

基于 Faster-RCNN 的船舶焊缝 X 射线缺陷图像检测技术应用

卢志鹏, 黄凯华, 刘思明, 尹嘉雯, 周昌智
(上海船舶工艺研究所, 上海 200032)

摘要: 将目标检测网络 Faster-RCNN 应用在船舶焊缝 X 射线缺陷图像检测中, 探讨了 Faster-RCNN 在 X 射线焊缝缺陷检测中的效果。针对船舶工业中的 X 射线焊缝图像, 首先采用 CLAHE 方法对焊缝 X 射线图像进行预处理, 并将焊缝中存在的气孔、裂纹、未熔合等 5 种具有典型特征的缺陷作为识别目标进行标注并对数据进行增强。在目标识别上, 采用 ResNet-50 作为主干网络来减少梯度弥散现象提高模型准确率, 并针对焊缝缺陷目标小的特点对 RPN 网络锚点参数进行改进优化, 同时引入 FPN 网络提取缺陷特征。最后与其他检测算法进行对比, 试验结果表明, 该数据集在模型上的 m_{AP} 值达到 96.33%, 可以满足 X 射线焊缝缺陷自动化辅助检测要求。

关键词: Faster-RCNN; X 射线; CLAHE; 焊缝缺陷检测

中图分类号: TG115.28; U671.84 文献标志码: A 文章编号: 1000-6656(2023)07-0036-05

Application of X-ray defect image detection technology for ship welds based on Faster-RCNN

LU Zhipeng, HUANG Kaihua, LIU Siming, YIN Jiawen, ZHOU Changzhi
(Shanghai Shipbuilding Technology Research Institute, Shanghai 200032, China)

Abstract: In this paper, the target detection network Faster-RCNN was applied to the X-ray image defect detection of ship welds, and the effect of Faster-RCNN in the X-ray weld defect detection was discussed. Aiming at the X-ray weld image in the shipbuilding industry, this paper first used the CLAHE method to preprocess the weld X-ray image, and took the five types of defects with typical characteristics such as pores, cracks, and LOF in the weld as the identification target annotated and enhanced the data. In object detection, ResNet-50 was used as the backbone network to reduce the gradient dispersion phenomenon and improve the accuracy of the model. The anchor point parameters of the RPN network were improved and optimized for the characteristics of small weld defects. At the same time, the FPN network was introduced to extract the defect features. Finally, a comparative experiment with other detection methods was carried out. The experimental results showed that the m_{AP} value of the data set on the model reached 96.33%, which can meet the requirements of automatic auxiliary detection of X-ray weld defects.

Key words: Faster-RCNN; X-ray; CLAHE; detection of weld defect

在船舶建造中, 焊接作为船舶工业的基础工艺和技术得到了十分广泛的应用。X 射线检测作为船舶建造中最常见的无损检测技术, 能够直观显示出焊接接头内部的缺陷位置和大小, 然而其自动化程

度很低, 检测仍采用人工肉眼识别的方法^[1], 检测结果受评片人员的经验影响较大, 检测效率低。因此, 为了提高船舶焊缝的检测效率, 对焊缝缺陷图像进行自动检测研究具有重要意义。

针对船舶焊缝缺陷图像进行自动检测通常采用基于深度学习卷积神经网络的目标检测算法。目标检测分为两个任务: 分类和定位^[2]。比较流行的目标检测算法可以大致分为两类, 一种是一阶段如

收稿日期: 2022-11-29
作者简介: 卢志鹏(1995—), 男, 工程师, 主要从事数字射线图像自动识别与无损检测的研究工作
通信作者: 卢志鹏, njlzp2018@163.com

YOLO(You Only Look Once)系列^[3-4]、SSD(Single Shot Multibox Detector)算法^[5]和二阶段算法如 Faster-RCNN(Faster Region-CNN)^[6]。一阶段算法采用一个卷积神经网络直接预测目标的类别与位置,优点是检测速度快,但精度略低;二阶段算法是先生成目标候选框,然后再进行分类回归,优点是检测精度高,但检测速度略慢。胡晓轩等^[7]基于 YOLO V3 网络,结合深度迁移学习方法,开发了一套焊缝表面缺陷智能识别系统。李砚峰等^[8]等引入特征金字塔、减小网络深度、引入跳跃连接卷积块和 K-means 算法等方法将深度学习网络对单个焊缝图像平均识别率提升至 94.9%。

笔者基于船舶焊缝数据集,采用限制对比度直方图均衡化(CLAHE)^[9]图像处理方法对图像进行预处理,再对原始 Faster-RCNN 网络进行优化,采

用残缺神经网络 ResNet-50 进行特征提取,引入特征金字塔网络(Feature Pyramid Networks, FPN)进行多尺度特征融合并优化锚框参数,获得了较高的识别率。

1 船舶焊缝缺陷检测模型

1.1 Faster-RCNN 网络结构

一般来说, Faster-RCNN 由以下 4 个部分组成:特征提取网络、区域生成网络(RPN)、感兴趣区域池化层(ROI-Pooling)以及分类回归。首先输入网络的图像经过特征提取网络初步提取特征值,然后 Faster-RCNN 网络使用 RPN 来提取候选框生成候选区域(Region Proposal),最后感兴趣区域池化层将不同大小的特征图统一送入全连接层进行分类和定位。Faster-RCNN 主要架构如图 1 所示。

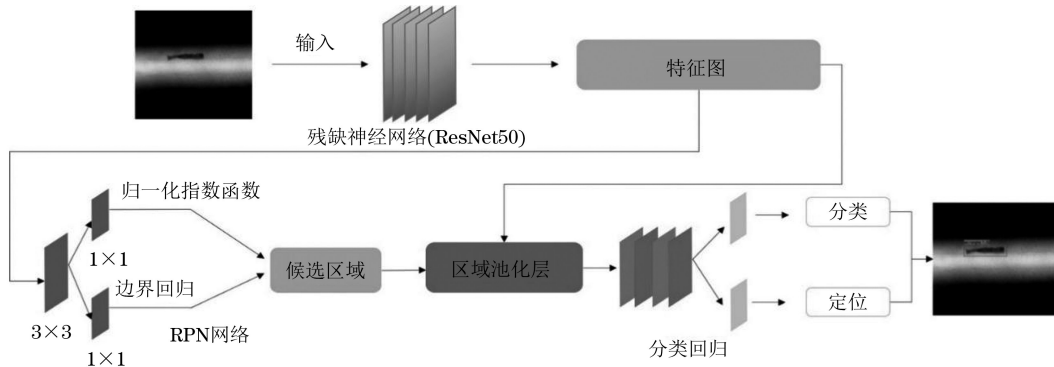


图 1 Faster-RCNN 主要架构

1.2 区域生成网络

RPN 是一个全卷积网络。首先 RPN 会采用一个滑动窗口在特征图上进行滑窗选择,每一个点会产生 k 个坐标边界框(边框, Anchor),一张 $w \times h$ 大小的特征图会产生 $w \times h \times k$ 个坐标边界框,再将每个点映射到一个低维向量。RPN 中间会进行边框分类和边框回归,边框分类是指利用 Softmax 分类器分类 Anchor 得到相对应的前景和背景,边框回归得到回归偏移量进行修正。在 RPN 的最后,将边框分类和边框回归的结果进行汇总,删除不符合条件的坐标框,根据边框分类的结果采用非极大值抑制算法去除冗余的边界框,最后根据边框回归的结果对坐标边界框进行修正,输出需要的建议区域。

RPN 的损失函数由分类交叉熵损失和回归 Smooth L_1 损失组成,整个网络的损失函数定义如下

$$L(\{p_i\}\{p_i^*\}) = \frac{1}{N_{\text{cls}}} \sum_i L_{\text{cls}}(p_i, p_i^*) + \lambda \frac{1}{N_{\text{reg}}} \sum_i p_i^* L_{\text{reg}}(t_i, t_i^*) \quad (1)$$

式中: i 为坐标边界框序号; p_i 为第 i 个坐标边界框中目标的预测概率; p_i^* 为其对应真实位置的预测值,如果坐标边界框中真实标签为正样本,则 $p_i^* = 1$,若真实标签为负样本,则 $p_i^* = 0$; N_{cls} 和 N_{reg} 为归一化常数,由锚点大小以及数量决定; λ 为平衡因子; t_i 为候选框相对于真实框预测的偏移量,即预测框 4 个坐标向量; t_i^* 为候选框相对于真实框的实际偏移量。 $L_{\text{cls}}(p_i, p_i^*)$ 为 p_i 和 p_i^* 的对数损失,包含目标与非目标两类

$$L_{\text{cls}}(p_i, p_i^*) = -\log [p_i p_i^* + (1 - p_i)(1 - p_i^*)] \quad (2)$$

L_{reg} 为回归损失, R 为 Smooth L_1 函数,分别定义为

$$L_{\text{reg}}(t_i, t_i^*) = R(t_i - t_i^*) \quad (3)$$

$$R(t_i - t_i^*) = \text{Smooth } L_1(t_i - t_i^*) = \begin{cases} 0.5(t_i - t_i^*)^2, & |t_i - t_i^*| < 1 \\ |t_i - t_i^*| - 0.5, & |t_i - t_i^*| \geq 1 \end{cases} \quad (4)$$

1.3 感兴趣区域池化层

ROI-Pooling 收到来自特征提取网络的输出特征图和区域生成网络输出的候选目标区域,将特征图与 RPN 候选框的大小相统一,将感兴趣区域映射到特征图的对应位置,再将映射区域划分为相同大小的块(数量与输出维度相同)并进行最大池化操作。因此,对于不同大小的感兴趣区域,可以得到固定大小的特征池化图,最后将特征池化图送入全连接层。

2 船舶焊缝数据与检测模型优化

2.1 数据集制作与缺陷标注

目前针对焊缝 X 射线图像的开源数据集有限,人工构建了包含常见缺陷类别的焊缝数据集。文章焊缝 X 射线数据包含 2 012 张 X 射线焊缝图像,从中选取 5 种具备典型特征的缺陷类型,分别为气孔、密集气孔、裂纹、未熔合、未焊透,按照 8:1:1 划分训练集、验证集和测试集。

根据经验丰富的工程师给出的缺陷类型结果进行数据集标注,标注软件为 LabelImg,采用 PASCAL VOC 2007 格式。PASCAL VOC 2007 数据集由三个文件夹组成,分别是 Annotations(存放每张图片对应标注的 XML 文件)、JPEGImages(存放所有图片)、ImageSets(存放符合训练集和测

试集图片的 TXT 文件)。

2.2 数据集优化

(1) 图像预处理

焊缝 X 射线图像都是灰度图,为得到较高的识别准确率,在进行模型训练之前需对图像进行灰度变换。直方图均衡化(HE)是一种常见的图像处理技术,其原理是通过图像的灰度分布直方图确定一条映射曲线,然后对图像进行灰度转化从而增强图像对比度,但图像中某一处比其他区域更亮或者更暗时,该区域的细节信息不能很好地显示。自适应直方图均衡化(AHE)通过对像素周边矩形区域进行直方图均衡化改进了局部对比度的问题,但会存在过度放大图像中相同区域的噪声的问题。

CLAHE 与普通自适应直方图均衡的不同之处在于可以进行对比度限幅。在 CLAHE 中,对于每个小区域都必须使用对比度限幅,CLAHE 主要用于克服 AHE 带来的噪声过度放大的问题。焊缝 X 图像经过 CLAHE 算法处理之后,图像局部细节更清晰、缺陷区域对比度得到提高、图像更加平滑。CLAHE 算法对噪声敏感程度小,幅度较小,因而能增强图像对比度,故文章数据集的预处理采用 CLAHE 算法。原始图像与采用 HE、AHE、CLAHE 预处理后的图像对比如图 2 所示。




图 2 原始图像与预处理后的图像对比

(2) 数据在线增强

由于数据量(只有 2 012 张图像样本)对于神经学习来说不够丰富,所以为了增强模型的泛化能力,采用了数据增强的手段。数据增强是一种提高目标检测算法鲁棒性的重要方法,主要是对图像进行平移、旋转、镜像、调整亮度的操作。文章没有采用本地增强的方法,而是在每一张焊缝图像进入神经网络训练前进行数据增强的操作,同时每一个焊缝图像增强的操作都是随机的,所以每一次训练的数据集都不同,相当于增加了数据集的数据量,即一边训练一边进行数据增强,而本地的数据集不会发生改

变,这就是数据在线增强,增强后图像样本数据可达到 4 024 张。

2.3 锚框参数优化

针对 PASCAL VOC 数据集上 20 个种类的目标大小,原始 Faster-RCNN 网络设计了 3 种形状边界框,长宽比分别为 0.5,1.0 和 2.0,锚框尺度分别为 8,16,32,每个边界框会产生 9 个矩形框。但是焊缝缺陷图像特征并不适用于该尺度,需对锚框参数进行优化:由于焊缝缺陷目标较小,故将锚框尺度分别减少为 4,8,16,设置候选框长宽比为 0.1,0.2,0.5,1,2,5。坐标边界框调整前后对比如图 3 所示。




图3 坐标边界框调整前后对比

2.4 特征金字塔网络

Faster-RCNN 对目标的预测只会基于最后一次下采样的特征图,易导致小目标特征的丢失。为解决目标检测中多尺度变化的问题,引入特征金字塔网络结构 FPN,对原始 Faster-RCNN 网络进行优化。

FPN 由三部分组成,第一部分前馈网络自底向上提取特征;第二部分自顶向下采用反池化方法得到低层特征;第三部分采用横向连接将前面两部分得到的特征图进行融合,得到多尺度特征图。Faster-RCNN 与 FPN 结合后,FPN 将每一层输出的特征图送入 RPN 网络进行预测,这样高层的语义信息与浅层的特征信息都得到了保留。

2.5 模型训练及超参数设置

采用深度残差网络 ResNet-50 作为骨干网络来提取焊缝缺陷图像的特征。由于采用“跳层连接”,随着网络的加深,ResNet-50 不仅能减缓梯度消失的速度,而且更利于识别小目标,而原始主干网络采用 Visual Geometry Group 会耗费更多计算资源且易产生梯度消失现象;模型训练 100 个训练迭代轮次,训练时冻结后 50 个训练迭代轮次以加快训练速度,同时防止训练初期权值被破坏;激活函数采用 Relu 函数以稳定收敛速度;训练批尺寸设置为 2;梯度下降算法采用自适应学习率算法 Adam;学习率初始值设为 0.001,每次更新后衰减值设为 0.000 5,候选框长宽比设置为 0.1,0.2,0.5,1,2,5。

3 试验与分析

3.1 模型评价指标

对于多分类的目标检测模型常用 m_{AP} 值作为模型的评价指标。

焊缝缺陷识别时,用 T_P 表示正值正样本; T_N 表示正值负样本; F_P 表示负值正样本; F_N 表示负值负样本;精确度为 $P = T_P / (T_P + F_P)$,表示实际正样本占有所有被检测出的正样本中的比例;召回率 $R = T_P / (T_P + F_N)$,表示被检测出的正样本占被检

测的所有目标即检测总数的比例。然后,通过绘制 Precision-Recall(精确度-召回率)曲线来计算 A_P 值(曲线下面的面积), m_{AP} 就是对所有类的 A_P 值求平均。

3.2 试验结果与分析

将胶片数据集和 DR 数据集分别在 Faster-RCNN 以及其改进网络上进行对比试验,并与其他一阶段网络结果对比。将准备好的测试集送入训练好的模型中预测,其中气孔 49 个、密集气孔 42 个、裂纹 40 个、未熔合 47 个、未焊透 40 个,5 种分类缺陷的预测结果如图 4 所示。

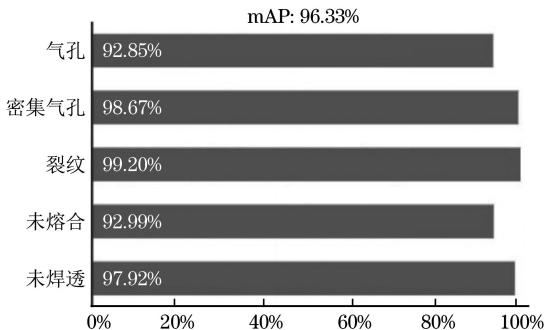


图4 各分类缺陷的识别 A_P 值

由图 4 可知,调整后的模型训练后 m_{AP} 值能达到 96.33%,其中作为焊缝缺陷中危害程度最大的裂纹 A_P 值达到 99.20%,危害程度较大的条形缺陷未熔合和未焊透的 A_P 值达到 92.99%和 97.92%,但是气孔的 A_P 值只有 92.85%,这是由于气孔为小目标缺陷,通常目标检测算法很难在小目标上得到较大的 A_P 值。实际检测中,对于极小的气孔缺陷通常可以忽略不计,模型部分焊缝缺陷图像检测结果如图 5 所示。

此外,用上述试验的数据集在其他主流一阶段目标检测网络 YOLO V3、SSD 上进行训练,使用优化后的模型与原始网络和原始数据集的训练结果进行对比,共进行了 5 次试验。分析 5 种检测方法的结果发现,改进后的 Faster-RCNN 网络训练时间最长达到 16.62 h,这是 Anchor 改进后数量变多所致,并且文章方法得到了最高的 m_{AP} 值 96.33%。对于一阶段的目标检测算法 YOLO V3、SSD,其相对二阶段算法更简单,故训练时间更短,但准确率相对 Faster-RCNN 来说更低,在检测速度上也更快,而文章方法在检测速度上最慢。在实际检测中,船厂探伤部门对焊缝缺陷的检测精度要求更高,对检测速度没有很高的需求。文章对焊缝缺陷中的夹渣并没有进行识别试验,这

是由于夹渣缺陷没有典型特征,圆形夹渣以及条形夹渣与气孔和未熔合无明显的特征区别,经验丰富的评片员对此类缺陷通常将其归类为圆形缺陷或者条形缺陷。实际工作中,只有将焊缝进行剖开才能验证缺陷的正确分类。5 种检测方法在目标检测任务上的检测结果如表 1 所示,可见,采

用 DR 数据集的 m_{AP} 值比胶片数据集的高 6.31%;用 ResNet-50 作为主干网络并改进锚点参数引入 FPN 后的模型在 DR 数据集上得到的 m_{AP} 达到 96.33%。此外与其他模型相比,改进后的 Faster-RCNN 模型 m_{AP} 值最高,故该模型可以满足 X 射线焊缝缺陷自动化辅助检测要求。




图 5 焊缝缺陷图像检测结果

表 1 5 种不同方法在目标检测任务上的结果

| 检测方法 | m_{AP} / % | 总训练时间/h | 检测速率/fps |
|------------------------------|--------------|---------|----------|
| Faster-RCNN+胶片数据集 | 88.33 | 8.32 | 15 |
| Faster-RCNN+DR 数据集 | 94.64 | 13.27 | 15 |
| 改进后 Faster-RCNN+DR 数据集(文章方法) | 96.33 | 16.62 | 10 |
| YOLO V3+DR 数据集 | 82.56 | 5.84 | 20 |
| SSD+DR 数据集 | 93.67 | 12.83 | 14 |

4 结语

- (1) 针对焊缝 X 射线图像,采用 CLAHE 方法对其进行图像预处理,训练前对数据集进行数据在线增强,解决了焊缝数据不够充分的问题。
- (2) 采用 ResNet-50 作为主干网络进行特征提取,通过特征金字塔网络 FPN 融合网络深层和浅层的特征,优化 Anchor 参数,从而提高了模型对焊缝缺陷的识别率。
- (3) 优化后的模型 m_{AP} 达到了 96.33%,与其他方法相比在 DR 数据集上取得了最高的识别率,可

满足 X 射线焊缝缺陷自动化辅助检测要求。

参考文献:

[1] 褚慧慧. 基于视觉的焊缝质量检测技术研究[D]. 哈尔滨:哈尔滨工程大学,2017.

[2] COLLOBERT R. Natural language processing from scratch[J]. Journal of Machine Learning Research, 2011(8): 2493-2537.

[3] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: unified, real-time object detection[C]// Proceedings of the IEEE conference on computer vision and pattern recognition. Las Vegas; IEEE, 2016: 779-788.

[4] REDMON J, FARHADI A. YOLO9000: better, faster, stronger [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. Hawaii; IEEE, 2017: 6517-6525.

[5] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]// Proceedings of European conference on computer vision. Cham; Springer, 2016: 21-37.

(下转第 64 页)




图 4 环缝源在内壁单影透照方式(F>R)布置示意




图 5 环缝源在内壁单影透照方式(F<R)布置示意

$$\alpha = 180^\circ - \theta - \sin^{-1} \left(\frac{r}{R + P - F} \sin \theta \right) \quad (18)$$

$$\theta = 180^\circ - \cos^{-1} \left(\frac{T(1 - K^2) - D_0}{K(D_0 - 2T)} \right) \quad (19)$$

$$\eta = \alpha + \theta \quad (20)$$

$$L_3 = \frac{D_i \pi}{N} \quad (21)$$

$$L_3' = \frac{D_0 \pi}{N} \quad (22)$$

$$\Delta L = 2(F \tan \eta - F \tan \alpha) \quad (23)$$

$$L_T = 2F \tan \eta \quad (24)$$

式中: L_3' 为探测器侧等分长度。

若 $F > R$, 则无需考虑搭接的问题; 若 $F < R$, 则需考虑搭接长度, 以避免漏检。

5 结语

(1) 根据辐射角计算出射线源有效照射场范围, 比较射线源有效照射场范围与平板探测器有效成像区大小, 选择两者较小值作为探测器可用长度。

(2) 管道环焊缝曲率直径大于探测器成像长度时, 几何放大比的变化对图像的影响不大, 此时 K 值小于标准规定值, 一次透照长度可取探测器有效成像长度。

(3) 管道环焊缝曲率直径不大于探测器成像长度时, K 值的选择应满足一次透照长度小于被检工件内径, 且图像灰度值满足要求, 以保证该区域内的图像质量基本满足标准的要求。

参考文献:

- [1] 钱青江. 无损检测技术在压力管道检验中的运用研究[J]. 中国设备工程, 2022(6): 165-166.
- [2] 刘全利, 白世武, 薛岩, 等. 管道环焊缝数字射线检测技术研究[J]. 管道技术与设备, 2010(3): 20-22.
- [3] 强天鹏. 数字射线(DR+CR)检测技术[M]. 南京: 南京出版社, 2021.
- [4] 强天鹏. 射线检测[M]. 北京: 中国劳动社会保障出版社, 2007.

(上接第 40 页)

- [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, 2017, 39(6): 1137-1149.
- [7] 胡晓轩, 甄希金, 朱琦, 等. 深度迁移学习下的船舶焊接表面缺陷智能检测系统[J]. 造船技术, 2021, 49

(3): 84-88.

- [8] 李砚峰, 刘翠荣, 吴志生, 等. 基于深度学习 One-stage 方法的焊缝缺陷智能识别研究[J]. 广西大学学报(自然科学版), 2021, 46(2): 362-372.
- [9] 郑林涛, 董永生, 史恒亮. 一种新型 X 射线安检图像增强算法[J]. 科学技术与工程, 2014, 14(23): 252-256.