DOI: 10.3901/JME.2021.01.148

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*

董绍江¹ 裴雪武¹ 吴文亮¹ 汤宝平² 赵兴新³

(1. 重庆交通大学机电与车辆工程学院 重庆 400074;

2. 重庆大学机械传动国家重点实验室 重庆 400030;

3. 重庆长江轴承股份有限公司 重庆 401336)

摘要: 针对滚动轴承微弱故障在强噪声下难以实现有效诊断的问题, 提出了一种基于多层降噪技术及改进卷积神经网络(Improved convolution neural network, ICNN)的轴承故障诊断新方法。首先, 对滚动轴承的一维振动信号进行预处理, 得到标签化的数据样本, 分为训练集和测试集; 然后采用奇异值分解(Singular value decomposition, SVD)处理训练样本, 通过二分法之均值法选择有效奇异值个数, 获得原始降噪信号和带噪信号; 为了避免丢失微弱故障细节特征, 将带噪信号经过 SVD 进一步去噪消除模态混叠并输入经验模态分解(Empirical mode decomposition, EMD)得到内禀模态函数, 根据方差贡献率大小选出 IMF 分量并与原始降噪信号叠加得到最终信号; 将处理后的训练集数据输入到引入注意力机制(Attention mechanism, AM)的 ICNN 中进行学习; 最后将得到的诊断模型应用于测试集, 输出故障类别诊断结果。通过滚动轴承故障诊断模拟试验, 在强噪声环境下进行测试, 结果表明所提方法能更准确的在强噪声环境中实现轴承的故障诊断。

关键词: 故障诊断; 奇异值分解; 经验模态分解; 注意力机制; 卷积神经网络

中图分类号: TH165; TN911

Rolling Bearing Fault Diagnosis Method Based on Multilayer Noise Reduction Technology and Improved Convolutional Neural Network

DONG Shaojiang¹ PEI Xuewu¹ WU Wenliang¹ TANG Baoping² ZHAO Xingxin³

(1. School of Mechantronics and Vehicle Engineering, Chongqing Jiaotong University, Chongqing 400074;

2. The State Key Laboratory of Mechanical Transmission, Chongqing University, Chongqing 400030;

3. Chongqing Changjiang Bearing Co., Ltd, Chongqing 401336)

Abstract: Aiming at the problem that the weak fault characteristics of rolling bearings are difficult to achieve effective diagnosis under strong noise, a new method of bearing fault diagnosis based on multilayer noise reduction technology and improved improved convolutional neural network(ICNN) is proposed. First, the vibration signal of the rolling bearing is pre-processed to obtain labeled data samples, which are divided into a training set and a test set. Then singular value decomposition(SVD) is used to process the training samples, the number of valid singular values is selected by the singular value mean method to obtain the original noise-reduced signal and the noisy signal. In order to avoid losing the details of weak faults, the noisy signal is further denoised by SVD to eliminate modal aliasing and input empirical mode decomposition to obtain the intrinsic mode function(IMF). The IMF component is selected according to the variance contribution rate and superimpose it with the original noise reduction signal to obtain the final signal. The processed training set data is input into the improved ICNN that introduces attention mechanism for learning. Finally, the obtained diagnostic model is applied to the test set, the fault category diagnosis results are output. Through the rolling bearing fault diagnosis simulation test, the test is performed in a strong noise environment, the results show that the proposed method

* 国家自然科学基金(51775072)和重庆市科技创新领军人才支持计划(CSTCCCXLJRC201920)资助项目。20200330 收到初稿, 20201010 收到修改稿

can more accurately realize the bearing fault diagnosis in a strong noise environment.

Key words: fault diagnosis; singular value decomposition; empirical mode decomposition; attention mechanism; convolutional neural network

0 前言

滚动轴承是机械系统中关键零部件之一，一旦出现严重故障可能会导致机器停机，造成巨大的经济损失。在实际工作过程中，轴承故障振动信号微弱，容易被强干扰信号覆盖^[1]。因此，从强噪声环境下的轴承故障振动信号中提取出故障特征，对故障进行及时诊断可以有效避免故障的持续恶化^[2]。

张建财等^[3]先利用变分模态分解方法得到多个模态分量，再计算每个分量的多尺度排列熵，但基于粗粒化的方式获得短时时间序列下的多尺度信息时，熵值误差会增加。陈宗祥等^[4]先利用小波包分解消除原始振动信号中的大部分干扰信号，然后采用经验模态分解(Empirical mode decomposition, EMD)提取故障特征信号，最后对故障特征信号进行双谱解调，但双谱图的分辨率较低。

目前，除了信号处理方法，深度学习方法也应用于轴承故障检测。卷积神经网络(Convolution neural network, CNN)是一种有监督的深度学习算法，该方法无需对原始信号进行预处理就能实现从端到端的轴承故障诊断。ZHANG 等^[5]提出了基于自适应批量归一化(Adaptive batch normalization, AdaBN)算法的卷积神经网络模型，该方法直接将原始振动信号作为网络模型的输入，可以避免丢失重要时域特征，成功实现了变工况负载下的轴承故障诊断。余博等^[6]利用深度卷积变分自编码网络训练由傅里叶变换得到的频域数据，在识别变工况负载下轴承故障信号比文献[5]的效果更佳，但是都没有考虑到轴承服役在强噪声环境下的情况。

基于以上分析，本文通过模拟工业现场的强噪声环境下滚动轴承故障诊断试验，采用一种基于多层降噪技术及改进卷积神经网络的方法实现了滚动轴承故障诊断。该方法首先将处理好的训练样本构造 Harkel 矩阵；再采用奇异值分解(Singular value decomposition, SVD)将 Hankel 矩阵分解为奇异值矩阵和奇异值矢量矩阵，通过二分之均值法计算信号的有效奇异值个数，并将其用于信号重构；再将带噪信号经过 SVD 去噪和 EMD 分解，最后将提取出的故障信号输入到改进卷积神经网络(Improved convolution neural network, ICNN)中进行训练，得

到轴承故障诊断模型。最后在强噪声环境下进行轴承故障测试，结果表明所提方法的可行性和有效性。

1 Harkel 矩阵与奇异值分解降噪原理

对于一个含有强干扰信号的一维轴承振动信号 $\mathbf{X} = \{x_1, x_2, x_3, \dots, x_N\}$ ，无法对其直接进行 SVD，因此选择先对 $\mathbf{X}$ 构造 Hankel 矩阵 $\mathbf{A}_{m \times n}$ ，结构如下

$$\mathbf{A}_{m \times n} = \begin{bmatrix} x(1) & \dots & x(n) \\ \vdots & & \vdots \\ x(m) & \dots & x(N) \end{bmatrix} = \mathbf{D}_{m \times n} + \mathbf{W}_{m \times n} \quad (1)$$

式中， $N = m + n + 1$ ， $\mathbf{D}_{m \times n}$ 为真实信号空间； $\mathbf{W}_{m \times n}$ 为干扰信号空间。当 Hankel 矩阵的维度取 $m = N / 2$ 时，SVD 算法会有比较好的降噪效果^[7]。

SVD 分解的降噪效果往往取决于奇异值个数的选择^[8]，由于有用信号主要集中在前面 i 个较大的奇异值，通过保留合适的奇异值，再进行 SVD 的逆过程就可以消除原始振动信号中的噪声，从而提取到有用的特征信号。有效奇异值个数可以通过奇异值均值法、奇异值中值法、奇异值差分谱法、中心差商法等阈值方法获得。各个奇异值的中心差商可由式 (2) 得到

$$Z_i = \frac{\sigma_{i-1} - \sigma_{i+1}}{2} \quad (i = 2, 3, \dots, p-1) \quad (2)$$

式中， Z_i 为第 i 个奇异值的中心差商，且 $Z_1 = 0$ ； σ_{i-1} 和 σ_{i+1} 分别为第 $i-1$ 个和第 $i+1$ 个奇异值。当中心差商取得最大值时，此时的 i 为有效奇异值的个数，将奇异值矩阵的前 i 个奇异值选出而其余所有的奇异值置零，从而可以实现奇异值个数的准确选择。

2 经验模态分解方法

EMD^[9-10]可以自适应的将非线性、非平稳性信号分解成一定数量的 IMF 分量和一个单调趋势项，EMD 的本质是将原始信号从高频分解到低频，从而得到一系列不同尺度特征的 IMF 分量。即

$$X(t) = \sum_{i=1}^n c_i(t) + r(t) \quad (3)$$

式中， $c_i(t)$ 为各阶模态函数 IMF； $r(t)$ 为残余分量； n 为 IMF 的个数。可以看出，得到的 IMF 分量需满

足: ① 极大、极小值点的数目和应该与过零点的数目相等或相差一个; ② 在 IMF 分量的任何时间点处, 上包络线和下包络线的均值应为零。

3 提出的轴承故障诊断方法

3.1 数据集增强

训练神经网络模型需要的大量数据, 使用更多的训练样本可以增强模型的泛化能力^[11]。文中在获得轴承故障信号数据集时采用重叠采样方法, 不仅增多了训练样本数量, 防止数据过拟合, 还增强样本数据之间尽可能多的相关性。

3.2 SVD 结合 EMD 的多层降噪技术

通过以上介绍, 针对滚动轴承故障信号微弱且工业现场噪声干扰大的问题, 本文提出基于 SVD 和 EMD 的组合降噪方法。先对原始含噪信号进行噪声消除, 再提取故障特征, 最后将根据降噪信号训练得到的改进卷积神经网络模型应用于滚动轴承故障诊断。其具体步骤如图 1 所示。

图 1 SVD 结合 EMD 的多层降噪技术流程图

(1) SVD 将 Hankel 矩阵分解得到奇异值矩阵和奇异值矢量矩阵, 通过奇异值二分之均值法将奇异值分为两部分。第一部分是二分之均值选取的有效奇异值, 用于传统 SVD 方法反演得到信号 $x_1(t)$, $x_1(t)$ 实现了信号的滤波处理, 有用信号的能量较强; 第二部分是选取的有效奇异值置零取余下部分奇异值, 再反演得到信号 $x_2(t)$, $x_2(t)$ 是传统 SVD 降噪的残余项, 其中含有微弱的有用信号。

(2) 为了避免丢失时域特征, 将信号 $x_2(t)$ 首先通过基于中心差商算法的 SVD 去除大量干扰信号为 EMD 分解做准备, 可以有效抑制 EMD 分解的模式混叠问题; 再采用 EMD 方法得到一系列 IMF 分

量, 根据对每个分量计算得到的方差贡献率大小提取故障特征, 贡献率越大表明该 IMF 分量对原始信号的贡献程度越大, 其他 IMF 分量可视作虚假分量而被消除, 最后对选择出的 IMF 分量进行叠加得到降噪信号 $x_3(t)$ 。

(3) 将 $x_1(t)$ 、 $x_3(t)$ 叠加得到最终信号 $x(t)$, 将 $x(t)$ 直接作为 ICNN 的输入。

3.3 改进的卷积神经网络模型

在本文中 ICNN 的输入为预处理后的一维振动信号, ICNN 的学习过程主要分为正向传播和反向参数更新。正向传播的参数通过反向传播算法进行优化。正向传播由多个交替连接的卷积层和池化层、几个完全连接 (Fully connected, FL) 的层组成, CNN 的详细训练过程见文献[12]。

3.3.1 注意力机制结构

近年来, 注意力机制 (Attention mechanism, AM) 在深度学习方向研究火热, 其核心是选出对当前任务目标更重要的信息^[13], AM 的目的就是帮助神经网络学习权重分布。本文将 AM 引入到 CNN 的各个特征提取层中以建立特征提取通道之间的联系, 从而提取更加敏感的深层特征。AM 通过 CNN 模型计算每一个特征提取层的输出特征 Z_j 的注意力权重 a_j 对 Z_j 加权, 实现对 Z_j 的重要性表达。主要实现步骤如下:

(1) 特征提取层的特征聚合。将 CNN 的每个特征提取层的输出特征 Z_j 进行特征聚合, 使每个经过池化层降采样后得到的特征变成一个特征矢量, 建立该特征矢量与两个全连接层的通道联系。

$$K_j = \frac{1}{N_j} \sum_i Z_j^i \quad (4)$$

式中, K_j 表示第 j 个特征聚合生成的特征矢量; Z_j^i 表示第 j 个输出特征中的第 i 个特征矢量; N_j 为单个特征的映射长度。

(2) 通道间的权重生成。两个全连接层融合各特征提取通道的信息并生成权重 A_j , 建立与每个特征提取层之间的联系。

$$C_j = LRelU(w_1, K_j) \quad (5)$$

$$A_j = \text{sigmoid}(w_2, C_j) \quad (6)$$

式中, w_1 和 w_2 分别为两个全连接层的连接权重; C_j 为第一全连接层的输出; A_j 为得到的权重矢量。

(3) 特征通道的权重分配。利用权重矢量 A_j 分别与该池化层的输出特征 Z_j 对应相乘即得到新特征 Z_j , Z_j 将代替原来的特征并输入到下一个特征

提取层。

$$Z_j = A_j \cdot Z_j \quad (7)$$

3.3.2 ICNN 模型的结构参数确定和模型设计

针对在强噪声环境中滚动轴承一维振动信号提出的改进卷积神经网络结构参数如表 1 所示。

表 1 提出的 ICNN 模型结构参数

网络层	参数		
卷积层 1	宽度=104	步幅=8	核个数=32
池化层 1	宽度=4	步幅=4	核个数=32
卷积层 2	宽度=33	步幅=1	核个数=64
池化层 2	宽度=4	步幅=4	核个数=64
卷积层 3	宽度=6	步幅=1	核个数=128
池化层 3	宽度=4	步幅=4	核个数=128
卷积层 4	宽度=2	步幅=1	核个数=128
池化层 4	宽度=4	步幅=4	核个数=128
FC 层	128		1
Softmax 层	10		1

所提出的 ICNN 模型共建立 11 层模型, 包括 1 个输入层, 4 个交替连接的卷积层和池化层, 1 个全连接层, 1 个 Softmax 层。第一、二层卷积内核大小分别为 1×104 , 步长为 1×8 , 其中第一卷积层选用的宽卷积核能够削弱高频信号对提取特征时的影响^[5]。卷积层其余内核大小分别为 1×33 、 1×4 、 1×4 , 步长均为 1×1 ; 激活函数为 ReLU, 池化类型为最大池化层, 全连接层的神经元个数为 128, 输出层节点数为 10。设计的 ICNN 诊断模型结构如图 2 所示。

图 2 建立的 ICNN 轴承故障诊断结构图

首先, 经过多层降噪技术后得到的最终信号进入第一卷积层提取短时特征。其次, 输出的特征经过批量归一化层(Batch normalization, BN)处理后被迫呈标准正态分布落入激活函数的敏感区域^[14]。然后特征经过池化层。另外, 在各个特征提取层引入

注意力机制建立特征提取通道之间的联系, 增强对非敏感特征的提取能力。最后在交替连接的卷积层和池化层间完成特征提取的全过程, 将其输出作为全连接层的输入。提取好的特征最后依次经过两个 FC 层、BN 层、ReLU 激活层和 Softmax 层, 最后输出故障类型。

4 试验对比验证

本节中, 基于 Python-Tensorflow 搭建 ICNN 模型, 运用所提出的多层降噪技术结合 ICNN 故障诊断模型, 对噪声环境中的轴承振动信号进行训练与测试, 设置不同的试验方案全面地验证本文所提模型的抗噪声能力和泛化能力。

4.1 数据来源和样本制作

试验数据来自美国凯斯西储大学(Case western reserve university, CWRU)实验室的滚动轴承故障信号。本节分别选取了轴承在 0~3 hp 负载工况下工作时的振动信号, 信号的采样频率为 12 kHz。实验中的 SKF6 205 轴承通过电火花加工凹槽方式在其内圈、外圈、滚动体加工出 0.177 8 mm、0.355 6 mm、0.533 4 mm 单点故障, 另外还包含正常轴承在内的共十类故障类型。采用数据增强技术将一维信号数据切分为每类故障 200 个样本, 每个样本包含 2 048 个数据点, 制作成的标签化的 F3、F2、F1、F0 四个数据集均包含 2 000 个数据样本, 试验按比例 4: 1 无交集的划分训练集和测试集。

4.2 基于多层降噪技术的诊断方法验证

以采集到的 3 hp 工况下轴承滚动体故障振动信号进行分析; 在原始振动信号中引入 $\text{SNR} = -10 \sim 0$ db 的白高斯噪声, 时域波形如图 3 所示。其信号的幅值增大, 干扰增强, 故障信号被进一步淹没。

图 3 滚动体原始和加噪振动信号时域图

4.2.1 基于 SVD 和 ICNN 的诊断效果验证

使用提出的奇异值分解方法对加噪轴承滚动体振动信号进行分解, 得到的奇异值曲线如图 4 所示。

图 4 加噪信号的奇异值曲线

本小节将验证所提奇异值降噪方法结合 ICNN 模型的有效性,并和其他降噪方法结合 ICNN 模型进行对比。表 2 示出 10 种不同降噪方法对十个样本降噪效果的平均值。

表 2 不同降噪方法得到的 SNR 和 RMSE

降噪方法	评价标准	
	SNR/db	RMSE
二分之均值法(Q1: $i=784$)	-4.751	0.285
奇异值中值法(Q2: $i=512$)	-4.376	0.271
奇异值阈值降噪法(Q3: $i=400$)	-4.799	0.284
奇异值阈值降噪法(Q4: $i=300$)	-4.301	0.265
奇异值阈值降噪法(Q5: $i=200$)	-2.903	0.223
奇异值阈值降噪法(Q6: $i=100$)	-1.402	0.188
小波 Daubechis 降噪法(W1)	-3.328	0.242
小波软阈值降噪法(W2)	-4.279	0.274
小波硬阈值降噪法(W3)	-4.501	0.281
EMD 降噪法(EMD)	-5.569	0.315

首先选择不同阶次的有效奇异值重构得到降噪信号,同时与小波、EMD 方法作比较。表 2 中 Q1 表示二分之均值去噪;Q2 表示奇异值中值去噪;Q3、Q4、Q5、Q6 分别表示有效奇异值个数为 400、300、200、100。信号的信噪比(SNR)越大,且原始信号与降噪信号的均方根误差(RMSE)越小,则得到更好降噪效果的信号。然后将降噪信号输入到 ICNN 中进行训练,最后在测试集中加入 -10~0 db 的白高斯噪声并进行测试。每一种降噪方法结合 ICNN 模型的故障诊断结果均为十次试验的平均值,如表 3 所示。

表 3 不同降噪方法结合 ICNN 的诊断正确率(%)

方法	SNR/db					
	-10	-8	-6	-4	-2	0
Q1+ICNN	80.59	92.07	97.03	98.62	99.65	99.95
Q2+ICNN	80.21	92.03	96.70	98.57	99.66	99.91
Q3+ICNN	76.66	91.28	97.45	99.19	99.78	99.93
Q4+ICNN	74.91	92.99	97.19	99.25	99.67	99.94
Q5+ICNN	66.97	91.84	98.25	99.63	99.91	99.97
Q6+ICNN	37.32	66.41	91.84	97.84	99.09	99.72
W1+ICNN	75.29	89.30	96.16	98.03	98.91	99.75
W2+ICNN	81.83	94.03	98.56	99.44	99.75	99.94
W3+ICNN	77.72	89.97	94.81	97.81	98.75	99.38
EMD+ICNN	82.27	91.93	96.45	98.32	99.08	99.58
无降噪+ICNN	80.09	90.89	94.27	97.35	98.43	99.05

由表 2 可见,对含有大量干扰的信号进行降噪处理,10 种方法都能去除部分干扰信号。EMD 方

法的降噪效果最差,因为在大量干扰信号下 EMD 方法存在严重模态混叠现象。三种常见的小波变换方法也有很好的降噪效果,SNR 从原来的 -10~0 db 上升至 -3.328 db、-4.279 db、-4.501 db。将降噪信号输入到 ICNN 中进行学习,在 SNR=-10 db 环境中平均诊断率均在 75% 以上;在 SNR=0 db 时的平均诊断率保持在 99.30% 以上,相比没进行降噪处理的信号结合 ICNN 的诊断效果更好。基于奇异值方法的降噪效果也明显,当有效奇异值个数 $i=100$ 时,SNR 甚至从原来的 -10~0 db 上升至 -1.402 db。结合表 3 可见,在 SNR=-10 db 环境中,此时重构得到的降噪信号结合 ICNN 模型(Q6+ICNN)的平均诊断正确率仅为 37.32%。随着选择的有效奇异值个数 i 的增加,降噪信号的 SNR 值减小,奇异值降噪方法结合 ICNN 的诊断正确率上升,当 $i=784$ 时,Q1+ICNN 的平均诊断正确率达 80.59%。结果表明传统 SVD 方法在去除大量噪声的同时,也会丢失微弱故障细节特征。选择合适的奇异值降噪方法既可以保留原始信号的细节特征,也去除了一定的噪声,训练出来的模型更具抗干扰能力。本文利用二分之均值法选择合适的奇异值进行信号重构得到降噪信号 $x_2(t)$,为了避免丢失微弱故障细节特征,再对带噪信号进行 SVD-EMD 联合处理。

4.2.2 基于 SVD-EMD 的联合降噪方法

基于奇异值分解的降噪方法可以避免丢失时域特征,即将第一部分所用的奇异值置零取余下的奇异值进行信号重构得到第二部分含微弱有用信号的噪声信号 $x_2(t)$,再对 $x_2(t)$ 做进一步的故障特征提取。因为信号 $x_2(t)$ 含噪声极多,故采用中心差商算法选出奇异值进行微弱信号重构加以去噪,计算各个奇异值的中心差商,得到奇异值曲线和奇异值中心差商曲线如图 5 所示。

图 5 $x_2(t)$ 信号的奇异值曲线和奇异值中心差商曲线

再采用 EMD 分解信号得到一系列 IMF 分量,图 6、7 给出由两个不同样本得到的带噪信号 $x_2(t)$ 经

SVD 去噪和 EMD 分解得到的 IMF 分量时域图(图 5、6 实际分解层数分别为 2 层、8 层)。

图 6 EMD 变换后的 2 个 IMF 分量时域波形图

图 7 EMD 变换后的前 4 个 IMF 分量时域波形图

由图 6、7 可见,可以看出基于中心差商法的 SVD 方法消除了 EMD 方法的模态混叠现象。经计算,图 6 中 IMF1、IMF2 的贡献率分别为 99.86%、0.14%;图 7 中 IMF1~IMF4 的贡献率依次为 53.53%、23.45%、11.84%、9.40%。再取 15 个样本按照上述方法进行试验,得到的 IMF 分量平均贡献率为 IMF1=71.59%、IMF2=15.43%、IMF3=6.14%。所以有用特征信息大多集中在 IMF1 分量中;最后将 $x_1(t)$ 和 IMF1 分量叠加得到最终信号 $x(t)$ 。

4.3 所提方法抗噪性能验证

本节将通过试验验证提出的 SVD-EMD 多层降噪技术结合 ICNN 模型具有较强的抗噪性能,试验模拟了工业噪声对训练样本和测试样本的影响,即在训练样本和测试样本中分别加入 $\text{SNR} = -10 \sim 0$ db 和 $\text{SNR} = -10 \sim 10$ db 的白高斯噪声。首先,为了证明所提出方法的优势,使用本文所提的方法、WDCNN(AdaBN)、FD-CNN 来分析相同的数据集(F3+F2+F1)并进行分析比较,各个方法对轴承故障

程度的诊断正确率见表 4。

表 4 不同模型对轴承故障程度的诊断正确率(%)

SNR(db)	模型		
	WDCNN(AdaBN) ^[5]	FD-CNN ^[15]	本文方法
-4	92.65	96.51	98.16
-2	97.04	98.90	99.04
0	98.77	99.12	99.29
2	99.57	99.35	99.45
4	99.70	99.65	99.83
AVG	97.55	98.70	99.15

由表 4 示出,在 $\text{SNR} = -4 \sim 4$ db 环境中,基于 WDCNN (AdaBN) 方法在测试样本上的平均诊断正确率为 97.55%,基于 FD-CNN 方法的平均诊断正确率达到 98.70%,而本文所提方法的平均诊断正确率更是达到 99.15%,相比前两种方法分别高出 2.23%和 1.08%。特别是在 $\text{SNR} = -4$ db 强噪声环境中,本文方法在测试集的正确率更是达到 98.16%,相比现有方法分别提升了 5.51%和 1.65%,具有更高的故障诊断正确率。

另外,为进一步验证和对比所提模型改进部分在强噪声环境下的优越性,将采用不同的方案进行试验验证。A 表示本文所提方法, SVD-EMD 多层降噪技术结合 ICNN 模型的故障诊断方法; B 表示 SVD-EMD 多层降噪技术结合传统 CNN 模型,传统 CNN 模型和 ICNN 模型参数相同,见表 1; C 表示基于传统奇异值分解得到的信号 $x_1(t)$ 结合 ICNN 模型; D 表示基于小波硬阈值降噪法结合 ICNN 模型; E 表示将加噪振动信号直接作为 ICNN 模型的输入。

4.3.1 ICNN 模型的训练过程可视化

本小节选用 t-随机邻近嵌入(t-distributed stochastic neighbor embedding, t-SNE)算法将所有卷积层与全连接层的特征表达降成 2 维后的分布,通过对 ICNN 训练过程的可视化展示模型特征提取过程。由于篇幅原因,图 8 给出通过在 F2 负载下的 1 600 个样本训练好的模型 A,在 $\text{SNR} = -2$ db 环境中 F2 从每个卷积层通过 t-SNE 方法提取的 400 个测试样本的特征分布的可视化图。随着层的深入,特征可分割性不断增强,最终实现特征的有效分类。随着 ICNN 模型网络层数的增加,每一层的特征的可分性越来越强,说明了深度结构的必要性。从最后的全连接层中可以看出,用 F2 数据集经过 SVD-EMD 多层降噪技术方法提取出的故障特征信号经训练得到的 ICNN 网络模型,在噪声环境下对 F2 数据集有很好的故障类别识别能力,验证了本文

所提方法的有效性。

图 8 测试样本的特征分布图

4.3.2 ICNN 模型的抗干扰能力分析

试验分别将数据集 F3、F2、F1、F0 按照 A、B、C、D、E 方案进行多层降噪处理、故障特征提取和网络模型的训练,再将加噪测试样本输入到各自训练好的模型中进行测试。对比试验所对应的故障诊断结果是在 10 次试验下取得的平均值,表 5 和图 9 对比了 F3 数据集在不同噪声下 5 个模型的诊断正确率,图 10 依次比较了不同噪声下 A、B、C、E 四种训练好的模型分别在 F2、F1、F0 三个数据集的故障诊断正确率。

表 5 不同噪声下不同模型在 F3 数据集上的诊断正确率(%)

SNR(db)	模型				
	A	B	C	D	E
-10	85.39	78.61	80.59	77.72	80.09
-8	95.19	90.36	92.07	89.97	90.89
-6	98.13	96.13	97.03	94.81	94.27
-4	99.40	98.34	98.62	97.81	97.35
-2	99.83	99.10	99.65	98.75	98.43
0	99.98	99.51	99.85	99.38	99.05
10	100.0	99.85	100.0	99.88	99.58

图 9 不同噪声下不同模型在 F3 数据集上的诊断正确率

由表 5 和图 9 示出,当采用 F3 数据集进行训练和测试时,A、B、C、D、E 五个模型在 SNR=-10 db 高噪声环境下的诊断率均达到了 75%。相比之下,模型 A 的识别正确率最高,达到了 85.39%,分别比模型 B、C、D、E 高出 6.78%、4.80%、7.67%、5.30%。值得注意的是,在-10 db 到-2 db 环境中,模型 C 的正确率比模型 D 高出 0.81%~4.48%;模型 C 的正确率比模型 E 高出 0.50%~2.76%;模型 A 分别

比模型 B、C、D、E 平均高出 3.08%、1.99%、3.78%、3.38%。随着 SNR 的增大,所有模型的诊断正确率都有所提高,在-2 db 到 10 db 环境中,趋近 100% 的准确率。

图 10 不同模型在 F2、F1、F0 数据集上的诊断正确率

同理,由图 10 可以看出,当采用 F2、F1、F0 数据集进行训练和测试时,无论在何种噪声环境中,A 模型的诊断正确率始终高于其他 3 个模型,体现出本文所提方法的优越性,在强噪声环境下具有极高的故障诊断能力。

分别将模型 C 与模型 E 相比,在任意负载下进行试验,任意信噪比下模型 C 的诊断效果的提升最为明显,特别是在-10 db 到-2 db 高噪声环境下,模型 C 比 E 总体高出 9.36%。结果表明,经过 SVD 均值方法去噪处理得到的信号,在训练时,ICNN 模型对故障特征更为敏感,得到的模型在噪声中的表现更加良好。将模型 A 和模型 C 相比,无论采用何种负载数据进行训练和测试试验,在-10 db 到 0 db 高噪声环境下,模型 A 的诊断正确率都要比模型 C 的正确率高。结果表明采用传统 SVD 去噪方法可能会丢失重要的时域特征,通过对第二部分含微弱有用信号的强噪声信号采用 SVD-EMD 方法作进一步特征提取,可以很好的避免时域特征丢失。同理,在任意信噪比下,模型 A 的诊断效果都比模型 B 好,结果表明在各个特征提取层中引入注意力机制,可以对降采样操作后的表达重新加权以改善每个特征提取层的输出,从而增强有用信息的权重,提高了提取非敏感特征的能力。

综上,试验有效地验证了本文所提多层降噪技

术及 ICNN 故障诊断模型的实用性和有效性。

4.4 所提方法泛化性能验证

在实际的机械设备中, 轴承上的负载可能会出现变化, 因此本节对所提出方法的泛化性能进行了试验。本试验从 F3、F2、F1、F0 四个数据集中随机选出 3 个数据集, 将其中的 4 800 个样本作为训练集, 将剩下的样本和余下的一个数据集作为测试集。如 F012→F012、F3 表示先利用融合数据集 F0、F1、F2 进行模型训练, 再利用融合数据集 F012 和数据集 F3 进行模型测试, 以此类推。在训练模型时, 将直接引入抗噪性能试验中训练得到的 A 模型, 并在测试集中加入 $\text{SNR} = -4 \sim 4 \text{ dB}$ 的白高斯噪声, 得到的诊断正确率如表 6 所示。

表 6 本文方法在融合数据集上的故障诊断正确率(%)

试验设置		SNR/db				
		-4	-2	0	2	4
F012	F012	95.82	97.51	98.49	98.94	99.39
	F3	90.01	90.25	90.28	93.83	94.25
F023	F023	98.14	99.08	99.37	99.51	99.62
	F1	91.25	92.56	93.15	94.38	94.31
F013	F013	97.26	98.32	98.86	99.22	99.51
	F2	99.21	99.54	99.75	99.81	100.0
F123	F123	98.16	99.04	99.29	99.45	99.83
	F0	91.15	93.92	94.80	94.49	96.08

由表 6 可见, 本文方法在融合数据集上的平均诊断正确率均在 90% 以上。为进一步验证所提出方法在噪声环境下的泛化能力, 直接引入在抗噪性试验中训练好的四类模型, 用另外一种负载数据集中的 2 000 个样本进行测试, 并且在测试样本中加入 $\text{SNR} = -2 \text{ dB}$ 的噪声, 得到的诊断正确率如表 7 所示。

表 7 本文方法在噪声下跨负载测试的故障诊断正确率(%)

测试集	训练集			
	F0	F1	F2	F3
F0	—	84.83	84.7	82.60
F1	87.06	—	93.13	82.06
F2	84.22	87.38	—	88.81
F3	82.03	83.09	90.59	—

对于在某一工况下训练样本, 在噪声环境中跨工况进行样本测试, 本文所提方法在 $\text{SNR} = -2 \text{ dB}$ 噪声环境中的诊断正确率均在 82% 以上, 且平均诊断正确率达到 85.88%。验证了多层降噪技术及 ICNN 模型的抗噪声和变负载工况下故障诊断能力。

5 结论

(1) 本文提出了一种新的解决在强噪声环境下轴承微弱故障难以实现准确诊断的多层降噪技术及 ICNN 模型。ICNN 训练经过 SVD 降噪和 EMD 故障特征提取后得到的标签化降噪信号, 对 CWRU 轴承数据库, 在 $\text{SNR} = -10 \sim 0 \text{ dB}$ 时, 可取得 93.71% 的平均诊断正确率; 在 $\text{SNR} = -2 \text{ dB}$ 环境中变负载工况下的平均诊断正确率可达 85.88%。

(2) 本文对含强噪声的故障信号进行多层降噪处理主要通过 SVD 和 EMD 相结合而实现的。每个池化层输出端引入注意力机制可以改善特征提取层的输出, 通过强迫池化后的表达重新加权提高变复杂特征的提取能力。针对在噪声环境下的轴承微弱故障难以实现有效诊断的问题, 根据构建出的 ICNN 模型训练经过 SVD-EMD 多层降噪方法得到的降噪信号, 试验结果表明, 所提的多层降噪技术与 ICNN 结合, 可以有效地抑制噪声信号和提取出敏感特征, 相比其他模型对噪声和变负载工况下轴承故障信号的诊断正确率更高。

参 考 文 献

- [1] OJAGHI M, YAZDANDOOST N. Oil-whirl fault modeling, simulation, and detection in sleeve bearings of squirrel cage induction motors[J]. IEEE Transactions on Energy Conversion, 2015, 30(4): 1537-1545.
- [2] WANG Ziwei, ZHANG Qinghua, XIONG Jianbin, et al. Fault diagnosis of a rolling bearing using wavelet packet denoising and random forests[J]. IEEE Sensors Journal, 2017, 17(17): 5581-5588.
- [3] 张建财, 高军伟. 基于变分模态分解和多尺度排列熵的滚动轴承故障诊断[J]. 噪声与振动控制, 2019, 39(6): 181-186.
ZHANG Jiancai, GAO Junwei. Fault diagnosis of rolling bearings based on variational mode decomposition and multi-scale permutation entropy[J]. Noise and Vibration Control, 2019, 39(6): 181-186.
- [4] 陈宗祥, 陈明星, 焦民胜, 等. 基于改进 EMD 和双谱分析的电机轴承故障诊断实现[J]. 电机与控制学报, 2018, 22(5): 82-87.
CHEN Zongxiang, CHEN Mingxing, JIAO Minsheng, et al. Realization of motor bearing fault diagnosis based on improved EMD and bispectrum analysis[J]. Journal of Motor and Control, 2018, 22(5): 82-87.

- [5] ZHANG Wei, PENG Gaoliang, LI Chuanhao, et al. A new deep learning model for fault diagnosis with good anti-noise and domain adaption ability on raw vibration signals[J]. *Sensors*, 2017, 17(2): 1-21.
- [6] 余博, 田福庆, 梁伟阁. 基于深度卷积变分自编码网络的故障诊断方法[J]. *仪器仪表学报*, 2018, 39(10): 27-35.
- SHE Bo, TIAN Fuqing, LIANG Weige. Fault diagnosis method based on deep convolution variational self-encoding network[J]. *Journal of Instrumentation*, 2018, 39(10): 27-35.
- [7] PANG Bin, HE Yuling, TANG Guiji, et al. Rolling bearing fault diagnosis based on optimal notch filter and enhanced singular value decomposition[J]. *Entropy*, 2018, 20(7): 482.
- [8] GAI Jingbo, SHEN Junxian, HU Yifan, et al. An integrated method based on hybrid grey wolf optimizer improved variational mode decomposition and deep neural network for fault diagnosis of rolling bearing[J]. *Measurement*, 2020, 162: 107901.
- [9] SINGH P, HARSHA S P. Statistical and frequency analysis of vibrations signals of roller bearings using empirical mode decomposition[J]. *Proceedings of the Institution of Mechanical Engineers Part K-Journal of Multi-Body Dynamics*, 2019. 233(4): 856-870.
- [10] GAI Jingbo, HU Yifan, SHEN Junxian. A bearing performance degradation modeling method based on EMD-SVD and fuzzy neural network[J]. *Shock and Vibration*, 2019, 2019: 1-10.
- [11] LI Shaobo, LIU Guokai, TANG Xianghong, et al. An ensemble deep convolutional neural network model with improved D-S evidence fusion for bearing fault diagnosis[J]. *Sensors*, 2017, 17(8): 1729.
- [12] KHODJA A Y, GUERSI N, SAADI M N, et al. Rolling element bearing fault diagnosis for rotating machinery using vibration spectrum imaging and convolutional neural networks[J]. *The International Journal of Advanced Manufacturing Technology*, 2019, 106(5-6): 1737-1751.
- [13] 李艺伟. 基于改进 CNN 的变工况下滚动轴承故障诊断方法研究[D]. 哈尔滨: 哈尔滨理工大学, 2019.
- LI Yiwei. Research on fault diagnosis method of rolling bearings under variable operating conditions based on improved CNN[D]. Harbin: Harbin University of Science and Technology, 2019.
- [14] ZHAO Minghang, ZHONG Shisheng, FU Xuyun, et al. Deep residual shrinkage networks for fault diagnosis[J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(7): 4681-4690.
- [15] 杨平, 苏燕辰, 张振. 基于卷积胶囊网络的滚动轴承故障诊断研究[J]. *振动与冲击*, 2020, 39(4): 55-62, 68.
- YANG Ping, SU Yanchen, ZHANG Zhen. Research on fault diagnosis of rolling bearings based on convolution capsule network[J]. *Vibration and Shock*, 2020, 39(4): 55-62, 68.

作者简介: 董绍江(通信作者), 男, 1982 年生, 博士, 教授, 博士研究生导师。主要研究方向为机械故障诊断和机电一体化技术。
E-mail: dongshaojiang100@163.com