

基于双向加权特征融合网络的铸件内部缺陷检测方法

王 蕾^{1, 2}, 贺万山^{1, 2}, 张泽琳^{1, 2}, 夏绪辉^{1, 2}

(1. 武汉科技大学冶金装备及其控制教育部重点实验室, 湖北武汉 430081;

2. 武汉科技大学机械传动与制造工程湖北省重点实验室, 湖北武汉 430081)

摘要: 针对X射线无损探伤过程中铸件内部缺陷小、对比度弱、人工识别效率低等问题, 提出了一种基于双向加权特征融合网络的铸件内部缺陷检测方法。在YOLOv5网络模型基础上引入改进的坐标注意力模块(NCA), 以提高网络对不规则缺陷和小缺陷的学习能力; 引入双向特征金字塔网络(BiFPN)代替原有路径聚合网络(PANet), 以实现缺陷特征多尺度高效融合, 并使用EIoU Loss回归损失函数提高缺陷边界框定位的精度。试验结果表明, 本文所提方法对铸件内部小目标、弱对比度缺陷具有良好的检测性能。

关键词: 铸件; 缺陷检测; 深度学习; 注意力模块; 双向加权特征融合

作者简介:

王蕾(1987-), 女, 工学博士, 教授, 主要研究方向为绿色智能制造技术及装备。

通讯作者:

张泽琳, 男, 工学博士, 教授。E-mail: zhangzelin@wust.edu.cn

中图分类号: TG115

文献标识码: A

文章编号: 1001-4977(2024)

06-0843-09

基金项目:

国家自然科学基金面上项目(52275503); 湖北省重点研发计划项目(2022BAD102, 2023BAB048)。

收稿日期:

2023-08-03 收到初稿,

2023-11-06 收到修订稿。

近年来, 合金铸件通过强韧化、轻量化、精密化、高效化发展, 在汽车、家电、电子电器、通讯设备等领域广泛应用。然而, 合金件压铸过程中常常伴随气孔、缩松、裂纹和夹杂等缺陷影响其产品质量, 需要进行内部缺陷高效、精确检测^[1-2]。X射线无损探伤检测因其穿透性能好、避免材料浪费、图像直观、缺陷检测方便等优点, 已成为合金铸件缺陷检测的主要手段之一^[3-5]。但是, 工业应用过程中仍然存在合金铸件内部缺陷小、图像对比度弱、人工识别效率低等问题, 缺乏高效、精确的铸件质量自动化检测技术。

基于X射线成像和机器视觉的铸件内部缺陷自动检测技术得到了长足的发展, 大多通过对铸件X射线透射图像进行预处理、特征提取和识别分类达到缺陷检测的目的。其中, 图像预处理方法包括特征提取和分类器等, 特征提取方法主要有方向梯度直方图(Hog)^[6]、尺度不变特征变换(ORB)^[7]和局部二值模式(LBP)^[8]等; 识别分类典型方法包括支持向量机(SVM)^[9]和人工神经网络(ANN)^[10]等。上述方法很大程度上依赖复杂的图像预处理和特征工程^[11], 对不同铸件类型和不同工况环境适应性不强, 难以满足良好的自动化检测效果。

随着计算机视觉软硬件技术的快速发展, 深度学习在目标检测领域取得了广泛成功, 包括合金铸件内部缺陷识别领域。现有深度学习缺陷识别方法主要包括两类, 一类是基于候选区域的双阶段检测算法, 主要有R-CNN、Fast R-CNN、Faster R-CNN等。M.Ferguson等^[12-13]在R-CNN卷积神经网络架构上使用迁移学习技术, 证明该检测系统在铸造数据集上有良好的适用性。Wang等^[14]提出一种基于Faster R-CNN的X射线缺陷检测系统, 采用特征金字塔网络和数据增强的方法提高对汽车铝铸件X射线图像小缺陷的检测精度。另一类是单阶段算法, 如SSD、YOLO系列, 闫学顺等^[15]通过将SENet注意力机制引入YOLOv5网络模型, 增强特征提取网络对不同铸造缺陷识别的准确性。叶卓勋等^[16]将YOLOv4主干特征提取网络替换为GhostNet, 并引入改进的金字塔结构PANet, 实现对金属表面小目标缺陷更高效的检测性能。Han等^[17]设计一种带有自适应深度选择机制的Resnet18来提取和聚合不同的深度特征, 并引入自适应感受野块应对尺度变化的方法提升对铸件X射线缺陷语义分割性能。目

前,深度学习在缺陷目标检测领域取得了长足发展,但在铸件内部缺陷检测方面仍有较大发展空间,主要体现在标准数据集收集难、缺陷类型少、弱对比度缺陷区域难识别等方面。

因此,本文针对工业场景中铸件内部形状不规则、对比度弱的小缺陷区域难以检测识别的问题,提出了一种基于双向加权特征融合网络和注意力机制相结合的目标检测模型X-YOLOv5s。旨在减少不规则小缺陷、缺陷目标与铸件背景之间的边界模糊和灰度变化不明显等问题造成的缺陷漏检,提高合金铸件质量检测性能。

1 铸件内部缺陷检测模型构建

YOLO系列算法将目标检测转化为回归问题,根据网络深度和特征图宽度的不同可分为YOLOv5s、YOLOv5m、YOLOv5l和YOLOv5x,其网络的层数和结构依次增加。YOLOv5s能够在检测精度和速度之间取得平衡,因此本文选择YOLOv5s作为基础模型,该网

络由头部、主干、颈部和预测四部分组成。

在YOLOv5s模型基础上,以头部为输入,利用马赛克数据增强和自适应图像缩放,一方面扩大数据样本,丰富测试数据集,增加网络的鲁棒性;另一方面,解决小目标数据集分布不均匀的问题。主干模块进行特征提取,由焦点、CBS、C3和空间金字塔池(SPP)四部分组成。在颈部网络中,将原有的路径聚合网络(PANet)替换为双向特征金字塔网络(BiFPN),融合从3级到6级的多尺度特征,即在网络的第6层到第20层的路径中使用新的BiFPN-Concat层,实现简单快速的多尺度特征融合。将改进的N-CA注意力机制放入每个C3模块的后面,从自底向上路径中提供更好的特征判别和互补,在宽度和高度两个方向对缺陷信息进行权衡,使得特征信息中包含更多的铝合金内部缺陷,增强网络的特征传递和重用性,解决数据集中目标特征混淆的问题。同时引入损失函数EIoU_Loss,降低模型的损失值,减少缺陷的漏检和误检。图1为本文所提模型X-YOLOv5s的总体框架。

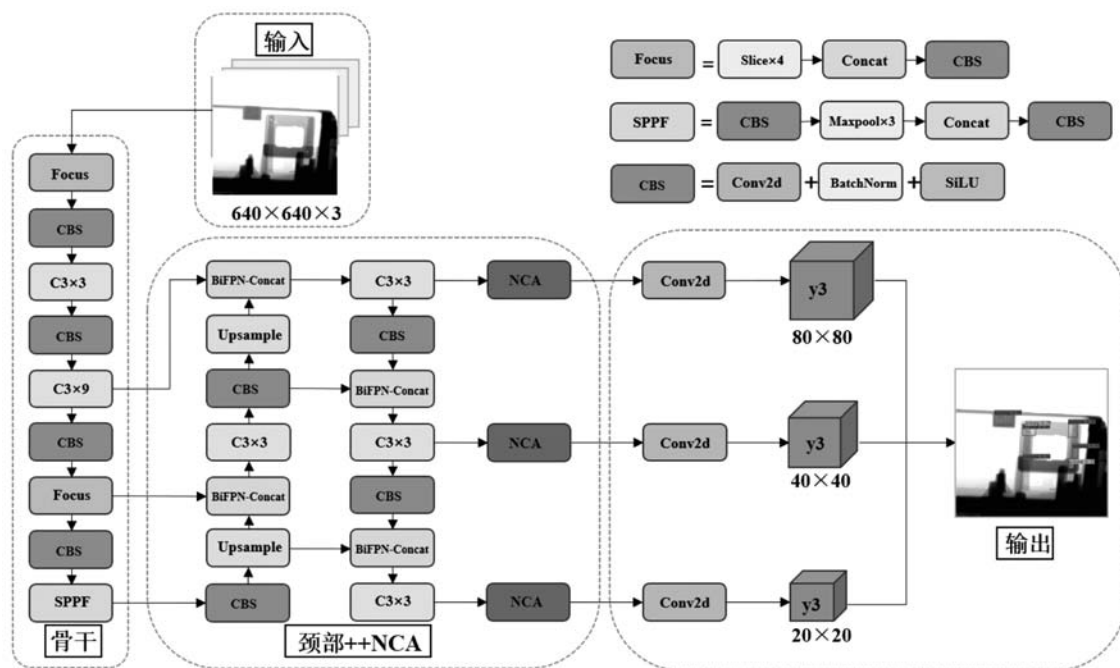


图1 X-YOLOv5s模型结构图

Fig. 1 Structure diagram of the X-YOLOv5s model

2 算法模型的改进

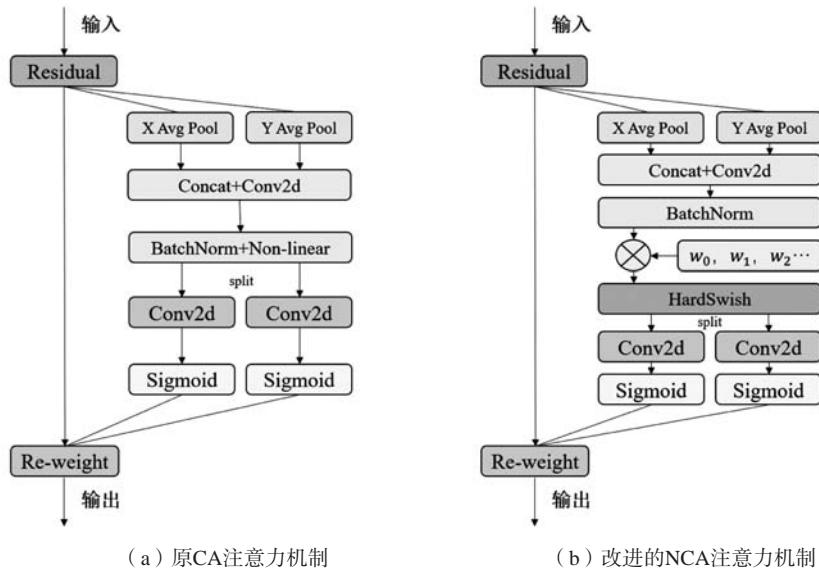
2.1 注意力机制 NCA 模块的改进

由于不同结构的缺陷大小和形状的差异很大,不同大小的特征很容易被忽略,注意力机制是提高目标检测性能的重要方法。坐标注意力CA(Coordinate attention)模块以较低的成本获取二维平面上不同维度特征的交互信息^[18],该模块遵循嵌入坐标信息和产

生坐标注意力这两个基本步骤,前者将全局池化分解为一对垂直和水平方向的一维特征编码操作,得到两个独立方向的长程依赖感知特征图;后者首先级联之前模块生成的两个特征图,然后使用一个共享的 1×1 卷积进行变换,生成的中间特征图是在水平和垂直两个方向的空间信息,选取一定的下采样比例用来控制模块大小,接着对中间特征图进行切分、卷积、归一化

等操作，最终输出生成含有位置信息的注意力权重。但忽略来自训练的调优权重的信息，使得全局池化造成位置信息的丢失。针对上述不足，本文引入一种改

进的高效协调坐标注意力模块NCA（New Coordinate attention）。图2为调节后的新型NCA基本结构块示意图。



(a) 原CA注意力机制 (b) 改进的NCA注意力机制

图2 注意力机制结构

Fig. 2 Structure of the attention mechanisms

新的NCA机制集成了基于归一化注意模块（NAM）^[19]的通道注意子模块，在识别不太突出的缺陷特征时具有更好的精度。NAM模块使用批量归一化的缩放因子，一方面提高梯度的收敛程度，加快模型的训练速度；另一方面使得每一层可以尽量面对同一特征分布的输入值，抑制不太显著的通道特征，也降低对后层网络的影响，各层网络变得相对独立，缓解训练中的梯度消失问题。同时引入HardSwish函数^[20]提升模型泛化能力，HardSwish激活函数是对Swish激活函数的改进，在一定程度上可以提高神经网络对缺陷识别的准确性。还可以实现为分段功能，以减少内存访问次数，从而大大降低等待时间成本。经过激活函数后可以自动削弱或消除一些对网络贡献不大的神经元。另外，由于归一化很少发生缺陷数据分布不同导致的网络参数变动过大问题，提高模型对小目标缺陷


检测的性能。

$$\text{HardSwish} = \begin{cases} 0, & \text{if } x \leq -3 \\ x, & \text{if } x \geq 3 \\ \frac{x(x+3)}{6}, & \text{otherwise} \end{cases} \quad (1)$$

式中： x 为神经网络传递的实值输入。

2.2 引入双向加权特征融合网络

在颈部网络进行特征融合时，原PANet^[21]结构对不同层次的输入特征时只是简单的汇总，存在单向信息流限制，且没有考虑特征内部的冗余，导致融合输出特征的成本和贡献不平衡。本文基于FPN和PANet重复双向跨尺度连接的思想，采用更高效双向跨尺度连接和加权多尺度特征融合的BiFPN^[22]，它在不增加成本的情况下，可以实现更简单快速的多尺度特征融合。BiFPN的结构如图3所示。



(a) FPN (b) PANet (c) BiFPN

图3 不同的颈部结构图

Fig. 3 Diagram of different neck structures

该方法简化双向网络,删除单输入边的节点,并在同一水平的通道节点新增加一条边,引入可学习权重来学习不同缺陷特征的重要性,多次迭代同一层的双向路径以实现更高级的多尺度特征融合。这些融合的特征被反馈到后序网络中分别产生对象的类和边界盒预测,从而提高缺陷特征的提取和表达能力。它有助于检测不同特征的铸件内部缺陷,减轻网络对微小和重叠模糊缺陷的不准确识别。

2.3 损失函数的改进

在网络模型进行训练的时候,需要最小化损失函数来使得模型趋于收敛。在原YOLOv5s中定位损失是CIoU损失函数,它在引入一个最小包围框的概念基础上,又添加一个纵横比约束,比较两个盒子的长宽吻合度。虽然考虑的范围更多,包括重叠的面积、中心点距离、纵横比,但没有反应宽高分别与其置信度的真实差异,所以有时会阻碍模型有效的优化相似性,无法准确完成铸件缺陷定位的回归任务。

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (2)$$

$$LCIoU = 1 - IoU + \frac{\rho^2(b, b^{gt})}{c^2} + \alpha v \quad (3)$$

针对这一问题,本文引入EIoU Loss^[23]作为目标检测任务的回归损失函数,该损失函数考虑三个部分:即交并比损失,中心距损失和宽高损失。针对本文缺陷的边界框回归任务,将原有基础上的纵横比损失项

拆开,直接得到预测的宽高分别与最小外接框宽高的差值最小,加速收敛速度。同时优化缺陷训练样本不平衡问题,聚焦高质量锚框缺陷样本对网络训练中梯度的贡献度,忽略异常值带来过大的梯度影响,从而提高模型对缺陷的检测性能。公式如下:

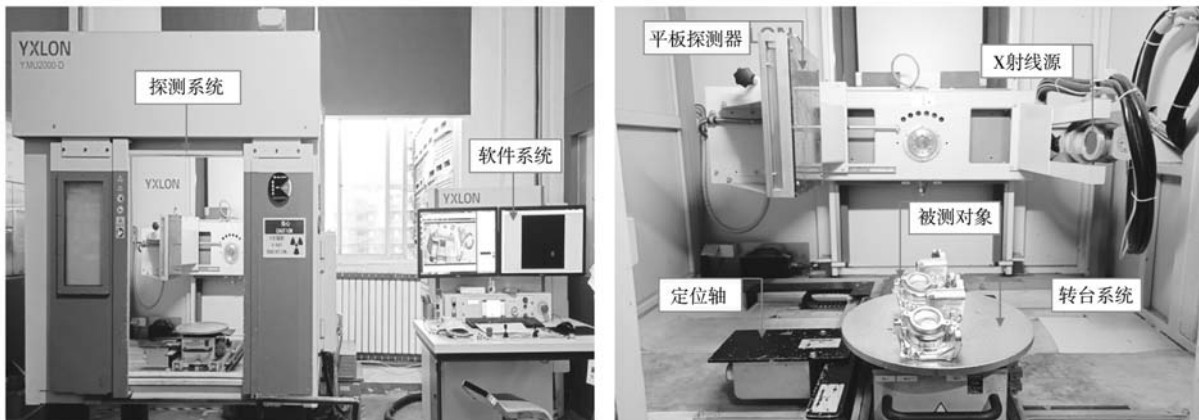
$$LCLIoU = 1 - IoU + \frac{\rho^2(b, b^{gt})}{(C_m^w)^2 + (C_m^h)^2} + \frac{\rho^2(w, w^{gt})}{(C_m^w)^2} + \frac{\rho^2(h, h^{gt})}{(C_m^h)^2} \quad (4)$$

式中:IoU为真实框和预测框的交并比, b 、 w 、 h 分别为预测框的中心点、长度和宽度, g_t 为真实框的中心点、长度和宽度。 ρ^2 为预测坐标系的中心点到真实坐标系的欧式距离, C_m^w 和 C_m^h 为最小外框的宽度和高度。

3 试验结果与分析

3.1 数据获取与预处理

本试验数据从专业铝合金铸造公司的生产车间现场采集,工作设备型号为德国YXLON依科视朗X射线透视机YMU2000-D,由160 kV开放式X射线管、非晶硅平板探测器、载物控制平台和计算机软件系统等组成,设备如图4所示。所有X射线探伤图像均由人工操作采集获得,数据集包含由压铸冷却完成的各种汽车三电系统壳体以及通信机体等结构件,筛除图像中无明显缺陷的图像,得到1 000 × 1 000像素的1 374张数字X射线缺陷图像。每张影像图都有一定区域的缺陷类型,如缩松、气孔、夹杂、裂纹等4种常见的压铸合金铸件的内部缺陷,如图5所示。



(a) 设备外形图

(b) 内部工作台结构图

图4 YMU2000-D X射线透视机平台

Fig. 4 YMU2000-D X-ray fluoroscopy machine platform

在获取的图像中,由于目标件结构和工人操作的差异性,会使得到的X影像中某些位置的小缺陷无法准确聚焦而造成模糊虚化。因此引入直方图均衡化算法和伽马变换来模拟图像曝光,改变图像对比度,提高图像质量和缺陷特征,将增强后的图像加入训练集,

从而提高后续训练的缺陷检测模型的泛化能力。如图6所示。

所有图像由专业人员用labelIMG软件仔细注释,生成带有类别标签和保证概率的矩形轨迹边界框,每个矩形边界框代表已识别缺陷的一个区域。将图像分




图5 常见铸件内部缺陷图像

Fig. 5 Images of the internal defects in common castings




图6 数据图像增强示例

图6 数据图像增强示例

Fig. 6 Example of the data image enhancement

为 640×640 像素的多个子图像作为输入，在交叉标记分类数据集按照8:1:1的比例随机分为训练集、验证集和测试集。数据集中各类缺陷的详细标注框数量如表1所示。

表1 数据集中各缺陷数量

Table 1 Numbers of the defects in the dataset

缺陷名称	训练集	验证集	测试集	总计
缩松	3 786	529	663	4 978
气孔	1 510	243	207	1 960
夹杂	547	97	106	750
裂纹	375	39	44	458

3.2 环境配置

硬件配置为 AMD Ryzen5 4600H CPU、NVIDIA GTX 1650 Ti 显卡、16 G 内存，试验开发环境基于 Windows 10 系统、CUDA Toolkit 11.0、Pytorch 1.7 深度学习框架平台。在训练过程中，学习率为0.01，动量为0.937，权值衰减为0.000 5。迭代次数为300，图像批大小设置为32，输入图像分辨率均匀调整为 640×640 。采用随机梯度下降法 (SGD) 对神经网络参数进行优化，保留网络模型中所有的数据增强，包括随机水平翻转、马赛克、随机图像缩放、随机图像平移和HSV颜色空间增强。

3.3 评估指标

考虑到铸造企业的实际需求及应用，本文将查准率、查全率、平均精确率 (mAP) 和每秒检测帧率 (FPS) 作为性能评价指标。Precision, Recall, mAP 的具体计算公式如下：

$$\text{Precision} (P) = \frac{TP}{FP+TP} \quad (5)$$

$$\text{Recall} (R) = \frac{TP}{FN+TP} \quad (6)$$

$$F1 = \frac{2 \times P \times R}{P+R} \quad (7)$$

$$mAP = \frac{1}{C} \sum_{k=i}^N P(K) \Delta R(K) \quad (8)$$

式中： TP 为真实阳性样本数， FP 为假阳性样本数， FN 为假阴性样本数， C 为检测类的个数， N 为参考阈值数， K 为阈值， P 为查准率， R 为查全率， $F1$ 为两者的调和平均值。 mAP 表示多个类别 AP 的平均值，本文选取 IoU 阈值为0.5，用于评估所有类别分类的综合能力指标。

3.4 试验结果与分析

3.4.1 模型评估

将所提模型X-YOLOv5用于训练铸件内部缺陷数据集，试验的迭代损失曲线和不同模型对比的 mAP 曲线如图7所示，从图7a可以看出，当模型训练到230个周期后，训练集和预测集的损失值逐渐收敛并趋于平稳，没有观察到过拟合或欠拟合。图7b显示四种不同模型在训练过程中平均精度的具体变化，在前100个周期迅速上升并出现小幅振荡，之后达到稳定，结果表明了模型训练的有效性。

3.4.2 消融试验结果

本文建立消融试验来验证不同优化模块的有效性，通过在原YOLOv5s模型中依次加入NCA注意力模块、BiFPN模块和EIoU损失函数构建改进的算法模型，用铸件缺陷测试数据集进行试验对比，每组使用

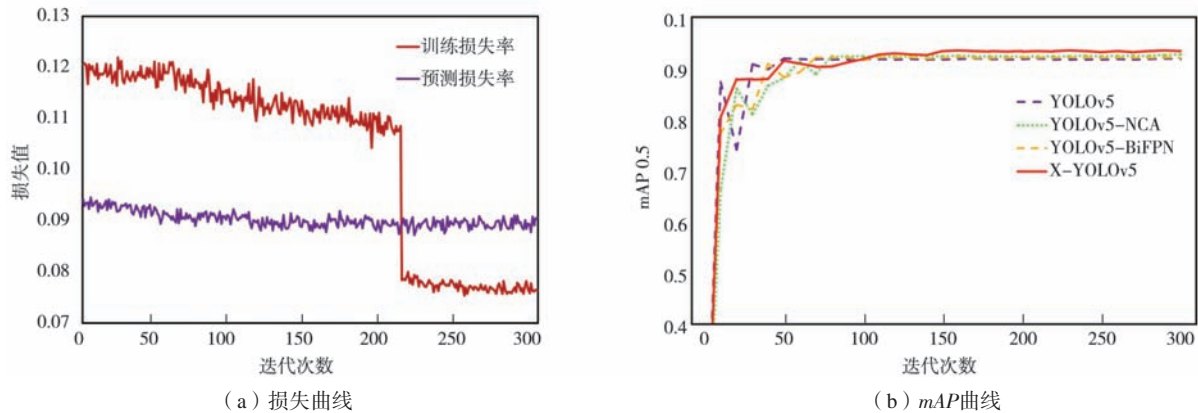


图7 模型训练的损失曲线和mAP曲线

Fig. 7 Loss curves and mAP curves for the model training

相同的超参数和训练方法。试验结果如表2所示。原始YOLOv5s模型在缺陷数据集上的平均识别精度 $mAP_{0.5}$ 为91.11%，通过加入注意力模块（NCA）、BiFPN模块和EIoU损失函数的三个改进模型在 $mAP_{0.5}$ 值与原始YOLOv5s相比，分别提高2.12%、1.54%和0.31%。本文提出的X-YOLOv5检测框架以 $mAP_{0.5}$ 值为93.89%实现最佳结果，相比于原始模型YOLOv5s提高2.78%。这些数据可以看出，注意力机制模块NCA和双向特征金字塔网络（BiFPN）模块的适当引入可以有效提高铸件内部缺陷的检测精度。

表2 不同改进策略的检测性能比较
Table 2 Comparison of the detection performance of different improvement strategies

模型	AP/%				$mAP_{0.5}/\%$
	缩松	气孔	夹杂	裂纹	
YOLOv5s	94.18	92.64	90.15	87.47	91.11
YOLOv5s-NCA	97.04	94.35	92.83	88.70	93.23
YOLOv5s-BiFPN	95.98	94.11	92.56	87.95	92.65
YOLOv5s-EIoU	94.53	93.24	90.33	87.58	91.42
X-YOLOv5s	97.43	95.12	93.64	89.37	93.89

表3 不同算法的检测性能比较
Table 3 Comparison of the detection performance of different algorithms

模型	参数量/ 10^6	GFLOPs	查准率/%	查全率/%	F1/%	$mAP_{0.5}/\%$	FPS
YOLOv5s	7.0	16.1	91.93	88.43	90.15	91.11	8.9
YOLOv4-tiny	5.9	16.2	82.57	80.18	79.36	74.46	7.1
YOLOx-s	9.0	26.8	88.61	86.76	87.68	88.40	3.8
YOLOv7	37.3	105.3	92.30	89.98	91.13	92.03	10.3
YOLOv8s	11.1	28.8	92.69	90.03	91.34	92.32	9.3
FasterR-CNN	60.2	523.9	64.32	62.45	63.37	62.16	2.6
Cascade R-CNN	88.0	543.7	66.32	63.16	64.71	65.29	2.1
X-YOLOv5s	9.5	18.8	93.34	89.75	91.50	93.89	8.1

3.4.3 不同检测模型对比

为更全面地评估本文模型检测性能和效率，将X-YOLOv5s模型与当前主流的双阶段检测模型Faster R-CNN、级联Cascade R-CNN和单阶段检测模型YOLOv4-tiny、YOLOx-s、YOLOv7、YOLOv8s进行比较试验，每组使用相同的试验参数和测试数据进行训练，结果如表3所示。本文提出的组合改进算法X-YOLOv5s在缺陷数据集上的准确率、召回率和F1值分别为93.34%、89.75%和91.50%，显著高于当前各个主流模型，且 $mAP_{0.5}$ 值相比与原始模型YOLOv5s增加2.78%。该模型的FPS达到每秒8.1帧，满足在实际工业缺陷检测中的部署应用。以上结果表明，本文改进的算法具有良好性能，在工业场景中对铸件内部缺陷的检测效果更加出色。

3.4.4 检测结果可视化

为验证本文算法对铸件内部缺陷的检测效果，通过选择不同结构件下的缺陷图像数据集进行实验，并与原始YOLOv5s模型对比结果。实验结果如图8所示。从图8a1、b1可看出，原始YOLOv5s模型对缩松缺陷存在漏检，而改进后的模型能在模糊背景下对缩松缺陷





图8 不同铸件内部缺陷检测对比
Fig. 8 Comparison of the defect detection results of different castings

实现完全检测。从图8a2、b2看出，本文改进的模型检测到原始YOLOv5遗漏的小尺寸夹杂缺陷，且整体具有更高的置信度。图8a3、b3显示对目标密集且存在背景干扰场景的缺陷检测性能，与原始YOLOv5s模型相比，本文改进后的模型可以从分布密集的疏松缺陷中

准确识别气孔缺陷，且对不同区域缺陷的检测框定位更加准确。

为进一步观察改进YOLOv5s模型的特征提取能力，本文采用Grad-CAM热图可视化方法^[24]，结果如图9所示。从两个模型的热图可以看出，与原始YOLOv5s



(a) 原图 (b) 原始YOLOv5s (c) 改进的X-YOLOv5s

图9 不同铸件内部缺陷检测的热力图可视化效果对比
Fig. 9 Comparison of the heat map visualizations of the internal defect detection in different castings

模型相比, 本文的X-YOLOv5s模型对小尺寸缺陷所在区域的响应颜色更深, 体现模型在检测过程中对图像缺陷热点更高的关注度。同时过滤掉某些形状相似的干扰特征(如结构孔和模糊背景), 对于不同缺陷区域的识别更加准确。这些结果表明, 本文提出的X-YOLOv5s模型对于铸件内部各类缺陷具有更强的识别能力, 并且在一定程度上可以去除模糊背景等干扰信息的影响, 增强模型的鲁棒性。

4 结语

本文提出了一种在双向加权特征融合网络中结合注意力机制的铸件内部缺陷检测方法, 以解决小目标、模糊场景下对比度弱的铸件内部缺陷准确定位和

识别问题。通过在原始YOLOv5s的颈部网络中添加改进的NCA注意机制模块, 从自底向上路径中提高网络提取小目标特征的能力; 引入BiFPN模块以实现高级的多尺度特征融合, 并提供更多的语义信息; 使用EIoU Loss作为边界回归的损失函数, 提高缺陷检测边界框的定位精度。在试验阶段, 使用图像处理技术有效地扩展测试样本, 以提高网络模型训练缺陷样本的精度和泛化能力。通过消融试验和对比试验结果表明, 本文提出的方法的调和平均值($F1$)达到91.50%, 检测平均精确度 $mAP_{0.5}$ 达到93.89%, 比YOLOv5s分别提高了1.35%和2.78%。检测精度明显高于其他方法, 适用于实际工业场景下对复杂多样的铝合金铸件内部缺陷检测应用。

参考文献:

- [1] INGLE V, SORTE M. Defects, Root causes in casting process and their remedies: review [J]. International Journal of Engineering Research and Applications, 2017, 07 (3): 47-54.
- [2] 丛明, 卢长奇, 刘冬, 等. 基于Refine-ACTDD的铸件外观微小缺陷检测方法 [J]. 计算机集成制造系统, 2022, 28 (9): 2815-2824.
- [3] JOLLY M R, PRABHAKAR A, STURZU B, et al. Review of non-destructive testing (NDT) techniques and their applicability to thick walled composites [J]. Procedia CIRP, 2015, 38: 129-136.
- [4] 武博, 计效园, 孙晓龙, 等. 基于X射线图像的铸件缺陷智能检测与识别方法研究进展 [J]. 铸造, 2022, 71 (6): 709-718.
- [5] 张仕军, 金振林. 基于多模型级联的双目视觉铸件缺陷检测方法 [J]. 机械工程学报, 2022, 58 (5): 34-43.
- [6] CHAUDHARI C V. Steel surface defect detection using Gcm, Gabor wavelet, Hog, and Random forest classifier [J]. Turkish Journal of Computer and Mathematics Education, 2021, 12 (12): 263-273.
- [7] 李思璇, 胡志刚, 王新征, 等. 改进人工鱼群的ORB特征匹配算法 [J]. 计算机工程与应用, 2022, 58 (1): 292-299.
- [8] LIU Y, XU K, XU J. An improved MB-LBP defect recognition approach for the surface of steel plates [J]. Applied Sciences, 2019, 9 (20): 4222.
- [9] WANG Y, GUO H. Weld defect detection of X-ray images based on support vector machine [J]. IETE Technical Review, 2014, 31 (2): 137-142.
- [10] RALE A P, GHARPURE D C, RAVINDRAN V R. Comparison of different ANN techniques for automatic defect detection in X-Ray images [C]//2009 International Conference on Emerging Trends in Electronic and Photonic Devices & Systems. IEEE, 2009: 193-197.
- [11] 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.
- [12] FERGUSON M, AK R, LEE Y T T, et al. Automatic localization of casting defects with convolutional neural networks [C]//2017 IEEE international conference on big data (big data). IEEE, 2017: 1726-1735.
- [13] 王军敏, 樊养余, 李祖贺. 基于深度卷积神经网络和迁移学习的纹理图像识别 [J]. 计算机辅助设计与图形学学报, 2022, 34 (5): 701-710.
- [14] DU W, SHEN H, FU J, et al. Approaches for improvement of the X-ray image defect detection of automobile casting aluminum parts based on deep learning [J]. Ndt & E International, 2019, 107: 102144.
- [15] 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.
- [16] 叶卓勋, 刘妹琴, 张森林. 基于轻量化深度学习网络的工业环境小目标缺陷检测 [J]. 控制与决策, 2023, 38 (5): 1231-1238.
- [17] YU H, LI X, SONG K, et al. Adaptive depth and receptive field selection network for defect semantic segmentation on castings X-rays [J]. NDT & E International, 2020, 116 (6): 102345.
- [18] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design [C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2021: 13713-13722.
- [19] LIU Y, SHAO Z, TENG Y, et al. NAM: Normalization-based attention module [J]. 2021, 2111, 12419.
- [20] HOWARD A, SANDLER M, CHU G, et al. Searching for mobilenetv3 [C]//Proceedings of the IEEE/CVF international conference on computer vision. 2019: 1314-1324.

- [21] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2017: 2117–2125.
- [22] TAN M, PANG R, LE Q V. Efficientdet: Scalable and efficient object detection [C]//Proceedings of the IEEE/CVF conference on computer vision and pattern recognition. 2020: 10781–10790.
- [23] ZHANG Y F, REN W, ZHANG Z, et al. Focal and efficient IOU loss for accurate bounding box regression [J]. Neurocomputing, 2022, 506: 146–157.
- [24] SELVARAJU R R, COGSWELL M, DAS A, et al. Grad-cam: visual explanations from deep networks via gradient-based localization [J]. International Journal of Computer Vision, 2020, 128 (2) : 336–359.

Casting Internal Defect Detection Method Based on Bidirectional Weighted Feature Fusion Network

WANG Lei^{1,2}, HE Wan-shan^{1,2}, ZHANG Ze-lin^{1,2}, XIA Xu-hui^{1,2}

(1. Key Laboratory of Metallurgical Equipment and Control, Ministry of Education, Wuhan University of Science and Technology, Wuhan430081, Hubei, China; 2. Hubei Provincial Key Laboratory of Mechanical Transmission and Manufacturing Engineering, Wuhan University of Science and Technology, Wuhan430081, Hubei, China)

Abstract:

Aiming at the problems of small internal defects, weak contrast and low efficiency of manual recognition in the process of X-ray nondestructive testing, a method of casting internal defects detection based on bi-weighted feature fusion network was proposed. Based on the YOLOv5 network model, an improved coordinate attention module (NCA) was introduced to improve the learning ability of the network for irregular defects and minor defects. Bidirectional feature pyramid network (BiFPN) was introduced to replace the original path aggregation network (PANet) to achieve multi-scale efficient fusion of defect features, and EIou Loss regression loss function was used to improve the accuracy of defect boundary frame location. The experimental results showed that the proposed method had good performance in detecting small targets and weak contrast defects in the castings.

Key words:

castings; defect detection; deep learning; attention module; bidirectional weighted feature fusion