

基于不均衡卷积特征提取的燃料棒焊缝缺陷检测方法

黄 帆¹ 向 勃¹ 李 平¹ 刘 悦²

1(中核建中核燃料元件有限公司 宜宾 644000)

2(哈尔滨工业大学 哈尔滨 150001)

摘要 核燃料棒在反应堆运行中面临极端服役环境,其包壳管与端塞焊缝的精密检测是核安全的重要保障措施。针对真实缺陷发生概率低、X射线成像设备成本高等原因造成高质量的训练数据集缺乏,以及现有模型难以满足实时性检测需求等问题,本文设计了一种基于不均衡卷积特征提取的智能缺陷检测算法,通过在边界回归损失函数中引入距离注意力机制,构建基于不均衡卷积的特征提取主干网络,获得了具有高检测精度和良好实时性的检测模型 YOLOv8n-WIOU-Fasternet,解决缺陷特征不均衡导致的检测模型精度有限和稳定性差的问题。通过自行采集的 500 支燃料棒的 X 射线数字成像(Digital Radiography, DR)图像,制成一批包含气孔、气胀、未焊透、夹钨和堵孔等异常缺陷样品。选取端塞焊缝附近作为感兴趣区域,采用开源图像标注工具 LabelImg 对缺陷区域进行手动标注,获得 720 张缺陷图像。通过对该数据集进行了系统性的数据扩充,生成带有“伪缺陷”的样本,构建出包含不同类型缺陷的燃料棒 DR 图像共计 7 200 张,其中气孔、夹钨、未焊透等不同类型的缺陷在训练集中的数量相同,并按 8:2 的比例划分为训练集和验证集。另行采集了 72 张未参与训练和验证过程的燃料棒缺陷图像,作为独立测试集,对本文所提出的缺陷检测模型进行了性能评估与实验验证。实验结果表明,该模型的检测精度明显优于人工特征提取类缺陷检测方法和原始的 YOLOv8 模型,漏检率和误检率均低于 5%。本文所提出的模型在检测精度和计算效率之间实现了良好的平衡,为燃料棒缺陷检测提供了一种创新且实用的解决方案。

关键词 燃料棒, 焊缝, 缺陷检测, 不均衡卷积特征提取, 卷积神经网络

中图分类号 TL352, TP18, TP391.41

DOI: 10.11889/j.0253-3219.2025.hjs.48.250187

CSTR: 32193.14.hjs.CN31-1342/TL.2025.48.250187

A defect detection method for fuel rod welds based on imbalanced convolution feature extraction

HUANG Fan¹ XIANG Bo¹ LI Ping¹ LIU Yue²

1(CNNC Jianzhong Nuclear Fuel Co., Ltd, Yibin 644000, China)

2(Harbin Institute of Technology, Harbin 150001, China)

Abstract [Background] Nuclear fuel rods operate under extreme service environments in reactor systems, hence precise inspection of cladding tube and end plug welds represents a critical nuclear safety safeguard. Traditional detection methods face significant challenges including the scarcity of high-quality training datasets due to low real defect occurrence rates and high X-ray imaging equipment costs, alongside existing models' inability to meet real-time detection requirements. [Purpose] This study aims to develop an intelligent weld defect detection algorithm

第一作者: 黄帆, 男, 1987 年出生, 2011 年毕业于四川理工学院, 研究领域为燃料棒检验、无损检测, E-mail: 879967686@qq.com

收稿日期: 2025-04-28, 修回日期: 2025-05-19

First author: HUANG Fan, male, born in 1987, graduated from Sichuan University of Science and Engineering in 2011, focusing on fuel rod inspection and non-destructive testing, E-mail: 879967686@qq.com

Received date: 2025-04-28, revised date: 2025-05-19

based on imbalanced convolution feature extraction that achieves both high detection accuracy and real-time performance for fuel rod weld defect identification. **[Methods]** A novel defect detection model, named as YOLOv8n-WIOU-Fasternet, was designed through comprehensive architectural modifications. Firstly, a distance-aware attention mechanism was integrated into the bounding box regression loss function, incorporating a two-level distance penalty mechanism to focus on ordinary-quality anchor boxes while mitigating adverse gradients from low-quality anchors. Secondly, distribution focal loss (DFL) was incorporated to refine edge-level position estimation, enabling more precise boundary localization through cross-entropy optimization of probability distributions around target labels. Meanwhile, by collecting digital radiography (DR) images of 500 fuel rods, a batch of samples containing abnormal defects such as porosity, gas expansion, incomplete penetration, tungsten inclusion, and blockage were prepared. The area near the end plug weld was selected as the region of interest (ROI), and open-source image annotation tool Labelling was applied to manual annotation of the defect area to obtain 720 defect images. By systematically expanding the dataset, samples with "pseudo defects" were generated, and a total of 7 200 DR images of fuel rods containing different types of defects were constructed. Among them, the number of different types of defects such as pores, tungsten inclusions, and incomplete penetration was the same in the training set, and were divided into training and validation sets in an 8:2 ratio. An additional 72 fuel rod defect DR images that did not participate in the training and validation process were collected as an independent test set to evaluate and experimentally validate the performance of the defect detection model. Finally, traditional convolutional modules were replaced by a newly designed partial convolution (PConv) structure that selectively applies convolution to a subset of input channels while retaining others, followed by pointwise convolution for spatial information fusion and maintaining representational completeness. **[Results]** The experimental validation results demonstrate that the proposed YOLOv8n-WIOU-Fasternet model achieves false negative and false positive rates both below 5%, representing significant performance improvements across multiple metrics and substantial reductions compared to baseline models. The maximum F1 score reaches 0.947 at a confidence threshold of 0.285, with corresponding false positive and false negative rates of 3.1% and 3.5%, respectively. The average precision (AP) performance significantly surpasses both traditional feature extraction methods and the original YOLOv8 model across various IoU thresholds. **[Conclusions]** The proposed model successfully achieves an optimal balance between detection accuracy and computational efficiency through its innovative architectural design. The integration of distance-aware attention mechanisms and partial convolution structures reduces computational overhead while maintaining superior detection performance. This comprehensive approach provides a robust and practical solution for automated fuel rod defect detection in real-world nuclear fuel manufacturing applications, meeting both precision requirements and real-time processing constraints essential for industrial deployment.

Key words Fuel rods, Weld line, Defect detection, Uneven convolution feature extraction, Convolutional neural network

燃料棒在反应堆运行中面临极端服役环境,需持续承受高温、高压工况,经受每秒十余米流速的冷却剂反复冲刷,面对耦合裂变产物的化学腐蚀、复杂机械载荷及高温蒸汽侵蚀等多重破坏因素。燃料元件包壳作为核反应堆安全系统的第一道屏障,与端塞构成的环形焊缝在焊接过程中易产生夹钨、气孔、未焊透等多类型缺陷,成为放射性物质泄漏的主要风险源^[1-2]。根据 HAF60409 核安全法规及 ASME BPVC-III 核设备建造规范要求,燃料棒制造须执行全过程质量管控。燃料棒焊缝的 100% 无损检测被列为强制性质量控制节点。X 射线数字成像 (Digital Radiography, DR) 是焊缝的重要检测手

段^[2-3],然而仍依赖人工经验进行缺陷判读,在检测效率、评判标准一致性方面存在主观性制约。

目前针对 X 射线 DR 图像的构件缺陷检测方法主要分为传统的人工特征提取类方法和深度学习类方法^[4-6]。传统的人工特征提取类方法通过显式设计或选择的算子提取,通常速度快、体小,检测结果可解释性强。然而,该方法在低对比度 DR 图像场景下的检测效果有限,难以获得缺陷的高级语义信息和高判别性特征,导致缺陷检测精度的上限较低,存在较高的漏检率和误检率。深度学习类方法的网络模型可自动学习特征,所依赖的先验知识较少,但需要大量的数据集,训练过程时间成本较高。

近年来随着深度学习的蓬勃发展,其在缺陷检测领域的应用被不断发掘且由于其高检测精度和良好的稳定性得到了越来越多研究人员的青睐。目前用于缺陷检测的主流神经网络模型包括卷积神经网络、自动编码器网络和递归神经网络等。

国外方面,2018年Ferguson等^[7]参考Mask R-CNN在Faster R-CNN的基础上添加了语义分割模块,并根据数据集内的实际缺陷的尺度分布定义了15种尺度的长宽比各异的先验框,将构建的模型在ImageNet和COCO数据集上学得的知识迁移至精密构件X射线图像内部缺陷定位任务中,实现了构件内部缺陷的定位,获得了0.957的平均精度(mean Average Precision, mAP)值。2021年Mery团队^[8]针对基于X射线图像的精密构件内部缺陷定位任务中标注耗时、耗力的问题,使用少量的无缺陷的铝合金轮毂铸件X射线图像与模拟生成的缺陷叠加,同时自动获取缺陷的真实包围框,从而构建了数据集,并用此数据集训练了8种的深度模型(YOLO系列, RetinaNet和EfficientDet)。其中YOLOv5s在其构建的测试集上取得了较好的结果:平均精度为0.90, F1分数为0.91;FPS为90。2023年Lal等^[9]提出了一种轻量级模型,通过深度可分卷积和全局平均卷积等方法最小化计算需求,与诸如MobileNet、Inception和ResNet等先进的、经过预先训练的CNN模型相比,在准确性和推理时间方面都具有优势。采用深度可分离卷积的590 K参数定制模型在准确率(81.87%)方面优于ResNet和Vision Transformers等经过预训练的架构,在推理时间(12 ms)方面也轻松超过了ResNet和Inception等架构。这项工作表明了无须依赖预训练架构,也有可能构建具有高效架构和更快推理时间的定制网络。

国内方面,2019年周洲等^[10]针对精密构件中的缺陷定位问题,提出了一种双阶段缺陷定位模型。该模型以VGG16为基础网络,对基础网络输出的特征进行空洞卷积以提升感受野,融合多个尺度的特征获取完备信息,使用位置敏感的卷积层和池化层实现建议框内的对象分类和建议框回归。实验结果表明,该模型在其任务上表现优于Faster R-CNN和SSD,定位结果与人工标注结果的平均交并比为80.59%。2020年郭瑞琦等^[11]通过引入Dropout层降低过拟合风险,用多步长卷积代替最大池化进行下采样减少信息丢失从而改进了Unet模型,提升了网络模型的缺陷分割定位性能。同年,Yu等^[12]提出了一种用于精密构件X射线缺陷语义分割的自适应深度和感受野选择网络。首先,设计了带有自适应深度选择机制的ResNet18来提取和自适应聚合不同

的深度特征,这有利于区分类似的缺陷;然后,提出了自适应感受野块,以数据驱动的方式选择最佳感受野,以适应缺陷的尺度变化;最后,建立了一个铸件缺陷分割数据集SRIF-CDS,以训练和评估该方法。在SRIF-CDS上的实验表明,该方法实现了0.86联合上的平均交集(mean Intersection over Union, mIoU)和0.92平均准确度(mean Accuracy, mAcc)。2021年,Du等^[13]以DetNet作为主干网络,弥补下采样过程丢失的位置信息;参照路径聚合网络(Path Aggregation Network, PANet)构建具有增强的自下而上的路径的特征金字塔,缩小了特征图及相应提议框之间的特征差异;采用软非极大抑制(soft Non-Maximum Suppression, soft-NMS)保留了更多的具有较高置信度的建议框。通过上述改进方法,mAP值与基础网络架构相比提升了0.118。

但是,目前深度学习类方法由于真实缺陷发生概率低、X射线成像设备成本高等原因缺乏高质量的训练数据集,此外模型的实时性性能往往难以满足实际工业生产需求。由于YOLO系列单阶段检测模型在保证高检测精度的同时具有良好的实时性,因此在各种实际工业生产场景中应用广泛。本文在单阶段检测模型之一YOLOv8模型的基础上对损失函数和主干特征提取网络进行重新设计,使得模型更适应于低对比度缺陷检测场景,引入新型部分卷积思想,设计了一种新型智能缺陷检测算法。

1 理论与方法

1.1 智能检测算法的回归损失函数设计

1) 边界回归损失

在原始YOLOv8模型中,采用CIOU损失作为边界回归损失函数,其主要是基于目标框与预测框的比值,将预测框与目标框之间的中心点距离、重叠程度和长宽比因素结合^[14],具体公式如下:

$$\begin{aligned} \text{CIOU} &= 1 - \text{IoU} + \frac{\rho^2(b, b^{gt})}{c^2} + \alpha v \\ \text{IoU} &= \frac{G \cap D}{G \cup D} \\ \alpha &= \frac{v}{(1 - \text{IoU}) + v} \\ v &= \frac{4 \cdot \left(\arctan\left(\frac{w_{b^{gt}}}{h_{b^{gt}}}\right) - \arctan\left(\frac{w_b}{h_b}\right) \right)^2}{\pi^2} \end{aligned} \quad (1)$$

式中:IoU为缺陷预测框与缺陷真实框之间的交并比;G表示缺陷真实框;D表示缺陷预测框; ρ 为预测框与目标框中心点之间的距离; b 表示预测框; b^{gt} 表

示目标框; c 表示预测框与目标框的最小外接矩形的对角线距离; α 是一个权重参数; v 是一个修正因子, 将目标框的形状和方向考虑其中, 用于进一步优化损失函数 $v; (w_{b^{gr}}, h_{b^{gr}})$ 和 (w_b, h_b) 分别表示目标框和预测框的宽高。

这种 CIOU 损失函数虽然综合考虑了预测框与目标框的位置、形状、方向等多个因素且对定位精度的敏感性相较于传统单一的 IoU 值损失函数得到了提升, 但是 CIOU 中的一些关键参数, 比如修正因子的权重参数 α 等, 会对损失函数的收敛产生较大影响, 需要对其取值进行仔细调节以获得更优的模型性能。此外, 长宽比修正因子无法完全反映预测框与目标框的形状和方向, 当预测框与目标框的长宽比相同但实际宽高值不同时, 该修正因子的惩罚项始终为 0, 会阻碍模型的进一步优化。由于训练数据会不可避免地包含低质量图像锚框和高质量锚框, 根据 CIOU 的计算方式, 修正因子会加重对低质量锚框的惩罚同时加强高质量锚框的竞争力, 多数普通质量锚框对模型的影响被削弱, 从而降低模型的泛化性能^[15]。

针对上述问题, 本文引入一种基于双层距离注意力机制的边界回归损失函数 WIOU。WIOU 是在 WIOU v3 的基础上构建的^[16], 主要参考了其双层距离惩罚机制, 通过一层距离离群度 $\mathcal{R}_{WIOU}$ 的计算和一层交并比 $\mathcal{L}_{IOU}$ 的计算使模型的收敛更聚焦于普通质量锚框:

$$\begin{aligned} WIOU &= \mathcal{R}_{WIOU} \mathcal{L}_{IOU} \\ \mathcal{R}_{WIOU} &= \exp \left(\frac{(x - x_{gr})^2 + (y - y_{gr})^2}{(W_g^2 + H_g^2)^*} \right) \\ \mathcal{L}_{IOU} &= 1 - \text{IoU} = 1 - \frac{W_l H_l}{S_u} \end{aligned} \quad (2)$$

式中: $\mathcal{R}_{WIOU} \in [1, e)$ 反映了两个锚框的离群度, 显著放大了普通质量锚框的损失函数; $\mathcal{L}_{IOU} \in [0, 1]$ 反映了两个锚框的重合程度, 即交并比, 显著降低了高质量锚框的 $\mathcal{R}_{WIOU}$ 及其对两个锚框中心点之间距离的聚焦能力; 此外 WIOU 未将长宽比等几何度量直接引入损失函数的计算, 减少了低质量锚框所产生的有害梯度。

2) 分布焦损失

分布焦损失又称 DFL 损失, 在边界回归损失的基础上, 进一步采用 DFL 损失函数增强模型对标签的聚焦能力, DFL 损失函数主要是使用交叉熵函数对目标标签最接近的左右两个位置的概率分布进行优化, 使得模型更快更准地聚焦于目标标签附近。通过这种方式, 模型所学习的分布理论上位于目标

浮点坐标的附近并且通过线性插值得到一左一右两个最接近的整数坐标的权重。DFL 损失的计算公式如下:

$$\text{DFL} = - \left((y_{i+1} - y) \lg(S_i) + (y - y_i) \lg(S_{i+1}) \right) \quad (3)$$

式中: y 表示预测值; y_{i+1} 表示临近预测值; S_i 表示标签为 $y = i$ 类的估计概率。通俗来说, 就是将回归问题转化为一个分类问题并利用交叉熵函数进行优化。

综上所述, 在本文的模型中, 采用 WIOU 和 DFL 相结合作为模型的回归损失函数, 其中 DFL 负责对预测框的每条边的位置进行优化, WIOU 对优化后的预测框整体的位置、形状和方向进行优化。

1.2 智能检测算法的主干特征提取网络设计

考虑到燃料棒生产中的实时性检测需求, 采用单阶段检测模型 YOLOv8 的网络结构为基础进行缺陷检测。网络的主干部分采用的是 CSPDarknet 结构, 这种结构通过差分特征图的方式有效降低了计算量以保证模型的轻量化。此外, 与前代 YOLO 系列模型相比, YOLOv8 还结合了 ELAN (Efficient Layer Aggregation Networks) 的核心思想, 并将主干网络中的 C3 模块优化为更高效的 C2f (Cross Stage Partial with two convolutions and feature fusion) 模块, 在进一步轻量化的同时保证模型获得了更丰富的梯度流信息, 更利于保证检测精度^[14]。然而, 由于 CSPDarknet 结构本身在小目标检测方面的性能有限, YOLOv8 模型的检测精度距离预期目标还有一定距离。针对上述问题, 本文将进一步对检测模型的主干特征提取网络进行优化和重新设计。

1.2.1 新型部分卷积算法研究

在对 YOLO 系列模型提升检测精度时, 引入各种注意力机制模块以增强模型对目标前景特征的聚焦能力, 注意力机制模块的引入不仅需要专门的硬件支持, 而且会导致网络结构更加复杂, 网络延迟时间加长, 进而带来计算成本的大幅增加^[14]。为了解决这一问题, 在提升精度的同时尽量降低计算成本, 缩短模型运行时间, 目前大多数方法都在尝试减小浮点运算数量。但实际上, 网络的延迟时间不仅取决于浮点运算数量, 还与内存访问量有关, 如式(4)所示, 单纯地降低总浮点运算数量可能会导致内存访问量增加这一副作用, 最终无法实现真正的网络低延迟, 节约计算成本。

$$\text{Latency} = \frac{\text{FLOPs}}{\text{FLOPS}} \quad (4)$$

式中: FLOPs 代表总浮点运算数量, FLOPS 代表每秒浮点运算数量。FLOPS 取决于模型网络中各模

块的内存。

深度可分离卷积模块 (Depthwise Separable Convolution, DWConv) 就是一种典型的与注意力机制模块结合以降低总浮点运算量的方法, 它通过 c 个 $k \times k$ 的滤波器在各个输入通道上滑动并只计算一个输出通道的值实现卷积操作, 如图 1 所示。通过分析可得, 常规卷积的总浮点计算量为 $h \times w \times k^2 \times c^2$, 而深度可分离卷积的总浮点计算量为 $h \times w \times k^2 \times c$, 有效降低了 FLOPs。但由于深度可分离卷积模块只计算了一个输出通道的值, 不能单独使用来代替常规卷积, 否则会造成严重的精度下降, 通常会与逐点卷积模块 (Pointwise Convolution, PWConv) 配合使用, 这样其通道数会变宽为 c' ($c' > c$), 一个深度分离卷积模块的内存访问量变为:

$$h \times w \times 2c' + k^2 \times c' \approx h \times w \times 2c' \quad (5)$$

而一个常规卷积的内存访问数量为:

$$h \times w \times 2c + k^2 \times c^2 \approx h \times w \times 2c \quad (6)$$

深度可分离卷积模块的内存访问数量大于常规卷积的内存访问数量, 深度可分离卷积带来的总浮点计算量由于内存访问量的增加无法有限转化为网络延迟时间的降低, 无法有效缩短模型运行时间, 节约计算成本。

针对上述深度可分离卷积存在的问题, 引入一




图 1 深度可分离卷积原理示意图
Fig.1 Schematic of depthwise separable convolution

种新型部分卷积 PConv, 可以同时减小总浮点计算量和内存访问量。新型部分卷积 PConv 通过对部分输入通道进行常规卷积操作而保持其余通道不变, 如图 2 所示, 设执行常规卷积操作的通道数为 c_p , 卷积核大小为 $k \times k$, 输入特征图的宽和高分别为 h 和 w , 则一个新型部分卷积模块的总浮点计算量为:

$$h \times w \times k^2 \times c_p^2 \quad (7)$$

在实际实现时取 $r = \frac{c_p}{c} = \frac{1}{4}$, 此时一个新型部分卷积模块的总浮点计算量仅为一个常规卷积模块的 $\frac{1}{16}$; 此外, 其内存访问量为:

$$h \times w \times 2c_p + k^2 \times c_p^2 \approx h \times w \times 2c_p \quad (8)$$

内存访问量仅为一个常规卷积模块的 $\frac{1}{4}$, 剩余 $(c - c_p)$ 个通道由于不参与卷积计算, 所以不消耗内存访问量。




图 2 新型部分卷积原理示意图

h —特征图的高, w —特征图的宽, c —特征图的通道数, c_p —不平衡卷积通道数, k —卷积核大小

Fig.2 Schematic of the principle of new partial convolution

h —height of feature map, w —width of feature map, c —number of channels in feature map, c_p —number of imbalanced convolution channels, k —convolution kernel size

由于在上述部分卷积中还有部分通道未进行卷积操作, 信息未被利用, 所以在上述新型部分卷积之后连接一个逐点卷积模块 PWConv, 如图 3 所示, 在 $k \times k \times c_p$ 的新型部分卷积之后连接一个 $1 \times 1 \times c$ 的逐点卷积 PWConv, 此时的 PConv+PWConv 模块的综合总浮点计算量为:

$$h \times w \times (k^2 \times c_p^2 + c \times c_p) \quad (9)$$

由于 PConv+PWConv 模块的效果可以等效为一个单步的 T 型卷积, 如图 3 所示, 计算单步 T 型卷积的总浮点运算量为:

$$h \times w \times (k^2 \times c_p \times c + c \times (c - c_p)) \quad (10)$$

式中: $c > c_p$, $c - c_p > c_p$, 因此解耦成两步实现的 PConv+PWConv 充分利用了过滤器间的冗余, 比其等效的单步 T 型卷积更能降低总浮点运算量 FLOPs。

1.2.2 基于新型部分卷积的主干特征提取网络设计

基于上述的新型部分卷积思想, 本文设计了一种能够与 YOLOv8-head 相匹配的 4 层主干特征提取网络结构, 如图 4 所示。其每一层均包含若干个 Fasternet 模块, 第一层中在 Fasternet 模块前首先通过一个步长为 4, 卷积核大小为 4×4 的嵌入模块, 第二、三、四层中在 Fasternet 模块前均使用一个步长为




图3 新型部分卷积连接逐点卷积的原理示意图
 c —特征图的通道数, c_p —不平衡卷积通道数, k —卷积核大小

Fig.3 Schematic of novel partial convolution with pointwise convolution

c — number of channels in feature map, c_p — number of imbalanced convolution channels, k — convolution kernel size

2, 卷积核大小为 2×2 的降采样模块, 用于空间下采样和通道数扩展。其中, 最后两层中由于消耗的内

存访问更少具有更大的浮点计算量冗余, 因此最后两层中的Fasternet模块数多于前两层, 用以承担更多的计算任务。




图4 基于新型部分卷积的4层主干特征提取网络结构示意图

Conv—卷积, Fasternet—不平衡卷积核心模块, c_i —输入通道数, h —特征图高, w —特征图宽, l_i —模块数量

Fig.4 Structural diagram of four-layer backbone feature extraction network structure based on novel partial convolution

Conv — convolution, Fasternet — imbalanced convolution core module, c_i — number of input channels, h — height of feature map, w — width of feature map, l_i — number of modules

每个Fasternet模块都是由一个新型部分卷积PConv连接两个逐点卷积PWConv构成, 如图5所示, 形成一个倒残差的结构。在每个Fasternet模块中, 对指定的通道执行部分卷积, 剩余通道执行逐点卷积, 并将批归一化(Batch Normalization, BN)层和

激活函数仅放在中间的逐点卷积后, 以保证特征多样性, 降低计算复杂度。其中BN层的优点是可以通




图5 Fasternet模块示意图 PConv—不平衡卷积, Conv—常规卷积, BN—归一化, ReLu—激活函数

Fig.5 Diagram of Fasternet module

PConv — partial convolution, Conv — conventional convolution, BN — batch normalization, ReLu — activation function

上述基于新型部分卷积的主干特征提取网络只完成了对输入图像特征信息的提取, 还需要一个Neck层对特征进行降维和调整, 以及一个Head层作为边界框回归器和分类器对特征进行处理产生最终的输出。

PANet结构通过引入自上而下和自下而上的双向路径聚合机制, 有效利用了不同层次的特征图信息, 使得模型对不同尺度目标和场景的适应性更强。PANet包含两个路径聚合模块, 分别是自上而下的

PA模块和自下而上的PAM模块。PA从较低分辨率的特征图开始, 通过上采样逐层向上传递信息, 而PAM则从高分辨率的特征图开始, 通过下采样逐层向下传递信息。这两个路径聚合模块相互配合, 构成了PANet结构能够更好地整合不同尺度的特征信息。因此本文中采用PANet结构作为Neck层, 主干网络的输出最终经过一个空间金字塔池化(Spatial Pyramid Pooling Fast, SPPF)层后整体共执行了32倍下采样, 将此32倍下采样结果与之前的16倍下采

样结果和8倍下采样结果输入PANet结构,经过上采样和通道融合等操作得到3个输出进入后续Head层中计算损失函数并输出结果。

Decoupled-head解耦头结构通过在主干网络特征图的基础上额外加入一个分支将特征提取和像素级预测分离,使得网络可以更加灵活地处理不同尺度的语义信息,进一步提高目标检测的准确性;同时Decoupled-head结构通过在主干网络的不同层级添加分支,可以对来自多尺度的特征信息进行融合,提高整个网络对多尺度目标的检测能力;将像素级的预测作为独立的任务进行处理,可以更好地保留细节和边缘信息,提高检测的准确性。此外,Decoupled-head结构与其他Head结构相比可以更方便的根据需要进行扩展和修改,以适应不同的检测任务和数据集需求。本文中来自PANet层的3个不同尺度的输出特征信息输入Decoupled-head结构,通过解耦分离、特征融合和独立的预测分支处理后,得到损失函数和预测结果。

使用基于新型部分卷积的4层主干特征提取网络结构作为模型的主干特征提取网络,并将其3个不同尺度的输出特征输入至PANet-neck结构进行降维和融合调整。最后,将Neck处理后的3个不同尺度的特征输入到Decoupled-head解耦头中进行三类损失函数运算和结果预测,实现缺陷的准确检测,4层Fasternet主干网络和PANet以及Decoupled-head解耦头共同组成了一种新型的网络结构YOLOv8n-WIOU-Fasternet,该模型在低对比度小缺陷目标检测方面具有出色的性能。

1.3 算法总体流程

本文在YOLOv8模型的基础上对损失函数和主干特征提取网络进行了重新设计,使得模型更适用于低对比度小目标检测场景,并实现时间成本的有效控制。YOLOv8n-WIOU-Fasternet的网络结构如图6所示,主要包括损失函数、主干特征提取网络、对特征进行降维和调整的Neck层和作为边界框回归器和分类器的Head层。

2 实验与结果分析

2.1 数据采集

本次实验数据均为自行采集的500支燃料棒的数字DR图像,非公共数据集。调整X射线照射参数,设置焦距为1 000 mm,管电压为220 kV,图像显示的窗宽、窗位分别调整至30 000、35 000左右。每次DR投影同时采集多支燃料棒数据,如图7所示。




图6 不平衡深度可分离卷积神经网络YOLOv8n-WIOU-Fasternet模型结构流程图

Conv—卷积, Fasternet Block—不平衡卷积核心模块, SPPF—空间金字塔池化, C2f—局部混合神经网络, Concat—连接层

Fig.6 Flowchart of imbalanced depthwise separable convolutional neural network YOLOv8n-WIOU-Fasternet model structure

Conv — convolution, Fasternet Block — imbalanced convolution core module, SPPF — spatial pyramid pooling fast, C2f — cross stage partial with two convolutions and feature fusion, Concat — concatenation layer

样品在制备过程中,通过调整焊接工艺参数,制成一批包含气孔、气胀、未焊透、夹钨和堵孔等异常缺陷样品,其中的气孔缺陷、夹钨和未焊透如图8(a)、(b)和(c)所示。

在采集燃料棒X射线原始图像后,自动将多个燃料棒分割成单个图像,并选取端塞焊缝附近作为感兴趣区域。在感兴趣区域内,采用开源图像标注工具LabelImg对缺陷区域进行手动标注,如图9所示,共获得了共计720张缺陷图像。随后,对该数据集进行了系统性的数据扩充,主要包括以下三类操




图7 燃料棒的X射线原始图像
Fig.7 X-ray raw images of fuel rods




图8 燃料棒的典型缺陷图 (a) 气孔缺陷, (b) 夹钨, (c) 未焊透
Fig.8 Photos of typical defects in fuel rods (a) Porosity defect, (b) Tungsten inclusion, (c) Lack of penetration

作:一是通过旋转、缩放和平移等几何变换增强样本多样性;二是引入噪声和模糊等扰动增强模型的抗干扰能力;三是采用缺陷拷贝粘贴的方法,从真实缺陷图像中裁剪缺陷区域并粘贴至无缺陷图像上,生成带有“伪缺陷”的样本。最终,构建出包含不同类型缺陷的燃料棒 DR 图像共计 7 200 张,其中气孔、

夹钨、未焊透等不同类型缺陷在训练集中的数量相同,并按 8:2 的比例划分为训练集和验证集,用于模型的训练与性能评估。最终,另行采集了 72 张未参与训练和验证过程的燃料棒缺陷图像,作为独立测试集,用于对本文所提出的缺陷检测模型进行性能评估与实验验证。




图9 燃料棒缺陷手动标记 (a) 补仓块内的一组燃料棒投影, (b) 单个燃料棒投影, (c) 感兴趣区域, (d) 手动标记的缺陷
Fig.9 Manual tagging of fuel rod defect (a) Projection of a fuel rod assembly within a replenishment block, (b) Single fuel rod projection, (c) Region of interest, (d) Manually labeled defects

2.2 缺陷检测模型的精度性能分析

模型的训练与测试实验在一台配置为 NVIDIA GeForce RTX 3060 GPU (12 GB 显存) 与 Intel(R) Core(TM) i9-14900HX CPU (2.20 GHz) 的服务器上,系统内存为 32 GB。所采用的深度学习开发环境基于 PyTorch 框架,一些工具包的版本为 torch 1.8.0, torchvision 0.9, Ultralytics YOLOv8 版本为

8.0。此外, CUDA 版本为 10.6。根据中的训练参数得到边界回归损失和分布焦损失的函数曲线如图 10 所示。从图 10 可以看出,本文所设计的 YOLOv8n-WIOU-Fasternet 检测模型的损失函数收敛更平稳,收敛速度更快,尤其在边界回归损失函数上表现尤为卓越。其中边界回归损失函数最终收敛至 0.5 左右,分布焦损失函数最终收敛至 0.8 左右。




图10 损失函数曲线 (a) 边界回归损失, (b) 分布焦损失
Fig.10 Loss function curves (a) Boundary regression loss, (b) Distribution focal loss

1) 漏检率

漏检率与用于判断样本是否检测正确的IoU阈值有关,在预测结果不变的情况下,IoU阈值越大,则样本预测正确的比例越小,综合考虑缺陷尺寸和对比度等因素,在本次实验中将该项IoU阈值设置为0.25。此外,在基于深度学习的检测模型中,漏检率还与置信度阈值相关,置信度阈值用于筛选置信度得分高于该阈值的候选框并将其作为预测结果。根据漏检率的定义得到:

$$N_p = \frac{FN}{TP + FN} = 1 - \frac{TP}{TP + FN} = 1 - R_p \quad (11)$$

式中: R_p 称为召回率,召回率表征了真实缺陷中被检测出的真实缺陷的占比,根据模型输出的召回率可以计算得到漏检率随模型置信度阈值的变化曲线,如图11所示,随着置信度阈值的增加,漏检率随之提高,且本文的YOLOv8n-WIOU-Fasternet模型的漏检率明显低于其他几种模型。




图11 漏检率-置信度阈值曲线
Fig.11 Curves of false negative ratio-confidence threshold

2) 误检率

误检率与用于判断样本是否检测正确的IoU阈值有关,IoU阈值设置为与漏检率相同的0.25。此外,在基于深度学习的检测模型中,漏检率也与置信度阈值相关。根据漏检率的定义得到:

$$W_p = \frac{FP}{TP + FP} = 1 - \frac{TP}{TP + FP} = 1 - P_p \quad (12)$$

式中: P_p 称为准确率,准确率表征了检测出的所有缺陷中真实缺陷的占比,根据模型输出的准确率可以计算得到误检率随模型置信度阈值的变化曲线,如图12所示,随着置信度阈值的增加,误检率随之降低,且本文的YOLOv8n-WIOU-Fasternet模型的误检率明显低于其他几种模型。

根据漏检率与误检率与置信度阈值变化的关系,可以得到误检率与漏检率的关系曲线,如图13所示。随着置信度阈值增加,漏检率升高而误检率降低,因此为了衡量不同置信度阈值下模型的综合精度性能,本领域中常使用F1分数和AP值来反映模型的最优综合精度性能和平均综合精度性能。




图12 误检率-置信度阈值曲线
Fig.12 Curves of false predicted ratio-confidence threshold

3) 最优综合精度性能指标:F1分数

F1分数是衡量不同置信度阈值下模型最优精度性能的一项指标,定义为准确率 P_p 和召回率 R_p 的调和平均数,如式(13)所示,取值位于[0,1]区间,值越大说明模型的综合精度性能越好,最大F1分数即反映了模型的最优精度性能。

$$F1 = 2 \cdot \frac{P_p \cdot R_p}{P_p + R_p} \quad (13)$$




图13 误检率-漏检率曲线
Fig.13 Curves of false predicted ratio-false negative ratio

表1展示了几种模型在最大F1分数下的漏检率和误检率,从表1可以看出,本文的YOLOv8n-WIOU-Fasternet模型的综合精度性能明显优于其他模型,最优综合精度性能下的误检率和漏检率分别为3.1%和3.5%。

4) 平均综合精度性能指标 (Average comprehensive Precision performance index, AP)

为了进一步衡量不同置信度阈值下模型的综合精度性能,引入平均综合精度性能指标AP,定义为误检率-漏检率曲线中曲线与 $x=1$ 、 $y=1$ 之间围成的区域面积,该值仅与IoU阈值有关,AP值随IoU阈值的变化曲线如图14所示,AP值越高,模型在不同置

信度阈值下的平均综合精度性能越好,从图14可以看出,本文设计的YOLOv8n-WIOU-Fasternet模型的平均综合精度性能明显优于其他几个模型。




图14 AP-IoU曲线图(彩图见网络版)
Fig.14 Curves of AP-IoU (color online)

2.3 缺陷检测模型的速度性能分析

除以上精度指标外,本文对模型的检测速度进行了测试,实验平台均采用NVIDIA GeForce RTX 3060,结果如表2所示。实验结果表明,设计的YOLOv8n-WIOU-Fasternet模型与原YOLOv8模型相比用较少的计算成本增加获得了显著的精度提升,同时与传统加入自注意力机制模块的模型相比计算成本大幅降低,更好地实现了检测精度性能与速度性能的平衡。

表1 几种模型的最大F1分数
Table 1 Maximum F1 score for several models

模型 Models	最大F1分数 Maximum F1 scores	置信度阈值 Confidence thresholds	误检率 False predicted ratio / %	漏检率 False negative ratio / %	平均检测精度 Average precision
YOLOv8n	0.919	0.355	6.9	10.2	0.910
YOLOv8n-WIOU	0.931	0.285	5.1	10.8	0.949
YOLOv8n-WIOU-Fasternet	0.947	0.285	3.1	3.5	0.992

表2 不同模型的检测速度对比
Table 2 Comparison of detection speed among different models

模型 Models	每秒浮点运算次数 Floating point operations per second	参数 Parameters	单轮训练时长 Single round training duration / s	训练总时长 Total training duration / h	单张图片检测用时 Single image detection duration / ms
YOLOv8n	8.1 G	3 005 843	78.5	1.090	9.0
YOLOv8n-WIOU	8.1 G	3 005 843	82.9	1.151	8.9
YOLOv8n-WIOU-Fasternet	11.4 G	4 321 636	90.2	1.253	10.4
YOLOv8-Swintransformer	79.8 G	30 135 610	单轮训练时长超过20 min A single round of training lasting more than 20 min		

3 结语

本文设计了一种基于新型部分卷积的智能二维

缺陷检测算法,通过优化边界回归损失函数和重新设计基于新型部分卷积的主干特征提取网络获得了具有高检测精度和良好的实时性的检测模型

YOLOv8n-WIOU-Fasternet。实验表明,该模型的检测精度明显优于人工特征提取类缺陷检测方法和原始的YOLOv8模型,漏检率和误检率均低于5%,该模型在燃料棒焊缝缺陷检测精度和检测速度平衡能力上表现良好。

作者贡献说明 黄帆负责数据采集、编程、方法设计和初稿写作;向勃负责数据采集和标注;李平负责验证和修改稿件;刘悦负责编程和方法设计,修改稿件。

参考文献

- 1 杨钦轲,王华才,程焕林,等.压水堆核电站完整和破损燃料棒硬度和杨氏模量研究[J].原子能科学技术,2024,58(1):157-165. DOI: 10.7538/yzk.2023.youxian.0086.
YANG Qinke, WANG Huacai, CHENG Huanlin, *et al.* Hardness and Young's modulus of intact and leak PWR fuel rods[J]. Atomic Energy Science and Technology, 2024, 58(1): 157-165. DOI: 10.7538/yzk.2023.youxian.0086.
- 2 黄帆,向勃,李平,等.燃料棒数字成像亮度融合与多尺度优化增强算法[J].核技术,2025,48(2):240004. DOI: 10.11889/j.0253-3219.2025.hjs.48.240004.
HUANG Fan, XIANG Bo, LI Ping, *et al.* Brightness fusion and multi-scale optimized enhancement algorithm for fuel rod DR images[J]. Nuclear Techniques, 2025, 48(2): 240004. DOI: 10.11889/j.0253-3219.2025.hjs.48.240004.
- 3 Naddaf-Sh M M, Naddaf-Sh S, Zargarzadeh H, *et al.* Defect detection and classification in welding using deep learning and digital radiography[M]//Fault Diagnosis and Prognosis Techniques for Complex Engineering Systems. Academic Press, 2021: 327-352. DOI: 10.1016/B978-0-12-822473-1.00007-0.
- 4 武博.航空钛合金铸件内部缺陷自动识别关键技术研究[D].武汉:华中科技大学,2022. DOI: 10.27157/d.cnki.ghzku.2022.000486.
WU Bo. Research on key technologies for automatic identification of internal defects in aerospace titanium alloy castings[D]. Wuhan: Huazhong University of Science and Technology, 2022. DOI: 10.27157/d.cnki.ghzku.2022.000486.
- 5 张小刚,俞东宝,汤慧,等.基于深度学习的X射线燃料棒端塞缺陷自动检测方法研究[J].原子能科学技术,2024,58(8):1767-1776. DOI: 10.7538/yzk.2023.youxian.0706.
ZHANG Xiaogang, YU Dongbao, TANG Hui, *et al.* Research on automatic detection method of X-ray fuel rod end plug defects based on deep learning[J]. China Industrial Economics, 2024, 58(8): 1767-1776. DOI: 10.7538/yzk.2023.youxian.0706.
- 6 王睿,高少泽,刘卫朋,等.一种轻量级高效X射线焊缝图像缺陷检测方法[J].焊接学报,2024,45(7):41-49.
WANG Rui, GAO Shaoze, LIU Weipeng, *et al.* A lightweight and efficient X-ray weld image defect detection method[J]. Transactions of the China Welding Institution, 2024, 45(7): 41-49.
- 7 Ferguson M K, Ronay A, Lee Y T, *et al.* Detection and segmentation of manufacturing defects with convolutional neural networks and transfer learning[J]. Smart and Sustainable Manufacturing Systems, 2018, 2: 10.1520/SSMS20180033. DOI: 10.1520/SSMS20180033.
- 8 Mery D. Aluminum casting inspection using deep object detection methods and simulated ellipsoidal defects[J]. Machine Vision and Applications, 2021, 32(3): 72. DOI: 10.1007/s00138-021-01195-5.
- 9 Lal R, Bolla B K, Sabeesh E. Efficient neural net approaches in metal casting defect detection[J]. Procedia Computer Science, 2023, 218: 1958-1967. DOI: 10.1016/j.procs.2023.01.172.
- 10 周洲.轮芯缺陷检测及缺陷样本生成技术[D].广州:华南理工大学,2019. DOI: 10.27151/d.cnki.ghnlu.2019.001245.
ZHOU Zhou. Technology of wheel core defect detection and defect sample generation[D]. Guangzhou: South China University of Technology, 2019. DOI: 10.27151/d.cnki.ghnlu.2019.001245.
- 11 郭瑞琦,王明泉,张俊生,等.基于U-Net卷积神经网络的轮毂缺陷分割[J].自动化与仪表,2020,35(4):43-47. DOI: 10.19557/j.cnki.1001-9944.2020.04.010.
GUO Ruiqi, WANG Mingquan, ZHANG Junsheng, *et al.* Hub defect segmentation based on U-Net convolutional neural network[J]. Automation & Instrumentation, 2020, 35(4): 43-47. DOI: 10.19557/j.cnki.1001-9944.2020.04.010.
- 12 Yu H, Li X J, Song K C, *et al.* Adaptive depth and receptive field selection network for defect semantic segmentation on castings X-rays[J]. NDT & E International, 2020, 116: 102345. DOI: 10.1016/j.ndteint.2020.102345.
- 13 Du W Z, Shen H Y, Fu J Z, *et al.* Automated detection of defects with low semantic information in X-ray images

-
- based on deep learning[J]. Journal of Intelligent Manufacturing, 2021, **32**(1): 141 - 156. DOI: 10.1007/s10845-020-01566-1.
- 14 Sohan M, Sai Ram T, Rami Reddy C V. A review on YOLOv8 and its advancements[M]//Data Intelligence and Cognitive Informatics. Singapore: Springer Nature Singapore, 2024: 529 - 545. DOI: 10.1007/978-981-99-7962-2_39.
- 15 Ding B D, Zhang H M, Huang Z H, *et al.* Data enhanced YOLOv8s algorithm for X-ray weld defect detection[J]. Nondestructive Testing and Evaluation, 2024: 1 - 24. DOI: 10.1080/10589759.2024.2421941.
- 16 Wang G, Chen Y F, An P, *et al.* UAV-YOLOv8: a small-object-detection model based on improved YOLOv8 for UAV aerial photography scenarios[J]. Sensors, 2023, **23** (16): 7190. DOI: 10.3390/s23167190.