

基于 EMD 二值化图像和 CNN 的滚动轴承故障诊断

谷玉海, 朱腾腾, 饶文军, 黄艳庭

(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 针对传统故障诊断方法识别准确率低、泛化能力差,而基于深度学习的故障诊断普遍存在需要海量训练数据的问题,提出了一种基于经验模态分解(empirical mode decomposition,简称 EMD)与卷积神经网络(convolutional neural networks,简称 CNN)的滚动轴承智能故障诊断方法。首先,对轴承振动数据进行 EMD,同时对相关系数最大的本征模函数(intrinsic mode function,简称 IMF)分量进行频谱分析,获取频谱图,并将频谱图数据压缩成特征二值化图像作为 CNN 分类网络训练的输入数据;其次,将正常状态下和各类故障状态下的滚动轴承特征二值化图像作为 CNN 的输入得到训练模型,利用训练好的模型对各类故障进行分类识别。实验结果表明:在较少的训练数据下,轴承故障诊断准确率达到 97.61%,远超过使用反向传播神经网络(back propagation,简称 BP)和概率神经网络(probabilistic neural network,简称 PNN)方法,证明了所提出方法与传统故障诊断方法相比能够更加准确地识别各类故障类别;对原始信号加入 6 dB 白噪声后的识别准确率也达到了 96.19%,证明了所提出方法具有良好的泛化能力与抗噪性能。

关键词 经验模态分解;卷积神经网络;滚动轴承;故障诊断

中图分类号 TH133.33

引言

滚动轴承是一种应用非常广泛的机械零件,同时也是机器中最容易出现故障的零件之一。如果能够及时、准确地对滚动轴承故障状态进行识别,对保持机器运转的稳定性和安全性具有重要意义。随着故障诊断理论研究的不断深入,学者们提出了各种故障诊断方法,例如:BP 神经网络^[1]、PNN^[2]、小波分析^[3]、EMD^[4]、集合经验模态分解(ensemble empirical mode decomposition,简称 EEMD)^[5]和奇异值分解(singular value decomposition,简称 SVD)^[6]等。目前,基于机器学习的故障诊断方法主要有 Logistic 回归^[7]、支持向量机(support vector machine,简称 SVM)^[8]、人工神经网络(artificial neural network,简称 ANN)^[9]和模糊推断^[10]。

随着人工智能的快速发展,深度学习在图像识别和语音识别等方面的应用日益广泛,在故障诊断领域的应用也越来越成为研究的热点^[11]。文献[12]采用随机高斯矩阵的方法对轴承信号进行变换域压缩采集,并将处理后的信号作为深度神经网络的输入实现故障的智能诊断与识别。文献[13]采用双树复小波(dual-tree complex wavelet transform,

简称 DTCWT)与深度信念网络(deep belief network,简称 DBN)结合的故障诊断方法对故障类型进行识别。

由于深度学习需要大量的训练数据,所以在没有足够数据的情况下难以取得令人满意的结果。CNN 是一种广泛应用于图像识别领域的深度学习网络方法并取得了优异效果,其初衷是对二维图片进行分类,不能直接用来识别一维振动数据。Peng 等^[14]提出了一种一维残差块,并在此基础上提出了一种新的更深层次的一维卷积神经网络(deeper one-dimensional convolutional neural network,简称 Der-1DCNN)。该框架包含了残差学习的思想,能够有效学习高层次和抽象的特征,同时缓解了训练困难和更深层次网络性能下降的问题。Levent 等^[15]提出了一种基于原始时间序列传感器数据的通用实时轴承故障诊断方法,该方法利用自适应 Der-1DCNN 分类器进行特征提取和模式识别。

如何将一维时域振动信号转换为二维矩阵或图像,是目前基于卷积神经网络的研究热点。Wen 等^[16]提出了一种基于 51 个卷积层的调整卷积神经网络(tweaked convolutional neural networks,简称

TCNN)故障诊断方法。将TCNN结合迁移学习,在数据集ImageNet上训练ResNet-50作为特征提取器进行故障诊断。实验表明,TCNN优于其他深度学习模型和传统方法。Chang等^[17]针对局部弱特征信息,提出了一种基于变分模态分解(variational mode decomposition,简称VMD),SVD和CNN的行星齿轮特征提取与故障诊断方法。实验结果表明,该方法能够有效提取局部弱特征信息,准确识别不同的故障。Sheng等^[18]提出了一种利用CNN直接对连续小波变换(continuous wavelet transform,简称CWT)进行分类的诊断方法,利用该方法在转子实验平台进行了一系列实验。结果表明,该方法能较准确地诊断故障特征。

笔者提出了一种基于EMD二值化图像和CNN的故障诊断方法,将采集到的各类滚动轴承数据转化为特征明显的二值化图像,采用CNN进行分类训练和识别。

1 EMD二值化图像构造

滚动轴承数据是由轴承加速计获得,可在短期内快速获得大量的振动数据。笔者将振动数据等距划分为若干段,对每段振动数据进行EMD,对采用相关系数筛选得到的IMF分量进行快速傅里叶变换(fast Fourier transform,简称FFT)获取频谱图,并将频谱图数据压缩成灰度图像作为CNN分类网络训练的输入数据。

1.1 EMD及IMF分量选择

EMD方法是一种自适应信号时频分析方法^[19],对于非线性和非平稳信号的处理具有独特优势,在海洋^[20]、大气^[21]及故障诊断^[4]等领域得到了广泛应用。EMD方法获得的各IMF分量包括了原始

信号不同时间尺度的局部特征,前几个IMF分量体现了原始信号的主要特征。为保证构造的二值化图像能够有效保留原始信号的故障特征,同时避免噪声等成分的干扰,笔者采用相关系数法筛选分解后的各个IMF分量,使用相关系数最大的IMF分量作为生成二值化图像的信号。相关系数的计算公式^[22]为

$$\rho(i) = \frac{\sum_{j=1}^L x(j) \text{IMF}_i(j)}{\sqrt{\sum_{j=1}^L x^2(j) \sum_{j=1}^L \text{IMF}_i^2(j)}} \quad (1)$$

其中: L 为信号长度; $\rho(i)$ 为第 i 个IMF分量与原始信号 $x(t)$ 之间的相关系数。

1.2 二值化图像构造

EMD二值化图像构造流程如图1所示。为了满足CNN的训练要求,需要生成具有一定特征的图片作为训练数据。首先,选取一段长度为 M 的振动信号进行EMD;其次,将获取的一阶IMF分量进行FFT。假设FFT后有 $2N$ 个数据点,根据FFT对称性,选取前 N 个数据点作为构造灰度图的一行。一共进行 N 次,得到 N 行数据,将 N 行长度为 N 的数据点进行堆叠,即可生成一个尺寸为 $N \times N$ 的灰度图矩阵。

为了避免图像对比度不足而对后续处理带来干扰,对生成的灰度图矩阵的每行进行归一化处理,并对整体进行二值化处理。归一化处理的公式为

$$y = \frac{x - V_{\min}}{V_{\max} - V_{\min}} \quad (2)$$

其中: x, y 分别代表归一化前、归一化后的数值; V_{\max}, V_{\min} 分别为原始灰度图像的最大值和最小值。

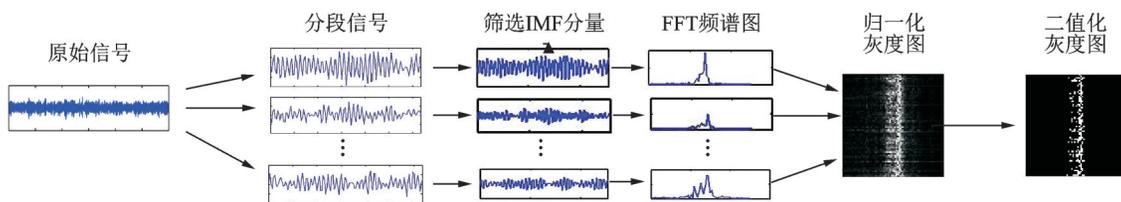


图1 EMD二值化图像构造流程

Fig.1 EMD binarization image construction process

2 CNN网络设计

为了能够有效识别轴承故障二值化图像,需要

设计合理的CNN。目前,CNN主流的设计方式,如经典的LeNet-5网络,其输入的二维图像先经过2次卷积层到池化层,再经过全连接层,使用Softmax分

类作为输出层。由于LeNet-5的网络结构设计和参数选择不适合用于本研究轴承故障二值化图像的识别,故对CNN网络结构进行简要介绍。

2.1 输入层

输入层是整个神经网络的第1层,也是整个卷积神经网络获取图像的途径,表示输入的一张图片的像素矩阵,在Lenet-5原始模型框架中,输入层的图像像素为 32×32 。

2.2 卷积层

卷积层是整个网络最重要的组成部分,用来实现对输入的图像进行特征提取,从而获得比原始图像抽象程度更高的特征。在通过卷积层处理后,网络的节点矩阵会明显加深。卷积层特征的计算公式为

$$X_i = f\left(\sum x_i^{l-1} * K_{ij}^l + b_j^l\right) \quad (3)$$

其中: $x_i^{l-1} * K_{ij}^l$ 为从第1层到 $l+1$ 层产生的特征总数; b 为偏置的数量;将得到的数据通过激活函数运算,得到第 i 层的图像 X_i 。

2.3 池化层

池化层通常出现在卷积层之后,二者相互交替出现,且每个卷积层都与一个池化层一一对应。池化函数常用的池化方法有最大池化、平均池化和随机池化等。池化层 l 中激活值 a_j^l 的计算公式为

$$a_j^l = f\left(b_j^l + \beta_j^l \text{down}(a_j^{l-1}, M_l)\right) \quad (4)$$

其中: $\text{down}(\cdot)$ 为池化函数; b_j^l 为偏置值; β_j^l 为乘数残差; M_l 为第 l 层所采用的池化像素。

笔者采用最大池化,即选取输入图像中像素为 $M_l \times M_l$ 的非重叠滑动框内所有像素的最大值。池化层的作用是对图像进行降维处理,缩减图像的像素,但会增加图像的“厚度”,目的是把更多特征从图像中提取出来。

2.4 损失函数

损失函数是用来估量模型的预测值 $f(x)$ 与真实值 Y 的不一致程度,它是一个非负实值函数,通常用 $L(Y, f(x))$ 来表示。损失函数值越小,说明模型的鲁棒性越好。笔者采用的损失函数公式为

$$L(\hat{y}, y) = -\left(y \log \hat{y} + (1 - y) \log(1 - \hat{y})\right) \quad (5)$$

其中: \hat{y} 为预测值; y 为标签值。

为使卷积神经网络损失函数 $L(\hat{y}, y)$ 取得全局最小值,实质上是不断更新权值 W 和偏差向量 b ,使其取得最优值。为防止神经网络过拟合,损失函数会增加二范数项。改进后的损失函数为

$$L(\hat{y}, y)_{\text{update}} = -L(\hat{y}, y) + \frac{\lambda}{2} W^T W \quad (6)$$

其中: λ 为超参数项。

2.5 全连接层

通过卷积和池化处理之后,图像信息被抽象成更高级的图像特征,在网络的末尾由全连接层实现网络的最终分类结果。

2.6 输出层

输出层主要用来实现最终分类,通过输出层得到输入图像属于不同类别预测的概率值。

笔者采用控制变量的方式对网络进行实验,确定最终的网络结构和参数。根据CNN设计的研究^[23]以及笔者所需要识别的图像相对简单,将卷积层在2~5层之间进行选取,卷积核主要有 3×3 、 5×5 和 7×7 共3种,典型的激活函数主要有Sigmoid, Tanh, ReLU和Leaky ReLU 4种^[24-25]。为了得到更加科学有效的网络,笔者采用排列组合的方式对以上结构参数进行研究。实验分组情况如表1所示。

表1 实验分组情况

Tab.1 Experimental grouping			
组号	卷积层数量	激活函数	卷积核
1	2/3/4/5	Tanh	3×3
2	2/3/4/5	Tanh	5×5
3	2/3/4/5	Tanh	7×7
4	2/3/4/5	ReLU	3×3
5	2/3/4/5	ReLU	5×5
6	2/3/4/5	ReLU	7×7
7	2/3/4/5	Leaky ReLU	3×3
8	2/3/4/5	Leaky ReLU	5×5
9	2/3/4/5	Leaky ReLU	7×7

3 基于EMD和CNN故障诊断框架

图2为整体技术路线流程图,数据处理步骤如下:

1) 将采集到的各种类型的时间序列数据进行等间隔划分,作为制作训练及测试数据集的原始样本数据;

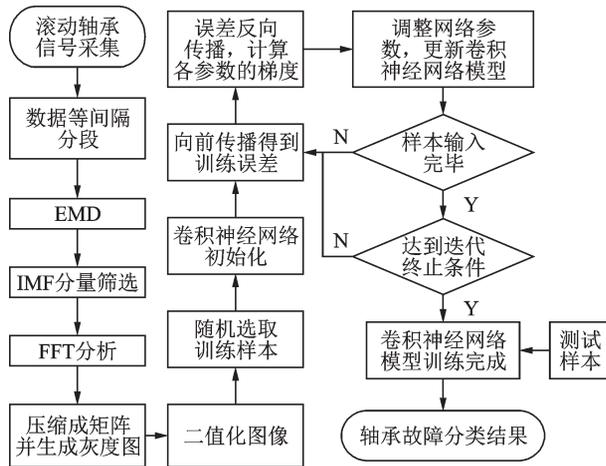


图2 笔者整体技术路线流程图

Fig.2 This article overall technical route flow chart

2) 采用 EMD 对已经划分的各段数据进行分解, 将获取的 IMF 采用相关系数进行筛选, 筛选相关系数最大的 IMF 分量, 并将 IMF 分量进行 FFT;

3) 将每次 FFT 分析后的数据值作为矩阵的一行, 不断提取数据进行处理, 累积构造矩阵;

4) 将矩阵进行归一化处理得到灰度图, 并将灰度图像转化为二值化图像, 按照以上方式将各种轴承状态的时间序列数据生成若干幅二值化图像, 作为 CNN 训练和测试的数据集;

5) 采用生成的二值化图像数据集训练卷积神经网络, 同时在训练过程中根据训练结果优化、调整网络结构和网络参数;

6) 将训练好的网络对测试数据集进行测试, 得出图片分类结果, 从而得到数据故障分类, 输出诊断结果并分析结论。

4 实验结果分析

4.1 实验数据描述

笔者使用的实验数据来源于美国凯斯西储大学轴承数据中心的轴承数据集^[26]。实验平台包含功率为 1 492 W 的电机、转矩传感器、负载电机以及其他相关元件。采用电火花加工技术在轴承上布置了单点故障, 损伤直径为 0.177 8 mm, 损伤深度为 2.794 mm。为了验证笔者所提出的方法可用于变工况下的故障诊断, 在一定程度上可以克服转速差异、故障程度大小的影响, 选取了 3 种转速、4 种故障类型、2 种故障严重程度下的故障数据, 共 12 种工况的数据混合生成 4 种类型的二值化图像数据集。轴承故障类型和实验条件如表 2 所示。

表 2 轴承故障类型和实验条件
Tab.2 Bearing failure types and test conditions

类型	电机转速/ ($r \cdot \text{min}^{-1}$)	损伤尺寸/ mm
正常	1 797	0
	1 772	0
	1 750	0
	1 730	0
内圈故障/外圈故障/滚动体故障	1 797	0.117 8 0.335 6
	1 772	0.117 8 0.335 6
	1 750	0.117 8 0.335 6
	1 730	0.117 8 0.335 6

由于采用不同长度的振动信号生成的二值化图像像素不同, 所体现出的特征效果也不同, 所以需要经过实验确定图像像素。笔者分别采用长度为 32, 64, 128 和 256 共 4 种情况下的振动信号生成的二值化图像进行对比, 将特征效果最明显的二值化图像像素点数量作为网络训练和测试的最终像素点数目。根据二值化图像构造方法, 长度为 32, 64, 128 和 256 的信号分别可以构造出像素为 16×16 , 32×32 , 64×64 和 128×128 的二值化图像, 分别使用正常状态、外圈故障、内圈故障和滚动体故障的数据进行实验。 16×16 , 32×32 这 2 种像素的二值化图像由于像素点太少, 图像特征非常不明显, 完全无法区分 4 类状态。像素为 64×64 , 128×128 这 2 种二值化图像都能较好地地区分 4 种状态。由于构造一张像素为 16×16 的二值化图像需要 8 192 个原始振动信号数据点, 而构造一张像素为 128×128 的二值化图像则需要 32 768 个原始振动信号数据点, 所以在相同长度振动信号的情况下, 构造一张像素为 128×128 的二值化图像可以构造 4 张像素为 64×64 的二值化图像。在相同数量原始信号条件下, 如果能构造出更多的二值化图像数据, 则有利于 CNN 的训练和识别。因此, 虽然像素为 128×128 的二值化图像特征更加明显, 综合考虑, 笔者最终采用像素为 64×64 的二值化图像作为 CNN 训练和测试的图像像素。

像素为 64×64 的二值化图像示例如图 3 所示。可以看出, 经上述方法构造的 4 种不同状态的轴承数据的灰度图像具有明显特征。

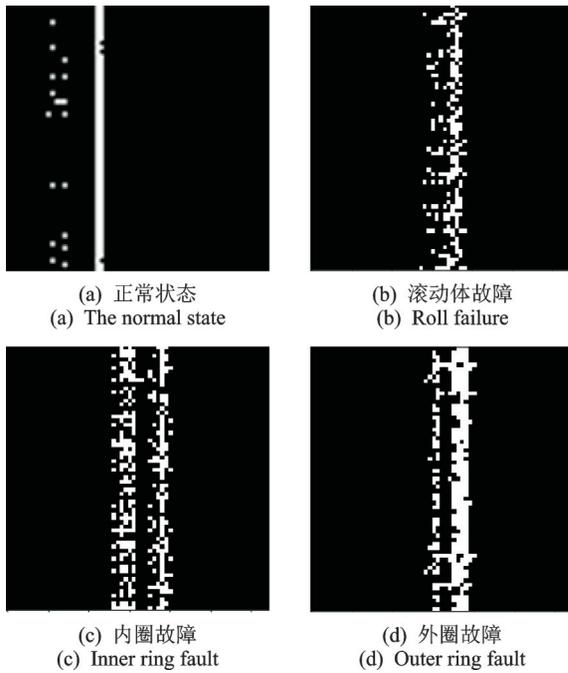


图 3 像素为 64×64 的二值化图像示例

Fig.3 Examples of binary images with 64×64 pixels

4.2 实验数据处理

笔者进行的各项实验均由 Matlab 2015b 和 Spyder 2 种软件完成。使用 Matlab 2015b 对信号进行 EMD, 筛选出相关系数最大的 IMF 分量进行 FFT, 求得时频数据并生成矩阵。导入 TensorFlow 和 OpenCV 的 Spyder 软件, 将时频数据矩阵归一化并生成最终的二值化图像, 使用 Spyder 对图片进行训练和测试, 通过 TensorBoard 可视化工具查看准确率、损失函数等曲线的变化。计算机硬件和软件的配置参数如表 3, 4 所示。

表 3 硬件配置环境参数

Tab.3 Hardware configuration environment parameters

硬件	配置参数
CPU	Intel(R) Core(TM) i5-8500@3.00GHZ
显卡	NVIDIA GeForce GTX 1080 Ti
内存	16G
固态硬盘	120G

根据表 2 所示的数据, 一共生成 4 种状态下的 433 张二值化图像。将图像进行随机分配, 训练集和测试集的分配数量如表 5 所示。

通过使用表 5 中分配的数据集对表 1 中设计的所有网络进行逐一训练、测试对比, 最终确定了输入

表 4 软件配置环境参数

Tab.4 Software configuration environment parameters

软件	配置	作用
操作系统	Windows 10	电脑操作系统
操作系统	ubuntu16.04.05(64 位)操作系统	电脑操作系统
开发平台	Matlab2015b	代码开发编译平台
开发平台	Spyder	代码开发编译平台
开发框架	TensorFlow	深度学习框架
开发框架	OpenCV	计算机视觉库
可视化平台	TensorBoard	可视化工具

表 5 训练集和测试集分配数量

Tab.5 Training set and test set allocation

序号	类型	数据集	数量	
1	正常	训练集	78	104
		测试集	26	
2	内圈故障	训练集	81	112
		测试集	31	
3	外圈故障	训练集	81	104
		测试集	23	
4	滚动体故障	训练集	88	113
		测试集	25	

图像的像素为 64×64, 卷积层为 4 层, 使用 7×7 卷积核。采用 Leak ReLU 作为激活函数的 CNN 模型, 将全连接层之后的分类输出结果调整为 4 类。笔者设计的网络模型如图 4 所示, 网络模型的训练和测试曲线如图 5 所示。

在训练中一个迭代次数是指所有的数据送入网络中完成一次前向计算及反向传播的过程。准确率反映了模型正确识别的图像个数。损失率是用来估量模型的预测值与真实值的不一致程度。准确率越大、损失率越小, 说明模型的识别能力和鲁棒性越好。从图 5 可以看出, 无论训练还是测试, 其准确率曲线的上升速度和损失曲线的下降速度都非常迅速, 经过 100 轮迭代次数后, 最终的训练准确率、训练损失率、验证准确率和验证损失率的值分别为 97.56%, 4.4736×10^{-3} , 96.69% 和 0.010 21。

4.3 与传统方法对比及抗噪性能测试

为了验证笔者提出的方法比传统故障诊断方法更能有效识别轴承的故障类别, 将此方法与参考文

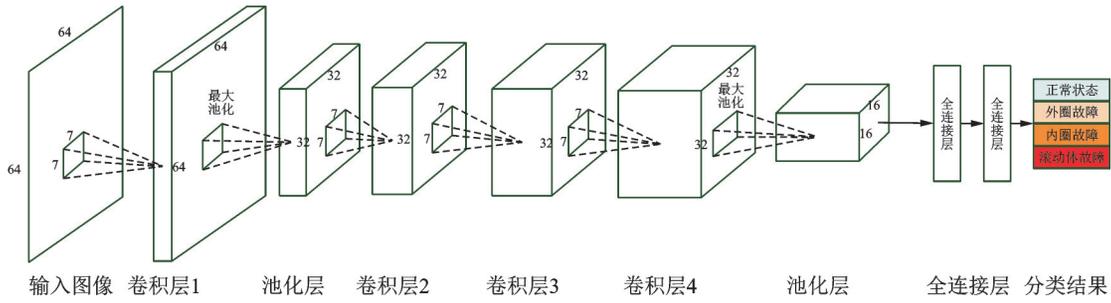


图 4 笔者设计的网络模型

Fig.4 The network model designed in this paper

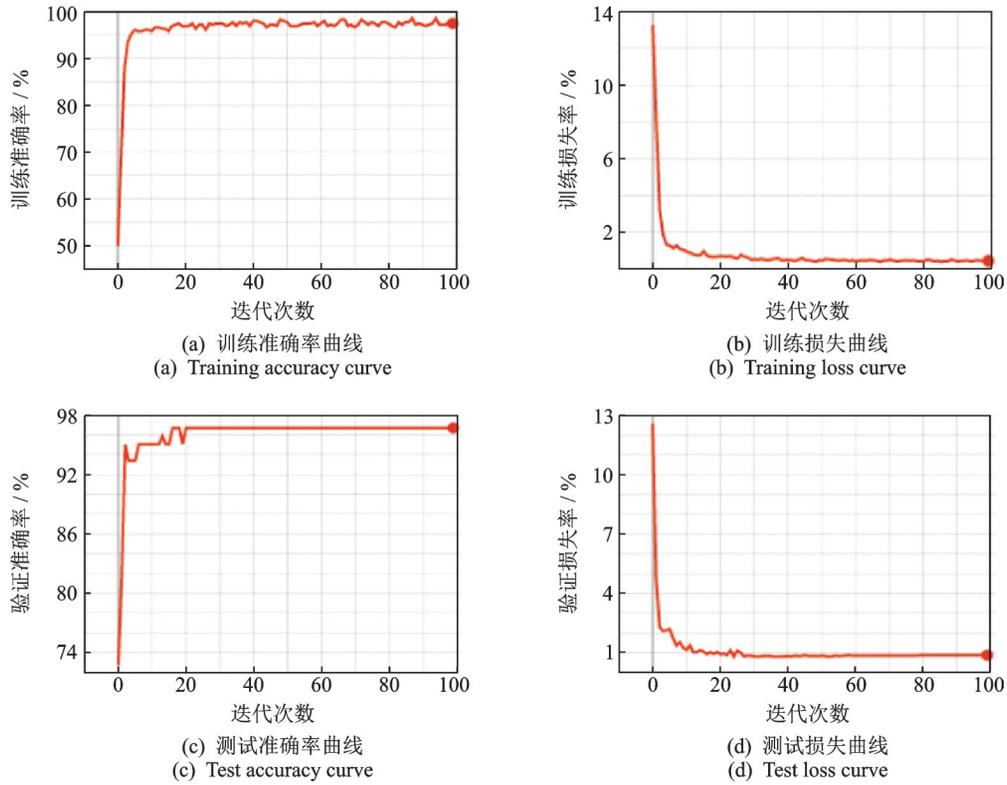


图 5 网络模型的训练和测试曲线

Fig.5 The training and testing curves of the network model are finally determined

献 [27] 中采用 BP 和概率神经网络 (probabilistic neural network, 简称 PNN) 方法的分类准确率进行对比, 如表 6 所示。

表 6 平均分类准确率对比

Tab.6 Comparison table of average classification accuracy

故障类型	方法		
	EMD 二值化 图像+CNN	BP	PNN
正常	100.00	80	100
内圈故障	96.67	70	90
外圈故障	97.78	75	90
滚动体故障	96.00	70	95
平均准确率	97.61	73.75	93.75

通过表 6 可以看出, 笔者提出的方法能够实现很高的准确率。在正常状态下, 图片的正确分类准确率最高, 为 100%, 这是由于正常状态下的滚动轴承二值化图像的特征非常明显, 容易被 CNN 分类器识别。内圈故障和滚动体故障状态下的图片相似度较高, 在识别过程中混淆相对较多, 准确率相对较低, 但也达到了 96% 以上。故障分类平均准确率达到 97.61%, 能够有效检测各类故障。笔者提出的方法识别效果都远优于传统的 BP 和 PNN 方法的准确率, 具有更好的泛化能力。

为了测试笔者所提出算法和模型的抗噪性, 在 4 种状态下的轴承振动信号中加入 6dB 的白噪声。图 6 为原始信号和加入 6dB 白噪声后的信号对比。

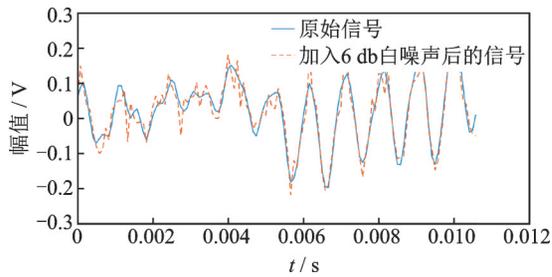
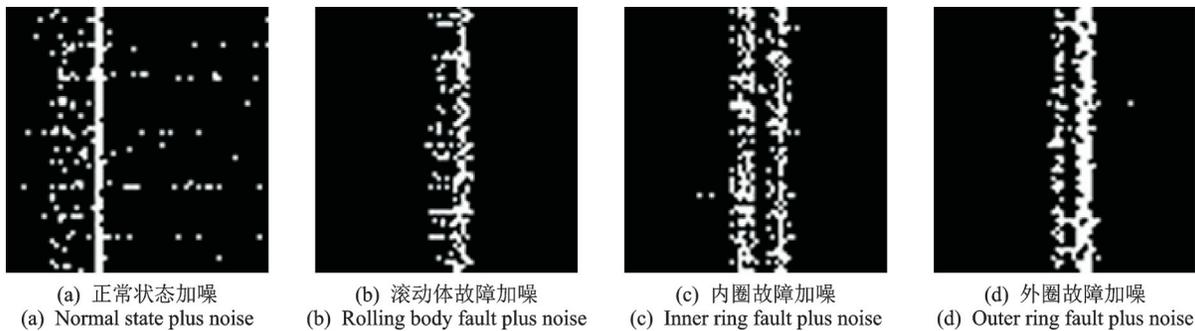


图 6 原始信号和加入 6db 白噪声后的信号对比图

Fig.6 The original signal and the signal after adding 6db white noise

可以看出,在加入白噪声后的波形出现了一些毛刺,没有原始信号显得平滑。图 7 为加噪后的二值化图像示例图。可以看出,正常状态下的轴承信号加噪

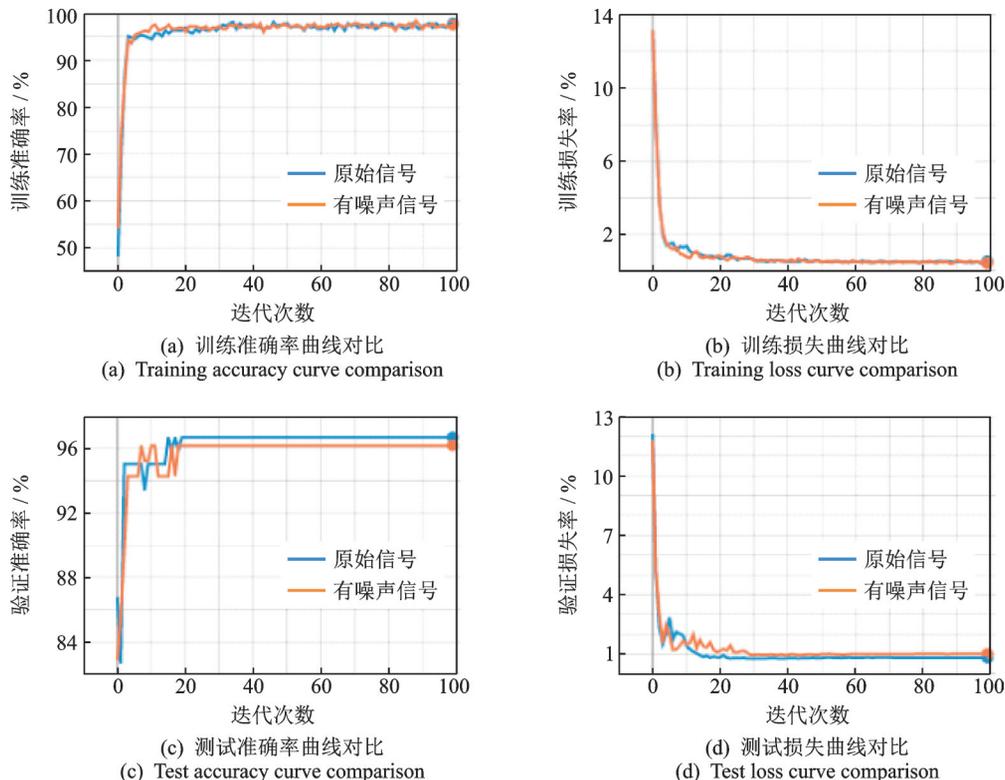
后生成的二值化图像中出现了一些噪点,但左侧的白色亮带依然很明显,未受到太大影响;其他 3 种状态下的轴承信号在加噪后几乎没有出现噪点。这也证明了笔者所提出的方法本身具有一定的抗噪能力。在抗噪性能测试中,分别在 4 种状态下的训练集和测试集中各加入 15 张加噪的图像,图 8 为加噪前后准确率和损失曲线对比。可见,2 种曲线的整体变化趋势非常接近。加噪后最终识别的准确率略有降低,测试准确率达到 96.19%,略低于未加噪的测试准确率值 97.61%,这说明加入的噪声图像对网络产生影响非常小,证明了笔者所设计的 CNN 网络模型具有很强的鲁棒性和抗噪能力。



(a) 正常状态加噪 (b) 滚动体故障加噪 (c) 内圈故障加噪 (d) 外圈故障加噪
 (a) Normal state plus noise (b) Rolling body fault plus noise (c) Inner ring fault plus noise (d) Outer ring fault plus noise

图 7 加噪后的二值化图像示例图

Fig.7 A sample image of the denoised binary image



(a) 训练准确率曲线对比
 (a) Training accuracy curve comparison

(b) 训练损失曲线对比
 (b) Training loss curve comparison

(c) 测试准确率曲线对比
 (c) Test accuracy curve comparison

(d) 测试损失曲线对比
 (d) Test loss curve comparison

图 8 加噪前后准确率和损失曲线对比

Fig.8 Comparison of accuracy and loss curves before and after noise addition

5 结束语

提出了一种基于EMD二值化图像和CNN的智能故障诊断方法,将振动信号转化为具有明显特征的二值化图像。在CNN设计方法的基础上,根据训练要求设计了36种CNN网络结构。通过实验数据集测试,确定了一种最优的CNN网络模型。笔者采用的基于EMD二值化图像和卷积神经网络的滚动轴承故障诊断方法整体上能够达到97.61%的识别准确率,远超过传统的BP方法的识别准确率73.75%和概率神经网络方法的识别准确率93.75%,在抗噪能力测试中达到了96.19%的识别准确率,体现了优异的抗噪能力和鲁棒性,证明了笔者所提出方法的可行性,为采用CNN进行故障诊断提供了新的思路,具有较好的技术应用前景。

参 考 文 献

- [1] 冯玉芳,卢厚清,殷宏,等.基于BP神经网络的故障诊断模型研究[J].计算机工程与应用,2019,55(6):24-30.
FENG Yufang, LU Houqing, YIN Hong, et al. Study on fault diagnosis model based on BP neural network [J]. Computer Engineering and Applications, 2019, 55(6): 24-30. (in Chinese)
- [2] 李文业,杨帆,周亚星,等.基于改进EMD与PNN的汽轮机通流部分故障诊断[J].振动、测试与诊断,2018,38(6):1138-1142.
LI Wenyue, YANG Fan, ZHOU Yaxing, et al. Research on fault diagnosis of steam turbine flow passage based on improved EMD and PNN[J]. Journal of Vibration, Measurement & Diagnosis, 2018, 38(6): 1138-1142. (in Chinese)
- [3] NIKOLAOU N G, ANTONIADIS L A. Rolling element bearing fault diagnosis using wavelet packets [J]. NDT & E International, 2002, 35(3):197-205.
- [4] 向丹,岑健.基于EMD熵特征融合的滚动轴承故障诊断方法[J].航空动力学报,2015,30(5):1149-1155.
XIANG Dan, CEN Jian. Method of roller bearing fault diagnosis based on feature of EMD entropy [J]. Journal of Aerospace Power, 2015, 30(5):1149-1155. (in Chinese)
- [5] LU C Q, WANG S P, MAKIS V. Fault severity recognition of aviation piston pump based on feature extraction of EEMD paving and optimized support vector regression model [J]. Aerospace Science and Technology, 2017,67(8):105-117.
- [6] 冯波.基于SVD-PE的高速列车滚动轴承故障诊断模型[J].组合机床与自动化加工技术,2018(7):108-110,114.
FENG Bo. Fault diagnosis of rolling bearing of high speed train based on SVD-PE [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2018(7): 108-110, 114. (in Chinese)
- [7] 钟鑫.基于逻辑回归和高斯混合模型的设备故障诊断技术研究与应用[D].北京:北京化工大学,2010.
- [8] WANG D, PETER W T, GUO W, et al. Support vector data description for fusion of multiple health indicators for enhancing gearbox fault diagnosis and prognosis [J]. Measurement Science and Technology, 2010, 22(2): 025102.
- [9] SHEN C, WANG D, KONG F, et al. Fault diagnosis of rotating machinery based on the statistical parameters of wavelet packet paving and a generic support vector regressive classifier [J]. Measurement Journal of the International Measurement Confederation, 2013, 46(4): 1551-1564.
- [10] WIDODO A, YANG B S. Support vector machine in machine condition monitoring and fault diagnosis [J]. Mechanical Systems and Signal Processing, 2007, 21(6): 2560-2574.
- [11] LE C Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521(7553): 436.
- [12] 温江涛,闫常弘,孙洁娣,等.基于压缩采集与深度学习的轴承故障诊断方法[J].仪器仪表学报,2018,39(1):171-179.
WEN Jiangtao, YAN Changhong, SUN Jiedi, et al. Bearing fault diagnosis method based on compressed acquisition and deep learning [J]. Chinese Journal of Scientific Instrument, 2018, 39(1):171-179. (in Chinese)
- [13] 张淑清,胡永涛,姜安琦,等.基于双树复小波和深度信念网络的轴承故障诊断[J].中国机械工程,2017,28(5):532-536,543.
ZHANG Shuqing, HU Yongtao, JIANG Anqi, et al. Bearing fault diagnosis based on DTCWT and DBN [J]. China Mechanical Engineering, 2017, 28(5): 532-536, 543. (in Chinese)
- [14] PENG D, LIU Z, WANG H, et al. A novel deeper one-dimensional CNN with residual learning for fault diagnosis of wheelset bearings in high-speed trains [J]. IEEE Access, 2018, 7(12):10278-10293.
- [15] LEVENT E, TURKER I, SERKAN K. A generic intelligent bearing fault diagnosis system using compact adaptive 1D CNN classifier [J]. Journal of Signal Processing Systems, 2018,91(2):179-189.
- [16] WEN L, LI X, GAO L. A transfer convolutional neural network for fault diagnosis based on ResNet-50

- [J]. *Neural Computing and Applications*, 2019, 32 (11):6111-6124.
- [17] CHANG L, GANG C, XIHUI C, et al. Planetary gears feature extraction and fault diagnosis method based on VMD and CNN[J]. *Sensors*, 2018, 18(5): 1523.
- [18] SHENG G, TAO Y, WEI G, et al. A novel fault diagnosis method for rotating machinery based on a convolutional neural network [J]. *Sensors*, 2018, 18 (5):1429.
- [19] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. *Proceedings of The Royal Society A: Mathematical, Physical and Engineering Sciences*, 1998, 454 (1971): 903-995.
- [20] 王坤,胡煜斌,郭志旭.利用 EMD 方法提高海洋重力 Eötvös 改正精度[J]. *测绘科学*, 2018(10):1-7.
WANG Kun, HU Yubin, GUO Zhikui. Using empirical mode decomposition to improve accuracy of Eötvös correction for marine gravity data[J]. *Science of Surveying and Mapping*, 2018(10):1-7. (in Chinese)
- [21] 徐栋璞,王振会,曾庆锋,等.近地面大气电场数据 EMD 方法分析[J]. *气象科技*, 2013, 41(1):170-176.
XU Dongpu, WANG Zhenhui, ZENG Qingfeng, et al. EMD based analysis of atmospheric electric field data [J]. *Journal of the Meteorological Sciences*, 2013, 41 (1): 170-176. (in Chinese)
- [22] 刘东瀛,邓艾东,刘振元,等.基于 EMD 与相关系数原理的故障声发射信号降噪研究[J]. *振动与冲击*, 2017, 36(19):71-77.
LIU Dongying, DENG Aidong, LIU Zhenyuan, et al. De-noising method for fault acoustic emission signals based on the EMD and correlation coefficient [J]. *Journal of Vibration and Shock*, 2017, 36 (19) : 71-77. (in Chinese)
- [23] HAO W, BIE R, GUO J, et al. Optimized CNN based image recognition through target region selection [J]. *Optik-International Journal for Light and Electron Optics*, 2017, 156:772-777.
- [24] LIU X, HOU F, QIN H, et al. Multi-view multi-scale CNNs for lung nodule type classification from CT images[J]. *Pattern Recognition*, 2018, 77: 262-275.
- [25] ZEILER M D, FERGUS R. Visualizing and understanding convolutional networks [J]. *Lecture Notes in Computer Science*, 2013, 8689(1):818-833.
- [26] LOPARO K A. Bearing vibration dataset, case western reserve university [EB/OL]. [2014-10-12]. http://csegroups.case.edu/bearing_dat_dat_datacenter/pages/download-data-file
- [27] 刘乐,孙虎儿,谢志谦.基于 SVD-LMD 模糊熵与 PNN 的滚动轴承故障诊断[J]. *机械传动*, 2017, 41(3): 172-176.
LIU Le, SUN Huer, XIE Zhiqian. Fault diagnosis of bearing on SVD-LMD fuzzy entropy and PNN[J]. *Journal of Mechanical Transmission*, 2017, 41 (3) : 172-176. (in Chinese)



第一作者简介:谷玉海,男,1976年5月生,博士、研究员、硕士生导师。主要研究方向为故障诊断与状态监测。曾发表《自动扫描多光栅单色仪系统研制》(《仪器仪表学报》2009年第30卷第3期)等论文。
E-mail:gyuhai@163.com

欢迎订阅《振动、测试与诊断》

《振动、测试与诊断》由工业和信息化部主管,南京航空航天大学 and 全国高校机械工程测试技术研究会联合主办,是反映振动、动态测试及故障诊断学科领域的科研成果及其应用情况的技术性刊物。主要刊登国内外以振动测试与故障诊断为中心的动态测试理论、方法和手段的研究及应用方面的技术文献,包括实验测试技术、测试仪器的研制、方法和系统组成、信号分析、数据处理、参数识别与故障诊断以及有关装置的设计、使用、控制、标定和校准等,不拘泥于行业和测试项目。

本刊为 EI Compendex 数据库收录期刊和中文核心期刊,双月刊,每逢双月末出版,每本定价 30 元,全年 180 元。欢迎订阅和投稿,欢迎在本刊刊登各类广告和科技信息。

编辑部地址:南京市御道街 29 号 邮政编码:210016 电话:(025)84893332

邮发代号:28-239 E-mail:qchen@nuaa.edu.cn 网址:<http://zdc.nuaa.edu.cn>