

基于深度学习的铝合金轮毂铸件图像缺陷检测

闫学顺¹ 汪东红² 吴文云¹ 姜 森³ 邱慧慧⁴ 龚潜海⁵ 疏 达²

(1.上海工程技术大学材料科学与工程学院;2.上海交通大学材料科学与工程学院;3.嘉善鑫海精密铸件有限公司;
4.湖州鼎盛机械科技股份有限公司;5.浙江佳力风能技术有限公司)

摘 要 基于传统 X 射线图像的铝合金轮毂铸件缺陷检测方法存在人工检测效率低、误检率高、检测精度较差等问题,提出一种基于深度学习的铝合金轮毂铸件图像缺陷检测方法。通过引入直方图均衡化方法,实现 533 组铝合金铸件 X 射线图像缺陷特征增强;同时基于 Mosaic 数据增广策略随机生成含有多尺度不同缺陷类型的新图像数据,提升图像的复杂度;修改了 YOLOv5 主干网络,引入 SENet 注意力机制模块对输入特征图的重要通道进行特征提取增强。结果表明,该方法对铸件缺陷平均检测精度(mAP)达到了 99.6%,对比 YOLOv3、YOLOv4 以及 YOLOv5 主流算法,平均检测精度分别提升了 9%、5.1%、4.2%。相较于原网络模型,常见的 4 种类型(气孔、缩松、裂纹、夹杂)铸件缺陷平均检测精度提升了 10.83%。该方法具有更好的泛化能力,可实现铸件多类型缺陷的自动检测,能够满足工业实际需求。

关键词 铝合金铸件;缺陷检测;深度学习;X 射线图像;注意力机制

中图分类号 TG146.21;TP311

文献标志码 A

DOI:10.15980/j.tzzz.2023.04.005

开放科学(资源服务)标识码(OSID):



Image Defect Detection of Aluminum Alloy Wheel Hub Casting Based on Deep Learning

Yan Xueshun¹, Wang Donghong², Wu Wenyun¹, Jiang Miao³, Qiu Huihui⁴, Gong Qianhai⁵, Shu Da²

(1.School of Materials Science and Engineering, Shanghai University of Engineering Science; 2.School of Materials Science and Engineering, Shanghai Jiaotong University; 3.Jiashan Xinhai Pecision Casting Co., Ltd.;
4.Huzhou Dingsheng Machinery Technology Co., Ltd.; 5.Zhejiang Jiali Wind Energy Technology Co., Ltd.)

Abstract: Considering the existing problems of traditional X-ray image defect detection method for aluminum alloy hub castings, such as low manual detection efficiency, high error detection rate, and poor detection accuracy, a new method for aluminum alloy hub castings was proposed based on deep learning. By introducing the histogram equalization method, defect feature enhancement of 533 groups of X-ray images of aluminum alloy castings were achieved. Meanwhile, new image data with multi-scale and different defect types were generated randomly based on mosaic data augmentation strategy to improve the complexity of the image. The YOLOv5 backbone network was modified, and the SENet attention mechanism module was introduced to enhance the feature extraction of the important channels of the input feature map. The results indicate that the average detection accuracy(mAP) for casting defects reaches 99.6%, which is improved by 9%, 5.1% and 4.2%, respectively, compared with the mainstream algorithms of YOLOv3, YOLOv4 and YOLOv5. Compared with the original network model, the average detection accuracy of the four common types of casting defects(blowhole, porosity, crack and slag inclusion) is improved by 10.83%. The method possesses desirable generalization ability, which can realize the automatic detection of multiple types of defects in castings, and meet the actual demand of industry.

Key Words: Aluminum Alloy Castings, Defect Detection, Deep Learning, X-ray Image, Attention Mechanism

近年来,基于深度学习的研究在材料领域不断发展,在材料的微观组织分析、加工制备设计、表面粗糙度预测以及缺陷检测等方面均取得了重要的研究成果。一方面,深度学习网络可用于零件材料表面粗糙度的预

收稿日期:2022-05-30;修改稿收到日期:2022-07-07
基金项目:国家重点研发计划资助项目(2020YFB1710101,2022YFB3706800);国家科技重大专项资助项目(J2019-VI-0004-0117);国家自然科学基金资助项目(51821001,52074183,52090042);浙江省重点研发计划资助项目(2020C01056,2021C01157,2022C01147);长寿命高温材料国家重点实验室开放基金资助项目(DECSKL202109)
第一作者简介:闫学顺,男,1996 年出生,硕士研究生,上海(201620),E-mail:yanxueshun2022@163.com
通信作者:汪东红,男,1984 年出生,副研究员,上海(200240),E-mail:wangdh2009@sjtu.edu.cn
引用格式:闫学顺,汪东红,吴文云,等. 基于深度学习的铝合金轮毂铸件图像缺陷检测[J]. 特种铸造及有色合金,2023,43(4):457-463.
YAN X S, WANG D H, WU W Y, et al. Image defect detection of aluminum alloy wheel hub casting based on deep learning[J]. Special Casting & Nonferrous Alloys, 2023, 43(4):457-463.

测领域,从而实现表面粗糙度的准确预测^[1];另一方面,利用卷积神经网络模型也可以进行材料行为和加工制备的方法设计^[2]。此外,深度学习在材料缺陷检测领域取得了飞速发展,在缺陷的分类、定位等方面均取得了有益的结果^[3]。特别是随着航空航天、汽车等相关领域迅猛发展,铸件的需求也在不断增长,其品质直接影响到生产生活的各个方面。在实际生产过程中,受不同制造工艺的限制,不可避免地产生大量具有缺陷的铸件。因此,提高缺陷检测的精度,减少漏检、误检十分重要。目前,国内的汽车轮毂厂商大多采用人工评定铸件的品质。通过分析铸件 X 射线图像中的不同像素特征,对气孔、裂纹等缺陷进行分析^[4]。传统 X 射线图像的轮毂缺陷检测方法存在人工识别不稳定、误检率高、检测精度较低等问题。随着工业缺陷检测技术的不断进步,目前基于传统机器视觉和深度学习的检测法已经得到了广泛应用,提高了铸件缺陷的识别精度,大大节省了检测成本。

传统的机器视觉方法,通过提取图像的纹理、颜色、轮廓等作为缺陷检测特征,并利用支持向量机 SVM 或神经网络来实现对目标缺陷的分类^[5]。KAMALA-KANNAN A 等^[6]为了克服图像灰度形态变化而导致内部缺陷分割困难的问题,提出一种基于空间平滑的分割方法,提高了铸件内部缺陷的识别和检测率。ZHAO X 等^[7]针对微小而模糊的气孔缺陷,提出一种基于双向增强和全方位分析的铸件 X 射线气孔检测方法,有效提高了铸件中气孔缺陷的检测精度。傅可清等^[8]针对铝合金铸件 X 射线图像缺陷特征提取维度缺乏、效率低等问题,提出一种铝合金压铸件 X 射线成像典型缺陷特征提取算法,利用滤波、去噪、阈值分割等方法完成相关特征提取。

一般来说,传统机器视觉方法尽管可以实现缺陷的分类,但还不能有效地实现缺陷定位,具有一定的局限性。基于深度学习的检测方法,利用卷积神经网络对缺陷目标进行识别定位,具有较高的检测精度和效率,在工业领域得到了更为广泛的应用。目前基于深度学习的目标检测方法主要分为两类:一类是以 Faster R-CNN 为代表的 Two-Stage 算法模型,张雪荣等^[9]提出基于深度学习的钢卷端面缺陷检测系统,采用改进后的 Faster R-CNN 作为系统的目标识别算法,对钢卷端面缺陷进行识别检测,得到了较好的识别效果。蔡彪等^[10]采用 Mask R-CNN 对铸件内部缺陷进行了缺陷检测。但这类算法先生成候选框,然后再对每个候选框进行分类,检测速度较慢,影响实时性。另一类是以 SSD、YOLO 为代表的 One-stage 检测方法。鲍春生等^[11]基于改进的 YOLOv3 网络模型,对铸件划痕缺陷改进,有效提高了缺陷检测精度。此外, MERY D 等^[12]提出一种用于铸件缺陷检测的卷积神经网络,在

数据集基础上使用生成对抗网络(GAN 网络)对数据集进行模拟训练,使用滑动窗口法对 X 射线图像进行缺陷检测,实现了不同铸件缺陷类型的有效检测。WU B 等^[13]采用改进的卷积神经网络对 X 射线图像的钛合金铸件缺陷进行识别分类,对工业铸件缺陷提供了多种检测方法。

综上,基于深度学习的图像检测算法已经较为成熟,YOLO 系列算法在工业缺陷检测领域也得到较为广泛的应用,该类算法使得检测实时性得到了一定的提升,但检测精度略低,特别是对缺陷特征不太明显的 X 射线图像,模型检测效果不佳。为此,本研究采用 YOLOv5-SE 网络模型,引入直方图均衡化方法和注意力机制,进一步增强数据特征,旨在提高铸件图像的缺陷检测精度,为铸件缺陷检测提供一种基于深度学习的解决方案。

1 试验方法

铸件 X 射线图像的采集往往需要投入较大的人力和物力,高品质的铸件 X 射线图像获取较为困难^[14]。此外,受拍摄环境影响,部分图像的缺陷特征并不明显,采集到的图像由于部分缺陷只占其中极小的像素,较少的数据难以保证检测模型充分学习缺陷特征,增加图像检测难度。为此,提出一种基于深度学习的铝合金轮毂铸件图像缺陷检测方法,通过采用直方图均衡化方法和 Mosaic 数据增广策略,实现图像数据的扩充与增强,同时改进 YOLOv5 网络模型,引入通道注意力模块,加强对图像缺陷的特征提取,有效提高铸件缺陷的检测精度,其流程见图 1。




图1 铸件图像缺陷检测方法示意图


Fig.1 Schematic diagram of image defect detection method for castings

2 图像数据预处理

2.1 图像数据增强


受拍摄环境影响,部分图像的缺陷特征并不明显,

存在整体图像较暗或者较亮,见图 2,原图的灰度集中在中间,整体图像适中,但缺陷的边缘及特征并不清晰。为了让图像灰度相对均匀地占据图像,突出图像的数据



(a) 原图像

(b) 原图像直方图



(c) 增强后图像

(d) 增强后图像直方图

图 2 图像增强前后形貌及直方图对比

Fig.2 Comparison before and after image enhancement

直方图均衡化法原理是对图像中像素个数较多的灰度值进行展宽,对像素个数少的灰度值(对缺陷特征影响不大的灰度值)进行归并,把原始图像的灰度直方图均匀化,增大对比度,实现图像增强。首先,对灰度图所有像素进行扫描,将原图像的像素值均衡映射到新直方图 S ,其表达如下:

$$S(p_k) = \frac{n_k}{n} \quad (1)$$

式中, n 为图像的总和;下标 k 为图像的第 k 个灰度级别($k=0,1,2,\dots,L-1$),其中 L 为图像中的灰度级总数。其次,计算直方图积分。

$$\hat{S}(i) = \sum_{j=0}^i S(j) \quad (2)$$

然后完成图像转换:

$$\text{dst}(x, y) = \hat{S}[\text{src}(x, y)] \quad (3)$$

式中, $\text{dst}(x, y)$ 表示图像取阈值的原理方法; $\text{src}(x, y)$ 为输入的单通道图像。从图 2 可以看出,该方法重新分配图像的像素值,增大了图像的信息量,突出了图像数据特征,有利于提高模型的特征学习能力。利用该方法对数据集图像进行进一步处理。

2.2 图像数据扩充

铸件图像数据特征分布较为稀疏,每张图像含有一种或者微量缺陷,这种数据分布特点不利于模型充分学习缺陷特征。为了提高模型的泛化能力,采用 Mosaic 数据增广策略。

Mosaic 数据增广策略可以实现 4 张图像的拼接,对含有微量缺陷的单张图像来说,由于数据特征稀疏、特征不明显,不利于算法模型的训练。为此,采用 Mosaic 数据增广策略能够将多张含有微量缺陷的图像拼接为新图像传入到神经网络中学习。图 3 为该方法的主要流程:①随机选取 4 张图像,按象限排布;②选取高为 h ,宽为 w 的尺寸作为输出图像大小,并将图像分割为 4 个不同区域;③选取离分割线较远的顶点作为重合

特征,受图像像素值重分布来实现医疗图像增强的方法启示^[15],采用直方图均衡方法对局部细节缺失、背景较暗的铸件 X 图像进行图像增强。

点,按流程②分割区域的分割线,对分割的各象限图像进行拼接,生成新图像作为训练数据。




图 3 简化 Mosaic 数据增广方法

Fig.3 Simplified Mosaic data augmentation method

利用该方法,能够将多张含有单一缺陷类型的图像随机拼接为一张含有多尺度多类别缺陷的新图像,有效解决了 X 射线图像获取困难。缺陷特征分布稀疏、模型难以充分学习等问题。该方法丰富了图像的背景特征,使得多尺度不同类型缺陷出现在同一图像中,采用新图像作为子训练集,有利于提高模型的泛化能力。

3 YOLOv5 原理与改进

基于 YOLO 系列的网络模型已经成为小目标缺陷检测领域的最重要的模型之一^[16]。采用体积和权重都较小的 YOLOv5s,具有更快的检测速度,便于打包应用到实际生产中。YOLOv5s 将整个网络结构分成输入端、骨干网络、颈部结构、输出端 4 个部分,网络结构见图 4。

(1)输入端 输入数据集图像,并对数据集图像进行组合变换,将多背景多目标图像组合起来。

(2)骨干网络 将输入的网络图像进行裁剪,输入到 Focus 结构,进行特征图拼接,完成后进入到 CSP 结构进行最后的特征提取工作。

(3)颈部结构 用特征金字塔(FPN)与路径聚合方式,完成特征图的融合和特征读取、传达等操作,对不同检测层进行特征聚合^[17]。

(4)输出端 将利用网络结构对图像进行预测信息检测,完成最终的目标检测。




图 4 改进的 YOLOv5 网络结构图

Fig.4 Structure diagram of modified YOLOv5 network

YOLOv5 结构在原 YOLOv3、YOLOv4 基础上,主干网络采用 Focus 和 C3 结构,加强了对图像的特征提取,尽管检测速度得到一定的提升,但检测精度相对降低^[18]。

为了在运用 YOLOv5 保证检测实时性的同时,尽可能地提高检测的精度,采用在网络结构中增加通道注意机制 SENet 模块的方法。SENet 模块插入到网络结构的合适位置能够加强对特征层的特征提取,从而有效提高模型的检测精度,其设计简单,计算量小,易于加载到现有的 YOLOv5 模型框架中,网络结构见图 5。为了获得在通道维度上的注意力,首先对输入的特征层进行全局平均池化,使空间特征降维到 1×1 :

$$z_c = F_{sq}(x_c) = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W x_c(i, j) \quad (4)$$

式中, $H \times W$ 为特征图计算每个像素值的和,获取全局平均池化结果 F_{sq} ,即将 $H \times W \times C$ 的特征图,转化为 $1 \times 1 \times C$ 的特征,保持通道数量不变。

然后进行两次全连接,完成后和 Sigmoid 激活函数建立通道间的连接:

$$Z = T_2 \{ \text{ReLU}[T_1(Z)] \} \quad (5)$$

式中,ReLU 为激活函数,取 $\max(0, 1)$; T_1 为第一次全连接操作,执行降维操作; T_2 为第二次全连接操作,经

过激活函数获得归一化权重,最后通过乘法逐通道加权到原始特征图的每一个通道上,完成通道注意力对原始特征的重新标定^[19]。




图 5 SENet 网络结构图

Fig.5 Structure diagram of SENet network

经过反复试验,采用在骨干网络的第 6 层与第 7 层之间,加入 SENet 模块,来增强对重要通道的特征提取。添加位置见图 4 虚线框处,得到改进的 YOLOv5-SE 模型见图 5。

4 试验分析与验证

4.1 试验数据

采用射线计算机层析照相技术,将获得的 533 张通道数为 3、尺寸大小为 $768 \text{ ps} \times 672 \text{ ps}$ 的轮毂铸件 X 射线缺陷图像相关特征利用 Labelimage 工具进行标记,以 XML 文件形式存储图像的文件名、分辨率、缺陷类型与区域等信息^[20]。

图像包含 4 种常见的缺陷类型(气孔、缩松、裂纹和夹杂),所研究的缺陷图像见图 6。气孔一般出现在轮毂壁厚较大的地方,形状接近圆形,尺寸略小;缩松具有小而分散等特点;裂纹通常表现为铸件出现直线或者不规则曲线裂口;夹杂一般表现的特征为铸件内存在与其金属成分不同的异物、面积突出的黑色小块。




图 6 不同铸件缺陷的轮毂 X 射线图像

Fig.6 X-ray images of wheel hub with different casting defects

在 533 张图像的基础上,按照 6 : 3 : 1 将缺陷图像依次随机划分为训练集、测试集、验证集,共得到训练集

图像 320 张,测试集图像 160 张,验证集图像 53 张。为保证检测模型充分学习缺陷特征,采用直方图均衡化方

法对图像缺陷进行数据增强,强化了缺陷局部数据特征。利用几何变换(如放缩、旋转)进一步扩充缺陷数据,图像数据集扩充到4 797张。将得到的新训练图像进行Mosaic数据增广,将图像尺寸缩放到640 ps×640 ps,对所有图像随机分组,并随机选4张图像进行拼接,生成子数据集;最后利用YOLOv5-SE模型对图像数据不断训练,从而得到最优小目标铸件缺陷图像检测方法。

4.2 缺陷检测结果分析

将处理得到的图像数据,采用YOLOv5-SE模型进行训练。模型训练在python环境下进行,采用深度学习框架为PyTorch,输入图像的尺寸为640 ps×640

ps,模型训练迭代次数为1 000,每次训练选取的样本数为4,初始学习率为0.01,采用Precision(准确率)、Recall(召回率)、mAP@0.5(IoU阈值为0.5时所有目标类别的平均精度值)、mAP@0.5 : 0.95(IoU阈值在0.5~0.95之间所有阈值的平均检测精度值)等参数作为模型性能评价指标。收敛情况结果见图7。可以看出,随着迭代次数增加,平均检测精确度达到80%以上,当IoU值为0.5时平均精度(mAP)趋近于1,达到99.6%,对测试集进行检测,结果见图8,不同颜色的框图数字代表一类缺陷类型(其中0为裂纹缺陷,1为气孔缺陷,2为缩松缺陷)。




图7 YOLOv5-SE模型训练曲线图
Fig.7 Training curves of YOLOv5-SE model




图8 YOLOv5-SE测试集检测结果

Fig.8 Detection results of YOLOv5-SE test set

4.3 结果对比与验证

采用YOLO系列主流算法对相同测试集图像进行训练,输入尺寸为640 ps×640 ps的图像,YOLOv3、YOLOv4模型训练迭代次数为500,每次训练选取的样本数为8,YOLOv5、YOLOv5-SE模型训练迭代次数为1 000,每次训练选取的样本数为4,不同模型检测得到的单批次样本大小、全样本训练次数、FPS(检测实时性)、mAP(平均精度)等值见表1。可以看出,改进后的YOLOv5-SE模型检测精度达到了99.6%,尽管检测速度略有下降,但仍满足实际需要。

表1 不同算法模型检测结果表

Tab.1 Test results of different algorithm models					
检测模型	样本大小	训练次数	FPS	mAP/%	mAP@0.5 : 0.9/%
YOLOv3	8	500	63.5	90.6	66.4
YOLOv4	8	500	58.6	94.5	70.2
YOLOv5	4	1 000	61.8	95.4	72.4
YOLOv5-SE	4	1 000	60.5	99.6	84.8

进一步选取模型训练 mAP 值较高的 YOLOv5、YOLOv5-SE 模型进行研究,采用 160 张测试集图像,比较采用不同检测模型组合、所有类型缺陷的具体检测效果。检测模型组合见表 2,其中+表示采用,-表示未采用。

表 2 不同检测模型组合

Tab.2 Combination of different detection models			
检测组合	直方图均衡化	Mosaic 数据增广	注意力机制
Y ₁	+	+	+
Y ₂	+	-	+
Y ₃	-	+	-
Y ₄	-	-	-

采用 Y₁~Y₄ 4 种模型均基于 YOLOv5 网络结构,不同之处在于是否采用不同的数据处理方式以及网络结构中是否加入注意力机制。对 4 种组合模型进行训练,检测结果见表 3,其中 α_m 为检测精度的平均值。

可以看出,模型 Y₁ 和模型 Y₂ 对 4 种缺陷类型的平均检测精度要高于 Y₃、Y₄,进一步验证了采用直方图均衡化方法和引入注意力机制的模型具有更优的检测性

表 3 不同模型组合检测结果

Tab.3 Test results of different model combinations					%
检测模型	裂纹	缩松	气孔	夹杂	α_m
Y ₁	90.5	92.3	86	90.3	89.78
Y ₂	88.6	80.7	80.5	82.7	83.13
Y ₃	80.5	90	62	83.3	78.95
Y ₄	65.6	72.6	60	60.5	64.68

能。此外,气孔缺陷在模型 Y₁ 和 Y₂ 中具有较好的检出率,而在没有采用直方图均衡化方法的模型 Y₃、Y₄ 中表现较差,说明对此类缺陷采用直方均衡化进行图像增强后,更容易被识别分类出来。相较于原网络(Y₃),YOLOv5-SE(Y₁)对常见的 4 种类型(气孔、缩松、裂纹和夹杂)铸件缺陷平均检测精度提高了 10.83%。

为了进一步验证模型的检测性能,采用改进后的 YOLOv5-SE(Y₁)和原网络模型(Y₃)在 53 张验证集图像上进行图像缺陷检测,图 9 为 2 种模型的检测结果(如缩松 0.3,表示此处为缩松缺陷的识别精度为 0.3)。可以看出,YOLOv5-SE 对缺陷识别精度特别是对缩松、气孔缺陷的检测精度明显高于原始网络,检测效果




图 9 两种网络模型缺陷检测结果图

Fig.9 Defect detection results of both network models

更优,进一步证明了该模型具有更好的泛化能力。

5 结 论

(1)采用直方图均衡化方法和 Mosaic 数据增广策略,完成了图像的增强与扩充,提升图像复杂度,提高模型训练的准确性。

(2)改进了 YOLOv5 主干网络,加入了 SENet 注意力机制模块,采用改进后的 YOLOv5-SE 模型,对铝合金轮毂铸件缺陷平均检测精度(mAP)达到了99.6%,较原 YOLOv5 模型 mAP 提升了 4.2%。

(3)相较于原网络,YOLOv5-SE 对常见的 4 种类型(气孔、缩松、裂纹和夹杂)铸件缺陷平均检测精度提升了 10.83%,能够实现铸件多类型缺陷的自动检测,该方法具有较好的泛化能力。

参 考 文 献

[1] 牛蒙蒙.基于深度学习的零件表面粗糙度预测研究[D].辽宁大连:大连理工大学,2021.

[2] 周志敏.基于深度学习的合金设计与预报方法[J].特种铸造及有色合金,2019,39(5):493-496.

[3] 张建明,廖敦明,孙飞.基于全连接卷积神经网络的铸造缩松缩孔缺陷快速预测[J].特种铸造及有色合金,2020,40(8):841-845.

[4] DU W Z, SHEN H Y, FU J Z, et al. Automated detection of defects with low semantic information in X-ray images based on deep learning[J]. Journal of Intelligent Manufacturing, 2020, 32(1): 141-156.

[5] 冯世杰.基于机器学习的铸件缺陷识别方法研究[D].西安:西安电子科技大学,2020.

[6] KAMALAKANNAN A, RAJAMANICKAM G. Spatial smoothing based segmentation method for internal defect detection in X-ray images of casting components[C]. Trends in Industrial Measurement and Automation (TIMA). IEEE, 2017,12(1): 1-6.

石墨烯纳米片/AZ91D 镁基复合材料腐蚀行为

张露露¹ 陈利文¹ 李利民¹ 侯 华^{1,2} 赵宇宏¹

(1.中北大学材料科学与工程学院; 2.太原科技大学材料科学与工程学院)

摘 要 研究了固溶处理后不同石墨烯纳米片(G_{nps})含量的 AZ91D 镁基复合材料在模拟体液(SBF)中的腐蚀行为。结果表明,随着 G_{nps} 含量的增加,镁基复合材料的固溶组织晶粒细化程度先增大后减小,耐腐蚀性也随着晶粒细化程度增加而增大。电化学试验结果表明,当 G_{nps} 质量分数为 0.6% 时,耐腐蚀性能最好,腐蚀电流密度(J_{corr})降低至 $1.06 \times 10^{-4} \text{ A/cm}^2$ 。研究表明, G_{nps} 做为增强体对镁合金腐蚀性能的改善具有潜在价值。

关键词 镁基复合材料; 石墨烯纳米片; 电化学腐蚀; 固溶处理

中图分类号 TB331; TG146.22

文献标志码 A

DOI:10.15980/j.tzzz.2023.04.006

开放科学(资源服务)标识码(OSID):



Corrosion Behavior of Graphene Nanosheets/AZ91D Magnesium Matrix Composites

Zhang Lulu¹, Chen Liwen¹, Li Limin¹, Hou Hua^{1,2}, Zhao Yuhong¹

(1 School of Materials Science and Engineering, North University of China;

2.School of Materials Science and Engineering, Taiyuan University of Science and Technology)

Abstract: The corrosion behavior of magnesium matrix composites with different contents of graphene nanosheets (G_{nps}) after solid solution treatment was investigated in Simulated Body Fluid(SBF). The results indicate that with the increase of content of G_{nps} , the grain refining degree of the solid solution structure in magnesium matrix composites is firstly increased and then decreased, and the corrosion resistance is also increased. The electrochemical experiment results reveal that the corrosion resistance is optimal when G_{nps} content is 0.6%, and the corrosion current density (J_{corr}) is reduced to $1.06 \times 10^{-4} \text{ A/cm}^2$, implying the potential value of G_{nps} as reinforcement for the corrosion properties of magnesium alloys.

Key Words: Magnesium Matrix Composites, Graphene Nanosheets, Electrochemical Corrosion, Solid Solution Treatment

收稿日期:2022-11-26;修改稿收到日期:2023-02-10

基金项目:国家自然科学基金资助项目(52074246, 22008224, 52275390, 52205429, 52201146);国防基础科研资助项目(JCKY2020408B002, WDZC2022-12);山西省重点研发计划资助项目(202102050201011)

第一作者简介:张露露,男,1995 年出生,硕士研究生,太原(030051),E-mail:1453576707@qq.com

通信作者:赵宇宏,女,1974 年出生,教授,太原(030051),E-mail:zhaoyuhong@nuc.edu.cn

引用格式:张露露,陈利文,李利民,等. 石墨烯纳米片/AZ91D 镁基复合材料腐蚀行为[J]. 特种铸造及有色合金,2023,43(4):463-468.

ZHANG L L, CHEN L W, LI L M, et al. Corrosion behavior of graphene nanosheets/AZ91D magnesium matrix composites[J]. Special Casting & Nonferrous Alloys, 2023, 43(4):463-468.

[7] ZHAO X, LIANG J, HE Z, et al. Blowhole detection based on bi-directional enhancement and omnidirectional analysis for X-Ray inspection of castings[J]. Mathematical Problems in Engineering, 2019, 12(7): 1-16.

[8] 傅可清, 马源, 伍俊杰, 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] 张雪荣, 向峰, 李红军, 等. 基于深度学习的钢卷端面缺陷检测系统设计[J]. 计算机集成制造系统, 2022, 4(4): 1-19.

[10] 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): 61-69.

[11] 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.

[12] MERY D, JAEGER T, FIBERT D. A review of methods for automated recognition of casting defects [J]. Insight-wigston Then Northampton, 2002, 44(7): 428-436.

[13] WU B, ZHOU J, YANG H, et al. An ameliorated deep dense convolutional neural network for accurate recognition of casting defects in X-ray images[J]. Knowledge-Based Systems, 2021, 226(6): 96-107.

[14] LI W, LI K, HUANG Y, et al. A new trend peak algorithm with X-ray image for wheel hubs detection and recognition[A]. International Symposium on Computational Intelligence and Intelligent Systems[C]. Singapore, 2015.

[15] 许纪亚, 孙佳宁, 乔双. 基于多尺度二维直方图均衡化的医学图像增强方法[J]. 东北师大学报(自然科学版), 2020, 52(1): 88-91.

[16] REDMON J, FARHADI A. YOLO9000: Better, Faster, Stronger [A]. IEEE Conference on Computer Vision and Pattern Recognition[C]. Honolulu, USA, 2017.

[17] JING J F, ZHUO D, ZHANG H H, et al. Fabric defect detertion using the improved YOLOv3 model[J]. Journal of Engineered Fibers and Fabrics, 2020, 15(4): 1-10.

[18] 朱衍波. 基于改进 YOLOv4 算法的目标检测算法研究[D]. 西安: 西安电子科技大学, 2021.

[19] ZHANG J, KANG X, NI H, et al. Surface defect detection of steel strips based on classification priority YOLOv3-dense network[J]. Ironmaking & Steelmaking, 2021, 48(5): 547-558.

[20] 刘洋帆, 王召巴, 陈友兴, 等. 基于超声检测的镁合金棒材缺陷识别及定位[J]. 特种铸造及有色合金, 2011, 31(7): 661-664.

(编辑: 栗万仲)