

DOI: 10.19650/j.cnki.cjsi.J1904987

基于BP神经网络的超声表面波定量表征 金属表层裂纹深度研究*

董珍一, 林莉, 孙旭, 马志远

(大连理工大学 无损检测研究所 大连 116085)

摘要:针对超声参量-目标特征经验拟合方法预测金属表层裂纹深度准确性不高的问题,提出一种基于差异性与最小集合原则优选特征并训练BP神经网络的金属表层裂纹深度的声表面波(SAW)定量表征技术。该技术运用有限元法模拟激光激发SAW过程,提取裂纹引起的反射与透射SAW峰值、平均值等多个特征训练BP神经网络用以预测裂纹深度,实现不锈钢表层深度0.1~2.0 mm的20组开口裂纹定量表征。模拟结果表明:裂纹深度预测结果相对误差在3%以内,与经验拟合曲线预测结果相比,准确率提高60%以上。实验采用5 MHz表面波探头采集不锈钢试样表层深度1.0与1.5 mm预加工裂纹各20个反射波信号,通过BP神经网络预测的裂纹深度相对误差在0.1%以内,验证了定量表征技术的可行性与准确性。

关键词:声表面波;表层裂纹;BP神经网络

中图分类号: TB553 TP183 **文献标识码:** A **国家标准学科分类代码:** 520.20

Study on the quantitative characterization of metal surface crack depth through BP neural network combined with SAW technique

Dong Zhenyi, Lin Li, Sun Xu, Ma Zhiyuan

(NDT & E Laboratory, Dalian University of Technology, Dalian 116085, China)

Abstract: Aiming at the low accuracy of crack depth prediction in metal surface utilizing the empirical fitting method based on specific ultrasonic signal parameter and object characteristic, based on the divergence analysis and least parameter set principle, as well as training BP neural network, a surface acoustic wave (SAW) quantitative characterization technique of metal surface crack depth is proposed. This technique simulates the laser exciting SAW process with finite element method and extracts the characteristics of peak and mean values of the reflected and transmitted SAW signals caused by the surface crack, which is used to train BP neural network and predict the crack depth. The quantitative characterization of 20 groups of the opening cracks with crack depth of 0.1~2.0 mm on stainless steel specimen surface was realized. The simulation results show that the relative errors of the predicted crack depth are within 3%. Compared with the prediction result of empirical fitting curve, the accuracy is improved by more than 60%. Experiments adopted a 5 MHz SAW transducer to acquire 20 reflected SAW signals of two preprocessed cracks of the stainless steel specimens at surface depth of 1.0 and 1.5 mm, respectively. The relative errors of the crack depth predicted by BP neural network are within 0.1%, which verifies the feasibility and accuracy of the proposed quantitative characterization technique.

Keywords: surface acoustic wave; surface crack; BP neural network

0 引言

在工程金属材料中,表层开口裂纹是一种典型的危

害性缺陷,易诱发疲劳扩展形成贯穿裂纹^[1-2]。在壁厚方向上的裂纹深度是断裂力学分析与结构寿命预测最关心的参数。因此,本文提出一种有效的表层裂纹深度定量无损表征技术,对确保航空航天、核电和化工行业等核心

收稿日期:2019-04-16 Received Date:2019-04-16

* 基金项目:国家自然科学基金(51675083, 51805072)、中国博士后科学基金(2018M641689)资助项目

部件的表面完整性及工件服役安全至关重要。

超声表面波具有衰减小、传播距离远等优点,常用于检测金属表层裂纹缺陷,许多学者通过分析声波信号单个特征的经验拟合来识别一定范围内的表层裂纹深度。如 He 等^[3]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%。Longo 等^[4]利用表面波透过裂纹的低通频率阈值与裂纹深度存在的反比例关系对钢梁表层 0.2~0.4 mm 的裂纹深度进行表征。当裂纹深度小于 0.3 mm 时,相对误差为 7.5%~20%。此类研究缺乏对多个特征的综合分析,检测准确性低。另外,当裂纹尺寸参数改变时,需重新确定参考曲线,耗时且工作量大。近年来,有关神经网络的研究进展为上述问题提供了新的解决途径。神经网络通过对多个输入样本的学习,模拟输入与输出间隐含的非线性关系,在模式识别、预测、工业检测等领域体现出明显优势,逐渐应用到超声波预测金属裂纹尺寸方面。Zgonc 等^[5]利用神经网络预测铝薄板铆钉孔 0.5~3.0 mm 裂纹长度。采用有限元法,通过两个超声探头激发和采集裂纹前后散射场 4 个电压信号,结合探头响应函数及传递函数等计算 15 个连续位置反射波与透射波信号相似频率分量的比值进行训练,实验相对误差最大为 7.25%。该研究的检测系统和信号的处理过程较为复杂,在实际应用中存在局限性。Li 等^[6]利用粒子群优选神经网络预测 Al 板表层 0.2~2.0 mm 裂纹深度。采用高斯过程回归分析方法从原始特征集中筛选优选,并通过小波变换提取反射波与透射波的时域及时频域特征进行训练。该研究对于特征的计算、提取和优选需借助复杂处理技术,其结果相对误差在 9% 以内。

本文针对超声无损表征金属表层开口裂纹深度的问题,将超声表面波检测技术与 BP 神经网络相结合,提出差异性与最小集合特征优选原则,仅需利用表层裂纹反射波或透射波的时域信号,提取优选特征训练神经网络,即可实现 0.2~2 mm 不锈钢表层裂纹深度的定量表征。该方法预测相对误差在 3% 以内,且提取特征方法更为简便。模拟结果与实验结果较好的一致性证明了该方法的有效性。

2 基于 BP 神经网络检测表层裂纹深度原理

2.1 表面波的传播与激励

表面波在 $z=0$ 的自由表面内满足边界条件的位移 μ 可用如下方程表示^[7]:

$$u = A(\text{re}^{-qz} - 2sqe^{-qz})e^{ik(x-ct)} \quad (1)$$

式中: c 为表面波声速; r, q, s 分别为与 c 、纵波声速 c_L 、横波声速 c_T 有关的常数; k 为表面波波数。可以看出表面

波幅值随渗入深度 z 的增加以 e 指数形式衰减,其能量主要集中在表面约一个波长深度范围内^[8-9]。因此,在采用表面波幅值特征预测裂纹深度时,常用 e 指数曲线进行经验拟合。

2.2 BP 神经网络预测技术

BP 神经网络是应用最为广泛的神经网络之一,其网络模型如图 1 所示。BP 神经网络具有结构简单、可操作性强、能模拟任意非线性输入-输出关系等优点^[10-11],且并行分布的信息处理方式使其具有强大的联想记忆能力,能够通过预存储信息和学习机制进行自适应训练,从不完整的信息和噪声干扰中恢复完整的原始信息,适用于实际操作中的预测与非线性映射。




图1 典型3层BP神经网络模型

Fig.1 Typical three-layer BP neural network model

BP 神经网络包含一层输入层、多层隐含层和一层输出层^[12]。它是一种前馈神经网络,即在神经网络中包含反馈回路,其中每个神经元将自身输出信号向前反馈给输入信号,通过调整输入信号的权重系数 w ,使输出信号逐渐接近理论输出值^[13-15]。

假设有 P 个训练样本,即有 P 个输入-输出对 $(\mathbf{x}_p, \mathbf{t}_p)$, $p=1, \dots, P$, 其中输入向量为:

$$\mathbf{x}_p = (i_{p1}, \dots, i_{pm})^T \quad (2)$$

神经网络实际输出向量为:

$$\mathbf{t}_p = (t_{p1}, \dots, t_{pn})^T \quad (3)$$

神经网络理论输出向量为:

$$\mathbf{o}_p = (o_{p1}, \dots, o_{pn})^T \quad (4)$$

记 w_{ij} 为从输入向量的第 $j(j=1, \dots, m)$ 个分量到输出向量的第 $i(i=1, \dots, n)$ 个分量的权重。BP 神经网络的学习过程即不断比较理论值与实际值,通过修改参数 w_{ij} ,使误差平方和最小;每次训练都会将权重所需修改量 Δw_{ij} 反馈给现有权重 w_{ij} ,使其不断更新以缩小误差。式(6)中 η 为学习速率,表示每次更新权重程度大小。

$$\min \sum_{i=1}^n (t_{pi} - o_{pi})^2 (p=1, \dots, P) \quad (5)$$

$$\Delta w_{ij} = \sum_{p=1}^P \eta (t_{pi} - o_{pi}) i_{pj} = \sum_{p=1}^P \eta \delta_{pi} i_{pj} \quad (6)$$

设有一 f 层(输入层不计入层数)的 BP 神经网络,输出层为第 f 层,则训练中其权重迭代公式为:

$$w_f^{(p)}(i,j) = w_f^{(p-1)}(i,j) + \eta \delta_i^{(p)} a_{f-1}^{(p)}(j), \quad f = 1, \dots, F \quad (7)$$

式中: $w_f^{(p)}(i,j)$ 表示第 $f-1$ 层第 j 个神经元对第 f 层第 i 个神经元第 p 次迭代时的权重。利用此式进行反向修正,直到误差达到精度要求,得到最终神经网络模型。

2.3 输入向量特征的提取与优选

BP 神经网络算法的核心问题之一是提取合理特征作为输入向量^[16-17]。随着裂纹深度变化,所提取的超声信号特征变化应具有一定规律。特征数量太少,算法所需信息不足,预测准确率低;而特征数量过多可能出现冗余数据,加重算法的训练负荷,导致最终结果过度拟合^[18]。本研究对超声信号提取 10 个特征:峰值、平均值、均方根、方差、偏度、峰度、波峰因数、形状因子、脉冲因子和边缘因子,分别用 P_1-P_{10} 表示,如表 1 所示。

表 1 特征参数

Table 1 Characteristic parameters

P_1-P_5	P_6-P_{10}
$P_1 = x(n)_{\max} $	$P_6 = \frac{1}{N} \sum_{n=1}^N \left(\frac{x(n) - \bar{x}}{\sigma^4} \right)^4$
$P_2 = \frac{1}{N} \sum_{n=1}^N x(n) $	$P_7 = \frac{ x(n) _{\max}}{T_3}$
$P_3 = \sqrt{\frac{1}{N} \sum_{n=1}^N x(n)^2}$	$P_8 = \frac{T_3}{\frac{1}{N} \sum_{n=1}^N x(n) }$
$P_4 = \frac{1}{N-1} \sum_{n=1}^N (x(n) - \bar{x})^2$	$P_9 = \frac{ x(n) _{\max}}{\frac{1}{N} \sum_{n=1}^N x(n) }$
$P_5 = \frac{1}{N} \sum_{n=1}^N \frac{(x(n) - \bar{x})^3}{\sigma^3}$	$P_{10} = \frac{ x(n)_{\max} - x(n)_{\min} }{T_3}$

将提取的特征用于 BP 神经网络训练时,应选择与目标量(即裂纹深度)相关的最敏感特征,丢弃不敏感或冗余特征以提高表征准确性,即特征优选^[19-20]。特征优选原则为:1)对于相同的裂纹深度,特征之间的差值必须较小,对于不同的裂纹深度差值必须较大;2)所选特征数量必须是能够充分区分不同裂纹深度的最小集合。

3 数值模拟

3.1 参数设置与模型建立

一种常用的激发表面波的方法是用激光照射固体表面使其受热膨胀,产生位移场引起表面应力,进而激发表

面波,有限元法能够精确模拟这一过程。Li 等^[6]利用模拟扫描激光源在铝块表面激发表面波用以表征表层裂纹深度;Guan 等^[21]建立脉冲激光源有限元分析模型,在铝板中模拟了激光产生频率为 4~15 MHz 表面波的过程,与实验结果吻合较好。本文使用 COMSOL5.2 有限元软件建立固体力学与热力学耦合物理模型,通过激光超声技术模拟表层不同裂纹深度不锈钢中的表面波传播过程。表 2 所示为用于模拟的不锈钢材料特性。

表 2 不锈钢的材料特性

Table 2 Material properties of stainless steel

性能	参数值
热膨胀系数 $\alpha/(K^{-1})$	12.3×10^{-6}
恒定压力下的热容 $C_p/(J \cdot kg^{-1} \cdot K^{-1})$	475
导热系数 $A/(W \cdot m^{-1} \cdot K^{-1})$	44.5
密度 $\rho/(kg \cdot m^{-3})$	7 850
杨氏模量 E/Pa	205×10^9
泊松比 $\sigma/(a.u.)$	0.28

如图 2 所示范区,将表层裂纹设置为矩形凹槽,其深度 h 在位置 $x = 2.0 \text{ mm}$, $z = 0.1 \sim 2.0 \text{ mm}$ 范围内以 0.1 mm 等间隔增大,裂纹宽度为 0.1 mm。激光激励源位于模型表面 $x = -1.5 \text{ mm}$ 处,其能量为 10^6 W ,中心频率为 10 MHz。设置 2 个超声波接收探头 Tr、Tt,固定在距离裂纹-2.0 mm 和 2.0 mm 处,分别用于接收裂纹反射与透射的表面波。




图 2 带有表层裂纹的不锈钢表面波激励与接收

Fig.2 Exciting and receiving SAW signals on a stainless steel specimen with surface crack

图 3 所示为激光源激发的表面波遇到裂纹发生反射和透射随时间 t 的变化过程。当表面波远离裂纹时,Tr 探头只能检测到直达表面波。当表面波继续传播遇到不同深度裂纹时,Tr 与 Tt 探头分别接收到裂纹反射与透射的表面波,其中包含能够表征裂纹深度的信息。

3.2 表面波峰值经验拟合结果与分析

图 4 所示为表面波遇到裂纹后的反射波(a)及透射波(b)时域信号。由图 4 可见,随裂纹深度 h 的增加,反射波峰值 P_1 增加,而透射波的 P_1 降低,两者变化速度随




图 3 表面波传播过程
Fig.3 SAW propagation process






图 4 表面波与不同深度裂纹相互作用的时域信号
Fig.4 The time-domain signals generated by the interaction of SAW with the cracks at different depths

裂纹深度增加逐渐降低,此结果与理论分析中表面波幅值随渗入深度 z 的增加以 e 指数形式衰减一致。

分别选用图 4 中反射波与透射波的峰值特征 P_1 与裂纹深度 h 作 e 指数经验拟合。由于表面波渗入深度为一个波长左右,当 h 大于一个波长时,表面波无法到达裂纹深处。经计算表面波波长约为 1.2 mm,故选取 h 在约一个波长范围(0.1~1.2 mm)内的 P_1 进行拟合,如图 5 所示。



(a) 表面反射波峰值与裂纹深度拟合曲线
(a) The fitting curve of the peak of the reflected SAW signal vs. crack depth




(b) 表面透射波峰值与裂纹深度拟合曲线
(b) The fitting curve of the peak of the transmitted SAW signal vs. crack depth


图 5 表面波峰值特征与裂纹深度的指数拟合曲线
Fig.5 Exponential fitting curves of the peak SAW signal vs. crack depth

将全部深度裂纹的反射波与透射波峰值特征 P_1 代入对应的拟合公式中,求得预测裂纹深度 h_p 与实际裂纹深度 h 的相对误差如图 6 所示。由图 6 可知,采用反射波特征 P_1 预测的裂纹深度在 $0.6 < h < 1.2$ mm 范围内相对误差小于 10%,当 $h < 0.6$ mm 时,由于裂纹反射的表面波能量较低,易被其它衍射波干扰,相对误差最大达到 112%,见图 6 (a);采用透射波特征 P_1 预测的裂纹深度在 $h < 0.8$ mm 范围内相对误差小于 15%,裂纹深度 h 越小,表面波越容易透过裂纹,表征误差越小,见图 6(b)。由于表面波渗入深度有限,当 $h > 1.2$ mm 时, h 的增大对其反射与透射影响均

不大,因此误差随 h 增大而增大,最大相对误差可达-50%。总体相对误差在 10% 以内的占 37.5%。



(a) 反射波峰值预测裂纹深度的相对误差
(a) Relative error of the crack depth predicted with the peak value of reflected SAW signal




(b) 透射波峰值预测裂纹深度的相对误差
(b) Relative error of the crack depth predicted with the peak value of transmitted SAW signal

图 6 指数拟合法预测裂纹深度的相对误差
Fig.6 Relative error of the crack depth predicted with exponential fitting method


3.3 BP 神经网络优选特征定量表征结果与讨论

对每个信号分别添加 5 个在信号幅值 0.2%~1.0% 范围内等间隔增大的噪声信号,用以模拟检测过程电噪声的干扰,丰富神经网络训练信息量,而后分别提取 $P_1 \sim P_{10}$ 特征。反射波平均值特征 P_2 随裂纹深度 h 的变化如图 7 所示,图 7(b) 为 7(a) 的局部放大图。由图 7 可知,不同裂纹深度 h 所对应的 P_2 差值大于 0.3 mm 的占 50% 以上;而当 h 一定时,添加不同级别噪声信号后的 P_2 差值小于 0.03 mm。表明 P_2 特征值对于不同裂纹深度差别较大,对于相同裂纹深度差别较小,能够有效区分裂纹深度,可以作为训练特征之一。同时,反射波形状因子特征 P_8 随裂纹深度 h 的变化见图 7(c),当 $h=0.6$ mm 时,添加不同级别噪声信号后的 P_8 值在 30~140 间分布,无法与对应裂纹深度建立映射关系;当 h 在 1.0~2.0 mm 之间时, P_8 值基本相同,不能有效区分裂纹深度。因此


判断形状因子 P_8 在预测裂纹深度上为无效特征,予以剔除。



(a) 反射波平均值 P_2 随裂纹深度变化曲线
(a) The changing curve of the reflected SAW mean value P_2 vs. crack depth



(b) 图 (a) 的局部放大图
(b) Partial enlargement of figure (a)



(c) 反射波形状因子 P_8 随裂纹深度变化曲线
(c) The changing curve of the reflected SAW shape factor P_8 vs. crack depth

图 7 反射波特征随裂纹深度变化曲线
Fig.7 The changing curves of the reflected SAW characteristics vs. crack depth

按上述特征优选原则,对于反射波信号,剔除特征 P_6 、 P_8 、 P_9 ;对于透射波信号,剔除特征 P_5 、 P_7 。将余下优选特征按照裂纹深度分为两组:1) 0.1, 0.3, ..., 1.9 mm; 2) 0.2, 0.4, ..., 2.0 mm。1) 组反射波及透射波特征用于

分别训练 BP 神经网络,而 2) 组特征用于神经网络预测裂纹深度的输入。结果如图 8(a) 与(b) 所示,预测裂纹深度 h_p 与实际裂纹深度 h 的相对误差如图 9 所示。反射波与透射波两种信号的优选特征预测的裂纹深度绝对误差均小于 0.02 mm,相对误差不超过 3%。与经验拟合预测裂纹深度结果相比,准确率提高 60% 以上。




图 8 BP 神经网络利用表面波优选特征预测的裂纹深度
Fig.8 The crack depth predicted by optimized SAW characteristics based on BP neural network







图 9 BP 神经网络预测裂纹深度的相对误差
Fig.9 The relative error of the crack depth predicted with BP neural network

Li 等^[6] 预测表层裂纹深度的研究,需通过高斯过程回归分析筛选特征,并借助小波分析技术提取时频域特征。本研究仅提取反射波时域信号的 7 个特征或透射波时域信号的 8 个特征进行训练,即可准确地预测表层裂纹深度,相对误差均不超过 3%。

4 超声检测实验

采用型号为 5Z6×6BMW 的表面波探头、Model 5800 脉冲式收发探伤仪和 DPO 4032 示波器对不锈钢表层深度 1.0 与 1.5 mm、宽度 0.1 mm 的开口裂纹进行实验。将表面波探头置于试样表面,保持探头与裂纹间距离 2 cm,以 2 mm 为间隔平稳横向移动探头,分别对 1.0 和 1.5 mm 深度裂纹各采集 20 个反射波信号,共 2 组。每组选取 10 个信号,提取与模拟部分相同的 7 个反射波信号优选特征,采用 BP 神经网络进行训练。利用训练后的神经网络测试未用于训练的 2 组剩余各 10 个信号,其结果及相对误差如图 10 所示。





(b) $h=1.5$ mm 时的预测裂纹深度结果
(b) The predicted crack depth result when $h=1.5$ mm

图 10 优选特征预测的裂纹深度与预测相对误差

Fig.10 The crack depth and relative error predicted with optimized characteristics

由图 10 可知,预测结果相对误差在 0.1% 以内,验证了 BP 神经网络优选特征预测裂纹深度的可行性。

5 结 论

本文提出一种基于差异性与最小集合的 BP 神经网络特征优选原则,优选反射 SAW 的峰值等 7 个特征或透射 SAW 的平均值等 8 个特征,均可作为 BP 神经网络预测表层裂纹深度的有效特征。通过数值模拟与实验验证了基于 BP 神经网络的超声表面波检测表层裂纹深度的有效性。模拟不锈钢表层裂纹深度为 0.1~2.0 mm,预测结果相对误差不超过 3%。与单参量经验拟合法相比,准确率提升 60% 以上。实验预测不锈钢表层 1.0 mm 和 1.5 mm 裂纹深度,相对误差在 0.1% 以内,为表层裂纹深度定量表征提供了有效途径。

参考文献

[1] 吴志学. 表面裂纹疲劳扩展的数值模拟(II)[J]. 应用力学学报, 2007, 24(1): 42-46.
WU ZH X. Numerical simulation to surface crack fatigue growth(II)[J]. Chinese Journal of Applied Mechanics, 2007, 24(1): 42-46.

[2] LIN X B, Smith R A. Finite element modelling of fatigue crack growth of surface cracked plates-Part II: Crack shape change [J]. Engineering Fracture Mechanics, 1999, 63(5): 503-522.

[3] HE C F, DENG P, LU Y, et al. Estimation of surface crack depth using Rayleigh waves by electromagnetic acoustic transducers [J]. International Journal of Acoustics and Vibration, 2017, 22(04): 541-548.

[4] LONG O R, VANLANDUI T S, VANHERIEELE J, et al. A method for crack sizing using Laser Doppler Vibrometer measurements of surface acoustic waves[J]. Ultrasonics, 2009, 50(1): 76-80.

[5] ZEONG K, ACHENBACH J D. A neural network for crack sizing trained by finite element calculations[J]. NDT & E International, 1996, 29(3): 147-155.

[6] LI K S, MA ZH Y, FU P, et al. Quantitative evaluation of surface crack depth with a scanning laser source based on particle swarm optimization-neural network [J]. NDT&E International, 2018, 98(09): 208-214.

[7] JJ L R. 固体中的超声波[M]. 何存富,译. 北京:科学出版社, 2004, ISBN7-03-011620-8.
JOSEPH L R, HE C F. Ultrasonic in solid[M]. HE C F, Trans. Beijing: Science Press, 2004, ISBN7-03-011620-8.

[8] 沈中华, 石一飞, 严刚, 等. 激光声表面波的若干应用研究进展[J]. 红外与激光工程, 2007, 36(z1): 507-512.
SHEN ZH H, SHI Y F, YAN G, et al. Progresses in the applications of laser induced surface acoustic waves[J]. Infrared and Laser Engineering, 2007, 36(z1): 507-512.

[9] LIU X L, LIN B, LIANG X H. Study of laser-induced surface acoustic wave propagating on materials with machined surfaces based on wavelet analysis[J]. Surface and Coatings Technology, 2019, 358: 173-181.

[10] LI Q, YU J Y, MU B CH, 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.

[11] 骆志高, 张保刚, 何鑫. 基于 BP 神经网络的金属拉深件裂纹在线监测[J]. 振动与冲击, 2012, 31(10): 102-105.
LUO ZH G, ZHANG B G, HE X. On-line crack monitoring of metal deep drawing parts based on BP neural network [J]. Journal of Vibration and Shock, 2012, 31(10): 102-105.

[12] XU J B, LIU H M, LI Q. Optimization of process parameters of preparing foamed Al-Si alloy based on Ga-based BP neural network [J]. Light Metals, 2012: 521-525.

[13] 田大新, 刘衍珩, 李宾, 等. 基于 Hebb 规则的分布神经网络学习算法[J]. 计算机学报, 2007(8): 1379-

- 1388.
- TIAN D X, LIU Y H, LI B, et al. Distributed neural network learning algorithm based on Hebb rule [J]. Chinese Journal of Computers, 2007(8): 1379-1388.
- [14] DING SH F, SU CH Y, YU J ZH. An optimizing BP neural network algorithm based on genetic algorithm[J]. Artificial Intelligence Review, 2011, 36(2): 153-162.
- [15] SADEGHI B H M. A BP-neural network predictor model for plastic injection molding process [J]. Journal of Materials Processing Technology, 2000, 103 (3): 411-416.
- [16] 韩英莉, 颜云辉. 基于 BP 神经网络的带钢表面缺陷的识别与分类[J]. 仪器仪表学报, 2006, 27(12): 1692-1694.
- HAN Y L, YAN Y H. Discernment and classification of banding strip surface defect based on BP neural network[J]. Chinese Journal of Scientific Instrument, 2006, 27(12): 1692-1694.
- [17] LI Q H, LIU D. Aluminum plate surface defects classification based on the BP neural network [J]. Applied Mechanics and Materials, 2015, 734: 543-547.
- [18] 梁远远, 杨生胜, 文轩, 等. 脉冲涡流无损检测中缺陷量化技术研究[J]. 仪器仪表学报, 2018, 39(11): 73-81.
- LIANG Y Y, YANG SH SH, WEN X, et al. Research on the quantification of defect in the nondestructive testing of pulse eddy current [J]. Chinese Journal of Scientific Instrument, 2018, 39(11): 73-81.
- [19] 袁海英, 陈光福, 谢永乐. 故障诊断中基于神经网络的特征提取方法研究[J]. 仪器仪表学报, 2007, 28(1): 90-94.
- YUAN H Y, CHEN G J, XIE Y L. Feature extraction method in fault diagnosis based on neural network [J]. Chinese Journal of Scientific Instrument, 2007, 28(1): 90-94.
- [20] 唐万梅. BP 神经网络网络结构优选问题的研究[J]. 系统工程理论与实践, 2005, 25(10): 95-100.
- TANG W M. The study of the optimal structure of BP neural network [J]. Systems Engineering-Theory & Practice, 2005, 25(10): 95-100.
- [21] GUAN J F, SHEN ZH H, LU J, et al. Finite element analysis of the scanning laser line source technique[J]. Japanese Journal of Applied Physics, 2006, 45(6A): 5046-5050.

作者简介



董珍一, 2018 年于大连理工大学获得学士学位, 现为大连理工大学硕士研究生, 主要研究方向为材料超声无损检测。

E-mail: dzy_dlut@qq.com

Dong Zhenyi received her B. Sc. degree in 2018 from Dalian University of Technology. Now, she is a M. Sc. candidate in Dalian University of Technology. Her main research interest is material ultrasonic nondestructive testing.



马志远 (通信作者), 博士, 现为大连理工大学讲师, 主要从事材料无损检测与评价、超声数值仿真等工作。

E-mail: zhiyuan@dlut.edu.cn

Ma Zhiyuan (corresponding author) is a Ph. D. and lecturer in Dalian University of Technology. His main research focuses on material nondestructive testing and evaluation, ultrasonic numerical simulation and etc.