

◇ 研究报告 ◇

卷积神经网络的缺陷类型识别分析*

高子洋^{1,2} 师芳芳^{1,2†} 张碧星^{1,2} 苏业旺^{3,4}

(1 中国科学院大学 北京 100049)

(2 中国科学院声学研究所 声场声信息国家重点实验室 北京 100190)

(3 中国科学院力学研究所 非线性力学国家重点实验室 北京 100190)

(4 中国科学院大学工程科学学院 北京 100049)

摘要: 该文提出一种基于卷积神经网络直接对阵列超声检测原始信号进行缺陷类型识别的方法,该方法无需对超声回波原始信号进行特征提取。文章研究对比了不同卷积神经网络及其优化的识别性能。首先采用超声相控阵系统对不同试块上的平底孔、球底孔、通孔三种缺陷进行超声检测,然后利用 LeNet5、VGG16 和 ResNet 三种卷积神经网络对一维和二维数据分别进行缺陷识别,并使用 Leaky ReLU、Dropout、Batch Normalization 等来对网络进行优化,对比分析识别准确率和效率等。研究结果表明,虽然一维卷积在训练速度上快于二维,但是二维卷积在识别准确度方面更高,同时网络模型结构如果过于复杂会导致准确率的下降,数据增强和优化方式有助于加快收敛速度、提高准确率。

关键词: 卷积神经网络; 超声检测; 缺陷类型识别

中图分类号: O429

文献标识码: A

文章编号: 1000-310X(2022)02-0301-09

DOI: 10.11684/j.issn.1000-310X.2022.02.017

Recognition and analysis of defect types by convolutional neural network

GAO Ziyang^{1,2} SHI Fangfang^{1,2} ZHANG Bixing^{1,2} SU Yewang^{3,4}

(1 University of Chinese Academy of Sciences, Beijing 100049, China)

(2 State Key Laboratory of Acoustics, Institute of Acoustics, Chinese Academy of Sciences, Beijing 100190, China)

(3 State Key Laboratory of Nonlinear Mechanics Institute of Mechanics, Chinese Academy of Sciences, Beijing 100190, China)

(4 School of Engineering Science, University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: In this paper, a method of the defect type recognition based on the convolutional neural network is proposed by the original signal from the array ultrasonic testing. The method does not require feature extraction of the original ultrasonic echo signals. The recognition performance and optimization characteristic of different convolutional neural networks are studied and analyzed. Firstly, the experiments are conducted by the ultrasonic phased array system to collect detection signals which comes from the flat-bottom hole, spherical-bottom hole and via hole. Then, Lenet5, VGG16 and Resnet convolutional neural networks are used to identify the defects in one and two dimensions, and the network is optimized by Leaky ReLU, Dropout and

2021-03-26 收稿; 2021-04-09 定稿

*中国科学院声学研究所青年英才计划项目(QNYC201736), 中国科学院基础前沿科学研究计划(ZDBS-LY-7023), 非线性力学国家重点实验室开放基金资助项目, 声场声信息国家重点实验室开放课题研究基金项目(SKLA202109)

作者简介: 高子洋(1995-), 男, 山东烟台人, 硕士研究生, 研究方向: 超声检测与成像。

†通信作者 E-mail: fangfangshi@mail.ioa.ac.cn

Batch Normalization respectively. Subsequently, the identification accuracy and efficiency are analyzed. It is shown that 2-d convolution has higher recognition accuracy although its training speed is slower than that of 1-d convolution. At the same time, the identification accuracy will decline if the network model structure is too complex, and the data enhancement and optimization methods can help to accelerate the convergence speed and improve the accuracy.

Keywords: Convolutional neural network; Ultrasonic testing; Defect type recognition

0 引言

在超声检测中,如果不能准确判断缺陷的性质,就会使某些无危险或者危险性很小的产品返修从而导致浪费,也会造成含有危险性缺陷的产品被忽视,使得其在使用过程中产生安全隐患^[1],因此对缺陷的类型识别分析尤为重要,对保障产品质量和安全运行意义重大。超声检测中对缺陷进行类型识别,开始主要依靠人工经验,识别结果有一定的主观性。自20世纪70年代起,研究者开始使用神经网络对超声检测数据进行缺陷分类,这部分研究主要集中在两个方面,一方面是采用特征提取加浅层神经网络的方法对检测数据进行分类,另一方面是采用深度学习方法,输入数据主要是人工提取的特征值,近年逐渐发展到自动提取特征。

在浅层神经网络方面,Song等^[2]提出利用概率神经网络对通过超声散射特征提取的时域特征进行焊接缺陷分类。Masnata等^[3]提出了利用Fischer线性判别分析对缺陷回波信号提取形状参数,使用神经网络实现焊缝缺陷的自动分类。Margrave等^[4]选择对神经网络进行调整,使用各种类型和配置的神经网络对时域和频域分别进行训练以找到未知缺陷。卢超等^[5]利用小波变换对超声检测回波信号进行分解,并将分解信号的能量分布特征送入神经网络中进行训练和分类。Liu等^[6]提出利用仿真得到的A扫超声无损检测信号提取的特征值和反向传播(Back propagation, BP)网络结合对裂纹的大小、类型和位置进行判别。Drai等^[7]对焊接缺陷回波通过时域、频域和离散小波提取特征值,使用K近邻分类(K-nearest neighbor classification, KNN)算法、贝叶斯统计、人工智能网络进行分类识别。Veiga等^[8]对脉冲焊缝使用脉冲回波和超声衍射时差(Time of flight diffraction, TOFD)技术获得的超声信号,通过预处理以后使用BP网络进行缺陷分类。Sambath等^[9]利用小波变换得到缺陷的特征向量,通过BP网络对这些特征向量进行识别分

类。Filho等^[10]提出通过离散傅里叶变换、小波变换和余弦变换对超声信号进行特征提取,使用BP网络对复合材料中的缺陷进行训练分类检测。Cruz等^[11]采用了Filho等^[10]的特征提取方法,并使用了不同的特征选择手段,采用多层感知(Multilayer perceptron, MLP)机,使用不同分类器对焊接缺陷进行分类。

在深度学习方面,对卷积神经网络(Convolutional neural network, CNN)的研究可追溯到20世纪80年代,1998年,Lecun等^[12]在前人基础上提出了LeNet-5,形成了当代CNN的雏形,在识别手写数字上取得了不错的效果。2012年,Krizhevsky等^[13]提出的Alexnet网络在Imagenet图像识别大赛中取得了历史性突破,从此人们意识到CNN在图像识别领域的优势。

在超声检测领域也有不少研究者开展了采用深度学习方法进行缺陷分析的工作。施成龙等^[14]使用小波包变换对A扫信号进行缺陷特征信息提取,将得到的能量分布特征向量通过深度信念网络进行分类识别,准确率达到98.83%。Meng等^[15]提出分层组合小波变换系数,利用CNN对不同特征提取方法分类器进行训练,从而实现对碳纤维聚合物的缺陷分类,准确率达到98.15%。Khumaidi等^[16]提出使用焊接表面缺陷超声检测图像作为输入,使用CNN对不同类型焊接缺陷进行分类,准确率达到95.83%。Munir等^[17-18]对焊接缺陷进行超声检测得到的信号在不同信噪比下使用全连接深度神经网络、CNN进行缺陷分类,发现CNN效果更好。张重远等^[19]采用基于相似矩阵的盲源分离方法对得到的超声检测信号进行预处理,使用CNN进行识别,准确率达到90%。Munir等^[20]将超声信号通过自编码器进行去噪后使用CNN进行分类。

目前为止,多数研究者都是在预处理阶段使用统计或信号处理方法提取特征来提高识别准确率。本文将不对信号进行特征提取,直接针对阵列探头采集的原始超声信号,使用一维数据(A扫信号数

据)和二维图像(A扫信号的波形显示图)分别作为输入,采用不同CNN结构实现缺陷的分类识别,在此基础上对网络性能进行优化,实现识别准确率的提升。

1 CNN基本原理和结构

CNN通过卷积核与输入数据的卷积操作提取特征,然后通过激活函数和池化来对特征进行处理,经过训练之后使网络输出端能够正确识别输入数据进行分类。训练过程如图1所示,输入特征经过网络主干部分后分类识别,如未达到迭代次数,跟真实标签比较通过损失函数和优化函数来对参数进行修正,再次进入卷积训练过程,当达到迭代次数以后,停止训练并保存当前网络的权重。

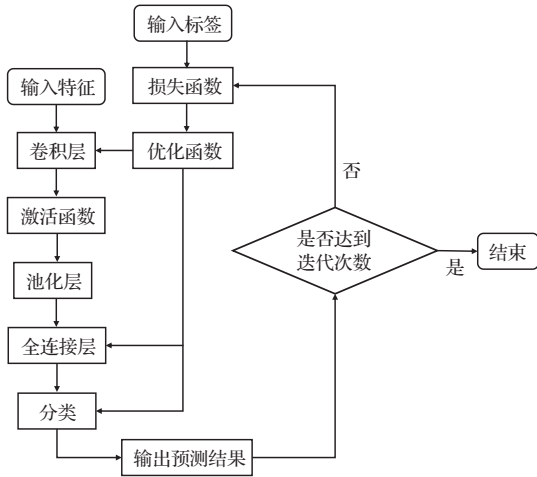


图1 训练过程
Fig. 1 Training process

1.1 卷积核

CNN中卷积的特点在于获得输入的局部空间特征,依靠的是内部包含的多个卷积核,按照维度的不同可分为一维卷积、二维卷积和 multidimensional 卷积。一维卷积输入通常为时间或频谱采样,卷积核在一维空间滑动计算,计算公式如下:

$$y_t = \sum_{k=1}^K w_k x_{t-k+1}, \tag{1}$$

其中, w_k 为卷积核权重, y_t 为卷积输出,常用于信号、序列模型、自然语言处理领域等。二维卷积输入一般包含多个通道,通常为图像,卷积核在二维空间滑动计算,计算公式如下:

$$y_{ij} = \sum_{u=1}^U \sum_{v=1}^V w_{uv} x_{i-u+1, j-v+1}. \tag{2}$$

跟一维卷积类似, w_{uv} 为卷积核权重, y_{ij} 为卷积输出,常用于计算机视觉、图像处理领域。

1.2 激活函数

目前对于CNN激活函数的研究中普遍使用ReLU (Rectified Linear Unit) 函数^[21]或ReLU函数的变种,ReLU函数定义为

$$a_{i,j,k} = \max(z_{i,j,k}, 0), \tag{3}$$

其中, $z_{i,j,k}$ 是第 k 通道在 (i, j) 位置激活函数的输入,优点是计算效率高,可以很快收敛,但是会导致神经元死亡问题,如果学习率过大,那么网络中可能有很多神经元都无法正常更新参数。在此基础上衍生出了Leaky ReLU函数^[22],定义为

$$a_{i,j,k} = \max(z_{i,j,k}, 0) + \lambda \min(z_{i,j,k}, 0), \tag{4}$$

其中, λ 是 $(0,1)$ 范围内的预定义参数,它与ReLU函数的区别是在输入小于0时,会有一个很小的常数 λ 与输入相乘,使得信息不会全部丢失,解决了神经元死亡问题。图2为ReLU和Leaky ReLU函数示意图。

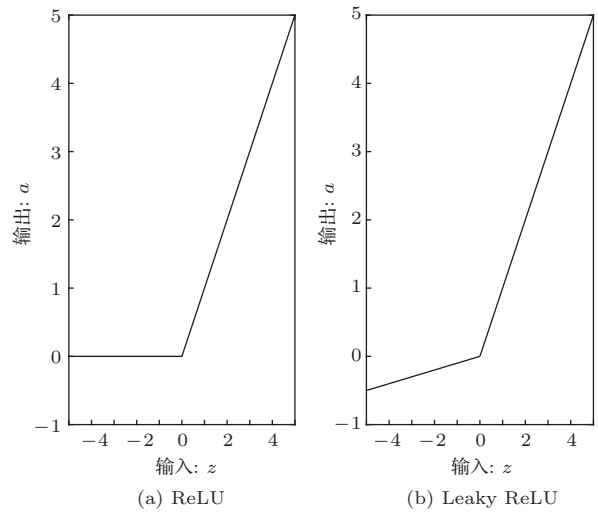


图2 ReLU与Leaky ReLU函数
Fig. 2 ReLU and Leaky ReLU activation function

1.3 Dropout和Batch Normalization

Dropout和Batch Normalization为在训练过程中防止过拟合使用的优化手段,Dropout是在训练的时候,随机使一部分隐藏节点值为0,即不参与训练,减少隐藏节点间的相互作用。Batch Normalization^[23]为将输入分布转化为均值为0、标准差为1的正态分布,其主要作用为加快网络收敛速度,防止过拟合,在最近几年的深度学习模型

Faster RCNN、YOLO系列中,都已经使用Batch Normalization来代替Dropout功能。

1.4 数据增强

在计算机视觉领域,数据增强是深度学习增加数据量的一种非常有效的方式。在这种技术中,从原有实例生成相似的类似实例,人为地增加数据库的大小。本研究中,由于没有适用的关于超声无损检测的数据库,实验中也较难获得大量的实测数据,最有效可行的方法是对数据进行增强,即对已有的数据进行翻转、平移或旋转等操作,创造出更多的数据,来使神经网络具有更好的泛化效果,同时提升模型的识别准确率。

2 CNN缺陷识别方法

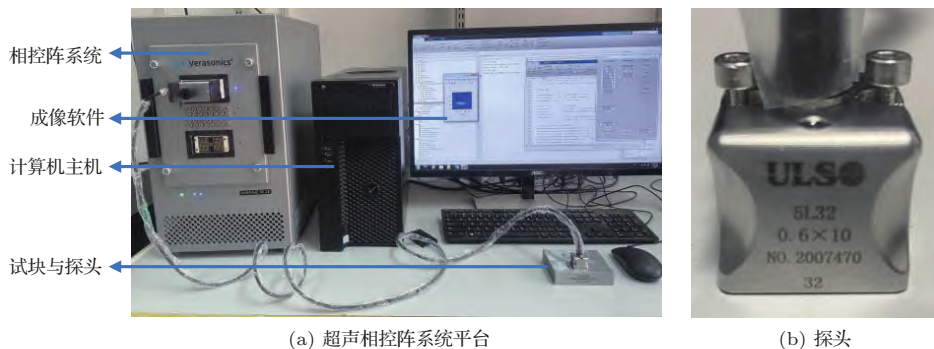
本文采用超声相控阵系统对不同的缺陷进行检测,将得到的缺陷信号进行预处理,然后利用不同网络结构对缺陷信号进行分析,实现缺陷类型识别,

调节网络中参数来观测识别准确率的影响。

2.1 实验系统

获取数据的实验系统如图3所示,包括Verasonics Vantage超声相控阵系统、计算机主机、探头及试块。Verasonics Vantage超声相控阵系统含有32个独立通道,可以同时激发与接收所有通道,并能存储所有通道的原始回波数据。探头使用超声相控阵探头,该探头中心频率为5 MHz,阵元数量为32,如图3(b)所示。

实验中对3种类型试块进行检测,如图4所示。3种试块对应3类缺陷,分别为:(1) $\phi 3$ mm通孔,试块长300 mm,宽40 mm,高25 mm,通孔直径为3 mm,埋深为15 mm;(2) $\phi 3$ mm平底孔,试块长100 mm,宽40 mm,高25 mm,平底孔直径为3 mm,埋深为15 mm;(3) $\phi 3$ mm球底孔,试块长100 mm,宽40 mm,高25 mm,球底孔直径为3 mm,埋深为15 mm。



(a) 超声相控阵系统平台

(b) 探头

图3 实验系统

Fig. 3 Experimental system




图4 3种缺陷实物图

Fig. 4 Three kinds of test blocks

2.2 数据获取及处理

使用如图3所示的实验系统获取检测原始数据,检测过程中相控阵系统的采样率为20 MHz,采用全聚焦方法依次激发所有阵元,每次激发所有阵元接收,即阵元1发射,1~32阵元接收,阵元2发射,1~32阵元接收,以此类推,一次检测共可接收1024个回波信号。从每种缺陷回波信号的1024个数据中各选取100个样本,每个样本时长为2 μ s,表1中列出了每种缺陷的信号数量。图5展示了3种缺陷的回波信号,可以观察到从信号中很难分辨出它们的缺陷类型。




图5 3种缺陷的回波信号

Fig. 5 Echo signals of three defects

表1 各缺陷类型信号样本数量

Table 1 Number of signal samples of each defect type

缺陷类型	平底孔	球底孔	通孔	总计
样本数量	100	100	100	300

在超声检测数据集中,由于原始数据样本只有几百个,在复杂的神经网络结构中容易造成过拟合,不易判断测试信号的类别,本文对数据库进行数据

增强并研究其增强效果。在对数据集进行数据增强时分为两种方式,第一种^[18]是改变缺陷与阵元之间的距离,反映到信号上为改变信号的到时,即将数据向前和向后各时移0.05 μs,样本数增加两倍;第二种是改变信号的幅度,将信号向上和向下分别平移,样本数增加两倍,如图6所示。针对二维数据,采取这两种方式,此时数据样本数变为原来的5倍。针对一维数据,只采取第二种措施,此时数据样本数变为原来的3倍。扩增的样本数量如表2所示。




图6 数据增强示意图

Fig. 6 Data augmentation schematic

表2 数据扩增的数量

Table 2 The number of data augmentation

缺陷类型	样本数量	
	一维	二维
幅值增加	300	300
幅值减少	300	300
时域前移	0	300
时域后移	0	300
总计	600	1200

在训练网络时,为了验证网络性能是否达到满意的效果,通常会对数据集进行划分,选取一部分数据集不进行训练而用来验证网络效果。在本文中,选择总数据集的90%用于训练,10%用于测试。表3显示了数据增强后不同维度用于训练和测试数据集的每个缺陷的总样本数量。

表3 训练集和测试集

Table 3 Training and testing datasets

缺陷类型	样本数量			
	一维		二维	
	训练集	测试集	训练集	测试集
平底孔	270	30	450	50
球底孔	270	30	450	50
通孔	270	30	450	50
总计	810	90	1350	150

本文中用于训练和测试的数据分为两种类型,一类是一维缺陷回波数据,用一维卷积模型进行训练;另一类是缺陷回波的二维显示图形,用二维卷积模型进行训练。为了加快收敛速度,在将数据输入到神经网络之前,对数据进行归一化处理。在对A显波形的图片进行预处理时,因为只需要学习其信号特征,在读取时以单通道进行读取来减少计算量。

2.3 环境配置及结构

本研究采用的CNN是基于Tensorflow2.0版本中的Keras框架实现的,CPU型号为I7-8750H, GPU型号为1050TI,内存为16 G。

采用的网络结构有3种,分别是LeNet-5、VGG16和ResNet。LeNet5结构最为简单,含有2个卷积层、2个池化层、3个全连接层;VGG16结构较为复杂,含有13个卷积层、5个池化层、3个全连接层;残差网络ResNet含有残差结构,结构最为复

杂,含有5个残差模块和2个全连接层,其中2个残差模块分别包含4个卷积层、1个池化层,另3个残差模块分别包含5个卷积层、1个池化层。一维卷积和二维卷积使用的网络结构完全一样。表4展示了不同网络结构的参数对比。

表4 不同网络参数对比

Table 4 Parameters between different networks

模型名称	LeNet-5	VGG16	ResNet
层数	5	16	25
卷积层数	2	13	23
卷积核大小	5	3	1, 3
池化层数	2	5	5
池化选择	Max Pooling	Max Pooling	Max Pooling
池化核大小	2	2	2
全连接层数	3	3	2

3 实验结果分析

本文将根据CNN理论从以下5个方面对识别准确率及效率的影响来进行对比分析,分别是一维卷积和二维卷积模型、数据增强、迭代次数、Dropout和Batch Normalization优化、ReLU和Leaky ReLU激活函数。

3.1 一维卷积和二维卷积对识别准确率的影响

采用不同的网络结构模型,分别使用一维卷积和二维卷积进行训练,迭代次数为100次,数据集使用扩充后的数据集。识别准确率及训练时长如表5所示。LeNet5、VGG16、ResNet在一维卷积模型中的识别准确率分别为95.56%、98.89%和97.78%,训练时间分别为10.47 s、49.37 s、50.28 s。在二维卷积模型中的识别准确率分别为99.33%、100%、100%,训练时间分别为263.8 s、494.1 s、521.5 s。可以看到二维卷积模型的识别率比一维卷积模型有了明显的提升,但是在训练时间上大大增加,为一维卷积模型的10倍以上,这是由于二维卷积比一维卷积在参数量上有了几十倍的增加,可以更好地拟合函数,但是也会增加训练时间。

从表5可以看出,在本文数据集样本数目有限的情况下,VGG16和ResNet网络在二维卷积识别准确度可达到100%,无需进行优化,因此下文中的优化针对LeNet5结构进行。

表5 一维卷积和二维卷积模型对识别准确率的影响

Table 5 The influence of one-dimensional convolution and two-dimensional convolution models on identification accuracy

网络类型	一维		二维	
	准确率/%	训练时间/s	准确率/%	训练时间/s
LeNet5	95.56	10.47	99.33	263.8
VGG16	98.89	49.37	100	494.1
ResNet	97.78	50.28	100	521.5

表6 数据增强对识别准确率的影响

Table 6 The influence of data augmentation on identification accuracy

(单位: %)

网络类型	LeNet5-1D	VGG16-1D	ResNet-1D	LeNet5-2D	VGG16-2D	ResNet-2D
原始数据集	90.00	93.33	90.00	96.67	100	96.67
增强后数据集	95.56	98.89	97.78	99.33	100	100

3.3 迭代次数对识别准确率的影响

每一次迭代都要对参数进行修正, 迭代次数代表着对数据的拟合程度, 迭代次数越多说明对数据拟合得越好, 但是迭代次数过多又会造成过拟合。针对原始数据集, 使用不同网络结构在一维卷积上迭代不同轮次, 对比识别准确率。从表7可以看出, LeNet5在训练100、200、300轮次时的准确率分别为90%、93.33%、96.67%, 准确率一直上升, 说明网络还没有完全拟合, 随着迭代次数的增加网络识别准确率更高。VGG16在训练100、200、300轮次时的准确率分别为93.33%、96.67%、90%, ResNet在训练100、200、300轮次时的准确率分别为90%、93.33%、86.67%, 这两个网络在训练300轮次的时候准确率都出现了降低, 说明这个时候网络已经过拟合。由此可见, 在网络训练的时候迭代次数并不是越多越好, 特别是复杂网络, 选择合适的迭代次数很重要。

表7 迭代次数对识别准确率的影响

Table 7 The influence of iteration number on identification accuracy

(单位: %)

网络类型	100 epoch	200 epoch	300 epoch
LeNet5-1D	90.00	93.33	96.67
VGG16-1D	93.33	96.67	90.00
ResNet-1D	90.00	93.33	86.67

3.2 数据增强对识别准确率的影响

表6展示了不同网络结构在原始数据集和数据增强后总数据集下的表现差异, 迭代次数为100次。LeNet5、VGG16、ResNet在原始数据集上一维卷积模型识别准确率分别为90%、93.33%、90%, 二维卷积模型识别准确率分别为96.67%、100%、96.67%, 对比在增强后数据集上各网络的表现, 可以看到数据增强后各网络结构的识别准确率均有明显的提升。

3.4 Dropout和Batch Normalization对识别准确率的影响

不同的优化方法(Dropout和Batch Normalization)对识别准确率及训练时间的影响如表8所示。使用LeNet5结构在扩充后的数据集上进行训练, 结果表明当使用Dropout时准确率为97.78%, 训练时间为11.4 s, 使用Batch Normalization时准确率为100%, 训练时间为13.67 s, 两者都不使用时准确率仅为95.56%, 训练时间为10.47 s。图7展示了3种模式在训练过程中验证集准确率和损失函数随着迭代次数的变化, 可以看出Batch Normalization在训练过程中验证集准确率增长速度最快, 损失值最低, 说明收敛速度更快。综合来看, 使用Dropout或Batch Normalization虽然在训练时间上都有了一定的增加, 但是准确率也有一定的提升, Batch Normalization表现尤为突出。

表8 Dropout和Batch Normalization对识别准确率的影响

Table 8 The influence of Dropout and Batch Normalization on identification accuracy

	准确率/%	训练时间/s
使用 Dropout	97.78	11.4
使用 Batch Normalization	100	13.67
都不使用	95.56	10.47

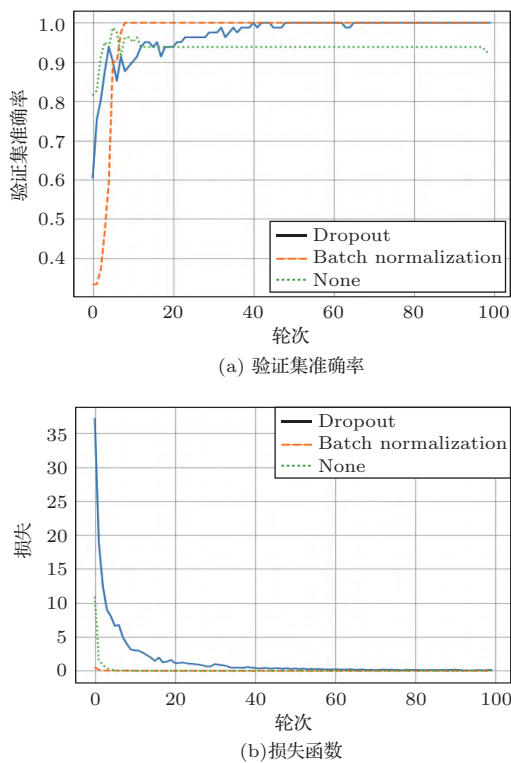


图7 网络训练曲线

Fig. 7 Training curve of network

3.5 激活函数对识别准确率的影响

表9展示了不同激活函数ReLU和Leaky ReLU对识别准确率的影响。使用LeNet5结构在扩充后数据集上进行训练,Leaky ReLU中的 λ 取值为0.1。结果表明当使用ReLU激活函数时准确率为95.56%,使用Leaky ReLU激活函数时准确率为98.89%,可以看出Leaky ReLU的效果更好。这是因为Leaky ReLU激活函数保留了更多的信息,使识别准确率得到提升。

表9 ReLU和Leaky ReLU对识别准确率的影响

Table 9 The influence of ReLU and Leaky ReLU on identification accuracy

	使用 ReLU	使用 Leaky ReLU
准确率/%	95.56	98.89

4 结论

本研究采用CNN对超声检测回波信号进行缺陷识别,目标是寻找一种不依赖于特征提取技术的网络结构,它要有良好的鲁棒性,并具有很高的识别准确率。研究得出以下结论:

(1) 合适的网络结构很重要。在实验对比中,发现VGG16网络的性能要优于LeNet5和ResNet。LeNet5模型相对简单,不能更好地拟合数据,而ResNet具有残差结构,在复杂度方面高于VGG16,导致在训练过程中更容易过拟合。

(2) 使用相同的CNN结构训练时,二维图像比一维数据的识别准确率高。当使用相同的CNN结构训练时,二维卷积的参数数量比一维卷积多了几十倍,可以更好地拟合函数。

(3) 当数据量少的时候使用数据增强能够提高识别准确率。由于目前没有公开的超声缺陷检测回波信号数据集,想要大规模的获取也很困难,数据增强就可以部分解决这个问题。

(4) 不同的优化手段有利于提高识别准确率。可以在网络中将激活函数改为Leaky ReLU,添加Batch Normalization层等来减少过拟合,提高网络的泛化能力。

分析实验证明,只要选取合适的CNN模型,不需要进行特征提取就可以得到非常高的准确率,这正是因为CNN独特的结构和优秀的性能。

参 考 文 献

- [1] 彭应秋. 超声波检测工艺 [M]. 北京: 航空工业出版社, 1990: 5-7.
- [2] Song S J, Schmerr L W. Ultrasonic flaw classification in weldments using probabilistic neural networks[J]. Journal of Nondestructive Evaluation, 1992, 11(2): 69-77.
- [3] Masnata A, Sunseri M. Neural network classification of flaws detected by ultrasonic means[J]. NDT & E International, 1996, 29(2): 87-93.
- [4] Margrave F W, Rigas K, Bradley D A, et al. The use of neural networks in ultrasonic flaw detection[J]. Measurement, 1999, 25(2): 143-154.
- [5] 卢超, 张维, 彭应秋, 等. 小波分析和神经网络在金属超声无损检测缺陷分类中的应用 [J]. 南昌航空工业学院学报, 2001, 15(3): 51-54.
Lu Chao, Zhang Wei, Peng Yingqiu, et al. Application of wavelet analysis and artificial neural networks to flaw classification in ultrasonic nondestructive testing[J]. Journal of Nanchang Institute of Aeronautical Technology, 2001, 15(3): 51-54.
- [6] Liu S W, Huang J H, Sung J C, et al. Detection of cracks using neural networks and computational mechanics[J]. Computer Methods in Applied Mechanics and Engineering, 2002, 191(25-26): 2831-2845.
- [7] Drai R, Khelil M, Benchaala A. Time frequency and wavelet transform applied to selected problems in ul-

- trasonics NDE[J]. *NDT & E International*, 2002, 35(8): 567–572.
- [8] Veiga J L B C, Carvalho A A D, de Silva I C, et al. The use of artificial neural network in the classification of pulse-echo and TOFD ultra-sonic signals[J]. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 2005, 27(4): 394–398.
- [9] Sambath S, Nagaraj P, Selvakumar N. Automatic defect classification in ultrasonic NDT using artificial intelligence[J]. *Journal of Nondestructive Evaluation*, 2011, 30(1): 20–28.
- [10] Filho E F S, Silva M M, Farias P C M A, et al. Flexible decision support system for ultrasound evaluation of fiber-metal laminates implemented in a DSP[J]. *NDT & E International*, 2016, 79: 38–45.
- [11] Cruz F C, Simas Filho E F, Albuquerque M C S, et al. Efficient feature selection for neural network based detection of flaws in steel welded joints using ultrasound testing[J]. *Ultrasonics*, 2017, 73: 1–8.
- [12] Lecun Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. *Proceedings of the IEEE*, 1998, 86: 2278–2324.
- [13] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[J]. *Communications of The ACM* 2017, 60(6): 84–90.
- [14] 施成龙, 师芳芳, 张碧星. 利用深度神经网络和小波包变换进行缺陷类型分析[J]. *声学学报*, 2016, 41(4): 499–506.
Shi Chenglong, Shi Fangfang, Zhang Bixing. Analysis on defect classification by deep neural networks and wavelet packet transform[J]. *Acta Acustica*, 2016, 41(4): 499–506.
- [15] Meng M, Chua Y J, Wouterson E, et al. Ultrasonic signal classification and imaging system for composite materials via deep convolutional neural networks[J]. *Neurocomputing*, 2017, 257: 128–135.
- [16] Khumaidi A, Yuniarno E M, Purnomo M H. Welding defect classification based on convolution neural network (CNN) and Gaussian kernel[C]. *IEEE*, 2017: 261–265.
- [17] Munir N, Kim H J, Song S J, et al. Investigation of deep neural network with drop out for ultrasonic flaw classification in weldments[J]. *Journal of Mechanical Science and Technology*, 2018, 32(7): 3073–3080.
- [18] Munir N, Kim H J, Park J, et al. Convolutional neural network for ultrasonic weldment flaw classification in noisy conditions[J]. *Ultrasonics*, 2019, 94: 74–81.
- [19] 张重远, 岳浩天, 王博闻, 等. 基于相似矩阵盲源分离与卷积神经网络的局部放电超声信号深度学习模式识别方法[J]. *电网技术*, 2019, 43(6): 1900–1907.
Zhang Chongyuan, Yue Haotian, Wang Bowen, et al. Pattern recognition of partial discharge ultrasonic signal based on similar matrix bss and deep learning CNN[J]. *Power System Technology*, 2019, 43(6): 1900–1907.
- [20] Munir N, Park J, Kim H J, et al. Performance enhancement of convolutional neural network for ultrasonic flaw classification by adopting autoencoder[J]. *NDT & E International*, 2020, 111: 102218.
- [21] Nair V, Hinton G E. Rectified linear units improve restricted boltzmann machines[C]. *Proceeding, Twenty-Seventh International Conference on Machine Learning (ICML 2010)*, Haifa, Israel, 2010: 807–814.
- [22] Maas A L, Hannun A Y, Ng A Y. Rectifier nonlinearities improve neural network acoustic models[C]. *Atlanta, Georgia, USA: Proceedings of the 30th International Conference on Machine Learning*, 2013.
- [23] Santurkar S, Tsipras D, Ilyas A, et al. How does batch normalization help optimization?[C]. *Montréal, Canada: 32nd Conference on Neural Information Processing Systems(NeurIPS)*, 2018.