

# 基于电磁超声的小样本铝板表面缺陷检测方法<sup>\*</sup>

杨斌 易朋兴 郝峰旭

(华中科技大学机械科学与工程学院 武汉 430074)

**摘要:** 使用基于电磁超声技术的智能缺陷检测算法可以实现对重要零件质量状态的监测,保证设备安全可靠运行。在实际检测过程中,一方面采集的信号往往会被噪声污染进而对检测结果造成干扰,另一方面重要零件缺陷信号往往数据量较少不能满足神经网络训练的需求。因此本文提出了一种基于变分模态分解的降噪算法对检测信号进行降噪预处理以提升信号质量,提出了一种改进型的虚拟样本生成技术用来扩充样本集,并使用迁移学习技术减少神经网络训练的参数量以解决样本数量不足的问题。在铝板表面缺陷的深度检测样例中该方法达到了97.2%的平均预测准确率,因此该方法对非铁磁性材料表面缺陷检测有一定的借鉴意义。

**关键词:** 小样本;迁移学习;变分模态分解;缺陷检测

中图分类号: TB52+9 文献标识码: A 国家标准学科分类代码: 460.99

## A small sample aluminum plate surface defect detection method based on electromagnetic ultrasound

Yang Bin Yi Pengxing Hao Zhengxu

(School of Mechanical Science and Engineering, Huazhong University of Science and Technology, Wuhan 430074, China)

**Abstract:** The intelligent defect detection algorithm based on electromagnetic ultrasonic technology can be used to monitor the quality status of important parts and ensure the safe and reliable operation of equipment. In the actual detection process, on the one hand, the collected signals are often polluted by noise, which interferes with the detection results. On the other hand, the defect signals of important parts often have less data and cannot meet the needs of neural network training. Therefore, this paper proposes a noise reduction algorithm based on variational mode decomposition to pre-process detected signals to improve signal quality, proposes an improved virtual sample generation technology to expand the sample set, and uses transfer learning technology to reduce the number of parameters in neural network training to solve the problem of insufficient sample number. The average prediction accuracy of this method is 97.2% in the depth detection example of aluminum plate surface defects. Therefore, this method has certain reference significance for the surface defect detection of non-ferromagnetic materials.

**Keywords:** small sample; transfer learning; variational mode decomposition; defect detection

## 0 引言

随着我国航空航天、国防军工、船舶、汽车和轨道交通等工业领域的飞速发展,在提高性能和轻量化等需求下,新型合金材料被广泛应用于设备重要部件,特别是非铁磁性合金材料(铝合金、钛合金、镁合金等)<sup>[1-2]</sup>。但这些零件长期处于复杂的工作环境中,不可避免会产生缺陷。开展非铁磁性合金材料重要零件的质量状态无损检测与评估研究有助于保证设备安全可靠运行,避免重大事故的发生。

目前,对于缺陷的识别与评估,通常是基于某一检测技

术(射线检测<sup>[3]</sup>、涡流检测<sup>[4]</sup>、激光超声检测<sup>[5-6]</sup>等)获取蕴含大量缺陷信息的信号,然后提取缺陷信号的关键特征量(如幅值大小,频带分布等),进而基于智能识别和评估算法实现缺陷的识别。其中决定缺陷识别与表征精度的关键是缺陷关键特征量的识别和表征能力。针对蕴含大量缺陷特征的信号,不同的分析方法可以从不同角度和以不同方式对信号进行描述,在客观上存在各自的优势和劣势<sup>[7]</sup>,然而仅仅使用单一分析方法获取的特征量很难全面且精确的反映缺陷的特征。通过对检测信号不同分析域的优势进行互补在一定程度上可以改善单一分析域信息不完备的问题<sup>[8]</sup>。

另外在进行缺陷关键特征选取时,对操作者的专业知识有较强的需求,如果选择的特征量不同,缺陷的识别与评估将存在差异。卷积神经网络(convolutional neural network,CNN)作为一个强大的特征提取工具<sup>[9]</sup>可以在一定程度上克服缺陷关键特征选取对专业知识的依赖。随着深度学习理论的迅猛发展,基于卷积神经网络的缺陷识别方法越来越成为研究热点。谷玉海等<sup>[10]</sup>使用经验模态分解(empirical mode decomposition,EMD)算法对滚动轴承表面缺陷故障振动数据进行关键固有模态函数(inherent mode function,IMF)分量的提取,并将其进行二维化处理,使用CNN神经网络进行训练,其故障识别准确率达到了97.61%。高艺平<sup>[11]</sup>对冷轧钢铁表面缺陷识别的研究工作中使用了基于特征聚类卷积神经网络方法,其平均识别准确率达到91.87%,边裂、孔洞、拼接的识别准确率达到了100%。

但深度学习往往需要大量的数据进行训练,在大多数情况下实际样本数量不能达到网络训练的需求<sup>[12-13]</sup>。为了解决小样本的数据驱动深度学习问题,学者们提出了一些包括虚拟样本生成的数据增强技术<sup>[14-16]</sup>。由于数据是由计算机基于原始真实数据虚拟生成的,理论上可以产生无限的虚拟数据,在很大程度上可以解决原始数据不足的问题。

为解决小样本电磁超声缺陷检测问题,本文提出了一种基于变分模态分解(variational mode decomposition,VMD)的信号降噪预处理算法以提升采集信号的质量;提出了一种改进的虚拟样本生成技术以扩充样本集,并使用迁移学习技术减少训练参数量以解决小样本困境;通过融合频域与小波域信号分析的优势,解决单一分析域信息不完备的问题以提升缺陷检测准确度。

## 1 算法流程

小样本铝板表面缺陷检测算法流程如图1所示。首先使用4.1节中的信号采集设备采集真实样本数据,将其分为两部分,一部分用来生成虚拟样本扩充现有样本集,由于采集的信号包含噪声,为加快网络训练,使用基于VMD的降噪技术对该部分进行降噪处理。之后使用虚拟样本生成技术得到用于训练与验证的虚拟样本集,并使用2.2节中介绍的谱图融合方法将一维样本信号的小波域图与频域图作为红绿蓝三色(red green blue,RGB)图像的不同通道以融合多域特征。

通过迁移学习技术并设计新的全连接层得到铝板表面缺陷识别的网络结构,使用经处理的二维图片对该网络进行训练与验证,最后使用另一部分真实样本数据用于对神经网络进行测试。

## 2 数据预处理

### 2.1 基于VMD的降噪算法

为了减少噪声成分的干扰,需要对原始信号进行降噪

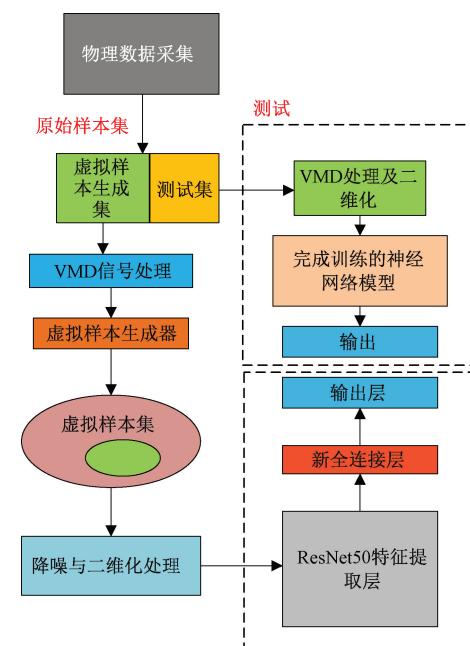


图1 小样本铝板表面缺陷检测算法流程图

处理,这里本文使用了基于变分模态分解的降噪技术。变分模态分解是Dragomiretskiy等提出的一种自适应信号分解方法<sup>[17]</sup>。不同于经验模态分解容易发生混叠现象,在对非线性、非平稳信号的处理上VMD拥有更为坚实的理论基础,目前VMD已经被广泛地应用在降噪<sup>[18]</sup>、缺陷检测<sup>[19]</sup>以及故障诊断<sup>[20]</sup>等领域。经VMD分解后,部分IMF分量保留了信号中的主要信息,本文提出使用综合评价系数 $K_w$ 对IMF分量进行选择,综合评价系数 $K_w$ 定义如下:

$$K_w = \text{sign}(C)K \mid C \mid ^T Q \quad (1)$$

其中,  $K$  为信号峰度值反映了随机变量概率分布的峰态,  $K$  值可以作为评价信号衰减的指标;交叉相关系数  $C$  反应两个信号之间的关联度,噪声信号和去噪信号的相似性可以通过  $C$  值来体现。同时,纯净信号的能量随VMD分解层级的增加会快速衰减,可以通过引入功率  $Q$  进一步区分噪声与纯净信号。

算法完整步骤为:

- 1) 初始化VMD分解层数  $k=3$ , 对信号进行  $k$  层VMD分解。
  - 2) 计算各IMF分量的  $K_w$  值以及相邻IMF  $K_w$  值的比值  $K_c = \frac{K_w(i+1)}{K_w(i)}$ , 当  $\min\{K_c\} < Ta$  时不再进行更深层次的分解;否则增加分解层级  $k=k+1$  并返回步骤1)。
  - 3) 当  $\min\{K_c\} < Ta$  可以认为有用信号与噪声的分界点已经产生,此时  $K_c$  对应的序号记为  $i$ , 选择  $i+2, \dots, k-1$  对应的IMF分量对信号进行重构。
- 步骤2)、3)中的阈值  $Ta$  所代表的含义为:由于噪声信号的无序性,当VMD分解到一定的层级时,相邻IMF  $K_w$  的比值  $K_c$  将接近于1,此时  $\text{IMF}(i)$  与  $\text{IMF}(i+1)$  均为噪

声,仅选择到  $k-1$  对应的 IMF 是因为在此次的工作中  $k$  阶 IMF 分量对应的是由电子元件产生的无有效信息的低频偏置。由于  $K_c$  是由大逐渐减小到 1 的,  $T_a$  值可由式(2)进行保守估计,其中  $s$  为裕度,本文中使用的  $s$  为 1.2。

$$T_a = 1 \times s \quad (2)$$

图 2 展示了信号经上述方法处理后的结果,可以看出信号的低频偏置与高频噪声已从原始信号中分离,但仍有部分微弱中频噪声残留,该部分噪声在 2.2 节中的二值化处理中将被滤除。

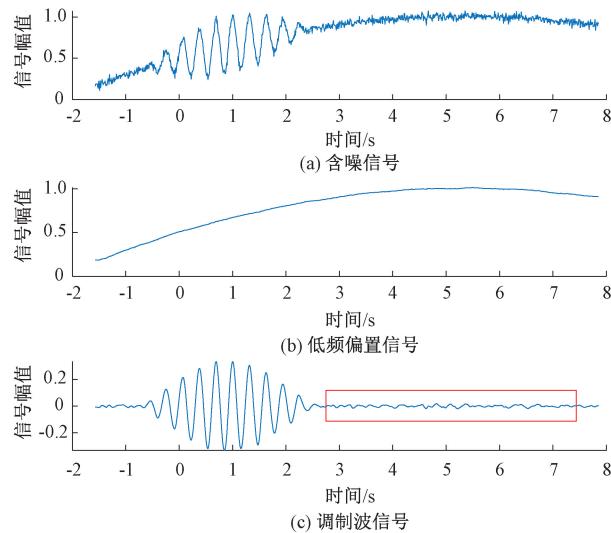


图 2 VMD 降噪算法处理前后检测信号对比图

## 2.2 缺陷检测信号谱图融合

为融合多域谱图的不同信息,首先对经 2.1 节降噪处理后的信号进行快速傅里叶变换与小波变换,分别得到信号的频谱图(如图 3 所示)与小波谱图(如图 4 所示)。为提升神经网络训练时的梯度,使边缘特征更加明显对小波域图像进行二值化处理将处理后的小波域图、小波域图、频域图分别作为 RGB 通道数据组合成包含两域信息的彩色图像,如图 5 所示。由于小波域进行了二值化处理,丢失了信号绝对能量信息,只保留了相对能量信息,而通过引入频域图可以弥补这一问题。这里小波域图使用了两次是因为本文在实验中发现使用频域与小波域的信息 CNN 已经能够达到很好的分类效果,由于小波域包含的信息比频域中包含的信息更多,为提高小波域信息在训练中所占的权重,因此 RG 通道均使用了小波域谱图。

## 3 卷积神经网络与数据增强

### 3.1 卷积神经网络与迁移学习

一个典型的 CNN 的结构包含一个接受输入图像的输入层,提取特征的卷积层,通过非线性变换增强特征的激活层,减少数据大小的池化层,以及将输入分类为预设标签的全连接层和一个归一化分类层<sup>[21]</sup>。网络的参数通过训练

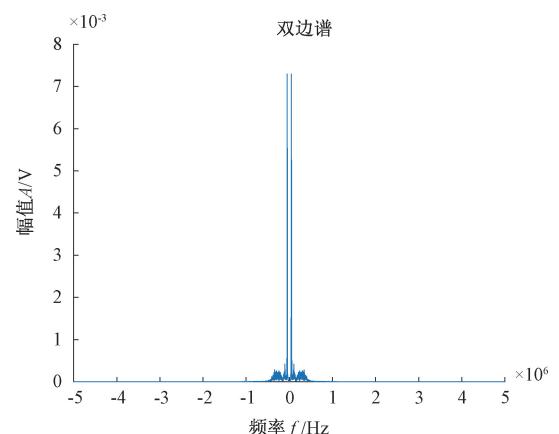


图 3 检测信号频谱图

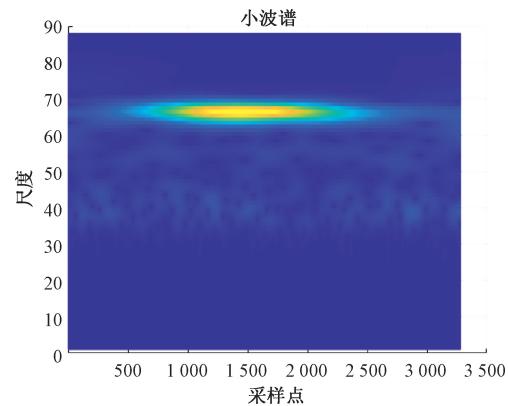


图 4 检测信号小波谱图

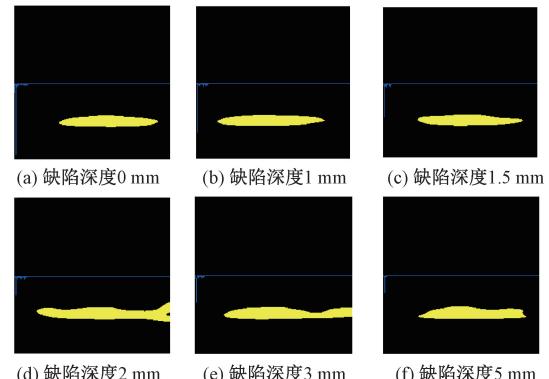


图 5 不同缺陷深度检测信号二维化对比图

数据进行训练,并使用反向传播算法进行更新。CNN 通过在其架构中结合和堆叠卷积层、池化层和全连接层来学习如何提取和识别目标任务的特征。当网络参数被现有数据正确训练后,可以在一个抽象的层次中自动提取代表性的特征,而不需要手动提取特征。

在一个特定的图像识别任务中,可以通过先使用预训练的模型初始化目标模型的参数,然后用少量的任务相关的图像样本进行微调,从而获得一个具有良好性能的模型<sup>[21]</sup>。该过程的原理为 CNN 神经网络模型的浅层结构用

以提取图像的通用特征,仅在最后的全连接层起分类作用,因此针对某一特定问题只需更改最后全连接层的结构并进行训练,如图 6 所示。另一方面,该过程由于除全连接层外的其他层参数均保持不变,大大减少了新任务模型训练参数,在一定程度上能弥补数据不足的问题。在本文的工作中,使用了 He 等<sup>[22]</sup>等提出的残差神经网络 (residual network 50, ResNet50) 进行迁移学习。

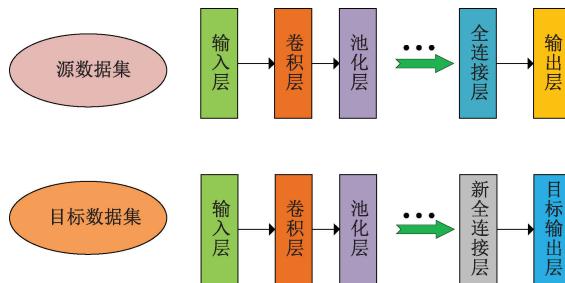


图 6 卷积神经网络的迁移学习示意图

迁移学习具体步骤为:

- 1) 复制 ResNet50 预训练神经网络的结构与参数,并删除 ResNet50 神经网络中用于分类的全连接层。
- 2) 根据特定的分类任务重新分配全连接层神经元个数,神经元个数与分类问题的种类相等。
- 3) 将新的全连接层接入步骤 1) 的神经网络中并随机初始化参数。
- 4) 固定步骤 1) 中神经网络所有神经元参数,仅对最后全连接层的神经元参数使用训练集数据进行训练,最终得到求解特定问题的网络模型。

### 3.2 虚拟样本生成技术

本小节的目的是通过增加虚拟样本来提高预测模型的准确性,换句话说,本文试图设计一个独特的虚拟样本生成机制,该机制可以生成不同的虚拟样本用以扩充现有样本集。虚拟样本质量的优劣将直接影响神经网络训练结果,如图 7 所示,可采纳的虚拟样本数据将对神经网络参数的更新起推进作用,相反不可采纳的虚拟样本数据将对参数的更新起阻碍作用。

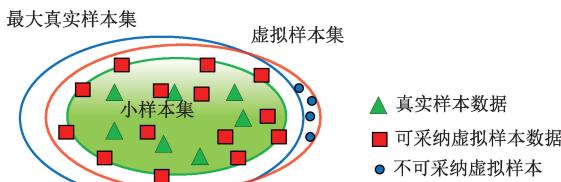


图 7 虚拟样本集、小样本集与最大真实样本集关系图

虚拟样本生成技术的关键在于确定虚拟样本集的界限,文献[12]中给出了一种利用三角形相似性确定虚拟样本界限的方法,如图 8 所示。

其中,  $LB$  为虚拟样本下界,  $UB$  为虚拟样本上界,  $CL$

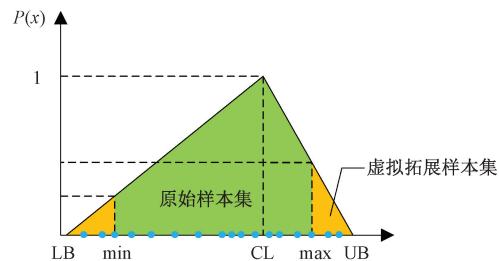


图 8 虚拟样本边界确定方法示意图

为样本中心,  $min$  为真实样本最小值,  $max$  为真是样本最大值。但该方法仅考虑了分布在样本中心两侧的样本数量,并未考虑样本分布的集中程度,事实上相同样本数目的不同分布情况将对样本上下界的确定有重要影响,如图 9 所示。因此本文提出了一种考虑样本分布集中程度的改进型虚拟样本上下界计算方法,如式(3)~(6)所示。其中  $N_L$  与  $N_U$  分别为分布在样本中心左右两侧的样本数量;  $\sigma_L$  与  $\sigma_U$  为分布在样本中心左右两侧的样本的标准差;  $\lambda$  为平衡参数,可通过试凑法获得。

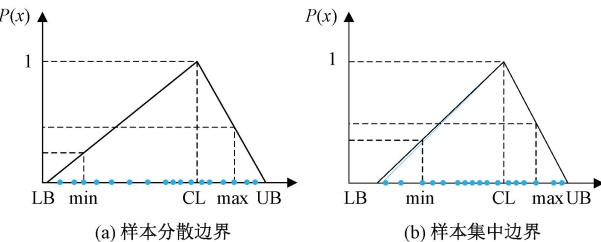


图 9 分布集中程度对边界确定的影响示意图

$$Skew_L = \lambda \left( \frac{N_L}{N_L + N_U} \right) + (1 - \lambda) \left( \frac{\sigma_U}{\sigma_L + \sigma_U} \right) \quad (3)$$

$$Skew_U = \lambda \left( \frac{N_U}{N_L + N_U} \right) + (1 - \lambda) \left( \frac{\sigma_L}{\sigma_L + \sigma_U} \right) \quad (4)$$

$$LB = CL - \frac{1}{Skew_L} (CL - min) \quad (5)$$

$$UB = CL + \frac{1}{Skew_U} (max - CL) \quad (6)$$

上下界确定后,虚拟样本生成问题随即转换为如何在  $[LB, UB]$  的区间中寻找某一函数  $f(x)$  使得该函数与真实样本数据  $f_r(x)$  的相似性最大。在本文的工作中,相似性使用相对百分比误差进行描述,如式(7)所示,  $\alpha$  越小则  $f$  越接近真实样本。因此上述问题转化为式(8)的最优化问题。文献[12]中指出只有当  $\alpha < 0.1$  时,生成的虚拟样本才能用以扩充样本集,因此式(8)转化为式(9),由于粒子群优化算法正是求解此类问题的一种优化算法,本文使用了文献[12]中提供的粒子群约束算法对式(9)进行求解。使用上述方法便可大量生成虚拟样本扩充样本集以解决小样本问题。

$$\alpha = \left| \frac{f - f_r}{f_r} \right| \times 100\% \quad (7)$$

$$\begin{cases} \min \left\{ \left| \frac{f - f_r}{f_r} \right| \times 100\% \right\} \\ \text{s.t. } LB \leq x \leq UB \end{cases} \quad (8)$$

$$\begin{cases} \min \left\{ \left| \frac{f - f_r}{f_r} \right| \times 100\% \right\} \\ \text{s.t. } \begin{cases} LB \leq x \leq UB \\ \left| \frac{f - f_r}{f_r} \right| < 0.1 \end{cases} \end{cases} \quad (9)$$

## 4 实验与结果讨论

实验设备及型号如下:信号发生器型号为 SDG6032X;门控脉冲放大器型号为 GA-2500A;电磁超声探头为回折线圈;带宽接收器型号为 BR640;示波器型号为 DPO7254,一台PC机处理器为 Inter i3-9100F 3.60 GHz, RAM 规格 16 GB, 显卡型号为 NVIDIA GeForce GT 1030 以及数据处理使用的软件 MATLAB2020b。

### 4.1 原始实验数据获取

实验平台搭建如图 10 所示,信号发生器产生的激励信号与永磁铁的电磁相互作用在铝板表面激发表面波,当表面波沿固体表面传播遇到缺陷时,会在缺陷处产生反射、透射和模式转换。表面波经接收端的回折线圈再次转化为电信号,对接收端信号进行分析即可完成对缺陷的识别与检测。图 11 为表面缺陷深度 1.5 mm 铝板俯视图,图 12 分别为缺陷深度为 1、1.5 和 2 mm 铝板截面图,在本文的实验中缺陷截面形状为矩形。其它深度缺陷与图 11,图 12 展示类似。图 13 展示了实测完整信号,图 14 为包含大量有用信息的信号局部放大图。



图 10 实验设备连接图



图 11 1.5 mm 深度缺陷俯视图



图 12 不同缺陷深度铝板截面图

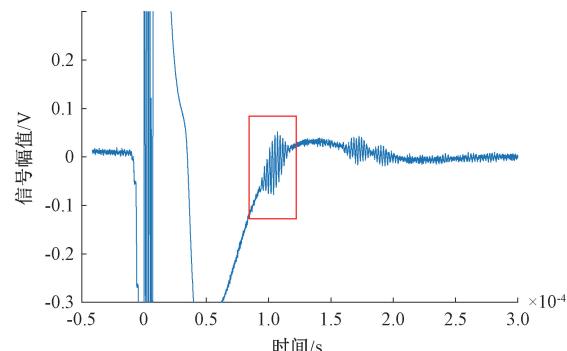


图 13 电磁超声检测信号

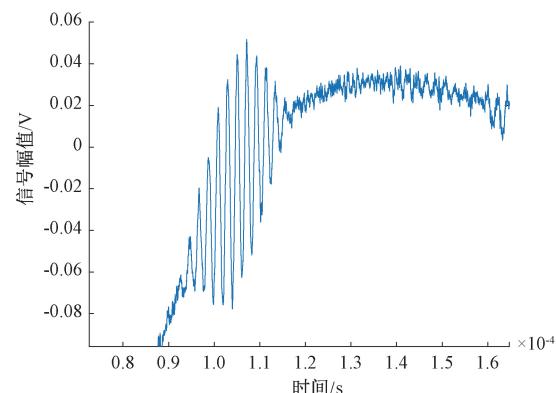


图 14 电磁超声检测信号局部放大图

### 4.2 样本集扩充

对原始信号使用 2.1 节中的降噪技术预处理后,使用 3.2 节中的虚拟样本生成技术将 50% 的原始样本集作为虚拟样本生成的源数据集,为每种缺陷深度扩充 500 个虚拟数据。其中式(3)~(4)中的  $\lambda$  在本文的工作中使用的是 0.7。图 15 展示了该技术生成的部分虚拟数据时域图。

### 4.3 神经网络训练与结果讨论

本文通过使用 3.1 节中介绍的迁移学习技术,充分利用 ResNet50 预训练模型的通用特征提取能力,分别对缺陷检测信号的频域图及小波域图的特征进行提取,通过训练全连接层以及输出层之间的权重系数实现缺陷识别的任务。真实样本数目每个类别各 24 个原始数据,使用其中的

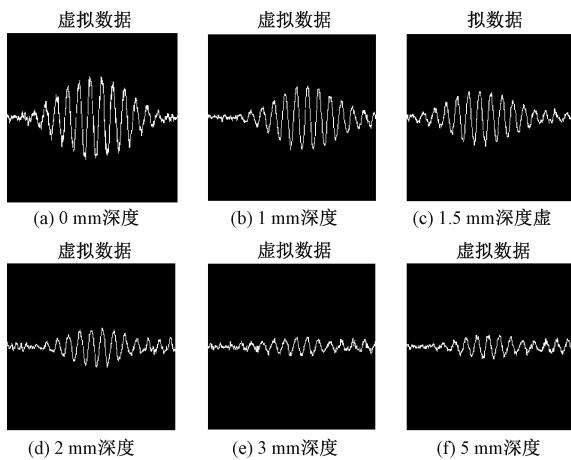


图 15 不同缺陷深度虚拟样本数据时域图

12 个生成虚拟样本并参与训练与验证,另 12 个进行测试,各样本集样本数目如表 1 所示。为提升神经网络的鲁棒性与进一步扩充样本集,使用了常见的数据增强技术:平移变换。神经网络训练过程的准确率曲线与损失函数曲线如图 16 所示,可以看到经过 15 次迭代该网络在验证集上迅速收敛到 100% 的准确率。

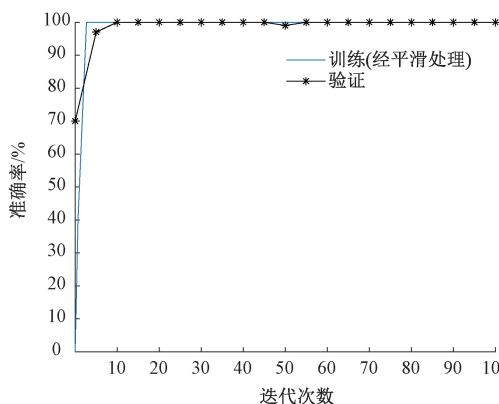


图 16 神经网络准确率与损失曲线

表 1 训练集验证集及测试集样本数量

缺陷深度/mm	训练集	验证集	测试集	真实样本数量
0	412	100	12	24
1	412	100	12	24
1.5	412	100	12	24
2	412	100	12	24
3	412	100	12	24
5	412	100	12	24

将模型进行保存,使用未参与生成虚拟样本的原始数据集进行测试,并与文献[10]、文献[23]中的方法进行对比,结果如表 2 所示。另外为了对比结合小波域与频域的方法与单独使用二者的方法之间的差异性,本文将单独使

用频谱图与小波谱图的相同神经网络分别独立地进行训练其结果如表 3 所示。

表 2 不同算法预测准确率

缺陷深度	0 mm	1 mm	1.5 mm	2 mm	3 mm	5 mm	平均准确率
本文方法/%	100	100	91.7	100	100	91.7	97.2
文献[10]/%	100	83.3	100	100	100	33.3	86.1
文献[23]/%	100	91.7	100	100	100	83.3	95.8
文献[6]/%	100	91.7	91.7	91.7	100	91.7	94.4

表 3 单一谱图预测结果

缺陷深度	0 mm	1 mm	1.5 mm	2 mm	3 mm	5 mm	平均准确率
频谱图/%	100	33.3	33.3	66.7	66.7	33.3	55.6
小波谱图/%	100	91.7	91.7	100	83.3	83.3	91.7

结果表明本文提出的缺陷深度检测方法具有更优异的性能,在小样本数据的情况下对 4 种缺陷深度的识别准确率均达到了 100%,对缺陷深度为 1.5 mm、5 mm 的识别准确度为 91.7%,平均识别准确度达到了 97.2%。相比于只使用频谱与小波谱的预测结果,使用频谱与小波谱共同分析的方法融合了二者的优势,使得最终预测结果的平均准确率分别提升了 41.6% 与 5.5%。

图 16 中神经网络收敛速度较快与 2.2 节中的二值化操作有着必然的联系,表 2~3 中的结果表明小波谱图比频谱蕴含更多的有用信息,与本文设想的一样,由于为了提高训练时的梯度而进行的二值化处理使小波谱图丢失了相关幅值信息,因此在引入包含幅值信息的频谱后相比于单一小波谱,神经网络的预测准确率提升了 5.5%。

相比于文献[10]中的 EMD-CNN 方法,本文提出的方法使正确率提升了 11.1%,性能的显著提升主要表现在缺陷深度为 5 mm 的情况,本文猜测是与本文使用的降噪算法有关。与文献[23]的方法对比,本文提出的方法仍有 1.4% 的优势。本文猜测或许是相比于一维时域信号二维谱图能够提供更多的有效信息。与文献[6]方法的对比结果表明,使用深度学习的方法对缺陷深度进行检测比使用扫查位置-峰值特征图的方法更具优势。

## 5 结 论

无损检测技术中常常面临信号质量差与样本数量不足的问题。本文提出了一种小样本铝板表面缺陷识别检测方法,通过使用基于变分模态分解的降噪算法对原始信号进行降噪处理,使用虚拟样本生成技术扩充样本集以及使用迁移学习技术减少参数量。将一维电磁超声检测信号的小波域图及频域图分别作为图片的不同通道以融合多域信息,在验证集与测试集上分别达到了 100% 与 97.2% 的平

均准确率,相比于单独使用频谱图与小波谱图,该方法的准确率有了大幅提升。研究得知,使用该方法对小样本铝板表面缺陷的检测中有着优异的性能,对非铁磁性合金材料关键零部件表面缺陷的智能化检测有一定的参考意义。

## 参考文献

- [1] 熊柏青,闫宏伟,张永安,等.我国航空铝合金产业发展战略研究[J].中国工程科学,2023,25(1):88-95.
- [2] 徐默雷.铝合金材料的应用与开发潜力[J].当代化工研究,2018(10):132-133.
- [3] 陶海斌,颜学清,易一平,等.基于数字射线检测的船舶焊缝无损检测应用[J].造船技术,2022,50(6):60-66.
- [4] 喻星星,朱颖,曹艳,等.碳纤维复合材料热损伤涡流检测技术研究[J].失效分析与预防,2022,17(6):385-391.
- [5] 罗朝莉,朱冰,王波,等.铝板表面裂纹的激光超声检测与信号处理研究[J].电子测量与仪器学报,2023,37(10):41-52. DOI:10.13382/j.jemi.B2306698.
- [6] 颜江涛,赵纪元,訾艳阳,等.激光超声信号变分模态分解与裂纹定量检测[J].仪器仪表学报,2023,44(1):223-230. DOI:10.19650/j.cnki.cjsi.J2210339.
- [7] 张书瑜.基于深度学习和多尺度多特征融合的高分辨率遥感地表覆盖分类研究[D].杭州:浙江大学,2020. DOI:10.27461/d.cnki.gzjdx.2020.001324.
- [8] 孙屹博,龙海威,邹丽,等.基于声发射多特征融合的搅拌摩擦焊缺陷监测[J].焊接学报,2022,43(6):96-101,118-119.
- [9] KRIZHEVSKY A, SUTSKEVER I, HINTON E G. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6):84-90.
- [10] 谷玉海,朱腾腾,饶文军,等.基于EMD二值化图像和CNN的滚动轴承故障诊断[J].振动.测试与诊断,2021,41(1):105-113,203. DOI:10.16450/j.cnki.issn.1004-6801.2021.01.015.
- [11] 高艺平.基于特征聚类卷积神经网络的表面缺陷识别方法[D].武汉:华中科技大学,2021. DOI:10.27157/d.cnki.ghzku.2021.000350.
- [12] CHEN Z S, ZHU B, HE Y L, et al. A PSO based virtual sample generation method for small sample sets: Applications to regression datasets [J]. Engineering Applications of Artificial Intelligence, 2016, 59: 236-243.
- [13] LI X X, CHANG D L, MA Z Y, et al. Deep InterBoost networks for small-sample image classification [J]. Neurocomputing, 2020, 456: 492-503.
- [14] LI L, KUMAR D S, WANG Y L, et al. A Gaussian mixture model based virtual sample generation approach for small datasets in industrial processes[J]. Information Sciences, 2021, 581: 262-277.
- [15] PARIDA S S, BOSE S, APOSTOLAKIS G. Earthquake data augmentation using wavelet transform for training deep learning based surrogate models of nonlinear structures [J]. Structures, 2023 (55): 638-649.
- [16] PAN Y, JING Y T, WU T H, et al. Knowledge-based data augmentation of small samples for oil condition prediction [J]. Reliability Engineering and System Safety, 2022, 217: 108114.
- [17] WANG X W, CAO H L. Improved VMD-ELM Algorithm for MEMS gyroscope of temperature compensation model based on CNN-LSTM and PSO-SVM[J]. Micromachines, 2022, 13(12):2056.
- [18] WEI J J, XIE T, SHI M, et al. Imbalance fault classification based on VMD denoising and S-LDA for variable-speed marine current turbine[J]. Journal of Marine Science and Engineering, 2021, 9(3): 248.
- [19] 冉茂霞,黄沁元,刘鑫,等.基于优化变分模态分解的磁瓦内部缺陷检测[J].浙江大学学报(工学版),2020,54(11):2158-2168,2213.
- [20] 张涛.基于VMD的航空发动机中介轴承故障诊断[D].大连:大连理工大学,2017.
- [21] ZHONG X P, BAN H. Pre-trained network-based transfer learning: A small-sample machine learning approach to nuclear power plant classification problem[J]. Annals of Nuclear Energy, 2022, 175.
- [22] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition [J]. CoRR, 2015, abs/1512.03385.
- [23] 韩晓东,李光亚,胡雅妮,等.基于一维CNN的时域超声信号识别技术研究[J].电子测量技术,2022,45(12):20-25. DOI:10.19651/j.cnki.emt.2208984.

## 作者简介

杨斌,硕士研究生,主要研究方向为信号处理与缺陷诊断。

E-mail:1617768486@qq.com

易朋兴(通信作者),博士,教授,硕士研究生导师,主要研究方向为信号处理、智能检测、诊断与控制、装备智能维护与再利用。

E-mail:m202170484@hust.edu.cn