

DOI:10.19651/j.cnki.emt.2208984

基于一维 CNN 的时域超声信号识别技术研究 *

韩晓东¹ 李光亚¹ 胡雅妮¹ 简丽² 张国花²

(1. 中北大学信息与通信工程学院 太原 030051; 2. 山西省古建筑与彩塑壁画保护研究院 太原 030000)

摘要: 超声检测缺陷是一种主流的缺陷识别手段,二维卷积神经网络一直是该领域的主要技术,一般从二维 C 扫、D 扫等图像中提取属性特征来进行识别分类,这些研究主要采用二维卷积层,会产生较大的资源消耗。在所有类型的缺陷识别方法中,超声回波信号分析是最主要和有用的工具之一,本研究从原始时域超声信号中提取特征,首先使用来自实验室的 JPR-600C 空气耦合超声波无损检测系统采集数据;然后通过使用不同的超参数进行实验、t-sne 可视化等手段构建并优化一维 CNN 网络模型;最后实现超声信号缺陷识别分类。实验结果表明,所提出的 CNN 模型的性能令人满意,缺陷识别准确率为 97.57%,高于其他机器学习方法,为实现缺陷识别自动化的需要提供辅助。

关键词: 卷积神经网络;超声信号;缺陷识别

中图分类号: TP391 文献标识码: A 国家标准学科分类代码: 520.2040

Research on time-domain ultrasonic signal recognition technology based on one-dimensional CNN

Han Xiaodong¹ Li Guangya¹ Hu Yan¹ Jian Li² Zhang Guohua²

(1. School of Information and Communication Engineering, North University of China, Taiyuan 030051, China;

2. Shanxi Ancient Architecture and Painted Mural Protection Research Institute, Taiyuan 030000, China)

Abstract: Ultrasonic defect detection is a mainstream means of defect recognition, and two-dimensional convolution neural network has always been the main technology in this field. Generally, attribute features are extracted from two-dimensional C-scan, D-scan and other images for recognition and classification. These studies mainly use two-dimensional convolution layer, which will consume a lot of resources. Among all kinds of defect identification methods, ultrasonic echo signal analysis is one of the most important and useful tools. In this study, features are extracted from the original time domain ultrasonic signals, firstly, the data are collected using the JPR-600C air-coupled ultrasonic nondestructive testing system from the laboratory, and then the one-dimensional t-sne network model is constructed and optimized by using different hyperparameters, t-sne visualization and other means. Finally, ultrasonic signal defect recognition and classification is realized. The experimental results show that the performance of the CNN model proposed in this paper is better, and the correct rate of defect identification is 97.57%, which is higher than other machine learning methods, which provides some assistance for the automation of defect recognition.

Keywords: convolution neural network; ultrasonic signal; defect recognition

0 引言

超声缺陷信号的正确诊断主要取决于提取的特征信号,由于特征样本的可用性有限,缺陷识别经常面临问题^[1]。在这种情况下,机器学习方法发挥至关重要的作用。早期的智能识别主要是^[2]通过短时傅立叶变换、经验模态分解、局部均值分解、变分模态分解、小波变换和小波包变换等提取时频特征等,然后输入到 K 近邻判别、BP 神经网

络模型、支持向量机等实现缺陷分类。比如徐蒋明等^[3]利用 BP 神经网络对提取的小波分析理论得到的特征量进行评估和识别;郭徽^[4]运用小波包分析与 BP 神经网络方法相结合,有效的对碳纤维复合材料中 3 种常见缺陷进行了识别与分类,并且有较高的缺陷识别率;朱建峰等^[5]对多层复合材料超声检测回波信号提取特征的方法中引入小波变换方法,提取小波变换后各频段的信号能量作为特征,为缺陷分析及识别提供依据;Hosseinabadi 等^[6]基于 DWT 降

收稿日期:2022-02-09

* 基金项目:国家重点研发计划“制造基础技术与关键部件”重点专项项目(2020YFB2009102)资助

噪后再对超声信号提取特征,结合 SVM 实现了结构健康和受损状态的区分; Yi 等^[7]提出基于小波包的超声回波信号特征选择方法,利用 SVM 实现超声信号的分类。

自从 2012 年以来,CNN 在图像相关研究上表现出色,CNN 热潮袭来,其相关的智能应用在生活中越来越多,在缺陷识别领域也取得了较大的进展。从文献[8-10]回顾可以得出,迄今为止,已经进行了许多研究来使用卷积神经网络对超声缺陷进行分类,较少研究^[11-13]对原始时域超声信号进行缺陷识别,这些研究通过直接从二维图像中提取属性特征来进行识别分类,由于图像的获得比较耗时,本研究从原始时域超声信号中提取特征,然后使用一维 CNN 对信号进行分类,一维(1-D)卷积网络比二维(2-D)卷积网络快,并且 1-D 卷积网络可以为 2-D 卷积网络提供计算成本低廉的替代方案。本研究使用存储在逗号分隔值(CSV)文件中的数据集。

本研究的目的是设计一种一维深度学习模型,用于更准确地自动分类,并且将所提出的模型与一些机器学习方法进行比较。对材料的缺陷进行预先检测,可以有效防止材料突然断裂,较早的发现危险事故的苗头,减少更大经济的损失以及人身危险。

1 一维卷积工作原理

CNN 是一种前馈神经网络,卷积核模仿人类的神经元对输入的数据进行感知,基本的 CNN 一般由卷积层、激活函数和池化层组成,卷积过程中通过卷积核在输入信号上滑动,完成特征提取,之后利用非线性激活函数输出特征矢量^[14]。

卷积采用两个向量或矩阵作为输入,其中一个是原始输入,另一个是核或过滤器。在输入激活函数时,会生成第 3 个向量或矩阵作为输出。

如果输入向量 f 的长度为 n ,滤波器 g 的长度为 m ,那么一维卷积 $f * g$ 可以这样定义:

$$(f * g)(i) = \sum_{j=1}^m g(j) \cdot f(i - j + \frac{m}{2}) \quad (1)$$

内核映射到输入张量上,对于每个核,将核和输入张量的重叠值相乘并求和,这个乘积总和将是输入中内核居中点的输出值^[15]。研究中使用的一维卷积层可以定义为:

$$y^l = b^l + \sum_{i=1}^{n_l-1} (f^{l-1} * g^{l-1})(i) \quad (2)$$

其中, y^l 是第 1 层输出, b^l 是第 1 层偏置, f^{l-1} 是第 $(l-1)$ 层输出, g^{l-1} 是第 $(l-1)$ 层过滤器。模型的密集层输出 O 采用典型的感知器形式, b 为偏置, w 为权重, x 为输入:

$$o = b + \sum_{i=1}^n w^{(i)} x^{(i)} \quad (3)$$

\hat{y} 的预测是由 softmax 激活函数完成的:

$$\hat{y} = softmax(o) \quad (4)$$

$$softmax = \frac{e^{o_i}}{\sum_j e^{o_j}} \quad (5)$$

其中, O_i 是属于类别 i 的置信水平。

交叉熵损失可以测量为:

$$l(y, \hat{y}) = - \sum_i y_i \log \hat{y}_i \quad (6)$$

其中, y 是实际值, \hat{y} 是预测值。

2 网络设计

本文所提出的模型如图 1 所示,4 个主要特征提取层和两个分类层组成,4 个特征提取层旨在捕获 4 种不同频率的特征。每个特征提取层都使用一组卷积、激活、批标准化(batch normalization, BN)和池化操作进行设计,卷积层提取多频特征,池化操作检测主要特征。将批量归一化(BN)加入卷积神经网络模型中有助于提高训练速度和模型的精度,并且还可以防止梯度分散^[16]。两个分类层是使用全连接层实现的。

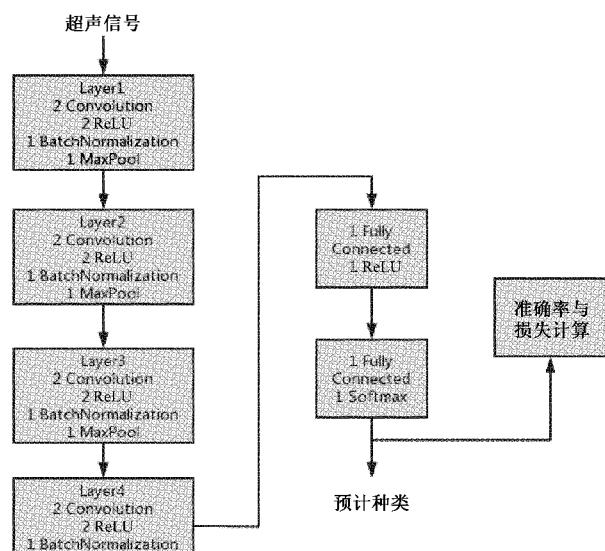


图 1 网络架构

综上所述,所提出的 1-D CNN 网络有 8 个 1-D 卷积运算、8 个 ReLU 激活函数、4 个池化运算、4 个 BN 和 2 个全连接矩阵乘法运算。所有的操作被分为 4 个主要特征提取和两个分类层,卷积和池化运算符代表特征提取,而全连接层代表分类器。第 1 层捕获所有低级细节,而最后一层捕获超声信号整体特征模式。网络内部具体描述如下:

第 1 层~第 4 层各有 2 个一维卷积运算、2 个 ReLU 运算、1 个 BN 和 1 个 MaxPool 运算;第 5 层有一个全连接运行和一个 ReLU 运行;最后一层有一个全连接操作和一个 Softmax 运行,它将之前转换的特征映射到缺陷类中。

网络模型中输入层随后的每一个层中,内核被 Maxpooling 层减半,池大小为 2,步幅为 1,即在池化外期间

没有跳过任何内容。在 8 个卷积层之后,输出被展平并送入到两个全连接密集层,最后一个密集层的内核等于输出的数量,例如,此处为 5 分类,所以研究中使用 5 个分类系统。该模型除了最后一层选用 Softmax 激活函数,其余均为 ReLU 激活函数^[17]。实验测量了训练和测试精度,并将结果与一些机器学习技术进行了比较:长短期记忆人工神经网络(LSTM)、CNN-LSTM、BP(back propagation)神经网络和支持向量机(SVM)。

3 数据集和实验验证

3.1 实验环境

本实验在 Tensorflow1.14 和 Python3.6 环境下进行,软件编程采用 Python 语言。硬件的配置是 Inter(R)i5-10400F-CPU, NVIDIA GeForce RTX 2060-GPU, Windows 10(64)操作系统。

3.2 数据库建立

由于没有公开的超声一维信号数据集,本文使用 JPR-600C 空气耦合超声波无损检测系统如图 2 所示。对 6 种不同缺陷的铝板进行数据采集,构建数据集,其中训练样本为 1 200 个,测试样本为 300 个,研究中使用的特征集概览如图 3 所示,图 4 所示为部分缺陷样本数据波形图。

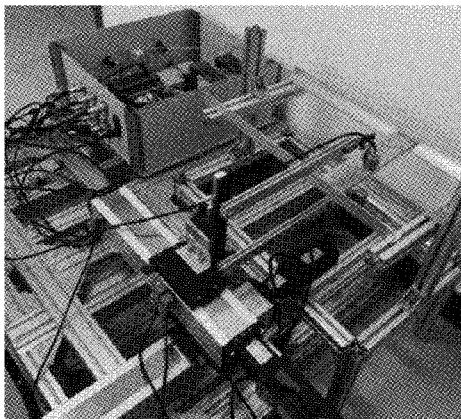


图 2 数据采集系统

id	特征值															label				
1	-0.107	-0.099	-0.162	-0.099	-0.049	-0.059	-0.019	0.023	-0.049	-0.034	-0.064	-0.039	-0.129	-0.225	0.143	0.259	0.031	-0.024	-0.154	2
2	-0.046	-0.011	0.039	0.128	0.077	0.035	0.101	0.207	0.196	-0.178	0.219	0.009	-0.022	0.058	0.038	-0.069	-0.020	-0.061	3	
3	-0.138	-0.103	-0.208	-0.102	-0.089	-0.018	0.008	0.041	0.016	-0.121	0.095	-0.051	-0.001	-0.048	0.066	0.279	0.123	0.009	4	
4	-0.099	-0.001	-0.091	-0.078	0.057	0.088	0.012	-0.142	-0.132	-0.152	0.039	0.013	0.005	0.008	0.003	0.073	0.144	0.005	1	
5	0.104	0.010	0.019	0.019	0.028	-0.028	0.048	0.089	0.124	-0.017	-0.077	-0.036	0.059	0.115	0.064	-0.060	-0.204	-0.137	1	
476	-0.048	-0.134	-0.223	-0.057	-0.161	-0.123	-0.115	0.011	-0.211	-0.082	-0.035	-0.155	-0.235	-0.205	-0.187	-0.022	-0.008	2		
477	0.075	0.003	0.046	0.145	0.134	0.116	0.077	0.112	0.145	0.033	0.081	0.021	0.093	0.071	0.152	0.208	0.016	0.214	0	
478	-0.074	-0.095	-0.077	-0.001	0.026	-0.132	-0.113	0.047	0.101	-0.029	-0.039	-0.104	-0.084	-0.024	0.119	-0.043	-0.093	-0.015	4	
479	0.078	-0.007	-0.100	-0.002	0.094	0.016	0.008	0.003	0.211	-0.320	-0.344	-0.144	-0.022	-0.030	-0.020	-0.117	-0.103	0.006	3	
480	0.141	-0.075	-0.028	0.016	0.096	0.071	0.032	-0.029	0.009	0.029	0.006	0.132	0.072	-0.152	-0.047	0.190	0.020	0.058	0	

图 3 研究中使用的特征集概览

3.3 超参数的选择

使用 Tensorflow 包来稳健学习网络的超参数。深度网络的成功取决于大量的训练样本和超参数训练框架,本文设计了一个训练、验证和测试工作流程,从所采集的超声

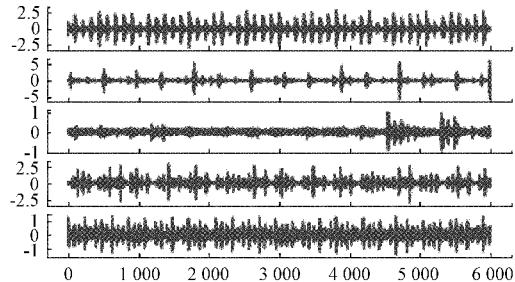


图 4 部分缺陷样本数据波形图

数据集中学习超参数。所采用的超参数学习框架具有 3 个主要模块和一个控制逻辑,如图 5 所示。

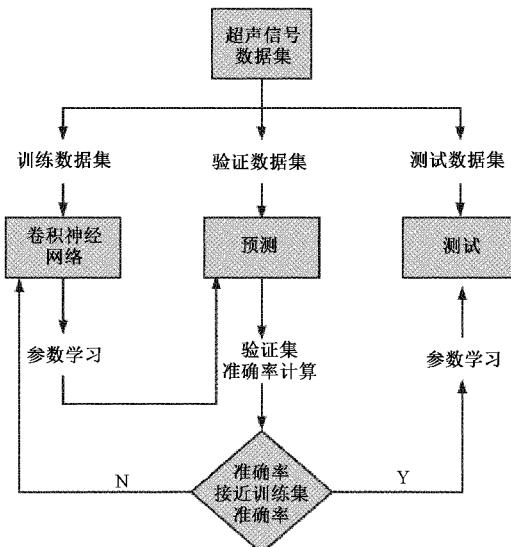


图 5 超参数学习工作流程

使用训练数据学习参数,使用验证数据集检查学习参数的泛化能力,训练和验证过程一直持续到达到泛化标准。以下部分详细描述了参数学习流程的每个步骤。

深度卷积网络由数百万个参数和一些超参数组成,即学习率、层数和过滤器的大小。采用 Tensorflow 简化超参数学习框架来学习最佳网络参数,以最大限度地提高测试精度。该网络首先接收训练数据,然后从训练数据集中学习参数,然后使用验证数据集验证学习网络的性能,如果验证数据集可以达到所需的准确度,则应用这些参数进行测试;如果验证数据集的结果没有达到训练准确率,则通过神经网络学习新参数,并使用参数中的新信息,学习或更新权重发生在反向传播期间。通过重复实验确定使用 Adam 优化器,学习率为 0.0002;使用的批量大小为 32。

为了了解模型内部机理以及辅助分析网络性能,我们采用一种目前比较主流的非线性降维方法可视化—t 分布随机邻域嵌入(t-sne),这个技术能够保留给定数据的局部结构^[18-19]。如图 6 所示为 epochs 确定过程的输出数据 t-sne 可视化,通过分析可得,本实验最佳 epochs 取值 50。

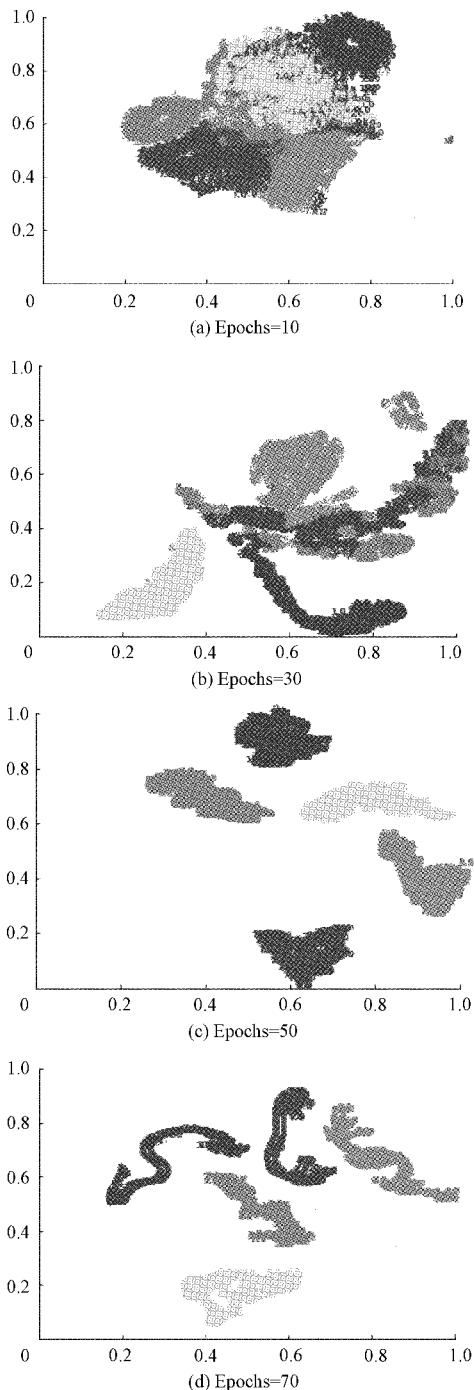


图 6 网络数据输出 t-SNE 可视化

3.4 评价指标

选取准确率(Accuracy)、精确率(Prec)、召回率(R)、F1 值作为评价指标来验证不同方法的分类效果, 其中, 模型 Prec 和 R 的调和平均值是 F1 值, 具体公式如式(7)、(8)所示。

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + TN + FN} \quad (7)$$

其中, TP (true positive) 指的是正确识别阳性数量,

FN (false negative) 指的是错误识别阳性数量, FP (false positive) 指的是错误识别阴性数量, TN (true negative) 指的是正确识别阴性数量^[20]。

$$F1 = \frac{2 \cdot \text{Prec} \cdot R}{\text{Prec} + R} \quad (8)$$

在相同实验环境下, 构建相应的网络结构, 分别对比 CNN、LSTM、CNN-LSTM、BP 神经网络和 SVM, 实验结果如表 1 所示。

表 1 不同方法的比较结果 %

方法	准确率	精确率	召回率	F1
CNN	97.57	98.16	98.24	98.19
LSTM	94.64	93.73	93.26	93.49
CNN-LSTM	89.16	88.41	88.54	88.45
BP	74.24	—	—	—
SVM	82.73	—	—	—

由表 1 可以看出, 所提出的一维卷积神经网络(CNN)模型表现令人满意, CNN 的整体缺陷分类精度约为 97.57%, 高于其最接近的竞争 LSTM 2.93%。通过绘制不同方法的准确率折线图, 如图 7 所示可以更加直观的看出所提出网络模型的优势。

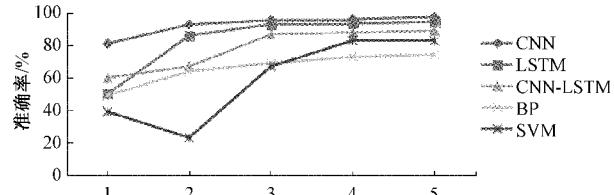
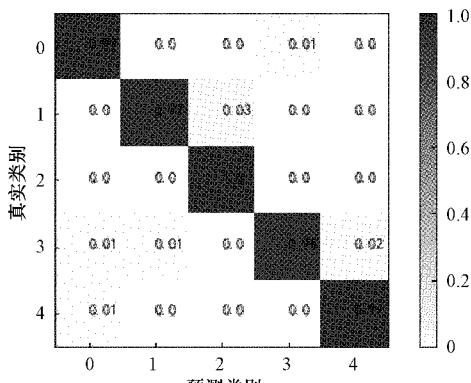


图 7 不同方法的准确率比较曲线

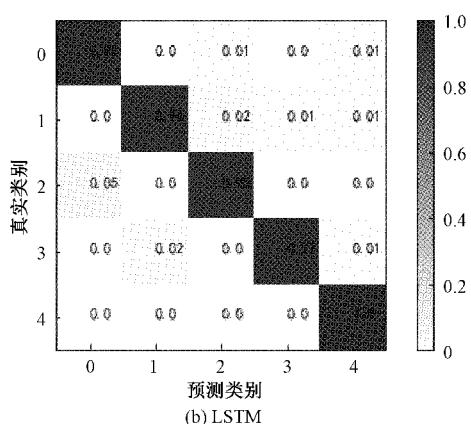
目前, 常用的一个评价识别效果的指标还有混淆矩阵, 它是一张总结了模型分类结果的分析表, 横坐标代表预测标签值, 纵坐标代表真实标签值, 可可视化地展示算法的分类性能, 如图 8 所示为上述不同模型的混淆矩阵识别分类结果图。

综上可得本实验所建立的一维 CNN 模型结果最优, 如图 9 所示是代码运行直接显示出的时域超声信号的 CNN 模型。经过 50 轮训练后, 模型的可训练参数总数为 1 271 612。从表 1 可以看出, 输入层的激活形状是 (None, 1 747, 16)。此处, None 意味着批次长度是可变的; 1 747 是接下来要传送的特征数, 计算公式为((特征数量-内核大小)/步长+1), 1 指的是滤波器偏置; 16 是该层中所使用的过滤器数量。Maxpooling 和 flatten 层没有可学习的参数。对于 dense_2 层, 参数=(来自 dense_1 的输入 × 过滤器数量)+bias=(250×6)+6=1 500+6=1 506。

如图 10、11 所示分别显示了该模型训练和验证集的准确率和损失图, 从图中可得该模型效果良好。



(a) CNN



(b) LSTM

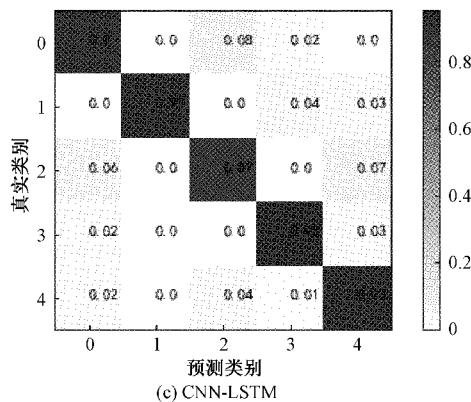


图 8 CNN、LSTM 与 CNN-LSTM 模型识别分类结果图

4 结 论

在超声缺陷识别研究领域完成的大多数工作都基于相关图像数据集,即在 2D CNN 上建模,图像数据集的获得较为复杂和费时。本研究使用原始超声时域信号,通过构建一维 CNN 模型,输入到卷积层中进行特征提取来识别超声缺陷信号,在模型构建中结合 t-sne 可视化和多种参数对比实验来确定超参数及网络层数等细节问题。一般说来是在时间序列问题中使用一维 CNN,本文应用于超声 A 扫信号较为新颖,实验结果表明该研究不仅取得了较高的总体

Layer (type)	Output Shape	Param #
conv1d_1 (Conv1D)	(None, 1747, 16)	144
conv1d_2 (Conv1D)	(None, 874, 16)	2 064
batch_normalization_1 (Batch Normalization)	(None, 874, 16)	64
max_pooling1d_1 (MaxPooling1D)	(None, 437, 16)	0
conv1d_3 (Conv1D)	(None, 219, 64)	4 160
conv1d_4 (Conv1D)	(None, 110, 64)	16 448
batch_normalization_2 (Batch Normalization)	(None, 110, 64)	256
max_pooling1d_2 (MaxPooling1D)	(None, 55, 64)	0
conv1d_5 (Conv1D)	(None, 28, 256)	65 792
conv1d_6 (Conv1D)	(None, 14, 256)	262 400
batch_normalization_3 (Batch Normalization)	(None, 14, 256)	1 024
max_pooling1d_3 (MaxPooling1D)	(None, 7, 256)	0
conv1d_7 (Conv1D)	(None, 7, 512)	262 656
conv1d_8 (Conv1D)	(None, 7, 512)	524 800
batch_normalization_4 (Batch Normalization)	(None, 7, 512)	2 048
max_pooling1d_4 (MaxPooling1D)	(None, 3, 512)	0
global_average_pooling1d_1 (Global Average Pooling1D)	(None, 512)	0
dropout_1 (Dropout)	(None, 512)	0
dense_1 (Dense)	(None, 250)	128 250
dense_2 (Dense)	(None, 6)	1 506

图 9 拟议的 CNN 架构的迭代一览图

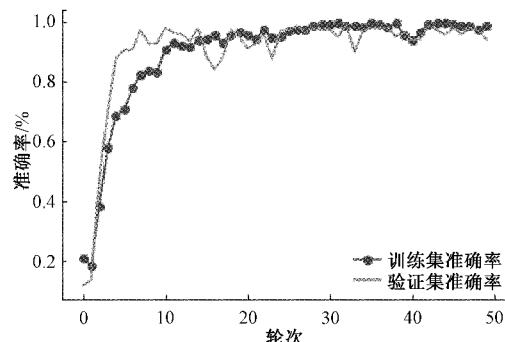


图 10 不同轮次模型准确率图

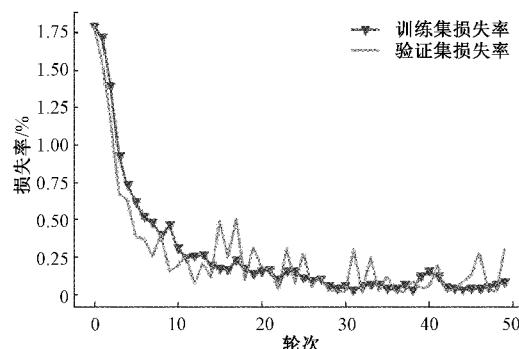


图 11 不同轮次模型损失率图

准确性,而且还展示了一种对超声缺陷信号进行分类的较好方法,可以进一步训练这样的网络,以在缺陷识别中获得更好的结果,该类模型在缺陷自动分类中有较好的应用前景,这样的模型可以作为工程师工程缺陷评判的决策支持系统。

参考文献

- [1] DASH P, NAIK K. A very deep one dimensional convolutional neural network(VDOCNN) for appliance power signature classification[C]. 2018 IEEE Electrical Power and Energy Conference(EPEC), IEEE, 2018: 1-6.
- [2] 李萍,宋波,毛捷,等.深度学习在超声检测缺陷识别中的应用与发展[J].应用声学,2019,38(3):458-464.
- [3] 徐将明,柯黎明.拌摩擦焊焊缝缺陷超声检测信号特征分析与神经网络模式识别[J].核动力工程,2020,41(1):163-166.
- [4] 郭薇.碳纤维复合材料缺陷检测方法研究[D].天津:天津大学,2014.
- [5] 朱建峰,郭伟剑,刘俊邦,等.小波变换在多层复合材料的超声波检测中的应用[J].四川兵工学报,2014,35(7):67-70.
- [6] HOSSEINABADI H Z, AMIRFATTAHI R, NAZARI B, et al. GUW-based structural damage detection using WPT statistical features and multiclass SVM[J]. Applied Acoustics, 2014, 86:59-70.
- [7] YI Q J, WANG H T, GUO R P, et al. Laser ultrasonic quantitative recognition based on wavelet packet fusion algorithm and SVM [J]. Optik-International Journal for Light and Electron Optics, 2017, 149:206-219.
- [8] 严治.基于卷积神经网络的铸件内部缺陷超声检测方法研究[D].沈阳:沈阳工业大学,2019.
- [9] 胡文博,邱实,许馨月,等.基于深度学习的钢轨伤损超声检测与分类[J].铁道学报,2021,43(4):108-116.
- [10] 卢伟.基于深度学习方法的焊接缺陷超声图像识别[D].大连:大连交通大学,2019.
- [11] 宫文峰,陈辉,张美玲,等.基于深度学习的电机轴承微小故障智能诊断方法[J].仪器仪表学报,2020,41(1): 195-205.
- [12] VIRUPAKSHAPPA K, MARINO M, ORUKLU E, et al. A multi-resolution convolutional neural network architecture for ultrasonic flaw detection [C]. 2018 IEEE International Ultrasonics Symposium, Piscataway, New York: IEEE, 2018:8579888.
- [13] NAUMAN M, HAK-JOON K, PARK J, et al. Convolutional neural network for ultrasonic weldment flaw classification in noisy conditions[J]. Ultrasonics, 2019, 94: 74-81.
- [14] 牟欣颖,何赟泽,王洪金,等.基于一维卷积神经网络的联动扫描热成像缺陷自动识别与深度回归[J].电子测量与仪器学报,2021,35(4):211-217.
- [15] MOITRA D, MANDAL R K. Classification of non-small cell lung cancer using one-dimensional convolutional neural network[J]. Expert Systems with Applications, 2020, 159: 113564.
- [16] 彭禹,宋耀莲.基于 STFT 的卷积神经网络在 MI-EEG 分类中的应用[J].电子测量技术,2021,44(6):36-41.
- [17] 常博.基于 DOG 特征与深度学习的工件表面缺陷检测算法[J].电子测量技术,2019,42(14):28-32.
- [18] ZHANG W, PENG G, LI C, et al. A new deep learning model for fault diagnosis with good anti-noise and domain adaptation ability on raw vibration signals[J]. Sensors, 2017, 17(2): 425.
- [19] LI C, ZHANG W, PENG G, et al. Bearing fault diagnosis using fully-connected winner-take-all autoencoder[J]. IEEE Access, 2017, 6: 6103-6115.
- [20] 韩宇,李剑,马慧宇,等.基于 CNN-LSTM 的桥梁结构损伤诊断方法[J].国外电子测量技术,2021,40(7): 1-6.

作者简介

韩晓东,硕士研究生,主要研究方向为信号与信息处理、深度学习。

E-mail:2140566187@qq.com

李光亚,博士,硕士生导师,主要研究方向为测试计量技术及仪器。

E-mail:40827562@qq.com