

# 改进注意力机制的滚动轴承故障诊断方法研究

肖安<sup>1</sup>, 李开宇<sup>1</sup>, 范佳能<sup>1</sup>, 仲志强<sup>2</sup>, 贾银亮<sup>1</sup>

(1. 南京航空航天大学自动化学院, 南京 211100; 2. 南瑞集团有限公司, 南京 211106)

**摘要:** 针对滚动轴承在实际工作环境中噪声较大和负载变化的问题, 提出一种基于双注意卷积机制的残差神经网络 (DACM\_ResNet, double attention convolution mechanism ResNet) 轴承故障诊断方法; 首先, 对滚动轴承振动信号进行短时傅里叶变换 (STFT, short-time fourier transform) 并使用伪彩色处理得到三通道图像数据; 然后, 对残差神经网络在轴承故障诊断上进行研究, 在残差单元的卷积层之后, 使用 DACM 模块, 将残差特征在通道和空间维度上进行进一步提取, 最后, 在凯斯西储大学 (CWRU) 数据集上进行试验验证, 试验结果表明所提出的方法在噪声环境下及负载变化时, 平均诊断准确率达到 98% 以上, 说明所提出的模型有较好的鲁棒性。

**关键词:** 轴承故障诊断; 短时傅里叶变换; 伪彩色处理; 双注意卷积机制模块; 残差网络

## Research on Fault Diagnosis Method of Rolling Bearing with Improved Attention Mechanism

XIAO An<sup>1</sup>, LI Kaiyu<sup>1</sup>, FAN Jianeng<sup>1</sup>, ZHONG Zhiqiang<sup>2</sup>, JIA Yinliang<sup>1</sup>

(1. College of Automation Engineering, Nanjing University of Aeronautics and Astronautics, Nanjing 211100, China;

2. NARI Group Corporation, Nanjing 211106, China)

**Abstract:** Aiming at the problems of high noise and load changes in actual working environments of rolling bearings, a bearing fault diagnosis method based on double attention convolution mechanism (DACM)\_ResNet is proposed. Firstly, a short-time Fourier transform (STFT) is performed on the vibration signal of rolling bearings, and a pseudo-color processing is used to obtain three-channel image data. Then, the residual neural network is studied on the bearing fault diagnosis. After the convolution layer of the residual block, the DACM module is used to further extract the residual features in the channel and spatial dimensions, and the connection between the residual and input is established. Finally, the experiments are verified on the dataset in Case Western Reserve University (CWRU), and the test results show that the proposed method has an average accuracy of over 98% under the noise environment and load changes, indicating that the proposed model has a good robustness of noise.

**Keywords:** bearing fault diagnosis; STFT; pseudo-color processing; dual attention convolution mechanism; ResNet

## 0 引言

目前在旋转机械设备中, 滚动轴承是易损部件之一, 对轴承的诊断是目前研究的热点<sup>[1]</sup>。在传统的轴承故障诊断中, 对采集到的振动信号使用小波变换、经验模态分解等信号处理技术, 获取故障信号特征<sup>[2]</sup>, 但这些方法只是对信号进行了处理, 并未得到确切的故障诊断结果。

近年来, 在智能故障诊断领域, 基于数据驱动的方法逐渐成为主流<sup>[3]</sup>, H. S. Kumar 等<sup>[4]</sup>采用 KNN 分类器和经验模态分解进行了故障诊断研究。Song 等<sup>[5]</sup>使用经验模态和小波变换相结合的方式, 将振动信号进行分解, 从而实现了对滚子轴承的故障诊断。基于数据驱动的方法虽然具有较好的诊断性能<sup>[6]</sup>, 但依赖于先验知识和经验, 对于不同的故障类型所使用的方法也不一致。

基于深度学习的方法在轴承故障诊断中的快速发展<sup>[7]</sup>, 解决了传统方法的不足。Wang 等<sup>[8]</sup>将轴承的一维振动信号

转换为二维灰度图像, 作为卷积神经网络 (CNN) 的输入, 在不同工况下的轴承故障诊断下取得了较好的效果。Gao 等<sup>[9]</sup>提出一种新的弱故障特征提取与诊断方法, 该方法由 LSTM 和多通道连续小波变换 (MCCWT) 构成, 在轴承弱故障特征的情况下进行诊断。Chen 等<sup>[10]</sup>提出一种基于自编码器的径向神经网络轴承故障诊断方法, 提高了在噪声中进行诊断的准确率。Liang 等<sup>[11]</sup>使用残差网络进行网络层的融合。虽然深度学习在故障诊断领域取得了较大的成功, 但对于轴承诊断方面仍存在一些不足<sup>[12-13]</sup>, 对于深度学习来说, 网络结构越深, 意味着能够提取到的特征就越多, 但同时带来的训练参数也越多, 训练时梯度爆炸和消失的问题, 同时无法对存在噪声的信号进行精确诊断<sup>[14]</sup>。

针对以上问题, Sanghyun Woo 等<sup>[15]</sup>人提出了卷积注意力机制模块 (CBAM, convolutional block attention module), 该模块沿着两个单独的维度 (通道和空间) 依次推断注意力图, 然后将注意力图乘以输入特征图, 以进行自适

收稿日期: 2022-11-23; 修回日期: 2023-02-28。

作者简介: 肖安 (1998-), 男, 硕士研究生。

引用格式: 肖安, 李开宇, 范佳能, 等. 改进注意力机制的滚动轴承故障诊断方法研究[J]. 计算机测量与控制, 2023, 31(11): 11-30.

应特征细化, 并且 CBAM 模块是一个轻量级通用模块, 可无缝集成到任何网络架构中。这能够提取在复杂环境中收集到的轴承故障信号的深层特征, 提高诊断的准确率。李俊等<sup>[16]</sup>针对不平衡数据集进行故障诊断的研究存在局限性, 提出了一种将基于双阶段注意的递归神经网络 (DA-RNN) 和卷积块注意模块 (CBAM) 相结合的滚动轴承故障诊断模型。该方法相比较于其他智能诊断方法, 具有较高的性能, 表明该方法在不平衡数据条件下的滚动轴承故障诊断中具有广阔的应用前景。田科位等人<sup>[17]</sup>将残差神经网络进行改进并融合注意力机制, 对变负载下的轴承进行识别。胡向东<sup>[18]</sup>等人将挤压注意力机制与 ResNeXt 结合, 对存在噪声的轴承信号进行诊断, 能够更好的集中轴承的故障特征。

本文受卷积注意机制模块的启发, 将通道注意力与空间注意力和残差网络进行融合, 并对通道注意机制进行改进, 将传统的通道注意机制模块中的全连接层改为卷积层, 通过卷积层的局部特征提取, 获取到更多的轴承故障特征, 将输入与输出之间的关系进行联系, 提出了一种新的诊断方法, 主要内容如下:

- 1) 使用 STTF 技术得到灰度图像后采用伪彩色处理技术将单通道图像数据转换为三通道图像;
- 2) 对 DACM 模块的位置和数量进行研究, 构建了基于 DACM\_ResNet 的故障诊断模型;
- 3) 将提出的 DACM\_ResNet 模型用于噪声和变负载环境下诊断。

## 1 理论基础

### 1.1 时频图像生成方法

在一般的滚动轴承故障诊断系统中<sup>[19]</sup>, 数据采集系统采集到的原始振动信号都是一维时变非稳态信号, 而对于深度神经网络来说, 处理二维图像来说更得心应手<sup>[20]</sup>。本方法采用 STFT 来生成二维时频图像<sup>[2]</sup>, 这既能够保持信息含量, 又可以保证信号处理的快速。信号  $x(t)$  与  $\omega(t)$  乘积后再进行傅里叶变换, STFT 的定义如下:

$$T_{STFT}(\omega, \tau) = \int_R x(t)\omega(t - \tau)e^{-j\omega t} dt \quad (1)$$

式中,  $x(t)$  为连续信号信号,  $\omega(t)$  为时窗信号。

实际使用 STFT 的离散形式来计算, 如下所示:

$$X[m, k] = \sum_{n=0}^{N-1} x[n]\omega[n - k]\exp(-j\frac{2\pi}{N}mn), \quad m = 0, 1, \dots, N-1 \quad (2)$$

式中, 时窗信号  $\omega(t)$  的宽度为  $N$ ; 序列  $x[k]$  为连续信号  $x(t)$  的采样信号, 采样频率满足香农采样定律。

### 1.2 残差神经网络

He 等<sup>[21]</sup>提出了深度残差网络 (ResNet)。其核心为在网络层中构建残差块, 引入残差元, 残差元的存在有效解决了由于网络层数较深时出现的梯度爆炸和消失问题。

结构原理图如图 1 所示。残差块以  $x$  为输入,  $H(x)$  为输出,  $F(x)$  为残差映射函数。He 等<sup>[21]</sup>通过恒值传递的方式

来搭建深层次网络, 当通过快捷连接时, 则输出值为输入值  $x$ , 最终输出如式 (3) 所示; 当存在不同维度的输入输出层时, 快捷连接需要使用一个卷积核大小为  $1 \times 1$  的卷积层来匹配输出结果的维度, 从而得到快捷连接的输出  $H(x)$ , 最终输出结果如式 (4) 所示:

$$H(x) = F(x) + x \quad (3)$$

$$F(x) = H(x) - x \quad (4)$$

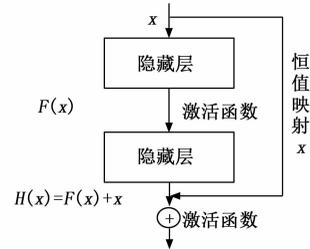


图 1 残差块结构图

### 1.3 注意力机制

滚动轴承的不同故障模式, 采集到的故障特征是不同的, 对于一些幅值较高的一维振动信号特征, 在诊断时是比较准确的, 而对于与幅值类似的噪声信号, 诊断会存在较大的干扰。而注意力机制的出现, 可使模型获得更多的不同特征的权重系数, 能够在一定程度上避免这种诊断干扰。因此本文受 CBAM 的启发, 将通道注意力机制与空间注意力机制进行结合, 并对通道注意力机制进行改进, 将原有的多层感知机进行替换, 换成两个卷积层进行权值共享, 提出了新的双注意卷积机制模块 (DACM), 与残差神经网络进行融合, 同时对这两个维度上的特征进行提取。该模块和 CBAM 一样, 能够直接运用到现有的网络架构中, 减少训练的时间和参数。

首先对于通道注意机制, 为了更高效的计算通道注意力特征, 要做的就是压缩特征图的空间维度, 通过最大池化层和平均池化层学习目标的程度信息, 然后将该特征送入到一个共享的多层感知机 (MLP) 网络中产生最终的通道注意力特征图  $M_c \in \mathbf{R}^{C \times 1 \times 1}$ , 为了降低计算参数, 在 MLP 中采用了一个降维系数  $r$ ,  $M_c \in \mathbf{R}^{C/r \times 1 \times 1}$ 。

综上, 通道注意机制可表示为下式:

$$M_c(F) = \sigma(MLP(Avg\ pool(F)) + MLP(max\ pool(F))) = \sigma(W1(W0(F_{avg}^c)) + W1(W0(F_{max}^c))) \quad (5)$$

之后进入空间注意机制, 来生成空间注意力特征图, 由式 (5) 得出, 在通道注意力机制层经过平均池化和最大池化后, 之后进行这两个特征的融合, 最后在拼融合的特征图上, 使用卷积操作来产生最终的空间注意力特征图:

$$M_s(F) \in \mathbf{R}^{H \times W} \quad (6)$$

和通道注意力一样, 使用两种池化方法来产生 2D 特征图:

$$F_{avg}^s \in \mathbf{R}^{1 \times H \times W} \quad (7)$$

$$F_{max}^s \in \mathbf{R}^{1 \times H \times W} \quad (8)$$

最终空间特征如下式 (9) 所示:

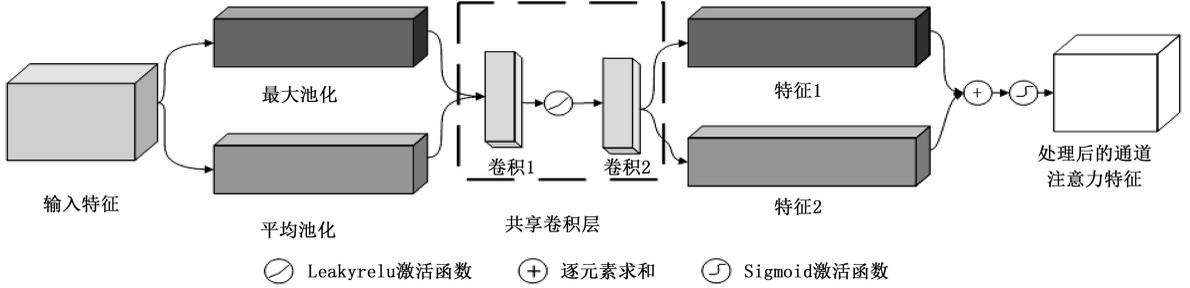


图 2 通道卷积注意机制结构图

$$M_s(F) = \sigma(f^{7 \times 7}([\text{AvgPool}(F); \text{MaxPool}(F)])) = \sigma(f^{7 \times 7}(F_{avg}^s; F_{max}^s)) \quad (9)$$

最终给定的 CBAM 依次推导出二维通道注意力映射  $M_c \in \mathbf{R}^{C \times 1 \times 1}$  和二维空间注意力映射  $M_s \in \mathbf{R}^{1 \times 1 \times H \times W}$ ，整个过程可以总结为如下式：

$$F' = M_c(F) \otimes F \quad (10)$$

$$F'' = M_s(F') \otimes F' \quad (11)$$

其中： $\otimes$ 表示基于元素的乘法。在乘法过程中，通道注意力值沿着空间维度传播，反之亦然。 $F''$ 为最终得到的特征。

## 2 基于 DACM\_ResNet 的算法模型

### 2.1 基于 DACM 的残差单元结构

对于深层网络结构，会存在训练时梯度消失，同时错误率也会上升。在网络中引出残差块，不仅能够维持网络的深度，也能减少模型的参数量，这使得提取复杂且带有严重噪声的轴承振动信号成为了可能，注意力机制能够对不同通道进行权重分配。为此提出了带有双注意卷积机制的残差块。在双注意卷积机制模块中，首先是经过通道卷积注意机制模块，在传统的通道注意力机制中，是使用全连接层将最大池化层与平均池化层进行链接，而在本文中，则是使用卷积层将这两个进行连接，通过卷积操作，可得到一组新的特征。其具体结构如图 2 所示，假设经过最大池化和平均池化之后的特征图为  $F_{max}^c, F_{avg}^c$ ，在经过共享卷积层之后进行逐元素求和并进入到激活函数中，可得到最后的通道注意力特征图如下式所示，

$$F_c(F) = \sigma\left\{\sum_{i=1}^2 \text{conv}_i(\text{maxPool}(F)) + \sum_{j=1}^2 \text{conv}_j(\text{avgPool}(F))\right\} = \sigma\left\{\sum_{i=1}^2 \text{conv}_i F_{max}^c + \sum_{j=1}^2 \text{conv}_j F_{avg}^c\right\} \quad (12)$$

其中： $\sigma$ 为 Sigmoid 激活函数，在经过两次卷积后进行逐元素求和，最后通过激活函数进行输出最后的通道卷积注意机制特征图  $F_c(F)$ 。

经过通道卷积注意机制得到的特征图作为输入直接送到空间注意机制模块中，空间注意机制模块的结构图如图 3 所示。

相比于传统的残差块，改进的部分为在经过两次卷积和批量归一化层之后，进入到 DACM 注意力机制模块，之后将结果进行输出。根据残差块计算公式：

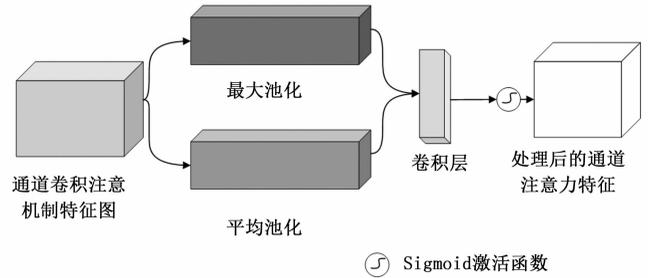


图 3 空间注意机制结构图

$$F_a = F_c + x \quad (13)$$

式中， $F_c$ 为经过 DACM 模块之后的特征，这使得残差块能够同时获得经过双注意卷积之后的特征和快捷连接的输入值  $x$ 。改进残差块模型如图 4 所示。

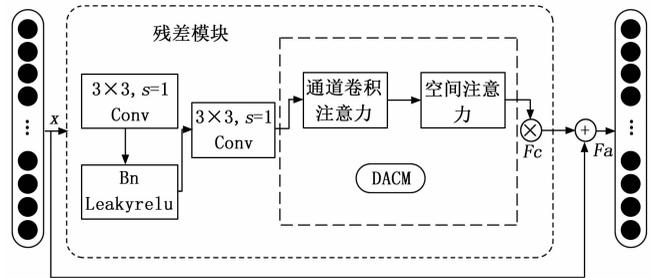


图 4 改进残差块结构图

### 2.2 算法框架

本文所提出的基于 DACM\_ResNet 的诊断模型主要由三部分组成，包括原始信号收集和样本的制作、数据预处理和 DACM\_ResNet 网络结构，最后进行轴承故障类型的输出：

1) 原始信号收集和样本的制作：通过加速度传感器收集轴承的振动信号，按照采样频率进行样本分割，采样频率为  $f_s$ ，则样本为在这个周期内采集到时间序列，样本规模为  $n = f_s/v$ ， $v$ 为电机转速。以 12 k 采样率为例，电机转速理论值为 1 772 rpm，则样本规模为  $60/1\ 772 \times 12\ 000 = 406.67$ ，所以将 400 个数据点作为一个样本；

2) 数据预处理：将分割好的一维数据进行 STFT，得到二维数组，然后运用伪彩色处理技术进行通道变换，得到三通道的彩色图片，得到的样本如图 5 所示，最后进行训练集和测试集的划分；

3) DACM\_ResNet 网络结构：首先是将信号输入一个较

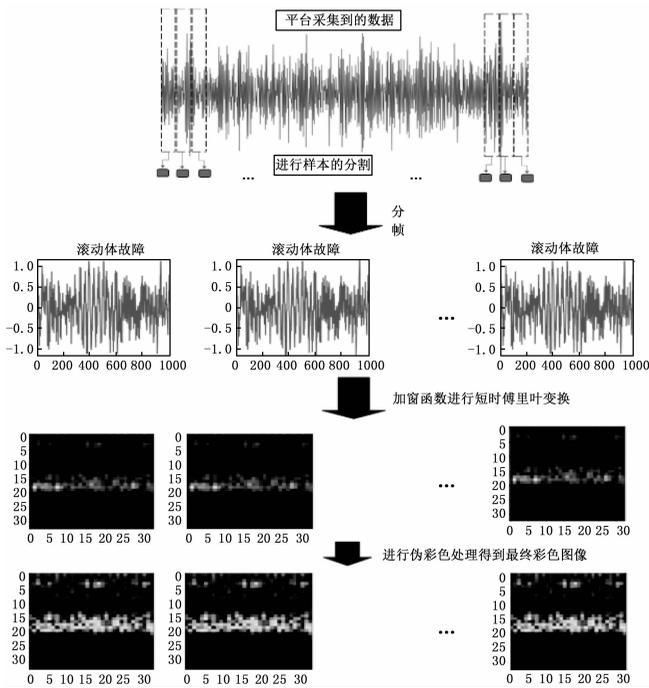


图 5 数据预处理图

大的卷积核中, 大卷积核具有较大的感受野, 可获取较多的特征, 然后经过最大池化层, 之后经过带有 DACM 模块的残差块和平均池化层, 最终通过全连接层输出故障类别, 得出诊断结果。

基于 DACM\_ResNet 的诊断模型框架如图 6 所示。

### 3 实验验证

#### 3.1 实验参数设置

实验所用深度学习框架为 pytorch, 电脑配置为 AMD3700x, 16 g 内存, GTX960, Windows10 操作系统。对于神经网络而言, 需要对参数进行初始化设置。通过对文献中的代码进行分析, 选取初始学习率为 0.001, 使用 Adam 进行网络参数的优化, 即在训练过程中会进行学习率的调整。每一次训练的样本数为 64, 其他一些参数则保持不变。

CWRU 数据集作为公开的数据集, 本实验中也采取该数据集进行验证。实验装置如图 6 第一部分 (原始信号收集) 中所示。数据主要由加速度传感器在 4 种负载条件 (0、1、2 和 3 hp) 下收集, 采样率为 12 kHz。根据负载的不同, 电机转速在 1 730~1 797 rpm 之间变化。

本次实验中使用的振动信号是电机工作在 4 种不同负载下采集的。同时存在以下 4 种工作状态: 1) 正常状态; 2) 外圈故障; 3) 滚动体故障; 4) 内圈故障。这 3 种故障方式通过人为造成, 一般是通过放电的形式对轴承造成微小的损伤。故障直径分别为 0.117 8 mm、0.355 6 mm 和 0.533 4 mm。因此, 凯斯西储大学轴承数据集包含 4 种负载下共计 10 类数据。数据集的详细描述如表 1 所示。为了便于分类, 将故障位置和故障大小不同的 10 种健康状况分别设置为类别标签 0~9。具体如表 1 所示。

表 1 CWRU 轴承故障分类及标签值

标签值	故障类型	故障深度
0	正常	0
1	内圈故障 1	0.117 8 mm
2	滚动体故障 1	0.117 8 mm
3	外圈故障 1	0.117 8 mm
4	内圈故障 2	0.355 6 mm
5	滚动体故障 2	0.355 6 mm
6	外圈故障 2	0.355 6 mm
7	内圈故障 3	0.533 4 mm
8	滚动体故障 3	0.533 4 mm
9	外圈故障 3	0.533 4 mm

对于 CWRU 数据集的振动信号, 按负载 0, 负载 1, 负载 2, 负载 3 制作成数据集 A、B、C、D。并将 A、B、C、D 合并得到一个总的数据集 E。之后进行样本的划分, 训练集占 80%, 测试集则为 20%, 其中在训练集中按照同样的比例划分, 得到四分之一的验证。最终得到的数据集如表 2 所示。

表 2 CWRU 样本数量表

样本	故障深度	负载 0	负载 1	负载 2	负载 3	总计
正常	—	608	1 208	1 211	1 210	4 237
内圈故障	0.117 8 mm	302	303	304	305	1 214
	0.355 6 mm	303	303	303	304	1 213
	0.533 4 mm	304	302	303	303	1 212
外圈故障	0.117 8 mm	303	305	304	303	1 215
	0.355 6 mm	303	304	305	304	1216
	0.533 4 mm	305	303	303	302	1 213
滚动体故障	0.117 8 mm	305	303	304	303	1 215
	0.355 6 mm	303	304	303	303	1 213
	0.533 4 mm	303	303	303	305	1 214
总计	—	3 339	3 938	3 943	3 942	15 162
数据集		A	B	C	D	E

#### 3.2 模型参数设置

根据残差神经网络相关结构, 针对使用了短时傅里叶变换与伪彩色处理相结合的数据预处理方法, 对第一层的卷积层的卷积核进行改进, 选取了 7×7 大小的卷积核, 经过多次实验对比, 确定了如表 3 的模型参数。

表 3 模型参数设置

网络层	层参数
卷积层	filters=64, kernel_size=7, strides=2
池化层	filters=64, kernel_size=2, strides=2
残差块 1	filters=64, kernel_size=3, strides=2
	filters=64, kernel_size=3, strides=2 DACM 模块
残差块 2	filters=128, kernel_size=3, strides=2
	filters=128, kernel_size=3, strides=2 DACM 模块
残差块 3	filters=256, kernel_size=3, strides=2
	filters=256, kernel_size=3, strides=2 DACM 模块
残差块 4	filters=512, kernel_size=3, strides=2
	filters=512, kernel_size=3, strides=2 DACM 模块

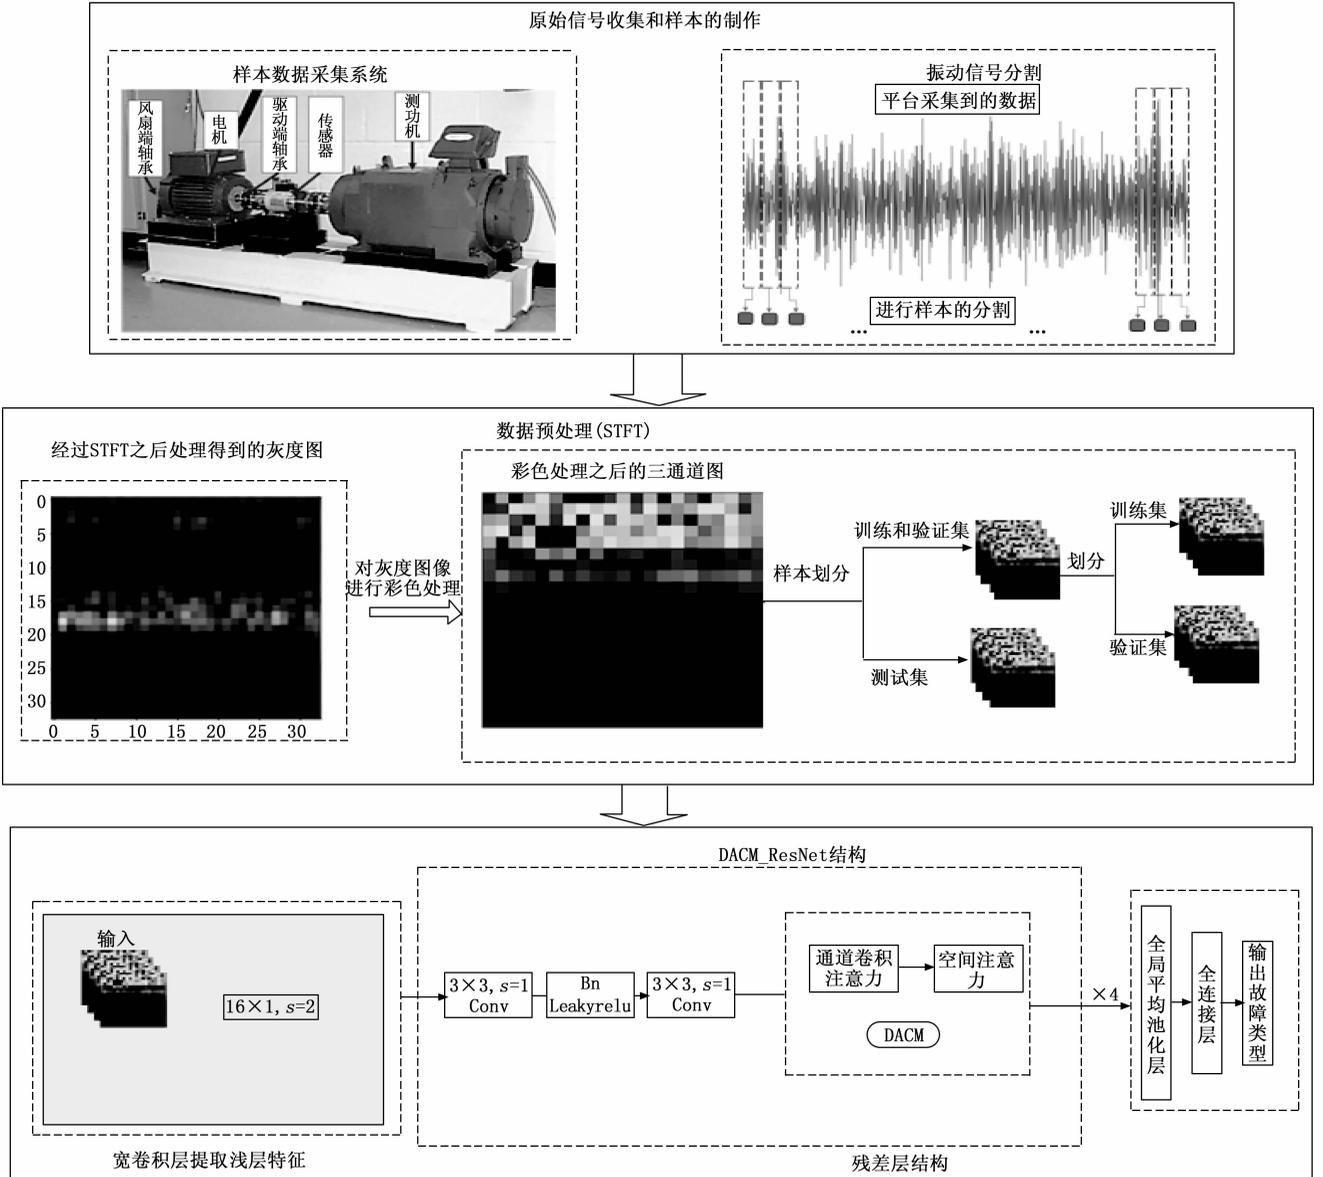


图 6 整体算法结果框图

### 3.3 在原始信号下进行模型测试

#### 3.3.1 原始信号下模型诊断结果

将原始信号经过数据预处理之后作为样本分别送入到原残差神经网络模型和基于双注意卷积机制的残差神经网络模型中，迭代次数为 100，得到其训练准确率如图 7 所示。

从图中可以看出，带有双卷积注意机制的残差神经网络模型的训练准确率均高于原有的残差神经网络和添加 CBAM 模块的残差神经网络，其中准确率达到了 99.5% 以上。而对于添加的 CBAM 模块，虽然其准确率比原始 ResNet 要高，但其稳定性不够。

使用 VGG16、VGG19、CNN、LeNet 和 ResNet 等模型在原始信号下进行对比试验。在构建好的数据集 A、B、

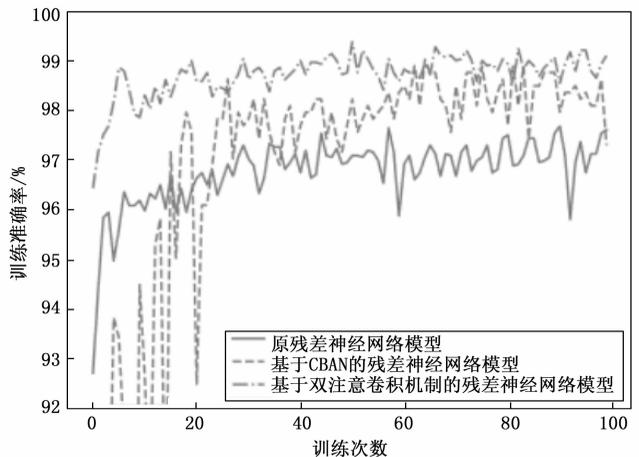


图 7 训练准确率图曲线对比

C、D 和 E 进行实验。实验结果如表 4 所示, 每次实验分别进行 10 次, 然后取其平均值。可以看出, 相比于其他模型, ResNet 的诊断准确率较高。而对于 LeNet, 该模型在数据集 C 上准确率较高, 但在其他数据集上却表现的没那么优异, 说明其在轴承故障诊断中稳定性不够高, 而对于 DACM\_ResNet 模型, 其在每个数据集上的诊断率均高于 99%, 相比于 ResNet 提高了 2.72%, 并且平均诊断率为 99.65%, 这体现了本文所提出的基于双注意卷积机制的残差神经网络在轴承故障诊断上的优越性。

表 4 各模型的试验结果

模型	数据集 A	数据集 B	数据集 C	数据集 D	数据集 E	平均
VGG16	79.03%	90.06%	91.25%	92.36%	93.23%	89.19%
VGG19	93.73%	88.86%	94.62%	88.95%	90.63%	91.36%
CNN	95.88%	95.19%	94.92%	95.88%	96.49%	95.67%
LeNet	96.89%	95.41%	98.19%	96.32%	97.35%	96.23%
ResNet	96.43%	96.78%	97.12%	96.99%	97.32%	96.93%
DACM_ResNet	99.92%	99.60%	99.83%	99.42%	99.47%	99.65%

### 3.3.2 DACM\_ResNet 与传统滚动轴承故障诊断算法的对比

将所提方法与传统滚动轴承故障诊断算法进行对比, 选取数据集 E 作为本次实验的样本集, 实验结果如表 5 所示, 所选取的传统方法包括合粒子群参数优化的支持向量机 (SVM-PSO)、极限学习机 (ELM)、 $k$  最近邻 (KNN), 对于 SVM-PSO, 选取加速因子  $c_1 = 1.5$ ;  $c_2 = 1.7$ , 粒子数设置为 20, 迭代次数为 200 次, 对于 ELM, 隐藏层神经元数目  $L$  为 2 000, 惩罚系数  $C$  为 0.5, 对于 KNN 模型, 选取初始值  $k = 5$ 。

表 5 DACM\_ResNet 与传统方法实验结果对比

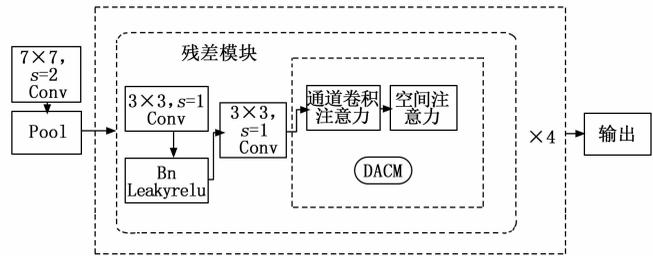
算法	平均准确率/%
DACM_ResNet	99.47
SVM-PSO	98.75
ELM	96.60
KNN	97.25

从实验结果可看出, 传统方法在数据集 E 上也有着良好的诊断效果, 但相比于 DACM\_ResNet, 还略微的低一些。

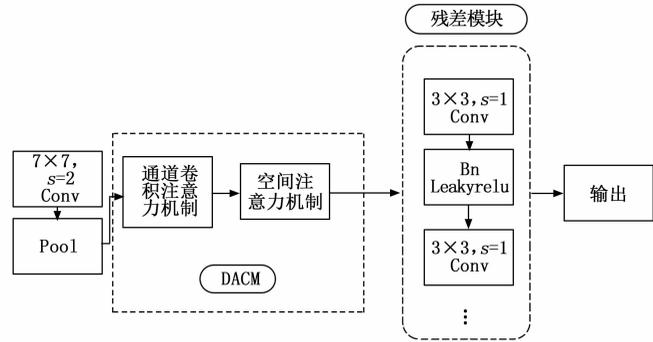
### 3.3.3 在 ResNet 不同位置加入 DACM 模块

同时为验证注意力模块位置和数量对实验的影响, 对位置而言, 将 DACM 模块插入到进入残差块之前的主干网络中和残差块中。对于数量而言, 将 DACM 模块插入到主干网络中, 分别是进入残差模块之前和残差模块之后, 各插入一个 DACM 模块, 具体结构如图 8 所示。

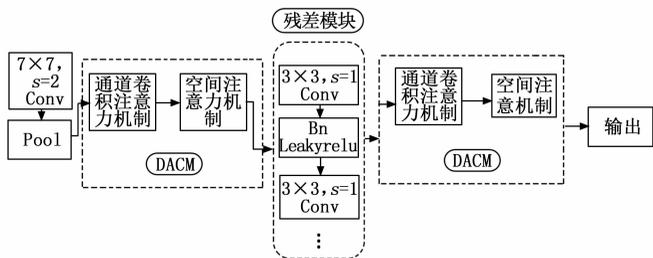
对比 VGG16、VGG19、CNN 和 LeNet, 选取 ResNet 添加 DACM 模块, 对不同位置和数量的 DACM 模块的试验结果如图 9 所示, 可以看出, DACM 模块的位置和数量对结果有的较大的影响, 当 DACM 模块加入到残差模块中时,



(a) 将 DACM 嵌入到残差模块中



(b) 将一个 DACM 模块添加到残差模块之前



(c) 将 DACM 模块分别添加至残差模块之前和之后

图 8 不同位置和数量的 DACM 结构图

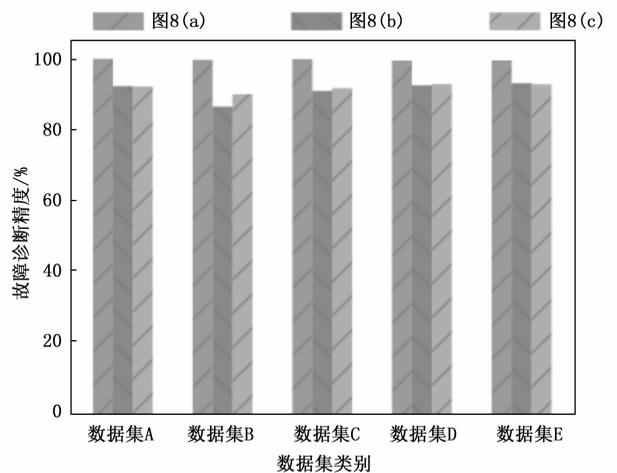


图 9 不同结构与数据集诊断率图

	数据集A	数据集B	数据集C	数据集D	数据集E
图8(a)	99.92%	99.60%	99.83%	99.42%	99.47%
图8(b)	92.27%	86.53%	90.92%	92.50%	93.08%
图8(c)	92.15%	90.01%	91.70%	92.83%	92.79%

诊断的准确率有较大的提升,而在其他位置确存在准确率降低的问题。

### 3.4 噪声环境下模型分类测试

在滚动轴承的实际工作环境中,由于各个部件之间的摩擦和振动,使得采集到的轴承振动信号会存在一定的噪声。在本实验中,我们在数据集中叠加高斯白噪声来模拟在复杂环境下采集到的振动信号。具体来说,我们将不同信噪比(SNR)的噪声信号添加到测试样本中,以构建不同强度的噪声信号。另外需要说明的是,本研究仅在测试样本中添加噪声信号,而不是在训练样本中添加噪声信号,并且通过噪声测试样本评估了所提出方法的抗噪声性。信噪比的定义如下:

$$SNR_{db} = 10\log_{10}(P_{signal}/P_{noise}) \quad (13)$$

其中:  $P_{signal}$  表示原始信号功率,  $P_{noise}$  表示高斯噪声功率。

如图 10 所示,在该图中,展示了高斯白噪声信号,和未加噪声的轴承滚动体故障原始信号,以及两者相加之后带有噪声的滚动体故障信号。可以看出,信号已经被严重污染了,和原始信号相比,几乎没有过多的相似,人眼很难进行分辨。因此,从带有噪声的信号中提取出有效的故障特征,有很大的难度。

在图 11 中,分别为原始正常信号、内圈故障信号、外圈故障信号和滚动体故障信号与叠加高斯噪声的信号图,通过对高斯白噪声的控制,得到了信噪比为 -2 db 的信号。

在本实验中,分别在 A、B、C、D 四个数据集进行测试,并使用 4 个 SNR 的噪声信号 -4, -2, 2, 4 dB 测试

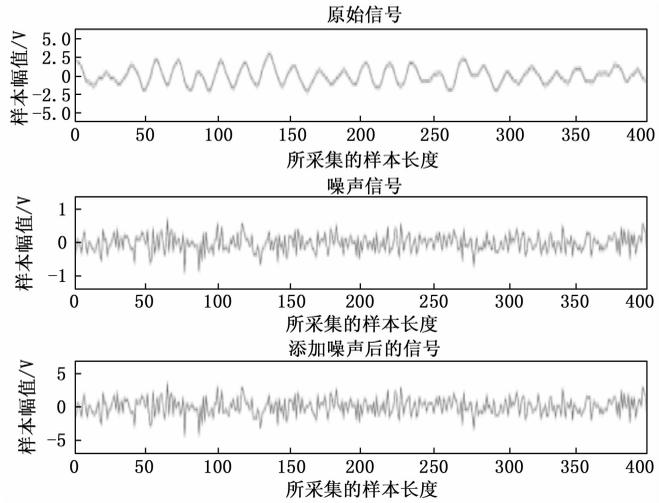


图 10 原始信号、高斯白噪声和叠加噪声后的信号

了所提方法的优越性。实验结果如图 12 所示。

从实验结果的看出, DACM\_ResNet 的识别准确率高于其他比较方法,这表明所提出的方法具有更强的抗噪声性和稳定性。特别是当信噪比为 -4 dB 时, DACM\_ResNet 仍能获得 93.40% 的诊断准确率,比 WDCNN 高 0.75%。这表明 DACM\_ResNet 在强噪声环境下仍具有很大的性能优势,这一特性将极大地增强 DACM\_ResNet 在实际应用中的潜力。相比之下,在残差层中加入了 CBAM 模块,通过 DACM 模块,将残差的通道和空间两个维度上的特征进行集中,得到一个残差上整体的特征表示。然后将得到的特征表示与输入进行融合,最终得到故障特征的提高。

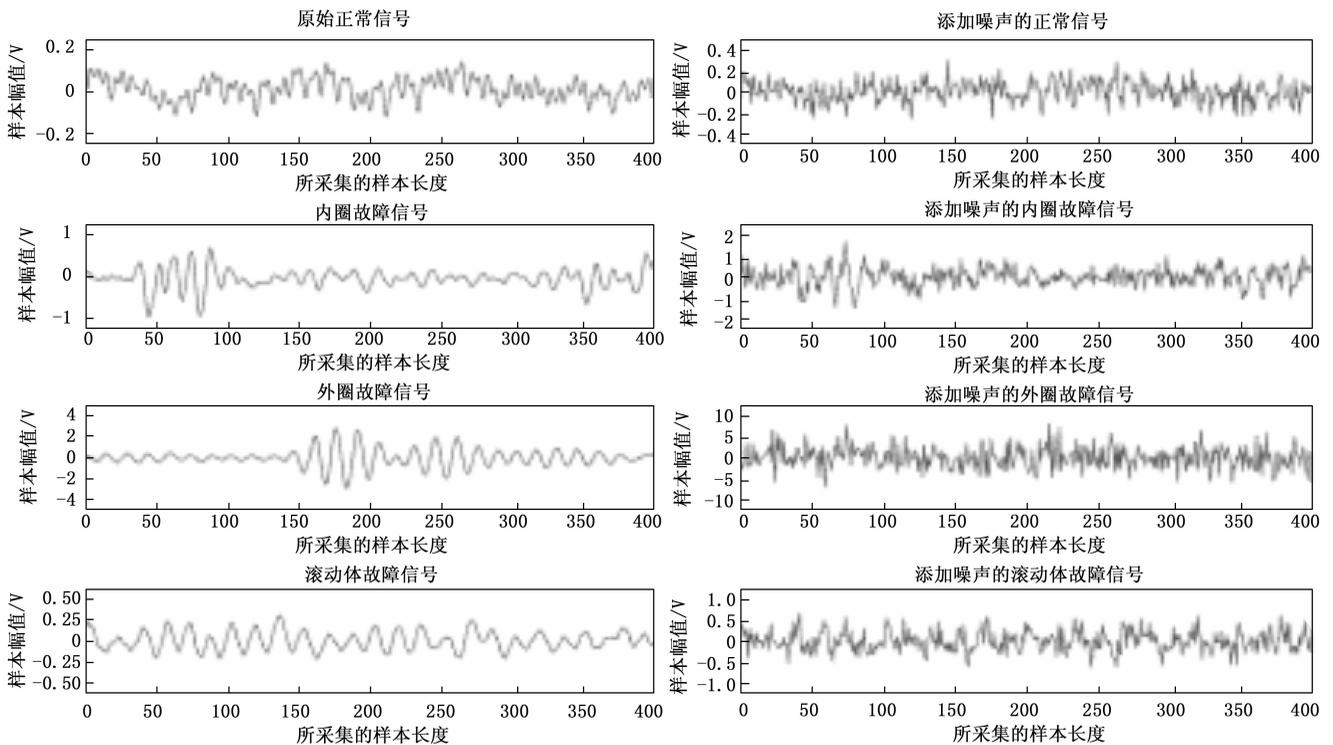


图 11 原始信号和信噪比为 2 db 的信号对比图

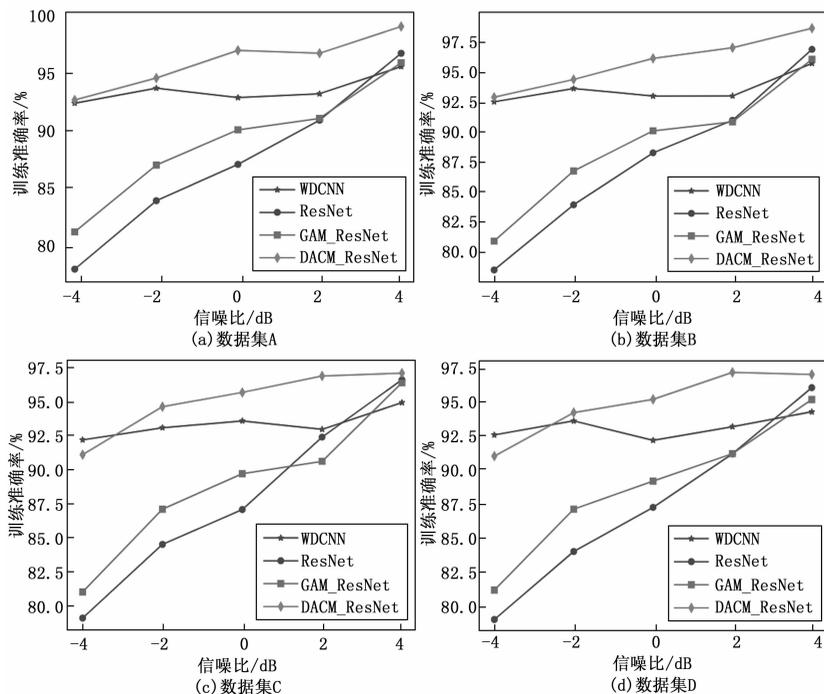


图 12 不同噪声环境下各数据集的识别准确率

### 3.5 不同负载下诊断性能分析

在实际的工作环境中, 轴承往往是工作在不同负载的环境下。将 DACM\_ResNet 分别与 ResNet、WDCNN、GAM\_ResNet 三种模型进行对比, 实验结果如图 13 所示。通过对实验的分析, 本文所 DACM\_ResNet 模型的识别准确率达到 96% 以上。而进行对比的传统模型如 ResNet, 识别率为 84.32%, CNN 的改进版 WDCNN 则为 83.52%, 而其他注意力机制结合的 ResNet 反而更低, 为 81.93%。相比于 DACM\_ResNet, GAM\_ResNet 和 WDCNN 在不同工况下故障识别率不够稳定, 例如 B→A 中 WDCNN 模型的故障识别率达到了 99.6%, 而在 A→C 中的识别率仅仅只有 83.52%, 说明 WDCNN 在工况迁移下泛化能力稍微欠缺。DACM\_ResNet 在所有负载变化中识别率均超过了 98%。这说明所提出的模型在工况迁移下能够保持较稳定的识别率, 这对实际工作环境下具有一定的诊断意义。

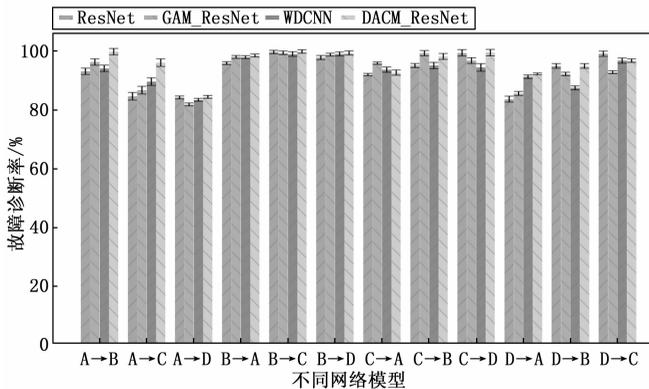


图 13 不同负载下的诊断准确率

将得到的高维数据通过 T-SNE 算法进行降维操作, 降至二维进行可视化操作, 将模型的全连接层提取到的故障特征, 降至二维平面, 并以散点图的方式进行绘制, 如图 14 所示。

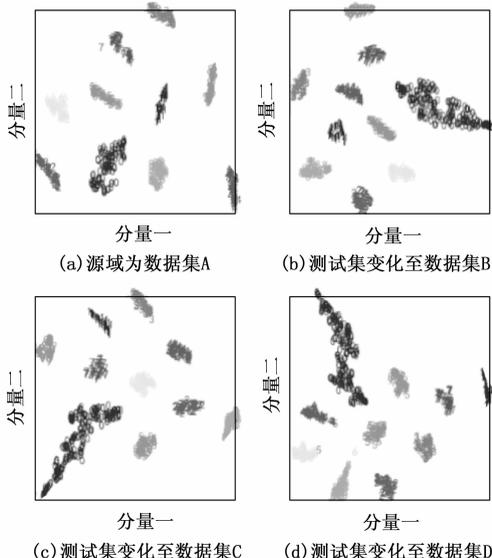


图 14 源域为工况 0 的 DACM\_ResNet 向其他工况变化时的故障特征散点图

从图 14 中可以看出, 通过 DACM\_ResNet 模型, 所有的故障特征均可以较好的进行分类且具有明显的界限。而对于标签为 5, 深度为 0.3556 mm 的滚动体故障存在一些分类混叠的现象, 这也对应了在直方图中 A→D 的测试任务中准确率低下。

### 4 结束语

针对滚动轴承在实际工作环境中噪声较大、收集到的振动信号易被淹没和带负载工况问题, 提出了基于注意力机制的改进残差网络模型。本文得出的结论如下:

本文提出了一种融合 DACM 的残差神经网络模型。经过对 DACM 模块在残差网络中的位置数量的研究, 确定了将 DACM 模块添加在残差块中具有更好的效果, 提升了在噪声背景和变负载下的识别准确率。使用 STFT 将振动信号转换至图像信号, 其次使用伪彩色通道处理技术, 使得模型能够更好的进行训练和测试。在训练过程中, 对训练样本进行加噪处理, 模拟实际环境中存在的噪声问题, 提升了模型在实际应用的可行性。

#### 参考文献:

[1] 曹现刚, 雷卓, 罗璇, 等. 滚动轴承自适应组合状态预测方法研究 [J]. 机床与液压, 2022, 50 (4): 162-166.  
 [2] 李恒, 张氢, 秦仙蓉, 等. 基于短时傅里叶变换和卷积神经网络的轴承故障诊断方法 [J]. 振动与冲击, 2018, 37 (19): 124-131.

- [3] TIWARI P, UPADHYAY S H. Novel self-adaptive vibration signal analysis: Concealed component decomposition and its application in bearing fault diagnosis [J]. *Journal of Sound and Vibration*, London: Academic Press Ltd- Elsevier Science Ltd, 2021, 502: 116079.
- [4] KUMAR H S, MANJUNATH S H. Use of empirical mode decomposition and K- nearest neighbour classifier for rolling element bearing fault diagnosis [C] // *Materials Today-Proceedings*, Amsterdam: Elsevier, 2022, 52: 796-801.
- [5] SONG Y, ZENG S, MA J, et al. A fault diagnosis method for roller bearing based on empirical wavelet transform decomposition with adaptive empirical mode segmentation [J]. *Measurement*, Oxford: Elsevier Sci Ltd, 2018, 117: 266-276.
- [6] 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: 111935.
- [7] PLAKIAS S, BOUTALIS Y S. Fault detection and identification of rolling element bearings with Attentive Dense CNN [J]. *Neurocomputing*, Amsterdam: Elsevier, 2020, 405: 208-217.
- [8] WANG X, MAO D, LI X. Bearing fault diagnosis based on vibro-acoustic data fusion and 1D-CNN network [J]. *Measurement*, Oxford: Elsevier Sci Ltd, 2021, 173: 108518.
- [9] GAO D, ZHU Y, REN Z, et al. A novel weak fault diagnosis method for rolling bearings based on LSTM considering quasi-periodicity [J]. *Knowledge-Based Systems*, Amsterdam: Elsevier, 2021, 231: 107413.
- [10] 陈国成, 张 建, 菅光雷. 基于改进叠加自动编码器轴承智能故障诊断方法 [J]. *噪声与振动控制*, 2022, 42 (1): 156-161.
- [11] LIANG H, CAO J, ZHAO X. Multi-scale dynamic adaptive residual network for fault diagnosis [J]. *Measurement*, Oxford: Elsevier Sci Ltd, 2022, 188: 110397.
- [12] WANG G, ZHANG M, HU Z, et al. Bearing fault diagnosis based on multi-scale mean permutation entropy and parametric optimization SVM [J]. *Journal of Vibration and Shock*, 2022, 41 (1): 221-228.
- [13] SU K, LIU J, XIONG H. A multi-level adaptation scheme for hierarchical bearing fault diagnosis under variable working conditions [J]. *Journal of Manufacturing Systems*, 2022, 64: 251-260.
- [14] 肖 娜, 周孟申. 基于卷积自编码神经网络的航空发动机轴承故障诊断方法研究 [J]. *计算机测量与控制*, 2021, 29 (12): 84-88.
- [15] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional Block Attention Module [C] // V. Ferrari, M. Hebert, C. Sminchisescu, 等. *Computer Vision-ECCV 2018*, Cham: Springer International Publishing, 2018: 3-19.
- [16] Li J, Liu Y, Li Q. Intelligent fault diagnosis of rolling bearings under imbalanced data conditions using attention-based deep learning method [J]. *Measurement*, Oxford: Elsevier Sci Ltd, 2022, 189: 110500.
- [17] 田科位, 董绍江, 姜保军, 等. 基于改进深度残差网络的轴承故障诊断方法 [J]. *振动与冲击*, 2021, 40 (20): 247-254.
- [18] 胡向东, 梁 川. 基于 SE-ResNeXt 的滚动轴承故障诊断方法 [J]. *计算机测量与控制*, 2021, 29 (7): 46-51.
- [19] LI D Z, ZHENG X, XIE Q W, et al. A sequential feature extraction method based on discrete wavelet transform, phase space reconstruction, and singular value decomposition and an improved extreme learning machine for rolling bearing fault diagnosis [J]. *Proceedings of the Institution of Mechanical Engineers Part E-Journal of Process Mechanical Engineering*, London: Sage Publications Ltd, 2018, 232 (6): 635-649.
- [20] 刘 飞, 陈仁文, 邢凯玲, 等. 基于迁移学习与深度残差网络的滚动轴承快速故障诊断算法 [J]. *振动与冲击*, 2022, 41 (3): 154-164.
- [21] HE K, ZHANG X, REN S, et al. Deep Residual Learning for Image Recognition [C] // 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2016: 770-778.
- [22] 沈 龙, 耿 浩, 马 仪, 等. 粗 DEM 辅助的广域 PS-InSAR 数据预处理方法及应用 [J]. *雷达科学与技术*, 2022, 20 (2): 173-180.
- [23] 郭国栋, 龚雁峰, 吴 迪, 等. 引入 HoloLens 进行信息融合与数据挖掘的新型巡检方式及体验 [J]. *中国电力*, 2021, 54 (7): 208-216.
- [24] 盛裕杰, 郭庆来, 刘梦洁, 等. 多源数据融合的用户充电行为分析与充电设施规划实践 [J]. *电力系统自动化*, 2022, 46 (12): 151-162.
- [25] 石宜金, 谭贵生, 赵 波, 等. 基于模糊综合评估模型与信息融合的电力变压器状态评估方法 [J]. *电力系统保护与控制*, 2022, 50 (21): 167-176.
- [26] 石明宽, 赵荣珍. 基于局部质心均值最小距离鉴别投影的旋转机械故障数据降维分析研究 [J]. *振动工程学报*, 2021, 34 (2): 421-430.
- [27] 张小飞, 李宝宝, 曾浩威, 等. 未知互耦影响下的多阵直接定位: 基于子空间数据融合与降维搜索 [J]. *数据采集与处理*, 2022, 37 (6): 1208-1217.
- [28] 周稻祥, 冯 妹. 联合 Gabor 滤波器和核池化特征学习的单样本人脸识别与验证 [J]. *太原理工大学学报*, 2023, 54 (2): 384-391.
- [29] 孙 林, 黄金旭, 徐久成. 基于邻域容差互信息和鲸鱼优化算法的非平衡数据特征选择 [J]. *计算机应用*, 2023, 43 (6): 1842-1854.
- [30] 姚 芳, 陆 乐, 王刘浏, 等. 基于输入电流和输出电压的 Vienna 整流器单管开路故障诊断方法 [J]. *电力自动化设备*, 2022, 42 (3): 82-89.
- [31] 宁 剑, 任怡睿, 林济铿, 等. 基于人工智能及信息融合的电力系统故障诊断方法 [J]. *电网技术*, 2021, 45 (8): 2925-2936.

(上接第 21 页)