

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

张小刚, 俞东宝, 汤慧, 朱永利

(中核北方核燃料元件有限公司, 内蒙古 包头 014035)

摘要: 为了提高深度学习在 X 射线燃料棒端塞缺陷检测中的准确性, 实现更高精度的无损检测, 本文基于 YOLOX 的目标检测模型, 针对该场景下目标缺陷尺寸极小的特点, 对网络结构和损失函数进行了相应的改进, 并在工业数据集上进行了验证。结果表明, 该算法方案在保持较高识别速度的同时, 识别精度获得了明显的提升, 达到生产检测要求。该研究方法为今后燃料棒端塞焊缝 X 射线数字检测图像的高精度自动分析评价打下了坚实的基础。

关键词: 燃料棒; 焊缝探伤; 缺陷检测; 深度学习; X 射线

中图分类号: TL99; TP181

文献标志码: A

文章编号: 1000-6931(2024)08-1767-10

doi: [10.7538/yzk.2023.youxian.0706](https://doi.org/10.7538/yzk.2023.youxian.0706)

Detection Method of X-ray Fuel Rod End Plug Defect Based on Deep Learning

ZHANG Xiaogang, YU Dongbao, TANG Hui, ZHU Yongli

(China North Nuclear Fuel Co., Ltd., Baotou 014035, China)

Abstract: Amidst the global expansion of nuclear power generation, ensuring the integrity of nuclear fuel rods is crucial for the safe operation of nuclear power plants. As a vital component of fuel rods, the detection of defects in the end plugs is a key step in ensuring nuclear safety. Traditional manual detection methods are not only time-consuming and inefficient but also susceptible to subjective influences. To address these issues, this study proposed an automatic detection method for defects in fuel rod end plugs based on deep learning X-ray imaging, aiming to enhance the accuracy and efficiency of detection. The research began by collecting a large number of X-ray images of fuel rod end plugs and preprocessing these images, including single-rod segmentation and extraction of effective evaluation areas, to optimize image quality. Subsequently, an improved YOLOX model was adopted as the core detection algorithm, with adjustments made to the network structure and loss function to address the characteristics of small target defects. The introduction of a coordinate attention module enables the model to more accurately locate and identify tiny defects. Additionally, the CIoU loss function was employed in place of the traditional IoU loss function to improve the model's localization precision for small targets. During the model training phase, data augmentation techniques such as Mosaic, Copy and Paste, and Mixup were implemented to enhance the model's adaptability to new scenarios. The

experimental results demonstrate that the improved model excels in the task of end plug defect detection, with significant enhancements in detection accuracy and speed compared to traditional methods and unimproved deep learning models. Tests on industrial datasets show a notable increase in the model's mean average precision (mAP) while maintaining a fast detection speed, meeting the requirements of actual production. The model also performs well in detecting various types of defects, including accurate identification of porosity, swelling, incomplete welding, tungsten inclusion, and plug abnormalities. In summary, this study successfully develops an efficient and accurate automatic detection method for defects in fuel rod end plugs based on deep learning X-ray imaging. This method not only improves the level of detection automation but also provides strong technical support for the safe management and maintenance of fuel rods. Future research will continue to explore the potential for model optimization to better adapt to a wider range of industrial applications.

Key words: fuel rod; weld inspection; defect detection; deep learning; X-ray

燃料棒端塞焊缝在焊接过程中可能形成夹钨、气孔、气胀、未焊透等缺陷,焊缝质量是燃料棒生产制造中的一道关键控制点,根据HAF0409核燃料棒的采购设计和制造中的质量保证,设计规范要求对核燃料棒焊缝进行100%检查。针对燃料棒缺陷检测,目前业内主要采用X射线检测^[1]、超声波检测^[2]、涡流检测^[3]等。其中,X射线检测是主要的熔化焊端塞焊缝检测方法^[4],目前业内主要根据工程师的经验来判断检测结果,但在检测效率和检测标准上会受到工程师主观性的制约。

随着计算机和人工智能技术的发展,焊缝缺陷检测从人工主观评估逐渐转向利用机器视觉算法的方式实现自动检测。Tian等^[5]使用图像数据融合进行自动缺陷检测的图像处理方法,该方法综合了边缘提取、波形轮廓分析、动态阈值分割和焊缝区域提取等多种方法。Wang等^[6]提出了一种基于深度学习的方法,通过采用预训练的基于RetinaNet的卷积神经网络来自动识别X射线图像中的多种焊接缺陷类型和位置。针对X射线焊缝中存在较多微小缺陷,且卷积过程中较容易丢失微小缺陷的特征信息,Liu等^[7]应用注意机制的AF-RCNN目标检测框架,将残差网络(ResNet)与特征金字塔网络(FPN)相结合作为骨干,应用高效卷积注意模块(ECAM)自适应地对感兴趣的目标特征进行细节处理,以提高锚点定位精度。王睿等^[8]基于YOLO-M网络引入轻量级的倒残差结构,采用多尺度预测机制,减少了网络计算量,极大降低了检测任务的硬件需求,提高了检测

速度。

目前,基于深度学习的图像处理技术正在迅速发展。然而,燃料棒端塞缺陷的种类多样性和形态多变性对基于深度学习的自动化检测技术提出了更高要求。卷积神经网络已被广泛应用于图像处理、图像分割和目标检测等复杂任务^[9]。目前主流的检测模型分为双阶段模型和单阶段模型。双阶段模型包括SSD^[10-11]、Faster-RCNN^[12-13]等,而在目标检测中,单阶段检测模型如YOLO算法等^[14-16]仍然是最常用的。单阶段检测模型具有更快的检测速度和更高的精确率,在实际工业中应用更为广泛。本文以YOLOX算法为基础,针对小目标缺陷,增加协同注意力模块,并采用优化后的损失函数,在不增加模型参数量的同时,保持较好的端塞焊缝缺陷识别速度和精度。

1 数据集收集与预处理

1.1 数据获取

本次实验数据均为数字DR(digital radiography)图像,非公共数据集,合计1 000根燃料棒图像。样品为CF3型号燃料棒端塞,在制备过程中,通过调整焊接工艺参数制成一批缺陷样品。经人工审核后,样品缺陷包含气孔、气胀、未焊透、夹钨和堵孔异常等。调整X射线照射参数,设置焦距为900 mm,管电压为260 kV,窗宽、窗位分别调整至50 000、25 000左右(根据实际情况微调),对端塞焊缝采用双壁双影透照并进行120°×3次透照,得到1组3张原始图像,端塞图像如图1所示。



图 1 燃料棒上端塞 X 射线原始图像

Fig. 1 Original X-ray image of upper end plug of fuel rod

1.2 单棒分割

在实际检测中,为了提高检测效率,一般在生产线上会对 5~10 根燃料棒同时进行 X 射线照射。而单棒分割环节是将单根燃料棒图像提取出来,以方便进行后续分析处理。

1) 高斯二值化

高斯二值化是 1 种局部二值化方法,也叫自适应阈值法。通过设定 1 个区域大小,比较这个点与区域里面像素点的平均值(或其他特征)的大小关系以确定这个像素点的情况。高斯二值化后燃料棒图像如图 2 所示,使用高斯二值化后,燃料棒图像轮廓较清晰,干扰小。

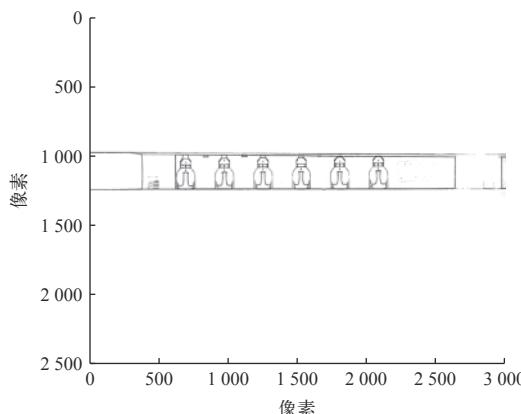


图 2 高斯二值化后的燃料棒图像

Fig. 2 Image of fuel rod after Gaussian binarization

2) 轮廓提取

原始图像像素为 3008×2512 , 有大量空白区域。对高斯二值化后的图像进行轮廓提取, 获取图像真实的紧凑区域, 如图 3 所示。

3) 垂直投影

对轮廓提取后的图像进行垂直投影, 统计水平方向上的像素分布, 如图 4 所示。为了减少噪

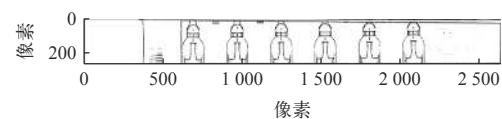


图 3 轮廓提取后裁切的图像

Fig. 3 Image cropped after extraction

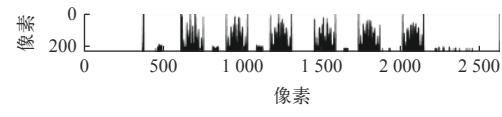


图 4 垂直投影后的图像

Fig. 4 Image after vertical projection

声干扰,对统计的结果进行了阈值截断,即垂直方向上像素个数小于阈值的位置,其值置为 0, 表示此处于棒与棒分隔区域。

在此基础上进行单棒分割,分割后的图像如图 5 所示。



图 5 单棒分割效果展示

Fig. 5 Single-rod segmentation demonstration

1.3 评定区提取

本文为上、下端塞各准备了 2 张标准图像, 将单棒分割后的图像与标准图像进行模板匹配, 以提取出有效评定区。模板匹配的目的为: 1) 检查图像是否符合标准, 是否有缺失, 有无燃料棒未完全插入情况等; 2) 精准匹配出待评定区域, 调高缺陷检出效率。使用归一化相关系数匹配方法对燃料棒图像进行模板匹配, 计算方法如下:

$$T'(x', y') = T(x', y') - 1/(w \cdot h) \cdot \sum_{x'', y''} T(x'', y'') \quad (1)$$

$$I'(x+x', y+y') = I(x+x', y+y') - 1/(w \cdot h) \cdot \sum_{x'', y''} I(x+x'', y+y'') \quad (2)$$

$$R(x, y) = \frac{\sum_{x', y'} (T'(x', y') \cdot I'(x+x', y+y'))}{\sqrt{\sum_{x', y'} T'(x', y')^2 \cdot \sum_{x', y'} I'(x+x', y+y')^2}} \quad (3)$$

式中: T 为模板图像; I 为待匹配图像; w 为模板图像宽度; h 为模板图像高度; (x, y) 为待匹配图像的坐标; (x', y') 为像素在模板中的坐标; (x'', y'') 为模板中遍历的像素坐标; T' 为归一化后的模板图像; I' 为归一化后的待匹配图像; $R(x, y)$ 为像素在

(x, y) 处待匹配图像与模板图像的匹配系数。

具体计算方法为在要检测的图像上,从左到右,从上到下遍历这一幅图像,计算模板与重叠子图像的像素匹配度,如果匹配的程度越大,说明相同的可能性越大。如果待匹配图像为 $W \times H$,模板图像为 $w \times h$,则结果矩阵大小为 $(W-w+1) \times (H-h+1)$ 。最终的相关性数值被缩放到 $[-1, 1]$ 范围,匹配结果根据返回的匹配矩阵取最大值,大于匹配阈值,则认为图像与模板图像匹配。如图 6 所示,左侧为模板图像,右侧为待匹配对象,模板匹配度约为 0.92。

1.4 数据增强

针对小目标检测,本文采用了多种数据增强方法,包括 Mosaic、Copy and Paste 和 Mixup。Mosaic 数据增强是一种新的数据增强方法,其将 4 个输入图像拼接在一起形成 1 个大图像,如图 7a 所示。该方法可以有效提升训练集图像数量,提高模型的泛化能力。Copy and Paste 数据增强的具

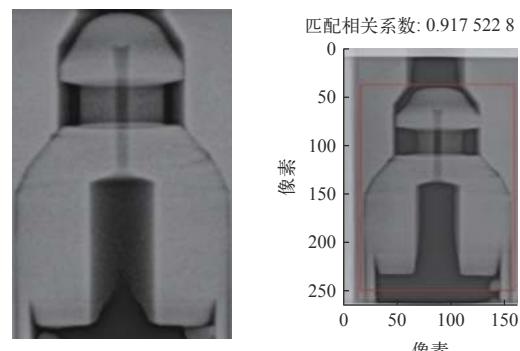
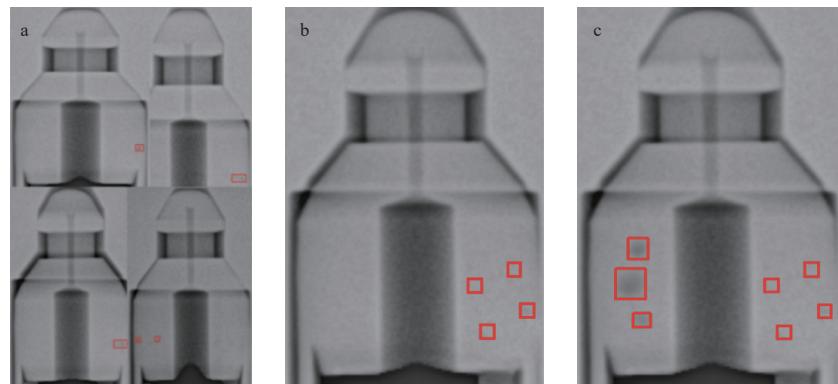


图 6 通过模板匹配方式提取评定区
Fig. 6 Extract evaluation area through template matching

体做法为先将所有小目标抠出来备用,然后在图像上复制这些小目标,要求两两之间不重合,并且复制的位置不能超出图像评定区边界,如图 7b 所示。原始的 Mixup 方法是将两张图像进行加权融合,合并为 1 张图像,如图 7c 所示。这里根据燃料棒缺陷图像的特点,结合 Copy and Paste,将不同图像的缺陷部分经过缩放,加权融合为 1 张图像。



a—Mosaic; b—Copy and Paste; c—Mixup

图 7 数据增强后的图像

Fig. 7 Image after data augmentation

2 模型设计

为了平衡算法的检测精度和速度,本文提出了一种以 YOLOX 为基础网络框架的改进型燃料棒 X 射线缺陷目标检测算法。通过修改原始网络结构、优化模型训练损失函数,改善算法对 X 射线图像复杂信息的提取能力,在工业生产线的燃料棒缺陷目标检测数据集上,结果验证了所提算法的检测性能。

2.1 YOLOX 框架与原理

模型整体架构如图 8 所示,主要由输入端、

模型 Backbone 网络、模型 Neck 网络以及模型 Prediction 4 部分组成。

YOLOX 的 Backbone 部分采用了类似于 ResNet 的模型结构。与 DarkNet Backbone 不同, YOLOX 中的 Backbone 使用轻量级的模块来减少计算复杂度和参数数量。这种设计使得 YOLOX 在保持较高性能的同时,具有更低的计算复杂度和更少的参数。YOLOX 的 Neck 部分采用了特征金字塔网络(feature pyramid network, FPN)结构,用于结合不同尺度的特征图。这种设计有助于捕

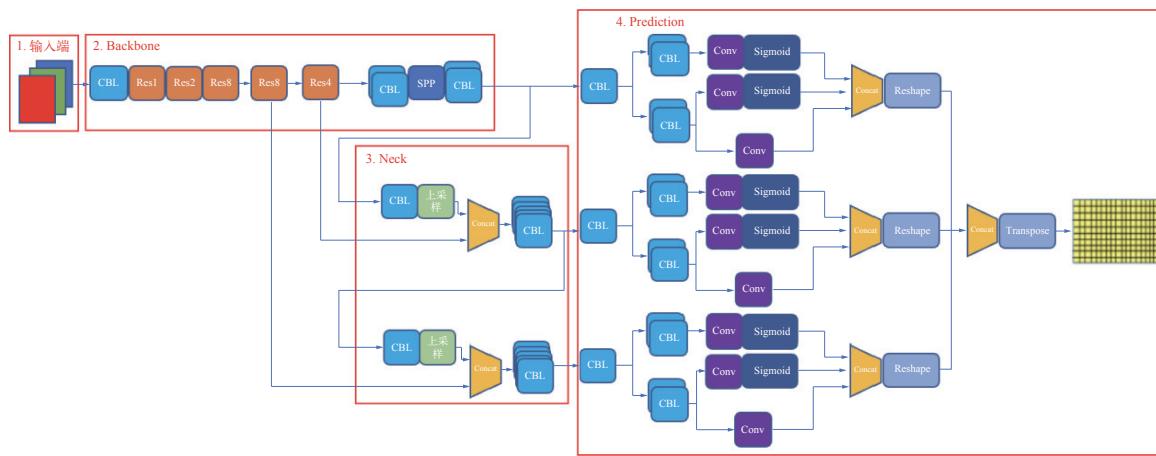


图 8 YOLOX 模型框架

Fig. 8 YOLOX model framework

捉多尺度的目标,提高模型对不同大小目标的检测能力。同时,YOLOX还采用了自上而下的路径增强策略,通过跨层连接来进一步提高特征的表达能力。YOLOX的Prediction部分负责在特征图上进行预测。与其他YOLO系列模型相似,YOLOX的Prediction部分采用了单阶段目标检测的设计。

在每个特征图位置,模型预测1个目标的类别、边界框和目标对象的置信度。主要从Decoupled Head、Anchor Free、标签分配和Loss计算4个方面进行了改进优化。

原来的YOLO系列都采用了1个耦合在一起的检测头,同时进行分类、回归的检测任务(参数更小)。YOLOX在结构上采用了解耦头(Decoupled Head)设计(从RetinaNet后就被广泛应用),将特

征平行分成两路卷积特征,同时为了降低参数量提前进行了降维处理,如图9所示,其好处在于:在检测过程中分类需要的特征和回归所需要的特征往往不同,所以在Decoupled Head中进行解耦处理后,特征的学习过程会变得更加简单,而且回归分支里还添加了IoU分支。

YOLOX的预测头采用了Anchor Free的设计,消除了传统基于Anchor的方法中手动选择Anchor尺寸的需求。这有助于简化模型,同时提高泛化性能。YOLOX采用了Focal Loss作为损失函数,用于解决类别不均衡问题。Focal Loss在训练过程中对难以分类的样本给予更大的权重,从而使模型更关注这些样本。这有助于提高模型在各类别间的检测性能。

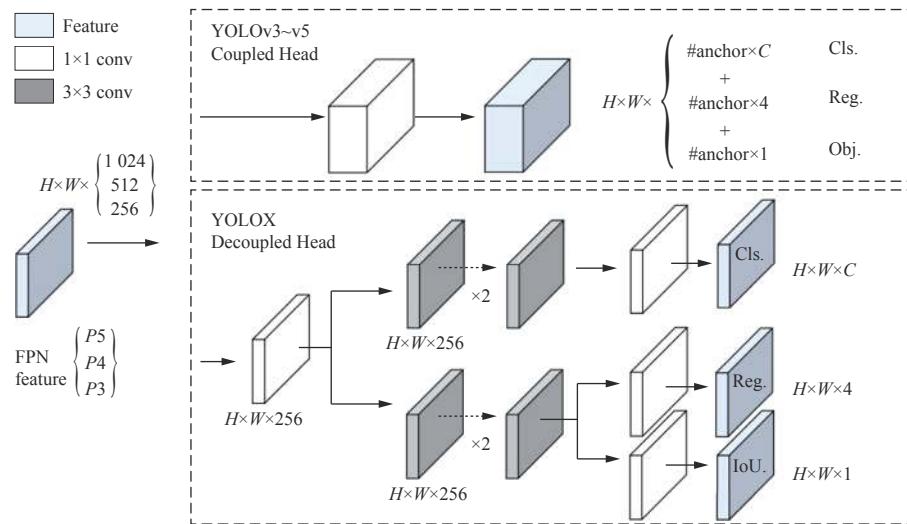


图 9 YOLOX 的解耦头图解

Fig. 9 Decoupled Head diagram of YOLOX

2.2 算法改进

针对 X 射线燃料棒端塞缺陷检测场景, 算法主要从模型网络结构和损失函数两个方面进行了针对性的改进优化。

1) 网络修改

改进的空间多尺度网络如图 10 所示, 将骨干网络最后 3 层特征层, 分别经过协同注意力模块 (CA) 后, 生成对应的 Neck 层网络。对于多尺度预测, 参考 FPN 的思想, 采用直接添加的方式构建额外预测特征图 N4。即选取充分融合上下文信息的 N3 层, 通过卷积操作和上采样后, 扩大特征图尺寸, 并与包含大量细节信息的 F4 层拼接 (Concat), 经过基础构建块 CSP2_1 充分混合特征, 输出特征图 N4。特征图 N4 由于其感受野更小, 包含了更多细节信息, 因而更适合小目标检测任务。

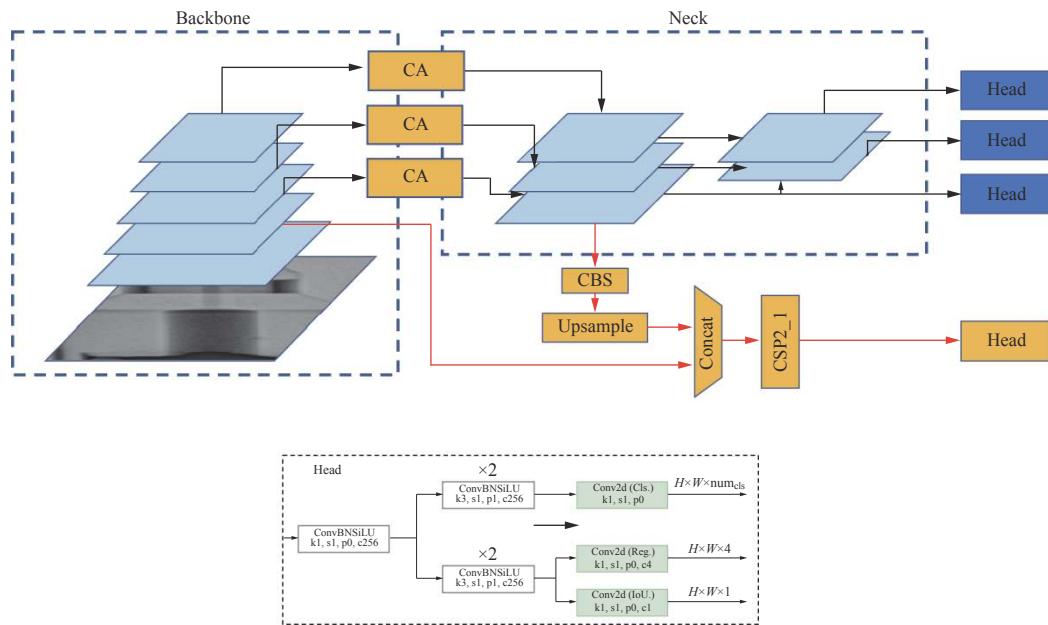


图 10 改进后的 YOLOX 模型框架结构
Fig. 10 Improved structure of YOLOX model framework

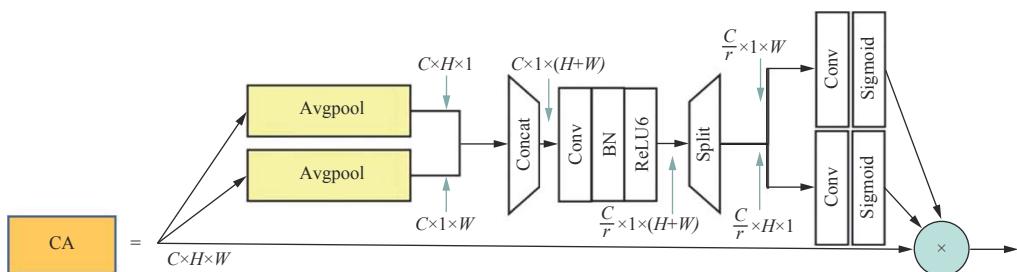


图 11 CA 网络结构
Fig. 11 Coordinate attention module structure

CA 用于发掘现有数据的关联性。其将位置信息嵌入信道注意力中, 这不仅建模了数据通道间的关系, 而且捕获了位置信息间的依赖关系, 突出重要特征。此外, 该模块计算量和参数量较小, 带来的计算负担可以忽略不计, 且支持热插拔, 即插即用, 非常适合在轻量级算法中使用。CA 结构如图 11 所示。

给定输入特征图:

$$\mathbf{I} \in \mathbb{R}^{C \times H \times W} \quad (4)$$

式中, \mathbf{I} 为输入特征图, 是尺寸为 C (通道数) \times H (高度) \times W (宽度) 的实数矩阵。首先, 通过两个沿着不同空间维度的平均池化层(池化核大小分别为 $(1, W)$ 和 $(H, 1)$), 得到两个聚合了不同维度信息的特征向量, 然后通过维度转换来拼接这两个维度的特征向量, 再通过 1×1 的卷积进行通道扩充, 充分学习二者捕获的位置和关联信息, 准确

地突显感兴趣的区域。这样不仅捕获了当前空间方向的依赖关系,而且保留了另一个空间方向精确的位置信息。最后得到的特征向量大小为:

$$\text{shape}(\text{output}) = \frac{C}{r} \times 1 \times (H + W) \quad (5)$$

式中: $\text{shape}(\text{output})$ 为输出特征向量的形状尺寸; r 为控制通道数缩小的比例, 可降低计算量, 减少推断时间。紧接着, 沿着空间维度再次分割为两个独立的特征向量, 并通过 1×1 卷积和激活函数变换为通道数量相同的特征图。最后, 与输入特征图逐元素相乘。

2) 损失函数改进

采用 IoU 损失函数作为边界框回归损失时, 如果出现重叠, 将不能为边界框提供准确的移动方向, 这会导致在小目标检测问题上定位性能不佳。CIoU 损失函数是 IoU 损失函数改良版, 引入了中心位置和长宽比误差计算, 一方面解决了与目标框的重叠问题, 另一方面对重叠区域、中心点距离和长宽比方面的考量, 使得损失函数收敛速度更快。因此, 本文采用 CIoU 损失函数作为边界框回归损失

$$L_{\text{CIoU}} = 1 - \text{IoU} + \frac{\rho^2(b, b^{\text{gt}})}{c^2} + \alpha v \quad (6)$$

其中:

$$\alpha = \frac{v}{1 - \text{IoU} + v} \quad (7)$$

$$\rho = \frac{4}{\pi^2} \left(\arctan \frac{w^{\text{gt}}}{h^{\text{gt}}} - \arctan \frac{w}{h} \right)^2 \quad (8)$$

式中: IoU 为预测框和真实框之间的交并比; ρ 为两点欧式距离; b 和 b^{gt} 分别为预测框和真实框的中心点; c 为预测框和真实框最小外接矩形的对角线距离; α 为协调比例参数; v 为用于衡量框的长宽比一致性的参数; w 、 h 和 w^{gt} 、 h^{gt} 分别为预测框的宽度、高度和真实框的宽度、高度。

更进一步, 综合各 IoU 损失函数, 综合修改损失函数为:

$$L_{\beta-\text{CIoU}} = 1 - \text{IoU}^\beta + \frac{\rho^{2\beta}(b, b^{\text{gt}})}{c^{2\beta}} + (\alpha v)^\beta \quad (9)$$

式中, β 为可调节的指数超参。经实验表明, $\beta=3$ 时效果较好。

3 实验及结果分析

3.1 训练模型

本次端塞焊缝缺陷 X 射线图像数据集共

1 000 张, 焊缝缺陷包括气孔、气胀、未焊透、夹钨以及堵孔异常 5 种内部缺陷。采用 Mosaic、Mixup、Copy and Paste 进行数据增强后, 数据集扩充到 3 854 张, 扩充后的数据集具有多样性。数据集根据缺陷类型进行分层采样, 训练集、验证集、测试集占比约为 6 : 2 : 2, 即训练集 2 312 张, 验证集 771 张, 测试集 771 张。

在 Linux 系统下, 基于 Pytorch 深度学习框架并结合 Python 进行实验, 硬件设施如表 1 所列。

表 1 硬件设施

Table 1 Hardware configuration

硬件	配置
CPU	I7-13700
GPU	NVIDIA V100×4
内存, GB	32

训练时输入图片大小为 640 pixel×640 pixel, 批次大小(batch size)设置为 64。迭代轮次(epoch, 训练完所有样本为 1 轮)为 700, 设置了 early stopping 策略(如果 50 个 epoch 模型效果没有提升即停止)。为了方便比较, 均使用 Adam 优化器对模型参数进行优化。在最后 15 个 epoch 时关闭数据增强。在训练过程中采用了随机尺度调整, 以适应不同大小的目标。这种策略可以提高模型对输入图像尺度变化的鲁棒性。图 12 展示了算法训练和验证过程中各损失量随训练轮次变化收敛的情况。其中, 定位损失用于衡量模型预测的边界框(包括位置和大小)与真实边界框之间的差异, 目标损失用于评估模型预测的边界框内是否真的有目标存在, 分类损失衡量的是模型对于已定位目标的缺陷类别预测准确性。

3.2 结果

1) 评价指标

本文采用目标检测领域常用的评价指标 AP(平均精度)和 mAP(mean average precision, 平均精度均值, 即各类别 AP 的平均值)来评价模型精度, 用 FPS(每秒能处理图片的张数)来评价算法速度。

定义: TP(true positive), 预测值和真实值一样, 预测值为正样本(真实值为正样本); TN(true neg-

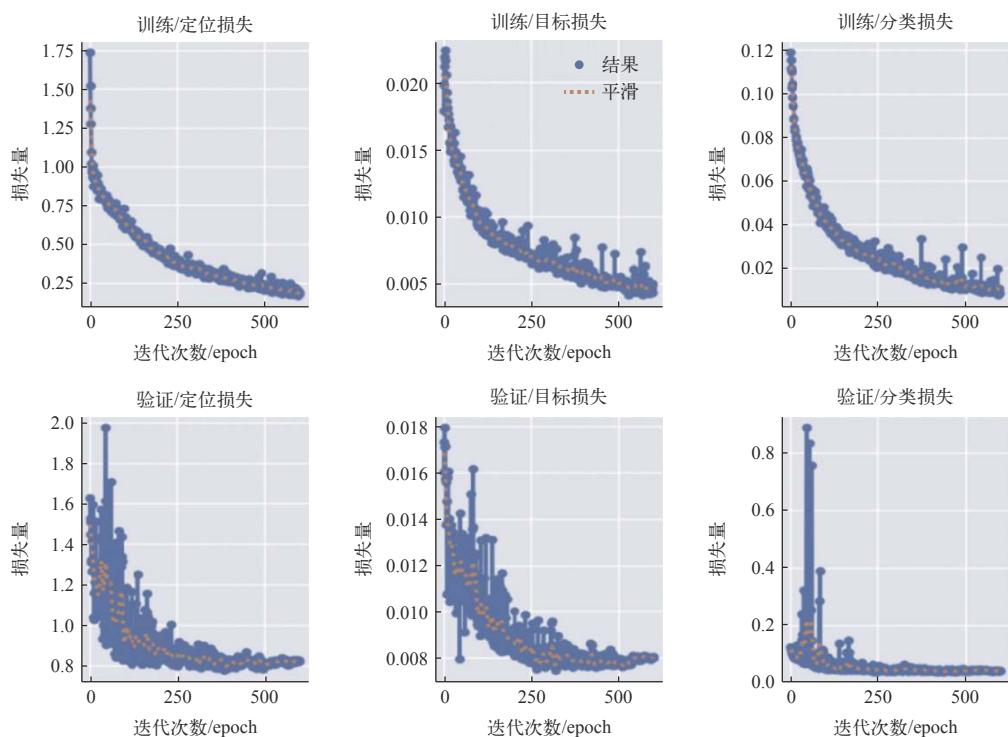


图 12 训练过程损失量的变化

Fig. 12 Variation of loss value during training process

ative), 预测值和真实值一样, 预测值为负样本(真实值为负样本); FP(false positive), 预测值和真实值不一样, 预测值为正样本(真实值为负样本); FN(false negative), 预测值和真实值不一样, 预测值为负样本(真实值为正样本)。则精度定义为 $\text{precision} = \text{TP} / (\text{TP} + \text{FP})$, 召回率定义为 $\text{recall} = \text{TP} / (\text{TP} + \text{FN})$ 。PR 曲线, 即 precision 和 recall 的曲线, 当取不同阈值时可以得到不同的 P 、 R 值, 画成图像就是 PR 曲线。AP 为 precision-recall 曲线下面的面积, AP 值越高, 代表模型的性能越好。

在目标检测中, 1 个模型通常会检测很多种物体, 那么每一类都能绘制 1 个 PR 曲线, 进而计算出 1 个 AP 值。那么多个类别的 AP 值的平均值就是 mAP。

2) 结果对比

表 2 为不同模型的 AP、mAP、检测速度的对比, 可以看出, 改进后的 YOLOX 模型与原始模型相比, 在检测速度增加不明显的情况下, AP 和 mAP 均有提升, 这说明在网络中增加了 CA 以及采用更新的损失函数后, 有效提升了检测精度水平。

表 2 端塞焊缝缺陷识别效果对比(测试集)

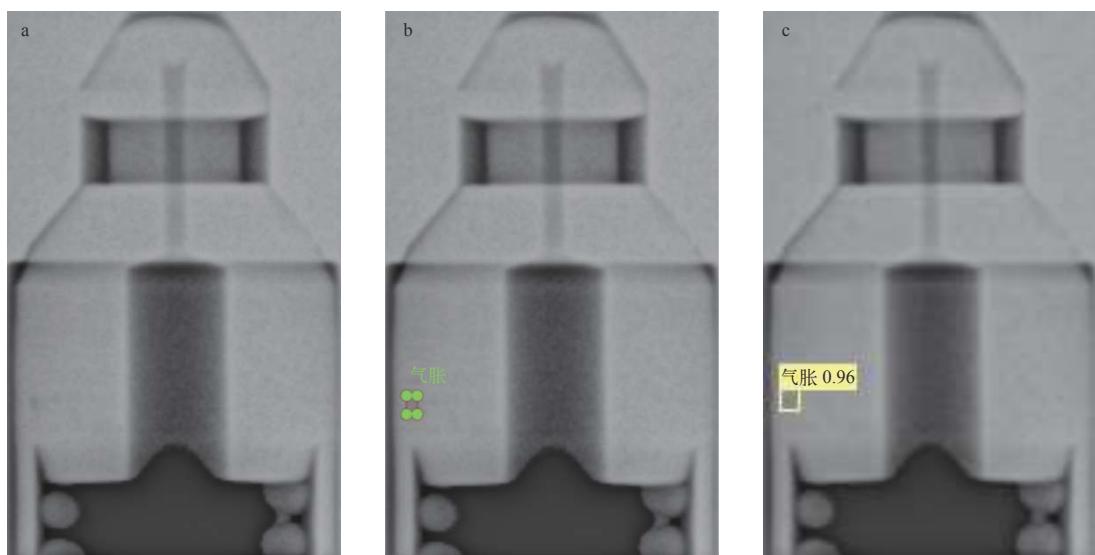
Table 2 Comparison of defect recognition result for end plug weld (test dataset)

模型	AP					mAP 0.5 : 0.95	检测速度 (GPU)/FPS	模型参数量/M
	气孔	气胀	未焊透	夹钨	堵孔异常			
改进后的 YOLOX	0.89	0.80	0.88	0.93	0.86	0.87	55.56	63.9
YOLOX	0.86	0.76	0.85	0.89	0.83	0.84	57.80	63.7
YOLOv5	0.85	0.75	0.83	0.87	0.82	0.82	62.50	46.5
Faster-RCNN(ResNet-50 FPN)	0.87	0.79	0.86	0.90	0.84	0.85	11.17	42

检测结果样例如图 13 所示, 可以看出图像输入改进的 YOLOX 模型后, 对于缺陷预测效果有较高的准确度。

4 结论

本文针对 X 射线燃料棒端塞缺陷检测问题, 基于其缺陷目标极小的特点, 在 YOLOX 目标检



a——原始图像; b——标注后图像; c——预测结果图像

图 13 检测结果样例

Fig. 13 Example of detection result

测算法基础上,改进了深度学习网络结构和优化损失函数,并与常见深度学习目标检测算法进行对比。在实际工业生产数据集上验证结果表明,本文所提出的算法方案,在保持较高识别速度的同时,识别精度获得了明显提升,达到生产需要,证明了其有效性。该研究方法为今后燃料棒端塞焊缝X射线数字检测图像的高精度自动分析评价打下了坚实的基础。

参考文献:

- [1] 汤琪,王华才,梁政强.反应堆乏燃料棒的X射线数字成像检测工艺及其应用[J].无损检测,2020,42(10):14-17.
TANG Qi, WANG Huacai, LIANG Zhengqiang. Application of X-ray digital imaging technology to the examination of irradiated fuel rods from nuclear reactor[J]. Nondestructive Testing Technology, 2020, 42(10): 14-17(in Chinese).
- [2] 殷振国,王华才,刘歆粤,等.燃料棒破损超声检测技术研究[J].原子能科学技术,2015,49(2): 324-329.
YIN Zhengguo, WANG Huacai, LIU Xinyue, et al. Research on ultrasonic detection technique of fuel rod failure[J]. Atomic Energy Science and Technology, 2015, 49(2): 324-329(in Chinese).
- [3] 许俊龙,马官兵,王贤彬,等.核反应堆燃料组件的无损检测和修复[J].无损检测,2014,36(11): 38-41.
XU Junlong, MA Guanbing, WANG Xianbin, et al. Non-destructive inspection and repair of fuel assembly in nuclear reactor[J]. Nondestructive Testing Technology, 2014, 36(11): 38-41(in Chinese).
- [4] 李文兴.核电站燃料棒焊缝X射线检测质量监督[J].无损检测,2001,23(2): 74-77.
LI Wenxing. Quality supervision of X-ray testing of the welds in nuclear power plant fuel rods[J]. Nondestructive Testing, 2001, 23(2): 74-77(in Chinese).
- [5] TIAN Y, DU D, CAI G, et al. Automatic defect detection in X-ray images using image data fusion[J]. Tsinghua Science and Technology, 2006, 11: (6): 720-724.
- [6] WANG Y, SHI F, TONG X. A welding defect identification approach in X-ray images based on deep convolutional neural networks[C]//International Conference on Intelligent Computing. Cham: Springer, 2019: 53-64.
- [7] LIU W, SHAN S, CHEN H, et al. X-ray weld defect detection based on AF-RCNN[J]. Welding in the World, 2022, 66(6): 1165-1177.
- [8] 王睿,胡云雷,刘卫朋,等.基于边缘AI的焊缝X射线图像缺陷检测[J].焊接学报,2022,43(1): 79-84.
WANG Rui, HU Yunlei, LIU Weipeng, et al. Defect detection of weld X-ray image based on edge AI[J]. Transactions of the China Welding Institution, 2022, 43(1): 79-84(in Chinese).
- [9] 周飞燕,金林鹏,董军.卷积神经网络研究综述[J].计算机学报,2017,40(6): 1229-1251.
ZHOU Feiyan, JIN Linpeng, DONG Jun. Review of convolutional neural network[J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251(in Chinese).
- [10] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single

- shot multibox detector[C]//Computer Vision-ECCV 2016: 14th European Conference. Amsterdam: Springer International Publishing, 2016: 21-37.
- [11] LI Y, DONG H, LI H, et al. Multi-block SSD based on small object detection for UAV railway scene surveillance[J]. *Chinese Journal of Aeronautics*, 2020, 33(6): 1747-1755.
- [12] 唐茂俊, 黄海松, 张松松, 等. 改进的 Faster-RCNN 在焊缝缺陷检测中的应用[J]. 组合机床与自动化加工技术, 2021(12): 83-86.
- TANG Maojun, HUANG Haisong, ZHANG Songsong, et al. Application of improved Faster-RCNN in weld defect detection[J]. *Modular Machine Tool & Automatic Manufacturing Technique*, 2021(12): 83-86(in Chinese).
- [13] JIANG D, LI G, TAN C, et al. Semantic segmentation for multiscale target based on object recognition using the improved Faster-RCNN model[J]. *Future Generation Computer Systems*, 2021, 123: 94-104.
- [14] 石振华, 陈杰. 改进 Yolo V3 算法在工件缺陷检测中的应用[J]. *机械设计与制造*, 2021(4): 62-65.
- SHI Zhenhua, CHEN Jie. Research on the detection of workpiece surface defects based on Yolo V3[J]. *Machinery Design & Manufacture*, 2021(4): 62-65(in Chinese).
- [15] 来文豪, 周孟然, 胡峰, 等. 基于多光谱成像和改进 YOLO v4 的煤矸石检测[J]. *光学学报*, 2020, 40(24): 2411001.
- LAI Wenhao, ZHOU Mengran, HU Feng, et al. Coal gangue detection based on multi-spectral imaging and improved YOLO v4[J]. *Acta Optica Sinica*, 2020, 40(24): 2411001(in Chinese).
- [16] 程松, 杨洪刚, 徐学谦, 等. 基于 YOLO v5 的改进轻量型 X 射线铝合金焊缝缺陷检测算法[J]. *中国激光*, 2022, 49(21): 2104005.
- CHENG Song, YANG Honggang, XU Xueqian, et al. Improved lightweight X-ray aluminum alloy weld defects detection algorithm based on YOLO v5[J]. *Chinese Journal of Lasers*, 2022, 49(21): 2104005(in Chinese).