

图谱数据深度学习融合模型及 焊缝缺陷识别方法

支泽林^{1,2}, 姜洪权¹, 杨得焱¹, 程志翔¹, 高建民¹, 王泉生², 王晓桥², 王景人², 石养鑫³

(1. 西安交通大学机械制造系统工程国家重点实验室, 710049, 西安; 2. 陕西省特种设备检验检测研究院, 710048, 西安; 3. 西安优耐特容器制造有限公司, 710201, 西安)

摘要: 针对当前利用超声衍射时差法(TOFD)图谱数据进行缺陷类型判定时以人工判别为主, 主观性大、效率低以及缺乏从波形特征及图像特征进行集成分析的问题, 提出了一种深度学习融合模型及焊缝缺陷识别方法。通过对 TOFD 检测原理及缺陷检测图谱数据特点进行分析, 建立了综合考虑波形数据和图像数据的缺陷特征表征方法, 实现了缺陷标准数据集构建; 通过构建基于时间卷积网络(TCN)的波形序列数据分析模块、基于卷积神经网络(CNN)的图像数据分析模块以及特征自适应融合分类模块, 建立了一种可以实现波形序列特征与图像特征综合分析的深度学习融合网络模型(DLFM)及模式分类方法。以企业实际 TOFD 检测焊缝缺陷数据对所提方法进行了验证, 结果表明所提 DLFM 方法对缺陷类型的识别率明显高于单独使用基于 TCN、CNN 以及 CNN-TCN 的方法; 所提方法拓展了现有深度学习模型的构建方法, 并可以推广应用到其他模式识别领域, 具有较强的通用性。

关键词: 超声衍射时差法; 焊缝缺陷识别; 自适应融合; 深度学习

中图分类号: TP391 **文献标志码:** A

DOI: 10.7652/xjtuxb202105009 **文章编号:** 0253-987X(2021)05-0073-10



OSID 码

A Deep Learning Fusion Model of Wave and Image Data for Weld Defect Recognition

ZHI Zelin^{1,2}, JIANG Hongquan¹, YANG Deyan¹, CHENG Zhixiang¹, GAO Jianmin¹,
WANG Quansheng², WANG Xiaoqiao², WANG Jingren², SHI Yangxin³

(1. State Key Laboratory for Manufacturing Systems Engineering, Xi'an Jiaotong University, Xi'an 710049, China;

2. Shaanxi Special Equipment Inspection and Testing Institute, Xi'an 710048, China;

3. Xi'an United Pressure Vessel Co., Ltd., Xi'an 710201, China)

Abstract: Aiming at the problems of manual identification, subjectivity, low efficiency, and lack of integrated analysis from waveform features and image features in using the time-of-flight, diffraction (TOFD) data for weld defect recognition, a deep learning fusion model (DLFM) and a weld defect recognition method are proposed. Based on the analyses of TOFD detection principle and weld defect detection data characteristics, a defect feature representation method considering waveform data and image data is set up, and the defect standard data set is established. Combining waveform sequence data analysis module based on time convolution network (TCN), image data analysis module based on convolutional neural network (CNN) and feature adaptive

收稿日期: 2020-10-11。 作者简介: 支泽林(1982—),男,博士生;姜洪权(通信作者),男,副教授,博士生导师。 基金项目: 陕西省市场监管局专项资助项目(2019KY05);国家质量基础的共性技术研究与应用重点研发计划资助项目(2017YFF0210502);陕西省特检院科技计划资助项目(SXTJKJXM-202003)。

网络出版时间: 2021-02-01

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1069.T.20210201.1429.002.html>

fusion classification module, the DLFM with pattern classification is constructed. A case study of TOFD weld defect recognition is conducted to illustrate the work. The results show that the proposed DLFM has higher defect recognition rate than the method based on CNN, TCN or CNN-TCN. The proposed method improves the traditional deep learning models, and can be applied to the other pattern recognition fields with stronger universality.

Keywords: time-of-flight diffraction; weld defect recognition; feature adaptive fusion; deep learning

能源动力、航空航天、船舶等领域大型装备制造过程中大量采用焊接工艺,焊缝缺陷的检测与评价是保证装备在服役过程中安全可靠运行的重要手段。超声衍射时差法(TOFD)具有检测信息丰富、抗噪声强、效率高、定位定量准确等优势,已成为最为广泛的焊缝无损检测方法之一^[1-2]。例如,陕西省特检院在特种设备焊缝检验检测过程中采用了TOFD检测技术,2020年全年的TOFD检测焊缝图谱数据累计已达5万余米。目前在利用数据进行缺陷识别时主要采用人工评判方式,受成像机理、焊缝组织、检测环境的影响,TOFD检测图谱数据易产生噪声及条纹干扰^[3],缺陷识别效率低下、主观性大、误判率高。因此,开展以TOFD检测图谱数据为对象的焊缝缺陷类型识别方法,对提升缺陷检测能力及装备质量管控能力具有重要意义。

随着TOFD检测技术逐步应用和检测数据的积累,如何利用图像处理及模式识别技术提高缺陷识别效率、减少人工识别不一致性已经成为重点关注问题^[4]。文献[5]利用傅里叶变换对TOFD衍射信号(A扫波形信息)的频率进行分段特征分析,并结合神经网络进行缺陷检测;文献[6]利用TOFD-D扫图像数据,首先提出一种基于分水岭的缺陷区域分割技术,再利用人工识别以提高缺陷识别的准确性;文献[7]通过对TOFD直通波信息进行分析与特征提取,并采用BP神经网络对近表面缺陷进行识别分类;文献[8]利用TOFD-B扫图像转化成波信号,通过分析波的传播时间、振幅大小等特征实现厚壁构件进行表面缺陷的分析。以上主要是以区域分割—特征提取—类型识别的串联式思路进行研究,且主要关注近表面缺陷分析。显然,串联式方法每个环节的准确与否对于最终识别精度和效率有着重要影响。随着深度学习等理论的发展,以无损检测图像数据为对象开展端到端识别方法的研究逐步引起关注^[9],但在以TOFD检测图像数据为对象的缺陷识别技术研究还不多见。文献[10]首先探讨了TOFD-D扫描图像缺陷轮廓与图像特征的关系,然

后利用快速卷积神经网络(Faster RCNN)对缺陷进行分类,该方法可以克服传统串联式方法的不足,但容易对TOFD数据中的界面波及噪声造成缺陷误判。

综上所述,传统串联式技术思路已经不能满足当前具有海量数据特征的TOFD检测数据的分析与应用,以深度学习理论为基础的端到端方法将是未来研究重点之一^[11-12]。虽然TOFD检测图谱的波形数据和图像数据分别蕴含着重要的缺陷信息,但现有方法主要分别以A扫、B扫、D扫产生的波形数据或者图像数据单独进行分析,缺乏两种数据的综合分析,制约了缺陷的识别效率和精度。

针对以上问题,本文提出了一种可实现图像特征、波形特征融合分析的TOFD焊缝缺陷类型识别技术。首先,结合TOFD图谱成像特点,提出了一种综合考虑图像和波形的缺陷数据集构建方法;然后,构建了一种可分别对TOFD图像数据和波形数据进行分析的多模块深度学习网络模型,并在全连接层采用特征自适应融合方法实现缺陷类型的识别。最后,本文以企业实际TOFD检测数据对所提方法进行了验证。

1 TOFD焊缝缺陷表征及数据集构建

1.1 TOFD检测技术概述

TOFD检测是一种可利用从待检试件内部缺陷的“端角”和“端点”处得到的衍射能量来检测缺陷的方法^[1,13]。TOFD检测技术及图谱成像原理如图1所示,TOFD检测过程中采用双探头一发一收模式,两个探头具有相同频率、角度及晶片尺寸,可将探头横跨焊缝两侧进行非平行及平行扫查。如图1a所示,当发射纵波遇到缺陷后,将在缺陷上、下端点产生衍射波2和3,接收探头在接收A扫描信号的同时,同步产生相对应的D扫二维图像,图像中会在直通波1和底面反射波4之间出现缺陷波。通过一系列A扫描信号构成一幅TOFD检测图像,如图1b所示,接收衍射波A扫信号经过处理形成不同的灰度图像,利用灰阶度表示波幅大小,例如当波形向

正半周期变化时,灰度向白色渐变;当波形向负半周期变化时,灰度向黑色渐变。





图 1 TOFD 检测技术及图谱成像原理

Fig. 1 TOFD detection technology and mapping principles

1.2 综合图像与波形特征的缺陷表征及数据集构建

TOFD 图谱数据实际上包含了图像和波形两种数据,即缺陷的特征信息应该从图像数据和波形数据两个方面来考虑。实际上,当前 TOFD 技术人员在分析缺陷时,既要观察图像数据,也要结合波形数据进行分析。

在 TOFD 检测图像数据中截取可以完整包含缺陷的区域,TOFD 检测焊缝缺陷类型如图 2 所示。一般的,TOFD 检测缺陷类型可分为表面开口型缺陷和内部埋藏型缺陷。本文主要关注内部埋藏型缺陷的识别问题,可以分为 4 种类型:①点状缺陷一般为气孔和点状夹渣,危害程度小,缺陷呈双曲线弧状,缺陷图像尾部向底面坠落,不具有长度和高度;②线状缺陷一般为裂纹缺陷,缺陷的上下端点衍射信号混叠,两端曲线接近水平,不具有明显高度;③条状缺陷一般为夹渣、未熔合、未焊透等缺陷,显示为长条状,上下两个端点产生的衍射信号,且靠近底面处产生的衍射信号相位与直通波相位相同,靠近扫查面处端点产生的衍射信号相位与直通波相位;④无缺陷是在焊缝中不会有衍射信号,在图像没有

明显的灰度变化。




Fig. 2 Weld defect types detected by TOFD

由图 1b 可知,缺陷图谱中每一列即对应着不同的波形数据,尤其是在缺陷区域两个端点处,波形将会有明显的区别。假设获取缺陷长度为 d ,缺陷区域及其 A 扫位置如图 3 中的虚线框及垂直线段所示,则可分别在缺陷左端点、 $d/2$ 处、右端点 3 个位置处获取对应的 A 扫波形数据。图 4 给出了缺陷图谱中不同位置点对应的波形图。可以看出,获得的 3 个波形数据具有不同的形式,且可以明确表







Fig. 3 Defect region and A-scan position





(c)缺陷右端点处波形图

图 4 缺陷图谱中不同位置点对应的 A 扫波形图

Fig. 4 A-scan waveforms corresponding to different positions in defect spectrum

达缺陷灰度变化情况。因此,依据缺陷图像数据和波形数据可以更加完整地表征该类缺陷,可以用来作为缺陷类型识别的数据基础。

2 基于深度学习融合模型的缺陷类型识别方法

2.1 基于卷积神经网络与时间卷积网络的深度学习融合模型构建

针对缺陷类型的识别需要综合考虑 TOFD 图像数据和波形数据需求,本文以深度学习理论中卷积神经网络(CNN)和时间卷积神经网络(TCN)^[14-17]为基础,提出一种可综合考虑两种类型数据的深度学习融合模型(DLFM),如图 5 所示。DLFM 包括 3 个部分,即用于分析缺陷二维图像数据特征的 CNN 模块、用于分析一维波形数据特征的 TCN 模块以及用于特征自适应融合分类模块。

在 CNN 模块中,本文采用 7 层的卷积神经网络实现缺陷二维图像特征分析。CNN^[14]是当前图像识别领域应用最广泛的图像特征提取方法,它的本质是一种能够学习输入到输出的映射关系,而不需要任何输入和输出之间的精确数学表达式,只要用已知的模式对卷积网络加以训练,网络就具有输入输出对之间的映射能力。本文采用的 CNN 模块结构如表 1 所示,输入层为 Input,卷积层为 Conv;池化层为全局最大池化层 MaxPooling,使用全 0 填充,激活函数使用线性整流函数 ReLu;展开层为 Flatten;全连接层为 Dense; s 和 c 分别代表卷积核的移动步长和个数; n 代表全连接层神经元的个数。Input 层中 $(N,64,64,1)$ 的 4 个量分别代表图像个数、图像宽、高以及图像通道数。本文输入图像宽 $\times$ 高为 64×64 ,图像通道数为 1,即为灰度图像;输出为长度 32 的一维图像特征向量;同时,也将输出 32 个特征对应的重要性系数 $\alpha_i(i=0,1,\cdots,31)$ 。

表 1 图像特征提取的 CNN 模块结构

Table 1 CNN module structure for image feature extraction

结构层次	输出数据维度
输入	$(N,64,64,1)$
Conv1, $3\times3,s=1,c=6$	$(N,62,62,6)$
Pool1, $2\times2,s=2,\text{Relu}$	$(N,31,31,6)$
Conv2, $3\times3,s=1,c=16$	$(N,29,29,16)$
Pool2, $2\times2,s=2,\text{Relu}$	$(N,15,15,16)$
Flatten	$(N,3\ 600)$
Dense 层神经元数为 32	$(N,32)$

2.2 基于 TCN 的缺陷波形数据特征分析

在用于分析缺陷波形数据特征的 TCN 模块,考虑到 A 扫波形遇到缺陷信号会发生衍射现象,将产生明显的幅值波动,而反映到图谱中则是具有明显的灰度变化,因此,可采用反应数据波动变化的方差作为衡量波形幅值波动程度的指标,其计算公式如下

$$s_j = \frac{1}{w-1} \sum_{i=1}^w (D_{ij} - \bar{D})^2, j = 0, 1, 2, \cdots, w \quad (1)$$

式中: s_j 为图像中第 j 列对应的超声信号波动值; w 为第 j 列的像素点个数; D_{ij} 为第 i 行第 j 列的灰度值; $\bar{D}$ 为第 j 列的灰度平均值。为了关注波幅变化情况,设定阈值 S ,用来界定缺陷区域和非缺陷区域。若超出阈值的波动点作为关注的波形数据,并记所在列为 $q=(m,\cdots,n)$,则 1.2 节所述的缺陷左端点、 $d/2$ 处、右端点所对应波形数据为第 m 、 $\left[\frac{m+n}{2}\right]$ 、 n 列,即为本文 TCN 模块所需的缺陷波形数据。

例如,设缺陷图像高 91、宽 103,图像的超声信号波动分布如图 6 所示,则利用式(1)对其响应 A 扫波的波动程度计算结果为

$$S=(s_1,\cdots,s_{102},s_{103})=(8.56,83.8,\cdots,9.79) \quad (2)$$

取 $S=1\ 000$,可得 $q=(44,45,46,\cdots,56,57,58,59)$,则用于 TCN 模块的 3 个代表缺陷的波形数据分别为 $m=44$, $\left[\frac{m+n}{2}\right]=51$ (取整), $n=59$ 列。

由图 6 可以看出,缺陷区域对应的 A 扫波的波动程度很大(黄色),非缺陷区域的 A 扫波的波动程度较小(蓝色)。一般的,在选取阈值 S 时,可以通过对整体数据集的波动程度进行分析来确定。如图 6 所示, S 值域范围约在 $0\sim2\ 500$ 范围内,且在 $S>1\ 000$ 时,该列波数据对应区域为有缺陷区域,因此,本文后续将选取 $S=1\ 000$ 作为波动度量阈值。




图 5 基于 CNN 和 TCN 的缺陷识别双通道深度学习模型

Fig. 5 A dual-channel deep learning model for defect recognition based on CNN and TCN




图 6 图像的超声信号波动分布图

Fig. 6 Distribution of ultrasonic signal fluctuation in image

由于获得缺陷波形数据是一类典型的一维序列数据,本文将采用 TCN 对波形数据进行分析。TCN 是新提出的一种深度学习网络模型^[15-16],该模型将卷积操作应用在时间序列数据中,不仅比传统 RNN 法^[17-18]具有更快的训练速度,同时更加擅长捕捉时序上的依赖关系,而且因为使用了卷积可以捕捉到局部信息,图 7 给出了基于时间卷积神经网络的波形特征分析模型。其中,dcn 膨胀因果卷积层^[8]一共有 3 层,膨胀系数 e 分别为 1,2,4,输入为 TOFD 图谱焊缝缺陷对应的第 m 、 $\left[\frac{m+n}{2}\right]$ 、 n 列 3 个波形,输出为长度 32 的一维时间序列的特征向量;同时,也将输出 32 个特征对应的重要性系数 β_i ($i=0,1,\cdots,31$)。

表 2 所示为本文所用 TCN 模块的结构。其

中,输入层 Input 中的 $(N,64,3)$ 分别代表波形数据组的个数、波形长度和一个波形组含有 3 段超声波序列。其中 dcn 为 TCN 的基本模块,dcn 中的卷积核大小指的是残差连接中两个非 1×1 卷积核的大小,卷积核的滑动步长设置为 1,网络中用到的激活函数为 ReLu。

表 2 波形特征提取的 TCN 模块结构参数

Table 2 TCN module structural parameters for waveform feature extraction

结构层次	输出数据维度
输入	$(N,64,3)$
dcn, $3\times 3,e=1,c=32$	$(N,64,32)$
dcn, $3\times 3,e=2,c=16$	$(N,64,16)$
dcn, $3\times 3,e=4,c=8$	$(N,64,8)$
Flatten	$(N,512)$
Dense	$(N,32)$

通过利用 TCN 深度学习网络,可以捕捉缺陷 TOFD 检测波形数据在时序上的依赖关系,同时也可以捕捉到波形数据局部变化特征信息。

2.3 CNN 与 TCN 模型的特征自适应融合策略

由于不同的特征对缺陷类型分析具有不同的重要程度,因此在融合 CNN 模块和 TCN 模块特征时需要重点解决特征的重要性问题^[19-20]。对于获得的 32 个图像特征及其 32 个特征对应的重要性系数 α_i ($i=0,1,\cdots,31$),和 32 个波形特征及其 32 个特征对应的重要性系数 β_i ($i=0,1,\cdots,31$),在融合模块




图 7 基于时间卷积神经网络(TCN)的波形特征分析模型

Fig. 7 Analysis model of waveform features based on time convolution neural network (TCN)

中增加以下约束关系

$$\alpha_i + \beta_i = 1, i = 0, 1, \dots, 31 \quad (3)$$

上述 $\alpha_i (i=0, 1, \dots, 31)$ 和 $\beta_i (i=0, 1, \dots, 31)$ 可以作为对应特征重要性系数进行融合分析。

具体的,在 CNN 模块和 TCN 模块基础上构建一个特征自适应融合分类模块,如图 8 所示,CNN 图像处理模块提取的特征向量会输入到共享全连接层 1,在输出 32 个图像特征向量的同时,会输出同样维度的图像特征重要性向量;TCN 波形处理模块提取的特征向量输入到共享全连接层 2,在输出 32 个波形特征的同时,会输出同样维度的波形特征重要性向量。两种特征的重要性向量通过一个 Sigmoid 函数进行归一化,使得两者之和为 1,计算出图像特征重要性系数和波形特征重要性系数,再与图像特征和波形特征相乘之后相加,即可获得自适应融合特征。需要指出的是,CNN 模块和 TCN 模块获得的高维特征(如 $f_{pic-0}, \dots, f_{pic-31}$ 等)是对输入图数据或者波数据的特征提取结果,不包括重要度信息。其计算过程如下

$$f_{pic} = F_{CNN}(D_{image}) \quad (4)$$




图 8 缺陷的图像特征与波形特征自适应融合

Fig. 8 Adaptive fusion of image features and waveform features of defects

$$f_{wav} = F_{TCN}(D_{waves}) \quad (5)$$

$$f_{fu-i} = f_{pic-i}\alpha_i + f_{wav-i}\beta_i \quad (i = 0, 1, \dots, 31) \quad (6)$$

式中: F_{CNN} 、 F_{TCN} 分别是 CNN 模块和 TCN 模块所代表的变换函数。

最后,利用 Softmax 层进行缺陷类型的分类。Softmax 层作为分类器相当于多层感知机,如图 5 所示,输入 TOFD 检测焊缝缺陷的融合特征后,即输入长度 32 的一维特征向量,输出为每个类别对应的概率大小,概率最大的即为缺陷分类结果。此外,本文所述模型的损失函数选择交叉熵损失函数如下式

$$L = - \sum_i (y_i \ln(a_i)) \quad (7)$$

式中: L 为损失值, y_i 为真实值, a_i 为预测值;网络参数的自适应学习使用 Adam 优化器,Adam 可以替代传统随机梯度下降过程,它能基于训练数据迭代地更新神经网络权重,具有很强的鲁棒性。

综上所述,对于待分析缺陷的 TOFD 检测图谱,通过 CNN 模块、TCN 模块及特征自适应融合分类模块,可以综合考虑图像特征和波形特征进行缺陷类型分类。

3 实例说明

本文利用某企业在 2020 年检测压力球罐的 TOFD 数据进行验证。数据集包括 1 432 例 TOFD 缺陷检测图谱数据划分, 如表 3 所示, 数据集类型分为无缺陷、点状缺陷、线状缺陷、条状缺陷 4 类; 并按照 8:1:1 的比例, 将数据集随机划分为训练集、验证集、测试集, 其中训练集 1 143 例, 验证集 147 例, 测试集 142 例。训练集用来训练所提模型参数, 验证集则是在训练的过程中调整模型参数, 测试集用来评价模型识别结果。

表 3 TOFD 焊缝缺陷数据划分

Table 3 Division of TOFD weld defect data set

数据集	无缺陷	点状缺陷	线状缺陷	条状缺陷	合计
训练集	288	280	285	290	1 143
验证集	37	36	37	37	147
测试集	36	35	35	36	142

为验证本文所提基于 DLFM 方法的有效性, 将基于 DLFM 与传统 TCN、CNN、CNN-TCN 的方法进行对比分析。基于 TCN 的方法是依据本文 2.2 节所述仅采用 TOFD 波形数据进行缺陷识别分析, 基于 CNN 的方法是依据本文 2.1 节所述仅对 TOFD

图像数据进行缺陷识别分析, 基于 CNN-TCN 的方法是在无重要性系数时图像特征与波形特征融合进行缺陷识别分析。4 种方法共同采用表 3 所述的数据进行训练、验证和测试, 迭代次数均为 500。为避免实验过程的随机性影响, 按照表 3 所示训练集、验证集及测试集划分比例对整个数据集进行随机选取, 重复进行 9 次实验, 并计算实验平均值及上下偏差作为该方法的最终识别结果。

表 4 所示为分别采用基于 TCN、CNN、CNN-TCN 以及本文所提方法实现缺陷类型识别的结果。可以看出, 相对于基于 CNN、DLFM、CNN-TCN 的方法, 基于 TCN 的方法在验证集和测试集上识别率都是最低的, 且识别率与其他方法相差较大。这是因为 TCN 主要关注的是一维序列的波形特征, 这类特征显然不足以有效刻画不同缺陷模式的区别; 而基于 CNN、CNN-TCN 和 DLFM 的方法都包含对图像特征的分析, 由图 2 可以看出, 不同缺陷模式的图像特征是很明显的, 因此, 包含图像特征的缺陷类型识别方法将明显提高识别率。同时, 表 4 也表明基于 DLFM 的方法由于结合了 TOFD 检测数据的波形特征和图像特征并且考虑了重要性系数, 因此在测试集上具有最好的缺陷识别率($(88.028 \pm 0.70)\%$)。

表 4 不同方法对不同种类缺陷分类测试结果对比

Table 4 Comparison of defect recognition results by different methods

分类网络	模型结构	验证集识别率	测试集识别率
TCN	膨胀卷积+因果卷积+输出类别	$(76.87 \pm 3.40)\%$	$(73.239 \pm 2.11)\%$
CNN	卷积+池化+激活+全连接层+输出类别	$(84.35 \pm 2.04)\%$	$(85.915 \pm 1.41)\%$
CNN-TCN	图像特征+波形特征	$(86.40 \pm 1.36)\%$	$(83.802 \pm 2.82)\%$
DLFM	图像特征+波形特征+自适应融合	$(87.07 \pm 0.68)\%$	$(88.028 \pm 0.70)\%$

表 5 所示为基于 TCN、CNN、CNN-TCN 及本文所提方法 DLFM 4 种方法对于不同缺陷种类的分类结果。首先, 可以看出对无缺陷模式, 4 种方法在测试集上都可达到 100% 的识别精度, 即利用 TOFD 检测数据对产品缺陷检测率非常高。实际上, TOFD 作为一种先进无损检测方法, 其检测数据中的无缺陷模式与有缺陷模式具有很强的区别(如图 4 所示), 在图谱上很容易判别无缺陷模式, 因而相对无损射线检测等其他检测方法, TOFD 检测技术在检测产品内部缺陷时具有较高的灵敏度和可靠性。

由表 5 可以看出, 不同方法对于不同缺陷类型具有不同的识别率。其中, 基于 TCN 的方法不但对所有缺陷类型识别率低, 尤其是对线状缺陷识别

率最低, 即将 37.14% 线状缺陷错分为条状缺陷。由图 7 所示的 TCN 模型可知, 由于线状缺陷与条状缺陷主要在缺陷高度上存在较小差异, 仅依据贯穿于缺陷区域的 3 条波形特征很难表现这种差异性, 因此基于 TCN 的方法对线状缺陷产生较大的误判率。基于 CNN 的方法对于 3 种缺陷模式的识别率有了很大提高, 但却将 20% 的线状缺陷误判为点状缺陷。由图 2 所示的缺陷形貌特征可看出, 线状缺陷与点状缺陷在高度上较为相似, 在长度上有较大差异; 但由于基于 CNN 的方法仅仅采用缺陷图像特征进行分析, 因此 CNN 网络在池化及网络参数学习过程中体现该两类缺陷长度上差异, 因此对线状缺陷产生较高的误判。基于 CNN-TCN 的

方法对点状缺陷和线状缺陷的识别率反而低于基于 CNN 的方法,这是因为波形特征和图像特征的重要程度不一,简单特征融合无法计算出两者重要度信息,导致识别精度反而降低。

表 5 不同方法对不同种类缺陷分类结果对比

Table 5 Comparison of classification results of different defects by different methods					
方法	缺陷类型	分类识别率/%			
		无缺陷	点状缺陷	线状缺陷	条状缺陷
TCN	无缺陷	100.00	0	0	0
	点状缺陷	0	77.14	8.57	22.22
	线状缺陷	0	8.57	54.29	16.67
	条状缺陷	0	14.29	37.14	61.11
CNN	无缺陷	100.00	0	0	0
	点状缺陷	0	94.29	20.00	5.56
	线状缺陷	0	0	74.29	19.44
	条状缺陷	0	5.71	5.71	75.00
CNN-TCN	无缺陷	100.00	0	0	0
	点状缺陷	0	88.57	20.00	2.78
	线状缺陷	0	5.71	74.29	25.00
	条状缺陷	0	5.71	5.71	72.22
DLFM	无缺陷	100.00	0	0	0
	点状缺陷	0	94.29	0	8.33
	线状缺陷	0	2.86	85.71	19.44
	条状缺陷	0	2.86	14.29	72.22

由表 5 不难看出,本文所提基于 DLFM 的方法在点状缺陷和线状缺陷类型识别上表现出最好的识别率,尤其对其他方法时误判率较高的线状缺陷取得了最大的识别率(85.71%)。这是由于 DLFM 方法包含 TCN 模块,且基于 TCN 的方法对线状缺陷和点状缺陷具有较好的区分能力(例如,仅采用基于 TCN 的方法时,只有 8.57% 的线状缺陷误判为点状缺陷)。因此 DLFM 方法对线状缺陷与点状缺陷具有较强的区分能力,即没有 1 例线状缺陷误判为点状缺陷。DLFM 方法对线状缺陷与条状缺陷类型的区分能力(14.29% 误判率)高于 TCN 的方法(37.14% 的误判率),而低于 CNN 的方法(5.71% 的误判率),即将 14.29% 的线状缺陷误判为条状缺陷;并且,DLFM 的方法识别条状缺陷类型正确率(72.22%),略低于 CNN 对条状缺陷的识别率(75.00%),表明 DLFM 中 TCN 模块的影响比重较大,降低了对线状缺陷与条状缺陷的区分能力。

总体而言,本文所提 DLFM 方法在保证 3 种缺陷类型高识别率基础上,对实际 TOFD 检测过程中最难区分的线状缺陷具有较高识别率,表明了本文所述 DLFM 方法的有效性。

4 结 论

本文提出了一种图谱数据深度学习融合模型及焊缝缺陷识别方法,并通过缺陷识别实例验证了本文方法的有效性,主要结论如下:

(1)本文以焊缝缺陷 TOFD 检测数据为对象,构建了一种综合 TOFD 检测波形特征与图像特征的缺陷数据集表征方法,克服了传统超声检测缺陷仅依据波形或仅依据图像表征缺陷类型方法的不足。

(2)基于传统 CNN 与 TCN 方法,提出了一种可进行缺陷图像特征和波形特征综合分析的深度学习融合模型(DLFM)及自适应特征融合策略,扩展了现有深度学习模型构建方法,实现了波形序列与图像两类数据的综合分析,提高了深度学习模型的模式识别能力。

(3)以企业实际 TOFD 检测焊缝缺陷数据对所提方法进行了验证,结果表明所提 DLFM 方法比传统 CNN、TCN 和 CNN-TCN 方法具有更高的识别率,尤其对于难以识别线状缺陷具有较高识别准确率,为当前 TOFD 检测数据的深层分析与应用提供技术途径。同时,本文方法具有一定普适性,在技术

上可以推广应用到常规超声、相控阵、太赫兹等具有波和图特征的检测数据分析领域;在应用上也可以推广到医学影像等其他领域。

参考文献:

- [1] BABY S, BALASUBRAMANIAM T, PARDIKAR R J, et al. Time-of-flight diffraction technique for accurate sizing of surface-breaking cracks [J]. *Insight-Non-Destructive Testing and Condition Monitoring*, 2003, 45(6): 426-430.
- [2] BASKARAN G, BALASUBRAMANIAM K, LAKSHMANA RAO C. Shear-wave time of flight diffraction (S-TOFD) technique [J]. *NDT and E International*, 2006, 39(6): 458-467.
- [3] PRAVEEN A, VIJAYAREKHA K, ABRAHAM S T, et al. Fourier analysis of ultrasonic TOFD signals for defect detection in austenitic stainless steel welds [J]. *International Journal of Computer Applications*, 2013, 71(9): 14-17.
- [4] 陈尧, 冒秋琴, 石文泽, 等. 基于相位相干性的厚壁焊缝 TOFD 成像检测研究 [J]. *机械工程学报*, 2019, 55(4): 25-32.
CHEN Yao, MAO Qiuqin, SHI Wenze, et al. Research on ultrasonic TOFD imaging inspection for heavy-walled weld based on phase coherence characteristics [J]. *Journal of Mechanical Engineering*, 2019, 55(4): 25-32.
- [5] SILVA L C, FILHO E F S, ALBUQUERQUE M C S, et al. Segmented analysis of time-of-flight diffraction ultrasound for flaw detection in welded steel plates using extreme learning machines [J]. *Ultrasonics*, 2019, 102: 106057.
- [6] 盛朝阳, 刚铁, 迟大钊. 基于分水岭方法的超声 TOFD 检测图像分割 [J]. *机械工程学报*, 2011, 47(8): 35-40.
SHENG Zhaoyang, GANG Tie, CHI Dazhao. Segmentation of ultrasonic TOFD testing image based on watershed method [J]. *Journal of Mechanical Engineering*, 2011, 47(8): 35-40.
- [7] 陈振华, 胡怀辉, 卢超. 基于超声 TOFD 直通波及神经网络的近表面缺陷自动识别 [J]. *无损检测*, 2014, 36(3): 14-17.
CHEN Zhenhua, HU Huaihui, LU Chao. Automatic identification technology of near surface defects based on neural network and through wave of ultrasonic TOFD [J]. *Nondestructive Testing*, 2014, 36(3): 14-17.
- [8] JIN S J, SUN X, MA T T, et al. Quantitative detection of shallow subsurface defects by using mode-converted waves in time-of-flight diffraction technique [J]. *Journal of Nondestructive Evaluation*, 2020, 39(2): 1-8.
- [9] 姜洪权, 贺帅, 高建民, 等. 一种改进卷积神经网络模型的焊缝缺陷识别方法 [J]. *机械工程学报*, 2020, 56(8): 235-242.
JIANG Hongquan, HE Shuai, GAO Jianmin, et al. An improved convolutional neural network for weld defect recognition [J]. *Journal of Mechanical Engineering*, 2020, 56(8): 235-242.
- [10] 黄焕东, 胡利晨, 李斌彬, 等. 基于区域的快速卷积神经网络的焊缝 TOFD 检测缺陷识别 [J]. *无损检测*, 2019, 41(7): 12-18.
HUANG Huandong, HU Lichen, LI Binbin, et al. Recognition of defect in TOFD image based on faster region convolutional neural networks [J]. *Nondestructive Testing*, 2019, 41(7): 12-18.
- [11] HAMMAD M, LIU Yashu WANG Kuanquan. Multi-modal biometric authentication systems using convolution neural network based on different level fusion of ECG and fingerprint [J]. *IEEE Access*, 2019, 7: 25527-25542.
- [12] MARKUS K, FRIEDHELM S. Cascaded fusion of dynamic, spatial, and textural feature sets for person-independent facial emotion recognition [C] // *Proceedings of the 22nd International Conference on Pattern Recognition*. Piscataway, NJ, USA: IEEE Computer Society, 2014: 4660-4665.
- [13] 吕磊, 张艳飞, 谢利明, 等. TOFD 检测技术应用和发展 [J]. *内燃机与配件*, 2020(7): 246-248.
LÜ Lei, ZHANG Yanfei, XIE Liming, et al. Application and development of TOFD detection technology [J]. *Internal Combustion Engine and Parts*, 2020(7): 246-248.
- [14] LÉCUN Y, BOTTOU L, BENGIO Y, et al. Gradient-based learning applied to document recognition [J]. *Proceedings of the IEEE*, 1998, 86(11): 2278-2324.
- [15] BAI Shaojie, ZICO KOLTER J, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling [EB/OL]. (2018-03-04) [2020-08-06]. <https://arxiv.org/abs/1803.01271>.
- [16] GREFF K, SRIVASTAVA R K, KOUTNÍK J, et al. LSTM: a search space odyssey [J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28(10): 2222-2232.

- [17] AL-JANABI S, MOHAMMAD M, AL-SULTAN A. A new method for prediction of air pollution based on intelligent computation [J]. *Soft Computing*, 2020, 24(1): 661-680.
- [18] HANG Renlong, LIU Qingshan, HONG Danfeng. Cascaded recurrent neural networks for hyperspectral image classification [J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(8): 5384-5394.
- [19] WOO S, PARK J, LEE J Y, et al. CBAM: convolutional block attention module [C]// *Proceedings of the 15th European Conference on Computer Vision*. Berlin, Germany: Springer, 2018: 3-19.
- [20] 李伟, 杨向东, 陈恳. 基于 CNN 和 RNN 联合网络的心音自动分类 [J]. *计算机工程与设计*, 2020 41(1): 46-51.
- LI Wei, YANG Xiangdong, CHEN Ken. Heart sound classification based on CNN and RNN [J]. *Computer Engineering and Design*, 2020 41(1): 46-51.
- (编辑 武红江)

(上接第 72 页)

- [20] YANG Qijiang, LI Weiguang, et al. A study of the dynamic performance for tilting-pad bearing considering thermohydrodynamic and perturbation frequency effects [J]. *Journal of the Balkan Tribological Association*, 2016, 22(2): 766-781.
- [21] 罗健彬. 变支点滑动轴承测控系统设计与优化试验 [D]. 广州: 华南理工大学, 2015: 12-16.
- [22] CHAUHAN A, SEHGAL R, SHARMA R K. Thermohydraulics analysis of elliptical journal bearing with different grade oils [J]. *Tribology International*, 2010, 43: 1970-1977.
- [23] LOU Mingyang, BAREILLE O. Experimental and numerical investigation on the performance of fluid pivot journal bearing in one-sided floating state [J]. *Tribology International*, 2019, 138: 353-364.
- [24] 娄明阳. 流体枢轴轴承减振性能研究及全局性敏感性分析在流体膜轴承中的应用 [D]. 西安: 西安交通大学, 2020: 10-12.
- [25] BOOSER E R. CRC handbook of lubrication (theory and practice of tribology): volume II theory and design [M]. Boca Raton, FL, USA: CRC Press Inc., 1984: 264-266.
- [26] NICHOLAS J, WHALEN J, FRANKLIN S. Improving critical speed calculations using flexible bearing support FRF compliance data [C]// *Proceedings of the 15th Turbomachinery and Pump Symposia*. Turbomachinery Laboratory, Texas A&M University, TX, USA; TPS, 1986: 69-78.
- [27] HE M. Thermoelastohydrodynamic analysis of fluid film journal bearings [D]. Charlottesville, VA, USA: University of Virginia, 2003: 23-26.
- (编辑 武红江)