

基于改进 YOLOX 算法的铝铸件表面成孔缺陷检测研究

胡佳琪¹ 王成军² 杨超宇² 胡 鹏²
(1.安徽理工大学计算机科学与工程学院;2.安徽理工大学人工智能学院)

摘 要 针对铸件在铸造过程中易出现漂芯、漏芯等成孔类缺陷,采用视觉检测时铸件与背景特征相近,产生特征网络提取能力欠缺的问题,提出改进 YOLOX 的铝铸件表面成孔缺陷检测方法。构建成孔缺陷数据集;引入 SE 注意力机制,提升特征重用率;替换原卷积块为 CBH,稳定特征拟合过程;完善 CIOU 边界框回归损失函数,加速模型收敛。试验证明,改进模型在铝铸件缺陷数据集的平均检测精度提升至 97.13%,单图推理速度为 0.016 2 s,可快速准确地完成铝铸件表面缺陷检测。

关键词 铝铸件;表面缺陷检测;端到端;深度学习;注意力机制

中图分类号 T391;TG245;TP311 文献标志码 A

DOI:10.15980/j.tzzz.2023.09.008

开放科学(资源服务)标识码(OSID):



Detection of Hole-forming Defects on Aluminum Casting Based on Optimized YOLOX

Hu Jiaqi¹, Wang Chengjun², Yang Chaoyu², Hu Peng²

(1.School of Computer Science and Engineering, Anhui University of Science and Technology;
2.School of Artificial Intelligence, Anhui University of Science and Technology)

Abstract: Aiming at the problem of floating cores and missing cores that commonly occurs during the casting process, and the lack of feature network extraction capabilities due to the similarity of casting and background features when visual inspection is used, an optimized YOLOX method for detecting pore-forming defects on the surface of aluminum castings was proposed. A hole defect dataset was constructed, and SE attention mechanism was introduced to improve feature reuse rate. Meanwhile, original convolution block was replaced by CBH to stabilize feature fitting process, and CIOU bounding box regression loss function was modified to accelerate model convergence. The results indicate that the average detection accuracy of optimized model in the aluminum casting defect dataset is increased to 97.13%, and the single-image reasoning speed is 0.016 2 s, which can quickly and accurately detect aluminum casting surface defects.

Key Words: Aluminum Casting, Surface Defect Detection, End-to-End, Deep Learning, Attention Mechanism

因生产环节复杂等问题,铸件在铸造过程中易出现偏芯、漂芯、漏芯等成孔缺陷,直接影响后续加工。待检测件具有缺陷成因多、形状不规则、特征提取困难等特点,而采用深度学习技术检测铸件表面成孔缺陷存在难度大、检测精度低等难题^[1]。

近年来,基于端到端算法的表面缺陷检测成为工业检测的新手段。KONOVALENKO I 等^[2]构建残差分类器捕捉特征形状,对金属表面缺陷检测精度达到 96.7%,但未解决感受野区域捕捉受限问题;翁玉尚等^[3]提出 K-Means II 聚类改进锚框的 Mask R-CNN 算法,检测精度明显提升,但仍为 Two-Stage 检测算法,难以实现实时检测。One-Stage 检测算法直接利用卷积神经网络回归目标边界框坐标和分类概率,明显提

升检测速度并降低硬件依赖度,其中以 SSD^[4]、YOLO 系列^[5]为基础的端到端算法适用于表面缺陷的实时检测。端到端缺陷检测法已用于汽车轮毂、工业轴承等目标的缺陷检测^[6-8]。针对铸件表面缺陷,常用 X 射线检测^[9]、荧光渗透检测^[10]和工业内窥镜检测^[11],基于端到端算法中 One-Stage 检测方法对铝铸件表面缺陷检测方法研究报道较少。鲍春生等^[12]针对铸件划痕缺陷的检测精度有了很大的提高,而其提出的 YOLOv3-Mv2 模型采用预设锚框 Anchor-Base 检测方式,运算耗时和算力大大增加,检测精度大幅提高。

本研究提出一种基于 One-Stage 算法的铝铸件表面成孔类缺陷检测方法,以 YOLOX 为基础模型并对其进行改进,在 PAFPN 层引入通道注意力机制 SE

收稿日期:2022-11-26;修改稿收到日期:2022-12-15
基金项目:安徽省自然科学基金资助项目(2208085ME128)
第一作者简介:胡佳琪,女,1997 年出生,硕士研究生,安徽淮南(232001),E-mail:819985406@qq.com
通信作者:王成军,男,1978 年出生,教授,安徽淮南(232001),E-mail:cumt1279@163.com
引用格式:胡佳琪,王成军,杨超宇,等. 基于改进 YOLOX 算法的铝铸件表面成孔缺陷检测研究[J]. 特种铸造及有色合金,2023,43(9):1 205-1 209.
HU J Q, WANG C J, YANG C Y, et al. Detection of hole-forming defects on aluminum casting based on optimized YOLOX[J]. Special Casting & Nonferrous Alloys, 2023, 43(9):1 205-1 209.

(Squeeze-and-Excitation block, SE),提升铸件特征识别度;优化 CBL 基础卷积块为 CBH 卷积块,增加模型非线性因素,加速拟合;预测层引入 CIOU 边界框回归损失函数,缓解目标遮挡造成的漏检情况,以期铸件表面缺陷的自动化检测提供参考。

1 YOLOX 算法

YOLOX 目标检测算法输入端采用 Masic 和 Mix-up 两种数据增强方式预处理输入图片,并将其缩放至分辨率为 $640 \text{ pix} \times 640 \text{ pix}$ 。Backbone 层采用 Focus 结构将图像切片调整分辨率为 $320 \text{ pix} \times 320 \text{ pix} \times 32$ 的特征图,其中 32 代表将图像切分为 32 块同等大小的小特征图;主干网络由 CSP Darknet53 和空间金字塔池化 SPP^[13] (Spatial Pyramid Pooling, SPP) 组成,提取前景特征。PAFPN 层沿用 FPN 结构,通过上采样传递高层特征信息、下采样融合浅层特征的方式,增强网络特征融合能力。Prediction 层提出解耦头技术,采用无预设锚框 Anchor-Free 检测方式、Multi positives 机制和 SimOTA 标签匹配策略,缓解了训练过程中正负样本不均衡问题,改进前 YOLOX 网络结构见图 1。




图 1 改进前 YOLOX 网络结构图

Fig.1 YOLOX network structure diagram before optimization

铝铸件表面成孔类缺陷检测难点在于铸件与背景特征相像,引发特征提取能力不足和有效感受野区域受限的问题,影响缺陷检测精确度和处理速度。针对上述问题,改进后 YOLOX 算法将目标检测任务重新定义为单一的回归预测问题,模型框架见图 2。




图 2 改进后 YOLOX 网络结构图

Fig.2 YOLOX network structure diagram after optimization

2 改进 YOLOX 的铝铸件表面缺陷检测模型

为满足铝铸件表面成孔缺陷检测的精度和实时性需求,对原始 YOLOX 网络进行 3 点改进,见图 2。

2.1 基于 CBH 卷积块稳定数据拟合

CSP Darknet53 网络作为 YOLOX 主干网络,使用 CBL 基础卷积块,由 Conv、批归一化层 (Batch Normal, BN) 和 SiLU 激活函数组成,可防止网络饱和,避免产生不可导问题。但在深层网络中才能体现其优势,且 SiLU 函数中的 Sigmoid 指数函数将导致求导过程计算量增加。

$$\text{SiLU}(x) = x \cdot \text{Sigmoid}(x) \in (0, x)$$

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

在铝铸件表面成孔类缺陷检测中引入 HardSwish 激活函数,输入特征经 BN 层调整每层网络输出数据后,由 HardSwish 激活函数代替线性 SiLU 函数,规避 Sigmoid 函数所导致的梯度消失问题,降低梯度弥散率,加速模型收敛。同时,使用分段函数稳定拟合检测数据,可降低内存访问次数。

$$\text{HardSwish}(x) = \begin{cases} 0 & (x \leq -3) \\ x & (x \geq 3) \\ \frac{x \cdot (x + 3)}{6} & (-3 < x < 3) \end{cases} \quad (2)$$

式中, x 为输入的值或神经元的加权和,代表神经元接收到的输入信号的大小。

故可将改进 YOLOX 的铝铸件表面缺陷检测模型中的 CBL 基础卷积块替换为由 Conv、BN 和 HardSwish 激活函数组成的 CBH 卷积块,见图 3。




图 3 CBH 卷积块

Fig.3 CBH convolution block

2.2 通道注意力模块

YOLOX 算法中主干网络利用叠加 CBL 卷积块与 CSP 结构增加网络深度,提取图像特征。CSP Darknet53 特征提取网络中浅层特征局部感受野小,使得捕捉明暗、特征边缘等细节更准确,适合检测小型缺陷目标,但语义知识欠缺,信息传递过程易受网络干扰。浅

层特征经 4 次卷积叠加后获得分辨率缩小至原图 1/16 的深层特征。深层特征局部感受野变大,反映整体结构,语义知识丰富,但获得细节有效特征信息持续减少,减弱较小缺陷目标特征的表达能力,导致漏检和误检。

通道注意力模块以 SENet^[14] 为基础设计,从主干特征提取网络的多尺度特征作为输入,先进行全局最大池化操作,实现空间维度特征信息压缩(Squeeze);然后通过 1×1 全连接卷积层(Fully Connected Layers,FC)学习压缩卷积后重分配权重的特征值,并通过 Sigmoid 激活函数,获得各通道注意力模块的权重信息;最终,将各个通道与其对应权重信息拼接,并与原始特征以点乘方式实现对特征信息的激励(Excitation),代替原始特征作为骨干网络的输出,提高可用特征利用率。

铝铸件表面成孔类缺陷中因砂芯漂移导致铸件表面出现漂芯缺陷。故在特征金字塔网络中引入 SE 注意力机制,增强对漂芯类缺陷的小目标信息的特征提取能力。从 3 种尺度特征中获得更具鲁棒性的特征图像,强化特征提取网络对成孔缺陷特征的关注,抑制无关背景信息,减少铝铸件表面小缺陷特征信息丢失,兼顾细节与整体,提升模型对铝铸件表面缺陷特征感知能力,见图 4。




图 4 压缩与激活注意力机制

Fig.4 Squeeze-and-Excitation attention mechanism

2.3 基于 CIOU 构造损失函数

损失函数是衡量预测算法模型对真实目标拟合效果的关键指标,边框回归损失函数直接影响目标定位结果。YOLOX 模型输出端中采用解耦头(Decoupled Head)将预测目标框类别的分类任务与预测边界框坐标和置信度的回归任务区分开。YOLOX 采用 IOU 作为反映检测缺陷准确度的标准,但此损失函数无法精确反应预测框与真实框重合度。

铸件成孔缺陷成因复杂,对表面成孔类缺陷检测算法中充分考虑到预测网络中预测框与真实框边界不重合时 IOU 值、中心点距离相同和边界框宽高比不同时所产生的问题。验证表面成孔类缺陷定位预测框时,采用 CIOU^[15] (Complete-IOU) 边界框回归损失函数计算损失,加速预测边框稳定回归。CIOU 边界框回归损失函数在两框不重合时指出锚框随后移动方向,保证模型正常训练;当两框中心点重合且边框长宽比不同时,

及时调整预测框,得到准确的预测框与真实框两框位置关系。

$$L = 1 - \left(I + \frac{\rho^2(\rho, g^{gt})}{c^2} + \alpha v \right) \tag{3}$$

$$\alpha = \frac{v}{(1 - I) + v} \tag{4}$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right)^2 \tag{5}$$

式中, I 为真实框与预测框交并比; ρ 和 g^{gt} 为预测框与真实框的中心点; c 为同时包含预测框和真实框的最小闭包区域对角线距离; α 为平衡比例的参数; v 为衡量预测框和真实框的宽高比例一致性的参数; w^{gt} 、 h^{gt} 为真实框的宽度和高度; w 和 h 为预测框的宽度和高度。

3 试验及结果分析

3.1 铝铸件表面缺陷数据采集与处理

选用工业相机采集铝铸件表面缺陷图像,设置拍摄时间间隔为 0.2 s,图像分辨率为 1 280 pix×720 pix。铝铸件缺陷位置具有随机性,故在固定角度、背景下连续拍摄铝铸件缺陷图片无法充分满足工业场景。在不同背景和光照强度下采集表面缺陷铝铸件图像,经筛选最终收集 9 500 张铝铸件表面缺陷图像,每张图像至少包含一种缺陷;同时采集了 2 000 张正常铝铸件图像。

铝铸件表面缺陷数据集标签分布见表 1。数据处理过程使用开源工具 LableImg 实现铝铸件表面成孔类缺陷图像标注,分为检测整面漏铸孔、柱体漏铸孔、铸孔漂芯 3 种类型缺陷,缺陷标签分别为 Surface Leak Punch、Cylinder Leak Punch、Wafer Leak Punch,正常铸件标签为 Defect-Free。单个铝铸件在实际工业场景下有多处成孔需求,故成孔缺陷标签数均大于数据集总数。以 COCO 数据格式制作数据集,将标注文件存为 .xml 类型,文件中包含缺陷类型、缺陷框坐标和图像分辨率等信息。标注数据按 8 : 1 : 1 比例随机划分为训练集、测试集和验证集。

表 1 铝铸件表面缺陷数据集标签分类表
Tab.1 Label classification table of aluminum casting surface defect dataset

缺陷名称	标签名称	数据集/张	标签数
整面漏铸孔	Surface Leak Punch (SLP)	2 600	5 455
柱体漏铸孔	Cylinder Leak Punch (CLP)	3 400	6 020
铸孔漂芯	Wafer Leak Punch (WLP)	3 500	4 225
正常铸件	Defect-Free (DF)	2 000	2 000

3.2 试验环境

试验采用的硬件配置为 Intel Xeon Platinum 8255C CPU@2.50 GHz 处理器,显卡型号为 NVIDIA GeForce RTX 3080-10G,编译环境为 PyCharm,Py-

Torch 1.8.1 搭建网络模型, Python3.8 编译器, Cuda11.1和 Cudnn8.4 加速 GPU 训练。

铝铸件表面成孔类缺陷模型训练设置最大迭代轮数为 300,初始学习率为 0.005,权重衰减系数设置为 0.000 5,非极大值抑制值(NMS)为 0.65,Mosaic 和 Mix-Up 数据增强尺度为(0.1,2.0)。

3.3 评价指标

试验采用表面缺陷检测常用评价指标对铝铸件表面缺陷检测模型精度评估,包括准确率(Precision, P)、召回率(Recall, R)、平均精度均值(Mean Average Precision, m_{AP})。

$$P = \frac{T_P}{T_P + F_P} \tag{6}$$


$$R = \frac{T_P}{T_P + F_N} \tag{7}$$

$$m_{AP} = \frac{1}{n} \sum_{i=1}^n \int_0^1 P_i(R_i) dR_i \tag{8}$$

式中, T_P 为真正例; F_P 为假正例; F_N 为假反例; n 为某缺陷类别数。评估算法模型时 m_{AP} 值越高,预测模型精度越高。本研究采用 $m_{AP}@0.5$ 与 $m_{AP}@0.5 : 0.95$ 作为精度衡量指标,其中 $m_{AP}@0.5$ 为真实框与预测框交并比阈值为 0.5 时每个铝铸件缺陷类别的 m_{AP} 值; $m_{AP}@0.5 : 0.95$ 为真实框与预测框交并比阈值为 0.5 到 0.95 每个铝铸件缺陷类别的平均 m_{AP} 值。


考虑铝铸件表面缺陷模型需适应真实工厂环境,采用推理时间衡量模型推理速度,其值越小表示检测模型每秒处理图片数量越多,其数学表达式为:

$$t_{推} = \frac{t_{总}}{P_{总}} \tag{9}$$




(a) 原始模型 P-R 曲线

(b) 改进模型 P-R 曲线




(c) $m_{AP}@0.5$

(d) $m_{AP}@0.5 : 0.95$



(e) 总损失

(f) 改进模型总损失



(g) 原始模型 CIoU 损失

(h) 改进模型 CIoU 损失

图 5 改进前后 YOLOX 模型运行结果对比图

Fig.5 Comparison of YOLOX model running results before and after optimization

式中, $t_{推}$ 为图片推理时间; $t_{总}$ 为检测模型消耗总时间; $P_{总}$ 为检测图片总数量。

3.4 试验结果

以相同数据集和同一 GPU 为基准,为更直观表示各改进模块贡献效果和比较改进后 YOLOX 算法与其他算法在铝铸件表面缺陷检测中的识别效果,对比试验的结果见表 2。改进后算法平均检测精度($m_{AP}@0.5$)比传统 YOLOv5 和 YOLOX 提升了 2.63% 和 2.32%,平均检测精度($m_{AP}@0.5 : 0.95$)比传统 YOLOv5 和 YOLOX 提升了 3.06% 和 1.47%,优于上述检测算法。

从检测精度数据看,SE 注意力机制提升了网络对不同通道特征提取的能力,使整面漏铸孔和片状漏铸孔缺陷检测精度均有明显提升;CBH 卷积块对柱体漏铸孔和铸孔漂芯缺陷的检测效果有所提升,有效缓解了铸件与背景特征相近的问题;最后,引入 CIOU 边界框回归损失函数,有效解决两框不重合时导致的回归问题。改进后 YOLOX 算法较 YOLOv5 和 YOLOX 算法得到明显的精度提升,虽推理时间略有增加,但仍在可接受范围,符合实时检测的需求。

表 2 对比试验结果表

序号		AP			$m_{AP}@0.5 : 0.95$		推理时间/s
		SLP	CLP	WLP	0.5/%	0.95/%	
1	YOLOv5 ^[5]	93.4	94.2	95.0	94.50	68.80	0.014 2
2	改进前 YOLOX	96.4	96.0	96.2	94.81	70.39	0.015 6
3	2+ SE	97.3	95.9	97.1	96.37	71.39	0.016 8
4	3+ CBH	96.0	96.7	97.6	95.16	70.56	0.015 8
5	改进后 YOLOX	97.9	96.1	97.0	97.13	71.86	0.016 2

图 5 为 YOLOX 算法与改进后 YOLOX 算法对铝铸件表面缺陷数据集检测 P-R 曲线、 m_{AP} 值和损失函数回归结果对比。结果显示,在 multi-class 缺陷检测精度有所提升。图 6 为实验室环境下对各类铝铸件缺陷的检测效

果,可见改进模型可检测出多种缺陷且错检率较低。综上所述,本研究提出的改进 YOLOX 算法性能较好,在

检测精度和速度方面表现良好,可满足铝铸件成孔类缺陷检测的需要。




图 6 铝铸件检测效果图
Fig.6 Detection effect diagram of aluminum casting

4 结 论

- (1)对网络模型重新设计,引入 CBH 卷积块,优化有效感受野区域;CIOU 边界框回归损失函数关注预测框与真实框之间逻辑关系,促进模型拟合过程稳定。
- (2)采用 SE 注意力机制对通道特征信息压缩和激励,提高缺陷铸件特征权重,降低背景权重,减少特征信息损失。与原模型对比,验证了模型对解决铸件特征与背景相近的有效性。
- (3)改进后 YOLOX 算法对铝铸件表面缺陷检测精度 m_{AP} 比 YOLOX 提升了 2.32% 和 1.47%;在检测速度方面,单张图像推理时间满足铝铸件成孔类缺陷实时检测的需求。

参 考 文 献

[1] 张辉,张邹铨,陈煜嵘,等.工业铸件缺陷无损检测技术的应用进展与展望[J].自动化学报,2022,48(4):935-956.

[2] KONOVALENKO I, MARUSCHAK P, BREVUS V. Steel surface defect detection using an ensemble of deep residual neural networks[J].Comput. Inf. Sci. Eng., 2021, 22(1): 1-8.

[3] 翁玉尚,肖金球,夏禹.改进 Mask R-CNN 算法的带钢表面缺陷检测[J].计算机工程与应用,2021,57(19):235-242.

[4] WEI L, DRAGOMIR A, DUMITRU E, et al. SSD: Single shot multiBox detector[A].European Conference on Computer Vision [C]. Springer, Cham, 2016.

[5] REDMON J, FARHADI A. YOLOv3: An incremental improvement [J]. ARXIV, 2018, 1804: 02767.

[6] 孙晓红.基于卷积神经网络的轮毂表面缺陷识别方法研究[D].江苏镇江:江苏大学,2021.

[7] 陈进.基于机器视觉的轴承缺陷检测技术研究[D].杭州:浙江大学,2021.

[8] 何国忠,梁宇.基于卷积神经网络的 PCB 缺陷检测[J].图学学报,2022,43(1):21-27.

[9] 迟大钊,马子奇,程怡,等.不等厚板搭接焊缝缺陷数字 X 射线检测[J].焊接学报,2019,40(11):45-48,163.

[10] 刘甜甜,徐桂荣,迟天佐,等.荧光渗透检测法在铝合金件上的应用及分析[J].兵器材料科学与工程,2021,44(6):118-122.

[11] 董继秋,牛德良.精密铸造航空复杂铸件油路缺陷准确检测技术[J].特种铸造及有色合金,2021,41(7):918-920.

[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] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 37(9): 1904-1916.

[14] JIE H, LI S, SAMUEL A, et al. Squeeze-and-Excitation Networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 42(8): 7132-7141.

[15] ZHENG Z H, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression[A]. Proceedings of the AAAI Conference on Artificial Intelligence[C]. Palo Alto, CA: AAAI Press, 2020.

(编辑:栗万仲)

贵州航天风华研制出超大型
镁合金铸件

近日,贵州航天风华精密设备有限公司采用新型高强度耐热镁合金研制生产的超大型舱段铸件,各项技术指标满足设计要求并通过客户验收,这也是该合金在国内首次成功应用于超大型铸件生产,其铸造技术居国内领先水平。

据介绍,研制开发的这款高强度耐热镁合金,其常温性能较常规的航空标准的铸造镁合金要高 70 MPa,它的高温性能,尤其在 250℃ 以上的高温性能,能够达到常规镁合金的 3 倍,可以广泛地应用在航空航天装备部件的制造上。

(摘自压铸周刊)