

DOI:10.19651/j.cnki.emt.2005574

基于深度学习与多频电磁阵列检测的金属板材表面和内部缺陷识别方法*

李秀艳¹ 夏琦琦¹ 王琦¹ 张荣华² 汪剑鸣¹ 王化祥³(1.天津工业大学 电子与信息工程学院 天津 300387; 2.天津工业大学 电气工程与自动化学院 天津 300387;
3.天津大学 电气自动化与信息工程学院 天津 300372)

摘要:针对传统电磁检测技术对金属内部缺陷检测能力不足问题,提出一种基于深度学习与电磁检测的金属板材表面和内部缺陷识别方法。实验建立了不同深度、位置、数量的9类表面与内部典型气隙缺陷模型,验证了多频检测可行性,考虑阵列传感器激励电压与感应电压关系,引入保持平衡性的数据采集方法扩充数据集并预处理;构建DNN与CNN深度学习网络对各类检测数据特征训练,并由实验效果选取合适参数的网络。实验结果表明,应用DNN或CNN的电磁检测,可实现9类金属板材表面与内部缺陷识别,准确率为90%以上,解决电磁检测数据分类困难问题;对比DNN、CNN效果,DNN分类训练速度更快且更高效。

关键词:深度学习;电磁检测;内部缺陷;分类

中图分类号: TP274+.3 文献标识码: A 国家标准学科分类代码: 510.99

A recognition method for sheet metal surface and internal defects based on deep learning and multi-frequency electromagnetic array detection

Li Xiuyan¹ Xia Qiqi¹ Wang Qi¹ Zhang Ronghua² Wang Jianming¹ Wang Huaxiang³(1. School of Electronics and Information Engineering, Tianjin Polytechnic University, Tianjin 300387, China;
2. School of Electrical Engineering and Automation, Tianjin Polytechnic University, Tianjin 300387, China;
3. School of Electrical Automation and Information Engineering, Tianjin University, Tianjin 300372, China)

Abstract: In practice, traditional metal electromagnetic detection technology is insufficient to detect sheet metal internal defects. In order to solve this problem, a method of recognizing surface and internal defects based on deep learning and electromagnetic detection is proposed in this paper. In our experiment, nine types of surface and internal air-gap defect models with different depths, positions and quantities are built. The feasibility of multi-frequency detection is verified. The relation between excitation voltage and induction voltage detected by array electromagnetic sensor is concerned. Data balance acquisition method is introduced to expand data set before data preprocessing. In order to get the characteristics of measurement data, DNN and CNN are constructed. The appropriate network with suitable parameters is chosen according to the recognition results. The experimental results show that 9 kinds of air-gap defects with different quantities, positions and depths can be recognized by electromagnetic detection applied with DNN or CNN. The recognition accuracy is over 90%. Compared with CNN, DNN is faster and more efficient to classify.

Keywords: deep learning; electromagnetic detection; internal defects; classification

0 引言

金属材料制品已广泛应用于社会生活的各个行业中。在生产过程中,若缺陷存在于金属材料内部,其位置隐蔽却始终存在安全隐患,这会对使用者造成难以估量的损失。

近些年来,随着科技发展,针对金属表面缺陷的检测技术已取得较大发展,最常用的手段有超声波检测^[1]、磁粉检测^[2]、工业视觉法^[3]等,但对内部缺陷的检测能力仍需提高。

基于电磁感应原理并兼具无辐射、非接触、灵敏度高

收稿日期:2020-12-21

*基金项目:国家自然科学基金(61872269,61903273)、天津市自然科学基金(18JCYBJC85300)项目资助

• 118 •

优点的电磁检测^[4-5]技术,能实时反映目标体内物质分布的电特性变化情况。不同被测对象的检测信号包含了不同特征信息,传统电磁检测通过单线圈检测方法^[6]得到被测目标单点特征数据。而对于实际的工业检测过程,局部单点测量数据并不足以反映被测对象的整体信息。所以,由传统单点测量模式发展成为面向二三维空间分布的多点测量模式,可为实时检测设计提供一种全新的优化手段。文中采用阵列传感器^[7]获取被测目标体多组检测数据,但检测过程中多种噪声干扰因素常导致检测数据不确定性。电磁检测数据识别属于不确定性数据分类问题,传统分类算法有KNN^[8]、贝叶斯^[9]等。但传统分类算法有其局限性,例如:对未知样本的识别,KNN可取得较高准确率,但其时间、空间的高复杂度表现易出现在多维样本中;贝叶斯算法假定样本单一属性独立,但实际情况常不成立,故分类准确率在实际情况表现不佳。而深度学习作为一种处理大量先验信息实现数据分类的方法,能结合模拟与实际数据中寻找映射关系,以获取有效的特征表示,并具有较强的鲁棒性、泛化性。

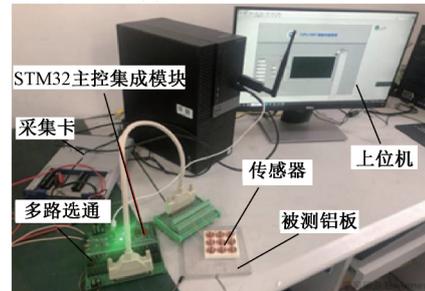
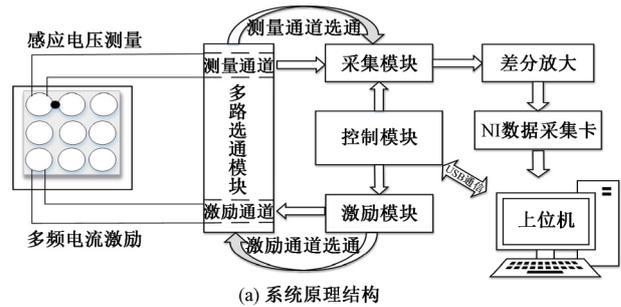
近年来,深度学习在电学检测领域的应用已有初步进展。Xiao等^[10]提出SSAE+RBF和优化的全连接网络两种深度学习方法来学习电磁检测样本之间输入与输出的关系以对检测数据识别。李峰等^[11]以电阻检测数据为基础,提出了一种基于深度学习的6层全连接深度神经网络重建算法,实现了表面缺陷识别可视化。然而,已有研究不仅在数据集、分类算法上存有局限性,且研究对象多为金属表面缺陷或实体,对金属内部缺陷的研究并未涉及。针对这些问题,本文将深度学习与电磁检测相结合,建立9类在金属表面和内部存在典型气隙缺陷的铝板作为研究对象,验证多频检测可行性并建立数据集;搭建深度学习网络训练得到表面和内部缺陷分类模型,实现对金属材料中不同位置、数量、深度的缺陷与测量数据的映射分类。

1 电磁检测系统

1.1 系统结构与检测原理

本文基于电磁测量原理设计了多频电磁检测系统用于金属板材的数据采集。它由电磁传感器、激励模块、STM32控制模块、采集模块、多路选通模块和上位机组成,其原理和实际系统如图1所示。系统总体工作流程为:在激励模块对系统施加激励信号时,控制模块与上位机通过USB双工通信以实现激励通道和测量通道的选择与驱动。其中,激励信号通过激励通道传输至传感器特定线圈,而传感器线圈的感应电压通过测量通道输出,最后测量信号经差分放大电路后由NI采集卡传至上位机。

为与实际检测匹配,设计了阵列传感器,实现了对金属材料电磁检测的感应电压信号获取^[12]。其数据采集策略是先向一个线圈施加激励电流,再依次测量其余线圈感应电压。之后按次序将下一个线圈作为激励线圈通入电流并



(b) 实际系统

图1 系统原理结构与实际系统

测量其余线圈感应电压,重复该过程直到末位线圈激励,最终得到 9×8 个测量数据。传感器既要实现各线圈自感值等同以保证各线圈检测信号的一致性,又要考虑传感器大小与实际板材形状与大小匹配,所以线圈设置了相同且合适的几何参数。线圈模型与几何参数如图2、表1所示。

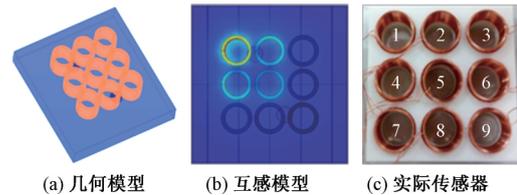


图2 平面阵列电磁传感器

表1 平面阵列传感器的线圈参数

平面阵列传感器线圈参数	
线圈匝数/ n	50
线圈外径/mm	2.2
线圈内径/mm	1.2
线圈高度/mm	6
线径/mm	0.25

1.2 多频检测可行性测试

基于阵列传感器的电磁检测,通过传感器线圈对被测目标体施加一定频率激励来检测包含目标体内部电特征信息的感应电压^[13]。为验证电磁检测对被测目标的内表缺陷可行性,观察了内表面缺陷铝板的磁通密度模的分布情况。3类表面缺陷模型的磁通密度模分布如图3所示,可以发现,表面缺陷直接影响了被测材料的磁通密度模分布,验证了电磁检测对于金属表面缺陷的可行性。

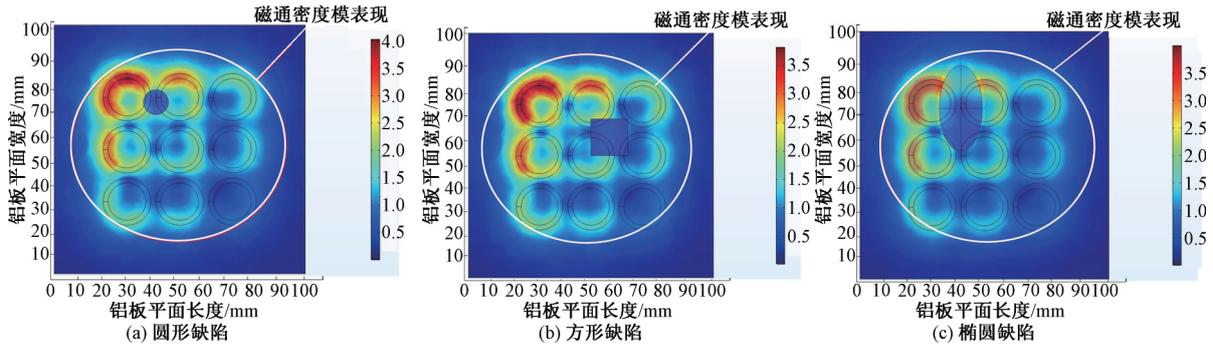


图 3 表面缺陷对铝板磁通密度模影响

电磁检测对金属深度下的内部缺陷测量,须考虑集肤效应^[14],它提供了多激励频率下传感器感知金属材料不同深度层信息的理论支撑。交流信号通过导体,导体表面电子相对集中,有效载流空间相对狭窄,此现象为集肤效应。

$$\delta = \sqrt{\frac{2}{\omega\mu\sigma}} = \frac{1}{\sqrt{\pi f\mu\sigma}} \quad (1)$$

式中: δ 表示集肤深度; ω 为角频率; σ 为电导率; μ 为磁导率; f 为频率, $\omega = 2\pi f$ 。由式(1)可知金属的集肤深度与

频率的 $1/2$ 次方成反比。可知金属的集肤深度与频率的 $1/2$ 次方成反比。在材料确定时检测频率越高所对应集肤深度越小。若缺陷深度远大于检测频率对应集肤深度,缺陷不会对感应磁场产生扰动而导致无法检测,所以多频激励^[15]被广泛用于电磁检测以获取金属材料不同深层的信息。因此,实验建模分析了多激励频率下缺陷铝板内部的磁通密度模分布状态,如图 4 所示,直观展现了多激励频率对检测深度的影响。

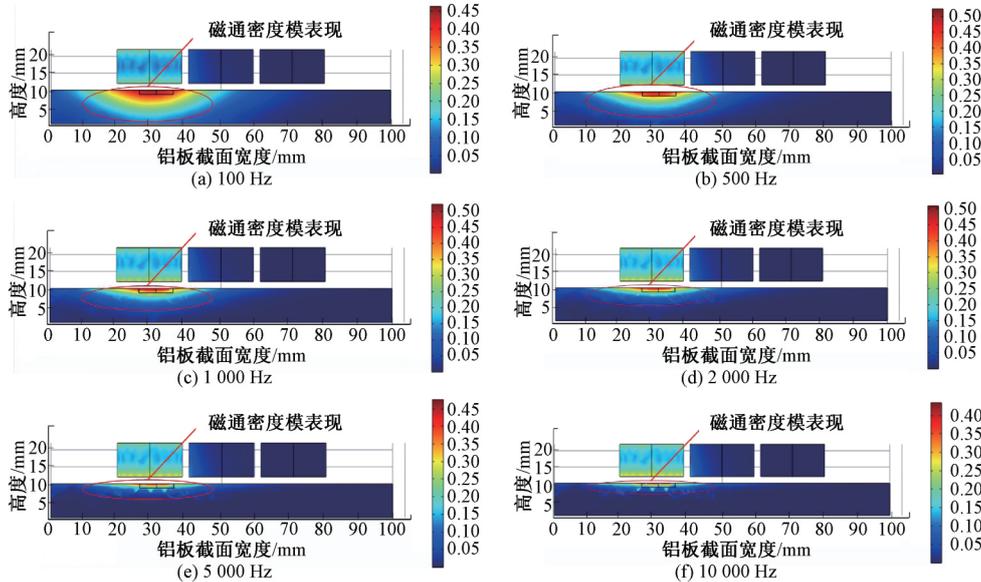


图 4 多频激励对缺陷铝板深度的磁通密度模影响

在此分析的基础上,进一步量化了检测频率与铝板检测深度深度的非线性映射关系,从而得到铝板检测深度与敏感检测频率的对照曲线,如图 5 所示。

由图 4、5 分析可知,线圈激励频率为 100、500、1 000、2 000、5 000、10 000 Hz 时,被测铝板磁通密度受频率影响,被测铝板的可检测缺陷深度随激励频率变化而改变。当激励频率减小,内置缺陷铝板感应磁场深度会增大,此时集肤深度基本符合该激励频率参数下的理论值;当检测频率区间为[500 Hz, 1 000 Hz]、[1 kHz, 3 kHz]、[5 kHz, 15 kHz]时,其对应检测深度区间约为[2.5 mm, 3.7 mm]、

[1.5 mm, 2.5 mm]和[0.05 mm, 1.1 mm]。这验证了电磁检测对于内部缺陷的可行性。同时,根据此对应关系对金属板材深度区间进行传感器信号的采集,为数据集建立提供了理论依据。

2 适用于电磁检测的深度学习网络

为实现对金属缺陷的识别,本文结合了深度学习的特征提取能力,以建立多频率激励条件下的电磁检测数据与缺陷的映射关系。为选择适合电磁检测数据分类的网络,需要考虑检测数据输入与各网络输入特性的匹配度。由

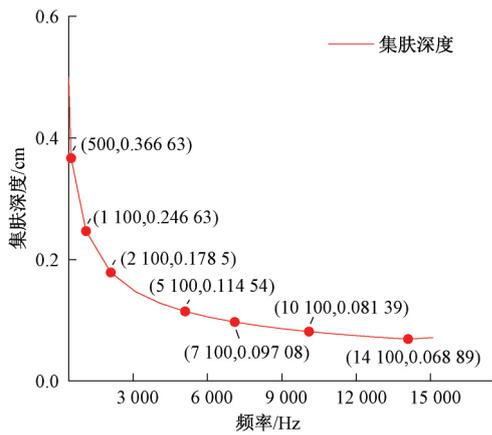


图 5 铝板检测深度与敏感频率对照曲线

于检测数据为维度为 9×8 的数据矩阵,这与 DNN 或 CNN 网络输入相匹配,所以本文采用 DNN 与 CNN 网络进行了电磁检测对金属板材表面、内部缺陷识别研究,并对比两种网络的识别效果。

2.1 深度神经网络(DNN)

本文采用 DNN 网络^[16]对金属板材表面和内部缺陷识别。DNN 包括输入层、多个隐含层和输出层。每一层输出作为下一层输入,利用激活函数对输出做非线性变换以预测输出。根据电磁检测过程设计了用于缺陷识别的 DNN 网络结构,如图 6 所示。将 72 个检测信号预处理后作为网络输入层。根据输入数据大小设置了不同深度与

结点的网络层来满足实验要求,最后通过全连接 softmax 层选择输出最大概率的缺陷类别,以实现分类识别。

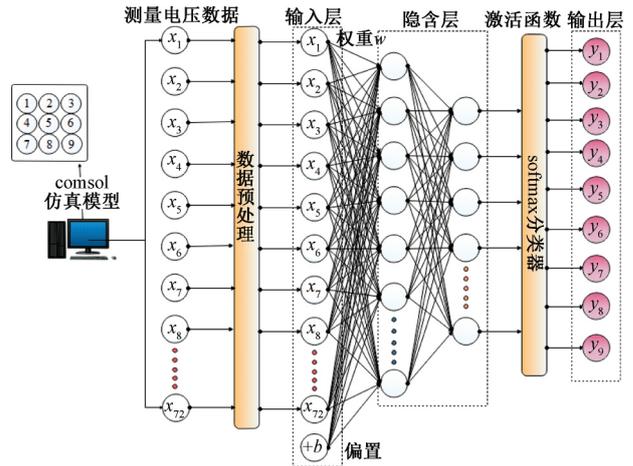


图 6 适用于电磁检测的 DNN 网络

2.2 卷积神经网络(CNN)

CNN 已广泛应用于图像识别^[17-18]等领域,将电磁检测数据转化为图像格式同样可将 CNN 网络应用于电磁检测信号识别。为对比识别效果,本文进一步构建 CNN 缺陷识别网络,如图 7 所示。首先,将测量数据矩阵经插值算法扩展为维度为 32×36 的数据矩阵以满足 CNN 输入需求,然后经卷积与池化对输入压缩并提取反映缺陷位置、数量、深度的数据特征,最后经 softmax 输出识别结果。

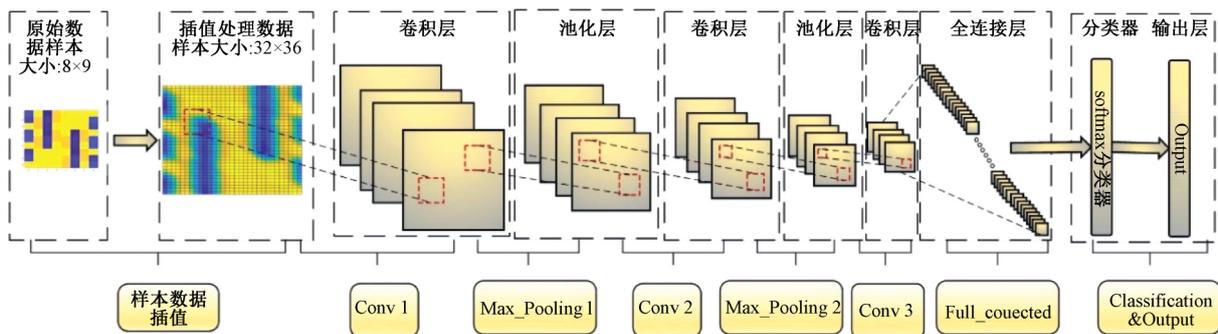


图 7 适用电磁检测的 CNN 网络

3 数据集与预处理

在金属板材中常见缺陷主要为表面凹坑、内部气隙等^[17]。不同缺陷的电磁检测数据存在不同的特征状态。本文设计了不同数量、位置、深度的同种属性的 9 类典型气隙缺陷,采用铝板为被测对象,其尺寸为 $12 \text{ cm} \times 12 \text{ cm} \times 1 \text{ cm}$,缺陷为半径 0.5 cm ,高度 0.1 cm 的典型气隙圆柱。

3.1 数据集组成与扩充

不同缺陷模型的检测数据集构建在研究中占有很大工作量,也是后续研究的基础。建立了气隙缺陷数量为 1、

2、4,缺陷分布如图 8 所示的 3 种金属板材表面缺陷模型。为便于分析,3 种模型对应命名为 1D、2D、4D。

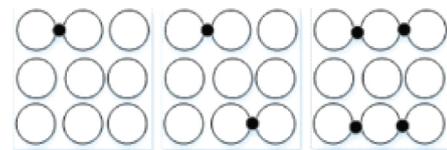


图 8 平面下不同数量、位置的缺陷设置

为表现缺陷深度差异,将 3 种模型的缺陷置于 3 种深度,最终得到 9 类缺陷模型。因缺陷自身属性决定其占用相对深度间隔为 1 mm 。深度区间换算为铝板高度后,将

缺陷放置于金属铝板的 [9 mm, 10 mm]、[7.5 mm, 8.5 mm]、[6.3 mm, 7.3 mm] 3 种深度区间, 各区间对应命名为 depth1、depth2、depth3, 则缺陷在铝板截面深度分布如图 9 所示。

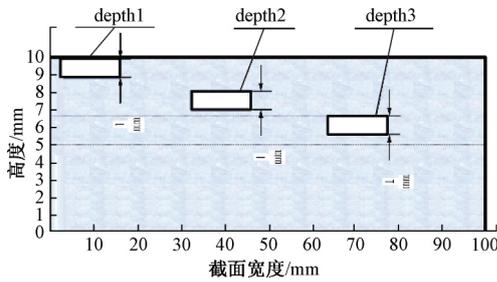


图 9 缺陷深度分布

由 1.2 中集肤效应模拟结果可为缺陷深度区间的检测频率范围设定提供依据。需特别指出的是, 当检测频率在 15 kHz 以上时, 其检测深度基本趋于金属表面, 所以该频率区间可用于进行表面缺陷的检测。因此, 将 3 种深度区间对应的检测频率区间设置为 [500 Hz, 1 000 Hz]、[1 kHz, 3 kHz]、[5 kHz, 30 kHz]。为获得足量数据集, 本文将处于较浅深度的缺陷检测频率上限取为 30 kHz。为便于说明, 将 9 类模型分别命名为 1D_depth1、2D_depth1、4D_depth1、1D_depth2、2D_depth2、2D_depth3、1D_depth3、4D_depth2、4D_depth3。

以上述的检测频率设定方法对 9 类模型进行测量, 得到对应的电磁检测数据, 如图 10 所示。分析发现, 铝制板材虽受缺陷数量、位置和深度的影响, 但各类电磁检测数据之间区分度并不明显。所以, 采用深度学习网络对数据样本进行训练, 通过提取各类缺陷的电磁检测数据特征, 得到分类网络模型, 最终可实现对金属板材表内部

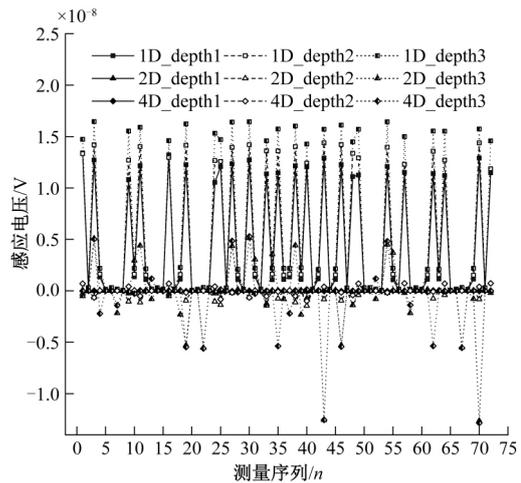


图 10 9 类缺陷对应的电磁检测数据对比

缺陷的识别。

由于电磁检测训练数据不充足时常导致训练过程过拟合, 影响识别准确率。各类数据不均衡, 数据偏斜也对其有影响。所以, 为保证电磁检测数据的样本容量及平衡性, 需获取各类模型足量且具有良好质量的样本。因此, 本文构建数据集时采取了最优测量深度区间与最优检测频率区间的等距离交叉^[19]选取的采集方法来保证样本分布均衡性。将检测深度区间和对应检测频率区间以特定深度步长和频率步长分割, 分别得到对应数量的深度序列 (m) 和频率序列 (n), 由二者组合确定检测激励条件, 最终得到理论条件 $m \times n = x$ 个均衡分布的感应电压数据。经数据筛选, 9 类模型得到 43 120 个样本。每类数据的采集策略和样本数量如表 2 所示。将样本按 4 : 1 的比例分为训练集、测试集用网络训练和测试。

表 2 9 类模型电磁检测数据集采集策略和样本集

被测模型	检测深度区间/mm	检测深度步长/mm	检测频率区间/kHz	检测频率步长/Hz	理论样本量	实际样本量
1D_depth1	[9, 10]	0.1	[5, 30]	100	6 061	5 550
2D_depth1	[9, 10]	0.1	[5, 30]	100	6 061	5 100
4D_depth1	[9, 10]	0.1	[5, 30]	100	6 061	5 300
1D_depth2	[7.5, 8.5]	0.1	[1, 3]	3	5 511	4 800
2D_depth2	[7.5, 8.5]	0.1	[1, 3]	3	5 511	4 750
4D_depth2	[7.5, 8.5]	0.1	[1, 3]	3	5 511	4 770
1D_depth3	[6.3, 7.3]	0.1	[0.05, 1]	1	5 511	4 200
2D_depth3	[6.3, 7.3]	0.1	[0.05, 1]	1	5 511	4 350
4D_depth3	[6.3, 7.3]	0.1	[0.05, 1]	1	5 511	4 300

3.2 数据预处理

电磁检测中不同属性缺陷模型所检测的信号相似且复杂, 故对数据集进行了预处理。因检测数据包含了金属材料内部物场信息并反映在测量数据幅值高点, 为提高数据质量, 设定幅值在 0 附近的检测数据为无效数据点并置 0。

为提高模型求解精度和求解速度, 保证每组数据序列差异性, 将数据进行分组归一化。

$$U^* = \frac{U_i - U_{\min}}{U_{\max} - U_{\min}} \quad (2)$$

式中: U_i 表示检测信号序列第 i 个电压; U_{\min} 表示检测信

号序列最小电压; U_{\max} 表示检测电压序列最大电压; U^* 表示第*i*个检测信号归一化值。另外,为满足CNN输入条件并保持数据特征稳定,将 8×9 的数据矩阵插值扩充为 32×36 大小作为输入。

4 实验方法和结果分析

4.1 实验环境与参数设定

本文实验的硬件环境为:CPU: Intel (R) Core (TM) i7-7700 CPU@3.60 GHz;GPU:NVIDIA GeForce RTX2060;RAM:16G。

通过检测获得预处理数据集后,对深度学习网络进行训练实验。为选取合适的超参数以识别不同检测数据,两类深度学习网络训练过程中,以训练误差来反映训练的状态。其中,在DNN训练中,将隐含层设置为2层,通过更改隐含层结点数,设置不同学习率训练,最后分析两种网络实验结果。两种DNN隐含层结点数分别为30,15和15,15,对应网络以DNN-1、DNN-2表示;在CNN训练中,设定了4种卷积核大小或网络层数存在差异的CNN结构,并用CNN-1、CNN-2、CNN-3、CNN-4表示。DNN和CNN网络参数设置分别如表3、4所示。

表3 DNN网络参数设置

DNN	DNN-1	DNN-2
输入层	9×8	9×8
隐含层1	15	30
隐含层2	15	15
输出层	9类输出	9类输出

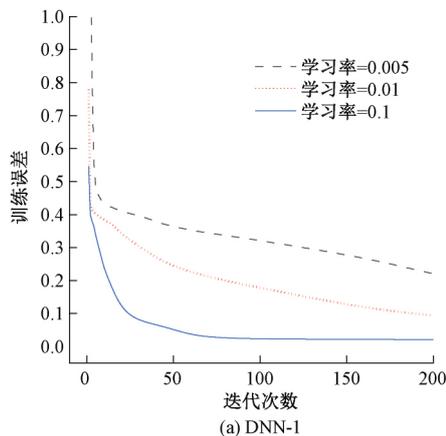


表4 CNN网络参数设置

CNN	CNN-1	CNN-2	CNN-3	CNN-4
输入层	32×36	32×36	32×36	32×36
卷积核	5×5 /步长1	3×3 /步长1	3×3 /步长1	3×3 /步长1
卷积层	28×32	30×34	30×34	30×34
池化核	2×2	2×2	2×2	2×2
池化层	14×16	15×17	15×17	15×17
卷积核	3×3 /步长1	4×4 /步长1	6×6 /步长1	4×4 /步长1
卷积层	12×14	12×14	10×12	12×14
池化核	2×2	2×2	2×2	None
池化层	6×7	6×7	5×6	None
输出层	9类输出	9类输出	9类输出	9类输出

4.2 DNN训练

为确定两种适用于电磁检测的DNN网络最优学习率,令数据训练达到良好收敛速度。两种DNN网络训练模型将初始学习率分别设置为0.005、0.01、0.1,以训练误差随迭代次数的变化来反映训练收敛过程,如图11所示。可以发现,两种网络训练模型在迭代次数为200次的训练过程中逐步学习,训练误差逐渐减小,最终达到0.01左右,说明输出值与电磁检测的归一化输入数据之间的误差在逐渐减小;两种网络结构在学习率设定为0.1时,训练误差下降最快,迭代次数最少,说明此条件下DNN-1与DNN-2网络训练速度最快。

根据所得的最优学习率0.1,进一步对比学习率0.1时,DNN-1与DNN-2训练过程中的训练误差变化,如图12所示。可以发现,DNN-1与DNN-2分别在迭代次数

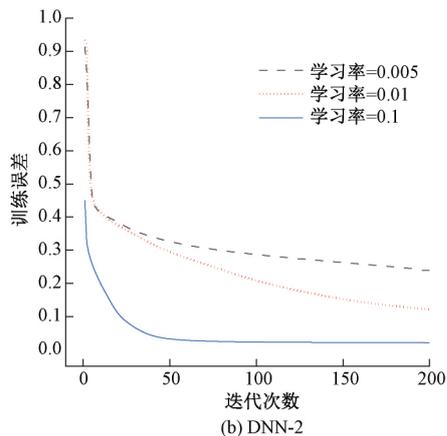


图11 学习率为0.005、0.01、0.1时,DNN-1与DNN-2的训练误差变化

为70和50时下降平缓,说明DNN-2训练模型的用时最少,训练效率更高。因此,在DNN网络实验中,应用DNN-2更适用于电磁检测对金属板材表面和内部缺陷的识别问题。

4.3 CNN训练

为分析学习率对CNN训练检测数据过程的影响,对

4种CNN网络设置了3种学习率来进行实验。图13反映了学习率为0.2、0.5、1时,4种CNN网络训练过程中的训练误差变化。CNN-1、CNN-2、CNN-3、CNN-4在学习率设定为0.5、1时,训练误差在迭代过程中不断减小,最终均保持在0.05以下;学习率为1时训练误差最小,说明网络学习9类数据特征表现相对最佳;学习率为0.2时,4种网络

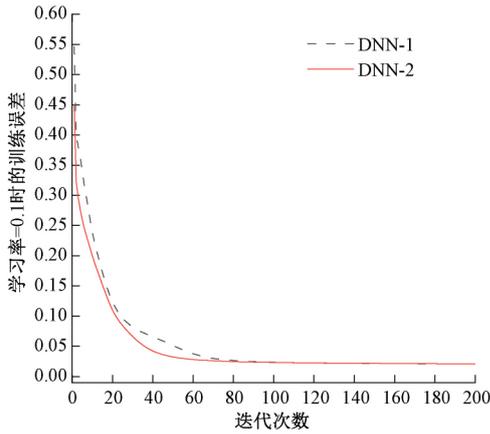


图 12 学习率 0.1 时 DNN-1 与 DNN-2 训练误差变化

训练误差下降至 0.4 并保持,说明训练遇到瓶颈,不适合实验中的缺陷识别,所以在训练过程选取最佳学习率为 1 效果最优。

选取学习率为 1 时的 4 种 CNN 网络训练过程下的训练误差变化状况作对比,如图 14 所示。训练过程中,CNN-3 的训练误差下降最快至 0.01。所以,CNN-3 在 4 种 CNN 模型中具有更好训练效果。

4.4 网络效果对比

根据 DNN 和 CNN 网络训练的训练误差变化,选取了训练误差最小的 DNN-2 和 CNN-3 两种网络以进行实验效果的对比。利用测试集中的电磁检测数据在网络模型中进行测试,分析了 9 类缺陷模型的每一类识别率与平均识别率。另外,对两类模型训练用时进行了分析比较,如表 5 所示。

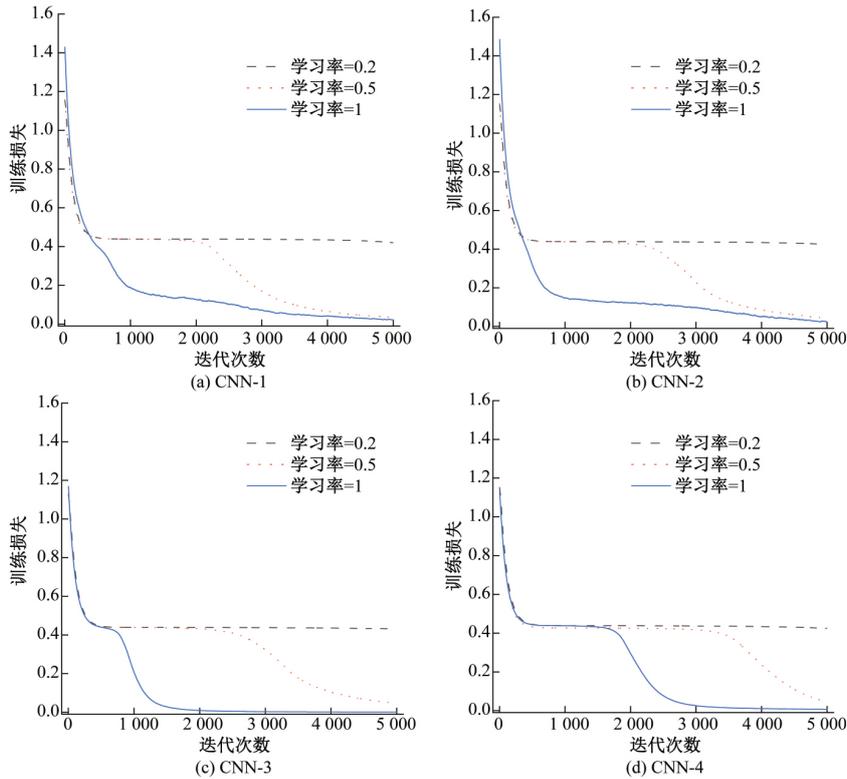


图 13 学习率 0.2、0.5、1 时,4 种 CNN 网络训练误差变化

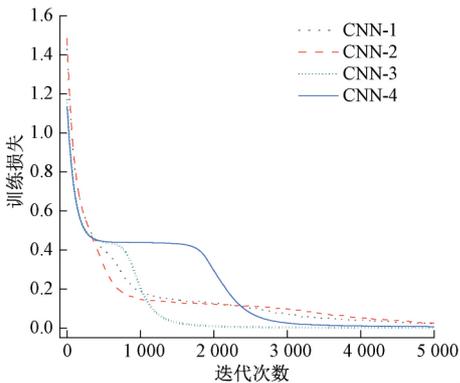


图 14 学习率 1 时,4 种 CNN 网络训练误差变化对比

表 5 DNN,CNN 网络对电磁检测数据识别率

网络类型	DNN2	CNN3
1D_depth1	97.5%	95.8%
2D_depth1	97.8%	96.0%
4D_depth1	97.1%	94.6%
1D_depth2	95.3%	95.0%
2D_depth2	96.6%	96.3%
4D_depth2	96.3%	96.0%
1D_depth3	94.4%	94.5%
2D_depth3	97.5%	95.8%
4D_depth3	97.8%	94.6%
平均识别率	96.7%	95.4%
训练时间	200 s	3 600 s

在识别准确率方面,DNN-2和CNN-3对不同位置、数量、深度的各类缺陷均可得到90%以上的平均识别率,其平均识别率分别为96.7%和95.4%。且该方法为直接识别,检测数据直接映射对应缺陷种类标签。

在网络训练用时方面,DNN-2明显耗时更短,故相比于CNN-3,DNN-2更适用于电磁检测数据的分类问题。归结耗时区别原因,主要由于与CNN相比,DNN网络的数据输入较少而具有较小运算量。

5 结 论

本文提出了一种基于深度学习与多频电磁阵列检测的金属板材表面和内部缺陷识别方法,通过缺陷模型设置、检测数据采集、深度学习网络训练,实现了对铝制金属板材中不同深度、位置、数量的9类典型气隙缺陷的分类,有效解决了目前检测方法对于金属板材表面和内部缺陷识别能力不足的问题。实验结果表明,DNN和CNN对于金属表面和内部缺陷分类能力可以达到90%以上的准确率;DNN输入数据尺寸小,网络参数量小,速度快,更适用于工业电磁检测中大批量产品在线实时的连续测量任务,充分证明了DNN应用于电磁检测缺陷识别的优越性。考虑到真实环境下的板材缺陷种类复杂,在今后的工作中还需进一步建立多缺陷种类的模型以扩展数据集,从而提高网络识别的泛化性。

参考文献

- [1] 鲁改凤,侯鹏飞,范茜勉,等.一种变压器套管末屏放电超声检测装置的研究[J].电测与仪表,2018,55(17):120-124.
- [2] STRAUB M, SCHULZ V. Joint reconstruction of tracer distribution and background in magnetic particle Imaging[J]. IEEE Transactions on Medical Imaging, 2018,37(5):1192-1203.
- [3] XU J K, WANG E Y, ZHOU R. Real-time measuring and warning of surrounding rock dynamic deformation and failure in deep roadway based on machine vision method[J]. Measurement, 2020,149:107028-107028.
- [4] 霍继伟,刘泽,王成飞,等.基于幅值特征提取的混频电磁钢轨探伤方法[J].电子测量技术,2020,43(13):105-110.
- [5] 王超,高鹏.基于GMR的电磁无损检测研究[J].电子测量与仪器学报,2015,29(6):783-792.
- [6] 杨理践,李春华,高文凭,等.铝板材电磁超声检测中波的产生与传播过程分析[J].仪器仪表学报,2012,33(6):1218-1223.
- [7] 汪剑鸣,杨伟明,王琦,等.基于平面阵列电磁传感器的金属缺陷检测新方法[J].传感技术学报,2018,31(1):6-12.
- [8] 李养胜,李俊.基于支持向量机与k-近邻的工件表面缺陷识别算法[J].电子测量技术,2018,41(7):50-53.
- [9] 王琦,张静薇,张荣华,等.基于贝叶斯统计模型的金属缺陷电磁成像方法研究[J].仪器仪表学报,2020,41(1):47-55.
- [10] XIAO J, LIU Z, ZHAO P F, et al. Deep learning image reconstruction simulation for Electromagnetic Tomography[J]. IEEE Sensors Journal, 2018,18(8):3290-3298.
- [11] 李峰,谭超,董峰.全连接深度网络的电学层析成像算法[J].工程热物理学报,2019,40(7):1526-1531.
- [12] 梁远远,杨生胜,文轩,等.脉冲涡流无损检测中缺陷定量技术[J].仪器仪表学报,2018,39(11):70-78.
- [13] 崔东辉,张晓丽,刘同胜.一种高可靠性电涡流位移传感器的设计[J].电子测量技术,2013,36(12):87-91.
- [14] 卢秋朋,张清鹏,秦润杰.传输线中趋肤效应的介绍及仿真[J].电子测量技术,2015,38(6):27-30.
- [15] 白旭,胡辉.基于快速傅里叶变换和互相关的多频微弱信号重构法[J].电子测量与仪器学报,2019,33(3):168-175.
- [16] 王克杰,张瑞.基于改进BP神经网络的短期电力负荷预测方法研究[J].电测与仪表,2019,56(24):115-121.
- [17] 王洋,余祖俊,朱力强,等.基于CNN的高速铁路侵限异物特征快速提取算法[J].仪器仪表学报,2017,38(5):1267-1275.
- [18] 郭蕴欣,张越,马宏.基于CNN的数字信号调制识别研究[J].电子测量技术,2019,42(14):112-116.
- [19] FANG J, QU B, YUAN Y. Distribution equalization learning mechanism for road crack detection [J]. Neurocomputing, 2019, 424(1):193-204.

作者简介

李秀艳,硕士生导师,副教授,主要研究方向为机器学习和电学成像。

E-mail:lixuayan@tiangong.edu.cn

夏琦琦,硕士研究生,主要研究方向为电磁检测与层析成像研究。

E-mail:419030838@qq.com

王琦(通信作者),硕士生导师,副教授,主要研究方向为智能信息处理和电学成像。

E-mail:wangqitju@163.com