

# 基于 SE-ResNeXt 的滚动轴承故障诊断方法

胡向东, 梁川

(重庆邮电大学 自动化学院, 重庆 400065)

**摘要:** 针对滚动轴承在故障诊断过程中信号特征提取困难导致诊断准确率低、鲁棒性差的问题, 提出一种基于 Squeeze-Excitation-ResNeXt (SE-ResNeXt) 网络的滚动轴承故障诊断方法; 将采集的一维轴承振动信号作为输入, 进行滑动窗口采样与标准化处理, 通过压缩、激励操作进行特征重标定, 扩大模型感受野, 并级联聚集残差变换网络自适应提取故障信号特征; 在模型训练过程中选择最优压缩率为 1/8 以及 8 个组卷积, 引入 Relu 函数加快网络收敛, 使用全局平均池化替代全连接层避免过拟合现象, 构造能够自主进行表征学习的最优故障诊断模型; 通过仿真实验表明: 与目前的深度学习算法相比, SE-ResNeXt 网络能够准确的实现轴承故障诊断, 并在高噪声的环境下仍具有较好的鲁棒性。

**关键词:** 故障诊断; 滚动轴承; SE-ResNeXt

## Fault Diagnosis Method of Rolling Bearing Based on SE-ResNeXt

HU Xiangdong, LIANG Chuan

(College of Automation, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

**Abstract:** For the problem of low diagnostic accuracy and robustness due to the difficulty in extracting the signal features of rolling bearings during fault diagnosis, a new rolling bearing fault diagnosis method is proposed based on Squeeze-Excitation-ResNeXt (SE-ResNeXt). The collected one-dimensional bearing vibration signals were taken as input, the sliding window sampling and standardization were conducted, the feature re-calibration was carried out through compression and excitation operation, the model receptive field was enlarged and the fault signal characteristics were extracted adaptively by cascading aggregate residual transformation network. In the process of model training, the optimal compression rate was selected as 1/8 and 8 sets of convolution, Relu function was introduced to accelerate the convergence of the network, global average pooling was used to replace the full connection layer to avoid overfitting, and an optimal fault diagnosis model capable of independent characterization learning was constructed. Simulation experiments show that compared with the current deep learning algorithm, the SE-ResNeXt network can accurately realize bearing fault diagnosis and still has good robustness under high noise environment.

**Keywords:** fault diagnosis; rolling bearing; SE-ResNeXt

## 0 引言

随着信息处理分析技术和传感器技术的不断发展与日益创新, 故障诊断已经发展成为一种多个学科交叉融合的新技术。故障诊断是通过测量设备的工作状况并对其异常状态做出技术判断, 为后续维修计划提供参考依据<sup>[1]</sup>。因为存在较多无法预测的状况, 工业生产的机械设备可能出现不同的问题, 引起系统功能故障, 造成严重的工厂事故。滚动轴承是机械设备的易损部件, 其健康状况对机械设备的性能、稳定性和使用寿命有重大影响<sup>[2]</sup>。当机械轴承出现故障时, 会产生异于正常工作时的振动信号, 故障点不同, 产生的信号特征也不相同, 因此分析缺陷轴承的振动信号来判断轴承故障状态, 是一种科学的检测、诊断方法<sup>[3]</sup>。

传统的机械轴承智能诊断方法一般需要借助于快速傅里叶变换 (FFT)、小波变换 (WT) 和经验模态分解 (EMD) 等现代信号处理技术<sup>[4]</sup>对采集到的信号进行处理,

然后经过工程经验获取故障特征, 进而实现故障的判别。郭宇庭等<sup>[5]</sup>提出了一种基于小波变换的自适应时频特性的轴承故障诊断方法。但该方法只是比较了轴承正常与故障时的信号特征规律, 并未得出确切的诊断结果。刘畅等<sup>[6]</sup>提出了一种改进支持向量机的机械轴承故障诊断方法, 虽然此方法能够获得不错的诊断准确率, 但是对技术人员的理论知识要求较高, 并且其故障信号判别过程较为繁琐, 并未实现端到端的故障诊断。李继猛等<sup>[7]</sup>提出一种融合经验模态与奇异值分解的滚动轴承故障诊断方法, 该方法虽然特征提取精度较高, 但是需要技术人员来进行故障分辨, 仍然存在一定的分辨误差。传统的轴承故障诊断方法在特征选取环节的好坏会直接影响诊断精度, 因此依靠工程经验提取振动信号特征并不是最优解。

目前使用原始振动信号特征进行轴承故障诊断逐渐成为研究重点, 许多学者利用深度学习直接挖掘信号潜在特征, 通过深层次神经网络和批量训练样本来提高分类准确

收稿日期: 2020-12-22; 修回日期: 2021-01-03。

作者简介: 胡向东(1971-), 男, 四川省广安市人, 博士, 教授, 主要从事智能感知、网络化测量及工业大数据安全, 物联网安全智能理论与技术, 复杂系统建模、仿真与优化等方向的研究。

引用格式: 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.

率<sup>[8]</sup>。张颖等<sup>[9]</sup>提出结合时频图像与卷积神经网络的轴承故障诊断方案, 利用短时傅立叶变换获得二维图像, 然后将其输入到卷积神经网络, 获得了较好的故障诊断准确率, 但是该方法仍未实现端到端学习。Miao He 等<sup>[10]</sup>利用可调滤波器大小的卷积核进行振动信号的分割, 使用训练的离散傅里叶变换—逆离散傅里叶变换自编码器来得到振动信号谱平均值, 并使用谱平均值重构振动信号, 然后将重构的振动信号送入分类层进行轴承故障诊断。该方法虽然在诊断的准确率上表现不错, 但是较为繁琐, 目前在工业现场部署还较为困难。

针对以上问题, 张伟<sup>[11]</sup>研究出直接在时域振动信号进行处理的卷积神经网络模型。该模型虽然对轴承的故障识别准确率较高, 但是模型鲁棒性还有待提高, 其超参数的选择也需要多次实验才能确定。咎涛等<sup>[12]</sup>设计出多输入层的诊断方案, 提高了测试准确率, 但却需要在卷积或池化层输入低维的频谱数据, 过程繁琐且未实现端到端的故障诊断。宫文峰等<sup>[13]</sup>提出一种使用全局均值池化技术代替传统 CNN 的全连接部分的改进卷积神经网络的轴承故障诊断方法, 但对于内圈的轻度缺陷检测准确率只有 96%, 仍还有提升的空间。

综合以上分析, 本文提出一种基于 SE-ResNeXt 的端到端故障诊断模型, 不仅避免了繁琐的振动信号特征提取过程, 很好地解决了轴承故障诊断准确率低的问题, 而且模型鲁棒性较好, 实现了端到端的轴承故障诊断, 具有良好的可操作性与通用性。本文所做的主要内容如下:

(1) 以 441 位数据点为一个样本, 使用滑动窗口采样法对原始的轴承振动信号数据进行扩增, 根据数据集长度获取 8 000 个样本并划分 5 600 个训练集, 2 400 个测试集后随机打散。

(2) 选定压缩率、组卷积分支数和残差网络参数, 并将 SE-net 与 ResNeXt 进行级联, 搭建易于拓展的 SE-ResNeXt 故障诊断模型。

(3) 将本文所提模型与现有的深度学习算法进行多次故障诊断实验, 进行可行性分析与有效性验证, 并向测试数据中加入噪声信号, 进行模型的鲁棒性测试。

## 1 基于 SE-ResNeXt 的故障诊断方法

采用 SE-ResNeXt 模型对滚动轴承进行故障诊断的思路是先将一维信号进行滑动窗口采样并标准化处理后作为输入, 利用 SE-net 网络进行特征重标定, 并级联 ResNeXt 网络对一维振动信号进行深层次的空间特征学习, 最后利用 Softmax 函数完成故障分类。模型训练流程如图 1 所示。

### 1.1 实验数据来源

为测试所提模型对轴承故障诊断的可行性和鲁棒性, 本文采用凯斯西储大学轴承数据<sup>[14]</sup>进行故障仿真实验。故障轴承振动信号来源于如图 2 的仿真实验平台, 左边为三相感应电机用于产生驱动力, 中间的扭转传感器用于测量扭矩和转速, 右侧为测力计用于产生不同负载, 测试轴承型号为 SKF6205, 安置在驱动端。

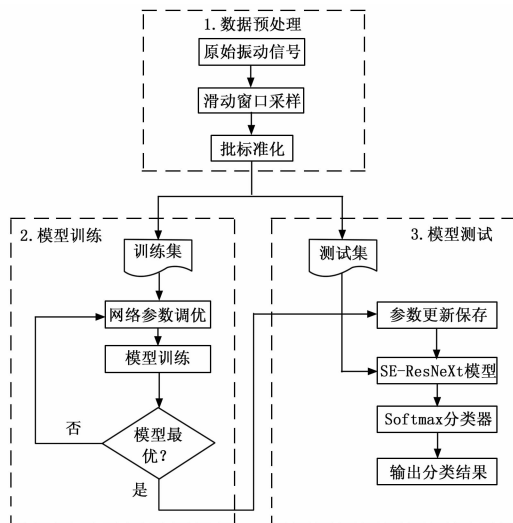


图 1 模型训练流程图




图 2 轴承故障试验台

实验为人工采用电火花在轴承的内圈、外圈和滚动体上加工出尺寸为 0.007 英寸、0.014 英寸、0.021 英寸的单点故障, 用来表示不同的故障损坏程度, 实验共有 9 种不同的损伤状态和 1 种健康状态。所产生的信号使用 16 通道数据记录仪进行收集, 采样频率为 12 kHz, 电机载荷有 4 种, 分别为 0、1、2、3 hp (1 hp=0.746 kW)。

### 1.2 数据预处理

本实验在采样频率 12 kHz, 0 hp 负载下进行测试, 该负载对应的转速为 1 797 rpm, 因为原始振动信号有限, 本文使用了一种固定步长的滑动窗口采样算法进行数据扩增, 如图 3 所示。

算法 1: 滑动窗口采样算法 DataSample ( $D_A$ ,  $w$ ,  $len$ )  
输入: 原始数据集  $D_A$ , 滑动窗口大小  $w$ , 滑动步长  $len$

输出: 采样后的数据集  $D_B$

- (1) 初始化  $w, len$
- (2) for  $i=0$  to  $length(D_A)$  do:
- (3) if  $i < length(D_A)$  then:
- (4)  $D_{new} = i * w$  to  $(i * w + len)$  do:
- (5)  $D_B = D_B + D_{new}$
- (6) end if
- (7) end for
- (8) return  $D_B$

图 3 滑动窗口采样算法伪代码

本文设定的滑动窗口大小  $w = 441$ ，滑动步长为 150，并且按照 7:3 划分训练集与测试集，采样后的数据集组成如表 1 所示。

表 1 轴承数据集

标签	损伤位置	损伤 (英寸)	样本长度	训练集数量	测试集数量
0	滚动体故障	0.007	441	560	240
1	滚动体故障	0.014	441	560	240
2	滚动体故障	0.021	441	560	240
3	内圈故障	0.007	441	560	240
4	内圈故障	0.014	441	560	240
5	内圈故障	0.021	441	560	240
6	外圈故障	0.007	441	560	240
7	外圈故障	0.014	441	560	240
8	外圈故障	0.021	441	560	240
9	无	0	441	560	240

因一维振动信号幅值较为分散，在划分训练集和测试集后，使用批标准化方法将数据进行转换，转换后将数据变为均值为 0，方差为 1 的标准正态分布，使得模型更能学到数据之间的规律，并加快梯度收敛速度，其计算公式为：

$$x = \frac{x_i - \bar{x}}{\sigma} \quad (1)$$

式中， $x_i$  为当前振动信号样本的第  $i$  个幅值； $\bar{x}$  为当前振动信号样本的均值； $\sigma$  为当前振动信号样本的标准差。

### 1.3 SE-ResNeXt 轴承故障诊断模型

在生产过程中，轴承设备一般处于较为恶劣的环境中，对滚动轴承故障的准确诊断较为困难，且噪声的干扰会严重影响故障诊断的精度。本节提出一种 SE-ResNeXt 网络的轴承故障诊断模型，该模型首先使用一维卷积神经网络层对输入的原始故障振动信号进行初步特征提取，利用特征重标定层扩大模型感受野，增强模型的抗噪声能力，并级联 ResNeXt 网络进行深层次的空间特征学习，使用全局平均池化将特征信号转为一维向量展平，最后使用 Softmax 函数进行故障分类。为优化模型训练过程，实验网络均采用 Relu 作为激活函数，为防止过拟合现象的发生，将传统的全连接层替换为全局平均池化层，对模型的参数进行缩减，增强模型的泛化能力。SE-ResNeXt 模型结构如图 4 所示。

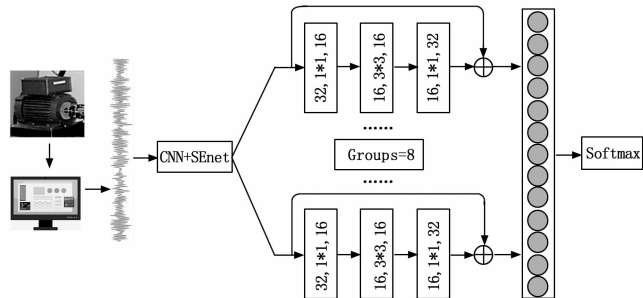


图 4 SE-ResNeXt 模型结构

接下来分别介绍网络的各个部分。

#### 1) CNN+SEnet 网络层：

原始振动信号经过批标准化后首先输入到一维卷积层，一维卷积层采用 8 个尺寸为 3 的滤波器，滑动步长为 1，初步提取振动信号特征。利用卷积层权值共享的特点能够减少网络参数，避免由于参数过多造成的过拟合现象，并降低系统所需内存。一维卷积层的卷积计算公式为：

$$X_j^l = f\left(\sum_{i \in M_l} (X_i^{l-1} * \omega_{ij}^l) + b_j^l\right) \quad (2)$$

式中， $X_j^l$  为  $l$  层第  $j$  个输出特征，上标代表是具体层，下标代表具体输出； $\omega$  为卷积核； $b$  为偏置量； $f$  是激活函数。在本文中，采用 ReLU 激活函数，其能够在一定程度上缓解神经网络的梯度消失问题，加速梯度下降，函数定义为：

$$ReLU(x) = \max(0, x) \quad (3)$$

将经过卷积后得到的向量采用最大池化进行稀疏，其能够选取特征图中的最大值，简化网络参数加速模型训练，最大池化公式为：

$$x_i^l = \max_{pooling}(k, s) \quad (4)$$

其中： $x_i^l$  代表  $l$  层的第  $i$  个神经元输出值； $k$  为最大池化的尺寸； $s$  代表最大池化的更新步长。在经过隐藏层获取最突出特征后，输入给下一层的 SEnet 网络。

Squeeze and Excitation Networks (SEnet 网络)<sup>[15]</sup> 是胡杰团队于 2017 年提出的新型网络结构，并利用该模型获得了 ImageNet 2017 竞赛图像分类任务的冠军。本课题利用该网络作为特征重标定层，通过损失函数值去学习特征权重，调整有效的特征信息权重，从而优化模型达到更好的训练效果，SEnet 网络结构如图 5 所示。




图 5 SEnet 网络结构

在振动信号数据经过卷积与池化层后，将其输入到 SEnet 网络进行特征重标定，自适应获取每个特征通道的重要程度。SEnet 网络主要包含 Squeeze (压缩) 和 Excitation (激励) 两个部分。

Squeeze 操作：数据  $X$  经过  $F_{sq}$  卷积池化转换后得到图 5 中的第二个模块  $U$ ，其中  $H, W_1, C$  代表张量的长度、宽度以及通道数。模块  $U$  经过  $F_{sq}$  操作变为  $1 * 1 * C$  的输出，其公式为：

$$z_c = F_{sq}(U_c) = \frac{1}{H * W_1} \sum_{i=1}^H \sum_{j=1}^{W_1} u_c(i, j) \quad (5)$$

式中， $z_c$  为压缩操作后的输出量， $u_c(i, j)$  为  $c$  通道中第  $i$  行第  $j$  列的输出值。经过 Squeeze 操作进行特征映射后，原始的多维信号特征被映射为一个数值，该数值具有全局感受野，这使得靠近输入的层也能获得全局感受野，增强了模型的泛化能力。

Excitation 操作: 通过压缩操作得到的结果为  $z_c$ , 将  $W_1$  与  $z_c$  进行全连接操作, 如公式 (6) 所示。

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

选取  $W_1 \in \mathbf{R}^{r \times c}$ , 其中  $r$  为缩放参数, 目的是减少参数降低计算量。将  $W_1 z_c$  相乘的结果经过  $ReLU$  激活函数再与  $W_2$  相乘, 经过 Sigmoid 函数得到结果  $s$ , 最后将特征权重  $s$  与经过卷积池化后的矩阵  $U$  进行相乘, 如公式 (7) 所示, 式中,  $U_c$  为  $c$  通道的数值, 最后得到经过权重调整后的  $\tilde{X}$  并输出。

$$\tilde{X}_c = F_{scale}(U_c, s_c) = U_c * s_c \quad (7)$$

### 2) ResNeXt 网络层:

ResNeXt 是 ResNet 和 Inception 的重构网络, 将残差和多尺度思想相融合, 既避免了因为网络模型过深而带来的梯度弥散现象, 又利用多尺度学习信号特征。该模型不需要多次实验设计复杂的 Inception 结构细节, 而是选用一致的拓扑结构共享超参数, 通过基数来改变控制组卷积的分支数量, 极大地提高了模型的可扩展性。

将经过特征重标定后的振动信号输入到 ResNeXt 网络层, 该网络平行堆叠相同拓扑结构的残差块, 减少超参数, 便于模型的移植。ResNeXt 的单个残差块在低维嵌入上实施一系列变换, 再将输出数据通过相加的方式聚合, ResNet 与 ResNeXt 基本模块的结构对比如图 6 所示。

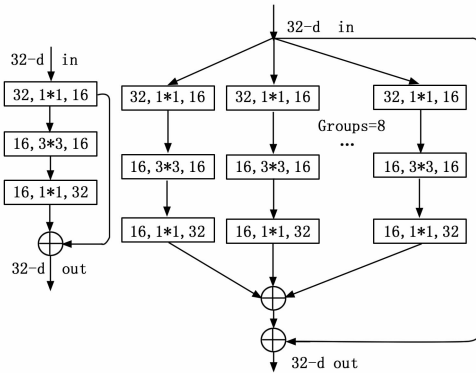


图 6 ResNet 和 ResNeXt 模块结构对比

左图为常见的 ResNet 网络, 当网络深度较深或参数较多时, 模型训练梯度可能会发生弥散现象, 本文采用残差结构优化信息传递路径, 避免梯度弥散现象的发生。图 6 中右图为改进的 ResNeXt 网络, 拆分-转换-合并的形式可表示为:

$$R(x) = \sum_{i=1}^c T_i(x) \quad (8)$$

其中:  $T_i$  为相同的拓扑结构,  $c$  为一个模块中所具有的不同分支的数目, 通常将  $c$  称为基数,  $c$  的取值可以是任意数。ResNeXt 网络既可以对信号的空间特征进行更加深层次的学习, 又可以利用多尺度结构提高模型性能。

### 3) 故障分类层:

在经过 ResNeXt 模型提取信号特征后, 利用全局平均池化将向量展平为一维, 最后使用全连接层的  $Softmax$  函数将

输出进行特征转换, 完成轴承故障诊断。Softmax 函数如式 9 所示。  $p(i)$  为第  $i$  个样本的概率值, 且  $0 < p(i) < 1$ 。

$$p(i) = softmax(x_i) = \frac{\exp(x_i)}{\sum_{j=1}^c \exp(x_j)} \quad (9)$$

本文采用交叉熵损失函数进行网络优化, 损失函数定义如式 (10) 所示, 式中  $n$  为每个训练批次的大小,  $k$  代表分类的类别数,  $k = [0, 1, \dots, 9]$ ,  $Y$  代表输出的概率分布,  $P$  代表真实的故障标签。

$$Loss(Y, P) = -\frac{1}{N} \sum_{i=0}^{n-1} \sum_{k=0}^{k-1} y_k \log(P_k) \quad (10)$$

## 2 实验及结果分析

为测试模型的诊断准确率, 本实验在采样频率为 12 kHz, 0hp 负载的条件下进行了测试实验, 该负载对应的转速为 1 797 rpm, 实验数据共包含 5 600 条训练数据, 2 400 条测试数据, 仿真实验采用 Python 的深度学习框架 keras 来实现; 仿真平台为 Intel i7-6700 CPU 3.40 GHz, 24 G 内存, Win 10 64 位操作系统; 不采用 GPU 加速。实验参数: 输入一维信号长度为 441, 采用 Adam 优化器进行梯度下降, 最大迭代次数 200, 每批次训练样本 256。

### 2.1 参数设置

虽然本文提出的 SE-ResNeXt 模型使用了组卷积的概念, 简化了超参数的选取, 但是卷积和池化层仍然需要进行参数的设定, 经过多次重复性实验, 最后得到了如表 2 的参数设置与模型结构。

表 2 模型参数

层类型	层参数
卷积层	$filters=8, kernel\_size=3, strides=1$
池化层	$pool\_size=2, strides=2$
SE 层	$ratio=8$
卷积层	$filters=16, kernel\_size=3, strides=1$
池化层	$pool\_size=2, strides=2$
SE 层	$ratio=8$
卷积层	$filters=64, kernel\_size=7, strides=2$
池化层	$pool\_size=3, strides=2$
ResNeXt 层 1	$\left[ \begin{array}{l} ker\_size=1, filters=16 \\ ker\_size=3, filters=16, C=8 \\ ker\_size=1, filters=32 \end{array} \right] \times 3$
ResNeXt 层 2	$\left[ \begin{array}{l} ker\_size=1, filters=32 \\ ker\_size=3, filters=32, C=8 \\ ker\_size=1, filters=64 \end{array} \right] \times 4$
平均池化层 (Softmax 层)	
全连接层	10

### 2.2 故障诊断试验

图 7 为 SE-ResNeXt 网络迭代 200 次的训练与测试准确率曲线图, 其中模型输入为原始一维振动信号数据, 图中可以看到本文所提模型在迭代大约 120 轮后训练准确率已达到

99.2 左右, 虽有较小波动但是后续逐渐趋于平稳, 证明了所提模型能够较好的完成滚动轴承的故障诊断与分类。




图 7 SE-ResNeXt 模型训练准确率曲线

本文采取的轴承故障诊断评估指标有准确率 (Accuracy): 所有正确分类的样本与所有样本之比; 召回率 (Recall): 实际正常的

样本与预测为正常样本之比; F1 (F1-Score): 准确率与召回率的调和平均, 其对应公式为:

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (11)$$

$$Rec = \frac{TP}{TP + FN} \quad (12)$$

$$F1 = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (13)$$

式中,  $TN$  代表将正常样本正确分类的样本数;  $TP$  代表将故障样本正确分类的样本数;  $FN$  代表错误分类故障样本数;  $FP$  代表错误分类正常样本数。利用上述指标对 SE-ResNeXt 模型诊断实验结果的评价如表 3 所示。

表 3 SE-ResNeXt 模型分类结果

类别	准确率/%	召回率/%	F1/%	样本数
0	97.90	97.08	97.49	240
1	99.58	98.33	98.95	240
2	96.68	97.08	96.88	240
3	100.00	100.00	100.00	240
4	100.00	100.00	100.00	240
5	98.77	100.00	99.38	240
6	100.00	100.00	100.00	240
7	99.59	100.00	99.79	240
8	100.00	100.00	100.00	240
9	100.00	100.00	100.00	240

在未使用模型时, 模型训练用时为 456 s, 利用模型复用技术, 该网络调用已训练完毕的模型, 进行故障诊断, 得到的平均准确率为 99.25%, 重构时间为 2.16 s。在本次实验中, 我们采用了 NIN、Inception-V1、VGG16、1DCNN 四种模型与 SE-ResNeXt 进行了十分类对比测试, 实验结果如图 8 所示。

为进一步分析模型的诊断分类效果, 将模型训练的 0 hp

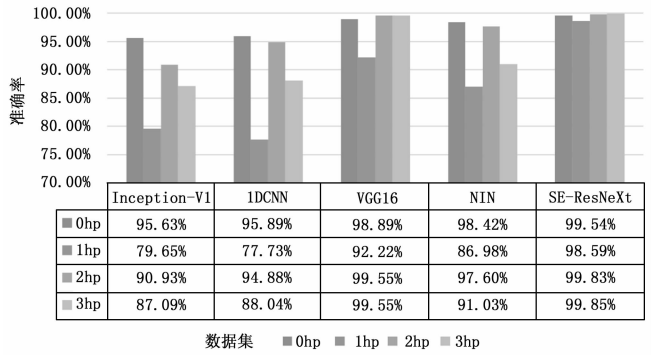


图 8 十次实验的平均测试准确率

负载数据在全连接层进行 T-SNE 技术的特征降维, 然后将二维特征向量进行可视化, 结果如图 9 所示。降维可视化表明, 在未进行分类时, 各种故障特征杂糅在一起, 难以区分, 经过 SE-ResNeXt 模型训练后在全连接层已经具有较为明显的十类分布。

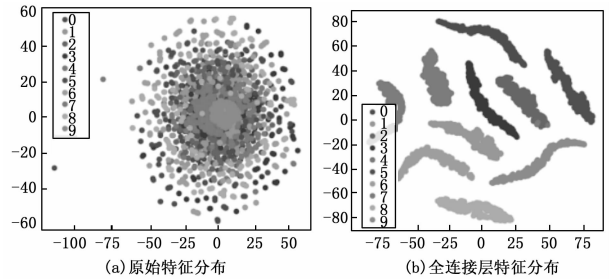


图 9 T-SNE 特征可视化

### 2.3 模型鲁棒性实验

在实际的工业生产中, 机械设备的滚动轴承往往处于较为复杂的环境条件下, 实验测量所得到的振动信号并不都是纯净的, 经常夹杂着许多的噪声。因此为了进一步的测试模型的鲁棒性, 使用 1 hp 的正常数据进行训练, 并在测试数据中加入不同强度的高斯白噪声, 评估模型在不同信噪比下的性能。

以正常振动信号与外圈故障 0.007 英寸的振动信号为例, 加入 10 dB 与 20 dB 的噪声信号, 信噪比的定义如式 (14) 所示。

$$SNR = 20 \times \log_{10} \left( \frac{A_{\text{signal}}}{A_{\text{noise}}} \right) \quad (14)$$

式中,  $A_{\text{signal}}$  为信号的幅度,  $A_{\text{noise}}$  为噪声幅度, 实验十次取平均值, 测试结果如表 4 所示。

表 4 模型抗噪声实验结果

方法 \ 信噪比	%					
	20 dB	18 dB	16 dB	14 dB	12 dB	10 dB
NIN	85.60	84.21	80.99	74.25	64.86	54.33
Inception-V1	78.74	77.67	76.42	72.73	66.77	58.43
VGG16	91.81	91.34	90.30	87.52	82.30	73.68
1DCNN	77.51	77.15	76.85	76.01	74.52	70.86
SE-ResNeXt	98.54	98.42	98.30	97.79	96.88	95.11

由表中的数据可知,模拟真实工业生产环境,添加不同的噪声信号后,模型的检测准确率有所下降,且噪声越大,对模型的影响越大。多次实验所测得的结果是SE-ResNeXt模型诊断准确率最高。分析1DCNN的抗噪声能力不错是其采用了卷积神经网络,提取的特征具有平移不变的特点,增加了模型的鲁棒性,但因为其并未进行特征重标定,模型感受野有限且学习深度不够而导致模型的准确率较低。VGG16仅仅依靠堆叠较深层次的卷积网络,虽然模型在噪声较小的情况下准确率较高,但是由于感受野有限,导致模型的鲁棒性欠佳。

### 3 结束语

本文首先介绍了常用的轴承故障诊断方法,然后在相关研究的基础上,提出了一种基于SE-ResNeXt网络的轴承故障诊断方法,该方法直接从原始一维振动信号提取特征进行学习,通过设计相应的网络参数完成最优诊断模型的构建,从而实现了端到端的轴承故障诊断。

实验结果表明:与目前常用的深度学习算法相比,本文所提模型具有更好地检测准确率,利用模型复用技术,可以在较短时间内实现故障的快速诊断。工业生产中的噪声会严重影响模型的诊断准确性,本文所提模型可减小噪声对诊断结果的影响,提高在噪声影响下的诊断准确率。

在将来的工作中,本文将针对以下两个方面进行更加深入的探索:

- 1) 研究数据类别高度不平衡的滚动轴承故障检测算法。
- 2) 在保持高准确率的情况下,探索故障检测时间较短的深度学习算法。

#### 参考文献:

[1] 赵磊,张永祥,朱丹宸.复杂装备滚动轴承的故障诊断与预测方法研究综述[J].中国测试,2020,46(3):17-25.

[2] CUI L, JIN Z, HUANG J, et al. Fault severity classification and size estimation for ball bearings based on vibration mechanism[J]. IEEE Access, 2019, 7: 56107-56116.

[3] 胡智勇,胡杰鑫,谢里阳,等.滚动轴承振动信号处理方法综述[J].中国工程机械学报,2016,14(6):525-531.

[4] AKHAND RAI, UPADHYAY S H. A review on signal processing techniques utilized in the fault diagnosis of rolling element bearings[J]. Tribology International, 2016, 96.

[5] 郭宇庭,肖树岩.基于小波变换的滚动轴承故障信号分析

(上接第40页)

[16] DAS S, BISWAS A, DASGUPTA S, et al. Bacterial foraging optimization algorithm: theoretical foundations, analysis, and applications[M]. Foundations of Computational Intelligence, 2009, 3: 23-55.

[17] BORDOLOI D J, TIWARI R. Optimum multi-fault classification of gears with integration of evolutionary and SVM algorithms[J]. Mechanism and Machine Theory, 2014, 73: 49

[J]. 中国测试, 2017, 43 (S1): 142-147.

[6] 刘畅,伍星,刘韬,等.基于近似等距投影和支持向量机的滚动轴承故障诊断[J].振动与冲击,2018,37(5):234-239.

[7] 李继猛,李铭,姚希峰,等.基于集合经验模式分解和K-奇异值分解字典学习的滚动轴承故障诊断[J].计量学报,2020,41(10):1260-1266.

[8] ZHAO R, YAN R Q, CHEN Z H, et al. Deep learning and its applications to machine health monitoring[J]. Mechanical Systems and Signal Processing, 2019, 115: 213-237.

[9] ZHANG Y, XING K S, BAI R X, et al. An enhanced convolutional neural network for bearing fault diagnosis based on time-frequency image[J]. Measurement, 2020, 157: 107667

[10] MIAO H, DAVID H. A new hybrid deep signal processing approach for bearing fault diagnosis using vibration signals[J]. Neurocomputing, 20-20, 396.

[11] 张伟.基于卷积神经网络的轴承故障诊断算法研究[D].哈尔滨:哈尔滨工业大学,2017.

[12] 管涛,王辉,刘智豪,王民,高相胜.基于多输入层卷积神经网络的滚动轴承故障诊断模型[J].振动与冲击,2020,39(12):142-149.

[13] 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.

[14] Case Western Reserve University Bearing Data Center [EB/OL]. [2020-12-22]. [http://cse.groups.ca-se.edu/bearing\\_data\\_center/pages/download-data-file](http://cse.groups.ca-se.edu/bearing_data_center/pages/download-data-file).

[15] HU J, SHEN L, ALBANIE SAMUEL, et al. Squeeze-and-Excitation Networks. [J]. IEEE transactions on pattern analysis and machine intelligence, 2020, 42 (8): 7132-7141.

[16] CUI X, GOEL V, KINGSBURY B. Data augmentation for deep convolutional neural network acoustic modeling [C] // 2015 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), IEEE, 2014.

[17] 周林春,陈春俊.复数卷积神经网络滚动轴承故障诊断研究[J].中国测试,2020,46(11):109-115.

[18] 董绍江,裴雪武,吴文亮,等.基于多层降噪技术及改进卷积神经网络的滚动轴承故障诊断方法[J].机械工程学报,2021,57(1):1-9.

[19] 熊剑,邓松,时大方.基于改进残差网络的滚动轴承故障诊断[J].轴承,2020(11):50-55.

[18] SUGUMARAN V, RAMACHANDRAN K I. Effect of number of features on classification of roller bearing faults using SVM and PSVM [J]. Expert Systems with Applications, 2011, 38 (4): 4088-4096.

[19] 戴婧睿,吴奇.飞行员负荷通过飞行数据优化识别仿真[J].计算机仿真,2017,34(8):45-49.