

◇ 研究论文 ◇

基于深度分类网络与激光超声的焊深测量方法

王志颖 孙凯华[†] 何华彬

(中国工程物理研究院机械制造工艺研究所 绵阳 621000)

摘要: 焊深是衡量焊接质量的重要参数,其对焊接产品的性能有极大影响,因此发展焊深的无损测量方法尤为重要。在众多无损测量方法中,激光超声凭借其无耦合剂、高时空分辨率等特点,在小结构焊深测量中具有独特的优势。由于小尺寸结构中存在超声模式混叠且焊缝的衍射波微弱的问题,该文提出将激光超声与深度学习相结合的焊深测量方法,在线切割模拟焊接样品上进行激光超声扫描实验。将超声 A 扫信号压缩为矩阵格式可加速深度网络收敛、减少网络参数规模。与反射横波模式方法相比,训练得到的深度分类模型能够实现焊深测量误差小于 0.1 mm。最终的结果表明,深度网络在焊深测量中具有良好的发展前景。

关键词: 激光超声;深度学习;焊深测量

中图法分类号: TG115.28

文献标识码: A

文章编号: 1000-310X(2025)05-1150-09

DOI: 10.11684/j.issn.1000-310X.2025.05.006

Welding depth measurement method based on depth classification network and laser ultrasonic

WANG Zhiying, SUN Kaihua and HE Huabin

(China Academy of Engineering Physics, Institute of Mechanical Manufacturing Process, Mianyang 621000, China)

Abstract: Welding depth is an important parameter for measuring welding quality and has a great impact on the performance of welded products. Therefore, it is particularly important to develop non-destructive measurement methods for welding depth. Among many non-destructive measurement methods, laser ultrasonic has unique advantages in weld depth measurement of small structures due to its characteristics of no coupling agent and high spatial and temporal resolution. Due to the problems of ultrasonic mode mixing in small-size structures and weak diffraction waves of welds, this paper proposes a welding depth measurement method that combines laser ultrasonic and deep learning to conduct laser ultrasonic scanning experiments on wire-cut simulated welding samples. Compressing the ultrasonic A-scan signal into a matrix format accelerates the convergence of deep networks and reduces the scale of network parameters. Compared with the reflected shear wave mode method, the trained depth classification model can achieve a welding depth measurement error of less than 0.1 mm. The final results show that the depth network has good development prospects in welding depth measurement.

Keywords: Laser ultrasonic; Deep learning; Welding depth measurement

2024-04-07 收稿; 2024-05-16 定稿

作者简介: 王志颖(2000-), 男, 甘肃张掖人, 硕士研究生, 研究方向: 激光超声无损检测。

[†]通信作者 E-mail: KaihuaSun_CAEP@163.com

0 引言

焊接工艺在航空航天、船舶汽车和武器装备等领域被广泛应用。焊接质量对装备的可靠性有着极大的影响,因此对焊接质量的检测尤为重要。焊深是评价焊接质量的关键参数,焊深的测量对优化焊接参数、提高焊接质量具有非常重要的意义。目前焊缝检测方法多种多样,常用的手段包括金相解剖、射线、光学以及超声检测。结合实际的焊接流程,焊接质量控制方法大致可以划分为工艺参数稳定性控制和焊接后检测。

目前大部分焊接产品依靠焊接工艺参数稳定性保证其产品一致性。通过金相检测或其他破坏性手段在平行试验件上重复试验,找到稳定的焊接参数,以此保证产品质量的一致性,如Schmoeller等^[1]利用机器学习方法研究了激光束焊接工艺参数对焊缝深度的影响,以数据驱动开发了基于工艺参数预测焊接深度的模型;Singh等^[2]研究了惰性气体保护焊在不同电压、电流、焊接速率和进给率下焊接参数对低碳钢焊缝熔深的影响。在焊接工艺复杂时,为获得更优的焊接质量,需通过相干光断层扫描^[3-5]、熔池形态监控^[6-7]、焊接声音采集^[8]等手段实时监控熔深和焊接参数,同时动态调整焊接参数。

焊接时参数监控和调整能有效地控制焊接深度,但都是依靠熔池形态等方法对焊深做出间接判断,真实的焊深仍需焊接完成后进一步确认。常用的焊接后检测方法包括金相解剖、射线检测和超声检测。金相解剖法用于检测平行试验件,用平行试验件的检测结果代替实际零件的结果,由于没有检测实际使用的零件,在产品性能要求较高的特殊场合存在很大的不确定性。射线检测通过射线穿过焊接件的衰减量来区分焊接区域和未焊接区域,但在焊缝很窄的情况下,射线在这两个区域的衰减梯度不明显,难以分辨焊接区域和未焊接区域。焊深的无损测量方法除了射线检测外,还有超声检测,超声相较于射线而言,其检测成本低、部署方便、无辐射危害,因此在焊缝无损检测中占据重要地位。

本文主要面向小尺寸焊接件的检测,相较于传统超声,激光超声^[9]具有无耦合剂、激励位置定位准确的优点。对于常规尺寸的焊件检测,激光超声所激发的各种模式在时域上能有效分离,应用脉冲回波法、透射法^[10]、聚焦算法^[11-15]等方法就能实

现焊缝尖端的定位。但是在小尺寸焊接件中,激光超声采集信号时激发探测点分离,导致扫描到样品边缘时会存在盲区,丢失一部分可检测区域,对浅焊缝检测能力不足;另外,由于激光超声激励的模式较多,在样品内部反射后声场混乱,单一模式波提取困难,合成孔径算法等虚拟聚焦方法的成像质量也严重下降。

近年来,深度学习算法在目标识别、自然语言处理等领域飞速发展,其对数据强大的表达能力也引起超声检测领域的关注。随着检测复杂度增加以及检测要求的不断提高,深度学习也逐渐引入于超声检测领域,被应用于缺陷成像^[16-20]、超声测厚^[21]、寿命评估^[22-23]等方向。如Song等^[24-25]构建了缺陷定位网络和缺陷超分辨网络,实现了对点缺陷和线缺陷的有效定位,并获得了质量较高的缺陷形态图;Wang等^[26]提出一种基于卷积神经网络的快速导波成像方法,对铝合金板表面腐蚀缺陷有82.73%的检出率,腐蚀区域尺寸接近 $\lambda/2$ 时,位置检测精度达到84%;Lee等^[27]使用自动编码网络实现了对碳纤维材料的疲劳寿命检测,利用网络中的隐藏层做信号聚类,最终可以准确地判别碳纤维材料中的疲劳损伤。然而目前的深度网络都面向单一应用场景,网络和数据强关联,面对不同的工程问题时需要二次训练或重新设计,无法实现本课题中小尺寸焊缝焊深的高精度测量。

因此本文面向小尺寸焊件焊深激光超声检测时存在的焊缝尖端衍射波微弱、激光超声模式混杂难以分离的问题,提出基于深度分类网络的测量方法,向深度网络输入矩阵化的超声A扫信号,通过信号分类实现焊缝尖端的定位。为了验证方法的可行性,本文设计了多个焊深和焊缝宽度不同的模拟焊接件,并以相同参数进行激光超声扫描实验获取超声A扫信号。最后将深度网络测量结果与反射横波模式提取方法的测量结果对比,以此评估深度学习测量焊深的能力。

1 实验

1.1 试样制备

为了初步验证提出的焊深测量方法,设计了如图1(a)所示的样品。首先使用线切割加工样品,以便准确控制模拟焊缝的深度和宽度,然后对其进行激光超声扫描实验。实验样品的高度为20 mm,

宽度为20 mm, 模拟焊深 h 分别为1 mm、2 mm、3 mm, 缝隙宽度 w 分别为0.2 mm、0.3 mm, 样品的尺寸见图1(b), 实际测量的模拟焊深见下文表2和表3。将 w 、 h 交叉得到6个尺寸不同的铝合金样品和6个尺寸不同的抗氢钢样品, 所用材料的超声波波速见表1, 并对样品编号, 包括材料、 w 以及 h 参数, 如Al-h3-w3代表焊深3 mm、缝宽0.3 mm的铝样品。激光在样品表面激励后产生超声波, 各模式波的传播路径如图1(b)所示, 包括表面波(R)、掠面纵波(Ls)、反射横波(SS)、反射纵波(LL)、横波模式转换波(SL)以及纵波模式转换波(LS)。

1.2 实验装置

实验中使用的激光超声检测系统如图2所示, 包括脉冲激光器、干涉仪、直线滑台、示波器、计

算机等部件。激光器作为激励源产生单脉冲能量5 mJ、波长1064 nm、脉宽7 ns、重复频率1 kHz的脉冲激光。脉冲激光经过分光镜后, 少部分光反射到光电探测器作为触发信号, 大部分光透射到聚焦透镜, 光斑直径3 mm的激光源经柱面透镜聚焦为宽0.2 mm、长3 mm的线型光斑斜入射到试件表面, 以热弹机制诱导产生超声, 用波长为532 nm、带宽为27 MHz的干涉仪接收产生的超声波。

表1 材料参数
Table 1 Material parameters

材料名称	$C_L/(mm \cdot \mu s^{-1})$	$C_S/(mm \cdot \mu s^{-1})$	$C_R/(mm \cdot \mu s^{-1})$
6061	6.046	3.066	2.924
抗氢钢	5.461	3.088	2.909

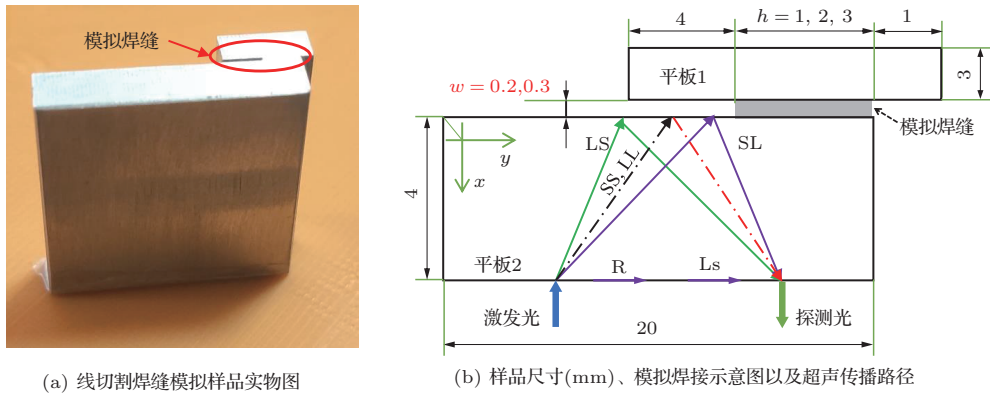


图1 样品结构

Fig. 1 Sample structure

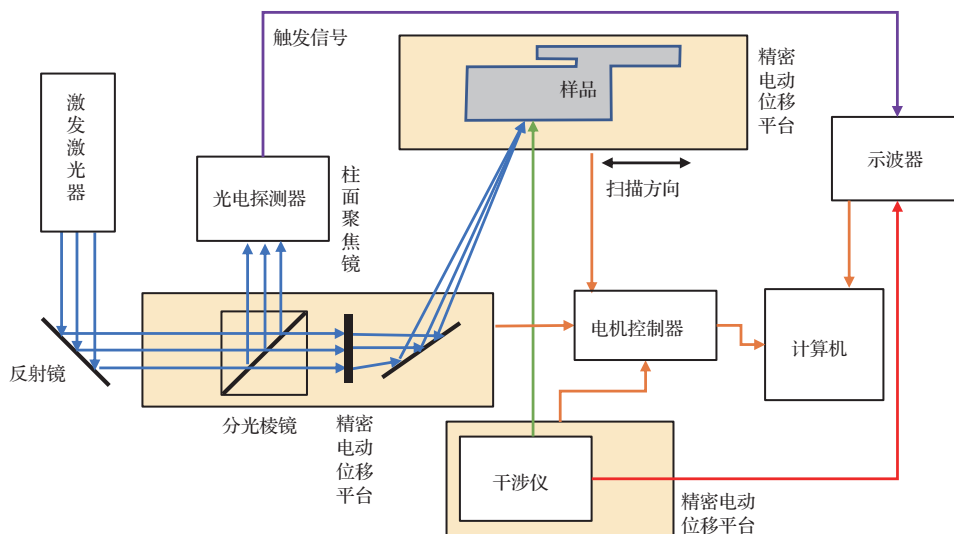
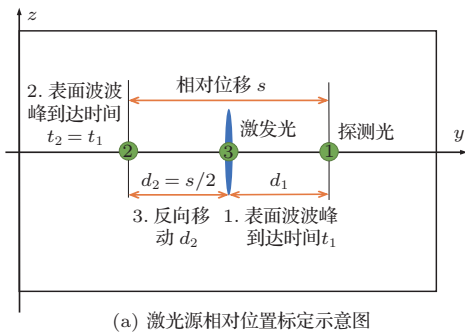


图2 激光超声检测系统示意图


Fig. 2 Schematic diagram of laser ultrasonic inspection system

1.3 激发探测间距调整

由于激光超声在不同方向上的强度不同,因此在扫描前需要确定激发光和探测光之间的距离,保证最终采集的信号具有高信噪比。为了确保激发光和探测光之间的相对位置准确且具有一致性,利用表面波波峰到达时间对其进行标定,标定流程如图3(a)所示。(1)通过红外相机调整探测光在激发光右侧 d_1 附近,如图3(b)所示,并从示波器准确读取表面波波峰到达时间 t_1 ; (2)调整探测光精密位移台,使探测光在激发光左侧时,表面波波峰到达时间 $t_2 = t_1$; (3)读取位移台的总相对位移 s ,反向移动 $s/2$ 使激发光和探测光完全重合。实验中结合激光超声指向性理论对激发探测间距做微调,最终确定在激发探测间距 $d = 2.00 \text{ mm}$ 时,所采集的信号质量较高。



(a) 激光源相对位置标定示意图



(b) 红外相机拍摄激光

图3 激发光与探测光相对位置确定示意图

Fig. 3 Schematic diagram of relative position calibration of excitation light and detection light

为了保证测量结果的准确性,实验中还需要对激发光在样品表面的位置 l 做精确标定,如图4所示。在本实验中使用左行表面反射波和右行表面反射波间的时间差来计算,具体的计算方法为:左行表面波声程为 $(2l + d)$ mm,右行表面波声程为 $(2L - 2l - d)$ mm,当激发光在样品中心时,声程差为4 mm,结合表面波波速 C_R ,Al和Fe样品的反射时间差分别为 $1.368 \mu\text{s}$ 、 $1.375 \mu\text{s}$,调整样品滑台并

观察示波器,直到左行反射峰和右行反射峰间的延迟满足上述要求就可以保证激发光在样品中心。




图4 表面波定位样品中心

Fig. 4 Rayleigh wave positioning sample center

1.4 实验结果和分析

采集过程中,固定激发光和探测光所在的滑台,驱动样品所在的直线滑台,以 0.01 mm 的步长从工件 14 mm 处扫描到 18 mm 处,共401点。信号采样率为 1.25 GHz ,单个A扫信号时长 $8 \mu\text{s}$ 、长度10000。将全部样品扫描后,得到铝合金样品和抗氢钢样品的超声B扫描信号分别如图5和图6所示。从B扫描中可以观察到表面波、表面波反射波(RR)、SS波以及SL/LS波,其传播路径^[28]见图1(b)。从图中可以看出,在激光位置处于焊接区域(接近 18 mm)时,SS波在时域上逐渐消失,所以SS波与焊深之间存在很强的关联性。但是随着扫描位置靠近边界,RR波的到达时间提前,并在约 15.5 mm 处与SS波在时域上重叠,导致无法完美分离SS波和RR波,从而使利用SS波提取方法来测量焊深的难度增加。

从样品Al-h3-w3的B扫信号中提取出激发坐标为 14 mm 的信号,如图7实线所示,其中SS波较为强烈,但是在激发坐标为 15 mm 时,由于表面波反射波的存在,无法分离SS波。在这种情况下,利用SS波测量焊深会更加困难。为了测试SS波焊深测量方法的性能,从整个B扫信号中截取横波反射时间附近宽度为 $0.4 \mu\text{s}$ 的信号,并取每个子A扫信号的最大值,得到的结果如图8中蓝线所示,前半段的信号由于没有表面波反射波的干扰,其最大值变化稳定;而在中间区域表面波反射波的干扰导致最大值出现了严重的畸变;在信号尾部由于底面深度变化,横波在时间窗内消失,因此最大值也表现为平稳变化。由于信号中存在突变,阶跃函数拟合可能出现参数发散的情况,因此在拟合位置时使用变化较为缓和的Sigmoid函数,其表达式为

$$f(x; a, b, c, h') = -a \frac{1}{1 + e^{-(bx+h')}} + c, \quad (1)$$




图5 铝合金样品超声B扫描信号

Fig. 5 Ultrasonic B-scan signal of aluminum sample

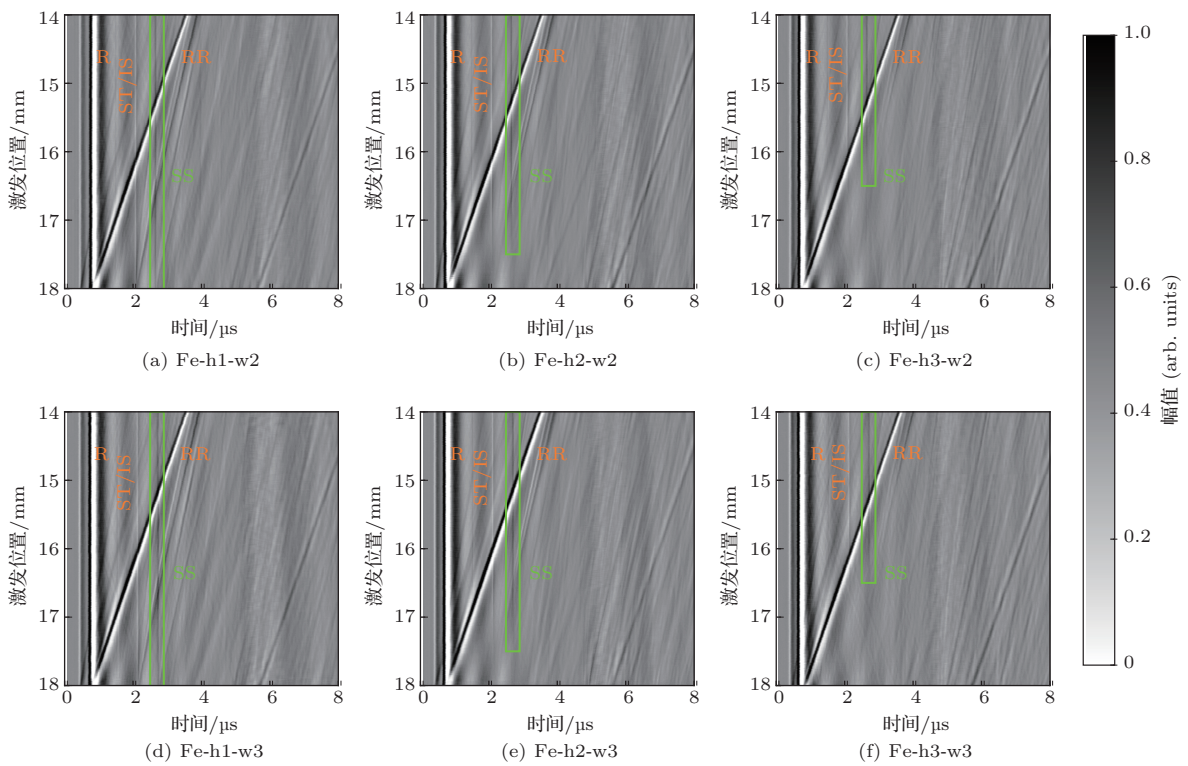


图6 抗氢钢样品超声B扫描信号

Fig. 6 Ultrasonic B-scan signal of hydrogen-resistant steel sample




图7 样品 Al-h3-w3 激发点在 14 mm 和 15 mm 的超声 A 扫信号

Fig. 7 Ultrasonic A-scan signals of sample Al-h3-w3 excitation point at 14 mm and 15 mm




图8 横波反射峰最大值拟合效果 (横轴坐标反转)

Fig. 8 Fitting the maximum value of the shear wave reflection peak (inverting the horizontal axis coordinates)

其中, 参数 h' 代表焊缝尖端的位置。函数的优化目标为平方误差最小, 经过迭代优化后, Al-h3-w3 样品的拟合结果如图8中的点画线所示, 函数的参数为 (0.25, 10.53, 0.82, -16.75), 拟合信号以

-16.75 作为信号突变的中心点。焊深以样品的右端面为原点, 将中心点转换到焊深坐标, 得到焊深 $h = L + h' = 3.25$ mm, 绝对误差 0.27 mm。

使用相同的方法对其余样品的结果做拟合处理, 得到的结果见表2和表3, 从表中可以看出, 采用SS波提取方法在焊深大于2 mm时有较好的效果。但是在焊深接近1 mm时, 由于激发探测间距为2 mm, B扫信号中并不包含19~20 mm区域的底面反射信号, SS波提取方法完全失效, 采用底面反射波单一模式无法实现浅焊深的准确测量。

同时也注意到靠近边缘区域的超声信号较为复杂, 焊缝尖端的衍射信号在B扫图中也不存在明显的衍射峰, 因此手工提取衍射波或其他模式也较为困难。面对这种情况, 借助深度学习自动提取特征, 进而实现焊深测量的方法更具备可行性。

2 深度分类网络测量方法

目前常用的智能检测算法包括基于传统机器学习的检测算法和基于深度网络的检测算法两大类。传统的机器学习算法需要人工的提取有效特征, 如中心频率、信号能量等时频域或统计特征, 然后利用支持向量机、K-Means等传统算法实现对信号的分类和预测。然而随着信号复杂度增加、维度提升, 从信号中人工提取有效特征已经极其困难, 面对这种情况, 科研工作者提出了表示学习^[29]这一概念, 其核心想法就是给定网络的输入和输出,

表2 反射横波模式方法在铝合金样品上的模拟焊深测量结果

Table 2 Simulated welding depth measurement results of reflected shear wave mode method on aluminum samples

样品代号	Al-h1-w3	Al-h2-w3	Al-h3-w3	Al-h1-w2	Al-h2-w2	Al-h3-w2
真实值/mm	0.96	2.00	2.98	0.98	1.98	3.00
测量值/mm	2.53	2.44	3.25	1.07	2.05	3.22
绝对误差/mm	1.57	0.44	0.27	0.09	0.07	0.22

表3 反射横波模式方法在抗氢钢样品上的模拟焊深测量结果

Table 3 Simulated welding depth measurement results of reflected shear wave mode method on hydrogen-resistant steel samples

样品代号	Fe-h1-w3	Fe-h2-w3	Fe-h3-w3	Fe-h1-w2	Fe-h2-w2	Fe-h3-w2
真实值/mm	1.00	2.04	3.02	1.00	2.04	3.06
测量值/mm	1.99	3.11	3.10	2.01	2.51	3.26
绝对误差/mm	0.99	1.07	0.08	1.01	0.47	0.2

由网络本身确定合适的特征。而深度学习就是解决表示学习的一种途径。深度学习算法包括数据、算法和策略三个要素,在实践中分别对应数据集、网络结构、训练策略。本小节就以三要素为基础,参考ResNet^[30]、VGG^[31]等经典网络,构建超声信号分类网络实现模拟焊深的测量。

2.1 数据集与网络结构设计

深度网络中数据集的质量对最终的预测结果有着显著的影响,在实验中需要保持所有样品扫描时的激光能量、激光的聚焦状态一致,经过处理后共获得有效信号4812个,其中未焊接区域3600个,焊接区域1212个。然后按照采集信号时探测光所处的位置为信号进行标记,也即探测光在焊接区域标记为 $y = 0$,代表异常信号;探测光在未焊接区域标记为 $y = 1$,代表正常信号。最后将超声信号组合成一个维度为(4812, 1, 10000)的原始数据集 \mathbf{R} 。从浅层语义角度讲,超声信号中是否包含SS模式回波是划分信号有无异常的一个重要判据,但是其他的模式波,如SL/LS波,甚至一些无法直接观察得到的隐特征也会对最终的判断有不同权重的贡献,因此为了保证信号特征的完整性,训练中不对信号做截断或者掩膜操作。对于深度网络而言,要感知一个长信号的全部空间关系,就必须用一个层数较多的网络,这会使网络参数量暴涨,降低计算速度。为了加快训练速度,将原始的信号变换为一个 100×100 的矩阵,由于更关注空间特征而非时序依赖,因此对信号矩阵化并不会对预测结果产生负面影响。最后经过矩阵化得到的数据集 \mathbf{G} 的规模为(4812, 1, 100, 100)。

数据集 \mathbf{G} 划分为训练集 $\mathbf{G}_{\text{train}}$ 、测试集 \mathbf{G}_{test} 以及验证集 $\mathbf{G}_{\text{valid}}$ 用于网络训练、测试和验证。为了更好地量化网络模型的可用性,将Al-h1-w3和Fe-h1-w2的全部信号都放置到 $\mathbf{G}_{\text{valid}}$ 中,剩余的信号作为训练集和测试集,并按照比例为8:2随机分割,最终训练集和测试集的大小分别为 $N = 3208$ 、 $M = 802$ 。接下来根据信号搭建深度卷积网络来进行训练,具体的网络结构如图9所示。网络的输入是经过矩阵化后的信号 X ,输出为信号 X 属于异常信号和正常信号的类别概率 $P(y|X)$ 。深度网络由特征提取层、全局池化层以及分类层构成。其中,特征提取层由多个残差块^[30]和最大池化串联构成,每个残差块中又包含2层卷积计算和2层Batch Norm环节,并使用ReLU作为激活函数。全局池化

层将特征图池化为 1×1 的矩阵,只保留图像的主特征信息。最后的分类层中包括一个输入神经元数量为24、输出神经元数量为2的全连接层,然后采用Sigmoid归一化,最后用SoftMax对结果进行概率预测,网络内部的可训练参数大概为 5×10^3 。

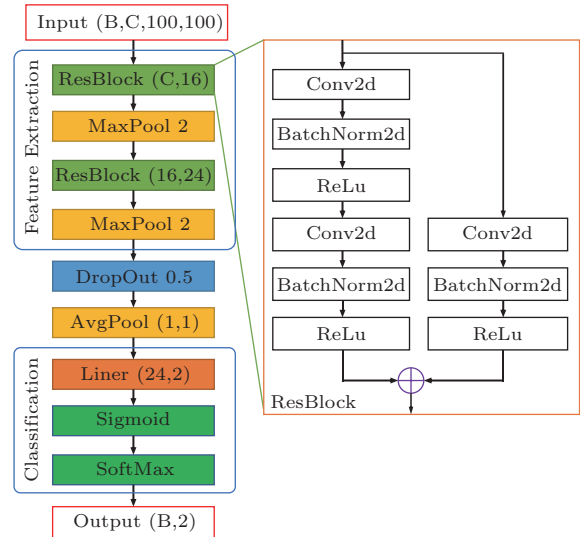


图9 卷积网络结构

Fig. 9 Convolutional network structure

在训练过程中选用交叉熵损失作为损失函数进行网络参数优化,其具体计算方法如下:

$$L = -\frac{1}{N} \sum_{i=1}^N \sum_y Q_i(y|X) \cdot \lg(P(y|X)), \quad (2)$$

其中, $Q_i(y|X)$ 表示的one-hot编码分布函数。交叉熵与相对熵类似,都可以度量当真实分布为 Q 而预测分布为 P 时的无效性,也即预测分布与真实分布之间的偏差。

2.2 预测结果与分析

为了得到更好的预测效果,在信号初步提取后添加了一个Dropout层^[32]来增强模型的泛化能力。经过训练后,在测试集上的分类准确率达到99%。同时为了验证模型的稳定性,进行了多次重复训练,在测试集上总体准确率均保持在95%以上,表明网络收敛稳定。最后将模型应用在验证集上,得到Al-h1-w3和Fe-h1-w2样品的焊深测量结果,如图10所示,最终的测量值分别为1.01 mm和0.93 mm,绝对误差分别为0.05 mm和-0.07 mm,且置信度都在0.7以上,表明测量的结果具有良好的可信度,说明所提出的深度学习测量焊深的方法具备优于SS波提取方法的性能。

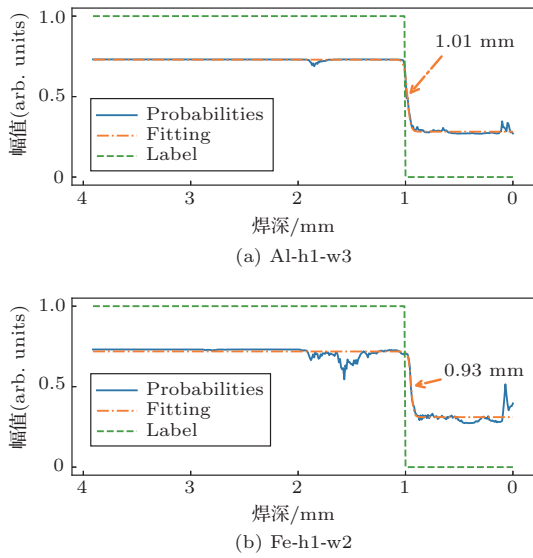


图10 验证集预测结果

Fig. 10 Validation set prediction results

2.3 模型计算效率

为了验证将A扫信号矩阵化对网络预测准确率和训练速度的影响,将全部卷积层中的卷积核修改为 1×3 大小,其余参数保持不变,使用原始数据集 \mathbf{R} 进行训练,使用不同批次大小训练一次网络耗费的时间,如表4所示。对比计算速度可以看出,使用矩阵化后的数据在网络中计算速度是原始数据的1.4倍。

表4 计算耗时统计

Table 4 Calculation time-consuming statistics

Batch size	向量信号计算耗时/s	矩阵信号计算耗时/s
128	180	127
1024	185	140
3208	GPU 显存不足	165

更为重要的是,采用原始信号的网络对信号分类的准确率一直无法提高,经过多次超参数调节和训练,其准确率始终为83.06%,对照数据集分布,在该准确率下所有的信号都被预测为无异常。这是由于网络深度不足,卷积层的视野没有覆盖到整个信号,使得训练过程中卷积层的参数变化过快,难以搜索到合适的收敛方向,如果将网络深度增加到14层以上并且每做一次卷积都将信号特征图折半,就可以获得整个信号的视野,但是这会导致网络参数规模增大,加剧训练的困难程度,增加训练时间。作为对比,使用矩阵信号的网络只使用了2个残差块就

能使网络分类准确率达到99%,且焊深测量误差小于0.1 mm。所以将A扫信号矩阵化能够使网络预测准确率大幅提高,同时还可以加速训练速度、提高收敛稳定性。

3 结论

为了解决SS波提取方法不能准确定位焊缝尖端以及尖端衍射波微弱的问题,提出了使用深度网络测量焊深的方法。基于此方法,得出以下结论:

(1) 相较于输入原始的超声A扫描信号,将信号转换为矩阵输入到网络中可以加速网络收敛,而且深度网络参数规模也会更小。

(2) 所提出的深度网络分类方法通过学习信号上的隐特征实现了模拟焊接样品焊深的准确测量,精度优于0.1 mm。相较于SS波提取方法,基于深度网络的测量方法在浅焊深测量上更具有可行性,有良好的应用前景。

未来将继续对该方法做出更全面的优化,以适应厚度样品、激发探测间距变化时的焊深测量。并在信号信噪比降低时对网络的焊深测量能力进行综合评估,增加测量结果的可靠性。

参 考 文 献

- [1] Schmoeller M, Stadter C, Wagner M, et al. Investigation of the influences of the process parameters on the weld depth in laser beam welding of aa6082 using machine learning methods[J]. Procedia CIRP, 2020, 94: 702–707.
- [2] Singh R P, Agrawal M K. Influence of process parameters on depth of penetration of tungsten inert gas welded joints for low carbon steel aisi 1010 plates[J]. Materials Today: Proceedings, 2021, 45: 3656–3661.
- [3] Boley M, Fetzner F, Weber R, et al. Statistical evaluation method to determine the laser welding depth by optical coherence tomography[J]. Optics and Lasers in Engineering, 2019, 119: 56–64.
- [4] Kang S, Lee K, Kang M, et al. Weld-penetration-depth estimation using deep learning models and multisensor signals in Al/Cu laser overlap welding[J]. Optics & Laser Technology, 2023, 161: 109179.
- [5] Li S, Jiang P, Gao Y, et al. A penetration depth monitoring method for Al-Cu laser lap welding based on spectral signals[J]. Journal of Materials Processing Technology, 2023, 317: 117972.
- [6] Nomura K, Fukushima K, Matsumura T, et al. Burn-through prediction and weld depth estimation by deep learning model monitoring the molten pool in gas metal

- arc welding with gap fluctuation[J]. *Journal of Manufacturing Processes*, 2021, 61: 590–600.
- [7] Sweeney N E, Parke S, Lines D, et al. In-process phased array ultrasonic weld pool monitoring[J]. *NDT & E International*, 2023, 137: 102850.
- [8] Yusof M F M, Ishak M, Ghazali M F. Weld depth estimation during pulse mode laser welding process by the analysis of the acquired sound using feature extraction analysis and artificial neural network[J]. *Journal of Manufacturing Processes*, 2021, 63: 163–178.
- [9] 沈中华, 袁玲, 张宏超, 等. 固体中的激光超声[M]. 北京: 人民邮电出版社, 2015.
- [10] Fang H J, Ye G, Liang J, et al. Laser ultrasound in transmission mode for defect detection of additive manufactured parts[C]//2021 IEEE 5th Advanced Information Technology, Electronic and Automation Control Conference (IAEAC). Chongqing, China: IEEE, 2021: 2403–2407.
- [11] Lévesque D, Asaumi Y, Lord M, et al. Inspection of thick welded joints using laser-ultrasonic saft[J]. *Ultrasonics*, 2016, 69: 236–242.
- [12] Ni C Y, Chen C, Ying K N, et al. Non-destructive laser-ultrasonic synthetic aperture focusing technique (SAFT) for 3d visualization of defects[J]. *Photoacoustics*, 2021, 22: 100248.
- [13] Pei C, Yi D, Liu T, et al. Fully noncontact measurement of inner cracks in thick specimen with fiber-phased-array laser ultrasonic technique[J]. *NDT & E International*, 2020, 113: 102273.
- [14] Ying K N, Ni C Y, Dai L N, et al. Multi-mode laser-ultrasound imaging using time-domain synthetic aperture focusing technique (T-SAFT)[J]. *Photoacoustics*, 2022, 27: 100370.
- [15] 钟华, 孙凯华, 孙铭, 等. 激光超声的多模式合成孔径聚焦成像仿真分析[J]. *应用声学*, 2022, 41(4): 535–547.
Zhong Hua, Sun Kaihua, Sun Ming, et al. Simulation analysis of multi-mode synthetic aperture focusing technique based on laser ultrasound[J]. *Journal of Applied Acoustics*, 2022, 41(4): 535–547.
- [16] Mohammad Ali Fakh, Chiachío M, Chiachío J, et al. A bayesian approach for damage assessment in welded structures using Lamb-wave surrogate models and minimal sensing[J]. *NDT & E International*, 2022, 128: 102626.
- [17] Munir N, Park J, Kim H J, et al. Performance enhancement of convolutional neural network for ultrasonic flaw classification by adopting autoencoder[J]. *NDT & E International*, 2020, 111: 102218.
- [18] Cai Y, Song Y, Ni P, et al. Subwavelength ultrasonic imaging using a deep convolutional neural network trained on structural noise[J]. *Ultrasonics*, 2021, 117: 106552.
- [19] Liu H, Zhang Y. Deep learning based crack damage detection technique for thin plate structures using guided Lamb wave signals[J]. *Smart Materials and Structures*, 2020, 29(1): 015032.
- [20] Xu W, Li X, Zhang J. Multi-feature fusion imaging via machine learning for laser ultrasonic based defect detection in selective laser melting part[J]. *Optics & Laser Technology*, 2022, 150: 107918.
- [21] Min J, Chen X, Wang Z, et al. Deep learning-based identification of characteristic regions for picosecond ultrasonics metrology[J]. *Measurement*, 2023, 218: 113205.
- [22] Chapon A, Pereira D, Toews M, et al. Deconvolution of ultrasonic signals using a convolutional neural network[J]. *Ultrasonics*, 2021, 111: 106312.
- [23] Cheng X, Ma G, Wu Z, et al. Automatic defect depth estimation for ultrasonic testing in carbon fiber reinforced composites using deep learning[J]. *NDT & E International*, 2023, 135: 102804.
- [24] Song H, Yang Y. Noncontact super-resolution guided wave array imaging of subwavelength defects using a multiscale deep learning approach[J]. *Structural Health Monitoring*, 2021, 20(4): 1904–1923.
- [25] Song H, Yang Y. Super-resolution visualization of sub-wavelength defects via deep learning-enhanced ultrasonic beamforming: A proof-of-principle study[J]. *NDT & E International*, 2020, 116: 102344.
- [26] Wang X, Lin M, Li J, et al. Ultrasonic guided wave imaging with deep learning: Applications in corrosion mapping[J]. *Mechanical Systems and Signal Processing*, 2022, 169: 108761.
- [27] Lee H, Lim H J, Skinner T, et al. Automated fatigue damage detection and classification technique for composite structures using Lamb waves and deep autoencoder[J]. *Mechanical Systems and Signal Processing*, 2022, 163: 108148.
- [28] 孙凯华, 沈中华, 李远林, 等. 材料内部缺陷的激光超声反射横波双阴影检测方法[J]. *中国激光*, 2018, 45(7): 243–251.
Sun Kaihua, Shen Zhonghua, Li Yuanlin, et al. Inspection of material internal defects using double shadow method based on laser ultrasonic reflected shear waves[J]. *Chinese Journal of Lasers*, 2018, 45(7): 243–251.
- [29] Goodfellow I, Bengio Y, Courville A. *Deep learning*[M]. Cambridge: MIT Press, 2016.
- [30] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[Z/OL]. (2015-12-10) [2023-09-06]. <http://arxiv.org/abs/1512.03385>.
- [31] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[Z/OL]. (2015-04-10) [2024-03-25]. <http://arxiv.org/abs/1409.1556>.
- [32] Hinton G E, Srivastava N, Krizhevsky A, et al. Improving neural networks by preventing co-adaptation of feature detectors[Z/OL]. (2012-07-03)[2024-03-15]. <http://arxiv.org/abs/1207.0580>.