

MHSACAE-CNN 在噪声下的电机轴承故障诊断

文 斌^{1,2}, 李知聪¹, 朱 晗¹, 曹仁轩¹

(1. 三峡大学电气与新能源学院, 湖北 宜昌 443002;
2. 三峡大学新能源微电网湖北省协同创新中心, 湖北 宜昌 443002)

摘要: 电机的运行情况复杂, 实际运行工况下会有大量的噪声, 导致其轴承故障诊断精度下降。为了改善这一问题, 提出了一种基于多头自注意力机制的一维全卷积自编码网络 (One-dimensional Fully Convolutional Autoencoding Network Based on Multi-head Self-attention, MHSACAE) 与卷积神经网络 (Convolutional Neural Network, CNN) 结合的轴承故障诊断方法。该方法先采用 MHSACAE 网络进行降噪, 再通过 CNN 进行故障诊断。其中 MHSACAE 去噪网络采用无监督训练的方式, 充分考虑了实际工况和序列数据内在联系, 在实现对噪声的滤除效果的同时, 最大限度地保留下了原始的故障信息, 使得 CNN 可以实现在噪声情况下对电机轴承故障的高精度诊断。通过与其他轴承故障诊断方法在噪声情况下进行对比, 证明提出的方法具有更好的效果。

关键词: 故障诊断; 轴承; 自注意力; 噪声; 卷积神经网络

中图分类号: TH165⁺.3; TH133.33 **文献标志码:** A **文章编号:** 1004-4523(2023)04-1169-10

DOI: 10.16385/j.cnki.issn.1004-4523.2023.04.030

引 言

轴承是电机最重要的零件之一, 轴承故障会直接影响到电机的运转, 严重时甚至会造成电机损伤和使用寿命缩短^[1]。突发性的故障更可能会造成人员受伤和高额经济损失, 因此对电机轴承进行精准的、实时的故障诊断十分重要^[2]。

振动信号分析是电机轴承故障诊断中常用的方法^[3]。传统的故障诊断方法依靠人类专业知识提取特征并判断其故障状态。传统的特征提取方法是对振动信号分别在时域、频域或者时频域中采用时域统计分析^[4]、短时傅里叶变换^[5]、小波变换^[6]和经验模态分解^[7]等方法提取其特征。提取的特征依靠人类丰富的经验来判断具体故障状态, 十分耗时耗力。

在过去几年时间里, 基于深度学习的方法得到了快速发展, 并应用于各个领域, 例如自然语言处理、计算机视觉和模式识别。同样, 使用深度学习进行电机轴承故障诊断和轴承寿命预测也取得了一些成果。

Zhang 等^[8]提出一种基于第一层宽卷积核的卷积神经网络 (Deep Convolutional Neural Networks with Wide First-layer Kernel, WDCNN), 第一层卷积采用宽卷积核, 增大了感受野, 与传统的卷积神经

网络相比极大提高了故障诊断的精度。宫文峰等^[9]采用全局均值池化技术代替传统 CNN 的全连接部分, 有效解决了传统 CNN 模型参数过多的问题, 在减少参数的情况下实现了对轴承的故障诊断。肖雄等^[10]将一维振动信号转换为二维灰度图, 然后利用卷积神经网络进行特征提取, 得到了较好的结果。

上述方法在无噪声情况下取得了很好的结果, 但是在实际情况中, 采集到的振动信号往往伴随着各种随机噪声, 无法直接采用带噪声的振动信号对轴承故障做出明确诊断, 因此去噪已经成为振动信号处理中的关键问题。为了解决噪声问题, Zhao 等^[11]提出了深度残差收缩网络, 将注意力机制与软阈值滤波结合, 实现自适应阈值滤波, 在高噪声情况下取得了较好的效果。但是阈值滤波不仅过滤掉了噪声, 也会滤掉实际的振动信号, 造成原始信号的缺失。

卷积自编码网络已经在图像去噪方面得到了广泛应用。为了在滤波的同时, 较好地保留原始信号, 万齐杨等^[12]使用卷积自编码网络去噪, 再用 CNN 网络进行故障诊断。但是该方法采用有监督学习的训练方式进行训练, 采用原始振动信号的带噪声时频图作为卷积自编码网络输入, 不带噪声学习的训练时频图作为标签, 可实际情况中很难得到噪声信号的标签。丁云浩等^[13]采用一维多尺度卷积自编码网

络对轴承故障进行诊断,能在去除噪声的同时较好地还原原始数据。该方法先训练好自编码网络,在网络基础之上添加 softmax 分类层,对网络进行分类训练微调。但是随着分类训练的进行,预先训练的去噪能力被改变为分类能力,削弱了网络去噪效果。

基于上述情况,为了改善在噪声下的轴承故障诊断问题,本文将多头自注意力机制和一维全卷积自编码网络相结合,提出 MHSACAE 去噪网络,并采用无监督学习的训练方式对 MHSACAE 网络进行训练,在实现无监督去噪的同时能较好地保留原始振动信号。再通过 CNN 网络进行故障诊断,构造了一种无需人工提取特征的端到端的 MHSACAE-CNN 故障诊断模型。

1 卷积自编码网络

卷积神经网络是受生物视觉皮层运作机理启发而来,2012年 Alex 设计的 AlexNet 使其大火^[14]。网络包含了卷积层和池化层,对数据有很好的特征提取能力,是目前运用最为广泛的深度学习网络架构之一。

卷积自编码网络^[15]使用卷积神经网络代替自编码网络中的全连接神经网络,使用卷积操作进行编码,反卷积操作进行解码,可以对输入数据进行还原重构。卷积自编码网络结合了自编码网络和卷积神经网络的优点,不仅可以还原数据,而且充分利用了卷积神经网络强大的特征提取能力和滤波功能,在处理复杂数据方面具有更好的效果。其结构如图 1 所示。




图 1 卷积自编码网络结构图

Fig. 1 MSACAE unsupervised denoising training principle diagram

2 改进的一维卷积自编码网络

本文对一维卷积自编码网络在网络结构、激活函数方面做了一定的改进,并加入了多头自注意力模块,具体改进内容如下。

2.1 激活函数

在有噪声干扰的情况下,振动信号和噪声信号的关系十分的复杂,无法用线性关系表示,而卷积和反卷积的本质都是线性运算。所以,为了提高网络的非线性学习能力,必须在卷积和反卷积的操作后添加非线性的激活函数。目前常用的激活函数是 Relu 激活函数,该函数将小于 0 的部分置零,这个函数适合处理数据全为正的图像。但是,振动信号是有正有负的,且负值部分也包含了很多有效信息,而使用 ReLU 函数会忽略大量的负值信息,导致有效特征的大量丢失。为了解决这一问题,在网络中采用了被称为 PReLU 的激活函数^[16]。它的数学表达式如下:

$$PReLU(x) = \begin{cases} x, & x > 0 \\ ax, & x \leq 0 \end{cases} \quad (1)$$

式中 a 的初始值为 0.25,可以固定或者随着学习一起更新。当 $a=0$ 时, PReLU 就变化为 ReLU 激活函数,当 $a=0.01$ 时,变化为 Leaky ReLU 激活函数。

2.2 多头自注意力机制

注意力机制^[17]模仿人类的对事物的思维方式,能够对输入信息进行筛选,忽略一些不重要的信息,自动寻找对当前任务最有帮助的信息,充分利用计算资源。它的数学本质是一种数据加权的方式,给重要信息高的权重,不重要信息低的权重。在噪声背景下,噪声是冗余信息,而原始振动信号是重要的特征信息,所以利用注意力机制可以有效滤除噪声。

自注意力机制^[18]是注意力机制的一种改进,在普通注意力的基础上,更加注重样本数据的内相关性。振动数据本身是一种时间序列,其数据内部之间在时间上有很强的相关性,所以自注意力机制十分适合用于一维振动数据的特征提取。其数学表达式如下:

$$\begin{cases} Q = W^q I \\ K = W^k I \\ V = W^v I \\ Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \end{cases} \quad (2)$$

式中 I 表示输入振动数据,是一个时序的向量; W^q, W^k 和 W^v 分别表示数据向量线性映射所需要的权重矩阵; Q 代表当前时刻数据的信息映射; K 代表其他时刻数据的信息映射; V 代表输入向量自身的特征映射; d_k 为输入向量的维度,用于归一化处理。两个向量的点乘可以表示两个向量的相似度,它们的相似度越高,点乘后的值越大。为了得到不同数据的内在联系,使用 Q 与 K 进行内积,得到表征数

据之间相关性的度量值。网络结构如图2所示。




图2 自注意力机制原理图

Fig. 2 Principle diagram of self-attention mechanism

自注意力机制计算过程如下:

首先将输入的数据乘以权重参数得到 Q, K 和 V 向量;然后计算每一个向量的权重分数: $score = Q \cdot K$, 为了保证梯度的稳定性,将 $score$ 通过 $softmax$ 进行归一化得到权重分布 α ;最后将 α 与表征特征的 V 进行加权求和得到最终结果。

为了最大尺度地表征数据的信息和特征,对每个数据采用了多个 Q, K, V 进行信息和特征映射,这种注意力机制被称为多头自注意力机制^[19],多头自注意力机制是在自注意力机制上的进一步改善。多头自注意力机制从多个角度对轴承故障信号进行特征提取映射,可以更全面地提取输入信息的特征,深入挖掘轴承振动信号内在的时序关系,增强神经网络抗噪能力。其数学表达式如下:

$$\begin{cases} head_i = Attention(QW_i^q, KW_i^k, VW_i^v) \\ MultiHead(Q, K, V) = Concat(head_1, \dots, head_n) \end{cases} \quad (3)$$

由式(3)可知,多头注意力机制采用了多个参数矩阵对数据求取不同 Q, K 和 V ,再将得到的结果进行拼接,得到更加全面的特征。

2.3 改进的卷积自编码网络模型

改进的 MHSACAE 网络模型如图3所示。池化层会模糊数据的特征,为了增强网络特征的提取能力,在该网络中采用了全卷积的方式,去除了在传统卷积自编码网络中采用的池化层。为了增强故障诊断的能力,本文将 CNN 宽卷积核的思想引入到该网络之中, MHSACAE 网络的第一层卷积层核最后一层反卷积层均采用了较宽的卷积核,增强了感受野,提高网络的滤波能力。在网络的编码和解码部分,分别加入 2.2 节中所提的多头自注意力层,加强了数据内部相关性特征的提取,进一步提高网络的滤波能力。为了保持较好滤波的同时还原原始数据,激活函数采用 2.1 节所提的 PReLU 函数。




图3 MHSACAE网络结构图

Fig. 3 MHSACAE network structure diagram

3 MHSACAE-CNN 轴承故障诊断

3.1 诊断模型介绍

基于 MHSACAE-CNN 的故障诊断模型如图4所示。




图4 MHSACAE-CNN网络结构图

Fig. 4 MHSACAE-CNN network structure diagram

首先通过一维的 MHSACAE 网络对输入的数据进行降噪还原处理,然后将降噪后的数据作为 CNN 输入,最后使用 CNN 网络进行故障诊断。

由于 MHSACAE 网络和 CNN 故障分类网络并没有特定的结构,受文献[8]提出的 WDCNN 网络

的启发,第一层卷积均采用宽卷积核,增大感受野,提高诊断精度。后续卷积层均采用小卷积核,可以深入挖掘样本间隐藏的深层信息,且网络参数量少,反应速度快。MHSACAE 网络参数如表1所示。CNN 网络参数如表2所示。

对于整个 MHSACAE-CNN 诊断模型,优化器统一采用 Adam 优化器,学习率为 0.001。MHSACAE 采用 MSELoss 损失函数,CNN 采用交叉熵损失函数。

表 1 MHSACAE 网络参数

Tab. 1 MHSACAE network parameters

层名	卷积核大小	步长	卷积核数量	Head 数	激活函数
Conv1	32×1	4	16		PReLU
Self-attention1				2	
Conv2	4×1	4	32		PReLU
Self-attention2				2	
Conv3	4×1	4	64		PReLU
Conv4	4×1	4	128		PReLU
DConv1	3×1	2	128		PReLU
DConv2	3×1	2	64		PReLU
DConv3	4×1	4	32		PReLU
Self-attention3				1	
DConv4	4×1	4	16		PReLU
DConv5	13×1	2	1		PReLU

表 2 CNN 网络参数

Tab. 2 CNN network parameters

层名	卷积核大小	步长	卷积核数量	池化长度	激活函数
Conv1	3×1	16	16	2×2	ReLU
Conv2	3×1	1	32	2×2	ReLU
Conv3	3×1	1	64	2×2	ReLU
Conv4	3×1	1	128	2×2	ReLU
Conv5	3×1	1	128	2×2	ReLU

3.2 故障诊断步骤

本文将无监督学习的 MHSACAE 与有监督学习的 CNN 网络相结合,构造了一种端到端的基于深度学习的轴承故障诊断网络,具体的故障诊断过程如下。

3.2.1 数据预处理

采集电机在正常、外圈故障、内圈故障和滚动体故障 4 种状态下的轴承振动信号。然后将信号分为训练集、验证集和测试集。在测试集上加入不同信噪比的噪声,得到不同噪声等级的测试集。

3.2.2 网络训练

对 MHSACAE 网络和 CNN 网络分别进行训练。首先采用无监督学习方式对 MHSACAE 网络进行训练,以原始无噪声的振动信号作为输入数据,同样的数据作为标签作为误差反馈,使去噪网络可以充分学习到原始数据的特征。训练原理图如图 5 所示。




图 5 MHSACAE 无监督去噪训练原理图

Fig. 5 MHSACAE unsupervised denoising training principle diagram

CNN 采用有监督训练的方式,将原始无噪声的振动信号作为输入,各种故障种类作为标签,训练 CNN 网络对故障进行分类。训练原理如图 6 所示。




图 6 CNN 网络有监督分类训练原理图

Fig. 6 CNN supervised denoising training principle diagram

3.2.3 网络验证和测试

训练时使用无噪声的数据,而在验证和测试的时候向原始数据中加入不同信噪比(Signal to Noise Ratio, SNR)的高斯白噪声。信噪比的计算公式如下:

$$SNR = 10 \lg \left(\frac{P_{\text{Signal}}}{P_{\text{Noise}}} \right) \quad (4)$$

式中 P_{Signal} 和 P_{Noise} 分别表示原始信号和噪声的能量。

将带噪声的数据作为 MHSACAE 降噪网络的输入,而降噪网络的输出作为 CNN 网络的输入,最终通过分类网络得到故障诊断精度。精度计算公式如下:

$$accuracy = \frac{N_{\text{True}}}{N_{\text{all}}} \quad (5)$$

式中 N_{True} 和 N_{all} 分别表示分类正确的样本数和测试集总的样本数。

故障诊断原理图如图 7 所示。




图 7 MHSACAE-CNN 故障诊断原理图

Fig. 7 MHSACAE-CNN fault diagnosis principle diagram

4 实验结果与分析

所有的实验均是在单张 GT730 GPU 上完成,

使用PyTorch深度学习框架。在本节通过两个实验案例验证所提方法的效果,并可视化各种噪声等级下去噪实验的结果,展现降噪网络的性能。最后在各个已知的噪声水平下,通过与其他去噪方法进行比较,展示所提方法的优越性。

4.1 实验一

实验采用美国凯斯西储大学的轴承故障数据验证本文方法的有效性,其轴承数据采集系统如图8所示。




图8 CWRU轴承数据采集系统

Fig. 8 CWRU bearing data acquisition system

通过在电机驱动端以48 kHz的采样频率进行采样获得故障数据。被诊断的轴承一共有4种状况,分别是正常、内圈故障、外圈故障和滚动体故障,对于每种故障考虑了3种故障大小,共计9种故障情况。

为了使多头自注意力层最大限度地提取样本在时序上的相关性,通过重叠采样的方法,将各种不同故障状况的数据划分为660个样本,每个样本2048个数据点,并按照8:1:1的比例划分为训练集、验证集和测试集。训练集总共5280个样本,测试集和训练集各660个样本。

为了符合实际情况,以及充分体现所提方法的去噪能力,在训练时用的数据是原始无噪声数据,验证和测试时用带噪声的数据。为了模拟实际情况,在验证集和测试集中都分别加入一定信噪比的噪声来污染数据,希望通过训练好的网络消除噪声,并对轴承故障进行诊断。

4.1.1 超参数的选择

本文采用多头自注意力机制与卷积自编码结合对数据降噪,其中自注意力层的头数和其层数至关重要。本文通过多次实验选择最优的参数。自注意力层数实验如表3所示。

在表3中,解码部分层数代表MHSACAE网络的解码部分中包含的自注意力层的层数,同样的编码部分层数代表网络中编码部分自注意力层的层数。为了得到网络最优参数,表3以0 dB下的故障诊断精度作为参数选取的标准。

表3 0 dB下自注意力层数对MHSACAE网络抗噪性的影响

Tab. 3 Influence of the number of self-attention layers on the noise immunity of MHSACAE network at 0 dB

编码部分 层数	解码部分层数		
	1	2	3
1	89.84%	85.30%	75.60%
2	90.45%	85.90%	76.67%
3	80.60%	84.24%	55.60%

从表3可以看出,解码部分层数增加会明显削弱MHSACAE的抗噪性,导致在高噪声情况下故障诊断精度下降。所以通过实验,选择在MHSACAE网络编码部分加入两层自注意力层,在解码部分加入一层自注意力层。

确定自注意力层后,在确定的网络模型下,继续通过实验选择自注意力层的头数。其实验参数如表4所示。

表4中编码部分头数表示编码部分自注意力层的头数,解码部分头数表示解码部分自主注意力层的头数。由2.3节所知,MHSACAE网络的作用主要分为两个部分:一个部分是对噪声的滤除;另一部分是对原始数据的恢复。由表4数据可知,在MHSACAE网络中,编码部分的自注意力层的头数增加更加注重于噪声的滤除,但会降低原始数据恢复能力,解码部分自注意力层的头数增加更有利于原始数据恢复,但是会降低抗噪能力。通过实验综合分析,选择MHSACAE网络解码部分自注意力层头数为2,编码部分为1。

表4 0 dB下自注意力层头数对MHSACAE网络抗噪性的影响

Tab. 4 Influence of the number of self-attention layers heads on the noise immunity of MHSACAE network at 0 dB

编码部分头数	解码部分头数		
	1	2	3
1	90.00%	93.74%	95.15%
2	95.30%	92.12%	93.18%
3	92.87%	89.24%	85.76%

4.1.2 降噪实验分析

为了检验MHSACAE网络的降噪能力,首先对网络的降噪部分进行了可视化。选取3种信噪比情况下的噪声数据,即4, 0, -2 dB。通过将3种情况下的去噪前数据、原始数据和去噪后的数据同时进行可视化对比,直观地展现了网络的去噪能力,其数据可视化如图9所示。

图9从左到右分别为原始无噪声数据,加噪信号和去噪后的信号。由图9可以看出在各个噪声等

级下,去噪效果都比较好。再通过用本文方法去噪后的故障诊断精度与其他方法在不同噪声情况下的

精度进行对比,来展示所提方法的优越性。其在 $-4\sim 6$ dB下的精度对比如图10所示。

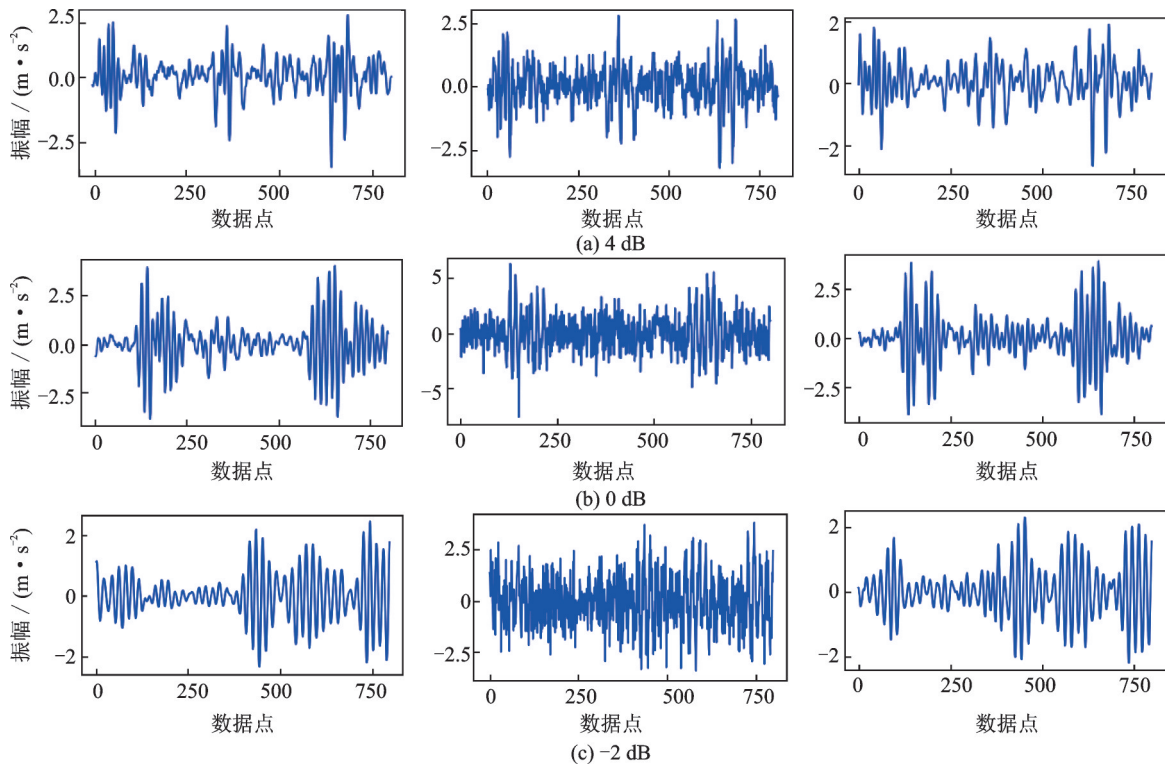


图9 各噪声等级下MHSACAE网络去噪效果图

Fig. 9 MHSACAE network denoising effect diagram under various noise levels

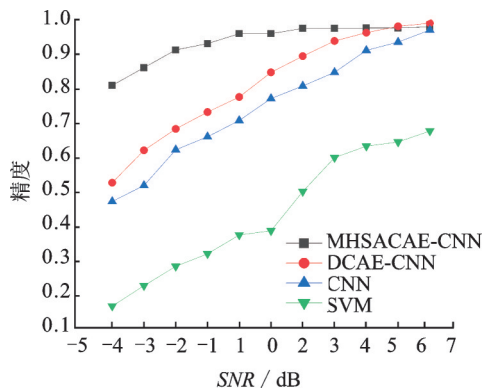


图10 凯斯西储大学数据集实验精度对比图

Fig. 10 Comparison of experimental accuracy of Case Western Reserve University data set

在图10中,CNN是仅通过卷积神经网络进行诊断的方法,DCAE-CNN是普通的卷积自编码去噪后再用CNN诊断的方法,MHSACAE-CNN是本文提出的方法,SVM是使用传统机器学习支持向量机的诊断方法。由图10可知,当信噪比在6 dB的情况下,3种深度学习方法得到的诊断精度差异均不大,达到98%,说明3种网络对于低噪声都具有一定的抵抗力,但SVM的预测精度仅为70%,其抗噪性能较差。随着信噪比逐渐降低,3种深度学习方法的精度差异也越来越大。

在0 dB情况下,本文的方法依然有95.30%的精度,DCAE-CNN的方法却只有70%的精度,用CNN进行故障诊断的精度仅仅只有48%。当信噪比低于0 dB时,后面两种方法的精度会更低。本文所提出的方法在 -2 dB的情况下诊断精度依然超过90%, -4 dB的情况下也有超80%的精度,充分体现了MHSACAE-CNN方法的抗噪能力。

前面只采用了高斯白噪声检验网络的抗噪性能,在此使用脉冲噪声与高斯白噪声混合的混合噪声进一步检验MHSACAE网络的抗噪性能。在振动信号中最明显的特征是脉冲特征,用脉冲噪声来代表强干扰下产生的噪声,可以对原始特征产生有效干扰。加噪后信号如图11所示,图11从左到右分别为原始无噪声信号、加高斯白噪声信号和加混合噪声后的信号。与其他方法在0 dB混合噪声下的诊断精度对比如图12所示。

由图12可知,在0 dB的混合噪声情况下,基于MHSACAE-CNN的诊断精度高于其他方法,表现出良好的抗噪性能。

为了进一步明确在噪声情况下使用本文方法对轴承故障诊断的情况,在测试数据信噪比为0 dB的情况下进行测试,并对测试结果做分类混淆矩阵热力图,展示各个类别故障的分类情况,混淆矩阵热力图如图13所示。




图11 加噪后信号图

Fig. 11 Signal graph after adding noise

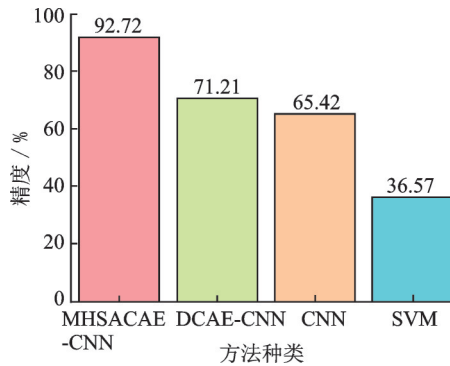


图12 凯斯西储大学数据集混合噪声实验精度对比图

Fig. 12 Accuracy comparison of mixed noise experiments of the Case Western Reserve University dataset

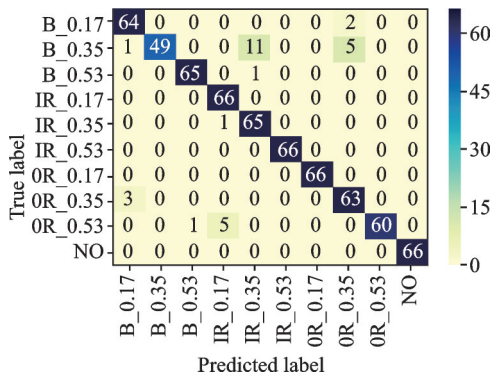


图13 测试结果混淆矩阵热力图

Fig. 13 Test result confusion matrix heat map

在图13中,横坐标为网络预测的故障种类,纵坐标为实际的故障种类。测试数据集有10类故障,各类故障66个样本,共660个样本。B代表滚动体故障,IR代表内圈故障,OR代表外圈故障,NO代表正常状态;0.17,0.35和0.53分别代表故障损伤直径,单位为mm。对角线为各类故障预测正确的数量,其余为各类别预测混淆数量。由图13可知,在0 dB的信噪比下,0.35 mm损伤的故障混淆程度最大,其中滚轴故障与内圈故障混淆了11个样本,与外圈故障混淆5个样本。

4.2 实验二

为了进一步验证MHSACAE网络的去噪效果,采用巴西里约热内卢联邦大学所提供的轴承诊断数据集进行实验。该数据集由机械故障模拟器对平

衡振动训练器上的传感器获得。该数据集包括正常状态、不平衡故障、外圈故障、内圈故障和滚轴故障5种状态。为了与实验一作对比,选取正常、外圈故障、内圈故障和滚轴故障4种状态作为本次实验数据集。每种状态有500个样本,每个样本有2048个数据点。同样按照8:1:1的比例划分为训练集、验证集和测试集。网络的结构和超参数与实验一相同。与其他方法的实验比较结果如图14所示。




图14 里约热内卢联邦大学数据集实验精度对比图

Fig. 14 Comparison of experimental accuracy of Federal University of Rio de Janeiro data set

由图14可知,采用SVM时诊断精度整体低于深度学习方法,且抗噪性能较低,在0 dB信噪比下诊断精度仅有30%。在只采用CNN的方法时,在信噪比为15 dB的情况下,诊断精度为97%,而当信噪比降低,噪声量加大,其诊断精度迅速下降。当信噪比为10 dB时,CNN诊断精度为86%,当信噪比为6 dB时,诊断精度只有73%。

由图14可知,在采用DCAE-CNN和MHSACAE-CNN的方法时,抗噪性有了明显提升,尤其是在使用MHSACAE-CNN方法的情况下。在信噪比为4~15 dB的情况下,使用MHSACAE-CNN方法的诊断精度一直稳定在98%以上,而DCAE-CNN的方法诊断精度下降明显,说明了MHSACAE-CNN方法优越的抗噪性。

在-4~4 dB的区间中,对比实验一和实验二中MHSACAE-CNN方法的诊断精度,发现实验二的精度低于实验一,而且精度下降尤为明显。在实验

一中,信噪比为 0 dB 的情况下诊断精度为 95.3%,但实验二只有 84.64%;在 -4 dB 的情况下,实验一的精度为 80%,实验二只有 65%。

分析原因是因为该实验数据集中的原始噪声大于凯斯西储大学数据集中的原始噪声,而噪声与原始数据之间并没有直接的联系,使得 MHSACAE 网络的多头自注意力模块不能很好地学习到样本中的内相关性,导致其抗噪性在强噪声情况下效果不够好。所以为了保证 MHSACAE 网络的去噪效果,需要在无监督训练的时候使用尽量干净无污染的数据,这是该网络的一个局限性,有待后续改进。

采用混合噪声进一步检验 MHSACAE 网络的抗噪性能,在 2 dB 信噪比下的故障诊断精度如图 15 所示。

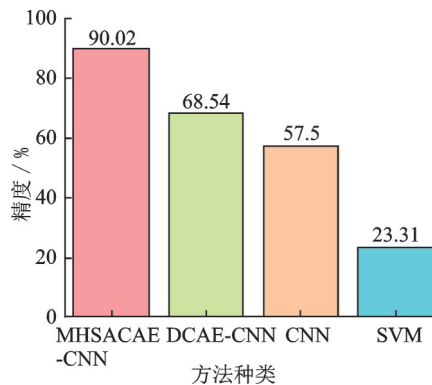


图 15 里约热内卢联邦大学混合噪声实验精度对比图
Fig. 15 Comparison of the accuracy of the mixed noise experiment of the Federal University of Rio de Janeiro

由图 15 可知,在 2 dB 的混合噪声情况下,基于 MHSACAE-CNN 的诊断精度高于其他方法,表现出良好的抗噪性能。

为了进一步明确诊断情况,在 2 dB 信噪比下测试结果混淆矩阵热力图如图 16 所示。

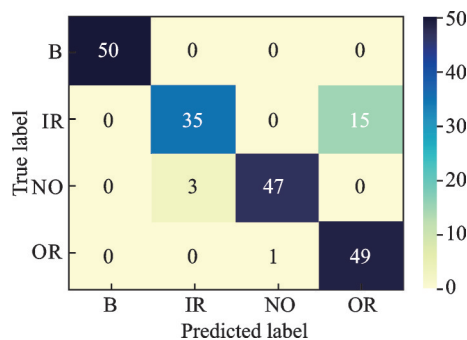


图 16 测试结果混淆矩阵热力图

Fig. 16 Test result confusion matrix heat map

由图 16 可知,在噪声情况下,内圈故障预测误差最大,测试结果与外圈故障混淆了 15 个样本。

4.3 噪声对训练影响分析

通过实验二分析得到的结论是在无监督训练时尽量使用干净无污染的数据,原始数据中的噪声会影响 MHSACAE 网络的抗噪性能。为了定量分析噪声对训练的影响,本文以实验一的实验数据进行实验,通过在训练数据中添加不同含量的噪声观察测试结果,以具体的测试精度衡量训练数据中的噪声对 MHSACAE 网络抗噪性能的影响,同时给出训练时数据噪声含量的量化标准,具体的实验结果如表 5 所示。

表 5 训练噪声含量对网络抗噪性的影响分析

Tab. 5 Analysis of the influence of training noise content on network noise immunity

测试信噪比/dB	训练信噪比/dB				
	17	16	15	14	13
6	97.75%	98.03%	97.69%	96.89%	95.16%
4	96.83%	96.86%	96.64%	96.08%	94.43%
2	96.80%	96.74%	96.42%	95.47%	93.85%
0	95.15%	95.47%	95.15%	94.52%	92.03%

在表 5 中训练信噪比和测试信噪比分别代表训练数据集和测试数据集中的噪声含量,信噪比越大,噪声含量越低,反之相反。由表 5 可知,在训练数据信噪比不低于 15 dB 时,在测试信噪比为 0 dB 得到的测试精度都在 95% 以上。当训练数据信噪比等于 13 dB 时,在测试信噪比为 0 dB 得到的测试精度只有 92.03%,所以在训练时候应使训练数据信噪比在 14 dB 以上,可以使 MHSACAE 网络得到较好的抗噪性能。

5 结 论

为了改善复杂环境下高噪声导致的轴承故障诊断精度低下的问题,通过研究提出了一种基于 MHSACAE-CNN 的故障诊断方法,并使用凯斯西储大学和里约热内卢联邦大学的公开轴承数据集验证了该方法的有效性和优越性,得到以下结论:

(1) 提出的基于 MHSACAE-CNN 端到端的轴承故障自动诊断的方法,改善了人工提取故障特征耗时耗力的问题。

(2) 将自注意力机制与一维卷积自编码网络结合,设计了用于降噪的 MHSACAE 网络。不仅可以很好地保留原始信息,而且充分地考虑到了序列数据的内在联系,实现在强噪声情况下的故障诊断。

(3) 采用无监督学习的方式对去噪网络进行训练,更加符合实际工况,在实用性能方面表现更为

优异。

(4)通过实验,定量分析了训练数据中噪声对MHSACAE网络的抗噪性能影响,给出了量化标准。

除此之外,该方法需要在训练时尽量使用污染程度小的数据,但是获取大量无污染的训练数据难度较大。下一步将研究在本文算法的基础上优化网络和损失函数,用较少且带噪声的训练数据得到更好的结果,以改善实际工程中训练数据难获取的问题。

参考文献:

- [1] 李兵,韩睿,何怡刚,等.改进随机森林算法在电机轴承故障诊断中的应用[J].中国电机工程学报,2020,40(4):1310-1319.
Li Bing, Han Rui, He Yigang, et al. Application of improved random forest algorithm in fault diagnosis of motor bearing[J]. Proceedings of the Chinese Society of Electrical Engineering, 2020,40(4):1310-1319.
- [2] 杜小磊,陈志刚,王衍学,等.形态经验小波变换和改进分形网络在轴承故障识别中的应用[J].振动工程学报,2021,34(3):654-662.
Du Xiaolei, Chen Zhigang, Wang Yanxue, et al. Application of morphological experience wavelet transform and improved fractal network in bearing fault recognition[J]. Journal of Vibration Engineering, 2021, 34(3): 654-662.
- [3] 陈向民,于德介,李蓉.齿轮箱复合故障振动信号的形态分量分析[J].机械工程学报,2014,50(3):108-115.
Chen Xiangmin, Yu Dejie, Li Rong. Morphological component analysis of gearbox compound fault vibration signal[J]. Chinese Journal of Mechanical Engineering, 2014,50(3):108-115.
- [4] Poongodi C, Hari B S, Arunkumar S. Vibration analysis of nylon gear box utilizing statistical method[J]. Materials Today: Proceedings,2020,33(7): 3525-3531.
- [5] Peng B, Wei X, Deng B, et al. A sinusoidal frequency modulation Fourier transform for radar-based vehicle vibration estimation[J]. IEEE Transactions on Instrumentation and Measurement, 2014,63(9): 2188-2199.
- [6] LEE W, PARK C G. Double fault detection of cone-shaped redundant IMUs using wavelet transformation and EPSA[J]. Sensors,2014,14(2):3428-3444.
- [7] 朱文龙,周建中,肖剑,等.独立分量分析-经验模态分解特征提取在水电机组振动信号中的应用[J].中国电机工程学报,2013,33(29):95-101.
Zhu Wenlong, Zhou Jianzhong, Xiao Jian, et al. Independent component analysis-application of empirical mode decomposition feature extraction in vibration signals of hydroelectric generating units[J]. Proceedings of the Chinese Society of Electrical Engineering, 2013, 33(29):95-101.
- [8] Zhang W, Peng G, Li C, 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] 宫文峰,陈辉,张泽辉,等.基于改进卷积神经网络的滚动轴承智能故障诊断研究[J].振动工程学报,2020,33(2):400-413.
Gong Wenfeng Chen Hui, Zhang Zehui, et al. Research on intelligent fault diagnosis of rolling bearing based on improved convolutional neural network[J]. Journal of Vibration Engineering, 2020,33(2):400-413.
- [10] 肖雄,王健翔,张勇军,等.一种用于轴承故障诊断的二维卷积神经网络优化方法[J].中国电机工程学报,2019,39(15):4558-4568.
Xiao Xiong, Wang Jianxiang, Zhang Yongjun, et al. A two-dimensional convolutional neural network optimization method for bearing fault diagnosis[J]. Proceedings of the Chinese Society of Electrical Engineering, 2019, 39(15):4558-4568.
- [11] Zhao M, Zhong S, Fu X, et al. Deep residual shrinkage networks for fault diagnosis[J]. IEEE Transactions on Industrial Informatics, 2020,16(7):4681-4690.
- [12] 万齐杨,熊邦书,李新民,等.基于DCAE-CNN的自动倾斜器滚动轴承故障诊断[J].振动与冲击,2020,39(11):273-279.
Wan Qiyang, Xiong Bangshu, Li Xinmin, et al. Fault diagnosis of rolling bearing of automatic tilter based on DCAE-CNN[J]. Journal Vibration and Shock, 2020, 39(11):273-279.
- [13] Ding Yunhao, Jia Minping. A multi-scale convolutional self-encoding network and its application in fault diagnosis of rolling bearings[J].Journal of Southeast University (English Edition),2019,35(4):417-423.
- [14] Krizhevsky A, Sutskever I, Hinton G. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017,60(6):84-90.
- [15] 张继冬,邹益胜,蒋雨良,等.基于全卷积变分自编码网络FCVAE的轴承剩余寿命预测方法[J].振动与冲击,2020,39(19):13-18.
Zhang Jidong, Zhou Yisheng, Jiang Yuliang, et al. Prediction method of bearing remaining life based on fully convolutional variational auto-encoding network FCVAE[J]. Journal of Vibration and Shock,2020,39(19): 13-18.
- [16] He K, Zhang X, Ren S, et al. Delving deep into rectifiers: surpassing human-level performance on imageNet classification [C]. Proceedings of IEEE International Conference on Computer Vision (ICCV). Samtiago,

- Chile, 2015:1026-1034.
- [17] Li F, Bai H, Zhao Y. Learning a deep dual attention network for video super-resolution [J]. IEEE Transactions on Image Processing, 2020, 29:4474-4488.
- [18] Wang X, Girshick R, Gupta A, et al. Non-local neural networks [C]. 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA, 2018:7794-7803.
- [19] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need [C]. Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach, CA, USA, 2017:6000-6010.

Fault diagnosis of motor bearing under high noise based on MHSACAE-CNN

WEN Bin^{1,2}, LI Zhi-cong¹, ZHU Han¹, CAO Ren-xuan¹

(1.College of Electricity Engineering and New Energy, China Three Gorges University, Yichang 443002, China; 2.Hubei Provincial Collaborative Innovation Center for New Energy Microgrid, China Three Gorges University, Yichang 443002, China)

Abstract: The operation of the motor is complicated and there will be a lot of noise under actual operating conditions. The noise causes low-accuracy of bearing fault diagnosis. In order to improve this problem, a bearing fault diagnosis method based on the multi-head self-attention mechanism of one-dimensional fully convolutional self-encoding network (MHSACAE) combined with convolutional neural network (CNN) is proposed. Firstly, we use the MHSACAE for noise reduction. And then we use CNN for fault diagnosis. Particularly, the MHSACAE adopts an unsupervised training method. The method fully considers actual working conditions and the inherent connection of the sequence data, while the ability to filter noise is achieved and the original fault information is retained to the greatest extent. So that CNN can realize high-precision diagnosis of motor bearing faults under noise conditions. Finally, the comparison with other bearing fault diagnosis methods under noisy conditions proves that the proposed method has better results.

Key words: fault diagnosis; bearing; self-attention; noise; convolutional neural network

作者简介: 文 斌(1985—),男,博士,讲师。电话: 17763382273; E-mail: wenbin_08@126.com。

通讯作者: 李知聪(1997—),男,硕士研究生。电话: 15736128929; E-mail: 3035655351@qq.com。