

DOI:10.19651/j.cnki.emt.2313277

# 基于注意力机制与 Inception-ResNet 的轴承故障诊断方法<sup>\*</sup>

张瑞博 李凌均

(郑州大学机械与动力工程学院 郑州 450001)

**摘要:** 针对滚动轴承在噪声环境下故障难以识别的问题,提出了一种结合注意力机制与 Inception-ResNet 滚动轴承故障判定方法。首先提出了一种将灰度图与伪色彩处理相结合的方法,将一维振动信号转化为三维 RGB 图像;然后结合 Inception 模块与残差网络,在宽度和深度两个方面拓展网络,提高网络的表达能力;最后结合 CBAM 注意力机制,融合通道注意力模块与空间注意力模块,增强输入特征中更重要的特征,抑制不必要的噪声特征,从而有效提高了诊断准确率。本文采用凯斯西储大学轴承数据集进行验证,并选用几个主流的深度的学习方法进行对比试验。试验结果表明:本方法具有很好的诊断准确率,平均准确率高达 99.32%,在噪声状态下进行分析实验,结果表明在噪声状态下本方法依然具有良好的准确率,验证了本方法的鲁棒性。

**关键词:** 滚动轴承;故障诊断;Inception-ResNet;注意力机制;深度学习

中图分类号: TH133.3 TH165.3 文献标识码: A 国家标准学科分类代码: 460.1520

## Bearing fault diagnosis method based on attention mechanism and Inception-ResNet

Zhang Ruibo Li Lingjun

(School of Mechanical and Power Engineering, Zhengzhou University, Zhengzhou 450001, China)

**Abstract:** Aiming at the problem that rolling bearings are difficult to identify faults in noisy environments, a rolling bearing fault judgment method combining attention mechanism and Inception-ResNet is proposed. Firstly, a method combining grayscale image and pseudo-color processing is proposed to convert one-dimensional vibration signal into three-dimensional RGB image; then combined with Inception module and residual network, the network is expanded in both width and depth, and the network is improved. Finally, combined with the CBAM attention mechanism, the channel attention module and the spatial attention module are integrated to enhance the more important features of the input features and suppress unnecessary noise features, thereby effectively improving the diagnostic accuracy. In this paper, the bearing data set of Case Western Reserve University is used for verification, and several mainstream deep learning methods are selected for comparative experiments. The test results show that this method has a good diagnostic accuracy rate, the average accuracy rate is as high as 99.32%. The analysis experiment is carried out under the noise state, and the results show that the method still has a good accuracy rate under the noise state, which verifies the robustness of this method.

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

## 0 引言

旋转机械作为现代工业中最重要的设备之一,已广泛应用于火车、涡轮机、航空发动机等领域。然而在运行过程中,设备故障可能导致巨大的损失甚至是灾难性的人员伤

亡<sup>[1]</sup>。而滚动轴承作为旋转机械的基础部件,其健康状况对机械设备有相当大的影响。对轴承的运行状态进行有效的检测和故障预警,可以节省宝贵的时间和成本采取补救措施以避免危险情况。

传统的故障诊断方法精度很大程度上受到人工特征提

收稿日期:2023-04-04

\* 基金项目:国家自然科学基金(51775515)项目资助

取步骤的影响,这个过程高度依赖领域知识,并且极大地影响了最终结果<sup>[2]</sup>。随着人工智能领域的快速发展,深度学习提供了有效的解决方案来克服上述限制。深度学习具有从输入数据中自动学习多个复杂特征的能力,减少了传统故障诊断方法在人工选择和信息提取过程中的不确定性<sup>[3]</sup>。最近几年,各种不同的深度学习模型,特别是卷积神经网络(convolutional neural networks, CNN),在机械故障智能诊断中得到了广泛应用。Eren 等<sup>[4]</sup>开发了紧凑型自适应一维卷积神经网络用于实时轴承故障诊断系统,该架构简单高效,无需任何预先的数据转换。Yang 等<sup>[5]</sup>提出了基于多源原始振动信号的卷积神经网络,使用由多个传感器收集的多源原始振动信号作为输入,并使用设计的卷积神经网络进行分类,具有更高的故障识别率,而且具有一定抗噪性能。

近年来,注意力机制已经成为深度学习的一个重要分支。在神经网络中加入注意力机制,可以提取到更为关键的信息。孔子迁等<sup>[6]</sup>通过小波分解将原始振动信号分解为频带和时间维度作为输入,分别使用卷积神经网络和双向门控循环单元融合特征,最后由注意力机制对不同时间点特征自适应动态加权融合,通过分类器实现行星齿轮箱故障诊断。

如上述所言,深度学习的方法正越来越多地应用于故障诊断领域,但也有一定的限制和缺点。一维卷积神经网络随着网络深度的增加,参数量和消耗资源量不断增加,却容易出现过拟合的问题。同时,常用的卷积神经网络在无噪声环境下尚且能获得较好的效果,在噪声环境下的准确率却很低,模型鲁棒性较差。

因此本文提出了一种结合注意力机制与多尺度残差分支网络 Inception-Resnet 的轴承故障诊断方法, 使用 Inception 结构将不同大小的卷积核对输入数据进行并行处理, 并将不同卷积核处理的特征图在深度这个维度拼接起来, 得到一个更深的特征图。Inception 结构的使用相当于增加了神经网络的宽度, 提取到的特征图更加全面。卷积注意力模块将通道注意力模块与空间注意力模块融合来关注重要特征, 抑制不必要特征以增强网络的表达能力。将本方法与常见的深度学习方法进行对比, 结果表明本方法具有良好的故障诊断准确率, 在噪声状态下进行分析实验, 结果表明在噪声状态下本章方法依然具有良好的准确率, 验证了本方法的鲁棒性。

## 1 理论基础

### 1.1 卷积神经网络

卷积神经网络是具有前馈结构的神经网络。卷积神经网络具有在二维分析中 3 个重要的优势: 局部连接、权值共享和下采样<sup>[7]</sup>。一般来说, 卷积神经网络包含三种层: 卷积层、池化层和全连接层。

卷积层的作用是对输入数据进行特征提取, 其内部包

含多个卷积核, 每个卷积核具有相同的大小并提取输入局部区域的局部特征。一般来说, 卷积层的数学模型可以由以下公式来描述:

$$x_j^l = f \left( \sum_{i \in M_j} x_i^{l-1} * k_{ij}^l + b_j^l \right) \quad (1)$$

式中: \* 是卷积运算;  $M$  是输入特征图的集合;  $l$  是网络中的第  $l$  层;  $k$  是卷积核;  $b$  是偏置项;  $i$  是输入特征图层数;  $j$  是输出特征图层数;  $f$  是非线性激活函数。

池化层通常应用于卷积层之后, 它对先前的特征图执行下采样操作。池化层减小了输入特征的大小, 还减少了网络中的参数数量, 这在一定程度上加快了计算速度并防止了过拟合。最大池化是最常见的池化方法。最大池化将选择池化区域内的最大值并将其传播到下一层, 具体公式为:

$$x_{ij}^l = \max(x_{in}^{l-1}), i-1 \leq n \leq i+1 \quad (2)$$

式中:  $l$  为网络层数;  $i$  为通道数;  $n$  为参数序号。

全连接层的作用是从之前的特征图中收集所有特征进行分类。该层中的所有神经元都连接到前一层中的所有激活。softmax 用作输出层的激活函数。softmax 函数将输入的实值向量的每个值映射为 0~1 之间的实数, 并且保证它们的和为 1。softmax 函数的定义如下:

$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}}, j = 1, \dots, K \quad (3)$$

### 1.2 Inception 模块

Inception 结构最早在 GoogLeNet<sup>[8]</sup> 中被提出, 它的核心思想就是使用不同的卷积核对输入数据进行并行处理, 并将不同卷积核处理的特征图在深度这个维度拼接起来, 得到一个更深的特征图。因为  $1 \times 1, 3 \times 3, 5 \times 5$  等不同卷积的运算与池化操作从输入图像中提取不同尺度的特征, 并行处理这些运算并将结果拼接在一起得到的特征图更加全面和多样。Inception-v1 的结构图 1 所示。在  $3 \times 3$  和  $5 \times 5$  卷积之前应用  $1 \times 1$  卷积的作用是降维, 以减少参数量和计算量, 增加模型深度并提高非线性表达能力。在 Inception-v2<sup>[9]</sup> 中引入 BN 层, 将每一层的输出都规范化。在 Inception-v3<sup>[10]</sup> 中, 引入非对称卷积, 并将大尺度卷积( $5 \times 5$  卷积和  $7 \times 7$  卷积)分解为多个小尺度卷积(2 个  $3 \times 3$  卷积和 3 个  $3 \times 3$  卷积), 可以在感受野不变的同时减少计算量。Inception-v4<sup>[11]</sup> 在此前的基础上对结构进行进一步改进, Stem 模块使用了不对称卷积和池化层的并行结构, 并为每个网格大小的 Inception 模块做出统一的选择, 降低了计算量。

### 1.3 深度残差网络

残差结构首先被提出<sup>[12]</sup>以解决网络退化问题: 随着网络层数的增加, 训练集误差逐渐下降并趋于饱和, 然后会迅速退化导致误差增大。网络退化不是由过拟合导致的, 因为过拟合只会导致测试集误差逐渐变大, 而训练集误差是一直减小的。残差网络通过构建残差块, 并将很多残差块

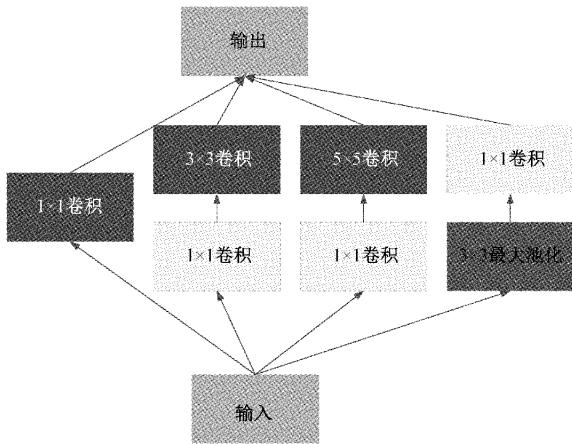


图 1 Inception V1 模块

堆叠在一起,形成一个很深的神经网络。即残差块使用一个恒等映射,让堆叠的非线性层拟合残差映射  $F(x) := H(x) - x$  而非直接拟合映射  $H(x)$ 。残差块的结构如图 2 所示。

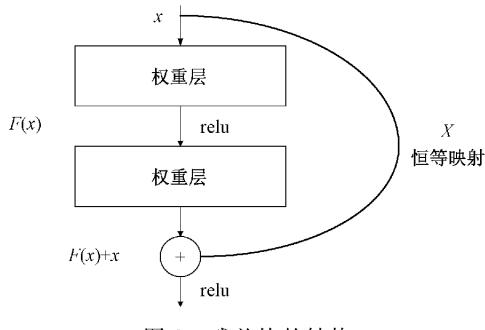


图 2 残差块的结构

## 2 结合注意力机制与 Inception-Resnet 的模型

### 2.1 数据预处理

数据预处理方法在传统的故障诊断方法中相当重要,甚至可以决定准确率,这是因为大多数数据驱动方法不能直接处理原始振动信号。由于轴承的振动信号是一维时域信号,而 Inception-Resnet 网络的输入是 RGB 图像,因此需要将时域信号转化为 RGB 图像作为输入。Do<sup>[13]</sup> 将一维振动信号转换为二维灰度图像,可以有效地提取感应电机故障状况的特征。本节基于 Do 提出的将一维振动信号转为灰度图的方法,提出了一种将振动信号转化为 RGB 三通道图像的方法。

图 3 显示了振动图像的构建过程。将振动信号中每个样本的幅度归一化到 0~255 范围内,也就是灰度图的像素值范围。之后每个样本归一化后的幅度变为对应图像中对应像素的强度。为了获得  $M \times M$  大小的图像,从原始信号中截取长度为  $M^2$  的分段信号,样本的归一化幅度与相应像素之间的转换可以用下式表示:

$$P(i, j) = \frac{L((i-1) \times M + j) - \text{Min}(L)}{\text{Max}(L) - \text{Min}(L)} \times 255 \quad (4)$$

式中: $L(k), k=1, 2, \dots, M^2$ , 代表原始信号端的值; $P(i, j), i=1, 2, \dots, M, j=1, 2, \dots, M$ , 代表图像第  $i$  行第  $j$  列的像素值大小。

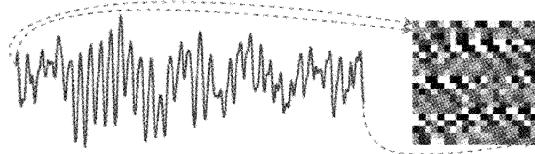


图 3 信号转换为图像的方法

把信号转化为灰度图后,应用 opencv 中的伪彩色函数(applyColorMap),将灰度图转化为三通道的 RGB 图像。本文采用的是伪彩色函数中的 COLORMAP\_JET 方法,转化的图像如图 4 所示。

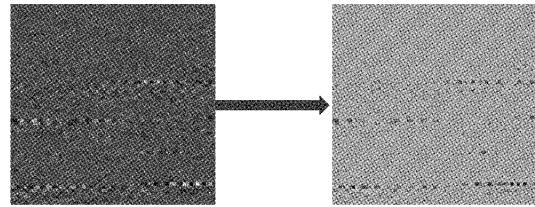


图 4 伪彩色处理前后的图像

### 2.2 CBAM 卷积块注意模块

卷积块注意模块(convolutional block attention module,CBAM)最早由 Woo 等<sup>[14]</sup>提出,CBAM 是将通道注意力模块与空间注意力模块融合的注意力机制,关注重要特征,抑制不必要特征以增强网络的表达能力。通道注意力关注输入特征中有意义的部分。图 5 为 CBAM 的示意图。通道注意力模块首先使用平均池化和最大池化操作聚合特征图的空间信息,然后经过由多层感知器(MLP)组成的共享网络模块,将通道数压缩为原来的  $1/r$ ,再扩张回原通道数,经过 ReLU 激活函数得到两个激活后的结果,将输出结果逐元素求和并通过 sigmoid 激活函数,得到最终的通道注意力模块输出。计算方法如下:

$$\begin{aligned} M_c(F) &= \sigma(\text{MLP}(\text{AvgPool}(F)) + \\ &\text{MLP}(\text{MaxPool}(F))) = \sigma(W_1(W_0(F_{\text{avg}}^c)) + \\ &W_1(W_0(F_{\text{max}}^c))) \end{aligned} \quad (5)$$

式中: $\sigma$  代表 sigmoid 激活函数,  $F$  代表输入特征图,  $W_0 \in R^{C/r \times C}, W_1 \in R^{C \times C/r}$ , MLP 的权重  $W_0$  和  $W_1$  共享, ReLU 激活函数后跟  $W_0$ 。

与通道注意力不同,空间注意力模块关注的是目标的信息位置。空间注意力模块首先使用平均池化和最大池化聚合特征图的通道信息生成两个二维特征图,然后将它们连接起来并通过标准卷积层进行卷积得到空间注意力模块特征图。计算方法如下:

$$M_s(F) = \sigma(f^{7 \times 7}([\text{AvgPool}(F); \text{MaxPool}(F)])) = \sigma(f^{7 \times 7}([F_{\text{avg}}^s; F_{\text{max}}^s])) \quad (6)$$

式中: $\sigma$  代表 sigmoid 激活函数,  $f^{7 \times 7}$  代表  $7 \times 7$  大小的卷积核。

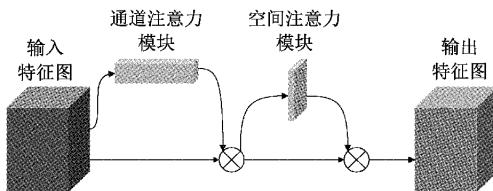


图 5 卷积块注意模块(CBAM)结构图

### 2.3 CBAM-Inception-Resnet 网络结构

Inception-Resnet 网络是在 Inception 结构中引入残差结构实现的, Inception-ResnetV2 是由 Stem、Inception-

Resnet-A、Inception-Resnet-B、Inception-Resnet-C、Reduction-A、Reduction-B 几种模块堆叠而成。通过引入 Inception 结构和残差结构, 神经网络在宽度和深度两个维度加深, 可以提取到更为深层的特征, 提升故障诊断的精度而不会引发网络退化和过拟合现象。在每个 Inception-Resnet 结构后加入 CBAM 注意力模块, 可以进一歩提高故障诊断能力, 同时由于 CBAM 的轻量性, 网络整体的参数量变化不大, 训练时间的变化几乎可以忽略不计。CBAM-Inception-ResnetV2 网络结构如图 6 所示。模型结构参数如表 1 所示。

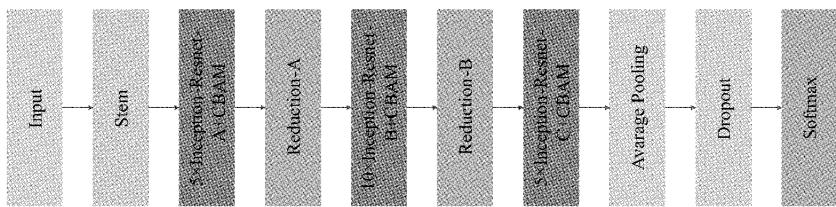


图 6 CBAM-Inception-ResnetV2 网络结构

表 1 模型结构参数

网络层	感受野大小	输出大小
输入层		$128 \times 128 \times 3$
Stem 层	$3 \times 3$	$35 \times 35 \times 256$
Inception-Resnet-A+CBAM	$1 \times 1$ $3 \times 3$	$35 \times 35 \times 256$
Reduction-A	$1 \times 1$ $3 \times 3$	$17 \times 17 \times 896$
Inception-Resnet-B+CBAM	$1 \times 7$ $7 \times 1$	$17 \times 17 \times 896$
Reduction-B	$1 \times 1$ $3 \times 3$	$8 \times 8 \times 1792$
Inception-Resnet-C+CBAM	$1 \times 3$ $3 \times 1$	$8 \times 8 \times 1792$
Avarage Pooling		1 792
Dropout	Keep=0.8	2 048
Softmax		10

## 3 实验结果及分析

### 3.1 实验介绍

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 7 所示。该平台由一个电动机(图左侧)、一个扭

矩传感器(图中间连接处)、一个功率测试计(图右侧)和电子控制器(图中没显示)组成。驱动端轴承型号为 SKF 6205-2RS JEM, 风扇端轴承型号为 SKF 6203-2RS JEM。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 0.18、0.36 和 0.54 mm 的单点故障, 加上正常状态下滚动轴承的实验数据, 一共有十种不同类型的故障类型, 如表 2 所示。

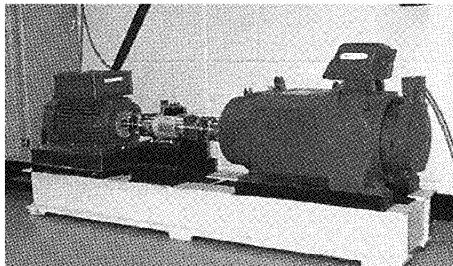


图 7 CWRU 轴承故障实验平台

表 2 CWRU 轴承故障分类及标签值

标签值	故障类型	故障直径/mm
0	正常状态	无
1	内圈故障	0.18
2	内圈故障	0.36
3	内圈故障	0.54
4	外圈故障	0.18
5	外圈故障	0.36
6	外圈故障	0.54
7	滚动体故障	0.18
8	滚动体故障	0.36
9	滚动体故障	0.54

本实验选取 12K 采样频率下的驱动端轴承数据。选取样本的采样长度为 4 096, 转化为  $64 \times 64$  的三通道图像, 每种故障类型各构造 1 000 个样本, 包括训练集样本 800 个, 测试集样本 200 个。

### 3.2 超参数的选择

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<sup>[15]</sup>。本文设置了一组学习率分别为 0.005、0.001、0.0005、0.0001、0.00005、0.00001 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 8 所示。

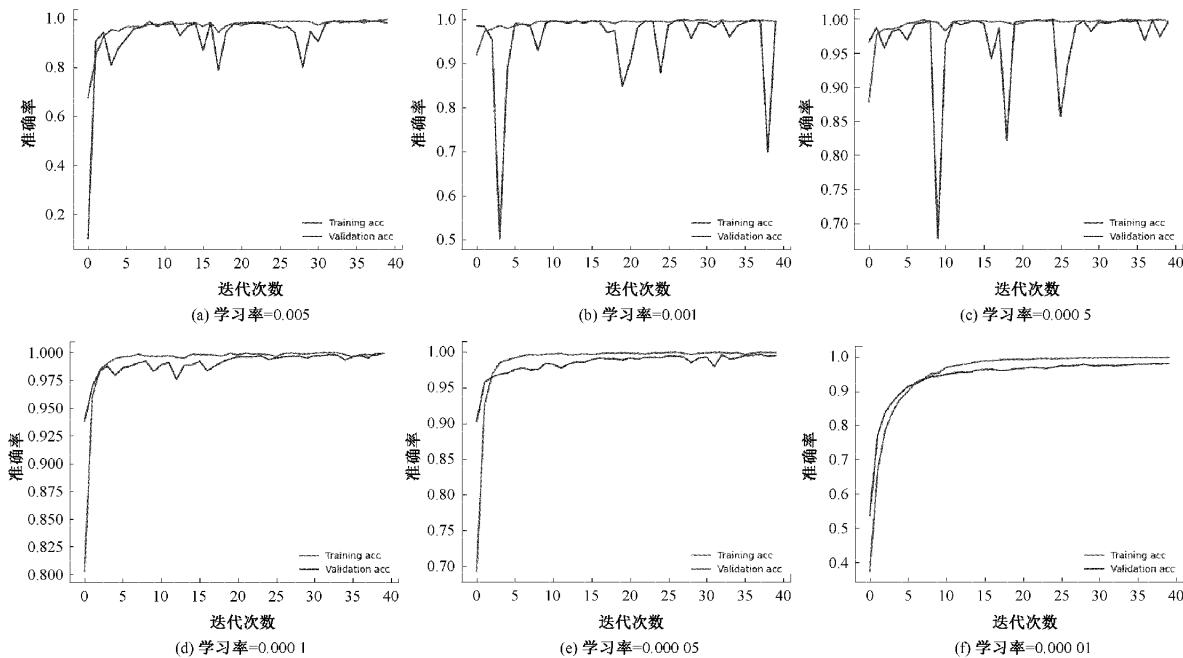


图 8 不同学习率下准确率随迭代次数的变化

由图 8 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, 训练集准确率会继续缓慢增加, 但测试集准确率波动很大, 有时准确率甚至不足 60%。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 3 所示。

表 3 模型超参数取值

学习率	批大小	迭代次数
0.0001	32	20

### 3.3 对比试验及实验结果分析

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 AlexNet、GoogLeNet、ResNet、Inception-ResnetV2 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 优化器和交叉熵损失函数 (CrossEntropy Loss)。实验对比结果如表 4 所示。

根据表 4 可以看出, 所选取的方法都具有较高的准确率。本文方法相较于其他方法具有更高的实验准确率。相对于 GoogLeNet、ResNet 网络, 本文方法融合了

表 4 各方法的实验对比结果

模型	平均	最高	最低	训练时间/s
	准确率	准确率	准确率	
AlexNet	86.8%	93.1%	80.5%	37
GoogLeNet	92.38%	94.1%	91.2%	119
ResNet	94.72%	96.0%	93.6%	145
Inception-ResnetV2	96.16%	97.70%	94.45%	162
本文方法	99.32%	99.55%	99.0%	168

Inception 模块和残差网络的优点, 同时使用  $1 \times 1$ 、 $3 \times 3$ 、 $5 \times 5$  等不同大小的卷积核提取特征, 可以提取到输入图像中不同的信息, 加入残差网络又解决了网络退化现象, 因此获得了很高的准确率。而对比未加入注意力机制的原生 Inception-ResnetV2 网络, 本方法由于加入 CBAM 注意力机制来关注输入特征中更重要的特征, 大大增加了网络的准确率, 同时由于 CBAM 的轻量化属性, 训练时间的增加很少, 几乎可以忽略不计。

图 9 是其中一次实验的混淆矩阵, 其中 ball、inner、outer、normal 分别代表滚动体故障、内圈故障、外圈故障和正常状态, 后面的数字代表故障直径 0.18、0.36、0.54 mm。根据混淆矩阵可以直观地看出本文方法具有

很高的识别准确率,能够有效的对故障类别准确分类。

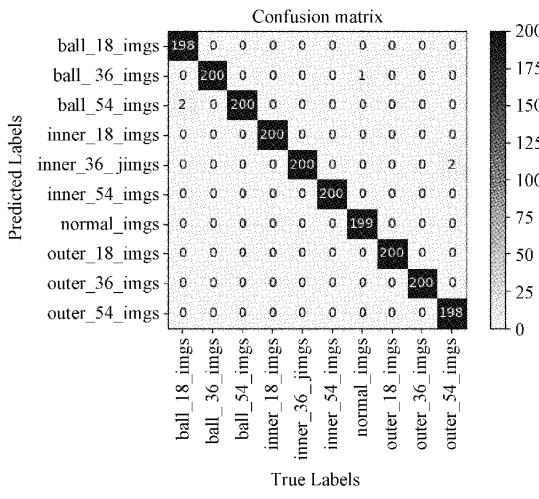


图 9 混淆矩阵

### 3.4 噪声状态实验分析

在滚动轴承的工作环境下,零件间的振动和摩擦引起的噪音是无法避免的。然而,噪音的存在会影响振动数据的有效性,从而影响故障诊断的准确性。凯斯西储大学轴承数据集是在相对安静的环境下采集的,因此为了验证本算法的鲁棒性,在原始信号中加入不同信噪比的高斯白噪声来模拟噪音干扰。信噪比的定义如下:

$$\text{SNR} = 10 \lg \left( \frac{P_{\text{signal}}}{P_{\text{noise}}} \right) = \frac{\sum_{t=0}^{N-1} x^2(t)}{\sum_{t=0}^{N-1} n^2(t)} \quad (7)$$

式中:SNR 代表信噪比,单位是 dB,  $P_{\text{signal}}$  代表原始信号功率,  $P_{\text{noise}}$  代表噪声功率,  $x(t)$  代表原始信号,  $n(t)$  代表噪声信号,  $N$  代表原始信号的长度。

由式(7)推导可得到噪声信号计算公式如下:

$$|n| = \frac{\sum_{t=0}^{N-1} x^2(t)}{N 10^{\frac{\text{SNR}}{10}}} \quad (8)$$

服从高斯分布对信号进行放大,得到的高斯白噪声计算公式如下:

$$\text{noise} = \text{random}(N) \sqrt{|n|} \quad (9)$$

原始信号加入高斯白噪声后得到的信号大小公式如下:

$$X = X + \text{noise} \quad (10)$$

图 10 展示了加入信噪比为 2 dB 的高斯白噪声前后振动信号的图像,上图代表原始信号,下图表示加入高斯白噪声后的信号。

本小节将 CBAM-Inception-Resnet 模型与 AlexNet、GoogLeNet、Resnet 和 Inception-ResnetV2 在不同信噪比的条件下进行对比试验,来验证不同模型在噪声环境下的诊断效率。本次实验采用信噪比为 5 dB、2 dB、0 dB、-2 dB、-5 dB 的高斯白噪声分别进行实验,每次实验进行 5 次取平均值,得到的结果如表 5 所示。

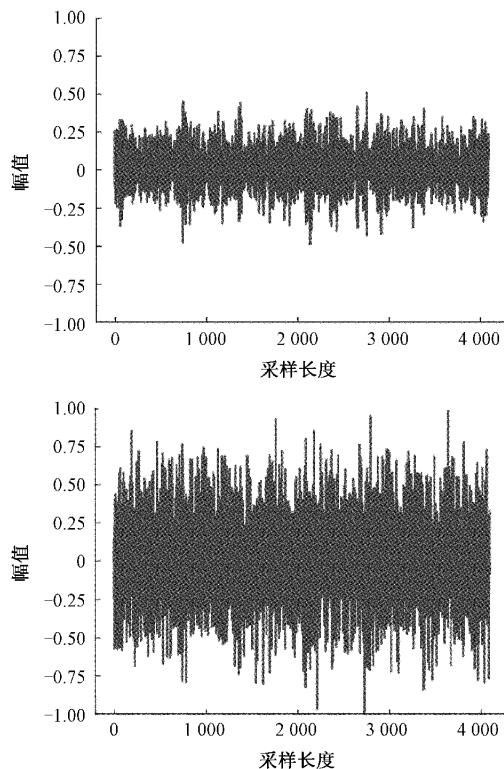


图 10 原始信号和加入高斯白噪声后的信号

表 5 变噪声状态下的对比试验

故障诊断方法	信噪比/dB				
	5	2	0	-2	-5
AlexNet	86.27%	85.67%	82.72%	76.29%	68.57%
GoogLeNet	92.17%	89.89%	85.39%	80.67%	72.46%
Resnet	94.26%	93.36%	90.65%	86.12%	81.76%
Inception-ResnetV2	95.83%	94.97%	91.61%	87.37%	82.61%
本章方法	99.14%	98.07%	97.98%	97.42%	96.17%

根据表 5 可以看出,本章提出的方法在信噪比为 5、2、0、-2、-5 dB 时故障诊断准确率均高于其他方法,且准确率都高于 95%。这是因为 CBAM-Inception-Resnet 模型中的 Inception 模块使用不同大小的卷积核最大限度地提取了噪音信号中特征信息,同时卷积注意力模块也可以自动关注噪音信号中原始的特征信息,从而大大提高了在噪音状态下模型的故障诊断准确率。本次噪声实验证明了 CBAM-Inception-Resnet 模型在噪音环境下具有很强的抗噪声能力,具有很好的鲁棒性来有效抑制噪音的干扰。

## 4 结 论

针对传统卷积神经网络,本文提出了结合 CBAM 注意力机制与 Inception-ResNet 的轴承故障诊断新方法,并使用凯斯西储大学滚动轴承数据集进行验证试验。试验结果表明,该模型在轴承故障诊断中具有良好的性能。

本模型使用灰度图与伪色彩处理相结合的方法,将一维时域振动信号快速转换为 RGB 三通道图像,避免了人工提取特征提取的不确定性,提高了模型的泛化能力。

根据对比试验可知,本模型具有很高的识别准确率,而且由于 CBAM 的轻量性质,训练时间的增加可以忽略不计。两者都证明了本模型的优越性。本方法在噪声状态下进行分析实验,结果表明在噪声状态下本方法依然具有良好的准确率,验证了本方法的鲁棒性。

## 参考文献

- [1] JIAO J, ZHAO M, LIN J, et al. Hierarchical discriminating sparse coding for weak fault feature extraction of rolling bearings [J]. Reliability Engineering & System Safety, 2019,184:41-54.
- [2] 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.
- [3] 汪祖民, 张志豪, 秦静, 等. 基于卷积神经网络的机械故障诊断技术综述[J]. 计算机应用, 2022,42(4): 1036-1043.
- [4] 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.
- [5] YANG H B, ZHANG J A, CHEN L L, et al. Fault diagnosis of reciprocating compressor based on convolutional neural networks with multisource raw vibration signals [J]. Mathematical Problems in Engineering, 2019,2019. DOI:10.1155/2019/6921975.
- [6] 孔子迁, 邓蕾, 汤宝平, 等. 基于时频融合和注意力机制的深度学习行星齿轮箱故障诊断方法[J]. 仪器仪表学报, 2019,40(6): 221-227.
- [7] KRIZHEVSKY A, SUTSKEVER I, HINTON G. ImageNet classification with deep convolutional neural networks[Z]. New York: ACM, 2017: 60, 84-90.
- [8] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions [J]. IEEE Computer Society, 2014. DOI:10.1109.
- [9] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[J]. JMLR,2015, DOI:10.48550.
- [10] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision[C]. IEEE, 2016:2818-2826.
- [11] SZEGEDY C, IOFFE S, VANHOUCKE V, et al. Inception-v4, inception-ResNet and the impact of residual connections on learning [J]. Thirty-First AAAI Conference on Artificial Intelligence, 2017: 7. DOI:10.48550.
- [12] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [J]. 2016 IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2016:9. DOI:10.1109.
- [13] DO V T, CHONG U P. Signal model-based fault detection and diagnosis for induction motors using features of vibration signal in two-dimension domain[J]. Strojnicki Vestnik-Journal of Mechanical Engineering, 2011, 57(9): 12.
- [14] WOO S H, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module[J]. Computer Vision-ECCV 2018, 11211: 17.
- [15] 赵小强, 罗维兰. 改进卷积 Lenet-5 神经网络的轴承故障诊断方法[J]. 电子测量与仪器学报, 2022, 36(6): 113-125.

## 作者简介

张瑞博,硕士研究生,主要研究方向为信号处理与故障诊断。

E-mail:zzuzhangruibo@163.com

李凌均(通信作者),郑州大学副教授,博士,主要研究方向为设备故障机理及智能诊断技术。

E-mail:lingjun@zzu.edu.cn