

DOI: 10.13382/j.jemi.B2508597

基于 YOLOv8n 的锆合金板表面缺陷检测模型^{*}

李海宇¹ 燕芳¹ 李小娜² 冯金秋¹ 杨阳¹
(1. 内蒙古科技大学自动化与电气工程学院 内蒙古自治区高等学校流程工业综合自动化重点实验室 包头 014010;
2. 云知尚(西安)智能科技有限公司 西安 712000)

摘要:传统的锆合金板生产质量检测主要依靠人工,费时费力且精度不高。为提高锆合金板表面缺陷的检测精度、检测效率,针对 YOLOv8n 目标检测模型的网络结构进行改进,提出一种轻量级多尺度融合缺陷检测模型(lite edge fusion-YOLOv8, LEF-YOLOv8)。首先,为了解决锆合金板表面小目标缺陷特征容易丢失的问题,设计一种提取缺陷边缘特征并结合空间信息的 C2f-EDEM(C2f-edge detail enhancement module, C2f-EDEM)模块,有效提高模型的特征提取能力;然后,针对原模型缺乏显式的特征选择和注意力机制的问题,提出一种全局-局部注意力融合模块(global-local interactive attention, GLIA),以提高模型融合局部、全局语义上下文的能力;最后,针对原模型检测头信息融合能力较弱且计算量较大等问题,提出一种轻量级多尺度融合检测头(lightweight multi-scale fusion detection head, LMSFD),以提升模型的特征表达能力并减少模型的复杂度。在自制锆合金板数据集和 NEU-DET 公共数据集上分别进行模型验证实验。实验结果显示,LEF-YOLOv8 模型在不引入过多计算量的同时 mAP@0.5 分别达到 86.7% 和 75.9%,相较基线模型 YOLOv8n 分别提高 3.2 和 2.4 个百分点。实验结果证实,改进后的模型提高了检测精度,适用于计算能力受限的检测终端,为锆合金板材表面缺陷自动检测提供了解决方案。

关键词: 锆合金板;缺陷检测;YOLOv8n;多尺度门控信息聚合

中图分类号: TG133⁺.4;TP391.41;TN98 **文献标识码:** A **国家标准学科分类代码:** 510.80

Surface defect detection model for zirconium alloy plates based on YOLOv8n

Li Haiyu¹ Yan Fang¹ Li Xiaona² Feng Jinqiu¹ Yang Yang¹
(1. School of Automation and Electrical Engineering, Inner Mongolia University of Science and Technology, Key Laboratory of Synthetical Automation for Process Industries at Universities of Inner Mongolia Autonomous Region, Baotou 014010, China;
2. YZS Precision Technology Co., Ltd., Xi'an 712000, China)

Abstract: Traditional quality inspection of zirconium alloy plates mainly relies on manual methods, which are time-consuming, labor-intensive, and prone to low accuracy. To improve the detection accuracy and efficiency of surface defects on zirconium alloy plates, the network structure of the YOLOv8n object detection model was enhanced, and a lightweight multi-scale fusion defect detection model (LEF-YOLOv8) was proposed. To address the issue of small defect features being easily lost, a C2f-edge detail enhancement module (C2f-EDEM) was designed to extract defect edge features while incorporating spatial information, thereby enhancing feature extraction capability. To overcome the lack of explicit feature selection and attention mechanisms in the original model, a global-local interactive attention (GLIA) module was introduced, improving the integration of local and global semantic context. Furthermore, to mitigate the weak information fusion and high computational cost of the original detection head, a lightweight multi-scale fusion detection head (LMSFD) was proposed, which enhances feature representation while reducing model complexity. Experiments on a self-collected zirconium alloy plate dataset and the NEU-DET public dataset demonstrate that LEF-YOLOv8 achieves mAP@0.5 of 86.7% and 75.9%, respectively, improving by 3.2% and 2.4% over the baseline YOLOv8n, without introducing significant computational

overhead. These results indicate that the proposed model improves detection accuracy and is suitable for resource-constrained inspection systems, providing an effective solution for automated surface defect detection of zirconium alloy plates.

Keywords: zirconium alloy plate; defect detection; YOLOv8n; multi-scale gated information aggregation

0 引言

锆合金具有优异的耐腐蚀性、良好的力学性能及低热中子吸收截面,其耐腐蚀性能明显优于不锈钢和钛合金,使其在高温高压环境下依然能够保持良好稳定性,广泛应用于苛刻工业环境中。在化工设备领域,锆合金板主要用于制造耐腐蚀的压力容器、换热器和反应釜,其耐腐蚀性能明显优于不锈钢和钛合金。在海洋环境中,锆合金可用作潜艇结构件和海洋平台设备的防腐蚀构件。在先进核能系统中,采用锆合金板材替代传统不锈钢结构材料不仅有助于提高燃料利用效率,也有助于优化系统的整体经济性,是实现高能耗、长周期运行的关键材料^[1]。

锆合金板材作为关键工程结构材料,其表面完整性直接影响装备服役性能与寿命。在轧制、热处理等制备工序中,板材表面易出现划痕、微小孔洞等缺陷,这些缺陷的早期精确检测对保障产品质量具有决定性作用。当前工业检测主要采用人工目检与机器视觉技术,但人工目检易受主观经验影响,机器视觉技术存在复杂纹理背景下抗干扰能力弱、微尺寸缺陷识别精度不足等问题。

近年来,深度学习目标检测技术已成为缺陷检测的有效解决方案。目前,基于深度学习的缺陷检测算法主要分为单阶段目标检测和两阶段目标检测。两阶段目标检测首先预测物体的位置生成预测框,然后将预测框分类,因此具有较高的准确度。冷岳峰等^[2]将快速区域卷积神经网络(faster region-based convolutional neural network, Faster R-CNN)应用于钢材表面缺陷检测,在 FPN 与 RPN 之间引入特征融合模块与轻量化通道注意力模块,增加模型对精细特征的捕捉能力。李玉等^[3]提出一种改进 Faster R-CNN 的钢板表面缺陷检测模型,引入特征金字塔将深层次的高语义特征和浅层特征融合,进一步提高模型的效率和精度。陈海燕等^[4]提出了一种基于 Faster R-CNN 的小目标检测模型,设计了一种基于通道-空间注意力机制的特征融合方法,有效降低特征融合过程中引起的混叠效应。然而,以上两阶段目标检测算法仍存在参数量和计算量大的问题,无法保证实时性。

单阶段目标检测算法将定位与分类任务合并,检测速度相较于两阶段目标检测算法更快,实时性更好。阎馨等^[5]提出了一种钢材表面缺陷检测的改进单阶段多尺度目标检测(single shot multibox detector, SSD)算法,采用

Transformer 多头注意力机制模块代替原 SSD 结构中的 Conv5_1 层,以提高小目标检测的能力。李和平等^[6]提出一种改进 YOLOv5s(you only look once)的钢材缺陷检测算法,将主干提取网络的 C3 模块与 Swin Transformer 结构融合,以增强模型的特征提取能力。Zhou 等^[7]提出了一种基于 YOLOX 的带钢表面缺陷检测模型,在主干中引入了三元卷积坐标注意力模块(tri-coordinate convolutional attention, TCCA)捕获跨通道特征,能够精确识别缺陷的位置信息。Xia 等^[8]在 YOLOv8x 基础上结合全局特征金字塔网络和双层高效注意力,更全面地关注重要区域,从而提高缺陷检测精度。赵志宏等^[9]提出一种 KAN-YOLOv8 的带钢表面缺陷检测方法,将 KAN(kolmogorov-arnold network)神经网络中可学习的激活函数引入到 C2f(cross stage partial with 2 convolutions)模块中得到新模块 KAN_C2f,去除图像中噪声提升网络对缺陷特征的提取能力。上述方法都在不同程度上提升了检测的实时性,但在小目标、强背景干扰场景仍然存在检测精度不足等问题。

针对上述问题,本文基于 YOLOv8n 模型,设计了一种轻量级多尺度融合锆合金板表面缺陷检测模型(lite edge fusion-YOLOv8, LEF-YOLOv8),在提高检测精度的同时保持模型的轻量化。主要工作如下,首先设计一种提取缺陷边缘特征并结合空间信息的模块(C2f-edge detail enhancement module, C2f-EDEM),能够使模型获取到更丰富的缺陷原始特征。然后,为了增强模型对小目标和复杂场景的建模能力以及提升低层细节特征与高层语义特征之间的协同表达能力,提出一种全局-局部注意力融合模块(global-local interactive attention, GLIA),利用门控机制提升主干特征与引导特征之间的空间协同感知能力,从而减少背景干扰和特征冗余。最后,提出一种轻量化检测头(lightweight multi-scale fusion detection head, LMSFD),在共享卷积的结构下引入可重参数化的卷积模块(diverse branch block, DBB)^[10],降低模型复杂度的同时充分融合多分支语义信息,补偿共享卷积带来的精度损失。最后在自制锆合金板数据集验证改进模型的性能,并在 NEU-DET 数据集上验证其泛化能力,结果表明改进相比基线模型具有更好的检测能力。

1 数据集构建

实验所使用的锆合金板表面缺陷数据集图像采集于云知尚(西安)智能科技有限公司。所采集缺陷图像全

部为铝合金板生产过程中产生的表面缺陷,采集设备为 XFCAM1080PHB 面阵相机搭配高精度变倍光学镜头,采用五环八区 LED 光源模拟实际检测环境的光照条件变化,采集设备如图 1 所示。



图 1 采集设备
Fig. 1 Collection device

缺陷图像为 RGB 图像,原始分辨率为 $1\,920 \times 1\,080$ pixels,存储格式为 JPG 格式。数据集中共包含 5 种缺陷类别,如图 2 所示,即蹭痕、点坑、过度抛光 (excessive polishing, EP)、划痕和测量痕迹 (measurement trace, MT)。

为了提高模型的泛化能力和鲁棒性并防止其在特定数据集上过拟合,对采集到的缺陷图像随机进行翻转、局部裁剪、镜像、加噪以及调节亮度等操作,最终扩充为 2 240 张图像。随后使用图像标注软件 LabelImage 对图像进行标注,生成对应的标签 txt 文件供缺陷检测模型的训练学习使用。将所有数据集标签和图像随机分配并按照 7 : 2 : 1 的比例将数据集划分为训练集 (1 568 张)、测试集 (448 张) 和验证集 (224 张)。其中缺陷总数为 3 327 个,各缺陷类别数量如表 1 所示。

表 1 数据集各类缺陷数据详情

Table 1 Details of various defect data in the dataset

缺陷类别	缺陷数量	缺陷总数
蹭痕	784	/
点坑	643	/
过度抛光	672	3 327
划痕	543	/
测量痕迹	685	/




图 2 铝合金板表面缺陷
Fig. 2 Zirconium alloy surface defect

2 LEF-YOLOv8 模型构建

为提高模型在铝合金板表面缺陷检测任务中的性能,以及避免引入过多参数量、计算量,本文提出一种轻量级多尺度融合铝合金板表面缺陷检测模型 LEF-YOLOv8,其结构如图 3 所示。

2.1 C2f-EDEM 模块结构

YOLOv8 中采用了大量的 C2f^[11] 模块,主要依赖常规卷积提取特征,这对于捕获全局信息效果良好,然而在边缘和细节特征方面有所欠缺,在处理局部特征和保持全局上下文之间存在平衡难题,影响模型的性能和鲁棒性^[12]。此外,C2f 模块采用深层网络结构,导致

计算复杂度高,影响模型运行效率。为此,本文提出一种边缘特征与空间信息相结合的模块 (edge detail enhancement module, EDEM) 嵌入至 C2f 模块中,其结构如图 4 所示。EDEM 模块结合了 Sobel Block 和卷积分支, Sobel Block 通过 Sobel 算子提取图像 2 个方向上的边缘特征,另一个卷积分支同时提取缺陷的空间信息,二者通过 Concat 拼接进行特征融合,拼接后的特征通过 1×1 卷积核进行特征压缩和非线性映射,确保拼接后的特征具有紧凑性和区分能力,通过最后的 1×1 卷积核使拼接后的特征能够重新映射到统一的特征空间。原始的输入加入至卷积输出,形成残差连接,能够显著增强梯度流动能力的同时保留低级的特征信息。




图 3 LEF-YOLOv8 模型结构
Fig. 3 LEF-YOLOv8 model structure




图 4 EDEM 结构
Fig. 4 EDEM structure

Sobel 算子^[13]是经典的边缘检测方法,它主要通过计算图像在水平和垂直方向的梯度强度,从而提取图像的边缘特征。如图 5 所示,Sobel Block 通过 2 个 3×3 卷

积核分别提取图像水平、垂直方向的边缘信息,并将两个方向的特征信息融合输出到网络的下一层,使模型能够得到更加丰富的边缘特征。




图 5 Sobel Block 结构
Fig. 5 Sobel Block structure

此外,Sobel Block 是基于固定权重的卷积操作,且不参与梯度更新,因此不会增加训练参数。虽然 Sobel Block 在提取边缘特征时仍然需要额外的计算,但其计算

量要低于完整的卷积操作。假设输入特征维度为 $H\times W$ 且输入通道数为 C_{in} , 输出通道数为 C_{out} , 卷积核大小为 3×3 :

标准卷积计算量为:

$$FLOPs_{conv} = H \times W \times C_{in} \times C_{out} \times 3^2 \quad (1)$$

Sobel Block 的计算量为:

$$FLOPs_{sobel} = H \times W \times C_{in} \times 2 \quad (2)$$

式中:2 为 Sobel Block 在 2 个方向上的卷积操作。由式(2)可知,当输出通道数大于输入通道数时,Sobel Block 的计算量会显著低于标准卷积计算量。

因此包含 Sobel Block 的 EDEM 模块相比原 C2f 中的 Bottleneck 模块在特征融合上更为轻量化。

2.2 GLIA 模块

在 YOLOv8 的主干网络与颈部网络的特征交互过

程中,缺乏显式的特征选择或注意力机制,导致各通道特征在语义重要性上的差异未被有效建模,所有通道被默认赋予相同权重。这种无差异处理容易引入无效或冗余信息,削弱了特征表示的判别性,从而影响对小目标的感知能力,并可能导致复杂背景下的误检问题^[14]。为增强 YOLOv8 模型对小目标和复杂场景的建模能力以及提升低层细节特征与高层语义特征之间的协同表达能力,本文提出一种全局-局部注意力融合模块 GLIA。如图 6 所示,该模块由局部特征提取、全局特征提取、动态注意力权重、双向门控交互 4 部分组成。




图 6 GLIA 模块结构

Fig. 6 GLIA module architecture

局部特征提取模块采用双层深度可分离卷积结构,以增强模型对局部信息的感知能力。首先,主干特征 X 经由标准的 3×3 深度可分离卷积处理,实现对各通道的独立编码,有效避免特征通道间的信息混叠,从而更关注于目标的细节特征及边缘轮廓。随后,引入带有空洞率的深度可分离卷积以扩大感受野,有助于捕捉更大尺度

的结构语义与背景上下文信息,提升局部特征对复杂场景的适应能力^[15]。最后,采用 BN (batch normalization) 层对特征分布进行标准化,进一步稳定训练过程并加速网络收敛。

全局特征提取模块旨在增强模型对全局上下文的建模能力,抑制冗余背景干扰。该模块首先对来自颈部的

引导特征 Y 进行通道平均池化,通过在空间维度上计算通道均值,保留整体场景的背景信息与全局分布特征。随后,采用通道最大化以提取在空间维度上最具响应的特征,突出显著区域的结构信息。2路特征在拼接后通过 1×1 卷积实现通道融合,并经 BN 层生成一张单通道的空间权重图。这种设计有助于模型强化对全局结构的感知能力,从而提升对关键区域的聚焦,同时降低背景噪声对特征判别的干扰。

动态注意力权重模块通过 1×1 卷积及 BN 层统一尺度与分布,实现局部特征、全局特征的高效融合,融合后的特征通过 softmax 操作对每个像素位置的两个注意力通道进行归一化,最后将其分别作用于主干特征 X 、引导特征 Y 。传统的特征融合中,不同分支提供的语义信息可能存在显著差异,直接相加或拼接会导致语义混杂^[16],所以该动态注意力权重模块能够通过显式学习位置相关的权重,并为每个空间位置动态分配权重,从而过滤低效特征,提升模型的特征表达质量。

融合全局、局部特征的特征图 A 为:

$$A = \text{Conv}_{1 \times 1}(X \oplus Y) \quad (3)$$

通过 softmax 操作,对每个像素的 2 个注意力通道进行归一化:

$$[\alpha_{i,j}, \beta_{i,j}] = \text{softmax}(A_{:,i,j}) \quad (4)$$

$$\alpha_{i,j} + \beta_{i,j} = 1 \quad (5)$$

将其分别作用于主干特征和引导特征:

$$X' = X \oplus (\alpha \otimes X) \quad (6)$$

$$Y' = Y \oplus (\beta \otimes Y) \quad (7)$$

式中: $\text{Conv}_{1 \times 1}(\cdot)$ 为卷积操作; $\alpha_{i,j}, \beta_{i,j}$ 分别为主干特征、引导特征注意力系数; X', Y' 分别为注意力调制后的主干特征和引导特征; $\oplus$ 为逐元素相加; $\otimes$ 为逐元素相乘。

双向门控交互模块旨在进一步提升主干特征与引导特征之间的空间协同感知能力,该模块通过 Sigmoid 函数实现两路信息的动态融合与特征增强^[17]。

生成主干分支门控映射:

$$M_{X'} = \sigma(X') \quad (8)$$

生成引导分支门控映射 $M_{Y'}$:

$$M_{Y'} = \sigma(Y') \quad (9)$$

主干、引导分支双向调制:

$$\tilde{X} = M_{Y'} \otimes X' \quad (10)$$

$$\tilde{Y} = M_{X'} \otimes Y' \quad (11)$$

式中: $\sigma(\cdot)$ 为 Sigmoid 函数操作; $\tilde{X}$ 为主干特征受分支门控调制结果; $\tilde{Y}$ 为引导特征受主干门控调制结果。在传统模型中,单一路径往往难以同时兼顾局部细节与全局语义,而双向门控机制通过互为引导的方式使主干分支更容易捕捉由全局语义强化的目标;引导分支通过主

干分支的结构引导补全缺失信息。这种机制有助于提升最终特征的判别性,并且使得模型计算资源更聚焦于关键区域,减少背景干扰和特征冗余。

2.3 LMSFD 轻量化检测头

YOLOv8n 模型检测头采用了解耦结构^[18],包含 2 个分支,每个分支中都包括 2 个 3×3 卷积和一个 1×1 卷积,检测头部分的计算量相对较大;其次,YOLOv8 检测头的卷积结构较为简单,缺乏复杂的特征表达和信息融合能力,在处理细小目标、复杂边缘或者纹理时效果欠佳^[19]。因此可以通过改进检测头来降低模型复杂度和融合多尺度的特征信息,从而实现模型的轻量化并且提升模型的特征表达能力。

为解决上述问题,提出一种轻量级多尺度融合卷积检测头 LMSFD。首先,将检测头卷积中的批归一化 BN 层替换为组归一化 GN(group normalization)层。GN 层不受批量大小的限制,而是将每个通道划分为多个组,分别在组内计算均值和方差,因此在目标检测任务中表现更加稳定,它的去中心化和标准化效果使得模型能更好地应对不同数据分布^[20]。因此使用 GN 层替换 BN 层可以提高检测头的定位和分类性能,进而提升检测任务的精度和稳定性。

为了减少模型的参数量和计算量,检测头采用共享卷积的结构。共享卷积能够显著减少卷积操作的次数,从而降低计算量^[21]。假设输入特征维度为 $H \times W$, 隐藏层通道数为 C_h , 共享卷积层的计算量 M 和参数量 S 分别为:

$$M = 9C_h^2 + C_h \quad (12)$$

$$S = H \times W \times (9C_h^2 + C_h) \quad (13)$$

由于共享卷积无法捕捉复杂程度不同的特征导致的精度损失,因此为了弥补共享卷积在实现轻量化过程中带来的负面影响,本检测头引入可重参数化的卷积模块 DBB,其多分支结构使得在特征整合过程中,不同尺度的特征信息能够有效交互,提升模型对复杂场景的适应能力。

DBB 的设计通过引入更多多样化的可学习参数(例如不同大小的卷积核、不同的池化操作),增强了网络在训练阶段的特征提取能力。DBB 结构如图 7 所示,它允许模型在训练时捕捉不同尺度、不同方向的特征信息^[22],有效提升参数的表达能力,从而弥补轻量化模型的精度损失问题。此外,DBB 的设计在推理阶段通过重参数化将多个不同分支的卷积核合并为一个等效的卷积核,使其在推理阶段仅需一个卷积操作,与普通卷积无异。这不仅实现模型的轻量化,还保证了推理效率和模型精度,是一种无损的优化方案。

为了进一步使模型轻量化,将回归分支(Conv_Reg)和分类分支(Conv_Cls)以共享卷积的方式去分别处理




图 7 DBB 结构图

Fig. 7 DBB structure diagram

P3、P4、P5 层经过 DBB 层后的特征图。同时为弥补共享卷积无法为每个特征层单独调整卷积参数而带来的目标尺度感知的差异,在 Conv_Reg 后引入 Scale 层,Scale 层

能够为每个输出通道动态调整目标的尺度感知能力,从而使不同特征层能够更好适应不同尺度的目标检测需求,检测头最终结构如图 8 所示。




图 8 LMSFD 结构图

Fig. 8 LMSFD structure diagram

3 实验与分析

3.1 实验环境

本文实验全部基于 Windows11 操作系统下进行训练,CPU 主频为 3.8 GHz、核心数为 8,运行内存为 16 GB。此外 GPU 型号为 NVIDIA GeForceRTX4060,显存大小为 8 GB。软件方面,深度学习框架采用 pytorch2.2.2,软件环境为 CUDA12.1、python3.10。超参数设置方面,初始学习率设置为 0.01,批量为 16,训练周期为 200,动量参数为 0.937,权重衰减系数为 0.000 5,使用的优化器为 SGD。

3.2 评价指标

本文使用准确率 (Precision)、召回率 (Recall)、平均精度 (mAP @ 0.5)、参数量 (Params)、浮点计算量 (GFLOPs) 和帧率 (frames per second, FPS) 6 个指标评估模型的性能。各指标计算公式如下:

$$\text{Precision} = \frac{TP}{TP + FP} \quad (14)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (15)$$

$$\text{mAP} = \frac{\sum_{i=1}^C AP_i}{C} \quad (16)$$

式中: TP 表示真正例; FP 表示假正例; FN 表示假负例; AP_i 为第 i 类缺陷的检测精度; C 为缺陷类别数。

3.3 C2f-EDEM 位置对比实验

为了提升模型的特征表达能力并且丰富空间结构信息,将 YOLOv8n 网络模型中的 C2f 模块替换为改进后的 C2f-EDEM 模块。为探讨不同替换位置对模型性能的影响,设计 4 组实验,实验结果如表 2 所示。

根据表格的结果可以得知,实验 5 将 C2f-EDEM 模块替换到 YOLOv8n Backbone 的位置时,模型的 mAP@0.5 达到最高 85.4%,相较于基准模型提升了 1.9 个百分点。而 Backbone 是浅层特征提取的关键阶段,这表明了 C2f-EDEM 模块能够有效提取到缺陷的边缘特征并充分结合空间信息,使模型更好地检测到小目标及复杂背景目标^[23]。

表 2 C2f-EDEM 模块在不同位置的模型检测性能
Table 2 Detection performance of the C2f-EDEM module at different positions in the model

实验组	C2f-EDEM Position		mAP@ 0.5/%	参数量/($\times 10^6$)	GFLOPs	FPS
	Backbone	Neck				
1	×	×	83.5	3.0	8.1	156
2	√	×	85.4	2.8	7.7	161
3	×	√	83.2	2.8	7.8	152
4	√	√	84.9	2.7	7.5	168




图 9 特征热力图
Fig. 9 Feature heatmap

特征热力对比图为图 9,其中第 1 行为原始图像;第 2 行为 YOLOv8n 模型特征热力图;第 3 行为改进模型 LEF-YOLOv8 特征热力图。可以从特征热力图对比结果中看出加入 C2f-EIEM 模块后,模型更好地捕捉到了铝合金板表面缺陷的边缘信息和细节区域,缺陷区域的特征更明显地突显出来,削弱了背景噪声造成的干扰。

3.4 消融实验

为进一步检验本文的每个改进点对基准模型的提升

效果,设计消融实验,首先将 YOLOv8n 作为基线模型分别与加入改进的模块进行对比,改进模块包括:融合 C2f-EDEM 的增强型主干网络;在模型 Backbone 与 Neck 间加入 GLIA 注意力模块;将原检测头更换为 LMSFD 检测头,实验结果如表 3 所示。

由表 3 可知,本文每个改进策略的平均精度都有不同程度的提升,而且参数量、计算量没有大幅上升。主干融合 C2f-EDEM 模块显著提升模型特征表达能

力和丰富空间结构信息,mAP 较基线模型相比提升 1.9 个百分点。接下来,GLIA 注意力模块的加入有效提升主干特征与引导特征之间的空间协同感知能力,mAP 继续上升 1.1 个百分点。最后,将原检测头更换为 LMSFD 检测头,参数量、计算量得到明显下降的同

时 mAP 上升 0.2 个百分点。总体而言,LEF-YOLOv8 模型相较于基线模型 mAP 提高 3.2 个百分点,且参数量、计算量变化不大,实现轻量化的同时提升精度,对检测设备的配置要求友好,更有利于终端设备部署。

表 3 消融实验
Table 3 Ablation study

YOLOv8n	C2f-EDEM	GLIA	LMSFD	Precision/%	Recall/%	mAP@0.5/%	参数量/($\times 10^6$)	GFLOPs	模型大小/MB
✓				81.0	78.8	83.5	3.0	8.1	6.3
✓	✓			79.2	82.7	85.4	2.8	7.7	5.6
✓		✓		86.5	80.1	85.7	3.9	10.0	8.1
✓			✓	82.3	85.6	83.9	2.3	6.5	5.2
✓	✓	✓		87.0	82.2	86.5	3.8	9.7	7.7
✓	✓	✓	✓	89.4	83.8	86.7	3.2	8.1	6.8

为了更直观地了解改进前后的检测效果,随机选取 5 种缺陷样本进行对比检测,实验结果如图 10 所示,其中第 1 行为原始图像;第 2 行为 YOLOv8n 模型的检测效果图;第 3 行为改进模型 LEF-YOLOv8 的检测效果图。可以看出,对于蹭痕、过度抛光缺陷改进后的模型比基准模型的置信度更高,检测框更加贴合实际缺陷的位置;对于点坑和测量痕迹这两种缺陷,基准模型均出现了漏检的情况,改进模型则检测到全部缺陷;对于划痕缺陷,基准模型出现误检的情况,改进模型则没有误检。综上所述,改进后的模型在对铝合金板缺陷检测的识别效果和

准确率明显优于基准模型。
3.5 检测模型对比实验

为进一步验证 LEF-YOLOv8 的检测性能,在实验环境和数据集不变的情况下将其与现阶段主流目标检测模型进行对比,实验结果如表 4 所示。

由表 4 可知,与传统的 Faster R-CNN、SSD^[24]、CenterNet 检测模型对比,LEF-YOLOv8 的 mAP 更高,且模型的参数量、计算量和模型体积具有明显优势;对比模型内存相似的 YOLOv6n、YOLOv10n^[25]、YOLOv11n^[26],LEF-YOLOv8 的 mAP 均有不同程度的领先;由以上可




图 10 铝合金板数据集上可视化对比图

Fig. 10 Visualization comparison on zirconium alloy plate dataset

表 4 主流检测模型对比

Table 4 Comparison of mainstream detection models

模型	mAP@ 0. 5/%	Precision/%	Recall/%	参数量/(×10 ⁶)	GFLOPs	模型大小/MB
Faster R-CNN	81. 8	79. 1	80. 4	72. 0	167. 3	143
SSD	76. 7	82. 8	74. 5	41. 1	145. 3	29. 3
CenterNet	83. 7	81. 7	81. 9	34. 5	72	127
YOLOv6n	79. 6	75. 8	76. 6	4. 2	11. 9	8. 7
YOLOv7-Tiny	85. 9	79. 8	82. 4	6. 0	13. 1	12. 3
YOLOv8n	83. 5	81. 0	78. 8	3. 0	8. 1	6. 3
YOLOv9n	85. 3	82. 2	82. 4	4. 4	18. 2	9. 1
YOLOv10n	83. 0	78. 8	76. 4	2. 3	6. 5	5. 5
YOLOv11n	86. 3	80. 0	86. 0	2. 6	6. 3	5. 2
LEF-YOLOv8	86. 7	89. 4	83. 8	3. 2	8. 1	6. 8

知,LEF-YOLOv8 在保证检测精度的同时有着计算量参数量低、模型体积小等优势,更有利于部署在硬件条件受限的终端设备上。

3. 6 泛化性验证

为评估 LEF-YOLOv8 在不同检测任务的泛化性,选择 NEU-DET 东北大学钢材缺陷数据集进行泛化性验证。该数据集共包含 1 800 张图片,如图 11 所示分为裂缝、夹杂物、点蚀、斑块、氧化皮、划痕 6 类缺陷,每类缺陷约 300 张样品,图片像素大小为 200×200 pixels。数据集划分、实验参数和铝合金板数据集一致。

将本文模型与基线模型在 NEU-DET 数据集上进行实验对比,实验结果如表 5 所示。

从表 5 可知 LEF-YOLOv8 在 NEU-DET 数据集上除召回率之外,测试指标均优于基线模型,相较于基线模型,在参数量、计算量相近的同时 mAP 提升 2. 4 个百分点、FPS 提高 19 帧,展示了 LEF-YOLOv8 具备较强的泛




图 11 NEU-DET 钢材缺陷数据集

Fig. 11 NEU-DET steel defect dataset

表 5 两种模型在 NEU-DET 数据集检测性能对比

Table 5 Comparison of detection performance of two models on the NEU-DET dataset

数据集	Model	mAP@ 0. 5/%	Precision/%	Recall/%	参数量/(×10 ⁶)	GFLOPs	FPS
NEU-DET	YOLOv8n	73. 5	67. 7	75. 3	3. 0	8. 1	129
	LEF-YOLOv8	75. 9	73. 6	71. 9	3. 2	8. 1	148

化性能。

LEF-YOLOv8 和基线模型在 NEU-DET 数据集上的可视化对比结果如图 12 所示,其中第 1 行为原始图像;第 2 行为 YOLOv8n 模型的检测效果图;第 3 行为改进模型 LEF-YOLOv8 的检测效果图。从图中可以看出,尽管,2 种模型都存在漏检情况,但 LEF-YOLOv8 整体检测效果明显优于基线模型,检测到的缺陷置信度更高,漏检情况也更少,进一步表明 LEF-YOLOv8 相比基线模型更有优势。

4 结 论

针对传统铝合金板表面缺陷检测主要依靠人工,存

在效率低、精度低等问题,本文基于 YOLOv8n 改进提出一种检测模型有效提高缺陷的检测精度和实时性,同时不引入过多的参数量和计算量,使改进模型能够更好的部署在计算资源受限的终端上。改进模型在铝合金板数据集和 NEU-DET 数据集上 mAP 分别提高了 3. 2 和 2. 4 个百分点,实验结果表明本文提出的改进模型具有很好的泛化性,在保持高精度检测的同时所需计算资源较少,在铝合金板表面缺陷检测上表现出色。未来工作会进一步优化模型的复杂度并提高检测实时性,在保证精度的同时提升检测效率,为以后应用于铝合金板自动检测系统打下坚实基础。

参考文献

[1] 邱国兴,韦旭立,缪德军,等. 核级 FeCrAl 包壳材料研




图 12 NEU-DET 数据集上可视化对比图

Fig. 12 Visualization comparison on the NEU-DET dataset

究进展[J]. 钢铁研究学报, 2022, 34(9): 884-894.

QIU G X, WEI X L, MIAO D J, et al. Research progress of nuclear FeCrAl cladding materials [J]. Journal of Iron and Steel Research, 2022, 34(9): 884-894.

[2] 冷岳峰, 刘正, 徐宝祯, 等. 改进 Faster R-CNN 的钢材表面缺陷检测[J]. 机械科学与技术, 2025, 44(1): 75-83.

LENG Y F, LIU ZH, XU B Y, et al. Detection of steel surface defect based on improved faster R-CNN [J]. Mechanical Science and Technology for Aerospace Engineering, 2025, 44(1): 75-83.

[3] 李玉, 汤勃, 孙伟, 等. 基于改进 Faster R-CNN 的钢板表面缺陷检测[J]. 组合机床与自动化加工技术, 2022(5): 113-115, 119.

LI Y, TANG B, SUN W, et al. Detection of steel plate surface defects based on improved faster R-CNN [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2022(5): 113-115, 119.

[4] 陈海燕, 甄霞军, 赵涛涛. 一种注意力机制特征融合的小目标检测模型[J]. 华中科技大学学报(自然科学版), 2023, 51(3): 60-66.

CHEN H Y, ZHEN X J, ZHAO T T. Small object detection model based on feature fusion of attention mechanism [J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2023, 51(3): 60-66.

[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] 李和平, 陈中举, 许浩然, 等. 改进 YOLO 的钢材表面缺陷检测算法[J]. 现代电子技术, 2024, 47(13): 7-14.

LI H P, CHEN ZH J, XU H R, et al. Improved YOLO steel surface defect detection algorithm [J]. Modern Electronic Technology, 2024, 47(13): 7-14.

[7] ZHOU Q Q, WANG H C. CABF-YOLO: A precise and efficient deep learning method for defect detection on strip steel surface [J]. Pattern Analysis and Applications, 2024, 27(2): 1-10.

[8] XIA Y, LU Y, JIANG X, et al. Enhanced multiscale attentional feature fusion model for defect detection on steel surfaces [J]. Pattern Recognition Letters, 2025, 18815-18821.

[9] 赵志宏, 赵世哲. KAN-YOLOv8: 一种带钢表面缺陷检测方法[J/OL]. 控制工程, 1-8[2025-06-18]. <https://doi.org/10.14107/j.cnki.kzgc.20240804>.

ZHAO ZH H, ZHAO SH ZH. KAN-YOLOv8: A method

- for surface defect detection of strip steel[J/OL]. Control Engineering of China, 1-8 [2025-06-18]. <https://doi.org/10.14107/j.cnki.kzgc.20240804>.
- [10] WANG C Y, WU Y, WANG Y H, et al. Scene recognition using deep softpool capsule network based on residual diverse branch block [J]. Sensors, 2021, 21 (16): 5575-5575.
- [11] MA Y H, YUAN G W, YUE K, et al. CJS-YOLOv5n: A high-performance detection model for cigarette appearance defects[J]. Mathematical Biosciences and Engineering: MBE, 2023, 20(10): 17886-17904.
- [12] 吴永泽, 俞建峰, 化春键, 等. 基于改进 YOLOv8n 的圆柱电池壳多维缺陷检测技术研究[J]. 电子测量与仪器学报, 2024, 38(12): 62-71.
- WU Y Z, YU J F, HUA CH J, et al. Research on multi-dimensional defect detection technology for cylindrical batteryshells based on an improved YOLOv8n [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(12): 62-71.
- [13] 张琪, 王艺, 陈兆飞. 基于 Sobel 算子图像预处理的目标检测算法[J]. 电子技术与软件工程, 2020(5): 151-153.
- ZHANG Q, WANG Y, CHEN ZH F. Object detection algorithm based on image preprocessing using Sobel operator [J]. Electronic Technology & Software Engineering, 2020(5): 151-153.
- [14] 谢星星, 程堪, 姚艳清, 等. 动态特征融合的遥感图像目标检测[J]. 计算机学报, 2022, 45(4): 735-747.
- XIE X X, CHENG G, YAO Y Q, et al. Dynamic feature fusion for object detection in remote sensing images[J]. Chinese Journal of Computers, 2022, 45(4): 735-747.
- [15] 刘文星, 单慧琳, 王兴涛, 等. 基于阶梯式残差与坐标信息重组的 SAR 舰船检测方法[J]. 光学学报, 2025, 45(9): 0928001.
- LIU W X, SHAN H L, WANG X T, et al. SAR ship detection method based on dadder residual and coordinate information recombination [J]. Acta Optica Sinica, 2025, 45(9): 0928001.
- [16] 张不凡, 俞经虎, 朱行飞, 等. 面向同轴封装金属底座缺陷的 Metal-YOLO 检测算法[J]. 激光与光电子学进展, 2024, 61(22): 132-140.
- ZHANG B F, YU J H, ZHU X F, et al. Metal-YOLO detection algorithm for defects in coaxial packaged base[J]. Laser & Optoelectronics Progress, 2024, 61 (22): 132-140.
- [17] 更藏措毛, 黄鹤鸣, 杨毅杰. 融合多尺度特征与上下文信息的语音增强方法[J]. 计算机工程, 2024, 50(6): 138-147.
- GENGZANGCUOMAO, HUANG H M, YANG Y J. Speech enhancement method incorporating multi-scale features and contextual information [J]. Computer Engineering, 2024, 50(6): 138-147.
- [18] 杨本臣, 李世熙, 李依泽, 等. 改进 YOLOv8n 的钢材表面缺陷检测算法[J/OL]. 机械科学与技术, 1-10 [2025-07-10]. <https://doi.org/10.13433/j.cnki.1003-8728.20240135>.
- YANG B CH, LI SH X, LI Y Z, et al. Improved YOLOv8n algorithm for steel surface defectdetection [J/OL]. Mechanical Science and Technology for Aerospace Engineering, 1-10 [2025-07-10]. <https://doi.org/10.13433/j.cnki.1003-8728.20240135>.
- [19] 刘航, 李明, 刘志坚, 等. 基于轻量化改进 YOLOv8n 绝缘子自爆缺陷检测方法[J]. 电子测量与仪器学报, 2025, 39(1): 57-69.
- LIU H, LI M, LIU ZH J, et al. Self-explosion defect detection method of insulator based on lightweight and improved YOLOv8n [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39 (1): 57-69.
- [20] TIAN Z, SHEN C H, CHEN H, et al. FCOS: A simple and strong anchor-free object detector [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(4): 1922-1933.
- [21] 郭业才, 唐宇捷. 基于 MHD-YOLO 的钢表面缺陷检测算法[J]. 激光与光电子学进展, 2025, 62(20): 2012007.
- GUO Y C, TANG Y J. Steel surface defect detection algorithm based on MHD-YOLO [J]. Laser & Optoelectronics Progress, 2025, 62(20): 2012007.
- [22] 高德勇, 陈泰达, 缪兰. 改进 YOLOv8n 的道路目标检测算法[J]. 计算机工程与应用, 2024, 60(16): 186-197.
- GAO D Y, CHEN T D, MIAO L. Improved road object detection algorithm for YOLOv8n [J]. Computer Engineering and Applications, 2024, 60(16): 186-197.
- [23] 方力涵, 张庆文, 李卫国, 等. 基于改进 YOLOv5 的隧道衬砌病害精确检测方法[J]. 科学技术与工程, 2025, 25(16): 6812-6820.
- FANG L H, ZHANG Q W, LI W G, et al. Tunnel lining defects precision detection methodbased on improved

YOLOv5[J]. Science Technology and Engineering, 2025, 25(16):6812-6820.

[24] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [EB/OL]. (2016-09-17). https://doi.org/10.1007/978-3-319-46448-0_2.

[25] WANG A, CHEN H, LIU L, et al. YOLOv10: Real-time end-to-end object detection [EB/OL]. (2024-10-30) <https://doi.org/10.48550/arXiv.2405.14458>.

[26] KHANAM R, HUSSAIN M. YOLOv11: An overview of the key architectural enhancements [J/OL]. (2024-10-23) <https://doi.org/10.48550/arXiv.2410.17725>.

作者简介



李海宇, 2020 年于辽宁石油化工大学获得学士学位, 现为内蒙古科技大学硕士研究生, 主要研究方向为目标检测。
E-mail: 1965668544@qq.com

Li Haiyu received his B. Sc. degree from Liaoning Petrochemical University in 2020. He is currently a M. Sc. student at Inner Mongolia University of

Science and Technology. His main research interest is object detection.



燕芳 (通信作者), 2001 年于包头钢铁学院获得学士学位, 2005 年于内蒙古科技大学获得硕士学位, 2016 年于北京科技大学获得博士学位, 现为内蒙古科技大学教授, 主要研究方向为太赫兹时域光谱技术与应用研究、无损检测及智能仪器仪表开发、目标检测等。
E-mail: 0472yanfang@163.com

Yan Fang (Corresponding author) received her B. Sc. degree from Baotou Institute of Iron and Steel Technology in 2001, the M. Sc. degree from Inner Mongolia University of Science and Technology in 2005, and the Ph. D. degree from University of Science and Technology Beijing in 2016. She is currently a professor at Inner Mongolia University of Science and Technology. Her main research interests include terahertz time-domain spectroscopy and its applications, nondestructive testing, intelligent instrumentation development, and object detection.