

DOI:10.19651/j.cnki.emt.2209590

基于改进 YOLOv5 的金属焊缝缺陷检测^{*}

李衍照 于雷 田金文

(青岛科技大学自动化与电子工程学院 青岛 266061)

摘要: 为提高工业上焊缝缺陷自动检测与处理的效率, 基于深度学习提出一种改进的 YOLOv5 焊缝缺陷检测方法。针对焊缝样本数据不足的问题, 提出一种 Mosaic+Mixup 的数据增强策略, 同时为减少网络的计算量和网络参数量, 引入轻量型的 GhostNet 网络代替 YOLOv5 主干网络中 CSP1 模块中的残差模块, 并且采用 CIOU_Loss 作为坐标位置损失提高算法的收敛速度与准确率。最后使用测试集进行焊缝缺陷检测, 改进的 YOLOv5 的平均精度均值 (mAP) 达到 96.88%, 单张图片检测时间不超过 50 ms, 优于传统机器学习算法, 能够满足实际工程中对焊缝缺陷的实时性检测要求。

关键词: 深度学习; 焊缝缺陷检测; YOLOv5; 目标检测; GhostNet

中图分类号: TP391.41; TG441.7 文献标识码: A 国家标准学科分类代码: 520.6040

Metal weld defect detection based on improved YOLOv5

Li Yanzhao Yu Lei Tian Jinwen

(College of Automation and Electronic Engineering, Qingdao University of Science and Technology, Qingdao 266061, China)

Abstract: An improved YOLOv5 weld defect detection method based on deep learning was proposed in response to improve the efficiency of automatic detection and processing of weld defects in industry. Aiming at the insufficient weld sample data, a mosaic + mixup data augmentation strategy was proposed. At the same time, in order to reduce the amount of calculation and parameters of network, a lightweight GhostNet network was introduced to replace the residual module in CSP1 module in YOLOv5 backbone network, and CIOU_Loss was used as the coordinate position loss to improve the convergence rate and accuracy of the algorithm. Finally, the testing set was used for weld defect detection. The improved YOLOv5 has a mean average precision (mAP) of 96.88%, and the detection time of a single image is no more than 50 milliseconds, which is better than the traditional machine learning algorithms, could meet the real-time detection requirements of weld defects in practical engineering.

Keywords: deep learning; weld defect detection; YOLOv5; target detection; GhostNet

0 引言

随着我国近几年工业化水平的提高, 工业焊接工艺也在不断地追求完美。焊缝美观是检验焊接工艺的重要评判标准之一, 但是在焊接过程中由于焊接部件受到外界因素的影响, 在焊接部位会形成不同类型的缺陷^[1], 像焊缝余高, 溅射、气孔、夹渣、未焊透、咬边、焊瘤、焊偏等, 这些工艺缺陷是不可避免的。然而一部分缺陷像余高、溅射、焊瘤是可以通过打磨进行处理的, 为了保证焊接产品的质量以及焊接工艺的完美, 需要对焊接部位进行检测, 检测是否存在工艺缺陷, 并将检测到的缺陷进行分类, 或是打磨处理或是再次焊接。最开始这种检测依靠人工, 人工检测需要耗费大量人力和时间, 因工人经验不同导致检测结果一致性差,

无法满足现代工业的生产需求^[2]。随着近些年科学技术的不断改进, 尤其是在工业领域的成功应用, 人们逐渐引入机器视觉等方法对焊缝表面进行缺陷检测。

马强等^[3]对 YOLOv3 模型网络结构进行改进, 在部分卷积层之间添加残差层, 缓解了梯度消失问题, 去除了一些冗余训练, 减少部分权重数据量, 实现了焊缝缺陷的检测。Khumaidi 等^[4]为实现焊缝缺陷的分类与识别, 提出了一种卷积神经网络和高斯代数结合的方法, 并达到了较高的准确度。王宸等^[5]使用 Mish 激活函数作为 YOLOv3 主干网络的激活函数, 利用改进的 YOLOv3 模型对焊缝进行检测。焦敬品等^[6]分析了不同焊缝图像的特征, 选出几种用于表征缺陷的特征参数, 使用 BP 神经网络对焊缝缺陷进

收稿日期: 2022-04-13

*基金项目: 山东省重大科技创新工程(2021SFJC0601)项目资助

行检测。鲍峰等^[7]采用 K 均值算法对焊缝缺陷数据集进行聚类获取目标框的策略对 YOLOv3 进行改进,并将其应用于焊缝缺陷检测中。唐茂俊等^[8]提出改进的 Faster-RCNN 检测模型,利用 K 均值算法优化锚框并引入 FPN 多尺度检测和 DCR 解耦分类细化结构进行分类细化,提高焊缝缺陷检测的精度。谷静等^[9]采用动态增强的方法对数据进行处理,并引入密集连接卷积网络的焊缝缺陷检测算法对焊缝缺陷进行检测。Malarvel 等^[10]提出一种焊缝图像去噪的方法,增强焊缝图像特征,实现了焊缝缺陷检测。虽然现在已经把深度学习引用到焊缝的缺陷检测中,但是识别精度和识别速度仍需提高。

因此本文提出一种基于 YOLOv5 的缺陷检测方法,采集焊缝图像制作数据集,对 YOLOv5 进行改进,实现焊缝缺陷的识别分类和定位功能。最终通过实验验证了该方法的可行性。

1 焊缝数据采集与处理

1.1 图像采集

焊缝常见的缺陷主要有余高、溅射、气孔、夹渣、未焊透、咬边、焊瘤、焊偏等几种类型,本文主要识别余高、溅射和焊瘤三种类型缺陷,用于后期的直接打磨处理。为实现缺陷识别,需要采集大量的焊缝图像制作用于训练模型的数据集。本文采用工业 CMOS 相机在不同光照强度下采集焊接产品的缺陷图像,共采集 1070 张焊缝图像,因拍摄的焊缝缺陷多样性有限,数量达不到训练模型数据集的要求,于是从网上收集了 600 张不同焊缝缺陷类型的图像。

1.2 数据标注

训练 YOLOv5 模型之前需要对采集到的焊缝缺陷进行分类标注,本文标注时使用网络上开源的图像标注软件 LabelImg^[11]。标注类型共三类,余高、溅射、焊瘤分别为类别 0~2,缺陷标签为 Bulge、Sputter、Weld bead。图像标注以后会自动生成 txt 文件,文件中的部分文本内容如表 1 所示, x 、 y 、 w 、 h 分别表示为标注框中心点在 x 、 y 轴的坐标以及标注框的长和宽。

表 1 缺陷标注

缺陷类别	x	y	w	h
0	0.856 574	0.562 749	0.143 426	0.185 259
1	0.624 502	0.979 084	0.049 801	0.041 832
2	0.536 853	0.683 267	0.209 163	0.103 586

1.3 数据增强方法改进

由于深度学习算法是通过大量带有标签信息的样本学习图像的特征参数,如果数据集不足可能会导致训练过程中产生过拟合问题。因此为避免数据集不足这一问题,在训练模型之前需要建立一个标签样本充足的数据集用于训练。为使训练数据集更充足、训练效果更好,使用数据增强

技术对收集到的 1670 张图像进行扩充。一般常用的数据增强方法有图像剪切、图像缩放、颜色变换和翻转、旋转等。然而,这些方法本质上只是扩增数据的数量,并不能提高数据集的质量。

为此本文提出一种 Mosaic + Mixup 的数据增强方法对收集到的数据集进行扩增。Mosaic 数据增强理论上类似于 CutMix 数据增强,但是 Mosaic 是利用四张图像进行拼接,并且每一张图像都有其对应的标注框。Mosaic 数据增强的基本流程是首先选取 4 张带有标注框的缺陷图像,对其进行翻转、缩放、色域变化等操作,然后将四张图像分别放到 4 张只有灰色背景的图像上^[12],最后利用矩阵方式将 4 张图像截取下来,并将其拼接成一张新图像,新的图像背景丰富,并且包含原图像上的标注框,如图 1 所示。

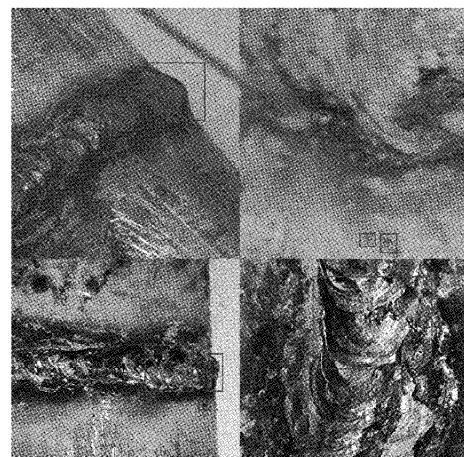


图 1 Mosaic 数据增强

Mosaic 数据增强只能丰富图像的背景并不能增加缺陷数量,因此使用 Mosaic + Mixup 数据增强策略丰富缺陷数量。Mixup 数据增强可以将不同类型的图像进行混合,在图像、文本、语音等多个领域都有应用。Mixup 对两个样本及样本标签按比例相加后生成新的样本及标签,计算公式为:

$$Data_s = \lambda Data_{s1} + (1 - \lambda) Data_{s2} \quad (1)$$

$$Data_L = \lambda Data_{L1} + (1 - \lambda) Data_{L2} \quad (2)$$

$$\lambda \sim Beta(\alpha, \beta), \lambda \in [0, 1]$$

式中: $Data_{si}$ 为数据集中的样本, $Data_s$ 为混合后的样本, $Data_{Li}$ 是 $Data_{si}$ 样本所对应的标签, $Data_L$ 为混合后的样本标签, $Beta$ 为贝塔分布,即 λ 是由 α, β 的贝塔分布计算出来的混合系数。

根据以上所述,首先从经过 Mosaic 数据增强后的图像中提取缺陷部分,然后利用 Mixup 对其进行数据增强处理,来增加图像上缺陷的数量,以此来扩增数据集。

2 基于 YOLOv5 的焊缝缺陷检测模型

2.1 YOLOv5 网络模型原理

YOLOv5 是 YOLO 目标检测算法中检测精度、检测速

度等各方面都相对较好的一个版本^[13],是典型的单阶段目标检测算法之一^[14]。根据网络深度和宽度的不同,YOLOv5 又分为 YOLOv5s、YOLOv5m、YOLOv5l 和 YOLOv5x 四个不同的模型,其中 YOLOv5s 检测速度最快、模型的文件最小。由于本研究方法主要用于工业上对焊缝进行检测,考虑精度的同时也要关注检测速度与模型大小,因此本研究使用便于嵌入系统的 YOLOv5s 作为主干网络模型。

YOLOv5 模型网络结构由四大部分组成,如图 2 所示分别为 Input、Backbone、Neck 和 Output。Input 采用 Mosaic 数据增强方式同时能够对图片进行自适应缩放,自动计算出数据集的最佳锚框值。Backbone 主要由 Focus 结构和 CSPNet 结构组成,Focus 结构的主要工作就是对图片进行切片操作,在进行四次切片操作以后再进行一次卷积核为 32 的卷积操作,将分辨率为 $640 \times 640 \times 3$ 的原始图像变成 $320 \times 320 \times 32$ 的特征图像。CSPNet 为跨阶段局部融合网络,主要功能是提取特征图的特征,获取不同层的特征来丰富图像信息。为了增大感受野,使不同尺度的特征融合,YOLOv5 将 SPP 放到了 Backbone 部分,能够提取出重要的特征。在 Neck 部分,使用 FPN + PAN 的结构,FPN 采用上采样的方式得到拼接后的特征图,之后通过 PAN 网络结构自下而上聚合浅层特征,充分整合各层的图像特征。在 Neck 部分含有 CSP2 结构,与 Backbone 中的 CSPNet 结构不同的是,CSPNet 含有残差模块,而 CSP2 中含有基本卷积 CBS 模块。在 YOLOv5 的 Output 部分使用 CIOU_Loss 作为损失函数,使用非极大值抑制筛掉多余的目标框,预测图像特征并找到最佳的检测位置。

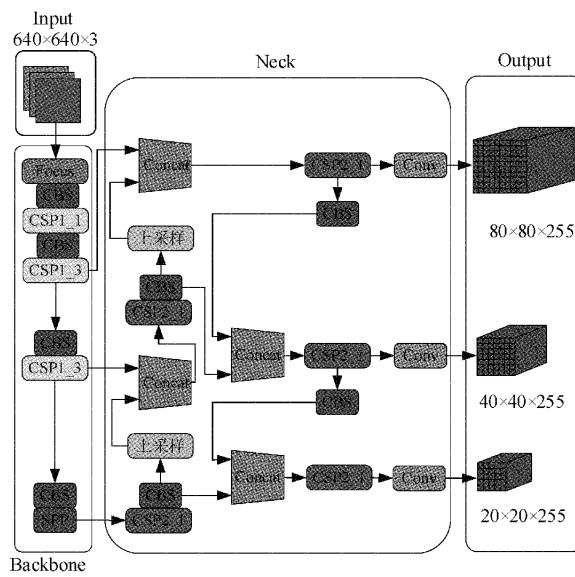


图 2 YOLOv5 模型网络结构

2.2 YOLOv5 主干网络改进

由图 2 可以看出,在 YOLOv5 网络模型中有很多层 CBS 基本卷积块,CBS 卷积块由卷积层(convolution,

Conv)、批量归一化层(batch normal, BN)和激活函数 SiLu 组成。然而卷积层太多会增大计算量和网络参数量,因此本文利用轻量型的 GhostNet 网络替代 YOLOv5 主干网络中 CSP1 结构中的残差模块,改进后的 CSP1 如图 3 所示。

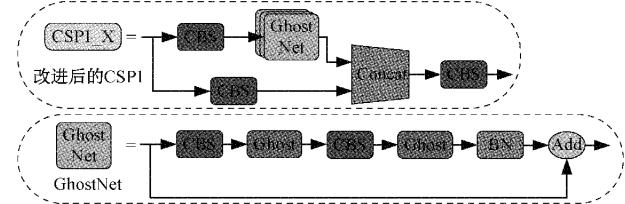


图 3 改进后的 CSP1

GhostNet 卷积模块采用传统卷积与轻量的冗余特征生成器相结合的方式代替传统的卷积层^[15],网络参数和计算量相对较少,更容易部署到终端。Ghost 卷积是 GhostNet 卷积模块的主要部分,相比于传统卷积,Ghost 卷积的实现分为两部分,首先经过正常的卷积计算得到一部分通道较少的特征图,然后对这些特征图进行简单的线性操作得到更多特征图,最后将两组特征图进行拼接组成新的输出,普通卷积与 Ghost 的网络原理如图 4 所示。

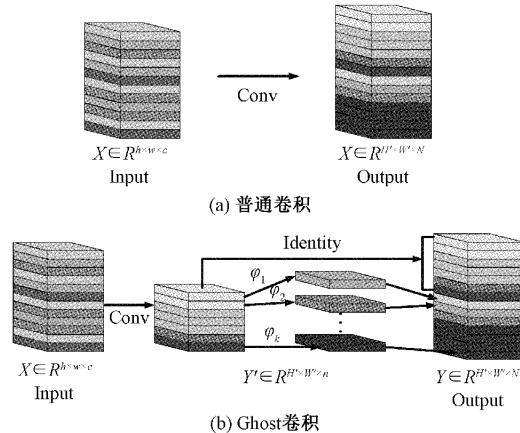


图 4 普通卷积与 Ghost 卷积网络原理

普通的卷积和 Ghost 卷积可以分别用式(3)、(4)表示,式(5)、(6)分别为普通卷积与 Ghost 卷积的计算量 FLOPs 的表达式:

$$Y = X \times f + b \quad (3)$$

$$\begin{cases} Y' = X \times f' \\ Y_{ij} = \varphi_{i,j}(Y'), i \in [1, m], j \in [1, s] \end{cases} \quad (4)$$

$$FLOPs_1 = H' \times W' \times N \times c \times k \times k \quad (5)$$

$$FLOPs_2 = H' \times W' \times n \times c \times k \times k + H' \times W' \times (N - n) \times c \times k \times k, n \leqslant N \quad (6)$$

式中: $X \in R^{h \times w \times c}$ 表示卷积输入高度为 h ,宽度为 w ,通道数为 c 的特征图, $Y \in R^{H' \times W' \times N}$ 表示卷积输出 N 个高度为 H' ,宽度为 W' 的特征图, $Y' \in R^{H' \times W' \times n}$ 表示在 Ghost 进行普通卷积后输出的 n 个大小为 $H' \times W'$ 的特征图, $f \in R^{c \times N \times k \times k}$ 表示 N 个大小为 $k \times k$ 的卷积核, b 为偏置项,

$f' \in R^{c \times N \times k \times k}$ 表示 n 个大小为 $k \times k$ 的卷积核, Y'_i 表示 Y' 中第 i 个特征图, Y_{ij} 表示通过 $k \times k$ 大小的卷积核线性变换 $\varphi_{i,j}$ 生成的第 j 个 Ghost 特征图。

2.3 损失函数

网络损失函数由两部分组成,分别是回归损失和分类损失。回归损失又称坐标位置损失,采用 CIOU_Loss 作为位置损失如式(7)所示^[16]。分类损失又包括类别损失和置信损失,如式(11)所示用 Focal_Loss 评价类损失和置信度损失。

$$CIOU_loss = 1 - CIOU \quad (7)$$

$$CIOU = IOU - \frac{\rho^2(b, b^{gt})}{c^2} - \alpha v \quad (8)$$

$$\alpha = \frac{v}{v - IOU + 1} \quad (9)$$

$$v = \frac{4}{\pi^2} (\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h})^2 \quad (10)$$

$$Focal_Loss = -(1 - p_i)^\gamma \lg p_i \quad (11)$$

式中: IOU 表示预测框与真实框的交并比, $\rho(b, b^{gt})$ 表示待检测目标预测框与真实框中心点之间的欧式距离, c 表示待检测目标的预测框与真实框最小外接矩形的对角线距离, α 为权重系数, v 表示衡量长宽比一致性的参数, $\frac{w^{gt}}{h^{gt}}$

表示真实框长宽比, $\frac{w}{h}$ 表示预测框的长宽比, p_i 表示预测样本概率, γ 为常数参数。

3 实验过程及结果分析

3.1 实验配置

本文模型的训练和测试均在 Windows10 操作系统上完成,选用 Pytorch1.2 框架,并配置 Nvidia GeForce RTX 2080Ti 显卡,具体实验环境配置如表 2 所示。

表 2 环境配置

配置名称	配置信息	
操作系统	Windows10	
内存	32 G	
CPU	Inter® Core™ i7-10700CPU@2.90 GHz	$\times 16$
GPU	Nvidia GeForce RTX 2080Ti	
语言	Python3.6	
GPU 加速	Cuda10.0	Cudnn9.0

3.2 模型评价指标

为对改进的 YOLOv5 模型的性能进行客观评价,采用常用的精确率(precision, P)、召回率(recall, R)、平均精度(average precision, AP)和平均精度均值 mAP 作为评价指标^[17]。准确率 P 表示所有预测为正样本中真实的正样本所占比例;召回率 R 表示在实际正样本中被预测为正样本

的比例;以 R 为横轴 P 为纵轴绘制 PR 曲线并对其进行平滑处理,PR 曲线与横轴围成的面积即为平均精度 AP,表示每一类别准确率的平均值,PR 曲线分为连续型和离散型,因此 AP 计算公式有两种;均值平均精度 mAP 表示所有类别的 AP 的均值,mAP 值越大证明模型性能越好,各指标具体计算公式如下:

$$P = \frac{TP}{FP + TP} \quad (12)$$

$$R = \frac{TP}{FN + TP} \quad (13)$$

$$AP = \begin{cases} \int_0^1 P(r)dr, & PR \text{ 曲线为连续型} \\ \sum_{n=1}^N P(n)\Delta r, & PR \text{ 曲线为离散型} \end{cases} \quad (14)$$

$$mAP = \frac{1}{k} \sum_{i=1}^k AP(i) \quad (15)$$

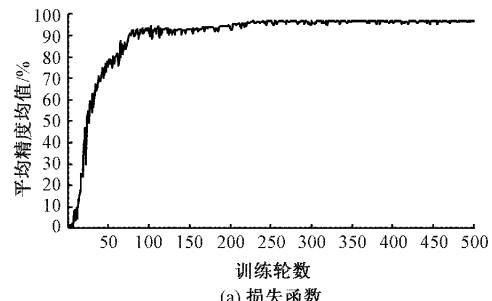
式中: TP (true positive) 表示真实正样本中被预测为正样本的个数, FP (false positive) 表示真实负样本中被预测为正样本的个数, FN (false negative) 表示真实正样本中被预测为负样本的个数, k 表示检测总类别数, $AP(i)$ 表示第 i 个类别的 AP 值,特别的当 $k = 1$ 时, $AP = mAP$ 。

3.3 YOLOv5 网络训练

由于数据样本数量较少,使用改进的数据增强方法 Mosaic+Mixup 将其扩充为 3 340 张图像,并随即抽取 500 张图片作为测试集,分别为 200 张含有余高缺陷的图像、160 张含有溅射缺陷的图像和 120 张含有焊瘤缺陷的图像。为实现 YOLOv5 模型的最佳性能,本文使用随机梯度下降法 SGD 优化器优化训练的网络。在模型训练开始之前需要对训练的超参数进行设置,初始学习率设置为 0.01,动量为 0.937,权重衰减系数为 0.0005,输入图像分辨率选用 640×640 ,模型训练批大小设置为 16,训练总轮数为 500 轮。

训练完成后,为方便分析训练过程,对模型的训练过程进行可视化处理,其损失函数和平均精度均值 mAP 如图 5 所示,其中横轴表示训练轮数,纵轴表示对应参数。

由图 5 可以看出,随着训练轮数的增加损失函数的损失值在减小,训练 50 轮之前损失函数快速收敛,在 200 轮之后损失值趋于稳定,收敛于 0.1, mAP 趋于稳定,基本稳定在 96.88%。



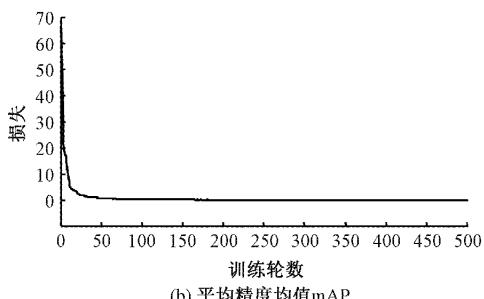


图 5 模型性能可视化

此外, 使用相同的超参数和数据集在未改进的 YOLOv5、YOLOv4 和 FasterRCNN 算法上进行对比训练, 并检测各模型各类指标, 如表 3 所示。

表 3 不同网络评价指标对比

模型	P	R	mAP
FasterRCNN	82.56	82.95	86.57
YOLOv4	88.72	87.57	88.47
YOLOv5	93.31	93.83	93.76
改进的 YOLOv5	95.64	95.56	96.88

由表3可以看到,本文改进的YOLOv5算法的精确率和召回率相对于未改进的YOLOv5略有提高,明显高于YOLOv4和FasterRNCC网络。改进的YOLOv5的mAP比传统的YOLOv5提高了3.12%,比YOLOv4模型高8.41%,比FaterRNCC网络高10.31%,对比四种模型的各项指标可以看出,改进后的YOLOv5网络模型各项参数明显提高,效果较为理想。

3.4 实验结果与分析

为验证改进后的 YOLOv5 模型的实际检测效果, 使用测试集进行测试。在对测试集进行检测时置信度阈值设为 0.5, 3 种焊缝缺陷的检测效果如图 6 所示, 从图中可以看出检测出来的缺陷置信度较高, 符合检测要求。在检测结束后, 统计各类缺陷检测的正确性, 分析检测精度, 统计结果如表 4 所示。

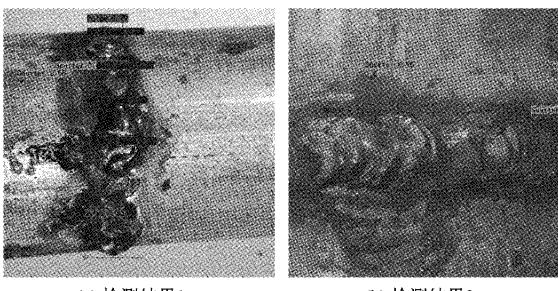


图 6 模型检测结果

根据表 4 中的数据可以看出,余高的检测正确率为 98.5%, 溅射和惺瘤的检测正确率均为 100%, 整体检测精

表 4 焊缝缺陷检测结果

缺陷类型	测试数量	错检数量	正确率/%
余高	200	3	98.5
溅射	160	0	100
焊瘤	120	0	100

度较高，效果较为理想。在余高缺陷中，有几处缺陷被误检为焊瘤，分析误检图像知，由于拍摄角度垂直于焊缝，加上有斜光照射入使拍摄出来的余高缺陷反光导致误检。因此为在实际检测应用中减少误检，一方面在采集缺陷图像时应该注意拍摄角度和光线的入射方向，其次应该增加数据集的数量，使用更多的样本去训练模型。

4 结 论

为提高工业上焊缝缺陷自动检测与处理的效率,本文基于深度学习提出一种改进的 YOLOv5 焊缝缺陷检测方法。首先提出一种 Mosaic+Mixup 的数据增强方法对收集到的数据集进行扩增,然后使用轻量型的 GhostNet 网络代替原主干网络中 CSP1 结构中的残差模块降低网络的计算量和减少网络参数量。该方法能够对焊接过程中产生的余高、溅射和焊瘤缺陷进行识别,方便后期对这几类缺陷进行打磨处理。经过大量实验测试,改进后的模型 mAP 达到 96.88%,单张图像检测速度不超过 50 毫秒,说明该模型拥有较高的精度和检测速度,能够满足实时性检测要求实现焊缝缺陷的自动检测处理。在后续工作中将会收集更多的焊缝缺陷样本来提高模型的泛化能力,并将训练好的模型部署到终端,实现移动端的实时检测,方便后续焊缝缺陷的打磨处理。

参考文献

- [1] 宋寿鹏,乔梦丽. 基于 NLFM Barker 编码的板材焊缝缺陷超声检测方法研究 [J]. 仪器仪表学报, 2020, 41(4):246-254.
 - [2] 郑中华,陈文坚,卢宇,等.一种皮带轮规格测量及微缺陷检测方法研究 [J]. 国外电子测量技术, 2021, 40(11):58-63.
 - [3] 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.
 - [4] KHUMAIDI A, YUNIARNO E M, PURNOMO M H. Welding defect classification based on convolution neural network(CNN) and Gaussian kernel[C]. 2017 international seminar on intelligent technology and its applications(ISITIA), IEEE, 2017: 261-265.
 - [5] 王宸,张秀峰,刘超,等. 改进 YOLOv3 的轮毂焊缝缺陷检测 [J]. 光学精密工程, 2021, 29(8):1942-1954.
 - [6] 焦敬品,李思源,常予,等. 集箱管接头内焊缝表面缺陷识别方法研究 [J]. 仪器仪表学报, 2017, 38(12):

- 3044-3052.
- [7] 鲍峰,王俊红,张峰,等.基于 YOLO V3 的管道环焊缝缺陷检测[J].焊接,2021(8):56-61,64.
- [8] 唐茂俊,黄海松,张松松,等.改进的 Faster-RCNN 在焊缝缺陷检测中的应用[J].组合机床与自动化加工技术,2021(12):83-86.
- [9] 谷静,王琦雯,张敏,等.基于 DenseNet 网络的焊缝缺陷检测识别[J].传感器与微系统,2020,39(9):129-131.
- [10] MALARVEL M, SETHUMADHAVAN G, BHAGI P C R, et al. Anisotropic diffusion based denoising on X-radiography images to detect weld defects [J]. Digital Signal Processing, 2017, 68: 112-126.
- [11] 吴亚辉,刘春阳,谢赛宝,等.基于视觉深度学习的机器人环境感知及自主避障[J].电子测量技术,2021, 44(20):99-106.
- [12] 辛彦,吴国新,左云波.基于 EfficientDet 的风机叶片缺陷检测方法[J].电子测量技术,2022,45(5):124-131.
- [13] SONG Q, LI S, BAI Q, et al. Object detection method for grasping robot based on improved YOLOv5 [J]. Micromachines, 2021, 12(11): 1273.
- [14] 刘琛,王江涛,王明阳.引入视觉机制的 SSD 网络在摩托车头盔佩戴检测中的应用[J].电子测量与仪器学报,2021,35(3):144-151.
- [15] 李文婧,徐国伟,孔维刚,等.基于改进 YOLOv4 的植物叶茎交点目标检测研究[J].计算机工程与应用, 2022,58(4):221-228.
- [16] REZATOFIGHI H, TSOI N, GWAK J Y, et al. Generalized intersection over union: A metric and a loss for bounding box regression[C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 658-666.
- [17] HE Y, SONG K, MENG Q, et al. An end-to-end steel surface defect detection approach via fusing multiple hierarchical features[J]. IEEE Transactions on Instrumentation and Measurement, 2019, 69 (4): 1493-1504.

作者简介

李衍照,硕士,主要研究方向为自主导航与智能控制、深度学习等。

E-mail: liyanzhao5411@163.com