

# 基于 HPDE-YOLO 的钢材表面缺陷检测算法

冯迎宾, 刘文泽

(沈阳理工大学 自动化与电气工程学院, 沈阳 110159)

**摘要:** 针对钢材表面缺陷检测算法精度低、计算量大等问题, 提出一种基于 YOLOv8n 的检测算法 HPDE-YOLO (high-level path aggregation dynamic efficient network-YOLO)。首先, 引入高效多尺度注意力 (efficient multi-scale attention, EMA) 机制, 与主干部分的 C2f 融合, 增强特征提取能力, 并采用 C2f-Faster 结构提高模型计算速度; 其次, 提出一种高级筛选双向特征融合金字塔与路径聚合网络 (high-level screening-feature bidirectional fusion pyramid and path aggregation network, HS-FPAN), 在多个尺度上同时增强语义特征, 有效提升模型对细节的捕捉能力; 最后, 融合动态上采样模块 DySample, 进一步提升模型检测速度。在 NEU-DET 数据集上的实验结果表明, 相较 YOLOv8n 模型, HPDE-YOLO 模型检测的平均精度均值 mAP@0.5 达到 84.2%, 提升了 5.7 个百分点, 裂纹类缺陷检测的平均精度均值 mAP 提升了 26.88 个百分点, 参数量减少了 45%, 浮点运算量减少了 32%。HPDE-YOLO 模型在满足轻量化的同时能够有效提升钢材表面缺陷检测的精度, 且易于移动端部署, 满足工业生产需求。

**关键词:** YOLOv8n; 缺陷检测; 轻量化; 特征融合; DySample

中图分类号: TP391.4 文献标志码: A DOI:10.3969/j.issn.1003-1251.2025.01.005

## Steel Surface Defect Detection Algorithm Based on HPDE-YOLO

FENG Yingbin, LIU Wenzhe

(Shenyang Ligong University, Shenyang 110159, China)

**Abstract:** To address the issues of low accuracy and high computational demand in steel surface defect detection algorithms, a detection algorithm based on YOLOv8n, named HPDE-YOLO, is proposed. Initially, an efficient multi-scale attention (EMA) mechanism is introduced, which is integrated with the backbone's C2f to enhance feature extraction capabilities. It is coupled with a C2f-Faster structure to improve the model's computational speed. Subsequently, a high-level screening-feature bidirectional fusion pyramid with path aggregation network is proposed, which simultaneously strengthens semantic features at multiple scales, effectively enhancing the model's ability to capture details. Finally, the model's detection speed is further increased by incorporating a dynamic upsampling module, DySample. Experimental results on the NEU-DET dataset show that compared to the YOLOv8n model, the HPDE-YOLO model achieves an average mean precision (mAP) of 84.2% at an IoU threshold of 0.5, representing an improvement of 5.7 percentage points. Specifically, the mAP for crack defect detection has increased by 26.88 percentage points. Additionally, the model reduces the number of parameters by 45% and floating-point operations by 32%. The HPDE-YOLO model not only effectively improves the accuracy of steel surface defect detection while

being lightweight but also facilitates deployment on mobile devices, meeting the demands of industrial production.

**Key words:** YOLOv8n; defect detection; lightweight; feature fusion; DySample

我国为钢材出口大国,近年来出口量大幅增长。钢材在生产和加工过程中会受到各种外力因素影响,导致出现各种各样的产品缺陷,影响其在相关领域中的应用,特别是航空航天、汽车等需要精密器件的行业。因此,关系到产品质量和加工安全的钢材表面缺陷检测具有重要意义。

随着科技发展,传统人工检测及激光红外检测等方法存在耗时多、精度低等问题,逐渐无法满足工业生产的要求,机器学习方法则存在计算复杂、对环境适应性差等问题。目前,速度快、精度高、鲁棒性强的深度学习方法成为钢材缺陷检测的主要研究方向之一<sup>[1]</sup>。常见的基于深度学习的目标检测算法可分为一阶段和两阶段算法:两阶段算法主要有 R-CNN、Fast R-CNN、Faster R-CNN 算法等,该类算法包括特征提取和候选框分类回归两部分,检测精度较高;一阶段算法主要有 YOLO 系列和单次多框检测器(SSD)等,该类算法只需一个阶段即可同时完成特征提取和分类,检测速度较快。

杨珂等<sup>[2]</sup>提出了一种将 ROI Align 插值和 Faster R-CNN 模型相结合的方法,用于检测铸件缺陷,提高了模型多尺度特征融合能力,有效减小了漏检风险。Liu 等<sup>[3]</sup>提出了一种基于 Faster R-CNN 的检测模型,其中并行的卷积结构由空洞卷积组成,有效减少了信息的混淆。杨锦辉等<sup>[4]</sup>将 GhostConv 卷积引入 YOLOv5s,减少了模型参数量,实现了模型轻量化。曹义亲等<sup>[5]</sup>对 YOLOv5 算法进行了改进,构建了 SPP\_Res 特征金字塔结构,并加入多头注意力机制,有效提高了对语义信息的获取能力。以上改进算法取得了一定效果,但对于小尺度目标的检测仍不理想。Wang 等<sup>[6]</sup>基于 YOLO-V7 算法,引入加权双向特征金字塔网络,提升了网络在融合不同层次特征时的性能,并有效降低了卷积过程中钢材表面缺陷特征信息的丢失,但计算量过大。张文铠等<sup>[7]</sup>在 YOLOv8s 算法中添加了 Triplet 模块,并引入 CARAFF 上采样算子,同时将损失函数替换为 Siou,虽然在一定程度上提高了检测的平均精度,但对裂纹类缺陷检测精度仍不理想,且参数量较大。

为解决上述问题,本文以 YOLOv8n 为基础算法进行改进。为使模型能够提取到更多的特征

信息并提高模型处理特征的能力,将原模型主干网络第 8 层融入高效多尺度注意力 (efficient multi-scale attention, EMA) 机制和加速模块 FasterBlock,为进一步加快检测速度,将原主干网络第 2、4、6 层中特征融合模块 C2f 改进为更高效的 C2f-Faster 模块;为提高 YOLOv8n 对小目标缺陷检测的精度,受文献[8]启发,将原模型颈部网络进行重构,运用双向融合策略,在 HS-FPN (high-level screening-feature fusion pyramid network) 结构中增设一个自底部向上的多层网络结构,提出一种高级筛选双向特征融合金字塔与路径聚合网络 (high-level screening-feature bidirectional fusion pyramid and path aggregation network, HS-FPAN);在对原模型颈部网络重构的同时,采用 DySample<sup>[9]</sup> 替换其中的上采样模块,以提升检测精度和处理速度。本文将经上述三方面改进后的算法简称为 HPDE-YOLO (high-level path aggregation dynamic efficient network-YOLO)。

## 1 HPDE-YOLO 算法

HPDE-YOLO 网络结构如图 1 所示。图中: Backbone 表示主干部分; Neck 表示颈部; Head 表示头部; Conv 表示卷积模块; SPPF 表示金字塔池化操作; CAHSPAN 表示含 CA 特征选择模块的选择性特征融合模块; Multiply 表示乘法操作; Detect 表示检测头; Add 表示加和操作。

### 1.1 高效多尺度特征提取模块 EMA

为提高模型训练与推理速度,将 FasterNet 中的 FasterBlock 融入 C2f 中的瓶颈 (Bottleneck) 部分,通过融合部分卷积 (PConv),实现高效的空问特征提取,降低模型计算量。PConv 的浮点运算次数 (FLOPs) 计算式为

$$\text{FLOPs}_{\text{PConv}} = H \times W \times K^2 \times c_p^2 \quad (1)$$

式中:  $H$  和  $W$  分别表示所提取特征图的高和宽;  $K$  为卷积核大小;  $c_p$  为进行卷积的通道数。由于 PConv 通道数只有标准卷积的 1/4,故其计算量只有标准卷积的 1/16。每个信息传递阶段包含一系列 FasterNet 块,且每个 FasterNet 块由一个 PConv 层和两个逐点卷积 (PWConv) (或  $1 \times 1$  卷积) 层组成。该结构采用批量归一化和 ReLU 激活层有

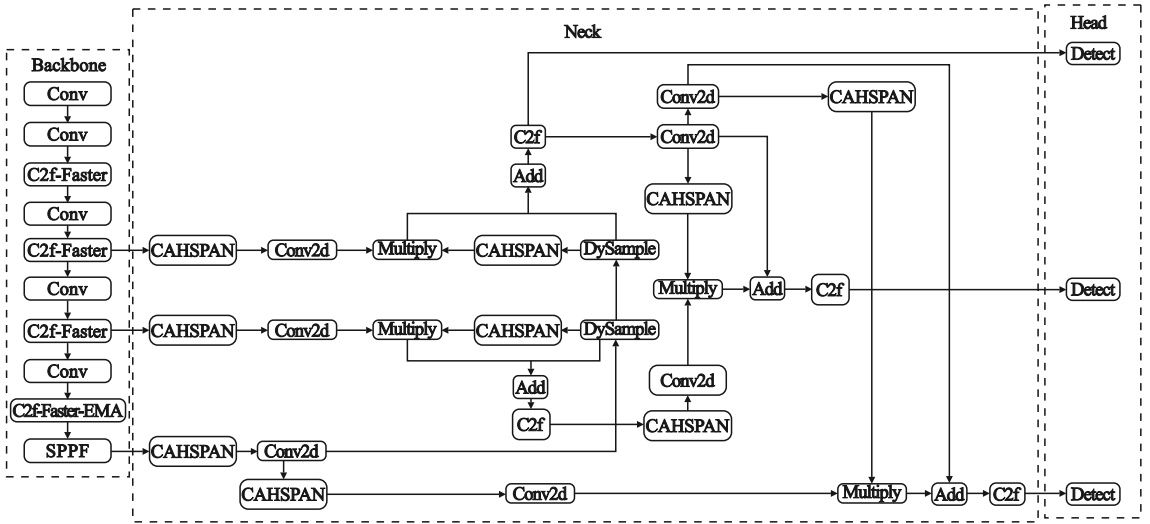


图 1 HPDE-YOLO 网络结构图

Fig. 1 HPDE-YOLO network structure diagram

效降低 FLOPs, 加快计算速度。

为增强像素间的依赖关系, 部分研究中引入卷积块注意力模块<sup>[10]</sup> (CBAM)、高效通道注意力模块 (ECA)<sup>[11]</sup> 等, 提高了目标检测能力, 但这些注意力模块包含大量池化操作, 显著增加了计算需求。为此, 本文采用 EMA 机制, 其能够在不降低的情况下进行跨通道建模, 避免传统方法可能导致的深度视觉信息损失等问题。EMA 使用三条平行路径提取分组特征图的动态聚焦权重描述符, 从而捕获跨通道的交互特征, 实现跨空间学习, 其网络结构如图 2 所示。图中: Groups 表示划分的组; X AvePool 和 Y AvePool 分别表示一维水平和垂直方向全局池化; Softmax 为软最大化激活函数; Matmul 为矩阵乘法; Concat 为连接操作; Sigmoid 为 S 型激活函数; GroupNorm 表示归一化方法; Rw 表示重塑后的批量维度。

## 1.2 HS-FPAN-DySample 模块

### 1.2.1 HS-FPAN 模块

原始 YOLOv8n 模型在面对特征稀疏和图像质量低下等检测场景时, 存在识别困难、精度低等问题, 且只对某些特定类型的缺陷识别效果较好, 对多类别缺陷的识别缺乏适用性。因此, 采用多级融合策略增强模型特征的表达能。受 HS-FPAN 启发, 设计一种高级筛选双向特征融合网络 HS-FPAN, 其结构如图 3 所示。图中: S1 ~ S5、P2 ~ P5、N2 ~ N5、M2 ~ M5 分别表示不同的模块; CA 表示特征选择模块; DM 表示维度匹配模块; SFF 表示选择性特征融合模块。

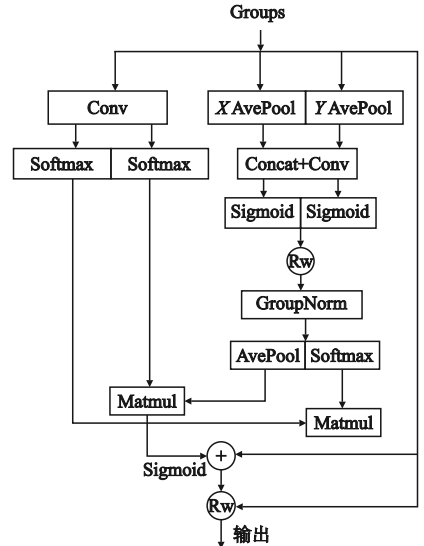


图 2 EMA 网络结构图

Fig. 2 EMA network structure diagram

为增强模型特征表达能力并解决错误分类、特征稀疏、图像质量差等问题。HS-FPAN 通过层级较高的特征作为权重指导一个通道筛选出更为基础的低级特征信息, 同时收集关键特征信息, 并将筛选后的低级特征与高级特征合并, 以优化全局特征的提取效果。

HS-FPAN 主要包括特征选择模块和特征融合模块两部分。

#### 1) 特征选择模块

特征选择 (CA) 模块首先对输入的钢材表面缺陷特征图  $f_{in}$  ( $f_{in} \in \mathbf{R}^{C \times H \times W}$ , 其中  $C$  为通道数) 进行全局平均池化和全局最大池化, 得到新的特征; 然后使用 Sigmoid 激活函数确定每个通道的权重值  $f_{CA}$  ( $f_{CA} \in \mathbf{R}^{C \times 1 \times 1}$ )。CA 模块通过全局最大池

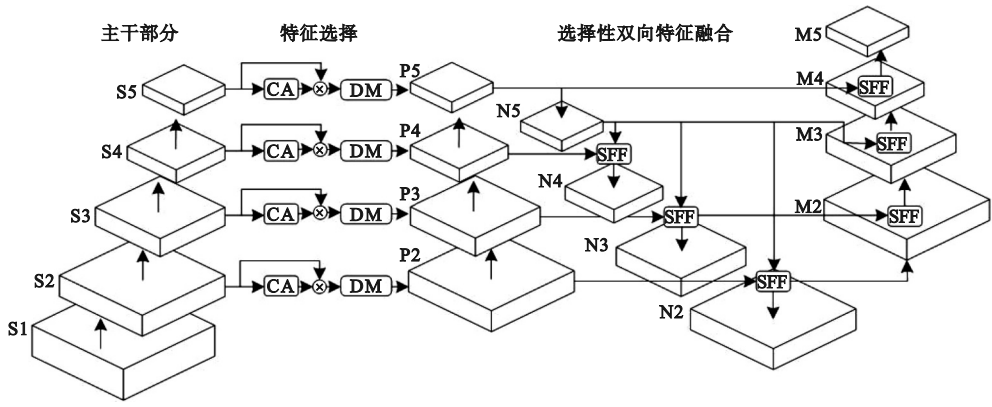


图3 HS-FPAN网络结构

Fig.3 HS-FPAN network structure

化提取每个通道中相关性最高的数据,通过全局平均池化将特征图上每个池化窗口内的像素取平均值,以获取特征图中数据,最小化信息的丢失。这种结合使用两种池化方法的策略使得CA模块能够有效提取每个通道中的关键信息,同时保持信息的完整性。CA模块结构如图4所示。为使不同通道数的特征有效融合,DM模块通过 $1 \times 1$ 卷积操作将通道数统一降至256,以确保不同尺度特征图之间的维度一致性。




图4 CA模块结构

Fig.4 CA module structure

## 2) 特征融合模块

主干网络生成的多尺度特征图含有丰富的高层语义信息,但目标定位较为粗糙,低层特征图虽然能够提供更精确的目标位置信息,但缺乏足够的语义内容。本文借鉴HS-FPN的经验,采用选择性特征融合(selective feature fusion, SFF)模块,并使用拼接操作。SFF模块结构如图5所示。




图5 SFF模块结构

Fig.5 SFF module structure

SFF模块把高层特征作为筛选权重,有选择性地提炼低层特征中的重要语义信息,实现一种策略性的特征融合。给定一个输入高层特征 $f_{high}$  ( $f_{high} \in \mathbf{R}^{C \times H \times W}$ ) 和一个输入低层特征 $f_{low}$  ( $f_{low} \in \mathbf{R}^{C \times H_1 \times W_1}$ ,  $H_1$  和  $W_1$  为对应特征图的高度和宽度)。SFF先使用步长为2、卷积核为 $3 \times 3$ 的转置卷积(T-Conv)扩展高层特征得到高级特征图 $f_{high}$  ( $f_{high} \in \mathbf{R}^{C \times 2H \times 2W}$ );然后通过双线性插值(BL)对上述高层特征进行上采样或下采样,用以匹配低层特征的维度,得到相应的采样特征图 $f_{att}$  ( $f_{att} \in \mathbf{R}^{C \times H_1 \times W_1}$ );再使用CA模块将高级特征转换为相应的注意力权重,用以过滤低尺度特征;将经过筛选的低分辨率特征图与相应高分辨率特征图进行拼接,生成一个更为完善且语义丰富的特征图,并输出融合后的特征图 $f_{out}$  ( $f_{out} \in \mathbf{R}^{C \times H_1 \times W_1}$ )。选择性特征融合公式表示为

$$f_{att} = \text{BL}(\text{T-Conv}(f_{high})) \quad (2)$$

$$f_{out} = f_{low} \times \text{CA}(f_{att}) + f_{att} \quad (3)$$

HS-FPAN采用双向融合策略,将以上两个模块连接,通过自底向上的特征融合,缩短了不同层级特征之间的信息路径,将高分辨率和低分辨率特征图相融合;通过自顶向下的路径增强,增强了低层特征的语义信息,避免了信息损失。HS-FPAN通过两个模块协同工作,可有效解决目标检测中的多尺度问题,提高检测准确性和鲁棒性。

### 1.2.2 DySample模块

尽管动态上采样器CARAFE<sup>[12]</sup>、FADE和SAPA可有效提升检测性能,如张文钺等<sup>[7]</sup>在基于改进YOLOv8s的钢材表面缺陷检测算法中采用了CARAFE上采样算子,检测精度平均提升了2.2个百分点,但同时引入了大量的计算负载,而FADE和SAPA对高分辨率特征的需求在某种程

度上限制了其应用场景。由 Liu 等<sup>[9]</sup>提出的轻量动态上采样模块 DySample 解决了上述问题,其避开动态卷积,采用点采样方法构建上采样模块,对给定的上采样比例因子  $s$  和尺寸为  $C \times H \times W$  的特征映射  $\mathbf{x}$ ,使用输入和输出通道分别为  $C$  和  $2gs^2$  ( $g$  为通过网格采样函数生成的采样点数量)的线性层,生成尺寸为  $2gs^2 \times H \times W$  的偏移量  $\mathbf{O}$ 。为增加偏移量灵活性,进一步通过对输入特征的线性映射生成逐点的动态范围因子,并通过 Sigmoid 函数和静态因子生成偏移量,最终偏移量与原始网格采样加和生成采样集。静态因子取为 0.5,既可防止空间位移可能导致的图像失真,又能避免因重叠而影响边界附近的预测。偏移量生成过程表示为

$$\mathbf{O} = 0.5 \text{Sigmoid}(\text{linear}_1(\mathbf{x})) \cdot \text{linear}_2(\mathbf{x}) \quad (4)$$

式中  $\text{linear}$  表示线性映射函数。

使用 DySample 更加节省资源、更高效,且易于使用 PyTorch 中的内置标准函数来实现,满足钢材表面缺陷检测的实时性。DySample 网络结构如图 6 所示,图中  $\mathbf{x}'$  表示通过上采样生成的较大尺寸图像。




图 6 DySample 网络结构

Fig. 6 DySample network structure

将 HS-FPAN 和 DySample 结合得到的 HS-FPAN-DySample 特征融合模块参数量少、计算量小、特征表达能力强,可提升图像处理效率和质量,适于计算量有限的工业生产中钢材表面缺陷检测。具体融合过程表示为

$$f_{\text{att}}' = \text{DS}(\text{T-Conv}(f_{\text{high}})) \quad (5)$$

$$f_{\text{out}}' = f_{\text{low}} \times \text{CA}(f_{\text{att}}') + f_{\text{att}}' \quad (6)$$

式中:DS 表示 DySample 上采样过程; $f_{\text{att}}'$  表示上采样后的特征图; $f_{\text{out}}'$  表示融合后的特征图。

## 2 实验及结果分析

### 2.1 实验平台及参数设置

实验环境如表 1 所示。训练过程中,为得到局部最优值,初始学习率设为 0.01,学习率动量设为 0.937,为防止模型过拟合和梯度爆炸,同时保

持模型参数的数值稳定性,设置权重衰减系数为 0.0005,根据个人设备选取批次大小为 32,训练轮次为 350,输入图像大小为  $640 \times 640$  像素,为更好地调整模型,在最后 10 个训练迭代周期关闭 Mosaic 增强。

表 1 实验环境

Table 1 Experimental environment

名称	环境配置
操作系统	Windows11
CPU	Intel(R) Core(TM) i5-13600KF
GPU	NVIDIA GeForce RTX 4070 SUPER
深度学习框架	Pytorch1.13.1
开发环境	Python3.11
加速计算框架	CUDA12.1

### 2.2 实验数据集

本文使用 NEU-DET 钢材缺陷数据集,其中包含 1 800 张灰度图像,训练集、验证集、测试集按照 8:1:1 进行划分,训练集共 1 440 张,每类缺陷各 240 张,测试集和验证集各 180 张图像,每类缺陷各 30 张,该数据集共包含六种类别缺陷,分别是裂纹、夹杂物、斑块、点蚀面、轧入氧化皮、划痕,部分带标签数据集图像如图 7 所示。




图 7 部分带标签数据集图像

Fig. 7 Partially labeled dataset images

### 2.3 评价指标

采用精确率、召回率、各类平均精度均值 mAP(Cr 表示裂纹类、In 表示夹杂物类、Pa 表示斑块类、Ps 表示点蚀面类、Rs 表示轧入氧化皮类、

Sc 表示划痕类)、平均精度均值  $mAP@0.5$ 、参数量、浮点运算量 (GFLOPs) 等评价模型检测的性能。

## 2.4 不同位置嵌入 C2f-Faster-EMA 的对比实验

为验证 C2f-Faster-EMA 的有效性及其最佳嵌入位置,进行对比实验,结果如表 2 所示。表中 C2f-Faster-EMA- $i$  ( $i = 1, 2, 3, 4$ ) 表示在图 1 中主干部分由上至下第  $i$  个 C2f 位置嵌入的 C2f-Faster-EMA。

由表 2 可知,不同嵌入位置的 C2f-Faster-EMA 均可在一定程度上提升检测精度。与 YOLOv8n 相比,引入 C2f-Faster-EMA-1、C2f-Faster-EMA-2、C2f-Faster-EMA-3、C2f-Faster-EMA-4、C2f-Faster-EMA (全局) 时算法的  $mAP@0.5$  分别提升了 0.76%、2.29%、0.89%、3.57%、2.55%,引入 C2f-Faster-EMA-4 时提升最多。此外,引入 C2f-Faster-EMA-4 时较好地平衡了检测的精确率及召回率,满足工业生产中稳定性要求。故 C2f-Faster-EMA-4 为

最佳嵌入位置,该模块可有效提取语义信息,模型的识别与定位更准确。

表 2 不同位置嵌入 C2f-Faster-EMA 的实验结果

Table 2 Experimental results of C2f-Faster-EMA with different embedding positions

嵌入位置	精确率	召回率	$mAP@0.5$
YOLOv8n	0.753	0.748	0.785
C2f-Faster-EMA-1	0.796	0.727	0.791
C2f-Faster-EMA-2	0.668	0.740	0.803
C2f-Faster-EMA-3	0.666	0.828	0.792
C2f-Faster-EMA-4	0.779	0.740	0.813
C2f-Faster-EMA(全局)	0.684	0.768	0.805

## 2.5 消融实验

为验证模型改进效果,以 YOLOv8n 算法为基础进行消融实验,分别对引入 C2f-EMA、C2f-Faster-EMA、HS-FPN、HS-FPAN、HS-FPAN-DySample、HPDE-YOLO 的模型进行对比,实验结果如表 3 所示。

表 3 消融实验结果

Table 3 Results of ablation experiments

模型	精确率	参数量	GFLOPs	召回率	$mAP@0.5$
YOLOv8n	0.753	3 006 818	8.1	0.748	0.785
YOLOv8n-C2f-EMA	0.779	3 017 186	8.2	0.740	0.813
YOLOv8n-C2f-Faster-EMA	0.814	2 305 986	6.4	0.739	0.818
YOLOv8n-HS-FPN	0.697	1 934 428	6.9	0.843	0.827
YOLOv8n-HS-FPAN	0.796	2 082 594	7.1	0.794	0.832
YOLOv8n-HS-FPAN-DySample	0.762	2 012 898	6.5	0.771	0.838
HPDE-YOLO	0.801	1 654 322	5.5	0.815	0.842

由表 3 可知:与原 YOLOv8n 模型相比, YOLOv8n-C2f-EMA 模型的参数量与浮点运算量基本保持不变,平均精度均值  $mAP@0.5$  提高了 2.8 个百分点;与 YOLOv8n-C2f-EMA 模型相比, YOLOv8n-C2f-Faster-EMA 模型的参数量下降了 23.5%、浮点运算量下降了 22%;引入 HS-FPN 模块后的 YOLOv8n-HS-FPN 模型与 YOLOv8n 模型相比较,参数量下降了 36.6%、浮点运算量下降了 15%, $mAP@0.5$  提高了 4.2 个百分点;引入本文提出的 HS-FPAN 模块后,模型 YOLOv8n-HS-FPAN 的参数量和浮点运算量与 YOLOv8n-HS-FPN 基本一致,相较原模型,其  $mAP@0.5$  提高了 4.7 个百分点,再通过 DySample 改进上采样模块后,模型的浮点运算量进一步下降,且  $mAP@0.5$

有一定程度提升;本文采用三种方案共同改进后的 HPDE-YOLO 模型与原 YOLOv8n 模型相比较,参数量减少了 45%,浮点运算量下降了 32%,且其  $mAP@0.5$  提高了 5.7 个百分点,召回率和精确率分别提高了 9.0% 和 6.4%,进一步验证了本文模型的可靠性。

## 2.6 不同模型的对比实验

为进一步验证本文 HPDE-YOLO 模型的有效性,将其与其他主流目标检测算法在 NEU-DET 数据集上进行对比实验,结果如表 4 所示,表中  $mAP$  后括号内字母表示缺陷类别。

由表 4 可知,HPDE-YOLO 对小目标裂纹的检测效果显著优于其他模型,且在平均精度上也取得了有效提升,同时参数量和浮点运算量均大

幅下降,与最新的 YOLOv5-EDGS 改进算法相比也有较大的优势,其在实现高精度的同时也保持

了模型的轻量化。综合来看,HPDE-YOLO 在钢材表面缺陷检测中表现良好。

表 4 不同模型的对比实验结果

Table 4 Experimental results of different models

模型	mAP(Cr)/ %	mAP(In)/ %	mAP(Pa)/ %	mAP(Ps)/ %	mAP(Rs)/ %	mAP(Sc)/ %	mAP/ %	参数量/ 10 <sup>6</sup>	GFLOPs
Faster R-CNN	36.01	81.77	88.37	81.32	59.56	86.33	72.23	137.09	402.1
SSD	38.32	80.67	94.01	82.42	67.87	71.13	72.40	26.28	282.0
RetinaNet	36.22	81.37	91.23	82.04	60.57	88.21	73.27	37.97	191.4
YOLOv5s	39.32	79.13	96.32	87.43	60.44	84.35	74.49	9.15	24.2
YOLOX	34.33	84.67	96.89	88.76	66.83	89.48	76.83	54.21	156.0
YOLOv7	38.89	82.07	93.29	81.74	62.19	83.97	73.69	37.62	106.5
YOLOv8	43.31	87.09	95.14	96.53	61.19	87.81	78.51	3.01	8.1
YOLOv5-EDGS <sup>[13]</sup>	43.60	87.00	94.90	83.10	62.40	91.20	77.00	3.98	—
本文模型	70.19	89.91	99.17	99.46	57.64	89.05	84.24	1.65	5.5

## 2.7 缺陷检测效果

为进一步验证算法的优越性,使用改进前后的模型对测试集进行检测,部分检测结果如图 8 所示。由图 8 可见,原 YOLOv8n 模型对部分目标

存在漏检,对于小目标类(如裂纹)的漏检问题尤为严重,而 HPDE-YOLO 模型明显改善了漏检问题。HPDE-YOLO 能够对钢材表面缺陷进行有效检测,可为实际应用提供可靠方案。

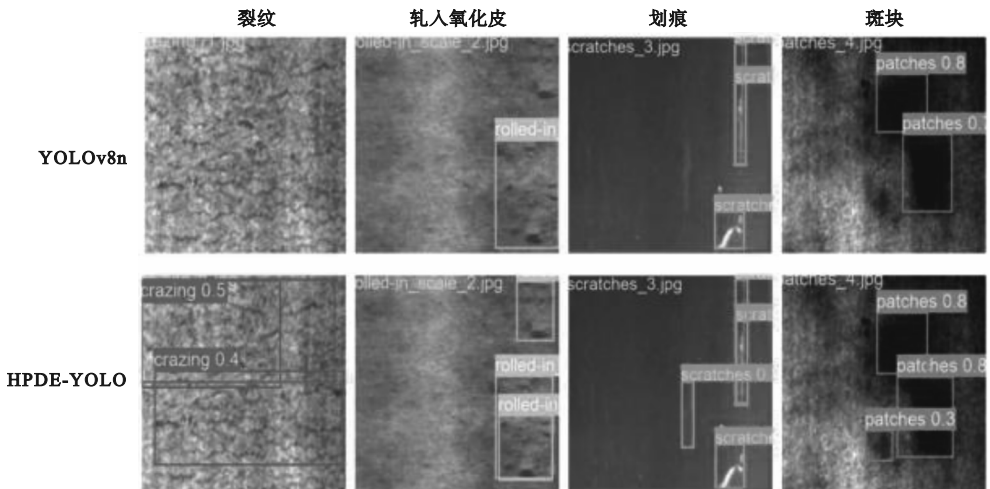


图 8 部分检测结果对比

Fig. 8 Comparison of partial detection results

## 3 结论

为解决小目标(如裂纹等)检测精度不足且计算量大等问题,提出了一种适于钢材表面缺陷的检测模型 HPDE-YOLO。对 YOLOv8n 主干网络中 Bottleneck 进行融合创新,为高效提取特征,引入 FasterNet,并在此基础上融合 EMA 进行二次创新,增强了特征提取能力;对特征融合网络部分重

新构造,提出一种新的特征融合方法 HS-FPAN,解决目标太小、分辨率过低带来的多尺度问题,提高了特征融合能力;引入动态上采样模块 DySample,解决了工业生产中计算负载过高、实时性差等问题。实验结果表明,HPDE-YOLO 在 NEU-DET 数据集上的 mAP@0.5 达到 84.2%,相较于 YOLOv8n 模型,提升了 5.7 个百分点,其中裂纹类目标检测的 mAP 提高了 26.88 个百分点,参数量减少了 45%,浮点运算量减少了 32%,从多个

方面证明了模型的有效性。

## 参考文献 (References):

- [1] SINGH S A, DESAI K A. Automated surface defect detection framework using machine vision and convolutional neural networks[J]. *Journal of Intelligent Manufacturing*, 2023, 34(4): 1995–2011.
- [2] 杨珂, 方诚, 段黎明. 基于深度学习模型融合的铸件缺陷自动检测[J]. *仪器仪表学报*, 2021, 42(11): 150–159.
- YANG K, FANG C, DUAN L M. Automatic detection of casting defects based on deep learning model fusion[J]. *Chinese Journal of Scientific Instrument*, 2021, 42(11): 150–159. (in Chinese)
- [3] LIU R Q, HUANG M, GAO Z M, et al. MSC-DNet: an efficient detector with multi-scale context for defect detection on strip steel surface[J]. *Measurement*, 2023, 209: 112467.
- [4] 杨锦辉, 李鸿, 杜芸彦, 等. 基于改进 YOLOv5s 的轻量化目标检测算法[J]. *电光与控制*, 2023, 30(2): 24–30.
- YANG J H, LI H, DU Y Y, et al. A lightweight object detection algorithm based on improved YOLOv5s[J]. *Electronics Optics & Control*, 2023, 30(2): 24–30. (in Chinese)
- [5] 曹义亲, 伍铭林, 徐露. 基于改进 YOLOv5 算法的钢材表面缺陷检测[J]. *图学学报*, 2023, 44(2): 335–345.
- CAO Y Q, WU M L, XU L. Steel surface defect detection based on improved YOLOv5 algorithm[J]. *Journal of Graphics*, 2023, 44(2): 335–345. (in Chinese)
- [6] WANG Y, WANG H Y, XIN Z H. Efficient detection model of steel strip surface defects based on YOLO-V7[J]. *IEEE Access*, 2022, 10: 133936–133944.
- [7] 张文铠, 刘佳. 基于改进 YOLOv8s 的钢材表面缺陷检测[J]. *北京信息科技大学学报(自然科学版)*, 2023, 38(6): 33–40.
- ZHANG W K, LIU J. Steel surface defect detection based on improved YOLOv8s[J]. *Journal of Beijing Information Science & Technology University (Science and Technology Edition)*, 2023, 38(6): 33–40. (in Chinese)
- [8] CHEN Y F, ZHANG C Y, CHEN B, et al. Accurate leukocyte

detection based on deformable-DETR and multi-level feature fusion for aiding diagnosis of blood diseases[J]. *Computers in Biology and Medicine*, 2024, 170: 107917.

- [9] LIU W Z, LU H, FU H T, et al. Learning to upsample by learning to sample[C]//2023 IEEE/CVF International Conference on Computer Vision (ICCV). Paris, France: IEEE, 2023: 6004–6014.
- [10] 张嘉雄, 曾水玲, 李昭贤. 基于改进 YOLOv7 的钢板表面缺陷检测的方法[J/OL]. *控制工程*, 2024; 1–11 [2024–04–07]. <https://link.cnki.net/urlid/21.1476.TP.20240329.1525.004>.
- ZHANG J X, ZENG S L, LI Z X. Method for surface defect detection in steel plates based on improved YOLOv7[J/OL]. *Control Engineering of China*, 2024; 1–11 [2024–04–07]. <https://link.cnki.net/urlid/21.1476.TP.20240329.1525.004>. (in Chinese)
- [11] 卢俊哲, 张毓怡, 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 J Z, ZHANG C Y, LIU S P, et al. Lightweight DCN-YOLO for strip surface defect detection in complex environments[J]. *Computer Engineering and Applications*, 2023, 59(15): 318–328. (in Chinese)
- [12] 王春梅, 刘欢. YOLOv8-VSC: 一种轻量级的带钢表面缺陷检测算法[J]. *计算机科学与探索*, 2024, 18(1): 151–160.
- WANG C M, LIU H. YOLOv8-VSC: lightweight algorithm for strip surface defect detection[J]. *Journal of Frontiers of Computer Science and Technology*, 2024, 18(1): 151–160. (in Chinese)
- [13] 甄国涌, 赵林榕, 李文越, 等. 改进 YOLOv5 的钢材表面缺陷检测网络轻量化研究[J]. *组合机床与自动化加工技术*, 2024(3): 58–63.
- ZHEN G Y, ZHAO L R, LI W Y, et al. Research on lightweight of steel surface defect detection network based on improved YOLOv5[J]. *Modular Machine Tool & Automatic Manufacturing Technique*, 2024(3): 58–63. (in Chinese)

(责任编辑: 宋颖韬)

## (上接第30页)

- ZHANG T, SUI T, YU M D, et al. Research of ODBR-DCSK system modulation technology[J]. *Journal of Shenyang Ligong University*, 2021, 40(3): 24–28. (in Chinese)
- [14] SUI T, FENG Y X, JIANG Q, et al. Design and analysis of a short reference orthogonal double bit rate differential chaotic shift keying communication scheme[J]. *Electronics*, 2022, 11(13): 2020.
- [15] 武畅, 焦曙阳, 钱程东. 基于 GNURadio 与 USRP 的 OFDM 无线通信系统实验[J]. *实验科学与技术*, 2024, 22(1): 1–8.
- WU C, JIAO S Y, QIAN C D. OFDM wireless communication

system experiment based on GNURadio and USRP[J]. *Experiment Science and Technology*, 2024, 22(1): 1–8. (in Chinese)

- [16] 王若璇, 刘珩, 纪俊维. 基于 USRP 与 LabVIEW 的频谱感知实验平台设计[J]. *实验室科学*, 2023, 26(4): 53–57.
- WANG R X, LIU H, JI J W. Design of teaching experimental platform for spectrum sensing based on LabVIEW and USRP[J]. *Laboratory Science*, 2023, 26(4): 53–57. (in Chinese)
- [17] 陈俊. 差分混沌移位键控技术的研究与改进[D]. 重庆: 重庆邮电大学, 2020.

(责任编辑: 和晓军)