

DOI: 10.13382/j.jemi.B1902745

一种基于卷积神经网络的电涡流金属辨识方法

钦杰¹ 张力平¹ 叶云飞² 胡鹏¹ 简宏良¹

(1. 长安大学 工程机械学院 西安 710064; 2. 南京铁道职业技术学院 智能工程学院 南京 210031)

摘要:为实现对主要金相组织同为铁素体和珠光体的3种碳素结构钢的辨识,提出一种基于卷积神经网络的金属辨识方法。卷积神经网络可以很好地处理环境信息复杂、推理规则不明确和样品本身有缺陷情况下的分类,利用涡流无损检测技术和卷积神经网络算法搭建了该金属辨识平台,首先在涡流传感器的工作频率范围内随机选取8个高频点,并通过该传感器分别采集各个频点下金属的信息;然后通过傅里叶变换、坐标变换等数据处理使得每种金属的信息图像化;最终通过卷积神经网络训练来获得辨识模型。结果表明,该方案对比传统方式可在不损伤金属的情况下识别金属;对比现有的BP神经网络算法(86.20%),对3种金属的正确识别率都达到了92.33%。

关键词: 涡流;卷积神经网络;金属辨识;铁素体;珠光体

中图分类号: TP391.4 **文献标识码:** A **国家标准学科分类代码:** 460.40

Metal type identification method based on convolutional neural network and eddy current

Qin Jie¹ Zhang Liping¹ Ye Yunfei² Hu Peng¹ Lin Hongliang¹

(1. School of Innovation, Chang'an University, Xi'an 710064, China;

2. College of Intelligence Engineering, Nanjing Institute of Railway Technology, Nanjing 210031, China)

Abstract: In order to identify three types of carbon structural steels whose metallographic structures are ferrite and pearlite. This paper proposes a metal identification method based on convolutional neural network. Convolutional neural networks can efficiently implement classification with complex environmental information, ambiguous inference rules, and flawed samples. The metal identification platform was built based on eddy current non-destructive testing technology and convolutional neural network. First, 8 high-frequency points are randomly selected from the bandwidth of the eddy current sensor, and the metal information that under each frequency point is separately collected by this eddy current sensor. Then, this information is imaged through data processing such as Fourier transform and coordinate transformation. Finally, the identification model is obtained by convolutional neural network. The results show that the proposed scheme can identify metals without damaging the metal compared to the traditional method. The accuracy of the CNN model for all three metals increased to 92.33%, which is superior to the BP neural network (86.20%).

Keywords: eddy currents; CNN; metal identification; ferrite; pearlite

0 引言

随着全球资源的开采利用,金属材料的成本不断上升,存在不符合国家规格或规范的金属制品流入市场,给

社会和人们的生活带来隐患,金属材料种类的辨识在当下就显现的尤为重要^[1]。传统的物理、化学金属识别方法都会对金属产生破坏,同时检测过程耗时费力,现有的基于BP神经网络的涡流识别方法对金属的识别率为86.198%^[2]。基于以上所述现状,在利用涡流技术实现

收稿日期:2019-11-11 Received Date: 2019-11-11

* 基金项目:长安大学陕西省高速公路施工机械重点实验室开放基金(300102259513)、中央高校基本科研业务费专项(300102258205)、江苏省高校自然科学研究面上项目(17KJB510033)、江苏高校“青蓝工程”资助项目

对金属的无损辨识的基础上提出卷积神经网络(convolutional neural network, CNN)算法在涡流领域中的辨识应用,提高对金属的辨识能力。

传统的金属辨识方法包含物理法和化学法,具体包括断口识别、火花辨识、重量分析、滴定分析、容量分析方法^[3-4],但都会给金属带来损伤。涡流在辨识领域的应用已取得了一定的发展,张荣华等^[5]使用空间域相频谱分析方法,将相位梯度作为缺陷检测信号特征量,对不同类型的缺陷进行检测和分类。曹青松等^[2]利用电涡流技术以及神经网络辨识的方法能有效的识别吸铁、黄铜和铝合金3种金属,文献[2]只是对于3种不同金属进行了识别,未做同类金相组织金属的识别,且识别率是86.198%尚有提高的空间。本文提出的方法主要针对工业和生活中大量使用的碳素结构钢中金相组织为珠光体和铁素体的3种金属进行辨识;最后也验证了不同的金属(铁、铝、不锈钢201和不锈钢304)之间的辨识情况。

1 电涡流辨识金属材料的理论模型

涡流传感器的线圈在正弦激励信号下产生交变磁场,放置于该交变磁场中的待检测金属感应出方向与发射线圈相反的磁场,待测金属的感应磁场会对涡流传感器线圈的等效阻抗产生影响。通过引用文献[2]中的公式,由式(1)~(3)可以推导出,在保证金属的尺寸、检测距离等外界因素不变的条件下,由于不同金属的电导率和磁导率存在差异,这会导致涡流传感器线圈的等效阻抗产生不同的变化情况;同时也可以推导出频率的不同也会对线圈的等效阻抗产生不同影响。待测金属在多个正弦频率的激励下,所对应的多个频点也会有多组幅值参数的变化。此处的频率范围的选择依据以下3个因素:1)避免金属表层下的缺陷影响;2)涡流的趋肤效应;3)所选购的涡流传感器的带宽。为减小表层下未知缺陷带来的影响,此处利用高频涡流的趋肤效应来对金属浅表层的信息进行采集,为此该实验平台配备了高频涡流探头,该高频涡流探头的工作频率范围为3~9.3 MHz,具体的频点是在该频率范围内随机产生8个: $f_1 = 3.01$ MHz、 $f_2 = 4.37$ MHz、 $f_3 = 5.21$ MHz、 $f_4 = 6.37$ MHz、 $f_5 = 7.01$ MHz、 $f_6 = 7.93$ MHz、 $f_7 = 8.37$ MHz、 $f_8 = 9.21$ MHz。如何在这个频段里选择最优的频点是一个难点,这也将是课题后期研究的方向。图1所示为探头在正弦激励频率分别为4.27、6.37、7.93、9.21 MHz激励下,探头贴合金属和未贴合金属的波形对比。实线描述的是探头结合金属表面的波形,虚线描述的是探头未结合金属表面的波形。可以观察到高低频的峰值点都表现出了明显差值,这些差异就是用以辨识金属种类的依据。

$$L = L_1 - \frac{\omega^2 M^2}{R_2^2 + (\omega L_2)^2} L_2 \quad (1)$$

$$R = R_1 + \frac{\omega^2 M^2}{R_2^2 + (\omega L_2)^2} R_2 \quad (2)$$

$$Q = \frac{\omega \left[L_1 - \frac{\omega^2 M^2}{R_2^2 + (\omega L_2)^2} L_2 \right]}{R_1 + \frac{\omega^2 M^2}{R_2^2 + (\omega L_2)^2} R_2} = \frac{\omega L_1}{R_1} \frac{1 - \frac{L_2}{L_1} \left(\frac{\omega^2 M^2}{Z_2} \right)}{1 + \frac{R_2}{R_1} \left(\frac{\omega^2 M^2}{Z_2} \right)} \quad (3)$$

式中: $Z_2 = R_2^2 + (\omega L_2)^2$ 称为涡流环阻抗; L 、 R 为待测金属影响下涡流传感器接收线圈的等效电感和等效电阻; Q 为其品质因数。通过理论和波形对比分析可得,在金属辨识的试验中,仅改变金属材质,其他参数都不变。根据多个频点反馈信号的幅值变化理论上可直接推导出对应的金属材料。但在实际应用中就要考虑金属与对应幅值变化关系的复杂度、实验仪器对数据的精确测量、数据的精度问题的探讨,上述的问题都给金属辨识的实际工作带来了困难。

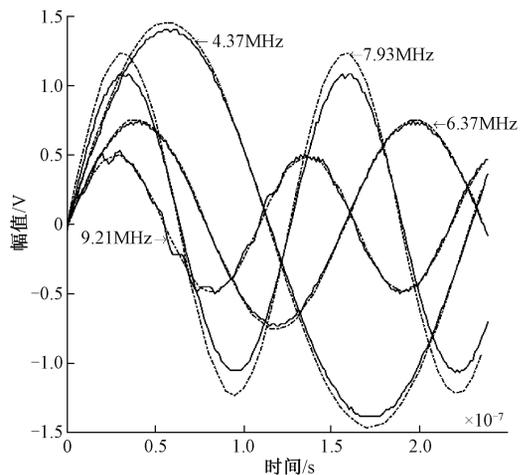


图1 多个频点下涡流探头的波形

Fig. 1 Waveform of eddy current probe under multiple frequency conditions

2 卷积神经网络

实际应用中金属在各个频点下的幅值变化与理论公式的推导结果存在着很大的差异,金属表面粗糙度、待测金属的大小、仪器精度和外界干扰等因素都会使实际操作偏离理论推导的结果,这些对不同的金属的精确识别都是很大的难题。

卷积神经网络在处理环境信息复杂、推理规则不确定、样品本身有缺陷等问题上表现出了良好的特征分类能力^[6];并在图像分类、图像理解、人脸目标检测等领域

得到了很多的成功应用^[7-8]。通过该 CNN 算法可以解决上述电涡流辨识金属在实际应用中的种种难题,为此将卷积神经网络运用于此。

2.1 CNN 网络结构

CNN 具有多层网络结构,主要包含卷积层、池化层、全连接层和输出层。多层的卷积层和池化层对输入图像提取大量的特征,全连接层和输出层依据提取特征对结果进行分类^[9]。

1) 卷积层

通过卷积核对输入对象进行特征提取,是 CNN 的核心^[10]。卷积核按照规定的步长沿着输入图像的横纵坐标方向对输入的图像进行卷积计算,再将得到的特征图中的特征强度较弱的通过激活函数 ReLU 置为 0。

卷积层的具体操作如下:

$$X_j^l = f\left(\sum_{i \in N_j} X_i^{l-1} \cdot \omega_{ij}^l + b_j^l\right) \quad (4)$$

式(4)表示为第 l 层的第 j 个特征图 X_j^l 由前一层若干个特征图 X_i^{l-1} 和当前层的卷积核 ω_{ij}^l 进行卷积计算,之后再加上偏移量 b_j^l ,最后经过激活函数 $f(\cdot)$ 去除特征强度较弱的特征点。其中卷积核的层数与输入的层数相等; N_j 代表 $l-1$ 层中用于计算第 l 层的第 j 个特征图 X_j^l 的特征图的集合, b_j^l 为第 l 层的第 j 个特征图偏置量。

2) 池化层

池化层一般紧随卷积层之后,其作用是对特征图进行压缩,简化网络的计算复杂度^[11]。池化(pooling)操作主要是通过对图片某一位置的相邻区域做一个概括统计。池化操作如下:

$$X_j^{l+1} = \text{lrn}(\text{down}(X_j^l)) \quad (5)$$

其中, $\text{down}(X)$ 为池化操作函数,当前使用较多的是最大池化和平均池化,池化层的特征图的数量和卷积层的特征图数量相等。池化后执行 $\text{lrn}()$ 操作,局部响应归一化,对训练有利。

3) 全连接层

全连接层是将提取的高维特征图平铺为一维的一个向量,一方面输出图像特征,另一方面将实现卷积层和普通层二者之间的连接。全连接的操作如下:

$$X^{l+2} = f(X^{l+1} \omega^{l+2} + b^{l+2}) \quad (6)$$

其中 $f(\cdot)$ 是激活函数,也使用的 ReLU 激活函数。

2.2 输入层图像设计

训练样本的大小将直接影响卷积神经网络的训练结果的好坏^[12-13],为取得较好的训练结果,此处将多个频点下的信息进行全排列以扩充数据量,具体设计过程如下。

收集金属的幅值信息,此处采用了 8 个频点作为激励信号,随机在涡流探头的工作频率范围 3~9.3 MHz 之间产生 8 个高频正弦激励信号 f_i ,其中 $i=1 \sim 8$,每个频点 f_i 下对每种金属采集 5 组数据。图 2 所示是频点为

8.37 MHz 的涡流探头的时域波形图和 2 个局部放大图,通过波峰和波谷的数据可以验证金属对涡流的确产生了峰值的影响。该实验中所有的操作就是基于 8 个这样不同频点下的波形图进行的操作。

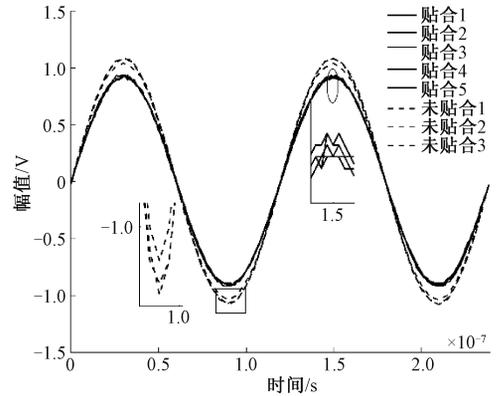


图 2 频率为 8.37 MHz 的波形

Fig. 2 Waveform at 8.37 MHz

通过 MATLAB 对采集的数据进行快速傅里叶变换 (FFT),提取各个频点对应的幅值,并对各种金属的幅值数据处理,图像生成中会依据去均值的结果乘以增益。

$$\bar{y}_i = \frac{\sum_{j=1}^3 y_{i,j}}{3} \quad (7)$$

$$\Delta y_{i,i} = |y_{i,i} - \bar{y}_i| \quad (8)$$

$$y_{i,i} = g(k \cdot \Delta y_{i,i}) \quad (9)$$

$$Y_{i,i} = y_{i,i} + 1 \quad (10)$$

其中, $j=1, \dots, 3$; $y_{i,j}$ 是频率为 f_i 条件下探头未贴合金属表面所测波形 FFT 后的幅值; \bar{y}_i 是频率为 f_i 条件下测定 3 次 $y_{i,j}$ 后的均值; $i=1, \dots, 5$; $y_{i,i}$ 是频率为 f_i 条件下探头贴合金属表面所测波形 FFT 后的幅值;为减少仪器所带来的误差此处所得 5 个 $y_{i,i}$ 都减去了均值 \bar{y}_i ; $\Delta y_{i,i}$ 表示的是幅值变化值的绝对值。像素图像上点图的绘制必须要求坐标点为正整数,所以需要计算的数值 $\Delta y_{i,i}$ 放大并取整;其中 $g(\cdot)$ 是四舍五入取整函数; $y_{i,i}$ 是幅值变化值的绝对值放大 k 倍后四舍五入取整的结果。此处 $Y_{i,i}$ 中加 1 是为了避免 $y_{i,i}$ 为 0 的所带来的图像无法绘制的情况。

一个频点对应 5 个幅值信息,8 个频点组成一个 8×5 的矩阵。该矩阵列全排列(即每一行随机取一列数组成一个 1×8 的特征子集)的方式将会有 $5^8 = 390\ 625$ 个结果,形成一个 $390\ 625 \times 8$ 的特征矩阵。

将 1×8 的特征子集均匀排布在像素为 $8\ m \times 8\ m$ (其中 m 为奇数)的白色背景图像中。为将结果显示的符合坐标系,需要对像素平面坐标系 (u, v) 进行变换:

$$x_n = 8 \times (n - 1) + (m + 1)/2 \quad (11)$$

$$\begin{cases} u_n = x_n \\ v_n = 8m - y_n \end{cases} \quad (12)$$

其中 $n = 1 \sim 8$, x_n 是各个频点的位置信息,图中 x 轴的信息不是频点的具体值,是各个频点的排序信息; y_n 是 1×8 的特征子集中的元素。图 3 所示为坐标变换的操作示意图,通过变换提高了图像化信息的可读性。图 4 所示为图中分布 8 个频点后点图的样例。

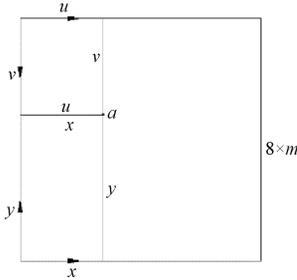


图 3 坐标系转换示意图

Fig. 3 Schematic diagram of coordinate system transformation

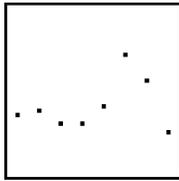


图 4 多频点点图示意图

Fig. 4 Schematic diagram of multi-frequency point

3 实验分析

依据上述理论来搭建实验平台并进行数据的采集和处理,构建用于卷积神经网络的训练集、试验集和验证集,搭建 CNN 卷积神经网络,训练和测试模型,最终验证对各类金属的识别结果。

3.1 实验系统

整个金属辨识的硬件部分主要由任意信号发生器、高频涡流探头、数字示波器、配备高性能 GPU 的电脑组成。软件部分主要是由 WaveStudio 采集数字示波器上的波形数据,Matlab 对波形数据预处理并生成最终的点图,Python 通过 TensorFlow-GPU 搭建卷积神经网络的模型。

1) 检测平台搭建

整个系统框架如图 5 所示,通过泰克公司任意信号发生器 AFG3022C 产生 8 个高频信号;通过力科公司的 WaveSurfer 3104z 电子示波器进行采集,并将波形信息保存在电脑上;通过 MATLAB 处理数据得到图像化结果;最后将图像送入基于 TensorFlow 搭建好的 CNN 中进行模型的训练和测试,上述硬件设施如图 6 所示。

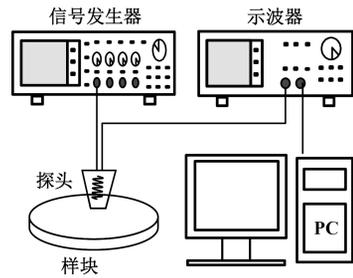


图 5 实验平台框图

Fig. 5 Experimental platform block diagram



图 6 实验平台实物

Fig. 6 Experimental platform

基于 TensorFlow 深度学习平台进行 CNN 的结构搭建和模型训练,为提高模型的运算速度,在 GPU 加速的版本(TensorFlow-GPU)上搭建和运行 CNN 模型,GPU 上表现了良好的加速能力^[14]。

2) 实验样例

碳素结构钢作为建筑、铁道、车辆、船舶、桥梁等领域广泛使用的工业钢种,表现出用途广、产量大、种类多等特点,为此对工业生产中大量使用的碳素结构钢进行辨识就尤为重要。按照普通低合金高强度钢的金相组织分类,可以将普通低合金高强度结构钢分为三大类:铁素体+珠光体型;贝氏体+少量珠光体型;回火马氏体+贝氏体型^[15]。实验中用于辨识的材料的主要金相组织是铁素体和珠光体,具体的信息如表 1 所示。

表 1 金相组织相同的碳素结构钢

Table 1 Sorted carbon structural steel and its metallographic structure

金相组织	材料
	F45MnVS
铁素体+珠光体	20CrMnTiH
	20 号钢

同时为验证该模型对不同金属的辨识情况,增加铁、铝、不锈钢 201 和不锈钢 304 一组辨识材料;也为了排除

该模型训练过程中存在过拟合的情况。第 2 组辨识金属是每类金属设置 2 个规格大小的样例。此处要求加工的 2 个规格分别为直径为 $\phi 16\text{ mm}$ 和 $\phi 20\text{ mm}$, 厚度为 2 mm 的金属圆片。采用 $\phi 16\text{ mm}$ 的数据训练, $\phi 20\text{ mm}$ 的数据进行验证, 最终判别该模型是否存在过拟合问题。

3.2 实验结果对比

将实验采集的第 1 组金属的数据按照式(7)和(8)处理得出如表 2 所示的数据信息。第 1 组中幅值变化的绝对值的最大值为 0.235 6, 最小值为 0; 由式(10)可知, 此处为避免像素点不能绘制于坐标轴上, 各个频点需要加 1。为充分凸显点图的位置信息, 同时考虑到像素过大导致卷积神经网络的计算量剧增等问题。将式(9)中的增益 k 取 100, 由式(9)和(10)推导出此时的最大值为 25, 由式(11)中的 v_i 只能是正整数推出此时的 m 最小值为 5。为减小因图片大小使得卷积神经网络中运算量的剧增, 此处 m 选定最小值, 最终确定点图背景大小为 40×40 , 最终第 1 组送入 CNN 模型中的部分金属图像结果如表 3 所示。通过表 3 可以发现同一金属的结果基本类似, 不同金属间的图像也存在着肉眼可观的分辨信息。

表 2 第 1 组的数据处理结果

Table 2 Data processing results of the first group

金属种类	频点	幅值变化量的绝对值/ $(\times 10^{-2})$				
F45MnVS	f_1	0.44	0.44	1.78	2.44	1.11
	f_2	7.22	12.22	12.22	13.89	12.22
	f_3	3.56	3.56	4.89	4.89	4.89
	f_4	1.78	3.11	4.44	3.11	3.11
	f_5	8.89	6.22	8.89	7.56	7.56
	f_6	22.22	18.22	20.89	22.22	23.56
	f_7	15.11	15.11	13.78	13.78	15.11
	f_8	1.11	0.22	1.56	0.22	0.22
20CrMnTiH	f_1	2.78	2.78	2.78	2.78	2.78
	f_2	7.22	7.22	3.89	7.22	7.22
	f_3	1.11	1.11	1.11	1.11	1.11
	f_4	3.89	3.89	0.56	3.89	3.89
	f_5	8.33	8.33	5.00	8.33	8.33
	f_6	17.22	17.22	20.56	18.89	22.22
	f_7	12.22	10.56	10.56	10.56	10.56
	f_8	0.56	0.56	1.11	0.56	1.11
20 号钢	f_1	1.67	1.67	1.67	0.00	1.67
	f_2	6.67	6.67	6.67	5.00	6.67
	f_3	0.00	0.00	1.67	0.00	0.00
	f_4	3.33	3.33	3.33	3.33	1.67
	f_5	7.22	7.22	7.22	7.22	7.22
	f_6	15.00	15.00	16.67	16.67	16.67
	f_7	10.00	11.67	10.00	8.33	8.33
	f_8	1.11	0.56	1.11	1.11	0.56

表 3 第 1 组金属图像化结果

Table 3 Imaged results of the first group

金属	金属点图				
F45MnVS					
20CrMnTiH					
20 号钢					

通过对于第 2 组金属材料的数据分析, 其增益 k 设置为 100, 最终的各金属各个频点下的 Y_i 如表 4 所示, 其中加阴影是该表的最大值 48, 由式(10)推导其 m 设置为 7。最终确定点图背景大小为 56×56 。

表 4 第 2 组的数据处理结果

Table 4 Data processing results of the second group

金属种类	频点	幅值变化量的绝对值/ $(\times 10^{-2})$				
不锈钢 201	f_1	11	9	11	11	11
	f_2	3	3	2	3	5
	f_3	6	6	8	6	6
	f_4	9	9	11	13	11
	f_5	20	22	18	18	20
	f_6	37	32	35	37	34
	f_7	16	16	13	16	16
	f_8	5	7	7	9	7
不锈钢 304	f_1	9	8	8	9	8
	f_2	4	2	4	4	2
	f_3	6	6	6	6	6
	f_4	12	12	12	12	12
	f_5	17	15	17	18	18
	f_6	43	44	46	46	46
	f_7	29	28	31	31	31
	f_8	14	14	14	14	13
铝	f_1	9	10	10	10	10
	f_2	3	3	3	1	3
	f_3	7	7	7	7	7
	f_4	13	11	13	13	13
	f_5	20	17	20	20	20
	f_6	48	48	48	48	48
	f_7	30	30	30	30	30
	f_8	20	20	20	20	20
铁	f_1	1	1	1	1	3
	f_2	11	11	11	8	9
	f_3	1	3	3	3	3
	f_4	6	6	3	6	6
	f_5	9	10	9	10	12
	f_6	24	23	26	23	24
	f_7	15	15	17	12	15
	f_8	1	3	3	1	1

分别随机收取了两组中的样例进行对比,如图7~10所示。通过观察图7和9可以发现各金属在各频点下的数据的变化趋势是相近的,但是具体到各频点下的数据存在着差异性,该差异性就是让模型识别并归类为所对应的金属的训练样本。同时也对比了两组不同金属各个频点下的点图,通过图8和10可以观察出两组金属的变化趋势也是相近的。但是具体到各个频点下的第1组和第2组的金属的变化就表现出很大差异性,该差异性就是来进行辨识不同金属种类的依据。

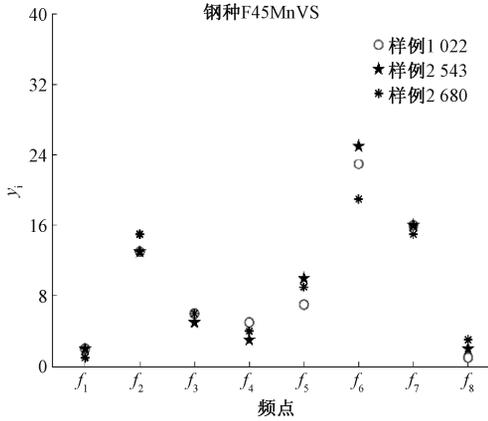


图7 钢种 F45MnV 随机样例对比结果

Fig.7 Comparison of random samples of steel grade F45MnV

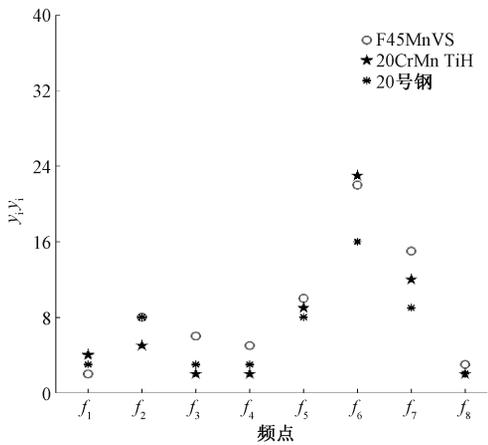


图8 第1组不同钢种的样例对比结果

Fig.8 Comparison results of the first set of different steel samples

金属种类的辨识就是依据上述绘制的点图进行的,采用的CNN网络结构类似于 AlexNet^[16-17],图11所示为第1组金属辨识所搭建的CNN结构框图。其中 $3 \times 5 \times 5 \times 16(1)@36 \times 36$ 是指输入是3层的数据,卷积核大小为 5×5 ,输出为16张特征图,卷积核移动步长为1,输出像素大小为 36×36 。

最终将3种结构钢的识别情况进行了汇总,如表5

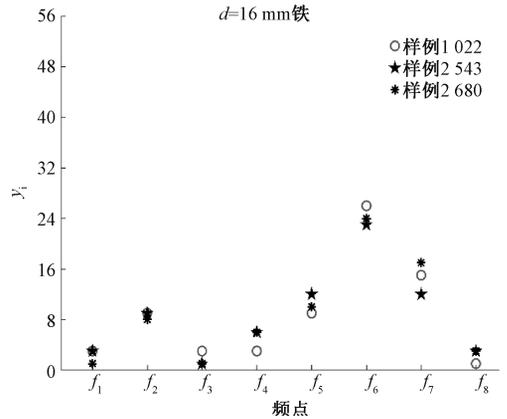


图9 铁随机样例对比结果

Fig.9 Comparison of random samples of iron

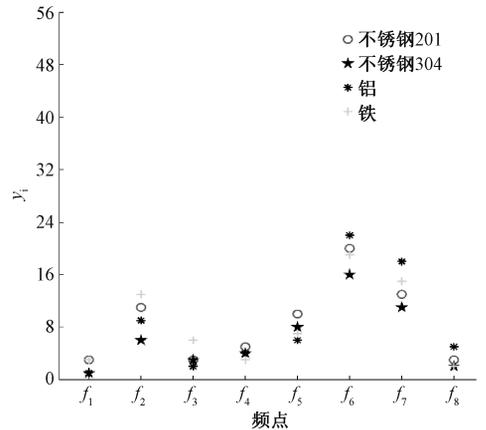


图10 第2组不同金属样例对比结果

Fig.10 Comparison results of the second group of different metal samples

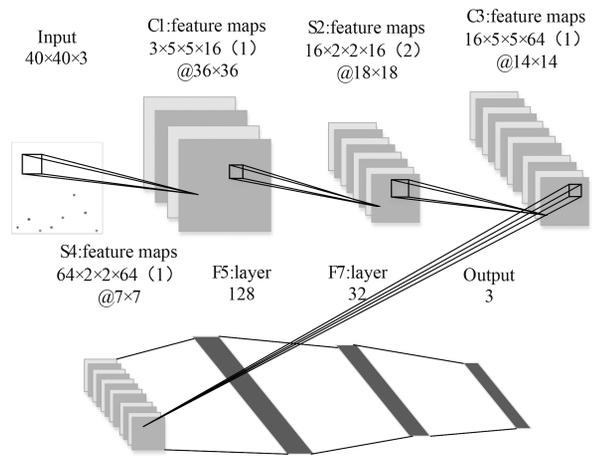


图11 CNN 结构框图

Fig.11 Convolutional neural network block diagram

所示,CNN 以 92.335 9% 辨识正确率识别了 3 种金属。

与现有的传统神经网络的辨识方法对比,如表 6 所示。从表 6 可以观察到, CNN 的识别准确率提高了 6.137 9%。

表 5 第 1 组的识别结果

Table 5 Identification results of the first group

种类	平均识别率
F45MnVS	0.923 373
20CrMnTiH	0.923 363
20 号钢	0.923 342

表 6 不同辨识方法的比较

Table 6 Comparison of different identification methods

辨识方法	平均辨识正确率/%
BP 神经网络 ^[2]	86.198 0
CNN	92.335 9

为避免 CNN 模型训练带来的过拟合影响,同时也为验证整套方案对不同金属(铁、铝、不锈钢 201 和不锈钢 304)的辨识情况,最终结果如表 7 所示,以 92.105 9% 的平均识别率完成了辨识工作。实验排除了该模型过拟合的可能,同时也进一步说明该模型对同类金属不同金相组织和不同金属的辨识都可以胜任。

表 7 第 2 组的识别结果

Table 7 Identification results of the second group

种类	平均识别率
不锈钢 201	0.920 201
不锈钢 304	0.923 030
铝	0.920 401
铁	0.920 607

4 结 论

针对涡流探头对金属在反馈信息复杂、推理规则不明确、样品存在较大缺陷等情况下的辨识, CNN 以 92.335 9% 的分辨率胜任涡流对金属的辨识工作。基于 CNN 的金属辨识和传统的 BP 神经网络对比,发现卷积神经网络下的涡流对金相组织相似的不同金属和金相组织不同的金属(不锈钢 201、不锈钢 304、铝、铜)的准确率都得到了提高。文中辨识的金属类别较少,后期随着识别金属种类的增加肯定会引出新的问题和思路;频点的选择是在探头的工作范围内随机产生的,频点的选择肯定会给该模型带来影响,关于最优频点的确定后期可以开展一个课题讨论。该方法的提出为 CNN 在涡流领域进行金属辨识提出了新的见解,同时也为 CNN 在涡流无损检测领域的应用提供了借鉴,这也将是后期继续研究和探索学习的方向。

参考文献

- [1] 田彦平,贺西平,张宏普,等. 基于声参量的金属材料辨识方法[J]. 陕西师范大学学报(自然科学版), 2014,42(3):34-40.
TIAN Y P, HE X P, HANG H P, et al. The acoustic parameters of preliminary research on the identification of metal materials [J]. Journal of Shaanxi Normal University (Natural Science Edition), 2014, 42(3): 34-40.
- [2] 曹青松,周继惠. 基于电涡流的金属种类识别技术的理论与实验研究[J]. 仪器仪表学报, 2007, 28(9): 1718-1722.
CAO Q S, ZHOU J H. Theoretical and experimental study on metal type identification based on eddy current [J]. Chinese Journal of Scientific Instrument, 2007, 28(9): 1718-1722.
- [3] 李志农,吴伟校. 基于 2DPCA 的金属断口图像识别方法研究[J]. 南昌航空大学学报(自然科学版), 2019, 33(1):48-52.
LI ZH N, WU W X. Image recognition method of metal fracture based on 2DPCA [J]. Journal of Nanchang Hangkong University (Natural Sciences), 2019, 33(1): 48-52.
- [4] 姜帅,刘权,田碧英. 浅谈合金钢中铬的分析[J]. 中国石油和化工标准与质量, 2016, 36(21):62-63.
JIANG SH, LIU Q, TIAN B Y. Analysis of chromium in alloy steel [J]. China Petroleum and Chemical Standard and Quality, 2016, 36(21):62-63.
- [5] 张荣华,叶松,马明,等. 电涡流相位梯度及其在导电材料缺陷识别中的应用[J]. 仪器仪表学报, 2018, 39(10):134-141.
ZHANG R H, YE S, MA M, et al. Eddy current phase gradient and its application in identification of conductive material defects [J]. Chinese Journal of Scientific Instrument, 2018, 39(10):134-141.
- [6] 陆璐. 卷积神经网络的研究及其在车牌识别系统中的应用[D]. 合肥:合肥工业大学, 2006.
LU L. Study of convolutional neural network and its applications in license plate recognition [D]. Hefei: Hefei University of Technology, 2006.
- [7] WEI H, YANGYU H, LI W, et al. Deep convolutional neural networks for hyperspectral image classification [J]. Journal of Sensors, 2015, doi: 10.1155/2015/258619.
- [8] LOPES A T, AGUIAR E D, SOUZA A F D, et al. Facial expression recognition with convolutional neural networks: Coping with few data and the training sample order [J]. Pattern Recognition, 2016(61):610-628.

- [9] 惠文珊,李会军,陈萌,等. 基于 CNN-LSTM 的机器人触觉识别与自适应抓取控制[J]. 仪器仪表学报, 2019, 40(1):214-221.
HUI W SH, LI H J, CHEN M, et al. Robotic tactile recognition and adaptive grasping control based on CNN-LSTM [J]. Chinese Journal of Scientific Instrument, 2019, 40(1):214-221.
- [10] 常亮,邓小明,周明全,等. 图像理解中的卷积神经网络[J]. 自动化学报,2016,42(9):1300-1312.
CHANG L, DENG X M, ZHOU M Q, et al. Convolutional neural networks in image understanding [J]. Acta Automatica Sinica, 2016, 42(9):1300-1312.
- [11] 林思思,叶东毅,陈昭炯. 多特征融合的花卉图像深度学习分类算法[J]. 小型微型计算机系统,2018, 39(7):72-76.
LING S S, YE D Y, CHEN ZH J. Deep learning-based flower image classification algorithm with multi-features fusion [J]. Journal of Chinese Computer Systems, 2018, 39(7):72-76.
- [12] 杨钊,陶大鹏,张树业,等. 大数据下的基于深度神经网络的相似汉字识别[J]. 通信学报,2014, 35(9): 184-189.
YANG ZH, TAO D P, ZHANG SH Y, et al. Similar handwritten Chinese character recognition based on deep neural networks with big data [J]. Journal on Communications, 2014, 35(9):184-189.
- [13] 王金甲,陈浩,刘青玉. 大数据下的深度学习研究[J]. 高技术通讯,2017,27(1):27-37.
WANG J J, CHEN H, LIU Q Y. The study of deep learning under big data [J]. Chinese High Technology Letters, 2017, 27(1):27-37.
- [14] 朱虎明,李佩,焦李成,等. 深度神经网络并行化研究综述[J]. 计算机学报,2018, 41(8):171-191.
ZHUN H M, LI P, JIAO L CH, et al. Review of parallel deep neural network [J]. Chinese Journal of Computers, 2018, 41(8):171-191.
- [15] 薛祖德,陈进文,林冬华. 低合金高强度结构钢的发展及应用[J]. 造船技术,2002(6):15-20.
XIE Z D, CHEN J W, LIN D H. Development and application of low alloy high strength structural steel [J]. Marine Technology, 2002(6):15-20.
- [16] 李宁,王雨萱,徐守坤,等. 基于 AlexNet 的小样本水面漂浮物识别[J]. 计算机应用与软件,2019, 36(2): 245-251.
LI N, WANG Y X, XU SH K, et al. Recognition of floating objects on water surface with small sample based on AlexNet [J]. Computer Applications and Software, 2019, 36(2):245-251.
- [17] 潘卫军,段英捷,张强,等. 基于 AlexNet 卷积神经网络的激光雷达飞机尾涡识别研究[J]. 光电工程,2019, 46(7):121-128.
PAN W J, DUAN Y J, ZHANG Q, et al. Research on aircraft wake vortex recognition using AlexNet [J]. Opto-Electronic Engineering, 2019, 46(7):121-128.

作者简介



钦杰,2016年于武汉轻工大学获得学士学位,现为长安大学硕士研究生,主要研究方向为深度学习和测试技术。

E-mail:642494705@qq.com



张力平(通信作者),博士,长安大学副教授、硕士生导师,主要研究方向为机械设计,测试技术,控制方法。

E-mail:77302385@qq.com

Zhang Liping (Corresponding author)

Ph. D. degree, associate professor and M. Sc. supervisor at Chang'an University. Her main research interests include mechanical design, testing technology, control method.