

文章编号:1005-0523(2020)04-0082-06

DOI:10.16749/j.cnki.jecjtu.2020.04.013

# 基于联合抗噪算法的滚动轴承故障诊断研究

刘冲

(华东交通大学电气与自动化工程学院,江西 南昌 330013)

**摘要:**轴承通常工作于复杂噪声环境下,使得时域振动信号容易受到各种噪声的污染,从而误导诊断结果。针对以上问题,提出基于一维卷积自编码(1D-DCAE)和一维卷积神经网络(1D-CNN)的联合抗噪故障诊断算法。为了模拟真实噪声环境,在原始振动信号中添加不同信噪比的高斯噪声,用1D-DCAE对原始信号降噪,再将降噪信号用于1D-CNN进行故障诊断。基于全卷积神经网络搭建1D-DCAE模型,并舍弃池化层以降低信息丢失,以提高联合诊断模型的抗噪能力。结果表明:采用基于全卷积神经网络搭建的1D-DCAE有更好的降噪效果,改进后的模型能自适应诊断各种噪声环境下的故障。

**关键词:**降噪自编码;卷积神经网络;故障诊断;抗噪诊断

中图分类号:TP165

文献标志码:A

本文引用格式:刘冲. 基于联合抗噪算法的滚动轴承故障诊断研究[J]. 华东交通大学学报,2020,37(4):82-87.

**Citation format:**LIU C. Research on joint anti-noise algorithm and its application in rolling bearing fault diagnosis[J]. Journal of East China Jiaotong University,2020,37(4):82-87.

滚动轴承广泛存在于机械设备,由于滚动轴承的工作环境恶劣且噪声情况复杂,故障尺寸微小又难以直接观察,业界普遍采用数据驱动的方式实现故障诊断,但是振动信号易受噪声污染,使得有效特征难以被提取,因此如何提高滚动轴承在复杂噪声环境下故障诊断的准确性,成为了当前研究热点。

随着计算机、传感器的迅猛发展,机械设备的状态检测进入了“大数据”时代<sup>[1]</sup>。使得故障诊断技术向深度学习方向发展。深度学习模型依靠其多个隐含层,在特征提取和分类方面的卓越表现,在故障诊断领域取得了较多研究成果。Long等<sup>[2]</sup>将原始振动信号转换为二维图像,使用LeNet-5模型对二维图像进行故障诊断。2016年Turker等<sup>[3]</sup>提出了一种含有3个改进的卷积层和2个全连接层的一维卷积神经网络,直接以原始电流信号为输入,准确率达到97.2%。Chen<sup>[4]</sup>提出了一种单卷积层和2个全连接层的二维卷积神经网络模型,并将算法应用于齿轮箱故障诊断。张西宁,向宙等<sup>[5]</sup>用堆叠卷积自编码进行轴承故障诊断,使得诊断精度从79.9%提高到92.1%。向宙等<sup>[6]</sup>用改进的区分自编码网络对不同工况下的轴承数据进行诊断,使得所提出的区分型网络的特征提取能力不受工况影响。虽然很多基于卷积神经网络的研究已经取得较好诊断效果,但仅证明了模型在使用无噪声实验数据的有效性。然而,振动信号易受噪声污染。近年来,为了提高模型的抗噪能力,一些训练技巧(如使用dropout操作<sup>[7]</sup>)和结构改进(如添加AdaBn层<sup>[8]</sup>)的方法被提出来,在图像降噪领域,Zhang等<sup>[9]</sup>提出一种基于深度卷积神经网络的非固定噪声模板图像训练方法。Mao<sup>[10]</sup>等提出了一种基于深度卷积去噪自编码的图像降噪方法。然而这些方法仅适用于二维或者三维图像的降噪。目前针对一维振动信号降噪的方法大多基于信号处理技术,如黄正平等<sup>[11]</sup>提出一种基于MED和Teager能量算子的故障诊断模型,能有效消除信号的带内噪声,但是信号处理技术过于依靠人工特征提取,费时费力。因此,本文提出一种基于全卷积网络(fully convolutional networks,FCN)<sup>[12]</sup>的一维卷积降噪自编码器(1D-convolutional denoising auto-encoder,1D-DCAE)与一维卷积神经网络(1-D convolutional neural network,1D-CNN)联合的诊断方法来解决上述问题。前者对原始信号降噪,后者对1D-DCAE输出的降噪信号进行故障诊断。

收稿日期:2019-12-16

作者简介:刘冲(1995—),男,硕士研究生,研究方向为机械故障诊断。

此外,1D-DCAE 模型了舍弃池化层以减少 1D-DCAE 在数据重构过程中造成的信息丢失,从而提升降噪能力。

## 1 卷积降噪自编码和卷积神经网络结构

### 1.1 一维卷积神经网络

卷积神经网络(convolutional neural network,CNN)是一种多模块的前馈神经网络,传统 CNN 的结构主要由特征提取模块和分类模块 2 部分组成,特征提取模块由输入层、卷积层、激活函数、池化层组成,分类模块包含全连接层和分类层。特征提取模块的作用是从数据中提取特征,分类模块实现对隐层特征的回归和分类。卷积层是 CNN 提取特征的关键,卷积层由一组滤波器组成,滤波器由多个神经元组成,神经元都只与输入层中的神经元局部连接,且每个滤波器中的神经元共享权值,这也是 CNN 能减少网络参数的根本原因。第  $k$  个滤波器的滤波操作的公式为

$$Y(k)=\sum_{x=1}^m\sum_{y=1}^n\sum_{z=1}^pX_{x,y,z}\times W_{x,y,z}^k+b^k,k=1,2,\dots,q \quad (1)$$

式中: $Y(k)$ 为第  $k$  个滤波器学到的特征图; $X$ 为输入; $x,y,z$ 为输入数据的维度; $W_{x,y,z}^k,b^k$ 为第  $k$  层的权重和偏置。

卷积层的输出经  $ReLU$  函数激活后输入池化层,池化层是下采样的过程,其作用是对卷积层学习到的特征降维,提取重要纹理特征。全连接作用是将特征提取模块学习到的分布式特征表示映射到样本标记,起到分类器的作用,但由于其庞大的参数量可能会导致网络陷入拟合,大量的参数也会大量增加训练时间,影响算法的时效性。针对以上的问题,1D-CNN 采用全局平均池化(global average pooling)作为分类器,全局平均池化能对特征提取模块学习到的高维特征直接降维,因其本身没有可供学习的特征,于传统的全连接层相比,全局平均池化极大地减少了网络的参数。

联合诊断模型基于 1D-CNN 来诊断滚动轴承故障,1D-CNN 的模型和参数如图 1 所示,模型由 3 个卷积层、2 个最大池化层、1 个全局平均池化层组成,在特征学习方面采用卷积层和池化层交替来实现,分类器选用的是全局平均池化层而不是传统的全连接层。其中,20@32 表示该层使用 32 个长度为 20 的卷积核进行卷积运算,模型的卷积核和池化核均为一维结构,以适应一维振动信号。




图 1 1D-CNN 结构  
Fig.1 Structure of 1D-DCAE

### 1.2 一维卷积降噪自编码

传统的自编码器(auto encoder,AE)由编码器和解码器两部分组成,编码器经非线性映射对输入  $X$  降维,得到隐藏层表示  $Z$ ,解码器由另一个非线性变换将隐藏表示  $Z$  映射回重构数据

$$Z=f(WZ+b) \quad (2)$$

$$\hat{X}=f(\hat{W}Z+\hat{b}) \quad (3)$$

式中: $W,b,\hat{W}$ 和 $\hat{b}$ 分别表示编码器和解码器的权重和偏置, $f$ 和 $g$ 为激活函数。AE 通过优化网络参数  $\theta=(W,b,\hat{W},\hat{b})$ 使得输入  $X$  与输出 $\hat{X}$ 的重构误差最小,通常采用均方误差函数(MSE)作为重构误差的损失函数

$$L(\theta)=\sum_i\|X-\hat{X}\|^2 \quad (4)$$

降噪自编码器(denoising auto-encoder,DAE)由 Vincent 等<sup>[13]</sup>提出。DAE 的大致思想为:原始输入  $X$  被随机映射 $\tilde{X}\sim q(\tilde{X}|X)$ 破坏为 $\tilde{X}$ ,DAE 再将损坏的 $\tilde{X}$ 作为输入数据,映射到相应的隐藏表示  $Z$ 和最终的重构目标 $\tilde{X}$ ,

通过不断训练使得输出 $\hat{X}$ 与原始输入 $X$ 之间的重构误差最小。DAE将含噪的样本重构为干净的样本,并不是简单的复制输入,消除损坏样本的过程可视为降噪。

传统的DAE是基于全连接网络的,但是全连网络参数过多,网络容易陷入过拟合。针对该问题,本文提出一种基于FCN的1D-DCAE模型。FCN是一种特殊类型的卷积神经网络,FCN和CNN两者之间的区别是FCN移除了全连接层,与基于全连接层的DAE相比,FCN主要优势有两点:移除全连接层能减少参数数量和网络过拟合风险;FCN使得每个输出特征图相互关联,能保留原始输入的局部空间信息。此外,为了让输入和输出信号精准匹配,基于FCN的1D-DCAE模型没有使用池化层,因为池化层可能会造成信息的少量细节丢失<sup>[14]</sup>。

本文使用1D-DCAE对含噪信号做降噪处理,以联合诊断模型的抗噪能力,与CNN类似,1D-DCAE也能通过增加深度来提升重构能力。图2为其结构和参数示意图,1D-DCAE同样包含解码器和编码器这一基本结构,编码器和解码器均由3个一维的卷积层组成。其去噪的主要思想是将卷积池化后的低维特征通过反卷积重构,以重构信号与原信号的重构误差作为优化目标,对卷积核和反卷积核的参数进行求解优化。




图2 1D-DCAE结构

Fig.2 Structure of 1D-DCAE

为了测试所设计模型在受到噪声干扰环境下的诊断能力,需要模拟在实际工业环境下的噪声情况,在原始信号的基础上加入了一定信噪比(signal-to-noise ratio, SNR)的高斯白噪声,考虑到实际工业环境的噪声情况是复杂多变的,输入模型的信噪比也应不同,信噪比定义为信号功率与噪声功率的比值

$$SNR=10 \lg \left( \frac{P_s}{P_n} \right) \quad (5)$$

式中: $P_s$ 为原信号功率; $P_n$ 为噪声信号功率。

### 1.3 1D-DCAE和1D-CNN的联合诊断流程

基于联合算法的诊断流程主要分为5个阶段:以1 dB为间隔,在原始数据集中分别加入 $SNR=-2 \sim 9$  dB范围的高斯白噪声,共得到11种不同的噪声信号;将得到的每种噪声分别按4:1分为训练集和测试集,将 $SNR=-2, 0, 2, 4, 6, 8$  dB环境下的6种噪声训练集混合并洗牌,用于训练1D-DCAE,所有的测试集用于测试模型性能;用混合高斯噪声的训练样本 $\tilde{x}$ 对1D-DCAE训练,完成1D-DCAE的训练后,得到降噪的训练样本 $\hat{x}$ ;将降噪后的训练样本 $\hat{x}$ 作为1D-CNN的输入,利用训练样本标签完成模型训练;将测试样本输入联合诊断模型,完成轴承故障的诊断。

## 2 实验验证

### 2.1 数据描述

实验所用滚动轴承时域振动信号来自美国西储大学轴承中心,信号采样频率为12 kHz。故障类型为内圈故障、外圈故障、滚球体故障,故障的损伤直径分别为0.18, 0.36, 0.54 mm三种程度故障,有9类故障加正常状态共计10类数据样本。本次所有实验数据均在0负载情况下采集,每0.1 s采集一次数据,每个样本长度为1 200个数据点,每类样本采集1 000个,共计10 000个样本,其中4/5的样本用于训练,其余的样本用于测试。实验使用深度学习框架Tensorflow,处理器为i7-4790@3.60 GHz,内存为8 GB硬件平台进行实验。

### 2.2 基于1D-DCAE的降噪实验

本文实验结果由两部分组成:一部分为1D-DCAE的重构误差,另一部分为1D-CNN的诊断精度,以此来验证联合抗噪算法的有效性。前者重构误差所反映的是1D-DCAE降噪效果,后者诊断精度验证了本文

算法在噪声环境下的诊断效果。

1D-DCAE 训练参数和超参数设置如下:学习率设为 0.01, *epochs* 设为 50, *batchsize* 设为 100, DAE 的输入、隐藏层、输出维度分别设为 1 200, 600, 1 200, 激活函数为 *ELU*。为了验证池化层对 1D-DCAE 算法去噪效果的影响, 将本文提出改进的 1D-DCAE 与经典 1D-DCAE 的进行比对, 除了含有池化层之外, 其余参数与改进的 1D-DCAE 算法一致, 每组实验重复 10 次, 实验结果如表 2 所示。

表 1 在不同信噪比下 DAE 和 1D-DCAE 的重构误差  
Tab.1 Reconstruction errors of DAE and 1D-DCAE under different SNR

算法	SNR/dB					
	-1	1	3	5	7	9
DAE	0.047 3	0.040 2	0.036 7	0.034 1	0.033 1	0.032 4
改进的 1D-DCAE	0.019 9	0.015 1	0.011 4	0.009 2	0.007 0	0.005 8
经典 1D-DCAE	0.022 4	0.018 3	0.015 5	0.013 8	0.012 7	0.012 2

由以上实验结果可知, 在所有信噪比环境下, 改进的 1D-DCAE 的重构误差均小于 DAE 和标准的 1D-DCAE 算法。实验结果表明, 改进的 1D-DCAE 算法降噪效果最好, 卷积自编码模型去噪能力强于 DAE, 原因如下: 由于 1D-DCAE 的结构较深, 其特征重构能力优于 DAE; 1D-DCAE 的参数远少于 DAE。其中, 1D-DCAE 的参数数量为  $2 \times (20 \times 16 + 5 \times 32 \times 16 + 5 \times 64 \times 32) = 26\ 240$ , DAE 的参数数量为  $1\ 200 \times 600 \times 2 = 1\ 440\ 000$ , 所以 1D-DCAE 算法在噪声环境下不易过拟合。当  $SNR > 5$  dB 时, 改进的 1D-DCAE 算法的重构误差随着信噪比的增加不断减小, 而标准 1D-DCAE 的重构误差几乎没有变化, 其原因是在高信噪比环境下, 标准 1D-DCAE 造成信息丢失大于降噪得到的收益。因此, 舍弃池化层能提升对振动信号的降噪效果, 并且减少模型对输入数据的信息丢失。

图 3 为内圈中故障在  $SNR = -1$  dB 噪声环境下的原始信号, 加噪信号, 由 1D-DCAE 和 DAE 重构的降噪信号, 由信号图可看出经本文提出的 1D-DCAE 算法降噪之后的波形与原始信号波形相比, 两者基本没有形态差异, 信号噪声明显少于经 DAE 降噪的信号噪声。




图 3 信号图

Fig.3. Figures of signals

### 2.3 联合算法的故障诊断

本文使用 1D-CNN 对降噪信号进行故障诊断,1D-CNN 的训练参数和超参数设置如下: $epochs$  为 120,学习率为 0.001, $batchsize$  为 100,重复 10 次实验,1D-CNN 在不同信噪比条件下的诊断结果如图 4 和表 2 所示,在  $SNR=-1$  dB 时的诊断高达 96.2%, $SNR>1$  dB 时,诊断精度能达到 98.5%以上。因此,联合诊断方法能自适应的处理任何噪声环境,即使是较低信噪比的噪声环境下。

为了验证本文联合诊断方法的有效性,本文算法与 DCE+1D-CNN,未降噪处理+1D-CNN 进行实验结果的比对,在  $SNR=-1$  dB 噪声环境下,DCE+1D-CNN 联合诊断的方法和 1D-CNN 的诊断正确率分别下降至 93.86%和 84.55%。实验结果表明,在低信噪比环境下,本文所用的 1D-DCAE 对数据进行降噪处理,能有效的提升诊断精度。

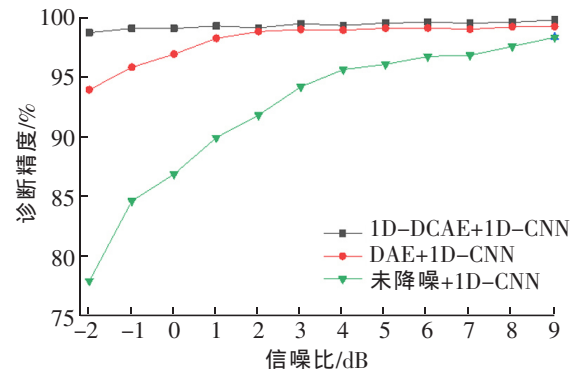


图 4 1D-CNN 在不同降噪方法下的诊断精度

Fig.4 Diagnosis accuracy of 1D-CNN with different denoising processes

表 2 1D-CNN 在不同降噪方法下的诊断精度

Tab.2 Diagnosis accuracy of 1D-CNN with different denoising processes

诊断算法	SNR/ dB					
	-1	1	3	5	7	9
1D-DCAE+1D-CNN	96.23	98.54	99.37	99.28	99.67	99.75
DAE+1D-CNN	93.86	96.85	98.73	98.85	99.03	99.14
未降噪+1D-CNN	84.55	89.85	94.10	96.00	96.75	98.20

### 2.4 特征可视化

本文为了证明 1D-CNN 在噪声环境下的特征提取能力,在  $SNR=1$  dB 的噪声环境下,采用了 t 分布随机近邻嵌入流形学习算法(T-SNE)将特征降维至 2 维,对输入层和三个卷积层进行特征可视化,其中每一种颜色表示一种故障类别,每一个点表示一个样本,可视化结果如图 5 所示,a,b,c,d 从左至右分别为输入,Conv4,Conv5,Conv6 的特征可视化结果。




图 5 t-SNE 特征学习可视化

Fig.5 Feature learning visualization with t-SNE

## 3 结论

提出一种基于 1D-DCAE 和 1D-CNN 联合抗噪诊断算法。该方法能有效解决复杂噪声环境下的故障诊断问题,提高了系统的抗噪能力。对实验结果进行分析得出以下结论:

1) 基于 FCN 的 1D-DCAE 对于轴承信号的降噪效果均优于传统 DAE 和经典 DCAE 算法,即使在  $SNR=-1$  dB 低信噪比环境下,1D-DCAE 算法的重构误差仅为 0.019,在  $SNR>5$  dB 的高信噪比环境下,重构误差小于 0.01,表明本文提出算法在舍弃池化层后,在数据重构过程几乎没有造成信息丢失。

2) 经 1D-DACE 降噪后,1D-CNN 即使在  $SNR=-1$  dB 低信噪比噪声环境下,其诊断精度达到了 96.2%, $SNR>1$  dB 时,诊断精度能达到 98.5%以上,若未作降噪处理,其诊断精度仅为 84.6%。结果表明联合诊断算法能实现对各种噪声环境下的故障精准诊断。

## 参考文献:

- [1] 雷亚国,贾峰,周昕,等. 基于深度学习理论的机械装备大数据健康监测方法[J]. 机械工程学报,2015,51(21):49-56.
- [2] WEN L,LI X,GAO L,et al. A new convolutional neural network-based data-driven fault diagnosis method[J]. IEEE Transactions on Industrial Electronics,2017,65(7):5990-5998.
- [3] INCE T,KIRANYAZ S,EREN L,et al. Real-time motor fault detection by 1-D convolutional neural networks[J]. IEEE Transactions on Industrial Electronics,2016,63(11):7067-7075.
- [4] CHEN Y,JIANG H,LI C,et al. Deep feature extraction and classification of hyperspectral images based on convolutional neural networks[J]. IEEE Transactions on Geoscience and Remote Sensing,2016,54(10):6232-6251.
- [5] 张西宁,向宙,唐春华. 一种深度卷积自编码网络及其在滚动轴承故障诊断中的应用[J]. 西安交通大学学报,2018,52(7):1-8.
- [6] 向宙,张西宁,张雯雯,等. 区分自编码网络及其在滚动轴承故障特征提取中的应用[J]. 西安交通大学学报,2019,53(8):47-55.
- [7] ZHANG W,LI C,PENG G L,et al. A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load[J]. Mechanical Systems and Signal Processing,2018,100:439-453.
- [8] ZHANG W,PENG G L,LI G H,et al. A new deep learning model for fault diagnosis with good anti-noise and domain adaptation ability on raw vibration signals[J]. Sensors,2017,17(2):425.
- [9] ZHANG F,CAI N,WU J,et al. Image denoising method based on a deep convolution neural network[J]. IET Image Processing,2017,12(4):485-493.
- [10] MAO X J,SHEN C,YANG Y B. Image restoration using very deep convolutional encoder-decoder networks with symmetric skip connections[C]//Proceedings of the 30th International Conference on Neural Information Processing Systems. Curran Associates Inc,2016:2810-2818.
- [11] 刘正平,胡俊,胡俊锋,等. 基于 MED-Teager 能量算子的滚动轴承故障诊断[J]. 华东交通大学学报,2017,34(04):97-103.
- [12] ER E,TREVOR D. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis & Machine Intelligence,2014,39(4):640-651.
- [13] VINCENT P,LOROCHELLE H,BENGIO Y,et al. Extracting and composing robust features with denoising autoencoders[C]//International Conference on Machine Learning,Helsinki,ACM,2008:1096-1103.
- [14] TAIGMAN Y,YANG M,RANZATO M,et al. Deepface:Closing the gap to human-level performance in face verification[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. IEEE Computer Society,2014:1701-1708.

## Research on Joint Anti-Noise Algorithm and Its Application in Rolling Bearing Fault Diagnosis

Liu Chong

(School of Electrical and Automation Engineering, East China Jiaotong University, Nanchang 330013, China)

**Abstract:** Bearings usually work in the complex noise environment, which makes the time-domain vibration signal easy to be polluted by various noises, thus misleading the diagnosis results. To solve this problem, a method combining a one-dimensional (1-D) denoising convolutional autoencoder (DCAE) and a (1-D) convolutional neural network (CNN) is proposed. In order to simulate the real noise environment, Gaussian noise with different signal-to-noise ratio was added to the original vibration signal. 1D-DCAE was used to denoise the original signals, and then the denoised signal was used for 1D-CNN fault diagnosis. 1D-DCAE was built based on full convolution network (FCN) and the pooling layer was discarded to improve the anti-noise capability. The results show that FCN-based 1D-DCAE has better noise reduction effect, and the improved model can adaptively diagnose faults of various noise environments.

**Key words:** denoising convolutional autoencoder (DCAE); convolutional neural network (CNN); fault diagnosis; anti-noise diagnosis