

基于 MR-DCA 的滚动轴承微弱故障诊断

肖乾¹, 李楷文¹, 周生通¹, 汪寒俊¹, 宾浩翔¹, 常运清¹

(1. 华东交通大学 载运工具与装备教育部重点实验室, 南昌 330013)

摘要: 针对滚动轴承微弱故障难以识别的问题, 提出了一种基于 MR-DCA 的滚动轴承故障诊断方法。利用最大相关峭度解卷积以及共振稀疏分解的方法对输入样本进行预处理, 可以有效地滤除原信号中的噪声, 突出故障冲击成分。将所获得的故障分量的二维时频图以及原始信号作为网络的训练样本, 经两个特征学习模块后, 使用注意力机制对输入特征进行筛选, 通过权重重分配可以有效地提高模型计算效率和识别精度。为了验证模型性能, 使用某大学的滚动轴承微弱故障数据进行故障诊断分析, 同时开展消融实验, 对诊断模型的各个模块的有效性进行验证。结果表明, 所提模型在进行滚动轴承微弱故障诊断时可以实现的良好的诊断性能。

关键词: 最大相关峭度解卷积; 共振稀疏分解; 卷积神经网络; 注意力机制

中图分类号: TH133

文献标志码: A

本文引用格式:

MR-DCA based diagnosis of weak faults of rolling bearings

Xiao Qian¹, Li Kai-wen¹, Zhou Sheng-tong¹, Wang Han-jun¹, Bin Hao-xiang¹, Chang Yun-qing¹

(1. Key Laboratory of Conveyance and Equipment of the Ministry of Education of China, East China Jiaotong University, Nanchang 330013, China)

Abstract: The MR-DCA based rolling bearing fault diagnosis method is proposed for the problem that rolling bearing weak faults are difficult to identify. The input samples are pre-processed by using the maximum correlated kurtosis deconvolution and resonance-based sparse signal decomposition, which can effectively filter out the noise of original signal and feature the fault impact components. The obtained two-dimensional time-frequency diagrams of the fault components and the original signal are used as the training samples of the network, and after two feature learning modules, the input features are filtered using the attention mechanism, and the model computational efficiency and recognition accuracy can be effectively improved by weight reassignment. In order to verify the model performance, a rolling bearing weak fault dataset is used for fault diagnosis analysis, while ablation experiments are carried out to verify the effectiveness of each module of the diagnostic model. The results show that the proposed model can achieve good diagnostic performance in the diagnosis of rolling bearing weak faults.

Key words: Maximum correlated kurtosis deconvolution; Resonance-based sparse signal decomposition; Convolutional neural networks; Attention mechanism

Citation format:

基金项目: 国家自然科学基金项目 (51975210, 52065022)

江西省自然科学基金项目 (20202BABL204036)

轴承发生微弱故障时,会产生周期性的冲击,但由于环境噪声的干扰,从原始信号中分离出故障特征并不容易^[1]。如何在轴承早期故障时期实现故障特征的提取并准确识别,是滚动轴承诊断中的关键问题。

传统的时域分析和频域分析方法往往假设信号平稳且线性,然而微弱故障信号往往呈现非线性、非平稳和非高斯分布的特征,因此难以实现良好的诊断效果^[2]。由于故障信号往往表现为冲击信号,McDonald^[3]提出了一种最大相关峭度解卷积(Maximum correlated kurtosis deconvolution, MCKD)算法并成功实现了齿轮箱故障的诊断。该方法适合对周期冲击进行分离,是较为典型的盲解卷积方法。然而该方法对于微弱故障信号效果不佳,且解卷积效果依赖于算法参数的选取^[4]。在此基础上,Cui^[5]将VMD和MCKD方法结合实现了对滚动体故障的诊断。宋^[6]等将改进的EMD方法与MCKD结合实现了对滚动轴承早期故障的提取。李^[7]等在强噪声环境下使用MCKD与改进EWT结合的方法实现了滚动轴承早期故障识别。以上改进方法均有效提升了MCKD方法在微弱故障诊断方面的性能,为了实现最佳诊断效果,MCKD方法通常与其他算法结合使用。

共振稀疏分解(Resonance-based sparse signal decomposition, RSSD)是Selensick^[8]提出的一种可以将信号平稳循环成分与故障冲击分离的算法,适用于对降噪信号进行进一步故障分离。孙^[9]等研究了RSSD方法在滚动轴承故障诊断方面的应用。张^[10]等使用改进的RSSD方法精确实现轴承复合故障诊断。何^[11]等利用RSSD算法实现了齿轮箱的故障诊断。这些方法都有效实现了对故障冲击信号的分离,但在强噪声环境下,RSSD方法并不能实现良好的故障特征分离效果。

卷积神经网络(Convolution Neural Network, CNN)具有自适应挖掘数据深层次特征的特性,可以实现针对抽象特征的分类识别^[12]。赵^[13]等利用CNN实现了强噪声变工况情况下的滚动轴承故障诊断。雷^[14]等利用改进的CNN实现了小样本情况下的滚动轴承故障诊断。杨^[15]等利用改进的CNN增强了对小尺寸目标的定位能力。然而上述方法都是从单一的时域或频域进行特征学习,模型鲁棒性不强,可能影响诊断精度。Wang等^[16]提出了一种分别将小波系数和原始信号作为双通道CNN输入的方法,实现了煤矿生产中的微震事件检测。Song等^[17]则利用双通道CNN对空间光谱

特征进行融合,实现了高光谱图像的分类。张^[18]等则提出一种双通道CNN-GRU模型实现了齿轮箱的故障诊断。然而进行双通道CNN模型往往计算量大,且有可能因为特征冗余引起过拟合,注意力机制^[19]由于其可以对输入特征进行自适应筛选的特性,在复杂样本的CNN模型训练中体现出独特优势。

基于上述原因,本文提出一种时频特征结合的滚动轴承微弱故障诊断方法。通过MCKD与RSSD结合对微弱故障信号进行降噪重构,将重构信号时频图以及一维原始信号分别输入双通道CNN进行深度特征提取;然后结合注意力机制对时频特征进行重筛选,最后对滚动轴承微弱故障进行分类。并通过某大学微弱故障实验数据验证了提出方法的有效性与优越性。

1 诊断模型与基本理论

1.1 诊断模型

滚动轴承微弱故障往往在时域上表现为能量低强度弱的冲击信号,为了实现对微弱故障的分离与诊断,本文提出了一种智能诊断模型。模型主要由两个阶段组成,分别是对输入样本进行预处理的MCKD-RSSD方法以及开展分类的改进的双通道CNN模型。其中MR方法可以自适应地对原始信号噪声进行分离,且不依赖于研究者的先验经验。而改进的双通道CNN模型不需要人为进行特征提取,可以智能地对抽象的输入样本开展分类。模型的诊断流程如图1所示。

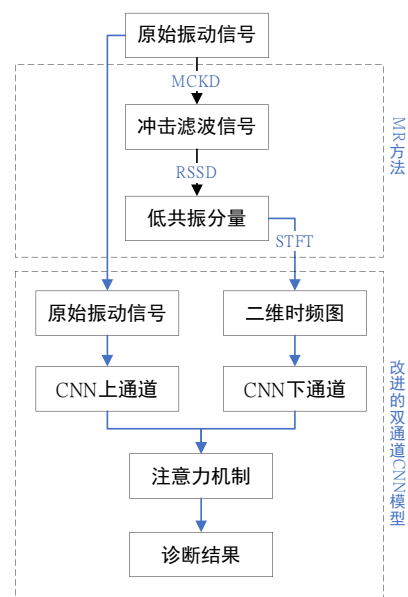


图1 诊断模型流程图

Fig. 1 Flow chart of diagnosis model

1.2 MR 方法

最大相关峭度解卷积本质上是一个滤波算法。在计算过程中，以滤波信号的相关峭度值作为目标函数，利用一个有限冲击响应滤波器 f 获得相关峭度最大时的滤波信号。由于算法突出了信号中的冲击成分，可以有效地对原信号进行噪声的滤除，适用于开展后续研究。

共振稀疏分解可以将复杂的信号分解成平稳循环成分和瞬态冲击成分，瞬态冲击成分中包含大量故障信息，对其进行特征提取所得的样本适用于作为深度学习网络的训练样本。但滚动轴承微弱故障信号强度低，强烈的环境噪声会掩盖原信号中的冲击成分，因此共振稀疏分解难以在信噪比低的情况下实现良好的分离效果。

针对以上分析，本文提出将 MCKD 与 RSSD 两种方法结合，并使用粒子群算法分别对两种算法的参数进行寻优，以实现最好的降噪与微弱故障分离效果。MR 算法流程如下所示：

(1)确定最大相关峭度解卷积中解卷积周期的范围。

(2)使用相关峭度作为粒子群算法的目标函数。对原始信号进行MCKD分解，选取双目标函数最大时的信号分量做进一步分析；

(3)确定共振稀疏分解中高低品质因子以及高低分解层数的范围。

(4)使用包络谱熵作为粒子群算法的目标函数，对(1)中得到的信号分量进行共振稀疏分解参数寻优，得到包络谱熵最小时的低共振分量和高共振分量；

(5)确定目标函数最优时的品质因子及分解层数，使用该参数对输入信号进行共振稀疏分解并得到所需的低共振分量；

1.3 改进的双通道 CNN 模型

传统的机器学习训练表明，故障数据的训练没有重点会使学习效率极低。由于缺乏聚焦，对

微弱故障诊断的识别精度也会受到影响。因此，考虑将注意力机制与CNN相结合，以提高识别精度。

显然，针对双通道CNN的输入，二维时频图像和一维时域信号存在特征重叠，且并非所有特征对识别任务都同样重要。CNN模型的输出只代表一个振动信号样本的全局特征，经卷积后的所有特征权重是相同的。本文通过注意力机制，针对双通道特征进行权重分配，有效避免了由于特征冗余引起的过拟合问题，提升了模型的训练速度以及识别准确率。

1.3.1 注意力机制

为了对诊断模型的融合输出 $H = [h_1, h_2, h_3, \dots, h_n]$ 使用注意力机制重赋权值，引入查询向量 q ，然后通过权值函数 $s(h, q)$ 计算查询向量 q 和每个输入 h_i 之间的相关性，得出一系列的权值。接下来使用 softmax 对这些权值进行归一化，归一化后的结果便是查询向量 q 在各个输入 h_i 上的注意力分布 $a = [a_1, a_2, a_3, \dots, a_n]$ ，其中每一项数值和原始的输入 $H = [h_1, h_2, h_3, \dots, h_n]$ 一一对应。 a_i 如式 (1) 计算：

$$a_i = \text{softmax}(s(h_i, q)) = \frac{\exp(s(h_i, q))}{\sum_{j=1}^n \exp(s(h_j, q))} \quad (1)$$

根据注意力分布 a 可以有选择性的从输入信息 H 中提取关键信息，DCA 架构采用的提取方式为软性注意力机制，即根据注意力分布对输入信息进行加权求和，最终结果 context 为在识别中对分类结果影响更大的特征：

$$\text{context} = \sum_{i=1}^n a_i \cdot h_i \quad (2)$$

1.3.2 DCA 模型架构

将双通道CNN的输入以注意力机制的方式相结合，提出一种双通道融合模型的卷积神经网络模型DCA (Dual-channel CNN combined attention mechanism)，模型同时具有对时间和空间的特征处理能力。DCA的结构和如图2所示。对原始信号使用MR方法处理的过程中，无法保证所滤除的全部为噪声信号，可能部分故障信息也被过滤，因此将原信号及MR方法处理获得的二维时频图共同作为DCA模型的输入。

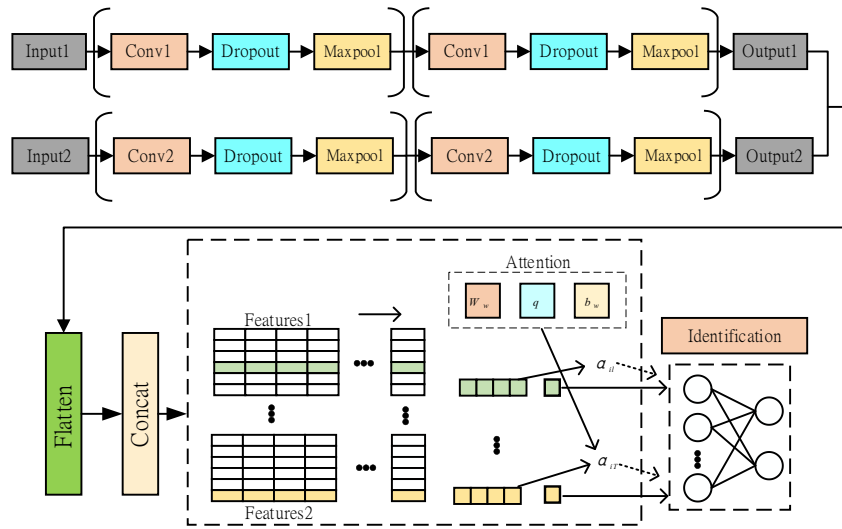


图2 DCA 模型架构

Fig. 2 Architecture of DCA model

DCA模型中每个通道包含两个特征学习模块，模块由卷积层、dropout层和最大池化层组成。其中上通道的输入信号为原始信号，因此为一维卷积，输入样本的形状为 5121×1 。下通道的输入信号为二维时频图像，因此为二维卷积，输入样本的形状为 64×64 。在特征提取模块中，两个卷积层之间的卷积核数量是不同的。卷积层有16个大小为10的卷积核，第二个卷积层有8个大小为10的卷积核。两个卷积层的激活函数设为ReLU。Dropout层被添加以防止过拟合，速率设置为0.5。为了降低特征维数，提高计算效率，提取更多的信号判别特征，在架构中加入最大池化层以实现微弱故障特征的放大。最大池化层设置为大小为2，步幅为2。经过最大池化层后，连接两个通道的输出。经注意力机制进行特征权重重分配后最终输出预测结果。优化算法为Adam，学习率为0.001，损失函数为二元交叉熵。

2 滚动轴承微弱故障数据集

本文采用某大学的滚动轴承微弱故障样本进行实验，使用的数据采集仪器为CoCo80，采样频率为25.6kHz，NSK6203型电机轴承，故障轴承位于电机驱动端与齿轮箱的同步带连接处，加速度传感器通过磁体底座部署在电机驱动端盖中。

在本实验中，通过加工具有确定损伤直径和深度的单点缺陷量化故障损伤程度，微弱故障形式统一为宽度2mm，深度0.5mm的微裂纹，并模拟了总共三种故障以及正常状态。其中故障位置包括内圈、外圈以及滚动体三种位置。本实验使用的滚动轴承如图3所示，其中(a)为外圈故障，

(b)为内圈故障，(c)为滚动体故障。(d)为正常状态。

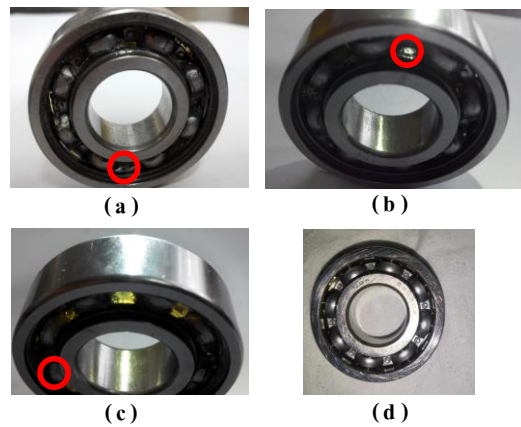


图3 四种状态滚动轴承

Fig. 3 Four kinds of rolling bearings

在本次实验中，每种样本采集8次，每次采集时间为20s，去除在电机启动加速时间段的信号，共获得每种故障类型的样本共500个。每种类型的数据随机抽取250个，按照80%和20%的比例划分训练集和测试集。训练集样本共有800个，测试集样本共有200个。

3 实验结果与讨论

3.1 实验结果

根据第1节中所提出的诊断模型，使用MR方法对输入信号进行降噪重构，并对重构信号使用短时傅里叶变换得到低共振分量二维时频图如图4所示。其中，M1为外圈故障，M2为内圈故障，M3为滚动体故障，M4为正常状态。可以发

现, 经处理所获得的二维时频图像, 可以观察到多条水平清晰的条纹, 说明经处理获得的信号有效分离出了特征频率并且在整个信号的持续时间均稳定存在。由此可以确定, 噪声信号被有效滤除, 微弱故障冲击得到有效凸显。

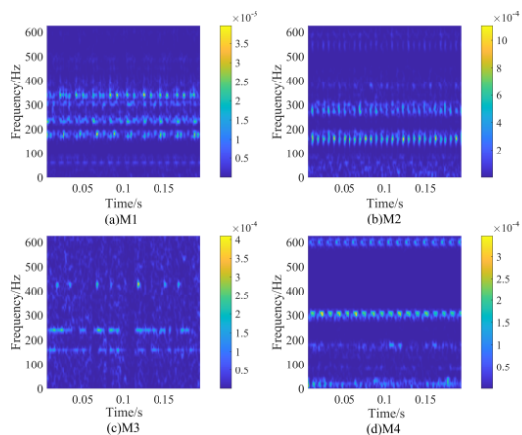


图 4 MR 方法处理结果时频图

Fig. 4 Time frequency diagram of MR method processing result

将经 MR 方法处理得到的二维时频图以及一维原始信号进行重构, 以适应 DCA 训练格式。重构后模型上通道的输入为 5121×1 的原始信号样本, 下通道的输入为 64×64 的二维时频图。试验环境设置如下: Windows 10 64 位操作系统, 运行内存为 16 GB, 显卡为 NVIDIA Quadro P600, 程序语言为 Python 3.6, 程序运行环境为 TensorFlow 2.1.0。训练时单次训练迭代大小、批大小、Adam 算法学习率分别 30,100,0.001。为了充分利用训练数据集, 严格评价 DCA 的学习性能, 采用 10 倍的分层 k-fold 交叉验证。

绘制程序首次运行时, 训练样本与验证样本的损失函数以及准确率随着训练迭代的变化曲线, 如图 5 所示。可以发现, 在前 10 次迭代中, 训练样本与验证样本的损失函数值迅速下降, 模型快速拟合; 随后损失函数下降趋势减缓, 在第 20 次训练迭代后两损失曲线几乎重合, 下降斜率趋近于 0, 并在第 23 次迭代后停止下降, 此时损失函数值停止下降且接近于 0, 模型完成收敛。而训练样本与验证样本准确度曲线在前 15 次训练迭代中迅速上升, 准确度值接近 0.98。在第 18 个单次训练迭代后准确度曲线重合, 斜率为 0, 值达到最大 0.981。

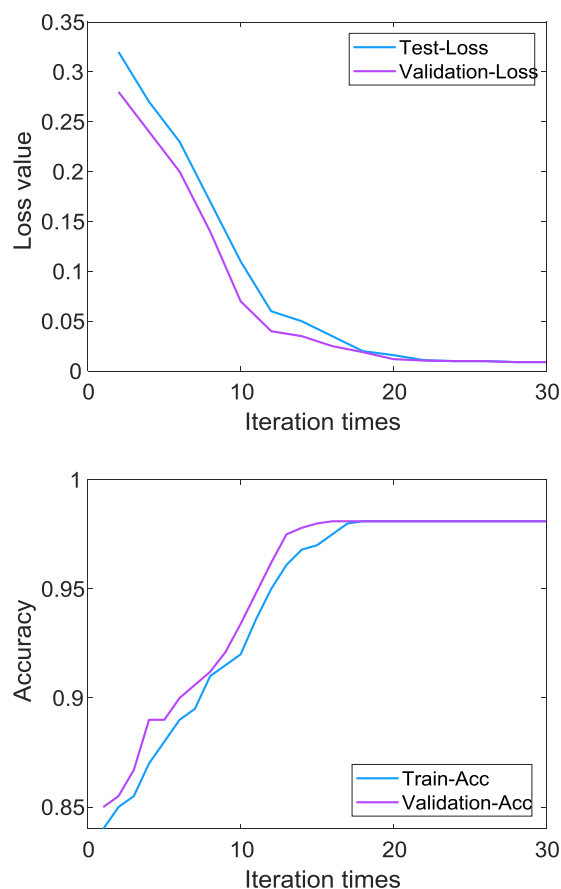


图 5 DCA 模型损失及准确率

Fig. 5 Loss value and accuracy of DCA model

为了直观地显示模型诊断效果, 使用混淆矩阵将测试集分类结果可视化, 如图 6 所示。为了避免结果的偶然性, 对输入数据进行 10 次随机重组, 每次划分不同的训练集以及测试集, 取 10 次诊断的平均结果作为模型的最终准确率。最终计算得出 10 次诊断的平均准确率为 98.1%, 证明本文方法具有很好的分类性能, 且模型的鲁棒性与泛化能力优异。

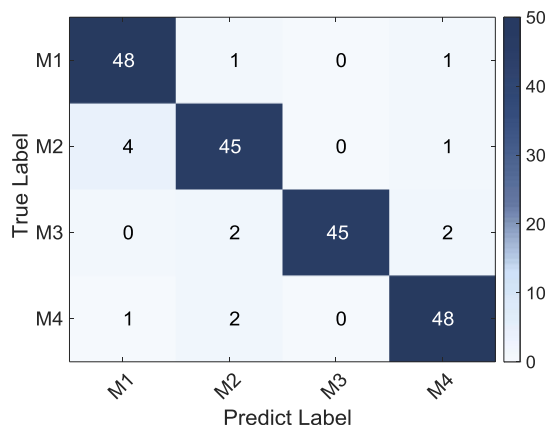


图 6 DCA 模型诊断结果混淆矩阵

Fig. 6 Fuse matrix of DCA model diagnosis result

3.2 消融实验与结果讨论

为了探索注意力机制和 MR 方法对识别准确性和效率的贡献,本节开展了一项消融研究。分别构建了三个诊断模型,第一个模型为将未经过 MR 方法处理过的时频图像及原始信号分别作为 DCA 输入,第二个模型则为将经过 MCKD-RSD 处理过的时频图及原始信号作为不加入注意力机制的传统双通道 CNN 输入 (MR-DC),第三个模型为没有 MR 方法处理且未加入注意力机制的双

通道 CNN 模型,分别比较这四个模型的性能。

分别将测试集输入到训练好的模型中,为避免结果的偶然性,多次训练模型并开展诊断,取 10 次诊断的平均结果作为模型的最终准确率。计算得 MR-DC 模型、DCA 模型以及 DC 模型的平均诊断精度分别为 90.6%, 87.1% 以及 80.1%。

为了进一步对比三种模型的性能,分别对三个模型统计其单次训练时间以及达到收敛的迭代次数,本文以准确率不再变化作为模型收敛的判据。结果见表 2。

表 2 四种模型性能对比

	准确率/%	训练时间/s	平均迭代次数
MR-DCA	98.1	14.83	18
MR-DC	90.6	25.34	26
DCA	87.1	18.23	22
DC	80.1	30.97	31

由表 2 可知,所提出的 MR-DCA 模型在三个指标上的表现都明显优于其他三个模型。对比 MR-DC 模型和 DCA 模型发现,相较于传统 DC 模型,MR-DC 在识别准确率上表现更佳,而 DCA 模型则拥有更短的训练时间以及只需要更少的迭代次数达到收敛。对于 MR-DC 模型,输入的样本时频图具有更小的噪声,且原信号中的平稳循环成分被滤除,微弱故障冲击成分明显,相对于没有经过 MR 方法处理的样本,具有更加明显的特征,有效地提升了识别的准确性,然而所输入的时频图和原始信号数据,存在一定的特征重叠,这有可能导致特征冗余,不仅使得训练时间和达到收敛的迭代次数增加,还有可能引起模型的过拟合。而对于 DCA 模型,由于注意力机制的存在,可以自适应地对融合特征进行重赋权,对于结果影响不大的特征权值被降低,加快了模型的训练时间,同时减少了达到收敛所需要的迭代次数。因此,本文提出的 MC-DCA 模型,在去除噪声和平稳循环成分保留微弱故障冲击的基础上,通过注意力机制减少了输入特征的冗余,并通过权值重分配保留了对识别结果影响更大

的特征,节省了算力的消耗,提升了整体诊断效率。

4 结论

本文采用某大学的滚动轴承振动数据集,对出现不同微弱故障的滚动轴承开展了研究,得出了以下结论。

(1) 提出了一种基于 MR-DCA 的滚动轴承微弱故障诊断方法。首先通过 MR 方法对 DCA 模型的输入进行重构,有效实现了对原始信号的降噪重构以及微弱故障的凸显。同时在双通道 CNN 模型的基础上加入注意力机制,增强了模型的特征提取能力和整体计算效率,提高了诊断模型的精度。

(2) 通过消融实验验证所提出方法的优越性,分别将本文提出的 MR-DCA 模型与 MR-DC、DCA、DC 模型对比,并对实验结果进行讨论。结果表明,本文所提出的方法识别准确率更高,且具有更快的训练速度和迭代速度。

参考文献:

[1] 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 Xiangnan, ZHAO Xuezhi, SHANGGUAN Wenbin. The impact features extraction of rolling bearing under

strong background noise [J]. Journal of Vibration Engineering, 2021, 34(1): 202-210.
[2] 张苑. 基于信号稀疏表示的滚动轴承微弱故障特征提取方法研究[D]. 东南大学, 2018.
Zhang Wan. Research on rolling bearing faint fault feature extraction method based on signal sparse

- representation[D]. Southeast University,2018
- [3] MCDONALD G L, ZHAO QING, ZHOU M J. Maximum correlated kurtosis deconvolution and application on gear tooth chip fault detection[J]. *Mechanical Systems and Signal Processing*, 2012(33): 237-255
- [4] 张龙,蔡秉桓,熊国良,等.小波滤波与最大相关峭度解卷积参数同步优化的轴承故障诊断[J].*振动工程学报*,2021,34(06):1313-1322.
Zhang Long, Cai Binghuan, Xiong Guoliang, et al. Simultaneous optimization of wavelet filtering and maximum correlation cliff deconvolution parameters for bearing fault diagnosis[J]. *Journal of Vibration Engineering*,2021,34(06):1313-1322.
- [5] Cui H, Guan Y, Chen H. Rolling element fault diagnosis based on VMD and sensitivity MCKD[J]. *IEEE Access*, 2021, PP(99):1-1.
- [6] 宋宇博,刘运航,朱大鹏.自适应 UPEMD-MCKD 轴承故障特征提取方法[J].*振动与冲击*,2023,42(03):83-91.
Song Yubo, Liu Yunhang, Zhu Dapeng. Adaptive UPEMD-MCKD bearing fault feature extraction method[J]. *Vibration and Shock*,2023,42(03):83-91.
- [7] 李政,张炜,明安波等.基于 IEWT 和 MCKD 的滚动轴承故障诊断方法[J].*机械工程学报*,2019,55(23):136-146.
Li Zheng, Zhang Wei, Ming Anbo et al. A rolling bearing fault diagnosis method based on IEWT and MCKD[J]. *Journal of Mechanical Engineering*,2019,55(23):136-146.
- [8] Selesnick I W. Resonance-based signal decomposition: A new sparsity-enabled signal analysis method[J]. *Signal Processing*, 2012, 91(12):2793-2809.
- [9] 孙占龙. 基于共振稀疏分解的滚动轴承故障诊断方法研究[D].北京交通大学,2017.
Sun Zhanlong. Research on rolling bearing fault diagnosis method based on resonant sparse decomposition[D]. Beijing Jiaotong University,2017.
- [10]张守京,慎明俊,杨静雯等.改进的共振稀疏分解方法及其在滚动轴承复合故障诊断中的应用[J].*中国机械工程*,2022,33(14):1697-1706.
Zhang Shoujing, Shen Mingjun, Yang Jingwen et al. Improved resonant sparse decomposition method and its application in rolling bearing composite fault diagnosis[J]. *China Mechanical Engineering*,2022,33(14):1697-1706.
- [11]何群,郭源耕,王霄等.基于信号共振稀疏分解和最大相关峭度解卷积的齿轮箱故障诊断[J].*中国机械工程*,2017,28(13):1528-1534.
He Qun, Guo Yuangong, Wang Xiao et al. Gearbox fault diagnosis based on signal resonance sparse decomposition and maximum correlation cliff deconvolution[J]. *China Mechanical Engineering*,2017,28(13):1528-1534.
- [12]周飞燕,金林鹏,董军.卷积神经网络研究综述[J].*计算机学报*,2017,40(06):1229-1251.
Zhou Feiyan, Jin Linpeng, Dong Jun. A review of convolutional neural network research[J]. *Journal of Computer Science*,2017,40(06):1229-1251.
- [13]赵小强,张亚洲.利用改进卷积神经网络的滚动轴承变工况故障诊断方法[J].*西安交通大学学报*,2021,55(12):108-118.
Zhao Xiaoqiang, Zhang Yazhou. A fault diagnosis method for rolling bearing variable conditions using improved convolutional neural network[J]. *Journal of Xi'an Jiaotong University*,2021,55(12):108-118.
- [14]雷春丽,夏奔锋,薛林林等.基于 MTF-CNN 的滚动轴承故障诊断方法[J].*振动与冲击*,2022,41(09):151-158.
Lei Chunli, Xia Benfeng, Xue Linlin et al. MTF-CNN based rolling bearing fault diagnosis method[J]. *Vibration and Shock*,2022,41(09):151-158.
- [15]杨丰萍,彭云帆,李远征.基于深度学习的小样本绝缘子自爆检测研究[J].*华东交通大学学报*,2022,39(02):110-117.
YANG FengPing, PENG YunFan, LI YuanZheng. Research on self-detonation detection of insulators with small samples based on deep learning[J]. *Journal of East China Jiaotong University*,2022,39(02):110-117.
- [16]Wang Yaojun, Qiu Q, Lan Zhiqiang, et al. Identifying microseismic events using a dual-channel CNN with wavelet packets decomposition coefficients. *Computers & Geosciences*, 2022, 166: 105164.
- [17]Haifeng Song, Weiwei Yang, Songsong Dai, Using dual-channel CNN to classify hyperspectral image based on spatial-spectral information[J]. *Mathematical Biosciences and Engineering*, 2020, 17(4): 3450-3477.
- [18]张龙,甄灿壮,易剑昱等.双通道特征融合 CNN-GRU 齿轮箱故障诊断[J].*振动与冲击*,2021,40(19):239-245+294.
Zhang L, Zhen C Z, Yi J Y et al. Dual-channel feature fusion CNN-GRU gearbox fault diagnosis[J]. *Vibration and Shock*,2021,40(19):239-245+294.
- [19]刘建伟,刘俊文,罗雄麟.深度学习中注意力机制研究进展[J].*工程科学学报*,2021,43(11):1499-1511.
Liu Jianwei, Liu Junwen, Luo Xionglin. Advances in the study of attention mechanism in deep learning[J].

作者简介



肖乾(1977-), 男, 博士, 二级教授, 江西省“井冈学者”特聘教授, 载运工具与装备教育部重点实验室主任, 轨道交通基础设施性能监测与保障国家重点实验室副主任。近年来, 主持国家自然科学基金 3 项, 省部级项目 5 项; 发表 SCI、EI 收录论文 40 余篇, 获省科技进步一等奖等省部级奖励 3 项、授权发明专利 6 项、软件著作权 20 余项, 成果转化 3 项。



李楷文(1997-), 男, 硕士研究生, 主要研究方向: 齿轮箱故障诊断, 邮箱: 490819906@qq.com

修改说明

尊敬的各位审稿老师好！本文已按照审稿意见进行修改，此处就每条审稿意见做出修改说明。

一、第一审稿人专家审稿意见：

叙述了一种分析滚动轴承微弱故障信号的方法。该方法结合最大相关峭度解卷积和共振稀疏分解，将信号降噪重组。利用 CNN 网络进行深度特征提取。论文采用的方法有一定的前沿性。在信号分析方法的组合方面，有一定新意。

1、文献应有效引用，例如参考文献[2-4]并没有说“传统的时频分析方法难以对微弱故障信号实现有效分离”，并且时频方法很多，如小波、小波包、希尔伯特-黄变换，并不是都不能对微弱故障信号实现有效分离。

原文写作不严谨，本意是表达单纯的时域分析方法或者频域分析方法对微弱故障信号的降噪和分离效果不佳。已经对原文进行修改，并重新引用了参考文献。

修改文字在原文中使用蓝色字体标出，具体内容如下：

传统的时域分析和频域分析方法往往假设信号平稳且线性，然而微弱故障信号往往呈现非线性、非平稳和非高斯分布的特征，因此难以实现良好的诊断效果^[2]

2、“1.1 诊断模型”，宜对图 1 作必要说明。何谓“智能诊断模型”？

智能诊断模型主要体现在两个方面，一是对原始信号进行处理的方法的自适应性，通过优化算法对算法的参数进行选取以实现最佳的噪声分离及凸显故障特征的效果。二是诊断模型不需要进行特征选取，CNN 模型可以智能地将抽象的输入样本进行分类。在原文中已针对此添加说明。

具体内容如下：

模型主要由两个阶段组成，分别是对输入样本进行预处理的 MR 方法以及开展分类的改进的双通道 CNN 模型。其中 MR 方法可以自适应地对原始信号噪声进行分离，且不依赖于研究者的先验经验。而改进的双通道 CNN 模型不需要人为进行特征提取，可以智能地对抽象的输入样本开展分类。

3、“MR 方法”。MR 是缩写还是作者自创的名词？第一次出现时，宜作说明。MR 算法流程的第三步，“粒子群算法”出现得很突然，宜作必要解释。目标函数如何确定？

MR 方法为 MCKD-RSSD 方法的缩写，已在智能诊断模型的说明中进行了介绍。并在 1.2 节中相

对详细地对两种方法的特性进行阐述。

除此之外，对 MR 方法的进行了一定的优化，由于 MCKD 方法和 RSSD 方法都需要进行参数优化，因此都使用粒子群算法对算法参数进行寻优，其中 MCKD 算法目标函数为相关峭度，相关峭度可以反映信号冲击的强弱，其值越大说明包含的冲击成分越强。因此粒子群算法的目标为寻找相关峭度最大。而 RSSD 算法目标函数为包络谱熵，包络谱熵可以在频域上体现故障冲击的周期性强弱，其值越小说明故障冲击的强度越高。因此粒子群算法的目标为寻找包络谱熵最小。

修改后具体内容如下：

针对以上分析，本文提出将 MCKD 与 RSSD 两种方法结合，并使用粒子群算法分别对两种算法的参数进行寻优，以实现最好的降噪与微弱故障分离效果。MR 算法流程如下所示：

(1)确定最大相关峭度解卷积中解卷积周期的范围。

(2)使用相关峭度作为粒子群算法的目标函数。

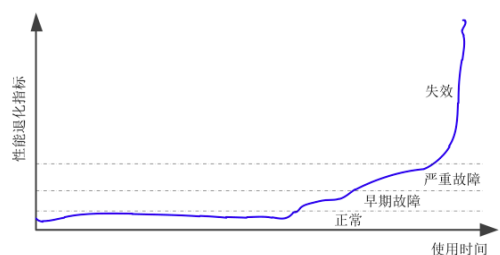
对原始信号进行MCKD分解，选取双目标函数最大时的信号分量做进一步分析；

(3)确定共振稀疏分解中高低品质因子以及高低分解层数的范围。

(4)使用包络谱熵作为粒子群算法的目标函数，对(1)中得到的信号分量进行共振稀疏分解参数寻优，得到包络谱熵最小时的低共振分量和高共振分量；

4、“2 滚动轴承微弱故障数据集”，微弱故障的标准是什么？

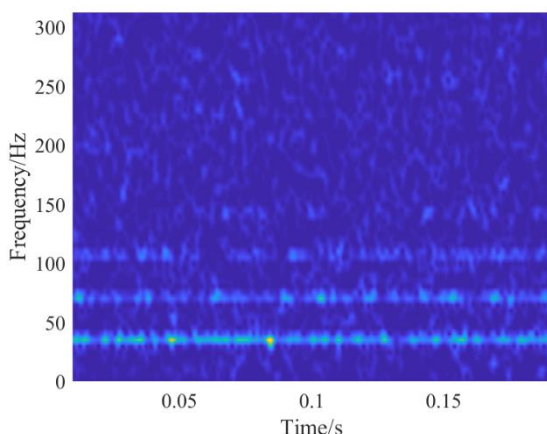
对此我查阅了很多针对微弱故障的文献，文献中没有给出具体的标准，一般可以将微弱故障等同于早期故障，即在滚动轴承刚刚出现故障时定义为微弱故障。



如图为 2018 年东南大学张菀博士的学位论文基于信号稀疏表示的滚动轴承微弱故障特征提取

方法研究中给出的性能退化曲线，参考此曲线以及部分微弱故障相关的文献，我认为可以将滚动轴承早期故障定义为微弱故障，其时域信号具有强度低且易被噪声成分干扰的特点。

5、时频图的解读比较困难，建议说明如何从“图 4 MR 方法处理结果时频图”中解读出“噪声信号被有效滤除，微弱故障冲击得到有效凸显”。



对时频图的解读可以以上图为例，x轴为时间，y轴为频率。图上分别在 35Hz、70Hz、105Hz 处可以观察到较清晰的条纹，且在整个 0.2s 的时间内均存在，说明在原信号中，存在频率为这三种的成分，且在整个采样时间内均持续。原图中其他散落且不连续的蓝色斑点则可以理解为噪声。

以上述类似的解读方式在原文中增加对时频图像的解读。具体内容如下：

可以发现，经处理所获得的二维时频图像，可以观察到多条水平清晰的条纹，说明经处理获得的信号有效分离出了特征频率并且在整个信号的持续时间均稳定存在。由此可以确定，噪声信号被有效滤除，微弱故障冲击得到有效凸显。

二、第二审稿人专家审稿意见：

1、在文中，如何确定样本数据集的训练集与测试集划分标准？

已在原文中增加对样本数据集训练集与测试集划分标准的叙述，具体内容如下：

每种类型的数据随机抽取 250 个，按照 80%和 20%的比例划分训练集和测试集。训练集样本共有 800 个，测试集样本共有 200 个。

2、文中和图中解释不符，图 1 中解释上通道输入为原始，下通道为频谱，而文中 3.1 小节中解释相反。

原文撰写时不够严谨，出现低级错误，已修正。

具体内容如下：

重构后模型上通道的输入为 5121×1 的原始信号样本，下通道的输入为 64×64 的二维时频图。

3、文中没有解释双通道卷积的输入用上通道用原始信号，下通道用频谱，作用是什么，没有阐述明白。

考虑到作为输入样本的二维时频图在经 MR 方法处理的过程中，无法保证所滤除的一定为噪声信号，有部分包含故障信息的信号会随着噪声一起被滤除，因此采用双通道 CNN 结构，将原始信号作为补充输入。

对此在原文中增加说明如下：

对原始信号使用 MR 方法处理的过程中，无法保证所滤除的全部为噪声信号，可能部分故障信息也被过滤，因此将原信号及 MR 方法处理获得的二维时频图共同作为 DCA 模型的输入。

4、文中所用卷积层是几维卷积；文中所用双通道的卷积层的输入需要形状一致吗，输入形状为多少？

原文中上通道为原始信号，因此为一维卷积，输入形状为 5121×1 的原始信号样本。下通道的输入为 64×64 的二维视频图，因此是二维卷积。两通道的输入形状不需要一致，经两个卷积层处理后，会在 flatten 层转换为相同维度但长度不同的特征，再经 concat 层连接。

修改后内容如下：

重构后模型上通道的输入为 5121×1 的原始信号样本，下通道的输入为 64×64 的二维时频图。

三、第三审稿人专家审稿意见：

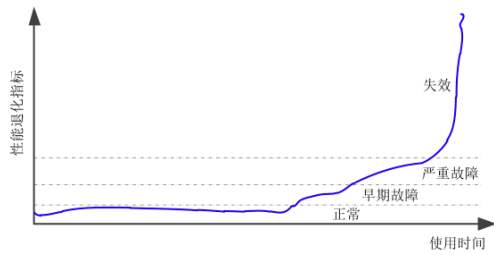
本文针对滚动轴承故障问题，提出了一种基于 MR-DCA 的滚动轴承故障诊断方法，并通过实验验证了模型的良好诊断性能。

文章还有以下问题需要补充说明：

1.本文的题目是针对微弱故障，什么故障算“微弱”？在第 2 部分中提及“通过加工具有确定损伤直径和深度的单点缺陷量化故障损伤程度”，具体的直径和深度是多少？这种尺寸的故障是不是微弱？

微弱故障的定义在对上一位审稿老师的回复中进行了说明，此处采用相同说明如下：

所参考的文献中没有给出微弱故障具体的标准，一般可以将微弱故障等同于早期故障，即在滚动轴承刚刚出现故障时定义为微弱故障。



如图为 2018 年东南大学张菡博士的学位论文基于信号稀疏表示的滚动轴承微弱故障特征提取方法研究中给出的性能退化曲线，参考此曲线以及部分微弱故障相关的文献，我认为可以将滚动轴承早期故障定义为微弱故障，其时域信号具有强度低且易被噪声成分干扰的特点。

在本实验中，轴承外径为 40mm，内径 17mm，所设置的故障尺寸为宽度 2mm 深度 0.5mm 的裂纹。张菡博士的论文中所采用的轴承外径 52mm，内径 25mm，所设置的故障尺寸为宽度 1.6mm，深度 2mm。经对比，可以认为所加工的故障为微弱故障。

在原文中增加了对故障尺寸的说明：

微弱故障形式统一为宽度 2mm，深度 0.5mm 的微裂纹

2. 图 5 DCA 模型损失及准确率，图不是很清晰，而且图中需要将英文部分改成中文部分

已经将图 5 重新绘制，提高了分辨率。由于期刊要求，绘图时图中内容要求使用英文标注，因此未作修改。

3. “3.2 消融实验与结果讨论”部分，以及表 2 训练时间，实在什么条件得出的，需要补充一些内容，比如说，电脑配置，软件版本，编程语言等等。

已经将相关内容加入原文，增加内容如下：

试验环境设置如下：Windows 10 64 位操作系统，运行内存为 16 GB，显卡为 NVIDIA Quadro P600，程序语言为 Python 3.6，程序运行环境为 TensorFlow 2.1.0。