

DOI:10.19651/j.cnki.emt.2417293

# 基于注意力的多尺度残差卷积网络轴承故障诊断\*

李强 马超 黄民

(北京信息科技大学机电工程学院 北京 100192)

**摘要:** 针对轴承故障信号中存在复杂特征的特点,提出了一种结合注意力机制与多尺度残差卷积网络轴承故障判定方法。该模型结合了卷积神经网络(CNN)的强大特征提取能力和注意力机制的自适应加权能力,能够有效地处理轴承故障信号中的复杂特征。模型采用了多尺度卷积层,通过不同大小的卷积核捕获信号的多尺度特征,有助于识别不同类型和严重程度故障。同时,引入残差结构,通过高维与低维特征的协同决策机制,有效整合多层卷积提取的特征,增强了模型对关键信息的感知能力,并降低了深度网络训练中的梯度消失和特征冗余问题,从而保证了模型的稳定性和准确性。注意力机制(如SEBlock和ECABlock)的融合,使模型能够自适应地关注更加重要的特征通道,进一步提升了诊断性能。实验结果表明,该模型在强噪声下能够实现高精度的诊断,展示了其在智能维护和故障预警系统中的应用潜力。

**关键词:** 轴承故障诊断;ResNet-MSCNN;注意力机制;深度学习

**中图分类号:** TH133.3;TN06 **文献标识码:** A **国家标准学科分类代码:** 460.2020

## Attention-based Multi-scale residual convolutional network for bearing fault diagnosis

Li Qiang Ma Chao Huang Min

(School of Electromechanical Engineering, Beijing Information Science and Technology University, Beijing 100192, China)

**Abstract:** Aiming at the characteristics of complex features in bearing fault signals, a bearing fault determination method combining the attention mechanism and multi-scale residual convolutional network is proposed. The model combines the powerful feature extraction capability of convolutional neural network (CNN) and the adaptive weighting capability of the attention mechanism, which can effectively deal with the complex features in the bearing fault signal. The model employs a multi-scale convolutional layer, which captures the multi-scale features of the signal through different sizes of convolutional kernels, which helps to recognize different types and severities of faults. Meanwhile, the residual structure is introduced to effectively integrate the features extracted by multilayer convolution through the cooperative decision-making mechanism of high-dimensional and low-dimensional features, which enhances the model's ability to perceive the key information and reduces the problems of gradient vanishing and feature redundancy in the training of the deep network, so as to ensure the stability and accuracy of the model. The fusion of attention mechanisms (e. g., SEBlock and ECABlock) enables the model to adaptively focus on more important feature channels, which further improves the diagnostic performance. The experimental results show that the model can achieve high-precision diagnosis under various fault modes, demonstrating its potential application in intelligent maintenance and fault warning systems.

**Keywords:** bearing fault diagnosis; ResNet-MSCNN; attention mechanism; deep learning

## 0 引言

旋转机械作为现代工业中的关键设备,在航空航天,轨道交通车辆等众多行业中有着广泛的应用。然而在现实中的应

用场景中,随着工作寿命增长加之工作环境的影响,其一旦损坏,将会带来相应的损失。作为旋转机械的基础部件,滚动轴承的健康状况对机械设备的运行性能和寿命具有重要影响。为了预防可能的故障发生,对轴承运行状态进行准

收稿日期:2024-11-06

\* 基金项目:国家自然科学基金(62303065)项目资助

确的检测和故障预警至关重要,这不仅可以降低成本,还能在事故发生前尽早采取防范措施。

传统的轴承故障诊断方法主要依赖于人工特征提取,这一过程高度依赖于领域知识和人工经验,对最终诊断结果具有很大影响<sup>[1]</sup>。然而,这种方法在复杂多变的工业环境中往往面临适应性差、诊断精度低等问题。随着人工智能和深度学习技术的快速发展,深度学习方法为故障诊断领域提供了新的解决方案。深度学习模型,尤其是卷积神经网络(convolutional neural networks, CNNs),能够自动从输入数据中学习多种复杂特征,减少了传统方法中人工选择特征的不确定性。

近年来,多尺度卷积神经网络<sup>[2]</sup>(multi-scale convolutional neural networks, MSCNN)由于其优越的特征提取能力,在轴承故障诊断领域得到了广泛应用。例如,沈启敏等<sup>[3]</sup>在传统 MSCNN 的基础上,提出一种合理的截取采样方式通过连续小波变换将其转化为二维矩阵进行处理,并使用注意力模块重点关注有效信息。徐紫薇等<sup>[4]</sup>构建了多尺度卷积神经网络与双向门控循环单元的网络(multi-scale convolutional neural network-bidirectional gated recurrent unit, MSCNN-BiGRU)特征提取模块对信号进行多尺度特征提取,为实现在噪声干扰下的轴承故障诊断提供了新思路。张玺君等<sup>[5]</sup>提出了一种基于注意力的多尺度卷积神经网络抗噪模型,在两种轴承数据集上证明其有着良好的抗噪能力。许子非等<sup>[6]</sup>基于被采信号具有时间多尺度特性,提出时间多尺度特征提取概念,从单一振动时域信号中提取具有不同时间尺度的子信号,提出多尺度特征卷积神经网络(multiple time scale characteristic extracted convolutional neural network, MTSC-CNN),对多种故障类型进行识别,证明其在复杂环境下性能更好。张家安等<sup>[7]</sup>在网络结构上进行优化,提出了一种改进多头自注意力机(improve multi-head self-attention mechanism, IMHSA)-多尺度卷积网络(MSCNN)-双向长短期记忆网络(bidirectional long short term memory network, BiLSTM)的风机轴承故障诊断方法,其中的多尺度卷积模块为其大模型提供了更强的泛化能力。滚动轴承的故障诊断在跨工况和跨设备条件下具有挑战性,Wang 等<sup>[8]</sup>为此提出了基于多分支卷积网络(multi-branch convolutional neural network, MBCNN),改网络设计多个特征提取分支,每个分支聚焦于不同的特征子空间,通过融合以获得多样化的特征表示。针对滚动轴承故障诊断中存在的分布差异问题(如工作条件、设备变化),Chen 等<sup>[9]</sup>提出一种具有特征对齐的多尺度卷积神经网络(multiscale convolutional neural network with feature alignment, MSCNN-FA),网络结构设计上采用分支结构,通过各分支分别提取不同尺度的特征,并融合为全局特征表示。针对工业机器人谐波减速器在复杂工况下的故障诊断问题,He 等<sup>[10]</sup>提出了一种多尺度混合卷积神经网络(multi-scale

mixed convolutional neural networks, MSMCNN),旨在提升模型对谐波减速器故障特征的提取能力和诊断性能。结合信号的时间多尺度特性,提出多尺度特征提取模块,通过不同尺度的卷积核对振动信号进行并行卷积,提取不同时间尺度的特征。引入空洞卷积,以扩大感受野,增强对长时间依赖特征的捕获能力。通过多层卷积融合,提升了模型对故障特征的鲁棒性和复杂工况下的分类能力。

近年来,注意力机制作为深度学习的一个重要分支,在故障诊断领域也表现出了显著的潜力。通过在神经网络中引入注意力机制,模型可以更有效地关注重要的特征信息,忽略次要特征,从而提升诊断性能。张瑞博等<sup>[11]</sup>提出了结合卷积块注意力模块(convolutional block attention module, CBAM)注意力机制与 Inception-ResNet 的轴承故障诊断新方法,其中 CBAM 将通道注意力与空间注意力模块融合,可以更加关注重要特征,通过实验验证了有更好的性能。张菀等<sup>[12]</sup>提出一种基于多头注意力机制和长短时记忆神经网络的电机轴承剩余寿命预测模型。其多头注意力机制可以更好捕捉不同特征的依赖关系,强化与剩余寿命相关度较高特征的权重,使得模型有更好的效果。车鲁阳等<sup>[13]</sup>在三通道网络模型的结构基础上添加多头注意力机制,重新调整网络输出权重,加快其整体模型的收敛速度,对其模型预测寿命曲线起到了一定的作用。

这些改进 MSCNN 在轴承故障诊断中的应用,展示了多尺度卷积神经网络在复杂工业环境中的潜力和优势。然而,这些方法仍然面临一些挑战,如传统卷积神经网络在噪声环境下表现不佳,鲁棒性较差。因此,本文提出了一种结合注意力机制与多尺度残差卷积网络的轴承故障判定方法,旨在解决现有方法的不足,提升模型的诊断性能和鲁棒性。该方法通过多尺度卷积网络对于原始信号直接提取不同尺度的特征,捕捉信号中的全局与局部信息。同时,引入残差结构,通过高维与低维特征的协同决策机制,有效整合多层卷积提取的特征,增强了模型对关键信息的感知能力,并降低了深度网络训练中的梯度消失和特征冗余问题,从而保证了模型的稳定性和准确性。同时,注意力机制能够自适应地为不同通道的特征分配权重,抑制不必要的特征以增强网络的表达能力。实验结果表明,与传统的深度学习方法以及相关的多尺度神经网络相比,该方法在各种噪声环境下均表现出更高的故障诊断准确率,验证了其在噪声环境中的鲁棒性和优越性。

## 1 理论基础

### 1.1 MSCNN 网络

MSCNN 是一种专门设计用于处理多尺度特征的卷积神经网络。它通过在不同的尺度上应用卷积操作来捕捉输入数据中不同大小和形状的特征,从而提高模型的性能和鲁棒性。MSCNN 在图像识别、目标检测、语义分割等领域有广泛的应用。



## 2) 卷积操作

为了捕获局部通道间的依赖关系, ECA 块使用了一维卷积而不是全连接层来进行交互:

$$z' = \text{Conv1d}(z) \quad (5)$$

使用带有适当卷积核大小的 1D 卷积, 这样可以减少参数开销并捕获相邻通道之间的关系。

## 3) 激活

使用 Sigmoid 函数对卷积后的输出进行激活, 生成每个通道的权重:

$$w = \sigma(\text{Conv1d}(z)) \quad (6)$$

## 4) 重标定

最后,  $w$  将通道权重作用到原始输入特征上, 对每个通道进行加权操作:

$$\hat{X}_c = w_c \cdot X_c \quad (7)$$

## 1.3 残差连接

随着网络的加深, 深层网络的性能往往不一定优于浅层网络, 甚至有时会退化。这是因为传统的深层神经网络难以有效地训练, 它们很容易出现梯度消失或梯度爆炸问题, 使得网络的性能无法随着深度的增加而提高。这种现象称为退化问题。

残差连接<sup>[16]</sup>的核心思想是, 假设理想情况下, 输入的特征  $x$  已经足够好, 如果深度网络能够拟合一个恒等映射  $H(x) = x$ , 那么网络就没有必要进行进一步的变换。但在实际中, 网络很难直接学习这个恒等映射。为了解决这个问题, 残差网络引入了一个简化目标: 学习输入与输出之间的残差, 即让网络学习:

$$F(x) = H(x) - x \quad (8)$$

也就是说, 网络通过优化残差函数  $F(x)$ , 得到最终的输出为:

$$H(x) = F(x) + x \quad (9)$$

这样, 网络只需学习如何在输入的基础上进行少量的调整, 而不是完全重新计算特征。这种残差形式使得网络的优化过程更简单, 也更容易训练深层网络。

由于通过残差连接引入了输入与输出的直接连接, 模型中即使没有学习到有用的特征, 也可以直接通过恒等映射  $x$  将输入传播到更深层。这避免了梯度的消失或爆炸问题, 有助于梯度通过反向传播更顺利地传递到浅层网络。此外, 恒等映射为网络提供了一个合理的初始化起点, 使得即便在网络初期的训练阶段, 也能保持不错的性能。

## 2 结合注意力机制与多尺度残差卷积网络的模型

该模型集成了多尺度卷积, 注意力机制 (SEBlock 和 ECABlock) 以及残差连接, 以增强特征提取能力和提升模型性能。模型及相关参数如图 4 所示。下面是对该模型的详细介绍, 包括每一层的作用及其工作流程。

该模型主要由以下几部分组成:

1) 初始特征提取: 输入数据经过初始卷积层、批量归一

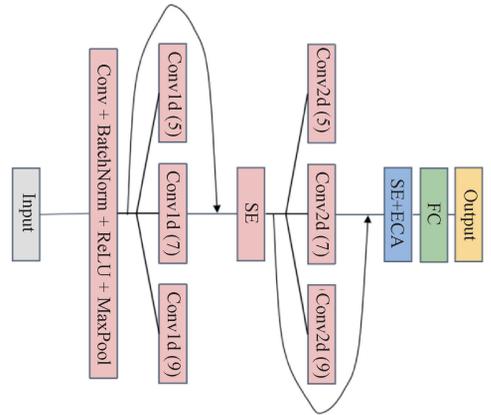


图 4 基于注意力的多尺度残差卷积网络模型结构图

Fig. 4 Attention-based multi-scale residual convolutional network model structure

化、ReLU 激活和最大池化, 提取初步特征并降维。其中包括一个大小为 64 的卷积核, 对较长的输入数据进行特征提取。

2) 多尺度特征提取 (第 1 组卷积层): 通过 3 种不同大小 (5, 7, 9) 的卷积核提取不同尺度的特征, 3 个卷积层的输出会通过相加操作融合到一起 (跳过连接), 同时引入残差连接。残差连接不仅能够避免梯度消失问题, 还能够实现高低维度特征的协同决策。在本架构中, 残差连接并非简单地跳过某些层, 而是通过将浅层卷积层的低维特征与深层卷积层的高维特征相加, 充分利用不同层级特征的互补性。残差连接使得模型能够综合多种层级信息, 提升对复杂信号的表征能力。使用 SEBlock 进行通道加权, 用于给卷积层输出添加通道维度的注意力机制, 通过自适应池化和全连接层计算每个通道的重要性, 然后调整特征图的各个通道的权重。这样可以使模型聚焦在更重要的特征上, 提升模型性能。

3) 多尺度特征提取 (第 2 组卷积层): 将输出的通道数增加到 128, 进一步通过 3 种不同大小的卷积核提取更深层次的特征, 然后将所有特征在通道维度上拼接, 这一过程中, 不仅延续了残差连接对高低维特征的协同融合, 还通过通道注意力机制 (SEBlock 和 ECABlock) 进一步优化特征权重分布。ECABlock 以更轻量化的方式自适应调整通道间的权重分布, 与 SEBlock 形成互补, 强化了特征的表达能力。

4) 全局特征和分类: 通过全局平均池化层得到每个通道的全局特征, 然后通过全连接层输出最终分类结果。

这种架构有效地结合了多尺度卷积、残差连接和多种注意力机制, 有助于提高模型对不同尺度特征的捕获能力, 残差连接有效地融合了这些特征, 使得模型能够同时捕获细节信息与全局信息, 增强模型的表达能力和泛化性能。

### 3 结果及分析

#### 3.1 数据介绍

本文使用凯斯西储大学 (Case Western Reserve University, CWRU) 的滚动轴承数据集<sup>[17]</sup>作为实验对象, 此数据集已被许多其他研究人员认为是轴承故障诊断领域的基准数据集。CWRU 轴承故障数据集所使用的实验台平台如图 5 所示, 该平台由一个电动机 (左侧)、一个扭矩传感器 (中间连接处)、一个功率测试计 (右侧) 和电子控制器 (未显示) 组成。驱动端轴承型号为 SKF6205-2RSJEM, 风扇端轴承型号为 SKF6203-2RSJEM 使用电火花加工为电机轴承提供故障, 在滚动体、内圈和外圈上分别引入了故障直径分别为 0.007、0.014 和 0.021 inch 的单点故障, 加上正常状态下滚动轴承的实验数据, 一共有 10 种不同类型的故障类型, 如表 1 所示。

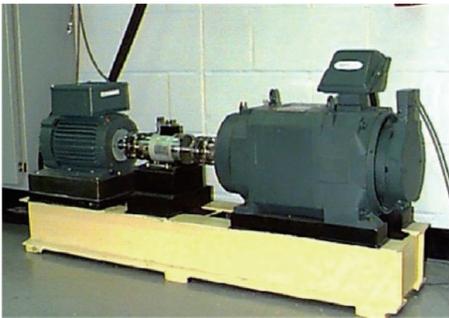


图 5 CWRU 轴承故障实验平台

Fig. 5 Experimental platform for CWRU bearing failure

表 1 CWRU 轴承故障分类及标签值

Table 1 CWRU bearing fault classification and tagged values

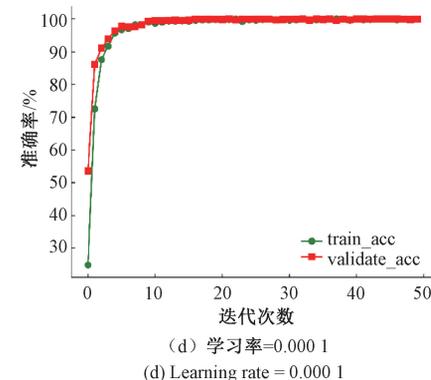
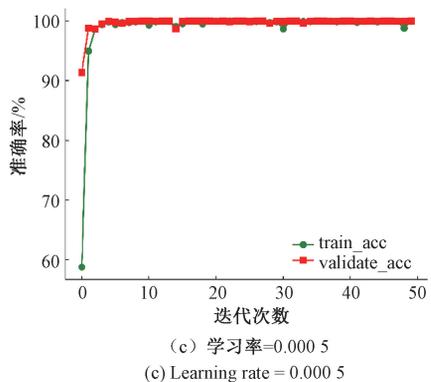
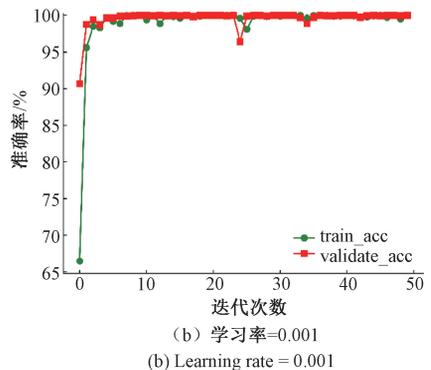
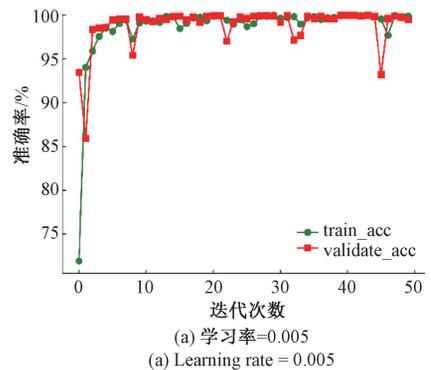
标签值	故障类型	故障直径/inch
0	正常状态	无
1	内圈故障	0.007
2	滚动体故障	0.007
3	外圈故障	0.007
4	内圈故障	0.014
5	滚动体故障	0.014
6	外圈故障	0.014
7	内圈故障	0.021
8	滚动体故障	0.021
9	外圈故障	0.021

本实验选取 12 K 采样频率下的驱动端轴承数据, 选取样本的采样长度为 512, 重叠率为 0.75, 训练集与测试集比例为 8:2。

#### 3.2 超参数选择

超参数不仅仅对模型的分类准确率有很大影响, 而且对模型的训练时间也有很大影响。所以选择合适的超参数

对神经网络模型是至关重要的。本文设置了一组学习率分别为 0.005、0.001、0.000 5、0.000 1、0.000 05、0.000 01 的情况进行对照实验, 实验过程中训练集和测试集的准确率随迭代次数变化的曲线如图 6 所示。



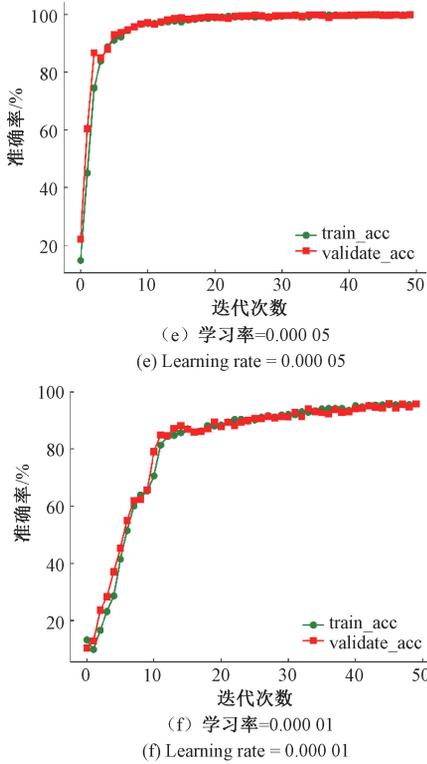


图 6 不同学习率下准确率随迭代次数的变化  
Fig. 6 Variation of accuracy with the number of iterations at different learning rates

由图 6 可以看出,当学习率较大时,测试集准确率会很快逼近最大值。随着迭代次数继续增加,会出现过拟合问题。学习率为 0.000 1 时,相较于学习率为 0.000 5 时训练集准确率更高,且收敛速度更快。而学习率较小时,模型收敛较慢,导致模型的训练速度过长。综合以上因素综合考虑,经过调试最终确定模型的超参数如表 2 所示。

表 2 模型超参数取值  
Table 2 Model hyperparameter values

超参数	值
学习率	0.000 1
批大小	32
迭代次数	30

### 3.3 消融实验分析

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:

$$SNR = 10\lg\left(\frac{P_{\text{signal}}}{P_{\text{noise}}}\right) \quad (10)$$

其中,  $P_{\text{signal}}$  是信号的功率,  $P_{\text{noise}}$  是噪声的功率, SNR

单位为 dB。

为验证模型各个部分的重要性,加入的噪声的信噪比为 -10 dB,分别在相同的实验条件下改变模型,分为 5 种模型:原模型、无多尺度模块、无残差连接、无 SE 块和无 ECA 块。4 个参考的性能指标为准确率、F1 分数、查准率、查全率。其中准确率是模型预测正确的样本占总样本数的比例。F1 分数是查准率(Precision)和查全率(Recall)的调和平均值,它综合了查准率和查全率,兼顾了模型的精确性和覆盖率。查准率是指模型预测为正类的样本中,真正为正类的样本所占的比例。查全率是指真正的正类样本中被模型正确识别出来的比例,也称为召回率。在强噪声环境下的消融实验模型性能对比如表 3 所示,如图 7 所示。

表 3 消融实验模型性能对比  
Table 3 Comparison of ablation experiment model performance

模型	准确率	查准率	查全率	F1 分数
原模型	92.88	92.68	92.86	92.78
无多尺度模块	90.24	90.08	90.48	90.14
无残差连接	81.83	81.34	84.28	81.73
无 SE 块	88.73	88.33	90.92	88.63
无 ECA 块	88.95	88.61	90.55	88.85

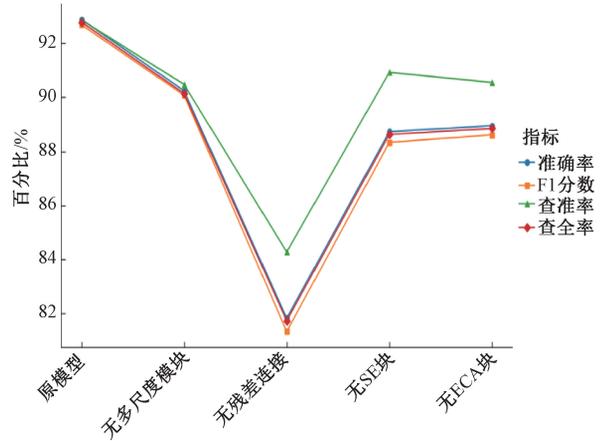


图 7 模型消融实验  
Fig. 7 Model ablation experiment

从图 7 中可以看出,原模型在所有指标上都达到了最高的表现,尤其是在准确率、查准率和查全率 3 个指标上接近或超过了 92%。这表明原模型的整体性能最佳,能够在准确识别、正确率以及召回率上都有很好的平衡。去掉多尺度模块后,各项指标都有轻微的下,特别是准确率和 F1 分数都下降到 90% 左右。多尺度模块在捕获不同尺度特征上可能起到了关键作用,去掉后模型的识别能力有所降低。去掉残差连接后,模型的性能显著下降,特别是查准率降至接近 82%,其他指标也大幅下降。这表明残差连接在模型中起到了非常重要的作用,残差机制可能帮助模型

缓解了梯度消失问题,提高了信息流动和特征表示的能力。去掉 SE 块和 ECA 块后,模型的表现也略微下降。通过该图,可以看出模型的优势在于其复杂的结构设计,每个模块都对性能提升有着不同的贡献。

### 3.4 结果对比分析

为了验证本方法的性能和优势,本文选用常见的神经

网络算法 WDCNN<sup>[18]</sup>、Resnet、Inception<sup>[19]</sup> 以及 MBCNN、MSCNN-FA、MSMCNN 进行对比试验。由于神经网络的初始权重是随机生成的,所以单次实验具有偶然性和随机性,本次实验过程中每一种方法做 5 次实验,取平均准确率进行判断,所有算法均使用 Adam 优化器和交叉损失函数 (CrossEntropyLoss)。实验对比结果如表 4 和图 8 所示。

表 4 对比试验结果

Table 4 Comparative test results

模型	信噪比/dB					
	-9	-7	-5	-3	-1	1
WDCNN	78.92	87.84	92.60	95.04	97.25	98.87
Inception	77.63	81.05	85.65	89.62	92.42	94.12
Resnet	83.03	87.39	94.29	95.74	97.55	98.68
MBCNN	74.06	84.69	94.17	95.02	96.45	98.62
MSCNN-FA	79.97	88.16	91.21	93.49	96.11	99.60
MSMCNN	77.02	90.26	91.35	95.40	96.09	99.02
本模型	89.17	94.52	97.50	98.80	99.68	99.89

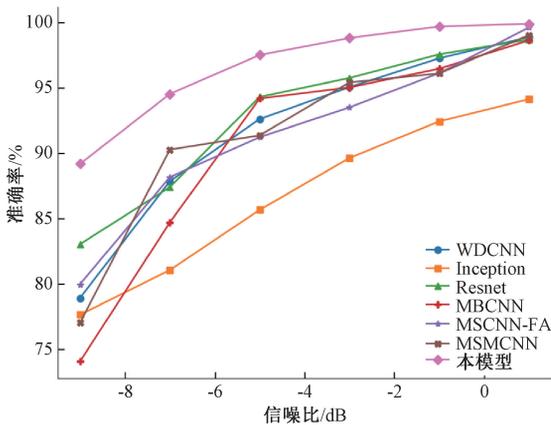


图 8 噪声模型对比实验

Fig. 8 Noise model comparison experiment

本文方法相较于其他方法具有更高的实验准确率。WDCNN 的宽卷积核结构在信噪比较低时,容易遗漏细节特征,导致其抗噪能力较弱。而本模型结合了更加深度的卷积,能够在复杂噪声条件下提取更精细的信号特征,从而在低信噪比下表现突出。Inception 的多尺度卷积结构在处理图像数据时表现卓越,但在噪声较大的时序信号中,可能导致对有效信号的分辨力降低。相比之下,本模型在高信噪比条件下表现更为优越。ResNet 依赖于深层残差连接,可以提取到更加复杂的特征,因此在中高信噪比下表现较好。然而,深层网络在处理噪声时可能会出现信息冗余,导致性能下降。MBCNN 在中高信比时表现较好,但在低信噪比下,准确率明显低于本文方法的。这说明,虽然 MBCNN 在多分支结构下能够对部分噪声进行抑制,但在噪声强度较高的环境下,其多分支卷积可能导致特征提取的

有效性下降。MSCNN-FA 通过特征对齐技术在复杂环境下具有一定优势。在高信噪比条件下,其准确率接近本文方法,但在低信噪比时,其准确率有所下降。这可能是由于特征对齐模块在噪声较强的信号中对噪声特征的对齐效果不如对有效特征的强化效果,从而降低了模型在噪声环境下的鲁棒性。MSMCNN 在高信比下表现较为稳定。然而,在低信噪比条件下,其准确率低于本文方法。这表明,尽管 MSMCNN 的多尺度混合卷积设计可以增强对多样化信号特征的捕获能力,但在强噪声环境中,其对不同尺度特征的混合可能导致噪声特征的放大或融合特征的模糊化,从而降低模型对关键特征的提取能力。相比之下,本文方法通过引入更深的卷积结构、多维度协同决策以及注意力机制,在低信噪比和高信噪比条件下均表现优越。

## 4 结 论

针对传统卷积神经网络,本文提出了一种结合多尺度卷积与残差连接的 ResNet-MACNN 模型,用于轴承故障诊断。该模型使用 SE 块和 ECA 注意力机制增强了特征提取的有效性,并通过多尺度卷积层捕捉信号中的不同尺度特征。同时,模型利用残差连接减少维度方面的特征丢失。通过实验验证,本模型在凯斯西储大学滚动轴承数据集上表现出优异的诊断性能,尤其在噪声环境下依然能保持较高的准确率,通过消融实验,可以看出每个模块都对性能提升有着不同的贡献。而通过对比 WDCNN、Inception、ResNet、MBCNN、MSCNN-FA 和 MSMCNN,本模型在处理复杂噪声和高信噪比条件下展现出了更强的适应能力和特征提取能力,具备更高的准确率、抗噪能力和稳定性。

## 参考文献

- [1] WANG J, MA Y, ZHANG L, et al. Deep learning for smart manufacturing: Methods and applications[J]. Journal of Manufacturing Systems, 2018, 48:144-156.
- [2] NAM H, HAN B. Learning multi-domain convolutional neural networks for visual tracking[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016: 4293-4302.
- [3] 沈启敏, 贾月静, 程艳. 改进 MSCNN-ECA 的轴承故障诊断方法研究[J]. 重庆理工大学学报(自然科学), 2024, 38(7):180-187.  
SHEN Q M, JIA Y J, CHENG Y. Research on bearing fault diagnosis method with improved MSCNN-ECA[J]. Journal of Chongqing Polytechnic University(Natural Science), 2024, 38(7):180-187.
- [4] 徐紫薇, 李彦锋, 黄洪钟, 等. 基于 MSCNN-BiGRU 的轴承故障诊断模型[J]. 质量与可靠性, 2024(4):16-24.  
XU Z W, LI Y F, HUANG H ZH, et al. Bearing fault diagnosis model based on MSCNN-BiGRU[J]. Quality and Reliability, 2024(4):16-24.
- [5] 张玺君, 尚继洋, 余光杰, 等. 基于注意力的多尺度卷积神经网络轴承故障诊断[J]. 吉林大学学报(工学版), 2024, 54(10):3009-3017.  
ZHANG X J, SHANG J Y, YU G J, et al. Attention-based multi-scale convolutional neural network bearing fault diagnosis [J]. Journal of Jilin University (Engineering Edition), 2024, 54(10):3009-3017.
- [6] 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 Z F, JIN J T, LI CH. A rolling bearing fault diagnosis method based on multi-scale convolutional neural network [J]. Vibration and Shock, 2021, 40(18):212-220.
- [7] 张家安, 邓强, 马增强, 等. 基于 IMHSA-MSCNN-BiLSTM 的风机轴承故障诊断[J]. 电子测量技术, 2024, 47(7):170-176.  
ZHANG J AN, DENG Q, MA Z Q, et al. Fault diagnosis of fan bearings based on IMHSA-MSCNN-BiLSTM [J]. Electronic Measurement Technology, 2024, 47(7):170-176.
- [8] WANG G X, ZHANG M, LEI X, et al. A multi-branch convolutional transfer learning diagnostic method for bearings under diverse working conditions and devices[J]. Measurement, 2021, 182: 109627.
- [9] CHEN J, HUANG R, ZHAO K, et al. Multiscale convolutional neural network with feature alignment for bearing fault diagnosis[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-10.
- [10] HE Y, CHEN J, ZHOU X, et al. In-situ fault diagnosis for the harmonic reducer of industrial robots via multi-scale mixed convolutional neural networks[J]. Journal of Manufacturing Systems, 2023, 66: 233-247.
- [11] 张瑞博, 李凌均. 基于注意力机制与 Inception-ResNet 的轴承故障诊断方法[J]. 电子测量技术, 2023, 46(21):107-113.  
ZHANG R B, LI L J. Bearing fault diagnosis method based on attention mechanism and inception-ResNet[J]. Electronic Measurement Technology, 2023, 46(21): 107-113.
- [12] 张菀, 张秦瑀, 贾民平, 等. 多传感器融合和 MHA-LSTM 的电机轴承剩余寿命预测[J]. 仪器仪表学报, 2024, 45(3):84-93.  
ZHANG W, ZHANG T Y, JIA M P, et al. Residual life prediction of motor bearings by multi-sensor fusion and MHA-LSTM [J]. Chinese Journal of Scientific Instrument, 2024, 45(3):84-93.
- [13] 车鲁阳, 高军伟, 付惠琛. 基于多通道融合的滚动轴承剩余寿命预测[J]. 电子测量与仪器学报, 2023, 37(12):225-233.  
CHE L Y, GAO J W, FU H CH. Residual life prediction of rolling bearings based on multi-channel fusion [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(12):225-233.
- [14] HU J, SHEN L, SUN G, et al. Squeeze-and-excitation networks[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2018:7132-7141.
- [15] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2020.
- [16] HE K M, ZHANG X Y, REN SH Q, et al. Deep residual learning for image recognition [C]. IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [17] 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: 100-131.
- [18] 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.
- [19] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2015: 1-9.

## 作者简介

李强, 硕士研究生, 主要研究方向为故障诊断。

E-mail: liqiang1232022@163.com

黄民, 博士, 教授, 主要研究方向为机器人与智能感知。

E-mail: huangmin@bistu.edu.cn

马超(通信作者), 博士, 副研究员, 主要研究方向为信号处理。

E-mail: mach2006@126.com