

基于CEEMDAN和优化形态学滤波的电机轴承故障诊断

孙本晗

上海理工大学机械工程学院, 上海

收稿日期: 2024年8月5日; 录用日期: 2024年8月29日; 发布日期: 2024年9月5日

摘要

电机轴承在运行过程中, 存在较多的不规则噪声干扰分量, 使得对电机轴承故障诊断存在一定的难度, 针对上述背景, 本文提出了一种基于完全集合经验模态分解和优化形态学差值滤波的新方法, 用于电机轴承的故障诊断。通过使用西储大学故障轴承振动数据对算法的有效性进行验证。完全集合经验模态分解能够有效分解非线性、非平稳信号, 提供精细的分解信号。随后筛选出包含故障特征的分量信号进行重构, 利用优化后形态学差值滤波器对重构信号进行去噪处理, 以增强故障信号特征。实验结果表明, 该方法在提取故障特征方面具有高精度和鲁棒性, 显著优于传统方法。

关键词

信号分解, 形态学, 差值滤波, 信号特征, 故障诊断

Fault Diagnosis of Motor Bearings Based on CEEMDAN and Optimized Morphological Filtering

Benhan Sun

School of Mechanical Engineering, University of Shanghai for Science and Technology, Shanghai

Received: Aug. 5th, 2024; accepted: Aug. 29th, 2024; published: Sep. 5th, 2024

Abstract

During the operation of motor bearings, there are more irregular noise interference components, which makes it difficult to diagnose the faults of motor bearings. In view of the above background, this paper proposes a new method based on the complete EEMD with adaptive noise and optimal

morphological difference filtering for the fault diagnosis of motor bearings. The effectiveness of the algorithm is verified by using vibration data of faulty bearings from Western Reserve University. The complete ensemble empirical modal decomposition can effectively decompose nonlinear and nonsmooth signals and provide fine decomposition signals. Subsequently, the component signals containing fault features are screened for reconstruction, and the reconstructed signals are denoised using an optimised morphological difference filter to enhance the fault signal features. The experimental results show that the method has high accuracy and robustness in extracting fault features, which is significantly better than the traditional method.

Keywords

Signal Decomposition, Morphology, Difference Filtering, Signal Features, Fault Diagnosis

Copyright © 2024 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

随着工业设备自动化程度的提高，机械设备的故障诊断与健康监测变得尤为重要。电机的故障类别主要分为机械故障和电气故障，其中轴承的故障约占到 51.1%，为主要的故障部位。轴承作为电机中关键部件，其性能好坏直接影响与之相连的转轴甚至整个设备的性能。而轴承的损伤形式是十分复杂的，一旦发生故障便会引发重大安全事故，造成经济损失和人员伤亡[1]。利用传感器信号进行分析是机械故障诊断的重要手段之一，利用传感器设备故障诊断技术对电机状态进行检测至关重要，而智能故障诊断技术因其降低了维修成本并提高了安全性和可靠性，受到越来越多的关注[2]。

近年来，经验模态分解(Empirical Mode Decomposition, EMD)及其改进算法在振动信号处理领域得到了广泛关注。最初由 EMD 进行轴承故障诊断技术盛行，EMD 是一种在故障诊断中应用较多的信号处理方法，能把测得的非线性时域信号转化成相对应的固有模态分量(Intrinsic Mode Functions, IMF) [3]。吴宏亮等[4]提出了基于 EMD 分解和 Hilbert 包络的方法，引入了相关系数指标进行筛选 IMF 分量，重构信号后进行 Hilbert 包络得到故障特征频率。但 EMD 会存在一个模态混叠的现象，针对 EMD 的改进方法，刘佳昕等[5]提出了改进的 EMD 算法(简称 EEMD)，在每次进行 EMD 分解时在原始信号加入同一幅值的白噪声，然后对产生的相关 IMF 进行整体平均处理，从而有效地抑制了模态混叠的发生，但是分解时加入的高斯白噪声在分解后会存在残留，这会导致在信号重构时会逐步形成误差。

完全集合经验模态分解(Complete EEMD with Adaptive Noise, CEEMDAN)作为 EMD 和 EEMD 的改进版本，能够更好地解决分解后重构信号中有白噪声残余、集总次数大且耗时多的缺陷。其基本工作原理可以细化为在 EMD 的基础上有次数地加入自适应白噪声的 IMF 分量，这样一来，基本消除了重构误差，与 EEMD 相比，CEEMDAN 不仅保证了分解效果，而且抑制了重构信号中存在的误差，进一步提高了分解信号的精度和效率[6]。

形态滤波(morphological filter, MF)是基于数学运算上再进行形态学变换的一种非线性信号滤波方法。它利用设定的结构元素与原始信号的形态学运算，来达到提取信号的边缘轮廓、形状和提取冲击特征的目的，因此形态滤波可以有效地用于轴承故障诊断。李非等[7]结合 EMD 并在形态学基本运算中提出差值滤波方法，通过峭度指标来优化单一结构元素的尺寸，差值滤波可以达到提取信号中的正、负冲击，非常适合用于对轴承振动信号的特征提取，最后得出了故障特征频率，取得了较好的滤波效果。

基于上述理论, 本文提出了一种结合 CEEMDAN 和优化形态学差值滤波的方法, 旨在提高机械故障诊断中振动信号处理的精度和鲁棒性。通过实测的轴承振动数据和西储大学故障轴承振动数据集共同来验证, 评估该方法在实际应用中的有效性和可靠性。研究结果不仅为振动信号处理提供了一种新的思路, 也为机械故障诊断技术的发展提供了有力支持。

2. CEEMDAN

CEEMDAN 是在 EMD 基础上优化而来, 本部分主要介绍 EMD 的原理及衍生出来 CEEMDAN 的原理, 以及 IMF 分量的筛选指标。

2.1. EMD

EMD 方法作为一种自适应的时频信号处理技术, 对于分析非线性和非平稳的时频信号具有较好的效果。它的核心是将信号分解为若干个独立成分信号的叠加, 通过数据自身的时间尺度特征进行分解, 具有自适应性。EMD 的优点在于它是一种自适应的、数据驱动的分解方法, 不需要预先假设信号的分布或结构。这使得它适用于处理各种类型的信号, 包括非线性和非平稳信号。

EMD 认为任何复杂序列的时域信号都是由多个单频率信号叠加形成, 因而原始信号可以分解成若干个 IMF。每个 IMF 代表原始信号中的不同频率的分量, 并按照从频率从高到低的顺序进行排列, 这就是 IMF 的物理意义。

EMD 算法的原理如下:

- 1) 将待分解的信号称为原始信号(x), 如图 1 所示。
- 2) 找到原始信号中的极值点(局部最大值和最小值), 通过连接这些极值点形成上下包络线。
- 3) 计算原始信号与上下包络线的平均值, 得到一条均值曲线。

$$m_1 = \frac{1}{2}[b_{\max} + b_{\min}] \quad (1)$$

式中 b_{\max} 代表上极值点形成的包络线, b_{\min} 代表下极值点形成的包络线, m_1 代表均值曲线。

4) 将原始信号减去均值曲线, 判断细节曲线(x_1)是否满足 IMF 的条件: 在整个数据段内, 极值点和过零点的个数相等或相差不超过一个; 任意时刻, 上包络线和下包络线的平均值为零, 即局部对称。如不满足上述条件, 则将细节曲线作为新的原始信号, 重复步骤 2~3, 得到满足条件的 IMF1。

$$x_1 = x - m_1 \quad (2)$$

5) 将原始信号减去满足条件的 IMF1, 重复步骤 2~4, 直到得到满足要求的 IMF 集合, 且当最终多次分解后剩余分量为单调函数时, 完成分解。按频率由高到低排列。

$$x = \sum_{k=1}^n IMF_k + e_n \quad (3)$$

式中 $IMF_1, IMF_2 \dots IMF_k$ 为对应的模态分量, e_n 为残差分量。

2.2. CEEMDAN

针对 EMD 算法分解信号存在模态混叠的问题, 影响后续信号的分析 and 处理。为了解决这些问题, 提出了一种改进算法完全自适应噪声集合经验模态分解, 又称完全集合经验模态分解。

CEEMDAN 算法的原理如下:

- 1) M 组高斯白噪声添加至原始信号 x 中, 得到 M 组待处理新信号:

$$x_{new}^i = x \pm \varepsilon \mathcal{O}^i \quad (4)$$

式中： δ^i 为满足标准正态分布的高斯白噪声信号， $i=1,2,\dots,M$ ， ε 为白噪声的标准差； x_{new}^i 为第 j 组新信号数据。

2) 对每一组新信号依次 EMD 分解，对分解出来的第一个 IMF 分量取平均，获取 CEEMDAN 的首个固有模态分量：

$$K_1 = \sum_{i=1}^M IMF_1(x_{new}^i) / M \quad (5)$$

3) 求取原信号去除 IMF1 后的残差分量：

$$\alpha_1 = x - K_1 \quad (6)$$

4) 再次将 M 组高斯白噪声添加 α_1 ，重复上述 EMD 分解，取平均，即可得到 CEEMDAN 的第 2 个固有模态分量：

$$K_2 = \sum_{i=1}^M IMF_1(x_{new}^i) / M \quad (7)$$

5) 循环上述过程，当最终多次分解后剩余分量为单调函数时，完成分解，则原信号表示：

$$x = \sum_{A=1}^n K_A + e_n \quad (8)$$

2.3. 分量重构指标

2.3.1. 峭度

在轴承没有故障时，轴承时域信号通常符合正态分布，趋于平稳，因此其峭度值一般约为 3；而当轴承出现故障时，就会出现较多的周期性冲击，峭度值随之上升。因此，峭度指标的数值大小与信号的冲击成分有很大关联，当峭度值大于 3 时表明其包含更多的故障冲击信息，可作为评判轴承信号中是否包含故障的有效指标，其表达式：

$$Kurt = \frac{\sum_{i=1}^N [x(i) - \bar{x}]^4}{N * \sigma^4} \quad (9)$$

式中： N 代表信号长度； \bar{x} 代表信号平均值； σ 为信号的标准差。

2.3.2. 方差贡献率

单一的指标很难作为有效的筛选指标，因此引入方差贡献率(VAF)这个指标，VAF 的数值代表了在一系列信号中每个信号的重要程度。则本文提出通过计算各 IMF 分量的方差贡献率来说明各阶 IMF 分量的重要程度，因子分析法的统计意义表明，方差贡献率可以确定因子的相对重要性[8]。信号经过 CEEMDAN 分解为 K_1, K_2, \dots, K_n 分量，定义各分量与原信号的方差贡献率计算如下：

$$VAF_j = \frac{D(K_j)}{\sum_{j=1}^n D(K_j) + D(e_n)} \times 100\% \quad (10)$$

式中： $D(K_j)$ 表示信号分解出来的 K_j 分量的方差； $D(e_n)$ 为残差分量的方差。VAF 的取值范围为[0, 1]，当小于 0.1 时，则表示关联程度低，即为分解出来的信号重要程度越低，当取值越接近 1 时，信号的重要程度越高，更加适合于故障特征的提取。

综上所述，本方法集合峭度和 VAF 两个指标，选择 VAF 大于 0.1 的分量且峭度值大于 3 的 IMF 分量作为有效分量，及筛选出主要信号分量进行分解信号的重构。

3. 形态学滤波

传统形态学滤波是一种基于数学形态学的信号处理技术，主要用于图像和信号的噪声抑制、边缘检测和形态特征提取。其基本操作包括膨胀、腐蚀、开运算和闭运算。通过组合这些基本操作，传统形态学滤波可以有效地提取图像或信号的形态特征，去除噪声和突出重要结构。

$f(n)$ 是一维离散信号，定义在 $0, 1, \dots, N-1$ 上， $g(m)$ 是创建的结构元素定义在 $0, 1, \dots, M-1$ 上，且 $N \geq M$ 关于的腐蚀和膨胀运算定义为[9]：

$$(f \ominus g)(n) = \min[f(n+m) - g(m)] \quad (11)$$

$$(f \oplus g)(n) = \max[f(n-m) + g(m)] \quad (12)$$

$f(n)$ 关于 $g(m)$ 的开运算和闭运算分别为：

$$(f \circ g)(n) = (f \ominus g \oplus g)(n) \quad (13)$$

$$(f \cdot g)(n) = (f \oplus g \ominus g)(n) \quad (14)$$

形态滤波的基本算子中，对于用于冲击信号的故障诊断来说，腐蚀运算作用是削减正向冲击；膨胀算子作用是削减负向冲击；开算子作用是维持负向冲击，减小正向冲击；闭算子作用是减小负向冲击，维持正向冲击。

3.1. 优化形态学差值滤波

常用的结构元素有直线形、三角形和半圆形。直线形结构元素可以较好地保留信号形状特征，三角形结构元素可以抑制信号中随机噪声，半圆形相较于三角形既能抑制随机噪声也可抑制随机脉冲噪声。当只用了单一结构元素的情况下，会存在结果偏移的情况，且不能保留所有信号的特征。本方法提供了一个新的思路，在既要保持原有信号的特征，又要去除背景噪声突出冲击特征，结合使用两种不同形状的结构元素直线形及半圆形 ($g_1 \cdot g_2$)，优化传统形态学滤波方式，来实现正负脉冲的有效提取。

在传统形态学滤波中，简单来说开运算削弱正冲击、闭运算削弱负冲击，可以组合使用来达到突出噪声的目的，即差值滤波：

$$\text{diff}(f(n)) = (f \cdot g)(n) - (f \circ g)(n) \quad (15)$$

当使用两种结构元素时，同样可以构造差值滤波，首先定义两个结构元素时的闭运算和开运算：

$$f_{\text{close}}(n) = (f \oplus g_1 \ominus g_1 \oplus g_2 \ominus g_2)(n) \quad (16)$$

$$f_{\text{open}}(n) = (f \ominus g_1 \oplus g_1 \ominus g_2 \oplus g_2)(n) \quad (17)$$

根据上述优化后的形态学开运算和闭运算，为了突出信号中的周期冲击成分，可得到优化后的差值滤波方法。其公式如下：

$$f_{\text{NEW}}(n) = f_{\text{close}}(n) - f_{\text{open}}(n) \quad (18)$$

3.2. 形态学结构元素尺寸选取

结构元素和形态运算方式是影响形态滤波的 2 个最主要因素。结构元素的特性与形状、高度和长度有关，结构元素的形状对滤波效果的影响较小[10]。最常用的结构元素是直线型的，因为其简单的结构和高效的计算能力，这种直线型结构元素的高度为零。选择结构元素的最佳长度是关键。若长度过长，可能会将冲击信号误认为噪声而被滤除；若长度过短，则可能残留大量噪声，导致信号解调困难。对于半圆形结构元素来说，其半径的取值是影响其滤波效果的主要因素。

常用的形态学结构元素尺度的范围为：

1. 直线结构元素：长度 5~15；
2. 半圆形结构元素：半径 3~10；

筛选指标：TEK (Teager Energy Kurtosis)。

TEK 指标：TEK 指标是在峭度和 Teager 能量算子的基础上演变而来，对于识别信号的冲击成分较为灵敏。TEK 指标结合峭度和 Teager 能量算子的优缺点，对信号的冲击成分很敏感，同时考虑了对尖峰的描述及信号瞬时能量的变化可以更加精确、有效地反映出故障信号的冲击特征，引入 TEK 作为筛选结构元素最佳长度的评判指标[11]。TEK 计算公式为：

$$TEK = \frac{(N-1) \sum_{t=1}^N (\varphi_x(t) - \bar{\varphi}_x)^4}{\left(\sum_{t=1}^N (\varphi_x(t) - \bar{\varphi}_x)^2 \right)^2} \quad (19)$$

式中：N 为信号长度， $\varphi_x(t)$ 为信号在第 t 个点处的 Teager 能量， $\bar{\varphi}_x$ 为 $\varphi_x(t)$ 的平均值。

对于一维的时域信号 $x(t)$ ，某一点 n 处的 Teager 能量的计算公式为：

$$\varphi_x(t) = \varphi[x(t)] = [x(t)]^2 - x(t+1)x(t-1) \quad (20)$$

通过引入指标，解决传统结构元素尺寸无法选取的问题，同时对于电机轴承故障诊断来说，更好地识别和保留了时域信号的冲击部分，对于后续频谱的呈现具有较好的影响。

4. 诊断流程及实验步骤

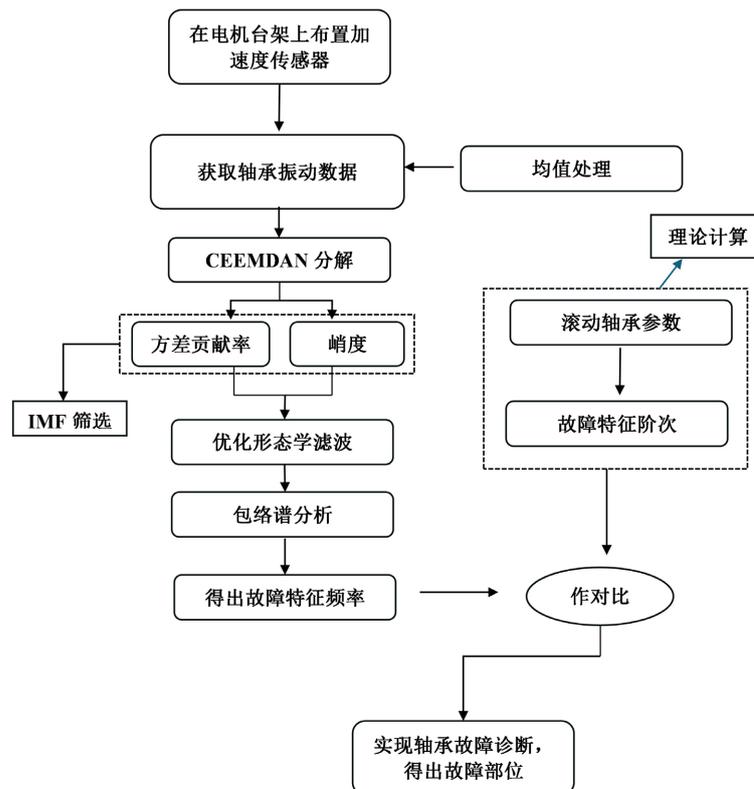


Figure 1. Process of CEEMDAN + improved morphological method
图 1. CEEMDAN + 改进形态学方法流程

详细步骤如下：

步骤 1 在电机上布置加速度传感器，采集电机在运转过程中的振动信号。

步骤 2 使用 CEEMDAN 算法对测得的振动信号进一步模态处理，通过峭度和方差贡献率两个指标来筛选所需的 IMF 分量，再将信号重构，达到抑制背景噪声对实验数据后续分析的影响和突出信号特征的目的。

步骤 3 使用优化后的形态学差值滤波算法对步骤 2 处理过的数据进一步滤波，达到突出信号特征和捕捉脉冲信号的目的，完成对时域信号的处理。

步骤 4 对算法处理过后的信号进行包络谱分析，并与理论特征频率对比，实现轴承的故障特征提取，进而可以得到轴承发生故障的具体部位。

5. 实验及结果分析

5.1. 轴承故障频率计算

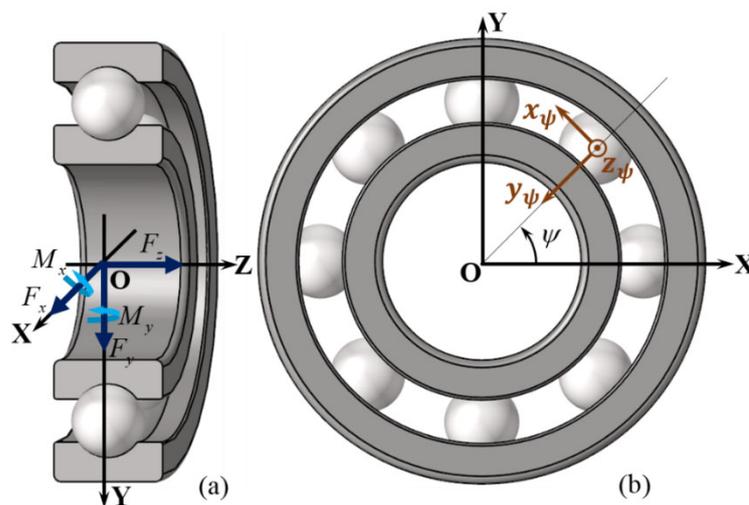


Figure 2. Structural diagram of rolling bearing

图 2. 滚动轴承结构图

在大多数应用场合中，滚动轴承的外圈通常固定在轴承座孔或其他旋转机械设备的壳体上，起到支撑的作用，并在设备运行时保持静止。相比之下，内圈一般通过过盈配合的方式与旋转机械设备的传动轴连接，并随传动轴一起旋转。滚动体作为轴承的核心部件，主要作用是将内圈和外圈之间的相对运动产生的滑动摩擦转变为滚动摩擦。而保持架的作用则是保护滚动体，减少损坏或防止其损坏。

由图 2 滚动轴承的结构图可知，一般轴承发生故障都是会出现在这四个位置，因而不同的部位发生故障就会存在不同的故障特征频率，特征频率的计算公式为：

滚动轴承中，滚动体沿着内圈和外圈滚动，并与它们发生周期性的接触。当滚动轴承部位发生故障时，这种周期性的接触会产生特征频率。基本参数：

f_r ：轴承转速(单位：Hz)；

n ：滚动体的个数；

d ：滚动体的直径；

D ：节圆的直径；

β ：接触角；

假设内圈故障每当滚动体通过内圈缺陷一次，外圈故障每当滚动体通过外圈缺陷一次。

每秒钟内圈与每个滚动体接触的次数： $\frac{f_r}{60} \times n$ ；

每秒钟外圈与每个滚动体接触的次数： $\frac{f_r}{60} \times n$ 。

考虑到接触角和滚动体的直径，修正公式得到：

$$\text{BPFI} = \frac{n}{2} \left(1 + \frac{d}{D} \cos \beta \right) f_r \quad (21)$$

$$\text{BPFO} = \frac{n}{2} \left(1 - \frac{d}{D} \cos \beta \right) f_r \quad (22)$$

滚动体故障频率推导

滚动体自旋的频率可以通过考虑滚动体相对于内圈和外圈的运动速度来计算：

$$\text{BSF} = \frac{D}{d} \left(1 - \left(\frac{d}{D} \cos \beta \right)^2 \right) f_r \quad (23)$$

保持架故障频率推导

保持架每转动一次的频率与滚动体数量和接触角有关：

$$\text{FTF} = \frac{1}{2} \left(1 - \frac{d}{D} \cos \beta \right) f_r \quad (24)$$

这些公式可以用于分析轴承时域信号，从而有效地进行故障诊断。

5.2. 实例验证

为了进一步验证本文所描述方法的鲁棒性，我们选用了西储大学(Case Western Reserve University, CWRU)的轴承数据集进行实例验证。CWRU 轴承数据集是机械故障诊断领域中广泛使用的标准数据集，具有丰富的故障类型和运行状态数据，可用于验证故障诊断方法的有效性。CWRU 轴承数据集包含了不同故障类型(如内圈故障、外圈故障和滚动体故障)和不同故障严重程度(如 0.007、0.014 和 0.021 英寸)的轴承振动信号。这些数据通过安装在不同位置(如驱动端、风扇端)的加速度传感器采集，并在各种负载条件(如 0、1、2 和 3 马力)下记录。

5.2.1. CWRU 轴承实验台介绍

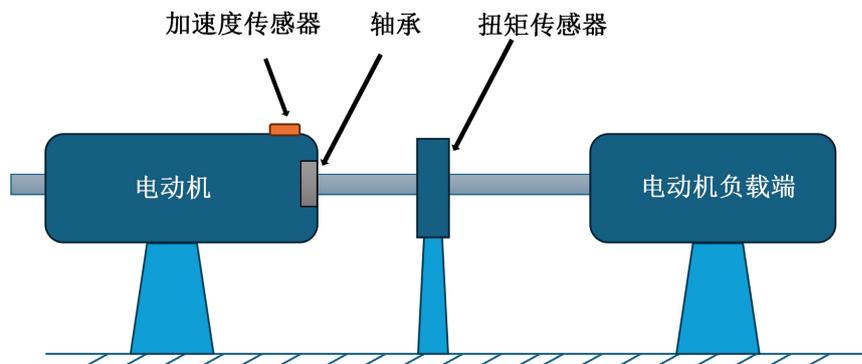


Figure 3. CWRU bearing test stand

图 3. CWRU 轴承实验台

该实验台如图 3 所示, 主要包括一个 2 马力(1.5 KW)的电动机, 一个扭矩传感器, 一个功率测试计。待检测的轴承支撑着电动机的转轴, 电机驱动端轴承型号为 SKF6205, 轴承用电火花加工单点损伤, 损伤直径分为(0.007 英寸 = 7 mils = 0.1778 mm, 0.014 英寸 = 14 mils = 0.3556 mm, 0.021 英寸 = 21 mils = 0.5334 mm)其中, 轴承外圈的损伤点在时钟: 3 点钟、6 点钟、12 点钟 3 个不同位置进行设置。电动机驱动端的轴承座上方放置一个加速度传感器用来采集故障轴承的振动加速度信号。振动信号由 16 通道数据记录仪采集得到, 采样频率为 12 kHz。

轴承参数及故障特征频率阶次:

Table 1. SKF6205 bearing parameters table

表 1. SKF6205 轴承参数表

内圈直径/mm	外圈直径/mm	滚动体个数	滚动体直径 d /mm	节经 D /mm
25	52	9	8.18	44.2

根据表 1 轴承的参数再结合 5.1 部分理论计算公式可得出此轴承的故障特征阶次(相对应转频的倍数), 汇总至表 2:

Table 2. SKF6205 bearing fault characteristic frequency order

表 2. SKF6205 轴承故障特征频率阶次

内圈	外圈	滚动体	保持架
5.42	3.58	0.398	4.713

5.2.2. 内圈故障轴承

选择内圈故障数据的具体的参数如表 3 所示:

Table 3. SKF6205 bearing inner ring fault data

表 3. SKF6205 轴承内圈故障数据

数据集名称	故障部位	故障直径(英尺)	轴承转速(rpm)	数据采样率(Hz)	数据片段点数
105.mat	内圈	0.007	1797	12000	8192

根据表 2 和表 3 可知, 当轴承内圈发生故障时其故障特征频率为 162.329 Hz。

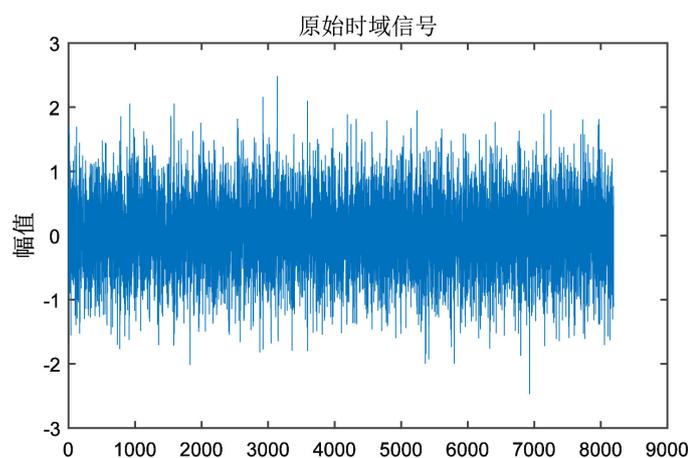


Figure 4. Original vibration signal of inner ring fault

图 4. 内圈故障原始振动信号

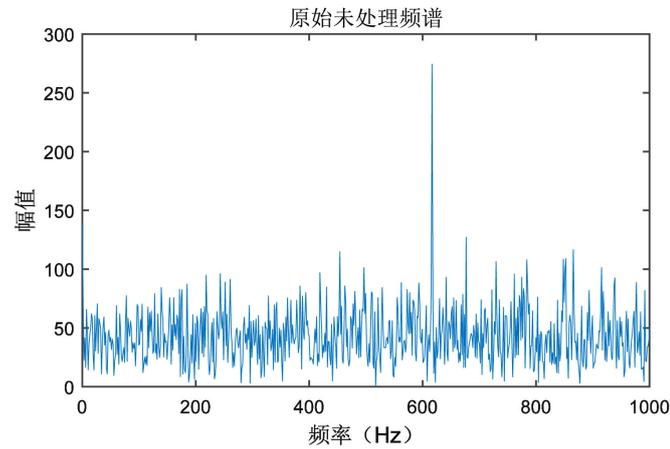


Figure 5. Spectrum diagram of the original vibration signal of the inner ring fault
图 5. 内圈故障原始振动信号频谱图

内圈受轴承安装位置的影响，信号中间传导部件较多，因而信号的传递时间较长，故其故障信号在采集过程中易受到噪声的影响。图 4 为内圈故障的时域波形图，波形中的故障特征被噪声和杂乱波干扰，无法直接进行时域信号判断；图 5 为内圈故障的频谱图，但由于大量噪声的干扰，频率主要在中、高频段较为突出，然而故障频率处于低频段，因幅值过低且周边频率谱线相近，故障特征频率并不明显，基本无法判别具体是哪类故障。

通过 CEEMDAN 对信号进行分解，分解结果如图 6 所示，分解后各个 IMF 分量的峭度和方差贡献率如图 7 所示，依据图 6 和图 7 的结果，选择分量进行信号重构。对重构信号进行优化形态学滤波，最后进行包络谱分析。

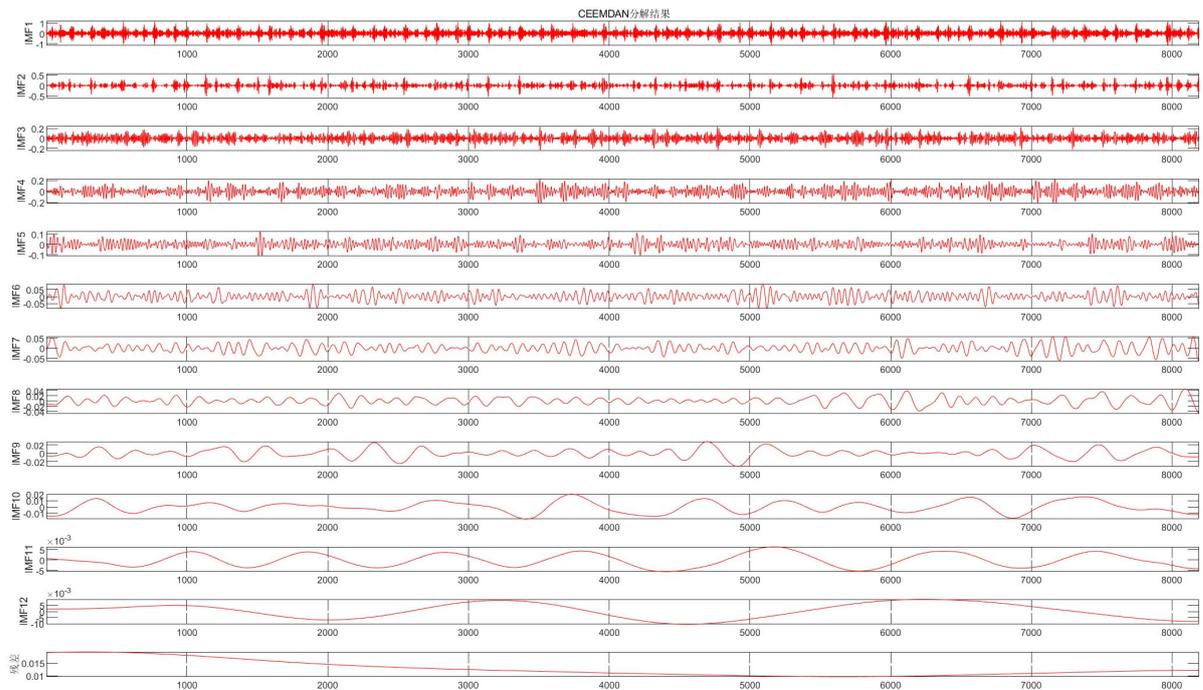


Figure 6. Picture of the inner circle signal after CEEMDAN decomposition
图 6. 内圈信号 CEEMDAN 分解图

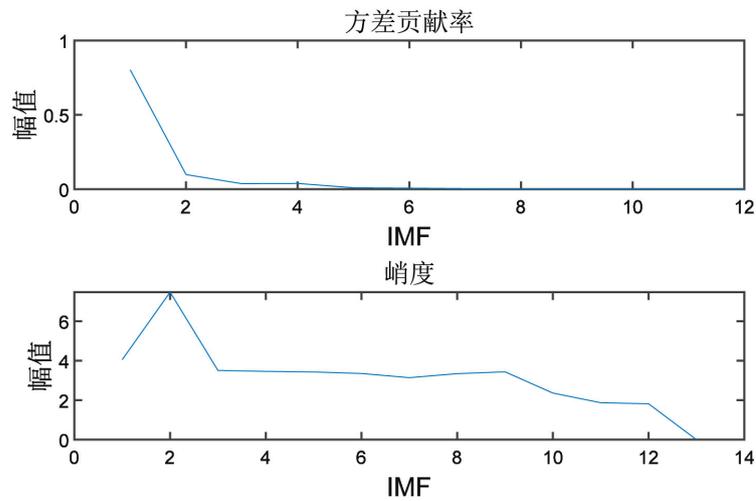


Figure 7. Picture of kurtosis and variance contribution rate of inner circle decomposed signal
图 7. 内圈分解信号的峭度及方差贡献率图

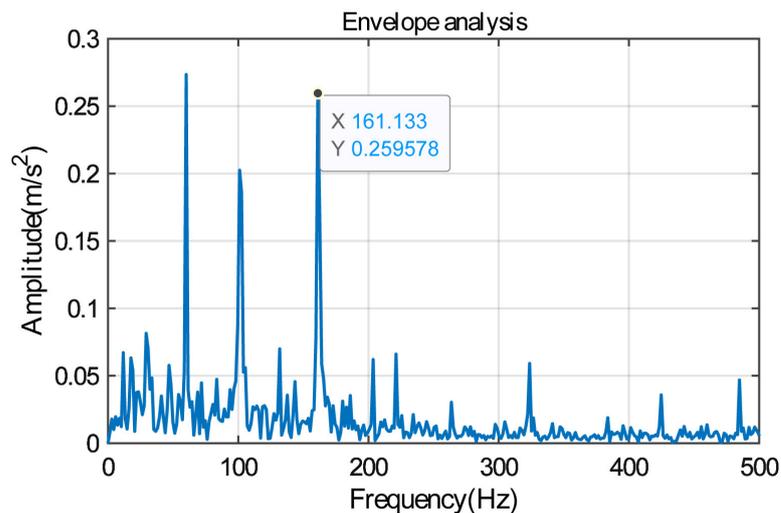


Figure 8. Spectrum diagram of inner ring fault vibration signal after processing
图 8. 内圈故障振动信号处理后频谱图

通过观察图 8 包络谱可以得到频率峰值为 161.133 Hz，对应理论计算故障为 162.329 Hz，对比可得轴承发生故障的部位为内圈。

5.2.3. 外圈故障轴承

选择外圈故障数据的具体的参数如表 4 所示：

Table 4. SKF6205 bearing outer ring fault data

表 4. SKF6205 轴承外圈故障数据

数据集名称	故障部位	故障直径(英尺)	轴承转速(rpm)	数据采样率(Hz)	数据片段点数
130.mat	外圈	0.007	1796	12000	8192

根据表 2 和表 4 可知，当轴承内圈发生故障时其故障特征频率为 107.16 Hz。

轴承外圈比内圈更靠近电机机壳上的传感器，且其振动信号在传导过程中不需要穿过滚动体，因此

采集到的外圈故障信号中噪声含量更低。图 9 显示了外圈故障的时域波形图，与内圈故障信号相比，外圈故障的波形中故障特征更加明显，但仍存在杂波和噪声的干扰，无法确定具体的故障情况。图 10 为外圈故障的频谱图，与内圈故障情况相似，由于噪声的影响，频率主要集中在高频段，而低频段的频率幅值很小，故障特征频率难以识别，依然法准确判断故障类型。通过以上分析，可以看出尽管外圈故障信号中噪声较少，但由于噪声对频谱的影响，仍然难以清晰地识别故障特征，从而难以准确地判断轴承故障类型。

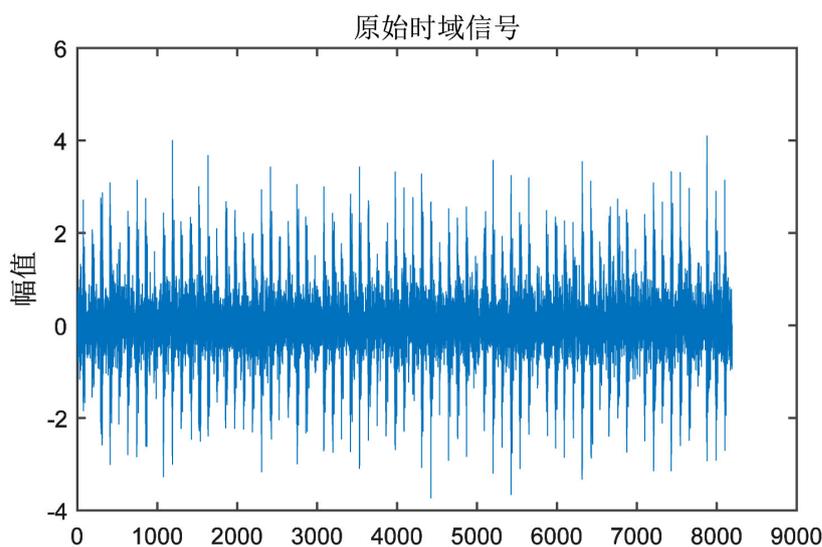


Figure 9. Original vibration signal of outer ring fault

图 9. 外圈故障原始振动信号

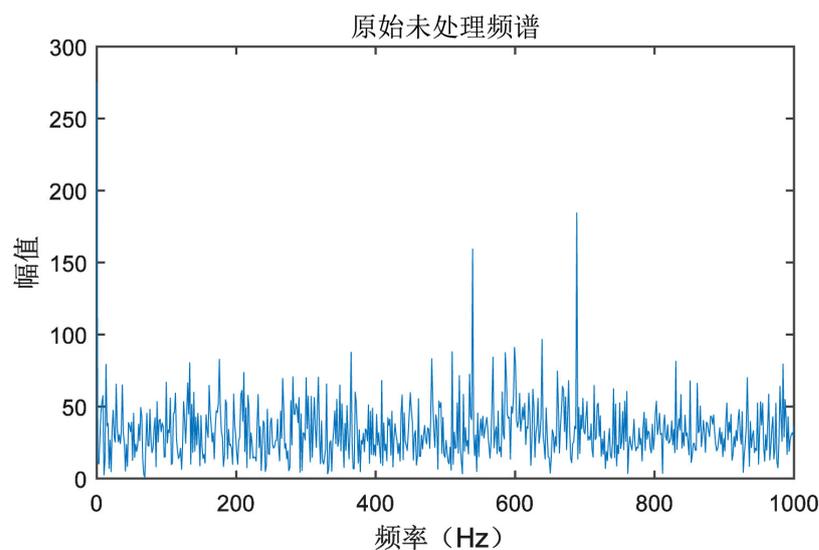


Figure 10. Spectrum diagram of the original vibration signal of the outer ring fault

图 10. 外圈故障原始振动信号频谱图

通过 CEEMDAN 对信号进行分解，分解结果如图 11 所示，分解后各个 IMF 分量的峭度和方差贡献率如图 12 所示，依据图 11 和图 12 的结果，选择分量进行信号重构。对重构信号进行优化形态学滤波，最后进行包络谱分析。

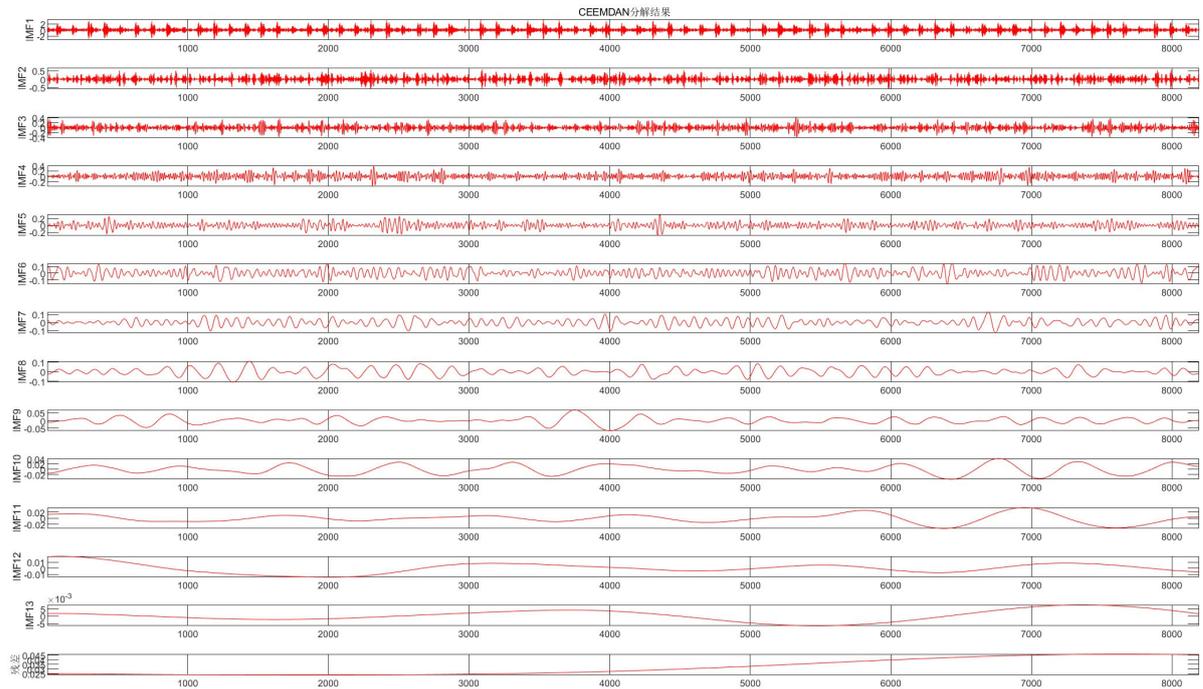


Figure 11. Picture of the outer circle signal after CEEMDAN decomposition

图 11. 外圈信号 CEEMDAN 分解图

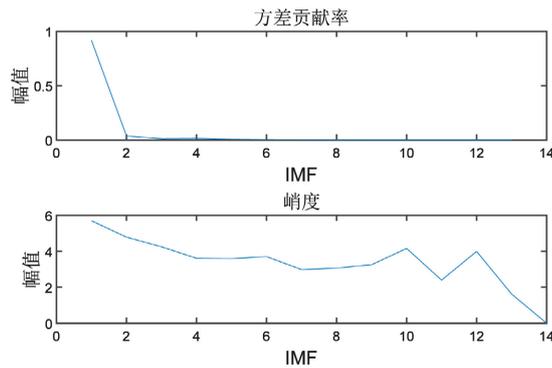


Figure 12. Picture of kurtosis and variance contribution rate of outer circle decomposed signal

图 12. 外圈分解信号的峭度及方差贡献率图

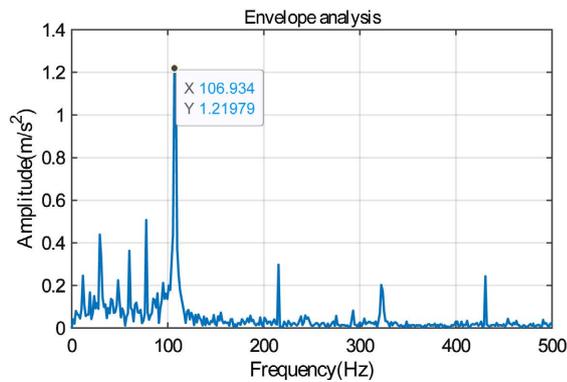


Figure 13. Frequency spectrum of outer ring fault vibration signal after processing

图 13. 外圈故障振动信号处理后频谱图

通过观察图 13 包络谱可以得到频率峰值为 106.934 Hz，对应理论计算故障为 107.16 Hz，对比可得轴承发生故障的部位为外圈。

6. 结论

本文研究了一种结合 CEEMDAN 与优化形态学差值滤波的轴承故障诊断方法，以应对噪声影响导致的诊断困难。通过西储大学实例数据分析得出以下结论：

1. 增强滤波效果：将 CEEMDAN 的自适应分解能力与优化形态差值滤波在有效滤噪和突出冲击特征方面的优势结合起来，显著提升了滤波效果，也间接地增强了冲击特征。
2. 削弱噪声：在应对强背景噪声的情况下，在保留故障特征信息的同时，仍具有滤除噪声的作用。
3. 有效的故障诊断：实例数据分析表明，所提出的方法能够有效地提取故障冲击特征信息，实现滚动轴承精准的故障诊断。

通过以上结论，可以看出本研究提出的方法在轴承故障诊断中具有重要的应用价值和显著的效果。

参考文献

- [1] 黄迅迪, 庞雄文. 基于深度学习的智能设备故障诊断研究综述[J]. 计算机科学, 2023, 50(5): 93-102.
- [2] 仇莹, 张涛, 葛平淑, 等. 电机轴承智能故障诊断综述[J]. 机电工程技术, 2024, 53(3): 1-6.
- [3] Huang, N.E., Shen, Z., Long, S.R., *et al.* (1998) The Empirical Mode Decomposition and the Hilbert Spectrum for Non-linear and Non-Stationary Time Series Analysis. *Proceedings of the Royal Society of London. Series A: Mathematical, Physical and Engineering Sciences*, **454**, 903-995.
- [4] 吴宏亮, 尚坤. 基于 EMD 分解及 Hilbert 包络的电机轴承故障诊断[J]. 电子技术, 2021, 50(7): 112-115.
- [5] 刘佳昕, 周风波. EMD 算法的改进及在信号去噪中的应用[J]. 电子制作, 2024, 32(4): 73-75+27.
- [6] 张又才, 朱伏平. 基于全矢 CEEMDAN 滚动轴承故障诊断研究[J]. 机械设计, 2023, 40(S2): 68-72.
- [7] 李非, 郝如江. 基于 EMD 模态相关和形态学降噪的齿轮故障诊断研究[J]. 石家庄铁道大学学报(自然科学版), 2018, 31(3): 56-62+74.
- [8] 殷红, 陈强, 彭珍瑞. 传感器优化布置的齿轮箱轴承故障特征提取[J]. 噪声与振动控制, 2020, 40(4): 67-72+154.
- [9] Raj, A.S. and Murali, N. (2012) Early Classification of Bearing Faults Using Morphological Operators and Fuzzy Inference. *IEEE Transactions on Industrial Electronics*, **60**, 567-574.
- [10] 章立军, 杨德斌, 徐金梧, 等. 基于数学形态滤波的齿轮故障特征提取方法[J]. 机械工程学报, 2007(2): 71-75.
- [11] 余建波, 李传锋, 吕靖香. 轴承故障信号的平均组合差值形态滤波分析[J]. 浙江大学学报(工学版), 2018, 52(10): 1845-1853+1910.