

# 基于激光超声波金属机械零件表面缺陷检测方法

韩瀚<sup>†</sup>

(平顶山平煤机煤矿机械装备有限公司,河南 平顶山 467100)

**摘 要:**针对目前金属表面缺陷检测时存在数据集不足、检测精度低的缺陷,提出了一种基于激光超声波金属机械零件表面缺陷检测方法。首先,研究了基于热弹性机制的激光超声生成机制,提出应用数值模拟产生大量超声波样本数据。其次,设计了一种基于深度学习的金属表面缺陷检测模型,从而实现端对端的金属表面缺陷检测。实验结果表明,与 CNN 和 LSTM 网络相比,所提金属表面检测模型综合性能更优。仿真结果进一步验证了所提模型对激光超声波下金属零件表面缺陷检测研究具有一定借鉴作用。

**关键词:**激光超声波;金属;缺陷检测;深度学习;数值模拟

**中图分类号:**TP393

**文献标识码:**A

## Surface Defect Detection Method of Metal Mechanical Parts Based on Laser Ultrasonic

HAN Han<sup>†</sup>

(Pingdingshan PMJ Coal Mine Machinery Equipment Co., Ltd., Pingdingshan, Henan 467100, China)

**Abstract:** Aiming at the defects of insufficient data set and low detection accuracy in the current metal surface defect detection, a surface defect detection method of metal mechanical parts based on laser ultrasonic is proposed. Firstly, the mechanism of laser ultrasonic generation based on thermoelastic mechanism is studied, and a large number of ultrasonic sample data are generated by numerical simulation. Secondly, a metal surface defect detection model based on deep learning is designed to realize end-to-end metal surface defect detection. The experimental results show that the proposed metal surface detection model has better comprehensive performance than CNN and LSTM networks. The simulation results further verify that the proposed model has a certain reference value for the research of surface defect detection of metal parts under laser ultrasound.

**Key words:** laser ultrasound; metal; defect detection; deep learning; numerical simulation

在现代工业化进程<sup>[1]</sup>中,许多金属机械零件设备因老化、人为破坏等因素导致的金属表面裂纹可能导致灾难性事故<sup>[2]</sup>。为此,基于物联网、通信、计算机等技术<sup>[3-5]</sup>检测和量化金属缺陷对于确保金属设备的安全性和可靠性至关重要。

目前,许多学者针对金属表面缺陷检测进行了研究,根据所用传感器的不同可分为基于光学与基于超声波两类。基于光学主要是利用可见光对金

属表面纹理进行分析,提取裂纹特征进行分类。如文献[6]提出了一种在 YOLOX 网络基础上引入双向特征融合网络的金属锅圆柱表面缺陷检测方法。该模型可实现高亮反射金属圆柱形锅的自动快速检测及分拣。文献[7]提出了一种改进 YOLOv5 的金属工件表面缺陷检测模型。该模型在原网络中增加通道注意力模块,提高目标的检测精度。然而光学方法检测条件苛刻,需要大量清晰

收稿日期:2023-03-07

作者简介:韩瀚(1988—),男,河南南阳人,本科,工程师,研究方向:机械设计与制造。

<sup>†</sup>通信联系人,E-mail: hanhan1988h@2980.com

的裂纹图像样本,且该方法无法适用于微小裂纹金属材料。基于激光超声波技术主要使用脉冲激光产生超声波,并采用与干涉仪耦合的宽带激光测量固体的表面位移,现已广泛用于检查各种金属结构材料表面缺陷。如文献[8]提出了一种基于集合经验模态分解和低秩稀疏分解相结合的金属表面缺陷检测方法。然而在大多数情况下,缺陷尺寸与超声信号之间的相关性不是线性的,并且通过实验获得这种相关性昂贵且耗时。此外,目前大部分研究主要基于数据分析对超声波回波进行处理,很少有研究利用深度学习强大的拟合能力提高超声波数据处理能力。

为改善上述问题,在研究数值模拟的金属表面缺陷基础理论上,利用数据模拟结果产生与实际实验相似的大量样本,从而提高数据样本多样性。同时,提出了一种基于深度学习的金属表面缺陷检测模型,从而提升样本分类精度。

## 1 样品和试验设置

试验中样品采用具有不同表面裂纹宽度的铝(Al)合金板。试验前使用放电加工和切割加工方法制造了宽度为 0、2、3 和 4 mm 的亚表面缺陷样品,每类样品仅包含一个手工裂缝。

试验过程中,使用波长为 1064 nm、脉冲持续时间为 12 ns、脉冲能量为 0~50 mJ 的 Nd:YAG 脉冲激光器(Centurion+),可产生频率为 2.2 MHz、带宽为 -6 dB 的瑞利超声波。接着,应用激光干涉仪(TEMPO)的自适应参考光束和光折变晶体中的两波混频,获取超声波的面外位移。通过操纵柱面镜和凸透镜,脉冲激光束将移动并聚焦在样品合金板表面。激光源在 X 方向上固定在距表面缺陷中心 +5 mm 处,检测器位于距缺陷中心 +5 mm 处,以检测透射的瑞利波。同时,采集的信号由采样频率为 250 MHz 的高分辨率数据采集卡(DAC)进行数字化处理,并由 NI PXI 设备触发传输到计算机,以生成超声时域信号。为了排除表面粗糙度的随机影响,试验样品的表面粗糙度保持在约 0.8  $\mu\text{m}$ 。在激光超声试验中,将试验样品固定在工作台上,并对数值模拟模型采用相同的边界条件。

## 2 模型建立

### 2.1 基于热弹性机制的激光超声生成

当脉冲激光照射在铝合金板表面时,部分能量

被吸收并产生瞬态温度场。不均匀的温度分布驱动热膨胀和热应力产生应力波。在热弹性力学<sup>[9]</sup>中,激光诱导的超声波可以描述为热传递公式和热弹性位移公式:

$$\rho C_v \frac{\partial T}{\partial t} - k \nabla^2 T = Q \quad (1)$$

$$\alpha(3\lambda + 2\mu) \nabla T + \mu \nabla^2 u + \rho \frac{\partial u^2}{\partial t^2} = (\lambda + 2\mu) \nabla(\nabla \cdot u) \quad (2)$$

式中:  $T$  为金属材料中的温度场;  $k$  为导热系数;  $C_v$  为热容量;  $\lambda$  和  $\mu$  为 Lamé 常数;  $u$  为随时间变化的位移矢量;  $\rho$  和  $\alpha$  分别为密度和热膨胀系数;  $Q$  为热源,可描述为:

$$Q = I_0(1 - R)f(x)g(t) \quad (3)$$

式中:  $I_0$  为入射激光的功率密度;  $R$  为材料表面的反射系数;  $g(t)$  和  $f(x)$  分别为激光脉冲的透射和空间分布。 $g(t)$  和  $f(x)$  分别计算如下:

$$f(x) = \exp\left(-\frac{x^2}{x_0^2}\right) \quad (4)$$

$$g(t) = \frac{t}{\tau} \exp\left(-\pi \frac{t}{\tau}\right) \quad (5)$$

式中:  $x_0$  为激光光斑半径;  $\tau$  为脉冲激光的上升时间。此外,温度场和位移场初始条件可以表示为:

$$\dot{T}(x, y, t) |_{t=0} = 0, T(x, y, t) |_{t=0} = 300K \quad (6)$$

$$\dot{u}(x, y, t) |_{t=0} = u(x, y, t) |_{t=0} = 0 \quad (7)$$

对于大多数金属材料,照射区域  $z = 0$  处的边界条件计算如下:

$$n[\sigma - (3\lambda + 2\mu)\alpha \nabla T \cdot I] = 0 \quad (8)$$

式中:  $n$  为材料表面的法向单位向量;  $\sigma$  为应力张量;  $I$  为单位张量。

### 2.2 数值模拟

考虑到实际试验次数有限,无法获取足够多的样本数据,本节基于商用有限元软件 Comsol Multiphysics 建立了数值模型以模拟铝合金板上激光超声波的产生和检测各种尺寸的人工裂纹,从而产生大量样本数据。

根据前述分析,热力学方程可以描述如下:

$$\mathbf{K}_T \dot{\mathbf{T}} + \mathbf{K} \mathbf{T} = \mathbf{P}_1 + \mathbf{P}_2 \quad (9)$$

式中:  $\mathbf{K}_T$  为电导率矩阵;  $\mathbf{T}$  为温度矢量;  $\mathbf{P}_1$  为热通量矢量;  $\mathbf{P}_2$  为热源矢量;  $\mathbf{K}$  为热容;  $\dot{\mathbf{T}}$  为温升率矢量。

对于脉冲激光器产生的瑞利超声波,为简化计算,假定传播过程中忽略阻尼,则有限元公式可以定义为:

$$KU + M\dot{U} = F_{ext}$$

(10)

式中:  $K$  和  $M$  分别为刚度矩阵和质量矩阵;  $U$  和  $\dot{U}$  分别为位移矢量和加速度矢量;  $F_{ext}$  为外力矢量, 可由以下公式计算:

$$F_{ext} = \int_V B^T E \epsilon_0 dV$$

(11)

式中:  $E$  为材料参数矩阵,  $\epsilon_0$  为热应变矢量;  $B^T$  为形状函数矩阵的转置矩阵。

模拟过程中, 矩形裂缝的建模高度和深度固定为 1 mm, 宽度在横轴方向为 0~6 mm 不等, 步长为 0.2 mm。激光源在横轴方向上固定在距次表面缺陷中心-5 mm 处, 探测器位于距缺陷中心+5 mm 处。与激光功率密度、上升时间、脉冲持续时间有关的所有参数设置与试验条件相同。表 1 为数值模拟时铝合金的材料参数配置。

表 1 数值模拟时铝合金的材料参数配置

| 参数                      | 值    |
|-------------------------|------|
| 密度/(kg/m <sup>3</sup> ) | 2780 |
| 杨氏模量/GPa                | 71   |
| 泊松比                     | 0.33 |
| 热膨胀系数/μK                | 23   |
| 导热系数/(k/m)              | 120  |
| 热容量/(JK/kg)             | 880  |
| 反射系数                    | 9    |

考虑到数值模拟值的收敛性实质上受到模型的时间和空间分辨率的影响, 同时模拟值的精度和计算时间取决于数值模拟的迭代时间步长。为此, 模拟时的时间步长  $\Delta t$  计算如下:

$$\Delta t = \frac{1}{20f_{max}}$$

(12)

式中:  $f_{max}$  为超声的最高频率。同时, 数值模拟时网格尺寸设置如下:

$$L_e = \frac{\lambda_{min}}{10}$$

(13)

式中:  $\lambda_{min}$  为激光产生的超声波的最短波长;  $L_e$  为网格的尺寸。

综上, 数值模型时间步长设置为 4 ns。为满足温度梯度的变化, 同时节省计算时间, 激光照射区域附近的网格尺寸设置为 2 μm, 而远离加热影响区域的元件的最大尺寸设置为 20 μm, 从而保证超声波的连续传播。在模型的两侧应用低反射边界条件以抑制超声波的反射。数值模拟时间设置为 10 μs, 从而保证有足够的时间检测传输波。在模型中, 提取检测位置处的节点位移以获取超声信

号, 因此不需要额外的传感器模型。为了预测不同缺陷的宽度, 模拟时生成了 31 个样例, 其中缺陷的宽度范围为 0~6 mm, 增量为 0.2 mm。

基于前述试验以及数值模拟可获取大量瑞利波超声波数据。接下来, 可对这些数据基于所提金属表面缺陷检测模型进行处理, 提取出关键特征, 以表示检测到的超声波信号与各种缺陷宽度之间的线性或非线性关系。

3 金属表面缺陷检测模型

考虑到瑞利波超声随机性强、噪声干扰严重, 提出了一种金属表面缺陷检测模型, 可实现对瑞利波超声波数据进行特征提取并分类金属表面缺陷宽度。

与只有一个隐含层的 RNN 相比, LSTM 考虑了隐藏在长期状态中的时间相关性。对于普通 RNN 单元, 隐藏状态的计算方法为:

$$h_t = \tanh(W_{ih}x_t + b_{ih} + W_{hh}h_{t-1} + b_{hh})$$

(14)

式中:  $h_t \in \mathbb{R}^h$  为时间  $t$  时的隐藏状态;  $x_t \in \mathbb{R}^d$  输入;  $W_{ih} \in R^{h \times d}$ ,  $W_{hh} \in R^{h \times d}$ ,  $b_{ih}, b_{hh} \in \mathbb{R}^h$  为可训练的参数;  $\tanh(\cdot)$  为激活函数。然而, 在时间  $t$ , LSTM 的输入包括当前网络的输入  $x_t$ , 上一时刻的状态  $h_{t-1}$ , 以及记忆单元上一时刻的状态  $c_{t-1}$ 。因此, LSTM 由遗忘门、输入门和输出门共同学习数据特征。目前, LSTM 单元有许多变体, 本研究采用的模型定义如下:

$$h_t = \tanh(W_{ih}x_t + b_{ih} + W_{hh}h_{t-1} + b_{hh})$$

(15)

$$i_t = \sigma(W_{ii}x_t + b_{ii} + W_{hi}h_{t-1} + b_{hi})$$

(16)

$$f_t = \sigma(W_{if}x_t + b_{if} + W_{hf}h_{t-1} + b_{hf})$$

(17)

$$g_t = \tanh(W_{ig}x_t + b_{ig} + W_{hg}h_{t-1} + b_{hg})$$

(18)

$$o_t = \sigma(W_{io}x_t + b_{io} + W_{ho}h_{t-1} + b_{ho})$$

(19)

$$c_t = f_c * c_{t-1} + i_t * g_t$$

(20)

$$h_t = o_t * \tanh(c_t)$$

(21)

式中:  $i_t$  为输入门;  $f_t$  为遗忘门;  $g_t$  为单元门;  $o_t$  为输出门;  $h_t \in \mathbb{R}^h$  为时间  $t$  时的隐藏状态;  $x_t \in \mathbb{R}^d$  输入;  $c_t \in \mathbb{R}^h$  为细胞态;  $W_{ii}$ 、 $W_{if}$ 、 $W_{ig}$ 、 $W_{io}$  为各门输入向量上的可训练权重;  $W_{hi}$ 、 $W_{hf}$ 、 $W_{hg}$ 、 $W_{ho}$  为各门隐藏状态的可训练权重;  $b$  为可训练的相应偏差;  $*$  为哈达玛积;  $\sigma(\cdot)$  为 sigmoid 激活函数。

图 1 为本研究提出的金属表面缺陷检测模型。考虑到瑞利波超声波数据为一维数据, 深度神经网络通常需要二维输入, 为此, 本研究将瑞利波超声波数据的 Mel 频谱图作为网络输入。Mel 频谱图

通常用于音频信号的时频表示。本文借鉴音频领域 Mel 频谱图概念,对超声波数据的 Mel 频率进

行采样,得到更紧凑的频谱表示,从而提高模型训练效果。




图 1 金属表面缺陷检测模型

如图 1 所示,模型的输入为超瑞利超声波数据的 2D 格式 Mel 谱图层,具有 128 个 Mel 波段,然后进行频率轴批量归一化处理。在归一化之后,有 3 个卷积块,每个卷积块的末尾都有 2D 卷积、批标准化、ELU 激活和 Max-pooling 操作。之后,将提取的特征共同输入 LSTM,充分结合上下文信息进行特征学习。同时,本研究使用注意力融合来提高模型对分类特征的敏感性,从而提高模型学习性能。因此,在 LSTM 后进行注意融合,后接 Drop-Out 和 SoftMax 完成金属表面缺陷检测分类过程。

分类过程中选择交叉熵函数作为损失函数。交叉熵函数可表征两个概率分布之间的距离,交叉熵越小,两个概率分布越接近。交叉熵公式如下:

$$L = - \sum_{i=1}^n y_i \log y'_i \tag{22}$$

式中:  $n$  为训练样本的大小;  $y_i$  和  $y'_i$  分别为实际值和预测值。损失值越接近于零,预测模型就越契合训练集。

4 实验与分析

本节应用所提金属表面缺陷检测模型对激光波与铝合金金属样本表面缺陷(裂缝宽度分别为 0、2、3 和 4 mm)的内在联系进行了实验研究。

4.1 数据集

为了获得可靠的评估结果,需要大量数据来训练金属表面缺陷检测模型。然而,从实际试验中获取训练数据极其昂贵且耗时。因此,本研究首先建立了一个数值模拟模型,以获得足够的数据来训练深度神经网络模型。接着,使用与试验相同的参数进行了数值模拟,并对模拟和试验数据进行了归一化比较。图 2 为数值模拟和试验数据归一化对比结果,其中  $L$  为通过测量的 6100 m/s 的速度识别的超声掠面纵波,  $R_t$  表示通过测量速度 3100 m/s 识别的透射瑞利超声波。

实验结果表明,与超声掠面纵波相比,瑞利超声波对金属裂缝的宽度更为强烈和敏感。因此,在

随后的研究中,选择瑞利超声波来训练深度神经网络模型。结果也表明,数值模拟和试验结果基本一致,波动较低。实验结果验证了模拟模型的有效性,因此可使用该模拟模型可代替实际试验以获得足够的训练数据。

最终,从数值模拟和实际试验中获得了总共 10839 个数据。模拟数据由裂缝宽度以 0.2 mm 为步长,0~6 mm 不等的的数据组成,且每个数据具有 5 种不同高斯随机噪声水平的污染数据。数据训练时,按 8 : 2 将数据集分为训练集和测试集。




图 2 数值模拟和试验数据归一化对比结果

4.2 训练环境与指标选取

试验过程中软件环境为 pycharm 搭建算法框架,并由 python 基于 tensorflow 搭建基础网络。同时,算法运行硬件环境为酷睿 i7 CPU,内存为 128 G ARM 的联想服务器,操作系统为 Ubuntu 18.04 64 位,显卡为 NVIDIA RTX2080Ti 11G。实验过程涉及的相关参数设置如下:最大迭代次数为 15000,优化器选取 Adam 优化器,批处理大小设置为 32,初始学习率设置为 0.05。

为了验证所提金属表面缺陷检测模型的有效性,在相同的仿真参数下分别对比了 CNN、长短时记忆(long short tterm memory, LSTM)在平均绝对误差(mean absolute error, MAE)、平均绝对百

分比误差 (mean absolute percentage error, MAPE)和均方根误差 (root mean squared error, RMSE)三个评估指标中的综合性能性能。其中, MAE 反映了实际值和预测值之间的差异,且对异常值非常敏感。MAPE 是衡量系统准确性的评估指标。RMSE 旨在根据平方误差和结果值的相对大小来描述模型拟合性能。三个误差度量分别根据以下式计算:

$$M_{AE} = \frac{1}{N} \sum_{t=1}^N |y_t - \hat{y}_t|$$

(23)

$$M_{APE} = \frac{1}{N} \sum_{t=1}^N \left| \frac{y_t - \hat{y}_t}{y_t} \right|$$

(24)

$$R_{MSE} = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - \hat{y}_t)^2}$$

(25)

式中:  $y_t$  为时间  $t$  时的实际值;  $\hat{y}_t$  为时间  $t$  时的预测值;  $N$  为样本数量。

4.3 性能与分析

4.3.1 训练性能对比

本节对比了主流 CNN、LSTM 和所提金属表面缺陷检测模型在训练集和测试集中的训练性能。不同模型训练曲线如图 3 所示。可以看出,所提金属表面缺陷检测模型训练性能优于 CNN 和 LSTM 模型。其中 CNN 和 LSTM 在训练数据集上的损失约为 18% 和 16%,但在测试数据集上 CNN 的损失最大,约为 22%。分析其原因,CNN 学习了许多训练数据集的特征,然而存在过拟合问题,导致了在测试数据集中性能下降严重。LSTM 模型较 CNN 模型有一定缓解,然而性能提升有限。与 CNN 和 LSTM 相反,所提金属表面缺陷检测模型在训练集产生的损失约为 7%,在测试集上的损失约为 10%,训练集和测试集之间的误差仅为 3%。试验结果表明,所提金属表面缺陷检测模型的多层特征提取器能够有效学习超声波特征,从而获得更优的训练性能。

4.3.2 综合性能分析

为了评估所提金属表面缺陷检测模型的有效性,本节分别对比了 CNN、LSTM 在 MAE、MAPE、RMSE 三个评估指标中的综合性能性能。不同模型综合性能如表 2 所示。可以看出,所提金属表面缺陷检测模型性能最优,MAE、MAPE、RMSE 分别为 189.67%、9.02%、238.62%。分析其原因,瑞利超声波数据特征复杂,传统 CNN 模型以及 LSTM 模型无法更深层次理解特征与特征之间的关系。所提基于深度学习的多相流量预测模型可以有效提升提取特征之间的关键信息。实验结果验证了所提基于深度学习的多相流量预测模型的可行性和有效性。




图 3 不同模型训练曲线

表 2 不同模型综合性能

| 模型   | MAE    | MAPE/% | RMSE   |
|------|--------|--------|--------|
| CNN  | 596.58 | 22.08  | 680.74 |
| LSTM | 286.43 | 18.42  | 349.45 |
| 所提模型 | 189.67 | 9.02   | 238.62 |

5 结 论

对金属表面缺陷检测方法进行了研究与分析,建立了一种基于激光超声波与深度学习的金属表面缺陷检测模型。该模型为激光超声波分析以及金属表面缺陷检测发展提供了一定借鉴作用。

参考文献

[1] 马定柱,张亚鑫. 智能化趋势下的城市交通规划发展构想[J]. 智能城市,2021,7(22):157—158.

[2] WANG Zhengdong, YANG Xiaoqing, Zhou Xin, et al. A flexible sensor tag for surface crack detection of curved film-coated metals[J]. IEEE Sensors Journal, 2022, 22(6): 5662—5668.

[3] 毛龙灿,杨南. 基于大数据背景下的皮革人才培养优化研究[J]. 中国皮革,2021,50(9):38—41.

[4] 杨涛. 互联网时代下皮革行业电商物流体系研究分析[J]. 中国皮革,2021,50(8):82—85.

[5] 钟建翔,余少锋,廖崇阳,等. 基于云计算的电力设备智能监测系统[J]. 云南师范大学学报(自然科学版),2022,42(3): 37—41.

[6] 乔健,陈能达,伍雄雄,等. 融合注意力机制的金属锅圆柱表面缺陷检测[J]. 光学精密工程,2023,31(3):404—416.

[7] 王一,龚肖杰,程佳,等. 基于改进 YOLOv5 的金属工件表面缺陷检测[J]. 包装工程,2022,43(15):54—60.

[8] 周航锐,孙坚,徐红伟,等. 基于 EEMD 和低秩稀疏分解的超声缺陷回波检测方法[J]. 计量学报,2022,43(1):77—84.

[9] SMAISIM G F, BIDGOLI M O, GOH K L, et al. Review of thermoelastic, thermal properties and creep analysis of functionally graded cylindrical shell[J]. Australian Journal of Mechanical Engineering, 2022: 1—12.