

DOI:10.19651/j.cnki.emt.2417699

基于 SGF-YOLO 的钢板缺陷检测方法^{*}雷 超¹ 陈德基^{2,3} 孙家栋² 施 珮²(1. 南京信息工程大学计算机学院 南京 210044; 2. 无锡学院物联网工程学院 无锡 214105;
3. 无锡学院江苏省外国专家工作室-无锡学院物联网工程学院外国专家工作室 无锡 214105)

摘 要: 钢板产品的表面质量对其使用性能和市场竞争力具有重要影响。针对钢板表面缺陷检测精度不足导致的误检频发和漏检严重等问题,本文提出了一种基于 YOLOv8n 的改进模型 SGF-YOLOv8n。首先,引入了 Slim-neck 结构,以有效减少模型的参数量和计算复杂度,从而提升计算效率。其次,集成 GAM 注意力机制以增强模型对全局特征的感知能力,从而提高了对细微缺陷的检测性能。最后,采用 Focaler-IoU 损失函数,进一步优化了模型在处理边界模糊及小尺寸缺陷区域时的定位精度。此外,针对数据集样本量有限问题,本文采用数据增强技术对 NEU-DET 数据集进行了样本扩充并展开实验。实验结果表明,SGF-YOLOv8n 在 NEU-DET 数据集上的 mAP50 值达到 81.6%,比基线模型提升 3.8%。同时,在 GC10-DET 数据集上的泛化实验中,SGF-YOLOv8n 的 mAP50 达到 70.4%,较基线模型提升 6.7%。结果表明,本文提出的改进算法具有良好的鲁棒性和有效性。

关键词: 钢板表面缺陷检测;YOLOv8n;Slim-neck;GAM;损失函数

中图分类号: TP391;TN01 **文献标识码:** A **国家标准学科分类代码:** 520.60

Steel defect detection method based on SGF-YOLO

Lei Chao¹ Chen Deji^{2,3} Sun Jiadong² Shi Pei²(1. School of Computer Science, Nanjing University of Information Science & Technology, Nanjing 210044, China;
2. School of Internet of Things Engineering, Wuxi University, Wuxi 214105, China;
3. Jiangsu Provincial Foreign Experts Workshop-Foreign Experts Workshop of the
School of Internet of Things Engineering, Wuxi University, Wuxi 214105, China)

Abstract: The surface quality of steel plate products significantly impacts their performance and market competitiveness. To address the challenges of insufficient detection accuracy, frequent false positives, and severe missed detections in steel plate surface defect detection, this paper proposes an improved model, SGF-YOLOv8n, based on YOLOv8n. First, a Slim-neck structure is introduced to effectively reduce the model's parameter count and computational complexity, thereby enhancing computational efficiency. Second, the GAM attention mechanism is integrated to strengthen the model's perception of global features, improving its ability to detect subtle defects. Finally, the Focaler-IoU loss function is employed to further optimize the model's localization accuracy when dealing with blurry boundaries and small defect areas. Additionally, to address the issue of limited dataset samples, data augmentation techniques were applied to expand the NEU-DET dataset, followed by extensive experiments. The experimental results demonstrate that SGF-YOLOv8n achieves an mAP50 of 81.6% on the NEU-DET dataset, representing a 3.8% improvement over the baseline model. Furthermore, in generalization experiments on the GC10-DET dataset, SGF-YOLOv8n achieved an mAP50 of 70.4%, a 6.7% increase compared to the baseline. These results indicate that the proposed algorithm exhibits robust performance and high effectiveness.

Keywords: steel plate surface defect detection;YOLOv8n;Slim-neck;GAM;loss function

0 引 言

钢材广泛应用于建筑、工业和航空航天等领域,在现代

社会发展中发挥着重要作用^[1]。然而,在钢板生产和加工过程中,受原材料质量、工艺条件以及设备稳定性等多种因素的影响^[2],钢板表面可能出现多种缺陷,如划痕、气孔、裂

收稿日期:2024-12-22

^{*} 基金项目:国家自然科学基金(62072216)、无锡学院引进人才科研启动专项经费(2023r005)项目资助

纹、凹坑、杂质等。此类缺陷不仅对产品的美观和使用舒适性产生不利影响,还会影响其性能^[3-5]。缺陷检测技术是减少产品缺陷不利影响的有效方法^[6]。

国内外在钢板表面缺陷检测领域的研究持续深入,国外企业如 Cognex、Ametek 和 Futech 已开发出成熟的检测系统,结合高精度工业相机与深度学习技术,实现了在线自动检测。国外研究较早引入 CNN 进行缺陷检测,并在工业应用中取得显著成效。国内研究起步较晚,但近年来发展迅速,当前工业应用仍面临数据不平衡、实时性要求高等挑战。

传统的钢板表面缺陷检测通常依赖于人工检查^[7]。然而,人工检测效率低、误判率高,且在故障可能导致危险的场景中不可行^[8]。因此,需要开发更高效和更可靠的视觉图像检测技术^[9]。

目前,在图像检测算法中,单阶段和二阶段检测算法是两种主流的技术路线^[10]。典型的单阶段检测算法有 YOLO 系列、SSD 等^[11]。单阶段算法的核心思想是在密集特征图上直接生成大量锚框,并通过神经网络对其进行分类和回归调整,以获得最终的检测结果^[12]。单阶段算法无需分离候选框生成和检测,可一次性完成预测,检测速度更快。典型的二阶段算法有 R-CNN^[13]、Fast R-CNN、Faster R-CNN。二阶段算法通过选择性搜索或区域建议网络(region proposal network, RPN)生成候选框,并对这些区域进行详细检查。这种分步处理提高了检测精度,适合小目标检测和复杂场景,但检测速度逊于单阶段算法^[14],难以满足实时性要求。因此,单阶段算法凭借速度快、计算量低的优势,更适合工业缺陷检测的基本需求^[15]。

在单阶段算法中,SSD 算法可同时预测目标位置和类别,但在小目标检测中表现较弱。陈榕榕等^[16]提出了 Swin-IdentityFormer 网络架构,替代 YOLOv5 中的 CSP-Darknet53 骨干网络,同时引入 skipconcatFPN 结构并使用 MPDIoU 损失函数,以减少参数量并提升检测精度。改进模型在 NEU-DET 数据集上的 mAP 达到 79.59%。徐浩等^[17]提出了一种双流 YOLOv4 网络用于金属表面缺陷检测,将 YOLOv4 中的骨干网络分成浅分支和深分支,通过削减两分支的层数和通道数来减少参数量,又提出了一种树形多尺度融合方法(tree-structured multi-scale feature fusion, TMFF),以强化低级语义特征,并结合极化自注意力机制和空间金字塔池化的特征融合模块提升检测精度,在 NEU-DET 数据集上 mAP 可达 80%。齐向明等^[18]基于 YOLOv7-tiny 算法进行改进,将激活函数替换为 SiLU 以增强特征提取能力;结合张量拼接与双向特征金字塔网络(bidirectional feature pyramid network, BiFPN),并用轻量级内容感知的特征重组算子(content-aware reAssembly of features, CARAFE)替代上采样中的最邻近插值,提升特征融合效果;输出端引入多头自注意力机制(multi-head self-attention, MHSA)和尺度保持检测(scale-preserving

detection, SPD)卷积模块,加强小目标检测性能。在 NEU-DET 数据集上, mAP 提升了 11.7%,性能显著。然而,由于 YOLOv7-tiny 参数量较大,导致计算资源消耗增加、推理延迟加大,难以满足高实时性应用需求。

针对目前钢材表面缺陷检测优化方法虽能提升精度,但伴随网络复杂度增加,难以满足工业实时检测需求。同时尽管特征融合方法有所优化,但在复杂背景或光照变化下,复杂缺陷检测仍存在一定误检和漏检问题。因此,本文基于 YOLOv8n 提出了一种改进的钢板表面缺陷检测算法 SGF-YOLOv8n。本文主要工作如下:

1)在 YOLOv8 的头部引入 GSConv 模块,通过引入门控制机制(gate mechanism, GM),对卷积核进行自适应调整,从而对不同形状的特征进行加权,增强模型的表达能力。同时结合 Slim-neck 轻量化结构设计,减少了参数量和计算量的同时保持精度。

2)在主干网络部分引入全局注意力机制(global attention mechanism, GAM)注意力机制模块,使得模型能够自适应地调节不同通道和空间位置,从而避免无效特征的干扰,提升模型精度。

3)在损失函数部分采用 Focaler-IoU 代替传统的 CIOU 损失函数,通过结合 Focal Loss 的思路,对容易定位的目标施加较低的权重,聚焦于难定位的目标,从而提升模型对小目标缺陷和稀疏物体的检测能力。

1 YOLOv8n 模型

YOLOv8n 网络架构如图 1 所示,主要由三大部分组成:特征提取网络(Backbone)、特征融合网络(Neck)和检测头(Head)。

在 Backbone 部分,输入图像经过五次下采样,生成不同尺度的特征图。YOLOv8n 引入 C2f 模块,通过优化梯度流和引入梯度分流,减少卷积层数量并提升梯度传递效率。生成的特征图经(spatial pyramid pooling with features, SPPF)模块处理,该模块通过 3 个最大池化层自适应生成固定尺寸的输出特征图,既减少计算量又显著提升推理效率。

在 Neck 部分, YOLOv8n 采用了(feature pyramid network-pixel aggregation network, FPN-PAN)结构^[19],进一步提升了特征融合的能力。FPN-PAN 结合了自上而下和自下而上的特征融合策略,通过多尺度特征的结合提升了模型对不同尺度目标的检测能力。

在 Head 部分, YOLOv8n 采用解耦头结构,将分类和回归任务分开处理,以提高训练效率和精度。回归任务中引入分布焦点损失(distribution focal loss, DFL)和 CIOU 损失函数以提升定位精度;分类任务中则使用二元交叉熵损失(binary cross-entropy loss, BCE Loss)优化分类性能。

2 YOLOv8n 算法改进

本文针对钢板缺陷检测中因目标特征复杂性和多样性

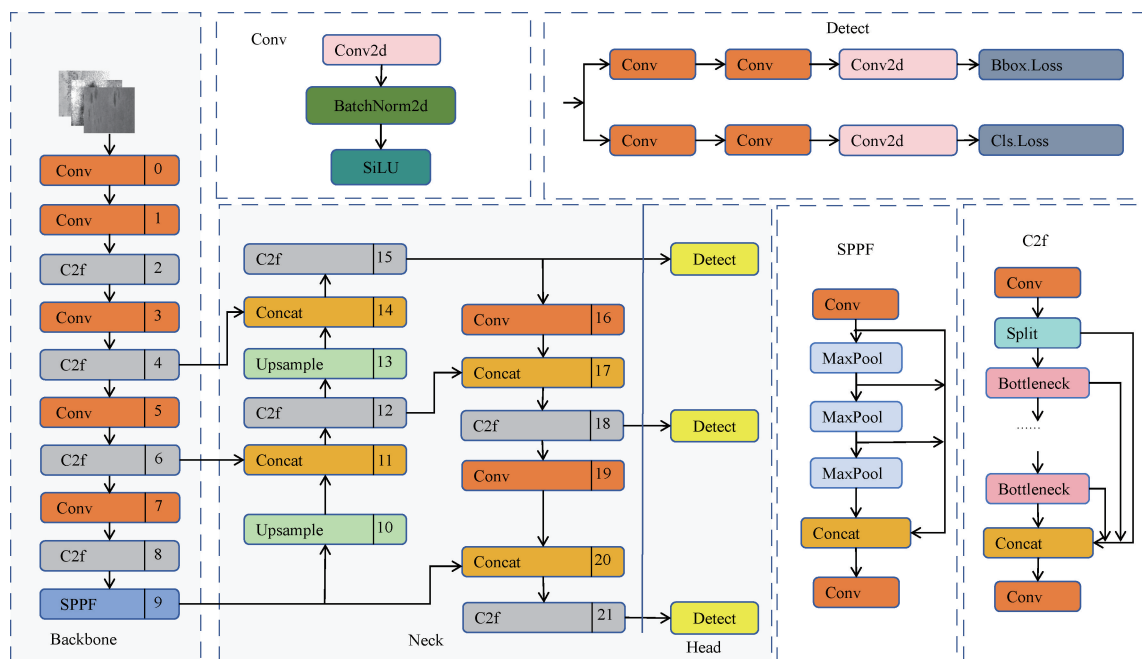


图1 YOLOv8网络结构

Fig. 1 YOLOv8 network architecture

导致工业视觉算法精度不足的问题,提出了一种改进的SGF-YOLOv8n算法,从以下3个方面优化基线模型:首先,引入轻量化Slim-neck结构作为特征融合网络,显著减少模型参数数量和计算成本,同时增强特征融合与表达能力,提升检测精度。其次,集成GAM,增强模型对关键特征区域的聚焦能力,并提升全局与局部特征的代表性能。最后,采用Focaler-IoU作为回归损失函数,优化目标框的定位损失,提高模型在小目标检测和复杂背景下的鲁棒性。通过Slim-neck、GAM和Focaler-IoU的协同作用,改进后的模型在保持高计算效率的同时,显著提升了检测精度和特征表达能力。SGF-YOLOv8n的网络结构如图2所示。

2.1 Slim-neck 特征融合网络

YOLOv8的颈部网络通过连接骨干网络和头部网络实现特征的融合与处理,其中使用的C2f模块基于标准卷积(standard convolution, SC)。然而,随着网络深度的增加,标准卷积带来的参数数量和计算量显著增大,影响了YOLOv8的整体性能。

为了解决这一问题,Li等^[20]提出了一种轻量化卷积技术GSConv和轻量级结构VoV-GSCSP,并将两者结合形成了轻量级特征融合网络Slim-neck范式。本文将YOLOv8的颈部网络替换为Slim-neck结构,以在保持特征提取能力的前提下显著减少模型参数数量。GSConv的结构如图3所示,其由SC、深度可分离卷积(depth-wise separable convolution, DSC)以及拼接与通道混洗操作组成。具体而言,GSConv将SC提取的深层语义信息与DSC提取的浅层特征信息进行拼接,随后通过通道混洗操

作,使深层特征与浅层特征相互渗透,从而在保证模型精度的同时提升计算效率。GSConv的计算成本约为SC的50%,同时贡献的模型学习能力可以与SC相当。

VoV-GSCSP是通过研究了提升CNN学习能力的通用方法,并结合一次性聚合策略设计而成的高效的跨阶段部分网络模块^[21]。图4(a)展示的GS bottleneck模块由GSConv构成,同时引入了SC瓶颈,旨在增强特征的非线性表达能力并提高信息的复用性。而VoV-GSCSP模块的结构如图4(b)所示,主要用于不同阶段特征图之间的高效信息融合。

Slim-neck特征融合网络是由GSConv和VoV-GSCSP结合而成的。本文将YOLOv8中的特征融合网络部分替换为Slim-neck范式,在降低整体模型的参数数量和计算量的同时,也提高了模型的特征融合能力,从而进一步提升了模型的检测精度。

2.2 GAM 注意力机制

在钢板缺陷检测任务中,缺陷通常具有不规则形状和分布不均匀的特点,比如,裂纹和划痕缺陷的形状不规则,方向不规律;麻点缺陷的密度不均,大小不同等。这些特点对钢板表面缺陷检测精度造成极大的挑战。

GAM模块在通道和空间维度上进行联合建模。相较于传统的注意力机制(如SE模块),混合域注意力机制融合了通道注意力和空间注意力的优势,能够自适应地调节通道和空间维度之间地相互作用,从而实现捕捉到不规则的缺陷。因此本文在主干网络中嵌入GAM全局注意力机制模块,使得模型在检测钢板表面缺陷瑕疵时具有更好的聚焦能力。GAM^[22]通过引入卷积块注意力模块(convolutional

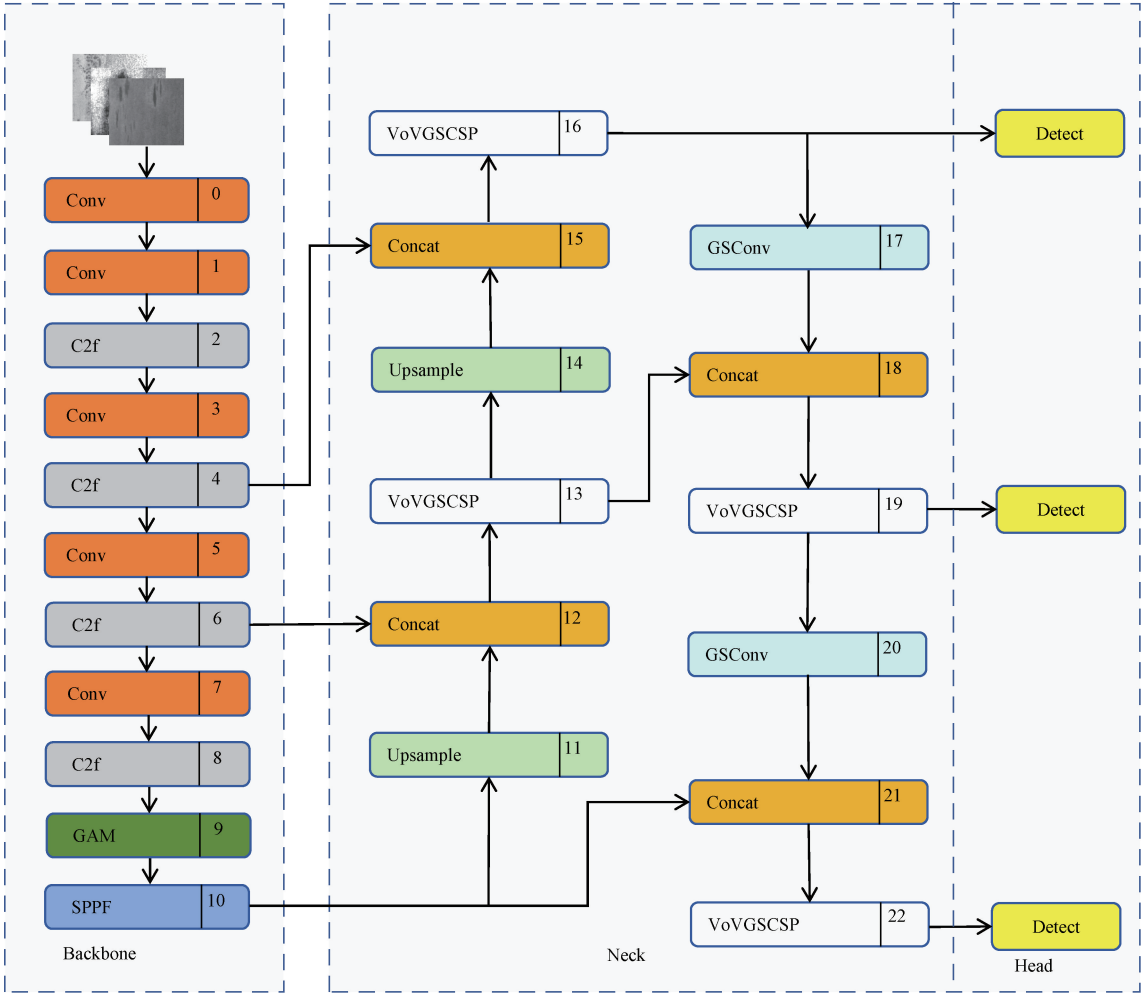


图 2 SGF-YOLOv8n 结构
Fig. 2 SGF-YOLOv8n architecture

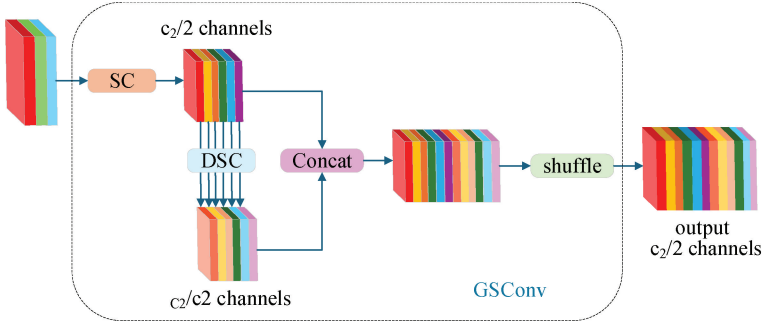


图 3 GSConv 结构图
Fig. 3 GSConv architecture diagram

block attention module, CBAM^[23] 中的通道和空间顺序注意机制,对其子模块进行了全新的设计。GAM 的整个过程如图 5 所示。中间状态 F_2 和输出状态 F_3 由式(1)和式(2)定义。

$$F_2 = M_c(F_1) \otimes F_1 \quad (1)$$

$$F_3 = M_s(F_2) \otimes F_2 \quad (2)$$

其中, M_c 和 M_s 分别是通道和空间注意力图; \otimes 表示元素乘法。

GAM 方法由通道注意力子模块与空间注意力子模块组成。通道注意力子模块首先通过 3D 排列操作,将输入特征图的通道维度重新分布至空间维度 ($C \times W \times H$) 之后,从而获得 $W \times H \times C$ 的特征表示。接着,通过具有与

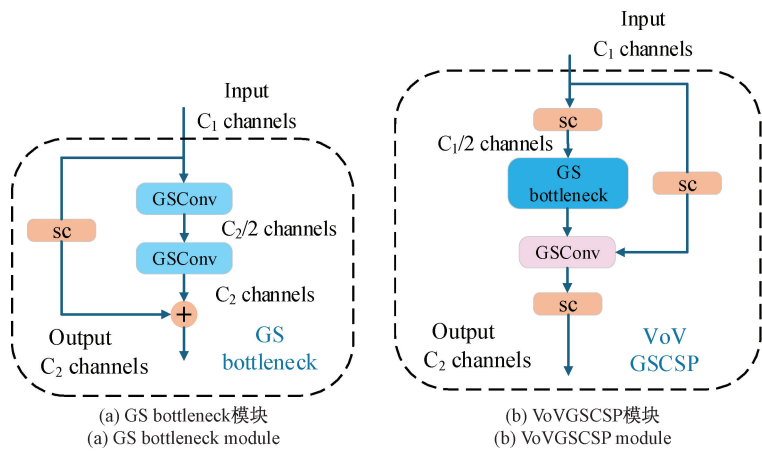


图4 GS bottleneck 模块结构图和 VoVGSCSP 模块结构图

Fig. 4 Structure diagrams of the GS bottleneck module and the VoVGSCSP module

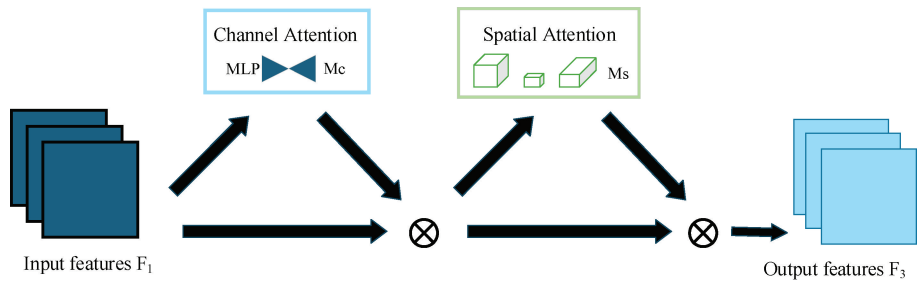


图5 GAM 模块原理图

Fig. 5 GAM module schematic diagram

BAM 相同缩减比 r 的多层感知器 (multilayer perceptron, MLP) 来增强特征在通道与空间上的依赖性, 并提取相应的权重系数。完成通道压缩后, 再通过逆排列与激活函数生成加权后的通道特征图。通道注意力子模块如图 6 所示。

随后, 在空间注意力子模块中, 该方法利用两个 7×7

卷积层对经过通道加权的特征图进行空间信息融合。同样采用缩减比 r 对参数进行调控, 避免因最大池化引入的信息损失与不必要的参数膨胀, 该方法移除了池化操作, 并在 ResNet-50 中借助带通道混洗的组卷积方案^[24]降低参数开销, 从而更高效地获取空间注意力信息。空间注意力子模块如图 7 所示。




图6 通道注意力子模块

Fig. 6 Channel attention submodule




图7 空间注意力子模块

Fig. 7 Spatial attention submodule

将 GAM 模块融入 YOLOv8n 模型的钢板表面缺陷检测中, 帮助算法在保持较轻量化模型的同时, 能在通道与

空间两个层面更加充分地利用特征信息,从而提升算法对密度不均且大小不同的缺陷的识别能力。

2.3 Focaler-IoU 损失函数

针对 IoU 损失函数在处理复杂场景时存在的梯度消失、对低像素图像过于敏感和收敛速度慢等问题,本文采用 Focaler-IoU 损失函数替代 YOLOv8 的默认 CIoU 损失函数。Focaler-IoU 损失函数通过在不同检测任务中自适应关注不同的回归样本,从而提升检测器的性能。其计算方法如式(3)所示,损失的具体定义如式(4)所示。

$$IoU^{focaler} = \begin{cases} 0, & IoU < d \\ \frac{IoU - d}{u - d}, & d \ll IoU \ll u \\ 1, & IoU > u \end{cases} \quad (3)$$

$$L_{Focaler-IoU} = 1 - IoU^{focaler} \quad (4)$$

其中, $IoU^{focaler}$ 是重构后的 Focaler-IoU 值, IoU 表示原始的 IoU 数值,而参数 d 与 u 的取值均在 $[0, 1]$ 范围内^[25]。通过适当调整这两个参数,即可使 $IoU^{focaler}$ 对不同样本进行有针对性的聚焦,从而实现更灵活、可控的特征关注策略。

在钢板表面缺陷检测中,不同类型的缺陷往往难度各异,一些微小、形状不规则或不易辨别的缺陷样本可能在训练过程中难以得到充分学习。Focaler-IoU 通过引入可调参数(d 与 u),使得度量指标可以更为精确地聚焦在这类困难样本上,从而在训练中给予它们更高的关注度,提升模型对复杂缺陷的辨识能力。同时在缺陷检测中,非缺陷区域(负样本)数量往往远多于缺陷区域(正样本),造成训练过程中正负样本不平衡^[26]。Focaler-IoU 通过对 IoU

值进行“聚焦”调节,使模型在更新权重时更倾向于对难以判断或易混淆的正样本区域加大力度,有利于缓解正负样本不平衡,从而促进模型更稳定地收敛。

3 实验与结果分析

3.1 实验环境

本实验环境使用的 Python 版本为 3.9,Pytorch 的版本为 1.13.1,配备了 AMD Ryzen 7 3700X, NVIDIA GeForce RTX3080,显存为 10 GB,CUDA 版本为 12.1,选择在 Win11 系统上训练模型。本实验的训练参数设置如表 1 所示。

表 1 训练参数
Table 1 Training parameters

参数名	参数值
学习率	0.01
权重衰减系数	0.000 5
动量	0.937
优化器	SGD
批量大小	16
训练轮数	250

3.2 数据集及数据增强

本实验选用的数据集为东北大学的钢板表面缺陷数据集 NEU-DET^[27],其中包括裂纹(crazing)、夹杂(inclusion)、斑块(patchs)、表面麻点(pitted_surface)、轧制鳞片(rolled-in_scale)、划痕(scratches)6 种缺陷,图片总数为 1 800 张。样本如图 8 所示。




图 8 NEU-DET 数据集样本

Fig. 8 NEU-DET dataset samples

为了更真实地模拟工业相机在拍摄钢板表面时可能遇到的复杂情况,本文对数据集进行了数据增强。处理方法包括随机亮度调整、添加噪声、动态模糊、随机缩放以及

随机旋转等。经过处理后,数据集中的图像总数扩充至 3 600 张,增强后样本如图 9 所示。本文对训练集、验证集和测试集的分配比例为 8:1:1。




图 9 数据增强后数据集样本
Fig. 9 Augmented dataset samples

3.3 评价指标

本实验中,使用准确率(precision, P)、召回率(recall, R)、平均准确率(average precision, AP)以及 mAP 等指标来评价模型的检测性能。同时,以参数量(Params)作为衡量模型空间复杂度的指标,并以浮点运算次数(FLOPs)来量化模型的计算资源消耗。其中 P、R、AP 和 mAP 的表达式分别为:

$$P = \frac{TP}{TP + FP} \tag{5}$$

$$R = \frac{TP}{TP + FN} \tag{6}$$

$$AP = \int_0^1 P(R) dR = \sum_{k=0}^n P(k) \Delta R(k) \tag{7}$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i \tag{8}$$

式中:TP 表示真正例,模型正确检测到的目标数量。FP 表示假正例,模型错误检测的目标数量。FN 表示假负例,模型漏检的目标数量。AP 表示平均准确率,表示模型在不同召回率阈值下的准确率的平均值。mAP 表示多类别问题的平均精确度,它衡量的是模型在不同类别上的整体检测性能,越高的 mAP 值代表模型的检测效果越好。

3.4 消融实验

为验证各改进模块的有效性,本文以 YOLOv8n 作为基础模型进行消融实验。实验通过 Precision、Recall、mAP50、mAP50-95、Params、FLOPs 等评价指标进行对比分析。其中,“√”表示模型采用了该改进模块,“—”表示模型未采用该改进模块。并将 YOLOv8n 模型记为 Y, Slim-neck 模块记为 S, GAM 模块记为 G, Focaler-IoU 损失函数记为 F。消融实验结果如表 2 所示。

表 2 消融实验

Table 2 Ablation experiments

实验	Y	S	G	F	Precision/%	Recall/%	mAP50/%	mAP50-95/%	Params/M	FLOPs/G
1	√	—	—	—	77.3	71.0	77.8	46.1	3.0	8.2
2	√	√	—	—	79.4	73.6	79.0	46.8	2.8	7.4
3	√	—	√	—	78.0	71.3	78.4	47.5	4.6	9.5
4	√	—	—	√	77.5	69.5	76.7	45.6	3.0	8.2
5	√	√	√	—	78.3	75.4	80.6	47.7	4.4	8.7
6	√	√	√	√	82.8	73.9	81.6	48.5	4.4	8.7

通过表 2 实验结果可知,引入 Slim-neck 模块后,模型 $mAP50$ 提升至 79%,参数量和 $FLOPs$ 显著下降,证明该模块能提升检测精度并降低计算资源消耗。

引入 GAM 模块, $mAP50$ 提升至 78.4%,但伴随参数量增加 1.6 M 和 $FLOPs$ 上升 1.3 G,表明性能提升以增加计算资源为代价。为优化计算效率,实验联合引入 Slim-neck 和 GAM 模块,使 $mAP50$ 提升至 80.6%。随后引入 Focaler-IoU

损失函数,模型精度显著提升, $Precision$ 达 82.8%, $mAP50$ 达 81.6%, $mAP50-95$ 提升至 48.5%。最终提出的 SGF-YOLOv8 模型相比基础 YOLOv8n,在 $Precision$ 、 $Recall$ 、 $mAP50$ 和 $mAP50-95$ 上分别提升 5.5%、2.9%、3.8%、3.4%, $FLOPs$ 仅增加 0.5 G,达成性能与效率的平衡。图 10 展示了本次消融实验 1~6 中 6 组实验的验证效果图,更加直观地表现了模型对各类缺陷的检测效果上的提升。




图 10 消融实验模型检测缺陷效果图

Fig. 10 Defect detection results of ablation experiments models

3.5 对比实验

为验证本文提出的 SGF-YOLOv8 算法相较于当前主流算法的优越性,本实验在 NEU-DET 数据集上进行了对比实验。选取的对比算法包括 Faster R-CNN、

SSD、YOLOv5n、YOLOv5s、YOLOv8n、YOLOv8s、YOLOv10n、YOLOv10s 和 YOLOv11n。实验采用 $mAP50$ 、参数量 $Params$ 、 $FLOPs$ 、FPS 以及各类缺陷的 AP 值作为衡量模型性能的评价指标,全面评估不同算

法在钢板表面缺陷检测任务中的表现。对比试验结果 如表 3 所示。

表 3 不同模型对比实验
Table 3 Comparative experiment of different models

模型	<i>mAP</i> 50/	<i>Params</i> /	<i>FLOPs</i> /	<i>FPS</i> /	<i>AP</i> /%					
	%	M	G	S	裂纹	夹杂	斑块	麻点	轧制鳞片	划痕
Faster R-CNN	80.1	137.1	370	20.1	57.3	79.5	92.3	90.3	64.1	96.9
SSD	63.8	26.3	62.8	48.2	42.3	89.4	72.1	72.8	52.3	63.8
YOLOv5n	74.8	1.77	4.2	108.4	61.8	72.4	94.9	79.4	95.6	44.7
YOLOv5s	80.5	7.03	16.0	96.5	62.8	75.2	94.7	87.8	96.5	66.2
YOLOv8n	77.8	3.0	8.2	75.2	60.5	75.0	95.5	89.7	95.0	51.1
YOLOv8s	80.2	11.1	28.7	68.7	60.6	74.5	95.5	88.3	96.3	66.0
YOLOv10n	78.4	2.7	8.4	78.3	62.1	73.2	90.5	87.1	93.3	64.2
YOLOv10s	82.4	8.0	24.8	67.4	65.1	76.8	94.0	92.1	97.9	68.9
YOLOv11n	80.9	2.59	6.4	69.2	59.2	78.9	97.1	90.6	63.9	95.9
SGF-YOLOv8	81.6	4.4	8.7	83.6	68.7	79.2	96.5	89.9	95.9	59.5

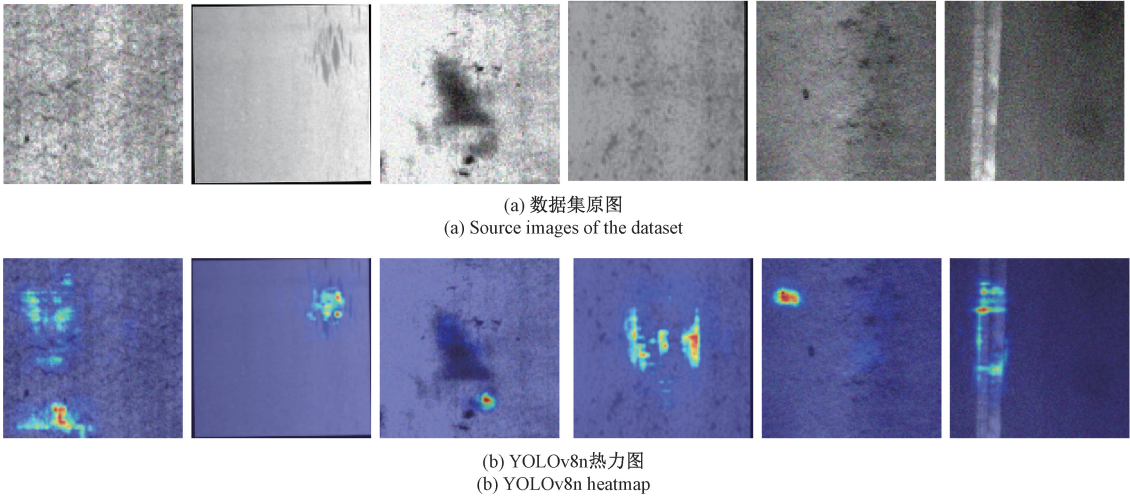
由表 3 可知,Faster R-CNN 作为唯一的两阶段检测算法,参数量和计算量远高于单阶段算法,对计算资源需求较大。尽管其整体 *mAP*50 处于中等水平,但在划痕检测中表现突出,准确率达 96.9%,适合以划痕为主要目标的工业检测场景。SSD 算法在本实验中的 *mAP*50 最低,仅为 63.8%,计算资源消耗位列第二。但其在夹杂缺陷检测中表现优异,准确率达 89.4%,适合作为夹杂缺陷检测的首选。YOLO 系列算法在参数量和计算量上显著优化,其中轻量化模型 YOLOv5n 参数量仅 1.77 M,*FLOPs* 为 4.2 G 且 *FPS* 高达 108.4,适合资源受限的设备。然而,其 *mAP*50 仅为 74.8%,为系列中最低。相比之下,YOLOv10s 的 *mAP*50 达 82.4%,但其参数量和 *FLOPs* 分别为 8 M 和 24.8 G,计算需求较高,不适合在钢板生产现场进行实时检测和轻量化部署。

本文提出的 SGF-YOLOv8 算法在钢板缺陷检测中表现优异,*mAP*50 达 81.6%。与 YOLOv8n 相比,6 类缺陷

的 *AP* 值平均提升 5.5%,在划痕和裂纹检测中提升尤为显著,分别达到 8.4%和 8.2%。相比 YOLOv10s,*mAP*50 仅下降 0.8%,但参数量减少 3.6 M,*FLOPs* 降低 16.1 G,同时 *FPS* 达到 83.6,属于较高水准。有效平衡了检测精度与计算效率的需求。

3.6 可视化分析

本文利用 HiResCAM 技术生成异物检测热力图,通过前向传播展示网络对关键区域的关注程度。HiResCAM 通过卷积网络最后一层特征图加权求和,生成高分辨率热力图,其中红色代表高关注区域,黄色为次要关注,蓝色为低关注或冗余区域。该方法在小尺寸目标和边界模糊的缺陷检测中表现优异,能精准呈现模型的关注区域,直观揭示检测依据,有助于优化模型结构和策略。图 11 展示了钢板表面缺陷的热力图。改进模型相比初始模型更聚焦于真实异物区域,特征提取更精准,环境干扰更小,展现出更高的检测精度与目标感知能力。






图 11 钢板表面缺陷检测热力图

Fig. 11 Heatmap of steel plate surface defect detection

3.7 泛化性实验

为验证 SGF-YOLOv8 模型的泛化能力,本文采用通用目标检测公开数据集 GC10-DET 对 SGF-YOLOv8 的检测性能

进行泛化性实验。GC10-DET 是真实工业中收集的表面缺陷数据集,包括 3 570 张灰度图像,涵盖了 10 类表面缺陷。在运行环境与上文保持一致的情况下,实验结果如表 4 所示。

表 4 GC10-DET 数据集泛化实验结果

Table 4 Generalization experiment results on the GC10-DET dataset

模型	Precision/%	Recall/%	mAP50/%	Params/M	FLOPs/G
YOLOv8n	70.7	62.4	63.7	3	8.2
SGF-YOLOv8	72.0	69.8	70.4	4.4	8.7

由表 4 可知,本文所提的 SGF-YOLOv8 模型相较于 YOLOv8n 模型,在 Precision、Recall 和 mAP50 上均取得显著提升,分别提高了 1.3%、7.4% 和 6.7%。表明了 SGF-YOLOv8 模型在检测钢板表面缺陷上具有卓越的泛化能力。

4 结 论

本文提出了一种基于 SGF-YOLOv8 的深度学习模型,旨在解决钢板表面缺陷检测中精度不足的问题。该模型能够在精准检测和实时性能之间实现良好平衡,满足工业检测中对高精度和高效率的双重需求。在原始的 YOLOv8n 模型基础上,SGF-YOLOv8 采用 Slim-neck 轻量化卷积结构,对模型的骨干网络和颈部结构进行了优化,显著减少了参数数量和计算量,实现了更高的模型轻量化和推理速度。此外,模型中引入的 GAM 注意力机制增强了特征的全局上下文感知能力,提升了对小尺寸和边缘模糊缺陷的检测效果。为进一步优化模型的检测精度,Focaler-IoU 损失函数被引入,用于强化边界区域的定位精度,降低了对小目标的漏检率,进一步提升了模型的检测性能。数据增强技术的应用也提升了模型对不规整性、图像模糊和小样本缺陷的检测能力。实验结果表明,SGF-YOLOv8 在 NEU-DET 和 GC10-DET 钢板表面缺陷检测中的平均检测精度分别达到 81.6% 和 70.4%,与基线模型 YOLOv8n 相比,分别提高了 3.6% 和 6.7%。总体来看,SGF-YOLOv8 在检测精度方面取得了良好的优化效果,为工业生产中钢板表面缺陷检测提供了一种新的方案。

参考文献

[1] 梁礼明,陈康泉,钟奕,等. DCD-YOLOv8n: 一种高效

的钢材表面缺陷检测算法[J]. 计算机工程与应用, 2025,61(7):117-127.
LIANG L M, CHEN K Q, ZHONG Y, et al. DCD-YOLOv8n: An efficient steel surface defect detection algorithm [J]. Computer Engineering and Applications, 2025,61(7):117-127.
[2] DEMIR K, AY M, CAVAS M, et al. Automated steel surface defect detection and classification using a new deep learning-based approach [J]. Neural Computing and Applications, 2023, 35 (11): 8389-8406.
[3] 姚讯杰,王佳玮,杨雁程,等. 金属构件激光增材制造缺陷产生机理及控制机制探究[J]. 中国激光, 2022, 49(14): 286-296.
YAO X J, WANG J W, YANG Y CH, et al. Investigation of the mechanism and control mechanism of defects in metal component laser additive manufacturing[J]. Chinese Journal of Lasers, 2022, 49(14): 286-296.
[4] RAO X, ZHANG F, LU Y, et al. Surface and subsurface damage of reaction-bonded silicon carbide induced by electrical discharge diamond grinding[J]. International Journal of Machine Tools and Manufacture, 2020, 154: 103564.
[5] RAVIMAL D, KIM H, KOH D, et al. Image-based inspection technique of a machined metal surface for an unmanned lapping process[J]. International Journal of Precision Engineering and Manufacturing-Green Technology, 2020, 7: 547-557.
[6] 陶显,侯伟,徐德. 基于深度学习的表面缺陷检测方法综述[J]. 自动化学报,2021,47(5):1017-1034.
TAO X, HOU W, XU D. A review of surface defect detection methods based on deep learning[J]. Acta

- Automatica Sinica, 2021, 47(5): 1017-1034.
- [7] 赵朗月, 吴一全. 基于机器视觉的表面缺陷检测方法研究进展[J]. 仪器仪表学报, 2023, 43(1): 198-219. ZHAO L Y, WU Y Q. Research progress on surface defect detection methods based on machine vision[J]. Chinese Journal of Scientific Instrument, 2023, 43(1): 198-219.
- [8] 谭博韬, 黄民, 刘跃, 等. 基于CNN-LSTM故障诊断的自动扶梯监测软件设计[J]. 电子测量技术, 2023, 46(12): 1-7. TAN B T, HUANG M, LIU Y, et al. Design of escalator monitoring software for fault diagnosis based on CNN-LSTM [J]. Electronic Measurement Technology, 2023, 46(12): 1-7.
- [9] REN Z, FANG F, YAN N, et al. State of the art in defect detection based on machine vision [J]. International Journal of Precision Engineering and Manufacturing-Green Technology, 2022, 9 (2): 661-691.
- [10] LIU Z, GAO Y, DU Q, et al. YOLO-extract: Improved YOLOv5 for aircraft object detection in remote sensing images[J]. IEEE Access, 2023, 11: 1742-1751.
- [11] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[J]. ArXiv preprint arXiv:2004.10934, 2020.
- [12] LI H, WU Z, ZHU C, et al. Learning from noisy anchors for one-stage object detection[C]. IEEE/CVF Conference on Computer Cision and Pattern Recognition, 2020: 10588-10597.
- [13] XIE X X, CHENG G, WANG J B, et al. Oriented R-CNN for object detection [C]. IEEE/CVF International Conference on Computer Vision, 2021: 3520-3529.
- [14] BHARATI P, PRAMANIK A. Deep learning techniques—R-CNN to mask R-CNN: A survey[J]. Computational Intelligence in Pattern Recognition: Proceedings of CIPR 2019, 2020: 657-668.
- [15] 吕秀丽, 杨昕升, 曹志民. 改进 YOLOv8 的 PCB 表面缺陷检测算法[J]. 电子测量技术, 2024, 47(12): 100-108. LYU X L, YANG X SH, CAO ZH M. Improved YOLOv8-based PCB surface defect detection algorithm[J]. Electronic Measurement Technology, 2024, 47(12): 100-108.
- [16] 陈榕榕, 陈壹华, 余松森, 等. SwinIdentity-YOLO: 基于Transformer改进 YOLOv5 的缺陷检测算法及其应用[J]. 微电子学与计算机, 2025, 42(7): 136-148. CHEN R R, CHEN Y H, YU S S, et al. SwinIdentity-YOLO: A Transformer-based improvement of YOLOv5 for defect detection and its application[J]. Microelectronics & Computers, 2025, 42(7): 136-148.
- [17] 徐浩, 李丰润, 陆璐. 基于双流 YOLOv4 的金属表面缺陷检测方法[J]. 计算机科学, 2024, 51(4): 209-216. XU H, LI F R, LU L. Metal surface defect detection method based on dual-stream YOLOv4[J]. Computer Science, 2024, 51(4): 209-216.
- [18] 齐向明, 董旭. 改进 YOLOv7-tiny 的钢材表面缺陷检测算法 [J]. 计算机工程与应用, 2023, 59 (12): 176-183. QI X M, DONG X. Improved YOLOv7-tiny algorithm for steel surface defect detection [J]. Computer Engineering and Applications, 2023, 59(12): 176-183.
- [19] LIU S, QI L, QIN H, et al. Path aggregation network for instance segmentation [C]. IEEE Conference on Computer Cision and Pattern Recognition, 2018: 8759-8768.
- [20] LI H, LI J, WEI H, et al. Slim-neck by GSConv: A lightweight-design for real-time detector architectures[J]. Journal of Real-Time Image Processing, 2024, 21(3): 62.
- [21] SINGH D, KUMAR V, KAUR M. Densely connected convolutional networks-based COVID-19 screening model[J]. Applied Intelligence, 2021, 51: 3044-3051.
- [22] LIU Y, SHAO Z, HOFFMANN N. Global attention mechanism: Retain information to enhance channel-spatial interactions [J]. ArXiv preprint arXiv: 2112.05561, 2021.
- [23] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[C]. European Conference on Computer Vision(ECCV), 2018: 3-19.
- [24] ZHANG X, ZHOU X, LIN M, et al. Shufflenet: An extremely efficient convolutional neural network for mobile devices[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2018: 6848-6856.
- [25] ZHANG H, ZHANG S. Focaler-IoU: More Focused Intersection over Union Loss [J]. ArXiv preprint arXiv:2401.10525, 2024.
- [26] BAI D, LI G, JIANG D, et al. Surface defect detection methods for industrial products with imbalanced samples: A review of progress in the 2020s [J]. Engineering Applications of Artificial Intelligence, 2024, 130: 107697.
- [27] HE Y, SONG K, MENG Q, 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.

作者简介

雷超, 硕士研究生, 主要研究方向为计算机视觉、目标检测。

E-mail: leichao233@163.com

陈德基, 博士, 教授, 主要研究方向为实时系统、工业互联网。

E-mail: dejichen@cw Xu. edu. cn

孙家栋(通信作者), 硕士, 讲师, 主要研究方向为模式识别、智能系统。

E-mail: sunjiadong@cw Xu. edu. cn

施珮, 博士研究生, 副教授, 主要研究方向为智能检测、图像处理。

E-mail: ship@cw Xu. edu. cn