

YOLOv8-SSDW: 基于 YOLOv8 的带钢表面缺陷检测算法

戴林华, 黎远松, 石睿

四川轻化工大学 计算机科学与工程学院, 四川 宜宾 643002

摘要:目的 针对现有带钢表面缺陷检测精度较低、存在漏检和误检等问题,提出了一种改进 YOLOv8 的缺陷检测算法 YOLOv8-SSDW。方法 该算法以 YOLOv8n 为基准模型,在骨干网络结构中引入 SKNet (Selective Kernel Networks) 注意力模块,加强骨干网络的特征提取能力和自适应能力,使网络在特征提取过程中更关注缺陷目标;同时,在 YOLOv8 的颈部使用 Slim-Neck 结构,减少模型的参数量和计算量;为进一步提升网络的特征提取能力,提出一种融合可变形卷积,强化对缺陷目标的特征学习;考虑缺陷样本质量不平衡问题,使用 WIoU (wise intersection over union) 损失函数,其梯度增益分配策略使问题得到有效改善,并且提高模型收敛速度和回归精度。结果 改进后的模型在带钢数据集上进行实验,结果表明:改进后的模型的平均精度达到 85.5%,相比基准模型提高了 2.7%。结论 通过大量实验可以证明改进网络的有效性,改善了带钢表面缺陷检测精度较低的问题,减少了漏检和误检的情况,同时满足实时性要求;相较于目前主流模型,该改进算法在检测精度具有一定优势,对后续研究用于实际检测具有参考价值。

关键词:YOLOv8; 注意力机制; 可变形卷积; WIoU

中图分类号:TP391.41 **文献标识码:**A **doi:**10.16055/j.issn.1672-058X.2025.0004.006

YOLOv8-SSDW: A Steel Surface Defect Detection Algorithm Based on YOLOv8

DAI Linhua, LI Yuansong, SHI Rui

School of Computer Science and Engineering, Sichuan University of Science & Engineering, Sichuan Yibin 643002, China

Abstract: Objective In response to the issues of low detection accuracy, missed detections, and false alarms in existing steel surface defect detection methods, an improved defect detection algorithm, YOLOv8-SSDW, based on YOLOv8, was proposed. **Methods** This algorithm took YOLOv8n as the benchmark model and introduced the SKNet (Selective Kernel Networks) attention module into the backbone network structure to enhance the feature extraction and adaptability of the backbone network, allowing the network to pay more attention to defect targets during the feature extraction process. At the same time, the Slim-Neck structure was used in the neck of YOLOv8 to reduce the number of model parameters and computational load. To further enhance the network's feature extraction capability, a deformable convolution fusion method was proposed to strengthen the feature learning for defect targets. Considering the imbalance in defect sample quality, the WIoU (wise intersection over union) loss function was used, which effectively addressed the issue through its

收稿日期:2023-12-11 **修回日期:**2024-05-15 **文章编号:**1672-058X(2025)04-0044-09

基金项目:国家自然科学基金资助项目(42074218)。

作者简介:戴林华(1999—),男,江西九江人,硕士,从事目标检测研究。Email: 3228958982@qq.com.

通信作者:黎远松(1970—),男,教授,硕士生导师,从事地图学与地理信息系统、在线实时测量与无损检测、机器学习等研究。

Email: yuansongli@suse.edu.cn.

引用格式:戴林华,黎远松,石睿. YOLOv8-SSDW: 基于 YOLOv8 的带钢表面缺陷检测算法[J]. 重庆工商大学学报(自然科学版), 2025, 42(4): 44-52.

DAI Linhua, LI Yuansong, SHI Rui. YOLOv8-SSDW: A steel surface defect detection algorithm based on YOLOv8[J]. Journal of Chongqing Technology and Business University (Natural Science Edition), 2025, 42(4): 44-52.

gradient gain allocation strategy, enhancing model convergence speed and regression accuracy. **Results** Experiments on the steel dataset showed that the average accuracy of the improved model reached 85.5%, which was an increase of 2.7% over the benchmark model. **Conclusion** Extensive experiments demonstrate the effectiveness of the improved network, which resolves the issue of low accuracy in steel strip surface defect detection, reduces missed and false detections, and meets real-time requirements. Compared with current mainstream models, the proposed model has certain advantages in detection accuracy and offers a valuable reference for practical detection in future research.

Keywords: YOLOv8; attention mechanism; deformable convolution; WIoU

1 引言

带钢在钢铁行业中占据了重要的地位,广泛应用于工业生产的各个领域。据调研数据显示,2023年8月,热轧带钢全国产量为728.82万吨。然而,在带钢生产过程中,由于环境因素的限制^[1-2],带钢表面易出现裂纹、划痕等缺陷。这些缺陷不仅影响带钢表面的外观,还会降低其使用寿命。因此,在生产过程中需要对带钢表面进行检测,及时发现缺陷产品。传统带钢表面缺陷检测有以下方法:人工检测法依靠检测人员用肉眼观察,该方法不仅速度慢,而且容易出现准确率、漏检和误检等问题;涡流检测法利用交流电检测是否存在缺陷,当存在大规模的缺陷时,检测速度可能会受到影响,因此这种方法在生产线上的应用可能会受到限制;红外检测法通过红外检测设备捕捉带钢表面温度的差异识别潜在缺陷,但该方法无法区分缺陷类型且成本较高;漏磁检测法将带钢置于磁场中,当带钢表面存在缺陷时,磁场会发生变化形成漏磁场。该方法虽然有效,但是当缺陷较小时难以检测,而且还有一定技术要求;激光扫描检测法利用激光投射,但这种方法在实际环境中容易受粉尘影响光线的反射,进而影响检测效果。上述传统方法都存在很大的局限性,难以解决目前带钢表面缺陷检测的问题。

近年来,随着计算机视觉领域的高速发展,越来越多研究者使用深度学习的方法进行缺陷检测研究。基于深度学习的方法主要有两类:一类以YOLO系列^[3]和SSD^[4]等代表的一阶段算法,一阶段算法不需要生成区域候选框的过程,直接生成检测类别和位置,一个阶段即可得到最终的检测结果;另一类以RCNN^[5]和Faster-RCNN^[6]等代表的两阶段算法,需要先进行区域候选框生成,然后进行样本分类。例如,翁玉尚等^[7]提出一种改进Mask R-CNN算法,采用k-means II聚类算法改进区域建议网络,同时去掉掩码分支。该方法

虽然提升了检测精度,但检测速度不佳。陆尧等^[8]提出基于Cascade RCNN算法改进,将主干网络的标准卷积替换成空洞卷积增加感受野,并添加特征金字塔自上而下的连接方式,同时采用CARAFE上采样提高采样精度,但裂纹缺陷检测精度仅46%,达不到检测要求。上述方法虽然通过改进网络算法提升性能,但是难以满足实时目标检测的需求。而一阶段算法,无需生成候选框,一个阶段即可检测的特点,大大节省了检测时间。因此,更适合缺陷检测。例如,马千文等^[9]利用MobileNetv2替换YOLOv3的主干网络,使用两个尺度的输出,使模型轻量化,但检测精度低并且还会出现缺陷目标检测的漏检和误检。Li等^[10]提出EFD-YOLOv4算法,利用残差连接有效扩大感受野,但模型的时间复杂度过高。Wang等^[11]提出YOLOv5-CD算法,在主干网络加入CA(Coordinate Attention)注意力机制,头部使用解耦的头部检测器,有效提高模型检测精度,但模型检测的实时性不佳。马燕婷等^[12]在YOLOv5主干网络中引入Transformer自注意力机制并与BiFPN网络结构相结合,同时使用轻量化网络RepVGG替换主干网络中的部分卷积层,虽然该方法的平均精度值达到了82.4%,但部分缺陷目标检测精度较低。卢俊哲等^[13]提出可变形卷积网络与原始YOLOv5结合,有效降低了模型的计算量,但检测精度较差。Huang等^[14]提出改进YOLOv8n算法,引入GhostNetv2模块,使模型的表达能力提高,但模型的时间复杂度过高。

综上所述,现有研究方法往往通过提高模型的特征提取能力来提高检测精度,并通过实验证明其改进的有效性,为后续研究提供了一些启发,但普遍存在检测精度不佳的问题。针对这些问题,提出YOLOv8-SSDW算法,有效提高了缺陷检测精度,本文的主要贡献如下:在骨干网络中添加SKNet注意力,实现网络对缺陷目标自适应调节;引入Slim-Neck结构,减少参数

量的同时降低计算量;为增强网络学习缺陷目标的信息能力,提出一种融合可变形卷积,将可变形卷积 DCNv2 与主干网络的倒数第二个 C2f 模块相融;使用 WIoU 损失函数,改善缺陷样本质量不平衡问题,提高模型检测精度。

2 YOLOv8 算法及其改进

YOLOv8 是 Ultralytics 公司开发的 YOLO(You Only Look Once) 物体检测和图像分割模型的最新版本。YOLOv8 是一种优秀的一阶段算法模型,建立在先前 YOLOv5 成功基础上,将骨干网络和颈部网络的 C3 结构换成了梯度流丰富的 C2f 模块,同时对不同尺度的模

型调整通道数;Head 部分换成了主流的解耦头结构,将分类与检测分离,并从 Anchor-Based 换成 Anchor-Free,进一步提高模型的性能和结构的灵活性。YOLOv8 提供多个版本,分为 n 、 s 、 m 、 l 、 x , 5 个不同的版本,模型权重大小依次增加。考虑缺陷检测需求,同时 YOLOv8 具有良好的实时性和准确度,且目前主流模型难以兼顾实时性和准确度,因此本文选择最小版本 YOLOv8n 进行改进。

为实现带钢表面缺陷检测更高的检测精度要求,提出 YOLOv8-SSDW 带钢表面缺陷检测算法。YOLOv8-SSDW 网络结构如图 1 所示。

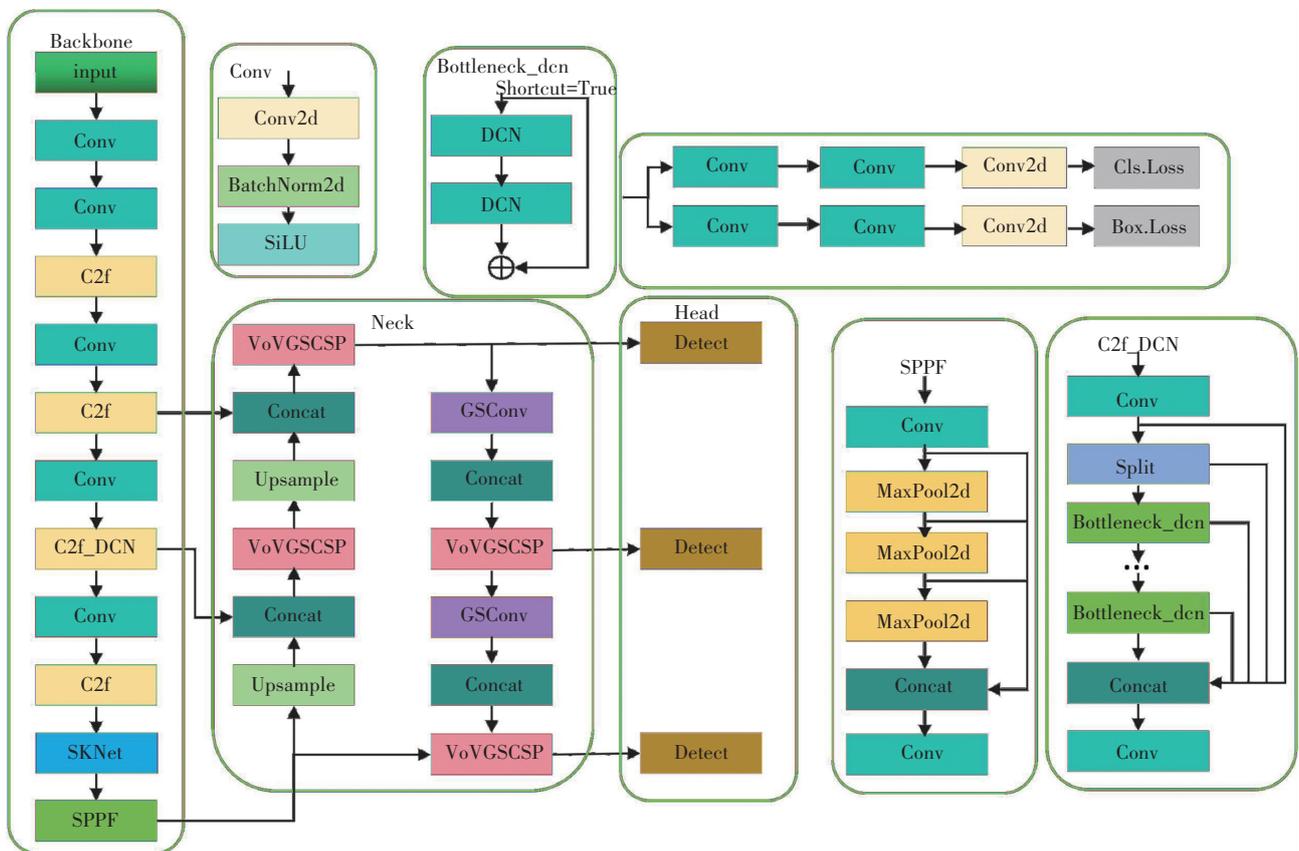


图 1 YOLOv8-SSDW 网络结构

Fig. 1 Network structure of YOLOv8-SSDW

2.1 SK 注意力机制

带钢表面缺陷数据集存在分辨率较低、缺陷目标形状和尺寸差异较大等问题,使模型难以准确识别和定位目标。因此,在基准模型中引入 SKNet 模块。该模块是基于 SENet 模块的改进,SENet 带来轻量级的门控机制,可以通过 channel-wise 的重要性自校准特征图。SKNet 是首个通过引入注意力机制明确地关注神经元的自适应调整感受野大小的模块。它是一种通道注

意力机制,利用非线性方法聚合多个卷积核的信息,实现神经元的自适应感受野大小。这种特性使 SKNet 可以为不同的缺陷样本生成不同的卷积核。将其引入 YOLOv8 骨干网络,能进一步加强特征提取能力,使网络聚焦于感兴趣区域,优化算法。实现 SKNet 需要通过 3 个操作:分割(Split)、融合(Fuse)和选择(Select),其网络结构如图 2 所示。分割是使用 3×3 、 5×5 两个不同大小的卷积核,分别对输入特征图进行卷积、批量标准

化、ReLU 激活,分别得到 $U1$ 和 $U2$;融合是利用门控法控制多个分支信息,首先对上一步分割得到的两个分支通过元素求和融合两个分支得到 U ,如式(1)所示:

$$U1+U2=U \quad (1)$$

然后进行全局平均池化,生成通道方面的信息 $s \in \mathbf{R}^c$,即 s 的第 c 个元素通过空间维度 $H \times W$ 收缩 U 来计算:

$$s_c = F_{sp}(U_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W U_c(i,j) \quad (2)$$

此外,再对 S 进行全连接操作得到 $Z \in \mathbf{R}^{d \times 1}$,以降低维度提高效率:

$$Z = F_{fc}(s) = \delta(B(Ws)) \quad (3)$$

其中, δ 是 ReLU 函数, B 是批量标准化, $W \in \mathbf{R}^{d \times c}$ 使用

缩减比 r 控制 d 值:

$$d = \max(C/r, 32) \quad (4)$$

选择是在通道方向使用 softmax 函数得到不同尺度的权重矩阵 a 和 b ,如式(5)所示:

$$a_c = \frac{e^{A_c z}}{e^{A_c z} + e^{B_c z}}, b_c = \frac{e^{B_c z}}{e^{A_c z} + e^{B_c z}} \quad (5)$$

其中, $A, B \in \mathbf{R}^{d \times c}$, A_c, B_c 分别为 A 的第 c 行和 B 的第 c 行, a_c, b_c 分别为 a 和 b 的第 c 个元素,且 a, b 分别为 $U1$ 和 $U2$ 的权重向量,再分别对 $U1$ 和 $U2$ 进行加权融合操作并最终得到特征图 V ,如式(6)所示:

$$V_c = a_c \cdot U1 + b_c \cdot U2, a_c + b_c = 1 \quad (6)$$

其中, $V = [V_1, V_2, V_3, V_4, \dots, V_c]$, $V_c \in \mathbf{R}^{H \times W}$.

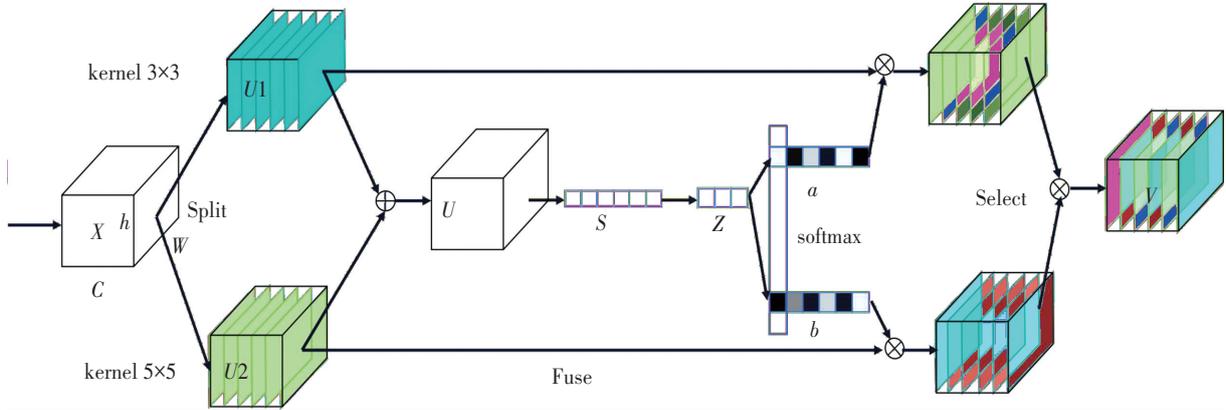


图 2 SKNet 网络结构

Fig. 2 Network structure of SKNet

2.2 Slim-neck 结构化

计算机视觉领域的发展使模型的计算精度不断提升,这并非仅靠增大模型参数量实现,还需采用轻量级的设计策略。深度可分离卷积虽然可以减少模型的参数量和计算的时间复杂度,但其特征提取和融合能力远远低于标准卷积。基于 DensNet^[15]、VoVNet^[16] 和 CSPNet^[17] 方法理论设计出 Slim-Neck 结构,该设计有效改善了上述问题。为进一步提高模型的检测性能,利用其设计思想优化 YOLOv8 颈部网络。首先使用轻量级卷积 GSConv 代替标准卷积。GSConv 卷积通过将卷积与标准卷积、深度可分离卷积和 shuffle 混合实现,其结构如图 3 所示。GSConv 的计算成本约为标准卷积的一半,同时对模型性能的提升与后者相当。GSConv 还能更好地平衡模型的准确性和速度。然后,在 GSConv 模块启发下,构建了跨级部分网络模块,即 VoV-GSCSP。这种设计简化了网络结构,同时确保精度不受影响,其模块结构如图 4 所示。在 YOLOv8 的 Neck

部分引入 Slim-Neck,用轻量化卷积 GSConv 替换传统卷积 Conv,同时用 VoV-GSCSP 模块替换 Neck 中的 C2f 模块,降低模型的参数量和计算复杂度,同时提高模型的检测精度。

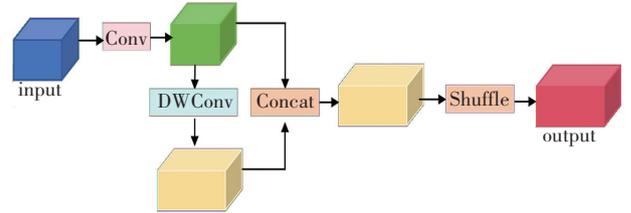


图 3 GSConv 网络结构图

Fig. 3 Network structure of GSConv

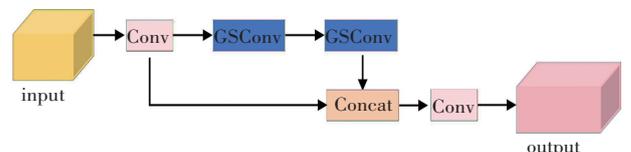


图 4 VoV-GSCSP 网络结构

Fig. 4 Network structure of VoV-GSCSP

2.3 可变形卷积

YOLOv8 中的传统卷积采用固定的卷积核尺寸,无法更好地处理缺陷目标的几何形状变化。DAI 等^[18]提出的可变形卷积网络 DCN (Deformable Convolution Networks) 可以很好地解决这个问题。DCN 实际上是在标准卷积操作过程中的采样位置增加一个偏移量,使可变形卷积根据不同的目标进行各种尺度、长宽比和旋转的变换,同时增大其感受野的范围,以更好地适应物体的几何形变^[19]。如图 5 所示,在可变形卷积的操作流程中,偏移量是通过在同一输入特征图上应用单独的卷积层进行训练而获得的。由可变形卷积得到的公式为

$$y(p_0) = \sum_{k=1}^K w_k \cdot x(p_0 + p_k + \Delta p_k) \quad (7)$$

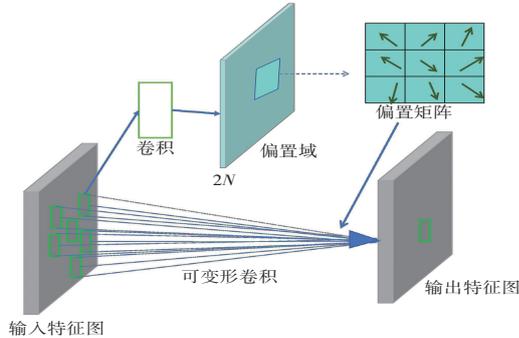


图 5 可变形卷积

Fig. 5 Deformable convolution

其中, x, y 分别为输入、输出特征图, K, k 分别为采样点总数和采样位置点, P_0 为输出特征图的当前位置, w_k 和 p_k 分别为第 k 个采样点投影权重、预定义卷积网格采样的第 k 个位置, Δp_k 为第 k 个位置对应的偏移量。但该版本的可变形卷积感受野对应位置超出了目标范围,导致特征不受图像内容影响。为解决无关区域问题,提出可变形卷积 DCNv2 (Deformable ConvNets v2), 提高特征提取能力。相比于 DCN, DCNv2 扩展了可变形卷积, 增强建模能力, 同时提出特征模拟方案指导网络培训, 引入权重项进行惩罚, 将不感兴趣的位置权重设为 0, 其公式为

$$y(p_0) = \sum_{k=1}^K w_k \cdot x(p_0 + p_k + \Delta p_k) \cdot \Delta m_k \quad (8)$$

式(8)中, Δm_k 为第 k 个位置的调制标量, 调制标量 Δm_k 在 $[0, 1]$ 范围。

将可变形卷积融入 YOLOv8 的特征层, 如图 6 所示, 在特征提取时, 通过调整尺度缺陷感受野, 适应缺陷目标大小以提高卷积的学习能力, 优化算法。

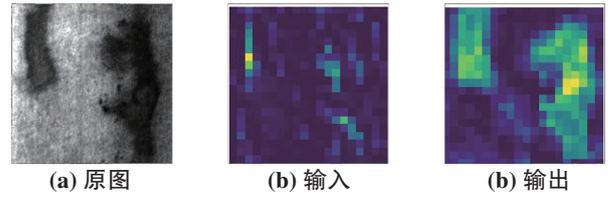


图 6 可变形卷积模块的输入与输出特征图

Fig. 6 Input and output feature maps for DCN module

2.4 损失函数优化

目标检测性能与回归的损失函数设计有重要关系, 基准模型使用 CIoU 作为损失函数。CIoU 损失虽考虑重叠面积、中心点距离和长宽比, 但长宽比描述是相对值, 存在模糊性, 且未考虑难易样本平衡问题, 可能导致模型收敛速度慢和预测准确度低, 而带钢表面缺陷样本存在质量不平衡。为此, 本文采用 WIoU 损失函数代替 CIoU 损失函数, 更好地解决样本不平衡问题, 同时提高模型收敛速度。此方法采用动态非单调聚焦的梯度增益分配策略, 旨在降低高质量锚框的竞争优势, 并减轻由低质量样本产生的不利梯度影响, 使模型具有更高的精确度。同时根据距离度量构建距离注意力机制, 得到具有两层注意力机制的 WIoUv1, 如式(9)所示:

$$L_{\text{WIoUv1}} = R_{\text{WIoU}} \cdot L_{\text{IoU}} \quad (9)$$

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

式(9)中, R_{WIoU} 表示高质量锚框损失, (x, y) 表示锚框的位置对应目标框的位置 (x_{gt}, y_{gt}) , W_g, H_g 分别为最小包围框的高和宽, $*$ 表示为分离操作。该方法没有引入长宽比且有效地消除阻碍收敛的因素。为使模型更聚焦困难样本, 提升分类性能, 利用单调聚焦系数 $L_{\text{IoU}}^{\gamma*}$ 构成 WIoUv2, 如式(10)所示:

$$L_{\text{WIoUv2}} = L_{\text{IoU}}^{\gamma*} L_{\text{WIoUv1}}, \gamma > 0 \quad (10)$$

但在模型训练过程中, $L_{\text{IoU}}^{\gamma*}$ 随着 IoU 损失的减少而减少, 影响模型收敛, 为此引入 IoU 损失的均值作为归一化因子, 如式(11)所示:

$$L_{\text{WIoUv2}} = \left(\frac{L_{\text{IoU}}^*}{L_{\text{IoU}}}\right)^{\gamma} L_{\text{WIoUv1}} \quad (11)$$

3 仿真实验与结果分析

3.1 实验数据集

采用公开 NEU-DET 数据集, 该数据集是带钢表面缺陷数据集, 包含 6 种缺陷图像: 压入氧化铁皮 (rolled-in_scale, RS)、裂纹 (crazing, Cr)、麻点 (pitted_surface, PS)、斑块 (patches, Pa)、划痕 (scratches, Sc)、夹杂 (inclusion, In)。数据集中每种缺陷的图像有 300 张, 共 1 800 张, 图像样本如图 7 所示。

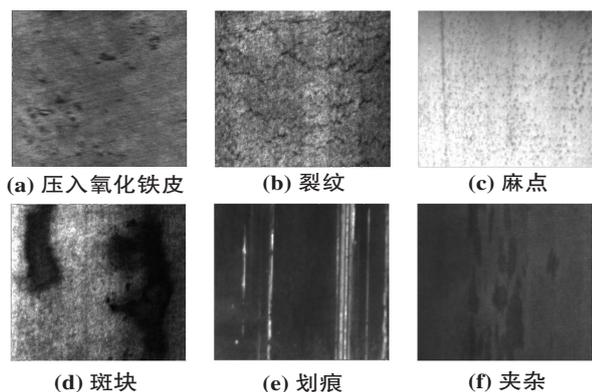


图7 缺陷示意图

Fig. 7 Schematic diagrams of defects

为增强缺陷检测模型的稳定性,使模型能够更好地检测出缺陷。本实验通过裁剪、平移、旋转等方式对数据集进行增强,将基础数据集扩充到7 200张。为使模型有效训练,将数据集按7:1:2的比例分为训练集6 300张图片、验证集900张图片和测试集1 800张图片。

3.2 实验环境及参数设置

实验使用GPU进行训练,实验环境操作系统为ubuntu20.04,显卡RTX A4000,CPU为Intel(R) Xeon(R) Gold 5320,Cuda11.3,采用PyTorch 1.10.0深度学习框架,使用Python 3.8编程。训练图像分辨率为640×640,批量大小Batch size设为16,迭代次数设为120,学习率设为0.01,动量参数设为0.937,权重衰减系数为0.0005,并使用SGD随机梯度下降优化器。

3.3 评价指标

实验选取召回率(recall) R 、准确率(precision) P 、平均精度(AP)、平均精度均值(mean average precision)mAP、参数数量和浮点运算作为评价指标,并使用变量 f_{AP} 和 f_{mAP} 分别表示平均精度和平均精度均值,公式如下:

$$P = \frac{T_p}{T_p + F_p} \quad (12)$$

$$R = \frac{T_p}{T_p + F_N} \quad (13)$$

$$f_{AP} = \int_0^1 P(R) dR \quad (14)$$

$$f_{mAP} = \frac{1}{n} \sum_{i=0}^n AP(i) \quad (15)$$

其中, T_p 、 F_p 和 F_N 分别表示正确检测的缺陷目标数量、错误检测的缺陷目标数量和漏检的缺陷目标数量。

3.4 注意力机制实验

为验证引入SKNet注意力机制的优越性,同时对不同注意力机制对缺陷检测性能的影响,选取CBAM、SE、GAM、SimAM注意力机制进行对比,实验结

果如表1所示。

表1 注意力对比实验

Table 1 Attention contrast experiments /%			
模块	P	R	f_{mAP}
—	82.4	75.6	82.8
CBAM	80.0	73.8	80.8
SE	80.0	74.4	80.8
GAM	81.8	75.6	82.3
SimAM	79.8	73.4	80.8
SKNet	83.2	76.8	84.2

由表1可知,只有SKNet注意力机制有提升, f_{mAP} 达到84.2%,其他注意力模块的效果不理想。为更直观地观察添加各种注意力机制模块的效果,生成图像热力图,如图8所示,SKNet注意力相比其他方法,对缺陷位置的热力值更高,位置更精准,使模型更有效提高对缺陷目标的聚焦,增强特征提取能力。

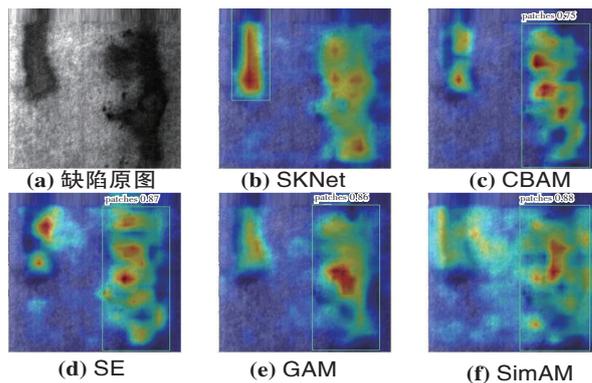


图8 注意力对比热力图

Fig. 8 Attention contrast heat map

3.5 损失函数对比实验

为验证引入WIoU损失函数对缺陷检测性能有更好的提升,选取CIoU、DIoU、GIoU、SIoU和EIoU等常用的边界框回归损失函数与本文使用的WIoU损失函数作对比实验。实验结果如表2所示。由实验结果可知,引入DIoU和WIoU的平均精准度高于其他损失函数,但DIoU的精确度不及基准模型采用的CIoU损失函数。相比之下,WIoU损失函数的精确度和平均精准度都高于CIoU以及其他损失函数。这得益于WIoU采用动态非单调聚焦机制,使模型聚焦于普通缺陷样本质量的锚框,保证模型性能的平衡性。WIoU损失作为回归损失,通过提高模型的收敛速度,使模型具有更好的预测效果。如图9所示,WIoU的收敛速度更快,效果最好。同时,Pa类型缺陷的平均精度(AP)达到了96.3%。因此,选用WIoU作为损失函数更有利于提高缺陷检测性能。

表 2 损失函数对比实验

Table 2 Comparative experiments with loss functions

/%

损失函数	P	R	f_{mAP}	f_{AP}					
				RS	Cr	PS	Pa	Sc	In
CIoU	82.4	75.6	82.8	74.3	63.6	89.8	95.9	92.9	80.4
DIoU	80.5	77.0	83.2	73.6	63.9	92.0	95.8	94.0	79.8
GIoU	80.1	76.6	82.2	72.6	61.8	90.4	95.3	93.3	79.8
SIoU	81.0	75.3	82.0	72.9	60.4	90.2	95.4	93.5	79.6
EIoU	79.5	74.0	80.4	70.5	57.8	88.5	95.3	92.9	77.3
WIoU	83.2	77.2	83.7	75.1	67.2	90.4	96.3	93.2	80.0

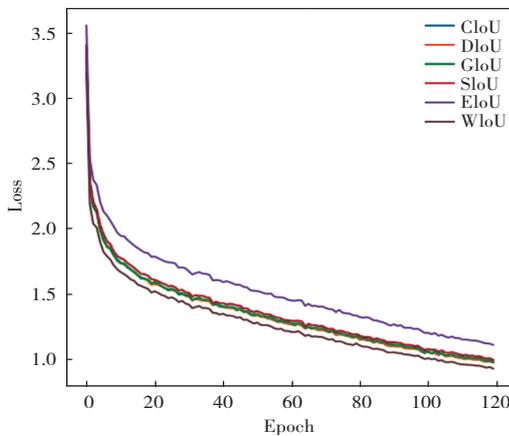


图 9 损失函数对比

Fig. 9 Comparison of loss functions

3.6 消融实验

为分析模型的每项改进点对模型性能提升的作用,设计了 8 组消融实验。具体来说,以 YOLOv8n 模型为基准实验;模型 YOLOv8n_1 表示使用 WIoU 损失函数;模

型 YOLOv8n_2 表示在主干网络引入可变形卷积,将其融合到原来的主干网络的倒数第 2 个 C2f 模块中;模型 YOLOv8n_3 表示在颈部网络引入 Slimneck 结构化;模型 YOLOv8n_4 表示在主干网络引入 SKNet 注意力机制;模型 YOLOv8n_5 表示在模型 YOLOv8n_4 的基础上引入 Slimneck 结构化;模型 YOLOv8n_6 表示在 YOLOv8n_5 基础上引入可变形卷积;最后的 YOLOv8-SSDW 的模型引入所有改进。由表 3 可得,仅在主干网络的 SPPF 模块之前单独引入 SKNet 注意力机制,模型的 mAP 提高了 1.4%,对模型的检测精度提升最为显著。SKNet 通过自适应调节感受野大小,提取缺陷信息,增强模型检测的精确度。另外,在颈部网络单独引用 Slimneck 结构,参数量和计算量分别下降了 6.9%和 9.8%,但精度略降,其原因是模型的特征提取信息不佳。采用 Slimneck 结构和 SKNet 注意力模块配合能够得到更好的性能,mAP 提高了 1.8%。因此,Slimneck 结构并不适合单独使用。

表 3 消融实验

Table 3 Ablation experiments

模型	SKNet	Slimneck	DCN	WIoU	$P/\%$	$R/\%$	$f_{mAP}/\%$	Params/M	GFLOPs/G
YOLOv8n	—	—	—	—	82.4	75.6	82.8	3.01	8.1
YOLOv8n_1	—	—	—	✓	83.2	77.2	83.7	3.01	8.1
YOLOv8n_2	—	—	✓	—	82.2	76.0	83.5	3.04	8.0
YOLOv8n_3	—	✓	—	—	80.9	75.8	82.3	2.80	7.3
YOLOv8n_4	✓	—	—	—	83.2	76.8	84.2	8.57	12.5
YOLOv8n_5	✓	✓	—	—	83.6	76.6	84.6	8.35	11.7
YOLOv8n_6	✓	✓	✓	—	83.2	77.3	84.7	8.38	11.5
YOLOv8-SSDW	✓	✓	✓	✓	83.2	78.9	85.5	8.38	11.5

随后在此基础上,在主干网络的倒数第 2 个 C2f 模块中单独引入可变形卷积 DCNv2,使得特征融合过程中保留更多的缺陷信息,其 mAP 值达到了 84.7%,相比基准模型提高了 1.9%。最后采用 WIoU 损失函数,

增强模型的收敛能力,同时 mAP 提升至 85.5%。

3.7 缺陷检测结果对比分析

为更直观看出本文算法的有效性,以图像的方式展示基准模型和 YOLOv8-SSDW 的检测结果。如图 10

所示,输入 6 种不同的缺陷,原始 YOLOv8n 模型存在漏检,且对小目标检测效果一般。相比之下,本文的

YOLOv8-SSDW 模型检测具有明显优势。

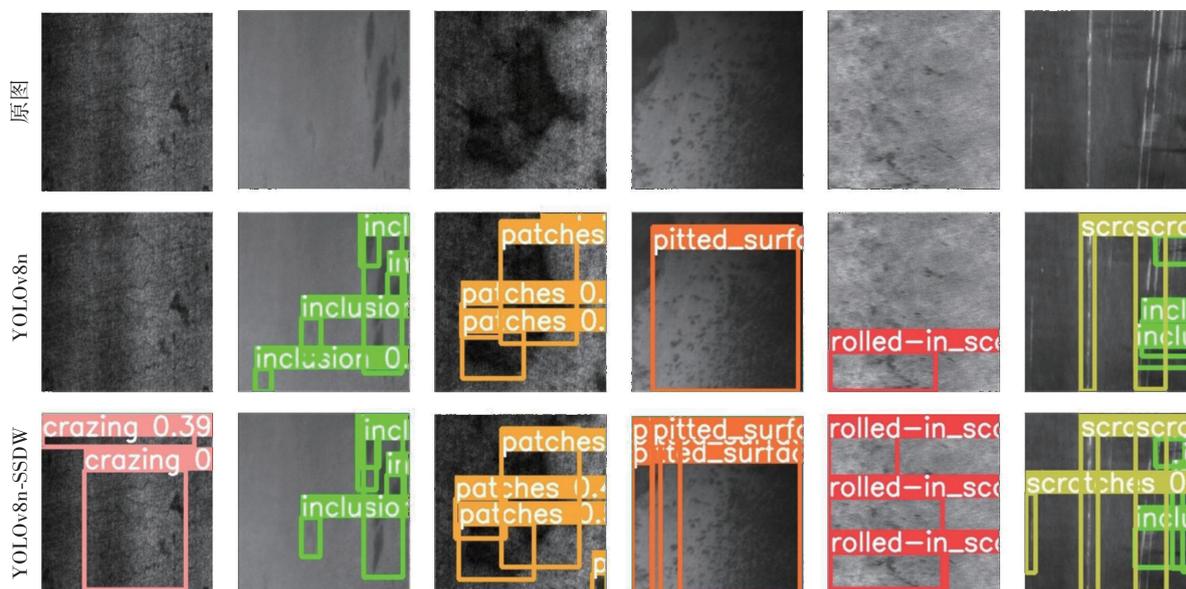


图 10 YOLOv8n 与 YOLOv8-SSDW 检测可视化对比

Fig. 10 Visual comparison between YOLOv8n and YOLOv8-SSDW detection

3.8 对比实验

为进一步验证改进后模型的性能,将其与目前主流模型: SSD、YOLOv3、YOLOv5、CenterNet、YOLOv7 和 YOLOX 等算法进行对比实验,实验结果如表 4 所示。

表 4 算法对比

Table 4 Comparison of algorithms

模型	P/%	R/%	$f_{mAP}/%$	FPS/s	Params/M
SSD	70.2	47.1	68.6	47.8	26.29
YOLOv3	51.6	61.4	57.6	294.1	8.68
YOLOv5n	67.1	68.2	71.2	163.9	1.77
YOLOv5s	70.5	73.3	76.9	142.9	7.03
YOLOv7	68.4	73.7	75.5	42.4	36.51
YOLOX	88.0	72.5	84.4	67.1	8.97
CenterNet	79.4	63.3	74.5	37.4	32.67
YOLOv8n	82.4	75.6	82.8	137	3.01
本文算法	83.2	78.9	85.5	95.2	8.38

由表 4 可知,本文算法的参数量相较于基准算法有所增加,但依然适合部署在移动端,并且其精确度、召回度和平均精度均值相比于基准 YOLOv8n 分别提升了 0.8%、3.3%和 2.7%,进一步证明了本文改进算法的有效性。与其他算法相比,本算法相比于 YOLOv3,精确度、召回度和平均精度均值分别提升了 31.6%、17.5%和 27.9%;相比于 YOLOv5n 和 YOLOv7,精确度

分别提升了 16.1%和 14.8%;与 CenterNet 相比,平均精度均值提升了 11%,参数量减少了 24.29M。本文算法的 FPS 相较于基准 YOLOv8n 有所下降,原因是引入了更复杂的模块结构,但该算法依然满足带钢表面缺陷实时检测的要求,可实现实际场景的部署。综上所述,相较于目前主流模型,本文算法具有更优的检测性能。

4 结论

针对现有带钢表面缺陷检测算法在实际检测中的问题,本文在 YOLOv8n 的基础上进行改进,在主干网络中引入 SKNet 和可变形卷积加强网络特征提取能力,在颈部采用 Slim-neck 结构化机制,最后使用 WIoU 损失函数,提高检测精度。通过大量的消融实验和对比实验,验证了改进后算法的可行性,同时也突出本文算法的优越性,有效提高带钢表面缺陷检测算法的检测精度,同时还减少了缺陷目标检测的漏检和误检,且该算法适合实际检测,满足带钢表面缺陷检测算法的需求。在今后的工作中,将继续优化该模型,对模型进行轻量化,在保证检测精确度的同时提升检测速度。

参考文献(References):

[1] 王少,陈斌,司小明,等. 热轧板带表面质量智能化自动判定系统的开发应用[J]. 中国冶金, 2019, 29(7): 70-73, 78.
WANG Shao, CHENG Bin, SI Xiao-ming, et al. Development and application of intelligent automatic judgment system for surface quality of hot-rolled strip[J]. China

- Metallurgy, 2019, 29(7): 70–73, 78.
- [2] 李维刚, 徐康, 李金灵, 等. 热轧带钢表面缺陷识别算法研究与应用[J]. 钢铁, 2022, 57(10): 139–147.
LI Wei-gang, XU Kang, LI Jin-ling, et al. Research and application of surface defect identification algorithm for hot-rolled strip[J]. Iron and Steel, 2022, 57(10): 139–147.
- [3] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Piscataway, NJ: IEEE, 2016: 779–788.
- [4] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]//Proceedings of the 14th European Conference on Computer Vision Amsterdam. The Netherlands: Springer, 2016: 21–37.
- [5] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2014: 580–587.
- [6] REN S, HE K, 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, 2017, 39(6): 1137–1149.
- [7] 翁玉尚, 肖金球, 夏禹. 改进 Mask R-CNN 算法的带钢表面缺陷检测[J]. 计算机工程与应用, 2021, 57(19): 235–242.
WENG Yu-shang, XIAO Jin-qiu, XIA Yu. Strip surface defect detection based on improved Mask R-CNN algorithm[J]. Computer Engineering and Applications, 2021, 57(19): 235–242.
- [8] 陆尧, 薛林, 王云森, 等. 基于 Cascade RCNN 的热轧带钢表面缺陷检测[J]. 仪表技术与传感器, 2023(8): 101–106+126.
LU Yao, XUE Lin, WANG Yun-sen, et al. Surface defect detection of hot-rolled strip based on Cascade RCNN [J]. Instrumentation Technology and Sensors, 2023(8): 101–106, 126.
- [9] 马千文, 刘国华. 基于轻量化 YOLOv3 的带钢表面缺陷检测方法[J]. 光电子·激光, 2023, 34(7): 743–751.
MA Qian-wen, LIU Guo-hua. Strip surface defect detection method based on lightweight YOLOv3[J]. Optoelectronics & Laser, 2023, 34(7): 743–751.
- [10] LI S, KONG F, WANG R, et al. EFD-YOLOv4: A steel surface defect detection network with encoder-decoder residual block and feature alignment module[J]. Measurement, 2023, 220(5): 1–10.
- [11] WANG B, WANG M, YANG J, et al. YOLOv5-CD: Strip steel surface defect detection method based on coordinate attention and a decoupled head[J]. Measurement: Sensors, 2023, 30(5): 1–6.
- [12] 马燕婷, 赵红东, 阎超, 等. 改进 YOLOv5 网络的带钢表面缺陷检测方法[J]. 电子测量与仪器学报, 2022, 36(8): 150–157.
MA Yan-ting, ZHAO Hong-dong, YAN Chao, et al. Strip steel surface defect detection method by improved YOLOv5 network[J]. Journal of Electronic Measurement and Instrumentation, 2022, 36(8): 150–157.
- [13] 卢俊哲, 张铨怡, 刘世鹏, 等. 面向复杂环境中带钢表面缺陷检测的轻量级 DCN-YOLO [J]. 计算机工程与应用, 2023, 59(15): 318–328.
LU Jun-zhe, ZHANG Cheng-yi, LIU Shi-peng, et al. Lightweight DCN-YOLO for strip surface defect detection in complex environments[J]. Computer Engineering and Application, 2023, 59(15): 318–328.
- [14] HUANG M, CAI Z. Steel surface defect detection based on improved YOLOv8[C]//International Conference on Algorithms, High Performance Computing, and Artificial Intelligence (AHPCAI 2023). SPIE, 2023, 12941: 1356–1360.
- [15] HUANG G, LIU Z, VAN DER M L, et al. Densely connected convolutional networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, NJ: IEEE, 2017: 4700–4708.
- [16] LEE Y, HWANG J, LEE S, et al. An energy and GPU-computation efficient backbone network for real-time object detection[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Piscataway, NJ: IEEE, 2019: 1–11.
- [17] WANG C Y, LIAO H Y M, WU Y H, et al. CSPNet: A new backbone that can enhance learning capability of CNN[C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops. Piscataway, NJ: IEEE, 2020: 390–391.
- [18] DAI J, QI H, XIONG Y, et al. Deformable convolutional networks[C]//Proceedings of the IEEE International Conference on Computer Vision. Piscataway, NJ: IEEE, 2017: 764–773.
- [19] 李富豪, 赵希梅. 基于 D-Unet 神经网络的鼻腔鼻窦肿瘤分割算法[J]. 计算机工程, 2022, 48(1): 281–287.
LI Fu-hao, ZHAO Xi-mei. Nasal cavity and paranasal sinuses tumor segmentation algorithm based on D-Unet neural network[J]. Computer Engineering, 2022, 48(1): 281–287.

责任编辑: 吴 倩