

DOI: 10.13382/j.jemi.B2306848

嵌入 NLB 模块的 FCN 在轴承信号降噪中的应用 *

范啸宇^{1,2} 刘 韬^{1,2} 王振亚^{1,2} 陶 佳³ 朱振军³

(1. 昆明理工大学机电工程学院 昆明 650500; 2. 云南省先进装备智能制造技术重点实验室 昆明 650500;
3. 上汽通用汽车有限公司 上海 201200)

摘 要:深度学习在故障诊断取得了显著的进展,然而其多为端到端的智能诊断,在信号降噪方面的应用较少。本文提出了一种基于全卷积神经网络 (fully convolutional network, FCN) 的降噪方法。首先,模型整体采用了 encoder-decoder 架构,其中 encoder 部分由三层卷积层组成,decoder 部分由四层反卷积层组成。其次,引入了残差连接对模型的学习目标进行了约束,使得模型在传播过程中更多地关注噪声信息。并且为了增强模型的特征提取能力,在 encoder 和 decoder 中引入了非局部块 (non-local block, NLB)。然后,通过仿真信号对比实验选择网络的超参数,与目前主流的降噪方法进行对比,初步验证模型的降噪效果。最后,通过实际案例对所提方法的降噪效果进行对比验证,结果表明本文提出的方法在直观观察和降噪性能指标方面均取得了良好的应用效果,能够有效提高故障诊断的准确率。

关键词: 全卷积神经网络;残差连接;反卷积;降噪;故障诊断

中图分类号: TP183 **文献标识码:** A **国家标准学科分类代码:** 460.1520

Application of FCN embedded in NLB module for bearing signal noise reduction

Fan Xiaoyu^{1,2} Liu Tao^{1,2} Wang Zhenya^{1,2} Tao Jia³ Zhu Zhenjun³

(1. Faculty of Mechanical and Electrical Engineering, Kunming University of Science and Technology, Kunming 650500, China; 2. Engineering Research Center for Intelligent Maintenance of Advanced Equipment of Yunnan Province, Kunming 650500, China; 3. SAIC-GM, Shanghai 201200, China)

Abstract: Deep learning has made significant progress in fault diagnosis, but it is mostly an end-to-end intelligent diagnosis with limited application in signal denoising. This article proposes a denoising method based on fully convolutional network (FCN). Firstly, the overall model adopts the encoder decoder architecture, where the encoder part consists of three convolutional layers and the decoder part consists of four deconvolution layers. Secondly, residual connections were introduced to constrain the learning objectives of the model, allowing the model to focus more on noise information during propagation. And in order to enhance the feature extraction ability of the model, non-local blocks (NLB) are introduced in the encoder and decoder. Then, through simulation signal comparison experiments, select the hyperparameters of the network and compare them with current mainstream noise reduction methods to preliminarily verify the noise reduction effect of the model. Finally, the denoising effect of the proposed method was compared and verified through practical cases. The results showed that the method proposed in this paper achieved good application effects in both intuitive observation and denoising performance indicators, and can effectively improve the accuracy of fault diagnosis.

Keywords: fully convolutional network; residual connections; deconvolution; denoising; fault diagnosis

0 引言

滚动轴承作为机械设备的关键零部件,其健康状况和设备的运行状态密切相关^[1]。工程实际中轴承信号存在着噪声干扰,很难直接从振动信号中挖掘到有效信息。因此,在故障诊断当中,对采集到的轴承信号进行降噪处理是非常有必要的。

传统轴承信号的降噪方法主要包括奇异值分解(singular value decomposition, SVD)降噪、小波(wavelet)降噪、经验模态分解(EMD)降噪等^[2-3]。文献[4]使用了SVD对轴承振动信号进行降噪处理,该方法能够有效地突出信号的故障特征,提高了故障诊断的准确性。文献[5]针对SVD降噪能力差的问题提出了一种增强型SVD,此方法能够确定SVD重构阶数和奇异包络峰度相对变化率,通过对滚动轴承仿真数据和实际情况的分析验证了该方法的有效性和优越性。文献[6]针对电机轴承信号易受高频噪声干扰的问题,提出了利用Wavelet降噪及Hibert变换的方法对采集的电机轴承故障振动数据进行故障诊断,并验证了该方法能够有效进行轴承故障分析及诊断。文献[7]根据轴承发生故障时振动信号的特点,提出了一种基于峭度和歪度的LMD降噪方法,并通过实测滚动轴承振动信号验证了该方法的有效性。文献[8]针对滚动轴承早期故障信号易受背景噪声干扰的问题提出了一种基于MCKD-EMD的滚动轴承早期故障诊断方法,通过对实际工程信号进行故障诊断验证了该方法的有效性。文献[9]针对机车轴承振动信号总是受到某些类型噪声污染的问题,提出了基于EMD和自适应滤波的新型振动信号增强方法,通过对机车轴承内滚道和外滚道故障信号进行处理,可以成功检测出代表机车轴承故障特征的瞬态之间的周期。但是,传统信号处理方法由于先验知识与参数选择的难题,当面对海量的故障数据时,略显吃力。

随着人工智能与大数据的发展,深度学习在故障诊断领域也掀起了一股热潮^[10]。相比于传统的降噪算法,以CNN为代表的神经网络能够自适应挖掘信号特征。文献[11]针对传统的智能诊断算法依赖人工特征提取和专家知识,缺乏自适应性的问题,提出了“端到端”的自适应一维卷积神经网络(ACNN-FD)故障诊断算法,通过轴承数据库实验验证表明该算法能够实现高达99%以上的故障识别准确率。文献[12]提出了一种基于LeNet-5的新型CNN用于轴承故障诊断,该方法可以提取转换后的二维图像的特征,并消除手工特征的影响,与其他深度学习方法和传统方法相比,均取得了显著进步。文献[13]针对滚动轴承剩余寿命预测的问题,提出基于CNN-BLSTM的轴承寿命预测模型,将模型预测结果与真

实轴承退化数据进行比较,结果表明,所提方法相比传统方法能够有效提高轴承性能退化的预测精度。文献[14]针对真实滚动轴承故障数据不平衡的问题,提出了基于GAN的不平衡故障诊断方法,结果表明,该方法可以在生成相似故障样本的基础上,为不平衡故障诊断提供更好的解决方案。但综合来看,当前的大部分研究都集中在诊断过程的后端,如何使用深度学习进行信号的特征提取与同尺度降噪仍有较大的探索空间。

基于上述,本文提出了一种嵌入非局部块的全卷积神经网络。首先该模型采用了encoder-decoder架构,其次引入了残差连接约束网络的学习目标,最后引入NLB模块使网络更好的捕捉全局信息。将加噪信号和原始信号的时域波形作为网络的输入和输出进行训练和测试,实现了端到端的降噪方式。

1 理论知识

1.1 卷积层和反卷积层

全卷积神经网络就是用卷积层代替了全连接层、池化层,其内部只有卷积层或反卷积层。

卷积层的运算公式如式1所示。式中, $X_{i,j}^m$ 为第 m 层的第 i 行 j 列的输出, $W_{a,b}^m$ 为第 m 层卷积核 a 行 b 列的权重, $B_{i,j}^m$ 为第 m 层的第 i 行 j 列的偏置项。 $f(\cdot)$ 为激活函数。

$$X_{i,j}^m = f\left(\sum_{a=-\Delta b}^{\Delta} \sum_{b=-\Delta}^{\Delta} X_{i+a,j+b}^{m-1} \cdot W_{a,b}^m + B_{i,j}^m\right) \quad (1)$$

反卷积又称为转置卷积,其主要作用是增大输出的高宽^[15]。反卷积层的运算原理如图1所示。图中的蓝色小方块表示反卷积层的输入,灰色方框表示权重矩阵,而绿色小方块表示反卷积层某一部分的输出。反卷积层的输出大小由输入矩阵尺寸、步长、填充等参数共同决定^[16]。




图1 反卷积层运算原理图

Fig. 1 Schematic diagram of deconvolution layer operation

1.2 Leaky-ReLU 激活函数

为了提取振动信号的负值信息,模型采用了 Leaky-ReLU 作为激活函数,具体计算公式如式 2 所示。Leaky-ReLU 激活函数相比于 ReLU 激活函数没有简单的把负值变为 0,而是通过线性分量保留负值,并且它的函数范围是从负无穷到正无穷^[17]。网络降噪后的输出最后是通过残差连接得到的,这说明此网络主要学习的目标是反向噪声,最后通过学到的反向噪声和原始的有噪声的输入信号相加,从而得到了滤波后的信号。因此,保留负值的权重是非常有必要的,这严重影响着网络的降噪性能。

$$\text{LeakyReLU}(x) = \max(0, x) + \alpha \times \min(0, x) \quad (2)$$

1.3 NLB 模块

旋转机械的故障信号一般都具有较强的周期性和相关性,模型的感受野越大,更容易捕捉到故障信息。对于卷积层来说,它的每次卷积操作的感受野就是卷积核的大小,但是时序序列的长度较长,而卷积核的大小不能无限变大,这样就导致了如果要时序列相隔较远的信息联系起来就需要不断增加卷积层的层数。卷积层数的不断增加会影响模型的计算效率和性能表现。当然,如果使用全连接层也能解决卷积层感受野较小的问题,但是全连接带来了大量的参数,给优化带来了困难。如果能够在某些层引入全局的信息,就能很好的解决卷积层感受野较小的问题,能够为后面的层带去更丰富的信息。

NLB 模块就能很好的解决卷积层感受野较小的问题,捕获序列相距较远的点之间的信息关系,为后面的层引入全局的信息^[18]。NLB 的输入和输出大小相同,因此可以将其嵌入网络而不改变网络原本的结构。其运算过程如下:

$$z_i = W_i y_i + x_i \quad (3)$$

$$y_i = \frac{1}{C(x)} \sum_{j_j} f(x_i, x_j) g(x_j) \quad (4)$$

其中, x 表示输入特征, y 表示输出特征, i 表示所要计算的目标位置的索引, j 表示其他所有位置的索引。 $f(x_i, x_j)$ 是一个二元函数,用来计算输入特征两个位置之间的相似度。 $g(x_j)$ 表示对输入 x 进行 embedding 操作, $C(x)$ 表示归一化的参数。由于 $f(x_i, x_j)$ 的选择对降噪的结果影响不大,所以选择常用的 Embedded Gaussian 作为相似性度量函数^[18],那么 $f(x_i, x_j)$ 和 $C(x)$ 的计算公式如下所示。

$$f(x_i, x_j) = e^{\theta(x_i)^T \cdot \phi(x_j)} \quad (5)$$

$$C(x) = \sum_{j_j} f(x_i, x_j) \quad (6)$$

其中, $\theta(x_i)$ 、 $\phi(x_j)$ 和 $g(x_j)$ 操作一样,相当于对 x 使用一个 1×1 Conv 层。非局部块结构图如图 2 所示,其中 C 表示通道数, L 表示数据长度。




图 2 非局部块结构图

Fig. 2 Non-local block structure diagram

1.4 嵌入 NLB 模块的全卷积神经网络

该网络整体采用 encoder-decoder 架构,使用三层卷积层和一层非局部块作为编码器,解码器则使用四层反卷积层和一层非局部块。而每层卷积层和反卷积层后都使用 Leaky-ReLU 作为激活函数,它既可以保证网络的非线性学习能力还能学习到振动信号负值中所包含的信息。网络的整体架构如图 3 所示。卷积层和反卷积层上的数字分别代表输出通道数、卷积核大小、步长。编码器将输入的信号不断提取特征并压缩,再将压缩的特征信息送入由反卷积层和 NLB 模块组成的解码器当中,然后对压缩的特征进行层层解码,并还原成与输入信号相同的长度。最后在编码器的输出信号和原始噪声信号之间使用了残差连接,约束网络学习噪声的信息,输出信号和原始噪声信号相减得到了降噪后的信号,实现了对原始信号端到端的降噪处理。其原理如式(7)所示。

$$y_{denoise} = x_{input} + noise \quad (7)$$

其中, x_{input} 表示编码解码架构网络的输入信号,而 $noise$ 表示通过编码解码架构网络的输出信号,表示网络学习到的相反的噪声信息,然后将两者相加就得到了降噪后的信号。

此外,两个 NLB 模块分别嵌入到网络的编码部分和解码部分。旋转机械振动信号一般都具有较强的周期性和相关性,加入 NLB 模块可以增大网络的感受野,捕获序列相距较远的点之间的信息关系,为后面的层引入全局的信息。在编码器的开始和解码器的结束之前,特征信号足够长,包含足够多的周期信息, NLB 模块就可以很好的捕捉这些信息,但是所需运算时间较长。而如果将 NLB 模块放在编码器和解码器的中间部分,特征信号已经进行多次编码,特征信号长度较短并且信号的部分周期信息也可能丢失,嵌入 NLB 模块的优势就不够明显。因此,在第一层卷积层后和最后一层反卷积前嵌入 NLB 模块既可以捕捉更多的周期信息也能保证模型运算效率,使模型降噪性能更好。




图 3 全卷积降噪网络结构图

Fig. 3 Structure diagram of fully convolutional denoising network

2 仿真研究

2.1 数据介绍和实验设置

为验证本文所提方法的有效性,根据轴承发生故障的特点构建故障仿真信号进行分析,该仿真信号的表达式如式 8 所示。试验中设计了 3 组不同故障特征频率的轴承故障仿真信号^[19]。

$$\begin{cases} A_i = A_0 \cos(2\pi f_p t) \\ s(t) = e^{-Bt} \cos(2\pi f_n t) \\ x(t) = \sum_i A_i s(t - iT - \tau_i) + n(t) \end{cases} \quad (8)$$

仿真信号的基本参数如下:初始幅值 $A_0 = 1.5$, 采样频率 $f_s = 12\ 000\ \text{Hz}$, 共振频率 $f_n = 2\ 500\ \text{Hz}$, 衰减系数 $B = 500$, T 是故障冲击周期, f_p 为转频, f_r 为故障特征频率, τ_i 为服从 $\mu = 0, \delta^2 = 0.01 \times f_r$ 的正态分布随机滑动系数, 高斯白噪声 $n(t) = -6\ \text{dB}$, 试验中模拟了 3 组信号长度均为 $1 \times 5\ 120\ 000$ 的不同故障类型的轴承振动信号, 其主要参数如表 1 所示。取长度 2 048 个点为一个样本, 每种故障状态得到 2 500 个样本, 随机将其中 1 500 组划分为训练集, 500 组划分为验证集, 其余 500 组作为测试集。

表 1 仿真信号参数

Table 1 Simulated signal parameters

信号编号	转频/Hz	故障特征频率/Hz
$x_1(t)$	30	90
$x_2(t)$	30	120
$x_3(t)$	30	150

图 4 分别展示了 3 组仿真故障信号某一个样本的时

域波形,其中很多的周期信息都被白噪声掩盖,一般的故障诊断方法难以对发生的故障进行诊断,因此需要进行降噪处理提高信号的信噪比,以提高故障诊断方法的准确率。




图 4 仿真信号时域波形

Fig. 4 Simulated signal time-domain waveform

为了对降噪的结果进行对比,选择了 3 个性能指标用于表述降噪性能,有信噪比 (signal-to-noise ratio, SNR)、均方误差 (mean square error, MSE) 以及波形相似参数 (normalized correlation coefficient, NCC), 它们的具体计算公式如下所示:

$$SNR = 10 \lg \frac{A_{signal}^2}{|A_{denoised} - A_{signal}|^2} \quad (9)$$

$$MSE = \frac{\sum_{i=1}^N |A_{denoised} - A_{signal}|^2}{N} \quad (10)$$

$$NCC = \frac{\sum_{n=1}^N A_{signal} A_{denoised}}{\sqrt{(\sum_{n=1}^N A_{signal}^2)(\sum_{n=1}^N A_{denoised}^2)}} \quad (11)$$

其中, A_{signal} 为纯净信号的幅值序列, $A_{denoised}$ 表示降噪后信号的幅值序列。

模型在训练过程中使用了 Adam 优化器, 损失函数采用均方损失。学习率和批量大小分别设置为 0.000 5 和 32, 训练总共进行了 50 次, 先进行模型训练, 然后保存训练好的模型进行测试。实验在 Windows 系统上使用 PyTorch 1.7, 并在配备 GeForce RTX 4070 Laptop 显卡和 8 G 显存的计算机上执行。

2.2 超参数的选择

由于超参数较多, 对比分析了大部分的超参数, 选取了最有可能影响网络降噪性能的超参数, 其中包括了 Leaky-ReLU 激活函数的 α 取值和网络第一层卷积核的大小。下面对各个参数进行对比实验分析, 选择合适的取值。为了方便对比分析, 在得到所有降噪性能指标的平均值后, 进行归一化处理。

排除网络结构中的非局部块对实验结果的影响, 仅使用卷积层和反卷积层作为此次对比实验的网络结构。初定第一层卷积核的大小为 64, 更改 Leaky-ReLU 激活函数 α 的取值进行对比实验, 当 α 的取值为 0 时就相当于 ReLU 激活函数。对比实验结果如图 5 所示。其中 SNR 和 NCC 越大表示降噪效果越好, 而 MSE 越小表示降噪效果越好。由于 NCC 波动较小, 对结果的影响也较小, 因此主要根据信噪比 (SNR) 和均方损失 (MSE) 来选择合适的 α 。显然, 在 $\alpha = 0.1$ 时, 信噪比和均方损失均达到最优, 因此选择 $\alpha = 0.1$ 来进行本文往后的实验。




图5 Leaky-ReLU 参数对比结果

Fig. 5 Leaky ReLU parameter comparison results

同样卷积核的大小也会影响降噪网络的性能, 特别是第一层卷积核的大小。在前一次的对比实验当中选择第一层的卷积核大小为 64, 但这并不意味着 64 是第一层卷积核大小最优的取值, 因此需要进行对比实验验证第一层卷积核大小的最优取值。同样将网络结构中的 NLB 模块去除, 仅使用卷积层和反卷积层作为此次对比实验

的网络结构。取 Leaky-ReLU 激活函数的 $\alpha = 0.1$, 在不改变其他参数的条件下进行对比实验, 第一层卷积核大小对比实验结果如图 6 所示。




图6 第一层卷积核大小对性能指标的影响

Fig. 6 The influence of the size of the first layer convolutional kernel on performance metrics

分析可知, 随着第一层卷积核逐渐变大, SNR 的总体趋势是逐渐上升, MSE 的总体趋势是逐渐下降, 但当 $K = 256$ 时, 与 $K = 128$ 相比, 信噪比和均方误差与整体趋势是相反的, 这意味着 $K = 128$ 时是网络性能的局部最优点。而 NCC 数值变化不大, 对降噪性能的表述效果有限, 因此在这里也忽略 NCC 这个性能指标。通过对第一层卷积核大小的降噪性能指标的对比, 第一层卷积核大小为 512 时的信噪比和均方损失指标最优。但是卷积核越大, 网络所需的训练时间也在快速增长, 如图 6 中 TIME 这个指标所示, 第一层卷积核大小在超过 128 以后网络所需训练时间快速上升。在 $K = 128$ 时, MSE 与 TIME 相交, 并且 $K = 128$ 时也是 SNR 的局部最优点, 为了平衡降噪性能和网络训练时间, 选择 $K = 128$ 是个合理的选择。因此在接下来的实验中, 模型第一层的卷积核大小为 $K = 128$, 最终的神经网络结构如图 3 所示。

2.3 仿真实验结果

本节将以仿真为例, 验证全卷积神经网络的降噪能力。使用训练数据集训练网络后得到模型的权重, 再冻结网络的权重, 然后将测试集送入网络进行测试, 得到全卷积降噪后的时域波形图, 并与原始仿真信号和加噪仿真信号作对比, 验证网络的降噪能力。

模型的参数设置如下: 每层卷积层和反卷积层后都设置了批量归一化层 (BN) 以提高模型的泛化性, 激活函数都采用 Leaky-ReLU, 其中 $\alpha = 0.1$ 。第一层卷积核的大小为 128, 其他层的卷积核大小和步长如图 3 所示。本次实验设置批量大小为 32, 迭代次数为 50 次。使用训练集训练模型, 模型损失如图 7 所示。分析可知模型在第 10 次迭代以后趋于稳定。训练完成后保存模型权重, 将测试集送入已训练好的网络中, 得到降噪后的信号。从测试集中随机挑选一个样本进行时域和包络谱分析, 加噪仿真信号、纯净信号和降噪后信号的时域波形和频域分布对比如图 8(a) 所示。




图 7 网络模型损失

Fig. 7 Network model loss

分析可知,全卷积网络在降噪方面具有良好的效果,不管是在时域还是频域,降噪后的信号与纯净信号都有相同的变化趋势。加噪的仿真信号在其包络谱中是无法分别出故障特征频率及其倍频,但是经过全卷积网络降噪以后,在包络谱中能够明显看出降噪后信号的故障特征频率及倍频,并且和纯净信号的包络谱相比仅在幅值上稍微减小了一点,滤掉了大部分的噪声并保留了绝大部分的故障信息,初步验证了全卷积神经网络在降噪方面的强大性能。

2.4 与目前主流的降噪方法相比较

为了进一步验证全卷积神经网络在降噪滤波方面的强大性能,本节使用了 SVD、CEEMD^[20]、SSD^[19] 降噪方法与本文所提的 FCN 降噪网络对同一段测试集中的信号进行降噪效果对比,指标结果如表 2 所示。

表 2 不同降噪方法的指标结果

Table 2 The index results of different noise reduction methods

降噪方法	SNR/dB	MSE	NCC
输入信号信噪比	-6.000	0.229	0.451
FCN	8.151	0.009	0.958
SVD	0.137	0.057	0.536
CEEMD	-1.971	0.093	0.151
SSD	-1.094	0.076	0.696

通过图 8 的时域波形、频域分布对比可知,全卷积神经网络降噪优于其他的降噪方法,不仅滤掉了绝大部分的噪声,还保留了大部分的故障特征信息,能够从包络谱上准确分辨出故障特征频率及其倍频,拥有良好的降噪效果。同样,根据表 2 可知,全卷积神经网络降噪后的各项性能指标均是最优的,也证明全卷积神经网络相比于其他降噪方法具有更好的降噪效果。而其他降噪方法虽然也有一定的降噪效果,但其降噪后的故障特征频率周围仍然存在严重的边频干扰,这导致无法从包络谱中准确分辨出故障特征频率。




图 8 不同降噪方法在时域波形和包络谱上的降噪前后对比

Fig. 8 Before and after noise reduction of different reduction methods on time domain waveforms and envelope spectra

经上述分析可知,本文提出的全卷积神经网络的降噪方法具有强大的降噪性能,并且保留绝大部分的故障信息,不论是从性能指标上还是从实际降噪前后信号的对比都显示出良好的降噪效果。

3 实际案例验证

3.1 实验数据

使用轴承疲劳强化试验机故障数据对所提的方法进

行了详细的验证。轴承疲劳强化试验机各部分结构如图 9 所示。




图 9 轴承疲劳试验机组成结构

Fig. 9 Bearing fatigue testing machine composition

轴承疲劳试验机的轴承型号为 SKF6205-2RSH 单列深沟球轴承。实验中模拟了轴承在正常、内圈故障、滚动体故障、外圈故障的运行情况并采集了相应的振动加速度信号。实验设置的转频 $f_r = 40\text{ Hz}$ ，采样频率 $f_s = 12\ 800\text{ Hz}$ ，故障状态有正常、轴承内圈故障、轴承外圈故障和轴承滚动体故障 4 大类，总共有 10 种故障状态，详细信息如图 10 所示。由于在实验室数据采集的过程中，采集到的信号已经被机械内部其他部件噪声所污染，然而对于本文的降噪方法来说，想要恢复被机械内部噪声污染的信号是不可能的。本文所提方法的目标是为了在工厂生产环境下，去除混入到信号当中的环境噪声。将实验室采集的信号视为纯净信号，加入 noise-92 工厂环境噪声模拟真实工厂运行环境下所采集的加噪信号。在实验室采集的信号中分别加入 -2 dB 、 -6 dB 、 -10 dB 的环境噪声，然后采用滑动窗口^[21]截取 2 048 个点，滑动窗口每次的步长取 512 个点，其具体操作过程如图 11 所示，总共获得 6 100 个样本。将 6 100 个样本中的 5 000 个样本随机划分成训练集，其余 1 100 个样本作为测试集，最后将数据集送入网络训练。由于实际数据和仿真数据存在一定的幅值差距，需要对模型的超参数进行微调，将本次实验的模型迭代步长改为 0.001，迭代次数改为 100，其余模型参数保持不变进行模型训练。

3.2 降噪效果

为了更好的验证本文所提方法的降噪效果，需要计算本次实验所使用的故障轴承的故障特征频率。根据轴承的故障特征频率的计算公式^[22]，经过计算可得轴承的内圈故障频率 $f_{r-i} = 216.65\text{ Hz}$ ，外圈故障频率 $f_{r-o} = 143.35\text{ Hz}$ ，滚动体故障频率 $f_{r-b} = 94.17\text{ Hz}$ 。随机抽取测试集中的正常、内圈故障、外圈故障、滚动体故障样本进行降噪前后的分析，其结果如图 12 所示。




图 10 各类故障轴承

Fig. 10 Various types of faulty bearings




图 11 滑动窗口截取数据

Fig. 11 Sliding window to intercept data

在纯净信号上分别加入 -2 dB 、 -6 dB 、 -10 dB 的工厂环境噪声后分别对网络进行训练，降噪后的性能指标如表 3 所示。从降噪性能指标可以看出，在不同分贝的噪声情况下，本文所提的网络的模型均具有良好的降噪效果。

表 3 降噪后的指标

Table 3 Indicators after noise reduction

信噪比	SNR/dB	MSE/ 10^{-3}	NCC/ 10^{-1}
-2 dB	8.259	3.453	8.862
-6 dB	5.537	5.909	7.804
-10 dB	3.395	11.104	6.075

进一步分析，在添加 -6 dB 的环境噪声后各类状态信号降噪前后的对比如图 12 所示。通过对降噪前后信号的时域和频域分析发现，本文提出的方法具有良好的降噪效果。特别是内圈故障和外圈故障样本，在图 12 (a) 和 (b) 中可以看出，在降噪前其故障特征频率都被噪声掩盖，而降噪后能够明显看出故障特征频率，并且和其纯净信号的故障特征频率相对应。而滚动体故障信号由

于样本的长度不够,在图 12(c) 中,不论是纯净信号还是降噪后的信号在其包络谱上都不能分辨出故障特征频

率,但是降噪后的包络谱上纯净信号和降噪后的信号也具有相同的分布趋势。




图 12 FCN 降噪前后时域波形和包络谱上的对比

Fig. 12 Comparison on time domain waveform and envelope spectrum before and after FCN noise reduction

3.3 不同降噪方法的对比

为了进一步验证本文所提网络的降噪性能,选取测试集中的外圈故障信号作为数据样本,和仿真案例一样加入-6 dB 的环境噪声。同样与 SVD、CEEMD 和 SSD 降噪方法进行了对比,其降噪前后对比如图 13 所示。从图中可以看出,除了 SSD 降噪以外,CEEMD 降噪和 SVD 降噪后的包络谱上,故障特征频率几乎都被残留的噪声频

率淹没,降噪后的信号无法准确在包络谱上分辨出故障特征频率。而在时域波形上,可以明显看出 SVD 和 CEEMD 的降噪效果不理想,降噪后的信号的变化趋势和纯净信号有较大的差距。相比于本文提出的降噪方法,SSD 降噪也有一定的效果,在其降噪后的包络谱上也能分辨出故障特征频率及其倍频。但从时域图上可以看出 SSD 降噪效果比起 FCN 降噪效果还是具有一定的差距。




图 13 其他降噪方法降噪前后时域波形和包络谱上的对比

Fig. 13 Comparison on time domain waveform and envelope spectrum before and after noise reduction by other methods

为了进一步量化分析不同降噪方法的性能,在原始纯净信号中分别加入-2 dB、-6 dB、-10 dB 的环境噪声,对比各种降噪方法的降噪性能,其不同降噪方法的降噪指标如图 14 所示。图 14(a)表示从加噪信号到降噪后的信号信噪比的提升程度,可以看出本文提出的 FCN 网络降噪的方法相比其他降噪的方法信噪比提升的幅度最大。图 14(b)表示降噪后的信号和原始信号之间的均方

误差,可以看出 FCN 降噪方法的均方误差是最低的。图 14(c)表示降噪后的信号和原始信号的波形相似参数,可以看出 FCN 降噪方法的波形相似参数也是最优的。综上所述,本文所提的 FCN 降噪的方法在不同分贝的噪声干扰情况下,降噪性能指标都是优于其他方法的,证明了全卷积神经网络在降噪方面的强大性能。




图 14 不同噪声情况下降噪后的性能指标对比

Fig. 14 Comparison of performance indexes after noise reduction in different noise situations

3.4 与不同分类方法的对比

为了验证本文所提降噪方法对轴承故障诊断的影响,在原始信号中加入不同等级的噪声,将全卷积神经网络和不同的故障诊断方法结合,分析降噪前后对轴承故障诊断准确率的影响。在本次实验也采用实验室自制轴承疲劳强化试验机的十分类数据,由于本文所提的降噪网络和故障诊断网络都需要训练,因此需要更多的样本数量。为了扩大样本数量,将图 12 中滑动窗口的步长改为 128,以此截取数据,得到 25 000 个样本,将 12 500 样本作为训练集用于训练降噪网络,剩余的 12 500 个样本用作故障诊断网络的训练和测试,其中 10 000 个样本用作故障诊断网络的训练,其余 2 500 个样本作为故障诊断网络的测试集验证故障诊断网络的准确率。在本次实验中,选择了 4 种基于深度学习的故障诊断方法与本文所提的降噪方法相结合,验证降噪前后对故障诊断准确率的影响。其中 WDCNN^[23]、TICNN^[24]、ResNet-18^[25]都是将振动信号直接输入到网络中,而 LeNet-5^[12]先将一维振动信号转化为二维信号然后完成故障诊断任务。取 10 次实验的平均准确率作为网络最终的准确率,其结果如表 4 所示。特别地,由于 LeNet-5 是将一维信号堆叠成二维信号造成了信号特征信息的损失,从而导致故障诊断准确率低于其他网络,并且在训练过程中 LeNet-5 模型也更容易受到噪声的影响。在-2 dB、-6 dB 信噪比情况下,除了 LeNet-5 以外,其他网络降噪前后准确率差别不大,但是在添加-10 dB 及以上的噪声以后,降噪后的故

障诊断准确率大部分都有提升。特别是在添加-15 dB 和-20 dB 环境噪声的情况下,使用 FCN 网络降噪后,所有故障诊断网络的故障准确率均有提升,这证明了全卷积神经网络在降噪方面的强大性能,不仅过滤了噪声,还保留了绝大部分的特征信息。

表 4 故障诊断网络的准确率

Table 4 Accuracy of fault diagnostic networks

信噪比	FCN 降噪	WDCNN/%	TiCNN/%	ResNet-18/%	LeNet-5/%
原始信号		99.30	99.80	100	96.27
-2 dB	降噪前	99.00	99.60	99.94	94.67
	降噪后	98.92	99.60	99.92	95.47
-6 dB	降噪前	98.96	99.84	99.88	92.19
	降噪后	98.68	99.76	99.96	94.55
-10 dB	降噪前	97.20	99.88	99.96	82.65
	降噪后	98.16	99.76	100	92.55
-15 dB	降噪前	91.15	97.72	99.96	54.45
	降噪后	95.75	99.08	100	88.90
-20 dB	降噪前	77.20	85.54	99.64	41.00
	降噪后	88.78	95.00	99.92	78.27

4 结 论

本文将全卷积神经网络应用在轴承降噪,将网络设计成输入输出长度一致,并在网络的最后接一个残差连接用于约束网络的学习目标,实现了端到端的轴承信号降噪。通过仿真信号对比实验首先确认了最佳的 Leaky-ReLU 激活函数的 α 取值和网络第一层卷积核的大小。

然后通过仿真信号实验计算全卷积神经网络和其他降噪方法的降噪性能指标,初步验证全卷积神经网络的降噪性能,并将降噪后的仿真信号与原始仿真信号进行时域和包络谱分析。此外,还使用采集的轴承故障数据对比主流的降噪方法,验证全卷积神经网络的降噪性能。实验结果表明在绝大多数的情况下,全卷积神经网络的降噪性能都是优于其他3种降噪方法。最后再将FCN与故障诊断网络相结合,结果表明使用FCN降噪后进行故障诊断的准确率相比于没降噪进行故障诊断的准确率大部分情况下都有明显的提升。

本文使用全卷积神经网络进行降噪,需要使用纯净信号作为网络的标签引导网络训练,并且也需要一定量的数据才能取得较好的降噪效果。在网络的约束方法上仍有探索空间,后期将基于物理意义约束规则对降噪网络进行约束以达到更好的降噪效果。

参考文献

- [1] CERRADA M, SÁNCHEZ R V, LI C, et al. A review on data-driven fault severity assessment in rolling bearings [J]. *Mechanical Systems and Signal Processing*, 2018, 99: 169-196.
- [2] 徐明林. 基于小波降噪和经验模态分解的滚动轴承故障诊断[D]. 哈尔滨:哈尔滨工业大学, 2014.
XU M L. Rolling bearing fault diagnosis based on wavelet denoising and empirical mode decomposition [D]. Harbin: Harbin Institute of Technology, 2014.
- [3] YANG H, CHENG Y, LI G. A denoising method for ship radiated noise based on Spearman variational mode decomposition, spatial-dependence recurrence sample entropy, improved wavelet threshold denoising, and Savitzky-Golay filter [J]. *Alexandria Engineering Journal*, 2021, 60(3): 3379-3400.
- [4] 刘湘楠, 赵学智, 上官文斌. 强背景噪声振动信号中滚动轴承故障冲击特征提取[J]. *振动工程学报*, 2021, 34(1): 202-210.
LIU X N, ZHAO X ZH, SHANGGUAN W B. Extraction of impact characteristics of rolling bearing faults in strong background noise vibration signals [J]. *Journal of Vibration Engineering*, 2021, 34(1): 202-210.
- [5] LI H, LIU T, WU X, et al. A bearing fault diagnosis method based on enhanced singular value decomposition [J]. *IEEE Transactions On Industrial Informatics*, 2021, 17(5): 3220-3230.
- [6] 丁锋, 秦峰伟. 小波降噪及Hilbert变换在电机轴承故障诊断中的应用[J]. *电机与控制学报*, 2017, 21(6): 89-95.
DING F, QIN F W. Application of wavelet noise reduction and Hilbert transform in motor bearing fault diagnosis [J]. *Journal of Electrical Machines and Control*, 2017, 21(6): 89-95.
- [7] 杜冬梅, 张昭, 李红, 等. 基于LMD和增强包络谱的滚动轴承故障分析[J]. *振动测试与诊断*, 2017, 37(1): 92-96, 201.
DU D M, ZHANG ZH, LI H, et al. Fault analysis of rolling bearings based on LMD and enhanced envelope spectrum [J]. *Vibration Testing and Diagnosis*, 2017, 37(1): 92-96, 201.
- [8] 赵洪山, 李浪. 基于MCKD-EMD的风电机组轴承早期故障诊断方法[J]. *电力自动化设备*, 2017, 37(2): 29-36.
ZHAO H SH, LI L. Early fault diagnosis method for wind turbine bearings based on MCKD-EMD [J]. *Power Automation Equipment*, 2017, 37(2): 29-36.
- [9] SHA C, WANG C, WU M, et al. An algorithm to remove noise from locomotive bearing vibration signal based on adaptive EMD filter [C]. *Proceedings of the Proceedings of the 33rd Chinese Control Conference*, 2014.
- [10] 雷亚国, 贾峰, 周昕, 等. 基于深度学习理论的机械装备大数据健康监测方法[J]. *机械工程学报*, 2015, 51(21): 49-56.
LEI Y G, JIA F, ZHOU X, et al. A big data health monitoring method for mechanical equipment based on deep learning theory [J]. *Journal of Mechanical Engineering*, 2015, 51(21): 49-56.
- [11] 曲建岭, 余路, 袁涛, 等. 基于一维卷积神经网络的滚动轴承自适应故障诊断算法[J]. *仪器仪表学报*, 2018, 39(7): 134-143.
QU J L, YU L, YUAN T, et al. Adaptive fault diagnosis algorithm for rolling bearings based on one-dimensional convolutional neural network [J]. *Journal of Instrumentation*, 2018, 39(7): 134-143.
- [12] WEN L, LI X, GAO L, et al. A new convolutional neural network-based data-driven fault diagnosis method [J]. *IEEE Transactions on Industrial Electronics*, 2018, 65(7): 5990-5998.
- [13] 刘文彪, 段礼祥, 耿帆, 等. 基于CNN-BLSTM网络的轴承性能退化预测[J]. *电子测量与仪器学报*, 2021, 35(2): 80-86.
LIU W B, DUAN L X, GENG F, et al. Prediction of bearing performance degradation based on CNN-BLSTM network [J]. *Journal of Electronic Measurement and Instrumentation*, 2021, 35(2): 80-86.
- [14] MAO W, LIU Y, DING L, et al. Imbalanced fault diagnosis of rolling bearing based on generative adversarial network: A comparative study [J]. *IEEE*

- Access, 2019, 7: 9515-9530.
- [15] IM D, HAN D, CHOI S, et al. DT-CNN: An energy-efficient dilated and transposed convolutional neural network processor for region of interest based image segmentation [J]. IEEE Transactions on Circuits and Systems I: Regular Papers, 2020, 67(10): 3471-3483.
- [16] DUMOULIN V, VISIN F. A guide to convolution arithmetic for deep learning [J]. ArXiv Preprint, 2016, ArXiv:160307285.
- [17] PARHI R, NOWAK R D. The role of neural network activation functions [J]. IEEE Signal Processing Letters, 2020, 27: 1779-1783.
- [18] WANG X, GIRSHICK R, GUPTA A, et al. Non-local neural networks[C]. Proceedings of the Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2018.
- [19] 王振亚, 伍星, 刘韬, 等. 奇异谱分解联合互信息的主轴轴承故障特征提取研究 [J]. 振动与冲击, 2023, 42(15): 23-30, 47.
- WANG ZH Y, WU X, LIU T, et al. Research on fault feature extraction of spindle bearings using singular spectrum decomposition combined with mutual information [J]. Vibration and Shock, 2023, 42 (15): 23-30, 47.
- [20] 周涛涛, 朱显明, 彭伟才, 等. 基于 CEEMD 和排列熵的故障数据小波阈值降噪方法 [J]. 振动与冲击, 2015, 34(23): 207-211.
- ZHOU T T, ZHU X M, PENG W C, et al. Wavelet thresholding denoising method for fault data based on CEEMD and permutation entropy [J]. Vibration and Shock, 2015, 34 (23): 207-211.
- [21] 仇媛, 常相茂, 仇倩, 等. 基于长短期记忆网络和滑动窗口的流数据异常检测方法 [J]. 计算机应用, 2020, 40(5): 1335-1339.
- QIU Y, CHANG X M, QIU Q, et al. Anomaly detection method for streaming data based on long and short-term memory network and sliding window [J]. Computer Applications, 2020, 40(5): 1335-1339.
- [22] WANG Z, LIU T, WU X, et al. Application of an oversampling method based on GMM and boundary optimization in imbalance-bearing fault diagnosis [J]. IEEE Transactions on Industrial Informatics, 2023: 1-10.
- [23] ZHANG W, PENG G L, LI C H, et al. A new deep learning model for fault diagnosis with good anti-noise and domain adaptation ability on raw vibration signals [J]. Sensors, 2017, 17(2): 425.
- [24] ZHANG W, LI C, PENG G, et al. A deep convolutional neural network with new training methods for bearing fault diagnosis under noisy environment and different working load [J]. Mechanical Systems and Signal Processing, 2018, 100: 439-453.
- [25] 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.

作者简介



范啸宇, 2021 年于西南交通大学希望学院获得学士学位, 现为昆明理工大学硕士研究生, 主要研究方向为机电系统故障诊断。

E-mail: fan15283587542@163.com

Fan Xiaoyu received his B. Sc. degree from Southwest Jiaotong University Hope College in 2021. Now he is a M. Sc. candidate in Kunming University of Science and Technology. His main research interests include mechanical and electrical system fault diagnosis.



刘韬 (通信作者), 2014 年于上海交通大学获得博士学位, 现为昆明理工大学教授, 博士生导师, 主要研究方向为现代信号处理技术及其应用、人工智能理论及其应用和设备健康运维理论及系统。

E-mail: kmliutao@aliyun.com

Liu Tao (Corresponding author) received his Ph. D. degree from Shanghai Jiao Tong University in 2014. Now he is a professor, doctoral supervisor at Kunming University of Science and Technology. His main research interests include modern signal processing technology and its applications, artificial intelligence theory and its applications, and equipment health operation and maintenance theory and systems.