

基于注意力的多尺度卷积神经网络 轴承故障诊断

张玺君, 尚继洋, 余光杰, 郝俊

(兰州理工大学 计算机与通信学院, 兰州 730050)

摘要: 针对卷积神经网络在噪声环境下轴承故障诊断精度较低的问题, 提出一种加入通道注意力的多尺度卷积神经网络抗噪模型(MACNN)。该模型首先在提取不同尺度的特征时利用通道注意力自适应地选择包含故障特征的通道提高模型的抗噪能力, 抑制噪声的影响; 然后利用自适应大小的一维卷积调整不同尺度的特征通道权重, 自适应融合不同尺度的特征; 最后通过全连接层进行特征分类。两个轴承数据集上的实验结果表明: 在不同信噪比的噪声干扰下, 相比其他方法, MACNN有更强的轴承故障诊断能力。

关键词: 故障诊断; 滚动轴承; 卷积神经网络; 注意力机制

中图分类号: TP277 **文献标志码:** A **文章编号:** 1671-5497(2024)10-3009-09

DOI: 10.13229/j.cnki.jdxbgxb.20221537

Bearing fault diagnosis based on attention for multi-scale convolutional neural network

ZHANG Xi-jun, SHANG Ji-yang, YU Guang-jie, HAO Jun

(School of Computer and Communication, Lanzhou University of Technology, Lanzhou 730050, China)

Abstract: Aiming at the problem of low accuracy of bearing fault diagnosis based on convolution neural network in noisy environment, a multi-scale convolution neural network anti-noise model (MACNN) with channel attention was proposed. When extracting features of different scales, the model adaptively selected channels containing fault features by using channel attention to improve the anti-noise ability of the model and suppressed the influence of noise; In addition, the one-dimensional convolution of adaptive size was used to adjust the channel weights of features of different scales, and the features of different scales were adaptively fused; Finally, feature classification is carried out through full connection layer. Experimental results on two bearing datasets show that MACNN has better fault diagnosis ability than other methods under noise interference with different signal-to-noise ratios.

Key words: fault diagnosis; rolling bearing; convolutional neural network; attention mechanism

收稿日期: 2022-12-01.

基金项目: 国家自然科学基金项目(62162040, 61966023); 甘肃省高等学校创新基金项目(2021A-028); 甘肃省科技计划项目(21ZD4GA028); 甘肃省自然科学基金重点项目(22JR5RA226).

作者简介: 张玺君(1980-), 男, 副教授, 博士. 研究方向: 智能交通, 深度学习. E-mail: zhangxijun198079@sina.com

0 引言

滚动轴承是现代机械设备的组成部件之一,由于长时间运行在重载、高温的恶劣环境中,产生的故障会影响设备运行安全,甚至可能形成严重的事故,造成经济损失,而轴承故障占有所有机器故障的30%~40%^[1],为了让机械设备安全可地靠运行,及时对轴承故障进行诊断有重要意义。

轴承故障诊断大致包括3个步骤:通过传感器系统收集数据、提取轴承故障特征以及通过分类模型识别故障进行分类^[2]。提取故障特征的方法常见的有基于信号处理的方法和基于机器学习的方法。由于轴承振动信号是非平稳、非线性的,为了突出故障特征信息,基于信号处理的方法有傅里叶变换(Fourier transform, FT)^[3]、小波变换(Wavelet transform, WT)^[4]、经验模态分解(Empirical mode decomposition, EMD)^[5]等,模型可以在频域和时频域上对信号进行分析诊断,但其特征提取和故障诊断过程非常耗时且依赖专家经验。基于机器学习的方法中,传统的机器学习方法有多层感知机(Multilayer perceptron, MLP)^[6]、主元分析法(Principal component analysis, PCA)^[7]、支持向量机(Support vector machine, SVM)^[8]等,此类学习方法因依赖人工设计特征,已经不能满足现今故障诊断需求^[1]。

深度学习的故障诊断方法能在大量数据中自动提取特征,有着强大特征提取和处理复杂问题的能力。Janssens等^[9]首次引入卷积神经网络(Convolutional neural network, CNN)作为轴承故障诊断的模型,在此之后CNN被广泛应用于轴承故障诊断。Eren等^[10]采用了紧凑自适应1DCNN对多个轴承数据集进行故障诊断。孙祺淳等^[11]提出一种差分进化算法优化的卷积神经网络对轴承故障进行诊断。CNN虽然在提取轴承故障特征方面有较好的表现,但在有噪声干扰的情况下,提取故障特征就变得困难,导致诊断精度下降。Zhai等^[12]提出了域自适应的CNN模型在信噪比为0~10 dB的噪声环境下有良好的诊断结果。Zhang等^[13]提出第一层为宽卷积核的深度卷积神经网络,用以提取轴承故障特征,在信噪比为-4~10 dB的噪声环境下依旧能够进行轴承故障诊断。传统CNN故障诊断模型都是在单一尺度下或者加深网络层数提取轴承故障特征,而滚动轴承振动信号具有复杂的时间尺度特征^[14],若采

用固定大小的卷积,不能获得其他时间尺度的特征,采用多尺度卷积可以学习不同时间尺度的特征,有助于卷积神经网络识别故障特征。

Huang等^[15]提出了多尺度卷积神经网络(Multi-scale cascade convolutional neural network, MC-CNN)在信噪比为0~6 dB的噪声环境下进行轴承故障诊断。许子非等^[16]提出并行学习的多尺度卷积神经网络,在信噪比为-4~12 dB的噪声环境下有着较高的故障诊断精度。虽然上述研究采用多尺度卷积提取不同尺度的特征,但提取特征时忽略了不同通道有着不同的故障特征信息,包含噪声和无关特征的通道会影响模型的诊断^[17]。其次大多数多尺度卷积神经网络获得不同尺度的特征后只是简单地拼接再与全连接层连接进行分类,没有考虑不同尺度的特征差异,融合后的特征容易拟合噪声,导致故障诊断精度下降。

针对以上问题,本文提出使用通道注意力的多尺度卷积神经网络(Multi-scale attention convolutional neural network, MACNN),首先利用宽卷积层从原始轴承振动信号进行特征筛选,之后由不同尺度的卷积提取故障特征,再使用通道注意力调整不同特征的通道权重,选择有效的故障特征进行学习,减小无效特征的影响,抑制噪声干扰,最后利用自适应大小的1D卷积在特征融合层进行自适应融合。

1 MACNN故障诊断模型

1.1 卷积神经网络

CNN是深度学习中典型的前馈神经网络,利用卷积计算把简单特征提取为复杂特征,是一种分层结构的学习方法,具有很强的表征学习能力。CNN有减少训练参数和避免网络过拟合等优点。CNN一般由卷积层、池化层、激活函数、全连接层等组成,可以有效提取特征并进行分类。卷积层通过卷积核与局部输入区域进行卷积计算提取局部特征,其卷积核的数量决定输出特征的通道数,其计算公式为:

$$y_j^l = \sum_i^k x_i^{l-1} \times k_j^l + b_j^l \quad (1)$$

式中: x_i^{l-1} 为第 l 层的输入; k_j^l 为卷积核权重; b_j^l 为卷积核偏置; y_j^l 为 l 层的输出。

卷积后获得的特征一般需要通过池化层进行下采样操作,目的是进行特征选择和信息过滤,可

有效防止过拟合,通常有平均池化和最大池化,最大池化在实践中应用更广泛^[14],其计算公式为:

$$P_k^l = \max(x_k^l) \quad (2)$$

式中: P_k^l 为 l 层的最终输出; x_k^l 为对应最大池化第 l 个区域。

常见的激活函数有 Sigmoid 和 ReLU,激活函数能在卷积后的特征中加入非线性因素,ReLU 因具有单侧抑制、增强稀疏性^[2,14]等优点被广泛应用,其计算公式为:

$$f(x) = \begin{cases} x, & x \geq 0 \\ 0, & x < 0 \end{cases} \quad (3)$$

全连接层一般置于网络最后,用于将提取的特征进行非线性整合再作为网络输出,之后经 Softmax 进行分类,Softmax 计算公式为:

$$Q_j(x) = \frac{e^{x_j}}{\sum_{j=1}^K e^{x_j}} \quad (4)$$

式中: K 为分类类别数目; x_j 为第 j 个特征; $Q_j(x)$ 为 x_j 属于第 j 类的概率。

1.2 通道注意力

通道注意力 SEnet 由 Hu 等^[18]提出,通过显式建模通道的依赖关系,自适应地重新校准通道的特征响应,显著提升了 CNN 的性能。SEnet 的核心组件为 SE (Squeeze-and-Excitation) block,主要由 Squeeze 和 Excitation 两部分组成,如图 1 所示。




图 1 通道注意力

Fig. 1 Channel attention mechanism

Squeeze (挤压):普通 CNN 中,每个通道都是在其局部感受野进行学习,不能利用其他通道上下文信息。为此,通过卷积获得特征图 U 后再通过全局平均池化 (Global average pooling, GAP) 压缩特征图 U 获得全局信息 z , z_c 是 z 的第 c 个元素,其计算公式为:

$$z_c = F_{sq}(u_c) = \frac{1}{H \times W} \sum_{i=1}^H u_{c(i,j)} \quad (5)$$

式中: u_c 为 U 的第 c 个通道; H 和 W 为输入特征图的高和宽。

Excitation (激励):计算通道之间的关系,得到权重系数 s ,其计算公式为:

$$s = F_{ex}(z, W) = \sigma(g(z, W)) = \sigma(W_2 \delta(W_1 z)) \quad (6)$$

式中: δ 为 ReLU 函数; $W_1 \in \mathbb{R}^{r \times C}$, $W_2 \in \mathbb{R}^{C \times r}$; σ 为 Sigmoid 函数; r 为缩减率,本文取 16。

最后得到的特征图 X_c ,其计算公式为:

$$X_c = F_{scale}(u_c, s_c) = s_c \times u_c \quad (7)$$

式中: s_c 为 s 的第 c 个元素。

1.3 模型结构

多尺度注意力卷积神经网络 (MACNN) 主要由卷积层和通道注意力组成,其结构如图 2 所示。一维原始轴承振动信号首先通过宽卷积层进行特征筛选,宽卷积层在提取轴承振动信号中的故障特征信息时比小卷积层能更好地抑制噪声干扰^[13],并且能从振动信号中获取较长的时间尺度特征。之后使用批量归一化 (Batch normalization, BN) 加快训练速度,经过 ReLU 层进行非线性激活,利用最大池化层降维和减少参数计算量,其计算公式为:

$$Y_j = P(f(\text{BN}(k_j \times x_i + b_j))) \quad (8)$$

式中: Y_j 为特征输出; k_j 和 b_j 分别为卷积权重矩阵和偏差矩阵;BN 为批量归一化; f 为 ReLU 函数; P 为最大池化。

多尺度特征提取层由 3 个不同尺度的卷积层和通道注意力组成,多尺度卷积可以获得不同尺度的特征信息,提高模型的泛化能力^[19]。不同尺度卷积提取特征之后通过通道注意力调整重要通道权重,提高提取故障特征的能力,最后经自适应池化调整输出维度。

常见的多尺度卷积神经网络的特征融合都使用单一的拼接方式并与全连接层连接进行分类,融合后的特征存在冗余不利于模型的学习。因此,在特征融合层使用 ECA (Efficient channel attention) block^[20]中自适应大小的 1 维卷积对融合后的特征通道进行自适应调整,对每个通道分配不同权重,其计算公式为:

$$k = \phi(c) = \left\lfloor \frac{\log_2(C)}{\gamma} + \frac{b}{\gamma} \right\rfloor \quad (9)$$

$$\omega = \sigma(C1D_k(Y_j)) \quad (10)$$

式中: Y_j 为输入特征; C 为输入特征的通道数; b 和 γ 为常数, b 取 1, γ 取 2; k 为 1 维卷积核大小; $C1D_k$ 为 k 大小的 1 维卷积; σ 为 Sigmoid 激活函数; ω 为得到的通道权重。

之后使用GAP层减少自适应融合后的特征参数,在一定程度上防止模型过拟合,再连接全连

接层输出到Softmax层进行分类。模型主要网络参数见表1。

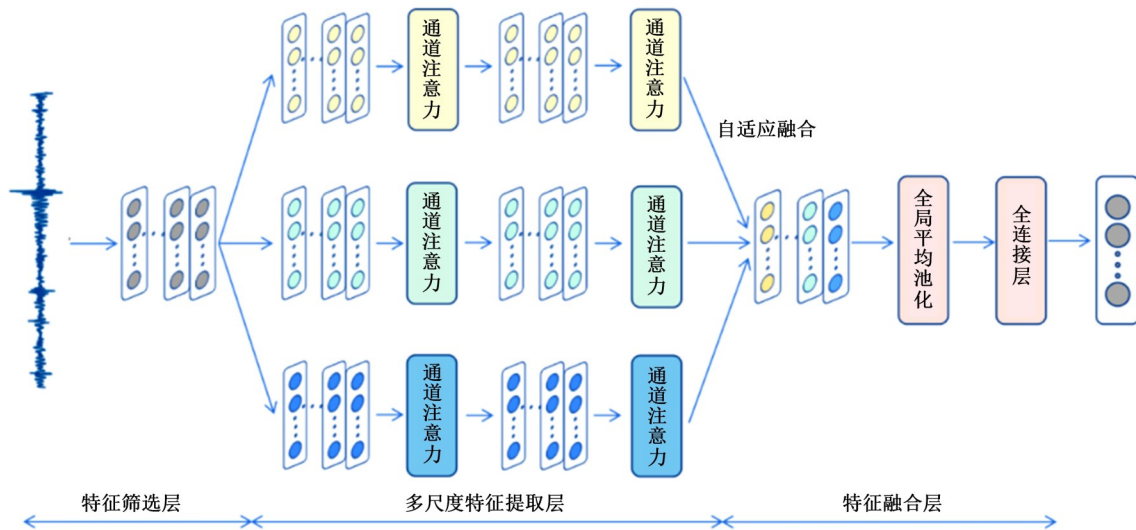


图 2 MACNN 模型结构

Fig. 2 MACNN model structure

表 1 MACNN 网络参数

Table 1 MACNN network parameters

层的名称	核尺寸	核数	步长
宽卷积层	64×1	32	2
池化层	2×1	32	2
多尺度卷积层 1	5×1/7×1/9×1	64/64/64	1/1/1
多尺度池化层 1	2×1/2×1/2×1	64/64/64	2/2/2
注意力层 1	—	64/64/64	—
多尺度卷积层 2	5×1/7×1/9×1	128/128/128	1/1/1
多尺度池化层 2	2×1	128/128/128	2/2/2
注意力层 2	—	128/128/128	—
全局平均池化	—	—	—
全连接层	—	—	—

1.4 模型诊断流程

MACNN 模型诊断流程如图 3 所示,分为数据划分、模型训练、故障诊断 3 个步骤。首先从轴承数据集划分出训练集、验证集和测试集,训练集和验证集进入初始化的 MACNN 模型进行训练。训练采用交叉熵损失函数衡量模型预测值和真实值的差距,使用 Adam 优化算法训练更新模型参数,训练轮数为 100,批量大小为 16,学习率为 0.001。模型达到指定最大训练轮数后保存模型。最后利用训练好的模型对测试集进行故障诊断。实验使用 Pytorch 作为深度学习框架,运行环境为 Intel Core i5-8300H 处理器, NVIDIA GeForce 1050Ti 图像处理器, 16 GB 内存。

2 实验设计与验证

2.1 实验数据集描述

为验证 MACNN 模型的有效性,选用 CWRU 轴承数据集^[21]和 XJTU-SY 轴承数据集^[22]作为本次实验的数据集。CWRU 数据集已经被广泛应用于轴承故障诊断,实验平台由电动机、传感器、功率测试器等组成,如图 4 所示。以 12.48 kHz 频率收集轴承驱动端和风扇端振动信号。每种故障数据集下有不同故障直径,每种故障直径下有 4 种不同的电机负载载荷 0、1、2、3 hp,每个负载下拥有 3 种故障类型,分别为内圈、外圈和滚动体故障,外圈故障按位置又分为 3、6、12 点钟 3 个位置。本次实验采用采样频率为 12 kHz 的驱动端数据,轴承型号为 SKF6205 深沟球轴承,根据故

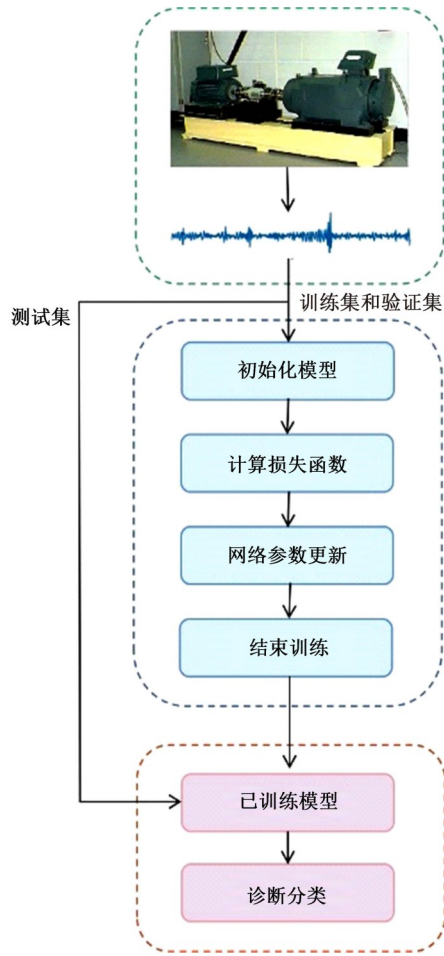


图3 MACNN 诊断流程

Fig. 3 The flow chart of MACNN for fault diagnosis




图4 轴承实验平台

Fig. 4 Rolling bearing test bench

障直径大小和故障位置与正常数据分为 10 个类别,负载为 0 hp 工况下的数据集见表 2。XJTU-SY 轴承数据集也被应用于轴承故障诊断,测试轴承类型为 LDK UER204,采集频率为 25.6 kHz,每次采样 32 768 个数据点,采样周期为 1 min,数据集包含 3 种工况下 15 个轴承运行到失效的数据,包含内圈磨损、保持架断裂、外圈磨损、外圈断裂等失效类型,设置为 15 个分类类别。

表 2 0 hp 轴承数据集

Table 2 0 hp Rolling bearing dataset

分类类别	故障位置	故障直径/mm
0	健康	—
1	内圈	0.177 8
2	内圈	0.355 6
3	内圈	0.553 4
4	外圈	0.177 8
5	外圈	0.355 6
6	外圈	0.553 4
7	滚动体	0.177 8
8	滚动体	0.355 6
9	滚动体	0.553 4

2.2 实验参数设置

实验数据集采用滑动窗口进行不重叠采样,每个样本包含 1 024 个数据点,对数据进行归一化处理,以加速模型收敛,计算公式为:

$$x_i = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (11)$$

式中: x_i 为归一化处理后的数据。之后随机划分训练、验证和测试数据集,其划分比例为 8:1:1。

2.3 噪声干扰实验

在实际工业中,滚动轴承是在噪声干扰的工作环境中运行。为模拟复杂噪声环境下收集的轴承振动信号,在振动信号中加入高斯白噪声以达到噪声干扰的效果,加入的高斯白噪声有不同信噪比(Signal to noise ratio, SNR),信噪比计算公式为:

$$\text{SNR}_{\text{dB}} = 10 \log_{10} \left(\frac{P_{\text{signal}}}{P_{\text{noise}}} \right) \quad (12)$$

式中: P_{signal} 为原始信号功率; P_{noise} 为高斯噪声功率。

图 5 分别显示了原始故障信号和信噪比为 -7 dB 噪声下的故障信号,可以明显看出轴承故障特征被噪声严重干扰。

2.3.1 可视化训练过程

使用 t-SNE (t-Distributed stochastic neighbor embedding)^[23] 降维技术可以可视化模型训练过程,观察模型训练前后的特征分布情况。在信噪比为 1 dB 的噪声环境下对模型训练过程进行可视化,如图 6 所示。

图 6(a) 的初始分布中,在噪声干扰下不同类的的数据处于聚集混叠状态。随着模型的深入,图 6(b) 显示不同类的类内距离较小,有较为明显




图 5 原始故障信号和噪声下的故障信号

Fig. 5 Original fault signal and fault signal under noise 的分类但类间距离还存在混叠现象。输出分布图 6(c)中,不同类之间的类间距离较大,基本实现故障分类,可以看出 MACNN 在噪声环境下故障分类效果良好。

2.3.2 注意力有效性实验

为验证通道注意力加入模型的有效性,在信噪比为 -9 dB 的噪声环境下测试通道注意力对模型故障诊断精度的影响,实验测试 10 次,其他实验参数保持一致,其结果如图 7 所示。

实验结果表明:有通道注意力的模型(AM)在噪声干扰下,故障诊断精度比无通道注意力模型(NAM)平均提升 4.08%,可以观察出在负载为 0 hp 的工况下故障诊断精度均低于其他负载下的故障诊断精度,但加入通道注意力的模型仍有 4.56%的提升。由此可见,加入通道注意力的模型的抗噪能力有一定的提升。

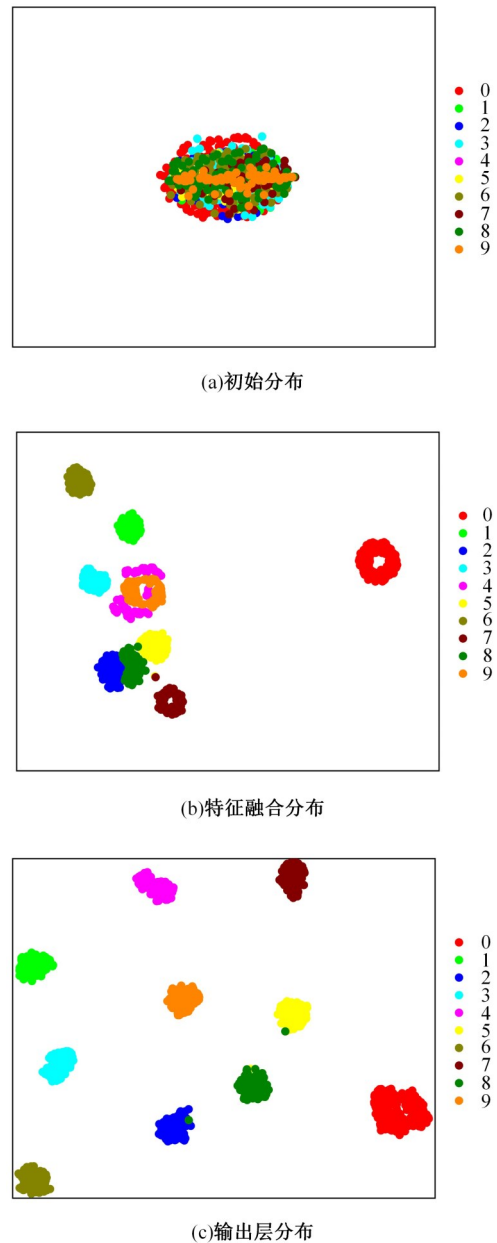


图 6 模型训练过程可视化

Fig. 6 Visualization of model training process

2.3.3 不同方法对比

为验证 MACNN 模型的抗噪能力,首先选用 CWRU 轴承数据集进行实验,添加信噪比为 $-7\sim 1\text{ dB}$ 的高斯白噪声到负载为 0 hp 工况下的数据集中,分别与 MLP、WDCNN^[13]、MC-CNN^[15]、ResNet^[24]、MCNN、MACNN 方法进行对比。其中,WDCNN 模型第一层是卷积核大小为 64 的宽卷积层,之后连接 4 个卷积核大小为 3 的卷积层提取特征。MC-CNN 第一层由 3 个宽卷积层构成,卷积核大小分别为 100、200、300,再连接卷积核大小为 8、32、16 的卷积层提取特征;




图 7 注意力机制的影响

Fig. 7 Effect of attention mechanism

ResNet 的网络深度为 18, ResNet 擅长提取深层特征,有较强的故障识别能力;MCNN 为特征融合层只使用全连接层的 MACNN,对比实验结果如图 8 所示。

从图 8 中可以看出,信噪比下降时,模型故障诊断精度也会下降,在信噪比最低时传统机器学习方法 MLP 诊断精度很低,ResNet 可以利用残差连接有效抑制网络过度拟合的影响^[14],在 -5 dB 以上的噪声环境下有较高的故障诊断精度。MCNN 由于在特征融合层只有全连接层,在 -7 dB 噪声环境下容易拟合噪声,其诊断精度远低于 MACNN,MACNN 在信噪比下降过程中保持良好的故障诊断精度,最低为 93%。




图 8 不同方法在噪声下的对比

Fig. 8 Comparison of different methods under noise

为进一步验证 MACNN 在噪声环境下的鲁棒性,用以上方法在 XJTU-SY 轴承数据集上进行噪声干扰实验,在振动信号中加入信噪比为 -5~1 dB 的高斯白噪声,实验结果见表 3。

从表 3 中可知,MACNN 在不同信噪比的噪声干扰下故障诊断精度均高于 85%,优于其他模型,表明 MACNN 在不同轴承数据集上的噪声干扰下依然有良好的轴承故障诊断能力。

表 3 不同方法在噪声下的对比

Table 3 Comparison of different methods under noise

诊断方法	-5 dB	-3 dB	-1 dB	1 dB
WDCNN	25.62±2.23	34.84±3.98	56.83±3.94	74.79±2.07
MC-CNN	54.69±2.20	75.88±1.25	80.57±2.61	92.71±1.95
ResNet	71.23±2.01	85.99±2.66	90.10±1.20	96.25±1.36
MCNN	71.77±3.48	86.61±1.41	92.24±1.19	95.52±1.27
MACNN	88.80±2.21	96.51±1.63	98.53±0.59	99.58±0.41

2.3.4 噪声下变负载实验

实际工作环境中,负载工况经常变化,模型需要具备在不同负载工况下的故障诊断能力。因此,选择 CWRU 数据集的 1、2、3 hp 3 种不同负载工况数据进行跨负载故障诊断,并且加入信噪比为 -5 dB 的高斯白噪声。其中一种工况数据用于训练,其他工况下的数据用于测试。例如,在 1 hp 工况下训练,2、3 hp 作为测试。实验结果如图 9 所示。

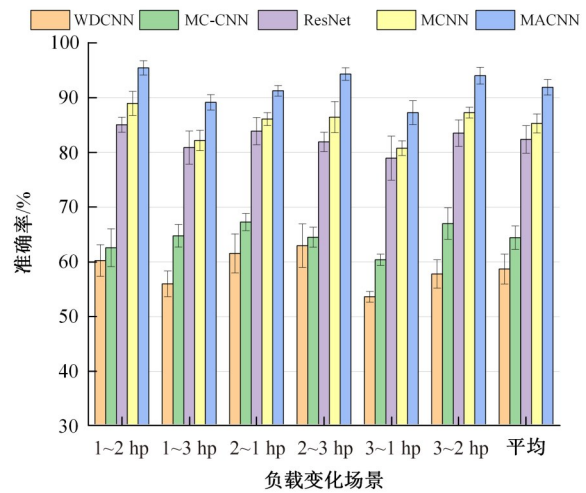


图 9 不同方法变负载诊断

Fig. 9 Different methods of variable load diagnosis

可以看出,MACNN 在每组跨负载故障诊断中均获得了最高的故障诊断精度,平均故障诊断精度为 91.91%,比 MCNN 的平均故障诊断精度高 5% 左右。分析结果表明:在噪声干扰下,MACNN 依然有良好的变负载轴承故障诊断能力。

3 结束语

为了提高卷积神经网络在噪声环境下的轴承故障诊断能力,本文提出一种基于注意力的多尺

度卷积神经网络抗噪模型。首先利用不同尺度卷积提取故障特征,加入通道注意力自适应选择关键的故障特征,之后自适应融合不同尺度的特征,提高模型在噪声环境下的轴承故障诊断能力。分别在CWRU和XJTU-SY轴承数据集上进行了噪声干扰实验,实验结果表明:MACNN在噪声环境下有着良好的轴承故障诊断能力。实验是在大量标记数据下进行的,但实际应用中某些特定的轴承故障数据很难获得,后续将进一步研究如何在不平衡的数据集上进行轴承故障诊断。

参考文献:

- [1] Zhang S, Zhang S, Zhang S B, et al. Deep learning algorithms for bearing fault diagnostics—a comprehensive review[J]. IEEE Access, 2020, 8: 29857–29881.
- [2] Huang Y J, Liao A H, Hu D Y, et al. Multi-scale convolutional network with channel attention mechanism for rolling bearing fault diagnosis[J]. Measurement, 2022, 203: No. 111935.
- [3] Cai J H, Xiao Y L, Fu L Y. Fault diagnosis of rolling bearing based on fractional fourier instantaneous spectrum[J]. Experimental Techniques, 2022, 46(2): 249–256.
- [4] Islam M M M, Kim J M. Automated bearing fault diagnosis scheme using 2D representation of wavelet packet transform and deep convolutional neural network[J]. Computers in Industry, 2019, 106: 142–153.
- [5] 胡葛庆, 陈徽鹏, 程哲, 等. 基于经验模态分解和深度卷积神经网络的行星齿轮箱故障诊断方法[J]. 机械工程学报, 2019, 55(7): 9–18.
Hu Niao-qing, Chen Hui-peng, Cheng Zhe, et al. Fault diagnosis for planetary gearbox based on EMD and deep convolutional neural networks[J]. Journal of Mechanical Engineering, 2019, 55(7): 9–18.
- [6] Li J M, Yao X F, Wang X D, et al. Multiscale local features learning based on BP neural network for rolling bearing intelligent fault diagnosis[J]. Measurement, 2020, 153: No. 107419.
- [7] Malhi A, Gao X R. PCA-based feature selection scheme for machine defect classification[J]. IEEE Transactions on Instrumentation and Measurement, 2004, 53(6): 1517–1525.
- [8] Zhang X Y, Li C S, Wang X B, et al. A novel fault diagnosis procedure based on improved symplectic geometry mode decomposition and optimized SVM[J]. Measurement, 2021, 173: No. 108644.
- [9] Janssens O, Slavkovikj V, Vervisch B, et al. Convolutional neural network based fault detection for rotating machinery[J]. Journal of Sound and Vibration, 2016, 377: 331–345.
- [10] Eren L, Ince T, Kiranyaz S. A generic intelligent bearing fault diagnosis system using compact adaptive 1D CNN classifier[J]. Journal of Signal Processing Systems, 2019, 91(2): 179–189.
- [11] 孙祺淳, 李媛媛. DE算法优化CNN的滚动轴承故障诊断研究[J]. 噪声与振动控制, 2022, 42(4): 165–171, 176.
Sun Qi-chun, Li Yuan-yuan. Research on fault diagnosis of rolling bearings based on DE algorithm optimization of CNN[J]. Noise and Vibration Control, 2022, 42(4): 165–171, 176.
- [12] Zhai X D, Qiao F, Ma Y, et al. A novel fault diagnosis method under dynamic working conditions based on a CNN with an adaptive learning rate[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1–12.
- [13] Zhang W, Peng G L, Li C 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.
- [14] Liang H P, Cao J, Zhao X Q. Multi-scale dynamic adaptive residual network for fault diagnosis[J]. Measurement, 2022, 188: No. 110397.
- [15] Huang W Y, Cheng J S, Yang Y, et al. An improved deep convolutional neural network with multi-scale information for bearing fault diagnosis[J]. Neurocomputing, 2019, 359: 77–92.
- [16] 许子非, 金江涛, 李春. 基于多尺度卷积神经网络的滚动轴承故障诊断方法[J]. 振动与冲击, 2021, 40(18): 212–220.
Xu Zi-fei, Jin Jiang-tao, Li Chun. New method for the fault diagnosis of rolling bearings based on a multi-scale convolutional neural network[J]. Journal of Vibration and Shock, 2021, 40(18): 212–220.
- [17] 康涛, 段蓉凯, 杨磊, 等. 融合多注意力机制的卷积神经网络轴承故障诊断方法[J]. 西安交通大学学报, 2022, 56(12): 68–77.
Kang Tao, Duan Rong-kai, Yang Lei, et al. Bearing fault diagnosis method using convolutional neural network fused with multi-attention mechanism[J]. Journal of Xi'an Jiao Tong University, 2022, 56(12): 68–77.
- [18] Hu J, Li S, Samuel A, et al. Squeeze-and-excitation networks[J]. IEEE Transactions on Pattern Anal-

- ysis and Machine Intelligence, 2020, 42(8): 2011-2023.
- [19] An Z H, Li S M, Wang J R, et al. Generalization of deep neural network for bearing fault diagnosis under different working conditions using multiple kernel method[J]. *Neurocomputing*, 2019, 352: 42-53.
- [20] Wang Q L, Wu B G, Zhu P F, et al. ECA-Net: efficient channel attention for deep convolutional neural networks[C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition, Piscataway, USA, 2020: 11531-11539.
- [21] Smith W A, Randall R B. Rolling element bearing diagnostics using the case Western Reserve University data: a benchmark study[J]. *Mechanical Systems and Signal Processing*, 2015, 64-65: 100-131.
- [22] Wang B, Lei Y G, Li N P, et al. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings[J]. *IEEE Transactions on Reliability*, 2020, 69(1): 401-412.
- [23] Van D M L, Maaten, Hinton G. Visualizing data using t-SNE[J]. *Journal of Machine Learning Research*, 2008, 9: 2579-2605.
- [24] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]//IEEE Conference on Computer Vision and Pattern Recognition. Piscataway, USA, 2016: 770-778.