

基于高密度点云的激光焊接缺陷智能在线检测(特邀)

张臣^{1*}, 胡佩佩², 朱新旺³, 杨长祺²¹武汉大学工业科学研究院, 湖北 武汉 430072;²上海航天精密机械研究所, 上海 201600;³湖北省计量测试技术研究院, 湖北 武汉 430223

摘要 铝合金薄板激光焊接经常会出现咬边、凹陷等表面缺陷。这两种缺陷由于尺寸小、特征相似,难以通过传统视觉在线检测手段对其进行精确分类和测量。开发了一种基于深度学习缺陷分类-点云测量的在线监测系统,利用高密度的点云数据对缺陷进行识别、分类与测量,解决了上述检测难题。通过双目结构光传感器采集点云数据;利用基于区域推荐网络的卷积神经网络模型识别和定位缺陷;在识别和定位缺陷后,通过对局部缺陷区域的点云进行操作,快速测量缺陷尺寸。高密度点云数据训练的模型的识别准确率达到93%,高于传统二维视觉传感器图像训练的模型。该检测系统在线检测允许的最大焊接速度为316.87 mm/s,适用于大多数激光焊接。

关键词 激光技术; 激光焊接; 焊接缺陷; 实时检测; 高密度点云数据; 深度学习

中图分类号 TG439.4

文献标志码 A

DOI: 10.3788/CJL231293

1 引言

激光焊接是重要的铝合金加工技术之一,它已被广泛应用于工业领域,包括航空航天、汽车、新能源、电子制造等^[1-3]。目前,自动焊接机器人正逐步取代人工,大大提高了生产效率。但是,激光焊接铝合金薄板材时非常容易产生表面缺陷,如凹陷、气孔、飞溅、咬边等^[4]。这是铝合金的焊接特性、不当的焊接参数、复杂的焊接环境等原因造成的。因此,采用焊缝质量在线检测系统,可以及时识别焊缝缺陷,提高焊接质量和制造效率^[5-6]。易混淆的缺陷类型、较小的焊缝尺寸和较高的焊接速度是铝合金激光焊接精确在线监控面临的主要挑战。另外,激光焊接在线监测对检测技术的抗干扰性、数据采集速度和处理速度等都有着较高的要求。

表面缺陷适合通过视觉进行检测。视觉传感器由于具有非接触特性、精度高、检测速度快、适应性强等优点,在焊接检测中得到了广泛的关注^[7-9]。铝合金具有高反射率的特点,导致被动视觉设备在不同光源下采集到的图像内容具有较大差异。与被动视觉相比,主动视觉对环境噪声(如光照变化)的鲁棒性更强,可以获得焊缝的特征参数或信息^[10-13]。焊接质量标准根据缺陷的特征尺寸确定缺陷等级,而缺陷的特征尺寸往往需要在复杂的三维(3D)空间中进行测量。为了判断缺陷是否符合标准,需要检测出缺陷的精确3D轮

廓。小尺寸激光焊缝需要精细的检测方法。双目结构光传感器作为主动视觉技术之一,可以提供高密度点云数据,完美反映了焊缝精细的3D表面轮廓。基于点云数据的表面缺陷检测在各种制造工艺中受到越来越多的重视^[14-16]。Chen等^[17]提出了一种基于立体结构光传感器的焊缝三维路径提取新方法,避免了线结构光效率低和被动视觉鲁棒性差的问题。Li等^[18]研究了一种基于双目式结构光立体视觉的高反射焊接表面三维重建技术,利用条纹投影轮廓术在感兴趣区域上生成点云。上述研究只关注焊缝的跟踪、测量和重建,关于焊接表面缺陷精确分类的研究却很少。例如,咬边和凹陷在特征尺寸和形状上相似,这使得它们不容易被区分。它们的产生机制也不同,且评价标准也不一样。如果能够准确区分,就可以通过调整工艺参数,避免出现缺陷。此外,基于双目结构光传感器高密度点云数据的焊缝表面缺陷分类也鲜有详细报道。

由于曲面点云数据量大,直接处理每个点需要大量的计算。较高的激光焊接速度进一步压缩了实时数据的处理时间范围,因此难以实现实时在线监控。压缩数据可以减少数据处理的工作量。但是,高密度点云数据的压缩可能会导致精度的损失。如果只测量缺陷的局部高密度点云数据,数据处理速度将大大提高。这涉及到目标的分类、定位和测量,它需要高效处理算法的支持。基于深度学习的自动视觉检测系统是一个

收稿日期: 2023-10-16; 修回日期: 2023-11-05; 录用日期: 2023-11-27; 网络首发日期: 2023-12-12

基金项目: 国家自然科学基金(52075393)、装备预研航天科技应用创新项目、湖北省青年拔尖人才项目

通信作者: *c.zhang@whu.edu.cn

合适的选择。深度学习技术具有很强的统计学习能力,可以提取深度抽象特征^[19]。在实际应用中,它具有更强的鲁棒性和更好的泛化能力。在深度学习技术的训练过程中,不需要复杂的实时调整和人为干预。Jiao 等^[20]介绍了一种端到端深度学习方法,在焊接过程中利用熔池顶部图像预测焊缝熔透;设计并训练了端到端卷积神经网络,其自动定义和提取特征。Dai 等^[21]提出了一种小物体检测网络模型,用于检测车身焊点的位置和质量。Yang 等^[22]提出了一种模型尺寸小、计算复杂度低、预训练的 SqueezeNet 模型,用于检测动力电池安全气孔上的激光焊接缺陷。Liu 等^[23]使用卷积神经网络(CNN) VGG-16 对三种焊缝类型进行了分类,包括气孔或固体夹杂物、横向裂纹和无缺陷。Xia 等^[24]开发了一种基于摄像机拍摄的熔池图像的 CNN 模型,用于识别焊缝良好、未焊透、烧透、错位和咬边。CNN 在焊接检测中的应用还有很多^[7, 25-26]。Ren 等^[27]提出了更快的基于区域的卷积神经网络(Faster R-CNN),通过结合区域推荐网络(RPN)生成了候选盒,大大提高了检测速度。与 YOLO(You Only Look Once)、SSD(Single Shot MultiBox Detector)等主要目标识别算法比较,Faster R-CNN 检测小目标时具有更高的精度,适用于细小、多种类缺陷目标的分类和检测^[28-31]。因此,本文设计了一种基于 Faster R-CNN 的改进模型,基于高密度点云数据检测焊缝表面缺陷。

本文提出了一种基于高密度点云的铝合金激光焊接质量在线检测新方法。目的是准确检测薄板铝合金激光焊接中最常见、最容易混淆的表面缺陷——咬边与凹陷。具体技术路线如下:1) 制作数据集;2) 处理数据;3) 训练模型;4) 设计在线监测模型;5) 在线测试模型。实验结果表明,识别+定位+局部测量的方法大大减少了点云数据的操作次数,该方法能有效提高缺陷检测的精度和计算效率。

2 实验流程和分析方法

实验流程如图 1 所示。激光焊接缺陷检测实验系统如图 2 所示。首先,基于课题组前期制作的激光焊接实验样品,收集激光焊缝试样。然后,使用双目结构光传感器,获取焊缝表面形貌的高密度点云数据并转换为深度图,其参数如表 1 所示。通过多次曝光减少不同表面反射特性导致的点云缺失。再次,利用 Labelimg 区域标记软件在深度图上标记缺陷的位置、大小和类型,构建焊缝表面数据集。然后,基于数据集训练 Faster R-CNN 模型。该模型可以从深度图中识别出缺陷的位置和类型。最后,使用经过训练的模型系统,采用图 2 所示的实验设置进行在线检测缺陷并提取其几何尺寸。此外,为了进一步验证所提方法的有效性和先进性,还对比了基于点云和二维红绿蓝(RGB)图像检测焊缝缺陷的结果。使用传感器采集焊缝的 RGB 图像。

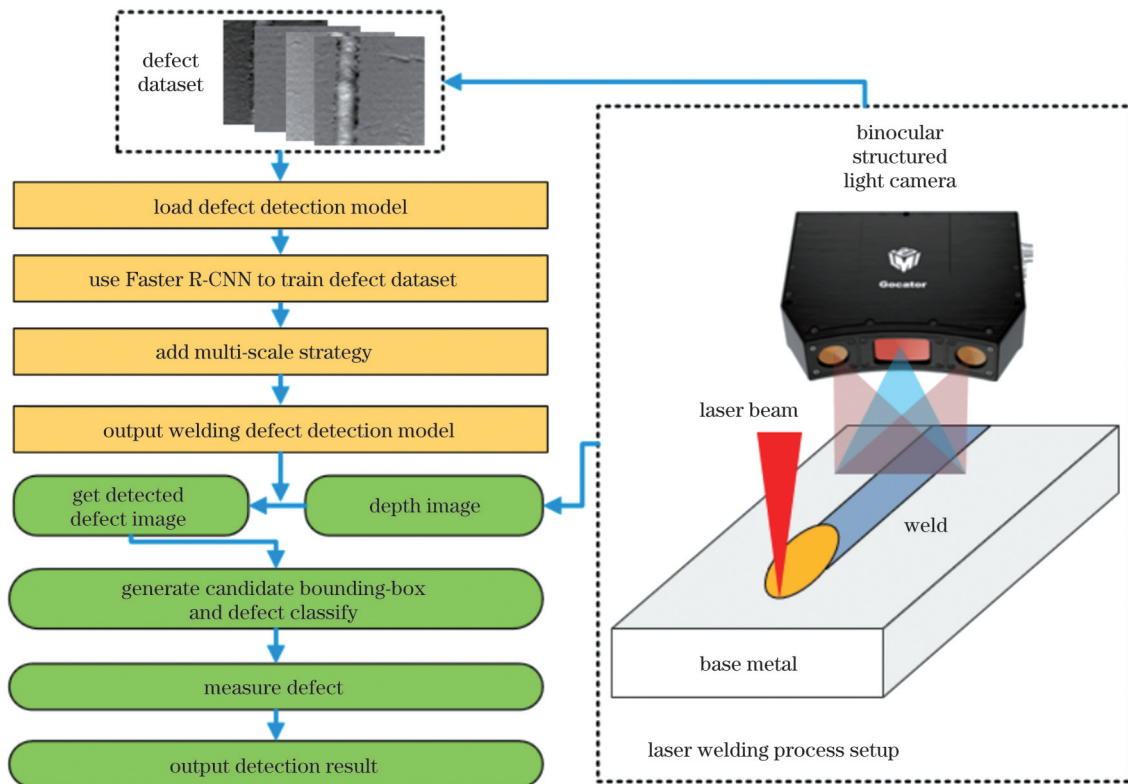


图 1 缺陷检测总体工作流程图

Fig. 1 Overall workflow chart of defect detection



图 2 激光焊接缺陷检测实验系统

Fig.2 Experiment system for laser welding defect detection

表 1 双目结构光传感器的具体参数

Table 1 Specific parameters of binocular structured light sensor

Parameter	Value
Size of sensor / (pixel × pixel)	$(2 \times 10^3) \times (2 \times 10^3)$
Repeatability in Z direction / μm	3.3
Resolution of image on XY plane / mm	0.06–0.09
Field of view / (mm × mm)	$71 \times 90 - 100 \times 154$
Clearance distance / mm	164
Measuring range / mm	110

2.1 数据集构建与数据预处理

焊缝试样采用的基材为铝合金板材,包含了 2 系、5 系、6 系等不同牌号,厚度为 1~5 mm,长度和宽度范围为 20~200 mm。在线测试使用尺寸为 3 mm × 100 mm × 100 mm 的 5 系板材。采用光纤激光器进行焊接实验,其最大激光功率为 6 kW,光束模式为连续多模,波长为 1070 nm。焊接工艺设置与文献[32]一致。保护气体为体积分数为 99.99% 的 Ar。制造数据集样本和在线测试的焊接参数如表 2 所示,共生产了 300 多个样品,图 3 为典型焊缝的完整样品。

表 2 焊接参数

Table 2 Welding parameters

Parameter	Range	Value in online test	
		Sagging	Undercut
Laser power / kW	1–6	2	4
Welding speed / (m/min)	0.5–10.0	2	5
Defocus / mm	–5–5	–2	–2
Shielding gas flow rate / (L/min)	1–20	15	15




图 3 典型焊缝完整样本图像。(a)薄板对接焊缝;(b)厚板对接焊缝;(c)堆焊焊缝

Fig. 3 Complete sample images of typical welds. (a) Sheet butt weld; (b) thick plate butt weld; (c) bead-on-plate weld

收集了 300 个样本的点云高清晰度数据(HDM)。图 4(a)给出了 HDM 数据预处理的三个步骤:空隙填充/滤波、规则排列和灰度转换。将高密度点云数据的高度信息(Z 坐标)转换为像素灰度值,将 X、Y 坐标转换为像素坐标^[15]。图 4(b)~(d)为典型焊缝的 RGB 彩色图像、最终点云图和深度图。样品的原始图像被裁

剪成 450 张图像,随机选取 315 张作为训练数据集,另外 135 张图片用于验证。表 3 记录了数据集的具体组成。为了提高模型的鲁棒性,增加数据集的多样性,在训练数据集上进行了随机翻转、添加白噪声等一系列图像增强操作。收集 200 张焊缝 RGB 彩色图像作为另一个数据集进行比较。

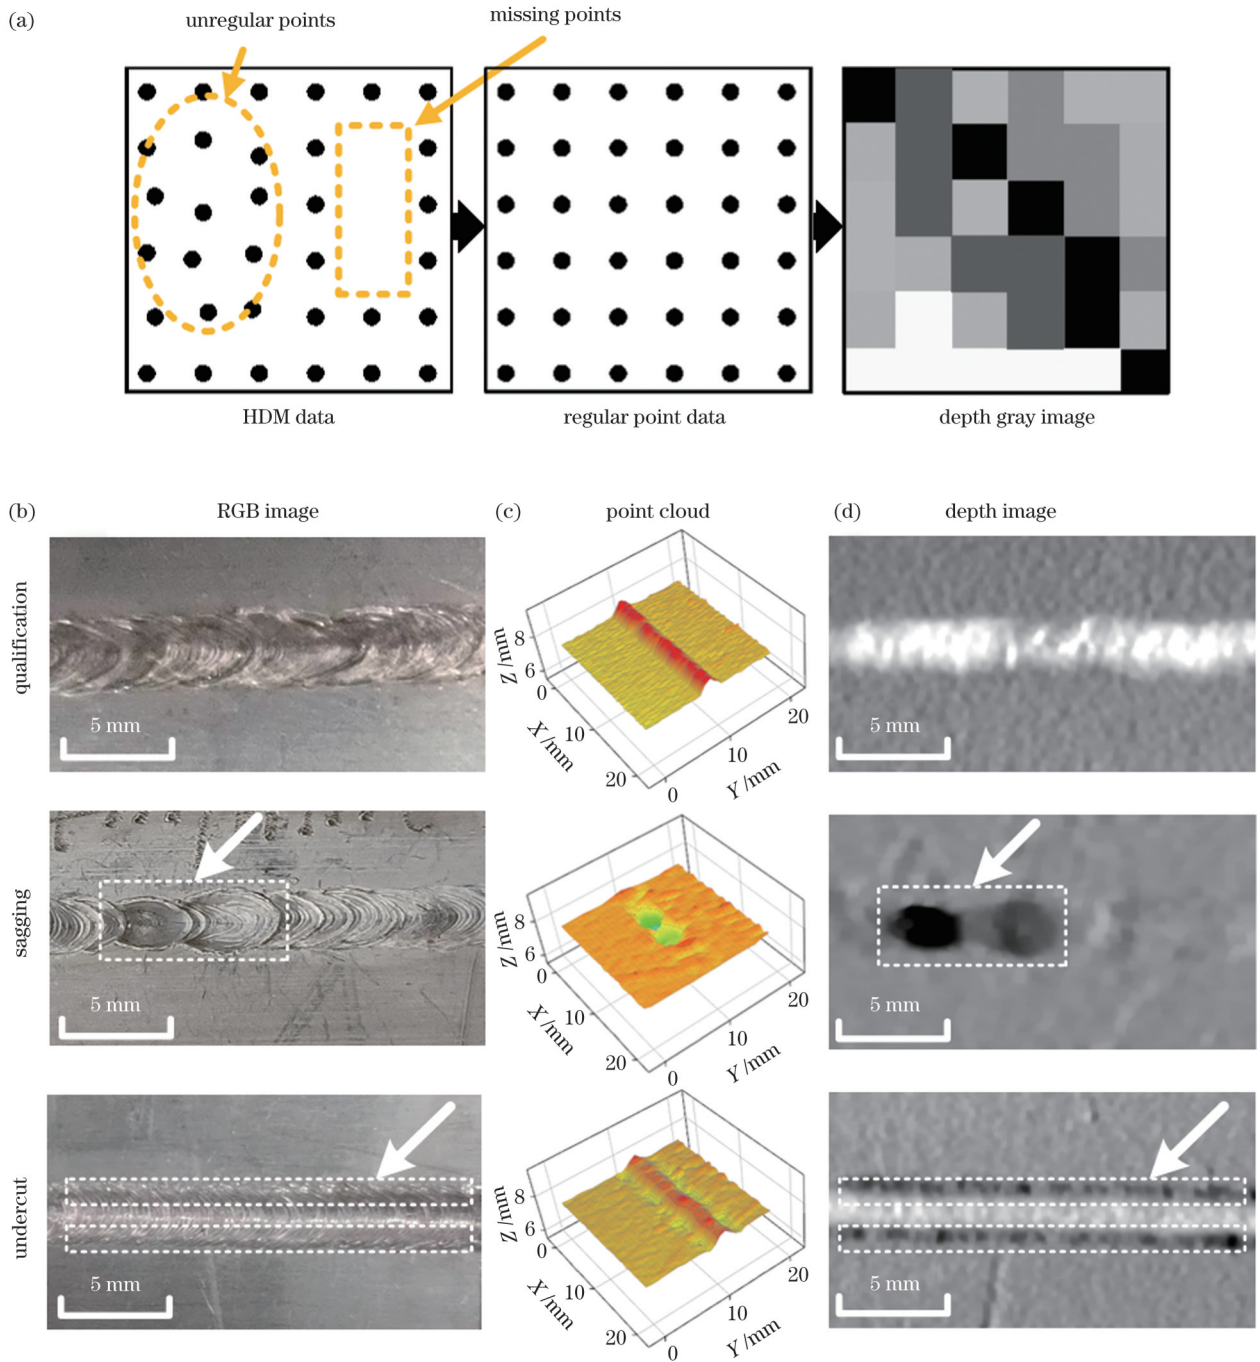


图 4 数据预处理过程中不同形式的数据库。(a)点云 HDM 数据预处理;(b)表面缺陷的 RGB 图像;(c)高密度点云数据;(d)包含缺陷三维轮廓信息的深度图像

Fig. 4 Different forms of data during data preprocessing. (a) Preprocessing of point cloud HDM data; (b) RGB images of surface defects; (c) high-density point cloud data; (d) depth images including 3D profile information of defects

表 3 数据扩充后的数据集

Table 3 Datasets after data augmentation

Image	Dataset	Undercut	Sagging	Defect-free	Total number	Data augmentation
Point cloud image	Total	170	150	130	450	
	Training	119	105	91	315	Noise addition
	Testing	51	45	39	135	Mirroring
RBG image	Total	84	80	36	200	
	Training	58	56	26	140	Noise addition
	Testing	26	24	10	60	Mirroring

2.2 缺陷分类检测模型

Faster R-CNN 目标检测包括三个基本步骤:特征提取、兴趣候选区域生成及目标分类和位置回归。图 5 为 Faster R-CNN 的模型结构。Faster R-CNN 模型由 RPN 和 Fast R-CNN 两个模块组成。首先,将待训练或检测的图像输入到检测网络中。其次,使用卷积神经网络提取特征,形成特征映射。然后,将特征映射输入到 RPN 中,生成可能的缺陷建议区

域,并将其映射到卷积特征映射上。接着,感兴趣区域(ROI)池化层将不同大小的候选区域映射到卷积特征图上,提取出相同维数的特征。最后,使用缺陷分类层和边界盒回归层对提出的区域进行特定分类和精确边界回归操作。RPN 通过滑动窗口遍历特征图提取锚盒,并将低维短向量输入到两个并行的全连通网络层,即缺陷边界盒回归层和图像缺陷分类层。

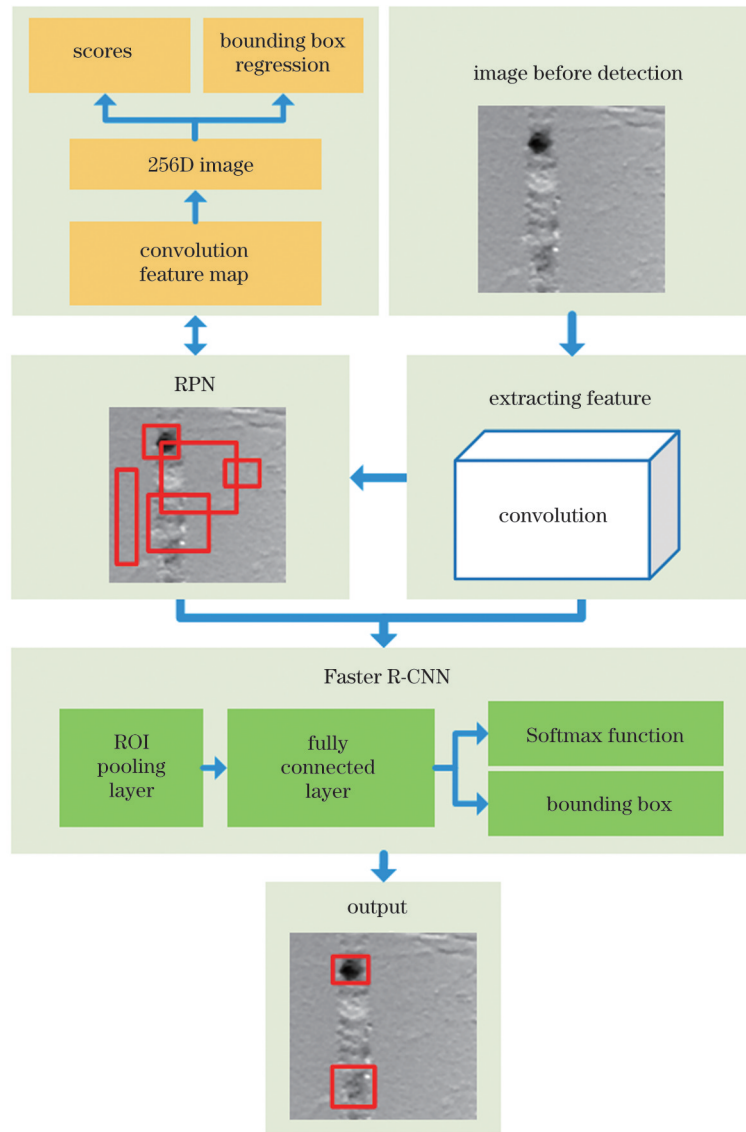


图 5 Faster R-CNN 结构示意图

Fig. 5 Structural diagram of Faster R-CNN

在特征提取网络部分,分别使用 ResNet18、ResNet50 和 ResNet101 网络,形成三种不同的 Faster R-CNN 模型^[33]。在三种模型的特征提取中分别使用不同数量的卷积层。使用上述数据集对三种模型进行训练和测试。测试环境为 64 位 Windows 系统和 4 GB 内存的 Quadro P2000 显卡。检测模型采用 PyTorch 平台实现。

2.3 缺陷尺寸测量方法

根据 Faster R-CNN 模型输出缺陷的类型和位置,基于局部点云数据测量表面缺陷尺寸。利用缺陷区域两侧的母材表面对深度图像进行标定,将标定后的母材表面高度作为缺陷分割阈值。在获得缺陷类型和位置后,测量几何特征尺寸,对焊缝进行评价。

2.4 检测过程的时间分析

为了验证本文方法的实效性,进行了检测时间研究。利用系统代码记录数据采集、检测和测量所花费的时间。本文检测装置采集数据的平均耗时约为 0.222 s。其他时间视实际实验情况而定。

3 结果与讨论

3.1 缺陷分类及定位

基于训练数据集训练 Faster R-CNN 模型,模型在测试数据集上的典型检测结果如图 6 所示。虚线框为缺陷的真实区域,实线框为模型计算出的缺陷区域,实线框旁边的数字为置信度数据。基于 ResNet50 的 Faster R-CNN 模型的凹陷检测结果比基

于 ResNet18 和 ResNet101 的 Faster R-CNN 模型的凹陷检测结果具有更高的置信度,回归盒的大小基本等于凹陷的实际面积。基于 ResNet101 的 Faster R-CNN 模型的凹陷检测结果存在假阴性区域,这是由于缺陷区域较小,与背景区域相似。图 6 也给出了咬边的检测结果。基于 ResNet50 的 Faster R-CNN 模型的回归盒基本与咬边的真实面积相等。虽然基于 ResNet18 的 Faster R-CNN 模型的置信度稍高,但给出的回归框与真实区域相差较大。基于 ResNet101 的 Faster R-CNN 模型给出了两个缺陷区域,与实际情况不符。由此可见,基于 ResNet50 的 Faster R-CNN 模型具有更高的检测精度和更好的检测结果。

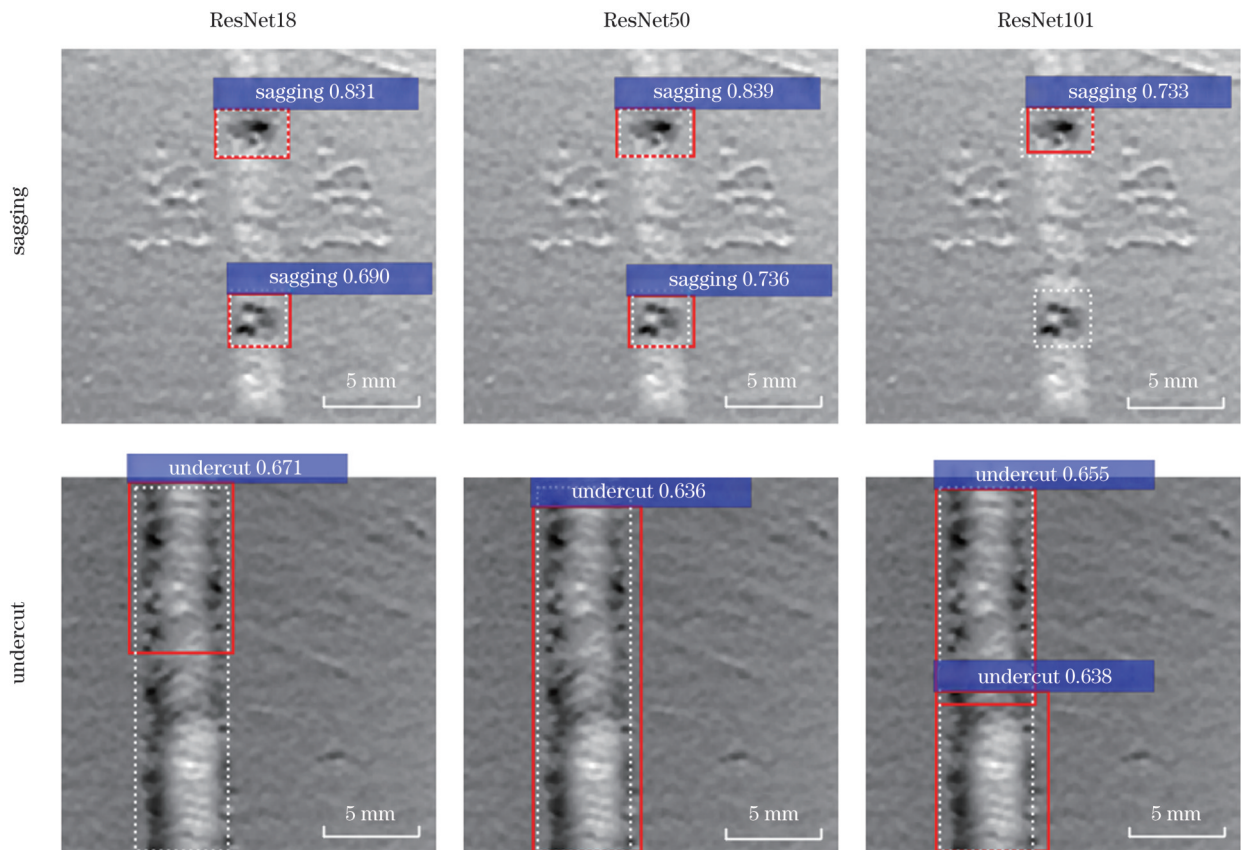


图 6 基于 ResNet18、ResNet50、ResNet101 的 Faster R-CNN 的检测结果

Fig. 6 Detection results using Faster R-CNNs based on ResNet18, ResNet50, and ResNet101

3.2 检测精度分析

利用损失值、模型准确率、召回率和平均精度 (mAP) 等参数,定量分析了基于 ResNet18、ResNet50 和 ResNet101 的 Faster R-CNN 模型的识别性能。准确率 (P) 是指正确预测的缺陷样本数量与预测的缺陷样本数量的比值:

$$P = \frac{T_p}{T_p + F_p}, \quad (1)$$

式中:真阳性数 (T_p) 为正确预测的缺陷样本数量,本实验中预测缺陷样本的置信度及实际样本与预

测样本之间的交并比 (IOU) 均不低于 0.5;假阳性数 (F_p) 是错误预测 (错检) 的缺陷样本的数量,本实验中预测缺陷样本的置信度不低于 0.5,但实际样本与预测样本之间的 IOU 小于 0.5。召回率 (R_c) 是正确预测的缺陷样本数量与所有实际缺陷样本数量的比值:

$$R_c = \frac{T_p}{T_p + F_N}, \quad (2)$$

式中: F_N 为漏检的缺陷样本的数量。

表 4 为基于点云分析的三种模型的性能参数。随训

练周期(epoch)变化的损失值如图 7(a)所示。在最初的 10 个 epoch,网络收敛速度很快。训练集的损失值逐渐减小到 0.2 以下,然后逐渐减小到 0.1。从第 10 个 epoch 开始,三种模型的损失值稳定,收敛效果普遍较好。

表 4 基于点云分析的三种模型的性能参数

Table 4 Performance parameters of three models based on point cloud analysis

Model	Overall precision / %	Overall recall rate / %	mAP / %	Run time / s
ResNet18	79	77.0	72.4	0.191
ResNet50	93	89.5	91.9	0.194
ResNet101	73	66.5	62.4	0.253

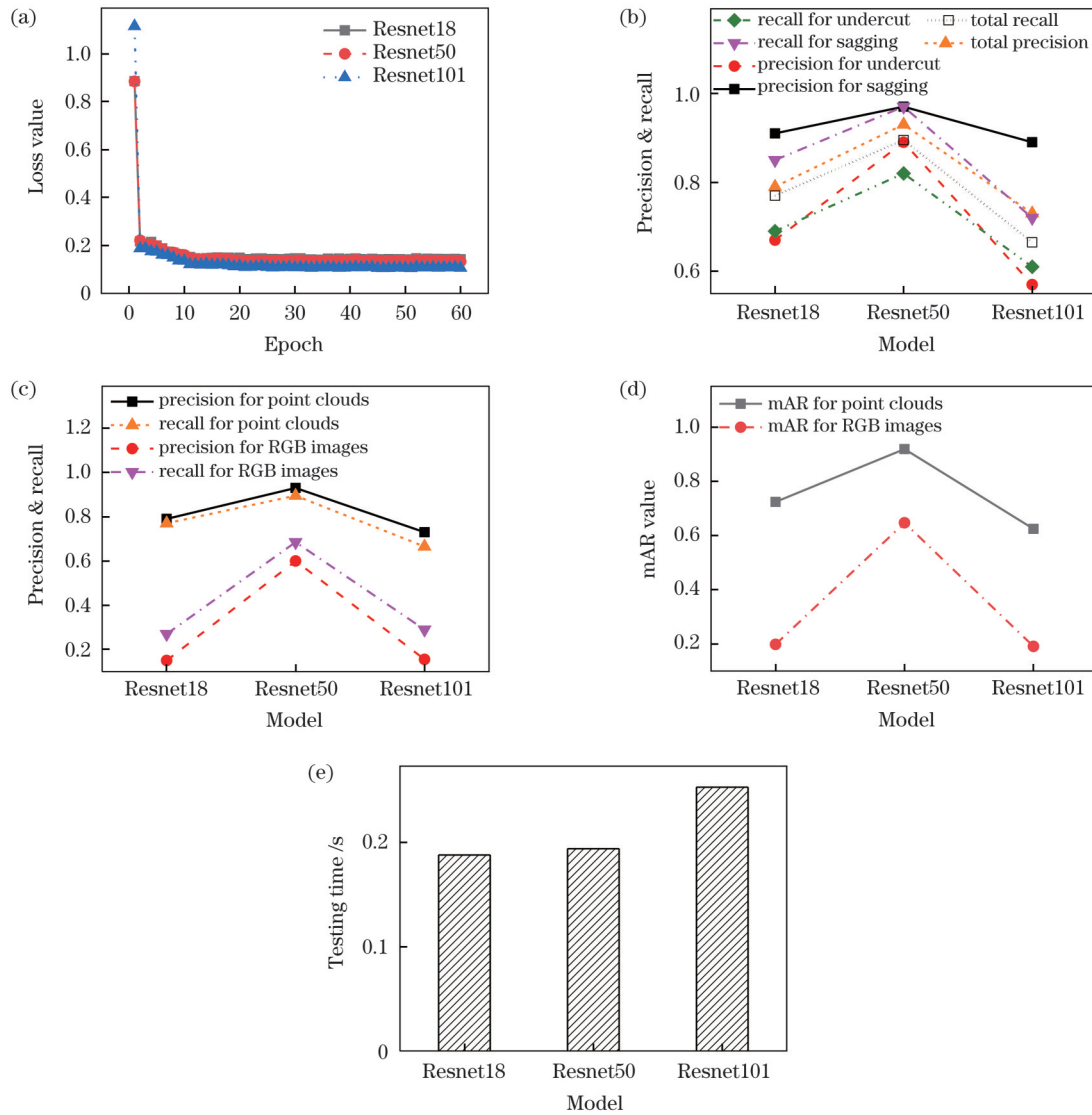


图 7 三种模型的统计结果。(a)不同模型的损失演化;(b)不同模型下的点云检测准确率和召回率;(c)不同模型对点云和 RGB 图像的缺陷的检测准确率和召回率;(d)不同模型对点云和 RGB 图像的缺陷的检测 mAP;(e)不同模型的测试时间
Fig.7 Statistical results of three models. (a) Loss evolution of different models; (b) point cloud detection precisions and recall rates with different models; (c) detection precisions and recall rates of defects for point clouds and RGB images with different models; (d) detection mAPs of defects for point clouds and RGB images with different models; (e) testing time of different models

图 7(b)为三种模型的点云检测准确率和召回率。三种模型均使用了测试数据集的 135 幅图像,其中 96 幅图像存在缺陷。凹陷的检测准确率和召回率均高于咬边。长度较短的咬边可能被识别为凹陷,导致其检测准确率较低。基于 ResNet50 的 Faster R-

CNN 模型的整体检测准确率达到 93%;基于 ResNet18 的 Faster R-CNN 模型排名第二,整体检测准确率为 79%;基于 ResNet101 的 Faster R-CNN 模型的整体检测准确率最低,为 73%。基于 ResNet50 的 Faster R-CNN 模型的整体召回率达到 89.5%;基

于 ResNet18 的 Faster R-CNN 模型排名第二,整体召回率为 77%;基于 ResNet101 的 Faster R-CNN 模型的整体召回率最低,为 66.5%。图 7(c)为利用基于 Faster R-CNN 的二维 RGB 图像对焊缝缺陷进行检测时的准确率和召回率。RGB 图像的检测精度明显低于点云图像。不含焊缝表面高度信息的 RGB 图像的纹理相似度较高,故不能很好地识别缺陷和合格焊缝。

在目标检测中,mAP 是指多个类别的平均精度,用来衡量检测精度。三种模型在所有类别上的 mAP 如图 7(d)所示。基于 ResNet50 的 Faster R-CNN 模型的 mAP 最高,达到 91.9%。基于 ResNet18 的 Faster R-CNN 模型排名第二,mAP 为 72.4%,基于 ResNet101 的 Faster R-CNN 模型的 mAP 最低,为 62.4%。图 7(d)还显示了利用基于 Faster R-CNN 的 RGB 图像对焊缝缺陷进行检测时的 mAP。RGB 图像的最高 mAP 值为 64.7%,明显低于点云图像。

在大多数情况下,网络层数更多的 ResNet 在大多数情况下具有更高的准确率,具有更强的特征学习能

力。在本文中,基于 ResNet50 的 Faster R-CNN 模型的性能通常优于基于 ResNet18 的 R-CNN 模型。然而,基于 ResNet101 的 Faster R-CNN 模型显示出最差的结果,因为多层的神经网络容易过拟合。深度模型在反向传播中通常伴随着梯度消失,在正向传播中特征重用的现象减少。

另外,基于 ResNet50 的 Faster R-CNN 模型的典型假阴性检测结果如图 8 所示。虚线框为实际缺陷区域,实线框为计算结果。由于表面纹理粗糙,缺陷面积小,与正常焊缝难以区分,检测结果的置信度低于 0.5。预测缺陷面积与实际缺陷面积之间的 IOU 较小。针对小缺陷和可视性差的缺陷改进算法或检测装置是未来将要开展的工作。

最后,为了评估三种模型的检测时间,对 100 张带有缺陷的点云图像进行了测试。图 7(e)显示了单幅图像的平均处理时间。基于 ResNet50 的 Faster R-CNN 模型所需的时间为 0.194 s,接近 ResNet18。基于 ResNet101 的 Faster R-CNN 模型的时间较长,为 0.253 s,比其他两个模型的时间多 25% 左右。




图 8 基于 ResNet50 的 Faster R-CNN 模型的典型假阴性检测结果

Fig. 8 Typical false negative test results of Faster R-CNN model based on ResNet50

3.3 缺陷尺寸测量

图 9 为咬边和凹陷尺寸的测量过程。图 9(a)为缺陷样品的 RGB 图像,从中很难识别缺陷。传感器采集的点云数据[图 9(b)]直接说明了缺陷类型。为了识别它们的类型,将由点云数据转换而来的深度图输入到基于 ResNet50 的经过预训练的 Faster R-CNN 模型中。图 9(c)不仅给出了缺陷分类数据,还给出了缺陷定位区域。通过阈值分割对缺陷区域进行预处理,即图 9(d)中的纯灰色块覆盖区域。最后,在局部焊缝截面上测量缺陷深度,如图 9(e)、(f)所示。为了验证测量结果的准确性,表 5 给出了上述算法测量的两个特定缺陷的特征尺寸,包括最大深度、面积、宽度和长度。同时,利用游标卡尺测量实际的宽度和长度以进行对比。计算缺陷宽度和长度的相对误差,结果如图 10 所示。缺陷尺寸的最小测量精度达到 96.7%,最大绝对误差小于 0.1 mm,在允许的

测量范围内。

局部测量大大提高了测量速度,测量缺陷局部点云的平均耗时为 0.07 s,而测量焊缝整体点云的平均耗时为 0.173 s。

3.4 检测速度分析

根据上述研究结果可知,数据采集、检测和测量的平均耗时分别为 0.222、0.194、0.070 s。因此,整个检测过程的总耗时(t_{total})为上述时间之和,即 0.486 s。检测系统允许的最大焊接速度(v_{max})可由下式确定:

$$v_{max} = \frac{L}{t_{total}}, \quad (3)$$

式中: L 为传感器的最大检测长度,根据表 1 的视场计算得到 L 为 154 mm。计算得到的 v_{max} 为 316.87 mm/s,远高于普通激光焊接速度^[34]。意味着该系统能够在激光焊接过程中实现在线检测。

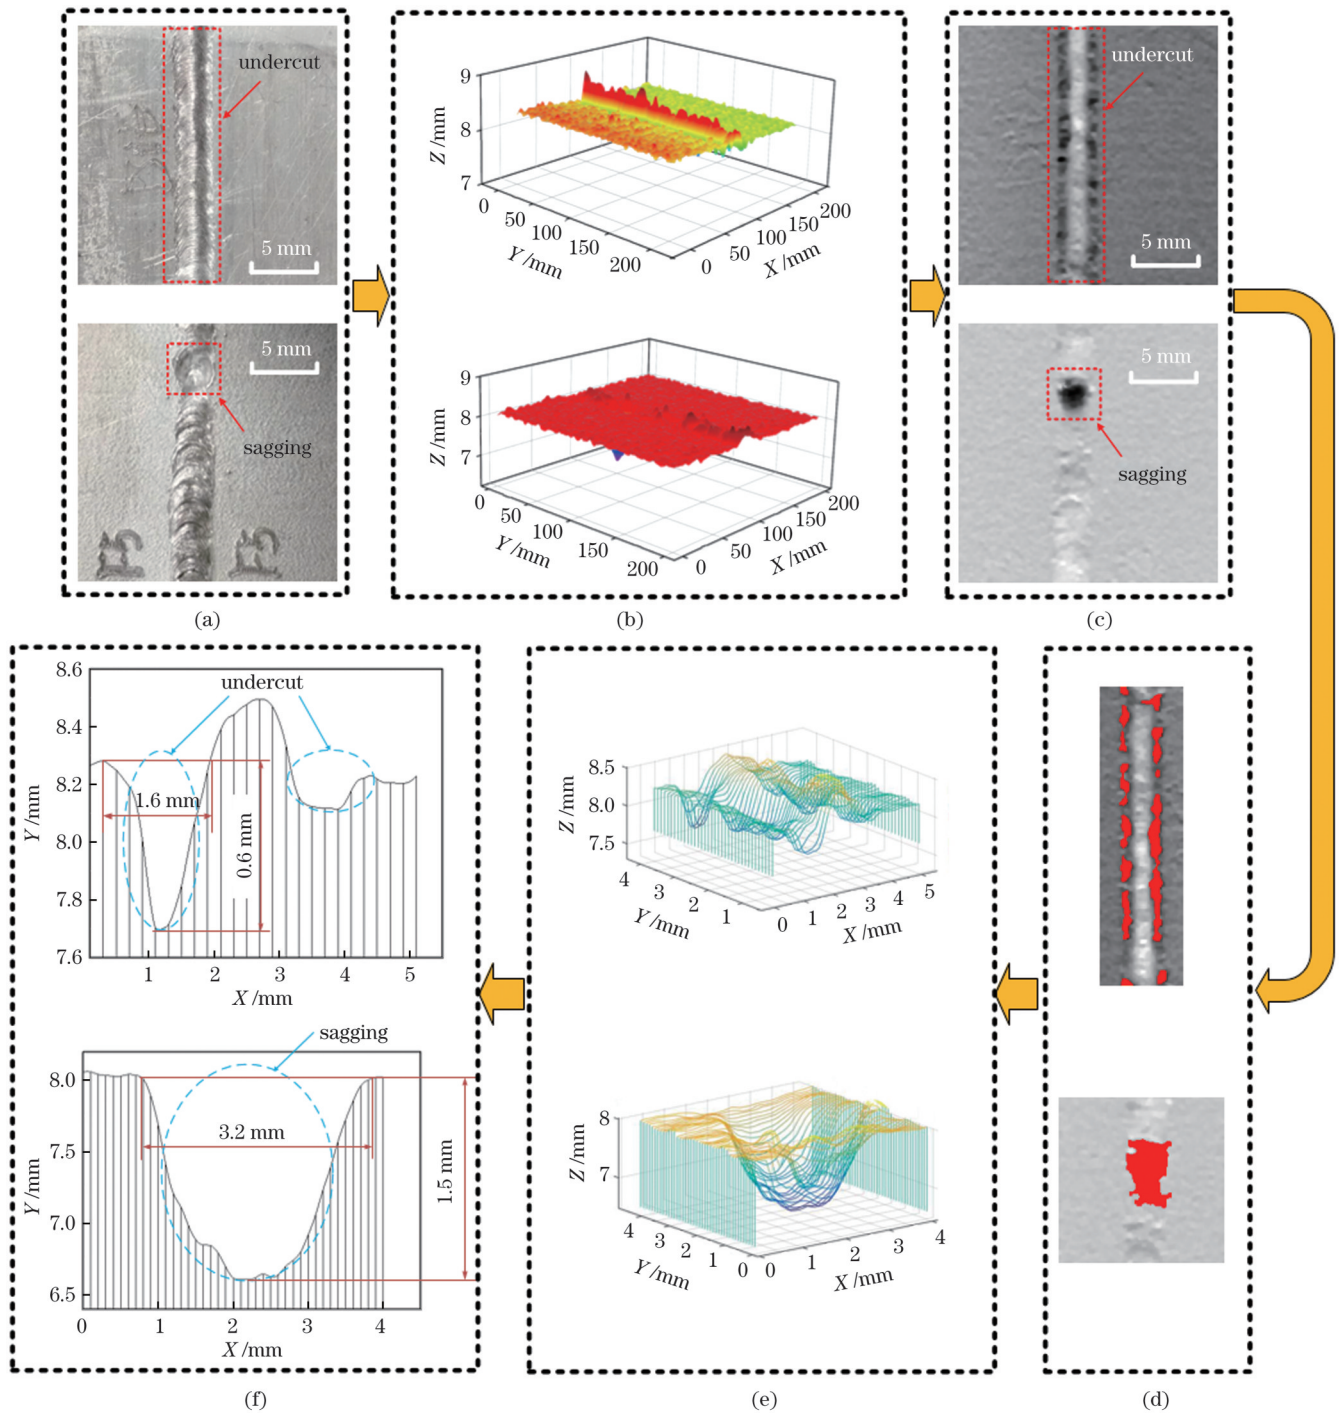


图9 缺陷尺寸的测量过程。(a)RGB图;(b)点云;(c)深度灰度图;(d)阈值分割;(e)缺陷区域定位;(f)缺陷特征尺寸测量
 Fig. 9 Measurement process of defect sizes. (a) RGB images; (b) point clouds; (c) depth gray images; (d) threshold segmentation; (e) locating defect areas; (f) defect feature size measurement

表5 缺陷尺寸测量结果

Table 5 Measurement results of defect sizes

No.	Defect type	Maximum depth /mm	Area /mm ²	Width /mm	Length /mm	Actual width /mm	Actual length /mm
1	Sagging	1.514	7.53	3.00	3.55	2.96	3.52
2		2.030	8.67	2.20	5.85	2.17	5.83
3		1.810	9.68	3.35	4.00	3.39	3.94
4	Undercut	0.438	18.97	1.45	30.55	1.47	30.64
5		0.565	33.66	1.20	56.25	1.18	56.34
6		0.473	23.86	0.95	39.25	0.92	39.32

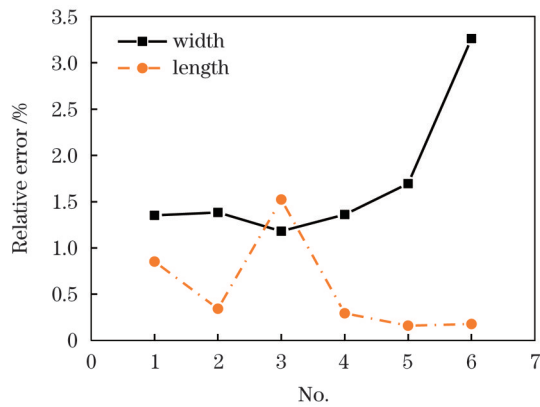


图 10 缺陷测量结果的相对误差

Fig. 10 Relative errors of defect measurement results

4 结 论

提出了一种新的焊缝缺陷检测方案。根据实验结果验证了该方案的可行性和优越性,该方案由高密度点云数据采集、深度图像生成和深度学习算法组成。建立 Faster R-CNN 模型,其特征提取骨干网为 ResNet50。该模型的平均准确率为 93%。与基于 ResNet18 的模型相比,基于 ResNet50 的模型的检测时间只有些许增加。利用 Faster R-CNN 模型捕获的局部缺陷点云,有效地测量了缺陷的特征尺寸,缺陷尺寸测量的准确率为 96.7%。该检测系统满足了缺陷在线检测的要求。

参 考 文 献

- [1] Hou J C, Li R F, Xu C, et al. A comparative study on microstructure and properties of pulsed laser welding and continuous laser welding of Al-25Si-4Cu-Mg high silicon aluminum alloy[J]. *Journal of Manufacturing Processes*, 2021, 68: 657-667.
- [2] 占小红,李悦,赵艳秋,等. 纳米颗粒对 2195 铝锂合金激光焊微观组织的影响[J]. *中国激光*, 2023, 50(12): 1202101.
Zhan X H, Li Y, Zhao Y Q, et al. Influence of nanoparticles on laser weld microstructure of 2195 Al-Li alloy[J]. *Chinese Journal of Lasers*, 2023, 50(12): 1202101.
- [3] Malikov A, Orishich A, Vitoshkin I, et al. Effect of post-heat treatment on microstructure and mechanical properties of laser welded Al-Cu-Mg alloy[J]. *Journal of Manufacturing Processes*, 2021, 64: 620-632.
- [4] Stavridis J, Papacharalampopoulos A, Stavropoulos P. Quality assessment in laser welding: a critical review[J]. *The International Journal of Advanced Manufacturing Technology*, 2018, 94(5/6/7/8): 1825-1847.
- [5] You D Y, Gao X D, Katayama S. Review of laser welding monitoring[J]. *Science and Technology of Welding and Joining*, 2014, 19(3): 181-201.
- [6] Cai W, Wang J Z, Jiang P, et al. Application of sensing techniques and artificial intelligence-based methods to laser welding real-time monitoring: a critical review of recent literature[J]. *Journal of Manufacturing Systems*, 2020, 57: 1-18.
- [7] 蔡旺,蒋平,舒乐时,等. 基于机器视觉的高功率激光焊接过程飞溅监测方法与飞溅特征研究[J]. *中国激光*, 2023, 50(24): 2402106.
Cai W, Jiang P, Shu L S, et al. Machine vision-based spatter monitoring method and spatter characterization for high power laser welding process[J]. *Chinese Journal of Lasers*, 2023, 50(24): 2402106.
- [8] 李召阳,李中梁,南楠,等. 基于偏振 OCT 的激光焊接匙孔深度测量方法[J]. *中国激光*, 2023, 50(20): 2002106.
Li Z Y, Li Z L, Nan N, et al. Measurement method of keyhole depth in laser welding based on polarization sensitive OCT[J]. *Chinese Journal of Lasers*, 2023, 50(20): 2002106.
- [9] Fan X, Gao X D, Liu G Q, et al. Research and prospect of welding monitoring technology based on machine vision[J]. *The International Journal of Advanced Manufacturing Technology*, 2021, 115(11/12): 3365-3391.
- [10] Li Y, Li Y F, Wang Q L, et al. Measurement and defect detection of the weld bead based on online vision inspection[J]. *IEEE Transactions on Instrumentation and Measurement*, 2010, 59(7): 1841-1849.
- [11] Han Y Q, Fan J F, Yang X Z. A structured light vision sensor for on-line weld bead measurement and weld quality inspection[J]. *The International Journal of Advanced Manufacturing Technology*, 2020, 106(5/6): 2065-2078.
- [12] Muhammad J, Altun H, Abo-Serie E. Welding seam profiling techniques based on active vision sensing for intelligent robotic welding[J]. *The International Journal of Advanced Manufacturing Technology*, 2017, 88(1): 127-145.
- [13] Liu Y K, Zhang Y M. Control of 3D weld pool surface[J]. *Control Engineering Practice*, 2013, 21(11): 1469-1480.
- [14] Dastoorian R, Elhabashy A E, Tian W M, et al. Automated surface inspection using 3D point cloud data in manufacturing: a case study[C]//*Proceedings of ASME 2018 13th International Manufacturing Science and Engineering Conference*, June 18-22, 2018, College Station, Texas, USA. New York: ASME Press, 2018.
- [15] Wang M, Xi L F, Du S C. 3D surface form error evaluation using high definition metrology[J]. *Precision Engineering*, 2014, 38(1): 230-236.
- [16] Yan Z H, Shi B W, Sun L P, et al. Surface defect detection of aluminum alloy welds with 3D depth image and 2D gray image[J]. *The International Journal of Advanced Manufacturing Technology*, 2020, 110(3): 741-752.
- [17] Chen L, Li X H, Zhou X. A 3D seam extraction and tracking method based on binocular structured light sensor[J]. *Proceedings of SPIE*, 2020, 11519: 115191Y.
- [18] Li B Z, Xu Z J, Gao F, et al. 3D reconstruction of high reflective welding surface based on binocular structured light stereo vision[J]. *Machines*, 2022, 10(2): 159.
- [19] Hinton G E, Salakhutdinov R R. Reducing the dimensionality of data with neural networks[J]. *Science*, 2006, 313(5786): 504-507.
- [20] Jiao W H, Wang Q Y, Cheng Y C, et al. End-to-end prediction of weld penetration: a deep learning and transfer learning based method [J]. *Journal of Manufacturing Processes*, 2021, 63: 191-197.
- [21] Dai W, Li D Y, Tang D, et al. Deep learning assisted vision inspection of resistance spot welds[J]. *Journal of Manufacturing Processes*, 2021, 62: 262-274.
- [22] Yang Y T, Yang R Z, Pan L H, et al. A lightweight deep learning algorithm for inspection of laser welding defects on safety vent of power battery[J]. *Computers in Industry*, 2020, 123: 103306.
- [23] Liu B, Zhang X Y, Gao Z Y, et al. Weld defect images classification with VGG16-based neural network[M]//Zhai G T, Zhou J, Yang X K. *International forum on digital TV and wireless multimedia communications. Communications in computer and information science*. Singapore: Springer, 2018, 815: 215-223.
- [24] Xia C Y, Pan Z X, Fei Z Y, et al. Vision based defects detection for Keyhole TIG welding using deep learning with visual explanation[J]. *Journal of Manufacturing Processes*, 2020, 56: 845-855.
- [25] Zhang Z F, Wen G R, Chen S B. Weld image deep learning-based on-line defects detection using convolutional neural networks for Al alloy in robotic arc welding[J]. *Journal of Manufacturing*

- Processes, 2019, 45: 208-216.
- [26] Guo Z Y, Ye S F, Wang Y J, et al. Resistance welding spot defect detection with convolutional neural networks[M]//Liu M, Chen H Y, Vincze M. Computer vision systems. Lecture notes in computer science. Cham: Springer, 2017, 10528: 169-174.
- [27] Ren S Q, He K M, Girshick R, et al. Faster R-CNN: towards real-time object detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(6): 1137-1149.
- [28] Oh S J, Jung M J, Lim C, et al. Automatic detection of welding defects using faster R-CNN[J]. Applied Sciences, 2020, 10(23): 8629.
- [29] Xiao R Q, Xu Y L, Hou Z, et al. An adaptive feature extraction algorithm for multiple typical seam tracking based on vision sensor in robotic arc welding[J]. Sensors and Actuators A: Physical, 2019, 297: 111533.
- [30] Chen Z H, Huang G L, Lu C, et al. Automatic recognition of weld defects in TOFD D-scan images based on faster R-CNN[J]. Journal of Testing and Evaluation, 2020, 48(2): 20170563.
- [31] Guo W M, Liu K, Qu H F. Welding defect detection of X-ray images based on faster R-CNN model[J]. Journal of Beijing University of Posts and Telecommunications, 2019, 42(6): 20-28.
- [32] Wang L, Gao M, Zhang C, et al. Effect of beam oscillating pattern on weld characterization of laser welding of AA6061-T6 aluminum alloy[J]. Materials & Design, 2016, 108: 707-717.
- [33] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [34] Cao X, Wallace W, Poon C, et al. Research and progress in laser welding of wrought aluminum alloys. I. Laser welding processes [J]. Materials and Manufacturing Processes, 2003, 18(1): 1-22.

Intelligent Online Detection of Laser Welding Defects Based on High Density Point Clouds (Invited)

Zhang Chen^{1*}, Hu Peipei², Zhu Xinwang³, Yang Changqi²

¹The Institute of Technological Sciences, Wuhan University, Wuhan 430072, Hubei, China;

²Shanghai Spaceflight Precision Machinery Institute, Shanghai 201600, China;

³Hubei Institute of Measurement and Testing Technology, Wuhan 430223, Hubei, China

Abstract

Objective The primary objective of this study is to transform the status quo of laser-welding defect detection. By developing an online deep learning system, this study aims to enable the identification and measurement of surface defects in laser-welded aluminum-alloy sheets with high precision and efficiency. The specific focus is on two prevalent defects: undercuts, characterized by the insufficient melting of the base material at the weld toe, and sagging, which is the undesirable downward displacement of the material along the weld seam. The use of high-density point cloud data is key to overcoming the limitations of traditional defect detection methods and enhancing the adaptability of the system to diverse welding conditions.

Methods A binocular-structured light sensor capable of capturing detailed point cloud data of defects in laser-welded samples is used. This sensor is strategically positioned to cover the entire welding area, which ensures the collection of comprehensive defect data. The acquired point cloud data undergo meticulous preprocessing to eliminate noise and artifacts, resulting in a clean and informative dataset. The dataset serves as the foundation for training the faster region-based convolutional neural network (Faster R-CNN) model, a deep learning architecture renowned for its object detection capabilities. The Faster R-CNN model is augmented with an area recommendation network, a critical addition to improve defect localization precision. The training process involves subjecting the model to various defect scenarios to ensure its adaptability to various welding conditions and defect types.

Results and Discussions The trained Faster R-CNN model exhibits an outstanding recognition precision rate of 93% when is tested on high-density point cloud data. This significant improvement compared to that of the model trained on images from a traditional two-dimensional vision sensor demonstrates the efficiency of leveraging point cloud data in defect detection. The ability of the Faster R-CNN model to recognize and locate defect positions is essential for swift, accurate, real-time online detection during laser welding. A noteworthy finding of the study is the significant increase in the maximum welding speed allowed by the developed inspection system for online detection. The system demonstrates a maximum speed of 316.87 mm/s, a considerable advancement beyond typical laser-welding speeds. This achievement not only showcases the potential for high-speed online detection without compromising precision but also underscores the transformative impact of the developed system on industrial practices. The discussions extend beyond the principal results, exploring the implications of the system performance in various laser welding scenarios. Variations in the material thickness, welding parameters, and defect types are systematically analyzed to assess the robustness of the proposed model. The results show the adaptability of the model to different welding conditions, highlighting its versatility in practical applications. The robustness test also provides insights into potential optimizations and improvements, setting the stage for future developments in laser-welding defect detection. The study emphasizes the significance of defect localization in achieving precise measurements. The integration of an area recommendation network with the Faster R-CNN model significantly contributes to improved defect localization, a critical factor for enhancing defect measurement accuracy. This aspect of the model design is examined in detail, clarifying the mechanisms that contribute to its superior performance in defect detection.

Conclusions The developed online detection system, powered by the Faster R-CNN model and high-density point cloud data, achieves a recognition precision rate of 93%. This demonstrates a substantial advancement in defect detection. By effectively addressing the challenges of classifying and measuring surface defects in laser welding, the system is established as a transformative technology with far-reaching implications in the manufacturing industry. The integration of high-density point cloud data provides rich information that enhances the efficiency and accuracy of defect detection. This breakthrough not only mitigates the limitations of traditional two-dimensional vision sensors but also positions the system as a pioneering solution for high-speed online detection in laser-welding processes. The study opens new avenues for research and development in smart manufacturing, paving the way for the integration of advanced technologies in industrial applications.

Key words laser technique; laser welding; welding defect; real-time detection; high density point cloud data; deep learning