

改进 U-Net 模型的 A356 合金铸造轮毂内部缺陷检测

张俊生^{1,2} 赫英凤¹ 杨 鹏¹ 全晓刚¹

(1.太原工业学院电子工程系;2.中北大学信息探测与处理山西省重点实验室)

摘 要 A356 合金轮毂在低压铸造生产过程中,容易出现气孔、缩孔等内部缺陷,需要使用 X 射线无损探伤设备来检测。轮毂 X 射线检测的核心问题是缺陷自动判定,引入深度卷积神经网络中的 U-Net 模型作为框架,结合 VGG 模型改进编码器和解码器,在构建的数据库上展开缺陷自动识别研究。在准确定义轮毂缺陷检测识别率、误判率和漏判率的基础上,发现改进 U-Net 模型的性能与原始 U-Net 模型相比明显提升,缺陷识别率达到 96.15%,满足实际检测需求。

关键词 A356 合金轮毂;X 射线;缺陷检测;U-Net 模型;VGG 模型

中图分类号 TP391.4;TP311;TG146.21;TG249.2 **文献标志码** A

DOI:10.15980/j.tzzz.2023.07.019 **开放科学(资源服务)标识码(OSID):**



Internal Defect Detection of A356 Alloy Casting Hub Based on Improved U-Net Model

Zhang Junsheng^{1,2}, He Yingfeng¹, Yang Peng¹, Tong Xiaogang¹

(1.Department of Electronic Engineering, Taiyuan Institute of Technology;

2.Shanxi Key Laboratory of Signal Capturing & Processing, North University of China)

Abstract: In the process of low-pressure casting, A356 alloy hubs easily generate internal defects such as gas hole and shrinkage porosities, which need to be detected online by X-ray nondestructive testing. The key problem of hub X-ray detection is the automatic determination of defects. The U-Net model in deep convolution neural network is introduced as framework, and the encoder and decoder are improved combined with VGG model. The automatic identification of internal defects was carried out on the constructed database. On the basis of accurately defining the recognition rate, misjudgment rate and missed detection rate, it is found that the performance of the improved U-Net model is significantly improved compared with the original U-Net model, and the defect recognition rate reaches 96.15%, meeting the actual detection requirements.

Key Words: A356 Alloy Hub, X-ray, Defect Detection, U-Net Model, VGG Model

轮毂作为汽车的重要构成部件和主要受力部件,主要有钢质轮毂和铝质轮毂两类,制造工艺多采用锻造成形和铸造成形等。随着汽车轻量化的不断推广,低压铸造生产的 A356 铝合金轮毂成为目前市场上的主流产品^[1]。为了进一步提高轮毂的品质,研究者从材料构成、工艺参数改进、计算机数值模拟等角度出发,分析了影响轮毂性能的众多因素^[2-4],其中合金液冷却成形的过程中容易出现气孔、缩孔或缩松等内部缺陷,需要通过 X 射线无损检测技术来解决^[5-6]。汽车轮毂 X 射线检测的核心工作是准确判断被检轮毂有无缺陷以及缺陷的等级大小,传统的人工判定方式具有劳动强度大、检测结果主观性强、难以量化等缺点,因此使用图像处理算法来实现缺陷的自动判定成为研究热点^[7-8]。

深度卷积神经网络技术的飞速发展大大提升了图像处理领域中目标识别的准确率^[9-10],同时也给汽车轮毂内部缺陷自动检测带来了新的解决思路^[11-12]。本研究基于汽车轮毂 X 射线图像缺乏大型数据库、工控机上运行实时性要求高的特点,提出使用深度学习中改进 U-Net 模型进行缺陷自动识别的技术方案,并在现有的数据上验证了其有效性,为轮毂的自动检测提供参考。

1 U-Net 模型的结构及特点

U-Net 模型最早诞生于 2015 年,其构建了完整的编码器-解码器结构来实现目标物体的语义分割,在样本数据较少的生物医学图像领域取得了良好效果^[13]。U-Net 模型的基本结构见图 1,左边的编码器使用卷积

收稿日期:2022-08-18;修改稿收到日期:2022-11-09
基金项目:山西省高等学校科技创新资助项目(2020L0624,2020L0672);信息探测与处理山西省重点实验室开放基金资助项目(ISPT2020-5);山西省重点研发计划资助项目(201803D121069);太原工业学院引进人才科研资助项目(2021XKLG01,2022KJ003)
第一作者简介:张俊生,男,1981 年出生,副教授,太原(030008),E-mail:zhangjs@tit.edu.cn
引用格式:张俊生,赫英凤,杨鹏,等.改进 U-Net 模型的 A356 合金铸造轮毂内部缺陷检测[J].特种铸造及有色合金,2023,43(7):959-962.
ZHANG J S, HE Y F, YANG P, et al. Internal defect detection of A356 alloy casting hub based on improved U-Net model[J]. Special Casting & Nonferrous Alloys, 2023, 43(7):959-962.

层和池化层逐步提取特征,把输入大小为 512×512 的单通道图像经过 4 次压缩,每次压缩时通道数增加 1 倍,最后得到大小为 $28 \times 28 \times 1\,024$ 的特征图,完成输入图像的特征提取工作。U-Net 模型右边的解码器使用转置卷积来分层恢复目标的细节和空间维度,从最底层的特征图开始经过 4 次 2×2 大小的转置卷积操作,在采样的过程中拷贝和裁剪同层传递过来的特征数据,叠加在自身数据上并把通道数减少为原来的一半,最后将 $28 \times 28 \times 1\,024$ 大小的特征图恢复为 $388 \times 388 \times 64$,通过 1×1 的卷积操作合并为 $388 \times 388 \times 2$ 的输出图,分别代表目标和背景,完成最后的语义分割。




图 1 U-Net 模型的网络结构^[13]

Fig.1 Network structure of U-Net model^[13]

U-Net 模型用于训练的原始数据只有几十张图片,通过旋转、平移、裁剪、随机弹性形变等方法进行数据增强,在背景相似的医学图像语义分割上性能良好,但拓展到其他领域时容易出现收敛速度慢、目标边缘分割不够精确等问题,实际应用中经常通过改进编码器来提升性能。VGG 模型是在图像语义分割领域中被广泛使用的编码器,其使用 3×3 大小、步长为 1 的卷积运算加 ReLu 激活函数构成卷积层,使用 2×2 大小、步长为 2 的最大池化运算构成池化层,卷积层和池化层反复堆叠来加深网络结构,在大型数据集上被证明具有良好的通用特征提取能力。本研究以 VGG 模型为基础构成轮毂缺陷的特征提取器,借助于 U-Net 模型的对称网络结构实现图像重构,完成轮毂内部缺陷的自动检测。

2 改进 U-Net 模型的构成

2.1 编码器设计

从图 1 中可以看到,U-Net 模型的编码器可以视为 4 个模块,每个模块都是由 2 个 3×3 的卷积层和 1 个 2×2 的最大池化层构成,再加上底部的 2 个卷积层,一共由 10 个卷积层、4 个池化层组成。按照深度卷积神经网络理论中层数越深特征提取能力越强的基本理论,本次试验选择 VGG 模型中的 VGG16 作为编码器,具

体来说是去掉 VGG16 模型中的 3 个全连接层,保留剩余 13 个 3×3 的卷积层进行特征提取,中间通过 2×2 的最大池化层进行特征压缩,网络结构见图 2。




图 2 改进编码器的结构

Fig.2 Improved encoder structure

2.2 解码器设计

U-Net 模型的解码器同样可以视为 4 个模块,从网络底部 2×2 的上采样转置卷积开始,每个模块由 1 个 2×2 的上采样转置卷积层和 2 个 3×3 的卷积层构成,最后通过 1×1 的卷积运算合并恢复的特征,输出分割结果。按照 U-Net 模型对称网络结构的特点,每个模块在上采样转置卷积后接收对应编码器模块的特征,组合后再进行 3×3 的卷积运算,同时每个卷积层进行批量标准化的 BN 运算,改进之后的解码器见图 3。




图 3 改进解码器的结构

Fig.3 Improved decoder structure

2.3 改进 U-Net 模型的完整网络结构

改进之后的编码器和解码器按照 U-Net 模型的对称结构组合起来,完整的网络见图 4。各个卷积层旁边未明确标识特性图大小和通道数目,具体与图 2、图 3 中保持一致。编码器输入 512×512 大小的单通道轮毂 X 射线图像,经过 5 个模块的卷积池化运算,在模型底部形成 $16 \times 16 \times 1\,024$ 大小的抽象特征,再经过 5 次上采样转置卷积运算,将抽象特征恢复为 $512 \times 512 \times 64$ 大小的图像,最后通过 1×1 的卷积运算合并后输出缺陷的提取结果。




图 4 改进 U-Net 模型的结构

Fig.4 Improved U-Net model structure

改进的 U-Net 模型与原始 U-Net 模型相比,加深了编码器的网络深度,由原来的 10 个卷积层拓展到 14

层,同时卷积运算采用有填充的方式进行,使得输入特征图与输出特征图大小一致,边界处理效果更好。

3 试验与结果分析

3.1 试验数据

试验数据来源于 GDXray^[15]数据库和研究过程中自行采集的轮毂射线图像。GDXray 数据集共包含 5 组 X 射线图像,其中轮毂 X 射线图像共 1 626 张。研究过程中分别使用图像增强器和平板探测器采集不同型号轮毂的 X 射线图像 1 182 张,共同构成了试验的基础数据,见表 1。

表 1 轮毂 X 射线图像数据库

Tab.1 X-ray image database of wheel hub		
图像来源	图像分辨率	图像数量
GDXray	768×572	1 626
图像增强器	768×576	1 049
平板探测器	1 024×1 024	133
合计		2 808

3.2 试验环境

试验环境搭建充分考虑轮毂内部缺陷检测的实际工业运行环境,在硬件上选择以通用电脑配置为主的运行平台,尽量接近工业应用中的工控机配置,其核心部件的基本参数为:英特尔 i9-9900K@3.60 GHz CPU 处理器,英伟达 GeForce RTX 2080ti GPU 处理器,32 G DDR4 内存,1 T 固态硬盘,华硕 ROG STRIX Z390-H 主板。在软件环境配置上采用 64 位的 Windows10 操作系统,开发语言采用 Python 3.9.12,算法平台采用 TensorFlow 和 Keras 的 2.6.0 版本,GPU 驱动采用 Cuda10.0 版本和 Cudnn7.4.2 版本。

3.3 评价指标

汽车轮毂内部缺陷的质量检测目前尚无国家标准或行业标准可供使用,工业检测中常用的缺陷识别率、误判率和漏判率缺乏统一、科学的定义。假设待检测的轮毂 X 射线图像共有 L 张,其中 P 张图像经判定存在缺陷,剩余的 N 张图像不存在缺陷,则算法判断的结果共有真正例 T_P 、真负例 T_N 、假正例 F_P 和假负例 F_N 4 种情况。在此基础上定义试验的相关评价指标如下。

(1)缺陷识别率 缺陷识别率也即模型的正确率,用来衡量系统的缺陷检测性能,定义为算法正确判断的图像占有所有图像的比例大小。在本次测试中计算公式为:

$$acc = \frac{T_P + T_N}{T_P + T_N + F_P + F_N} = \frac{T_P + T_N}{L} \quad (1)$$

(2)缺陷误判率 缺陷误判指 X 射线图像上本来没有缺陷但被算法判断为有缺陷,对应于 4 种输出结果中的假正例情况,共有 F_P 张图像。缺陷误判率定义为

缺陷误判图像所占总图像的比例大小,本次测试中的计算公式为:

$$r_{F_P} = \frac{F_P}{T_P + T_N + F_P + F_N} = \frac{F_P}{L} \quad (2)$$

(3)缺陷漏判率 缺陷漏判指 X 射线图像上本来有缺陷但算法判定为没有缺陷,对应于 4 种输出结果中的假负例情况,共有 F_N 张图像。缺陷漏判率定义为缺陷漏判图像所占总图像的比例大小,本次测试中的计算公式为:

$$r_{F_N} = \frac{F_N}{T_P + T_N + F_P + F_N} = \frac{F_N}{L} \quad (3)$$

3.4 试验过程与结果分析

3.4.1 试验数据的预处理与模型迁移训练

在构建轮毂 X 射线图像的数据库之后,需要对其进行一系列的预处理操作,才能输入到搭建的网络模型中进行训练和测试。对数据库的图像进行灰度归一化和翻转、平移、灰度调整等强化处理,最终将图像数量由 2 808 扩充到 3 900,同时使用开源软件 LabelMe 对图像进行缺陷标注,最后把大小不同的图像统一缩减到为 512×512。

为了更好地对比改进模型的性能,本次训练使用迁移学习的方式同时对原始 U-Net 模型和改进 U-Net 模型进行,也即使用各自预训练好的权重系数作为初始参数来训练。改进 U-Net 模型解码器的参数使用 He 参数初始化的方法初始化,每个卷积层都进行批量标准化运算,最后一层使用 softmax 函数作为分类函数,配合交叉熵损失函数来计算输出的实际误差。

输入模型的 3 900 张轮毂 X 射线图像按照 70% 训练集、10% 验证集、20% 测试集的比例划分,三者互不重叠,打包为 TFRecord 格式的标准数据,以 16 为批次大小依次送入模型。训练过程中参数更新的优化器采用 Adam 算法,学习率设置为固定的 0.001,当验证集上的精度不再提升时就停止训练,作为模型的最终结果。改进的 U-Net 模型在上述训练参数设置下,最终通过 92 轮、65.2 h 的训练后交叉熵损失函数取值达到最小,训练结束;原始 U-Net 模型最终训练轮数为 76,用时 47.3 h,输出误差达到最小。

3.4.2 试验结果分析

训练完成的两个模型分别在测试集上的 78 张图像上进行测试。U-Net 模型能够准确识别其中 64 张图像,有 9 张图像被误判,5 张图像被漏判;改进的 U-Net 模型可以准确识别 75 张图像,有 3 张被误判,没有漏判图像。将上述数据使用评价指标量化,见表 2,最后一列的运行时间是 78 张测试图像的平均耗时。

选择测试过程中的部分图像来直观比较两个模型

表 2 模型的测试技术指标
Tab.2 Test technical indexes of model

模型名称	识别率/%	误判率/%	漏判率/%	运行时间/ms
U-Net	82.05	11.54	6.41	396.4
改进 U-Net	96.15	3.85	0	436.2

的识别效果,具体见图 5。图 5a、图 5e 和图 5i 是为了显示方便统一裁剪后的原始 X 射线图像,目标区域位于




图 5 部分轮毂图像的试验结果

Fig.5 Experimental results of partial wheel images

从表 2 和图 5 可以看到,改进 U-Net 模型在缺陷检测的识别、漏判和误判方面,性能均要优于原始 U-Net 模型。虽然改进 U-Net 模型在运行时间上比原始 U-Net 模型多 39.8 ms,但轮毂内部缺陷实时检测一般要求 1~2 s 之内完成一副 X 射线图像的采集和识别,上述时间差异在实际检测中可以忽略不计。

4 结 论

提出一种以 U-Net 模型为网络主体结构、结合 VGG 模型优化编码器和解码器的轮毂 X 射线图像缺陷检测方案,在构建的数据集上进行训练和测试。结果表明该方案缺陷识别率为 96.15%,误判率为 3.85%,漏判率为 0,识别一副图像平均用时 436.2 ms,能够满足轮毂在线实时检测的精度要求和速度要求。

参 考 文 献

[1] 吴国荣,陈旭辉.汽车轮毂材料轻量化与造型设计研究[J].材料导报, 2021, 35(19): 19 181-19 185.
[2] 任凯,冯立超,孙立,等.低压铸造铝合金轮毂的研究现状[J].热加工工艺, 2021, 50(9): 10-15.

图像的中心部位;图 5b、图 5f 和图 5j 为手工标注结果,白色区域为缺陷区域,不存在缺陷则为全黑的图像。对比可以看到,对于缺陷明显的图像,两个模型都可以做到准确检测;对于不存在缺陷的图像,U-Net 模型出现了误判;对于缺陷区域形状复杂的图像,U-Net 模型出现了漏判。

[3] 毛建辉,张玉贤,姜路文,等.A356 铸造铝合金轮毂组织与性能分析[J].中国冶金, 2021, 31(5): 66-71.
[4] 姜巨福,王迎,肖冠菲,等.A356 铝合金挤压铸造过程数值模拟与试验验证[J].特种铸造及有色合金, 2020, 40(7): 697-703.
[5] 刘军,陶维道.X 射线数字成像技术在铸造铝合金轮毂检测中的应用[J].无损探伤, 2017, 41(3): 42-44.
[6] 焦腾云.基于 X 射线图像的轮毂铸件缺陷检测技术研究[D].太原: 中北大学, 2020.
[7] 楼国红,张俊生,郭晋秦.铝合金轮毂内部缺陷的定量分析[J].特种铸造及有色合金, 2018, 38(7): 787-789.
[8] 傅可清,马源,伍缘杰,等.铝合金压铸件 X 射线成像典型缺陷特征提取算法与实现[J].特种铸造及有色合金, 2021, 41(12): 1 472-1 477.
[9] 张顺,龚怡宏,王进军.深度卷积神经网络的发展及其在计算机视觉领域的应用[J].计算机学报, 2019, 42(3): 453-482.
[10] 罗会兰,张云.基于深度网络的图像语义分割综述[J].电子学报, 2019, 47(10): 2 211-2 220.
[11] 曹富强,王明泉,张俊生,等.基于深度学习的铸件 X 射线图像分割研究[J].应用光学, 2021, 42(6): 1 025-1 033.
[12] 鲍春生,谢刚,王银,等.基于深度学习的铸件缺陷检测[J].特种铸造及有色合金, 2021, 41(5): 580-584.
[13] MERY D, VLADIMIR R, UWE Z, et al. GDXray: The database of X-ray images for nondestructive testing[J]. Journal of Non-destructive Evaluation, 2015, 34(4): 1-12.

(编辑:张正贺)