in mAP at 50% and a 21.95% decrease in computational complexity (GFLOPs). This showcases superior localization and recognition capabilities for steel surface defects while meeting the speed requirements for industrial applications.

Keywords: steel; defect detection; YOLOv8n; omni-dimensional dynamic convolution (ODConv); asymptotic feature pyramid network (AFPN); Wise-IoUv3

0 引言

钢材作为现代建筑的核心材料,凭借其高强度、高韧性及优良的可加工性,不仅在日常生活用品制造中发挥关键作用,更在国家基础设施建设领域占据举足轻重的地位。钢材的性能与其表面状态密切相关。生产工艺的差异、实际应

用环境的复杂性以及使用年限的增长等因素均可能导致钢材表面出现裂纹、斑点及划痕等各类缺陷。这些表缺陷不仅直接影响钢材的韧性、塑性及疲劳强度,还在电力传输、交通运输及化学工业等高风险领域构成重大的安全隐患。因此,强化钢材表面缺陷检测技术对于确保产品质量、提升经济效能以及维护社会公共安全具有至关重要的意义。

收稿日期:2024-05-21

* 基金项目:辽宁省教育厅基本科研项目面上项目(LJKMZ20220782)资助

目前,钢材表面缺陷检测主要依赖人工目检、磁粉探伤、涡流检测、激光扫描和红外成像等技术。尽管此类技术已在一定程度上成功实现了缺陷的识别与定位,但由于其效率低、缺陷分类难度较高、设备成本昂贵且应用条件苛刻,难以大规模应用。在此背景下,机器视觉技术,特别是深度学习驱动的目标检测算法,凭借其高实时性、高精度等优势,成为解决该问题的研究热点。基于深度学习的目标检测算法可分为两类:一是基于滑窗或候选区域生成的两阶段方法,典型代表为 R-CNN 系列(包括 R-CNN、Fast R-CNN 和 Faster R-CNN^[1]),此类方法先产生可能包含目标物体的候选区域,再进行精细分类与边界框回归;二是以 SSD^[2](single shot multibox detector)与 YOLO(you only look once)^[3]为代表的单阶段方法,此类方法通过一次前向传播直接从输入图像中预测出目标物体的位置及其类别,简化检测流程的同时提高了运行速度,更符合工业级实时检测的需求。

综上所述,深度学习驱动的目标检测技术有望克服传统方法的局限性,为实现高效、精准且普适性强的钢材表面缺陷检测提供强有力的技术支撑。目前已有许多研究将深度学习目标检测算法应用在钢材表面缺陷检测领域。陆家林等^[4]提出了一种改进 Faster R-CNN 的钢材表面缺陷算法,通过融合 VGG-16 网络中 Block3 与 Block5 层级特征,并采取双 IOU 阈值级联策略,增强了对候选区域的精确分类与定位能力,提升了整体检测精度。然而两阶段检测方法涉及后期处理环节,推理速度较低。阎馨等^[5]对 SSD 算法进行改进以应用于钢材表面缺陷检测,通过引入 Transformer 的多头注意力机制来提升对小尺寸缺陷的识别能力。但这种侧重于高分辨率小目标的关注方式,导致对小目标缺陷的检测精度下滑,且整体检测速度下降。蒋博等^[6]提出了一种改进 YOLOv5 的轻量化钢材表面缺陷检测模型,该模型选用 MobileNetv3-Small 作为 YOLOv5s 的主干网络,同时融入加权双向特征金字塔结构,并加入 CBAM 注意力机制,旨在提高检测速度并实现模型轻量化。然而,尽管轻量化措施有效地减少了模型参数量,但不可避免地削弱了网络的非线性表达能力,从而对精度产生一定负面影响。Ye 等^[7]结合 Swin-Transformer 架构,提出一种改进 YOLOv7 的表面裂纹检测方法,提升了检测精度,然而,其引入的特征提取模块造成网络推理时计算负担,无法确保实时响应,限制了其在边缘设备上的部署可行性。

针对当前钢材表面缺陷检测算法在精确度与模型体积方面的局限性,本研究通过系统分析各类钢材表面缺陷的独特属性,提出了一种基于改进 YOLOv8n 算法的创新检测模型,即 YOLOv8-ODAW。该算法在骨干网络中嵌入全维动态卷积模块,从多个维度捕捉和提炼钢材表面缺陷的细微特征,从而增强模型对缺陷信息的敏感性和识别能力;其次,在特征融合模块引入渐进特征金字塔结构,通过

层次化的特征融合机制,实现了对不同尺度缺陷的有效整合;此外,采用 Wise-IoUv3 损失函数替换传统的 CIoU 损失函数,加速收敛的同时提高回归精度。YOLOv8-ODAW 模型在不增加参数量的前提下,显著提升了钢材表面缺陷的检测效率和准确率,为深度学习技术在钢材质量控制领域的应用提供了理论支撑和实践指导。

1 YOLOv8 算法概述

YOLOv8 算法由 Ultralytics 公司推出,提供 n/s/m/l/x 五种不同尺度的模型,由于钢材表面缺陷检测需工业化应用,须同时考虑检测精度和检测速度,所以采用 YOLOv8n 网络模型。其整体架构可细分为 Input、Backbone、Neck 和 Head 四个部分。在 Input 阶段,图像被适配至训练所需尺寸,同时进行 Mosaic 数据增强^[8]。Backbone 部分借鉴 YOLOv7 的 ELAN^[9]设计理念,采用梯度流更为丰富的 C2f 结构。Neck 部分沿用特征金字塔(feature pyramid network, FPN)与路径聚合结构(path aggregation network, PAN)构建多尺度特征融合的金字塔^[10]。Head 部分摒弃了 Anchor-Based 机制转向 Anchor-Free 设计,并引入当前主流的解耦头结构,将分类与检测任务分别交由独立的分类头与检测头处理;在样本匹配方面,采用了 TaskAlignedAssigner 的动态正样本分配策略^[11];在损失函数方面,分类分支仍然采用 BCE Loss 作为分类损失,回归分支则采用 DFL(distribution focal loss)和 CIoU(complete intersection over union)^[12]作为回归损失。

2 YOLOv8n 算法改进

2.1 全维动态卷积

由于钢材表面缺陷尺度不一,传统卷积可能导致细粒度的信息丢失或者低效的特征学习。为此,本文使用全维动态卷积(omni-dimensional dynamic convolution, ODConv)^[13]替代特征提取网络的部分卷积下采样。该方法创新性地运用多维注意力机制,在卷积核空间的全部 4 个维度(空间尺寸、输入通道数、输出通道数及卷积核个数)上并行学习互补的注意力权重,以针对性地调整卷积操作在各维度的敏感性,从而更好地捕捉输入数据中复杂的上下文信息,增强模型的适应性和特征提取能力。其结构如图 1 所示。

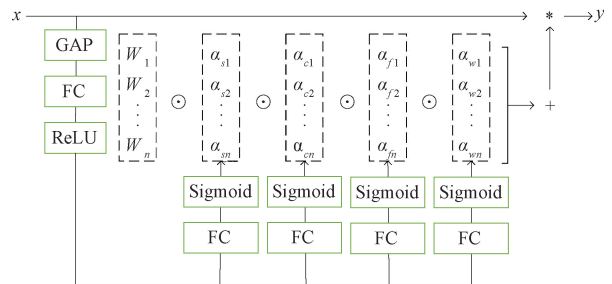


图 1 ODConv 结构示意图

Fig. 1 ODConv structure diagram

其对卷积核应用注意力的过程如图 2 所示。具体而言:

- 1)空间维度:利用 $k \times k$ 大小的注意力矩阵 α_{si} , 对卷积核的空间位置进行位置级加权, 使模型对输入图像不同空间位置产生差异化的响应, 如图 2(a)所示。
- 2)输入通道维度:通过一维向量 α_{ci} , 对输入通道进行注意力加权, 增强模型对输入特征不同通道信息的区分能

力, 如图 2(b)所示。

- 3)输出通道维度:运用长度为 c_{out} 的一维向量 α_{fi} , 差异化处理各输出滤波器, 使模型能根据输入内容动态调整各输出通道的重要性, 如图 2(c)所示。
- 4)卷积核数量维度:使用标量 α_{wi} 赋予单个卷积核全局注意力权重, 调整其整体影响力, 如图 2(d)所示。

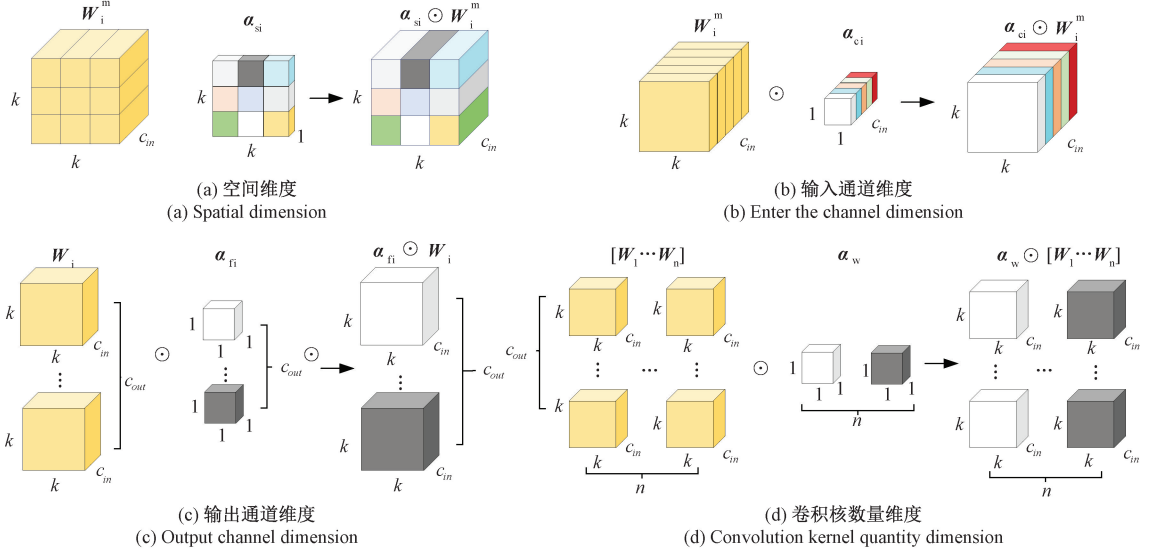


图 2 应用 4 种注意力的过程

Fig. 2 The process of applying four types of attention

其定义如式(1)所示:

$$y = \left(\sum_{i=1}^n \alpha_{si} \odot \alpha_{ci} \odot \alpha_{fi} \odot \alpha_{wi} \odot W_i \right) * x \quad (1)$$

式中: $\alpha_{wi} \in \mathbb{R}$ 表示卷积核 W_i 的关注标量, $\alpha_{si} \in \mathbb{R}^{k \times k}$ 、 $\alpha_{ci} \in \mathbb{R}^{c_{in}}$ 、 $\alpha_{fi} \in \mathbb{R}^{c_{out}}$ 表示空间维度、输入通道维度和输出通道维度的注意力; \odot 表示沿不同维度的卷积核空间的乘法操作, $*$ 表示卷积操作。

全动态卷积凭借多维注意力机制, 显著提升特征提取能力和模型精度。实验表明, ODCConv 在钢材表面缺陷任务中表现出优越性能。

2.2 渐进特征金字塔网络

传统特征金字塔网络在处理钢材表面缺陷数据集时, 尽管在一定程度上提高了模型的尺度适应性, 但仍存在以下两个主要局限性: 上采样或下采样导致的信息丢失或退化、非相邻层特征融合产生冲突。

针对上述问题, 本文引入了渐进特征金字塔网络 (asymptotic feature pyramid network, AFPN)^[14] 来改进 YOLOv8n 的颈部特征融合网络, 以提升钢材表面缺陷检测模型对多尺度缺陷的识别性能。AFPN 结构如图 3 所示。

AFPN 通过引入非相邻层次间的直接交互以及自适应空间融合操作, 有效克服了传统特征金字塔网络的局限性。具体如下:




图 3 AFPN 结构示意图

Fig. 3 AFPN structure diagram

- 1)选取输入: AFPN 从主干网络 (backbone) 中获取多级特征图 (如 P3、P4、P5), 包括较低层次的详细特征和较高层次的语义丰富的特征。

- 2)渐进式特征融合: AFPN 采用渐近融合的方式, 首先将 2 个相邻的低层次特征进行融合, 并逐步递增地整合更高层次的特征, 避免了由于层次间较大的语义差距导致的信息丢失, 实现了非相邻层次之间的直接互动。

- 3)自适应空间融合 (adaptive spatial fusion, ASFF): AFPN 引入了自适应空间融合操作^[15], 具体说明如图 4 所示。使用空间权重分配策略动态地筛选和调整融合特征, 从而强化关键层的贡献并降低由不同目标矛盾信息带来的负面影响。




图 4 自适应空间融合操作

Fig. 4 Adaptive spatial fusion operation

AFPN 通过精细化的多层次特征融合,有效捕捉钢材表面缺陷的多尺度特征,尤其对非相邻层间信息丢失问题有显著改善。实验证明,AFPN 在提升模型对多尺度钢材表面缺陷的处理能力、检测精准度及鲁棒性方面表现出色,同时实现了在参数量几乎不增加的情况下,计算复杂度的小幅度下降。

2.3 Wise-IoU 损失函数

YOLOv8n 采用 CIoU Loss^[16] 作为边界框损失函数,忽视了类别间难度差异、样本分布不均及实际应用中的类别关注度差异,从而影响检测性能。为此,本文提出将 CIoU 损失函数替换为 WIoUv3 损失函数^[17]。WIoUv3 引入动态非单调聚焦机制,通过利用离群度(β)替代 IoU 来评估预测框的质量来智能分配梯度增益。有效降低了高质量与低质量预测框的竞争性和有害梯度,优化了普通质量预测框的学习,提升了模型的定位性能,具体如式(2)~(6)所示。

$$L_{wIoUv3} = r \cdot R_{wIoU} L_{IoU} \quad (2)$$

$$L_{IoU} = 1 - IOU \quad (3)$$

$$R_{wIoU} = \exp\left(\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)^*}\right) \quad (4)$$

$$r = \frac{\beta}{\delta \cdot \alpha^{\beta-\delta}} \quad (5)$$

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

其中, L_{IoU} 表示预测框与真实框的重叠程度距离理想状态(完全重叠)有多远的一种损失值, R_{wIoU} 表示一种运行权重,动态调节 WIoU 损失中各类预测框的影响力,优化模型对误差惩罚分配,提升整体检测精度。式(4)中的参数示意图如图 5 所示。表示将 W_g 和 H_g 从计算图中分离。 $\overline{L_{IoU}}$ 为动量为 m 的滑动平均值,其动态地更新确保整体 β 保持在较高水平,从而有效解决训练后期收敛速度较慢的问题。 r 为非单调聚焦系数,影响梯度增益对 L_{IoU}^* (实际 IoU 值)变化的敏感度。 δ 与 α 为超参数,它们共同决定 r 随 β 变化的斜率和范围,进而影响对不同质量预测框梯度增益的分配策略。




图 5 WIoU 参数示意图

Fig. 5 WIoU parameters diagram

实验数据表明,面对钢材表面缺陷的多样性,WIoUv3 针对性解决了 CIoU 存在的关注度失衡与尺度适应性问题,实现了钢材表面缺陷检测精准且高效的识别与定位。

基于上述对 YOLOv8n 模型的改进,针对钢材表面缺陷的检测,提出全新的 YOLOv8-ODAW 模型,模型结构如图 6 所示。

3 实验及结果分析

3.1 实验环境与参数配置

本文实验环境的软硬件配置如表 1 所示。

训练参数:批大小 batch_size 设为 16,迭代次数 epoch 为 200,其余参数为默认值。

3.2 实验数据集介绍

本文采用东北大学钢材表面缺陷数据集 NEU-DET^[18],该数据集涵盖了 6 种常见的钢材表面缺陷,包括裂纹(crazing, Cr)、杂质(inclusion, In)、斑块(patch, Pa)、点蚀表面(pitted_surface, PS)、氧化皮(rolled-in_scale, RS)和划痕(scratches, SC),如图 7 所示。其中,每种缺陷类型包含 300 张图片,共 1 800 张。为了确保训练的合理性与公正性,对数据集进行随机划分,使得训练集、验证集和测试集比例为 8 : 1 : 1。

3.3 评价指标

本文实验中采用全类别平均精度(mean average precision, mAP)、参数量(Parameters)和计算量(GFLOPs)作为评价指标。其中,mAP 主要关注 mAP@50%与 mAP@50-90%。mAP@50%衡量模型在 IoU 阈值为 50%时的宽松匹配条件下目标检测准确性,而 mAP@50-90%通过统计 50%至 90%区间内多个 IoU 阈值的平均 AP,评价模型在不同精度要求下的综合检测性能。mAP 具体计算公式如式(7)~(10)所示。

$$P = \frac{TP}{TP + FP} \quad (7)$$

$$R = \frac{TP}{TP + FN} \quad (8)$$

$$AP = \int_0^1 P(R) dR \quad (9)$$

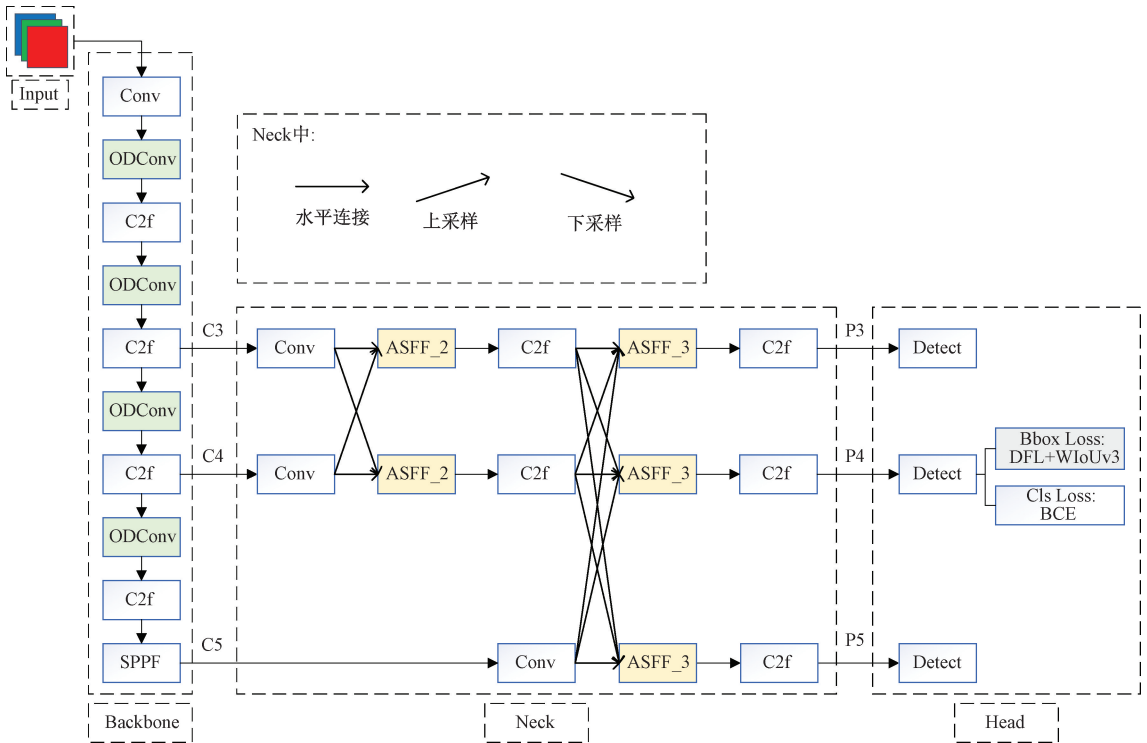


图 6 YOLOv8-ODAW 网络结构

Fig. 6 YOLOv8-ODAW network structure diagram

表 1 实验环境

Table 1 Experimental environment

名称	参数
操作系统	Windows 11
解释器	Python 3.11
深度学习框架	Pytorch 2.2.1+CuDa 12.1
内存	16 GB
CPU	AMD Ryzen 7 7840H
GPU	NVIDIA GeForce RTX 4060 Laptop 8 GB

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \tag{10}$$

其中, TP 表示正类样本被正确预测的数量, FP 表示负类样本被错误地预测为正类的数量, FN 表示正类样本被错误地预测为负类的数量; 准确率 (precision, P) 表示模型正确检测到的目标实例占所有被预测为正例的比例, 反映了模型预测的准确性; 召回率 (recall, R) 表示模型成功检测到的正例占实际正例总数的比例, 反映模型识别全部正类实例的能力; 平均精度 (average precision, AP) 综合评估模型在某类别上的检测性能。 mAP 表示所有类别 AP 值的平均值, 用以衡量模型在所有类别上的总体检测效果。

3.4 实验结果与分析

在 NEU-DET 数据集上分别对原始 YOLOv8n 模型与改进 YOLOv8-ODAW 模型进行训练与验证, 可以看出改进后的 YOLOv8-ODAW 模型在 6 类钢材表面缺陷的平均精度的值相较于 YOLOv8n 检测数据的值均有一定提升, 且改进后的模型在模型计算量上有一定幅度的下降。对比结果如表 2 所示。

为了进一步验证模型的实际效能, 使用原始 YOLOv8n 算法与改进后的 YOLOv8-ODAW 分别对测试集进行测试。算法改进前后检测效果对比如图 8 所示。对比结果表明, 本研究中的 YOLOv8-ODAW 模型对形态各异的钢材表面缺陷展现出优异的适应性, 而且能更精准定位各类缺陷位置, 具备卓越的检测能力。





图 7 NEU-DET 数据集

Fig. 7 NEU-DET dataset


表 2 算法改进前后对比
Table 2 Comparison before and after algorithm improvement

模型	Params/ $\times 10^6$	GFLOPS	AP						mAP@0.5%
			Cr	In	Pa	PS	RS	Sc	
YOLOv8n	3.01	8.2	46.4	82.5	91.6	96.8	63.9	87.1	78.0
YOLOv8-ODAW	3.17	6.4	54.5	89.2	94.1	99.5	72.8	92.0	83.7


原图片标签



YOLOv8n检测结果



YOLOv8-ODAW检测结果



(a) Cr

(b) In

(c) Pa

(d) PS

(e) RS

(f) Sc

图 8 算法改进前后检测结果对比

Fig. 8 Comparison of detection results before and after algorithm improvement

3.5 消融实验

为了系统评估本文所引入的算法改进模块对钢材表面缺陷检测模型性能提升的有效性,本文设计了一系列消

融实验。实验以基础 YOLOv8n 模型为参照基准,通过逐步添加各个改进模块,探究各模块对整体模型性能的影响。实验结果如表 3 所示。

表 3 消融实验结果
Table 3 Results of ablation experiment

模型	ODConv	AFPN	WIoUv3	GFLOPS	Params/ $\times 10^6$	mAP@0.5%	mAP@0.5-0.9/%
YOLOv8n				8.2	3.01	78.0	47.8
YOLOv8n-OD	✓			7.2	3.02	81.1	48.9
YOLOv8-ODA	✓	✓		6.4	3.17	82.9	49.2
YOLOv8-ODAW	✓	✓	✓	6.4	3.17	83.7	49.7

表 3 中“✓”代表 YOLOv8n 网络已采用相应改进方案,其中,YOLOv8-OD 模型通过引入 ODConv 优化骨干网络,实现精度显著提升(mAP@50%提高了 3.97%)与计算量大幅降低(GFLOP 减少了 12.2%),且无明显参数增加。YOLOv8-ODA 模型在此基础上加入了渐进特征金字塔网络,再降计算量,mAP@50%和 mAP@50-90%相比 YOLOv8n 分别提升了 6.3%和 2.9%。YOLOv8-ODAW

则以 WIoUv3 损失函数替代 CIoU 再次提升了检测性能,相较于 YOLOv8n,mAP@50%和 mAP@50-90%分别增长了 7.3%和 4%。综上所述,YOLOv8-ODAW 模型在钢材表面缺陷检测任务上表现优异的性能,证实各模块改进有效。

3.6 对比实验

为进一步验证本文提出的 YOLOv8-ODAW 改进算法

在钢材表面缺陷检测任务中的优越性,本文在相同的实验环境下,采用统一的数据集划分标准,选取了几种当前业界广泛认可且性能优良的目标检测算法进行对比测试。对比实验结果如表4所示。

表4 对比实验结果

Table 4 Results of comparative experiments

模型	mAP@0.5/%	Parameters/ $\times 10^6$
Faster RCNN	70.66	100.02
SSD	58.94	24.19
YOLOv5s	73.49	7.13
Retinanet ^[19]	72.29	33.56
YOLOv7	76.35	36.96
本文	83.70	3.17

由表4可知,相较于上述算法,YOLOv8-ODAW显著减小了模型参数量与计算量,且mAP@50%分别提高了18.5%、42.0%、13.9%、15.8%、9.6%。对比表明,本文提出的改进算法YOLOv8-ODAW在钢材表面缺陷检测领域表现卓越,保持高精度而不增参数,实现了精度与速度的兼顾优化。

4 结 论

为了实现钢材表面缺陷的高质量实时监测,提出YOLOv8-ODAW算法。该算法使用ODConv替换特征提取网络的部分下采样层,增强多维特征提取;引入渐进特征金字塔结构,促进非相邻层特征的直接交互,消除语义断层,提升特征融合效果;采用动态非单调聚焦的WiseIoU v3损失函数替换CIoU,抑制高质量预测框的竞争力的同时减少了低质量样本产生的有害梯度,引导模型聚焦于普通质量的预测框,从而加速收敛并提升检测准确率。实验结果表明,YOLOv8-ODAW相较于原YOLOv8n模型GFLOPs下降了21.95%,mAP@50%和mAP@50-90%分别提升了7.3%和4%,具有更高的检测精度且检测速度符合工业检测标准,具有一定的实际应用价值。后续将继续优化模型对裂纹类网状缺陷的检测能力,进一步提高模型精度。

参考文献

- [1] REN SH Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(6):1137-1149.
- [2] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]. Computer Vision-ECCV 2016, 2016: 21-37.
- [3] 钱承山,沈有为,孙宁,等.改进YOLOv5s的遥感图像

检测研究[J]. 国外电子测量技术, 2022, 41(11): 57-66.

QIAN CH SH, SHEN Y W, SUN N, et al. Improved YOLOv5s remote sensing image detection research[J]. Foreign Electronic Measurement Technology, 2022, 41(11):57-66.

- [4] 陆家林,程颖,冯赛,等.基于机器视觉的钢材表面缺陷检测[J]. 机电工程技术, 2022, 51(7):159-163.
LU J L, CHENG Y, FENG S, et al. Machine vision-based inspection of steel surface defects [J]. Mechanical & Electrical Engineering Technology, 2022, 51(7):159-163.
- [5] 阎馨,杨月川,屠乃威.基于改进SSD的钢材表面缺陷检测[J]. 现代制造工程, 2023, (5):112-120.
YAN X, YANG Y CH, TU N W. Steel surface defect detection based on improved SSD [J]. Modern Manufacturing Engineering, 2023, (5):112-120.
- [6] 蒋博,万毅,谢显中.改进YOLOv5s的轻量化钢材表面缺陷检测模型[J]. 计算机科学, 2023, 50(2): 271-277.
JIANG B, WAN Y, XIE X ZH. Improved YOLOv5s lightweight steel surface defect detection model[J]. Computer Science, 2023, 50(2):271-277.
- [7] YE G T, QU J SH, TAO J T, et al. Autonomous surface crack identification of concrete structures based on the YOLOv7 algorithm[J]. Journal of Building Engineering, 2023. DOI: 10.1016/j.job. 2023. 106688.
- [8] MAHBUB A M I, MALIKOPOULOS A A. Platoon formation in a mixed traffic environment: A model-agnostic optimal control approach[C]. 2022 American Control Conference(ACC), 2022: 4746-4751.
- [9] HAQUE M S, RILETT L, ZHAO L. Impact of platooning connected and automated heavy vehicles on interstate freeway work zone operations[J]. Journal of Transportation Engineering, Part A: Systems, 2023. DOI:10.1061/jtepbs. teeng-7434.
- [10] 李忠科,刘小芳.基于轻量级YOLOv8n网络的PCB缺陷检测算法[J]. 电子测量技术, 2024, 47(4): 120-126.
LI ZH K, LIU X F. PCB defect detection algorithm based on lightweight YOLOv8n network[J]. Electronic Measurement Technology, 2024, 47(4):120-126.
- [11] FENG CH J, ZHONG Y J, GAO Y, et al. Tood: Task-aligned one-stage object detection [C]. 2021 IEEE/CVF International Conference on Computer Vision(ICCV), 2021: 3490-3499.
- [12] 彭继慎,孙礼鑫,王凯,等.基于模型压缩的ED-YOLO

- 电力巡检无人机避障目标检测算法[J]. 仪器仪表学报, 2021, 42(10):161-170.
- PENG J SH, SUN L X, WANG K, et al. ED-YOLO power inspection UAV obstacle avoidance target detection algorithm based on model compression[J]. Chinese Journal of Scientific Instrument, 2021, 42(10):161-170.
- [13] LI CH, ZHOU AO J, YAO AN B. Omni-dimensional dynamic convolution[J]. ArXiv preprint arXiv:2209.07947, 2022.
- [14] YANG G Y, LEI J, ZHU ZH K, et al. AFPN: Asymptotic feature pyramid network for object detection[C]. 2023 IEEE International Conference on Systems, Man, and Cybernetics (SMC), 2023: 2184-2189.
- [15] LIU S T, HUANG D, WANG Y H. Learning spatial fusion for single-shot object detection [J]. ArXiv preprint arXiv:1911.09516, 2019.
- [16] ZHENG ZH H, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression [J]. AAAI Conference on Artificial Intelligence, 2020, 34(7):12993-13000.
- [17] TONG Z J, CHEN Y H, XU Z W, et al. WIOU: Bounding box regression loss with dynamic focusing mechanism[J]. ArXiv preprint arXiv:2301.10051, 2023.
- [18] HE Y, SONG K CH, MENG Q G, et al. An end-to-end steel surface defect detection approach via fusing multiple hierarchical features[J]. IEEE Transactions on Instrumentation and Measurement, 2019, 69(4): 1493-1504.
- [19] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection [C]. IEEE International Conference on Computer Vision, 2017: 2980-2988.

作者简介

赵洋, 博士, 讲师, 主要研究方向为图像处理与计算机视觉。

E-mail: sy_zhaoyang@yeah.net

王军凯, 硕士研究生, 主要研究方向为计算机视觉和缺陷检测。

E-mail: 403503669@qq.com

林志毅, 硕士研究生, 主要研究方向为图像处理与计算机视觉。

E-mail: lzy25650583@qq.com

周忠祥, 硕士研究生, 主要研究方向为缺陷检测与计算机视觉。

E-mail: 1980899231@qq.com

徐森(通信作者), 博士, 讲师, 主要研究方向为网络安全与密码学、安全协议的设计与分析、无线网络协议、安全多播等。

E-mail: xusen@syuct.edu.cn