

DOI:10.19651/j.cnki.emt.2313297

# 基于改进 Faster RCNN 的射线图像焊缝 缺陷检测方法<sup>\*</sup>

罗仁泽<sup>1,2</sup> 唐祥<sup>1</sup> 余泓<sup>2</sup> 李华督<sup>2</sup>

(1.西南石油大学计算机科学学院 成都 610500; 2.西南石油大学电气信息学院 成都 610500)

**摘要:**针对 X 射线图像中小目标缺陷检测和多尺寸缺陷检测的问题,提出一种基于改进 Faster RCNN 的焊缝缺陷检测算法。首先,该算法采用 ResNet50、特征金字塔网络作为 Faster RCNN 检测网络的主干网络,达到在多个特征图上检测不同尺寸缺陷的目的;然后在主干网络前增加背景减去网络层,来降低图像背景对小目标缺陷的干扰;接着利用三支路区域推荐网络层细化原始区域推荐网络层中候选框的预测任务,从而减少候选框数量、优化检测速度;最后对网络中卷积层的数量进行微调,增强网络特征提取能力。实验结果表明,改进网络的均值平均精度和每张图像检测速度分别为 83.09%、20.8 ms,相比改进前的网络,预设的锚框增加了 10 779 个,检测速度仅仅降低了 3.1 ms,均值平均精度提高了 19.43%。改进网络在保证检测速度的基础上,有效提高了对小目标缺陷和多尺寸缺陷的检测效果。

**关键词:** 焊缝缺陷;深度学习;目标检测;Faster RCNN

**中图分类号:** TP391 **文献标识码:** A **国家标准学科分类代码:** 520.20

## Weld defect detection method of ray image based on improved Faster RCNN

Luo Renze<sup>1,2</sup> Tang Xiang<sup>1</sup> Yu Hong<sup>2</sup> Li Huadu<sup>2</sup>

(1. School of Computer Science, Southwest Petroleum University, Chengdu 610500, China; 2. School of Electrical Engineering and Information, Southwest Petroleum University, Chengdu 610500, China)

**Abstract:** Aiming at the issue of small target defect detection and multi-size defect detection in X-ray images, a weld defect detection algorithm based on improved Faster RCNN is proposed. Firstly, the algorithm utilizes ResNet50 and feature pyramid network as the backbone network of Faster RCNN for detecting defects of different sizes on multiple feature maps. Then, the background subtraction layer is added before the backbone network to reduce the interference of the image background on the small target defects. Then, the three-branch region proposal network layer refine the predictions of candidate boxes in the original region proposal network layer, thereby reducing the number of candidate boxes and optimizing the detection speed. Finally, the number of convolutional layers in the network is fine-tuned to enhance the network's feature extraction ability. The experimental results show that the improved network has a mean average precision of 83.09% and a single image detection speed of 20.8 ms. Compared to the network before improvement, the preset anchor boxes are increased by 10 779, and the mean average precision is increased by 19.43%, while the detection speed is only decreased by 3.1 ms. The improved network effectively improves the detection effect of small target defects and multi-size defects while maintaining detection speed.

**Keywords:** weld defect; deep learning; object detection; Faster RCNN

## 0 引言

在工业生产中,焊接技术作为长输管道的主要连接方式,具有重要应用价值。然而以现在的焊接水平,焊缝依然会出现圆形缺陷、条形缺陷、裂纹、未熔合、咬边、内凹等缺

陷<sup>[1]</sup>。因此,焊缝缺陷检测对确保长输管道的安全性很重要。目前,人工检测仍然是缺陷检测的常用方法,然而该方法检测效率低下、准确度受限于检测人员的专业性。于是,研究人员开始结合机器学习算法在 X 射线焊缝图像上进行焊缝缺陷自动检测的研究。

收稿日期:2023-04-07

\* 基金项目:四川省科技计划项目(2019CXRC0027)资助

Duan 等<sup>[2]</sup>检测缺陷时首先利用背景差分法得到潜在缺陷区域,再利用级联 AdaBoost 判断潜在区域的真实性和缺陷类型。张小琳等<sup>[3]</sup>利用背景估计和多方向多级梯度来抵消背景对缺陷检测的影响,从而提升缺陷检测效果。然而这类传统目标检测方法难以得到精确的缺陷位置,与之相比,利用 Faster RCNN<sup>[4]</sup>和 YOLOv3<sup>[5]</sup>等深度学习算法检测缺陷更受关注。郭文明等<sup>[6]</sup>设计了一个基于 Faster RCNN 的焊接缺陷检测系统,对缺陷检测进行了简单尝试;韦若禹等<sup>[7]</sup>选择 YOLOv3 的两个预测分支来检测缺陷。然而,X 射线焊缝图像存在缺陷尺寸较小、不同类型缺陷尺寸差异大的问题,比如在  $224 \times 224$  的图像中,圆形缺陷的面积占比百分之一左右;内凹缺陷的面积为圆形缺陷的十倍左右,这限制了模型的检测效果。因此,人们围绕小缺陷目标检测、多尺寸缺陷目标检测的问题做了大量研究。针对小缺陷目标检测问题,人们对模型进行改进。Chen 等<sup>[8]</sup>结合 Res2Net 残差模块和带加权特征的特征金字塔网络(feature pyramid network, FPN)模块改进 Faster RCNN 网络,提高模型对小缺陷的检测能力。Liu 等<sup>[9]</sup>提出 AF-RCNN 网络检测焊缝缺陷,该算法将 ResNet 与 FPN 作为 Faster RCNN 的主干网络,结合高效卷积注意力模块和 CIOU 损失函数,提高 Faster RCNN 对小缺陷的检测能力。针对多尺寸缺陷问题,人们对模型进行改进。陈海永等<sup>[10]</sup>利用基于 FPN 的 Faster RCNN 检测缺陷,其在 FPN 中引入自下而上的通道增强各层特征图的缺陷信息、提高检测效果。朱安康等<sup>[11]</sup>针对缺陷尺寸不均匀造成检测效果低的问题,在 Faster RCNN 网络模型中加入可变形卷积提高检测准确率。Ji 等<sup>[12]</sup>结合 FPN 和 SPAM 注意力机制增强 Faster RCNN 对不同大小缺陷的检测能力。除了模型精度的优化,研究人员也对模型速度进行了优化。唐茂俊等<sup>[13]</sup>利用解耦分类细化结构提高模型的检测速度。李衍照等<sup>[14]</sup>利用 GhostNet 轻量级结构替代 YOLOv5 主干网络中的残差模块,减少网络的计算量和参数量从而提高网络检测速度。上述研究围绕缺陷检测作了大量工作,显然如何提升小尺寸缺陷的检测精度、如何降低缺陷尺寸差异对检测效果的影响以及如何提高检测速度受到广泛关注。

因此,根据上述研究情况,本文改进 Faster RCNN 网络来进行缺陷检测。该算法通过背景减去网络层降低背景干扰,增强小尺寸缺陷的检测效果;采用 ResNet50 和 FPN 提取出不同尺寸的特征图,使模型能检测不同大小的缺陷;利用三支路区域推荐网络层优化检测速度。

## 1 方法与流程

本文算法主要分为图像预处理、改进 Faster RCNN 目标检测网络和后处理 3 个部分。该算法流程为:焊缝图像经过预处理后利用改进 Faster RCNN 网络模型得到一定数量的预测边框,每个预测边框都含有模型预测出的缺陷

位置和缺陷种类两部分信息,这些预测边框经过后处理的筛选得到最终的预测结果。以下对上述涉及的相关方法进行介绍。

图像预处理切割原始 X 射线焊缝图像到  $224 \times 224$  大小,并且利用灰度变换和滤波处理来增强图像对比度、平滑图像噪声。操作过程为:首先利用固定大小的滑动窗口对原始图像中焊缝区域进行裁剪,得到  $224 \times 224$  大小的图像数据集;然后利用灰度变换将图像灰度值拉伸到  $0 \sim 255$  灰度级范围;最后对图像进行  $3 \times 3$  大小滤波核的中值滤波。以圆形缺陷图像和裂纹缺陷图像为例,图像增强和去噪结果如图 1。图中第 1 列为裁剪后的图像,第 2 列为灰度范围拉伸到  $0 \sim 255$  范围的图像,第 3 列为滤波后的图像,第 1 行为含有圆形缺陷的图像,第 2 行为含有裂纹缺陷的图像。

改进 Faster RCNN 目标检测网络在第 2 节进行介绍。

后处理去除检测网络输出的不合格预测边框。处理过程为:首先去除分类标签为 0(类型为非缺陷)的预测边框;然后去除左上角坐标、右下角坐标超过图像边界的预测边框;最后剩余的预测边框按分类出的缺陷种类进行划分,同一种类的预测边框按照分类评分降序排序,去除评分低、但是又与评分更高预测边框的交并比超过 50% 的预测边框,剩余的预测边框作为最终的预测结果。

## 2 改进的 Faster RCNN 目标检测网络

相比原始 Faster RCNN 网络,本文网络包括背景减去网络层、特征提取网络层、三支路区域推荐网络层、兴趣区域池化层、分类与位置回归层 5 个部分。其中,背景减去网络层模拟图像背景,降低背景噪声对缺陷检测的影响;特征提取层能输出多层特征图,使后续网络层能选择不同尺寸的缺陷特征;三支路区域推荐网络层利用独立的支路参数关联不同的候选框信息,提高候选框的预测效果;兴趣区域池化层具有更多的卷积层,能进一步增强候选框内的缺陷特征。整体结构如图 2 所示。

### 2.1 背景减去网络层

在焊缝图像中,缺陷的面积比背景小得多。即使内凹缺陷属于较大类型的缺陷,其在  $224 \times 224$  的图像中也仅仅占比  $1/10$  左右。因此,模型对缺陷进行检测时更容易受到背景的影响。本文设计背景减去网络层来模拟图像背景,通过输入矩阵与模拟背景相减达到降低背景影响的作用。该网络结构如图 3,由大尺寸均值池化、 $1 \times 1$  卷积和跳跃连接组成。该结构首先利用大尺寸均值池化拟合图像背景,得到初始背景;再通过卷积为初始背景增加可优化的参数,使初始背景能随着网络训练进行自适应变换,得到模拟背景;最后利用输入图像减去模拟背景,得到网络层的输出结果。其中,输出结果的计算方式如式(1);卷积对初始背景进行变换的计算方式如式(2),其参数能通过网络训练不断更新,使模拟背景逐渐向更优的趋势靠近。

$$H(c, i, j) = f(c, i, j) - B(c, i, j) \quad (1)$$




图 1 图像增强与去噪结果

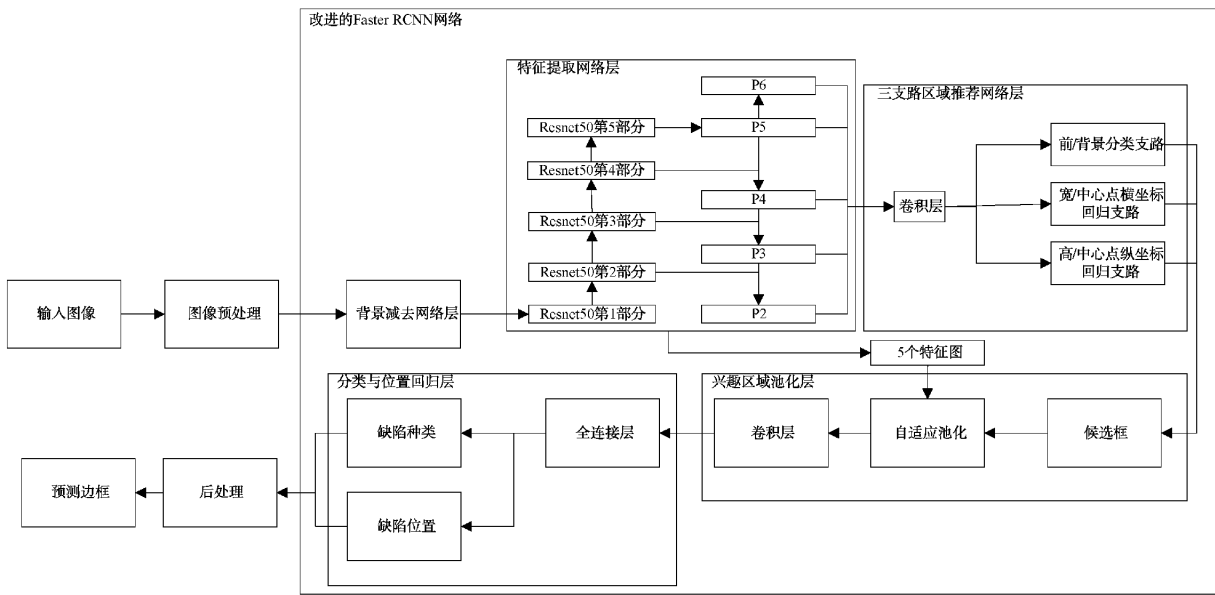


图 2 改进 Faster RCNN 检测网络整体结构图

在式(1)中,  $H(c, i, j)$  表示第  $c$  通道、第  $i$  行、第  $j$  列的网络输出值,  $f(c, i, j)$  表示第  $c$  通道、第  $i$  行、第  $j$  列的网络输入值,  $B(c, i, j)$  表示第  $c$  通道、第  $i$  行、第  $j$  列的模拟背景值。

$$B = wb + bs \tag{2}$$

在式(2)中,  $w$  为权重参数,  $b$  为初始背景,  $bs$  为偏移量。

### 2.2 特征提取网络层

特征提取层由 ResNet50<sup>[15]</sup>、FPN<sup>[16]</sup> 组成。特征提取网络层利用 ResNet50 进行图像特征提取,它具有比 VGG16 更深层次的结构,能提高模型对图像中缺陷特征的提取能力。FPN 能利用多层的特征图进行缺陷检测,提

升模型检测各种大小缺陷的准确率,在缺陷检测任务中,不同类型的缺陷具有不同的大小。以实验数据集为例,样本中圆形缺陷的尺寸较小,其面积占比 1% 左右;但是内凹缺陷的尺寸较大,其面积占比 1/10 左右。顶层的特征图更倾向内凹缺陷的预测,但是顶层特征图的下采样次数多,使圆形缺陷的位置信息丢失,不利于进行检测。加入 FPN 模块能有效利用网络低层次特征图,这部分特征图的下采样次数少,特征图较大,具有更多的细节信息,让低层次特征图负责小缺陷的预测,能增强对小缺陷的检测能力。模型中的 FPN 结构从 ResNet50 的第 2 部分开始对特征图进行自顶向下的融合,得到 P2、P3、P4、P5、P6 5 层特征图,分别对应网络输入图像的 4、8、16、32、64 倍下采样的特征图。




图 3 背景减去网络结构图

### 2.3 三支路区域推荐网络层

三支路区域推荐网络包括前/背景分类支路、宽/中心点横坐标回归支路、高/中心点纵坐标回归支路 3 个支路,其双回归结构降低了候选框位置预测相关参数的关联程度,使候选框的位置信息能得到相对独立的预测,提高候选框的预测效果。原始的区域推荐网络层中含有前/背景

分类、边框位置回归两个分支,其回归分支负责预测候选框的位置信息,并且表示为基于锚框的偏移量,包括中心点横坐标的偏移量、中心点纵坐标的偏移量、高的偏移量以及宽的偏移量。但是,根据实际的偏移计算方式,横坐标的偏移量只与锚框的中心点横坐标和宽相关,宽的偏移量只与锚框的宽相关,纵坐标的偏移量只与锚框的中心点纵坐标和高相关,高的偏移量只与锚框的高相关。因此,三支路区域推荐网络层细分了原始区域推荐网络层的预测任务,具有两个边框位置回归分支,一个分支预测横坐标和宽的偏移量,另一个分支预测纵坐标和高的偏移量,使偏移量的预测分支既具有独立的待优化参数,又具有共享的待优化参数,结构如图 4。在该结构中,首先利用  $3 \times 3$  卷积对特征提取网络层输出的特征图进行特征融合,然后传入前/背景分类支路和两条回归支路得到分类得分和区域的位置建议。其中, $3 \times 3$  卷积的融合结果传入回归支路后,为减少参数量,将该融合矩阵按通道拆分为等通道的两个特征矩阵,分别传入两条回归分支,利用两层  $1 \times 1$  卷积对偏移进行预测。该结构降低了原始区域推荐网络层中分类支路和回归支路的参数相关程度,3 个支路都共享  $3 \times 3$  卷积的参数,但是共享参数对分类支路的影响更大,同时两个回归支路增加了独立的参数,对各自的结果进行调整。




图 4 三支路区域推荐网络层结构图

### 2.4 卷积层数量的调整

由于 FPN 结构利用多层特征图进行预测,低层次特征图的抽象能力存在不足,因此,增加兴趣区域池化层后的卷积层数量,使网络能对候选框提取更深层

次的特征,结构如图 5。该结构由  $1 \times 1$  卷积、批量标准化(batch normalization, BN)、ReLU(rectified linear unit)激活函数、 $3 \times 3$  卷积组成,并且通过残差结构进行连接。




图 5 ROI 层后的卷积结构图

## 3 实验结果及分析

### 3.1 实验数据及设置

本文采集了 412 张 X 射线管道焊缝图像作为实验数

据集,该数据集中图像尺寸为  $2048 \times 2560$ ,包括圆形缺陷、条形缺陷、未熔合缺陷、内凹缺陷、咬边缺陷、裂纹缺陷 6 种缺陷类型。本文对数据集中图像进行裁剪,得到  $224 \times 224$  固定大小的缺陷图像,并且利用 180 度旋转、水平翻转



和垂直翻转三种数据增强方法扩大数据集数量,得到 4 800 张训练集图像和 300 张测试集图像。

在本文网络中,特征提取网络层的 5 层特征图(P2、P3、P4、P5、P6)各自对应 3 种锚框的预测,包括 1 种面积和 3 种高宽比的组合。锚框的尺寸利用 k-mean 聚类算法进行获取,得到 5 层特征图对应的锚框大小如下:P2 层对应  $8 \times 49$ 、 $13 \times 30$ 、 $19 \times 20$  的锚框,P3 层对应  $16 \times 98$ 、 $26 \times 60$ 、 $38 \times 41$  的锚框,P4 层对应  $26 \times 159$ 、 $42 \times 98$ 、 $63 \times 66$  的锚框,P5 层对应  $38 \times 236$ 、 $62 \times 145$ 、 $93 \times 98$  的锚框,P6 层对应  $51 \times 311$ 、 $83 \times 191$ 、 $122 \times 129$  的锚框。

本文在兴趣区域池化层利用公式  $k = \lfloor k_0 + \log_2(\sqrt{wh}/224) \rfloor$  进行特征图的选择。由于 P6 层特征图的大小仅为  $4 \times 4$ ,如果自适应到  $7 \times 7$  大小容易造成特征失真,因此,特征图的初始层  $k_0$  设置在 P5 层,然后根据兴趣区域池化层得到的候选框的大小( $w, h$ )计算出对应的特征图。例如,如果候选框的大小为  $224 \times 224$ ,选择在 P5 层进行特征提取;如果候选框的大小为  $112 \times 112$ ,选择在 P4 层进行特征提取。

本文利用 PyTorch 下的预训练参数初始化本文网络相同结构的参数,其中,在预训练网络的分类与位置回归层中,全连接层的输入通道为 12 544,为了保证能正确加载预训练参数,本文将兴趣区域池化层后的卷积层输出通道设为 784。

本文使用的硬件配置如下:显卡 GTX1660、显存 6 G、处理器 I5-9400F、内存 16 G。

### 3.2 评价指标

实验衡量模型效果的评价指标包括准确率(*accuracy*)、召回率(*recall*)、平均精度(*AP*)和均值平均精度(*mAP*),相关公式如式(3)~(7)所示。

$$accuracy = \frac{TP}{TP + FP + TN + FN} \quad (3)$$

$$recall = \frac{TP}{TP + FN} \quad (4)$$

$$precision = \frac{TP}{TP + FP} \quad (5)$$

在式(3)~(5)中, $TP$  为预测是正例、实际也是正例的样本; $FP$  为预测是正例、实际是负例的样本; $TN$  为预测是负例、实际也是负例的样本; $FN$  为预测是负例、实际是正例的样本; $precision$  表示精确率。

$$AP = \int_0^1 P(R) dR \quad (6)$$

在式(6)中, $P(R)$  表示精确率相对召回率的曲线,实际中由于无法得到连续曲线, $AP$  值取一定数量的等间距召回率区间下的最大精确率的平均值。

$$mAP = \frac{AP}{N} \quad (7)$$

在式(7)中, $N$  表示类别数量。

### 3.3 背景减去实验结果

背景减去网络层的参数能随着网络训练不断更新,使

该层抵消背景干扰的效果变得更好,输出结果变得更加平滑,如图 6 和 7 所示。图 6 和 7 为某张含有裂纹缺陷的图像在背景减去网络层训练前后的模拟背景干扰和输出结果。背景减去网络层涉及的图像矩阵为 3 通道的,为了方便可视化,图 6 和 7 中的图像为转化后的单通道灰度图像。在图 6 和 7 中,第 1 列是背景减去网络层的输入,第 1 行是含有裂纹缺陷的图像;第 2 行是第 1 行对应图像中方框区域的三维图( $X$  轴表示行、 $Y$  轴表示列、 $Z$  轴表示灰度值);图中的方框区域是缺陷区域。图 6 的第 2 列是网络训练之前,卷积层使用默认参数的模拟背景,第 3 列是网络训练之前,卷积层使用默认参数的输出,即输入图像减去背景的结果。图 7 的第 2 列是网络训练完成之后的模拟背景,第 3 列是网络训练完成之后的输出。比较两幅图中的模拟背景,图 7 中模拟背景的方框区域更突出,相比图 6 更侧重缺陷区域;比较两幅图中输出结果的三维图,图 7 的模块输出比图 6 的输出更加光滑。

图 6 和 7 表明,背景减去网络层的参数能随着网络训练逐渐趋于更优化,网络训练后,背景减去网络层对背景干扰的抵消效果更好。

### 3.4 模型检测速度对比

为了验证三支路区域推荐网络优化速度的效果,实验将基于 VGG16 的原始 Faster RCNN、本文算法、去掉三支路区域推荐网络层的本文算法进行比较,结果如表 1 所示。在表 1 中,候选框是能输入到兴趣区域池化层的预测框,即区域推荐层根据回归结果对锚框进行调整后得到的分类为正例(含有缺陷的前景)、边框之间交并比不超过 0.5、并且未超过图像边界的预测框。由于候选框直接参与模型后续的检测任务,模型的速度与候选框的数量有直接关系,同时,候选框是通过锚框得到的,候选框数量受到锚框数量的控制。一般情况下,网络会设置更多的锚框,使其能覆盖的目标尺寸范围更大,其准确率也就更高;但是锚框越多容易产生更多候选框,使检测速度降低。因此,在设置大量锚框的基础上尽可能降低候选框数量,有利于平衡检测精度和检测速度。

在实验中,原始 Faster RCNN 网络每张图像有 1 764 个锚框,本文算法由于采用 FPN 结构,每张图像有 12 543 个锚框。由表 1 可知,加入三支路区域推荐网络后,12 543 个锚框中平均有 7.52 个能作为候选框输入到下一层网络,相比加入该结构前减少了 46.17 个候选框,能使单张图像的处理时间减少 6.4 ms。相比原始 Faster RCNN 网络,本文网络有更复杂的网络结构,锚框数量也增加了 10 779 个,但是从表 1 可以看出经过三支路区域推荐网络层的优化,检测速度仅仅增加了 3.1 ms。

实验表明,加入三支路区域推荐网络层后能有效减少候选框的数量,优化模型的检测速度。

### 3.5 模型检测效果对比

为了验证本文算法检测缺陷的效果,实验利用 3.1 节




图 6 训练前的背景减去结果

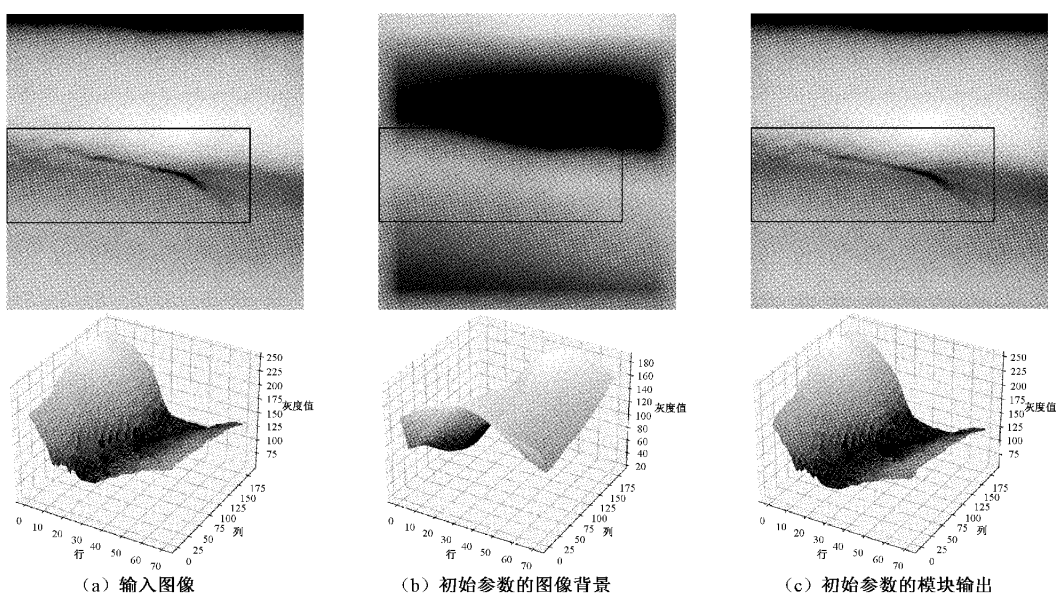


图 7 训练后的背景减去结果

表 1 RPN 层输出候选框数量和模型检测速度

算法	候选框个数	检测速度(张/s)
Faster RCNN(VGG16)	10.48	0.017 7
本文算法(无三支路)	53.69	0.027 2
本文算法	7.52	0.020 8

所述的训练集对原始 Faster RCNN、基于 ResNet50 和 FPN 的 Faster RCNN、本文算法、YOLOv3 进行训练,训练后的模型在测试集上进行检测效果对比。在训练过程中,选择 Adam 优化器更新参数,初始更新步长为 0.000 1,训练轮数为 100 轮。图 8 为训练过程中不同模型损失值和评

价指标曲线图,其可视化了 4 种模型训练时损失值和评价指标的变化趋势。在图 8 中,4 种模型在训练集上的损失值随着训练次数的增加逐级降低,最终趋于稳定,同时模型在测试集上的检测效果也逐渐增加到稳定的范围。

本文选择训练集损失值最小时对应的模型在测试集上比较检测效果,实验结果如表 2、表 3 所示。表 2 为不同模型各类缺陷的 AP 值,表 3 为不同模型的准确率、检出率(召回率)以及 mAP 值。同时,为了结合焊缝缺陷尺寸来分析结果,表 4 统计了测试集中 6 类缺陷的平均高度、平均宽度以及平均面积比例。

表 2 反映了模型检测各类缺陷的具体效果。从表 2 和 4 可以看出,尺寸较大的缺陷更容易检测,且尺寸差异较大

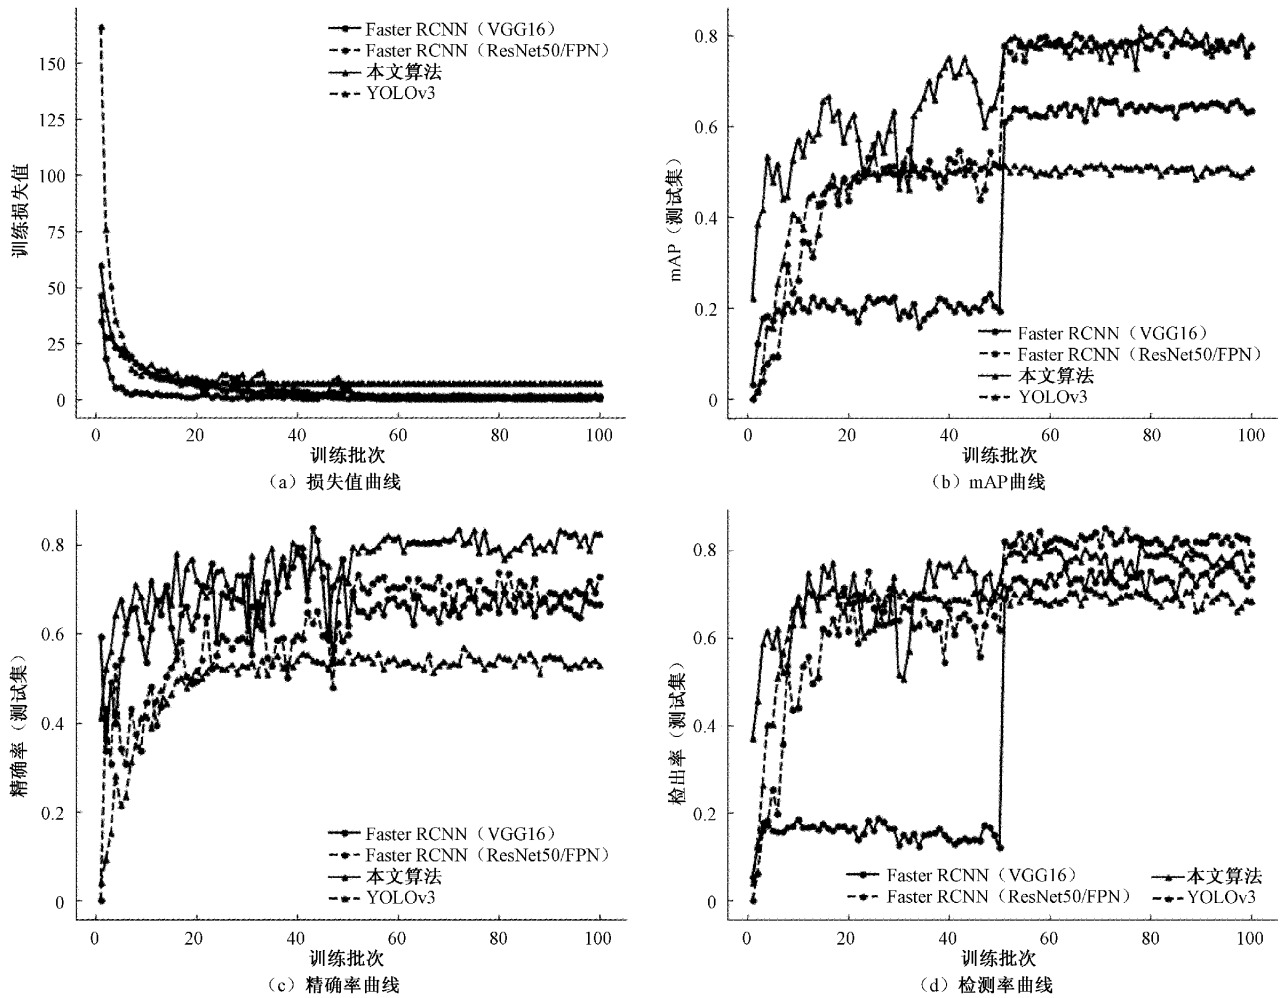


图 8 损失和评价指标曲线图

表 2 不同模型下各类缺陷的 AP 值

算法	AP					
	圆缺	条缺	未熔合	内凹	咬边	裂纹
YOLOv3	0.288 0	0.386 8	0.440 8	0.822 9	0.653 2	0.261 2
原始的 Faster RCNN	0.238 9	0.595 9	0.701 9	0.972 2	0.693 9	0.616 7
Faster RCNN(ResNet50/FPN)	0.492 3	0.707 1	0.797 2	0.946 4	0.955 0	0.754 6
本文算法	0.511 5	0.750 1	0.827 3	0.983 0	0.995 2	0.918 5

表 3 不同模型的准确率和检测率

算法	YOLOv3	原始的 Faster RCNN (ResNet50/FPN)	Faster RCNN	本文 算法
准确率	0.498 5	0.771 1	0.716 4	0.764 7
检出率	0.643 2	0.646 8	0.803 1	0.826 0
mAP	0.475 5	0.636 6	0.775 4	0.830 9

时检测结果会存在明显差异。例如，表 4 中内凹的尺寸明显大于其它缺陷，其对应表 2 中的 AP 值在各个模型中均较大；相反，圆缺、条缺对应表 2 中的 AP 值均较小。

表 2 表明，本文算法能提高各类缺陷的检测精度。由于原始的 Faster RCNN 网络是基于 VGG16 的，网络层数较少，并且仅仅在顶层特征图进行后续的预测，使得网络对小尺寸缺陷的检测效果较差，从表 2 可以看出，原始 Faster RCNN 网络对于圆缺这类小尺寸缺陷的精度不足内凹这种大尺寸缺陷的 1/4。在加入更深层的 ResNet50 和 FPN 后，Faster RCNN 能在低层特征图预测小缺陷，使得模型对小缺陷的精度得到显著提升，如表 2 第 3 行的数据表明，相比原始 Faster RCNN，它对圆形缺陷的检测精度提高了 1 倍。在此基础上，本文利用背景减去网络层降



表4 不同缺陷的平均面积比例

缺陷类型	圆缺	条缺	未熔合	内凹	咬边	裂纹
高度	17.317 8	16.555 6	14.769 2	50.811 3	22.560 0	11.804 9
宽度	20.093 5	50.214 0	95.487 2	150.000 0	81.000 0	94.170 7
面积比例/%	0.945 3	1.927 2	2.916 1	15.722 9	3.701 8	2.938 2

低了背景对缺陷的干扰,进一步提高模型的检测精度,如相比表2第3行的数据,表2第四行中圆形缺陷的检测精度提高1.92%、条形缺陷的检测精度提高4.3%、未熔合的检测精度提高3.01%等。

表3反映了模型的整体检测效果,表示模型从图像中检测出缺陷的能力以及检测的正确性。从表3可以看出,本文算法对缺陷检测的整体效果更好,缺陷的检出率为82.6%、准确率为76.47%,mAP为83.09%。

实验结果表明,改进模型能更好地检测出焊缝图像中的小尺寸缺陷,对不同尺寸的缺陷也具有更好的适应性,能更有效地检测出焊缝图像中的缺陷。

### 3.6 模型检测结果

检测网络输出的预测边框经过后处理选择后,得到图像最终的检测结果。图9为不同模型对6类缺陷的检测结果图,图中利用方框的形式标记出缺陷,每行的缺陷类型从上到下依次为圆形缺陷(round)、条形缺陷(bar)、未熔合缺陷(not fused)、内凹缺陷(concave)、咬边缺陷(undercut)、裂纹缺陷(crack)。从图9可以看出,四种模型对内凹、咬边等这类较大的缺陷检测效果都较好,但是面对圆缺、条缺这类较小的缺陷时,容易出现漏检、多检的情况,相较而言,本文网络对这类缺陷的检测效果更好。




图9 缺陷检测的结果图

## 4 结 论

针对焊缝缺陷检测中小缺陷、多尺寸缺陷导致的检测

精度低的问题,本文对Faster RCNN网络模型进行改进。首先为了使模型能适应不同尺寸的缺陷,采用FPN结构在不同大小的特征图上预测不同大小的缺陷,提高了缺陷



检测的准确率。然后为了降低背景对小缺陷的干扰,增加了一个背景减去网络层,抵消背景干扰、进一步提高检测效果。最后为了优化检测速度,通过三支路区域推荐网络层预测候选区域,降低候选框数量,提升检测速度。经过实验验证,改进后网络的 mAP 为 83.09%、每张图像检测时间为 20.8 ms,具有较高的检测精度和检测速度,能有效实现 X 射线焊缝图像中缺陷的自动化检测。后续工作将继续探讨如何进一步提高圆形缺陷的检测效果,研究具有更高小尺寸缺陷检测精度的检测方法。

### 参考文献

- [1] 石油天然气钢质管道无损检测: SY/T 4109—2020[S]. 北京:国家能源局, 2020: 232.
- [2] DUAN F, YIN S F, SONG P P, et al. Automatic welding defect detection of X-Ray images by using cascade AdaBoost with penalty term [J]. IEEE Access, 2019, 7: 125929-125938.
- [3] 张小琳, 刘祎, 白贇汎, 等. 基于背景估计的焊缝缺陷检测[J]. 电子测量技术, 2022, 45(14): 116-122.
- [4] 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, 2017, 39(6): 1137-1149.
- [5] REDMON J, FARHADI A. YOLOv3: An incremental improvement[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2017: 6517-6525.
- [6] 郭文明, 刘凯, 渠慧帆. 基于 Faster R-CNN 模型 X 射线图像的焊接缺陷检测[J]. 北京邮电大学学报, 2019, 42(6): 20-28.
- [7] 韦若禹, 李舒婷, 吴松荣, 等. 基于改进 YOLOv3 算法的轨道扣件缺陷检测[J]. 铁道标准设计, 2020, 64(12): 30-36.
- [8] CHEN Y B, WANG J R, WANG G T. Intelligent welding defect detection model on improved R-CNN[J]. IETE Journal of Research, 2022: 1-10.
- [9] LIU W P, SHAN S Q, CHEN H Y, et al. X-ray weld defect detection based on AF-RCNN[J]. Welding in the World, 2022, 66(6): 1165-1177.
- [10] 陈海永, 赵鹏, 闫皓炜. 融合注意力的多尺度 Faster RCNN 的裂纹检测[J]. 光电工程, 2021, 48(1): 64-74.
- [11] 朱安康, 王尧芬, 张振宇. 基于深度学习的铝材表面缺陷检测系统设计[J]. 传感器与微系统, 2022, 41(8): 96-99, 103.
- [12] JI C, WANG H B, LI H H. Defects detection in weld joints based on visual attention and deep learning[J]. NDT and E International, 2023, 133: 102764.
- [13] 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.
- [14] 李衍照, 于镭, 田金文. 基于改进 YOLOv5 的金属焊缝缺陷检测[J]. 电子测量技术, 2022, 45(19): 70-75.
- [15] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[J]. 2016 IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [16] LIN T, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[J]. 30th IEEE Conference on Computer Vision and Pattern Recognition, 2017: 936-944.

### 作者简介

罗仁泽, 教授, 博士生导师, 主要研究方向为深度学习新算法研究等。

唐祥, 硕士研究生, 主要研究方向为目标检测。

E-mail: 2061185774@qq.com

余泓, 硕士研究生, 主要研究方向为图像分割。

李华督, 硕士研究生, 主要研究方向为图像处理。