

# 基于柔性薄膜阵列压力传感器的抱闸故障诊断<sup>①</sup>

皮 瑶<sup>②</sup> 刘惠康<sup>③</sup> 李 倩

(武汉科技大学教育部冶金自动化与检测技术工程研究中心 武汉 430081)

**摘 要** 抱闸制动装置广泛应用于工业提升装置、民用曳引式电梯,针对抱闸制动器的运行状态监测和故障诊断,本文提出一种基于柔性薄膜阵列压力传感器的故障诊断方法,运用卷积神经网络(CNN)对传感器的数据进行处理达到故障诊断的目的。本文在 LeNet\_5 模型的基础上引入跨连接部分,将网络结构中提取的低层次特征与高层次特征相结合,经过全连接层达到多分类的目的。通过训练来自柔性薄膜阵列压力传感器的实验数据,该模型实现了 4 种基本抱闸故障和正常状态的自动识别。实验结果表明,改进的 LeNet 卷积神经网络模型在抱闸故障诊断上的检测正确率达到 99.19%,该模型在同一训练数据集上的表现明显优于传统的 LeNet\_5 模型。

**关键词** 柔性薄膜阵列压力传感器; LeNet 模型; 跨连接; 抱闸制动器; 故障诊断

## 0 引言

抱闸装置作为工业桥式吊车、民用电梯的安全保障,其运行的安全性和可靠性一直是备受关注的焦点。对制动器工作状态进行在线监测,进而对制动器由于摩擦性能劣化引发的各种故障进行诊断与预报,是从根本上避免制动事故发生的一种有效技术手段<sup>[1]</sup>。工业上吊运设备作业过程以吊运炽热液态金属为主<sup>[2]</sup>,如果抱闸装置出现失灵、制动力不足时,可能导致铁水罐、钢水罐坠落,将会产生极其严重的后果,甚至造成人员伤亡。

传统的机械故障诊断主要包括传感器信号采集、特征提取与选择、故障分类 3 个阶段<sup>[3]</sup>。关于制动器的安全性能检测,文献[4]提出一种检验制动器状况的方法,给曳引轮施加一个固定转矩,如果在制动器工作时能保持静止,制动器正常;如果曳引轮发生运动,则说明制动力不足。文献[5]建立了工况条件下的制动器动力学模型,提出了制动器性

能检测的新方法,并设计了性能测试样机,建立了样机中加载电极的数学模型和基于能量补偿方法的加载算法。文献[6]研发了制动器在线检测系统,通过实时检测制动器的闸瓦间隙、闸瓦摩擦系数、电磁线圈绕组的温度等参数,来检测制动器的性能。目前国内关于制动器状态监测、故障诊断技术的研究还处于初级的固定周期检查和事后人工维修阶段。

深度学习在分类任务上具有出色的表现,为故障诊断技术的研究提供了新思路<sup>[7]</sup>。复杂系统的故障诊断技术对于高阶、非线性、自适应特征提取有要求,而深度学习的优势就是特征表示学习能力,智能的故障诊断会让设备更加高效、安全<sup>[8]</sup>。文献[9]对 C4.5 决策树算法进行了改进,增加了 Kendall 一致性系数,从而得到了能对矿机提升机制动器进行故障诊断的算法模型。文献[10]提出将树贝叶斯网络(Bayesian network)用于制动系统的基本故障诊断。智能故障诊断技术具有快速的工业大数据处理能力和准确的分类能力,具有很好的应用前景,而传统的诊断方法需要依赖知识、诊断经验进

① 国家重点研发计划(2017YFC0805104)资助项目。

② 男,1997年生,硕士生;研究方向:故障诊断;E-mail:1242847269@qq.com

③ 通信作者,E-mail: liuhuikang@wust.edu.cn

(收稿日期:2020-08-20)

行特征提取,耗时耗力<sup>[11]</sup>。

随着现代制造系统的发展,低成本的传感器被广泛部署并与互联网相连接,基于数据驱动的状态监测与故障诊断技术越来越受欢迎,相信在大机器数据时代,深度学习将会对机器健康监测产生越来越有前景的影响<sup>[12]</sup>。本文将柔性薄膜阵列压力传感器用于抱闸制动器故障诊断,提出利用改进的LeNet模型对柔性薄膜阵列压力传感器的数据进行处理并分类从而进行基本故障类型的识别,不仅可以实时直观监测抱闸制动器闸瓦受力情况,而且在抱闸制动器的故障诊断上也取得较高的正确率。

## 1 数据获得与处理

### 1.1 抱闸制动器及传感器介绍

抱闸制动系统是熔融金属吊运作业中重要的安全保障设备,抱闸制动器(也称鼓式制动器)结构如图1所示。吊运设备制动系统状态监测与故障诊断技术,可早期发现制动系统设备故障从而达到避免事故发生的目的。柔性薄膜阵列压力传感器是实现抱闸制动器状态监测和故障诊断的重要组成部分,在应用于铸造起重机时,需适应高温、强振动、金属粉尘环境及现场安装空间限制。柔性薄膜阵列压力传感器支持多种通讯协议,性能指标满足工业级应用要求。图2是正在测试压力传感器单元的柔性薄膜阵列压力传感器,该传感器由24个电阻式薄膜压力传感器单元按4×6矩阵分布构成,左右两侧制动闸瓦均安装有该传感器,在抱闸制动器工作时,传感器的数据会通过工业以太网传递到工程师站,通过MCGS组态环境可以实时观察左右闸瓦表面受力



图1 抱闸制动器



图2 柔性薄膜阵列压力传感器

大小及力的分布情况,并且将制动器闸瓦的受力数据以4×6矩阵形式保存。

### 1.2 实验数据获得

最初实验台处于正常状态(所有部件都是全新的)。抱闸制动器常见的故障有以下4种:闸瓦表面摩擦系数降低导致滑动、制动力不足、制动力过高、闸瓦表面有异物。所以需要获取以上4种基本故障状态和正常运行状态下的闸瓦表面受力数据。实验确保每次模拟一种抱闸故障时,没有其他故障同时出现,其他设备部件处于正常状态,并在MCGS组态环境保存相应的压力矩阵数据,MCGS组态环境观测到的制动器闸瓦受力情况如图3所示,图中方格颜色代表压力的大小。

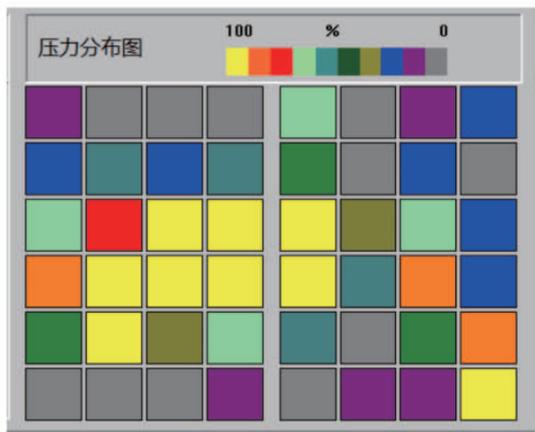


图3 制动器闸瓦受力观测图

### 1.3 数据预处理

每一次信号取样,会获得左闸瓦和右闸瓦各一组  $4 \times 6$  的压力矩阵信号,将左右闸瓦的压力信号拼接到一起获得一组  $6 \times 8$  的压力矩阵数据,再将连续 12 次信号取样的  $6 \times 8$  的压力矩阵数据拼接得到一组  $24 \times 24$  的压力矩阵数据。压力矩阵数据处理示意图如图 4 所示。

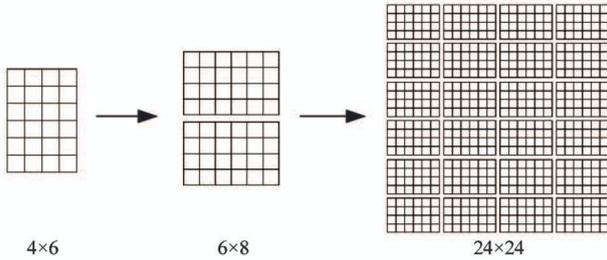


图 4 压力矩阵数据处理示意图

接着将 4 种基本故障状态和正常状态的  $24 \times 24$  压力矩阵数据转化为灰度图以供卷积神经网络模型处理,5 种实验数据的灰度图样本如图 5 所示。

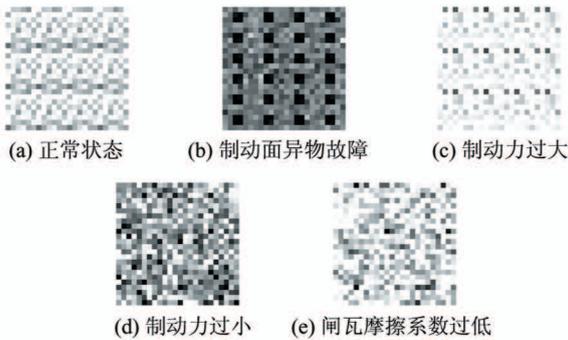


图 5 实验数据灰度图样本

## 2 引入跨连接部分的 LeNet 网络

LeNet\_5 卷积神经网络算法作为手写体数字图像识别的典型卷积神经网络(convolutional neural network, CNN),准确率高,最先被广泛用于美国银行支票手写体识别<sup>[13]</sup>,被誉为早期卷积神经网络中最有代表性的实验系统之一。与 VGG\_16、AlexNet、GoogleNet 相比,LeNet\_5 在处理低像素输入分类上更加简洁合适,LeNet\_5 模型如图 6 所示。

LeNet\_5 先将输入进行一系列的非线性变化,最终利用高层次的特征来达到分类的目的,但是这

种模型会忽视低层次的特征细节,随着训练层数的增加,梯度消失、梯度爆炸等问题更加明显。文献[14]提出了基于跨连接卷积神经网络的绝缘子检测方法,该方法检测精度达到 95%,远高于 DPM (deformable parts model) 方法,也高于 CNN、Fast R-CNN 和 Faster R-CNN 等方法。文献[15]在传统卷积神经网络的基础上,提出跨连接卷积神经网络(cross-connected convolutional neural network),在性别分类数据集中测试,该模型准确率不低于传统神经网络。文献[16]提出一种基于跨连接的特征融合神经网络(cross-connected feature fuse, CFF)模型,该模型在 REN\_VFEdb 面部表情数据库上的分类准确率达到 93.56%。文献[17]通过跨连接将底层特征细节和高层特征细节结合构造分类器,改进后的卷积神经网络在 JAFFE 表情公开库和 CK+ 数据库上取得了较好的结果,对于面部表情的识别准确率高于 LeNet\_5 模型。在跨连接思想的影响下,本文针对实验数据样本像素低的特点对经典的 LeNet\_5 模型做出如下调整。

(1)调整卷积核大小和数量。由于实验数据样本大小为  $24 \times 24$ ,将卷积核调小能更好地保留样本的特征,增加卷积核的个数可以提高网络的分类能力,本文对传统的 LeNet\_5 模型在卷积核方面做出的改动如下。

Layer1 是卷积层,输入大小为  $1 \times 24 \times 24$ ,用 10 个大小为  $3 \times 3$  的卷积核对输入层进行卷积运算,移动步长为 1,输出大小为  $10 \times 22 \times 22$ 。

Layer2 是池化层,采用尺寸大小为  $2 \times 2$  的最大池化,输出大小为  $10 \times 11 \times 11$ 。

Layer3 是卷积层,用 20 个大小为  $3 \times 3$  的卷积核对输入层进行卷积运算,移动步长为 1,输出大小为  $20 \times 9 \times 9$ 。

Layer4 是池化层,采用尺寸大小为  $3 \times 3$  的最大池化,输出大小为  $20 \times 3 \times 3$ 。

Layer5 是卷积层,用 120 个大小为  $3 \times 3$  的卷积核对输入层进行卷积运算,移动步长为 1,输出大小为  $120 \times 1 \times 1$ 。

Layer6 是全连接层,与 Layer2、Layer3、Layer5 连接,有 1440 个单元。

Layer7 是全连接层,由于 Layer6 有 1440 个单元,而 Output 输出层只有 5 个单元,所以为了更好地提取分布式特征,添加 Layer7 全连接层,共有 500 个单元。

Output 输出层,有 5 个单元。

(2) 引入跨连接部分。经典的 LeNet\_5 模型在手写字体识别上取得了很大的成功,但是应用于不同的数据集时,卷积神经网络结构需要做相应的调

整才能提取到更好的数据特征,从而获得满意的识别准确率。传统的 LeNet\_5 模型如果结构不做改变,在处理制动器压力矩阵数据时难以得到理想的结果,本文在 LeNet\_5 模型基础上引入跨连接部分,将 Layer2、Layer3 的输出直接添加到 Layer6,实现低层特征细节与高层特征细节的融合,利用融合的特征细节来达到分类的目的,改进的 LeNet 模型如图 7 所示。

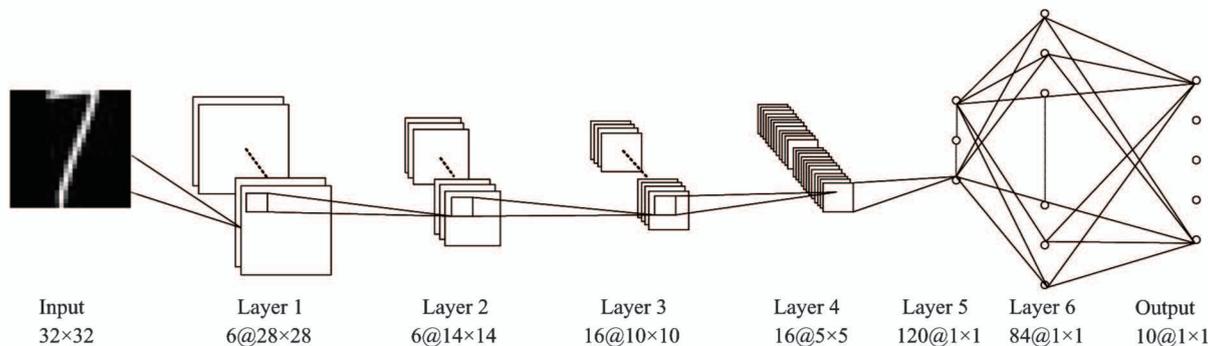


图 6 LeNet\_5 模型

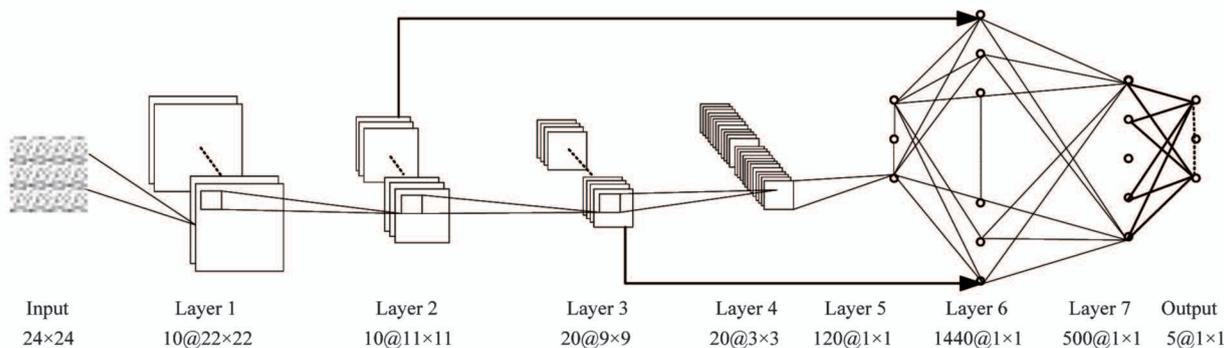


图 7 本文方法——改进的 LeNet 模型

整个卷积神经网络主要分为前向计算过程和反向传播权值更新过程,算法流程图如图 8 所示。前向传播主要是通过卷积、池化等操作提取输入的特征,关于整个网络的前向传播的计算过程如下。

### (1) 卷积层

输入特征图与卷积核进行卷积,再通过 Relu 激活函数,就可以得到输出特征图,计算公式如式(1)所示。

$$x_j^l = f\left(\sum_{i \in M_j} x_i^{l-1} \times k_{ij}^l + b_j^l\right) \quad (1)$$

其中,  $x_i^{l-1}$  代表前一层特征输出图,  $k_{ij}^l$  代表卷积核,  $M_j$  代表第  $j$  个输入特征图,  $b_j^l$  代表卷积特征图的偏

置,本文  $f(\cdot)$  代表 Relu 激活函数,  $x_j^l$  代表  $l$  层第  $j$  个特征输出图。

### (2) 下采样层

本文采用最大池化,是一种非线性下采样,输入图像下采样的结果就是下采样层,有  $N$  个输入图像,下采样之后就有  $N$  个输出图像,具体计算公式如下:

$$x_j^l = f(\beta_i^l \text{down}(x_i^{l-1}) + b_i^l) \quad (2)$$

其中,  $\beta$  代表下采样的权重系数,  $\text{down}(\cdot)$  代表下采样函数,  $f(\cdot)$ 、 $x_i^{l-1}$ 、 $b_j^l$  含义与式(1)相同。

### (3) 全连接层

全连接需要提前将输入的二维特征图转换为一维的特征图再输入,然后将一维特征图加权求和,计算公式为

$$x_j^l = f(\omega^l x^{l-1} + b^l) \tag{3}$$

式中  $\omega^l$  代表全连接层的权重系数,  $b^l$  代表全连接层的偏置,  $f(\cdot)$ 、 $x_i^{l-1}$  含义与式(1)相同。

反向传播过程主要计算输出与正确值的误差,通过传递误差大小来改变神经网络中的权值大小,从而进一步改善模型的识别能力。

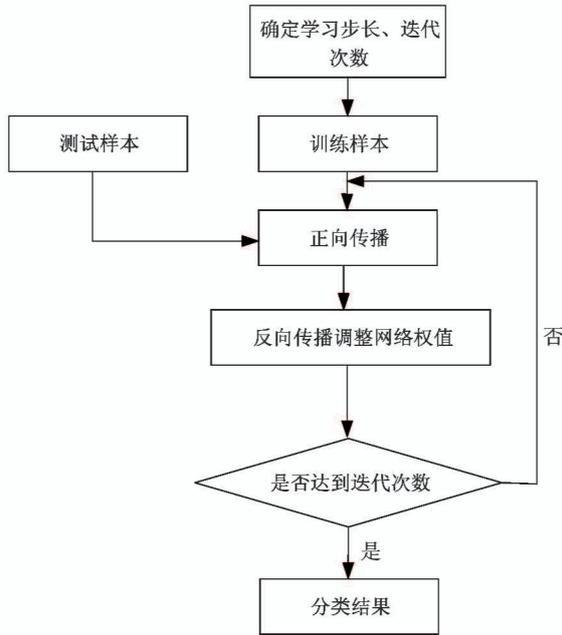


图8 算法流程图

### 3 实验与结果分析

实验数据集由 1600 组抱闸制动器压力矩阵数据组成,每组数据包含闸瓦表面摩擦系数较低、制动力不足、制动力过高、闸瓦表面有异物及正常状态 5 种制动器运行状态的灰度图,所以实验数据集有共 8000 张灰度图。随机选取 75% 的实验数据集作为训练集,剩下的作为测试集。实验结果的准确率取平均值。所有实验均在 Python 3.6 (pytorch)-cuda 上完成,硬件平台为 XiaoXin Air15IKBR, Intel(R) Core(TM) i7-8550U CPU,内存为 8.00 GB。

#### 3.1 模型参数设置

样本训练集由 1200 组图像分辨率为  $24 \times 24$  的灰度图组成,每一组样本包含抱闸制动器 5 种工作

状态的灰度图。batch\_size 选取 64, epoch 选取 20, 详细参数设置如表 1 所示。文献[18]发现使用 ReLU 激活函数的收敛速度会比 sigmoid/tanh 快很多,所以本文选择采用 ReLU 激活函数。使用卷积神经网络,尤其是使用卷积神经网络处理分类任务时, CrossEntropy 损失函数相比于均方差损失函数取得了更好的效果<sup>[19]</sup>,因此本文选择 CrossEntropy 损失函数。Adam 优化函数作为随机梯度下降函数的扩展,具有计算效率高、需要内存小的优点<sup>[20]</sup>,广泛应用于深度学习网络中,故本文选择 Adam 优化函数。

表1 本文方法参数设置表

层数	种类	特征图个数	卷积核大小
1	Layer1 卷积层	10	$3 \times 3$
2	Layer2 池化层	10	$2 \times 2$
3	Layer3 卷积层	20	$3 \times 3$
4	Layer4 池化层	20	$3 \times 3$
5	Layer5 卷积层	120	$3 \times 3$
	激活函数		Relu
	损失函数		CrossEntropy
	优化函数		Adam

#### 3.2 本文方法与 LeNet\_5 模型检测结果对比

首先采用经典 LeNet\_5 模型对训练集进行训练,训练的准确率曲线如图 9 所示,当 LeNet\_5 模型稳定后,准确率在 89% 左右浮动,且浮动的范围较大;采用本文方法也就是改进后的 LeNet 模型训练的准确率曲线如图 10 所示,当本文方法稳定之后,准确率在 99% 左右浮动,且浮动的范围比 LeNet\_5 模型小,无论是在准确率还是稳定性上,本文方法都要优于 LeNet\_5 模型。

卷积神经网络没有一种解决多种问题的通用模式,针对不同的问题需要将卷积神经网络的结构根据数据集的特点、分类任务的特点进行调整,这也是本文的意义所在。传统的 LeNet\_5 模型已经成为经典,但是直接应用于不同的应用场景并不能一直获得理想的成绩,本文在 LeNet\_5 模型的基础上添加了跨连接部分,改进后的模型准确率提升 10% 左右,而且更稳定。

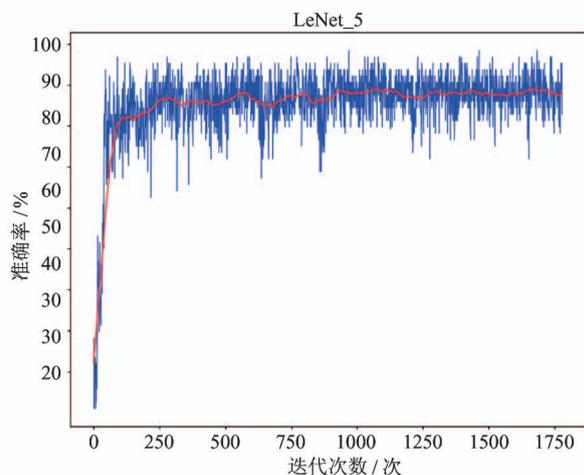


图9 LeNet\_5 模型检测结果

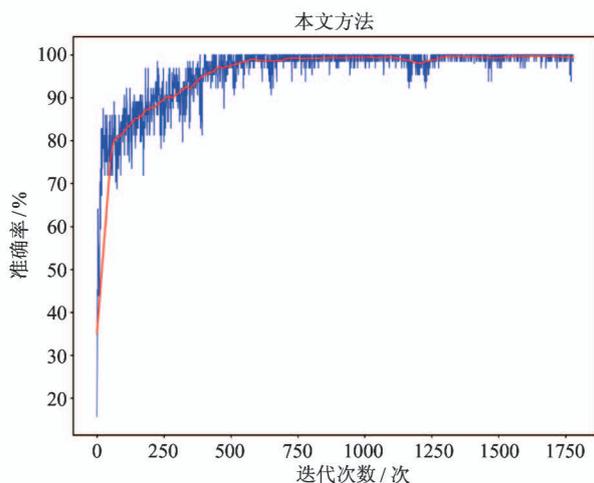


图10 本方法检测结果

### 3.3 不同方法检测结果对比

实现模式识别的常用方法有很多,其中具有代表性的有 LeNet\_5 模型<sup>[21]</sup>、CNN、主成分分析方法 (principal component analysis, PCA) + softmax 分类器<sup>[22]</sup>和方向梯度直方图的特征提取 (histogram of oriented gradient, HOG) + softmax 分类器<sup>[23]</sup>。将本文方法与以上方法进行平均正确率测试,证明本文方法的有效性和稳定性。本文方法及以上方法的平均准确率如表 2 所示,所有数据均采用准确率均值  $\pm$  标准差的形式。

将不同种常见的检测方法对比可知,本文方法在实现抱闸制动器故障诊断上平均准确率最高,高达 99.19%,准确率的标准差也只有 0.32,可见本文方法的可靠性和稳定性较好。

表2 不同检测方法准确率比较

检测方法	平均准确率/%
本文方法	99.19 $\pm$ 0.32
LeNet_5	88.62 $\pm$ 1.93
CNN	88.07 $\pm$ 1.42
PCA + softmax	72.45 $\pm$ 9.16
HOG + softmax	81.05 $\pm$ 0.05

PCA 是一种使用最广泛的数据降维算法,其主要思想是将  $n$  维特征映射到  $k$  维上,这  $k$  维是全新的正交特征也被称为主成分,是在原有  $n$  维特征的基础上重新构造出来的  $k$  维特征<sup>[24]</sup>。PCA 检测方法的第一步是中心化、标准化预处理,常见的标准化处理就是除以标准差。这种处理方法会导致一个问题,如果带有噪声的数据标准差很小,那么对于噪声数据的放大效果会很明显,相反对于没有噪声污染的数据放大效果则不明显。PCA 检测方法的主要原理是消除变量之间的相关性,并且默认变量之间的相关性是线性的,对于非线性的相关性则没有很好的检测结果,使用 PCA 检测方法进行线性降维处理后,变量之间的非线性相关性可能消失。由于 PCA 存在以上缺点,PCA 检测方法在处理抱闸制动器的多点压力数据集时,准确率较低且不稳定。

HOG 即方向梯度直方图特征,是一种在计算机视觉和图像处理中用来进行物体检测的特征描述子。它通过计算和统计图像局部区域的梯度方向直方图来构成特征<sup>[25]</sup>。由于 HOG 是在图像的局部方格单元上操作,所以它对图像几何和光学的形变都能保持很好的不变性,这两种形变只会出现在更大的空间领域上。HOG 这种特征描述子生成过程冗长,导致速度慢、实时性差,由于梯度的性质,该描述子对噪点相当敏感。由于 HOG 检测方法的以上特性,HOG 在处理抱闸制动器的多点压力数据集时,速度较慢,准确率也只有 81% 左右,不过准确率的波动很小。

此实验表明了改进型卷积神经网络具有良好的性能,能很好地运用于抱闸制动器故障诊断领域。

## 4 结论

卷积神经网络 (CNN) 能够自动地学习特征,并

且通过反向传播来提高识别的准确率,也可以通过调整结构来防止过拟合和欠拟合。随着用于卷积神经网络训练的样本数量的增加,网络模型可以找到的特征越好,能够达到的识别准确率越高。如果数据集的样本数很小,那么卷积神经网络的优势就没有了,丰富可靠的数据集对于卷积神经网络的训练极为重要。本文在传统经典 LeNet-5 网络模型的基础上,引入跨连接的方法,设计出新的卷积神经网络结构,将其应用于抱闸故障诊断。实验结果表明,相比于常用的检测方法,改进的网络模型可以获得更好的分类效果。

普遍的卷积神经网络的输入都是光学传感器收集到的图片数据,本文提出了将卷积神经网络技术用于多点压力传感器的数据处理的方法,这有助于对一些光学传感器不能收集到数据的地方进行监测和模式识别,该方法具有潜在价值。下一步研究计划将卷积神经网络与柔性薄膜阵列压力传感器的结合应用到更多领域,在光学传感器不方便采集数据的场合,继续发挥卷积神经网络的作用,服务于更多行业。

参考文献

[ 1 ] 阴妍. 盘式制动器摩擦故障融合诊断与智能预报方法研究[D]. 徐州:中国矿业大学机电工程学院,2019: 1-116

[ 2 ] 王赓. 450/80t 铸造起重机主起升机构紧急制动器安全性能检测及实际应用[D]. 大连:大连海事大学船舶电气工程学院,2012: 1-40

[ 3 ] Shao S, McAleer S, Yan R, et al. Highly accurate machine fault diagnosis using deep transfer learning [J]. *IEEE Transactions on Industrial Informatics*, 2019, 15 (4):2446-2455

[ 4 ] 阿里·亨尼南. 用于检验电梯制动器状况的方法 [P]. 中国专利,200580002149.2,2007-02-07

[ 5 ] 谢小鹏,牛高产,浦汉军,等. 电梯制动器性能检测方法的研究[J]. *中国机械工程*, 2011(22):2667-2671

[ 6 ] 巩建华. 电磁制动器实时性能检测与故障预测研究 [D]. 太原:中北大学信息与通信工程学院,2015: 1-78

[ 7 ] 余萍,曹洁. 深度学习在故障诊断与预测中的应用 [J]. *计算机工程与应用*, 2020, 56(3):1-18

[ 8 ] 文成林,吕菲亚. 基于深度学习的故障诊断方法综述 [J]. *电子与信息学报*, 2020, 42(1):234-248

[ 9 ] Jegadeeshwaran R, ugumaran V. Fault diagnosis of automobile hydraulic brake system using statistical features and support vector machines[J]. *Mechanical Systems and Signal Processing*, 2015, 52-53:436-446

[ 10 ] Wang D, Tian Y, Wang T Y, et al. Fault diagnosis of the foundation brake rigging system based on fault tree and Bayesian network [J]. *Key Engineering Materials*, 2016, 693:1734-1740

[ 11 ] Lei Y, Jia F, Lin J, et al. An intelligent fault diagnosis method using unsupervised feature learning towards mechanical big data [J]. *IEEE Transactions on Industrial Electronics*, 2016, 63(5):3137-3147

[ 12 ] Zhao R, Yan R Q, Chen Z H, et al. Deep learning and its applications to machine health monitoring [J]. *Mechanical Systems and Signal Processing*, 2019, 115: 213-237

[ 13 ] 鲍云峰. 基于异构计算系统的卷积神经网络应用研究 [D]. 武汉:湖北大学计算机与信息工程学院,2018: 1-68

[ 14 ] 左国玉,马蕾,徐长福,等. 基于跨连接卷积神经网络的绝缘子检测方法 [J]. *电力系统自动化*, 2019, 43 (5):101-106

[ 15 ] 张婷,李玉鑑,胡海鹤,等. 基于跨连卷积神经网络的性别分类模型 [J]. *自动化学报*, 2016, 42(6):858-865

[ 16 ] 黄倩露. 基于跨连特征融合网络的面部表情识别 [J]. *计算机工程与设计*, 2019, 40(10):2969-2973

[ 17 ] 李勇,林小竹,蒋梦莹. 基于跨连接 LeNet-5 网络的面部表情识别 [J]. *自动化学报*, 2018, 44(1):176-182

[ 18 ] Krizhevsky A, Sutskever I, Hinton G. ImageNet classification with deep convolutional neural networks [J]. *Advances in Neural Information Processing Systems*, 2012, 25(2):1-9

[ 19 ] McCaffrey J D. Why you should use cross-entropy error instead of classification error or mean squared error for neural network classifier training [EB/OL]. <https://jamesMccaffrey.wordpress.com>: Wordpress, 2013

[ 20 ] Kingma D, Ba J. Adam: a method for stochastic optimization [J]. *arXiv*:1412.6980v8, 2015

[ 21 ] 张倩,王建平,李帷韬. 基于反馈机制的卷积神经网络绝缘子状态检测方法 [J]. *电工技术学报*, 2019, 34

(16):3311-3321

- [22] 梁敏健,崔啸宇,宋青松,等. 基于 HOG-Gabor 特征融合与 Softmax 分类器的交通标志识别方法[J]. 交通运输工程学报, 2017, 17(3):151-158
- [23] Singh G, Chhabra I. Effective and fast face recognition system using complementary OC-LBP and HOG feature descriptors with SVM classifier[J]. *Journal of Information*

*Technology Research*, 2018,11(1): 91-110

- [24] 李琳. 基于机器学习方法的肝癌预后预测模型研究[D]. 乌鲁木齐:新疆医科大学公共卫生学院,2019: 1-45
- [25] 赵铭鑫. 社交网络图像中 LOGO 检测与识别[D]. 深圳:哈尔滨工业大学深圳研究生院,2013: 1-49

## Fault diagnosis of brake by flexible film array pressure sensor

Pi Yao, Liu Huikang, Li Qian

(Engineering Research Center of Metallurgical Automation and Measurement Technology,  
Ministry of Education, Wuhan University of Science and Technology, Wuhan 430081)

### Abstract

Brake device is widely used in industrial and civil traction elevator. Aiming at the condition monitoring and fault diagnosis of brake, a method based on flexible film array pressure sensor is proposed in this paper. Convolution neural network (CNN) is used to process the sensor data to achieve the purpose of fault diagnosis. This paper adds the cross-connected part which combines the low-level features with the high-level features to the classical LeNet\_5 convolution neural network, and achieves the goal of multi classification through the full connection layer. This method can identify four basic faults and normal condition automatically by training the experimental data of flexible film array pressure sensor. The experimental results show that the detection accuracy of the improved LeNet convolution neural network reaches 99.19%, and the performance of this model is better than that of the traditional LeNet\_5 model on the same training data set.

**Key words:** flexible film array pressure sensor, LeNet model, cross-connected, drum brake, fault diagnosis