

DOI: 10.19650/j.cnki.cjsi.J2108170

基于深度学习模型融合的铸件缺陷自动检测*

杨珂^{1,2}, 方诚^{1,2}, 段黎明^{1,2}

(1. 重庆大学光电技术及系统教育部重点实验室 ICT 研究中心 重庆 400044;

2. 重庆大学机械与运载工程学院 重庆 400044)

摘要:针对目前铸件缺陷检测漏检率高的问题,提出一种基于深度学习模型融合的铸件缺陷检测方法。首先对 Faster RCNN 网络进行改进,利用特征金字塔结构改进特征提取网络模块,实现多尺度的特征融合,完成铸件缺陷的特征提取;然后,基于 ROI Align 对网络中的 ROI 池化层进行改进,将 IOU 分数引入 NMS 算法判定过程;再将改进后的网络与 Cascade RCNN 以及 YOLOv3 进行融合;最后进行实验研究,验证了融合模型能够有效降低铸件缺陷的漏检率。实验结果表明,将感兴趣区域池化改进后,在 Faster RCNN 模型中的缺陷召回率提升了 1.73%,在本文网络模型中的缺陷召回率提升了 4.08%;采用模型融合的方法在不考虑分类准确度的情况下,整个模型的缺陷识别率达到 95.71%,与单个模型相比,在保证铸件缺陷检测准确率的同时,提高了缺陷检测的召回率,满足了工业应用的要求。

关键词: 缺陷检测;深度学习;模型融合;铸件

中图分类号: TH164 TG245 TP391.41 **文献标识码:** A **国家标准学科分类代码:** 460

Automatic detection of casting defects based on deep learning model fusion

Yang Ke^{1,2}, Fang Cheng^{1,2}, Duan Liming^{1,2}

(1. ICT Research Center, Key Laboratory of Optoelectronic Technology and Systems of Ministry of Education, Chongqing University, Chongqing 400044, China; 2. College of Mechanical and Vehicle Engineering, Chongqing University, Chongqing 400044, China)

Abstract: Aiming at the high missed detection rate of casting defects, a casting defect detection method based on deep learning model fusion is proposed. Firstly, the Faster RCNN network is improved, the feature pyramid structure is used to improve the feature extraction network module, multi-scale feature fusion is realized, and the feature extraction of casting defects is completed. Then, the ROI pooling layer in the network is improved based on ROI Align, and the IOU score is introduced into the judgment process of NMS algorithm. And the improved network is integrated with Cascade RCNN and YOLOv3. Finally, an experiment study was carried out to verify that the fusion model can effectively reduce the missed detection rate of casting defects. The experiment results show that the defect recall rates in the Faster RCNN model and the network model proposed in this paper are increased by 1.73% and 4.08%, respectively after the pooling improvement of the region of interest. Using the method of model fusion, in the condition without considering the classification accuracy, the defect recognition rate of the entire model reaches 95.71%. Compared with single model, while guaranteeing the detection accuracy of casting defects, the method also improves the defect detection recall rate and meets the requirements of industrial applications.

Keywords: defect detection; deep learning; model fusion; casting

0 引言

铸件在铸造过程中不可避免的会产生各种内部缺陷,如气孔、缩松、裂纹、夹渣、冷隔^[1]等。数字式辐射成

像技术^[2](digital radiography, DR)可以保证在不破坏零件内部结构的条件下,直观地显示铸件内部的缺陷信息。经过数字成像技术扫描得到表征铸件内部纹理的 DR 图像后,采用传统的人工识别缺陷方法效率低,采用图像处理检测的方法漏检率高,难以达到工业应用要求,所以亟

收稿日期:2021-06-28 Received Date: 2021-06-28

* 基金项目:重庆市技术创新与应用发展专项(cstc2019jcsx-msxmX0058)、国家重大科学仪器设备开发专项(2013YQ030629)资助

需寻求一种效率和准确率高的检测方法。

针对图像的缺陷检测^[3],目前有 3 种方法:第 1 种是基于图像分割的方法,第 2 种是基于机器学习的方法,第 3 种是基于深度学习的方法。

采用图像分割的检测方法,需要对预处理后的图像进行阈值分割或图像二值化,从而突显缺陷轮廓信息。Anand 等^[4]通过分水岭分割算法把一整张图像分割成多个小图像,然后对每个小图像进行相应的去噪处理,并获得小图像的边界阈值,最后对整张大图像进行分割处理。Aminzadeh 等^[5]提出了一种新的自动阈值处理方法,通过近似定位缺陷来自动检测无缺陷区域,可以有效地从背景中分割大型缺陷或小型缺陷。Anwar 等^[6]、Tsai 等^[7]结合梯度特征和各向异性扩散,通过对缺陷位置进行锐化处理以及对非缺陷位置进行平滑处理,来检测太阳能电池中的缺陷。Yuan 等^[8]针对对象和背景的分离措施,对最大类间方差法进行改进,提出一种加权对象方差法,可以检测各种表面缺陷。Sindagi 等^[9]提出了一种自适应支持向量数据描述法,并通过对修改后的局部二进制图案进行了增强,用于检测有机发光二极管面板中的缺陷。采用图像分割的检测方法相对于人工检测可以提高缺陷检测效率,但进行阈值分割需要对象和背景具有较高对比度,不能有效适用于复杂环境下的缺陷检测。

采用机器学习的方法一般是对缺陷进行分类识别,若要确定缺陷位置,需要采用模板匹配等算法。Li 等^[10]提出了一种基于模板匹配算法的工业冲压件缺陷的检测方法,通过建立冲压件的缺陷模板特征库来计算输入图像和标准图像的偏差矩阵,然后将偏差矩阵与缺陷位置的轮廓特征进行比较,缺陷位置通过两个阈值滤波器来确定,从而实现零件表面缺陷的自动检测。但采用模板匹配算法需要建立缺陷的标准样本特征库对于铸件来说极难获得。Jeon 等^[11]利用支持向量机(support vector machines, SVM)算法对后钢板表面的周期性缺陷进行识别。杨水山等^[12]结合了 Boosting 算法和 SLIQ (supervised learning in quest, SLIQ) 决策树得到了组合分类器,并用于缺陷的识别。但采用机器学习的方法需要手动提取缺陷特征,难以实现端到端的缺陷检测。

采用深度学习进行缺陷检测,王宪保等^[13]针对太阳能电池表面存在的缺陷,提出利用深度置信网络算法进行缺陷检测,该算法能够有效定位缺陷在图片中的位置,但是受限于单目标检测且无法对缺陷进行分类。Akram 等^[14]基于卷积神经网络提出了一种用于电致发光图像中的光伏模块的缺陷检测的轻量级架构,该方法也属于单目标的检测,不适用于铸件 DR 图像中包含多个缺陷的情况。针对大型工件内部缺陷,余永维等^[15-16]将深度学习中的特征匹配与选择性注意力机制结合,提出一种缺陷动态跟踪检测方法,并提出了一种铸件缺陷实时定

位方法,该方法可以实现缺陷位置的检测,但无法进行缺陷的分类,并对小目标缺陷检测效果不佳。蔡彪等^[17]采用了 Mask RCNN (region-convolutional neural networks, RCNN)对铸件内部缺陷进行了缺陷检测,但其准确率仍较低,难以达到实用的目的。

本文以铸件为研究对象,提出了一种基于模型融合的深度学习检测方法。针对 Faster RCNN 特征提取网络细节信息表征能力较弱的问题,提出采用多尺度特征融合结构进行特征提取,并结合感兴趣区域(region of interest, ROI) Align 对网络中的 ROI 池化层进行改进,将交并比(intersection-over-union, IOU)分数引入非极大值抑制(non-maximum suppression, NMS)算法判定过程。针对目前缺陷检测漏检率高的问题,提出模型融合的方法,将改进后的 Faster RCNN 与 YOLOv3 (you only look once, YOLO)、Cascade RCNN 网络模型融合。本文方法对于铸件缺陷检测具有较好的检测效果,并解决了传统检测方法漏检率高的问题。

1 基于 Faster RCNN 网络的改进

1.1 特征提取

Faster RCNN 的特征提取网络采用串联结构的 VGG16 (visual geometry group network, VGG)^[18],网络每进行一次池化过程,整个图片缩小为原来的 1/2,经过 5 次池化过程,会将图片变为原来的 1/2⁵。本文研究的铸件 DR 图像大小为 2 240×2 048,使用 VGG16 进行特征提取,由于卷积池化次数太多,图像处理到最后一层已经被缩小成尺度为 70×64 大小的特征图,图像过于抽象,原图中尺度小于 32×32 的缺陷将被下采样至小于 1 pixel,对于这类缺陷的检测意义不大。如果利用这些特征图进行缺陷检测,会极大地降低缺陷检测的准确率,造成很大一部分小缺陷漏检。

目前针对特征提取网络常常使用多层卷积的方法对图像进行逐层抽象,但是这会导致网络对图像从高层到低层的下采样过程中分辨率逐渐降低。对于低层网络而言,其感受野较小,图像分辨率较高,对图像细节信息的表征能力较强,但是对于图像语义信息的表征能力较弱。对于高层网络而言,其感受野较大,对图像中的语义信息表征能力较强,然而其分辨率较低,难以表达图像中的几何细节信息。本文将低层信息和高层信息融合,使得特征提取既保留了细节信息又保留了语义信息。

传统的金字塔方式^[19]如图 1 所示,左侧网络对图片进行下采样得到图片的高层特征,右侧网络对图片进行上采样得到图片的低层特征,最后对高层特征和低层特征的特征图进行分类预测。

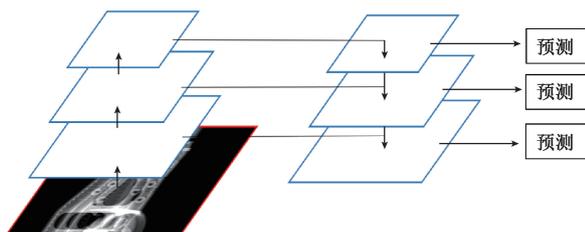


图1 传统金字塔网络

Fig. 1 Traditional pyramid network

如图2所示是本文所采用的多尺度特征融合网络结构,将铸件DR图像输入网络,经过5个卷积和5个0.5倍下采样过程,生成5个尺度不同的特征图(C1, C2, C3, C4, C5),特征图C5经过 1×1 的卷积生成特征图M5,由M5经过2倍上采样与特征图C4进行特征融合,生成M4特征图,以同样的方法,可以生成4个特征图(M2, M3, M4, M5),将这些特征图经过一个 3×3 的卷积过程便可产生最终的特征图(P2, P3, P4, P5),达到了特征提取的目的。

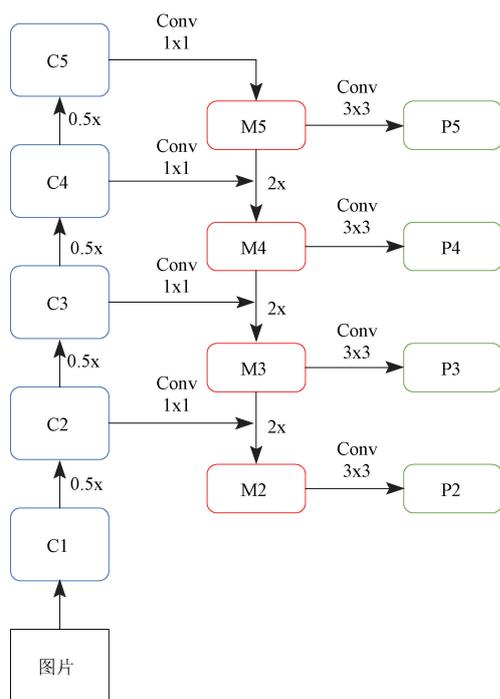


图2 多尺度特征融合结构图

Fig. 2 The structure diagram of multi-scale feature fusion

1.2 感兴趣区域池化方式

ROI是将图像输入进训练网络经过特征提取得到图像的特征,然后经过区域建议网络(region proposal network, RPN)生成多个候选框后,候选框在特征图中的映射区域。对感兴趣区域进行池化操作可以对在深度网络中利用多个不同的卷积核处理后图像形成固定大小的

特征图,有利于提高目标的分类准确率并且提高训练和检测的速度。Faster RCNN中采用基于映射的感兴趣区域池化方式,感兴趣区域池化在进行映射的过程中会将浮点数的坐标取整量化,在确定窗口大小的过程中也会有一个取整量化的过程,这两次取整量化会导致候选框的位置出现偏差,影响了对小缺陷的检测精度。

为了解决以上问题,本文引入ROI Align,对其进行改进,整体流程如下:

1) 对于每一张特征图,遍历得到其感兴趣区域,候选框边界若为浮点数,不做取整操作。

2) 针对输出区域大小,确定池化采样点数 k ,将候选区域分割成 $k \times k$ 个小区域,对每个区域的边界也不做取整操作。

3) 利用双线性内插法根据每个区域中心周围距离最近的四个像素点的像素值计算其中心的值。

4) 最后对 k 个区域进行最大值池化。

1.3 检测框生成

目标检测在RPN阶段产生了大量的边界框(bounding box, BB)或检测框,而NMS算法常常被用作对生成的检测框进行后处理操作,以保留最佳的检测框,删除一些多余的检测框。Faster RCNN中采用NMS算法,但是由于NMS算法仅仅以候选框的分类置信度作为指标与设定的阈值进行比较,导致缺失了定位置信度,这会使得某些位置检测准确度较高但是分类置信度不准确的检测框被删除,对于铸件缺陷识别而言,容易造成一定程度的漏检。本文对NMS算法进行改进,以减少缺陷的漏检率,提高检测准确度。

IOU即交并比,表示候选框与原始标定框的重叠度。本文以检测框的IOU分数作为其定位置信度引入算法,以尽可能检测到更多的缺陷,防止产生缺陷漏检的情况,该算法的步骤为:

1) 对某类缺陷所有检测框按照IOU分数进行排序,得到IOU分数最高的检测框,以 B_m 表示;

2) 设定一个阈值,并逐渐判断剩余检测框与 B_m 的重叠程度;

3) 将重叠程度最大的检测框的分类置信度以及 B_m 作为输出;

4) 对每个类别的缺陷重复以上步骤,直到不再有检测框。

1.4 网络结构图

改进后的Faster RCNN网络结构图如图3所示。首先将铸件DR图像经过多尺度特征融合网络,提取出一系列深层特征图和浅层特征图,然后将这些特征图通过RPN网络进行候选框的生成,生成的候选框映射到特征图中并由ROI网络处理,最后将处理后的图像进行分类与回归训练。

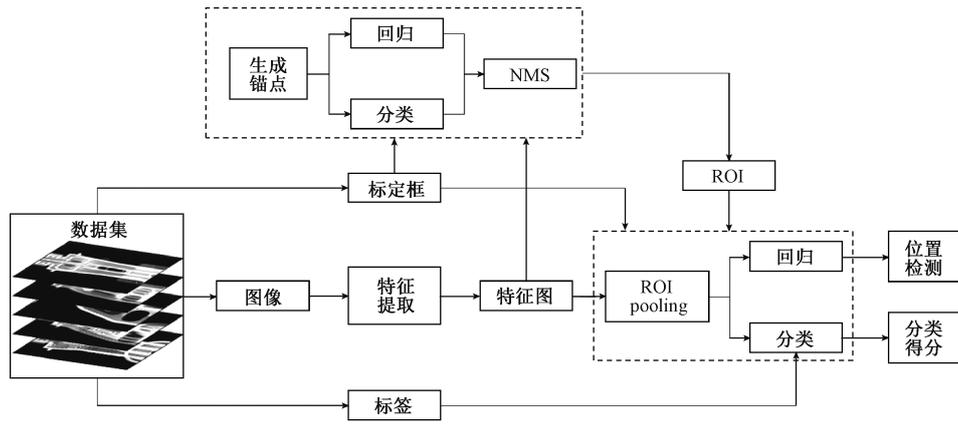


图 3 改进的网络结构图

Fig. 3 Improved network structure diagram

2 模型融合

对于单模型而言,仍然存在较多的漏检情况,为了降低铸件缺陷检测的漏检率,保证铸件在使用期间的可靠性,本文利用不同网络对铸件 DR 图像进行大量训练,不同层次的网络生成不同的模型权重,针对图像中某位置的缺陷检测,不同的网络会产生不同位置精度及类别精度的检测信息。为了更进一步提高缺陷检测的缺陷召回率,及整个模型的检测准确率,对不同的模型进行融合,使得模型能够检测出来更多的缺陷,并优化缺陷检测置信度得分,方便人工校核。融合算法流程如下:

1)由改进后的网络以及 Cascade RCNN、YOLOv3 网络进行训练得到的 3 个不同的模型分别进行缺陷检测,得到相应的检测框信息,包括检测框的位置坐标、检测类型以及置信度。

2)计算不同的模型任意两个检测框的 IOU 值,设定阈值,若 IOU 值大于该阈值,则认为两个检测框检测的同一缺陷,反之,则检测的两个不同缺陷,为了提高整体模型的缺陷召回率,应保留检测情况为不同缺陷的情况。

3)若两个检测框检测的同一缺陷,采用算法更新其置信度的值。首先,根据不同的模型对不同缺陷的检测准确率的不同设置相应的权重;接着将每一个模型对于该类缺陷的置信度得分乘以相应的权重指标,得到整体模型的置信度得分;最后保留置信度得分最高的检测框的位置坐标,并更新其置信度得分。

4)若两个检测框检测的不同缺陷,则保留其置信度得分及其检测框位置坐标信息。

3 实验研究

3.1 实验平台

本实验平台环境为 Ubuntu18.04.1 系统,CUDA9.0,cudnn7,GPU 为 NVIDIA GeForce GTX 1080 Ti,处理器为 Intel(R) Core(TM) i7-8700,内存为 16 G,使用 Pytorch 深度学习框架以及 Python3.6。

3.2 铸件 DR 图像数据分析

本文以摇枕和侧架为研究对象进行实验。摇枕和侧架在铸造过程中产生的主要缺陷类型为气孔和缩松,因此本文针对铸件在铸造成型后气孔和缩松进行检测。

对无损检测中的铸件射线检测底片进行级别评定时,常常采用 ASTM E446 标准。该标准将铸件缺陷分为 7 个大类,分别为:气孔(A类),夹砂和夹渣(B类),缩松(C类),裂纹(D类),热撕裂(E类),内冷铁(F类),斑纹(G类)。在这 7 个大类中,根据 A、B、C 类缺陷产生的严重程度,将其分为 1~5 共 5 个等级,而 D、E、F、G 类缺陷没有等级区别。

本文所提取的数据集中,存在两类缺陷,分别为气孔类(A类)和缩松类(C类)缺陷。气孔为孔洞类缺陷,在 DR 图像中通常呈现出黑色的圆形或者椭圆形的斑点状,缩松为细小而分散的孔洞群,在 DR 图像中通常呈大面积黑色斑点群。缺陷形貌特征如图 4 所示,每类缺陷被分为 5 个等级,一共 10 种缺陷。

本文使用的缺陷 DR 数据集共有图像 5 000 张,将其中的 4 500 张作为训练集,500 张作为测试集。数据集中的每个图像均为 3 通道,像素大小为 2 240×2 048。每个 DR 图像可能都具有气孔和缩松缺陷,它们被分类为 1~5 级。对 5 000 张样本数据针对缺陷种类形态和数量

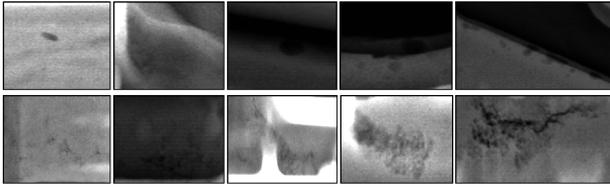


图4 气孔、缩松缺陷形貌特征

Fig. 4 Morphological characteristics of pores and shrinkage defects

进行统计分析,结果如图5所示,发现图片中气孔2、3级缺陷所占比例较高,而缩松2、3、4级缺陷占用比例较高。针对这一现象,为了平衡气孔与缩松训练样本,提高训练效果,首先对其进行样本均衡化处理。

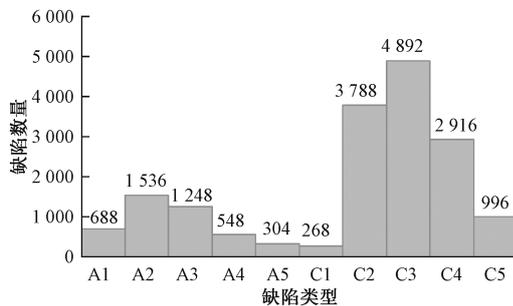


图5 不同缺陷数量统计

Fig. 5 Statistics of the number of different defects

3.3 图像预处理

铸件DR图像在采集的过程中,不可避免的会产生噪声,有的甚至会存在散射、雾化等现象,因此必须对采集的DR图像进行滤波处理,以增强缺陷的识别能力。

由于铸件DR图像缺陷相对于铸件本身较小,特别是A1、A2类,C1、C2类缺陷,它们在DR图像中的像素值以及本身的缺陷尺寸都相对于其他缺陷明显存在不突出的特点,采用一般的滤波算法对图片进行处理的过程中会对噪声和缺陷轮廓信息进行一致性处理,在去除噪声的同时,一些缺陷的边缘轮廓等重要信息也会被过滤掉,导致了后续的缺陷检测过程难以进行,从而降低缺陷检测的准确率,容易造成漏检的情况。为了防止在进行滤波过程中,缺陷信息的丢失,本文采用导向滤波对铸件DR图像进行预处理。

将具有噪声的DR图像经过导向滤波处理后再经过图像增强,如图6所示为未经过增强处理的图像及其灰度直方图,如图7所示为经过增强处理后的图像及其灰度直方图,从图7中可以很容易地观测到铸件DR图像中存在的一系列缺陷。由对比增强前后图像的灰度直方图可知,增强后的图像相比于增强前的图像的直方图更加均衡,整个图像像素值范围更广,图像局部细节视觉效果更明显,缺陷更容易辨识。

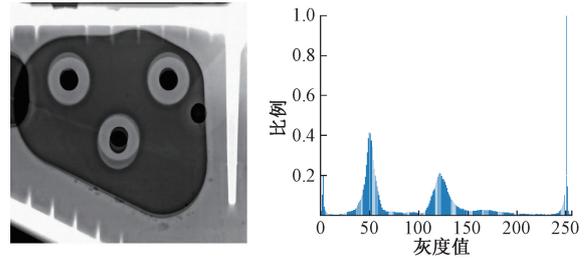


图6 原始图像及其灰度直方图

Fig. 6 Original image and its grayscale histogram

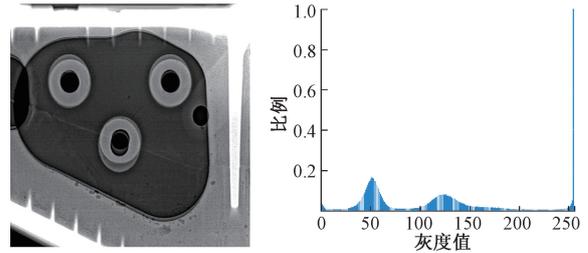


图7 增强后的图像及其灰度直方图

Fig. 7 The enhanced image and its grayscale histogram

3.4 超参数的设置

1) 标定框的聚类分析

为了减少训练模型损失函数收敛时间,提升检测框的准确性,需要预先对每种缺陷的候选框进行初始化。由于对缺陷进行标定时,每种缺陷的标定框大小不一样,因此在进行网络训练前,需要对标定框进行聚类分析,本文采用K-means聚类算法。

聚类的最终结果是求出每个标定框到聚类中心的距离函数之和达到最小,其数学表达式为:

$$J(k) = \min \sum_{i=0}^k \sum_{j=0}^y D_i(x_j) \quad (1)$$

通过K-means算法对缺陷标定框进行聚类后,经过分析选取最优聚类 k 值。

如图8所示,横坐标为设定的 k 值,纵坐标为每个标定框到聚类中心的最小距离 J ,由分析可知,当 k 为1时,最短距离最大, $J(k)$ 的值为2852.486,而随着 k 逐渐增大,最短距离的值逐渐减小,当 k 小于13时, $J(k)$ 的值下降速率较快,而当 k 大于13时,曲线逐渐趋于稳定,此时,随着 k 的增大,聚类效果降低。因此,对于铸件DR图像的最优聚类数目 k 为13。随着 k 的增加,初始候选框的平均交并比也铸件增加,当 k 等于13时,平均交并比达到83.45%。K-means算法在训练过程中保证生成的候选框具有较大的交并比的基础上,使得模型更加快速地收敛,并且减少了计算机资源的浪费。

2) 训练参数的设置

(1) BASE ANCHOR SIZE LIST 以及 ANCHOR RATIOS 的设置。

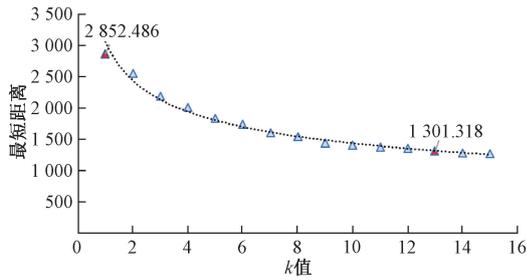


图 8 不同 k 值聚类目标函数值变化

Fig. 8 Change of objective function value for clustering with different k values

BASE ANCHOR SIZE LIST 和 ANCHOR RATIOS 是网络配置文件中比较重要的两个参数,他们的值直接影响候选框的生成,因此需要对其进行初始化设置,设置如下:

①由 K-means 算法得到了 13 个簇的候选框,分别为: (45, 44), (201, 31), (27, 23), (342, 164), (117, 197), (198, 106), (124, 78), (352, 62), (102, 28), (188, 57), (59, 104), (80, 56), (128, 43)。设置 BASE_ANCHOR_SIZE_LIST 为 [16, 32, 64, 128, 256, 512]。

②它们的宽高比为: [1.0, 6.5, 1.2, 2.1, 0.6, 1.9, 1.6, 5.7, 3.6, 3.3, 0.6, 1.4, 3.0], 其中最大宽高比为 6.5, 最小的宽高比为 0.6, 因此设置 ANCHOR_RATIOS 为 [0.01, 0.1, 10]。

(2) 其他参数的设置

采用本文的网络结构对 4 500 张 DR 图像训练样本数据进行训练,迭代 10 000 次, batch size 设置为 2, mini-batch 设置为 40, 采用预热后的余弦函数衰减学习率, 0~1 000 次迭代时, 设置初始学习率由 0 线性增加到 $1e-3$, 到 1 000~10 000 次迭代时, 学习率采用余弦函数衰减学习率。

3.5 实验结果与分析

1) 感兴趣区域池化改进前后对比实验

通过实验发现, 铸件背景极大地影响了缺陷的检测效果, 如图 9 所示, 局部放大处为 A2 缺陷, 但在铸件本身环境的影响下, 采用原感兴趣区域池化的方式并不能检测出该处的缺陷。因此, 为了准确检测在铸件轮廓边缘的小尺度的缺陷, 本文对感兴趣区域池化进行改进。

仅针对感兴趣区域池化的改进, 本文在原 Faster RCNN 基础上做了对比实验, 对比了感兴趣区域池化改进前后的效果, 同时, 还对比了其在本网络模型的实验的效果, 对比结果如表 1 所示, 明显可以发现, 改进感兴趣区域池化后在 Faster RCNN 模型中的缺陷召回率提升了 1.73%。改进感兴趣区域池化后在本网络模型中的缺陷召回率提升了 4.08%。因此, 本文针对铸件 DR 图像, 改

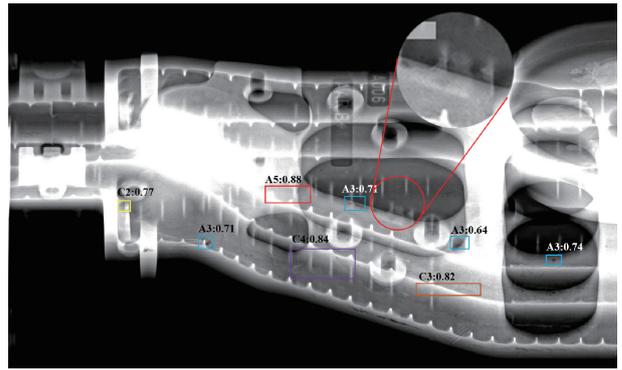


图 9 ROI 池化检测效果

Fig. 9 ROI pooling detection effect

进了感兴趣区域池化方式, 有效地提高了铸件缺陷的平均准确度及其缺陷召回率。

表 1 ROI 改进前后效果对比
Table 1 Effect comparison before and after ROI improvement

网络类型	感兴趣区域池化方式	缺陷召回率
Faster RCNN	改进前	0.751
	改进后	0.764
特征融合+Faster RCNN	改进前	0.857
	改进后	0.892

2) 训练误差实验分析

如图 10 所示, 为改进后的铸件缺陷检测网络训练损失函数图, 结果表明, 损失函数在开始收敛时并未出现波动较大的情况, 随着训练迭代次数的增加, 模型的训练损失精度逐渐降低, 模型的损失函数曲线逐渐收敛, 当模型迭代至 6 000 次时, 模型的损失函数值趋于稳定, 约为 1.2 左右, 说明模型训练效果较好, 能够满足铸件缺陷训练要求。

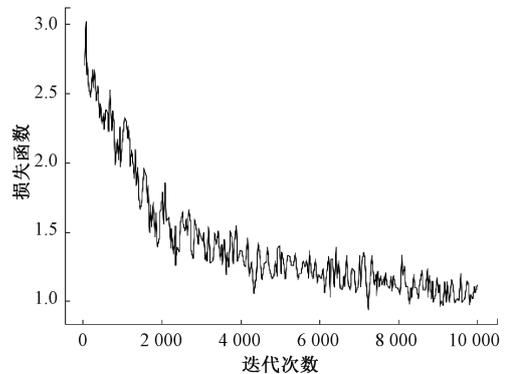


图 10 改进后的网络损失函数

Fig. 10 Improved network loss function

3) 单个模型训练结果对比

利用训练生成的权重模型对测试集进行检测,并将测试结果可视化,检测结果如图 11、12 所示,图 11 所示为 Faster RCNN 检测结果图,图 12 为改进后的网络检测结果图。由图中可看出,Faster RCNN 检测结果存在较多漏检的情况,检测效果不达标,而改进后的网络对于小缺陷的检测能力有明显的提升。

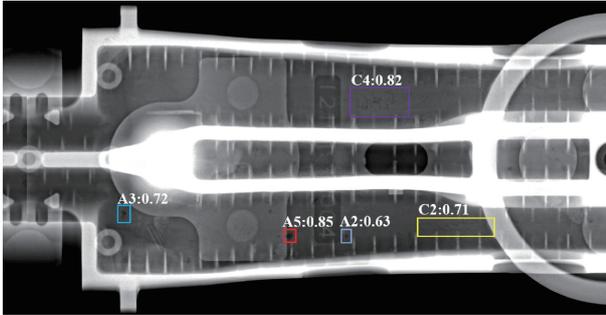


图 11 Faster RCNN 检测结果
Fig. 11 The detection result of Faster RCNN

将未经过数据增强的原始样本中随机取出 100 张图片作为测试集。本文一共对 431 个缺陷进行检测并统计检测效果,得到表 2 和 3,其中表 2 为 Faster RCNN 网

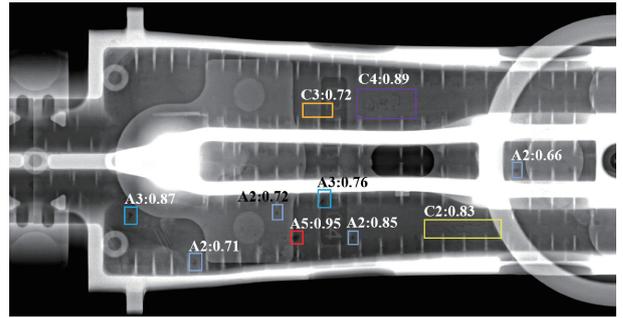


图 12 改进后的网络检测结果
Fig. 12 The detection result of improved network

络检测结果,表 3 为改进后的网络检测结果。表中横向标签代表缺陷的正确类型,纵向标签代表被检测缺陷的类型。粗体数字为正确检测数量,其余为误检缺陷数量。从结果表中得出,本文针对 Faster RCNN 进行改进,有效提升了模型的铸件缺陷检测性能,对于 A4、A5、C4、C5 等尺度较大的缺陷,容易出现误检的情况,而对于 A1、A2、A3、C1、C2、C3 等尺度较小的缺陷,漏检与误检都会存在,但更多的是会出现漏检的情况。

表 2 Faster RCNN 网络检测结果
Table 2 The detection results of Faster RCNN network

检测类型	正确类型									
	A1	A2	A3	A4	A5	C1	C2	C3	C4	C5
A1	9	3	1	0	0	0	0	0	0	0
A2	2	7	5	0	0	0	0	0	0	0
A3	0	1	22	3	0	0	0	3	0	0
A4	0	0	0	11	3	0	0	0	0	0
A5	0	0	0	1	12	0	0	0	0	0
C1	1	0	0	0	0	8	5	0	0	0
C2	0	0	1	0	0	2	72	7	0	0
C3	0	0	0	0	0	0	3	86	9	0
C4	0	0	0	0	0	0	0	6	59	7
C5	0	0	0	0	0	0	0	0	2	18
共检测数	18	19	32	17	15	14	95	123	73	25
漏检数	6	8	4	2	0	4	15	21	3	0
误检数	3	4	6	4	3	2	8	16	11	7

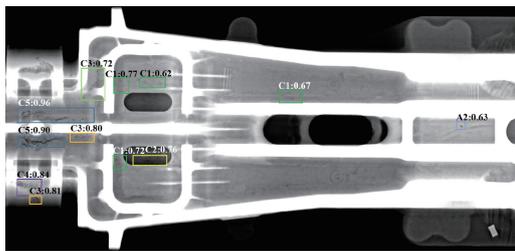
4) 模型融合实验分析

本文训练了改进后的 Faster RCNN 模型, Cascade RCNN 模型, YOLOv3 模型 3 个模型, 识别率分别达到了 92.63%, 90.71%, 86.79%。接着采用模型融合方法将 3 种模型进行融合, 如图 13 所示, 展示了经过模型

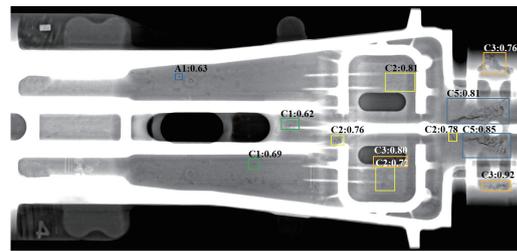
融合后的缺陷检测结果图, 可以得出, 相比于单模型训练, 多模型训练对铸件缺陷的检测效果有很大的提升, 缺陷召回率显著提高, 特别是对于小缺陷来说。不考虑分类准确度的情况下, 整个模型的缺陷识别率为 95.71%。

表 3 改进后的网络检测结果
Table 3 The detection result of improved Faster RCNN network

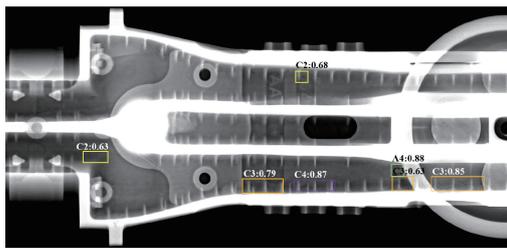
检测类型	正确类型									
	A1	A2	A3	A4	A5	C1	C2	C3	C4	C5
A1	12	2	0	0	0	0	0	0	0	0
A2	2	15	3	0	0	0	0	0	0	0
A3	0	0	28	1	0	0	0	0	0	0
A4	0	0	0	13	2	0	0	0	0	0
A5	0	0	0	0	6	0	0	0	0	0
C1	1	0	0	0	0	5	1	0	0	0
C2	0	0	1	0	0	0	87	4	0	0
C3	0	0	0	0	0	0	0	116	4	0
C4	0	0	0	0	0	0	0	3	69	2
C5	0	0	0	0	0	0	0	0	0	23
共检测数	18	19	32	14	8	7	95	123	73	25
漏检数	3	2	0	0	0	2	7	0	0	0
误检数	3	2	4	1	2	0	1	7	4	2



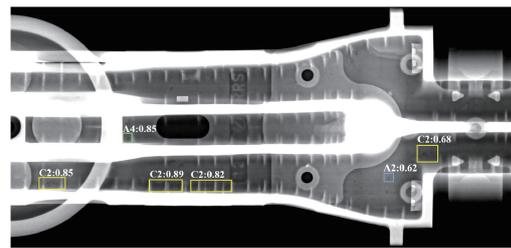
(a) 摇枕 I 左侧检测结果
(a) Test result on the left side of bolster I



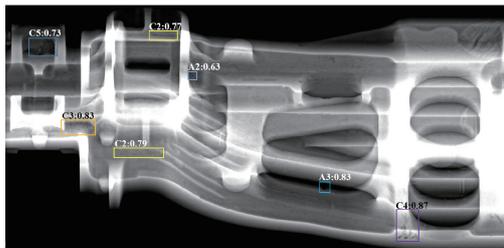
(b) 摇枕 I 右侧检测结果
(b) Test result on the right side of bolster I



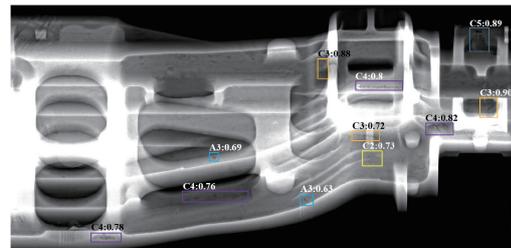
(c) 摇枕 II 左侧检测结果
(c) Test result on the left side of bolster II



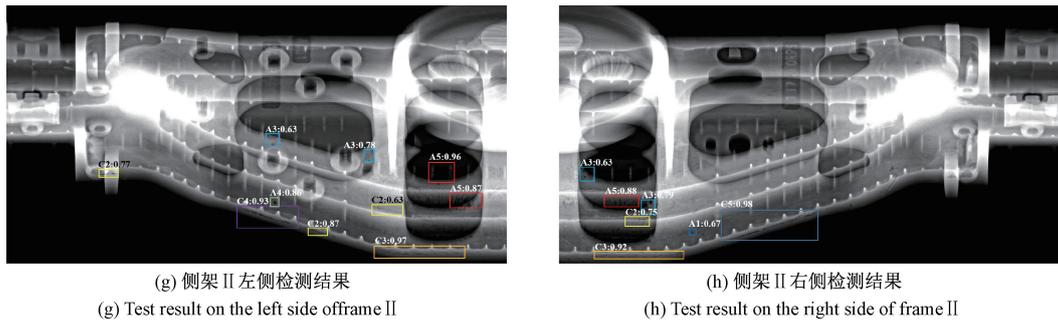
(d) 摇枕 II 右侧检测结果
(d) Test result on the right side of bolster II



(e) 侧架 I 左侧检测结果
(e) Test result on the left side of frame I



(f) 侧架 I 右侧检测结果
(f) Test result on the right side of frame I



(g) 侧架 II 左侧检测结果
(g) Test result on the left side of frame II

(h) 侧架 II 右侧检测结果
(h) Test result on the right side of frame II

图 13 模型融合检测结果图

Fig. 13 Model fusion detection result graph

4 结 论

本文针对铸件缺陷检测环境复杂、漏检率高的特点,改进了 Faster RCNN 网络用于检测,并与原网络进行对比分析,验证了改进后的方法优于原 Faster RCNN。针对不同的深度学习网络模型缺陷检测性能的差异性,融合了改进后的网络、Cascade RCNN、YOLOv3 网络模型,与单个模型相比,虽然多模型融合训练时间较长,内存占用量相对较多,但是可以有效降低铸件缺陷漏检率,实现了铸件内部缺陷的准确检测,达到了工业应用要求。本文方法在某企业的侧架摇枕铸件缺陷识别中得到了应用。后续可针对训练时间复杂度问题进行相关研究。

参考文献

- [1] 羊肇俊,曾理. 基于加权最小二乘滤波和引导滤波的铸件 DR 图像融合[J]. 仪器仪表学报, 2021, 42(6): 211-220.
YANG ZH J, ZENG L. Casting DR image fusion based on weighted least square filter and guided filter [J]. Chinese Journal of Scientific Instrument, 2021, 42(6): 211-220.
- [2] BRITO A R, VERNER F S, JUNQUEIRA R B, et al. Detection of fractured endodontic instruments in root canals; Comparison between different digital radiography systems and cone-beam computed tomography [J]. Journal of Endodontics, 2017, 43(4): 544-549.
- [3] 李少波,杨静,王铮,等. 缺陷检测技术的发展与应用研究综述[J]. 自动化学报, 2020, 46(11): 2319-2336.
LI SH B, YANG J, WANG ZH, et al. Review of development and application of defect detection technology [J]. Acta Automatica Sinica, 2020, 46(11): 2319-2336.
- [4] ANAND R S, KRMAR P. Flaw detection in radiographic weldment images using morphological watershed segmentation technique [J]. NDT & E International,

2009, 42(1): 2-8.

- [5] AMINZADEH M, KURFESS T. Automatic thresholding for defect detection by background histogram mode extents[J]. Journal of Manufacturing Systems, 2015, 37(3): 83-92.
- [6] ANWAR S A, ABDULLAH M Z. Micro-crack detection of multicrystalline solar cells featuring an improved anisotropic diffusion filter and image segmentation technique [J]. EURASIP Journal on Image and Video Processing, 2014, 2014(1): 1-17.
- [7] TSAI D M, CHANG, C C, CHAO S M. Micro-crack inspection in heterogeneously textured solar wafers using anisotropic diffusion [J]. Image & Vision Computing, 2010, 28(3): 491-501.
- [8] YUAN X C, WU L S, PEBG Q. An improved otsu method using the weighted object variance for defect detection [J]. Applied Surface Science, 2015, 349(15): 472-484.
- [9] SINDAGI V A, SRIVASTAVA S. Domain adaptation for automatic OLED panel defect detection using adaptive support vectorData description[J]. International Journal of Computer Vision, 2017, 122(2): 1-19.
- [10] LI B, WU Y, GUO F, et al. Real-time detection method for surface defects of stamping parts based on template matching [J]. IOP Conference Series Earth and Environmental Science, 2019, 252: 1-8.
- [11] JEON Y J, CHOI D C, YUN J P, et al. Detection of periodic defects using dual-light switching lighting method on the surface of thick plates [J]. Isij International, 2015, 55(9): 1942-1949.
- [12] 杨水山,何永辉,赵万生. Boosting 优化决策树的带钢表面缺陷识别技术[J]. 红外与激光工程, 2010(5): 954-958.
YANG SH SH, HE Y H, ZHAO W SH. Strip steel surface defect recognition based on Boosting optimized decision tree [J]. Infrared and Laser Engineering,

- 2010(5): 954-958.
- [13] 王宪保, 李洁, 姚明海, 等. 基于深度学习的太阳能电池片表面缺陷检测方法[J]. 模式识别与人工智能, 2014, 27(6): 517-523.
WANG X B, LI J, YAO M H, et al. Solar cells surface defects detection based on deep learning [J]. Pattern Recognition and Artificial Intelligence, 2014, 27(6): 517-523.
- [14] AKRAM M W, LI G, JIN Y, et al. CNN based automatic detection of photovoltaic cell defects in electroluminescence images [J]. Energy, 2019, 189(6): 116-124.
- [15] 余永维, 杜柳青, 闫哲, 等. 基于深度学习特征的铸件缺陷射线图像动态检测方法[J]. 农业机械学报, 2016, 47(7): 407-412.
YU Y W, DU L Q, YAN ZH, et al. Dynamic detection of casting defects radiographic image based on deep learning feature [J]. Transactions of the Chinese Society for Agricultural Machinery, 2016, 47(7): 407-412.
- [16] 余永维, 杜柳青, 曾翠兰, 等. 基于深度学习特征匹配的铸件微小缺陷自动定位方法[J]. 仪器仪表学报, 2016, 37(6): 1364-1370.
YU Y W, DU L Q, ZENG C L, et al. Automatic localization method of small casting defect based on deep learning feature [J]. Chinese Journal of Scientific Instrument, 2016, 37(6): 1364-1370.
- [17] 蔡彪, 沈宽, 付金磊, 等. 基于 Mask R-CNN 的铸件 X 射线 DR 图像缺陷检测研究[J]. 仪器仪表学报, 2020, 41(3): 63-71.
CAI B, SHEN K, FU J L, et al. Research on defect detection of X-ray DR images of casting based on Mask R-CNN [J]. Chinese Journal of Scientific Instrument, 2020, 41(3): 63-71.
- [18] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. Computer Science, 2014, 45(3): 1-14.
- [19] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[J]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2117-2125.

作者简介



杨珂, 2017 年于中国石油大学(华东)获得学士学位, 2021 年于重庆大学获得硕士学位, 主要研究方向为基于工业 CT 的逆向制造、计算机辅助制造等。
E-mail: 393741905@qq.com

Yang Ke received bachelor degree from China University of Petroleum (East China) in 2017 and master degree from Chongqing University in 2021. His main research direction is reverse manufacturing based on industrial CT, computer-aided manufacturing, etc.



段黎明 (通信作者), 1985 年于成都科技大学获得学士学位, 1988 年于重庆大学获得硕士学位, 1998 年于重庆大学获得博士学位。现任重庆大学教授, 博士生导师。主要研究方向为工业计算机层析成像技术及系统、精密机械及仪器等。

E-mail: duanliming163@163.com

Duan Liming (Corresponding author) received his B. Sc. degree in 1985 from Chengdu University of Science and Technology, and received his M. Sc. and Ph. D. degrees both from Chongqing University in 1988 and 1998, respectively. He is currently a professor and a Ph. D. supervisor at Chongqing University. His main research direction include industrial computer tomography technology and system, precision machinery and instruments.