

# 基于优化 BP 神经网络激光超声表面缺陷识别

陈超, 张兴媛\*, 陆思烨

上海工程技术大学航空运输学院, 上海 201620

**摘要** 为了解决激光超声检测过程中定量识别表面缺陷深度较困难的问题,提出了一种粒子群(PSO)优化 BP 神经网络表面矩形缺陷深度定量识别方法。基于热弹机制,利用有限元软件 COMSOL 建立了利用激光超声检测含有表面缺陷铝材料的有限元模型,得到了脉冲激光照射下不同深度缺陷对应的透射波信号,提取透射波信号的时域峰值、中心频率、频域上 3 dB 带宽、上限截止频率和下限截止频率等多个变量作为神经网络的特征向量,建立了 PSO-BP 神经网络缺陷深度定量识别模型,实现了 0.1~3 mm 深度缺陷的定量识别。计算结果表明:经过粒子群算法优化后的 BP 神经网络能够准确地识别出金属表面缺陷的深度信息,识别相对误差在 6% 以内,结果证明了该神经网络模型对矩形缺陷深度的识别具有一定的可行性和准确性。

**关键词** 传感器; 激光超声; 有限元; 神经网络; 粒子群; 表面缺陷

中图分类号 O426

文献标志码 A

doi: 10.3788/LOP202158.2228008

## Laser Ultrasonic Surface Defect Recognition Based on Optimized BP Neural Network

Chen Chao, Zhang Xingyuan\*, Lu Siye

School of Air Transport, Shanghai University of Engineering Science, Shanghai 201620, China

**Abstract** Aiming to solve the problem of difficult quantitative identification of surface defect depth during laser ultrasonic detection, a particle swarm (PSO) optimized quantitative identification method for BP neural network surface rectangular defect depth is proposed. Based on the thermoelastic mechanism, a finite element model for laser ultrasonic detection of aluminium materials containing surface defects was established by using the finite element software COMSOL, the transmission wave signals corresponding to defects of different depths under pulsed laser irradiation were obtained, and then the time domain peak, centre frequency, 3 dB bandwidth in the frequency domain, upper cut-off frequency, and lower cut-off frequency of the transmission wave signals were extracted as the feature vectors of the neural network. A quantitative recognition model of PSO-BP neural network defect depth was developed to achieve the quantitative recognition of defects from 0.1 mm to 3 mm in depth. The calculation results show that the BP neural network optimized by the particle swarm algorithm can accurately identify the depth information of metal surface defects, and the relative error of identification is within 6%, which proves that the neural network model has certain feasibility and accuracy for the identification of rectangular defect depth.

**Key words** sensors; laser ultrasound; finite element; neural networks; particle swarm; surface defects

**OCIS codes** 280.3375; 200.4260

## 1 引言

激光超声无损检测技术与传统的检测技术相比

较,能够在高温、高压、腐蚀等恶劣环境下进行各类材料的检测工作,不需要耦合剂即可实现超声波信号的激发和接收,并且可以同时产生纵波、横波、瑞

收稿日期: 2021-01-08; 修回日期: 2021-01-27; 录用日期: 2021-02-04

基金项目: 国家自然科学基金(51465047)

通信作者: \*zhyy\_yuan@163.com

利波等多种模态的超声信号。激光激发的超声信号具有频带宽、精度高的特点,适用于对材料表面缺陷的检测<sup>[1-2]</sup>。近些年来,众多学者将激光超声检测技术与神经网络相结合,在材料表面缺陷的检测和识别工作上展开了广泛的研究。苟文韬<sup>[3]</sup>提取了弹壳各类缺陷的几何特征和形状特征等特征数据库,提出了基于 BP 神经网络的弹壳缺陷的分类方法,得到分类的误判率保持在 17% 以内。柯常波等<sup>[4]</sup>研究了基于端点回波反射法的 BP 神经网络模型,以探头  $K$  值与对应高度裂纹端点的反射波声程差为输入向量进行网络训练。结果证明,实际裂纹高度与神经网络预测值的绝对误差保持在 1 mm 左右。惠冰<sup>[5]</sup>在利用电磁换能器对材料表面缺陷进行检测的研究中,通过线性插值扩充样本数量,基于 BP 神经网络完成了缺陷的量化检测以及非金属涂层厚度的检测,得到的误差均在较小的范围内。刘松等<sup>[6]</sup>利用 MATLAB 设计和训练神经网络,以超声回波信号作为神经网络的输入,对底板中的三角形缺陷、凸起缺陷和矩形缺陷进行了识别检测,识别率为 93.33%。Kesharaju 等<sup>[7]</sup>建立了基于前馈神经网络和超声传感技术的在线质量检测系统,从接收到的超声信号中检测、定位和分类各种裂纹缺陷。Deng 等<sup>[8]</sup>利用基于核的主成分分析(KPCA)算法和极限学习机(ELM)的方法提取涡流信号中的缺陷参数,并对其进行自动识别和分类。徐风云<sup>[9]</sup>在针对识别钢材表面缺陷的研究中,提出了一种基于神经网络的缺陷识别方法,实验结果表明,此分类方法可有效识别钢材表面的缺陷类型,识别率达到 96% 以上。李浩然等<sup>[10]</sup>利用 ANSYS 软件对含有空洞缺陷的金属板进行红外锁相分析,利用粒子群(PSO)优化 BP 神经网络并对缺陷的面积和深度进行预测,平均误差保持在 5% 以下。He 等<sup>[11]</sup>将钢板表面波的反射和透射系数与二维有限元法模拟得到的参考曲线相比较,估算 0.2~3.0 mm 表层裂纹深度,相对误差为 5%~17%。周西峰等<sup>[12]</sup>通过检测获得的多组超声信号进行小波包分析,提取小波包频谱能量特征作为神经网络的特征向量,实现了对缺陷类型的快速准确识别。然而,目前将激光超声技术与 BP 神经网络相结合的研究较少,并且这些研究主要是针对裂纹或者缺陷的分类的研究,而在缺陷定量分析方面的研究较为缺乏。

本文针对激光超声检测金属表面缺陷深度的问题,将激光超声无损检测和 BP 神经网络结合,利用 COMSOL Multiphysics 软件建立激光超声热结构耦合二维模型,探究激光激发的超声在铝材料中与

不同深度表面缺陷相互作用的过程,并获得不同深度缺陷情况下对应的透射波信号,通过对信号在时域和频域上的分析,提取能够区分不同深度缺陷的特征向量构成神经网络的数据集。对于 BP 神经网络容易陷入局部极值的问题,进一步利用粒子群算法优化神经网络,可实现对深度为 0.1~3 mm 的表面缺陷的定量识别。计算结果表明该表面缺陷定量识别网络模型合理有效。

## 2 BP 神经网络与 PSO 算法

### 2.1 BP 神经网络

BP 神经网络的基本结构图如图 1 所示,一般由一个输入层、一个甚至多个隐含层以及一个输出层构成<sup>[13]</sup>,其中输入层通过外界输入提供信息,每一层的节点将上一层的输出作为次层的输入。神经元是 BP 神经网络的基本结构单元,分布在每一层中并且相互连接。当大量的神经元以一定的方式连接构成神经网络框架,则可以获得输入数据和输出数据的非线性映射。




图 1 BP 神经网络的基本结构图

Fig. 1 Basic structure diagram of BP neural network

BP 神经网络的学习主要包含两个过程:输入数据的正向传播过程和误差信息的反向传播过程。输入信号沿着输入层、隐含层、输出层的方向进行传播,在传播过程中,神经网络的阈值和权值均保持不变。当输出层的输出结果与训练目标相差较大时,输出层的神经元节点产生误差信号并逆向传播,从而修正神经网络的阈值与权值。两个过程交替进行,一直到误差满足其输出条件。BP 神经网络具体的学习过程如下。如图 1 所示, $n, j, p$  分别为输入层的神经元个数、隐含层的神经元个数和输出层的神经元个数, $x_n, y_j, z_p$  分别为 BP 神经网络的第  $i$  个神经元输入、隐含层第  $j$  个神经元的输出和输出层的第  $k$  个神经元的输出, $\omega_{ij}, \omega_{jk}$  分别为输入层到隐含层的权值和隐含层到输出层的权值, $\theta_j, \theta_k$  为隐含层第  $j$  个神经元阈值和输出层第  $k$  个神经元阈

值,  $f(\cdot)$  和  $g(\cdot)$  为隐含层和输出层的激励函数。

在信号的正向传播中, 隐含层第  $j$  个神经元的输出为

$$y_j = f\left(\sum_{i=1}^n \omega_{ij} x_i + \theta_j\right) = f(I_{\text{net},j}), \quad (1)$$

式中:  $I_{\text{net},j}$  为隐含层第  $j$  个神经元的输入。输出层第  $k$  个神经元的输出函数为

$$z_k = g\left(\sum_{j=1}^p \omega_{jk} y_j + \theta_k\right) = f(I_{\text{net},k}), \quad (2)$$

式中:  $I_{\text{net},k}$  为输出层第  $k$  个神经元的输入。用  $o_k$  表示输出层第  $k$  个神经元的期望误差, 则第  $k$  个神经元实际输出与期望输出的误差为

$$e_k = o_k - z_k. \quad (3)$$

网络输出的总误差为

$$E = \frac{1}{2} \sum_{k=1}^q (o_k - z_k)^2 = \frac{1}{2} \sum_{k=1}^q e_k^2, \quad (4)$$

如果输出的总误差不满足其结束条件, 通过误差反向传播优化神经网络的权值和阈值; 若满足结束条件, 则训练结束。

在误差信号的反向传播过程中, 利用梯度下降法调节神经元的权值、阈值, 使得输出层的误差满足要求。若  $d_j$  为隐含层第  $j$  个神经元的输出误差, 则

$$d_j = \sum_{k=1}^q e_k \times \theta_k \times f'\left(\sum_{i=1}^n \omega_{ij} x_i + \theta_j\right), \quad (5)$$

输出层的阈值调节为

$$\theta_k(k+1) = \theta_k(k) + \eta \times e_k, \quad (6)$$

式中:  $\eta$  为神经网络的学习率。

隐含层的阈值调节为

$$\theta_j(k+1) = \theta_j(k) + \eta \times d_j. \quad (7)$$

隐含层与输出层之间的连接权值调节为

$$\omega_{jk}(k+1) = \omega_{jk}(k) + \eta \times e_k \times y_j. \quad (8)$$

输入层与隐含层之间的连接权值调节为

$$\omega_{ij}(k+1) = \omega_{ij}(k) + \eta \times d_j \times x_i. \quad (9)$$

## 2.2 PSO 算法

PSO 算法是一种由鸟群觅食行为而引申出的群体优化算法, 主要是通过鸟群之间的相互合作、相互寻找指导优化搜索。在 PSO 算法中, 优化问题的解集被抽象成寻找空间中的粒子, 这些粒子具有各自的初始速度和位置, 粒子通过自身目前所找到的最优适应度值 ( $p_{\text{best}}$ ) 与整个种群目前的最优适应度值 ( $g_{\text{best}}$ ) 来调整自身的位置和速度。在寻找空间中不断迭代搜索, 最终找到全局的最优解。粒子的速度与位置的更新公式为

$$v_{i,d}^{k+1} = \omega \cdot v_{i,d}^k + c_1 \cdot r_1 \cdot (p_{\text{best},i,d}^k - x_{i,d}^k) + c_2 \cdot r_2 \cdot (g_{\text{best},i,d}^k - x_{i,d}^k), \quad (10)$$

$$x_{i,d}^{k+1} = x_{i,d}^k + v_{i,d}^{k+1}, \quad (11)$$

式中:  $\omega$  为惯性权重;  $v_{i,d}^k$  和  $x_{i,d}^k$  分别为粒子  $i$  在第  $k$  次迭代中第  $d$  维的速度和位置;  $c_1$  和  $c_2$  分别为个体学习因子和社会学习因子;  $r_1$  和  $r_2$  均为  $0 \sim 1$  之间的随机数;  $p_{\text{best},i,d}^k$  与  $g_{\text{best},i,d}^k$  分别为粒子  $i$  在第  $k$  次迭代中第  $d$  维的个体极值和全局极值。

## 2.3 PSO 优化 BP 神经网络

由于缺陷的定量识别是复杂的多输入网络模型, 具有高阶非线性特征<sup>[14]</sup>, 在 BP 神经网络中, 随机初始化权值与阈值通常会使得网络陷入局部极值点, 进一步影响其非线性拟合能力和网络的运行效率。针对此问题, 本文利用 PSO 算法优化 BP 神经网络的初始权值和阈值, 初始阈值和权值相当于粒子群算法中的粒子, BP 神经网络的测试误差作为适应度函数, 选择透射波信号的时域峰值、中心频率、频域上 3 dB 带宽、上限截止频率  $f_H$  和下限截止频率  $f_L$  为神经网络的输入, 表面缺陷深度为神经网络的输出, 建立 PSO-BP 神经网络缺陷深度定量识别模型。PSO-BP 神经网络缺陷深度定量识别模型的流程如图 2 所示。

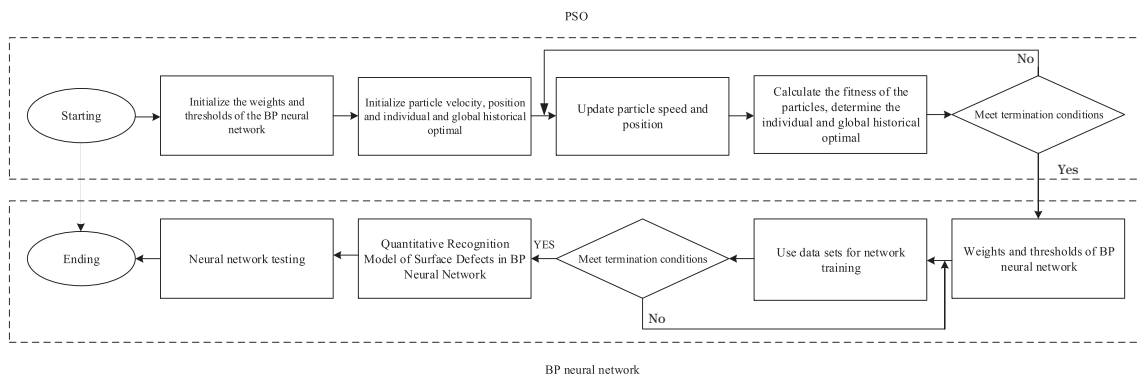


图 2 PSO-BP 神经网络缺陷深度定量识别模型流程图

Fig. 2 Flow chart of defect depth quantitative identification model based on PSO-BP neural network



### 3 数值计算研究

#### 3.1 有限元模型的建立

本文首先利用 COMSOL 有限元软件对激光超声与表面缺陷的相互作用进行数值计算,获得超声

信号,以为下文 BP 神经网络的训练提供数据基础。激光光源作用在模型表面时,由于入射激光轴对称分布的特点和材料具有各向同性、均匀线弹性的特点,可将三维问题简化为平面二维问题,简化的脉冲激光作用在无缺陷材料表面,示意图如图 3 所示。




图 3 激光辐照在试件上的简化模型图

Fig. 3 Simplified model diagram of laser irradiation on specimen

所建立的模型所选材料为铝,其各项热力学参数如表 1 所示。为减少模型边界回波的干扰,模型上表面设定为自由边界,左右两侧设定为低反射边界,下表面设定为固定边界。为了精确地获得激光超声在铝材料中的物理传播过程和超声波信号,网格单元尺寸不超过波长的 1/4<sup>[15]</sup>。在网格划分时,采用变网格技术<sup>[16-17]</sup>对激光源附近的区域网格进行细化处理,其他部分采用普通网格划分,如图 4 所示,这样可同时满足计算精度和计算效率要求。激光辐照在材料模型表面时,激光热源函数  $F$  可描述为

$$F = PA(T)f(x)g(t), \quad (12)$$

式中: $P$  为激光的能量功率密度; $A(T)$  为材料表面的激光吸收率; $f(x)$  和  $g(t)$  为激光关于空间和时间的分布函数,可分别表示<sup>[18]</sup>为

$$f(x) = \exp(-x^2/a_0^2), \quad (13)$$

$$g(t) = t/t_0 \exp(-t/t_0), \quad (14)$$

式中: $a_0$  为脉冲激光的光斑半径; $t_0$  为脉冲宽度。在计算过程中,材料的初始温度与位移满足

$$T(x, y, 0) = 300 \text{ K}, \quad (15)$$

$$U(x, y, 0) = \frac{\partial U(x, y, T)}{T} \Big|_{T=0} = 0. \quad (16)$$

表 1 模型中铝材料的热力学参数

Table 1 Thermodynamic parameters of aluminum material in model

Parameter	Unit	Value
Specific heat capacity	$\text{J} \cdot \text{kg}^{-1} \cdot \text{K}^{-1}$	900
Thermal conductivity	$\text{W} \cdot \text{m}^{-1} \cdot \text{K}^{-1}$	238
Thermal expansion coefficient	$\text{K}^{-1}$	$2.3 \times 10^{-5}$
Density	$\text{kg} \cdot \text{m}^{-3}$	2700
Young's modulus	Pa	$7 \times 10^{10}$
Poisson's ratio	—	0.33




图 4 有限元模型的网格划分

Fig. 4 Mesh division of finite element model

#### 3.2 数值计算结果与分析

通过 COMSOL 所建立的数值计算模型中,脉

冲激光的半径  $a_0$  为 0.3 mm,激光上升时间为 10 ns,激光峰值功率密度为  $100 \text{ W} \cdot \text{m}^{-2}$ 。图 5 为激

光激发的超声波在不含表面缺陷的铝材料中不同时刻超声场分布的模拟结果。从图中可知,在激光照射作用下,铝材料内部能够同时激发出纵波 L、横波 S、头波 H 以及表面波 R<sup>[19]</sup>,且纵波的传播速度

最快,横波的传播速度较慢,表面波传播最慢,但表面波的幅值明显高于纵波和横波的幅值,所以激光激发的声表面波更适用于材料的表面缺陷检测。

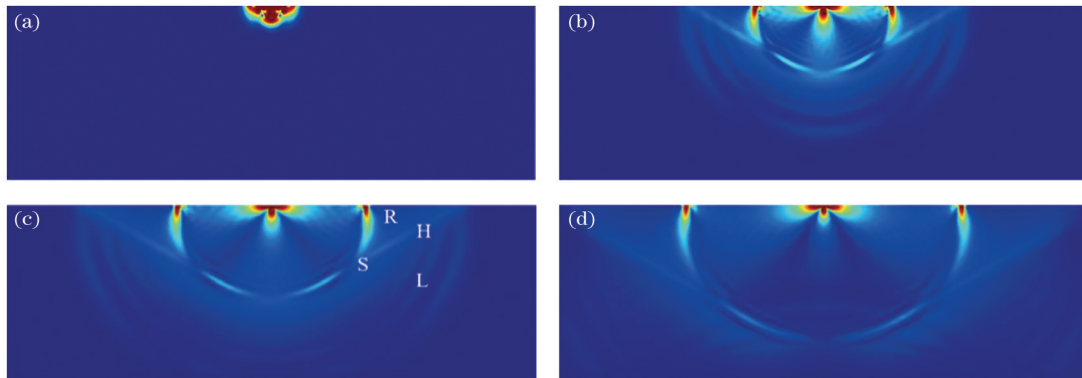


图 5 激光激发的超声波在不含表面缺陷的铝材料中不同时刻超声场分布的模拟结果。

(a)  $t=0.2 \mu\text{s}$ ; (b)  $t=0.8 \mu\text{s}$ ; (c)  $t=1.2 \mu\text{s}$ ; (d)  $t=1.8 \mu\text{s}$

Fig. 5 Simulation results of ultrasonic field distributions at different moments of ultrasonic waves excited by laser in aluminum material without surface defects at different moments. (a)  $t=0.2 \mu\text{s}$ ; (b)  $t=0.8 \mu\text{s}$ ; (c)  $t=1.2 \mu\text{s}$ ; (d)  $t=1.8 \mu\text{s}$

图 6 给出了激光激发的超声波在含有表面缺陷模型内部不同时刻超声场的模拟结果。所建立的铝块模型宽度和高度分别为 20 mm 和 7 mm,模型中的缺陷宽度和深度分别为 0.2 mm 和 1 mm。从图中可以看出,在激光激发的超声与缺陷相互作用后,一部分直达波会在缺陷左侧边沿发生反射产

生额外的反射回波 RW,还有一部分波沿着缺陷边缘越过缺陷,形成透射波 TW。通过仿真模拟发现,反射回波的波形复杂,难以对缺陷深度进行表征和区分,而透射波信号波形单一,差异明显,易于区分,所以本文针对透射波信号对缺陷深度的识别进行探究。

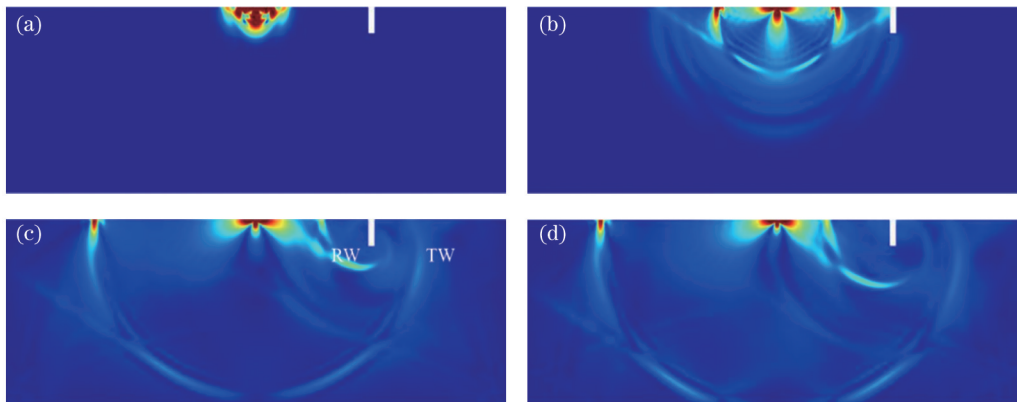


图 6 激光激发的超声波在含表面缺陷铝材料中不同时刻超声场分布的模拟结果。

(a)  $t=0.2 \mu\text{s}$ ; (b)  $t=0.8 \mu\text{s}$ ; (c)  $t=2.2 \mu\text{s}$ ; (d)  $t=2.5 \mu\text{s}$

Fig. 6 Simulation results of ultrasonic wave field distribution at different moments of ultrasonic wave excited by laser in aluminum material with surface defects. (a)  $t=0.2 \mu\text{s}$ ; (b)  $t=0.8 \mu\text{s}$ ; (c)  $t=2.2 \mu\text{s}$ ; (d)  $t=2.5 \mu\text{s}$

图 7 所示为几种不同缺陷深度(如深度分别为 0.1, 0.3, 0.5, 0.7 mm)下随时间变化的时域响应波形图。激光源位于距离缺陷左侧 4.5 mm 处,探测点位于距离缺陷左侧 1.5 mm 处。从图中可明显观察到,当缺陷深度很小(如深度为 0.1 mm)时,探测点接收到的超声信号与无缺陷时响应的超声信号变

化趋势相似。但随着缺陷深度的增加,透射波 TW 的幅值逐渐减小,波形也逐渐被展宽。

进一步考虑不同缺陷深度对频域中透射波信号的影响,对不同深度缺陷情况下响应的透射信号通过快速傅里叶变换(FFT)进行时频分析。图 8 所示为不同深度缺陷对应的超声波透射信号频谱图。从

图中可以看出:表面缺陷深度对透射波信号有很大影响,随着缺陷深度的增加,透射波的频谱成分逐渐向低频方向移动,高频部分减弱,中心频率逐渐减小,信号带宽也明显变窄。这是由于随着矩形缺陷深度逐渐增大,超声信号与缺陷相互作用后反射回

来的信号越多,同时越过缺陷的超声信号越少。当缺陷深度越来越大时,透射波的高频成分越来越少,而透射波的低频成分越来越多,缺陷深度对频谱中高频部分的衰减作用增强,频域中相应频谱的主频左移,符合低通滤波效应。




图 7 不同深度缺陷响应的透射时域信号。(a)深度为 0.1 mm;(b)深度为 0.3 mm;(c)深度为 0.5 mm;(d)深度为 0.7 mm  
Fig. 7 Transmission time domain signals of different depth defect response. (a) Depth is 0.1 mm; (b) depth is 0.3 mm; (c) depth is 0.5 mm; (d) depth is 0.7 mm

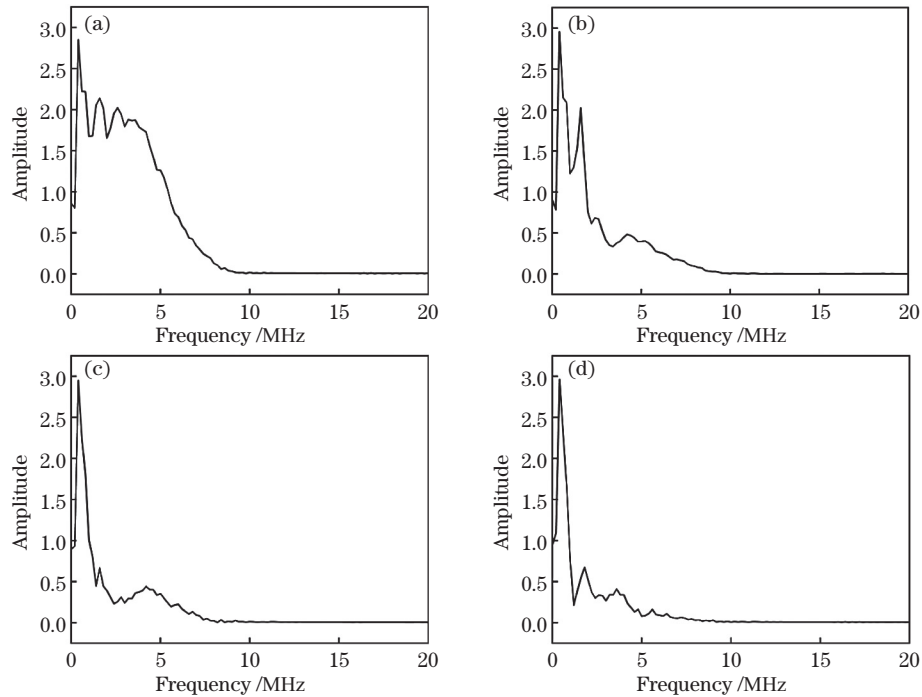


图 8 不同高度缺陷响应的透射频域信号。(a)深度为 0.1 mm;(b)深度为 0.3 mm;(c)深度为 0.5 mm;(d)深度为 0.7 mm  
Fig. 8 Transmission frequency domain signals of different height defect response. (a) Depth is 0.1 mm; (b) depth is 0.3 mm; (c) depth is 0.5 mm; (d) depth is 0.7 mm

针对以上分析可知,随着铝材料表面缺陷深度的增加,激光超声信号与缺陷相互作用后产生的透射信号的时域幅值逐渐减小,频谱信号的带宽也明显变窄,中心频率呈减小趋势。由此可知以上时域和频域上的信号特征皆可以作为表面缺陷深度定量识别的依据,它们彼此相互制约并呈现非线性映射关系。

## 4 PSO-BP 神经网络表面缺陷深度的定量识别

### 4.1 特征向量的选择与提取

通过上文所建的数值模型,以 0.1 mm 为增量,对 0.1~3 mm 表面缺陷深度进行了数值模拟,共采集了 90 组数据。通过对数据进行时频分析,总结了

表 2 不同缺陷深度情况下的特征向量(部分)

Table 2 Feature vectors for different defect depths (part)

Defect depth /mm	Time domain peak	Center frequency	3 dB bandwidth	$f_H$	$f_L$
0.1	-2.146560	2.21960	3.9740	0.2326	4.2066
0.2	-1.740667	1.64385	3.0609	0.2234	3.0643
0.3	-1.358564	0.66580	1.5584	0.2166	1.1150
0.4	-1.010040	0.84985	0.2665	0.2166	1.4831
0.5	-0.782374	0.48620	0.5574	0.2075	0.7649
0.6	-0.645267	0.46910	0.5574	0.1904	0.7478
0.7	-0.547497	0.45940	0.5825	0.2736	0.8561
0.8	-0.495937	0.44630	0.5506	0.1710	0.7216
0.9	-0.473476	0.43375	0.5461	0.1607	0.7068
1.0	-0.460262	0.40750	0.5450	0.1150	0.7000

### 4.2 PSO-BP 神经网络模型设计

从 90 组数据中选择 75 组作为训练样本,15 组数据作为检测样本进行计算测试。利用 MATLAB 编写程序,建立 PSO-BP 神经网络模型。输入层定义为 5 个节点,输出层定义为 1 个节点即表面缺陷的深度值;传递函数采用  $\text{transing}$ ,训练函数为  $\text{trainlm}$  函数,BP 学习函数为  $\text{learngdm}$ 。隐含层节点个数的确定参照以下经验公式: $l = \sqrt{n+m} + a$ ,其中  $l$  为隐含层节点数, $n$  为输入层节点数, $m$  为输出层节点数, $a$  为  $[1,10]$  之间的常数。通过多次试验选取隐含层节点数为 10,为保证网络误差趋于误差最小值,神经网络学习率设为 0.1,训练目标误差为  $10^{-9}$ 。设置粒子群算法参数:种群规模为 50,进化次数为 200,个体学习因子  $c_1$  和社会学习因子  $c_2$  均为 1.495,惯性权重  $\omega$  为 0.9。对样本数据经过归一化处理,分别利用 BP 神经网络模型和 PSO-BP

不同表面缺陷深度对超声透射信号在时域和频域上的影响,并选择透射波信号的时域峰值、中心频率、频域上 3 dB 带宽、上限截止频率  $f_H$  和下限截止频率  $f_L$  等 5 个变量作为神经网络的特征向量,构成缺陷深度识别模型的训练集和测试集。为了验证所选特征向量的合理性,利用 MATLAB 软件中  $\text{corrcoef}$  函数分别对各个输入向量与输出向量(缺陷深度)的相关性进行计算,计算得出:时域峰值、中心频率、频域上 3 dB 带宽、上限截止频率、下限截止频率与缺陷深度向量的相关系数分别为 0.89, -0.95, -0.87, -0.73, -0.94(负号表示负相关),其中缺陷深度与上限截止频率显著相关,与其他 4 个输入向量呈强相关。表 2 为一部分缺陷深度对应的信号特征向量。

神经网络模型进行训练和测试。

### 4.3 计算结果与误差分析

粒子群算法的适应度曲线如图 9(a) 所示。从图 9 中可知,初始的权值和阈值从 0 代进化到 25 代时,适应度值急剧下降,在进化 130 代之后,适应度曲线保持稳定状态,适应度值不再发生变化。神经网络模型的收敛曲线图如图 9(b) 所示,经过粒子群优化后的 BP 神经网络表面缺陷深度识别模型经过 25 次迭代之后便达到了目标误差,这体现了所建立模型的高效性。

BP 神经网络模型和 PSO 优化后的 BP 神经网络模型回归结果如图 10、11 所示。对比两图可以观察到,经过粒子群优化后的 BP 神经网络无论在训练集还是测试集上,回归效果更好,训练集、测试集和总体的  $R$  值分别为 0.99834、0.99256 和 0.99726,都接近于 1。



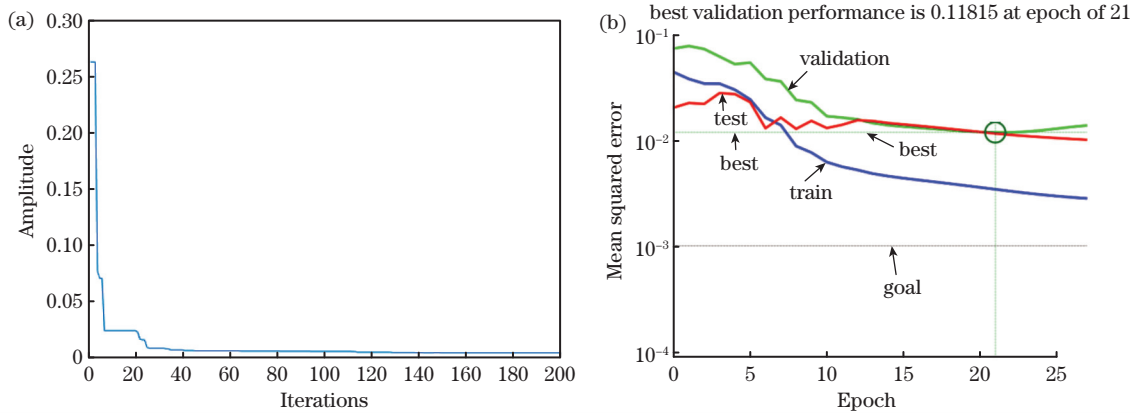


图 9 神经网络模型的适应度变化曲线及收敛图。(a)适应度曲线;(b)收敛曲线

Fig. 9 Fitness change curve and convergence curves of neural network model. (a) Fitness curve; (b) convergence curves

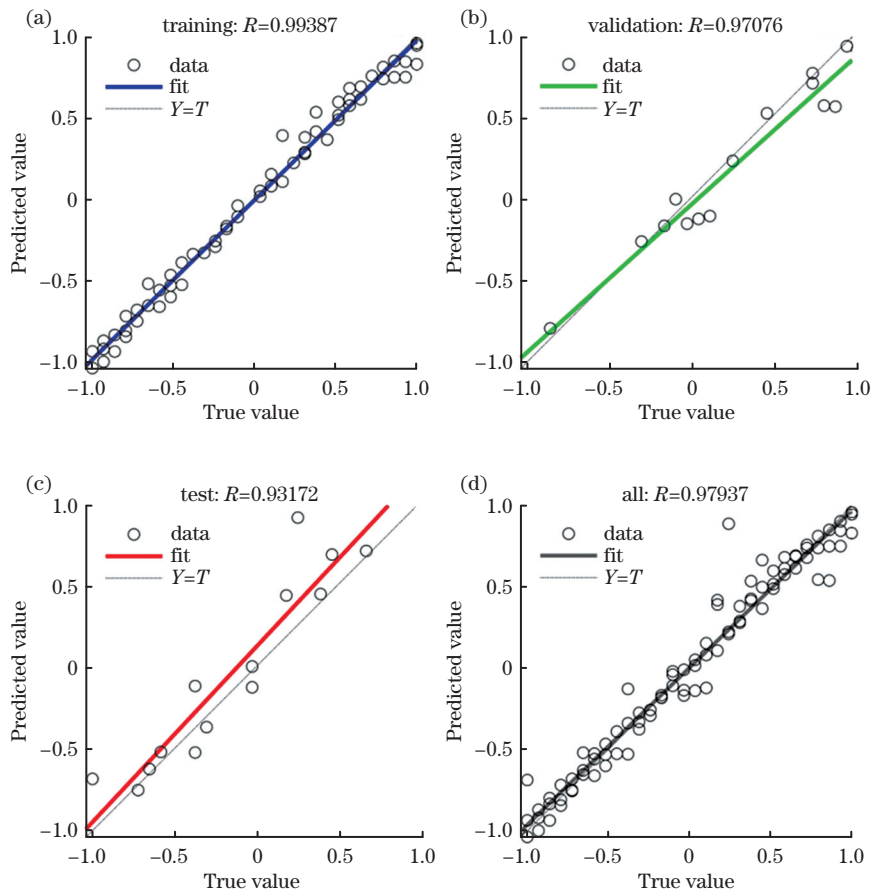


图 10 BP 神经网络模型回归结果  $R$ 。(a)训练集;(b)验证集;(c)测试集;(d)总体

Fig. 10 Regression results  $R$  of BP neural network model. (a) Training set; (b) validation set; (c) test set; (d) total

分别通过两种算法对样本数据中的 15 组数据进行测试,其中缺陷深度为 0.1, 0.3, 0.5, 0.7, 1.0 mm 测试结果与绝对误差如表 3 所示。可以看出,经过粒子群算法优化过的 BP 神经网络较未优化的神经网络测试效果更好,绝对误差维持在 0.05 mm 以下,而未优化的网络模型测试结果不太稳定,误差波动较剧烈。

由表 3 可知,优化前的神经网络对缺陷深度的识别性能不够稳定,缺陷的实际深度和预测深度在前两个样本中差距不大,相对误差较小,但是在其他三个样本中误差明显增大,最高超过 0.1 mm,精度降低。而经过粒子群优化后的 BP 神经网络泛化能力有所提高,性能得到了较大的提升,绝对误差最小可达 0.0029 mm。



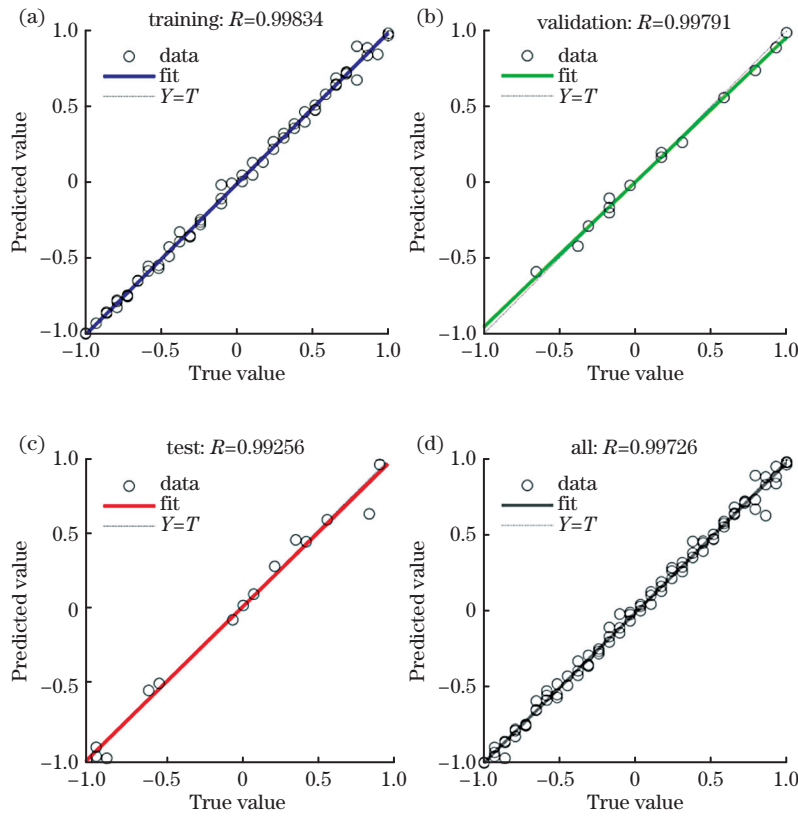


图 11 PSO-BP 神经网络模型回归结果 R。(a) 训练集；(b) 验证集；(c) 测试集；(d) 总体

Fig. 11 Regression results R of PSO-BP neural network model. (a) Training set; (b) validation set; (c) test set; (d) total

表 3 BP 神经网络模型和 PSO-BP 神经网络模型的测试结果

Table 3 Test results of BP neural network model and PSO-BP neural network model

Actual depth / mm	0.1	0.3	0.5	0.7	1
Predicted depth of BP neural network	0.1134	0.2516	0.5597	0.5915	0.9089
Absolute error	0.0134	-0.0484	0.0597	-0.1085	0.0911
Predicted depth of PSO-BP	0.0971	0.2901	0.4566	0.6620	0.9471
Absolute error	-0.0029	-0.0099	-0.0434	-0.0380	-0.0529

为了更直观地对比两种算法的识别效果,绘制了相对误差柱状图(图 12),从图中可以明显地看出经过粒子群优化后的神经网络测试效果优于原始的神经网络模型,PSO-BP 神经网络缺陷实际高度与预测高度吻合度较高,相对误差基本保持在 6% 以内。相较于 BP 神经网络,PSO-BP 神经网络对表面缺陷高度的识别相对误差更小,网络性能也更加稳定。这表明粒子群优化后的 BP 神经网络模型对

表面缺陷高度的识别精度较高,证明了此网络模型对缺陷定量识别的可行性。

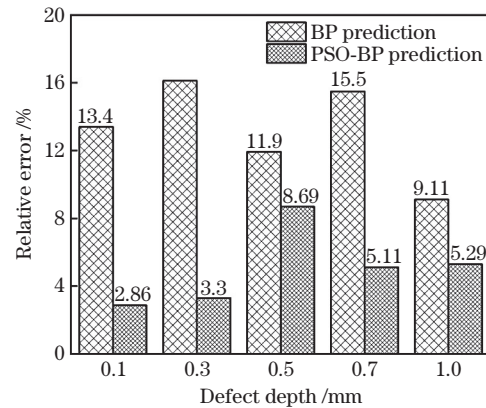


图 12 两种算法识别的相对误差比较

Fig. 12 Comparison of relative errors of two algorithms

为了探究网络模型对不同区间深度的测试效果,进一步通过粒子群算法优化后的 BP 神经网络对数据集中深度为 2.6~3.0 mm 的缺陷进行测试。如表 4 所示,缺陷深度较大时,测试结果相对误差较大,但依然保持在 10% 以下。经过分析,其主要原因是缺陷深度较大时,数据集中的特征向量之间区分度在没有较小缺陷的情况下较明显,从而导致相对误差有一定的增大。

表 4 不同缺陷深度区间的测试结果

Table 4 Test results for different defect depth intervals

Defect depth /mm	0.1	0.3	0.5	0.7	1.0
Relative error /%	2.86	3.30	8.69	5.11	5.29
Defect depth /mm	2.6	2.7	2.8	2.9	3.0
Relative error /%	10.00	7.67	4.68	7.95	9.60

为了验证本文提出的粒子群优化 BP 神经网络缺陷深度识别算法的优越性,在相同的实验数据环境中分别通过径向基(RBF)神经网络和支持向量机(SVM)两种定量识别算法对矩形深度进行了识别,并计算出不同识别方法的相对误差及平均误差,详细结果如表 5 所示。

表 5 不同算法的相对深度误差对比

Table 5 Comparison of relative depth errors of

Algorithm	different algorithms				/%
	BP neural network	PSO-BP	RBF	SVM	
Depth is 0.1 mm	13.40	2.86	11.60	8.32	
Depth is 0.3 mm	16.10	3.30	8.30	7.89	
Depth is 0.5 mm	11.90	8.69	10.50	9.55	
Depth is 0.7 mm	15.50	5.11	9.76	10.08	
Depth is 1.0 mm	9.11	5.29	11.70	10.63	
Average error	13.20	5.05	10.37	9.24	

分析表 5 可以得到:通过粒子群优化的 BP 神经网络对缺陷的识别平均误差为 5.05%,未优化的 BP 神经网络、径向基神经网络以及支持向量机对缺陷的识别平均误差分别为 13.20%、10.37% 和 9.24%,均大于粒子群优化的 BP 神经网络。计算结果表明:使用粒子群优化的 BP 神经网络对缺陷深度识别的误差较小,精度更高。

## 5 结 论

将激光超声无损检测方法和 BP 神经网络相结合,基于 BP 神经网络的非线性映射功能,构建了缺陷深度识别网络模型,实现了材料表面矩形缺陷深度的定量识别。

从激光激发超声的原理出发,基于 COMSOL 有限元软件建立激光超声热-固耦合模型,数值模拟了激光激发的声表面波与材料表面缺陷的相互作用过程,得到了不同高度缺陷情况下的透射波信号,并通过快速傅里叶变换对信号进行时频分析。结果表明:表面缺陷深度对透射波信号有着很大的影响,随

着缺陷深度的增加,透射波时域信号峰值逐渐减小,时域信号展宽,频域信号变窄,频谱成分向低频方向偏移,中心频率也随之减小。

选择透射波信号的时域峰值、中心频率、频域上的 3 dB 带宽、上限截止频率  $f_H$  和下限截止频率  $f_L$  作为特征向量构成神经网络模型训练和测试的数据集,通过 PSO 算法优化 BP 神经网络模型以对缺陷深度进行定量识别,并与传统的 BP 神经网络、径向基神经网络和支持向量机等算法的识别效果进行比较。计算结果表明:使用粒子群优化后的神经网络的识别精度更高,其平均误差均低于其他三类识别算法。结果证明了 PSO-BP 神经网络在激光超声检测材料表面矩形缺陷中的可行性和准确性。下一步工作将从搭建的激光超声检测实验平台中采集实验信号,验证并进一步改善神经网络缺陷深度定量识别模型。

## 参 考 文 献

- [1] Ma B Q, Zhou Z G. Progress and development trends of composite structure evaluation using noncontact nondestructive testing techniques in aviation and aerospace industries [J]. Acta Aeronautica et Astronautica Sinica, 2014, 35(7): 1787-1803.  
马保全, 周正干. 航空航天复合材料结构非接触无损检测技术的进展及发展趋势[J]. 航空学报, 2014, 35(7): 1787-1803.
- [2] Zhu Q, Qiu J H, Zhang C, et al. Application of laser ultrasonic detection method for double-layer laminated material [J]. Laser & Optoelectronics Progress, 2016, 53(3): 031402.  
朱倩, 裘进浩, 张超, 等. 双层层压材料中激光超声检测方法的应用[J]. 激光与光电子学进展, 2016, 53(3): 031402.
- [3] Gou W T. Cartridge case surface defect classification based on BP neural network [J]. Ordnance Industry Automation, 2015, 34(4): 90-91, 96.  
苟文韬. 基于 BP 神经网络的弹壳表面缺陷分类方法[J]. 兵工自动化, 2015, 34(4): 90-91, 96.
- [4] Ke C B, Chen T Q, Zhang X Y. Ultrasonic testing of height of surface breaking cracks base on BP neural networks [J]. Ordnance Material Science and Engineering, 2007, 30(1): 17-21.  
柯常波, 陈铁群, 张欣宇. 基于 BP 神经网络的超声无损测定表面开口裂纹高度[J]. 兵器材料科学与工程, 2007, 30(1): 17-21.
- [5] Hui B. Detecting and calibration of the surface defect with electromagnetic acoustic testing based on BP neural network [D]. Wuhan: Huazhong University of

- Science and Technology, 2017.
- 惠冰. 基于 BP 神经网络的电磁超声表面缺陷量化检测与校准[D]. 武汉: 华中科技大学, 2017.
- [6] Liu S, Gu J J, Wang Y, et al. Design of BP neural network defect recognition method based on ultrasound detection [J]. Pressure Vessel Technology, 2019, 36(8): 62-66, 49.
- 刘松, 顾继俊, 汪颖, 等. 基于超声波检测的 BP 神经网络缺陷识别方法设计 [J]. 压力容器, 2019, 36(8): 62-66, 49.
- [7] Kesharaju M, Nagarajah R, Zhang T, et al. Ultrasonic sensor based defect detection and characterisation of ceramics [J]. Ultrasonics, 2014, 54(1): 312-317.
- [8] Deng W Q, Ye B, Bao J, et al. Classification and quantitative evaluation of eddy current based on kernel-PCA and ELM for defects in metal component [J]. Metals, 2019, 9(2): 155.
- [9] Xu F Y. Rapid detection of steel surface defects based on neural network [J]. Science Mosaic, 2010(5): 116-118.
- 徐风云. 基于神经网络的钢材表面缺陷快速检测 [J]. 科技广场, 2010(5): 116-118.
- [10] Li H R, Lu J G. Identification of infrared phase-locked defects attribute based on PSO-BP neural network [J]. Modern Manufacturing Engineering, 2019(12): 117-123.
- 李浩然, 陆金桂. 基于 PSO-BP 神经网络的红外锁相缺陷属性识别 [J]. 现代制造工程, 2019(12): 117-123.
- [11] He C F, Deng P, Lu Y, et al. Estimation of surface crack depth using Rayleigh waves by electromagnetic acoustic transducers [J]. The International Journal of Acoustics and Vibration, 2017, 22(4): 541-548.
- [12] Zhou X F, Suo H Y, Guo Q G, et al. Faults identification based on wavelet packet and BP neural network for ultrasonic testing [J]. Journal of PLA University of Science and Technology (Natural Science Edition), 2012, 13(5): 521-526.
- 周西峰, 索会迎, 郭前岗, 等. 基于小波包-BP 网络的超声检测缺陷类型识别 [J]. 解放军理工大学学报 (自然科学版), 2012, 13(5): 521-526.
- [13] Zhou C, Tao J C. Adaptive combination forecasting model for China's logistics freight volume based on an improved PSO-BP neural network [J]. Kybernetes, 2015, 44(4): 646-666.
- [14] Li Q, Yu J Y, Mu B C, et al. BP neural network prediction of the mechanical properties of porous NiTi shape memory alloy prepared by thermal explosion reaction [J]. Materials Science and Engineering: A, 2006, 419(1/2): 214-217.
- [15] Jin L, Wang W, Pan Y D. Theoretical study of the interaction of laser excited surface acoustic waves with subsurface defects [J]. Chinese Journal of Solid Mechanics, 2017, 38(2): 170-179.
- 金磊, 王威, 潘永东. 激光激发表面波与亚表面缺陷作用的理论研究 [J]. 固体力学学报, 2017, 38(2): 170-179.
- [16] Tao C, Yin A M, Ying Z Q, et al. Quantitative analysis of surface-breaking defects by surface acoustic waves under different temperatures [J]. Laser & Optoelectronics Progress, 2018, 55(12): 121409.
- 陶程, 殷安民, 应志奇, 等. 不同温度下表面微缺陷的声表面波定量分析 [J]. 激光与光电子学进展, 2018, 55(12): 121409.
- [17] Sui H, Gao X R, Luo L, et al. Finite element simulation and experiment on interaction of surface waves excited by laser point or line source with rail defects [J]. Laser & Optoelectronics Progress, 2019, 56(8): 081201.
- 隋皓, 高晓蓉, 罗林, 等. 激光点源与线源激发表面波与钢轨缺陷作用的有限元仿真和实验 [J]. 激光与光电子学进展, 2019, 56(8): 081201.
- [18] Wang J J, Shen Z H, Xu B Q, et al. Numerical simulation of laser-generated ultrasound in non-metallic material by the finite element method [J]. Optics & Laser Technology, 2007, 39(4): 806-813.
- [19] Yang L J, Li Y, Sun J J, et al. Reflection and transmission of laser ultrasonic waves on surface defects [J]. Laser & Optoelectronics Progress, 2019, 56(4): 041203.
- 杨连杰, 李阳, 孙俊杰, 等. 激光超声表面波在表面缺陷上的反射与透射 [J]. 激光与光电子学进展, 2019, 56(4): 041203.