

基于卷积神经网络和声振图像的磁瓦内部缺陷检测

刘鑫¹ 黄沁元^{1,2} 李强¹ 冉茂霞¹ 周颖¹ 杨天¹

1 四川轻化工大学自动化与信息工程学院 四川 自贡 643000

2 人工智能四川省重点实验室 四川 自贡 643000

(lx19502@163.com)

摘要 磁瓦作为永磁电机中的关键部件,其产品质量易受到内部缺陷的影响而下降。然而传统的声振检测手段在面对快速、精准的检测需求下已暴露出一些低效率的问题,因此开发一种针对磁瓦内部缺陷的高效智能化检测方法具有重要的现实意义。文中结合深度学习的优势,提出了一种基于卷积神经网络的磁瓦内部缺陷声振检测方法。在该方法中,磁瓦的一维声振信号首先被转换为二维声振图像,再输入针对信号特点所设计的卷积神经网络进行学习训练,以完成从声振图像中自主学习和提取能区分内部缺陷有无的信号特征,最后由 softmax 完成对应特征的识别。4 类磁瓦样本的检测实验结果表明,提出的方法可实现准确率为 99.38% 的磁瓦内部缺陷检测,单片磁瓦的检测时间低于 0.031 s,模型具有良好的鲁棒性。

关键词: 磁瓦; 缺陷检测; 深度学习; 卷积神经网络; 声振图像

中图分类号 TG115.28

Fault Detection for Arc Magnet Based on Convolutional Neural Network and Acoustic Vibration Image

LIU Xin¹, HUANG Qin-yuan^{1,2}, LI Qiang¹, RAN Mao-xia¹, ZHOU Ying¹ and YANG Tian¹

1 School of Automation and Information Engineering, Sichuan University of Science & Engineering, Zigong, Sichuan 643000, China

2 Artificial Intelligence Key Laboratory of Sichuan Province, Zigong, Sichuan 643000, China

Abstract As a key component in permanent magnet motor, the product quality of arc magnet is susceptible to degradation due to internal defects. However, traditional acoustic vibration detection methods have revealed some inefficiencies in the face of fast and accurate inspection requirements, so it is of great practical importance to develop an efficient and intelligent detection method for internal defects in arc magnets. This paper combines the advantages of deep learning and proposes a convolutional neural network-based acoustic vibration detection method for internal defects of arc magnets. In this method, the one-dimensional acoustic vibration signal of the arc magnets is firstly converted into the two-dimensional acoustic vibration image, and then fed into a convolutional neural network designed for the signal characteristics for learning and training, to complete the autonomous learning from the acoustic vibration image and extract the features that can distinguish the presence or absence of internal defects. Finally, the corresponding features are identified by softmax. The experimental results of four types of arc magnet samples show that the proposed method can achieve 99.38% accuracy of internal defect detection of arc magnets, the detection time of a single arc magnet is less than 0.031 s and has a high robustness of the model.

Keywords Arc magnet, Fault detection, Deep learning, Convolutional neural network, Acoustic vibration image

1 引言

磁瓦作为永磁电机中关键的部件之一,用于产生稳定的磁场。由于制造过程中不当的温度、压力或人为因素,磁瓦的内部可能出现意想不到的缺陷。这些内部缺陷即使相对较弱,也总是能够降低磁瓦的机械强度,有可能影响其磁性能,也有可能损坏永磁电机,导致致命的事故。然而,由于内部缺陷的隐蔽性和随机性,以及对低成本、速度快的要求,磁瓦内部缺陷检测充满了挑战。目前,常用的检测磁瓦内部缺陷的方法是通过特殊的手工作业来实现的,由训练有素、听觉灵敏

的检测人员通过识别声信号来判断内部缺陷的存在与否。为了在不造成结构破坏的前提下,产生适合鉴定的声信号,通常将磁瓦从一定的高度落下,并在落下的方向上与金属块发生碰撞。磁瓦的硬度高、强度大,当它受到适当的外力冲击时,利于激发声振信号。由于这种人工检测严重依赖人为因素,检测的准确率和速度很难满足检测需求,因此,开发一种磁瓦内部缺陷的自动检测方法具有重要的现实意义。

声振检测是一种取代人工听音辨识的有效方法,其原理是被测磁瓦内部缺陷会影响其激励振动下的声学响应,对这种声学响应进行分析,就能间接地对磁瓦内部缺陷进行定性

或定量判定。基于此,国内学者开展了关于磁瓦内部缺陷检测方法的研[1-4],这些学者利用双谱分析、小波包变换、变分模态分解等方法对信号进行分析,并提取表征磁瓦内部缺陷的特征,再利用朴素贝叶斯、人工神经网络、随机森林等分类器对特征分类识别,实现磁瓦的内部缺陷检测。一个典型的智能诊断方法包含4步:数据获取、特征提取、特征筛选和特征分类。通过传感器系统从设备上采集信号,一般为声发射信号和振动信号。获得的机械振动信号不仅包含反映设备状况的有用信息,也包含无用的噪声信号。因此,特征提取就是只提取有用特征,避免无用信息的干扰。振动信号原本是时域信号,但也可以用频域或时频域表示,相应地,振动信号特征可以从时域、频域和时频域中提取。在特征提取后,因为不能保证所有的特征在反映设备状态方面是同样有用的,高维度的特征集不仅会降低性能,而且会增加分类器学习的负担。最后,将筛选后的特征输入机器学习分类器进行分类识别,判定设备状态。

长期以来,传统的机器学习算法在故障诊断中广泛采用,但这些方法存在一些不足。首先,分类准确率主要取决于提取特征的有效性,这需要对待提取信号有一定的理解并具备丰富的信号处理知识,对每一个具体的故障诊断任务,必须重新设计特征提取器[5]。其次,传统的机器学习算法的结构较为简单,限制了分类器学习复杂故障诊断问题中分类特征的能力[6]。最近,深度学习是机器学习研究中的热门趋势,深度学习是采用深度架构的算法,对不同的抽象层次,学习到多层次的数据表示,具有从输入数据中自动学习多个复杂特征的能力,具有较大潜力克服传统机器学习算法的缺点。目前,已有很多深度学习模型被提出,例如循环神经网络(Recurrent-Neural Network, RNN)、深度置信网络(Deep Belief Network, DBN)、深度玻尔兹曼机(Deep Boltzmann Machines, DBM)、堆栈自编码网络(Stacked Autoencoder, SAE)和卷积神经网络(Convolutional Neural Network, CNN),并应用于实际故障诊断中。深度学习在很多实际应用中大有可为,例如计算机视觉[7]、自然语言处理[8]、医学图像分析[9]和机械健康状态诊断[10]。Yin等[11]利用原始时域信号训练深度1D-CNN,借助CNN逐层挖掘信号隐藏特征,完成智能诊断。Zou等[12]应用离散小波变换和DBN完成高速铁路列车牵引电机轴承故障的诊断。Chi等[13]提出一种基于多标签LSTM-RNN的滚动轴承故障分类方法,提高了故障分类的正确率并减少了训练样本量。

在深度学习算法中,DBM和DBN是基于玻尔兹曼机的,SAE是基于自编码器的,它们都是无监督学习方法,而CNN是监督学习算法,适合处理二维数据。一些研究者已经尝试应用一维CNN模型。Wang等[14]利用一维CNN构建声振传感器数据融合算法,通过分析不同信噪比下的损失函数和准确率,证实其比单模态传感器算法具有更高的诊断正确率。Song等[15]利用奇异谱分解将原始振动信号分解成若干奇异谱分量,再构建一维CNN模型对重构的有效奇异谱分量进行训练和诊断。然而,CNN模型更易于从高维数据中提取信息。基于此,本文提出一种CNN模型,利用二维形式声振图像完成磁瓦内部缺陷诊断。

2 基于CNN的磁瓦内部缺陷检测

正如第1节中提及的,CNN模型更易于从二维图像中提取信息。基于此,我们提出了一种利用CNN在图像分类中的能力进行磁瓦内部缺陷故障诊断的算法。算法整体流程如图1所示。首先,利用2.1节的式(1)[16]将频域振动信号转换为灰度图像。其次,CNN模型自动于灰度声振中学习高维抽象特征。最后,通过softmax函数进行特征分类,完成磁瓦内部缺陷的智能诊断。




图1 提出的模型流程图

Fig. 1 Flow chart of the proposed model

2.1 构建声振图像

磁瓦声振信号都是一维形式,本节将详细描述将振动信号转换为灰度图像的方法,我们称这种类型的图像为声振图像。图2为构建声振图像的过程。首先,将时域磁瓦声振信号通过快速傅里叶变换得到频域信号,然后,将每个样本的振幅归一化,最后利用式(1)将归一化振幅转换为图像中相应像素强度。

$$Pixel[i, j] = A[i * N + j] \quad (1)$$

其中, $i=0:N; j=0:M; Pixel[i, j]$ 是 $M \times N$ 声振图像中相应像素强度; $A[\cdot]$ 是频域振动信号样本归一化幅值。声振图像中像素点个数与振动信号采样点个数相等。

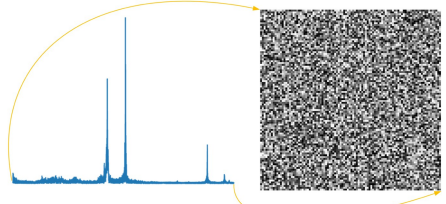


图2 声振图像的构建

Fig. 2 Construction of acoustic vibration images

2.2 利用CNN进行图像分类

一个CNN一般由激活函数、池化层、卷积层、全连接层以及基于梯度优化的方法组成。虽然与传统的多层感知器等方法相比,这些组件可以提高性能,但卷积运算明显改变了训练数据分布,IOFFE等开发了批量归一化算法(Batch Normalization, BN)[17],并采用归一化、缩放和移位等操作来解决内部协方差移位问题。BN不仅可以防止梯度爆炸和梯度消失,加速训练网络收敛,而且可以提高性能。因此在本文提出的方法中引入BN层来提高模型的性能。

文献[17]将BN层放在激活层前面,据此,提出的CNN网络结构如图3所示,共9层,包含卷积层,BN,ReLU,平均池化层,全连接Dense层和softmax分类层。除了表1中给出的网络结构参数,其余层都使用ReLU作为激活函数。




图3 提出的卷积神经网络结构

Fig. 3 Structure of the proposed convolutional neural network

表1 卷积神经网络的结构和参数

Table 1 Structure and parameters of convolutional neural networks

网络结构	卷积核	stride	Padding	输出大小
输入	—	—	—	100×100×1
卷积	8×(2,2)	2	same	50×50×8
卷积	64×(3,3)	2	same	25×25×64
BN	—	—	—	25×25×64
ReLU	—	—	—	25×25×64
平均池化	(2,2)	—	—	12×12×64
Dense	—	—	—	9216×1
Dense	—	—	—	1024×1
softmax	—	—	—	8×1

声振图像输入 CNN 网络,由卷积层和池化层提取特征,最后由 softmax 进行分类。模型的损失函数是估计 softmax 输出概率分布和目标概率分布之间的交叉熵 (Cross-Entropy, CE)。CE 损失函数定义为^[18]:

$$CE = - \sum_i t_i \log(s_i) \quad (2)$$

其中, t_i 和 s_i 是 C (softmax 输出的总维数) 中每个 i 类的真值和 CNN 得分。

确定损失函数后,可利用众多优化算法来训练网络,例如随机梯度下降、动量梯度下降、RMSprop 和 Adam 随机优化等。本文选择 Adam 随机优化来训练我们的 CNN 网络模型,因为该方法实现简单,计算效率高,具有很小的存储要求^[19]。

3 实验与结果

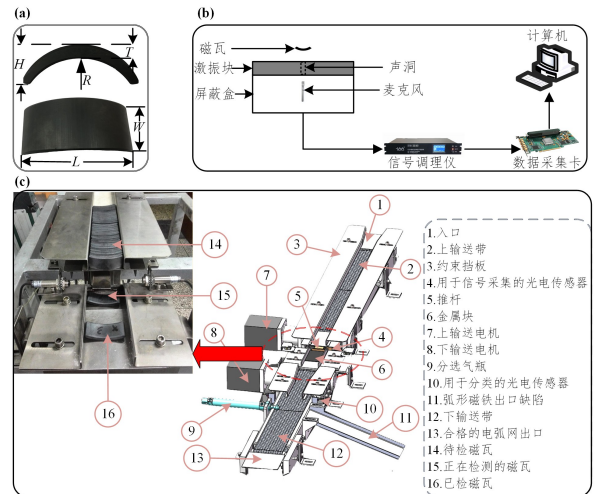
3.1 实验设计

本文采用 4 类未磁化磁瓦作为实验样本。为了便于描述,根据外形分别命名为 A, B, C, D 类。这 4 类磁瓦不仅涵盖了传统产品中常见的材料,而且尺寸范围广,因而具有代表性。每种类型磁瓦有 240 块,合格与缺陷样品均分。合格样本是指磁瓦本身没有任何缺陷,反之不合格样品只有内部缺陷。为了保证样本的可靠性,统一由 3 名熟练检验员利用人工检测的方法共同确认磁瓦的状态。表 2 列出了磁瓦详细外形尺寸,磁瓦示意图如图 4(a)所示。

表2 实验样本信息

Table 2 Information of experimentals

样本	尺寸/mm					状态	样本个数
	W	L	H	R	T		
A	64	36	21	50	8	合格	120
						缺陷	120
B	62	30	23	45	7	合格	120
						缺陷	120
C	50	21	10	30	5	合格	120
						缺陷	120
D	25	35	9	20	3	合格	120
						缺陷	120



注:(a)为磁瓦示意图;(b)为声振信号激励与采集模型;(c)为检测系统三维设计图和部分实际细节

图4 实验设计

Fig. 4 Experimental design

基于声振信号的磁瓦内部缺陷检测是建立和识别结构特性与声学特性之间的关系,以确定内部结构的物理状态。这种检测的核心原理是当物体受到足够外力作用时,其振动将产生与其结构明显有关的声音。如图 4(b)、图 4(c)所示,两台高度不同的平行输送装置组成阶梯式输送结构,从上层输送带输送到下层传送带的磁瓦要垂直下落。根据实验数据,落差高度设置为 20 mm,这样不仅能保证每个磁瓦无损跌落,还能产生高质量的声音信号。坠落的磁瓦与置于坠落方向的金属块发生碰撞,产生声学信号,并由位于屏蔽箱内的传声器收集。采集到的信号经信号调理仪放大、滤波后,再由数据采集卡保存至计算机。

每个时域声振信号包含 20 000 个采样点,采样频率为 40 kHz。检测算法是基于 Python 开发的,负责声振信号的分析与识别,以判断磁瓦内部是否存在缺陷。检测系统配置于生产线时,只对当前生产的磁瓦进行缺陷检测,但开发的算法需要满足多类型磁瓦的缺陷检测,节省了为每类磁瓦开发检测算法的时间。计算机配置:CPU 为 i5-8300H, GPU 为 GTX-1060,内存为 16 GB。

3.2 数据预处理

本文选择 4 类具有代表性的磁瓦作为对象。受人耳听音辨识磁瓦内部缺陷的启发,着重关注合格与缺陷磁瓦声振信号在频域之间的差异。为了实现磁瓦内部缺陷检测,引入声振图像概念,将一维声振信号处理问题转换为二维图像处理问题。首先,将采集到的磁瓦声振信号利用快速傅里叶变换得到频域信号。其次,每个频域信号利用除以其最大值的方

法得到归一化信号,图 5 展示了 4 类磁瓦声振信号归一化的频域波形。从图中可以看出,不同类别的磁瓦声振信号的频域波形存在较大差异,而同类别中合格与缺陷磁瓦声振信号之间的差异较小。最后,根据式(1)将一维频域声振信号转换

为二维灰度声振图像。由于频域声振信号有 10 000 个数据点,因此 $M=100,N=100$,即声振图像大小为 100×100 ,以保证声振图像包含所有频域数据点。4 类磁瓦的声振灰度图像的反相图如图 6 所示。

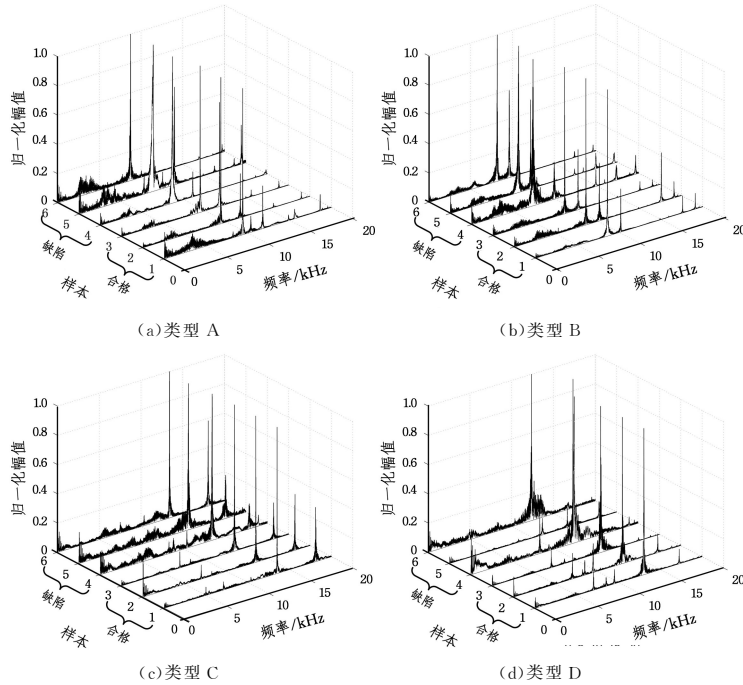


图 5 4 类磁瓦声振信号频域波形

Fig. 5 Frequency domain waveforms of four types acoustic vibration signals for arc magnets




图 6 磁瓦声振图像的反相图

Fig. 6 Inverse phase diagram of acoustic vibration image

3.3 超参数选择

每个超参数不仅影响分类准确率,而且影响 CNN 模型的训练时间,到目前为止,没有一个标准的方法来选择合适的超参数。我们将基于实验的方法选择合适的超参数。

首先应该选择的参数是模型的训练次数 $epoch$ 。当 $epoch$ 设为 100 时,模型在训练集上的准确率和损失曲线分别如图 7 中蓝线和红线所示。




图 7 模型训练的准确率和损失曲线(电子版为彩色)

Fig. 7 Accuracy and loss curves for model training

从图 7 可以看出,当 $epoch$ 超过 50 后,CNN 模型的准确率和损失都趋于稳定,分别达到各自的最值。因此,用于磁瓦内部缺陷检测的 CNN 模型的训练时 $epoch$ 设置为 50。

其次,学习率也是影响 CNN 模型的准确率和训练时间的重要参数。学习率是梯度下降方法在搜索过程中的步长^[20]。该值越低,模型沿着梯度下降越慢,越易陷入局部最优,训练时间越长;该值较大,会导致模型震荡。通常情况下,固定 $epoch$ 为 50,通过设置不同大小的学习率,观察比较模型的准确率和训练时间,根据模型的效果设置学习率。图 8 给出了几个学习率典型值对 CNN 模型的影响。从图中可以看出,当学习率为 0.0001 时,不仅准确率最高,模型的训练时间也是最短的。因此,学习率设置为 0.0001。




图 8 学习率对 CNN 模型的影响

Fig. 8 Effect of learning rate on CNN model

最后,训练集占总样本的比例也是影响模型准确率最重要的参数。普遍认为,训练集占比为 $[1/3, 2/3]$ 。训练集占比越大,模型学习到的信息越多,利于分类识别,但过大的占比会引起重复训练,过小的占比会导致模型满足不了缺陷检测的准确率。图 9 给出了不同训练集占比对模型准确率的影响。从图中可以看出训练集占比为 $2/3$ 时,准确率最高,为 99.38%。因此,训练集占比设置为 $2/3$,测试集为剩下的

1/3,即4类磁瓦样本共960个,其中640个样本用于训练网络模型,其余320个则用于测试网络模型的性能,用于训练和测试的合格与缺陷样本的数量相等,不同类别的磁瓦样本的数量也相等。

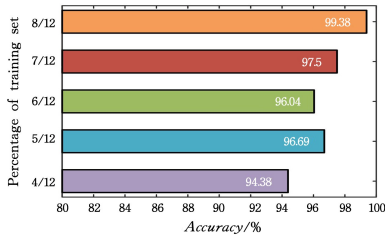


图9 训练集占比对模型准确率的影响

Fig. 9 Model accuracy of different training set occupancies

3.4 提出方法的性能

本文提出的CNN模型针对磁瓦内部缺陷这类问题,只需设计并训练一个缺陷检测模型,就能完成不同类型磁瓦的检测。4类磁瓦分为合格和缺陷,共8类。将磁瓦声振信号按3.3节所给参数分为训练集和测试集,训练集用于训练CNN模型,学习不同类型磁瓦缺陷与合格的特征。利用t-SNE^[21]将要输入softmax层进行分类识别的高维特征进行降维并可视化呈现,如图10所示。类别0-7分别对应A类合格样本、A类缺陷样本、B类合格样本、B类缺陷样本、C类合格样本、C类缺陷样本、D类合格样本和D类缺陷样本。可以看出,类与类之间间距足够大,验证了模型的合理性。




图10 特征可视化

Fig. 10 Feature visualisation

图11为提出的CNN模型对测试集的分类识别结果的混淆矩阵,每一行代表数据的预测标签,每一列代表数据的真实标签。从图中可以看出,仅两个样本分类识别错误,C类样本中的一个缺陷样本被识别为D类样本中的合格样本和D类样本中的一个合格样本被识别为D类样本中的缺陷样本。精确率(Precision, P)和召回率(Recall, R)是广泛用于信息检索和统计分类领域的两个度量指标,其计算公式分别为:

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

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

Actual label	0	1	2	3	4	5	6	7
0	40	0	0	0	0	0	0	0
1	0	40	0	0	0	0	0	0
2	0	0	40	0	0	0	0	0
3	0	0	0	40	0	0	0	0
4	0	0	0	0	40	0	0	0
5	0	0	0	0	0	39	1	0
6	0	0	0	0	0	0	39	1
7	0	0	0	0	0	0	0	40
	0	1	2	3	4	5	6	7

图11 CNN模型测试结果

Fig. 11 Test results of CNN model

对于特定的一类, TP 是正确识别的数量, FP 则是其他类别被错误分到这一特定类别的样本数量, FN 则是这一特定类被错误分到其他类的样本数量。 P 和 R 两者相互制约,引入 F_1 折中。 F_1 越高,分类器的性能越好, F_1 的计算公式为:

$$F_1 = \frac{TP}{TP + FP} \quad (5)$$

根据图11的混淆矩阵,训练的分类器模型的 P , R 和 F_1 值如表3所列,提出的CNN模型的 P , R 和 F_1 值都大于或等于0.975,验证了该模型的性能。提出的CNN模型整体测试准确率为99.38%,满足磁瓦内部缺陷检测的准确率要求。

表3 不同样本的 P , R 和 F_1 值

Table 3 P , R and F_1 values for different samples

磁瓦样本	标签	P	R	F_1
A	合格(0)	1	1	1
	缺陷(1)	1	1	1
B	合格(2)	1	1	1
	缺陷(3)	1	1	1
C	合格(4)	1	1	1
	缺陷(5)	1	0.975	0.987
D	合格(6)	0.975	0.975	0.975
	缺陷(7)	0.976	1	0.988

3.5 模型的验证

本文所提出方法主要在以下方面做了改进。

(1)引入声振图像概念:将磁瓦内部缺陷检测中使用的一维信号通过式(1)转换为声振图像,利用二维图像处理技术代替一维信号分析方法完成缺陷检测。

(2)改变一般CNN网络结构:CNN网络结构基本上是卷积层、池化层成对出现,即卷积层后紧跟池化层。本文所提方法的网络结构中,在第一层卷积之后再紧跟一层卷积。

(3)增加BN层:在第二层卷积计算后,将卷积结果输入BN层,完成数据批归一化。具体改进后的网络结构如图3所示。

为了验证上述改进对磁瓦内部缺陷检测的积极作用,分别引入以下方法作为对比。针对改进(1),去除频域声振信号转声振图像步骤,将CNN方法用一维CNN替代,简述为1D-CNN。针对改进(2),在第一层卷积后增加一层平均池化,简述为CNN_V2。针对改进(3),将增加的池化层删除,简述为CNN_V3。本文提出的方法简述为CNN_V1。1D-CNN, CNN_V2, CNN_V3是在CNN_V1方法的基础上所做的相应改动。

本文提出的方法CNN_V1与其他3种方法的对比如表4所列,CNN_V1对4类磁瓦样本的总体测试准确率最高,为99.38%,单片磁瓦测试时间最低,为0.031s。其中,单片测试时间 t_c 的计算公式为:

$$t_c = \frac{T_c}{N_c} \quad (6)$$

$$T_c = T_1 + T_2 + T_3$$

其中, T_1 将所有测试样本的一维声振信号转换为二维声振图像所花费的时间, T_2 为提出的CNN_V1模型对测试样本中声振图像分析并提取高维特征花费的时间, T_3 为利用训练样本训练得到的模型对测试样本进行测试花费的时间, N_c 为磁瓦测试样本的总个数。

表4 不同方法的对比

Table 4 Comparison of different methods

方法	训练	测试	模型	单片
	准确率/%	准确率/%	训练时间/s	测试时间/s
CNN_V1	100	99.38	15	0.031
CNN_V2	100	93.75	12	0.055
CNN_V3	100	98.12	16	0.047
1D-CNN	100	97.81	53	0.065

虽然 CNN_V2 增加了一池化层,能减少模型的训练时间,但其对测试集的准确率和时间都是表现最差的。因此,本文提出的方法不仅满足磁瓦内部缺陷检测的准确率要求,且符合大批量磁瓦缺陷检测时的快速性要求。

考虑到噪声也是影响磁瓦内部缺陷检测性能的重要因素,本文还验证了低信噪比(SNR)条件下上述方法的鲁棒性和准确率。将具有不同标准方差的加性高斯白噪声添加到原始声振信号中,以模仿低 SNR 声振信号。SNR 定义为^[22]:

$$SNR = 10 \log \left(\frac{P_{\text{signal}}}{P_{\text{noise}}} \right) \quad (7)$$

其中, P_{signal} 和 P_{noise} 分别是原信号和噪声的功率。

CNN_V1 在不同噪声条件下的表现如图 12 所示。从图中可以看出,当噪声信号的 SNR 高于 -4 dB 时,准确率下降明显,但噪声的 SNR 低于 -4 dB 时, CNN_V1 方法的测试准确率高于 97.5%。结果表明,本文所提出的方法具有良好的鲁棒性,可以很好地处理含有噪声的声振信号。




图12 不同噪声条件下 CNN_V1 的性能

Fig. 12 Performance of CNN_V1 under different noise conditions

结束语 本文提出了一种基于 CNN 的磁瓦内部缺陷检测的新方法。通过将一维声振信号转换为二维声振图像,利用 CNN 在图像识别中的优势,实现准确率为 99.38% 的磁瓦内部缺陷检测,单片磁瓦的检测时间为 0.031 s,同时兼顾可观的抗噪性能。

本文对比了利用 1D-CNN 于一维信号提取特征进而完成检测的方法和传统声振检测的方法,本文所提出的方法在速度方面占有绝对优势。改变一般 CNN 网络结构,可提高磁瓦内部缺陷的检测准确率;引入 BN 层,可加速网络收敛,提高网络性能。

本文采用实验的方法选择 CNN 模型的超参数。然而,设计深度学习算法完成磁瓦内部缺陷检测,再选择合适的超参数仍然是一个挑战。

参考文献

[1] HUANG Q, XIE L, YIN G, et al. Acoustic signal analysis for detecting defects inside an arc magnet using a combination of variational mode decomposition and beetle antennae search[J]. ISA Transactions, 2020, 102: 347-364.

[2] HUANG Q, YIN Y, ZHAO Y, et al. Acoustic Inspection of In-

ternal Defect in Magnetic Tile Based on Bispectrum Analysis [J]. Journal of Sichuan University (Engineering Science Edition), 2014, 46(5): 188-194.

[3] RAN M, HUANG Q, LIU X, et al. Internal defect detection of arc magnets based on optimized variational mode decomposition [J]. Journal of Zhejiang University (Engineering Science), 2020, 54(11): 2158-2168.

[4] ZHAO Y, YIN M, HUANG Q, et al. Acoustic impact testing of magnetic tile internal defects based on wavelet packet transform and artificial neural network [J]. China Measurement & Test, 2015, 41(6): 81-85.

[5] LI C, SANCHEZ R V, ZURITA G, et al. Multimodal deep support vector classification with homologous features and its application to gearbox fault diagnosis [J]. Neurocomputing, 2015, 168: 119-127.

[6] JIA F, LEI Y, LIN J, et al. Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data [J]. Mechanical Systems and Signal Processing, 2016, 72/73: 303-315.

[7] LU H, ZHANG Q. Applications of Deep Convolutional Neural Network in Computer Vision [J]. Journal of Data Acquisition & Processing, 2016, 31(1): 1-17.

[8] TONG X, WANG B, WANG R, et al. Survey on Adversarial Sample of Deep Learning Towards Natural Language Processing [J]. Computer Science, 2021, 48(1): 258-267.

[9] LI Y, SIXOU B, PEYRIN F. A review of the deep learning methods for medical images super resolution problems [J]. IRBM, 2021, 42(2): 120-133.

[10] REN H, QU J, CHAI Y, et al. Deep learning for fault diagnosis: The state of the art and challenge [J]. Control and Decision, 2017, 32(8): 1345-1358.

[11] YIN Y, XIE L, HUANG T. A deep learning method for magnetic tile internal defect inspection based on acoustic vibration [J]. China Measurement & Test, 2020, 46(3): 32-38.

[12] ZOU Y, ZHANG Y, MAO H. Fault diagnosis on the bearing of traction motor in high-speed trains based on deep learning [J]. Alexandria Engineering Journal, 2021, 60(1): 1209-1219.

[13] CHI Y, YANG S, JIAO W. A Multi-label Fault Classification Method for Rolling Bearing Based on LSTM-RNN [J]. Journal of Vibration Measurement & Diagnosis, 2020, 40(3): 563-571.

[14] WANG X, MAO D, LI X. Bearing fault diagnosis based on vibroacoustic data fusion and 1D-CNN network [J]. Measurement, 2021, 173(6): 108518.

[15] SONG L, SU L, LI K, et al. Fault diagnosis method of rolling bearings based on SSD and 1DCNN [J]. Journal of Huazhong University of Science and Technology (Natural Science Edition), 2020, 48(12): 38-43.

[16] HOANG D T, KANG H J. Rolling element bearing fault diagnosis using convolutional neural network and vibration image [J]. Cognitive Systems Research, 2019, 53: 42-50.

[17] IOFFE S, SZEGEDY C. Batch Normalization: Accelerating Deep Network Training by Reducing Internal Covariate Shift [J]. arXiv: 1502.03167.

[18] DE BOER P T, KROESE D P, MANNORS, et al. A tutorial on the cross-entropy method [J]. Annals of Operations Research,

2005,134(1):19-67.

- [19] BOCK S, WEIß M. A proof of local convergence for the Adam optimizer [C]// 2019 International Joint Conference on Neural Networks (IJCNN). IEEE, 2019:1-8.
- [20] YU X H, CHEN G A, CHENG S X. Dynamic learning rate optimization of the backpropagation algorithm[J]. IEEE Transactions on Neural Networks, 1995, 6(3):669-677.
- [21] LAURENS V D M, HINTON G. Visualizing Data using t-SNE [J]. Journal of Machine Learning Research, 2008, 9 (2605): 2579-605.
- [22] PAULUZZI D R, BEAULIEU N C. A comparison of SNR estimation techniques for the AWGN channel[J]. IEEE Transactions on Communications, 2000, 48(10):1681-1691.



LIU Xin, born in 1995, postgraduate. His main research interests include deep learning and intelligent information processing.



HUANG Qin-yuan, born in 1984, Ph.D., associate professor. His main research interests include artificial intelligence, signal processing and evolutionary computation.

(上接第 647 页)

由图 9(a)和图 10(a)、图 9(b)和图 10(b)的对比可以看出,采用本文方法重建的云层图像在满足一定速度的前提下,能直观地分辨出雷达回波的强回波、中回波和弱回波各强度云层的基本轮廓,弱回波数据主要集中在整个轮廓的外部,表示该区域被降水云系笼罩,内部的强回波区域预示着有降雨现象。

当将其与相关地理位置信息相结合,在不同视角下观察云层时,可让人们对所关心区域的回波强度、位置有一个定性的认识,再根据观察到的层状云垂直厚度和空间分布来分析预报该地区的气象信息。


结束语 本文将三维可视化技术应用到天气雷达数据上,根据多普勒雷达数据特点,在空间上采用 Barnes 和傅里叶插值对数据进行加密,让三维重建结果细节信息更加丰富,接着对处理后的数据采用新的六面体作为剖分四面体的基本单元来进行等值面的构建,并利用多层次面绘制技术渲染三维图。重建的结果表明,采用优化后的方法实现的多个回波强度的气象雷达数据三维重建结果更加直观形象,所包含的细节信息更多,能更大程度地挖掘雷达回波数据的有效信息,对于分析把握强回波的演变状况有一定的意义。

参 考 文 献

- [1] DOBASHI Y, YAMAMOTO T, NISHITA T. An interactive rendering system using hierarchical data structure for earth-scale clouds[J]. Science China (Information Sciences), 2010, 53(5):920-931.
- [2] LAMPERTI E, DENHAM M, ARETA J. Weather radar data processing on graphic cards[J]. Journal of Supercomputing, 2018, 74(2):868-885.
- [3] LIU Z N, SHI Z Z, JIANG M R, et al. Using MC Algorithm to Implement 3D Image Reconstruction for Yunnan Weather Radar Data[J]. Journal of Computer and Communications, 2017, 5(5): 50-61.
- [4] XIE Y H, ZHU C F, ZHENG Y, et al. Three-Dimensional Visualization of Weather Forecast Cloud Data Based on Adaptive Grid Structure[J]. Computer Simulation, 2019, 36(7):203-207.
- [5] LU Y. Research on 3D Visualization Method of Weather Radar Base Data[D]. Nanjing: Nanjing University of Information Science and Technology, 2016.
- [6] JIAO P C, WANG Z H, CHU Z G, et al. Weather radar image interpolation method based on Fourier spectrum analysis[J]. Plateau Weather, 2016, 35(6):1683-1693.
- [7] ZHOU J. 3D-surface Reconstruction Algorithm for Medical Images Based on MITK[J]. Computer Science, 2016, 43(S1):194-197.
- [8] WANG M, FENG J Q, YANG B. Comparison and Evaluation of Marching Cubes and Marching Tetrahedra[J]. Journal of Computer-Aided Design & Computer Graphics, 2014, 26(12):2099-2106.
- [9] LI C. Geological data rendering based on MT algorithm[J]. Digital Communication, 2014, 41(4):35-38.
- [10] PENG J. Research on Doppler Weather Radar echo Data Visualization Technology[D]. Hangzhou: Zhejiang University of Technology, 2019.



MA Jun-cheng, born in 1995, postgraduate. His main research interests include 3D visualization and so on.



JIANG Mu-rong, born in 1963, professor. Her main research interests include mathematical method of image processing and its intelligent calculation.