

引文格式: 张祥春, 彭文胜, 楚峻溢, 等. 基于改进Mask R-CNN的航空铸件智能检测技术研究[J]. 航空制造技术, 2025, 68(23/24): 26-33.

ZHANG Xiangchun, PENG Wensheng, CHU Junyi, et al. Aviation casting intelligent detection technology based on improved Mask R-CNN[J]. Aeronautical Manufacturing Technology, 2025, 68(23/24): 26-33.

基于改进Mask R-CNN的航空铸件智能检测 技术研究*

张祥春^{1,2}, 彭文胜^{1,2}, 楚峻溢^{1,2,3}, 曾照洋^{1,2}, 王振宇^{1,2,4}, 魏明贤¹, 徐 然¹

(1. 中国航空综合技术研究所, 北京 100028;

2. 航空综合环境航空科技重点实验室, 北京 100028;

3. 重庆大学, 重庆 400044;

4. 大连理工大学, 大连 116024)

[摘要] 针对航空产品研制生产过程中由于质量缺陷产生原因复杂、缺陷特征种类多、检测要求高而缺少有效智能检测方法的问题, 首先通过系统梳理航空装备智能检测技术研究现状, 总结了面向此应用场景和针对具体缺陷特征开展智能检测方法研究的思路和实施途径; 其次, 设计了融合全局特征金字塔网络的Mask R-CNN改进算法, 并面向缺陷特征复杂和检测要求比较高的航空铸件, 利用剪切、翻转、Overlap切图和Mosaic等数据增广技术构建了航空铸件数字射线检测缺陷特征数据集; 最后利用改进算法及构建的数据集对航空铸件中的疏松、裂纹及高密度夹杂3类缺陷进行测试与验证试验。试验结果表明, 所提改进算法的检测精度达93.25%, 召回率达96.51%, 具有良好检测效果。

关键词: 深度学习; 智能检测; 航空铸件; Mask R-CNN; 全局特征金字塔网络; 数据增广

中图分类号: V26; TP18

文献标志码: A

DOI: 10.16080/j.issn1671-833x.2025.23/24.026



张祥春

研究员, 研究方向为数字化质量与智能检测技术。

智能检测技术作为智能制造的核心关键技术, 是“工业六基”的重要组成和产业基础高级化的重要领域, 对航空制造业的高端化、智能化、绿色化发展至关重要^[1]。对于航空装备的智能检测, 目前已经取得一些进展。陈银等^[2]提出了一种基于图像特征融合的航空装备检测方法, 通过阈值化分割法获得图像检测结果并进行维修决策。陈新波等^[3]采用Sobel边缘检测算法和最大熵阈值分割法搭建了航空发动机内部损伤智能检测系统, 缩短了对发动机内部损伤缺陷的评估周期。然而随着航空

工业的快速发展和对安全性、可靠性要求的提高, 传统的检测方法在处理复杂、多变的航空装备检测任务时逐渐显示出局限性。近年来, 深度学习因强大的特征提取与泛化能力, 已成为检测领域的研究热点, 并在航空智能检测中得到广泛应用。

目前, 智能检测技术的主流算法框架有YOLO (You only look once) 和掩码区域卷积神经网络(Mask R-CNN)等。基于YOLO的研究, 张杰等^[4]提出了一种基于YOLO-v5的智能检测方法, 将其应用于航空发动机叶片装配过程, 有效降低了人力、

* 基金项目: 国防科工局基础科研项目 (JSBZ2024205B008)。

物力和时间成本。何宇豪等^[5]构建了 SW-YOLO 模型,将其用于孔探视频损伤检测,提高了航空发动机叶片损伤实时检测的速度和准确性。Qu 等^[6]提出了基于 YOLO-v5 的飞机发动机表面缺陷快速检测算法,增强了检测的鲁棒性。基于 Mask R-CNN 的研究,樊玮等^[7]开发了一种基于 Mask R-CNN 的航空发动机损伤图像检测网络,实现了从二分类到多分类的递进式检测,显著提升了孔探图像损伤的分类精度。Wong 等^[8]基于 Mask R-CNN 构建了自动检测和评估燃气轮机叶片损坏的系统,实现了叶片损伤的自动检测。Shang 等^[9]提出了一种基于 Mask R-CNN 的叶片损伤检测方法,该方法能够捕捉损伤形状的浅层纹理信息。

目前,为了解决深层网络训练中常会遇到梯度消失或梯度爆炸,导致网络参数无法有效更新,从而影响模型的学习能力和收敛速度的问题,几乎所有的深度网络都采用残差结构(ResNet)。Mask R-CNN 主干网络通常采用 ResNet 架构, YOLO-v3 及其后续版本中也引入类似 ResNet 的残差块来增强特征提取效果,但 Mask R-CNN 算法在精确度、鲁棒性及灵活性方面具有明显优势,这对于航空器的精密部件和复杂结构的检

测尤为重要,而 YOLO 算法则更适用于需要快速响应的实时检测场景。针对航空铸件的智能检测,为提供更高的检测精度,本文选择使用 Mask R-CNN 作为深度学习框架。

特征提取是深度学习研究的关键阶段,其中 He 等^[10]引入了特征金字塔网络(FPN),将传统图像金字塔概念应用于特征映射,并在残差网络不同阶段之间构建自顶向下的连接路径以增强特征识别能力;Li 等^[11]提出多层特征级联聚合金字塔网络(MCA-FPN),该网络结合不同层次的语义信息生成优化的特征图,提高了对不同大小特征的表达能力;Liu 等^[12]提出路径汇聚网络(PANet),增加了一条自底向上的路径以补充 FPN 的自顶向下路径,进一步提升特征的表达效果。这些研究成果为解决信息流中特征不平衡的问题提供了新的视角,但在处理局部特征时可能会忽略全局信息,导致特征不均衡的问题仍然存在。

因此,本文提出一种全局特征金字塔网络(Global feature pyramid network, GFPN),该网络在不增加超参数的情况下,通过将不同层语义信息与各自特征相结合,形成包含各层语义信息的特征网络,以提高网络检测精度。将该改进算法应用于航空

铸件数字射线检测中,试验结果表明,该改进算法对航空铸件疏松、裂纹及高密度夹杂 3 类微小缺陷具有良好的检测效果。

1 Mask R-CNN

1.1 网络结构

Mask R-CNN 是由 Facebook AI Research 团队在 2017 年提出的一种基于 Faster R-CNN 的新型目标检测和实例分割框架^[10],如图 1 所示,包括 1 个用于提取特征的主干网络和 1 个用于生成候选区域的区域推荐网络(RPN),但不同于 Faster R-CNN,Mask R-CNN 在检测分支之外增加了 1 个并行的掩码分支^[13-16]。

Mask R-CNN 主干网络采用了 FPN 的深度学习架构,如图 2 所示。通过构建自底向上的特征金字塔和自顶向下的特征融合,有效捕捉不同尺度的特征信息,并引入深度残差网络(ResNet101)解决深度网络中的梯度消失问题。这种组合能够在保持高计算效率的同时,提供丰富的特征信息,提高目标检测和实例分割的精度。

RPN 是首次在 Faster R-CNN 中被提出的。Mask R-CNN 中,RPN 接受来自主干神经网络的特征图作为输入,采用滑动窗口机制,在特征图

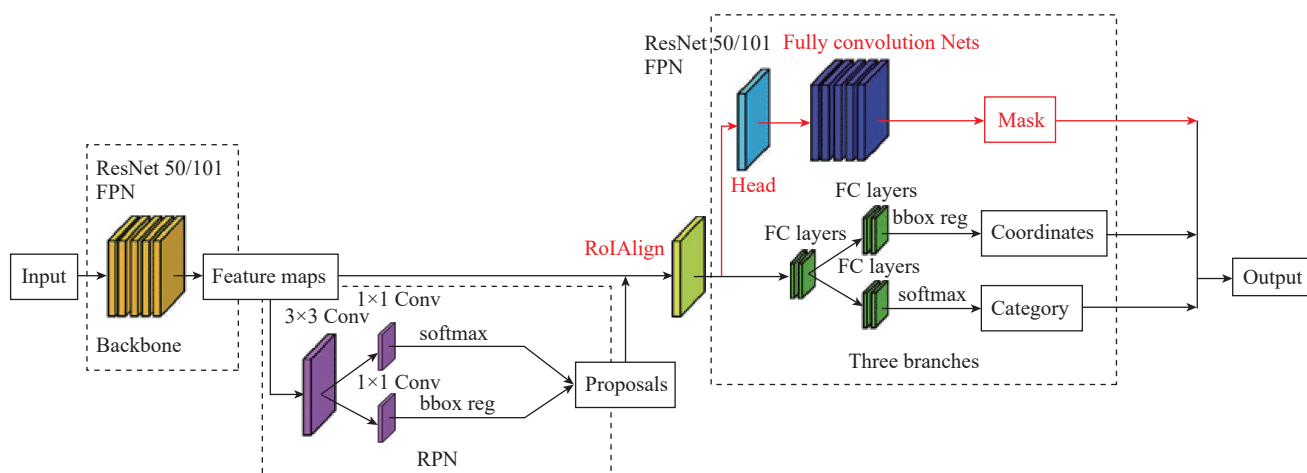


图 1 Mask R-CNN 的结构示意图^[13-16]

Fig.1 Schematic structure of Mask R-CNN^[13-16]




图2 FPN 的结构示意图

Fig.2 Schematic structure of FPN

上使用两个并行的卷积层来检测目标,一个用于生成区域候选框,另一个用于对这些候选框进行分类,以确定它们是否包含目标。RPN 输出一组经过筛选的候选区域,这些区域将被传递到后续的 RoIAlign (Region of interest align) 和分类器,用于进一步的目标检测和实例分割。RPN 的设计使得候选区域生成过程与特征提取过程紧密结合,从而提高了目标检测的效率和准确性。

在 Faster R-CNN 中, RoIPool (Region of interest pooling) 通过将候选区域划分为固定数量的子区^[17],然后对每个子区域进行最大池化操作来提取固定大小的特征图。然而,这种方法在划分和池化过程中会对候选区域的边界进行量化,从而引入量化误差。这些量化误差在某些情况下会导致特征对齐不精确,进而影响检测和分割的精度。

RoIAlign 是 Mask R-CNN 引入的一种新的区域特征对齐方法,用于替代 Faster R-CNN 中的 RoIPool,主要目的是解决量化误差问题,从而提高实例分割和目标检测的精度。RoIAlign 使用双线性插值的方法对候选区域进行精确对齐,将候选区域在原始特征图上的边界映射为连续坐标,而不是进行离散化,然后对每个子区域采用双线性插值方法计算出精确的特征值,考虑特征图上 4 个最接近的像素并根据它们的距离进行加权平均,从而得到更精确的特征值。RoIAlign 的引入显著提高了

Mask R-CNN 在实例分割和目标检测任务中的性能。由于消除了量化误差, RoIAlign 能够更准确地对齐候选区域和特征图,从而提高了特征提取的精度。

1.2 损失函数

Mask R-CNN 的损失函数^[18]由多个部分组成,以便同时优化不同的任务。这些部分包括分类损失、边界框回归损失和掩码损失,即

$$L = L_{\text{cls}} + L_{\text{box}} + L_{\text{mask}} \quad (1)$$

式中, L_{cls} 表示分类损失函数; L_{box} 表示边界框回归损失; L_{mask} 表示掩码损失函数。总损失函数中每个部分的权重可以根据具体的应用场景进行调整,以平衡不同任务之间的影响。通过优化这个综合损失函数, Mask R-CNN 模型能够在训练过程中同时学习物体的分类、边界框定位和像素级分割。

分类损失函数用于评估预测的类别标签与真实标签之间的差异,通常使用交叉熵损失函数来计算,即

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

式中, p_i 表示物体被识别为目标的置信度; p_i^* 是一个 0、1 函数,当物体为正例时, p_i^* 为 1, 否则为 0, 即只有当第 i 个框内物体为正例时,该锚点才对损失函数有贡献。

边界框回归损失函数用于评估预测的边界框与真实边界框之间的差异,通常使用 smooth L1 损失函数来计算,

$$L_{\text{box}}(t_i, t_i^*) = \sum_{i \in \{x, y, w, h\}} \text{smooth}_{L1}(t_i - t_i^*) \quad (3)$$

式中, t_i 是预测的边界框参数; t_i^* 是真实的边界框参数。smooth_{L1} 函数定义为

$$\text{smooth}_{L1}(x) = \begin{cases} 0.5x^2 & |x| < 1 \\ |x| - 0.5 & |x| \geq 1 \end{cases} \quad (4)$$

Mask R-CNN 模型中,为了得到更加精准的锚框坐标,不仅使用线性回归对目标区域坐标偏移量进行回归,还使用全卷积网络 (FCN) 输出每个类别的掩码。为了监督掩码分支的训练,模型引入了掩码分支损失函数, Mask R-CNN 中掩码分支使用的是平均二值交叉熵损失函数,

$$L_{\text{mask}}(m_i, m_i^*) = - \sum_{i=1}^N [m_i^* \log(m_i) + (1 - m_i^*) \log(1 - m_i)] \quad (5)$$

式中, m_i 表示物体被预测为目标的置信度; m_i^* 表示第 i 个掩码层中逐像素经过 Sigmoid 函数后的输出。这样避免了类间竞争,将分类任务交给分类函数, mask 层只区分掩码中的特定小类。

2 Mask R-CNN 的改进与技术路线

2.1 改进 Mask R-CNN

航空铸件实际检测过程不仅需要实现缺陷的分类和回归,还需要实现缺陷的分割,结合不同深度学习模型的检测精度、检测速度和实现原理,决定选择 Two-stage 算法中的 Mask R-CNN 模型^[18]。Mask R-CNN 一般采用 ResNet50 或 ResNet101 作为主干网络来提取图像特征,并通过 FPN 来提升特征提取性能,利用 RPN 对特征图按照一定规律生成系列锚定框并映射到特征图上,然后将结果输入 RoIAlign,依据损失函数实现分类、回归及掩码分割。

通过对航空铸件缺陷特征数据集的分析,发现铸件中缺陷如疏松、裂纹、高密度夹杂的缺陷特征比较

小,通常小于 32×32 像素,属于小目标检测。传统 Mask R-CNN 算法中,特征提取网络不断将特征图尺寸缩小,导致如果目标区域小于 32×32 像素,深度学习网络就无法学习到这类小目标特征,因此传统 Mask R-CNN 算法对微小缺陷进行检测时识别精度较差^[17,19]。针对这类问题,本文通过改进特征金字塔网络,增加特征信息统一模块和集成模块,对不同层次的特征信息进行有效集成,重新匹配原始特征层,使之具有更多特征信息。改进后的特征金字塔模型架构如图3所示,主要通过“同步-集成-匹配”的方法提高小目标的检测精度。具体做法是:首先通过上采样或者下采样方式将各特征层的分辨率统一并同步到中间层;其次通过特征信息集成模块集成各特征图,确保集成后特征分辨率与原始特征分辨率一样;然后基于集成后的特征信息去匹配原有特征信息,以实现特征信息的均衡化,使原始特征信息的分辨力更强,有助于提高小目标的识别精度^[20]。

特征信息集成模块由 $1 \times 1 \times N$ 和 $3 \times 3 \times N$ 两个卷积层构成,作用是集成特征图并降低其维度^[12,21-22]。利用经过特征尺寸统一模块和信息集成模块处理的特征,基于残差网络连接,重新匹配原始特征图,使之包含全部特征信息,提升小目标的检测能力。

2.2 技术路线

基于改进的 Mask R-CNN,采用一个完整的智能检测流程,包括图像的获取与预处理、数据增强、模型开发与训练、最终的检测结果分析。技术路线如图4所示。

待检测图像的获取是整个流程的基础。随后,图像预处理成为关键步骤,其中包括裁剪以去除无关背景、平移以调整图像位置、镜像以增加数据多样性。此外,图像的旋转和缩放等操作进一步增强了模型对不同图像尺

寸和方向的适应性,从而增强了模型对缺陷识别的准确性和鲁棒性。

为了进一步提升数据集的多样性并模拟实际应用中的复杂情况,采用了Overlap切片法和Mosaic图像技术作为数据增强手段。这些技术通过生成重叠的图像切片和组合来自不同图像的区域,不仅增加了数据量,而且提高了模型对新情况的泛化能力。

精确的缺陷特征标注对于模型训练至关重要。通过专业的标注工具,可以确保图像中缺陷的准确识别和分类。此外,合理划分数据集为训

练集、验证集和测试集,为模型的评估和优化提供了坚实的基础。

在模型开发阶段,设计并优化深度学习模型的架构是实现高效检测的关键。通过调整模型参数和损失函数,可以最小化检测误差,提高模型的检测性能。使用训练集对模型进行训练,并通过验证集评估其泛化能力,确保模型在未见数据上的表现。最终,使用测试集对模型进行全面评估,分析其在实际应用中的表现。通过准确率、召回率、F1分数等指标量化模型的性能,并识别潜在的改进空间。

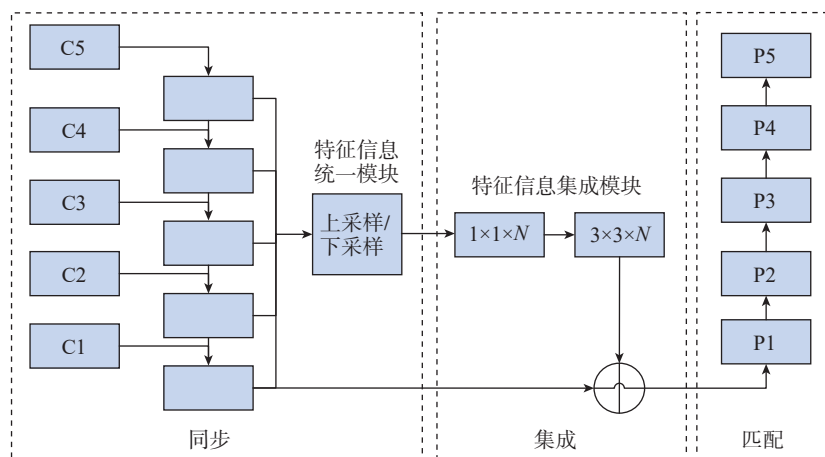


图3 改进后的FPN模型框架

Fig.3 Framework of the improved FPN model

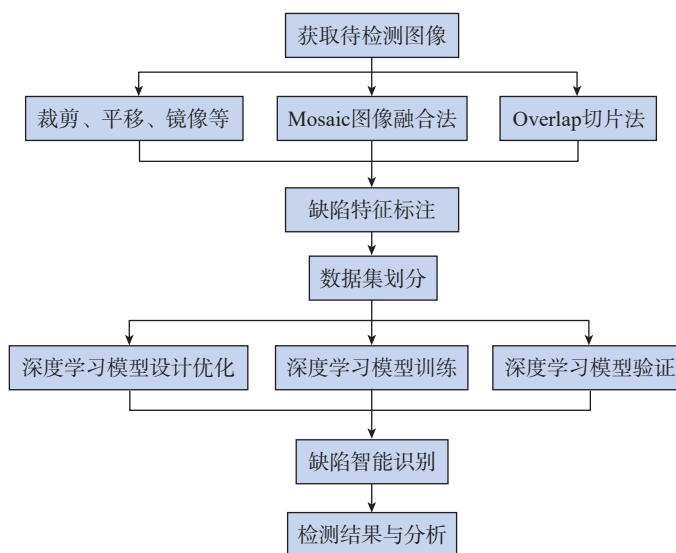


图4 基于深度学习的智能检测技术路线

Fig.4 Intelligent detection technology route based on deep learning

3 试验结果与分析

3.1 试验数据集

对航空铸件数字射线检测图像进行灰度变换、中值滤波和图像增强等预处理,确保减少图像部分噪声、提升原始图像质量并保留图像的原始细节特征,减少噪声对深度学习模型训练的影响。然后采用数据增广技术扩充训练数据集,本文在开发训练数据集中不仅采用了翻转、旋转、缩放、镜像、裁剪和平移等常规图像数据增广方法,还结合航空铸件缺陷微小、数字射线图像数据稀疏分布等特点,采用基于 Overlap 切图法和 Mosaic 图像融合的图像增广方法,得到新的缺陷数据图像,提升模型对微小缺陷的检测能力和模型泛化能力,如图 5 所示。

针对航空铸件,共收集 13800 幅数字射线图像原始数据,均为铝合金材质铸件,主要包括疏松、裂纹和高密度夹杂 3 类缺陷。典型缺陷数字射线图像如图 6 所示。

借助 labelme 工具对缺陷进行标注。labelme 是深度学习领域目前最为常用的开源标注工具,不仅标注缺陷的类型,也标注缺陷的外轮廓边缘,可以在图像分类、目标检测、语义分割、实例分割等多种任务中使用。

本文首先对收集整理的 13800 幅缺陷图像进行图像预处理,并通过翻转、旋转、缩放、镜像、裁剪、平移、Overlap 切图和 Mosaic 等图像增广方法扩展缺陷图像数量,最终得到 41400 幅图像,并使用标注工具 labelme 对这些图像进行标注,形成了航空铸件数字射线缺陷特征数据集。

3.2 试验环境与参数设置

基于构建的航空铸件数字射线缺陷特征数据集(包含图像和相应的标签文件),按照 8:1:1 划分为训练集、测试集和预测集,并采用 TensorFlow 深度学习框架、显卡 NVIDIA RTX A6000、AMD 锐龙

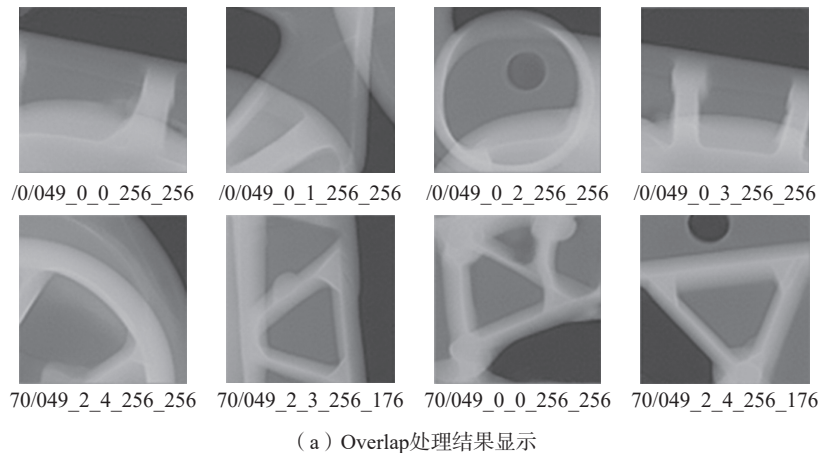
Threadripper 3975WX CPU,借助自行开发的深度学习智能检测算法平台训练、测试改进后的 Mask R-CNN 算法和传统 Mask R-CNN 算法,训练、评估与识别过程如图 7 所示。

训练过程中,选用基于随机梯度下降算法的优化器,采用交叉熵损失函数,权重衰减系数设为 10^{-5} ,动量值


设置为 0.9,初始学习率设置为 0.001,并对优化算法改进部分单独进行训练,之后将学习率调整为 0.0001,实现整体网络的微调。

3.3 试验数据分析

所提算法和传统 Mask R-CNN 算法在训练过程中的损失函数收敛情况如图 8 所示,准确率如图 9 所示。




(a) Overlap处理结果显示



(b) Mosaic处理结果显示

图 5 图像增广处理结果显示

Fig.5 Display of image augmentation processing results



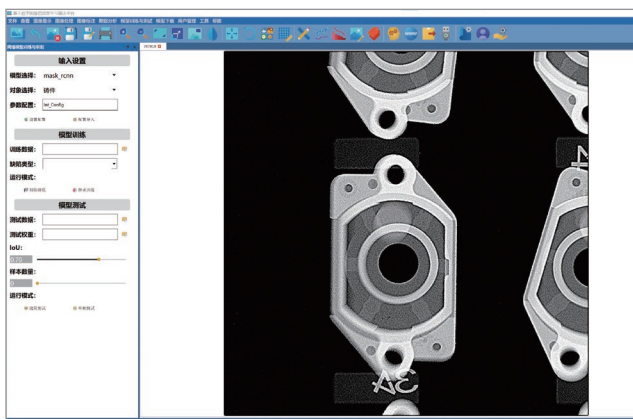
(a) 疏松

(b) 裂纹

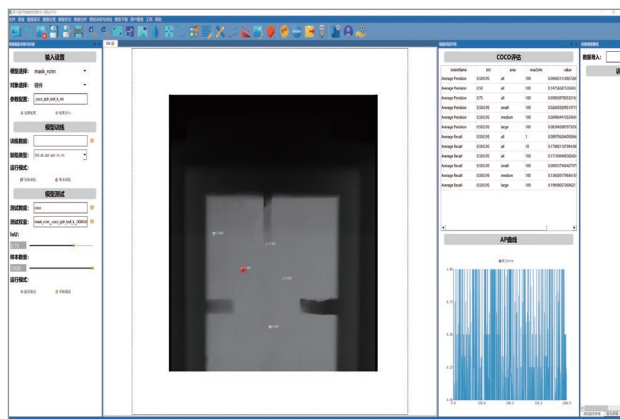
(c) 高密度夹杂

图 6 铸件典型缺陷数字射线图

Fig.6 Digital ray graphs of typical casting defects



(a) 深度学习优化算法训练和评估



(b) 缺陷智能识别

图7 深度学习优化算法训练、评估与识别


Fig.7 Training, evaluation, and recognition of the deep learning optimization algorithm

由图8和图9可知,算法模型在训练数据集和测试数据集上的发展趋势一致。通过图8损失函数曲线趋势可知,30000轮训练后算法模型的下降趋势趋于平稳,损失函数趋近最小,说明算法模型已收敛。随

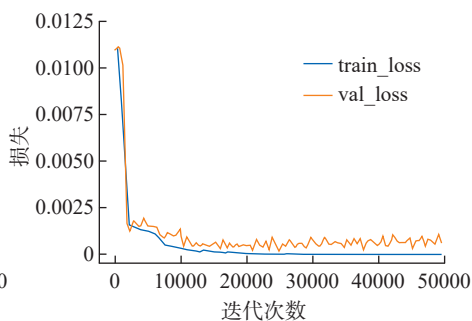
后采用测试数据集对训练好的算法模型进行测试,测试结果如图10所示,对各类缺陷进行了有效识别与分割^[23]。

另外针对疏松、裂纹及高密度夹杂3类缺陷,开展现场随机比对测试

试验,比对结果如表1所示。测试中将专业射线检测人员(射线Ⅲ级人员)判定的结果作为参考答案,并与传统Mask R-CNN检测结果进行对比统计。结果表明,所提算法对航空铸件中的疏松、裂纹及高密度夹杂3类缺陷的检测精度可达93.25%,召回率可达96.51%,缺陷识别的结果与专业人员的人工检测结果基本一致,优于传统Mask R-CNN算法的检测结果^[24]。



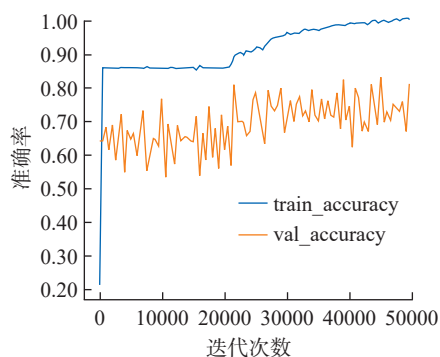
(a) 传统Mask R-CNN算法




(b) 所提算法

图8 损失函数收敛情况

Fig.8 Convergence of the loss function



(a) 传统Mask R-CNN算法



(b) 所提算法

图9 训练准确率情况

Fig.9 Training accuracy rate




图10 优化算法检测铸件缺陷的结果

Fig.10 Casting defects detected by the optimization algorithm

表1 所提算法与传统 Mask R-CNN 算法、人工检测效果的对比

Table 1 Comparison of the proposed algorithm with the traditional Mask R-CNN algorithm and the manual detection effect

缺陷类别	人工检测	本文算法				传统 Mask R-CNN 算法			
	标准数量	识别数量	识别准确数量	精度/%	召回率/%	识别数量	识别准确数量	精度/%	召回率/%
疏松	45	47	44	93.62	97.78	46	41	89.13	91.11
裂纹	28	29	27	93.10	96.43	26	23	88.46	89.29
高密度夹杂	13	13	12	92.31	92.31	12	10	83.33	84.61
总计	86	89	83	93.25	96.51	84	74	88.10	86.0

4 结论

面向航空铸件数字射线检测图像,利用剪切、翻转、Overlap 切图和 Mosaic 等数据增强技术实现缺陷特征数据集的开发,针对传统 Mask R-CNN 算法对小目标检测效果不佳的现状,开展了融合全局特征金字塔网络的 Mask R-CNN 算法的改进设计,并利用航空铸件数字射线缺陷数据集对该改进算法进行了测试与验证试验。试验结果表明,该改进模型算法的检测精度达 93.25%,召回率可达 96.51%,相比传统 Mask R-CNN 算法模型,精度提升了 5.15 百分点,召回率提升了 10.51 百分点,缺陷识别的结果与专业人员的工检测结果基本一致。所提算法能够准确识别航空铸件数字射线图像小目标缺陷,有效改善了传统 Mask R-CNN 算法的小目标检测效果,检测效果良好。下一步将在不改变模型结构及不引入其他超参数的情况下,采用深度可分离卷积对 Mask R-CNN+GFPN 进行轻量化处理,以进一步提高检测速度,促进该方法在航空航天检测领域中的应用。

参考文献

[1] 工业和信息化部. 智能检测装备产业发展行动计划(2023—2025 年)[EB/OL]. (2023-02-21)[2024-05-15]. <https://www.gov.cn/zhengce/zhengceku/2023-02/23/5743016/files/fabeccdce334aac818e85b038e54944.pdf>.

Ministry of Industry and Information

Technology. Action plan for the development of intelligent testing equipment industry (2023—2025)[EB/OL]. (2023-02-21)[2024-05-15]. <https://www.gov.cn/zhengce/zhengceku/2023-02/23/5743016/files/fabeccdce334aac818e85b038e54944.pdf>.

[2] 陈银, 郝田义, 彭寒. 基于图像特征融合的航空装备多属性维修决策方法[J]. 制造业自动化, 2022, 44(10): 170-173.

CHEN Yin, HAO Tianyi, PENG Han. Multi-attribute maintenance decision method for aviation equipment based on image feature fusion[J]. Manufacturing Automation, 2022, 44(10): 170-173.

[3] 陈新波, 袁英民, 李小丽, 等. 航空发动机内部损伤智能诊断系统研制[J]. 无损检测, 2016, 38(4): 70-73.

CHEN Xinbo, YUAN Yingmin, LI Xiaoli, et al. Development of intelligent diagnostic system for internal damage of aero engine[J]. Nondestructive testing, 2016, 38(4): 70-73.

[4] 张杰, 王淑侠, 何卫平, 等. 航空发动机叶片装配执行过程智能检测及 AR 引导[J]. 计算机集成制造系统, 2024, 30(4): 1263-1272.

ZHANG Jie, WANG Shuxia, HE Weiping, et al. Intelligent detection and AR guidance in the assembly and execution process of aero engine blades[J]. Computer Integrated Manufacturing System, 2024, 30(4): 1263-1272.

[5] 何宇豪, 曹学国, 刘信良, 等. 基于 SW-YOLO 模型的航空发动机叶片损伤实时检测[J]. 推进技术, 2024, 45(2): 197-203.

HE Yuhao, CAO Xueguo, LIU Xinliang, et al. Real-time detection of aircraft engine blade damage based on SW-YOLO model[J]. Propulsion Technology, 2024, 45(2): 197-203.

[6] QU Y, WANG C, XIAO Y L, et al. Optimization algorithm for surface defect detection of aircraft engine components based on YOLOv5[J]. Applied Sciences, 2023, 13(20): 11344.

[7] 樊玮, 李晨炫, 邢艳, 等. 航空发动机

损伤图像的二分类到多分类递进式检测网络[J]. 计算机应用, 2021, 41(8): 2352-2357.

FAN Wei, LI Chenxuan, XING Yan, et al. Binary to multi-classification progressive detection network for aeroengine damage images[J]. Computer Applications, 2021, 41(8): 2352-2357.

[8] WONG C Y, SESHADRI P, PARKS G T. Automatic borescope damage assessments for gas turbine blades via deep learning[C]//AIAA Scitech 2021 Forum, VIRTUAL EVENT. Reston, Virginia: AIAA, 2021: 1488.

[9] SHANG H B, SUN C, LIU J X, et al. Deep learning-based borescope image processing for aero-engine blade in situ damage detection[J]. Aerospace Science and Technology, 2022, 123: 107473.

[10] HE K M, GKIOXARI G, DOLLÁR P, et al. Mask R-CNN[C]//2017 IEEE International Conference on Computer Vision (ICCV). Piscataway, NJ: IEEE, 2017: 2980-2988.

[11] LI C, HUANG F Z, YANG Z X, et al. Target detection algorithm based on feature optimization and sample equalization[M]//Wireless Algorithms, Systems, and Applications. Cham: Springer Nature Switzerland, 2022: 343-355.

[12] LIU S, QI L, QIN H F, et al. Path aggregation network for instance segmentation[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition, Piscataway, NJ: IEEE, 2018: 8759-8768.

[13] YU L Y, WANG Z, DUAN Z J. Detecting gear surface defects using background-weakening method and convolutional neural network[J]. Journal of Sensors, 2019, 2019(1): 3140980.

[14] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Piscataway, NJ: IEEE, 2016: 770-778.

[15] 葛轶洲, 刘恒, 王言, 等. 小样本困

境下的深度学习图像识别综述[J]. 软件学报, 2022, 33(1): 193–210.

GE Yizhou, LIU Heng, WANG Yan, et al. A review of deep learning image recognition in the small-sample dilemma[J]. Journal of Software, 2022, 33(1): 193–210.

[16] HENAFF O J, SRINIVAS A, DE FAUW J, et al. Data-efficient image recognition with contrastive predictive coding[J]. Proceedings of the 37th International Conference on Machine Learning, 2020: 4182–4192.

[17] 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.

[18] LI Z M, PENG C, YU G, et al. Light-head R-CNN: In defense of two-stage object detector[EB/OL]. (2017–11–23)[2024–05–15]. <https://arxiv.org/abs/1711.07264>.

[19] BACHMAN P, HJELM R D, BUCHWALTER W. Learning representations by maximizing mutual information across views[C]// Proceedings of the 33rd Conference on Neural Information Processing Systems. New York: Curran Associates, 2019, 15071.

[20] 文韬, 周稻祥, 李明. Mask R-CNN 中特征不平衡问题的全局信息融合方法[J]. 计算机工程, 2021, 47(3): 256–260, 268.

WEN Tao, ZHOU Daoxiang, LI Ming. Global information fusion method for feature imbalance problem in Mask R-CNN[J]. Computer Engineering, 2021, 47(3): 256–260, 268.

[21] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640–651.

[22] 高宏伟, 韩晓红, 周稻祥. 基于改进 Faster R-CNN 的超新星目标检测方法[J]. 计算

机工程, 2020, 46(10): 282–288.

GAO Hongwei, HAN Xiaohong, ZHOU Daoxiang. Supernova target detection method based on improved Faster R-CNN[J]. Computer Engineering, 2020, 46(10): 282–288.

[23] 刘聪. 基于卷积神经网络的微小零件表面缺陷检测技术研究[D]. 哈尔滨: 哈尔滨理工大学, 2019.

LIU Cong. Research on surface defects detection of micro parts based on convolutional neural network[D]. Harbin: Harbin University of Science and Technology, 2019.

[24] 缪寅宵, 孙增玉, 杨奕, 等. 基于深度学习的X射线胶片数字化与缺陷检测算法[J]. 航空制造技术, 2023, 66(7): 50–56, 72.

MIAO Yinxiao, SUN Zengyu, YANG Yi, et al. X-ray film digitization and defect detection algorithm based on deep learning[J]. Aeronautical Manufacturing Technology, 2023, 66(7): 50–56, 72.

Aviation Casting Intelligent Detection Technology Based on Improved Mask R-CNN

ZHANG Xiangchun^{1,2}, PENG Wensheng^{1,2}, CHU Junyi^{1,2,3}, ZENG Zhaoyang^{1,2}, WANG Zhenyu^{1,2,4}, WEI Mingxian¹, XU Ran¹

(1. China Aero-Polytechnology Establishment, Beijing 100028, China;

2. Aviation Key Laboratory of Science and Technology on Aero Combined Environment, Beijing 100028, China;

3. Chongqing University, Chongqing 400044, China;

4. Dalian University of Technology, Dalian 116024, China)

[ABSTRACT] In view of the lack of effective intelligent detection methods due to the complex causes of quality defects, the variety of defect features, and the high detection requirements in the development and production of aviation products, this paper first systematically reviews the research status of the intelligent detection technology of aviation equipments, and summarizes the ideas and implementation methods for the research of intelligent detection methods for this application scenario and specific defect characteristics. Secondly, an improved Mask R-CNN algorithm fused with global feature pyramid network is designed, and a digital radiographic detection defect feature dataset for aviation castings is constructed by using data augmentation techniques such as cutting, flipping, Overlap and Mosaic for aviation castings with complex defect features and high detection requirements. Finally, the improved algorithm and the constructed dataset are used to test and verify three types of defects in aviation castings, including porosity, cracks, and high-density inclusions. The experimental results show that the detection accuracy of the improved algorithm is 93.25% and the recall rate is 96.51%, having a good detection effect.

Keywords: Deep learning; Intelligent detection; Aviation casting; Mask R-CNN; Global feature pyramid network; Data expansion

(责编 青燕)