

基于深度学习的特种设备裂纹超声检测技术研究

朱涛平, 蔡福磊

江联重工集团股份有限公司, 江西南昌 330000

DOI:10.61369/ME.2025050029

摘要 : 随着工业自动化和智能化的发展, 特种设备的安全运行愈发受到重视。裂纹作为特种设备常见且危害严重的缺陷类型, 其早期准确检测对保障设备安全具有重要意义。传统超声检测方法在裂纹识别中面临信号噪声大、人工经验依赖强等问题。近年来, 深度学习技术凭借其强大的特征自动提取和模式识别能力, 成为提升超声检测准确性和效率的重要手段。本文系统研究了基于深度学习的特种设备裂纹超声检测技术, 重点探讨了数据预处理、模型设计、裂纹识别与定位等关键技术环节, 并通过实验验证了该方法在裂纹检测中的优越性能。研究结果表明, 深度学习显著提升了裂纹检测的准确率和鲁棒性, 为特种设备无损检测技术的发展提供了新的思路和技术支持。

关键词 : 深度学习; 特种设备; 裂纹检测; 超声检测; 无损检测; 信号处理

Research on Ultrasonic Crack Detection Technology for Special Equipment Based on Deep Learning

Zhu Taoping, Cai Fulei

Jianglian Heavy Industry Group Co., LTD., Nanchang, Jiangxi 330000

Abstract : With the development of industrial automation and intelligence, the safe operation of special equipment has received increasing attention. Cracks, as a common and highly hazardous defect type in special equipment, their early and accurate detection is of great significance for ensuring equipment safety. Traditional ultrasonic testing methods face problems such as large signal noise and strong reliance on manual experience in crack identification. In recent years, deep learning technology, with its powerful capabilities in automatic feature extraction and pattern recognition, has become an important means to enhance the accuracy and efficiency of ultrasonic testing. This paper systematically studies the ultrasonic crack detection technology for special equipment based on deep learning, focusing on discussing key technical links such as data preprocessing, model design, crack identification and location, and verifies the superior performance of this method in crack detection through experiments. The research results show that deep learning significantly improves the accuracy and robustness of crack detection, providing new ideas and technical support for the development of non-destructive testing technology for special equipment.

Keywords : deep learning; special equipment; crack detection; ultrasonic testing; non-destructive testing; signal processing

引言

特种设备广泛应用于电力、化工、冶金等关键行业, 其安全运行直接关系到人员生命财产安全和社会稳定。设备在长期运行过程中, 容易因腐蚀、疲劳等原因产生裂纹缺陷, 若未能及时发现和处理, 将导致设备性能下降甚至发生严重事故。因此, 裂纹的早期检测与准确识别成为特种设备安全保障的核心环节。

超声检测作为一种成熟的无损检测技术, 因其穿透力强、检测灵敏度高、无辐射污染等优点, 被广泛应用于裂纹检测领域。然而, 传统超声检测依赖于专业人员的经验分析, 且检测信号常受环境噪声影响, 导致误检、漏检问题较为突出, 检测效率和准确性难以满足现代工业生产的需求。

一、特种设备裂纹超声检测技术概述

(一) 特种设备及裂纹缺陷简介

特种设备是指在工业生产和社会生活中，承担重要安全职责，运行过程对人身安全和环境保护有较高风险的设备，主要包括锅炉、压力容器、电梯、起重机械及管道等。这类设备普遍承受高温、高压及复杂工况，长期运行中容易出现材料疲劳、腐蚀、制造缺陷等问题，进而导致裂纹产生。裂纹作为一种典型的结构缺陷，具有隐蔽性强、扩展速度快的特点，一旦未及时发现，极易引发设备失效甚至重大安全事故。因此，裂纹的早期准确检测对特种设备安全运行具有重要意义。

(二) 超声检测技术原理及应用

超声检测是一种基于高频声波传播特性进行材料内部缺陷检测的无损检测方法。其基本原理是利用超声波发生器产生高频声波，通过换能器将其导入被测件内部。当声波遇到裂纹、夹杂物或界面等不连续区域时，会发生反射、散射或衍射，换能器接收回波信号，通过分析回波的时域、频域特征实现缺陷的定位和尺寸评估。超声检测具有穿透深度大、灵敏度高、对人体无害等优点，广泛应用于特种设备内部裂纹检测、厚度测量及结构完整性评估。

(三) 传统超声检测技术的局限性

尽管超声检测技术已相对成熟，但传统方法在实际应用中仍存在诸多挑战。首先，超声信号往往受到环境噪声、设备振动以及材料各向异性等影响，导致回波信号复杂且易混淆，给裂纹识别带来困难。其次，检测结果高度依赖检测人员的经验和技术水平，存在主观判断差异，容易产生误检或漏检。此外，传统数据处理方法多依赖人工设计特征和简单阈值判定，缺乏对复杂信号模式的深层次挖掘，限制了检测精度和自动化水平。再者，面对复杂结构或多层复合材料，超声波的传播路径和反射模式更加复杂，传统检测手段难以全面准确识别裂纹。

二、深度学习技术基础

(一) 深度学习简介

深度学习是机器学习的一个分支，主要通过构建多层神经网络模型来实现对数据的高级抽象和特征自动提取。与传统的浅层学习模型相比，深度学习能够从原始数据中自动学习出复杂的、层级化的表示形式，无需依赖人工设计特征，极大地提升了模型的表达能力和泛化性能。

深度学习的基本单元是人工神经网络，其结构模拟人脑神经元的连接方式，包含输入层、多个隐藏层和输出层。通过逐层非线性变换，神经网络能够捕捉输入数据中的高维复杂关系。常见的深度学习网络结构包括卷积神经网络、循环神经网络、生成对抗网络等。

卷积神经网络（CNN）主要用于处理图像和二维信号，利用局部感受野、权重共享等机制，有效提取空间特征，广泛应用于图像识别和视觉检测领域。

循环神经网络（RNN）适合处理序列数据，如语音、时间序列信号等，能够捕捉时间上的动态变化和上下文依赖。

生成对抗网络（GAN）通过两个神经网络相互对抗训练，实现高质量数据生成和增强，提升模型的鲁棒性和泛化能力。

(二) 深度学习在图像和信号处理中的优势

1. 自动特征提取

传统图像和信号处理方法往往依赖人工设计特征，如边缘、纹理、频域特征等，这不仅需要专业领域知识，而且难以适应复杂多变的应用环境。深度学习通过多层神经网络结构，能够自动从原始数据中学习到有区分度的特征，涵盖从低级边缘到高级语义的多层次表达，极大地简化了特征工程过程。

2. 处理复杂非线性关系能力强

图像和信号数据通常包含大量非线性和时空相关性。深度学习模型利用非线性激活函数、多层结构和递归机制，能够捕获复杂的模式和时序关系，提高识别和分类的准确率。例如，卷积神经网络能识别图像中的局部模式和全局结构，循环神经网络能有效建模信号中的时间依赖性。

3. 鲁棒性和泛化能力优异

深度学习通过大规模数据训练，能够自动适应不同噪声水平、变形和失真，提高模型在实际复杂环境中的鲁棒性。此外，数据增强、正则化等技术进一步增强了模型的泛化能力，减少过拟合风险，确保模型在未见样本上的良好表现。

4. 端到端学习能力

深度学习支持端到端训练，将输入的原始图像或信号直接映射到最终检测或分类结果，避免了传统方法中多步骤处理带来的信息损失和误差传递，简化了处理流程，提升了系统整体性能。

5. 可扩展性和适应性强

深度学习模型结构灵活，可以根据不同任务和数据特点进行设计和调整，如增加网络深度、宽度，结合注意力机制、多任务学习等，实现多样化的应用需求。此外，模型易于迁移学习和在线更新，适应不同场景和设备的变化。

三、基于深度学习的超声检测方法研究

(一) 数据采集与预处理

数据质量直接影响深度学习模型的训练效果和检测性能，因此，超声检测数据的采集和预处理是关键环节。

数据采集系统：采用高精度超声探伤仪和相应的换能器对特种设备进行扫描，获取高分辨率的超声回波信号。采集过程中需控制探头位置、扫描速度及耦合介质，保证信号质量和一致性。

数据格式与存储：采集的超声信号通常为时域波形或B扫描图像，数据量大且维度高，需合理设计数据存储格式与管理机制，支持后续快速读取与处理。

信号预处理：包括去噪、归一化和数据增强等。去噪技术如小波变换、中值滤波和自适应滤波用于降低环境噪声影响，提高信号信噪比。归一化处理可减小不同设备、环境条件下数据分布差异。数据增强方法如时间翻转、幅度调整和随机裁剪等，扩充训练样本多样性，增强模型泛化能力。

(二) 特征提取与表示

传统超声检测依赖人工设计特征，如时域峰值、频域能量等，难以全面描述复杂裂纹信息。深度学习自动学习多层特征表达，有效提升识别能力。

自动特征提取：采用卷积神经网络（CNN）自动提取多尺度、多层次的空间特征，从原始超声信号或图像中捕获裂纹的局部纹理和全局形态。

时序特征处理：对于超声波的时域信号，结合循环神经网络

(RNN) 或长短时记忆网络 (LSTM) 模型, 学习时间动态特性, 有助于识别裂纹的信号演变规律。

多模态特征融合: 结合多种超声检测模式 (如 A 扫描、B 扫描、相控阵数据) 提取特征, 通过特征融合技术整合多源信息, 提升检测的准确性和鲁棒性。

特征可视化与解释: 利用梯度加权类激活映射 (Grad-CAM) 等技术, 辅助理解模型关注区域, 提高检测结果的可信度。

(三) 裂纹检测模型设计

深度学习模型的设计直接决定裂纹检测效果, 需结合超声信号特点和检测需求进行合理构建。

模型结构选择: 常用 CNN 结构如 ResNet、DenseNet 因其较强的特征提取能力被广泛采用, 结合轻量化设计满足实时检测需求。

网络深度与宽度调节: 通过调整网络层数和通道数平衡模型复杂度和计算开销, 避免过拟合或欠拟合。

多任务学习设计: 同时完成裂纹检测、分类与定位任务, 提高模型的综合能力和检测效率。

损失函数设计: 针对不平衡数据问题, 引入加权交叉熵、焦点损失 (等, 提升对少数类裂纹样本的识别能力。

训练策略: 采用迁移学习初始化模型参数, 结合数据增强和正则化方法提升模型稳定性。通过学习率调度、早停策略优化训练过程。

(四) 裂纹识别与定位

准确识别裂纹存在与否并定位其具体位置, 是超声检测的核心目标。

分类方法: 基于训练好的深度模型, 对输入超声信号或图像进行裂纹与非裂纹的二分类判断, 或多类别裂纹形态分类。

目标检测技术: 利用目标检测框架 (如 FasterR-CNN、YOLO) 实现裂纹区域的自动定位, 输出裂纹边界框及置信度。

语义分割: 采用全卷积网络 (FCN)、U-Net 等分割模型, 实现对裂纹形态的精细分割, 提供像素级裂纹区域信息, 支持裂纹尺寸和形状评估。

多尺度检测: 结合不同尺度特征, 提高对大小不同裂纹的检测能力, 增强模型对微小裂纹的敏感性。

后处理技术: 基于形态学操作和连通域分析, 优化检测结果, 去除伪影, 提高定位准确度。

(五) 模型性能评估指标与验证方法

科学合理的性能评估是验证检测模型有效性和推广应用的基础。

常用指标:

准确率 (Accuracy): 整体正确识别的比例, 适合类别均衡数据。

精确率 (Precision): 检测为裂纹样本中真正裂纹的比例, 反映误报率。

召回率 (Recall): 真实裂纹样本被正确检测的比例, 反映漏检率。

F1 分数: 精确率与召回率的调和平均, 综合评价模型性能。

ROC 曲线及 AUC 值: 评估模型在不同阈值下的分类性能。

定位精度: 采用交并比 (IoU) 评估检测框与真实裂纹区域的重叠度, 衡量定位准确性。

鲁棒性测试: 在不同噪声水平、设备型号和工况条件下验证模型稳定性。

交叉验证与测试集验证: 采用多折交叉验证减少偶然性, 确保模型泛化能力。

对比分析: 将深度学习模型与传统方法或其他先进方法进行性能对比, 体现技术优势。

四、实验设计与结果分析

(一) 实验平台与数据集介绍

实验平台主要包括高精度超声检测设备与计算分析系统。超声检测仪器选用某型号相控阵超声探伤仪, 配备多频段换能器,^[1] 保证采集数据的高分辨率和多样性。数据采集环境模拟工业现场真实工况, 涵盖不同材料、厚度和裂纹类型。

所用数据集包括自主采集的特种设备裂纹超声波信号数据以及公开数据集。数据集涵盖 A 扫描波形、B 扫描图像及相控阵数据, 样本数量达到数千组, 涵盖裂纹与非裂纹样本, 裂纹类型包括表面裂纹、内部裂纹及疲劳裂纹, 尺寸和形态多样, 满足模型训练的需求。数据经过严格标注与审核, 确保标签准确性^[2]。

(二) 实验方案设计

实验方案分为数据预处理、模型训练、验证测试三阶段。预处理环节对超声信号进行去噪、归一化及数据增强, 增强数据多样性。模型训练采用卷积神经网络 (CNN) 结构, 基于迁移学习策略, 初始化权重加速收敛。训练中采用交叉熵损失函数和 Adam 优化器, 设定学习率调度策略防止过拟合。

(三) 结果展示与对比分析

实验结果显示, 基于深度学习的超声裂纹检测模型在准确率、召回率和 F1 分数方面均显著优于传统方法。例如, 模型在测试集上的准确率达到 92% 以上, 召回率和精确率均超过 90%, 而传统方法平均准确率不足 85%。此外, 模型在定位裂纹边界的交并比 (IoU) 指标上表现优异, 实现了裂纹形态的精细分割。

五、结束语

特种设备作为关系公共安全和工业生产的重要装备, 其结构完整性直接影响运行的安全与稳定。裂纹作为最具危险性的结构性缺陷之一, 亟需高效、可靠的检测技术加以识别与定位。本文围绕基于深度学习的裂纹超声检测技术展开系统研究, 从数据采集与预处理、特征提取、模型构建到识别与定位方法进行了深入探讨, 并通过实验证明了该技术在提高检测精度、自动化水平及鲁棒性方面的显著优势。

参考文献

- [1] 方昊昱, 向林浩, 尹康迪, 等. 基于目标检测技术的主船体结构外部裂纹检测方法 [J]. 船海工程, 2024, 53(2): 45-49.
 [2] 王斌, 赵义鹏, 孟豪, 等. 基于改进 YOLOv5 的金属构件表面裂纹检测 [J]. 信息技术与信息化, 2023(11): 90-94.