

基于 CNN 的金属疲劳裂纹超声红外热像检测与识别方法研究

林 丽¹, 刘 新¹, 朱俊臻², 冯辅周^{2*}

(1. 大连交通大学 机车车辆工程学院, 辽宁大连 116000;

2. 陆军装甲兵学院 车辆工程系, 北京 100072)

摘要: 传统超声红外热像检测与识别金属疲劳裂纹主要是通过图像处理算法提取红外热图像的相关热特征, 并与裂纹特征进行匹配, 其过程过于繁琐, 识别率较低且需要人工筛选有效特征。结合主动红外热成像技术以及卷积神经网络 (Convolutional Neural Network, CNN) 在金属结构无损检测与缺陷自动识别中的优势, 提出了一种基于 CNN 的金属疲劳裂纹超声红外热像检测与识别方法。通过超声红外热成像装置对实验对象 (文中为金属平板试件) 进行检测, 获取红外热图像并制作图像数据集。运用设计的卷积神经网络对不同尺寸裂纹的超声红外热图像进行特征提取与识别分类。此外, 对所提出的方法与两种常见图像分类网络模型以及支持向量机的分类结果进行对比。实验结果表明, 设计的卷积神经网络在该数据集上识别分类准确率为 100%, 优于其他网络模型和支持向量机的识别分类, 可以有效检测与识别金属疲劳裂纹。

关键词: 振动热成像; 卷积神经网络; 图像识别; 图像分类

中图分类号: TG115.28 **文献标志码:** A **DOI:** 10.3788/IRLA20210227

Research on vibrothermography detection and recognition method of metal fatigue cracks based on CNN

Lin Li¹, Liu Xin¹, Zhu Junzhen², Feng Fuzhou^{2*}

(1. College of Locomotive and Rolling Stock Engineering, Dalian Jiaotong University, Dalian 116000, China;

2. Department of Vehicle Engineering, Army Academy of Armored Forces, Beijing 100072, China)

Abstract: Traditional methods of detecting and recognizing metal fatigue cracks by ultrasonic infrared thermal images mainly extract relevant thermal characteristics of infrared thermal images through image processing algorithms and match crack characteristics. This process is tedious and the recognition rate is low. Additionally, the effective characteristics need to be manually selected. Taking the advantages of active thermography and Convolutional Neural Network (CNN) in metal structure testing and automatic defect recognition, a vibrothermography crack detection and recognition method based on CNN was proposed. The specimens (metal plates in this work) were tested and thermal data sets were obtained by the proposed CNN-based vibrothermography. The designed convolutional neural network was applied to the feature extraction, recognition and classification of vibration-induced infrared thermal images with different crack sizes. In addition, the proposed method was compared with two common image classification network models and support vector machine. Experimental results show that the designed convolutional neural network can recognize and classify

收稿日期: 2021-04-06; 修订日期: 2021-06-02

基金项目: 国家自然科学基金 (51875576, 52005510); 无损检测技术教育部重点实验室开放基金 (EW201980445)

作者简介: 林丽, 女, 副教授, 硕士生导师, 博士, 主要从事列车故障诊断方面的研究。

通讯作者: 冯辅周, 男, 教授, 博士生导师, 博士, 主要从事故障诊断与无损检测技术方面的研究。

metal fatigue cracks with an accuracy of 100% on the experimental data sets, which is better than other network models and support vector machine, and can effectively detect and recognize metal fatigue cracks.

Key words: vibrothermography; Convolutional Neural Network (CNN); image recognition; image classification

0 引言

在大型设备的运转中,关键构件中经常出现形式多样的裂纹,如钢轨的滚动接触疲劳裂纹^[1]、压力管道的应力腐蚀裂纹^[2]等。构件内裂纹在设备的使用过程中会不断扩展,当裂纹扩展到快速发展阶段极易引发设备构件的脆性断裂,危害人员生命和造成经济损失^[3]。因此,采取有效的方法对设备裂纹的检测与识别是非常必要的。

超声红外热成像(振动热成像)检测技术作为新型裂纹检测方法被广泛关注。其理论研究、数学模型的推导以及检测可行性的验证已相对成熟。超声红外热图像处理方法的研究也成为近年来的热点。参考文献[4]提出的方法有效地滤除了图像噪声,实现了分割目标缺陷区域;参考文献[5]提出了基于小波变换的超声红外热图像处理方法,有效提高了红外图像的对比度与信噪比;参考文献[6]指出超声红外热成像作为一种用于非自热物体质量评价和安全保证的无损检测方法,其未来发展趋势必定是通过引入人工智能方法来快速、可靠和智能地进行检测。深度学习的飞速发展会使得基于红外热成像的机器视觉越来越智能化和高度自动化,从而大大增加其应用范围。

卷积神经网络(Convolutional Neural Network, CNN)在图像自动识别中获得巨大成功,同时也在缺陷识别中发挥着重要作用。图像经过卷积变换及降采样后被映射到一个较低维的空间中,并自动地提取图像的特征。参考文献[7]设计了基于改进型CNN的深度学习算法,成功地解决了现有焊接异常图像识别算法误检率与漏检率偏高的问题,且该算法对多种焊点缺陷类型识别优势巨大;参考文献[8]通过对短时傅里叶变换后振动信号的时频图进行CNN的训练,实现了对滚动轴承的故障状态识别。

文中针对金属疲劳裂纹检测与识别的问题,结合超声红外热成像技术以及CNN在图像特征自动提取与图像分类以及裂纹缺陷识别中的广泛应用,提出了一种结合超声红外热成像与CNN的裂纹检测与识别

方法。利用超声红外热成像技术获得多种不同尺寸裂纹的红外热图像,并将预处理后的红外热图像输入到CNN中进行特征自动提取与识别分类。实验结果表明,CNN在超声红外热像的后处理分类中具有一定的可行性,同时设计的CNN具有较高的识别精度和鲁棒性,能有效地对金属疲劳裂纹进行识别分类。为超声红外热图像的后续研究提供了参考方向。

1 理论基础

1.1 超声红外热成像检测技术

超声红外热成像检测技术使用超声脉冲作为激励源,振动能量注入被测试件,能量传播至裂纹、脱粘等接触面类型缺陷区域时,缺陷区域因摩擦、塑性变形等产生热量,产生的热量同时也取决于试件材料和施加的振动应力水平^[9]。产生的热量使缺陷处局部升温,通过红外热像仪获得材料表面热图像,进行计算机分析和处理,从而获取有效的裂纹信息。超声在试件内只对缺陷部位加热,检测技术灵敏度较高。典型的超声红外热成像热系统如图1所示,主要包括超声枪、红外热像仪、加载单元、固定夹具等^[10]。




图 1 超声红外热成像检测系统示意图

Fig.1 Schematic diagram of ultrasonic infrared thermal imaging detection system

1.2 卷积神经网络

CNN是一种特殊的多层感知器或前馈神经网络,具有局部连接、权值共享的特点^[11],其实质是构造多个用来提取输入数据特征的滤波器,通过滤波器对

数据进行卷积和池化操作,不断提取隐藏在数据集中的特征信息,特征信息不仅包含图像色彩,同时也能获取图像上的边缘特征,如裂纹轮廓、大小等。CNN 一般包含卷积层、池化层、全连接层以及激活函数层。

卷积层中可包含一个或多个卷积面(特征图)。输入的图像为矩阵形式,卷积层对应的卷积运算是该矩阵与参数矩阵在卷积层中做卷积操作的过程。参数矩阵也被称作卷积核,不同的卷积核能够提取到图像中的不同特征。卷积核的每个元素与图像对应位置相乘,再求和。通过卷积核的不断移动就会产生新的图像,该图像完全由卷积核在各个位置时的乘积求和的结果组成^[12]。

池化层可降低数据维度,避免过拟合、增强局部感受野以及提高平移不变性^[13]。常用最大池化(Max Pooling)或平均池化(Mean Pooling)。

图像经过数层卷积以及池化操作后会连接至全连接层。全连接层中的每个神经元与其前一层的所有神经元进行全连接,全连接层能将前层学习到具有类别区分性的特征信息进行整理。

激活函数层主要对卷积层的输出进行一个非线性映射,通过激活函数层的激励函数来加入非线性因素,以此增加模型的表达能力。常用的激活函数有 sigmoid 函数、双曲正切函数 tanh 和校正线性单元 ReLU 等,其表达式如公式(1)~(3)所示:

$$\sigma(x) = \text{sigm}(x) = \frac{1}{1 + e^{-x}} \quad (1)$$

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2)$$

$$\text{ReLU}(x) = \max(0, x) \quad (3)$$

2 超声红外热图像采集及其预处理

2.1 疲劳裂纹试件

文中预制疲劳裂纹试样采用金属平板,尺寸大小为 370 mm×100 mm×5 mm,材料为 45 钢,其抗拉强度和屈服强度分别为 620 MPa 和 451 MPa,预制裂纹过程中采用柔度法监测和控制裂纹长度,裂纹尺寸范围控制在 0.4~9.5 mm 之间,并将上述预裂纹试件采用电火花线切割的方式得到被测试件^[14],获得如图 2 所




图 2 被测试件示意图

Fig.2 Schematic diagram of test plate

示的被测试件。图 2 中给出了试件夹持位置(Clamp position)以及超声激励位置(Excitation position)。

2.2 超声红外热图像采集

超声红外热图像采集实验在陆军装甲兵学院车辆工程系 PHM 和无损检测实验室进行。

采集实验在一套超声红外热成像无损检测实验台上进行,通过自主编写的一套超声红外无损检测系统,实现了在软件及硬件上的实验要求。采集条件为预紧力 25 kg,激励强度 35%,激励时间 4 s,激励位置偏离中心 50 mm。试件共 15 类,每类含不同长度裂纹或没有裂纹,裂纹光学测量长度如表 1 所示,其中第 15 类为无裂纹试件。参考文献 [14] 给出了装置的具体组成。红外热像仪采用美国 FLIR 公司生产的

表 1 15 类金属试件的裂纹光学测量长度

Tab.1 Crack and optical measurement length of 15 kinds of metal specimens

Number of test piece	Crack length/ μm
01	5374.71
02	5477.40
03	5624.33
04	6570.00
05	6629.00
06	7275.00
07	7507.79
08	7930.00
09	8537.50
10	9143.00
11	9301.36
12	9453.00
13	3474.50
14	3898.49
15	0

T640, 用于实现采集对象表面的温度场信息。该热像仪可以提供红外图像分辨率为 640×480 pixel, 热灵敏度小于等于 $0.035 \text{ }^\circ\text{C}$, 图像采集帧频为 30 Hz , 镜头可实现 120° 上下翻转。激励结束后实验采集系统会自动生成对应文件, 然后通过 FLIR-ResearchIR 软件生成 CSV 文件。

2.3 超声红外热图像预处理及数据集形成

将实验所得的 CSV 文件输入到 MATLAB 软件中进行图像处理, 裁剪掉非试件区域, 选取所需的实验范围, 制作实验所需的数据集。最终获得数据集包含 15 类超声红外实验获得的红外热图像, 但采集的数据样本量较少, 因此需要对原始数据集进行扩增, 常用的数据扩增方法有图像旋转、图像裁剪、缩放、图像亮度变化、图像加入噪声等^[15]。为有效保留图像的原有特征信息, 文中采用图像旋转的方法对数据进行扩增, 如图 3 所示。最终获得每类 300 张, 共计 4500 张红外热图像, 部分无裂纹图像如图 4 所示, 有裂纹图像如图 5 所示。




图 3 数据集扩增
Fig.3 Data amplification




图 4 无裂纹红外热图像
Fig.4 Crack-free infrared thermal images

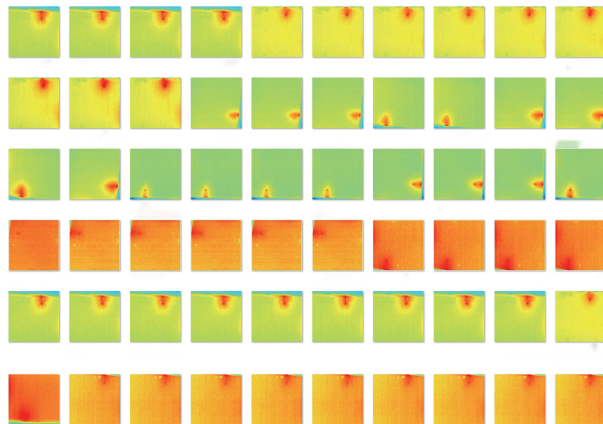


图 5 有裂纹红外热图像
Fig.5 Infrared thermal image with cracks

3 裂纹检测与识别分析

3.1 实验环境

实验环境: Windows 10 教育版, 64 位操作系统, 安装内存 (RAM) 8 G, 处理器为 AMD Ryzen 52600 Six-Core Processor 3.4 GHz, 显卡为 GeForce GTX 16606 G。

3.2 卷积神经网络的设计

不同的 CNN 结构对于不同问题、不同数据集, 具有不同的效果。并非越庞大的网络就越好, 因此, 文中针对当前超声红外热图像数据设计了一个 CNN 结构, 包含三层交替出现的卷积层和池化层 (最大池化), 两个全连接层, 激活函数选择校正线性单元 ReLU。

3.2.1 输入层

输入层为网络第一层, 图像经过输入层后转化为矩阵作为下一层卷积层的输入, 文中输入数据为 224×224 的彩色超声红外热图像。

3.2.2 卷积核尺寸及数量

在 CNN 的卷积运算中, 在达到相同感受野的情况下, 卷积核越小, 所需要的参数和计算量越小, 卷积核尺寸大小必须为大于 1 的奇数才有提升感受野的作用^[16]。因此文中卷积核大小选用 5 和 3。三层卷积层的卷积核大小依次为 5-3-3。CNN 三层卷积层的卷积核的数量设置为 8-16-32。

3.2.3 全连接层

文中设计的 CNN 结构设置两层全连接层, 分别置于第三层池化层后与 Softmax 层之前。

3.2.4 Softmax 回归模型

文中设计的 CNN 结构分类器使用 Softmax 回归

模型, Softmax 是 logistic 回归模型在多分类问题上的推广, 在多分类问题中, 类标签 y 可以取两个以上的值^[17]。Softmax 回归模型对于多分类问题非常有效,

它是有监督的回归模型。对于 n 类的分类问题, Softmax 的回归输出可通过公式 (4) 获得:

$$\theta = \begin{bmatrix} P(y = 1|x; W_1, b_1) \\ P(y = 2|x; W_2, b_2) \\ \dots \\ P(y = N|x; W_n, b_n) \end{bmatrix} = \frac{1}{\sum_{j=1}^n \exp(W_j x + b_j)} \begin{bmatrix} \exp(W_1 x + b_1) \\ \exp(W_2 x + b_2) \\ \dots \\ \exp(W_n x + b_n) \end{bmatrix} \quad (4)$$

式中: W 和 b 分别为权重矩阵和偏置值; θ 为 CNN 的输出。

技巧, 其基本思想是通过阻止特征检测器的共同作用来提高神经网络的泛化能力^[13]。网络参数如表 2 所示, 网络结构示意图如图 6 所示。

为避免过拟合, 在网络中使用丢失输出 (Dropout) 技术, 大小取 0.5。Dropout 是一种简单有效的正则化

表 2 文中设计的网络模型具体参数说明

Tab.2 Description of network model parameters designed in this article

Layer	Description	Layer	Description
input	224×224×3, images with "zerocenter" normalization	conv_3	32 3×3×16 convolutions with stride[1 1] and padding[1 1 1 1]
conv_1	8 5×5×3 convolutions with stride [1 1] and padding[0 0 0 0]	relu_3	Relu
relu_1	ReLU	maxpool_3	2×2 max pooling with stride [2 2] and padding[0 0 0 0]
crossnorm_1	Cross channel normalization with 5 channels per element	fc_1	512 fully connected layer
maxpool_1	2×2 max pooling with stride [2 2] and padding [0 0 0 0]	relu_4	ReLU
conv_2	16 3×3×8 convolutions with stride [1 1] and padding[2 2 2 2]	dropout	50% dropout
relu_2	Relu	fc_2	15 fully connected layer
crossnorm_2	Cross channel normalization with 5 channels per element	Softmax	Softmax
maxpool_2	2×2 max pooling with stride [2 2] and padding "same"	classoutput	crossentropyex

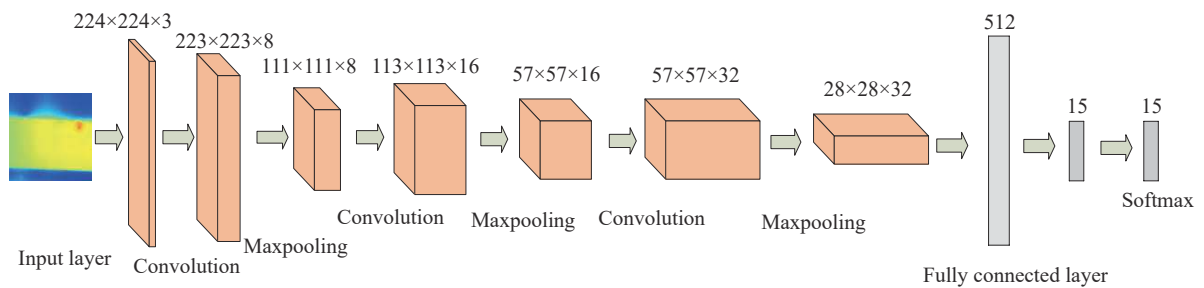


图 6 文中设计的卷积神经网络结构示意图

Fig.6 Structure diagram of convolutional neural network designed in this article

3.3 实验过程与结果

文中采用深度学习框架 Deep Network Designer 构建卷积神经网络, Deep Network Designer 是一个基于 MATLAB 的神经网络设计平台。

3.3.1 改变批量尺寸进行实验

批量尺寸 (Batch Size) 即每次训练时在训练集中

取一定量样本训练, 批量尺寸在 CNN 的训练中, 影响网络的训练速度和网络最终的训练效果, 当批量尺寸较大时, 网络训练收敛速度比较快, 但由于权值调整次数减少会影响训练效果, 批量尺寸较小时则反之, 所以需选择合适的批量尺寸。实验选择批量尺寸依次为 32、64、128。重复实验 10 次, 取 10 次实验最终

分类正确率的平均值和训练所用时间的平均值为标准。实验结果如表 3 所示,结果表明,批量尺寸为 64 时准确率最高。

表 3 不同批量尺寸识别率结果

Tab.3 Results of different batch size recognition rate

Batch size	Accuracy	Time/s
32	99.3%	296
64	100%	206
128	95.4%	188

3.3.2 卷积神经网络迭代次数的确定

在 CNN 的训练中,迭代过程是不断拟合、不断逼近的过程,迭代次数 (Epoch) 会影响拟合效果。当迭代次数达到一定数量时,拟合误差会接近收敛,不再减小,过高的迭代次数会加大时间成本。所以选择适当的迭代次数能在获得最佳拟合效果的同时拥有最小的时间成本。为测试最佳的迭代次数,将迭代次数以外的其他参数设为固定值,应用文中设计的 CNN 网络模型,设定最大迭代次数为 20,通过网络的训练选取最佳的迭代次数。随着迭代次数增多,识别的准确率不断提升,损失函数不断降低直达到最

优,训练过程如图 7 所示。当迭代次数达到 8 次,即训练次数达到 400 次以上,识别准确率基本稳定,训练模型的准确率达到 100%。

最终确定选取批量尺寸为 64,迭代次数为 10 次,学习率为 0.001, Dropout 为 0.5。并使用数据集对网络进行测试,在测试的输出环节中引入混淆矩阵 (Confusion matrix)^[18]。某次测试样本的分类结果如图 8 所




图 7 训练结果曲线

Fig.7 Curves of training results




图 8 测试样本分类结果

Fig.8 Classification results of testing samples

示。其中,纵轴表示预测裂纹,横轴表示真实裂纹。所有测试样本分类以及总的分类正确率和错误率都可从混淆矩阵中读出。

3.4 文中设计的网络可视化分析

为了更加直观地观察文中设计的 CNN 的数据聚类效果,使用 t 分布领域嵌入算法 (t-distributed Stochastic Neighbor Embedding, t-SNE)^[19] 进行可视化分析,分析数据集在 CNN 下的聚类效果,结果如图 9(a)~(c) 所示,分别表示网络第一层池化层、最后

一层全连接层以及 Softmax 层的输出数据的聚类效果。t-SNE 是一种非常有效的非线性降维方法,它是基于在邻域图上随机游走的概率分布,可以在数据中找到其结构关系。t-SNE 关心的是学习维持数据的局部结构,降到二维空间时会保留数据的流形结构,类间的距离远近并不代表真实数据的分类距离,仅为一个聚类示意图。由图 9 可知,数据集在文中提出的模型中有着很好的聚类效果,分类效果明显。

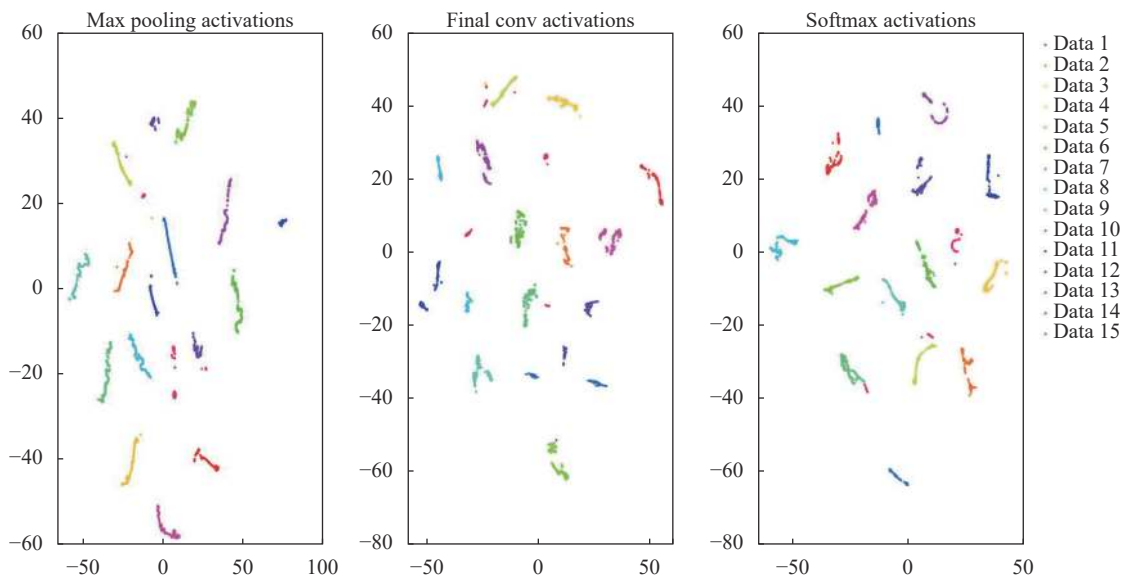


图 9 网络模型对测试集的 t-SNE 可视化

Fig.9 t-SNE visualization of test set based on network model

4 CNN 网络模型验证

4.1 可行性验证

为验证文中设计的 CNN 的可行性,除在表 1 数据集上进行测试外,还在与表 1 数据集不同实验条件下获得的热图像上进行了验证,所用的超声红外实验条件为预紧力 15 kg,激励强度 40%,激励时间 3 s,激励位置不变,获得红外热图像共 10 类,每类包含 300 张,共计 3 000 张红外热图像,裂纹大小如表 4 所示。使用训练好的网络对验证所用的数据集进行识别分类,多次实验的平均识别率在 99% 以上,某次裂纹的真实结果与预测分类结果如图 10 所示。实验

结果表明,设计的 CNN 在不同检测条件下获得的热图像仍具有一定的可行性。

表 4 金属平板试件及光学测量裂纹大小

Tab.4 Metal plate specimen and optical measurement of crack size

Number of test piece	Crack length/ μm	Number of test piece	Crack length/ μm
A	9453.00	F	6577.41
B	9301.36	G	6629.00
C	9143.00	H	6740.50
D	8537.50	I	6983.00
E	8014.54	J	7275.00

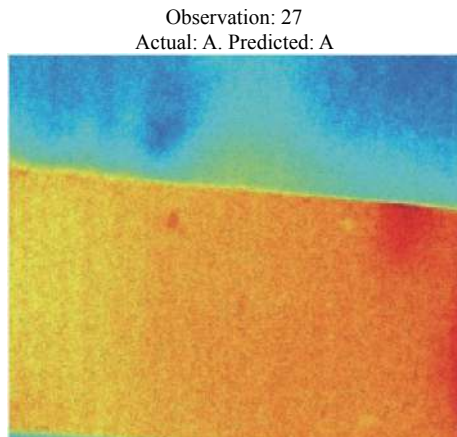


图 10 某次裂纹预测结果
Fig.10 Prediction results of a crack

4.2 有效性验证

为验证文中设计的 CNN 的有效性,选取在图像识别中现常用的网络模型 Alexnet^[20] 以及 GoogLeNet^[21] 进行对比实验,同时也使用支持向量机 (SVM)^[22] 对图像进行分类。使用表 1 的实验数据进行验证。实验结果显示,设计的 CNN 分类准确率优于两种常用模型的准确率且网络训练时间较少,对比支持向量机,其识别效果更为显著,可知文中提出的方法优于传统检测与识别方法。具体实验结果如表 5 所示。

表 5 不同算法对裂纹识别分类情况

Tab.5 Crack recognition and classification by different algorithms

Algorithm	Accuracy	Time/s
CNN designed in this article	100%	206
Alexnet	99.6%	236
GoogLeNet	98.9%	326
SVM	95.3%	1154

5 结 论

文中针对超声红外热图像的后处理及裂纹的自动识别问题,提出了一种基于 CNN 的金属疲劳裂纹超声红外热像检测与识别方法,该方法对自制裂纹图像数据集识别分类准确率达到 100%。为超声红外热图像的后处理及裂纹自动识别的研究提供了一定的参考。同时可得以下结论:

(1) 针对金属疲劳裂纹检测与识别的问题,提出

的方法可同时对多种裂纹以及无裂纹红外热图像进行识别分类,验证了 CNN 自动识别超声红外热图像的可行性。

(2) 对不同超声红外实验条件下获得的红外热图像进行实验验证,结果表明,设计的 CNN 依然具有很高的识别率,验证了方法的可行性及网络良好的鲁棒性。

(3) 相比 Alexnet 网络、GoogLeNet 网络和支持向量机 (SVM),设计的 CNN 识别准确率最高。

参考文献:

- [1] Fan Xinguang. Study of fatigue crack initiation and propagation of railroad wheel under rolling contact[D]. Beijing: Beijing Jiaotong University, 2019. (in Chinese)
- [2] Gong Ke, Wu Ming, Xie Fei, et al. Effect of dry/wet ratio and pH on the stress corrosion cracking behavior of rusted X100 steel in an alternating dry/wet environment [J]. *Construction and Building Materials*, 2020, 270: 124826.
- [3] Zhou Zhixin. Overview of NDT methods for mechanical cracks [J]. *Mechanical and Electrical Engineering*, 2017, 34(10): 1138-1143. (in Chinese)
- [4] Tang Changming, Zhong Jianfeng, Zhong Shuncong, et al. Ultrasound infrared thermography defect recognition based on improved adaptive genetic algorithm with two-dimensional maximum entropy [J]. *Infrared Technology*, 2020, 42(8): 801-808. (in Chinese)
- [5] Ji Longxin, Feng Fuzhou, Min Qingxu. Ultrasonic infrared thermal image processing based on wavelet transform [J]. *Journal of Changchun University of Science and Technology (Natural Science Edition)*, 2020, 43(4): 112-116, 128. (in Chinese)
- [6] He Yunze, Deng Baoyuan, Wang Hongjin, et al. Infrared machine vision and infrared thermography with deep learning: A review [J]. *Infrared Physics & Technology*, 2021, 116: 103754.
- [7] Chang Ying, Chang Dajun. Research on solder joint defect recognition algorithm based on improved convolutional neural network [J]. *Laser Technology*, 2020, 44(6): 779-783. (in Chinese)
- [8] Liu Bingji, Xiong Bangshu, Ou Qiaofeng, et al. Fault diagnosis of rolling bearing based on time-frequency representations and CNN [J]. *Journal of Nanchang Hangkong University (Natural Science Edition)*, 2018, 32(2): 86-91. (in Chinese)
- [9] Renshaw J, Chen J C, Holland S D, et al. The sources of heat

- generation in vibrothermography [J]. *NDT and E International*, 2011, 44(8): 736-739.
- [10] Min Qingxu, Zhu Junzhen, Feng Fuzhou, et al. Study on optimization method of test conditions for fatigue crack detection using lock-in vibrothermography [J]. *Infrared Physics and Technology*, 2017, 83: 17-23.
- [11] Zhou Feiyan, Jin Linpeng, Dong Jun. Review of convolutional neural network [J]. *Chinese Journal of Computers*, 2017, 40(6): 1229-1251. (in Chinese)
- [12] Kang Chaomeng. Cloud detection in domestic high-resolution remote sensing image based deep neural networks[D]. Xi'an: University of Chinese Academy of Sciences (Xi'an Institute of Optics & Precision Mechanics, Chinese Academy of Sciences), 2018. (in Chinese)
- [13] Zhang Anan, Huang Jinying, Ji Shuwei, et al. Bearing fault pattern recognition based on image classification with CNN [J]. *Vibration and Impact*, 2020, 39(4): 165-171. (in Chinese)
- [14] Feng Fuzhou, Zhang Chaosheng, Song Aibin, et al. Probability of detection model for fatigue crack in ultrasonic infrared imaging [J]. *Infrared and Laser Engineering*, 2016, 45(3): 0304005. (in Chinese)
- [15] Xue Shan, Zhang Zhen, Lv Qiongying, et al. Image recognition method of anti UAV system based on convolutional neural network [J]. *Infrared and Laser Engineering*, 2020, 49(7): 20200154. (in Chinese)
- [16] Zhang Xiangxiang. Research on convolutional code decoders based on deep learning under correlated noise[D]. Beijing: Beijing University of Posts and Telecommunications, 2019. (in Chinese)
- [17] Wu Yunxia, Tian Yimin. A coal-rock recognition method based on max-pooling sparse coding [J]. *Chinese Journal of Engineering*, 2017, 39(7): 981-987. (in Chinese)
- [18] Jiao Jinyang, Zhao Ming, Lin Jing, et al. A multivariate encoder information based convolutional neural network for intelligent fault diagnosis of planetary gearboxes [J]. *Knowledge-Based Systems*, 2018, 160(15): 237-250.
- [19] Zhu Wenbo, Webb Z T, Mao Kaitian, et al. A deep learning approach for process data visualization using t-distributed stochastic neighbor embedding [J]. *Industrial & Engineering Chemistry Research*, 2019, 58(22): 9564-9575.
- [20] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [C]//International Conference on Neural Information Processing Systems, 2012: 1106-1114.
- [21] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions [C]//2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2015: 1-8.
- [22] Liu Li, Sun Lijie, Wang Wenju. Classification of fluorescent images in high-throughput dPRC gene chips based on SVM [J]. *Packaging Engineering*, 2020, 41(19): 223-229. (in Chinese)