

# 基于 Bi-LSTM 的金属疲劳裂纹涡流脉冲热像技术检测与识别

林 丽<sup>1</sup>, 姜 景<sup>1</sup>, 朱俊臻<sup>2,3</sup>, 冯辅周<sup>2</sup>

(1. 大连交通大学 机车车辆工程学院, 大连 116000; 2. 陆军装甲兵学院 车辆工程系, 北京 100072;

3. 北京信息科技大学 现代测控技术教育部重点实验室, 北京 100192)

**摘要:** 涡流脉冲热像 (Eddy current pulsed thermography, ECPT) 技术是一种新型的无损检测方法, 广泛应用于金属材料结构的检测, 但该技术常依赖人工经验提取特征进行裂纹检测与识别, 自动化和智能化程度不足。结合涡流脉冲热像技术以及循环神经网络 (Recurrent Neural Network, RNN) 的特性, 提出一种基于双向长短期记忆网络 (Bidirectional Long Short-Term Memory Network, Bi-LSTM) 金属疲劳裂纹涡流脉冲热像分类识别方法。实验通过涡流加热装置对被测金属试件进行感应加热, 使用红外热像采集装置对金属平板试件进行实时的数据采集, 获得图像序列并制作数据集。运用设计的 Bi-LSTM 模型增强特征向量中的时序信息, 对不同尺寸裂纹的热图像进行训练并测试。实验分析表明, Bi-LSTM 网络可有效应用于金属疲劳裂纹检测与识别, 针对现有裂纹检测准确率可达到 100%, 优于传统神经网络和其他深度学习的模型, 具有更高的识别精度。

**关键词:** 涡流脉冲热像技术; 双向长短期记忆网络; 裂纹识别; 特征提取

**中图分类号:** TG115.28      **文献标志码:** A      **文章编号:** 1001-8891(2023)09-0982-08

## Detection and Recognition of Metal Fatigue Cracks by Bi-LSTM Based on Eddy Current Pulsed Thermography

LIN Li<sup>1</sup>, JIANG Jing<sup>1</sup>, ZHU Junzhen<sup>2,3</sup>, FENG Fuzhou<sup>2</sup>

(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;

3. Key Laboratory of Modern Measurement & Control Technology of Ministry of Education,

Beijing Information Science and Technology University, Beijing 100192, China)

**Abstract:** Eddy current pulsed thermography is a new nondestructive testing method that is widely used in metal structure testing. However, the extraction of features for crack detection and identification relies on manual experience, and the degree of automation and intelligence is insufficient. By combining the characteristics of eddy current pulsed thermography with a recurrent neural network (RNN), a bidirectional long short-term memory (Bi-LSTM)-based eddy current pulse thermography method is proposed for metal fatigue crack classification and recognition. The Bi-LSTM model was designed to enhance the transient information in the feature vectors. In the experiments, an eddy current heating device was used to heat the tested metal specimens. A real-time dataset was created using an infrared thermal camera that collected sequences of images. The Bi-LSTM model was trained on thermal images of cracks of different sizes and tested. Experimental analyses show that the Bi-LSTM network can be effectively applied for metal fatigue crack detection and recognition, with the detection accuracy reaching 100% for the cracks used in the experiments, which is superior to that of traditional neural networks and other deep learning models.

**Key words:** eddy current pulsed thermography, Bi-LSTM, crack identification, feature extraction

收稿日期: 2022-09-22; 修订日期: 2022-11-23.

作者简介: 林丽 (1971-), 女, 副教授, 博士, 硕士生导师, 主要从事列车故障诊断方面的研究。E-mail: julandalili@126.com.

通信作者: 冯辅周 (1971-), 男, 教授, 博士生导师, 主要从事故障诊断与无损检测技术研究。E-mail: fengfuzhou@tsinghua.org.cn.

基金项目: 国家自然科学基金 (51875576, 52005510); 现代测控技术教育部重点实验开放课题 (KF20211123204)。

## 0 引言

随着我国经济向高质量转型发展,现代科技正助推机械设备向高精密、高复杂和高效率方向发展,机械设备的高负荷运转必然造成关键部件常承受巨大的冲击与载荷,进而极易产生疲劳,萌生裂纹<sup>[1]</sup>。如不能在初期及时发现,裂纹会逐渐扩展,进而导致整个设备损坏,造成人力、物力资源损失,甚至存有重大的安全隐患<sup>[2]</sup>。因此,确保设备的安全是非常重要的任务,具有重大的研究意义。

涡流脉冲热像(Eddy current pulse thermography, ECPT)技术是一种将涡流检测和热像技术相结合的新型无损检测技术<sup>[3]</sup>。作为新晋的无损检测手段,其具有检测面积大、速度快、非接触、无污染、空间分辨率高以及成像直观等优势<sup>[4]</sup>。涡流热图像处理方法成为近年来的研究热点。毕野等<sup>[5]</sup>设计一套涡流热像无损检测系统,并提出一种基于深度学习模型的识别诊断试件的损伤程度;Gao 等<sup>[6]</sup>提出了一种定量分析策略,以验证各种热特征提取技术的检测性能;孙吉伟等<sup>[7]</sup>探究了利用图像特征提取技术对涡流脉冲热成像缺陷检测。然而,在实际应用中,由于裂纹缺陷类型不同,进而产生不同状态的温度场分布,降低了图像特征提取的准确性和效率。随着深度学习技术的迅速发展,基于计算机视觉进行热像无损检测愈发智能化和现代化,其应用领域将会得到极大地拓宽。它的发展趋势必然是采用人工智能技术来实现快速、可靠、智能的检测。

为了解决人工提取特征效率低下和智能化不足等问题,本文采用涡流脉冲热像无损检测系统采集具有微小裂纹的金属热像数据,对图像进行预处理,将循环神经网络应用到金属疲劳裂纹检测中,利用卷积神经网络(Convolutional Neural Network, CNN)善于提取图像特征的优势,提出一种涡流脉冲热像技术背景下基于 Bi-LSTM 模型的金属裂纹识别分类方法。首先将预处理后的涡流脉冲热图像输入 CNN 模型提取图像特征,在经过特征压缩,变为序列特征输入 Bi-LSTM 模型,最后通过分类器 Softmax 实现涡流热图像识别分类,并与其他网络模型的识别率进行对比。经实验验证,该方法在金属疲劳裂纹检测方面获得更高的效率和识别精度。

## 1 循环神经网络

循环神经网络是一类以序列数据为输入,在序列的演进方向进行递归并且所有的节点(循环单元)按照链式连接的递归网络。主流的循环神经网络是长短

期记忆网络(long short-term memory, LSTM)和双向循环神经网络(Bi-RNN)。循环神经网络具有记忆性、参数共享并且图灵完备,因此在对序列的非线性特征学习时具有一定优势,常用于处理一段文字或声音、购物或观影的顺序,同时也能处理图像的一行或者一列像素<sup>[8]</sup>。

### 1.1 长短期记忆循环神经网络

长短期记忆神经网络是一种循环神经网络结构的变体,可以解决循环神经网络的梯度消失和梯度爆炸问题。LSTM 相比于 RNN 的最大不同是通过“门”结构来控制神经网络中每个时刻的信息状态, LSTM 中引入了 3 个门,既输入门(input gate)、遗忘门(forget gate)、和输出门(output gate),以及与隐含状态形状相同的记忆细胞从而记录额外的信息<sup>[9]</sup>。LSTM 内部结构如图 1 所示。




图1 LSTM 神经网络结构组成

Fig.1 The structure of LSTM neural network

图中:  $X_t$  表示输入状态;  $i$  是输入门;  $f$  是遗忘门;  $\tilde{c}_t$  是候选记忆细胞;  $o$  是输出门;  $c_t$  是记忆细胞;  $h_t$  是隐藏状态。

### 1.2 双向长短期记忆循环神经网络

传统的 RNN 网络没有记忆功能,单向的 LSTM 网络由前向后推测信息,都只能利用以往的信息,而没考虑之后的隐含层神经元的的信息,缺乏前后的逻辑性<sup>[10]</sup>。双向长短期记忆神经网络(Bi-LSTM)是在 LSTM 结构基础上演变而来的,通过前向和后向传播双向运算,加深之前序列特征的提取,可以提高模型输出结果的准确性。这样的双向 LSTM 网络即可获得以往信息和未来信息,从而在整个时间上获得更多的信息<sup>[11]</sup>。

Bi-LSTM 的双向结构,不仅具备了 LSTM 解决 RNN 中的梯度消失、爆炸的能力,而且相较于单方向的 LSTM,既能充分利用前面的历史信息,又能考虑到后面的信息数据。Bi-LSTM 很好地实现了记忆和累积功能,尽可能地利用了所能用到的信息,对前后序列捕捉特征更加有效。Bi-LSTM 能够充分利用前后序

列的相关信息来解决序列问题<sup>[12]</sup>。Bi-LSTM 结构示意图如图 2 所示。




图 2 Bi-LSTM 网络结构

Fig.2 Bi-LSTM network structure

在 Bi-LSTM 网络的计算过程中, 分别对前向隐向量  $\vec{h}_{t-1}$  产生新的向量  $\vec{h}_t$  和后向隐向量  $\vec{h}_{t+1}$  产生新的向量  $\vec{h}'_t$  进行计算。计算公式分别为:

$$\vec{h}_t = g(W_{x\vec{h}} x_t + W_{\vec{h}\vec{h}} \vec{h}_{t-1} + b_{\vec{h}}) \quad (1)$$

$$\vec{h}'_t = g(W_{x\vec{h}'} x_t + W_{\vec{h}\vec{h}'} \vec{h}_{t+1} + b_{\vec{h}'}) \quad (2)$$

Bi-LSTM 中, 将前后正反两个方向 LSTM 相加, 最终输出结果  $y_t$ :

$$y_t = f(W_{hy} \vec{h}_t + W_{hy'} \vec{h}'_t + b_y) \quad (3)$$

式中:  $W$  是权重参数;  $b$  是偏差参数。

另外, 如果模型过拟合, 那么得到的模型几乎不能用。为了防止过拟合现象, 提高网络模型的适用性, 引入 Dropout 方法。此方法通过使部分神经元随机失去活性, 保证所有的训练都具有不同的弱分类器的性质, 从而保证了模型的泛化能力<sup>[13]</sup>。


## 2 涡流脉冲热像的数据获取及处理

涡流脉冲热像技术是目前国内外研究的一个热点, 它将电磁生热和瞬态红外热成像相结合, 可以在较大范围内快速、高效地进行缺陷的检测和特征提取, 其核心是涡流脉冲热图像的识别。本文实验采用涡流加热装置对被测金属试件进行涡流加热, 同时搭建红外热像检测装置, 实时采集红外热波检测图像, 并将数据转换成图像, 再对图像进行预处理后作为样本数据集。

### 2.1 涡流脉冲热像实验系统


设计搭建一套涡流脉冲热像无损检测实验台, 能够定量控制激励时间、激励强度和提取距离等检测条件参数, 同时编写一套涡流脉冲热像无损检测系统软件, 满足软件和硬件上的实验要求, 其组成如图 3 所示, 主要由型号为 FILR-T640 的红外热像仪 (分辨率为  $640\text{pixel} \times 480\text{pixel}$ , 采集频率为 30Hz, 热灵敏度

为 35mK)、感应电磁激励装置 (功率为 3kW 的高频激励电源、电磁线圈、支座、水冷装置)、采集控制终端 (PC) 和其他辅助设备 (三维移动平台等)。



(a) 涡流脉冲热像系统示意图

(a) Schematic diagram of ECPT



(b) 涡流脉冲热像检测实物图

(b) Demonstration of ECPT

图 3 涡流脉冲热像检测实验系统

Fig.3 ECPT experimental system

### 2.2 检测试件和数据采集

为得到实际应用中经常遇到的缺陷裂纹, 实验采用一种具有预制疲劳裂纹的金属平板, 如图 4 所示, 尺寸大小为  $240\text{mm} \times 47.7\text{mm} \times 5\text{mm}$ , 材料为 45 钢<sup>[14]</sup>。由于加工过程的约束, 不能在金属试件的内部进行缺陷破坏, 因此本实验仅对金属试件表面缺陷进行研究, 即在平板长边一侧进行人工预制贯穿疲劳裂纹。此外, 在实验之前, 被测金属平板表面喷涂黑色哑光漆, 以改善其表面的发射率。

为了充分考虑实验数据的多样性, 此次选取的实验数据在不同的激励时间、激励强度 (系统功率的百分比) 和提取距离 (电磁线圈下表面与试件上表面的距离) 条件进行图像序列采集。本文以 18 类试件为研究对象, 采集条件为激励时间 200ms, 激励强度



80%，提取距离 10mm，采集时间 1s，每类含不同长度裂纹或没有裂纹，其编号和尺寸如表 1 所示，其中第 1 类为无裂纹（正常）试件。




图 4 含疲劳裂纹的 45 钢平板试件

Fig.4 45 steel flat specimen with fatigue crack

2.3 红外图像预处理及样本集形成

将样本输入模型之前需要通过 MATLAB 软件对实验采集的金属试件样本进行图像预处理，对非试件区域进行裁剪，获得所需的实验范围，进行样本集制作。该数据集包括 18 类不同类型的涡流脉冲热像实验所得的红外热图像，由于采集的样本数量较少所以需要 对原始样本集进行扩增，数据扩增的常见的方法有图像缩放、图像裁剪、图像平移、图像亮度调整、

图像色彩调整、图像添加噪声和滤波等<sup>[15]</sup>。为更好保持原始图片的特征信息，采用图像旋转的方法对样本数据扩增，图片进行顺时针旋转 90°、180°和 270°，如图 5、6 所示，分别为含裂纹图像和无裂纹图像，每类 180 张，共采集 3240 张金属试件的涡流脉冲热图像。

表 1 18 类金属试件裂纹长度及其编号

Table 1 Crack length and numbering of 18 metal specimens

Serial numbers	Crack length/ $\mu\text{m}$
1	0
2	1707.41
3	1986.66
4	2181.48
5	3454.42
6	3474.50
7	3898.49
8	4639.50
9	4866.00
10	5263.50
11	5374.71
12	5477.50
13	5624.33
14	6559.11
15	6570.00
16	6577.41
17	6629.00
18	6740.50

将 3240 张图片按照 7:3 的比例分为训练数据集和测试数据集，其中训练图像 2268 张，测试图像 972 张。

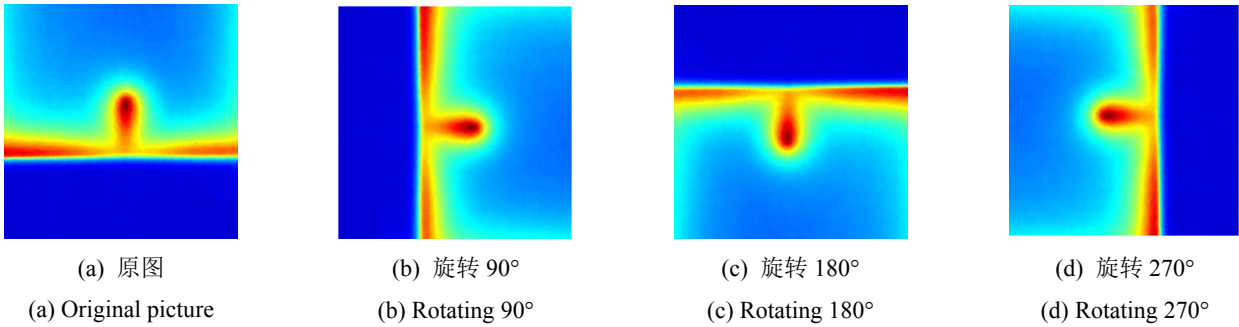


图 5 有裂纹数据集扩增图

Fig.5 Expansion of crack dataset




图6 无裂纹数据集扩增图

Fig.6 Expansion of the crack-free dataset

### 3 基于 Bi-LSTM 金属试件缺陷检测

#### 3.1 环境配置

文中实验采用硬件环境是 Intel (R), Core (TM) i5-7500 CPU@3.40 GHz, 内存 16 G, 显卡为 GeForce GTX 1060 6 GB, 软件环境为: Windows10 (64 位) 操作系统, MATLAB R2021b。

#### 3.2 网络模型建立

首先, 输入图像为预处理后图像, 确保所有图像的尺寸相同, 卷积神经网络善于提取图像特征, 但是难以捕捉到序列数据中的长期依赖关系<sup>[16]</sup>。因此, 文中针对当前涡流脉冲热图像数据设计一个 Bi-LSTM 网络结构, 弥补这一不足。网络结构示意图如图 7 所示。

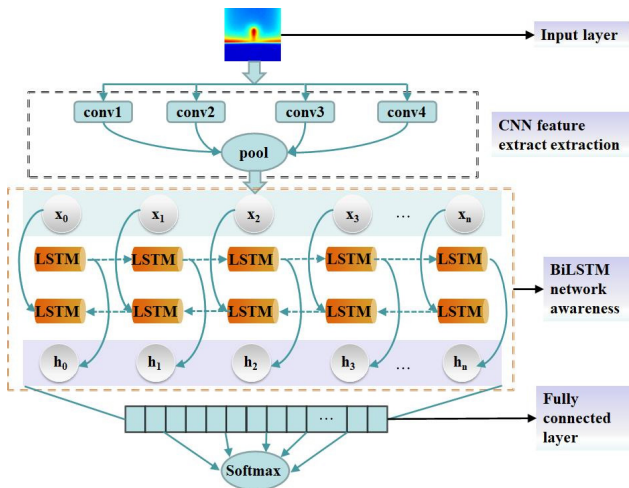


图7 文中设计模型主体结构

Fig.7 Main structure of the model in this paper

1) 输入层: 作为网络结构的首层, 图像通过输入层后转化为矩阵作为下一层卷积层的输入, 文中输入涡流脉冲热图像的大小为  $256 \times 256$ , 以便进行卷积操作。

2) 卷积层: 实验采用 4 个卷积层, 利用多个不同大小的多个卷积核, 可以获得更多的特征图, 从而使特征信息显示的更加丰富。

3) 池化层: 池化层可以使特征变得更加明显, 池化后的特征图分辨率变为原来的  $1/2$ 。

4) Bi-LSTM 网络层: 将之前得到的特征压缩, 变为序列特征输入 Bi-LSTM 模型处理分类, 使用 Adam 自适应可变学习率优化器, 对网络进行训练<sup>[17]</sup>。经过多次反复实验调参, 采用两层堆积的 LSTM 结构, 其隐含层节点数分别为 64 和 32。

5) 全连接层: 可以看作是卷积、池化操作之后, 将局部特征重新进行拟合, 文中在 Softmax 层之前设置 1 个全连接层, 均采用 128 个神经元。

6) Softmax 回归模型: 分类器采用 Softmax 回归模型, 它是 logistic 回归模型在多分类问题上的扩展, 在多分类问题中, 类标签  $y$  可以取两个以上的值。Softmax 回归模型对多分类问题非常有效。

其中, 批标准化 (BatchNorm, BN) 层能够加快网络的收敛速度, 使网络更加稳定, 同时, 为避免在双向训练时过拟合, 使其提取更有用的特征, 在网络模型中加入丢失输出 (Dropout) 方法<sup>[18]</sup>, 大小取 0.5。Dropout 是一种简单而高效的正则化方法, 它的主要目的是通过阻止特征检测器的共同作用, 从而提高神经网络的泛化能力。具体网络参数如表 2 所示。

#### 3.3 实验结果分析

实验采用深度学习框架 Deep Network Designer 构建循环神经网络, Deep Network Designer 是基于 MATLAB 的神经网络设计平台。

##### 3.3.1 迭代次数对模型训练精度的影响

迭代 (Iteration) 是指使用一个 Batch 数据对网络模型进行一次参数更新的过程, 称作“一次训练”, 也叫“迭代次数 (Epoch)”。对于 Bi-LSTM 模型来说, 如果训练阶段的迭代次数过小, 会导致数据训练不够充分, 分类准确率低; 相反如果迭代次数过大, 会加大时间成本, 使得计算成本增加。所以选择合适的迭代次数能在获得最佳训练效果的同时拥有最小的成本。为了确定最佳的 Epoch, 把除了迭代次数以外的其他参数设为固定值, 使用本文设计的 Bi-LSTM 网

络模型, 设定最大迭代次数为 30。损失函数是一种用于求解和评估网络模型的非负值函数, 其损失函数值越低, 则该模型具有更好的鲁棒性。随着迭代次数的增加, 识别准确率逐步增加, 损失函数不断降低达到最佳。当迭代次数达到 5 次, 即训练次数达到 1000 次以上, 识别准确率不在增加, 震荡幅度基本稳定, 训练模型的准确率到达 100%且损失趋近于 0, 说明模型训练效果很好。训练集准确率和损失变化曲线如图 8 所示。

表 2 本文设计的模型各网络层具体参数


Table 2 Specific parameters of each network layer in this paper

Layer	Detailed parameters
Input	256×256, Thermal image
Conv1	Number and size of convolution kernels, 2 5×5×1
Conv2	Number and size of convolution kernels, 4 5×5×1
Conv3	Number and size of convolution kernels, 8 5×5×1
Conv4	Number and size of convolution kernels, 16 5×5×1
Pool	Number and size of convolution kernels, 1 2×2×1
Drop	Dropout (0.2)
FC	128 fully connected layer
Bi-LSTM1	Number of hidden layer nodes 64
Bi-LSTM2	Number of hidden layer nodes 32
Softmax	Softmax

3.3.2 批量尺寸对模型训练精度的影响


在模型训练过程中, 批量尺寸的大小对模型的性能有着至关重要的影响。使用小批量尺寸时, 虽然能够更快地收敛, 但是并不容易并行化, 分类效果不理想, 使用批改尺寸较大时, 网络训练收敛速度加快, 但是权值调整次数减少, 导致训练效果较差。因此, 在选择批量尺寸的同时, 需要衡量分类的正确率和时间, 选择合适的批量尺寸, 在保证时间的条件下, 提高分类的正确率。迭代次数选择 30 次, 分别取批量尺寸 16、32、64、128, 在每种批量尺寸的情况下进行 10 次实验, 不同批量尺寸下的实验结果的平均值对比如图 8 所示。

根据表 3 可以看出, 批量尺寸选择 16 时, 用时最少, 但准确率相对于批量尺寸 32 和 64 较低, 批量尺寸选择 128 时, 准确率最低, 并且时间成本较高, 当批量尺寸为 64 时, 模型准确率最高, 达到 100%, 并且用时也较短, 故选取批量尺寸为 64 最佳。



(a) 准确率随迭代次数变化情况

(a) Variation of accuracy with number of iterations



(b) 损失随迭代次数变化情况

(b) Variation of loss with number of iterations

图 8 训练结果曲线

Fig.8 Training result curves

表 3 不同批量尺寸识别准确率

Table 3 Different batch size identification accuracy

Batch size	Accuracy/%	Time/s
16	98.77	261
32	99.87	220
64	100	197
128	94.78	162

通过实验, 模型最终选取迭代次数为 30 次, 批量尺寸为 64, 学习率为 0.0001, Dropout 层参数设置为 0.5。

3.4 模型可视化效果

同时为了更清楚评价本文方法的性能, 在测试的输出环节设计了混淆矩阵<sup>[19]</sup>。其中某次测试样本的分类结果如图 9 所示, 横坐标表示了 18 类真实裂纹缺陷, 纵坐标表示 18 类预测裂纹缺陷。通过混淆矩阵的方法, 有无裂纹图像识别准确率都可以看到。

4 Bi-LSTM 网络模型性能评估

4.1 复合检测条件下可行性验证

在实际的涡流脉冲热像检测中, 针对不同材料、不同结构, 通常需要采用不同的检测条件。缺陷尺寸的识别准确率不仅和模型结构有关, 也受到涡流脉冲热像检测时的检测条件影响。为了验证文中提出的 Bi-LSTM 模型的可行性, 选用不同检测条件下获得的涡流脉冲图像混合在一起进行验证, 每组数据采集时间和激励位置不变, 6 种检测条件激励强度分别为 60%、80%、100%, 提取距离分别为 4 mm、7 mm、



13 mm、16 mm，每类标签含 180 张，6 种检测条件下共 1800 张图像。选择 10 类缺陷长度的金属平板试件，缺陷尺寸及对应标签如表 4 所示。复合检测条件下金属缺陷尺寸的分类识别依然用训练好的网络模型，多次实验验证准确率达到 98.7%左右。实验结果表明，本文提出的循环神经网络模型适用于复合检测条件下涡流脉冲热图像的识别，具有一定的可行性。




图9 测试结果的准确性  
Fig.9 Accuracy of test results

表4 复合检测条件下裂纹尺寸及其标签

Table 4 Crack size and label under composite detection conditions			
Serial number	Crack length/ $\mu\text{m}$	Serial number	Crack length/ $\mu\text{m}$
a	5374.71	f	7507.79
b	5624.33	g	7930
c	6559.11	h	8414.54
d	6577.41	i	9143
e	7275	j	9453

4.2 对比模型构建与分析

本文采用准确率作为模型的评价指标。同时，为了验证本文所设计的 Bi-LSTM 模型的性能，对比两种传统机器学习模型（Support Vector Machine，SVM<sup>[20]</sup>、K-Nearest Neighbor Classifier，KNN<sup>[21]</sup>）、三种深度学习模型（Google Inception Net，GooLeNet<sup>[22]</sup>、Visual Geometry Group Network，VGGNet<sup>[23]</sup>和 Deep residual network，ResNet<sup>[24]</sup>），在相同预处理条件下趋于稳定时，取多次实验进行比较，实验结果表明，文中设计的 Bi-LSTM 模型准确率优于其他方法，识别分类效果更好，具体实验结果如表 5 所示。

表5 Bi-LSTM 与其他算法的实验对比

Table 5 Experimental comparison between BI-LSTM and other algorithms						
Model	Bi-LSTM (This paper)	SVM	KNN	GooLeNet	VGG	ResNet
Accuracy%	100	96.7	99.59	97.8	98.6	99.3
Recognition time/s	197	462	293	309	345	322

5 结论

本文通过将循环神经网络模型应用到涡流脉冲热图像的智能识别分类中，探究了不同迭代次数和批量尺寸对模型训练精度的影响，提出一种基于 Bi-LSTM 的金属疲劳裂纹智能检测与识别分类方法，对得到的数据集识别分类准确率可达到 100%，解决了涡流脉冲热图像智能检测识别的问题。得出了以下结论：

- 1) 为了解决传统诊断方法在金属缺陷裂纹检测不具有智能化的问题，提出的方法可从数据中直接自动提取涡流脉冲热图像特征，提高金属缺陷识别的准确性和智能性的方法。
- 2) 在复合检测条件下对涡流脉冲热图像混合在一起进行验证，多次实验验证，本文提出的 Bi-LSTM 网络模型适用于复合检测条件下涡流脉冲热图像的

- 识别，具有一定的可行性。
- 3) 对比传统神经网络（SVM、KNN）和深度学习模型（GooLeNet、VGG 和 ResNet），本文提出的方法识别精度最高，针对现有裂纹识别精度可高达 100%。
- 参考文献：
- [1] 韩丽民. 采煤机关键部件故障分析与诊断[J]. 能源与节能, 2021(11): 156-157, 159. DOI: 10.16643/j.cnki.14-1360/td.2021.11.061  
HAN limin. Fault analysis and diagnosis of key parts of shearer[J]. *Energy and Conservation*, 2021(11): 156-157, 159. DOI: 10.16643/j.cnki.14-1360/td.2021.11.061
  - [2] 窦建. 机电设备维修管理的现状和对策认识实践[J]. 中国设备工程, 2022(13): 79-81.  
DOU Jian. Current situation and countermeasures of maintenance management of mechanical and electrical equipment[J]. *China Equipment Engineering*, 2022(13): 79-81.
  - [3] 冯辅周, 朱俊臻, 闵庆旭,等. 涡流热像无损检测技术综述[J]. 装甲兵工程学院学报, 2016, 30(6): 60-67.

- FENG Fuzhou, ZHU Junzhen, MIN Qingxu, et al. Review of eddy current thermography nondestructive testing[J]. *Journal of Academy of Armored Force Engineering*, 2016, **30**(6): 60-67.
- [4] 苗玲, 高斌, 石永生, 等. 基于电涡流热成像的钢轨滚动接触疲劳裂纹动态检测研究[J]. *机械工程学报*, 2021, **57**(18): 86-97.
- MIAO Ling, GAO Bin, SHI Yongsheng, et al. Dynamic detection of rolling contact fatigue cracks in rail based on eddy current thermal imaging[J]. *Journal of Mechanical Engineering*, 2021, **57**(18): 86-97.
- [5] 毕野, 熊新, 叶波, 等. 基于深度学习的涡流热成像技术在无损检测中的应用[J]. *化工自动化及仪表*, 2019, **46**(9): 690-696.
- BI Ye, XIONG Xin, YE Bo, et al. Application of eddy current thermal imaging technology based on deep learning in nondestructive testing[J]. *Chemical Automation and Instrumentation*, 2019, **46**(9): 690-696.
- [6] GAO B, LI X, WOO W L, et al. Quantitative validation of eddy current stimulated thermal features on surface crack[J]. *Ndt & E International*, 2017, **85**: 1-12.
- [7] 孙吉伟, 孙浩, 谢敏, 等. 涡流脉冲热像技术中基于神经网络的检出/漏检预测研究[J]. *红外技术*, 2020, **42**(8): 795-800.
- SUN Jiwei, SUN Hao, XIE Min, et al. Prediction of detection detection based on neural network in eddy current pulse thermography[J]. *Infrared Technology*, 2020, **42**(8): 795-800.
- [8] 刘建伟, 宋志妍. 循环神经网络研究综述[J]. *控制与决策*, 2022, **37**(11): 16.
- LIU Wei, SONG Zhiyan. Review of recurrent Neural networks[J]. *Control and Decision Making*, 2022, **37**(11): 16.
- [9] YU Y, SI X, HU C, et al. A review of recurrent neural networks: LSTM cells and network architectures[J]. *Neural Computation*, 2019, **31**(7): 1235-1270.
- [10] Crisóstomo de Castro Filho H, Abílio de Carvalho Júnior O, Ferreira de Carvalho O L, et al. Rice crop detection using LSTM, Bi-LSTM, and machine learning models from sentinel-1 time series[J]. *Remote Sensing*, 2020, **12**(16): 2655.
- [11] TIAN G, WANG Q, ZHAO Y, et al. Smart contract classification with a bi-LSTM based approach[J]. *IEEE Access*, 2020, **8**: 43806-43816.
- [12] 高玉才, 付忠广, 王诗云, 等. 基于 Bi-LSTM 和自注意力机制的旋转机械故障诊断方法研究[J]. *中国工程机械学报*, 2022, **20**(3): 273-278.
- GAO Yucai, FU Zhongguang, WANG Shiyun. Research on fault diagnosis method of rotating machinery based on Bi-LSTM and self-attention mechanism[J]. *Chinese Journal of Construction Machinery*, 2022, **20**(3): 273-278.
- [13] 温惠英, 张东冉, 陆思园. GA-LSTM模型在高速公路交通流预测中的应用[J]. *哈尔滨工业大学学报*, 2019, **51**(9): 81-87, 95.
- WEN Huiying, ZHANG Dongran, LU Siyuan. Application of GA-LSTM model in expressway traffic flow prediction[J]. *Journal of Harbin Institute of Technology*, 2019, **51**(9): 81-87, 95.
- [14] MIN Q, ZHU J, SUN J, et al. Investigation of heat source reconstruction of thickness-through fatigue crack using lock-in vibrothermography[J]. *Infrared Physics & Technology*, 2018, **94**: 291-298.
- [15] 林丽, 刘新, 朱俊臻, 等. 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[J]. *红外与激光工程*, 2022, **51**(3): 475-483.
- LIN Li, LIU Xin, ZU Junzhen, et al. Research on detection and identification of metal fatigue crack by ultrasonic infrared thermography based on CNN[J]. *Infrared and Laser Engineering*, 2022, **51**(3): 475-483.
- [16] 纪盟盟, 肖金壮, 李瑞鹏. CNN 联合 BI-LSTM 混合模型的手势识别算法[J]. *激光杂志*, 2021, **42**(6): 88-91.
- Ji Mengmeng, XIAO Jinzhuang, LI Ruipeng. Gesture recognition algorithm based on CNN combined with BI-LSTM hybrid model[J]. *Laser Magazine*, 2021, **42**(6): 88-91.
- [17] 于洋, 马军, 王晓东, 等. 融合深度可分离小卷积核和 CBAM 的改进 CNN 故障诊断模型[J]. *电子测量技术*, 2022, **45**(6): 171-178.
- YU Yang, MA Jun, WANG Xiaodong, et al. Improved CNN fault diagnosis model by fusing deep separable small convolution kernel and CBAM[J]. *Electronic Measurement Technique*, 2022, **45**(6): 171-178.
- [18] GAO Hongbin, ZHANG Ya, LV Wenkai, et al. A deep convolutional generative adversarial networks-based method for defect detection in small sample industrial parts images[J]. *Applied Sciences*, 2022, **12**(13): 6569.
- [19] JIAO J, ZHAO M, LIN J, et al. A multivariate encoder information based convolutional neural network for intelligent fault diagnosis of planetary gearboxes[J]. *Knowledge-Based Systems*, 2018, **160**: 237-250.
- [20] 刘杰, 丁武学, 孙宇, 等. 基于 SVM 的搅拌摩擦焊表面缺陷分类[J]. *组合机床与自动化加工技术*, 2022(3): 130-133, 137.
- LIU Jie, DING Xuewu, SUN Yu, et al. Surface defect classification of friction stir welding based on SVM[J]. *Modular Machine Tools and Automatic Processing Technology*. 2022(3): 130-133, 137.
- [21] GUO J, WANG X. Image classification based on SURF and KNN[C]//*IEEE/ACIS 18th International Conference on Computer and Information Science (ICIS)*, 2019: 356-359.
- [22] MA J, RAO J, QIAO Y, et al. Sprouting potato recognition based on deep neural network GoogLeNet[C]//*IEEE 3rd International Conference on Cloud Computing and Internet of Things (CCIoT)*, 2018: 502-505.
- [23] DUAN C, YIN P, ZHI Y, et al. Image classification of fashion-MNIST data set based on VGG network[C]//*Proceedings of 2019 2nd International Conference on Information Science and Electronic Technology (ISET)*. *International Informatization and Engineering Associations: Computer Science and Electronic Technology International Society*, 2019: 19.
- [24] Mahajan A, Chaudhary S. Categorical image classification based on representational deep network (RESNET)[C]//*2019 3rd International conference on Electronics, Communication and Aerospace Technology (ICECA)*, 2019: 327-330.