

基于卷积神经网络的白蚀缺陷超声探测*

朱琦^{1)†} 许多¹⁾ 张元军¹⁾ 李玉娟¹⁾ 王文¹⁾ 张海燕^{2)‡}

1) (上海大学机电工程与自动化学院, 上海 200444)

2) (上海大学通信与信息工程学院, 上海 200444)

(2022 年 7 月 25 日收到; 2022 年 8 月 23 日收到修改稿)

不同于经典滚动接触疲劳形成的缺陷, 亚表面白蚀缺陷会引起轴承零件的早期失效, 严重缩短零件的寿命. 它位于金属亚表面且尺寸微小, 难以使用常规手段实现检测. 白蚀缺陷成因尚不明确, 不同演化阶段的缺陷样品制备耗时费力. 本文建立了白蚀缺陷演化模型, 基于 k 空间伪谱法开展了水浸超声检测过程数值实验. 对于含裂纹的白蚀缺陷演化后期, 可以忽略内部晶粒结构建立均匀层状模型, 使用经典声压反射系数幅度谱获取裂纹深度, 误差为 1.5%. 对于不含裂纹的其他白蚀缺陷状态, 则存在内部声阻抗差异较小, 频谱特征不再明显等问题. 基于维诺图 (Voronoi) 建立轴承晶粒模型, 利用晶粒对超声的背散射效应来放大微观结构信号. 高频情况下, 基于深度卷积神经网络的训练准确率达 92%, 验证准确率为 97%. 即使在较低检测频率下, 背散射信号较弱, 仍能获得 81% 的准确率. 为白蚀缺陷的早期检测提供了有效方案.

关键词: 白蚀缺陷, 超声背散射, 深度学习, 声压反射系数幅度谱

PACS: 43.20.+g, 43.20.Fn, 81.70.Cv, 87.85.dq

DOI: 10.7498/aps.71.20221504

1 引言

白蚀缺陷^[1]是一种轴承亚表面组织变化, 主要以白蚀区 (white etching area) 或白蚀裂纹 (white etching crack) 形式存在于距离表面 100—300 μm 的区域^[2]. 该区域的晶粒组织比周围基体组织尺寸小 1/80—1/1200^[3]、硬度 (HRC) 高 10%—60%^[4], 通过硝酸酒精溶液腐蚀并使用光学显微镜观察呈现亮白色, 主要成分为铁素体和非晶相组织. 白蚀缺陷的形成机理尚不明确^[5–7], 主要由氢聚、温度、摩擦等多种因素混合产生. 因白蚀缺陷与正常组织存在较大的硬度差, 反复滚动摩擦过程会加速周围正常组织的转变和裂纹延伸, 使得机械设备在其额定使用寿命的早期就发生失效.

常规的金相检测和扫描电子显微镜、透射电子显微镜主要研究白蚀缺陷的微观组织分布和特性, 但这些方法具有破坏性且制样复杂, 而无损检测手段更便于现场评价. 在众多手段中, 超声检测过程简便、灵敏度高, Hu 等^[8]使用高频换能器对轴承进行 C 型扫描, 能识别出轴承内圈亚表面存在的疲劳裂纹和夹杂物. Sreeraj 等^[9]利用模拟数据中瑞利波与白蚀缺陷的相互作用, 分析波形变化的规律, 与实验超声数据相结合, 基于声波在滚子表面的不同传播路径及飞行时间, 求得实际缺陷的位置和深度. 现今的超声检测方法主要针对白蚀缺陷发展的中后期, 此阶段往往已出现裂纹, 易于检测识别. 若能实现白蚀缺陷的早期诊断, 不仅能够减少经济损失, 也有助于进一步研究其形成机理.

* 国家自然科学基金 (批准号: 11904223, 12174245, 11874255)、国家重点研发计划 (批准号: 2018YFB2000300) 和精密测试技术及仪器国家重点实验室开放基金 (批准号: pilab2209) 资助的课题.

† 通信作者. E-mail: Q_ZHU@shu.edu.cn

‡ 通信作者. E-mail: hyzh@shu.edu.cn

如果把轴承视作多层介质, 可通过声压反射系数幅度谱 (URCAS) 利用回波信号的幅度谱提取出与被检测材料相关的超声特征参量, 实现材料特性的表征^[10]. Ma 等^[11] 从理论上分析了热障涂层氧化物与相邻介质之间的声阻抗匹配关系, 实现了涂层氧化物这一中间层厚度的无损表征. 之后他们为了确定非均匀多层结构的几何参数和声学参数^[12], 在理论 URCAS 的基础上, 提出了一种结合最小二乘和互相关算法的目标函数, 可同时识别多层涂层特别是中间层材料的厚度、声速、密度、衰减系数变化规律. 在上述多层介质的检测中, 首层介质的厚度均小于 300 μm , 说明 URCAS 是实现亚表面区域的无损检测有效方法. 然而, 当亚表面区域与周边基体的阻抗差减小, 所得信号的信噪比逐步下降. 另一方面, 当亚表面层厚变小, 需要不断提高检测频率, 这导致出现信号散射等干扰. 上述问题都使得类似方法不再适用. 在高频超声检测时, 轴承晶粒引起的背散射信号^[13] 或“结构噪声”包含大量的微观组织信息, 是一种加强不同组织之间声学特性差异的有效手段. 晶粒的尺寸、取向强烈影响超声波的传播, Chen 等^[14] 通过考虑晶粒影响模拟了超声波在厚壁离心铸造不锈钢中的传播, 所得结果能够再现结构噪声、信号失真等现象, 与实验高度吻合. Norouziyan 等^[15] 研究了 6 种具有相同平均晶粒尺寸但不同尺寸分布下的超声波衰减与散射变化情况, 表明晶粒分布特征对频率依赖性的衰减有重要作用. 由于背散射信息是从统计角度对介质进行表征, 不易直接对白蚀缺陷等亚表面状态进行定量分析.

近年来, 卷积神经网络作为深度学习的经典算

法已被广泛运用于图像识别、缺陷分类、医学超声等领域^[16]. Liu 和 Zhang^[17] 采用模拟的兰姆波检测数据基于 VGG-16 网络建立了迁移学习模型, 并使用实验数据成功检测了金属铝板的表面切口. Pyle 等^[18] 基于有限元方法生成的散射矩阵和射线模型模拟创建了全矩阵捕获下的管道裂纹缺陷信号, 同时结合少量实验数据训练了深度学习神经网络, 可有效分辨裂纹的大小、种类和位置. Cai 等^[19] 利用卷积神经网络识别亚波长缺陷散射和晶粒结构散射引起的变化, 能避免噪声干扰, 实现亚波长精度的超声 C 扫描成像. 相比于传统的基于物理模型的分类检测方法, 卷积神经网络在特征提取、分类、运算速度方面有着很大的优势, 受噪声、激励等其他因素的影响较小, 能够实现常规手段难以实现的检测能力. 本文首先建立了包含白蚀缺陷的多晶计算模型, 然后开展超声-晶粒相互作用计算, 分析相应的背散射信号, 比较其与经典方法的差异, 最后训练卷积神经网络获取分类结果, 探讨该方法对于白蚀缺陷演化过程的检测效果.

2 原理

2.1 声压反射系数幅度谱

当平面声波从一种介质垂直入射到另一种介质时, 由于两者的声阻抗不同, 声波会发生多次反射和透射. 对轴承截面多层介质而言, 由于亚表面白蚀缺陷厚度小, 存在回波混叠. 包含白蚀裂纹的典型截面结构如图 1(a) 所示, 图 1(b) 中 P_m , T_m ($m = 1, 2, 3, \dots$) 分别是入射波在界面之间多次发生反射的回波和穿透界面的透射波.

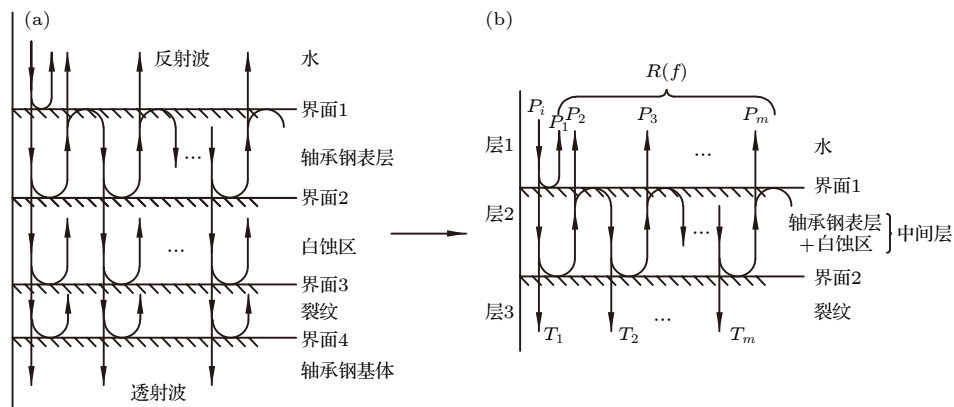


图 1 (a) 多层结构的轴承截面; (b) 三层介质简化模型

Fig. 1. (a) Multilayer cross-section of bearing; (b) simplified three-layer model.

因为轴承钢基体与白蚀区的声阻抗相近, 所以可将二者视为同一种介质^[11], 此处简称为“中间层”. 由于裂纹的存在, 大部分能量在该层被反射, 可进一步将复杂的多层结构轴承截面简化成三层介质模型(图 1(b)). 其声压反射系数可由(1)—(3)式表示^[20]:

$$K = \frac{Z_j}{Z_i}, \quad (1)$$

$$R_{ij} = \frac{K - 1}{K + 1}, \quad (2)$$

$$|R(f)| = \sqrt{\text{Re}^2 + \text{Im}^2} = \left[\frac{R_{12} + R_{23} \exp(-2\alpha d)^2 - 4R_{12}R_{23} \exp(-2\alpha d) \sin^2(2\pi f d/c_2)}{1 + R_{12}R_{23} \exp(-2\alpha d)^2 - 4R_{12}R_{23} \exp(-2\alpha d) \sin^2(2\pi f d/c_2)} \right]^{1/2}. \quad (4)$$

当 $\sin^2(2\pi f d/c_2) = 1$ 时, $|R(f)|$ 取极小值, 此时对应的频率可以满足:

$$f_n = \frac{nc_2}{4d} (n = 1, 2, 3, \dots). \quad (5)$$

其中 f_n 和 n 分别是谐振频率与谐振频率阶数, f_n 在声压反射系数幅度谱中呈现极大值或极小值. 通过提取谱线上极值之差来计算谐振频率, 通过介质之间的阻抗差异确定谐振频率阶数. 简化后模型的中间层厚度可利用(5)式求出.

2.2 卷积神经网络

对于图 1(a) 所示的未简化模型而言, 由于层数多、层间距小, 声波会发生反复的反射、透射, 最终造成信号混叠. 特别当无裂纹存在时, 难以直接提取信息进行分析. 而卷积神经网络作为深度学习的一种模型, 可对微小的信号差异做出分类, 通常由卷积层、激活函数、池化层、全连接层、分类函数组成. 将预处理的图像作为输入层的输入, 经过卷积层提取特征, 池化层进行特征选择和信息过滤, 全连接层用来组合被筛选后的高级特征, 最后实现图像分类和识别. 一般来说, 提高模型准确率的方法包括减小卷积核尺寸、减少步进大小和提升网络的深度. 在卷积核尺寸与步进大小无法调整的前提下, 网络深度的提高意味着能够提取和整合更多的特征, 有助于训练精度的提升.

但随着深度进一步的增大, 普通网络模型的训练精度反而会低于浅层网络模型, 甚至最终结果不收敛. 造成这类现象的原因是: 1) 特征进一步的增

$$R(f) = \sum_{m=1}^{\infty} P_m = \frac{R_{12} + R_{23} \exp[2\alpha(f)d] \exp\left(\frac{i4\pi f d}{c_2}\right)}{1 + R_{12}R_{23} \exp[2\alpha(f)d] \exp\left(\frac{i4\pi f d}{c_2}\right)}, \quad (3)$$

其中 Z 为介质的声阻抗 ($i, j \in \{1, 2, 3\}, i \neq j$), K 为两介质的声阻抗比例, R_{ij} 是介质 i 和 j 界面的声压反射系数, c_2 为中间层的波速, α 是中间层的衰减系数, d 是中间层的厚度. 对三层介质中的 $R(f)$ 取模, 得到实数域的声压反射系数幅度谱:

多, 梯度呈指数级增长, 会发生梯度爆炸或消失的现象; 2) 深度意味着卷积层数量增多, 每次卷积运算的误差叠加致使结果不收敛, 这也称为网络的退化. ResNet 网络模型^[21] 能够提高卷积层的层数, 同时避免上述问题.

ResNet 网络模型是一种深层卷积神经网络模型, 可达 100 层以上, 能够保证训练结果的收敛, 提升训练精度. ResNet 网络引入深度残差网络结构, 该结构如图 2 所示. 作为一种旁路连接的结构, 使得反向传播能够一次性跨越多层网络进行传播, 而不会在逐层运算中出现梯度爆炸或消失的现象, 进一步优化了网络的性能. 残差结构的输入输出公式为

$$y = F(x) + x, \quad (6)$$

式中, x, y 表示该结构的输入和输出; $F(x)$ 是输入 x 的残差映射.




图 2 残差网络

Fig. 2. Residual network.

BN (batch normalization) 表示批量标准化, 其作用是将保证训练集的特征图像满足一定的分布规律, 使得非线性变换的输入落入到对输入比较敏感的区域, 进而对特征进行标准化处理. 在梯度较大的前提下, 避免深度学习网络发生性能退化, 保证结果的收敛. 批量标准化的过程为

$$\begin{cases} \mu_R = \frac{1}{m} \sum_{i=1}^m x_i, \\ \sigma_R^2 = \frac{1}{m} \sum_{i=1}^m (x_i - \mu_R)^2, \\ \hat{x}_i = \frac{x_i - \mu_R}{\sqrt{\sigma_R^2 + \varepsilon}}, \\ y_i = \gamma \hat{x}_i + \beta \equiv BN_{\gamma, \beta}(x_i), \end{cases} \quad (7)$$

式中, x_i 和 y_i 分别为批量归一化的输入与输出, 用 $y = BN_{\gamma, \beta}(x)$ 表示; μ_R 和 σ_R^2 表示第 R 次训练的方差与标准差; γ 和 β 是残差结构的标准化参数; ε 是为了保持数值稳定而添加到方差计算中的常数.

3 计算模型建立

基于维诺图 (Voronoi) 在 Matlab 中建立轴承晶粒模型^[22], 该方法已被成功应用于滚动接触疲劳过程中轴承亚表面缺陷的发展过程^[23] 以及超声波散射的分析^[24]. 晶粒的尺寸和取向之间的差异共同决定了超声波的背散射程度. 由于实际的晶粒弹性参数矩阵不易获取, 将晶粒间不同取向引起的差异简化为声阻抗差异. 根据 Yin 等^[25] 和 Dryburgh 等^[26] 对金属晶粒的声速研究表明, 不同取向的晶粒所带来的声速误差不超过 10%. 模型中的所有声学参数如表 1 所列, 在本次建模过程中, 设定轴承钢基体的平均晶粒尺寸 $\bar{d}_{\text{基体}} = 20 \mu\text{m}$, 而白蚀缺陷周围的细化晶粒平均尺寸 $\bar{d}_{\text{细化}} = 6 \mu\text{m}$ ^[3]. 根据经典散射理论, 当晶粒尺寸小于波长时 ($\bar{d} < \lambda/10$)

处于瑞利散射区间^[27], 由晶粒带来的波散射十分微弱^[14]. 因此当检测频率 $f < 100 \text{ MHz}$ 时, 可以忽略具有纳米尺度晶粒的白蚀区影响. 虽然继续提高频率 ($f > 100 \text{ MHz}$) 能够获取更多亚表层信息, 但是穿透性能随之减小.

参考实验室已有的白蚀裂纹显微成像结果 (图 3(a)), 选取尺寸为 $1000 \mu\text{m} \times 500 \mu\text{m}$ 区域, 基于 k 空间伪谱法^[29] 开展波传导分析, 分别建立均质层状模型 (图 3(b)) 和晶粒特征模型 (图 3(c)), 设置激励线源位于水层中, 周边为完美匹配层 (PML) 来消除边界处的反射, 提高计算效率. 为了保证数值计算稳定性并满足奈奎斯特采样定理^[30], 已知网格尺寸 $\Delta x = 0.5 \mu\text{m}$ 及最大声速 $c_{\text{max}} = 6090 \text{ m/s}$, 根据 CFL (Courant-Friedrichs-Lewy) 判据^[31]:

$$c_{\text{max}} \Delta t \leq \Delta x / \sqrt{2}, \quad (8)$$

在计算中设置 $\Delta t = 0.018 \text{ ns}$, 所对应的 $\text{CFL} = 0.22$, 满足 (8) 式的要求.

在此基础上, 假定各层声学性能在白蚀缺陷演化过程中保持一致, 进一步建立包括“无白蚀缺陷-白蚀区出现-白蚀区扩大-白蚀裂纹出现-白蚀裂纹扩展”^[32,33] 等 5 种演化状态模型 (图 4, 对应图 3(c) 中虚线框), 用于后续卷积神经网络分类识别.

4 结 果

4.1 层状均匀介质模型

对图 3(b) 层状介质模型求声压反射系数幅度谱, 所得的结果如图 5 所示. 由于裂纹与基体的声阻抗差异较大, 谱线的极小值 (红圈) 间隔均匀, 可直接从谱线中提取谐振频率差求出裂纹深度为 $162.5 \mu\text{m}$. 实际模型的设定是 $160 \mu\text{m}$, 误差为 1.5%. 说明该方法能较好检测处于演化后期 (图 4(d) 和图 4(e)) 存在亚表面裂纹的轴承样品.

表 1 模型使用的声学参数及晶粒尺寸

Table 1. Acoustic characteristics and crystalline grain size of different materials.

	声速 $V/(\text{m}\cdot\text{s}^{-1})$	密度 $\rho/(\text{kg}\cdot\text{m}^{-3})$	声阻抗 $Z (\text{MRayl})$	晶粒尺寸
空气	340	1.29	4.39×10^{-4}	—
水	1500	1000	1.5	—
白蚀组织	4350 ^[28]	7850 ^[9]	34.15	5—300 nm ^[3]
轴承钢	5620	7840	44.06	正常 15—25 μm , 细化后 2—10 μm
不同晶粒取向的轴承钢	5510—6090	7410—8190	40.82—49.87	—

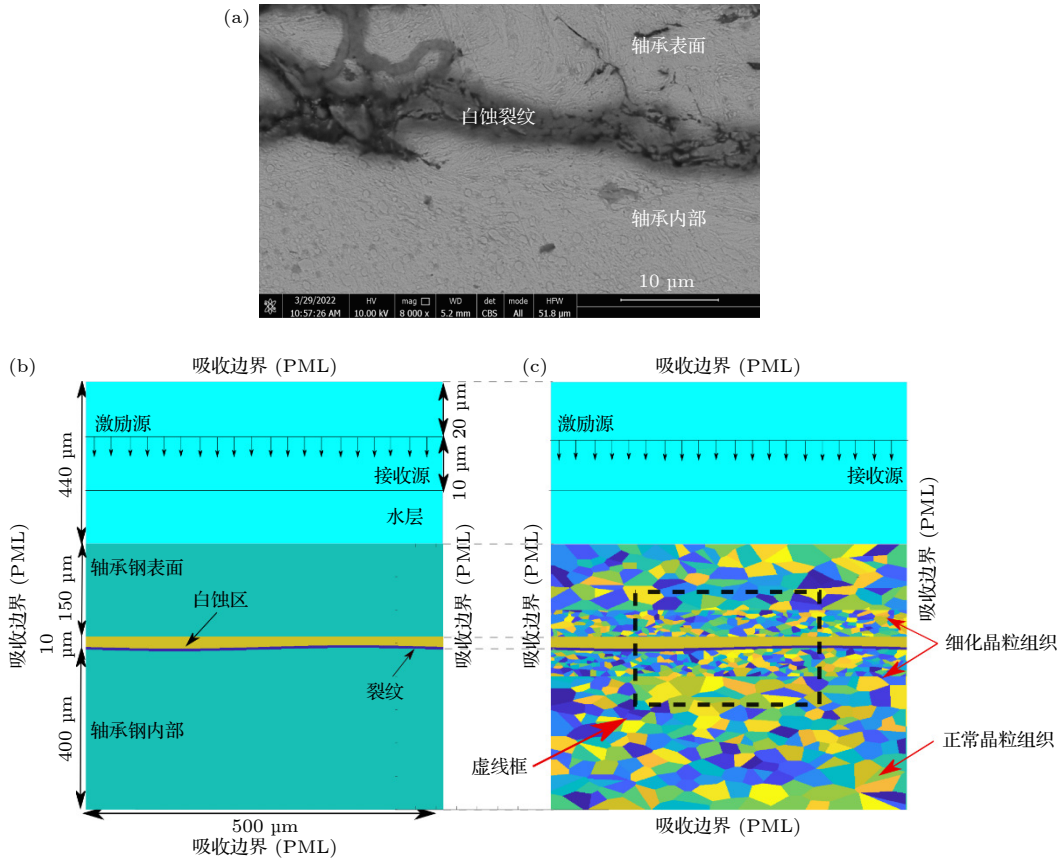


图 3 (a) 白蚀缺陷显微成像; (b) 层状介质的超声仿真模型; (c) 包含晶粒特征的超声仿真模型

Fig. 3. (a) Microscopic imaging of white etching defect; (b) ultrasonic simulation model of layered medium; (c) ultrasonic simulation model including grains.




图 4 白蚀缺陷演化过程的 5 种不同状态

Fig. 4. Five different states of white etching defect during evolution.




图 5 裂纹对声压反射系数幅度谱的影响

Fig. 5. Effect of crack on ultrasonic reflection coefficient amplitude spectrum.

当无裂纹存在时 (图 4(a)–(c)), 因为白蚀缺陷与轴承钢基体的声阻抗差异较小, 该方法不再适用. 图 6(a) 是调整图 1(b) 三层介质模型中层 2, 3 之间的声阻抗比所得到的幅频谱, 结果表明当声阻抗比 K 接近于 1, 极值位置难以确定, 基于 (5) 式所计算的厚度误差快速增大 (图 6(b)).

4.2 多晶计算模型

4.2.1 时域分析

对比不同频率下 (25, 50, 100 MHz) 的超声背散射信号, 其典型的波传播过程快照如图 7 所示. 由

图 8(a) 可见, 随着检测频率的提高, 背散射信号逐渐增强. 根据频域信息 (图 8(b)), 25 MHz 和 50 MHz 的频域信号峰值分别为 27.5 MHz 和 58 MHz, 与超声换能器给定的频率范围接近, 符合超声检测规律. 但 100 MHz 的频域信号中, 两个波峰分别为 72 MHz 和 130 MHz, 峰值位置出现了明显波

动. 这是因为不同的微观结构只对某些频段表现出高敏感性^[34], 说明此时的晶粒结构对 100 MHz 的超声信号产生了较大的影响, 该频段包含着大量的频域信息. 三者的时域、频域信号差异是由晶粒尺寸与超声波长共同决定的.




图 6 不同声阻抗比下的 (a) 声压反射系数幅度谱和 (b) 厚度计算误差

Fig. 6. (a) URCAS and (b) thickness calculation errors under different acoustic impedance ratios.

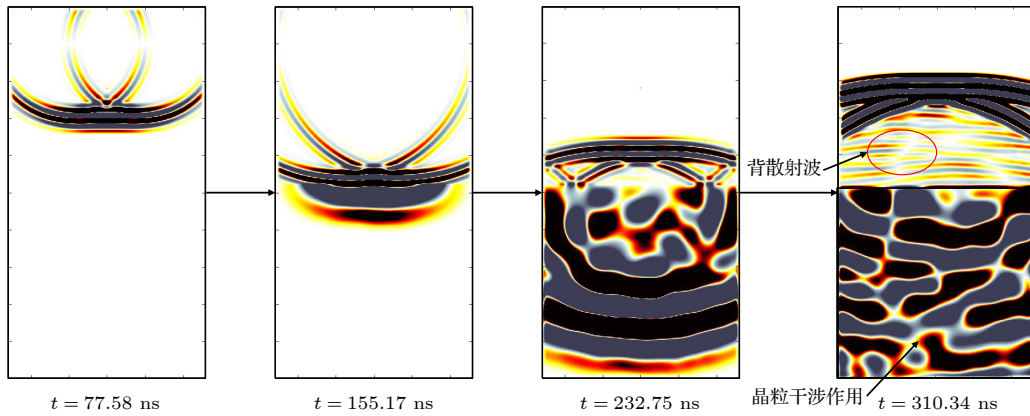


图 7 不同时刻下二维水浸超声检测在多晶模型的传播过程 ($f = 100$ MHz)

Fig. 7. Two-dimensional simulation of ultrasonic immersion testing of polycrystalline model ($f = 100$ MHz).

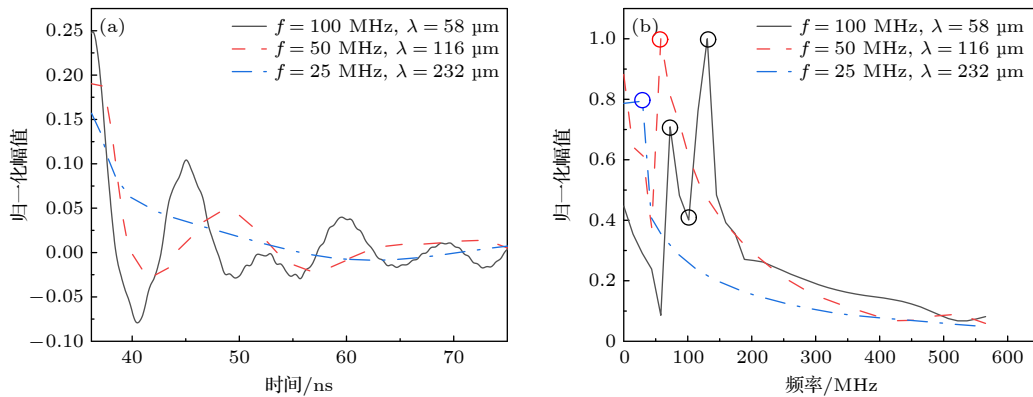


图 8 不同频率下的背散射信号 (a) 时域; (b) 频域

Fig. 8. Backscattering signals under different frequencies: (a) Time domain; (b) frequency domain.

4.2.2 卷积神经网络的结构与数据集

为实现白蚀缺陷的早期筛查,以 ResNet 网络为基础调整参数,构建本次卷积神经网络的结构.将一维超声信号通过短时傅里叶变换 (STFT)^[17,35] 转化为二维时频图.使用宽度 (window size) 为 120,重叠数 (number of overlapped samples) 为 115 的汉宁窗,对图 9(a) 虚线框内的背散射信号进行 STFT 转换,转换结果如图 9(b).以转换后所得的时频图作为卷积神经网络的输入数据集.为保证足够多的数据量,对超声信号添加 25—40 dB 之间的白噪声扩充数据集,每种状态转换出 500 张时频图,共 2500 张.为防止过拟合现象的产生^[36—38],将

其中的 70% 作为训练集,30% 作为验证集,并设置 dropout 参数为 0.5.

为保证识别的精度,该网络设置为 50 层.经过多轮卷积运算后提取特征信息,接着对特征信息使用批量标准化 (BN) 使其满足均值为零、方差为 1 的特定规律.在重复上述卷积的过程中,为防止因层数过高而产生梯度消失的现象,引入残差结构运算,在增加层数的同时不产生额外的参数.每次残差运算之后都通过 Relu 函数来激活,使其具有解决非线性问题的能力.最后将得到的特征量作为全连接层的输入,通过 softmax 函数转化为对应的概率分布,计算误差、记录权重并完成一回合的训练过程.整体流程如图 10 所示.




图 9 (a) 典型超声波形图 ($f = 100$ MHz); (b) STFT 转换的时频图

Fig. 9. (a) Typical ultrasonic waveform ($f = 100$ MHz); (b) time-frequency diagram of STFT conversion.

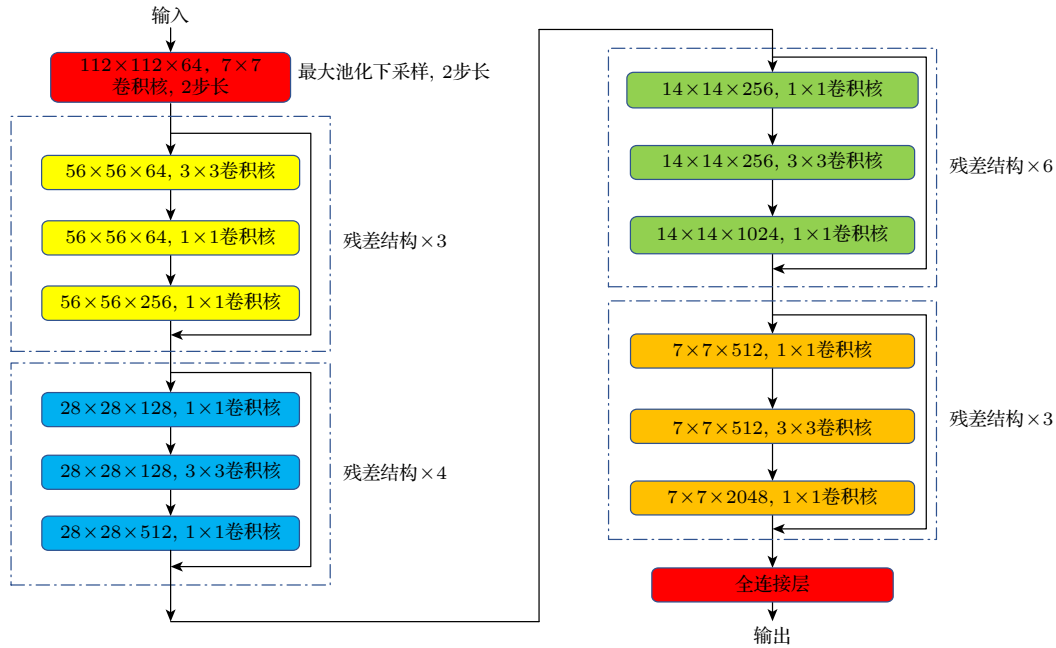


图 10 卷积神经网络结构图

Fig. 10. Convolutional neural network structure.

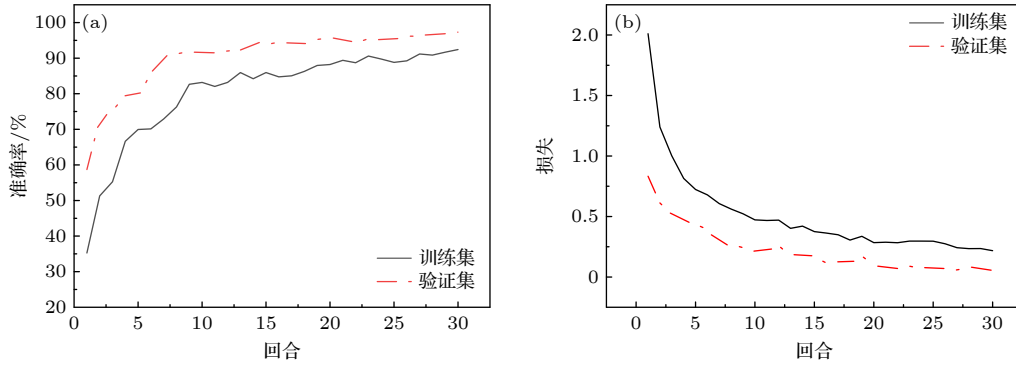


图 11 100 MHz 仿真模型的训练结果

Fig. 11. Training results of 100 MHz simulation model.

表 2 不同频率超声换能器的卷积神经网络计算结果

Table 2. Convolution neural network calculation results of different frequency ultrasonic transducer.

检测频率/MHz	回合	训练集准确率/%	验证集准确率/%	损失	检测频率/MHz	回合	训练集准确率/%	验证集准确率/%	损失
100	1	35.24	58.70	2.05	50	1	34.21	56.48	2.20
	10	83.19	91.28	0.46		10	81.68	88.70	0.48
	20	88.20	95.66	0.31		20	86.40	93.77	0.33
	30	92.42	97.31	0.21		30	90.01	95.16	0.22
25	1	32.14	50.02	2.32	15	1	26.80	45.96	2.35
	10	74.65	87.95	0.63		10	70.52	83.66	0.68
	20	81.43	90.71	0.43		20	79.92	88.50	0.45
	30	85.99	93.40	0.22		30	81.03	91.02	0.22

4.2.3 训练结果与分析

当检测频率为 100 MHz 时, 其训练集准确率达到 92%, 验证集准确率达到 97%, 效果良好, 损失均下降到 0.2 左右 (图 11). 该网络模型能够满足区分白蚀缺陷不同状态的要求, 解决了单一时、频域特征成像的局限性, 提高了检测精度.

类似地, 在 50, 25, 15 MHz 下重复上述步骤进行训练, 所有结果如表 2 列出. 高频检测下产生了较强的背散射信号, 时频图中具有丰富的白蚀缺陷信息, 预测准确率较高. 而随着频率的降低, 波长远大于晶粒尺寸 (20 μm), 导致超声散射不显著, 训练的准确率下降. 尽管如此, 表 2 中相对低频的 15 MHz 超声换能器的训练准确率依旧超过了 81%, 说明该方法也适用于低频及白噪声干扰情况.

5 总结

针对白蚀缺陷尺寸小、与基体声阻抗差异小等特点, 本文提出一种结合背散射信息与卷积神经网络

的理论检测方法, 可以有效应用于白蚀缺陷的无裂纹早期演化阶段预测. 主要得出以下结论:

- 1) 经典 URCAS 可准确表征演化后期的白蚀缺陷裂纹深度, 但尚不适用于演化早期状态表征;
- 2) 高频检测下的超声-晶粒相互作用产生背散射信号, 这些信号包含了更多的晶粒特征, 能更好区分白蚀缺陷的早期各演化阶段;
- 3) 卷积神经网络对全演化阶段的白蚀缺陷有较高的识别度, 即使在背散射较弱的情况下也有较高的正确率, 可辅助用于轴承剩余寿命预测.

另外, 由于不同演化状态的白蚀缺陷轴承制样和金相观测耗时费力, 模拟实验能有效避免以上限制, 并为实测数据提供理论依据. 将基于模拟数据训练的神经网络模型用于实验样品的预测, 能大大降低成本并提高模型的泛化能力. 后续为了能较好匹配实测波形与模拟计算波形, 需进一步考虑表面粗糙度对声波反射与传递带来的影响^[10], 使模拟实验更接近真实状态; 另外, 也可在计算过程中设置聚焦换能器^[39], 提高细节检测的效果.

参考文献

- [1] Manieri F, Stadler K, Morales-Espejel G E, Kadiric A 2019 *Int. J. Fatigue* **120** 107
- [2] Linzmayer M, Sous C, Gutiérrez Guzmán F, Jacobs G 2021 *Wear* **480–481** 203925
- [3] Leung J F W, Bedekar V, Voothaluru R, Neu R W 2019 *Metall. Mater. Trans. A* **50** 4949
- [4] Curd M E, Burnett T L, Fellowes J, Donoghue J, Yan P, Withers P J 2019 *Acta Mater.* **174** 300
- [5] Evans M H, Walker J C, Ma C, Wang L, Wood R J K 2013 *Mater. Sci. Eng. A* **570** 127
- [6] Lai J, Stadler K 2016 *Wear* **364–365** 244
- [7] López-Uruñuela F J, Fernández-Díaz B, Pagano F, López-Ortega A, Pinedo B, Bayón R, Aguirrebeitia J 2021 *Int. J. Fatigue* **145** 106091
- [8] Hu P, Turner J A, Tarawneh C, Wilson B, Fuller A J 2015 *Proceeding of the Joint Rail Conference*, San Jose, March 23–26, 2015 p5785
- [9] Sreeraj K, Maheshwari H K, Rajagopal P, Ramkumar P 2021 *Tribol. Int.* **162** 107134
- [10] Ma Z, Zhang W, Gao J, Lin L, Krishnaswamy S 2016 *43rd Annual Review of Progress in Quantitative Nondestructive Evaluation*, Atlanta, July 17–22, 2016 p1016
- [11] Ma Z, Zhao Y, Luo Z, Lin L 2014 *Ultrasonics* **54** 1005
- [12] Ma Z, Qi T, Lin L, Lei M 2022 *Ultrasonics* **119** 106626
- [13] Li S, Li X B, Song Y F, Chen C 2018 *Acta Phys. Sin.* **67** 107 (in Chinese) [李珊, 李雄兵, 宋永锋, 陈超 2018 物理学报 **67** 107]
- [14] Chen Y, Luo Z, Zhou Q, Zou L, Lin L 2015 *Ultrasonics* **59** 31
- [15] Norouziian M, Islam S, Turner J A 2020 *Ultrasonics* **102** 106032
- [16] Zhang Y Z, Xin Q Z, Wang Y L, Kong X M, Liu F, Yang Z S 2021 *Mater. Rep.* **35** 24152 (in Chinese) [张永志, 辛全忠, 王永亮, 孔祥明, 刘昉, 杨再胜 2021 材料导报 **35** 24152]
- [17] Liu H, Zhang Y 2019 *Smart Mater. Struct.* **29** 015032
- [18] Pyle R J, Bevan R L T, Hughes R R, Rachev R K, Ali A A S, Wilcox P D 2021 *IEEE Trans. Ultrason. Ferroelectr. Freq. Control* **68** 1854
- [19] Cai Y, Song Y, Ni P, Liu X, Li X 2021 *Ultrasonics* **117** 106552
- [20] Zhao Y, Lin L, Li X M, Lei M K 2010 *NDT & E Int.* **43** 579
- [21] He K, Zhang X, Ren S, Sun J 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, June 27–30, 2016 p770
- [22] Zhen Z G, Wang Z L, Feng Q, Yuan S, Wang J X 2016 *J. Guangxi Uni. (Nat Sci Ed)* **41** 460 (in Chinese) [郑战光, 汪兆亮, 冯强, 袁帅, 王佳祥 2016 广西大学学报 (自然科学版) **41** 460]
- [23] Weinzapfel N, Sadeghi F 2013 *Tribol. Int.* **59** 210
- [24] Bai X, Tie B, Schmitt J H, Aubry D 2018 *Ultrasonics* **87** 182
- [25] Yin A, Wang X, Glorieux C, Yang Q, Dong F, He F, Wang Y, Sermeus J, Van der Donck T, Shu X 2017 *Ultrasonics* **78** 30
- [26] Dryburgh P, Smith R J, Marrow P, Lainé S J, Sharples S D, Clark M, Li W 2020 *Ultrasonics* **108** 106171
- [27] Smith R L 1982 *Ultrasonics* **20** 211
- [28] Wei Q, Wei T, Dong S R, Zhang H L 2012 *J. Jiangsu Univ. Sci. Technol. (Nat. Sci. Ed)* **26** 27 (in Chinese) [魏勤, 卫婷, 董师润, 张海林 2012 江苏科技大学学报 (自然科学版) **26** 27]
- [29] Martin E, Jaros J, Treeby B E 2020 *IEEE Trans. Ultrason. Ferroelectr. Freq. Control* **67** 81
- [30] Gottlieb D, Tadmor E 1991 *Math. Comput.* **56** 565
- [31] Tillett J C, Daoud M I, Laceyfield J C, Waag R C 2009 *J. Acous. Soc. Am.* **126** 1231
- [32] Loos J, Blass T, Franke J, Kruhoeffler W, Bergmann I 2016 *J. Mech. Eng. Autom.* **6** 85
- [33] Zhang Z Y, Toni B, Tang Y, Wei J F 2020 *China Metallurgy* **30** 2 (in Chinese) [章桢彦, Toni B, 唐瑜, 韦剑飞 2020 中国冶金 **30** 2]
- [34] Song Y F, Li X B, Wu H P, Si J Y, Han X Q 2016 *Acta Metall. Sin.* **52** 378 (in Chinese) [宋永锋, 李雄兵, 吴海平, 司家勇, 韩晓芹 2016 金属学报 **52** 378]
- [35] Bai X T 2021 *M. S. Thesis* (Xi'an: Xi'an University of Technology) (in Chinese) [白旭天 2021 硕士学位论文 (西安: 西安理工大学)]
- [36] Behmke M, Guo S, Guo W G 2021 *Proc. Manuf.* **53** 656
- [37] Ha C, Tran V D, Ngo Van L, Than K 2019 *Int. J. Approx. Reason.* **112** 85
- [38] Mutasa S, Sun S, Ha R 2020 *Clin. Imaging* **65** 96
- [39] Song G, Qin D, Lyu Y, Hong G, Xu Y, Wu B, He C 2017 *Int. J. Acoust. Vib.* **22** 511

Ultrasonic detection of white etching defect based on convolution neural network*

Zhu Qi^{1)†} Xu Duo¹⁾ Zhang Yuan-Jun¹⁾ Li Yu-Juan¹⁾
Wang Wen¹⁾ Zhang Hai-Yan^{2)‡}

1) (*School of Mechatronic and Automation Engineering, Shanghai University, Shanghai 200444, China*)

2) (*School of Communication & Information Engineer, Shanghai University, Shanghai 200444, China*)

(Received 25 July 2022; revised manuscript received 23 August 2022)

Abstract

Unlike classical defects formed by rolling contact fatigue, white etching defect (WED) including white etching area and white etching crack will cause surface to spall in the early stage and the service life to shorten seriously. Located in the subsurface of bearings, the tiny size WED is difficult to detect by conventional ultrasonic methods. The root cause of WED generation remains unclear. It is time consuming and expensive to prepare samples during the evolution of such defects. For characterizing the WED at early stage, five evolving states concerning the existing microscopic information are established in this paper. The immersion ultrasonic inspection process is simulated based on k -space pseudo spectrum method.

For the later evolutionary stage with crack, the bearing can be simplified into a homogeneous three-layer model by ignoring the internal grain structure. The crack depth is obtained by using the ultrasonic reflection coefficient amplitude spectrum (URCAS), with an error of 1.5%. For other states without crack, the spectrum characteristic is no longer evident with slight acoustic impedance difference between layers. The polycrystalline structure on a microscale is thus realized based on Voronoi diagram, from which the grain induced backscattering can be used to amplify the microstructure variations at different stages. The backscattering signal is influenced by the grain size and detection frequency from the simulation. Since a direct comparison of backscattering information among evolutionary stages is difficult, the five different evolutionary stages of WED are recognized with the help of deep learning. The received waveform is transformed into a time-frequency map by short-time Fourier transform. Based on RESNET network structure, the results show that the train accuracy and validation accuracy reach 92% and 97% respectively. This study provides a sound way to characterize WED, which is conducive to early failure prediction and residual life evaluation.

Keywords: white etching defect, ultrasonic backscattering, deep learning, ultrasonic reflection coefficient amplitude spectrum

PACS: 43.20.+g, 43.20.Fn, 81.70.Cv, 87.85.dq

DOI: [10.7498/aps.71.20221504](https://doi.org/10.7498/aps.71.20221504)

* Project supported by the National Natural Science Foundation of China (Grant Nos. 11904223, 12174245, 11874255), the National Key R&D Program of China (Grant No. 2018YFB2000300), and the Open Fund of State Key Laboratory of Precision Measuring Technology and Instruments, China (Grant No. pilab2209).

† Corresponding author. E-mail: Q_ZHU@shu.edu.cn

‡ Corresponding author. E-mail: hyzh@shu.edu.cn



基于卷积神经网络的白蚀缺陷超声探测

朱琦 许多 张元军 李玉娟 王文 张海燕

Ultrasonic detection of white etching defect based on convolution neural network

Zhu Qi Xu Duo Zhang Yuan-Jun Li Yu-Juan Wang Wen Zhang Hai-Yan

引用信息 Citation: *Acta Physica Sinica*, 71, 244301 (2022) DOI: 10.7498/aps.71.20221504

在线阅读 View online: <https://doi.org/10.7498/aps.71.20221504>

当期内容 View table of contents: <http://wulixb.iphy.ac.cn>

您可能感兴趣的其他文章

Articles you may be interested in

基于深度学习的光学表面杂质检测

Deep-learning-assisted micro impurity detection on an optical surface

物理学报. 2021, 70(16): 168702 <https://doi.org/10.7498/aps.70.20210403>

基于深度学习压缩感知与复合混沌系统的通用图像加密算法

General image encryption algorithm based on deep learning compressed sensing and compound chaotic system

物理学报. 2020, 69(24): 240502 <https://doi.org/10.7498/aps.69.20201019>

基于深度学习的流场时程特征提取模型

Flow feature extraction models based on deep learning

物理学报. 2022, 71(7): 074701 <https://doi.org/10.7498/aps.71.20211373>

基于深度学习的相位截断傅里叶变换非对称加密系统攻击方法

Attacking asymmetric cryptosystem based on phase truncated Fourier transform by deep learning

物理学报. 2021, 70(14): 144202 <https://doi.org/10.7498/aps.70.20202075>

基于深度学习的新混沌信号及其在图像加密中的应用

A new chaotic signal based on deep learning and its application in image encryption

物理学报. 2021, 70(23): 230502 <https://doi.org/10.7498/aps.70.20210561>

基于深度学习的联合变换相关器光学图像加密系统去噪方法

In depth learning based method of denoising joint transform correlator optical image encryption system

物理学报. 2020, 69(24): 244204 <https://doi.org/10.7498/aps.69.20200805>