

基于 E-YOLO 的冷轧板材表面缺陷检测方法

陈 栋¹, 刘欣宜^{2,3,4}, 齐振涛¹, 杨配轻¹, 申 震¹

(1. 冀南技师学院 装备制造工程系, 河北 邯郸 056046; 2. 河北工程大学 机械与装备学院, 河北 邯郸 056038;
3. 河北省智能工业装备技术重点实验室, 河北 邯郸 056038; 4. 河北省冀南新区现代装备制造协同创新中心, 河北 邯郸 056038)

摘要: 在实际的制造系统中, 冷轧板材表面缺陷会导致材料强度下降造成安全风险, 而传统检测方法的准确率与稳定性难以保证。因此, 提出一种轻量且高效的缺陷检测模型 E-YOLO (Efficient-YOLO)。针对 YOLOv8 模型在小目标检测、特征提取效率及模型推理速度上的不足, 对其结构进行了创新优化, 修改了原始模型的低效颈部连接结构, 引入多分支特征融合机制, 并创新性地采用了特征重提取结构来增强模型对细微缺陷特征的感知能力。最后, 实验表明, 相较于 YOLOv8, E-YOLO 的检测准确率提高了 7.3%; 相较于大型模型 Faster RCNN, 其检测速度提升约 18 倍, 为冷轧板材表面缺陷的高效、准确检测提供了一种可行的方法。

关键词: 冷轧板材; 表面缺陷检测; 深度学习; YOLO; 轻量化模型

DOI: 10.13330/j.issn.1000-3940.2025.02.016

中图分类号: TH113.1; TG335.5 **文献标志码:** A **文章编号:** 1000-3940 (2025) 02-0125-07

Surface defect detection method on cold rolled sheet metal based on E-YOLO

Chen Dong¹, Liu Xinyi^{2,3,4}, Qi Zhentao¹, Yang Peiqing¹, Shen Zhen¹

(1. Department of Equipment Manufacturing Engineering, Jinan Technician College, Handan 056046, China;
2. School of Mechanical and Equipment Engineering, Hebei University of Engineering, Handan 056038, China;
3. Key Laboratory of Intelligent Industrial Equipment Technology of Hebei Province, Handan 056038, China;
4. Collaborative Innovation Center for Modern Equipment Manufacturing of Jinan New Area (Hebei), Handan 056038, China)

Abstract: In practical manufacturing systems, surface defects on the cold rolled sheet metal can lead to a decrease in material strength and pose a safety risk, while the accuracy and stability of traditional detection methods are difficult to guarantee. Therefore, a lightweight and efficient defect detection model E-YOLO (Efficient-YOLO) was proposed, and in response to the shortcomings of the YOLOv8 model in small target detection, feature extraction efficiency and model inference speed, the structural innovations and optimizations about YOLOv8 model were conducted. The inefficient neck connection structure of the original model was modified, the perception ability of the model for subtle defect features was enhanced by introducing a multi-branch feature fusion mechanism and innovatively adopting a feature re-extraction structure. Finally, experiments show that compared with YOLOv8, E-YOLO improves the detection accuracy by 7.3% and increases the detection speed by approximately 18 times compared with the larger model Faster RCNN, providing a feasible way for efficient and accurate detection of surface defects on cold rolled sheet metal.

Key words: cold rolled sheet metal; surface defect detection; deep learning; YOLO; lightweight model

在实际的制造系统中, 由于冷轧板材的表面缺陷会导致材料的强度下降, 进而产生安全相关的风险

[1]。但传统的人工检查方法成本高且受到工作时长影响, 准确率不稳定。漏磁检测法与红外检测法等[2]受材料特征的影响, 不能够准确地检测出缺陷类型。为了提高制造系统的安全性、减少经济损失并提高产品质量, 设计高效且准确的冷轧板材表面缺陷识别方法十分重要。

计算机视觉算法因其优秀的可扩展性和鲁棒性, 被广泛应用于各个领域, 早期的研究使用支持向量机、人工神经网络[3]等提取计算机图像中的特征。

收稿日期: 2024-09-06; 修订日期: 2024-12-05

基金项目: 河北省专精特新小巨人企业科技特派团资助项目 (SJ240140123); 河北工程大学创新基金项目 (SJ2401002049)

作者简介: 陈 栋 (1991-), 男, 硕士, 讲师

E-mail: 2313030095@qq.com

通信作者: 刘欣宜 (1993-), 女, 博士, 讲师

E-mail: liuxy93@126.com

例如, Zhang B Y 等^[4]提出了一种基于区域归一化互相关定位特征的算法,但此类方法仍然依赖于手动特征提取,效率较低,同时工件缺陷种类多样,表面情况复杂,更增加了检测的难度。卷积神经网络得益于其参数共享思路,相比传统检测方法极大地提高了效率,在机械领域受到了广泛的研究关注。例如,豆远航等^[5]利用基于卷积的对抗网络进行非接触应变测量图像的修复,取得了相比传统检测方法更高的准确率。而在缺陷检测中,典型的基于卷积神经网络的算法主要分为以 Faster-RCNN^[6]为代表的两阶段算法与以 YOLO 系列^[7]为代表的单阶段算法。相较于其他分类任务,冷轧板材表面受生产水平、表面高度和亮度变化等影响,检测的背景通常比较复杂,也更容易出现模糊和阴影。针对这些问题,基于东北大学发布的 NEU-DET 数据集^[8], Du W Z 等^[9]将特征金字塔网络 (Feature Pyramid Network, FPN) 加入到 Faster-RCNN 中,提高了对铸造缺陷的检测性能;Chen W 等^[10]集成了多个卷积神经网络来预测缺陷样本;刘艳菊等^[11]通过替换 VGG (Visual Geometry Group) 网络结构来提高小目标检测准确率。以上的研究通过融入各类优秀算法以及修改网络主干,有效地提高了 NEU-DET 数据集中板材表面缺陷检测的准确率,但他们通常通过集成多个深度学习网络来提升网络的特征提取能力

而未考虑模型的结构优化,在提升模型性能的同时也伴随着模型参数量与计算量的激增,这导致模型训练与推理变得困难,对运行设备要求极高,因此,为了模型的可用性与便利性,设计更加轻量、高效的网络结构是十分重要的。

本文提出了一种轻量、高效的冷轧板材表面缺陷检测模型——E-YOLO (Efficient-YOLO),其网络基于 YOLOv8 模型,针对现有模型小目标检测准确率低、特征提取不充分、模型推理效率较低等问题,提出了一系列改进措施。首先,修改了原始模型的低效颈部连接结构;再利用多分支结构对模型中的特征融合与提取方式进行修改;然后,针对小目标检测问题,提出了特征重提取结构,进一步提升了模型小目标的准确率;最后,设计了一系列验证实验,证明了本文提出的 E-YOLO 模型相比于现有的检测方法,具有更快的检测速度与更高的检测精度。

1 YOLOv8 模型

1.1 YOLOv8 模型简介

YOLOv8 模型是 YOLO 系列模型的最新研究成果,模型结构如图 1 所示,其中,CONV1 和 CONV3 为不同卷积核大小的卷积层,Concat 为特征连接操作,Split 为特征分离操作。YOLOv8 模型引

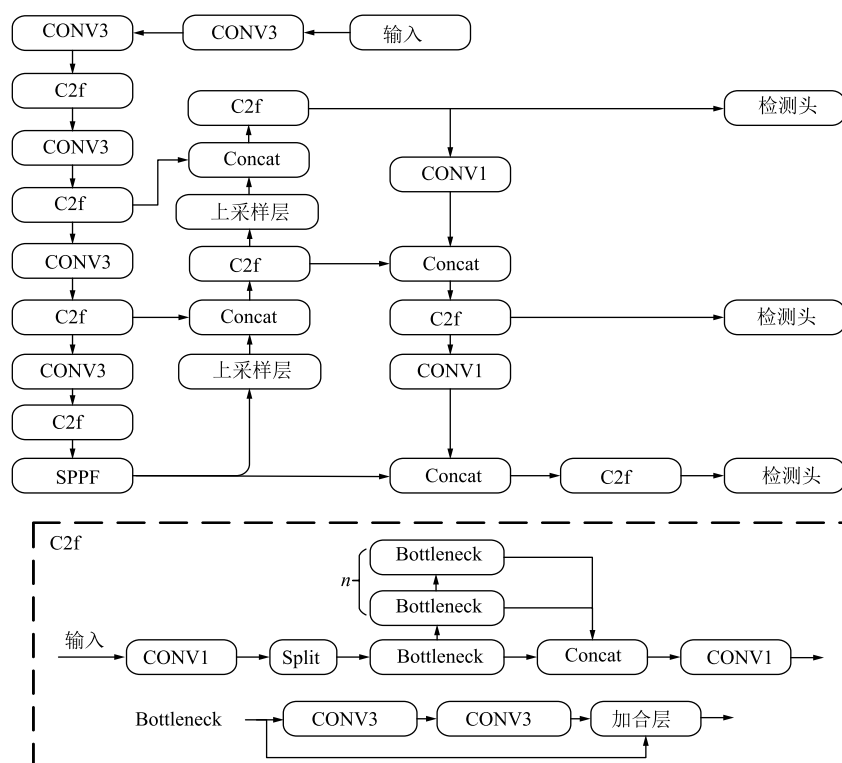


图 1 YOLOv8 模型结构

Fig. 1 Structure of YOLOv8 model

入的多项技术有效地提高了模型的性能。输入部分, YOLOv8 模型采用了 Mosaic 图像增强等技术来提高数据集的特征多样性, 进而提升模型的泛化能力。网络主干中, 引入了梯度流更加丰富的 C2f (CSP Bottleneck with 2 Convolutions) 结构, 通过跨阶段连接结构来加强不同维度特征之间的联系, 其中 n 为串联瓶颈层 Bottleneck 的数量, 用以动态调节模型的规模, 提高深层网络的学习效率, 加合层用以将来自不同层或相同层的多个输入进行相加操作。模型的池化部分使用 SPPF (Spatial Pyramid Pooling Fast) 使网络能够处理任意大小的输入图像。模型中的检测头部分更换为解耦头结构, 定位也采用无锚点的设计思路, 以提高模型的检测性能与扩展性。

此外, YOLOv8 模型采用了完全交并比 (Complete Intersection over Union, CIoU) 损失, 全面考虑了距离、重叠度等因素, 能够使模型的训练过程更加稳定。在原始交并比损失的基础上引入了矩形面积完全交并比损失 R_{CIoU} , 其计算方式如下:

$$R_{\text{CIoU}} = \frac{\rho^2(b, b^{\text{gt}})}{C^2} + \alpha v \quad (1)$$

式中: b 为预测框的中心点; b^{gt} 为真实框的中心点; ρ 为两点之间的距离; C 为能够同时包含预测框和真实框的最小外接矩形的对角线长度; α 为权重; v 为用来度量宽高比一致性的参数。

v 和 α 可由式 (2) 和式 (3) 计算。

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{\text{gt}}}{h^{\text{gt}}} - \arctan \frac{w}{h} \right)^2 \quad (2)$$

$$\alpha = \frac{v}{(1 - R_{\text{IoU}}) + v} \quad (3)$$

式中: w^{gt} 、 h^{gt} 分别为真实框的宽度和高度; w 、 h 分别为预测框的宽度和高度; R_{IoU} 为原始交并比损失。

最后, 得到完全交并比损失 L_{CIoU} 为:

$$L_{\text{CIoU}} = 1 - R_{\text{IoU}} + \frac{\rho^2(b, b^{\text{gt}})}{C^2} + \alpha v \quad (4)$$

1.2 模型缺陷分析

尽管 YOLOv8 模型性能优秀且高效, 但其设计主要面向通用检测目标。冷轧板材表面缺陷数据具有与背景相似、目标尺寸较小等特征, 使得 YOLOv8 模型并不能发挥出最佳的效果, 具体而言, 现有的 YOLOv8 模型存在以下问题:

(1) 颈部特征连接结构单一, 特征融合不充分;

(2) C2f 模块特征提取结构追求深度, 使得网络的计算量激增;

(3) 模型未针对细小目标进行进一步的特征提取, 导致复杂小目标检测困难。

因此, 为了得到更加高效的检测模型, 必须对 YOLOv8 模型进行针对性优化。

2 E-YOLO 模型

2.1 模型整体结构

图2展示了本文提出的高效 E-YOLO 模型的整体结构, 相较于 YOLOv8 模型, E-YOLO 模型通过设计更加高效的特征连接与提取结构, 提高了模型的特征提取能力与小目标检测能力。首先, 本文将 YOLOv8 模型主干部分的 C2f 模块改为了感受域更广的多维特征提取块 (Multifeature Extraction, MFE); 然后, 将 YOLOv8 模型原始的低效颈部结构进行了重组; 最后, 结合注意力机制, 提出了特征重提取结构 (Feature Re-extraction Structure, FRS), 进一步提升网络特征的感知能力, 进而提高小目标检测准确率。

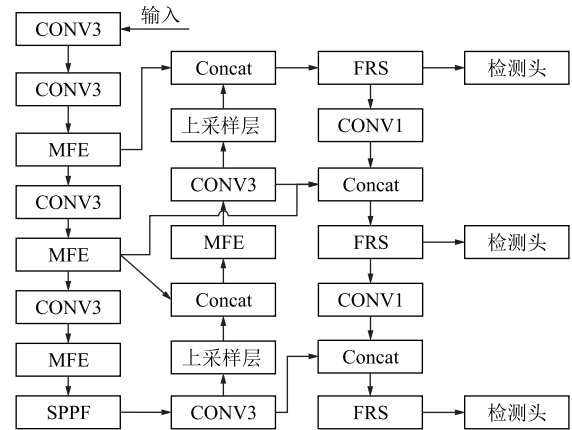


图2 E-YOLO 模型结构

Fig. 2 Structure of E-YOLO model

2.2 高效连接结构设计

原始的 YOLOv8 模型颈部结构需要融合不同特征层的信息, 不但增加了计算量, 也更容易受到噪声的干扰。受到双向特征金字塔网络 (Bi-directional Feature Pyramid Network, BiFPN) 结构^[12]的启发, 本文对原始的 YOLOv8 模型颈部连接结构进行了修改, 提出了更加高效的连接结构, 将连接路径改为同级特征融合, 使得融合特征更加全面且稳定。

此外, 原始的连接结构仅仅是对特征的简单融合, 未考虑各特征之间的差异, 为此, 本文在连接块后增加了可训练权重, 如图3所示。最后得到的特征计算如下:

$$Output = \sum_{i=1}^N \frac{\omega_i}{\varepsilon + \sum_{i=1}^N \omega_i} \cdot x_i \quad (5)$$

式中: $Output$ 为加权后的特征; x_i 为第 i 维的特征; ω_i 为第 i 维的特征对应的权重; N 为特征维度总数, 其同时影响了可训练权重的维度; $(\varepsilon + \sum_{i=1}^N \omega_i)$ 用来将特征归一化, 其中 ε 取 1×10^{-4} , 避免除 0 错误。由于权重是一维的, 因此, 几乎不会增加网络的参数。




图 3 加入权重后的连接结构

Fig. 3 Connection structure after adding weights

经过对连接结构与连接算法的优化, E-YOLO 模型能够学习到不同特征图对于检测结果的权重, 使得特征融合更加高效。

2.3 多维特征提取块设计

图 4 展示了多维特征提取块 MFE 的结构, 其中 D 为膨胀卷积的膨胀度。相比于 C2f, MFE 处理过程首先是将原始特征进行分割, 极大降低了计算量, 后续处理抛弃了 C2f 的深度连接结构, 改为了多分支结构, 利用不同尺度的卷积提高模型的感受野, 有效弥补了深度不足带来的性能损失, 膨胀卷积^[13]的应用也有效地限制了模块的计算量。




图 4 多维特征提取块结构

Fig. 4 Structure of multi-feature extraction

2.4 特征重提取结构设计

YOLOv8 模型无论是输入端的浅层特征还是检测头前的深层特征, 均采用 C2f 模块进行提取, 并未考虑这些特征之间的差异, 导致特征未得到充分利用。在网络深层, 更加需要对多维特征的空间联

系进行分析来提高网络对细节信息的表征能力。为此本文引入了 CA (Coordinate Attention) 注意力机制^[14], 其结构如图 5 所示。

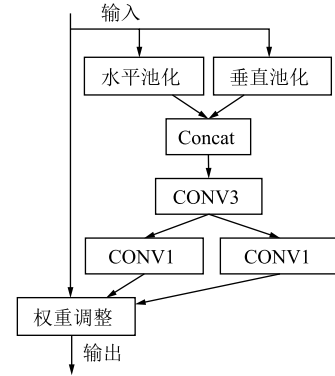


图 5 协同注意力机制模块

Fig. 5 Collaborative attention mechanism module

以往的注意力机制模型往往使用全局池化方法, 但这种方式会导致空间信息被压缩至通道层面, 不同位置信息之间的信息被忽略。为了解决这一问题, CA 模块将全局池化分解为如下过程:

$$z_c = \frac{1}{H \times W} \sum_{p=1}^H \sum_{q=1}^W x_c(p, q) \quad (6)$$

式中: z_c 为第 c 通道的输出; $x_c(p, q)$ 为第 c 通道的特征; H 和 W 分别为水平和垂直特征维度数量。

给定输入特征 x_c 后, CA 注意力机制将使用维度为 $(H, 1)$ 与 $(1, W)$ 的平均池化核, 分别对特征的水平和垂直关系进行编码, 得到高度为 h_e 的第 c 通道的输出 $z_c^h(h_e)$ 为:

$$z_c^h(h_e) = \frac{1}{W} \sum_{0 \leq q < W} x_c(h_e, q) \quad (7)$$

同理可求得宽度为 w_e 的第 c 通道的输出 $z_c^w(w_e)$:

$$z_c^w(w_e) = \frac{1}{H} \sum_{0 \leq p < H} x_c(p, w_e) \quad (8)$$

这种处理方式有效提高了模型的全局感知能力, 但也带来了严重的计算复杂性, 为此, 受到幽灵卷积设计思路的启发^[15], 本文提出了特征重提取结构 FRS, 如图 6 所示。其考虑到深层特征之间的相似性, 设计了特征拆分与重组结构: 首先, 通过一维卷积将输入特征进行分类, 并将特征均分为两部分, 其中一条支路通过 CA 注意力机制, 用于细粒度处理, 另一条支路使用膨胀卷积弥补模型细节, 显著降低了注意力机制带来的计算开销。

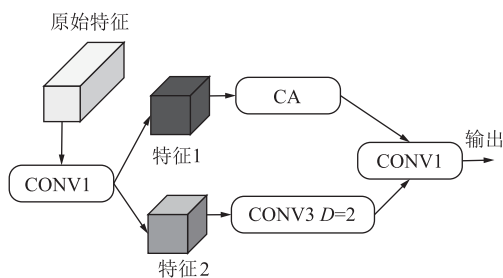


图 6 特征重提取结构 FRS

Fig. 6 Structure of feature re-extraction FRS

3 实验论证与结果分析

3.1 模型训练细节

模型的训练与测试使用了 NEU-DET 数据集。训练过程中，图像尺寸预处理为 640 像素×640 像素，并沿用了 YOLOv8 模型的 Mosaic 图像增强技术，批处理大小设置为 16，训练轮数为 300 轮，优化器选择 ADAM，初始学习率为 0.01，实验按照 7 : 2 : 1 的比例将数据集划分为训练集、验证集和测试集，所有实验均在 RTX 3090 平台上进行。

为了对比模型之间的性能，本文引入了当前广泛使用的准确率 P 、召回率 R 和平均精度均值 mAP 来衡量模型的性能。 P 和 R 的计算公式如下：

$$P = \frac{TP}{TP + FP} \quad (9)$$

$$R = \frac{TP}{TP + FN} \quad (10)$$

式中： TP 为识别正确的数量； FP 为误判为目标的背景数量； FN 为未检测出的目标数量。

以准确率 P 为纵坐标、召回率 R 为横坐标绘制 P - R 曲线，其与坐标所围成的面积即平均精度 AP (Average Precision)， mAP 值为 AP 的均值，用来反映整体的检测效果，计算如下：

$$AP = \int_0^1 PRdR \quad (11)$$

$$mAP = \frac{1}{T} \sum_{k=1}^T AP_k \quad (12)$$

式中： AP_k 为第 k 类目标的 AP 值； T 为待检测的类型总数。

此外，为了衡量模型的效率，本文引入了模型参数量与缺陷检测速度。

3.2 消融实验

本文基于 YOLOv8 模型进行了一系列改进，提出了高效的 E-YOLO 模型，为了证明 E-YOLO 模型中每个组分对性能的影响，本节进行了消融实验。

实验依次将各个模块添加至原始的 YOLOv8 模型中，实验结果记录于表 1，其中括号部分为各指标相较于上一行的提升值。

表 1 消融实验结果

Table 1 Results of ablation experiment

模块	$P/\%$	$R/\%$	$mAP/\%$
YOLOv8	59.4	75.6	78.8
添加高效连接结构	62.3 (+2.9)	76.1 (+0.5)	79.0 (+0.2)
添加多维特征提取块	64.0 (+1.7)	77.2 (+1.1)	79.8 (+0.8)
添加特征重提取结构	66.7 (+2.7)	78.5 (+1.3)	80.3 (+0.5)

分析表 1 可以得出：

(1) 高效连接结构：通过更加高效的特征连接与融合方法，模型的性能得到了全方位的提升，证明了本文的结构改进思路的有效性；

(2) 多维特征提取块：得益于更加高效的提取策略与结构设计，模型参数量压缩的同时，所有的指标均得到了进一步提升；

(3) 特征重提取结构：在原始的 YOLO 拓扑结构外添加的重提取结构使得图像特征得到了更加充分的应用，从而得到了更佳的性能。

3.3 对比分析

图 7 为 E-YOLO 与 YOLOv8 训练过程中的损失变化曲线，直观地展示了两者的差异。可以看出，E-YOLO 模型无论是收敛速度还是收敛值均优于 YOLOv8 模型，证明 E-YOLO 模型更加有利于模型收敛。




图 7 YOLOv8 与 E-YOLO 模型损失曲线对比

Fig. 7 Comparison of loss curves between YOLOv8 and E-YOLO models

为体现模型在小目标检测上的优越性，本文参考 COCO 数据集的标准^[16]，对数据集中像素面积小于 42×42 的目标进行了测试，与 YOLOv8 的对比结果展示在表 2 中，可以看出，E-YOLO 在各项指标上均有明显提升，证明了文中各项改进对于小目标特征提取能力的积极作用。

表 2 小目标检测对比结果

Table 2 Comparison results of small target detection

模型	P/%	R/%	mAP/%
E-YOLO	65.2	70.6	69.3
YOLOv8n	55.3	67.3	66.3

为证明本文所提出的 E-YOLO 模型的先进性, 本节挑选了一些现有的先进方法与 E-YOLO 模型进行对比, 结果记录在表 3 中。

表 3 不同方法对比结果

Table 3 Comparison results of different methods

方法	mAP/%	参数量/M	缺陷检测速度/FPS
YOLOv5n	75.3	1.9	105.1
YOLOv8n	78.8	2.4	99.1
YOLOXs	79.5	7.4	82.9
YOLOv8s	79.8	8.0	85.7
Faster-RCNN	73.4	323	5.2
Sparses-RCNN	80.7	124	18.0
E-YOLO	80.2	2.7	96.2

分析表 3 数据可以得出:

(1) 性能方面, 相比于各类轻量模型, E-YOLO 模型领先于 YOLO 系的 YOLOv5, YOLOX 等模型, 同时缺陷检测速度相近;

(2) 效率方面, E-YOLO 模型相较于两阶段算法, 速度优势明显, 以 Sparse-RCNN^[17] 为例, E-YOLO 模型的参数量降低了约 46 倍, 同时缺陷检测速度提升约 5 倍, 而仅损失了 0.5% 的 mAP 值, 证明了 E-YOLO 模型的高效性; 相比于参数量更多的 YOLOv8s, E-YOLO 模型依然以更快的检测速度得到了更优的测试精度, 证明本文的多分支结构设计以及特征拆分与重组结构在限制模型参数量、提高模型检测效率上效果显著。

为了直观地展示改进后模型检测效果的提升, 图 8 展示了 E-YOLO 模型与 YOLOv8 模型在训练集中的检测实例, 其中数字均为置信度。由图 8a、图 8b、图 8e、图 8f、图 8i 和图 8j 可知, YOLOv8 均出现了不同程度的漏检问题, 而 E-YOLO 检测准确率更高; 由图 8c、图 8d、图 8g 和图 8h 可知, E-YOLO 展现了更高的置信度; 由图 8k 和图 8l 可知, YOLOv8 模型出现了误检情况。通过实例对比可以看出, E-YOLO 模型的准确率与稳定性明显优于 YOLOv8 模型。

4 结语

针对冷轧板材表面缺陷检测的挑战, 本文基于

YOLOv8 模型设计了轻量、高效的深度学习模型——E-YOLO 模型。本文针对 YOLOv8 存在的问题针对性地提出了优化特征连接结构、引入多分支机制和特征重提取技术的改进措施。在对比实验中, 相较于同类型的 YOLOv8s, E-YOLO 模型以其 33.75% 的参数量取得了更优的准确率, 与两阶段的 Sparses-RCNN 相比参数量降低了约 46 倍但性能几乎无损失, 在小目标检测上性能也全面提升, 证明本文提出的改进方案不仅能有效提升小目标检测的准确率, 而且极大压缩了模型的推理时间, 但研究过程受限于数据集类型, 未考虑在光照不足与极端拍摄角度等问题, 未来工作还需进一步探索模型的鲁棒性问题。

参考文献:

- [1] Wang Y C, Gao L, Gao Y P, et al. A new graph-based semi-supervised method for surface defect classification [J]. Robotics and Computer-Integrated Manufacturing, 2021, 68: 102083.
- [2] Kim H M, Rho Y W, Yoo H R, et al. A study on the measurement of axial cracks in the magnetic flux leakage NDT system [A]. Proceedings of the 2012 IEEE International Conference on Automation Science and Engineering (CASE 2012) [C]. Seoul, Korea: IEEE, 2012.
- [3] Jeon Y J, Choi D C, Lee S J, et al. Defect detection for corner cracks in steel billets using a wavelet reconstruction method [J]. Journal of the Optical Society of America A, 2014, 31 (2): 227-237.
- [4] Zhang B Y, Yang H, Yin Z P. A region-based normalized cross correlation algorithm for the vision-based positioning of elongated IC chips [J]. IEEE Transactions on Semiconductor Manufacturing, 2015, 28 (3): 345-352.
- [5] 豆远航, 崔学习, 钟馨平, 等. 基于深度学习的非接触应变测量网格图像修复技术 [J]. 锻压技术, 2024, 49 (8): 195-204.
Dou Y H, Cui X X, Zhong X P, et al. Grid image restoration technology for non-contact strain measurement based on deep learning [J]. Forging & Stamping Technology, 2024, 49 (8): 195-204.
- [6] Ren S 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.
- [7] Redmon J, Divvala S, Girshick R, et al. You Only Look Once: Unified, real-time object detection [A]. Proceedings of the 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR) [C]. Las Vegas Nevada, USA: IEEE, 2016.
- [8] He Y, Song K C, 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.
- [9] Du W Z, Shen H Y, Fu J Z, et al. Approaches for improvement of the X-ray image defect detection of automobile casting aluminum parts based on deep learning [J]. NDT & E International, 2019, 107: 102144.
- [10] Chen W, Gao Y P, Gao L, et al. A new ensemble approach based

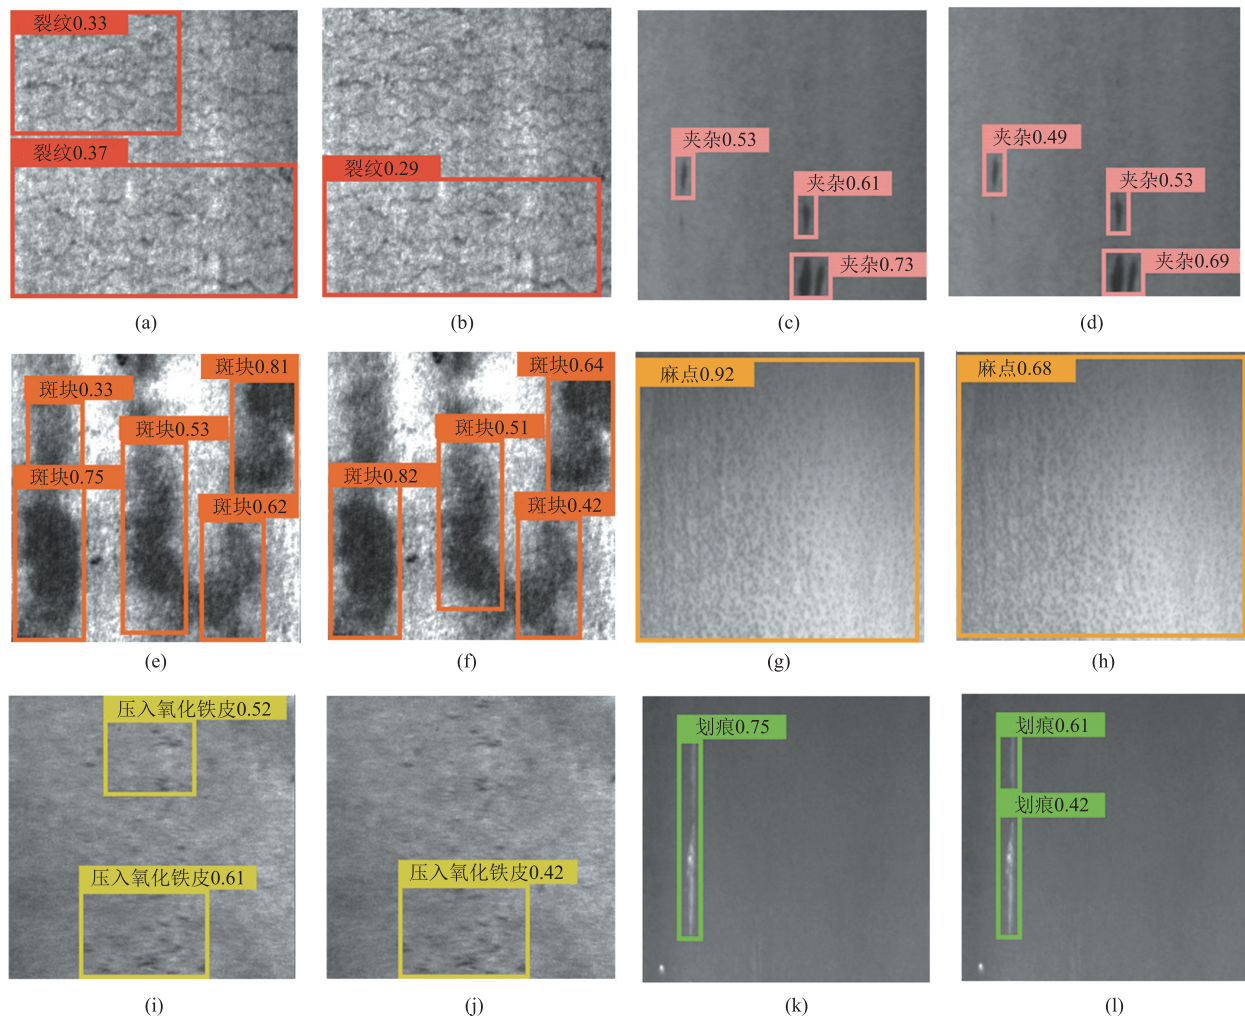


图8 E-YOLO 与 YOLOv8 模型检测结果实例

- (a) 裂纹, E-YOLO (b) 裂纹, YOLOv8 (c) 夹杂, E-YOLO (d) 夹杂, YOLOv8
 (e) 斑块, E-YOLO (f) 斑块, YOLOv8 (g) 麻点, E-YOLO (h) 麻点, YOLOv8
 (i) 压入氧化铁皮, E-YOLO (j) 压入氧化铁皮, YOLOv8 (k) 划痕, E-YOLO (l) 划痕, YOLOv8

Fig. 8 Examples of detection results by E-YOLO and YOLOv8 models

- (a) Crack, E-YOLO (b) Crack, YOLOv8 (c) Inclusion, E-YOLO (d) Inclusion, YOLOv8
 (e) Patch, E-YOLO (f) Patch, YOLOv8 (g) Pit, E-YOLO (h) Pit, YOLOv8
 (i) Rolled in scale, E-YOLO (j) Rolled in scale, YOLOv8 (k) Scratch, E-YOLO (l) Scratch, YOLOv8

on deep convolutional neural networks for steel surface defect classification [J]. Procedia CIRP, 2018, 72: 1069–1072.

- [11] 刘艳菊, 王秋霖, 张惠玉, 等. 基于改进 SSD 的工件表面缺陷检测 [J]. 热加工工艺, 2024, 53 (2): 134–139.

Liu Y J, Wang Q J, Zhang H Y, et al. Defect detection of workpiece surface based on improved SSD [J]. Hot Working Technology, 2024, 53 (2): 134–139.

- [12] Tan M X, Pang R M, Le Q V. EfficientDet: Scalable and efficient object detection [A]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition [C]. Seattle, WA, USA: IEEE, 2020.

- [13] Wang P Q, Chen P F, Yuan Y, et al. Understanding convolution for semantic segmentation [A]. Proceedings of the 2018 IEEE Winter Conference on Applications of Computer Vision (WACV) [C]. Lake Tahoe, NV, USA: IEEE, 2018.

- [14] Hou Q B, Zhou D Q, Feng J S. Coordinate attention for efficient mobile network design [A]. Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition [C]. Nashville, TN, USA: IEEE, 2021.

- [15] Han K, Wang Y H, Tian Q, et al. GhostNet: More features from cheap operations [A]. Proceedings of the 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition [C]. Seattle, WA, USA: IEEE, 2020.

- [16] Lin T Y, Maire M, Belongie S, et al. Microsoft COCO: Common objects in context [A]. Computer Vision-ECCV 2014 [C]. Berlin, Germany: Springer International Publishing, 2014.

- [17] Sun P, Zhang R, Jiang Y, et al. Sparse R-CNN: End-to-end object detection with learnable proposals [A]. Proceedings of the 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition [C]. Nashville, TN, USA: IEEE, 2021.