

doi:10.12068/j.issn.1005-3026.2024.11.009

# 深度残差收缩网络在滚动轴承故障诊断中的应用

张执锦, 李鹤, 黄宇实, 王文学  
(东北大学 机械工程与自动化学院, 辽宁 沈阳 110819)

**摘要:** 针对滚动轴承故障在强噪声环境下难以进行精准诊断的问题, 提出一种基于池化融合的深度残差收缩网络用于滚动轴承故障诊断. 首先, 通过引入残差连接避免由于网络过深而带来的梯度消失或爆炸的风险; 然后, 采用多尺度池化特征融合提取振动信号更丰富的局部特征并通过注意力机制自动推导软阈值函数的最优阈值进行自适应去噪; 最后, 通过带标签的滚动轴承故障数据对所提网络进行训练, 以实现滚动轴承在强噪声环境下的精准故障诊断. 实验结果表明, 在不同信噪比(signal-to-noise ratio, SNR)的噪声条件下, 基于池化融合的深度残差收缩网络与传统的模型相比能够实现更高的故障诊断精度.

**关键词:** 深度残差收缩网络; 池化融合; 注意力机制; 滚动轴承; 故障诊断

中图分类号: TH 7 文献标志码: A 文章编号: 1005-3026(2024)11-1587-08

## Application of Deep Residual Shrinkage Network in Rolling Bearing Fault Diagnosis

ZHANG Zhi-jin, LI He, HUANG Yu-shi, WANG Wen-xue

(School of Mechanical Engineering & Automation, Northeastern University, Shenyang 110819, China.  
Corresponding author: LI He, E-mail: hli@mail.neu.edu.cn)

**Abstract:** Given that it is difficult to accurately diagnose rolling bearing faults in a strong noise environment, a deep residual shrinkage network is proposed with pooling fusion for rolling bearing fault diagnosis. Firstly, the proposed method employs residual connections to avoid the risk of gradient vanishing or explosion due to excessive network depth. Then, the approach uses multi-scale pooling feature fusion to extract more comprehensive local features from vibration signals, and an attention mechanism to automatically derive the optimal threshold of a soft threshold function. Finally, the network is trained through labeled data to achieve the accurate fault diagnosis of rolling bearings in a strong noise environment. Experiment results show that the deep residual shrinkage network based on pooling fusion can outperform the traditional models in diagnosing rolling bearing faults under noise conditions with different SNRs.

**Key words:** deep residual shrinkage network; pooling fusion; attention mechanism; rolling bearing; fault diagnosis

滚动轴承是现代机械设备的重要组成部分, 由于其长期服役在恶劣的环境中而极易发生故障, 容易带来经济损失, 更严重的会造成人员伤亡<sup>[1-2]</sup>. 因此, 对滚动轴承的健康状态进行有效的诊断至关重要<sup>[3]</sup>.

目前, 滚动轴承故障诊断方法主要包括信号处理方法与机器学习方法. 其中, 基于信号处理的故障诊断方法通过从振动信号中提取故障特

征来识别故障<sup>[4-6]</sup>. 例如, Ni等<sup>[4]</sup>提出了一种新的基于变分模态分解(variational mode decomposition, VMD)的信号处理方法, 该方法对参数进行了优化, 使其能够更有效地检测故障特征. 罗忠等<sup>[6]</sup>将改进二阶循环平稳解卷积方法应用于轴承的故障检测. 然而, 信号处理方法关键参数的选择需要专业知识和经验, 这对工程师提出了挑战, 并阻碍了信号处理技术在现实工业场景中的应用.

收稿日期: 2023-06-05

基金项目: 国家自然科学基金资助项目(51675091).

作者简介: 张执锦(1995-), 男, 辽宁盘锦人, 东北大学博士研究生; 李鹤(1975-), 男, 河南方城人, 东北大学教授, 博士生导师.

相比之下,基于机器学习的方法依赖于训练具有足够标记的历史监控数据的自动分类器,然后将其用于故障诊断任务.这些方法的主要优点是工程师可以在不需要专家知识的情况下进行故障诊断.近年来,传统的基于机器学习的故障诊断方法得到了广泛关注<sup>[7-9]</sup>.例如,Chen等<sup>[8]</sup>利用小波分析从时频域提取多域特征,利用多核相关向量机进行故障诊断.Van等<sup>[9]</sup>利用非局部均值和经验模态分解获得特征,提出了一种新的轴承故障诊断分类器.传统的基于机器学习的故障诊断方法通常需要一些能够表征健康状态的统计参数,如峰度和熵等,来训练故障分类器,从而实现故障类型的识别.传统基于机器学习的故障诊断方法的诊断精度很大程度上取决于统计特征参数的选择.

为了解决上述问题,深度学习作为一种能够从数据中自动提取特征的深度架构并且能够建立健康状态与输入数据之间端到端的映射关系,从而受到了众多学者的青睐.目前,应用在故障诊断领域的深度学习方法主要包括:①卷积神经网络(convolutional neural network, CNN)<sup>[10-11]</sup>;②深度置信网络(deep belief network, DBN)<sup>[12-13]</sup>;③自动编码器(autoencoder, AE)<sup>[14-15]</sup>.例如,Chen等<sup>[10]</sup>采用循环谱分析与CNN有效地实现了轴承的故障分类.Niu等<sup>[12]</sup>采用粒子群优化算法对DBN的网络结构进行了优化,并将优化后的网络应用于轴承的故障诊断.Meng等<sup>[14]</sup>改进了传统的去噪自编码器,并应用于滚动轴承的故障诊断.上述文献证明了深度学习方法具备故障诊断的能力.然而,滚动轴承的实际工作场景是复杂多变的,常伴随着较强的背景噪声,这些噪声往往会使振动信号的故障特征被淹没,从而导致传统的深度学习方法的故障诊断精度降低.

为了提升传统深度学习方法在强噪声环境下的故障诊断能力,Zhao等<sup>[16]</sup>提出了一种深度残差收缩网络(deep residual shrinkage network, DRSN),该网络在CNN的基础上通过引入残差思想、软阈值去噪以及注意力机制,可以消除振动信号中的噪声特征.目前,DRSN已经广泛应用于故障诊断领域.然而,传统DRSN忽略了阈值自动推导过程中单一池化特征提取的局限性,这阻碍了其诊断性能的进一步提升.

综上,本文提出基于池化融合的深度残差收缩网络,在阈值推导子网络中采用平均池化与最大池化同时进行振动信号的多尺度特征提

取,使得阈值的推导综合考虑了更为全面的局部特征,进一步提升其在噪声条件下的故障诊断精度.

## 1 理论基础

DRSN可以视为CNN的变体,其延续了CNN的主体结构,并在此基础上融合了残差学习、软阈值去噪和注意力机制.DRSN有效解决了传统深层网络难以训练的难题并且提升了对含噪振动信号的特征提取能力,即具有良好的去噪能力.

### 1.1 残差学习

如图1所示,残差学习思想依靠其独特的恒等映射结构而广泛应用在深度学习架构中,它可以有效避免深层网络结构中的梯度消失或爆炸现象.残差学习可以表示为

$$Y = \Gamma(X, \{S_i\}) + X. \quad (1)$$

式中: $X$ 和 $Y$ 分别是输入和输出向量; $S_i$ 是第 $i$ 个权重层的系数; $\Gamma$ 是残差函数,其表达式为

$$\Gamma = S_2 \gamma(S_1^T X). \quad (2)$$

式中, $\gamma$ 是激活函数.




图1 残差学习的结构

Fig. 1 Structure of the residual learning

### 1.2 软阈值函数

软阈值函数是一种应用广泛的去噪函数,其核心思想是消除阈值区域的近零特征.软阈值函数的定义为

$$y = f(x) = \begin{cases} \text{sgn}(x)(|x| - \tau), & |x| \geq \tau; \\ 0, & |x| < \tau. \end{cases} \quad (3)$$

式中: $x$ 和 $y$ 分别是输入特征和输出特征; $\tau$ 表示阈值; $\text{sgn}(\cdot)$ 为符号函数,当 $x > 0$ 时, $\text{sgn}(x) = 1$ ;当 $x = 0$ 时, $\text{sgn}(x) = 0$ ;当 $x < 0$ 时, $\text{sgn}(x) = -1$ .

阈值设置是软阈值去噪的关键问题,文献[16]采用注意力机制自适应推导出最优阈值,有效地解决了这一问题.

### 1.3 注意力机制

Squeeze-and-excitation(SE)是一种常用的注意力机制,可以自适应调节网络对于不同信道特

征的关注程度. SE 可以用来突出重要的特征, 忽略不重要的特征, 首先, 这些特征被压缩到一个通道描述符中, 以获得包含全局信息的聚合特征, 使得  $y$  的第  $i$  个元素计算式为

$$y_i = \frac{1}{a \times b} \sum_{m=1}^a \sum_{n=1}^b x_i(m, n). \quad (4)$$

式中,  $a \times b$  表示空间维度.

通过激励步骤得到不同通道的权重系数  $s$ , 其计算方法为

$$s = \sigma(W_2 \delta(W_1 y)). \quad (5)$$

式中:  $\sigma$  和  $\delta$  分别表示 Sigmoid 和 ReLU 激活函数,

$W_i$  为第  $i$  组可训练参数.

## 2 基于池化融合的 DRSN

### 2.1 DRSN 网络

如图 2 所示, DRSN 由输入层、卷积层(Conv)、残差收缩建筑单元(residual building shrinkage unit, RSBU)、批量标准化层(batch normalization, BN)、线性整流层(rectifier linear unit, ReLU)、全局平均池化层(global average pooling, GAP)、全连接层(fully connected, FC)和输出层组成.




图2 DRSN的整体结构

Fig. 2 Overall structure of DRSN

Conv 是区别于传统全连接神经网络的关键组成部分, 是通过使用卷积而不是矩阵乘法来实现的, Conv 使卷积层中的卷积核可以比 FC 中的变换矩阵具有更少的参数.

BN 是一种特征归一化技术, 作为可训练的过程被插入深度学习架构中, 目的是将特征转换成理想的分布, 从而加快训练速度.

ReLU 是深度神经网络中最流行的激活函数之一. 它的非零输出特征相对于输入特征的偏导数总是 1, 从而有效地降低了梯度爆炸和消失的风险.

GAP 计算输出特征图的每个通道的平均值,

从而使 FC 中需要训练的参数减少.

RSBU 是 DRSN 的核心模块. 如图 3 所示, 除一些基本功能组件外, 还融合了残差学习的思想以及软阈值去噪. 具体来说, 一方面通过恒等映射路径, 使得梯度可以有效地流向靠近输入层的较早层, 从而可以更有效地更新参数, 降低训练难度; 另一方面利用注意力机制针对每个样本自适应推导相应的阈值, 然后利用软阈值函数对振动信号进行去噪, 如图 4 所示. 因此, DRSN 相较于传统的 CNN 具备训练难度小、去噪能力强等诸多优势, 被广泛应用于故障诊断领域.

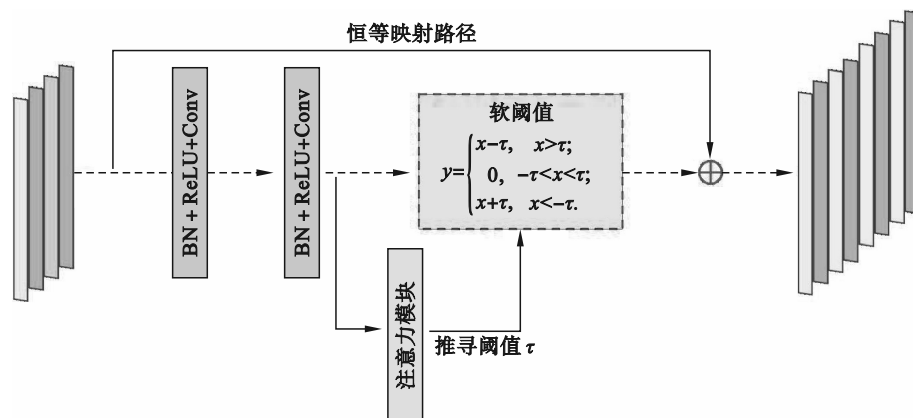


图3 RSBU的整体结构

Fig. 3 Overall structure of RSBU




图4 注意力模块的结构

Fig. 4 Structure of the attention module

### 2.2 基于池化融合的DRSN

如图5所示,本文提出的基于池化融合的DRSN(DRSN based on pooling fusion, DRSN-PF)采用最大池化层与平均池化层的多池化融合设计来替代原始的GAP,以实现阈值推导过程中的

信息补偿,使注意力模块生成考虑更全面的局部特征的阈值,进一步增强了对噪声振动信号的提取能力,值得注意的是,DRSN-PF的其他组成部分与原始DRSN保持一致.此外,基于DRSN-PF的滚动轴承故障诊断模型的流程如图6所示.

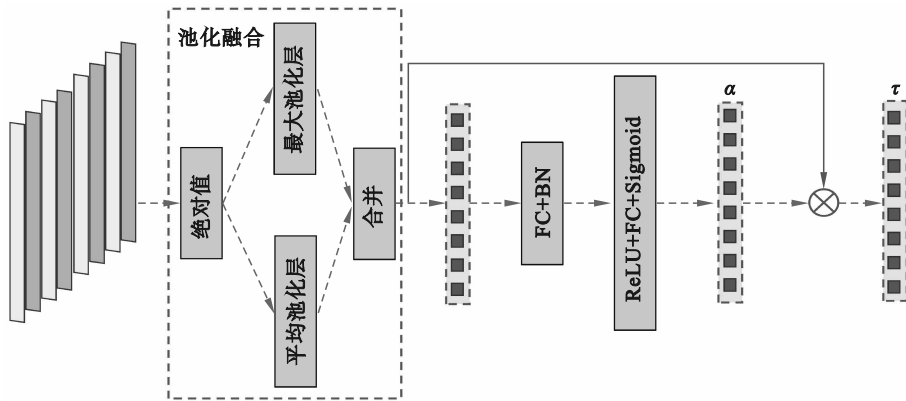


图5 基于池化融合的注意力模块结构

Fig. 5 Structure of the attention module based on pooling fusion

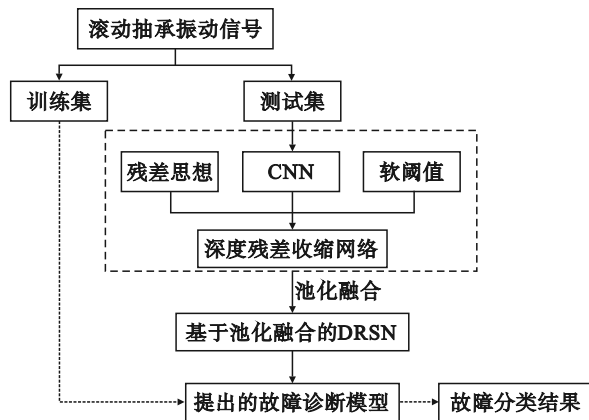


图6 基于DRSN-PF的滚动轴承故障诊断流程

Fig. 6 Fault diagnosis flowchart of rolling bearing based on DRSN-PF

优越性,本文使用了西储大学(case western reserve university, CWRU)的数据集,其实验台如图7所示.




图7 CWRU的实验台

Fig. 7 Experiment bench of CWRU

## 3 实验验证

### 3.1 实验数据

为了验证本文提出的DRSN-PF的有效性及

在本实验中,采集频率为12 kHz,负载为0 W,轴承状态包括一种健康状态(H)和3种故障状态,包括内圈故障(IF)、外圈故障(OF)和球圈故障(BF),而且在每种故障条件下都包含不同程度的故障尺寸,分别为0.177 8,0.355 6和0.533 4 mm.

关于数据集的详细描述如表 1 所示,其中每种故障状态包含 3 000 个样本,且每个样本由 400 个振动信号点组成.训练集与测试集的样本数目比例为 14:1.

表 1 CWRU 数据集的详细描述  
Table 1 Detailed description of the CWRU dataset

标签	故障状态(直径/mm)	训练样本	测试样本
0	正常	2 800	200
1	外圈故障(0.177 8)	2 800	200
2	外圈故障(0.355 6)	2 800	200
3	外圈故障(0.533 4)	2 800	200
4	内圈故障(0.177 8)	2 800	200
5	内圈故障(0.355 6)	2 800	200
6	内圈故障(0.533 4)	2 800	200
7	滚动体故障(0.177 8)	2 800	200
8	滚动体故障(0.355 6)	2 800	200
9	滚动体故障(0.533 4)	2 800	200

### 3.2 超参数设置

本文提出的 DRSN-PF 的主体网络结构与 DRSN 保持一致,如表 2 所示,主要包括 6 个 RSBU,主要区别在于本文的 RSBU 中的注意力模块由本文提出的基于池化融合的注意力模块所取代.该方法采用的相关优化参数设置主要依据参考文献[16],其中,学习率设置为 0.001,动量比设置为 0.9,训练的 epoch 数目设置为 16.

### 3.3 实验结果分析

为了验证本文提出的 DRSN-PF 优势,将此

方法与经典的 CNN, ResNet 以及 DRSN 进行了实验对比.为了确保实验对比的公平性,所有方法采用相同的超参数设置与数据集,此外, CNN, ResNet 的网络结构与 DRSN 的区别在于 RSBU 模块不同,具体来说, ResNet 的 RSBU 相较于 DRSN 缺少阈值去噪部分, CNN 相较于 DRSN 不仅缺少了阈值去噪部分,还缺少了恒等映射路径.4 种方法在不同信噪比条件下的诊断精度实验结果如图 8 所示,可以看出本文提出的 DRSN-PF 相较于其他 3 种方法可以实现更好的诊断精度,尽管在 SNR=2 dB 的噪声条件下, DRSN-PF 的诊断精度略低于 DRSN,但在大多数情况下,本文提出的 DRSN-PF 可以实现更高的诊断准确率,例如当 SNR=-4 dB 时, DRSN-PF 的诊断精度相较于 CNN, ResNet 和 DRSN 分别提升了 10.4%, 9.7%, 和 2.7%.

表 2 DRSN-PF 的网络结构  
Table 2 Network structure of DRSN-PF

模块名称	模块数量	卷积核的数量,卷积核的尺寸,步长	输出尺寸
Conv	1	(4,3,2)	4×200×1
RSBU	1	(4,3,2)	4×100×1
RSBU	1	(4,3,1)	4×100×1
RSBU	1	(8,3,2)	8×50×1
RSBU	1	(8,3,1)	8×50×1
RSBU	1	(16,3,2)	16×25×1
RSBU	1	(16,3,2)	16×25×1
BN, ReLU, GAP	1	—	16
FC	1	—	10

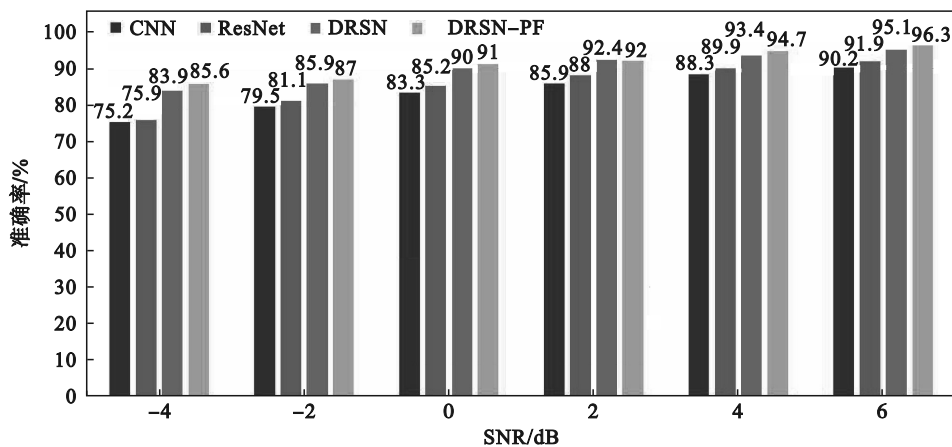


图 8 4 种方法在不同信噪比条件下的诊断结果

Fig. 8 Diagnostic results of four methods under different SNR conditions

为了更清晰地观察不同类别实际的诊断结果,4 种对比方法在 SNR=-4 dB 情况下的混淆矩阵如图 9 所示.可以看出,图 9d 中有 5 个类别的识

别精度达到了 100%,相比之下,图 9a~图 9c 中最多仅有两个类别达到了 100%,进一步说明 DRSN-PF 的分类效果是最优的.

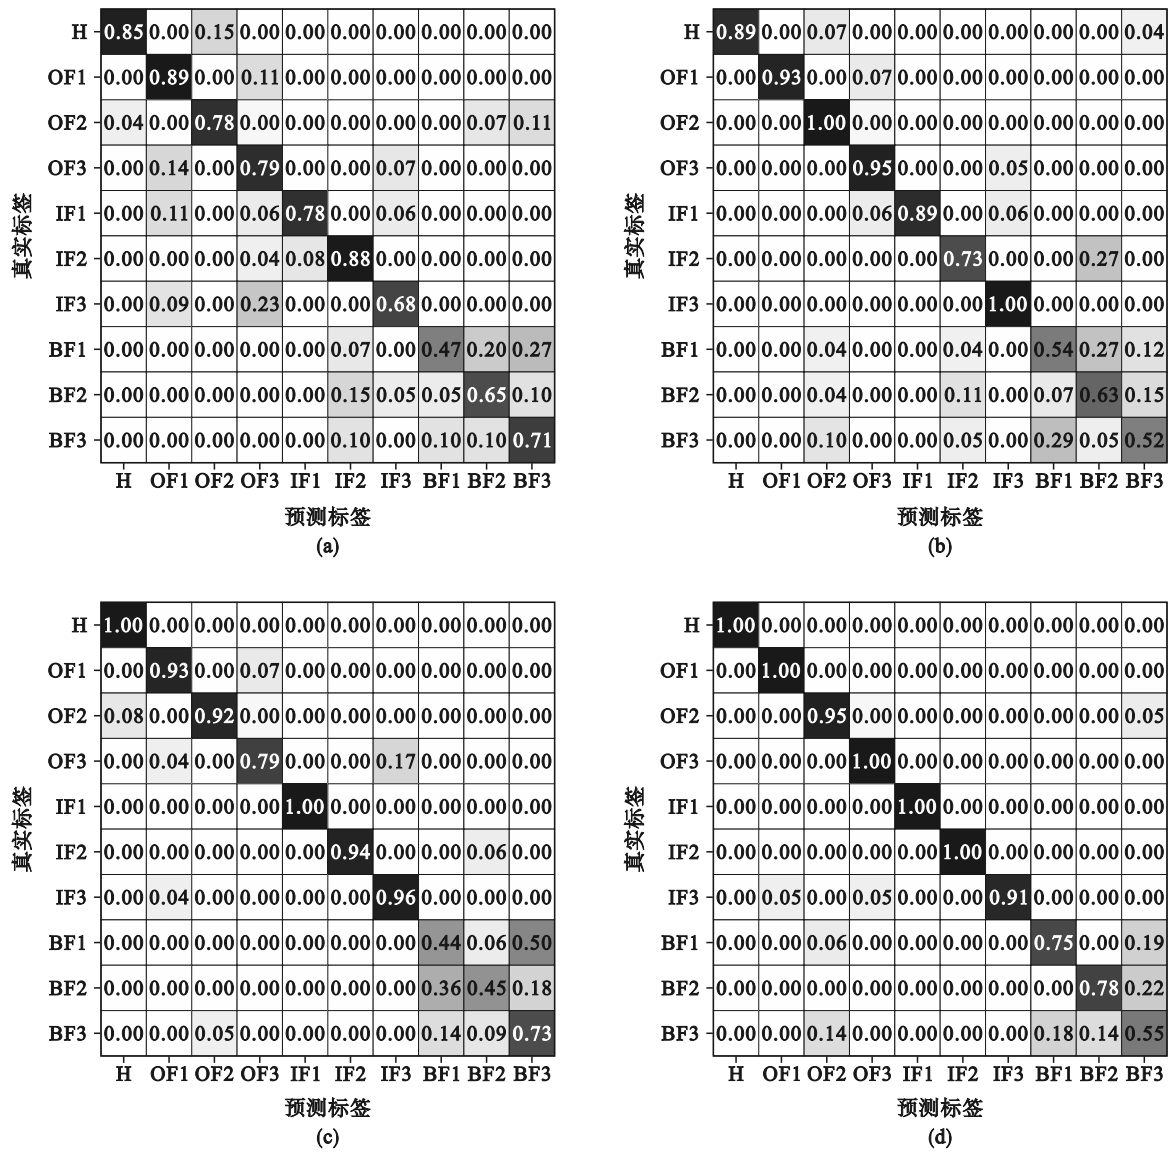




图9 不同方法的混淆矩阵(SNR=-4 dB)

Fig. 9 Confusion matrix for different methods (SNR=-4 dB)

(a)—CNN; (b)—ResNet; (c)—DRSN; (d)—DRSN-PF.

为了从空间特征分布的角度更直观地评估所有方法的诊断效果,采用t-SNE技术进行高维特征的可视化.如图10所示,可以看出,当SNR=-4 dB时,在CNN, ResNet和DRSN方法中,3种

BF健康状态在二维特征空间存在严重的重叠,相比之下在DRSN-PF中3种BF健康状态类别区分的效果是最佳的.






图 10 不同方法的特征可视化 (SNR=-4 dB)

Fig. 10 Feature visualization for different methods (SNR=-4 dB)

(a)—CNN; (b)—ResNet; (c)—DRSN; (d)—DRSN-PF.

所有方法的训练和测试曲线如图 11 所示,可以看出,当 SNR=-4 dB 时,DRSN-PF 的训练损失

与测试损失要明显低于 CNN, ResNet 和 DRSN 3 种方法,进一步证明了本文提出方法的优越性.

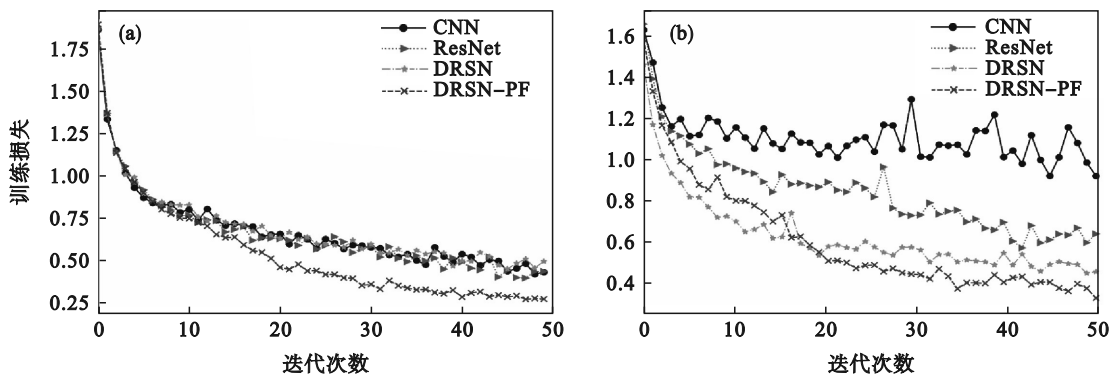


图 11 不同方法的训练损失与测试损失曲线 (SNR=-4 dB)

Fig. 11 Training loss and test loss curves for different methods (SNR=-4 dB)

(a)—训练曲线; (b)—测试曲线.

### 4 结 语

本文针对强噪声环境下诊断模型诊断精度下降的问题,提出了一种基于池化融合的深度残差收缩网络用于滚动轴承故障诊断.该方法在深度残差收缩网络的阈值推导阶段,采用平均池化与最大池化同时提取振动信号的多尺度特征并进行特征融合,进一步提升其在噪声条件下的诊断精度.通过实验证明了本文提出的 DRSN-PF 方法可以在不同信噪比的噪声条件下有效实现滚动轴承的故障诊断,同时实验结果表明该方法与传统的方法相比,可以实现更高的故障诊断准确率.本文所采取的池化融合特征提取方式也可以简易地应用于其他网络结构中,进一步提升网络的特征提取能力.

#### 参考文献:

[ 1 ] Zhao H M, Liu H D, Jin Y, et al. Feature extraction for

data-driven remaining useful life prediction of rolling bearings [J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 70:3511910.

[ 2 ] Shi H T, Shang Y J. Initial fault diagnosis of rolling bearing based on second-order cyclic autocorrelation and DCAE combined with transfer learning [J]. *IEEE Transactions on Instrumentation and Measurement*, 2021, 71:3503818.

[ 3 ] Cheng Y W, Lin M X, Wu J, et al. Intelligent fault diagnosis of rotating machinery based on continuous wavelet transform-local binary convolutional neural network [J]. *Knowledge-Based Systems*, 2021, 216:106796.

[ 4 ] Ni Q, Ji J C, Feng K, et al. A fault information-guided variational mode decomposition (FIVMD) method for rolling element bearings diagnosis [J]. *Mechanical Systems and Signal Processing*, 2022, 164:108216.

[ 5 ] 王新刚,王超,韩凯忠.基于优化 VMD 和 MCKD 的滚动轴承早期故障诊断方法[J]. *东北大学学报(自然科学版)*, 2021, 42(3):373-380, 388.

(Wang Xin-gang, Wang Chao, Han Kai-zhong. Early fault diagnosis method of rolling bearings based on optimization of VMD and MCKD [J]. *Journal of Northeastern University (Natural Science)*, 2021, 42(3):373-380, 388.)

[ 6 ] 罗忠,徐迪,李雷,等.基于改进二阶循环平稳解卷积的轴承故障检测方法[J]. *东北大学学报(自然科学版)*, 2021, 42(5):673-678.

(Luo Zhong, Xu Di, Li Lei, et al. Bearing fault detection

