

文章编号: 2095-2163(2023)05-0117-06

中图分类号: TP391.41

文献标志码: A

一种基于 A 扫缺陷识别的多任务深度学习方法

邹宸玮, 王狄颀

(上海工程技术大学 航空运输学院, 上海 201620)

摘要: 针对超声相控阵(NDT)缺陷检测, 本文提出一种利用多任务深度学习网络进行 A 扫缺陷分类的方法。运用超声相控阵探伤仪检测物体缺陷, 得到 A 扫缺陷波形图; 将得到的 A 扫图像经过预处理, 运用 MATLAB 将波形图像中曲线上的数据进行提取转为二维时序数据; 利用小波变换(WCT)将得到的一维时序数据转为二维时频图像; 最后, 利用深度学习网络 Resnet 进行训练。实验结果表明, 利用小波变换结合深度学习的缺陷识别方式有较高的准确率。

关键词: 时频图像; 缺陷识别; A 扫; 深度学习; 小波变换

A multi-task deep learning method based on A-scan defect recognition

ZOU Chenwei, WANG Diyang

(Aviation Portage College, Shanghai University of Engineering and Technology, Shanghai 201620, China)

【Abstract】 For ultrasonic phased array (NDT) defect detection, this paper proposes a method to classify A-scan defects using a multi-task deep learning network. The ultrasonic phased array detector is used to detect object defects and obtain A-scan defect waveform images; the obtained A-scan images are pre-processed and the data on the curve in the waveform images are extracted and converted into one-dimensional time-series data using MATLAB; the obtained one-dimensional time-series data are converted into two-dimensional time-frequency images using wavelet transform (WCT); finally, the deep learning network Resnet is used for training. The experimental results show that the defect recognition method using wavelet transform combined with deep learning has a high accuracy rate.

【Key words】 time-frequency images; defect identification; A-scan; deep learning; wavelet transform

0 引言

在工业生产过程以及实验研究过程中, 由于各种不可控的原因造成材料或零部件的损伤和腐蚀等情况, 带来的影响不言而喻, 如: 导致工业产品不合格, 缩短材料或设备使用寿命, 因材料或零部件的不合格有可能会产生一系列事故。

近年来, 无损检测技术迅速发展, 国内外针对缺陷图像缺陷检测的方法层出不穷。孙晓帮^[1]等设计基于线扫视觉的自动表面缺陷检测系统, 利用二值计算过滤较小瑕疵, 对图像进行腐蚀, 随后进行膨胀, 去除毛刺、孤立点等, 实验表明该方法适用于较为明显的缺陷, 对于内部缺陷或表面不明显的缺陷检测效果不佳; 韩君利^[2]等提出一种基于机器视觉的检测方法, 利用线扫相机自动完成对表面缺陷检测任务, 该方法在检测的便捷性上有一定的优势, 但重度依赖线性相机; 蔡松钱^[3]提出一种卷积神经网络的缺陷检测

方法, 首先对网络参数与结构进行微调, 放入图像, 并提取特征部分进行缺陷分类和定位, 该方法网络层数低, 对图像中较小特征的识别效果较差, 训练时间长, 精度不高; 姚宗伟^[4]提出一种使用全卷积神经网络进行缺陷检测, 但该方法的理解能力不足, 模型过于冗余, 训练过程时间长; 陈宗仁^[5]提出一种基于深度学习的缺陷检测方法, 经过预处理后, 利用 FCN 网络训练多个级联分类器, 结合决策权重, 实现缺陷检测。

利用深度学习进行检测的方法层出不穷, 通过二维时频图像进行缺陷检测较少。本文利用深度学习 Resnet 网络相关方法, 能够准确的对缺陷进行识别与分类, 具有训练时间短, 准确率高等特点。

1 Resnet 网络结构

Resnet 网络是基于卷积神经网络而提出的^[6], 其最大的特点在于从输入到输出只有一条主线, 能

作者简介: 邹宸玮(1996-), 男, 硕士研究生, 主要研究方向: 图像处理、图像识别; 王狄颀(1998-), 男, 硕士研究生, 主要研究方向: 图像处理、图像识别、深度学习。

收稿日期: 2022-05-23

够直观的保留部分容易被忽略的小感受野目标特征,同时还能解决神经网络的退化问题,可以实现跨层式的信息传递,以这种方式保留更多的细节特征信息,有效的避免由非线性问题引起的衰减。Resnet 网络加入了对网络学习和测试起到重要作用的 BN (Batch Normalization) 层,能够有效解决梯度爆炸和收敛速度缓慢的问题,在一定程度加快网络的训练速度,减少网络训练时间。另一方面,加入 BN 层能够起到正则化的作用,再考虑过拟合中 Dropout、L2 正则化参数的问题。

神经网络学习的过程中,当网络加深到一定层次时,权值梯度弥散较慢,进而造成训练效果很差。而 Resnet 网络中的残差结构就是基于这一理念而设计的,该网络将输入直接加到输出中,有效的避免了网络不断加深时,非线性函数的衰减问题,残差结

构如图 1 所示。

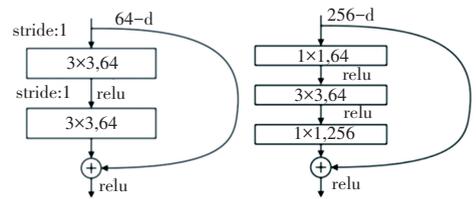


图 1 残差结构

Fig. 1 Residual structure

Resnet 网络结构灵活,只要适当的修改网络内的残差结构块数量,就能够起到调整网络的作用。相较于传统的卷积神经网络,Resnet 网络对网络权重的波动更为敏感,Resnet 网络所需的计算量大幅下降,复杂度也进一步降低^[7]。具体 Resnet 网络结构如图 2 所示。

layer name	output size	18-layer	34-layer	50-layer	101-layer	152-layer
conv1	112×112	7×7,64, stride 2				
conv2.x	56×56	3×3,max pool, stride 2				
		$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 64 \\ 3 \times 3, 64 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 64 \\ 3 \times 3, 64 \\ 1 \times 1, 256 \end{bmatrix} \times 3$
conv3.x	28×28	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 128 \\ 3 \times 3, 128 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 4$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 128 \\ 3 \times 3, 128 \\ 1 \times 1, 512 \end{bmatrix} \times 8$
		$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 256 \\ 3 \times 3, 256 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 6$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 23$	$\begin{bmatrix} 1 \times 1, 256 \\ 3 \times 3, 256 \\ 1 \times 1, 1024 \end{bmatrix} \times 36$
conv4.x	14×14	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 2$	$\begin{bmatrix} 3 \times 3, 512 \\ 3 \times 3, 512 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$	$\begin{bmatrix} 1 \times 1, 512 \\ 3 \times 3, 512 \\ 1 \times 1, 2048 \end{bmatrix} \times 3$
		average pool,1000-d fc, softmax				
FLOPs		1.8×10 ⁹	3.6×10 ⁹	3.8×10 ⁹	7.6×10 ⁹	11.3×10 ⁹

图 2 Resnet 网络结构

Fig. 2 Resnet network structure

本文对 Letnet-5、Alexnet、Resnet18、Resnet34、Mobilenet-V2 等 5 种网络进行了实验,网络训练准确率汇总见表 1。Resnet18 与 Resnet34 效果较好,网络训练的准确率较高,但综合训练时间与精度两个因素,最后选择 Resnet18 网络与小波变换作为本文的主要网络和方法。

表 1 网络训练准确率

Tab. 1 Network training accuracy %

网络	短时傅里叶变换 Train-Acc	小波变换 Train-Acc
Letnet-5	67.3	73.9
Alexnet	71.7	87.5
Resnet18	92.2	98.9
Resnet34	89.7	98.4
Mobilenet-V2	47.2	79.2

2 时频图像转换

2.1 数据提取

将时频图像作为训练集进行训练之前,需提取 A 扫波形图像的数据,随后将提取出的一维时序数据转换为二维时频图像。

首先进行预处理,预处理包括对数据进行归一化处理和去噪,主要有极大值抑制、相关性去噪、阈值等去噪方式。阈值去噪的方法计算速度更快且噪声抑制效果好^[8],本文选择阈值去噪方式,随后进行波形数据的提取,在波形数据提取过程根据波形变化,若波形变化缓慢,则采用离散小波变换分解(DWT);若波形变化较快,则采用非抽取性小波变

换分解(UWT)。

2.2 时频图像转换

目前,针对一维时序数据转为二维时频图像的方法较多,如短时傅里叶变换(SIFT)、马尔科夫变迁场(MTF)、格拉姆角场(GAF)、小波变换(WCT)、S变换等方法^[9]。本文采用小波变换将波形图像中得到的时序数据转换成二维时频图像,随后放入深度学习网络模型中进行训练。

小波变换有较强的数据提取能力,其能量较为集中,能够在信号中提取到有用的信息。在利用小波变换的过程中,小波基函数尤为重要,其会发生衰减且其长度有限^[10]。利用这个特点,使用小波基函数代替三角函数实现傅里叶变换,并按照需求调整小波变换的尺度,得到不同时度的小波,进而实现多分辨率与局部的时频分析^[11]。小波变换的公式(1)^[12]:

$$WT(a, \tau) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) * \varphi\left(\frac{t - \tau}{a}\right) dt \quad (1)$$

其中, $\varphi(t)$ 、 a 、 τ 分别代表小波母函数、尺度值与偏移量,可以控制小波函数的收缩和平移。

根据需求对小波变换的时频窗进行调整,对不同特点的信号进行调节,对低频信号加宽窗,对高频信号降低窗值。

利用小波变换,将图 3 中的原图数据转为二维时频图像并分别转换为二维时频图像,结果如图 4 所示。

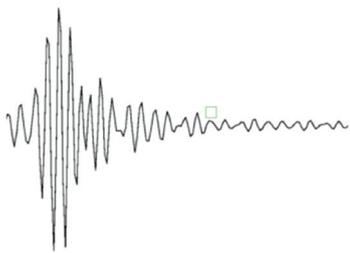


图 3 原图数据

Fig. 3 Original drawing data

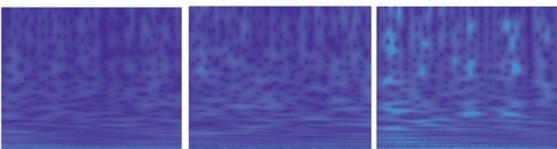


图 4 二维时频图像

Fig. 4 Two dimensional time-frequency image

3 实验与分析

本文将数据集 5 个类型的图像以 8 : 2 的比例分为训练集与验证集。用 Resnet18 网络,对优化器的选取与学习率参数进行选择,以筛选出适合的

优参数。

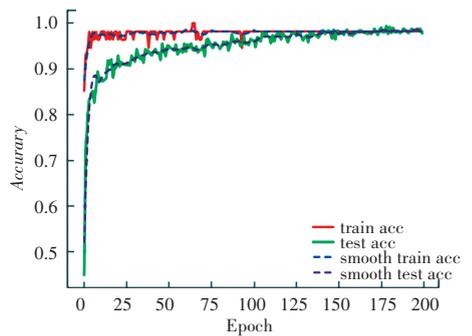
实验样件的缺陷分为裂纹、腐蚀、划痕、油渍、夹杂等 5 种,分别用标号 1-5 对上述 5 种缺陷进行表示。对实验样本中的各个缺陷类型进行多次采样,获取对应缺陷的 A 扫描样本数据集。随即提取数据,并将其转为二维时频图像,并对时频图像数据进行扩充,最后进行训练。

3.1 实验步骤

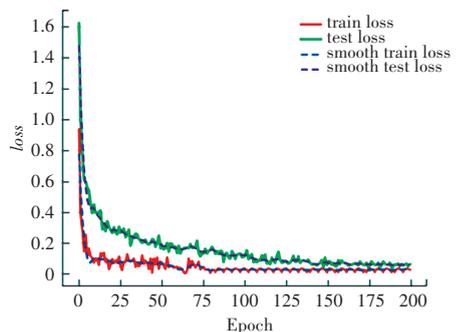
- (1) 利用超声相控阵探伤仪对缺陷检测样本进行检测,得到 A 扫图像数据;
- (2) 提取波形图上数据;
- (3) 将提取到的一维时序数据进行小波变换,转为二维时频图像;
- (4) 将所采集的数据进行数据扩充,利用本文的网络进行训练,得到训练模型;
- (5) 对模型中参数进行微调,避免过拟合、训练精度低等情况。

3.2 实验参数设置

选用 Resnet18 网络,将 SGD 与 Adam 两种优化器作为实验变量,选择 3 种学习率 learning rate (lr) 即 0.000 1、0.001、0.01 分别进行训练。设定每轮训练次数 Epoch 为 200,每批样本大小 Batch size 为 16,利用小波变换得到二维时频图像,训练曲线图如图 5~图 10 所示。



(a) 准确率



(b) 损失率

图 5 SGD+lr=0.000 1 训练曲线图

Fig. 5 SGD+lr=0.0001 training curve

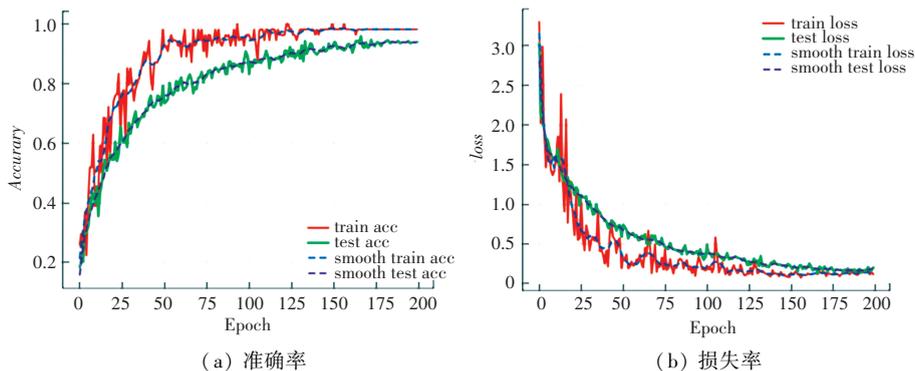


图6 SGD+lr=0.001 训练曲线图
Fig. 6 SGD+lr=0.001 Training Curve

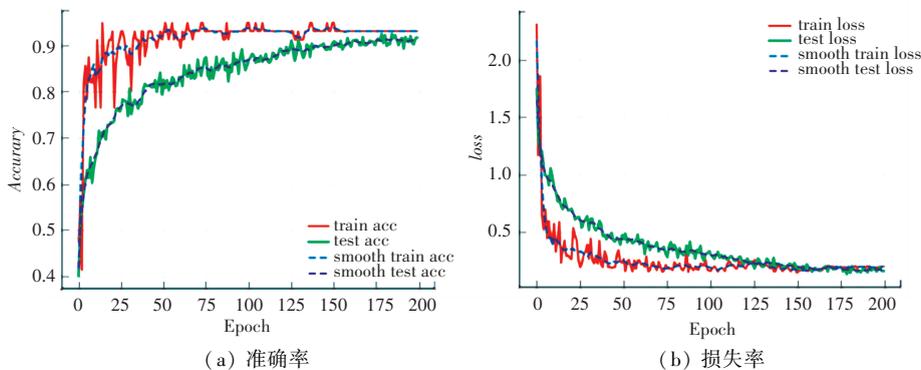


图7 SGD+lr=0.01 训练曲线图
Fig. 7 SGD+lr=0.01 training curve

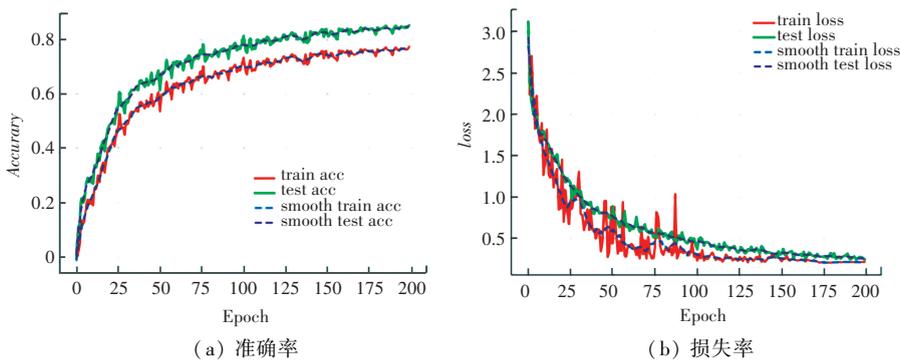


图8 Adam+lr=0.0001 训练曲线图
Fig. 8 Adam+lr=0.0001 training curve

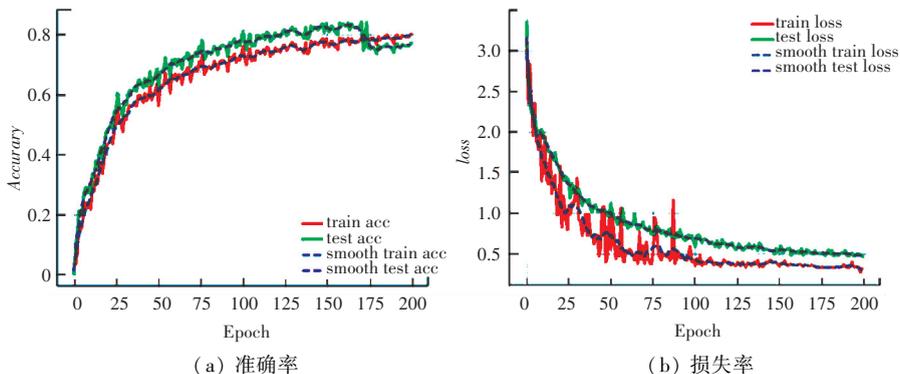


图9 Adam+lr=0.001 训练曲线图
Fig. 9 Adam+lr=0.001 training curve

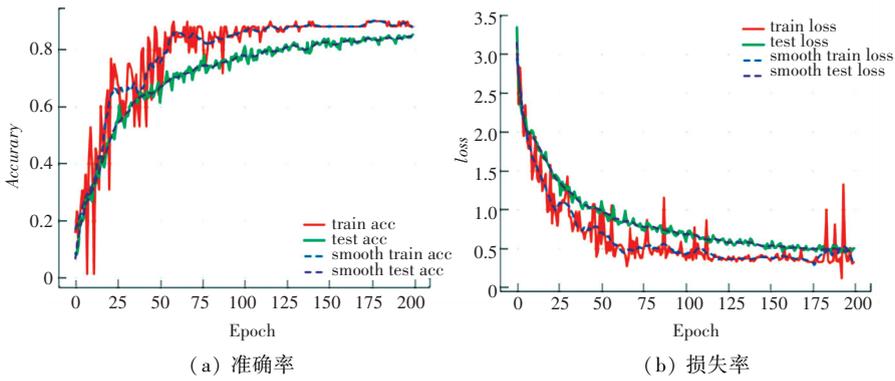


图 10 Adam+lr=0.01 训练曲线图

Fig. 10 Adam+lr=0.01 training curve

3.3 实验结果分析

由图 5~图 10 可知,使用不同的优化器与学习率,训练准确率有所差异,所有方式的训练准确率均大于 78.32%,效果较为良好,但有的训练曲线图的振荡较为明显,拟合度较差,采用 Adam 优化器,学习率为 0.01 的情况下尤为明显;利用 SGD 优化器,学习率为 0.0001 时,准确率最高。不同优化器与学习率对应的最高准确率见表 2。

表 2 两种优化器对应不同学习率的最高准确率

Tab. 2 Maximum accuracy of two optimizers corresponding to different learning rates

优化器类型	学习率	最高准确率/%
SGD	0.000 1	98.90
SGD	0.001	98.57
SGD	0.01	93.15
Adam	0.000 1	85.24
Adam	0.001	81.79
Adam	0.01	86.71

通过表 2 与不同组合的训练曲线图,可以得出结论:本文 Resnet18 网络采用 SGD 优化器,学习率参数设置为 0.000 1 时,效果最好,最高准确率能够达到 98.90%。

3.4 缺陷识别

将验证集中每种类型图像各选取 5 张,对其进行识别与类型检测,得到具体某张图像的分类以及其对应的概率见表 3,可见各类型检测效果较好,识别率较高,能够较为准确的识别出图像所对应的类型。

表 3 识别概率

Tab. 3 Recognition probability

编号	实际类型	预测类型	概率/%
1	裂纹	裂纹	99.5
2	夹杂	夹杂	96.7
3	腐蚀	腐蚀	100
4	划痕	划痕	99.8
5	油渍	油渍	99.2

3.5 评价指标

本文采用准确率 (Accuracy)、查准率 (Precision)、召回率 (Recall) 作为模型的评价指标。Accuracy 代表模型预测正确的样本比例; Precision 表示预测正确的正样本准确率; Recall 也叫查全率,旨在找到实际为正的样本中多少被预测正确。

计算公式(2)~式(4):

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

其中, TP 为正样本中被正确识别的数量; FP 为误报的负样本数量; TN 为负样本中被正确识别的数量; FN 为漏报的正样本数量。

经计算求得整个模型的准确率、查准率和召回率,分别为 98.90%、99.25%、98.60%。

4 结束语

本文提出一种基于 A 扫缺陷识别的多任务深度学习,将超声相控阵 A 扫检测的缺陷图像,经过小波变换转换为二维时频图像,利用 Resnet 网络对 5 种类型缺陷进行准确识别。

参考文献

[1] 孙晓帮,苏春阳,王敬朋,等. 基于线扫视觉的活塞杆表面瑕疵检测系统设计[J]. 机床与液压,2020,48(17):75-78.
 [2] 韩君利,李帅孝,於胜军,等. 一种基于机器视觉的炮弹表面缺陷检测系统方案[J]. 中国新技术新产品,2021(15):16-18.
 [3] Tan Abraham Choa(蔡松钱). Defect detection of steel surface using deep learning based on faster R-CNN[D]. 广州:华南理工大学,2019.