

基于 YOLOv5 的改进轻量型 X 射线铝合金焊缝缺陷检测算法

程松¹, 杨洪刚¹, 徐学谦¹, 李敏², 陈云霞^{1*}

¹上海电机学院机械学院, 上海 201306;

²上海电力大学, 上海 201306

摘要 基于计算机视觉的图像识别和处理技术迅速发展,因此,X射线焊缝图像智能化评片已成为无损 X 射线检测的研究热点之一。快速准确识别焊缝内部小目标缺陷是智能评片的一个难点,鉴于此,本文提出了一种基于 YOLOv5-Tiny 的轻量型焊缝缺陷识别方法。首先,在 Backbone 部分加入注意力机制 SELayer,使模型实现持续的性能提升;然后,用 GhostBottleneck 模块替换 Head 层中的 C3 模块,保留边缘信息;最后,去除用于检测大物体的 13×13 特征层,并将多数普通卷积替换成深度可分离卷积,加快模型的训练与预测。模型分别采用 DIoU 与 CIoU 两种损失函数进行训练。实验结果表明:与 YOLOv5s 模型相比,YOLOv5-Tiny 模型的参数量减少了 33.6%,处理速度提升了 17.5%,预测权重减小了 32.8%,更好地实现嵌入式使用,模型的平均精度均值得到提升。

关键词 测量;无损检测;YOLOv5;缺陷识别;轻量型模型

中图分类号 TG441.7

文献标志码 A

DOI: 10.3788/CJL202249.2104005

1 引言

由于生产工艺和焊接环境等因素的影响,焊缝位置容易产生各类焊接缺陷^[1],如气孔、夹渣及未焊透等。在焊缝内部缺陷检测的实际场景中,小样本现象比较常见,因此,国内外研究人员从数据扩充、模型优化和迁移学习三方面改进了模型对数据采集量的需求^[2]。正因为如此,目前在线实时评片研究的重心仍是检测精度,其次是检测的实时性。在保证精度的同时提升检测速度对于工业实时检测具有重要意义。高效率的实时 X 射线铝合金焊缝内部缺陷检测是目前无损检测的热点问题。

在焊缝缺陷的 X 射线成像中,微小缺陷的成像十分棘手。微小缺陷缺乏肉眼可见的详细特征,对其进行检测时难以区分前景与背景,这是实时缺陷检测中的一个难点^[3]。随着计算机技术的发展,很多研究人员将智能算法引入铝合金焊缝图像的智能化评片领域,这些智能算法包括支持向量机算法、神经网络算法、主成分分析算法、卷积神经网络算法等^[4]。曾伟等^[5]提出了一种离散正弦/余弦变换与希尔伯特变换相结合的激光超声波成像技术,并采用该技术检测出了焊缝中缺陷的位置、大小及形状等,但实时性不易实现。韩家杰等^[6]通过基于线结构光的检测系统提取焊

缝中心线和特征点,从而测量出余高和焊缝宽度等参数,但该系统的自动化程度不高。

目前,基于深度学习的图像处理技术正在迅速发展,但焊缝缺陷的种类多样性和形态多变性,对基于深度学习的自动化检测技术提出了更高要求^[7]。卷积神经网络已被用于完成更复杂的任务,如图像处理、图像分割和目标检测等^[8]。目前主流的检测模型分为双阶段模型与单阶段模型,双阶段模型包括 SSD^[9-11]、FasterRCNN^[12-14]等,但目前对于目标检测使用最多的还是单阶段检测模型,如 YOLOv2^[15-16]、YOLOv3^[17-20]、YOLOv4^[21-25]等。单阶段检测模型的检测速度更快且精确率更高,在实际工业中的应用更为广泛。为了解决复杂环境下焊缝定位不准确的问题,张永帅等^[26]采用全卷积神经网络来预测焊缝的特征信息,并融合低层与高层特征信息来补充焊缝边缘的特征信息。

目前最新的 YOLOv5 网络相比前几代网络增加了 Focus 结构,改变了网络特征提取的架构,预测权重更小,检测精度更高,但图像处理效率不高,且在 X 射线铝合金焊缝内部缺陷检测中的应用较少。为了检测和识别焊缝的内部缺陷,本团队提出一种基于 YOLOv5-Tiny 模型的轻量 X 射线铝合金焊缝缺陷检测算法。通过结合注意力机制与 GhostBottleneck 模块,该算法更加注重缺陷的边缘信息,同时可以获取更

收稿日期: 2022-01-28; 修回日期: 2022-02-14; 录用日期: 2022-03-09

基金项目: 国家自然科学基金(51809161, 52005315)

通信作者: *chenyx@sdju.edu.cn

多的特征图,以此来消除冗余特征;此外,该算法根据焊缝内部缺陷数据集的特征去除了 13×13 的特征层,并结合深度可分离卷积,获取更加轻量的缺陷检测模型,可以满足工业实时检测中速度与精度的要求。

2 YOLOv5 网络

2.1 框架及原理

YOLOv5 网络根据宽度和深度可分为 4 个版本,分别为 YOLOv5s、YOLOv5m、YOLOv5l 和 YOLOv5x。本次实验选择宽度及深度最小的 YOLOv5s 网络。先对数据进行 Mosaic 增强,特征图经过 Focus 结构变换后输入网络,再经过 CBS (Convolution-BatchNormalization-SiLU)、C3 等进行特征提取,提取后的特征通过空间金字塔池化(SPP)整合后输入增强特征提取网络中,最后通过特征金字塔网络(FPN)和金字塔注意力网络(PAN)分别进行特征提取和融合。其中激活函数采用 SiLU,其示意图如图 1 所示。




图 1 SiLU 激活函数

Fig. 1 SiLU activation function

2.2 损失函数

DIoU (Distance-IntersectionoverUnion) 是 GIoU 的改进版,考虑了重叠面积及中心点距离的影响,其计

算公式为

$$L_{DIoU} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{c^2}, \quad (1)$$

式中:IoU 是交并比; $\rho^2(b, b^{gt})$ 表示预测框 b 与目标框 b^{gt} 中心点的欧氏距离; c 表示预测框 b 与目标框 b^{gt} 最小外接矩形对角线的距离。

CIoU (Complete IoU) 损失函数是在 DIoU 的基础上考虑了两框的长宽比而发展起来的,其计算公式为

$$L_{CIoU} = 1 - IoU + \frac{\rho^2(b, b^{gt})}{c^2} + av, \quad (2)$$

其中,

$$a = \frac{v}{1 - IoU + v}, \quad (3)$$

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

式中: a 和 v 分别表示权衡参数和衡量长宽比一致性参数; w^{gt} 与 h^{gt} 分别表示目标框的宽和高; w 与 h 分别表示预测框的宽和高。

3 算法改进

3.1 注意力机制

不同缺陷的特征对整个训练过程的贡献度不同。若对主干网络进行多次步长为 2 的卷积操作,就会导致特征信息丢失。为此,本文引入了注意力机制 (SELayer)^[27-28]。图 2 为注意力机制示意图,其中 fc 表示经过两次全连接后取 Sigmoid,将值固定在 0~1 之间, W 、 H 与 C 分别表示特征图的长、宽及通道数。首先对输入的特征层进行全局平均池化,获得 $1 \times 1 \times C$ 的特征层,然后经过 fc 模块获得输入特征层各层的通道数和权重,最后将各个权重与对应的通道数相乘。加入注意力机制后的模型更加注重气孔及未焊透缺陷边缘特征的提取,可以提升检测效果。




图 2 注意力机制示意图

Fig. 2 Schematic of attention mechanism

3.2 GhostBottleneck 模块

为了使模型在保证检测结果的同时更加轻量化,将原 YOLOv5s 的加强特征提取网络中的 C3 模块替换为 GhostBottleneck 模块^[29]。GhostBottleneck 模块由两个 GhostConv 模块与一个残差边融合组成,其中:第一个模块 (GhostConv_1) 通过卷积 (Conv) 层、标准化 (BN) 层和激活函数 (SiLU) 层对特

征图进行处理;第二个模块 (GhostConv_2) 不使用激活函数,通过卷积及标准化对特征图进行处理,使上下文信息得以连接,即模型对非线性卷积后的特征图进行卷积和标准化,以捕捉更多的特征图,消除冗余特征,得到更轻量化的模型。图 3 为 GhostConv_1 模块与 GhostConv_2 模块,图 4 为 GhostBottleneck 模块。




图 3 GhostConv 模块
Fig. 3 GhostConv module



图 4 GhostBottleneck 模块
Fig. 4 GhostBottleneck module

3.3 去除 YOLO Head 层

焊缝 X 射线探伤数据集集中的焊接缺陷在整张图

中所占像素值较少,属于小目标检测,而原 YOLOv5s 网络中 13×13 特征层的单个网格划分较大,适用于检测大目标,不适用于本文的检测对象,故将其去除,只保留 26×26 和 52×52 两个特征层用于预测气孔、夹渣与未焊透缺陷。此外,加入了深度可分离卷积,既可以保证模型精度又可以加快模型的训练和预测。

图 5 为改进后网络的整体框架图。主干特征网络新增加了 C3 模块和注意力机制,目的是使模型更关注气孔、夹渣等焊接缺陷边缘信息的提取与保留。改进后的网络通过深度可分离卷积减少参数量,利用 SPP 模块进行多重感受野融合,通过 GhostBottleneck 模块联合提取更多边缘特征,再与上文特征进行拼接,加深网络模型,使其具有良好的非线性表达能力,能学习更加复杂的变换和拟合更加复杂的特征输入。此外,改进后的网络去除了用于检测大目标的预测层,使得模型的处理速度提高,预测速度更快。

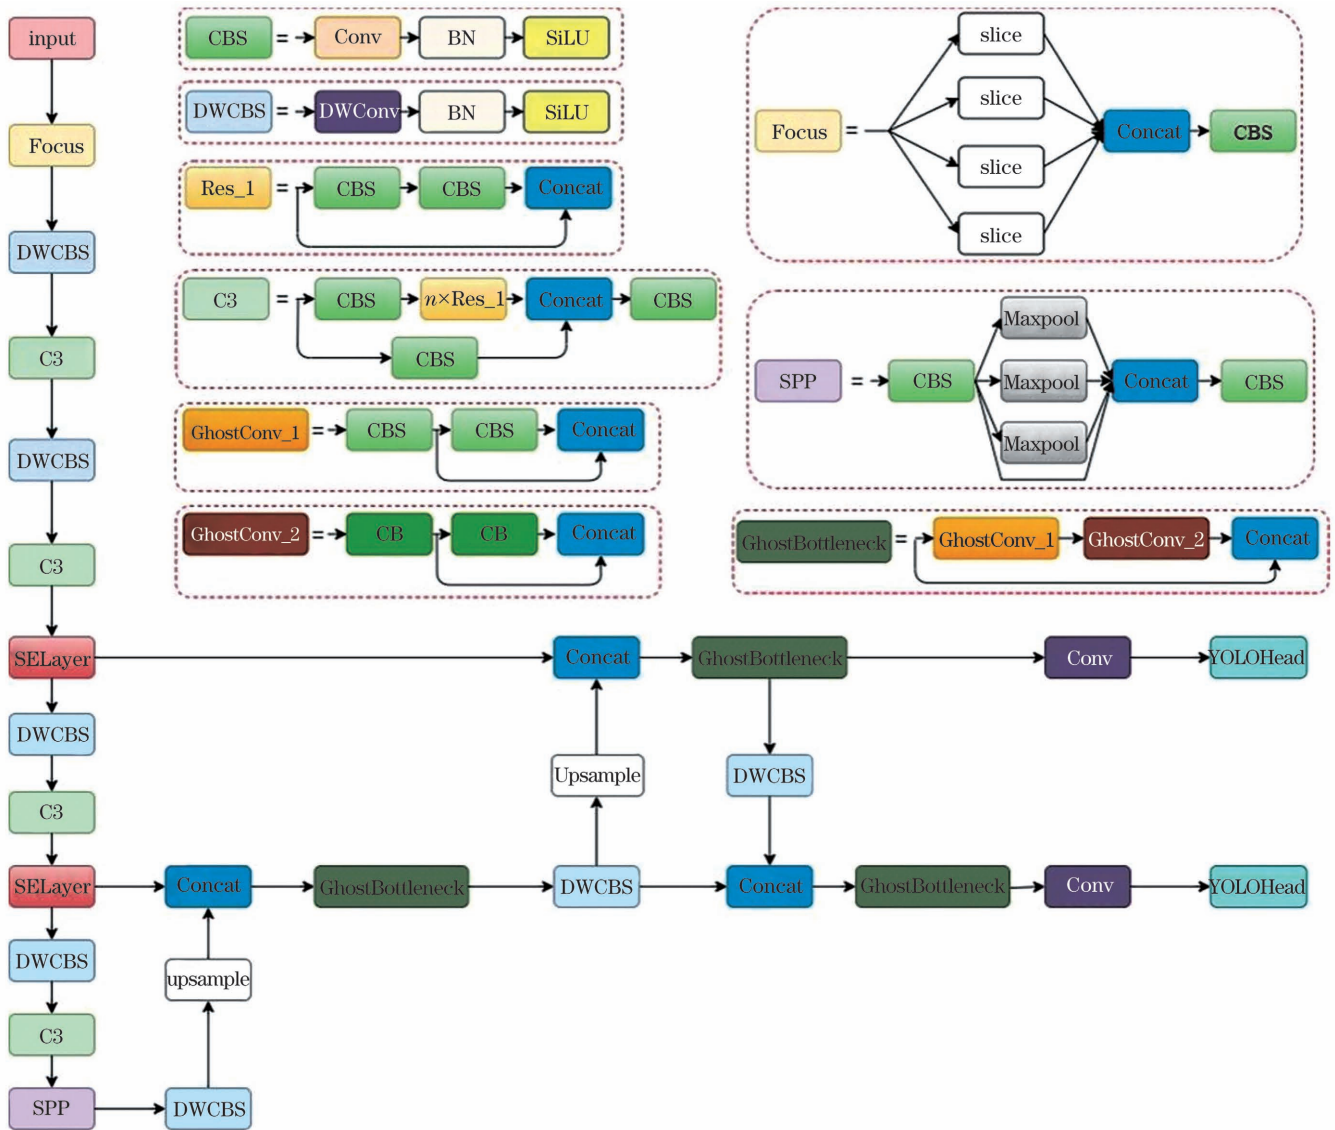


图 5 YOLOv5-Tiny 框架图
Fig. 5 YOLOv5-Tiny frame diagram

表 1 为 YOLOv5-Tiny 结构图,参数“-1”表示承接上层通道数,参数[-1,8]表示连接上层和第 8 层的

特征层,参数[32,64,3,2]分别代表输入通道数、输出通道数、卷积核大小和步长。

表 1 YOLOv5-Tiny 结构图
Table 1 YOLOv5-Tiny structure diagram

Serial number	From	Parameters	Module	Arguments
0	-1	3520	Focus	[3,32,3]
1	-1	704	DWConv	[32,64,3,2]
2	-1	35200	C3	[64,64,1]
3	-1	1408	DWConv	[64,128,3,2]
4	-1	222464	C3	[128,128,3]
5	-1	2048	SELayer	[128,16]
6	-1	2816	DWConv	[128,256,3,2]
7	-1	887296	C3	[256,256,3]
8	-1	8192	SELayer	[256,16]
9	-1	5632	DWConv	[256,512,3,2]
10	-1	2231296	C3	[512,512,1]
11	-1	656896	SPP	[512,512,[5,9,13]]
12	-1	1024	DWConv	[512,256,1,1]
13	-1	0	Upsample	[None,2]
14	[-1,8]	0	Concat	[1]
15	-1	408192	GhostBottleneck	[512,512]
16	-1	768	DWConv	[512,128,1,1]
17	-1	0	Upsample	[None,2]
18	[-1,5]	0	Concat	[1]
19	-1	105792	GhostBottleneck	[256,256]
20	-1	2560	DWConv	[256,128,3,2]
21	[-1,16]	0	Concat	[1]
22	-1	105792	GhostBottleneck	[256,256]
23	[19,22]	12336	Detect	

4 实验及结果分析

4.1 训练模型

实验数据集为焊缝内部缺陷 X 射线图片,共 1005 张,为数字 DR(digital radiography)图像,非公共数据集。焊缝缺陷主要包括气孔、夹渣及未焊透三种焊接

内部缺陷。采用图像旋转及亮度调节等方式将实验数据集扩充到 2801 张,扩充后的数据集具有多样性。图 6 为图像增强后的结果。本次实验通过 Mosaic 方法降低目标检测模型对相同缺陷所在位置的敏感性。

在 Window10 系统下,基于 Pytorch 深度学习框架并结合 Python 程序进行实验。表 2 为硬件设施。




图 6 图像增强。(a)旋转;(b)增加对比度

Fig. 6 Image enhancement. (a) Rotating; (b) increasing the contrast

表 2 硬件设施

Table 2 Hardware facilities

Hardware	Configure
CPU	I5-11400
GPU	RTX 3060
Memory /GB	16

数据集标签框的中心点坐标(x,y)、宽度和高度均进行了归一化处理。图 7(a)显示大部分缺陷集中在图像中间,图 7(b)中深色部分多集中于(0.1,0.1)处。这表明归一化后的标注框宽度和高度相对于整个图像的宽度和高度来说较小,缺陷的像素占比小,属于小目标缺陷检测,所以模型应更加重视小目标边缘特

征的提取与保留。

YOLOv5s 和 YOLOv5-Tiny 均使用 SGD 优化器对模型参数进行优化。输入图片大小为 416 pixel × 416 pixel, 模型训练过程中的 Batch_size 设置为 16, 总 Epoch 设置为 200, 初始学习率为 0.01, 动量为 0.937, 权值衰减 (weight_decay) 设置为 0.0005。模型刚开始

训练时使用 warmup 策略, warmup_momentum 设置为 0.8, 学习率为 0.1, Epoch 设置为 3, 即: 在前 3 个 Epoch 训练时, 模型学习率会由初始值逐渐变大, 训练 3 个 Epoch 后, 学习率变为 0.01, 之后, 学习率随着 Epoch 不断迭代而逐渐减小。这样可在保证模型深层稳定性的同时防止过拟合现象提前发生。




图 7 数据分析。(a)标注框中心点分布;(b)标注框大小分布

Fig. 7 Data analysis. (a) Distribution of center point of labeling frame; (b) size distribution of labeling frame

除了 YOLOv5s 外, 还将 YOLOv3、YOLOv4、YOLOv4-Tiny 作为对比模型, 而且后三个模型均通过解冻训练的方式进行对比, 优化器选择 Adam, 以便在取得较好结果的同时使时间和资源得到更充分利用。表 3、4 分别是解冻前后的训练参数。

表 3 解冻前的训练参数

Table 3 Training parameters before thawing

Parameter	Content
Size / (pixel × pixel)	416 × 416
Batch_size	16
Learning_rate	10 ⁻³
Optimizer	Adam
Epoch	0-80

表 4 解冻后训练参数

Table 4 Training parameters after thawing

Parameter	Content
Size / (pixel × pixel)	416 × 416
Batch_size	8
Learning_rate	10 ⁻⁴
Optimizer	Adam
Epoch	80-200

YOLOv5s 和 YOLOv5-Tiny 在测试集上的精确率和召回率变化曲线。

由图 8 可知, 在前 100 个 Epoch 训练中, YOLOv5-Tiny 模型精确率和召回率曲线的整体波动都比 YOLOv5s 模型更平缓。精确率 P 与召回率 R 的计算公式分别为

$$P = \frac{T_P}{T_P + F_P}, \quad (5)$$

$$R = \frac{T_P}{T_P + F_N}. \quad (6)$$

4.2 结果对比

模型的整体预测效果通过 5 种评判指标进行综合评价, 这 5 种指标为精确率、召回率、平均精度、平均精度均值、处理速度 (单位为 frame / s)^[30]。图 8 为

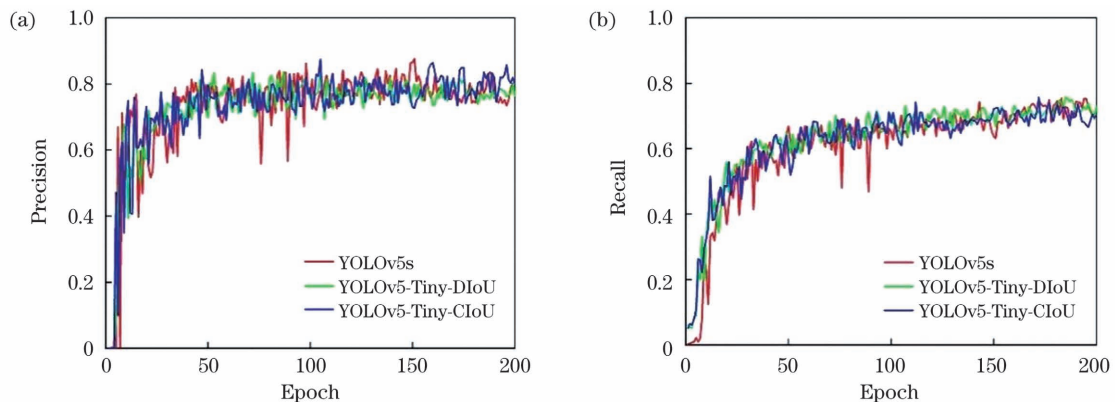


图 8 精确率与召回率的变化曲线。(a)精确率;(b)召回率

Fig. 8 Change curves of precision rate and recall rate. (a) Precision; (b) recall

以气孔缺陷为例,式(5)与式(6)中的 T_P 表示正确检测出该缺陷是气孔的数量, F_P 表示将非气孔缺陷错误地检测为气孔的缺陷数量, F_N 表示该缺陷是气孔但未检测出是气孔的缺陷数量。

表 5 为 YOLOv5-Tiny-DIoU 等 6 种不同模型对不同缺陷检测的精确率与召回率的对比。由表 5 可知,与 YOLOv5s 模型相比, YOLOv5-Tiny-DIoU 模型对气孔、夹渣、未熔合这三种缺陷的召回率上分别提

升了 5、2.3、6.1 个百分点。YOLOv5-Tiny-DIoU 模型在主干特征提取网络中添加了注意力机制 SELayer,增大了有用特征信息通道数的权重,使模型更注重该特征。在加强特征提取网络中,原来的 C3 模块被替换为 GhostBottleneck 模块,可在加深网络的同时,通过多个 GhostConv 小模块获取更多的特征图,因而能消除冗余特征并充分融合上下特征层的信息。

表 5 不同模型对三种缺陷的精确率与召回率

Table 5 Precision and recall rate of different models on three defects

unit: %

Model	Precision			Recall		
	Pore	Slag inclusion	Incomplete penetration	Pore	Slag inclusion	Incomplete penetration
YOLOv5-Tiny-DIoU	85.3	88.2	84.6	89.2	91.2	70.8
YOLOv5-Tiny-CIoU	85.4	88.7	84.4	88.4	90.3	69.4
YOLOv5s	86.3	88.5	84.2	84.2	88.9	64.7
YOLOv4	85.4	86.9	87.9	46.5	65.9	21.1
YOLOv3	87.9	90.8	88.4	58.2	69.3	63.3
YOLOv4-Tiny	82.3	89.1	74.8	52.4	67.1	26.6

本文通过引入 F_1 参数来综合考虑精确率与召回率。 F_1 参数的计算公式为

$$F_1 = \frac{2PR}{P+R} \quad (7)$$

表 6 为不同模型在 F_1 、参数量(Parameters)、权重及处理速度上的对比。表 6 表明,与 YOLOv5s 模型相比, YOLOv5-Tiny 模型对三种缺陷精确率与召回率的调和平均值 F_1 均有所提升。YOLOv5-Tiny 模型通过

GhostBottleneck 模块进行轻量化,去除了 YOLOv5s 模型中用于检测大目标的 13×13 特征层,加快了网络解码、预测的速度,处理速度提升了 17.5%,单帧图片的处理时间由 0.0175 s 缩短到 0.0149 s,能够满足工业实时检测的需求。同时, YOLOv5-Tiny 模型通过深度可分离卷积改变卷积过程,使得参数量相对于 YOLOv5s 模型减少了 33.6%,预测权重减小了 32.8%,有利于模型的嵌入式使用。

表 6 不同模型的性能对比

Table 6 Performance comparison of different models

Model	F_1			Parameters	Weight /MB	Detection speed / (frame·s ⁻¹)
	Pore	Slag inclusion	Incomplete penetration			
YOLOv5-Tiny-DIoU	0.87	0.90	0.77	4693936	9.2	67
YOLOv5-Tiny-CIoU	0.87	0.89	0.76	4693936	9.2	67
YOLOv5s	0.85	0.89	0.73	7068936	13.7	57
YOLOv4	0.60	0.75	0.34	64040001	244.4	42
YOLOv3	0.70	0.79	0.74	61949149	235.1	51
YOLOv4-Tiny	0.64	0.77	0.39	5961014	22.5	155

图 9 更直观地展现了 6 种检测模型 F_1 值的变化趋势,可以发现 YOLOv5-Tiny 模型在焊缝内部焊接缺陷检测中的效果最好。

平均精度(AP,记为 P_{AP})与平均精度均值(mAP,记为 P_{mAP})是评判模型的重要指标,其中后者是所有缺陷类型的平均精度。平均精度与平均精度均值的计算公式为

$$P_{AP, j} = \frac{\sum_{i=1}^{N_j} P_i}{N_j} \quad (8)$$

$$P_{mAP} = \frac{\sum_{j=1}^j P_{AP, j}}{j} \quad (9)$$

以气孔为例, $P_{AP, j}$ 表示气孔缺陷所有精确率之和与气孔缺陷总数的比值, P_{mAP} 表示不同种类缺陷的平均精度 AP 的总和与缺陷类别数的比值。表 7 为不同模型对三种缺陷的平均精度 AP 与平均精度均值 mAP。

由表 7 可知,与 YOLOv5s 模型相比, YOLOv5-Tiny 模型对三种缺陷的平均精度 AP 与平均精度均值 mAP 均有所提升。这说明在 YOLOv5s 网络中加入注意力机制关注相关信息,并通过联合加强特征提取网络中的 GhostBottleneck 模块,可以实现较快的检测速度。图 10 是不同模型的测试结果。

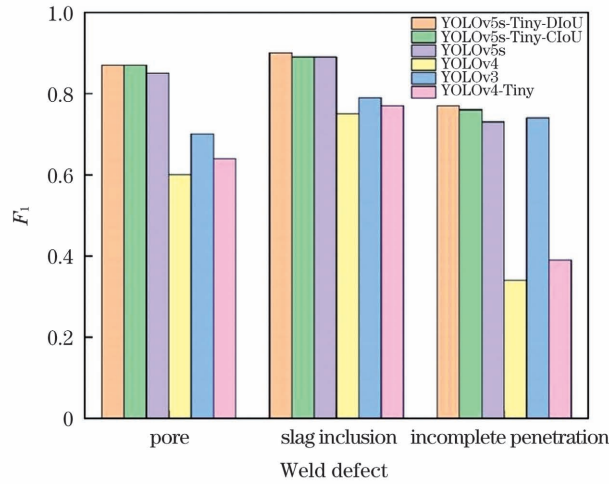


图 9 不同模型的 F_1 值

Fig. 9 F_1 values of different models

表 7 不同模型的平均精度 AP 与平均精度均值 mAP

Table 7 Average precision (AP) and mean average precision (mAP) of different models

unit: %

Model	AP			mAP@0.5
	Pore	Slag inclusion	Incomplete penetration	
YOLOv5-Tiny-DIoU	89.9	91	81.4	87.4
YOLOv5-Tiny-CIoU	89.8	91.2	80.6	87.2
YOLOv5s	88.2	91.1	77.1	85.5
YOLOv4	67.3	79.3	54.4	67.0
YOLOv3	75.2	86.1	75.3	78.8
YOLOv4-Tiny	63.9	77.6	45.6	62.3

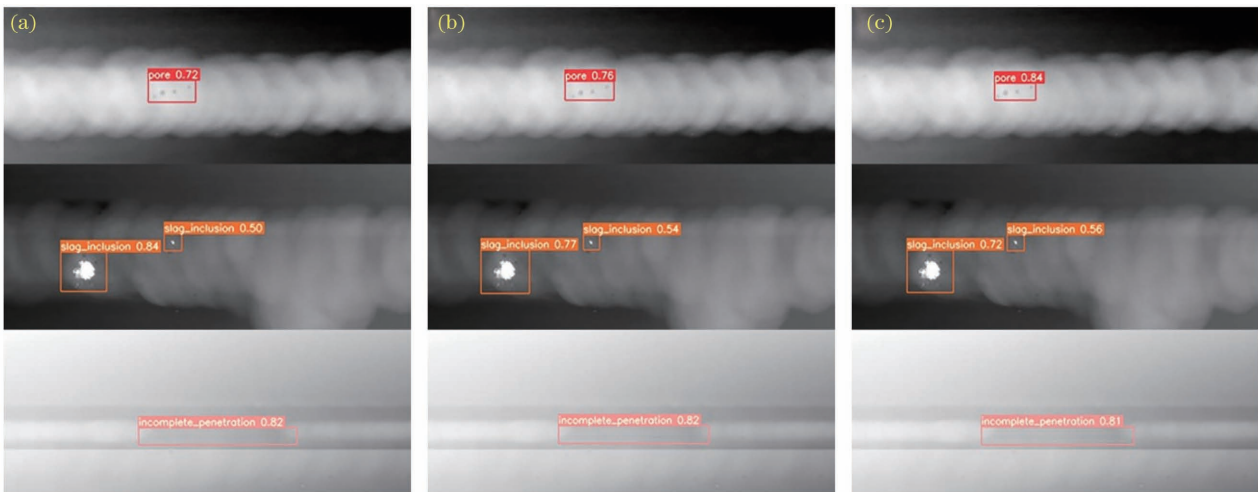


图 10 不同模型的检测效果图。(a)YOLOv5s;(b)YOLOv5-Tiny-DIoU;(c)YOLOv5-Tiny-CIoU

Fig. 10 Detection effect diagrams of different models. (a) YOLOv5s; (b) YOLOv5-Tiny-DIoU; (c) YOLOv5-Tiny-CIoU

5 结 论

针对焊缝内部小目标缺陷难以检测的问题,本文提出了一种基于 YOLOv5-Tiny 的轻量型 X 射线焊缝内部缺陷检测模型。该模型在原 YOLOv5 模型中的基础上加入了注意力机制,并新增了 GhostBottleneck 模块,删除了加强特征提取网络中的 C3 模块,同时删除了用于检测大目标的 13×13 特征层并将部分普通

卷积替换为深度可分离卷积,从而使得模型参数量减少,同时更精确地保留了气孔、夹渣和未焊透等三种缺陷的边缘信息。最后,通过 CIoU 与 DIoU 两种损失函数对改进后的模型进行训练,训练结果表明,改进后的模型在提升三种缺陷 F_1 参数、平均精度与平均精度均值等检测指标的同时,处理速度得到了显著提升,单帧图片的处理时间由 0.0175 s 缩短到 0.0149 s。与原 YOLOv5s 模型相比,YOLOv5-Tiny 模型的检测

速度更快且召回率更高,较小的预测权重更便于嵌入式使用。YOLOv5-Tiny 模型对于实现铝合金焊缝 X 射线图像中缺陷的快速、准确检测具有重要意义。

参 考 文 献

- [1] 王靖然, 王桂棠, 杨波, 等. 深度学习在焊缝缺陷检测的应用研究综述[J]. 机电工程技术, 2021, 50(3): 65-68.
Wang J R, Wang G T, Yang B, et al. Summary of research on application of deep learning in weld defect detection[J]. Mechanical & Electrical Engineering Technology, 2021, 50(3): 65-68.
- [2] 刘颖, 雷研博, 范九伦, 等. 基于小样本学习的图像分类技术综述[J]. 自动化学报, 2021, 47(2): 297-315.
Liu Y, Lei Y B, Fan J L, et al. Survey on image classification technology based on small sample learning[J]. Acta Automatica Sinica, 2021, 47(2): 297-315.
- [3] 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):1-22.
Zhang H, Zhang Z Q, Chen Y R, et al. Application progress and Prospect of nondestructive testing technology for defects of industrial castings[J]. Acta Automatica Sinica, 2022, 48(4):1-22.
- [4] 王思宇, 高炜欣, 张翔松. X 射线焊缝图像缺陷检测算法综述[J]. 热加工工艺, 2020, 49(15): 1-8.
Wang S Y, Gao W X, Zhang X S. Summary of defect detection algorithms for X-ray weld image[J]. Hot Working Technology, 2020, 49(15): 1-8.
- [5] 曾伟, 王海涛, 田贵云, 等. 激光超声波成像技术在奥氏体不锈钢焊缝检测中的研究[J]. 中国激光, 2014, 41(7): 0703004.
Zeng W, Wang H T, Tian G Y, et al. Research on laser ultrasound imaging in detection of austenitic stainless steel weld [J]. Chinese Journal of Lasers, 2014, 41(7): 0703004.
- [6] 韩家杰, 周建平, 薛瑞雷, 等. 线结构光管道焊缝表面形貌重建与质量评估[J]. 中国激光, 2021, 48(14): 1402010.
Han J J, Zhou J P, Xue R L, et al. Surface morphology reconstruction and quality evaluation of pipeline weld based on line structured light[J]. Chinese Journal of Lasers, 2021, 48(14): 1402010.
- [7] 马强, 李龙涛, 耿志卿, 等. 基于改进的 YOLOv3 模型的焊缝缺陷检测方法研究[J]. 上海汽车, 2021(6): 56-62.
Ma Q, Li L T, Geng Z Q, et al. Research on the welding flaw detection method based on enhanced YOLOv3 model [J]. Shanghai Auto, 2021(6): 56-62.
- [8] Xing J J, Jia M P. A convolutional neural network-based method for workpiece surface defect detection[J]. Measurement, 2021, 176: 109185.
- [9] Li Y D, Dong H, Li H G, et al. Multi-block SSD based on small object detection for UAV railway scene surveillance[J]. Chinese Journal of Aeronautics, 2020, 33(6): 1747-1755.
- [10] Huang Z, Yin Z Y, Ma Y, et al. Mobile phone component object detection algorithm based on improved SSD[J]. Procedia Computer Science, 2021, 183: 107-114.
- [11] Sun X H, Gu J N, Huang R. A modified SSD method for electronic components fast recognition[J]. Optik, 2020, 205: 163767.
- [12] Sun X D, Wu P C, Hoi S C H. Face detection using deep learning: an improved faster RCNN approach [J]. Neurocomputing, 2018, 299: 42-50.
- [13] Mansour R F, Escorcía-Gutiérrez J, Gamarra M, et al. Intelligent video anomaly detection and classification using faster RCNN with deep reinforcement learning model[J]. Image and Vision Computing, 2021, 112: 104229.
- [14] Jiang D, Li G F, Tan C, et al. Semantic segmentation for multiscale target based on object recognition using the improved Faster-RCNN model[J]. Future Generation Computer Systems, 2021, 123: 94-104.
- [15] 刘伟铭, 邹星宇. 基于改进 YOLOv2 的动车组裙板螺栓检测[J]. 铁道标准设计, 2022, 66(1): 161-166.
Liu W M, Zou X Y. Detection of bolts on apron boards of EMUs based on improved YOLOv2 [J]. Railway Standard Design, 2022, 66(1): 161-166.
- [16] Kavitha N, Chandrappa D N. Optimized YOLOv2 based vehicle classification and tracking for intelligent transportation system [J]. Results in Control and Optimization, 2021, 2: 100008.
- [17] 石振华, 陈杰. 改进 YoloV3 算法在工件缺陷检测中的应用[J]. 机械设计与制造, 2021(4): 62-65, 69.
Shi Z H, Chen J. Research on the detection of workpiece surface defects based on YoloV3[J]. Machinery Design & Manufacture, 2021(4): 62-65, 69.
- [18] 孙迎春, 潘树国, 赵涛, 等. 基于优化 YOLOv3 算法的交通灯检测[J]. 光学学报, 2020, 40(12): 1215001
Sun Y C, Pan S G, Zhao T, et al. Traffic light detection based on optimized YOLOv3 algorithm[J]. Acta Optica Sinica, 2020, 40(12): 1215001
- [19] 鞠默然, 罗海波, 王仲博, 等. 改进的 YOLO V3 算法及其在小目标检测中的应用[J]. 光学学报, 2019, 39(7): 0715004
Ju M R, Luo H B, Wang Z B, et al. Improved YOLO V3 algorithm and its application in small target detection[J]. Acta Optica Sinica, 2019, 39(7): 0715004
- [20] Li Y, Lu Y J, Chen J. A deep learning approach for real-time rebar counting on the construction site based on YOLOv3 detector[J]. Automation in Construction, 2021, 124: 103602.
- [21] 来文豪, 周孟然, 胡锋, 等. 基于多光谱成像和改进 YOLO v4 的煤矸石检测[J]. 光学学报, 2020, 40(24): 2411001
Lai W H, Zhou M G, Hu F, et al. Coal gangue detection based on multi-spectral imaging and improved YOLO v4 [J]. Acta Optica Sinica, 2020, 40(24): 2411001
- [22] 高伟, 周宸, 郭谋发. 基于改进 YOLOv4 及 SR-GAN 的绝缘子缺陷辨识研究[J]. 电机与控制学报, 2021, 25(11): 93-104.
Gao W, Zhou C, Guo M F. Insulator defect identification via improved YOLOv4 and SR-GAN algorithm [J]. Electric Machines and Control, 2021, 25(11): 93-104.
- [23] Yu Z W, Shen Y G, Shen C K. A real-time detection approach for bridge cracks based on YOLOv4-FPM [J]. Automation in Construction, 2021, 122: 103514.
- [24] Guo F, Qian Y, Shi Y F. Real-time railroad track components inspection based on the improved YOLOv4 framework [J]. Automation in Construction, 2021, 125: 103596.
- [25] He D Q, Zou Z H, Chen Y J, et al. Obstacle detection of rail transit based on deep learning [J]. Measurement, 2021, 176: 109241.
- [26] 张永帅, 杨国威, 王琦琦, 等. 基于全卷积神经网络的焊缝特征提取[J]. 中国激光, 2019, 46(3): 0302002.
Zhang Y S, Yang G W, Wang Q Q, et al. Weld feature extraction based on fully convolutional networks [J]. Chinese Journal of Lasers, 2019, 46(3): 0302002.
- [27] 孙美君, 吕超章, 韩亚洪, 等. 弱监督学习下的融合注意力机制的表面缺陷检测[J]. 计算机辅助设计与图形学学报, 2021, 33(6): 920-928.
Sun M J, Lü C Z, Han Y H, et al. Weakly supervised surface defect detection based on attention mechanism [J]. Journal of Computer-Aided Design & Computer Graphics, 2021, 33(6): 920-928.
- [28] 伍艺佳, 华雄, 王丽蓉, 等. 基于注意力机制学习的变电设备缺陷检测方法[J]. 计算机与现代化, 2021(2): 7-12, 17.
Wu Y J, Hua X, Wang L R, et al. Method of substation equipment defect detection based on attention mechanism learning[J]. Computer and Modernization, 2021(2): 7-12, 17.
- [29] Han K, Wang Y H, Tian Q, et al. GhostNet: more features from cheap operations [C] // 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 13-19, 2020, Seattle, WA, USA. New York: IEEE Press, 2020: 1577-1586.
- [30] 杨耘, 李龙威, 高思岩, 等. 基于 YOLOv3 网络训练优化的分辨率遥感影像目标检测[J]. 激光与光电子学进展, 2021, 58(16): 1601002.
Yang Y, Li L W, Gao S Y, et al. Objects detection from high-resolution remote sensing imagery using training-optimized YOLOv3 network[J]. Laser & Optoelectronics Progress, 2021, 58(16): 1601002.

Improved Lightweight X-Ray Aluminum Alloy Weld Defects Detection Algorithm Based on YOLOv5

Cheng Song¹, Yang Honggang¹, Xu Xueqian¹, Li Min², Chen Yunxia¹

¹*School of Mechanical Engineering, Shanghai Dianji University, Shanghai 201306, China;*

²*Shanghai University of Electric Power, Shanghai 201306, China*

Abstract

Objective Industrial equipment is prone to various internal welding defects during the process owing to factors such as the manufacturing process and welding environments, such as pores, slag inclusion, and incomplete penetration. However, the problem of small defects in radiographic inspection of weld defects is challenging as well. The most serious problem is the lack of detailed features visible to the naked eye, making it difficult to distinguish between the foreground and background during the inspection process. Therefore, it is essential to detect the internal defects of the weld in real-time. In industrial inspection, the type of X-ray flaw detection images is generally determined and located manually. Manual film evaluation has a high workload and low efficiency, as well as false and missed detection. Deep learning is now widely used in target recognition, thanks to the rapid development of computer and digital image processing technology. In this paper, a weld defect detection algorithm based on lightweight YOLOv5-Tiny is proposed, which is combined with the characteristics of weld internal defects in X-ray images.

Methods First, the edges of pores and incomplete penetration are blurred, making it difficult for the model to extract the edge information of defects, resulting in a low model recall rate. Therefore, an attention mechanism SELayer is added to the Backbone part. This mechanism can use limited attention resources to quickly filter out high-value information from a large amount of information, allowing the model to pay more attention to the edge information of defects, retains more edge information, and improve the model's performance continuously. Second, replace all C3 modules with the GhostBottleneck module in the Head section. The GhostBottleneck module is composed of two GhostConv modules and a residual edge. The function of the GhostConv_1 module is to process the input feature map by convolution, normalization, and activation function; the GhostConv_2 module removes the activation function and processes the feature map using convolution and normalization to connect the context information. Therefore, after nonlinear convolution, the model is convolved and normalized again on the feature map, allowing it to capture more feature maps and eliminate redundant features, resulting in a more lightweight model. Finally, the 13×13 feature layer used to detect large objects is removed, and the 26×26 and 52×52 feature layers are reserved for predicting pores, slag inclusion, and incomplete penetration, thereby speeding up the training and prediction of the model.

Results and Discussions When compared to the original YOLOv5 model, the improved model changes more gently in accuracy and recall without large fluctuations during the training process (Fig. 8). The attention mechanism and GhostBottleneck module enable the model to learn more defect features, and various detection indicators such as accuracy, recall, AP (average precision), and mAP (mean average precision) values have significantly improved (Table 5 and Table 7). The 13×13 feature layer is removed and combined with depth separable convolution, so that the model reduces the number of parameters by 33.6%, the processing time of each frame by 14.9% (shortens from 0.0175 s to 0.0149 s), and the size of the prediction weight by 32.8% (Table 6).

Conclusions An improved lightweight YOLOv5-Tiny weld internal defect detection algorithm is proposed to address the problem of difficult detection of small target defects in X-ray weld images. The algorithm adds an attention mechanism, replaces the C3 module in the enhanced feature extraction network with the GhostBottleneck module, deletes the 13×13 feature layer used to detect large targets, and replaces part of ordinary convolution with depthwise separable convolution when compared to the original YOLOv5 model. Therefore, while the number of model parameters is reduced, the edge information of three defects, such as pore, slag inclusion, and incomplete penetration, is more accurately preserved. Finally, the improved model is trained using the CIoU and DIoU loss functions, respectively. The training results show that the improved model can improve the detection indicators of F_1 , AP, and mAP of the three defects, and its processing velocity has been significantly improved. The processing time of a single frame of images is reduced from 0.0175 s of the YOLOv5 model to 0.0149 s. When compared to the original YOLOv5s algorithm, the YOLOv5-Tiny algorithm has a faster detection speed and higher recall rate, and its smaller prediction weight is more convenient for embedded use. The proposed algorithm is of great significance for the rapid and accurate defect detection of aluminum alloy weld radiographic images.

Key words measurement; nondestructive examination; YOLOv5; defect identification; lightweight model