

改进的经验模态分解方法和解析能量算子在电机轴承故障诊断中的应用

姚丹, 孙敏, 李睿敏, 付锐, 南江萍

(西安交通工程学院 机械与电气工程学院, 西安 710300)

摘要: 针对电机轴承故障信号能量微弱导致极易被噪声干扰所淹没的不足, 进行了电机轴承故障特征提取研究; 提出了一种改进的经验模态分解方法, 包括谱峭度指标和一种新颖的解析能量算子相结合的电机轴承故障诊断方法; 经实际测试与应用实现了对电机轴承故障信号中背景噪声干扰的去除, 从而满足了电机轴承微弱故障特征提取的应用; 通过与常用的电机轴承故障诊断方法对比验证了所提方法的有效性和优越性, 为电机轴承故障诊断提供一个新思路。

关键词: 电机轴承; 故障诊断; 改进的经验模态分解方法; 包络谱峭度; 解析能量算子

Application of Improved Empirical Mode Decomposition and Analytic Energy Operator in Motor Bearing Fault Detection

YAO Dan, SUN Min, LI Ruimin, FU Rui, NAN Jiangping

(School of Mechanical and Electrical Engineering, Xi'an Traffic Engineering Institute, Xi'an 710300, China)

Abstract: Aimed at the shortage of motor bearing fault weak signal energy, it is easily overshadowed by noise interferences, motor bearing fault characteristic extraction methods are carried out to be investigated. This paper proposes an improved empirical mode decomposition approach for diagnosing motor bearing faults, including the envelope spectrum kurtosis indicator and the improved empirical mode decomposition technique combined with a newly developed analytical energy operator. The background noise interference is removed from motor bearing fault signals through practical testing and application, thereby ensuring the successful extraction of weak fault features from the motor bearing. The proposed method has the effectiveness and superiority compared with conventional motor bearing fault diagnosis methods, which provides a new idea for motor bearing fault diagnosis.

Keywords: motor bearing; fault diagnosis; improved empirical mode decomposition method; envelope spectrum kurtosis; analytic energy operator

0 引言

随着旋转机械自动化水平的不断提高, 为了提高旋转机械的可靠性, 减少不可预见的损坏和故障而可能造成的损失, 故障诊断越来越受到人们的重视。轴承是各种旋转机械中最重要的部件之一^[1]。电机作为旋转机械中最为常见的一种基础性部件, 具有传动力矩大、结构简单、维修方便等诸多优点。此外, 电动机还具备易于控制的特点。通过调整输入电流或者改变工作方式等手段, 可以实现对电动机输出功率和转速的精确控制。这使得各类机械设备在使用过程中更加灵活多样化, 并且满足了适应不同工况下的需求。正是由于以上优点, 电动机已经广泛应用于各类机械设备中, 并成为主要的动力装置之一^[2-3]。

电机轴承的制造工艺非常复杂, 需要高精度的装配。此外, 这些零部件通常在高速、重负荷、疲劳、腐蚀和高

温等恶劣环境下连续运行。因此, 不可避免地会发生各种程度的故障, 成为导致机械设备无法正常运转的常见原因之一。同时也会导致生产和收入损失, 甚至发生人身伤亡。作为电机中重要的传动件, 轴承在传递过程中发挥着关键作用。然而, 由于电机较为恶劣的工作环境, 电机轴承很容易受到损伤。据报道, 电机的故障中的 45~55% 来自轴承故障^[4]。频繁维修轴承故障虽然可以减少事故的发生, 但会增加设备运行成本, 还会严重影响设备正常运转。因此, 研究快速有效的电机故障检测与诊断方法对于预防突发性故障、降低设备维修费用、确保机械设备安全运行以及避免经济损失和人员伤亡具有极其重要的现实意义。

近年来, 各种故障诊断方法被有效地用于电机轴承故障的早期检测, 以保持电机及其相关机械设备的有效运行, 避免异常产生, 减少生产损失。由于机械振动信号包含了丰富的动力学特征信息, 因此基于振动的信号处理方法是

收稿日期: 2024-01-18; 修回日期: 2024-02-23。

基金项目: 西安交通工程学院 2022 年度中青年基金项目(2022KY-04); 西安交通工程学院 2024 年度科学研究重点项目(2024KY-07)。

作者简介: 姚丹(1988-), 女, 硕士, 讲师。

引用格式: 姚丹, 孙敏, 李睿敏, 等. 改进的经验模态分解方法和解析能量算子在电机轴承故障诊断中的应用[J]. 计算机测量与控制, 2024, 32(8): 72-77, 85.

诊断电机轴承故障的主要工具之一^[5]。但是, 实际测量的电机轴承振动信号通常是非平稳的, 即非平稳性更为普遍和一般化, 而非平稳性只在特定条件下成立。事实上, 由于机械振动的瞬态过程信号往往包含比稳态振动信号更多样的信息, 可以反映系统特性更全面, 因此在实际工程中对机械设备的非稳定状态进行监测通常比稳态过程更具现实意义^[6]。此外, 由于电机的工作环境背景较为恶劣, 因此提取出来的振动信号包含了大量的背景噪声和其他振动干扰。

对于这种非平稳且包含不同干扰的振动信号, 经验模态分解技术 (EMD, empirical mode decomposition) 是一种非常合适的信号处理方法。因为 EMD 技术是一种将复杂信号分解为一组本征模函数并进行时频分析的工具, 专门用于处理非平稳信号^[6]。通过对信号进行分解, 可以将环境噪声和干扰分量作为特定的干扰分量从原始信号中分离出来。因此, EMD 技术在电机故障诊断领域得到了广泛的应用。例如, 文献 [8] 针对无刷直流电机噪声溯源问题, 提出了一种基于经验模态分解谱峭度重构峰值定位的电机噪声追踪方法。文献 [9] 提出了一种利用 EMD 和希尔伯特包络谱分解技术进行旋转电机故障特征提取的方法。文献 [10] 将 EMD 方法应用于永磁同步电机定子短路故障检测的可能性, 提出了一种基于 EMD 的瞬时频率在线统计分析的方法, 并通过实时半实物仿真和实验结果进行了验证。文献 [11] 针对异步电机转子断条故障原始信号中包含的故障特征成分能量微弱, 并且提取这些特征成分需要耗费大量时间和精力, 提出了一种基于 EMD 的转子断条故障诊断方法。文献 [12] 提出了一种基于 EMD 方法和小波包量化相结合的码头集装箱起重机电机非平稳信号分析方法。

虽然 EMD 方法在电机诊断中已被证明是可行有效的, 但 EMD 仍有一个明显的不足, 即模态混叠问题。这是指 EMD 方法分解出来的一个单一的本征模函数 (IMF, intrinsic mode function) 可能由不同尺度的信号组成, 或者一个相似尺度的信号存在于不同的 IMF 分量中。为了解决这一问题, 本文引入了一种改进的 EMD 方法, 称之为鲁棒经验模态分解方法 (RMED, robust empirical mode decomposition)。该种 REMD 方法可以缓解 EMD 分解信号时的模态混叠问题, 提高信号解调的解调性能。此外, REMD 还可以适应输入信号, 并通过跟踪筛选过程来确定筛选过程的最优迭代次数^[13]。

在 REMD 处理完原始的电机轴承故障信号后, 需要从处理后的 IMF 中进一步提取出故障特征。当轴承的组成部件, 如内圈、外圈和滚珠, 发生缺陷并且滚珠通过该缺陷时, 就会产生携带轴承故障特征的周期性脉冲。当能量被内部阻尼耗尽后, 这些脉冲以一种近似于指数包络线的方式衰减。这样的信号被认为是调制信号, 其中调制信号的基频 (包络) 是有缺陷轴承的故障特征^[14]。因此, 包络分析 (解调技术) 是非常适合用来分析该种调幅调频信号。

而最为常用的包络分析工具之一就是能量算子技术。在这些能量算子技术中, 最具代表性的工作是 Kaiser 设计的 Teager 能量算子 (TEO, Teager energy operator)^[15]。TEO 是一种非线性微分算子, 可以有效地估计任意调制信号的时变包络。此外, 与其他包络分析工具相比, 它还具有以下优点: 1) 由于 TEO 可以提供小的时间窗口, 使其非常适合调制信号的局部分析, 因此它提供了优越的定位特性; 2) TEO 只处理 3 个相邻的信号样本, 使其实现非常简单, 因此使用的计算机资源少, 计算量少^[16-17]。然而, TEO 极易受到背景噪声和其他干扰的影响, 导致降低它的解调性能^[18-19]。为了克服这一不足, 本文引入了一种新颖的能量算子形式, 即解析能量算子 (AEO, analytic energy operator)。该 AEO 方法利用其希尔伯特变换形式以及它的导数形式构造而成, 可以提高信号的信噪比, 因此该能量算子也可以有效地处理复杂的背景噪声干扰。

因此, 本文提出了一种 REMD 与 AEO 相结合的电机轴承故障方法。该方法首先利用 REMD 分解原始故障信号从而将背景噪声和振动干扰分离出去。然后, 利用一种名为包络谱峭度指标选择具有显著轴承故障特征的 IMF。最后, 采用 AEO 技术从选中的 IMF 中识别轴承故障特征。

1 REMD

EMD 方法是一种非常经典的模态分解技术, 很多文献已经详细阐述了它的基本原理, 这里不再赘述, 主要进行改进部分的详细解释。事实上, 相较于原始 EMD 方法, REMD 方法最显著的改进部分就是在筛分停止准则上的改进。这种筛分停止准则上的改进可以缓解原始 EMD 分解信号时的模态混叠问题, 从而提高信号解调的解调性能。

EMD 中的筛分停止准则定义为,

$$\lim_{k \rightarrow \infty} g_k(n) = 0 \quad (1)$$

式中, $m(n)$ 代表一个离散时间信号 $x(n)$ 相对应的均值信号。其中, $g(n) = m(n)$, 即此处采用 $g(n)$ 代表离散均值信号。如果 $m(n)$ 的每个值都小于预定义值, 则停止筛选过程。理想情况下, 该信号每一点的值都应该等于零, 但在实际应用中这种情况是不可能的。因此, 如何使这个信号尽可能接近于零, 何时停止筛选过程是一个值得探讨的问题。因此, 改进的筛分停止准则由两个主要部分组成。一是提出一种可行的信号量化方法。二是提出一种自适应策略, 使筛分过程根据具体的输入信号自动停止。

首先, 针对如何以可行的方式量化信号的问题。为了使该目标信号各点处的值为零, 整体能量值也应为零。使用一个统计指标: 均方根 (RMS, root mean square) 来定义该目标信号的总能量。RMS 定义为均方的平方根, 如式 (2) 所示:

$$\text{RMS}_k = \sqrt{\frac{1}{N_s} \sum_{n=1}^{N_s} [g_k(n)]^2} \quad (2)$$

式中, N_s 代表采样点数。如上所述, RMS 值应该尽可能接近于零。另一方面, 一种可能的情况是, 大多数点的值非

常小,甚至为零,而少数点的值特别高。在这种情况下,RMS 值仍然很小,但不满足公式 (1) 定义的要求,因此需要另一个指标来限制这种情况的发生。峰度被广泛用于捕获一个信号的峰值信号。如果在一个信号中有更多的峰,峰度的值就会更高。因此,该指标可以很好地定义上述情况,较小的峰度值可以避免这种情况。正态分布的峰度等于 3。这里使用超额峰度指标,即峰度值减 3 来评估一个信号的峰性。超额峰度可以定义为:

$$EK_k = \frac{\frac{1}{N_s} \sum_{n=1}^{N_s} [g_k(n) - \bar{g}_k]^4}{\left\{ \frac{1}{N_s} \sum_{n=1}^{N_s} [g_k(n) - \bar{g}_k]^2 \right\}^2} - 3 \quad (3)$$

式中, \bar{g}_k 是 $g_k[n]$ 的平均值。

同样,期望 EK 的值越小越好。通过使用 RMS 和 EK 这两个指标,可以实际地定义目标信号。因此提出一个目标函数 f_k ,如公式 (4) 所示,即 RMS 值与 EK 绝对值之和。

$$f_k = \text{RMS}_k + |EK_k| \quad (4)$$

其次,在如何停止筛选过程方面,提出了一种自适应启发式机制。该机制能够以最优迭代次数自适应停止筛选过程。具体来说,在每个筛选过程中,计算公式 (4) 中定义的 f_k 的值,并将其与前一个筛选过程的值进行比较。筛选直到满足条件 $f_{k-2} < f_{k-1}$ 和 $f_{k-1} < f_k$ 停止筛选。保存并返回第 $(k-2)$ 次迭代的对应结果。否则,当迭代次数达到预定义的阈值时,筛选过程停止,并返回上一次筛选过程的相应结果。因此,通过这种自适应启发式机制可以得到一个局部最优迭代数。

为了体现 REMD 的优越性,这里采用一组复杂信号来进行验证,此外还采用原始的 EMD 方法来进行对比。该复杂信号的数学模型如下式所示:

$$\begin{cases} x(t) = [2 \times (t - 0.5)^2 + 0.2] \times \sin[20\pi t + 0.2\cos(40\pi t)] \\ y(t) = 4(t - 0.5)^2 \\ z(t) = x(t) + y(t) + 1 \end{cases} \quad (5)$$

图 1 显示了两个子信号 $x(t)$ 和 $y(t)$ 及其两个信号复合而成的信号 $z(t)$ 。




图 1 两个子信号及其复合信号

采用两种模态分解技术进行混合信号分解。图 2 显示了解析的结果。从图中可以看出,EMD 和 REMD 分解出的第一个 IMF 的波形与 $x(t)$ 的波形基本相似,EMD 相比 REMD 分解效果相对精确。然而,在第二个信号 $y(t)$ 的分解结果可以看到,EMD 分解出的 IMF2 与信号 $y(t)$ 的误差非常大。而 REMD 分解的结果基本与信号 $y(t)$ 吻合,只在端点处有少许误差。因此,从整体分解结果上可以看到,相较于原始的 EMD,改进的 REMD 在分解精度上有了显著提升,说明了 REMD 的优越性。




图 2 EMD 和 REMD 的分解结果

2 AEO 能量算子

解析信号的概念首先由 Gabor 提出,并且通过解析信号的形式定义了瞬时频率和相位的概念。假设有一组调制信号如下式:

$$x(t) = A(t)\cos\phi(t) \quad (6)$$

式中, $A(t)$ 代表瞬时幅值, $\phi(t)$ 代表初始相位。

该信号的解析形式可以表示如下:

$$X(t) = |X(t)| [\cos\phi(t) + j\sin\phi(t)] = A(t)e^{j\phi(t)} \quad (7)$$

它的瞬时幅值可以表示为,

$$A(t) = \pm |X(t)| = \pm \sqrt{x^2(t) + x^2(t)} \quad (8)$$

$$\hat{x}(t) = H[x(t)] = \frac{1}{\pi t} * x(t) = \frac{1}{\pi} \int_{-\infty}^{+\infty} \frac{x(\tau)}{t-\tau} d\tau \quad (9)$$

式中, $H(x(t))$ 表示对信号 $x(t)$ 进行希尔伯特变换。

它的瞬时相位表示式为:

$$\phi(t) = \arctan \frac{\hat{x}(t)}{x(t)} \quad (10)$$

又因为它的瞬时频率为瞬时相位的一阶导数^[20],根据求导法则得到:

$$\omega(t) = \dot{\phi}(t) = \frac{x(t)\ddot{x}(t) - \dot{x}(t)\dot{x}(t)}{A^2(t)} \quad (11)$$

将上式变换得到:

$$x(t)\ddot{x}(t) - \dot{x}(t)\dot{x}(t) = A^2(t)\omega(t) \quad (12)$$

通过上式可以发现,式子当中也包含了幅值解调和频率解调,可以看到这种形式与 TEO 类似,因此可以将其看作为一种能量算子,定义如下,

$$\Theta[x(t)] = x(t)\ddot{x}(t) - \dot{x}(t)\dot{x}(t) \quad (13)$$

其离散形式可以写成:

$$\Theta[x(n)] = x(n)h[\dot{x}(n)] - \dot{x}(n)h[x(n)] \quad (14)$$

式中, $h(n) = H[x(n)]$ 代表离散希尔伯特变换。

为了更好地突出 AEO 技术在抗噪声性能方面的优势, 这里与经典的 TEO 算法进行对比。图 3 显示了两种方法在不同输入信噪比 ($-10 \sim -1$ dB) 下的输出信噪比。可以看到, 在不同的信噪比下, 经过 AEO 变换的输出信噪比都要高于 TEO 的, 因此说明 AEO 的抗噪性能要明显优于 TEO 的。




图 3 TEO 和 AEO 的输出信噪比对比结果

3 实验验证

为了验证本文所提方法的工程实用性, 本小节采用一组真实电机轴承故障数据进行验证。此外, 还采用了基于原始的 EMD 方法和其他先进的电机轴承诊断方法进行对比, 以凸显所提方法的优越性。在实验验证中, 采用由西安交通大学提供的公开故障轴承数据集^[21]。轴承实验台及其主要组成部分如图 4 所示。

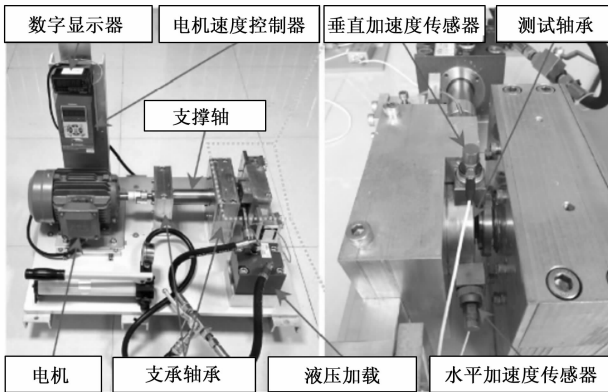


图 4 电机轴承故障模拟实验平台

所测轴承为 LDK UER204 型, 详细参数见表 1。用于验证所提出方法的故障信号在初始阶段从被测轴承的内滚道记录。运行工况 (转速和负载) 设置为 2 250 rpm (37.5 Hz) 和 11 kN。采样频率设置为 25.6 kHz。实验总共使用了 25 600 个数据点, 相当于 1 s 的持续时间。根据表 1 中的几何参数, 旋转频率 $f = 37.5$ Hz, 计算出轴承内圈故障特征频率 $BPFI = 184.5$ Hz。需要注意的是, 由于安装和制造误差, 理论故障频率与实际故障频率可能会有轻微的差异。

表 1 轴承的几何尺寸

滚珠直径 /mm	节径/mm	滚珠数量/个	接触角/(°)
7.92	34.55	8	0

图 5 (a) 显示了从内圈故障信号波形。在初始阶段, 故障诱发的周期脉冲分量几乎被环境噪声所掩盖。图 5 (b) 为故障信号对应的包络谱。可以看到, 故障特征频率 $BPFI = 184.5$ Hz 在包络频谱中无法进行识别。因此, 一般的包络分析不能直接检测轴承故障特征频率, 这是由于循环脉冲分量在故障早期阶段能量非常低, 而包络分析对强噪声的敏感性高, 导致了包络分析无法直接检测到微弱的轴承故障特征频率。




图 5 内圈故障信号波形图和包络谱

现使用 REMD 对该内圈故障信号进行分解处理, 从而得到不同的 IMFs, 得到的 IMFs 如图 6 所示。注意: 由于后续的 IMF 包含的故障信息已经很少, 因此这里选择前 5 个 IMF 进行分析。




图 6 REMD 分解后的 IMFs

接下来, 需要从分解后的 IMFs 选择一个合适的 IMF 进行进一步的分析。从图 6 中不同的 IMFs 可以看到, IMF2 的故障脉冲最为明显。为了确定这一推断, 这里采用一种名为包络谱峭度 (ESK, envelope spectrum kurtosis) 的指标来进行量化选择合适的 IMF。ESK 可以测量信号的周期平稳性^[22], 它的表达式为:

$$ESK = \frac{\frac{1}{N} \sum_{i=1}^N |SE(x)|^4}{\left[\frac{1}{N} \sum_{i=1}^N |SE(x)|^2 \right]^2} \quad (15)$$

其中: N 为包络谱 (能谱) 的时间段数; SE 是通过包

络解调方法变换的信号的能量谱。表 2 为 5 个分解后的 IMF 的 ESK 值。

表 2 REMD 分解的 IMF 的 ESK 值

序号	ESK 值
IMF1	4.245
IMF2	6.876
IMF3	3.223
IMF4	1.982
IMF5	1.091

从表中可以看到，与预想一样，IMF2 的 ESK 值最高，因此选择 IMF2 进行下一步的故障特征提取。下来，采用 AEO 技术将 IMF2 进行包络解调变换，得到相对应的包络信号，然后做出包络信号的包络谱，如图 7 所示。




图 7 AEO 包络谱

从图 7 可以看到，经过 AEO 技术转换后的 IMF2 的信号包络谱可以明显地展示出内圈故障 BPF1 及其二倍频 2BPF1 和三倍频 3BPF1，说明了本文所提方法可以很好地诊断出电机轴承的早期故障。

为了体现本文所提方法的优越性，选择文献 [6] 中的变分模态分解 (VMD, variation mode decomposition) 和 TEO 技术相结合的方法与本文方法进行对比。VMD+TEO 的诊断方法思路与本文所提方法一样，首先采用 VMD 分解方法将原始故障信号进行分解，达到过滤背景噪声和其他干扰的目的。然后选择合适的 IMF 进行故障特征提取。最后，采用 TEO 技术对合适的 IMF 进行包络解调，最终得到包络信号的包络谱。

图 8 为 VMD 技术分解的 IMF。这里同样选择前 5 个 IMF 进行分析。

与之前一样，采用 ESK 值选择合适的 IMF 进行进一步分析。表 3 列出了 VMD 分解的 IMF 的 ESK 值。

表 3 VMD 分解的 IMF 的 ESK 值

序号	ESK 值
IMF1	2.131
IMF2	3.275
IMF3	4.912
IMF4	3.351
IMF5	2.264




图 8 VMD 分解的 5 个 IMF

通过表 3 的 ESK 值，可以看到 IMF3 的 ESK 值最高，因此选择 IMF3 进行下一步的故障特征提取分析。最后，采用 TEO 方法对 IMF3 进行故障特征提取，得到的 TEO 包络谱如图 9 所示。




图 9 TEO 包络谱

从 TEO 包络谱可以观察到，尽管该方法也能够提取出内圈故障特征频率 BPF1，但与图 7 中的结果相比较，可以发现故障特征频率的倍频不明显，例如，在 TEO 包络谱中无法清晰地区分出二倍频和三倍频。

通过该对比实验可以看出，相较于相同思路的“VMD+TEO”电机轴承故障诊断方法，本文提出的方法具有一定优势。

为了更进一步展现该方法的优越性，对比实验还选择了文献 [15] 中的基于 B 样条插值的改进能量算子方法进行对比。该电机故障诊断方法采用了 B 样条技术与 TEO 技术相结合。利用建立的 B 样条曲线对信号进行插值，以实现滤波效果；然后使用 TEO 对滤波后的信号进行包络解调得到包络信号，最终通过傅里叶变换获取包络信号的 TEO 包络图，以揭示故障特征。

图 10 展示了基于 B 样条插值的 TEO 的包络谱。可以看到，基于 B 样条插值的 TEO 方法相较于“VMD+TEO”方法的提取效果要好，因为该方法可以提取出故障特征频率 BPF1，及其它的二倍频和三倍频。但是同本文所述方法得到的结果相比，故障特征频率及其倍频的幅值都相对

较低, 例如三倍频 (3BPFI) 的能量相对较低。




图 10 基于 B 样条插值的 TEO 的包络谱

为了更好地进行对比, 这里采用一种故障特征系数 (FFC, fault feature coefficient) 指标来定量评价两种方法得到的结果, 该定量评价指标为 $FFC^{[23]}$ 如式 (16) 所示:

$$FFC = \frac{\sum [A(f)]^2}{\sum [A(f)]^2 + \sum [A(f')]^2} \times 100\% \quad (16)$$

式中, $A(f)$ 为故障信息相关分量的幅值, $A(f')$ 为干扰频率相关分量的幅值。指数越大, 说明故障信息成分占比越多。表 4 列出了两种方法得到结果的 FFC 值。

表 4 两种方法的 FFC 值

诊断方法	FFC 值
基于 B 样条插值的 TEO	8.6%
REMD+AEO	11.2%

从表 4 的 FFC 值也可以看到, 本文所提方法得到的诊断结果的 FFC 值要高于基于 B 样条插值的 TEO 方法的 FFC 值。因此, 也从量化角度证实了本文所提方法的优越性。

通过对真实案例实验的结果可以发现, REMD 和 AEO 结合的电机轴承故障诊断方法有着明显的优越性和实用性。REMD 在分解出 IMF 的同时能够除去噪声和振动干扰; AEO 方法可以从分解出的 IMF 中有效地提取出轴承的故障特征频率。相反, 所采用进行对比的“VMD+TEO”诊断方法和基于 B 样条插值的 TEO 诊断方法虽然可以提取出故障特征频率, 但提取效果都稍差于本文所提方法。

4 结束语

本文提出了一种基于改进的鲁棒经验模态分解算法和一种新颖的解析能量算子技术相结合的电机轴承早期故障诊断方法。该方法在强背景噪声的情况下可以有效地提取出电机早期轴承故障特征频率。将该故障诊断方法应用于模拟信号和西安交通大学提供的真实电机轴承早期故障振动信号, 并且与具有相同思路的故障诊断方法和其他先进故障诊断方法进行了对比, 得出了以下结论:

1) 考虑到经典的经验模态分解 (EMD) 方法容易产生模态混叠问题和抗噪性较差的不足, 本文采用了一种改进的鲁棒经验模态分解 (REMD) 算法来进行轴承故障信号

的分解。通过模拟信号实验, 验证了 REMD 可以有效缓解 EMD 的模态混叠效应, 从而提高了分解精度。

2) 利用包络谱峭度作为衡量指标用来选择合适的本征模函数, 从而为下一步故障提取提供可靠前提。

3) 考虑到经典的 Teager 能量算子 (TEO) 极易受到噪声和其他干扰的影响, 本文引入了一种鲁棒性更好的解析能量算子 (AEO)。通过模拟实验验证了 AEO 的抗噪性能要优于经典的 TEO 技术。

4) 将 REMD 和 AEO 结合进行真实电机轴承故障诊断, 实验结果验证了该方法的有效性。并将其与其他故障诊断方法进行对比, 也展示了该方法的优越性。

参考文献:

- [1] 朱传同, 李卓军, 苑得鑫. 融合 GA 优化算法的数字孪生模型在石油旋转机械诊断中的应用 [J]. 计算机测量与控制, 2023, 31 (11): 137-141.
- [2] 张凯, 林谷焯, 罗权. 改进 LSTM 神经网络在电机故障诊断中的应用 [J]. 计算机测量与控制, 2021, 29 (4): 45-50.
- [3] 赵凯辉, 易金武, 刘文昌, 等. 一种永磁同步电机无模型超螺旋快速终端滑模控制方法 [J]. 电力系统保护与控制, 2023, 51 (22): 88-98.
- [4] WANG S B, CAI G, HUANG W, et al. Transient signal analysis based on Levenber-Marquardt method for fault feature extraction of rotating machines [J]. Mechanical Systems and Signal Processing, 2015, 55: 485-520.
- [5] RANDALL R B. Vibration-based diagnostics of gearboxes under variable speed and load conditions [J]. Meccanica, 2016, 51 (12): 3227-3239.
- [6] 李占龙, 刘林霞, 李虹, 等. 基于 VMD-Teager 的非平稳振动时频特性研究 [J]. 兵器装备工程学报, 2021, 42 (1): 150-156.
- [7] ABDELKADER R, KADDOUR A, BENDIABDELLAH A. Rolling bearing fault diagnosis based on an improved denoising method using the complete ensemble empirical mode decomposition and the optimized thresholding operation [J]. IEEE Sensors Journal, IEEE, 2018, 18 (17): 7166-7172.
- [8] 冯爽, 许琦, 罗园庆, 等. 基于经验模态分解谱峭度重构峰值定位的电机噪声溯源方法 [J]. 汽车技术, 2023 (12): 35-39.
- [9] 张能文, 姜天尚, 杨凯铭, 等. 基于 EMD-Hilbert 和主成分降维的电机故障信号特征提取 [J]. 工业控制计算机, 2023, 36 (1): 53-55.
- [10] ALVAREZ F, GRIFFO A. Permanent magnet synchronous machine stator windings fault detection by Hilbert-Huang transform [J]. The Journal of Engineering, 2019, 2019 (17): 3505-3509.
- [11] 荆双喜, 赵行宇, 郭松涛, 等. 异步电机转子断条故障诊断研究 [J]. 河南理工大学学报 (自然科学版), 2016, 35 (2): 224-229.

(下转第 85 页)